



การประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงการปลูกข้าวด้วยข้อมูลอนุกรมเวลาภาพถ่ายจาก
ดาวเทียมระบบ SYNTHETIC APERTURE RADAR

AN APPLICATION OF DEEP LEARNING FOR RICE TRANSPLANTATION STAGE
CLASSIFICATION BY USING SYNTHETIC APERTURE RADAR TIME SERIES DATA

อรรณภูมิ นารณกุลพัฒน์

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2567

การประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงการปลูกข้าวด้วยข้อมูลอนุกรมเวลาภาพถ่ายจาก
ดาวเทียมระบบ SYNTHETIC APERTURE RADAR



ปริญญานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปรัชญาดุษฎีบัณฑิต สาขาวิชาภูมิสารสนเทศ
คณะสังคมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2567
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

AN APPLICATION OF DEEP LEARNING FOR RICE TRANSPLANTATIONSTAGE
CLASSIFICATION BY USING SYNTHETIC APERTURE RADAR TIME SERIES DATA



ATTAWUT NARDKULPAT

A Dissertation Submitted in Partial Fulfillment of the Requirements
for the Degree of DOCTOR OF PHILOSOPHY
(Ph.D. (Geoinformatics))

Faculty of Social Sciences, Srinakharinwirot University

2024

Copyright of Srinakharinwirot University

ปริญญานิพนธ์
เรื่อง
การประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงการปลูกข้าวด้วยข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียม
ระบบ SYNTHETIC APERTURE RADAR
ของ
อรรณวุฒิ นารณกุลพัฒน์

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาปรัชญาดุษฎีบัณฑิต สาขาวิชาภูมิสารสนเทศ

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าปริญญานิพนธ์

..... ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย บุญพุก)

..... ที่ปรึกษาร่วม
(ผู้ช่วยศาสตราจารย์ ดร.อสมารณ สิริธิ)

..... ประธาน
(ผู้ช่วยศาสตราจารย์ ดร.สรวิศ สุภเวชย์)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ชูเดช โลศิริ)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.สถาพร มนต์ประภัสสร)

ชื่อเรื่อง	การประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงการปลูกข้าวด้วยข้อมูล อนุกรมเวลาภาพถ่ายจากดาวเทียมระบบ SYNTHETIC APERTURE RADAR
ผู้วิจัย	อรรณวุฒิ นารณกุลพัฒน์
ปริญญา	ปรัชญาดุษฎีบัณฑิต
ปีการศึกษา	2567
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. วุฒิชัย บุญพุก
อาจารย์ที่ปรึกษาร่วม	ผู้ช่วยศาสตราจารย์ ดร. อสมารณ์ สิทธิ

ประเทศไทยเป็นหนึ่งในประเทศที่มีการส่งออกข้าวเป็นลำดับต้นๆของโลก โดยผลผลิตข้าวที่ส่งออกสู่ตลาดในแต่ละเดือนมีความแตกต่างกันตามช่วงเวลาการเริ่มปลูกข้าวโดยเฉพาะข้าวไม่ไวแสงที่มีช่วงเวลาการเพาะปลูกที่สั้นกว่าข้าวไวแสง อันเนื่องมาจากความแตกต่างด้านภูมิอากาศในการเพาะปลูกข้าวและปริมาณน้ำในแต่ละพื้นที่ ส่งผลให้การคาดการณ์ผลผลิตในแต่ละช่วงเวลามีความท้าทาย ในการศึกษาวิจัยครั้งนี้มีวัตถุประสงค์ในการศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ Synthetic Aperture Radar (SAR) โดยมีการดำเนินการเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR และพัฒนากระบวนการเรียนรู้เชิงลึกในการสกัดพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR โดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายดาวเทียมระบบ SAR จากดาวเทียม Sentinel-1 จำนวน 28 ภาพ ในปี พ.ศ. 2565 ครอบคลุมพื้นที่ศึกษาจังหวัดสุพรรณบุรี ผลการศึกษาพบว่า การจำแนกพื้นที่เพาะปลูกข้าวพบว่า ทั้งการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกให้ความแม่นยำสูง โดยแบบจำลอง Random Forest ให้ค่าความถูกต้องโดยรวมสูงสุดที่ 93.73% เมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือนโพลาริเซชัน VH+VV ในขณะที่สถาปัตยกรรม Gated Recurrence Unit ให้ผลดีที่สุดในกลุ่มการเรียนรู้เชิงลึกที่ 92.44% ด้วยข้อมูลรูปแบบเดียวกัน สำหรับการจำแนกช่วงระยะเวลาการเพาะปลูกข้าว (พฤษภาคม-สิงหาคม) พบว่าข้อมูลค่าเฉลี่ยรายเดือนให้ประสิทธิภาพสูงกว่าข้อมูลอนุกรมเวลาเต็มอย่างมีนัยสำคัญ โดยแบบจำลอง Bidirectional Long-Short Term Memory ให้ค่าความถูกต้องโดยรวมสูงสุดที่ 71.65% เมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือน VH

คำสำคัญ : การเรียนรู้ของเครื่อง, การจำแนกพื้นที่ปลูกข้าว, การจำแนกช่วงระยะเวลาเพาะปลูก, Sentinel-1, ข้อมูลอนุกรมเวลา

Title	AN APPLICATION OF DEEP LEARNING FOR RICE TRANSPLANTATIONSTAGE CLASSIFICATION BY USING SYNTHETIC APERTURE RADAR TIME SERIES DATA
Author	ATTAWUT NARDKULPAT
Degree	DOCTOR OF PHILOSOPHY
Academic Year	2024
Thesis Advisor	Assistant Professor Dr. Wuttichai Boonpook
Co Advisor	Assistant Professor Dr. Asamaporn Sitthi

Thailand is one of the world's leading rice exporters. However, the monthly rice output supplied to the market varies according to the planting start times, especially for non-photoperiod sensitive rice, which has a shorter cultivation period than photoperiod-sensitive varieties. These variations are due to differing planting calendars and irrigation availability in each area, making production forecasting for specific periods challenging. This study aims to investigate the performance of deep learning for classifying rice planting periods using Synthetic Aperture Radar (SAR) time-series data. This involves comparing the performance of machine learning and deep learning for classifying SAR time-series data and developing a deep learning process to extract rice cultivation areas from this data. The research utilized a time-series dataset of 28 SAR images from the Sentinel-1 satellite, acquired in 2022 over the study area of Suphan Buri province. The results for rice cultivation area classification showed that both machine learning and deep learning achieved high accuracy. The Random Forest model yielded the highest overall accuracy at 93.73% using monthly mean VH+VW data, while the Gated Recurrent Unit model performed best among the deep learning models with 92.44% accuracy using the same data configuration. For the classification of the rice planting period (May-August), it was found that monthly mean data significantly outperformed the full time-series data. The Bidirectional Long-Short Term Memory model achieved the highest overall accuracy of 71.65% when using monthly mean VH data.

Keyword : Machine Learning, Rice Crop Classification, Planting Period Classification, Sentinel-1, Time Series

กิตติกรรมประกาศ

ปริญญานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดี ด้วยความช่วยเหลือและได้รับคำแนะนำจากผู้ช่วยศาสตราจารย์ ดร.วุฒิชัย บุญพุก อาจารย์ที่ปรึกษาหลักปริญญานิพนธ์ และผู้ช่วยศาสตราจารย์ ดร.อสมารักษ์ สิทธิ อาจารย์ที่ปรึกษาร่วม ที่ให้คำแนะนำ ความรู้และข้อคิดเห็นในการดำเนินการวิจัยตลอดระยะเวลาการศึกษา และช่วยตรวจสอบและแก้ไขปริญญานิพนธ์ฉบับนี้ให้มีความสมบูรณ์ และขอขอบพระคุณกรรมการสอบป้องกันปริญญานิพนธ์ทุกท่าน ประกอบไปด้วย ผู้ช่วยศาสตราจารย์ ดร.สรวิศ สุภเวชย์ ผู้ช่วยศาสตราจารย์ ดร.ชูเดช โลศิริ และผู้ช่วยศาสตราจารย์ ดร.สถาพร มนต์ประภัสสร ที่กรุณาให้ความคิดเห็นและข้อเสนอแนะต่าง ๆ เพื่อนำไปปรับปรุงแก้ไขปริญญานิพนธ์ฉบับนี้ให้สมบูรณ์ยิ่งขึ้น

ขอขอบคุณความช่วยเหลือจากคุณศักดิ์สิทธิ์ กล้าโทก นักวิเคราะห์นโยบายและแผนชำนาญการ ศูนย์สารสนเทศการเกษตร สำนักงานเศรษฐกิจการเกษตร ที่ให้ความอนุเคราะห์ห้องสมุดความรู้เรื่องข้าว ตลอดจนจนถึงองค์ความรู้ในการประยุกต์การสำรวจระยะไกลกับการจำแนกข้าว

ท้ายนี้ผู้เขียนขอกราบขอบพระคุณพ่อพัฒนภูมิ และคุณแม่พิมพ์มณี นารกุลพัฒน์ ที่ให้การอุปการะอบรมเลี้ยงดู ตลอดจนส่งเสริมการศึกษา และให้กำลังใจเป็นอย่างดี และขอขอบคุณความช่วยเหลือจากคณาจารย์รวมถึงเจ้าหน้าที่ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ทุกท่าน

อรรณู ฒิ นารกุลพัฒน์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฅ
สารบัญรูปภาพ.....	ฑ
บทที่ 1 บทนำ	1
1. ที่มาและความสำคัญของปัญหา.....	1
2. วัตถุประสงค์ของการศึกษา.....	6
3. ขอบเขตการศึกษา.....	6
3.1 ขอบเขตเชิงเวลา	6
3.2 ขอบเขตเชิงพื้นที่.....	6
3.3 ขอบเขตเชิงข้อมูล	6
3.4 ขอบเขตเชิงเนื้อหา	7
4. นิยามศัพท์เฉพาะ	7
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	9
1. การเจริญเติบโตข้าวในประเทศไทย	9
2. การปลูกข้าวในจังหวัดสุพรรณบุรี	12
3. หลักการถ่ายภาพในระบบ RADAR และภาพถ่ายระบบ SAR	14
4. การวิเคราะห์อนุกรมเวลา (Time series analysis)	16
5. การเรียนรู้ของเครื่อง (Machine Learning).....	17

6. Support Vector Machine (SVM).....	18
7. Random Forest (RF).....	19
8. XGBoost (eXtreme Gradient Boosting)	21
9. Grid Search และ Cross-Validation	22
10. โครงข่ายประสาทเทียม (Artificial Neural Network).....	23
10.1 ส่วนประกอบของโครงข่ายประสาทเทียม	23
10.2 ฟังก์ชันกระตุ้น (Activation Function).....	25
10.3 ฟังก์ชันเรกติไฟด์เชิงเส้น (Rectified liner Unit - ReLU)	25
10.4 ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax function).....	25
10.5 ฟังก์ชันต้นทุน (Cost Function)	26
10.6 วิธีการหาค่าที่เหมาะสม (Optimization).....	26
10.7 การแพร่กระจายย้อนกลับ	27
11. โครงข่ายแบบ Recurrent Neural Network (RNN).....	28
12. โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM).....	31
14. โครงข่ายประสาทเทียมแบบ Bidirectional Long Short-Term Memory (BI-LSTM).....	36
15. การวัดประสิทธิภาพ (Evaluation).....	36
16. การกำหนดกลุ่มตัวอย่าง (Sampling)	38
17. งานวิจัยที่เกี่ยวข้องกับการประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงอายุการปลูกข้าว ด้วย ข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียมระบบ SAR.....	39
17.1 งานวิจัยด้านการประยุกต์การจำแนกพื้นที่ปลูกข้าวด้วยข้อมูลภาพถ่ายจากดาวเทียม ระบบออปติคัล.....	39
17.2 งานวิจัยด้านการประยุกต์จำแนกพื้นที่ปลูกข้าวด้วยข้อมูลภาพถ่ายดาวเทียมระบบ SAR	40

17.3 งานวิจัยด้านการประยุกต์การจำแนกพื้นที่ปลูกข้าวข้อมูลภาพถ่ายจากดาวเทียมระบบ SAR.....	41
17.4 งานวิจัยด้านการประยุกต์การเรียนรู้เชิงลึกกับการจำแนกพื้นที่ปลูกข้าวข้อมูลภาพถ่ายจากดาวเทียมระบบ SAR.....	42
บทที่ 3 วิธีดำเนินการวิจัย.....	45
1. พื้นที่ศึกษา	45
2. ข้อมูลที่ใช้ในการศึกษา	47
3. ขั้นตอนการดำเนินการวิจัย.....	49
3.1 การเตรียมข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1	50
3.2 การเตรียมข้อมูล (Preparation Data)	51
3.3 การเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR	55
3.4 การเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR.....	57
3.5 การพัฒนากระบวนการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR	59
บทที่ 4 ผลการดำเนินการวิจัย.....	62
4.1 ผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้ของเครื่อง.....	62
4.2 ผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้เชิงลึก.....	81
4.3 การเปรียบเทียบแบบจำลองที่ดีที่สุดสำหรับการจำแนกพื้นที่ปลูกข้าว	101
4.4 ผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้เชิงลึก.....	105
บทที่ 5 อภิปรายและสรุปผล	126

5.1 อภิปรายผลการศึกษา	126
5.2 สรุปผลการศึกษา	130
5.3 ข้อเสนอแนะ	131
บรรณานุกรม	132
ประวัติผู้เขียน	133




สารบัญตาราง

หน้า

ตาราง 1 ดาวเทียมในระบบเรดาร์ที่นิยมใช้งานในปัจจุบัน	16
ตาราง 2 Confusion Matrix ของค่าที่ถูกจำแนก (Prediction) เทียบกับผลลัพธ์จริง (Actual)	36
ตาราง 3 ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1 ที่ใช้ดำเนินการวิจัย	49
ตาราง 4 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพอนุกรมเวลา SAR	63
ตาราง 5 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	65
ตาราง 6 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH	67
ตาราง 7 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VV	68
ตาราง 8 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH+VV	69
ตาราง 9 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH	71
ตาราง 10 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV	72
ตาราง 11 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV	74
ตาราง 12 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลภาพอนุกรมเวลา SAR	76
ตาราง 13 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	77
ตาราง 14 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพอนุกรมเวลา SAR	83

ตาราง 15 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	84
ตาราง 16 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH	86
ตาราง 17 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VV.....	87
ตาราง 18 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH+VV	88
ตาราง 19 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH	90
ตาราง 20 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV	91
ตาราง 21 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV	93
ตาราง 22 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพอนุกรมเวลา SAR.....	95
ตาราง 23 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	96
ตาราง 24 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพอนุกรมเวลา SAR	108
ตาราง 25 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	109
ตาราง 26 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VH.....	110
ตาราง 27 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VV.....	112
ตาราง 28 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH+VV	113

ตาราง 29 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH.....	115
ตาราง 30 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV	116
ตาราง 31 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV.....	117
ตาราง 32 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกร่วมกับข้อมูลภาพอนุกรมเวลา SAR.....	119
ตาราง 33 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกข้อมูลอนุกรมค่าเฉลี่ยภาพ SAR.....	120



สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 การเจริญเติบโตของข้าวในแต่ละระยะ.....	10
ภาพประกอบ 2 การบินถ่ายภาพในระบบ RADAR.....	14
ภาพประกอบ 3 การหาไฮเปอร์เพลนที่เหมาะสมที่สุด	19
ภาพประกอบ 4 โครงสร้างโครงข่ายประสาทเทียม	24
ภาพประกอบ 5 โครงสร้างของโครงข่าย Recurrent Neural Network	29
ภาพประกอบ 6 การทำงานของโครงข่าย Recurrent Neural Network.....	29
ภาพประกอบ 7 การวนซ้ำของโครงข่าย Recurrent Neural Network.....	30
ภาพประกอบ 8 การทำงานของ Long Short-Term Memory	31
ภาพประกอบ 9 Gate ภายใน Cell ของ Long Short-Term Memory	32
ภาพประกอบ 10 การทำงานของ Gated Recurrent Unit (GRU).....	35
ภาพประกอบ 11 การทำงานของ Bidirectional Long Short-Term Memory (BI-LSTM).....	36
ภาพประกอบ 12 พื้นที่ศึกษาในการวิจัย โดย (ก) ขอบเขตประเทศไทย (ข) พื้นที่ศึกษา และ (ค) แปลงปลูกข้าวที่มีช่วงเวลาการปลูกที่ต่างกัน.....	46
ภาพประกอบ 13 ภาพถ่ายดาวเทียม Sentinel-1 ในพื้นที่ศึกษา.....	47
ภาพประกอบ 14 การประมวลผลข้อมูลค่าเฉลี่ยรายเดือน.....	48
ภาพประกอบ 15 ขั้นตอนการเตรียมข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1.....	51
ภาพประกอบ 16 การกระจายเชิงพื้นที่ของจุดข้อมูล.....	52
ภาพประกอบ 17 ข้อมูลพื้นที่ปลูกข้าวจำแนกตามช่วงระยะเวลาเริ่มปลูก.....	53
ภาพประกอบ 18 รูปแบบการกระเจิงของสัญญาณเฉลี่ยในแต่ละเดือนจำแนกตามการใช้ประโยชน์ ที่ดิน โดย (ก) แสดงโพลาไรเซชัน VH และ (ข) โพลาไรเซชัน VV.....	54
ภาพประกอบ 19 ขั้นตอนการดำเนินการวิจัย	54

ภาพประกอบ 20 ขั้นตอนการเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR	57
ภาพประกอบ 21 ขั้นตอนการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR.....	59
ภาพประกอบ 22 ขั้นตอนการพัฒนากระบวนการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR	61
ภาพประกอบ 23 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลอนุกรมเวลา SAR	78
ภาพประกอบ 24 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	79
ภาพประกอบ 25 ผลการจำแนกพื้นที่เพาะปลูกข้าวข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV ร่วมกับแบบจำลองด้วยวิธี Random Forest เทียบกับข้อมูลการใช้ประโยชน์ที่ดินจากกรมพัฒนาที่ดิน ปี พ.ศ.2564	81
ภาพประกอบ 26 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพอนุกรมเวลา SAR.....	97
ภาพประกอบ 27 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพค่าเฉลี่ย SAR รายเดือน	98
ภาพประกอบ 28 ผลการจำแนกพื้นที่เพาะปลูกข้าวข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV ร่วมกับแบบจำลองด้วยโครงข่ายประสาทเทียม GRU เทียบกับข้อมูลการใช้ประโยชน์ที่ดินจากกรมพัฒนาที่ดิน ปี พ.ศ.2564	100
ภาพประกอบที่ 29 เปรียบเทียบความถูกต้องโดยรวมของการเรียนรู้ของเครื่อง	101
ภาพประกอบที่ 30 เปรียบเทียบสัมประสิทธิ์แคปปาของการเรียนรู้ของเครื่อง.....	101
ภาพประกอบที่ 31 เปรียบเทียบความถูกต้องโดยรวมของการเรียนรู้เชิงลึก.....	102
ภาพประกอบที่ 32 เปรียบเทียบสัมประสิทธิ์แคปปาของการเรียนรู้เชิงลึก	102
ภาพประกอบที่ 33 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่แหล่งน้ำด้วยการเรียนรู้ของเครื่อง	103

ภาพประกอบที่ 34 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่แหล่งน้ำด้วยการเรียนรู้เชิงลึก.....	103
ภาพประกอบที่ 35 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่ปลูกข้าวด้วยการเรียนรู้ของเครื่อง	103
ภาพประกอบที่ 36 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่ปลูกข้าวด้วยการเรียนรู้เชิงลึก.....	104
ภาพประกอบที่ 37 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เกษตรกรรมด้วยการเรียนรู้ของเครื่อง	104
ภาพประกอบที่ 38 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เกษตรกรรมด้วยการเรียนรู้เชิงลึก	104
ภาพประกอบที่ 39 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เมืองและพื้นที่อื่นๆด้วยการเรียนรู้ของเครื่อง.....	105
ภาพประกอบที่ 40 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เมืองและพื้นที่อื่นๆด้วยการเรียนรู้เชิงลึก.....	105
ภาพประกอบ 41 ผลการจำแนกช่วงเวลาการปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกข้อมูลอนุกรมค่าเฉลี่ยภาพ SAR.....	121
ภาพประกอบ 42 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกข้อมูลอนุกรมค่าเฉลี่ยภาพ SAR.....	122
ภาพประกอบ 43 ผลการจำแนกช่วงเวลาเพาะปลูกข้าวด้วยข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV ร่วมกับโครงข่าย BI-LSTM เทียบกับข้อมูลการเพาะปลูกข้าวนาปี ปี พ.ศ.2565 จากสำนักงานเศรษฐกิจการเกษตร	124

บทที่ 1

บทนำ

1. ที่มาและความสำคัญของปัญหา

ประเทศไทยเป็นหนึ่งในประเทศที่มีการส่งออกสินค้าเกษตรกรรมลำดับต้น ๆ ของโลก โดยเฉพาะอย่างยิ่งการส่งออกข้าว ด้วยลักษณะภูมิประเทศของประเทศไทยที่ตั้งอยู่ในบริเวณมรสุมเขตร้อนและมีปากแม่น้ำหลายสายจึงทำให้มีความอุดมสมบูรณ์ของดินและน้ำที่เหมาะสมต่อการเจริญเติบโตของพืช โดยในปี พ.ศ. 2565/2566 พื้นที่เกษตรกรรมส่วนใหญ่ของประเทศไทยถูกใช้สำหรับเพาะปลูกข้าวทั้งหมด 73.94 ล้านไร่ แบ่งเป็นพื้นที่ปลูกข้าวนาปี 62.84 ล้านไร่ และพื้นที่ปลูกข้าวนาปรัง 11.10 ล้านไร่ มีผลผลิตข้าวเปลือกทั้งหมด 33.91 ล้านตัน แบ่งออกเป็นข้าวนาปี 26.71 ล้านตันและข้าวนาปรัง 7.20 ล้านตัน ข้าวจึงถือว่าเป็นสินค้าเกษตรหลักของประเทศไทยทั้งเพื่อการบริโภคภายในประเทศและการส่งออก จากข้อมูลการส่งออกพบว่าในปี พ.ศ. 2565 ประเทศไทยสามารถส่งออกข้าวได้ 7.7 ล้านตัน เป็นผู้ส่งออกอันดับ 2 ของโลกรองจากประเทศอินเดีย (22.24 ล้านตัน) (สำนักงานนโยบายและยุทธศาสตร์การค้า, 2567) อย่างไรก็ตามผลผลิตข้าวที่ถูกส่งออกสู่ตลาดในแต่ละเดือนมีความแตกต่างกันอย่างมาก อันเนื่องมาจากความแตกต่างด้านพฤติกรรมการเพาะปลูกข้าวในแต่ละพื้นที่ จากข้อมูลผลผลิตข้าวในปี พ.ศ. 2562 พบว่าข้าวนาปีให้ผลผลิตสูงสุดในช่วงเดือนพฤศจิกายน ความแตกต่างของผลผลิตในแต่ละช่วงเวลานี้มีอิทธิพลต่อราคาขายข้าวตามกลไกตลาด ดังนั้นการคาดการณ์ผลผลิตข้าวในแต่ละช่วงเวลาจึงมีความสำคัญอย่างยิ่งต่อการกำหนดราคาขายข้าว โดยการมีข้อมูลพื้นที่เพาะปลูก ช่วงเวลาการเพาะปลูกข้าวหรือระยะการเจริญเติบโตของข้าวในแต่ละแปลงเพาะปลูก สามารถเป็นข้อมูลพื้นฐานในการคาดการณ์ผลผลิตได้เพื่อให้หน่วยงานที่รับผิดชอบสามารถนำไปใช้วางแผนจัดในการปริมาณข้าวที่ออกสู่ตลาดได้อย่างเหมาะสม ประเมินผลผลิตล่วงหน้า และคาดการณ์ราคาได้อย่างมีประสิทธิภาพมากขึ้น จะช่วยสนับสนุนการตัดสินใจเชิงนโยบายและการบริหารจัดการภาคการเกษตรของประเทศ

ในปัจจุบันกระบวนการสำรวจข้อมูลพื้นที่เพาะปลูกข้าวนั้นมีอยู่ 2 วิธีหลัก ได้แก่ การสำรวจข้อมูลจากภาคพื้นดินโดยการเข้าไปสำรวจหรือสอบถามกับประชาชนในแต่ละพื้นที่ วิธีการดังกล่าวใช้ต้นทุนในการสำรวจข้อมูลค่อนข้างสูงและใช้เวลานานในการเก็บบันทึกข้อมูล แต่ข้อมูลที่ได้จะมีความถูกต้องและแม่นยำ (ผ่องแผ้ว, 2543) และการประยุกต์ใช้เทคโนโลยีสำรวจจากระยะไกลในการสำรวจข้อมูลพื้นที่เพาะปลูกข้าว (Remote Sensing) (Kuenzer & and Knauer, 2013) วิธีนี้จะเป็นการได้มาข้อมูลเกี่ยวกับวัตถุ พื้นที่ และปรากฏการณ์บนพื้นผิวโลก โดยใช้เครื่องรับรู้ (Sensor) โดยปราศจากการสัมผัสวัตถุเป้าหมาย มาเป็นเครื่องมือที่ช่วยเก็บข้อมูลจากพื้นที่ขนาดใหญ่และนำมา

วิเคราะห์หรือศึกษาเกี่ยวกับข้าวได้ (Liu et al., 2019) การประยุกต์การสำรวจจากระยะไกลยังนำมาใช้ในการศึกษาข้อมูลด้านการเกษตรกรรมอื่น ๆ โดย ศศิกานต์ ไพลกลาง และคณะ (2562) ได้นำข้อมูลภาพถ่ายดาวเทียม Landsat 8 จำแนกพื้นที่ปลูกพืชเศรษฐกิจประกอบไปด้วย มันสำปะหลัง อ้อยและข้าวโพด ด้วยแบบจำลองซัพพอร์ทเวกเตอร์แมชชีน (Support Vector Machine : SVM) โดยใช้ข้อมูลค่าความสว่าง (Brightness), ค่าความเขียว (Greenness), ค่าความชื้น (Wetness), ความสูง (Height), ความชัน (Slope) และข้อมูลทิศทางการรับแสง (Aspect) เข้ามาทำการประมวลผลให้ค่าความถูกต้องโดยรวมมากถึง 92.76% (ศศิกานต์ ไพลกลาง, 2563) นอกจากนี้ Wei et al., 2023 ได้ใช้ข้อมูลอนุกรมเวลาจากข้อมูลภาพถ่ายดาวเทียม Sentinel-2 จำแนกพื้นที่ปลูกข้าว โดยใช้ดัชนีพืชพรรณผลต่างแบบนอร์มอลไลซ์ (NDVI) เข้าร่วมในการจำแนกข้อมูลสิ่งปกคลุมดินอื่น ๆ โดยมีความถูกต้องโดยรวม 90% (Wei et al., 2023) และ Genc et al (2014) ประยุกต์เทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis : PCA) ร่วมกับข้อมูลอนุกรมเวลาที่ได้จากภาพถ่ายดาวเทียม Landsat 8 นำมาลดจำนวนชั้นข้อมูลก่อนทำการจำแนกพื้นที่ปลูกข้าวด้วยการใช้วิธีการจำแนกประเภทข้อมูลความน่าจะเป็นสูงสุด (Maximum Likelihood Classification) โดยมีความถูกต้องโดยรวมในการจำแนกที่ 87.89% (Genc, Inalpulat, Kizil, & Aksu, 2014)

ปัจจุบัน การบันทึกข้อมูลภาพถ่ายดาวเทียมในปัจจุบันมี 2 ระบบหลัก คือ การบันทึกข้อมูลด้วยระบบพาสซีฟเซนเซอร์ (Passive Sensor) และระบบแอคทีฟเซนเซอร์ (Active Sensor) ระบบพาสซีฟเซนเซอร์ทำการบันทึกค่าการสะท้อนพลังงานจากแสงอาทิตย์ในแต่ละช่วงคลื่น สามารถใช้จำแนกประเภทสิ่งปกคลุมดินหรือพื้นที่เพาะปลูกได้ดี โดยมีงานวิจัยที่ได้แสดงให้เห็นถึงศักยภาพของข้อมูลจากดาวเทียมระบบออปติคัล (Optical) เช่น Landsat 8 และ Sentinel-2 จำแนกพืชเศรษฐกิจ มีการประยุกต์การเรียนรู้ของเครื่อง (Machine Learning) เช่น แบบจำลอง SVM ร่วมกับข้อมูลเสริมหลายประเภทเพื่อเพิ่มความแม่นยำในการจำแนกพืชเศรษฐกิจในประเทศไทย (ศศิกานต์ ไพลกลาง, 2563) นอกจากนี้การใช้ข้อมูลอนุกรมเวลา (Time Series) จากดาวเทียมออปติคัลยังช่วยในการติดตามการเปลี่ยนแปลงชีพวัณของพืช (Phenology) และเมื่อใช้ร่วมกับเทคนิคการลดมิติข้อมูล (เช่น PCA) และแบบจำลองจำแนกประเภท (เช่น Maximum Likelihood) ก็สามารถทำการจำแนกพื้นที่ปลูกข้าวได้อย่างแม่นยำ (Genc et al., 2014) การวิเคราะห์การเปลี่ยนแปลงของดัชนีพืชพรรณ เช่น NDVI ตลอดช่วงการเติบโตจากข้อมูลอนุกรมเวลาของดาวเทียม Sentinel-2 เป็นอีกแนวทางหนึ่งที่ประสบความสำเร็จในการจำแนกพื้นที่ปลูกข้าวด้วยความถูกต้องในระดับสูง (Wei et al., 2023) อย่างไรก็ตามระบบนี้ต้องอาศัยพลังงานแสงอาทิตย์และไม่สามารถบันทึกข้อมูลทะเลขึ้นเมฆได้ จึงมีข้อจำกัดด้านเวลาการบันทึกข้อมูลและประสบปัญหาเมื่อมีเมฆปกคลุมเป็นอุปสรรคสำคัญต่อการติดตามการเพาะปลูกข้าวที่ส่วนใหญ่มักมีการเพาะปลูกในฤดูฝน ทำให้ไม่สามารถได้ข้อมูล

ภาพถ่ายดาวเทียมที่ต่อเนื่อง ข้อจำกัดดังกล่าวสามารถแก้ไขได้ด้วยการประยุกต์ใช้ระบบระบบแอดทิฟเซนเซอร์ โดยมีเทคโนโลยีที่สำคัญคือ เรดาร์ชนิดช่องเปิดสังเคราะห์ (Synthetic Aperture Radar : SAR) ทำการส่งสัญญาณไมโครเวฟไปยังพื้นผิวโลกและบันทึกสัญญาณที่สะท้อนกลับมา โดยที่ SAR มีความสามารถในการบันทึกข้อมูลภาพได้ในทุกสภาพอากาศทั้งในเวลากลางวันและกลางคืน แม้ในช่วงเวลาที่มีเมฆปกคลุมหรือฝนตก เนื่องจากช่วงคลื่นไมโครเวฟสามารถเดินทางทะลุผ่านเมฆได้ ทำให้สามารถบันทึกภาพได้อย่างต่อเนื่องตลอดฤดูเพาะปลูกและมีความไวต่อลักษณะทางกายภาพและความชื้นของพื้นผิว เป็นประโยชน์อย่างยิ่งในการจำแนกรูปแบบและติดตามการเปลี่ยนแปลงในนาข้าว (เริงศักดิ์ & ปาณัฏฐ์, 2554) ด้วยข้อดีดังกล่าวจึงมีงานวิจัยที่นำข้อมูลภาพถ่ายดาวเทียมระบบ SAR ประยุกต์ใช้ในการจำแนกและติดตามการเพาะปลูกข้าว ร่วมกับเทคนิคการเรียนรู้ของเครื่องสุริยะ ผลพูน และคณะ (2559) ประยุกต์ข้อมูล RADARSAT-2 ร่วมกับแบบจำลอง SVM พบว่าโพลาริเซชัน HH ให้ค่าความถูกต้องในการจำแนกข้าว (โดยเฉพาะข้าวนาปรัง) สูงกว่า VV (สุริยะ, ชชาติชาย, & มาชามุ, 2559) Xu et al (2019) เปรียบเทียบเทคนิค Decision Tree, Naïve Bayes และ Spectral Similarity Value (SSV) กับข้อมูลอนุกรมเวลา Sentinel-1 จำแนกพื้นที่เกษตรกรรมหลายชนิดรวมถึงข้าว พบว่าวิธี SSV ร่วมกับโพลาริเซชัน VH ให้ความถูกต้องสูงสุด (Xu, Zhang, Wang, Zhang, & Liu, 2018) Bazzi et al (2019) ใช้แบบจำลอง Random Forest กับข้อมูลอนุกรมเวลา Sentinel-1 ในการจำแนกพื้นที่ปลูกข้าวในประเทศฝรั่งเศสได้ความถูกต้องสูงถึง 96.6% (Bazzi et al., 2019) นอกจากนี้ Chang et al (2021) พัฒนาแบบจำลองโดยกำหนดเงื่อนไขจากค่าสถิติของข้อมูลอนุกรมเวลา Sentinel-1 (เช่น Backscatter Difference, Variation Rate) เพื่อจำแนกพื้นที่ปลูกข้าว ให้ผลดีกว่าการเรียนรู้ของเครื่องบางวิธี (Chang, Chen, Wang, & Chang, 2021) และ Phung et al (2020) ใช้ข้อมูล Sentinel-1 ร่วมกับข้อมูลภาคสนามในการจำแนกอายุข้าวได้อย่างแม่นยำ ($R^2 = 0.92$) (Phung, Nguyen, Nguyen-Huy, Le-Toan, & Apan, 2020) การประยุกต์ใช้ข้อมูล SAR ดังกล่าวแสดงให้เห็นถึงศักยภาพในการจำแนกข้อมูลข้าว อย่างไรก็ตามเทคนิคการเรียนรู้ของเครื่องแบบดั้งเดิม และ Rule-based จำเป็นต้องมีการสกัดลักษณะเด่น (Feature Extraction) หรือการปรับจูนค่าพารามิเตอร์ต่างๆ อย่างละเอียดเพื่อให้ได้ประสิทธิภาพสูงสุดและอาจต้องปรับแก้พารามิเตอร์ใหม่เมื่อมีการเปลี่ยนแปลงคุณลักษณะข้อมูลหรือพื้นที่ศึกษา ข้อจำกัดในการต้องปรับแก้พารามิเตอร์หรือสกัดลักษณะเด่นด้วยผู้เชี่ยวชาญดังกล่าว อาจแก้ไขได้ด้วยการประยุกต์ใช้การเรียนรู้เชิงลึก (Deep Learning : DL) เป็นกลุ่มย่อยของการเรียนรู้ของเครื่องที่ได้รับความนิยมอย่างสูงในปัจจุบัน มีความสามารถโดดเด่นในการเรียนรู้ลักษณะข้อมูลที่ซับซ้อนจากข้อมูลดิบได้โดยอัตโนมัติผ่านโครงข่ายประสาทเทียม (Neural Network) ที่เลียนแบบการทำงานของสมองมนุษย์ (LeCun, Bengio, & Hinton, 2015) โครงสร้างพื้นฐานประกอบด้วย ชั้นรับข้อมูล (Input Layer) ทำหน้าที่รับข้อมูล, ชั้นซ่อน (Hidden Layer) อาจมีหลายชั้นและในแต่ละชั้นมีเซลล์ประสาท

(Neuron) จำนวนมากทำหน้าที่ประมวลผลและสกัดลักษณะเด่นที่ซับซ้อนขึ้นเรื่อยๆ และชั้นขาออก (Output Layer) ทำหน้าที่จำแนกหรือคาดการณ์ผลลัพธ์ตามที่ต้องการ ด้วยความสามารถในการเรียนรู้ลำดับชั้นของลักษณะเด่นนี้เอง ทำให้การเรียนรู้เชิงลึกสามารถจัดการกับข้อมูลที่มีความซับซ้อนสูง เช่น ข้อมูลอนุกรมเวลา SAR ได้ดี

การศึกษาวงจรชีพลักษณะ (Phenology) ของพืชพรรณเพื่อจำแนกประเภทหรือช่วงอายุการเจริญเติบโตด้วยข้อมูลอนุกรมเวลา (Time Series) ถือว่ามีความสำคัญอย่างยิ่งยวด โดยข้อมูลอนุกรมเวลาคือการรวบรวมข้อมูลจากพื้นที่เดียวกันตามลำดับเวลาอย่างต่อเนื่อง ช่วยให้สามารถติดตามและแสดงลักษณะการเปลี่ยนแปลงที่เกิดขึ้นเมื่อเวลาผ่านไปได้ เช่น การเจริญเติบโตของพืชที่มีการเปลี่ยนแปลงลักษณะทางกายภาพในแต่ละระยะ การเปลี่ยนแปลงเหล่านี้สามารถศึกษาได้จากการวิเคราะห์ค่าสัญญาณที่บันทึกได้จากดาวเทียมหลายช่วงเวลา จะสะท้อนความแตกต่างในแต่ละระยะการเติบโต สำหรับการประยุกต์ใช้ภาพถ่ายดาวเทียมระบบ SAR กับข้อมูลอนุกรมเวลาเพื่อติดตามพืชเกษตรนั้น Anuphao Aobpaet (2022) ศึกษาค่าการสะท้อนกลับ (Backscatter) จากโพลาไรเซชัน VV และ VH ของดาวเทียม Sentinel-1 ในการติดตามการเจริญเติบโตของข้าว, ข้าวโพดเลี้ยงสัตว์, มันสำปะหลัง, และอ้อย ตั้งแต่เริ่มเพาะปลูกจนเก็บเกี่ยว ผลการศึกษาพบว่า ค่า Backscatter ของข้าวมีความอ่อนไหวและเปลี่ยนแปลงไปตามช่วงการเจริญเติบโตอย่างมีนัยสำคัญ บ่งชี้ว่าคุณลักษณะการสะท้อนกลับของ SAR ในรูปแบบอนุกรมเวลามีศักยภาพในการนำมาใช้จำแนกข้อมูลข้าวและระยะการเติบโตได้ การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกกับข้อมูลอนุกรมเวลา SAR ดังกล่าวได้แสดงให้เห็นถึงประสิทธิภาพประกอบเพิ่มขึ้นในการจำแนกข้อมูลพืชเกษตรที่มีความซับซ้อน (Aobpaet, 2022) และ Qu et al (2020) ทำการจำแนกพื้นที่ปลูกข้าวและพืชอื่นรวม 5 ประเภทโดยนำข้อมูลอนุกรมเวลา Sentinel-1 มาทดสอบกับโครงข่ายประสาทเทียมหลากหลายรูปแบบ อาทิ Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Gated Recurrent Unit (GRU) และแบบจำลองที่พัฒนาขึ้นเอง (DSCRNN) ผลการทดลองพบว่าทุกแบบจำลองให้ค่าความถูกต้องสูง (93.1% - 96.03%) แสดงให้เห็นถึงความสามารถของโครงข่ายประสาทเทียมที่แตกต่างกันในการเรียนรู้ลักษณะเด่นจากอนุกรมเวลา SAR (Qu, Zhao, Yuan, & Chen, 2020) อีกทั้ง Jo H W, et al (2020) ยังได้แสดงให้เห็นว่าการใช้เทคนิคการเรียนรู้เชิงลึกขั้นสูง เช่น การผสมผสานโครงข่ายที่แตกต่างกัน หรือการใช้ Domain Adaptation สามารถเพิ่มประสิทธิภาพในการจำแนกพื้นที่ปลูกข้าวด้วยข้อมูล SAR ให้มีความถูกต้องสูงถึง 96.42% (Jo et al., 2020) บ่งชี้ว่าคุณลักษณะค่าการสะท้อนกลับของ SAR ในรูปแบบของอนุกรมเวลามีศักยภาพเมื่อนำมาประยุกต์กับเทคนิคการเรียนรู้เชิงลึก แสดงให้เห็นถึงประสิทธิภาพประกอบเพิ่มขึ้นในการช่วยจำแนกข้อมูลพืชเกษตรที่มีความซับซ้อน นอกจากนี้ การวิเคราะห์อนุกรมเวลายังช่วยให้สามารถเข้าใจรูปแบบของแต่ละองค์ประกอบในข้อมูลอนุกรมเวลา เช่น แนวโน้ม (Trend), การเคลื่อนไหวตาม

ฤดูกาล (Seasonal Movement), การเคลื่อนไหวตามวัฏจักร (Cyclical Movement) และการเคลื่อนไหวผิดปกติ (Irregular Movement) เป็นสิ่งจำเป็นสำหรับการสร้างแบบจำลองที่สามารถจำแนกได้อย่างแม่นยำ

การติดตามพื้นที่เพาะปลูกข้าวโดยเฉพาะอย่างยิ่งในช่วงระยะเวลาการเจริญเติบโตหรือเดือนที่เริ่มเพาะปลูกข้าวเป็นสิ่งสำคัญอย่างยิ่งต่อการบริหารจัดการภาคการเกษตรของประเทศไทย แต่การสำรวจภาคพื้นดินมีข้อจำกัดด้านต้นทุนและเวลา ขณะที่ดาวเทียมระบบอวกาศไม่สามารถให้ข้อมูลต่อเนื่องได้ในฤดูฝนเนื่องจากปัญหาการปกคลุมของเมฆ ถึงแม้ว่าดาวเทียมระบบ SAR จะสามารถบันทึกข้อมูลภาพทะลุเมฆและให้ข้อมูลอนุกรมเวลาที่ต่อเนื่องได้ อีกทั้งยังมีการประยุกต์ใช้ร่วมกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกเพื่อจำแนกพื้นที่ข้าวและติดตามการเจริญเติบโตได้ในระดับหนึ่ง แต่การใช้การเรียนรู้ของเครื่องแบบดั้งเดิมมักต้องการการสกัดลักษณะเด่นที่ซับซ้อนและปรับปรุงค่าพารามิเตอร์ส่วนการเรียนรู้เชิงลึกแม้จะมีศักยภาพในการเรียนรู้ลักษณะเด่นจากข้อมูลอนุกรมเวลา SAR โดยอัตโนมัติ ก็ยังมีความท้าทายเรื่องความต้องการข้อมูลฝึกสอนปริมาณมากและทรัพยากรประมวลผลสูง

และด้วยความท้าทายในการคาดการณ์ผลผลิตข้าวและข้อจำกัดของเทคโนโลยีการสำรวจจากระยะไกลที่มีอยู่ การเลือกพื้นที่ศึกษาที่เหมาะสมจึงมีความสำคัญอย่างยิ่งต่องานวิจัยนี้ ผู้วิจัยเลือกจังหวัดสุพรรณบุรีเป็นพื้นที่ศึกษา เนื่องจากเป็นศูนย์กลางการผลิตข้าวที่สำคัญของประเทศ มีระบบชลประทานที่สมบูรณ์ทำให้สามารถเพาะปลูกข้าวได้ตลอดทั้งปี ส่งผลให้มีข้อมูลแปลงนาข้าวที่หลากหลาย อีกทั้งมีการเพาะปลูกข้าวในช่วงเวลาที่แตกต่างกัน จึงเป็นสาเหตุโดยตรงที่ทำให้การคาดการณ์ผลผลิตมีความคลาดเคลื่อน อีกทั้งเป็นที่ตั้งของสถาบันวิทยาศาสตร์ข้าวแห่งชาติ ที่ช่วยสนับสนุนการสร้างชุดข้อมูลและการตรวจสอบความถูกต้องของแบบจำลองให้มีความน่าเชื่อถือ

ดังนั้น งานวิจัยนี้จึงต้องการศึกษาประสิทธิภาพในการจำแนกช่วงระยะเวลาการเพาะปลูกข้าวโดยวิธีการเรียนรู้เชิงลึก โดยดำเนินการศึกษาและเปรียบเทียบประสิทธิภาพระหว่างการเรียนรู้ของเครื่อง 4 รูปแบบ ประกอบไปด้วย Support Vector Machine, Random Forest, Artificial Neural Network และ XGBoost และการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม ประกอบไปด้วย Recurrent Neural Network , Gated Recurrent Unit, Long-Short Term Memory และ Bidirectional Long-Short Term Memory เพื่อทดสอบการจำแนกพื้นที่ปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียม Sentinel-1 จากนั้นนำผลลัพธ์การจำแนกพื้นที่ปลูกข้าวที่มีความถูกต้องโดยรวมมากที่สุดใช้เป็นข้อมูลพื้นฐานในการดำเนินการทดสอบการจำแนกช่วงระยะเวลาการเพาะปลูกข้าว ด้วยโครงข่ายประสาทเทียม การเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม ประกอบไปด้วย Recurrent Neural Network, Gated Recurrent Unit, Long-Short Term Memory และ

Bidirectional Long-Short Term Memory เพื่อศึกษาประสิทธิภาพในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

2. วัตถุประสงค์ของการศึกษา

2.1 เพื่อทำการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องในการจำแนกข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

2.2 เพื่อพัฒนากระบวนการเรียนรู้เชิงลึกในการสกัดพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

2.3 เพื่อศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

3. ขอบเขตการศึกษา

3.1 ขอบเขตเชิงเวลา

การกำหนดขอบเขตเชิงเวลาสำหรับงานวิจัยนี้ พิจารณาจากปฏิทินการเพาะปลูกข้าวนาปีในพื้นที่ศึกษาจังหวัดสุพรรณบุรี โดยทั่วไปเกษตรกรส่วนใหญ่จะเริ่มดำเนินการเพาะปลูกในช่วงเดือนพฤษภาคมถึงสิงหาคม และเก็บเกี่ยวผลผลิตในเดือนตุลาคมถึงเดือนพฤศจิกายน ดังนั้น เพื่อให้การติดตามและจำแนกช่วงระยะเวลาการเพาะปลูกมีความสอดคล้องกับความเป็นจริงและสามารถนำไปใช้ประโยชน์ในการคาดการณ์ระยะเวลาเก็บเกี่ยวได้ งานวิจัยนี้จึงจำกัดขอบเขตการศึกษาโดยใช้ข้อมูลเฉพาะในช่วงนาปี พ.ศ. 2565

3.2 ขอบเขตเชิงพื้นที่

งานวิจัยนี้ได้มีการเลือกพื้นที่ศึกษาในพื้นที่บริเวณพื้นที่จังหวัดสุพรรณบุรี เนื่องจากพื้นที่ดังกล่าวมีการทำเกษตรกรรมทั่วทั้งพื้นที่ศึกษาทั้งพืชสวน พืชไร่ และการเพาะปลูกข้าว อีกทั้งมีการเพาะข้าวปลูกตลอดทั้งปี (นาปีและนาปรัง) เนื่องจากอยู่ในพื้นที่เขตชลประทาน แต่การเพาะปลูกข้าวในพื้นที่ดังกล่าวมีช่วงเวลาในการเพาะปลูกที่แตกต่างกันจึงทำให้การคาดการณ์ปริมาณข้าวที่ออกมาในแต่ละเดือนนั้นมีความคาดเคลื่อน อีกทั้งเป็นที่ตั้งสถาบันวิทยาศาสตร์ข้าวแห่งชาติ ที่มีการเก็บข้อมูลการเพาะปลูกข้าวอยู่ตลอดเวลา ข้อมูลดังกล่าวสามารถนำมาใช้ในการวิจัยครั้งนี้

3.3 ขอบเขตเชิงข้อมูล

งานวิจัยนี้ใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพถ่ายดาวเทียมระบบ SAR จากดาวเทียม Sentinel-1 ที่อยู่ใน Relative orbit 62 จำนวน 28 ภาพ ในโหมด Interferometric Wide

ครอบคลุมพื้นที่ศึกษา ทำการบันทึกข้อมูลภาพในช่วงระหว่างเดือนมกราคมถึงเดือนธันวาคม พ.ศ. 2565

3.4 ขอบเขตเชิงเนื้อหา

การศึกษานี้ใช้เทคนิควิธีการจำแนกด้วยการเรียนรู้ของเครื่อง ประกอบไปด้วยแบบจำลอง Support Vector Machine, Random Forest, Artificial Neural Network และ XGBoost ในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR เพื่อเปรียบเทียบประสิทธิภาพกับการเรียนรู้เชิงลึก ประกอบไปด้วยโครงข่ายประสาทเทียม Recurrent Neural Network , Gated Recurrent Unit, Long-Short Term Memory และ Bidirectional Long-Short Term Memory และในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ใช้โครงข่ายประสาทเทียม Recurrent Neural Network , Gated Recurrent Unit, Long-Short Term Memory และ Bidirectional Long-Short Term Memory ในการทดสอบ จากนั้นประเมินผลทดสอบโดยใช้เมตริกซ์ความสับสนและค่าสัมประสิทธิ์แคปปาในการประเมินประสิทธิภาพ

