

การประยุกต์ใช้การเรียนรู้ของเครื่องสำหรับการประเมินสุขภาพ ของป่าชายเลนด้วยอากาศยานไร้คนขับ

An Application of Machine Learning for Mangrove Heath Assessment with Unmanned Aerial Vehicle

ภูริช เทพณรงค์¹ และ วีรนันท์ สงสม^{1,2*}

Phurit Thepnarong¹ and Veeranun Songsom^{1,2*}

¹คณะเทคโนโลยีและสิ่งแวดล้อม มหาวิทยาลัยสงขลานครินทร์ วิทยาเขตภูเก็ต ประเทศไทย

²ศูนย์ฝึกอบรมและบริการด้านเทคโนโลยีภูมิสารสนเทศ คณะเทคโนโลยีและสิ่งแวดล้อม มหาวิทยาลัยสงขลานครินทร์ วิทยาเขตภูเก็ต ประเทศไทย

¹Faculty of Technology and Environment, Prince of Songkla university, Phuket campus, Thailand

²Geoinformatics Services and Training Center, Faculty of Technology and Environment,
Prince of Songkla University, Phuket campus, Thailand

Received: 24 December 2025, Received in revised form: 26 February 2026, Accepted: 3 March 2026

Available online: 10 March 2026

บทคัดย่อ

วัตถุประสงค์และที่มา: ป่าชายเลนเป็นระบบนิเวศสำคัญในเขตร้อนที่มีบทบาททั้งด้านนิเวศวิทยาและเศรษฐกิจ ทำหน้าที่เป็นแหล่งกักเก็บคาร์บอน เป็นถิ่นอาศัยของสิ่งมีชีวิตหลากหลายชนิด ช่วยลดการกัดเซาะชายฝั่ง และบำบัดน้ำเสียก่อนระบายลงสู่ทะเล ดังนั้น การติดตามและประเมินสุขภาพของป่าชายเลนจึงมีความสำคัญต่อการอนุรักษ์ความหลากหลายทางชีวภาพและการบริหารจัดการพื้นที่ชายฝั่งอย่างยั่งยืน อย่างไรก็ตาม วิธีการประเมินสุขภาพป่าชายเลนแบบดั้งเดิมส่วนใหญ่อาศัยการสำรวจภาคสนาม ซึ่งใช้เวลาและทรัพยากรสูง อีกทั้งยังไม่สามารถครอบคลุมพื้นที่ขนาดใหญ่ การประยุกต์เทคโนโลยีสำรวจระยะไกล (Remote Sensing) เช่น ภาพถ่ายดาวเทียม ภาพถ่ายจากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) จึงเป็นเครื่องมือที่สำคัญ แม้ภาพถ่ายดาวเทียมสามารถถ่ายภาพเป็นบริเวณกว้าง แต่เมฆและสิ่งรบกวนในชั้นบรรยากาศเป็นอุปสรรคสำคัญต่อคุณภาพของภาพถ่ายดาวเทียม โดยเฉพาะในเขตร้อนชื้น ดังนั้นภาพถ่ายจาก UAV ที่มีความละเอียดสูงจึงเป็นทางเลือกในการประเมินสุขภาพของป่าชายเลนได้ ทั้งนี้การประเมินสุขภาพของป่าชายเลนจากภาพถ่าย UAV มักอาศัยดัชนีพืชพรรณ (Vegetation Indices) ควบคู่กับเทคนิคการเรียนรู้ของเครื่อง (Machine Learning: ML) แต่การศึกษาเกี่ยวกับการประเมินสุขภาพป่าชายเลนด้วยข้อมูล UAV ยังมีอยู่จำกัด ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อคัดเลือกดัชนีพืชพรรณที่เหมาะสมสำหรับการจำแนกสุขภาพของป่าชายเลนจากภาพถ่าย UAV แบบหลายช่วงคลื่น (Multispectral) และพัฒนา

แบบจำลองการจำแนกสุขภาพของป่าชายเลนโดยใช้อัลกอริทึมการเรียนรู้ของเครื่อง เพื่อให้สามารถติดตามการเปลี่ยนแปลงสุขภาพป่าชายเลนได้อย่างมีประสิทธิภาพและแม่นยำ

วิธีการดำเนินงานวิจัย: การศึกษานี้ดำเนินการในพื้นที่ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต โดยเก็บรวบรวมข้อมูล 2 ส่วน ได้แก่ ข้อมูลภาคสนาม ด้วยการใช้การวัดค่าการสะท้อนเชิงสเปกตรัมของใบไม้โดยใช้เครื่อง Spectroradiometer และข้อมูลภาพถ่ายทางอากาศจาก UAV แบบ Multispectral จากฤดูร้อนและฤดูฝน เพื่อนำมาคำนวณดัชนีพืชพรรณจำนวน 16 ดัชนี ได้แก่ NDVI (Normalized Difference Vegetation Index), GNDVI (Green Normalized Difference Vegetation Index), NDWI (Normalized Difference Water Index), SAVI (Soil Adjusted Vegetation Index), EVI (Enhanced Vegetation Index), NDRE (Normalized Difference Red Edge Index), NDI (Normalized Difference Index), TCARI (Transformed Chlorophyll Absorption Ratio Index), RECI (Red Edge Chlorophyll Index), CCCI (Canopy Chlorophyll Content Index), GCC (Green Chromatic Coordinate), VDV (Visible Difference Vegetation Index), MTCI (MERIS Terrestrial Chlorophyll Index), ExG (Excess Green Index), PSRI (Plant Senescence Reflectance Index) และ VARI (Visible Atmospherically Resistant Index) ภาพถ่ายเรซินยอดป่าชายเลนถูกจัดเก็บด้วย UAV ตามตำแหน่งที่กำหนดและนำมาจำแนกสุขภาพสุขภาพออกเป็นกลุ่มสุขภาพดีและสุขภาพไม่ดี โดยใช้การประเมินด้วยสายตาตามลักษณะสีใบ ความหนาแน่นและความผิดปกติของโครงสร้างเรซินยอด ผลการจำแนกด้วยสายตาถูกตรวจสอบความถูกต้องโดยเปรียบเทียบกับผลการวิเคราะห์สุขภาพพืชจากเครื่อง Spectroradiometer หลังจากนั้นได้ขยายการกำหนดขอบเขตสุขภาพไปยังเรซินยอดของต้นพืชอื่น ๆ เพื่อใช้เป็นข้อมูลอ้างอิงในการพัฒนาแบบจำลอง ML ค่าเฉลี่ยของดัชนีพืชพรรณถูกคำนวณภายในขอบเขตสุขภาพดังกล่าว และคัดเลือกเฉพาะดัชนีที่สามารถแยกความแตกต่างระหว่างเรซินยอดที่มีสุขภาพดีและสุขภาพไม่ดีด้วยวิธีแผนภาพกล่อง (Boxplot) เพื่อใช้เป็นตัวแปรต้นในการพัฒนาแบบจำลอง ML จำนวน 3 วิธี ได้แก่ อัลกอริทึมป่าแบบสุ่ม (Random Forest: RF) เครื่องเวกเตอร์สนับสนุน (Support Vector Machine: SVM) และการเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (Extreme Gradient Boosting: XGBoost) ผลการจำแนกถูกแบ่งออกเป็น 3 กลุ่ม ได้แก่ พื้นที่ที่มีสุขภาพดี พื้นที่ที่มีสุขภาพไม่ดี และพื้นที่อื่น ๆ (น้ำ โคลน และสิ่งปลูกสร้าง) แบบจำลองทั้งสามถูกฝึกซ้ำจำนวน 50 รอบ โดยในแต่ละรอบแบ่งข้อมูลสำหรับการฝึกและการทดสอบในอัตราส่วน 70:30 และเลือกแบบจำลองที่ให้ค่าความแม่นยำโดยรวม (Overall Accuracy) สูงที่สุดจะเป็นแบบจำลองที่เหมาะสมที่สุด ทั้งนี้กระบวนการวิเคราะห์ทั้งหมดดำเนินการด้วยภาษา Python

ผลการวิจัย: ผลการศึกษาพบว่าดัชนีพืชพรรณทั้งหมด 6 ดัชนีจากทั้งหมด 16 ดัชนีที่สามารถแยกความแตกต่างของกลุ่มสุขภาพดีและไม่ดีได้ คือ GNDVI, NDWI, NDRE, CCCI, ExG และ MTCI ทั้งนี้เมื่อนำดัชนีทั้ง 6 ชนิดเป็นตัวแปรนำเข้าสู่แบบจำลอง ML ทั้ง 3 ชนิด (RF, SVM และ XGBoost) พบว่า RF ให้ผลการจำแนกแม่นยำสูงที่สุด ด้วยค่า Overall Accuracy เท่ากับ 77% และค่า Kappa = 0.62 แบบจำลองที่พัฒนาขึ้นยังถูกนำไปทดสอบกับพื้นที่นอกชุดข้อมูลฝึก พบว่ากลุ่มสุขภาพดี

ให้ค่า Producer's Accuracy = 99% และ User's Accuracy = 95% กลุ่มสุขภาพไม่ดีแม้มี Producer's Accuracy = 61% แต่มี User's Accuracy สูงถึง 88% แสดงถึงศักยภาพในการนำไปใช้วิเคราะห์สุขภาพพืชได้อย่างมีประสิทธิภาพ

สรุปผลการวิจัย: งานวิจัยนี้ประยุกต์อัลกอริทึมการเรียนรู้ของเครื่อง 3 ชนิด ได้แก่ RF, SVM และ XGBoost ร่วมกับข้อมูลภาพถ่าย UAV แบบ Multispectral เพื่อประเมินสุขภาพของป่าชายเลน ผลการศึกษายืนยันว่า ภาพถ่าย UAV มีศักยภาพสูงในการจำแนกสุขภาพพืช โดยแบบจำลอง RF ร่วมกับดัชนีพืชพรรณ 6 ดัชนี ได้แก่ GNDVI, NDWI, NDRE, CCCI, ExG และ MTCI ให้ผลลัพธ์ที่ดีที่สุด แบบจำลองที่พัฒนาขึ้นสามารถใช้ในการติดตามสุขภาพของป่าชายเลนทั้งในฤดูร้อนและฤดูฝน รวมถึงสนับสนุนการฟื้นฟู บริหารจัดการ และติดตามการเปลี่ยนแปลงทรัพยากรป่าชายเลนได้อย่างเป็นระบบในระยะยาว

คำสำคัญ: ป่าชายเลน; ภาพถ่ายทางอากาศ; ดัชนีพืชพรรณ; การเรียนรู้ของเครื่อง

Abstract

Background and Objectives: Mangrove forests are important tropical ecosystems that play significant ecological and economic roles. They function as carbon sinks, provide habitats for diverse species, reduce coastal erosion, and treat wastewater before discharge into the sea. Therefore, monitoring and assessing mangrove forest health is essential for biodiversity conservation and sustainable coastal management. However, traditional approaches for assessing mangrove health mainly rely on field surveys, which are time-consuming, resource-intensive, and unable to comprehensively cover large areas. The application of remote sensing technologies, such as satellite imagery and Unmanned Aerial Vehicle (UAV) imagery, has therefore become an important tool. Although satellite imagery can cover extensive areas, cloud cover and atmospheric disturbances pose major limitations to image quality, particularly in tropical humid regions. High-resolution UAV imagery thus represents an alternative for mangrove health assessment. Assessments based on UAV imagery commonly employ vegetation indices in combination with machine learning (ML) techniques; however, studies focusing on mangrove health assessment using UAV data remain limited. Accordingly, this study aims to select appropriate vegetation indices for classifying mangrove health from multispectral UAV imagery and to develop machine learning-based classification models to enable efficient and accurate monitoring of mangrove health changes.

Methodology: This study was conducted in the mangrove forest of Khlong Koh Phi, Phuket Province. Two types of data were collected: field data obtained by measuring leaf spectral reflectance using a spectroradiometer, and multispectral UAV imagery acquired during the summer and rainy seasons. Sixteen vegetation indices were calculated, including NDVI (Normalized Difference Vegetation Index), GNDVI (Green Normalized Difference

Vegetation Index), NDWI (Normalized Difference Water Index), SAVI (Soil Adjusted Vegetation Index), EVI (Enhanced Vegetation Index), NDRE (Normalized Difference Red Edge Index), NDI (Normalized Difference Index), TCARI (Transformed Chlorophyll Absorption Ratio Index), RECI (Red Edge Chlorophyll Index), CCCI (Canopy Chlorophyll Content Index), GCC (Green Chromatic Coordinate), VDVI (Visible Difference Vegetation Index), MTCI (MERIS Terrestrial Chlorophyll Index), ExG (Excess Green Index), PSRI (Plant Senescence Reflectance Index), and VARI (Visible Atmospherically Resistant Index). Mangrove canopy images were collected using UAV at predefined locations and classified into healthy and unhealthy categories based on visual interpretation of leaf color, canopy density, and structural abnormalities. The visual classification results were validated by comparison with plant health analysis obtained from the spectroradiometer. The health boundaries were then extended to other tree canopies to serve as reference data for ML model development. Averaged vegetation index values were calculated within the defined health boundaries, and indices capable of distinguishing between healthy and unhealthy canopies were selected using boxplot analysis as input variables for three ML models: Random Forest (RF), Support Vector Machine (SVM), and Extreme Gradient Boosting (XGBoost). The classification results were divided into three classes: healthy areas, unhealthy areas, and other areas (water, mud, and built-up areas). Each model was trained 50 times, with data split into training and testing sets at a ratio of 70:30 in each iteration. The model achieving the highest Overall Accuracy (OA) was selected as the most suitable model. All analytical processes were conducted using Python.

