



การพัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลนด้วยวิธีการสำรวจระยะไกล
Development of a mangrove health monitoring algorithm using remote sensing

ภูริช เทพนรงค์
Phurit Thepnarong

วิทยานิพนธ์นี้สำหรับการศึกษิตามหลักสูตรปริญญา วิทยาศาสตร์มหาบัณฑิต
สาขาวิชาเทคโนโลยีและการจัดการสิ่งแวดล้อม
มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Fulfillment of the Requirements for the Degree of Master
of Science in Technology and Environmental Management

Prince of Songkla University

2568

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์



การพัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลนด้วยวิธีการสำรวจระยะไกล
Development of a mangrove health monitoring algorithm using remote sensing

ภูริช เทพณรงค์
Phurit Thepnarong

วิทยานิพนธ์นี้สำหรับการศึกษิตามหลักสูตรปริญญา วิทยาศาสตร์มหาบัณฑิต
สาขาวิชาเทคโนโลยีและการจัดการสิ่งแวดล้อม
มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Fulfillment of the Requirements for the Degree of Master
of Science in Technology and Environmental Management
Prince of Songkla University

2568

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์

คณะกรรมการสอบ

5182626.

Digitally signed: 2025.06.12 15:58:20 +07:00

(ผู้ช่วยศาสตราจารย์ ดร.วีรพันธ์ สงสม)

25th Nov

Digitally signed: 2025.06.13 16:38:33 +07:00

(ดร.จิราพร กุลสุนทรรัตน์)

..ประธาน

⑤ 8182626

Digitally signed: 2025.06.12 15:58:22 +07:00

(ผู้ช่วยศาสตราจารย์ ดร.วีรพันธ์ สงสม)

..กิจกรรมการ

[Signature]

Digitally signed : 2025.06.16 16:02:36 +07:00

(รองศาสตราจารย์ ธงชัย สุนิรศักดิ์)

..กิจกรรมการ

บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ อนุมัติให้บัณฑิตวิทยาลัยรับผิดชอบสำหรับการ
ศึกษาตามหลักสูตรปริญญา วิทยาศาสตร์มหาบัณฑิต สาขาวิชาเทคโนโลยีและการจัดการสิ่งแวดล้อม




Digitally signed : 2025.06.17 13:49:32 +07:00

(ศาสตราจารย์ ดร. มิตรชัย จงเชื้อวานานาญ)

คณะบดีบัณฑิตวิทยาลัย


(3)

ขอรับรองว่า ผลงานวิจัยนี้มาจากการศึกษาวิจัยของนักศึกษาเอง และได้แสดงความขอบคุณบุคคลที่มี
ส่วนช่วยเหลือแล้ว

ลงชื่อ.....

Digitally signed : 2025.06.12 15:58:24 +07:00

(ผู้ช่วยศาสตราจารย์ ดร.วีรนนท์ สงสม)

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ลงชื่อ.....


(นายภูริช เทพณรงค์)

นักศึกษา

ข้าพเจ้าขอรับรองว่า ผลงานวิจัยนี้ไม่เคยเป็นส่วนหนึ่งในการอนุมัติปริญญาในระดับใดมาก่อน และ
ไม่ได้ถูกใช้ในการยื่นขออนุมัติปริญญาในขณะนี้

ลงชื่อ ภูริช
(นายภูริช เทพณรงค์)
นักศึกษา

ชื่อวิทยานิพนธ์	การพัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลนด้วยวิธีการสำรวจระยะไกล
ผู้เขียน	นายภูริช เทพณรงค์
สาขาวิชา	เทคโนโลยีและการจัดการสิ่งแวดล้อม
ปีการศึกษา	2567

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อคัดเลือกดัชนีพืชพรรณที่เหมาะสมและพัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลนจากภาพถ่ายทางอากาศด้วยวิธีการสำรวจระยะไกล โดยดำเนินการเก็บข้อมูลภาคสนามในพื้นที่ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต ผ่านการวัดค่าการสะท้อนเชิงสเปกตรัมของใบไม้ด้วยเครื่อง Spectroradiometer และใช้ร่วมกับภาพถ่ายจาก UAV แบบหลายช่วงคลื่น (Multispectral) จากนั้นคำนวณค่าดัชนีพืชพรรณ 16 ดัชนี ได้แก่ NDVI, GNDVI, NDWI, SAVI, EVI, NDRE, NDI, TCARI, RECI, CCCI, GCC, VDMI, MTCI, ExG, PSRI และ VARI และวิเคราะห์คัดเลือกจนได้ดัชนีที่เหมาะสมสำหรับการพัฒนาอัลกอริทึม 3 รูปแบบ ได้แก่ Random Forest (RF), Support Vector Machine (SVM) และ Extreme Gradient Boosting (XGBoost) ผลการศึกษาพบว่า GNDVI, NDWI, NDRE, CCCI, ExG และ MTCI เป็นดัชนีที่เหมาะสมสำหรับจำแนกสุขภาพของป่าชายเลนจากภาพถ่ายทางอากาศแบบหลายช่วงคลื่น โดยอัลกอริทึม Random Forest (RF) ให้ผลการจำแนกที่ดีที่สุด ด้วยค่าความแม่นยำโดยรวม (Overall Accuracy) 95% และค่า Kappa 0.87 กลุ่มสุขภาพดีมีค่าความแม่นยำสูงทั้งในด้าน Producer's Accuracy (99%) และ User's Accuracy (95%) ส่วนกลุ่มสุขภาพไม่ดีแม้มีค่า Producer's Accuracy อยู่ที่ 61% แต่เมื่อพิจารณาพร้อมกับ User's Accuracy ที่อยู่ในระดับสูง ที่ 88% ยังคงสามารถใช้ในการวิเคราะห์สุขภาพพืชได้อย่างมีประสิทธิภาพ เพื่อให้สามารถทราบถึงพื้นที่ป่าชายเลนที่มีสุขภาพดีหรือไม่ดี ทั้งนี้หน่วยงานที่เกี่ยวข้อง เช่น กรมทรัพยากรทางทะเลและชายฝั่ง ศูนย์วิจัยและพัฒนาทรัพยากรป่าชายเลน สามารถเข้าไปยังพื้นที่เพื่อฟื้นฟูป่าชายเลนได้ถูกพื้นที่

คำสำคัญ: ป่าชายเลน, สุขภาพของป่าชายเลน, การรับรู้ระยะไกล, ภาพถ่ายทางอากาศแบบหลาย

ช่วงคลื่น, ดัชนีพืชพรรณ, การเรียนรู้ของเครื่อง, การวิเคราะห์เชิงสเปกตรัม

Thesis Title	Development of a mangrove health monitoring algorithm using remote sensing
Author	Mister Phurit Thepnarong
Major Program	Technology And Environmental Management
Academic Year	2024

ABSTRACT

This study aims to identify suitable vegetation indices and develop classification algorithms for monitoring mangrove forest health from aerial imagery using remote sensing methods. Field data were collected in the mangrove area of Khlong Ko Phi, Phuket Province, by measuring leaf spectral reflectance with a spectroradiometer, combined with multispectral UAV imagery. Sixteen vegetation indices were calculated: NDVI, GNDVI, NDWI, SAVI, EVI, NDRE, NDI, TCARI, RECI, CCCI, GCC, VDMI, MTCI, ExG, PSRI, and VARI. From these, GNDVI, NDWI, NDRE, CCCI, ExG, and MTCI were identified as the most effective indices for algorithm development using three models: Random Forest (RF), Support Vector Machine (SVM), and Extreme Gradient Boosting (XGBoost). The RF algorithm yielded the best classification performance, achieving 95% overall accuracy and a Kappa coefficient of 0.87. The healthy mangrove class showed high Producer's Accuracy (99%) and User's Accuracy (95%), while the unhealthy class, despite a lower Producer's Accuracy (61%), maintained a high User's Accuracy (88%), indicating reliable classification performance. The findings can support relevant agencies, such as the Department of Marine and Coastal Resources and the Mangrove Resources Research and Development Center, in identifying degraded areas for targeted restoration efforts.

Keyword: Mangrove, Mangrove health, Remote Sensing, Multispectral aerial imagery, Vegetation Indices, Machine learning, Spectral Analysis

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยความอนุเคราะห์และการสนับสนุนอย่างดียิ่งจาก ผู้ช่วยศาสตราจารย์ ดร. วีรพันธ์ สงสม อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก ผู้ซึ่งได้กรุณาให้คำแนะนำ ถ่ายทอดความรู้ ตลอดจนให้คำปรึกษาอย่างใกล้ชิดในการดำเนินงานวิจัย อีกทั้งได้ช่วยตรวจสอบและแก้ไขข้อบกพร่องต่าง ๆ ซึ่งเป็นประโยชน์อย่างยิ่งต่อการจัดทำเล่มวิทยานิพนธ์ตั้งแต่เริ่มต้นจนแล้วเสร็จ ผู้วิจัยจึงขอขอบพระคุณมา ณ โอกาสนี้

ขอขอบพระคุณ ดร. จิราพร กุลสุนทรรัตน์ ประธานกรรมการสอบ และ รองศาสตราจารย์ ธงชัย สุธีรศักดิ์ กรรมการสอบ สำหรับคำแนะนำ ข้อเสนอแนะ ตลอดจนแก้ไขข้อบกพร่องในการทำงานวิจัยทำให้วิทยานิพนธ์ฉบับนี้มีความสมบูรณ์ยิ่งขึ้น

ขอขอบพระคุณ คณะเทคโนโลยี และ สิ่งแวดล้อม และ บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ ที่ให้การสนับสนุนทุนวิจัยสำหรับการทำวิทยานิพนธ์ในครั้งนี้ รวมถึงเจ้าหน้าที่บัณฑิตศึกษาทุกท่านที่คอยให้คำแนะนำ และติดต่อประสานงานในด้านต่าง ๆ ตลอดระยะเวลาการทำวิทยานิพนธ์

ขอขอบพระคุณ ผู้อำนวยการศูนย์บริหารจัดการทรัพยากรป่าชายเลน จังหวัดภูเก็ต ที่ได้กรุณาอนุเคราะห์พื้นที่ป่าชายเลนสำหรับการลงพื้นที่เก็บข้อมูลภาคสนามและการเก็บภาพถ่ายทางอากาศด้วยอากาศยานไร้คนขับ รวมทั้งให้คำแนะนำในการดำเนินงานเก็บข้อมูลในพื้นที่อย่างดียิ่ง

ขอขอบพระคุณ คณะนักศึกษาจากคณะเทคโนโลยีและสิ่งแวดล้อม สาขาเทคโนโลยีภูมิสารสนเทศสิ่งแวดล้อม ที่ได้ให้ความอนุเคราะห์ในการช่วยดำเนินการเก็บข้อมูลภาคสนามและการเก็บข้อมูลภาพถ่ายทางอากาศ ด้วยความเอื้อเฟื้อและตั้งใจเป็นอย่างดี

ขอขอบพระคุณนายจิรายุ แห่อ่อง นางสาวกัญจน์ณภัทร์ สุขสวัสดิ์ และนายสุรเชษฐ์ ปั่นแก้ว สำหรับความช่วยเหลือในการวัดค่าการสะท้อนแสงของใบไม้ การบินอากาศยานไร้คนขับ และการเก็บภาพถ่ายทางอากาศ รวมถึงเพื่อน พี่ และน้องในคณะเทคโนโลยีและสิ่งแวดล้อมทุกคน ที่คอยให้กำลังใจและคำแนะนำตลอดระยะเวลาการทำวิทยานิพนธ์

สุดท้ายนี้ ผู้วิจัยขอขอบพระคุณ บิดา มารดา เพื่อน พี่ น้อง ตลอดจนบุคคลทุกท่านที่มีส่วนเกี่ยวข้องกับการทำวิทยานิพนธ์ ที่ได้ให้ความช่วยเหลือ ให้คำแนะนำ ให้กำลังใจ และให้การสนับสนุนในด้านต่าง ๆ จนส่งผลให้วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยดี ผู้วิจัยขอขอบพระคุณมา ณ โอกาสนี้

ภูริช เทพณรงค์

สารบัญ

	หน้า
บทคัดย่อ	(5)
Abstract	(6)
กิตติกรรมประกาศ	(7)
สารบัญ	(8)
รายการตาราง	(11)
รายการสมการ	(12)
รายการรูปภาพ	(14)
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์	4
1.3 ขอบเขตของการวิจัย	4
1.3.1 ขอบเขตเชิงเนื้อหา	4
1.3.2 ขอบเขตเชิงพื้นที่	4
1.4 กรอบแนวคิด	5
1.5 ประโยชน์ที่คาดว่าจะได้รับ	6
1.6 ระยะเวลาทำงานวิจัย	7
บทที่ 2 ทฤษฎีและเนื้อหาที่เกี่ยวข้อง	8
2.1 ป่าชายเลน (Mangrove)	8
2.1.1 ความหมายและลักษณะของป่าชายเลน	8
2.1.2 ความสำคัญของป่าชายเลน	9
2.2 การรับรู้ระยะไกล (Remote Sensing)	10
2.2.1 ความหมายของการรับรู้ระยะไกล	10
2.2.2 ประโยชน์ของการรับรู้ระยะไกล	11
2.2.3 คุณลักษณะของอากาศยานไร้คนขับ DJI P4 Multispectral	12
2.2.4 การรับรู้ระยะไกลกับสุขภาพพืชพรรณ	14
2.2.5 ดัชนีพืชพรรณ (Vegetation indices)	16
2.3 การเรียนรู้ของเครื่อง (Machine Learning)	23

สารบัญ (ต่อ)

	หน้า
2.3.1 ความหมายของการเรียนรู้ของเครื่อง	23
2.3.2 การเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (Extreme Gradient Boosting)	24
2.3.3 เครื่องเวกเตอร์สนับสนุน (Support Vector Machine)	24
2.3.4 อัลกอริทึมป่าแบบสุ่ม (Random Forest)	25
2.4 สถิติที่เกี่ยวข้อง	26
2.4.1 แผนภูมิกล่อง (Boxplot)	26
2.4.2 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)	27
2.4.3 ค่าสัมประสิทธิ์กำหนด (Coefficient of Determination)	27
2.5 งานวิจัยที่เกี่ยวข้อง	28
บทที่ 3 วิธีการวิจัย	32
3.1 ข้อมูล อุปกรณ์ และเครื่องมือที่ใช้ในการวิจัย	32
3.1.1 ข้อมูลที่ใช้ในการวิจัย	32
3.1.2 อุปกรณ์และเครื่องมือที่ใช้ในการวิจัย	32
3.2 พื้นที่ศึกษา	33
3.3 วิธีการดำเนินงานวิจัย	35
3.3.1 เตรียมข้อมูลก่อนการวิเคราะห์	36
3.3.2 การพัฒนาอัลกอริทึมสำหรับติดตามสุขภาพของป่าชายเลน	40
บทที่ 4 ผลการศึกษาและอภิปรายผล	46
4.1 การจำแนกสุขภาพป่าชายเลนจากข้อมูลภาคสนาม	46
4.2 ผลการจำแนกสุขภาพด้วยสายตาจากภาพถ่ายทางอากาศ	50
4.3 การจำแนกสุขภาพป่าชายเลนจากข้อมูลดัชนีพืชพรรณ	51
4.4 ผลการจำแนกสุขภาพของป่าชายเลนจากโมเดล	64
4.4.1 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล จากโมเดล XGB	64
4.4.2 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล จากโมเดล SVM	66
4.4.3 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล จากโมเดล RF	68
4.4.4 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่ทดสอบ จากโมเดล RF	72
4.4.5 ผลการจำแนกสุขภาพป่าชายเลนคลองเกาะผี จากโมเดล RF	75

สารบัญ (ต่อ)

	หน้า
บทที่ 5 สรุปผลการศึกษา ปัญหา และข้อเสนอแนะ	76
5.1 สรุปผลการศึกษา	76
5.1.1 ดัชนีพืชพรรณที่มีประสิทธิภาพ	76
5.1.2 การเลือกโมเดลหลักในการประเมินสุขภาพของป่าชายเลน	76
5.1.3 ประสิทธิภาพในการจำแนกของโมเดล Random Forest	77
5.2 ปัญหา	78
5.3 ข้อเสนอแนะ	78
เอกสารอ้างอิง	79
ภาคผนวก	87
ภาคผนวก ก	88
ภาคผนวก ข	91
ภาคผนวก ค	93
ประวัติผู้เขียน	94

รายการตาราง

	หน้า
ตารางที่ 1.1 ระยะเวลาทำการวิจัยและแผนการดำเนินงานตลอดโครงการวิจัย	7
ตารางที่ 2.1 รายละเอียดของอากาศยานไร้คนขับ DJI P4 Multispectral	13
ตารางที่ 2.2 คุณสมบัติและช่วงคลื่นของอากาศยานไร้คนขับ DJI P4 Multispectral	13
ตารางที่ 4.1 การเปรียบเทียบสุขภาพของพืชที่ได้จากค่าการสะท้อน DN และการตีความด้วยสายตาจากภาพถ่ายทางอากาศ	47
ตารางที่ 4.2 ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน	52
ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน	57
ตารางที่ 4.4 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล XGboost ในพื้นที่สร้างโมเดล	65
ตารางที่ 4.5 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล SVM ในพื้นที่สร้างโมเดล	67
ตารางที่ 4.6 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล Random Forest ในพื้นที่สร้างโมเดล	70
ตารางที่ 4.7 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล Random Forest ในพื้นที่ทดสอบโมเดล	73

รายการสมการ

	หน้า
สมการที่ 2.1 ดัชนีพืชพรรณผลต่างแบบนอร์มัลไลซ์ (Normalized Difference Vegetation Index)	17
สมการที่ 2.2 ดัชนีพืชพรรณผลต่างความชื้น (Normalized Difference Water Index)	17
สมการที่ 2.3 ดัชนีความแตกต่างพืชพรรณด้วยช่วงคลื่นสีเขียว (Green Normalized Difference Vegetation Index)	17
สมการที่ 2.4 ดัชนีพืชพรรณปรับแก้ดิน (Soil-adjusted Vegetation Index)	18
สมการที่ 2.5 ดัชนีเน้นภาพพืชพรรณ (Enhanced Vegetation Index)	18
สมการที่ 2.6 ดัชนีความแตกต่างแบบปกติของแถบคลื่นขอบแดง (Normalized Difference Red Edge Index)	19
สมการที่ 2.7 ดัชนีความแตกต่างแบบปกติ (Normalized Difference Indices)	19
สมการที่ 2.8 อัตราการดูดกลืนคลอโรฟิลล์ที่เปลี่ยนรูป (Transformed chlorophyll absorption ratio)	19
สมการที่ 2.9 ดัชนีคลอโรฟิลล์ขอบแดง (Red Edge Chlorophyll Index)	20
สมการที่ 2.10 ดัชนีปริมาณคลอโรฟิลล์ของเรือนยอด (Canopy Chlorophyll Content Index)	20
สมการที่ 2.11 ดัชนีพิกัดสีเขียว (Green Chromatic Coordinate)	21
สมการที่ 2.12 ดัชนีความแตกต่างของพืชพรรณจากแสงที่ตามองเห็น (Visible-band Difference Vegetation Index)	21
สมการที่ 2.13 ดัชนีคลอโรฟิลล์บนพื้นดินของ MERIS (MERIS Terrestrial Chlorophyll Index)	22

รายการสมการ (ต่อ)

	หน้า
สมการที่ 2.14 ดัชนีความเขียวส่วนเกิน (Excess Green Index)	22
สมการที่ 2.15 ดัชนีการสะท้อนแสงของพืชในช่วงเสื่อมสภาพ (Plant Senescence Reflectance Index)	23
สมการที่ 2.16 ดัชนีต้านทานผลกระทบจากชั้นบรรยากาศในช่วงแสงที่ตามองเห็น (Visible Atmospherically Resistant Index)	23
สมการที่ 2.17 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)	27
สมการที่ 2.18 ค่าสัมประสิทธิ์กำหนด (Coefficient of Determination)	27
สมการที่ 3.1 ความถูกต้องโดยรวม (Overall Accuracy)	43
สมการที่ 3.2 ความถูกต้องของผู้ผลิต (Producer's Accuracy)	44
สมการที่ 3.3 ความถูกต้องของผู้ใช้ (User's Accuracy)	44
สมการที่ 3.4 ค่าสถิติแคปปา (Kappa Statistic)	45

รายการรูปภาพ

	หน้า
รูปที่ 1.1 แผนที่พื้นที่ศึกษาจังหวัดภูเก็ต	5
รูปที่ 1.2 กรอบแนวคิด	6
รูปที่ 2.1 ป่าชายเลน	9
รูปที่ 2.2 อากาศยานไร้คนขับ รุ่น DJI P4 Multispectral	12
รูปที่ 2.3 การสะท้อนแสงของพืชที่ตาย มีความเครียด และสุขภาพดี	15
รูปที่ 2.4 การสะท้อนแสงของพืชพรรณ ดิน และน้ำ	16
รูปที่ 2.5 ภาพรวมของกระบวนการ Machine Learning เบื้องต้น	24
รูปที่ 2.6 โครงสร้างของ Random Forest	26
รูปที่ 3.1 แผนที่ภาพถ่ายทางอากาศพื้นที่ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต แสดงพื้นที่สร้างโมเดลและพื้นที่ทดสอบโมเดล	34
รูปที่ 3.2 ขั้นตอนการดำเนินการ	35
รูปที่ 3.3 รูปแบบแปลงและตำแหน่งจุดเก็บข้อมูลตัวอย่าง	37
รูปที่ 3.4 แผนที่ตำแหน่งจุดเก็บข้อมูลตัวอย่างใบไม้ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต	37
รูปที่ 3.5 การตรวจวัดค่าการสะท้อนแสงของใบไม้ ด้วยเครื่อง Spectroradiometer	39
รูปที่ 3.6 ตัวอย่างการจำแนกสุขภาพของเรือนยอดป่าชายเลนด้วยสายตา โดยใช้ภาพถ่าย UAV ความละเอียดสูง	40
รูปที่ 3.7 รูปแบบตาราง Error Matrix	43
รูปที่ 4.1 แผนที่ตำแหน่งจุดเก็บตัวอย่างและจำแนกสุขภาพใบไม้ในพื้นที่ป่าชายเลน คลองเกาะผี	48
รูปที่ 4.2 ค่า DN ของตัวอย่างใบไม้ในป่าชายเลน ตามความยาวช่วงคลื่น	49
รูปที่ 4.3 ความสัมพันธ์ระหว่างตำแหน่งตัวอย่างใบไม้ ลักษณะทางสายตา และค่าการสะท้อนเชิงสเปกตรัมของพืชป่าชายเลน	49
รูปที่ 4.4 แผนที่การจำแนกสุขภาพของเรือนยอดป่าชายเลนโดยใช้วิธีการแปลภาพด้วยสายตา จากภาพถ่าย UAV ทั้งในช่วงฤดูร้อนและฤดูฝน	51
รูปที่ 4.5 กราฟความสัมพันธ์ระหว่างฤดูร้อนและฤดูฝนของดัชนีพืชพรรณทั้ง 6 ดัชนี	63
รูปที่ 4.6 แผนที่การจำแนกสุขภาพของโมเดล XGboost ป่าชายเลนคลองเกาะผี ในพื้นที่สร้างโมเดล ช่วงฤดูร้อนและฤดูฝน	66

รายการรูปภาพ (ต่อ)

	หน้า
รูปที่ 4.7 แผนที่การจำแนกสุขภาพของโมเดล SVM ป่าชายเลนคลองเกาะผี ในพื้นที่สร้างโมเดล ช่วงฤดูร้อนและฤดูฝน	68
รูปที่ 4.8 แผนที่การจำแนกสุขภาพของโมเดล RF ป่าชายเลนคลองเกาะผี ในพื้นที่สร้างโมเดล ช่วงฤดูร้อนและฤดูฝน	71
รูปที่ 4.9 แผนที่การจำแนกสุขภาพของโมเดล RF ป่าชายเลนคลองเกาะผี ในพื้นที่ข้อมูลทดสอบ ช่วงฤดูฝน	74
รูปที่ 4.10 แผนที่การจำแนกสุขภาพพืชป่าชายเลนโดยโมเดล RF พื้นที่ป่าชายเลนคลองเกาะผี จ.ภูเก็ต	75
รูปภาคผนวก 1 Code สำหรับฝึกโมเดล Random forest	88
รูปภาคผนวก 2 Code สำหรับใช้โมเดล Random forest ทำนายสุขภาพป่าชายเลน	88
รูปภาคผนวก 3 Code สำหรับฝึกโมเดล XGboost	89
รูปภาคผนวก 4 Code สำหรับใช้โมเดล XGboost ทำนายสุขภาพป่าชายเลน	89
รูปภาคผนวก 5 Code สำหรับฝึกโมเดล Support Vector Machine	90
รูปภาคผนวก 6 Code สำหรับใช้โมเดล Support Vector Machine ทำนายสุขภาพป่าชายเลน	90
รูปภาคผนวก 7 บรรยายภาคการลงพื้นที่ภาคสนาม	92
รูปภาคผนวก 8 บรรยายภาคการเก็บข้อมูลภาพถ่ายทางอากาศ	93

สัญลักษณ์และคำย่อ

CCCI	Canopy Chlorophyll Content Index
EVI	Enhanced Vegetation Index
ExG	Excess Green Index
GCC	Green Chromatic Coordinate
GNDVI	Green Normalized Difference Vegetation Index
GIS	Geographic Information System
ML	Machine Learning
MTCI	MERIS Terrestrial Chlorophyll Index
NDI	Normalized Difference Indices
NDRE	Normalized Difference Red Edge Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
PSRI	Plant Senescence Reflectance Index
RECI	Red Edge Chlorophyll Index
RF	Random Forest
SAVI	Soil-adjusted Vegetation Index
SVM	Support Vector Machine
TCARI	Transformed Chlorophyll Absorption Ratio
UAV	Unmanned Aerial Vehicle
VARI	Visible Atmospherically Resistant Index
VDVI	Visible-band Difference Vegetation Index
XGB	XGboost or Extreme Gradient Boosting

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ป่าชายเลนเป็นระบบนิเวศที่ตั้งอยู่ในบริเวณที่เป็นจุดเชื่อมระหว่างผืนดินกับทะเล โดยเฉพาะในเขตร้อนซึ่งเป็นแหล่งสะสมคาร์บอนหรือมวลชีวภาพที่มีขนาดใหญ่ (Alatorre et al., 2016) สภาพแวดล้อมของป่าชายเลนประกอบด้วยดินเลนและน้ำกร่อย ที่พบในเขตน้ำขึ้นน้ำลง พืชพรรณในป่าชายเลนมีความหลากหลาย เช่น ต้นโกงกาง (*Rhizophora spp.*) แสมขาว (*Avicennia alba*) ตะบูน (*Xylocarpus granatum*) ลำพูทะเล (*Sonneratia alba*) และจาก (*Nypa fruticans*) เป็นต้น นอกจากนี้ยังเป็นที่อยู่อาศัยของสัตว์หลากหลายชนิด อาทิ ปูแสมก้ามแดง (*Chiromantes eumolpe*) ปลาตีน (*Boleophthalmus*) และปูทะเล (*Scylla serrata*) เป็นต้น ป่าชายเลนเป็นระบบนิเวศที่มีความสำคัญต่อโลกในหลายมิติ ทั้งด้านเศรษฐกิจและการอนุรักษ์สิ่งแวดล้อม ในแง่เศรษฐกิจและการท่องเที่ยว ป่าชายเลนเป็นแหล่งท่องเที่ยวที่น่าสนใจด้วยกิจกรรมทางธรรมชาติ เช่น การพายเรือคายัคและการเดินศึกษาธรรมชาติ นอกจากนี้ทรัพยากรจากป่าชายเลน เช่น กุ้ง หอย ปู ปลา และถ่านไม้ ยังเป็นแหล่งรายได้สำคัญของชุมชนอีกด้วย ในแง่ของระบบนิเวศวิทยา ป่าชายเลนมีบทบาทสำคัญในการอนุบาลสัตว์น้ำ อีกทั้งยังช่วยป้องกันการกัดเซาะชายฝั่งจากการกระทำของน้ำทะเล ลมพายุ และมรสุม โดยป่าชายเลนสามารถดักตะกอนและบำบัดน้ำเสียก่อนที่น้ำจะไหลลงสู่ทะเล (กรมทรัพยากรทางทะเลและชายฝั่ง, 2562) สุขภาพของป่าชายเลนที่ดีจึงเป็นตัวชี้วัดถึงความหลากหลายทางชีวภาพและความสมดุลของระบบนิเวศในบริเวณนั้น หากป่าชายเลนบริเวณใดมีสุขภาพผกผันย่อมหมายถึงความหลากหลายทางระบบนิเวศสูงเช่นกัน

พื้นที่ป่าชายเลนในประเทศไทยมีความสำคัญอย่างยิ่งต่อการอนุรักษ์สิ่งแวดล้อมและเศรษฐกิจ ปัจจุบัน ประเทศไทยมีพื้นที่ป่าชายเลนคงสภาพรวมประมาณ 1,737,000 ไร่ ซึ่งเพิ่มขึ้นร้อยละ 0.24 เมื่อเทียบกับปี พ.ศ. 2557 ที่มีพื้นที่ 1,534,585 ไร่ พื้นที่เหล่านี้กระจายอยู่ตามแนวชายฝั่งของภาคตะวันออก ภาคกลาง และภาคใต้ โดยพื้นที่ป่าชายเลนในภาคตะวันออกมีประมาณ 79,000 ไร่ คิดเป็นร้อยละ 7.5 ของพื้นที่ทั้งหมด ในขณะที่ภาคกลางมีพื้นที่ป่าชายเลนประมาณ 34,056 ไร่

หรือร้อยละ 3.3 ซึ่งถือว่าน้อยมากเมื่อเทียบกับภาคใต้ที่มีพื้นที่ป่าชายเลนมากที่สุด คือประมาณ 934,220 ไร่ คิดเป็นร้อยละ 89.2 (ยวทัศน์ รักสิ่งแวดล้อม, 2552) อย่างไรก็ตาม ในจังหวัดภูเก็ตพบว่าอัตราการเปลี่ยนแปลงของพื้นที่ป่าชายเลนมีแนวโน้มลดลง (กรมทรัพยากรทางทะเลและชายฝั่ง, 2562) ปัจจุบัน จังหวัดภูเก็ตมีพื้นที่ป่าชายเลนที่ยังคงสภาพตามแนวชายฝั่งประมาณ 17,000 ไร่ (กรมพัฒนาที่ดิน, 2563) การลดลงของพื้นที่ป่าชายเลนในภูเก็ตมีสาเหตุหลักจากการเปลี่ยนแปลงการใช้ประโยชน์ที่ดิน เช่น การทำการเกษตร นาเกลือ และการสร้างท่าเทียบเรือ เป็นต้น ซึ่งกิจกรรมเหล่านี้อาจส่งผลกระทบต่อสุขภาพและความสมบูรณ์ของระบบนิเวศป่าชายเลนในระยะยาว