4. นิยามศัพท์เฉพาะ

4.1 RADAR (Radio Detection and Ranging) หมายถึง ระบบการตรวจวัดที่ต้องมีแหล่งของพลังงานที่มนุษย์สร้างขึ้น และส่งสัญญาณในช่วงคลื่นไมโครเวฟไปยังวัตถุเป้าหมายแล้ววัดความเข้มขึ้นของพลังงานที่กระจัดกระจายกลับ (Backscatter) ไปสู่เครื่องรับรู้

4.2 SAR (Synthetic Aperture Radar) หมายถึง ระบบเรดาร์ช่องเปิดสังเคราะห์ อาศัยการเคลื่อนที่ของตัวยาน (Doppler Effect) สร้างเป็นจานรับและส่งสัญญาณสมมติ ทำให้ได้รายละเอียดข้อมูลที่สูง แม้จะบินสูงจากพื้นโลกมาก ๆ

4.3 การเรียนรู้ของเครื่อง (Machine Learning) หมายถึง การให้คอมพิวเตอร์เรียนรู้งานใดงานหนึ่งจากตัวอย่างหรือประสบการณ์จำนวนหนึ่งเพื่อให้ทำงานนั้นๆได้อย่างมีประสิทธิภาพ และสามารถเพิ่มประสิทธิภาพจากการเรียนรู้ตัวอย่างหรือประสบการณ์ที่เพิ่มขึ้นได้

4.4 การเรียนรู้เชิงลึก (Deep Learning) หมายถึง วิธีการเรียนรู้แบบอัตโนมัติด้วยการเลียนแบบการทำงานของระบบประสาทของมนุษย์ โดยใช้โครงข่ายประสาทเทียมจำนวนหลายๆชั้น ทำการเรียนรู้จากข้อมูลตัวอย่าง เพื่อทำการทำนายหรือจำแนกตามที่คุณสอนได้กำหนดไว้

4.5 โครงข่ายประสาทเทียม (Network architecture) หมายถึงโครงข่ายประสาทเทียมการเรียนรู้เชิงลึก ที่มีผู้วิจัยทำการทดสอบ เป็นที่ยอมรับและมีการใช้งานในด้านต่างๆอย่างแพร่หลาย

4.6 ข้อมูลอนุกรมเวลา (Time series data) หมายถึง ชุดของข้อมูลที่เก็บรวบรวมตามระยะเวลาเป็นช่วง ๆ อย่างต่อเนื่องกัน

4.7 ข้าวนาปี (In-season rice) หมายถึง ข้าวที่ปลูกตามฤดูกาล โดยเฉพาะในช่วงฤดูฝน โดยทั่วไปจะเริ่มปลูกตั้งแต่เดือนพฤษภาคมถึงตุลาคม และเก็บเกี่ยวในช่วงเดือนตุลาคมถึงกุมภาพันธ์



บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

การดำเนินงานวิจัยครั้งนี้ได้ศึกษารวบรวมเอกสารและงานวิจัยที่เกี่ยวข้องเพื่อให้ครอบคลุมประเด็นศึกษาต่าง ๆ โดยแบ่งหัวข้อดังต่อไปนี้ คือ การเจริญเติบโตข้าวในประเทศไทย การปลูกข้าวในจังหวัดสุพรรณบุรี หลักการถ่ายภาพในระบบ RADAR และภาพถ่ายระบบ SAR การวิเคราะห์อนุกรมเวลา การเรียนรู้ของเครื่อง โครงข่ายประสาทเทียม (Artificial Neural Network) การวัดประสิทธิภาพ (Evaluation) และงานวิจัยที่เกี่ยวข้อง โดยได้มีการทบทวนงานวิจัยเกี่ยวกับการประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงอายุการปลูกข้าว ด้วยข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียมระบบ SAR


1. การเจริญเติบโตข้าวในประเทศไทย

ข้าว (*Oryza sativa* L.) เป็นธัญพืชที่มีความสำคัญอย่างยิ่งต่อเศรษฐกิจและวัฒนธรรมของประเทศไทยมายาวนาน โดยมีประวัติการเพาะปลูกย้อนหลังไปหลายพันปี ข้าวที่ปลูกในประเทศไทยส่วนใหญ่เป็นข้าวเจ้า (Indica type) มีหลากหลายพันธุ์ทั้งพันธุ์พื้นเมืองและพันธุ์ปรับปรุง การศึกษาการเจริญเติบโตของข้าวหรือชีพลักษณ์ (phenology) เป็นการติดตามการเปลี่ยนแปลงของพืชที่มีการแสดงออกที่ต่างกันในแต่ละช่วงเวลาของข้าว โดยทั่วไปวงจรชีวิตของต้นข้าวในเขตร้อนจะใช้เวลาประมาณ 100-200 วัน ขึ้นอยู่กับพันธุ์กรรมและสภาพแวดล้อม ลักษณะทางสรีรวิทยาที่สำคัญของข้าว (กรมการข้าว, 2555) ประกอบไปด้วย

- ระยะพักตัวของเมล็ด (Seed dormancy) เมล็ดข้าวบางพันธุ์ โดยเฉพาะกลุ่มอินดิกาที่เก็บเกี่ยวใหม่ ๆ อาจไม่งอกทันทีแม้สภาพแวดล้อมเหมาะสม โดยทั่วไปต้องใช้เวลาพักตัวประมาณ 15-30 วัน หรืออาจนานกว่านั้นในข้าวป่า (5-6 เดือน) การทำลายระยะพักตัวสามารถทำได้โดยใช้ความร้อนที่อุณหภูมิ 50 องศาเซลเซียส เป็นเวลา 4-5 วัน หรือโดยการตากบนพื้นซีเมนต์ 1-2 สัปดาห์

- ความไวต่อช่วงแสง (Photoperiod sensitivity) ความยาวของช่วงวันมีอิทธิพลต่อการออกดอกของข้าวบางพันธุ์ โดยสามารถแบ่งข้าวออกเป็น 2 กลุ่ม คือ ข้าวที่ไวต่อช่วงแสง (ข้าวนาปี) จะออกดอกเมื่อช่วงแสงสั้น และข้าวที่ไม่ไวต่อช่วงแสง (ข้าวนาปรัง) สามารถปลูกและออกดอกได้ตลอดปีโดยไม่ขึ้นกับความยาวของช่วงแสง

การเจริญเติบโตของข้าวแบ่งออกเป็น 3 ระยะหลักๆ ดังนี้ (ประพาส วีระแพทย์, 2520)



ภาพประกอบ 1 การเจริญเติบโตของข้าวในแต่ละระยะ

ที่มา : Andres, A 2019

1.1 การเจริญเติบโตทางลำต้นและใบ (Vegetative Growth)

- ระยะงอก (Germination Stage) ใช้เวลาประมาณ 4-7 วัน เริ่มจากรากอ่อนและยอดอ่อนแทงออกจากเมล็ด
- ระยะต้นกล้า (Seedling Stage) เป็นช่วงที่ต้นข้าวงอกจนถึงระยะก่อนแตกกอ ใช้เวลาประมาณ 20 วัน เมื่อสิ้นสุดระยะนี้ ต้นข้าวจะมีใบประมาณ 5-6 ใบ รากชุดแรกจะดูดน้ำเลี้ยงต้นอ่อน จากนั้นรากชุดที่สองจะเจริญออกจากข้อตอนล่างของต้นกล้า ต้นกล้าจะเริ่มสังเคราะห์อาหารได้เมื่อมีใบที่ 3 และ 4
- ระยะแตกกอ (Tillering Stage) เริ่มตั้งแต่ต้นข้าวเริ่มแตกกอจนถึงระยะเริ่มสร้างช่อดอกอ่อน (panicle initiation) ใช้เวลาประมาณ 30-50 วัน ขึ้นอยู่กับการตอบสนองต่อช่วงแสงของพันธุ์ข้าว การแตกกอจะเกิดเป็นระยะเวลาประมาณ 50-80 วันหลังปักดำ
- ระยะยืดปล้อง (Stem Elongation Stage) หากยังไม่ถึงระยะกำเนิดช่อดอก ต้นข้าวจะเริ่มยืดปล้องตอนล่าง ทำให้ต้นสูงขึ้น

1.2 การเจริญเติบโตทางด้านการสืบพันธุ์ (Reproductive Growth)

- เริ่มจากข้าวสร้างช่อดอกอ่อน ผ่านระยะตั้งท้อง (booting stage) จนถึงการโผล่ช่อดอกและผสมเกสร (heading, flowering, fertilization) โดยใช้เวลาประมาณ 30-35 วัน

- ระยะกำเนิดช่อดอก (Panicke Initiation) ช่อดอกเริ่มกำเนิดที่จุดเจริญของลำต้นหลักและหน่อ โดยทั่วไปเกิดขึ้นประมาณ 60-65 วันก่อนเก็บเกี่ยว
- ระยะตั้งท้อง (Booting Stage) รวงอ่อนเจริญเติบโตและพัฒนาอวัยวะต่าง ๆ ของดอกก่อนออกดอกประมาณ 15 วัน รวงข้าวจะยาวประมาณ 1.5 ซม. พร้อมกับการยืดปล้องตอนบนเพื่อดันรวงข้าวโผล่ออกจากกาบใบรวง
- ระยะออกรวง (Heading Stage) รวงข้าวเริ่มโผล่ออกจากกาบหุ้มใบธง
- ระยะดอกข้าวบาน (Flowering/Anthesis) ดอกข้าวจะบานหลังจากออกรวงประมาณ 1 วัน โดยปกติจะบานระหว่างเวลา 7.00-12.00 น. อุณหภูมิที่เหมาะสมสำหรับการบานดอกคือประมาณ 30 องศาเซลเซียส

1.3 การพัฒนาการของเมล็ด (Grain Development / Ripening Phase)

- เป็นระยะหลังการผสมเกสร ที่อาหารจากการสังเคราะห์แสงจะถูกสะสมในเมล็ด ใช้เวลาประมาณ 25-35 วัน
 - ระยะเมล็ดนํ้านม (Milk Grain Stage) 7-10 วันหลังผสมเกสร อาหารในเมล็ดข้าวยังอยู่ในรูปของเหลวคล้ายนํ้านม
 - ระยะแบ่งในเมล็ดแข็งตัว (Dough Grain Stage) 14-21 วันหลังผสมเกสร เนื้อแบ่งในเมล็ดเริ่มแข็งตัว
 - ระยะเมล็ดสุกแก่ (Mature Grain Stage) เมล็ดข้าวพัฒนาเต็มที่ ทั้งขนาด ความแข็ง ความใส และสีเขียวหมดไป โดยสิ้นสุดเมื่อเมล็ดสุกประมาณ 90% ของทั้งหมด
- เมื่อรวมระยะต่าง ๆ แล้ว ข้าวจะมีอายุประมาณ 110-120 วันสำหรับข้าวไม่ไวแสง และประมาณ 120-140 วันสำหรับข้าวไวแสง

1.4 ปัจจัยที่มีผลต่อการเจริญเติบโตของข้าว

การเจริญเติบโตของข้าวได้รับอิทธิพลจากปัจจัยหลักสองกลุ่มคือ ปัจจัยทางพันธุกรรมและปัจจัยสิ่งแวดล้อม

- ปัจจัยทางพันธุกรรม (Genetic Factors) พันธุ์ข้าวแต่ละชนิดมีลักษณะทางพันธุกรรมที่ควบคุมอัตราการเจริญเติบโต การตอบสนองต่อธาตุอาหาร การแตกกอ ความไวต่อช่วงแสง อายุการเก็บเกี่ยว และความต้านทานต่อโรคและแมลงที่แตกต่างกัน
- ปัจจัยทางกายภาพ (Abiotic Factors)
 - แสงสว่าง (Light) ข้าวต้องการแสงเพื่อการสังเคราะห์แสง โดยในฤดูนาปรังมักให้ผลผลิตสูงกว่านาปีเนื่องจากมีปริมาณรังสีแสงมากกว่า

- อุณหภูมิ (Temperature) อุณหภูมิมีผลต่อทุกระยะการเจริญเติบโต อุณหภูมิที่เหมาะสมแตกต่างกันไปในแต่ละระยะ เช่น ระยะงอก 18-40°C ระยะต้นอ่อน 25-30°C ระยะผสมพันธุ์ 30-33°C และระยะสุกแก่ 20-29°C

- น้ำ (Water) ข้าวเป็นพืชที่ต้องการน้ำมาก การขาดน้ำโดยเฉพาะในช่วงแตกกอและออกรวงจะส่งผลกระทบต่อผลผลิต

- ดิน (Soil) ดินที่เหมาะสมคือดินร่วนเหนียวหรือดินเหนียวที่มีความอุดมสมบูรณ์สูง ความเป็นกรด-ด่าง (pH) ของดินมีผลต่อการดูดใช้ธาตุอาหาร ในประเทศไทยพบปัญหาดินเปรี้ยว (Acid sulfate soils) ในภาคกลางและภาคใต้ และดินเค็ม (Saline soils) ในภาคตะวันออกเฉียงเหนือและชายฝั่งทะเล ต้องมีการจัดการที่เหมาะสม

- ธาตุอาหาร (Nutrients) ข้าวต้องการธาตุอาหารหลัก (N, P, K) และธาตุอาหารรอง/จุลธาตุในปริมาณที่เหมาะสม

- อากาศ (Air) พืชต้องการอากาศเพื่อการหายใจและก๊าซคาร์บอนไดออกไซด์เพื่อการสังเคราะห์แสง

- ปัจจัยทางชีวภาพ (Biotic Factors)

- โรคพืช (Diseases) เช่น โรคไหม้ โรคกาบใบเน่า เป็นภัยคุกคามสำคัญ

- แมลงศัตรูพืช (Insect Pests) เช่น เพลี้ยกระโดดสีน้ำตาล หนอนกอ

- วัชพืช (Weeds) รวมถึงข้าววัชพืชแย่งน้ำและธาตุอาหารจากข้าว

- จุลินทรีย์ (Microorganisms) บางชนิดมีประโยชน์ในการส่งเสริมการเจริญเติบโตหรือสร้างกลิ่นหอมในข้าว

2. การปลูกข้าวในจังหวัดสุพรรณบุรี

จังหวัดสุพรรณบุรีเป็นหนึ่งในฐานการผลิตข้าวที่สำคัญของประเทศไทย การเกษตรโดยเฉพาะอย่างยิ่งการทำนา เป็นอาชีพหลักของประชากรมากกว่าร้อยละ 80 สะท้อนให้เห็นถึงความผูกพันอย่างลึกซึ้งระหว่างวิถีชีวิตของผู้คน เศรษฐกิจของจังหวัด และการเพาะปลูกข้าว ความเหมาะสมของจังหวัดสุพรรณบุรีต่อการเกษตรกรรมนั้น มาจากปัจจัยสำคัญคือการมีแหล่งน้ำธรรมชาติที่อุดมสมบูรณ์ และระบบชลประทานที่ได้รับการพัฒนาอย่างต่อเนื่อง ปัจจัยเหล่านี้เป็นรากฐานสำคัญที่ทำให้การปลูกข้าวเจริญรุ่งเรืองในพื้นที่นี้มาอย่างยาวนาน

การที่ประชากรส่วนใหญ่ของจังหวัดสุพรรณบุรีพึ่งพาภาคเกษตรกรรม และมีข้าวเป็นพืชเศรษฐกิจหลัก ย่อมหมายความว่าเสถียรภาพทางเศรษฐกิจและสังคมของจังหวัดเชื่อมโยงอย่างใกล้ชิด ความสำเร็จและความท้าทายของภาคการผลิตข้าว ดังนั้น ปัจจัยใดๆ ก็ตามที่มีผลกระทบต่อการผลิตข้าว ไม่ว่าจะเป็นความแปรปรวนของสภาพภูมิอากาศ ความผันผวนของราคาในตลาด หรือการ

เปลี่ยนแปลงนโยบายของภาครัฐ ย่อมส่งผลกระทบต่อครัวเรือนส่วนใหญ่และเศรษฐกิจโดยรวมของจังหวัด ความเปราะบางนี้จำเป็นต้องมีกลยุทธ์เชิงรุกในการลดความเสี่ยงและส่งเสริมการพัฒนาที่ยั่งยืนในภาคข้าว

2.1 สถิติทั่วไปเกี่ยวกับพื้นที่และผลผลิตข้าว

จังหวัดสุพรรณบุรี มีพื้นที่ส่วนใหญ่เป็นพื้นที่ราบลุ่ม ในปี พ.ศ.2564 มีการใช้ประโยชน์ที่ดินมากที่สุดคือพื้นที่เกษตรกรรม 2,426,164 ไร่ คิดเป็น 72.44% ของพื้นที่ทั้งหมด และมีพื้นที่นาข้าวมากถึง 1,245,023 ไร่ คิดเป็น 37.18% ของพื้นที่ทั้งหมด (กรมพัฒนาที่ดิน, 2564) ด้วยปริมาณน้ำที่มาจากแม่น้ำท่าจีนตัดผ่าน อีกทั้งพื้นที่ส่วนใหญ่ของจังหวัดอยู่ในพื้นที่เขตชลประทาน สะท้อนให้เห็นถึงศักยภาพของจังหวัดสุพรรณบุรีในการทำนาอย่างเข้มข้นและต่อเนื่องหลายฤดู ความแตกต่างของผลผลิตระหว่างข้าวนาปีและนาปรังในระดับประเทศ โดยที่นาปรังให้ผลผลิตสูงกว่า ชี้ให้เห็นว่าระบบชลประทานที่ดีของจังหวัดสุพรรณบุรี เอื้ออำนวยอย่างยิ่งต่อการเพิ่มผลผลิตโดยรวมต่อปีผ่านการทำนาปรังที่ประสบความสำเร็จ หมายถึงศักยภาพในการได้รับผลตอบแทนจากการลงทุนที่สูงกว่าในพื้นที่ชลประทานเมื่อเทียบกับพื้นที่ที่อาศัยน้ำฝนเพียงอย่างเดียว

2.2 ประเภทของการปลูกข้าว

จังหวัดสุพรรณบุรีมีการเพาะปลูกข้าวทั้ง ข้าวนาปี (การทำนาในฤดูฝนปกติ เริ่มเพาะปลูกประมาณเดือนพฤษภาคมถึงตุลาคม และเก็บเกี่ยวไม่เกินเดือนกุมภาพันธ์) และ ข้าวนาปรัง (การทำนาออกฤดูฝน อาศัยน้ำชลประทานเป็นหลัก เริ่มเพาะปลูกประมาณเดือนมกราคมเป็นต้นไป) การทำนาปรังเป็นที่นิยมในภาคกลาง รวมถึงจังหวัดสุพรรณบุรี เนื่องจากมีระบบชลประทานที่ดี

ศักยภาพในการเพาะปลูกข้าวได้ทั้งสองฤดู (นาปีและนาปรัง) ช่วยเพิ่มโอกาสในการผลิตและสร้างรายได้ให้แก่เกษตรกรในจังหวัดสุพรรณบุรีตลอดทั้งปี อย่างไรก็ตาม การทำนาปรังจำเป็นต้องพึ่งพาชลประทานที่มีประสิทธิภาพและการบริหารจัดการน้ำอย่างระมัดระวัง ทำให้การจัดการทรัพยากรน้ำเป็นปัจจัยสำคัญต่อเสถียรภาพของภาคการผลิตข้าว นอกจากนี้ การทำนาสองฤดูยังหมายถึงความต้องการปัจจัยการผลิตและแรงงานที่ต่อเนื่องมากขึ้น และมีผลต่อปริมาณข้าวที่เข้าสู่ตลาดอย่างสม่ำเสมอจากภูมิภาคนี้

2.3 กระบวนการปลูกข้าว

การเจริญเติบโตข้าวในจังหวัดสุพรรณบุรีนั้นจะเริ่มปลูกนาปีเดือนพฤษภาคม และจะเก็บเกี่ยวผลผลิตประมาณเดือนสิงหาคม – กันยายน (ศูนย์บริการและถ่ายทอดเทคโนโลยีการเกษตร ต่าบลศาลาขาว, 2562) โดยทั่วไปทำโดยการปักดำหรือหว่านเมล็ดลงนาโดยตรง แต่ก่อนที่จะเริ่มปลูกต้องดำเนินการเตรียมแปลงปลูกข้าวเพราะหลังฤดูการเก็บเกี่ยว จะมีวัชพืชและเศษใบข้าว โดยดำเนินการปรับหน้าดินให้พร้อมสำหรับการปลูกข้าวครั้งถัดไป (สำนักงานพัฒนาเศรษฐกิจจากฐานชีวภาพ, 2548) ในพื้นที่จังหวัดสุพรรณบุรีส่วนใหญ่ใช้วิธีปลูกข้าวแบบปักดำ โดยจะมีการเพาะกล้าใน

แปลงขนาดเล็กให้มีอายุประมาณ 1 เดือน และถอนกล้าไปปักดำในพื้นที่ที่มีการเตรียมขังน้ำ ต่อมา การปลูกข้าวนาหว่าน ดำเนินการโดยหว่านเมล็ดข้าวลงบนพื้นที่ที่เตรียมไว้ และสุดท้ายการปลูกข้าว นาโยน จะดำเนินการคล้ายกับการปลูกข้าวนาดำคือมีการการเพาะกล้าในแปลงขนาดเล็กก่อนเมื่อโต ได้ประมาณ 1 เดือน ทำการโยนลงไปในพื้นที่ที่เตรียมไว้ เมื่อเริ่มทำการปลูกข้าวแล้ว ข้าวจะใช้ ระยะเวลาในการเจริญเติบโตจนถึงช่วงเก็บเกี่ยวประมาณ 3 – 6 เดือน (ถนอมกลิ่น, 2561) โดยในแต่ละช่วงเวลาจะมีระยะการเจริญเติบโต (โปร่งศิริวัฒนา, 2534)


3. หลักการถ่ายภาพในระบบ RADAR และภาพถ่ายระบบ SAR

การถ่ายภาพในระบบ RADAR (Radio Detection And Ranging) เป็นการบันทึกข้อมูลแบบ Active โดยใช้ช่วงคลื่น Microwave (3 – 125 GHz) ระบบจะทำการสร้างสัญญาณและส่งสัญญาณ Microwave ออกไปยังเป้าหมายและรับค่าสัญญาณสะท้อนกลับ โดยระบบจะสลับหน้าที่ส่งและรับ สัญญาณอย่างละครึ่ง (Pulse) สัญญาณที่กลับมาจากการสะท้อนของเป้าหมายจะถูกบันทึกไว้ ในการ บินถ่ายภาพในระบบ RADAR จะทำการถ่ายภาพทางด้านข้าง ดังภาพประกอบ 2 โดยจะตั้งฉากกับ แนวบินถ่ายภาพ เรียกว่า Side Looking Airborne Radar (SLAR) ในกรณีระบบเรดาร์ (Real Aperture Radar) ขนาดรายละเอียดจุดภาพ สามารถคำนวณโดยใช้สมการ 1 (Lusch, 1999)

$$R_a = \frac{\lambda R}{l} \quad (1)$$

โดยที่

R_a	=	ความละเอียดเชิงพื้นที่ในแนวราบ (Azimuth Resolution)
l	=	ขนาดหรือความยาวของสายอากาศ (Antenna)
R	=	ระยะทางจากสายอากาศ (Antenna) ถึงเป้าหมาย
λ	=	ความยาวช่วงคลื่นที่ใช้



ภาพประกอบ 2 การบินถ่ายภาพในระบบ RADAR

ที่มา : <https://www.radartutorial.eu/20/airborne/!ab01en.html>

หากต้องการรายละเอียดข้อมูลสูง ต้องใช้จานรับและส่งสัญญาณที่มีขนาดใหญ่ และต้องบินระดับต่ำ ต่อมาจึงได้มีการพัฒนาระบบเรดาร์ช่องเปิดสังเคราะห์ (Synthetic Aperture Radar หรือ SAR) โดยอาศัยการเคลื่อนที่ของตัวยาน (Doppler Effect) สร้างเป็นจานรับและส่งสัญญาณสมมติ ทำให้ได้รายละเอียดข้อมูลที่สูง แม้จะบินสูงจากพื้นโลกมาก ๆ โดยขนาดรายละเอียดข้อมูลคำนวณโดยใช้สมการ 2

$$R_a = \frac{l}{2} \quad (2)$$

โดยที่

$$\begin{aligned} R_a &= \text{ความละเอียดเชิงพื้นที่ในแนวราบ (Azimuth Resolution)} \\ l &= \text{ขนาดหรือความยาวของสายอากาศ (Antenna)} \end{aligned}$$

ข้อมูลที่ได้จากระบบ SAR จะจัดเก็บในรูปแบบภาพจำนวนเชิงซ้อน โดยมีรูปแบบอาเรย์สองมิติ ในแต่ละจุดภาพจะแทนด้วยรายละเอียดเชิงพื้นที่ตามแนว Range และ Azimuth ข้อมูลที่ได้จากระบบ SAR จะประกอบไปด้วย ข้อมูล 2 ชนิด คือ (Sharav, 2003)

- ข้อมูลภาพ Amplitude คือ ข้อมูลภาพประกอบแสดงผลค่าการกระเจิงกลับ (Backscatter) ที่เกิดขึ้นจะมีค่าต่างกันตามชนิดวัตถุ หากมีความสว่างมาก แปลว่ามีค่าการกระเจิงกลับค่อนข้างสูง จะเกิดขึ้นกับวัตถุที่ขรุขระ หากมีความสว่างต่ำค่อนข้างน้อย แปลว่าค่าการกระเจิงกลับค่อนข้างน้อย หรือไม่มีเลย วัตถุที่จะเกิดเช่นนี้มักจะมีผิวนิ่ง หรือพื้นที่แหล่งน้ำ
- ข้อมูลภาพ Phase คือ ข้อมูลที่ภาพประกอบแสดงผลจำนวนลูกคลื่นที่กลับมายังตัวรับสัญญาณ ผลลัพธ์จะเป็นภาพประกอบแสดงผลแบบสุ่ม (Random Image) เป็นข้อมูลที่สำคัญในการประมวลผล Interferometry จากข้อมูลภาพระบบ SAR

ตาราง 1 ดาวเทียมในระบบเรดาร์ที่นิยมใช้งานในปัจจุบัน

ความยาวคลื่น	ดาวเทียม	ระยะเวลาที่ ปฏิบัติการ (ปี คศ)	ประเทศที่ส่งขึ้น วงโคจร	บันทึกข้อมูลซ้ำ (วัน)
X	TerraSAR-X	2007 – ปัจจุบัน	DLR, เยอรมันนี	11
	Cosmo-Skymed	2007 – ปัจจุบัน	ASI, อิตาลี	16
C	ERS-1	1991 – 2001	ESA, ยุโรป	35
	ERS-2	1995 – 2011	ESA, ยุโรป	35
	Radarsat-1	1995 – 2013	CSA, แคนาดา	24
	Radarsat-2	2007 - ปัจจุบัน	CSA, แคนาดา	24
	Envisat	2007 - ปัจจุบัน	ESA, ยุโรป	35
	Sentinel-1	2014 – ปัจจุบัน	ESA, ยุโรป	12
L	JERS-1	1992 – 1998	NASDA,	44
	ALOS-PALSAR 1	2006 – 2010	JAXA,	46
	ALOS-PALSAR 2	2014 – ปัจจุบัน	JAXA,	14

ที่มา : (Zhou, Chang, & Li, 2009)

4. การวิเคราะห์อนุกรมเวลา (Time series analysis)

การวิเคราะห์อนุกรมเวลาเป็นเทคนิคทางสถิติที่ใช้ในการทำนายหรือพยากรณ์ค่าของตัวแปรในอนาคต โดยอาศัยการศึกษารูปแบบความสัมพันธ์จากข้อมูลในอดีตของตัวแปรนั้นๆ หัวใจของการวิเคราะห์คือการจำแนกองค์ประกอบต่างๆ ที่ซ่อนอยู่ในข้อมูลอนุกรมเวลาออกมา เพื่อทำความเข้าใจรูปแบบของแต่ละองค์ประกอบแล้วนำไปสร้างแบบจำลองสำหรับการพยากรณ์ โดยทั่วไป ข้อมูลอนุกรมเวลาสามารถแบ่งออกเป็น 4 องค์ประกอบหลัก ดังนี้

- แนวโน้ม (Trend หรือ T) คือทิศทางการเคลื่อนที่ของข้อมูลใน ระยะเวลา อาจมีแนวโน้มเพิ่มขึ้น ลดลง หรือคงที่ก็ได้ โดยทิศทางดังกล่าวอาจมีลักษณะเป็นเส้นตรง (Linear) หรือเส้นโค้ง (Non-linear) ก็ได้ เช่น การศึกษาแนวโน้มผลผลิตข้าวในช่วง 10 ปี

- การเคลื่อนไหวตามฤดูกาล (Seasonal Movement หรือ S) คือรูปแบบการเปลี่ยนแปลงที่เกิดขึ้นซ้ำๆ อย่างสม่ำเสมอในรอบระยะเวลาที่แน่นอน น้อยกว่าหนึ่งปี เช่น ข้อมูลรายเดือน รายไตรมาส หรือรายสัปดาห์ โดยมีสาเหตุมาจากอิทธิพลของฤดูกาลนั้นๆ

- การเคลื่อนไหวตามวัฏจักร (Cyclical Movement หรือ C) คือการเปลี่ยนแปลงที่ขึ้นลงเป็นรอบๆ คล้ายกับฤดูกาล แต่มีคาบเวลายาวนาน มากกว่า 1 ปี และมักมีรูปแบบที่ไม่คงที่ ทำให้

พยากรณ์ได้ยาก โดยทั่วไปมีสาเหตุจากสภาวะเศรษฐกิจ นโยบายภาครัฐ หรือการเปลี่ยนแปลงรสนิยมของผู้บริโภค

- การเคลื่อนไหวผิดปกติ (Irregular Movement หรือ I) คือความผันผวนที่เกิดขึ้นอย่างไม่สม่ำเสมอและไม่สามารถคาดเดาได้ เป็นส่วนที่เหลืออยู่หลังจากการแยกองค์ประกอบ 3 ส่วนแรกออกไปแล้ว มักเกิดจากเหตุการณ์เฉพาะกิจที่ไม่ได้คาดการณ์ล่วงหน้า เช่น สภาพดินฟ้าอากาศที่แปรปรวน หรือเหตุการณ์พิเศษต่างๆ

5. การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) คือสาขาย่อยของปัญญาประดิษฐ์ (Artificial Intelligence) ที่มุ่งเน้นการพัฒนาระบบที่สามารถเรียนรู้จากข้อมูลและปรับปรุงประสิทธิภาพการทำงานได้ด้วยตนเอง โดยไม่ต้องได้รับการตั้งโปรแกรมอย่างชัดเจน (Alpaydin, 2020) สาระสำคัญของ Machine Learning อยู่ที่ความสามารถของเครื่องจักรในการ เรียนรู้ (Learning) และ อนุมาน (Inference) ผ่านการวิเคราะห์และค้นหาแบบแผนหรือโครงสร้างที่ซ่อนอยู่ในชุดข้อมูลฝึกฝน (Training Data) เพื่อนำไปสร้างแบบจำลอง (Model) ที่สามารถใช้ในการทำนายผลลัพธ์หรือตัดสินใจสำหรับข้อมูลใหม่ที่ไม่เคยพบเห็นมาก่อน (Goodfellow, Bengio, Courville, & Bengio, 2016) โดยมีความแตกต่างจากการเขียนโปรแกรม ในการเขียนโปรแกรมปกติ (Traditional Programming) การทำงานของระบบจะถูกกำหนดโดยชุดคำสั่งและกฎเกณฑ์ที่ชัดเจน ถูกสร้างขึ้นโดยผู้เชี่ยวชาญตามความเข้าใจด้านตรรกะ (Logical Foundation) (Russell & Norvig, 2010) คอมพิวเตอร์จะประมวลผลและส่งออกผลลัพธ์ตามคำสั่งเชิงตรรกะ (Logical Statement) ที่ถูกป้อนเข้าไป หากความซับซ้อนของปัญหามีมากขึ้น การกำหนดกฎเกณฑ์ทั้งหมดจะยิ่งมีความยุ่งยากและใช้เวลานาน (Mitchell, 1997) ตรงกันข้ามกับ Machine Learning ที่มีการปรับเปลี่ยนกระบวนการทัศน์ โดยแทนที่จะกำหนดกฎเกณฑ์ เครื่องจักรจะเรียนรู้ความสัมพันธ์ระหว่างข้อมูลขาเข้า (Input Data) และข้อมูลขาออก (Output Data) ด้วยตนเอง การเรียนรู้ของเครื่องจะสร้างแบบจำลองที่สามารถสรุปกฎเกณฑ์จากข้อมูลที่ได้รับ ทำให้ไม่จำเป็นต้องเขียนกฎใหม่ทุกครั้งเมื่อมีข้อมูลใหม่เข้ามา แบบจำลองจะปรับปรุงและปรับเปลี่ยนแบบจำลองตามข้อมูลใหม่ที่ได้รับ เพื่อเพิ่มประสิทธิภาพในการประมวลผลและทำนายผล (Shalev-Shwartz & Ben-David, 2013) โดยการเรียนรู้ของเครื่องสามารถแบ่งออกเป็น 2 ประเภทหลัก ประกอบไปด้วย

5.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นกลุ่มของอัลกอริทึมที่คอมพิวเตอร์จะเรียนรู้จากชุดข้อมูลฝึกฝนที่มีป้ายกำกับ (Labeled Training Data) ข้อมูลแต่ละตัวอย่างประกอบด้วยทั้งข้อมูลขาเข้าและผลลัพธ์ที่ถูกต้อง (หรือป้ายกำกับ) ที่ทราบอยู่แล้ว (Hastie, Tibshirani, & Friedman, 2009) วัตถุประสงค์คือการสร้างแบบจำลองที่สามารถทำนายผลลัพธ์ที่

ถูกต้องสำหรับข้อมูลใหม่ที่ยังไม่มีป้ายกำกับ การประยุกต์ใช้หลักของ Supervised Learning แบ่งออกเป็น 2 รูปแบบ

- การถดถอย (Regression) ใช้สำหรับการทำนายค่าตัวเลขต่อเนื่อง เช่น การทำนายราคาส่งหาปริมาณการใช้พลังงาน, หรือการประเมินความเสี่ยง (Montgomery, Peck, & Vining, 2021)


- การจำแนกประเภท (Classification) ใช้สำหรับการจัดหมวดหมู่ข้อมูลให้อยู่ในกลุ่มที่กำหนด เช่น การระบุว่าเป็นอีเมลสแปมหรือไม่, การจำแนกประเภทของรูปภาพ, หรือการวินิจฉัยโรคจากข้อมูลทางการแพทย์ (Bishop, 2006)

5.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) คือกลุ่มของอัลกอริทึมที่คอมพิวเตอร์เรียนรู้จาก ชุดข้อมูลที่ไม่มีป้ายกำกับ (Unlabeled Data) กล่าวคือ ไม่มีข้อมูลเป้าหมายหรือผลลัพธ์ที่ต้องระบุไว้ล่วงหน้า (Jain, Murty, & Flynn, 1999) วัตถุประสงค์ของการเรียนรู้แบบไม่มีผู้สอนคือการค้นหาโครงสร้างที่ซ่อนอยู่, รูปแบบ, หรือความสัมพันธ์ภายในข้อมูลโดยไม่มีคำแนะนำจากภายนอก การประยุกต์ใช้หลักของ Unsupervised Learning คือการจัดกลุ่ม (Clustering) เป็นการรวมข้อมูลที่มีความคล้ายคลึงกันเข้าไว้ในกลุ่มเดียวกัน โดยอาศัยคุณสมบัติที่คล้ายคลึงกันภายในข้อมูลเอง เช่น การแบ่งกลุ่มลูกค้าตามพฤติกรรมการซื้อ, การจัดหมวดหมู่เอกสารอัตโนมัติ, หรือการตรวจจับความผิดปกติ (Anomaly Detection) (Fahad et al., 2014)

6. Support Vector Machine (SVM)

เป็นอัลกอริทึมการเรียนรู้ของเครื่องจักรแบบมีผู้สอน (supervised machine learning algorithm) ที่ใช้สำหรับการจัดหมวดหมู่ (classification) และการถดถอย (regression) โดยเฉพาะอย่างยิ่งสำหรับการจัดหมวดหมู่แบบไบนารี (binary classification) SVM มีประสิทธิภาพสูงในการจัดการกับข้อมูลที่มีมิติสูงและมีขนาดตัวอย่างเล็ก นอกจากนี้ยังมีความทนทานต่อการเกิดภาวะเรียนรู้เกิน (overfitting)

หลักการสำคัญของ SVM คือการหา ไฮเปอร์เพลนที่เหมาะสมที่สุด (optimal hyperplane) (ภาพประกอบ 3) ที่สามารถแยกข้อมูลออกเป็นคลาสต่างๆ ได้อย่างมีประสิทธิภาพสูงสุด โดยไฮเปอร์เพลนนี้จะถูกเลือกให้มี ระยะขอบ (margin) กว้างที่สุดเท่าที่จะเป็นไปได้ระหว่างจุดข้อมูลของคลาสต่างๆ จุดข้อมูลที่อยู่ใกล้หรือบนระยะขอบนี้เรียกว่า เวกเตอร์สนับสนุน (support vectors) เป็นจุดข้อมูลที่สำคัญที่สุดในการกำหนดตำแหน่งของไฮเปอร์เพลน (Cortes & Vapnik, 2009)



ภาพประกอบ 3 การหาไฮเปอร์เพลนที่เหมาะสมที่สุด

ที่มา : https://en.wikipedia.org/wiki/Support_vector_machine

สำหรับกรณีข้อมูลที่สามารถแยกเชิงเส้นได้ (linearly separable data) SVM จะหาไฮเปอร์เพลนที่แยกข้อมูลทั้งสองคลาสออกจากกันโดยมีระยะห่างจากเวกเตอร์สนับสนุนของทั้งสองคลาสมากที่สุด สำหรับกรณีข้อมูลที่ไม่สามารถแยกเชิงเส้นได้ (non-linearly separable data) SVM จะใช้เทคนิคที่เรียกว่า เคอร์เนลทริก (kernel trick) เพื่อแปลงข้อมูลจากพื้นที่ที่มีมิติเดิมไปสู่พื้นที่ที่มีมิติสูงขึ้น ในพื้นที่ใหม่นี้ ข้อมูลอาจสามารถแยกเชิงเส้นได้ ตัวอย่างฟังก์ชันเคอร์เนลที่นิยมใช้ได้แก่ เคอร์เนลเชิงเส้น (Linear Kernel), เคอร์เนลพหุนาม (Polynomial Kernel), เคอร์เนลฟังก์ชันพื้นฐานแบบรัศมี (Radial Basis Function - RBF Kernel หรือ Gaussian Kernel) และเคอร์เนลซิกมอยด์ (Sigmoid Kernel) (Vapnik, 1998)

7. Random Forest (RF)

Random Forest เป็นอัลกอริทึมการเรียนรู้ของเครื่องจักรแบบมีผู้สอนที่จัดอยู่ในกลุ่ม Ensemble Learning ประเภท Bagging (Bootstrap Aggregating) ใช้อย่างแพร่หลายสำหรับการจัดหมวดหมู่ (classification) และการถดถอย (regression) จุดเด่นของ Random Forest คือความสามารถในการจัดการกับชุดข้อมูลขนาดใหญ่และข้อมูลที่มีมิติสูง ลดการเกิดภาวะเรียนรู้เกิน (overfitting) และให้ผลลัพธ์ที่มีความแม่นยำสูง (Breiman, 2001)

Random Forest สร้างขึ้นจากแนวคิดของการรวมต้นไม้ตัดสินใจ (Decision Trees) จำนวนมากเข้าด้วยกัน โมเดลนี้ช่วยเพิ่มประสิทธิภาพการทำนายโดยการลดความแปรปรวน (variance) ของแต่ละต้นไม้ตัดสินใจ มีแนวโน้มที่จะเกิด Overfitting ได้ง่ายเมื่อฝึกบนชุดข้อมูลเพียงชุดเดียว หลักการสำคัญสองประการที่ทำให้ Random Forest มีประสิทธิภาพสูงคือ

7.1 Bagging (Bootstrap Aggregating)

- การสุ่มตัวอย่างข้อมูล (Bootstrap Sampling) ในการสร้างต้นไม้แต่ละต้นในป่า Random Forest จะทำการสุ่มตัวอย่างข้อมูลแบบใส่คืน (sampling with replacement) จากชุดข้อมูลฝึกอบรมต้นฉบับที่มีขนาด N ตัวอย่าง ผลลัพธ์คือได้ชุดข้อมูลย่อย (bootstrap sample) ที่มีขนาด N ตัวอย่างเช่นกัน แต่บางจุดข้อมูลอาจถูกเลือกซ้ำกันหลายครั้ง ในขณะที่บางจุดอาจไม่ถูกเลือกเลย (เรียกว่า Out-of-Bag (OOB) samples)

- การสร้างโมเดลย่อย (Base Learners) ต้นไม้ตัดสินใจแต่ละต้นจะถูกฝึกฝนอย่างเป็นอิสระบนชุดข้อมูลย่อยที่แตกต่างกัน การทำเช่นนี้ช่วยลดความสัมพันธ์ (correlation) ระหว่างต้นไม้แต่ละต้น

- การรวมผลลัพธ์ (Aggregation) สำหรับงานจำแนกประเภท ผลลัพธ์สุดท้ายจะถูกตัดสินโดยการ โหวตเสียงข้างมาก (majority vote) จากการทำนายของต้นไม้ทุกต้น สำหรับงานถดถอย ผลลัพธ์สุดท้ายจะถูกตัดสินโดยการ หาค่าเฉลี่ย (average) ของผลลัพธ์จากต้นไม้ทุกต้น

7.2 Feature Randomness (Random Subspace Method)

- การสุ่มเลือกคุณลักษณะ นอกจาก Bagging แล้ว Random Forest ยังเพิ่มความสุ่มอีกชั้นหนึ่งในกระบวนการสร้างต้นไม้ โดยที่แต่ละโหนดในการตัดสินใจ (node splitting) แทนที่จะพิจารณาคุณลักษณะ (features) ทั้งหมดที่มี Random Forest จะ สุ่มเลือกชุดย่อยของคุณลักษณะ มาพิจารณาเท่านั้น

- การลดความสัมพันธ์ระหว่างต้นไม้ การสุ่มเลือกคุณลักษณะนี้ช่วยลดความสัมพันธ์ระหว่างต้นไม้แต่ละต้นให้มากยิ่งขึ้น ทำให้แต่ละต้นไม้มีความหลากหลาย (diversity) และมีความเป็นอิสระต่อกัน เป็นสิ่งสำคัญในการลดความแปรปรวนของ Ensemble Model

7.3 การเติบโตของต้นไม้ (Tree Growth) ต้นไม้ตัดสินใจแต่ละต้นใน Random Forest มักจะถูกสร้างให้เติบโตอย่างเต็มที่โดยไม่มีการตัดแต่งกิ่ง (pruning) ช่วยลดความเอนเอียง (bias) ของโมเดล อย่างไรก็ตาม การรวมกันของต้นไม้จำนวนมากและการสุ่มในกระบวนการสร้างต้นไม้ ช่วยป้องกันไม่ให้เกิด Overfitting แม้ว่าแต่ละต้นไม้อาจเกิด Overfitting กับชุดข้อมูลย่อยของตนเองก็ตาม

7.4 การประมาณค่าข้อผิดพลาด Out-of-Bag (OOB Error Estimation) เนื่องจากแต่ละต้นไม้ถูกฝึกบนชุดข้อมูลย่อยที่สุ่มมา จึงมีจุดข้อมูลบางส่วนที่ไม่ถูกนำมาใช้ในการฝึกต้นไม้ต้นนั้นๆ (OOB

samples) Random Forest สามารถใช้จุดข้อมูล OOB เหล่านี้ในการประมาณค่าข้อผิดพลาดของโมเดลโดยรวมได้โดยไม่ต้องพึ่งพาการแบ่งชุดข้อมูลออกเป็นชุดทดสอบ (test set) โดยสำหรับแต่ละจุดข้อมูล OOB จะถูกนำไปทำนายโดยเฉพาะต้นไม้ที่ไม่ได้ใช้จุดข้อมูลนั้นในการฝึก และนำผลการทำนายมาประเมินข้อผิดพลาด

8. XGBoost (eXtreme Gradient Boosting)

XGBoost (eXtreme Gradient Boosting) เป็นอัลกอริทึมการเรียนรู้ของเครื่องจักรแบบมีผู้สอนที่จัดอยู่ในกลุ่ม Ensemble Learning ประเภท Gradient Boosting ได้รับความนิยมอย่างสูงและมักถูกเลือกใช้ในการแข่งขัน Machine Learning (เช่น Kaggle) เนื่องจากให้ประสิทธิภาพที่ยอดเยี่ยมทั้งในด้านความแม่นยำและความเร็วในการประมวลผล XGBoost เหมาะสำหรับการจำแนกประเภท (classification), การถดถอย (regression), และการจัดอันดับ (ranking) พัฒนามาจากแนวคิดของ Gradient Boosting Machines (GBMs) (Friedman, 2000) โดยเน้นการเพิ่มประสิทธิภาพและความเร็วในการประมวลผล หัวใจสำคัญของ Gradient Boosting คือการสร้างโมเดลแบบต่อเนื่อง (additive manner) โดยแต่ละโมเดลย่อย มักจะเป็นต้นไม้ตัดสินใจ จะพยายามแก้ไขข้อผิดพลาดที่เกิดจากโมเดลก่อนหน้าอย่างเป็นลำดับ (Chen & Guestrin, 2016)

8.1 การสร้างโมเดลแบบ Additive

XGBoost สร้างชุดของต้นไม้ตัดสินใจโดยมีแนวคิดว่าการทำนายสุดท้ายสำหรับข้อมูลแต่ละจุด เป็นผลรวมของการทำนายจากต้นไม้ที่สร้างขึ้นมาแล้วทั้งหมด บวกกับการทำนายของต้นไม้ใหม่ที่ถูกเพิ่มเข้ามาในแต่ละขั้นตอน เป้าหมายหลักคือการหาต้นไม้ใหม่นี้เพื่อลดฟังก์ชันความสูญเสีย (loss function) วัดความแตกต่างระหว่างค่าจริงและค่าที่โมเดลทำนายได้

8.2 Objective Function และ Regularization

XGBoost กำหนด Objective Function สำหรับการทำซ้ำแต่ละครั้ง ประกอบด้วยสองส่วนหลัก ส่วนแรกคือฟังก์ชันความสูญเสียที่วัดว่าโมเดลทำนายได้ดีเพียงใด และส่วนที่สองคือ เทอม Regularization ที่ถูกเพิ่มเข้ามาเพื่อควบคุมความซับซ้อนของโมเดล การเพิ่มเทอม Regularization นี้ช่วยป้องกันภาวะเรียนรู้เกิน (overfitting) โดยจะพิจารณาทั้งจำนวนใบของต้นไม้ และขนาดของคะแนนที่อยู่ในแต่ละใบ

8.3 Second-Order Taylor Expansion

เพื่อเพิ่มความยืดหยุ่นในการใช้ฟังก์ชันความสูญเสียที่หลากหลายและเพื่อให้การคำนวณมีประสิทธิภาพมากขึ้น XGBoost ใช้การประมาณค่า Objective Function ด้วยอนุกรมเทย์เลอร์อันดับสอง เกี่ยวข้องกับการใช้ทั้งอนุพันธ์อันดับหนึ่ง (first-order gradient) และอนุพันธ์อันดับสอง

(second-order gradient หรือ Hessian) ของ loss function การใช้ข้อมูลจากอนุพันธ์อันดับสองนี้ทำให้ XGBoost สามารถหาจุดที่เหมาะสมที่สุดได้อย่างแม่นยำยิ่งขึ้นในการปรับปรุงโมเดล