Main Results: The results indicated that 6 out of the 16 vegetation indices could distinguish between healthy and unhealthy mangrove canopies: GNDVI, NDWI, NDRE, CCCI, ExG, and MTCI. When these six indices were used as input variables for the three ML models (RF, SVM, and XGBoost), RF achieved the highest classification performance, with an Overall Accuracy of 77% and a Kappa coefficient of 0.62. The developed model was further tested on areas outside the training dataset. For the healthy class, Producer's Accuracy was 99% and User's Accuracy was 95%. For the unhealthy class, although Producer's Accuracy was 61%, User's Accuracy reached 88%, indicating the model's potential for effective plant health analysis.

Conclusions: This study applied three machine learning algorithms RF, SVM, and XGBoost in combination with multispectral UAV imagery to assess mangrove forest health. The findings confirm that UAV imagery has high potential for plant health classification. Among the tested models, RF combined with six vegetation indices (GNDVI, NDWI, NDRE, CCCI, ExG, and MTCI) produced the best results. The developed model can be used to

monitor mangrove health in both dry and rainy seasons and to support restoration, management, and long-term systematic monitoring of mangrove forest resources.

Keywords: mangrove health; UAV; Vegetation Index; machine learning

*Corresponding author. Email: veeranun.s@phuket.psu.ac.th

Introduction

ป่าชายเลนเป็นระบบนิเวศสำคัญในเขตร้อนซึ่งมีบทบาททั้งในด้านนิเวศวิทยาและเศรษฐกิจ โดยทำหน้าที่เป็นแหล่งกักเก็บคาร์บอน (Wang *et al.*, 2025) เป็นที่อยู่อาศัยของพืชและสัตว์หลากหลายชนิด อีกทั้งยังช่วยป้องกันการกัดเซาะชายฝั่งและบำบัดน้ำเสียก่อนลงสู่ทะเล (De Dominicis *et al.*, 2023) ดังนั้นการศึกษาสุขภาพของป่าชายเลนจึงมีความสำคัญที่สะท้อนถึงความหลากหลายทางชีวภาพในพื้นที่ชายฝั่ง การประเมินสุขภาพป่าชายเลนแบบเดิมอาศัยการลงพื้นที่ ซึ่งมีข้อจำกัดด้านงบประมาณ เวลา และความต่อเนื่องในการสำรวจ โดยเฉพาะในพื้นที่ขนาดใหญ่ (Meebunmak *et al.*, 2020) การใช้เทคโนโลยีสำรวจระยะไกล เช่น ภาพถ่ายดาวเทียมจึงเป็นทางเลือกที่มีศักยภาพสูงในการติดตามพื้นที่ที่กว้างได้ (Alatorre *et al.*, 2016) ดัชนีพืชพรรณถูกนำมาใช้ในการประเมินสุขภาพของพืชพรรณด้วยข้อมูลจากระยะไกล โดยดัชนีที่นิยมใช้ได้แก่ NDVI (Abdollahnejad & Panagiotidis, 2020; Guerra-Hernández *et al.*, 2021; Prabakaran *et al.*, 2014), SAVI (Simarmata *et al.*, 2022), EVI (Kureel *et al.*, 2021) และ Vegetation health index (VHI) (Abdollahnejad & Panagiotidis, 2020; Bento *et al.*, 2018; Kloos *et al.*, 2021) อย่างไรก็ตาม งานวิจัยส่วนใหญ่มุ่งเน้นการศึกษาป่าบกหรือพืชเกษตรกรรม ซึ่งมีลักษณะระบบนิเวศแตกต่างจากป่าชายเลนอย่างมีนัยสำคัญ งานวิจัยของ Prabakaran *et al.* (2014) ได้ประยุกต์ใช้ดัชนี NDVI สำหรับการประเมินสุขภาพของป่าชายเลน แต่งานวิจัยดังกล่าวใช้วิธีการแบ่งค่าช่วงของดัชนีซึ่งอาจไม่ใช่วิธีการที่เหมาะสม ทั้งนี้ ข้อมูลภาพถ่ายดาวเทียมยังมีข้อจำกัดในการนำไปประยุกต์ใช้กับพื้นที่ศึกษาขนาดเล็ก รวมถึงการรบกวนของเมฆ ด้วยเหตุนี้ การใช้ภาพถ่ายทางอากาศจาก UAV จึงเป็นแนวทางที่เหมาะสมสำหรับการเพิ่มความละเอียดเชิงพื้นที่และความถูกต้องแม่นยำในการประเมินสุขภาพพืชในระบบนิเวศป่าชายเลน นอกจากนี้การประยุกต์ใช้เทคนิค ML ร่วมกับชุดดัชนีพืชพรรณที่หลากหลาย สามารถสนับสนุนให้การจำแนกสถานะสุขภาพของป่าชายเลนมีประสิทธิภาพมากยิ่งขึ้น พร้อมทั้งช่วยลดระยะเวลาในการประมวลผลข้อมูลขนาดใหญ่ที่มีลักษณะซ้ำซ้อน และส่งเสริมให้กระบวนการวิเคราะห์ข้อมูลมีโครงสร้างเป็นระบบ และสามารถทำซ้ำได้

หลายงานวิจัยแสดงให้เห็นถึงความสามารถของ ML ในการจำแนกชนิดพันธุ์ไม้และสุขภาพพืชในป่าบกจากภาพถ่าย UAV (Abdollahnejad & Panagiotidis, 2020; Guerra-Hernández *et al.*, 2021) ขณะเดียวกันภาพถ่ายดาวเทียมถูกนำมาใช้สำหรับการจำแนกชนิดพันธุ์ไม้ป่าชายเลน (Wang, *et al.*, 2008) และการจำแนกพื้นที่ป่าชายเลน (Ghorbanian *et al.*, 2022)

ทั้งนี้งานวิจัยที่ใช้ภาพถ่าย UAV และ ML กับป่าชายเลนส่วนใหญ่เน้นไปที่มวลชีวภาพ (Budiarto & Dewanto, 2025; Li *et al.*, 2024) การนำเทคโนโลยี ML มาประยุกต์ใช้ในการประเมินสุขภาพของป่าชายเลนโดยตรงจากข้อมูลภาพถ่าย UAV แบบ Multispectral จึงอยู่ในวงจำกัด รวมทั้งการคัดเลือกดัชนีพืชพรรณที่เหมาะสมและการประเมินผลในบริบทของความแตกต่างตามฤดูกาล งานวิจัยนี้จึงมุ่งเน้นการประยุกต์ใช้ข้อมูลภาพถ่ายจาก UAV ที่มีความละเอียดเชิงพื้นที่สูงและสามารถสะท้อนลักษณะสุขภาพเรือนยอดของพืชได้โดยตรงเพื่อประเมินสุขภาพของป่าชายเลนได้ พร้อมทั้งบูรณาการการวิเคราะห์ประสิทธิภาพของดัชนีพืชพรรณและการพัฒนาอัลกอริทึม ML สำหรับการจำแนกสุขภาพ ทั้งในฤดูร้อนและฤดูฝน โดยผลการวิจัยสามารถใช้การติดตาม การฟื้นฟู และการบริหารจัดการพื้นที่ป่าชายเลนในอนาคตได้อย่างมีประสิทธิภาพ

Methodology

Figure 1 แสดงกระบวนการดำเนินงานวิจัย งานวิจัยนี้ใช้ข้อมูล 2 ประเภท ได้แก่ ข้อมูลภาพถ่ายทางอากาศจาก UAV และข้อมูลภาคสนาม โดยข้อมูลภาคสนามประกอบด้วย (1) ระดับสุขภาพของป่าชายเลนที่ประเมินจากค่าการสะท้อนเชิงสเปกตรัมของใบพืช และ (2) ภาพถ่ายเรือนยอดของป่าชายเลนที่เก็บด้วย UAV ข้อมูลทั้งหมดถูกนำไปใช้วิเคราะห์ดัชนีพืชพรรณที่หลากหลาย และใช้ในการพัฒนาแบบจำลองด้วยเทคนิค ML เพื่อให้ระบบสามารถเรียนรู้รูปแบบข้อมูลและจำแนกสุขภาพของป่าชายเลนได้อย่างแม่นยำ โดยผลลัพธ์ถูกแสดงในรูปแบบแผนที่สุขภาพป่าชายเลน

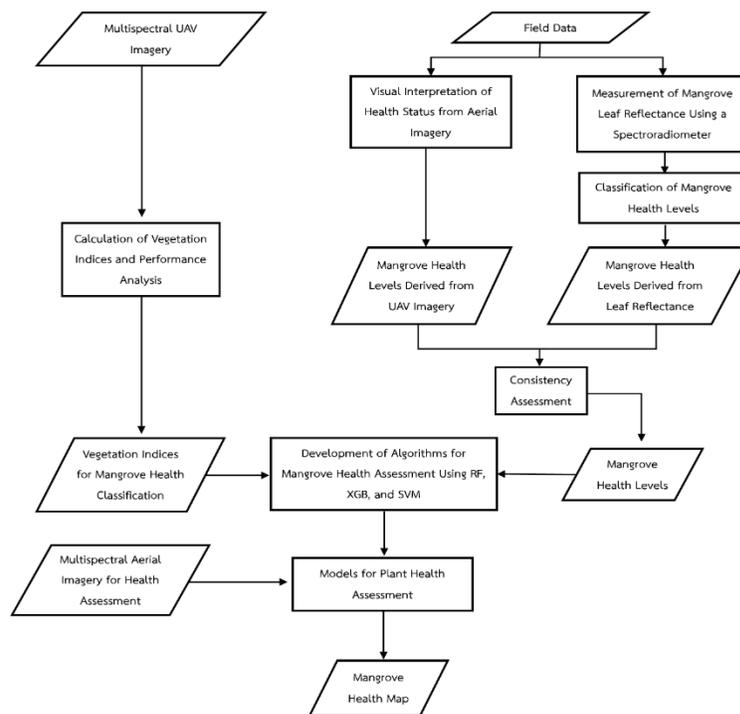


Figure 1 Research Workflow for Mangrove Health Assessment

1. พื้นที่ศึกษา

งานวิจัยนี้ใช้ข้อมูลจากพื้นที่ป่าชายเลนคลองเกาะผี จังหวัดภูเก็ต (Figure 2) ตั้งอยู่ทางฝั่งตะวันออกเฉียงใต้ของจังหวัดภูเก็ต มีเนื้อที่ประมาณ 94,000 ตารางเมตร ในการประเมินขั้นต้น พื้นที่ดังกล่าวมีความแตกต่างของลักษณะสภาพพืช จึงมีความเหมาะสมสำหรับการวิเคราะห์และจำแนกสภาพของป่าชายเลน ชนิดพันธุ์เด่นของป่าชายเลนบริเวณนี้ได้แก่ โกงกางใบเล็ก (*Rhizophora apiculata*) แสมขาว (*Avicennia alba*) ใบพาย (*Aegialitis rotundifolia*) ถั่วขาว (*Bruguiera cylindrica*) ตะบูนขาว (*Xylocarpus granatum*) และแสมดำ (*Avicennia officinalis*) ฤดูกาลในจังหวัดภูเก็ตประกอบด้วย 2 ฤดูกาล ได้แก่ ฤดูร้อน (กุมภาพันธ์ ถึง พฤษภาคม) และฤดูฝน (พฤษภาคม ถึง เดือนตุลาคม) (Amatayakul & Chomtha, 2017)

2. ภาพถ่าย UAV

งานวิจัยนี้ใช้ UAV รุ่น DJI P4 Multispectral โดยบันทึกภาพในช่วงคลื่นสีน้ำเงิน (Blue: 450 nm), สีเขียว (Green: 560 nm) สีแดง (Red: 650 nm) สีขอบแดง (Red Edge: 730 nm) และอินฟราเรดใกล้ (Near Infrared: 840 nm) การเก็บข้อมูลแบ่ง 2 ช่วงฤดู ได้แก่ ฤดูร้อน (พฤษภาคม พ.ศ. 2564) และฤดูฝน (ตุลาคม พ.ศ. 2564) ด้วยแผนการบิน Front Overlap 80% Side Overlap 75% และความสูงการบิน 60 เมตร ทำให้ได้ภาพที่มีความละเอียดเชิงพื้นที่ 3.2 เซนติเมตรต่อจุด ภาพถ่ายถูกประมวลผลในโปรแกรม Pix4Dmapper ทั้งนี้งานวิจัยนี้แบ่งพื้นที่ออกเป็น 2 โซน ได้แก่ พื้นที่พัฒนาแบบจำลอง และพื้นที่ทดสอบแบบจำลอง (Figure 2) เพื่อทดสอบความน่าเชื่อถือของอัลกอริทึม

