



การเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำ
จากภาพถ่ายดาวเทียมแบบอนุกรมเวลา: กรณีศึกษาพื้นที่ลุ่มน้ำโขง

COMPARATIVE ANALYSIS OF SURFACE WATER
CLASSIFICATION MODELS USING SATELLITE IMAGE
TIME-SERIES: A CASE STUDY OF THE MEKONG RIVER BASIN

เจนจิรา วงศ์อุทะ

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2567

การเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำ
จากภาพถ่ายดาวเทียมแบบอนุกรมเวลา: กรณีศึกษาพื้นที่ลุ่มน้ำโขง



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2567
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

COMPARATIVE ANALYSIS OF SURFACE WATER
CLASSIFICATION MODELS USING SATELLITE IMAGE
TIME-SERIES: A CASE STUDY OF THE MEKONG RIVER BASIN



An Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2024

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำ
จากภาพถ่ายดาวเทียมแบบอนุกรมเวลา: กรณีศึกษาพื้นที่ลุ่มน้ำโขง

ของ

เจนจิรา วงศ์อุคะ

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์จักรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

ที่ปรึกษาหลัก

(อาจารย์ ดร.บรรพตวี คมขำ)

ประธาน

(รองศาสตราจารย์ ดร.รัชลิดา ลิปิกรณ์)

กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำ จากภาพถ่ายดาวเทียมแบบอนุกรมเวลา: กรณีศึกษาพื้นที่ลุ่มน้ำโขง
ผู้วิจัย	เจนจิรา วงศ์อุคะ
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2567
อาจารย์ที่ปรึกษา	อาจารย์ ดร. บรรพตริ คมขำ

จากการเปลี่ยนแปลงสภาพภูมิอากาศที่ส่งผลกระทบต่อทั่วโลกในปัจจุบัน การพัฒนาแบบจำลองการจำแนกพื้นที่น้ำที่มีประสิทธิภาพมีความสำคัญต่อการบริหารจัดการทรัพยากรน้ำและการเฝ้าระวังน้ำท่วม งานวิจัยนี้นำเสนอการวิเคราะห์เปรียบเทียบแบบจำลองการจำแนกพื้นที่น้ำโดยใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 แบบอนุกรมเวลา ตั้งแต่วันที่ 8 กุมภาพันธ์ 2020 ถึง 19 ธันวาคม 2023 ในพื้นที่ข้ามพรมแดนของแม่น้ำโขง บริเวณตำบลอาจสามารถ อำเภอเมืองนครพนม จังหวัดนครพนม ประเทศไทย และเกาะดอนโดน เมืองท่าแขก สาธารณรัฐประชาธิปไตยประชาชนลาว โดยงานวิจัยนี้ได้ทำการทดสอบประสิทธิภาพของแบบจำลอง 5 ตัวแบบ ได้แก่ Gaussian Mixture Model (GMM) Logistic Regression (LR) Spectral Index Classification (SIC) DeepWaterMap (DWM) และ WatNet (WN) โดยมีการใช้ recursive classifiers เพื่อปรับปรุงความแม่นยำในการจำแนกพื้นที่น้ำ ผลการทดลองพบว่า GMM ให้ค่าความแม่นยำสูงสุดที่ 90.01% ในขณะที่ WN มีประสิทธิภาพต่ำสุดที่ 68.79% ในขณะที่การใช้ recursive classifiers สามารถช่วยเพิ่มค่าความแม่นยำได้ โดยที่ตัวแบบ GMM มีค่าความแม่นยำสูงสุดที่ 94.36% ซึ่งการใช้ recursive classifiers สามารถช่วยเพิ่มค่าความแม่นยำเฉลี่ยจาก 78.41% เป็น 82.16% ผลการศึกษานี้แสดงให้เห็นถึงความสำคัญของการเลือกแบบจำลองที่เหมาะสมในการจำแนกพื้นที่น้ำจากภาพถ่ายดาวเทียม และ การใช้ recursive classifiers สามารถเพิ่มประสิทธิภาพของแบบจำลองได้อย่างมีนัยสำคัญ การพัฒนาและปรับปรุงแบบจำลองด้วยเทคนิคดังกล่าวไม่เพียงแต่ช่วยเพิ่มความแม่นยำในการจำแนกพื้นที่น้ำ แต่ยังเป็นเครื่องมือสำคัญในการบริหารจัดการทรัพยากรน้ำและการเฝ้าระวังสถานการณ์น้ำท่วมในพื้นที่ลุ่มน้ำโขง หรือพื้นที่อื่นที่มีลักษณะใกล้เคียงกัน

คำสำคัญ : การจำแนกพื้นที่น้ำ, Sentinel-2, การวิเคราะห์อนุกรมเวลา, พื้นที่ลุ่มน้ำโขง, การเรียนรู้ของเครื่อง, recursive classifiers

Title	COMPARATIVE ANALYSIS OF SURFACE WATER CLASSIFICATION MODELS USING SATELLITE IMAGE TIME-SERIES: A CASE STUDY OF THE MEKONG RIVER BASIN
Author	JENJIRA WONG-UKA
Degree	MASTER OF SCIENCE
Academic Year	2024
Thesis Advisor	Banphatree Khomkham , Ph.D.

Due to the global impacts of climate change, the development of efficient surface water classification models is crucial for water resource management and flood monitoring. This study presents a comparative analysis of water classification models using Sentinel-2 time-series satellite imagery from February 8, 2020, to December 19, 2023, in a cross-border area of the Mekong River, including the At Samran Subdistrict, Mueang Nakhon Phanom District, Nakhon Phanom Province, Thailand, and Don Don Island, Thakhek, Laos. The study evaluated the performance of five classification models: Gaussian Mixture Model (GMM), Logistic Regression (LR), Spectral Index Classification (SIC), DeepWaterMap (DWM), and WatNet (WN), with recursive classifiers used to improve classification accuracy. The experimental results indicated that GMM achieved the highest accuracy at 90.01%, while WN exhibited the lowest accuracy at 68.79%. The use of recursive classifiers significantly enhanced accuracy, with the GMM model reaching 94.36%. Additionally, recursive classifiers increased the average accuracy from 78.41% to 82.16%. The findings highlight the importance of selecting appropriate models for classifying water areas from satellite imagery. The use of recursive classifiers significantly improves model performance. Such enhancements not only improve classification accuracy but also serve as important tools for water resource management and flood monitoring, particularly in the Mekong River Basin or other similar regions.

Keyword : Surface water classification, Sentinel-2, time-series analysis, Mekong River Basin, Machine learning, recursive classifiers

กิตติกรรมประกาศ

สารนิพนธ์นี้สำเร็จลุล่วงได้ด้วยความช่วยเหลือจาก อ.ดร.บรรพตริ คมขำ อาจารย์ที่ปรึกษา ที่ได้ให้คำแนะนำ แนวคิดที่เป็นประโยชน์ ตลอดจนแก้ไขข้อบกพร่องต่าง ๆ มาโดยตลอดจนสารนิพนธ์นี้เสร็จสมบูรณ์ ผู้ศึกษาจึงขอขอบพระคุณเป็นอย่างสูง

ขอขอบพระคุณคณะกรรมการสอบปากเปล่า รศ.ดร.รัชลิดา ลิปิกรณ์ และ ผศ.ดร.ศิริสรรพ เหล่าหะเกียรติ ที่ได้ให้คำแนะนำในการปรับปรุงคุณภาพของสารนิพนธ์ให้ดียิ่งขึ้น

ขอขอบคุณ คุณศิริประภา ชมพูพันธ์ และคุณณัฐศรณ สิริธิ นักภูมิสารสนเทศชำนาญการ ที่ได้ให้ความช่วยเหลือในการเก็บรวบรวมข้อมูลที่นำมาใช้ในการศึกษา การจัดทำข้อมูลจริงที่นำมาใช้ในการประเมินประสิทธิภาพแบบจำลอง ตลอดจนให้คำแนะนำที่เป็นประโยชน์ในการทำสารนิพนธ์นี้

ขอขอบคุณเจ้าหน้าที่บัณฑิตวิทยาลัย สำหรับข้อมูลและการดำเนินงานเอกสารต่าง ๆ ที่เกี่ยวข้องกับการทำสารนิพนธ์นี้ให้สำเร็จลุล่วงไปได้ด้วยดี

ขอขอบคุณเพื่อนพี่น้องจากสาขาวิทยาการข้อมูล ภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ ที่ได้ให้ความช่วยเหลือ คำแนะนำและเป็นกำลังใจให้กับผู้ศึกษาเสมอมา

สุดท้ายนี้ขอขอบพระคุณครอบครัวของผู้ศึกษาที่ให้กำลังใจและสนับสนุนเป็นอย่างดี และขอขอบพระคุณครูบาอาจารย์ที่อบรมสั่งสอนให้ความรู้ด้วยความเอาใจใส่ตลอดมา

เจนจิรา วงศ์อุคะ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ณ
สารบัญรูปภาพ	ญ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ประโยชน์ที่ได้รับ	2
1.4 ขอบเขตงานวิจัย	2
1.5 กรอบแนวคิดงานวิจัย.....	3
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	4
2.1 หลักการและทฤษฎีการรับรู้จากระยะไกลด้วยดาวเทียม Sentinel-2.....	4
2.2 หลักการและทฤษฎีการอ่านแปลตีความและวิเคราะห์ภาพถ่ายดาวเทียมด้วยสายตา	10
2.3 แบบจำลองการจำแนกพื้นที่น้ำที่ใช้ในการศึกษา	11
2.3.1 Gaussian Mixture Model (GMM)	11
2.3.2 Logistic Regression (LR)	14
2.3.3 Spectral Index Classification (SIC)	14
2.3.4 DeepWaterMap (DWM)	17
2.3.5 WatNet (WN)	18

2.3.6 Recursive Bayesian Classification (RBC)	19
2.4 อัลกอริทึมการตรวจจับแมลงและเงาของแมลง	22
2.5 หลักการการตรวจสอบประสิทธิภาพของแบบจำลองด้วยกระบวนการ IoU.....	24
2.6 งานวิจัยที่เกี่ยวข้อง	26
บทที่ 3 วิธีดำเนินการวิจัย.....	39
3.1 กระบวนการทำงาน.....	40
3.2 การรวบรวมข้อมูล.....	41
3.3 การเตรียมข้อมูล	43
3.4 การทำงานของแบบจำลอง	46
3.5 การประเมินผล	49
บทที่ 4 ผลการดำเนินงานวิจัย.....	50
4.1 ผลลัพธ์การตรวจจับแมลงและเงาของแมลงที่ใช้ในการฝึกฝน	50
4.2 ผลลัพธ์การทดสอบการจำแนกพื้นที่น้ำของแบบจำลอง	52
4.3 ผลลัพธ์การประเมินประสิทธิภาพของแบบจำลอง	52
บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	61
5.1 สรุปผลการวิจัย.....	61
5.2 อภิปรายผลการวิจัย	62
5.3 ข้อเสนอแนะ.....	66
บรรณานุกรม	67
ประวัติผู้เขียน.....	72

สารบัญตาราง

หน้า

ตาราง 1 รายละเอียดข้อมูลของช่วงคลื่นแม่เหล็กไฟฟ้า.....	5
ตาราง 2 ข้อมูลภาพถ่ายความละเอียดสูงชนิดหลายช่วงคลื่นของดาวเทียม Sentinel-2.....	10
ตาราง 3 ค่าความแม่นยำของแต่ละแบบจำลอง.....	30
ตาราง 4 การสรุปผลการศึกษาการจำแนกการใช้ประโยชน์ที่ดินแบบไม่กำกับดูแล	33
ตาราง 5 ข้อมูลไฮเพอร์พารามิเตอร์ที่ใช้ในการทดสอบ	35
ตาราง 6 การเปรียบเทียบค่า F1-score ของกลุ่มที่ได้รับการจำแนกในแต่ละวิธีการจำแนก	35
ตาราง 7 ตารางแสดงการกำหนดชื่อแบบจำลองที่ใช้ในการศึกษา	39
ตาราง 8 การตั้งค่าพารามิเตอร์	48
ตาราง 9 ตารางแสดงผลการตรวจจับเมฆและเงาของเมฆจากภาพถ่ายดาวเทียม	51
ตาราง 10 ผลการทดสอบการทำนายของแบบจำลอง SIC.....	56
ตาราง 11 ผลการทดสอบการทำนายของแบบจำลอง GMM.....	57
ตาราง 12 ผลการทดสอบการทำนายของแบบจำลอง LR.....	58
ตาราง 13 ผลการทดสอบการทำนายของแบบจำลอง DWM.....	59
ตาราง 14 ผลการทดสอบการทำนายของแบบจำลอง WN.....	60
ตาราง 15 สรุปผลการทดสอบการทำนายของแบบจำลอง	61
ตาราง 16 สรุปผลการทดสอบการทำนายของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียม	62
ตาราง 17 ผลการทดสอบการทำนายของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียมวันที่ 23/4/2023	63
ตาราง 18 ผลการประเมินประสิทธิภาพของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียมที่นำข้อมูล วันที่ 23/4/2023 ออก.....	63
ตาราง 19 ผลการประเมินประสิทธิภาพของแบบจำลองหลังจากปรับค่า $\tau_w = 0.07$	65

สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 กรอบแนวคิดการทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำจากภาพถ่ายดาวเทียมแบบอนุกรมเวลา: กรณีศึกษาพื้นที่ลุ่มน้ำโขง	3
ภาพประกอบ 2 ความแตกต่างของความละเอียดเชิงพื้นที่	7
ภาพประกอบ 3 ความละเอียดเชิงสเปกตรัม	8
ภาพประกอบ 4 กรอบแนวคิด RBC	20
ภาพประกอบ 5 กรอบการทำนาย (สีแดง) กรอบข้อมูลจริง (สีเขียว) เป้าหมายคือการคำนวณค่า IoU ระหว่างทั้งสองกรอบ	25
ภาพประกอบ 6 หลักการคำนวณ IoU	25
ภาพประกอบ 7 การกำหนดตัวชี้วัดการประเมินผล IoU	26
ภาพประกอบ 8 boxplot แสดงผลการกระจายตัวของค่าความแม่นยำ SIC, GMM, LR, DWM และ WN (สีเหลือง) และ recursive (สีฟ้า)	27
ภาพประกอบ 9 กระบวนการของ EDCM	28
ภาพประกอบ 10 ผลการสกัดพื้นที่น้ำจากภาพถ่ายดาวเทียม Landsat-8 Bands 5, 4 และ 3 ใช้ภาพสีผิด (false color) และเปรียบเทียบผลของแต่ละแบบจำลอง	30
ภาพประกอบ 11 ผลการจำแนกพื้นที่ ภาพสีธรรมชาติ (บนซ้าย) ข้อมูลจริง (บนขวา) ผลการจำแนก SVM (ล่างซ้าย) และผลการจำแนกการสุ่มป่าไม้ (ล่างขวา) ของอำเภอ Georgia แคนาดา 32	
ภาพประกอบ 12 แผนภูมิแสดงค่าความถูกต้องในการจำแนกการใช้ประโยชน์ที่ดินแบบไม่กำกับดูแล	34
ภาพประกอบ 13 เปรียบเทียบผลการจำแนกการใช้ประโยชน์ที่ดินของแต่ละวิธีการจำแนก	36
ภาพประกอบ 14 กราฟแสดงค่าความเที่ยงและค่าเรียกคืนกับการประมาณค่าความน่าจะเป็นที่น้ำจะท่วมก่อนใช้ recursive bayesian สำหรับข้อมูลทั้ง 3 ชุด	37

ภาพประกอบ 15 กราฟแสดงค่าความเที่ยงและค่าเรียกคืนกับการประมาณค่าความน่าจะเป็นที่น้ำจะท่วมหลังใช้ recursive bayesian สำหรับข้อมูลทั้ง 3 ชุด	38
ภาพประกอบ 16 กระบวนการทำงานโดยรวม	40
ภาพประกอบ 17 บริเวณพื้นที่ศึกษา กรอบสีแดงคือจุดที่ทดสอบการจำแนกพื้นที่น้ำ	41
ภาพประกอบ 18 หน้าเว็บไซต์ของ Copernicus Data Space Ecosystem, Programme of the European Union โดยสามารถเลือกบริเวณที่ต้องการดาวน์โหลดภาพถ่ายดาวเทียมได้	42
ภาพประกอบ 19 ข้อมูลปี-เดือน-วัน ที่ถ่ายภาพของข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ที่นำมาใช้ในการศึกษา	42
ภาพประกอบ 20 หน้าโปรแกรม SNAP Desktop	43
ภาพประกอบ 21 12 แถบหลังการปรับความละเอียดของข้อมูล	43
ภาพประกอบ 22 หน้าโปรแกรม ArcMap กรอบสีแดงคือบริเวณที่ทำการตัดภาพ	44
ภาพประกอบ 23 กรอบการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม ในโปรแกรม ArcMap (เส้นสีแดง)	45
ภาพประกอบ 24 การใส่ป้ายกำกับตามผลของการอ่านแปลอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมในตาราง	45
ภาพประกอบ 25 ตัวอย่างผลการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมที่มีการติดป้ายกับ (เส้นสีแดง)	46
ภาพประกอบ 26 ตัวอย่างภาพผลการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมที่ถูกกำหนดสีตามป้ายกำกับ	46
ภาพประกอบ 27 ผลการทดสอบการจำแนกพื้นที่น้ำของแบบจำลองฟิกเชลที่แบบจำลองทำนายว่าเป็นพื้นที่น้ำ (สีม่วง) และไม่ใช่พื้นที่น้ำ (สีเหลือง)	52
ภาพประกอบ 28 แสดงการกำหนดสีการซ้อนทับภาพแผนที่ของข้อมูลการทำนายกับข้อมูลจริง ..	53
ภาพประกอบ 29 การซ้อนทับภาพแผนที่ของข้อมูลการทำนายกับข้อมูลจริงของแบบจำลองที่ไม่ทำ recursive classifiers	54

ภาพประกอบ 30 แสดงการซ้อนทับภาพแผนที่ของข้อมูลการทำนายกับข้อมูลจริงของแบบจำลอง ที่ทำ recursive classifiers	55
ภาพประกอบ 31 ภาพถ่ายดาวเทียมแถบ B11 (SWIR)	64



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

จากภาวะการณ์การเปลี่ยนแปลงภูมิอากาศ (climate change) ทั่วโลกในปัจจุบันล้วนเป็นเหตุมาจากการทำกิจกรรมต่าง ๆ ของมนุษย์ ส่งผลกระทบให้ภูมิประเทศเกิดการเปลี่ยนแปลง เช่น อุณหภูมิที่เพิ่มสูงขึ้นทำให้ภูเขาน้ำแข็งละลายจนทำให้ระดับน้ำทะเลเพิ่มสูงขึ้นหรือในบางพื้นที่แห้งแล้งจนกลายเป็นทะเลทราย เป็นต้น เพราะฉะนั้นการติดตามสถานการณ์ของธรรมชาติที่มักจะแปรปรวนอยู่เสมอจึงเป็นสิ่งสำคัญ โดยเฉพาะการเพิ่มหรือลดของระดับน้ำในแม่น้ำ ทั้งที่เปลี่ยนไปตามฤดูกาล หรือเปลี่ยนแปลงอย่างฉับพลัน เพื่อให้ได้ข้อมูลที่จะมีส่วนช่วยในการวางแผนรับมือกับปรากฏการณ์ต่าง ๆ ได้อย่างทันทั่วทั้งที่ เช่น การวางแผนรับมือน้ำท่วม และการสำรองน้ำเพื่อการดำรงชีพเพื่อรับมือกับภัยแล้ง เป็นต้น

ในประเทศไทยนั้นมีพื้นที่ที่ประสบปัญหาเกี่ยวกับน้ำหลายพื้นที่ ซึ่งพื้นที่ที่เห็นได้ชัดถึงปัญหาคือพื้นที่ลุ่มน้ำโขง ที่มีต้นกำเนิดจากการละลายของธารน้ำแข็ง บริเวณเทือกเขาหิมาลัยของทิเบต สาธารณรัฐประชาชนจีน ปลายทางไหลลงสู่ทะเลจีนใต้โดยตัดผ่านเมียนมา ลาว ไทย กัมพูชา และเวียดนาม ระยะทางโดยประมาณ 4,900 กิโลเมตร เป็นแม่น้ำที่มีระบบนิเวศที่มีความหลากหลายที่สำคัญของโลก แต่ในเมื่อปี พ.ศ. 2539 ประเทศจีนได้ทำการสร้างเขื่อนม่านวาน (Manwan) เพื่อผลิตกระแสไฟฟ้า และสร้างต่อมาถึงปัจจุบันรวมทั้งหมด 11 เขื่อน เป็นเขื่อนขั้นบันได (Lancang cascade) เรียงยาวตามทิศทางของกระแสน้ำ ส่งผลให้ปรากฏการณ์ธรรมชาติเกิดความแปรปรวน เช่น น้ำขึ้น-ลงผิดปกติ บ้างน้ำท่วม บ้างแห้งขอด น้ำใสไม่มีตะกอน เป็นต้น (กริช วรรณโนรมณ์, 2564) พื้นที่ลุ่มน้ำโขงช่วงที่ไหลผ่านประเทศไทยตอนบนจึงน่าสนใจที่จะนำมาทดสอบประสิทธิภาพแบบจำลองการจำแนกพื้นที่น้ำ

ปัจจุบันสามารถศึกษาสภาพภูมิศาสตร์และสภาพแวดล้อมที่เกิดขึ้นบนพื้นโลกได้จากเทคโนโลยีการรับรู้ระยะไกล โดยส่วนใหญ่จะเป็นข้อมูลภาพถ่ายทางอากาศหรือภาพถ่ายดาวเทียม แล้วจะถูกนำมาจำแนกและวิเคราะห์เพื่อให้เข้าใจถึงวัตถุและสิ่งที่เกิดขึ้นบนพื้นโลก (สำนักงานส่งเสริมเศรษฐกิจดิจิทัล, 2564) โดยการเรียนรู้จะนำภาพถ่ายดาวเทียมพื้นที่บริเวณลุ่มน้ำโขง มาทดสอบประสิทธิภาพแบบจำลองการจำแนกพื้นที่น้ำ จากงานวิจัย Recursive Classification of Satellite Imaging Time-Series: An Application to Land Cover Mapping (Calatrava et al., 2024) ที่ผ่านการฝึกฝนและทดสอบจากข้อมูลภาพถ่ายดาวเทียมพื้นที่น้ำของ

