

การพยากรณ์ปริมาณน้ำฝนโดยใช้การเรียนรู้เชิงลึกด้วยภาพเรดาร์เสริมด้วยภาพจากดาวเทียม



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต


สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2563

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Precipitation Nowcasting Using Deep Learning on Radar Images Augmented with  
Satellite 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	การพยากรณ์ปริมาณน้ำฝนโดยใช้การเรียนรู้เชิงลึกด้วยภาพเรดาร์เสริมด้วยภาพจากดาวเทียม
โดย	นายวิคม ไตศิริ
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล

---

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

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

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ  
(รองศาสตราจารย์ ดร.ธนรัตน์ ชลิตาพงศ์)

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

..... กรรมการภายนอกมหาวิทยาลัย  
(ดร.ภาณุ เศรษฐฐเสถียร)

CHULALONGKORN UNIVERSITY

วิกรม โตศิริ : การพยากรณ์ปริมาณน้ำฝนโดยใช้การเรียนรู้เชิงลึกด้วยภาพเรดาร์เสริมด้วย  
ภาพจากดาวเทียม. ( Precipitation Nowcasting Using Deep Learning on Radar  
Images Augmented with Satellite Images ) อ.ที่ปรึกษาหลัก : ผศ. ดร.พีรพล เวที  
กุล

การทำนายปริมาณน้ำฝนระยะสั้นด้วยข้อมูลปริมาณน้ำฝนจากเรดาร์ตรวจอากาศ  
ภาคพื้นดินและแบบจำลองการเรียนรู้เชิงลึกถือได้ว่าเป็นกระบวนการใหม่ในการทำนายปริมาณ  
น้ำฝนระยะสั้น อย่างไรก็ตาม เนื่องจากข้อจำกัดของระยะทำการของเรดาร์ตรวจอากาศภาคพื้นดิน  
นั้นมีระยะทำการที่จำกัด งานวิจัยนี้จึงนำเสนอวิธีการปรับปรุงการทำนายปริมาณน้ำฝนระยะสั้น  
ด้วยแบบจำลองการเรียนรู้เชิงลึก U-NET ด้วยการผนวกข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จาก  
ดาวเทียม เข้าด้วยกันกับข้อมูลปริมาณน้ำฝนที่ได้จากข้อมูลจากเรดาร์ตรวจอากาศภาคพื้นดิน  
ประเภท Type C Doppler งานวิจัยนี้ได้เสนอว่า วิธีการที่ถูกเสนอในงานวิจัยนี้สามารถปรับปรุง  
ผลลัพธ์การทำนายปริมาณน้ำฝนได้ดีขึ้นในหลายชุดข้อมูลทดสอบ เช่น ชุดข้อมูลพายุไต้ฝุ่น เป็นต้น



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์  
ปีการศึกษา 2563

ลายมือชื่อนิสิต .....

ลายมือชื่อ อ.ที่ปรึกษาหลัก .....

# # 6270260721 : MAJOR COMPUTER SCIENCE

KEYWORD: Machine learning, Machine learning approaches, Neural networks,  
Precipitation Nowcasting, U-NET, deep learning, data-fusion,  
convolutional neural network (CNN)

Wikom Tosiri : Precipitation Nowcasting Using Deep Learning on Radar  
Images Augmented with Satellite Images . Advisor: Asst. Prof. Dr.  
PEERAPON VATEEKUL

Precipitation nowcasting based on deep learning methods using ground-based weather radars data and satellite-based precipitation data will open a new avenue for weather prediction. However, it is confined to areas where nowcasting can be done using ground-based weather radars. By combining precipitation data from with precipitation data from Type C Doppler radars that detect precipitation in the atmosphere, we propose an improved deep learning precipitation prediction. It has been demonstrated that our proposed method can improve the efficiency of precipitation nowcasting with U-NET model by the proposed deep learning technique in many extreme weather cases, i.e., typhoons.



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY

Field of Study: Computer Science

Student's Signature .....

Academic Year: 2020

Advisor's Signature .....

## กิตติกรรมประกาศ

ข้าพเจ้าขอขอบพระคุณ ผศ.ดร.พีรพล เวทีกุล อาจารย์ที่ปรึกษา และขอขอบพระคุณ รศ. ดร. ธนารัตน์ ชลิตาพงศ์, ดร. ภาณุ เศรษฐฐเสถียร ที่เป็นประธานและกรรมการในการสอบวิทยานิพนธ์ของข้าพเจ้า ขอขอบพระคุณอย่างสูง

ขอขอบคุณ ดร.สยาม ลววิโรจน์วงศ์, ดร.ธีรพงศ์ ปานบุญยืน และ ดร.ภาณุ เศรษฐฐเสถียร ที่ให้ความอนุเคราะห์ให้การให้คำแนะนำต่างๆที่มีประโยชน์อย่างยิ่งในงานวิจัยชิ้นนี้

ขอขอบคุณบริษัท Weathernews จำกัด ที่สนับสนุนชุดข้อมูลสำหรับงานวิจัยนี้

ขอขอบคุณ เพื่อนร่วมรุ่นนิสิตปริญญาโทและรุ่นพี่นิสิตปริญญาเอกทุกท่านที่ให้ความช่วยเหลือแก่ข้าพเจ้า ทั้งที่อยู่ในแลปเดียวกันกับข้าพเจ้าก็ดี ไม่ได้อยู่ในแลปเดียวกันกับข้าพเจ้าก็ดี ที่ช่วยให้คำแนะนำในการเรียนตลอดสองปีที่ผ่านมา ข้าพเจ้าเชื่ออย่างยิ่งว่า ข้าพเจ้าคงไม่สามารถศึกษาเล่าเรียนจนจบได้ หากไม่มีทุกท่านเหล่านี้

ขอขอบพระคุณ มารดา แพน และสมาชิกในครอบครัวทุกท่านของข้าพเจ้าที่ได้ให้กำลังใจและเคียงข้างให้ข้าพเจ้าตั้งใจให้ตั้งใจศึกษาเล่าเรียน ซึ่งข้าพเจ้าเชื่ออีกเช่นกันว่า หากไม่มีบุคคลเหล่านี้แล้ว ข้าพเจ้าคงถอดใจเลิกศึกษาเล่าเรียนไปเสียก่อน

งานวิจัยชิ้นนี้ จะไม่มีทางสำเร็จขึ้นได้ หากปราศจากทุกๆท่าน ข้าพเจ้าขอขอบพระคุณอีกครั้ง



วิคม โตศิริ

## สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ณ
สารบัญรูป.....	ณ
บทที่ 1 บทนำ .....	1
1.1 ที่มาและความสำคัญของปัญหา .....	1
1.2 วัตถุประสงค์ของงานวิจัย .....	3
1.3 ขอบเขตของการวิจัย.....	3
1.4 ประโยชน์ที่ได้รับ .....	4
1.5 วิธีการดำเนินงานวิจัย.....	4
1.6 ผลงานตีพิมพ์จากงานวิจัย.....	5
1.7 แผนภูมิแกนต์ (Gantt chart) .....	6
บทที่ 2 แนวคิดและทฤษฎีที่เกี่ยวข้อง .....	7
2.1 การพยากรณ์ปริมาณน้ำฝนในระยะสั้น (Precipitation Nowcasting) .....	7
2.2 การทำนายเฟรมวิดีโอ (Video Frame Prediction) .....	8
2.3 การประเมินผลประสิทธิภาพ (Performance Evaluation) .....	8
2.4 ข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียม .....	9
2.5 ข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน (C-Band Doppler Radars) .....	11
2.6 การทำให้ข้อมูลปกติ (Normalization).....	12

บทที่ 3 เอกสารและงานวิจัยที่เกี่ยวข้อง .....	13
3.1 งานวิจัยที่เกี่ยวกับการใช้การเรียนรู้เชิงลึกทำนายภาพวิดีโอ (Video Prediction Deep Learning) .....	13
3.1.1 แบบจำลอง U-NET .....	13
3.1.2 หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (Convolutional Long short-term memory) .....	14
3.2 งานวิจัยที่เกี่ยวข้องกับการแก้ปัญหาจำนวนอัตราภาพของข้อมูล .....	15
3.2.1 การประมาณค่าในช่วงของเฟรมภาพวิดีโอที่มีการรับรู้เชิงลึก (Depth-Aware Video Frame Interpolation) .....	15
3.3 งานวิจัยที่เกี่ยวข้องกับการปรับค่าอคติ (Bias Correction) .....	16
3.4 งานวิจัยที่เกี่ยวข้องกับการผสานข้อมูลในเชิงพื้นที่และเวลา (Spatiotemporal data fusion) .....	17
บทที่ 4 แนวคิดและวิธีการดำเนินงาน .....	19
4.1 การรวบรวมชุดข้อมูล .....	19
4.1.1 ชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดิน .....	19
4.1.2 ชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียม .....	20
4.1.3 ชุดข้อมูลปริมาณน้ำฝนสำหรับทดสอบประสิทธิภาพการทำงาน .....	21
4.2 การประมวลผลข้อมูลก่อน (Data Preprocessing) .....	24
4.2.1 การแปลงข้อมูลเป็นนมพายอาเรีย .....	24
4.2.2 การลดทอนข้อมูล (Data Reduction) .....	24
4.2.3 การเพิ่มจำนวนอัตราภาพของข้อมูล .....	26
4.2.4 การขยายขนาดภาพ (Image Upsampling) .....	27
4.2.5 การผสานข้อมูลเชิงพื้นที่และเวลา (Spatial and Temporal Data Fusion) .....	27
4.2.6 การสอบเทียบข้อมูล (Data Calibration) .....	30
4.3 แนวทางการฝึกสอนแบบจำลองการเรียนรู้เชิงลึก .....	33



4.4 ชุดข้อมูลที่ใช้ฝึกแบบจำลองการเรียนรู้เชิงลึก .....	36
บทที่ 5 บทสรุปของงานวิจัยและอภิปรายผลการวิจัย.....	38
5.1 การแบ่งชุดข้อมูลในการฝึกสอนแบบจำลอง .....	38
5.3 การประเมินประสิทธิภาพการทำนาย (Performance Evaluation).....	39
5.4 ผลการทดลอง .....	39
5.4.1 ผลการทดลองจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก แบบจำลองการเรียนรู้.....	41
5.4.2 ผลการทดลองจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักในการฝึกแบบจำลองด้วยวิธี Balanced Custom Weights .....	59
5.5 สรุปผลลัพธ์ประสิทธิภาพการทำนายปริมาณน้ำฝนที่ได้จากการทดลองปรับค่าน้ำหนักค่าความ สูญเสียในการฝึกแบบจำลองการเรียนรู้เชิงลึกในรูปแบบต่างๆ และ ชุดข้อมูลฝึกสอนรูปแบบ ต่างๆ .....	72
5.5.1 สรุปผลลัพธ์จากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้.....	72
5.5.2 สรุปผลลัพธ์จากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความผิดพลาดในการฝึกแบบจำลอง การเรียนรู้.....	75
บทที่ 6 สรุปผลการวิจัยและแนวทางการวิจัยในขั้นถัดไป .....	79
6.1 สรุปผลการวิจัย.....	79
6.2 แนวทางการวิจัยถัดไป.....	79
ภาคผนวก.....	80
บรรณานุกรม.....	104
ประวัติผู้เขียน.....	106

## สารบัญตาราง

	หน้า
ตารางที่ 1 คุณลักษณะของข้อมูล GsMAP_NRT .....	10
ตารางที่ 2 คุณลักษณะของข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน .....	11
ตารางที่ 3 คุณสมบัติของชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินที่จะนำมาใช้ในการผนวกข้อมูล .....	20
ตารางที่ 4 ค่าสถิติของระดับน้ำฝนในชุดข้อมูลจากเรดาร์ .....	20
ตารางที่ 5 คุณสมบัติของชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมก่อนที่จะนำมาใช้ในกระบวนการลดทอนข้อมูล การเพิ่มจำนวนอันตรายภาคและผนวกข้อมูล .....	21
ตารางที่ 6 ชุดข้อมูลที่ใช้ประเมินประสิทธิภาพการทำนาย .....	23
ตารางที่ 7 ค่าสถิติพื้นที่ที่ให้ความสนใจของชุดข้อมูลทดสอบเทียบกับขนาดความละเอียดของข้อมูลทั้งหมด .....	23
ตารางที่ 8 ค่าสถิติปริมาณน้ำฝนของชุดข้อมูลทดสอบแต่ละชุดเทียบกับจำนวนข้อมูลทั้งหมด .....	23
ตารางที่ 9 เปรียบเทียบพิกัดพิกัดภูมิศาสตร์ระหว่างสองชุดข้อมูลก่อนหน้าการลดข้อมูล .....	25
ตารางที่ 10 การตั้งค่าไฮเปอร์พารามิเตอร์สำหรับการทดลองบนชุดข้อมูลต่างๆ .....	34
ตารางที่ 11 จำนวนชุดข้อมูลในข้อมูลการสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ .....	38
ตารางที่ 12 จำนวนข้อมูลขาเข้าตามจำนวนขั้นตอนเวลาและจำนวนข้อมูลขาออกตามจำนวนขั้นตอนเวลาที่ใช้ในชุดข้อมูลต่างๆ .....	39
ตารางที่ 13 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 1 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ .....	43
ตารางที่ 14 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 2 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ .....	45
ตารางที่ 15 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ .....	47











ตารางที่ 64 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ..... 99

ตารางที่ 65 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 4 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ..... 100

ตารางที่ 66 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 5 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ..... 101

ตารางที่ 67 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 6 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ..... 102

ตารางที่ 68 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 7 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ..... 103



## สารบัญรูป

	หน้า
รูปที่ 1 ตัวอย่างปัญหาข้อมูลที่ขาดหายไปในช่วงข้อมูลที่ได้จากรadarภาคพื้นดิน .....	2
รูปที่ 2 ตัวอย่างภาพของข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม.....	3
รูปที่ 3 แผนที่ความครอบคลุมของข้อมูล (Data Coverage Map).....	10
รูปที่ 4 แบบจำลอง U-NET [1] .....	14
รูปที่ 5 ภาพตัวอย่างสถาปัตยกรรมภายในของแบบจำลองการเรียนรู้เชิงลึก Depth-Aware Video Frame Interpolation (DAIN) [10].....	16
รูปที่ 6 รูปสถาปัตยกรรมของชั้นเครือข่ายการสกัดบริบท (Context Extraction Network) .....	16
รูปที่ 7 ภาพเปรียบเทียบผลการผนวกข้อมูลระหว่างข้อมูลที่ได้จากรadarภาคพื้นดินและจากดาวเทียมด้วยกระบวนการต่างๆ[12].....	18
รูปที่ 8 ขั้นตอนการดำเนินงาน .....	19
รูปที่ 9 ตัวอย่างข้อมูลปริมาณน้ำฝน GsMAP ก่อนผ่านขั้นตอนการลดทอนข้อมูล .....	25
รูปที่ 10 ตัวอย่างข้อมูลปริมาณน้ำฝน GsMAP หลังผ่านขั้นตอนการลดทอนข้อมูล.....	26
รูปที่ 11 ตัวอย่างผลลัพธ์การใช้แบบจำลอง DAIN ในการสังเคราะห์เฟรมภาพข้อมูลปริมาณน้ำฝน GsMAP ณ วันที่ 1 เดือนมิถุนายน 2561.....	27
รูปที่ 12 ตัวอย่างภาพของข้อมูลปริมาณน้ำฝนที่ได้จากรadarภาคพื้นดิน และข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมและข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมที่ได้จากการสังเคราะห์ในช่วงของเฟรมภาพวิดีโอด้วยแบบจำลอง DAIN ในวันที่ 1 มิถุนายน 2561 ระหว่างเวลา 00:00 น. ถึง 01:00 น.....	28
รูปที่ 13 ข้อมูลปริมาณน้ำฝนจากรadarภาคพื้นดินโดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง.....	29
รูปที่ 14 ข้อมูลปริมาณน้ำฝนจาก GsMAP โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง .....	29
รูปที่ 15 ข้อมูลปริมาณน้ำฝนที่ได้จากการผสานข้อมูลเชิงพื้นที่โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง..	30
รูปที่ 16 ตัวอย่างไฟล์หน้ากาก (Mask) ที่ใช้ในการระบุขอบเขตระยะทำการของเรดาร์ .....	30

รูปที่ 17 ตัวอย่างข้อมูลปริมาณน้ำฝนจากเรดาร์และข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมที่สามารถนำไปใช้ในการสอบเทียบข้อมูลได้.....	31
รูปที่ 18 ตัวอย่างข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมที่ยังไม่ผ่านกระบวนการ Mean Bias Correction โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง .....	32
รูปที่ 19 ตัวอย่างข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมที่ผ่านกระบวนการ Mean Bias Correction โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง .....	32
รูปที่ 20 ตัวอย่างข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมที่ผ่านกระบวนการ Multi Class Mean Bias Correction โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง.....	33
รูปที่ 21 ภาพรวมขั้นตอนแนวทางการฝึกแบบจำลองการเรียนรู้เชิงลึก.....	37
รูปที่ 22 กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 1 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	44
รูปที่ 23 กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 2 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	46
รูปที่ 24-กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	48
รูปที่ 25 กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 4 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	50
รูปที่ 26 กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 5 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	52
รูปที่ 27 กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 6 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	54
รูปที่ 28 กราฟเส้นเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 7 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI.....	56
รูปที่ 29 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยชุดข้อมูลในรูปแบบต่างๆ โดยไม่มีการแก้ไขค่าน้ำหนักเองในแบบจำลองการเรียนรู้เชิงลึกจากชุดข้อมูลทดสอบที่ 1 .....	57
รูปที่ 30 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยชุดข้อมูลในรูปแบบต่างๆ โดยไม่มีการแก้ไขค่าน้ำหนักเองในแบบจำลองการเรียนรู้เชิงลึกจากชุดข้อมูลทดสอบที่ 2 .....	58

รูปที่ 31 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยการฝึกด้วยชุดข้อมูลในรูปแบบต่างๆ โดยมีการแก้ไข  
 ค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced  
 Custom Weights จากชุดข้อมูลทดสอบประสิทธิภาพที่ 1 ..... 70

รูปที่ 32 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยการฝึกด้วยชุดข้อมูลในรูปแบบต่างๆ โดยมีการแก้ไข  
 ค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced  
 Custom Weights จากชุดข้อมูลทดสอบประสิทธิภาพที่ 2 ..... 71



# บทที่ 1

## บทนำ


### 1.1 ที่มาและความสำคัญของปัญหา

ในปัจจุบัน การทำนายปริมาณน้ำฝนที่ตกมา โดยเฉพาะปริมาณน้ำฝนที่เกิดจากพายุรูปแบบต่าง ๆ เป็นสิ่งที่มีความจำเป็นต่อดำเนินชีวิตของประชาชนทั่วไป รวมไปถึงการออกแบบการป้องกันและการบรรเทาอุทกภัยที่เกิดจากพายุฝน เพื่อให้หน่วยงานทั้งในภาครัฐและเอกชนที่เกี่ยวข้อง สามารถประเมินสถานการณ์ ในการรับมือกับพื้นที่ฝนตกที่อาจจะขึ้นได้ แม้ในปัจจุบันจะมี C Doppler Radar ซึ่งเป็นเรดาร์ภาคพื้นดินที่สามารถใช้ตรวจจับปริมาณน้ำฝนในชั้นบรรยากาศได้ แต่ก็ยังมีข้อจำกัดในพื้นที่ที่เรดาร์ภาคพื้นดินไม่สามารถตรวจจับปริมาณน้ำฝนในชั้นบรรยากาศได้ เช่นพื้นที่ในทางทะเล หรือพื้นที่ภาคพื้นดินที่อยู่นอกระยะของเรดาร์ภาคพื้นดินจะสามารถตรวจจับปริมาณน้ำฝนได้และเพื่อเสริมประสิทธิภาพในการทำนายปริมาณน้ำฝนจากวิธีการการเรียนรู้เชิงลึก เราจึงเสนอการทำนายปริมาณน้ำฝน โดยเพิ่มแหล่งข้อมูลปริมาณน้ำฝนจากแหล่งอื่น ๆ นำมาผนวกเข้ากับข้อมูลปริมาณน้ำฝนจากแหล่งเดิมที่มีอยู่แล้วอย่าง ข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินจากบริษัท WeatherNews จำกัด ที่ได้ข้อมูลปริมาณน้ำฝนจากเรดาร์ตรวจวัดปริมาณน้ำฝนประเภท C Doppler Radar ที่ใช้ตรวจจับปริมาณน้ำฝนจากภาคพื้นดินมาผนวกเข้ากับ ข้อมูลปริมาณน้ำฝนที่ได้จากชุดข้อมูล JAXA Global Rainfall Watch (GSMAP) ซึ่งเป็นชุดข้อมูลปริมาณน้ำฝนที่วิเคราะห์จากข้อมูลที่ได้จากดาวเทียมที่เป็นผลิตภัณฑ์จาก องค์การสำรวจอวกาศญี่ปุ่น (Japan Aerospace Exploration Agency) ที่มีระยะตรวจจับปริมาณน้ำฝนกว้างขวางกว่าข้อมูลของบริษัท WeatherNews จำกัด ผนวกเข้าไปด้วยกัน

การทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้น (Precipitation Nowcasting) ที่ทำนายปริมาณปริมาณน้ำฝนล่วงหน้าในช่วงเวลาไม่เกิน 2 ชั่วโมงนั้นเป็นสิ่งที่มีความท้าทายเป็นอย่างยิ่ง ในอดีตนั้น กระบวนการพยายามทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้น ด้วยกระบวนการการทำนายโดยใช้แบบจำลองการทำนายสภาพอากาศเชิงตัวเลขแบบดั้งเดิม (Numerical Weather Prediction) มีข้อจำกัดในการทำนายเช่นจำเป็นต้องทำนายในพื้นที่เฉพาะเจาะจงในพื้นที่หนึ่ง รวมไปถึงการจำเป็นต้องมีข้อมูลเชิงกายภาพในพื้นที่นั้น ๆ ด้วย นอกเหนือจากนั้นแล้ว การทำนายด้วยแบบจำลองการทำนายสภาพอากาศเชิงตัวเลขแบบดั้งเดิม จำเป็นต้องมีการตั้งค่าคงที่หรือค่าคงตัวเฉพาะการณ (Parameter) จำนวนมากที่มีความสลับซับซ้อนก่อนที่จะเริ่มทำการทำนายได้ รวมไปถึง


การจำเป็นต้องมีทรัพยากรของระบบที่จำเป็นต้องใช้ในการเริ่มการทำนายที่สูง ดังนั้นการทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้นด้วยเทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เป็นส่วนหนึ่งของศาสตร์การเรียนรู้ด้วยเครื่อง (Machine Learning) ที่เป็นแพร่หลายและประสบความสำเร็จในการแก้ปัญหาการทำนายโจทย์การเคลื่อนไหว (Motion Prediction) หรือการทำนายภาพวิดีโอในอนาคต (Future Video Frame Prediction) จึงเป็นอีกหนึ่งวิธีการตัวเลือกที่สามารถนำมาใช้ในการทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้นได้

อย่างไรก็ตาม การใช้ข้อมูลปริมาณน้ำฝนในชั้นบรรยากาศที่ได้จากเรดาร์ภาคพื้นดินเป็นหลักมักประสบปัญหาข้อมูลที่ขาดหายไปในช่วงข้อมูลเนื่องจากระยะเวลาทำการของเรดาร์ที่ไม่สามารถครอบคลุมได้เพียงพอและเรื่องสถานที่ตั้งของสถานีเรดาร์ ที่มีความสามารถในการปรับขนาดการตรวจวัดได้ต่ำรวมไปถึงราคาในการติดตั้งที่มีราคาสูงในการติดตั้งเพิ่มเติมนั้นต้องมีการทำข้อตกลงยินยอมกับหน่วยงานรัฐและประชาชนในท้องถิ่นซึ่งอาจทำให้ไม่สามารถติดตั้งสถานีตรวจวัดปริมาณน้ำฝนด้วยเรดาร์ภาคพื้นดินได้หรือต้องมีการฝึกอบรมเจ้าหน้าที่และบุคลากรเพิ่มเติม ซึ่งส่งผลถึงค่าใช้จ่ายที่สูงขึ้นอย่างเลี่ยงไม่ได้ ตามรูปที่ 1



รูปที่ 1 ตัวอย่างปัญหาข้อมูลที่ขาดหายไปในช่วงข้อมูลที่ได้จากเรดาร์ภาคพื้นดิน

ทั้งนี้เพื่อชดเชยข้อมูลปริมาณน้ำฝนที่ขาดหายไปจากการตรวจวัดปริมาณน้ำฝนด้วยเรดาร์ภาคพื้นดินและเพื่อเสริมประสิทธิภาพการทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้น งานวิจัยนี้จึงมุ่งเน้นไปที่จะพัฒนาการผนวกข้อมูลปริมาณน้ำฝนที่ได้จากวิเคราะห์จากชุดข้อมูลภาพถ่ายดาวเทียมตามรูปที่ 2 เขารวมกับชุดข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน เพื่อเพิ่มข้อมูลปริมาณน้ำฝนโดยรวมทั้งหมด โดยมีจุดมุ่งหมายเพื่อเสริมประสิทธิภาพการทำปริมาณน้ำฝนล่วงหน้าในระยะสั้น ที่มีตัวบ่งชี้ประสิทธิภาพหลักของการทำนายคือ ค่าดัชนีความสำเร็จสำคัญ (Critical Success Index) และ ค่าดัชนีความสำเร็จสำคัญแบบหลายระดับ (Multi-Class Critical Success Index)



รูปที่ 2 ตัวอย่างภาพของข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม

## 1.2 วัตถุประสงค์ของงานวิจัย

งานวิจัยนี้มีจุดประสงค์เพื่อเสนอการปรับปรุงประสิทธิภาพการทำนายปริมาณน้ำฝนในระยะสั้นด้วยการผสมผสานข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ตรวจวัดปริมาณน้ำฝนภาคพื้นดินและข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากภาพถ่ายดาวเทียม เพื่อเสริมประสิทธิภาพการทำนายด้วยแบบจำลองการเรียนรู้เชิงลึกที่มีอยู่แล้วให้สูงขึ้น กว่าการทำงานด้วยชุดข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินอย่างเดียว

## 1.3 ขอบเขตของการวิจัย

- ใช้ข้อมูลปริมาณน้ำฝนจากชุดข้อมูลที่ได้จากเรดาร์ภาคพื้นดินของประเทศญี่ปุ่นของบริษัท WeatherNews จำกัด มีอัตราภาคจาก 10 นาที
- ใช้ข้อมูลปริมาณน้ำฝนจากชุดข้อมูลที่ได้จากการวิเคราะห์จากภาพถ่ายดาวเทียม (GsMAP) มีอัตราภาคเป็น 1 ชั่วโมง
- ใช้แบบจำลองการเรียนรู้เชิงลึก (Deep Learning Model) ในการทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้น
- มีเป้าหมายที่จะทำนายปริมาณน้ำฝนระยะสั้นในอัตราภาคเป็น 10 นาที
- เปรียบเทียบประสิทธิภาพการทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้น โดยเปรียบเทียบผลการทำงานก่อนและหลังการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยการผนวกชุดข้อมูลจากทั้งสองแหล่ง กับชุดข้อมูลที่ได้จากบริษัท WeatherNews จำกัด

- มีตัวบ่งชี้ประสิทธิภาพการทำนายคือ ค่าดัชนีความสำเร็จสำคัญ (Critical Success Index) ค่าดัชนีความสำเร็จสำคัญแบบหลายระดับ (Multi-Class Critical Success Index) และ ค่ารากของค่าเฉลี่ยความผิดพลาดกำลังสอง (RMSE หรือ Root Mean Square Error)
- เปรียบเทียบประสิทธิภาพการทำนายปริมาณน้ำฝนล่วงหน้าในระยะสั้น โดยเปรียบเทียบผลการทำนายระหว่างแบบจำลองการเรียนรู้เชิงลึกที่มีการฝึกสอนด้วยการแก้ไขค่าน้ำหนักในแบบจำลองเอง (Custom Weight) และแบบจำลองการเรียนรู้เชิงลึกที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองเองในการฝึกสอน

#### 1.4 ประโยชน์ที่ได้รับ

สามารถเสริมประสิทธิภาพการทำนายปริมาณน้ำฝนในระยะสั้นโดยใช้ชุดข้อมูลปริมาณน้ำฝนที่มีการผนวกชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินและชุดข้อมูลน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียมเข้าไปด้วยกัน ซึ่งจะให้ผลการทำนายด้วยวิธีการที่ใช้การเรียนรู้เชิงลึกที่มีความแม่นยำมากกว่าการใช้ชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินอย่างเดียว

#### 1.5 วิธีการดำเนินงานวิจัย

1. ศึกษางานวิจัยที่เกี่ยวข้องกับหัวข้อวิจัย เช่น การเรียนรู้เชิงลึก การเรียนรู้ด้วยเครื่อง การทำนายปริมาณน้ำฝนระยะสั้น การผนวกข้อมูลจากหลายแหล่ง กระบวนการการประเมินประสิทธิภาพการทำนาย
2. รวบรวมชุดข้อมูลที่ใช้ฝึกและใช้เป็นชุดข้อมูลทดสอบที่ได้รับจากบริษัท WeatherNews จำกัด
3. รวบรวมชุดข้อมูลปริมาณน้ำฝนที่จะใช้ทำการผนวกข้อมูลจาก องค์การสำรวจอวกาศ ญี่ปุ่น
4. ศึกษาการใช้งานเครื่องมือการพัฒนาแบบจำลองการเรียนรู้เชิงลึกจากภาษาไพธอน (Python) ที่เรียกว่า ไพทอช (PyTorch) [1]
5. ศึกษาการใช้งานเครื่องมือการคำนวณทางคณิตศาสตร์จากภาษาไพธอนที่เรียกว่า umpy (NumPy) [2]
6. ดำเนินการพัฒนาชุดคำสั่ง (Code) ที่ใช้สำหรับการทดลอง การผนวกข้อมูล ทำการทดลองและบันทึกผลการทดลอง
7. จัดทำงานวิจัยและตีพิมพ์เพื่อนำเสนอผลงานทางวิชาการ

## 8. จัดทำวิทยานิพนธ์

### 1.6 ผลงานตีพิมพ์จากงานวิจัย

งานวิจัยจากวิทยานิพนธ์ฉบับนี้ได้รับการตีพิมพ์เป็นบทความทางวิชาการ

Wikom Tosiri, Nutnaree Kleawsirikul, Patamawadee Leepaisomboon, Natnapat

Gaviphatt, Hidetomo Sakaino, and Peerapon Vateekul. 2021. Precipitation Nowcasting Using Deep Learning on Radar Data Augmented with Satellite Data. In The 12th International Conference on Advances in Information Technology (IAIT2021), June 29–July 01, 2021, Bangkok, Thailand. ACM, New York, NY, USA





### 1.7 แผนภูมิแกนต์ (Gantt chart)

งาน	1/2563		2/2563		1/2564		2/2564	
	เทอมต้น	เทอมปลาย	เทอมต้น	เทอมปลาย	เทอมต้น	เทอมปลาย	เทอมต้น	เทอมปลาย
เลือกหัวข้อวิจัย								
ศึกษางานวิจัยที่เกี่ยวข้อง								
รวบรวมข้อมูล								
ศึกษาข้อมูลที่ได้รับ								
จัดเตรียมข้อมูลที่ได้รับ								
จัดเตรียมวิธีการมาตรฐาน								
ออกแบบและวิธีการที่เสนอ								
วิเคราะห์และสรุปผลการทดลอง								
จัดทำวิทยานิพนธ์								
เสนอผลงานวิจัย								

## บทที่ 2

### แนวคิดและทฤษฎีที่เกี่ยวข้อง

#### 2.1 การพยากรณ์ปริมาณน้ำฝนในระยะสั้น (Precipitation Nowcasting)

การทำนายปริมาณน้ำฝนในระยะสั้นเป็นหนึ่งในปัญหาของกระบวนการพยากรณ์อากาศที่มีมานาน สภาพอากาศโดยเฉพาะปริมาณน้ำฝนนั้นมีผลต่อการดำรงชีวิตประจำวันของประชาชนทั้งในแง่เศรษฐกิจและสังคม เช่น ข้อมูลปริมาณน้ำฝนที่ได้จากการทำนายปริมาณน้ำฝนในระยะสั้นนั้นสามารถนำไปแจ้งแก่ประชาชน เพื่อให้ประชาชนสามารถวางแผนการเดินทางล่วงหน้าได้ หรือแม้แต่สามารถทำให้ประชาชนสามารถอพยพล่วงหน้าได้ทันท่วงที ในกรณีที่ปริมาณน้ำฝนที่ทำนายได้นั้นสูงมากจนอาจเกิดอุทกภัยได้

หนึ่งในวิธีการแบบดั้งเดิมในการทำนายปริมาณน้ำฝนระยะสั้นคือวิธีการการใช้ แบบจำลองการทำนายสภาพอากาศเชิงตัวเลข (Numerical Weather Prediction) ซึ่งจะใช้ข้อมูลจากสภาพอากาศในช่วงเวลาปัจจุบันและทำการประมวลผลด้วยแบบจำลองทางคอมพิวเตอร์เพื่อทำนายสภาพอากาศในอนาคตต่อไป โดยนำข้อมูลจากสภาพอากาศในช่วงเวลาปัจจุบันมาทำให้เป็นข้อมูลขาเข้า (Input) แล้วนำเข้าไปยัง แบบจำลองทางคอมพิวเตอร์เชิงตัวเลข (Numerical Computer Model) ผ่านกระบวนการผนวกข้อมูลทางกายภาพที่ได้จากการตรวจวัด (Data Assimilation) เพื่อผลิตข้อมูลขาออก (Output) เป็นข้อมูลปริมาณน้ำฝน, อุณหภูมิ หรือข้อมูลทางอุตุนิยมวิทยาอื่น ๆ ซึ่งในปัจจุบันการใช้แบบจำลองการทำนายสภาพอากาศเชิงตัวเลขนั้นมีความคลาดเคลื่อนอยู่ เพราะปรากฏการณ์ธรรมชาติที่เกิดขึ้นเป็นปรากฏการณ์ที่มีความซับซ้อน ต้องใช้ทรัพยากรข้อมูลทางกายภาพมาก ต้องอาศัยทรัพยากรของระบบประมวลผลที่มีสมรรถนะสูง อีกปัจจัยที่ทำให้มีผลต่อ การทำนายสภาพอากาศคือ คุณภาพของข้อมูลทางกายภาพที่ได้จากการตรวจวัดที่ถูกใช้เป็นข้อมูลขาเข้าเข้าสู่แบบจำลองการทำนายสภาพอากาศเชิงตัวเลข

ซึ่งในปัจจุบันนี้ ได้มีการวิจัยและพัฒนาการเรียนรู้ด้วยเครื่อง (Machine Learning) ที่สูงขึ้นเป็นอย่างมาก รวมถึงการเรียนรู้เชิงลึก (Deep Learning) ที่สามารถนำไปใช้ในการแก้ปัญหาหลากหลายแขนงได้ หนึ่งในเรื่องที่มีการเรียนรู้เชิงลึกสามารถนำไปใช้ได้คือ เรื่องคอมพิวเตอร์วิทัศน์ (Computer Vision) ที่สามารถนำมาประยุกต์ใช้กับโจทย์ การทำนายปริมาณน้ำฝนระยะสั้น

ได้<sup>1</sup> เช่นแบบจำลอง UNET [3] ที่เสนอโดย Ronneberger, O., P. Fischer และ T. Brox. แบบจำลอง Convolutional LSTM Network [4] ที่เสนอโดย Shi, X., et al. แบบจำลอง Memory to Memory [5] ที่เสนอโดย Wang, Y., et al. และ Trajectory GRU [6] ที่เสนอโดย Shi, X., et al. เป็นต้น

## 2.2 การทำนายเฟรมวิดีโอ (Video Frame Prediction)

การทำนายปริมาณน้ำฝนระยะสั้นสามารถจัดเป็นส่วนหนึ่งของปัญหาการทำนายเฟรมวิดีโอด้วยการเรียนรู้เชิงลึกได้ เนื่องจากข้อมูลปริมาณน้ำฝนที่มีอยู่นั้นมีลักษณะของความเป็นอนุกรมเวลา (Time Series data) ซึ่งเป็นข้อมูลที่มีการรวบรวมตามระยะเวลาอย่างต่อเนื่อง และมีลักษณะเป็นข้อมูลเชิงคอมพิวเตอร์วิทัศน์ (Computer Vision) กล่าวคือ ข้อมูลปริมาณน้ำฝนนั้นสามารถนำเสนอในรูปแบบของข้อมูลรูปภาพ 2 มิติได้ ซึ่งมีลักษณะคล้ายคลึงกับชุดข้อมูลวิทัศน์การเคลื่อนที่ของมนุษย์ หรือชุดข้อมูลวิทัศน์การเคลื่อนที่ของกลุ่มก้อนเมฆ

## 2.3 การประเมินผลประสิทธิภาพ (Performance Evaluation)

การประเมินผลประสิทธิภาพของการทำนายปริมาณน้ำฝนระยะสั้นจะใช้ค่าดัชนีความสำเร็จสำคัญ (Critical Success Index) [7] หรือในชื่อหนึ่งคือ Threat score (TS) ค่าดัชนีความสำเร็จสำคัญแบบหลายระดับ (Multi-class Critical Success Index) ซึ่งมีสมการที่ใช้คำนวณได้ดังสมการที่ (1)

$$CSI = \frac{Hit}{Hit + Miss + False} * 100 \quad (1)$$

โดยกำหนดให้

- Hit คือ จำนวนการทำนายทั้งหมดที่ถูกต้อง กล่าวคือจำนวนการทำนายที่ทำนายได้คลาสที่ถูกต้องตามคลาสในผลเฉลย (True Positive)
- Miss คือ จำนวนการทำนายทั้งหมดที่คลาดเคลื่อนเป็นคลาสอื่นแต่ผลลัพธ์ในผลเฉลยคือคลาสนั้น ๆ (False Negative)
- False คือ จำนวนการทำนายทั้งหมดที่คลาดเคลื่อนเป็นคลาสอื่น ๆ แต่ผลลัพธ์ในผลเฉลยคือคลาสอื่น ๆ (False Positive)

<sup>1</sup> อ้างอิงจาก <https://ai.googleblog.com/2020/01/using-machine-learning-to-nowcast.html>

- เส้นแบ่ง (Threshold) นั้นถูกกำหนดไว้ที่ 1 มิลลิเมตรต่อชั่วโมง

สำหรับค่าดัชนีความสำเร็จแบบหลายระดับ จะใช้บ่งบอกประสิทธิภาพของการทำนาย สำหรับปริมาณน้ำฝนที่ต่างกัน โดยมีการกำหนดเส้นแบ่ง อีกสามคลาส คือ ที่มีเส้นแบ่งที่ 1 มิลลิเมตร (Class 1) ต่อชั่วโมง 10 มิลลิเมตรต่อชั่วโมง (Class 2) และ 30 มิลลิเมตรต่อชั่วโมง (Class 3)

อีกวิธีที่งานวิจัยนี้ได้ใช้ในการประเมินประสิทธิภาพการทำนายคือค่าจากรากของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (RMSE หรือ Root Mean Squared Error) ดังสมการที่ (2)

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

โดยที่  $N$  แทนจำนวนชั้นเวลาของข้อมูล

$H$  แทนขนาดความสูงของข้อมูล

$W$  แทนขนาดความกว้างของข้อมูล

$x$  แทนค่าของข้อมูล ณ ชั้นเวลาและตำแหน่งต่างๆ


## 2.4 ข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียม

ข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียมที่ใช้ในงานวิจัยนี้ นำข้อมูลมาจากโครงการ GsMAP (Global Satellite Mapping of Precipitation) [8] ซึ่งเป็นผลิตภัณฑ์ที่อยู่ในความรับผิดชอบขององค์การสำรวจอวกาศญี่ปุ่น (Japan Aerospace Exploration Agency) และเป็นผลิตภัณฑ์ส่วนหนึ่งของภารกิจ Global Precipitation Measurement (GPM) มีจุดประสงค์เพื่อสร้างข้อมูลปริมาณน้ำฝนทั่วโลกที่มีรายละเอียดสูงและมีความแม่นยำ ค่าอัตราปริมาณน้ำฝนที่ได้จากชุดข้อมูลนี้เกิดจากการวิเคราะห์ด้วยเครื่องมือในหลากหลายช่วงคลื่นจากดาวเทียมหลากหลายดวง ข้อมูลช่วงคลื่นไมโครเวฟจากดาวเทียมวงโคจรต่ำและข้อมูลในช่วงคลื่นอินฟราเรดที่ติดตั้งบนดาวเทียมค้างฟ้า (GPM Core Observatory Satellite) โดยมีอัลกอริทึมในการค้นคืนอัตราปริมาณน้ำฝนบนฐานของแบบจำลองการถ่ายโอนด้วยรังสี (Radiative Transfer Model) ชุดข้อมูล GsMAP ที่เลือกใช้ในงานวิจัยนี้เป็นข้อมูลชนิด GsMAP\_NRT ซึ่งเป็นชุดข้อมูล GsMAP ประเภทเผยแพร่ใกล้เวลาจริง (Near Real Time) และเหมาะสำหรับการนำไปประยุกต์ใช้ในการกิจทำนายปริมาณน้ำฝนระยะสั้น อยู่ในรูปแบบไฟล์ข้อมูลฐานสองแบบโพลต์ 4 ไบต์ ลิตเติลเอนเดรียน (4-Byte Float Plain Binary, Little-Endian) ถูกบีบอัดด้วย “gzip” และมีคุณลักษณะอื่น ๆ ตามที่แสดงในตารางที่ 1

ตารางที่ 1 คุณสมบัติของข้อมูล GsMAP\_NRT

คุณสมบัติ	ค่า
ความละเอียดเชิงช่วงเวลา (Temporal Resolution)	1 ชั่วโมง
ความละเอียดกริด (Grid Resolution)	เส้นตารางละติจูด/ลองจิจูด 0.1 องศา (10 กม. ที่เส้นศูนย์สูตร) ละติจูดและลองจิจูดของเส้นตารางแรก [1, 1] คือ [59.95 ° N, 0.05 ° E]
ขอบเขต (Domain)	ทั่วโลก (60 ° N-60 ° S)
ช่วงเวลาที่เก็บข้อมูล	รุ่น 6: ตั้งแต่ 1 มีนาคม 2543 ถึงปัจจุบัน รุ่น 7: ตั้งแต่ 1 เมษายน 2560 ถึงปัจจุบัน

ซึ่งไฟล์ไบนารีทุกไฟล์จะมีข้อมูลกริด อันประกอบด้วย 3600 แถว x 1200 บรรทัดซึ่งเป็นองค์ประกอบละติจูด - ละติจูดที่สอดคล้องกับ ตาราง 0.1 ° x 0.1 ° ที่ครอบคลุมภูมิภาคทั่วโลก ตั้งแต่ 60 ° N ถึง 60 ° S ละติจูดศูนย์และละติจูดของ พิกเซลแรก [1, 1] (ณ มุมบนซ้าย) คือ [0.05 ° E, 59.95 ° N] ดังรูปที่ 3



รูปที่ 3 แผนที่ความครอบคลุมของข้อมูล (Data Coverage Map)

## 2.5 ข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน (C-Band Doppler Radars)

ข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินเป็นข้อมูลที่ได้จากเรดาร์ตรวจอากาศดอปเปลอร์ (Doppler Weather Radar) ซึ่งข้อมูลปริมาณน้ำฝนที่ได้มีคุณสมบัติมีคุณภาพสูง (High Resolution) แต่จะมีข้อมูลบางส่วนที่ขาดหายไปเมื่อเทียบกับข้อมูลปริมาณน้ำฝนที่ได้จาก GsMAP เนื่องจากธรรมชาติของเรดาร์ตรวจอากาศดอปเปลอร์ที่มีระยะทำการไม่สูง เมื่อเทียบกับดาวเทียมที่โคจรในชั้นบรรยากาศ สามารถแบ่งออกได้เป็น ข้อมูลสำหรับใช้ฝึกสอน ข้อมูลสำหรับตรวจสอบ และ ข้อมูลสำหรับทำการทดสอบ มีคุณลักษณะอื่น ๆ ตามในตารางที่ 2

ตารางที่ 2 คุณลักษณะของข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน

คุณสมบัติ	ค่า
ความละเอียด (พิกเซล)	3360 x 2560 (สูง x กว้าง)
ชนิดของเรดาร์	เรดาร์ตรวจอากาศดอปเปลอร์แบบC-BAND
ภูมิภาค	ญี่ปุ่น
พิกัดภูมิศาสตร์	ละติจูด [20.005 ถึง 47.9958] ลองจิจูด [118.006 ถึง 149.994]
อันตรายภาค	10 นาที
รูปแบบไฟล์	ข้อมูลฐานสอง ( Binary Files)
ช่วงเวลาของข้อมูล	1 มิถุนายน 2561 ถึง 30 กันยายน 2561 (4 เดือน) 1 มิถุนายน 2562 ถึง 31 ธันวาคม 2562 (7 เดือน)
ขนาดไฟล์	280 กิกะไบต์โดยประมาณต่อเดือน หากอยู่ใน ไฟล์นามสกุล “.bin” 2.8 กิกะไบต์โดยประมาณต่อเดือน หากยังอยู่ใน รูปไฟล์บีบอัด “.gz”

## 2.6 การทำให้ข้อมูลปกติ (Normalization)

เนื่องจาก ข้อมูลปริมาณน้ำฝนที่ได้จากทั้งเรดาร์ตรวจอากาศดอปเพลอร์ และจากการวิเคราะห์จากภาพถ่ายดาวเทียมนั้น มีค่าการกระจายตัวที่ไม่เหมาะสมต่อการนำไปใช้กับตัวแบบจำลองการเรียนรู้เชิงลึกโดยตรง จึงมีความจำเป็นที่จะต้องแปลงค่ากลับมาอยู่ในหน่วยเดซิเบล (dBZ) เพื่อให้ค่าปริมาณน้ำฝนจากทั้งสองแหล่งมีความกระจายตัวอย่างสม่ำเสมอโดยใช้สมการที่ (2)

$$\frac{R}{mm/h} = \left( \frac{10^{\frac{dBZ}{10}}}{200} \right)^{\frac{5}{8}} \quad (2)$$



## บทที่ 3

### เอกสารและงานวิจัยที่เกี่ยวข้อง

เอกสารและงานวิจัยที่เกี่ยวข้องกับการทำนายปริมาณน้ำฝนในระยะสั้นด้วยการใช้การเรียนรู้เชิงลึกนั้นประกอบด้วย งานวิจัยที่เกี่ยวข้องกับการใช้การเรียนรู้เชิงลึกทำนายภาพวิดีโอ (Video Prediction Deep Learning) งานวิจัยที่เกี่ยวข้องกับการแก้ปัญหาจำนวนอันตรายภาคของข้อมูล งานวิจัยที่เกี่ยวข้องกับการปรับค่าอคติ (Bias Correction) และ งานวิจัยที่เกี่ยวข้องกับการผสานข้อมูลในเชิงพื้นที่และเวลา (Spatiotemporal Data Fusion)

#### 3.1 งานวิจัยที่เกี่ยวข้องกับการใช้การเรียนรู้เชิงลึกทำนายภาพวิดีโอ (Video Prediction Deep Learning)


ในงานวิจัยที่เกี่ยวข้องกับการใช้การเรียนรู้เชิงลึกทำนายภาพวิดีโอในปัจจุบันนั้นได้ถูกนำไปใช้ในการทำนายภาพแบบอนุกรมเวลา (Sequential Images Prediction) โดยแบบจำลองการเรียนรู้เชิงลึกที่เกี่ยวข้องกับงานวิจัยนี้ได้แก่ U-NET [1], Convolutional LSTM [2]

##### 3.1.1 แบบจำลอง U-NET

โครงข่ายประสาทเทียม U-NET [1] ถูกเสนอโดย Ronneberger, O., P. Fischer, และ T. Brox. เป็นโครงข่ายประสาทแบบ Convolutional (Convolutional Neural Network) และเป็นที่ยอมรับมากในโจทย์ปัญหาการแบ่งส่วนภาพทางชีวการแพทย์ (Biomedical Image Segmentation) มีโครงสร้างตามรูปที่ 4 และจะแบ่งโครงสร้างของแบบจำลองออกเป็นสองฝั่ง ฝั่งซ้ายมือประกอบด้วย Convolution Block (3x3 conv) ที่มีฟังก์ชันเปิดการใช้งาน (Activation Function) แบบ Rectified Linear Unit (ReLU) ทำซ้ำทั้งหมด 2 ครั้ง และมีการทำพูลลิ่ง (Pooling) แบบขนาด 2 x 2 ซึ่งจะมีช่วงกึ่งกลางระหว่างลดขนาดเพิ่มขนาดเรียกว่าช่วงคอขวด (Bottleneck) มีหน้าที่เปลี่ยนการทำพูลลิ่งเป็นการทำ up-sampling ขนาด 2 x 2 และมีการทำคอนโวลูชัน 3 x 3 ที่มีฟังก์ชันเปิดการใช้งานเป็น Rectified linear unit ทำซ้ำอีกสองครั้ง เพื่อให้ภาพกลับมาามีขนาดเท่าเดิม ในแต่ละชั้นจะมีการนำพีเจอร์รี่ในแต่ละระดับจากฝั่งซ้ายมือมารวมคำนวณด้วย ชั้นสุดท้ายคือการทำคอนโวลูชันที่มีขนาด 1 x 1 ให้มีจำนวนช่อง (Channels) เป็นไปตามที่แบบจำลองถูกตั้งไว้

ซึ่งการนำแบบจำลองการเรียนรู้เชิงลึกแบบ U-NET มาประยุกต์ในการทำงานปริมาณน้ำฝนระยะสั้นนั้นได้แสดงให้เห็นว่า มีประสิทธิภาพที่ดีกว่าวิธีการแบบดั้งเดิม [9]





รูปที่ 4 แบบจำลอง U-NET [1]

### 3.1.2 หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (Convolutional Long short-term memory)

หน่วยความจำระยะสั้นระยะยาวแบบคอนโวลูชัน (Convolutional Long short-term memory หรือตัวย่อ ConvLSTM) [2] เสนอโดย Shi, X., et al. เป็นโครงสร้างประสาทเทียมแบบเกิดขึ้นอีก (Recurrent neural network) ที่ถูกออกแบบมาสำหรับโจทย์การทำนายเชิงพื้นที่-ช่วงเวลา (Spatio-temporal) ที่มีโครงสร้างคอนโวลูชันทั้งในการเปลี่ยนเข้าสู่สถานะ (input to state) และแบบ สถานะเข้าสู่สถานะ (state to state) ซึ่งเหมาะกับการประมวลผลข้อมูลภาพสองมิติที่มีลักษณะเป็นลำดับ (Sequence Image) มีสมการดังสมการที่ 3 โดย  $\odot$  แทนผลิตภัณฑ์ของ Hadamard (Hadamard product) และ  $*$  แทนการทำคอนโวลูชัน

$$\begin{aligned}
 i_t &= \sigma(W_{xi} * X_t + W_{hi} * H_{t-1} + W_{ci} \odot C_{t-1} + b_i) \\
 f_t &= \sigma(W_{xf} * X_t + W_{hf} * H_{t-1} + W_{cf} \odot C_{t-1} + b_f) \\
 C_t &= f_t \odot C_{t-1} + i_t \odot \tanh(W_{xc} * X_t + W_{hc} * H_{t-1} + b_c) \\
 o_t &= \sigma(W_{xo} * X_t + W_{ho} * H_{t-1} + W_{co} \odot C_t + b_o) \\
 \mathcal{H}_t &= o_t \odot \tanh(C_t)
 \end{aligned}
 \tag{3}$$

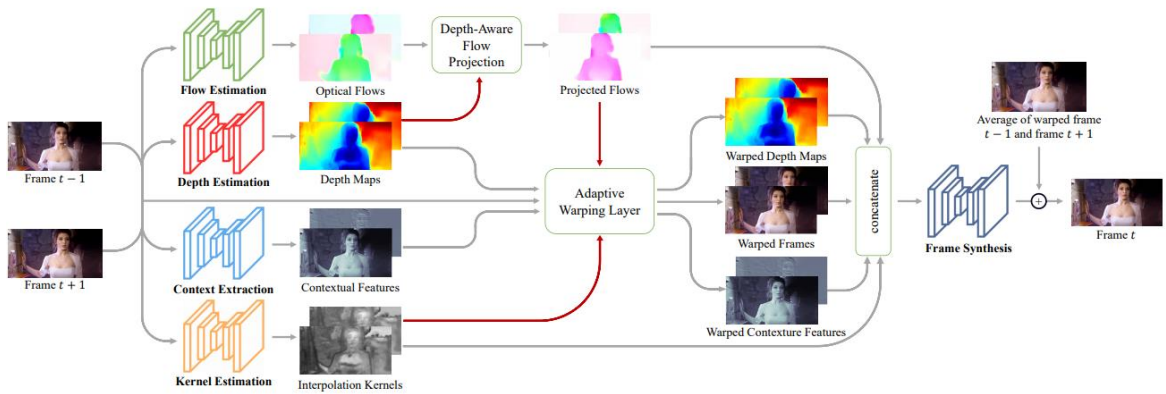
โดยที่	$i_t$	แทนผลลัพธ์จากประตูขาเข้า (Input gate)
	$f_t$	แทนผลลัพธ์จากประตูลืม (Forget gate)
	$o_t$	แทนผลลัพธ์จากประตูผลลัพธ์ (Output gate)
	$\sigma$	แทนฟังก์ชันซิกมอยด์ (Sigmoid)
	$W$	แทนน้ำหนักที่ถูกใช้ในประตูต่างๆ
	$X_t$	แทนข้อมูลขาเข้า
	$H$	แทนผลลัพธ์ของหน่วย
	$C$	แทนข้อมูลในเซลล์ความจำ
	$b$	แทนค่าลำเอียง (Bias)

### 3.2 งานวิจัยที่เกี่ยวข้องกับการแก้ปัญหาจำนวนอันตรภาคของข้อมูล

การแก้ปัญหาจำนวนอันตรภาคของข้อมูลเป็นกระบวนการที่มีความจำเป็นสำหรับการผนวกข้อมูลที่มีจำนวนอันตรภาคของข้อมูลที่ไม่เท่ากันโดยชุดข้อมูลข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากภาพถ่ายดาวเทียม (GsMAP) มีอันตรภาคเป็น 1 ชั่วโมง เพื่อให้สามารถนำมาผนวกกับข้อมูลปริมาณน้ำฝนจากชุดข้อมูลที่ได้จากเรดาร์ภาคพื้นดินของประเทศญี่ปุ่นของบริษัท WeatherNews จำกัด ที่มีอันตรภาคจาก 10 นาที จึงจำเป็นต้องมีการปรับอันตรภาคของชุดข้อมูล GsMAP จาก อันตรภาคที่ 1 ชั่วโมง เป็น 10 นาที ด้วยเทคนิคการประมาณค่าในช่วงของเฟรมภาพวิดีโอ (Video Frame Interpolation)


#### 3.2.1 การประมาณค่าในช่วงของเฟรมภาพวิดีโอที่มีการรับรู้เชิงลึก (Depth-Aware Video Frame Interpolation)

การประมาณค่าในช่วงของเฟรมภาพวิดีโอ มีจุดมุ่งหมายเพื่อสังเคราะห์เฟรมภาพที่ไม่มีอยู่ระหว่างเฟรมภาพดั้งเดิม โดยแบบจำลองการเรียนรู้เชิงลึก Depth-Aware Video Frame Interpolation (DAIN) [10] ที่สามารถตรวจจับการบิดของวัตถุในรูปได้โดยใช้ข้อมูลเชิงลึก รวมถึงมีชั้นการฉายสะท้อนเชิงลึก (Depth-Aware Flow Projection Layer) ที่สามารถรับรู้ระยะวัตถุที่อยู่ใกล้หรือไกลที่ต่างกันได้ดี ซึ่งมีประสิทธิภาพดีกว่า เทคนิคการประมาณค่าในช่วงเฟรมภาพแบบอื่นๆ



รูปที่ 5 ภาพตัวอย่างสถาปัตยกรรมภายในของแบบจำลองการเรียนรู้เชิงลึก Depth-Aware Video Frame Interpolation (DAIN) [10]