8.4 Optimal Output Value และ Gain

หลังจากที่โครงสร้างของต้นไม้ถูกสร้างขึ้นแล้ว XGBoost จะคำนวณค่าเอาต์พุตที่เหมาะสมที่สุดสำหรับแต่ละใบของต้นไม้ทุกๆ เพื่อให้ Objective Function มีค่าน้อยที่สุด นอกจากนี้ ในระหว่างกระบวนการสร้างต้นไม้ XGBoost ยังใช้สูตร Gain เพื่อประเมินคุณภาพของการแยกโหนด โดยจะเลือกคุณลักษณะและจุดตัดที่ให้ค่า Gain สูงสุด เพื่อให้ได้การแบ่งข้อมูลที่มีประสิทธิภาพที่สุด

8.5 การปรับปรุงอื่นๆ

- Shrinkage (Learning Rate) คล้ายกับอัลกอริทึม Gradient Boosting ทั่วไป XGBoost ใช้พารามิเตอร์ `learning_rate` เพื่อลดผลกระทบของการทำนายจากต้นไม้แต่ละต้นที่เพิ่มเข้ามา ทำให้กระบวนการเรียนรู้เป็นไปอย่างช้าๆ และช่วยป้องกัน Overfitting
- Column Subsampling XGBoost สามารถสุ่มเลือกคุณลักษณะ (columns) เพียงบางส่วนมาใช้ในการสร้างต้นไม้แต่ละต้น ช่วยลด Overfitting และเพิ่มความเร็วในการประมวลผล
- Handling Missing Values XGBoost มีกลไกในตัวสำหรับการจัดการกับข้อมูลที่ขาดหาย ทำให้สามารถทำงานกับชุดข้อมูลที่ไม่สมบูรณ์ได้
- Parallel Computing XGBoost ได้รับการออกแบบมาเพื่อรองรับการประมวลผลแบบขนาน ทำให้สามารถฝึกโมเดลบนชุดข้อมูลขนาดใหญ่ได้อย่างรวดเร็วและมีประสิทธิภาพ

9. Grid Search และ Cross-Validation

การปรับจูนไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) เป็นขั้นตอนที่มีความสำคัญอย่างยิ่งในการพัฒนากระบวนการเรียนรู้ของเครื่อง เพื่อให้ได้แบบจำลองที่มีประสิทธิภาพสูงสุด เทคนิคพื้นฐานที่เป็นที่รู้จักอย่างแพร่หลายคือ การค้นหาแบบกริด (Grid Search) เป็นกระบวนการค้นหาแบบครบถ้วน (Exhaustive Search) โดยระบบจะทำการสร้างและประเมินประสิทธิภาพของแบบจำลองจาก ทุกชุดค่าผสมที่เป็นไปได้ ของไฮเปอร์พารามิเตอร์ที่ผู้ใช้กำหนดไว้ล่วงหน้าในลักษณะของเมทริกซ์หรือกริด (Malakouti, Menhaj, & Suratgar, 2023)

อย่างไรก็ตาม การประเมินประสิทธิภาพของแบบจำลองแต่ละชุดค่าผสมจำเป็นต้องมีกระบวนการที่น่าเชื่อถือ เพื่อป้องกันการเลือกไฮเปอร์พารามิเตอร์ที่ทำงานได้ดีกับข้อมูลฝึกสอนชุดใดชุดหนึ่งโดยเฉพาะ แต่ไม่สามารถสรุปอ้างอิงไปยังข้อมูลใหม่ได้ (Overfitting) ด้วยเหตุนี้ เทคนิค การตรวจสอบไขว้ (Cross-Validation) โดยเฉพาะอย่างยิ่ง K-Fold Cross-Validation จึงถูกนำมาใช้ร่วมกัน


หลักการของ K-Fold คือการแบ่ง ชุดข้อมูลสำหรับฝึกสอน (Training Set) ออกเป็น K ส่วน (Fold) ที่มีขนาดเท่ากัน จากนั้นจะทำการฝึกสอนและประเมินแบบจำลองวนซ้ำเป็นจำนวน K รอบ ในแต่ละรอบจะใช้ข้อมูล K-1 ส่วนในการฝึกสอน และใช้ข้อมูล 1 ส่วนที่เหลือในการทดสอบและวัดผล เมื่อครบทั้ง K รอบแล้ว ผลการประเมินจากทุกรอบจะถูกนำมาหาค่าเฉลี่ยเพื่อเป็นคะแนน ประสิทธิภาพตัวแทนของแบบจำลองนั้น ดังนั้น ในกระบวนการ Grid Search ที่สมบูรณ์ สำหรับไฮเปอร์พารามิเตอร์ แต่ละชุด ในกริด จะถูกประเมินประสิทธิภาพด้วยกระบวนการ K-Fold Cross-Validation เพื่อให้ได้คะแนนเฉลี่ยที่มีความน่าเชื่อถือ จากนั้นจึงเลือกชุดไฮเปอร์พารามิเตอร์ที่ให้คะแนนเฉลี่ยสูงสุดมาเป็นชุดที่ดีที่สุดสำหรับแบบจำลองขั้นสุดท้าย วิธีการนี้ช่วยให้มั่นใจได้ว่า แบบจำลองที่ได้จะสามารถทำงานได้ดีกับ ชุดข้อมูลสำหรับทดสอบ (Test Set) เป็นข้อมูลที่แบบจำลองไม่เคยพบเห็นมาก่อน

10. โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียมถูกใช้เป็นพื้นฐานของการเรียนรู้เชิงลึกที่ได้รับความนิยมมากในปัจจุบัน ถูกพัฒนาจากเครือข่ายการเชื่อมต่อกันทางชีววิทยา (Biological Neural Network) ของสมอง โดยคำว่า เชิงลึก เกิดจากเชื่อมต่อกันหลาย ๆ ชั้นภายในโครงข่ายประสาทเทียม แต่ละชั้นต่างๆ จะทำหน้าที่สกัดข้อมูลคุณลักษณะและทำการถ่ายโอนไปยังชั้นต่อไป จนถึงขั้นสุดท้ายที่ทำการแบ่งประเภทในที่สุด

10.1 ส่วนประกอบของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียม เป็นเทคนิคการเรียนรู้จากข้อมูลที่เลียนแบบการเชื่อมต่อของเซลล์ประสาทของมนุษย์ ประกอบไปด้วย ชั้นรับข้อมูล (Input Layer) ทำหน้าที่รับข้อมูลส่งต่อไปยังชั้นซ่อน (Hidden Layer) ที่สามารถมีมากกว่า 1 ชั้น โดยแต่ละชั้นจะประกอบนิวรอน (Neuron) จำนวนมากมาย และส่งข้อมูลออกไปยังชั้นขาออก (Output Layer) ที่จะเป็นตัวจำแนกหรือทำนายผล โดยแสดงส่วนประกอบของโครงข่ายประสาทเทียมดังภาพประกอบ 4 เมื่อทำการฝึกชุดข้อมูลจะเข้าสู่โครงข่ายหลายครั้ง ทำให้แบบจำลองมีประสิทธิภาพในการทำนายหรือจำแนกได้ดียิ่งขึ้น (Goodfellow et al., 2016)



ภาพประกอบ 4 โครงสร้างโครงข่ายประสาทเทียม

ที่มา : <https://wwwsmartsheetcom/neural-network-applications>

การเชื่อมต่อกันภายในโครงข่ายประสาทเทียม จะส่งต่อกันแบบทั่วถึง หรือที่เรียกว่าการเชื่อมโยงเต็มรูปแบบ (Fully-connected layer) โดยที่นิวรอนทุกตัวในแต่ละชั้นจะทำการเชื่อมต่อถึงกันหมด โดยแต่ละการเชื่อมต่อจะมีค่าน้ำหนัก (Weight) ที่ต่างกัน เพราะน้ำหนักแต่ละนิวรอนมีความสำคัญไม่เท่ากัน เมื่อข้อมูลนำเข้าคูณด้วยค่าถ่วงน้ำหนัก จะมีการใช้ค่าความเอนเอียง (Bias) บวกเข้า ดังสมการที่ 3 เมื่อประมวลผลเสร็จแล้วจะเข้าสู่ฟังก์ชันกระตุ้น (Activation Function) ดังสมการที่ 4

$$z_j^l = \sum_{k=1}^n w_{jk}^l a_k^{l-1} + b_j^l \quad (3)$$

$$a_j^l = g(z_j^l) \quad (4)$$

โดยที่

z_j^l	=	ผลการคำนวณตัวที่ j ในลำดับชั้น l
n	=	จำนวนนิวรอนในลำดับชั้น l-1
a_k^{l-1}	=	ผลลัพธ์ของเพอร์เซพตรอนตัวที่ k ในลำดับชั้น l-1
w_{jk}^l	=	น้ำหนักของเพอร์เซพตรอนตัวที่ j ในลำดับชั้น l
b_j^l	=	ค่าความเอนเอียงตัวที่ j ในลำดับชั้น l
a_j^l	=	ค่าส่งออกตัวที่ j ในลำดับชั้น l

g = ฟังก์ชันกระตุ้น

10.2 ฟังก์ชันกระตุ้น (Activation Function)

ปัจจุบันมีฟังก์ชันกระตุ้นมากมายหลายรูปแบบ ในงานวิจัยครั้งนี้เลือก ฟังก์ชันเรกติไฟด์เชิงเส้น (Rectified liner Unit) และฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax function) มาใช้ในงานวิจัย

10.3 ฟังก์ชันเรกติไฟด์เชิงเส้น (Rectified liner Unit - ReLU)

เป็นฟังก์ชันที่ให้ผลลัพธ์มีค่ามากกว่าหรือเท่ากับศูนย์เสมอ (สมการที่ 5) เป็นฟังก์ชันที่นิยมใช้กับการวิเคราะห์ภาพ เนื่องจากค่าจุดภาพของภาพถ่ายหลังจากนำเข้าสู่โครงข่ายแล้วจะถูก Normalization ให้มีค่าระหว่าง 0 – 255

$$f(z) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases} \quad (5)$$

โดยที่

z = ผลลัพธ์ในชั้นปัจจุบัน

10.4 ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax function)

เป็นฟังก์ชันที่ให้ค่าผลลัพธ์อยู่ในช่วง 0 ถึง 1 ได้รับการพัฒนามากจาก Binary logistic regression (ผลลัพธ์ส่งออกมีสองค่า) ให้มีค่าผลลัพธ์ส่งออกเป็นแบบ Multiple classes และ Normalize ค่าความน่าจะเป็น (สมการที่ 6) โดยผลรวมของผลลัพธ์ทุกคลาสมีค่าเป็น 1 นิยมใช้กระตุ้นในชั้นแอ็บซอลูชันสุดท้ายก่อนออกให้ค่าผลลัพธ์

$$f(z)_j = \frac{e^{z_j}}{\sum_{i=1}^k e^{z_i}} \quad (6)$$

โดยที่

z = ผลลัพธ์

e = ค่าคงตัวทางคณิตศาสตร์

j = ลำดับของผลลัพธ์

k = จำนวนชั้นของโครงข่ายที่ต้องการคำนวณ

10.5 ฟังก์ชันต้นทุน (Cost Function)

เป็นตัวบ่งบอกถึงต้นทุนของโครงข่ายประสาทเทียม โดยมีเป้าหมายคือลดค่าความผิดพลาดที่ได้จากฟังก์ชันต้นทุนให้ได้มากที่สุด เราสามารถสังเกตอัตราค่าความผิดพลาดจากชุดข้อมูลตัวอย่างสำหรับการเรียนรู้ของโครงข่ายประสาทเทียม ในงานวิจัยนี้เลือกใช้วิธีคำนวณความผิดพลาดครอส-เอนโทรปี (Categorical cross entropy) ในการช่วยคำนวณ เอนโทรปีคือความไม่แน่นอน วิธีคำนวณนี้จะให้ค่าระยะทางระหว่างค่าการกระจายของผลลัพธ์จากโครงข่ายประสาทเทียมกับผลลัพธ์จริง ดังสมการที่ 7

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (7)$$

โดยที่

J	=	ฟังก์ชันต้นทุน
n	=	จำนวนข้อมูลทั้งหมด
$\hat{y}_i$	=	ผลลัพธ์จริงที่ต้องการของข้อมูลชุดที่ i
y_i	=	ผลลัพธ์ที่ทำนายได้ของข้อมูลชุดที่ i

10.6 วิธีการหาค่าที่เหมาะสม (Optimization)

การหาค่าน้ำหนักที่เหมาะสมจะเป็นการช่วยลดค่าความผิดพลาดที่ได้จากฟังก์ชันต้นทุนลง การปรับค่าน้ำหนักจึงเป็นเรื่องสำคัญอย่างยิ่งมว่าจะทำให้โครงข่ายประสาทเทียมมีประสิทธิภาพในการทำนายหรือจำแนกได้ดียิ่งขึ้น งานวิจัยนี้เลือกใช้วิธี Stochastic gradient descent (SGD) (สมการที่ 8) วิธีนี้จะแบ่งข้อมูลออกเป็นชุดย่อยๆ เพื่อลดความซับซ้อนของข้อมูล และเปลี่ยนค่าน้ำหนักตลอดเวลาการฝึก เพื่อลดปัญหาในกรณีที่ค่าความผิดพลาดที่ได้จากฟังก์ชันต้นทุนตกอยู่ในช่วงค่า Local Minimum และมีการปรับค่าโดยใช้โมเมนตัม (Momentum) (สมการที่ 9 และ 10) ทำให้การเรียนรู้มีค่าที่ดีขึ้น (อินทรัตน์, 2561)

$$W_t = W_{t-1} - \alpha \frac{\partial J_t}{\partial w} \quad (8)$$

โดยที่

W	=	ค่าน้ำหนักที่ต้องการปรับค่า
α	=	อัตราการเรียนรู้

$$\frac{\partial J_t}{\partial w} = \text{อัตราการเปลี่ยนแปลงของฟังก์ชันต้นทุนเทียบกับค่าน้ำหนัก}$$

$$V_t = yv_{t-1} + \alpha \frac{\partial J_t}{\partial w} \quad (9)$$

$$W_t = W_{t-1} + V_t \quad (10)$$

โดยที่

$$v = \text{ค่าความเร็วที่มีการปรับพร้อมน้ำหนัก}$$

$$y = \text{ค่าสัมประสิทธิ์โมเมนตัม}$$

10.7 การแพร่กระจายย้อนกลับ

เป็นวิธีการที่ทำให้โครงข่ายประสาทเทียมหาความผิดพลาดของนิรอนระหว่างชั้นได้ เนื่องด้วยการป้อนไปข้างหน้าของโครงข่ายประสาทเทียมทำได้เพียงคำนวณความผิดพลาดจากการทำนายหรือจำแนกชั้นสุดท้ายเท่านั้น ไม่ได้สามารถคำนวณระหว่างชั้นได้โดยตรง ทำให้การเปลี่ยนแปลงค่าน้ำหนักจากการใช้วิธี Stochastic gradient descent ต้องหาวิธีที่นำเอาค่าความผิดพลาดมาสู่ชั้นก่อนหน้าเพื่อสังเกตค่าความผิดพลาดระหว่างชั้น สามารถหาค่าความผิดพลาดดังสมการที่ 11

$$\delta_j^l = \frac{\partial J}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} \frac{\partial a_j^l}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} f'(z_j^l) \quad (11)$$

โดยที่

$$\delta_j^l = \text{ค่าความผิดพลาดของเพอร์เซปตรอนตัวที่ j ในลำดับชั้น l}$$

$$J = \text{ฟังก์ชันต้นทุน}$$

$$a = \text{ค่าผลลัพธ์ที่ส่งออกไปในชั้นถัดไป}$$

$$z = \text{ค่าผลรวมของโครงข่ายประสาทเทียม}$$

การหาค่า $\frac{\partial J}{\partial a_j^l}$ ในลำดับชั้นก่อนหน้า ทำการคำนวณด้วยวิธีแพร่กระจายย้อนกลับ โดยมีการคำนวณคล้ายกับการป้อนไปข้างหน้าของโครงข่ายประสาทเทียม แต่จะกลับทิศทางในการคำนวณดังสมการที่ 12 ในลำดับสุดท้ายสามารถคำนวณโดยใช้ฟังก์ชันต้นทุน

$$\frac{\partial J}{\partial a_j^l} = \sum_{k=1}^m \frac{\partial J}{\partial z_k^{l+1}} \frac{\partial z_k^{l+1}}{\partial a_j^l} = \sum_{k=1}^m \delta_k^{l+1} W_{kj}^{l+1} \quad (12)$$

โดยที่

δ_k^{l+1} = ค่าความผิดพลาดของเพอร์เซพตรอนตัวที่ k ในลำดับชั้นที่ l+1

m = จำนวนเพอร์เซพตรอนในลำดับที่ l+1

W = ค่าน้ำหนัก

เมื่อได้ค่าความผิดพลาดของลำดับชั้นเรียบร้อยแล้ว ทำการเปรียบเทียบกับค่าน้ำหนัก และค่าความเอนเอียง ดังสมการที่ 13 และ 14 เพื่อเปรียบเทียบค่าความผิดพลาด จากนั้นใช้วิธี Stochastic gradient descent (Luus, Salmon, Van den Bergh, & Maharaj, 2015) ปรับปรุงค่าน้ำหนัก ดังสมการที่ 15

$$\frac{\partial J}{\partial w_{jk}^l} = \frac{\partial J}{\partial z_j^l} \frac{\partial z_j^l}{\partial w_{jk}^l} = \delta_j^l \delta_k^{l-1} \quad (13)$$

$$\frac{\partial J}{\partial b_j^l} = \frac{\partial J}{\partial z_j^l} \frac{\partial z_j^l}{\partial b_j^l} = \delta_j^l \quad (14)$$

$$w_{jk,t}^l = w_{jk,t-1}^l - \alpha a_{k,t}^{l-1} \delta_{j,t}^l \quad (15)$$

โดยที่

b = ค่าความเอนเอียง

$w_{jk,t}^l$ = ค่าน้ำหนักที่ได้รับการปรับปรุง


α = อัตราการเรียนรู้

ทำการปรับปรุงค่าน้ำหนักให้มีความเหมาะสมในแต่ละรอบของการการแพร่กระจายย้อนกลับ ทำซ้ำด้วยวิธีการเดียวในทุกๆชั้นจนย้อนกลับไปถึงชั้นข้อมูลแรก จากนั้นทำการคำนวณการป้อนไปข้างหน้าเช่นเดียวกับตอนแรกที่เริ่มคำนวณ ทำซ้ำตามกระบวนการทั้งหมดจนค่าฟังก์ชันต้นทุนลดลงตามค่าที่กำหนดไว้

11. โครงข่ายแบบ Recurrent Neural Network (RNN)

โครงข่าย RNN เป็นขั้นตอนวิธีของการเรียนรู้เชิงลึกใช้หลักการวิเคราะห์ข้อมูลรูปแบบของอนุกรมลำดับเหตุการณ์ (Sequence) มีลำดับการเกิดของเหตุการณ์ที่ชัดเจน และสามารถเปลี่ยนบริบทของเหตุการณ์ตามลำดับได้ การทำงานของ RNN เป็นการเอาผลลัพธ์ที่ได้จากการคำนวณย้อนกลับมาใช้เป็นข้อมูลเข้าอีกครั้ง โดยเรียกสถานะภายในของแบบจำลองนี้ว่า สถานะซ่อน


(Hidden State) หรือสถานะภายใน (Internal State) ช่วยให้แบบจำลองรู้จำรูปแบบของลำดับข้อมูลเข้า (Input Sequence) โดยมักถูกใช้ในการรู้จำเสียง (Speech recognition) และการประมวลผลภาษาธรรมชาติ (Prabha & Srikanth, 2019) ดังภาพประกอบ 5



ภาพประกอบ 5 โครงสร้างของโครงข่าย Recurrent Neural Network

ที่มา : Prabha & Srikanth, 2019)

โครงข่าย RNN พัฒนามาจากโครงข่ายประสาทเทียม โดยแต่เดิมจะมีฟังก์ชันในการรับข้อมูลเข้าแต่ละตัวแยกจากกัน ในการทำงานจะประมวลผลเป็นข้อมูลขาออกโดยไม่พิจารณาลำดับของข้อมูล และส่งผลเสียต่อการประมวลผลข้อมูลที่เป็นเชิงลำดับ เช่น ลำดับตัวอักษรในข้อความ ลำดับแรงดันอากาศของเสียง ลำดับของภาพและเสียงในวิดีโอ และข้อมูลแบบต่อเนื่อง (Time Series) เป็นต้น โครงข่าย RNN พัฒนามาให้มีโครงสร้างที่แตกต่างจากโครงข่ายประสาทเทียม โดยโครงสร้างของโครงข่าย RNN ที่เล็กที่สุดเรียกว่าเซลล์ (Cell) ที่อยู่ในส่วนสถานะซ่อนสำหรับใช้เก็บข้อมูลวิเคราะห์จากข้อมูลในชุดที่ผ่านมา เพื่อใช้ในการวิเคราะห์ในครั้งถัดไป (Mienye, Swart, & Obaido, 2024) ภาพประกอบ 6 แสดงการวนซ้ำ A ในโครงข่าย RNN ของข้อมูลขาเข้า x_t และข้อมูลขาออก h_t ให้ข้อมูลผ่านจากจุดหนึ่งไปจุดต่อไป



ภาพประกอบ 6 การทำงานของโครงข่าย Recurrent Neural Network

ที่มา : Data Science, 2018

ในการปรับค่าพารามิเตอร์โครงข่าย RNN จะอาศัยการป้อนข้อมูลแบบย้อนกลับเพื่อคำนวณค่า Gradient ที่ได้จากค่า Error สำหรับการปรับปรุงค่าพารามิเตอร์ของแบบจำลอง (B, K.P., & Kumar, 2018) ดังสมการที่ 16 และสมการที่ 17


$$h_t = f(W_{xh}x_t + W_{hh}h_{t-1} + b_h) \quad (16)$$

$$\hat{y}_t = g(W_{yh}h_t + b_y) \quad (17)$$

โดยที่

h_t	=	ค่า Hidden State ของหน่วยเวลา
f	=	ฟังก์ชันสำหรับคำนวณค่า Hidden State ของหน่วยเวลา
W_{xh}	=	ค่าน้ำหนักสำหรับคำนวณค่า Input ใน Hidden State
x_t	=	ค่า Input ของข้อมูล
W_{hh}	=	ค่าน้ำหนักสำหรับคำนวณค่า Hidden จากหน่วยเวลาก่อนหน้า
h_{t-1}	=	ค่า Hidden State จากหน่วยเวลาก่อนหน้า
b_h	=	ค่า Bias สำหรับคำนวณค่า Hidden State
$\hat{y}_t$	=	ค่า Output ที่ได้จากโครงข่าย RNN
g	=	ฟังก์ชันสำหรับคำนวณค่า Output
W_{yh}	=	ค่าน้ำหนักสำหรับคำนวณค่า Hidden State
b_y	=	ค่า Bias สำหรับคำนวณค่า Output

ในการทำงานแต่ละ Node ของ RNN จะประกอบด้วย 1 ข้อมูลขาเข้า ณ Node ปัจจุบัน และ 2 ข้อมูลขาออกที่ได้จากการคำนวณใน Node ก่อนหน้า จากนั้นข้อมูลทั้งสองจะถูกนำมารวมกัน และให้ผลลัพธ์ในสองทางคือ ข้อมูลขาออก ณ Node นั้น และข้อมูลขาออกสำหรับไปเข้าเป็นข้อมูลขาเข้าใน Node ถัดไป ภาพประกอบ 7 แสดงการวนซ้ำในโครงข่าย RNN โดยสถานะซ่อน (h) จะถูกคำนวณ ณ เวลา t (h_t คือ internal knowledge) จะถูกป้อนกลับ ณ เวลาต่อไป




ภาพประกอบ 7 การวนซ้ำของโครงข่าย Recurrent Neural Network

ที่มา : Data Science, 2018

12. โครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM)

ในโครงข่าย RNN เมทริกซ์ค่าน้ำหนักที่จะคูณเข้ากับข้อมูลขาเข้าจะทำหน้าที่เป็นหน่วยความจำระยะยาว (Long-Term Memory) เปลี่ยนแปลงหน้าที่เป็นหน่วยความจำระยะสั้น (Short-Term Memory) แบบชั่วคราวในระหว่างการฝึกฝนข้อมูลตัวอย่าง นั่นหมายถึง โครงข่าย RNN สามารถใช้ข้อมูลก่อนหน้าในการทำนายข้อมูลต่อไปที่อาจจะเกิดขึ้นในอนาคต อย่างไรก็ตาม ข้อจำกัดของโครงข่าย RNN คือสามารถดูย้อนกลับได้เพียงช่วงระยะเวลาสั้น ๆ นั่นหมายถึงโครงข่าย RNN จะมีความสามารถในการทำนายข้อมูลได้ลดลงเมื่อมีข้อมูลนำเข้าที่มีความยาวมากเกินไป ปัญหาหลักของโครงข่าย RNN มาจากค่า Gradient ลดลงในขณะที่ข้อมูลมีความยาวมากขึ้นจนกระทั่งไม่สามารถพบความเปลี่ยนแปลงได้อีก เรียกว่า ปัญหาการสูญหายของเกรเดียนต์ (Vanishing Gradient Problem) (B et al., 2018; Hochreiter & Schmidhuber, 1997)


การแก้ไข Vanishing Gradient Problem ของ LSTM โดยจะรักษาสถานะเซลล์หน่วยความจำ (Memory-State Cell) ด้วยการเพิ่มข้อมูลตามบริบทใหม่ให้กับเซลล์หน่วยความจำ และลบบริบทบางอย่างออกจากเซลล์หน่วยความจำ ภาพประกอบ 8 แสดงการทำงานของ LSTM



ภาพประกอบ 8 การทำงานของ Long Short-Term Memory

ที่มา : FU, J, CHU, J, GUO, P & CHEN, Z, 2016

โดยในการทำงานโครงข่าย RNN อาศัย Logistic Gates สำหรับวิเคราะห์การเพิ่มบริบทข้อมูลหรือลบบริบทข้อมูลในหน่วยความจำประกอบด้วย Input Gate, Output Gate, Forget Gate และ Memory-Cell Activation Gate ดังภาพประกอบ 9



ภาพประกอบ 9 Gate ภายใน Cell ของ Long Short-Term Memory

ที่มา : Rajkumar, 2019

Input Gate มีหน้าที่ในการตัดสินใจนำข้อมูลจากขั้นตอนก่อนหน้าเข้ามาวิเคราะห์ภายในเซลล์หน่วยความจำหรือลบออกจากเซลล์หน่วยความจำ ดังสมการที่ 18

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (18)$$

โดยที่

- i_t = ผลลัพธ์ที่ได้จาก Input Gate
- σ = ฟังก์ชัน Sigmoid
- W_{xi} = ค่าน้ำหนักสำหรับคำนวณ Input ใน Input Gate
- x_t = ค่า Input ของข้อมูลที่น่าเข้ามาคำนวณ
- W_{hi} = ค่าน้ำหนักสำหรับคำนวณค่า Hidden State ใน Input Gate
- h_{t-1} = ค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
- W_{ci} = ค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Input Gate
- c_{t-1} = ค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
- b_i = ค่า Bias ที่ใช้ในการคำนวณใน Input Gate

Forget Gate มีหน้าที่ควบคุมจำนวนข้อมูลจากขั้นตอนก่อนหน้าเพื่อเก็บค่าไว้ในเซลล์หน่วยความจำของสถานะซ่อน ณ ปัจจุบัน ดังสมการที่ 19

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (19)$$

โดยที่

f_t	=	ผลลัพธ์ที่ได้จาก Forget Gate
σ	=	ฟังก์ชัน Sigmoid
W_{xf}	=	ค่าน้ำหนักสำหรับคำนวณ Input ใน Forget Gate
x_t	=	ค่า Input ของข้อมูลที่น่าเข้ามาคำนวณ
W_{hf}	=	ค่าน้ำหนักสำหรับคำนวณค่า Hidden State ใน Forget Gate
h_{t-1}	=	ค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
W_{cf}	=	ค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Forget Gate
c_{t-1}	=	ค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
b_f	=	ค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

Memory-cell state gate มีหน้าที่กำหนดข้อมูลที่ได้รับจาก Input Gate และ Forget Gate ภายใน เซลล์หน่วยความจำและคำนวณค่าสถานะสำหรับการคำนวณครั้งถัดไป ดังสมการที่ 20

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_{xc}x_t + W_{hc}h_{t-1} + b_c) \quad (20)$$

โดยที่

c_t	=	ค่า Memory Cell State ในช่วงหน่วยเวลา
f_t	=	ผลลัพธ์ที่ได้จาก Forget Gate
c_{t-1}	=	ค่า Memory Cell State จากหน่วยเวลาก่อนหน้า
i_t	=	ผลลัพธ์ที่ได้จาก Input Gate
$\tanh$	=	ฟังก์ชัน Hyperbolic tangent
W_{xc}	=	ค่าน้ำหนักสำหรับคำนวณค่า Input จาก Memory Cell State Gate
x_t	=	Input ของข้อมูลที่น่าเข้ามาคำนวณ
W_{hc}	=	ค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Memory Cell State Gate
h_{t-1}	=	ค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
b_c	=	ค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

Output gate มีหน้าที่ควบคุมจำนวนข้อมูลของ Memory-cell state gate สำหรับใช้ในการคำนวณ Output ของเซลล์หน่วยความจำ ผลลัพธ์คือ Output และ Hidden State สำหรับใช้ในการคำนวณครั้งถัดไป ดังสมการที่ 21

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + W_{co} + c_{t-1} + b_o) \quad (21)$$

โดยที่

o_t	=	ผลลัพธ์ที่ได้จาก Output Gate
σ	=	ฟังก์ชัน Sigmoid
W_{xo}	=	ค่าน้ำหนักสำหรับคำนวณ Input ใน Output Gate
x_t	=	ค่า Input ของข้อมูลที่น่าเข้ามาคำนวณ
W_{ho}	=	ค่าน้ำหนักสำหรับคำนวณค่า Hidden State ใน Output Gate
h_{t-1}	=	ค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
W_{co}	=	ค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Output Gate
c_{t-1}	=	ค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
b_o	=	ค่า Bias ที่ใช้ในการคำนวณใน Output Gate
h_t	=	ค่า Hidden State ที่ได้จากการคำนวณ

13. โครงข่ายประสาทเทียมแบบ Gated Recurrent Unit (GRU)

เป็นโครงข่ายประสาทเทียมที่ถูกพัฒนาต่อยอดจากโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) โดยลดความซับซ้อนในการทำงานเมื่อเจอกับข้อมูลที่มีลำดับข้อมูลยาว โดยภายในจะมีลักษณะคล้าย LSTM อาศัย Logistic Gates เช่นเดียวกับ LSTM แต่จะมีส่วนต่างอยู่ 2 ส่วนประกอบด้วย Update Gate และ Reset Gate (Chung, Gulcehre, Cho, & Bengio, 2014) ดังภาพประกอบ 10

โดย Update Gate มีหน้าที่ในการตัดสินใจนำข้อมูลจากขั้นตอนก่อนหน้าเข้ามาวิเคราะห์มากหรือน้อยเพียงใด ดังสมการที่ 22

$$z_t = \sigma(W_z[h_{t-1}, X_t]) \quad (22)$$

โดยที่

z_t = ผลลัพธ์ที่ได้จาก Update Gate

σ = ฟังก์ชัน Sigmoid

W_z = ค่าน้ำหนักสำหรับคำนวณ Input ใน Update Gate

x_t = ค่า Input ของข้อมูลที่น่าเข้ามาคำนวณ

h_{t-1} = ค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า

และ Reset Gate มีหน้าที่ควบคุมจำนวนข้อมูลจากขั้นตอนก่อนหน้าเพื่อเก็บค่าไว้ในเซลล์หน่วยความจำของสถานะซ่อน ณ ปัจจุบัน ดังสมการที่ 23

$$r_t = \sigma(W_r[h_{t-1}, X_t]) \quad (23)$$

โดยที่


r_t = ผลลัพธ์ที่ได้จาก Forget Gate

σ = ฟังก์ชัน Sigmoid

W_r = ค่าน้ำหนักสำหรับคำนวณ Input ใน Forget Gate

x_t = ค่า Input ของข้อมูลที่น่าเข้ามาคำนวณ

h_{t-1} = ค่า Hidden State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า




ภาพประกอบ 10 การทำงานของ Gated Recurrent Unit (GRU)

ที่มา : Anishnama, 2023

14. โครงข่ายประสาทเทียมแบบ Bidirectional Long Short-Term Memory (BI-LSTM)

เป็นการพัฒนาต่อยอดจากโครงข่ายประสาทเทียมแบบ Long Short-Term Memory (LSTM) โดยหลักการของ Bidirectional สามารถนำไปใช้ร่วมกับโครงข่ายอื่นได้ เป็นการเพิ่มการเรียนรู้ให้โครงข่ายแบบสองทางในลำดับแบบเดินหน้าและลำดับแบบถอยหลัง (Jang, Kim, Harerimana, Kang, & Kim, 2020) ดังภาพประกอบ 11



ภาพประกอบ 11 การทำงานของ Bidirectional Long Short-Term Memory (BI-LSTM)

ที่มา : Huang, Zet al, 2015

15. การวัดประสิทธิภาพ (Evaluation)

Confusion Matrix คือการประเมินผลของการจำแนกที่ได้จากแบบจำลองเปรียบเทียบกับผลลัพธ์จริง โดยแสดงผลในรูปแบบเมตริกซ์ดังตาราง 2 ประกอบไปด้วย (Stehman, 1997)

ตาราง 2 Confusion Matrix ของค่าที่ถูกจำแนก (Prediction) เทียบกับผลลัพธ์จริง (Actual)

Actual / Prediction	Positive	Negative
Positive	True Positive (TP)	False Positive (FP)
Negative	False Negative (FN)	True Negative (TN)

- 1) True Positive (TP) คือ จำนวนข้อมูลที่แบบจำลองจำแนกถูกและผลลัพธ์จริงเป็นถูก
- 2) True Negative (TN) คือ จำนวนข้อมูลที่แบบจำลองจำแนกผิดและผลลัพธ์จริงเป็นผิด
- 3) False Positive (FP) คือ จำนวนข้อมูลที่แบบจำลองจำแนกถูกและผลลัพธ์จริงเป็นผิด
- 4) False Negative (FN) คือ จำนวนข้อมูลที่แบบจำลองจำแนกผิด และผลลัพธ์จริงเป็นถูก

ความแม่นยำ (Accuracy) ใช้วัดความถูกต้องในการจำแนกว่ามีความถูกต้องเท่าไร โดยใช้สมการ 24 โดย N คือจำนวนกลุ่มตัวอย่าง

$$\frac{TP+TN}{N} \quad (24)$$

ความเที่ยง (Precision) ใช้วัดความเข้าใจในการทำนายหรือจำแนก คำนวณดังสมการที่ 25

$$\frac{TP}{TP+FP} \quad (25)$$

ความการระลึกได้ (Recall) เป็นอัตราส่วนที่แบบจำลองทำนายหรือจำแนกคลาสที่ถูกพิจารณาว่ามีความถูกต้องจากข้อมูลที่ถูกต้องทั้งหมด คำนวณดังสมการที่ 26

$$\frac{TP}{TP+FN} \quad (26)$$

ค่า F1-Score เป็นค่า Harmonic mean ของค่า Precision และค่า Recall คำนวณดังสมการที่ 27

$$F1 = 2 * \left(\frac{Precision * Recall}{Precision + Recall} \right) \quad (27)$$

จากนั้นคำนวณค่าความถูกต้องโดยรวม (Overall Accuracy) (สมการที่ 28) และค่าสัมประสิทธิ์แคปปา (Kappa Coefficient) (สมการที่ 29) เพื่อวัดความถูกต้องการจำแนกที่ได้จากแบบจำลองโดยรวม และสัมประสิทธิ์แคปปาของโคเฮน (Kraemer, 2015) เพื่อวัดความสอดคล้อง (Consistency) ระหว่างผลการจำแนกที่ได้จากแบบจำลองกับข้อมูลจริง

$$\text{overall accuracy} = \frac{\sum_{i=1}^k n_{ii}}{N} \quad (28)$$

$$\hat{K} = \frac{N \sum_{i=1}^k n_{ii} - \sum_{i=1}^k (n_{i+} \times n_{+i})}{N^2 - \sum_{i=1}^k (n_{i+} \times n_{+i})} \quad (29)$$

โดยที่

k	=	จำนวนแถว
n_{ii}	=	ผลรวมแนวทแยงมุมของเมทริกซ์ความคลาดเคลื่อน
n_{i+}	=	ผลรวมของแถวของเมทริกซ์ความคลาดเคลื่อน
n_{+i}	=	ผลรวมของคอลัมน์ของเมทริกซ์ความคลาดเคลื่อน
N	=	จำนวนจุดตรวจสอบทั้งหมด

16. การกำหนดกลุ่มตัวอย่าง (Sampling)

การกำหนดกลุ่มตัวอย่างเป็นกระบวนการสำคัญทางสถิติในการเลือกศึกษาเฉพาะบางส่วนของประชากร หรือที่เรียกว่า กลุ่มตัวอย่าง (Sample) แทนการศึกษา ประชากร (Population) ทั้งหมด มักมีข้อจำกัดด้านเวลาและงบประมาณ การเลือกกลุ่มตัวอย่างที่เป็นตัวแทนที่ดีจะช่วยให้สามารถอ้างอิงผลลัพธ์กลับไปยังประชากรทั้งหมดได้อย่างน่าเชื่อถือ โดยวิธีการสุ่มตัวอย่างแบ่งออกเป็น 2 ประเภทหลัก (Cohen, Manion, & Morrison) ดังนี้

16.1. การสุ่มตัวอย่างโดยไม่ใช้ความน่าจะเป็น (Non-probability Sampling) เป็นการเลือกตัวอย่างโดยอาศัยวิจารณญาณของผู้วิจัยหรือตามความสะดวก ไม่ใช้การสุ่มทางสถิติ ทำให้ไม่สามารถระบุโอกาสที่แต่ละหน่วยจะถูกเลือกได้ และไม่สามารถอ้างอิงผลในเชิงสถิติไปยังประชากรทั้งหมดได้ แต่มักทำได้ง่ายและประหยัดค่าใช้จ่าย ประกอบด้วย

- การเลือกแบบบังเอิญ (Accidental/Convenience Sampling) การเลือกตัวอย่างตามความสะดวกของผู้เก็บข้อมูล โดยไม่มีหลักเกณฑ์ที่ชัดเจน
- การเลือกแบบโควตา (Quota Sampling) การกำหนดสัดส่วนของกลุ่มตัวอย่างที่ต้องการล่วงหน้า (เช่น เพศ, อายุ) แล้วจึงเลือกตัวอย่างให้ครบตามจำนวนโควตานั้น
- การเลือกแบบเจาะจง (Purposive/Judgmental Sampling) การเลือกตัวอย่างโดยใช้ดุลยพินิจและประสบการณ์ของผู้วิจัย เพื่อให้ได้กลุ่มตัวอย่างที่ตรงตามวัตถุประสงค์ของการวิจัยมากที่สุด

16.2. การสุ่มตัวอย่างโดยใช้ความน่าจะเป็น (Probability Sampling) เป็นกระบวนการที่ทุกหน่วยในประชากรมีโอกาสถูกเลือกอย่างเท่าเทียมกันหรือสามารถระบุความน่าจะเป็นได้ ทำให้ผลลัพธ์ที่ได้จากกลุ่มตัวอย่างสามารถเป็นตัวแทนและอ้างอิงกลับไปยังประชากรทั้งหมดได้ทางสถิติ ประกอบด้วย

- การสุ่มอย่างง่าย (Simple Random Sampling) ทุกหน่วยในประชากรมีโอกาสถูกเลือกเท่ากันทั้งหมด โดยอาจใช้วิธีจับสลากหรือตารางเลขสุ่ม
- การสุ่มอย่างเป็นระบบ (Systematic Sampling) การเลือกตัวอย่างแรกแบบสุ่ม จากนั้นเลือกตัวอย่างถัดไปตามช่วงที่กำหนดไว้อย่างสม่ำเสมอจากบัญชีรายชื่อทั้งหมด
- การสุ่มแบบชั้นภูมิ (Stratified Sampling) การแบ่งประชากรออกเป็นกลุ่มย่อย (ชั้นภูมิ) ที่มีลักษณะภายในกลุ่มเหมือนกัน แล้วจึงสุ่มตัวอย่างจากแต่ละกลุ่มย่อยนั้น
- การสุ่มแบบกลุ่ม (Cluster Sampling) การแบ่งประชากรตามพื้นที่ทางภูมิศาสตร์ (เช่น จังหวัด, อำเภอ) แล้วสุ่มเลือกพื้นที่นั้นๆ มาเป็นกลุ่มตัวอย่างเพื่อทำการศึกษาทั้งหมด หรือสุ่มย่อยลงไปอีกระดับ

17. งานวิจัยที่เกี่ยวข้องกับการประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงอายุการปลูกข้าว ด้วยข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียมระบบ SAR

การศึกษานี้ ผู้วิจัยทบทวนงานวิจัยที่เกี่ยวข้องกับการนำการเรียนรู้เชิงลึกประยุกต์กับข้อมูลภาพถ่ายจากดาวเทียมระบบ SAR จากการทบทวนงานวิจัยสามารถแบ่งกลุ่มงานวิจัยออกเป็น 4 กลุ่ม ดังนี้

17.1 งานวิจัยด้านการประยุกต์การจำแนกพื้นที่ปลูกข้าวด้วยข้อมูลภาพถ่ายจากดาวเทียมระบบออปติคัล

ดาวเทียมระบบออปติคัลเป็นเทคโนโลยีการสำรวจระยะไกลยุคแรกๆ ที่มีการใช้งานอย่างแพร่หลายทั้งการจำแนกการใช้ประโยชน์ที่ดินและการจำแนกพื้นที่การเกษตร โดยอาศัยความแตกต่างของคุณสมบัติการสะท้อนแสงในแต่ละช่วงคลื่นของวัตถุในการจำแนก ในประเทศไทย มีการศึกษาการจำแนกพื้นที่ปลูกพืชเศรษฐกิจด้วยดาวเทียมระบบออปติคัล เช่น งานวิจัยโดย (ศศิ กานต์ ไพลกลาง, 2563) ที่ใช้ข้อมูลภาพถ่ายจากดาวเทียม Landsat 8 ในการจำแนกพื้นที่ปลูกมันสำปะหลัง อ้อย และข้าวโพด ด้วยวิธี Support Vector Machine โดยผสมผสานข้อมูลหลายประเภท (เช่น ค่า Brightness, Greenness, Wetness, ความสูง, ความชัน, Aspect) เพื่อเพิ่มความแม่นยำ ได้ค่าความถูกต้องโดยรวมสูงถึง 92.76% ส่วน (Genc et al., 2014) ได้ประยุกต์ใช้ ข้อมูลอนุกรมเวลา (Time Series) จากดาวเทียม Landsat 8 ช่วยในการติดตามการเปลี่ยนแปลงตามชีพจรของพืช (Phenology), โดยทำการลดมิติข้อมูลด้วยเทคนิค Principal Component Analysis (PCA) ก่อนนำไปจำแนกพื้นที่ปลูกข้าวด้วยวิธี Maximum Likelihood ได้ค่าความถูกต้องโดยรวมสูงสุด 87.89% ต่อมาเมื่อดาวเทียม Sentinel-2 มีช่วงคลื่นใกล้เคียงกับ Landsat 8 แต่มีความละเอียดเชิงพื้นที่สูงกว่า ได้เข้าสู่วงโคจร ก็มีการนำมาประยุกต์ใช้อย่างแพร่หลายเช่นกัน โดย (Wei et

al., 2023) ใช้ ข้อมูลอนุกรมเวลาจากดาวเทียม Sentinel-2 เพื่อจำแนกพื้นที่ปลูกข้าว อาศัยการเปลี่ยนแปลงของดัชนีพืชพรรณ NDVI ตลอดช่วงการเติบโต เป็นข้อมูลสำคัญในการจำแนก ได้ค่าความถูกต้องโดยรวมมากกว่า 90%

17.2 งานวิจัยด้านการประยุกต์จำแนกพื้นที่ปลูกข้าวด้วยข้อมูลภาพถ่ายดาวเทียมระบบ SAR

การประยุกต์ใช้ข้อมูลดาวเทียม SAR และเทคนิคการเรียนรู้เชิงลึกหรือการเรียนรู้ของเครื่อง ในบริบทของประเทศไทยนั้น มีงานวิจัยที่น่าสนใจหลายชิ้น ตัวอย่างเช่น (Aobpaet, 2022) ได้ศึกษา ศักยภาพของข้อมูลอนุกรมเวลาจากดาวเทียม Sentinel-1 (โพลาไรเซชัน VV และ VH) ในการ ติดตามการเจริญเติบโตของพืชเศรษฐกิจหลายชนิดรวมถึงข้าว โดยพบว่าค่าการสะท้อนกลับ (Backscatter) ของข้าวมีความอ่อนไหวและเปลี่ยนแปลงตามช่วงการเติบโตอย่างมีนัยสำคัญ เป็น พื้นฐานสำคัญในการนำข้อมูล SAR มาจำแนกข้าวและระยะการเติบโต นอกจากนี้ (Sirirattanapol, Tamkuan, Nagai, & Ito, 2020) ได้แสดงให้เห็นถึงการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก โดยใช้ แบบจำลอง VGG-16 กับข้อมูลภาพถ่ายดาวเทียม ALOS-2 (ระบบ L-band) โพลาไรเซชันเดียว ใน การจำแนกการใช้ประโยชน์ที่ดิน 4 ประเภท รวมถึงพื้นที่เกษตรกรรม/นาข้าว/ทุ่งหญ้า (Agriculture, Paddy Field, Grassland) และให้ค่าความถูกต้องโดยรวมสูงถึง 91% เมื่อเทียบกับข้อมูลทดสอบ

ในขณะเดียวกัน งานวิจัยในต่างประเทศก็ได้ศึกษาการใช้ข้อมูล SAR กับการเรียนรู้ของเครื่อง อย่างกว้างขวาง โดยเน้นการเปรียบเทียบคุณลักษณะข้อมูลและการสกัดลักษณะเด่น ตัวอย่างเช่น (Turkar, Deo, Hariharan, & Rao, 2011) เปรียบเทียบศักยภาพระหว่างข้อมูลแบบ Fully Polarimetric และ Dual-โพลาไรเซชัน จากดาวเทียมหลายดวง (ALOS-PALSAR, TerraSAR-X, etc) ในการจำแนกการใช้ประโยชน์ที่ดินในอินเดีย (Abdikan, Sanli, Ustuner, & Calo, 2016) ใช้ ข้อมูล Sentinel-1 และเปรียบเทียบการผสมผสานลักษณะเด่น (Feature Combination) ต่างๆ ที่ ได้จากโพลาไรเซชัน VV และ VH เพื่อจำแนกการใช้ประโยชน์ที่ดินในตุรกี พบว่าการรวมหลาย ลักษณะเด่นให้ผลดีที่สุด (93.16% OA) (Camargo, Sano, Almeida, Mura, & Almeida, 2019) เปรียบเทียบแบบจำลองการเรียนรู้ของเครื่อง 5 ชนิด (NB, J48, RF, MLP, SVM) กับข้อมูล ALOS-2 ในการจำแนกการใช้ประโยชน์ที่ดินในบราซิล พบว่า SVM ให้ผลดีที่สุด (74.18% OA) และ (Hu, Ghamisi, & Zhu, 2018) ใช้ Canonical Correlation Forest (CCF) ร่วมกับการสกัดลักษณะเด่น หลายประเภท (Polarimetric, Statistical, Texture, Morphological) จากข้อมูล Sentinel-1 เพื่อ จำแนกการใช้ประโยชน์ที่ดิน 17 ประเภทในพื้นที่เมืองทั่วโลก

นอกจากนี้ การประยุกต์ใช้การเรียนรู้เชิงลึกกับข้อมูล SAR ทั้งแบบภาพเดียวและอนุกรม เวลา ได้รับความสนใจเพิ่มขึ้นอย่างมาก และมักแสดงให้เห็นประสิทธิภาพประจักษ์เหนือกว่าการ เรียนรู้ของเครื่องแบบดั้งเดิม (Kussul, Lavrenik, Skakun, & Shelestov, 2017) ใช้ข้อมูลหลาย

