

การพัฒนาแบบจำลองการจำแนกพื้นที่ปลูกอ้อยด้วยภาพถ่ายจากดาวเทียม Sentinel-1 และ Sentinel-2

อาเชต สุขสมนึก^{1,2}, อสมารณ สิทธิ^{1*} และ ชูเดช โลศิริ¹

Development of a Sugarcane Plantation Classification Model Using Sentinel-1 and Sentinel-2 Satellite Imagery

Arket Sooksomnuek^{1,2}, Asamaporn Sitthi^{1*} and Chudech Losiri¹

¹ Department of Geography, Faculty of Social Sciences, Srinakharinwirot University, Bangkok, 10110

² Hydro-Informatics Institute (Public Organization), Bangkok, 10900

* Corresponding author: asamaporn@g.swu.ac.th

Received: 14 February 2026; Revised: 24 May 2026; Accepted: 24 June 2026

บทคัดย่อ

อำเภอภูเขียว จังหวัดชัยภูมิ เป็นพื้นที่ปลูกอ้อยที่มีความสำคัญของภาคตะวันออกเฉียงเหนือ ทั้งในด้านขนาดพื้นที่และปริมาณผลผลิตที่ใช้เป็นวัตถุดิบหลักของอุตสาหกรรมน้ำตาล อย่างไรก็ตาม การจัดทำข้อมูลพื้นที่ปลูกอ้อยยังคงพึ่งพาการสำรวจภาคสนามเป็นหลัก ส่งผลให้การวางแผนจัดการอ้อยขาดความต่อเนื่องและความละเอียดเชิงพื้นที่ การศึกษานี้พัฒนาแบบจำลองการจำแนกพื้นที่ปลูกอ้อยด้วยอัลกอริทึมป่าสุ่ม (Random Forest) โดยใช้ข้อมูล Sentinel-1 และ Sentinel-2 จำนวน 21 features ประกอบด้วย Spectral Bands 13 Bands ดัชนีพืชพรรณ 6 ดัชนี และโพลาไรเซชัน VV และ VH บนแพลตฟอร์ม Google Earth Engine โดยใช้แปลงตัวอย่าง 400 แปลง (54,304 จุดภาพ) สำหรับฝึกสอน และจุดตรวจสอบอิสระ 400 จุดสำหรับประเมินความถูกต้องการศึกษาได้เปรียบเทียบชุดข้อมูล 4 รูปแบบ ได้แก่ (1) ข้อมูลเชิงแสง RGB (2) ดัชนีพืชพรรณ (Vis) (3) ดัชนีพืชพรรณร่วมกับข้อมูลเรดาร์ (Vis + SAR) และ (4) ข้อมูลเรดาร์ (SAR) ผลการศึกษาพบว่าการบูรณาการดัชนีพืชพรรณร่วมกับข้อมูลเรดาร์ (Vis + SAR) ให้ผลดีที่สุด โดยมีค่าความถูกต้องโดยรวม (Overall Accuracy) ที่ 88.50% และสัมประสิทธิ์แคปปา (Kappa Coefficient) ที่ 81.90% และค่าความถูกต้องของผู้ผลิต (Producer Accuracy) สำหรับอ้อย 94.0% โดยดัชนีกลุ่มคลื่นขอบแดง ได้แก่ $CI_{red-edge}$ และ SAREI มีบทบาทสำคัญในการลดการทับซ้อนเชิงคลื่น เนื่องจากอ้อยในช่วงก่อนเปิดทึบมีปริมาณคลอโรฟิลล์สูงและสม่ำเสมอทั่วแปลง ทำให้ค่า $CI_{red-edge}$ ของอ้อยมีช่วงการกระจายของข้อมูลต่ำและแยกออกจากพืชชนิดอื่นได้ชัดเจนกว่าดัชนีความเขียวทั่วไป ผลการศึกษาชี้ให้เห็นว่าการบูรณาการข้อมูลหลายเซนเซอร์ร่วมกับดัชนีกลุ่มคลื่นขอบแดงมีความเหมาะสมต่อการจำแนกพื้นที่ปลูกอ้อย และสามารถนำไปประยุกต์ใช้เป็นต้นแบบสำหรับการติดตามพื้นที่ปลูกอ้อยต่อไป

คำสำคัญ: อ้อย, ภาพถ่ายจากดาวเทียมเซ็นติเนล-1/2, ช่วงคลื่นขอบแดง, ภูเกิลเอิร์ธเอนจิน, อัลกอริทึมป่าสุ่ม

¹ ภาควิชาภูมิศาสตร์ คณะสังคมศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพมหานคร 10110

² สถาบันสารสนเทศทรัพยากรน้ำ (องค์การมหาชน) กรุงเทพมหานคร 10900

Abstract

Phu Khiao District, Chaiyaphum Province, is a significant sugarcane-growing area in northeastern Thailand, both in terms of cultivation area and production volume serving as the primary raw material for the sugar industry. However, sugarcane area mapping still relies largely on field surveys, leading to limitations in spatial detail and temporal consistency. This study develops a sugarcane plantation classification model using a Random Forest algorithm with 21 features comprising 13 Sentinel-2 spectral bands, 6 vegetation indices, and VV and VH polarizations from Sentinel-1, processed on Google Earth Engine. A total of 400 training polygons (54,304 pixels) and 400 independent field validation points were used. Four feature datasets were compared: (1) RGB optical data, (2) vegetation indices (VIs), (3) vegetation indices combined with SAR data (VIs + SAR), and (4) SAR data alone. The results indicate that integrating vegetation indices with SAR data (VIs + SAR) yields the best performance, achieving an Overall Accuracy of 88.50%, a Kappa Coefficient of 81.90%, and a Producer's Accuracy for sugarcane of 94.0%. The Red-edge indices, particularly CI red edge and SAREI, effectively reduced spectral overlap between sugarcane and other vegetation types, as sugarcane prior to harvest exhibits high and uniform chlorophyll content, resulting in a narrow interquartile range that is clearly distinguishable from other crops. These findings suggest that multi-sensor integration with Red-edge indices is effective for sugarcane plantation classification and can serve as a prototype for large-scale sugarcane monitoring.

Keywords: Sugarcane, Sentinel-1/2 Imagery, Red-Edge Band, Google Earth Engine, Random Forest Algorithm