การประเมินสุขภาพของป่าชายเลนโดยทั่วไปมักต้องอาศัยการลงพื้นที่เพื่อเก็บตัวอย่างพืชดิน น้ำ หรือปัจจัยสิ่งแวดล้อมอื่น ๆ อย่างไรก็ตาม วิธีการนี้อาจไม่เหมาะสมสำหรับพื้นที่ขนาดใหญ่ หรือการประเมินที่ต้องทำอย่างต่อเนื่องเป็นเวลานาน นอกจากนี้ การลงพื้นที่เพื่อเก็บข้อมูลยังมีข้อจำกัดด้านงบประมาณสำหรับการจ้างบุคคลและการเข้าถึงพื้นที่ (เยวาลักษณ์ มีบุญมาก และคณะ, 2563) หนึ่งในวิธีการที่สามารถช่วยลดข้อจำกัดเหล่านี้ได้คือการใช้ภาพถ่ายดาวเทียม ภาพถ่ายดาวเทียมมีข้อได้เปรียบในการครอบคลุมพื้นที่กว้างและสามารถประเมินสภาพพื้นที่ได้อย่างต่อเนื่อง (Alatorre et al., 2016) การใช้ภาพถ่ายดาวเทียมยังช่วยให้สามารถระบุจุดหรือบริเวณที่พืชในป่าชายเลนมีสุขภาพไม่ดี และสามารถเข้าไปดำเนินการแก้ไขปัญหาได้อย่างตรงจุด

มีงานวิจัยจำนวนมากที่มุ่งเน้นการประเมินสุขภาพของป่าชายเลนโดยใช้ข้อมูลจากภาพถ่ายดาวเทียม เช่น การประเมินสุขภาพของป่าชายเลนในประเทศอินเดียโดยอาศัยดัชนีพืชพรรณจากภาพถ่าย Landsat (Prabakaran et al., 2014) และการวัดปริมาณคลอโรฟิลล์ในใบพืชของป่าชายเลนด้วยข้อมูลจาก Sentinel-2 (Zhen et al., 2021) ซึ่งแสดงให้เห็นว่าข้อมูลจากดาวเทียมสามารถใช้ในการประเมินสุขภาพของป่าชายเลนในระดับพื้นที่กว้างได้ อย่างไรก็ตาม งานวิจัยหลายชิ้นยังพบว่าภาพถ่ายดาวเทียมอาจมีข้อจำกัดในการสะท้อนความแตกต่างของสุขภาพป่าชายเลนในระดับพื้นที่ขนาดเล็ก โดยเฉพาะอย่างยิ่งในพื้นที่ที่มีความหลากหลายของชนิดพันธุ์ไม้และโครงสร้างเรือนยอดที่ซับซ้อน เช่น พื้นที่ป่าชายเลน ซึ่งมีลักษณะของสิ่งปกคลุมดินที่ไม่สม่ำเสมอ เพื่อเพิ่มความแม่นยำในการประเมินสุขภาพของป่าชายเลน การเก็บข้อมูลเชิงลึกผ่านเทคโนโลยีภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ (UAV) ที่ติดตั้งกล้องถ่ายภาพหลายช่วงคลื่น (Multispectral) จึงเป็นทางเลือกที่เหมาะสม เนื่องจากสามารถให้ข้อมูลที่มีความละเอียดเชิงพื้นที่ในระดับเซนติเมตร ควบคุมช่วงเวลาเก็บข้อมูลได้ และลดผลกระทบจากเมฆซึ่งเป็นข้อจำกัดของภาพถ่ายดาวเทียม นอกจากนี้ การใช้ข้อมูลภาคสนาม เช่น การตรวจสอบสุขภาพใบไม้จริงในพื้นที่ ร่วมกับข้อมูลภาพถ่ายจาก UAV ยังช่วยเพิ่มความแม่นยำในการวิเคราะห์และจำแนกสุขภาพของป่าชายเลนได้อย่างเป็นระบบและสอดคล้องกับความเป็นจริงมากยิ่งขึ้น ข้อมูลที่ได้สามารถนำไปประยุกต์ใช้ร่วมกับเทคนิคการเรียนรู้

ของเครื่อง (Machine Learning) เพื่อพัฒนาอัลกอริทึมสำหรับจำแนกสุขภาพของป่าชายเลนได้อย่างมีประสิทธิภาพ ช่วยประหยัดเวลาในการวิเคราะห์ข้อมูลซ้ำ ๆ จัดกระบวนการวิเคราะห์ให้เป็นระเบียบมากขึ้น และสามารถปรับตัวตามข้อมูลที่ป้อนเข้าไปได้อย่างอัตโนมัติ

หลายงานวิจัยได้ประยุกต์ใช้ ML ในการวิเคราะห์สุขภาพและการจำแนกชนิดพันธุ์ไม้ในพื้นที่ป่า ตัวอย่างเช่น การจำแนกชนิดพันธุ์ไม้และการประเมินสุขภาพของป่าสน โดยใช้ข้อมูลดัชนีพืชพรรณจำนวน 9 ดัชนี ได้แก่ NDVI, SAVI, MCARI2, NDRE, RESR, CI, PSRI, M3CI และ SR จากภาพถ่ายจากอากาศยานไร้คนขับ (Abdollahnejad and Panagiotidis, 2020) และการสร้างแบบจำลอง RF โดยใช้ข้อมูลดัชนีพืชพรรณ NDVI เพื่อติดตามสถานะสุขภาพของป่าเอลเดอร์ดำ จากภาพถ่ายจากอากาศยานไร้คนขับ (Guerra-Hernández et al., 2021) งานวิจัยเหล่านี้มุ่งเน้นไปที่การประเมินสุขภาพของป่าบก สำหรับการศึกษาป่าชายเลน การประยุกต์ใช้การเรียนรู้ของเครื่องมีบทบาทสำคัญเช่นกัน เช่น การใช้ ML ในการจำแนกสิ่งปกคลุมดินเพื่อสร้างแผนที่ป่าชายเลน โดยใช้ภาพถ่ายดาวเทียม Sentinel-1 และ Sentinel-2 (Ghorbanian et al., 2022) รวมถึงการใช้ ML ในการจำแนกชนิดป่าชายเลน โดยใช้ข้อมูล Multispectral จากภาพถ่ายดาวเทียม Ikonos (Wang, Silván-Cárdenas, and Sousa, 2022) อย่างไรก็ตาม จากการศึกษพบว่า ยังไม่มีงานวิจัยที่นำเทคโนโลยี ML มาประยุกต์ใช้ในการประเมินและจำแนกสุขภาพของป่าชายเลนจากภาพถ่ายทางอากาศโดยตรง ในงานวิจัยนี้ ผู้วิจัยเลือกใช้อากาศยานไร้คนขับ (UAV) รุ่น DJI P4 Multispectral ซึ่งสามารถเก็บข้อมูลภาพถ่ายเชิงหลายช่วงคลื่น (Multispectral Imaging) ที่มีความละเอียดเชิงพื้นที่สูงเหมาะสำหรับการวิเคราะห์ในระดับพื้นที่ขนาดเล็ก โดรนรุ่นนี้มีแถบคลื่นสำคัญ เช่น Red, Green, Red Edge และ Near-Infrared ซึ่งสามารถนำไปใช้คำนวณดัชนีพืชพรรณเพื่อติดตามความเปลี่ยนแปลงของสุขภาพพืชพรรณได้อย่างแม่นยำ โดยงานวิจัยนี้ได้พัฒนาอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) โดยอาศัยข้อมูลดัชนีพืชพรรณ (Vegetation Indices) เป็นตัวแปรนำเข้า โดยมีการคำนวณดัชนีทั้งหมด 16 ชนิด ได้แก่ NDVI, GNDVI, NDWI, SAVI, EVI, NDRE, NDI, TCARI, RECI, CCCI, GCC, VDMI, MTCI, ExG, PSRI และ VARI ก่อนที่จะทำการวิเคราะห์คัดเลือกเพื่อหาดัชนีที่เหมาะสมที่สุดสำหรับการจำแนกสุขภาพของป่าชายเลนเพื่อพัฒนาอัลกอริทึม 3 รูปแบบ ได้แก่ Random Forest (RF), Support Vector Machine (SVM) และ Extreme Gradient Boosting (XGBoost) งานวิจัยนี้พัฒนาอัลกอริทึมเพื่อประมวลผลข้อมูลภาพถ่ายที่ได้จาก DJI P4 Multispectral โดยมีเป้าหมายเพื่อจำแนกสุขภาพของป่าชายเลน และสนับสนุนการติดตามสภาพแวดล้อมของพื้นที่ป่าชายเลนในอนาคต การประเมินสุขภาพของป่าชายเลนด้วยวิธีการทางการสำรวจระยะไกลนี้ จะเป็นประโยชน์ต่อการวางแผนจัดการพื้นที่ เช่น พื้นที่น้ำท่วมหรือพื้นที่เกษตรที่อยู่รอบป่าชายเลน รวมถึงการติดตามการเปลี่ยนแปลงในพื้นที่ป่าชายเลน ซึ่งการทำนากุ้งถือเป็นกิจกรรม

ที่มีผลกระทบโดยตรงต่อสุขภาพของป่าชายเลน (Alatorre et al., 2016) ดังนั้น เพื่อให้เกิดความเข้าใจที่ลึกซึ้งถึงสุขภาพของป่าชายเลน และเพื่อให้การทำเกษตรกรรมรอบป่าชายเลนมีประสิทธิภาพมากขึ้น ลดผลกระทบต่อสิ่งแวดล้อม และสามารถติดตามการเปลี่ยนแปลงได้อย่างมีประสิทธิภาพ การนำเทคโนโลยีการสำรวจระยะไกลมาใช้ในการบริหารจัดการจึงมีความสำคัญอย่างยิ่งในการอนุรักษ์และฟื้นฟูป่าชายเลนในระยะยาว

1.2 วัตถุประสงค์

1.2.1 เพื่อคัดเลือกดัชนีพืชพรรณที่เหมาะสมสำหรับการจำแนกสุขภาพของป่าชายเลนจากข้อมูลภาพถ่ายทางอากาศ

1.2.2 เพื่อพัฒนาอัลกอริทึมในการติดตามสุขภาพของป่าชายเลนด้วยภาพถ่ายทางอากาศ

1.3 ขอบเขตของการวิจัย

1.3.1 ขอบเขตเชิงเนื้อหา

1) ข้อมูลภาพถ่ายทางอากาศที่ใช้ในการศึกษาครั้งนี้คือ ภาพถ่ายทางอากาศจาก DJI P4 Multispectral


2) การศึกษาครั้งนี้ ไม่คำนึงถึงชนิดพันธุ์ไม้ป่าชายเลน

3) การเก็บข้อมูลตัวอย่างครั้งนี้ ทำการเก็บข้อมูล ณ ตำแหน่งจุดศูนย์กลางของแปลง (10 x 10 เมตร) (Miao et al., 2024)

4) การลงพื้นที่เก็บข้อมูลภาคสนาม ใช้เครื่องมือวัดค่าการสะท้อนแสงเชิงสเปกตรัม (Spectroradiometer)

1.3.2 ขอบเขตเชิงพื้นที่


พื้นที่ศึกษาครั้งนี้คือ พื้นที่จังหวัดภูเก็ต มีขนาดพื้นที่ 551.41 ตารางกิโลเมตร (รูปที่ 1.1)



รูปที่ 1.1 แผนที่พื้นที่ศึกษาจังหวัดภูเก็ต

1.4 กรอบแนวคิด

งานวิจัยนี้ใช้ข้อมูล 2 ส่วน ได้แก่ ข้อมูลภาพถ่ายทางอากาศ และข้อมูลภาคสนาม โดยข้อมูลภาคสนามประกอบด้วย (1) ข้อมูลระดับคุณภาพของป่าชายเลนที่ได้จากการวิเคราะห์ค่าการสะท้อนแสงเชิงสเปกตรัมของตัวอย่างใบไม้ และ (2) ข้อมูลภาพถ่ายเรณอยอดของป่าชายเลนจากอากาศยานไร้คนขับ ทั้งนี้ ข้อมูลดังกล่าวถูกนำเข้าสู่กระบวนการพัฒนาอัลกอริทึมด้วยวิธี ML (Machine Learning) เพื่อให้อัลกอริทึมเรียนรู้จากข้อมูลที่ป้อนเข้าไป และสามารถจำแนกคุณภาพของป่าชายเลนได้อย่างแม่นยำ โดยผลลัพธ์สุดท้ายถูกนำเสนอในรูปแบบแผนที่คุณภาพของป่าชายเลน (รูปที่ 1.2)



รูปที่ 1.2 กรอบแนวคิด

1.5 ประโยชน์ที่คาดว่าจะได้รับ

ข้อมูลที่ได้สามารถใช้เป็นแนวทางในการระบุพื้นที่ป่าชายเลนที่มีสุขภาพดีหรือไม่ดีได้อย่างชัดเจน ซึ่งจะเป็นประโยชน์ต่อหน่วยงานที่เกี่ยวข้อง เช่น กรมทรัพยากรทางทะเลและชายฝั่ง หรือ ศูนย์วิจัยและพัฒนาทรัพยากรป่าชายเลน ในการวางแผนและดำเนินการฟื้นฟูพื้นที่ป่าชายเลนได้อย่างตรงจุดและมีประสิทธิภาพ

1.6 ระยะเวลาทำงานวิจัย

ตารางที่ 1.1 ระยะเวลาทำการวิจัยและแผนการดำเนินงานตลอดโครงการวิจัย

กิจกรรม	ปีที่ 1		ปีที่ 2	
	เดือนที่	เดือนที่	เดือนที่	เดือนที่
	1-6	7-12	1-6	7-12
1. ทบทวนวรรณกรรม และงานวิจัยที่เกี่ยวข้อง	✓			
2. จัดทำโครงร่างวิทยานิพนธ์	✓			
3. ลงพื้นที่เก็บตัวอย่างข้อมูลการสะท้อนแสงของใบไม้ในป่าชายเลน		✓		
4. ประมวลผลภาพถ่ายทางอากาศ		✓		
5. พัฒนาอัลกอริทึมประเมินสุขภาพของป่าชายเลน		✓		
6. วิเคราะห์ความถูกต้อง			✓	
7. นำอัลกอริทึมไปติดตามสุขภาพของป่าชายเลนด้วยภาพถ่ายทางอากาศ			✓	✓

บทที่ 2

ทฤษฎีและเนื้อหาที่เกี่ยวข้อง

งานวิจัยนี้เกี่ยวข้องกับการนำเทคโนโลยีการสำรวจระยะไกล (Remote Sensing) และการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อประเมินสุขภาพของพืชในป่าชายเลนจากข้อมูลภาพถ่ายทางอากาศแบบหลายช่วงคลื่น (Multispectral) มีเนื้อหาดังต่อไปนี้

2.1 ป่าชายเลน (Mangrove)

2.1.1 ความหมายและลักษณะของป่าชายเลน

ป่าชายเลน (Mangrove) คือ กลุ่มสังคมพืชซึ่งประกอบด้วยพรรณไม้หลากหลายชนิดที่มีลักษณะใบเขียวตลอดปี (Evergreen Species) (ดูรูปที่ 2.1) มักมีความต้องการทางนิเวศวิทยาที่ใกล้เคียงกัน ประกอบด้วยพันธุ์ไม้ที่สำคัญ ได้แก่ ไม้สกุลโกงกาง (*Rhizophora spp.*), ประดู่ทะเล (*Acrostichum aureum*), ปอทะเล (*Hibiscus tiliaceus*), ตะบูนขาว (*Xylocarpus granatum*) เป็นต้น และประกอบด้วยสัตว์หลากหลายชนิด ได้แก่ กุ้งกุลาดำ (*Penaeus monodon*), ปูก้ามดาบ (*Fiddler Crab*), ปูทะเล (*Scylla serrata*) เป็นต้น ซึ่งดำรงชีวิตร่วมกันภายใต้สภาพแวดล้อมที่เป็นดินเลนน้ำกร่อย และมีน้ำทะเลท่วมถึงอย่างสม่ำเสมอ ลักษณะดินป่าชายเลนในจังหวัดภูเก็ตมีความลึกประมาณ 40 เซนติเมตร ส่วนมากเป็นดินเหนียวปนทราย (Sandy Clay) ดินเหนียว (Clay) และดินทราย (Sand) เนื้อดินบางส่วนเป็นดินที่มีเนื้อละเอียดมากแต่บางส่วนมีเนื้อค่อนข้างหยาบส่วนมากมีกลิ่นของซากพืช ซากสัตว์ (กรมทรัพยากรทางทะเลและชายฝั่ง, 2562)



รูปที่ 2.1 ป่าชายเลน

2.1.2 ความสำคัญของป่าชายเลน

ป่าชายเลนมีความสำคัญต่อมนุษย์ทั้งทางด้านเศรษฐกิจ สังคม และนิเวศวิทยา ได้แก่ คุณค่าทางด้านเศรษฐกิจ ในด้านป่าไม้ นำมาใช้เพื่อการเผาถ่านยังสามารถใช้เพื่อเป็นไม้ฟืน ไม้เสาเข็ม และด้านการประมง เป็นแหล่งอาหารให้กับมนุษย์ คุณค่าด้านระบบนิเวศ เป็นแหล่งที่อยู่อาศัยของ สัตว์น้ำ เป็นที่ป้องกันชายฝั่งทะเล โดยป่าชายเลนทำหน้าที่เสมือนเขื่อนป้องกันคลื่นลมพายุไม่ให้เกิด อันตรายต่อมนุษย์และทำหน้าที่เป็นแหล่งกักตะกอนสิ่งปฏิกูลและสารมลพิษต่าง ๆ จากบนบกไม่ให้ ลงสู่ทะเล เป็นต้น และคุณค่าด้านสังคม เป็นแหล่งพักผ่อนหย่อนใจ และแหล่งศึกษาทางธรรมชาติ สุขภาพของระบบนิเวศป่าชายเลนสามารถใช้เป็นตัวบ่งชี้คุณภาพของสิ่งแวดล้อมโดยรอบได้อย่างมีประสิทธิภาพ โดยเฉพาะในด้านคุณภาพของดินและน้ำ ซึ่งเป็นปัจจัยสำคัญที่ส่งผลต่อความหลากหลายทางชีวภาพและความสมบูรณ์ของทรัพยากรพันธุ์พืชและสัตว์ในพื้นที่ป่าชายเลน ดังนี้

1) คุณภาพของดิน สามารถใช้เป็นตัวชี้วัดเพื่อประเมินคุณภาพของดิน ซึ่งวัดได้จาก ความเค็ม ความเป็นกรด-ด่างในดิน และปริมาณอินทรีย์วัตถุ ซึ่งมีผลต่อการเจริญเติบโตและความหลากหลายของพืชป่าชายเลน (Ahmed et al., 2022) ปริมาณอินทรีย์วัตถุในดินมีบทบาทสำคัญในการรักษาโครงสร้างของดิน การดูดซับน้ำ และการเก็บรักษาธาตุอาหารที่จำเป็นต่อพืช (Jimenez et al., 2021) ค่าความเป็นกรด-ด่างของดินที่เหมาะสมสำหรับการฟื้นฟูและการดำรงอยู่ของป่าชายเลน อยู่ในช่วง pH 6.5 ถึง 7.5 ขณะที่ค่าความเค็ม ในช่วง 11.99 ถึง 20.92 mS/cm ถือว่ามีผลต่อโครงสร้างพืชและการดูดซับธาตุอาหารของพืชป่าชายเลนอย่างมีนัยสำคัญ (Jeyanny et al., 2018)

2) คุณภาพของน้ำ สามารถใช้เป็นตัวชี้วัดเพื่อประเมินคุณภาพของน้ำ ซึ่งวัดได้จาก ความเค็ม ความเป็นกรด-ด่างในน้ำ (pH) และปริมาณออกซิเจนละลายน้ำ (DO) โดยความเค็มของน้ำ

ทะเลอยู่ในช่วง 22–25 ppt ขณะที่ค่า pH อยู่ในช่วง 6.68–6.92 ซึ่งเป็นค่าที่เหมาะสมต่อการเจริญเติบโตของพืชป่าชายเลน และค่า DO อยู่ในช่วง 5.4–6.8 mg/L ซึ่งเป็นระดับที่เพียงพอต่อการดำรงชีวิตของสิ่งมีชีวิตในน้ำและส่งเสริมกระบวนการย่อยสลายอินทรีย์วัตถุในระบบนิเวศ (Yoswaty et al., 2024)

3) คุณภาพของพันธุ์ไม้ สามารถบ่งบอกได้ว่าพันธุ์ไม้ในป่าชายเลนมีคุณภาพในระดับที่เหมาะสมหรือเสื่อมโทรม ดูได้จากลักษณะการเจริญเติบโตของพันธุ์ไม้ และความหลากหลายทางชีวภาพของพันธุ์ไม้ในป่าชายเลน เจริญเติบโตในดินที่เป็นดินเลนมีทรายผสมและเป็นที่น้ำทะเลท่วมถึงเป็นประจำพันธุ์ไม้ชอบขึ้นอยู่ตามริมน้ำซึ่งเป็นดินเลนหนาสำหรับบริเวณที่มีป่าชายเลนถูกถางและทำลายจะพบพวกปรังทะเลขึ้นอยู่อย่างหนาแน่น และสามารถนำไปสู่ความสมบูรณ์ของแหล่งอาหารทั้งสารอาหาร ปริมาณอินทรีย์สาร ปริมาณแพลงก์ตอนพืช และแพลงก์ตอนสัตว์ (สุรชาติ เพชรแก้ว และคณะ, 2542)

4) คุณภาพของสัตว์ สามารถบ่งบอกได้ว่าสัตว์ในบริเวณป่าชายเลนทั้งสัตว์น้ำ สัตว์บก และสัตว์หน้าดิน มีคุณภาพในระดับที่เหมาะสมหรือเสื่อมโทรม ดูได้จากการที่มีสัตว์เข้ามาอยู่อาศัยในบริเวณพื้นที่ป่าชายเลน ความหลากหลายของสัตว์ในป่าชายเลน ซึ่งสิ่งมีชีวิตเหล่านี้ต่างมีบทบาทในการสร้างสมดุลให้แก่ระบบนิเวศป่าชายเลน (ชัยสิทธิ์ ตระกูลศิริพาณิชย์, 2542)

2.2 การรับรู้ระยะไกล (Remote sensing)

2.2.1 ความหมายของการรับรู้ระยะไกล

การรับรู้ระยะไกล (Remote Sensing) เป็นเทคโนโลยีที่ใช้สำหรับตรวจสอบและเก็บรวบรวมข้อมูลเกี่ยวกับวัตถุหรือปรากฏการณ์บนพื้นผิวโลก โดยไม่จำเป็นต้องสัมผัสวัตถุโดยตรง ผ่านการวัดพลังงานแม่เหล็กไฟฟ้าที่สะท้อนหรือแผ่ออกจากวัตถุเป้าหมายเข้าสู่เซนเซอร์ที่ติดตั้งอยู่บนอากาศยานหรือดาวเทียม เทคโนโลยีนี้ถูกนำมาใช้ครั้งแรกในประเทศสหรัฐอเมริกาเมื่อปี พ.ศ. 2503 และได้พัฒนาอย่างต่อเนื่องจนสามารถประยุกต์ใช้งานได้ในระดับพื้นที่ที่กว้างขึ้น หลังการปล่อยดาวเทียม Landsat-1 เมื่อปี พ.ศ. 2515 เพื่อรองรับการศึกษาทางทรัพยากรธรรมชาติ

ข้อมูลที่ได้จากระบบการรับรู้ระยะไกลสามารถนำมาใช้ในการวิเคราะห์และแปลความหมายของลักษณะวัตถุหรือสภาพแวดล้อมต่าง ๆ ได้อย่างมีประสิทธิภาพ โดยพิจารณาจากคุณลักษณะของการสะท้อนหรือการแผ่รังสีของคลื่นแม่เหล็กไฟฟ้า ข้อมูลจากการรับรู้ระยะไกลประกอบด้วยองค์ประกอบสำคัญ 3 ประการ ได้แก่ 1. ช่วงคลื่น (Spectral) ซึ่งแสดงลักษณะการ

ตอบสนองของวัตถุต่อความยาวคลื่นที่แตกต่างกัน 2. ช่วงเวลา (Temporal) ซึ่งแสดงการเปลี่ยนแปลงของวัตถุในช่วงเวลาต่าง ๆ และ 3. คุณลักษณะเชิงพื้นที่และรังสี (Spatial and Radiometric) แสดงถึงตำแหน่งเชิงพื้นที่และความเข้มของพลังงานที่บันทึกได้

ข้อมูลจากการรับรู้ระยะไกลสามารถจำแนกได้เป็น 2 ประเภทหลัก ได้แก่ ข้อมูลภาพถ่ายทางอากาศ (Aerial Photograph) ซึ่งได้จากอากาศยาน และข้อมูลภาพถ่ายจากดาวเทียม (Satellite Image) ซึ่งได้จากระบบรับรู้ระยะไกลที่โคจรผ่านชั้นบรรยากาศโลก โดยข้อมูลทั้งสองประเภทนี้มีบทบาทสำคัญในการสำรวจ วิเคราะห์ และประเมินสภาพภูมิประเทศและสิ่งแวดล้อมในระดับพื้นที่ขนาดใหญ่ องค์ประกอบที่สำคัญของการสำรวจข้อมูลระยะไกล คือ คลื่นแสง ซึ่งเป็นพลังงานแม่เหล็กไฟฟ้าที่เกิดขึ้นเองตามธรรมชาติไม่ว่าเป็นพลังงานที่ได้จากดวงอาทิตย์หรือเป็นพลังงานจากตัวเอง ซึ่งระบบการสำรวจข้อมูลระยะไกลมี 2 แบบ ดังนี้ (วิโรจน์ ละอองมณี และคณะ, 2565)

1) ระบบการสำรวจโดยอาศัยพลังงานแสงธรรมชาติ (Passive Remote Sensing)

เป็นระบบที่มีการใช้งานอย่างแพร่หลายตั้งแต่ช่วงเริ่มต้นจนถึงปัจจุบัน โดยอาศัยพลังงานจากธรรมชาติ โดยเฉพาะพลังงานแสงอาทิตย์ซึ่งเป็นแหล่งกำเนิดหลัก ระบบนี้สามารถรับและจัดเก็บข้อมูลได้ในช่วงเวลากลางวันเป็นส่วนใหญ่ แต่มีข้อจำกัดจากสภาพอากาศ เช่น ฤดูฝน หรือกรณีที่มีเมฆ หมอก หรือฝนตก ซึ่งส่งผลต่อความสามารถในการบันทึกข้อมูลอย่างมีประสิทธิภาพ

2) ระบบการสำรวจโดยพลังงานที่สร้างขึ้นเอง (Active Remote Sensing)

เป็นระบบที่พลังงานถูกสร้างขึ้นภายในตัวอุปกรณ์สำรวจเอง เช่น การใช้คลื่นไมโครเวฟจากระบบเรดาร์ซึ่งทำหน้าที่ส่งสัญญาณไปยังพื้นที่เป้าหมาย ก่อนจะตรวจวัดพลังงานที่สะท้อนกลับมา ระบบลักษณะนี้สามารถดำเนินการรับและจัดเก็บข้อมูลได้อย่างต่อเนื่องโดยไม่จำกัดเวลาและสภาพอากาศ กล่าวคือ สามารถใช้งานได้ทั้งในเวลากลางวันและกลางคืน รวมถึงสามารถเจาะผ่านกลุ่มเมฆ หมอก และฝนได้ในทุกฤดูกาล

2.2.2 ประโยชน์ของการรับรู้ระยะไกล

การรับรู้ระยะไกลเป็นกระบวนการจัดเก็บข้อมูลจากระยะไกลผ่านเซนเซอร์ที่ติดตั้งบนดาวเทียมหรืออากาศยาน ซึ่งช่วยให้สามารถได้มาซึ่งข้อมูลที่ครอบคลุมพื้นที่ขนาดใหญ่ภายในระยะเวลาสั้น และสามารถนำข้อมูลดังกล่าวไปใช้ในการวิเคราะห์ปรากฏการณ์ทางสิ่งแวดล้อมและภูมิประเทศได้อย่างมีประสิทธิภาพ ข้อมูลจากการรับรู้ระยะไกลจึงมีความสำคัญและสามารถนำไปประยุกต์ใช้งานได้หลากหลายสาขา เช่น ด้านป่าไม้ การเกษตร การใช้ที่ดิน ธรณีวิทยาและธรณีสัณฐาน อุทกวิทยา สมุทรศาสตร์ ภัยพิบัติธรรมชาติ การวางผังเมือง การประมง สิ่งแวดล้อม และการทำแผนที่ เป็นต้น (ณัฐพร ยวงเงิน, 2559)

2.2.3 คุณสมบัติของอากาศยานไร้คนขับ DJI P4 Multispectral

DJI P4 Multispectral เป็นอากาศยานไร้คนขับที่ออกแบบมาเพื่อการเก็บข้อมูลภาพถ่ายเชิงหลายช่วงคลื่นอย่างแม่นยำ โดรนรุ่นนี้ติดตั้งกล้องหกตัวที่ใช้เซนเซอร์ CMOS ขนาด 1/2.9 นิ้ว รองรับการบินที่ทั้งภาพสีและภาพในแถบคลื่นเฉพาะ โดยมีระบบ OCUSYNC™ สำหรับถ่ายทอดภาพความละเอียดสูงอย่างเสถียร การใช้งานร่วมกับซอฟต์แวร์ DJI GS Pro ช่วยให้ผู้ใช้สามารถวางแผนการบินและรวบรวมข้อมูลเชิงพื้นที่ได้อย่างมีประสิทธิภาพ ข้อมูลภาพที่ได้สามารถนำไปวิเคราะห์ค่าดัชนีชีพีพรรณ เช่น NDVI, GNDVI และ NDRE ได้แบบเรียลไทม์ เพื่อวิเคราะห์สุขภาพพืช การเจริญเติบโต และสภาพดินอย่างมีประสิทธิภาพ ข้อมูลภาพที่ได้ยังสามารถนำไปสร้างแผนที่ดัชนีเชิงพื้นที่ เพื่อสนับสนุนการจัดการเกษตรกรรมที่แม่นยำ โดรนยังมาพร้อมกับระบบ DJI Onboard D-RTK™ ซึ่งให้ความแม่นยำในการระบุตำแหน่งในระดับเซนติเมตร รายละเอียดแสดงไว้ในตารางที่ 2.1 (DJI, 2020; DJI Agriculture, n.d.)