ช่วงเวลาจากทั้ง Landsat 8 และ Sentinel-1 ร่วมกับเทคนิคการเรียนรู้เชิงลึก (1D-CNN, 2D-CNN) เปรียบเทียบกับ RF และ ENN ในการจำแนกการใช้ประโยชน์ที่ดินและพืชเกษตร 11 ชนิดในยูเครน พบว่า 2D-CNN ให้ความถูกต้องสูงสุด (94.6% OA) (Ahishali, Kiranyaz, Ince, & Gabbouj, 2019) ได้เปรียบเทียบโครงข่าย Deep CNN สมัยใหม่ (Xception, InceptionResNet-v2) กับข้อมูล SAR ระบบ X-band (COSMO-SkyMed, TerraSAR-X) ในการจำแนกการใช้ประโยชน์ที่ดิน 6 ประเภทใน อิตาลีและเยอรมนี โดยพิจารณาถึงผลของขนาด Window size และช่องสัญญาณที่ใช้ สำหรับข้อมูล อนุกรมเวลา (Niculescu, Ienco, & Hanganu, 2018) เปรียบเทียบ GRU (RNN) กับ RF โดยใช้ ข้อมูลอนุกรมเวลา Sentinel-1 จำแนกพืชพรรณ 10 ชนิดในโรมาเนีย พบว่า GRU ให้ผลดีกว่า (96.2% OA) และที่เกี่ยวข้องโดยตรงกับการจำแนกข้าว (Ndikumana, Minh, Baghdadi, Courault, & Hossard, 2018) ได้ใช้ข้อมูลอนุกรมเวลา Sentinel-1 เปรียบเทียบการเรียนรู้ของ เครื่อง (KNN, RF, SVM) กับการเรียนรู้เชิงลึก (LSTM, GRU) ในการจำแนกพื้นที่เกษตร 11 ประเภท รวมถึงข้าว ในฝรั่งเศส พบว่า GRU ให้ความถูกต้องสูงสุด (89.6% OA) และทุกแบบจำลองที่ทดสอบ ให้ค่าความถูกต้องสูงกว่า 85.6%

17.3 งานวิจัยด้านการประยุกต์การจำแนกพื้นที่ปลูกข้าวข้อมูลภาพถ่ายจากดาวเทียมระบบ SAR

การใช้ข้อมูลข้อมูลภาพถ่ายจากดาวเทียมระบบ SAR จำแนกพื้นที่ปลูกข้าว โดยดั้งเดิมมีการ ใช้แบบจำลองการเรียนรู้ของเครื่อง อาทิ (สุริยะ et al., 2559) ทำการเปรียบเทียบการใช้ข้อมูลภาพถ่ายจากดาวเทียม RADARSAT-2 หลายช่วงเวลา โพลาไรเซชัน HH และ VV เพื่อจำแนกพื้นที่ปลูก ข้าวนาปรัง บริเวณพื้นที่ลุ่มน้ำชีตอนล่าง ในการศึกษาได้มีการนำข้อมูลภาพถ่ายจากดาวเทียม RADARSAT-2 มาประมวลผล Image Registration, Speckle Noise Suppression (Enhanced Lee-Sigma 7x7) จากนั้นทำการจำแนกการใช้ประโยชน์ที่ดิน 5 ชั้นข้อมูล ประกอบไปด้วย 1)นาข้าว นาปรัง 2)นาขังนาปี 3)ป่าโปร่ง 4)แหล่งน้ำ 5)พื้นที่ชุมชน ด้วยแบบจำลอง Support Vector Machine ผลการวิจัยพบว่า โพลาไรเซชัน HH ให้ค่าความถูกต้องโดยรวม 80% มากกว่า VV ที่ 70% โดยเฉพาะนาปรัง HH มีค่าความถูกต้องที่ 80 % แต่ VV มีค่าความถูกต้องที่ 50% รวมถึงการใช้ เทคนิคพิเศษในงาน Image Processing อาทิ (Xu et al., 2018) ทำการจำแนกพื้นที่เกษตร ประกอบไปด้วย ข้าวโพด ถั่วเหลือง ข้าว และถั่วลิสง โดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียม Sentinel-1 ทำการจำแนกโดยใช้วิธี Spectral Similarity Value (SSV) เป็นเทคนิคหนึ่งที่ใช้กับภาพ Hyperspectral จากนั้นนำมาเปรียบเทียบกับจำแนกด้วยแบบจำลอง Decision Tree และ Naïve Bayes ผลการศึกษาพบว่า SSV ให้ค่าความถูกต้องโดยรวมมากที่สุดที่ 92.04% สำหรับ Site 1 โพลาไรเซชัน VH และ 90.81% สำหรับ Site 2 โพลาไรเซชัน VH (Bazzi et al., 2019) ทำการ

จำแนกพื้นที่ปลูกข้าวบริเวณ Camargue ประเทศฝรั่งเศสโดยใช้ข้อมูลภาพถ่ายจากดาวเทียมอนุกรมเวลาจากดาวเทียม Sentinel-1 นำมาประยุกต์กับ Decision Tree และ Random Forest ให้ความถูกต้องโดยรวมที่ 96.3% และ 96.6% ตามลำดับ จะสังเกตได้ว่าวิธีการที่เรียบง่าย แต่ให้ผลลัพธ์ที่ทรงพลังมากๆ เมื่อนำมาใช้กับข้อมูลคุณลักษณะ ดังนี้ ค่าความแปรปรวนของ โพลาริเซชัน VV/VH, โพลาริเซชัน VH และ โพลาริเซชัน VV/VH ที่ผ่านมาการฟิตจากสมการ Gaussian และ (Phung et al., 2020) ทำการติดตามการเติบโตของข้าวในลุ่มแม่น้ำโขง ประเทศเวียดนามโดยใช้ข้อมูลภาพถ่ายจากดาวเทียมอนุกรมเวลาจากดาวเทียม Sentinel-1 สามารถติดตามอายุของข้าวเมื่อเทียบกับข้อมูลภาคพื้นดินมีค่า R^2 มากถึง 0.92 และสามารถคาดการณ์ช่วงเวลาปลูกเทียบกับข้อมูลภาคพื้นดินมีค่า $R^2 = 0.92$ กับช่วงเวลาเก็บเกี่ยวเทียบกับข้อมูลภาคพื้นดินมีค่า R^2 มากถึง 0.70 นอกจากนี้ด้วยข้อมูลภาพถ่ายจากดาวเทียมอนุกรมเวลาจากดาวเทียม Sentinel-1 สามารถจำแนกอายุของข้าวเทียบกับข้อมูลภาคพื้นดินมีค่า $R^2 = 0.918$

17.4 งานวิจัยด้านการประยุกต์การเรียนรู้เชิงลึกกับการจำแนกพื้นที่ปลูกข้าวข้อมูลภาพถ่ายจากดาวเทียมระบบ SAR

การเรียนรู้เชิงลึกที่ดำเนินการใช้คุณลักษณะต่างๆที่ได้มาจากการถ่ายภาพจากดาวเทียมระบบ SAR มีทั้งรูปแบบ Convolution และ แบบ Sequence โดย (Zhao et al., 2019) ทำการจำแนกพื้นที่เกษตรกรรมโดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายจาก Sentinel-1 โพลาริเซชัน VV และ VH โดยนำการเรียนรู้เชิงลึก 3 แบบจำลอง และแบบจำลอง Random Forest เป็นวิวัฒนาการที่ต่อเนื่องกัน ประกอบไปด้วย 1D CNN, LSTM RNN และ GRU RNN โดยทำการจำแนกพื้นที่เกษตร 5 ชนิดข้อมูล ประกอบไปด้วย Paddy, Sugarcane, Banana, Pineapple และ Eucalyptus ทดสอบกับพื้นที่ขนาด 84×128 กิโลเมตรบริเวณ Suixi และ Leizhou เมือง Zhanjiang ประเทศสาธารณรัฐประชาชนจีน ทั้ง 4 แบบจำลอง มีความถูกต้องโดยรวมในการจำแนกสูง ประกอบไปด้วย 1D CNN 95.9%, LSTM RNN 93.1% ,GRU RNN 93.4% และ RF 93.7% (Qu et al., 2020) ทำการประยุกต์ Depthwise Separable Convolution Recurrent Neural Network (DSCRNN) กับข้อมูลอนุกรมเวลา Polarimetric Sentinel-1 เพื่อจำแนกพื้นที่เกษตรกรรม แบ่งออกเป็น 2 พื้นที่ พื้นที่ 1 ประกอบไปด้วย Alfalfa, Sugar beets, Lettuce, Onions, Winter Wheat และ Hay พื้นที่ 2 ประกอบด้วย Almond, Winter Wheat, Alfalfa, Sunflower, Tomato, Dry beans และ hay โดยผลลัพธ์เมื่อเทียบกับ Support Vector Machine, Random Forest, Conv1D, LSTM, Conventional CNN, Depthwise Convolution CNN, Convolution Recurrent Neural Network พบว่า DSCRNN ให้ความถูกต้องโดยรวมมากที่สุด โดยในพื้นที่ 1 96.03% และพื้นที่ 2 93.89% และ (Jo et al., 2020) ทำการจำแนกพื้นที่ปลูกข้าวโดยทำการประยุกต์การเรียนรู้เชิงลึกกับ

ข้อมูลอนุกรมเวลาภาพถ่ายจาก Sentinel-1 พื้นที่ประเทศเกาหลีใต้โดยทำการทดสอบแบบจำลอง 6 รูปแบบ ประกอบไปด้วย 1) Primary Learning Material (PLM) + Fully Connected Recurrent Neural Network (FCRNNs), 2) PLM + Domain-Adapted RNN (DARNNs), 3) Data Augmented Learning Material (DALM) + FCRNNs, 4) DALM + DARNNs, 5) Semi-Supervised Classification Learning Material (SSCLM) + FCRNNs และ 6) SSCLM + DARNNs ผลการทดสอบพบว่า DALM + FCRNNs และ DALM + DARNNs ให้ความถูกต้องโดยรวมมากที่สุดเท่ากัน มากถึง 96.42%

การติดตามและจำแนกพื้นที่เพาะปลูกข้าว รวมถึงช่วงระยะเวลาเจริญเติบโต ถือเป็นข้อมูลพื้นฐานที่มีความสำคัญอย่างยิ่งยวดต่อการบริหารจัดการภาคการเกษตร ความมั่นคงทางอาหาร และเศรษฐกิจของประเทศ เทคโนโลยีการสำรวจจากระยะไกล โดยเฉพาะข้อมูลภาพถ่ายจากดาวเทียม ได้เข้ามามีบทบาทสำคัญในการเก็บรวบรวมข้อมูลในพื้นที่ขนาดใหญ่ได้อย่างมีประสิทธิภาพ ทดแทนข้อจำกัดของการสำรวจภาคพื้นดิน แม้ว่าข้อมูลดาวเทียมระบบออปติคัล จะถูกนำมาใช้อย่างแพร่หลายในการจำแนกพืชพรรณ แต่ก็ประสบปัญหาสำคัญจากเมฆปกคลุม จำกัดความต่อเนื่องของข้อมูล โดยเฉพาะในฤดูเพาะปลูกข้าวของประเทศไทย

ในทางตรงกันข้าม ข้อมูลภาพถ่ายดาวเทียมระบบ SAR ได้แสดงให้เห็นถึงศักยภาพประกอบโดดเด่นในการทะลุเมฆและบันทึกข้อมูลได้อย่างต่อเนื่องในทุกสภาพอากาศ ทำให้ข้อมูลอนุกรมเวลา SAR (SAR Time Series) กลายเป็นเครื่องมือที่มีประสิทธิภาพสูงในการติดตามการเปลี่ยนแปลงทางกายภาพและซีฟลักษณะของต้นข้าวตลอดฤดูเพาะปลูก การประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่อง และโดยเฉพาะอย่างยิ่ง การเรียนรู้เชิงลึกกับข้อมูล SAR ทั้งแบบภาพเดียวและแบบอนุกรมเวลา ได้รับการพิสูจน์แล้วว่าสามารถจำแนกพื้นที่เกษตรกรรมและข้าวได้อย่างแม่นยำ โดยแนวโน้มปัจจุบันมุ่งไปสู่การใช้การเรียนรู้เชิงลึกมากขึ้น เนื่องจากความสามารถในการเรียนรู้ลักษณะเด่นที่ซับซ้อนจากข้อมูลโดยอัตโนมัติ และมีงานวิจัยจำนวนมากที่แสดงให้เห็นว่าการเรียนรู้เชิงลึก (เช่น CNN, LSTM, GRU) มักให้ประสิทธิภาพประกอบสูงกว่าการเรียนรู้ของเครื่องแบบดั้งเดิมในการจำแนกพืชด้วยข้อมูล SAR Time Series รวมถึงความสำเร็จในการประเมินอายุข้าว ใกล้เคียงกับการจำแนกช่วงระยะเวลาเจริญเติบโต

อย่างไรก็ตาม แม้จะมีความก้าวหน้าดังกล่าว การทบทวนวรรณกรรมยังชี้ให้เห็นถึงช่องว่างสำคัญ (Research Gaps) ที่งานวิจัยนี้มุ่งหวังจะเข้าไปเติมเต็ม ยังมีการศึกษาเปรียบเทียบประสิทธิภาพระหว่างโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึกที่หลากหลายกับวิธีการเรียนรู้ของเครื่องแบบดั้งเดิมอย่างเป็นระบบ สำหรับการจำแนกช่วงระยะเวลาการเพาะปลูกข้าว (Rice Plantation Stages) ด้วยข้อมูลอนุกรมเวลา SAR ไม่มากนักยังขาดการพัฒนาและนำเสนอกระบวนการที่ชัดเจนในการประยุกต์ใช้การเรียนรู้เชิงลึก (เช่น การเตรียมข้อมูล, การเลือกโครงข่าย

ประสาทเทียม , การฝึกสอนแบบจำลอง) เพื่อสกัดข้อมูลช่วงการปลูกข้าวจากอนุกรมเวลา SAR ให้ได้ประสิทธิภาพสูงสุด การศึกษาและยืนยันประสิทธิภาพของการเรียนรู้เชิงลึก ในการจำแนกช่วงการปลูกข้าวโดยตรง นอกเหนือจากการจำแนกชนิดพืชหรือประเมินอายุโดยรวม ยังเป็นประเด็นที่ต้องการการค้นคว้าเพิ่มเติม

ด้วยเหตุนี้ งานวิจัยฉบับนี้จึงได้กำหนดวัตถุประสงค์เพื่อตอบสนองต่อช่องว่างดังกล่าว โดยจะมุ่งเน้นการประยุกต์ใช้และเปรียบเทียบประสิทธิภาพของเทคนิคการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง ในการจำแนกช่วงระยะเวลาการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลา Sentinel-1 ผลการวิจัยที่ได้จะเป็นประโยชน์ต่อการพัฒนาองค์ความรู้และแนวทางปฏิบัติสำหรับการติดตามการเพาะปลูกข้าวให้มีความแม่นยำและทันท่วงที่ยั่งยืนต่อไป



บทที่ 3

วิธีดำเนินการวิจัย

การดำเนินการวิจัยเรื่องการประยุกต์การเรียนรู้เชิงลึกในการจำแนกช่วงอายุการปลูกข้าวด้วยข้อมูลอนุกรมเวลาภาพถ่ายดาวเทียมระบบ SAR โดยมีวัตถุประสงค์ได้แก่การเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องในการจำแนกข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR, การพัฒนากระบวนการเรียนรู้เชิงลึกในการสกัดพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR อีกทั้งและการศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR โดยเนื้อหาในบทนี้ได้แสดงการดำเนินการวิจัยที่ประกอบด้วยพื้นที่ศึกษา, ข้อมูลที่ใช้ในการศึกษา, และขั้นตอนการดำเนินการวิจัย


1. พื้นที่ศึกษา

จังหวัดสุพรรณบุรีเป็นจังหวัดที่อยู่ในบริเวณพื้นที่ภาคกลางของประเทศไทย งานวิจัยนี้กำหนดพื้นที่ศึกษาสำหรับการจำแนกช่วงระยะเวลาการเพาะปลูกข้าวด้วยข้อมูลภาพถ่ายดาวเทียมระบบ SAR ณ จังหวัดสุพรรณบุรี ตั้งอยู่บริเวณภาคกลางของประเทศไทย (ภาพที่ 12 ก). ลักษณะเด่นของจังหวัดสุพรรณบุรีคือเป็นพื้นที่ราบลุ่มส่วนใหญ่ มีชุดดินที่เหมาะสมกับการปลูกข้าวอาทิ ชุดดินกำแพงแสน, ชุดดินโคราช, ชุดดินจตุรัส และชุดดินจันทิก ดินเหล่านี้ส่วนใหญ่เป็นดินร่วน ดินเหนียว และดินตะกอนที่มีความอุดมสมบูรณ์ (นวลปรางค์ ไชยตะขบ, 2551) สามารถกักเก็บน้ำได้ดี อีกทั้งยังมีภูมิอากาศที่มีอุณหภูมิเปลี่ยนแปลงในช่วง 20 องศาเซลเซียสถึง 37 องศาเซลเซียสตลอดทั้งปีและมีแหล่งน้ำสำคัญหลายแห่ง โดยเฉพาะแม่น้ำท่าจีนเอื้ออำนวยต่อกิจกรรมทางการเกษตร โดยเฉพาะอย่างยิ่งการเพาะปลูกข้าว อีกทั้งยังมีรูปแบบการใช้ประโยชน์ที่ดินที่หลากหลาย (ภาพที่ 12 ข) โดยขอบเขตพื้นที่ศึกษาในการวิจัยนี้ครอบคลุมเนื้อที่ประมาณ 683 ตารางกิโลเมตร

การเพาะปลูกข้าวในจังหวัดสุพรรณบุรีสามารถดำเนินการได้ทั้งในฤดูนาปีและนาปรัง ข้าวนาปีส่วนใหญ่เพาะปลูกในช่วงฤดูฝน โดยมีระยะเวลาดังแต่เดือนพฤษภาคมถึงกรกฎาคมและเก็บเกี่ยวผลผลิตในช่วงเดือนกันยายนถึงพฤศจิกายน สำหรับข้าวนาปรังมีการเพาะปลูกในฤดูแล้ง (ช่วงเดือนพฤศจิกายนถึงกุมภาพันธ์) จำเป็นต้องอาศัยระบบชลประทานเป็นสำคัญ เนื่องจากปริมาณน้ำฝนตามธรรมชาติมีจำกัด โดยทั่วไปแล้ว ข้าวในพื้นที่จังหวัดสุพรรณบุรีจะสามารถเก็บเกี่ยวได้หลังจากเริ่มเพาะปลูกเป็นระยะเวลาไม่กี่เดือน ทั้งนี้ ขึ้นอยู่กับปัจจัยด้านพันธุ์ข้าวโดยส่วนใหญ่เป็นข้าวพันธุ์ กข 41 เป็นข้าวไม่ไวต่อช่วงแสง มีอายุเก็บเกี่ยวประมาณ 105 วัน บางพื้นที่มีการปลูกข้าวปทุมธานี 1

หรือข้าวพันธุ์ กข85 ล้วนเป็นข้าวไม่ไวต่อช่วงแสง อีกทั้งสภาพแวดล้อมในการเพาะปลูก อุณหภูมิ, ปริมาณน้ำฝน และประสิทธิภาพของระบบชลประทาน จัดเป็นปัจจัยแวดล้อมหลักที่มีอิทธิพลต่อวัฏจักรการปลูกข้าวในจังหวัดสุพรรณบุรี

อย่างไรก็ตาม ลักษณะการเพาะปลูกข้าวในจังหวัดสุพรรณบุรีมีความซับซ้อนเนื่องจากความหลากหลายของช่วงเวลาการเริ่มต้นเพาะปลูกในแต่ละแปลง (ภาพประกอบ 12 ค) อาทิเช่นในบางแปลงจะอยู่ในช่วงของการเตรียมดินสำหรับการเพาะปลูก และบางแปลงข้าวอยู่ในช่วงกำลังเจริญเติบโตจึงทำให้ปรากฏเป็นสีเขียวอ่อนบนภาพ และบางแปลงข้าวได้มีการเจริญเติบโตเต็มที่แล้วจึงทำให้ปรากฏเป็นสีเขียวเข้มบนภาพ อีกทั้งยังพบแปลงข้าวที่ยังไม่มีการดำเนินกิจกรรมเพาะปลูกดังที่ปรากฏเป็นสีน้ำตาล เนื่องจากปฏิทินการเพาะปลูก (asynchronous planting calendars) ที่แตกต่างกันในแต่ละแปลงนี้ ก่อให้เกิดความท้าทายที่สำคัญต่อการจำแนกช่วงระยะเวลาการเพาะปลูกข้าวอย่างแม่นยำ โดยใช้ข้อมูลอนุกรมเวลาจากดาวเทียม SAR. สภาวะดังกล่าวส่งผลให้ลักษณะการเจริญเติบโตทางกายภาพของข้าวในแต่ละแปลงมีความแตกต่างกัน แม้จะทำการบันทึกภาพในช่วงเวลาเดียวกัน ด้วยเหตุนี้ ลักษณะการตอบสนองของสัญญาณ SAR ที่บันทึกได้ (SAR backscatter temporal profiles) จากแปลงข้าวต่างๆ จึงแสดงความแปรผันสูง ทำให้การวิเคราะห์เพื่อจำแนกช่วงการเจริญเติบโตมีความซับซ้อน และเป็นอุปสรรคต่อการพัฒนาแบบจำลองการจำแนกที่มีความแม่นยำสูง



(ก)

(ข)


(ค)

ภาพประกอบ 12 พื้นที่ศึกษาในการวิจัย โดย (ก) ขอบเขตประเทศไทย (ข) พื้นที่ศึกษา และ (ค) แปลงปลูกข้าวที่มีช่วงเวลาการปลูกที่ต่างกัน

2. ข้อมูลที่ใช้ในการศึกษา

2.1 ข้อมูลภาพถ่ายดาวเทียมระบบ SAR

ข้อมูลที่ใช้ในการวิเคราะห์ของงานวิจัยนี้ได้เลือกใช้ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1 ที่บันทึกภาพบริเวณพื้นที่จังหวัดสุพรรณบุรี โดยอยู่ใน Relative orbit 62 (ดังภาพประกอบ 13) ที่ถูกบันทึกภาพในช่วงระหว่างวันที่ 12 มกราคม พ.ศ. 2565 ถึง 26 ธันวาคม พ.ศ. 2565 จำนวนทั้งสิ้น 28 ภาพ แสดงดังตาราง 4 ข้อมูลภาพประกอบได้เป็นข้อมูลภาพประเภท Ground Range Detection (GRD) ที่อยู่ในช่วงคลื่น C-band โดยมีความยาวช่วงคลื่น 5405 GHz มีลักษณะของคลื่นในรูปแบบโพลาไรเซชัน Cross-โพลาไรเซชัน (มีการส่งผ่านในแนวตั้ง (vertical transmit) และรับในแนวนอน (horizontal receive)) และ co-โพลาไรเซชัน -VV (มีการส่งผ่านในแนวตั้ง (vertical transmit) และรับในแนวตั้ง (vertical receive)) โหมด Interferometric Wide ในแนวการโคจรของดาวเทียมแบบขาลง (Descending) ใช้เวลาโคจรซ้ำที่เดิมมากที่สุด 12 วัน มีความละเอียดของภาพในแนว Range และ Azimuth อยู่ที่ 5 x 20 เมตร หรือ 100 ตารางเมตร ต่อหนึ่งจุดภาพ (ESA, 2015)



ภาพประกอบ 13 ภาพถ่ายดาวเทียม Sentinel-1 ในพื้นที่ศึกษา


2.2 การประมวลผลสร้างข้อมูลค่าเฉลี่ยรายเดือน (Monthly Mean Composites)

ในการวิเคราะห์ข้อมูลอนุกรมเวลา (Time Series) สัญญาณรบกวนหรือความแปรปรวนในระยะสั้นอาจจะบดบังแนวโน้มการเปลี่ยนแปลงที่สำคัญของข้อมูลได้ สัญญาณรบกวนเหล่านี้ในข้อมูล SAR เกิดจากหลายปัจจัย อาทิ การเปลี่ยนแปลงความชื้นของดินและพืชพรรณจากฝนที่ตกไม่

สมำเสมอ, ผลกระทบจากลมที่ทำให้ลักษณะทางกายภาพของต้นข้าวเปลี่ยนแปลงชั่วคราว, หรือ สัญญาณรบกวนประเภทจุด (Speckle) ที่ยังคงหลงเหลืออยู่แม้จะผ่านกระบวนการกรองแล้วก็ตาม เพื่อลดผลกระทบของความแปรปรวนระยะสั้นเหล่านี้และสกัดสัญญาณการเปลี่ยนแปลงทางชีพ วัฏจักร (Phenological Signal) ของต้นข้าวให้มีความชัดเจนยิ่งขึ้น งานวิจัยนี้จึงได้สร้างชุดข้อมูล ค่าเฉลี่ยรายเดือน (Monthly Mean Composites - MMCs) ขึ้นมา เพื่อหาค่าเฉลี่ยของข้อมูลในแต่ละเดือน ช่วยกรองความผันผวนที่ไม่เกี่ยวข้องออกไป และทำให้รูปแบบการเจริญเติบโตของข้าวในแต่ละเดือนปรากฏเด่นชัดขึ้น ส่งผลให้แบบจำลองสามารถเรียนรู้และจำแนกประเภทได้ง่ายและแม่นยำยิ่งขึ้น (Blickensdörfer, 2022) โดย

ในการประมวลผลสร้างข้อมูลค่าเฉลี่ยรายเดือน ดำเนินการโดยคำนวณค่าเฉลี่ย (Mean) ของค่าสัมประสิทธิ์การกระเจิงกลับ ในทุกจุดภาพ (Pixel) จากข้อมูลภาพถ่ายดาวเทียม Sentinel-1 (ดังภาพที่ 14) ทั้งหมดที่บันทึกได้ในแต่ละเดือน มีขั้นตอนดังนี้

- ดำเนินการจัดกลุ่มข้อมูล รวบรวมภาพถ่ายดาวเทียม Sentinel-1 ที่ผ่านการประมวลผลเบื้องต้นแล้ว จำนวน 28 ภาพ และจัดกลุ่มตามเดือนปฏิทิน (มกราคม ถึง ธันวาคม)
- คำนวณค่าเฉลี่ยรายจุดภาพสำหรับแต่ละจุดภาพ (Pixel) ในพื้นที่ศึกษา ดำเนินการคำนวณค่าเฉลี่ยของค่าสัมประสิทธิ์การกระเจิงกลับ จากภาพทั้งหมดที่อยู่ในกลุ่มของเดือนนั้นๆ การคำนวณนี้ประมวลผลแยกตามโพลาไรเซชัน VH และ VV
- การสร้างชุดข้อมูลอนุกรมเวลาใหม่ หลังจากที่ได้ดำเนินการประมวลผลเรียบร้อยแล้ว ผลลัพธ์ที่ได้คือชุดข้อมูลอนุกรมเวลาชุดใหม่มีความยาว 12 ช่วงเวลา (12 เดือน) ประกอบด้วยภาพค่าเฉลี่ยรายเดือนของโพลาไรเซชัน VH จำนวน 12 ภาพ และ VV จำนวน 12 ภาพ



ภาพประกอบ 14 การประมวลผลข้อมูลค่าเฉลี่ยรายเดือน

ตาราง 3 ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1 ที่ใช้ดำเนินการวิจัย

1) วันที่ 12 มกราคม พ.ศ.2565	11) วันที่ 24 พฤษภาคม พ.ศ.2565	21) วันที่ 21 กันยายน พ.ศ.2565
2) วันที่ 24 มกราคม พ.ศ.2565	12) วันที่ 5 มิถุนายน พ.ศ.2565	22) วันที่ 3 ตุลาคม พ.ศ.2565
3) วันที่ 5 กุมภาพันธ์ พ.ศ.2565	13) วันที่ 17 มิถุนายน พ.ศ.2565	23) วันที่ 27 ตุลาคม พ.ศ.2565
4) วันที่ 17 กุมภาพันธ์ พ.ศ.2565	14) วันที่ 29 มิถุนายน พ.ศ.2565	24) วันที่ 8 พฤศจิกายน พ.ศ.2565
5) วันที่ 13 มีนาคม พ.ศ.2565	15) วันที่ 11 กรกฎาคม พ.ศ.2565	25) วันที่ 20 พฤศจิกายน พ.ศ.2565
6) วันที่ 25 มีนาคม พ.ศ.2565	16) วันที่ 23 กรกฎาคม พ.ศ.2565	26) วันที่ 2 ธันวาคม พ.ศ.2565
7) วันที่ 6 เมษายน พ.ศ.2565	17) วันที่ 4 สิงหาคม พ.ศ.2565	27) วันที่ 14 ธันวาคม พ.ศ.2565
8) วันที่ 18 เมษายน พ.ศ.2565	18) วันที่ 16 สิงหาคม พ.ศ.2565	28) วันที่ 26 ธันวาคม พ.ศ.2565
9) วันที่ 30 เมษายน พ.ศ.2565	19) วันที่ 28 สิงหาคม พ.ศ.2565	
10) วันที่ 12 พฤษภาคม พ.ศ.2565	20) วันที่ 9 กันยายน พ.ศ.2565	

2.3 ข้อมูลแบบจำลองความสูงเชิงเลข

ข้อมูลแบบจำลองความสูงเชิงเลขจากโครงการ SRTM (Shuttle Radar Topography Mission) มีความละเอียดเชิงพื้นที่ 30 เมตร ได้ถูกนำมาใช้สำหรับอ้างอิงลักษณะความสูงต่ำของภูมิประเทศ ข้อมูล DEM นี้มีความสำคัญในการปรับแก้ความคลาดเคลื่อนทางเรขาคณิต ที่เกิดจากผลกระทบของภูมิประเทศ (Terrain Correction) ในข้อมูลภาพถ่ายดาวเทียม Sentinel-1

2.4 ข้อมูลภูมิสารสนเทศ

2.4.1 ข้อมูลขอบเขตการปกครอง จากกรมการปกครอง เพื่อใช้ในการระบุตำแหน่งของพื้นที่ศึกษา

2.4.2 ข้อมูลการใช้ประโยชน์ที่ดิน จากกรมพัฒนาที่ดิน ปี พ.ศ.2564 เพื่อใช้ในการจำแนกประเภทข้อมูลอื่นๆ

2.4.3 ข้อมูลการเพาะปลูกข้าวนาปี ปี พ.ศ.2565/66 จากสำนักงานเศรษฐกิจการเกษตร เพื่อใช้ในการจำแนกพื้นที่ปลูกข้าวและจำแนกช่วงเวลาระยะเวลาในการเพาะปลูกข้าวนาปี โดยงานวิจัยนี้มีการแบ่งออกช่วงระยะเวลาการเพาะปลูกประกอบไปด้วย เดือนพฤษภาคม, มิถุนายน, กรกฎาคมและเดือนสิงหาคม

3. ขั้นตอนการดำเนินการวิจัย

การวิเคราะห์ข้อมูลในการวิจัยนี้ แบ่งการทดลองออกเป็น 3 ส่วน ประกอบไปด้วย การเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR การเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR และ

การเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงเวลาของการเพาะปลูกข้าวในแต่ละพื้นที่จากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR โดยภาพรวมการดำเนินการวิจัยแสดงดังภาพประกอบ 12 โดยกระบวนการ ดังนี้

3.1 การเตรียมข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1

การจำแนกช่วงระยะเวลาการเพาะปลูกของข้าวจากภาพถ่ายจากดาวเทียมระบบเรดาร์ จำเป็นที่จะต้องมีการปรับแก้ข้อมูลก่อนจะดำเนินการวิจัย (ภาพประกอบ 15) โดยทำการเตรียมข้อมูลภาพจากดาวเทียม Sentinel-1 ด้วยโปรแกรม ESA Sentinel Application Platform (SNAP) จาก European Space Agency (ESA) เป็นโปรแกรม Open Source ที่ทำการตัดข้อมูล (Subset) บริเวณพื้นที่ศึกษา เพื่อลดระยะเวลาการประมวลผล เนื่องจากข้อมูลภาพจากดาวเทียม Sentinel-1 มีขนาดใหญ่ (Swath wide กว้าง 250 กิโลเมตร) ทำให้การประมวลผลใช้เวลานานและมีโอกาสเกิดข้อผิดพลาดระหว่างการประมวลผลสูง จึงต้องทำการตัดข้อมูลเพื่อให้การประมวลผลเร็วขึ้น จากนั้นทำการประมวลผล Thermal Noise Removal เพื่อลดสัญญาณรบกวนที่เกิดจากการเคลื่อนที่แบบสุ่มของอิเล็กทรอนิกส์เมื่อมีอุณหภูมิสูงขึ้น โดยจะปรากฏเป็น White Noise จากนั้นทำการ Apply Orbit ปรับแก้ความคลาดเคลื่อนจากวงโคจร เพื่อให้การ Co-registration ของภาพเพื่อให้ข้อมูลภาพมีความถูกต้องเชิงตำแหน่งมากที่สุด เมื่อปรับแก้วงโคจรเรียบร้อยแล้ว จึงทำการประมวลผล Remove GRD Border Noise เพื่อลดสัญญาณรบกวนระหว่างภาพ แล้วจึงทำการ Calibrate ข้อมูลภาพทั้ง 44 ช่วงเวลา เพื่อแปลงค่า Digital Number เป็นค่า Backscatter (σ^0) โดยใช้สมการที่ 30 (ESA, 2015)

$$\sigma_i^0 = \frac{DN_i^2}{A_i^2} \quad (30)$$

โดยที่

σ_i^0 = ค่า Sigma Naught ที่คำนวณได้ของแต่ละจุดภาพ (pixel) เป็นค่าที่สะท้อนคุณสมบัติทางกายภาพของวัตถุบนพื้นผิวโลก


DN_i = ค่า Digital Number หรือค่าความเข้มเริ่มต้นของแต่ละจุดภาพที่บันทึกมาในไฟล์ข้อมูล

A_i = ค่าสัมประสิทธิ์การปรับแก้ (Normalization Coefficient) เป็นค่าคงที่สำหรับการสอบเทียบ (Calibration) คำนี้นี้จะได้มาจากข้อมูลประกอบ (Metadata) ที่มาพร้อมกับภาพถ่ายดาวเทียม

จากนั้นทำการประมวลผลตัวกรอง (Speckle Filter) เพื่อลดสัญญาณรบกวน ในการวิจัยครั้งนี้ได้ใช้ตัวกรองแบบ Lee Sigma ขนาด 7×7 โดยกำหนดค่า Sigma = 09 และ ค่า target = 3×3

หลังจากนั้นทำการปรับแก้ความคลาดเคลื่อนที่เกิดจากภูมิประเทศและความคลาดเคลื่อนที่เกิดจากมุมมองการถ่ายภาพระบบ SAR (Terrain Corrections) โดยใช้ข้อมูลความสูงเชิงเลข (DEM) SRTM (Shuttle Radar Topography Mission) ความละเอียดจุดภาพประมาณ 30 เมตร และปรับแก้ระบบพิกัดจาก Radar Coordinate เป็น WGS84/UTM Zone 47N เพื่อใช้ร่วมกับข้อมูลสารสนเทศภูมิศาสตร์

เมื่อปรับแก้เสร็จเรียบร้อยแล้ว จึงทำการ Coregistration โดยอาศัยค่า Precise Orbit เพื่อปรับตำแหน่งในแต่ละจุดภาพระหว่างภาพทั้ง 28 ภาพ เพื่อเวลาลดค่าความเคลื่อนที่เกิดจากเรขาคณิตของภาพ และให้ตำแหน่งทั้ง 28 ภาพ คลาดเคลื่อนเชิงพิกัดให้น้อยที่สุด โดยกำหนดจุด GCP (Ground Control Point) จำนวน 2,000 จุด และใช้การประมาณค่าช่วงด้วยวิธี Cubic Convolution จากนั้นทำการแปลงค่าจาก Sigma Naught (Backscatter) เป็น dB ด้วยวิธี Linear to dB (Filipponi, 2019)



ภาพประกอบ 15 ขั้นตอนการเตรียมข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1

ที่มา : (Filipponi, 2019)


3.2 การเตรียมข้อมูล (Preparation Data)

การสร้างข้อมูลเพื่อใช้ในการดำเนินการวิจัยในการตอบวัตถุประสงค์ทั้ง 3 ข้อ ดำเนินการสร้างจากข้อมูลการเพาะปลูกข้าวนาปี ปี พ.ศ.2565/66 จากสำนักงานเศรษฐกิจการเกษตรและข้อมูล

การใช้ประโยชน์ที่ดิน ปีพ.ศ.2564 จากกรมพัฒนาที่ดิน นำมาสร้างข้อมูลตัวอย่างเพื่อใช้ในการแบบจำลอง โดยแบ่งข้อมูลออกเป็น 2 กลุ่ม ประกอบไปด้วย

3.2.1 เพื่อใช้ในการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องในการจำแนกข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR (วัตถุประสงค์ข้อที่ 1 และ 2) ในการเก็บรวบรวมข้อมูลตัวอย่างอ้างอิงภาคพื้นดินเพื่อใช้ในการสร้างและประเมินแบบจำลอง ผู้วิจัยได้ประยุกต์ใช้เทคนิค การสุ่มตัวอย่างแบบแบ่งชั้น (Stratified Sampling) เป็นวิธีการที่เหมาะสมอย่างยิ่งสำหรับการจำแนกประเภทการใช้ประโยชน์ที่ดิน โดยเริ่มต้นจากการแบ่งพื้นที่ศึกษาทั้งหมดออกเป็น 4 ชั้นภูมิ (Strata) ตามประเภทการใช้ประโยชน์ที่ดินหลักที่สนใจ ได้แก่ พื้นที่ปลูกข้าว, พื้นที่เมืองและพื้นที่อื่นๆ, พื้นที่แหล่งน้ำ, และพื้นที่เกษตรกรรม จากนั้นจึงทำการสุ่มเก็บข้อมูลตัวอย่างตามจำนวนที่ต้องการจากภายในแต่ละชั้นภูมิ โดยแบ่งออกเป็น (ภาพประกอบ 16)

- พื้นที่ปลูกข้าว จำนวน 2,698 จุด (จุดสีแดง)
- พื้นที่เมืองและพื้นที่อื่นๆ จำนวน 1,741 จุด (จุดสีเทา)
- พื้นที่แหล่งน้ำ จำนวน 1,000 จุด (จุดสีน้ำเงิน)
- พื้นที่เกษตรกรรม จำนวน 1,501 จุด (จุดสีเขียว)




ภาพประกอบ 16 การกระจายเชิงพื้นที่ของจุดข้อมูล

3.2.2 เพื่อใช้ในการศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR (วัตถุประสงค์ข้อที่ 3) โดยแบ่งออกเป็น (ภาพประกอบ 17)


- พื้นที่ปลูกข้าวที่เริ่มปลูกในเดือนพฤษภาคม จำนวน 765 แปลง (แปลงสีน้ำเงิน)
- พื้นที่ปลูกข้าวที่เริ่มปลูกในเดือนมิถุนายน จำนวน 628 แปลง (แปลงสีฟ้า)
- พื้นที่ปลูกข้าวที่เริ่มปลูกในเดือนกรกฎาคม จำนวน 645 แปลง (แปลงสีส้ม)

- พื้นที่ปลูกข้าวที่เริ่มปลูกในเดือนสิงหาคม จำนวน 660 จุด (แปลงสีแดง)




ภาพประกอบ 17 ข้อมูลพื้นที่ปลูกข้าวจำแนกตามช่วงระยะเวลาเริ่มปลูก

เมื่อทำการสร้างข้อมูลตัวอย่างเสร็จเรียบร้อยแล้ว ผู้วิจัยจะแบ่งข้อมูลดังข้อ 3.2.1 และ 3.2.2 ออกเป็น 3 ชุดประกอบไปด้วย ชุดข้อมูลสำหรับการฝึก (Training Data) จำนวน 60% ของข้อมูลทั้งหมด ข้อมูลสำหรับปรับแก้แบบจำลอง (Validation Data) จำนวน 20% ของข้อมูลทั้งหมด และข้อมูลสำหรับการทดสอบ (Test Data) จำนวน 20% โดยมีรูปแบบการกระจายของสัญญาณเฉลี่ยในแต่ละเดือน ดังภาพประกอบ 18 โดยการดำเนินงานตามวัตถุประสงค์ที่ได้ตั้งไว้ภาพรวมในการดำเนินการดังภาพประกอบ 19




(ก)



(ข)

— Rice — Agriculture & Forest — Urban — Water

ภาพประกอบ 18 รูปแบบการกระเจิงของสัญญาณเฉลี่ยในแต่ละเดือนจำแนกตามการใช้ประโยชน์ที่ดิน โดย (ก) แสดงโพลาไรเซชัน VH และ (ข) โพลาไรเซชัน VV



ภาพประกอบ 19 ขั้นตอนการดำเนินการวิจัย

3.3 การเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

ขั้นตอนนี้มุ่งเน้นการประเมินประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการจำแนกพื้นที่ปลูกข้าว โดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายดาวเทียม Sentinel-1 และข้อมูลค่าเฉลี่ยรายเดือนอนุกรมเวลาภาพถ่ายดาวเทียม Sentinel-1 ดำเนินการดังรายละเอียดต่อไปนี้ (ขั้นตอนการดำเนินงานแสดงดังภาพประกอบ 20)

3.3.1 การเลือกแบบจำลอง ในการวิจัยนี้ ผู้วิจัยเลือกแบบจำลองการเรียนรู้ของเครื่อง 4 แบบจำลองสำหรับการทดลองเปรียบเทียบ ประกอบไปด้วย Random Forest (RF), Support Vector Machine (SVM), XGBoost และ Artificial Neural Network (ANN)

3.3.2 การฝึกสอนเบื้องต้น นำข้อมูลสำหรับการฝึกสอน (Training Data) มาใช้ในการฝึกสอนแบบจำลองทั้ง 4 วิธีที่เลือกไว้

3.3.3 การปรับจูนไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) หลังจากการฝึกสอนเบื้องต้น จะนำข้อมูลสำหรับปรับแก้/ตรวจสอบ (Validation Data) มาใช้ในกระบวนการปรับจูนไฮเปอร์พารามิเตอร์ของแต่ละแบบจำลอง โดยใช้เทคนิค Grid Search เพื่อหาชุดพารามิเตอร์ที่ให้ประสิทธิภาพสูงสุด โดยมีการตั้งค่าปรับจูนพารามิเตอร์ ดังนี้

Support Vector Machine (SVM) ประกอบไปด้วย

- ค่า Regularization (C) ที่ใช้ควบคุมความยืดหยุ่นของแบบจำลอง โดยตั้งช่วงค่าทดสอบตั้งแต่ 1 – 1,000
- ค่าสัมประสิทธิ์ของเคอร์เนล (gamma) ใช้กำหนดขอบเขตอิทธิพลของข้อมูลแต่ละตัว โดยมีค่าทดสอบ 1, 0.1, 0.01, 0.001, 0.0001
- ประเภทของเคอร์เนลกำหนดเป็น Radial Basis Function (RBF)

Random Forest (RF) ประกอบไปด้วย

- จำนวนต้นไม้ (n_estimators) ตั้งช่วงค่าทดสอบตั้งแต่ 1 – 100
- ความลึกสูงสุดของแต่ละต้นไม้ (max_depth) ตั้งช่วงค่าทดสอบตั้งแต่ 1 – 100
- จำนวนตัวอย่างข้อมูลขั้นต่ำ (min_samples_split) ตั้งช่วงค่าทดสอบตั้งแต่ 1 – 10

XGBoost


- จำนวนต้นไม้ (n_estimators) ตั้งช่วงค่าทดสอบตั้งแต่ 1 – 100
- ความลึกสูงสุดของแต่ละต้นไม้ (max_depth) ตั้งช่วงค่าทดสอบตั้งแต่ 1 – 100
- อัตราการเรียนรู้ (learning_rate) ช่วยควบคุมไม่ให้แบบจำลอง Overfitting ตัว โดยมีค่าทดสอบ 0.1, 0.01, 0.001

Artificial Neural Network (ANN)

- จำนวนเซลล์ประสาท (hidden_layer_sizes) ในชั้นซ่อน (Hidden Layer) ตั้งช่วงค่าทดสอบตั้งแต่ 1 – 1000
 - ฟังก์ชันกระตุ้น (activation) มีค่าทดสอบเป็น 'tanh' และ 'relu'
 - อัตราการเรียนรู้ (learning_rate) มีค่าทดสอบ 0.1, 0.01, 0.001
- กระบวนการนี้จะดำเนินการวนซ้ำ โดยมีเป้าหมายหลักคือการหาชุดไฮเปอร์พารามิเตอร์ที่ให้ค่าความถูกต้องโดยรวมสูงสุดบนชุดข้อมูล Validation

3.3.4 การประเมินประสิทธิภาพขั้นสุดท้าย (Final Performance Evaluation)

- **การประเมินด้วยข้อมูลทดสอบ** เมื่อได้แบบจำลองการเรียนรู้ของเครื่องจักรแต่ละวิธีที่ผ่านการฝึกสอนและปรับจูนด้วยค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุด จึงนำชุดข้อมูลสำหรับการทดสอบ (Test Data) เป็นข้อมูลที่ไม่เคยถูกใช้ในการฝึกสอนหรือปรับจูนเลย มาใช้ในการประเมินประสิทธิภาพขั้นสุดท้ายของแบบจำลอง
- **การสร้าง Confusion Matrix** ผลการจำแนกที่ได้จากการประเมินบนชุดข้อมูลทดสอบจะถูกนำมาสร้างเป็น Confusion Matrix เพื่อแสดงผลการจำแนกแต่ละประเภทอย่างละเอียด
- **การคำนวณค่าสถิติประสิทธิภาพ** จาก Confusion Matrix จะทำการคำนวณค่าทางสถิติเพื่อเปรียบเทียบประสิทธิภาพระหว่างวิธีการต่างๆ ประกอบไปด้วย
 - **ค่าความถูกต้องโดยรวม** สัดส่วนของจำนวนข้อมูลที่จำแนกได้ถูกต้องทั้งหมด
 - **ค่าสัมประสิทธิ์แคปปา (Kappa Coefficient)** มาตราวัดความสอดคล้องระหว่างการจำแนกของโมเดลกับการจำแนกจริง โดยพิจารณาโอกาสที่การสอดคล้องนั้นเกิดจากการสุ่ม
 - **ค่า F1-Score** ค่าเฉลี่ยแบบฮาร์โมนิกของ Precision และ Recall สำหรับแต่ละประเภทข้อมูล โดยเน้นที่ประสิทธิภาพการจำแนกพื้นที่ปลูกข้าวเป็นหลัก



ภาพประกอบ 20 ขั้นตอนการเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

3.4 การเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

ขั้นตอนนี้มุ่งเน้นการประเมินและเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทเทียมที่แตกต่างกัน เพื่อจำแนกพื้นที่ปลูกข้าวในพื้นที่ศึกษา โดยใช้ชุดข้อมูลและประเภทการจำแนกเดียวกันกับที่ใช้ในการประเมินวิธีการเรียนรู้ของเครื่อง (ตามที่อธิบายในหัวข้อ 3.3) เพื่อให้ผลการเปรียบเทียบมีความสอดคล้องและน่าเชื่อถือ โดยดำเนินการดังรายละเอียดต่อไปนี้ (ขั้นตอนการดำเนินงานแสดงดังภาพประกอบ 21)

3.4.1 การเลือกโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึก ผู้วิจัยได้เลือกโครงข่ายประสาทเทียมที่ได้รับความนิยมและเหมาะสมกับการประมวลผลข้อมูลอนุกรมเวลาจำนวน 4 รูปแบบ เพื่อนำมาฝึกสอนและเปรียบเทียบ ประกอบไปด้วย Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM) และ Bidirectional Long-Short Term Memory (Bi-LSTM)

3.4.2 การฝึกสอนเบื้องต้น สำหรับแต่ละโครงข่ายประสาทเทียมที่เลือก จะทำการฝึกสอนแบบจำลองด้วยชุดข้อมูลสำหรับการฝึกสอน (Training Data)

3.4.3 การปรับจูนไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) หลังจากการฝึกสอนเบื้องต้น จะนำข้อมูลสำหรับปรับแก้/ตรวจสอบ (Validation Data) มาใช้ในกระบวนการปรับจูนไฮเปอร์พารามิเตอร์เพื่อหาชุดค่าที่เหมาะสมที่สุดสำหรับแต่ละโครงข่ายประสาทเทียม ตัวอย่างไฮเปอร์พารามิเตอร์ที่ปรับจูน ประกอบไปด้วย จำนวนชั้น (Number of layers), จำนวนหน่วยความจำในแต่ละชั้น (Number of hidden units), อัตราการเรียนรู้ (Learning rate), ขนาดแบตช์ (Batch size), จำนวนรอบการฝึก (Number of epochs), ตัวปรับปรุงแบบจำลอง (Optimizer) และอัตราการตัดออก (Dropout rate)