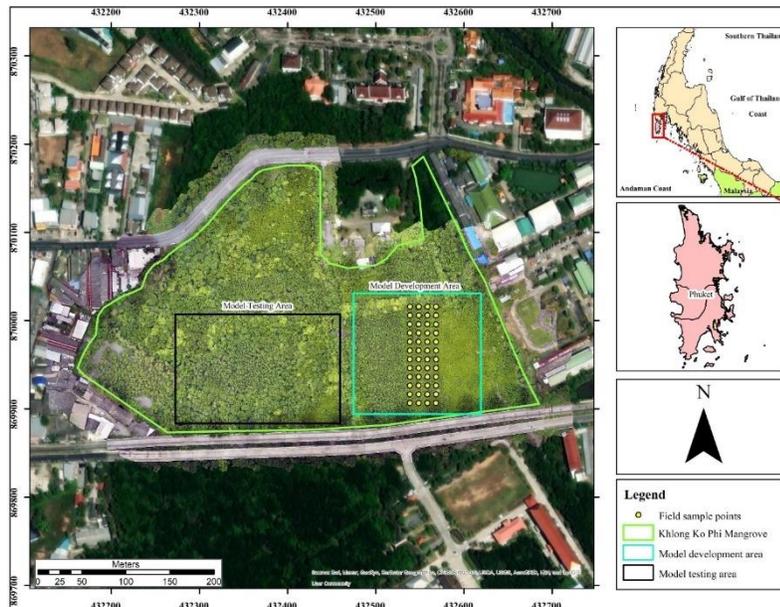


Figure 2 Aerial imagery map of the Khlong Ko Phi mangrove area, Phuket province, showing the model development and testing areas and Map of leaf sampling locations in the mangrove forest of Khlong Ko Phi, Phuket province

3. การจำแนกสุขภาพของเรือนยอดป่าชายเลนด้วยสายตา

ด้วยข้อจำกัดของการเข้าพื้นที่ในป่าชายเลน งานวิจัยนี้ได้ใช้วิธีการแปลภาพถ่ายทางอากาศด้วยสายตา (Visual Interpretation) เพื่อเพิ่มกลุ่มตัวอย่างของสุขภาพของพืช (Ecke *et al.*, 2024; Yin *et al.*, 2024) ภาพถ่ายเรือนยอดของป่าชายเลนถูกถ่ายด้วย UAV โดยการบังคับด้วยมือผ่านแอปพลิเคชันในโทรศัพท์มือถือ ทั้งนี้ตำแหน่งของการถ่ายภาพเรือนยอดห่างกัน 10 เมตร ยกเว้นพื้นที่ทดสอบแบบจำลองกำหนดให้ห่างกัน 20 เมตร ผู้วิจัยประเมินสุขภาพของพืชจากภาพถ่ายด้วยลักษณะสีใบ ความหนาแน่น และความผิดปกติของเรือนยอด โดยพืชที่มีสุขภาพดีมีลักษณะใบสีเขียวเข้ม และพืชสุขภาพไม่ดีมีลักษณะใบสีเหลืองหรือน้ำตาล จากนั้นวาดขอบเขตทรงพุ่มเป็นรูปปิด (Polygon) (Figure 3) เพื่อใช้เป็นกลุ่มตัวอย่างของข้อมูลฝึกและทดสอบ รวมถึงใช้ในการวิเคราะห์ดัชนีพืชพรรณ ในการประเมินความสอดคล้องระหว่างผลการจำแนกจากภาพถ่าย UAV กับข้อมูลภาคสนาม ผู้วิจัยได้ทำการวัดค่าการสะท้อนแสงของใบไม้โดยใช้เครื่อง Spectroradiometer ในช่วงความยาวคลื่น 325-1025 นาโนเมตร ที่ความละเอียดเชิงคลื่น 10 นาโนเมตร และกำหนดจุดเก็บตัวอย่างใบไม้จำนวน 48 จุด (Figure 2) เว้นระยะห่างระหว่างจุด 10 เมตร เพื่อลดผลกระทบจากความคลาดเคลื่อนเชิงตำแหน่งของเครื่อง GPS ภายใต้อากาศแวดล้อมป่าชายเลน ทั้งนี้จุดเก็บตัวอย่างดังกล่าวเป็นตำแหน่งเดียวกับจุดบินถ่ายภาพเรือนยอดของ UAV เพื่อให้สามารถเปรียบเทียบข้อมูลได้โดยตรง อย่างไรก็ตาม การปฏิบัติงานภาคสนามในพื้นที่ป่าชายเลนมีข้อจำกัดด้านช่วงเวลาน้ำขึ้น-น้ำลง ซึ่งส่งผลต่อความปลอดภัยและระยะเวลาในการเก็บข้อมูล อีกทั้งการเก็บตัวอย่างในช่วงเวลาที่แตกต่างกันอาจก่อให้เกิดความแปรปรวนจากการเปลี่ยนแปลงทางสรีรวิทยาของพืชได้ ขั้นตอนการวัดค่าการสะท้อนแสงของใบไม้จึงดำเนินการตามแนวทางของ Zhang *et al.* (2014) โดย Figure 4 แสดงกระบวนการวัดในห้องปฏิบัติการ สำหรับการกำหนดระดับสุขภาพของพืช งานวิจัยนี้อ้างอิงแนวคิดของ Malinee *et al.* (2021) โดยจำแนกสุขภาพใบไม้ออกเป็น 2 ระดับ ได้แก่ สุขภาพดี (Healthy) และสุขภาพไม่ดี (Unhealthy) ทั้งนี้ใบไม้ที่มีสุขภาพดีมีค่าการสะท้อนสูงในช่วงคลื่น Near Infrared (NIR) (Malinee *et al.*, 2021; Zhang *et al.*, 2014) ดังนั้นงานวิจัยนี้จึงประยุกต์เกณฑ์ดังกล่าวกับป่าชายเลน โดยจัดกลุ่มตัวอย่างออกเป็น 2 ระดับ และทำการวิเคราะห์ค่าการสะท้อน (Digital Number: DN) ของใบไม้ในแต่ละช่วงคลื่นเพื่อใช้เป็นข้อมูลอ้างอิงในการจำแนกสุขภาพพืช

4. การคำนวณดัชนีพืชพรรณ

หลังจากประมวลผลภาพถ่ายทางอากาศของแต่ละฤดูกาลและสร้างแผนที่ออร์โธ (orthomosaic) แล้ว ข้อมูลดังกล่าวถูกนำไปใช้ในการคำนวณดัชนีพืชพรรณจำนวน 16 ชนิด จาก 3 กลุ่มดัชนีดังแสดงในตาราง Table 1 ค่าเฉลี่ยของดัชนีพืชพรรณในแต่ละระดับสุขภาพของพืชในพื้นที่ปิด (Figure 3) จะถูกนำไปวิเคราะห์เพื่อคัดเลือกดัชนีพืชพรรณที่มีศักยภาพในการจำแนกระดับสุขภาพของพืช งานวิจัยนี้ใช้การวิเคราะห์เชิงสถิติด้วยแผนภาพกล่อง (Boxplot) เพื่อเปรียบเทียบค่าระหว่างกลุ่มสุขภาพดีและไม่ดี โดยเกณฑ์การพิจารณาประสิทธิภาพของแต่ละดัชนีประกอบด้วย ความแตกต่างของค่ามัธยฐาน (Median) ค่าเฉลี่ย (Mean) การไม่ซ้อนทับของช่วงค่าระหว่างควอไทล์ (Interquartile Range) และช่วงการกระจายของข้อมูล (Min–Max)

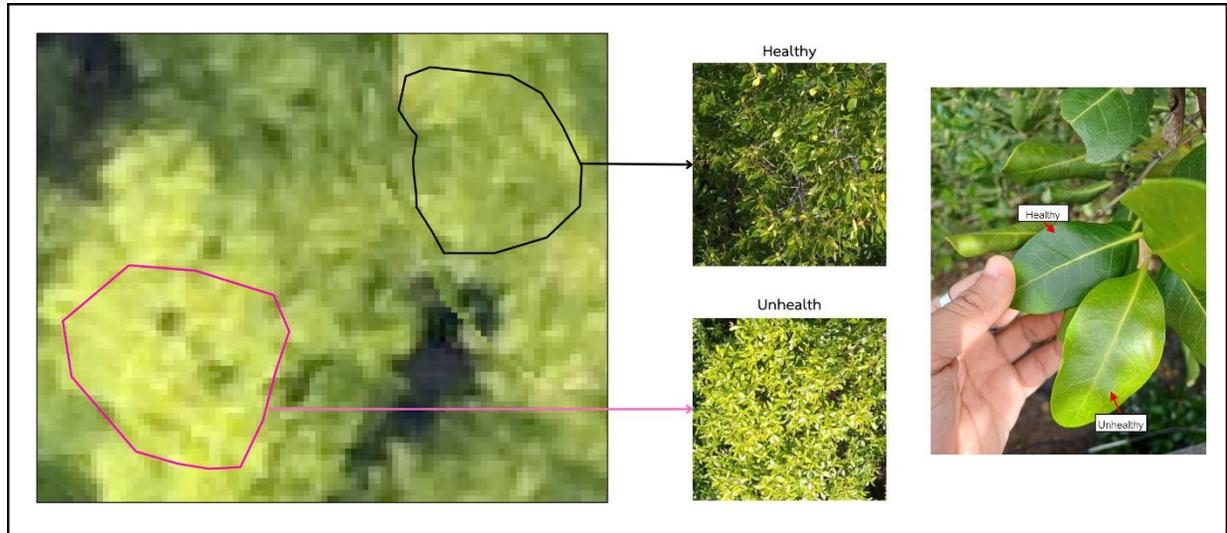


Figure 3 Visual interpretation example of mangrove canopy health classification using high-resolution UAV imagery (Black: healthy, Pink: unhealthy)

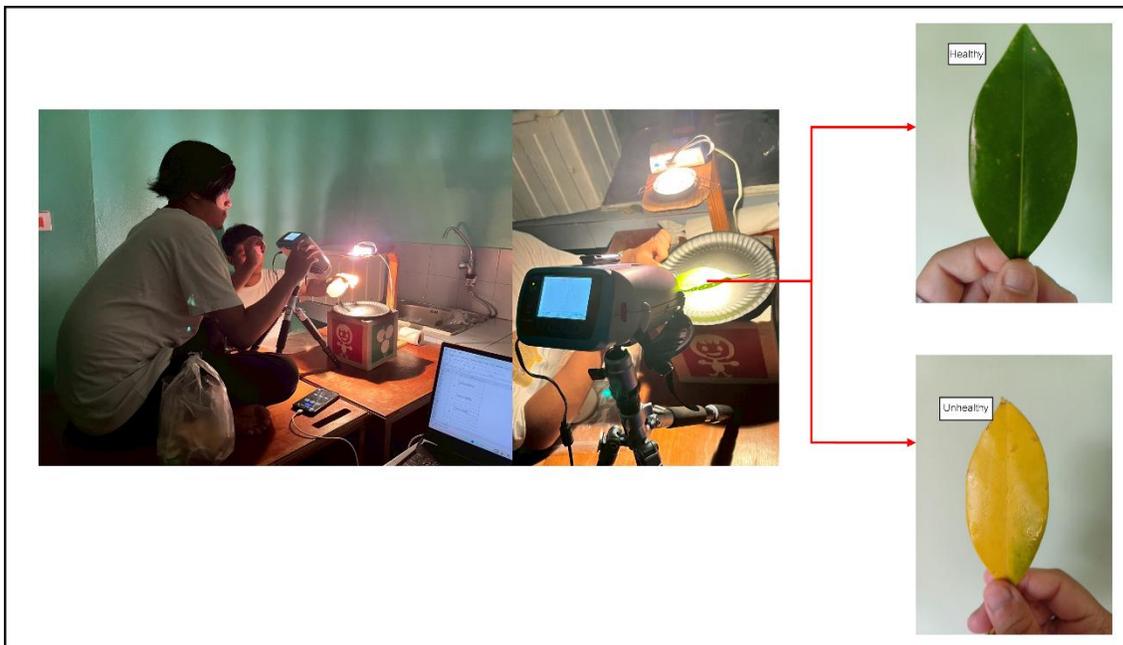


Figure 4 Leaf Reflectance Measurement Performed with a Spectroradiometer

Table 1 Formula for Vegetation Index Calculation.