ต่างประเทศ ที่มีสภาพภูมิประเทศ ภูมิอากาศ ฤดูกาล และกิจกรรมการใช้พื้นที่แตกต่างกันอย่างสิ้นเชิง

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อทดสอบและเปรียบเทียบประสิทธิภาพการจำแนกพื้นที่น้ำของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียมแบบอนุกรมเวลา โดยมีพื้นที่ศึกษาคือพื้นที่ลุ่มน้ำโขง

1.3 ประโยชน์ที่ได้รับ

เพื่อให้ได้ข้อมูลการจำแนกพื้นที่น้ำออกจากพื้นที่ที่ไม่ใช่พื้นที่น้ำ สำหรับนำไปใช้ทำแผนที่ประกอบการวางแผนการใช้น้ำ หรือวิเคราะห์ข้อมูลเพื่อรับมือภัยพิบัติทางน้ำที่อาจเกิดขึ้นได้ในอนาคต และเป็นแนวทางให้ผู้สนใจสามารถนำแบบจำลองไปพัฒนาต่อให้มีประสิทธิภาพดียิ่งขึ้น

1.4 ขอบเขตงานวิจัย

1.4.1 ขอบเขตด้านพื้นที่

พื้นที่ศึกษา ลุ่มน้ำโขง บริเวณพิกัด ละติจูด 17.468086 ลองจิจูด 104.743400 ในพื้นที่ข้ามพรมแดนของแม่น้ำโขง บริเวณตำบลอาจสามารถ อำเภอเมืองนครพนม จังหวัดนครพนม ประเทศไทย และเกาะดอนโดน เมืองท่าแขก สาธารณรัฐประชาธิปไตยประชาชนลาว

1.4.2 ขอบเขตด้านเนื้อหา

1. ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 Level-2A จากเว็บไซต์ของ Copernicus Data Space Ecosystem, Programme of the European Union โดยคัดเลือกภาพที่ติดเมฆไม่เกิน 25% จำนวน 30 ภาพ ใช้สำหรับฝึกฝน 21 ภาพ และทดสอบ 9 ภาพ

2. ปรับความละเอียดของข้อมูลใหม่เป็น 10 เมตร โดยใช้โดยวิธีเลือกค่าที่อยู่ใกล้ที่สุด (nearest-neighbor interpolation)

3. แถบพืชน้ำมาใช้คือ

- ใช้ในการคำนวณ MNDWI เพื่อฝึกฝนและทดสอบแบบจำลอง GMM, LR และ SIC: B3 (Green) และ B11 (SWIR 1)

- ใช้สำหรับทดสอบแบบจำลอง DWM และ WN: B2 (Blue), B3 (Green), B4 (Red), B8 (NIR) B8A (Narrow NIR Edge) และ B11 (SWIR 1)

4. ภาพภาพถ่ายดาวเทียมมีขนาด 2229x3341

5. พิกัดที่ใช้ในการทดสอบ x: [1400, 1550], y: [1540, 1650]


1.4.3 ขอบเขตระยะเวลาในการศึกษา

ช่วงเวลาของภาพถ่ายดาวเทียมตั้งแต่วันที่ 08/02/2020 ถึงวันที่ 19/12/2023

1.5 กรอบแนวคิดงานวิจัย

การศึกษานี้มีการออกแบบกรอบแนวคิดการทำงานออกเป็น 3 ส่วน โดยมีรายละเอียดแสดง

ดังภาพประกอบ 1



ภาพประกอบ 1 กรอบแนวคิดการทดสอบและเปรียบเทียบประสิทธิภาพของ
แบบจำลองการจำแนกพื้นที่น้ำจากภาพถ่ายดาวเทียมแบบอนุกรมเวลา: กรณีศึกษา
พื้นที่ลุ่มน้ำโขง

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ผู้ศึกษาได้ทำการศึกษาเอกสารและงานวิจัยที่เกี่ยวข้องกับงานวิจัยนี้ โดยจะนำเสนอตามหัวข้อดังต่อไปนี้

- 2.1 หลักการและทฤษฎีการรับรู้จากระยะไกลด้วยดาวเทียม Sentinel-2
- 2.2 หลักการและทฤษฎีการอ่านแปลตีความและวิเคราะห์ภาพถ่ายดาวเทียมด้วยสายตา
- 2.3 แบบจำลองการจำแนกพื้นที่น้ำที่ใช้ในการศึกษา
 - 2.3.1 Gaussian Mixture Model (GMM)
 - 2.3.2 Logistic Regression (LR)
 - 2.3.3 Spectral Index Classification (SIC)
 - 2.3.4 DeepWaterMap (DWM)
 - 2.3.5 WatNet (WN)
 - 2.3.6 Recursive Bayesian Classification (RBC)
- 2.4 อัลกอริทึมการตรวจจับเมฆและเงาของเมฆ
- 2.5 หลักการการตรวจสอบประสิทธิภาพของแบบจำลองด้วยวิธี IoU
- 2.6 งานวิจัยที่เกี่ยวข้อง

2.1 หลักการและทฤษฎีการรับรู้จากระยะไกลด้วยดาวเทียม Sentinel-2

เทคโนโลยีการรับรู้จากระยะไกล (remote sensing) คือการได้มาของข้อมูลและปรากฏการณ์ต่าง ๆ ที่เกิดขึ้นบนพื้นโลก โดยมีกระบวนการดังนี้

1. การได้มาของข้อมูล แหล่งกำเนิดพลังงานจะปล่อยคลื่นแม่เหล็กไฟฟ้าออกมา เช่น ดวงอาทิตย์เคลื่อนตัวตามชั้นบรรยากาศ ส่งพลังงานไปยังรูปลักษณะที่ปรากฏขึ้นบนพื้นผิวโลก แล้วสะท้อนกลับมายังตัวรับรู้ (sensor) ที่ติดตั้งบนดาวเทียมซึ่งจะบันทึกแล้วทำเป็นข้อมูลในรูปแบบภาพหรือแบบเชิงเลข
2. การวิเคราะห์ข้อมูล ได้แก่ การแปลตีความด้วยสายตา (visual interpretation) และการวิเคราะห์ทางดิจิทัล (digital analysis) ซึ่งมีข้อมูลที่เกี่ยวข้องมาอ้างอิง เช่น ข้อมูลชุดดิน ข้อมูลสถิติการเพาะปลูก เป็นต้น ได้ผลออกมาเป็นแผนที่ ข้อมูลตารางคำอธิบาย หรือแผนภูมิต่าง ๆ เพื่อให้สามารถนำไปใช้วิเคราะห์หรือสนับสนุนงานอื่นต่อไป

พลังงานแม่เหล็กไฟฟ้า (electromagnetic energy) มีดวงอาทิตย์เป็นแหล่งพลังงานหลักของการรับรู้จากระยะไกล มีการเคลื่อนที่แบบฮาร์มอนิก (harmonic motion) มีช่วงซ้ำและจังหวะเท่ากัน ณ เวลาหนึ่ง ความยาวคลื่นมีหน่วยวัดเป็นไมโครเมตร (micrometer) หรือไมครอน (micron, μ)

แถบ (band) คือการแบ่งช่วงตามความยาวคลื่น รายละเอียดข้อมูลของช่วงคลื่นแม่เหล็กไฟฟ้าแสดงดังตาราง 1 โดยช่วงคลื่นของเทคโนโลยีการรับรู้จากระยะไกล สามารถแบ่งออกเป็น 2 กลุ่ม ได้แก่

1. ช่วงคลื่นเชิงแสง (optical wavelength) อยู่ในช่วง 0.4-14 ไมโครเมตร สามารถถ่ายภาพและบันทึกภาพได้ด้วยฟิล์มถ่ายรูป

2. ช่วงคลื่นไมโครเวฟ (microwave) อยู่ระหว่าง 1 มิลลิเมตรถึง 1 เมตร หน่วยเป็นความถี่ เช่น ระบบเรดาร์ ที่ทำการบันทึกข้อมูลในช่วงคลื่นความถี่ระหว่าง 3-12.5 GHz (ความยาวคลื่นระหว่าง 2.4-100 เซนติเมตร)

ตาราง 1 รายละเอียดข้อมูลของช่วงคลื่นแม่เหล็กไฟฟ้า

ช่วงคลื่น	รายละเอียด	รายละเอียด
รังสีแกมมา (Gamma ray)	< 0.03 ไมโครเมตร	รังสีแกมมาถูกดูดซึมทั้งหมดโดยบรรยากาศชั้นบน
รังสีแกมมา (X-ray)	0.03-3.1 ไมโครเมตร	รังสีเอกซเรย์ถูกดูดซึมทั้งหมดโดยบรรยากาศ
รังสีเหนือม่วง หรือ รังสีอัลตราไวโอเล็ต	0.03-0.4 ไมโครเมตร	ช่วงคลื่นสั้นกว่า 0.3 ไมโครเมตร ถูกดูดซึมทั้งหมดโดยโอโซนในบรรยากาศชั้นบน
ช่วงคลื่นไวโอเล็ตภาพถ่าย (Photographic UV band)	0.03-0.4 ไมโครเมตร	ช่วงคลื่นผ่านชั้นบรรยากาศ แล้วสามารถบันทึกภาพได้ด้วยฟิล์มถ่ายรูป
ช่วงคลื่นที่ตามองเห็น	0.4-0.7 ไมโครเมตร	บันทึกภาพด้วยอุปกรณ์บันทึกภาพได้ มีการสะท้อนพลังงานสูงสุด (reflected energy peak) ที่ 0.5 ไมโครเมตร ช่วงคลื่นแคบที่มีผลตอบสนองสายตามนุษย์ แบ่งได้ 3 ช่วง คือ - 0.4-0.5 ไมโครเมตร: แถบสีน้ำเงิน (blue band) - 0.5-0.6 ไมโครเมตร: แถบสีเขียว (green band)

ตาราง 1 (ต่อ)

ช่วงคลื่น	รายละเอียด	รายละเอียด
อินฟราเรด	0.7-1.00 ไมโครเมตร	- 0.6-0.7 ไมโครเมตร: แถบสีแดง (red band) มีปฏิสัมพันธ์กับวัตถุตามความยาวคลื่นและ การผ่านชั้นบรรยากาศ มีการดูดซึมบางช่วง คลื่น
ช่วงคลื่นอินฟราเรดชนิด สะท้อน (Reflected IR band)	0.7-3.00 ไมโครเมตร	สะท้อนรังสีดวงอาทิตย์ สามารถถ่ายภาพด้วย ฟิล์ม เรียกว่า ช่วงคลื่นอินฟราเรด (Photographic IR band)
ช่วงคลื่นอินฟราเรดความ ร้อน	3-5 และ 8-14 ไมโครเมตร	การบันทึกภาพต้องใช้อุปกรณ์พิเศษ เช่น เครื่อง วาดภาพ
ไมโครเวฟ	0.1-30 เซนติเมตร	ช่วงคลื่นยาวสามารถทะลุผ่านหมอกและฝนได้ สามารถบันทึกภาพได้ทั้งระบบแพสซีฟ และแอ็กทีฟ
เรดาร์	0.1-3.0 เซนติเมตร	ระบบแอ็กทีฟมีความยาวช่วงคลื่นต่างๆ เช่น Ka band (10 มม.), X band 30 (มม.) และ L band (25 ซม.)
วิทยุ	> 30 เซนติเมตร	ช่วงคลื่นที่ยาวที่สุด บางครั้งมีเรดาร์อยู่ในช่วงนี้ ด้วย

ที่มา: สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ(องค์การมหาชน). (2558, กันยายน). พื้นฐานการรับรู้จากระยะไกล (1). สืบค้นจาก: https://www.gistda.or.th/news_view.php?n_id=2405&lang=TH

ระบบเครื่องรับรู้ (sensing system) ของเทคโนโลยีการรับรู้ระยะไกล แบ่งตามแหล่งพลังงานที่ใช้ได้ 2 แบบ คือ

1. ระบบแพสซีฟ (passive remote sensing) คือระบบการรับรู้ที่สามารถตรวจวัดพลังงานที่สะท้อนออกจากวัตถุและแผ่รังสีออกมาได้เองโดยธรรมชาติ เช่น พลังงานจากดวงอาทิตย์

2. ระบบแอ็กทีฟ (active remote sensing) คือระบบการรับรู้ที่มีแหล่งพลังงานที่สร้างขึ้นแล้วส่งไปยังวัตถุเป้าหมาย เช่น ระบบเรดาร์ ที่ต้องมีการส่งพลังงานที่สังเคราะห์ขึ้นไปกระทบวัตถุ

เป้าหมายแล้วตรวจหา (detect) พลังงานที่กระเจิงกลับ (backscatter) (สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ(องค์การมหาชน), 2558)

ในการเลือกใช้อุปกรณ์ภาพถ่ายดาวเทียมสามารถพิจารณาได้จากความละเอียด (resolutions) แบ่งเป็น 4 ประเภท ได้แก่


1. ความละเอียดเชิงพื้นที่ (spatial resolution) คือ ความละเอียดของพิกเซลบนภาพ ความละเอียดเชิงพื้นที่สูงหมายถึงมีรายละเอียดมากและกิริตของพิกเซลมีขนาดเล็ก ในทางกลับกัน ความละเอียดเชิงพื้นที่ต่ำ หมายถึงมีรายละเอียดน้อยขนาดกิริตของพิกเซลขนาดใหญ่ ดังแสดงในภาพประกอบ 2 (GIS Geography, 2022)



ภาพประกอบ 2 ความแตกต่างของความละเอียดเชิงพื้นที่

ที่มา: GIS Geography. (2022). spatial resolution vs spectral resolution. สืบค้นจาก: <https://gisgeography.com/spatial-resolution-vs-spectral-resolution/>

2. ความละเอียดเชิงสเปกตรัม (spectral resolution) คือ จำนวนช่วงคลื่นของข้อมูลหรือช่วงคลื่นที่ข้อมูลแต่ละชุดสามารถบอกได้ เช่น มีแถบ B8, B2, B3 และ B4 เรียกว่า ภาพหลายช่วงคลื่น (multispectral) หรือมีช่วงคลื่นเป็นจำนวนหลักร้อย เรียกว่า ภาพหลายช่วงคลื่นความละเอียดสูง (hyperspectral) ดังแสดงในภาพประกอบ 3 กล้องบนดาวเทียมจะมีจำนวนช่วงคลื่นมากกว่ากล้องปกติ เนื่องจากมีระยะทางไกลและในการตรวจจับวัตถุเป้าหมายบนพื้นโลก ถ้ามีหลายช่วงคลื่นจะทำให้สามารถสร้างลักษณะเฉพาะของวัตถุได้มีประสิทธิภาพมากกว่า (GIS Geography, 2022)



ภาพประกอบ 3 ความละเอียดเชิงสเปกตรัม

ที่มา: GIS Geography. (2022). spatial resolution vs spectral resolution. สืบค้นจาก: <https://gisgeography.com/spatial-resolution-vs-spectral-resolution/>

3. ความละเอียดเชิงรังสี (radiometric resolution) คือ ความละเอียดของข้อมูลที่แบ่งระดับตามความเข้มของแต่ละช่วงคลื่น เช่น ภาพจากกล้องปกติคือข้อมูล 8 บิต แสดงค่าที่แตกต่างกันได้ $2^8 = 256$ ระดับ แต่ข้อมูลดาวเทียม Landsat-8 มีข้อมูลแบบ 16 บิต ซึ่งสามารถแสดงค่าได้ $2^{16} = 65,536$ ระดับ ซึ่งจำนวนบิตที่มากจะแยกแยะความเข้มได้ละเอียดมาก

4. ความละเอียดเชิงเวลา (temporal resolution) คือการวัดช่วงเวลาที่จะได้ข้อมูลพื้นที่บริเวณเดิมอีกครั้ง หรือก็คือการโคจรซ้ำ (revisit time) เช่น ดาวเทียมที่มีข้อมูลทุกวันจะมีความละเอียดเชิงเวลามากกว่าดาวเทียมที่มีข้อมูลทุก 16 วัน โดยสามารถเลือกใช้ให้เหมาะสมกับงานได้ เช่น การติดตามสถานการณ์น้ำท่วมต้องบริหารจัดการแบบรายวัน ควรเลือกข้อมูลที่มีความละเอียดรายวัน แต่ในการประเมินพื้นที่ป่าไม้ที่หายไป ดูการเปลี่ยนแปลงในรอบหลายสิบปี ไม่จำเป็นต้องมีความละเอียดเชิงเวลาสูงมาก เป็นต้น

ในปัจจุบันมีงานวิจัยเกี่ยวกับงานด้านเทคโนโลยีการรับรู้จากระยะไกลโดยใช้การเรียนรู้ของเครื่อง (machine learning) หรือการเรียนรู้เชิงลึก (deep learning) เป็นจำนวนมาก และมีข้อมูลโอเพนซอร์สที่นิยมใช้ อย่างเช่น Landsat, MODIS, Sentinel, ฯลฯ (นฤตม์ สุนทรานนท์ & นววิทย์ พงศ์อนันต์, 2565)

ดาวเทียม Sentinel-2 เป็นดาวเทียมสำรวจโลกเชิงแสง (optical earth observation satellite) ดวงแรกในโครงการโคเปอร์นิคัสของยุโรป ซึ่งพัฒนาและสร้างขึ้นโดยบริษัท Airbus Defence and Space เพื่อองค์การอวกาศยุโรป (European Space Agency: ESA)

มีภารกิจมุ่งเน้นครอบคลุมพื้นที่ผิวดินทั่วโลกอย่างเต็มรูปแบบและเป็นระบบ รวมถึงเกาะสำคัญต่าง ๆ โดยมีเป้าหมายในการจัดหาภาพที่ไม่ติดจากเมฆทุก 15-30 วัน โดยเฉพาะในยุโรปและแอฟริกา

ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 จะช่วยสนับสนุนในการทำข้อมูลการใช้ที่ดิน การตรวจจับการเปลี่ยนแปลงของพื้นที่ แผนที่ตัวแปรทางกายภาพ เช่น ดัชนีพื้นที่ใบ (leaf area index) ปริมาณคลอโรฟิลล์ในใบพืช (leaf chlorophyll content) และปริมาณน้ำในใบพืช (leaf water content)

ข้อมูลเกี่ยวกับดาวเทียม Sentinel-2

- การปล่อยดาวเทียม: Sentinel-2A วันที่ 23 มิถุนายน 2015, Sentinel-2B วันที่ 7 กรกฎาคม 2016 และ Sentinel-2C วันที่ 5 กันยายน 2024 (THE EUROPEAN SPACE AGENCY, 2024)

- วงโคจร: วงโคจรแบบสัมพันธ์กับดวงอาทิตย์ (sun-synchronous orbit) ที่ความสูง 786 กิโลเมตร เวลาท้องถิ่นเฉลี่ยของดวงอาทิตย์ 10:30 (เนื่องจากการส่องสว่างจากดวงอาทิตย์ที่ดีที่สุด)

- การโคจรซ้ำ: ทุก 5 วัน

- อายุการใช้งาน: 7 ปี (บรรจุเชื้อเพลิงสำหรับ 12 ปีรวมถึงการลดวงโคจรเมื่อสิ้นอายุการใช้งาน)

- ภารกิจ: จัดการ พัฒนา ดำเนินการ และใช้ประโยชน์โดยหน่วยงานต่าง ๆ ของ ESA

- การระดมทุน: ประเทศสมาชิก ESA และสหภาพยุโรป

- ผู้รับเหมาหลัก: Airbus Defence and Space

- ความร่วมมือระหว่างหน่วยงาน:

1. CNES (หน่วยงานอวกาศฝรั่งเศส) ทำการปรับแต่งคุณภาพของภาพระหว่างการทดสอบในวงโคจร

2. DLR (ศูนย์อวกาศเยอรมัน) ระบบสื่อสารแสงเชิงแสงบนดาวเทียม (optical communication payload)

3. NASA การสอบเทียบร่วมกับ Landsat-8

- การใช้งานหลัก: การเกษตร ป่าไม้ การใช้ที่ดิน การทำแผนที่ตัวแปรทางชีวภาพ การติดตามสภาพน้ำชายฝั่งและน้ำในแผ่นดิน การทำแผนที่ความเสี่ยงและภัยพิบัติ

- โทรคมนาคม (telecommand): จะถูกส่งไปและกลับจากเมืองคิรูนา ประเทศสวีเดน

- สถานีรับข้อมูล: ข้อมูลส่ง x-bands ไปยังสถานีภาคพื้นดินหลักของ Sentinel และยิงแสงเลเซอร์ผ่าน EDRS (European Data Relay System)

- ภาพหลายช่วงคลื่น: ครบคลุม 13 แถบ (443–2190 นาโนเมตร) ด้วยความกว้างการสแกน 290 กิโลเมตร ดังแสดงในตาราง 2

ตาราง 2 ข้อมูลภาพถ่ายความละเอียดสูงชนิดหลายช่วงคลื่นของดาวเทียม Sentinel-2

Sentinel-2 Bands	Central Wavelength (μm)	Resolution (m)
Band 1 – Coastal aerosol	0.443	60
Band 2 – Blue	0.490	10
Band 3 – Green	0.560	10
Band 4 – Red	0.665	10
Band 5 – Vegetation Red Edge	0.705	20
Band 6 – Vegetation Red Edge	0.740	20
Band 7 – Vegetation Red Edge	0.783	20
Band 8 – NIR	0.842	10
Band 8A – Vegetation Red Edge	0.865	20
Band 9 – Water vapour	0.945	60
Band 10 – SWIR - Cirrus	1.375	60
Band 11 – SWIR	1.610	20
Band 12 – SWIR	2.190	20

ที่มา: Satellite imaging corporation. (2001). Sentinel-2A (10m) satellite sensor. สืบค้นจาก: <https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/>

(Satellite imaging corporation, 2001)