โดยในภาพตัวอย่างสถาปัตยกรรม กำหนดให้มีภาพขาเข้า 2 ภาพ ในขั้นแรกจะมีการคำนวณค่าการไหลของแสง (Optical Flow) และแผนที่ความลึก (Depth Map) จากนั้นจะมีการใช้ชั้นการฉายสะท้อนเชิงลึก (Depth Aware Flow Projection Layer) เพื่อสร้างชั้นไหลระดับกลาง (Intermediate Flow) จากนั้นจึงนำชั้นแปรปรวนแบบปรับได้ (Adaptive Warping Layer) เพื่อห่อหุ้มภาพขาเข้า แผนที่ความลึก และคุณลักษณะต่างๆ ที่ขึ้นอยู่กับชั้นไหลและสุดท้ายมีการใช้เครือข่ายสังเคราะห์ภาพเพื่อสร้างภาพขาออก



รูปที่ 6 รูปสถาปัตยกรรมของชั้นเครือข่ายการสกัดบริบท (Context Extraction Network)

### 3.3 งานวิจัยที่เกี่ยวข้องกับการปรับค่าอคติ (Bias Correction)

เนื่องจากกระบวนการและประสิทธิภาพของการตรวจวัดปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินและที่ได้จากการวิเคราะห์จากดาวเทียมนั้นมีความแตกต่างกันดังนั้นเพื่อให้ค่าปริมาณน้ำฝนที่ได้จากทั้งสองแหล่งนั้นมีความใกล้เคียงกัน ขั้นตอนการปรับค่าอคติ (Bias Correction) จึงมี

ความจำเป็นในงานวิจัยนี้ โดยในงานวิจัยนี้จะใช้วิธีการ การปรับค่าอคติโดยเฉลี่ย (Mean Bias Correction)


ค่าประกอบอคติ (Bias Factor) คือค่าอัตราส่วนระหว่างค่าจริงกับค่าอคติที่สัมพันธ์กัน (Corresponding Biased Value) ค่าอคติสามารถถูกปรับได้โดยการคูณค่าที่ได้จากพื้นที่ที่มีอคติ (Bias Field) กับค่าประกอบอคติ จากการศึกษาของ Anagnostou et al. (1998) [11] อัตราส่วนความอคติเชิงพื้นที่ (Area-Mean Bias Ratio) มีนิยามคือ อัตราส่วนของค่าเฉลี่ยจริงในพื้นที่เทียบกับค่าเฉลี่ยอคติในพื้นที่ เนื่องจากในงานวิจัยนี้ ต้องการที่จะปรับปรุงผลการทำนายปริมาณน้ำฝนในทอมของปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินเป็นหลัก จึงถือว่าค่าปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินเป็นค่า “จริง” และให้ค่าปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมเป็นค่าอคติ ดังนั้น สมการของอัตราส่วนอคติเชิงพื้นที่จะเป็น

$$B_m = \frac{\sum_{i=1}^n R_m(x_i)}{\sum_{i=1}^n G_m(x_i)} \quad (4)$$

เมื่อ  $R_m(x_i)$  คือปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน ณ ตำแหน่ง  $x_i$  ซึ่งจะถือว่าเป็นค่าที่ถูกต้องสำหรับงานวิจัยนี้ ในขณะที่  $G_m(x_i)$  คือปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม ณ ตำแหน่ง  $x_i$  ในทุกๆ 10 นาทีที่  $m$

### 3.4 งานวิจัยที่เกี่ยวข้องกับการผสมผสานข้อมูลในเชิงพื้นที่และเวลา (Spatiotemporal data fusion)

Vladimir Ivashkin และ Vadim Lebedev ได้เสนอแนวคิดของการผสมผสานข้อมูลในเชิงพื้นที่และเวลา [12] โดยอิงจากเทคนิคของ Computer Vision ซึ่งเจาะจงไปที่เทคนิคการใช้ Image Blending และ Alpha Blending และมีการพัฒนาอัลกอริทึมที่มี Soft Mark เพื่อกำจัดวัตถุแปลกปลอมที่เกิดขึ้นในภาพและเพื่อลบรอยต่อภายในภาพ รูปที่ 6 แสดงตัวอย่างผลลัพธ์การผนวกข้อมูลที่ได้จากเรดาร์และข้อมูลที่ได้จากดาวเทียมเข้าด้วยกันด้วยกระบวนการต่างๆ โดยคอลัมน์ที่ 1 แสดงให้เห็นถึงข้อมูลที่ได้จากเรดาร์ คอลัมน์ที่ 2 แสดงให้เห็นถึงข้อมูลที่ได้จากดาวเทียม คอลัมน์ที่ 3 แสดงให้เห็นถึงการผนวกโดยไม่มีการพยายามทำให้ภาพกลมกลืนกันซึ่งจะปรากฏรอยต่อให้เห็น คอลัมน์ที่ 4 แสดงให้เห็นถึงเทคนิคการผสมด้วยเทคนิค Alpha Blending ที่สามารถลดตะเข็บรอยต่อระหว่างข้อมูลเรดาร์และข้อมูลดาวเทียมได้ คอลัมน์ที่ 5 แสดงให้เห็นถึงเทคนิคการผสมที่ Vladimir Ivashkin และ Vadim Lebedev เสนอมาที่สามารถผนวกข้อมูลได้กลมกลืนกว่าเทคนิค Alpha Blending



รูปที่ 7 ภาพเปรียบเทียบผลการผนวกข้อมูลระหว่างข้อมูลที่ได้จากเรดาร์ภาคพื้นดินและจากดาวเทียม ด้วยกระบวนการต่างๆ[12]

การผนวกข้อมูลข้างต้นแม้จะมีการนำเสนอการผสมข้อมูลระหว่างสองแหล่งเข้าด้วยกันแต่ในงานวิจัยดังกล่าวไม่ได้จุดประสงค์ในการปรับปรุงประสิทธิภาพการทำนายปริมาณน้ำฝนในระยะสั้น หากแต่เป็นการนำเสนอวิธีการที่ทำให้ข้อมูลจากสองแหล่งมีความกลมกลืนกันเท่านั้น และงานวิจัยที่เกี่ยวข้องกับการปรับค่าอคติอย่างกระบวนการ Mean Bias Correction มีความเกี่ยวข้องกับงานวิจัยการปรับปรุงผลการทำนายปริมาณน้ำฝนระยะสั้นมากกว่า กระบวนการ Mean Bias Correction แบบจำลองการเรียนรู้เชิงลึก Depth-Aware Video Frame Interpolation และแบบจำลองการเรียนรู้เชิงลึกแบบ U-NET จึงเป็นรูปแบบที่จะเลือกใช้ในงานวิจัยนี้

## บทที่ 4

### แนวคิดและวิธีการดำเนินงาน

บทนี้จะเป็นการอธิบายวิธีการดำเนินงานและแนวคิด โดยจะออกเป็น 4 ส่วนหลักตามรูป 5 ดังนี้ (1) รวบรวมข้อมูลปริมาณน้ำฝนจากบริษัท WeatherNews จำกัด (WNI) และจาก GsMAP อยู่ในรูปแบบ (Format) ที่สามารถนำไปใช้งานต่อได้ (2) ทำการประมวลผลข้อมูลก่อน (Data Pre-processing) ให้มีขนาดที่เหมาะสมและสามารถนำไปป้อนเข้าแบบจำลองได้ (3) จัดทำโมเดลที่ได้ ออกแบบและป้อนชุดข้อมูลที่ผ่านมาประมวลผลก่อนเข้าฝึก (4) ขั้นตอนการประเมินผล สำหรับตรวจวัดผลการทำนายด้วยดัชนีวัดความสำเร็จตามรูปที่ 8



รูปที่ 8 ขั้นตอนการดำเนินงาน

#### 4.1 การรวบรวมชุดข้อมูล

ชุดข้อมูลที่ใช้ในงานวิจัยนี้ประกอบด้วย ข้อมูลปริมาณน้ำฝนสองแหล่ง คือ 1) มาจากบริษัท WeatherNews จำกัด และ 2) จาก GsMAP ซึ่งเป็นผลิตภัณฑ์จากองค์การสำรวจอวกาศญี่ปุ่น

##### 4.1.1 ชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดิน

ในส่วนของชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินที่ได้จากบริษัท WeatherNews นั้น เป็นไฟล์ในรูปแบบ ข้อมูลฐานสอง (Binary Files) มีอันตรภาพเป็น 10 นาที โดยข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินที่จะนำมาใช้ในการผนวกข้อมูลสำหรับข้อมูลฝึกแบบจำลองจะมีคุณสมบัติตามที่แสดงในตาราง 3

ตารางที่ 3 คุณสมบัติของชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินที่จะนำมาใช้ในการผนวกข้อมูล

คุณสมบัติ	ค่า
ความละเอียด (พิกเซล)	3360 x 2560 (สูง x กว้าง)
ชนิดของเรดาร์	เรดาร์ตรวจอากาศดอปเปลอร์แบบC-BAND
ภูมิภาค	ญี่ปุ่น
พิกัดภูมิศาสตร์	ละติจูด [20.005 ถึง 47.9958] ลองจิจูด [118.006 ถึง 149.994]
อันตรภาค	10 นาที
รูปแบบไฟล์	ข้อมูลฐานสอง (Binary Files)
ช่วงเวลาของข้อมูล	1 มิถุนายน 2561 ถึง 30 กันยายน 2561 (4 เดือน)
ขนาดไฟล์	280 กิกะไบต์โดยประมาณต่อเดือน

ตารางที่ 4 ค่าสถิติของระดับน้ำฝนในชุดข้อมูลจากเรดาร์

อัตราการตกของน้ำฝน (มิลลิเมตรต่อชั่วโมง)	สัดส่วน (ร้อยละ)	ปริมาณน้ำฝน	คลาส (Class)
$0 \leq x < 1$	67.65	ฝนไม่ตก	0
$1 \leq x < 10$	28.11	ฝนตกเบา	1
$10 \leq x < 30$	3.65	ฝนตกปานกลาง	2
$30 \leq x$	0.45	ฝนตกหนัก	3

#### 4.1.2 ชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียม

ในส่วนของชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียม GsMAP เป็นไฟล์ในรูปแบบไฟล์ข้อมูลฐานสองแบบไพลท 4 ไบต์ ลิตเติ้ลเอนเดรียน มีอันตรภาคเป็น 1 ชั่วโมง โดยข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมก่อนที่จะนำไปใช้ในกระบวนการลดทอนข้อมูล การแปลงจำนวนอันตรภาคเป็น 10 นาทีและนำไปผนวกกับข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ จะมีคุณสมบัติตามตารางที่ 5

ตารางที่ 5 คุณสมบัติของชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมก่อนที่จะนำมาใช้ในกระบวนการลดทอนข้อมูล การเพิ่มจำนวนอันตรายภาคและผนวกข้อมูล

คุณสมบัติ	ค่า
ความละเอียด (พิกเซล)	1200 x 3600 (สูง x กว้าง)
ภูมิภาค	ทั่วโลก
พิกัดภูมิศาสตร์	ละติจูด [-59.95 ถึง 59.95] ลองจิจูด [-179.95 ถึง 179.95]
อันตรายภาค	1 ชั่วโมง
รูปแบบไฟล์	ข้อมูลฐานสองแบบฟลอยด์ 4 ไบต์ ลิตเติ้ลเอนเดรียน (4-Byte Float Plain Binary, Little-Endian)
ช่วงเวลาของข้อมูล	มิถุนายน 2561 ถึง 30 กันยายน 2561 (4 เดือน)
ขนาดไฟล์	1 กิกะไบต์โดยประมาณต่อเดือน (ไฟล์บีบอัดนามสกุล .dat.gz)

#### 4.1.3 ชุดข้อมูลปริมาณน้ำฝนสำหรับทดสอบประสิทธิภาพการทำนาย

ชุดข้อมูลปริมาณน้ำฝนสำหรับใช้ทดสอบประสิทธิภาพการทำนายจากแบบจำลองทั้ง 7 ชุดนั้น เป็นชุดข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ตรวจจับอากาศภาคพื้นดิน ซึ่งจะเป็นชุดข้อมูลของพายุและฝนตกหนักรุนแรงในรูปแบบต่างๆ มีรายละเอียดโดยสังเขปตามลำดับของชุดข้อมูลดังนี้

##### 1. ชุดข้อมูล Typhoon FAXAI

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากพายุไต้ฝุ่น “ฟ้าใส” ซึ่งเป็นพายุที่เกิดขึ้น ณ ประเทศญี่ปุ่นใน วันที่ 8 กันยายน 2562

##### 2. ชุดข้อมูล Typhoon HAGIBIS

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากพายุไต้ฝุ่นฮาภิบิส ซึ่งเป็นพายุหมุนเขตร้อนขนาดใหญ่ และเป็นพายุที่สร้างความเสียหายให้กับประเทศญี่ปุ่นหลังจากพายุ “ฟ้าใส” ไปแล้วหนึ่งเดือนโดยประมาณ โดยข้อมูลที่ใช้อ้างอิงเป็นวันที่ 12 ตุลาคม 2562



### 3. ชุดข้อมูล Typhoon NARI

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากพายุโซนร้อนนารี พายุนี้ได้พัดเข้าประชิดประเทศญี่ปุ่นจากทางใต้และพัดขึ้นฝั่ง จากนั้นจึงอ่อนกำลังลงเป็นพายุดีเปรสชันเขตร้อน โดยข้อมูลที่ใช้อ้างอิงเป็นวันที่ 26 กรกฎาคม 2562

### 4. ชุดข้อมูล HEAVY RAINFALL

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากเหตุการณ์ฝนตกหนักในประเทศญี่ปุ่น ณ วันที่ 25 ตุลาคม 2562

### 5. ชุดข้อมูล Squall Line

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากแนวพายุฝนฟ้าคะนองที่มีลักษณะการก่อตัวแบบเป็นแถบแนวยาว ซึ่งจะเกิดลมกระโชกแรงตามขอบด้านหน้าของพายุ โดยข้อมูลที่ใช้อ้างอิงเป็นวันที่ 30 มิถุนายน 2562

### 6. ชุดข้อมูล Typhoon TRAMI

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากพายุไต้ฝุ่นโซนร้อนทรามิ โดยมีข้อมูลที่ใช้อ้างอิงเป็นวันที่ 30 กันยายน 2561

### 7. ชุดข้อมูล Typhoon KROSA

เป็นชุดข้อมูลปริมาณน้ำฝนที่ตรวจจับได้จากพายุโซนร้อนกรอซา โดยมีข้อมูลที่ใช้อ้างอิงเป็นวันที่ 15 สิงหาคม 2562

โดยในตารางที่ 5 นั้นจะมีค่าทางสถิติของชุดข้อมูลทดสอบสำหรับใช้ประเมินประสิทธิภาพการทำนาย ตารางที่ 6 นั้นจะมีค่าสถิติพื้นที่ที่ให้ความสนใจของชุดข้อมูลทดสอบเทียบกับขนาดความละเอียดของข้อมูลทั้งหมด และตารางที่ 7 ที่มี ค่าสถิติปริมาณน้ำฝนของชุดข้อมูลทดสอบแต่ละชุดเทียบกับจำนวนข้อมูลทั้งหมด

ตารางที่ 6 ชุดข้อมูลที่ใช้ประเมินประสิทธิภาพการทำนาย

ลำดับชุดข้อมูลทดสอบ (Case No.)	ชุดข้อมูลทดสอบ (Test Case)	ช่วงเวลาของข้อมูลที่ใช้ ทดสอบ (วัน/เดือน/ปี)
1	Typhoon FAXAI	08/09/2562
2	Typhoon HAGIBIS	12/10/2562
3	Typhoon NARI	26/07/2562
4	HEAVY RAINFALL	25/10/2562
5	SQUALL LINE	30/06/2562
6	Typhoon TRAMI	30/09/2561
7	Typhoon KROSA	15/08/2562

ตารางที่ 7 ค่าสถิติพื้นที่ที่ให้ความสนใจของชุดข้อมูลทดสอบเทียบกับขนาดความละเอียดของข้อมูล  
ทั้งหมด

พื้นที่ที่ให้ความสนใจ	ลำดับชุดข้อมูลทดสอบ (Case No.)						
	1	2	3	4	5	6	7
	5.09%	25.25%	11.07%	20.37%	10.07%	14.76%	21.80%

ตารางที่ 8 ค่าสถิติปริมาณน้ำฝนของชุดข้อมูลทดสอบแต่ละชุดเทียบกับจำนวนข้อมูลทั้งหมด

ปริมาณน้ำฝน (มิลลิเมตร/ชั่วโมง)	คลาส (Class)	ลำดับชุดข้อมูลทดสอบ (Case No.)						
		1	2	3	4	5	6	7
0 – 1	0	17.75%	15.47%	27.63%	22.55%	20.57%	12.18%	11.12%
1 – 10	1	66.02%	70.35%	64.12%	69.17%	68.82%	72.68	75.53%
10 – 20	2	10.35%	9.31%	5.80%	6.09%	7.50%	10.67%	9.13%
20 – 30	2	3.33%	2.92%	1.45%	1.31%	1.96%	2.73%	2.51%
30 – 50	3	1.99%	1.63%	0.75%	0.65%	0.93%	1.40%	1.35%
50 – 80	3	0.57%	0.32%	0.24%	0.22%	0.23%	0.35%	0.36%

## 4.2 การประมวลผลข้อมูลก่อน (Data Preprocessing)

เนื่องจากรูปแบบของชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินและ ชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียมมีรูปแบบ (Format) ขอบเขตของข้อมูล (Domain) และ ความละเอียดของข้อมูล (Resolution) ที่แตกต่างกัน ซึ่งมีความจำเป็นที่ต้องมีกระบวนการในการแปลงข้อมูลปริมาณน้ำฝนจากทั้งสองแหล่งให้อยู่ในรูปแบบเดียวกันเพื่อให้สามารถนำไปประมวลต่อด้วยคอมพิวเตอร์ได้

โดยการประมวลผลข้อมูลก่อนที่จะกระทำกับข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม (GsMAP) สามารถแบ่งออกเป็น 4 ขั้นตอนดังนี้ 1) การแปลงข้อมูลให้อยู่ในรูปของนัมพายอาร์เรย์ 2) การลดทอนขนาดของข้อมูล 3) การเพิ่มจำนวนอันตรายภาคของข้อมูล 4) การขยายขนาดภาพ

หลังจากนั้นจะเป็นการประมวลผลข้อมูลก่อนที่จะกระทำกับทั้งข้อมูล GsMAP และข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ประกอบด้วย 1) การผสมผสานข้อมูลเชิงพื้นที่และเวลา 2) การสอบเทียบข้อมูล

### 4.2.1 การแปลงข้อมูลเป็นนัมพายอาร์เรย์

ชุดข้อมูลปริมาณน้ำฝนจากทั้งสองแหล่งจะต้องถูกแปลงจากข้อมูลฐานสองที่มีรูปแบบแตกต่างกันให้อยู่ในรูปแบบนัมพายอาร์เรย์ (NumPy Array) [2] ก่อน โดยนัมพายอาร์เรย์คือรูปแบบการเก็บข้อมูลให้อยู่ในรูปของเมตริกตัวเลข เพื่อให้สามารถนำข้อมูลทั้งสองแหล่งนี้ไปคำนวณด้วยโปรแกรมที่เขียนด้วยภาษาไพธอน (Python) ได้ รวมถึงกระบวนการอื่น ๆ ที่จำเป็นต้องทำกับชุดข้อมูลในรูปแบบของนัมพายอาร์เรย์

สำหรับข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม (GsMAP) นั้นในเบื้องต้นข้อมูลจะได้มาในรูปของไฟล์สกุล “.dat.gz” และเป็นข้อมูลฐานสองแบบโพลต์ 4 ไบต์ ลิตเติลเอนเดรียน ซึ่งจำเป็นต้องมีการนำเข้าไปในรูปของนัมพายอาร์เรย์ ซึ่งจะได้ขนาดเป็น 1200 x 3600 พิกเซล (สูง x กว้าง) ซึ่งแต่ละพิกเซลจะมีพื้นที่ที่ครอบคลุม 10 ตารางกิโลเมตรต่อ 1 พิกเซล และจะมีข้อมูลของพิกัดทางภูมิศาสตร์ตั้งแต่ ละติจูด [-59.95 ถึง 59.95] และ ลองจิจูด [-179.95 ถึง 179.95]

### 4.2.2 การลดทอนข้อมูล (Data Reduction)


เนื่องจากชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียมมีขอบเขตทั่วโลก ซึ่งเป็นข้อมูลที่เกินความจำเป็น อันเนื่องมาจากขอบเขตการศึกษาของงานวิจัยนี้อยู่ในภูมิภาคญี่ปุ่นเป็นหลัก

จึงมีความจำเป็นที่จะต้องมีการลดทอนข้อมูลส่วนอื่นที่อยู่นอกเหนือขอบเขตการศึกษาออก โดยที่ชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินและที่ได้จากการวิเคราะห์จากดาวเทียม (GsMAP) นั้นครอบคลุมตามพิกัดภูมิศาสตร์ตามตารางที่ 6


ตารางที่ 9 เปรียบเทียบพิกัดพิกัดภูมิศาสตร์ระหว่างสองชุดข้อมูลก่อนหน้าการลดข้อมูล

พิกัดภูมิศาสตร์ของข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดิน	ละติจูด [20.005 ถึง 47.9958] ลองจิจูด [118.006 ถึง 149.994]
พิกัดภูมิศาสตร์ของข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียม	ละติจูด [-59.95 ถึง 59.95] ลองจิจูด [-179.95 ถึง 179.95]

เพื่อให้สามารถผนวกข้อมูลชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากภาพถ่ายดาวเทียม (GsMAP) ให้เข้ากับชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินได้ จึงจำเป็นต้องมีการลดทอนข้อมูล GsMAP ให้มีพิกัดภูมิศาสตร์ที่ใกล้เคียงกับข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดิน ซึ่งหลังจากขั้นตอนการนำเข้าข้อมูล GsMAP ให้อยู่ในรูปของนามพายอาร์เรย์นั้น ผู้วิจัยได้เขียนชุดคำสั่งเพื่อให้มีการคำนวณหาตำแหน่งในข้อมูล GsMAP ที่อยู่ในรูปของนามพายอาร์เรย์แล้วและมีตำแหน่งใกล้เคียงกับพิกัดทางภูมิศาสตร์จากข้อมูลปริมาณน้ำฝนจากเรดาร์มากที่สุด ซึ่งจะได้ข้อมูล GsMAP ที่มีความละเอียดที่ 279 x 319 พิกเซล (สูง x กว้าง)



รูปที่ 9 ตัวอย่างข้อมูลปริมาณน้ำฝน GsMAP ก่อนผ่านขั้นตอนการลดทอนข้อมูล




รูปที่ 10 ตัวอย่างข้อมูลปริมาณน้ำฝน GsMAP หลังผ่านขั้นตอนการลดทอนข้อมูล

#### 4.2.3 การเพิ่มจำนวนอัตราภาคของข้อมูล

เนื่องจากชุดข้อมูลจากการวิเคราะห์จากดาวเทียมมีจำนวนอัตราภาคของข้อมูลที่ต่างจากชุดข้อมูลที่ได้จากเรดาร์ภาคพื้นดิน โดยชุดข้อมูลที่ได้จากเรดาร์ภาคพื้นดินมีจำนวนอัตราภาคของข้อมูลที่ 10 นาที ในขณะที่ชุดข้อมูลจากการวิเคราะห์จากดาวเทียมมีจำนวนอัตราภาคของข้อมูลที่ 1 ชั่วโมง

สืบเนื่องจากธรรมชาติของข้อมูลปริมาณน้ำฝนในชุดข้อมูลจะมีการเปลี่ยนแปลงอันเนื่องมาจากการเคลื่อนที่ของลมอันเป็นผลให้มีการเคลื่อนไหวเกิดขึ้นในข้อมูลปริมาณน้ำฝน และเพื่อแก้ปัญหาจำนวนอัตราภาคที่ไม่เท่ากัน จึงมีการใช้แบบจำลองการเรียนรู้เชิงลึก DAIN [10] ซึ่งเป็นแบบจำลองที่สามารถสังเคราะห์เฟรมภาพที่ไม่มีอยู่ระหว่างเฟรมภาพดั้งเดิมที่ต่อเนื่องกัน 2 ภาพได้ จึงมีการประยุกต์ใช้แบบจำลองการเรียนรู้เชิงลึก DAIN ในการสังเคราะห์ชุดข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียม (GsMAP) ให้มีจำนวนอัตราภาคจาก 1 ชั่วโมงเป็น 10 นาที ด้วยการสังเคราะห์เฟรมภาพของข้อมูล GsMAP จากเดิมที่มีจำนวนเฟรม 2 ภาพต่อ 1 ชั่วโมงเป็น 7 ภาพต่อ 1 ชั่วโมง โดยผู้วิจัยได้ใช้แบบจำลอง DAIN ในการสังเคราะห์ข้อมูลปริมาณน้ำฝน GsMAP ในเดือนมิถุนายน 2561 ถึงเดือนกันยายน 2561 และวันที่ตามที่ระบุไว้ในตารางชุดข้อมูลชุดข้อมูลที่ใช้ประเมินประสิทธิภาพการทำนาย (ตารางที่ 5) โดยในรูปที่ 11 เป็นการแสดงตัวอย่างผลลัพธ์การใช้แบบจำลอง DAIN ในการสังเคราะห์เฟรมภาพข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม โดยเส้นลูกศรสีดำแทนข้อมูลปริมาณน้ำฝนที่ได้จากการสังเคราะห์ด้วยแบบจำลอง DAIN และเส้นลูกศรสีฟ้าแทนข้อมูลปริมาณน้ำฝนที่มีอยู่ก่อนแล้ว



รูปที่ 11 ตัวอย่างผลลัพธ์การใช้แบบจำลอง DAIN ในการสังเคราะห์เฟรมภาพข้อมูลปริมาณน้ำฝน GsMAP ณ วันที่ 1 เดือนมิถุนายน 2561

#### 4.2.4 การขยายขนาดภาพ (Image Upsampling)

ข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม (GsMAP) ที่ผ่านกระบวนการลดทอนข้อมูลให้เหลือเพียงข้อมูลที่มีพิกัดภูมิศาสตร์ที่ใกล้เคียงกับข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ และผ่านกระบวนการเพิ่มจำนวนอัตราภาคแล้ว ในแต่ไฟล์ข้อมูลนั้นจะมีอัตราภาคที่ 10 นาทีแล้วมีความละเอียดที่  $279 \times 319$  พิกเซล (สูง  $\times$  กว้าง) ซึ่งจะยังไม่สามารถนำไปผนวกกับข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ได้เนื่องจากความละเอียดที่ต่างกัน จึงจำเป็นต้องมีการมีแปลงข้อมูล GsMAP ให้มีความละเอียดที่  $3,360 \times 2,560$  พิกเซล (สูง  $\times$  กว้าง) เสียก่อน โดยจะใช้กระบวนการการประมาณค่า (Interpolate) แบบการประมาณค่าเชิงเส้นคู่ (Bilinear Interpolation)


#### 4.2.5 การผสานข้อมูลเชิงพื้นที่และเวลา (Spatial and Temporal Data Fusion)

หลังจากข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม (GsMAP) ที่ผ่านกระบวนการลดทอนข้อมูล กระบวนการเพิ่มจำนวนอัตราภาค และกระบวนการขยายขนาดภาพแล้ว ผู้วิจัยได้พัฒนาโปรแกรมเปรียบเทียบว่าตำแหน่งพิกเซลใดของข้อมูลปริมาณน้ำฝน GsMAP ที่สามารถแทรกเข้าไปกับข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ได้ ด้วยข้อมูลหน้ากาก (Mask) จากทาง WNI ที่ระบุว่าจุดพิกเซล ณ ตำแหน่งใดๆในข้อมูลปริมาณน้ำฝนจากเรดาร์ตรวจอากาศภาคพื้นดินสามารถตรวจจับได้ และสืบเนื่องจากในงานวิจัยนี้ได้ถือว่า ข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์เป็นข้อมูลที่มีความเที่ยงตรงสูงและงานวิจัยนี้ต้องการปรับปรุงการทำนายปริมาณน้ำฝนในเทอมของปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน จึงจะไม่มีกระบวนการผนวกข้อมูลปริมาณน้ำฝนจาก GsMAP เข้าไปในพื้นที่พิกเซลใดๆของข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ที่ระยะทำการของเรดาร์สามารถทำการตรวจวัดได้ถึง

หลังจากที่ได้คัดเลือกและจัดเรียงชุดข้อมูล GsMAP ที่มีช่วงวันและเวลาและพิกัดภูมิศาสตร์ตรงกันกับชุดข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินเพื่อป้องกันการผนวกข้อมูลผิดช่วงเวลาตามรูปที่ 12 ที่เป็นตัวอย่างภาพของข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินและข้อมูลปริมาณน้ำฝนที่


ได้จากการวิเคราะห์จากดาวเทียมและข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมที่ได้จากการสังเคราะห์ในช่วงของเฟรมภาพวีดิทัศน์ด้วยแบบจำลอง DAIN ในวันที่ 1 มิถุนายน 2561 ระหว่างเวลา 00:00 น. ถึง 01:00 น. โดยเส้นลูกศรสีดำแทนข้อมูลปริมาณน้ำฝนที่ได้จากการสังเคราะห์ด้วยแบบจำลอง DAIN และเส้นลูกศรสีฟ้าแทนข้อมูลปริมาณน้ำฝนที่มีอยู่ก่อนแล้ว

ในงานวิจัยนี้ยังได้มีการใช้ไฟล์หน้ากาก (Mask) เพื่อป้องกันการผนวกข้อมูล GsMAP ไปในข้อมูลเรดาร์ที่ระยะเรดาร์ทำการได้แล้ว ผู้วิจัยได้ทำการทดแทนข้อมูลปริมาณน้ำฝนของเรดาร์ภาคพื้นดินที่ไม่สามารถตรวจวัดได้ ด้วยข้อมูลปริมาณน้ำฝนที่ได้จาก GsMAP เข้าไป เพื่อแก้ปัญหาข้อมูลขาดหายซึ่งเกิดขึ้นกับข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน โดยในรูปที่ 13 แสดงให้เห็นถึงข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินของวันที่ 01/06/2018 00:00 UTC ที่ปรากฏข้อมูลขาดหายไปในช่วง ในรูปที่ 14 แสดงให้เห็นถึงข้อมูลปริมาณน้ำฝน GsMAP ที่ผ่านกระบวนการทำลดข้อมูลแล้ว ในรูปที่ 15 แสดงให้เห็นถึงข้อมูลปริมาณน้ำฝนที่ได้จากการผสานข้อมูลระหว่างข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินและข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม




รูปที่ 12 ตัวอย่างภาพของข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน และข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมและข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมที่ได้จากการสังเคราะห์ในช่วงของเฟรมภาพวีดิทัศน์ด้วยแบบจำลอง DAIN ในวันที่ 1 มิถุนายน 2561 ระหว่างเวลา 00:00 น. ถึง 01:00 น.