Groups	Vegetation indices	Equation	Reference
Structural Indices	Normalized Difference Vegetation Index (NDVI)	$NDVI = \frac{NIR - R}{NIR + R}$	(Reed <i>et al.</i> , 1994)
	Green Normalized Difference Vegetation Index (GNDVI)	$GNDVI = \frac{NIR - G}{NIR + G}$	(Gitelson <i>et al.</i> , 1996)
	Enhanced Vegetation Index (EVI)	$EVI = \frac{2.5(NIR - R)}{(NIR + 6R - 7.5B + 1)}$	(Huete <i>et al.</i> , 2002)
	Soil-adjusted Vegetation Index (SAVI)	$SAVI = \left(\frac{NIR - R}{NIR + R + L} \right) \times (1 + L), L = 0.5$	(Huete, 1988)
	Normalized Difference Indices (NDI)	$NDI = \frac{R_{edge} - R}{R_{edge} + R}$	(Woebbecke <i>et al.</i> , 1995)
	Green Chromatic Coordinate (GCC)	$GCC = \frac{G}{R + G + B}$	(Richardson <i>et al.</i> , 2007)
	Visible-band Difference Vegetation Index (VDVI)	$VDVI = \frac{2G - B - R}{2G + B + R}$	(Wang <i>et al.</i> , 2015)
	Excess Green Index (ExG)	$ExG = 2G - R - B + 50$	(Tran <i>et al.</i> , 2022)
	Visible Atmospherically Resistant Index (VARI)	$VARI = \frac{G - R}{G + R - B}$	(Gitelson <i>et al.</i> , 2002)
	Physiological Indices (Chlorophyll)	Normalized Difference Red Edge Index (NDRE)	$NDRE = \frac{NIR - R_{edge}}{NIR + R_{edge}}$

Groups	Vegetation indices	Equation	Reference
	Transformed chlorophyll absorption ratio (TCARI)	$TCARI = 3 \times \left\{ \left[(R_{edge} - R) - 0.2(R_{edge} - G) \right] \times \frac{R_{edge}}{R} \right\}$	(Haboudane <i>et al.</i> , 2002)
	Red Edge Chlorophyll Index (RECI)	$RECI = (NIR - R_{edge}) - 1$	(Gitelson <i>et al.</i> , 2003)
	Canopy Chlorophyll Content Index (CCCI)	$CCCI = \left(\frac{NIR - R_{edge}}{NIR + R_{edge}} \right) \div \left(\frac{NIR - R}{NIR + R} \right)$	(Barnes <i>et al.</i> , 2000)
	MERIS Terrestrial Chlorophyll Index (MTCI)	$MTCI = \frac{NIR - R_{edge}}{R_{edge} - R}$	(Dash & Curran, 2004)
Stress Indices	Plant Senescence Reflectance Index (PSRI)	$PSRI = \frac{R - B}{R_{edge}}$	(Ren <i>et al.</i> , 2017)
	Normalized Difference Water Index (NDWI)	$NDWI = \frac{G - NIR}{G + NIR}$	(McFeeters, 1996)

Note: G = Reflectance of green band, R = Reflectance of red band, B = Reflectance of blue band,

NIR = Reflectance of near infrared band

5. การพัฒนาแบบจำลองสำหรับติดตามสุขภาพของป่าชายเลน

งานวิจัยนี้ใช้แบบจำลอง ML จำนวน 3 ชนิด คือ อัลกอริทึมป่าแบบสุ่ม (Random Forest: RF) เครื่องเวกเตอร์สนับสนุน (Support Vector Machine: SVM) และการเพิ่มประสิทธิภาพเชิงลาดแบบขั้นสุด (Extreme Gradient Boosting: XGBOOST) โดย RF เป็นอัลกอริทึมที่อาศัยหลักการของการรวมผลจากต้นไม้ตัดสินใจหลายต้น (Decision Trees) ซึ่งช่วยลดความแปรปรวนของแบบจำลอง และเพิ่มความแม่นยำของผลลัพธ์ได้อย่างมีประสิทธิภาพ (Purwanto *et al.*, 2023) ในขั้นตอนการฝึกแบบจำลอง RF กำหนดจำนวนต้นไม้ตัดสินใจไว้ที่ 400 ต้น ขณะที่ SVM เป็นอัลกอริทึมที่ใช้การสร้างเส้นแบ่งข้อมูล (Hyperplane) สำหรับจำแนกข้อมูลเชิงเส้นและไม่เชิงเส้น ซึ่งได้กำหนดพารามิเตอร์หลัก C เท่ากับ 1.0 และ gamma เท่ากับ "scale" ส่วน XGBoost เป็นอัลกอริทึมที่ใช้วิธีการเรียนรู้แบบเสริมแรงโดยสะสมข้อผิดพลาดจากแบบจำลองก่อนหน้าแล้วปรับปรุงการพยากรณ์ให้แม่นยำขึ้น งานวิจัยนี้กำหนดพารามิเตอร์ n_estimators เท่ากับ 400 max_depth เท่ากับ 4 และ learning_rate เท่ากับ 0.1 แบบจำลองการจำแนกสุขภาพของป่าชายเลนในงานวิจัยนี้ไม่มีการพัฒนาแยกเป็นฤดูร้อนกับฤดูฝน

แต่จะใช้ข้อมูลทั้งสองฤดูรวมกันสำหรับการพัฒนาแบบจำลองเพียง 1 ชุดที่สามารถใช้ทั้งฤดูร้อนกับฤดูฝน ทั้งนี้งานวิจัยนี้ได้ทำการประมวลผลซ้ำเพื่อทำการสุ่มตัวอย่างของข้อมูลใหม่จำนวน 50 รอบ แต่ละรอบข้อมูลฝึก (Training Data) และข้อมูลทดสอบ (Testing Data) ถูกแบ่งในอัตราร้อยละ 70:30 การประมวลผลซ้ำนี้จัดทำขึ้นเพื่อคัดเลือกแบบจำลองที่ให้ค่า Overall Accuracy สูงที่สุด กระบวนการทั้งหมดดำเนินการด้วยการเขียนโปรแกรมภาษา Python

Results

1. ผลการจำแนกสุขภาพป่าชายเลนจากข้อมูลภาคสนาม

จากการวางแผนเก็บข้อมูลภาคสนามจำนวน 48 ต้น พบว่าสามารถเข้าถึงพื้นที่ได้เพียง 22 ต้น (Figure 5) เนื่องจากข้อจำกัดด้านการเข้าถึงพื้นที่ การวิเคราะห์ค่าการสะท้อนเชิงสเปกตรัมจากเครื่อง Spectroradiometer พบว่ากลุ่มสุขภาพดีมีค่าการสะท้อนสูงกว่าอย่างชัดเจนในช่วงคลื่น Red Edge (688–760 nm) และ NIR (> 800 nm) (Figure 6) โดยช่วงคลื่นดังกล่าวมีศักยภาพสูงในการจำแนกสุขภาพพืชออกจากกันได้อย่างชัดเจน ข้อมูลดังกล่าวสอดคล้องกับการตีความภาพถ่ายจาก UAV และการสังเกตลักษณะใบไม้ภาคสนาม (Table 2) โดยใบสีเขียวเข้มสัมพันธ์กับค่าการสะท้อนสูงและสุขภาพที่ดี ขณะที่ใบสีซีดหรือเหลืองสัมพันธ์กับค่าการสะท้อนต่ำและสุขภาพไม่ดี (Figure 3) ผลการตรวจสอบยืนยันการแปลตีความด้วยสายตาสามารถใช้เป็นวิธีการเพิ่มจำนวนจุดข้อมูลสำหรับการประยุกต์ร่วมกับ ML ได้



Figure 5 Map Showing Sample Collection Locations and Leaf Health Classification in the Mangrove Forest of Khlong Ko Phi and Correlation between leaf sample locations, Visual characteristics, and Spectral reflectance of mangrove vegetation: Unhealthy and healthy show red and blue, respectively.

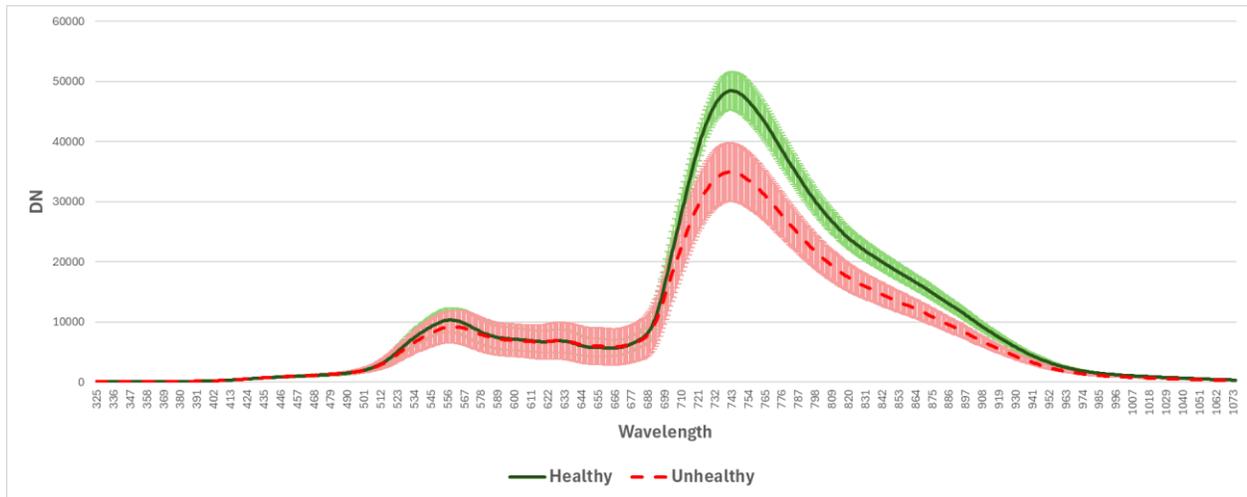


Figure 6 Digital Number (DN) values of mangrove leaf samples plotted against wavelengths, with red shades representing unhealthy leaf samples and green shades representing healthy ones.

Table 2 Comparison of plant health assessment using DN reflectance values and visual interpretation from aerial imagery

Point	Health based on reflectance values	Health based on visual interpretation	Tree canopy characteristics
A001	Unhealthy	Unhealthy	
A003	Healthy	Unhealthy	
A005	Unhealthy	Unhealthy	

Point	Health based on reflectance values	Health based on visual interpretation	Tree canopy characteristics
A006	Healthy	Healthy	
A009	Unhealthy	Unhealthy	
A011	Healthy	Healthy	
A013	Unhealthy	Unhealthy	
A014	Unhealthy	Unhealthy	
A015	Healthy	Healthy	
A018	Unhealthy	Unhealthy	

Point	Health based on reflectance values	Health based on visual interpretation	Tree canopy characteristics
A019	Healthy	Healthy	
A023	Healthy	Healthy	
A025	Unhealthy	Unhealthy	
A026	Unhealthy	Unhealthy	
A027	Healthy	Healthy	
A029	Unhealthy	Unhealthy	
A036	Healthy	Healthy	
A037	Unhealthy	Unhealthy	

Point	Health based on reflectance values	Health based on visual interpretation	Tree canopy characteristics
A042	Unhealthy	Unhealthy	
A044	Unhealthy	Unhealthy	
A046	Unhealthy	Unhealthy	
A048	Unhealthy	Unhealthy	

2. ผลการจำแนกสุขภาพป่าชายเลนจากข้อมูลดัชนีพืชพรรณ

สุขภาพของป่าชายเลนในงานวิจัยนี้แบ่งออกเป็น 2 กลุ่มคือ กลุ่มสุขภาพดีและสุขภาพไม่ดี ทั้งนี้อาศัยการจำแนกสุขภาพด้วยสายตาจากภาพถ่ายเรือนยอดของ UAV โดยอ้างอิงจากลักษณะทรงพุ่ม สีใบ และความหนาแน่นของเรือนยอด ผลการแปลตีด้วยสายตาความสามารถรวบรวมได้ทั้งหมด 1,404 จุด (ทั้งจากฤดูร้อนและฤดูฝน) (Figure 7) แยกเป็นกลุ่มสุขภาพดี 697 จุด กลุ่มสุขภาพไม่ดี 537 จุด และพื้นที่อื่น ๆ 170 จุด จาก Figure 7 พบว่ากลุ่มสุขภาพดีกระจายตัวมากทางฝั่งตะวันตกของพื้นที่ ขณะที่กลุ่มสุขภาพไม่ดีพบกระจายตัวเด่นบริเวณตอนกลางและค่อนข้างไปทางตะวันออก ข้อมูลที่ได้จากการจำแนกด้วยสายตาถูกนำไปใช้ในการวิเคราะห์ดัชนีพืชพรรณเพื่อคัดเลือกตัวแปรที่เหมาะสมสำหรับการสร้างแบบจำลอง และแบ่งออกเป็นชุดข้อมูลฝึกสอน 70% (983 จุด) และชุดข้อมูลทดสอบ 30% (422 จุด) สำหรับการพัฒนาและประเมินประสิทธิภาพของอัลกอริทึมการจำแนกสุขภาพป่าชายเลน