2.2 หลักการและทฤษฎีการอ่านแปลตีความและวิเคราะห์ภาพถ่ายดาวเทียมด้วยสายตา

ภาพถ่ายทางอากาศมีความแตกต่างจากภาพถ่ายทั่วไป อย่างน้อย 3 ประการ

1. วัตถุถูกถ่ายจากตำแหน่งเหนือศีรษะหรือมุมมองทางอากาศ
2. ภาพถ่ายถูกถ่ายในระดับความสูงที่คนทั่วไปไม่คุ้นเคยกับการมองเห็น
3. บางครั้งภาพที่ได้จากดาวเทียมใช้การถ่ายภาพสีอินฟราเรด (color-infrared) ซึ่งช่วยให้ผู้วิเคราะห์สามารถเห็นสิ่งที่ตามนุษย์มองไม่เห็น ทำให้มีเครื่องมือในการศึกษารูปทรงของพื้นดิน

มลพิษทางสิ่งแวดล้อม และผลกระทบของกิจกรรมมนุษย์บนพื้นผิวโลก

องค์ประกอบพื้นฐานเหล่านี้สามารถช่วยในการระบุวัตถุในภาพถ่ายทางอากาศ

1. โทนสี (tone, color or hue) หมายถึงความสว่างสัมพัทธ์ (relative brightness) หรือสีขององค์ประกอบ (color of elements) ในภาพถ่าย วัตถุบางอย่างอาจปรากฏมืดกว่าและชัดเจนกว่าองค์ประกอบอื่น
 2. ขนาด (size) ขนาดของวัตถุต้องพิจารณาในบริบทของระดับ (scale) ของภาพถ่าย ซึ่งจะช่วยกำหนดได้ว่าวัตถุเป็นบ่อน้ำขนาดเล็กหรือทะเลสาบขนาดใหญ่ ทางหลวงสายหลักสามารถแยกแยะได้จากถนนสายเล็ก และแม่น้ำสายยาวสามารถแยกแยะได้จากลำธารขนาดเล็ก
 3. รูปร่าง (shape) หมายถึงเส้นรอบนอกทั่วไปของวัตถุ รูปร่างเรขาคณิตปกติมักบ่งบอกถึงการมีอยู่และการใช้ของมนุษย์ พื้นที่เกษตรกรรมมักมีรูปร่างแบบเรขาคณิต เช่น สีเหลี่ยมผืนผ้า แม่น้ำมีลักษณะเส้นที่สามารถมีโค้งงอและเลี้ยวมากมาย ถนนมักจะมีโค้งน้อยกว่าแม่น้ำ
 4. เนื้อสัมผัส (texture) ลักษณะเรียบ หรือ หยาบ ขององค์ประกอบภาพเกิดจากการเปลี่ยนของโทนสีในภาพถ่าย หญ้า ซีเมนต์ และน้ำมักจะราบเรียบ ในขณะที่ป่าจะมีลักษณะหยาบ
 5. แบบแผน (pattern) เกิดจากรูปแบบของวัตถุในภาพสามารถใช้ระบุวัตถุนั้นได้ เช่น ความแตกต่างระหว่างต้นไม้ในพื้นที่ที่ไม่ได้มีการดูแลมักจะเป็นป่า และต้นไม้ที่ปลูกเป็นแถวเป็นแนวสม่ำเสมออาจจะเป็นสวนผลไม้
 6. เงา (shadow) ช่วยให้ผู้แปลภาพสามารถประมาณการณความสูงของวัตถุในภาพถ่ายทางอากาศได้ แต่บางครั้งเงาอาจจะบดบังวัตถุที่อยู่ในเงา
 7. ตำแหน่ง (site) หมายถึงตำแหน่งทางภูมิศาสตร์หรือตำแหน่งภูมิประเทศ ช่วยในการระบุชนิดของพืชและรูปร่างของพื้นดิน เช่น แอ่งลึกลึกขนาดใหญ่สามารถระบุได้ว่าเป็นหลุมยุบ
 8. ความสัมพันธ์ (association) วัตถุบางอย่างมักพบร่วมกับวัตถุอื่น ๆ บริบทของวัตถุสามารถให้ข้อมูลเชิงลึกกว่าวัตถุนั้นคืออะไร เช่น ตามปกติแล้วโรงไฟฟ้านิวเคลียร์จะไม่ตั้งอยู่ในย่านที่อยู่อาศัย พื้นที่ที่มีพืชในเมืองอาจเป็นสวนสาธารณะหรือสุสาน พื้นที่ชุ่มน้ำอาจตั้งอยู่ติดกับแม่น้ำ ทะเลสาบ หรือปากแม่น้ำ และศูนย์การค้าจะตั้งอยู่ติดกับถนนสายหลัก ทางรถไฟ หรือเส้นทางน้ำ
- (Environmental Literacy and Inquiry Working Group at Lehigh University, 2010)

2.3 แบบจำลองการจำแนกพื้นที่น้ำที่ใช้ในการศึกษา

2.3.1 Gaussian Mixture Model (GMM)

GMM เป็นการรวมกันของการกระจายแบบเกาส์เซียน (gaussian distribution) หลาย ๆ แบบ ซึ่งมีแนวคิดพื้นฐานดังนี้

1. มีกระบวนการบนแนวคิดของการผสมผสานการกระจายแบบเกาส์เซียน โดยสมมติว่าจุดข้อมูลได้มาจากการรวมกันของการกระจายแบบเกาส์เซียนหลายแบบ ซึ่งแต่ละแบบแทนกลุ่มที่แตกต่างกัน โดย GMM จะคำนวณความน่าจะเป็นที่จุดข้อมูลจะเป็นของแต่ละกลุ่ม และกำหนดให้กับกลุ่มที่มีความน่าจะเป็นสูงที่สุด

2. มีพารามิเตอร์หลัก 3 อย่าง คือ ค่าเฉลี่ย (mean) ความแปรปรวน (covariance) และสัดส่วนการผสม (mixing coefficient) สำหรับแต่ละกลุ่ม

3. อัลกอริทึม Expectation-Maximization (EM): ถูกใช้ในการประมาณค่าพารามิเตอร์ของ GMM โดยจะทำงานวนซ้ำเพื่อเพิ่มความน่าจะเป็นของข้อมูล โดยสลับระหว่าง Expectation step (E-step) ซึ่งใช้คำนวณความน่าจะเป็นที่แต่ละจุดข้อมูลจะถูกกำหนดให้อยู่ในองค์ประกอบ (component) ใดของแบบจำลอง และ Maximization step (M-step) ซึ่งปรับปรุงค่าพารามิเตอร์ของแบบจำลองตามผลการจัดสรรองค์ประกอบที่ได้จากขั้นตอนก่อนหน้านี้

สมการที่ (1): การแจกแจงความน่าจะเป็นของเกาส์เซียนสำหรับหนึ่งมิติ

$$G(X|\mu, \sigma) = \frac{1}{\sigma\sqrt{2\pi}} \exp - \frac{(x - \mu)^2}{2\sigma^2} \quad (1)$$

โดยที่ μ คือ ค่าเฉลี่ย

σ^2 คือ ความแปรปรวนของการแจกแจง

สมการที่ (2): การแจกแจงความน่าจะเป็นของเกาส์เซียนสำหรับหลายมิติ (d-dimensional)

$$G(X|\mu, \Sigma) = \frac{1}{\sqrt{(2\pi)^d}|\Sigma|} \exp \left(-\frac{1}{2} (X - \mu)^T \Sigma^{-1} (X - \mu) \right) \quad (2)$$

โดยที่ μ คือ เวกเตอร์ค่าเฉลี่ย

Σ คือ เมทริกซ์ความแปรปรวนร่วม

สมการที่ (3): การแจกแจงความน่าจะเป็นของข้อมูล X ภายใต้แบบจำลอง GMM ที่มี K คลัสเตอร์

$$p(X) = \sum_{k=1}^K \pi_k G(X|\mu_k, \Sigma_k) \quad (3)$$

โดยที่ π_k คือ ค่าสัมประสิทธิ์การผสมของคลัสเตอร์ที่ k ซึ่ง $\sum_{k=1}^K \pi_k = 1$

สมการที่ (4): การคำนวณค่าความน่าจะเป็นภายหลังของคลัสเตอร์

$$\gamma_k(X) = \frac{p(X|k)\pi_k}{\sum_{k=1}^K \pi_k p(X|k)} \quad (4)$$

โดยที่ $\gamma_k(x)$ คือ ค่าความน่าจะเป็นภายหลังของจุดข้อมูล X ที่เป็นของคลัสเตอร์ที่ k

การอัปเดตพารามิเตอร์ในขั้นตอน M-step

- สมการที่ (5): การอัปเดตค่าเฉลี่ย (μ_k)

$$\mu_k = \frac{\sum_{n=1}^N \gamma_k(x_n) x_n}{\sum_{n=1}^N \gamma_k(x_n)} \quad (5)$$

- สมการที่ (6): การอัปเดตเมทริกซ์ความแปรปรวนร่วม (Σ_k)

$$\Sigma_k = \frac{\sum_{n=1}^N \gamma_k(x_n) (x_n - \mu_k)(x_n - \mu_k)^T}{\sum_{n=1}^N \gamma_k(x_n)} \quad (6)$$

- สมการที่ (7): การอัปเดตค่าสัมประสิทธิ์การผสม (π_k)

$$\pi_k = \frac{1}{N} \sum_{n=1}^N \gamma_k(x_n) \quad (7)$$

โดยที่ $\gamma_k(x_n)$ คือ ความน่าจะเป็นที่จุดข้อมูล x_n จะเป็นของคลัสเตอร์ k

(Geeksforgeeks, 2023)

GMM สำหรับการแบ่งส่วนภาพ (image segmentation) มีจุดสำคัญดังนี้

1. GMM จะคำนวณค่าความน่าจะเป็นให้กับแต่ละพิกเซลในการเป็นสมาชิกของคลัสเตอร์ต่าง ๆ
2. GMM สามารถจำลองการกระจายข้อมูลที่ซับซ้อนได้ ทำให้เหมาะสมสำหรับการตรวจจับความเปลี่ยนแปลงของในภาพ
3. ความทนทานต่อสิ่งรบกวน (noise) ในภาพ และค่าผิดปกติ (outliers)

(Kumar, 2022)

2.3.2 Logistic Regression (LR)

LR ใช้สำหรับการจำแนกแบบไบนารี (binary classification) โดยจะทำนายค่าความน่าจะเป็นที่ข้อมูลจะอยู่ในกลุ่มใดกลุ่มหนึ่งระหว่างสองกลุ่ม ผลลัพธ์ที่ได้จะเป็นค่าไม่ต่อเนื่องกัน (discrete) มีค่าอยู่ในช่วง 0-1 ซึ่งโดยทั่วไปจะใช้จำแนกออกเป็น 2 กลุ่ม คือ กลุ่มเชิงบวก (positive class) (1) และกลุ่มเชิงลบ (negative class) (0) โดยจะใช้ฟังก์ชันลอจิสติก (logistic function) หรือ ฟังก์ชันซิกมอยด์ (sigmoid function) ซึ่งมีลักษณะดังสมการที่ (8)

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (8)$$

เมื่อ z เป็นสมการเชิงเส้น (linear equation) ดังสมการที่ (9)

$$z = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n \quad (9)$$

โดยที่ $\beta_0, \beta_1, \beta_2, \dots, \beta_n$ คือ ค่าสัมประสิทธิ์ของ LR

$x_1, x_2, \dots, x_n$ คือ คุณลักษณะของข้อมูล

ดังนั้น ค่าความน่าจะเป็นของกลุ่มเชิงบวกจะเท่ากับสมการที่ (10)

$$[P(y = 1|x_1, x_2, \dots, x_n) = \sigma(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)] \quad (10)$$

ส่วนค่าความน่าจะเป็นของกลุ่มเชิงลบจะเท่ากับสมการที่ (11)

$$[P(y = 0|x_1, x_2, \dots, x_n) = 1 - \sigma(\beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n)] \quad (11)$$

โดยที่ y คือ ค่าผลลัพธ์ที่ต้องการทำนาย

$x_1, x_2, \dots, x_n$ คือ คุณลักษณะของข้อมูล

(กิตติศักดิ์ ในจิต, 2566)

2.3.3 Spectral Index Classification (SIC)

SIC เป็นแบบจำลองที่ถูกพัฒนาขึ้นใหม่ในงาน Recursive Classification of Satellite Imaging Time-Series: An Application to Land Cover Mapping (Calatrava et al., 2024) โดยใช้ดัชนีทางสเปกตรัม (spectral indices) ซึ่งเป็นดัชนีที่คำนวณจากข้อมูลสเปกตรัม (broadband spectral indices) ของภาพถ่ายดาวเทียม เพื่อประเมินโอกาสที่พิกเซลหนึ่งจะเป็นน้ำหรือดิน

สามารถใช้ในการสกัดข้อมูลเกี่ยวกับคุณลักษณะเฉพาะของพื้นผิวโลก เช่น ความหนาแน่นของพืช ความชื้นในดิน หรือคุณภาพน้ำ ซึ่งการคำนวณใช้แถบต่อไปนี้จากดาวเทียม Sentinel-2

- Blue (B2): แถบสีฟ้า ความยาวคลื่น 490 นาโนเมตร และความกว้าง 65 นาโนเมตร ใช้ในการแยกความแตกต่างระหว่างน้ำและพืช

- Green (B3): แถบสีเขียว ความยาวคลื่น 560 นาโนเมตร และ ความกว้าง 35 นาโนเมตร ใช้ในการติดตามพืช

- Red (B4): แถบสีแดง ความยาวคลื่น 655 นาโนเมตร และความกว้าง 30 นาโนเมตร ใช้ในการติดตามพืช

- Near-infrared (B8): แถบอินฟราเรดใกล้ ความยาวคลื่น 842 นาโนเมตร และความกว้าง 115 นาโนเมตร ใช้ในการติดตามพืชและการจำแนกประเภทที่ดิน

- Short-Wave Infrared 1 (B11): แถบอินฟราเรดสั้น 1 ความยาวคลื่น 1,610 นาโนเมตร และความกว้าง 90 นาโนเมตร ใช้ในการสร้างแผนที่ลักษณะต่าง ๆ

- Short-Wave Infrared 2 (B12): แถบอินฟราเรดสั้น 2 ความยาวคลื่น 2,190 นาโนเมตร และความกว้าง 180 นาโนเมตร ใช้ในการติดตามพืช

(Adisa, 2023)

หลังจากเตรียมข้อมูลด้วยการแปลงเป็นค่าการสะท้อนและตัดให้พอดีกับขอบเขต แล้วทำการคำนวณกับช่วงคลื่นต่าง ๆ เพื่อให้ได้ดัชนีเฉพาะ ซึ่ง SIC ใช้ดัชนีทางสเปกตรัมหลัก เช่น

- NDVI (Normalized Difference Vegetation Index) สมการที่ (12) ใช้ในการวัดความเขียวของพืช และศึกษาความหนาแน่นของปริมาณพืชและสุขภาพของพืช โดยพืชที่มีสุขภาพดีจะดูดซับแสงที่มองเห็นได้ส่วนใหญ่ที่ตกกระทบ และสะท้อนแสงช่วงคลื่นอินฟราเรดใกล้ในปริมาณมาก ในขณะที่พืชที่ไม่แข็งแรงจะสะท้อนแสงที่มองเห็นได้มากขึ้น และสะท้อนแสงช่วงคลื่นอินฟราเรดใกล้ลดลง (USGS, 2019)

$$NDVI = \frac{NIR - R}{NIR + R} \quad (12)$$

โดยที่ NIR คือ ค่าพิกเซลจากช่วงคลื่นอินฟราเรดใกล้

R คือ ค่าพิกเซลจากช่วงคลื่นสีแดง

ค่า $NDVI$ จะอยู่ในช่วงตั้งแต่ -1 ถึง +1 แต่ไม่มีไบโมาสเขียวใดที่ให้ค่าใกล้เคียงกับศูนย์ เพราะค่าเป็นศูนย์หมายถึงไม่มีพืช และค่าที่ใกล้เคียงกับ +1 (0.8–0.9) แสดงถึงความหนาแน่นสูงสุดของไบโมาสเขียว (Earth Observatory, 2000)

- NDWI (Normalized Difference Water Index) สมการที่ (13) ใช้วัดปริมาณน้ำใน
ใบพืช

$$NDWI = \frac{NIR - SWIR}{NIR + SWIR} \quad (13)$$

โดยที่ *NIR* คือ ค่าพิิกเซลจากช่วงคลื่นอินฟราเรดใกล้

SWIR คือ ค่าพิิกเซลจากช่วงคลื่นอินฟราเรดสั้น

ค่า *NDWI* จะอยู่ในช่วงตั้งแต่ 1 ถึง -1 โดยค่าที่น้อยกว่า 0.3 จะหมายถึงไม่มีน้ำ และ
ค่าที่มากกว่าหรือเท่ากับ 0.3 จะหมายถึงมีน้ำ (McFeeters, 2013)

- MNDWI (Modified Normalized Water Index) สมการที่ (14) เป็นดัชนีที่ถูก
ปรับปรุงประสิทธิภาพในการตรวจจับแหล่งน้ำ

$$MNDWI = \frac{Green - SWIR}{Green + SWIR} \quad (14)$$

โดยที่ *Green* คือ ค่าพิิกเซลจากช่วงคลื่นสีเขียว

SWIR คือ ค่าพิิกเซลจากช่วงคลื่นอินฟราเรดสั้น

ค่า *MNDWI* ถูกใช้ในการแยกแยะระหว่างพื้นที่แหล่งน้ำและพื้นที่ที่ไม่ใช่ น้ำ โดยค่าที่
สูงกว่าจะแสดงถึงแหล่งน้ำ (ESRI, 2018)

SIC มีหลักการทำงานดังนี้

1. คำนวณค่าดัชนีสเปกตรัม $y(z_t)$ จากค่าพิิกเซล เช่น MNDWI ดังสมการที่ (15)

$$y(z_t) = \frac{Z_{t,Green} - Z_{t,SWIR}}{Z_{t,Green} + Z_{t,SWIR}} \quad (15)$$

2. คำนวณฟังก์ชันเกาส์เซียนสำหรับแต่ละกลุ่ม ดังสมการที่ (16)

$$f_{c_t}(y(z_t)) = \frac{1}{\sigma_{c_t}\sqrt{2\pi}} \exp\left(-\frac{1}{2}\left(\frac{y(z_t) - \mu_{c_t}}{\sigma_{c_t}}\right)^2\right) \quad (16)$$

โดยที่ μ_{c_t} คือ ค่าเฉลี่ยของกลุ่ม

σ_{c_t} คือ ส่วนเบี่ยงเบนมาตรฐานของกลุ่ม

$y(z_t)$ คือ ค่าดัชนีสเปกตรัมของพิิกเซล

3. คำนวณความน่าจะเป็นของแต่ละกลุ่ม ดังสมการที่ (17)

$$p(C_t|z_t) = \frac{f_{C_t}(y(z_t))}{\sum_{C'_t \in \mathbb{C}} f_{C'_t}(y(z_t))} \quad (17)$$

4. การขีดแบ่ง (thresholding) ของแต่ละกลุ่ม ใช้ค่า τ และพารามิเตอร์ μ, σ

- ช่วงของกลุ่มที่ j มีความยาว $L_j = \tau_j - \tau_{j-1}$
- ค่าเฉลี่ยของแต่ละช่วง $\mu_j = \frac{L_j}{2} + \tau_{j-1}$
- ส่วนเบี่ยงเบนมาตรฐาน $\sigma_j = \frac{L_j}{2}$

2.3.4 DeepWaterMap (DWM)

DWM เป็น เครือข่ายประสาทเทียมแบบคอนโวลูชันเต็มรูปแบบ (Fully Convolutional Neural Network: FCN) ที่ได้รับการออกแบบมาเพื่อจำแนกน้ำจากภาพถ่ายดาวเทียม Landsat โดยใช้วิธีการเรียนรู้เชิงลึก พัฒนามาจาก เครือข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) โดยได้ปรับเปลี่ยนเลเยอร์ที่เชื่อมต่อทั้งหมดให้เป็นเลเยอร์คอนโวลูชันทำให้สามารถคาดการณ์ที่ทุกพิกเซลได้ เพื่อรับมือกับความท้าทายในการจำแนกประเภทของพื้นผิวในบริบทที่มีความซับซ้อนต่าง ๆ โดยเรียนรู้ลักษณะของแหล่งน้ำจากข้อมูลที่ได้มาจากทั่วโลกแบบจำลองที่ถูกฝึกฝนแล้วสามารถแยกน้ำออกจากพื้นดิน หิมะ น้ำแข็ง เมฆ และเงาได้

สถาปัตยกรรมการเข้ารหัสและการถอดรหัส ประกอบด้วย

1. การเชื่อมต่อแบบการต่อรวม (concatenation) ใช้การเชื่อมต่อระหว่างเลเยอร์ที่ไม่ต่อเนื่องโดยการต่อรวม ผลลัพธ์จากการคำนวณที่ได้จากหลายสเกลแทนการรวม (summation) การใช้เลเยอร์คอนโวลูชันในการผสม (fuse) คุณลักษณะจากหลายสเกลดังสมการที่ (18)

$$Output = Conv(Concat(A, B)) \quad (18)$$

โดยที่ A และ B คือ เลเยอร์ที่เชื่อมต่อ

2.การเชื่อมต่อแบบข้าม (Skip) เชื่อมต่อไปยังเลเยอร์ก่อนหน้านี้เพื่อรักษา คุณลักษณะที่สำคัญจากเลเยอร์ที่ต่างกัสดังสมการที่ (19)

$$Output_{skip} = Output_{conv} + Output_{previous} \quad (19)$$

ใช้ median frequency balanced cross-entropy เพื่อแก้ปัญหาค่าความไม่สมดุลของกลุ่ม โดยการกำหนดน้ำหนักให้กับกลุ่มที่มีความถี่ต่ำกว่า ดังสมการที่ (20)

$$w_c = \frac{f_{median}}{f_c} \quad (20)$$

โดยที่ w_c คือ น้ำหนักของกลุ่ม c

fc คือ ความถี่ของกลุ่ม c

$fmedian$ คือ ความถี่กลางของกลุ่มทั้งหมด

ใช้ adam optimizer สำหรับการปรับน้ำหนักของแบบจำลอง ดังสมการที่ (21) และ (22) โดยมีการฝึกแบบแบทช์ย่อย (minibatch) ด้วยตัวอย่าง 8 ตัวอย่างต่อแบทช์

$$m_t = \beta_1 m_t + (1 - \beta_1) g_t \quad (21)$$

$$v_t = \beta_2 v_t + (1 - \beta_2) g_{2t} \quad (22)$$

โดยที่ m_t คือ โมเมนตัม (momentum)

v_t คือ การปรับตัว (adaptation)

g_t คือ การไหลแบบไล่ระดับ (gradient flow)

