



การพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อย ด้วยเทคนิคการเรียนรู้ของเครื่องจาก
ดัชนีพืชพรรณหลายช่วงเวลาจากภาพถ่ายอากาศยานไร้คนขับ
Yield Prediction Model of Sugarcane using Multi-temporal Vegetation
Indices with Machine Learning Techniques

ปานไพลิน ชมเชย

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

วิทยานิพนธ์ระดับปริญญาตรี เสนอภาควิชาทรัพยากรธรรมชาติและสิ่งแวดล้อม
คณะเกษตรศาสตร์ ทรัพยากรธรรมชาติและสิ่งแวดล้อม มหาวิทยาลัยนเรศวร

เพื่อเป็นส่วนหนึ่งของการศึกษาหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

สาขาวิชาภูมิศาสตร์

ตุลาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยนเรศวร




ชื่อเรื่องวิทยานิพนธ์ภาษาไทย การพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อย ด้วยเทคนิคการเรียนรู้ของเครื่องจากดัชนีพืชพรรณหลายช่วงเวลาจากภาพอากาศยานไร้คนขับ

ชื่อเรื่องวิทยานิพนธ์ภาษาอังกฤษ Yield Prediction Model of Sugarcane using Multi-temporal Vegetation Indices with Machine Learning Techniques

ผู้ศึกษาวิจัย นางสาว ปานไพลิน ชมเชย

ที่ปรึกษาวิทยานิพนธ์ ผศ.ดร. กัมปนาท ปิยะธำรงชัย

ประเภทสารนิพนธ์ วิทยานิพนธ์ปริญญาตรี วิทยาศาสตร์บัณฑิต (วท.บ.) สาขา ภูมิศาสตร์, มหาวิทยาลัยนเรศวร, 2568


.....
(ผู้ช่วยศาสตราจารย์ ดร. กัมปนาท ปิยะธำรงชัย) (อาจารย์ธัญญาลักษณ์ จันทร์สมบัติ) (ผู้ช่วยศาสตราจารย์ ดร. รังสรรค์ เกตุอืด)
อาจารย์ที่ปรึกษา ประธานบริหารหลักสูตร หัวหน้าภาควิชา
วิทยานิพนธ์ระดับปริญญาตรี วิทยาศาสตร์ สาขาวิชา ทรัพยากรธรรมชาติและสิ่งแวดล้อม

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

ชื่อเรื่อง

การพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อย ด้วยเทคนิคการเรียนรู้ของเครื่องจาก ดัชนีพืชพรรณหลายช่วงเวลาจากภาพถ่ายทางอากาศของไร่คนชัย

ผู้วิจัย

นางสาว ปานไพลิน ชมเชย

ที่ปรึกษาวิทยานิพนธ์

ผศ.ดร. กัมปนาท ปิยะธำรงชัย

ประเภทสารนิพนธ์

วิทยานิพนธ์ปริญญาตรี วิทยาศาสตร์บัณฑิต (วท.บ.) สาขา
ภูมิศาสตร์, มหาวิทยาลัยนเรศวร, 2568

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการคาดการณ์ผลผลิตอ้อย โดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ร่วมกับดัชนีพืชพรรณหลายช่วงเวลา (Multi-temporal Vegetation Indices) ที่ได้จากภาพถ่ายของอากาศยานไร้คนขับติดกล้องมัลติสเปกตรัม (UAV Multispectral Camera) ข้อมูลถูกเก็บจากแปลงอ้อยพันธุ์ขอนแก่น 3 ณ สถานีปฏิบัติการบึงราชนค จังหวัดพิษณุโลก ในพื้นที่ขนาด 6.25 ไร่ แบ่งเป็น 30 แปลงย่อย โดยทำการเก็บข้อมูลในช่วงเดือน มิถุนายน กันยายน และตุลาคม พ.ศ. 2568 จากการประมวลผลค่าดัชนีพืชพรรณ (NDVI) และนำข้อมูลไปสร้างแบบจำลองด้วยเทคนิค Random Forest Regression (RFR) และ XGBoost Regression (XG) พบว่าแบบจำลอง RFR ให้ผลคาดการณ์แม่นยำสูงที่สุด โดยมีค่า $R^2 = 0.8311$, $RMSE = 0.0839$ และ $MAE = 0.0745$ แสดงถึงความสามารถในการอธิบายความแปรปรวนของข้อมูลได้ถึง 83.11% ในขณะที่แบบจำลอง XGBoost มีค่า $R^2 = 0.3759$ ซึ่งต่ำกว่าอย่างมีนัยสำคัญ ผลการวิเคราะห์ความสำคัญของตัวแปร (Feature Importance) พบว่า NDVI เดือนตุลาคม ซึ่งเป็นช่วงก่อนการเก็บเกี่ยว มีอิทธิพลต่อการคาดการณ์ผลผลิตมากที่สุด (51%) รองลงมาคือ NDVI เดือนกันยายน (39%) และ NDVI เดือนมิถุนายน (10%) สะท้อนให้เห็นว่าช่วงปลายฤดูปลูกเป็นช่วงสำคัญที่ส่งผลต่อปริมาณผลผลิตสูงสุด โดยสรุป การใช้ข้อมูลดัชนีพืชพรรณหลายเวลาร่วมกับเทคนิคการเรียนรู้ของเครื่องสามารถเพิ่มความแม่นยำในการคาดการณ์ผลผลิตอ้อยได้อย่างมีประสิทธิภาพ และผลลัพธ์ที่ได้สามารถนำไปประยุกต์ใช้ในการวางแผนและบริหารจัดการเกษตรแม่นยำ (Precision Agriculture) ได้อย่างเหมาะสม

คำสำคัญ: อ้อย, ดัชนีพืชพรรณหลายช่วงเวลา, การสำรวจระยะไกล, อากาศยานไร้คนขับ, GNSS RTK, ระบบสารสนเทศภูมิศาสตร์, เทคนิคการเรียนรู้ของเครื่อง

Title Yield Prediction Model of Sugarcane using Multi-temporal Vegetation Indices with Machine Learning Techniques

Author Panphilin Chomchey

Advisor Assistant Professor Dr. Kampanart Piyathamrongchai

Academic Paper Thesis B.S. in Geography, Naresuan University, 2024

Keyword Sugarcane, Multi-temporal Vegetation Index, Remote Sensing, Multispectral UAV, GNSS RTK, Geographic Information System (GIS), Machine Learning Techniques.

Abstract

This research aimed to develop a sugarcane yield prediction model using machine learning techniques combined with multi-temporal vegetation indices (NDVI) derived from multispectral Unmanned Aerial Vehicle (UAV) imagery. The study was conducted in a 6.25-rai sugarcane field (Khon Kaen 3 variety) located at Bueng Rachanok Field Station, Phitsanulok Province. UAV data were collected in June, September, and October 2025. The vegetation index (NDVI) values were processed and analyzed using Random Forest Regression (RFR) and XGBoost Regression (XG) models. The results showed that the RFR model achieved the highest accuracy with $R^2 = 0.8311$, RMSE = 0.0839, and MAE = 0.0745, explaining 83.11% of the variance in sugarcane yield. In contrast, the XGBoost model performed less effectively with $R^2 = 0.3759$. Feature importance analysis indicated that the NDVI from October, representing the late growing stage before harvest, had the greatest influence on yield prediction (51%), followed by September (39%) and June (10%). These findings highlight the significant role of late-season vegetation indices in sugarcane yield estimation. In conclusion, integrating multi-temporal vegetation indices with machine learning techniques significantly improves the accuracy of sugarcane yield prediction. The resulting spatial yield maps provide valuable insights for precision agriculture and sustainable crop management.

Keywords: Sugarcane, Multi-temporal Vegetation Index, Remote Sensing, Multispectral UAV, GNSS RTK, Geographic Information System (GIS), Machine Learning Techniques

กิตติกรรมประกาศ

วิทยานิพนธ์ระดับปริญญาตรี เรื่อง การพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อย ด้วยเทคนิคการเรียนรู้ของเครื่องจาก ดัชนีพืชพรรณหลายช่วงเวลาจากภาพถ่ายอากาศยานไร้คนขับ (Yield Prediction Model of Sugarcane using Multi-temporal Vegetation Indices with Machine Learning Techniques) ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี เนื่องจากได้รับความอนุเคราะห์และการสนับสนุนจากหลายท่าน ทั้งในด้านข้อมูล คำแนะนำ และกำลังใจ ผู้วิจัยขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.กัมปนาท ปิยะธำรงชัย อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้สละเวลาให้คำปรึกษาอย่างใกล้ชิด ให้ข้อเสนอแนะอันมีคุณค่า และชี้แนะแนวทางการดำเนินงานจนวิทยานิพนธ์ฉบับนี้สำเร็จสมบูรณ์

ขอขอบพระคุณ 1. รองศาสตราจารย์ ดร.ธนชสิทธิ์ พูนไพบูรณ์พิพัฒน์ อาจารย์ภาควิชาวิทยาศาสตร์การเกษตร ผู้ให้ข้อมูลแปลงอ้อยและเอื้อเฟื้อสถานที่ทดลอง ณ สถานีปฏิบัติการบึงราชนกอำเภอวังทอง จังหวัดพิษณุโลก 2. ดร.นพรัตน์ อินตา ผู้ให้ความอนุเคราะห์ในการเก็บข้อมูลภาคสนามและการถ่ายภาพด้วยอากาศยานไร้คนขับในแต่ละช่วงเวลา 3. รองศาสตราจารย์ ดร.สิทธิชัย ชูสำโรง ภาควิชาทรัพยากรธรรมชาติและสิ่งแวดล้อม ที่ให้คำแนะนำด้านการตั้งค่าจุดควบคุมภาคพื้นดิน (GCP) การใช้ระบบ GNSS RTK และการวิเคราะห์ดัชนีพืชพรรณ และ 4. ผู้ช่วยศาสตราจารย์ ดร.กฤษฎา ภาณุมนต์วาทิ ที่ให้คำแนะนำเกี่ยวกับการวางแผนแปลงตัวอย่าง และผู้วิจัยขอขอบคุณเพื่อน ๆ และพี่ ๆ ทุกคนที่มีส่วนร่วมในการเก็บข้อมูลภาคสนาม ทั้งการตีกรอบแปลงอ้อย การวัดข้อมูลเชิงพื้นที่ และการช่วยเก็บเกี่ยวข้อมูลอย่างเต็มความร่วมมือ

สุดท้ายนี้ ผู้วิจัยขอกราบขอบพระคุณ บิดา มารดา และครอบครัว ที่คอยเป็นกำลังใจ สนับสนุนทั้งร่างกายและแรงใจมาโดยตลอด ซึ่งเป็นแรงผลักดันสำคัญให้ผู้วิจัยสามารถดำเนินงานจนสำเร็จลุล่วง ผู้วิจัยหวังเป็นอย่างยิ่งว่า วิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์ต่อผู้ที่สนใจศึกษาด้านภูมิสารสนเทศและการเกษตรแม่นยำ และสามารถนำองค์ความรู้ไปประยุกต์ใช้เพื่อพัฒนาเทคโนโลยีทางการเกษตรให้ก้าวหน้าต่อไป

Copyright by Naresuan University

All rights reserved

ปานไพลิน ชมเชย

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

อุตสาหกรรมอ้อยและน้ำตาลของประเทศไทยมีบทบาทสำคัญต่อเศรษฐกิจและการพัฒนาในระดับประเทศ โดยประเทศไทยจัดอยู่ในลำดับต้น ๆ ของโลกทั้งในด้านการผลิตและการส่งออกน้ำตาล คิดเป็นมูลค่าหลายแสนล้านบาทต่อปี ในปี พ.ศ. 2562 ประเทศไทยมีผลผลิตอ้อยมากกว่า 130 ล้านตัน คิดเป็นมูลค่าประมาณ 176 ล้านบาทสหรัฐ และเป็นผู้ส่งออกน้ำตาลรายใหญ่อันดับ สามของโลก รองจากบราซิลและอินเดีย (Som-ard et al., 2024) แต่อย่างไรก็ตาม อุตสาหกรรมนี้ยังคงประสบปัญหาความผันแปรของผลผลิตในแต่ละฤดูปลูก ซึ่งเกิดจากหลายปัจจัย ทั้งการเปลี่ยนแปลงของสภาพภูมิอากาศ ภัยแล้ง น้ำท่วม โรคและแมลงศัตรูพืช ตลอดจนการบริหารจัดการทรัพยากรที่ยังขาดข้อมูลที่ถูกต้องและทันเวลา

การประเมินผลผลิตอ้อยในปัจจุบันส่วนใหญ่ยังอาศัยการสำรวจภาคสนามโดยใช้แรงงานคน ซึ่งมีข้อจำกัดทั้งในด้านเวลา ความครอบคลุมของพื้นที่ และความแม่นยำ ข้อมูลดังกล่าวจึงอาจไม่สามารถสะท้อนสถานการณ์จริงของพื้นที่เพาะปลูกทั้งหมดได้ นอกจากนี้ การเปลี่ยนแปลงสภาพภูมิอากาศที่ทวีความรุนแรงขึ้นยังทำให้ผลผลิตอ้อยมีแนวโน้มผันผวนมากขึ้น ส่งผลให้การวางแผนจัดสรรวัตถุดิบเข้าสู่โรงงานน้ำตาลและการวางแผนนโยบายทางการเกษตรระดับประเทศขาดความแม่นยำ

ด้วยเหตุนี้ การพัฒนาเทคโนโลยีและเครื่องมือที่สามารถติดตามการเจริญเติบโตของอ้อยและคาดการณ์ผลผลิตได้อย่างมีประสิทธิภาพจึงมีความสำคัญอย่างยิ่ง โดยเฉพาะในยุคของ เกษตรแม่นยำ (Precision Agriculture) ที่เน้นการใช้ข้อมูลเชิงพื้นที่และเทคโนโลยีขั้นสูงเข้ามาช่วยตัดสินใจในกระบวนการผลิต หนึ่งในเทคโนโลยีที่ได้รับความนิยมอย่างแพร่หลายคือ อากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) ซึ่งสามารถติดตั้งกล้องถ่ายภาพแบบมัลติสเปกตรัมเพื่อเก็บข้อมูลเชิงพื้นที่ได้ละเอียดและครอบคลุมในระยะเวลาสั้น อีกทั้งสามารถนำข้อมูลดังกล่าวไปวิเคราะห์ด้วยเทคนิคทาง การเรียนรู้ของเครื่อง (Machine Learning: ML) เพื่อสร้างแบบจำลองความสัมพันธ์ระหว่างดัชนีพืชพรรณกับผลผลิตจริงได้อย่างมีประสิทธิภาพ

งานวิจัยที่ผ่านมาหลายชิ้นได้แสดงให้เห็นถึงศักยภาพของการใช้ภาพจากโดรนและดาวเทียมร่วมกับ Machine Learning ในการคาดการณ์ผลผลิตอ้อย (Pratum et al., 2024; Som-ard et al., 2024; Vargas et al., 2024) อย่างไรก็ตาม ส่วนใหญ่ของการศึกษายังมีข้อจำกัดในด้านขนาดพื้นที่ทดลอง ความต่อเนื่องของข้อมูล และความเฉพาะเจาะจงต่อสภาพพื้นที่และพันธุ์อ้อยของประเทศไทย

นอกจากนี้ การบูรณาการข้อมูลจาก UAV กับระบบสารสนเทศภูมิศาสตร์ (Geographic Information System: GIS) เพื่อสร้างแบบจำลองที่สามารถนำไปประยุกต์ใช้ในเชิงปฏิบัติยังมีอยู่น้อย

ดังนั้น การวิจัยครั้งนี้มีความสำคัญในการพัฒนาแบบจำลองการคาดการณ์ผลผลิตอ้อยโดยอาศัยภาพถ่ายมัลติสเปกตรัมจากโดรนร่วมกับเทคนิคการเรียนรู้ของเครื่องและระบบสารสนเทศภูมิศาสตร์ เพื่อเพิ่มความแม่นยำและลดข้อผิดพลาดในการประเมินผลผลิต นอกจากนี้จะช่วยยกระดับการจัดการข้อมูลของเกษตรกรและโรงงานน้ำตาลแล้ว ยังสามารถนำไปใช้ประกอบการตัดสินใจเชิงนโยบายด้านการวางแผนการผลิตและบริหารจัดการทรัพยากรทางการเกษตรของประเทศได้อย่างมีประสิทธิภาพ อีกทั้งยังเป็นแนวทางสำคัญในการขับเคลื่อนภาคเกษตรกรรมไทยสู่ระบบเกษตรอัจฉริยะ (Smart Agriculture) อย่างยั่งยืน

1.2 วัตถุประสงค์

1. เพื่อศึกษารูปแบบและเทคนิคการเก็บข้อมูลจากอากาศด้วยอากาศยานไร้คนขับ (UAV) ที่ติดกล้องถ่ายภาพแบบหลายช่วงคลื่น (Multispectral)
2. เพื่อวิเคราะห์และประมวลผลค่าดัชนีพืชพรรณ NDVI ที่ได้จากภาพถ่าย UAV ในแต่ละช่วงการเจริญเติบโต
3. สร้างแบบจำลองการคาดการณ์ผลผลิตอ้อยโดยใช้เทคนิค Machine Learning ร่วมกับข้อมูลดัชนีพืชพรรณ (NDVI) ที่ได้จากภาพถ่ายของอากาศยานไร้คนขับ (UAV) และ ประเมินความแม่นยำของโมเดลที่ได้

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร


Copyright by Naresuan University

All rights reserved

1.3 ขอบเขตของงานวิจัย

1.3.1 ขอบเขตด้านพื้นที่

พื้นที่ศึกษาแปลงอ้อยบริเวณสถานีปฏิบัติการบึงราชนก ต. วังพิกุล อ. วังทอง จ. พิษณุโลก เขตพื้นที่ปลูกอ้อยทั้งหมดมีเนื้อที่ประมาณ 32.5 ไร่ ซึ่งในงานวิจัยนี้ศึกษาพื้นที่ขนาด 6.25 ไร่



ภาพที่ 1.1 แผนที่แสดงพื้นที่ศึกษา

1.3.2 ขอบเขตด้านการศึกษา

ในการวิจัยนี้กำหนดขอบเขตการศึกษาในแปลงอ้อยพันธุ์ ขอนแก่น 3 ซึ่งเป็นพันธุ์อ้อยที่มีระยะเวลาเจริญเติบโตเฉลี่ยประมาณ 10–12 เดือน โดยมีการวางแผนเก็บข้อมูลในช่วงเวลาที่สำคัญของการเพาะปลูกและการเก็บเกี่ยว ได้แก่ 1. ช่วงก่อนการปลูก เดือนมีนาคม พ.ศ. 2568 2. ระยะการเจริญเติบโต ในเดือนมิถุนายน เดือนกันยายน และเดือนตุลาคม พ.ศ. 2568 มีการใช้ปุ๋ยสูตร 22-12-18 ในอัตรา 100 กิโลกรัมต่อไร่

งานวิจัยนี้อาศัยการใช้ ภาพถ่ายจากอากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) ติดตั้งกล้องมัลติสเปกตรัม ร่วมกับการ สำรวจข้อมูลภาคสนาม (Field Survey) เพื่อนำข้อมูลที่ได้มาแปรผลและวิเคราะห์ โดยมุ่งเน้นการสร้างและติดตาม ค่าดัชนีพืชพรรณ (Vegetation Indices) รายเดือน ซึ่งสะท้อนถึงสภาพการเจริญเติบโตของอ้อยในแต่ละระยะเวลา จากนั้นจึงนำข้อมูลที่ได้ไปวิเคราะห์ด้วยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อสร้างแบบจำลองเชิงคาดการณ์ผลผลิตของอ้อยที่เปลี่ยนแปลง