กระบวนการนี้มีเป้าหมายหลักเพื่อหาชุดไฮเปอร์พารามิเตอร์ที่ให้ค่าความถูกต้องโดยรวมสูงสุดบนชุดข้อมูล Validation และใช้เทคนิค Early Stopping เป็นเทคนิคที่หยุดการฝึกโมเดลเมื่อประสิทธิภาพบนชุด Validation ไม่มีการพัฒนาหรือเริ่มลดลง เพื่อป้องกัน Overfitting ประหยัดเวลาและป้องกันการเรียนรู้เกินร่วมด้วย


3.4.4 การประเมินประสิทธิภาพขั้นสุดท้าย (Final Performance Evaluation)

- การประเมินด้วยข้อมูลทดสอบ เมื่อได้แบบจำลองการเรียนรู้เชิงลึกแต่ละรูปแบบที่ผ่านการปรับจูนด้วยค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดแล้ว จึงนำชุดข้อมูลสำหรับการทดสอบ (Test Data) มาใช้ประเมินประสิทธิภาพขั้นสุดท้ายของแบบจำลอง

- การสร้าง Confusion Matrix ผลการจำแนกที่ได้จากการประเมินบนชุดข้อมูลทดสอบจะถูกนำมาสร้างเป็น **Confusion Matrix** เพื่อแสดงผลการจำแนกแต่ละประเภทอย่างละเอียด

- การคำนวณค่าสถิติประสิทธิภาพ จาก Confusion Matrix จะทำการคำนวณค่าทางสถิติเพื่อเปรียบเทียบประสิทธิภาพระหว่างโครงข่ายประสาทเทียมทั้ง 3 รูปแบบ ประกอบไปด้วย ค่าความถูกต้องโดยรวม, ค่าสัมประสิทธิ์แคปปาและค่า F1-Score สำหรับแต่ละประเภทข้อมูล

หลังจากที่ได้อธิบายกระบวนการสำหรับวัตถุประสงค์ข้อที่ 1 และ 2 มุ่งเน้นการเปรียบเทียบและพัฒนาแบบจำลองสำหรับการจำแนกพื้นที่ปลูกข้าวแล้ว ในส่วนต่อไปนี้จะขึ้นขั้นตอนการดำเนินงานตามวัตถุประสงค์ข้อที่ 3 โดยจะนำแบบจำลองและข้อมูลพื้นที่ปลูกข้าวที่มีความแม่นยำมากที่สุดที่ได้จากข้อ 3.3 และ 3.4 มาใช้เป็นข้อมูลพื้นฐานในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าว



ภาพประกอบ 21 ขั้นตอนการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกพื้นที่ปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

3.5 การพัฒนากระบวนการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

ขั้นตอนนี้มุ่งเน้นการพัฒนากระบวนการเรียนรู้เชิงลึกเพื่อจำแนกช่วงระยะเวลาเริ่มต้นเพาะปลูกข้าว (Planting Period) โดยดำเนินการเฉพาะภายในพื้นที่ที่ถูกจำแนกว่าเป็นพื้นที่ปลูกข้าวเท่านั้น โดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายดาวเทียม Sentinel-1 และข้อมูลค่าเฉลี่ยรายเดือนอนุกรมเวลาภาพถ่ายดาวเทียม Sentinel-1 เป็นข้อมูลหลักในการวิเคราะห์ การดำเนินการแสดงดังรายละเอียดต่อไปนี้ (ขั้นตอนการดำเนินงานแสดงดังภาพประกอบ 22)

3.5.1 การเตรียมข้อมูลและกำหนดประเภทการจำแนก ดำเนินการนำแปลงข้าวที่ผ่านการจำแนกพื้นที่ปลูกข้าวแล้วคำนวณค่าสถิติเชิงพื้นที่ (Zonal Statistics) โดยทำการคำนวณค่าเฉลี่ย (Mean) ของสัญญาณ Backscatter ในแปลงในทุกช่วงเวลา และดำเนินการจำแนกออกเป็น 4 ประเภทตามเดือนที่เริ่มเพาะปลูก โดยอ้างอิงจากข้อมูลการเพาะปลูกข้าวนาปี พ.ศ. 2565 ดังนี้ 1)

เริ่มปลูกเดือนพฤษภาคม 2) เริ่มปลูกเดือนมิถุนายน 3) เริ่มปลูกเดือนกรกฎาคม และ 4) เริ่มปลูกเดือนสิงหาคม


3.5.2 การเลือกโครงข่ายประสาทเทียมของเรียนรู้เชิงลึก ผู้วิจัยได้ทำการเลือกโครงข่ายประสาทเทียมที่ได้รับความนิยมและเหมาะสมกับการประมวลผลข้อมูลอนุกรมเวลาจำนวน 4 รูปแบบ เพื่อนำมาฝึกสอน เปรียบเทียบ และประเมินประสิทธิภาพ ประกอบไปด้วย Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), Long Short-Term Memory (LSTM) และ Bidirectional Long-Short Term Memory (Bi-LSTM)

3.5.3 การฝึกสอนแบบจำลอง ทำการฝึกสอนแบบจำลองแต่ละรูปแบบด้วยชุดข้อมูลสำหรับการฝึกสอน (Training Data) ที่เตรียมไว้ในขั้นตอนก่อนหน้านี้

3.5.4 การปรับจูนไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) เมื่อทำการฝึกสอนแบบจำลองแต่ละรูปแบบด้วย Training Data เรียบร้อยแล้ว จะนำ Validation Data มาใช้ในกระบวนการปรับจูนไฮเปอร์พารามิเตอร์ เพื่อค้นหาชุดค่าที่ให้ประสิทธิภาพดีที่สุดสำหรับแต่ละโครงข่ายประสาทเทียม ตัวอย่างไฮเปอร์พารามิเตอร์ที่ปรับ ได้แก่ จำนวนชั้น (Number of layers), จำนวนหน่วยความจำในแต่ละชั้น (Number of hidden units), อัตราการเรียนรู้ (Learning rate), ขนาด Batch (Batch size), จำนวนรอบการฝึก (Number of epochs), ตัวปรับปรุงแบบจำลอง (Optimizer), อัตราการตัดออก (Dropout rate) เป็นต้น โดยมีเป้าหมายเพื่อหาชุดค่าที่ให้ประสิทธิภาพความถูกต้องโดยรวมสูงสุดบนชุดข้อมูล Validation และอาจใช้เทคนิค Early Stopping ร่วมด้วยเพื่อป้องกันภาวะเรียนรู้เกิน

3.5.5 การประเมินและเปรียบเทียบประสิทธิภาพขั้นสุดท้าย (Final Performance Evaluation and Comparison)

- **การประเมินด้วยข้อมูลทดสอบ** เมื่อได้แบบจำลองการเรียนรู้เชิงลึกแต่ละรูปแบบที่ผ่านการปรับจูนด้วยค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดแล้ว จึงนำชุดข้อมูลสำหรับการทดสอบ (Test Data) มาใช้ประเมินประสิทธิภาพขั้นสุดท้าย
- **การสร้าง Confusion Matrix** ผลการจำแนกจะถูกนำมาสร้างเป็น Confusion Matrix เพื่อแสดงผลการจำแนกแต่ละประเภท (เดือนที่เริ่มปลูก) อย่างละเอียด
- **การคำนวณค่าสถิติประสิทธิภาพ** ทำการประเมินและเปรียบเทียบประสิทธิภาพในการจำแนกช่วงระยะเวลาเริ่มเพาะปลูกระหว่างแต่ละโครงข่ายประสาทเทียม โดยการคำนวณค่าทางสถิติที่สำคัญ ได้แก่ ความถูกต้องโดยรวม, สัมประสิทธิ์แคปปาและ F1-Score สำหรับแต่ละคลาส (แต่ละเดือนที่เริ่มปลูก)



ภาพประกอบ 22 ขั้นตอนการพัฒนากระบวนการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการ
เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR

บทที่ 4

ผลการดำเนินการวิจัย

บทที่ 4 แสดงผลการศึกษาจากการดำเนินงานวิจัยทั้ง 3 วัตถุประสงค์ประกอบด้วยการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องในการจำแนกข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR การเรียนรู้เชิงลึกในการสกัดพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR และการศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR โดยแสดงการศึกษาดังนี้

4.1 ผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้ของเครื่อง

จากผลการวิเคราะห์วิธีการดำเนินการวิจัยเพื่อประเมินประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องจำนวน 4 วิธี ได้แก่ Support Vector Machine (SVM), Random Forest (RF), XGBoost (XGB), และ Artificial Neural Network (ANN) สำหรับการจำแนกพื้นที่ปลูกข้าวนาปี ในพื้นที่ศึกษาอำเภอเมือง จังหวัดสุพรรณบุรี โดยใช้ข้อมูลอนุกรมเวลา SAR จากดาวเทียม Sentinel-1 ที่ครอบคลุมปี พ.ศ. 2565 การทดสอบได้แบ่งออกตาม รูปแบบข้อมูลนำเข้า (Input Data Configurations) ที่แตกต่างกัน 6 รูปแบบ เพื่อเปรียบเทียบผลกระทบของโพลาริเซชันและลักษณะข้อมูลอนุกรมเวลา ดังนี้

- ข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VH (จำนวน 28 ภาพ/ช่วงเวลา)
- ข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VV (จำนวน 28 ภาพ/ช่วงเวลา)
- ข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VH และ VV
- ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH (จำนวน 12 ภาพ/ช่วงเวลา)
- ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV (จำนวน 12 ภาพ/ช่วงเวลา)
- ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH และ VV ร่วมกัน

สำหรับแต่ละแบบจำลองการเรียนรู้ของเครื่องและแต่ละรูปแบบข้อมูลนำเข้า ได้ดำเนินการปรับแก้ไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) ด้วยวิธี Bayesian Optimization โดยใช้ชุดข้อมูลตรวจสอบ (Validation Set) เพื่อหาชุดพารามิเตอร์ที่ให้ประสิทธิภาพการจำแนกสูงสุด ค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดสำหรับแต่ละกรณี แสดงผลในตาราง 4 (สำหรับข้อมูลอนุกรมเวลา) และตาราง 5 (สำหรับข้อมูลค่าเฉลี่ยรายเดือน) ผลลัพธ์เชิงพื้นที่ในรูปแบบของแผนที่จำแนกพื้นที่ปลูกข้าวที่ได้จากแบบจำลองการเรียนรู้ของเครื่อง แสดงในภาพประกอบ 23 และ 24

ตาราง 4 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพอนุกรมเวลา SAR

โพลาไรเซชัน	แบบจำลอง	ไฮเปอร์พารามิเตอร์	ค่าที่ดีที่สุด
VH	SVM	C	10
		Gamma	0.01
		N estimators	1000
	RF	Max depth	100
		Min samples split	2
		Learning rate	0.095
	XGB	Max depth	15
		Min child weight	10
		Hidden layer sizes	200
	ANN	Activation	tanh
		learning_rate	0.0001
VV	SVM	C	9.032
		Gamma	001
		N estimators	447
	RF	Max depth	32
		Min samples split	2
		Learning rate	0.333
	XGB	Max depth	14
		Min child weight	9
		Hidden layer sizes	200
	ANN	Activation	tanh
		learning_rate	0.01
VH+VV	SVM	C	10.0
		Gamma	0.01
		N estimators	1000
	RF	Max depth	85
		Min samples split	2
		Learning rate	0.291
	XGB	Max depth	5
		Min child weight	1
		Hidden layer sizes	200
	ANN	Activation	0.007
		learning_rate	tanh

จากตาราง 3 นำเสนอผลลัพธ์ของกระบวนการปรับจูนไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) ด้วยวิธี Bayesian Optimization สำหรับแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) ทั้ง 4 วิธี ได้แก่ Support Vector Machine (SVM), Random Forest (RF), XGBoost (XGB), และ Artificial Neural Network (ANN) โดยใช้ข้อมูลอนุกรมเวลา SAR จากดาวเทียม Sentinel-1 (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางนี้ได้แสดงค่าไฮเปอร์พารามิเตอร์ที่ให้ประสิทธิภาพดีที่สุดสำหรับข้อมูลนำเข้า 3 รูปแบบตามโพลาริเซชันคือ การใช้เฉพาะโพลาริเซชัน VH , การใช้เฉพาะโพลาริเซชัน VV , และการใช้ทั้งโพลาริเซชัน VH และ VV ร่วมกัน

ผลการศึกษาพบว่าค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดมีความแตกต่างกันไปขึ้นอยู่กับทั้งแบบจำลองและข้อมูลโพลาริเซชันที่ใช้ อาทิ แบบจำลอง SVM มีการปรับค่า C และ Gamma; สำหรับแบบจำลอง RF มีการปรับจำนวนต้นไม้ (N estimators), ความลึกสูงสุด (Max depth), และจำนวนตัวอย่างน้อยสุดในการแบ่งโหนด (Min samples split) ; สำหรับแบบจำลอง XGBoost มีการปรับอัตราการเรียนรู้ (Learning rate), ความลึกสูงสุด (Max depth), และ Min child weight ; และสำหรับ ANN มีการปรับขนาดของชั้นซ่อน (Hidden layer sizes), ฟังก์ชันกระตุ้น (Activation), และค่า Alpha (regularization) จะเห็นได้ว่าค่าที่เหมาะสมที่สุดของพารามิเตอร์ส่วนใหญ่ เช่น ค่า N estimators ของแบบจำลอง RF, ค่า Learning rate ของแบบจำลอง XGBoost, หรือค่าพารามิเตอร์ C ของแบบจำลอง SVM มีค่าแตกต่างกันอย่างชัดเจนเมื่อใช้ข้อมูลนำเข้าคนละรูปแบบ (VH, VV, หรือ VH+VV) แสดงให้เห็นถึงความสำคัญของการปรับจูนไฮเปอร์พารามิเตอร์แยกกันสำหรับแต่ละกรณี อย่างไรก็ตาม บางพารามิเตอร์ เช่น Activation function ของ ANN (tanh) อาจให้ผลลัพธ์ที่ดีที่สุดเหมือนกันในทุกกรณี ค่าไฮเปอร์พารามิเตอร์ที่แสดงในตารางนี้ คือค่าที่ถูกนำไปใช้ในการสร้างแบบจำลองขั้นสุดท้ายเพื่อประเมินประสิทธิภาพด้วยชุดข้อมูลทดสอบต่อไป

ตาราง 5 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพค่าเฉลี่ย SAR รายเดือน

โพลาไรเซชัน	แบบจำลอง	ไฮเปอร์พารามิเตอร์	ค่าที่ดีที่สุด
VH	SVM	C	6.084
		Gamma	0.011
		N estimators	1,000
	RF	Max depth	58
		Min samples split	2
		Learning rate	01
	XGB	Max depth	9
		Min child weight	1
		Hidden layer sizes	200
	ANN	Activation learning_rate	Tanh 0.01
VV	SVM	C	5.8904
		Gamma	001
		N estimators	261
	RF	Max depth	28
		Min samples split	2
		Learning rate	06
	XGB	Max depth	13
		Min child weight	1
		Hidden layer sizes	100
	ANN	Activation learning_rate	Tanh 0.01
VH+VV	SVM	C	7.535
		Gamma	0.01
		N estimators	1,000
	RF	Max depth	49
		Min samples split	2
		Learning rate	0.47
	XGB	Max depth	20
		Min child weight	1
		Hidden layer sizes	200
	ANN	Activation learning_rate	Tanh 0.009

จากตาราง 5 แสดงผลลัพธ์ของกระบวนการปรับจูนไฮเปอร์พารามิเตอร์ด้วยวิธี Bayesian Optimization สำหรับแบบจำลองการเรียนรู้ของเครื่อง (SVM, RF, XGB, ANN) โดยในกรณีนี้ใช้ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน (12 ช่วงเวลา) เป็นข้อมูลนำเข้า แตกต่างจากตาราง 3 ที่ใช้ข้อมูลอนุกรมเวลาแบบเต็ม โครงสร้างของตารางยังคงเดิม คือแสดงค่าไฮเปอร์พารามิเตอร์ที่ให้ประสิทธิภาพดีที่สุดสำหรับแบบจำลองแต่ละชนิด ภายใต้ข้อมูลนำเข้า 3 รูปแบบตามโพลาริเซชัน (VH, VV, และ VH+VV)

ข้อสังเกตที่สำคัญจากการเปรียบเทียบค่าในตารางนี้กับตาราง 4 คือ ค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดสำหรับข้อมูลค่าเฉลี่ยรายเดือนนั้น มีความแตกต่างอย่างชัดเจน กับค่าที่ได้จากข้อมูลอนุกรมเวลาแบบเต็มในหลายๆ กรณี ตัวอย่างเช่น ค่า C ของ SVM, จำนวน N estimators และ Max depth ของ RF (โดยเฉพาะสำหรับ VV), ค่า Learning rate ของ XGBoost, และขนาด Hidden layer sizes ของ ANN (โดยเฉพาะสำหรับ VV) ล้วนมีการเปลี่ยนแปลง ชี้ให้เห็นว่าการรวมข้อมูลเป็นค่าเฉลี่ยรายเดือนส่งผลต่อลักษณะของข้อมูลที่เป็นแบบจำลองต้องเรียนรู้ ทำให้ค่าพารามิเตอร์ที่เหมาะสมที่สุดเปลี่ยนไป การค้นพบนี้ตอกย้ำความสำคัญของการดำเนินการปรับจูนไฮเปอร์พารามิเตอร์แยกต่างหากสำหรับข้อมูลนำเข้าแต่ละประเภทเพื่อให้ได้ประสิทธิภาพสูงสุด ค่าที่แสดงในตาราง 4 นี้ คือค่าสุดท้ายที่ถูกนำไปใช้ในการกำหนดค่าแบบจำลองการเรียนรู้ของเครื่องเพื่อประเมินประสิทธิภาพเมื่อทำงานกับข้อมูล SAR ค่าเฉลี่ยรายเดือนต่อไป

จากตาราง 6 นำเสนอผลการประเมินประสิทธิภาพเชิงลึกของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสหลัก ประกอบไปด้วย พื้นที่ปลูกข้าว (Rice) พื้นที่แหล่งน้ำ (Water) พื้นที่เกษตรกรรม (Agriculture) และพื้นที่เมืองและพื้นที่อื่นๆ (Urban/Other) โดยใช้แบบจำลองการเรียนรู้ของเครื่อง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อข้อมูลนำเข้าเป็น ข้อมูลอนุกรมเวลา SAR ที่ใช้โพลาริเซชัน VH เพียงอย่างเดียว (28 ช่วงเวลา) ตารางแสดงค่า Precision, Recall และ F1-Score สำหรับแต่ละคลาสแยกตามแบบจำลอง พร้อมทั้งค่าความถูกต้องโดยรวมและค่าสัมประสิทธิ์แคปปาของแต่ละแบบจำลอง

จากผลการประเมิน พบว่าแบบจำลองทั้งสี่สามารถจำแนกพื้นที่ปลูกข้าว และพื้นที่แหล่งน้ำ ได้ด้วยความแม่นยำสูงมาก โดยค่า Precision, Recall และ F1-Score ส่วนใหญ่อยู่ในระดับที่สูงกว่า 0.96 บ่งชี้ว่าลักษณะเฉพาะของสองคลาสนี้ในข้อมูลอนุกรมเวลา VH มีความชัดเจนเพียงพอสำหรับแบบจำลองส่วนใหญ่ในการเรียนรู้และจำแนกได้อย่างถูกต้อง อย่างไรก็ตาม สำหรับพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่อื่นๆ มีความท้าทายในการจำแนกมากกว่า โดยพื้นที่ปลูกข้าว มีค่า F1-Score อยู่ระหว่าง 0.72 (SVM) ถึง 0.78 (RF) และคลาสนี้พื้นที่เมืองและพื้นที่อื่นๆ มีค่า F1-Score อยู่ระหว่าง 0.65 (ANN) ถึง 0.76 (RF) ต่ำกว่าสองคลาสรแรกอย่างเห็นได้ชัด โดยเฉพาะอย่าง

ยั้งแบบจำลอง ANN แสดงค่า Precision ที่ต่ำมากสำหรับพื้นที่เมืองและพื้นที่อื่นๆ (0.53) แม้จะมีค่า Recall ที่สูง (0.85) ก็ตาม

ตาราง 6 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
SVM	Agriculture	0.80	0.66	0.72	84.89%	0.79	0.02
	Rice	0.97	0.97	0.97			1,536.45
	Urban/Other	0.64	0.78	0.70			0.01
	Water	0.98	0.97	0.97			
RF	Agriculture	0.82	0.78	0.78	88.11%	0.83	495
	Rice	0.97	0.96	0.97			818
	Urban/Other	0.71	0.81	0.76			199
	Water	0.98	0.98	0.98			25
XGBoost	Agriculture	0.80	0.71	0.76	87.46%	0.82	567
	Rice	0.97	0.97	0.97			770
	Urban/Other	0.71	0.79	0.75			174
	Water	0.98	0.97	0.97			26
ANN	Agriculture	0.90	0.61	0.73	84.58%	0.78	453
	Rice	0.97	0.97	0.97			1054
	Urban/Other	0.53	0.85	0.65			16
	Water	0.94	0.98	0.96			14

เมื่อพิจารณาประสิทธิภาพโดยรวมของแบบจำลองสำหรับข้อมูลนำเข้า VH นี้ พบว่า Random Forest (RF) ให้ค่าความถูกต้องโดยรวม (OA) สูงที่สุดที่ 88.11% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.83 ตามมาด้วย XGBoost (OA 87.46%, KC 0.82) ส่วน SVM (OA 84.89%, KC 0.79) และ ANN (OA 84.58%, KC 0.78) ให้ประสิทธิภาพโดยรวมที่รองลงมา ผลลัพธ์นี้แสดงให้เห็นว่า RF เป็นแบบจำลองที่ทำงานได้ดีที่สุดเมื่อใช้ข้อมูลอนุกรมเวลาโพลาริเซชัน VH เพียงอย่างเดียวในการจำแนกพื้นที่ปลูกข้าวและประเภทการใช้ที่ดินอื่นๆ ในการศึกษา

ตาราง 7 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
SVM	Agriculture	0.78	0.81	0.79	85.95%	0.80	318
	Rice	0.98	0.86	0.91			1118
	Urban/Other	0.80	0.83	0.82			99
	Water	0.75	1.00	0.86			1
RF	Agriculture	0.85	0.76	0.80	89.27%	0.85	516
	Rice	0.97	0.92	0.94			935
	Urban/Other	0.74	0.91	0.82			63
	Water	0.98	0.99	0.98			23
XGBoost	Agriculture	0.85	0.76	0.80	90.20%	0.86	580
	Rice	0.96	0.96	0.96			823
	Urban/Other	0.80	0.87	0.83			111
	Water	0.98	1.00	0.99			22
ANN	Agriculture	0.68	0.77	0.72	87.54%	0.83	580
	Rice	0.95	0.98	0.96			823
	Urban/Other	0.86	0.74	0.79			111
	Water	0.98	0.99	0.98			22

ตาราง 7 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาส ด้วยแบบจำลองการเรียนรู้ของเครื่อง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่ใช้โพลาริเซชัน VV เพียงอย่างเดียว (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินเมื่อใช้ข้อมูล VV พบว่า คลาส Water ถูกจำแนกได้แม่นยำเป็นพิเศษ โดย RF, XGBoost และ ANN ให้ค่า F1-Score สูงถึง 0.98-0.99 และมีค่า Recall เกือบสมบูรณ์ (0.99-1.00) บ่งชี้ว่าสัญญาณ VV สามารถแยกแยะพื้นที่แหล่งน้ำได้ดีมาก (แม้ SVM จะมี Precision ต่ำกว่า แต่ Recall ยังคงสมบูรณ์) สำหรับคลาสพื้นที่ปลูกข้าว แบบจำลอง XGBoost และ ANN ทำผลงานได้

ดีที่สุดด้วย F1-Score 0.96 ตามมาด้วย RF (F1=0.94) ส่วน SVM มีประสิทธิภาพต่ำกว่าแบบจำลองอื่นในการจำแนกข้าว (F1=0.91) โดยมีค่า Recall ที่ต่ำกว่า (0.86) ส่วนการจำแนกพื้นที่เกษตร และพื้นที่เมืองและอื่นๆ ยังคงมีความซับซ้อน โดย RF และ XGBoost ให้ F1-Score ที่ดีที่สุดสำหรับพื้นที่เกษตร (0.80) ขณะที่ ANN มีประสิทธิภาพต่ำสุด (F1=0.72) สำหรับคลาสนี้ พื้นที่เมืองและอื่นๆ มีค่า F1-Score ค่อนข้างใกล้เคียงกันในทุกแบบจำลอง (0.79-0.83) โดย XGBoost ให้ค่าสูงสุดที่ 0.83

ตาราง 8 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH+VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
SVM	Agriculture	0.94	0.80	0.86	91.79%	0.89	590
	Rice	0.97	0.96	0.97			781
	Urban/Other	0.78	0.94	0.85			145
	Water	0.97	0.98	0.98			20
RF	Agriculture	0.90	0.81	0.85	92.36%	0.89	576
	Rice	0.98	0.96	0.97			869
	Urban/Other	0.80	0.92	0.86			67
	Water	1.00	0.99	0.99			25
XGBoost	Agriculture	0.90	0.83	0.86	93.08%	0.90	642
	Rice	0.98	0.99	0.98			762
	Urban/Other	0.85	0.89	0.87			110
	Water	0.99	0.99	0.9			23
ANN	Agriculture	0.89	0.76	0.82	90.63%	0.87	642
	Rice	0.96	0.98	0.97			762
	Urban/Other	0.80	0.88	0.84			110
	Water	0.96	0.98	0.97			23

เมื่อพิจารณาประสิทธิภาพโดยรวม พบว่า XGBoost ให้ค่าความถูกต้องโดยรวม (OA) สูงที่สุดที่ 90.20% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.86 เป็นค่าที่ดีที่สุดเมื่อเทียบกับทุกแบบจำลองในการทดลองนี้ และสูงกว่าผลที่ได้จากการใช้ข้อมูล VH อย่างเดียว ตามมาด้วย RF (OA 89.27%,

KC 0.85), ANN (OA 87.54%, KC 0.83), และ SVM (OA 85.95%, KC 0.80) ผลลัพธ์นี้ชี้ให้เห็นว่า สำหรับข้อมูลอนุกรมเวลาเต็ม การใช้โพลาริเซชัน VV อาจให้ผลการจำแนกโดยรวมที่ดีกว่า VH เล็กน้อย โดยเฉพาะอย่างยิ่งเมื่อใช้ร่วมกับแบบจำลอง XGBoost

ตาราง 8 นำเสนอผลการประเมินประสิทธิภาพเชิงลึกของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้ของเครื่อง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่รวมข้อมูลทั้งโพลาริเซชัน VH และ VV เข้าด้วยกัน เป็นข้อมูลนำเข้า

ผลการประเมินแสดงให้เห็นว่าการรวมข้อมูลทั้งสองโพลาริเซชันส่งผลให้ประสิทธิภาพการจำแนก ดีขึ้นอย่างมีนัยสำคัญ ในภาพรวม โดยคลาสพื้นที่ปลูกข้าว และพื้นที่แหล่งน้ำ ยังคงถูกจำแนกได้อย่างยอดเยี่ยมด้วยค่า F1-Score ที่สูงมาก (ตั้งแต่ 0.97 ถึง 0.98 สำหรับพื้นที่ปลูกข้าว และ 0.97 ถึง 0.99 สำหรับพื้นที่แหล่งน้ำ) ในทุกแบบจำลอง ซึ่งชี้ให้เห็นถึงความสามารถในการแยกแยะสองคลาสนี้ได้อย่างชัดเจนเมื่อมีข้อมูลครบถ้วน โดยเฉพาะ XGBoost ที่ให้ค่า F1-Score สูงสุดสำหรับทั้งพื้นที่ปลูกข้าว (0.98) และพื้นที่แหล่งน้ำ (0.99)

ที่สำคัญคือ ประสิทธิภาพในการจำแนกคลาสที่ทำหายกว่าอย่างพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่อื่นๆ มีการพัฒนาดีขึ้นอย่างเห็นได้ชัด เมื่อเทียบกับการใช้โพลาริเซชันเดียว ค่า F1-Score สำหรับพื้นที่เกษตรกรรมอยู่ในช่วง 0.82 (ANN) ถึง 0.86 (SVM, XGBoost) และสำหรับพื้นที่เมืองและพื้นที่อื่นๆ อยู่ในช่วง 0.84 (ANN) ถึง 0.87 (XGBoost) แสดงว่าข้อมูลจากทั้งสองโพลาริเซชันช่วยเสริมกันในการแยกแยะลักษณะของคลาสเหล่านี้ได้ดียิ่งขึ้น โดย XGBoost ยังคงให้ประสิทธิภาพสูงสุดสำหรับสองคลาสนี้

เมื่อพิจารณาประสิทธิภาพโดยรวม XGBoost ให้ค่าความถูกต้องโดยรวม (OA) สูงที่สุดถึง 93.08% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.90 เป็นค่าที่ดีที่สุดในการทดลองนี้ ตามมาด้วย RF (OA 92.36%, KC 0.89) และ SVM (OA 91.79%, KC 0.89) ล้วนให้ผลลัพธ์ที่สูงมากเช่นกัน ส่วน ANN (OA 90.63%, KC 0.87) ก็ให้ผลที่ดีแต่ต่ำกว่าเล็กน้อย สรุปได้ว่าการใช้ข้อมูลอนุกรมเวลา SAR ทั้งโพลาริเซชัน VH และ VV ร่วมกันเป็นแนวทางที่ให้ประสิทธิภาพการจำแนกพื้นที่ปลูกข้าวได้ดีที่สุดในการศึกษานี้ โดยมี XGBoost เป็นแบบจำลองที่ให้ผลลัพธ์ที่โดดเด่นที่สุด

ตาราง 9 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
SVM	Agriculture	0.90	0.77	0.83	91.64%	0.88	595
	Rice	0.97	0.98	0.98			776
	Urban/Other	0.78	0.90	0.84			144
	Water	1.00	0.99	1.00			21
RF	Agriculture	0.86	0.76	0.80	90.49%	0.87	556
	Rice	0.98	0.97	0.97			824
	Urban/Other	0.77	0.89	0.83			134
	Water	0.98	0.99	0.98			22
XGBoost	Agriculture	0.88	0.76	0.82	90.92%	0.87	556
	Rice	0.97	0.98	0.97			797
	Urban/Other	0.77	0.88	0.82			163
	Water	1.00	0.99	1.00			20
ANN	Agriculture	0.92	0.62	0.74	85.81%	0.80	691
	Rice	0.97	0.97	0.97			794
	Urban/Other	0.55	0.93	0.69			24
	Water	0.97	0.97	0.97			27

ตาราง 9 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้ของเครื่อง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่ใช้โพลาริเซชัน VH เพียงอย่างเดียว (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสแยกตามแบบจำลอง พร้อมค่าความถูกต้องโดยรวม (OA) และค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

จากผลการประเมิน พบว่าข้อมูลค่าเฉลี่ยรายเดือน VH สามารถใช้จำแนกพื้นที่แหล่งน้ำ ได้อย่างยอดเยี่ยม โดยเฉพาะแบบจำลอง SVM และ XGBoost ที่ให้ค่า F1-Score สูงถึง 1.00 และมีค่า Precision ที่สมบูรณ์แบบ (1.00) ส่วน RF และ ANN ก็ให้ผลดีมากเช่นกัน ($F1 \geq 0.97$) พื้นที่ปลูกข้าวก็ถูกจำแนกได้ด้วยความแม่นยำสูงในทุกแบบจำลอง โดยมีค่า F1-Score อยู่ที่ 0.97-0.98 SVM ให้ค่า

F1 สูงสุดเล็กน้อยที่ 0.98 สำหรับคลาสพื้นที่เกษตรกรรมแบบจำลอง SVM ให้ประสิทธิภาพดีที่สุด (F1=0.83) ตามมาด้วย XGBoost (F1=0.82) และ RF (F1=0.80) ในขณะที่ ANN มีจุดอ่อนที่ค่า Recall ต่ำ (0.62) ทำให้ F1-Score ต่ำที่สุด (0.74) ส่วนพื้นที่เมืองและพื้นที่อื่นๆนั้น SVM ยังคงให้ผลดีที่สุด (F1=0.84) ตามด้วย RF (F1=0.83) และ XGBoost (F1=0.82) แต่ ANN มีประสิทธิภาพต่ำกว่ามาก (F1=0.69) โดยเฉพาะค่า Precision ที่ต่ำเพียง 0.55

ตาราง 10 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพถ่ายดาวเทียม SAR รายเดือน โพลาริเซชัน VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
SVM	Agriculture	0.93	0.74	0.83	91.43%	0.88	624
	Rice	0.96	0.99	0.97			786
	Urban/Other	0.77	0.92	0.84			105
	Water	1.00	0.99	0.99			21
RF	Agriculture	0.85	0.75	0.80	90.20%	0.86	507
	Rice	0.97	0.95	0.96			921
	Urban/Other	0.77	0.90	0.83			86
	Water	1.00	0.99	0.99			22
XGBoost	Agriculture	0.86	0.74	0.80	89.99%	0.86	541
	Rice	0.96	0.97	0.97			872
	Urban/Other	0.77	0.88	0.82			102
	Water	0.99	0.99	0.99			21
ANN	Agriculture	0.94	0.72	0.82	90.63%	0.87	541
	Rice	0.96	0.98	0.97			872
	Urban/Other	0.73	0.95	0.83			102
	Water	0.99	0.99	0.99			21

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลค่าเฉลี่ยรายเดือน VH พบว่า Support Vector Machine (SVM) ให้ค่าความถูกต้องโดยรวม (OA) สูงที่สุดที่ 91.64% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.88 ตามมาด้วย XGBoost (OA 90.92%, KC 0.87) และ RF (OA 90.49%, KC

0.87) ให้ผลลัพธ์ที่ดีมากเช่นกัน ในทางตรงกันข้าม ANN (OA 85.81%, KC 0.80) มีประสิทธิภาพโดยรวมต่ำกว่าแบบจำลองอื่นอย่างชัดเจนเมื่อใช้ข้อมูลรูปแบบนี้ ผลลัพธ์นี้ชี้ว่าข้อมูลค่าเฉลี่ยรายเดือน VH มีประสิทธิภาพสูงในการจำแนก โดยเฉพาะเมื่อใช้กับ SVM สามารถแยกแยะคลาสพื้นที่แหล่งน้ำ และ พื้นที่ปลูกข้าวได้ดีเยี่ยม และยังคงประสิทธิภาพดีในการจำแนกคลาสพื้นที่ปลูกข้าวและพื้นที่เมืองและพื้นที่อื่นๆ

ตาราง 10 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้ของเครื่อง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่ใช้โพลาริเซชัน VV เพียงอย่างเดียว (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

เมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือน VV พบว่า พื้นที่แหล่งน้ำยังคงถูกจำแนกได้อย่างยอดเยี่ยม โดยทุกแบบจำลองให้ค่า F1-Score สูงถึง 0.99 และมีค่า Precision หรือ Recall ที่สูงมาก (SVM และ RF มี Precision 1.00) พื้นที่ปลูกข้าวก็ถูกจำแนกได้แม่นยำสูงมากเช่นกัน ด้วยค่า F1-Score ระหว่าง 0.96 ถึง 0.97 ในทุกแบบจำลอง สำหรับพื้นที่เมืองและพื้นที่อื่นๆประสิทธิภาพการจำแนกถือว่าดี โดยมี F1-Score อยู่ในระดับ 0.82 ถึง 0.84 และมีความสมดุลระหว่าง Precision และ Recall ค่อนข้างดีในทุกแบบจำลอง ส่วนพื้นที่เกษตรกรรมมีค่า F1-Score อยู่ระหว่าง 0.80 ถึง 0.83 โดย SVM ให้ค่า F1 สูงสุดที่ 0.83 ขณะที่ RF และ XGBoost ให้ค่า F1 ที่ 0.80

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลค่าเฉลี่ยรายเดือน VV พบว่า Support Vector Machine (SVM) ให้ค่าความถูกต้องโดยรวม (OA) สูงที่สุดที่ 91.43% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.88 ตามมาด้วย ANN (OA 90.63%, KC 0.87), RF (OA 90.20%, KC 0.86), และ XGBoost (OA 89.99%, KC 0.86) ถือว่าทุกแบบจำลองให้ประสิทธิภาพในระดับสูงและใกล้เคียงกันมากเมื่อใช้ข้อมูลรูปแบบนี้ ผลลัพธ์โดยรวมมีความคล้ายคลึงกับกรณีที่ใช้ข้อมูลค่าเฉลี่ยรายเดือน VH โดยที่ SVM ยังคงให้ประสิทธิภาพสูงสุดเล็กน้อย ชี้ให้เห็นว่าข้อมูลค่าเฉลี่ยรายเดือน ไม่ว่าจะเป็น VH หรือ VV ต่างก็เป็นข้อมูลนำเข้าที่มีประสิทธิภาพสูงสำหรับการจำแนกด้วยแบบจำลองการเรียนรู้ของเครื่องเหล่านี้

ตาราง 11 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
SVM	Agriculture	0.91	0.83	0.87	93.59%	0.91	570
	Rice	0.98	0.98	0.98			797
	Urban/Other	0.84	0.92	0.88			150
	Water	1.00	0.99	0.99			19
RF	Agriculture	0.90	0.83	0.87	93.73%	0.91	558
	Rice	0.98	0.99	0.98			846
	Urban/Other	0.86	0.91	0.88			111
	Water	0.99	1.00	0.99			22
XGBoost	Agriculture	0.90	0.82	0.86	93.23%	0.91	572
	Rice	0.98	0.99	0.99			802
	Urban/Other	0.84	0.89	0.87			142
	Water	1.00	0.99	0.99			21
ANN	Agriculture	0.95	0.74	0.83	91.50%	0.88	697
	Rice	0.97	0.99	0.98			757
	Urban/Other	0.74	0.95	0.84			60
	Water	0.98	0.99	0.98			22

ตาราง 11 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้ของเครื่อง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่รวมข้อมูลทั้งโพลาริเซชัน VH และ VV เข้าด้วยกัน (12 ช่วงเวลา) เป็นข้อมูลนำเข้า

ผลการประเมินจากการใช้ข้อมูลค่าเฉลี่ยรายเดือน VH+VV แสดงให้เห็นถึงประสิทธิภาพการจำแนกที่ ยอดเยี่ยมในทุกคลาสและแทบทุกแบบจำลอง พื้นที่ปลูกข้าวและพื้นที่แหล่งน้ำถูกจำแนกได้ด้วยความแม่นยำสูงสุด โดยมีค่า F1-Score ไม่ต่ำกว่า 0.98 ในทุกแบบจำลองสำหรับพื้นที่ปลูกข้าว(XGBoost ทำได้ถึง 0.99) และ F1-Score 0.98-0.99 สำหรับพื้นที่แหล่งน้ำ (โดย SVM, RF, XGBoost ทำได้ 0.99) นอกจากนี้ ประสิทธิภาพการจำแนกพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่

อื่นๆ ก็อยู่ในระดับที่ดีมาก โดยมี F1-Score สำหรับพื้นที่เกษตรกรรม อยู่ในช่วง 0.83 (ANN) ถึง 0.87 (SVM, RF) และสำหรับพื้นที่เมืองและพื้นที่อื่นๆ อยู่ในช่วง 0.84 (ANN) ถึง 0.88 (SVM, RF) สูงกว่าการใช้ข้อมูลเฉลี่ยรายเดือนแบบโพลาริเซชันเดียวอย่างชัดเจน

เมื่อพิจารณาประสิทธิภาพโดยรวม พบว่าแบบจำลองสามอันดับแรกให้ผลลัพธ์ที่ใกล้เคียงกันมากและสูงเป็นพิเศษ โดย Random Forest (RF) ให้ค่า OA สูงที่สุดเล็กน้อยที่ 93.73% ตามมาด้วย SVM (OA 93.59%) และ XGBoost (OA 93.23%) โดยทั้งสามแบบจำลองนี้ให้ ค่าสัมประสิทธิ์แคปปาสูงถึง 0.91 เท่ากัน ส่วน ANN (OA 91.50%, KC 0.88) ก็ยังให้ผลลัพธ์ที่ดีมากเช่นกัน ผลลัพธ์นี้ชี้ให้เห็นว่า แม้จะเป็นข้อมูลค่าเฉลี่ยรายเดือน แต่การรวมข้อมูลทั้ง VH และ VV เข้าด้วยกันสามารถเพิ่มประสิทธิภาพการจำแนกได้อย่างมาก ทำให้ได้ความแม่นยำโดยรวมในระดับที่สูงใกล้เคียงกับการใช้ข้อมูลอนุกรมเวลาแบบเต็ม โดยมี RF, SVM, และ XGBoost เป็นแบบจำลองที่ทำงานได้ดีเยี่ยมกับข้อมูลรูปแบบนี้




ตาราง 12 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลภาพอนุกรมเวลา SAR


		VH	VV	VH+VV
SVM	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
RF	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
XGBoost	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
ANN	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water

ตาราง 13 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลภาพถ่ายเฉลี่ย SAR รายเดือน


		VH	VV	VH+VV
SVM	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
RF	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
XGBoost	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
ANN	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water




ภาพประกอบ 23 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้ของเครื่องจากข้อมูลภาพ
อนุกรมเวลา SAR




(A) VH (Random Forest)




(B) VV (Random Forest)




(C) VH+VV (Random Forest)




(D) VH (SVM)




(E) VV (SVM)




(F) VH + VV (SVM)




(G) VH (XGBoost)




(H) VV (XGBoost)



(I) VH + VV (XGBoost)



(J) VH (ANN)



(K) VV (ANN)




(L) VH + VV (ANN)

ภาพประกอบ 24 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้ของเครื่องจากข้อมูล
ภาพค่าเฉลี่ย SAR รายเดือน

จากการประเมินประสิทธิภาพความถูกต้องโดยรวมของแบบจำลองการเรียนรู้ของเครื่องทั้ง 4 วิธี (SVM, RF, XGBoost, ANN) เมื่อใช้ข้อมูลนำเข้า SAR ที่แตกต่างกัน 6 รูปแบบ พบว่า การใช้ข้อมูลทั้งโพลาไรเซชัน VH และ VV ร่วมกัน (VH+VV) ให้ประสิทธิภาพการจำแนกโดยรวมสูงสุด ทั้งในกรณีที่ใช้ข้อมูลอนุกรมเวลาแบบเต็ม (28 ช่วงเวลา) และข้อมูลค่าเฉลี่ยรายเดือน (12 ช่วงเวลา) โดยกรณีที่ให้ ค่า OA สูงสุดคือ การใช้ข้อมูลค่าเฉลี่ยรายเดือน VH+VV ร่วมกับแบบจำลอง Random Forest (RF) ได้ค่า OA ถึง 93.73% ตามมาด้วย SVM (93.59%) และ XGBoost (93.23%) ที่ให้ผลใกล้เคียงกันมากสำหรับข้อมูลนำเข้ารูปแบบเดียวกันนี้

เมื่อพิจารณาข้อมูลอนุกรมเวลาแบบเต็ม การใช้ VH+VV ร่วมกับ XGBoost ให้ OA สูงสุดที่ 93.08% ขณะที่การใช้โพลาไรเซชันเดี่ยว (VV หรือ VH) ให้ OA ที่ต่ำกว่า โดย XGBoost ทำได้ดีที่สุดกับ VV (90.20%) และ RF ทำได้ดีที่สุดกับ VH (88.11%) สำหรับข้อมูลค่าเฉลี่ยรายเดือน นอกจากกรณี VH+VV ที่ให้ผลดีเยี่ยมแล้ว การใช้ VH หรือ VV เพียงอย่างเดียวก็ยังให้ผลที่ดีมาก โดย SVM ให้ OA สูงสุดสำหรับทั้ง VH (91.64%) และ VV (91.43%) แสดงให้เห็นว่าข้อมูลค่าเฉลี่ยรายเดือนยังคงรักษาข้อมูลสำคัญไว้ได้ดี โดยรวมแล้ว แบบจำลอง RF, SVM, และ XGBoost แสดงประสิทธิภาพประกอบโดดเด่นและใกล้เคียงกันในหลายกรณี โดยเฉพาะเมื่อใช้ข้อมูล VH+VV ส่วน ANN มักจะให้ประสิทธิภาพประกอบต่ำกว่าเล็กน้อยในการทดลองส่วนใหญ่ ทั้งนี้ ผลการจำแนกเชิงพื้นที่จากกรณีที่ดีที่สุด (ข้อมูลค่าเฉลี่ยรายเดือน VH+VV กับ RF) ได้ถูกนำไปเปรียบเทียบกับข้อมูลการใช้ประโยชน์ที่ดินจากกรมพัฒนาที่ดิน ปี พ.ศ. 2564 ดังแสดงในภาพประกอบ 20



ภาพประกอบ 25 ผลการจำแนกพื้นที่เพาะปลูกข้าวข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV ร่วมกับแบบจำลองด้วยวิธี Random Forest เทียบกับข้อมูลการใช้ประโยชน์ที่ดิน จากกรมพัฒนาที่ดิน ปี พ.ศ.2564

4.2 ผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้เชิงลึก

ในส่วนนี้เป็นการนำเสนอผลการประเมินประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกจำนวน 4 โครงข่ายประสาทเทียม ประกอบไปด้วย Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), Long-Short Term Memory (LSTM), และ Bidirectional Long Short-Term Memory (BI-LSTM) สำหรับการจำแนกพื้นที่ปลูกข้าวนาปี ในพื้นที่ศึกษาอำเภอเมือง จังหวัดสุพรรณบุรี โดยใช้ข้อมูลอนุกรมเวลา SAR จากดาวเทียม Sentinel-1 ที่ครอบคลุมปี พ.ศ. 2565

การทดสอบได้ดำเนินการโดยใช้ รูปแบบข้อมูลนำเข้า (Input Data Configurations) ที่แตกต่างกัน 6 รูปแบบ เช่นเดียวกับการทดสอบแบบจำลองการเรียนรู้ของเครื่อง เพื่อเปรียบเทียบผลกระทบของโพลาริเซชันและลักษณะข้อมูลอนุกรมเวลา ดังนี้

- ข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VH (28 ภาพ/ช่วงเวลา)

- ข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VV (28 ภาพ/ช่วงเวลา)
- ข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VH และ VV ร่วมกัน
- ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH (12 ภาพ/ช่วงเวลา)
- ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV (12 ภาพ/ช่วงเวลา)
- ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH และ VV ร่วมกัน

สำหรับแต่ละโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึก และแต่ละรูปแบบข้อมูลนำเข้า ได้ดำเนินการ ปรับแก้ไฮเปอร์พารามิเตอร์ด้วยวิธี Bayesian Optimization โดยใช้ชุดข้อมูลตรวจสอบ เพื่อหาชุดพารามิเตอร์ที่ให้ประสิทธิภาพการจำแนกสูงสุด ค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดสำหรับแต่ละกรณี แสดงผลใน ตาราง 14 (สำหรับข้อมูลอนุกรมเวลา) และตาราง 15 (สำหรับข้อมูลค่าเฉลี่ยรายเดือน)

ประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก ที่ผ่านการปรับจูนแล้ว ถูกประเมินอย่างละเอียดด้วยชุดข้อมูลทดสอบ (Test Set) โดยใช้เมตริกซ์ความคลาดเคลื่อน (แสดงในตาราง 16 และ 17) และคำนวณค่าทางสถิติ ได้แก่ Precision, Recall, F1-Score สำหรับแต่ละคลาส ค่าความถูกต้องโดยรวมและค่าสัมประสิทธิ์แคปปา ผลการประเมินโดยละเอียด จำแนกตามประเภทข้อมูลนำเข้า ทั้ง 6 รูปแบบ แสดงใน ตาราง 16 ถึงตาราง 21 นอกจากนี้ ผลลัพธ์เชิงพื้นที่ในรูปแบบของแผนที่ จำแนกพื้นที่ปลูกข้าวที่ได้จากแบบจำลองการเรียนรู้เชิงลึกแสดงในภาพประกอบ 21 และ 22