ใช้ ค่าความเที่ยง (precision), ค่าการเรียกคืน (recall), และ ค่าประสิทธิภาพ F1 (F1-score) เพื่อเปรียบเทียบประสิทธิภาพของ DWM กับแบบจำลองอื่น ๆ เช่น MLP และ MNDWI

DWM แสดงให้เห็นถึงประสิทธิภาพที่ดีในการจำแนกพื้นที่น้ำเมื่อเปรียบเทียบกับวิธีการเดิม (MNDWI และ MLP) แต่มีข้อจำกัดในการจำแนกกลุ่มที่มีการแสดงผลต่ำ เช่น เมฆและเงา (Isikdogan et al., 2017)

2.3.5 WatNet (WN)

WN เป็นแบบจำลองการเรียนรู้เชิงลึกที่พัฒนาขึ้นเพื่อการทำแผนที่น้ำจากภาพถ่ายดาวเทียมในสภาพแวดล้อมที่มีความซับซ้อน เช่น พื้นที่เมืองและพื้นที่ภูเขา โดยมีวัตถุประสงค์หลักเพื่อปรับปรุงความแม่นยำในการตรวจจับแหล่งน้ำและลดความสับสนระหว่างน้ำและพื้นผิวอื่น ๆ ที่มีลักษณะคล้ายกัน

สร้างขึ้นด้วยการรวมกันของแบบจำลองการจำแนกที่ทันสมัย โดยมีการใช้ชุดข้อมูลที่ชื่อว่า ESWKB (Earth Surface Water Knowledge Base) ซึ่งรวบรวมจากภาพถ่ายดาวเทียมที่มีคุณภาพสูง เพื่อฝึกฝนแบบจำลองให้สามารถเรียนรู้ลักษณะหรือรูปแบบต่าง ๆ ของแหล่งน้ำได้อย่างมีประสิทธิภาพ ประกอบด้วยโครงสร้างที่สามารถเรียนรู้คุณสมบัติของน้ำจากภาพถ่ายได้ มี

การปรับแต่งเพื่อตอบสนองต่อการทำแผนที่น้ำ ซึ่งช่วยให้สามารถจัดการกับลักษณะเฉพาะของน้ำในสภาพแวดล้อมที่ซับซ้อนได้ดียิ่งขึ้น

WN ใช้ภาพถ่ายดาวเทียม Sentinel-2 โดยจะนำข้อมูลจากช่วงคลื่นที่ตามองเห็น ช่วงคลื่นอินฟราเรดใกล้ และช่วงคลื่นอินฟราเรดสั้น มาประมวลผลเป็นแพทช์ (patches) ที่ขนาด 512x512 พิกเซล จากนั้นจึงนำเข้าสู่แบบจำลองที่ผ่านการฝึกฝนเพื่อทำนายว่าแต่ละแพทช์มีแหล่งน้ำหรือไม่ ซึ่ง WN แบ่งการทำแผนที่น้ำออกเป็น 4 ขั้นตอน


1. เลือกช่วงคลื่นที่สำคัญจากภาพถ่ายดาวเทียม
2. แปลงภาพถ่ายให้เป็นแพทช์ขนาด 512x512
3. ใช้แบบจำลองที่ฝึกฝนแล้วทำนายผลของแต่ละแพทช์
4. แปลงผลลัพธ์จากแพทช์กลับมาเป็นภาพแผนที่น้ำทั้งหมด

แล้วจึงใช้ MIoU (Mean Intersection over Union) ในการประเมินความแม่นยำในการแยกแหล่งน้ำจากภาพถ่ายดาวเทียม

WN มีประสิทธิภาพสูงกว่าแบบจำลองการทำแผนที่น้ำแบบดั้งเดิม เช่น MNDWI และ OBIA โดยเฉพาะในพื้นที่ทดสอบที่มีสภาพแวดล้อมที่หลากหลาย สามารถทำแผนที่น้ำได้อย่างมีประสิทธิภาพในพื้นที่ที่มีปัญหา เช่น เมฆ เงา และพื้นผิวที่มีสีเข้ม (Luo et al., 2021)

2.3.6 Recursive Bayesian Classification (RBC)

RBC Framework จากงานวิจัย Recursive Classification of Satellite Imaging Time-series: An Application to Land Cover Mapping (Calatrava et al., 2024) นำผลลัพธ์ของแบบจำลองที่จำแนกได้จากแต่ละภาพมารวมกับข้อมูลจากภาพก่อนหน้าโดยใช้ทฤษฎีของเบย์ (Bayes' theorem) เพื่อให้การจำแนกประเภทมีความเสถียรและแม่นยำขึ้นในบริบทของการทำงานกับข้อมูลภาพหลายช่วงเวลา ถูกออกแบบมาให้ใช้งานได้กับแบบจำลองก่อกำเนิด (generative model) และแบบจำลองจำแนก (discriminative model) โดยมีการเพิ่มการควบคุมผ่านพารามิเตอร์ ϵ ซึ่งกำหนดความน่าจะเป็นในการเปลี่ยนกลุ่มของพิกเซล ดังแสดงในภาพประกอบ 4



ภาพประกอบ 4 กรอบแนวคิด RBC

ที่มา: Calatrava et al., (2024). Recursive Classification of Satellite Imaging Time-series: An Application to Land Cover Mapping

การคำนวณของ RBC อาศัยหลักการทฤษฎีของเบย์เพื่ออัปเดตค่าความน่าจะเป็นของกลุ่มในแต่ละช่วงเวลา โดยอิงจากข้อมูลที่มีอยู่ก่อนหน้า RBC มีกระบวนการคำนวณดังนี้

1. กำหนดข้อมูลเบื้องต้น ความน่าจะเป็นของกลุ่ม $p(C_0)$ ถูกตั้งค่าเป็นค่าตั้งต้นที่เท่ากันสำหรับทุกกลุ่มเนื่องจากไม่มีข้อมูลเบื้องต้น
2. การคำนวณความน่าจะเป็นก่อนหน้า (prior probability) ดังสมการที่ (23)

$$p(C_t | z_{1:t-1}) = \sum_{C_{t-1} \in C} p(C_t | C_{t-1}) p(C_{t-1} | z_{1:t-1}) \quad (23)$$

โดยที่ $p(C_t | z_{1:t-1})$ คือ ค่าความน่าจะเป็นก่อนหน้า

$p(C_t | C_{t-1})$ คือ ค่าความน่าจะเป็นของการเปลี่ยนสถานะ (transition probability) ที่ใช้กำหนดความน่าจะเป็นของการเปลี่ยนจาก C_{t-1} ไปเป็น C_t (กำหนดโดย ϵ)

$p(C_{t-1} | z_{1:t-1})$ คือ ค่าความน่าจะเป็นภายหลังจากช่วงเวลาก่อนหน้า (ใช้เป็นค่าก่อนหน้าในรอบถัดไป)

3. คำนวณค่าความเป็นไปได้จากข้อมูลใหม่ $p(z_t | C_t)$

- แบบจำลองก่อกำเนิด ใช้ในการคำนวณค่าความเป็นไปได้ (likelihood) ของพิกเซลในภาพ โดยใช้สมมติฐานว่ากลุ่มในเวลานั้นอาจมีความสัมพันธ์กับกลุ่มในช่วงเวลาที่ผ่านมา
- แบบจำลองจำแนก ใช้การคำนวณความน่าจะเป็นโดยตรงจากข้อมูลพิกเซลในช่วงเวลาปัจจุบันและไม่พิจารณาความสัมพันธ์ระหว่างกลุ่มในช่วงเวลาที่ผ่านมา

4. คำนวณค่าความน่าจะเป็นภายหลัง (posterior probability) ดังสมการที่ (24) ใช้ทฤษฎีของเบย์เพื่ออัปเดตค่าความน่าจะเป็นของกลุ่ม C_t เมื่อมีข้อมูลใหม่เข้ามา

$$p(C_t|z_{1:t}) = \frac{p(z_t|C_t)p(C_t|z_{1:t-1})}{p(z_t|z_{1:t-1})} \quad (24)$$

โดยที่ $p(C_t|z_{1:t})$ คือ ค่าความน่าจะเป็นภายหลังของกลุ่ม C_t ณ เวลาปัจจุบัน หลังจากได้รับข้อมูล $z_{1:t}$

$p(z_t|C_t)$ คือ ความเป็นไปได้ของข้อมูลใหม่ z_t เมื่ออยู่ในกลุ่ม C_t (จากข้อ 3)

$p(C_t|z_{1:t-1})$ คือ ค่าความน่าจะเป็นภายหลังของกลุ่ม C_t ที่อัปเดตจากข้อมูลก่อนหน้า $z_{1:t-1}$ (จากข้อ 2)

$p(z_t|z_{1:t-1})$ คือ ค่าความน่าจะเป็นของ z_t โดยไม่ขึ้นกับกลุ่ม C_t ทำหน้าที่เป็นค่าปรับสเกล (normalization factor)

5. ตัดสินใจเลือกกลุ่ม C_t ที่มีค่าความน่าจะเป็นภายหลังสูงสุด เป็นผลลัพธ์สุดท้าย ดังสมการที่ (25)

$$\hat{C}_t = \arg \max_{C_t, n \in \mathbb{C}} p(C_t|z_{1:t}) \quad (25)$$

6. ทำซ้ำสำหรับช่วงเวลาถัดไป ใช้ค่าความน่าจะเป็นภายหลังของรอบนี้เป็นค่าความน่าจะเป็นก่อนหน้าของรอบถัดไป

RBC ถูกออกแบบให้สามารถนำไปใช้ร่วมกับแบบจำลองทั้งแบบก่อกำเนิดและแบบจำแนก โดยเฉพาะในงานจำแนกประเภทภาพถ่ายดาวเทียมแบบหลายช่วงเวลา เพื่อให้ทนทานต่อการเปลี่ยนแปลงของภาพที่เกิดจากแสงหรือสภาพอากาศ ตัวอย่างแบบจำลองที่ใช้ในงานวิจัยได้แก่

- แบบจำลองก่อกำเนิด คือ GMM ใช้สมมติฐานว่าข้อมูลในแต่ละกลุ่มมีการกระจายแบบปกติหลายมิติ (multivariate gaussian) โดย recursive classifiers จะช่วยปรับปรุงโอกาสของการจำแนกแต่ละฟิสิกเซลล์เมื่อเวลาผ่านไป

- แบบจำลองจำแนก คือ LR ในการคำนวณโอกาสของฟิสิกเซลล์ที่เป็นกลุ่มต่าง ๆ โดยที่ RBC ช่วยลดผลกระทบจากข้อมูลที่เป็นค่านอกเกณฑ์หรือการเปลี่ยนแปลงในระดับเล็กน้อยที่อาจทำให้แบบจำลองจำแนกผิดพลาด

- SIC แปลงค่าของดัชนีสเปกตรัม เช่น MNDWI ให้เป็น ค่าความน่าจะเป็น โดยที่ RBC สามารถเพิ่มความทนทานในการจำแนกประเภทโดยเฉพาะกับพิกเซลที่มีการเปลี่ยนแปลงเล็กน้อย

- แบบจำลองการเรียนรู้เชิงลึก คือ DWM และ WN ที่ถูกฝึกมาแล้ว และ RBC จะถูกนำมาประยุกต์ใช้โดยไม่ต้องฝึกข้อมูลใหม่ ช่วยเพิ่มความทนทานต่อผลกระทบจากข้อมูลที่มีการเปลี่ยนแปลงขนาดเล็ก

2.4 อัลกอริทึมการตรวจจับสนิมและเงาของเมฆ

อัลกอริทึมการตรวจจับสนิมและเงาของเมฆ (Cloud/Shadow Detection Algorithm Based on Spectral Indices: CSD-SI) จากงานวิจัย Cloud/Shadow Detection Based on Spectral Indices for Multi/Hyperspectral Optical Remote Sensing Imagery (Zhai et al., 2018) ใช้ดัชนีสเปกตรัมเพื่อประยุกต์ใช้กับตัวรับรู้การสำรวจจากระยะไกลทั้งแบบหลายช่วงคลื่นและแบบช่วงคลื่นความถี่ละเอียดสูง

เมฆมีลักษณะการสะท้อนค่อนข้างเฉพาะตัวในภาพถ่ายดาวเทียม ความสว่างของพื้นที่ที่มีเมฆปกคลุมจะเพิ่มขึ้นอย่างมากในช่วงคลื่นที่ตามองเห็นได้ ช่วงคลื่นอินฟราเรดใกล้ และช่วงคลื่นอินฟราเรดสั้น ซึ่งหมายความว่า Digital Number (DN) ของพิกเซลที่เป็นเมฆจะสูงกว่าวัตถุอื่น ๆ ในช่วงคลื่นเหล่านี้อย่างมาก

จากลักษณะการสะท้อนดังกล่าว จึงมีการพัฒนา Cloud Index (CI) เพื่อใช้จำแนกเมฆออกจากวัตถุอื่น ๆ

1. สมการที่ (26) CI_1 นำมาใช้เพื่อวัดความคล้ายคลึงของลักษณะการสะท้อนในช่วงคลื่นที่ตามองเห็นและช่วงคลื่นอินฟราเรด โดยทั่วไป ค่าของ CI_1 มักอยู่ในช่วงคลื่นใกล้กับค่า 1 เนื่องจากเมฆมักมีลักษณะการสะท้อนคล้ายคลึงกันในช่วงคลื่นทั้งสอง

$$CI_1 = \frac{B_{NIR} + 2 \cdot B_{SWIR}}{B_B + B_G + B_R} \quad (26)$$

2. สมการที่ (27) CI_2 คือค่าเฉลี่ยของแถบที่เกี่ยวข้องทั้งหมด เพื่อบอกความสว่างของเมฆ

$$CI_2 = \frac{B_B + B_G + B_R + B_{NIR} + B_{SWIR1} + B_{SWIR2}}{6} \quad (27)$$

โดยที่ B_B, B_G และ B_R : แถบสีน้ำเงิน สีเขียว และสีแดง

B_{NIR} : แถบคลื่นอินฟราเรดใกล้

B_{SWIR1} และ B_{SWIR2} : แถบอินฟราเรดสั้นที่มีความยาวคลื่นสั้นกว่าและยาวกว่า สามารถตรวจจับเมฆได้ด้วยสมการที่ (28)

$$(|CI_1 - 1| < T_1) \text{ หรือ } (CI_2 > T_2) \quad (28)$$

โดยที่ T_1 : ค่าขีดแบ่งขนาดเล็ก (small threshold)

T_2 : ค่าขีดแบ่งขนาดใหญ่ (large threshold)

จากมุมมองทางทฤษฎี การรวมทั้งสองเกณฑ์นี้ช่วยให้สามารถตรวจจับเมฆในภาพได้ พร้อมทั้งลดปัจจัยรบกวนที่เกิดจากวัตถุพื้นดินที่มีความสว่าง เช่น หิน ดิน และถนนคอนกรีต

เมื่อเทียบกับการตรวจจับเมฆ การตรวจจับเงาเมฆมีความซับซ้อนและยากกว่า เนื่องจากเงาเมฆสามารถทอดลงบนวัตถุพื้นดินได้ทุกประเภท และค่า DN แสดงถึงลักษณะของเงาเมฆได้เพียงบางส่วน ซึ่งหมายความว่าลักษณะการสะท้อนของเงาเมฆขึ้นอยู่กับวัตถุพื้นดินที่อยู่ด้านล่างอย่างมาก ดังนั้น การกำหนดกฎเกณฑ์การตรวจจับที่มีประสิทธิภาพจึงเป็นเรื่องยาก นอกจากนี้ ลักษณะการสะท้อนของวัตถุมีดบางประเภท (เช่น แหล่งน้ำและเงาภูมิประเทศ) มีความคล้ายคลึงกับเงาเมฆ ซึ่งทำให้การแยกเงาเมฆออกจากวัตถุพื้นดินอื่น ๆ เป็นงานที่ท้าทาย

การออกแบบ Cloud shadow index (CSI) ในขั้นแรกใช้วิธีเดียวกับการตรวจจับเมฆ โดยออกแบบดัชนีเชิงสเปกตรัมที่มีช่องสัญญาณสเปกตรัมที่แสดงถึงลักษณะเงาเมฆอย่างชัดเจนที่สุด เพื่อบอกถึงเงาเมฆที่อาจเกิดขึ้น เงาเมฆจะปรากฏออกมาผ่านแสงที่กระเจิง เนื่องจากการบังแสงอาทิตย์โดยเมฆ นอกจากนี้ การกระเจิงของชั้นบรรยากาศจะรุนแรงกว่าในความยาวคลื่นที่สั้นกว่า เช่น ช่วงคลื่นที่ตามองเห็นได้ และรังสีแบบกระเจิงในเงาจะอ่อนกว่าที่ความยาวคลื่นที่ยาวกว่า ทำให้เงาเมฆมืดกว่าสภาพแวดล้อมรอบข้าง วัตถุพื้นดินหลายชนิด (เช่น พืชพรรณ หิน และดิน) มีค่าการสะท้อนค่อนข้างสูงในช่วงคลื่นอินฟราเรดใกล้ และช่วงคลื่นอินฟราเรดสั้น ทำให้ความแตกต่างของความมืดในเงาเมฆชัดเจนยิ่งขึ้น

ด้วยลักษณะการสะท้อนดังกล่าว Cloud Shadow Index (CSI) ถูกพัฒนาขึ้นเพื่อตรวจจับเงาเมฆในภาพเชิงแสง

1. สมการที่ (29) CSI แบบเฉลี่ยของแถบอินฟราเรดใกล้ และแถบอินฟราเรดสั้น

$$CSI = \frac{B_{NIR} + B_{SWIR1}}{2} \quad (29)$$

2. สมการที่ (30) CSI แบบใช้แถบอินฟราเรดใกล้เพียงอย่างเดียว

$$CSI = B_{NIR} \quad (30)$$

แต่น้ำก็มีลักษณะมีดคล้ายกันจึงจำเป็นต้องเพิ่มข้อกำหนดเพื่อแยกน้ำออกและระบุเงาเมฆที่ทอดลงบนแหล่งน้ำ โดยพิจารณาค่าการสะท้อนที่ค่อนข้างสูงของน้ำในช่วงคลื่นสีน้ำเงิน ช่วงคลื่นนี้จึงถูกใช้ในการแยกน้ำออก โดยการตรวจจับเงาเมฆสามารถทำได้ดังสมการที่ (31)

$$(CSI < T_3) \text{ และ } (B_B < T_4) \quad (31)$$


โดยที่ T_3 และ T_4 : ค่าขีดแบ่งขนาดเล็ก

มีหลายกรณีที่เงาภูมิประเทศไม่สามารถแยกออกได้ด้วยการทดสอบสเปกตรัมเพียงอย่างเดียว เนื่องจากมีลักษณะการสะท้อนที่คล้ายคลึงกับเงาเมฆ อย่างไรก็ตาม เมฆและเงาเมฆมักจะมีความสัมพันธ์เชิงพื้นที่ เงาของเมฆจะอยู่ใต้เมฆ ซึ่งหมายความว่าเมฆและเงาเมฆควรมีการปรากฏร่วมกันเชิงพื้นที่ (spatial coexistence) โดยใช้ข้อเท็จจริงนี้ เงาเมฆเทียม (pseudo cloud shadows) สามารถถูกลบออกได้ และผลการตรวจจับจะได้รับการปรับปรุงการจับคู่เชิงพื้นที่นี้ หากพบพิกเซลเมฆในพื้นที่นั้น พิกเซลเงาเมฆที่เป็นไปได้จะถูกระบุว่าเป็นเงาเมฆจริง หากไม่พบจะถูกระบุว่าเป็นเงาเมฆเทียมและลบออก

2.5 หลักการการตรวจสอบประสิทธิภาพของแบบจำลองด้วยกระบวนการ IoU

IoU (Intersection over Union) เป็นตัวชี้วัดการประเมินผลที่ใช้วัดความแม่นยำของการตรวจจับวัตถุ (object detection) โดยในการประเมินการตรวจจับวัตถุจำเป็นต้องมี 2 องค์ประกอบ ดังแสดงในภาพประกอบ 5

- กรอบข้อมูลจริง (ground-truth bounding boxes) ซึ่งเป็นกรอบที่ได้รับการทำเครื่องหมายด้วยมือจากชุดทดสอบที่ระบุตำแหน่งของวัตถุในภาพ
- กรอบการทำนาย (predicted bounding boxes)



ภาพประกอบ 5 กรอบการทำนาย (สีแดง) กรอบข้อมูลจริง (สีเขียว) เป้าหมายคือการ
คำนวณค่า IoU ระหว่างทั้งสองกรอบ

ที่มา: Adrian Rosebrock. (2022). Intersection over Union (IoU) for object detection.
สืบค้นจาก: <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>

เมื่อพิจารณาสมการของ IoU ดังแสดงในภาพประกอบ 6 เป็นเพียงอัตราส่วน โดยตัวเศษ
คำนวณจากพื้นที่ที่ทับซ้อนกันระหว่างกรอบการทำนายและกรอบข้อมูลจริง ส่วนตัวส่วนคือพื้นที่
รวมของทั้ง 2 กรอบ เมื่อนำมาหารกันจะได้คะแนน IoU โดยคะแนน IoU ที่มากกว่า 0.5 จะถือว่าเป็น
การทำนายที่ดี

$$IoU = \frac{\text{Intersect}}{\text{Union}}$$

ภาพประกอบ 6 หลักการคำนวณ IoU

การจำแนกประเภทจะมีการทำนายป้ายกำกับของกลุ่มซึ่งจะตอบเป็นป้ายกำกับเดียวที่
ถูกต้องหรือไม่ถูกต้อง การจำแนกประเภท การคำนวณความแม่นยำ (accuracy) ทำได้ไม่ยาก แต่
ในการตรวจจับวัตถุความเป็นจริงมีโอกาสน้อยมากที่พิกัด (x, y) ของกรอบการทำนายจะตรงกับ
พิกัด (x, y) ของกรอบข้อมูลจริงอย่างสมบูรณ์ จึงต้องมีการกำหนดตัวชี้วัดการประเมินผลที่ให้กับ
กรอบการทำนายที่มีการทับซ้อนกันมากกับกรอบข้อมูลจริง ดังแสดงในภาพประกอบ 7