การศึกษานี้ได้ประเมินศักยภาพของดัชนีพืชพรรณจำนวน 16 ดัชนี โดยใช้ช่วงค่าของแต่ละดัชนีแบบเดียวกัน ทั้งฤดูร้อนและฤดูฝน ผลการวิเคราะห์จากแผนที่เชิงพื้นที่ (Table 3) และกราฟ Box Plot (Table 4) พบว่า มี 6 ดัชนี ได้แก่ GNDVI, NDWI, NDRE, CCCI, ExG และ MTCI ที่สามารถแสดงความแตกต่างระหว่างกลุ่มพืชได้อย่างชัดเจนตามเกณฑ์ที่ผู้วิจัยได้

กำหนดไว้ในหัวข้อ Methodology ข้อที่ 4 โดยดัชนีทุกตัวแสดงค่าการสะท้อนของสุขภาพดีสูงกว่าไม่ดี ยกเว้น NDWI และ ExG กราฟ Box Plot ของดัชนีอื่น ๆ แสดงดังตาราง Table S1

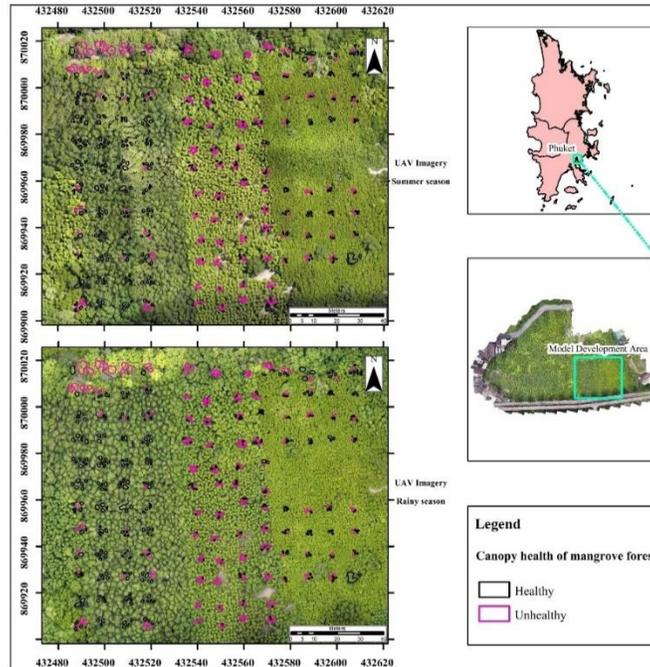


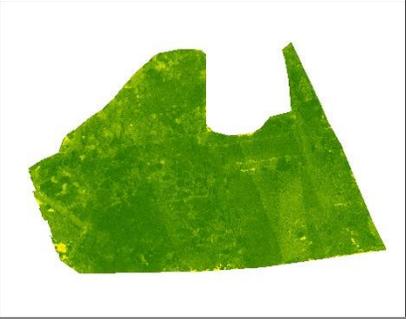
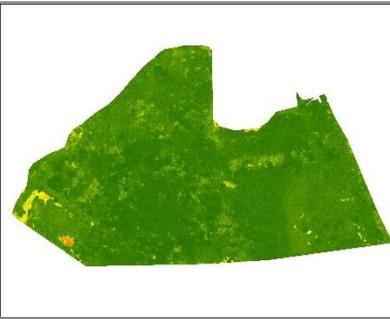
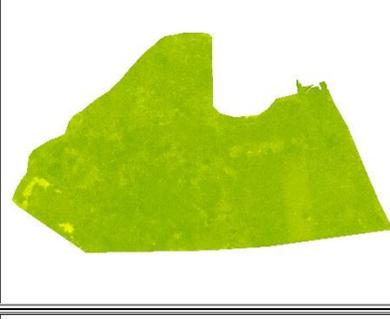
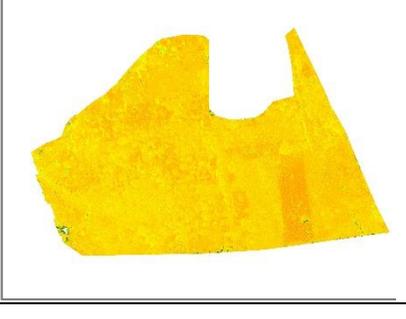
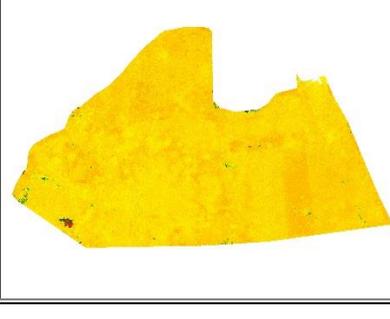
Figure 7 Mangrove canopy health classification map based on visual interpretation of UAV imagery during the dry and wet seasons

4. ผลการจำแนกสุขภาพของป่าชายเลนจากแบบจำลอง

Table 5 – 7 แสดงผลการประเมินความถูกต้องของแบบจำลองจาก SVM, XGBoost และ RF ตามลำดับ การประเมินประสิทธิภาพของแบบจำลองทั้ง 3 ชนิด สำหรับการจำแนกสุขภาพของป่าชายเลนในพื้นที่พัฒนาแบบจำลอง (Figure 2) พบว่าแบบจำลอง RF มีค่า Overall Accuracy มากที่สุด เท่ากับ 77% และค่า Kappa เท่ากับ 0.62 (Table 7) ขณะที่แบบจำลอง SVM และ XGBoost ให้ค่า Overall Accuracy เท่ากับ 71% (Kappa = 0.49) และ 69% (Kappa = 0.47) ตามลำดับ (Table 5 และ 6) ผลการจำแนกของแบบจำลอง RF แสดง Producer's Accuracy ของกลุ่มสุขภาพดี เท่ากับ 80% และ User's Accuracy เท่ากับ 76% แสดงถึงความแม่นยำที่ดี ส่วนกลุ่มสุขภาพไม่ดีมี Producer's Accuracy เท่ากับ 67% และ User's Accuracy 71% แม้จะต่ำกว่ากลุ่มอื่น แต่ยังถือว่ายอมรับได้ในบริบทของป่าชายเลนที่มีความซับซ้อนสูง และกลุ่มพื้นที่อื่น ๆ มีค่าความแม่นยำสูงที่สุดที่ 96% สำหรับทั้ง Producer's Accuracy และ User's Accuracy (Table 7) เนื่องจากแบบจำลอง RF มีค่า Overall Accuracy สูงที่สุด และสามารถจำแนกสุขภาพของพืชในแต่ละกลุ่มได้อย่างชัดเจนทั้งในแง่ของ Producer's

Accuracy และ User's Accuracy งานวิจัยนี้จึงเลือกใช้แบบจำลอง RF เพียงตัวเดียวสำหรับการประเมินสุขภาพป่าชายเลนในพื้นที่อื่นเพิ่มเติมในขั้นตอนถัดไป

Table 3 Vegetation indices derived from UAV imagery in the summer and rainy seasons.

Vegetation index	Summer	Rainy
GNDVI Range: -0.37 to 0.94		
NDWI Range: -0.94 to 0.37		
NDRE Range: -0.78 to 0.87		
CCCI Range: 0.0004 to 0.99		

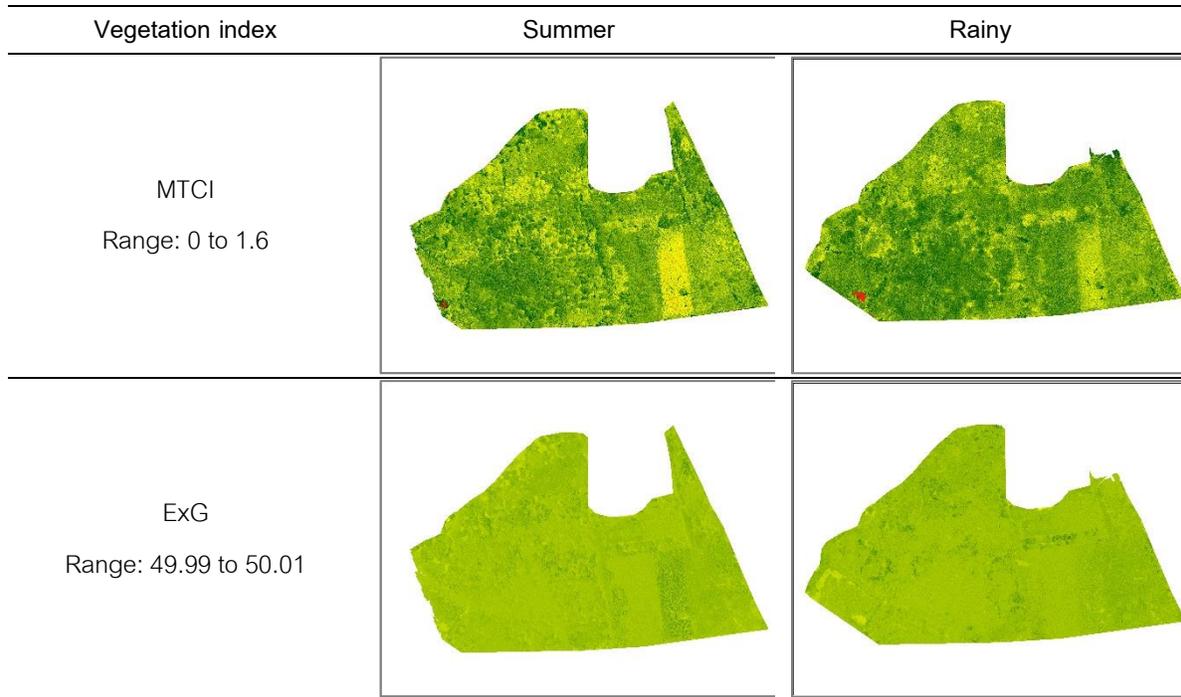
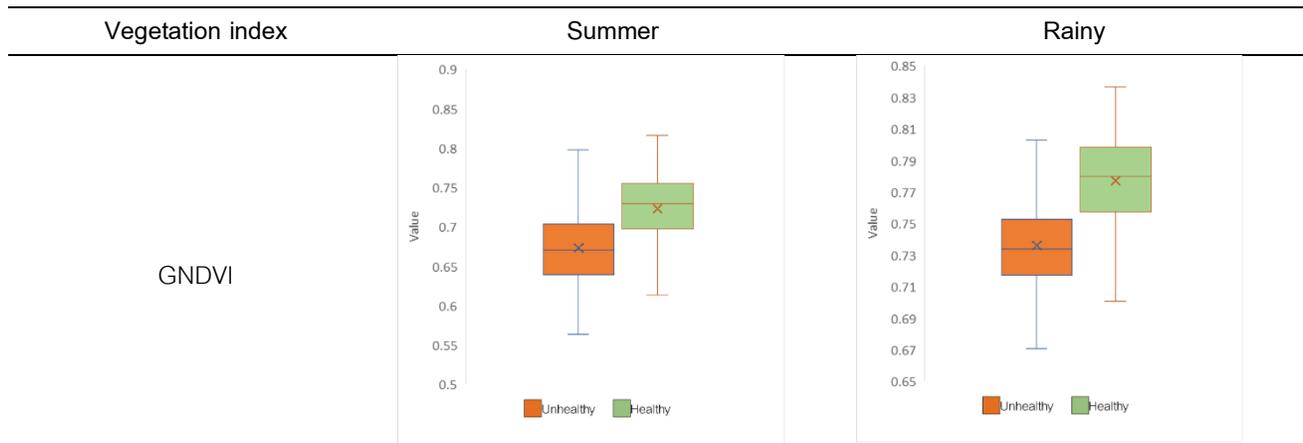
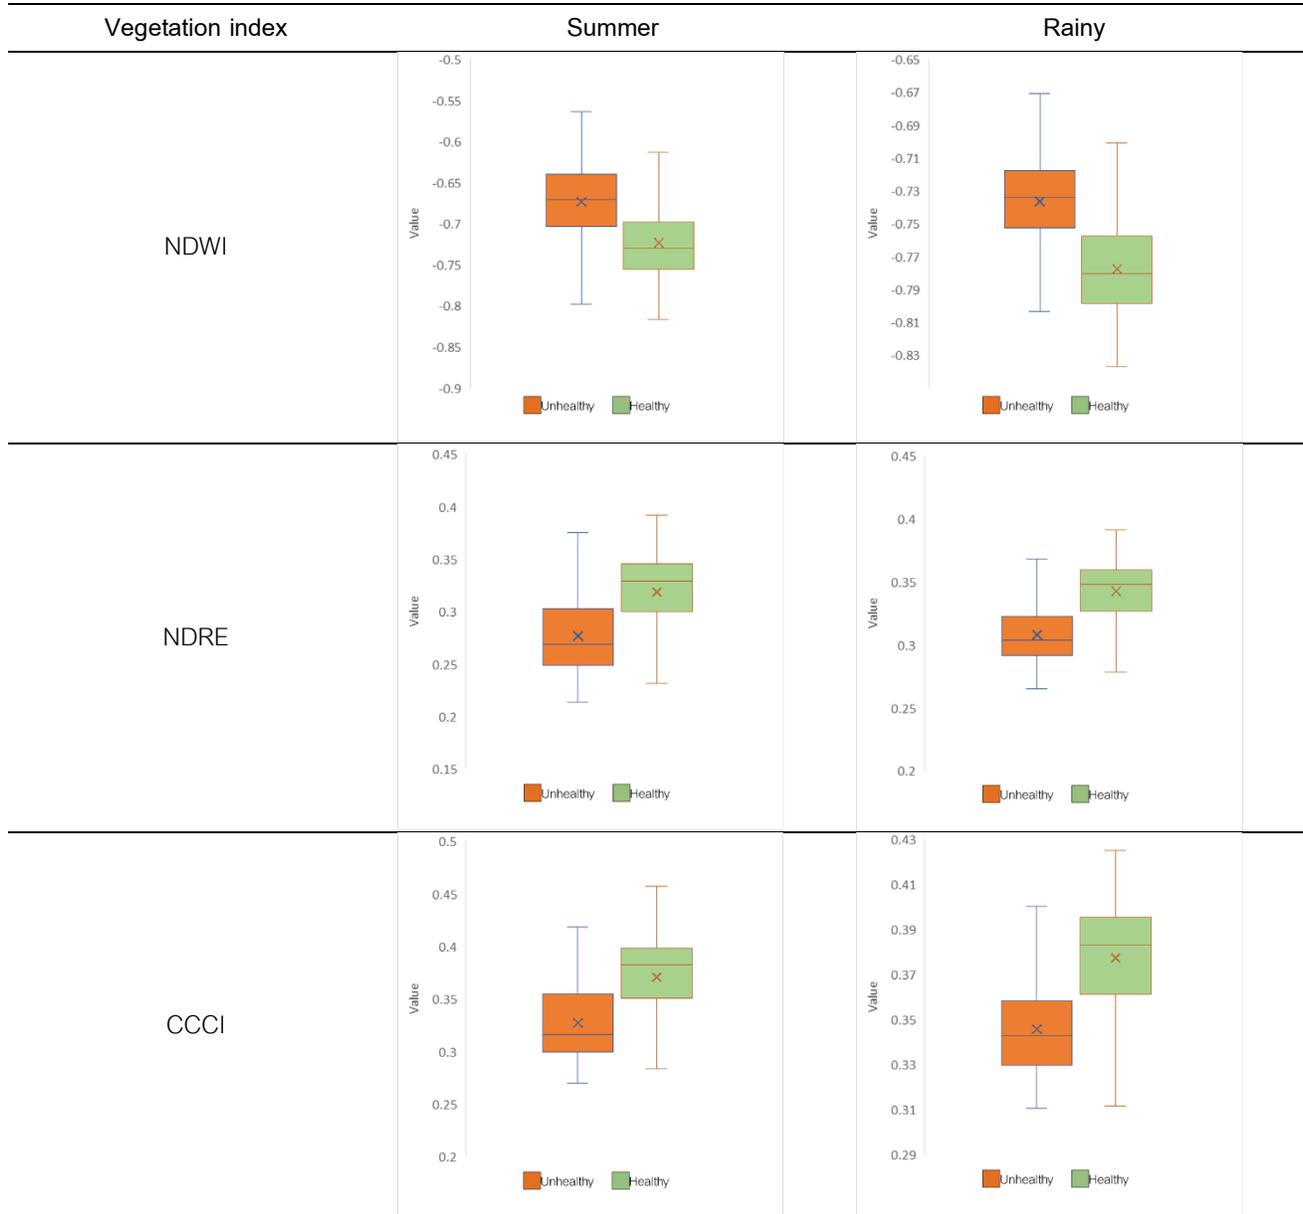