รูปที่ 2.2 อากาศยานไร้คนขับ รุ่น DJI P4 Multispectral

ตารางที่ 2.1 รายละเอียดของอากาศยานไร้คนขับ DJI P4 Multispectral

รายการ	รายละเอียด
ชื่ออุปกรณ์	DJI P4 Multispectral
ระบบกล้อง	กล้อง 6 ตัว (1 RGB + 5 multispectral: Blue, Green, Red, Red Edge, NIR)
เซนเซอร์	CMOS ขนาด 1/2.9 นิ้ว (6 ตัวแยกตามช่วงคลื่น)
ความละเอียดกล้อง	2 ล้านพิกเซล (กล้อง Multispectral), 20 ล้านพิกเซล (กล้อง RGB)
ความยาวโฟกัส	5.74 mm
ระบบ RTK	DJI Onboard D-RTK™ + รองรับ D-RTK 2 Mobile Station และ NTRIP
ระบบส่งข้อมูล	OcuSync™ HD transmission
เวลาบินสูงสุด	~27 นาที
แบตเตอรี่	LiPo 4S, ความจุ 5870 mAh
การแสดงผล VI	แสดงผล NDVI / GNDVI / NDRE แบบ Real-time บนแอป DJI GS Pro

ตารางที่ 2.2 คุณสมบัติและช่วงคลื่นของอากาศยานไร้คนขับ DJI P4 Multispectral

ชื่อแบนด์	ความยาวคลื่นกลาง (nm)	ความกว้างของแถบ (± nm)
Band 1 – Blue	450	±16
Band 2 – Green	560	±16
Band 3 – Red	650	±16
Band 4 – Red Edge	730	±16
Band 5 – Near Infrared (NIR)	840	±26
Band 6 – RGB**	-	-

**หมายเหตุ: ภาพถ่ายผสมสีจริง

2.2.4 การรับรู้ระยะไกลกับสุขภาพพืชพรรณ

แสงจากดวงอาทิตย์ที่ส่องมายังโลกประกอบด้วยคลื่นแม่เหล็กไฟฟ้าในช่วงต่าง ๆ ที่ช่วงที่ตามนุษย์มองเห็นได้ (Visible) เช่น สีแดง สีเขียว สีน้ำเงิน และช่วงคลื่นที่ตามองไม่เห็น เช่น คลื่นอินฟราเรด (Infrared) เมื่อแสงตกกระทบวัตถุ เช่น พืช แสงบางส่วนจะถูกดูดกลืน ขณะที่บางส่วนจะสะท้อนกลับ ซึ่งการสะท้อนแสงในช่วงความยาวคลื่นต่าง ๆ นี้สามารถนำมาใช้ในการวิเคราะห์สุขภาพของพืชพรรณได้ โดยทั่วไป พืชที่มีสุขภาพดีจะดูดกลืนแสงในช่วงคลื่นสีแดง (Red) ได้มาก และสะท้อนแสงในช่วงคลื่นอินฟราเรดใกล้ (Near Infrared; NIR) ได้มากเช่นกัน ในทางกลับกัน พืชที่มีสุขภาพแย่จะสะท้อนแสงสีแดงต่ำ และสะท้อนแสง NIR น้อยลงกว่าปกติ (Williams and Tech, 2014; Gogoi et al., 2018) (รูปที่ 2.3)

หลักการดังกล่าวถูกนำมาใช้ในการประยุกต์ใช้งานกับภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ DJI P4 Multispectral ซึ่งสามารถบันทึกข้อมูลภาพจากเซนเซอร์หลายช่วงคลื่นแม่เหล็กไฟฟ้า จนนำมาประมวลเป็นดัชนีพืชพรรณเพื่อประเมินคุณภาพของพืชพรรณ น้ำ และดิน ได้อย่างมีประสิทธิภาพ มีหลักการสังเคราะห์ดังนี้

1) การสะท้อนแสงของพืชพรรณ

ในช่วงคลื่นของแสงที่ตามองเห็นได้ (0.4–0.7 ไมโครเมตร) พืชสีเขียวมีค่าการสะท้อนแสงต่ำ เนื่องจากคลอโรฟิลล์ในใบไม้ดูดกลืนพลังงานแสงได้ดี โดยเฉพาะที่ความยาวคลื่น 0.45 ไมโครเมตร (สีน้ำเงิน) และ 0.65 ไมโครเมตร (สีแดง) ส่วนความยาวคลื่นที่มีการสะท้อนมากที่สุดคือ 0.54 ไมโครเมตร (สีเขียว) พืชที่มีสุขภาพดีจึงปรากฏเป็นสีเขียวจากปริมาณคลอโรฟิลล์ที่สูง ในขณะที่พืชที่มีสุขภาพไม่ดีมีการดูดกลืนน้อยลงและสะท้อนแสงสีแดงมากขึ้น ส่งผลให้เห็นเป็นสีเหลืองจากการรวมกันของสีเขียวและสีแดง พืชที่สมบูรณ์มีการสะท้อนต่ำในช่วงคลื่นสีน้ำเงินและสีแดงเนื่องจากการรวมกันของสีเขียวและสีแดง พืชที่สมบูรณ์มีการสะท้อนต่ำในช่วงคลื่นสีน้ำเงินและสีแดงเนื่องจากการรวมกันของสีเขียวและสีแดง พืชที่สมบูรณ์มีการสะท้อนต่ำในช่วงคลื่นสีน้ำเงินและสีแดงเนื่องจากการรวมกันของสีเขียวและสีแดง พืชที่สมบูรณ์มีการสะท้อนต่ำในช่วงคลื่นสีน้ำเงินและสีแดงเนื่องจากการรวมกันของสีเขียวและสีแดง พืชที่สมบูรณ์มีการสะท้อนต่ำในช่วงคลื่นสีน้ำเงินและสีแดงเนื่องจากการรวมกันของสีเขียวและสีแดง


2) การสะท้อนแสงของน้ำ

น้ำ เป็นสารที่สามารถดูดกลืนพลังงานแม่เหล็กไฟฟ้าได้ดีในช่วงความยาวคลื่นต่าง ๆ ส่งผลให้ลายเซ็นเชิงคลื่น (Spectral Signature) ของน้ำมีการสะท้อนแสงในระดับต่ำ (ดังรูปที่ 2.4) ช่วงคลื่นที่น้ำมีการสะท้อนแสงเห็นได้ชัดเจนคือ 0.4 ถึง 0.75 ไมโครเมตร การสะท้อนแสงของน้ำสูงที่สุดที่ปลายช่วงคลื่นสีน้ำเงินประมาณ 0.57 ไมโครเมตร และลดลงตามความยาวคลื่นที่เพิ่มขึ้น และการสะท้อนแสงของน้ำขึ้นอยู่กับธรรมชาติของน้ำ กรณีที่แหล่งน้ำมีสิ่งเจือปนหรือสารแขวนลอย

ต่าง ๆ เช่น ตะกอน สารเคมี จะมีผลทำให้สีของน้ำเปลี่ยนไปหรือน้ำขุ่น จึงมีการสะท้อนพลังงานปลายช่วงคลื่นสีแดง ดังนั้น น้ำขุ่นจึงปรากฏเป็นสีน้ำตาล (SEOS, 2020)


3) การสะท้อนแสงของดิน

การสะท้อนแสงของดินมีสองลักษณะ คือ การดูดกลืนและการสะท้อน (ดังรูปที่ 2.4) โดยไม่มีการส่งผ่านแสง ลายเซ็นต์เชิงสเปกตรัม (Spectral Signature) ของดินมีแนวโน้มเปลี่ยนแปลงตามค่าความชื้นในดิน โดยเฉพาะในช่วงคลื่นอินฟราเรดใกล้ ซึ่งมีการสะท้อนสูงขึ้นเมื่อความชื้นลดลง และอาจมีค่าการสะท้อนใกล้เคียงกับพืชสีเขียวในสภาวะที่ดินแห้ง ทั้งนี้ ค่าการสะท้อนแสงของดินยังขึ้นอยู่กับองค์ประกอบหลายประการ เช่น ปริมาณความชื้น อินทรีย์วัตถุ และปริมาณออกไซด์ภายในดิน ลักษณะเนื้อดินมีผลต่อปริมาณน้ำ โดยดินทรายหยาบที่มีการระบายน้ำดีมีแนวโน้มสะท้อนแสงได้มาก ในขณะที่ดินเนื้อละเอียดมีการระบายน้ำต่ำจึงสะท้อนได้น้อย ดินที่มีอินทรีย์วัตถุสูง มักมีสีคล้ำและดูดกลืนพลังงานได้มากในช่วงคลื่นที่ตามองเห็น เช่นเดียวกับดินที่มีปริมาณออกไซด์สูง ซึ่งปรากฏเป็นสีเข้มจากค่าการสะท้อนที่ลดลง นอกจากนี้ ผิวหน้าดินที่มีลักษณะขรุขระมากยังส่งผลให้การสะท้อนแสงลดลง (SEOS, 2020)



รูปที่ 2.3 การสะท้อนแสงของพืชที่ตาย มีความเครียด และสุขภาพดี

(ที่มา: <https://storymaps.arcgis.com/stories/91e794af4ce44a4685e6340d5480e70c>)



รูปที่ 2.4 การสะท้อนแสงของพืชพรรณ ดิน และน้ำ

(ที่มา: <https://seos-project.eu/classification/classification-c01-p05.html>)

2.2.5 ดัชนีพืชพรรณ (Vegetation indices)

คือการคำนวณโดยใช้ข้อมูลการสะท้อนแสงจากช่วงคลื่นที่สัมพันธ์กับพืชพรรณมาสร้างเป็นอัตราส่วน เพื่อจำแนกพื้นที่ที่มีการปกคลุมของพืชพรรณออกจากพื้นที่ที่ไม่มีพืชพรรณ ทั้งนี้ดัชนีพืชพรรณสามารถใช้ติดตามการเปลี่ยนแปลงของชีวมวลพืชและภาวะสิ่งแวดล้อมในพื้นที่ศึกษาได้อย่างมีประสิทธิภาพ (พิชิตพร ผลเกิดดี, 2562) ช่วงคลื่นสีแดง (Red) และ สีเขียว (Green) ซึ่งสะท้อนคุณสมบัติการดูดกลืนพลังงานโดยคลอโรฟิลล์ในใบพืช ช่วงคลื่นอินฟราเรดใกล้ (Near-Infrared: NIR) ซึ่งสามารถแยกแยะพืชพรรณจากพื้นผิวที่ไม่ใช่พืชได้อย่างมีประสิทธิภาพ (Zhang et al., 2014) และช่วงคลื่นขอบแดง (Red-edge) ซึ่งเป็นช่วงรอยต่อระหว่างช่วงคลื่นสีแดง (Red) และช่วงคลื่นอินฟราเรดใกล้ (NIR) บ่งชี้ถึงการเปลี่ยนแปลงจากการดูดกลืนแสงสีแดงโดยคลอโรฟิลล์ ไปสู่การกระเจิงของแสงในย่าน NIR ที่เกิดจากโครงสร้างภายในของใบพืช Red-edge มักใช้ในการวิเคราะห์สภาวะทางสรีรวิทยาของพืช เช่น ความเครียด ความเขียว และสุขภาพโดยรวม ซึ่งโดยทั่วไปต้องอาศัยข้อมูลจากระบบถ่ายภาพสเปกตรัมความละเอียดสูง (Hyperspectral) หรือข้อมูลจากเซนเซอร์ที่สามารถตรวจวัดแถบคลื่น Red-edge ได้ เช่น Sentinel-2 หรือ ระบบกล้อง Multispectral บนโดรน (Tran, Reef, and Zhu, 2022) โดยงานวิจัยนี้ทำการใช้ดัชนีพืชพรรณในการประเมินสุขภาพทางสิ่งแวดล้อมต่าง ๆ ของป่าชายเลน ดังนี้

1) ดัชนีพืชพรรณผลต่างแบบนอร์มัลไลซ์ (Normalized Difference Vegetation Index: NDVI) เป็นเทคนิคแบบง่ายสำหรับใช้เพื่อสกัดสารสนเทศเชิงปริมาณของปริมาณพืชพรรณ

หรือความเป็นสีเขียวในแต่ละจุดภาพของข้อมูลภาพ โดยนำช่วงคลื่นอินฟราเรดใกล้ (NIR) และช่วงคลื่นสีแดง (Red) มาทำสัดส่วนกัน มีค่าอยู่ระหว่าง -1 ถึง 1 ดังสมการที่ 2.1 (รฐนนท์ จันทรอินทร์ และคณะ, 2560)

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (\text{สมการที่ 2.1})$$

NDVI	=	Normalized Difference Vegetation Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง

2) ดัชนีพืชพรรณผลต่างความชื้น (Normalized Difference Water Index: NDWI) เป็นดัชนีที่ใช้ในการตรวจสอบระดับความชื้นในดินหรือพืชพรรณ สามารถแยกน้ำออกจากพืชพรรณ และดินที่มีการสะท้อนพลังงานในช่วงคลื่นอินฟราเรดใกล้ (NIR) ที่สูง มีค่าอยู่ระหว่าง -1 ถึง 1 ดังสมการที่ 2.2 (ไชยฤทธิ์ เสวตวงษ์ และพิพรรณ เรืองแสง, 2564)

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (\text{สมการที่ 2.2})$$

NDWI	=	Normalized Difference Water Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว

3) ดัชนีความแตกต่างพืชพรรณด้วยช่วงคลื่นสีเขียว (Green Normalized Difference Vegetation Index: GNDVI) เป็นดัชนีที่ใช้ในการประเมินความหนาแน่น และคุณภาพของพืชพรรณโดยรวม โดยหาค่าผลต่างการสะท้อนพืชพรรณ ที่ได้จากการสะท้อนแสงจากคลอโรฟิลล์ในใบของพืช มีค่าอยู่ระหว่าง -1 ถึง 1 ดังสมการที่ 2.3 (นิติศักดิ์ เจริญรูป และคณะ, 2565)

$$GNDVI = \frac{NIR - Green}{NIR + Green} \quad (\text{สมการที่ 2.3})$$

GNDVI	=	Green Normalized Difference Vegetation Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว

4) ดัชนีพืชพรรณปรับแก้ดิน (Soil-adjusted Vegetation Index: SAVI) เป็นดัชนีที่ได้รับการพัฒนาเพื่อแก้ปัญหการสะท้อนแสงจากดิน สามารถช่วยในการวิเคราะห์การเจริญเติบโตของพืชพรรณ และสามารถแยกพืชที่เติบโตในพื้นที่ที่มีความแตกต่างกันในสภาพดิน มีค่าอยู่ระหว่าง -1 ถึง 1 ดังสมการที่ 2.4 (เปรมศิริ คงแสง, 2560)

$$SAVI = \frac{NIR-Red}{NIR+Red+L} * (1 + L) \quad (\text{สมการที่ 2.4})$$

SAVI	=	Soil-adjusted Vegetation Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
L	=	ค่าการปกคลุมของพืช ส่วนใหญ่มักกำหนดให้เป็น 0.5 สำหรับพื้นที่ที่มีพืชปกคลุม

5) ดัชนีเน้นภาพพืชพรรณ (Enhanced Vegetation Index: EVI) เป็นสูตรที่ได้รับการพัฒนาขึ้นเพื่อให้สามารถประเมินลักษณะการสะท้อนพลังงานแสงของพืชพรรณได้อย่างเหมาะสม ทั้งยังสามารถลดผลกระทบจากการสะท้อนของพื้นดินและอิทธิพลของชั้นบรรยากาศต่อข้อมูลจากดาวเทียมแต่ละดวงได้อย่างมีประสิทธิภาพ ดัชนีนี้แสดงการตอบสนองที่ไวต่อการเปลี่ยนแปลงของพืชในบริเวณที่มีมวลชีวภาพหนาแน่น และสามารถนำมาใช้เพื่อปรับปรุงการแปลผลภาพถ่ายจากดาวเทียมในช่วงคลื่นที่เกี่ยวข้องกับการสะท้อนของพืช ดังสมการที่ 2.5 (Huete et al., 2002)

$$EVI = G * \frac{NIR-Red}{(NIR+(C1*Red))-((C2*Blue)+L)} \quad (\text{สมการที่ 2.5})$$

EVI	=	Enhanced Vegetation Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Blue	=	ค่าการสะท้อนในช่วงคลื่นสีน้ำเงิน
G	=	ค่าระดับพลังงาน (Grain Factor) มีค่า = 2.5
C ₁ , C ₂	=	ค่าสัมประสิทธิ์สำหรับค่าฝุ่นละอองในบรรยากาศ โดยที่ C ₁ = 6 และ C ₂ = 7.5
L	=	ค่าปรับแก้สำหรับดินการกำหนดค่าสำหรับพื้นที่ มีค่า = 1

6) ดัชนีความแตกต่างแบบปกติของแถบคลื่นขอบแดง (Normalized Difference Red Edge Index: NDRE) ใช้หลักการคล้าย NDVI แต่แทนแถบคลื่นสีแดงด้วยแถบ Red-edge ซึ่งช่วยลดปัญหาค่าดัชนีอิ่มตัวในพื้นที่ที่มีพืชพรรณหนาแน่น โดยเฉพาะในระยะกลางถึงปลายของการเจริญเติบโต NDRE จึงเหมาะสำหรับการประเมินสถานะไนโตรเจนและสุขภาพพืช ดังสมการที่ 2.6 (Rehman, Lundy, and Linquist, 2022)

$$NDRE = \frac{NIR - R_{edge}}{NIR + R_{edge}} \quad (\text{สมการที่ 2.6})$$

NDRE	=	Normalized Difference Red Edge Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
R _{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง

7) ดัชนีความแตกต่างแบบปกติ (Normalized Difference Indices: NDI) มักใช้ค่าเกณฑ์ของ NDI เพื่อวิเคราะห์พื้นที่ผิวที่เฉพาะเจาะจง เช่น พืชพรรณ ดิน น้ำ หรือพื้นที่สิ่งปลูกสร้าง หรือใช้เป็นขั้นตอนเบื้องต้นสำหรับการวิเคราะห์ในอนาคต (Chen et al., 2021) และถูกใช้ในการศึกษาปริมาณคลอโรฟิลล์หรือชีวมวลพืช ดังสมการที่ 2.7 (Tran, Reef, and Zhu, 2022)

$$NDI = \frac{R_{edge} - Red}{R_{edge} + Red} \quad (\text{สมการที่ 2.7})$$

NDI	=	Normalized Difference Indices
R _{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง

8) อัตราการดูดกลืนคลอโรฟิลล์ที่เปลี่ยนรูป (Transformed chlorophyll absorption ratio: TCARI) เป็นดัชนีที่ช่วยเพิ่มความแม่นยำในการประเมินปริมาณคลอโรฟิลล์ให้ ดังสมการที่ 2.8 (Vidican et al., 2023)

$$TCARI = 3 \times \left\{ [(R_{edge} - Red) - 0.2(R_{edge} - Green)] \times \frac{R_{edge}}{Red} \right\} \quad (\text{สมการที่ 2.8})$$

TCARI	=	Transformed chlorophyll absorption ratio
R_{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว

9) ดัชนีคลอโรฟิลล์ขอบแดง (Red Edge Chlorophyll Index: RECI) เป็นดัชนีที่ใช้บ่งชี้ระดับกิจกรรมการสังเคราะห์แสงของพืชในชั้นเรือนยอด โดยมีประโยชน์อย่างยิ่งในการตรวจสอบพื้นที่ที่มีใบไม้เปลี่ยนเป็นสีเหลืองหรือมีการร่วงหล่น ซึ่งมักสะท้อนถึงความเครียดหรือการเสื่อมโทรมของพืชพรรณ ดังสมการที่ 2.9 (Vidican et al., 2023)

$$RECI = (NIR - R_{edge}) - 1 \quad (\text{สมการที่ 2.9})$$

RECI	=	Red Edge Chlorophyll Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
R_{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง

10) ดัชนีปริมาณคลอโรฟิลล์ของเรือนยอด (Canopy Chlorophyll Content Index: CCCI) เป็นดัชนีที่ใช้ประเมินความเข้มข้นของคลอโรฟิลล์ในพืชระดับเรือนยอด ซึ่งสามารถใช้เป็นตัวบ่งชี้ความเครียดของพืชที่เกิดจากโรคพืช ความบกพร่องของธาตุอาหาร และปัจจัยแวดล้อมต่าง ๆ โดยดัชนีนี้มีความไวต่อการเปลี่ยนแปลงทางสรีรวิทยาของพืช ทำให้เหมาะสำหรับการติดตามสุขภาพพืชในระดับพื้นที่อย่างแม่นยำ ดังสมการที่ 2.10 (Vidican et al., 2023)

$$CCCI = \left(\frac{NIR - R_{edge}}{NIR + R_{edge}} \right) \div \left(\frac{NIR - R}{NIR + R} \right) \quad (\text{สมการที่ 2.10})$$

CCCI	=	Canopy Chlorophyll Content Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
R_{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง

11) ดัชนีพิกัดสีเขียว (Green Chromatic Coordinate: GCC) เป็นดัชนีที่ใช้กันอย่างแพร่หลายในการประเมินระดับความเขียวของเรือนยอดพืช โดยอาศัยค่าความเข้มของแถบสีเขียวจาก

ภาพถ่าย RGB เมื่อเทียบกับความเข้มรวมของทั้งสามแถบสี (แดง เขียว และน้ำเงิน) ดัชนีนี้มีความสามารถในการลดผลกระทบจากการเปลี่ยนแปลงของแสงในแต่ละช่วงเวลา และสามารถสะท้อนการเปลี่ยนแปลงของพืชพรรณตามฤดูกาลได้อย่างแม่นยำ ดังสมการที่ 2.11 (Zhao and Qu, 2024)

$$GCC = \frac{Green}{Red+Green+Blue} \quad (\text{สมการที่ 2.11})$$

GCC	=	Green Chromatic Coordinate
Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Blue	=	ค่าการสะท้อนในช่วงคลื่นสีน้ำเงิน

12) ดัชนีความแตกต่างของพืชพรรณจากแสงที่ตามองเห็น (Visible-band Difference Vegetation Index: VDMI) เป็นดัชนีที่พัฒนาขึ้นบนพื้นฐานของดัชนี NDVI โดยออกแบบมาเพื่อใช้กับข้อมูลจากแถบคลื่นในช่วงแสงที่ตามองเห็น (Visible Spectrum) VDMI มีประสิทธิภาพสูงในการจำแนกพื้นที่ที่มีพืชพรรณออกจากพื้นที่ที่ไม่มีพืชพรรณ โดยค่าของดัชนีมีแนวโน้มแยกกลุ่มได้อย่างชัดเจนและไม่ซ้อนทับกันระหว่างสองประเภทดังกล่าว จึงเหมาะสมอย่างยิ่งสำหรับการสกัดข้อมูลพืชพรรณจากภาพถ่ายที่ได้จากอากาศยานไร้คนขับ (UAV) (Zhou et al., 2021) ดังสมการที่ 2.12 (Tran, Reef, and Zhu, 2022)

$$VDVI = \frac{2Green-Blue-Red}{2Green+Blue+Red} \quad (\text{สมการที่ 2.12})$$

VDVI	=	Visible-band Difference Vegetation Index
Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Blue	=	ค่าการสะท้อนในช่วงคลื่นสีน้ำเงิน

13) ดัชนีคลอโรฟิลล์บนพื้นดินของ MERIS (MERIS Terrestrial Chlorophyll Index: MTCI) ถูกพัฒนาขึ้นโดยอาศัยความสามารถของเซนเซอร์ในการเก็บข้อมูลสเปกตรัมในช่วงคลื่นขอบแดง (Red edge) เพื่อใช้ในการประมาณค่าปริมาณคลอโรฟิลล์ในชั้นเรือนยอดพืช ดัชนี MTCI มีความ

ไวสูงต่อช่วงความเข้มข้นของคลอโรฟิลล์ในระดับกว้าง จึงเหมาะสมอย่างยิ่งสำหรับการประเมินความแปรปรวนของคลอโรฟิลล์ในพืชพรรณที่มีลักษณะทางสรีรวิทยาแตกต่างกัน (Pastor-Guzman et al., 2020) ดังสมการที่ 2.13 (Tran, Reef, and Zhu, 2022)

$$MTCI = \frac{NIR - R_{edge}}{R_{edge} - Red} \quad (\text{สมการที่ 2.13})$$

MTCI	=	MERIS Terrestrial Chlorophyll Index
NIR	=	ค่าการสะท้อนในช่วงคลื่นอินฟราเรดใกล้
R _{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง

14) ดัชนีความเขียวส่วนเกิน (Excess Green Index: ExG) เป็นดัชนีเชิงเปรียบเทียบที่ได้รับการยอมรับว่ามีประสิทธิภาพสูงในการจำแนกพื้นที่พืชพรรณ เมื่อเทียบกับดัชนีอื่น ๆ ในช่วงคลื่นแสงที่ตามองเห็น (Visible Spectrum) โดย ExG สามารถเน้นความแตกต่างระหว่างพืชพรรณกับพื้นหลังได้อย่างชัดเจน จึงเป็นหนึ่งในดัชนีที่ได้รับความนิยมอย่างแพร่หลายในการวิเคราะห์ภาพถ่าย RGB โดยเฉพาะในงานที่เกี่ยวข้องกับการแยกพื้นที่สีเขียวจากภาพถ่ายทางอากาศ (Larrinaga and Brotons, 2019) ดังสมการที่ 2.14 (Tran, Reef, and Zhu, 2022)

$$ExG = 2Green - Red - Blue + 50 \quad (\text{สมการที่ 2.14})$$

ExG	=	Excess Green Index
Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Blue	=	ค่าการสะท้อนในช่วงคลื่นสีน้ำเงิน

15) ดัชนีการสะท้อนแสงของพืชในช่วงเสื่อมสภาพ (Plant Senescence Reflectance Index: PSRI) เป็นดัชนีที่พัฒนาขึ้นเพื่อใช้ในการประเมินกระบวนการชราภาพของใบไม้และผลไม้ โดยอิงจากอัตราส่วนของคลอโรฟิลล์ต่อแคโรทีนอยด์ ซึ่งเปลี่ยนแปลงอย่างชัดเจนในช่วงเริ่มต้นของการเสื่อมสภาพ เนื่องจากเม็ดสีทั้งสองมีอัตราการสลายตัวที่แตกต่างกัน ดัชนี PSRI จึงมีข้อได้เปรียบเหนือ NDVI ในการตรวจจับสถานะเสื่อมโทรมของพืช (Anderegg et al., 2020) ดังสมการที่ 2.15 (Tran, Reef, and Zhu, 2022)

$$PSRI = \frac{Red-Blue}{R_{edge}} \quad (\text{สมการที่ 2.15})$$

PSRI	=	Plant Senescence Reflectance Index
R_{edge}	=	ค่าการสะท้อนในช่วงขอบคลื่นสีแดง
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Blue	=	ค่าการสะท้อนในช่วงคลื่นสีน้ำเงิน

16) ดัชนีด้านทานผลกระทบจากชั้นบรรยากาศในช่วงแสงที่ตามองเห็น (Visible Atmospherically Resistant Index: VARI) เป็นดัชนีที่พัฒนาขึ้นเพื่อเน้นพื้นที่พืชพรรณโดยเฉพาะในภาพถ่ายช่วงคลื่นแสงที่ตามองเห็น (RGB) โดยมีจุดเด่นในการลดผลกระทบจากความแตกต่างของแสงและชั้นบรรยากาศ ทำให้เหมาะสำหรับการวิเคราะห์พืชพรรณจากภาพสีในสภาพแวดล้อมที่มีความแปรปรวนของแสง (Vélez, Martínez-Peña, and Castrillo, 2023) ดังสมการที่ 2.16 (Tran, Reef, and Zhu, 2022)

$$VARI = \frac{Green-Red}{Green+Red-Blue} \quad (\text{สมการที่ 2.16})$$


Green	=	ค่าการสะท้อนในช่วงคลื่นสีเขียว
Red	=	ค่าการสะท้อนในช่วงคลื่นสีแดง
Blue	=	ค่าการสะท้อนในช่วงคลื่นสีน้ำเงิน

2.3 การเรียนรู้ของเครื่อง (Machine learning)

2.3.1 ความหมายของการเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่อง คือ การทำให้ระบบคอมพิวเตอร์สามารถประมวลผล คาดการณ์ ตัดสินปัญหาต่าง ๆ ด้วยตัวเอง ผ่านการเรียนรู้ด้วยชุดข้อมูลที่ผู้พัฒนาป้อนเข้าไปอย่างเป็นลำดับขั้นตอน ซึ่งช่วยให้ระบบเทคโนโลยีสารสนเทศรู้จักรูปแบบพื้นฐานของอัลกอริทึมและชุดข้อมูลต่าง ๆ เพื่อเป็นการเรียนรู้รูปแบบอัตโนมัติผ่านข้อมูลและประสบการณ์ด้วยตัวระบบเอง (Demeter, 2563 และ Cyber Elite, 2565) โดยกระบวนการเบื้องต้นของการเรียนรู้ของเครื่อง นั้นคือการนำข้อมูลทดสอบ (Training data) ป้อนเข้าไปยังตัวอัลกอริทึม (Machine Learning Algorithm) เพื่อให้

อัลกอริทึมเรียนรู้จากข้อมูลที่ป้อนเข้าไป เมื่ออัลกอริทึมเรียนรู้แล้วจะให้ผลลัพธ์เป็น แบบจำลองใหม่ (Model) เพื่อใช้ในการทำนายหรือคาดการณ์ (Predict) แล้วสามารถนำข้อมูลที่ต้องการคาดการณ์ ป้อนเข้าไปในแบบจำลอง (Model) เพื่อให้ได้ข้อมูลผลลัพธ์ใหม่ที่ทำนายหรือคาดการณ์ โดย อัตโนมติ (รูปที่ 2.5) (Mesquita, 2021)



รูปที่ 2.5 ภาพรวมของกระบวนการ Machine Learning เบื้องต้น

(ที่มา: <https://realpython.com/python-ai-neural-network/>)

2.3.2 การเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (Extreme Gradient Boosting: XGboost)

XGBoost เป็นอัลกอริทึมการเรียนรู้แบบเสริมแรง (Boosting) ที่พัฒนามาบนพื้นฐานของ ต้นไม้ตัดสินใจ โดยมีจุดเด่นในการสร้างต้นไม้ทีละต้นตามลำดับขั้น ตามกลยุทธ์ของ Gradient Boosting ซึ่งมุ่งเน้นการแก้ไขข้อผิดพลาดจากการพยากรณ์ของต้นไม้ก่อนหน้าในแต่ละรอบการเรียนรู้ ในแต่ละขั้นตอน XGBoost จะสร้างต้นไม้ใหม่โดยคำนึงถึงค่าคงเหลือของข้อผิดพลาดจากการทำนายก่อนหน้า และเมื่อสิ้นสุดกระบวนการฝึก จะได้ชุดของต้นไม้ที่แต่ละต้นมีการพยากรณ์เป็นของตนเอง ผลลัพธ์สุดท้ายจะเกิดจากการรวมคะแนนพยากรณ์ของต้นไม้ทั้งหมดเข้าด้วยกัน ซึ่งช่วยเพิ่มความแม่นยำในการจำแนกหรือทำนายค่าต่าง ๆ อย่างมีประสิทธิภาพ (Hidayaturrohman and Hanada, 2024)


2.3.3 เครื่องเวกเตอร์สนับสนุน (Support Vector Machine: SVM)

SVM เป็นอัลกอริทึมการเรียนรู้แบบมีผู้สอน (Supervised Learning) ที่ถูกออกแบบมาเพื่อรองรับงานจำแนกประเภท การถดถอย และการตรวจจับข้อมูลผิดปกติ โดยพัฒนาขึ้นโดย Cortes และ Vapnik บนพื้นฐานของทฤษฎีการเรียนรู้เชิงสถิติ Vapnik–Chervonenkis ซึ่งสามารถประยุกต์ใช้ได้ทั้งในกรณีเส้นตรงและไม่เป็นเส้นตรง ในกรณีของข้อมูลที่แยกได้เชิงเส้น SVM จะใช้ไฮเปอร์เพลนที่มีระยะขอบสูงสุดเป็นตัวแบ่งกลุ่มข้อมูล ขณะที่กรณีไม่เชิงเส้นจะใช้ Kernel Function