รูปที่ 13 ข้อมูลปริมาณน้ำฝนจากเรดาร์ภาคพื้นดินโดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง




รูปที่ 14 ข้อมูลปริมาณน้ำฝนจาก GsMAP โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง





รูปที่ 15 ข้อมูลปริมาณน้ำฝนที่ได้จากการผสานข้อมูลเชิงพื้นที่โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง



รูปที่ 16 ตัวอย่างไฟล์หน้ากาก (Mask) ที่ใช้ในการระบุขอบเขตระยะทำการของเรดาร์


#### 4.2.6 การสอบเทียบข้อมูล (Data Calibration)

กระบวนการ Mean Bias Correction (MBC) [11] ถูกนำมาใช้เพื่อใช้สอบเทียบข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์ดาวเทียม (GSMAP) ให้มีค่าที่ใกล้เคียงกับปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน (WNI) โดยแบ่งการทำ Mean Bias Correction เป็นสองรูปแบบด้วยกัน รูปแบบแรกคือการหาค่า Bias factor โดยไม่ได้แบ่งประเภท Class ของปริมาณน้ำฝนก่อนการทำ Mean Bias Correction รูปแบบที่สองคือการหาค่า factor โดยมีการแบ่งประเภท Class ของปริมาณน้ำฝนก่อนการทำ Mean Bias Correction (Multi Class Mean Bias Correction หรือ MMBC)


โดยในกระบวนการนี้จำเป็นต้องใช้ข้อมูลจากทั้งข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมและข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ ซึ่งจะต้องเป็นพื้นที่ที่ระยะทำการของเรดาร์เข้าถึงและเป็นพื้นที่ที่ระยะทำการของดาวเทียมเช่นกัน ผู้วิจัยจึงได้ใช้ไฟล์หน้ากากในการเลือกเฉพาะข้อมูลของพื้นที่ที่เป็นระยะทำการของเรดาร์ (WNI) ที่มีพิกัดทางภูมิศาสตร์เดียวกันกับข้อมูลของปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม

ซึ่งจะได้ข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียม (GsMAP) และข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ในพื้นที่ที่จะสามารถนำไปใช้ในการคำนวณหาค่า MBC และ MMBC ได้ รูปที่ 17 แสดงถึงตัวอย่างข้อมูลปริมาณน้ำฝนจากเรดาร์และข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมที่สามารถนำมาใช้ในการสอบเทียบข้อมูลด้วยกระบวนการ MBC และ MMBC ได้ เนื่องจากอยู่ในพื้นที่ที่ทั้งสองแหล่งมีระยะทำการที่ตรงกัน รูปที่ 18 เป็นตัวอย่างแสดงให้เห็นถึงข้อมูลปริมาณน้ำฝน GsMAP ที่ยังไม่ผ่านการสอบเทียบข้อมูล รูปที่ 19 เป็นตัวอย่างแสดงให้เห็นถึงข้อมูลปริมาณน้ำฝน GsMAP ที่ผ่านการสอบเทียบข้อมูลแบบ MBC รูปที่ 20 เป็นตัวอย่างแสดงให้เห็นถึงข้อมูลปริมาณน้ำฝน GsMAP ที่ผ่านการสอบเทียบข้อมูลแบบ MMBC


หลังจากที่ได้ค่าอคติ (Bias) จากกระบวนการสอบเทียบข้อมูลทั้งสองแบบแล้ว จะมีการนำค่าอคติดังกล่าวนำไปคูณกับข้อมูลปริมาณน้ำฝน GsMAP เดิมที่มีเพื่อให้ค่าปริมาณน้ำฝน GsMAP มีความใกล้เคียงกับข้อมูลปริมาณน้ำฝนจากเรดาร์ โดยค่าอคติของแต่ละข้อมูลปริมาณน้ำฝนในแต่ละประทับเวลา (Timestamp) จะแตกต่างกัน ขึ้นอยู่กับค่าปริมาณน้ำฝนของทั้งที่ได้จากเรดาร์และจาก GsMAP ในประทับเวลาเดียวกัน




รูปที่ 17 ตัวอย่างข้อมูลปริมาณน้ำฝนจากเรดาร์และข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมที่สามารถนำไปใช้ในการสอบเทียบข้อมูลได้



รูปที่ 18 ตัวอย่างข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมที่ยังไม่ผ่านกระบวนการ Mean Bias Correction โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง



รูปที่ 19 ตัวอย่างข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมที่ผ่านกระบวนการ Mean Bias Correction โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง



รูปที่ 20 ตัวอย่างข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมที่ผ่านกระบวนการ Multi Class Mean Bias Correction โดยมีหน่วยเป็นมิลลิเมตรต่อชั่วโมง

#### 4.3 แนวทางการฝึกสอนแบบจำลองการเรียนรู้เชิงลึก

การฝึกสอนแบบจำลองการเรียนรู้เชิงลึกมีจุดประสงค์เพื่อให้เครือข่ายประสาทเทียมภายในแบบจำลองการเรียนรู้เชิงลึกได้เรียนรู้ค่าพารามิเตอร์ที่เหมาะสมกับข้อมูลที่ได้ทำการป้อนเข้าไป กล่าวคือค่าพารามิเตอร์เหล่านี้จะมีการเปลี่ยนแปลงขึ้นอยู่กับข้อมูลที่ได้ป้อนเข้าไปในแบบจำลอง ซึ่งในงานวิจัยนี้ได้ฝึกสอนแบบจำลองการเรียนรู้เชิงลึก ด้วยชุดข้อมูลใช้การผสมข้อมูลปริมาณน้ำฝนจากสองแหล่งเพื่อเพิ่มประสิทธิภาพการทำนายปริมาณน้ำฝนด้วยแบบจำลองการเรียนรู้เชิงลึก ซึ่งจะมีขั้นตอนการฝึกแบบจำลองการเรียนรู้เชิงลึกตามที่แสดงในรูปที่ 21 และเพื่อแก้ปัญหาจำนวนข้อมูลที่ไม่สมดุลกัน (Class Imbalance) ดังที่ปรากฏในตารางที่ 4 ในบางการทดลองจะมีการแก้ค่าน้ำหนักในแบบจำลองเอง (Custom Weight) เพื่อให้แบบจำลองการเรียนรู้เชิงลึกให้ความสนใจกับข้อมูลปริมาณน้ำฝนในบางกลุ่มเป็นพิเศษ

สืบเนื่องมาจากงานวิจัยนี้ต้องการปรับปรุงประสิทธิภาพการทำนายปริมาณน้ำฝนด้วยแบบจำลองการเรียนรู้เชิงลึกในเทอมของปริมาณน้ำฝนที่ได้จากเรดาร์ตรวจอากาศภาคพื้นดินเป็นหลัก ดังนั้น ทุกชุดข้อมูลปริมาณน้ำฝนที่ผ่านการผนวกข้อมูลแล้ว จะถูกใช้ฝึกสอนแบบจำลองโดยยังมีผลเฉลี่ยในชุดข้อมูลเป็นข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ตรวจอากาศภาคพื้นดิน (WNI) เท่านั้น

ในการทดลองนี้มีการปรับค่าที่มีการใช้ควบคุมกระบวนการเรียนรู้ของแบบจำลองการเรียนรู้เชิงลึกหรือที่เรียกว่าไฮเปอร์พารามิเตอร์ (Hyperparameter) ดังในตารางที่ 10

สำหรับการฝึกสอนแบบจำลองด้วยชุดข้อมูลแต่ละรูปแบบนั้น จะมีการคำนวณค่าความสูญเสีย (Loss) ที่จะถูกนำไปใช้ในขั้นตอนการทำโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ

(Backpropagation) เพื่อปรับค่าพารามิเตอร์ในแบบจำลอง ซึ่งในงานวิจัยนี้จะมีการทดลองใช้การคำนวณค่า Loss ในสองรูปแบบ อันได้แก่ 1) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (MSE หรือ Mean Squared Error) และ 2) ค่าเฉลี่ยความผิดพลาดยกกำลังสองที่มีการให้น้ำหนัก (WMSE หรือ Weighted Mean Squared Error) เพื่อให้แบบจำลองนั้นมีความสามารถในการทำนายปริมาณน้ำฝนใน CSI คลาส 2 และ คลาส 3 ได้มากขึ้น

ตารางที่ 10 การตั้งค่าไฮเปอร์พารามิเตอร์สำหรับการทดลองบนชุดข้อมูลต่างๆ

พารามิเตอร์	ชุดข้อมูลเรดาร์ภาคพื้นดิน (WNI)	ชุดข้อมูลภาคพื้นดินผสมกับดาวเทียมแบบจำลอง DAIN (WNI-GsMAP-DAIN)	เรดาร์ภาคพื้นดินผนวกกับดาวเทียมแบบจำลอง DAIN และ Mean Bias Correction (WNI-GsMAP-DAIN-MBC)	เรดาร์ภาคพื้นดินผนวกกับดาวเทียมแบบจำลอง DAIN และ Multi Class Mean Bias Correction (WNI-GsMAP-DAIN-MMBC)
Optimizer	Adam	Adam	Adam	Adam
Learning Rate	0.00001	0.00001	0.00001	0.00001
Batch Size	2	2	2	2
Early Stopping patience	7	7	7	7
Dropout Rate	-	-	-	-
Loss Function	MSE, WMSE	MSE, WMSE	MSE, WMSE	MSE, WMSE

สำหรับสมการ MSE ที่ใช้ในทดลองจะเป็นดังสมการที่ 5

$$MSE = \frac{1}{N \times H \times W} \sum_{n=1}^N \sum_{i=1}^H \sum_{j=1}^W (x_{n,i,j} - \hat{x}_{n,i,j})^2 \quad (5)$$

โดยที่	N	แทนจำนวนของข้อมูล
	H	แทนขนาดความสูงของข้อมูล
	W	แทนขนาดความกว้างของข้อมูล
	$x_{n,i,j}$	แทนค่าที่ทำนายได้
	$\hat{x}_{n,i,j}$	แทนค่าจากผลเฉลย

สำหรับสมการ WMSE ที่ใช้ในการทดลองจะเป็นดังสมการที่ 6

$$\text{WMSE} = \frac{1}{N \times H \times W} \sum_{n=1}^N \sum_{i=1}^H \sum_{j=1}^W w_{n,i,j} (x_{n,i,j} - \hat{x}_{n,i,j})^2 \quad (6)$$

โดยที่	N	แทนจำนวนของข้อมูล
	H	แทนขนาดความสูงของข้อมูล
	W	แทนขนาดความกว้างของข้อมูล
	$x_{n,i,j}$	แทนค่าที่ทำนายได้
	$\hat{x}_{n,i,j}$	แทนค่าจากผลเฉลย
	$w_{n,i,j}$	แทนค่าน้ำหนักที่มีการแก้ไข ณ ชั้นเวลาของข้อมูลและตำแหน่งของข้อมูลที่ $n, i, j$

พจน์  $w$  หมายถึงพจน์น้ำหนักค่าความผิดพลาด (ค่า Error) ซึ่งจะขึ้นอยู่กับคลาสของปริมาณน้ำฝนในข้อมูลดังนี้

$$w(x) = \begin{cases} n_1, x < 1 \\ n_2, 1 \leq x < 10 \\ n_3, 10 \leq x < 30 \\ n_4, x \geq 30 \end{cases}$$

และพจน์  $n_1, n_2, n_3, n_4$  จะหมายถึงค่าน้ำหนักสำหรับค่าความผิดพลาดตามเงื่อนไขค่าปริมาณน้ำฝนจำนวน  $x$

ในงานวิจัยนี้จะมีการคำนวณค่าน้ำหนักสำหรับค่าความผิดพลาดของปริมาณน้ำฝนในแต่ละคลาส (พจน์  $n_1, n_2, n_3, n_4$ ) ด้วยวิธีการ Balances Custom Weights[13] ซึ่งเป็นวิธีการในการคำนวณค่าน้ำหนักในแต่ละคลาสสำหรับใช้ในการปรับแก้ค่าน้ำหนักเอง โดยอ้างอิงจากไลบรารี Scikit-learn[14] ซึ่งเป็นไลบรารีในภาษาไพธอนที่ใช้พัฒนาโปรแกรมสำหรับการใช้พัฒนาการเรียนรู้ด้วยเครื่อง เพื่อใช้แก้ปัญหาจำนวนคลาสในชุดข้อมูลฝึกที่ไม่สมดุลกัน (Class Imbalance) มีสมการดังสมการที่ 7

$$w_j = \frac{n_s}{(n_c \times n_j)} \quad (7)$$

โดยที่	$w_j$	แทนค่าน้ำหนักสำหรับค่าความผิดพลาดของคลาส $j$
--------	-------	--

$n_s$	แทนจำนวนตัวอย่าง (Sample) ทั้งหมดในชุดข้อมูล
$n_c$	แทนจำนวนคลาส (Class) ทั้งหมดในชุดข้อมูล
$n_j$	แทนจำนวนตัวอย่าง (Sample) ทั้งหมดของคลาส (Class) $j$

และค่าสำหรับพจน์  $n_1, n_2, n_3, n_4$  ในการทดลองนี้จะถูกแทนค่าใน 3 รูปแบบอันได้แก่ 1,3,10,30 ตามลำดับ 1,10,30,70 ตามลำดับและค่าที่ได้จากกระบวนการการคิดค่าน้ำหนักในแบบจำลองเองแบบ Balanced Class Weights ซึ่งในการสรุปผลการทดลองการทดลองปรับค่าน้ำหนักในแบบจำลองเองสำหรับงานวิจัยชิ้นนี้จะพิจารณาผลจากการใช้วิธีการปรับค่าน้ำหนักในแบบจำลองด้วยกระบวนการการคิดค่าน้ำหนักในแบบจำลองเองแบบ Balanced Class Weights เป็นหลัก เนื่องจากการทดลองแทนค่าอันได้แก่ 1,3,10,30 ตามลำดับ 1,10,30,70 ตามลำดับนั้นพบว่าไม่พบความแตกต่างอย่างมีนัยยะสำคัญ ดังนั้นผู้วิจัยจึงแนะนำให้ใช้วิธีการ Balanced Custom Weights อันเป็นวิธีการมาตรฐานในตัวเล่มนี้ ซึ่งผลลัพธ์จากการทดลองฝึกสอนแบบจำลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักค่าความผิดพลาดสำหรับปริมาณน้ำฝนในแต่ละช่วงที่มีการตั้งค่าด้วยตนเองที่ไม่มีหลักการในการประเมินค่าน้ำหนัก สามารถดูผลลัพธ์การทดลองได้ในภาคผนวก

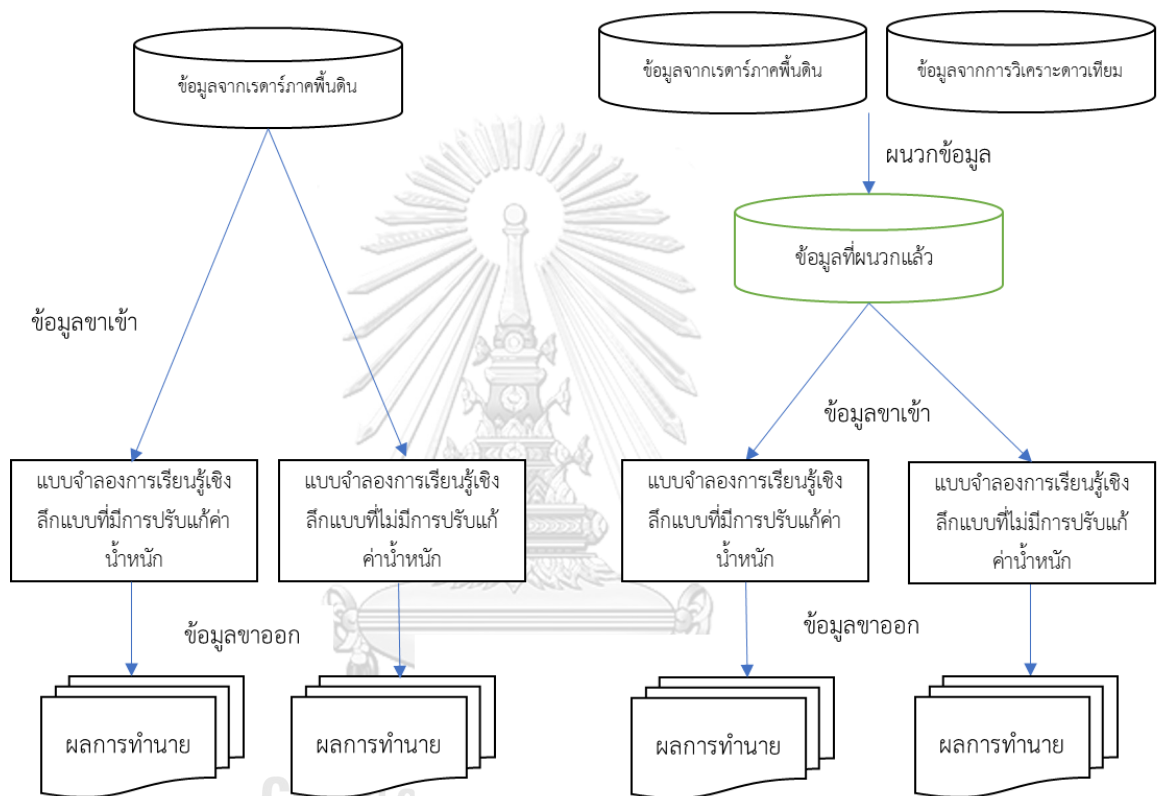
#### 4.4 ชุดข้อมูลที่ใช้ฝึกแบบจำลองการเรียนรู้เชิงลึก

ในการทดลองนี้ได้ใช้ชุดข้อมูลปริมาณน้ำฝนรูปแบบต่างๆ โดยในการฝึกแบบจำลองการเรียนรู้เชิงลึกจะแบ่งตามชุดข้อมูลที่ใช้ในการฝึกออกเป็น 4 ชุด คือ

- 1) ชุดที่ถูกฝึกด้วยชุดข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินอย่างเดียว (WNI)
- 2) ชุดที่ถูกฝึกโดยชุดข้อมูลปริมาณน้ำฝนที่ได้จากการผสมผสานข้อมูลสองแหล่งเข้าด้วยกันและมีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN (WNI-GsMAP-DAIN)
- 3) ชุดที่ถูกฝึกด้วยชุดข้อมูลปริมาณน้ำฝนที่ได้จากการผสมผสานข้อมูลสองแหล่งเข้าด้วยกัน มีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN และมีการปรับค่าอคติในข้อมูลปริมาณน้ำฝนของข้อมูล GsMAP ด้วยกระบวนการ Mean Bias Correction (WNI-GsMAP-DAIN-MBC)
- 4) ชุดที่ถูกฝึกด้วยชุดข้อมูลปริมาณน้ำฝนที่ได้จากการผสมผสานข้อมูลสองแหล่งเข้าด้วยกัน มีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN และมีการปรับค่าอคติในข้อมูล

ปริมาณน้ำฝนของข้อมูล GsMAP ด้วยกระบวนการ Multi Class Mean Bias Correction (WNI-GsMAP-DAIN-MMBC)

โดยทั้งสี่ชุดจะมีข้อมูลผลเฉลยคือข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินอย่างเดียว และมีภาพรวมการทดลองโดยสังเขปตามรูปที่ 21



รูปที่ 21 ภาพรวมขั้นตอนแนวทางการฝึกแบบจำลองการเรียนรู้เชิงลึก



## บทที่ 5

### บทสรุปของงานวิจัยและอภิปรายผลการวิจัย

บทนี้จะเป็นการอธิบายการทดลองและสรุปผลการทดลอง ซึ่งจะประกอบไปด้วยชุดข้อมูลที่ใช้ฝึกแบบจำลอง ชุดข้อมูลที่ใช้วัดประสิทธิภาพการทำนาย การสรุปผลการทดลองจากการทำนาย ปริมาณน้ำฝนด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพการทำนายจากแบบจำลองที่ผ่านการฝึกด้วยชุดข้อมูลรูปแบบต่างๆ รวมไปถึงจากแบบจำลองที่ผ่านการฝึกสอนด้วยการแก้ค่าน้ำหนักค่าความสูญเสีย

#### 5.1 การแบ่งชุดข้อมูลในการฝึกสอนแบบจำลอง

ในการแบ่งชุดข้อมูลสำหรับการฝึกสอนนั้น ได้มีการแบ่งชุดข้อมูลในรูปแบบตามตารางที่ 11 และข้อมูลที่ใช้ฝึกแต่ละประเภทนั้น จะมีจำนวนข้อมูลขาเข้าตามจำนวนขั้นตอนเวลา (Timestep) เป็นจำนวน 3 ขั้นตอนเวลา และ จำนวนข้อมูลขาออกที่เป็นผลลัพธ์ตามขั้นตอนเวลาเป็นจำนวน 3 ขั้นตอนเวลา ดังที่ระบุในตารางที่ 12

ตารางที่ 11 จำนวนชุดข้อมูลในข้อมูลการสอน ข้อมูลตรวจสอบ และข้อมูลทดสอบ

ชุดข้อมูล	ชุดข้อมูลฝึกสอน (Train)	ชุดข้อมูลตรวจสอบ (Validation)	ชุดข้อมูลทดสอบ (Test)
เรดาร์ภาคพื้นดิน(WNI)	17,422	1,742	1,742
เรดาร์ภาคพื้นดินผนวกกับดาวเทียม และแบบจำลอง DAIN (WNI-GsMAP- DAIN)	17,422	1,742	1,742
เรดาร์ภาคพื้นดินผนวกกับดาวเทียม แบบจำลอง DAIN และ Mean Bias Correction (WNI-GsMAP-DAIN-MBC)	17,422	1,742	1,742
เรดาร์ภาคพื้นดินผนวกกับดาวเทียม แบบจำลอง DAIN และ Multi Class Mean Bias Correction (WNI-GsMAP-DAIN-MMBC)	17,422	1,742	1,742

ตารางที่ 12 จำนวนข้อมูลขาเข้าตามจำนวนขั้นตอนเวลาและจำนวนข้อมูลขาออกตามจำนวนขั้นตอนเวลาที่ใช้ในชุดข้อมูลต่างๆ

ชุดข้อมูล	ชุดข้อมูลต่างๆที่ใช้ฝึกสอน		ชุดข้อมูลที่ตรวจสอบประสิทธิภาพ	
	ขั้นตอนเวลาขาเข้า	ขั้นตอนเวลาขาออก	ขั้นตอนเวลาขาเข้า	ขั้นตอนเวลาขาออก
	เข้า	ออก	เข้า	ออก
WNI	3	3	3	3
WNI-GsMAP-DAIN	3	3	3	3
WNI-GsMAP-DAIN-MBC	3	3	3	3
WNI-GsMAP-DAIN-MMBC	3	3	3	3

### 5.3 การประเมินประสิทธิภาพการทำนาย (Performance Evaluation)

ในการเปรียบเทียบประสิทธิภาพการทำนายด้วยแบบจำลองการเรียนรู้เชิงลึกด้วยชุดข้อมูลประเภทต่าง ๆ จะทำการทดสอบประสิทธิภาพบนชุดข้อมูลทดสอบ (Test Case) จำนวน 7 กรณีซึ่งเป็นชุดข้อมูลที่แยกออกมาจากข้อมูลที่ใช้ฝึกสอนแบบจำลอง และจะมีการตรวจสอบประสิทธิภาพการทำนายโดยใช้ค่า Root Mean Squared Error (RMSE) ค่า Critical Success Index (CSI) และ Multi-Class Critical Success Index (Multi-CSI) ซึ่งในบทที่ 2 มีการอธิบายกระบวนการประเมินประสิทธิภาพไว้แล้ว

### 5.4 ผลการทดลอง

ในหัวข้อนี้จะเป็นการอธิบายและสรุปผลการทดลองต่างๆ สำหรับผลการทดลองประสิทธิภาพการทำนายปริมาณน้ำฝนด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกฝึกสอนด้วยชุดข้อมูลแบบต่างๆ อันได้แก่

1. ชุดข้อมูลที่มีเพียงปริมาณน้ำฝนจากเรดาร์ภาคพื้นดิน (WNI)
2. ชุดข้อมูลปริมาณน้ำฝนที่ผสมระหว่างข้อมูลจากเรดาร์ภาคพื้นดินกับข้อมูลจากดาวเทียม และมีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN (WNI-GsMAP-DAIN)
3. ชุดข้อมูลปริมาณน้ำฝนที่ผสมระหว่างข้อมูลจากเรดาร์ภาคพื้นดินกับข้อมูลจากดาวเทียม มีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN และมีการปรับค่าอคติในข้อมูล

ปริมาณน้ำฝนของข้อมูล GsMAP ด้วยกระบวนการ Mean Bias Correction (WNI-GsMAP-DAIN-MBC)

4. ชุดข้อมูลปริมาณน้ำฝนที่ผสานระหว่างข้อมูลจากเรดาร์ภาคพื้นดินกับข้อมูลจากดาวเทียมมีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN และมีการปรับค่าอคติในข้อมูลปริมาณน้ำฝนของข้อมูล GsMAP ด้วยกระบวนการ Multi Class Mean Bias Correction (WNI-GsMAP-DAIN-MMBC)