Table 4 Box plots of vegetation indices from UAV imagery during the summer and rainy seasons





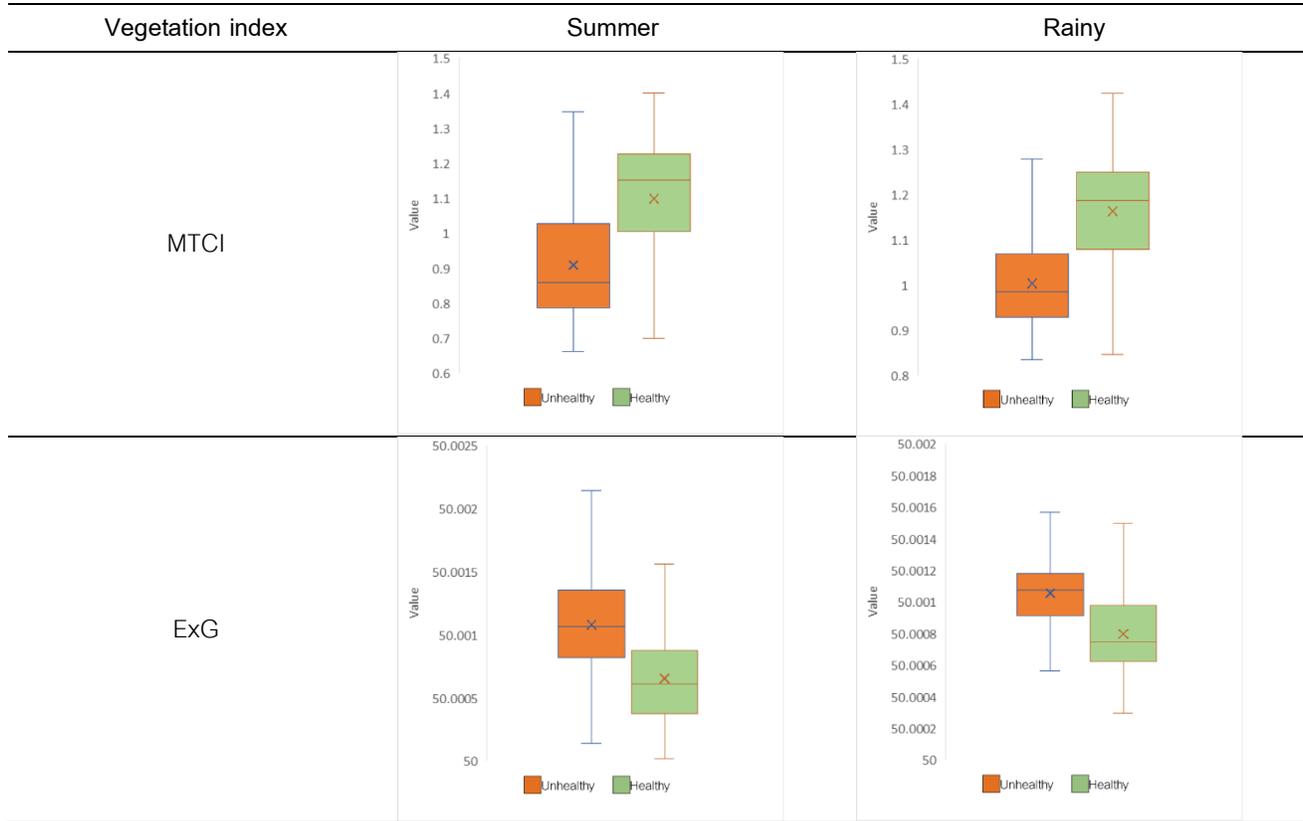


Table 5 Error matrix of mangrove health classification using the SVM model within the model development area (all season data)

Class	Healthy Mangrove	Unhealthy Mangrove	Other Areas	Total Points	User's Accuracy (%)
Healthy Mangrove	161	64	10	235	69
Unhealthy Mangrove	47	105	1	153	69
Other Areas	1	0	33	34	97
Total Points	209	169	44	422	
Producer's Accuracy (%)	77	62	75		
Overall Accuracy (%)				71	
Kappa (Khat)				0.49	

Table 6 Error matrix of mangrove health classification using the XGBoost model within the model development area (all season data)

Class	Healthy Mangrove	Unhealthy Mangrove	Other Areas	Total Points	User's Accuracy (%)
Healthy Mangrove	143	62	1	206	69
Unhealthy Mangrove	63	106	1	170	62
Other Areas	3	1	42	46	91
Total Points	209	169	44	422	
Producer's Accuracy (%)	68	63	95		
Overall Accuracy (%)			69		
Kappa (Khat)			0.47		

Table 7 Error matrix of mangrove health classification using the RF model within the model development area (all season data)

Class	Healthy Mangrove	Unhealthy Mangrove	Other Areas	Total Points	User's Accuracy (%)
Healthy Mangrove	167	51	1	219	76
Unhealthy Mangrove	41	105	1	147	71
Other Areas	1	1	54	56	96
Total Points	209	157	56	422	
Producer's Accuracy (%)	80	67	96		
Overall Accuracy (%)			77		
Kappa (Khat)			0.62		

5. การประเมินประสิทธิภาพของแบบจำลองในพื้นที่ทดสอบ

งานวิจัยนี้ได้กำหนดพื้นที่สำหรับการทดสอบแบบจำลอง (Figure 2) โดยที่ข้อมูลในพื้นที่ดังกล่าวไม่ได้ถูกนำไปใช้ในการพัฒนาแบบจำลอง ซึ่งแสดงถึงการทดสอบประสิทธิภาพของการนำแบบจำลองไปใช้งาน Figure 8 แสดงตำแหน่งของการทดสอบ โดยจำนวนจุดที่ใช้ทดสอบของพืชสุขภาพดี พืชสุขภาพไม่ดี และพื้นที่อื่น ๆ เป็นจำนวน 183, 23 และ 30 จุด ตามลำดับ การประเมินประสิทธิภาพของแบบจำลองในพื้นที่ทดสอบนี้ใช้แบบจำลอง RF เนื่องจากเป็นแบบจำลองที่ให้ความถูกต้องมากที่สุดในพื้นที่พัฒนาแบบจำลอง โดยผลประเมินพบว่าแบบจำลองมีค่า Overall Accuracy เท่ากับ 95% และค่า Kappa เท่ากับ 0.87 ซึ่งจัดอยู่ในระดับสูง สะท้อนถึงความสามารถในการจำแนกกลุ่มสุขภาพได้อย่างแม่นยำ โดยกลุ่มป่าชายเลนสุขภาพดีมีค่า Producer's Accuracy 99% และ User's Accuracy 95% ขณะที่กลุ่มสุขภาพไม่ดีมี Producer's Accuracy 61% และ User's Accuracy 88% แม้จะมีข้อจำกัดในด้านข้อมูลภาคสนาม แต่ยังคงอยู่ในระดับที่น่าเชื่อถือ ส่วนกลุ่มพื้นที่อื่น ๆ มีค่าความแม่นยำสูงสุดที่ 100% ทั้งสองตัวชี้วัด (Table 8)

Figure 9 แสดงผลการนำแบบจำลองการจำแนกสุขภาพของป่าชายเลนด้วยแบบจำลอง RF ที่พัฒนาจากดัชนีพืชพรรณร่วมกับข้อมูลภาคสนาม ไปจำแนกสุขภาพของพืชป่าชายเลนคลองเกาะผี (ตอนบน) ทั้งหมด จากรูปแสดงให้เห็นว่าพื้นที่ส่วนใหญ่ถูกจำแนกเป็นกลุ่มสุขภาพดี (สีเขียว) ขณะที่กลุ่มสุขภาพไม่ดี (สีเหลือง) กระจายตัวในลักษณะหย่อม ๆ โดยเฉพาะบริเวณรอยต่อกับสิ่งปลูกสร้างหรือพื้นที่ที่มีลักษณะเรือนยอดโปร่งและใบชิด ส่วนพื้นที่ที่ไม่ใช่ป่าชายเลน (สีแดง) เช่น ถนน อาคาร และพื้นที่โล่ง ถูกแยกออกอย่างชัดเจน สะท้อนความสามารถของแบบจำลองในการกรองพื้นที่เป้าหมายได้อย่างแม่นยำ นอกจากนี้การกระจายกลุ่มของป่าชายเลนที่สุขภาพไม่ดี (เขตสีเหลือง) ในฤดูร้อนสูงกว่าฤดูฝน และบริเวณพิกัดประมาณ $X = 432550$ และ $Y = 869950$ ปรากฏค่าในเขตสีเหลืองอย่างต่อเนื่องทั้งในช่วงฤดูร้อนและฤดูฝน ซึ่งสะท้อนถึงศักยภาพของแบบจำลองดังกล่าวในการประยุกต์ใช้เพื่อการติดตามและประเมินสุขภาพของระบบนิเวศป่าชายเลนได้