1.4 นิยามศัพท์เฉพาะ

อ้อย (*Saccharum officinarum*) หมายถึง พืชเศรษฐกิจที่มีความสำคัญยิ่งต่อประเทศไทย และนานาชาติทั่วโลก จัดอยู่ในวงศ์ Poaceae โดยมีลักษณะทางสัณฐานวิทยาที่โดดเด่น คือ มีลำต้นตั้งตรงแข็งแรง เส้นผ่านศูนย์กลาง 2-6 เซนติเมตร และความสูงเฉลี่ย 2-4 เมตร ลำต้นมีความสามารถในการสะสมซูโครสในระดับสูง ทำให้เป็นแหล่งวัตถุดิบหลักสำหรับอุตสาหกรรมน้ำตาลทรายและผลิตภัณฑ์น้ำตาลประเภทต่างๆ นอกจากนี้ อ้อยยังถือเป็นทรัพยากรพลังงานชีวมวลที่มีศักยภาพสูง สามารถนำไปผลิตเอทานอลและพลังงานทดแทนได้อย่างมีประสิทธิภาพ โดยเฉพาะส่วนที่เหลือใช้ เช่น ใบอ้อยและกากอ้อย สามารถใช้เป็นเชื้อเพลิงชีวมวลหรือปุ๋ยอินทรีย์เพื่อเสริมสร้างความอุดมสมบูรณ์ของดินในระบบการเพาะปลูก ในด้านนิเวศวิทยาการเพาะปลูก อ้อยต้องการสภาพแวดล้อมที่เฉพาะเจาะจง ได้แก่ ดินที่อุดมสมบูรณ์และมีระบบระบายน้ำที่ดี ปริมาณน้ำที่เพียงพอ โดยเฉพาะในช่วงวิกฤตของการงอกและการสะสมน้ำตาลในลำต้น ซึ่งส่งผลกระทบต่อปริมาณและคุณภาพของผลผลิต สภาพภูมิอากาศที่เหมาะสมประกอบด้วยอุณหภูมิสูงและแสงแดดที่เพียงพอ อ้อยจึงเจริญเติบโตได้อย่างเหมาะสมในเขตภูมิอากาศเขตร้อนและกึ่งเขตร้อน ประเทศไทยจึงมีสภาพภูมิอากาศที่เอื้อต่อการปลูกอ้อยเป็นอย่างมาก และกลายเป็นหนึ่งในผู้ผลิตและผู้ส่งออกน้ำตาลรายใหญ่ของโลก

ดัชนีพืชพรรณ (Normalized Difference Vegetation Index : NDVI) หมายถึง ตัวชี้วัดทางสเปกโทรสโกปีที่ใช้ในการประเมินความหนาแน่นและสภาวะสุขภาพของพืชพรรณบนพื้นผิวโลก โดยการคำนวณจากความแตกต่างระหว่างค่าการสะท้อนแสงในช่วงคลื่นอินฟราเรดใกล้ (Near-Infrared : NIR) กับช่วงคลื่นที่ตามองเห็นสีแดง (Red) ตามสูตร

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

ซึ่งให้ค่าผลลัพธ์ในช่วง -1 ถึง +1 โดยพื้นที่ที่มีพืชพรรณเขียวขจีและมีสุขภาพดีจะมีค่า NDVI ในช่วงสูง (0.3-0.8) เนื่องจากใบไม้สีเขียวจะดูดซับแสงสีแดงอย่างมากเพื่อใช้ในกระบวนการสังเคราะห์แสง แต่จะสะท้อนแสงอินฟราเรดใกล้ในปริมาณสูง ในขณะที่พื้นที่ที่เป็นดิน หิน ทราย หรือน้ำจะมีค่า NDVI ต่ำหรือติดลบ ดัชนีนี้ถูกนำไปใช้อย่างแพร่หลายในงานเทคโนโลยีสารสนเทศภูมิศาสตร์ การจัดการทรัพยากรธรรมชาติ การเกษตรแม่นยำ การติดตามการเปลี่ยนแปลงสิ่งแวดล้อม และการประเมินความแห้งแล้ง โดยเฉพาะการประยุกต์ใช้กับข้อมูลจากดาวเทียมสำรวจโลก เช่น Landsat และ Sentinel เพื่อการวิเคราะห์การเปลี่ยนแปลงของพืชพรรณในระยะเวลายาวและการตรวจสอบสุขภาพพืชในพื้นที่กว้าง

เทคนิคการเรียนรู้ของเครื่อง (Machine Learning : ML) หมายถึง สาขาวิชาหนึ่งของปัญญาประดิษฐ์ที่เน้นการพัฒนาและศึกษาขั้นตอนวิธีทางสถิติที่มีความสามารถในการเรียนรู้รูปแบบและทำการพยากรณ์จากข้อมูลโดยอัตโนมัติ โดยไม่จำเป็นต้องให้มนุษย์เขียนโปรแกรม ระบบจะสามารถปรับปรุงประสิทธิภาพการทำงานของตนเองผ่านประสบการณ์ที่ได้รับจากชุดข้อมูล เทคนิคนี้ถูกประยุกต์ใช้อย่างแพร่หลายในหลากหลายสาขา เช่น การวิเคราะห์ข้อมูลขนาดใหญ่ การจดจำรูปแบบ การประมวลผลภาษาธรรมชาติ ระบบแนะนำ การตรวจจับโรค และการขับอัตโนมัติ โดยมีเป้าหมายเพื่อให้เครื่องจักรสามารถทำงานที่ซับซ้อนได้เหมือนสมองมนุษย์ แต่ด้วยความเร็วและความแม่นยำที่สูงกว่า

Random Forest Regression หมายถึง วิธีการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้สำหรับการ วิเคราะห์การถดถอย (Regression Analysis) ซึ่งเป็นเทคนิคการทำนายตัวเลขที่ใช้ต้นไม้ตัดสินใจ (decision trees) หลายต้นพร้อมกัน แต่ละต้นจะสร้างจากตัวอย่างข้อมูลและตัวแปรที่สุ่มเลือกมา จากนั้นเอาผลทำนายของทุกต้นมาหาค่าเฉลี่ย วิธีนี้ช่วยให้โมเดลแม่นยำขึ้นและไม่โดนข้อมูลฝึกสอนมากเกินไป เหมาะสำหรับการทำนายค่าที่ซับซ้อนหรือมีหลายตัวแปร

XGBoost (eXtreme Gradient Boosting) หมายถึง วิธีสร้างโมเดลทำนายค่าหรือจำแนกข้อมูลโดยใช้ ต้นไม้ตัดสินใจ (decision trees) หลายต้น ซึ่งใช้แนวคิดของ การสร้างต้นไม้หลายต้นต่อเนื่อง โดยแต่ละต้นจะพยายามแก้ข้อผิดพลาดจากต้นไม้อีก่อนหน้า จากนั้นรวมผลทั้งหมดเข้าด้วยกัน ทำให้โมเดลแม่นยำและเสถียรกว่าการใช้ต้นไม้ต้นเดียว XGBoost จึงเหมาะกับการทำนายข้อมูลที่ซับซ้อนหรือมีตัวแปรหลายตัว

R^2 (R-squared) หมายถึง ค่าตัวเลขที่เป็นตัวชี้วัดว่าโมเดลสามารถอธิบายความแปรปรวนของข้อมูลได้ดีแค่ไหน มีค่าอยู่ระหว่าง 0-1 ค่าที่ใกล้ 1 หมายความว่า โมเดลพยากรณ์ใกล้เคียงกับค่าจริงมาก


RMSE (Root Mean Squared Error) หมายถึง ค่าเฉลี่ยของความต่าง ระหว่างค่าพยากรณ์กับค่าจริง แต่จะยกกำลังสองก่อนแล้วค่อยถอดรากที่สอง ทำให้ ค่าความผิดพลาดที่มากจะถูกเน้นมากขึ้น จึงเหมาะกับการที่ต้องการให้โมเดลไม่พลาดมาก ๆ

MAE (Mean Absolute Error) หมายถึง ค่าเฉลี่ยของความต่างแบบสัมบูรณ์ระหว่างค่าที่โมเดลทำนายกับค่าจริง หรือเป็นตัวเลขบอกว่าค่าของโมเดลผิดพลาดจากความเป็นจริงโดยเฉลี่ยเท่าไร

1.5 สมมติฐานของการวิจัย

การใช้ข้อมูลดัชนีพืชพรรณหลายช่วงเวลา (Multi-temporal vegetation indices) ร่วมกับเทคนิค Machine Learning จะช่วยเพิ่มความแม่นยำในการคาดการณ์ผลผลิตอ้อยเมื่อเทียบกับการใช้ข้อมูลเพียงช่วงเวลาเดียว

1.6 กรอบแนวคิด



ภาพที่ 1.2 กรอบแนวความคิด

งานวิจัยนี้เป็นการประยุกต์ใช้อากาศยานไร้คนขับ (UAV) ที่ติดตั้งกล้องมัลติสเปกตรัมร่วมกับระบบ D-RTK 2 GNSS Mobile Station เพื่อพัฒนาแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) สำหรับการคาดการณ์ผลผลิตอ้อย (Sugarcane Yield Prediction) โดยมีขั้นตอนการดำเนินงานหลัก 2 ส่วน ได้แก่

การเก็บข้อมูลภาคสนาม (Field Survey Data) ทำการกำหนดแปลงทดลองภายในพื้นที่ปลูกอ้อย แล้วทำการเก็บข้อมูลความสูง เส้นผ่านศูนย์กลาง จำนวนลำ และน้ำหนักเฉลี่ยของลำอ้อย เพื่อคำนวณหาค่าผลผลิตจริง (Yield Computation) ของแต่ละแปลง

การเก็บและประมวลผลข้อมูลจากอากาศยาน (UAV Data Processing) ทำการบินสำรวจพื้นที่ปลูกอ้อยในแต่ละช่วงการเจริญเติบโต โดยวางจุดควบคุมภาคพื้น (GCPs) และวางแผนเส้นทางบินด้วยโปรแกรม DJI GS PRO เพื่อเก็บภาพถ่ายทางอากาศ (RGB และ Multispectral) ข้อมูลที่ได้จะถูกประมวลผลด้วยโปรแกรม WebODM และ DJI Terra เพื่อสร้างแบบจำลองภูมิประเทศเชิงเลข (DSM) สำหรับประเมินความสูงของลำอ้อย ภาพ Orthomosaic (RGB) และภาพ NDVI เพื่อคำนวณค่าดัชนีพืชพรรณ (Vegetation Indices: VIs) จากนั้นนำข้อมูล NDVI และความสูงของอ้อยมาวิเคราะห์เชิงพื้นที่ด้วยเครื่องมือ Zonal Statistics ในโปรแกรม QGIS เพื่อสกัดค่าดัชนีในแต่ละกริดและส่งออกข้อมูลในรูปแบบ CSV สำหรับใช้สร้างแบบจำลองการเรียนรู้ของเครื่อง

การพัฒนาแบบจำลองการเรียนรู้ของเครื่อง (Machine Learning) ใช้ค่าดัชนี NDVI จากภาพถ่ายทั้งสามช่วงเวลา (NDVI_t1, NDVI_t2, NDVI_t3) เป็นตัวแปรอิสระ (X) และใช้น้ำหนักเฉลี่ยของลำอ้อยจากข้อมูลภาคสนามเป็นตัวแปรตาม (Y) เพื่อสร้างแบบจำลองคาดการณ์ผลผลิต โดยใช้เทคนิค Random Forest Regression (RFR) และ XGBoost Regression (XG) โดยแบ่งข้อมูลเป็นชุดฝึก (Training set) ร้อยละ 60 และชุดทดสอบ (Testing set) ร้อยละ 40 จากนั้นประเมินประสิทธิภาพของแบบจำลองด้วยค่าตัวชี้วัดทางสถิติ ได้แก่ ค่าสัมประสิทธิ์การตัดสินใจ (R^2) และ ค่ารากที่สองของความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) พร้อมเปรียบเทียบความถูกต้องของทั้งสองแบบจำลอง เพื่อเลือกเทคนิคที่เหมาะสมที่สุดสำหรับการคาดการณ์ผลผลิตอ้อย

1.7 ประโยชน์ที่คาดว่าจะได้รับ

การพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อยจากด้วยเทคนิคการเรียนรู้ของเครื่องจากดัชนีพืชพรรณหลายช่วงเวลาจากภาพถ่ายอากาศยานไร้คนขับ คาดว่าจะสามารถเพิ่มความแม่นยำในการคาดการณ์ผลผลิตอ้อยได้อย่างมีนัยสำคัญ ด้วยการใช้ข้อมูลดัชนีพืชพรรณ (NDVI) จากภาพถ่ายอากาศยานไร้คนขับ (UAV) ในหลายช่วงคลื่น (Multi-temporal) ที่มีความละเอียดสูง ซึ่งจะช่วยให้เข้าใจพลวัตการเจริญเติบโตของอ้อยตลอดฤดูกาลได้ดีกว่าวิธีดั้งเดิม และช่วยสนับสนุนการตัดสินใจและวางแผนการจัดการผลผลิตได้อย่างมีประสิทธิภาพและทันเวลา ตั้งแต่การจัดเตรียมวัตถุดิบ การวางแผนการเก็บเกี่ยว และการจัดการด้านการขนส่ง ซึ่งจะช่วยลดความสูญเสียเปล่าของทรัพยากรและเพิ่มผลกำไรสูงสุดให้กับเกษตรกรและโรงงานน้ำตาล เป็นแนวทางสำคัญในการพัฒนาเทคโนโลยีการเกษตรอัจฉริยะ (Smart Farming) ในประเทศไทย โดยเป็นตัวอย่างของการนำเทคโนโลยีการสำรวจระยะไกลและการเรียนรู้ของเครื่องมาประยุกต์ใช้เพื่อเพิ่มประสิทธิภาพการผลิตในภาคเกษตรกรรม และยังสามารถขยายการประยุกต์ใช้ไปยังพืชเศรษฐกิจชนิดอื่น ๆ ได้ในอนาคต

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 อ้อยและการเจริญเติบโตของอ้อย

อ้อย (*Saccharum officinarum* L.) เป็นพืชเศรษฐกิจสำคัญของประเทศไทย โดยมีการปลูกกระจายทั่วทุกภูมิภาค เนื่องจากเป็นพืชที่สามารถใช้ประโยชน์ได้หลายด้าน ทั้งในอุตสาหกรรมน้ำตาลและพลังงานชีวภาพ (เอทานอล) รวมทั้งยังสามารถนำส่วนเหลือจากการเกษตร เช่น ใบและชานอ้อยไปใช้ผลิตพลังงานชีวมวลอ้อยเป็นพืชล้มลุกอายุหลายปีที่มีระบบรากและลำต้นแข็งแรง สามารถปรับตัวได้ดีในสภาพแวดล้อมที่หลากหลาย (กรมส่งเสริมการเกษตร, 2566) การเจริญเติบโตของอ้อยแบ่งออกเป็น 3 ระยะหลัก ได้แก่

1. ระยะแตกกอ (Tillering Stage) เป็นระยะที่อ้อยเริ่มงอกจากตาตามท่อนพันธุ์ มีการแตกกอเพื่อเพิ่มจำนวนลำ
2. ระยะเจริญเติบโตทางลำต้น (Grand Growth Stage) เป็นช่วงที่อ้อยมีการเจริญเติบโตอย่างรวดเร็ว มีการเพิ่มความสูง เส้นผ่านศูนย์กลางลำ และน้ำหนักชีวมวล
3. ระยะสะสมน้ำตาล (Maturity Stage) เป็นช่วงที่การเจริญเติบโตทางกายภาพลดลง แต่มีการสะสมน้ำตาลในลำสูงสุด (de Oliveira et al., 2022)

จากแนวคิดของ (de Oliveira, Predicting Sugarcane Biometric Parameters by UAV Multispectral Images and Machine Learning, 2022) พบว่า การติดตามการเจริญเติบโตของอ้อยโดยใช้ภาพถ่ายทางอากาศจากอากาศยานไร้คนขับ (UAV) เพื่อติดตามการเจริญเติบโตของอ้อยสามารถสังเกตการเปลี่ยนแปลงของพืชในแต่ละช่วงได้ชัดเจน โดยเฉพาะในระยะสะสมน้ำตาล ซึ่งค่าดัชนีพืชพรรณมีความสัมพันธ์เชิงบวกกับผลผลิตจริงในภาค การใช้เทคโนโลยีดังกล่าวจึงเป็นแนวทางที่ช่วยลดการใช้แรงงานภาคสนามและเพิ่มประสิทธิภาพในการติดตามการเจริญเติบโตของอ้อยในระดับพื้นที่กว้าง การติดตามการเจริญเติบโตด้วย UAV ช่วยลดการใช้แรงงานและเพิ่มความถี่ในการสำรวจพื้นที่ขนาดใหญ่ (Sumesh et al., 2021)

2.2 ดัชนีพืชพรรณและการประยุกต์ใช้ในการประเมินผลผลิต

ดัชนีพืชพรรณ (Vegetation Indices) เป็นตัวชี้วัดที่ใช้ในการประเมินสุขภาพ ความหนาแน่น และชีวมวลของพืช โดยคำนวณจากค่าการสะท้อนแสงของพืชในช่วงคลื่นต่าง ๆ ซึ่งพืชที่มีสุขภาพดีจะดูดกลืนแสงในช่วงสีแดง (Red Band) เพื่อใช้ในกระบวนการสังเคราะห์แสง และสะท้อนแสงในช่วงอินฟราเรดใกล้ (NIR) ทำให้สามารถใช้ค่าความแตกต่างของการสะท้อนแสงเพื่อบ่งชี้ความเขียวของพืช

ได้ (Tucker, 1979) ซึ่งแตกต่างจากพื้นผิวอื่น เช่น ดิน หรือน้ำ ดัชนีที่นิยมใช้มากที่สุดคือ Normalized Difference Vegetation Index (NDVI) ซึ่งคำนวณจากสมการ

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

โดย NIR คือค่าการสะท้อนแสงในช่วงอินฟราเรดใกล้ (Near Infrared) และ Red คือค่าการสะท้อนแสงในช่วงคลื่นสีแดง (Red Band) ค่าของ NDVI มีช่วง -1 ถึง 1 โดยค่าสูงบ่งชี้ถึงความหนาแน่นและสุขภาพของพืช การใช้ NDVI ร่วมกับข้อมูลจาก UAV ช่วยให้สามารถติดตามการเจริญเติบโตของอ้อยในแต่ละช่วงเวลาและประเมินผลผลิตได้อย่างแม่นยำ นอกจากนี้ยังมีดัชนีพืชพรรณอื่น ๆ เช่น RVI, DVI, NDRE, ExG และ WDRVI ที่สามารถนำมาใช้ร่วมกับ Machine Learning เพื่อเพิ่มความแม่นยำในการคาดการณ์ผลผลิตอ้อย (Narmilan et al., 2022)

งาน Gonzalez et al. (2022) พบว่า การใช้ดัชนี NDVI, NDRE (Normalized Difference Red Edge) และ EVI (Enhanced Vegetation Index) จากกล้องมัลติสเปกตรัมของ UAV มีความสัมพันธ์เชิงบวกกับชีวมวลของอ้อย ($r^2 = 0.89$) สามารถบ่งชี้ความแตกต่างของความหนาแน่นชีวมวลอ้อยในแต่ละช่วงอายุได้อย่างมีนัยสำคัญ และเมื่อนำค่าดัชนีเหล่านี้ไปวิเคราะห์ร่วมกับข้อมูลภาคสนามผ่านเทคนิค Machine Learning จะช่วยเพิ่มความแม่นยำของแบบจำลองคาดการณ์ผลผลิตได้อย่างมาก

ในทำนองเดียวกันงาน Narmilan et al. (2022) พบว่า การใช้ข้อมูลดัชนีจากหลายช่วงเวลา (multi-temporal vegetation indices) สามารถติดตามความเปลี่ยนแปลงของพืชตลอดวงจรการเจริญเติบโต ซึ่งส่งผลให้แบบจำลอง Machine Learning มีความแม่นยำในการพยากรณ์ผลผลิตมากกว่าการใช้ข้อมูลเพียงช่วงเวลาเดียว

2.3 หลักการสำรวจด้วยอากาศยานไร้คนขับ (UAV)