โดยทั้งสี่ข้อมูลจะมีข้อมูลผลเฉลยเป็นชุดปริมาณน้ำฝนจากเรดาร์ภาคพื้นดิน และจะมีการแบ่งการแก้ค่าน้ำหนักในแบบจำลองเป็นสองรูปแบบคือ 1) มีการแก้ค่าน้ำหนักในแบบจำลอง และ 2) ไม่มีการแก้ค่าน้ำหนักในแบบจำลอง ในการทดลองนี้มีการฝึกแบบจำลองการเรียนรู้เชิงลึกและทดสอบชุดข้อมูลทั้งสองชุดด้วยแบบจำลอง UNet2D และมีผลลัพธ์การประเมินประสิทธิภาพการทำนายด้วยชุดข้อมูลปริมาณน้ำฝนสำหรับทดสอบประสิทธิภาพการทำนาย (Test Case) ทั้งหมด 7 กรณี

โดยในขั้นตอนการสรุปผลการทดลองการแก้ค่าน้ำหนักค่าความผิดพลาดในบนี้จะแบ่งเป็น

- 1) ผลการทดลองจากแบบจำลองไม่มีการแก้ค่าน้ำหนักในแบบจำลองการเรียนรู้สำหรับชุดข้อมูลปริมาณน้ำฝนสำหรับทดสอบประสิทธิภาพการทำนายที่ใช้ทดลองทั้ง 7 ชุด
- 2) ผลการทดลองจากแบบจำลองที่มีการแก้ค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักสำหรับค่าน้ำหนักของปริมาณน้ำฝนในแต่ละช่วง ตามค่าที่ได้จากการคำนวณจากสมการ Balanced Class Weights

ทั้งนี้ผู้วิจัยได้มีการทดลองสำหรับผลการทดลองแบบจำลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักค่าความผิดพลาดสำหรับปริมาณน้ำฝนในแต่ละช่วงที่มีการตั้งค่าด้วยตนเองที่ไม่มีหลักการในการประเมินค่าค่าน้ำหนัก (Manual Settings) เป็น [1,3,10,30] ตามลำดับ และผลการทดลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักค่าความผิดพลาดสำหรับปริมาณน้ำฝนในแต่ละช่วงมีการตั้งค่าด้วยตนเองที่ไม่มีหลักการในการประเมินค่าค่าน้ำหนัก เป็น [1,10,30,70] ตามลำดับนั้น พบว่าไม่พบความแตกต่างอย่างมีนัยยะสำคัญ ดังนั้นผู้วิจัยจึงแนะนำให้ใช้วิธีการ Balanced Custom Weights อันเป็นวิธีการ

มาตรฐานในตัวเล่มนี้ ซึ่งผลลัพธ์จากการทดลองฝึกสอนแบบจำลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักค่าความผิดพลาดสำหรับปริมาณน้ำฝนในแต่ละช่วงที่มีการตั้งค่าด้วยตนเองที่ไม่มีหลักการในการประเมินค่าน้ำหนัก สามารถดูผลลัพธ์การทดลองได้ในภาคผนวก

#### 5.4.1 ผลการทดลองจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลองการเรียนรู้

จากกรณีผลการทดลองจากชุดทดสอบทั้งหมด 7 ชุด ผลการทดลองจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลองการเรียนรู้ ได้ผลลัพธ์เป็นดังนี้

**จากชุดข้อมูลทดสอบชุดที่ 1** แบบจำลองการเรียนรู้เชิงลึกที่ถูกฝึกโดยชุดข้อมูลปริมาณน้ำฝนที่ได้จากการผสานข้อมูลสองแหล่งเข้าด้วยกันและมีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN (WNI-GsMAP-DAIN) ได้ผลลัพธ์การทำนายในเทอมของค่า Multi-CSI Class 2 และ Class 3 ที่ดีที่สุดที่ขึ้นตอนเวลา +1,+2,+3 รวมไปถึง ค่า Macro CSI ที่ออกมาดีที่สุดในเมื่อเทียบกับการฝึกด้วยชุดข้อมูลฝึกแบบอื่นๆ และค่า RMSE ที่ดีที่สุด ณ ขึ้นตอนเวลาที่ +2 และ +3

สำหรับค่า Binary CSI, Multi-CSI Class 0 และ Class 1 นั้น แบบจำลองที่ฝึกด้วยชุดข้อมูลปริมาณน้ำฝนที่ผสานระหว่างข้อมูลจากเรดาร์ภาคพื้นดินกับข้อมูลจากดาวเทียมมีการเพิ่มอัตราภาคของข้อมูล GsMAP ด้วยแบบจำลอง DAIN และมีการปรับค่าอคติในข้อมูลปริมาณน้ำฝนของข้อมูล GsMAP ด้วยกระบวนการ Mean Bias Correction (WNI-GsMAP-DAIN-MBC) ได้ผลลัพธ์การทำนายที่ดีที่สุดที่ ขึ้นตอนเวลา +2,+3 สำหรับ Multi-CSI Class 1 และ Binary CSI ที่ขึ้นตอนเวลา +1, +2

**จากชุดข้อมูลทดสอบชุดที่ 2** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI, Multi-CSI Class 0, Class 1 และ Class 2 รวมไปถึงในเทอมของ Macro CSI, Micro CSI และ RMSE โดยที่ Binary CSI นั้นมีผลลัพธ์การทำนายที่ดีที่สุดที่ขึ้นตอนเวลาที่ +1,+2 และ +3 ในส่วนของ Multi-CSI Class 0 และ Class 1 นั้นมีผลลัพธ์การทำนายที่ดีที่สุดที่ขึ้นตอนเวลาที่ +1,+2 และ +3 ในส่วนของ Multi-CSI Class 2 นั้นมีผลลัพธ์การทำนายที่ดีที่สุดที่ขึ้นตอนเวลาที่ +1 ในเทอมของ Macro CSI, Micro CSI และ RMSE นั้น ได้ผลลัพธ์การทำนายที่ดีที่สุดที่ขึ้นตอนเวลาที่ +1,+2 และ +3

**จากชุดข้อมูลทดสอบชุดที่ 3** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI, Multi-CSI Class 2, Multi-CSI Class 3 และ Macro CSI โดยได้ผลลัพธ์ที่ดีที่สุดในช่วงเวลาที่ +1,+2 และ +3 สำหรับค่า RMSE นั้นได้ผลลัพธ์ที่ดีที่สุดที่ช่วงเวลาที่ +2 และ +3

ในส่วนของเทอม Multi-CSI Class 0, Multi-CSI Class 1 นั้น แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดินอย่างเดียว (WNI) นั้นได้ผลลัพธ์การทำนายที่ดีที่สุดที่ช่วงเวลาที่ +1,+2,+3 สำหรับ Multi-CSI Class 0 และ ช่วงเวลาที่ +1,+2 สำหรับ Multi-CSI Class 1

**จากชุดข้อมูลทดสอบชุดที่ 4** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN นั้นให้ผลลัพธ์การทำนายได้ดีที่สุดในทุกๆเทอมซึ่งประกอบไปด้วย Binary CSI, Multi-CSI, Macro CSI, Micro CSI และ RMSE ในทุกช่วงเวลาที่


**จากชุดข้อมูลทดสอบชุดที่ 5** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN นั้นให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI, Multi-CSI, Macro CSI, Micro CSI และ RMSE โดยที่ในเทอมของ Binary CSI, Multi-CSI Class 2, Marco CSI, Micro CSI, RMSE ได้ผลลัพธ์ที่ดีที่สุดในช่วงเวลาที่ +1, +2, +3 ในเทอมของ Multi-CSI Class 0, Multi-CSI Class 1 ณ ช่วงเวลาที่ +1,+3

**จากชุดข้อมูลทดสอบชุดที่ 6** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN นั้นให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI, Multi-CSI Class 0, Multi-CSI Class 1 , Multi-CSI Class 2, Marco CSI, Micro CSI และ RMSE โดย Binary CSI, Multi-CSI Class 0, Multi-CSI Class 1, Marco CSI, Micro CSI RMSE ได้ผลลัพธ์ที่ดีที่สุด ณ ช่วงเวลาที่ +1, +2 และ +3

**จากชุดข้อมูลทดสอบชุดที่ 7** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN นั้นให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI, Multi-CSI Class 0, Multi-CSI Class 1 , Multi-CSI Class 2, Marco CSI, Micro CSI และ RMSE โดย Binary CSI, Multi-CSI Class 0, Multi-CSI Class 1, Marco CSI, Micro CSI RMSE ได้ผลลัพธ์ที่ดีที่สุด ณ ช่วงเวลาที่ +1, +2 และ +3

ตารางที่ 13 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 1 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
1	Binary CSI↑		0.7153	0.6625	0.6190	0.6656	0.7277	0.6683	0.6390	0.6784
	Multi-CSI↑	Class 0	0.9653	0.9585	0.9522	0.9587	0.9654	0.9576	0.9530	0.9587
		Class 1	0.5516	0.5005	0.4625	0.5049	0.5207	0.4884	0.4683	0.4925
		Class 2	0.1087	0.0631	0.0196	0.0638	0.2798	0.1959	0.1388	0.2048
		Class 3	0.0045	0.0000	0.0000	0.0015	0.1086	0.0228	0.0052	0.0455
	Macro CSI↑		0.4075	0.3805	0.3586	0.3822	0.4686	0.4162	0.3913	0.4254
	Micro CSI↑		0.8968	0.8847	0.8736	0.8850	0.8952	0.8835	0.8751	0.8846
	RMSE↓		2.7704	2.9826	3.1942	2.9824	2.6565	2.7962	2.9493	2.8006
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
	Binary CSI↑		0.7302	0.6709	0.6301	0.6771	0.6470	0.6187	0.5944	0.6200
	0.0411	0.0006	0.0000	0.0139	0.9529	0.9593	0.9542	0.9508	0.9465	0.9505
		Class 1	0.5506	0.5038	0.4731	0.5091	0.4850	0.4600	0.4424	0.4625
		Class 2	0.2405	0.1318	0.0649	0.1457	0.0407	0.0050	0.0047	0.0168
		Class 3	0.0411	0.0006	0.0000	0.0139	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.4497	0.3987	0.3727	0.4070	0.3839	0.3548	0.3488	0.3625
Micro CSI↑		0.8997	0.8848	0.8753	0.8866	0.8858	0.8749	0.8674	0.8760	
RMSE↓		2.5732	2.8849	3.0696	2.8426	2.9847	3.1602	3.2305	3.1251	

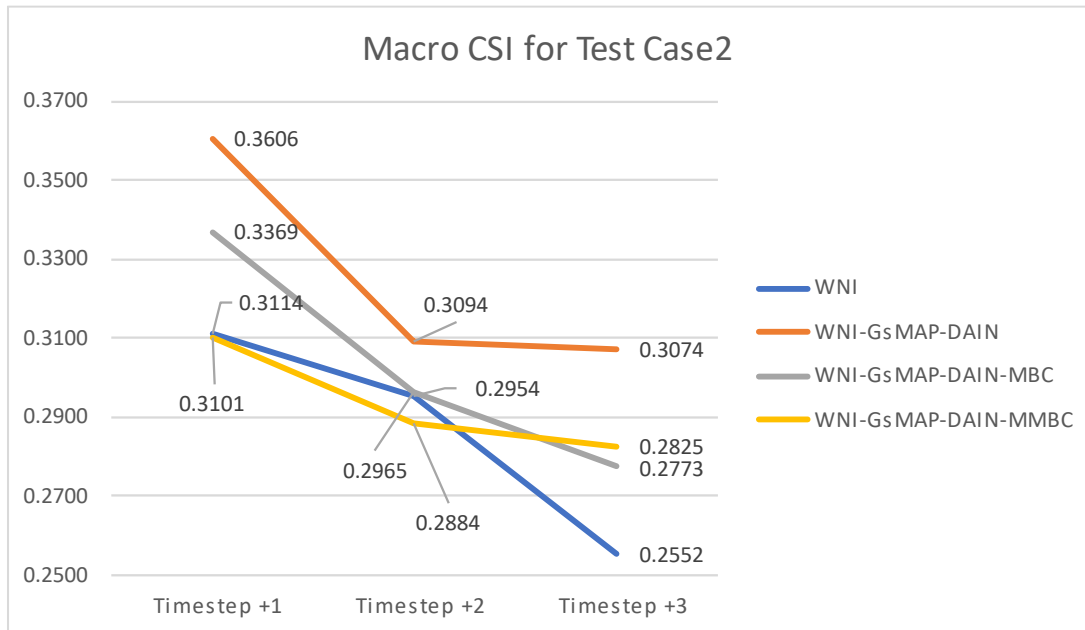


รูปที่ 22 กราฟเส้นเปรียบเทียบผลลัพธ์การทำงานจากชุดข้อมูลทดสอบชุดที่ 1 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI

ตารางที่ 14 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 2 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
2	Binary CSI↑		0.4902	0.4273	0.2568	0.3914	0.6672	0.4829	0.4705	0.5402
	Multi-CSI↑	Class 0	0.9110	0.9014	0.8768	0.8964	0.9388	0.9087	0.9068	0.9181
		Class 1	0.3344	0.2801	0.1440	0.2528	0.5033	0.3287	0.3227	0.3849
		Class 2	0.0000	0.0000	0.0000	0.0000	0.0003	0.0000	0.0000	0.0001
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.3114	0.2954	0.2552	0.2873	0.3606	0.3094	0.3074	0.3258
	Micro CSI↑		0.8061	0.7921	0.7596	0.7859	0.8496	0.8031	0.8015	0.8181
	RMSE↓		3.4387	3.5467	3.6124	3.5326	3.2261	3.5034	3.4972	3.4089
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
	Binary CSI↑		0.3884	0.3151	0.2886	0.3307	0.5858	0.4383	0.3584	0.4608
	Multi-CSI↑	Class 0	0.8945	0.8835	0.8796	0.8859	0.9252	0.9021	0.8904	0.9059
		Class 1	0.3871	0.3114	0.2776	0.3254	0.4223	0.2837	0.2187	0.3082
		Class 2	0.0001	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
Macro CSI↑		0.3369	0.2965	0.2773	0.3035	0.3101	0.2884	0.2825	0.2937	
Micro CSI↑		0.8278	0.7922	0.7765	0.7988	0.8008	0.7833	0.7793	0.7878	
RMSE↓		3.6728	3.7562	3.7207	3.7166	3.3556	3.5442	3.5669	3.4889	






รูปที่ 23 กราฟเส้นเปรียบเทียบผลลัพธ์การทำงานจากชุดข้อมูลทดสอบชุดที่ 2 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI

ตารางที่ 15 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ


Test Case	Metrics	WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที				
		ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)				
		1	2	3	avg	1	2	3	avg	
3	Binary CSI↑	0.6191	0.5480	0.4821	0.5497	0.6261	0.5526	0.4911	0.5566	
	Multi-CSI↑	Class 0	0.9855	0.9824	0.9798	0.9826	0.9846	0.9823	0.9798	0.9822
		Class 1	0.5012	0.4350	0.3803	0.4388	0.4769	0.4317	0.3846	0.4311
		Class 2	0.2348	0.1276	0.0318	0.1314	0.3122	0.1999	0.0900	0.2007
		Class 3	0.0376	0.0016	0.0000	0.0131	0.1322	0.0076	0.0000	0.0466
	Macro CSI↑	0.4398	0.3867	0.3480	0.3915	0.4765	0.4054	0.3636	0.4152	
	Micro CSI↑	0.9643	0.9579	0.9529	0.9584	0.9607	0.9577	0.9529	0.9571	
	RMSE↓	1.1351	1.2862	1.4107	1.2773	1.1889	1.2591	1.3750	1.2743	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที				
		ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.5416	0.4728	0.4164	0.4769	0.6243	0.5496	0.4822	0.5520	
	Multi-CSI↑	Class 0	0.9817	0.9793	0.9766	0.9792	0.9848	0.9822	0.9798	0.9823
		Class 1	0.4308	0.3721	0.3284	0.3771	0.4878	0.4308	0.3786	0.4324
		Class 2	0.1315	0.0334	0.0059	0.0569	0.2975	0.1568	0.0302	0.1615
		Class 3	0.0038	0.0000	0.0000	0.0013	0.0743	0.0001	0.0000	0.0248
Macro CSI↑	0.4611	0.3925	0.3472	0.4002	0.3886	0.3448	0.3312	0.3549		
Micro CSI↑	0.9621	0.9572	0.9529	0.9574	0.9586	0.9534	0.9484	0.9534		
RMSE↓	1.3017	1.4121	1.4800	1.3979	1.1615	1.3041	1.4249	1.2968		



รูปที่ 24-กราฟเส้นเปรียบเทียบผลลัพธ์การคำนวณจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI

ตารางที่ 16 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 4 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ


Test Case	Metrics	WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที				
		ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)				
		1	2	3	avg	1	2	3	avg	
4	Binary CSI↑	0.6641	0.6040	0.5256	0.5979	0.7677	0.6993	0.6748	0.7139	
	Multi-CSI↑	Class 0	0.9638	0.9578	0.9500	0.9572	0.9746	0.9672	0.9642	0.9687
		Class 1	0.5734	0.5205	0.4513	0.5151	0.6794	0.6131	0.5936	0.6287
		Class 2	0.1219	0.0922	0.0338	0.0826	0.1899	0.1333	0.1038	0.1424
		Class 3	0.0119	0.0005	0.0000	0.0041	0.0326	0.0008	0.0000	0.0111
	Macro CSI↑	0.4177	0.3927	0.3588	0.3897	0.4691	0.4286	0.4154	0.4377	
	Micro CSI↑	0.9177	0.9082	0.8960	0.9073	0.9367	0.9241	0.9197	0.9269	
	RMSE↓	1.9136	2.0390	2.0486	2.0004	1.7860	1.9504	1.9199	1.8854	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที				
		ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.7490	0.6653	0.6111	0.6751	0.6198	0.5494	0.4991	0.5561	
	Multi-CSI↑	Class 0	0.9724	0.9639	0.9582	0.9648	0.9590	0.9521	0.9467	0.9526
		Class 1	0.6585	0.5782	0.5312	0.5893	0.5367	0.4736	0.4302	0.4802
		Class 2	0.1550	0.0770	0.0361	0.0894	0.0647	0.0202	0.0008	0.0286
		Class 3	0.0121	0.0000	0.0000	0.0040	0.0025	0.0000	0.0000	0.0008
Macro CSI↑	0.3946	0.3623	0.3460	0.3676	0.4495	0.4048	0.3814	0.4119		
Micro CSI↑	0.9103	0.8983	0.8918	0.9001	0.9327	0.9182	0.9095	0.9201		
RMSE↓	1.8572	2.0327	2.0147	1.9682	1.9836	2.1223	2.0834	2.0631		



รูปที่ 25 กราฟเส้นเปรียบเทียบผลลัพธ์การคำนวณจากชุดข้อมูลทดสอบชุดที่ 4 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI

ตารางที่ 17 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 5 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที				
		ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)				
		1	2	3	avg	1	2	3	avg	
5	Binary CSI↑	0.6365	0.5941	0.4730	0.5679	0.7180	0.6032	0.5534	0.6249	
	Multi-CSI↑	Class 0	0.9406	0.9321	0.9145	0.9291	0.9505	0.9333	0.9245	0.9361
		Class 1	0.4985	0.4616	0.3469	0.4357	0.5939	0.4733	0.4280	0.4984
		Class 2	0.0696	0.0705	0.0138	0.0513	0.2289	0.0924	0.0578	0.1264
		Class 3	0.0037	0.0057	0.0000	0.0031	0.0815	0.0002	0.0000	0.0272
	Macro CSI↑	0.3781	0.3675	0.3188	0.3548	0.4637	0.3748	0.3526	0.3970	
	Micro CSI↑	0.8647	0.8516	0.8230	0.8464	0.8860	0.8545	0.8401	0.8602	
	RMSE↓	2.5327	2.6039	2.8810	2.6725	2.1224	2.5839	2.7597	2.4887	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที				
		ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.6137	0.5159	0.4110	0.5135	0.7072	0.6130	0.5454	0.6219	
	Multi-CSI↑	Class 0	0.9348	0.9205	0.9050	0.9201	0.9486	0.9338	0.9229	0.9351
		Class 1	0.4845	0.3921	0.2976	0.3914	0.5815	0.4815	0.4189	0.4939
		Class 2	0.0193	0.0014	0.0001	0.0069	0.1568	0.0268	0.0094	0.0643
Class 3		0.0000	0.0000	0.0000	0.0000	0.0087	0.0000	0.0000	0.0029	
Macro CSI↑	0.4239	0.3605	0.3378	0.3741	0.3624	0.3248	0.3020	0.3297		
Micro CSI↑	0.8803	0.8538	0.8366	0.8569	0.8538	0.8283	0.8075	0.8299		
RMSE↓	2.6778	2.8822	3.0404	2.8668	2.3411	2.6971	2.8694	2.6359		




รูปที่ 26 กราฟเส้นเปรียบเทียบผลลัพธ์การทำงานจากชุดข้อมูลทดสอบชุดที่ 5 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI

ตารางที่ 18 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 6 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
6	Binary CSI↑		0.5411	0.4792	0.3135	0.4446	0.6962	0.5297	0.4838	0.5699
	Multi-CSI↑	Class 0	0.8846	0.8730	0.8395	0.8657	0.9186	0.8822	0.8725	0.8911
		Class 1	0.3668	0.3162	0.1852	0.2894	0.5099	0.3610	0.3243	0.3984
		Class 2	0.0000	0.0000	0.0000	0.0000	0.0005	0.0000	0.0000	0.0002
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.3128	0.2973	0.2562	0.2888	0.3573	0.3108	0.2992	0.3224
	Micro CSI↑		0.7548	0.7406	0.6995	0.7316	0.8020	0.7530	0.7410	0.7653
	RMSE↓		4.4145	4.5001	4.6453	4.5200	4.1764	4.4842	4.5625	4.4077
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
	Binary CSI↑		0.4307	0.3379	0.2491	0.3392	0.6314	0.4713	0.3757	0.4928
	Multi-CSI↑	Class 0	0.8576	0.8420	0.8274	0.8423	0.9033	0.8701	0.8508	0.8748
		Class 1	0.3841	0.2909	0.2085	0.2945	0.4473	0.3054	0.2306	0.3278
		Class 2	0.0002	0.0000	0.0000	0.0001	0.0000	0.0000	0.0000	0.0000
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.3377	0.2939	0.2704	0.3006	0.3013	0.2791	0.2617	0.2807
Micro CSI↑		0.7802	0.7356	0.7123	0.7427	0.7376	0.7188	0.7035	0.7200	
RMSE↓		4.6159	4.7119	4.7738	4.7005	4.3340	4.5413	4.6332	4.5028	







รูปที่ 27 กราฟเส้นเปรียบเทียบผลลัพธ์การคำนวณจากชุดข้อมูลทดสอบชุดที่ 6 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI

ตารางที่ 19 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 7 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

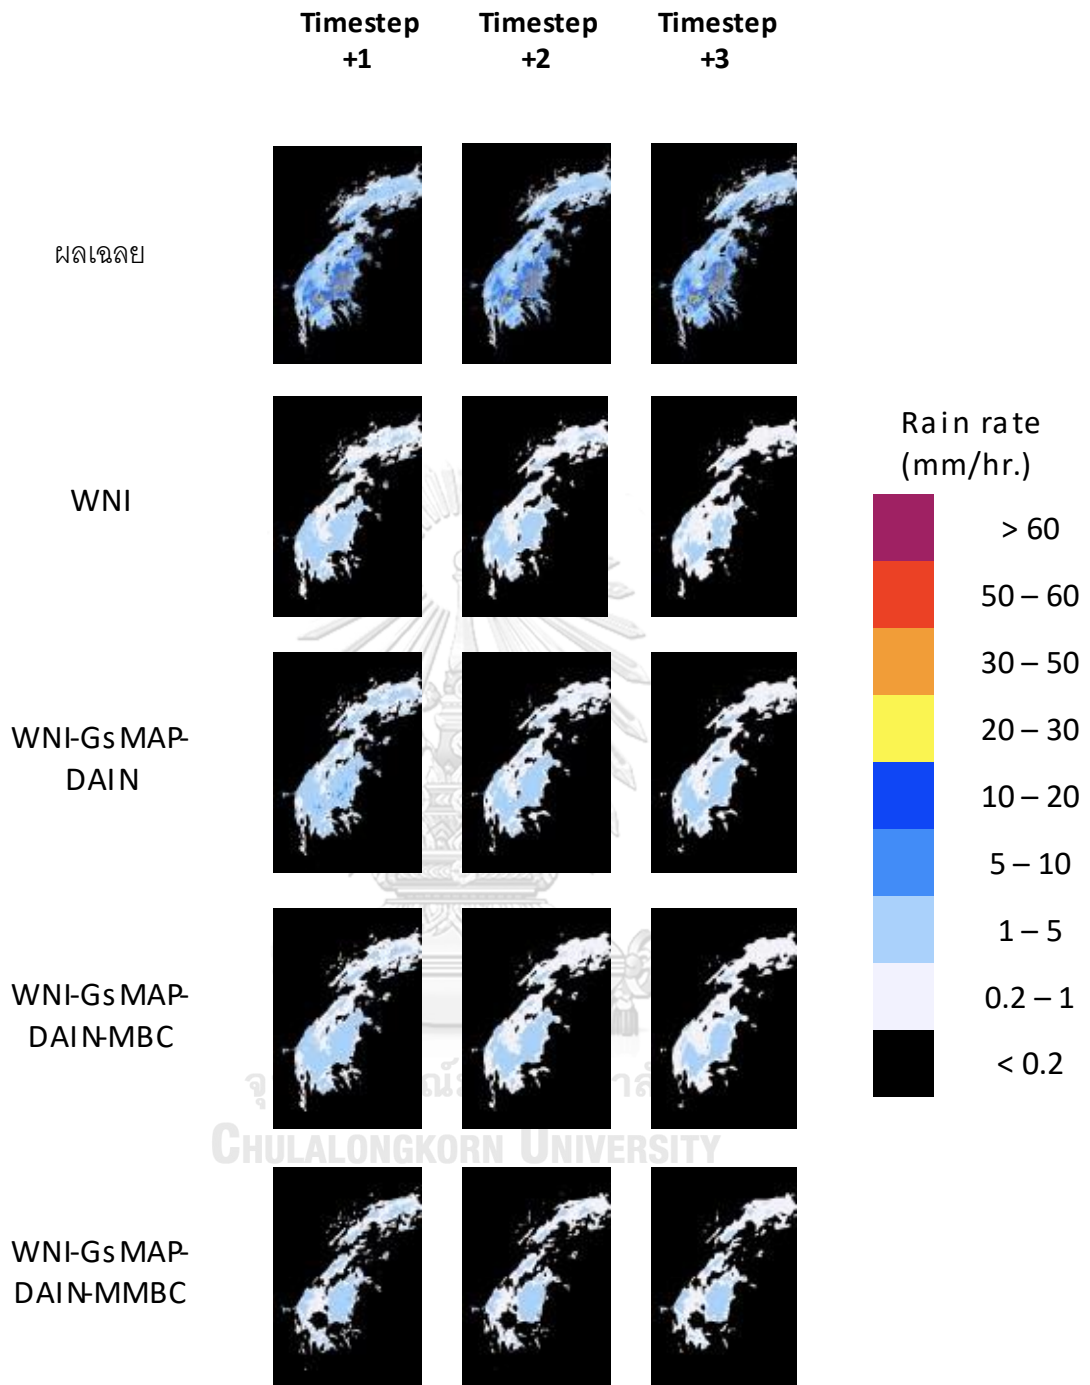
Test Case	Metrics		WNI อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
7	Binary CSI↑		0.6536	0.5985	0.5015	0.5845	0.7314	0.6344	0.5876	0.6511
	Multi-CSI↑	Class 0	0.9643	0.9582	0.9494	0.9573	0.9710	0.9611	0.9564	0.9628
		Class 1	0.5223	0.4757	0.3891	0.4624	0.6062	0.5113	0.4720	0.5298
		Class 2	0.0059	0.0046	0.0008	0.0038	0.0510	0.0038	0.0004	0.0184
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.3731	0.3596	0.3348	0.3559	0.4070	0.3691	0.3572	0.3778
	Micro CSI↑		0.9121	0.9022	0.8881	0.9008	0.9246	0.9073	0.8999	0.9106
	RMSE↓		2.1828	2.2644	2.3972	2.2815	1.9851	2.2066	2.2854	2.1590
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที			
			ขั้นตอนเวลา (Timestep)				ขั้นตอนเวลา (Timestep)			
			1	2	3	avg	1	2	3	avg
	Binary CSI↑		0.6066	0.5265	0.4349	0.5227	0.7107	0.6277	0.5571	0.6318
	Multi-CSI↑	Class 0	0.9589	0.9508	0.9423	0.9507	0.9691	0.9606	0.9539	0.9612
		Class 1	0.4827	0.4109	0.3286	0.4074	0.5806	0.5052	0.4440	0.5099
		Class 2	0.0037	0.0000	0.0000	0.0012	0.0056	0.0000	0.0000	0.0019
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
Macro CSI↑		0.3888	0.3664	0.3495	0.3682	0.3621	0.3358	0.3205	0.3395	
Micro CSI↑		0.9205	0.9063	0.8959	0.9076	0.9017	0.8874	0.8776	0.8889	
RMSE↓		2.1921	2.3570	2.4608	2.3366	2.1002	2.2610	2.3559	2.2390	