แปลงข้อมูลไปยังมิติที่สูงขึ้นเพื่อให้สามารถจำแนกได้ง่ายขึ้น โดย Kernel ที่นิยม ได้แก่ เส้นตรง พหุนาม ฟังก์ชันฐานรัศมี (RBF) และซิกมอยด์ ซึ่ง Kernel แบบซิกมอยด์มีลักษณะคล้ายฟังก์ชันกระตุ้นในโครงข่ายประสาทเทียม ทำให้กระบวนการพยากรณ์มีความยืดหยุ่นมากขึ้น นอกจากนี้ SVM ยังสามารถนำไปใช้กับการเรียนรู้แบบไม่มีผู้สอน เช่น เทคนิค Support Vector Clustering (SVC) ซึ่งเหมาะสำหรับการวิเคราะห์ข้อมูลที่ไม่มีป้ายกำกับ ในการฝึกโมเดล SVM จะใช้เทคนิคการเพิ่มระยะขอบระหว่างกลุ่มข้อมูลผ่านการแก้ปัญหา Optimization แบบ Quadratic Programming (QP) โดยทั่วไปนิยมใช้วิธีการแบบฮิวริสติกเพื่อแบ่งปัญหาใหญ่ออกเป็นส่วนย่อยเพื่อให้คำนวณได้มีประสิทธิภาพมากขึ้น (Cemiloglu et al., 2023)

2.3.4 อัลกอริทึมป่าแบบสุ่ม (Random Forest: RF)

อัลกอริทึม RF ได้รับการยอมรับอย่างกว้างขวางในฐานะเครื่องมือที่มีประสิทธิภาพสำหรับการจำแนกประเภทข้อมูลการใช้ประโยชน์ที่ดินและการปกคลุมพื้นที่ โดยเฉพาะในระบบนิเวศป่าชายเลน ซึ่งมีความซับซ้อนทางพื้นที่สูง RF จัดอยู่ในกลุ่มของเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ที่มีความสามารถในการเพิ่มประสิทธิภาพของการจำแนกรูปแบบได้อย่างมีนัยสำคัญ โดยมีการนำไปใช้ในหลากหลายงานวิจัยทางด้านนิเวศวิทยาอย่างประสบความสำเร็จ อัลกอริทึมนี้อาศัยหลักการของต้นไม้ตัดสินใจ (Decision Tree - DT) หลายต้น ซึ่งแต่ละต้นจะประเมินข้อมูลฝึกสอน (Training Data) เพื่อเลือกกลุ่มประเภทที่มีความโดดเด่นสูงสุด และใช้ผลรวมของต้นไม้ทั้งหมดในการพิจารณาจำแนกประเภทขั้นสุดท้าย โดยสรุปผลลัพธ์สุดท้ายด้วยวิธีการโหวตเสียงข้างมากจากผลการจำแนกของต้นไม้ทั้งหมด (Majority Voting) ทำให้สามารถลดความเอนเอียงและเพิ่มความแม่นยำของผลลัพธ์ได้อย่างมีประสิทธิภาพ (Purwanto et al., 2023) แสดงโครงสร้าง RF (รูปที่ 2.6)



รูปที่ 2.6 โครงสร้างของ Random Forest (RF) (Rudd and Ray, 2020)

2.4 สถิติที่เกี่ยวข้อง

2.4.1 แผนภูมิกล่อง (Boxplot)

เป็นเครื่องมือทางสถิติที่ใช้แสดงการกระจายของข้อมูลในเชิงภาพอย่างกระชับ โดยเน้นให้เห็นแนวโน้มของข้อมูล ค่ากลาง และความแปรปรวนภายในชุดข้อมูล แผนภูมินี้มีองค์ประกอบหลัก 5 ค่า ได้แก่ ค่าต่ำสุด (Minimum), ควอร์ไทล์ที่ 1 (Q1), ค่ามัธยฐาน (Q2), ควอร์ไทล์ที่ 3 (Q3) และค่าสูงสุด (Maximum) ซึ่งจะช่วยแบ่งข้อมูลออกเป็น 4 ส่วนที่มีจำนวนข้อมูลประมาณเท่ากันในแต่ละช่วง โครงสร้างของ Boxplot ประกอบด้วยกล่อง (Box) ที่แสดงช่วงระหว่าง Q1 ถึง Q3 ซึ่งเรียกว่าช่วงควอร์ไทล์ (Interquartile Range: IQR) โดยค่ามัธยฐาน (Q2) จะอยู่ภายในกล่อง ส่วนเส้นที่ยื่นออกจากกล่องทั้งสองด้านเรียกว่า "Whiskers" ใช้แทนข้อมูลที่อยู่ภายนอก IQR แต่ไม่เกินค่าขอบเขตที่กำหนด ($Q1 - 1.5 \times IQR$ และ $Q3 + 1.5 \times IQR$) ข้อมูลที่อยู่นอกช่วงดังกล่าวถือเป็นค่าผิดปกติ (Outliers) และมักแสดงด้วยจุดเดี่ยว ๆ นอกกล่อง Boxplot สามารถวาดในแนวนตั้งหรือแนวนอน ทั้งนี้เพื่อเพิ่มความสะดวกในการเปรียบเทียบการกระจายของข้อมูลระหว่างกลุ่มต่าง ๆ ได้อย่างมีประสิทธิภาพ (Li, Huang, and Lin, 2022)

2.4.2 การถดถอยเชิงเส้นอย่างง่าย (Simple Linear Regression)

การถดถอยเชิงเส้นอย่างง่ายเป็นวิธีการทางสถิติที่ใช้ศึกษาความสัมพันธ์เชิงเส้นระหว่างตัวแปรต้น (Independent Variable) และตัวแปรตาม (Dependent Variable) โดยมีวัตถุประสงค์หลักเพื่ออธิบายหรือทำนายค่าของตัวแปรตามจากค่าของตัวแปรต้น ซึ่งแสดงด้วยสมการเชิงเส้น ดังสมการที่ 2.17 (Montgomery, Peck, and Vining, 2012)

$$Y = \beta_0 + \beta_1 X + \varepsilon \quad (\text{สมการที่ 2.17})$$

Y	=	ค่าที่ต้องการพยากรณ์
X	=	ตัวแปรต้น
β_0, β_1	=	ค่าพารามิเตอร์ของแบบจำลอง
ε	=	ค่าความคลาดเคลื่อนของแบบจำลอง

2.4.3 ค่าสัมประสิทธิ์กำหนด (Coefficient of Determination: R^2)

R^2 คือค่าทางสถิติที่ใช้วัดความสามารถของสมการถดถอยในการอธิบายความแปรปรวนของตัวแปรตาม (Dependent Variable) จากตัวแปรอิสระ (Independent Variable) ที่กำหนดไว้ในแบบจำลอง โดยมีค่าระหว่าง 0 ถึง 1 ยิ่งค่า R^2 ใกล้ 1 มากเท่าใด ยิ่งแสดงว่าแบบจำลองสามารถอธิบายความแปรปรวนของข้อมูลได้มากเท่านั้น ในทางกลับกัน หากค่า R^2 ต่ำ แสดงว่าแบบจำลองมีประสิทธิภาพในการอธิบายข้อมูลน้อย ค่านี้นิยมใช้ในการประเมินคุณภาพของแบบจำลองเชิงเส้น โดยเฉพาะในงานวิเคราะห์ความสัมพันธ์เชิงปริมาณ ดังสมการที่ 2.18 (Montgomery, Peck, and Vining, 2012)

$$R^2 = 1 - \frac{SS_{res}}{SS_{tot}} = \frac{SS_{reg}}{SS_{tot}} \quad (\text{สมการที่ 2.18})$$

R^2	=	ค่าสัมประสิทธิ์กำหนด
SS_{tot}	=	ผลรวมกำลังสองของความแปรปรวนรวม (Total Sum of Squares)
SS_{res}	=	ผลรวมกำลังสองของค่าคงเหลือ (Residual Sum of Squares)
SS_{reg}	=	ผลรวมกำลังสองของการถดถอย (Regression Sum of Squares)

2.5 งานวิจัยที่เกี่ยวข้อง

Zhang et al. (2014) ศึกษาการแยกชนิดและสถานะของป่าชายเลน กรณีศึกษาป่าชายเลนที่เสื่อมโทรมในเม็กซิโกแปซิฟิก โดยใช้ข้อมูล Hyperspectral Data การศึกษานี้มีวัตถุประสงค์เพื่อระบุสภาพของป่าชายเลนในทะเลสาบชายฝั่งทางตอนใต้ของเมืองมาซาดาลัน ประเทศเม็กซิโก โดยใช้เทคนิคการสำรวจระยะไกลแบบไฮเปอร์สเปกตรัม ป่าชายเลนที่โดดเด่นในบริเวณนี้ ได้แก่ ป่าชายเลนสีแดง (*Rhizophora mangle*), ป่าชายเลนสีดำ (*Avicennia germinans*) และป่าชายเลนสีขาว (*Laguncularia racemosa*) นอกจากนี้ยังพบป่าโกงกางสีดำและสีแดง ที่มีสภาพไม่ดีและโกงกางแคระที่มีสุขภาพดีเป็นหย่อมใหญ่ เก็บตัวอย่างใบโกงกางจากพื้นที่ตัวอย่างที่กล่าวมา จากนั้นตัวอย่างใบไม้จะถูกส่งไปยังห้องปฏิบัติการเพื่อตรวจวัดสเปกตรัมโดยใช้ ASD FieldSpec® 3 JR Spectroradiometer จากนั้นทำการเลือกแถบคลื่นที่เหมาะสมที่สุดสำหรับการจำแนกประเภทป่าชายเลนเพิ่มเติม โดยใช้การวิเคราะห์องค์ประกอบหลักและการวิเคราะห์จำแนกแบบขั้นตอน ได้ทำการเลือกแถบคลื่นที่ 520, 560, 650, 710, 760, 2100 และ 2230 นาโนเมตร เนื่องจากพบว่าแถบคลื่นที่กล่าวมาสอดคล้องกับการดูดกลืนคลอโรฟิลล์ ขอบสีแดง แปร เซลลูโลส ไนโตรเจน และบริเวณโปรตีนของสเปกตรัม ผลการศึกษาพบว่าแถบคลื่นเหล่านี้สามารถระบุชนิดของป่าชายเลน และสภาพของป่าชายเลนที่พบได้ทั่วไปในผืนป่าเสื่อมโทรมแห่งนี้ด้วยความแม่นยำโดยรวม 90% ($Kappa = 0.9$) พบว่าการจำแนกประเภทของป่าชายเลนที่มีสภาพเครียด (สุขภาพไม่สมบูรณ์และแคระแกร็น) เป็นที่น่าพอใจโดยมีความแม่นยำสูงกว่า 80% และผลการศึกษาบ่งชี้ว่าเป็นไปได้ที่ใช้ข้อมูลไฮเปอร์สเปกตรัมในห้องปฏิบัติการในการจำแนกประเภทป่าชายเลนได้ และยังรวมถึงสภาวะสุขภาพของป่าชายเลนด้วย

Zhen et al. (2021) ศึกษาการทำแผนที่ปริมาณคลอโรฟิลล์ของใบในป่าชายเลนด้วยภาพถ่ายดาวเทียม Sentinel-2 การศึกษานี้มีวัตถุประสงค์เพื่อตรวจสอบความสัมพันธ์ระหว่างค่าปริมาณคลอโรฟิลล์สัมพัทธ์ (SPAD) กับดัชนีพืชพรรณที่ได้จากข้อมูลไฮเปอร์สเปกตรัมของใบและภาพ Sentinel-2 ในป่าชายเลน เพื่อพัฒนารูปแบบการประมาณค่า SPAD ใบโดยใช้ดัชนีพืชพรรณ และการถดถอยเคอร์เนลรีดจ์ (KRR) เพื่อทำแผนที่ใบ SPAD ในสี่ช่วงเวลาที่แตกต่างกันและสำรวจรูปแบบเชิงพื้นที่ชั่วคราวของแผนที่ และเพื่อทำความเข้าใจสภาพสุขภาพของป่าชายเลน สำรวจความสัมพันธ์ของค่า SPAD ของใบไม้ กับ ดัชนีพืชพรรณที่พัฒนาขึ้นใหม่ที่ได้มาจากข้อมูลไฮเปอร์สเปกตรัมของใบไม้และข้อมูล Sentinel-2 สี่ช่วง (พฤษภาคม 2018, มกราคม 2019, สิงหาคม 2019 และธันวาคม 2019) การถดถอยเชิงเส้นด้วยดัชนีพืชพรรณที่มีประสิทธิภาพดีที่สุด และ KRR ได้รับการพัฒนาเพื่อ

สร้างแบบจำลองการดึงข้อมูล SPAD ในแต่ละช่วงเวลา มีการใช้เทคนิค The leave-one-out เพื่อเปรียบเทียบผลการประมาณค่าของวิธีดัชนีพืชพรรณ และ KRR ส่วนแผนที่ SPAD ทั้งสี่ช่วงถูกสร้างขึ้นโดยแบบจำลองที่มีประสิทธิภาพดีที่สุด มีการใช้วิธีการประเมินโดยใช้ค่าสัมประสิทธิ์ความสัมพันธ์ (R^2) รากกำลังสองเฉลี่ยข้อผิดพลาด (RMSE) ค่าความผิดพลาดสัมพัทธ์ (RE) และมีการวิเคราะห์ Hotspot เพื่อระบุจุดที่มีมูลค่าสูงและต่ำอย่างมีนัยสำคัญทางสถิติในแผนที่ SPAD ผลการศึกษาพบว่าดัชนีที่พัฒนาขึ้นใหม่ (อัตราส่วนของการสะท้อนแสงแถบเดียวต่อผลรวมของการสะท้อนแสงสองแถบ, RSSI) ได้รับค่าสัมประสิทธิ์สหสัมพันธ์สูงโดยมีค่า SPAD ของใบที่ระดับทั้งใบและทรงพุ่ม ที่ระดับหลังคา พบว่า ดัชนี RSSI มีประสิทธิภาพดีกว่าการใช้ดัชนีแบบดั้งเดิม พบว่าโมเดล KRR ที่มีการปรับมีค่า $R^2 = 0.496, 0.742, 0.681$ และ 0.801 ค่า RMSE = 5.75, 4.29, 4.00 และ 3.46 ในส่วนของ RE = 7.67%, 5.68%, 4.97% และ 4.63% ในแต่ละเวลา และพบว่าศักยภาพที่ดีของดัชนี RSSI ที่พัฒนาขึ้นใหม่โดยใช้ข้อมูล Sentinel-2 สำหรับการการทำแผนที่การดึงปริมาณคลอโรฟิลล์ในใบ (LCC) ของป่าชายเลนในระดับภูมิภาคในช่วงเวลาต่าง ๆ ซึ่งเป็นสิ่งจำเป็นสำหรับการอนุรักษ์และฟื้นฟูระบบนิเวศป่าชายเลน

Prabakaran, Singh และ Panigrahy (2014) ศึกษาการประเมินภาวะสุขภาพของระบบนิเวศป่าชายเลน โดยใช้ Remote sensing หลายช่วงเวลา ประเทศอินเดีย การศึกษานี้มีวัตถุประสงค์เพื่อลักษณะภาวะสุขภาพของป่าชายเลน ด้วยข้อมูลการสำรวจระยะไกล โดยการใช้ดัชนีพืชพรรณ NDVI มีค่าตั้งแต่ -1 ถึง 1 ทำการแบ่งระดับสุขภาพของป่าชายเลนจาก NDVI เป็นระดับดีมาก ดี ปานกลาง และแย่ ผลการศึกษาพบว่าพื้นที่สุขภาพดีมาก ดี ปานกลาง และแย่ ของป่าชายเลนในอินเดีย คิดเป็น 17% 27.3% 37.6% และ 18.1% ตามลำดับ พบว่าป่าชายเลนที่มีสุขภาพดีที่สุดอยู่บริเวณฝั่งตะวันออก (เกาะอันดามัน , นิดโคบาร์) และต่ำที่สุดอยู่บริเวณฝั่งตะวันตก (แนวชายฝั่งคุชราต)

Abdollahnejad และ Panagiotidis (2020) ศึกษาการจำแนกชนิดพันธุ์ไม้และการประเมินภาวะสุขภาพของป่าใบกว้าง (ป่าสน) ด้วยภาพถ่ายทางอากาศ เมือง Kostelec ทางตะวันออกเฉียงใต้ของกรุงปราก สาธารณรัฐเช็ก การศึกษานี้มีวัตถุประสงค์เพื่ออำนวยความสะดวกในการจำแนกชนิดพันธุ์ไม้และการตรวจหาต้นไม้ที่มีสุขภาพดี ไม่แข็งแรง และตายแล้ว โดยใช้อัลกอริทึม Support Vector Machine (SVM) ในการจำแนกชนิดพันธุ์ไม้และภาวะสุขภาพ ใช้ข้อมูลดัชนีพืชพรรณ (Vegetation Index) เพื่อการศึกษาปริมาณพืชพรรณที่ปกคลุมและสุขภาพของพืช แล้วทำการแบ่งสุขภาพพืชเป็นสุขภาพดี ไม่แข็งแรง และตาย ผลการศึกษาพบว่า อัลกอริทึม SVM สามารถจำแนกชนิดไม้พันธุ์ไม้ ได้เป็น Norway Spruce , Broadleaves และ Scots Pine โดยให้ความแม่นยำโดย

รวมอยู่ที่ 81.18% (Kappa = 0.7) และสามารถจำแนกสภาวะสุขภาพได้ โดยให้ความแม่นยำโดยรวมอยู่ 84.71% (Kappa = 0.66) ถือว่าอัลกอริทึม SVM สามารถใช้ได้ดี

Guerra-Hernández et al. (2021) ศึกษาการประเมินแนวทางการสร้างแบบจำลอง สำหรับติดตามสถานะสุขภาพในป่าเอลเดอร์ดำ ด้วยภาพถ่ายทางอากาศ การศึกษานี้มีวัตถุประสงค์เพื่อประเมินวิธีการสร้างแบบจำลองใหม่โดยใช้ภาพถ่ายจากอากาศยานไร้คนขับความละเอียดสูง เพื่อตรวจสอบสถานะสุขภาพของป่าเอลเดอร์ดำที่ได้รับผลกระทบจากโรคที่เกิดจากเชื้อโรคที่เกิดจากพืช *Phytophthora alni* species complex เพื่อระบุตัวบ่งชี้สุขภาพป่าที่สำคัญและพัฒนาแบบจำลองการจำแนกประเภท เพื่อประเมินพื้นที่ที่ได้รับผลกระทบและไม่ได้รับผลกระทบจากโรค และเพื่อวางแผนมาตรการควบคุมและฟื้นฟูป่าเอลเดอร์ดำ ใช้ข้อมูลดัชนีพืชพรรณ NDVI กับ ข้อมูลแบบจำลองพื้นผิวดิจิทัล (DSM) เป็นตัวชี้วัดสุขภาพของป่า แล้วใช้อัลกอริทึม Random Forest (RF) เพื่อจำแนกอาการของพืชในป่าเอลเดอร์ ออกเป็น 3 แบบ ดังนี้ แบบที่ 1 แบ่งเป็น 4 ระดับ ได้แก่ พืชไม่มีอาการ (A), พืชมีการผลัดใบ <50% (B), พืชมีการผลัดใบ >50% (C) และพืชที่ตาย (D) แบบที่ 2 แบ่งเป็น 3 ระดับ ได้แก่ A, B+C และ D แบบที่ 3 แบ่งเป็น 2 ระดับ ได้แก่ A+B+C และ D ผลการศึกษาพบว่าอัลกอริทึม RF มีความสามารถในการจำแนกได้ดี ให้ความแม่นยำโดยรวมของการแบ่ง 4, 3 และ 2 ระดับ อยู่ที่ 67%, 72% และ 91% ตามลำดับ

Wang et al. (2025) ศึกษาการประเมินชีวมวลเหนือพื้นดินของป่า (Aboveground Biomass: AGB) โดยใช้ข้อมูล Remote Sensing หลายแหล่งร่วมกับอัลกอริทึม XGBoost ซึ่งมีความสามารถสูงในการจัดการข้อมูลที่มีมิติสูงและความสัมพันธ์ที่ซับซ้อนระหว่างตัวแปร การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาโมเดลการประมาณชีวมวลเหนือพื้นดินของป่าด้วยวิธี XGBoost โดยการสร้างชุดคุณสมบัติจากข้อมูล GF-7 (ความสูงต้นไม้: Tree Height), Sentinel-1, Sentinel-2 และ ALOS DEM รวม 15 ชุด จากนั้นใช้วิธี Recursive Feature Elimination (RFE) เพื่อคัดเลือกคุณสมบัติที่สำคัญที่สุดก่อนนำเข้าสู่การฝึกโมเดล XGBoost โดยโมเดล XGboost ที่ได้จากการผสมผสานข้อมูลทั้ง 4 ประเภท (TS1S2D) แสดงประสิทธิภาพสูงสุด โดยมีค่า R^2 เท่ากับ 0.71 และ RMSE เท่ากับ 18.11 Mg/ha คุณสมบัติที่มีอิทธิพลสูงสุดในโมเดลคือความสูงต้นไม้ (TH) คิดเป็น 19.8% รองลงมาคือแถบสเปกตรัม Band-5 และ Band-12 จาก Sentinel-2 และตัวแปรทางภูมิประเทศ SPI ผลการศึกษาสะท้อนถึงศักยภาพของอัลกอริทึม XGBoost ในการวิเคราะห์และพยากรณ์ AGB อย่างแม่นยำภายใต้บริบทของข้อมูลหลายแหล่งในระบบภูมิสารสนเทศ

จากการศึกษาวิจัยและเอกสารที่เกี่ยวข้อง พบว่าดัชนีพืชพรรณทั้ง 16 ดัชนี สามารถแบ่งกลุ่มได้ 3 กลุ่ม ได้แก่ กลุ่มดัชนีที่สะท้อนลักษณะทั่วไปของพืช เช่น ความหนาแน่นและความเขียว ซึ่งมักใช้ช่วงคลื่น Red และ NIR ประกอบด้วยดัชนี NDVI, NDWI, GNDVI, SAVI และ EVI กลุ่มดัชนีที่เกี่ยวข้องกับการประเมินปริมาณคลอโรฟิลล์ของพืช โดยเน้นการใช้ช่วงคลื่น Red edge และ NIR ประกอบด้วยดัชนี NDRE, MTCI, CCCI, RECI, TCARI, NDI และ PSRI และกลุ่มดัชนีที่ประเมินความเขียวของพืชในระดับเรือนยอด โดยเน้นการใช้เฉพาะช่วงคลื่นที่ RGB (Red, Green และ Blue) ซึ่งนิยมใช้ในข้อมูลจาก UAV ประกอบด้วยดัชนี GCC, VDI, ExG และ VARI ในส่วนของการจำแนกสุขภาพของป่าชายเลน อัลกอริทึมที่เลือกใช้ในงานวิจัยนี้ ได้แก่ XGB, SVM และ RF ซึ่งล้วนเป็นอัลกอริทึมที่ได้รับความนิยมในการประมวลผลข้อมูลจากภาพถ่ายทางอากาศและข้อมูลจากดัชนีพืชพรรณ โดย XGB มีข้อดีคือสามารถจัดการกับข้อมูลจำนวนมากได้ดี มีประสิทธิภาพในการจำแนกสูง เหมาะกับชุดข้อมูลที่มีตัวแปรจำนวนมากและมีความไม่สมดุล ในขณะที่ SVM มีข้อดีคือสามารถใช้ในการแบ่งแยกข้อมูลที่ไม่เป็นเชิงเส้นได้อย่างแม่นยำและสามารถประยุกต์ใช้กับข้อมูลที่มีมิติมาก และ RF มีข้อดีในเรื่องของความสามารถในการจัดการกับข้อมูลที่มีความไม่สมดุลได้ดี มีความยืดหยุ่น และปรับใช้ได้ง่าย การเลือกใช้อัลกอริทึมทั้งสามแบบในงานวิจัยนี้ ช่วยเสริมความน่าเชื่อถือในการจำแนกสุขภาพของพืชป่าชายเลนจากภาพถ่ายทางอากาศ และช่วยเปรียบเทียบประสิทธิภาพของอัลกอริทึมที่มีคุณสมบัติต่างกัน เพื่อเลือกแนวทางที่เหมาะสมที่สุดกับข้อมูลเฉพาะในบริบทของระบบนิเวศป่าชายเลน

บทที่ 3

วิธีการวิจัย

การพัฒนาอัลกอริทึมสำหรับติดตามความอุดมสมบูรณ์ของป่าชายเลน ทำได้โดยใช้ข้อมูล 2 ส่วน ได้แก่ ข้อมูลภาพถ่ายทางอากาศ และข้อมูลค่าการสะท้อนแสงของใบไม้ ซึ่งมีรายละเอียดวิธีการดำเนินงานดังนี้

3.1 ข้อมูล อุปกรณ์ และเครื่องมือที่ใช้ในการวิจัย

3.1.1 ข้อมูลที่ใช้ในการวิจัย

1) ข้อมูลภาพถ่ายทางอากาศ ใช้อากาศยานไร้คนขับ รุ่น DJI P4 Multispectral เพื่อนำไปวิเคราะห์ข้อมูลดัชนีพืชพรรณ โดยเก็บภาพจำนวน 2 ช่วงฤดู ได้แก่ ช่วงฤดูร้อน เก็บภาพวันที่ 14 พฤษภาคม ปี พ.ศ. 2567 และช่วงฤดูฝน เก็บภาพวันที่ 23 พฤศจิกายน ปี พ.ศ. 2567 รายละเอียดของแผนการบินมีดังนี้: Side Overlap 75%, Front Overlap 80%, ความสูง 60 m, ขนาด 3.2 cm/pix

2) ข้อมูลค่าการสะท้อนแสงของพืช มาจากการลงพื้นที่เก็บข้อมูลภาคสนาม เพื่อนำข้อมูลมาวิเคราะห์ระดับสุขภาพของพืช โดยใช้เครื่องมือค่าการสะท้อนแสง (Spectroradiometer) โดยลงพื้นที่ภาคสนามในวันที่ 14 พ.ค. 2567


3.1.2 อุปกรณ์และเครื่องมือที่ใช้ในการวิจัย

- 1) อากาศยานไร้คนขับ รุ่น DJI P4 Multispectral (รูปที่ 2.2)
- 2) โปรแกรมประมวลผล Pix4Dmapper เพื่อประมวลผลภาพถ่ายทางอากาศ
- 3) โปรแกรมประมวลผล (Python) ข้อมูลภาพถ่ายทางอากาศ เพื่อวิเคราะห์ข้อมูลดัชนีพืชพรรณและพัฒนาอัลกอริทึม
- 4) เครื่องมือวัดค่าการสะท้อนแสงของใบไม้ (Spectroradiometer) เพื่อวัดค่าการสะท้อนแสงของใบไม้ในพื้นที่ป่าชายเลน (รูปที่ 3.5)

3.2 พื้นที่ศึกษา


การศึกษาครั้งนี้ดำเนินการในพื้นที่ป่าชายเลนบริเวณจังหวัดภูเก็ต ซึ่งตั้งอยู่ทางทิศตะวันออกของจังหวัด โดยจังหวัดภูเก็ตเป็นจังหวัดหนึ่งในภาคใต้ตอนบนของประเทศไทย มีลักษณะเป็นเกาะและจัดเป็นเกาะที่มีขนาดใหญ่ที่สุดของประเทศ ตั้งอยู่ทางทิศตะวันตกของภาคใต้ในทะเลอันดามัน โดยมีความกว้างมากที่สุดประมาณ 21.3 กิโลเมตร และมีความยาวมากที่สุดประมาณ 48.7 กิโลเมตร จังหวัดภูเก็ตมีพื้นที่รวม 554.41 ตารางกิโลเมตร และพื้นที่ป่าชายเลนรวม 25.43 ตารางกิโลเมตร (กรมพัฒนาที่ดิน, 2561) พื้นที่จังหวัดภูเก็ตอยู่ในเขตภูมิอากาศแบบศูนย์สูตร ภายใต้อิทธิพลของลมมรสุมตะวันตกเฉียงใต้และลมมรสุมตะวันออกเฉียงเหนือ ทำให้มีสภาพอากาศร้อนชื้นตลอดทั้งปี โดยแบ่งออกเป็น 2 ฤดูกาล ได้แก่ ฤดูฝน ซึ่งกินเวลาตั้งแต่ปลายเดือนพฤษภาคมถึงต้นเดือนมกราคม และฤดูร้อน ตั้งแต่ปลายเดือนมกราคมถึงต้นเดือนพฤษภาคมของทุกปี (ศูนย์ภูมิอากาศ กรมอุตุนิยมวิทยา, 2560)

ในการศึกษานี้ได้เลือกพื้นที่ตัวอย่างบริเวณป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต ซึ่งมีพื้นที่รวมประมาณ 2,710,000 ตารางเมตร (2.71 ตารางกิโลเมตร) โดยกำหนดพื้นที่ศึกษาหลักในบริเวณตอนบนของพื้นที่ป่าชายเลนดังกล่าว ซึ่งมีขนาดพื้นที่ประมาณ 100,000 ตารางเมตร (0.1 ตารางกิโลเมตร) เนื่องจากบริเวณนี้แสดงลักษณะความแตกต่างของสีและโครงสร้างเรือนยอดได้อย่างชัดเจนจากภาพถ่ายทางอากาศและดาวเทียม จึงเหมาะสมต่อการวิเคราะห์สุขภาพของป่าชายเลน โดยในพื้นที่ศึกษานี้ ได้มีการกำหนดขอบเขตพื้นที่สำหรับการสร้างโมเดล และแยกพื้นที่ทดสอบโมเดลอย่างชัดเจน เพื่อใช้ประเมินประสิทธิภาพและความแม่นยำของโมเดลที่พัฒนา (รูปที่ 3.1)



รูปที่ 3.1 แผนที่ภาพถ่ายทางอากาศพื้นที่ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต แสดงพื้นที่สร้างโมเดล และพื้นที่ทดสอบโมเดล

3.3 วิธีการดำเนินงานวิจัย



รูปที่ 3.2 ขั้นตอนการดำเนินการ

3.3.1 เตรียมข้อมูลก่อนการวิเคราะห์


การพัฒนาอัลกอริทึมสำหรับติดตามสุขภาพของป่าชายเลน โดยใช้ข้อมูลภาพถ่ายทางอากาศ เพื่อวิเคราะห์ข้อมูลดัชนีพืชพรรณและสุขภาพของพืช โดยมีวิธีการเตรียมข้อมูลดังนี้

1) เตรียมข้อมูลภาพถ่ายทางอากาศ


ใช้อากาศยานไร้คนขับ รุ่น DJI P4 Multispectral โดยเก็บภาพจำนวน 2 ช่วงฤดู ได้แก่ ช่วงฤดูร้อน เก็บภาพในวันที่ 14 พ.ค. 2567 และช่วงฤดูฝนเก็บภาพในวันที่ 23 พฤศจิกายน พ.ศ. 2567 รายละเอียดของแผนการบินมีดังนี้: ความซ้อนทับด้านข้าง (Side Overlap) = 75%, ความซ้อนทับด้านหน้า (Front Overlap) 80%, ความสูงในการบิน 60 m และความละเอียดเชิงพื้นที่ 3.2 cm/pix ภายหลังการบิน ข้อมูลภาพถ่ายทางอากาศจะถูกนำเข้าสู่โปรแกรม Pix4Dmapper เพื่อประมวลผลและเชื่อมต่อภาพเข้าด้วยกัน (Mosaic) จนได้เป็นแผนที่ภาพถ่ายทางอากาศแบบ Orthomosaic ขนาดใหญ่ 1 ชุดต่อฤดูกาล ซึ่งใช้เป็นข้อมูลตั้งต้นสำหรับการวิเคราะห์ดัชนีพืชพรรณ และพัฒนาอัลกอริทึมต่อไป จากนั้นทำการแบ่งพื้นที่ศึกษาออกเป็น 2 โซน ได้แก่ พื้นที่สร้างโมเดล และ พื้นที่ทดสอบโมเดล (รูปที่ 3.1) เพื่อแยกชุดข้อมูลระหว่างกระบวนการฝึกอัลกอริทึมและการประเมินผลของโมเดล โดยข้อมูลจากพื้นที่สร้างโมเดลจะถูกใช้ในการฝึกอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) ส่วนข้อมูลจากพื้นที่ทดสอบโมเดลจะใช้ในการประเมินประสิทธิภาพของการจำแนกสุขภาพป่าชายเลนอย่างอิสระและไม่ซ้ำกับชุดข้อมูลฝึก ซึ่งการจัดสรรลักษณะนี้มีส่วนช่วยเพิ่มความน่าเชื่อถือของผลการจำแนกจากโมเดล Random Forest (RF), Support Vector Machine (SVM) และ Extreme Gradient Boosting (XGBoost) ได้อย่างมีประสิทธิภาพ