Introduction

ภาคการเกษตรนับเป็นรากฐานสำคัญของระบบเศรษฐกิจและความมั่นคงทางอาหารของประเทศไทย โดยพืชเศรษฐกิจหลายชนิดมีบทบาทต่อรายได้ของเกษตรกร การจ้างงาน และอุตสาหกรรมต่อเนื่อง โดยหนึ่งในพืชเศรษฐกิจที่มีความสำคัญอย่างยิ่งคือ อ้อย ซึ่งเป็นวัตถุดิบหลักของอุตสาหกรรมน้ำตาลและอุตสาหกรรมชีวภาพอื่น ๆ เช่น เอทานอล และพลังงานชีวมวล (Laohapattanalert et al., 2016) พื้นที่ปลูกอ้อยส่วนใหญ่พบในภาคตะวันออกเฉียงเหนือ ได้แก่ จังหวัดขอนแก่น อุดรธานี นครราชสีมา และชัยภูมิ ทั้งนี้จังหวัดชัยภูมิมีพื้นที่เพาะปลูกอ้อยประมาณ 593,597 ไร่ และมีปริมาณผลผลิตอ้อย 5.88 ล้านตัน โดยมีผลผลิตเฉลี่ยประมาณ 9.9 ตันต่อไร่ ซึ่งอยู่ในระดับสูงเมื่อเทียบกับจังหวัดสำคัญอื่น ๆ ในภาคตะวันออกเฉียงเหนือ สะท้อนถึงบทบาทของจังหวัดชัยภูมิในฐานะแหล่งผลิตอ้อยที่มีความสำคัญทั้งในระดับพื้นที่และระดับอุตสาหกรรม (Office of the Cane and Sugar Board, 2025) อีกทั้งยังมีรายได้ของเกษตรกรและการขับเคลื่อนอุตสาหกรรมแปรรูปสูง โดยเฉพาะใน อำเภอภูเขียว ซึ่งเป็นอำเภอที่มีพื้นที่ปลูกอ้อยมากที่สุดของจังหวัดชัยภูมิ จากข้อมูลรายงานสถานการณ์การปลูกอ้อย ปีการผลิต 2567/2568 พบว่าอำเภอภูเขียวมีพื้นที่ปลูกอ้อยประมาณ 196,386 ไร่ จากพื้นที่ทั้งหมด หรือคิดเป็นประมาณ ร้อยละ 39 ของพื้นที่อำเภอ (Office of the Cane and Sugar Board, 2025) สะท้อนให้เห็นว่าอ้อยเป็นพืชเศรษฐกิจหลักที่ครอบคลุมการใช้ที่ดินอย่างมีนัยสำคัญ และเป็นแหล่งวัตถุดิบสำคัญของโรงงานน้ำตาลขนาดใหญ่ส่งผลให้การวางแผนการผลิตและการจัดการอ้อยในพื้นที่ดังกล่าวมีความสำคัญทั้งในระดับพื้นที่และระดับอุตสาหกรรม (Mitr Phol Modern Farm, 2025) อย่างไรก็ตาม ลักษณะการปลูกอ้อยที่มีการขยายตัวอย่างต่อเนื่องและกระจายอยู่ในหลายสภาพพื้นที่ รวมถึงการปรับเปลี่ยนพื้นที่นามาเป็นพื้นที่ปลูกอ้อยจากผลกระทบของภัยแล้ง ส่งผลให้รูปแบบการใช้ที่ดินในพื้นที่มีความซับซ้อนมากขึ้น อีกทั้งการปลูกอ้อยที่อาศัยน้ำฝนเป็นหลัก

และมีความแปรผันตามฤดูกาล ยังทำให้การติดตามพื้นที่ปลูกอ้อยและประเมินสถานการณ์การเพาะปลูกด้วยวิธีสำรวจภาคสนามเพียงอย่างเดียวทำได้ยาก ทั้งในด้านเวลา ความครอบคลุม และความทันสมัยของข้อมูล

ในกระบวนการผลิตอ้อย โรงงานน้ำตาลและหน่วยงานที่เกี่ยวข้องจำเป็นต้องทราบข้อมูลสำคัญ ได้แก่ พื้นที่เพาะปลูกอ้อย อายุของอ้อย ระยะการเจริญเติบโตและปริมาณผลผลิต (Office of Agricultural Research and Development Region 5, 2017) เพื่อใช้ในการคาดการณ์ปริมาณอ้อยในแต่ละฤดูการผลิต รวมถึงการวางแผนการรับซื้อและการบริหารจัดการโรงงานตามหลักการปฏิบัติทางการเกษตรที่ดี อย่างไรก็ตามในทางปฏิบัติข้อมูลดังกล่าวมักได้มาจากการสำรวจภาคสนาม ซึ่งต้องใช้ทั้งเวลา งบประมาณและกำลังคนจำนวนมาก ส่งผลให้ข้อมูลการติดตามการเจริญเติบโตของอ้อยมีความคลาดเคลื่อนและไม่สอดคล้องกับสภาพจริง (Som-ard et al., 2024)

จากข้อจำกัดของการสำรวจภาคสนาม เทคโนโลยีการสำรวจระยะไกล (Remote Sensing) จึงถูกนำมาใช้เป็นเครื่องมือสำคัญในการติดตามพื้นที่เกษตรกรรมและจำแนกพื้นที่ปลูกอ้อย โดยงานวิจัยในระยะแรกมักใช้ข้อมูลดาวเทียมเชิงแสง (optical imagery) ร่วมกับดัชนีพืชพรรณในการจำแนกพื้นที่ปลูกอ้อย (Thaicharoen & Majandang, 2022; Nodthaisong et al., 2019) ซึ่งให้ผลลัพธ์ที่ดีในสภาพอากาศปลอดเมฆ แต่ยังมีข้อจำกัดจากเมฆปกคลุมและความคล้ายคลึงของค่าการสะท้อนคลื่นแสงระหว่างอ้อยกับพืชชนิดอื่น ต่อมาจึงมีการนำข้อมูลเรดาร์ SAR จาก Sentinel-1 มาใช้ร่วมกับข้อมูลเชิงแสง เนื่องจากสามารถเก็บข้อมูลได้ต่อเนื่องในทุกสภาพอากาศ (Wijitthanasarn & Obpaet, 2023; Selvaraj et al., 2024) อีกทั้งการบูรณาการข้อมูลหลายเซนเซอร์ร่วมกับอัลกอริทึม Random Forest (RF) บนแพลตฟอร์ม Google Earth Engine (GEE) ยังช่วยเพิ่มความแม่นยำในการจำแนกพื้นที่ปลูกอ้อยได้อย่างมีนัยสำคัญ (Vora et al., 2023; Sanchez et al., 2023; Magidi et al., 2021; Phan et al., 2020) โดยแนวโน้มของงานวิจัยในช่วงหลังเริ่มมุ่งเน้นการใช้ข้อมูลหลายช่วงเวลา (Multi-Temporal) และข้อมูลหลายเซนเซอร์ (Multi-Sensor) เพื่อเพิ่มความต่อเนื่องในการติดตามการเปลี่ยนแปลงพื้นที่เกษตรและลดผลกระทบจากสภาพอากาศ รวมถึงการผสานข้อมูลภาคสนามจำนวนมากเพื่อเพิ่มความแม่นยำของแบบจำลอง ซึ่งสามารถให้ค่าความถูกต้องโดยรวมในระดับสูงและมีศักยภาพต่อการติดตามพื้นที่ปลูกอ้อยในระดับพื้นที่ขนาดใหญ่ได้อย่างมีประสิทธิภาพ (Som-ard et al., 2022; Som-ard et al., 2025a)

อย่างไรก็ตาม จากการทบทวนงานวิจัยที่ผ่านมา พบว่าการใช้ข้อมูลเชิงแสงเพียงอย่างเดียวยังมีข้อจำกัดจากปัญหาเมฆปกคลุมและความคล้ายคลึงของลักษณะการสะท้อนคลื่นระหว่างอ้อยกับพืชเกษตรชนิดอื่น แม้ว่าการเพิ่มข้อมูล SAR จะช่วยลดข้อจำกัดด้านเมฆและเพิ่มข้อมูลเชิงโครงสร้างของพืชได้ แต่การใช้ SAR เพียงอย่างเดียวก็ยังไม่เพียงพอสำหรับการแยกชนิดพืชที่มีลักษณะใกล้เคียงกัน ขณะที่การใช้ข้อมูลหลายช่วงเวลาและหลายเซนเซอร์ แม้จะให้ความแม่นยำสูง แต่ยังคงอาศัยข้อมูลภาคสนามจำนวนมากและใช้ทรัพยากรในการประมวลผลค่อนข้างสูง ซึ่งอาจเป็นข้อจำกัดต่อการประยุกต์ใช้จริงในระดับพื้นที่ นอกจากนี้ งานวิจัยส่วนใหญ่ยังไม่ได้ให้ความสำคัญกับการบูรณาการดัชนีกลุ่มคลื่นขอบแดง (Red-edge indices) ร่วมกับข้อมูล SAR สำหรับการจำแนกพื้นที่ปลูกอ้อยในระดับอำเภอ ทั้งที่ดัชนีกลุ่มดังกล่าวมีศักยภาพในการลดความสับสนเชิงสเปกตรัมระหว่างอ้อยกับพืชพรรณประเภทอื่นได้อย่างมีประสิทธิภาพ