2.3.1 หลักการทำงานของ UAV

อากาศยานไร้คนขับ (Unmanned Aerial Vehicle: UAV) คือ ระบบการบินอัตโนมัติที่สามารถติดตั้งกล้อง RGB, Multispectral, Thermal หรือ LiDAR เพื่อเก็บข้อมูลภาพทางอากาศที่มีความละเอียดสูง UAV เป็นเครื่องมือสำคัญสำหรับการสำรวจและเก็บข้อมูลทางการเกษตร UAV สามารถถ่ายภาพความละเอียดสูง (High-Resolution Imagery) และรวบรวมข้อมูล Multispectral, RGB, หรือ Thermal Imagery เพื่อสร้าง Digital Surface Model (DSM), Digital Elevation Model (DEM) และ Orthomosaic สำหรับการวิเคราะห์ภูมิศาสตร์เชิงพื้นที่ (Liu et al., 2025) การประยุกต์

UAV ในอ้อยสามารถทำได้หลายรูปแบบ เช่น การติดตามการเจริญเติบโตของพืช การตรวจสอบโรค และแมลง และการคำนวณผลผลิตเบื้องต้น นอกจากนี้ UAV ยังสามารถใช้ร่วมกับซอฟต์แวร์ที่สเปคเปิด เช่น WebODM และ QGIS เพื่อประมวลผลและวิเคราะห์ข้อมูลได้อย่างมีประสิทธิภาพ ระบบ UAV ประกอบด้วย 3 ส่วนหลัก ได้แก่

1. แพลตฟอร์มอากาศยาน (UAV Platform) ทำหน้าที่ในการบินและบันทึกภาพ
2. ระบบเซนเซอร์ถ่ายภาพ (Sensor Payload) เช่น กล้อง RGB หรือกล้องมัลติสเปกตรัม
3. ระบบกำหนดตำแหน่งและนำทาง (GNSS/IMU System) ใช้ในการระบุตำแหน่งพิกัดที่ถูกต้องของแต่ละภาพ

2.3.2 การประมวลผลภาพ

ภาพจาก UAV จะถูกนำมาประมวลผลด้วยซอฟต์แวร์ Photogrammetry เช่น Pix4D, Agisoft Metashape, DJI Terra หรือ WebODM เพื่อสร้าง

- แผนที่ออร์โธโมเสก (Orthomosaic)
- แบบจำลองระดับพื้นผิว (Digital Surface Model: DSM)
- แผนที่ดัชนีพืชพรรณ (Vegetation Index Map)

ตามแนวคิดของ Colomina & Molina (2014) การสำรวจด้วย UAV สามารถสร้างภาพ Orthomosaic และ Digital Surface Model (DSM) ได้โดยใช้กระบวนการประมวลผลภาพแบบ Photogrammetry ผ่านซอฟต์แวร์ เช่น Pix4D, Agisoft Metashape หรือ DJI Terra เพื่อสร้างภาพที่มีความละเอียดเชิงพื้นที่สูง สามารถใช้ในการคำนวณค่าดัชนีพืชพรรณ เช่น NDVI, GNDVI, Cled-edge และอื่น ๆ ข้อดีของการใช้ UAV คือสามารถเก็บข้อมูลได้หลายช่วงเวลาและสามารถวิเคราะห์การเปลี่ยนแปลงของพืชได้แบบต่อเนื่อง (multi-temporal analysis) ซึ่งเหมาะสมกับการประเมินการเจริญเติบโตและคาดการณ์ผลผลิตของพืชเช่นอ้อย

2.4 หลักการเกษตรแม่นยำ (Precision Agriculture)

2.4.1 ความหมายและแนวคิด

เกษตรแม่นยำ (Precision Agriculture) หมายถึง แนวทางการจัดการทางการเกษตรที่อาศัยข้อมูลเชิงพื้นที่และเทคโนโลยีดิจิทัล เช่น ระบบกำหนดตำแหน่งบนโลก (GPS), ระบบสารสนเทศภูมิศาสตร์ (GIS), การสำรวจระยะไกล (Remote Sensing) และอากาศยานไร้คนขับ (UAV) เพื่อเพิ่มประสิทธิภาพการผลิต ลดต้นทุน และใช้ทรัพยากรทางการเกษตรอย่างเหมาะสมและยั่งยืน

แนวคิดของเกษตรแม่นยำมุ่งเน้นการใช้เทคโนโลยีสารสนเทศและระบบตรวจวัดระยะไกลเพื่อบริหารจัดการทรัพยากรให้เกิดประสิทธิภาพสูงสุด โดยลดการใช้ปัจจัยการผลิตที่ไม่จำเป็นและลดผลกระทบต่อสิ่งแวดล้อม (USDA, 2025)

2.4.2 หลักการสำคัญของเกษตรแม่นยำ ประกอบด้วย 3 องค์ประกอบหลัก ได้แก่

1. การเก็บข้อมูลเฉพาะจุด (Site-Specific Data Collection)
2. การวิเคราะห์ข้อมูลเชิงพื้นที่ (Spatial Analysis)
3. การจัดการตามผลการวิเคราะห์ (Decision-Based Management)

งานของ Som-ard et al. (2024) พบว่า การใช้ข้อมูลจาก Sentinel-2 และ Landsat ร่วมกับ Machine Learning สามารถเพิ่มความแม่นยำของการประเมินผลผลิตอ้อยได้กว่า 20% และช่วยให้สามารถจัดการพื้นที่ปลูกในระดับแปลงได้อย่างเหมาะสม

2.5 หลักการและเทคนิคของ Machine Learning ที่ใช้ในการคาดการณ์ผลผลิตอ้อย

เทคนิคการเรียนรู้ของเครื่อง (Machine Learning : ML) เป็นกระบวนการสร้างแบบจำลองทางคณิตศาสตร์เพื่อให้ระบบสามารถเรียนรู้จากข้อมูลได้เอง โดยไม่ต้องกำหนดสมการล่วงหน้า (Goodfellow et al., 2016) จึงเหมาะสำหรับการวิเคราะห์ข้อมูลทางการเกษตรที่มีความซับซ้อนและไม่เป็นเชิงเส้นสูง ML ถูกนำมาใช้ในด้านเกษตรกรรมเพื่อจำแนกชนิดพืช พยากรณ์ผลผลิต และวิเคราะห์ข้อมูลภาพจากอากาศยานไร้คนขับ (UAV)

2.5.1 เทคนิค Random Forest (RF)

Random Forest (RF) เป็นอัลกอริทึมที่ใช้หลักการ Ensemble Learning โดยสร้างต้นไม้ตัดสินใจ (Decision Trees) จำนวนมาก และนำผลลัพธ์จากแต่ละต้นมารวมกันด้วยการเฉลี่ยค่าเพื่อเพิ่มความแม่นยำและลดความเอนเอียง) และเพิ่มความแม่นยำ (Breiman, 2001) RF เหมาะกับข้อมูลที่มีความซับซ้อนสูงและไม่เป็นเชิงเส้น

หลักการของ RF สามารถอธิบายได้ง่าย ๆ ว่า แทนที่จะใช้ต้นไม้ตัดสินใจเพียงต้นเดียว ซึ่งอาจให้ผลคลาดเคลื่อนสูง RF จะใช้ “หลายต้น” มาช่วยกันตัดสินใจ เหมือนการให้ผู้เชี่ยวชาญหลายคนช่วยกันให้ความเห็น แล้วเฉลี่ยผลเพื่อให้ได้คำตอบที่เสถียรและน่าเชื่อถือมากขึ้น

หลักการคำนวณของ RF

$$\hat{y} = \frac{1}{N} \sum_{i=1}^N T_i(x)$$

โดยที่

- \hat{y} = ค่าที่ทำนายได้ (Predicted Value)
- $T_i(x)$ = ค่าที่ได้จากต้นไม้ที่ i
- N = จำนวนต้นไม้ทั้งหมดในป่า (Forest)

แนวคิดนี้ช่วยลดความเอนเอียง (Bias) และลดความแปรปรวน (Variance) ของแบบจำลอง ทำให้ RF เหมาะสมกับข้อมูลที่มีความซับซ้อนและมีความไม่เป็นเชิงเส้นสูง (Breiman, 2001)

งานของ Salgado et al. (2023) แสดงให้เห็นว่า RF สามารถจัดการกับข้อมูลที่มีตัวแปรจำนวนมากได้ดี และให้ความแม่นยำสูงเมื่อใช้ร่วมกับดัชนีความเขียว (NDVI) จากภาพ UAV โดยสามารถคาดการณ์ชีวมวลของอ้อยได้อย่างมีประสิทธิภาพ โดยมีค่า $R^2 = 0.95$ แสดงถึงความสัมพันธ์ที่สูงมากกว่าค่าที่คาดการณ์ได้และค่าจริง

2.5.2 เทคนิค Extreme Gradient Boosting (XGBoost)

Extreme Gradient Boosting (XGBoost) ซึ่งพัฒนาโดย Chen & Guestrin (2016) เป็นการปรับปรุงจากเทคนิค Gradient Boosting แบบดั้งเดิม โดยใช้หลักการเรียนรู้แบบลำดับขั้น (Sequential Learning) คือ แต่ละแบบจำลองจะเรียนรู้จากข้อผิดพลาดของแบบจำลองก่อนหน้า และค่อย ๆ ปรับค่าพารามิเตอร์เพื่อลดค่าความสูญเสีย (Loss Function) ทีละขั้นตอน ซึ่ง XGBoost มีจุดเด่นคือ ความเร็วในการประมวลผลสูง และ ความแม่นยำดีเยี่ยม เนื่องจากใช้เทคนิคการจัดการหน่วยความจำอย่างมีประสิทธิภาพ และการปรับน้ำหนักของตัวแปรที่เหมาะสม ทำให้เหมาะกับการคาดการณ์ผลผลิตที่ต้องใช้ข้อมูลจำนวนมาก (Chen T. a., 2016)

หลักการคำนวณของ XGBoost

$$\hat{y}_i^{(t)} = \hat{y}_i^{(t-1)} + \eta f_t(x_i)$$

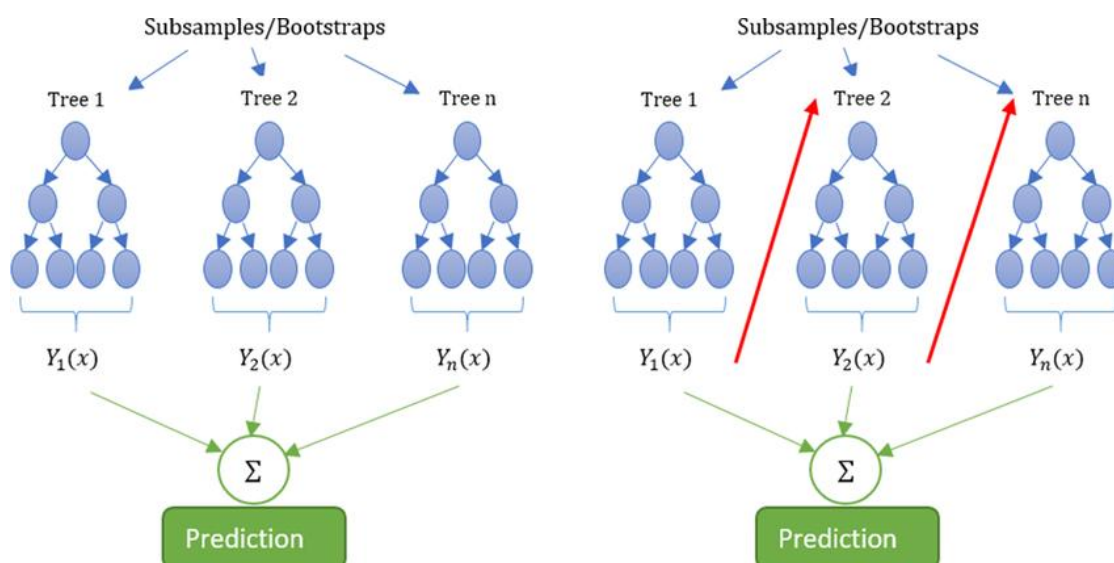
โดยที่

- $\hat{y}_i^{(t)}$ = ค่าที่ทำนายได้ในรอบที่ t
- η = อัตราการเรียนรู้ (Learning rate)
- $f_t(x_i)$ = ฟังก์ชันของต้นไม้ใหม่ที่สร้างขึ้นในรอบที่ t
- การเรียนรู้จะมุ่งลดค่าฟังก์ชันสูญเสีย (Loss Function) เช่น RMSE หรือ MAE

ข้อดีของ XGBoost คือความสามารถในการควบคุมการเรียนรู้ (Regularization) เพื่อลดการเกิด Overfitting และประมวลผลได้รวดเร็วกว่ารุ่นก่อน ๆ ด้วยเทคนิค Parallel Processing

จากการเปรียบเทียบของ Narmilan et al. (2023) พบว่า XGBoost ให้ค่าความแม่นยำสูงกว่า RF เล็กน้อย ($R^2 = 0.88$ เทียบกับ 0.84) แต่ RF มีความเสถียรมากกว่าในกรณีข้อมูลมีสัญญาณรบกวนสูง ซึ่งแสดงให้เห็นว่าทั้งสองเทคนิคสามารถนำไปประยุกต์ใช้กับข้อมูลภาพ UAV เพื่อพยากรณ์ผลผลิตอ้อยได้อย่างมีประสิทธิภาพ

ความแตกต่างระหว่าง Random Forest กับ XGBoost



ภาพที่ 2.1 ตัวอย่างการทำงานของ Random Forest (ซ้าย) และ XGBoost (ขวา)
(ที่มา: EL Mazgualdi et al., 2021)

คุณสมบัติ	Random Forest	XGBoost
การสร้างแบบจำลอง	การเรียนรู้แบบ Ensemble โดยสร้างต้นไม้ตัดสินใจ (Decision Trees) หลายต้นอย่างอิสระ	การเรียนรู้แบบ Ensemble แบบลำดับขั้น (Sequential) โดยแต่ละต้นจะช่วยแก้ไขข้อผิดพลาดของต้นก่อนหน้า
แนวทางการปรับให้เหมาะสม (Optimization Approach)	ทำนายผลโดยการเฉลี่ยค่าผลลัพธ์จากแต่ละต้นไม้	ใช้วิธี Gradient Boosting เพื่อลดค่าความสูญเสีย และเพิ่มความแม่นยำอย่างต่อเนื่อง
การจัดการข้อมูลที่ไม่สมดุล (Unbalanced Datasets)	อาจมีปัญหาบ้างในบางกรณี	จัดการได้ดีมาก มีวิธีการรองรับที่มีประสิทธิภาพ
ความง่ายในการปรับจูน (Ease of Tuning)	ปรับจูนง่าย เข้าใจไม่ยาก	ต้องใช้ความชำนาญมากกว่า แต่ให้ความแม่นยำที่สูงกว่า
การประยุกต์ในระบบคอมพิวเตอร์แบบกระจาย (Distributed Computing)	ทำงานได้ดีในระบบหลายเครื่อง	ต้องการการประสานงานมากกว่า แต่จัดการข้อมูลขนาดใหญ่ได้อย่างมีประสิทธิภาพ
การจัดการข้อมูลขนาดใหญ่ (Large Datasets)	รองรับได้ แต่เมื่อข้อมูลใหญ่มาก อาจทำงานช้าลง	ถูกออกแบบมาเพื่อความรวดเร็ว เหมาะกับข้อมูลขนาดใหญ่
ความแม่นยำในการทำนาย (Predictive Accuracy)	แม่นยำดี แต่ไม่สูงสุดในบางสถานการณ์	ให้ความแม่นยำสูงกว่า โดยเฉพาะในปัญหาที่ซับซ้อน

2.6 เทคนิคด้านภูมิสารสนเทศ (Geospatial Techniques)

เทคนิคภูมิสารสนเทศเป็นเครื่องมือสำคัญที่ช่วยวิเคราะห์ข้อมูลเชิงพื้นที่ในงานเกษตร เช่น

1. การสร้างโมเดลพื้นผิวพืช (Crop Surface Model: CSM) สำหรับวิเคราะห์ความสูงและปริมาตรของอ้อย (Sumesh et al., 2021)

2. การวิเคราะห์เชิงวัตถุ (Object-Based Image Analysis: OBIA) เพื่อจำแนกโครงสร้างของพืชและตรวจสอบความหนาแน่น (Sumesh et al., 2021)

3. การประมวลผลภาพ Multispectral และการวิเคราะห์ NDVI ในเชิงพื้นที่ (Zonal Statistics) เพื่อประเมินสภาพความสมบูรณ์ของพืชหรือสำหรับสกัดค่าดัชนี NDVI ในแต่ละแปลง (Wattananun et al., 2018)

4. Multilayer GIS Analysis เพื่อวิเคราะห์ความสัมพันธ์ระหว่างภูมิประเทศ ดิน และผลผลิต (วีรภัทร นวลอินทร์, 2567)

การใช้เทคนิคเหล่านี้ช่วยให้การประเมินผลผลิตและสุขภาพของพืชอ้อยมีความแม่นยำและสามารถนำไปประยุกต์ใช้ในระบบเกษตรแม่นยำได้อย่างมีประสิทธิภาพ

แนวคิดนี้อิงกับทฤษฎีความสัมพันธ์เชิงพื้นที่ (Spatial Relationship Theory) ของ Tobler (1970) ที่ระบุว่า “ทุกสิ่งเชื่อมโยงกัน แต่สิ่งที่อยู่ใกล้กันมีความสัมพันธ์กันมากกว่า” การใช้เทคนิคเหล่านี้จึงเป็นหัวใจสำคัญของการพัฒนาแบบจำลองเชิงพื้นที่สำหรับคาดการณ์ผลผลิตอ้อย

2.7 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับการคาดการณ์ผลผลิตอ้อยโดยใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ร่วมกับข้อมูลภาพจากอากาศยานไร้คนขับ (UAV) และดัชนีพืชพรรณ (Vegetation Indices) ได้รับความสนใจอย่างมากในช่วงทศวรรษที่ผ่านมา เนื่องจากเป็นแนวทางที่ช่วยเพิ่มความแม่นยำในการประเมินผลผลิตและลดการใช้แรงงานภาคสนาม

วีรภัทร นวลอินทร์ (2565) เรื่อง **การประยุกต์ใช้โดรนมัลติสเปกตรัมและการใช้ Machine Learning ร่วมกับระบบสารสนเทศภูมิศาสตร์ในการคาดการณ์ผลผลิตอ้อย** งานวิจัยนี้ใช้ อากาศยานไร้คนขับ (UAV) ที่ติดตั้ง กล้องมัลติสเปกตรัม (Multispectral Camera) เพื่อเก็บภาพในหลายช่วงคลื่น เช่น แดง (Red), เขียว (Green) และใกล้อินฟราเรด (NIR) จากนั้นนำภาพที่ได้มาประมวลผลด้วยโปรแกรมโฟโตแกรมเมตรี เช่น Pix4D หรือ Agisoft Metashape เพื่อสร้าง แผนที่ออร์โธโมเสก (Orthomosaic) และ แบบจำลองระดับพื้นผิว (DSM) หลังจากนั้นได้คำนวณ ดัชนีพืชพรรณ NDVI, GNDVI, Cired edge ค่าดัชนีเหล่านี้ถูกนำมาวิเคราะห์ร่วมกับ ข้อมูลภูมิสารสนเทศ (GIS) เช่น ความสูงจากระดับน้ำทะเล ความลาดชัน และความชื้นในดิน เพื่อดูความสัมพันธ์เชิงพื้นที่ โดยใช้เทคนิคสถิติถดถอยพหุคูณ (Multiple Linear Regression: MLR) และ การวิเคราะห์สหสัมพันธ์ของเพียร์สัน