ภาพประกอบ 7 การกำหนดตัวชี้วัดการประเมินผล IoU

ที่มา: Adrian Rosebrock. (2022). Intersection over Union (IoU) for object detection. สืบค้นจาก: <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>

นอกจากการใช้งาน IoU ด้วย Python และ NumPy แล้วยังมีการใช้งาน IoU อื่น ๆ ที่อาจเหมาะสมกว่าสำหรับแอปพลิเคชันและโปรเจกต์ เช่น เมื่อฝึกฝนแบบจำลองการเรียนรู้เชิงลึกโดยใช้ TensorFlow, Keras หรือ PyTorch (Rosebrock, 2022)

2.6 งานวิจัยที่เกี่ยวข้อง

2.6.1 Recursive Classification of Satellite Imaging Time-Series: An Application to Land Cover Mapping (Calatrava et al., 2024)

บทความนี้นำเสนอกรอบแนวคิดกระบวนการ recursive classification ที่ช่วยปรับปรุงกระบวนการตัดสินใจในอัลกอริทึมการจำแนกประเภทการใช้ที่ดินแบบหลายช่วงเวลาและหลายสเปกตรัม RBC เป็นวิธีการที่ช่วยปรับปรุงการจำแนกประเภทภาพหลายช่วงเวลาโดยการใช้ผลลัพธ์การจำแนกประเภทก่อนหน้านี้เพื่อเพิ่มความทนทานต่อการเปลี่ยนแปลงที่ไม่พึงประสงค์ เช่น ความแปรผันของแสงและสภาพบรรยากาศ


ในงานวิจัยนี้มีการใช้แบบจำลองการจำแนกประเภทหลายแบบเพื่อเปรียบเทียบประสิทธิภาพและทดสอบการวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมแบบหลายช่วงเวลา โดยเฉพาะในการทำแผนที่น้ำ (water mapping) โดยใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 บริเวณเขื่อนที่เมืองโอโรวิลล์ รัฐแคลิฟอร์เนีย (พื้นที่ทดสอบ 1a และ 1b) และพื้นที่ลุ่มน้ำแม่น้ำชาร์ลส์ในเมืองบอสตัน รัฐแมสซาชูเซตส์ ประเทศสหรัฐอเมริกา (พื้นที่ทดสอบ 2) และการตรวจจับการตัดไม้ทำลายป่า (deforestation detection) (พื้นที่ทดสอบ 3) ใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2

บริเวณป่าฝน อเมซอน แบบจำลองถูกแบ่งเป็นแบบที่ไม่ใช้ recursive classifiers และแบบที่ใช้ recursive classifiers

การทำแผนที่น้ำใน 2 พื้นที่ทดสอบ เมืองโอโรวิลล์ รัฐแคลิฟอร์เนีย และพื้นที่ลุ่มน้ำแม่น้ำชาร์ลส์ในเมืองบอสตัน รัฐแมสซาชูเซตส์ พบว่าแบบจำลองที่ทำ recursive classifiers (RGMM, RLR, RSIC) มีความสามารถในการจัดการกับการเปลี่ยนแปลงของแสงและสภาพอากาศได้ดีมากกว่าแบบจำลองที่ไม่ใช้กระบวนการ recursive classifiers เช่น GMM และ LR

แบบจำลองการเรียนรู้เชิงลึก DWM และ WN ก็แสดงผลลัพธ์ที่ดีเช่นกัน แต่ RBC ช่วยให้ผลลัพธ์มีความเสถียรมากขึ้นโดยไม่ต้องใช้ข้อมูลฝึกเพิ่มเติม

การทดสอบการตรวจจับการตัดไม้ทำลายป่าในพื้นที่ป่าอเมซอนพบว่าแบบจำลองที่ทำ recursive classifiers (RGMM, RLR, RSIC) สามารถตรวจจับพื้นที่ที่มีการตัดไม้ทำลายป่าได้ดีกว่าแบบที่ไม่ใช้ recursive classifiers โดย RSIC สามารถตรวจจับการเปลี่ยนแปลงในพื้นที่ที่มีการตัดไม้ทำลายป่าได้แม่นยำที่สุด แสดงดังภาพประกอบ 8



ภาพประกอบ 8 boxplot แสดงผลการกระจายตัวของค่าความแม่นยำ SIC, GMM, LR, DWM และ WN (สีเหลือง) และ recursive (สีฟ้า)

ที่มา: Calatrava et al., (2024). Recursive Classification of Satellite Imaging Time-series: An Application to Land Cover Mapping


การวิเคราะห์ความไวของพารามิเตอร์ ϵ ซึ่งเป็นพารามิเตอร์หลักที่ควบคุมโอกาสการเปลี่ยนแปลงกลุ่มของพิกเซล พบว่าค่าพารามิเตอร์ ϵ ที่ต่ำช่วยให้แบบจำลองมีความเสถียรมากขึ้น ในขณะที่ค่าพารามิเตอร์ที่สูงเกินไปจะทำให้แบบจำลองไวต่อการเปลี่ยนแปลงที่ไม่พึงประสงค์ เช่น แสงหรือภาพผิดปกติ

RSIC แสดงความไวต่อพารามิเตอร์ ϵ มากที่สุด ขณะที่ RGMM มีความไวต่ำกว่า ทำให้ RGMM มีความเสถียรในการเปลี่ยนแปลงพารามิเตอร์มากกว่า

2.6.2 Automatic Extraction of Surface Water Based on Lightweight Convolutional Neural Network (Wan & Yong, 2023)

งานวิจัยนี้ได้นำเสนอการใช้แถบอินฟราเรดร้อน (thermal infrared band) จากภาพถ่ายดาวเทียม Landsat-8 เพื่อเพิ่มความทนทาน (robustness) ของแบบจำลอง ระหว่างการฝึกฝนใช้การสุ่มพลิกภาพและการหมุนภาพ

และได้มีการนำเสนอแบบจำลอง EDCM (EfficientNetV2 and DeepLabV3+ Comprehensive Model) ซึ่งพัฒนาโดยใช้การเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน เพื่อสกัดคุณลักษณะของภาพในหลายขนาด (multi-scale features) ดังแสดงในภาพประกอบ 9 โดยแบบจำลองนี้ผสมผสานเทคโนโลยีด้านคอมพิวเตอร์วิทัศน์ (computer vision) และนำเสนอโครงข่ายประสาทเทียมแบบน้ำหนักเบา (lightweight neural network) สำหรับการประมวลผลข้อมูลภาพถ่ายดาวเทียม



ภาพประกอบ 9 กระบวนการของ EDCM

ที่มา: Wan & Yong. (2023). Automatic Extraction of Surface Water Based on Lightweight Convolutional Neural Network

แบบจำลอง EDCM ประกอบด้วยสองส่วนหลัก ได้แก่

1. ส่วนเข้ารหัส: ใช้การคอนโวลูชันแบบ Depthwise (DW) และ Pointwise (PW) ซึ่งเป็นองค์ประกอบของโครงข่าย EfficientNetV2 (Tan & Le, 2021)

- DW: ทำหน้าที่ดึงคุณลักษณะเชิงลึก (deep-layer features) ของภาพ เพื่อช่วยในการแยกแยะพื้นที่น้ำได้แม่นยำยิ่งขึ้น

- PW: ทำหน้าที่รวมข้อมูลที่ได้จากการคอนโวลูชันแบบ DW เพื่อเพิ่มประสิทธิภาพของการสกัดคุณลักษณะ

2. ส่วนถอดรหัส: ใช้โครงข่าย DeepLabV3+ (Chen et al., 2018) (Chen et al., 2018) ร่วมกับเทคนิค Atrous Spatial Pyramid Pooling (ASPP) เพื่อดึงคุณลักษณะจากหลายระดับความละเอียด (multi-scale features) โดยผสมผสานขอบเขตภาพจากคุณลักษณะระดับต่ำ (low-level features) เข้ากับคุณลักษณะระดับสูง (high-level features) เพื่อให้ได้ผลลัพธ์การจำแนกที่แม่นยำมากยิ่งขึ้น

ในการประเมินผลความแม่นยำใช้ MIOU เพื่อวัดความแม่นยำในการสกัดน้ำ หากค่า IoU มากกว่า 50% ถือว่าแบบจำลองสามารถทำนายได้ดี ซึ่งแบบจำลองถูกทดสอบใน 3 สถานการณ์ที่มีลักษณะแตกต่างกัน คือ ภูเขา เมือง และพื้นที่มีเมฆ และมีการเปรียบเทียบประสิทธิภาพ EDCM กับแบบจำลองอื่น ๆ ดังแสดงในภาพประกอบ 10 และตาราง 3 โดยสามารถอธิบายผลได้ดังนี้

1. วิธีการดั้งเดิม

- MNDWI: มีความสามารถในการลดอิทธิพลของเงาเมฆในภาพถ่ายดาวเทียมได้ในระดับหนึ่ง แต่จำเป็นต้องปรับค่าขีดแบ่งหลายครั้งเพื่อให้เหมาะสมกับแต่ละพื้นที่ และยังไม่สามารถหลีกเลี่ยงปัญหาในบริเวณที่มีการสะท้อนแสงสูงได้อย่างมีประสิทธิภาพ

- AWEIsh: ลดการรบกวนจากเงาเมฆได้อย่างมีประสิทธิภาพแต่ยังคงมีปัญหาในพื้นที่ที่มีการสะท้อนแสงสูง เช่น เมฆและพื้นที่ภูเขา


- SVM: มีผลลัพธ์การสกัดที่แย่ที่สุด เนื่องจากสเปกตรัมของน้ำและเงามีความคล้ายคลึงกัน และไม่พิจารณาข้อมูลพื้นผิวมากนักในการเลือกตัวอย่าง

2. วิธีการเรียนรู้เชิงลึก

- EDCM แสดงผลลัพธ์ที่ดีกว่าวิธีการเรียนรู้เชิงลึกอื่น ๆ โดยเฉพาะในการสกัดข้อมูลทีละเฉียดของน้ำ เช่น แม่น้ำเล็ก ๆ ในพื้นที่เมือง ซึ่งไม่สามารถจับข้อมูลได้อย่าง DeepLabV3+ และ DWM V2

- WN แสดงผลลัพธ์ที่ใกล้เคียงกับแบบจำลอง EDCM แต่ยังคงมีความแม่นยำต่ำกว่า เนื่องจาก EDCM ได้มีการประยุกต์ใช้กลไกการบีบกระตุ้นความสนใจ (squeeze and excitation attention mechanism ร่วมกับการคอนโวลูชันแบบ DW ซึ่งช่วยเพิ่มประสิทธิภาพในการสกัดคุณลักษณะจากข้อมูลภาพได้ดียิ่งขึ้น

- การใช้ช่วงคลื่นอินฟราเรดความร้อนใน EDCM ช่วยลดการรบกวนจากอนุภาคลอยในอากาศ และทำให้ข้อมูลของน้ำเด่นชัดขึ้น



ภาพประกอบ 10 ผลการสกัดพื้นที่น้ำจากภาพถ่ายดาวเทียม Landsat-8 Bands 5, 4 และ 3 ใช้ภาพสีผิด (false color) และเปรียบเทียบผลของแต่ละแบบจำลอง

ที่มา: Wan & Yong. (2023). Automatic Extraction of Surface Water Based on Lightweight Convolutional Neural Network

ตาราง 3 ค่าความแม่นยำของแต่ละแบบจำลอง

Testing region	Index	MNDWI	AWEI _{sh}	SVM	DeepLabV3+	DeepwatermapV2	WatNet	EDCM
Urban region	PA	75.73%	87.89%	77.12%	91.60%	93.19%	96.82%	98.02%
	UA	73.89%	82.11%	79.11%	95.91%	97.82%	92.89%	96.31%
	OA	74.36%	83.18%	78.56%	92.21%	95.60%	94.68%	97.01%
Mountain region	PA	80.37%	89.72%	76.32%	90.77%	91.21%	90.29%	92.89%
	UA	76.10%	83.97%	72.99%	94.15%	97.39%	95.55%	97.59%
	OA	81.98%	86.15%	73.18%	93.17%	94.48%	92.98%	95.67%
Cloudy region	PA	77.86%	88.74%	81.42%	90.86%	92.07%	91.27%	93.90%
	UA	87.74%	84.63%	78.89%	94.09%	96.31%	96.88%	96.01%
	OA	84.88%	85.77%	80.71%	91.22%	94.66%	93.46%	95.28%

ที่มา: Wan & Yong. (2023). Automatic Extraction of Surface Water Based on Lightweight Convolutional Neural Network

ในการใช้ข้อมูลแถบอินฟราเรดร้อนแทนแถบสีฟ้าช่วยลดผลกระทบจากการกระจายแสงในบรรยากาศและทำให้แบบจำลองสังกัดน้ำได้แม่นยำมากขึ้น เนื่องจากน้ำมีอุณหภูมิต่ำที่สุดเมื่อเทียบกับพื้นผิวธรรมชาติอื่น ๆ เนื่องจากความสามารถในการเก็บความร้อนสูงกว่าวัตถุอื่น ดังนั้นการนำแถบนี้มาใช้จะช่วยให้แบบจำลองมีความเข้าใจที่หลากหลายขึ้นเกี่ยวกับลักษณะของพื้นที่น้ำ

2.6.3 On Water and Ice Classification from Sentinel-2 Imagery Using Machine Learning (Jugier et al., 2022)

ภาพถ่ายดาวเทียมแบบหลายช่วงคลื่นมีประสิทธิภาพในการจำแนกพื้นที่ระหว่างน้ำ พื้นดิน และน้ำแข็ง อย่างไรก็ตาม ยังคงพบกรณีที่ทำให้เกิดความสับสนได้ เช่น พื้นที่น้ำขุ่นหรือทะเลสาบน้ำเค็ม ซึ่งอาจมีลักษณะคล้ายกับหิมะหรือน้ำแข็ง ในการศึกษาที่ใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 L2A จำนวน 31 ภาพ ซึ่งผ่านการปรับแก้เชิงบรรยากาศแล้ว โดยภาพทั้งหมดได้รับการติดป้ายกำกับ และนำมาใช้ในการฝึกแบบจำลอง Support Vector Machine (SVM) และการสุ่มป่าไม้ (random forest)

ภาพถ่ายดาวเทียม Sentinel-2 ใช้ข้อมูล L2A พื้นที่ศึกษาใช้พื้นที่ที่มีการปกคลุมของเมฆต่ำเพื่อให้ได้ผลลัพธ์ที่ดีที่สุด ได้รับการปรับแก้เชิงบรรยากาศโดยใช้ MAJA v4.5.3 atmospheric processor ซึ่งรวมถึงการตรวจจับเมฆ (cloud detection) และการใช้ข้อมูลพื้นผิวดิจิทัลของโครงการโคเปอร์นิคัส ที่มีความละเอียดเชิงพื้นที่ 30 เมตร ประเภทของภาพที่ใช้ในการศึกษามีกรณีของน้ำลึก น้ำขุ่น น้ำแข็งบาง และทะเลสาบน้ำเค็ม ซึ่งเป็นกรณีที่สามารถสร้างความสับสนระหว่างน้ำ น้ำแข็ง และพื้นดิน และใช้ข้อมูล L1C เป็นข้อมูลที่ไม่ได้รับการปรับแก้เชิงบรรยากาศ


การจำแนกประเภทประกอบด้วย น้ำ หิมะ น้ำแข็ง น้ำขุ่น ทะเลสาบน้ำเค็ม พื้นดิน (รวมถึงพืชพรรณ และสิ่งก่อสร้างของมนุษย์) เมฆ/เงาเมฆ และไม่มีข้อมูล

ผลการจำแนกประเภทด้วย SVM และการสุ่มป่าไม้ แสดงดังภาพประกอบ 11 โดยสามารถอภิปรายผลได้ดังนี้

- SVM เป็นเทคนิคที่ใช้เพื่อจำแนกข้อมูลโดยการหาชั้นที่แยกกลุ่มออกจากกันได้ดีที่สุดในพื้นที่หลายมิติ มีความถูกต้องสูงในการจำแนกประเภทพื้นที่น้ำ หิมะ/น้ำแข็ง และพื้นดินที่ 94.4% โดยมีการปรับใช้ค่า `class_weight='balanced'` และการตั้งค่า `max_iter=100K` เพื่อให้

การฝึกฝนเสร็จสิ้นและหลีกเลี่ยงปัญหาการไม่สมดุลของข้อมูล สามารถจำแนกประเภทได้ภายในเวลาไม่เกิน 30 นาที

- การสุ่มป่าไม้ มีหลักการมาจากการสร้างต้นไม้ตัดสินใจหลาย ๆ ต้น (decision tree) และรวมผลลัพธ์เพื่อปรับปรุงความแม่นยำ มีความถูกต้องที่ 91.3% การตั้งค่า min_samples_leaf = 0.001 ซึ่งช่วยลดการเรียนรู้ของข้อมูลที่มากเกินไป ของข้อมูลและ n_estimators = 20 ช่วยให้การประมวลผลรวดเร็วขึ้นโดยไม่สูญเสียความแม่นยำ ใช้เวลาในการจำแนกประเภทไม่เกิน 2 นาที ซึ่งช่วยให้การประมวลผลรวดเร็วขึ้นเมื่อเปรียบเทียบกับวิธีอื่น ๆ



ภาพประกอบ 11 ผลการจำแนกพื้นที่ ภาพสีธรรมชาติ (บนซ้าย) ข้อมูลจริง (บนขวา) ผลการจำแนก SVM (ล่างซ้าย) และผลการจำแนกการสุ่มป่าไม้ (ล่างขวา) ของอำเภอ Georgia แคนาดา

ที่มา: Jugier et al., (2022). On Water and Ice Classification from Sentinel-2 Imagery Using Machine Learning

ผลลัพธ์จากชุดทดสอบพบว่า การประเมินผลที่ใช้ชุดทดสอบที่เป็นอิสระแสดงให้เห็นความแม่นยำที่สูง โดยมีความสับสนต่ำระหว่างกลุ่มที่คล้ายกัน เช่น น้ำจืดกับทะเลสาบน้ำเค็ม และ

น้ำแข็งกับหิมะ แต่ในกรณีที่มีหมอกหรือการกระเจิงของแสงที่ไม่เป็นเนื้อเดียวกัน เช่น ละอองลอย ที่ไม่ได้ถูกจัดเป็นเมฆ อาจส่งผลกระทบต่อความแม่นยำในการทำนาย

นอกจากนี้ยังพบว่า การปรับแก้เชิงบรรยากาศมีผลกระทบน้อยหรือไม่มีผลเลยต่อผลลัพธ์ เนื่องจากการฝึกฝนและการประเมินจากภาพ L1C แทนที่จะเป็นภาพ L2A ให้ผลลัพธ์ที่คล้ายคลึงกันมาก

2.6.4 การประยุกต์ใช้ข้อมูลดาวเทียม Sentinel-2 กับ Landsat-8 เพื่อจำแนกการใช้ประโยชน์ที่ดินระดับ 2 พื้นที่คาบสมุทรสทิงพระ จังหวัดสงขลา (ชยณัฐ บัวทองเกื้อ et al., 2565)


งานวิจัยนี้ใช้ข้อมูลภาพถ่ายดาวเทียมจาก Sentinel-2 และ Landsat-8 ซึ่งเป็นข้อมูลระหว่างเดือนสิงหาคม พ.ศ. 2560 ถึงสิงหาคม พ.ศ. 2561 เพื่อเปรียบเทียบความถูกต้องของการจำแนกการใช้ประโยชน์ที่ดินแบบไม่กำกับดูแล (unsupervised classification) โดยใช้วิธี K-Means และ ISODATA

ผลการทดลองพบว่า ความถูกต้องของการจำแนกแตกต่างกันไปตามฤดูกาล โดยในช่วงฤดูร้อน วิธี K-Means ที่ใช้กับข้อมูล Sentinel-2 ให้ผลลัพธ์ที่เหมาะสมที่สุดในการจำแนกการใช้ประโยชน์ที่ดิน โดยมีความถูกต้องคิดเป็นร้อยละ 44.94 โดยมีข้อมูลการสรุปผลการศึกษาระบุแสดงดังตาราง 4 และภาพประกอบ 12

ตาราง 4 การสรุปผลการศึกษากการจำแนกการใช้ประโยชน์ที่ดินแบบไม่กำกับดูแล

กรณีศึกษา	วันที่ภาพถ่ายดาวเทียม	ฤดูกาล	Unsupervised Classification			
			SENTINEL -2		LANDSAT 8	
			K-Means	Isodata	K-Means	Isodata
1	30/08/2560	ฤดูฝน	✓			
2	30/08/2560	ฤดูฝน			✓	
3	30/08/2560	ฤดูฝน		✓		
4	30/08/2560	ฤดูฝน				✓
5	06/02/2561	ฤดูร้อน	✓			
6	06/02/2561	ฤดูร้อน			✓	
7	06/02/2561	ฤดูร้อน		✓		
8	06/02/2561	ฤดูร้อน				✓

ที่มา: ชยณัฐ บัวทองเกื้อ และคณะ. (2565). การประยุกต์ใช้ข้อมูลดาวเทียม Sentinel-2 กับ Landsat-8 เพื่อจำแนกการใช้ประโยชน์ที่ดินระดับ 2 พื้นที่คาบสมุทรสทิงพระ จังหวัดสงขลา



ภาพประกอบ 12 แผนภูมิแสดงค่าความถูกต้องในการจำแนกการใช้ประโยชน์ที่ดินแบบไม่กำกับดูแล

ที่มา: ชยณัฐ บัวทองเกื้อ และคณะ. (2565). การประยุกต์ใช้ข้อมูลดาวเทียม Sentinel-2 กับ Landsat-8 เพื่อจำแนกการใช้ประโยชน์ที่ดินระดับ 2 พื้นที่คาบสมุทรสทิงพระ จังหวัดสงขลา