การศึกษานี้มีวัตถุประสงค์เพื่อพัฒนาอัลกอริทึมป่าสุ่ม (Random Forest: RF) สำหรับการจำแนกพื้นที่ปลูกอ้อย โดยใช้ข้อมูลจากดาวเทียม Sentinel-1 และ Sentinel-2 ในพื้นที่อำเภอภูเขียว จังหวัดชัยภูมิ ผลลัพธ์ที่ได้จากการศึกษาสามารถจัดทำข้อมูลพื้นที่ปลูกอ้อยที่มีความถูกต้องแม่นยำสูง ซึ่งเป็นประโยชน์ต่อการบริหารจัดการของโรงงานน้ำตาล ทั้งในด้านการวางแผนการเก็บเกี่ยว การเตรียมกำลังการผลิต และการบริหารจัดการวัตถุดิบได้อย่างมีประสิทธิภาพ นอกจากนี้ ยังช่วยลดภาระการสำรวจภาคสนาม สนับสนุนการประยุกต์ใช้เทคโนโลยีเกษตรแม่นยำ (Precision Agriculture) และเป็นแนวทางสำคัญในการพัฒนาอุตสาหกรรมอ้อยและน้ำตาลให้มีความยั่งยืนในระดับประเทศ

Study Area

อำเภอภูเขียว เป็นอำเภอในจังหวัดชัยภูมิ พื้นที่ 801.929 ตารางกิโลเมตร (ร้อยละ 6.27 ของพื้นที่ทั้งจังหวัด)




Figure 1 The study area in the Phu Khiao District, Chaiyaphum Province

อำเภอภูเขียว เป็นอำเภอในจังหวัดชัยภูมิ พื้นที่ 801.929 ตารางกิโลเมตร (ร้อยละ 6.27 ของพื้นที่ทั้งจังหวัด) มีพื้นที่ปลูกอ้อยในปีการผลิต 2567/2568 จำนวน 196,386 ไร่ คิดเป็นร้อยละ 39.04 ของเนื้อที่อำเภอภูเขียว โดยอ้อยเป็นพืชเศรษฐกิจที่มีพื้นที่ปลูกมากเป็นอันดับสองรองจากข้าว และกระจายอยู่ในทุกหมู่บ้าน เนื่องจากอยู่ใกล้โรงงานน้ำตาล (Kwang Jhone Subdistrict Administrative Organization, n.d.) ในช่วงหลายปีที่ผ่านมา ปัญหาภัยแล้งส่งผลให้เกษตรกรบางส่วนปรับเปลี่ยนพื้นที่นามาปลูกอ้อยแทนข้าว โดยนิยมใช้อ้อยพันธุ์ขอนแก่น 3 ซึ่งมีคุณสมบัติทนแล้ง แตกกอดี คลุมวัชพืชได้ดี ทนน้ำขัง และให้ค่าความหวานสูง เหมาะสมต่อการปลูกในพื้นที่นา (Keawtungmuang et al., 2017) การปลูกอ้อยในพื้นที่ส่วนใหญ่เป็นอ้อยต้นฝน เริ่มปลูกช่วงเดือนพฤษภาคมถึงมิถุนายน อาศัยน้ำฝนเป็นหลัก โดยดินร่วนปนทรายในพื้นที่มีคุณสมบัติระบายน้ำได้ดีและเหมาะต่อการเจริญเติบโตของอ้อย แม้พื้นที่จะมีลักษณะเป็นที่ราบสูงสลับภูเขาและมีความเสี่ยงต่อภาวะฝนทิ้งช่วง แต่สภาพอากาศที่ค่อนข้างแห้งและอุณหภูมิสูงในช่วงปลายฤดูปลูกกลับเอื้อต่อการสะสมความหวานของอ้อย หากมีการจัดการน้ำและช่วงเวลาการปลูกอย่างเหมาะสม (Figure 1)

Dataset

1. ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-2

ข้อมูลภาพถ่ายดาวเทียม Sentinel-2 ภายใต้โครงการ Copernicus ประกอบด้วยช่วงคลื่นทั้งหมด 13 ช่วงคลื่น ครอบคลุมตั้งแต่ช่วงคลื่นแสงที่ตามองเห็นไปจนถึงอินฟราเรดคลื่นสั้น (SWIR) โดยมีความละเอียดเชิงพื้นที่ในช่วง 10–60 เมตร สำหรับงานวิจัยนี้เลือกใช้ข้อมูลผลิตภัณฑ์ระดับ Level-2A จากเซนเซอร์ Multi Spectral Instrument (MSI) ที่ผ่านกระบวนการปรับแก้เชิงตำแหน่งและผลกระทบจากชั้นบรรยากาศเรียบร้อยแล้ว โดยดำเนินการประมวลผลผ่านระบบ Google Earth Engine และคัดเลือกภาพในช่วงวันที่ 1–4 ธันวาคม 2568 ซึ่งเป็นระยะเวลาก่อนการเปิดหีบอ้อย เพื่อให้ข้อมูลสะท้อนสภาพการปกคลุมดินที่สอดคล้องกับช่วงฤดูกาลเก็บเกี่ยวมากที่สุด ทั้งนี้การเลือกช่วงเวลาดังกล่าวเนื่องจากในเดือนพฤศจิกายนซึ่งเป็นช่วงที่อ้อยมีการเจริญเติบโตสูงสุด มีเมฆปกคลุมสูงและไม่สามารถคัดเลือกภาพที่ผ่านเกณฑ์เมฆปกคลุมน้อยกว่าร้อยละ 10 ได้ ช่วงวันที่ 1–4 ธันวาคม จึงเป็นช่วงแรกที่ได้ภาพปลอดเมฆและครอบคลุมพื้นที่ศึกษาได้ครบถ้วน ซึ่งเป็นเหตุผลสำคัญประการหนึ่งในการบูรณาการข้อมูล Sentinel-1 (SAR) มีความจำเป็นในการศึกษานี้ เนื่องจากสามารถเก็บข้อมูลได้ในทุกสภาพอากาศ พร้อมทั้งดำเนินการปรับค่าสัมประสิทธิ์ (Rescaling Factor) เพื่อแปลงค่าข้อมูลให้อยู่ในรูปแบบค่าการสะท้อนที่ถูกต้องสำหรับการวิเคราะห์ดัชนีพืชพรรณและดัชนีเชิงคลื่นอื่น ๆ ในลำดับต่อไป (Pflumm et al., 2025)

2. ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1

ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1 โดยใช้ผลิตภัณฑ์ระดับ Ground Range Detected (GRD) ในโหมด Interferometric Wide Swath (IW) ซึ่งมีคุณสมบัติเด่นในการบันทึกข้อมูลผ่านสิ่งกีดขวางทางบรรยากาศได้ทุกสภาวะ โดยคัดเลือกข้อมูลโพลาไรเซชันแบบ VV และ VH เพื่อสกัดค่าการกระจัดกระจายกลับ (Backscatter) ที่สัมพันธ์กับโครงสร้างทางกายภาพและความชื้นของพื้นที่ปลูกอ้อย ข้อมูลทั้งหมดได้รับการประมวลผลด้วยวิธีการหาค่ามัธยฐานของข้อมูล (Median Composite) เพื่อรักษาความสอดคล้องทางเวลากับชุดข้อมูล Sentinel-2 ในช่วงก่อนฤดูเก็บเกี่ยว อันเป็นการเพิ่มประสิทธิภาพการบูรณาการข้อมูลแบบหลายเซนเซอร์ ให้มีความเที่ยงตรงสูงสุด โดยตัวอย่างข้อมูลสามารถแสดงได้ดัง Figure 2




Figure 2 Dataset derived from Sentinel-1 (VV Polarization) and Sentinel-2 (True color composite)

Methodology

กระบวนการศึกษานี้ประกอบด้วย 5 ขั้นตอนหลัก ได้แก่ การประมวลผลขั้นต้น การคำนวณดัชนีเชิงคลื่น การกำหนดชุดข้อมูล การจำแนกข้อมูลด้วยอัลกอริทึมป่าสุ่ม และการประเมินความถูกต้อง โดยที่ขั้นตอนการดำเนินงานทั้งหมดถูกแสดงใน Figure 3 และมีรายละเอียดดังต่อไปนี้

Framework of the Study




Figure 3 The conceptual framework

1. การประมวลผลข้อมูลขั้นต้น (Pre-processing)

การจัดเตรียมข้อมูลดาวเทียมผ่านแพลตฟอร์ม Google Earth Engine (GEE) ดำเนินการโดยการคัดเลือกชุดข้อมูล Sentinel-2 ระดับผลิตภัณฑ์ Level-2A ที่ผ่านกระบวนการแก้ไขความคลาดเคลื่อนทางบรรยากาศ (Atmospheric Correction) เพื่อแปลงค่าข้อมูลให้อยู่ในรูปค่าการสะท้อนพื้นผิว (Surface Reflectance) ที่ถูกต้อง บูรณาการร่วมกับข้อมูล Sentinel-1 (GRD) โพลาไรเซชัน VV และ VH ซึ่งผ่านกระบวนการปรับแก้เชิงรังสี (Radiometric Calibration) และการปรับแก้ความคลาดเคลื่อนเชิงเรขาคณิตจากลักษณะภูมิประเทศ (Terrain Correction) เพื่อให้ค่าการกระจัดกระจายกลับ (Backscatter) มีความถูกต้องเชิงตำแหน่งและเชิงปริมาณสูงสุด ในการเพิ่มคุณภาพข้อมูลได้ดำเนินการลดสัญญาณรบกวน (Speckle Noise) ด้วยตัวกรอง Focal Mean ซึ่งเป็นวิธีการที่นิยมใช้ในการเตรียมข้อมูล Sentinel-1 (SAR) (Mullissa et al., 2021; Badruzzaman et al., 2025) โดยเลือกข้อมูลจากชุดข้อมูลทั้งสองประเภทในช่วงเวลาที่สอดคล้องกัน เพื่อลดทอนความแปรผันชั่วคราวของสภาพชั้นบรรยากาศและสัญญาณรบกวนเชิงภาพ สำหรับการวิเคราะห์เชิงปริมาณในขั้นตอนถัดไป

2. การคำนวณดัชนีเชิงคลื่น

ภายหลังการปรับแก้ข้อมูลเชิงบรรยากาศและเชิงเรขาคณิต ข้อมูลค่าการสะท้อนพื้นผิวและค่าการกระจายกลับจะถูกนำมาคำนวณดัชนีเชิงคลื่นเพื่อสกัดคุณลักษณะเด่น (Feature Extraction) ของวัตถุบนพื้นผิว โดยดำเนินการผ่านความสัมพันธ์ระหว่างช่วงคลื่น ในการจำแนกคุณลักษณะของวัตถุ โดยข้อมูลจาก Sentinel-2 จะถูกแปลงเป็นดัชนีบ่งชี้สภาพพืชพรรณและความชื้น ขณะที่ข้อมูล Sentinel-1 จะใช้ในการวิเคราะห์โครงสร้างพื้นผิวผ่านดัชนีอัตราส่วนโพลาไรเซชันเพื่อสร้างชุดข้อมูล ที่มีความสมบูรณ์สำหรับการประมวลผลในขั้นตอนถัดไป โดยมีดัชนีที่สำคัญดังนี้

2.1 Normalized Difference Vegetation Index (NDVI)

ตัวชี้วัดพื้นฐานของความเขียวและความหนาแน่นพืช ทำหน้าที่แยกพื้นที่ที่มีพืชปกคลุมออกจากพื้นที่ไม่มีพืช และใช้ติดตามการเจริญเติบโตโดยรวมของอ้อยในเชิงพื้นที่ ค่าที่สูงแสดงถึงพืชที่มีความหนาแน่น เหมาะสำหรับการประเมินการเจริญเติบโตของพืชและการติดตามการเปลี่ยนแปลงสิ่งปกคลุมดิน (Jena et al., 2019 ; Shi et al., 2023) ดังสมการที่ 1

$$NDVI = \frac{NIR-RED}{NIR+RED} \quad (\text{Equation 1})$$

2.2 Green Normalized Difference Vegetation Index (GNDVI)

การตรวจจับความแตกต่างด้านความสมบูรณ์และโภชนาการของพืช ทำหน้าที่สะท้อนการเปลี่ยนแปลงของคลอโรฟิลล์ในอ้อย ซึ่งช่วยแยกอ้อยในระยะเจริญเติบโตต่าง ๆ ได้ชัดเจนกว่าการใช้ NDVI เพียงอย่างเดียว ค่าดัชนีสูงมักสอดคล้องกับพืชที่มีปริมาณคลอโรฟิลล์มาก เหมาะกับพืชที่เรื้อนยอดหนาแน่นหรือพืชในช่วงที่กำลังสะสมชีวมวล (Vera-Esmeraldas et al., 2025) ดังสมการที่ 2

$$GNDVI = \frac{NIR-GREEN}{NIR+GREEN} \quad (\text{Equation 2})$$

2.3 Moisture Stress Index (MSI)

การประเมินสถานะความเครียดจากการขาดน้ำของพืช ทำหน้าที่สะท้อนปริมาณความชื้นในเรื้อนยอดและลำต้นอ้อย ซึ่งช่วยแยกพื้นที่อ้อยที่มีสภาพน้ำแตกต่างจากพืชชนิดอื่นได้ ค่าที่สูงบ่งชี้ระดับความเครียดจากการขาดน้ำและความชื้นน้อย เนื่องจาก SWIR มีความไวต่อปริมาณน้ำในใบพืช เหมาะสำหรับการติดตามความเครียดน้ำและการประเมินความเสี่ยงไฟป่า (Ruenrom et al., 2024) ดังสมการที่ 3

$$MSI = \frac{SWIR}{NIR} \quad (\text{Equation 3})$$

2.4 Red-Edge Chlorophyll Index (CI_{red edge})

การประเมินปริมาณคลอโรฟิลล์เชิงลึก โดยอาศัยคุณสมบัติเฉพาะของช่วงคลื่น Red-edge ซึ่งเป็นช่วงรอยต่อระหว่างคลื่นแสงสีแดงและคลื่นอินฟราเรดใกล้ที่มีความไว สูงต่อการเปลี่ยนแปลงความเข้มข้นของคลอโรฟิลล์ในระดับเซลล์พืช ส่งผลให้สามารถตรวจจับการเปลี่ยนแปลงทางสรีรวิทยาของอ้อยในช่วงสะสมชีวมวลได้อย่างละเอียดมากกว่าการใช้ช่วงคลื่นแสงที่ตามองเห็นปกติ นอกจากนี้ ช่วงคลื่นดังกล่าวยังมีขีดความสามารถในการทะลุผ่านทรงพุ่ม ได้ดี จึงช่วยลดปัญหา