(Pearson Correlation) เพื่อระบุว่าปัจจัยใดส่งผลกระทบต่อการเจริญเติบโตของอ้อยมากที่สุด ผลการวิจัยพบว่า ดัชนี NDVI และ Cired edge มีความสัมพันธ์สูงกับความสูงและชีวมวลของอ้อย โดยมีค่า r^2 มากกว่า 0.80 โดยเฉพาะในพื้นที่ราบที่มีความชื้นเหมาะสม พื้นที่ที่มีความลาดชันน้อยกว่า 5% มีค่า NDVI เฉลี่ยสูงสุดประมาณ 0.78 ขณะที่พื้นที่ลาดชันมากกว่า 10% มีค่า NDVI เฉลี่ยต่ำสุดราว 0.56 แสดงให้เห็นว่าภูมิประเทศและความชื้นมีผลต่อการเจริญเติบโตอย่างมีนัยสำคัญ นอกจากนี้ การนำข้อมูล NDVI มารวมกับข้อมูลภูมิสารสนเทศในระบบ GIS ช่วยเพิ่มความแม่นยำของแบบจำลองในการอธิบายการเปลี่ยนแปลงของการเจริญเติบโตของอ้อยได้ถึง $R^2 = 0.89$ ซึ่งสะท้อนให้เห็นถึงประโยชน์ของการใช้เทคนิค Geospatial Analysis และ Machine Learning ขั้นพื้นฐาน ในการทำความเข้าใจปัจจัยทางสิ่งแวดล้อมที่มีผลต่อผลผลิต โดยแนวคิดหลักของงานนี้อิงกับ ทฤษฎีความสัมพันธ์เชิงพื้นที่ (Spatial Relationship Theory) และ แนวคิดภูมิสารสนเทศเชิงวิเคราะห์ (Geospatial Analytical Concept) ที่มุ่งเน้นการใช้ข้อมูลเชิงพื้นที่หลายชั้น (Multilayer GIS Data) เพื่อทำความเข้าใจการเปลี่ยนแปลงของพืชในระดับพื้นที่ ซึ่งสามารถนำไปประยุกต์ใช้ในการคาดการณ์ผลผลิตและการวางแผนเกษตรแบบแม่นยำ (Precision Agriculture) ได้อย่างมีประสิทธิภาพ

Chen & Guestrin (2016) ได้นำเสนอเทคนิค **XGBoost : A Scalable Tree Boosting System** ซึ่งเป็นอัลกอริทึม Machine Learning แบบ Gradient Boosting ที่ถูกพัฒนาให้มีความเร็วและประสิทธิภาพสูงกว่าวิธีการเดิม โดยใช้แนวคิดการเรียนรู้แบบลำดับขั้น (Sequential Learning) และการลดค่าความสูญเสีย (Loss Function) ทีละขั้นตอน ช่วยให้แบบจำลองสามารถจับความสัมพันธ์เชิงซับซ้อนของข้อมูลได้อย่างมีประสิทธิภาพ และเป็นที่ยอมรับอย่างแพร่หลายในงานด้านการเกษตรที่ต้องการคาดการณ์ผลผลิต เช่น อ้อย หรือข้าว เนื่องจากให้ค่าความแม่นยำสูงและสามารถจัดการกับข้อมูลที่มี Noise ได้ดี (Chen & Guestrin, 2016).

de Oliveira, R. P., et al. (2022) เรื่อง **Predicting Sugarcane Biometric Parameters by UAV Multispectral Images and Machine Learning** งานโดยมุ่งเน้นการใช้ภาพถ่ายมัลติสเปกตรัมจากอากาศยานไร้คนขับ (UAV) หลายช่วงเวลา (Multi-temporal Imagery) เพื่อคาดการณ์ตัวชี้วัดชีวสถิติของอ้อย เช่น ความสูง จำนวนลำ และเส้นผ่านศูนย์กลางของลำอ้อย งานวิจัยนี้ใช้แบบจำลอง Machine Learning หลายชนิด ได้แก่ Random Forest (RF), Support Vector Regression (SVR) และ Extreme Gradient Boosting (XGBoost) เพื่อวิเคราะห์ความสัมพันธ์ระหว่างค่าการสะท้อนแสงในช่วงคลื่น Blue, Green และ NIR กับตัวชี้วัดชีวสถิติของพืช แนวคิดหลักอิงจาก Remote Sensing Theory และ Ensemble Learning Principle ที่ใช้การรวมผลของหลายโมเดลเพื่อลดความเอนเอียงและเพิ่มความแม่นยำ ผลการศึกษาพบว่าแบบจำลอง XGBoost ให้ค่าความแม่นยำสูงสุด ($R^2 = 0.91$, RMSE = 5.2 cm) รองลงมาคือ RF ($R^2 = 0.88$) และสามารถแยกแยะความแตกต่างของการเจริญเติบโตได้ดี โดยแบนด์ Blue และ NIR มีความสำคัญเชิงพยากรณ์สูงสุด

แสดงถึงศักยภาพของการผสมผสานข้อมูลภาพถ่ายอากาศและ Machine Learning ในการติดตามการเติบโตของอ้อยอย่างต่อเนื่อง และในการประเมินสถานะการเจริญเติบโตของอ้อยได้อย่างแม่นยำในระดับแปลง

Kulasekara et al. (2022) ได้ศึกษา **Multi-temporal analysis of sugarcane growth using UAV multispectral images and machine learning** โดยใช้ข้อมูลภาพถ่ายจาก UAV หลายช่วงเวลาเพื่อประเมินการเจริญเติบโตของอ้อยในแต่ละระยะ ผลการศึกษาชี้ว่าค่าดัชนี NDVI และ CI red-edge มีความสัมพันธ์สูงกับชีวมวลและน้ำหนักสดของอ้อย ($r = 0.93$ และ $r = 0.90$ ตามลำดับ) และการใช้แบบจำลอง XGBoost ให้ค่าความแม่นยำสูงสุด ($R^2 = 0.94$) เหนือกว่า RF และ SVR แสดงให้เห็นถึงศักยภาพของข้อมูลหลายช่วงเวลาในการเพิ่มประสิทธิภาพของแบบจำลองพยากรณ์ผลผลิต ซึ่งสอดคล้องกับแนวคิด Precision Agriculture ที่มุ่งเน้นการติดตามและจัดการพืชในเชิงพื้นที่แบบต่อเนื่อง (Kulasekara et al., 2022).

Liu, H., et al. (2020) เรื่อง **A Seasonal Fresh Tea Yield Estimation Method with Machine Learning Algorithms Integrating UAV RGB and Sentinel-2 Imagery** เป็นการศึกษาผลผลิตใบชา แต่มีแนวคิดที่สามารถประยุกต์ใช้กับอ้อยได้โดยตรง งานนี้ใช้การผสมผสานข้อมูลจากภาพ UAV-RGB และ Sentinel-2 Multispectral ร่วมกับอัลกอริทึม Random Forest (RF) และ Support Vector Regression (SVR) เพื่อคาดการณ์ผลผลิตในระดับแปลง ผลการวิจัยพบว่าการผสมผสานข้อมูลทั้งสองแหล่งช่วยเพิ่มความแม่นยำของการคาดการณ์จาก $R^2 = 0.76$ (เมื่อใช้ข้อมูล UAV เพียงอย่างเดียว) เป็น $R^2 = 0.91$ เมื่อรวมกับข้อมูล Sentinel-2 แสดงถึงประโยชน์ของแนวคิด Multi-Source Data Fusion ในการเพิ่มคุณภาพของแบบจำลอง ในเชิงหลักการ งานนี้สนับสนุนทฤษฎี Precision Agriculture ที่มุ่งใช้ข้อมูลหลายแหล่งในการบริหารจัดการพื้นที่เพาะปลูกอย่างแม่นยำ ทั้งยังตอกย้ำบทบาทของ Machine Learning ในการประมวลผลข้อมูลภาพเชิงพื้นที่ขนาดใหญ่

Narmilan et al. (2022) ได้ศึกษาเรื่อง **Predicting Canopy Chlorophyll Content in Sugarcane Crops Using Machine Learning Algorithms and Spectral Vegetation Indices Derived from UAV Multispectral Imagery** งานวิจัยนี้มุ่งเน้นการประเมินปริมาณคลอโรฟิลล์ในพืชอ้อยโดยใช้ภาพจากกล้องมัลติสเปกตรัมบนอากาศยานไร้คนขับ (UAV) ร่วมกับเทคนิคการเรียนรู้ของเครื่อง ซึ่งได้แก่ Random Forest (RF), Support Vector Regression (SVR) และ Extreme Gradient Boosting (XGBoost) เพื่อสร้างแบบจำลองการพยากรณ์โดยใช้ดัชนีพืชพรรณหลายชนิด เช่น NDVI, NDRE, RVI, และ DVI ในเชิงทฤษฎี งานนี้สะท้อนถึงหลักการของ Remote Sensing ที่อธิบายถึงความสัมพันธ์ระหว่างการสะท้อนแสงในช่วงแบนด์ Red และ Near-Infrared (NIR) กับสุขภาพของพืช ซึ่งเป็นพื้นฐานของการคำนวณ NDVI ที่ใช้ประเมินชีวมวลและความ

หนาแน่นของพืชพรรณ (Tucker, 1979) ผลการศึกษาพบว่าแบบจำลอง XGBoost ให้ค่าความแม่นยำสูงที่สุด ($R^2 = 0.98$, $RMSE = 0.78$) รองลงมาคือ Random Forest ($R^2 = 0.95$) แสดงให้เห็นถึงศักยภาพของเทคนิค Ensemble Learning ที่สามารถจัดการกับข้อมูลที่มีความซับซ้อนได้ดีกว่าแบบจำลองเชิงเส้น และในเชิงเทคนิค การใช้ UAV Multispectral ทำให้ได้ข้อมูลความละเอียดสูงในระดับแปลงปลูก สามารถเชื่อมโยงค่าดัชนีกับปริมาณคลอโรฟิลล์และสถานะสุขภาพของพืชได้อย่างมีนัยสำคัญ และสนับสนุนแนวคิดของ Precision Agriculture ที่เน้นการจัดการเชิงพื้นที่แบบเฉพาะจุด

Salgadoe et al. (2020) เรื่อง **Use of Spectral Vegetation Indices for Monitoring Sugarcane Biomass and Yield under UAV Remote Sensing** งานนี้มุ่งศึกษาความสัมพันธ์ระหว่างดัชนีพืชพรรณหลายชนิด (NDVI, SAVI, GNDVI, EVI) กับชีวมวลของอ้อย เพื่อพัฒนาแบบจำลองเชิงประจักษ์ในการประเมินผลผลิต ทฤษฎีที่ใช้เป็นพื้นฐานคือ Spectral Reflectance Theory ซึ่งระบุว่า การสะท้อนแสงในช่วง NIR จะเพิ่มขึ้นเมื่อพืชมีความเขียวและมีคลอโรฟิลล์สูง ขณะที่การสะท้อนแสงในช่วง Red จะลดลงเมื่อพืชมีสุขภาพดี ส่งผลให้ค่า NDVI มีค่าสูงตามไปด้วย ผลการศึกษาแสดงให้เห็นว่าดัชนี NDVI และ GNDVI มีความสัมพันธ์สูงกับน้ำหนักชีวมวลของอ้อย ($r = 0.92$ และ 0.88 ตามลำดับ) และสามารถใช้เป็นตัวแปรสำคัญในการสร้างแบบจำลอง Machine Learning เพื่อพยากรณ์ผลผลิตในอนาคตได้ เทคนิคที่ใช้คือการวิเคราะห์เชิงพื้นที่ร่วมกับข้อมูล UAV ซึ่งสะท้อนถึงการบูรณาการระหว่าง Geospatial Analysis และ Data-Driven Modeling ในการประเมินผลผลิตเชิงพื้นที่

Som-ard et al. (2024) เรื่อง **Regional sugarcane yield prediction using machine learning and multi-sensor imagery in Thailand** ได้ประยุกต์เทคนิค Machine Learning ร่วมกับข้อมูลภาพ UAV และ Sentinel-2 ในการคาดการณ์ผลผลิตอ้อยระดับภูมิภาคในประเทศไทย โดยใช้ตัวแปรจาก NDVI และ SAVI เป็นอินพุตเข้าสู่แบบจำลอง RF และ XGBoost ผลการศึกษาแสดงว่า XGBoost ให้ค่าความแม่นยำสูงที่สุด ($R^2 = 0.89$, $RMSE = 3.8$ t/ha) และสามารถระบุปัจจัยเชิงพื้นที่ที่ส่งผลต่อผลผลิตได้อย่างชัดเจน เช่น ความชื้นดิน ความสูงภูมิประเทศ และ ชนิดดิน ซึ่งสนับสนุนแนวคิด Spatial Relationship Theory ที่อธิบายว่าการเปลี่ยนแปลงของผลผลิตมีความสัมพันธ์เชิงพื้นที่กับตัวแปรสิ่งแวดล้อม (Som-ard et al., 2024).

Sumesh, K. C., et al. (2021) เรื่อง **Integration of RGB-based Vegetation Index, Crop Surface Model and Object-Based Image Analysis Approach for Sugarcane Yield Estimation Using UAV** ได้ทำการศึกษาการประมาณผลผลิตอ้อยโดยใช้ภาพถ่ายทางอากาศจาก UAV ร่วมกับการวิเคราะห์แบบ Object-Based Image Analysis (OBIA) และการสร้าง Crop Surface Model (CSM) เพื่อวิเคราะห์โครงสร้างและความสูงของทรงพุ่มอ้อย ผลการวิเคราะห์พบว่า ความสูงของพืชจาก CSM มีความสัมพันธ์สูงกับน้ำหนักชีวมวลจริงในภาคสนาม ($r^2 = 0.87$) และการ

รวมค่าดัชนี NDVI เข้ากับข้อมูล CSM ช่วยเพิ่มค่าความแม่นยำของการพยากรณ์ผลผลิตได้มากกว่า 12% เมื่อเทียบกับการใช้ดัชนีเพียงอย่างเดียว งานนี้จึงสะท้อนถึงความสำคัญของเทคนิค ภูมิสารสนเทศ (Geospatial Techniques) ในการสร้างตัวแปรเชิงโครงสร้างของพืชเพื่อใช้ร่วมกับแบบจำลอง Machine Learning ในการประเมินผลผลิตเชิงพื้นที่อย่างละเอียด (Sumesh et al., 2021).

Wattananun, W., et al. (2018) ได้ทำการศึกษา **Monitoring Sugarcane Health and Yield Estimation Using NDVI Derived from UAV Imagery** ในจังหวัดกาญจนบุรี พบว่าค่า NDVI ที่สกัดจากภาพถ่ายทางอากาศสามารถจำแนกระดับสุขภาพของอ้อยได้อย่างแม่นยำ โดยมีความสัมพันธ์เชิงบวกกับค่าความหนาแน่นชีวมวลและน้ำตาลสะสม ($r = 0.89$) ซึ่งยืนยันว่า NDVI สามารถใช้เป็นตัวชี้วัดการเจริญเติบโตและศักยภาพผลผลิตได้อย่างดีในระดับแปลง และเมื่อรวมกับข้อมูลเชิงพื้นที่จาก GIS สามารถสร้างแผนที่ Zonal Statistics เพื่อใช้วางแผนเกษตรแม่นยำได้อย่างมีประสิทธิภาพ (Wattananun et al., 2018).



ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

บทที่ 3 วิธีดำเนินงานวิจัย

3.1 เครื่องมือที่ใช้ในการวิจัย

3.1.1 อุปกรณ์ที่ใช้ในงานวิจัย

อุปกรณ์	ชื่อ	รายละเอียด
	DJI Phantom4 multispectral	ใช้สำหรับการบินเก็บภาพแปลงอ้อยในช่วงอายุ แบบดัดที่ใช้ ได้แก่ RGB, Red, และ NIR
	เสา D-RTK 2 GNSS Mobile Station	ใช้สำหรับระบุค่าพิกัดและความสูง
	เครื่องวัดเส้นผ่าศูนย์กลาง	ใช้สำหรับวัดเส้นผ่าศูนย์กลางลำต้นของอ้อย
	เทปวัดระยะ	ใช้สำหรับวัดระยะด้านละ 10 เมตร เพื่อให้ได้พื้นที่ รวม 100 ตารางเมตร (10 × 10 m) เพื่อทำการ แบ่งขอบเขตแปลงได้ตรงและเป็นรูปสี่เหลี่ยม
	ตลับเมตร	ใช้สำหรับวัดความสูงอ้อย
	คอมพิวเตอร์	ใช้สำหรับประมวลผลภาพถ่าย วิเคราะห์ข้อมูล และใช้ในการทำแบบจำลองการคาดการณ์

3.1.2 ซอฟต์แวร์ที่ใช้ในงานวิจัย

- ในการวิจัยจะใช้ คือ 1. แอปพลิเคชัน DJI GS PRO
 2. โปรแกรม QGIS
 3. โปรแกรม WebODM
 4. โปรแกรม DJI Terra
 5. โปรแกรม Microsoft Excel

3.2 วิธีดำเนินการวิจัย


3.2.1 การเก็บข้อมูลภาคสนาม

ในงานวิจัยจะทำการบินเก็บข้อมูลภาคสนามโดยการบินสำรวจจากภาพถ่ายทางอากาศด้วยอากาศยานไร้คนขับ โดยใช้กล้องมัลติสเปกตรัมหรือ RGB ในแต่ละช่วงอายุของอ้อย 1. ก่อนปลูก คือ เดือน มีนาคม 2. ช่วงอ้อย กำลังโต คือช่วงเดือน มิถุนายน 3. ช่วงอ้อยกำลังโตเต็มที่และกำลังจะหยุดโต คือ ช่วงเดือน กันยายน และ 4. ช่วงก่อนเก็บเกี่ยว คือ เดือนตุลาคม โดยศึกษาอ้อยพันธุ์ขอนแก่น 3 ในพื้นที่แปลงศึกษาสาธิตปฏิบัติการบึงราชชนก (มหาวิทยาลัยนเรศวร) ตำบล วังพิกุล อำเภอ วังทอง จังหวัด พิษณุโลก ตีกรอบเป็นรูปสี่เหลี่ยม เป็นพื้นที่ย่อย ขนาด 10*10 ม. จำนวน 30 plot ให้ทั่วทั้งแปลงพื้นที่ศึกษา ซึ่งภายในแต่ละพล็อตจะเก็บข้อมูล จำนวนต้น เส้นผ่านศูนย์กลางลำ ความสูงของลำ อ้อย น้ำหนักเฉลี่ยอ้อย ซึ่งในการบินแต่ละครั้งจะใช้วิธีการ ติดตั้ง D-RTK 2 GNSS Mobile Station และทำการประกอบอากาศยานไร้คนขับ เช่น ใบพัด แบตเตอรี่ เมมโมรี่การ์ด (Memory card) จากนั้นทำการเปิดอากาศยานไร้คนขับและ RTK จากนั้นเริ่มทำการวางแผนแนวจับผ่านโปรแกรม DJI GS PRO ทำการเชื่อมต่อระหว่าง RTK และอากาศยานไร้คนขับ เลือก Band และเริ่มทำการบินถ่ายเก็บข้อมูล



ภาพ 3.1 การเก็บข้อมูลภาคสนาม

ทำการเก็บรวบรวมข้อมูลแต่ละพล็อต 30 ตัวอย่างที่เก็บมา ลงในตาราง Microsoft Excel เพื่อจะใช้เป็นข้อมูลในการวิเคราะห์ข้อมูลขั้นต่อไป



ภาพที่ 3.2 การเก็บข้อมูลภาคสนามทั้งหมด 30 ตัวอย่าง ขนาด (100 ตร.ม.)