จากนั้นได้ศึกษาการใช้ประโยชน์ที่ดินระดับ 2 โดยการจำแนกแบบกำกับดูแล (supervised classification) ด้วยวิธีการจำแนกแบบค่าเป็นไปได้สูงที่สุด โดยใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 วันที่ 30 สิงหาคม พ.ศ. 2561 ซึ่งเป็นช่วงที่ปราศจากเมฆมากที่สุดของบริเวณที่ศึกษา โดยมีค่าความน่าเชื่อถือเมื่อเทียบกับข้อมูลจุดตรวจภาคสนามอยู่ที่ร้อยละ 86.18-94.62

2.6.5 การจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายกด้วยอัลกอริทึมการเรียนรู้เครื่องและภาพถ่ายจากดาวเทียม Sentinel-2 (กฤษฎาณ อินทรรัตน์, 2021)

งานวิจัยนี้เป็นการทดสอบประสิทธิภาพของแบบจำลองการจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายก โดยนำแบบจำลองจำนวน 4 ชนิด ได้แก่ Artificial Neural Network (ANN), ต้นไม้ตัดสินใจ, การสุ่มป่าไม้ และ SVM มาจำแนกข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ด้วยวิธีการจำแนกเชิงจุดภาพ (pixel-based classification) เพื่อเปรียบเทียบค่าความถูกต้องของแต่ละแบบจำลองในการจำแนกการใช้ประโยชน์ที่ดิน โดยมีการปรับค่าไฮเพอร์พารามิเตอร์ของแต่ละ

แบบจำลองให้เหมาะสมที่สุดผ่านชุดข้อมูลฝึกฝนและทดสอบ การจำแนกด้วยวิธี การจำแนกแบบค่าเป็นไปได้อย่างที่สุด ถูกใช้เป็นค่ามาตรฐานสำหรับการเปรียบเทียบ เพื่อเลือกแบบจำลองที่ให้ค่าความถูกต้องในการจำแนกสูงที่สุด ดังแสดงในตาราง 5

ตาราง 5 ข้อมูลไฮเพอร์พารามิเตอร์ที่ใช้ในการทดสอบ

Algorithms	Testing hyperparameters
Artificial neural network (ANN)	hidden layer number, max iteration, learning rate, momentum
Decision tree (DT)	max number of tree depth, min number of sample node
Random forest (RF)	max number of tree depth, min number of sample node, max number of tree
Support vector machine (SVM)	kernel parameter (γ), error control (C)
Maximum likelihood (MLC)	threshold probability


ที่มา: กฤษฎาณ อินทร์. (2021). การจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายกด้วยอัลกอริทึมการเรียนรู้เครื่องและภาพถ่ายจากดาวเทียม Sentinel-2

ผลการจำแนกพบว่า การสุ่มป่าไม่มีประสิทธิภาพในการจำแนกการใช้ประโยชน์ที่ดินมากที่สุดโดยมีค่าความถูกต้องโดยรวมที่ร้อยละ 92.00 และผลการทดสอบ Z-test การสุ่มป่าไม่มีระดับความเชื่อมั่นร้อยละ 95.00 ซึ่งถ้าหากมีการเพิ่มข้อมูลที่มีนัยสำคัญต่อการจำแนกหรือเพิ่มรายละเอียดเชิงพื้นที่ของภาพถ่ายดาวเทียมอาจจะช่วยเพิ่มประสิทธิภาพของการจำแนกให้ดีขึ้น ดังแสดงในตาราง 6 และภาพประกอบ 13

ตาราง 6 การเปรียบเทียบค่า F1-score ของกลุ่มที่ได้รับการจำแนกในแต่ละวิธีการจำแนก

Class	Test sample	F1-score				
		MLC	ANN	DT	RF	SVM
Br	55	0.51	0.63	0.82	0.94	0.60
Bu	30	0.84	0.82	0.89	0.92	0.72
Fe	105	0.66	0.76	0.85	0.91	0.72
Fr	31	0.74	0.67	0.81	0.93	0.64
Or	73	0.46	0.48	0.79	0.91	0.42
Pe	73	0.65	0.69	0.87	0.95	0.66
Wa	33	0.77	0.81	0.84	0.84	0.75

ที่มา: กฤษฎาณ อินทร์. (2021). การจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายกด้วยอัลกอริทึมการเรียนรู้เครื่องและภาพถ่ายจากดาวเทียม Sentinel-2



ภาพประกอบ 13 เปรียบเทียบผลการจำแนกการใช้ประโยชน์ที่ดินของแต่ละวิธีการ
จำแนก

ที่มา: กฤษฎาณ อินทร์. (2021). การจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายกด้วย
อัลกอริทึมการเรียนรู้เครื่องและภาพถ่ายจากดาวเทียม Sentinel-2

2.6.6 Integrating Recursive Bayesian Estimation with Support Vector Machine to Map Probability of Flooding from Multispectral Landsat Data (Sarker et al., 2016)


งานวิจัยนี้นำทฤษฎีของเบย์มาใช้ในการประเมินความน่าจะเป็นของพื้นที่น้ำท่วมจากข้อมูลภาพถ่ายดาวเทียมแบบหลายช่วงคลื่น โดยใช้ตัวจำแนกจากการเรียนรู้ของเครื่องเพื่อสร้างแผนที่ขอบเขตน้ำท่วมผ่านการประมวลผลข้อมูลจากระยะไกลแบบหลายช่วงคลื่น โดยการวิเคราะห์มุ่งเน้นที่การจำแนกน้ำท่วมและน้ำถาวร เนื่องจากพื้นที่ทั้งสองมีลักษณะช่วงคลื่นที่คล้ายคลึงกัน ซึ่งส่งผลให้การจำแนกด้วยภาพถ่ายจากระยะไกลมีความซับซ้อน กำหนดกลุ่มเบื้องต้นด้วยวิธี K-Means แบ่งออกเป็น 8 กลุ่มจากข้อมูลภาพในฤดูแล้ง

แบบจำลองใหม่ที่เรียกว่า Extended Support Vector Machine (E-SVM) โดยใช้ชุดข้อมูลฝึกในการกำหนดระนาบที่ใช้แบ่งข้อมูลในปริภูมิหลายมิติ (hyperplanes) ที่สามารถแยก

ความแตกต่างระหว่างลักษณะของพื้นที่น้ำท่วมและพื้นที่ที่ไม่ท่วมได้อย่างแม่นยำ จากนั้นได้นำกระบวนการการประมาณความน่าจะเป็นแบบ recursive bayesian มาใช้เพื่อปรับปรุงค่าความน่าจะเป็นของพื้นที่น้ำท่วมหลังการจำแนกขั้นต้น ส่งผลให้ผลการคาดการณ์มีความแม่นยำมากขึ้น


ดังที่แสดงในภาพประกอบ 14 และ 15 ค่าความแม่นยำในพื้นที่ทดสอบ 4 เพิ่มขึ้นจาก 73% เป็น 92% หลังการประมาณด้วย recursive bayesian ส่วนในพื้นที่ทดสอบ 6 แม้ค่าความแม่นยำจะเพิ่มขึ้นเพียงเล็กน้อย (จาก 11% เป็น 36%) แต่อัตราค่าการเรียกคืนยังคงสูงกว่า 50%

ข้อจำกัดหลักของกระบวนการนี้คือ การใช้เวลาในการคัดเลือกข้อมูลฝึกฝนทั้งในช่วงฤดูแล้ง (น้ำตกร) และช่วงน้ำท่วม และปัญหาเรื่องทรัพยากรหน่วยความจำ จากการประมวลผลข้อมูลภาพขนาดใหญ่และหลายช่วงคลื่น



ภาพประกอบ 14 กราฟแสดงค่าความเที่ยงและค่าเรียกคืน จากการประมาณค่าความน่าจะเป็นที่น้ำจะท่วมก่อนใช้ recursive bayesian สำหรับข้อมูลทั้ง 3 ชุด

ที่มา: Sarker et al., (2016). Integrating Recursive Bayesian Estimation with Support Vector Machine to Map Probability of Flooding from Multispectral Landsat Data



ภาพประกอบ 15 กราฟแสดงค่าความเที่ยงและค่าเรียกคืนกับการประมาณค่าความน่าจะเป็นที่น้ำจะท่วมหลังใช้ recursive bayesian สำหรับข้อมูลทั้ง 3 ชุด

ที่มา: Sarker et al., (2016). Integrating Recursive Bayesian Estimation with Support Vector Machine to Map Probability of Flooding from Multispectral Landsat Data

บทที่ 3

วิธีดำเนินการวิจัย

การศึกษานี้จะทำการเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำจากข้อมูลภาพถ่ายดาวเทียม Sentinel-2 พื้นที่ศึกษาลุ่มน้ำโขง เพื่อหาแบบจำลองการจำแนกพื้นที่น้ำที่เหมาะสมกับพื้นที่ศึกษามากที่สุด โดยแบบจำลองที่นำมาใช้ทดสอบและเปรียบเทียบประสิทธิภาพได้มีการกำหนดชื่อย่อของแบบจำลองดังแสดงในตาราง 7

ตาราง 7 ตารางแสดงการกำหนดชื่อย่อแบบจำลองที่ใช้ในการศึกษา


ชื่อแบบจำลอง	ชื่อย่อ
Spectral Index Classification	SIC
Gaussian mixture model	GMM
Logistic Regression	LR
DeepWaterMap	DWM
WatNet	WN
Recursive Spectral Index Classification	RSIC
Recursive Gaussian mixture model	RGMM
Recursive Logistic Regression	RLR
Recursive DeepWaterMap	RDWM
Recursive WatNet	RWN

โดยในการศึกษามีขั้นตอนการดำเนินงานหลักดังนี้


- 3.1 กระบวนการทำงาน
- 3.2 การรวบรวมข้อมูล
- 3.3 การเตรียมข้อมูล
- 3.4 การทำงานของแบบจำลอง
- 3.5 การประเมินผล

3.1 กระบวนการทำงาน

การศึกษานี้มีกระบวนการทำงานโดยรวมแสดงดังในภาพประกอบ 16




ภาพประกอบ 16 กระบวนการทำงานโดยรวม



ภาพประกอบ 18 หน้าเว็บไซต์ของ Copernicus Data Space Ecosystem, Programme of the European Union โดยสามารถเลือกบริเวณที่ต้องการดาวน์โหลดภาพถ่ายดาวเทียมได้

3. ทำการดาวน์โหลดภาพถ่ายดาวเทียมในช่วงเวลาที่ถ่ายภาพตั้งแต่วันที่ 08/02/2020 ถึงวันที่ 19/12/2023 จำนวน 30 ภาพ โดยที่จำนวน 21 ภาพใช้สำหรับการฝึกฝนและจำนวน 9 ภาพใช้สำหรับการทดสอบ ดังแสดงในภาพประกอบ 19




ภาพประกอบ 19 ข้อมูลปี-เดือน-วัน ที่ถ่ายภาพของข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ที่นำมาใช้ในการศึกษา

3.3 การเตรียมข้อมูล


3.3.1 การเตรียมข้อมูลภาพถ่ายดาวเทียมที่ใช้ฝึกฝนและทดสอบ มีขั้นตอนดังนี้

1. ข้อมูลภาพถ่ายดาวเทียมที่ดาวเทียมโพลดมาจะมีความละเอียดเชิงพื้นที่ 20 เมตร จึงต้องนำมาปรับความละเอียดของข้อมูลใหม่เป็น 10 เมตรโดยใช้วิธีเลือกค่าที่อยู่ใกล้ที่สุด เพื่อเพิ่มจำนวนพิกเซลในภาพให้สามารถมองเห็นรายละเอียดที่เล็กลงได้ชัดเจนขึ้น และช่วยให้วิเคราะห์ภาพถ่ายดาวเทียมได้ละเอียดยิ่งขึ้นด้วยโปรแกรม SNAP Desktop ดังแสดงในภาพประกอบ 20




ภาพประกอบ 20 หน้าโปรแกรม SNAP Desktop

2. ภาพถ่ายดาวเทียมที่ดาวเทียมโพลดมาจะมี 13 แถบ หลังจากผ่านกระบวนการปรับความละเอียดของข้อมูลจะเหลือ 12 แถบ โดยแถบ B10 จะหายไป เพราะในข้อมูลดาวเทียม Sentinel-2 Level 2A จะไม่ได้ใช้แถบ B10 ที่ถูกใช้ในการปรับแก้ค่าบรรยากาศไปแล้ว ดังแสดงในภาพประกอบ 21



ภาพประกอบ 21 12 แถบหลังการปรับความละเอียดของข้อมูล

3. แอปที่นำมาใช้กับแบบจำลอง 6 แอป คือ B2 (Blue), B3 (Green), B4 (Red), B8 (NIR), B8A (Narrow NIR Edge) และ B11 (SWIR 1) นำข้อมูลภาพ 30 วัน 6 ช่วงคลื่น ไปตัดขอบภาพให้ใกล้เคียงกับขนาด 2229x3341 พิกเซล (ไม่จำเป็นต้องตัดให้พอดี เนื่องจากในกระบวนการเขียนโค้ดจะมีการกำหนดขนาดพิกเซลแล้ว) โดยใช้โปรแกรม ArcMap แล้วบันทึกไฟล์เป็นนามสกุล .tif ดังแสดงในภาพประกอบ 22



ภาพประกอบ 22 หน้าโปรแกรม ArcMap กรอบสีแดงคือบริเวณที่ทำการตัดภาพ

4. จะได้จำนวนข้อมูลภาพ 30 วัน 6 ช่วงคลื่น รวมทั้งหมด 180 ไฟล์ นำไปอัปโหลดลง Google drive โดยแยกไฟล์เดอร์ภาพที่จะใช้ฝึกฝนและทดสอบ แล้วแยกไฟล์เดอร์ออกตามแต่ละช่วงคลื่น


5. ในการฝึกฝนแบบจำลอง GMM และ LR จะต้องทำการตรวจจับเมฆและเงาเมฆโดยใช้อัลกอริทึม CSD-SI ในภาพก่อน โดยเมฆและเงาเมฆต้องไม่เกิน 25% จึงจะสามารถนำไปใช้ฝึกฝนได้ โดยสมการที่นำมาใช้ตรวจจับเมฆคือ CI_2 สมการที่ (28) ที่ได้กล่าวถึงไปในข้างต้น โดยกำหนด $T_2 \geq 0.2$ และมีการนำดัชนีสเปกตรัม $NDVI$ สมการที่ (12) ที่ได้กล่าวถึงไปในข้างต้นมาเพิ่มประสิทธิภาพในการตรวจจับเมฆ โดยกำหนด $T_{NDVI} = 0.5$ และในการตรวจจับเงาเมฆได้นำสมการที่ (29) CSI ที่ได้กล่าวถึงไปในข้างต้นมาใช้ โดยกำหนด $T_3 \leq 0.6$

3.3.2 การเตรียมข้อมูลจริงเพื่อใช้ประเมินประสิทธิภาพของแบบจำลอง มีขั้นตอนดังนี้

1. ใช้ข้อมูลภาพถ่ายดาวเทียมสำหรับทดสอบที่ทำการตัดขอบเขตแล้วจำนวน 8 ภาพ ไม่ใช้ภาพวันที่ 9/11/2022 เนื่องจากในกระบวนการ RBC เป็นการนำข้อมูลจากภาพก่อนหน้ามาใช้

เพิ่มประสิทธิภาพในการทำนาย ทำให้ภาพแรกที่ไม่มีภาพก่อนหน้าจึงไม่นำมาประเมินประสิทธิภาพการทำนายของแบบจำลอง

2. นำข้อมูลเข้าโปรแกรม ArcMap ทำข้อมูลในรูปแบบพื้นที่รูปปิดเป็นกรอบการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม ดังแสดงในภาพประกอบ 23




ภาพประกอบ 23 กรอบการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียม ในโปรแกรม ArcMap (เส้นสีเหลือง)

3. ทำการอ่านแปลตีความและวิเคราะห์ตามหลักการและทฤษฎีอ่านแปลตีความและวิเคราะห์ภาพถ่ายดาวเทียมด้วยสายตา 8 องค์ประกอบ โดยนักภูมิสารสนเทศที่มีประสบการณ์ไม่น้อยกว่า 5 ปี ทำข้อมูลในรูปแบบพื้นที่รูปปิด แล้วใส่ป้ายกำกับตามผลของการอ่านแปลตีความและวิเคราะห์ในตาราง (attribute) โดยให้ w คือ พื้นที่น้ำ และ nw คือ ไม่ใช่พื้นที่น้ำ ดังแสดงในภาพประกอบ 24 และ 25


Table			
Sentinel2_B8_20200208T032911_20200208T032911_T48QVE			
FID	Shape *	Id	label
0	Polygon	0	rw
1	Polygon	0	w
2	Polygon	0	rw

ภาพประกอบ 24 การใส่ป้ายกำกับตามผลของการอ่านแปลอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมในตาราง



ภาพประกอบ 25 ตัวอย่างผลการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมที่มีการติดป้ายกำกับ (เส้นสีเหลือง)

4. บันทึกข้อมูลเป็นไฟล์นามสกุล .tif ตั้งสีแสดงผลการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมตามป้ายกำกับที่ถูกกำหนด โดยให้สีขาวเป็นพื้นที่น้ำ (w) และสีดำไม่ใช่พื้นที่น้ำ (nw) ดังแสดงในภาพประกอบ 26



ภาพประกอบ 26 ตัวอย่างภาพผลการอ่านแปลตีความและวิเคราะห์ข้อมูลภาพถ่ายดาวเทียมที่ถูกกำหนดสีตามป้ายกำกับ

3.4 การทำงานของแบบจำลอง

มีขั้นตอนการทำงานดังนี้

3.4.1 ปรับแต่งโค้ดในไฟล์ "configuration.py" จาก GitHub

<https://github.com/neu-spiral/rbc-satimg> โดยจะต้องทำการปรับแต่งในส่วน
ของ debug และ config และ path file

3.4.2 ประมวลผลด้วย Google Colab โดยจะต้องติดตั้งไลบรารี GDAL (Geospatial Data Abstraction Library) for Python ซึ่งเป็นไลบรารีแบบโอเพนซอร์สที่ถูกใช้ในการจัดการข้อมูลภูมิสารสนเทศ (geospatial data) ซึ่งรวมถึงการอ่าน เขียน และประมวลผลไฟล์ข้อมูลทางภูมิศาสตร์ในรูปแบบต่าง ๆ โดยเฉพาะอย่างยิ่งข้อมูลเชิงพิกเซล (raster) และข้อมูลเชิงเรขาคณิต (vector) เช่น GeoTIFF, JPEG, PNG, ESRI Shapefile และ KML เป็นต้น

3.4.3 ติดตั้ง Packages เบื้องต้นตามไฟล์ requirements.txt

```
matplotlib>=3.3.4
```

```
numpy>=1.19.2
```

```
pandas>=2.2.3
```

```
scikit_image>=0.17.2
```

```
scikit_learn>=1.1.1
```

```
tifffile>=2020.10.1
```

```
tensorflow>=2.6.2
```

```
imageio>=2.36.1
```

3.4.4 ในการฝึกฝนแบบจำลอง GMM และ LR จะเป็นการฝึกฝนแบบกึ่งควบคุม (weakly supervised) ที่จะสร้างป้ายกำกับจริงของกลุ่ม หรือ ป้ายกำกับเทียม (pseudo-labels) ซึ่งพิกเซลจากการฝึกฝนจะจำแนกประเภทโดยใช้ดัชนีสเปกตรัม MNDWI และพิจารณาค่า τ เพื่อให้ได้แบบจำลองที่จะนำไปใช้ต่อในกระบวนการ recursive classification การฝึกฝน GMM จะดำเนินการแยกตามแต่ละกลุ่ม โดยในแต่ละกลุ่มจะฝึก GMM ตามการเลือกของ C_t เพื่อให้การแทนค่าพิกเซลในการฝึกมีความเหมาะสม และไม่เกิดภาวะเรียนรู้มากเกินไป (overfitting) โดยจะเลือกจำนวนส่วนประกอบ (components) ที่น้อยที่สุดซึ่งยังให้ผลลัพธ์ที่เพียงพอสำหรับแต่ละ GMM แล้วทำการบันทึกแบบจำลองที่ฝึกแล้วในรูปแบบไฟล์นามสกุล .pkl

3.4.5 การทดสอบแบบจำลอง โดยภาพที่ใช้ในการทดสอบจะไม่ทำการตรวจจับแมชและเงาเมฆ

- การทดสอบแบบจำลอง SIC ไม่ต้องผ่านการฝึกฝนเพราะคำนวณจากดัชนีสเปกตรัม
- การทดสอบแบบจำลอง GMM และ LR ใช้ไฟล์ที่ผ่านการฝึกฝนแล้วจากข้อ 3.4.4
- การทดสอบแบบจำลอง DWM สามารถดาวน์โหลดไฟล์ checkpoint trained model parameter ได้จาก GitHub <https://github.com/isikdogan/deepwatermap/tree/master>

- การทดสอบแบบจำลอง WN สามารถดาวน์โหลดไฟล์ pre-trained model ได้จาก GitHub <https://github.com/xinluo2018/WatNet>

- ในการทดสอบแบบจำลองการเรียนรู้เชิงลึกจะมีความเชื่อมั่นที่มากเกินไปโดยทำให้ข้อมูลก่อนหน้าสูญเสียความสำคัญซึ่งส่งผลเสียต่อ RBC จึงมีการแก้ไขโดยปรับค่าความน่าจะเป็นภายหลัง โดยเพิ่มค่าคงที่ λ เพื่อให้ค่าความน่าจะเป็นของทุกกลุ่มมีการกระจายตัวที่สม่ำเสมอมากขึ้น ลดค่าความเชื่อมั่นที่สูงเกินไปกับกลุ่มใดกลุ่มหนึ่ง อิงมาจากหลักการเอนโทรปีสูงสุด (maximum entropy principle) ที่กล่าวว่าผลลัพธ์ที่เหมาะสมที่สุดควรมีเอนโทรปีสูงสุด เพื่อลดความคลาดเคลื่อนของแบบจำลองดังสมการที่ (32)

$$p(C_t|z_t) = \frac{p'(C_t|z_t) + \lambda}{\sum_{C'_t \in \mathbb{C}} (p'(C'_t|z_t) + \lambda)} \quad (32)$$