Table 8 Error matrix of mangrove health classification using the RF model within the model testing area (all season data)

Class	Healthy Mangrove	Unhealthy Mangrove	Other Areas	Total Points	User's Accuracy (%)
Healthy Mangrove	181	9	0	190	95
Unhealthy Mangrove	2	14	0	16	88
Other Areas	0	0	30	30	100
Total Points	183	23	30	236	
Producer's Accuracy (%)	99	61	100		
Overall Accuracy (%)			95		
Kappa (Khat)			0.87		

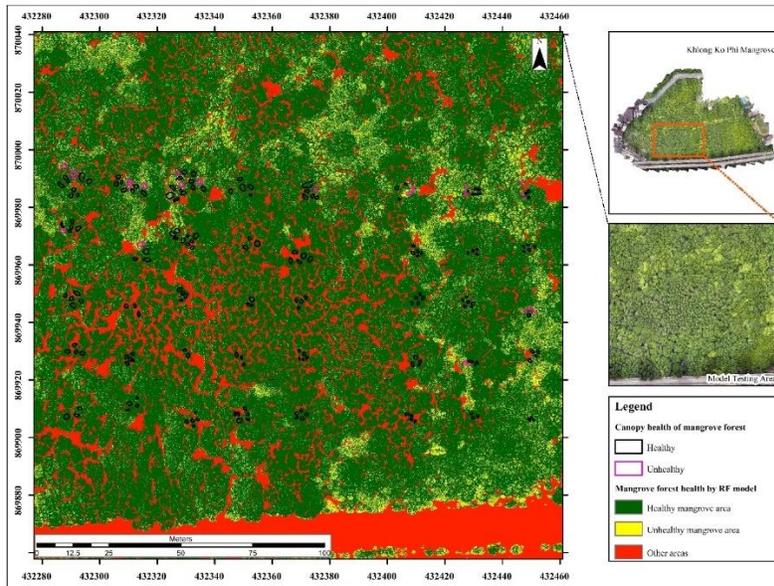


Figure 8 Map showing mangrove health classification using the RF model in the Khlong Ko Phi test area during the rainy season

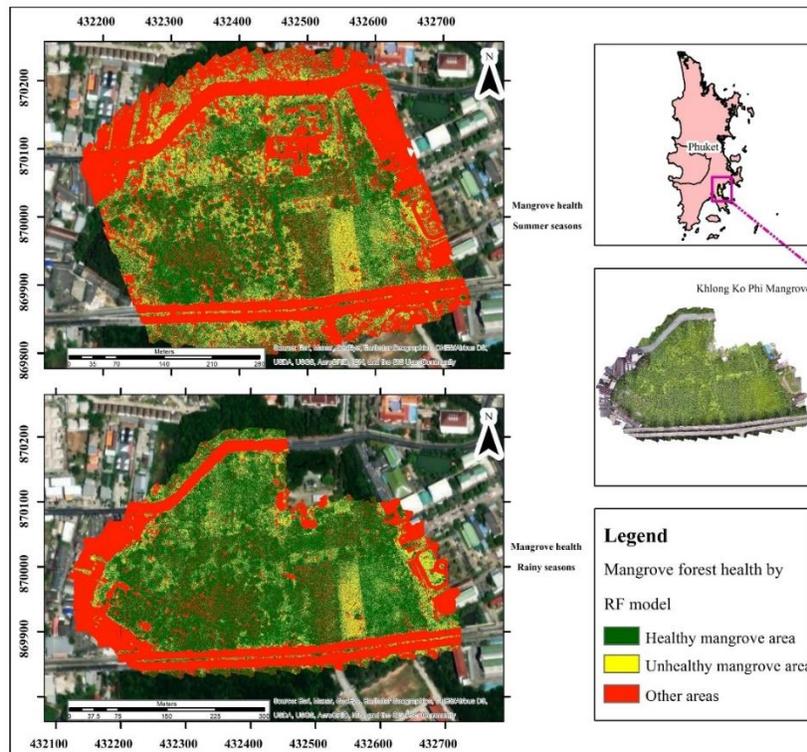


Figure 9 Map showing mangrove health classification using the RF model for both the summer and rainy seasons in the Khlong Ko Phi mangrove area, Phuket Province

Discussion

การพัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลนภาพถ่าย UAV พบว่า ดัชนีพืชพรรณที่เหมาะสมในการจำแนกสุขภาพของป่าชายเลนมีทั้งหมด 6 ดัชนี ได้แก่ CCCI, NDRE, MTCI, GNDVI, NDWI และ ExG จากทั้งหมด 16 ดัชนี โดยเฉพาะดัชนี CCCI, NDRE และ MTCI ซึ่งอาศัยข้อมูลในช่วงคลื่น Red edge และ NIR จัดอยู่ในกลุ่มดัชนีที่มีความไวต่อปริมาณคลอโรฟิลล์และกิจกรรมการสังเคราะห์ด้วยแสงของพืชสูง (Dash *et al.*, 2010; Fanshuri *et al.*, 2023; Pokovai *et al.*, 2025) จึงแสดงประสิทธิภาพสูงในการจำแนกความแตกต่างของระดับสุขภาพพืช ขณะที่ GNDVI และ NDWI ใช้ช่วงคลื่น NIR ร่วมกับแถบสีอื่น ทำให้สามารถสะท้อนความเขียวของพืชและปริมาณน้ำในใบไม้ได้ (Guerra-Hernández *et al.*, 2021) ส่วน ExG เป็นดัชนีที่คำนวณจากช่วงคลื่นที่มองเห็น (Visible) เท่านั้น จึงมีความไวต่อสภาพแสงและลักษณะของพื้นหลัง เช่น เงา น้ำ หรือพื้นดิน ส่งผลให้ค่าการสะท้อนที่ได้จากเรือนยอดของพืชในกลุ่มสุขภาพไม่ดีมีค่าสูงกว่าในกลุ่มสุขภาพดีได้ (Table 4) เช่นเดียวกับ NDWI เนื่องจากสัญญาณสีเขียวสามารถถูกยกดทับโดยปัจจัยแวดล้อมเหล่านั้นมากกว่าคุณสมบัติทางพืชจริง ซึ่งสอดคล้องกับงานวิจัยที่พบว่า ExG มีความไวต่อการเปลี่ยนแปลงของแสงและพื้นผิวที่ซับซ้อน (Abdullah & Yaakob, 2017; Chen *et al.*, 2022)

ผลจากการใช้แบบจำลอง 3 รูปแบบคือ RF, SVM และ XGBoost ในการประเมินสุขภาพของป่าชายเลนพบว่า อัลกอริทึม RF ที่พัฒนาขึ้นสามารถจำแนกสุขภาพของป่าชายเลนได้ โดยพิจารณาจากค่า Producer's Accuracy, User's Accuracy, Overall Accuracy และ Kappa สอดคล้องกับงานวิจัยของ Aziz *et al.* (2023) และ Guerra-Hernández *et al.* (2021) ที่แสดงค่าความแม่นยำของ RF มากที่สุด ทั้งนี้ RF มีความเหมาะสมกับข้อมูลดัชนีพืชพรรณจำนวนมากและมีความทนทานต่อสัญญาณรบกวน ขณะที่ SVM เหมาะกับกรณีที่กลุ่มข้อมูลสามารถแยกได้ชัดเจนแต่มีความไวต่อจำนวนตัวอย่าง และ XGBoost สามารถเรียนรู้รูปแบบข้อมูลที่ซับซ้อนได้ดีแต่ต้องอาศัยข้อมูลที่เพียงพอ ดังนั้นแบบจำลองแต่ละชนิดจึงมีความเหมาะสมในการนำไปประยุกต์ใช้แตกต่างกัน อย่างไรก็ตาม ค่าความแม่นยำของ RF ของงานวิจัยนี้อยู่ระดับปานกลางถึงดี โดยอาจมีสาเหตุจากปัจจัยหลัก 3 ประการ คือ 1) ข้อจำกัดของดัชนีพืชพรรณบางตัวที่มีค่าช่วงใกล้เคียงกันระหว่างกลุ่มสุขภาพดีและสุขภาพไม่ดี ทำให้แบบจำลองเรียนรู้ความแตกต่างได้ไม่เด่นชัด ซึ่งสอดคล้องกับงานวิจัยของ Malinee *et al.* (2021) ที่รายงานว่าดัชนีพืชพรรณไม่สามารถจำแนกระดับความรุนแรงของโรคพืชได้อย่างชัดเจน หรืออาจอยู่ระหว่างสุขภาพดีและไม่ดี จึงจำเป็นต้องมีการพัฒนาเพื่อเพิ่มประสิทธิภาพต่อไป 2) จากการสำรวจภาคสนาม พบว่าภาพรวมสามารถจำแนกสุขภาพของพืชได้ค่อนข้างชัดเจนจากสีของใบและลักษณะเรือนยอด ซึ่งสอดคล้องกับตัวอย่างใน (Figure 4) อย่างไรก็ตาม ในบางกรณีพบพืชที่อยู่ในสภาพก้ำกึ่ง เช่น ใบเริ่มเปลี่ยนสีหรือเรือนยอดไม่สม่ำเสมอ อาจก่อให้เกิดความไม่แน่นอนในการจำแนกระดับสุขภาพ โดยเฉพาะในกลุ่มพืชสุขภาพไม่ดีที่มีจำนวนตัวอย่างค่อนข้างจำกัด และ 3) จำนวนกลุ่มตัวอย่าง เนื่องด้วยข้อจำกัดในการเข้าถึงพื้นที่ทำให้มีผลต่อข้อจำกัดของจำนวนกลุ่มตัวอย่าง อาจมีผลต่อการพัฒนาแบบจำลองของ ML แม้งานวิจัยนี้มีข้อจำกัดดังกล่าว แต่ผลลัพธ์เชิงพื้นที่ของแบบจำลอง RF ยังคงสอดคล้องกับข้อมูลภาคสนามในระดับสูง แสดง

ให้เห็นถึงศักยภาพของแบบจำลองในการระบุพื้นที่สุขภาพดีและสุขภาพไม่ดีได้ เพื่อเพิ่มประสิทธิภาพของอัลกอริทึมในการประเมินสุขภาพป่าชายเลนในอนาคต ควรพิจารณาการใช้ข้อมูลภาพถ่าย UAV แบบไฮเปอร์สเปกตรัม (Hyperspectral) ซึ่งสามารถบันทึกข้อมูลเชิงสเปกตรัมได้อย่างละเอียดและครอบคลุมช่วงคลื่นที่หลากหลายมากกว่าระบบ Multispectral การใช้ข้อมูลดังกล่าวจะช่วยเพิ่มศักยภาพในการจำแนกกลุ่มตัวอย่าง โดยเฉพาะการเพิ่มจำนวนตัวอย่างในกลุ่มสุขภาพไม่ดีให้มีความสอดคล้องกับกลุ่มสุขภาพดี ส่งผลต่อความแม่นยำและความน่าเชื่อถือของแบบจำลอง นอกจากนี้ข้อมูล Hyperspectral ยังเอื้อต่อการประเมินสุขภาพพืชในระดับชนิดพันธุ์ได้อย่างมีประสิทธิภาพ โดยลดความจำเป็นในการเข้าปฏิบัติงานภาคสนามในพื้นที่ป่าชายเลนซึ่งมีข้อจำกัดด้านการเข้าถึงและความปลอดภัย งานวิจัยนี้เสนอให้ดำเนินการเก็บข้อมูลภาพถ่าย UAV ในหลายช่วงเวลาภายในแต่ละฤดูกาล และประมวลผลรวมภาพในลักษณะภาพเชิงประกอบ (Image Composite) เพื่อช่วยลดความแปรปรวนที่เกิดจากแสง สภาพอากาศ และความแตกต่างทางสรีรวิทยาของพืชในแต่ละช่วงเวลา วิธีการดังกล่าวจะช่วยเพิ่มความเสถียรของข้อมูลและยกระดับความแม่นยำของอัลกอริทึมในการติดตามและประเมินสุขภาพของป่าชายเลนในระยะยาว ผลการศึกษานี้แสดงให้เห็นศักยภาพของ UAV ในการติดตามสุขภาพป่าชายเลนเชิงพื้นที่และเชิงเวลา ช่วยระบุพื้นที่ที่มีแนวโน้มเสื่อมโทรมเพื่อจัดลำดับความสำคัญในการฟื้นฟู และสนับสนุนการวางแผนบริหารจัดการทรัพยากรป่าชายเลนอย่างเป็นระบบและต่อเนื่อง ดังที่แสดงผลการจำแนกสุขภาพใน Figure 9 ทั้งในฤดูร้อนและฤดูฝน นอกจากนี้การพิจารณาผลลัพธ์ร่วมกับลักษณะพื้นที่โดยรอบจาก Figure 2 บ่งชี้ว่าพื้นที่เมืองโดยรอบอาจส่งผลต่อสุขภาพป่าชายเลนในพื้นที่ศึกษาดังนั้น หน่วยงานรัฐควรบังคับใช้กฎหมายอย่างเข้มงวดและกำหนดนโยบายสอดคล้องกับ Sustainable Development Goals (SDG) โดยเฉพาะ SDG 13 (แหล่งกักเก็บคาร์บอน) SDG 14 ความหลากหลายทางชีวภาพทางทะเลและชายฝั่ง) และ SDG 15 (ความหลากหลายทางชีวภาพบนบก) เพื่อให้เกิดการอนุรักษ์ป่าชายเลนอย่างยั่งยืน