3.4 การวิเคราะห์ข้อมูล

3.4.1 การคำนวณผลผลิตอ้อย

โดยเริ่มต้นใช้โปรแกรม WebODM ส่งออกค่า DEM ก่อนปลูก คือ เดือนมีนาคม และ DSM (Digital Surface Model) เดือนมิถุนายน กันยายน และเดือนตุลาคมเป็นไฟล์ .Tiff Raw ส่งเข้า QGIS ทำการปรับแก้ค่าพิกัดเพื่อให้ตรงกัน โดยใช้เครื่องมือ Georeferencer แล้วสร้างแผนที่กริดให้ครอบคลุมและตัดให้อยู่ในขอบพื้นที่ศึกษา จากนั้นใช้เครื่องมือ Raster Calculator เพื่อหาค่าความสูงของอ้อย โดยใช้สมการ

$$H = \text{DSM}_{\text{แต่ละเดือน}} - \text{DEM}$$

เมื่อได้ค่าออกมา ตัดขอบเขตให้เท่ากับพื้นที่ศึกษา จากนั้นใช้เครื่องมือ Zonal Statistic มาใช้เพื่อหาค่าเฉลี่ยของ DSM (Digital Surface Model) ในบริเวณพื้นที่ตัวอย่าง 30 โดยทำทั้ง ภาพเดือน มิถุนายน กันยายน และเดือนตุลาคม ค่าที่ได้จะเป็นค่าความสูงของอ้อย จากนั้น แปลงค่าความสูงเป็นหน่วย เซนติเมตร โดยนำค่า mean * 100 จะได้ความสูงของลำอ้อยเป็นหน่วยเซนติเมตร

3.4.2 การวิเคราะห์ค่าดัชนีพืชพรรณ NDVI

ดาวนโหลตภาพถ่าย Ortho จาก WebODM แบบ Visible Light (RGB) และ ดาวนโหลตภาพถ่ายออร์โธสีแบบ Multispectral จากนั้นได้ทำการ ดาวนโหลตภาพถ่ายออร์โธสีแบบ Visible Light (RGB) จาก WebODM และ ภาพถ่ายออร์โธแบบ Multispectral ที่แยกเป็นแถบสเปกตรัมต่างๆ ได้แก่ Red และ Near-Infrared (NIR) เพื่อใช้ในการคำนวณค่าดัชนีพืชพรรณ (NDVI: Normalized Difference Vegetation Index) จากโปรแกรม DJI Terra ดาวนโหลตทั้งภาพหมด นำภาพเข้า QGIS แล้วปรับแก้ภาพให้มีพิกัดที่เท่ากันโดยใช้เครื่องมือ Georeferencer ซึ่งแต่ละเดือนจะได้ภาพถ่าย 1. DSM (Digital Surface Model) 2. ภาพถ่ายออร์โธสี Visible Light (RGB) 3. ภาพดัชนีพืชพรรณ (NDVI) จากโปรแกรม DJI Terra

ใช้เครื่องมือ Raster Calculator ในการคำนวณดัชนีพืชพรรณ (Vegetation Index) เป็นค่าบ่งบอกถึงสัดส่วนของพืชที่ปกคลุมผิวดิน อาศัยหลักการที่พืชสีเขียวจะสะท้อนแสงอินฟราเรดใกล้ (NIR) ซึ่งในงานวิจัยนี้จะใช้ดัชนีพืชพรรณ NDVI ซึ่งเป็นตัวบ่งบอกถึงความสมบูรณ์ของพืชพรรณ เพื่อใช้ประเมินปริมาณและบ่งบอกถึงความหนาแน่นของพืช มีค่าตั้งแต่ -1 ถึง 1 ซึ่งคำนวณจากความแตกต่างระหว่างการสะท้อนแสงในช่วงคลื่นใกล้อินฟราเรด (NIR) และช่วงคลื่นสีแดง (Red) โดยใช้สมการ

$$NDVI = \frac{NIR - Red}{NIR + Red}$$

ค่าของ NDVI จะอยู่ระหว่าง -1 ถึง +1 โดยค่าที่ใกล้ -1 หมายถึงพื้นที่ที่ไม่มีพืชพรรณ เช่น พื้นดินเปล่า น้ำ หรือสิ่งปลูกสร้าง ส่วนค่าที่ใกล้ +1 บ่งชี้ถึงพื้นที่ที่มีพืชพรรณเขียวขุ่มและมีการสังเคราะห์แสงสูง เช่น แปลงพืชที่มีสุขภาพดี ในทางปฏิบัติ พื้นที่ที่มี NDVI ต่ำมักสัมพันธ์กับความแห้งแล้งหรือการเจริญเติบโตต่ำ ขณะที่พื้นที่ที่มี NDVI สูงสะท้อนถึงความอุดมสมบูรณ์ของพืชพรรณและชีวมวลที่มากกว่า กล่าวคือ ค่า 0 หมายถึงไม่มีพืชพรรณใบเขียวอยู่ในพื้นที่ศึกษา ในขณะที่ 0.85 หมายถึง มีพืชพรรณใบเขียวหนาแน่นมากในพื้นที่ศึกษา

3.4.3 การวิเคราะห์ด้วยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning)

หลังจากวิเคราะห์ค่าดัชนี NDVI แล้ว ใช้เครื่องมือ Zonal Statistic โดยเลือกใช้ค่า Mean ที่เป็นค่าเฉลี่ย นำมาเฉลี่ยบริเวณตัวอย่างที่ศึกษา 30 ตัวอย่าง แต่ละช่อง จะได้ Attribute table แล้วส่งออกเป็นรูปแบบไฟล์ CSV เพื่อนำไปวิเคราะห์ในโมเดลของ Machine Learning ต่อไป

3.4.3.1 Random Forest Regression (RFR)

ในงานวิจัยใช้แบบจำลอง Random Forest Regression (RFR) ในการคาดการณ์ผลผลิตอ้อย โดยใช้ตัวแปร X ใช้ น้ำหนักเฉลี่ยต่อลำ (Kg) และตัวแปร Y ใช้ NDVI แต่ละเดือน

```
import pandas as pd
import numpy as np
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.metrics import r2_score, mean_squared_error, mean_absolute_error
import matplotlib.pyplot as plt
```

ภาพที่ 3.3 ไลบรารีที่ใช้ในแบบจำลอง Random Forest Regression (RFR)

- pandas คือ ไลบรารีที่ทำหน้าที่ในการจัดการข้อมูลเชิงตาราง (DataFrame) จะทำการอ่าน/เขียนไฟล์ (CSV, Excel)
- numpy คือ ไลบรารีที่ทำหน้าที่เป็นตัวคำนวณตัวเลข โดยใช้อาเรย์ (array) ในการคำนวณ เช่น คำนวณเวกเตอร์/เมทริกซ์, ฟังก์ชันทางคณิตศาสตร์, การสุ่มตัวอย่าง ซึ่งในหลายไลบรารี ซึ่งรวมถึง sklearn จะรับข้อมูลเป็น numpy array ซึ่งมักจะแปลงจาก DataFrame เป็น array ก่อน
 - from sklearn.model_selection import train_test_split จะทำหน้าที่แบ่งชุดข้อมูลเป็นชุดฝึก (train) และชุดทดสอบ (test) แบบสุ่ม
 - from sklearn.ensemble import RandomForestRegressor เป็นโมเดลการถดถอยแบบ Random Forest ซึ่งใช้ กลุ่มของการตัดสินใจ (Decision Trees) หลายๆ ต้นที่สุ่มตัวแปรและข้อมูลในแต่ละต้นไม้เพื่อพยากรณ์ค่าเฉลี่ย ของผลลัพธ์ ทำให้ Random Forest มีความเสถียรและลดการเกิด overfitting เหมาะสำหรับการทำนายข้อมูลที่ ซับซ้อนซึ่งมีหลายตัวแปรและความไม่เชิงเส้น (non-linearity)
 - from sklearn.metrics ฟังก์ชัน r2_score หรือค่า R-squared (R^2) เป็นค่าที่ใช้ในการวัดความสามารถของแบบจำลองในการอธิบายความแปรปรวนของข้อมูลจริง โดยเปรียบเทียบผลลัพธ์ของแบบจำลองกับค่าเฉลี่ยของข้อมูล ค่า R^2 แสดงสัดส่วนของความแปรปรวนในข้อมูลจริงที่แบบจำลองสามารถอธิบายได้ ซึ่งมีค่าระหว่าง 0 ถึง 1 หากค่า R^2 เข้าใกล้ 1 หมายความว่าแบบจำลองสามารถอธิบายข้อมูลได้ดีมาก แสดงถึงความแม่นยำในการพยากรณ์สูง แต่หากค่า R^2 เข้าใกล้ 0 หมายความว่าแบบจำลองอธิบายข้อมูลได้น้อย และหากค่าติดลบ แสดงว่าแบบจำลองทำงานได้แย่กว่าการคาดการณ์โดยใช้ค่าเฉลี่ยของข้อมูลจริง ฟังก์ชัน mean_squared_error (MSE) ใช้ในการวัดความคลาดเคลื่อนเฉลี่ยกำลังสอง ระหว่างค่าที่โมเดลคาดการณ์ (y_{pred}) และค่าจริง (y_{true}) โดยคำนวณจากผลรวมของค่าความต่างระหว่างค่าทั้งสอง ยกกำลังสองแล้วหารด้วยจำนวนข้อมูลทั้งหมด

ซึ่งค่าของ MSE แสดงถึงขนาดของข้อผิดพลาดโดยรวมระหว่างค่าที่คาดการณ์กับค่าจริง หากค่า MSE มีค่าต่ำ แสดงว่าโมเดลสามารถคาดการณ์ได้ใกล้เคียงกับค่าจริงมาก ซึ่งบ่งบอกถึงความแม่นยำและเสถียรภาพของแบบจำลองในการพยากรณ์ ฟังก์ชัน mean_absolute_error (MAE) ใช้ในการวัดความคลาดเคลื่อนเฉลี่ยแบบค่าสัมบูรณ์ โดยไม่ยกกำลังสอง เหมาะสำหรับกรณีที่ต้องการวัดค่าความผิดพลาดโดยไม่ให้น้ำหนักกับค่าผิดพลาดขนาดใหญ่เกินไป ค่า MAE จึงสะท้อนถึงความแตกต่างโดยเฉลี่ยระหว่างค่าที่แบบจำลองพยากรณ์ได้กับค่าจริง หากค่า MAE ต่ำ หมายความว่าแบบจำลองมีความคลาดเคลื่อนเฉลี่ยน้อย และสามารถทำนายค่าผลผลิตได้อย่างใกล้เคียงกับข้อมูลจริง

- matplotlib.pyplot ไลบรารี Matplotlib ที่ใช้สำหรับการสร้างกราฟและแผนภาพในภาษา Python เช่น กราฟเส้น, กราฟแท่ง

```
# 1. โหลดข้อมูล/Import data
df = pd.read_csv("sugarcane_yield1.csv")
df = df.dropna()
```

ภาพที่ 3.4 คำสั่ง Import data จากไฟล์ CSV

นำเข้าไฟล์ผลผลิตที่ CSV ผลผลิตที่เก็บจากภาคสนามและดัชนีพืชพรรณของทุกเดือน ที่นำออกมาจาก QGIS แล้วเขียนคำสั่งในการอ่านไฟล์ CSV จากนั้นเขียนคำสั่งลบค่า NaN

```
# 2. กำหนดตัวแปรเป้าหมาย (ผลผลิต) และตัวแปรอิสระ
X = df[[
    "NDVI Month 6",
    "NDVI Month 9",
    "NDVI Month 10"
]]
y = df["น้ำหนักเฉลี่ยต่อไร่ (Kg)"]
```

ภาพที่ 3.5 กำหนดตัวแปร X และ ตัวแปร Y ในโมเดล Random Forest Regression (RFR) ใช้ตัวแปร X คือ ค่า NDVI ของแต่ละเดือน และตัวแปร Y คือ ค่าน้ำหนักเฉลี่ยต่อไร่ (Kg)

```
# 3. แบ่งชุดข้อมูล
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=42)
```

ภาพที่ 3.6 คำสั่งแบ่งชุดข้อมูลฝึกและชุดทดสอบ

งานวิจัยนี้ได้แบ่งชุดข้อมูลออกเป็นชุดฝึก (training) และชุดทดสอบ (test) ซึ่งกำหนด test_size=0.2 คือ ข้อมูล 20% จะถูกใช้สำหรับทดสอบ และ 80% สำหรับฝึกโมเดล

```
# 4. สร้างโมเดล Random Forest
rfr = RandomForestRegressor(
    n_estimators=10,
    max_depth=5,
    random_state=42,
    n_jobs=-1
)
```

ภาพที่ 3.7 ชุดคำสั่งในโมเดล Random Forest Regression

คำสั่งสร้างออบเจกต์ของโมเดล RandomForestRegressor ซึ่งจะถูกใช้ในการฝึกแบบจำลอง (training) และทดสอบ (testing) ภายหลัง โดยในวงเล็บจะเป็นการกำหนดค่าพารามิเตอร์ที่ควบคุมพฤติกรรมของโมเดล n_estimators = 10 จำนวนต้นไม้ (Number of Trees) ที่ต้องการให้โมเดลสร้างขึ้นในป่าการตัดสินใจ (forest) ค่ามาก หมายถึง มีต้นไม้จำนวนมาก แบบจำลองจะมีความเสถียรและแม่นยำขึ้น แต่ใช้เวลาคำนวณนานขึ้น max_depth = 5 ความลึกสูงสุดของแต่ละต้นไม้ (Maximum Depth) ความลึกของต้นไม้บ่งบอกจำนวนการแยกกิ่ง (splits) ที่อนุญาต หากให้ลึกมาก (เช่น 10–20) ต้นไม้จะเรียนรู้ข้อมูลละเอียดมากเกินไปจนเกิด overfitting หากให้ตื้นเกินไป (เช่น 2–3) ต้นไม้จะเรียนรู้ข้อมูลน้อยเกินไปจนเกิด underfitting ในการทดลองนี้กำหนดให้ ความลึกสูงสุด = 5 เพื่อจำกัดความซับซ้อนของแต่ละต้นไม้ และช่วยให้โมเดลสามารถเรียนรู้ได้อย่างสมดุล หากไม่กำหนดค่าโมเดลจะขยายต้นไม้จนกว่าจะไม่มีกิ่งเพิ่มได้ ซึ่งอาจทำให้ overfitting ได้

```
rfr.fit(X_train, y_train)
y_pred = rfr.predict(X_test)
```

ภาพที่ 3.8 ชุดคำสั่งทำนายทำนายค่าผลผลิตของข้อมูลทดสอบ (test data)

คำสั่งนี้ใช้สำหรับ ทำนายค่าผลผลิตของข้อมูลทดสอบ (test data) โดยโมเดลที่ผ่านการฝึก (rfr) จะนำตัวแปรอิสระในชุดทดสอบ (X_test) มาคำนวณหาค่าผลลัพธ์ที่คาดการณ์ (y_pred) ซึ่งเป็นค่าผลผลิตที่โมเดลทำนายได้ ผลลัพธ์ที่ได้จากการพยากรณ์นี้จะถูกนำไปเปรียบเทียบกับค่าจริง (y_test) โดยใช้ตัวชี้วัด คือ ค่า R^2 , ค่า Mean Squared Error (MSE) และ Mean Absolute Error (MAE) เพื่อประเมินความแม่นยำและประสิทธิภาพของโมเดล

```

# 5. ประเมินผล
print(" ♦ Random Forest Regression")
print("R2 =", r2_score(y_test, y_pred))
print("RMSE =", np.sqrt(mean_squared_error(y_test, y_pred)))
print("MAE =", mean_absolute_error(y_test, y_pred))

# 6. แสดงความสำคัญของตัวแปร
importances = pd.Series(rfr.feature_importances_, index=X.columns)
importances.sort_values().plot(kind='barh', figsize=(5,3),color='skyblue')
plt.title("Feature Importance (Random Forest)")
plt.xlabel("Importance")
plt.show()

```

ภาพที่ 3.9 ชุดคำสั่งประเมินผลการทำนายผลผลิตในโมเดล Random Forest Regression

หลังจากที่โมเดล Random Forest Regression ผ่านการฝึกสอนด้วยข้อมูลชุดฝึกแล้ว ได้มีการประเมินความแม่นยำของโมเดลโดยใช้ข้อมูลชุดทดสอบ (out-of-sample) เพื่อวัดความสามารถของแบบจำลองในการพยากรณ์ผลผลิตได้อย่างเป็นกลางและไม่ลำเอียงต่อข้อมูลที่ใช้ฝึก ในการประเมินผลการคาดการณ์ ได้คำนวณตัวชี้วัดเชิงปริมาณหลัก 3 ค่า ได้แก่ R² (Coefficient of Determination), RMSE (Root Mean Squared Error) และ MAE (Mean Absolute Error)

การใช้ตัวชี้วัดทั้งสามร่วมกันช่วยให้ประเมินความสามารถของแบบจำลองได้รอบด้าน ทั้งในเชิงความแม่นยำโดยรวม (ผ่านค่า R²) และขนาดของความผิดพลาดที่เกิดขึ้นจริง (ผ่านค่า RMSE และ MAE) ทำให้สามารถสรุปได้อย่างมีหลักฐานเชิงปริมาณว่าแบบจำลองที่พัฒนาขึ้นมีประสิทธิภาพเพียงใดในการคาดการณ์ผลผลิตอ้อย

3.4.3.2 XGBoost Regression

ในงานวิจัยใช้แบบจำลอง XGBoost Regression ในการณ์คาดการณ์ผลผลิตอ้อย จะใช้ตัวแปรแบบเดียวกันกับ Random Forest Regression (RFR)

```

# 4. สร้างโมเดล XGBoost
xgbr = xgb.XGBRegressor(
    n_estimators=10,
    learning_rate=0.05,
    max_depth=5,
    subsample=0.8,
    colsample_bytree=0.8,
    random_state=42,
    n_jobs=-1
)

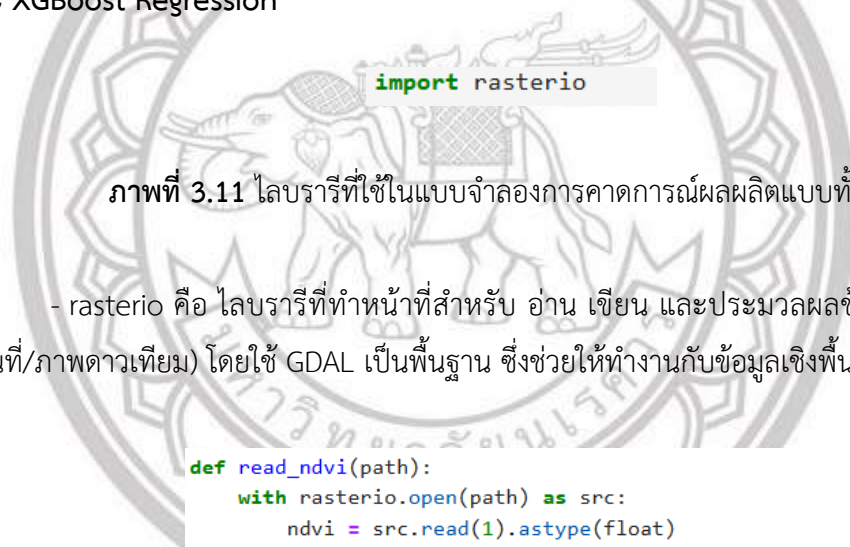
```

ภาพที่ 3.10 ชุดคำสั่งในโมเดล XGBoost Regression

XGBoost Regressor (XGBRegressor) เป็นเทคนิคการเรียนรู้แบบ Gradient Boosting สำหรับปัญหา regression โดยตั้งค่าพารามิเตอร์ n_estimators = 10 จำนวนต้นไม้ในการสร้าง

โมเดล (คล้ายกับ Random Forest) , learning_rate = 0.05 อัตราการเรียนรู้ ช่วยลดโอกาส overfitting , max_depth = 5 กำหนดความลึกสูงสุดของแต่ละต้นไม้ , subsample = 0.8 ใช้ตัวอย่างข้อมูลบางส่วนในแต่ละรอบการสร้างต้นไม้ , colsample_bytree = 0.8 ใช้ตัวแปรบางส่วนในแต่ละต้นไม้ , random_state = 42 เพื่อให้ผลลัพธ์สามารถทำซ้ำได้ , n_jobs = -1 ใช้ทุกคอร์ของเครื่องเพื่อเร่งความเร็วในการประมวลผล หลายค่าของพารามิเตอร์ เช่น n_estimators, max_depth และ random_state ถูกกำหนดให้เหมือนกับ Random Forest เพื่อให้สามารถเปรียบเทียบประสิทธิภาพของโมเดลทั้งสองได้อย่างเป็นธรรม

3.4.3.3 การคาดการณ์ผลผลิตแบบทั้งภาพจากโมเดล Random Forest Regression และ XGBoost Regression