รูปที่ 28 กราฟเส้นเปรียบเทียบผลลัพธ์การคำนวณจากชุดข้อมูลทดสอบชุดที่ 7 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ฝึกด้วยชุดข้อมูลรูปแบบต่างๆ ในเทอมของ Macro CSI



รูปที่ 29 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยชุดข้อมูลในรูปแบบต่างๆ โดยไม่มีการแก้ไขค่าน้ำหนักเองในแบบจำลองการเรียนรู้เชิงลึกจากชุดข้อมูลทดสอบที่ 1



รูปที่ 30 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยชุดข้อมูลในรูปแบบต่างๆ โดยไม่มีการแก้ไขค่าน้ำหนักเองในแบบจำลองการเรียนรู้เชิงลึกจากชุดข้อมูลทดสอบที่ 2

#### 5.4.2 ผลการทดลองจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักในการฝึกแบบจำลองด้วยวิธี

##### Balanced Custom Weights

จากผลการทดลองการทำนายปริมาณน้ำฝนจากชุดข้อมูลสำหรับใช้ทดสอบประสิทธิภาพการทำนายทั้งหมด 7 ชุด ด้วยแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลองการเรียนรู้แบบ Balanced Custom Weights ได้ผลลัพธ์เป็นดังนี้

**จากชุดข้อมูลทดสอบชุดที่ 1** พบว่าทุกชุดข้อมูลที่ผ่านการผนวกแล้ว (ได้แก่ WNI-GsMAP-DAIN WNI-GsMAP-DAIN-MBC และ WNI-GsMAP-DAIN-MMBC) สามารถเพิ่มประสิทธิภาพการทำนายได้ดีกว่าการฝึกด้วยชุดข้อมูลที่ไม่ผ่านการผนวกข้อมูล (WNI) ซึ่ง ชุดข้อมูล WNI-GsMAP-DAIN-MMBC ช่วยให้แบบจำลองเรียนรู้ได้ดีที่สุด โดย

- ในเทอมของ Macro CSI เฉลี่ยนั้น WNI-GsMAP-DAIN ได้ค่าที่ 0.4166 WNI-GsMAP-DAIN-MBC ได้ค่าที่ 0.4023 WNI-GsMAP-DAIN-MMBC ได้ค่าที่ 0.4230 และ WNI ได้ค่าที่ 0.3234
- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN-MMBC ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 2.8348 ในขณะที่ชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่แย่ที่สุดที่ 6.6509
- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลางและฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ)

##### จากชุดข้อมูลทดสอบชุดที่ 2

- ในเทอมของ Macro CSI เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN-MBC สามารถเพิ่มประสิทธิภาพได้ดีที่สุดโดยได้ค่าผลลัพธ์ Macro CSI ที่ 0.4618 ซึ่งสูงกว่า ชุดข้อมูล WNI ที่ได้ค่าผลลัพธ์ Macro CSI ที่ 0.4434
- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 2.5634 ซึ่งสูงกว่าชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่ 2.6797
- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลางและฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก

แบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ)

**จากชุดข้อมูลทดสอบชุดที่ 3** พบว่าทุกชุดข้อมูลที่ผ่านมาการผนวกแล้ว (ได้แก่ WNI-GsMAP-DAIN WNI-GsMAP-DAIN-MBC และ WNI-GsMAP-DAIN-MMBC) สามารถเพิ่มประสิทธิภาพการทำนายได้ดีกว่าการฝึกด้วยชุดข้อมูลที่ไม่ผ่านการผนวกข้อมูล (WNI) ซึ่ง ชุดข้อมูล WNI-GsMAP-DAIN ช่วยให้แบบจำลองเรียนรู้ได้ดีที่สุด โดย

- ในเทอมของ Macro CSI เฉลี่ยนั้น WNI-GsMAP-DAIN ได้ค่าที่ 0.3869 WNI-GsMAP-DAIN-MBC ได้ค่าที่ 0.3654 WNI-GsMAP-DAIN-MMBC ได้ค่าที่ 0.3797 และ WNI ได้ค่าที่ 0.2932
- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 1.9211 ซึ่งสูงกว่าชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่ 4.5474
- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลางและฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก แบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ) ยกเว้นแบบจำลองที่ฝึกด้วยชุดข้อมูล WNI ที่ได้ผลลัพธ์ Multi-CSI คลาส 2 และคลาส 3 ที่แย่งลง

**จากชุดข้อมูลทดสอบชุดที่ 4** พบว่าทุกชุดข้อมูลที่ผ่านมาการผนวกแล้ว (ได้แก่ WNI-GsMAP-DAIN WNI-GsMAP-DAIN-MBC และ WNI-GsMAP-DAIN-MMBC) สามารถเพิ่มประสิทธิภาพการทำนายได้ดีกว่าการฝึกด้วยชุดข้อมูลที่ไม่ผ่านการผนวกข้อมูล (WNI) ซึ่ง ชุดข้อมูล WNI-GsMAP-DAIN ช่วยให้แบบจำลองเรียนรู้ได้ดีที่สุด โดย

- ในเทอมของ Macro CSI เฉลี่ยนั้น WNI-GsMAP-DAIN ได้ค่าที่ 0.4646 WNI-GsMAP-DAIN-MBC ได้ค่าที่ 0.4621 WNI-GsMAP-DAIN-MMBC ได้ค่าที่ 0.4609 และ WNI ได้ค่าที่ 0.3887
- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 2.0683 ซึ่งสูงกว่าชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่ 4.4084

- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลาง และฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก แบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ)

**จากชุดข้อมูลทดสอบชุดที่ 5** พบว่าทุกชุดข้อมูลที่ผ่านมาผ่านการผนวกแล้ว (ได้แก่ WNI-GsMAP-DAIN WNI-GsMAP-DAIN-MBC และ WNI-GsMAP-DAIN-MMBC) สามารถเพิ่มประสิทธิภาพการทำนายได้ดีกว่าการฝึกด้วยชุดข้อมูลที่ไม่ผ่านการผนวกข้อมูล (WNI) ซึ่ง ชุดข้อมูล WNI-GsMAP-DAIN-MBC ช่วยให้แบบจำลองเรียนรู้ได้ดีที่สุด โดย

- ในเทอมของ Macro CSI เฉลี่ยนั้น WNI-GsMAP-DAIN ได้ค่าที่ 0.4368 WNI-GsMAP-DAIN-MBC ได้ค่าที่ 0.4577 WNI-GsMAP-DAIN-MMBC ได้ค่าที่ 0.4499 และ WNI ได้ค่าที่ 0.3721
- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 2.4636 ซึ่งสูงกว่าชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่ 4.7927
- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลาง และฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก แบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ)

**จากชุดข้อมูลทดสอบชุดที่ 6** พบว่าบางชุดข้อมูลที่ผ่านมาผ่านการผนวกแล้ว (ได้แก่ WNI-GsMAP-DAIN และ WNI-GsMAP-DAIN-MBC) สามารถเพิ่มประสิทธิภาพการทำนายได้ดีกว่าการฝึกด้วยชุดข้อมูลที่ไม่ผ่านการผนวกข้อมูล (WNI) ซึ่ง ชุดข้อมูล WNI-GsMAP-DAIN-MBC ช่วยให้แบบจำลองเรียนรู้ได้ดีที่สุด โดย

- ในเทอมของ Macro CSI เฉลี่ยนั้น WNI-GsMAP-DAIN ได้ค่าที่ 0.3936 WNI-GsMAP-DAIN-MBC ได้ค่าที่ 0.4276 WNI-GsMAP-DAIN-MMBC ได้ค่าที่ 0.3620 และ WNI ได้ค่าที่ 0.3823



- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 3.3413 ซึ่งสูงกว่าชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่ 3.6105
- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลางและฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก แบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ)

**จากชุดข้อมูลทดสอบชุดที่ 7** พบว่าทุกชุดข้อมูลที่ผ่านการผนวกแล้ว (ได้แก่ WNI-GsMAP-DAIN WNI-GsMAP-DAIN-MBC และ WNI-GsMAP-DAIN-MMBC) สามารถเพิ่มประสิทธิภาพการทำนายได้ดีกว่าการฝึกด้วยชุดข้อมูลที่ไม่ผ่านการผนวกข้อมูล (WNI) ซึ่ง ชุดข้อมูล WNI-GsMAP-DAIN-MBC ช่วยให้แบบจำลองเรียนรู้ได้ดีที่สุด โดย

- ในเทอมของ Macro CSI เฉลี่ยนั้น WNI-GsMAP-DAIN ได้ค่าที่ 0.4365 WNI-GsMAP-DAIN-MBC ได้ค่าที่ 0.4711 WNI-GsMAP-DAIN-MMBC ได้ค่าที่ 0.4582 และ WNI ได้ค่าที่ 0.4211
- ในเทอมของ RMSE เฉลี่ยนั้น ชุดข้อมูล WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์ค่าที่ดีที่สุดที่ 1.8745 ซึ่งสูงกว่าชุดข้อมูล WNI ให้ผลลัพธ์ค่าที่ 2.3411
- เมื่อเปรียบเทียบค่า Multi-CSI คลาส 2 และคลาส 3 อันเป็นคลาสที่บ่งบอกฝนตกปานกลางและฝนตกหนัก พบว่า แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก แบบจำลองการเรียนรู้แบบ Balanced Custom Weights ให้ผลลัพธ์ที่ดีกว่า แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึก (โดยเทียบดูจากค่า Multi-CSI คลาส 2 และคลาส 3 ที่ได้จากแบบจำลองทั้งสองแบบ)

ตารางที่ 20 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 1 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
1	Binary CSI↑	0.5118	0.4379	0.4245	0.4581	0.6913	0.6173	0.5811	0.6299	
	Multi-CSI↑	Class 0	0.8953	0.8544	0.8438	0.8645	0.9550	0.9358	0.9245	0.9384
		Class 1	0.2519	0.1784	0.2120	0.2141	0.4254	0.3626	0.3596	0.3825
		Class 2	0.1320	0.0972	0.1485	0.1259	0.2657	0.2622	0.2417	0.2565
		Class 3	0.1021	0.0704	0.0951	0.0892	0.1814	0.0671	0.0188	0.0891
	Macro CSI↑	0.3453	0.3001	0.3249	0.3234	0.4569	0.4069	0.3861	0.4166	
	Micro CSI↑	0.7494	0.6819	0.6861	0.7058	0.8619	0.8298	0.8154	0.8357	
	RMSE↓	6.3961	8.1672	5.3894	6.6509	3.1366	3.2368	3.2497	3.2077	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.6664	0.6019	0.5591	0.6091	0.6903	0.6367	0.5959	0.6410	
	Multi-CSI↑	Class 0	0.9490	0.9301	0.9143	0.9311	0.9550	0.9421	0.9300	0.9424
		Class 1	0.3908	0.3007	0.2850	0.3255	0.4600	0.4030	0.3573	0.4068
		Class 2	0.2737	0.2120	0.2150	0.2336	0.3173	0.2843	0.2506	0.2840
		Class 3	0.1768	0.1135	0.0667	0.1190	0.1294	0.0346	0.0121	0.0587
Macro CSI↑	0.4476	0.3891	0.3702	0.4023	0.4654	0.4160	0.3875	0.4230		
Micro CSI↑	0.8498	0.8062	0.7850	0.8137	0.8719	0.8465	0.8223	0.8469		
RMSE↓	2.9758	3.7586	3.6332	3.4558	2.5973	2.8494	3.0578	2.8348		

ตารางที่ 21 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 2 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
2	Binary CSI↑	0.7367	0.6908	0.6638	0.6971	0.7874	0.7748	0.7223	0.7615	
	Multi-CSI↑	Class 0	0.9430	0.9263	0.9169	0.9287	0.9578	0.9539	0.9429	0.9516
		Class 1	0.6080	0.5578	0.5400	0.5686	0.6513	0.6271	0.5721	0.6168
		Class 2	0.2273	0.2960	0.2227	0.2487	0.2504	0.1414	0.0849	0.1589
		Class 3	0.0305	0.0459	0.0068	0.0278	0.0027	0.0011	0.0004	0.0014
	Macro CSI↑	0.4522	0.4565	0.4216	0.4434	0.4656	0.4309	0.4001	0.4322	
	Micro CSI↑	0.8645	0.8380	0.8238	0.8421	0.8882	0.8762	0.8576	0.8740	
	RMSE↓	2.4776	2.7650	2.7966	2.6797	2.4151	2.7107	2.8739	2.6666	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.7865	0.7832	0.7150	0.7616	0.4897	0.4603	0.4381	0.4627	
	Multi-CSI↑	Class 0	0.9578	0.9555	0.9430	0.9521	0.8962	0.8879	0.8806	0.8882
		Class 1	0.6714	0.6549	0.5771	0.6345	0.4398	0.4050	0.3790	0.4079
		Class 2	0.3539	0.2704	0.1493	0.2578	0.1301	0.1190	0.1130	0.1207
		Class 3	0.0077	0.0010	0.0000	0.0029	0.0096	0.0018	0.0015	0.0043
Macro CSI↑	0.4977	0.4704	0.4173	0.4618	0.3689	0.3534	0.3435	0.3553		
Micro CSI↑	0.8954	0.8858	0.8620	0.8811	0.8040	0.7897	0.7779	0.7905		
RMSE↓	2.3497	2.5977	2.7427	2.5634	3.6591	3.7689	3.7944	3.7408		

ตารางที่ 22 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
3	Binary CSI↑	0.3139	0.2489	0.2323	0.2650	0.5531	0.4661	0.3996	0.4730	
	Multi-CSI↑	Class 0	0.9324	0.9085	0.9016	0.9142	0.9761	0.9672	0.9577	0.9670
		Class 1	0.1531	0.1098	0.1241	0.1290	0.3565	0.2820	0.2363	0.2916
		Class 2	0.0867	0.0688	0.0980	0.0845	0.2274	0.2053	0.1787	0.2038
		Class 3	0.0574	0.0371	0.0405	0.0450	0.1375	0.0735	0.0445	0.0852
	Macro CSI↑	0.3074	0.2810	0.2910	0.2932	0.4244	0.3820	0.3543	0.3869	
	Micro CSI↑	0.8518	0.8106	0.8051	0.8225	0.9378	0.9206	0.9029	0.9204	
	RMSE↓	4.4010	5.3341	3.9072	4.5474	1.7644	1.9180	2.0807	1.9211	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.5131	0.4291	0.3628	0.4350	0.5296	0.4505	0.3916	0.4573	
	Multi-CSI↑	Class 0	0.9717	0.9609	0.9487	0.9605	0.9741	0.9654	0.9564	0.9653
		Class 1	0.3190	0.2282	0.1828	0.2433	0.3150	0.2504	0.2183	0.2612
		Class 2	0.2130	0.1495	0.1344	0.1656	0.2071	0.1862	0.1739	0.1891
		Class 3	0.1295	0.0804	0.0663	0.0921	0.1473	0.0963	0.0664	0.1033
Macro CSI↑	0.4083	0.3547	0.3331	0.3654	0.4109	0.3746	0.3537	0.3797		
Micro CSI↑	0.9287	0.9044	0.8822	0.9051	0.9321	0.9151	0.8992	0.9155		
RMSE↓	1.9266	2.7119	2.7856	2.4747	1.8184	2.0305	2.0980	1.9823		

ตารางที่ 23 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 4 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
4	Binary CSI↑	0.6229	0.5387	0.5023	0.5979	0.7622	0.6991	0.6454	0.7022	
	Multi-CSI↑	Class 0	0.9434	0.9194	0.9074	0.9572	0.9722	0.9620	0.9526	0.9622
		Class 1	0.4713	0.3498	0.3624	0.5151	0.6438	0.5721	0.5189	0.5783
		Class 2	0.1791	0.1014	0.1208	0.0826	0.2733	0.2290	0.1919	0.2314
		Class 3	0.1512	0.0809	0.0770	0.0041	0.1672	0.0423	0.0496	0.0863
	Macro CSI↑	0.4363	0.3629	0.3669	0.3897	0.5141	0.4513	0.4282	0.4646	
	Micro CSI↑	0.8666	0.8107	0.8040	0.9073	0.9279	0.9068	0.8891	0.9079	
	RMSE↓	3.4131	5.6606	4.1514	2.0004	1.8337	2.0984	2.2727	2.0683	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.7577	0.6899	0.6458	0.6978	0.7429	0.6899	0.6457	0.6928	
	Multi-CSI↑	Class 0	0.9710	0.9592	0.9513	0.9605	0.9676	0.9590	0.9512	0.9593
		Class 1	0.5978	0.5068	0.4833	0.5293	0.5861	0.5302	0.4897	0.5353
		Class 2	0.2461	0.2010	0.1879	0.2117	0.2646	0.2315	0.2072	0.2344
		Class 3	0.1924	0.1401	0.1083	0.1469	0.1920	0.1055	0.0466	0.1147
	Macro CSI↑	0.5018	0.4518	0.4327	0.4621	0.5026	0.4566	0.4237	0.4609	
Micro CSI↑	0.9180	0.8909	0.8796	0.8962	0.9126	0.8957	0.8815	0.8966		
RMSE↓	2.2069	2.6789	2.6481	2.5113	2.0263	2.2024	2.2807	2.1698		

ตารางที่ 24 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 5 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
5	Binary CSI↑	0.5607	0.4895	0.4715	0.5072	0.7029	0.6400	0.5910	0.6446	
	Multi-CSI↑	Class 0	0.8744	0.8330	0.8201	0.8425	0.9376	0.9199	0.9025	0.9200
		Class 1	0.4108	0.3158	0.3293	0.3520	0.5437	0.4857	0.4409	0.4901
		Class 2	0.2203	0.1389	0.1783	0.1792	0.3196	0.2831	0.2395	0.2808
		Class 3	0.1568	0.1046	0.0829	0.1148	0.1617	0.0041	0.0026	0.0561
	Macro CSI↑	0.4156	0.3481	0.3527	0.3721	0.4907	0.4232	0.3964	0.4368	
	Micro CSI↑	0.7583	0.6866	0.6835	0.7095	0.8584	0.8298	0.8018	0.8300	
	RMSE↓	4.0470	5.9573	4.3737	4.7927	2.2978	2.4185	2.6746	2.4636	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.6976	0.6302	0.5757	0.6345	0.7024	0.6357	0.5835	0.6405	
	Multi-CSI↑	Class 0	0.9346	0.9123	0.8868	0.9112	0.9374	0.9157	0.8936	0.9156
		Class 1	0.5546	0.4692	0.4193	0.4810	0.5413	0.4596	0.4131	0.4713
		Class 2	0.3464	0.2894	0.2475	0.2945	0.3259	0.2805	0.2545	0.2870
		Class 3	0.2010	0.1304	0.1008	0.1441	0.1909	0.1166	0.0694	0.1256
Macro CSI↑	0.5092	0.4503	0.4136	0.4577	0.4989	0.4431	0.4076	0.4499		
Micro CSI↑	0.8579	0.8164	0.7771	0.8171	0.8573	0.8175	0.7837	0.8195		
RMSE↓	2.1623	2.6391	3.0355	2.6123	2.3236	2.7199	2.9175	2.6536		


ตารางที่ 25 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 6 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
6	Binary CSI↑	0.6866	0.6130	0.5784	0.6260	0.7710	0.7157	0.6596	0.7154	
	Multi-CSI↑	Class 0	0.8920	0.8523	0.8352	0.8598	0.9319	0.9140	0.8947	0.9135
		Class 1	0.5412	0.4748	0.4450	0.4870	0.6065	0.5472	0.4969	0.5502
		Class 2	0.1590	0.1991	0.1158	0.1580	0.1850	0.0880	0.0580	0.1103
		Class 3	0.0231	0.0356	0.0141	0.0243	0.0011	0.0000	0.0000	0.0004
	Macro CSI↑	0.4038	0.3905	0.3525	0.3823	0.4311	0.3873	0.3624	0.3936	
	Micro CSI↑	0.7763	0.7261	0.7021	0.7348	0.8284	0.7986	0.7709	0.7993	
	RMSE↓	3.4107	3.6237	3.7972	3.6105	3.3322	3.6874	3.8889	3.6362	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.7928	0.7478	0.6928	0.7445	0.5683	0.5235	0.4901	0.5273	
	Multi-CSI↑	Class 0	0.9393	0.9243	0.9075	0.9237	0.8670	0.8497	0.8328	0.8498
		Class 1	0.6358	0.5871	0.5293	0.5841	0.4634	0.4149	0.3825	0.4203
		Class 2	0.2626	0.2100	0.1306	0.2011	0.1837	0.1643	0.1536	0.1672
		Class 3	0.0041	0.0003	0.0000	0.0015	0.0224	0.0070	0.0025	0.0106
Macro CSI↑	0.4604	0.4304	0.3918	0.4276	0.3841	0.3590	0.3429	0.3620		
Micro CSI↑	0.8439	0.8192	0.7916	0.8182	0.7507	0.7253	0.7023	0.7261		
RMSE↓	3.0962	3.3434	3.5844	3.3413	4.2080	4.3435	4.4422	4.3313		


ตารางที่ 26 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 7 จากแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในการฝึกแบบจำลอง ด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics	WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
7	Binary CSI↑	0.5792	0.4908	0.4676	0.5125	0.7360	0.6675	0.6120	0.6718	
	Multi-CSI↑	Class 0	0.9288	0.8991	0.8909	0.9063	0.9676	0.9560	0.9451	0.9562
		Class 1	0.4608	0.3677	0.3707	0.3997	0.6250	0.5534	0.5015	0.5600
		Class 2	0.3057	0.2342	0.2490	0.2630	0.2966	0.2156	0.1712	0.2278
		Class 3	0.1721	0.1255	0.0484	0.1153	0.0054	0.0000	0.0000	0.0018
	Macro CSI↑	0.4669	0.4066	0.3898	0.4211	0.4737	0.4313	0.4044	0.4365	
	Micro CSI↑	0.8532	0.8012	0.7952	0.8165	0.9212	0.8988	0.8792	0.8997	
	RMSE↓	2.0810	2.6782	2.2640	2.3411	1.7110	1.9220	2.0702	1.9011	
	Metrics	WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ Balanced Custom weights				
		Timestep				Timestep				
		1	2	3	avg	1	2	3	avg	
	Binary CSI↑	0.7338	0.6753	0.6241	0.6778	0.7176	0.6505	0.5960	0.6547	
	Multi-CSI↑	Class 0	0.9663	0.9560	0.9453	0.9559	0.9634	0.9509	0.9390	0.9511
		Class 1	0.6239	0.5593	0.5151	0.5661	0.5945	0.5232	0.4779	0.5318
		Class 2	0.3370	0.3043	0.2495	0.2970	0.3589	0.3119	0.2659	0.3122
		Class 3	0.0711	0.0742	0.0510	0.0654	0.0797	0.0308	0.0018	0.0374
Macro CSI↑	0.4996	0.4734	0.4402	0.4711	0.4991	0.4542	0.4212	0.4582		
Micro CSI↑	0.9194	0.8995	0.8808	0.8999	0.9122	0.8885	0.8685	0.8897		
RMSE↓	1.6611	1.8920	2.0705	1.8745	1.7477	1.9710	2.0912	1.9366		





รูปที่ 31 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยการฝึกด้วยชุดข้อมูลในรูปแบบต่างๆ โดยมีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights จากชุดข้อมูลทดสอบประสิทธิภาพที่ 1



รูปที่ 32 รูปภาพตัวอย่างผลลัพธ์การทำนายด้วยการฝึกด้วยชุดข้อมูลในรูปแบบต่างๆ โดยมีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights จากชุดข้อมูลทดสอบประสิทธิภาพที่ 2

## 5.5 สรุปผลลัพธ์ประสิทธิภาพการทำนายปริมาณน้ำฝนที่ได้จากการทดลองปรับค่าน้ำหนักค่า ความสูญเสียในการฝึกแบบจำลองการเรียนรู้เชิงลึกในรูปแบบต่างๆ และ ชุดข้อมูลฝึกสอน รูปแบบต่างๆ

หัวข้อนี้จะเป็นการสรุปผลลัพธ์ที่ได้จากการทดลองเปลี่ยนแปลงค่าน้ำหนักในแบบจำลองการเรียนรู้เชิงลึก ซึ่งมี 2 รูปแบบอันได้แก่ 1) แบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้ 2) แบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้ด้วยกระบวนการ Balances Custom Weights ซึ่งแบบจำลองทั้งสองรูปแบบนี้จะถูกฝึกด้วยชุดข้อมูลที่ใช้ในการฝึก 4 รูปแบบ และจะวัดประสิทธิภาพด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพโดยเฉพาะอีก 7 ชุด

สามารถสรุปในรูปแบบของตารางค่าเฉลี่ยผลลัพธ์จากทุกขั้นตอนเวลา (Timestep) สำหรับแต่ละตัวชี้วัดประสิทธิภาพ (Metric) ได้ดังตารางที่ 30 ถึงตารางที่ 50 ตามลำดับ โดยตัวหนาแทนค่าที่ดีที่สุดและตัวที่มีขีดเส้นใต้จะแทนที่ค่าที่ตรงลงมาสำหรับแต่ละตัวชี้วัดประสิทธิภาพ

### 5.5.1 สรุปผลลัพธ์จากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้

ตารางที่ 27 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 1

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.6656	<b>0.9587</b>	<u>0.5049</u>	0.0638	0.0015	0.3822	<u>0.8850</u>	2.9824
WNI-GsMAP-DAIN	<b>0.6784</b>	<b>0.9587</b>	0.4925	<b>0.2048</b>	<b>0.0455</b>	<b>0.4254</b>	0.8846	<b>2.8006</b>
WNI-GsMAP-DAIN-MBC	<u>0.6771</u>	<u>0.9593</u>	<b>0.5091</b>	<u>0.1457</u>	<u>0.0139</u>	<u>0.4070</u>	<b>0.8866</b>	<u>2.8426</u>
WNI-GsMAP-DAIN-MMBC	0.6200	0.9505	0.4625	0.0168	0.0000	0.3625	0.8760	3.1251

ตารางที่ 28 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 2

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.3914	0.8964	0.2528	0.0000	0.0000	0.2873	0.7859	3.5326
WNI-GsMAP-DAIN	<b>0.5402</b>	<b>0.9181</b>	<b>0.3849</b>	<b>0.0001</b>	0.0000	<b>0.3258</b>	<b>0.8181</b>	<b>3.4089</b>
WNI-GsMAP-DAIN-MBC	0.3307	0.8859	<u>0.3254</u>	0.0000	0.0000	<u>0.3035</u>	<u>0.7988</u>	3.7166
WNI-GsMAP-DAIN-MMBC	<u>0.4608</u>	<u>0.9059</u>	0.3082	0.0000	0.0000	0.2937	0.7878	<u>3.4889</u>

ตารางที่ 29 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลอง  
การเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 3

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.5497	<b>0.9826</b>	<b>0.4388</b>	0.1314	0.0131	0.3915	<b>0.9584</b>	<u>1.2773</u>
WNI-GsMAP-DAIN	<b>0.5566</b>	0.9822	0.4311	<b>0.2007</b>	<b>0.0466</b>	<b>0.4152</b>	0.9571	<b>1.2743</b>
WNI-GsMAP-DAIN-MBC	0.4769	0.9792	0.3771	0.0569	0.0013	<u>0.4002</u>	<u>0.9574</u>	1.3979
WNI-GsMAP-DAIN-MMBC	<u>0.5520</u>	<u>0.9823</u>	<u>0.4324</u>	<u>0.1615</u>	<u>0.0248</u>	0.3549	0.9534	1.2968