2) การวางแผนเก็บข้อมูล

ทำการวางแผนบนพื้นที่ตัวอย่างป่าชายเลน ซึ่งเบื้องต้นได้กำหนดพื้นที่ตัวอย่างไว้ในบริเวณป่าชายเลนเกาะผี ทั้งนี้แปลงเก็บตัวอย่างกำหนดขนาดพื้นที่เป็น 10 x 10 เมตร เพื่อให้พอดีกับความละเอียดของภาพถ่ายดาวเทียม Sentinel-2 (10 x 10 เมตร) ครอบคลุมทั้งพืชสุขภาพดีและไม่ดี จากนั้นวางตำแหน่งจุดเก็บข้อมูล โดยตำแหน่งจุดนั้นอยู่บริเวณจุดศูนย์กลางของแปลง (รูปที่ 3.3) ขั้นตอนนี้เป็นไปตามระเบียบวิธีวิจัยของ Miao et al. (2024) ซึ่งศึกษาเรื่อง การสร้างแบบจำลองและปัจจัยที่ส่งผลต่อค่าการคายระเหยของน้ำในป่าชายเลนด้วยภาพถ่ายดาวเทียม Sentinel-2 ใน ปี พ.ศ. 2567 ดังนั้น ผู้วิจัยจึงได้ออกแบบแผนการเก็บข้อมูลตัวอย่างป่าชายเลนเป็นแผนที่ โดยตำแหน่งจุดเก็บข้อมูลตัวอย่างครั้งนี้มีจำนวน 48 จุด (รูปที่ 3.4)



รูปที่ 3.3 รูปแบบแปลงและตำแหน่งจุดเก็บข้อมูลตัวอย่าง



รูปที่ 3.4 แผนที่ตำแหน่งจุดเก็บข้อมูลตัวอย่างไปไม้ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต

3) การเก็บข้อมูลภาคสนาม

การลงพื้นที่เก็บข้อมูลภาคสนามตาม (รูปที่ 3.4) เพื่อเก็บตัวอย่างค่าการสะท้อนของใบไม้ในป่าชายเลน มีวิธีการเบื้องต้นดังนี้ (Zhang et al., 2014)

1. ลงพื้นที่ภาคสนาม ณ พื้นที่ตัวอย่างป่าชายเลน วันที่ 14 พฤษภาคม ปี พ.ศ. 2567
2. ทำการสุ่มจำนวนตัวอย่างการเก็บใบไม้ โดยแต่ละกิ่งทำการตัดเฉพาะใบที่ 3 ถึง 5 นับจากปลายยอด และเก็บเฉพาะใบที่โตเต็มที่เท่านั้น ทั้งนี้ใช้จำนวนใบประมาณ 20 ใบ รวมถึงเก็บพิกัดตำแหน่งเก็บตัวอย่างใบไม้
3. นำตัวอย่างใบไม้ใส่ถุงซิปล็อค เก็บไว้ในตู้รักษาอุณหภูมิความเย็น 4 องศาเซลเซียส
4. จากนั้นนำตัวอย่างส่งไปส่งห้องปฏิบัติการเพื่อเก็บบันทึกข้อมูลค่าการสะท้อนแสงของใบไม้ ด้วยเครื่องวัดค่าการสะท้อนแสงเชิงสเปกตรัม (Spectroradiometer) โดยวัดวันเดียวกับวันที่เก็บตัวอย่าง (รูปที่ 3.5)
5. ใช้หลอดไฟ Halogen เป็นแหล่งกำเนิดแสงในห้องมืดสนิท
6. นำตัวอย่างใบไม้หงายขึ้นบนแผ่นจานสีดำเส้นผ่านศูนย์กลาง 25 ซม.
7. เซนเซอร์รับภาพ 25° ติดตั้งไว้เหนือแผ่นที่ระยะ 30 ซม.
8. ปรับให้อ่านค่าจากแสงสีขาว (Spectralon) เพื่อเปรียบเทียบการวัดทุก ๆ 5 นาที
9. ตัวอย่างใบไม้แต่ละใบ วัด 4 ครั้ง โดยหมุนแผ่นจาน 90°
10. คำนวณค่าเฉลี่ยค่าการสะท้อนจากการวัด 4 ครั้ง
11. ทำการแบ่งเป็นค่าระดับสุขภาพของใบไม้ป่าชายเลน จากข้อมูลค่าการสะท้อนของใบไม้ป่าชายเลนที่เก็บมาจากภาคสนาม



รูปที่ 3.5 การตรวจวัดค่าการสะท้อนแสงของใบไม้ ด้วยเครื่อง Spectroradiometer

4) การจำแนกสุขภาพของป่าชายเลน

การจำแนกสุขภาพของป่าชายเลนสามารถพิจารณาจากกราฟการสะท้อนแสงของใบไม้ในป่าชายเลนในแต่ละจุดเก็บข้อมูล (Malinee et al., 2021; Zhang et al., 2014) ทั้งนี้งานวิจัยของ Malinee et al. (2021) ได้แบ่งระดับสุขภาพของใบไม้ออกเป็น 2 ระดับ ได้แก่ ใบไม้ที่มีสุขภาพดี (Healthy Leaf) และ ใบไม้ที่มีสุขภาพไม่ดี (Diseased Leaf) จากการทบทวนผลงานวิจัยที่เกี่ยวข้องพบว่าค่าการสะท้อนของใบไม้ที่มีสุขภาพดีจะสูงกว่าใบไม้ที่มีสุขภาพไม่ดี โดยเห็นชัดในช่วงคลื่น Near Infrared ดังนั้นในงานวิจัยครั้งนี้จึงแบ่งระดับสุขภาพของใบไม้ในป่าชายเลนออกเป็น 2 ระดับ ได้แก่ สุขภาพดีและสุขภาพไม่ดี

5) การจำแนกสุขภาพของเรือนยอดป่าชายเลนด้วยสายตา

เพื่อใช้เป็นข้อมูลอ้างอิงในการประเมินความแม่นยำของอัลกอริทึมที่พัฒนาขึ้นสำหรับการจำแนกสุขภาพของป่าชายเลน การจำแนกสุขภาพของเรือนยอดพืชเบื้องต้นจึงดำเนินการด้วยวิธีการแปลภาพถ่ายทางอากาศด้วยสายตา (Visual Interpretation) จากภาพ UAV ที่ได้ในช่วงฤดูร้อนและฤดูฝน โดยเริ่มจากการนำภาพ Orthomosaic เข้าสู่ระบบ GIS เพื่อระบุตำแหน่งของทรงพุ่ม และประเมินสุขภาพของพืชจากภาพ UAV ความละเอียดสูงในตำแหน่งเดียวกัน โดยพิจารณาจากสีใบ ความหนาแน่น และความผิดปกติของเรือนยอด จากนั้นจำแนกสุขภาพออกเป็น 2 กลุ่ม ได้แก่ สุขภาพดีและสุขภาพไม่ดี และทำการวาดขอบเขตเรือนยอดในลักษณะของรูปปิด (Polygon) (รูปที่ 3.5) เพื่อใช้ในการวิเคราะห์ดัชนีพืชพรรณ ตลอดจนเป็นข้อมูลภาคสนามสำหรับการฝึกและประเมินอัลกอริทึม



รูปที่ 3.6 ตัวอย่างการจำแนกสุขภาพของเรือนยอดป่าชายเลนด้วยสายตา โดยใช้ภาพถ่าย UAV ความละเอียดสูง

6) การคำนวณค่าดัชนีพืชพรรณ

ในการศึกษานี้ ได้ดำเนินการคำนวณค่าดัชนีพืชพรรณจำนวน 16 ดัชนี ได้แก่ NDVI, GNDVI, NDWI, SAVI, EVI, NDRE, NDI, TCARI, RECI, CCCI, GCC, VDMI, MTCI, ExG, PSRI และ VARI โดยอาศัยการคำนวณจากสมการที่ 2.1 ถึง 2.16 ซึ่งเป็นสมการที่ใช้อ้างอิงในการประมวลผลข้อมูลภาพถ่ายจาก UAV แบบ Multispectral ทั้งนี้ ดัชนีทั้งหมดจะถูกนำมาทดสอบเพื่อคัดเลือกดัชนีที่มีศักยภาพในการสะท้อน โดย สุขภาพของพืชในพื้นที่ศึกษาได้อย่างแม่นยำ และผลลัพธ์จากการคำนวณดัชนีจะถูกนำเสนอทั้งในรูปแบบเชิงพื้นที่และเชิงสถิติ (ผ่านการวิเคราะห์ด้วยกราฟ Box plot) เพื่อเปรียบเทียบค่าระหว่างกลุ่มสุขภาพพืชที่แตกต่างกัน โดยการคัดเลือกดัชนีจะพิจารณาจากเกณฑ์เชิงสถิติดังนี้ คือ ความแตกต่างของค่ามัธยฐาน (Median) ระหว่างกลุ่ม, ค่าเฉลี่ย (Mean) ที่สะท้อนค่ากลางของข้อมูลโดยรวม, การไม่ซ้อนทับกันมากเกินไปของช่วงค่าระหว่างควอไทล์ (Interquartile Range) ของแต่ละกลุ่ม และ ค่าต่ำสุด-ค่าสูงสุด (Min-Max) ที่แสดงการกระจายตัวของข้อมูลที่ชัดเจน ซึ่งเกณฑ์เหล่านี้ช่วยในการตัดสินใจคัดเลือกดัชนีที่เหมาะสมที่สุดสำหรับนำไปใช้ในการพัฒนาอัลกอริทึมในขั้นตอนถัดไป

3.3.2 การพัฒนาอัลกอริทึมสำหรับติดตามสุขภาพของป่าชายเลน

นำข้อมูลดัชนีพืชพรรณและข้อมูลภาคสนาม แบ่งเป็นข้อมูลฝึกซ้อม (Training Data) ประมาณร้อยละ 70 และข้อมูลทดสอบ (Testing Data) ประมาณร้อยละ 30 โดยใช้ Machine

Learning Algorithm ที่มีชื่อว่า อัลกอริทึมป่าแบบสุ่ม (Random Forest), การเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (XGboost) และเครื่องเวกเตอร์สนับสนุน (Support Vector Machine)

1) อัลกอริทึมป่าแบบสุ่ม (Random Forest)

การศึกษานี้ประยุกต์ใช้กระบวนการเรียนรู้ของเครื่องแบบป่าสุ่ม (RF) ในการพัฒนาอัลกอริทึมสำหรับจำแนกสุขภาพของป่าชายเลน โดย RF เป็นอัลกอริทึมที่อาศัยหลักการของการรวมผลจากต้นไม้ตัดสินใจหลายต้น (Decision Trees) ซึ่งช่วยลดความแปรปรวนของแบบจำลอง (variance) และเพิ่มความแม่นยำของผลลัพธ์ได้อย่างมีประสิทธิภาพ สำหรับข้อมูลนำเข้า (Input Features) กำหนดให้ใช้เฉพาะค่าดัชนีพืชพรรณที่ผ่านการทดสอบแล้วว่าเหมาะสมกับการจำแนกสุขภาพของป่าชายเลน ทั้งในรูปแบบเชิงพื้นที่และเชิงสถิติ ในส่วนของข้อมูลผลลัพธ์ (Output Class) กำหนดให้เป็นระดับสุขภาพของพืช ซึ่งจำแนกออกเป็น 3 กลุ่ม ได้แก่ สุขภาพดี สุขภาพไม่ดี และพื้นที่อื่น ๆ อ้างอิงจากการแปลภาพด้วยสายตาและผลการสำรวจภาคสนาม สำหรับการตั้งค่าพารามิเตอร์ของอัลกอริทึม RF ได้กำหนดจำนวนต้นไม้ตัดสินใจ (Decision Trees) เท่ากับ 400 ซึ่งเป็นค่าที่มากพอในการเพิ่มความเสถียรของแบบจำลอง โดยลดความแปรปรวนของผลลัพธ์ในแต่ละการสุ่ม และช่วยให้โมเดลสามารถเรียนรู้รูปแบบของข้อมูลได้อย่างครอบคลุม โดยไม่เกิดการ Overfitting มากเกินไป การกำหนดค่าในระดับนี้ถือว่าเหมาะสมต่อข้อมูลที่มีความหลากหลายเชิงสเปกตรัมจากหลายดัชนี (Saxena, 2024) กระบวนการประมวลผลทั้งหมดดำเนินการผ่านโปรแกรม Python ซึ่งเหมาะสมต่อการประยุกต์ใช้ในด้าน Machine Learning และการวิเคราะห์ข้อมูลเชิงพื้นที่ เพื่อเพิ่มความน่าเชื่อถือของผลการจำแนก และลดผลกระทบจากความไม่แน่นอนที่เกิดจากการสุ่มข้อมูลภายในอัลกอริทึม จึงได้ดำเนินการฝึกอัลกอริทึม RF ซ้ำหลายครั้ง โดยในแต่ละครั้งจะทำการฝึกจำนวน 50 รอบ ซึ่งในแต่ละรอบจะมีการฝึกและประเมินแบบจำลองใหม่ทั้งหมด จากนั้นจึงคัดเลือกโมเดลที่ให้ค่าความแม่นยำโดยรวม (Overall Accuracy) สูงที่สุด เพื่อใช้ในการจำแนกสุขภาพของป่าชายเลนในพื้นที่ศึกษาต่อไป

2) การเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (XGboost)

ในการศึกษานี้ ได้ทดลองใช้อัลกอริทึมการเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (XGBoost) เพื่อเปรียบเทียบประสิทธิภาพกับอัลกอริทึมอื่น ๆ โดย XGBoost เป็นเทคนิคการเรียนรู้แบบเสริมแรง (Boosting) ที่พัฒนาต่อยอดจาก Gradient Boosting Decision Tree (GBDT) ซึ่งทำงานโดยการเรียนรู้แบบสะสมข้อผิดพลาด (Residual Errors) จากแบบจำลองก่อนหน้า แล้วใช้แบบจำลองใหม่มาปรับปรุงการพยากรณ์ให้แม่นยำขึ้น โดยมีข้อได้เปรียบในด้านความเร็วในการประมวลผลและความสามารถในการจัดการกับข้อมูลที่ไม่สมดุล (Imbalanced Data) ได้อย่างมีประสิทธิภาพ ในการวิเคราะห์นี้ ข้อมูลนำเข้า (Input Features) ประกอบด้วยค่าดัชนีพืชพรรณที่ผ่าน

การทดสอบแล้วว่าเหมาะสมกับการจำแนกสุขภาพของป่าชายเลน ทั้งในรูปแบบเชิงพื้นที่และเชิงสถิติ เช่นเดียวกับที่ใช้ในอัลกอริทึม RF ในขณะที่ข้อมูลผลลัพธ์ (Output Class) แบ่งออกเป็น 3 กลุ่ม ได้แก่ สุขภาพดี สุขภาพไม่ดี และพื้นที่อื่น ๆ ซึ่งกำหนดจากการจำแนกด้วยสายตาและข้อมูลภาคสนาม การตั้งค่าพารามิเตอร์ของ XGBoost ดำเนินการโดยใช้ค่าพื้นฐานที่เหมาะสม ได้แก่ max_depth, learning_rate, และ n_estimators ซึ่งมีการปรับค่าทดลองเพื่อให้โมเดลสามารถเรียนรู้ข้อมูลได้ครอบคลุม และลดความเสี่ยงจาก Overfitting โดยกำหนด n_estimators เท่ากับ 400, max_depth เท่ากับ 4 และ learning_rate เท่ากับ 0.1 การวิเคราะห์ทั้งหมดประมวลผลด้วยภาษา Python เพื่อเพิ่มความน่าเชื่อถือของผลการจำแนก และลดผลกระทบจากความไม่แน่นอนที่เกิดจากการสุ่มข้อมูลภายในอัลกอริทึม จึงได้ดำเนินการฝึกอัลกอริทึม XGBoost ซ้ำหลายครั้ง จากนั้นจึงคัดเลือกโมเดลที่ให้ค่าความแม่นยำโดยรวม (Overall Accuracy) สูงที่สุด เพื่อใช้ในการจำแนกสุขภาพของป่าชายเลน เช่นเดียวกับอัลกอริทึม RF

3) เครื่องเวกเตอร์สนับสนุน (Support Vector Machine: SVM)

อัลกอริทึมเครื่องเวกเตอร์สนับสนุน (SVM) เป็นอัลกอริทึมที่ใช้สำหรับการจำแนกข้อมูลเชิงเส้นและไม่เชิงเส้น โดยอาศัยหลักการสร้างเส้นแบ่งข้อมูล (Hyperplane) ที่สามารถแยกกลุ่มข้อมูลออกจากกันได้อย่างมีประสิทธิภาพ ในการศึกษาครั้งนี้ SVM ถูกนำมาใช้เพื่อประเมินความสามารถในการจำแนกสุขภาพของพืชป่าชายเลนจากภาพถ่าย UAV ชุดข้อมูลนำเข้า (Input Features) ใช้ค่าดัชนีพืชพรรณที่ผ่านการทดสอบแล้ว เช่นเดียวกับโมเดลอื่น ส่วนข้อมูลผลลัพธ์ (Output Class) จำแนกสุขภาพเป็น 3 กลุ่ม ได้แก่ สุขภาพดี สุขภาพไม่ดี และพื้นที่อื่น ๆ โดยอ้างอิงจากการแปลภาพและการสำรวจภาคสนาม สำหรับการตั้งค่าพารามิเตอร์ของ SVM ได้ทำการปรับค่าพารามิเตอร์หลัก เช่น C และ gamma เพื่อเพิ่มประสิทธิภาพของโมเดลและลดปัญหา Overfitting โดยกำหนด C เท่ากับ 1.0 และ gamma เท่ากับ “scale” ซึ่งเป็นการปรับค่าตามลักษณะของข้อมูลอัตโนมัติ กระบวนการทั้งหมดดำเนินการผ่านภาษา Python ในการฝึกและประเมินโมเดล SVM โดยทำการเรียนรู้ซ้ำหลายรอบ เพื่อคัดเลือกโมเดลที่ให้ค่าความแม่นยำโดยรวม (Overall Accuracy) สูงที่สุด เพื่อใช้ในการจำแนกสุขภาพของป่าชายเลน เช่นเดียวกับอัลกอริทึมอื่น ๆ

4) การตรวจสอบความถูกต้อง

การประเมินความถูกต้องของผลการประมวลผลข้อมูลสำรวจระยะไกล เป็นกระบวนการเปรียบเทียบผลการจำแนกจากอัลกอริทึม กับข้อมูลภาคสนามจริงหรือข้อมูลสุขภาพของป่าชายเลนที่ตรวจสอบ ณ จุดตัวอย่าง ซึ่งถือเป็นข้อมูลอ้างอิง (Reference Data) หรือข้อมูลจริง (Ground Truth) จากนั้นจึงนำผลการเปรียบเทียบมาแสดงในรูปของตารางความคลาดเคลื่อน (Error Matrix) เพื่อประเมินระดับความแม่นยำของอัลกอริทึมที่ใช้ (รูปที่ 3.5) (กาญจน์เชจร ชูชีพ, 2565)

		Commission Errors →				
		Reference Data (Ex. Class form field)				
		Class 1	Class 2	Class k	Sum	
← Omission Errors	Classified Data	Class 1	n_{11}	n_{12}	n_{1k}	n_{1+}
		Class 2	n_{21}	n_{22}	n_{2k}	n_{2+}
		.	.	.	.	.
		.	.	.	.	.
		.	.	.	.	.
		Class k	n_{k1}	n_{k2}	n_{kk}	n_{k+}
Sum		n_{+1}	n_{+2}	n_{+k}	n	

รูปที่ 3.7 รูปแบบตาราง Error Matrix

โดยจากตาราง Error Matrix สามารถวิเคราะห์ความถูกต้องในดังนี้

4.1) ความถูกต้องโดยรวม (Overall Accuracy)

เป็นการแสดงความถูกต้องของอัลกอริทึมสำหรับประมาณค่าระดับคุณภาพ โดยตรวจสอบความถูกต้องระหว่าง จำนวนจุดตรวจสอบข้อมูลตัวประมาณค่า (Estimate) กับ จำนวนจุดตรวจสอบข้อมูลภาคสนาม ที่ถูกต้องตรงกันคิดเป็นเปอร์เซ็นต์ ไม่คำนึงความถูกต้องของแต่ละชั้นข้อมูล (Class) โดยสรุปแล้ว เป็นการประเมินค่าความถูกต้องแบบโดยรวม โดยพิจารณาจากผลการประมาณค่าของทุกชั้นข้อมูลรวมกัน เพื่อให้ได้ค่าความถูกต้องเพียงค่าเดียวที่สะท้อนภาพรวมของการจำแนก สามารถคำนวณได้ดังสมการที่ 3.1 (กาญจน์เชจร ชูชีพ, 2565)

$$OA = \frac{\sum_{i=1}^k n_{ii}}{n} \times 100 \quad (\text{สมการที่ 3.1})$$

OA = Overall Accuracy

n = จำนวนจุดตรวจสอบทั้งหมด

n_{ii} = จำนวนจุดตรวจสอบที่ถูกต้องของแต่ละชั้นข้อมูล

4.2) ความถูกต้องของผู้ผลิต (Producer's Accuracy)

เป็นการแสดงให้เห็นถึงความถูกต้องของแต่ละชั้นข้อมูล (Class) สะท้อนให้เห็นประสิทธิภาพของตัวประมาณค่าว่าสามารถประมาณค่าได้ดีมากน้อยเพียงใด โดยมองในมุมมองข้อมูลภาคสนาม (Ground Truth) หรือข้อมูลอ้างอิง (Reference Data) คิดเป็นเปอร์เซ็นต์ สามารถคำนวณได้ดังสมการที่ 3.2 (กาญจน์เชจร ชูชีพ, 2565)

$$PA = \frac{n_{ii}}{n_{+i}} \times 100 \quad (\text{สมการที่ 3.2})$$

PA = Producer's Accuracy

n_{ii} = จำนวนจุดตรวจสอบที่ถูกต้องของแต่ละชั้นข้อมูล

n_{+i} = จำนวนจุดตรวจสอบข้อมูลภาคสนามของแต่ละชั้นข้อมูลทั้งหมด

4.3) ความถูกต้องของผู้ใช้ (User's Accuracy)

เป็นการแสดงให้เห็นถึงความถูกต้องของแต่ละชั้นข้อมูล (Class) บ่งบอกความน่าเชื่อถือในแต่ละชั้นข้อมูล (Class) ว่ามีความถูกต้องมากแค่ไหน โดยมองในมุมของข้อมูลตัวประมาณค่า (Estimate) ว่าสามารถประมาณค่าออกมาได้ดีมากน้อยแค่ไหน คิดเป็นเปอร์เซ็นต์สามารถคำนวณได้ดังสมการที่ 3.3 (กาญจน์เชจร ชูชีพ, 2565)

$$UA = \frac{n_{ii}}{n_{i+}} \times 100 \quad (\text{สมการที่ 3.3})$$

UA = User's Accuracy

n_{ii} = จำนวนจุดตรวจสอบที่ถูกต้องของแต่ละชั้นข้อมูล

n_{i+} = จำนวนจุดตรวจสอบข้อมูลตัวประมาณค่าของแต่ละชั้นข้อมูลทั้งหมด

4.4) ค่าสถิติแคปปา (Kappa Statistic)

เป็นค่าที่แสดงถึงความถูกต้องโดยรวมเช่นกัน แต่มีการพิจารณาความผิดพลาดที่เกิดขึ้นใน Error Matrix และมีการพิจารณาทั้งความสอดคล้องระหว่างข้อมูลตัวประมาณค่า (Estimate) กับข้อมูลภาคสนาม (Ground Truth) มักวิเคราะห์เพื่อแสดงควบคู่กับค่าความถูกต้องโดยรวม โดยหากค่าทั้ง 2 มีค่าใกล้เคียงกันไปในทิศทางสูง แสดงว่าผลการจำแนกข้อมูลมีความแม่นยำและสอดคล้องกับข้อมูลจริง ในระดับที่น่าเชื่อถือ ดังนั้น แม้ว่าค่าความถูกต้องโดยรวม (Overall Accuracy) จะอยู่ในระดับสูง แต่ไม่ได้แสดงว่าผลการจำแนกมีความน่าเชื่อถือเสมอไป หากค่า Kappa อยู่ในระดับต่ำ ซึ่งสะท้อนถึงความไม่สอดคล้องของผลการจำแนก และอาจบ่งชี้ถึงความผันผวนหรือความไม่แน่นอนในการประมาณค่า ทั้งนี้ ในการแปลผลค่า Kappa ในการศึกษานี้ ได้พิจารณาตามเกณฑ์ของ Roldán-Nofuentes และ Regad (2021) ซึ่งแบ่งช่วงค่าออกเป็น 5 ระดับ ได้แก่ 0.00 ถึง

0.20 หมายถึงความสอดคล้องเล็กน้อย, 0.21 ถึง 0.40 หมายถึงความสอดคล้องปานกลาง, 0.41 ถึง 0.60 หมายถึงความสอดคล้องพอใช้, 0.61 ถึง 0.80 หมายถึงความสอดคล้องดี, และ 0.81 ถึง 1.00 หมายถึงความสอดคล้องดีมาก สามารถคำนวณได้ดังสมการที่ 3.4 (กาญจน์เชจร ชูชีพ, 2565)

$$Khat = \frac{(n \sum_{i=1}^k n_{ii}) - \sum_{i=1}^k n_{i+} n_{+i}}{n^2 - \sum_{i=1}^k n_{i+} n_{+i}} \quad (\text{สมการที่ 3.4})$$

Khat	=	Kappa Statistic
n	=	จำนวนจุดตรวจสอบทั้งหมด
n_{ij}	=	จำนวนจุดตรวจสอบที่ถูกต้องตรงกัน
n_{i+} , n_{+i}	=	จำนวนจุดตรวจสอบข้อมูลตัวประมาณค่าและ ข้อมูลภาคสนามของแต่ละชั้นข้อมูลทั้งหมด

บทที่ 4

ผลการศึกษาและอภิปรายผล

4.1 การจำแนกสุขภาพป่าชายเลนจากข้อมูลภาคสนาม

รูปที่ 4.1 แสดงตำแหน่งจุดเก็บตัวอย่างใบไม้ในพื้นที่ป่าชายเลนคลองเกาะผี สามารถเก็บข้อมูลจริงได้ 22 จุด โดยจำแนกออกเป็น 2 กลุ่ม ได้แก่ ใบไม้ที่มีสุขภาพดี (จุดสีน้ำเงิน) และใบไม้ที่มีสุขภาพไม่ดี (จุดสีแดง) ซึ่งได้จากการประเมินสุขภาพเบื้องต้นในภาคสนามโดยพิจารณาจากลักษณะทางสัณฐานวิทยา จากนั้นได้นำตัวอย่างใบไม้ทั้งหมดวิเคราะห์ค่าการสะท้อนแสงของตัวอย่างใบไม้แต่ละกลุ่มเป็นค่า Digital Number (DN) ด้วยเครื่อง Spectroradiometer ครอบคลุมช่วงคลื่น 350–1075 นาโนเมตร เพื่อวิเคราะห์ลักษณะการสะท้อนแสงเชิงสเปกตรัมของใบไม้ ผลการจำแนกสุขภาพป่าชายเลนจากข้อมูลภาคสนาม (รูปที่ 4.2) โดยเป็นกราฟแสดงค่าเฉลี่ยของ DN ตามช่วงความยาวคลื่นของตัวอย่างใบไม้จากป่าชายเลน แบ่งออกเป็น 2 กลุ่ม ได้แก่ ใบไม้สุขภาพดี (เส้นสีเขียวทึบ) และใบไม้สุขภาพไม่ดี (เส้นประสีแดง) พร้อมแสดงแถบค่าเบี่ยงเบนมาตรฐาน (Standard Deviation: STD) เป็นพื้นที่แรเงาสีสำหรับแต่ละกลุ่ม จากกราฟพบว่าในช่วง Green (500–565 nm) ค่า DN ของใบไม้สุขภาพดีสูงกว่าใบไม้สุขภาพไม่ดีเพียงเล็กน้อย ในช่วง Red Edge (688–760 nm) ความแตกต่างของค่า DN ระหว่างสองกลุ่มมีความชัดเจนมาก โดยกลุ่มสุขภาพดีมีค่า DN และค่า STD สูงกว่าอย่างชัดเจน ส่งผลให้สามารถแยกแยะทั้งสองกลุ่มได้อย่างแม่นยำ ทำให้ไม่เกิดความสับสนระหว่าง 2 กลุ่ม และในช่วง Near Infrared (NIR ตั้งแต่ 800 nm เป็นต้นไป) แม้ค่า DN มีแนวโน้มลดลง แต่ใบไม้สุขภาพดียังคงแสดงค่าที่สูงกว่ากลุ่มสุขภาพไม่ดีอย่างต่อเนื่อง ผลการวิเคราะห์ดังกล่าวชี้ให้เห็นถึงศักยภาพของข้อมูลเชิงสเปกตรัม โดยเฉพาะในช่วง Red Edge และ NIR ในการจำแนกสุขภาพของใบไม้ในป่าชายเลน สามารถแบ่งกลุ่มออกเป็น 2 กลุ่ม ได้แก่ ใบไม้สุขภาพดีและใบไม้สุขภาพไม่ดี ได้อย่างชัดเจน

จากผลการจำแนกสุขภาพของใบไม้จากการลงพื้นที่ภาคสนาม (รูปที่ 4.1) และการวิเคราะห์ค่าการสะท้อน DN ตามช่วงสเปกตรัม (รูปที่ 4.2) พบความแตกต่างอย่างชัดเจนระหว่างกลุ่มสุขภาพดีและสุขภาพไม่ดี โดยเฉพาะในช่วงความยาวคลื่น Red Edge และ NIR ซึ่งกลุ่มสุขภาพดีแสดงค่า DN ที่สูงกว่าต่อเนื่อง การวิเคราะห์นี้ได้รับการสนับสนุนเพิ่มเติมจากการเปรียบเทียบตำแหน่งและสุขภาพ