การอิ่มตัวของค่าดัชนี (Saturation Effect) ในสภาวะที่พืชมีความหนาแน่นสูง และเพิ่มความแม่นยำในการจำแนกย่อยออกจากพืชชนิดอื่นที่มีลักษณะความเขียวใกล้เคียงกัน (Liu et al., 2024) ดังสมการที่ 4

$$CI_{red-edge} = \frac{NIR}{RED-edge} - 1 \quad (\text{Equation 4})$$

2.5 Soil-Adjusted Vegetation Index (SAVI)

ดัชนี SAVI มีความสำคัญในการลดอิทธิพลของสภาพดินที่ยังไม่ถูกปกคลุมด้วยพืช ช่วยเพิ่มความถูกต้องในการระบุพื้นที่ที่อยู่ในระยะเริ่มปลูกหรือแปลงที่พืชยังปกคลุมไม่เต็มพื้นที่ โดยทั่วไปใช้ $L = 0.5$ เพื่อปรับผลกระทบจากพื้นดิน ทำให้สามารถแยกสัญญาณพืชออกจากพื้นผิวดินได้ชัดเจนยิ่งขึ้น เหมาะสำหรับพื้นที่ที่แห้งแล้งหรือพื้นที่เพาะปลูกที่ยังมีดินโผล่ให้เห็นเป็นจำนวนมาก นอกจากนี้ SAVI ยังช่วยเพิ่มประสิทธิภาพในการติดตามการเจริญเติบโตของพืชในช่วงต้นฤดูเพาะปลูกได้อย่างมีประสิทธิภาพ (Kareem et al., 2023) ดังสมการที่ 5

$$SAVI = \frac{(NIR-RED)}{(NIR+RED+L)} (1 + L) \quad (\text{Equation 5})$$

2.6 Soil Adjusted Red-Edge Index (SAREI)

ดัชนี SAREI มีความสำคัญในการผสานข้อมูลคลอโรฟิลล์และผลกระทบจากดิน ทำหน้าที่เพิ่มความสามารถในการแยกย่อยออกจากพืชชนิดอื่นในพื้นที่ที่มีการเปิดหน้าดินหรือมีสภาพแปลงไม่สม่ำเสมอ เหมาะสำหรับการติดตามสุขภาพพืชในระยะต้น และการตรวจจับความเครียดที่สัมพันธ์กับคลอโรฟิลล์ (Wolfe, 2017) ดังสมการที่ 6

$$SAREI = \frac{NIR-RED-edge}{NIR+RED-edge+L} \quad (\text{Equation 6})$$

3. การสกัดคุณลักษณะและการตรวจสอบคุณภาพข้อมูล

การสกัดค่าคุณลักษณะดำเนินการโดยใช้ฟังก์ชัน `ee.reduceRegion()` ร่วมกับ `ee.Reducer.mean()` และ `ee.Reducer.median()` เพื่อคำนวณค่าเฉลี่ยและค่ามัธยฐานของดัชนีเชิงคลื่นจำนวน 8 ชนิดภายในแต่ละแปลงตัวอย่างจำนวน 400 แปลง ซึ่งได้จากการแปลความหมายด้วยสายตาร่วมกับข้อมูลอ้างอิงภาคพื้นดิน วิธีการดังกล่าวทำให้ค่าที่สกัดได้เป็นตัวแทนของสภาพพืชพรรณโดยรวมของแต่ละแปลง และช่วยลดผลกระทบจากความแปรผันของค่าจุดภาพภายในแปลงอันเนื่องมาจากความไม่สม่ำเสมอของสภาพพืช ความคลาดเคลื่อนเชิงตำแหน่ง หรือการปะปนของจุดภาพบริเวณขอบแปลงก่อนการฝึกสอนแบบจำลอง ได้ดำเนินการตรวจสอบคุณภาพข้อมูลโดยวิเคราะห์การกระจายตัวของค่าดัชนีด้วยแผนภาพกล่อง (Boxplot) โดยใช้ส่วนต่างระหว่างค่าเฉลี่ยและค่ามัธยฐาน (Mean-Median Difference) เป็นเกณฑ์เสริมในการระบุค่าผิดปกติ (Outliers) ร่วมกับเกณฑ์ช่วงพิสัยระหว่างควอไทล์ (Interquartile Range: $1.5 \times IQR$) และทำการคัดกรองข้อมูลดังกล่าวออกจากชุดฝึกสอน เพื่อเพิ่มความสอดคล้องของข้อมูลภายในแต่ละคลาสและลดสัญญาณรบกวนในการฝึกอัลกอริทึมปาล์มในขั้นตอนถัดไป

4. การกำหนดชุดข้อมูล

การกำหนดชุดคุณลักษณะ (Feature Sets Design) ในงานวิจัยนี้มีวัตถุประสงค์เพื่อประเมินประสิทธิภาพการบูรณาการระหว่างข้อมูลเชิงแสงและข้อมูลเรดาร์ ในการจำแนกพื้นที่ปลูกอ้อยที่มีลักษณะทางชีพลักษณ์และโครงสร้างทางกายภาพเฉพาะตัว โดยมุ่งเน้นการแก้ปัญหาข้อจำกัดด้านเมฆปกคลุมและลดความสับสนเชิงคลื่น ระหว่างอ้อยและพืชพรรณชนิดอื่นที่มีค่าการสะท้อนใกล้เคียงกัน ทั้งนี้ เพื่อระบอบุคประกอบข้อมูลที่เหมาะสมที่สุดสำหรับการประเมินพื้นที่ปลูกอ้อยให้มีความถูกต้องแม่นยำเชิงตำแหน่งสูงสุด งานวิจัยจึงได้จำแนกชุดคุณลักษณะออกเป็น 4 รูปแบบ เพื่อวิเคราะห์เปรียบเทียบขีดความสามารถในการจำแนกจำเพาะ ดังนี้

4.1 ข้อมูลเชิงแสงแบบการมองเห็นด้วยตาเปล่า (RGB) ประกอบด้วยช่วงคลื่นสีน้ำเงิน (Blue) สีเขียว (Green) และสีแดง (Red) เพื่อใช้เป็นฐานข้อมูลพื้นฐานในการประเมินศักยภาพเชิงภาพ (Visual Potential) จากความแตกต่างของระดับสีและความเข้มส่องสว่างของพืชพรรณในการจำแนกพื้นที่เป้าหมาย (Ayhan & Kwan, 2020; Nyamekye et al., 2021; De Swaef et al., 2021)