ตารางที่ 30 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลอง  
การเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 4

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.5979	0.9572	0.5151	0.0826	<u>0.0041</u>	0.3897	0.9073	2.0004
WNI-GsMAP-DAIN	<b>0.7139</b>	<b>0.9687</b>	<b>0.6287</b>	<b>0.1424</b>	<b>0.0111</b>	<b>0.4377</b>	<b>0.9269</b>	<b>1.8854</b>
WNI-GsMAP-DAIN-MBC	0.5561	0.9526	0.4802	0.0286	0.0008	<u>0.4119</u>	<u>0.9201</u>	2.0631
WNI-GsMAP-DAIN-MMBC	<u>0.6751</u>	<u>0.9648</u>	<u>0.5893</u>	<u>0.0894</u>	0.0040	0.3676	0.9001	<u>1.9682</u>

ตารางที่ 31 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลอง  
การเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 5

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.5679	0.9291	0.4357	0.0513	<u>0.0031</u>	0.3548	0.8464	2.6725
WNI-GsMAP-DAIN	<b>0.6249</b>	<b>0.9361</b>	<b>0.4984</b>	<b>0.1264</b>	<b>0.0272</b>	<b>0.3970</b>	<b>0.8602</b>	<b>2.4887</b>
WNI-GsMAP-DAIN-MBC	0.5135	0.9201	0.3914	0.0069	0.0000	<u>0.3741</u>	<u>0.8569</u>	2.8668
WNI-GsMAP-DAIN-MMBC	<u>0.6219</u>	<u>0.9351</u>	<u>0.4939</u>	<u>0.0643</u>	0.0029	0.3297	0.8299	<u>2.6359</u>

ตารางที่ 32 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 6

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.4446	0.8657	0.2894	0.0000	0.0000	0.2888	0.7316	4.5200
WNI-GsMAP-DAIN	<b>0.5699</b>	<b>0.8911</b>	<b>0.3984</b>	<b>0.0002</b>	0.0000	<b>0.3224</b>	<b>0.7653</b>	<b>4.4077</b>
WNI-GsMAP-DAIN-MBC	0.3392	0.8423	0.2945	<u>0.0001</u>	0.0000	<u>0.3006</u>	<u>0.7427</u>	4.7005
WNI-GsMAP-DAIN-MMBC	<u>0.4928</u>	<u>0.8748</u>	<u>0.3278</u>	0.0000	0.0000	0.2807	0.7200	<u>4.5028</u>

ตารางที่ 33 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่ไม่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 7

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.5845	0.9573	0.4624	<u>0.0038</u>	0.0000	0.3559	0.9008	2.2815
WNI-GsMAP-DAIN	<b>0.6511</b>	<b>0.9628</b>	<b>0.5298</b>	<b>0.0184</b>	0.0000	<b>0.3778</b>	<b>0.9106</b>	<b>2.1590</b>
WNI-GsMAP-DAIN-MBC	0.5227	0.9507	0.4074	0.0012	0.0000	<u>0.3682</u>	<u>0.9076</u>	2.3366
WNI-GsMAP-DAIN-MMBC	<u>0.6318</u>	<u>0.9612</u>	<u>0.5092</u>	0.0019	0.0000	0.3395	0.8889	<u>2.2390</u>

### 5.5.2 สรุปผลลัพธ์จากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความผิดพลาดในการฝึกแบบจำลองการเรียนรู้

ตารางที่ 34 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 1

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.4581	0.8645	0.2141	0.1259	<u>0.0892</u>	0.3234	0.7058	6.6509
WNI-GsMAP-DAIN	<u>0.6299</u>	<u>0.9384</u>	<u>0.3825</u>	<u>0.2565</u>	0.0891	<u>0.4166</u>	<u>0.8357</u>	<u>3.2077</u>
WNI-GsMAP-DAIN-MBC	0.6091	0.9311	0.3255	0.2336	<b>0.1190</b>	0.4023	0.8137	3.4558
WNI-GsMAP-DAIN-MMBC	<b>0.6410</b>	<b>0.9424</b>	<b>0.4068</b>	<b>0.2840</b>	0.0587	<b>0.4230</b>	<b>0.8469</b>	<b>2.8348</b>

ตารางที่ 35 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 2

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.6971	<u>0.9287</u>	0.5686	<u>0.2487</u>	<b>0.0278</b>	<u>0.4434</u>	<u>0.8421</u>	2.6797
WNI-GsMAP-DAIN	<u>0.7615</u>	<u>0.9516</u>	<u>0.6168</u>	0.1589	0.0014	0.4322	0.8740	<u>2.6666</u>
WNI-GsMAP-DAIN-MBC	<b>0.7616</b>	<b>0.9521</b>	<b>0.6345</b>	<b>0.2578</b>	0.0029	<b>0.4618</b>	<b>0.8811</b>	<b>2.5634</b>
WNI-GsMAP-DAIN-MMBC	0.4627	0.8882	0.4079	0.1207	<u>0.0043</u>	0.3553	0.7905	3.7408

ตารางที่ 36 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 3

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.2650	0.9142	0.1290	0.0845	0.0450	0.2932	0.8225	4.5474
WNI-GsMAP-DAIN	<b>0.4730</b>	<b>0.9670</b>	<b>0.2916</b>	<b>0.2038</b>	0.0852	<b>0.3869</b>	<b>0.9204</b>	<b>1.9211</b>
WNI-GsMAP-DAIN-MBC	<u>0.4350</u>	0.9605	0.2433	0.1656	<u>0.0921</u>	0.3654	0.9051	2.4747
WNI-GsMAP-DAIN-MMBC	0.4573	<u>0.9653</u>	<u>0.2612</u>	<u>0.1891</u>	<b>0.1033</b>	<u>0.3797</u>	<u>0.9155</u>	<u>1.9823</u>

ตารางที่ 37 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 4

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.5546	0.9234	0.3945	0.1338	0.1030	0.3887	0.8271	4.4084
WNI-GsMAP-DAIN	<b>0.7022</b>	<b>0.9622</b>	<b>0.5783</b>	<u>0.2314</u>	0.0863	<b>0.4646</b>	<b>0.9079</b>	<b>2.0683</b>
WNI-GsMAP-DAIN-MBC	<u>0.6978</u>	<u>0.9605</u>	0.5293	0.2117	<b>0.1469</b>	<u>0.4621</u>	0.8962	2.5113
WNI-GsMAP-DAIN-MMBC	0.6928	0.9593	<u>0.5353</u>	<b>0.2344</b>	<u>0.1147</u>	0.4609	<u>0.8966</u>	<u>2.1698</u>

ตารางที่ 38 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 5

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.5072	0.8425	0.3520	0.1792	0.1148	0.3721	0.7095	4.7927
WNI-GsMAP-DAIN	<b>0.6446</b>	<b>0.9200</b>	<b>0.4901</b>	0.2808	0.0561	0.4368	<b>0.8300</b>	<b>2.4636</b>
WNI-GsMAP-DAIN-MBC	0.6345	0.9112	<u>0.4810</u>	<b>0.2945</b>	<b>0.1441</b>	<b>0.4577</b>	0.8171	<u>2.6123</u>
WNI-GsMAP-DAIN-MMBC	<u>0.6405</u>	<u>0.9156</u>	0.4713	<u>0.2870</u>	<u>0.1256</u>	<u>0.4499</u>	<u>0.8195</u>	2.6536

ตารางที่ 39 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพชุดที่ 6

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.6260	0.8598	0.4870	0.1580	<b>0.0243</b>	0.3823	0.7348	<u>3.6105</u>
WNI-GsMAP-DAIN	<u>0.7154</u>	<u>0.9135</u>	<u>0.5502</u>	0.1103	0.0004	<u>0.3936</u>	<u>0.7993</u>	3.6362
WNI-GsMAP-DAIN-MBC	<b>0.7445</b>	<b>0.9237</b>	<b>0.5841</b>	<b>0.2011</b>	0.0015	<b>0.4276</b>	<b>0.8182</b>	<b>3.3413</b>
WNI-GsMAP-DAIN-MMBC	0.5273	0.8498	0.4203	<u>0.1672</u>	<u>0.0106</u>	0.3620	0.7261	4.3313



ตารางที่ 40 ตารางสรุปผลลัพธ์การทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเอง  
ในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วยกระบวนการ Balanced Custom Weights ด้วยชุดข้อมูล  
ที่ใช้วัดประสิทธิภาพชุดที่ 7

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.5125</u>	0.9063	0.3997	0.2630	<b>0.1153</b>	0.4211	0.8165	2.3411
WNI-GsMAP-DAIN	0.6718	<b>0.9562</b>	<u>0.5600</u>	0.2278	0.0018	0.4365	<u>0.8997</u>	<u>1.9011</u>
WNI-GsMAP-DAIN- MBC	<b>0.6778</b>	<u>0.9559</u>	<b>0.5661</b>	<u>0.2970</u>	<u>0.0654</u>	<b>0.4711</b>	<b>0.8999</b>	<b>1.8745</b>
WNI-GsMAP-DAIN- MMBC	0.6547	0.9511	0.5318	<b>0.3122</b>	0.0374	<u>0.4582</u>	0.8897	1.9366

## บทที่ 6

### สรุปผลการวิจัยและแนวทางการวิจัยในขั้นถัดไป

#### 6.1 สรุปผลการวิจัย

วิทยานิพนธ์นี้ได้นำเสนอการปรับปรุงการทำนายปริมาณน้ำระยะฝนในระยะสั้นด้วยแบบจำลองการเรียนรู้เชิงลึก ด้วยการผนวกข้อมูลปริมาณน้ำฝนจากการวิเคราะห์จากดาวเทียมเข้าด้วยกันกับข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ตรวจอากาศภาคพื้นดิน จากเดิมที่มีการใช้เพียงข้อมูลปริมาณน้ำฝนที่ได้จากเรดาร์ภาคพื้นดิน รวมถึงมีการใช้เทคนิคแบบจำลองการเรียนรู้เชิงลึก DAIN เพื่อแก้ปัญหาจำนวนอัตราภาคของข้อมูลที่มีไม่ตรงกัน ระหว่างข้อมูลปริมาณน้ำระยะฝนจากเรดาร์ตรวจอากาศภาคพื้นดิน การใช้เทคนิค Mean Bias Correction ในการปรับค่าอคติในชุดข้อมูลปริมาณน้ำฝนที่ได้จากการวิเคราะห์จากดาวเทียมให้มีความใกล้เคียงกับค่าปริมาณน้ำฝนที่ได้จากเรดาร์ตรวจอากาศภาคพื้นดิน และมีการทดลองการแก้ไขค่าน้ำหนักในตัวแบบจำลองการเรียนรู้ในการฝึกแบบจำลองการเรียนรู้เชิงลึก เพื่อแก้ปัญหาชุดข้อมูลแต่ละคลาสที่ไม่สมดุลกันในชุดข้อมูล ซึ่งจากการทดลองพบว่า ในกรณีที่ไม่มีการแก้ไขค่าน้ำหนักใดๆในแบบจำลองการเรียนรู้เชิงลึก การใช้ข้อมูลปริมาณน้ำฝนที่ผ่านการผนวกแล้วมาใช้ในการทำนายปริมาณน้ำฝนระยะสั้นด้วยแบบจำลองการเรียนรู้เชิงลึกสามารถช่วยให้แบบจำลองการเรียนรู้เชิงลึกนั้น สามารถทำนายปริมาณน้ำฝนระยะสั้นได้แม่นยำยิ่งขึ้น ในส่วนของผลการทดลองการฝึกแบบจำลองการเรียนรู้เชิงลึกที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้เชิงลึกนั้นพบว่า สามารถช่วยเสริมประสิทธิภาพการทำนายปริมาณน้ำฝนระยะสั้นได้ในเทอมของ Multi-CSI Class 2 และ Class 3 เทอมของ RMSE และ เทอมของ Macro CSI ได้ในหลายชุดข้อมูลทดสอบ

#### 6.2 แนวทางการวิจัยถัดไป

สถาปัตยกรรมของแบบจำลองการเรียนรู้เชิงลึกที่ใช้การทดสอบนี้เป็นแบบจำลองการเรียนรู้เชิงลึกแบบ U-NET เป็นหลักที่เป็นแบบจำลองการเรียนรู้เชิงลึกที่เป็นที่นิยมในการทำนายปริมาณน้ำฝนระยะสั้น ซึ่งในอนาคตอาจมีแบบจำลองการเรียนรู้เชิงลึกแบบอื่นๆที่อาจมีประสิทธิภาพสูงกว่าหรือเทียบเท่าแบบจำลองการเรียนรู้เชิงลึกแบบ U-NET การที่จะนำวิธีการที่วิทยานิพนธ์นี้ไปใช้กับชุดข้อมูลปริมาณน้ำฝนจากแหล่งอื่นๆ อาจจำเป็นต้องมีการปรับค่าพารามิเตอร์ใหม่เพื่อให้ได้มีประสิทธิภาพการทำนายปริมาณน้ำฝนระยะสั้นที่ดี

## ภาคผนวก

ประกอบด้วยข้อมูลผลการทดลองการแก้ค่าน้ำหนักค่าความผิดพลาดในการฝึกสอนแบบจำลองเองแบบแทนค่าด้วย [1,3,10,30] และ [1,10,30,70]

ผลการทดลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักสำหรับค่าน้ำหนักของปริมาณน้ำฝนในแต่ละช่วง เป็น [1,3,10,30]

จากกรณีผลการทดลองจากชุดทดสอบทั้งหมด 7 ชุด ผลการทดลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักค่าความสูญเสียของปริมาณน้ำฝนในแต่ละช่วงเป็น [1,3,10,30] ตามลำดับ ได้ผลลัพธ์เป็นดังนี้

**จากชุดข้อมูลทดสอบชุดที่ 1** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI ณ ขั้นตอนเวลาที่ +2, +3 Multi-CSI Class 0 ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 1 ณ ขั้นตอนเวลาที่ +1,+2,+3 และ Micro CSI ณ ขั้นตอนเวลาที่ +2,+3 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Multi-CSI Class 2 ณ ขั้นตอนเวลาที่ +1,+2,+3 และ Macro CSI ณ ขั้นตอนเวลาที่ +1,+2 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Multi-CSI Class 3 ณ ขั้นตอนเวลาที่ +2,+3

**จากชุดข้อมูลทดสอบชุดที่ 2** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI ณ ขั้นตอนเวลาที่ +1,+2,+3 Multi-CSI Class 1 ณ ขั้นตอนเวลาที่ +1,+2,+3 Macro CSI ณ ขั้นตอนเวลาที่ +2,+3 Micro CSI ณ ขั้นตอนเวลาที่ +2,+3 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Multi-CSI Class 0 ณ ขั้นตอนเวลาที่ +1,+2 Multi-CSI Class 2 ณ ขั้นตอนเวลาที่ +1,+2 Multi-CSI Class 3 ณ ขั้นตอนเวลาที่ +1,+2,+3 และ RMSE ณ ขั้นตอนเวลาที่ +1,+2,+3

**จากชุดข้อมูลทดสอบชุดที่ 3** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Binary CSI ในทุกขั้นตอนเวลา Multi-CSI Class 0 ในทุกขั้นตอนเวลา Multi-CSI Class 1 ณ ขั้นตอนเวลาที่ +2,+3 Micro CSI ณ ขั้นตอนเวลาที่ +2,+3 และ RMSE ในทุกขั้นตอนเวลา แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์การทำนายได้ดีที่สุดในเทอมของ Multi-CSI Class 3 ณ ขั้นตอนเวลาที่ +2,+3



ตารางที่ 41 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 1

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.6643	0.9476	0.4693	<b>0.2927</b>	<u>0.1068</u>	<b>0.4541</b>	0.8647	2.6600
WNI-GsMAP-DAIN	<b>0.6905</b>	<b>0.9554</b>	<b>0.5349</b>	0.2426	0.0269	0.4400	<b>0.8833</b>	<b>2.5513</b>
WNI-GsMAP-DAIN-MBC	0.6358	0.9392	0.4011	0.2637	<b>0.1092</b>	0.4283	0.8399	3.0232
WNI-GsMAP-DAIN-MMBC	<u>0.6657</u>	<u>0.9488</u>	<u>0.4863</u>	<u>0.2805</u>	0.0704	<u>0.4465</u>	<u>0.8684</u>	<u>2.5750</u>

ตารางที่ 42 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 2

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.6989</u>	<u>0.9424</u>	0.5492	<b>0.1080</b>	<b>0.0056</b>	0.4013	<u>0.8588</u>	<b>2.7923</b>
WNI-GsMAP-DAIN	0.6558	0.9327	0.5902	0.0053	0.0000	0.3820	<u>0.8588</u>	3.3460
WNI-GsMAP-DAIN-MBC	<b>0.7316</b>	<b>0.9448</b>	<b>0.6422</b>	<u>0.0582</u>	0.0000	<b>0.4113</b>	<b>0.8733</b>	<u>3.0652</u>
WNI-GsMAP-DAIN-MMBC	0.6360	0.9242	<u>0.5983</u>	0.0958	<u>0.0018</u>	<u>0.4050</u>	0.8519	3.2917

ตารางที่ 43 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 3

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.5073</u>	0.9716	<u>0.3600</u>	0.2432	<u>0.1121</u>	<u>0.4217</u>	0.9334	1.6405
WNI-GsMAP-DAIN	<b>0.5525</b>	<b>0.9783</b>	<b>0.4401</b>	<u>0.2579</u>	0.0306	<b>0.4267</b>	<b>0.9497</b>	<b>1.1869</b>
WNI-GsMAP-DAIN-MBC	0.4920	0.9696	0.3301	0.2374	<b>0.1134</b>	0.4126	0.9281	1.6606
WNI-GsMAP-DAIN-MMBC	0.5007	<u>0.9717</u>	0.3502	<b>0.2630</b>	0.0921	0.4193	<u>0.9335</u>	<u>1.4850</u>

ตารางที่ 44 ตารางสรุปผลลัพธ์โดยเฉลี่ยการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพ

ชุดที่ 4

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.7240	<u>0.9669</u>	<u>0.6264</u>	<u>0.2327</u>	0.1197	<u>0.4864</u>	<u>0.9219</u>	<u>1.8325</u>
WNI-GsMAP-DAIN	<b>0.7414</b>	<b>0.9702</b>	<b>0.6603</b>	0.1783	0.0116	0.4551	<b>0.9296</b>	<b>1.7557</b>
WNI-GsMAP-DAIN-MBC	0.7174	0.9642	0.5961	0.2112	<u>0.1365</u>	0.4770	0.9125	2.0714
WNI-GsMAP-DAIN-MMBC	<u>0.7265</u>	0.9658	0.6160	<b>0.2408</b>	<b>0.1487</b>	<b>0.4928</b>	0.9178	1.8914

ตารางที่ 45 ตารางสรุปผลลัพธ์โดยเฉลี่ยการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพ

ชุดที่ 5

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.6807</u>	<u>0.9355</u>	<u>0.5538</u>	<u>0.2881</u>	<b>0.1480</b>	<b>0.4814</b>	<u>0.8617</u>	2.2456
WNI-GsMAP-DAIN	<b>0.6835</b>	<b>0.9379</b>	<b>0.5664</b>	0.1800	0.0175	0.4254	<b>0.8649</b>	2.3077
WNI-GsMAP-DAIN-MBC	0.6564	0.9212	0.5351	0.2822	0.1081	0.4616	0.8408	<u>2.2110</u>
WNI-GsMAP-DAIN-MMBC	<u>0.6624</u>	0.9241	0.5383	<b>0.3197</b>	<u>0.1094</u>	<u>0.4729</u>	0.8454	<b>2.1546</b>

ตารางที่ 46 ตารางสรุปผลลัพธ์โดยเฉลี่ยการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพ

ชุดที่ 6

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.6998	0.9158	0.5254	<u>0.0525</u>	<u>0.0005</u>	0.3736	0.8009	3.8371
WNI-GsMAP-DAIN	<u>0.7239</u>	<u>0.9226</u>	0.5454	0.0017	0.0000	0.3674	<u>0.8091</u>	4.1113
WNI-GsMAP-DAIN-MBC	<b>0.7614</b>	<b>0.9298</b>	<b>0.5877</b>	0.0347	0.0000	<b>0.3880</b>	<b>0.8198</b>	<u>3.8125</u>
WNI-GsMAP-DAIN-MMBC	0.7051	0.9108	<u>0.5705</u>	<b>0.0670</b>	<b>0.0006</b>	<u>0.3872</u>	0.8035	<b>3.7998</b>

ตารางที่ 47 ตารางสรุปผลลัพธ์โดยเฉลี่ยการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ด้วยชุดข้อมูลที่ใช้วัดประสิทธิภาพ

ชุดที่ 7

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.7009</u>	<u>0.9633</u>	<u>0.5934</u>	0.2294	<b>0.0179</b>	0.4510	<b>0.9142</b>	1.7863
WNI-GsMAP-DAIN	<u>0.7009</u>	<b>0.9654</b>	0.5770	0.0132	0.0000	0.3889	<u>0.9141</u>	2.0627
WNI-GsMAP-DAIN-MBC	<b>0.7030</b>	0.9611	<b>0.5992</b>	<u>0.2430</u>	0.0051	<u>0.4521</u>	0.9108	<u>1.7835</u>
WNI-GsMAP-DAIN-MMBC	0.6961	0.9596	0.5907	<b>0.3111</b>	<u>0.0089</u>	<b>0.4676</b>	0.9085	<b>1.7442</b>



ตารางที่ 48 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 1 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา(Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
1	Binary CSI↑		0.7310	0.6778	0.5840	0.7280	0.6894	0.6541
	Multi-CSI↑	Class 0	0.9643	0.9535	0.9249	0.9627	0.9559	0.9476
		Class 1	0.5497	0.4832	0.3751	0.5658	0.5368	0.5021
		Class 2	0.3365	0.2907	0.2509	0.3328	0.2337	0.1614
		Class 3	0.1782	0.0829	0.0593	0.0760	0.0042	0.0005
	Macro CSI↑		0.5072	0.4526	0.4025	0.4843	0.4326	0.4029
	Micro CSI↑		0.8986	0.8755	0.8200	0.8974	0.8843	0.8683
	RMSE↓		2.2985	2.6082	3.0732	2.3009	2.5934	2.7595
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.6958	0.6261	0.5855	0.7149	0.6593	0.6228
	Multi-CSI↑	Class 0	0.9555	0.9376	0.9246	0.9604	0.9481	0.9380
		Class 1	0.4695	0.3813	0.3525	0.5332	0.4788	0.4470
		Class 2	0.3014	0.2534	0.2363	0.3294	0.2820	0.2301
		Class 3	0.1650	0.0981	0.0645	0.0956	0.0714	0.0443
	Macro CSI↑		0.4729	0.4176	0.3945	0.4797	0.4451	0.4149
	Micro CSI↑		0.8725	0.8339	0.8134	0.8898	0.8668	0.8487
	RMSE↓		2.7118	3.1818	3.1759	2.3768	2.6100	2.7382



ตารางที่ 49 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 2 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
2	Binary CSI↑		0.7795	0.7264	0.5908	0.7088	0.6458	0.6129
	Multi-CSI↑	Class 0	0.9568	0.9466	0.9238	0.9426	0.9314	0.9240
		Class 1	0.6361	0.5773	0.4343	0.6453	0.5763	0.5490
		Class 2	0.1666	0.1250	0.0325	0.0143	0.0010	0.0005
		Class 3	0.0145	0.0023	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.4435	0.4128	0.3476	0.4006	0.3772	0.3684
	Micro CSI↑		0.8835	0.8656	0.8272	0.8747	0.8559	0.8457
	RMSE↓		2.5190	2.7173	3.1405	3.2276	3.4006	3.4099
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.7483	0.7466	0.6999	0.6595	0.6284	0.6202
	Multi-CSI↑	Class 0	0.9500	0.9463	0.9380	0.9306	0.9233	0.9188
		Class 1	0.6588	0.6588	0.6090	0.6267	0.5912	0.5769
		Class 2	0.0720	0.0811	0.0214	0.1205	0.0990	0.0679
		Class 3	0.0000	0.0000	0.0000	0.0040	0.0011	0.0004
	Macro CSI↑		0.4202	0.4216	0.3921	0.4204	0.4037	0.3910
	Micro CSI↑		0.8817	0.8760	0.8623	0.8629	0.8505	0.8425
	RMSE↓		3.0055	2.9996	3.1905	3.2289	3.3308	3.3153

ตารางที่ 50 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
3	Binary CSI↑		0.5976	0.5235	0.4007	0.6188	0.5523	0.4865
	Multi-CSI↑	Class 0	0.9813	0.9756	0.9579	0.9827	0.9787	0.9734
		Class 1	0.4477	0.3721	0.2603	0.4995	0.4392	0.3815
		Class 2	0.2978	0.2465	0.1854	0.3474	0.2412	0.1851
		Class 3	0.1614	0.1019	0.0731	0.0733	0.0172	0.0011
	Macro CSI↑		0.4720	0.4240	0.3692	0.4757	0.4191	0.3853
	Micro CSI↑		0.9532	0.9413	0.9058	0.9585	0.9505	0.9400
	RMSE↓		1.3791	1.5488	1.9938	1.0543	1.1971	1.3091
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.5704	0.4819	0.4237	0.5668	0.4944	0.4411
	Multi-CSI↑	Class 0	0.9781	0.9691	0.9617	0.9781	0.9715	0.9655
		Class 1	0.4091	0.3138	0.2674	0.4086	0.3394	0.3025
		Class 2	0.2897	0.2239	0.1987	0.2893	0.2611	0.2388
		Class 3	0.1456	0.1081	0.0865	0.1358	0.0861	0.0545
	Macro CSI↑		0.4556	0.4037	0.3786	0.453	0.4145	0.3903
	Micro CSI↑		0.9458	0.9262	0.9122	0.9459	0.9326	0.9219
	RMSE↓		1.4048	1.7433	1.8338	1.4380	1.5200	1.4970

ตารางที่ 51 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 4 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
4	Binary CSI↑		0.7789	0.7256	0.6674	0.7914	0.7346	0.6982
	Multi-CSI↑	Class 0	0.9750	0.9679	0.9577	0.9766	0.9698	0.9641
		Class 1	0.6788	0.6289	0.5715	0.7103	0.6517	0.6188
		Class 2	0.2781	0.2322	0.1878	0.2302	0.1628	0.1420
		Class 3	0.1866	0.1173	0.0551	0.0309	0.0015	0.0024
	Macro CSI↑		0.5296	0.4866	0.4430	0.4870	0.4465	0.4318
	Micro CSI↑		0.9367	0.9240	0.9052	0.9409	0.9287	0.9192
	RMSE↓		1.7421	1.8240	1.9314	1.6591	1.8151	1.7930
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.7716	0.7071	0.6735	0.7741	0.7231	0.6824
	Multi-CSI↑	Class 0	0.9731	0.9624	0.9569	0.9732	0.9657	0.9586
		Class 1	0.6531	0.5774	0.5577	0.6601	0.6104	0.5775
		Class 2	0.2433	0.2043	0.1859	0.2784	0.2326	0.2115
		Class 3	0.1697	0.138	0.1017	0.1971	0.1498	0.0991
	Macro CSI↑		0.5098	0.4705	0.4506	0.5272	0.4896	0.4617
	Micro CSI↑		0.9293	0.9076	0.9004	0.9307	0.9170	0.9056
	RMSE↓		1.8995	2.2019	2.1127	1.7769	1.9568	1.9405

ตารางที่ 52 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 5 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
5	Binary CSI↑		0.7339	0.6754	0.6327	0.7356	0.6772	0.6375
	Multi-CSI↑	Class 0	0.9497	0.9349	0.9218	0.9493	0.9373	0.9270
		Class 1	0.6075	0.5462	0.5078	0.6212	0.5587	0.5194
		Class 2	0.3472	0.2911	0.2262	0.2732	0.1586	0.1081
		Class 3	0.2134	0.1351	0.0955	0.0520	0.0005	0.0000
	Macro CSI↑		0.5294	0.4768	0.4378	0.4739	0.4138	0.3886
	Micro CSI↑		0.8859	0.8604	0.8388	0.8861	0.8629	0.8457
	RMSE↓		2.0942	2.2700	2.3726	2.0299	2.3534	2.5399
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.7112	0.6479	0.6102	0.7183	0.6566	0.6124
	Multi-CSI↑	Class 0	0.9391	0.9191	0.9053	0.9419	0.9235	0.9070
		Class 1	0.5908	0.5265	0.4880	0.6006	0.5312	0.4831
		Class 2	0.3365	0.2867	0.2235	0.3690	0.3151	0.2749
		Class 3	0.1512	0.1033	0.0698	0.1496	0.1049	0.0737
	Macro CSI↑		0.5044	0.4589	0.4216	0.5153	0.4687	0.4347
Micro CSI↑		0.8704	0.8374	0.8145	0.8755	0.8440	0.8168	
RMSE↓		1.9864	2.2260	2.4205	1.9233	2.1662	2.3743	