ของตัวอย่างใบไม้จากพื้นที่ภาคสนาม ลักษณะภายนอกของใบไม้จากภาพถ่าย UAV ความละเอียดสูง และค่าการสะท้อน DN จากเครื่อง Spectroradiometer (รูปที่ 4.3) ซึ่งพบว่าลักษณะและสีของใบไม้ กับค่าการสะท้อน DN มีความสอดคล้องกัน โดยกลุ่มใบไม้ที่มีสีเขียวเข้มสอดคล้องกับจุดสุภาพดี และมีค่า DN สูง ขณะที่กลุ่มใบไม้ที่มีสีซีด เหลือง หรือเขียวอ่อนปนเหลือง สอดคล้องกับจุดสุภาพไม่ดี และมีค่า DN ต่ำ ทั้งนี้ ตารางที่ 4.1 แสดงการเปรียบเทียบสุภาพของพืชที่ได้จากค่าการสะท้อน และการตีความด้วยสายตา โดยส่วนใหญ่มีความสอดคล้องกัน ผลการวิเคราะห์ดังกล่าวช่วยยืนยันความถูกต้องของการจำแนกสุภาพพืชป่าชายเลนด้วยสายตาจากภาพถ่าย UAV ของผู้วิจัยได้อย่างมีนัยสำคัญ


ตารางที่ 4.1 การเปรียบเทียบสุภาพของพืชที่ได้จากค่าการสะท้อน DN และการตีความด้วยสายตาจากภาพถ่ายทางอากาศ

จุด	สุภาพจากค่า การสะท้อน DN	สุภาพจากการแปล ตีความด้วยสายตา
A001	ไม่ดี	ไม่ดี
A003	ดี	ไม่ดี
A005	ไม่ดี	ไม่ดี
A006	ดี	ดี
A009	ไม่ดี	ไม่ดี
A011	ดี	ดี
A013	ไม่ดี	ไม่ดี
A014	ไม่ดี	ไม่ดี
A015	ดี	ดี
A018	ไม่ดี	ไม่ดี
A019	ดี	ดี
A023	ดี	ดี
A025	ไม่ดี	ไม่ดี
A026	ไม่ดี	ไม่ดี
A027	ดี	ดี
A029	ไม่ดี	ไม่ดี
A036	ดี	ดี

ตารางที่ 4.1 การเปรียบเทียบสุขภาพของพืชที่ได้จากค่าการสะท้อน DN และการตีความด้วยสายตาจากภาพถ่ายทางอากาศ (ต่อ)

จุด	สุขภาพจากค่า	สุขภาพจากการแปล
	การสะท้อน DN	ตีความด้วยสายตา
A037	ไม่ดี	ไม่ดี
A042	ไม่ดี	ไม่ดี
A044	ไม่ดี	ไม่ดี
A046	ไม่ดี	ไม่ดี
A048	ไม่ดี	ไม่ดี





รูปที่ 4.2 ค่า DN ของตัวอย่างใบไม้ในป่าชายเลน ตามความยาวช่วงคลื่น (เขตสีแดง ได้จากใบไม้ที่สุขภาพไม่ดี และ เขตสีเขียว ได้จากใบไม้ที่สุขภาพดี)




รูปที่ 4.3 ความสัมพันธ์ระหว่างตำแหน่งตัวอย่างใบไม้ ลักษณะทางสายตา และค่าการสะท้อนเชิงสเปกตรัมของพืชป่าชายเลน

จากผลการศึกษาการจำแนกสุขภาพป่าชายเลนจากข้อมูลภาคสนาม การวางจุดตัวอย่างของกลุ่มสุขภาพใบไม้ดีและไม่ดี ควรมีความใกล้เคียงกันทั้งในด้านจำนวนและตำแหน่งเชิงพื้นที่ เพื่อหลีกเลี่ยงความไม่สมดุลของข้อมูล ซึ่งอาจส่งผลให้เกิดความลำเอียงของโมเดล (Model Bias) และทำให้ความแม่นยำของผลการจำแนกลดลง

4.2 ผลการจำแนกสุขภาพด้วยสายตาจากภาพถ่ายทางอากาศ

จากการจำแนกสุขภาพของเรือนยอดป่าชายเลนโดยใช้วิธีการแปลภาพด้วยสายตา จากภาพถ่าย UAV ทั้งในช่วงฤดูร้อนและฤดูฝน บริเวณพื้นที่สร้างโมเดล สามารถจำแนกสุขภาพของเรือนยอดออกเป็น 2 กลุ่ม ได้แก่ สุขภาพดี (ขอบสีดำ) และสุขภาพไม่ดี (ขอบสีชมพู) (รูปที่ 4.4) โดยอ้างอิงจากลักษณะภายนอกของทรงพุ่มในภาพถ่ายความละเอียดสูง (รูปที่ 3.6) ซึ่งสะท้อนถึงคุณลักษณะของใบสี และความหนาแน่นของเรือนยอด ผลการศึกษาพบว่า กลุ่มสุขภาพดีมีแนวโน้มกระจายตัวอยู่มากในบริเวณฝั่งตะวันตกของพื้นที่สร้างโมเดล ซึ่งมีลักษณะเรือนยอดหนาแน่นและใบสีเขียวเข้ม ขณะที่กลุ่มสุขภาพไม่ดีมีการกระจายตัวชัดเจนในบริเวณตอนกลางและค่อนข้างไปทางตะวันออก ซึ่งลักษณะใบมีสีซีด เทียบอ่อนปนเหลือง เหลือง และเรือนยอดโปร่ง ทั้งนี้ ข้อมูลจากการจำแนกสุขภาพด้วยสายตาก็เป็นข้อมูลภาคสนามที่มีความแม่นยำ โดยทั้งสองฤดูกาล มีจำนวนข้อมูลทั้งหมดดังนี้: กลุ่มสุขภาพดีจำนวน 697 จุด สุขภาพไม่ดีจำนวน 537 จุด และพื้นที่อื่น ๆ จำนวน 170 จุด รวมทั้งสิ้น 1,404 จุด ซึ่งถูกนำมาใช้เป็นข้อมูลอ้างอิงในการวิเคราะห์ค่าดัชนีพืชพรรณรายจุด พร้อมทั้งแสดงผลในเชิงพื้นที่และเชิงสถิติด้วยกราฟ Box plot เพื่อประเมินความสามารถของแต่ละดัชนี และคัดเลือกดัชนีที่เหมาะสมที่สุดในการจำแนกกลุ่มสุขภาพป่าชายเลน จากนั้น ข้อมูลทั้งหมดจำนวน 1,404 จุด ถูกแบ่งออกเป็นชุดข้อมูลฝึกซ้อม (training data) ร้อยละ 70 คิดเป็น 983 จุด และชุดข้อมูลทดสอบ (testing data) ร้อยละ 30 คิดเป็น 422 จุด เพื่อใช้ในการพัฒนาและประเมินประสิทธิภาพของอัลกอริทึม




รูปที่ 4.4 แผนที่การจำแนกสุขภาพของเรือนยอดป่าชายเลนโดยใช้วิธีการแปลภาพด้วยสายตา จากภาพถ่าย UAV ทั้งในช่วงฤดูร้อนและฤดูฝน

4.3 การจำแนกสุขภาพป่าชายเลนจากข้อมูลดัชนีพืชพรรณ







ในการศึกษานี้ ได้ทำการประเมินศักยภาพของดัชนีพืชพรรณจำนวน 16 ดัชนี ได้แก่ NDVI, GNDVI, NDWI, SAVI, EVI, NDRE, NDI, TCARI, RECI, CCCI, GCC, VDMI, MTCI, ExG, PSRI และ VARI ในการจำแนกความแตกต่างระหว่างกลุ่มพืชที่มีสุขภาพดีและสุขภาพไม่ดี โดยใช้ข้อมูลจากภาพถ่ายทางอากาศที่ได้จากอากาศยานไร้คนขับ (UAV) และดัชนีแต่ละตัวมีการใช้ช่วงค่าเดียวกันใน

ทั้งสองฤดูกาล ผลการวิเคราะห์จากแผนที่เชิงพื้นที่ (ตารางที่ 4.2) และกราฟ Box Plot (ตารางที่ 4.3) พบว่า มีเพียง 6 ดัชนี ได้แก่ GNDVI, NDWI, NDRE, CCCI, ExG และ MTCI ที่สามารถแสดงความแตกต่างระหว่างกลุ่มพืชที่มีสุขภาพดีและสุขภาพไม่ดี ได้อย่างชัดเจนทั้งในเชิงพื้นที่และเชิงสถิติ โดยเฉพาะอย่างยิ่งในบริบทของป่าชายเลน ซึ่งมีความซับซ้อนทางโครงสร้างและความหลากหลายทางสภาพแวดล้อมสูง ต่อมาได้มีการวิเคราะห์ความสัมพันธ์ของดัชนีพืชพรรณทั้ง 6 ดัชนี ในฤดูร้อนและฤดูฝน (รูปที่ 4.3) ผลการวิเคราะห์พบว่า CCCI, NDRE และ MTCI แสดงค่าความสัมพันธ์ระหว่างฤดูกาลในระดับสูง ($R^2 > 0.70$) สะท้อนถึงความเสถียรของค่าการสะท้อนแสงในช่วงคลื่นที่เกี่ยวข้องกับปริมาณคลอโรฟิลล์ ขณะที่ GNDVI และ NDWI แสดงความสัมพันธ์ในระดับปานกลาง ($R^2 \approx 0.49$) ส่วน ExG แม้ว่าจะแสดงค่าความสัมพันธ์ระหว่างฤดูกาลในระดับต่ำ ($R^2 \approx 0.27$) แต่จากการวิเคราะห์เชิงพื้นที่และเชิงสถิติพบว่า ดัชนีนี้ยังคงสามารถแยกความแตกต่างระหว่างกลุ่มพืชได้อย่างชัดเจนภายในฤดูกาล จึงถือว่ายังมีคุณค่าทางข้อมูล และมีศักยภาพในการใช้งานร่วมกับดัชนีอื่น ๆ จากผลการวิเคราะห์ทั้งหมด ดัชนีทั้ง 6 ตัวจึงได้รับการคัดเลือกให้ใช้เป็น ชุดข้อมูลนำเข้า (Input Features) ร่วมกับข้อมูลภาคสนามสำหรับการฝึกโมเดลการเรียนรู้ของเครื่อง (Machine Learning) เพื่อใช้ในการจำแนกสุขภาพของป่าชายเลน





ตารางที่ 4.2 ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน

สมการ	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูร้อน	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูฝน
$NDVI = \frac{NIR - R}{NIR + R}$ ช่วงค่า: -0.13 ถึง 0.98		
$GNDVI = \frac{NIR - G}{NIR + G}$ ช่วงค่า: -0.37 ถึง 0.94		








ตารางที่ 4.2 ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูร้อน	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูฝน
$NDWI = \frac{G - NIR}{G + NIR}$ ช่วงค่า -0.94 ถึง 0.37		
$SAVI = \left(\frac{NIR - R}{NIR + R + L} \right) \times (1 + L)$ ช่วงค่า: -0.03 ถึง 0.52		
$EVI = \frac{2.5(NIR - R)}{(NIR + 6R + 7.5B + 1)}$ ช่วงค่า: -0.001 ถึง 0.03		
$NDRE = \frac{NIR - R_{edge}}{NIR + R_{edge}}$ ช่วงค่า: -0.78 ถึง 0.87		




ตารางที่ 4.2 ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูร้อน	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูฝน
$NDI = \frac{R_{edge} - R}{R_{edge} + R}$ ช่วงค่า: -0.29 ถึง 0.96		
$TCARI = \frac{3 \times \{[(R_{edge} - R) - 0.2(R_{edge} - G)] \times \frac{R_{edge}}{R}\}}{R}$ ช่วงค่า: -0.004 ถึง 0.4		
$RECI = (NIR - R_{edge}) - 1$ ช่วงค่า: -1.003 ถึง -0.99		
$CCCI = \left(\frac{NIR - R_{edge}}{NIR + R_{edge}} \right) \div \left(\frac{NIR - R}{NIR + R} \right)$ ช่วงค่า: 0.0004 ถึง 0.99		

ตารางที่ 4.2 ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูร้อน	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูฝน
$GCC = \frac{G}{R + G + B}$ ช่วงค่า: 0.11 ถึง 0.72		
$VDVI = \frac{2G - B - R}{2G + B + R}$ ช่วงค่า: -0.6 ถึง 0.67		
$MTCI = \frac{NIR - R_{edge}}{R_{edge} - R}$ ช่วงค่า: 0 ถึง 1.6		
$ExG = 2G - R - B + 50$ ช่วงค่า: 49.99 ถึง 50		

ตารางที่ 4.2 ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูร้อน	ดัชนีจากภาพถ่ายโดรน ช่วงฤดูฝน
$PSRI = \frac{R - B}{R_{edge}}$ ช่วงค่า: -5.81 ถึง 1.24		
$VARI = \frac{G - R}{G + R - B}$ ช่วงค่า: -1 ถึง 1		

ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน

สมการ	กราฟ Box plot ดัชนีจากภาพถ่าย โตรน ช่วงฤดูร้อน	กราฟ Box plot ดัชนีจากภาพถ่าย โตรน ช่วงฤดูฝน
$NDVI = \frac{NIR - R}{NIR + R}$	NDVI_Summer	NDVI_Rains
$GNDVI = \frac{NIR - G}{NIR + G}$	GNDVI_Summer	GNDVI_Rains
$NDWI = \frac{G - NIR}{G + NIR}$	NDWI_Summer	NDWI_Rains

ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูร้อน	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูฝน
$SAVI = \left(\frac{NIR - R}{NIR + R + L} \right) \times (1 + L)$	SAVI_Summer	SAVI_Rains
$EVI = \frac{2.5(NIR - R)}{(NIR + 6R + 7.5B + 1)}$	EVI_Summer	EVI_Rains
$NDRE = \frac{NIR - R_{edge}}{NIR + R_{edge}}$	NDRE_Summer	NDRE_Rains

ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูร้อน	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูฝน
$NDI = \frac{R_{edge} - R}{R_{edge} + R}$	NDI_Summer	NDI_Rains
$TCARI = 3 \times \{[(R_{edge} - R) - 0.2(R_{edge} - G)] \times \frac{R_{edge}}{R}\}$	TCARI_Summer	TCARI_Rains
$RECI = (NIR - R_{edge}) - 1$	RECI_Summer	RECI_Rains

ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)


สมการ	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูร้อน	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูฝน
$CCCI = \left(\frac{NIR - R_{edge}}{NIR + R_{edge}} \right) \div \left(\frac{NIR - R}{NIR + R} \right)$	CCCI_Summer	CCCI_Rains
$GCC = \frac{G}{R + G + B}$	GCC_Summer	GCC_Rains
$VDVI = \frac{2G - B - R}{2G + B + R}$	VDVI_Summer	VDVI_Rains

ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูร้อน	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูฝน
$MTCI = \frac{NIR - R_{edge}}{R_{edge} - R}$	MTCI_Summer	MTCI_Rains
$ExG = 2G - R - B + 50$	ExG_Summer	ExG_Rains
$PSRI = \frac{R - B}{R_{edge}}$	PSRI_Summer	PSRI_Rains

ตารางที่ 4.3 กราฟ Box Plot ดัชนีพืชพรรณจากภาพถ่ายทางอากาศ ในช่วงฤดูร้อนและฤดูฝน (ต่อ)

สมการ	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูร้อน	กราฟ Box plot ดัชนีจากภาพถ่าย โดรน ช่วงฤดูฝน
$VARI = \frac{G - R}{G + R - B}$	VARI_Summer Value 0.9 0.85 0.8 0.75 0.7 0.65 0.6 0.55 0.5 0.45 0.4 ■ ไม่ดี ■ ดี	VARI_Rains Value 1.2 1.1 1.0 0.9 0.8 0.7 0.6 ■ ไม่ดี ■ ดี



รูปที่ 4.5 กราฟความสัมพันธ์ระหว่างฤดูร้อนและฤดูฝนของดัชนีพืชพรรณทั้ง 6 ดัชนี ได้แก่ GNDVI, NDWI, NDRE, CCCI, ExG และ MTCTI

4.4 ผลการจำแนกสุขภาพของป่าชายเลนจากโมเดล

4.4.1 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล จากโมเดล XGboost (XGB)


การจำแนกสุขภาพของป่าชายเลนด้วยโมเดล XGB ในพื้นที่สร้างโมเดล (ตารางที่ 4.4) ผลการศึกษาพบว่าโมเดลสามารถจำแนกกลุ่ม “พื้นที่อื่น ๆ” ได้อย่างแม่นยำที่สุด โดยมีค่า Producer’s Accuracy เท่ากับ 95% และ User’s Accuracy เท่ากับ 91% สะท้อนถึงความสามารถของอัลกอริทึมในการแยกพื้นที่ที่ไม่ใช่ป่าชายเลนออกจากกลุ่มเป้าหมายได้อย่างมีประสิทธิภาพ ส่วนการจำแนกกลุ่ม “ป่าชายเลนสุขภาพดี” และ “ป่าชายเลนสุขภาพไม่ดี” มีความแม่นยำในระดับปานกลาง โดยกลุ่มสุขภาพดีมีค่า Producer’s Accuracy เท่ากับ 68% และ User’s Accuracy 69% ส่วนกลุ่มสุขภาพไม่ดีมีค่า Producer’s Accuracy 63% และ User’s Accuracy 62% ซึ่งแสดงให้เห็นว่าการจำแนกระหว่างกลุ่มสุขภาพดีและไม่ดีของโมเดล XGB มีแนวโน้มเกิดความคลาดเคลื่อนได้บ้าง โดยเฉพาะในบริเวณที่มีโครงสร้างของเรือนยอดคล้ายกันหรือมีค่าดัชนีพืชพรรณใกล้เคียงกัน อย่างไรก็ตาม โมเดลยังสามารถจำแนกภาพรวมของพื้นที่ได้ในระดับที่ยอมรับได้ โดยมีค่า Overall Accuracy เท่ากับ 69% และค่า Kappa เท่ากับ 0.47 ซึ่งความสอดคล้องอยู่ในระดับพอใช้ ทั้งนี้ การจำแนกสุขภาพเชิงพื้นที่ของป่าชายเลน โดยใช้โมเดล XGB ทั้งฤดูร้อนและฤดูฝน จำแนกออกเป็น 3 กลุ่ม ได้แก่ สุขภาพดี (สีเขียว), สุขภาพไม่ดี (สีเหลือง) และพื้นที่อื่น ๆ (สีแดง) เมื่อเปรียบเทียบกับข้อมูลอ้างอิงจากการแปลภาพด้วยสายตา (ขอบสีดำและชมพู) (รูปที่ 4.6) ผลการศึกษาพบว่า พื้นที่สุขภาพดี มีการกระจายตัวอยู่ทางด้านตะวันตกของพื้นที่ โดยเฉพาะในฤดูฝนที่โมเดลสามารถจำแนกพื้นที่กลุ่มนี้ได้ครอบคลุมกว่าฤดูร้อน ส่วนพื้นที่สุขภาพไม่ดี มีแนวโน้มกระจุกตัวในบริเวณตอนกลางถึงตะวันออกของพื้นที่ โดยเฉพาะในฤดูร้อนที่มีการกระจายของพื้นที่สีเหลืองชัดเจน และพื้นที่อื่น ๆ (สีแดง) ถูกจำแนกได้ดีตามขอบเขตป่าชายเลนและพื้นที่โล่ง ซึ่งให้เห็นว่าโมเดลสามารถแยกแยะพื้นที่นอกกลุ่มเป้าหมายได้อย่างมีประสิทธิภาพ ลักษณะการกระจายของสีในภาพยังสะท้อนถึงผลที่ปรากฏในตารางที่ 4.4 โดยเฉพาะความสัมพันธ์ระหว่างกลุ่มสุขภาพดีและสุขภาพไม่ดีที่เกิดขึ้นบริเวณรอยต่อของเรือนยอด ซึ่งเป็นพื้นที่ที่มีความแปรผันด้านโครงสร้างของเรือนยอดสูง และอาจมีค่าดัชนีพืชพรรณที่ทับซ้อนกัน ทำให้โมเดลเกิดการตีความคลาดเคลื่อนได้เช่นกัน

แม้ว่าค่า Overall Accuracy (69%) ของโมเดล XGBoost จะอยู่ในระดับปานกลางค่อนข้างดี แต่เมื่อตรวจสอบรายละเอียดจากตาราง Error Matrix (ตารางที่ 4.4) พบว่า ความแม่นยำโดยรวมอาจได้รับอิทธิพลจากคลาส “พื้นที่อื่น ๆ” ซึ่งมีจำนวนจุดน้อย (44 จุด) แต่มีอัตราการจำแนกถูกต้องสูงถึง 91% (42 จุด) จึงส่งผลให้ค่า OA สูงกว่าความเป็นจริง อย่างไรก็ตาม กลุ่มป่าชายเลนสุขภาพดีและสุขภาพไม่ดี ซึ่งเป็นกลุ่มหลักในการจำแนก กลับมีจำนวนจุดที่จำแนกผิดรวมกันถึง 127 จุด (63

และ 64 จุดตามลำดับ) สะท้อนให้เห็นถึงข้อจำกัดของโมเดลในการจำแนกความแตกต่างระหว่างกลุ่มเหล่านี้ได้อย่างชัดเจน ส่งผลให้ค่าความสอดคล้อง Kappa อยู่ในระดับปานกลาง (0.47) ซึ่งหมายถึงระดับความแม่นยำของโมเดลอาจยังไม่สอดคล้องกับข้อมูลจริงในระดับที่น่าเชื่อถืออย่างเต็มที่

ตารางที่ 4.4 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล XGboost ในพื้นที่สร้างโมเดล

กลุ่ม	ป่าชายเลน สุขภาพดี	ป่าชายเลน สุขภาพไม่ดี	พื้นที่ อื่น ๆ	ผลรวม จุด	User's Accuracy (%)
ป่าชายเลนสุขภาพดี	143	62	1	206	69
ป่าชายเลนสุขภาพไม่ดี	63	106	1	170	62
พื้นที่อื่น ๆ	3	1	42	46	91
ผลรวมจุด	209	169	44	422	
Producer's Accuracy (%)	68	63	95		
Overall Accuracy (%)			69		
Kappa (Khat)			0.47		



รูปที่ 4.6 แผนที่การจำแนกสุขภาพของโมเดล XGboost ป่าชายเลนคลองเกาะผีในพื้นที่สร้างโมเดล ช่วงฤดูร้อนและฤดูฝน


4.4.2 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล จากโมเดล Support Vector Machine (SVM)

การจำแนกสุขภาพของป่าชายเลนด้วยโมเดล SVM ในพื้นที่สร้างโมเดล (ตารางที่ 4.5) ผลการศึกษาพบว่า โมเดลสามารถจำแนกสุขภาพของพืชในระดับที่น่าพอใจ โดยให้ค่าความแม่นยำโดยรวม (Overall Accuracy) เท่ากับ 71% และค่า Kappa เท่ากับ 0.49 ซึ่งสะท้อนถึงระดับความสอดคล้องพอใช้ระหว่างผลจำแนกกับข้อมูลจริง ส่วนการจำแนกกลุ่ม “ป่าชายเลนสุขภาพดี” โมเดลให้ค่า Producer’s Accuracy เท่ากับ 77% และ User’s Accuracy เท่ากับ 69% แสดงถึง

ความสามารถในการระบุกลุ่มสุขภาพดีได้ค่อนข้างแม่นยำ ส่วนกลุ่ม “ป่าชายเลนสุขภาพไม่ดี” โมเดลให้ค่า Producer’s Accuracy เท่ากับ 62% และ User’s Accuracy เท่ากับ 63% ซึ่งอยู่ในระดับพอใช้ แต่ยังสามารถจำแนกได้ในระดับหนึ่ง และกลุ่ม “พื้นที่อื่น ๆ” ซึ่งรวมถึงพื้นที่ที่ไม่ใช่ทรงพุ่มของป่าชายเลน เช่น ถนน สิ่งปลูกสร้าง หรือพื้นที่โล่ง โมเดลสามารถจำแนกได้อย่างแม่นยำ โดยให้ค่า Producer’s Accuracy เท่ากับ 75% และ User’s Accuracy สูงถึง 97% แสดงถึงประสิทธิภาพของโมเดล SVM ในการแยกแยะพื้นที่นอกกลุ่มเป้าหมายได้ดี การจำแนกสุขภาพเชิงพื้นที่ของป่าชายเลนโดยใช้โมเดล SVM ทั้งฤดูร้อนและฤดูฝน จำแนกออกเป็น 3 กลุ่ม ได้แก่ สุขภาพดี (สีเขียว), สุขภาพไม่ดี (สีเหลือง) และพื้นที่อื่น ๆ (สีแดง) โดยเปรียบเทียบกับข้อมูลการจำแนกด้วยสายตา (ขอบสีดำและชมพู) (รูปที่ 4.7) ผลการศึกษาพบว่า กลุ่มสุขภาพดีมีการกระจายอยู่หนาแน่นบริเวณตะวันตกของพื้นที่ โดยเฉพาะในช่วงฤดูฝน มีการกระจายตัวของพื้นที่สุขภาพดีที่ชัดเจน ส่วนกลุ่มสุขภาพไม่ดีมีการกระจายตัวอยู่หนาแน่นบริเวณตอนกลางของพื้นที่ โดยเฉพาะในช่วงฤดูร้อน และกลุ่มพื้นที่อื่น ๆ มักปรากฏในลักษณะกระจุกเล็ก ๆ กระจายทั่วพื้นที่ โดยเฉพาะบริเวณที่เป็นพื้นที่โล่ง แนวขอบเขตของพื้นที่ศึกษาหรือรอยต่อกับสิ่งปลูกสร้างและถนน ซึ่งมักไม่แสดงลักษณะทรงพุ่มของพืชพรรณ

ตารางที่ 4.5 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล SVM ในพื้นที่สร้างโมเดล

กลุ่ม	ป่าชายเลน สุขภาพดี	ป่าชายเลน สุขภาพไม่ดี	พื้นที่ อื่น ๆ	ผลรวม จุด	User's Accuracy (%)
ป่าชายเลนสุขภาพดี	161	64	10	235	69
ป่าชายเลนสุขภาพไม่ดี	47	105	1	153	69
พื้นที่อื่น ๆ	1	0	33	34	97
ผลรวมจุด	209	169	44	422	
Producer's Accuracy (%)	77	62	75		
Overall Accuracy (%)			71		
Kappa (Khat)			0.49		



รูปที่ 4.7 แผนที่การจำแนกสุขภาพของโมเดล SVM ป่าชายเลนคลองเกาะผีในพื้นที่สร้างโมเดล ช่วงฤดูร้อนและฤดูฝน


4.4.3 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล จากโมเดล Random Forest (RF)

การวิเคราะห์ความแม่นยำของโมเดล RF ในการจำแนกสุขภาพป่าชายเลนในรูปแบบตารางความสับสนและข้อผิดพลาดของการจำแนก (Error Matrix) (ตารางที่ 4.6) ผลการวิเคราะห์พบว่าในพื้นที่ฝึกสอนโมเดล RF มีค่าความแม่นยำโดยรวม (Overall Accuracy) เท่ากับ 77% และค่า Kappa (Khat) เท่ากับ 0.62 ซึ่งมีความสอดคล้องของข้อมูลในระดับดี และสะท้อนว่าโมเดลสามารถจำแนกข้อมูลได้ในระดับที่น่าเชื่อถือ โดย กลุ่ม “ป่าชายเลนสุขภาพดี” มีค่า Producer’s Accuracy

เท่ากับ 80% และ User's Accuracy เท่ากับ 76% แสดงถึงความแม่นยำที่ดีทั้งจากข้อมูลภาคสนาม และผลการจำแนก ขณะที่ กลุ่ม “ป่าชายเลนสุขภาพไม่ดี” มีค่า Producer's Accuracy เท่ากับ 67% และ User's Accuracy เท่ากับ 71% แม้จะต่ำกว่าคลาสอื่น แต่ยังถือว่าอยู่ในระดับที่สามารถยอมรับได้ในบริบทของป่าชายเลนซึ่งมีลักษณะซับซ้อนทั้งทางโครงสร้างพืชพรรณและสภาพแวดล้อม รวมถึงข้อจำกัดในการเก็บข้อมูลภาคสนาม (Foody, 2002) และ กลุ่ม “พื้นที่อื่น ๆ” มีค่าความแม่นยำสูงที่สุดทั้งสองด้าน คือ Producer's และ User's Accuracy เท่ากับ 96% แสดงถึงความสามารถของโมเดลในการแยกแยะพื้นที่ที่ไม่ใช่ป่าชายเลนได้อย่างแม่นยำ การจำแนกสุขภาพของป่าชายเลนของโมเดล RF แสดงผลเป็นแผนที่การจำแนกสุขภาพของป่าชายเลนในพื้นที่สร้างโมเดล พร้อมเปรียบเทียบกับข้อมูลภาคสนาม ทั้งฤดูร้อนและฤดูฝน (รูปที่ 4.8) ผลลัพธ์แสดงให้เห็นการกระจายของกลุ่มสุขภาพดี (สีเขียว), สุขภาพไม่ดี (สีเหลือง) และพื้นที่อื่น ๆ (สีแดง) โดยเปรียบเทียบกับข้อมูลภาคสนามที่ประเมินจากภาพถ่าย UAV ด้วยสายตา (วงขอบดำและชมพู) จากการวิเคราะห์พบว่าการกระจายของสีในช่วงฤดูฝน พื้นที่ทางฝั่งตะวันตกมีการกระจายของสีเขียวอย่างหนาแน่นและต่อเนื่อง ซึ่งสะท้อนถึงกลุ่มป่าชายเลนที่มีสุขภาพดีและมีความสมบูรณ์ของพุ่มใบสูง ตรงกับข้อมูลภาคสนามกลุ่มสุขภาพดี (วงขอบดำ) ที่เก็บได้ในบริเวณดังกล่าว ขณะที่บริเวณตอนกลางของพื้นที่แสดงการกระจายของสีเหลืองในปริมาณมาก ซึ่งสามารถตีความได้ว่าเป็นพื้นที่ป่าชายเลนอยู่ในสภาพเสื่อมโทรมหรือมีสุขภาพไม่ดี ซึ่งตรงกับข้อมูลภาคสนามกลุ่มสุขภาพไม่ดี (วงขอบชมพู) ส่วนพื้นที่ฝั่งตะวันออกของแผนที่มีการกระจายของสีเขียวและสีเหลืองปะปนกันในส่วนใกล้เคียงกัน อาจสะท้อนถึงลักษณะของพื้นที่รอยต่อระหว่างเรือนยอดที่มีสุขภาพต่างกัน หรือพื้นที่ที่มีความหลากหลายของชนิดพันธุ์ ซึ่งเช่นเดียวกับช่วงฤดูร้อน เพียงแต่พบว่าพื้นที่ที่ถูกจำแนกเป็นกลุ่มสุขภาพไม่ดี (สีเหลือง) มีการกระจายตัวเพิ่มขึ้น ขณะที่พื้นที่กลุ่มสุขภาพดี (สีเขียว) มีสัดส่วนลดลง สะท้อนให้เห็นว่า ฤดูกาลอาจมีอิทธิพลต่อการเปลี่ยนแปลงสุขภาพของพืชป่าชายเลน

ตารางที่ 4.6 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล Random Forest ในพื้นที่สร้างโมเดล

กลุ่ม	ป่าชายเลน สุขภาพดี	ป่าชายเลน สุขภาพไม่ดี	พื้นที่ อื่น ๆ	ผลรวม จุด	User's Accuracy (%)
ป่าชายเลนสุขภาพดี	167	51	1	219	76
ป่าชายเลนสุขภาพไม่ดี	41	105	1	147	71
พื้นที่อื่น ๆ	1	1	54	56	96
ผลรวมจุด	209	157	56	422	
Producer's Accuracy (%)	80	67	96		
Overall Accuracy (%)			77		
Kappa (Khat)			0.62		