ภาพที่ 3.11 ไลบรารีที่ใช้ในแบบจำลองการคาดการณ์ผลผลิตแบบทั้งภาพ

- rasterio คือ ไลบรารีที่ทำหน้าที่สำหรับ อ่าน เขียน และประมวลผลข้อมูล Raster (ภาพแผนที่/ภาพถ่ายดาวเทียม) โดยใช้ GDAL เป็นพื้นฐาน ซึ่งช่วยให้ทำงานกับข้อมูลเชิงพื้นที่แบบ Raster ได้

```
def read_ndvi(path):
    with rasterio.open(path) as src:
        ndvi = src.read(1).astype(float)
    return ndvi

ndvi_june = read_ndvi("plant_NDVI(6).tif")
ndvi_sep = read_ndvi("plant_NDVI(9).tif")
ndvi_oct = read_ndvi("plant_NDVI(10)_2.tif")
```

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

ภาพที่ 3.12 ฟังก์ชันอ่าน NDVI ทั้ง 3 จาก .tif

Copyright by Naresuan University

All rights reserved

เปิดไฟล์ raster ตามที่กำหนด และอ่าน band แรก ของภาพ NDVI (แต่ละ pixel คือค่า NDVI) แปลงค่าเป็น float เพื่อให้สามารถคำนวณได้ง่าย return ndvi ให้คืนค่าเป็น NumPy array 2 มิติ ของ NDVI และใช้คำสั่งให้อ่านไฟล์ NDVI ของแต่ละเดือน เรียกฟังก์ชัน read_ndvi() สำหรับแต่ละไฟล์ NDVI ของเดือน มิถุนายน, กันยายน, ตุลาคม ผลลัพธ์จะได้เป็น array 2 มิติ ของ NDVI

```
june_flat = ndvi_june.flatten()
sep_flat = ndvi_sep.flatten()
oct_flat = ndvi_oct.flatten()

df = pd.DataFrame({
    "NDVI_June": june_flat,
    "NDVI_September": sep_flat,
    "NDVI_October": oct_flat
})

df = df.dropna()

print(df.head())
print("Total pixels:", len(df))

# -----
# เตรียมข้อมูลสำหรับโมเดล
# -----
X = df[["NDVI_June", "NDVI_September", "NDVI_October"]].values
```

ภาพที่ 3.13 ฟังก์ชันแปลงภาพ 2 มิติเป็น 1 มิติ และรวมเป็น DataFrame

ฟังก์ชัน.flatten() จะแปลง array 2 มิติ เป็น 1 มิติ (แต่ละ pixel เป็นแถว) ใช้ pd.DataFrame() รวม NDVI ของทั้ง 3 เดือนใน ตารางเดียว ลบค่าที่เป็น NaN (ไม่มีค่า) ออก เพื่อใช้สำหรับโมเดล df[...] เลือกเฉพาะ คอลัมน์ NDVI ของแต่ละเดือน แล้วแปลงเป็น NumPy array สำหรับนำไปใช้เป็น ตัวแปร X ในการสร้างโมเดล เช่น Random Forest, XGBoost

```
liขสิขธิ องงวคิทยาลัยนเรศวร
Copyright 2019

y_pred = rfr.predict(X)
y_pred = xgbr.predict(X)

C:\Users\HP\anaconda3\Lib\site
structure names, but RandomForestR
warnings.warn(
[4]:
df['y_pred'] = y_pred
```

(Random Forest)

(XGBoost)

ภาพที่ 3.14 ฟังก์ชันดึงข้อมูล และสร้างคอลัมน์

ฟังก์ชัน `xgbr` คือ โมเดล XGBoost Regressor ที่เคยฝึก (train) ไว้แล้ว ฟังก์ชัน `.predict(X)` ใช้โมเดลทำนายค่าผลผลิต จาก ข้อมูล input X ในที่นี้คือ array ของ NDVI 3 เดือน และสร้างคอลัมน์ใหม่ชื่อ 'y_pred' ใน DataFrame `df` เก็บค่าผลลัพธ์การทำนายของโมเดล (`y_pred`) ไว้ตรงกับแต่ละแถวของ DataFrame

```
ref_path = "plant_NDVI(9).tif"
with rasterio.open(ref_path) as src:
    ref_meta = src.meta.copy()
    height = src.height
    width = src.width
    nodata = src.nodata if src.nodata is not None else -9999
```

ภาพที่ 3.15 โหลด reference raster

`ref_path = "plant_NDVI(9).tif"` ใช้ทำการเปิดไฟล์ NDVI ของเดือนกันยายนเพื่อใช้เป็น ข้อมูลอ้างอิง (reference raster) และดึงข้อมูล metadata ของภาพ เช่น ระบบพิกัดและขนาดภาพ ตรวจสอบค่าพื้นที่ที่ไม่มีข้อมูล (NoData) และกำหนดค่าแทนเป็น -9999 หากไม่พบ

```
y_map = np.full((height, width), nodata, dtype=np.float32)

# เติมค่าจาก y_pred
y_map_flat = y_map.flatten()
y_map_flat[:len(y_pred)] = y_pred # assume y_pred เรียงตาม flatten ของ reference
y_map = y_map_flat.reshape((height, width))
```

ภาพที่ 3.16 สร้าง array 2D และเติมค่า

สร้าง แผนที่ผลผลิตเชิงพื้นที่ (Yield Map) จากค่าที่โมเดลคาดการณ์ (`y_pred`) โดยเริ่มจากการสร้างกริด (array) ขนาดเท่ากับภาพ NDVI อ้างอิง และกำหนดค่าเริ่มต้นเป็นพื้นที่ที่ไม่มีข้อมูล (NoData) จากนั้นนำค่าที่โมเดลทำนายได้มาบันทึกลงในกริดตามลำดับของพิกเซล แล้วปรับให้อยู่ในรูปแบบภาพสองมิติ (2D) เพื่อเตรียมใช้บันทึกเป็นไฟล์แผนที่ผลผลิต (GeoTIFF) ต่อไป

All rights reserved

```

out_path = "y_pred_map_RF.tif"
out_meta = ref_meta.copy()
out_meta.update({
    "dtype": "float32",
    "count": 1,
    "nodata": nodata
})

with rasterio.open(out_path, 'w', **out_meta) as dst:
    dst.write(y_map, 1)

print("GeoTIFF saved at:", out_path)

```

ภาพที่ 3.17 บันทึกผลลัพธ์การคาดการณ์เป็นไฟล์ GeoTIFF (.tif)

ขั้นตอนนี้เป็นกรบันทึกผลการคาดการณ์ผลผลิตออกจากโมเดล Random Forest ให้อยู่ในรูปแบบไฟล์ GeoTIFF เพื่อสามารถนำไปแสดงผลหรือวิเคราะห์ต่อในโปรแกรม GIS เช่น QGIS หรือ ArcGIS ได้ โดยใช้ไลบรารี rasterio ในการกำหนด metadata ของไฟล์ เช่น ชนิดข้อมูล ระบบพิกัด และพื้นที่ที่ไม่มีข้อมูล ก่อนเขียนผลลัพธ์ลงในแผนที่ raster และบันทึกไฟล์ชื่อ y_pred_map_RF.tif”

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

บทที่ 4

ผลการวิจัย

4.1 ผลการเก็บข้อมูลภาคสนาม

จากการดำเนินการเก็บข้อมูลภาคสนามในพื้นที่ปลูกอ้อยพันธุ์ขอนแก่น 3 ณ สถานีปฏิบัติการ บึงราชนก มหาวิทยาลัยนเรศวร ตำบลวังพิกูล อำเภอวังทอง จังหวัดพิษณุโลก ได้ทำการแบ่งพื้นที่ศึกษาขนาดรวม 6.25 ไร่ ออกเป็นพล็อตย่อยจำนวน 30 พล็อต แต่ละพล็อตมีขนาด 10 × 10 เมตร (100 ตารางเมตร) เพื่อใช้เป็นพื้นที่ตัวอย่างในการเก็บข้อมูลเชิงกายภาพของต้นอ้อย ได้แก่ ความสูงของต้นอ้อย เส้นผ่านศูนย์กลางลำต้น และน้ำหนักเฉลี่ยต่อลำ (Kg)

id	จำนวนลำ(ต่อ 100 ตร.ม.)	น้ำหนักรวม(Kg)	น้ำหนักเฉลี่ยต่อลำ(Kg)	ความยาวลำ(cm)	เส้นผ่านศูนย์กลาง (cm)	เส้นผ่านศูนย์กลาง (mm)	รัศมี (mm)	ค่าประมาณผลผลิต(Kg)
1	244	10.3	1.03	227	2.987	29.867	1.493	251.32
2	492	13	1.3	219	2.947	29.467	1.473	639.6
3	502	15	1.5	232	3.147	31.467	1.573	753
4	490	16	1.6	234	3.113	31.134	1.557	784
5	672	15.3	1.53	272	2.92	29.2	1.46	1028.16
6	715	16.2	1.62	261	2.813	28.134	1.407	1158.3
7	687	20	2	217.5	3.056	30.56	1.528	1374
8	427	17.2	1.72	267	2.437	24.367	1.218	734.44
9	486	16.3	1.63	220.5	3.103	31.034	1.552	792.18
10	473	15.1	1.51	218	3.157	31.567	1.578	714.23
11	511	16	1.6	203	2.927	29.267	1.463	817.6
12	536	18	1.8	259	2.493	24.934	1.247	964.8
13	502	14.8	1.48	202	2.523	25.233	1.262	742.96
14	531	19.1	1.91	232	3.05	30.5	1.525	1014.21
15	481	20.1	2.01	268	2.373	23.734	1.187	966.81
16	588	16.3	1.63	203	2.53	25.3	1.265	958.44
17	572	20.2	2.02	91.5	2.403	24.034	1.202	1155.44
18	584	16.1	1.61	84	2.677	26.767	1.338	940.24
19	492	15.9	1.59	72	2.553	25.534	1.277	782.28
20	508	19.1	1.91	216	2.78	27.8	1.39	970.28
21	598	21	2.1	288	2.807	28.067	1.403	1255.8
22	551	18	1.8	267	2.9	29	1.45	991.8
23	541	16.2	1.62	247	3.067	30.667	1.533	876.42
24	539	20.2	2.02	91.5	2.387	23.867	1.193	1088.78
25	526	20	2	218	3.056	30.56	1.528	1052
26	689	18.1	1.81	309	3.113	31.134	1.557	1247.09
27	710	17.1	1.71	300	2.487	24.867	1.243	1214.1
28	640	20.2	2.02	291	2.507	25.067	1.253	1292.8
29	593	18	1.8	265	2.957	29.567	1.478	1067.4
30	697	19	1.9	231	3.12	31.2	1.56	1324.3

ภาพที่ 4.1 แสดงรายละเอียดการเก็บข้อมูลภาคสนามจำนวน 30 ตัวอย่าง ซึ่งใช้เป็นข้อมูลพื้นฐานในการพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อย

4.2 ผลการประมวลผลข้อมูลจากอากาศยานไร้คนขับ (UAV)

ภาพถ่ายออร์โธจาก UAV ประกอบด้วย Ortho Image แบบ RGB และ Multispectral แยกเป็นแถบสเปกตรัม Red และ Near-Infrared (NIR) เพื่อใช้วิเคราะห์ค่าดัชนีพืชพรรณ (NDVI) และประเมินความสูงของต้นอ้อยในแต่ละช่วงเวลา โดยภาพทั้งหมดถูกปรับแก้ค่าพิกัดเชิงพื้นที่ใน QGIS ให้สอดคล้องกัน ผลลัพธ์ที่ได้ คือ 1. DSM (Digital Surface Model) 2. ภาพออร์โธ RGB 3. ภาพ NDVI ซึ่งดำเนินการในทุกช่วงเวลาที่ได้รับข้อมูลภาคสนาม ได้แก่ เดือน มิถุนายน กันยายน และตุลาคม



(1)


(2)

(3)

ภาพที่ 4.2 (1) ภาพถ่าย DSM (Digital Surface Model) (2) ภาพถ่ายออร์โธสี Visible Light (RGB)
(3) ภาพดัชนีพืชพรรณ (NDVI)

4.3 ผลการวิเคราะห์ดัชนีพืชพรรณ (NDVI)

ค่า NDVI เป็นตัวชี้วัดความสมบูรณ์และความหนาแน่นของพืชในพื้นที่ศึกษา ผลการคำนวณค่า NDVI เฉลี่ยจาก 30 พื้นที่ตัวอย่าง พบว่ามีแนวโน้มเพิ่มขึ้นตามช่วงเวลาการเจริญเติบโตของอ้อย



(1)

(2)


(3)

ภาพที่ 4.3 (1) NDVI เดือนมิถุนายน (2) NDVI เดือนกันยายน (3) NDVI เดือนตุลาคม

จากผลลัพธ์พบว่า NDVI เพิ่มขึ้นตามความสูงและความหนาแน่นของลำอ้อย ซึ่งสะท้อนถึงการเจริญเติบโตและความสมบูรณ์ของพืช


fid	id	count	sum	mean	median	stdev	min	max	range
1	1	40335	3068.69	0.07608	0	0.23446	0	1.09	1.09
2	2	40309	5142.89	0.12759	0	0.30892	0	1.322	1.322
3	3	40401	17787.2	0.44027	0	0.54253	0	1.667	1.667
4	4	39215	13762	0.35094	0	0.48753	0	1.586	1.586
5	5	39685	33517.6	0.84459	0.993	0.68149	0	2.03	2.03
6	6	39810	19875.6	0.49926	0	0.57803	0	1.788	1.788
7	7	40253	23189.2	0.57699	0.60607	0.60489	0	1.794	1.794
8	8	39197	14060.4	0.35871	0	0.4958	0	1.617	1.617
9	9	39342	7684.7	0.19533	0	0.39946	0	1.672	1.672
10	10	39813	24669.6	0.62023	0	0.21791	0	1.18	1.18
11	11	39693	4786.11	0.12058	0	0.28266	0	1.12	1.12
12	12	39914	11362.6	0.28468	0	0.45756	0	1.596	1.596
13	13	40280	11402.9	0.28309	0	0.44701	0	1.522	1.522
14	14	40000	18708	0.46777	0	0.57957	0	1.788	1.788
15	15	38884	19275.3	0.49571	0	0.52889	0	1.611	1.611
16	16	39144	9335.16	0.23848	0	0.4071	0	1.516	1.516
17	17	38000	12406.4	0.32649	0	0.46361	0	1.546	1.546
18	18	39521	5599.46	0.14168	0	0.34732	0	1.548	1.548
19	19	39465	9099.03	0.23056	0	0.39987	0	1.475	1.475
20	20	40193	15472.4	0.38495	0	0.52888	0	1.583	1.583
21	21	39672	14724.4	0.37115	0	0.48579	0	1.517	1.517
22	22	40931	16396.2	0.40058	0	0.49419	0	1.49	1.49
23	23	39262	16162.9	0.41167	0	0.47905	0	1.644	1.644
24	24	39980	20310.1	0.50801	0	0.55727	0	1.702	1.702
25	25	40460	19885.3	0.49099	0	0.54862	0	1.905	1.905
26	26	40060	23510	0.58687	0.629	0.60429	0	1.761	1.761
27	27	39812	19375.2	0.48667	0	0.55344	0	1.595	1.595
28	28	40273	23646.5	0.58716	0.60329	0.61317	0	1.774	1.774
29	29	40962	20998.2	0.49055	0	0.56552	0	1.698	1.698
30	30	40033	22050.7	0.55081	0.615	0.57405	0	1.712	1.712

ภาพที่ 4.4 ตารางผลค่าต่างๆ หลังการส่งออกเป็นไฟล์ CSV



(1) NDVI เดือนมิถุนายน

(2) NDVI เดือนกันยายน




(3) NDVI เดือนตุลาคม

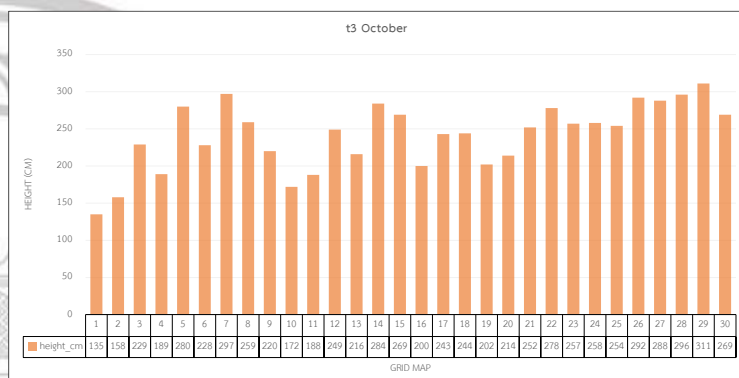
ภาพที่ 4.5 แผนที่ค่าเฉลี่ย NDVI ของแต่ละเดือน

4.4 ผลการวิเคราะห์ความสูงของอ้อย


การคำนวณความสูงของอ้อยได้จากการนำข้อมูลแบบจำลองภูมิประเทศ (DSM) ลบด้วยแบบจำลองระดับพื้นดิน (DEM) เพื่อให้ได้ค่าความสูงของพืช (Canopy Height Model: CHM) และแปลงหน่วยเป็นเซนติเมตร จากนั้นนำค่าที่ได้มาวิเคราะห์ในแต่ละช่วงเวลา พบว่าความสูงของอ้อยมีการเปลี่ยนแปลงอย่างต่อเนื่องเพิ่มขึ้นตามอายุการเจริญเติบโต



(1)

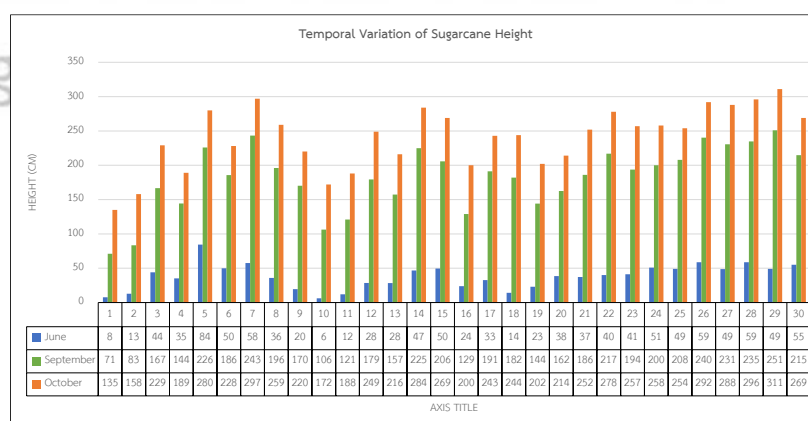


(2)



(3)

ภาพที่ 4.6 (1) กราฟแสดงความสูงของเดือนมิถุนายน (2) กราฟแสดงความสูงของเดือนกันยายน (3) กราฟแสดงความสูงของเดือนตุลาคม



ภาพที่ 4.7 การเปลี่ยนแปลงของความสูงอ้อยตามช่วงเวลา

จากภาพที่ 4.6 แสดงการเปลี่ยนแปลงของความสูงอ้อยในสามช่วงเวลา ได้แก่

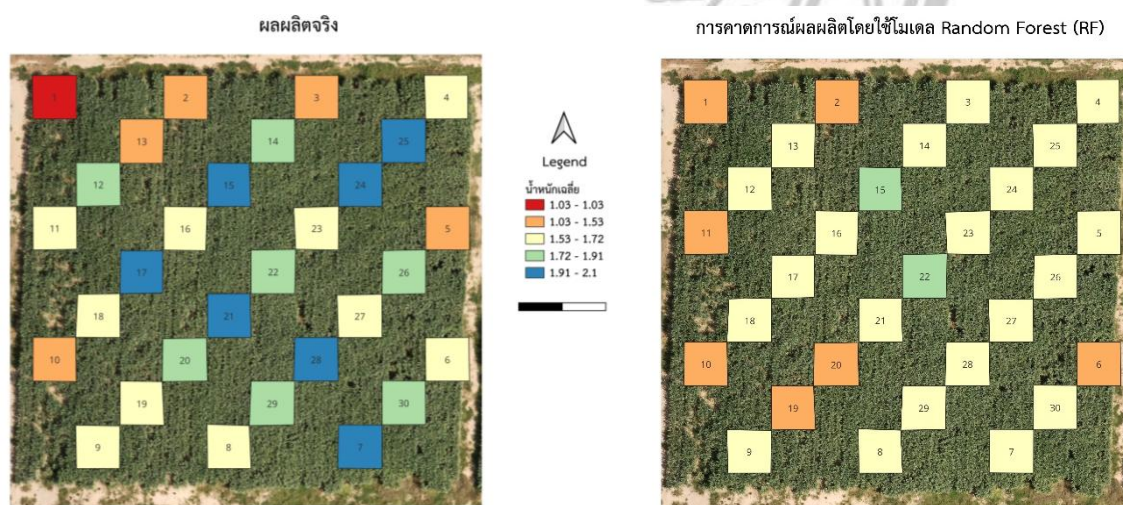
- (1) เดือนมิถุนายน (ระยะเริ่มต้นของการเจริญเติบโต)
- (2) เดือนกันยายน (ระยะกลางของการเจริญเติบโต)
- (3) เดือนตุลาคม (ระยะก่อนการเก็บเกี่ยว)