Conclusions

งานวิจัยนี้ได้พัฒนาอัลกอริทึมสำหรับการติดตามสุขภาพของป่าชายเลน โดยใช้ข้อมูลจาก UAV ทั้งในฤดูร้อนและฤดูฝน ผลการศึกษพบว่า จากดัชนีพืชพรรณทั้งหมด 16 ดัชนี สามารถคัดเลือกดัชนีที่มีศักยภาพสูงในการจำแนกสุขภาพของป่าชายเลนได้ 6 ดัชนี ได้แก่ GNDVI, NDWI, NDRE, CCCI, MTCI และ ExG ซึ่งสามารถสะท้อนความแตกต่างของสุขภาพพืชได้อย่างชัดเจนจากภาพถ่าย UAV แบบ Multispectral เมื่อนำดัชนีพืชพรรณที่ผ่านการคัดเลือกไปใช้ในการพัฒนาแบบจำลองการจำแนกสุขภาพของป่าชายเลนด้วยอัลกอริทึม ML ทั้ง 3 วิธี ได้แก่ RF, SVM และ XGBoost พบว่าแบบจำลอง RF ให้ประสิทธิภาพสูงสุด และสามารถประยุกต์ใช้ได้ทั้งในฤดูร้อนและฤดูฝน ดังนั้น แบบจำลอง RF ที่พัฒนาขึ้นในงานวิจัยนี้ มีศักยภาพในการใช้เป็นเครื่องมือสนับสนุนการติดตาม วางแผน ฟื้นฟู และจัดการทรัพยากรป่าชายเลนได้อย่างมีประสิทธิภาพ และต่อเนื่องในอนาคต อย่างไรก็ตาม งานวิจัยนี้ยังมีข้อจำกัดด้านช่วงเวลาและจำนวนกลุ่มข้อมูลโดยเฉพาะกลุ่มสุขภาพไม่ดี ดังนั้น การเก็บข้อมูลในช่วงเวลาที่หลากหลายมากขึ้น รวมถึงการบูรณาการข้อมูลจากเซนเซอร์ประเภทอื่นบน UAV อาจช่วย

เพิ่มความแม่นยำของแบบจำลองและขยายขีดความสามารถในการประยุกต์ใช้ในพื้นที่ที่กว้างขึ้นได้ โดยรวมแล้ว งานวิจัยนี้แสดงให้เห็นว่าการผสมข้อมูล UAV ดัชนีพืชพรรณ และ ML สามารถใช้ติดตามสุขภาพป่าชายเลน ระบุพื้นที่ที่มีแนวโน้มเสื่อมโทรมเพื่อจัดลำดับความสำคัญในการฟื้นฟู และสนับสนุนการวางแผนบริหารจัดการทรัพยากรป่าชายเลนอย่างเป็นระบบและยั่งยืนได้

Acknowledgments

งานวิจัยนี้ได้รับงบประมาณสนับสนุนการวิจัย จากมหาวิทยาลัยสงขลานครินทร์ “ทุนอุดหนุนการวิจัยเพื่อวิทยานิพนธ์ ประจำปีงบประมาณ 2567” ขอขอบพระคุณ ศูนย์บริหารจัดการทรัพยากรป่าชายเลน จังหวัดภูเก็ต ที่ได้กรุณาอนุเคราะห์พื้นที่ป่าชายเลนสำหรับการลงพื้นที่เก็บข้อมูลภาคสนามและการเก็บภาพถ่ายทางอากาศด้วยอากาศยานไร้คนขับ รวมทั้งให้คำแนะนำในการดำเนินงานเก็บข้อมูลในพื้นที่อย่างดียิ่ง และขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. วีรพันธ์ สงสม อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก ผู้ซึ่งได้กรุณาให้คำแนะนำ ถ่ายทอดความรู้ ตลอดจนให้คำปรึกษาอย่างใกล้ชิดในการดำเนินงานวิจัย

References

- Abdollahnejad, A., & Panagiotidis, D. (2020). Tree species classification and health status assessment for a mixed broadleaf-conifer forest with UAS multispectral imaging. *Remote Sensing*, 12(22), 372.
- Abdullah, W. M., & Yaakob, S. N. (2017). Modified excess green vegetation index for uneven illumination. *International Journal of Current Research*, 9, 48656–48661.
- 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, 98–109.
- Amatayakul, P., & Chomtha, T. (2017). Agricultural meteorology to know for Phuket. *Thai Meteorological Department*. (in Thai)
- Aziz, G., Minallah, N., Saeed, A., Frnda, J., & Khan, W. (2023). Remote sensing based forest cover classification using machine learning. *Scientific Reports*, 14, 69.

Barnes, E. M., Clarke, T. R., Richards, S. E., Colaizzi, P. D., Haberland, J., Kostrzewski, M., Waller, P., Choi, C., Thompson, T., Lascano, R. J., Li, H., & Moran, M. S. (2000). Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. *In Proceedings of the 5th International Conference on Precision Agriculture*.

Bento, V. A., Gouveia, C. M., DaCamara, C. C., & Trigo, I. F. (2018). A climatological assessment of drought impact on vegetation health index. *Agricultural and Forest Meteorology*, 259, 286–295.

Budiarto, R., & Dewanto, B. G. (2025). Unmanned aerial vehicles for assessing biomass and carbon stocks in mangrove forests: A systematic review. *Sustainable Futures*, 10, 101425.

Chen, Y., Fang, S., Sun, M., Liu, Z., Pan, L., Mo, W., & Chen, C. (2022). Mangrove growth monitoring based on camera visible images: A case study on typical mangroves in Guangxi. *Frontiers in Earth Science*, 9, 771753.

Dash, J., & Curran, P. J. (2004). The MERIS terrestrial chlorophyll index. *International Journal of Remote Sensing*, 25(23), 5403–5413.

Dash, J., Curran, P. J., Tallis, M. J., Llewellyn, G. M., Taylor, G., & Snoeijf, P. (2010). Validating the MERIS terrestrial chlorophyll index (MTCI) with ground chlorophyll content data at MERIS spatial resolution. *International Journal of Remote Sensing*, 31(20), 5513–5532.

De Dominicis, M., Wolf, J., van Hespén, R., Zheng, P., & Hu, Z. (2023). Mangrove forests can be an effective coastal defence in the Pearl River Delta, China. *Communications Earth & Environment*, 4, 1–13.

Ecke, S., Stehr, F., Frey, J., Tiede, D., Dempewolf, J., Klemmt, H. J., Endres, E., & Seifert, T. (2024). Towards operational UAV-based forest health monitoring: Species identification and crown condition assessment by means of deep learning. *Computers and Electronics in Agriculture*, 219, 108785.

Fanshuri, B. Al, Prayogo, C., Soemarno, Prijono, S., Arfarita, N. (2023). The reliability of Unmanned Aerial Vehicles (UAVs) equipped with multispectral cameras for estimating chlorophyll content, plant height, canopy area, and fruit total number of Lemons (*Citrus limon*). *Sains Tanah–Journal Soil Sci. Agroclimatol*, 20, 221–230.

- 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*, 14(2), 244.
- Gitelson, A.A., Kaufman, Y.J., Merzlyak, M.N., 1996. Use of a green channel in remote sensing of global vegetation from EOS- MODIS. *Remote Sens. Environ.*, 58, 289–298.
- Gitelson, A. A., Gritz, Y., & Merzlyak, M. N. (2003). Relationships between leaf chlorophyll content and spectral reflectance and algorithms for non-destructive chlorophyll assessment in higher plant leaves. *Journal of Plant Physiology*, 160(3), 271–282.
- Gitelson, A. A., Kaufman, Y. J., Stark, R., & Rundquist, D. (2002). Novel algorithms for remote estimation of vegetation fraction. *Remote Sensing of Environment*, 80(1), 76–87.
- 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*, 8(61),1-21.
- Haboudane, D., Miller, J. R., Tremblay, N., Zarco-Tejada, P. J., & Dextraze, L. (2002). Integrated narrow-band vegetation indices for prediction of crop chlorophyll content for application to precision agriculture. *Remote Sensing of Environment*, 81(2–3), 416–426.
- Huete, A.R., 1988. A soil-adjusted vegetation index (SAVI). *Remote Sens. Environ.*, 25, 295–309.
- 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, 195–213.
- Kloos, S., Yuan, Y., Castelli, M., & Menzel, A. (2021). Agricultural drought detection with MODIS-based vegetation health indices in southeast Germany. *Remote Sensing*, 13(19), 3907.
- Kureel, N., Sarup, J., Matin, S., Goswami, S., & Kureel, K. (2021). Modelling vegetation health and stress using hyperspectral remote sensing data. *Modeling Earth Systems and Environment*, 8, 733–748.

- Li, S., Zhu, Z., Deng, W., Zhu, Q., Xu, Z., Peng, B., Guo, F., Zhang, Y., & Yang, Z. (2024). Estimation of aboveground biomass of different vegetation types in mangrove forests based on UAV remote sensing. *Sustainable Horizons*, *11*, 100100.
- Malinee, R., Stratoulis, D., & Nuthammachot, N. (2021). Detection of oil palm disease in plantations in Krabi Province, Thailand with high spatial resolution satellite imagery. *Agriculture*, *11*, 251.
- McFeeters SK. (1996). The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. *International Journal of Remote Sensing*, *17*(7), 1425-1432.
- Meebunmak, Y., Khamthana, P., Mungkhamanee, S., Boonmee, L., Intana, J., Yatniyom, P., & Sirisabjanan, L. (2020). Field notes: Important instrument for qualitative researchers. *Journal of Nursing and Education*, *13*(3), 1–13. (in Thai)
- 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.
- Pokovai, K., Mészáros, J., Balog, K., Koós, S., Árvai, M., Fodor, N. (2025). Optical leaf area assessment supports chlorophyll estimation from UAV images. *Smart Agric. Technol.*, *11*, 1–10.
- 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 Sensing*, *15*(1), 16.
- Reed, B.C., Brown, J.F., VanderZee, D., Loveland, T.R., Merchant, J.W., Ohlen, D.O., 1994. Measuring phenological variability from satellite imagery. *J. Veg. Sci.*, *5*, 703–714.
- Ren, S., Chen, X., & An, S. (2017). Assessing plant senescence reflectance index-retrieved vegetation phenology and its spatiotemporal response to climate change in the Inner Mongolian grassland. *International Journal of Biometeorology*, *61*(4), 601–612.

- Richardson, A. D., Jenkins, J. P., Braswell, B. H., Hollinger, D. Y., Ollinger, S. V., & Smith, M. L. (2007). Use of digital webcam images to track spring green-up in a deciduous broadleaf forest. *Oecologia*, 152(2), 323–334.
- Simarmata, N., Wikantika, K., Darmawan, S., Harto, A. B., & Santo, A. A. (2022). Evaluation of multispectral image for mangrove health assessment using Sentinel-2A and field spectrometer data. *In 2022 IEEE International Conference on Aerospace Electronics and Remote Sensing Technology (ICARES)* (pp. 1–7).
- Tran, T. V., Reef, R., & Zhu, X. (2022). A review of spectral indices for mangrove remote sensing. *Remote Sensing*, 14(19), 4868.
- 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*, 74(8), 921–926.
- Wang, M., Zhang, T., Xie, Y., Zhang, Z., & Wu, X. (2025). Mapping accumulated carbon storage of global mangroves from 2000 to 2020 at a 1 km resolution. *Scientific Data*, 12, 1–17.
- Wang, X., Wang, M., Wang, S., & Wu, Y. (2015). Extraction of vegetation information from visible unmanned aerial vehicle images. *Transactions of the Chinese Society of Agricultural Engineering*, 31, 152–159.
- Woebbecke, D. M., Meyer, G. E., Von Bargen, K., & Mortensen, D. A. (1995). Color indices for weed identification under various soil, residue, and lighting conditions. *Transactions of the ASAE*, 38(1), 259–269.
- Yin, D., Cai, Y., Li, Y., Yuan, W., & Zhao, Z. (2024). Assessment of the health status of old trees of *Platyclusus orientalis* L. using UAV multispectral imagery. *Drones*, 8, 91.
- 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 Sensing*, 6, 11673–11688.