ตาราง 14 สรุปค่าไฮเปอร์พารามิเตอร์ที่สำคัญ เป็นผลจากการปรับจูนแบบจำลองการเรียนรู้เชิงลึกทั้ง 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR แบบเต็ม (28 ช่วงเวลา) เป็นข้อมูลนำเข้า โดยพิจารณาจากโพลาริเซชันที่แตกต่างกัน 3 รูปแบบ (VH, VV, และ VH+VV) ไฮเปอร์พารามิเตอร์ที่แสดงในตารางนี้ประกอบด้วย จำนวนหน่วย (Units) ในชั้น Recurrent และ รอบการฝึกที่ดีที่สุด (Best Epoch) เป็นรอบที่แบบจำลองให้ประสิทธิภาพสูงสุดบนชุดข้อมูลตรวจสอบ (Validation Set) และถูกเลือกนำมาใช้งานจริง

ข้อสังเกตที่น่าสนใจประการแรกจากตารางคือ จำนวน Units ที่ให้ผลดีที่สุดมีค่าเท่ากับ 59 สำหรับทุกโครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) และสำหรับข้อมูลนำเข้าทุกรูปแบบ (VH, VV, VH+VV) ในการทดลองนี้ อาจเป็นค่าที่ถูกกำหนดไว้ หรือเป็นค่าที่ได้จากกระบวนการปรับจูนที่ลู่เข้าสู่จุดเดียวกันอย่างสม่ำเสมอ ในทางตรงกันข้าม Best Epoch หรือจำนวนรอบการฝึกที่เหมาะสมที่สุดนั้น มีความแตกต่างกันอย่างมาก ระหว่างแบบจำลองและข้อมูลนำเข้าแต่ละประเภท คำนี้นสะท้อนถึงความเร็วในการเรียนรู้และลู่เข้าสู่ผลลัพธ์ที่ดีที่สุดที่แตกต่างกัน ตัวอย่างเช่น เมื่อใช้ข้อมูล VV แบบจำลอง RNN ต้องการเพียง 42 epochs ในขณะที่ GRU ต้องการมากถึง 985 epochs หรือเมื่อใช้ข้อมูล VH แบบจำลอง GRU ต้องการ 925 epochs ส่วน BI-LSTM ต้องการ

120 epochs ความแปรผันนี้ชี้ให้เห็นว่าระยะเวลาการฝึกที่เหมาะสมที่สุดขึ้นอยู่กับทั้งความซับซ้อนของโครงข่ายประสาทเทียมและลักษณะเฉพาะของข้อมูลนำเข้าแต่ละประเภท ค่า Units และ Best Epoch ที่แสดงในตารางนี้เป็นส่วนสำคัญของการกำหนดค่าแบบจำลองขั้นสุดท้ายที่นำไปใช้ในการประเมินประสิทธิภาพด้วยชุดข้อมูลทดสอบต่อไป ผลลัพธ์เชิงพื้นที่ในรูปแบบของแผนที่จำแนกพื้นที่ปลูกข้าวที่ได้จากแบบจำลองการเรียนรู้เชิงลึก แสดงในภาพประกอบ 26 และ 27

ตาราง 14 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพอนุกรมเวลา SAR

โพลาริเซชัน	แบบจำลอง	ไฮเปอร์พารามิเตอร์	ค่าที่ใช้
VH	RNN	Units	59
		Best Epoch	497
	GRU	Units	59
		Best Epoch	925
	LSTM	Units	59
		Best Epoch	497
	BI-LSTM	Units	59
		Best Epoch	120
VV	RNN	Units	59
		Best Epoch	42
	GRU	Units	59
		Best Epoch	985
	LSTM	Units	59
		Best Epoch	121
	BI-LSTM	Units	59
		Best Epoch	457
VH+VV	RNN	Units	59
		Best Epoch	247
	GRU	Units	59
		Best Epoch	151
	LSTM	Units	59
		Best Epoch	258
	BI-LSTM	Units	59
		Best Epoch	156

ตาราง 15 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพค่าเฉลี่ย SAR รายเดือน

โพลาริเซชัน	แบบจำลอง	ไฮเปอร์พารามิเตอร์	ค่าที่ใช้
VH	RNN	Units	59
		Best Epoch	978
	GRU	Units	59
		Best Epoch	231
	LSTM	Units	59
		Best Epoch	217
	BI-LSTM	Units	59
		Best Epoch	162
VV	RNN	Units	59
		Best Epoch	50
	GRU	Units	59
		Best Epoch	24
	LSTM	Units	59
		Best Epoch	49
	BI-LSTM	Units	59
		Best Epoch	34
VH+VV	RNN	Units	59
		Best Epoch	313
	GRU	Units	59
		Best Epoch	30
	LSTM	Units	59
		Best Epoch	188
	BI-LSTM	Units	59
		Best Epoch	221

ตาราง 15 สรุปค่าไฮเปอร์พารามิเตอร์ที่สำคัญบางส่วน เป็นผลจากการปรับจูนแบบจำลองการเรียนรู้เชิงลึกทั้ง 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน (12 ช่วงเวลา) เป็นข้อมูลนำเข้า โดยพิจารณาจากโพลาริเซชันที่แตกต่างกัน 3 รูปแบบ (VH, VV, และ VH+VV) ไฮเปอร์พารามิเตอร์ที่แสดงในตารางนี้คือ จำนวนหน่วย (Units)

ในชั้น Recurrent และ รอบการฝึกที่ดีที่สุด (Best Epoch) ที่แบบจำลองให้ประสิทธิภาพสูงสุดบนชุดข้อมูลตรวจสอบ

ผลการปรับจูนยังคงแสดงให้เห็นว่า จำนวน Units ที่เหมาะสมที่สุดมีค่าเท่ากับ 59 สำหรับทุกโครงข่ายประสาทเทียมและทุกรูปแบบข้อมูลนำเข้า เช่นเดียวกับผลที่ได้จากข้อมูลอนุกรมเวลาแบบเต็ม (ตาราง 13) อย่างไรก็ตาม Best Epoch หรือจำนวนรอบการฝึกที่เหมาะสมที่สุดสำหรับข้อมูลค่าเฉลี่ยรายเดือนนี้ มีความแตกต่างอย่างมากทั้งระหว่างแบบจำลองและเมื่อเทียบกับข้อมูลอนุกรมเวลาเต็ม ตัวอย่างเช่น เมื่อใช้ข้อมูล VH ค่า Best Epoch อยู่ในช่วงค่อนข้างกว้างตั้งแต่ 162 (BI-LSTM) ถึง 978 (RNN) แต่เมื่อใช้ข้อมูล VV ทุกแบบจำลองกลับเข้าสู่ผลลัพธ์ที่ดีที่สุดอย่างรวดเร็ว โดยมี Best Epoch อยู่ในช่วงเพียง 24 (GRU) ถึง 50 (RNN) เท่านั้น แตกต่างจากกรณีข้อมูลอนุกรมเวลาเต็มอย่างชัดเจน สำหรับข้อมูล VH+VV ค่า Best Epoch อยู่ในช่วง 30 (GRU) ถึง 313 (RNN) ความแตกต่างเหล่านี้ชี้ให้เห็นว่าลักษณะของข้อมูลนำเข้า (ค่าเฉลี่ยรายเดือนเทียบกับข้อมูลราย ~12 วัน) มีผลต่อความเร็วและระยะเวลาที่เหมาะสมในการฝึกสอนของแต่ละโครงข่ายประสาทเทียมค่า Units และ Best Epoch ที่แสดงในตารางนี้ เป็นค่าที่ใช้กำหนดโครงสร้างแบบจำลองการเรียนรู้เชิงลึกขั้นสุดท้ายสำหรับการประเมินประสิทธิภาพเมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือนต่อไป

ตาราง 16 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่ใช้โพลาไรเซชัน VH เพียงอย่างเดียว (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสแยกตามแบบจำลอง พร้อมค่าความถูกต้องโดยรวม (OA) และค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินแสดงให้เห็นว่าแบบจำลองการเรียนรู้เชิงลึก ทั้งหมดสามารถจำแนกคลาส Rice และ Water ได้อย่างมีประสิทธิภาพ โดยค่า F1-Score สำหรับพื้นที่ปลูกข้าวอยู่ที่ 0.96 อย่างสม่ำเสมอในทุกแบบจำลอง และสำหรับพื้นที่แหล่งน้ำอยู่ในระดับสูงมากที่ 0.97-0.98 โดย RNN และ LSTM สามารถทำ Precision ได้ถึง 1.00 สำหรับพื้นที่แหล่งน้ำ อย่างไรก็ตาม ประสิทธิภาพการจำแนกพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่อื่นๆยังคงมีความท้าทาย โดย F1-Score สำหรับ Agriculture อยู่ในช่วง 0.67 (GRU) ถึง 0.72 (RNN, LSTM, BI-LSTM) และสำหรับ Urban อยู่ในช่วง 0.73 (RNN, LSTM) ถึง 0.75 (BI-LSTM) แสดงให้เห็นว่าการแยกแยะสองคลาสนี้ด้วยข้อมูล VH เพียงอย่างเดียวยังมีความสับสนอยู่บ้าง โดยเฉพาะ GRU ที่มีค่า Precision ค่อนข้างต่ำสำหรับพื้นที่เกษตรกรรม (0.65)

ตาราง 16 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	Agriculture	0.75	0.69	0.72	86.02%	0.80	2.37
	Rice	0.96	0.97	0.96			427.24
	Urban/Other	0.70	0.76	0.73			1006.56
	Water	1.00	0.96	0.98			100.35
GRU	Agriculture	0.65	0.69	0.67	84.94%	0.79	0
	Rice	0.95	0.96	0.96			946.82
	Urban/Other	0.77	0.71	0.74			582.4
	Water	0.98	0.98	0.98			7.3
LSTM	Agriculture	0.75	0.69	0.72	86.02%	0.80	1131.62
	Rice	0.96	0.97	0.96			317.11
	Urban/Other	0.70	0.76	0.73			80.95
	Water	1.00	0.96	0.98			6.84
BI-LSTM	Agriculture	0.72	0.71	0.72	86.24%	0.81	987.42
	Rice	0.95	0.97	0.96			490.13
	Urban/Other	0.74	0.75	0.75			24.69
	Water	0.99	0.95	0.97			34.29

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลอนุกรมเวลา VH กับแบบจำลองการเรียนรู้เชิงลึก พบว่า BI-LSTM ให้ค่า OA สูงที่สุดเล็กน้อยที่ 86.24% และค่าสัมประสิทธิ์เคปป์สูงสุดที่ 0.81 ตามมาติดๆ ด้วย RNN และ LSTM ให้ผลลัพธ์เกือบเท่ากัน (OA 86.02%, KC 0.80) ส่วน GRU มีประสิทธิภาพโดยรวมต่ำที่สุดในกลุ่ม (OA 84.94%, KC 0.79) โดยรวมแล้ว แม้แบบจำลองการเรียนรู้เชิงลึกจะจำแนกพื้นที่ปลูกข้าวและพื้นที่แหล่งน้ำได้ดี แต่ค่าความถูกต้องโดยรวมที่ได้จากข้อมูล VH นี้ยังไม่สูงเท่ากับที่ได้จากแบบจำลองการเรียนรู้ของเครื่องบางตัว (เช่น RF) ที่ใช้ข้อมูลนำเข้าเดียวกันในการทดลองก่อนหน้านี้

ตาราง 17 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	Agriculture	0.79	0.76	0.77	88.54%	0.84	2
	Rice	0.96	0.93	0.95			427
	Urban/Other	0.77	0.87	0.82			1007
	Water	1.00	0.95	0.97			100
GRU	Agriculture	0.82	0.78	0.80	89.77%	0.86	947
	Rice	0.96	0.96	0.96			582
	Urban/Other	0.80	0.84	0.82			7
	Water	0.98	0.99	0.98			1132
LSTM	Agriculture	0.84	0.76	0.80	89.77%	0.86	317
	Rice	0.95	0.98	0.97			81
	Urban/Other	0.80	0.84	0.82			7
	Water	0.98	0.99	0.99			987
BI-LSTM	Agriculture	0.80	0.75	0.78	88.90%	0.84	490
	Rice	0.97	0.94	0.96			25
	Urban/Other	0.77	0.85	0.81			34
	Water	0.98	1.00	0.99			

ตาราง 17 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่ใช้โพลาไรเซชัน VV เพียงอย่างเดียว (28 ช่วงเวลา) เป็นข้อมูลนำเข้าตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

จากผลการประเมิน พบว่าข้อมูลอนุกรมเวลา VV ช่วยให้แบบจำลองการเรียนรู้เชิงลึกสามารถจำแนกพื้นที่แหล่งน้ำได้อย่างยอดเยี่ยม โดยทุกแบบจำลองมีค่า F1-Score สูงตั้งแต่ 0.97 ถึง 0.99 โดย LSTM และ BI-LSTM ทำได้ดีที่สุดที่ 0.99 พื้นที่ปลูกข้าวก็ถูกจำแนกได้ด้วยความแม่นยำสูงมากเช่นกัน โดยมี F1-Score ตั้งแต่ 0.95 (RNN) ถึง 0.97 (LSTM) สำหรับพื้นที่เกษตรกรรม และ

พื้นที่เมืองและพื้นที่อื่นๆ ประสิทธิภาพการจำแนกอยู่ในระดับที่ดีและค่อนข้างคงที่ในทุกแบบจำลอง โดย F1-Score สำหรับพื้นที่เกษตรกรรมอยู่ที่ 0.77 ถึง 0.80 และสำหรับพื้นที่เมืองและพื้นที่อื่นๆ อยู่ที่ 0.81 ถึง 0.82 แสดงให้เห็นว่าทุกโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึกที่ทดสอบสามารถจัดการกับสองคลาสนี้ได้ค่อนข้างดีเมื่อใช้ข้อมูล VV

ตาราง 18 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH+VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	Agriculture	0.85	0.77	0.81	88.54%	0.84	16
	Rice	0.95	0.94	0.94			1466
	Urban/Other	0.77	0.84	0.80			26
	Water	0.94	0.98	0.96			29
GRU	Agriculture	0.81	0.83	0.82	91.93%	0.89	688
	Rice	0.97	0.99	0.98			786
	Urban/Other	0.87	0.84	0.86			51
	Water	0.99	0.99	0.99			12
LSTM	Agriculture	0.90	0.72	0.80	88.62%	0.84	453
	Rice	0.97	0.93	0.95			1054
	Urban/Other	0.68	0.93	0.78			16
	Water	0.98	0.99	0.98			14
BI-LSTM	Agriculture	0.85	0.79	0.82	90.56%	0.87	453
	Rice	0.96	0.96	0.96			1054
	Urban/Other	0.80	0.86	0.83			16
	Water	0.98	0.99	0.99			14

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลอนุกรมเวลา VV กับแบบจำลองการเรียนรู้เชิงลึก พบว่า GRU และ LSTM ให้ค่า OA สูงที่สุดเท่ากันที่ 89.77% และค่าสัมประสิทธิ์คอปาสองสุดเท่ากันที่ 0.86 ตามมาด้วย BI-LSTM (OA 88.90%, KC 0.84) และ RNN (OA 88.54%, KC 0.84) ให้ผลลัพธ์ที่ใกล้เคียงกัน ผลลัพธ์นี้แสดงให้เห็นว่าข้อมูลอนุกรมเวลา VV สามารถนำมาใช้กับ

แบบจำลองการเรียนรู้เชิงลึกโดยเฉพาะ GRU และ LSTM เพื่อให้ได้ประสิทธิภาพการจำแนกโดยรวมที่ดี และสูงกว่าประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องที่ดีที่สุด (XGBoost) ใช้ข้อมูล VV เดียวกันเล็กน้อย

ตาราง 18 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่รวมข้อมูลทั้งโพลาไรเซชัน VH และ VV เข้าด้วยกัน (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินแสดงให้เห็นว่าการใช้ข้อมูล VH+VV ร่วมกับแบบจำลองการเรียนรู้เชิงลึก ช่วยเพิ่มประสิทธิภาพการจำแนกได้อย่างชัดเจนเมื่อเทียบกับการใช้โพลาไรเซชันเดียว โดยพื้นที่ปลูกข้าวและพื้นที่แหล่งน้ำสามารถจำแนกได้ด้วยความแม่นยำสูงมาก ค่า F1-Score สำหรับพื้นที่ปลูกข้าวอยู่ในช่วง 0.94 ถึง 0.98 โดย GRU ทำได้ดีที่สุด และ F1-Score สำหรับพื้นที่แหล่งน้ำอยู่ในช่วง 0.96 ถึง 0.99 โดย GRU และ BI-LSTM ทำได้ดีที่สุด ประสิทธิภาพสำหรับพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่อื่นๆ ดีขึ้นอย่างมีนัยสำคัญเช่นกัน โดย F1-Score สำหรับพื้นที่เกษตรกรรมอยู่ที่ 0.80-0.82 และพื้นที่เมืองและพื้นที่อื่นๆ อยู่ที่ 0.78 (LSTM) ถึง 0.86 (GRU) GRU ให้ผลการจำแนกคลาส Urban ได้ดีที่สุด และให้ผลที่ค่อนข้างสมดุลสำหรับพื้นที่เกษตรกรรม

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลอนุกรมเวลา VH+VV กับแบบจำลองการเรียนรู้เชิงลึก พบว่า Gated Recurrent Unit (GRU) ให้ค่า OA สูงที่สุดอย่างชัดเจนที่ 91.93% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.89 ตามมาด้วย BI-LSTM (OA 90.56%, KC 0.87) ส่วน LSTM (OA 88.62%, KC 0.84) และ RNN (OA 88.54%, KC 0.84) ให้ประสิทธิภาพประกอบต่ำกว่า ผลลัพธ์นี้บ่งชี้ว่าโครงข่ายประสาทเทียม GRU สามารถใช้ประโยชน์จากข้อมูลอนุกรมเวลา SAR สองโพลาไรเซชันร่วมกันได้อย่างมีประสิทธิภาพมากที่สุดในการทดลองนี้ และให้ประสิทธิภาพโดยรวมที่ใกล้เคียงกับแบบจำลอง การเรียนรู้ของเครื่องที่ดีที่สุด (เช่น RF, XGBoost) ใช้ข้อมูล VH+VV เดียวกัน

ตาราง 19 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	Agriculture	0.80	0.76	0.78	89.70%	0.86	513
	Rice	0.96	0.98	0.97			802
	Urban/Other	0.81	0.82	0.82			201
	Water	0.98	1.00	0.99			21
GRU	Agriculture	0.88	0.76	0.81	91.14%	0.88	579
	Rice	0.98	0.99	0.98			790
	Urban/Other	0.78	0.89	0.83			146
	Water	0.98	0.99	0.98			22
LSTM	Agriculture	0.91	0.73	0.81	90.42%	0.87	578
	Rice	0.98	0.97	0.98			818
	Urban/Other	0.71	0.93	0.80			118
	Water	0.99	0.99	0.99			23
BI-LSTM	Agriculture	0.85	0.75	0.80	90.63%	0.87	498
	Rice	0.98	0.98	0.98			831
	Urban/Other	0.78	0.87	0.82			187
	Water	0.99	1.00	0.99			21

ตาราง 19 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่ใช้โพลาริเซชัน VH เพียงอย่างเดียว (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาส และค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

จากการประเมิน พบว่าข้อมูลค่าเฉลี่ยรายเดือน VH สามารถนำมาใช้กับแบบจำลองการเรียนรู้เชิงลึก เพื่อจำแนกพื้นที่ปลูกข้าวและพื้นที่แหล่งน้ำได้อย่างยอดเยี่ยม โดยทุกแบบจำลองให้ค่า F1-Score สำหรับ Rice ระหว่าง 0.97-0.98 และสำหรับพื้นที่แหล่งน้ำระหว่าง 0.98-0.99 แสดงถึงความแม่นยำที่สูงมากในการแยกสองคลาสนี้ สำหรับพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่อื่นๆ

ประสิทธิภาพอยู่ในระดับดี โดย F1-Score สำหรับพื้นที่เกษตรกรรมอยู่ที่ 0.78 ถึง 0.81 (GRU และ LSTM ดีที่สุด) และสำหรับเมืองและพื้นที่อื่นๆ อยู่ที่ 0.80 ถึง 0.83 (GRU ดีที่สุด) แสดงให้เห็นว่าแม้จะเป็นข้อมูลค่าเฉลี่ยรายเดือน แบบจำลองการเรียนรู้เชิงลึกก็ยังสามารถแยกแยะคลาสที่ซับซ้อนเหล่านี้ได้ค่อนข้างดี

ตาราง 20 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	Agriculture	0.79	0.78	0.78	89.70%	0.86	405
	Rice	0.97	0.96	0.97			921
	Urban/Other	0.80	0.84	0.82			171
	Water	1.00	0.97	0.98			38
GRU	Agriculture	0.88	0.76	0.81	91.21%	0.88	592
	Rice	0.96	0.97	0.97			802
	Urban/Other	0.80	0.91	0.85			120
	Water	0.99	0.99	0.99			22
LSTM	Agriculture	0.85	0.76	0.80	90.56%	0.87	607
	Rice	0.97	0.97	0.97			798
	Urban/Other	0.80	0.88	0.84			111
	Water	0.99	0.99	0.99			20
BI-LSTM	Agriculture	0.89	0.74	0.81	90.35%	0.86	667
	Rice	0.96	0.97	0.96			764
	Urban/Other	0.78	0.91	0.84			81
	Water	0.97	0.99	0.98			24

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลค่าเฉลี่ยรายเดือน VH กับแบบจำลองการเรียนรู้เชิงลึก พบว่า Gated Recurrent Unit (GRU) ให้ค่า OA สูงที่สุดที่ 91.14% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.88 ตามมาด้วย BI-LSTM (OA 90.63%, KC 0.87) และ LSTM (OA 90.42%, KC 0.87) ให้ผลลัพธ์ใกล้เคียงกันมาก ส่วน RNN มีประสิทธิภาพต่ำกว่าเล็กน้อย (OA

89.70%, KC 0.86) ผลลัพธ์นี้ชี้ให้เห็นว่า GRU เป็นโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึกที่เหมาะสมที่สุดเมื่อทำงานกับข้อมูลค่าเฉลี่ยรายเดือน VH และให้ประสิทธิภาพโดยรวมที่ใกล้เคียงกับแบบจำลองการเรียนรู้ของเครื่องที่ดีที่สุด (SVM) ใช้ข้อมูลนำเข้าประเภทเดียวกัน

ตาราง 20 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่ใช้โพลาไรเซชัน VV เพียงอย่างเดียว (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาส และค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

จากผลการประเมิน พบว่าข้อมูลค่าเฉลี่ยรายเดือน VV สามารถใช้กับแบบจำลองการเรียนรู้เชิงลึก เพื่อให้ได้ประสิทธิภาพการจำแนกที่ดีในทุกคลาส พื้นที่ปลูกข้าวและพื้นที่แหล่งน้ำยังคงถูกจำแนกได้อย่างแม่นยำสูงมาก โดยมีค่า F1-Score สำหรับพื้นที่ปลูกข้าวอยู่ที่ 0.96-0.97 และสำหรับ Water อยู่ที่ 0.97-0.99 ในทุกแบบจำลอง พื้นที่เมืองและพื้นที่อื่นๆและพื้นที่เกษตรกรรม ก็ถูกจำแนกได้ในระดับที่ดีเช่นกัน โดย F1-Score สำหรับพื้นที่เมืองและพื้นที่อื่นๆอยู่ในช่วง 0.82 ถึง 0.85 (GRU ดีที่สุด) และพื้นที่เกษตรกรรมอยู่ในช่วง 0.78 ถึง 0.81 (GRU และ BI-LSTM ดีที่สุด) แสดงให้เห็นถึงความสามารถของแบบจำลองการเรียนรู้เชิงลึก ในการแยกแยะคลาสเหล่านี้ได้ค่อนข้างดีแม้ใช้ข้อมูลค่าเฉลี่ยรายเดือน VV

เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลค่าเฉลี่ยรายเดือน VV กับแบบจำลองการเรียนรู้เชิงลึก พบว่า Gated Recurrent Unit (GRU) ให้ค่า OA สูงที่สุดที่ 91.21% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.88 ตามมาด้วย LSTM (OA 90.56%, KC 0.87), BI-LSTM (OA 90.35%, KC 0.86), และ RNN (OA 89.70%, KC 0.86) ทั้งหมดให้ผลลัพธ์ในระดับสูงและใกล้เคียงกัน ผลลัพธ์นี้ยังคงสอดคล้องกับกรณีข้อมูล VH ที่ GRU ให้ประสิทธิภาพสูงสุด และเมื่อเปรียบเทียบกับผลของ การเรียนรู้ของเครื่องที่ใช้ข้อมูลเดียวกัน (ค่าเฉลี่ยรายเดือน VV) พบว่าประสิทธิภาพโดยรวมของ GRU, LSTM, และ BI-LSTM ใกล้เคียงหรือสูงกว่าเล็กน้อย เมื่อเทียบกับ SVM เป็นแบบจำลองการเรียนรู้ของเครื่องที่ดีที่สุดสำหรับข้อมูลประเภทนี้

ตาราง 21 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	Agriculture	0.88	0.80	0.83	92.29%	0.89	642
	Rice	0.98	0.99	0.98			750
	Urban/Other	0.83	0.89	0.86			122
	Water	0.98	0.99	0.99			22
GRU	Agriculture	0.85	0.84	0.84	92.44%	0.89	506
	Rice	0.99	0.97	0.98			816
	Urban/Other	0.86	0.87	0.86			199
	Water	0.97	1.00	0.98			15
LSTM	Agriculture	0.86	0.81	0.83	92.35%	0.89	535
	Rice	0.98	0.98	0.98			806
	Urban/Other	0.83	0.89	0.86			169
	Water	1.00	0.99	0.99			27
BI-LSTM	Agriculture	0.87	0.80	0.83	92.36%	0.89	538
	Rice	0.98	0.98	0.98			823
	Urban/Other	0.83	0.89	0.86			152
	Water	1.00	0.99	0.99			23

ตาราง 21 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่รวมข้อมูลทั้งโพลาริเซชัน VH และ VV เข้าด้วยกัน (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินแสดงให้เห็นว่า การใช้ข้อมูลค่าเฉลี่ยรายเดือน VH+VV ร่วมกับแบบจำลองการเรียนรู้เชิงลึก ให้ประสิทธิภาพการจำแนกที่ยอดเยี่ยมและมีความสม่ำเสมอสูงในทุกคลาสและทุกแบบจำลองที่ทดสอบ พื้นที่ปลูกข้าวและพื้นที่แหล่งน้ำถูกจำแนกได้อย่างแม่นยำสูงสุด โดยทุก

แบบจำลองให้ค่า F1-Score สำหรับพื้นที่ปลูกข้าวที่ 0.98 และสำหรับพื้นที่แหล่งน้ำที่ 0.98-0.99 ประสิทธิภาพการจำแนกพื้นที่เกษตรกรรมและพื้นที่เมืองและพื้นที่อื่นๆก็อยู่ในระดับที่ดีมากเช่นกัน โดยมี F1-Score สำหรับพื้นที่เกษตรกรรมอยู่ที่ 0.83-0.84 และสำหรับพื้นที่เมืองและพื้นที่อื่นๆอยู่ที่ 0.86 อย่างคงที่ในทุกโครงข่ายประสาทเทียม แสดงให้เห็นว่าข้อมูลรวมสองโพลาริเซชันนี้ แม้จะเป็นค่าเฉลี่ยรายเดือน ก็ยังคงให้ข้อมูลที่เพียงพอสำหรับแบบจำลองการเรียนรู้เชิงลึกในการแยกแยะทุกคลาสได้อย่างมีประสิทธิภาพ


เมื่อพิจารณาประสิทธิภาพโดยรวมของการใช้ข้อมูลค่าเฉลี่ยรายเดือน VH+VV กับแบบจำลองการเรียนรู้เชิงลึก พบว่า ทุกโครงข่ายประสาทเทียมให้ผลลัพธ์ในระดับที่สูงมากและใกล้เคียงกันอย่างยิ่ง โดย GRU ให้ค่า OA สูงที่สุดเล็กน้อยที่ 92.44% ตามมาด้วย LSTM (92.35%), BI-LSTM (92.36%), และ RNN (92.29%) ค่าสัมประสิทธิ์แคปปาก็อยู่ในระดับสูงและใกล้เคียงกันมากที่สุดที่ 0.89 สำหรับทุกแบบจำลอง (ยกเว้น BI-LSTM ที่อาจพิเศษต่างกันเล็กน้อย แต่ก็ยังสูงมาก) ผลลัพธ์นี้ตอกย้ำว่าข้อมูลค่าเฉลี่ยรายเดือน VH+VV เป็นข้อมูลนำเข้าที่มีประสิทธิภาพสูงอย่างยิ่งสำหรับแบบจำลองการเรียนรู้เชิงลึกทุกโครงข่ายประสาทเทียมที่ทดสอบ และให้ความแม่นยำโดยรวมในระดับที่ทัดเทียมกับแบบจำลองการเรียนรู้ของเครื่องที่ดีที่สุด (เช่น RF, SVM) ใช้ข้อมูลนำเข้าประเภทเดียวกัน

ตาราง 22 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพอนุกรมเวลา SAR


		VH	VV	VH+VV
RNN	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
		Predicted label	Predicted label	Predicted label
GRU	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
		Predicted label	Predicted label	Predicted label
LSTM	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
		Predicted label	Predicted label	Predicted label
BI-LSTM	True label	Agriculture	Agriculture	Agriculture
		Rice	Rice	Rice
		Urban&Other	Urban&Other	Urban&Other
		Water	Water	Water
		Predicted label	Predicted label	Predicted label

ตาราง 23 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพค่าเฉลี่ย SAR รายเดือน

		VH	VV	VH+VV
RNN	True label	Agriculture 0.76 0.04 0.20 0.00 Rice 0.01 0.98 0.01 0.01 Urban&Other 0.15 0.03 0.82 0.00 Water 0.00 0.00 0.00 1.00 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.78 0.02 0.20 0.00 Rice 0.03 0.96 0.01 0.00 Urban&Other 0.14 0.02 0.84 0.00 Water 0.00 0.01 0.02 0.97 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.80 0.04 0.16 0.00 Rice 0.01 0.99 0.01 0.00 Urban&Other 0.10 0.00 0.89 0.01 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label
GRU	True label	Agriculture 0.76 0.03 0.22 0.00 Rice 0.01 0.99 0.00 0.00 Urban&Other 0.10 0.01 0.89 0.01 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.76 0.06 0.18 0.00 Rice 0.02 0.97 0.01 0.00 Urban&Other 0.09 0.00 0.91 0.00 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.84 0.02 0.14 0.00 Rice 0.02 0.97 0.01 0.00 Urban&Other 0.10 0.01 0.87 0.02 Water 0.00 0.00 0.00 1.00 Agriculture Rice Urban&Other Water Predicted label
LSTM	True label	Agriculture 0.73 0.02 0.25 0.00 Rice 0.01 0.97 0.01 0.00 Urban&Other 0.07 0.01 0.93 0.00 Water 0.00 0.00 0.00 0.99 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.76 0.06 0.18 0.00 Rice 0.01 0.97 0.02 0.00 Urban&Other 0.11 0.00 0.88 0.00 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.81 0.03 0.17 0.00 Rice 0.01 0.98 0.01 0.00 Urban&Other 0.10 0.01 0.88 0.00 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label
BI-LSTM	True label	Agriculture 0.75 0.02 0.22 0.00 Rice 0.01 0.98 0.01 0.00 Urban&Other 0.12 0.01 0.87 0.00 Water 0.00 0.00 0.00 1.00 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.74 0.07 0.19 0.00 Rice 0.01 0.97 0.01 0.01 Urban&Other 0.08 0.00 0.91 0.01 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label	Agriculture 0.80 0.03 0.17 0.00 Rice 0.01 0.98 0.00 0.00 Urban&Other 0.09 0.01 0.89 0.00 Water 0.00 0.00 0.01 0.99 Agriculture Rice Urban&Other Water Predicted label



ภาพประกอบ 26 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูล
ภาพอนุกรมเวลา SAR



ภาพประกอบ 27 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกด้วยข้อมูลภาพ
ค่าเฉลี่ย SAR รายเดือน

การสรุปและเปรียบเทียบประสิทธิภาพด้าน ความถูกต้องโดยรวมของแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ข้อมูลนำเข้า SAR ที่แตกต่างกัน 6 รูปแบบ ได้จากการผสมผสานโพลาไรเซชัน (VH, VV, VH+VV) และลักษณะข้อมูลอนุกรมเวลา (ข้อมูลเต็ม 28 ช่วงเวลา และ ข้อมูลค่าเฉลี่ยรายเดือน 12 ช่วงเวลา)


เมื่อพิจารณาข้อมูลอนุกรมเวลาแบบเต็ม (28 ช่วงเวลา) พบว่า การใช้ข้อมูล VH+VV ให้ประสิทธิภาพโดยรวมสูงสุด โดยโครงข่ายประสาทเทียม GRU ทำได้ดีที่สุดด้วย OA 91.93% ตามมาด้วย BI-LSTM (90.56%) สำหรับข้อมูล VV โครงข่ายประสาทเทียม LSTM และ GRU ให้ผลดีที่สุดเท่ากันที่ OA 89.77% ส่วนข้อมูล VH ให้ประสิทธิภาพต่ำที่สุด โดย BI-LSTM ให้ OA สูงสุดที่ 86.24%

เมื่อพิจารณาข้อมูลค่าเฉลี่ยรายเดือน (12 ช่วงเวลา) พบว่า การใช้ข้อมูล VH+VV ยังคงให้ประสิทธิภาพโดยรวมสูงสุด โดยโครงข่ายประสาทเทียม GRU ทำได้ดีที่สุดด้วย OA 92.44% ตามมาด้วย BI-LSTM (92.36%) และ LSTM (92.35%) ให้ผลใกล้เคียงกันมาก สำหรับข้อมูล VV โครงข่ายประสาทเทียม GRU ยังคงดีที่สุด (OA 91.21%) และสำหรับข้อมูล VH โครงข่ายประสาทเทียม GRU ก็ยังคงให้ผลดีที่สุดเช่นกัน (OA 91.14%)


ข้อสรุปจากการเปรียบเทียบ การใช้ข้อมูล VH+VV ให้ประสิทธิภาพสูงสุดกับแบบจำลองการเรียนรู้เชิงลึก ทั้งในกรณีข้อมูลอนุกรมเวลาเต็มและข้อมูลค่าเฉลี่ยรายเดือน โดยข้อมูลค่าเฉลี่ยรายเดือน VH+VV ร่วมกับโครงข่ายประสาทเทียม GRU ให้ค่าความถูกต้องโดยรวมสูงสุดในการทดลองกลุ่ม Deep Learning ที่ 92.44% ผลการจำแนกเชิงพื้นที่จากกรณีที่ดียิ่งที่สุดนี้ (ค่าเฉลี่ยรายเดือน VH+VV กับ GRU) ได้ถูกนำไปเปรียบเทียบกับข้อมูลการใช้ประโยชน์ที่ดินจากกรมพัฒนาที่ดิน ปี พ.ศ. 2564 ดังแสดงใน ภาพประกอบ 23



(A) High Resolution
Satellite Image




(B) Landcover Map




(C) Prediction



(D) High Resolution
Satellite Image



(E) Landcover Map




(F) Prediction

ภาพประกอบ 28 ผลการจำแนกพื้นที่เพาะปลูกข้าวข้อมูลภาพถ่ายค่าเฉลี่ย SAR รายเดือน โพลาไรเซชัน
VH+VV ร่วมกับแบบจำลองด้วยโครงข่ายประสาทเทียม GRU เทียบกับข้อมูลการใช้ประโยชน์ที่ดิน
จากกรมพัฒนาที่ดิน ปี พ.ศ.2564


4.3 การเปรียบเทียบแบบจำลองที่ดีที่สุดสำหรับการจำแนกพื้นที่ปลูกข้าว

จากการวิเคราะห์และเปรียบเทียบประสิทธิภาพของแบบจำลองทั้งหมด 8 รูปแบบ (การเรียนรู้ของเครื่อง 4 วิธี และการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม) สำหรับการจำแนกพื้นที่ปลูกข้าวและสิ่งปกคลุมดินประเภทอื่น โดยพบว่า

แบบจำลองการเรียนรู้ของเครื่องที่ให้ประสิทธิภาพโดยรวมที่ดีที่สุดคือแบบจำลอง Random Forest โดยสามารถทำค่าความถูกต้องโดยรวม ได้สูงสุดถึง 93.73% (ดังภาพที่ 29) และมีค่าสัมประสิทธิ์แคปปาที่ 0.91 (ดังภาพที่ 30) ทั้งนี้ แบบจำลอง Support Vector Machine และ XGBoost ก็ให้ผลลัพธ์ที่ดีและใกล้เคียงกันมาก โดยมีค่าความถูกต้องโดยรวมสูงถึง 93.59% และ 93.23% ตามลำดับ เมื่อใช้ชุดข้อมูลค่าเฉลี่ยรายเดือน VH+VW เดียวกัน




ภาพประกอบที่ 29 เปรียบเทียบความถูกต้องโดยรวมของการเรียนรู้ของเครื่อง




ภาพประกอบที่ 30 เปรียบเทียบสัมประสิทธิ์แคปปาของการเรียนรู้ของเครื่อง

ในกลุ่มแบบจำลองการเรียนรู้เชิงลึก โครงข่ายประสาทเทียมที่ให้ผลลัพธ์ที่ดีที่สุดคือ Gated Recurrent Unit ให้ค่าความถูกต้องโดยรวมสูงถึง 92.44% (ดังภาพที่ 31) และค่าสัมประสิทธิ์แคปปาที่ 0.89 (ดังภาพที่ 32) แม้ว่าค่าความถูกต้องสูงสุดของกลุ่มการเรียนรู้เชิงลึกจะต่ำกว่ากลุ่มการเรียนรู้ของเครื่องเล็กน้อย แต่ก็ถือว่ามีประสิทธิภาพสูงและสามารถแข่งขันได้เป็นอย่างดี โดยมีแบบจำลอง BI-LSTM (92.36%) และ LSTM (92.35%) ที่ให้ผลลัพธ์ใกล้เคียงกันมาก




ภาพประกอบที่ 31 เปรียบเทียบความถูกต้องโดยรวมของการเรียนรู้เชิงลึก




ภาพประกอบที่ 32 เปรียบเทียบสัมประสิทธิ์แคปปาของการเรียนรู้เชิงลึก


เมื่อพิจารณาประสิทธิภาพในการจำแนกรายคลาส พบว่าทุกแบบจำลองสามารถจำแนกพื้นที่แหล่งน้ำ (ดังภาพที่ 33-34) ได้อย่างแม่นยำสูงสุด โดยมีค่า F1-Score ใกล้เคียง 1.00 สำหรับพื้นที่ปลูกข้าว แบบจำลองส่วนใหญ่ (RF, SVM, XGBoost, GRU) สามารถจำแนกได้ดี โดยมีค่า F1-Score สูงถึง 0.98-0.99 (ดังภาพที่ 35-36) ในขณะที่พื้นที่เกษตรกรรม (ดังภาพที่ 37-38) และพื้นที่เมืองและพื้นที่อื่นๆ (ดังภาพที่ 39-40) มีค่า F1-Score สูงสุดอยู่ที่ประมาณ 0.87-0.88




ภาพประกอบที่ 33 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่แหล่งน้ำด้วยการเรียนของเครื่อง




ภาพประกอบที่ 34 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่แหล่งน้ำด้วยการเรียนเชิงลึก




ภาพประกอบที่ 35 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่ปลูกข้าวด้วยการเรียนของเครื่อง




ภาพประกอบที่ 36 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่ปลูกข้าวด้วยการเรียนเชิงลึก




ภาพประกอบที่ 37 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เกษตรกรรมด้วยการเรียนของเครื่อง



ภาพประกอบที่ 38 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เกษตรกรรมด้วยการเรียนเชิงลึก



ภาพประกอบที่ 39 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เมืองและพื้นที่อื่นๆด้วยการเรียนของเครื่อง



ภาพประกอบที่ 40 เปรียบเทียบค่า F1-score ในการจำแนกพื้นที่เมืองและพื้นที่อื่นๆด้วยการเรียนรู้เชิงลึก

4.4 ผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้เชิงลึก

ในส่วนนี้เป็นการนำเสนอผลการทดสอบและประเมินประสิทธิภาพของแบบจำลอง การเรียนรู้เชิงลึกจำนวน 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM และ BI-LSTM) สำหรับการจำแนกช่วงระยะเวลาที่เริ่มเพาะปลูกข้าว (พฤษภาคม, มิถุนายน, กรกฎาคม, สิงหาคม) โดยใช้ข้อมูลอนุกรมเวลา SAR ระดับแปลงจากพื้นที่ศึกษาอำเภอเมือง จังหวัดสุพรรณบุรี ครอบคลุมปี พ.ศ. 2565

การทดสอบแบบจำลองการเรียนรู้เชิงลึก ได้ดำเนินการโดยใช้รูปแบบข้อมูลที่แตกต่างกัน 6 รูปแบบ เช่นเดียวกับการทดลองจำแนกพื้นที่ข้าวด้วยการเรียนรู้ของเครื่อง เพื่อเปรียบเทียบผลกระทบของโพลาริเซชันและลักษณะข้อมูลอนุกรมเวลา ดังนี้

- อนุกรมเวลาโพลาริเซชัน VH (28 ช่วงเวลา)
- อนุกรมเวลาโพลาริเซชัน VV (28 ช่วงเวลา)
- อนุกรมเวลาโพลาริเซชัน VH และ VV ร่วมกัน
- ค่าเฉลี่ยรายเดือนของโพลาริเซชัน VH (12 ช่วงเวลา)
- ค่าเฉลี่ยรายเดือนของโพลาริเซชัน VV (12 ช่วงเวลา)
- ค่าเฉลี่ยรายเดือนของโพลาริเซชัน VH และ VV ร่วมกัน

สำหรับแต่ละโครงข่ายประสาทเทียม การเรียนรู้เชิงลึกและแต่ละรูปแบบข้อมูลนำเข้า ได้ดำเนินการปรับแก้ไฮเปอร์พารามิเตอร์ โดยใช้ชุดข้อมูลตรวจสอบเพื่อหาชุดพารามิเตอร์ที่ให้ประสิทธิภาพการจำแนกสูงสุด ค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดสำหรับแต่ละกรณี แสดงผลในตาราง 24 (สำหรับข้อมูลอนุกรมเวลา) และ ตาราง 25 (สำหรับข้อมูลค่าเฉลี่ยรายเดือน)

ประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกที่ผ่านการปรับจูนแล้ว ถูกประเมินอย่างละเอียดด้วยชุดข้อมูลทดสอบ (Test Set) โดยใช้เมตริกซ์ความคลาดเคลื่อน (แสดงในตาราง 32 และ 33) และคำนวณค่าทางสถิติ ได้แก่ Precision, Recall, F1-Score สำหรับแต่ละเดือนที่เริ่มปลูก, ค่าความถูกต้องโดยรวมและ ค่าสัมประสิทธิ์แคปปา ผลการประเมินโดยละเอียดจำแนกตามประเภทข้อมูลนำเข้า แสดงในตาราง 26 ถึงตาราง 31 นอกจากนี้ ผลลัพธ์เชิงพื้นที่ในรูปแบบของแผนที่จำแนกช่วงเวลาเริ่มเพาะปลูกข้าวที่ได้จากแบบจำลองการเรียนรู้เชิงลึก แสดงในภาพประกอบ 41 และ 42

ตาราง 24 สรุปค่าไฮเปอร์พารามิเตอร์ที่สำคัญบางส่วน เป็นผลจากการปรับจูนแบบจำลองการเรียนรู้เชิงลึกทั้ง 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) สำหรับภารกิจ การจำแนกช่วงระยะเวลาเริ่มเพาะปลูกข้าว โดยเฉพาะ เมื่อใช้ ข้อมูลอนุกรมเวลา SAR แบบเต็ม (28 ช่วงเวลา) เป็นข้อมูลนำเข้าในรูปแบบโพลาริเซชันที่แตกต่างกัน 3 รูปแบบ (VH, VV, และ VH+VV) ไฮเปอร์พารามิเตอร์ที่แสดงในตารางคือ จำนวนหน่วย (Units) ในชั้น Recurrent และ รอบการฝึกที่ดีที่สุด (Best Epoch) ที่แบบจำลองให้ประสิทธิภาพสูงสุดบนชุดข้อมูลตรวจสอบ

ผลการปรับจูนสำหรับภารกิจจำแนกช่วงเวลาเพาะปลูกนี้แสดงให้เห็นว่า จำนวน Units ที่เหมาะสมที่สุดมีค่าเท่ากับ 45 สำหรับทุกโครงข่ายประสาทเทียมและทุกรูปแบบข้อมูลนำเข้า เป็นค่าที่คงที่แต่แตกต่างจากค่าที่พบในการจำแนกพื้นที่ปลูกข้าวโดยรวมก่อนหน้านี้ ซึ่งชี้ให้เห็นถึงความซับซ้อนของแบบจำลองที่เหมาะสมอาจขึ้นอยู่กับลักษณะเฉพาะของปัญหาการจำแนก ในส่วนของ Best Epoch พบว่ายังคงมีความแปรผันสูง ขึ้นอยู่กับโครงข่ายประสาทเทียมและข้อมูลนำเข้า เช่น เมื่อใช้ข้อมูล VV แบบจำลอง GRU ลู่เข้าสู่ผลดีที่สุดอย่างรวดเร็วในเวลาเพียง 18 epochs ขณะที่ BI-LSTM ต้องการถึง 421 epochs หรือเมื่อใช้ข้อมูล VH+VV แบบจำลอง BI-LSTM ต้องการจำนวนรอบสูงสุดถึง 626 epochs ความแตกต่างนี้สะท้อนถึงระยะเวลาที่แต่ละแบบจำลองต้องการในการเรียนรู้

ลักษณะเฉพาะของแต่ละช่วงเวลาเพาะปลูกจากข้อมูล SAR แต่ละประเภท ค่า Units และ Best Epoch เหล่านี้คือค่าที่ใช้กำหนดแบบจำลองขั้นสุดท้ายสำหรับประเมินผลการจำแนกช่วงเวลาเริ่มเพาะปลูกด้วยข้อมูลอนุกรมเวลาต่อไป

ตาราง 25 สรุปค่าไฮเปอร์พารามิเตอร์ที่สำคัญบางส่วน เป็นผลจากการปรับจูนแบบจำลองการเรียนรู้เชิงลึกทั้ง 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) สำหรับภารกิจ การจำแนกช่วงระยะเวลาเริ่มเพาะปลูกข้าว เมื่อใช้ ข้อมูลภาพถ่ายดาวเทียม SAR รายเดือน (12 ช่วงเวลา) เป็นข้อมูลนำเข้าในรูปแบบโพลาริเซชันที่แตกต่างกัน 3 รูปแบบ (VH Mean, VV Mean, และ VH+VV Mean) ไฮเปอร์พารามิเตอร์ที่แสดงในตารางคือ จำนวนหน่วย (Units) ในชั้น Recurrent และ รอบการฝึกที่ดีที่สุด (Best Epoch) ที่แบบจำลองให้ประสิทธิภาพสูงสุดบนชุดข้อมูลตรวจสอบ

ผลการปรับจูนยังคงแสดงให้เห็นว่า จำนวน Units ที่เหมาะสมที่สุดมีค่าเท่ากับ 45 อย่างสม่ำเสมอสำหรับทุกโครงข่ายประสาทเทียมและทุกรูปแบบข้อมูลนำเข้า เป็นค่าเดียวกันกับที่พบเมื่อใช้ข้อมูลอนุกรมเวลาเต็มสำหรับภารกิจเดียวกันนี้ (ตาราง 23) บ่งชี้ว่าจำนวน Units ที่ 45 นี้มีความเหมาะสมกับปัญหาการจำแนกช่วงเวลาเพาะปลูก 4 คลาสนี้ อย่างไรก็ตาม Best Epoch หรือจำนวนรอบการฝึกที่เหมาะสมที่สุดสำหรับข้อมูลค่าเฉลี่ยรายเดือน ยังคงมีความแปรผันสูง และมีรูปแบบที่แตกต่างจากการใช้ข้อมูลอนุกรมเวลาเต็ม ตัวอย่างเช่น เมื่อใช้ข้อมูล VH Mean แบบจำลอง LSTM ต้องการจำนวนรอบน้อยที่สุด (82 epochs) ขณะที่ RNN ต้องการมากที่สุด (494 epochs) หรือเมื่อใช้ข้อมูล VV Mean แบบจำลอง BI-LSTM ต้องการจำนวนรอบสูงสุดถึง 636 epochs ความแตกต่างเหล่านี้สะท้อนให้เห็นว่า การใช้ข้อมูลค่าเฉลี่ยรายเดือนส่งผลต่อความเร็วและระยะเวลาที่แต่ละโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึก ใช้ในการเรียนรู้และเข้าสู่จุดที่ให้ประสิทธิภาพดีที่สุดแตกต่างกันไป ค่า Units และ Best Epoch ที่แสดงในตารางนี้เป็นค่าที่ใช้กำหนดแบบจำลองขั้นสุดท้ายสำหรับประเมินผลการจำแนกช่วงเวลาเริ่มเพาะปลูกด้วยข้อมูลค่าเฉลี่ยรายเดือนต่อไป