4.5 ผลการวิเคราะห์ด้วยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning)

4.5.1 Random Forest Regression (RFR)

ในการคาดการณ์ผลผลิต ได้ใช้ตัวแปรดัชนีพืชพรรณ ได้แก่ NDVI Month 6, NDVI Month 9 และ NDVI Month 10 ซึ่งเป็นค่า NDVI ของอ้อยในเดือนที่ 6, 9 และ 10 ตามลำดับ เพื่อใช้เป็นตัวแปรอิสระในการทำนายผลผลิต โดยอาศัยแบบจำลอง Random Forest Regression (RFR)

ข้อมูลที่ใช้ในการสร้างแบบจำลองได้มาจาก แปลงทดลองจำนวน 30 แปลง (Plots) ซึ่งเก็บข้อมูลภาคสนามและคำนวณค่าดัชนีพืชพรรณจากภาพถ่ายอากาศยานไร้คนขับ (UAV Multispectral) เพื่อให้แบบจำลองสามารถเรียนรู้ความสัมพันธ์ระหว่างค่า NDVI กับผลผลิตจริงในแต่ละแปลง ข้อมูลทั้ง 30 แปลงนี้จึงมีความสำคัญต่อการเทรนและทดสอบแบบจำลองทางสถิติและ Machine Learning




รูปที่ 4.8 การเปรียบเทียบผลผลิตจริงกับผลผลิตที่คาดการณ์ได้จากโมเดล Random Forest (RF)

ผลการวิเคราะห์แบ่งออกเป็น 2 ส่วน คือ การประเมินประสิทธิภาพของแบบจำลอง และการวิเคราะห์ความสำคัญของตัวแปร

ผลการประเมินประสิทธิภาพของแบบจำลอง Random Forest Regression

◆ Random Forest Regression
 $R^2 = 0.8311746609944165$
 $RMSE = 0.08399418630675179$
 $MAE = 0.07453333333333327$



ภาพที่ 4.9 ผลการวิเคราะห์เทคนิคการเรียนรู้ของเครื่อง Random Forest Regression

ผลแบบจำลอง RFR ได้รับการประเมินประสิทธิภาพโดยใช้ชุดข้อมูลทดสอบ (Test Data) ค่าสัมประสิทธิ์การตัดสินใจ R^2 ค่าที่ได้คือ 0.8311 หรือประมาณ 83.11% เป็นข้อบ่งชี้ว่าแบบจำลองสามารถอธิบายความสัมพันธ์กับผลผลิตได้ในระดับที่สูงมาก RMSE คือค่าเฉลี่ยของขนาดความคลาดเคลื่อนของการทำนาย ค่าที่ได้คือ 0.0839 หมายความว่าโดยเฉลี่ยแล้ว ค่าทำนายผลผลิตของแบบจำลองจะคลาดเคลื่อนจากค่าจริงประมาณ ± 0.0839 กิโลกรัมต่อไร่ MAE คือค่าเฉลี่ยของผลต่างสัมบูรณ์ระหว่างค่าทำนายกับค่าจริง ค่าที่ได้คือ 0.0745 ซึ่งบ่งชี้ว่าขนาดความคลาดเคลื่อนเฉลี่ยของการทำนายคือ 0.0745 กิโลกรัมต่อไร่


สรุป ประสิทธิภาพของแบบจำลอง RFR ที่ค่า R^2 สูงกว่า 0.8 แสดงให้เห็นว่าแบบจำลองมีความแม่นยำและสามารถนำมาใช้ในการคาดการณ์ผลผลิตอ้อยจากค่า NDVI ได้ดี

ผลการวิเคราะห์ความสำคัญของตัวแปร (Feature Importance)


การวิเคราะห์ความสำคัญของตัวแปร (Feature Importance) เป็นการระบุว่าตัวแปรอิสระตัวใดมีอิทธิพลต่อการทำนายผลผลิตมากที่สุดในแบบจำลอง RFR ผลลัพธ์แสดงในรูปที่ 4.2 ผลการวิเคราะห์แสดงอย่างชัดเจนว่า NDVI Month 10 มีความสำคัญมากที่สุดในการคาดการณ์ผลผลิต โดยมีความสำคัญอยู่ที่ประมาณ 0.51 (หรือ 51%) บ่งชี้ว่าค่าดัชนีพืชพรรณในช่วง ปลายฤดูปลูก (เดือนที่ 10) มีความสัมพันธ์โดยตรงและมีอิทธิพลสูงสุดต่อผลผลิตอ้อย รองลงมา NDVI Month 9 มีความสำคัญเป็นอันดับสอง โดยมีค่าประมาณ 0.39 (หรือ 39%) และ NDVI Month 6 มีความสำคัญน้อยที่สุด โดยมีค่าเพียงประมาณ 0.10 (หรือ 10%) ซึ่งบ่งชี้ว่าค่าดัชนีพืชพรรณในช่วง กลางฤดูปลูก (เดือนที่ 6) มีอิทธิพลต่อผลผลิตน้อยที่สุด ซึ่งการกระจุกตัวของค่าความสำคัญส่วนใหญ่อยู่ที่ NDVI ในเดือนที่ 10 และ 9 แสดงให้เห็นว่า ระยะเวลาเจริญเติบโตที่เข้าสู่ช่วงแก่ มีผลต่อการสะสมน้ำหนักของลำอ้อยและเป็นปัจจัยสำคัญในการทำนายผลผลิตมากที่สุด

4.5.2 XGBoost Regression

เพื่อเปรียบเทียบประสิทธิภาพ แบบจำลอง XGBoost Regression ซึ่งเป็นวิธีการเรียนรู้ของเครื่องแบบ Boosting ได้ถูกนำมาใช้เพื่อคาดการณ์ผลผลิต โดยใช้ตัวแปรอิสระชุดเดิม คือ NDVI Month 6, NDVI Month 9, และ NDVI Month 10



รูปที่ 4.10 การเปรียบเทียบผลผลิตจริงกับผลผลิตที่คาดการณ์ได้จากโมเดล XGBoost



ภาพที่ 4.11 ผลการวิเคราะห์เทคนิคการเรียนรู้ของเครื่อง Random Forest Regression

ผลการประเมินประสิทธิภาพของแบบจำลอง XGBoost Regression

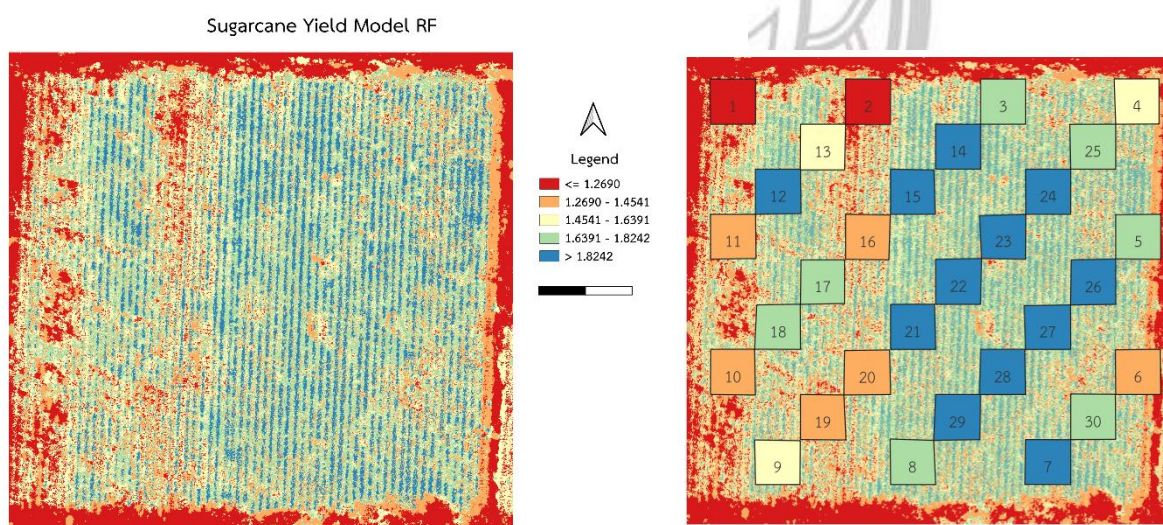
ผลการวิเคราะห์แบบจำลอง XGBoost ได้รับการประเมินประสิทธิภาพโดยใช้ชุดข้อมูลทดสอบ (Test Data) ค่าสัมประสิทธิ์การตัดสินใจ R^2 ค่าที่ได้คือ 0.3759 หรือประมาณ 37.59% ซึ่งบ่งชี้ว่าแบบจำลอง XGBoost สามารถอธิบายความแปรปรวนของผลผลิตได้เพียงประมาณหนึ่ง RMSE คือค่าเฉลี่ยของขนาดความคลาดเคลื่อนของการทำนาย ค่าที่ได้คือ 0.1615 หมายความว่าโดยเฉลี่ยแล้ว ค่าทำนายผลผลิตของแบบจำลองจะคลาดเคลื่อนจากค่าจริงประมาณ ± 0.1615 กิโลกรัมต่อไร่ MAE คือค่าเฉลี่ยของผลต่างสัมบูรณ์ระหว่างค่าทำนายกับค่าจริง ค่าที่ได้คือ 0.1409 ซึ่งบ่งชี้ว่าขนาดความคลาดเคลื่อนเฉลี่ยของการทำนายคือ 0.1409 กิโลกรัมต่อไร่

ผลการวิเคราะห์ความสำคัญของตัวแปร (Feature Importance)

การวิเคราะห์ความสำคัญของตัวแปรในแบบจำลอง XGBoost ยังคงแสดงให้เห็นถึงรูปแบบการมีอิทธิพลของตัวแปร NDVI ต่อผลผลิต ดังแสดงในรูปที่ 4.3 ตัวแปรความสำคัญ (Importance) NDVI Month 10 ประมาณ 0.58 , NDVI Month 9 ประมาณ 0.27, NDVI Month 6 ประมาณ 0.15 ค่า NDVI ในช่วงปลายฤดูปลูก (เดือนที่ 10 และ 9) เป็นปัจจัยที่มีอิทธิพลต่อผลผลิต้อยอย่างมีนัยสำคัญที่สุด

4.6 ผลลัพธ์จากการวิเคราะห์ผลผลิต้อยด้วยโมเดล Random Forest และ XGBoost

การวิเคราะห์ผลการทำนายผลผลิต้อยแบบจำลองการถดถอย Random Forest (RF) และ XGBoost (XG) ได้ถูกนำมาใช้เพื่อคาดการณ์ผลผลิต้อยเป็นแผนที่เชิงพื้นที่ (Spatial Prediction Map) โดยใช้ค่าดัชนีพืชพรรณ (NDVI) เป็นตัวแปรนำเข้า เพื่อแสดงการกระจายตัวของผลผลิตที่คาดการณ์ไว้ในแปลง้อย




ภาพที่ 4.12 แผนที่ผลการทำนายด้วยแบบจำลอง Random Forest

Copyright by Naresuan University

แผนที่ผลการทำนายด้วยแบบจำลอง Random Forest (Sugarcane Yield Model RF) แสดงการกระจายตัวของน้ำหนักเฉลี่ยต่อไร่ (Kg) เป็นสี่ระดับ

- ผลผลิตต่ำมาก (สีแดง) : ≤ 1.2690 กิโลกรัมต่อไร่
- ผลผลิตปานกลาง (สีเหลือง/สีครีม) : $1.2690 - 1.6391$ กิโลกรัมต่อไร่
- ผลผลิตสูง (สีเขียวอ่อน): $1.6391 - 1.8242$ กิโลกรัมต่อไร่
- ผลผลิตสูงมาก (สีน้ำเงิน): > 1.8242 กิโลกรัมต่อไร่

ภาพที่ 4.11 แสดงการกระจายตัวของผลผลิตอ้อยภายในพื้นที่ศึกษา โดยใช้ค่าดัชนีพืชพรรณ (NDVI) ในเดือนที่ 6, 9 และ 10 เป็นตัวแปรนำเข้าในการสร้างแบบจำลอง Random Forest Regression เพื่อคาดการณ์น้ำหนักเฉลี่ยต่อลำ (กก./ลำ) ของอ้อยในแต่ละตำแหน่งเชิงพื้นที่ ผลลัพธ์ชี้ให้เห็นการกระจายของผลผลิตที่แตกต่างกัน ภาคกลางแปลงมีแนวโน้มผลผลิตสูง (สีเขียวอ่อน-น้ำเงิน) สอดคล้องกับค่า NDVI สูง ขณะที่ขอบแปลงพบผลผลิตต่ำมาก (สีแดง) แปลงทดลองทั้ง 30 แปลงถูกระบุหมายเลขกำกับเพื่อเปรียบเทียบความถูกต้องระหว่างผลผลิตจริงและผลผลิตที่คาดการณ์จากแบบจำลอง แสดงให้เห็นว่าแบบจำลองสามารถจำแนกความแตกต่างของผลผลิตระหว่างแปลงได้อย่างชัดเจน



ภาพที่ 4.12 แผนที่ผลการทำนายด้วยแบบจำลอง XGBoost

แผนที่ผลการทำนายด้วยแบบจำลอง XGBoost (Sugarcane Yield Model XG) แสดงการกระจายตัวของน้ำหนักเฉลี่ยต่อลำ (Kg) เป็นสี่ระดับ

- ผลผลิตต่ำมาก (สีแดง): ≤ 1.6319 กิโลกรัมต่อลำ
- ผลผลิตปานกลาง (สีเหลือง/สีครีม) : 1.6319 - 1.731 กิโลกรัมต่อลำ
- ผลผลิตสูง (สีเขียวอ่อน) : 1.731 - 1.7557 กิโลกรัมต่อลำ
- ผลผลิตสูงมาก (สีน้ำเงิน): > 1.7557 กิโลกรัมต่อลำ

ภาพที่ 4.12 แสดงการกระจายตัวของผลผลิตอ้อยที่คาดการณ์ได้จากแบบจำลอง XGBoost Regression โดยใช้ค่าดัชนีพืชพรรณ (NDVI) ในเดือนที่ 6, 9 และ 10 เป็นตัวแปรนำเข้าเช่นเดียวกับแบบจำลอง Random Forest ผลการคาดการณ์แสดงให้เห็นถึงการกระจายของน้ำหนักเฉลี่ยต่อลำ

(กิโกรัมต่อลำ) ภายในพื้นที่ศึกษา โดยพื้นที่ที่มีผลผลิตต่ำมาก (สีแดง) พบกระจายอยู่รอบขอบแปลง เช่นเดียวกัน ส่วนบริเวณกลางแปลงส่วนใหญ่ให้ค่าผลผลิตปานกลางถึงสูง (สีเหลืองและสีเขียวอ่อน) ขณะที่พื้นที่ที่ให้ผลผลิตสูงมาก (สีน้ำเงิน) มีสัดส่วนน้อยกว่าแบบจำลอง Random Forest ซึ่งสอดคล้องกับค่าความแม่นยำของแบบจำลอง XGBoost ที่มีค่า R^2 ต่ำกว่า



ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

บทที่ 5

บทสรุป

งานวิจัยนี้มีวัตถุประสงค์เพื่อสร้างและประเมินแบบจำลองการคาดการณ์ผลผลิตอ้อยโดยใช้เทคนิค Machine Learning (Random Forest Regression และ XGBoost Regression) ร่วมกับข้อมูลดัชนีพืชพรรณ NDVI (Normalized Difference Vegetation Index) ที่ได้จากภาพถ่ายอากาศยานไร้คนขับ (UAV) ในแปลงอ้อยพันธุ์ขอนแก่น 3 ณ สถานีปฏิบัติการบึงราชชนก จังหวัดพิษณุโลก โดยใช้ข้อมูล NDVI 3 ช่วงเวลาหลัก คือ เดือนมิถุนายน (Month 6), เดือนกันยายน (Month 9) และเดือนตุลาคม (Month 10)

5.1 สรุปผลการดำเนินงาน

5.1.1 การวิเคราะห์ข้อมูลดัชนีพืชพรรณ (NDVI)

การวิเคราะห์ข้อมูลดัชนีพืชพรรณ (NDVI) สามารถประมวลผลค่า NDVI ในพื้นที่ตัวอย่าง 30 แปลงย่อย จากภาพถ่าย UAV แบบหลายช่วงคลื่นได้ครบถ้วนในเดือนมิถุนายน (Month 6), กันยายน (Month 9), และตุลาคม (Month 10) เพื่อใช้เป็นตัวแปรอิสระในการสร้างแบบจำลอง ค่า NDVI ที่คำนวณได้สะท้อนถึงการเปลี่ยนแปลงของสุขภาพพืชและชีวมวลอ้อยตามช่วงอายุ ซึ่งยืนยันว่าข้อมูลดัชนีพืชพรรณที่ได้จาก UAV สามารถนำไปใช้ในการวิเคราะห์เชิงปริมาณได้

5.1.2 ผลการประเมินประสิทธิภาพของแบบจำลอง

แบบจำลอง	R ² (ความแม่นยำ)	RMSE (กก./ลำ)	MAE (กก./ลำ)
Random Forest Regression	0.8311	0.0839	0.0745
XGBoost Regression	0.3759	0.1615	0.1409

ตารางที่ 5.2 สรุปเปรียบเทียบประสิทธิภาพการคาดการณ์ของแบบจำลอง

Random Forest และ XGBoost

แบบจำลอง Random Forest Regression (RFR) ให้ประสิทธิภาพการทำนายผลผลิตที่ สูงที่สุด โดยมีค่า R² เท่ากับ 0.8311 ซึ่งบ่งชี้ว่าแบบจำลองสามารถอธิบายความแปรปรวนของผลผลิตได้ถึง 83.11% และมีค่าความคลาดเคลื่อนเฉลี่ยต่ำ (MAE = 0.0745 กก./ลำ)

แบบจำลอง XGBoost Regression ให้ประสิทธิภาพการทำนายที่ต่ำกว่าอย่างมีนัยสำคัญ โดยมีค่า R² เพียง 0.3759

5.1.3 การวิเคราะห์ความสำคัญของตัวแปร

ตัวแปร NDVI Month 10 (ปลายฤดูปลูก) มีความสำคัญในการทำนายผลผลิตสูงสุดในทั้งสองแบบจำลอง (RFR : 51%, XGBoost : 58%) ลำดับความสำคัญของตัวแปร คือ NDVI Month 10 > NDVI Month 9 > NDVI Month 6 ซึ่งตอกย้ำว่าค่าดัชนีพืชพรรณในช่วงท้ายของการเจริญเติบโต มีความสัมพันธ์ใกล้ชิดกับผลผลิตสุดท้ายมากกว่าช่วงกลางฤดูปลูก

5.2 สรุปผลการวิจัย

ผลการวิจัยยืนยัน สมมติฐาน ที่ว่า การใช้ข้อมูลดัชนีพืชพรรณหลายช่วงเวลา (Multi-temporal vegetation indices) ร่วมกับเทคนิค Machine Learning จะช่วยเพิ่มความแม่นยำในการคาดการณ์ผลผลิตอ้อยเมื่อเทียบกับการใช้ข้อมูลเพียงช่วงเวลาเดียว โดยสามารถสรุปผลลัพธ์ ได้ดังนี้