4.2 ดัชนีพืชพรรณ (Vegetation Indices: VIs) ซึ่งเป็นการบูรณาการด้วยดัชนีเชิงคลื่น ได้แก่ NDVI, GNDVI, MSI, $Cl_{red\ edge}$, SAVI และ SAREI เพื่อเพิ่มประสิทธิภาพในการตรวจวัดคุณลักษณะทางชีพลักษณ์ (Phenology) เช่น ปริมาณคลอโรฟิลล์ ความหนาแน่นของพืชพรรณ ความชื้นในใบ และการลดทอนอิทธิพลจากการสะท้อนของดิน ซึ่งช่วยให้แบบจำลองสามารถรับรู้สรีรวิทยาการเจริญเติบโตของอ้อยได้ละเอียดกว่าการใช้ข้อมูลช่วงคลื่นพื้นฐานเพียงอย่างเดียว (Nsiah et al., 2024; Zhao et al., 2024; Li et al., 2024)

4.3 ดัชนีพืชพรรณและข้อมูลเรดาร์ (VIs + SAR) โดยเป็นการผสานข้อมูลเชิงแสงร่วมกับข้อมูลเรดาร์ (SAR) ในโพลาไรเซชัน VV และ VH เพื่อดึงคุณลักษณะเด่นด้านโครงสร้างเรือนยอด ความขรุขระของพื้นผิว และความชื้นสะสมในลำต้น ซึ่งเป็นลักษณะเฉพาะของอ้อยที่มีรูปแบบการกระจัดกระจายกลับ (Backscatter) ต่างจากพืชไร่ชนิดอื่น การผสานข้อมูลรูปแบบนี้ช่วยแก้ปัญหาข้อจำกัดด้านเมฆปกคลุมและลดความสับสนในการจำแนกพืชที่มีลักษณะเชิงคลื่นใกล้เคียงกัน (Yuan et al., 2023; Chabalala et al., 2022; Dagne et al., 2023) ชุดข้อมูลนี้ประกอบด้วยทั้งสิ้น 21 ช่วงคลื่น ได้แก่ ดัชนีเชิงคลื่นของ Sentinel-2 จำนวน 13 ช่วงคลื่น (B1, B2, B3, B4, B5, B6, B7, B8, B8A, B9, B10, B11, B12) โพลาไรเซชัน VV และ VH จาก Sentinel-1 จำนวน 2 ช่วงคลื่น และดัชนีเชิงคลื่น 6 ดัชนี ได้แก่ NDVI, GNDVI, MSI, $Cl_{red\ edge}$, SAVI และ SAREI เพื่อให้แบบจำลองสามารถวิเคราะห์ได้ทั้งลักษณะทางสรีรวิทยา ระดับความชื้น และโครงสร้างเรือนยอด ซึ่งเป็นปัจจัยสำคัญในการจำแนกอ้อยออกจากพืชชนิดอื่นได้อย่างแม่นยำ

4.4 ข้อมูลเรดาร์ (SAR) โดยวิเคราะห์เฉพาะข้อมูลโพลาไรเซชัน VV และ VH เพื่อประเมินขีดความสามารถของสัญญาณไมโครเวฟในการจำแนกพื้นที่ปลูกอ้อยโดยปราศจากข้อมูลเชิงแสง ซึ่งมีความสำคัญอย่างยิ่งในการติดตามพื้นที่เกษตรกรรมภายใต้ข้อจำกัดด้านสภาพอากาศและเมฆปกคลุมต่อเนื่อง โดยเน้นการใช้ข้อมูลโครงสร้างกายภาพและความชื้นของพืชเป็นตัวจำแนกหลัก (Tsuchiya & Sonobe, 2025; Xu et al., 2019; Tomppo et al., 2021)

5. การจำแนกข้อมูลด้วยอัลกอริทึมป่าสุ่ม

5.1 การกำหนดค่าตัวจำแนก

อัลกอริทึมป่าสุ่มเป็นเทคนิคการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงในการจัดการกับชุดข้อมูลที่มีความซับซ้อน ในการกำหนดจำนวนต้นไม้ตัดสินใจ (numberOfTrees) ที่เหมาะสม ทำการทดสอบในช่วง 50–500 ต้น โดยประเมินจากค่าความถูกต้องโดยรวม (OA) และค่าสัมประสิทธิ์แคปปา (Kappa) ของชุดทดสอบ (Test Set) ซึ่งใช้สำหรับการเลือก Hyperparameter เท่านั้น ซึ่งไม่ใช้การรายงานผลการจำแนกหลัก ผลการทดสอบแสดงใน Figure 4




Figure 4 Random Forest Optimization, the comparison between number of trees and accuracy

จากผลการทดสอบพบว่าค่า OA และ Kappa มีความแตกต่างกันน้อยมากไม่เกิน 0.3% ในทุกช่วงที่ทดสอบ โดย 100 ต้นให้ค่า OA สูงสุดที่ 96.84% และ Kappa 95.87% จึงเลือกใช้ 100 ต้นเพื่อความสะดวกระหว่างความแม่นยำและประสิทธิภาพการประมวลผล ทั้งนี้ค่าความถูกต้องดังกล่าวสูงกว่าค่าที่ได้จากชุดข้อมูลตรวจสอบอิสระ (Validation Data) เนื่องจากชุดทดสอบเป็นจุดภาพที่สุ่มมาจากแปลงข้อมูลเดียวกับชุดฝึกสอน ซึ่งมีความใกล้เคียงกันเชิงพื้นที่ (Spatial Autocorrelation) ทำให้แบบจำลองทำนายได้แม่นยำกว่าข้อมูลภาคสนามอิสระ ดังนั้นผลการจำแนกหลักของการศึกษานี้จึงอ้างอิงจากชุดข้อมูลตรวจสอบอิสระ (Validation Data) 400 จุด ซึ่งสะท้อนความแม่นยำที่แท้จริงของแบบจำลองในพื้นที่จริงได้อย่างเป็นอิสระ จากนั้นนำแบบจำลองดังกล่าวมาจำแนกสิ่งปกคลุมดิน (Land Cover) ทั้ง 6 ประเภท ได้แก่ พื้นที่เกษตรกรรม (Agriculture) พื้นที่ป่าไม้ (Forest) พื้นที่เบ็ดเตล็ด (Miscellaneous) พื้นที่ชุมชนและสิ่งปลูกสร้าง (Urban and Built-up) พื้นที่แหล่งน้ำ (Water) และพื้นที่ปลูกอ้อย (Sugarcane) การบูรณาการข้อมูลระหว่างช่วงคลื่นแสง ดัชนีพืชพรรณ และข้อมูลเรดาร์ (VV, VH) ช่วยให้แบบจำลองสามารถวิเคราะห์ได้ทั้งลักษณะทางสรีรวิทยา ระดับความชื้น และโครงสร้างเรือนยอด ซึ่งเป็นปัจจัยสำคัญในการจำแนกอ้อยออกจากพืชชนิดอื่นได้อย่างแม่นยำ

5.2 การฝึกสอนและจำแนกข้อมูล

ข้อมูลที่ผ่านการตรวจสอบคุณภาพแล้วจากแปลงตัวอย่างจำนวน 400 แปลง (54,304 จุดภาพ) ถูกแบ่งออกเป็นชุดฝึกสอน (Training Set) ร้อยละ 80 จำนวน 320 แปลง และชุดทดสอบ (Testing Set) ร้อยละ 20 จำนวน 80 แปลง เพื่อประเมินขีดความสามารถเบื้องต้นของแบบจำลอง นอกจากนี้ได้จัดเก็บข้อมูลตรวจสอบอิสระ (Validation Data) จำนวน 400 จุด จากการสำรวจภาคสนามแยกต่างหากระหว่างวันที่ 17–19 ธันวาคม พ.ศ. 2568 ซึ่งเป็นชุดข้อมูลสำหรับการตรวจสอบความถูกต้องที่แยกอิสระจากชุดข้อมูลฝึกสอนและทดสอบแบบจำลอง ในกระบวนการเรียนรู้ อัลกอริทึมป่าสุ่มจะจำแนกความแตกต่างระหว่างกลุ่มข้อมูล (Classes) โดยอาศัยความจำเพาะเชิงคลื่นของพืชพรรณและความเข้มของสัญญาณเรดาร์ที่สะท้อนถึงโครงสร้างลำต้นและความชื้นของอ้อย จากนั้นจึงนำแบบจำลองที่ผ่านการฝึกสอนมาดำเนินการจำแนกพื้นที่ศึกษาทั้งหมด (ROI) เพื่อจัดทำแผนที่ผลลัพธ์การใช้ประโยชน์ที่ดินที่ครอบคลุมพื้นที่อย่างต่อเนื่อง