ตารางที่ 53 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 6 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
6	Binary CSI↑		0.7582	0.7167	0.6246	0.7815	0.7172	0.6731
	Multi-CSI↑	Class 0	0.9313	0.9192	0.8971	0.9379	0.9213	0.9086
		Class 1	0.5837	0.5423	0.4502	0.5986	0.5367	0.5010
		Class 2	0.0846	0.0591	0.0138	0.0049	0.0001	0.0001
		Class 3	0.0014	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.4002	0.3802	0.3403	0.3853	0.3645	0.3524
	Micro CSI↑		0.8239	0.8062	0.7726	0.8300	0.8069	0.7903
	RMSE↓		3.5656	3.7738	4.1720	3.9043	4.1601	4.2696
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.8033	0.7639	0.7170	0.7489	0.6993	0.6670
	Multi-CSI↑	Class 0	0.9432	0.9292	0.9171	0.9251	0.9100	0.8974
		Class 1	0.6262	0.5919	0.5450	0.6182	0.5642	0.5290
		Class 2	0.0505	0.0358	0.0176	0.1076	0.0617	0.0317
		Class 3	0.0000	0.0000	0.0000	0.0017	0.0000	0.0000
	Macro CSI↑		0.4050	0.3892	0.3699	0.4132	0.3840	0.3645
	Micro CSI↑		0.8386	0.8192	0.8015	0.8258	0.8021	0.7827
	RMSE↓		3.6264	3.7513	4.0598	3.6225	3.8258	3.9510

ตารางที่ 54 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 7 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,3,10,30] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
7	Binary CSI↑		0.7482	0.6971	0.6576	0.7547	0.6926	0.6554
	Multi-CSI↑	Class 0	0.9712	0.9632	0.9557	0.9724	0.9647	0.9590
		Class 1	0.6417	0.5876	0.5510	0.6268	0.5678	0.5363
		Class 2	0.3104	0.2351	0.1428	0.0214	0.0107	0.0075
		Class 3	0.0401	0.0132	0.0004	0.0000	0.0000	0.0000
	Macro CSI↑		0.4908	0.4498	0.4124	0.4051	0.3858	0.3757
	Micro CSI↑		0.9294	0.9137	0.8996	0.9262	0.9128	0.9032
	RMSE↓		1.6143	1.7930	1.9515	1.9686	2.0862	2.1333
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,3,10,30]		
			ขั้นตอนเวลา (Timestep)			ขั้นตอนเวลา (Timestep)		
			1	2	3	1	2	3
	Binary CSI↑		0.7554	0.6965	0.6570	0.7509	0.6902	0.6472
	Multi-CSI↑	Class 0	0.9703	0.9600	0.9531	0.9691	0.9587	0.9509
		Class 1	0.6517	0.5924	0.5537	0.6472	0.5825	0.5425
		Class 2	0.2593	0.2649	0.2049	0.3608	0.3132	0.2595
		Class 3	0.0057	0.0072	0.0023	0.0237	0.0029	0.0002
	Macro CSI↑		0.4718	0.4561	0.4285	0.5002	0.4643	0.4382
Micro CSI↑		0.9272	0.9089	0.8961	0.9260	0.9067	0.8929	
RMSE↓		1.6820	1.7729	1.8958	1.6067	1.7537	1.8722	

ผลการทดลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักสำหรับค่าน้ำหนักของปริมาณน้ำฝนในแต่ละช่วง เป็น [1,10,30,70]

จากกรณีผลการทดลองจากชุดทดสอบทั้งหมด 7 ชุด ผลการทดลองที่มีการแก้ไขค่าน้ำหนักในแบบจำลองการเรียนรู้ที่มีการแก้ไขแทนค่าน้ำหนักสำหรับค่าน้ำหนักของปริมาณน้ำฝนในแต่ละช่วง เป็น [1,10,30,70] ตามลำดับ ได้ผลลัพธ์เป็นดังนี้

**จากชุดข้อมูลทดสอบชุดที่ 1** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MMBC ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Binary CSI ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 0 ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 1 ณ ขั้นตอนเวลาที่ +2,+3 Micro CSI ณ ขั้นตอนเวลาที่ +2,+3 และ RMSE ณ ขั้นตอนเวลาที่ +2,+3 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MBC ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Multi-CSI Class 3 ในทุกขั้นตอนเวลา

**จากชุดข้อมูลทดสอบชุดที่ 2** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Binary CSI ในทุกขั้นตอนเวลา Multi-CSI Class 0 ในทุกขั้นตอนเวลา Multi-CSI Class 1 ในทุกขั้นตอนเวลา Macro CSI ณ ขั้นตอนเวลาที่ +1,+2 Micro CSI ในทุกขั้นตอนเวลา และ RMSE ในทุกขั้นตอนเวลา แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MMBC นั้นให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Multi-CSI Class 3 ในทุกขั้นตอนเวลา

**จากชุดข้อมูลทดสอบชุดที่ 3** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MMBC ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Binary CSI ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 0 ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 1 ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 2 ณ ขั้นตอนเวลาที่ +2,+3 Micro CSI ณ ขั้นตอนเวลาที่ +2,+3 และ RMSE ณ ขั้นตอนเวลาที่ +2,+3 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Macro CSI ณ ขั้นตอนเวลาที่ +1,+2 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Multi-CSI Class 3 ณ ขั้นตอนเวลาที่ +2,+3

**จากชุดข้อมูลทดสอบชุดที่ 4** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MMBC ให้ผลลัพธ์การทำนายที่ดีที่สุดในเทอมของ Binary CSI ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 0 ณ ขั้นตอนเวลาที่ +2,+3 Multi-CSI Class 2 ในทุกขั้นตอนเวลา Macro CSI ณ ขั้นตอน

เวลาที่ +2,+3 แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Multi-CSI Class 1 ในทุกชั้นตอนเวลา Micro CSI ณ ชั้นตอนเวลาที่ +1,+3 และ RMSE ณ ชั้นตอนเวลาที่ +1, +3

**จากชุดข้อมูลทดสอบชุดที่ 5** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MMBC ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Binary CSI ณ ชั้นตอนเวลาที่ +2,+3 Multi-CSI Class 0 ณ ชั้นตอนเวลาที่ +2,+3 Multi-CSI Class 2 ณ ชั้นตอนเวลาที่ +2,+3 Micro CSI ณ ชั้นตอนเวลาที่ +2,+3 และ RMSE ในทุกชั้นตอนเวลา แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Multi-CSI Class 1 ณ ชั้นตอนเวลาที่ +1,+3 Multi-CSI Class 3 ในทุกชั้นตอนเวลา และ Macro CSI ในทุกชั้นตอนเวลา

**จากชุดข้อมูลทดสอบชุดที่ 6** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Binary CSI ในทุกชั้นตอนเวลา Multi-CSI Class 1 ในทุกชั้นตอนเวลา และ RMSE ในทุกชั้นตอนเวลา แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN-MMBC ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Multi-CSI Class 3 ในทุกชั้นตอนเวลา แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Multi-CSI 0 ณ ชั้นตอนเวลา +2,+3 และ Macro CSI ณ ชั้นตอนเวลาที่ +2,+3

**จากชุดข้อมูลทดสอบชุดที่ 7** พบว่าแบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Binary CSI ในทุกชั้นตอนเวลา Multi-CSI 0 ในทุกชั้นตอนเวลา Multi-CSI Class 1 ในทุกชั้นตอนเวลา Multi-CSI Class 3 ในทุกชั้นตอนเวลา และ Micro CSI ในทุกชั้นตอนเวลา แบบจำลองที่ถูกฝึกด้วยชุดข้อมูลแบบ WNI-GsMAP-DAIN ให้ผลลัพธ์การทำนายที่ดีที่สุด ในเทอมของ Multi-CSI Class 2 ณ ชั้นตอนเวลาที่ +1,+2 Macro CSI ณ ชั้นตอนเวลาที่ +1,+2 และ RMSE ในทุกชั้นตอนเวลา



ตารางที่ 55 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 1

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.6080</u>	<u>0.9290</u>	<u>0.4564</u>	<u>0.2830</u>	0.0572	<b>0.4314</b>	<u>0.8412</u>	<u>2.5933</u>
WNI-GsMAP-DAIN	0.5630	0.9131	0.3437	0.2471	<b>0.1033</b>	0.4018	0.7979	3.1935
WNI-GsMAP-DAIN-MBC	0.5721	0.9166	0.3793	0.2792	<u>0.0896</u>	0.4162	0.8121	2.8264
WNI-GsMAP-DAIN-MMBC	<b>0.6103</b>	<b>0.9319</b>	<b>0.4592</b>	<b>0.2853</b>	0.0372	<u>0.4284</u>	<b>0.8457</b>	<b>2.5606</b>

ตารางที่ 56 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 2

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.7726</u>	<u>0.9534</u>	0.6251	0.0746	0.0000	0.4133	<u>0.8755</u>	<u>2.7942</u>
WNI-GsMAP-DAIN	<b>0.7993</b>	<b>0.9567</b>	<b>0.6682</b>	0.0886	0.0000	<b>0.4284</b>	<b>0.8835</b>	<b>2.7728</b>
WNI-GsMAP-DAIN-MBC	0.7315	0.9388	<u>0.6587</u>	<b>0.0969</b>	0.0000	<u>0.4236</u>	0.8679	3.0042
WNI-GsMAP-DAIN-MMBC	0.4542	0.8836	0.4475	<u>0.0927</u>	<b>0.0020</b>	0.3565	0.7954	3.5857

ตารางที่ 57 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 3

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<b>0.4339</b>	<u>0.9584</u>	<b>0.3236</b>	<b>0.2667</b>	0.0983	<b>0.4117</b>	<u>0.9114</u>	<u>1.4426</u>
WNI-GsMAP-DAIN	0.3992	0.9523	0.2649	0.2316	<b>0.1133</b>	0.3905	0.8967	1.7261
WNI-GsMAP-DAIN-MBC	0.4095	0.9543	0.2820	0.2430	<u>0.1123</u>	0.3979	0.9015	1.6366
WNI-GsMAP-DAIN-MMBC	<u>0.4294</u>	<b>0.9599</b>	<u>0.3157</u>	<u>0.2651</u>	0.0698	<u>0.4026</u>	<b>0.9138</b>	<b>1.4179</b>

ตารางที่ 58 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 4

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<b>0.6854</b>	<b>0.9572</b>	<b>0.6027</b>	<u>0.2474</u>	0.1107	<b>0.4795</b>	<b>0.9069</b>	<b>1.7709</b>
WNI-GsMAP-DAIN	0.6650	0.9523	0.5696	0.2409	<b>0.1341</b>	0.4742	0.8962	1.8398
WNI-GsMAP-DAIN-MBC	0.6596	0.9509	0.5522	0.2270	<u>0.1296</u>	0.4649	0.8916	1.9836
WNI-GsMAP-DAIN-MMBC	<u>0.6766</u>	<u>0.9554</u>	<u>0.5847</u>	<b>0.2679</b>	0.1020	<u>0.4775</u>	<u>0.9027</u>	<u>1.7992</u>

ตารางที่ 59 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 5

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<u>0.6258</u>	<u>0.9058</u>	<b>0.5182</b>	0.2865	<b>0.1446</b>	<b>0.4638</b>	<u>0.8207</u>	2.2606
WNI-GsMAP-DAIN	0.5972	0.8905	0.4815	0.2937	<u>0.1092</u>	0.4437	0.7971	2.3066
WNI-GsMAP-DAIN-MBC	0.5975	0.8895	0.4942	<u>0.2953</u>	0.0723	0.4378	0.7987	<u>2.2057</u>
WNI-GsMAP-DAIN-MMBC	<b>0.6275</b>	<b>0.9072</b>	<u>0.5178</u>	<b>0.3223</b>	0.0944	<u>0.4604</u>	<b>0.8231</b>	<b>2.1533</b>

ตารางที่ 60 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
ประสิทธิภาพชุดที่ 6

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	0.7273	<u>0.9153</u>	0.5666	<u>0.0899</u>	<u>0.0009</u>	<u>0.3932</u>	<u>0.8031</u>	3.6609
WNI-GsMAP-DAIN	<b>0.7457</b>	<b>0.9179</b>	<b>0.5875</b>	0.0688	0.0000	<b>0.3936</b>	<b>0.8070</b>	<u>3.6432</u>
WNI-GsMAP-DAIN-MBC	<u>0.7329</u>	0.9094	<u>0.5798</u>	0.0700	0.0000	0.3898	0.7965	<b>3.6014</b>
WNI-GsMAP-DAIN-MMBC	0.4671	0.8303	0.4053	<b>0.0939</b>	<b>0.0049</b>	0.3336	0.7110	4.3268

ตารางที่ 61 ตารางสรุปผลลัพธ์โดยเฉลี่ยจากการทำนายจากแบบจำลองที่มีการแก้ไขค่าน้ำหนักค่า  
 ความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ด้วยชุดข้อมูลที่ใช้วัด  
 ประสิทธิภาพชุดที่ 7

	Binary CSI (avg)	Multi-CSI (avg)				Macro CSI (avg)	Micro CSI (avg)	RMSE (avg)
		Class 0	Class 1	Class 2	Class 3			
WNI	<b>0.6575</b>	<b>0.9496</b>	<b>0.5640</b>	0.2095	<b>0.0174</b>	0.4351	<b>0.8919</b>	1.8069
WNI-GsMAP-DAIN	<u>0.6454</u>	0.9457	0.5520	<b>0.2855</b>	0.0060	<b>0.4473</b>	<u>0.8862</u>	<b>1.7635</b>
WNI-GsMAP-DAIN-MBC	<u>0.6454</u>	<u>0.9458</u>	<u>0.5528</u>	0.2399	0.0022	0.4352	0.8859	1.8016
WNI-GsMAP-DAIN-MMBC	0.6344	0.9441	0.5405	<u>0.2801</u>	<u>0.0128</u>	<u>0.4444</u>	0.8834	<u>1.7947</u>



ตารางที่ 62 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 1 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
1	Binary CSI↑		0.6993	0.5825	0.5423	0.6298	0.5421	0.5171
	Multi-CSI↑	Class 0	0.9564	0.9232	0.9073	0.9375	0.9068	0.8951
		Class 1	0.5499	0.4205	0.3989	0.3832	0.3183	0.3295
		Class 2	0.3217	0.2989	0.2284	0.2501	0.2460	0.2454
		Class 3	0.0938	0.0670	0.0107	0.1631	0.0994	0.0474
	Macro CSI↑		0.4805	0.4274	0.3863	0.4335	0.3926	0.3794
	Micro CSI↑		0.8884	0.8299	0.8054	0.8312	0.7860	0.7764
	RMSE↓		2.3155	2.6348	2.8296	3.3303	3.2405	3.0097
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.6444	0.5533	0.5186	0.6693	0.6014	0.5603
	Multi-CSI↑	Class 0	0.9421	0.9117	0.8959	0.9497	0.9306	0.9154
		Class 1	0.4422	0.3504	0.3454	0.5149	0.4495	0.4132
		Class 2	0.3178	0.2680	0.2518	0.3263	0.2890	0.2405
		Class 3	0.1484	0.0876	0.0330	0.0730	0.0304	0.0083
	Macro CSI↑		0.4626	0.4044	0.3815	0.4659	0.4249	0.3944
	Micro CSI↑		0.8537	0.8006	0.7819	0.8757	0.8433	0.8183
	RMSE↓		2.6092	2.9699	2.9001	2.3580	2.5801	2.7436

ตารางที่ 63 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 2 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
2	Binary CSI↑		0.8053	0.7767	0.7356	0.8331	0.7972	0.7676
	Multi-CSI↑	Class 0	0.9612	0.9542	0.9449	0.9657	0.9545	0.9498
		Class 1	0.6539	0.6282	0.5933	0.7055	0.6663	0.6329
		Class 2	0.0676	0.0740	0.0821	0.1746	0.0664	0.0246
		Class 3	0.0000	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.4207	0.4141	0.4051	0.4615	0.4218	0.4018
	Micro CSI↑		0.8873	0.8762	0.8629	0.9000	0.8793	0.8712
	RMSE↓		2.7382	2.8420	2.8023	2.5652	2.7716	2.9814
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.7703	0.7228	0.7015	0.4761	0.4536	0.4329
	Multi-CSI↑	Class 0	0.9516	0.9351	0.9298	0.8930	0.8833	0.8746
		Class 1	0.6976	0.6521	0.6265	0.4744	0.4454	0.4226
		Class 2	0.1266	0.1106	0.0534	0.1014	0.0918	0.0848
		Class 3	0.0001	0.0000	0.0000	0.0054	0.0003	0.0004
	Macro CSI↑		0.4440	0.4245	0.4024	0.3685	0.3552	0.3456
	Micro CSI↑		0.8877	0.8628	0.8532	0.8099	0.7946	0.7817
	RMSE↓		2.9392	2.9913	3.0822	3.5383	3.6123	3.6065

ตารางที่ 64 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 3 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
3	Binary CSI↑		0.5502	0.4054	0.3461	0.4808	0.3778	0.3389
	Multi-CSI↑	Class 0	0.9756	0.9560	0.9436	0.9666	0.9493	0.9409
		Class 1	0.4318	0.2915	0.2475	0.3321	0.2389	0.2236
		Class 2	0.3272	0.2533	0.2197	0.2640	0.2133	0.2176
		Class 3	0.1428	0.0993	0.0528	0.1482	0.1088	0.0829
	Macro CSI↑		0.4693	0.4000	0.3659	0.4277	0.3776	0.3662
	Micro CSI↑		0.9442	0.9059	0.8841	0.9228	0.8902	0.8771
	RMSE↓		1.2110	1.5269	1.5898	1.5827	1.8712	1.7243
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.5024	0.3875	0.3385	0.5045	0.4194	0.3644
	Multi-CSI↑	Class 0	0.9698	0.9518	0.9411	0.9707	0.9595	0.9494
		Class 1	0.3668	0.2555	0.2236	0.3795	0.3037	0.2640
		Class 2	0.2972	0.2227	0.2091	0.3038	0.2611	0.2305
		Class 3	0.1509	0.1070	0.0791	0.1167	0.0682	0.0246
	Macro CSI↑		0.4462	0.3843	0.3632	0.4427	0.3981	0.3671
	Micro CSI↑		0.9312	0.8959	0.8774	0.9340	0.9126	0.8948
	RMSE↓		1.3649	1.7685	1.7764	1.2811	1.4622	1.5104

ตารางที่ 65 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 4 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
4	Binary CSI↑		0.7655	0.6691	0.6217	0.7285	0.6537	0.6128
	Multi-CSI↑	Class 0	0.9719	0.9545	0.9451	0.9651	0.9502	0.9415
		Class 1	0.6822	0.5819	0.5439	0.6303	0.5554	0.5232
		Class 2	0.2978	0.2339	0.2105	0.2877	0.2340	0.2009
		Class 3	0.1728	0.1095	0.0498	0.1875	0.1477	0.0671
	Macro CSI↑		0.5312	0.4700	0.4373	0.5177	0.4718	0.4332
	Micro CSI↑		0.9332	0.9011	0.8863	0.9186	0.8919	0.8782
	RMSE↓		1.6053	1.8743	1.8332	1.6985	1.9043	1.9166
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.7296	0.6448	0.6043	0.7331	0.6714	0.6252
	Multi-CSI↑	Class 0	0.9654	0.9482	0.9391	0.9659	0.9549	0.9456
		Class 1	0.6155	0.5319	0.5092	0.6384	0.5781	0.5378
		Class 2	0.2559	0.2249	0.2003	0.3000	0.2612	0.2424
		Class 3	0.1644	0.1408	0.0835	0.1491	0.0965	0.0603
	Macro CSI↑		0.5003	0.4615	0.4330	0.5133	0.4727	0.4465
	Micro CSI↑		0.9161	0.8856	0.8732	0.9207	0.9013	0.8861
	RMSE↓		1.8777	2.0883	1.9847	1.7059	1.8510	1.8406

ตารางที่ 66 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 5 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
5	Binary CSI↑		0.7017	0.6108	0.5648	0.6711	0.5845	0.5360
	Multi-CSI↑	Class 0	0.9357	0.9017	0.8799	0.9233	0.8876	0.8606
		Class 1	0.5935	0.5014	0.4596	0.5453	0.4697	0.4296
		Class 2	0.3396	0.2888	0.2311	0.3340	0.2987	0.2484
		Class 3	0.1910	0.1385	0.1043	0.1610	0.1008	0.0658
	Macro CSI↑		0.5150	0.4576	0.4187	0.4909	0.4392	0.4011
	Micro CSI↑		0.8668	0.8136	0.7816	0.8437	0.7923	0.7551
	RMSE↓		2.0249	2.3179	2.4390	2.1725	2.2857	2.4617
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.6786	0.5827	0.5314	0.6953	0.6217	0.5655
	Multi-CSI↑	Class 0	0.9258	0.8857	0.8568	0.9337	0.9072	0.8807
		Class 1	0.5753	0.4774	0.4298	0.5868	0.5119	0.4547
		Class 2	0.3408	0.2972	0.2480	0.3757	0.3154	0.2758
		Class 3	0.0854	0.0845	0.0470	0.1483	0.0742	0.0607
	Macro CSI↑		0.4818	0.4362	0.3954	0.5111	0.4522	0.4180
	Micro CSI↑		0.8528	0.7921	0.7512	0.8643	0.8224	0.7825
	RMSE↓		1.9637	2.2184	2.4349	1.9236	2.1660	2.3704



ตารางที่ 67 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 6 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70][1,3,10,30]		
			Timestep			Timestep		
			1	2	3	1	2	3
6	Binary CSI↑		0.7815	0.7299	0.6705	0.8050	0.7340	0.6982
	Multi-CSI↑	Class 0	0.9342	0.9176	0.8940	0.9403	0.9120	0.9016
		Class 1	0.6171	0.5659	0.5167	0.6479	0.5757	0.5391
		Class 2	0.1091	0.0734	0.0872	0.1481	0.0428	0.0155
		Class 3	0.0027	0.0000	0.0000	0.0000	0.0000	0.0000
	Macro CSI↑		0.4158	0.3892	0.3745	0.4341	0.3826	0.3640
	Micro CSI↑		0.8299	0.8051	0.7743	0.8411	0.7978	0.7821
	RMSE↓		3.4700	3.7223	3.7903	3.3127	3.6728	3.9442
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.7989	0.7179	0.6820	0.5051	0.4633	0.4329
	Multi-CSI↑	Class 0	0.9372	0.9021	0.8889	0.8500	0.8289	0.8121
		Class 1	0.6389	0.5679	0.5326	0.4476	0.3994	0.3688
		Class 2	0.1006	0.0755	0.0337	0.1130	0.0908	0.0778
		Class 3	0.0001	0.0000	0.0000	0.0087	0.0039	0.0020
	Macro CSI↑		0.4192	0.3864	0.3638	0.3548	0.3308	0.3152
	Micro CSI↑		0.8341	0.7874	0.7679	0.7383	0.7084	0.6864
	RMSE↓		3.4106	3.5683	3.8255	4.2497	4.3323	4.3986

ตารางที่ 68 ตารางเปรียบเทียบผลลัพธ์การทำนายจากชุดข้อมูลทดสอบชุดที่ 7 ด้วยแบบจำลองการเรียนรู้เชิงลึกที่ถูกแก้ไขการแก้ไขค่าน้ำหนักค่าความสูญเสียเองในการฝึกแบบจำลองการเรียนรู้เชิงลึกด้วย [1,10,30,70] ที่ถูกฝึกด้วยชุดข้อมูลรูปแบบต่างๆ

Test Case	Metrics		WNI อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN อัตราภาคที่ 10 นาที ปรับค่าน้ำหนักแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
7	Binary CSI↑		0.7360	0.6453	0.5913	0.7177	0.6314	0.5872
	Multi-CSI↑	Class 0	0.9660	0.9478	0.9351	0.9618	0.9428	0.9326
		Class 1	0.6383	0.5526	0.5011	0.6218	0.5368	0.4974
		Class 2	0.2709	0.2307	0.1270	0.3578	0.2948	0.2040
		Class 3	0.0313	0.0160	0.0049	0.0141	0.0027	0.0011
	Macro CSI↑		0.4766	0.4368	0.3920	0.4889	0.4443	0.4088
	Micro CSI↑		0.9205	0.8887	0.8665	0.9142	0.8811	0.8634
	RMSE↓		1.6502	1.8023	1.9683	1.5976	1.7732	1.9197
	Metrics		WNI-GsMAP-DAIN-MBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]			WNI-GsMAP-DAIN-MMBC อัตราภาคที่ 10 นาที แก่ค่าน้ำหนักในแบบจำลองแบบ [1,10,30,70]		
			Timestep			Timestep		
			1	2	3	1	2	3
	Binary CSI↑		0.7230	0.6322	0.5809	0.7126	0.6261	0.5645
	Multi-CSI↑	Class 0	0.9631	0.9433	0.9308	0.9616	0.9434	0.9273
		Class 1	0.6265	0.5397	0.4922	0.6149	0.5316	0.4749
		Class 2	0.2528	0.2652	0.2017	0.3262	0.2751	0.2388
		Class 3	0.0024	0.0038	0.0004	0.0265	0.0100	0.0021
	Macro CSI↑		0.4612	0.4380	0.4063	0.4823	0.4400	0.4108
	Micro CSI↑		0.9151	0.8818	0.8606	0.9134	0.8818	0.8551
	RMSE↓		1.6941	1.7857	1.9252	1.6460	1.8077	1.9304

## บรรณานุกรม

1. Paszke, A., et al., *Pytorch: An imperative style, high-performance deep learning library*. 2019. **32**: p. 8026-8037.
2. Van Der Walt, S., S.C. Colbert, and G. Varoquaux, *The NumPy array: a structure for efficient numerical computation*. Computing in science engineering, 2011. **13**(2): p. 22-30.
3. 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.
4. Shi, X., et al., *Convolutional LSTM network: A machine learning approach for precipitation nowcasting*. 2015.
5. Wang, Y., et al. *Memory in memory: A predictive neural network for learning higher-order non-stationarity from spatiotemporal dynamics*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019.
6. Shi, X., et al., *Deep learning for precipitation nowcasting: A benchmark and a new model*. 2017.
7. Schaefer, J.T., *The critical success index as an indicator of warning skill*. Weather forecasting, 1990. **5**(4): p. 570-575.
8. Okamoto, K., et al. *The global satellite mapping of precipitation (GSMaP) project*. in *Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS'05*. 2005. IEEE.
9. Agrawal, S., et al., *Machine learning for precipitation nowcasting from radar images*. arXiv:1912.12132, 2019.
10. Bao, W., et al. *Depth-aware video frame interpolation*. in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2019.
11. Anagnostou, E.N., et al., *Mean-field rainfall bias studies for WSR-88D*. Journal of Hydrologic Engineering, 1998. **3**(3): p. 149-159.
12. Ivashkin, V. and V. Lebedev *Spatiotemporal Data Fusion for Precipitation Nowcasting*. 2018. arXiv:1812.10915.

13. Paper, D. and D.J.H.-o.S.-L.f.M.L.A.D.S.F.w.P. Paper, *Scikit-Learn Classifier Tuning from Complex Training Sets*. 2020: p. 165-188.
14. Pedregosa, F., et al., *Scikit-learn: Machine learning in Python*. 2011. **12**: p. 2825-2830.



## ประวัติผู้เขียน

ชื่อ-สกุล	นายวิคม โตศิริ
วัน เดือน ปี เกิด	8 เมษายน 2536
สถานที่เกิด	จังหวัดเชียงใหม่
วุฒิการศึกษา	คณะวิศวกรรมศาสตร์ ภาควิชาวิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี



จุฬาลงกรณ์มหาวิทยาลัย  
CHULALONGKORN UNIVERSITY