โดยที่ $p'(C_t|z_t)$ คือ ค่าความน่าจะเป็นเดิม

λ คือ ค่าที่ใช้ดึงค่าความน่าจะเป็นไปทางกระจายตัวแบบสม่ำเสมอ (uniform distribution)

- ในกระบวนการ RBC จะนำผลการจำแนกก่อนหน้ามาใช้ปรับปรุงผลการจำแนกปัจจุบัน จึงทำให้ภาพสำหรับการทดสอบทั้ง 9 ภาพจะนำมาแสดงผลจริง 8 ภาพ

- การตั้งค่าพารามิเตอร์สำหรับการทดสอบ (Calatrava et al., 2024) แสดงดังตาราง 8 ค่าขีดแบ่ง τ_w ใช้สร้างป้ายกำกับจริงในการฝึกฝนแบบจำลอง GMM และ LR และใช้สร้างการทำนายความน่าจะเป็นของแบบจำลอง SIC

ตาราง 8 การตั้งค่าพารามิเตอร์

$C_t \in \mathbb{C}_w = \{land, water\}$	
SIC	$\tau_w = [-1, 0.13, 1];$ $\mu_w = [-0.435, 0.565];$ $\sigma_w = [0.565, 0.435];$ $y_{MNDWI}(z_t) = \frac{z_{t,Green} - z_{t,SWIR}}{z_{t,Green} + z_{t,SWIR}}$
RSIC	$\epsilon = 0.02 ; \lambda = 0.8$
RGMM	$\epsilon = 0.09 ; \lambda = 0.8$
RLR	$\epsilon = 0.02 ; \lambda = 0.8$
RDWM	$\epsilon = 0.095 ; \lambda = 0.8$
RWN	$\epsilon = 0.085 ; \lambda = 0.8$

3.5 การประเมินผล

ในการศึกษานี้ได้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลองโดยใช้วิธีการวัดค่า IoU ซึ่งเป็นวิธีที่ได้รับความนิยมอย่างแพร่หลายในงานประเภทการจำแนกภาพโดยเฉพาะในการตรวจจับวัตถุ และการแบ่งส่วนภาพ การคำนวณค่า IoU จำเป็นต้องใช้ข้อมูล 2 ชุด ได้แก่

1. ข้อมูลการทำนายของแบบจำลอง
2. ข้อมูลจริง

โดยข้อมูลทั้งสองชุดจะต้องถูกแปลงให้อยู่ในรูปแบบของหน้ากากข้อมูล (mask data) หรืออาร์เรย์ของ NumPy ซึ่งแสดงเป็นหน้ากากการแบ่งส่วนภาพ (segmentation masks) ของข้อมูลการทำนายและข้อมูลจริงในรูปแบบไบนารี (binary mask) โดยกำหนดให้พื้นที่น้ำ (water; w) มีค่าเท่ากับ 1 และพื้นที่ที่ไม่ใช่ น้ำ (not water; nw) มีค่าเท่ากับ 0 จากนั้นจึงนำข้อมูลดังกล่าวเข้าสู่กระบวนการคำนวณค่า IoU ทั้งนี้ แบบจำลองจะถือว่าสามารถจำแนกพื้นที่น้ำได้ดีหากมีค่า IoU มากกว่า 50%

บทที่ 4

ผลการดำเนินงานวิจัย

การศึกษานี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำจากข้อมูลภาพถ่ายดาวเทียม Sentinel-2 Level-2A แบบอนุกรมเวลา ช่วงเวลาที่ถ่ายภาพตั้งแต่วันที่ 08/02/2020 ถึงวันที่ 19/12/2023 จำนวน 30 ภาพ โดยที่จำนวน 21 ภาพใช้สำหรับการฝึกฝนซึ่งต้องผ่านกระบวนการตรวจจับเมฆและเงาเมฆให้ได้น้อยกว่า 25% และจำนวน 9 ภาพใช้สำหรับการทดสอบ ใช้ข้อมูลบริเวณลุ่มน้ำโขง ในพื้นที่ข้ามพรมแดนของแม่น้ำโขง บริเวณตำบลอาจสามารถ อำเภอเมืองนครพนม จังหวัดนครพนม ประเทศไทย และเกาะดอนโดน เมืองท่าแขก สาธารณรัฐประชาธิปไตยประชาชนลาว เพื่อหาแบบจำลองที่เหมาะสมกับการจำแนกพื้นที่น้ำของประเทศไทยที่มีความแตกต่างทางภูมิศาสตร์ กิจกรรมการใช้พื้นที่ และฤดูกาล กับแบบจำลองพื้นที่น้ำที่ถูกพัฒนาและทดสอบกับข้อมูลของต่างประเทศ โดยแบบจำลองการจำแนกพื้นที่น้ำที่จะนำมาใช้ทดสอบและเปรียบเทียบประสิทธิภาพ โดยแบ่งเป็นแบบจำลองที่ไม่ทำ recursive classifiers ได้แก่ GMM, LR, SIC, DWM และ WN กับแบบจำลองที่ทำ recursive classifiers ได้แก่ RGMM, RLR, RSIC, RDWM และ RWN ซึ่งจะประเมินประสิทธิภาพของแบบจำลองด้วยวิธี IoU เพื่อให้บรรลุวัตถุประสงค์ของการวิจัยที่ได้กำหนดไว้ ผลลัพธ์ที่ได้จะอธิบายดังต่อไปนี้

- 4.1 ผลลัพธ์การตรวจจับเมฆและเงาเมฆของภาพที่ใช้ในการฝึกฝน
- 4.2 ผลลัพธ์การทดสอบการจำแนกพื้นที่น้ำของแบบจำลอง
- 4.3 ผลลัพธ์การประเมินประสิทธิภาพของแบบจำลอง

4.1 ผลลัพธ์การตรวจจับเมฆและเงาเมฆของภาพที่ใช้ในการฝึกฝน

ภาพถ่ายดาวเทียมที่นำมาใช้ในการฝึกฝนแบบจำลอง GMM และ LR จำนวน 21 ภาพ ต้องมีการถ่ายติดเมฆและเงาเมฆไม่เกิน 25% ในเบื้องต้นมีการตรวจสอบด้วยสายตาก่อนที่จะทำการดาวน์โหลดภาพมาใช้งาน แต่เพื่อให้ได้ข้อมูลที่เหมาะสมสำหรับใช้ฝึกฝนแบบจำลอง จึงได้นำอัลกอริทึม CSD-SI มาช่วยในการตรวจจับเมฆและเงาเมฆ โดยได้ผลลัพธ์ในการตรวจจับเมฆและเงาเมฆแสดงดังตาราง 9

ตาราง 9 ตารางแสดงผลการตรวจจับเมฆและเงาของเมฆจากภาพถ่ายดาวเทียม


No.	Date	Cloud+Cloud Shadow Percentage
1	08/02/2020	7.36 %
2	09/03/2020	5.91 %
3	28/04/2020	5.04 %
4	27/06/2020	9.25 %
5	10/09/2020	7.50 %
6	14/11/2020	6.73 %
7	24/12/2020	8.43 %
8	07/02/2021	8.13 %
9	14/03/2021	5.32 %
10	18/04/2021	5.30 %
11	18/05/2021	17.62 %
12	12/07/2021	13.80 %
13	10/09/2021	10.66 %
14	19/11/2021	7.33 %
15	24/12/2021	8.09 %
16	07/02/2022	8.45 %
17	09/03/2022	6.95 %
18	08/04/2022	6.02 %
19	18/05/2022	7.48 %
20	27/07/2022	19.32 %
21	31/08/2022	12.76 %

จากผลการตรวจจับเมฆและเงาเมฆด้วยอัลกอริทึม CSD-SI ของภาพถ่ายดาวเทียมที่จะนำไปใช้ในการฝึกฝน ผ่านการตรวจจับเมฆและเงาเมฆทั้ง 21 ภาพ โดยมีค่าต่ำสุดที่ 5.04% เป็นภาพวันที่ 28/04/2020 และสูงสุดที่ 19.32% เป็นภาพวันที่ 27/07/2022

4.2 ผลลัพธ์การทดสอบการจำแนกพื้นที่น้ำของแบบจำลอง

ภาพถ่ายดาวเทียมที่นำมาใช้ในการทดสอบแบบจำลองจำนวน 9 ภาพ จะได้ผลลัพธ์จริง 8 ภาพ เนื่องจากกระบวนการ recursive classifiers อาศัยผลลัพธ์จากการจำแนกในภาพก่อนหน้า เพื่อปรับปรุงการจำแนกของภาพถัดไป ดังนั้นภาพถ่ายวันที่ 9/11/2022 ซึ่งเป็นภาพแรกในกระบวนการ จึงไม่สามารถนำมาใช้แสดงผลการทดสอบได้

ภาพถ่ายดาวเทียมที่นำมาแสดงผลจริงจะเป็นภาพตั้งแต่วันที่ 19/12/2022 ถึงวันที่ 19/12/2023 แสดงเป็นภาพแผนที่น้ำ โดยกำหนดให้สีม่วงคือพิกเซลที่แบบจำลองทำนายว่าเป็นพื้นที่น้ำ (1) และสีเหลืองคือพิกเซลที่แบบจำลองทำนายว่าไม่ใช่พื้นที่น้ำ (0) ดังแสดงในภาพประกอบ 27



ภาพประกอบ 27 ผลการทดสอบการจำแนกพื้นที่น้ำของแบบจำลองพิกเซลที่แบบจำลองทำนายว่าเป็นพื้นที่น้ำ (สีม่วง) และไม่ใช่พื้นที่น้ำ (สีเหลือง)

4.3 ผลลัพธ์การประเมินประสิทธิภาพของแบบจำลอง


การประเมินประสิทธิภาพของแบบจำลอง ใช้ข้อมูลจากการทดสอบของแบบจำลองที่ทำนายว่าเป็นพื้นที่น้ำ (1) และทำนายว่าไม่ใช่พื้นที่น้ำ (0) นำมาประเมินประสิทธิภาพของแบบจำลองโดยใช้วิธี IoU นำมาซ้อนทับกับข้อมูลจริงซึ่งเป็นข้อมูลที่ได้จากการอ่านแปลและวิเคราะห์ตีความภาพถ่ายดาวเทียมโดยนักภูมิสารสนเทศชำนาญการ ซึ่งสามารถแสดงผลเป็นแผนที่แสดงการ

ชั้นทับของข้อมูลทั้งสองชั้น ดังแสดงในภาพประกอบ 29 และ 30 โดยมีการกำหนดสีในแผนที่ตามเมทริกซ์ความสับสน (confusion matrix) ดังแสดงในภาพประกอบ 28


- สีเหลือง [255,255,0]: True Positive (TP) พิกเซลที่ข้อมูลทำนายและข้อมูลจริงชั้นทับกัน คือ แบบจำลองทำนายว่าเป็นพื้นที่น้ำ และข้อมูลจริงเป็นพื้นที่น้ำ
- สีดำ [0,0,0]: True Negative (TN) พิกเซลที่ไม่มีอยู่ทั้งในข้อมูลทำนายและข้อมูลจริง คือ แบบจำลองทำนายว่าไม่ใช่พื้นที่น้ำ และข้อมูลจริงไม่ใช่พื้นที่น้ำ
- สีแดง [255,0,0]: False Positive (FP) พิกเซลที่มีอยู่ในข้อมูลทำนาย แต่ไม่มีในข้อมูลจริง คือ แบบจำลองทำนายว่าเป็นพื้นที่น้ำ แต่ข้อมูลจริงไม่ใช่พื้นที่น้ำ
- สีเขียว [0,255,0]: False Negative (FN) พิกเซลที่ไม่มีอยู่ในข้อมูลทำนาย แต่มีในข้อมูลจริง คือ แบบจำลองทำนายว่าไม่ใช่พื้นที่น้ำ แต่ข้อมูลจริงเป็นพื้นที่น้ำ

		Ground Truth	
		Water (1)	Not Water (0)
Predicted	Water (1)	TP [255,255,0]	FP [255,0,0]
	Not Water (0)	FN [0,255,0]	TN [0,0,0]

ภาพประกอบ 28 แสดงการกำหนดสีการซ้อนทับภาพแผนที่ของข้อมูลการทำนายกับข้อมูลจริง



ภาพประกอบ 29 การซ้อนทับภาพแผนที่ของข้อมูลการทำนายกับข้อมูลจริงของ
แบบจำลองที่ไม่ทำ recursive classifiers



ภาพประกอบ 30 แสดงการซ้อนทับภาพแผนที่ของข้อมูลการทำนายกับข้อมูลจริงของ
แบบจำลองที่ทำ recursive classifiers

การประเมินประสิทธิภาพของแบบจำลองที่ผ่านเกณฑ์จะต้องมีผลการทดสอบการทำนายที่ถูกต้องมากกว่า 50%

4.3.1 ผลการทดสอบการทำนายของแบบจำลอง SIC แสดงดังตาราง 10

ตาราง 10 ผลการทดสอบการทำนายของแบบจำลอง SIC

No	Date	SIC	
		Non-recursive	Recursive
1	19/12/2022	91.82%	91.82%
2	27/2/2023	91.85%	91.93%
3	24/3/2023	94.20%	91.12%
4	23/4/2023	0.79%	88.12%
5	18/5/2023	74.42%	90.58%
6	20/9/2023	96.14%	66.94%
7	9/11/2023	92.85%	80.00%
8	19/12/2023	91.98%	88.66%
Avg of IoU		79.26%	86.15%

แบบจำลอง SIC ที่ทำ recursive classifiers สามารถทำนายได้ดีกว่าแบบจำลองที่ไม่ทำ recursive classifiers โดยมีรายละเอียดดังนี้

4.3.1.1 แบบจำลอง SIC ที่ไม่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 79.26%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 7 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 74.42%, 91.82%, 91.85%, 91.98%, 92.85%, 94.20% และ 96.14% ตามลำดับ

- ทำนายได้ถูกต้องน้อยกว่าเกณฑ์จำนวน 1 ภาพ โดยมีค่าความถูกต้อง 0.79%

4.3.1.2 แบบจำลอง SIC ที่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 86.15%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 8 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 66.94%, 80.00%, 88.12%, 88.66%, 90.58%, 91.12%, 91.82% และ 91.93% ตามลำดับ

- ไม่มีภาพที่สามารถทำนายได้ถูกต้องน้อยกว่าเกณฑ์

4.3.2 ผลการทดสอบการทำนายของแบบจำลอง GMM แสดงดังตาราง 11

ตาราง 11 ผลการทดสอบการทำนายของแบบจำลอง GMM

No	Date	GMM	
		Non-recursive	Recursive
1	19/12/2022	94.84%	94.84%
2	27/2/2023	94.24%	93.75%
3	24/3/2023	95.70%	95.38%
4	23/4/2023	22.07%	92.82%
5	18/5/2023	95.39%	94.86%
6	20/9/2023	96.35%	96.29%
7	9/11/2023	93.53%	93.82%
8	19/12/2023	93.15%	93.16%
Avg of IoU		85.66%	94.36%

แบบจำลอง GMM ที่ทำ recursive classifiers สามารถทำนายได้ดีกว่าแบบจำลองที่ไม่ทำ recursive classifiers โดยมีรายละเอียดดังนี้

4.3.2.1 แบบจำลอง GMM ที่ไม่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 85.66%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 7 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 93.15%, 93.53%, 94.24%, 94.84%, 95.39%, 95.70% และ 96.35% ตามลำดับ

- ทำนายได้ถูกต้องน้อยกว่าเกณฑ์จำนวน 1 ภาพ โดยมีค่าความถูกต้อง 22.07%

4.3.2.2 แบบจำลอง GMM ที่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 94.36%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 8 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 92.82%, 93.16%, 93.75%, 93.82%, 94.84%, 94.86%, 95.38% และ 96.29% ตามลำดับ

- ไม่มีภาพที่สามารถทำนายได้ถูกต้องน้อยกว่าเกณฑ์

4.3.3 ผลการทดสอบการทำนายของแบบจำลอง LR แสดงดังตาราง 12

ตาราง 12 ผลการทดสอบการทำนายของแบบจำลอง LR

No	Date	LR	
		Non-recursive	Recursive
1	19/12/2022	92.17%	92.17%
2	27/2/2023	92.08%	92.26%
3	24/3/2023	94.26%	93.66%
4	23/4/2023	0.90%	1.83%
5	18/5/2023	74.71%	65.02%
6	20/9/2023	96.15%	96.09%
7	9/11/2023	92.88%	93.17%
8	19/12/2023	91.96%	92.46%
Avg of IoU		79.39%	78.33%

แบบจำลอง LR ที่ไม่ทำ recursive classifiers สามารถทำนายได้ดีกว่าแบบจำลองที่ทำ Recursive Classifiers โดยมีรายละเอียดดังนี้

4.3.3.1 แบบจำลอง LR ที่ไม่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 79.39%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 7 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 74.71%, 91.96%, 92.08%, 92.17%, 92.88%, 94.26% และ 96.15% ตามลำดับ

- ทำนายได้ถูกต้องน้อยกว่าเกณฑ์จำนวน 1 ภาพ โดยมีค่าความถูกต้อง 0.90%

4.3.3.2 แบบจำลอง LR ที่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 78.33%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 7 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 65.02%, 92.17%, 92.26%, 92.46%, 93.17%, 93.66% และ 96.09% ตามลำดับ

- ทำนายได้ถูกต้องน้อยกว่าเกณฑ์จำนวน 1 ภาพ โดยมีค่าความถูกต้อง 1.83%

4.3.4 ผลการทดสอบการทำนายของแบบจำลอง DWM แสดงดังตาราง 13

ตาราง 13 ผลการทดสอบการทำนายของแบบจำลอง DWM

No	Date	DWM	
		Non-recursive	Recursive
1	19/12/2022	91.00%	91.00%
2	27/2/2023	90.99%	90.24%
3	24/3/2023	91.01%	88.52%
4	23/4/2023	0.00%	86.24%
5	18/5/2023	70.97%	87.84%
6	20/9/2023	95.45%	64.56%
7	9/11/2023	91.98%	77.93%
8	19/12/2023	91.11%	88.04%
Avg of IoU		77.81%	84.30%

แบบจำลอง DWM ที่ทำ recursive classifiers สามารถทำนายได้ดีกว่าแบบจำลองที่ไม่ทำ Recursive Classifiers โดยมีรายละเอียดดังนี้

4.3.4.1 แบบจำลอง DWM ที่ไม่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 77.81%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 7 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 70.97%, 90.99%, 91.00%, 91.01%, 91.11%, 91.98% และ 95.45% ตามลำดับ

- ทำนายได้ถูกต้องน้อยกว่าเกณฑ์จำนวน 1 ภาพ โดยมีค่าความถูกต้อง 00.00%

4.3.4.2 แบบจำลอง DWM ที่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 84.30%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 8 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 64.56%, 77.93%, 86.24%, 87.84%, 88.04%, 88.52%, 90.24% และ 91.00% ตามลำดับ

- ไม่มีภาพที่สามารถทำนายได้ถูกต้องน้อยกว่าเกณฑ์

4.3.5 ผลการทดสอบการทำนายของแบบจำลอง WN แสดงดังตาราง 14

ตาราง 14 ผลการทดสอบการทำนายของแบบจำลอง WN

No	Date	WN	
		Non-recursive	Recursive
1	19/12/2022	65.53%	65.53%
2	27/2/2023	70.86%	63.99%
3	24/3/2023	76.21%	66.37%
4	23/4/2023	60.12%	72.46%
5	18/5/2023	68.65%	71.17%
6	20/9/2023	78.63%	64.84%
7	9/11/2023	70.22%	67.93%
8	19/12/2023	69.31%	68.82%
Avg of IoU		69.94%	67.64%

แบบจำลอง WN ที่ไม่ทำ recursive classifiers สามารถทำนายได้ดีกว่าแบบจำลองที่ทำ recursive classifiers โดยมีรายละเอียดดังนี้

4.3.5.1 แบบจำลอง WN ที่ไม่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 69.94%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 8 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 60.12%, 65.53%, 68.65%, 69.31%, 70.22%, 70.86%, 76.21% และ 78.63% ตามลำดับ

- ไม่มีภาพที่สามารถทำนายได้ถูกต้องน้อยกว่าเกณฑ์

4.3.5.2 แบบจำลอง WN ที่ทำ recursive classifiers สามารถทำนายได้ถูกต้องเฉลี่ย 67.64%

- ทำนายได้ถูกต้องมากกว่าเกณฑ์จำนวน 8 ภาพ โดยมีค่าความถูกต้องตั้งแต่ 63.99%, 64.84%, 65.53%, 66.37%, 67.93%, 68.82%, 71.17% และ 72.46% ตามลำดับ

- ไม่มีภาพที่สามารถทำนายได้ถูกต้องน้อยกว่าเกณฑ์

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

ในการศึกษาเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำกับข้อมูลภาพถ่ายดาวเทียมแบบอนุกรมเวลา ผู้ศึกษาได้ทำการประเมินประสิทธิภาพของแบบจำลองในแต่ละอัลกอริทึมเพื่อนำมาเปรียบเทียบและสรุปผล โดยแบ่งหัวข้อในการนำเสนอต่อไปนี้

5.1 สรุปผลการวิจัย

5.2 อภิปรายผลการวิจัย

5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การประเมินประสิทธิภาพของแบบจำลองการจำแนกพื้นที่น้ำ ใช้ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ตั้งแต่วันที่ 19/12/2022 ถึงวันที่ 19/12/2023 จำนวน 8 ภาพ โดยแบบจำลองที่นำมาใช้ทดสอบแบ่งเป็นแบบจำลองที่ไม่ทำและแบบที่ทำ recursive classifiers แสดงดังตาราง 15

ตาราง 15 สรุปผลการทดสอบการทำนายของแบบจำลอง

Model	SIC	GMM	LR	DWM	WN	Avg of IoU
Non-recursive	79.26%	85.66%	79.39%	77.81%	69.94%	78.41%
Recursive	86.15%	94.36%	78.33%	84.30%	67.64%	82.16%
Avg Of IoU	82.70%	90.01%	78.86%	81.06%	68.79%	80.28%

ผลการทดสอบการทำนายโดยรวมพบว่าทุกแบบจำลองมีผลการทำนายโดยเฉลี่ยมากกว่า 50% แสดงว่าทุกแบบจำลองมีประสิทธิภาพในการจำแนกพื้นที่น้ำ