6. การประเมินความถูกต้อง

การประเมินประสิทธิภาพของแบบจำลองดำเนินการโดยใช้การวิเคราะห์เมทริกซ์ความสับสน (Confusion Matrix) เปรียบเทียบผลการจำแนกกับข้อมูลตรวจสอบอิสระ (Validation Data) จำนวน 400 จุด ที่สำรวจภาคสนามระหว่างวันที่ 17–19 ธันวาคม พ.ศ. 2568 เพื่อคำนวณค่าความถูกต้องโดยรวม (Overall Accuracy: OA) ค่าสัมประสิทธิ์แคปปา (Kappa Coefficient) ค่าความถูกต้องของผู้ผลิต (Producer's Accuracy: PA) และค่าความถูกต้องของผู้ใช้ (User's Accuracy: UA) สำหรับยืนยันความเที่ยงตรงเชิงพื้นที่ของผลการจำแนก

การกำหนดขนาดกลุ่มตัวอย่างดำเนินการตามหลักสถิติของ Taro Yamane ซึ่งใช้เป็นเกณฑ์กำหนดขนาดตัวอย่างขั้นต่ำ ได้จำนวน 400 จุด (ประมาณ 398 จุด) จากนั้นกระจายจุดตัวอย่างตามสัดส่วนพื้นที่จริงของแต่ละประเภทการใช้ที่ดิน (Area-proportional stratified sampling) ได้แก่ พื้นที่เกษตรกรรม 96 จุด พื้นที่ป่าไม้ 50 จุด พื้นที่เบ็ดเตล็ด 11 จุด พื้นที่ชุมชนและสิ่งปลูกสร้าง 16 จุด พื้นที่แหล่งน้ำ 12 จุด และพื้นที่ปลูกอ้อย 215 จุด รวมทั้งสิ้น 400 จุด เพื่อให้จุดตรวจสอบในแต่ละประเภทมีความเป็นตัวแทนของพื้นที่จริงอย่างเพียงพอ ทั้งนี้ ตัวเลขร้อยละ 39 ของพื้นที่อ้อยที่ระบุในส่วนพื้นที่ศึกษา หมายถึงสัดส่วนพื้นที่ปลูกอ้อยเมื่อเทียบกับเนื้อที่ทั้งหมดของอำเภอภูเขียว โดยอ้างอิงจากรายงานสถานการณ์การปลูกอ้อยปีการผลิต 2567/2568 (Office of the Cane and Sugar Board, 2025) ขณะที่สัดส่วนของจุดตัวอย่างอ้อยในชุดข้อมูลตรวจสอบ เป็นผลจากการสุ่มตัวอย่างแบบชั้นภูมิตามสัดส่วนพื้นที่ปกคลุมดินจริง (Land Cover) ภายในพื้นที่วิเคราะห์ ซึ่งเป็นข้อมูลคนละส่วนและมีวัตถุประสงค์ต่างกัน ดังนั้นจึงไม่ส่งผลให้ค่าความถูกต้องโดยรวมสูงเกินจริง

ช่วงเวลาระหว่างการเก็บข้อมูลภาคสนามสำหรับฝึกสอน (25–28 พฤศจิกายน) และการบันทึกภาพดาวเทียม (1–4 ธันวาคม) ห่างกันเพียงประมาณ 1 สัปดาห์ ซึ่งเป็นช่วงก่อนการเปิดหีบอ้อยที่สภาพการปกคลุมดินยังไม่มี การเปลี่ยนแปลงอย่างมีนัยสำคัญ จึงถือว่าข้อมูลอ้างอิงภาคสนามมีความสอดคล้องกับสภาพพื้นผิว ณ วันที่บันทึกภาพดาวเทียม อย่างไรก็ตาม ช่วงเวลาตรวจสอบความถูกต้อง (17–19 ธันวาคม) ซึ่งอยู่หลังการเปิดหีบอ้อยบางส่วน อาจทำให้เกิดความคลาดเคลื่อนเชิงเวลาเล็กน้อย อันเป็นข้อจำกัดของการศึกษาครั้งนี้ ดังนั้น การศึกษาในอนาคตควรวางแผนการเก็บข้อมูลภาคสนามให้สอดคล้องกับวันบันทึกภาพดาวเทียมมากขึ้น เพื่อลดผลกระทบจากการเปลี่ยนแปลงสภาพพื้นที่ตามช่วงเวลา ทั้งนี้ งานวิจัยได้เปรียบเทียบชุดข้อมูลจำนวน 4 รูปแบบ เพื่อวิเคราะห์อิทธิพลของแหล่งข้อมูลที่แตกต่างกันต่อความแม่นยำของการจำแนก โดยมุ่งเน้นการบูรณาการข้อมูลเชิงแสงและข้อมูลเรดาร์ เพื่อดึงคุณลักษณะด้านสรีรวิทยาและโครงสร้างพืชพรรณมาช่วยลดความคลาดเคลื่อนในการจำแนกพื้นที่ปลูกอ้อยให้มีประสิทธิภาพมากยิ่งขึ้น

Results

1. การวิเคราะห์การกระจายตัวของคุณลักษณะเชิงคลื่นและเรดาร์จากแปลงตัวอย่าง

ผลการวิเคราะห์การกระจายตัวของค่าคุณลักษณะจากแปลงตัวอย่างภาคสนามจำนวน 400 แปลง ซึ่งสกัดค่าด้วยสถิติค่าเฉลี่ย (Mean) จากข้อมูลดาวเทียมในช่วงเวลาเดียวกันที่ใช้ในการจำแนกพื้นที่ปลูกอ้อย โดยใช้แผนภาพกล่อง (Boxplot) ซึ่งช่วยให้สามารถพิจารณาค่ามัธยฐาน ช่วงควอไทล์ (Q1 – Q3) และค่าผิดปกติได้อย่างเป็นระบบ เป็นขั้นตอนสำคัญในการตรวจสอบคุณภาพและความเหมาะสมของชุดข้อมูลก่อนนำไปใช้ในระบบการฝึกสอนแบบจำลอง (Figure 5)




Figure 5 Box plots illustrating the value distributions of each vegetation index across classes

(A : Agricultural, F : Forest, M : Miscellaneous, U : Urban and Built-up, W : Water and S : Sugarcane)