1. แบบจำลอง Random Forest Regression เป็นแบบจำลองที่ดีที่สุดสำหรับการคาดการณ์ผลผลิตอ้อยในงานวิจัยนี้ โดยให้ความแม่นยำสูง ($R^2 = 0.8311$) และความคลาดเคลื่อนต่ำ
2. ตัวแปร NDVI ในเดือนตุลาคม (ก่อนเก็บเกี่ยว) เป็นปัจจัยสำคัญที่สุดในการทำนายผลผลิต ซึ่งสอดคล้องกับหลักการทางสรีรวิทยาของอ้อยที่การสะสมน้ำหนักรากและน้ำตาลจะเกิดสูงสุดในช่วงท้ายของการเจริญเติบโต
3. แผนที่ผลผลิตเชิงพื้นที่ (Yield Map) ที่ได้จากแบบจำลอง RFR แสดงให้เห็นว่าพื้นที่ ผลผลิตสูง มักกระจุกตัวอยู่บริเวณ ใจกลางแปลง ส่วนพื้นที่ ผลผลิตต่ำ จะกระจุกตัวอยู่ที่ ขอบแปลงอย่างชัดเจน ซึ่งเป็นข้อมูลเชิงลึกที่มีประโยชน์ในการบริหารจัดการแบบเกษตรแม่นยำ (Precision Agriculture)

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

อภิปรายผล

การอภิปรายผลด้านดัชนีพืชพรรณ (NDVI)

ผลการวิเคราะห์ค่าดัชนีดัชนีพืชพรรณ (Normalized Difference Vegetation Index: NDVI) จากภาพถ่ายมัลติสเปกตรัมของอากาศยานไร้คนขับ พบว่า NDVI เดือนตุลาคม มีความสัมพันธ์กับผลผลิตอ้อยสูงสุด รองลงมาคือเดือนกันยายนและมิถุนายน ซึ่งสอดคล้องกับช่วงเวลาที่ย้อยอยู่ในระยะการสะสมน้ำตาลสูงสุดก่อนการเก็บเกี่ยว

ผลดังกล่าวสอดคล้องกับงานวิจัยของ Wattananun et al. (2018) ที่พบว่า ค่า NDVI ในช่วงก่อนเก็บเกี่ยวมีความสัมพันธ์เชิงบวกกับชีวมวลและปริมาณน้ำตาลสะสม ($r = 0.89$) และสอดคล้องกับงานของ Jaturong Som-ard et al. (2024) ซึ่งระบุว่าค่าดัชนี NDVI จากข้อมูล Sentinel-2 และ UAV ในช่วงปลายฤดูปลูกเป็นตัวแปรสำคัญในการคาดการณ์ผลผลิตอ้อย

นอกจากนี้ การใช้ข้อมูล NDVI หลายช่วงเวลา (Multi-temporal NDVI) แสดงให้เห็นถึงประสิทธิภาพในการสะท้อนความเปลี่ยนแปลงของพืชตลอดช่วงการเจริญเติบโต ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้ลักษณะพลวัตของพืชได้ดีกว่าการใช้ข้อมูลจากช่วงเวลาเดียว ผลนี้สอดคล้องกับงานของ Narmilan et al. (2022) ที่รายงานว่า การใช้ข้อมูลดัชนีพืชพรรณหลายช่วงเวลาสามารถเพิ่มความแม่นยำของแบบจำลองการเรียนรู้ของเครื่องในการคาดการณ์ผลผลิตได้มากกว่าการใช้ข้อมูลจากช่วงเวลาเดียวกว่า 15–20%

ดังนั้น NDVI จึงมีบทบาทสำคัญในการอธิบายสภาวะชีวภาพของพืช และการใช้ข้อมูลหลายช่วงเวลาทำให้การคาดการณ์ผลผลิตอ้อยมีความแม่นยำและสะท้อนความจริงทางเกษตรได้ดียิ่งขึ้น

การอภิปรายผลด้านเทคนิคการเรียนรู้ของเครื่อง

จากการเปรียบเทียบแบบจำลอง Random Forest Regression (RFR) และ XGBoost Regression (XGB) พบว่า RFR ให้ค่าความแม่นยำสูงกว่าอย่างมีนัยสำคัญ โดยมีค่า $R^2 = 0.8311$ และ $RMSE = 0.0839$ ในขณะที่ XGBoost Regression มีค่า R^2 เพียง 0.3759 ซึ่งแสดงให้เห็นถึงความแตกต่างด้านประสิทธิภาพที่ชัดเจน

สาเหตุหนึ่งที่ทำให้ Random Forest Regression ทำงานได้ดีกว่า เนื่องจากมาจากลักษณะของข้อมูลที่มีขนาดตัวอย่างค่อนข้างน้อย (30 ตัวอย่าง) และมีความไม่เป็นเชิงเส้นสูง (Non-linear relationship) แบบจำลอง RFR สามารถจัดการกับข้อมูลที่มีลักษณะดังกล่าวได้ดี และยังคงลดความเสี่ยงของการเรียนรู้มากเกินไป (Overfitting) ผ่านการสร้างต้นไม้ตัดสินใจหลายต้นแบบอิสระ

ผลลัพธ์นี้สอดคล้องกับงานของ Salgado et al. (2023) ที่ใช้แบบจำลอง Random Forest คาดการณ์ผลผลิตอ้อยจากข้อมูล UAV และพบว่ามีความแม่นยำสูง ($R^2 = 0.95$) รวมถึงงานของ de Oliveira et al. (2022) ที่ชี้ว่า RF มีเสถียรภาพสูงเมื่อใช้กับชุดข้อมูลขนาดเล็กหรือมีสัญญาณรบกวน (Noise) มาก ขณะที่ XGBoost Regression มักต้องการข้อมูลจำนวนมากเพื่อให้ผลคาดการณ์มีเสถียรภาพ

ดังนั้น การเลือกใช้ RFR ในงานวิจัยนี้จึงถือว่าเหมาะสมกับลักษณะของข้อมูลทดลองในระดับแปลง และเป็นแบบจำลองที่สามารถให้ผลลัพธ์ที่น่าเชื่อถือกว่า XGBoost อย่างชัดเจน

การอภิปรายผลด้านความสำคัญของตัวแปร (Feature Importance)

ผลการวิเคราะห์ความสำคัญของตัวแปร (Feature Importance) พบว่า NDVI เดือนตุลาคม มีค่าน้ำหนักสูงสุด (51%) รองลงมาคือเดือนกันยายน (39%) และเดือนมิถุนายน (10%) ซึ่งแสดงให้เห็นว่าข้อมูล NDVI ในช่วงปลายฤดูปลูกเป็นปัจจัยสำคัญที่สุดในการคาดการณ์ผลผลิตอ้อย

ผลลัพธ์สอดคล้องกับงานของ Som-ard et al. (2024) ที่พบว่า NDVI ในช่วงใกล้เก็บเกี่ยวมีความสัมพันธ์สูงสุดกับผลผลิตของพืชไร่ เช่นเดียวกับ Kulasekara et al. (2022) ที่ชี้ว่าข้อมูล NDVI ในช่วงหลังการสะสมชีวมวลจะมีอิทธิพลสูงต่อการคาดการณ์ผลผลิตจริงในพืชเศรษฐกิจหลายชนิด

ดังนั้น การเลือกใช้ข้อมูล NDVI หลายช่วงเวลา โดยเฉพาะในช่วงปลายฤดูปลูก เป็นแนวทางที่ช่วยเพิ่มความสามารถของแบบจำลองในการอธิบายความแปรปรวนของผลผลิตและสนับสนุนแนวคิดการใช้ข้อมูลเชิงเวลา (Temporal Data) เพื่อการคาดการณ์ผลผลิตเชิงพื้นที่อย่างมีประสิทธิภาพ

การอภิปรายผลตามสมมติฐานการวิจัย

ตามสมมติฐานของการวิจัยที่ระบุว่า “การใช้ข้อมูลดัชนีพืชพรรณหลายช่วงเวลา (Multi-temporal vegetation indices) ร่วมกับเทคนิค Machine Learning จะช่วยเพิ่มความแม่นยำในการคาดการณ์ผลผลิตอ้อย เมื่อเทียบกับการใช้ข้อมูลเพียงช่วงเวลาเดียว”

ผลการทดลองยืนยันสมมติฐานดังกล่าว เนื่องจากแบบจำลองที่ใช้ข้อมูลหลายช่วงเวลาให้ค่าความแม่นยำสูงกว่าแบบจำลองที่ใช้ข้อมูลจากช่วงเวลาเดียวอย่างชัดเจน การผสมผสานข้อมูล NDVI จากหลายเดือนช่วยให้แบบจำลองเข้าใจรูปแบบการเปลี่ยนแปลงของพืชได้ดีขึ้น และเพิ่มความสามารถในการคาดการณ์ผลผลิตจริง

ผลลัพธ์สอดคล้องกับงานของ Sumesh et al. (2021) ที่ระบุว่า การใช้ข้อมูลดัชนีพืชพรรณหลายช่วงเวลา (Multi-temporal VIs) สามารถเพิ่มค่าความสัมพันธ์ของแบบจำลองกับผลผลิตจริงได้มากกว่า 20% เมื่อเทียบกับข้อมูลจากช่วงเวลาเดียว และสนับสนุนข้อสรุปของ Narmilan et al.

(2022) ที่ว่า การบูรณาการข้อมูลเชิงเวลาเข้ากับเทคนิค Machine Learning เป็นแนวทางสำคัญในการเพิ่มความแม่นยำของแบบจำลองคาดการณ์ผลผลิตทางการเกษตร

ดังนั้น สมมติฐานของงานวิจัยนี้จึงได้รับการพิสูจน์ว่า “เป็นจริง” และแสดงให้เห็นว่าการใช้ข้อมูล Multi-temporal NDVI ร่วมกับแบบจำลอง Random Forest Regression เป็นแนวทางที่มีศักยภาพสูงในการพัฒนาแบบจำลองคาดการณ์ผลผลิตอ้อยในอนาคต

ข้อเสนอแนะ

1. เพิ่มขนาดชุดข้อมูล ควรเพิ่มจำนวนแปลงตัวอย่างในการเก็บข้อมูลภาคสนาม (30 plot) เพื่อเพิ่มความหลากหลายและความน่าเชื่อถือของแบบจำลอง ซึ่งจะช่วยให้แบบจำลอง XGBoost (ซึ่งต้องการข้อมูลจำนวนมาก) มีโอกาสทำงานได้ดีขึ้น
2. ในงานวิจัยถัดไป ควรนำตัวแปรที่มีความสำคัญสูงมาบูรณาการเข้ากับ NDVI เพื่อเพิ่มความแม่นยำ อาทิ ความสูงของอ้อย (CHM) ที่คำนวณจาก DSM/DEM (ตามที่วิรัช นวลอินทร์, 2567 พบว่า DSM มีผลต่อการคาดการณ์สูงสุด) และข้อมูลความหวาน เนื่องจากงานวิจัยนี้มีข้อมูลความหวานที่ไม่เพียงพอต่อการคาดการณ์

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

บรรณานุกรม

- วีรภัทร นวลอินทร์. (2567). การประยุกต์ใช้โดรนมัลติสเปกตรัมและการใช้ Machine Learning ร่วมกับระบบสารสนเทศภูมิศาสตร์ในการคาดการณ์ผลผลิตอ้อย (วิทยานิพนธ์ปริญญาวิทยาศาสตรบัณฑิต สาขาภูมิศาสตร์). มหาวิทยาลัยนเรศวร.
- A. S. A., Gonzalez, F., & Kulasekara, B. S. (2020). Use of spectral vegetation indices for monitoring sugarcane biomass and yield under UAV remote sensing. *Remote Sensing Applications: Society and Environment*, 18, 100322. <https://doi.org/10.1016/j.rsase.2020.100322>
- A., Gonzalez, F., Salgadoe, A. S. A., Kumarasiri, U. W. L. M., Weerasinghe, H. A. S., & Kulasekara, B. R. N. (2022). Predicting canopy chlorophyll content in sugarcane crops using machine learning algorithms and spectral vegetation indices derived from UAV multispectral imagery. *Remote Sensing*, 14(5), 1140. <https://doi.org/10.3390/rs14051140>
- Barbosa Júnior, R. P., Pinto, M. R., Oliveira, A. A., Zerbato, J. L. P., & de Oliveira, C. E. A. Furlani. (2022). Predicting sugarcane biometric parameters by UAV multispectral images and machine learning. *Agronomy*, 12(9), 1992. <https://doi.org/10.3390/agronomy12091992>
- Breiman, L. (2001). Random forests. *Machine Learning*, 45(1), 5–32. <https://doi.org/10.1023/A:1010933404324>
- C. M., Heenkenda, M. K., & Vargas Romero, K. F. (2024). Estimating the aboveground fresh weight of sugarcane using multispectral images and LiDAR. *Land*, 13(5), 611. <https://doi.org/10.3390/land13050611>
- C., Kachenchart, B., Konglum, P., & Pratum Phutthai, T. (2024). Sugarcane yield estimation using UAV-based RGB images and allometric equations. *Current Applied Science and Technology*, e0259856. <https://doi.org/10.55003/cast.2024.259856>
- Chen, G., & Shang, Y. (2022). Transformer for tree counting in aerial images. *Remote Sensing*, 14(3), 476. <https://doi.org/10.3390/rs14030476>

- Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785–794). <https://doi.org/10.1145/2939672.2939785>
- Colomina, I., & Molina, P. (2014). Unmanned aerial systems for photogrammetry and remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 79(97), 92–101. <https://doi.org/10.1016/j.isprsjprs.2014.02.013>
- EL Mazgualdi, C., Masrour, T., Hassani, I., & Khoudi, A. (2021). Machine learning for KPIs prediction: a case study of the overall equipment effectiveness within the automotive industry [Figure 13: Bagging/random forest example (left), boosting/XG-boost example (right)]. In *Soft Computing*. Retrieved October 31, 2025, from https://www.researchgate.net/figure/Bagging-random-forest-example-left-boosting-XG-boost-example-right_fig13_346054329
- Som-ard, J., Suwanlee, S. R., Pinasu, D., Keawsomsee, S., Kasa, K., Seesanhao, N., Ninsawat, S., Borgogno-Mondino, E., & Sarvia, F. (2024). Evaluating sugarcane yield estimation in Thailand using multi-temporal Sentinel-2 and Landsat data together with machine-learning algorithms. *Land*, 13(9), 1481. <https://doi.org/10.3390/land13091481>
- Sumesh, K. C., Ninsawat, S., & Som-ard, J. (2021). Integration of RGB-based vegetation index, crop surface model and object-based image analysis approach for sugarcane yield estimation using unmanned aerial vehicle. *Computers and Electronics in Agriculture*, 180, 105903. <https://doi.org/10.1016/j.compag.2020.105903>



บรรณานุกรม

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved

ประวัติผู้วิจัย

ชื่อ - ชื่อสกุล ปานไพลิน ชมเชย
วัน เดือน ปี เกิด 18 กันยายน 2546
ที่อยู่ปัจจุบัน 9 หมู่ 5 ตำบลตะกุดไร อำเภอนนทบุรี
จังหวัดเพชรบูรณ์ 67190

ประวัติการศึกษา

พ.ศ. 2565-ปัจจุบัน ระดับอุดมศึกษา วท.บ (สาขาภูมิศาสตร์) มหาวิทยาลัยนเรศวร
อำเภอมะนังพิษณุโลก จังหวัดพิษณุโลก 65000 เกรดเฉลี่ย 3.41
พ.ศ. 2562-2564 ระดับมัธยมศึกษาตอนปลาย (วิทย์-คณิต) โรงเรียนดงขุยวิทยาคม
ตำบลดงขุย อำเภอนนทบุรี จังหวัดเพชรบูรณ์ เกรดเฉลี่ย 3.68
พ.ศ. 2559-2561 ระดับมัธยมศึกษาตอนต้น โรงเรียนบ้านหนองกลอย ตำบลตะกุดไร
อำเภอนนทบุรี จังหวัดเพชรบูรณ์

การเข้าร่วมกิจกรรม

- ตำแหน่งรองประธาน โครงการการพัฒนาทักษะการเรียนรู้ตลอดชีวิต (ค่ายสานสัมพันธ์พี่น้องประจำปี 2565 ถึง 2567 ณ อุทยานแห่งชาติภูหินร่องกล้า
- โครงการสานสัมพันธ์เกษตร ประจำปีการศึกษา 2565 ถึง 2568
- ฝ่ายนันทนาการ คณะเกษตรศาสตร์ ทรัพยากรธรรมชาติและสิ่งแวดล้อม ปีการศึกษา 2565 ถึง ปีการศึกษา 2568
- กิจกรรมแสดงความยินดีที่บัณฑิตในงานพิธีพระราชทานปริญญาบัตร ประจำปีการศึกษา 2564 ปี 2565
- ดำรงตำแหน่งกรรมการชมรมภูมิศาสตร์ ปีการศึกษา 2566
- กิจกรรมบูรณาการวัฒนธรรมและภูมิปัญญาท้องถิ่นด้านการเกษตรกับองค์ความรู้เทคโนโลยีสมัยใหม่ ปี 2566
- โครงการเทศกาลแสดงอัตลักษณ์มหาวิทยาลัยนเรศวร (NU Identity Festival) ปี 2566
- กิจกรรมความยินดีที่บัณฑิตในงานพิธีพระราชทานปริญญาบัตร ประจำปีการศึกษา 2565 ปี 2567
- โครงการอบรมและพัฒนาศักยภาพผู้ดำเนินกิจกรรม ประจำปีการศึกษา 2567 (Pre - Beginning Camp ครั้งที่ 23)

10. โครงการปฐมนิเทศนิสิตใหม่ มหาวิทยาลัยนเรศวร ประจำปีการศึกษา 2567 (Beginning Camp ครั้งที่ 23) Staff
11. กิจกรรมความยินดีที่บัณฑิตในงานพิธีพระราชทานปริญญาบัตร ประจำปีการศึกษา 2566 ปี 2568
12. โครงการ Recreation of NU 2568

รางวัลที่ได้รับ

1. ได้รับเกียรติบัตรด้านการเรียนผลการเรียนดี ประจำปีการศึกษา 2565 สาขาภูมิศาสตร์ ภาควิชาทรัพยากรธรรมชาติและสิ่งแวดล้อม มหาวิทยาลัยนเรศวร
2. ได้รับเกียรติบัตรด้านการเรียนผลการเรียนดี ประจำปีการศึกษา 2566 สาขาภูมิศาสตร์ ภาควิชาทรัพยากรธรรมชาติและสิ่งแวดล้อม มหาวิทยาลัยนเรศวร
3. ได้รับเกียรติบัตรด้านการเรียนผลการเรียนดี ประจำปีการศึกษา 2567 สาขาภูมิศาสตร์ ภาควิชาทรัพยากรธรรมชาติและสิ่งแวดล้อม มหาวิทยาลัยนเรศวร
4. ได้รับเกียรติบัตรนิสิตผลการเรียนดี ประจำปีการศึกษา 2567 โดย มหาวิทยาลัยนเรศวร
5. ได้รับเกียรติบัตรนิสิตผลการเรียนดีเด่น ประจำปีการศึกษา 2567 โดย มหาวิทยาลัยนเรศวร
6. ได้รับใบประกาศเกียรติคุณ จากการประกวดโมเดลธุรกิจ ด้านส่งเสริมชุมชนและตลาดสร้างสรรค์ ในตำแหน่ง Data Analyst โครงการ "MUSHROOM เห็ดนางฟ้า" ภายใต้โครงการเรียนรู้และฝึกประสบการณ์นิสิต รุ่นที่ 1
7. ได้รับรางวัล ชมเชย ในการประกวดนวัตกรรมและโครงงาน ด้านการเกษตร 2568 หัวข้อ "นวัตกรรมเกษตร สร้างสรรค์เพื่อความยั่งยืน"

ลิขสิทธิ์ มหาวิทยาลัยนเรศวร

Copyright by Naresuan University

All rights reserved