เมื่อนำผลการทดสอบการทำนายของแต่ละแบบจำลองมาเปรียบเทียบตามแต่ละชนิดของแบบจำลอง พบว่า GMM 90.01% มีประสิทธิภาพสูงที่สุด และต่ำที่สุดคือ WN 68.79% และเมื่อมีการใช้กระบวนการ recursive classifiers พบว่า RGMM 94.36% มีประสิทธิภาพสูงที่สุด และต่ำที่สุดคือ RWN 67.64%

RWN 67.64% เป็นแบบจำลองที่ทำ recursive classifiers แต่ทำนายได้ไม่ดีเท่า WN 69.94% ที่ไม่ทำ recursive classifiers และมี RLR 78.33% เช่นกันที่ทำ recursive classifiers

แต่ทำนายได้ไม่ดีเท่า LR 79.39% อาจกล่าวได้ว่า recursive classifiers ไม่ช่วยให้ WN และ LR มีประสิทธิภาพดีขึ้น

แต่จากผลการทดสอบการทำนายโดยรวมพบว่าการทำ recursive classifiers ช่วยให้แบบจำลองมีประสิทธิภาพที่ดีขึ้นจาก 78.41% เป็น 82.16%

5.2 อภิปรายผลการวิจัย

จากผลการทดสอบการทำนายของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียม 8 ภาพ แสดงดังตาราง 16

ตาราง 16 สรุปผลการทดสอบการทำนายของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียม

No	Date	Non-recursive	Recursive	Avg of IoU
1	19/12/2022	87.07%	87.07%	87.07%
2	27/2/2023	88.00%	86.44%	87.22%
3	24/3/2023	90.28%	87.01%	88.64%
4	23/4/2023	16.78%	68.29%	42.53%
5	18/5/2023	76.83%	81.89%	79.36%
6	20/9/2023	92.55%	77.75%	85.15%
7	9/11/2023	88.29%	82.57%	85.43%
8	19/12/2023	87.50%	86.23%	86.87%

พบว่า มี 1 ภาพที่ไม่ผ่านเกณฑ์การประเมินประสิทธิภาพ คือภาพวันที่ 23/4/2023 มีผลการทดสอบการทำนายเฉลี่ยรวม 42.53% ถ้าไม่ทำ recursive classifiers จะมีผลการทำนายต่ำกว่าเกณฑ์ที่ 16.78% แต่เมื่อทำ recursive classifiers จะมีผลการทำนายผ่านเกณฑ์ที่ 68.29% ซึ่งสามารถกล่าวได้ว่าการทำ recursive classifiers ช่วยปรับปรุงประสิทธิภาพของแบบจำลองให้ดีขึ้น และเมื่อวิเคราะห์ผลการทำนายของแต่ละแบบจำลองที่ทำนายภาพวันที่ 23/4/2023 แสดงดังตาราง 17

ตาราง 17 ผลการทดสอบการทำนายของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียมวันที่ 23/4/2023

Model	SIC	GMM	LR	DWM	WN	Avg of IoU
Non-recursive	0.79%	22.07%	0.90%	0.00%	60.12%	16.78%
Recursive	88.12%	92.82%	1.83%	86.24%	72.46%	68.29%
Avg of IoU	44.46%	57.44%	1.36%	43.12%	66.29%	42.53%

พบว่าเมื่อมีเพียงแบบจำลอง WN ทั้งแบบที่ไม่ทำและทำ recursive classifiers สามารถทำนายพื้นที่น้ำของภาพวันที่ 23/4/2023 ได้ดี โดยมีผลการทำนาย 60.12% และ 72.46% ตามลำดับ ถึงแม้ผลสรุปจากตาราง 15 จะชี้ให้เห็นว่าแบบจำลอง WN มีผลการประเมินประสิทธิภาพที่ต่ำที่สุด อาจกล่าวได้ว่าแบบจำลอง WN มีความยืดหยุ่นหรือทนทานกับข้อมูลภาพถ่ายดาวเทียมในหลายช่วงเวลา แม้ผลการประเมินประสิทธิภาพจะไม่สูงแต่ผ่านเกณฑ์ 50%

ในขณะที่แบบจำลอง SIC, GMM และ DWM จะต้องทำ recursive classifiers เพื่อให้มีประสิทธิภาพที่ดีขึ้น จาก 0.79% เป็น 88.12%, 22.07% เป็น 92.82% และ 0.00% เป็น 86.24% ตามลำดับ ซึ่งตรงกับสมมติฐานว่าการทำ recursive classifiers ช่วยปรับปรุงแบบจำลองให้มีประสิทธิภาพในการจำแนกมากยิ่งขึ้น

มีเพียงแบบจำลอง LR ที่ไม่ผ่านเกณฑ์ทั้งแบบที่ไม่ทำและทำ recursive classifiers โดยมีผลการทำนาย 0.90% และ 1.83% ตามลำดับ

ถึงแม้แบบจำลอง LR จะไม่มีความยืดหยุ่นหรือทนทาน แต่ข้อมูลภาพถ่ายดาวเทียมก็เป็นปัจจัยสำคัญที่ส่งผลกับการประเมินประสิทธิภาพของแบบจำลอง เพราะถ้านำข้อมูลวันที่ 23/4/2023 ออกแบบจำลอง LR จะมีผลการประเมินประสิทธิภาพที่สูงขึ้น ดังแสดงในตาราง 18


ตาราง 18 ผลการประเมินประสิทธิภาพของแบบจำลองกับข้อมูลภาพถ่ายดาวเทียมที่นำข้อมูลวันที่ 23/4/2023 ออก

Model	SIC	GMM	LR	DWM	WN	Avg of IoU
Non-recursive	90.47%	94.74%	90.60%	88.93%	71.34%	87.22%
Recursive	85.86%	94.59%	89.26%	84.02%	66.95%	84.14%
Avg of IoU	88.16%	94.66%	89.93%	86.47%	69.15%	85.68%

ถ้านำข้อมูลวันที่ 23/4/2023 ออก แบบจำลอง LR จะมีผลการประเมินประสิทธิภาพสูงเป็นอันดับที่ 2 รองจาก GMM โดยมีค่าเฉลี่ยรวม 89.93% จากอันดับที่ 4 (ตาราง 15)

แต่ในการเตรียมข้อมูลภาพถ่ายดาวเทียมก่อนข้างมีข้อจำกัดเพราะพื้นที่ลุ่มน้ำโขงปัจจุบันมีการทำเขื่อนช่วงต้นน้ำ ทำให้ปลายน้ำมีสภาพค่อนข้างแห้งแล้ง ซึ่งส่งผลให้การจำแนกพื้นที่น้ำค่อนข้างมีความท้าทาย เพราะพื้นที่ที่มีน้ำลึกกับน้ำตื้นจะมีลักษณะการสะท้อนของคลื่นแม่เหล็กไฟฟ้าต่างกัน จะมีเพียงช่วงฤดูฝนที่มีปริมาณน้ำมากกว่าฤดูอื่น ๆ แต่การนำมาภาพฤดูฝนมาใช้ก็มีข้อจำกัดเรื่องปริมาณเมฆและเงาเมฆในภาพที่เกิน 25%

เมื่อนำภาพถ่ายดาวเทียมแถบ B11 (SWIR) ซึ่งเป็นช่วงคลื่นที่ใช้สำหรับการทำแผนที่น้ำ โดยยึดจากสูตร MNDWI ที่ใช้ข้อมูลจากแถบอินฟราเรดสั้นเป็นหลักในการคำนวณ มานำเสนอเป็นภาพระดับสีเทา (grayscale image) แสดงดังภาพประกอบ 31



ภาพประกอบ 31 ภาพถ่ายดาวเทียมแถบ B11 (SWIR)

จากข้อมูลภาพถ่ายดาวเทียมทั้ง 8 ภาพ พบว่าภาพวันที่ 23/4/2023 จะมีสีของพื้นที่น้ำทั้งภาพสว่างกว่าภาพอื่น เพราะพื้นที่น้ำตื้นจะดูดซับแสงไว้ได้น้อย ส่วนมากจะตกกระทบลงบนพื้นดินได้น้ำก่อนจะส่งค่าสะท้อนกลับไปทีตัวรับรู้ดาวเทียม ทำให้แบบจำลองทำนายว่าไม่ใช่พื้นที่น้ำ ต่างจากภาพวันที่ 18/5/2023 ที่ถึงแม้จะมีบางส่วนเป็นสีสว่างซึ่งเป็นพื้นที่น้ำตื้นเช่นกัน แต่แบบจำลองก็สามารถทำนายได้ถูกต้องมากกว่า 50% เพราะว่าในภาพมีบางส่วนเป็นพื้นที่สีเข้มที่แบบจำลองสามารถทำนายว่าเป็นพื้นที่น้ำได้ถูกต้อง

จึงได้ทำการทดลองปรับค่า τ_w จาก 0.13 เป็น 0.07 ของการคำนวณค่าดัชนีสเปกตรัม MNDWI ที่ใช้กับแบบจำลอง GMM, LR และ SIC เพื่อให้แบบจำลองสามารถทำนายพื้นที่น้ำต้นได้ดีขึ้น ดังแสดงในตาราง 19

ตาราง 19 ผลการประเมินประสิทธิภาพของแบบจำลองหลังจากปรับค่า $\tau_w = 0.07$

Date	SIC		GMM		LR	
	Non-re	Recursive	Non-re	Recursive	Non-re	Recursive
19/12/2022	93.93%	93.93%	95.16%	95.16%	94.06%	94.06%
27/02/2023	93.77%	93.14%	93.87%	93.40%	93.26%	93.02%
24/03/2023	95.55%	93.93%	95.73%	96.11%	95.37%	93.45%
23/04/2023	8.00%	91.65%	94.63%	94.06%	9.27%	90.94%
18/05/2023	94.35%	94.19%	96.38%	96.63%	94.33%	93.79%
20/09/2023	96.33%	69.79%	96.23%	71.32%	96.29%	68.70%
09/11/2023	93.48%	83.08%	93.71%	94.05%	93.42%	81.84%
19/12/2023	93.01%	91.55%	93.40%	93.60%	92.65%	91.88%
Avg of IoU	83.55%	88.91%	94.89%	91.79%	83.58%	88.46%

เมื่อเปรียบเทียบผลการประเมินของตาราง 19 กับตาราง 10 , 11 และ 12 พบว่า

แบบจำลอง SIC

- $\tau_w = 0.13$ ผลการประเมินประสิทธิภาพของแบบจำลองที่ไม่ทำและทำ recursive classifiers เฉลี่ย คือ 79.26% และ 86.15% ตามลำดับ

- $\tau_w = 0.07$ ผลการประเมินประสิทธิภาพของแบบจำลองที่ไม่ทำและทำ recursive classifiers เฉลี่ย คือ 83.55% และ 88.91% ตามลำดับ

- ผลการประเมินประสิทธิภาพเฉลี่ยดีขึ้นทั้งแบบจำลองที่ไม่ทำและทำ recursive classifiers

แบบจำลอง GMM

- $\tau_w = 0.13$ ผลการประเมินประสิทธิภาพของแบบจำลองที่ไม่ทำและ recursive classifiers เฉลี่ย คือ 85.66% และ 94.36% ตามลำดับ

- $\tau_w = 0.07$ ผลการประเมินประสิทธิภาพของแบบจำลองที่ไม่ทำและ recursive classifiers เฉลี่ย คือ 94.89% และ 91.79% ตามลำดับ

- ผลการประเมินประสิทธิภาพเฉลี่ยดีขึ้นเฉพาะแบบจำลองที่ไม่ทำ recursive classifiers

แบบจำลอง LR

- $\tau_w = 0.13$ ผลการประเมินประสิทธิภาพของแบบจำลองที่ไม่ทำและ recursive classifiers เฉลี่ย คือ 79.39% และ 78.33% ตามลำดับ

- $\tau_w = 0.07$ ผลการประเมินประสิทธิภาพของแบบจำลองที่ไม่ทำและ recursive classifiers เฉลี่ย คือ 83.58% และ 88.46% ตามลำดับ

- ผลการประเมินประสิทธิภาพเฉลี่ยดีขึ้นทั้งแบบจำลองที่ไม่ทำและทำ recursive classifiers

ทั้งนี้ ถึงแม้จะมีบางภาพที่ใช้ $\tau_w = 0.13$ แล้วได้ผลลัพธ์ที่ดีกว่า แต่ผลการประเมินโดยรวมแล้ว $\tau_w = 0.07$ ได้ผลลัพธ์ที่ดีขึ้น ดังนั้นในการนำไปใช้งานจริงอาจจะต้องมีการปรับค่าให้เหมาะสมกับภาพที่นำมาใช้

5.3 ข้อเสนอแนะ

ในการเตรียมข้อมูลสำหรับฝึกฝนและทดสอบอาจจะไม่ต้องคำนึงถึงสัดส่วน 70:30 เพราะการทำ recursive classifiers คือการใช้ข้อมูลผลการทำนายก่อนหน้ามาปรับปรุงข้อมูลผลการทำนายปัจจุบัน การมีข้อมูลที่ใช้ทดสอบจำนวนมากอาจจะช่วยให้ผลลัพธ์การทำนายออกมาดียิ่งขึ้นเพราะมีการวนซ้ำของข้อมูลหลายครั้งกว่าจะมาเป็นข้อมูลล่าสุด และในการฝึกฝนข้อมูลภาพถ่ายดาวเทียมใช้เวลาค่อนข้างมาก ถ้าลดจำนวนการฝึกฝนแล้วไปเพิ่มจำนวนการทำ recursive classifiers อาจจะได้ผลลัพธ์อีกแบบ หรือนำกระบวนการปรับปรุงเพิ่มความคมชัดของภาพมาใช้เพื่อให้แบบจำลองสามารถทำนายได้ดียิ่งขึ้น และในการฝึกฝนแบบจำลองควรจะมีการนำภาพถ่ายดาวเทียมในพื้นที่บริเวณอื่น ๆ ที่มีความซับซ้อนหรือท้าทายมาใช้ฝึกฝนเพื่อให้แบบจำลองได้เรียนรู้พื้นที่น้ำในลักษณะต่าง ๆ หลากหลายรูปแบบ และในการจำแนกพื้นที่น้ำควรจะต้องมีการปรับค่าที่เหมาะสมกับภาพ โดยอาจจะแบ่งเป็นเกณฑ์ของแต่ละฤดูกาล ซึ่งจะส่งผลให้แบบจำลองมีศักยภาพในการจำแนกพื้นที่น้ำจากข้อมูลภาพถ่ายดาวเทียมที่มีความเป็นพลวัตได้ดีมากยิ่งขึ้น

บรรณานุกรม

- Adisa, O. A. (2023, April 23). *Spectral Indices in Remote Sensing: Meaning and Applications (An example)*. spatialnode.
<https://www.spatialnode.net/articles/spectral-indices-in-remote-sensing-meaning-and-applications-an-example06ac2>
- Calatrava, H., Duvvuri, B., Li, H., Borsoi, R., Beighley, E., Erdoğmuş, D., Closas, P., & Tales, I. (2024). Recursive classification of satellite imaging time-series: An application to land cover mapping. *ISPRS Journal of Photogrammetry and Remote Sensing*, 218, 447-465. <https://doi.org/10.1016/j.isprsjprs.2024.09.003>
- Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., & Adam, H. (2018). Encoder-Decoder with Atrous Separable Convolution for Semantic Image Segmentation.
<https://doi.org/10.48550/arXiv.1802.02611>
- Earth Observatory. (2000, August 30). *Measuring Vegetation (NDVI & EVI)*.
https://earthobservatory.nasa.gov/features/MeasuringVegetation/measuring_vegetation_2.php
- Environmental Literacy and Inquiry Working Group at Lehigh University. (2010). *Basic Elements of Aerial Photo Interpretation*.
https://eli.lehigh.edu/sites/eli.lehigh.edu/files/Air_Photo_Interpretation.pdf
- ESRI. (2018). *Indices gallery*. <https://pro.arcgis.com/en/pro-app/latest/help/data/imagery/indices-gallery.htm>
- Geeksforgeeks. (2023, June 10). *Gaussian Mixture Model*.
<https://www.geeksforgeeks.org/gaussian-mixture-model/>
- GIS Geography. (2022). *Spatial Resolution vs Spectral Resolution*.
<https://gisgeography.com/spatial-resolution-vs-spectral-resolution/>
- Isikdogan, F., Bovik, A. C., & Passalacqua, P. (2017). Surface Water Mapping by Deep Learning. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 10(11), 4909-4918. <https://doi.org/10.1109/jstars.2017.2735443>
- Jugier, R., Cremese, R., Fournier, H., Duran-Gomez, N., Salgues, G., & Thenoz, C. (2022).

On water and ice classification from Sentinel-2 imagery using machine learning.
ESS Open Archive.

https://d197for5662m48.cloudfront.net/documents/publicationstatus/98215/preprint_pdf/577576af22ce0a66bb2dee5d452291c9.pdf

Kumar, M. (2022). *Gaussian Mixture Model in Image Processing Explained*. cronj.

<https://www.cronj.com/blog/gaussian-mixture-model-in-image-processing-explained/>

Luo, X., Tong, X., & Hu, Z. (2021). An applicable and automatic method for earth surface water mapping based on multispectral images. *International Journal of Applied*

Earth Observation and Geoinformation, 103. <https://doi.org/10.1016/j.jag.2021.102472>

McFeeters, S. K. (2013). Using the Normalized Difference Water Index (NDWI) within a Geographic Information System to Detect Swimming Pools for Mosquito Abatement: A Practical Approach. *Remote Sensing*, 5(7), 3544-3561.

<https://doi.org/10.3390/rs5073544>

Rosebrock, A. (2022, April 30). *Intersection over Union (IoU) for object detection*.

Pyimagesearch. <https://pyimagesearch.com/2016/11/07/intersection-over-union-iou-for-object-detection/>

Sarker, C., Alvarez, L. M., & Woodley, A. (2016). Integrating recursive Bayesian estimation with support vector machine to map probability of flooding from multispectral Landsat data. 2016 *International Conference on Digital Image Computing:*

Techniques and Applications (DICTA). <https://doi.org/10.1109/DICTA.2016.7797054>

Satellite imaging corporation. (2001). *Sentinel-2A (10m) Satellite Sensor*.

<https://www.satimagingcorp.com/satellite-sensors/other-satellite-sensors/sentinel-2a/>

Tan, M., & Le, Q. V. (2021). EfficientNetV2 Smaller Models and Faster Training.

<https://doi.org/10.48550/arXiv.2104.00298>

THE EUROPEAN SPACE AGENCY. (2024). *About the launch*.

https://www.esa.int/Applications/Observing_the_Earth/Copernicus/Sentinel-2/About_the_launch

USGS. (2019). *Landsat Normalized Difference Vegetation Index*.

<https://www.usgs.gov/landsat-missions/landsat-normalized-difference-vegetation-index#:~:text=%28NIR%20%2D%20R%29%20%2F%20%28,shown%20in%20the%20table%20below.>

Wan, J., & Yong, B. (2023). Automatic extraction of surface water based on lightweight convolutional neural network. *Ecotoxicology and Environmental Safety*, 256.

<https://doi.org/10.1016/j.ecoenv.2023.114843>

Zhai, H., Zhang, H., Zhang, L., & Li, P. (2018). Cloud/shadow detection based on spectral indices for multi/hyperspectral optical remote sensing imagery. *ISPRS Journal of Photogrammetry and Remote Sensing*, 144, 235-253.

<https://doi.org/10.1016/j.isprsjprs.2018.07.006>

กฤษฎาณ อินทรรัตน์. (2021). การจำแนกการใช้ประโยชน์ที่ดินในจังหวัดนครนายกด้วยอัลกอริทึมการเรียนรู้เครื่องและภาพถ่ายจากดาวเทียม Sentinel-2. วารสารวิทยาศาสตร์บูรพา, 2.

<https://ojs.lib.buu.ac.th/index.php/science/article/view/8152>

กิตติศักดิ์ ในจิต. (2566). *Logistic Regression จัดกลุ่มแบบ Binary Classification ใน Machine Learning ด้วย Python*. <https://kittimasak.com/logistic-regression-binary-classification-machine-learning-python/>

ชยณัฐ บัวทองเกื้อ, บุษบากร ทองมาก, อักษรลักษณ์ ไชยรัตน์, พชรพล รัตนถาวร, & ณัฐพล แก้วทอง. (2565). การประยุกต์ใช้ข้อมูลดาวเทียม SENTINEL-2 กับ LANDSAT 8 เพื่อจำแนกการใช้ประโยชน์ที่ดินระดับ 2 พื้นที่คาบสมุทรสทิงพระ จังหวัดสงขลา. การประชุมวิชาการวิศวกรรมโยธาแห่งชาติ, 27.

<https://conference.thaince.org/index.php/ncce27/article/view/1738>

นฤตม์ สุนทรานนท์, & นววิทย์ พงศ์อนันต์. (2565, 29 มิถุนายน). เทคโนโลยี *Remote Sensing (Geospatial Big Data)* กับงานประยุกต์ด้านต่าง ๆ. BIG DATA INSTITUTE. <https://bdi.or.th/big-data-101/technology-remote-sensing-geospatial-big-data-and-innovations/>

ภูริช วรรณโนรมณ์. (2564, 4 พฤษภาคม). วิกฤต 'แม่น้ำโขง' ผันผวน กับปัญหาสิ่งแวดล้อมที่ถูกซ่อนอยู่ท้ายเขื่อน. มูลนิธิสืบนาคะเสถียร. <https://www.seub.or.th/blogging/news/global-news/วิกฤต-แม่น้ำโขง/>

สำนักงานพัฒนาเทคโนโลยีอวกาศและภูมิสารสนเทศ(องค์การมหาชน). (2558, 23 กันยายน). พื้นฐานการรับรู้จากระยะไกล (1). https://www.gistda.or.th/news_view.php?n_id=2405&lang=TH

สำนักงานส่งเสริมเศรษฐกิจดิจิทัล. (2564). การสำรวจข้อมูลระยะไกลเพื่อเกษตรแม่นยำด้วยเทคโนโลยี *Remote*

Sensing. <https://www.depa.or.th/th/article-view/remote-sensing-20210903>



ประวัติผู้เขียน