ตาราง 24 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพอนุกรมเวลา SAR

โพลาริเซชัน	แบบจำลอง	ไฮเปอร์พารามิเตอร์	ค่าที่ใช้
VH	RNN	Units	45
		Best Epoch	129
	GRU	Units	45
		Best Epoch	212
	LSTM	Units	45
		Best Epoch	319
	BI-LSTM	Units	45
		Best Epoch	449
VV	RNN	Units	45
		Best Epoch	240
	GRU	Units	45
		Best Epoch	18
	LSTM	Units	45
		Best Epoch	65
	BI-LSTM	Units	45
		Best Epoch	421
VH+VV	RNN	Units	45
		Best Epoch	166
	GRU	Units	45
		Best Epoch	192
	LSTM	Units	45
		Best Epoch	183
	BI-LSTM	Units	45
		Best Epoch	626

ตาราง 25 ไฮเปอร์พารามิเตอร์ของแบบจำลองร่วมกับข้อมูลภาพค่าเฉลี่ย SAR รายเดือน

โพลาริเซชัน	แบบจำลอง	ไฮเปอร์พารามิเตอร์	ค่าที่ใช้
VH Mean	RNN	Units	45
		Best Epoch	494
	GRU	Units	45
		Best Epoch	192
	LSTM	Units	45
		Best Epoch	82
	BI-LSTM	Units	45
		Best Epoch	345
VV Mean	RNN	Units	45
		Best Epoch	298
	GRU	Units	45
		Best Epoch	318
	LSTM	Units	45
		Best Epoch	193
	BI-LSTM	Units	45
		Best Epoch	636
VH+VV Mean	RNN	Units	45
		Best Epoch	228
	GRU	Units	45
		Best Epoch	222
	LSTM	Units	45
		Best Epoch	341
	BI-LSTM	Units	45
		Best Epoch	129

ตาราง 26 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลอนุกรมเวลา SAR โพลาริเซชัน VH

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	เดือนพฤษภาคม	0.44	0.43	0.43	36.67%	0.15	85.81
	เดือนมิถุนายน	0.26	0.45	0.33			286.94
	เดือนกรกฎาคม	0.05	0.26	0.08			238.48
	เดือนสิงหาคม	0.69	0.33	0.45			128.44
GRU	เดือนพฤษภาคม	0.22	0.77	0.35	52.11%	0.36	383.14
	เดือนมิถุนายน	0.22	0.59	0.32			120.34
	เดือนกรกฎาคม	0.59	0.46	0.52			154.41
	เดือนสิงหาคม	1.00	0.51	0.68			81.78
LSTM	เดือนพฤษภาคม	0.31	0.42	0.36	49.70%	0.32	415.88
	เดือนมิถุนายน	0.17	0.56	0.26			
	เดือนกรกฎาคม	0.49	0.46	0.47			235.69
	เดือนสิงหาคม	0.97	0.54	0.69			88.1
BI-LSTM	เดือนพฤษภาคม	0.68	0.29	0.40	38.12%	0.18	310.17
	เดือนมิถุนายน	0.17	0.43	0.25			112.46
	เดือนกรกฎาคม	0.12	0.57	0.20			154.57
	เดือนสิงหาคม	0.55	0.52	0.53			162.48

ตาราง 26 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนก ช่วงระยะเวลาเริ่มเพาะปลูกข้าว 4 คลาส(เดือนพฤษภาคม, เดือนมิถุนายน, เดือนกรกฎาคม, เดือนสิงหาคม) ด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่ใช้โพลาไรเซชัน VH เพียงอย่างเดียว (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินโดยรวมเผยให้เห็นว่า ประสิทธิภาพในการจำแนกช่วงเวลาเริ่มเพาะปลูกด้วยข้อมูลอนุกรมเวลา VH เพียงอย่างเดียวอยู่ในระดับที่ค่อนข้างต่ำมาก สำหรับทุกแบบจำลองที่ทดสอบ โดยมีค่าความถูกต้องโดยรวม (OA) อยู่ในช่วงเพียง 36.67% ถึง 52.11% และค่าสัมประสิทธิ์

แคปตาต่ำมาก (0.15 ถึง 0.36) บ่งชี้ถึงความยากลำบากและความสับสนอย่างมากในการแยกแยะระหว่างเดือนที่เริ่มเพาะปลูกต่างๆ ด้วยข้อมูลนำเข้ารูปแบบนี้ เมื่อพิจารณาเป็นรายคลาสพบว่าค่า F1-Score ส่วนใหญ่อยู่ในระดับต่ำ โดยเฉพาะคลาสเดือนมิถุนายน และ เดือนกรกฎาคม แบบจำลอง RNN และ BI-LSTM มีประสิทธิภาพต่ำมาก (เช่น F1-Score เพียง 0.08 และ 0.20 สำหรับคลาส เดือนกรกฎาคม ตามลำดับ) แม้ว่าคลาสเดือนสิงหาคม จะดูเหมือนมีความแตกต่างอยู่บ้าง โดย GRU และ LSTM ให้ค่า Precision ที่สูง แต่ค่า Recall ยังคงอยู่ในระดับปานกลาง ทำให้ F1-Score สูงสุดอยู่ที่เพียง 0.68-0.69 เท่านั้น

เมื่อเปรียบเทียบประสิทธิภาพโดยรวมระหว่างแบบจำลอง GRU เป็นแบบจำลองที่ให้ผลดีที่สุดในกลุ่มนี้ ด้วย OA 52.11% และ KC 0.36 อย่างไรก็ตาม ประสิทธิภาพระดับนี้ยังถือว่าไม่สูงนักสำหรับการนำไปใช้งานจริง ตามมาด้วย LSTM (OA 49.70%) ส่วน BI-LSTM และ RNN ให้ประสิทธิภาพประกอบต่ำกว่าอย่างชัดเจน โดยสรุป ผลการทดลองนี้แสดงให้เห็นว่าข้อมูลอนุกรมเวลา โพลาริเซชัน VH เพียงอย่างเดียว ไม่เพียงพออย่างยิ่ง สำหรับแบบจำลองการเรียนรู้เชิงลึก ที่ทดสอบในการจำแนกช่วงเวลาเริ่มเพาะปลูกข้าวได้อย่างน่าเชื่อถือและแม่นยำ

ตาราง 27 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนก ช่วงระยะเวลา เริ่มเพาะปลูกข้าว 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่ใช้โพลาริเซชัน VV เพียงอย่างเดียว (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่า ความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปตา (KC) ของแต่ละแบบจำลอง

ผลการประเมินโดยรวมเผยให้เห็นว่า ประสิทธิภาพในการจำแนกช่วงเวลาเริ่มเพาะปลูก ด้วยข้อมูลอนุกรมเวลา VV เพียงอย่างเดียวอยู่ในระดับที่ต่ำมากอย่างมีนัยสำคัญ สำหรับทุกแบบจำลอง โดยมีค่าความถูกต้องโดยรวม (OA) อยู่ในช่วงเพียง 38.81% (GRU) ถึง 46.08% (LSTM) และค่าสัมประสิทธิ์แคปตาต่ำมาก (0.19 ถึง 0.28) ชี้ชัดว่าข้อมูล VV เพียงลำพังมีข้อจำกัดอย่างยิ่งในการแยกแยะความแตกต่างระหว่างเดือนที่เริ่มเพาะปลูก และให้ผลลัพธ์ที่ต่ำกว่าการใช้ข้อมูล VH เพียงอย่างเดียว เมื่อพิจารณารายคลาสพบว่า ทุกคลาสมีการจำแนกที่ผิดพลาดสูงมาก โดยค่า F1-Score ส่วนใหญ่อยู่ในระดับต่ำ โดยเฉพาะคลาสเดือนมิถุนายน และ เดือนกรกฎาคม มีประสิทธิภาพต่ำมากในเกือบทุกแบบจำลอง (เช่น F1-Score ต่ำสุดเพียง 0.05 สำหรับ เดือนมิถุนายน ด้วย GRU และ 0.18 สำหรับ เดือนกรกฎาคม ด้วย BI-LSTM) แม้คลาสเดือนสิงหาคมจะดูแยกแยะได้ดีที่สุด แต่ก็มี F1-Score สูงสุดเพียง 0.60 (LSTM)

ตาราง 27 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	เดือนพฤษภาคม	0.34	0.49	0.40	43.55%	0.25	396.07
	เดือนมิถุนายน	0.44	0.36	0.40			229.67
	เดือนกรกฎาคม	0.17	0.47	0.25			30.93
	เดือนสิงหาคม	0.80	0.45	0.58			83
GRU	เดือนพฤษภาคม	0.44	0.37	0.40	38.81%	0.19	603.36
	เดือนมิถุนายน	0.03	0.20	0.05			3.09
	เดือนกรกฎาคม	0.26	0.38	0.31			0.11
	เดือนสิงหาคม	0.84	0.44	0.58			133.11
LSTM	เดือนพฤษภาคม	0.31	0.64	0.42	46.08%	0.28	388.21
	เดือนมิถุนายน	0.17	0.35	0.23			115.67
	เดือนกรกฎาคม	0.45	0.44	0.45			59.29
	เดือนสิงหาคม	0.87	0.46	0.60			176.5
BI-LSTM	เดือนพฤษภาคม	0.32	0.60	0.42	44.51%	0.26	376.32
	เดือนมิถุนายน	0.43	0.38	0.40			50.5
	เดือนกรกฎาคม	0.10	0.56	0.18			176.1
	เดือนสิงหาคม	0.95	0.43	0.59			136.76

เมื่อเปรียบเทียบประสิทธิภาพโดยรวมระหว่างแบบจำลอง LSTM เป็นแบบจำลองที่ให้ผลดีที่สุดในกลุ่ม ด้วย OA 46.08% และ KC 0.28 อย่างไรก็ตาม ค่านี้ก็ยังถือว่าอยู่ในระดับต่ำ ตามมาด้วย BI-LSTM (OA 44.51%) และ RNN (OA 43.55%) ส่วน GRU ให้ผลต่ำที่สุด (OA 38.81%) โดยสรุปผลการทดลองนี้แสดงให้เห็นอย่างชัดเจนว่าข้อมูลอนุกรมเวลาโพลาริเซชัน VV เพียงอย่างเดียว ไม่มีประสิทธิภาพเพียงพออย่างยิ่ง สำหรับแบบจำลองการเรียนรู้เชิงลึก ที่ทดสอบในการจำแนกช่วงเวลาเริ่มเพาะปลูกข้าวได้อย่างน่าเชื่อถือ

ตาราง 28 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพอนุกรมเวลา SAR โพลาริเซชัน VH+VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	เดือนพฤษภาคม	0.40	0.42	0.41	36.91%	0.15	273.11
	เดือนมิถุนายน	0.16	0.45	0.23			294.18
	เดือนกรกฎาคม	0.27	0.30	0.29			44.9
	เดือนสิงหาคม	0.63	0.36	0.46			127.48
GRU	เดือนพฤษภาคม	0.30	0.58	0.40	43.05%	0.24	500.98
	เดือนมิถุนายน	0.18	0.35	0.24			25.43
	เดือนกรกฎาคม	0.51	0.34	0.41			147.67
	เดือนสิงหาคม	0.70	0.50	0.58			65.59
LSTM	เดือนพฤษภาคม	0.54	0.37	0.44	42.34%	0.23	371.5
	เดือนมิถุนายน	0	0	0			17.91
	เดือนกรกฎาคม	0.35	0.34	0.35			287.62
	เดือนสิงหาคม	0.78	0.52	0.63			62.64
BI-LSTM	เดือนพฤษภาคม	0.43	0.33	0.37	41.14%	0.21	114.44
	เดือนมิถุนายน	0.23	0.41	0.30			472.21
	เดือนกรกฎาคม	0.01	0.09	0.02			80.18
	เดือนสิงหาคม	0.93	0.48	0.63			72.85

ตาราง 28 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนก ช่วงระยะเวลาเริ่มเพาะปลูกข้าว 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมเวลา SAR ที่รวมข้อมูลทั้งโพลาริเซชัน VH และ VV เข้าด้วยกัน (28 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินโดยรวมเผยให้เห็นว่า แม้จะรวมข้อมูลทั้งสองโพลาริเซชันแล้ว ประสิทธิภาพในการจำแนกช่วงระยะเวลาเริ่มเพาะปลูกด้วยข้อมูลอนุกรมเวลาเต็มก็ยังคงอยู่ในระดับที่ต่ำมาก สำหรับทุกแบบจำลอง โดยค่าความถูกต้องโดยรวม (OA) อยู่ในช่วงเพียง 36.91% ถึง 43.05%

และค่าสัมประสิทธิ์แคปปาต่ำมาก (0.15 ถึง 0.24) ไม่ได้แสดงให้เห็นถึงการปรับปรุงที่ชัดเจนจากการใช้โพลาริเซชันเดียว และบ่งชี้ถึงความสับสนอย่างมากในการแยกแยะระหว่างเดือนต่างๆ เมื่อพิจารณาจากคลาสพบว่า การจำแนกยังคงเป็นไปได้ยากและมีข้อผิดพลาดสูง ค่า F1-Score ส่วนใหญ่อยู่ในระดับต่ำ โดยเฉพาะคลาสเดือนมิถุนายน และ เดือนกรกฎาคม เป็นปัญหาอย่างยิ่ง เช่น LSTM ไม่สามารถจำแนกคลาสเดือนมิถุนายน ได้เลย ($F1=0$) และ BI-LSTM จำแนกคลาสเดือนกรกฎาคม ได้ด้วย F1-Score เพียง 0.02 แม้คลาสเดือนสิงหาคม จะดูแยกแยะได้ดีที่สุด แต่ก็มี F1-Score สูงสุดเพียง 0.63 (LSTM, BI-LSTM) เท่านั้น

เมื่อเปรียบเทียบประสิทธิภาพโดยรวมระหว่างแบบจำลอง GRU เป็นแบบจำลองที่ให้ผลดีที่สุดในกลุ่ม ด้วย OA 43.05% และ KC 0.24 แต่ประสิทธิภาพระดับนี้ก็ยังถือว่าต่ำมาก ตามมาด้วย LSTM (OA 42.34%), BI-LSTM (OA 41.14%), และ RNN (OA 36.91%) โดยสรุป ผลการทดลองนี้ตอกย้ำว่าการใช้ข้อมูลอนุกรมเวลา SAR แบบเต็ม (28 ช่วงเวลา) แม้จะรวม VH และ VV เข้าด้วยกัน ก็ ยังไม่มีประสิทธิภาพเพียงพอ สำหรับโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึกที่ทดสอบในการจำแนกช่วงเวลาเริ่มเพาะปลูกข้าวได้อย่างน่าเชื่อถือ

ตาราง 29 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนก ช่วงระยะเวลาเริ่มเพาะปลูกข้าว 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลอนุกรมค่าเฉลี่ยภาพ SAR ที่ใช้โพลาริเซชัน VH เพียงอย่างเดียว (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินแสดงให้เห็นว่า การใช้ข้อมูลค่าเฉลี่ยรายเดือน VH ช่วย ปรับปรุงประสิทธิภาพการจำแนกช่วงเวลาเริ่มเพาะปลูกให้ดีขึ้นอย่างมีนัยสำคัญ เมื่อเทียบกับการใช้ข้อมูลอนุกรมเวลาเต็ม VH ก่อนหน้านี้ โดยค่าความถูกต้องโดยรวม (OA) อยู่ในช่วง 64.90% ถึง 71.65% และค่าสัมประสิทธิ์แคปปาอยู่ในช่วง 0.53 ถึง 0.62 ถือว่าอยู่ในระดับปานกลาง คลาสเดือนสิงหาคม ถูกจำแนกได้ดีที่สุด โดยมีค่า F1-Score สูงในช่วง 0.84 ถึง 0.91 RNN ให้ผลดีที่สุดสำหรับคลาสนี้ ตามมาด้วย BI-LSTM คลาสเดือนกรกฎาคม และ เดือนมิถุนายน มีประสิทธิภาพรองลงมา โดย F1-Score สำหรับ เดือนกรกฎาคม อยู่ที่ 0.67-0.76 (BI-LSTM ดีที่สุด) และสำหรับ เดือนมิถุนายน อยู่ที่ 0.59-0.63 ส่วนคลาสเดือนพฤษภาคม ยังคงเป็นคลาสที่จำแนกได้ยากที่สุด แม้ว่า BI-LSTM จะให้ F1-Score ดีขึ้นเป็น 0.61 แต่แบบจำลองอื่นยังให้ผลค่อนข้างต่ำ

เมื่อเปรียบเทียบประสิทธิภาพโดยรวมระหว่างแบบจำลอง BI-LSTM เป็นแบบจำลองที่ให้ค่า OA สูงที่สุดที่ 71.65% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.62 ตามมาด้วย GRU (OA 69.60%, KC 0.59) ส่วน LSTM และ RNN ให้ประสิทธิภาพประกอบต่ำกว่า ผลลัพธ์นี้ชี้ให้เห็นว่าการรวมข้อมูลเป็นค่าเฉลี่ยรายเดือนสำหรับโพลาริเซชัน VH ช่วยเพิ่มความสามารถในการแยกแยะเดือนที่เริ่ม

เพาะปลูกได้ดีขึ้น โดยเฉพาะกับโครงข่ายประสาทเทียม BI-LSTM และ GRU แม้ว่าความแม่นยำโดยรวมจะยังอยู่ในระดับปานกลาง และยังมีความท้าทายในการจำแนกเดือนที่เริ่มปลูกเร็วกว่า (เดือนพฤษภาคม, เดือนมิถุนายน) อยู่

ตาราง 29 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	เดือนพฤษภาคม	0.22	0.51	0.31	64.90%	0.53	19.05
	เดือนมิถุนายน	0.82	0.48	0.60			119.24
	เดือนกรกฎาคม	0.58	0.79	0.67			157.87
	เดือนสิงหาคม	0.97	0.86	0.91			443.52
GRU	เดือนพฤษภาคม	0.46	0.66	0.54	69.60%	0.59	8.72
	เดือนมิถุนายน	0.69	0.58	0.63			122.89
	เดือนกรกฎาคม	0.86	0.66	0.75			249.01
	เดือนสิงหาคม	0.78	0.93	0.85			359.06
LSTM	เดือนพฤษภาคม	0.21	0.71	0.33	65.74%	0.54	12.45
	เดือนมิถุนายน	0.84	0.50	0.63			49.13
	เดือนกรกฎาคม	0.78	0.67	0.72			278.04
	เดือนสิงหาคม	0.81	0.89	0.84			400.05
BI-LSTM	เดือนพฤษภาคม	0.59	0.64	0.61	71.65%	0.62	12.46
	เดือนมิถุนายน	0.59	0.60	0.59			191.28
	เดือนกรกฎาคม	0.79	0.72	0.76			254.35
	เดือนสิงหาคม	0.89	0.90	0.89			281.58

ตาราง 30 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	เดือนพฤษภาคม	0.41	0.67	0.51	59.54%	0.46	16.19
	เดือนมิถุนายน	0.68	0.47	0.56			133.53
	เดือนกรกฎาคม	0.56	0.53	0.54			146.57
	เดือนสิงหาคม	0.73	0.82	0.77			443.38
GRU	เดือนพฤษภาคม	0.51	0.63	0.56	63.77%	0.52	39.59
	เดือนมิถุนายน	0.36	0.63	0.45			185.1
	เดือนกรกฎาคม	0.68	0.56	0.61			226.9
	เดือนสิงหาคม	1.00	0.71	0.83			288.08
LSTM	เดือนพฤษภาคม	0.48	0.61	0.54	61.71%	0.49	35.67
	เดือนมิถุนายน	0.37	0.57	0.45			175.08
	เดือนกรกฎาคม	0.70	0.54	0.61			262.08
	เดือนสิงหาคม	0.92	0.72	0.80			266.84
BI-LSTM	เดือนพฤษภาคม	0.55	0.51	0.53	51.09%	0.35	57.83
	เดือนมิถุนายน	0.20	0.36	0.26			95.26
	เดือนกรกฎาคม	0.53	0.45	0.49			286.06
	เดือนสิงหาคม	0.76	0.64	0.70			300.53

ตาราง 30 แสดงผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนก ช่วงระยะเวลา เริ่มเพาะปลูกข้าว 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึกโครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่ใช้โพลาริเซชัน VV เพียงอย่างเดียว (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาส และค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินแสดงให้เห็นว่า ประสิทธิภาพการจำแนกช่วงเวลาเริ่มเพาะปลูกด้วยข้อมูล ค่าเฉลี่ยรายเดือน VV อยู่ใน ระดับปานกลาง โดยค่าความถูกต้องโดยรวม (OA) อยู่ในช่วง 51.09% (BI-LSTM) ถึง 63.77% (GRU) และค่าสัมประสิทธิ์แคปปาอยู่ในช่วง 0.35 ถึง 0.52 โดยทั่วไปดีกว่า การใช้ข้อมูลอนุกรมเวลา VV แบบเต็ม แต่ยังไม่สูงนัก คลาสเดือนสิงหาคม เป็นคลาสที่ถูกจำแนกได้ดี

ที่สุด โดยเฉพาะแบบจำลอง GRU ($F1=0.83$ พร้อม Precision 1.00) และ LSTM ($F1=0.80$) ที่ให้ผลลัพธ์ดี คลาสเดือนกรกฎาคม และ เดือนพฤษภาคม มีประสิทธิภาพรองลงมาในระดับปานกลาง ($F1$ ประมาณ 0.5-0.6) อย่างไรก็ตาม คลาสเดือนมิถุนายน ยังคงเป็นคลาสที่จำแนกได้ยากที่สุด โดยมีค่า F1-Score ค่อนข้างต่ำในทุกแบบจำลอง โดยเฉพาะ BI-LSTM ($F1=0.26$)

ตาราง 31 ค่า Precision Recall และ F1-Score แต่ละคลาสของข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV

Classifier	Class	Precision	Recall	F1-Score	OA	KC	พื้นที่ (ตร.กม)
RNN	เดือนพฤษภาคม	0.60	0.53	0.56	65.68%	0.54	0
	เดือนมิถุนายน	0.34	0.58	0.43			0.11
	เดือนกรกฎาคม	0.79	0.64	0.71			71.59
	เดือนสิงหาคม	0.87	0.85	0.86			667.97
GRU	เดือนพฤษภาคม	0.75	0.52	0.61	66.98%	0.56	18.37
	เดือนมิถุนายน	0.35	0.61	0.44			38.6
	เดือนกรกฎาคม	0.71	0.73	0.73			138.27
	เดือนสิงหาคม	0.85	0.84	0.84			544.43
LSTM	เดือนพฤษภาคม	0.29	0.66	0.40	66.15%	0.55	44.43
	เดือนมิถุนายน	0.76	0.51	0.61			104.99
	เดือนกรกฎาคม	0.76	0.67	0.71			282.9
	เดือนสิงหาคม	0.81	0.90	0.85			307.35
BI-LSTM	เดือนพฤษภาคม	0.84	0.49	0.62	66.75%	0.56	1.1
	เดือนมิถุนายน	0.17	0.63	0.26			2.46
	เดือนกรกฎาคม	0.76	0.73	0.75			110.73
	เดือนสิงหาคม	0.88	0.87	0.88			625.39

เมื่อเปรียบเทียบประสิทธิภาพโดยรวม Gated Recurrent Unit (GRU) เป็นแบบจำลองที่ให้ค่า OA สูงที่สุดที่ 63.77% และค่าสัมประสิทธิ์แคปปาสูงสุดที่ 0.52 ตามมาด้วย LSTM (OA 61.71%, KC 0.49) และ RNN (OA 59.54%, KC 0.46) ส่วน BI-LSTM ให้ประสิทธิภาพต่ำที่สุดในกลุ่มนี้ (OA 51.09%, KC 0.35) ผลลัพธ์นี้ชี้ให้เห็นว่าข้อมูลค่าเฉลี่ยรายเดือน VV สามารถช่วย

ปรับปรุงการจำแนกช่วงเวลาเพาะปลูกได้บ้างเมื่อเทียบกับข้อมูลอนุกรมเวลาเต็ม VV โดยเฉพาะเมื่อใช้กับ GRU แต่ประสิทธิภาพโดยรวมยังคงต่ำกว่าการใช้ข้อมูลค่าเฉลี่ยรายเดือน VH อย่างมีนัยสำคัญ

ตาราง 31 นำเสนอผลการประเมินประสิทธิภาพโดยละเอียดของการจำแนก ช่วงระยะเวลาเริ่มเพาะปลูกข้าว 4 คลาสด้วยแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) เมื่อใช้ ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน ที่รวมข้อมูลทั้งโพลาไรเซชัน VH และ VV เข้าด้วยกัน (12 ช่วงเวลา) เป็นข้อมูลนำเข้า ตารางแสดงค่า Precision, Recall, F1-Score สำหรับแต่ละคลาสและค่าความถูกต้องโดยรวม (OA) กับค่าสัมประสิทธิ์แคปปา (KC) ของแต่ละแบบจำลอง

ผลการประเมินแสดงให้เห็นว่า การใช้ข้อมูลค่าเฉลี่ยรายเดือน VH+VV ให้ประสิทธิภาพการจำแนกช่วงเวลาเริ่มเพาะปลูกอยู่ใน ระดับปานกลาง โดยค่าความถูกต้องโดยรวม (OA) อยู่ในช่วงประมาณ 65.7% ถึง 67.0% และค่าสัมประสิทธิ์แคปปาอยู่ในช่วง 0.54 ถึง 0.56 เป็นผลลัพธ์ที่ดีที่สุดเมื่อเทียบกับข้อมูลนำเข้ารูปแบบอื่นๆ สำหรับภารกิจนี้ แต่ก็ยังไม่สูงมากนัก คลาสเดือนสิงหาคม ถูกจำแนกได้ดีที่สุด โดยมีค่า F1-Score อยู่ในช่วง 0.84 ถึง 0.88 (BI-LSTM ดีที่สุด) คลาสเดือนกรกฎาคม มีประสิทธิภาพรองลงมาในระดับดี ($F1=0.71-0.75$) โดย BI-LSTM ให้ผลดีที่สุดอีกครั้ง คลาสเดือนพฤษภาคม มีประสิทธิภาพปานกลาง ($F1=0.40-0.62$) BI-LSTM ยังคงให้ค่า F1 สูงสุด อย่างไรก็ตาม คลาสเดือนมิถุนายน ยังคงเป็นคลาสที่ท้าทายอย่างยิ่ง โดยเฉพาะสำหรับ BI-LSTM ที่มีค่า F1-Score ต่ำมากเพียง 0.26 ในขณะที่ LSTM ให้ค่า F1 สูงสุดสำหรับคลาสนี้ที่ 0.61


เมื่อเปรียบเทียบประสิทธิภาพโดยรวมระหว่างแบบจำลอง พบว่า GRU เป็นแบบจำลองที่ให้ค่า OA สูงที่สุดเล็กน้อยที่ 66.98% แต่ GRU และ BI-LSTM ให้ค่าสัมประสิทธิ์แคปปาสูงสุดเท่ากันที่ 0.56 ตามมาด้วย LSTM (OA 66.15%, KC 0.55) และ RNN (OA 65.68%, KC 0.54) ทั้งหมดให้ผลลัพธ์ที่ใกล้เคียงกันมาก โดยรวมแล้ว แม้ว่าข้อมูลค่าเฉลี่ยรายเดือน VH+VV จะให้ผลลัพธ์ที่ดีที่สุดสำหรับการจำแนกช่วงเวลาเริ่มเพาะปลูกด้วยการเรียนรู้เชิงลึก ในการศึกษาครั้งนี้ แต่ประสิทธิภาพโดยรวมก็ยังอยู่ในระดับปานกลาง และยังคงมีความท้าทายอย่างมากในการจำแนกคลาสเดือนมิถุนายน (โดยเฉพาะกับ BI-LSTM) และคลาสเดือนพฤษภาคม

ตาราง 32 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกร่วมกับข้อมูลภาพอนุกรมเวลา SAR


	VH	VV	VH+VV																																																																																										
RNN	<table><tr><td>May</td><td>0.43</td><td>0.20</td><td>0.20</td><td>0.17</td></tr><tr><td>June</td><td>0.12</td><td>0.45</td><td>0.24</td><td>0.20</td></tr><tr><td>July</td><td>0.13</td><td>0.34</td><td>0.26</td><td>0.26</td></tr><tr><td>Aug</td><td>0.20</td><td>0.21</td><td>0.26</td><td>0.33</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.43	0.20	0.20	0.17	June	0.12	0.45	0.24	0.20	July	0.13	0.34	0.26	0.26	Aug	0.20	0.21	0.26	0.33		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.49</td><td>0.20</td><td>0.24</td><td>0.08</td></tr><tr><td>June</td><td>0.18</td><td>0.36</td><td>0.35</td><td>0.10</td></tr><tr><td>July</td><td>0.21</td><td>0.24</td><td>0.47</td><td>0.08</td></tr><tr><td>Aug</td><td>0.19</td><td>0.15</td><td>0.20</td><td>0.45</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.49	0.20	0.24	0.08	June	0.18	0.36	0.35	0.10	July	0.21	0.24	0.47	0.08	Aug	0.19	0.15	0.20	0.45		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.42</td><td>0.20</td><td>0.24</td><td>0.14</td></tr><tr><td>June</td><td>0.20</td><td>0.45</td><td>0.21</td><td>0.14</td></tr><tr><td>July</td><td>0.14</td><td>0.31</td><td>0.30</td><td>0.25</td></tr><tr><td>Aug</td><td>0.21</td><td>0.20</td><td>0.23</td><td>0.36</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.42	0.20	0.24	0.14	June	0.20	0.45	0.21	0.14	July	0.14	0.31	0.30	0.25	Aug	0.21	0.20	0.23	0.36		May	June	July	Aug	True label	Predicted label			
May	0.43	0.20	0.20	0.17																																																																																									
June	0.12	0.45	0.24	0.20																																																																																									
July	0.13	0.34	0.26	0.26																																																																																									
Aug	0.20	0.21	0.26	0.33																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.49	0.20	0.24	0.08																																																																																									
June	0.18	0.36	0.35	0.10																																																																																									
July	0.21	0.24	0.47	0.08																																																																																									
Aug	0.19	0.15	0.20	0.45																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.42	0.20	0.24	0.14																																																																																									
June	0.20	0.45	0.21	0.14																																																																																									
July	0.14	0.31	0.30	0.25																																																																																									
Aug	0.21	0.20	0.23	0.36																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
GRU	<table><tr><td>May</td><td>0.77</td><td>0.23</td><td>0.00</td><td>0.00</td></tr><tr><td>June</td><td>0.36</td><td>0.59</td><td>0.05</td><td>0.00</td></tr><tr><td>July</td><td>0.24</td><td>0.30</td><td>0.46</td><td>0.00</td></tr><tr><td>Aug</td><td>0.15</td><td>0.16</td><td>0.18</td><td>0.51</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.77	0.23	0.00	0.00	June	0.36	0.59	0.05	0.00	July	0.24	0.30	0.46	0.00	Aug	0.15	0.16	0.18	0.51		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.37</td><td>0.30</td><td>0.34</td><td>0.00</td></tr><tr><td>June</td><td>0.36</td><td>0.26</td><td>0.28</td><td>0.16</td></tr><tr><td>July</td><td>0.17</td><td>0.27</td><td>0.38</td><td>0.19</td></tr><tr><td>Aug</td><td>0.19</td><td>0.17</td><td>0.20</td><td>0.44</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.37	0.30	0.34	0.00	June	0.36	0.26	0.28	0.16	July	0.17	0.27	0.38	0.19	Aug	0.19	0.17	0.20	0.44		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.58</td><td>0.42</td><td>0.00</td><td>0.00</td></tr><tr><td>June</td><td>0.23</td><td>0.35</td><td>0.40</td><td>0.03</td></tr><tr><td>July</td><td>0.22</td><td>0.24</td><td>0.34</td><td>0.21</td></tr><tr><td>Aug</td><td>0.15</td><td>0.17</td><td>0.18</td><td>0.50</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.58	0.42	0.00	0.00	June	0.23	0.35	0.40	0.03	July	0.22	0.24	0.34	0.21	Aug	0.15	0.17	0.18	0.50		May	June	July	Aug	True label	Predicted label			
May	0.77	0.23	0.00	0.00																																																																																									
June	0.36	0.59	0.05	0.00																																																																																									
July	0.24	0.30	0.46	0.00																																																																																									
Aug	0.15	0.16	0.18	0.51																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.37	0.30	0.34	0.00																																																																																									
June	0.36	0.26	0.28	0.16																																																																																									
July	0.17	0.27	0.38	0.19																																																																																									
Aug	0.19	0.17	0.20	0.44																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.58	0.42	0.00	0.00																																																																																									
June	0.23	0.35	0.40	0.03																																																																																									
July	0.22	0.24	0.34	0.21																																																																																									
Aug	0.15	0.17	0.18	0.50																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
LSTM	<table><tr><td>May</td><td>0.42</td><td>0.33</td><td>0.25</td><td>0.00</td></tr><tr><td>June</td><td>0.42</td><td>0.56</td><td>0.02</td><td>0.00</td></tr><tr><td>July</td><td>0.24</td><td>0.28</td><td>0.46</td><td>0.03</td></tr><tr><td>Aug</td><td>0.14</td><td>0.15</td><td>0.17</td><td>0.54</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.42	0.33	0.25	0.00	June	0.42	0.56	0.02	0.00	July	0.24	0.28	0.46	0.03	Aug	0.14	0.15	0.17	0.54		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.64</td><td>0.19</td><td>0.14</td><td>0.03</td></tr><tr><td>June</td><td>0.31</td><td>0.35</td><td>0.34</td><td>0.00</td></tr><tr><td>July</td><td>0.14</td><td>0.32</td><td>0.44</td><td>0.10</td></tr><tr><td>Aug</td><td>0.19</td><td>0.15</td><td>0.20</td><td>0.46</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.64	0.19	0.14	0.03	June	0.31	0.35	0.34	0.00	July	0.14	0.32	0.44	0.10	Aug	0.19	0.15	0.20	0.46		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.37</td><td>0.35</td><td>0.26</td><td>0.02</td></tr><tr><td>June</td><td>0.00</td><td>0.00</td><td>0.00</td><td>0.00</td></tr><tr><td>July</td><td>0.22</td><td>0.23</td><td>0.34</td><td>0.20</td></tr><tr><td>Aug</td><td>0.14</td><td>0.17</td><td>0.17</td><td>0.52</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.37	0.35	0.26	0.02	June	0.00	0.00	0.00	0.00	July	0.22	0.23	0.34	0.20	Aug	0.14	0.17	0.17	0.52		May	June	July	Aug	True label	Predicted label			
May	0.42	0.33	0.25	0.00																																																																																									
June	0.42	0.56	0.02	0.00																																																																																									
July	0.24	0.28	0.46	0.03																																																																																									
Aug	0.14	0.15	0.17	0.54																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.64	0.19	0.14	0.03																																																																																									
June	0.31	0.35	0.34	0.00																																																																																									
July	0.14	0.32	0.44	0.10																																																																																									
Aug	0.19	0.15	0.20	0.46																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.37	0.35	0.26	0.02																																																																																									
June	0.00	0.00	0.00	0.00																																																																																									
July	0.22	0.23	0.34	0.20																																																																																									
Aug	0.14	0.17	0.17	0.52																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
BI-LSTM	<table><tr><td>May</td><td>0.29</td><td>0.27</td><td>0.26</td><td>0.19</td></tr><tr><td>June</td><td>0.28</td><td>0.43</td><td>0.23</td><td>0.06</td></tr><tr><td>July</td><td>0.21</td><td>0.05</td><td>0.57</td><td>0.17</td></tr><tr><td>Aug</td><td>0.13</td><td>0.18</td><td>0.17</td><td>0.52</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.29	0.27	0.26	0.19	June	0.28	0.43	0.23	0.06	July	0.21	0.05	0.57	0.17	Aug	0.13	0.18	0.17	0.52		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.60</td><td>0.22</td><td>0.16</td><td>0.03</td></tr><tr><td>June</td><td>0.21</td><td>0.38</td><td>0.40</td><td>0.02</td></tr><tr><td>July</td><td>0.12</td><td>0.23</td><td>0.56</td><td>0.09</td></tr><tr><td>Aug</td><td>0.19</td><td>0.16</td><td>0.22</td><td>0.43</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.60	0.22	0.16	0.03	June	0.21	0.38	0.40	0.02	July	0.12	0.23	0.56	0.09	Aug	0.19	0.16	0.22	0.43		May	June	July	Aug	True label	Predicted label				<table><tr><td>May</td><td>0.33</td><td>0.32</td><td>0.32</td><td>0.04</td></tr><tr><td>June</td><td>0.35</td><td>0.41</td><td>0.24</td><td>0.01</td></tr><tr><td>July</td><td>0.41</td><td>0.27</td><td>0.09</td><td>0.23</td></tr><tr><td>Aug</td><td>0.15</td><td>0.16</td><td>0.21</td><td>0.48</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td>True label</td><td colspan="4">Predicted label</td></tr></table>	May	0.33	0.32	0.32	0.04	June	0.35	0.41	0.24	0.01	July	0.41	0.27	0.09	0.23	Aug	0.15	0.16	0.21	0.48		May	June	July	Aug	True label	Predicted label			
May	0.29	0.27	0.26	0.19																																																																																									
June	0.28	0.43	0.23	0.06																																																																																									
July	0.21	0.05	0.57	0.17																																																																																									
Aug	0.13	0.18	0.17	0.52																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.60	0.22	0.16	0.03																																																																																									
June	0.21	0.38	0.40	0.02																																																																																									
July	0.12	0.23	0.56	0.09																																																																																									
Aug	0.19	0.16	0.22	0.43																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												
May	0.33	0.32	0.32	0.04																																																																																									
June	0.35	0.41	0.24	0.01																																																																																									
July	0.41	0.27	0.09	0.23																																																																																									
Aug	0.15	0.16	0.21	0.48																																																																																									
	May	June	July	Aug																																																																																									
True label	Predicted label																																																																																												

ตาราง 33 เมตริกซ์ความคลาดเคลื่อนของแบบจำลองการเรียนรู้เชิงลึกข้อมูลอนุกรมค่าเฉลี่ยภาพ SAR


	VH	VV	VH+VV																																																																																										
RNN	<table><tr><td>May</td><td>0.51</td><td>0.21</td><td>0.29</td><td>0.00</td></tr><tr><td>June</td><td>0.43</td><td>0.48</td><td>0.09</td><td>0.00</td></tr><tr><td>July</td><td>0.08</td><td>0.09</td><td>0.79</td><td>0.04</td></tr><tr><td>Aug</td><td>0.00</td><td>0.01</td><td>0.13</td><td>0.86</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.51	0.21	0.29	0.00	June	0.43	0.48	0.09	0.00	July	0.08	0.09	0.79	0.04	Aug	0.00	0.01	0.13	0.86		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.67</td><td>0.13</td><td>0.18</td><td>0.02</td></tr><tr><td>June</td><td>0.31</td><td>0.47</td><td>0.16</td><td>0.05</td></tr><tr><td>July</td><td>0.10</td><td>0.19</td><td>0.53</td><td>0.18</td></tr><tr><td>Aug</td><td>0.05</td><td>0.04</td><td>0.09</td><td>0.82</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.67	0.13	0.18	0.02	June	0.31	0.47	0.16	0.05	July	0.10	0.19	0.53	0.18	Aug	0.05	0.04	0.09	0.82		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.53</td><td>0.39</td><td>0.08</td><td>0.00</td></tr><tr><td>June</td><td>0.41</td><td>0.58</td><td>0.01</td><td>0.00</td></tr><tr><td>July</td><td>0.11</td><td>0.15</td><td>0.64</td><td>0.10</td></tr><tr><td>Aug</td><td>0.00</td><td>0.02</td><td>0.13</td><td>0.85</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.53	0.39	0.08	0.00	June	0.41	0.58	0.01	0.00	July	0.11	0.15	0.64	0.10	Aug	0.00	0.02	0.13	0.85		May	June	July	Aug		Predicted label			
	May	0.51	0.21	0.29	0.00																																																																																								
	June	0.43	0.48	0.09	0.00																																																																																								
	July	0.08	0.09	0.79	0.04																																																																																								
	Aug	0.00	0.01	0.13	0.86																																																																																								
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.67	0.13	0.18	0.02																																																																																									
June	0.31	0.47	0.16	0.05																																																																																									
July	0.10	0.19	0.53	0.18																																																																																									
Aug	0.05	0.04	0.09	0.82																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.53	0.39	0.08	0.00																																																																																									
June	0.41	0.58	0.01	0.00																																																																																									
July	0.11	0.15	0.64	0.10																																																																																									
Aug	0.00	0.02	0.13	0.85																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
GRU	<table><tr><td>May</td><td>0.66</td><td>0.28</td><td>0.06</td><td>0.00</td></tr><tr><td>June</td><td>0.38</td><td>0.58</td><td>0.04</td><td>0.00</td></tr><tr><td>July</td><td>0.08</td><td>0.08</td><td>0.66</td><td>0.17</td></tr><tr><td>Aug</td><td>0.00</td><td>0.00</td><td>0.07</td><td>0.93</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.66	0.28	0.06	0.00	June	0.38	0.58	0.04	0.00	July	0.08	0.08	0.66	0.17	Aug	0.00	0.00	0.07	0.93		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.63</td><td>0.28</td><td>0.09</td><td>0.00</td></tr><tr><td>June</td><td>0.28</td><td>0.63</td><td>0.09</td><td>0.00</td></tr><tr><td>July</td><td>0.20</td><td>0.24</td><td>0.56</td><td>0.00</td></tr><tr><td>Aug</td><td>0.06</td><td>0.09</td><td>0.13</td><td>0.71</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.63	0.28	0.09	0.00	June	0.28	0.63	0.09	0.00	July	0.20	0.24	0.56	0.00	Aug	0.06	0.09	0.13	0.71		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.52</td><td>0.38</td><td>0.10</td><td>0.00</td></tr><tr><td>June</td><td>0.32</td><td>0.61</td><td>0.08</td><td>0.00</td></tr><tr><td>July</td><td>0.05</td><td>0.08</td><td>0.73</td><td>0.14</td></tr><tr><td>Aug</td><td>0.00</td><td>0.03</td><td>0.12</td><td>0.84</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.52	0.38	0.10	0.00	June	0.32	0.61	0.08	0.00	July	0.05	0.08	0.73	0.14	Aug	0.00	0.03	0.12	0.84		May	June	July	Aug		Predicted label			
	May	0.66	0.28	0.06	0.00																																																																																								
	June	0.38	0.58	0.04	0.00																																																																																								
	July	0.08	0.08	0.66	0.17																																																																																								
	Aug	0.00	0.00	0.07	0.93																																																																																								
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.63	0.28	0.09	0.00																																																																																									
June	0.28	0.63	0.09	0.00																																																																																									
July	0.20	0.24	0.56	0.00																																																																																									
Aug	0.06	0.09	0.13	0.71																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.52	0.38	0.10	0.00																																																																																									
June	0.32	0.61	0.08	0.00																																																																																									
July	0.05	0.08	0.73	0.14																																																																																									
Aug	0.00	0.03	0.12	0.84																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
LSTM	<table><tr><td>May</td><td>0.71</td><td>0.15</td><td>0.15</td><td>0.00</td></tr><tr><td>June</td><td>0.44</td><td>0.50</td><td>0.05</td><td>0.00</td></tr><tr><td>July</td><td>0.07</td><td>0.09</td><td>0.67</td><td>0.17</td></tr><tr><td>Aug</td><td>0.00</td><td>0.01</td><td>0.10</td><td>0.89</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.71	0.15	0.15	0.00	June	0.44	0.50	0.05	0.00	July	0.07	0.09	0.67	0.17	Aug	0.00	0.01	0.10	0.89		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.61</td><td>0.29</td><td>0.08</td><td>0.02</td></tr><tr><td>June</td><td>0.33</td><td>0.57</td><td>0.07</td><td>0.02</td></tr><tr><td>July</td><td>0.18</td><td>0.23</td><td>0.54</td><td>0.05</td></tr><tr><td>Aug</td><td>0.06</td><td>0.09</td><td>0.14</td><td>0.72</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.61	0.29	0.08	0.02	June	0.33	0.57	0.07	0.02	July	0.18	0.23	0.54	0.05	Aug	0.06	0.09	0.14	0.72		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.66</td><td>0.20</td><td>0.15</td><td>0.00</td></tr><tr><td>June</td><td>0.41</td><td>0.51</td><td>0.08</td><td>0.00</td></tr><tr><td>July</td><td>0.06</td><td>0.11</td><td>0.67</td><td>0.16</td></tr><tr><td>Aug</td><td>0.00</td><td>0.02</td><td>0.09</td><td>0.90</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.66	0.20	0.15	0.00	June	0.41	0.51	0.08	0.00	July	0.06	0.11	0.67	0.16	Aug	0.00	0.02	0.09	0.90		May	June	July	Aug		Predicted label			
	May	0.71	0.15	0.15	0.00																																																																																								
	June	0.44	0.50	0.05	0.00																																																																																								
	July	0.07	0.09	0.67	0.17																																																																																								
	Aug	0.00	0.01	0.10	0.89																																																																																								
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.61	0.29	0.08	0.02																																																																																									
June	0.33	0.57	0.07	0.02																																																																																									
July	0.18	0.23	0.54	0.05																																																																																									
Aug	0.06	0.09	0.14	0.72																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.66	0.20	0.15	0.00																																																																																									
June	0.41	0.51	0.08	0.00																																																																																									
July	0.06	0.11	0.67	0.16																																																																																									
Aug	0.00	0.02	0.09	0.90																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
BI-LSTM	<table><tr><td>May</td><td>0.64</td><td>0.31</td><td>0.05</td><td>0.00</td></tr><tr><td>June</td><td>0.34</td><td>0.60</td><td>0.06</td><td>0.00</td></tr><tr><td>July</td><td>0.08</td><td>0.10</td><td>0.72</td><td>0.10</td></tr><tr><td>Aug</td><td>0.00</td><td>0.00</td><td>0.10</td><td>0.90</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.64	0.31	0.05	0.00	June	0.34	0.60	0.06	0.00	July	0.08	0.10	0.72	0.10	Aug	0.00	0.00	0.10	0.90		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.51</td><td>0.36</td><td>0.09</td><td>0.04</td></tr><tr><td>June</td><td>0.33</td><td>0.36</td><td>0.26</td><td>0.05</td></tr><tr><td>July</td><td>0.14</td><td>0.26</td><td>0.45</td><td>0.15</td></tr><tr><td>Aug</td><td>0.08</td><td>0.10</td><td>0.18</td><td>0.64</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.51	0.36	0.09	0.04	June	0.33	0.36	0.26	0.05	July	0.14	0.26	0.45	0.15	Aug	0.08	0.10	0.18	0.64		May	June	July	Aug		Predicted label				<table><tr><td>May</td><td>0.49</td><td>0.42</td><td>0.09</td><td>0.00</td></tr><tr><td>June</td><td>0.33</td><td>0.63</td><td>0.04</td><td>0.00</td></tr><tr><td>July</td><td>0.06</td><td>0.10</td><td>0.73</td><td>0.11</td></tr><tr><td>Aug</td><td>0.00</td><td>0.03</td><td>0.10</td><td>0.87</td></tr><tr><td></td><td>May</td><td>June</td><td>July</td><td>Aug</td></tr><tr><td></td><td colspan="4">Predicted label</td></tr></table>	May	0.49	0.42	0.09	0.00	June	0.33	0.63	0.04	0.00	July	0.06	0.10	0.73	0.11	Aug	0.00	0.03	0.10	0.87		May	June	July	Aug		Predicted label			
	May	0.64	0.31	0.05	0.00																																																																																								
	June	0.34	0.60	0.06	0.00																																																																																								
	July	0.08	0.10	0.72	0.10																																																																																								
	Aug	0.00	0.00	0.10	0.90																																																																																								
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.51	0.36	0.09	0.04																																																																																									
June	0.33	0.36	0.26	0.05																																																																																									
July	0.14	0.26	0.45	0.15																																																																																									
Aug	0.08	0.10	0.18	0.64																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												
May	0.49	0.42	0.09	0.00																																																																																									
June	0.33	0.63	0.04	0.00																																																																																									
July	0.06	0.10	0.73	0.11																																																																																									
Aug	0.00	0.03	0.10	0.87																																																																																									
	May	June	July	Aug																																																																																									
	Predicted label																																																																																												