รูปที่ 4.8 แผนที่การจำแนกคุณภาพของโมเดล RF ป่าชายเลนคลองเกาะผีในพื้นที่สร้างโมเดล ช่วงฤดูร้อนและฤดูฝน

จากการทดลองเปรียบเทียบประสิทธิภาพของโมเดลทั้งสาม ได้แก่ Random Forest (RF), Support Vector Machine (SVM) และ XGBoost (XGB) บนพื้นที่สร้างโมเดล พบว่าโมเดล RF ให้ค่าความแม่นยำโดยรวม (Overall Accuracy) และค่า Kappa สูงกว่าทุกโมเดล อีกทั้งยังสามารถจำแนกคุณภาพของพืชในแต่ละกลุ่มได้อย่างชัดเจน ทั้งในแง่ของ Producer's Accuracy และ User's Accuracy โดยเฉพาะความสามารถในการแยกแยะกลุ่มสภาพไม่ดี ซึ่งเป็นกลุ่มที่มีความท้าทายในการจำแนก นอกจากนี้ รูปแบบการจำแนกเชิงพื้นที่ของ RF ยังแสดงผลที่สอดคล้องกับข้อมูลภาคสนามได้ดีกว่าโมเดลอื่น ผลการศึกษานี้สอดคล้องกับงานวิจัยของ Aziz et al. (2023) ซึ่งพบว่า

โมเดล RF มีความแม่นยำในการจำแนก โดยให้ความแม่นยำโดยรวม (Overall Accuracy) สูงถึง 96.98% และค่า Kappa เท่ากับ 0.954 ในการจำแนกพื้นที่ป่า เช่นเดียวกับ งานวิจัยของ Guerra-Hernández et al. (2021) ที่พบว่าโมเดล RF มีประสิทธิภาพสูงในการจำแนกสุขภาพของป่าเอลเดอร์ดำโดยให้ความแม่นยำโดยรวม (Overall Accuracy) สูงถึง 91% ด้วยเหตุนี้ การศึกษานี้จึงเลือกใช้โมเดล RF เพียงตัวเดียวในการทดสอบประสิทธิภาพในพื้นที่ทดสอบโมเดล (Test Zone) เพื่อประเมินความสามารถของอัลกอริทึมที่พัฒนาขึ้นในการจำแนกสุขภาพของป่าชายเลนในพื้นที่ที่ไม่เคยถูกใช้ในการฝึกโมเดลมาก่อน

ผลการประเมินความแม่นยำของโมเดล XGB, SVM และ RF ซึ่งพิจารณาจากค่า Producer's Accuracy, User's Accuracy, Overall Accuracy และ Kappa พบว่าอยู่ในระดับปานกลาง ถึง ดี โดยอาจมีสาเหตุจากปัจจัยหลัก 2 ประการ ประการแรก คือ ดัชนีพืชพรรณที่ใช้ในโมเดลยังไม่สามารถแยกแยะกลุ่มสุขภาพของพืชในระดับดีและไม่ดีได้อย่างชัดเจน เนื่องจากค่าดัชนีในบริเวณที่เป็นจุดแบ่งกลุ่มมีแนวโน้มอยู่ในช่วงค่าใกล้เคียงกัน ส่งผลให้โมเดลไม่สามารถเรียนรู้ความแตกต่างได้อย่างเด่นชัด สอดคล้องกับผลการศึกษาของ Malinee et al. (2021) ที่รายงานว่าดัชนีพืชพรรณไม่สามารถจำแนกระดับความรุนแรงของโรคในสวนปาล์มน้ำมันได้อย่างชัดเจนเช่นกัน ประการที่สอง คือ ดัชนีพืชพรรณบางตัวที่ใช้เป็นข้อมูลนำเข้าอาจมีความสัมพันธ์กับฤดูกาลในระดับต่ำ ซึ่งลดทอนประสิทธิภาพของโมเดลในการระบุความเปลี่ยนแปลงของสุขภาพพืชที่สัมพันธ์กับสภาพแวดล้อมตามช่วงเวลา อันอาจเป็นข้อจำกัดในการประเมินสุขภาพป่าชายเลนในภาพรวม


4.4.4 ผลการจำแนกสุขภาพของป่าชายเลนในพื้นที่ทดสอบ จากโมเดล Random Forest

การวิเคราะห์ความแม่นยำของโมเดล RF ในการจำแนกสุขภาพป่าชายเลนในรูปแบบตารางความสับสนและข้อผิดพลาดของผลการจำแนก (Error Matrix) (ตารางที่ 4.7) พบว่าในพื้นที่ทดสอบโมเดล RF มีความแม่นยำโดยรวม (Overall Accuracy) เท่ากับ 95% และค่า Kappa (Khat) เท่ากับ 0.87 ซึ่งจัดอยู่ในระดับความแม่นยำสูง สะท้อนถึงประสิทธิภาพของโมเดลในการจำแนกประเภทข้อมูลได้อย่างถูกต้อง โดย กลุ่ม “ป่าชายเลนสุขภาพดี” มีค่า Producer's Accuracy เท่ากับ 99% และ User's Accuracy เท่ากับ 95% แสดงถึงความแม่นยำทั้งจากมุมมองของข้อมูลจริงและการใช้งาน ส่วนกลุ่ม “ป่าชายเลนสุขภาพไม่ดี” มีค่า Producer's Accuracy เท่ากับ 61% แม้จะอยู่ในระดับต่ำ แต่ยังถือว่ายอมรับได้ในบริบทของป่าชายเลนที่มีความซับซ้อนเชิงโครงสร้างและข้อจำกัดของข้อมูลภาคสนาม (Foody, 2002) โดยเมื่อพิจารณาร่วมกับค่า User's Accuracy ที่สูงถึง 88% ยังสามารถใช้โมเดลนี้ในการวิเคราะห์สุขภาพพืชได้อย่างมีประสิทธิภาพ ขณะที่กลุ่ม “พื้นที่อื่นๆ” แสดงค่าความแม่นยำทั้ง Producer's และ User's Accuracy เท่ากับ 100% สะท้อนถึงการจำแนกที่ชัดเจนและแม่นยำสูงสุดของโมเดล การจำแนกสุขภาพของป่าชายเลนของโมเดล RF ที่ได้รับ

การฝึกจากพื้นที่อื่น แสดงผลเป็นแผนที่การจำแนกสุขภาพของป่าชายเลนในพื้นที่ในพื้นที่ข้อมูลทดสอบ พร้อมเปรียบเทียบกับข้อมูลภาคสนาม ช่วงฤดูฝน (รูปที่ 4.9) ผลลัพธ์แสดงให้เห็นการกระจายของกลุ่มสุขภาพดี (สีเขียว), สุขภาพไม่ดี (สีเหลือง) และพื้นที่อื่น ๆ (สีแดง) โดยเปรียบเทียบกับข้อมูลภาคสนามที่ประเมินจากภาพถ่ายทางอากาศเชิงสายตา (วงขอบดำและชมพู) จากการวิเคราะห์พบว่า พื้นที่ส่วนใหญ่มีการกระจายตัวของพื้นที่สีเขียวเป็นปริมาณมาก สามารถจำแนกเป็นกลุ่มป่าชายเลนสุขภาพดีอย่างชัดเจน โดยเฉพาะบริเวณตอนกลางและทิศเหนือของพื้นที่ ขณะที่กลุ่มสุขภาพไม่ดี ซึ่งเป็นพื้นที่สีเหลืองกระจายแทรกในบางบริเวณ และมีแนวโน้มสอดคล้องกับจุดข้อมูลภาคสนามกลุ่มสุขภาพไม่ดี ส่วนพื้นที่สีแดงซึ่งถูกจัดอยู่ในกลุ่มพื้นที่อื่น ๆ ส่วนใหญ่จะพบบริเวณแนวขอบพื้นที่และพื้นที่รอยต่อของป่าชายเลนกับพื้นที่สิ่งปลูกสร้าง ซึ่งแสดงถึงความสามารถของโมเดลในการแยกแยะพื้นที่ที่อยู่นอกขอบเขตการวิเคราะห์ได้อย่างเหมาะสม

ตารางที่ 4.7 ข้อผิดพลาดของผลการจำแนก (Error Matrix) สำหรับการจำแนกสุขภาพของป่าชายเลนโดยใช้โมเดล Random Forest ในพื้นที่ทดสอบโมเดล

กลุ่ม	ป่าชายเลน สุขภาพดี	ป่าชายเลน สุขภาพไม่ดี	พื้นที่ อื่น ๆ	ผลรวม จุด	User's Accuracy (%)
ป่าชายเลนสุขภาพดี	181	9	0	190	95
ป่าชายเลนสุขภาพไม่ดี	2	14	0	16	88
พื้นที่อื่น ๆ	0	0	30	30	100
ผลรวมจุด	183	23	30	236	
Producer's Accuracy (%)	99	61	100		
Overall Accuracy (%)			95		
Kappa (Khat)			0.87		




รูปที่ 4.9 แผนที่การจำแนกสุขภาพของโมเดล RF ป่าชายเลนคลองเกาะผีในพื้นที่ข้อมูลทดสอบ ช่วงฤดูฝน

ผลการจำแนกสุขภาพป่าชายเลนในพื้นที่ทดสอบด้วยโมเดล RF แม้จะให้ค่า Overall Accuracy สูงถึง 96% และ Kappa อยู่ในระดับดีมาก (0.88) แต่เมื่อพิจารณารายละเอียดจาก Error Matrix (ตารางที่ 4.7) พบว่าความแม่นยำของโมเดลอาจได้รับอิทธิพลจากความไม่สมดุลของข้อมูลระหว่างกลุ่มสุขภาพดีและสุขภาพไม่ดี กล่าวคือ กลุ่มป่าชายเลนสุขภาพดีมีจำนวนจุดตัวอย่างสูงถึง 190 จุด ขณะที่กลุ่มสุขภาพไม่ดีมีเพียง 16 จุด ซึ่งต่างกันหลายเท่าตัว ความแตกต่างดังกล่าวส่งผลให้โมเดลเรียนรู้ลักษณะของกลุ่มสุขภาพดีได้ดีกว่า และอาจลดทอนความสามารถของโมเดลในการจำแนกกลุ่มสุขภาพไม่ดีให้แม่นยำอย่างสม่ำเสมอ โดยค่า User's Accuracy ของกลุ่มสุขภาพไม่ดีอยู่เพียง 88% เทียบกับกลุ่มสุขภาพดีที่มีค่า 95% ดังนั้น เพื่อหลีกเลี่ยงความลำเอียงของโมเดล (Model Bias) และเพิ่มความน่าเชื่อถือของผลการจำแนกในอนาคต ควรมีการจัดสรรจำนวนจุดตัวอย่างให้แต่ละกลุ่มสุขภาพมีความใกล้เคียงกันมากยิ่งขึ้น

4.4.5 ผลการจำแนกสุขภาพป่าชายเลนคลองเกาะผี จากโมเดล Random Forest

การจำแนกสุขภาพพืชป่าชายเลนคลองเกาะผี (ตอนบน) โดยใช้แบบจำลอง RF ที่ผ่านการฝึกจากข้อมูลดัชนีพืชพรรณและข้อมูลภาคสนาม (รูปที่ 4.10) พบว่า พื้นที่ส่วนใหญ่ของป่าชายเลนถูกจำแนกเป็นกลุ่มสุขภาพดี (สีเขียว) ขณะที่กลุ่มสุขภาพไม่ดี (สีเหลือง) กระจายตัวเป็นหย่อม ๆ โดยเฉพาะบริเวณรอยต่อกับพื้นที่ที่สิ่งปลูกสร้าง หรือบริเวณที่มีลักษณะสีของใบที่ซีด เหลือง หรือเขียวอ่อนปนเหลือง รวมถึงบริเวณที่มีความหนาแน่นของเรือนยอดลดลง สำหรับพื้นที่อื่น ๆ ที่ไม่ใช่ป่าชายเลน (สีแดง) ส่วนใหญ่พบบริเวณขอบพื้นที่ เช่น ถนน อาคาร และพื้นที่โล่ง แสดงถึงความสามารถของโมเดลในการกรองพื้นที่นอกเป้าหมายได้อย่างแม่นยำ



รูปที่ 4.10 แผนที่การจำแนกสุขภาพพืชป่าชายเลนโดยโมเดล RF พื้นที่ป่าชายเลนคลองเกาะผี จ.ภูเก็ต

บทที่ 5

สรุปผลการศึกษา ปัญหา และข้อเสนอแนะ

5.1 สรุปผลการศึกษา

จากผลการศึกษาวิทยานิพนธ์เรื่อง การพัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลนด้วยวิธีการสำรวจระยะไกล ซึ่งมีวัตถุประสงค์เพื่อพัฒนาอัลกอริทึมในการติดตามสุขภาพของป่าชายเลนด้วยภาพถ่ายทางอากาศ โดยใช้อัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) จำนวน 3 อัลกอริทึม ได้แก่ RF, XGB และ SVM ศึกษา ณ พื้นที่ป่าชายเลนคลองเกาะผี (รูปที่ 3.1) จากการศึกษาสามารถสรุปผลการศึกษาได้ว่า ภาพถ่ายทางอากาศจาก DJI P4 Multispectral สามารถใช้เป็นข้อมูลในการพัฒนาอัลกอริทึม Random Forest (RF) ได้ และสรุปได้ว่า อัลกอริทึม Random Forest (RF) สามารถใช้ในการประเมินและติดตามสุขภาพของป่าชายเลนได้ โดยสรุปผลการศึกษาดังนี้

5.1.1 ดัชนีพืชพรรณที่มีประสิทธิภาพ

จากการประเมินดัชนีพืชพรรณทั้งหมด 16 ดัชนี ได้แก่ NDVI, GNDVI, NDWI, SAVI, EVI, NDRE, NDI, TCARI, RECI, CCCI, GCC, VDVI, MTCI, ExG, PSRI และ VARI พบว่ามีดัชนีพืชพรรณ 6 ดัชนี คือ GNDVI, NDWI, NDRE, CCCI, MTCI และ ExG เป็นดัชนีที่สามารถแสดงความแตกต่างของสุขภาพพืชได้ชัดเจนทั้งในเชิงพื้นที่และเชิงสถิติ จึงถูกนำมาใช้เป็นตัวแปรนำเข้าสู่สำหรับฝึกโมเดล เนื่องจากเป็นกลุ่มดัชนีที่สามารถบ่งบอกลักษณะโครงสร้างเรือนยอด ความเขียว และปริมาณคลอโรฟิลล์ได้ชัดเจน

5.1.2 การเลือกโมเดลหลักในการประเมินสุขภาพของป่าชายเลน

จากการเปรียบเทียบประสิทธิภาพของโมเดลทั้งสาม ได้แก่ Random Forest (RF), Support Vector Machine (SVM) และ XGBoost (XGB) บนพื้นที่สร้างโมเดล พบว่า RF มีค่าความแม่นยำโดยรวม (Overall Accuracy) และค่า Kappa สูงที่สุด อยู่ที่ 77% และ 0.62 ตามลำดับ รวมถึงสามารถจำแนกกลุ่มสุขภาพพืชได้อย่างแม่นยำและสอดคล้องกับข้อมูลภาคสนามมากที่สุด ด้วยเหตุนี้ ใช้โมเดล RF เพียงตัวเดียวสำหรับการทดสอบประสิทธิภาพในการจำแนกสุขภาพของป่าชายเลน

เล่นในพื้นที่ทดสอบโมเดล เนื่องจากโมเดล RF มีคุณลักษณะเด่นในการจัดการกับข้อมูลที่มีความไม่สมดุล และสามารถจัดการ ข้อมูลที่ไม่สม่ำเสมอ (Noise) ได้ดี โดยไม่ต้องปรับแต่งพารามิเตอร์มากนัก นอกจากนี้ RF ยังเป็นโมเดลแบบ Ensemble ที่ใช้การสร้างต้นไม้หลายต้นแบบสุ่ม (Decision Trees) ช่วยลดความลำเอียงของการจำแนก และเพิ่มเสถียรภาพของผลลัพธ์ได้ดีกว่าโมเดล SVM และ XGB ซึ่งต้องอาศัยการปรับค่าพารามิเตอร์ที่ซับซ้อนมากกว่า RF จึงเหมาะสมสำหรับนำไปใช้ในการทดสอบโมเดลในพื้นที่อื่น

5.1.3 ประสิทธิภาพในการจำแนกของโมเดล Random Forest

โมเดล RF ที่ผ่านทดสอบครั้งนี้ แสดงความสามารถในการจำแนกสุขภาพของเรื้อนยอดป่าชายเลนได้อย่างแม่นยำ โดยในพื้นที่สร้างโมเดล มีค่าความแม่นยำโดยรวม (Overall Accuracy) เท่ากับ 77% และค่า Kappa เท่ากับ 0.62 และในพื้นที่ทดสอบโมเดล มีค่าความแม่นยำโดยรวม (Overall Accuracy) เท่ากับ 95% และค่า Kappa เท่ากับ 0.87 ซึ่งจัดอยู่ในระดับความแม่นยำสูง

จากผลการศึกษาทั้งหมด อัลกอริทึม Random Forest ที่ได้รับการพัฒนาขึ้นแสดงให้เห็นถึงประสิทธิภาพในการจำแนกสุขภาพของป่าชายเลนได้อย่างแม่นยำ โดยสามารถแยกแยะกลุ่มสุขภาพดี สุขภาพไม่ดี และพื้นที่อื่น ๆ ได้อย่างชัดเจน ทั้งในเชิงพื้นที่และเชิงสถิติ การวิเคราะห์ดัชนีพืชพรรณร่วมกับข้อมูลภาคสนามที่มีการประเมินสุขภาพด้วยสายตา และการวัดค่าการสะท้อนแสงเชิงสเปกตรัม ช่วยสนับสนุนความถูกต้องของแบบจำลองและเพิ่มความน่าเชื่อถือของผลการจำแนกได้เป็นอย่างดี จึงสรุปได้ว่า อัลกอริทึม RF ที่พัฒนาขึ้นในการศึกษานี้ มีศักยภาพในการนำไปใช้เป็นเครื่องมือในการติดตามและประเมินสุขภาพของป่าชายเลนในพื้นที่จริงได้อย่างมีประสิทธิภาพ สามารถประยุกต์ใช้ร่วมกับข้อมูลจากภาพถ่ายทางอากาศที่ได้จากอากาศยานไร้คนขับ (UAV) แบบ Multispectral เพื่อสนับสนุนงานด้านการฟื้นฟู เฝ้าระวัง และจัดการทรัพยากรป่าชายเลนได้อย่างเป็นระบบและต่อเนื่องในอนาคต

5.2 ปัญหา

จากการศึกษาครั้งนี้ทำให้ทราบถึงปัญหาและอุปสรรคต่าง ๆ ที่มีผลต่อการดำเนินงานวิจัย ได้แก่

5.2.1 การลงพื้นที่เพื่อเก็บตัวอย่างใบไม้ในบริเวณป่าชายเลนมีข้อจำกัดหลายประการ ได้แก่ ข้อจำกัดด้านเวลาในการเก็บตัวอย่างเนื่องจากต้องเผื่อระดับน้ำขึ้น-น้ำลง ความยากลำบากในการเดินเท้าในสภาพพื้นที่ที่เป็นเลน หรือมีพืชพรรณหนาแน่น และข้อจำกัดในการเก็บตัวอย่างใบไม้จาก ต้นไม้ที่มีความสูงมาก

5.2.2 จำนวนข้อมูลตัวอย่างในกลุ่มพืชที่มีสุขภาพไม่ดีมีจำนวนน้อยเมื่อเทียบกับกลุ่มอื่น ส่งผลให้ประสิทธิภาพของการจำแนกในกลุ่มนี้ต่ำกว่าที่คาดหวัง และอาจกระทบต่อความแม่นยำของแบบจำลองในภาพรวม

5.3 ข้อเสนอแนะ

5.3.1 การเตรียมเครื่องมือช่วยเก็บใบไม้จากต้นสูง ควรเช็คความสูงต้นเบื้องต้นและเตรียมเครื่องมือที่สามารถเก็บตัวอย่างใบไม้จากต้นไม้สูงได้ และวางแผนสำรวจให้สอดคล้องกับช่วงน้ำลง ลดข้อจำกัดทั้งระยะเวลาและการลงพื้นที่

5.3.2 ควรเพิ่มจำนวนตัวอย่างกลุ่มสุขภาพไม่ดีให้สมดุลกับกลุ่มอื่น ช่วยเพิ่มความถูกต้องการจำแนกสุขภาพจากโมเดลได้

5.3.3 ควรเลือกพื้นที่ทดสอบโมเดลที่เป็นพื้นที่ป่าชายเลนบริเวณอื่นซึ่งมีจำนวนจุดตัวอย่างในแต่ละกลุ่มสุขภาพ (สุขภาพดีและสุขภาพไม่ดี) ที่ใกล้เคียงกัน เพื่อเพิ่มความสมดุลของข้อมูล ลดความลำเอียงของโมเดล และเพิ่มศักยภาพของอัลกอริทึมในการจำแนกสุขภาพพืชได้ดียิ่งขึ้น

5.3.4 ควรดำเนินการเก็บภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ (UAV) ในหลายวันของแต่ละฤดูกาล แล้วนำภาพเหล่านั้นมาสร้างเป็น Image Composite เพื่อให้ได้ภาพที่สามารถเป็นตัวแทนของลักษณะพืชพรรณในแต่ละฤดูกาลนั้นได้อย่างมีประสิทธิภาพและแม่นยำมากขึ้น

เอกสารอ้างอิง

- กรมทรัพยากรทางทะเลและชายฝั่ง. (2562). สถานการณ์ป่าชายเลน. (ออนไลน์). เข้าถึงได้ที่ https://km.dmcr.go.th/c_1/s_434/d_19146 (15 กันยายน 2566).
- กรมพัฒนาที่ดิน. (2563). ประเภทใช้ที่ดินจังหวัดภูเก็ต. (ออนไลน์). เข้าถึงได้ที่ http://www1.ldd.go.th/WEB_OLP/Lu_63/Lu63_S/PKT2563.htm (18 กันยายน 2566).
- กาญจน์เขจร ชูชีพ. (2561). การประเมินความถูกต้องในการสำรวจระยะไกล. Remote Sensing Technical Note No. 3 (2018). Faculty of Forestry, Kasetsart University, หน้า 1-18.
- ชัยสิทธิ์ ตระกูลศิริพาณิชย์. (2542). ป่าชายเลนจังหวัดภูเก็ต. เอกสารทางวิชาการ สถานีวิจัยและอนุรักษ์ป่าชายเลนที่ 1 (ภูเก็ต), สำนักวิชาการป่าไม้ กรมป่าไม้, หน้า 1-44.
- ไชยฤทธิ์ เศรษฐวงศ์ และพิพัทธ์ เรืองแสง. (2560). การเปรียบเทียบดัชนีน้ำแบบ NDWI, MNDWI1 และ MNDWI2 จากข้อมูลภาพถ่ายดาวเทียม Sentinel-2 สำหรับสกัดพื้นที่แหล่งน้ำผิวดิน บริเวณตัวเมือง จังหวัดขอนแก่น. วารสารวิทยาการสารสนเทศและเทคโนโลยีประยุกต์, 4(1): 2565, หน้า 1-12.
- ณัฐพร ยวงเงิน. (2559). เทคโนโลยีการสำรวจระยะไกล เพื่อช่วยสำรวจข้อมูลทรัพยากรในประเทศไทย. (ออนไลน์). เข้าถึงได้ที่ <https://citly.me/oVK5S> (18 กันยายน 2566).
- นิติศักดิ์ เจริญรูป, วรวิพรรณ เจริญรูป, สิทธิชัย จินะวงษ์ และสุจิตรา จินะวงษ์. (2565). การพัฒนาระบบสารสนเทศทางภูมิศาสตร์เพื่อนำไปสู่การขับเคลื่อนการเกษตรด้วยข้อมูล. Journal of Applied Research on Science and Technology (JARST), Vol 21, Issue 2, หน้า 57.
- เปรมศิริ คงแสง. (2560). การจำแนกการใช้ประโยชน์ที่ดินและสิ่งปลูกสร้างปกคลุมดินของจังหวัดภูเก็ต จากภาพถ่ายดาวเทียมแลนด์แซท 8 ด้วยคุณสมบัติทางซีฟลักซ์. วิทยานิพนธ์หลักสูตรปริญญาวิทยาศาสตรบัณฑิต, มหาวิทยาลัยสงขลานครินทร์, หน้า 9.
- พิชิตพร ผลเกิดดี. (2562). โครงการการประยุกต์เทคโนโลยีภูมิสารสนเทศเพื่อการศึกษาดัชนีพืชพรรณและความชื้นในการวิเคราะห์ความแห้งแล้งในพื้นที่เศรษฐกิจพิเศษภาคตะวันออก. คณะภูมิสารสนเทศศาสตร์, มหาวิทยาลัยบูรพา, หน้า 2-3.

เอกสารอ้างอิง (ต่อ)

- เยาวลักษณ์ มีบุญมาก, เพ็ญจมาศ คำธนะ, ศรีณธร มังคะมณี, ลักคณา บุญมี, จิรียา อินทนา, ปาริชาติ ญาตินิยม และลลิต ศิริทรัพย์จันทน์. (2563). **เครื่องมือสำคัญของนักวิจัยเชิงคุณภาพ**. วารสารการพยาบาลและการศึกษา, ปีที่ 13 ฉบับที่ 3 กรกฎาคม - กันยายน 2563, หน้า 1-13.
- ยวทัศน์ รักสิ่งแวดล้อม. (2552). **การกระจายของพื้นที่ป่าชายเลนในประเทศไทย**. (ออนไลน์). เข้าถึงได้ ที่ https://yawathutraksingwaedlorm.blogspot.com/2009/07/blog-post_6085.html (15 กันยายน 2566).
- รฐนนท์ จันทรอินทร์, สุชาติ ป้อมแก้ว และสุภาสพงษ์ รู้ทำนอง. (2560). **การศึกษาดัชนีความแตกต่างพืชพรรณแบบนอร์มอลไลซ์ หลายช่วงเวลาจากข้อมูลโมดิสสำหรับติดตามปัญหาภัยแล้ง พื้นที่ฝั่งตะวันออกของแม่น้ำปิง จังหวัดกำแพงเพชร**. รายงานสืบเนื่องจากการประชุมวิชาการระดับชาติ ครั้งที่ 4 สถาบันวิจัย มหาวิทยาลัยราชภัฏกำแพงเพชร, 22 ธันวาคม 2017, หน้า 621-632.
- วิโรจน์ ละอองมณี, สวรินทร์ ฤกษ์อยู่สุข และภาณุ อุทัยศรี. (2565). **การรับรู้จากระยะไกลเพื่อการศึกษาเกี่ยวกับความชื้นของดิน: เทคนิคการตรวจวัดและแหล่งข้อมูลที่มีให้บริการ**. วารสารวิศวกรรมศาสตรมหาวิทยาลัเทคโนโลยีราชมงคลล้านนา, ปีที่ 7 ฉบับที่ 2 กรกฎาคม - ธันวาคม 2022, หน้า 11-12.
- ศูนย์ภูมิอากาศ กรมอุตุนิยมวิทยา. (2560). **ภูมิอากาศจังหวัดภูเก็ต**. (ออนไลน์). เข้าถึงได้ที่ <https://citly.me/oTmAt> (18 กันยายน 2566).
- สุชาติ เพชรแก้ว, วิเชียร จาญพจน์ และชัยรัตน์ นิลนนท์. (2542). **ความสัมพันธ์ระหว่างสมบัติบางประการของดินและสังคมพืชในป่าชายเลนยะหริ่ง จังหวัดปัตตานี**. วิทยานิพนธ์, วิทยาลัยสงขลานครินทร์ วท. 21(2) : หน้า 235-251.
- Abdollahnejad, A.; Panagiotidis, D. (2020). **Tree Species Classification and Health Status Assessment for a Mixed Broadleaf-Conifer Forest with UAS Multispectral Imaging**. Remote Sens. 2020, 12, 3722.

เอกสารอ้างอิง (ต่อ)

- Ahmed, S.; Sarker, S. K.; Friess, D. A.; Kamruzzaman, M.; Jacobs, M.; Islam, M. A.; Alam, M. A.; Suvo, M. J.; Sani, M. N. H.; Dey, T.; Naabeh, C. S. S.; Pretzsch, H. (2022). **Salinity Reduces Site Quality and Mangrove Forest Functions: From Monitoring to Understanding**. *Sci. Total Environ.* 2022, 853, 158662.
- Alatorre, L. C.; Sánchez-Carrillo, S.; Miramontes-Beltrán, S.; Medina, R. J.; Torres-Olave, M. E.; Bravo, L. C.; Wiebe, L. C.; Granados, A.; Adams, D. K.; Sánchez, E.; Uc, M. (2016). **Temporal changes of NDVI for qualitative environmental assessment of mangroves: Shrimp farming impact on the health decline of the arid mangroves in the Gulf of California (1990-2010)**. *Journal of Arid Environments* 125 (2016) 98-109.
- Anderegg, J.; Yu, K.; Aasen, H.; Walter, A.; Liebisch, F.; Hund, A. (2020). **Spectral Vegetation Indices to Track Senescence Dynamics in Diverse Wheat Germplasm**. *Front. Plant Sci.* 10:1749.
- Aziz, G.; Minallah, N.; Saeed, A.; Frnda, J.; Khan, W. (2023). **Remote sensing based forest cover classification using machine learning**. *Scientific Reports*, (2024) 14:69.
- Cemiloglu, A.; Zhu, L.; Arslan, S.; Xu, J.; Yuan, X.; Azarafza, M.; Derakhshani, R. (2023). **Support Vector Machine (SVM) Application for Uniaxial Compression Strength (UCS) Prediction: A Case Study for Maragheh Limestone**. *Appl. Sci.* 2023,13, 2217.
- Chen, F.; Van de Voorde, T.; Roberts, D.; Zhao, H.; Chen, J. (2021). **Detection of Ground Materials Using Normalized Difference Indices with a Threshold: Risk and Ways to Improve**. *Remote Sens.* 2021, 13, 450.
- Cyber Elite. (2565). **Machine Learning เทคโนโลยีประโยชน์ครอบคลุมจักรวาล**. (ออนไลน์). เข้าถึงได้ที่ <https://www.cyberelite.co.th/blog/machine-learning/> (5 ตุลาคม 2566).

เอกสารอ้างอิง (ต่อ)

- Demeter. (2563). **Machine Learning คืออะไร**. (ออนไลน์). เข้าถึงได้ที่ <https://www.dmit.co.th/th/zendesk-updates-th/machine-learning-vs-deep-learning/> (25 กันยายน 2566).
- DJI. (2020). **P4 Multispectral User Manual v1.4**. (ออนไลน์). เข้าถึงได้ที่ https://dl.djicdn.com/downloads/p4-multispectral/20200806/P4_Multispectral_User_Manual_v1.4_EN.pdf (25 มีนาคม 2568)
- DJI Agriculture. (n.d.). **P4 Multispectral**. (ออนไลน์). เข้าถึงได้ที่ <https://ag.dji.com/p4-multispectral> (25 มีนาคม 2568)
- Foody, G. M. (2002). **Status of land cover classification accuracy assessment**. Remote Sensing of Environment 80 (2002) 185–201.
- Ghorbanian, A.; Ahmadi, S. A.; Amani, M.; Mohammadzadeh, A.; Jamali, S. (2022). **Application of Artificial Neural Networks for Mangrove Mapping Using Multi-Temporal and Multi-Source Remote Sensing Imagery**. Water 2022, 14, 244.
- Gogoi, N. K.; Deka, B.; Bora, L. C. (2018). **Remote sensing and its use in detection and monitoring plant diseases: A review**. Agricultural Reviews, 39(4) 2018: 307-313.
- Guerra-Hernández, J.; Díaz-Varela, R. A.; Álvarez-González, J. G.; Rodríguez-González, P. M. (2021). **Assessing a novel modelling approach with high resolution UAV imagery for monitoring health status in priority riparian forests**. Forest Ecosystems (2021) 8:61.
- Hidayaturrohman, Q. A.; Hanada, E. (2024). **Impact of Data Pre-Processing Techniques on XGBoost Model Performance for Predicting All-Cause Readmission and Mortality Among Patients with Heart Failure**. BioMedInformatics 2024, 4, 2201–2212.

เอกสารอ้างอิง (ต่อ)

- Huete, A.; Didan, K.; Miura, T.; Rodriguez, E. P.; Gao, X.; (2002). **Overview of the radiometric and biophysical performance of the MODIS vegetation indices.** Remote Sensing of Environment 83 (2002) 195 – 213.
- Jeyanny, V.; Siva Kumar, B.; Ne'ryez, S. R.; Fakhri, M. I.; Daljit, S. K.; Maisarah, M. Z.; Wan Rasidah, K.; Husni, M. H. A. (2018). **Assessing Soil Quality of a Regenerating Mangrove Forest Using Geospatial Modelling Approach.** Malays. J. Soil Sci. 2018, 22, 161–173.
- Jimenez, L. C. Z.; Queiroz, H. M.; Otero, X. L.; Nóbrega, G. N.; Ferreira, T. O. (2021) **Soil Organic Matter Responses to Mangrove Restoration: A Replanting Experience in Northeast Brazil.** Int. J. Environ. Res. Public Health 2021, 18 (17), 8981.
- Larrinaga, A. R.; Brotons, L. (2019). **Greenness Indices from a Low-Cost UAV Imagery as Tools for Monitoring Post-Fire Forest Recovery.** Drones 2019, 3, 6.
- Li, D.-C.; Huang, W.-K.; Lin, Y.-S. (2022). **New Product Short-Term Demands Forecasting with Boxplot-Based Fractional Grey Prediction Model.** Appl. Sci. 2022, 12, 5131.
- Malinee, R.; Stratoulas, D.; Nuthammachot, N. (2021). **Detection of Oil Palm Disease in Plantations in Krabi Province, Thailand with High Spatial Resolution Satellite Imagery.** Agriculture 2021, 11, 251, 1-17.
- Mesquita, D. (2021). **How to Build a Neural Network & Make Predictions.** (ออนไลน์). เข้าถึงได้ที่ <https://realpython.com/python-ai-neural-network/> (25 กันยายน 2566).
- Miao, J.; Wang, J.; Zhao, D.; Shen, Z.; Xiang, H.; Gao, C.; Li, W.; Cui, L.; Wu, G. (2024). **Modeling strategies and influencing factors in retrieving canopy equivalent water thickness of mangrove forest with Sentinel-2 image.** Ecological Indicators 158 (2024) 111497.

เอกสารอ้างอิง (ต่อ)

- Montgomery, D. C.; Peck, E. A.; Vining, G. G. (2012). **Introduction to Linear Regression Analysis**. (5th ed.). John Wiley & Sons. ISBN: 978-0-470-54281-1.
- Williams, P.; Tech, V. (2014). **Plant Health with Remote Sensing**. (ออนไลน์). เข้าถึงได้ที่ <https://storymaps.arcgis.com/stories/91e794af4ce44a4685e6340d5480e70c> (20 พฤศจิกายน 2566).
- Pastor-Guzman, J.; Brown, L.; Morris, H.; Bourg, L.; Goryl, P.; Dransfeld, S.; Dash, J. (2020). **The Sentinel-3 OLCI Terrestrial Chlorophyll Index (OTCI): Algorithm Improvements, Spatiotemporal Consistency and Continuity with the MERIS Archive**. Remote Sens. 2020, 12, 2652.
- Prabakaran, C.; Singh, C. P.; Panigrahy, S. (2014). **Assessment of the health status of Indian mangrove ecosystems using multi temporal remote sensing data**. Tropical Ecology 55(2): 245-253, 2014.
- Purwanto, A. D.; Wikantika, K.; Deliar, A.; Darmawan, S. (2023). **Decision Tree and Random Forest Classification Algorithms for Mangrove Forest Mapping in Sembilang National Park, Indonesia**. Remote Sens. 2023, 15, 16.
- Rehman, T. H.; Lundy, M. E.; Linquist, B. A. (2022). **Comparative Sensitivity of Vegetation Indices Measured via Proximal and Aerial Sensors for Assessing N Status and Predicting Grain Yield in Rice Cropping Systems**. Remote Sens. 2022, 14, 2770.
- Roldán-Nofuentes, J.A.; Regad, S.B. (2021). **Estimation of the Average Kappa Coefficient of a Binary Diagnostic Test in the Presence of Partial Verification**. Mathematics 2021, 9, 1694.
- Rudd, J. M.; Ray, H. G. (2020). **An Empirical Study of Downstream Analysis Effects of Model Pre-Processing Choices**. Open Journal of Statistics, 10, 735-809.

เอกสารอ้างอิง (ต่อ)

- Saxena, S. (2024). **A Beginner's Guide to Random Forest Hyperparameter Tuning.** (ออนไลน์). เข้าถึงได้ที่ https://www.analyticsvidhya.com/blog/2020/03/beginners-guide-random-forest-hyperparameter-tuning/?utm_source=chatgpt.com (20 เมษายน 2568)
- SEOS. (2020). **Classification Algorithms and Methods.** (ออนไลน์). เข้าถึงได้ที่ <https://seos-project.eu/classification/classification-c01-p05.html> (18 กันยายน 2566).
- Tran, T. V.; Reef, R.; Zhu, X. (2022). **A Review of Spectral Indices for Mangrove Remote Sensing.** Remote Sens. 2022, 14, 4868.
- Vidican, R.; Mălinas, A.; Ranta, O.; Moldovan, C.; Marian, O.; Ghețe, A.; Ghișe, C. R.; Popovici, F.; Cătunescu, G. M. (2023). **Using Remote Sensing Vegetation Indices for the Discrimination and Monitoring of Agricultural Crops: A Critical Review.** Agronomy 2023, 13, 3040.
- Vélez, S.; Martínez-Peña, R.; Castrillo, D. (2023). **Beyond Vegetation: A Review Unveiling Additional Insights into Agriculture and Forestry through the Application of Vegetation Indices.** J 2023, 6, 421–436.
- Wang, D.; Xing, Y.; Fu, A.; Tang, J.; Chang, X.; Yang, H.; Yang, S.; Li, Y. (2025). **Mapping Forest Aboveground Biomass Using Multi-Source Remote Sensing Data Based on the XGBoost Algorithm.** Forests 2025, 16, 347.
- Wang, L.; Silván-Cárdenas, J. L.; Sousa, W. P. (2008). **Neural Network Classification of Mangrove Species from Multi-seasonal Ikonos Imagery.** Photogrammetric Engineering & Remote Sensing · August 2008: 921-926.
- Yoswaty, D.; Siregar, Y. I.; Mubarak; Efriyeldi; Kurniawan, R.; Oktavian, R.; Ismet, G.; Maulana, A. **Seawater Quality Parameters in the Mangrove Conservation Area of Bukit Batu District, Bengkalis Regency, Riau Province.** BIO Web Conf. 2024, 136, 03004.

เอกสารอ้างอิง (ต่อ)

- Zhang, C.; Kovacs, J. M.; Liu, Y.; Flores-Verdugo, F.; Flores-de-Santiago, F. (2014). **Separating Mangrove Species and Conditions Using Laboratory Hyperspectral Data: A Case Study of a Degraded Mangrove Forest of the Mexican Pacific.** Remote Sens. 2014, 6, 11673-11688.
- Zhao, Q.; Qu, Y. (2024). **The Retrieval of Ground NDVI (Normalized Difference Vegetation Index) Data Consistent with Remote-Sensing Observations.** Remote Sens. 2024, 16, 1212.
- Zhen, J.; Jiang, X.; Xu, Y.; Miao, J.; Zhao, D.; Wang, J.; Wang, J.; Wu, G. (2021). **Mapping leaf chlorophyll content of mangrove forests with Sentinel-2 images of four periods.** International Journal of Applied Earth Observation and Geoinformation 102 (2021) 102387.
- Zhou, H.; Fu, L.; Sharma, R.P.; Lei, Y.; Guo, J. (2021). **A Hybrid Approach of Combining Random Forest with Texture Analysis and VDMI for Desert Vegetation Mapping Based on UAV RGB Data.** Remote Sens. 2021, 13, 1891.

ภาคผนวก

ภาคผนวก ก

Code ที่เกี่ยวข้อง

```

9 import random
10 import numpy as np
11 import pandas as pd
12 import matplotlib.pyplot as plt
13 import joblib
14 from sklearn.model_selection import train_test_split
15 from sklearn.ensemble import RandomForestClassifier
16 from sklearn.metrics import accuracy_score, confusion_matrix
17
18 # 1. Load dataset
19 file_path = r'F:\for_python\Dataset_Python.xlsx'
20 data = pd.read_excel(file_path)
21
22 # 2. Prepare Features and Labels
23 X = data[['GNDVI', 'NDVI', 'NDRE', 'CCI', 'Tst', 'HTC']]
24 y = data['Output']
25 X = X.fillna(X.mean())
26
27 # 3. Setup save folder
28 model_save_path = r'F:\for_python\RF_model'
29 os.makedirs(model_save_path, exist_ok=True)
30
31 # 4. Set loop condition
32 accuracy_threshold = 0.75
33 max_models = 50
34 model_count = 0
35 best_accuracy = 0
36 best_model = None
37 best_y_test = None
38 best_y_pred = None
39
40 # 5. Loop until condition met
41 while best_accuracy < accuracy_threshold and model_count < max_models:
42     model_count += 1
43     rand_state = random.randint(0, 10000)
44     X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.3, random_state=rand_state)
45     rf_model = RandomForestClassifier(n_estimators=100, random_state=rand_state)
46     rf_model.fit(X_train, y_train)
47     y_pred = rf_model.predict(X_test)
48     accuracy = accuracy_score(y_test, y_pred)
49
50     # 6. Save best model
51     if best_model is not None:
52         model_path = os.path.join(model_save_path, best_model_name)
53         joblib.dump(best_model, model_path)
54         print(f"Best model saved at: {model_path} (Accuracy: {best_accuracy:.4f})")
55     else:
56         print(f"No model exceeded the accuracy threshold.")
57
58 # 7. Confusion Matrix & User's & Producer's Accuracy
59 if best_model is not None:
60     conf_matrix = confusion_matrix(best_y_test, best_y_pred)
61     labels = sorted(np.unique(y))
62
63     user_accuracy = np.diag(conf_matrix) / np.sum(conf_matrix, axis=0)
64     producer_accuracy = np.diag(conf_matrix) / np.sum(conf_matrix, axis=1)
65
66     conf_matrix_df = pd.DataFrame(conf_matrix,
67                                   index=[f'Actual ({})' for i in labels],
68                                   columns=[f'Predicted ({})' for i in labels])
69
70     conf_matrix_df['Producer's Accuracy'] = list(producer_accuracy)
71     conf_matrix_df.loc['User's Accuracy'] = list(user_accuracy) + [np.nan]
72
73     print(f"Confusion Error Matrix with Accuracy:")
74     print(conf_matrix_df.round())

```

รูปภาคผนวก 1 Code สำหรับฝึกโมเดล Random forest

```

9 import os
10 import rasterio
11 import numpy as np
12 import joblib # Random Forest
13 import matplotlib.pyplot as plt
14 from rasterio.plot import show
15
16 # 1. Load Random Forest
17 model_path = r'F:\for_python\RF_model\random_forest_model\276_v0400_0.773.pkl'
18 rf_model = joblib.load(model_path)
19
20 # 2. Load input data
21 file_paths = [
22     r'F:\for_python\Survey\Dataset\Index\VT_Palae\Mask\area\GNDVI_mask.tif',
23     r'F:\for_python\Survey\Dataset\Index\VT_Palae\Mask\area\NDVI_mask.tif',
24     r'F:\for_python\Survey\Dataset\Index\VT_Palae\Mask\area\NDRE_mask.tif',
25     r'F:\for_python\Survey\Dataset\Index\VT_Palae\Mask\area\CCI_mask.tif',
26     r'F:\for_python\Survey\Dataset\Index\VT_Palae\Mask\area\Tst_mask.tif',
27     r'F:\for_python\Survey\Dataset\Index\VT_Palae\Mask\area\HTC_mask.tif'
28 ]
29
30 # 3. Load input data
31 range_index = [[-1,1], [-1,1], [-1,1], [0,1], [0,1], [0,1,1]]
32
33 # Load input data
34 def load_band(file_path, valid_range):
35     rasterio.open(file_path).src:
36     band_data = src.read(1, out_shape=(np.float32), dtype='float32')
37     band_data[band_data < valid_range[0]] | (band_data > valid_range[1]) = np.nan # Invalid
38     return band_data, src.meta
39
40 # Load input data
41 GNDVI, meta_1 = load_band(file_paths[0], range_index[0])
42 NDVI, meta_2 = load_band(file_paths[1], range_index[1])
43 CCI, meta_3 = load_band(file_paths[2], range_index[2])
44 Tst, meta_4 = load_band(file_paths[3], range_index[3])
45 HTC, meta_5 = load_band(file_paths[4], range_index[4])
46
47 # 4. Load input data
48 index_all = np.stack([GNDVI, NDVI, NDRE, CCI, Tst, HTC], axis=-1)
49
50 index_all = np.stack([GNDVI, NDVI, NDRE, CCI, Tst, HTC], axis=-1)
51
52 # 5. Load Mask
53 mask = np.isnan(GNDVI) # If GNDVI is NaN then mask is NaN
54
55 # 6. Load Mask
56 row, column, band = index_all.shape
57 reshape_band = index_all.reshape((row * column), band)
58
59 # Load Mask
60 non_mask = np.isnan(reshape_band)
61 col_means = np.nanmean(reshape_band, axis=0)
62 reshape_band[non_mask] = np.take(col_means, np.where(non_mask)[0])
63
64 # 7. Load Random Forest
65 predict_class = rf_model.predict(reshape_band)
66
67 # 8. Load input data
68 predict_2d = predict_class.reshape((row, column))
69
70 # 9. Load Mask
71 predict_2d[mask] = 0 # Invalid
72
73 # Load input data
74 Predict_file = r'F:\for_python\RF_model\RF_predict_class_raster\Palae_mask_0.773.tif'
75 meta_4.update(metadata, dtype=rasterio.uint8, count=1) # Load metadata on raster
76
77 with rasterio.open(Predict_file, "w", **meta_4):
78     dst.write(predict_2d.astype(rasterio.uint8), 1)
79
80 print(f"Prediction saved at: {Predict_file}")
81
82 # Load input data
83 plt.figure(figsize=(10, 6))
84 plt.title('Predicted mask? Classification (Masked)')
85 show(predict_2d, cmap='viridis')
86 plt.show()

```

รูปภาคผนวก 2 Code สำหรับใช้โมเดล Random forest ทำนายสุขภาพป่าชายเลน

```

8 import random
9 import numpy as np
10 import pandas as pd
11 import matplotlib.pyplot as plt
12 import joblib
13 from sklearn.metrics import confusion_matrix
14 from sklearn.preprocessing import LabelEncoder
15
16 # 1. Load dataset
17 file_path = "F:\For_The_Visualization_of_Data\dataset"
18 data = pd.read_csv(file_path)
19
20 # 2. Feature selection and label
21 X = data[['X0', 'X1', 'X2', 'X3', 'X4', 'X5', 'X6', 'X7']]
22 y = data['Y']
23 X = X.fillna(X.mean())
24
25 # 3. Feature scaling
26 label_encoder = LabelEncoder()
27 y_encoded = label_encoder.fit_transform(y)
28
29 # 4. Train-test split
30 model_path = "F:\For_The_Visualization_of_Data\model"
31 os.makedirs(model_path, exist_ok=True)
32
33 # 5. Train-test split
34 accuracy_threshold = 0.75
35 model_name = "XGBoost"
36 model_size = 0
37 best_model = None
38 best_acc = 0
39 best_size = None
40 test_size = 0.2
41 test_data = None
42
43 # 6. Loop until condition met
44 while best_accuracy < accuracy_threshold and model_size < max_model_size:
45     model_size += 1
46     train_data, test_data = train_test_split(X, y_encoded, test_size=test_size, random_state=random_state)
47     xgb_model = xgb.XGBClassifier(
48         learning_rate=0.1,
49         max_depth=10,
50         num_parallel_tree=10,
51         n_estimators=1000,
52         subsample=0.8,
53         colsample_bytree=0.8,
54         min_child_weight=10,
55         max_delta_step=1,
56         monotone_constraints=None,
57         num_boost_round=1000,
58         silent=True,
59         warm_start=True,
60     )
61     xgb_model.fit(train_data, test_data)
62     y_pred = xgb_model.predict(test_data)
63     confusion_matrix = confusion_matrix(y_test, y_pred)
64     accuracy = accuracy_score(y_test, y_pred)
65     model_size = xgb_model.get_booster().get_num_trees()
66     model_size = model_size * 1024 * 1024
67     model_size = model_size / 1024 / 1024
68     model_size = model_size * 1024 * 1024
69     model_size = model_size / 1024 / 1024
70     model_size = model_size * 1024 * 1024
71     model_size = model_size / 1024 / 1024
72     model_size = model_size * 1024 * 1024
73     model_size = model_size / 1024 / 1024
74     model_size = model_size * 1024 * 1024
75     model_size = model_size / 1024 / 1024
76     model_size = model_size * 1024 * 1024
77     model_size = model_size / 1024 / 1024
78     model_size = model_size * 1024 * 1024
79     model_size = model_size / 1024 / 1024
80     model_size = model_size * 1024 * 1024
81     model_size = model_size / 1024 / 1024
82     model_size = model_size * 1024 * 1024
83     model_size = model_size / 1024 / 1024
84     model_size = model_size * 1024 * 1024
85     model_size = model_size / 1024 / 1024
86     model_size = model_size * 1024 * 1024
87     model_size = model_size / 1024 / 1024
88     model_size = model_size * 1024 * 1024
89     model_size = model_size / 1024 / 1024
90     model_size = model_size * 1024 * 1024
91     model_size = model_size / 1024 / 1024
92     model_size = model_size * 1024 * 1024
93     model_size = model_size / 1024 / 1024
94     model_size = model_size * 1024 * 1024
95     model_size = model_size / 1024 / 1024
96     model_size = model_size * 1024 * 1024
97     model_size = model_size / 1024 / 1024
98     model_size = model_size * 1024 * 1024
99     model_size = model_size / 1024 / 1024
100    model_size = model_size * 1024 * 1024

```

รูปภาพผนวก 3 Code สำหรับฝึกโมเดล XGboost

```

8 import os
9 import rasterio
10 import numpy as np
11 import joblib
12 from rasterio.plot import show
13
14 # 1. Load dataset
15 model_path = "F:\For_The_Visualization_of_Data\model"
16 xgb_model = joblib.load(model_path)
17
18 # 2. Feature selection and label
19 xgb_model = xgb.XGBClassifier(
20     learning_rate=0.1,
21     max_depth=10,
22     num_parallel_tree=10,
23     n_estimators=1000,
24     subsample=0.8,
25     colsample_bytree=0.8,
26     min_child_weight=10,
27     max_delta_step=1,
28     monotone_constraints=None,
29     num_boost_round=1000,
30     silent=True,
31     warm_start=True,
32 )
33 xgb_model.fit(train_data, test_data)
34 y_pred = xgb_model.predict(test_data)
35 confusion_matrix = confusion_matrix(y_test, y_pred)
36 accuracy = accuracy_score(y_test, y_pred)
37 model_size = xgb_model.get_booster().get_num_trees()
38 model_size = model_size * 1024 * 1024
39 model_size = model_size / 1024 / 1024
40 model_size = model_size * 1024 * 1024
41 model_size = model_size / 1024 / 1024
42 model_size = model_size * 1024 * 1024
43 model_size = model_size / 1024 / 1024
44 model_size = model_size * 1024 * 1024
45 model_size = model_size / 1024 / 1024
46 model_size = model_size * 1024 * 1024
47 model_size = model_size / 1024 / 1024
48 model_size = model_size * 1024 * 1024
49 model_size = model_size / 1024 / 1024
50 model_size = model_size * 1024 * 1024
51 model_size = model_size / 1024 / 1024
52 model_size = model_size * 1024 * 1024
53 model_size = model_size / 1024 / 1024
54 model_size = model_size * 1024 * 1024
55 model_size = model_size / 1024 / 1024
56 model_size = model_size * 1024 * 1024
57 model_size = model_size / 1024 / 1024
58 model_size = model_size * 1024 * 1024
59 model_size = model_size / 1024 / 1024
60 model_size = model_size * 1024 * 1024
61 model_size = model_size / 1024 / 1024
62 model_size = model_size * 1024 * 1024
63 model_size = model_size / 1024 / 1024
64 model_size = model_size * 1024 * 1024
65 model_size = model_size / 1024 / 1024
66 model_size = model_size * 1024 * 1024
67 model_size = model_size / 1024 / 1024
68 model_size = model_size * 1024 * 1024
69 model_size = model_size / 1024 / 1024
70 model_size = model_size * 1024 * 1024
71 model_size = model_size / 1024 / 1024
72 model_size = model_size * 1024 * 1024
73 model_size = model_size / 1024 / 1024
74 model_size = model_size * 1024 * 1024
75 model_size = model_size / 1024 / 1024
76 model_size = model_size * 1024 * 1024
77 model_size = model_size / 1024 / 1024
78 model_size = model_size * 1024 * 1024
79 model_size = model_size / 1024 / 1024
80 model_size = model_size * 1024 * 1024
81 model_size = model_size / 1024 / 1024
82 model_size = model_size * 1024 * 1024
83 model_size = model_size / 1024 / 1024
84 model_size = model_size * 1024 * 1024
85 model_size = model_size / 1024 / 1024
86 model_size = model_size * 1024 * 1024
87 model_size = model_size / 1024 / 1024
88 model_size = model_size * 1024 * 1024
89 model_size = model_size / 1024 / 1024
90 model_size = model_size * 1024 * 1024
91 model_size = model_size / 1024 / 1024
92 model_size = model_size * 1024 * 1024
93 model_size = model_size / 1024 / 1024
94 model_size = model_size * 1024 * 1024
95 model_size = model_size / 1024 / 1024
96 model_size = model_size * 1024 * 1024
97 model_size = model_size / 1024 / 1024
98 model_size = model_size * 1024 * 1024
99 model_size = model_size / 1024 / 1024
100 model_size = model_size * 1024 * 1024

```

รูปภาพผนวก 4 Code สำหรับใช้โมเดล XGboost ทำนายสุขภาพป่าชายเลน

```

8 import random
9 import os
10 import numpy as np
11 import pandas as pd
12 import matplotlib.pyplot as plt
13 from sklearn.metrics import accuracy_score, confusion_matrix
14 from sklearn.model_selection import train_test_split
15 from sklearn.preprocessing import LabelEncoder, StandardScaler
16 import joblib
17
18 # 1. Load dataset
19 file_path = r"C:\Users\thaiy\Documents\python\svm"
20 data = pd.read_excel(file_path)
21
22 # 2. Prepare features and labels
23 X = data[['GNDVI', 'NDVI', 'NDWI', 'CCI', 'Tad', 'WCCI']]
24 y = data['Output']
25 X = X.fillna(-999)
26
27 # 3. Split into train and test
28 model_save_path = r"C:\Users\thaiy\Documents\python\svm\models"
29 os.makedirs(model_save_path, exist_ok=True)
30
31 # 4. Train model
32 label_encoder = LabelEncoder()
33 y_encoded = label_encoder.fit_transform(y)
34
35 # 5. Scale features
36 scaler = StandardScaler()
37 X_scaled = scaler.fit_transform(X)
38
39 # 6. Set loop condition
40 accuracy_threshold = 0.75
41 max_model = 10
42 model_count = 0
43 best_model = None
44 best_accuracy = None
45 best_label_encoder = None
46 best_scaler = None
47 best_x_scaled = None
48
49 # 7. Loop to find best model
50 while best_accuracy < accuracy_threshold and model_count < max_model:
51     model_count += 1
52     rand_state = random.randint(0, 1000)
53     X_train, X_test, y_train, y_test = train_test_split(X_scaled, y_encoded, test_size=0.3, random_state=rand_state)
54     svm_model = SVC(kernel='rbf', C=10, gamma='scale', probability=True, random_state=rand_state)
55     svm_model.fit(X_train, y_train)
56     y_pred = svm_model.predict(X_test)
57     acc = accuracy_score(y_test, y_pred)
58     conf_matrix = confusion_matrix(y_test, y_pred)
59     print(f"Model {model_count} Accuracy: {accuracy:.4f}")
60
61 # 8. Save best model
62 best_model = svm_model
63 best_label_encoder = label_encoder
64 best_scaler = scaler
65 best_x_scaled = X_scaled
66
67 # 9. Save best model
68 joblib.dump(best_model, os.path.join(model_save_path, 'svm_model.pkl'))
69 joblib.dump(best_label_encoder, os.path.join(model_save_path, 'label_encoder.pkl'))
70 joblib.dump(best_scaler, os.path.join(model_save_path, 'scaler.pkl'))
71 joblib.dump(best_x_scaled, os.path.join(model_save_path, 'x_scaled.pkl'))
72
73 # 10. Load best model
74 svm_model = joblib.load(os.path.join(model_save_path, 'svm_model.pkl'))
75 label_encoder = joblib.load(os.path.join(model_save_path, 'label_encoder.pkl'))
76 scaler = joblib.load(os.path.join(model_save_path, 'scaler.pkl'))
77 x_scaled = joblib.load(os.path.join(model_save_path, 'x_scaled.pkl'))
78
79 # 11. Predict
80 y_pred = svm_model.predict(x_scaled)
81 acc = accuracy_score(y_test, y_pred)
82 conf_matrix = confusion_matrix(y_test, y_pred)
83 print(f"Final Accuracy: {accuracy:.4f}")
84 print(f"Confusion Matrix: {conf_matrix}")
85
86 # 12. Plot
87 plt.figure(figsize=(10, 8))
88 plt.title("SVM Predicted Results Classification (Pachira)")
89 show_predict_3d(conf_matrix)
90 plt.show()

```

รูปภาพผนวก 5 Code สำหรับฝึกโมเดล Support Vector Machine

```

8 import os
9 import rasterio
10 import numpy as np
11 import joblib
12 from rasterio.plot import show
13
14 # 1. Load SVM model (.pkl file)
15 model_path = r"C:\Users\thaiy\Documents\python\svm\svm_model.pkl"
16 model_package = joblib.load(model_path)
17
18 svm_model = model_package['svm_model']
19 scaler = model_package['scaler']
20 label_encoder = model_package['label_encoder']
21
22 # 2. Load input data
23 file_paths = [
24     r"C:\Users\thaiy\Documents\python\svm\data\GNDVI_Peiris.tif",
25     r"C:\Users\thaiy\Documents\python\svm\data\NDVI_Peiris.tif",
26     r"C:\Users\thaiy\Documents\python\svm\data\NDWI_Peiris.tif",
27     r"C:\Users\thaiy\Documents\python\svm\data\CCI_Peiris.tif",
28     r"C:\Users\thaiy\Documents\python\svm\data\Tad_Peiris.tif",
29     r"C:\Users\thaiy\Documents\python\svm\data\WCCI_Peiris.tif",
30 ]
31
32 # 3. Load input data
33 range_index = [1, 2, 3, 4, 5, 6]
34
35 def load_band(file_path, valid_range):
36     with rasterio.open(file_path) as src:
37         band = src.read(1, out_shape=(np.float32))
38         band = band[valid_range[0]:valid_range[1]]
39         return band, src.meta
40
41 # 4. Load input data
42 GNDVI, meta_1 = load_band(file_paths[0], range_index[0])
43 NDVI, meta_2 = load_band(file_paths[1], range_index[1])
44 NDWI, meta_3 = load_band(file_paths[2], range_index[2])
45 CCI, meta_4 = load_band(file_paths[3], range_index[3])
46 Tad, meta_5 = load_band(file_paths[4], range_index[4])
47 WCCI, meta_6 = load_band(file_paths[5], range_index[5])
48
49 # 5. Load input data
50 index_all = np.stack([GNDVI, NDVI, NDWI, CCI, Tad, WCCI], axis=1)
51 row, column, band = index_all.shape
52
53 # 6. Load input data
54 mask = np.ones((row, column))
55
56 # 7. Load input data
57 reshape_band = index_all.reshape((row * column, band))
58 col_mask = np.ones((row * column, band))
59 col_mask = np.where(reshape_band, col_mask, 0)
60 reshape_band[~col_mask] = np.nan
61
62 # 8. Load input data
63 x_scaled = scaler.transform(reshape_band)
64
65 # 9. Predict
66 y_pred = svm_model.predict(x_scaled)
67
68 # 10. Load input data
69 x_scaled_scaled = x_scaled * 1
70 predict_3d = x_scaled_scaled.reshape((row, column))
71
72 # 11. Load input data
73 predict_3d[~col_mask] = 0
74
75 # 12. Load input data
76 predict_file = r"C:\Users\thaiy\Documents\python\svm\svm_model.pkl"
77 meta_3 = rasterio.open(predict_file, "r").meta
78
79 # 13. Load input data
80 with rasterio.open(predict_file, "w", meta=meta_3) as dst:
81     dst.write(predict_3d.astype(np.float32), 1)
82
83 # 14. Load input data
84 print(f"Save prediction band to: {predict_file}")
85
86 # 15. Load input data
87 plt.figure(figsize=(10, 8))
88 plt.title("SVM Predicted Results Classification (Pachira)")
89 show_predict_3d(conf_matrix)
90 plt.show()

```

รูปภาพผนวก 6 Code สำหรับใช้โมเดล Support Vector Machine ทำนายสุขภาพป่าชายเลน

ภาคผนวก ข
บรรยากาศการลงพื้นที่ภาคสนาม





รูปภาพผนวก 7 บรรยายภาพการลงพื้นที่ภาคสนาม

ภาคผนวก ค
บรรยากาศการเก็บข้อมูลภาพถ่ายทางอากาศ



รูปภาคผนวก 8 บรรยากาศการเก็บข้อมูลภาพถ่ายทางอากาศ

ประวัติผู้เขียน

ชื่อ สกุล นายภูริช เทพณรงค์
รหัสประจำตัวนักศึกษา 6630221002

วุฒิการศึกษา

วุฒิ	ชื่อสถาบัน	ปีที่สำเร็จการศึกษา
วิทยาศาสตร์บัณฑิต	มหาวิทยาลัยสงขลานครินทร์	2565
(ภูมิสารสนเทศสิ่งแวดล้อม)	วิทยาเขตภูเก็ต	

ทุนการศึกษา (ที่ได้รับในระหว่างการศึกษา)

1. ทุนการศึกษา นักศึกษาระดับบัณฑิตศึกษา คณะเทคโนโลยีและสิ่งแวดล้อม
2. ทุนอุดหนุนการวิจัยเพื่อวิทยานิพนธ์