ภาพประกอบ 41 ผลการจำแนกช่วงเวลาการปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกข้อมูลอนุกรม
ค่าเฉลี่ยภาพ SAR




(A) VH Mean (RNN)




(B) VV Mean (RNN)




(C) VH+VV Mean (RNN)




(D) VH Mean (GRU)




(E) VV Mean (GRU)




(F) VH + VV Mean (GRU)




(G) VH Mean (LSTM)




(H) VV Mean (LSTM)




(I) VH + VV Mean (LSTM)



(J) VH Mean (Bi-LSTM)



(K) VV Mean (Bi-LSTM)




(L) VH + VV Mean (Bi-LSTM)

ภาพประกอบ 42 ผลการจำแนกพื้นที่ปลูกข้าวด้วยแบบจำลองการเรียนรู้เชิงลึกข้อมูลอนุกรม
ค่าเฉลี่ยภาพ SAR

จากการสรุปและเปรียบเทียบประสิทธิภาพด้านความถูกต้องโดยรวมของแบบจำลองการเรียนรู้เชิงลึก 4 โครงข่ายประสาทเทียม (RNN, GRU, LSTM, BI-LSTM) สำหรับการจำแนกช่วงระยะเวลาเริ่มเพาะปลูกข้าว โดยใช้ข้อมูลนำเข้า SAR ที่แตกต่างกัน 6 รูปแบบ (ข้อมูลอนุกรมเวลาเต็ม 28 ช่วงเวลา และข้อมูลค่าเฉลี่ยรายเดือน 12 ช่วงเวลา สำหรับโพลาไรเซชัน VH, VV, และ VH+VV) เมื่อใช้ข้อมูลอนุกรมเวลาแบบเต็ม 28 ช่วงเวลา พบว่าประสิทธิภาพโดยรวมที่ได้อยู่ในระดับต่ำอย่างมีนัยสำคัญในทุกกรณี บ่งชี้ถึงความยากลำบากในการจำแนกช่วงเวลาเพาะปลูกด้วยข้อมูลรูปแบบนี้ โดยข้อมูลโพลาไรเซชัน VH ให้ผลลัพธ์ที่ GRU มี OA สูงสุดที่ 52.11% ตามมาด้วย LSTM ที่ 49.70% สำหรับโพลาไรเซชัน VV, LSTM ให้ OA สูงสุดที่ 46.08% ตามด้วย BI-LSTM ที่ 44.51% และเมื่อใช้โพลาไรเซชัน VH+VV, GRU ให้ OA สูงสุดที่ 43.05% ตามด้วย LSTM ที่ 42.34%

เมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือน 12 ช่วงเวลา ประสิทธิภาพโดยรวมดีขึ้นอย่างชัดเจนเมื่อเทียบกับการใช้ข้อมูลอนุกรมเวลาแบบเต็ม โดยข้อมูลโพลาไรเซชัน VH, BI-LSTM ให้ OA สูงสุดที่ 71.65% ตามด้วย GRU ที่ 69.60% สำหรับโพลาไรเซชัน VV, GRU ให้ OA สูงสุดที่ 63.77% ตามด้วย LSTM ที่ 61.71% และเมื่อใช้โพลาไรเซชัน VH+VV, GRU ให้ OA สูงสุดที่ 66.98% ตามมาด้วย BI-LSTM ที่ 66.75% และ LSTM ที่ 66.15% ให้ผลใกล้เคียงกันมาก

จากการเปรียบเทียบความถูกต้องโดยรวม ชี้ให้เห็นว่าข้อมูลค่าเฉลี่ยรายเดือนให้ผลการจำแนกช่วงเวลาเพาะปลูกที่ดีกว่าข้อมูลอนุกรมเวลาเต็มอย่างชัดเจนสำหรับทุกโพลาไรเซชันและทุกแบบจำลองการเรียนรู้เชิงลึกที่ทดสอบ โดยเฉพาะอย่างยิ่งข้อมูลค่าเฉลี่ยรายเดือนโพลาไรเซชัน VH ร่วมกับโครงข่ายประสาทเทียม BI-LSTM ให้ค่าความถูกต้องโดยรวมสูงสุดในการทดลองส่วนนี้ที่ 71.65% นอกจากนี้ โครงข่ายประสาทเทียม GRU และ BI-LSTM มักจะให้ประสิทธิภาพประกอบดีกว่า RNN และ LSTM ในหลายกรณี โดยเฉพาะเมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือน ทั้งนี้ ผลการจำแนกเชิงพื้นที่จากกรณีที่ดีที่สุด (ข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาไรเซชัน VH ร่วมกับโครงข่าย BI-LSTM) ได้ถูกนำไปเปรียบเทียบกับข้อมูลการเพาะปลูกข้าวนาปี ปี พ.ศ. 2565 จากสำนักงานเศรษฐกิจการเกษตร ดังแสดงใน ภาพประกอบ 26



ภาพประกอบ 43 ผลการจำแนกช่วงเวลาเพาะปลูกข้าวด้วยข้อมูลภาพค่าเฉลี่ย SAR รายเดือน โพลาริเซชัน VH+VV ร่วมกับโครงข่าย BI-LSTM เทียบกับข้อมูลการเพาะปลูกข้าวนาปี ปี พ.ศ.2565 จากสำนักงานเศรษฐกิจการเกษตร

ในการเปรียบเทียบประสิทธิภาพระหว่างแบบจำลองการเรียนรู้ของเครื่อง (SVM, RF, XGBoost, ANN) และการเรียนรู้เชิงลึก (RNN, GRU, LSTM, BI-LSTM) เพื่อจำแนกประเภทการใช้ประโยชน์ที่ดิน 4 คลาส (พื้นที่ปลูกข้าว, เกษตรกรรม, แหล่งน้ำ, และพื้นที่เมืองและอื่นๆ) พบว่าการใช้ข้อมูลทั้งสองโพลาริเซชัน (VH+VV) ให้ประสิทธิภาพสูงสุดในทุกกรณี ทั้งนี้การใช้ข้อมูลภาพค่าเฉลี่ยรายเดือน (12 ช่วงเวลา) ให้ผลลัพธ์ที่ยอดเยี่ยมและสูงกว่าหรือเทียบเท่ากับการใช้ข้อมูลอนุกรมเวลาแบบเต็ม (28 ช่วงเวลา) โดยแบบจำลองการเรียนรู้ของเครื่อง Random Forest (RF) ให้ค่าความถูกต้องโดยรวมสูงที่สุดที่ 93.73% เมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือน VH+VV ในขณะที่แบบจำลองการเรียนรู้เชิงลึก GRU ให้ค่าความถูกต้องโดยรวมสูงที่สุดที่ 92.44% บนข้อมูลชุดเดียวกัน ผลลัพธ์นี้ชี้ว่าสำหรับภารกิจจำแนกพื้นที่ปลูกข้าวและประเภทที่ดินโดยรวม แบบจำลองการเรียนรู้ของเครื่องมีประสิทธิภาพสูงมากและให้ผลลัพธ์ที่ดีกว่าการเรียนรู้เชิงลึกเล็กน้อยในการศึกษาครั้งนี้

ในการจำแนกช่วงเวลาเริ่มเพาะปลูกข้าว 4 ช่วง (พฤษภาคม, มิถุนายน, กรกฎาคม, สิงหาคม) โดยใช้แบบจำลองการเรียนรู้เชิงลึก พบว่าข้อมูลนำเข้ามีผลต่อประสิทธิภาพอย่างยิ่ง การใช้ข้อมูลอนุกรมเวลาแบบเต็ม (28 ช่วงเวลา) ให้ประสิทธิภาพที่ต่ำมากในทุกกรณี (ค่าความถูกต้องโดยรวมต่ำกว่า 53%) ในทางตรงกันข้าม การใช้ข้อมูลค่าเฉลี่ยรายเดือน (12 ช่วงเวลา) ช่วยเพิ่ม

ประสิทธิภาพการจำแนกได้อย่างมีนัยสำคัญ โดยให้ผลลัพธ์ที่ดีที่สุดคือ โครงข่ายประสาทเทียม BI-LSTM ที่ใช้ข้อมูลค่าเฉลี่ยรายเดือนโพลาริเซชัน VH เพียงอย่างเดียว ให้ค่าความถูกต้องโดยรวมสูงสุดที่ 71.65% ผลลัพธ์นี้แสดงให้เห็นว่าภารกิจการจำแนกช่วงเวลาเพาะปลูกมีความซับซ้อนและท้าทายกว่าการจำแนกพื้นที่ปลูกข้าวอย่างมากและการแปลงข้อมูลเป็นค่าเฉลี่ยรายเดือนเป็นขั้นตอนสำคัญที่ช่วยให้แบบจำลองสามารถเรียนรู้ลักษณะเด่นของแต่ละช่วงเวลาได้ดีขึ้น

จากผลการทดลองทั้งหมดนี้ ชี้ให้เห็นว่าข้อมูลอนุกรมเวลา SAR จากดาวเทียม Sentinel-1 มีศักยภาพสูงในการจำแนกพื้นที่เพาะปลูกข้าวและช่วงเวลาเพาะปลูก แต่ประสิทธิภาพสูงสุดขึ้นอยู่กับ การเลือกรูปแบบข้อมูลนำเข้าและโครงข่ายประสาทเทียมให้เหมาะสมกับวัตถุประสงค์ของงาน จะได้นำไปอภิปรายและสรุปผลในบทต่อไป



บทที่ 5

อภิปรายและสรุปผล

การศึกษาการเรียนรู้เชิงลึกในการจำแนกช่วงการปลูกข้าวด้วยข้อมูลอนุกรมเวลาภาพถ่ายจากดาวเทียมระบบ SAR เพื่อทำการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องในการจำแนกพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR พัฒนาระบบการเรียนรู้เชิงลึกในการจำแนกที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR และศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR กรณีศึกษาอำเภอเมือง จังหวัดสุพรรณบุรี แบ่งการสรุปผลการวิจัยและอภิปรายผลการวิจัยออกเป็น 3 ส่วน ประกอบด้วย ส่วนแรกเป็นผลการจำแนกพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้ของเครื่อง ส่วนที่สองเป็นผลการจำแนกพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้ของการเรียนรู้เชิงลึก และส่วนสุดท้ายเป็นผลการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR ด้วยการเรียนรู้เชิงลึก

5.1 อภิปรายผลการศึกษา

การประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่อง เพื่อจำแนกพื้นที่เพาะปลูกข้าวจากการวิเคราะห์ข้อมูลอนุกรมเวลาของดาวเทียม Sentinel-1 SAR ในการศึกษาี้ แสดงให้เห็นถึงศักยภาพที่โดดเด่นและให้ผลลัพธ์ที่มีความแม่นยำในระดับสูงอย่างยิ่ง การเลือกใช้ข้อมูล SAR ถือเป็นยุทธศาสตร์ที่เหมาะสมอย่างยิ่งสำหรับการติดตามการเกษตรในประเทศไทย มักเผชิญกับข้อจำกัดจากเมฆปกคลุมในช่วงฤดูฝนเป็นฤดูเพาะปลูกหลัก คุณสมบัติของ SAR ที่สามารถบันทึกภาพได้ในทุกสภาพอากาศและความไวต่อการเปลี่ยนแปลงลักษณะทางกายภาพของพื้นผิว เช่น ความชื้น, ความขรุขระ และโครงสร้างของพืชพรรณ ทำให้สามารถติดตามพลวัตของแปลงนาข้าวตั้งแต่ช่วงเตรียมดินที่มีน้ำท่วมขังไปจนถึงระยะการเจริญเติบโตของต้นข้าว และระยะเก็บเกี่ยวได้อย่างต่อเนื่อง ผลการวิจัยชี้ให้เห็นว่าแบบจำลองการเรียนรู้ของเครื่อง โดยเฉพาะกลุ่มที่เป็น Ensemble Learning เช่น Random Forest (RF) และ XGBoost รวมถึง Support Vector Machine (SVM) สามารถเรียนรู้และสร้างแบบจำลองการจำแนกที่มีประสิทธิภาพสูงจากข้อมูลอนุกรมเวลาดังกล่าว

ปัจจัยสำคัญที่สุดที่ส่งผลต่อประสิทธิภาพของแบบจำลองคือการกำหนดค่าข้อมูลนำเข้า (Input Data Configuration) ผลการวิจัยชี้ชัดว่า การใช้ข้อมูลที่ผนวกรวมทั้งสองโพลาไรเซชัน (VH+VV) ให้ประสิทธิภาพการจำแนกสูงกว่าการใช้โพลาไรเซชันเดียวในทุกกรณีการทดลอง

ปรากฏการณ์นี้สามารถอธิบายได้จากคุณสมบัติทางกายภาพของการสะท้อนกลับของสัญญาณเรดาร์โพลาไรเซชัน VV มีความไวต่อการกระเจิงของพื้นผิว (surface scattering) และโครงสร้างในแนวตั้งจึงสามารถแยกแยะลักษณะของผิวน้ำในแปลงนาหรือดินที่เปียกชื้นได้ดี ในขณะที่โพลาไรเซชัน VH เป็นการโพลาไรซ์ไขว้ (cross-polarization) มีความไวต่อการกระเจิงเชิงปริมาตร (volume scattering) ที่เกิดขึ้นเมื่อสัญญาณทะลุทะลวงและเกิดการสะท้อนหลายครั้งภายในเรือนยอดของพืช ดังนั้น การมีข้อมูลทั้งสองประเภทจึงช่วยให้แบบจำลองได้รับข้อมูลที่สมบูรณ์และรอบด้านเกี่ยวกับลักษณะของแปลงข้าวในแต่ละช่วงเวลา ทำให้สามารถแยกพื้นที่ปลูกข้าวออกจากสิ่งปกคลุมดินประเภทอื่นที่มีลักษณะการสะท้อนกลับแตกต่างกันได้อย่างชัดเจนยิ่งขึ้น สอดคล้องกับข้อสรุปจากงานวิจัยของ (Abdikan et al., 2016) ที่พบว่าการรวมลักษณะเด่นจากหลายโพลาไรเซชันช่วยเพิ่มความแม่นยำในการจำแนกได้อย่างมีนัยสำคัญ

ประเด็นที่น่าสนใจอย่างยิ่งคือผลกระทบของการประมวลผลข้อมูลเชิงเวลา แม้ว่าข้อมูลอนุกรมเวลาแบบเต็ม (Full Time Series) จะให้ข้อมูลที่มีความละเอียดเชิงเวลาสูงสุด แต่ผลการทดลองกลับพบว่า ข้อมูลค่าเฉลี่ยรายเดือน (Monthly Mean Composites) สามารถให้ประสิทธิภาพการจำแนกที่สูงที่สุด โดยแบบจำลอง Random Forest (RF) สามารถทำค่าความถูกต้องโดยรวมได้สูงสุดถึง 93.73% เมื่อใช้ข้อมูลค่าเฉลี่ยรายเดือนของ VH+VV การที่ข้อมูลค่าเฉลี่ยรายเดือนให้ผลลัพธ์ที่ดีกว่า อาจเนื่องมาจากการที่กระบวนการหาค่าเฉลี่ยทำหน้าที่เป็นตัวกรองสัญญาณรบกวน (noise filtering) ที่มีประสิทธิภาพ ช่วยลดทอนความผันผวนของสัญญาณในระยะสั้นอาจไม่ได้เกิดจากการเจริญเติบโตของพืชโดยตรง แต่เกิดจากปัจจัยอื่น เช่น สภาพอากาศ, ลม, หรือปริมาณน้ำฝนที่เปลี่ยนแปลงรายวัน การกรองสัญญาณรบกวนนี้ทำให้พลวัตและแนวโน้มการเปลี่ยนแปลงทางชีวลักษณะของข้าวในภาพรวมของแต่ละเดือนปรากฏเด่นชัดขึ้น ส่งผลให้แบบจำลองการเรียนรู้ของเครื่องสามารถสร้างขอบเขตการตัดสินใจ (decision boundaries) ที่มีความแม่นยำและเสถียรภาพมากขึ้น

การวิจัยนี้ได้ยืนยันว่าแบบจำลองการเรียนรู้ของเครื่อง โดยเฉพาะอย่างยิ่ง Random Forest, XGBoost และ SVM เป็นเครื่องมือที่มีประสิทธิภาพสูงและเชื่อถือได้สำหรับการจำแนกพื้นที่ปลูกข้าวด้วยข้อมูลอนุกรมเวลา Sentinel-1 ความสำเร็จนี้ไม่ได้ขึ้นอยู่กับพลังของอัลกอริทึมเพียงอย่างเดียว แต่ขึ้นอยู่กับกระบวนการเตรียมข้อมูลอย่างพิถีพิถัน ทั้งในมิติของการผสมผสานข้อมูลจากหลายโพลาไรเซชันเพื่อเพิ่มความสามารถในการแยกแยะ และการประมวลผลเชิงเวลาเพื่อสกัดสัญญาณที่สะท้อนถึงการเปลี่ยนแปลงทางชีวลักษณะที่แท้จริงของพืช เป็นแนวทางที่นำไปสู่การพัฒนาแผนที่พื้นที่ปลูกข้าวที่มีความแม่นยำสูงสำหรับการประยุกต์ใช้ในลำดับต่อไป

การประยุกต์ใช้โครงข่ายประสาทเทียมของการเรียนรู้เชิงลึกได้รับการออกแบบมาเพื่อวิเคราะห์ข้อมูลอนุกรมเวลาโดยเฉพาะ ได้แสดงให้เห็นถึงศักยภาพที่สูงมากในการจำแนกพื้นที่ปลูก

ข่าวจากการเปลี่ยนแปลงของสัญญาณ SAR แบบจำลองที่ทดสอบ อาทิ Recurrent Neural Network (RNN), Gated Recurrent Unit (GRU), Long-Short Term Memory (LSTM), และ Bidirectional Long-Short Term Memory (BI-LSTM) สามารถเรียนรู้ความสัมพันธ์เชิงเวลาที่ซับซ้อน (temporal dependencies) ในข้อมูลอนุกรมเวลาได้โดยอัตโนมัติ เป็นข้อได้เปรียบเชิงทฤษฎีที่สำคัญเมื่อเทียบกับแบบจำลองการเรียนรู้ของเครื่องแบบดั้งเดิม ผลการศึกษาพบว่าโครงข่ายประสาทเทียม GRU ให้ประสิทธิภาพสูงสุดในกลุ่มนี้ ด้วยค่าความถูกต้องโดยรวมที่น่าพอใจอย่างยิ่งถึง 92.44% ผลลัพธ์นี้มีความสอดคล้องอย่างยิ่งกับงานวิจัยของ (Ndikumana et al., 2018) และ (Niculescu et al., 2018) ได้ทำการเปรียบเทียบแบบจำลองหลายชนิดและพบว่า GRU สามารถให้ประสิทธิภาพที่สูงกว่าแบบจำลองการเรียนรู้ของเครื่องอย่าง Random Forest ในการจำแนกประเภทพืชพรรณจากข้อมูล Sentinel-1

อย่างไรก็ตาม ประเด็นที่น่าสนใจในการศึกษานี้คือ แม้ว่าแบบจำลองการเรียนรู้เชิงลึกจะให้ผลลัพธ์ที่ดีเยี่ยม แต่ค่าความถูกต้องสูงสุดที่ได้ (92.44% จาก GRU) ยังคงต่ำกว่าแบบจำลอง Random Forest (93.73%) เล็กน้อย ข้อค้นพบนี้ไม่ได้หมายความว่า การเรียนรู้เชิงลึกมีประสิทธิภาพด้อยกว่า แต่ชี้ให้เห็นถึงความจริงที่ว่าสำหรับชุดข้อมูลและการกักการจำแนกประเภทที่มีลักษณะเฉพาะนี้ แบบจำลองการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงและได้รับการปรับจูนอย่างเหมาะสมสามารถให้ผลลัพธ์ที่แข่งขันได้หรือเหนือกว่า

เช่นเดียวกับผลการทดลองในกลุ่มการเรียนรู้ของเครื่อง ปัจจัยด้านการเตรียมข้อมูลมีอิทธิพลอย่างยิ่งต่อประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก การใช้ข้อมูลที่ผนวกรวมโพลาไรเซชัน VH และ VV เข้าด้วยกัน ให้ผลลัพธ์ที่ดีกว่าการใช้โพลาไรเซชันเดี่ยวอย่างชัดเจน ข้อมูลที่สมบูรณ์จากทั้งการกระเจิงเชิงปริมาตร (VH) และการกระเจิงจากพื้นผิว/โครงสร้าง (VV) ทำให้โครงข่ายประสาทเทียมสามารถเรียนรู้คุณลักษณะที่ใช้แยกแยะนาข้าวออกจากสิ่งปกคลุมดินประเภทอื่นได้อย่างมีประสิทธิภาพ นอกจากนี้ ข้อค้นพบที่สำคัญคือ ข้อมูลค่าเฉลี่ยรายเดือนให้ประสิทธิภาพสูงสุด การทำ Temporal Aggregation ในลักษณะนี้ทำหน้าที่คล้ายกับการกรองสัญญาณรบกวนความถี่สูง (high-frequency noise) ออกจากอนุกรมเวลา ทำให้แบบจำลองสามารถมุ่งเน้นการเรียนรู้ไปที่แนวโน้มการเปลี่ยนแปลงทางซีฟลักซ์ที่สำคัญของข้าวได้ดียิ่งขึ้น ไม่เพียงแต่ช่วยเพิ่มความแม่นยำ แต่ยังมีประโยชน์ในทางปฏิบัติในการลดความซับซ้อนและภาระการประมวลผลของแบบจำลอง

โครงข่ายประสาทเทียมของการเรียนรู้เชิงลึก โดยเฉพาะ GRU, LSTM และ BI-LSTM ได้พิสูจน์ให้เห็นว่าเป็นเครื่องมือที่มีประสิทธิภาพสูงอย่างยิ่งสำหรับการจำแนกพื้นที่ปลูกข้าวด้วยข้อมูล SAR โดยให้ความแม่นยำในระดับที่ทัดเทียมกับแบบจำลองการเรียนรู้ของเครื่องที่ดีที่สุด ความสำเร็จนี้ขึ้นอยู่กับทางเลือกใช้ข้อมูลที่เหมาะสม (VH+VV) และการประมวลผลข้อมูลเชิงเวลาที่ช่วยสกัด

สัญญาณที่สำคัญออกมา เป็นแนวทางที่แสดงให้เห็นถึงศักยภาพในการพัฒนาระบบติดตามพื้นที่เกษตรกรรมที่มีความแม่นยำและน่าเชื่อถือต่อไป

การจำแนกพื้นที่เพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาจากภาพ SAR ด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกแสดงให้เห็นถึงประสิทธิภาพและความแม่นยำที่สูงในการศึกษาที่สอดคล้องกับคุณสมบัติเด่นของ SAR ที่สามารถถ่ายภาพทะลุเมฆได้ตลอดเวลา ทำให้ติดตามการเปลี่ยนแปลงพื้นที่เพาะปลูกได้อย่างต่อเนื่อง การศึกษานี้ได้ใช้ประโยชน์จากข้อมูลทั้ง ข้อมูลอนุกรมเวลาแบบเต็ม (28 ช่วงเวลา) ให้รายละเอียดการเปลี่ยนแปลงสูง เหมาะกับการติดตามระยะการเจริญเติบโตที่รวดเร็ว และ ข้อมูลค่าเฉลี่ยรายเดือน (12 ช่วงเวลา) ที่ช่วยลดภาระการประมวลผลและจับแนวโน้มภาพรวมได้ดีแม้ความละเอียดเชิงเวลาจะน้อยลง นอกจากนี้ การใช้โพลาริเซชัน VH และ VV ไวต่อลักษณะทางกายภาพและความชื้นที่แตกต่างกันในแต่ละระยะของข้าว พบว่า การรวมข้อมูล VH และ VV (VH+VV) ช่วยเพิ่มประสิทธิภาพการจำแนกได้อย่างชัดเจน เนื่องจากให้ข้อมูลที่สมบูรณ์กว่า ทำให้แบบจำลองแยกแยะนาข้าวออกจากพื้นที่ประเภทอื่นได้ดีขึ้น (Abdikan et al., 2016) (Kussul et al., 2017) ข้อมูล SAR ยังสามารถสะท้อนการเปลี่ยนแปลงทางกายภาพในแปลงนา เช่น ช่วงน้ำขังเปรียบเทียบกับช่วงข้าวโตเต็มที่ เป็นข้อมูลสำคัญที่แบบจำลองใช้เรียนรู้ (Turkar et al., 2011) (Ndikumana et al., 2018)

เมื่อเปรียบเทียบประสิทธิภาพระหว่างวิธีการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก สำหรับการจำแนกพื้นที่ปลูกข้าวโดยรวม พบว่า ทั้งสองกลุ่มวิธีการสามารถให้ผลลัพธ์ที่มีความแม่นยำสูงมากและใกล้เคียงกัน โดยเฉพาะเมื่อใช้ข้อมูล VH+VV แบบจำลองการเรียนรู้ของเครื่อง เช่น Random Forest (RF) และ XGBoost สามารถให้ค่าความถูกต้องโดยรวมสูงสุดได้ (ประมาณ 93%) แสดงให้เห็นถึงประสิทธิภาพประกอบยอดเยี่ยมเมื่อมีการปรับปรุงพารามิเตอร์ที่เหมาะสม ในขณะเดียวกันแบบจำลองการเรียนรู้เชิงลึกโดยเฉพาะโครงข่ายประสาทเทียมแบบ Recurrent เช่น GRU, LSTM และ BI-LSTM ก็ให้ประสิทธิภาพประกอบสูงมากเช่นกัน (สูงสุดประมาณ 92% สำหรับ GRU) แม้ว่าการทดลองนี้ ค่าความถูกต้องโดยรวมสูงสุดที่ได้จากการเรียนรู้ของเครื่อง อาจน้อยเล็กน้อย แต่การเรียนรู้เชิงลึกมีข้อได้เปรียบเชิงทฤษฎีที่สำคัญในการเรียนรู้ลำดับและความสัมพันธ์เชิงเวลาที่ซับซ้อน (temporal dependencies) โดยอัตโนมัติ อาจเป็นประโยชน์อย่างยิ่งในการวิเคราะห์ข้อมูลอนุกรมเวลาที่มีความละเอียดสูง (เช่น ข้อมูลเต็ม 28 ช่วงเวลา) และจับการเปลี่ยนแปลงที่ละเอียดอ่อนได้ดีกว่าก็ตาม (Niculescu et al., 2018) (Jo et al., 2020; Zhao et al., 2019) แบบจำลองการเรียนรู้ของเครื่อง เช่น RF และ XGBoost ก็ยังคงแสดงให้เห็นว่าเป็นทางเลือกที่มีประสิทธิภาพสูง โดยเฉพาะกับข้อมูลที่มีการลดทอนความซับซ้อนลงบ้าง เช่น ข้อมูลค่าเฉลี่ยรายเดือน

การใช้ข้อมูลอนุกรมเวลาภาพ SAR โดยเฉพาะการรวม VH+VV เป็นแนวทางที่มีประสิทธิภาพสูงในการจำแนกพื้นที่เพาะปลูกข้าว ทั้งแบบจำลองการเรียนรู้ของเครื่อง (เช่น RF,

XGBoost) และการเรียนรู้เชิงลึก (เช่น GRU, LSTM, BI-LSTM) ต่างก็ให้ผลลัพธ์ที่น่าพอใจและมีความแม่นยำสูง เมื่อได้รับการปรับจนเหมาะสม การเลือกใช้วิธีการและรูปแบบข้อมูล (อนุกรมเวลาเต็ม หรือ ค่าเฉลี่ยรายเดือน) อาจขึ้นอยู่กับความต้องการด้านความละเอียดในการวิเคราะห์เปรียบเทียบกับความเร็วและทรัพยากรในการประมวลผล การศึกษาในอนาคตอาจพิจารณาใช้ข้อมูลที่มีความละเอียดสูงขึ้น หรือประยุกต์ใช้โครงข่ายประสาทเทียมของการเรียนรู้เชิงลึก ที่ทันสมัยยิ่งขึ้น เช่น Transformers เพื่อพัฒนาประสิทธิภาพต่อไป

5.2 สรุปผลการศึกษา

การศึกษาวิจัยครั้งนี้มีวัตถุประสงค์ในการศึกษาประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าวโดยใช้ข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR โดยมีการดำเนินการเปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR และพัฒนากระบวนการเรียนรู้เชิงลึกในการสกัดพื้นที่เพาะปลูกข้าวจากข้อมูลอนุกรมเวลาที่ได้จากข้อมูลภาพ SAR โดยใช้ข้อมูลอนุกรมเวลาภาพถ่ายดาวเทียมระบบ SAR จากดาวเทียม Sentinel-1 จำนวน 28 ภาพ ปี พ.ศ. 2565 ครอบคลุมพื้นที่ศึกษาจังหวัดสุพรรณบุรี ผลการจากการทดสอบประสิทธิภาพของการเรียนรู้ของเครื่องในการจำแนกพื้นที่ปลูกข้าว พบว่าข้อมูลค่าเฉลี่ยรายเดือน VH+VV ร่วมกับแบบจำลอง Random Forest มีความถูกต้องโดยรวมสูงสุด 93.73% จากนั้นดำเนินการทดสอบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึก พบว่าโครงข่ายประสาทเทียม BI-LSTM ร่วมกับข้อมูลค่าเฉลี่ยรายเดือน VH+VV มีความถูกต้องโดยรวมสูงสุด 92.44% และการทดสอบประสิทธิภาพของการเรียนรู้เชิงลึกในการจำแนกช่วงระยะเวลาในการเพาะปลูกข้าว พบว่าประสิทธิภาพในการจำแนกมีความแตกต่างกันอย่างชัดเจนระหว่างการใช้ข้อมูลอนุกรมเวลาและข้อมูลค่าเฉลี่ยรายเดือน ผลการทดสอบพบว่าข้อมูลค่าเฉลี่ยรายเดือนให้ค่าความถูกต้องสูงกว่าข้อมูลอนุกรมเวลาอย่างมีนัยสำคัญในทุกกรณี โดยแบบจำลองที่ใช้ข้อมูลค่าเฉลี่ยรายเดือนให้ค่าความถูกต้องโดยรวมอยู่ในช่วงประมาณ 64% ถึง 72% ขณะที่แบบจำลองที่ใช้ข้อมูลอนุกรมเวลาเต็มให้ค่าความถูกต้องโดยรวมอยู่ต่ำกว่า 53% เมื่อพิจารณาข้อมูลนำเข้าและแบบจำลองที่ให้ประสิทธิภาพสูงสุด พบว่าข้อมูลค่าเฉลี่ยรายเดือนโพลาไรเซชัน VH เมื่อนำมาประมวลผลด้วยโครงข่ายประสาทเทียม BI-LSTM ให้ค่าความถูกต้องโดยรวมสูงที่สุดที่ 71.65%

5.3 ข้อเสนอแนะ

สามารถแบ่งออกได้เป็นสามประเด็นหลักเพื่อเพิ่มประสิทธิภาพและความสามารถในการจำแนก ดังนี้

1. การบูรณาการข้อมูลจากหลายแหล่ง (Sensor Fusion) โดยข้อมูล Synthetic Aperture Radar (SAR) จะมีประโยชน์ในการติดตามอย่างต่อเนื่อง แต่การรวมข้อมูลจากดาวเทียมระบบออปติคัล เช่น Sentinel-2 และ Landsat อาจช่วยเพิ่มความแม่นยำในการจำแนกชนิดพืชที่หลากหลาย รวมถึงปรับปรุงการจำแนกข้าวในบางระยะหรือสภาพแวดล้อมที่ข้อมูล SAR อาจมีข้อจำกัด โดยเฉพาะการใช้ดัชนีพืชพรรณ เช่น Normalized Difference Vegetation Index (NDVI), Enhanced Vegetation Index (EVI) หรือดัชนีความชื้น เช่น Normalized Difference Water Index (NDWI), Soil Moisture Index (SMI)

2. การใช้ลักษณะเด่นขั้นสูงจาก SAR ก็เป็นสิ่งจำเป็น นอกเหนือจากค่า Backscatter โดยตรง ควรพิจารณาสกัดและใช้ลักษณะเด่นอื่น ๆ เช่น ลักษณะพื้นผิว (Texture analysis - Gray Level Co-occurrence Matrix - GLCM) ข้อมูล Coherence หรือเทคนิค Polarimetric Decomposition เพื่อเพิ่มความสามารถในการแยกแยะ อีกทั้งการทดสอบโครงข่ายประสาทเทียมที่ทันสมัย อาทิ Transformers มีศักยภาพในการจับความสัมพันธ์ระยะยาวในข้อมูลอนุกรมเวลาได้ดียิ่งขึ้น หรือพิจารณาแบบจำลองที่ออกแบบมาสำหรับ Sensor Fusion โดยเฉพาะ

3. การประเมินความสามารถในการประยุกต์ใช้ในพื้นที่หลากหลาย เนื่องจากแบบจำลองที่พัฒนาขึ้นในการศึกษานี้ได้ทดสอบในพื้นที่จังหวัดสุพรรณบุรี ควรขยายการทดสอบและประเมินประสิทธิภาพของแบบจำลองไปยังพื้นที่อื่น ๆ ที่มีลักษณะภูมิประเทศและสภาพภูมิอากาศแตกต่างกัน เช่น พื้นที่ในภาคเหนือ ภาคตะวันออกเฉียงเหนือ หรือภาคใต้ของประเทศไทย การศึกษาเปรียบเทียบบนี้จะช่วยให้เข้าใจถึงความสามารถในการถ่ายโอน (Transferability) และความทนทาน (Robustness) ของแบบจำลอง ตลอดจนผลกระทบของปัจจัยเชิงพื้นที่ที่แตกต่างกันต่อประสิทธิภาพการจำแนก จะนำไปสู่การปรับปรุงแบบจำลองหรือเทคนิคให้สามารถประยุกต์ใช้ได้อย่างเหมาะสม และน่าเชื่อถือในแต่ละภูมิภาคต่อไป

บรรณานุกรม



ประวัติผู้เขียน



- Abdikan, S., Sanli, F. B., Ustuner, M., & Calo, F. (2016). *LAND COVER MAPPING USING SENTINEL-1 SAR DATA*.
- Ahishali, M., Kiranyaz, S., Ince, T., & Gabbouj, M. (2019). Dual and Single Polarized SAR Image Classification Using Compact Convolutional Neural Networks. *Remote Sens.*, 11(1340). doi:10.3390/rs11111340
- Alpaydin, E. (2020). *Introduction to Machine Learning*. Cambridge: MIT Press.
- Aobpaet, A. (2022). Monitoring of crop growth stages using Sentinel-1 synthetic aperture radar data. *AGRICULTURE AND NATURAL RESOURCES*, 56(2), 307.
- B, P., K.P., S., & Kumar, M. A. (2018). A deep learning approach for Malayalam morphological analysis at character level. *Procedia Comput. Sci.*, 132(C), 47–54. doi:10.1016/j.procs.2018.05.058
- Bazzi, H., Baghdadi, N., El Hajj, M., Zribi, M., Minh, D. H. T., Ndikumana, E., . . . Belhoucette, H. (2019). Mapping Paddy Rice Using Sentinel-1 SAR Time Series in Camargue, France. *Remote Sens.*, 11(887).
- Bishop, C. (2006). Pattern Recognition and Machine Learning. In (Vol. 16, pp. 140-155).
- Breiman, L. (2001). Random Forests. *Machine Learning*, 45(1), 5-32. doi:10.1023/A:1010933404324
- Camargo, F. F., Sano, E. E., Almeida, C. M., Mura, J. C., & Almeida, T. (2019). A Comparative Assessment of Machine-Learning Techniques for Land use and Land Cover Classification of the Brazilian Tropical Savanna Using ALOS-2/PALSAR-2 Polarimetric Images. *Remote Sens*, 11(1600). doi:10.3390/rs11131600
- Chang, L., Chen, Y. T., Wang, J. H., & Chang, Y. L. (2021). Rice-Field Mapping with Sentinel-1A SAR Time-Series Data. *Remote Sens.*, 13(103).
- Chen, T., & Guestrin, C. (2016). *XGBoost: A Scalable Tree Boosting System*. Paper presented at the Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, California, USA. <https://doi.org/10.1145/2939672.2939785>
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling.
- Cohen, L., Manion, L., & Morrison, K. *Research methods in education*, 6th ed.

- Cortes, C., & Vapnik, V. (2009). Support-vector networks. *Chem. Biol. Drug Des.*, 297, 273-297.
doi:10.1007/%2F00994018
- ESA. (2015). *Radiometric Calibration of S-1 Level-1 Products Generated by the S-1 IPF*. Retrieved from
- Fahad, A., Alshatri, N., Tari, Z., Alamri, A., Khalil, I., Zomaya, A., . . . Bouras, A. (2014). A Survey of Clustering Algorithms for Big Data: Taxonomy and Empirical Analysis. *Emerging Topics in Computing, IEEE Transactions on*, 2, 267-279.
doi:10.1109/TETC.2014.2330519
- Filipponi, F. (2019). Sentinel-1 GRD Preprocessing Workflow. *Proceedings*, 18(1).
doi:10.3390/ECRS-3-06201
- Friedman, J. (2000). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, 29. doi:10.1214/aos/1013203451
- Genc, L., Inalpulat, M., Kizil, U., & Aksu, S. (2014). *Determination Of Paddy Rice Field Using Landsat 8 Images*.
- Goodfellow, I., Bengio, Y., Courville, A., & Bengio, Y. (2016). *Deep learning* (Vol. 1): MIT press Cambridge.
- Hastie, T., Tibshirani, R., & Friedman, J. H. (2009). *The Elements of Statistical Learning: Data Mining, Inference, and Prediction*: Springer.
- Hochreiter, S., & Schmidhuber, J. (1997). Long Short-Term Memory. *Neural Comput.*, 9(8), 1735–1780. doi:10.1162/neco.1997.9.8.1735
- Hu, J., Ghamisi, P., & Zhu, X. X. (2018). Feature Extraction and Selection of Sentinel-1 Dual-Po Data For Global-Scale Local Climate Zone Classification. *ISPRS Int. J. Geo-Inf.*, 7(379).
doi:10.3390/ijgi7090379
- Jain, A. K., Murty, M. N., & Flynn, P. J. (1999). Data clustering: a review. *ACM Comput. Surv.*, 31(3), 264–323. doi:10.1145/331499.331504
- Jang, B., Kim, M., Harerimana, G., Kang, S.-u., & Kim, J. W. (2020). Bi-LSTM Model to Increase Accuracy in Text Classification: Combining Word2vec CNN and Attention Mechanism. *Applied Sciences*, 10(17). doi:10.3390/app10175841
- Jo, H. W., Lee, S., Park, E., Lim, C. H., Song, C., Lee, H., . . . Lee, W. K. (2020). Deep Learning Applications on Multitemporal SAR (Sentinel-1) Image Classification Using Confined

- Labeled Data: The Case of Detecting Rice Paddy in South Korea. *IEEE Transactions on Geoscience and Remote Sensing*, 58(11), 7589-7601.
- Kraemer, H. C. (2015). Kappa Coefficient. In *Wiley StatsRef: Statistics Reference Online* (pp. 1-4).
- Kuenzer, C., & Knauer, K. (2013). Remote sensing of rice crop areas. *International Journal of Remote Sensing*, 34(6), 2101-2139. doi:10.1080/01431161.2012.738946
- Kussul, N., Lavrenik, M., Skakun, S., & Shelestov, A. (2017). Deep Learning Classification of Land Cover and Crop Type Using Remote Sensing Data. *IEEE Geoscience and Remote Sensing Letter*, 15(5).
- LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521, 436-444. doi:10.1038/nature14539
- Liu, C.-a., Chen, Z.-x., Shao, Y., Chen, J.-s., Hasi, T., & Pan, H.-z. (2019). Research advances of SAR remote sensing for agriculture applications: A review. *Journal of Integrative Agriculture*, 18(3), 506-525. doi:[https://doi.org/10.1016/S2095-3119\(18\)62016-7](https://doi.org/10.1016/S2095-3119(18)62016-7)
- Lusch, D. P. (1999). *Introduction To Microwave Remote Sensing: Basic Science and Remote Sensing Initiative*, Department of Geography, Michigan State University.
- Luus, F. P., Salmon, B. P., Van den Bergh, F., & Maharaj, B. T. J. (2015). Multiview deep learning for land-use classification. *IEEE Geoscience and Remote Sensing Letters*, 12(12), 2448-2452.
- Malakouti, S. M., Menhaj, M. B., & Suratgar, A. A. (2023). The usage of 10-fold cross-validation and grid search to enhance ML methods performance in solar farm power generation prediction. *Cleaner Engineering and Technology*, 15, 100664. doi:<https://doi.org/10.1016/j.clet.2023.100664>
- Mienye, I. D., Swart, T. G., & Obaido, G. (2024). Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications. *Information*, 15(9). doi:10.3390/info15090517
- Mitchell, T. M. (1997). *Machine learning* (Vol. 1): McGraw-hill New York.
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to Linear Regression Analysis*: Wiley.

- Ndikumana, E., Minh, D. H. T., Baghdadi, N., Courault, D., & Hossard, L. (2018). Deep Recurrent Neural Network for Agricultural Classification using multitemporal SAR Sentinel-1 for Camargue, France. *Remote Sens.*, 10(1217). doi:10.3390/rs10081217
- Niculescu, S., Ienco, D., & Hanganu, J. (2018). *APPLICATION OF DEEP LEARNING OF MULTI-TEMPORAL SENTINEL-1 IMAGES FOR THE CLASSIFICATION OF COASTAL VEGETATION ZONE OF THE DANUBE DELTA.*
- Phung, H. P., Nguyen, L. D., Nguyen-Huy, T., Le-Toan, T., & Apan, A. A. (2020). Monitoring rice growth status in the Mekong Delta, Vietnam using multitemporal Sentinel-1 data. *Journal of Applied Remote Sensing*, 14(1).
- Prabha, M. I., & Srikanth, G. U. (2019, 25-26 April 2019). *Survey of Sentiment Analysis Using Deep Learning Techniques*. Paper presented at the 2019 1st International Conference on Innovations in Information and Communication Technology (ICIICT).
- Qu, Y., Zhao, W., Yuan, Z., & Chen, J. (2020). Crop Mapping from Sentinel-1 Polarimetric Time-Series with a Deep Neural Network. *Remote Sens.*, 12(2493).
- Russell, S., & Norvig, P. (2010). *Artificial Intelligence: A Modern Approach*. Upper Saddle River: Prentice-Hall.
- Shalev-Shwartz, S., & Ben-David, S. (2013). Understanding Machine Learning: From Theory to Algorithms. *Understanding Machine Learning: From Theory to Algorithms*. doi:10.1017/CBO9781107298019
- Sharav, A. (2003). *Differential SAT Interferometry for Crustal Deformation Study*. International Institute for Geo-information Science and Earth Observation, Enschede, The Netherlands.
- Sirirattanapol, C., Tamkuan, N., Nagai, M., & Ito, M. (2020). *Apply Deep Learning Techniques on Classification of Single-Band SAR Satellite Images*. *Geoinformatics for Sustainable Development in Asian Cities*: Springer.
- Stehman, S. V. (1997). Selecting and interpreting measures of thematic classification accuracy. *Remote Sensing of Environment*, 62(1), 77-89. doi:[https://doi.org/10.1016/S0034-4257\(97\)00083-7](https://doi.org/10.1016/S0034-4257(97)00083-7)
- Turkar, B., Deo, R., Hariharan, S., & Rao, Y. S. (2011). *Comparison of Classification Accuracy between Fully Polarimetric and Dual-Polarization SAR Images*.

- Vapnik, V. N. (1998). *Statistical Learning Theory*: Wiley.
- Wei, P., Ye, H., Qiao, S., Liu, R., Nie, C., Zhang, B., . . . Huang, S. (2023). Early Crop Mapping Based on Sentinel-2 Time-Series Data and the Random Forest Algorithm. *Remote Sensing*, 15(13). doi:10.3390/rs15133212
- Xu, L., Zhang, H., Wang, C., Zhang, B., & Liu, M. (2018). Crop Classification Based on Temporal Information Using Sentinel-1 SAR Time-Series Data. *Remote Sensing*, 11(53). doi:10.3390/rs11010053
- Zhao, H., Chen, Z., Jiang, H., Jing, W., Sun, & Feng, M. (2019). Evaluation of Three Deep Learning Models for Early Crop Classification Using Sentinel-1A Imagery Time Series-A Case Study in Zhanjing China. *Remote Sens.*, 11(2673). doi:10.3390/rs11222673
- Zhou, X., Chang, N.-B., & Li, S. (2009). Applications of SAR interferometry in earth and environmental science research. *Sensors*, 9(3), 1876-1912.
- เริงศักดิ์, ก., & ปาณทัต, ิ. (2554). การใช้ข้อมูล RADARSAT-1 SAR (Standard Mode) เพื่อใช้ในการทำแผนที่แสดงพื้นที่ปลูกข้าวในภาคตะวันออกเฉียงเหนือ. *แก่นเกษตร*, 39, 311-320.
- โปร่งศิริวัฒนา, จ. (2534). ความรู้เรื่องข้าว. กรุงเทพฯ: สถาบันวิจัยข้าว.
- กรมการข้าว. (2555). เทคโนโลยีการปลูกข้าวไร่อย่างยั่งยืน. Retrieved from กรมพัฒนาที่ดิน. (2564). สรุปประเภทการใช้ที่ดิน จังหวัดสุพรรณบุรี ปี พ.ศ. 2564. from กรมพัฒนาที่ดิน
- ถนนมกลิ่น, ณ. (2561). เทคนิคการสำรวจจากระยะไกลเพื่อการตรวจจับพื้นที่ที่มีการเตรียมแปลงปลูกข้าวนาปรังในช่วงต้นฤดูแล้ง กรณีศึกษา ในเขตชลประทานของจังหวัดสุพรรณบุรี. (วิศวกรรมศาสตรมหาบัณฑิต). จุฬาลงกรณ์มหาวิทยาลัย, กรุงเทพฯ.
- ศศิกานต์ ไพลกลาง, ต. แ. แ. ศ. (2563). การจำแนกพื้นที่ปลูกพืชเศรษฐกิจจากข้อมูลดาวเทียมแลนด์แซท8 และข้อมูลทุติยภูมิโดยวิธีซัพพอร์ตเวกเตอร์แมชชีนในพื้นที่ลุ่มน้ำลำเชียงไกรตอนบน. *วารสารวิทยาศาสตร์และเทคโนโลยี*, 28. doi:10.14456/tstj.2020.80
- ศูนย์บริการและถ่ายทอดเทคโนโลยีการเกษตรตำบลศาลาขาว. (2562). แผนพัฒนาการเกษตรระดับตำบล. Retrieved from สำนักงานนโยบายและยุทธศาสตร์การค้า. (2567). การศึกษา:แนวทางการสร้างเสถียรภาพการค้าสินค้าข้าว. Retrieved from
- สุริยะ, ผ., ขาติชาย, ป., & มาขาม, อ. (2559). การศึกษาเปรียบเทียบการใช้ข้อมูลดาวเทียมเรดาร์แซท-2 หลายช่วงเวลาที่ได้รับสัญญาณ โพลาริเซชันแบบ HH และแบบ VV เพื่อประเมินพื้นที่ปลูกข้าวนาปรัง. *วารสารวิจัย มข (บศ)*, 16(4).

อินทร์, ก. (2561). เทคโนโลยีโมเมนตัมซึ่งสำหรับการศึกษาปายาเลน: การจำแนกพันธุ์ไม้ปายาเลนเขตร้อนด้วยภาพถ่ายดาวเทียมและโครงสร้างแบบจำลองชีวมวลของต้นไม้ปายาเลนเขตร้อนด้วยเครื่องสแกนเลเซอร์ภาคพื้นดิน. จุฬาลงกรณ์มหาวิทยาลัย, กรุงเทพฯ.