ผลการวิเคราะห์การกระจายตัวชี้ให้เห็นว่า ดัชนีเชิงแสงกลุ่มความเขียว (NDVI, GNDVI, SAVI) ในพื้นที่ปลูกอ้อย แสดงค่าในระดับสูงและสามารถแยกออกจากแหล่งน้ำ ชุมชน และพื้นที่เบ็ดเตล็ดได้ชัดเจน แต่ยังคงมีการทับซ้อนกับเกษตรกรรมในช่วงควอไทล์ที่ 3 ขณะที่ดัชนีความเครียดน้ำ (MSI) ของอ้อยมีค่ามัธยฐานและการกระจายตัวที่เสถียรที่สุดเมื่อเทียบกับหลายประเภท แต่ยังซ้อนกับป่าไม้บางส่วน ด้านดัชนี Red-edge ($CI_{red\ edge}$ และ SAREI) ให้ประสิทธิภาพการจำแนกสูงสุด โดยสามารถแยกอ้อยออกจากประเภทอื่นได้ชัดเจนที่สุดจากระยะห่างของค่ามัธยฐานและช่วงควอไทล์ ส่วนข้อมูลเรดาร์ (VV, VH) แม้จะมีการทับซ้อนกับป่าไม้และพืชเกษตรอื่นค่อนข้างมาก แต่มีความได้เปรียบในการแยกแหล่งน้ำได้อย่างเด็ดขาด และสะท้อนความแปรปรวนของพื้นที่ชุมชนได้ชัดเจน โดยรวมสะท้อนว่าการบูรณาการหลายดัชนีช่วยเพิ่มศักยภาพในการจำแนกพื้นที่ปลูกอ้อยได้ดียิ่งขึ้น

2. การประเมินความถูกต้องของการจำแนก (Accuracy Assessment)

ประเมินความถูกต้องของการจำแนก โดยเปรียบเทียบผลลัพธ์จากโมเดลกับชุดข้อมูลตรวจสอบภาคสนาม ผ่านการวิเคราะห์เมทริกซ์ความสับสน เพื่อวัดความแม่นยำประกอบด้วยความถูกต้องรวมและค่าสถิติแคปปา ซึ่งกระบวนการนี้เป็นขั้นตอนสำคัญในการยืนยันความน่าเชื่อถือของแบบจำลองก่อนนำไปจัดทำแผนที่ผลการจำแนกพื้นที่ปลูกอ้อยในลำดับสุดท้าย โดยมีตารางการตรวจสอบความถูกต้องหลังการจำแนกสิ่งปกคลุมดิน แสดงใน Table 1

Table 1 Confusion matrix and accuracy assessment results for land cover classification

Method 1 : RGB							
Class	A	F	M	U	W	S	Total
Agriculture (A)	80	6	1	3	0	6	96
Forest (F)	13	32	0	0	5	0	50
Miscellaneous (M)	6	0	3	0	0	2	11
Urban and Built-up (U)	2	0	1	11	1	1	16
Water (W)	0	0	0	1	10	1	12
Sugarcane (S)	12	0	1	2	2	198	215
Total	113	38	6	17	18	208	400

Overall Accuracy = 83.50% | Kappa = 74.11%

Method 2 : VIs							
Class	A	F	M	U	W	S	Total
Agriculture (A)	81	4	1	3	0	7	96
Forest (F)	10	39	0	0	1	0	50
Miscellaneous (M)	5	0	5	0	0	1	11
Urban and Built-up (U)	3	0	0	11	0	2	16
Water (W)	0	0	0	1	11	0	12
Sugarcane (S)	14	0	0	1	1	199	215
Total	113	43	6	16	13	209	400

Overall Accuracy = 86.50% | Kappa = 78.74%

Method 3 : VIs + SAR							
Class	A	F	M	U	W	S	Total
Agriculture (A)	84	4	2	1	0	5	96
Forest (F)	8	41	0	0	1	0	50
Miscellaneous (M)	3	1	6	0	0	1	11
Urban and Built-up (U)	3	0	1	10	0	2	16
Water (W)	0	0	0	1	11	0	12
Sugarcane (S)	10	1	1	1	0	202	215
Total	108	47	10	13	12	210	400
Overall Accuracy = 88.50% Kappa = 81.90%							

Method 4 : SAR							
Class	A	F	M	U	W	S	Total
Agriculture (A)	45	20	1	0	1	29	96
Forest (F)	15	21	0	0	1	13	50
Miscellaneous (M)	3	2	3	1	0	2	11
Urban and Built-up (U)	5	4	0	5	1	1	16
Water (W)	0	0	0	1	11	0	12
Sugarcane (S)	44	33	0	2	0	136	215
Total	112	80	4	9	14	181	400
Overall Accuracy = 55.25% Kappa = 32.44%							

จากตาราง Confusion Matrix พบว่าวิธี Vis + SAR สามารถแยกแยะจุดภาพได้แม่นยำที่สุด โดยเฉพาะพื้นที่อ้อยที่จำแนกได้ถูกต้องถึง 202 จุด จาก 215 จุด ซึ่งส่งผลให้มีความถูกต้องโดยรวมสูงสุดที่ OA = 88.50% และ Kappa = 81.90% ในขณะที่ข้อมูล SAR เพียงอย่างเดียวแสดงให้เห็นระดับความสับสนสูงระหว่างพื้นที่อ้อยกับพื้นที่เกษตรกรรมและป่าไม้ โดยมีความถูกต้องโดยรวมต่ำที่สุดเพียง 55.25% ซึ่งให้เห็นว่าการบูรณาการข้อมูลร่วมกันให้ผลลัพธ์ที่ดีกว่าการใช้ข้อมูลชนิดเดียวอย่างมีนัยสำคัญ โดยสามารถแสดงค่าความถูกต้องของการจำแนกแต่ละชุดข้อมูลได้ดัง Figure 6 ทั้งนี้ เพื่อให้เห็นภาพรวมของประสิทธิภาพการจำแนกในแต่ละวิธีได้อย่างชัดเจน จึงได้สรุปค่าความถูกต้องโดยรวม ค่าสัมประสิทธิ์แคปปา และค่าความถูกต้องของผู้ผลิตสำหรับพื้นที่ปลูกอ้อยไว้ใน Table 2 และรายละเอียดค่าความถูกต้องของผู้ผลิต (Producer's Accuracy: PA) ค่าความถูกต้องของผู้ใช้ (User's Accuracy: UA) และค่า F1-Score แยกตามประเภทการใช้ที่ดินแต่ละคลาสไว้ใน Table 3




Figure 6 Accuracy comparison of different classification approaches

Table 2 Summary of classification accuracy for each method.

Method	Overall Accuracy (%)	Kappa Coefficient (%)	Recall Sugarcane (%)
Method 1: RGB	83.50	74.11	92.10
Method 2: Vis	86.50	78.74	92.60
Method 3: Vis + SAR	88.50	81.90	94.00
Method 4: SAR	55.25	32.44	63.30


Table 3 Recall (Producer's Accuracy), Precision (User's Accuracy), and F1-Score by land use category (%).

Class	Recall — Producer's Accuracy (%)				Precision — User's Accuracy (%)				F1-Score (%)			
	RGB	Vis	Vis+SAR	SAR	RGB	Vis	Vis+SAR	SAR	RGB	Vis	Vis+SAR	SAR
Agriculture (A)	83.3	84.4	87.5	46.9	70.8	71.7	77.8	40.2	76.6	77.5	82.4	43.3
Forest (F)	64.0	78.0	82.0	42.0	84.2	90.7	87.2	26.2	72.7	83.9	84.5	32.3
Miscellaneous (M)	27.3	45.5	54.5	27.3	50.0	83.3	60.0	75.0	35.3	58.8	57.1	40.0
Urban and Built-up (U)	68.8	68.8	62.5	31.2	64.7	68.8	76.9	55.6	66.7	68.8	69.0	40.0
Water (W)	83.3	91.7	91.7	91.7	55.6	84.6	91.7	78.6	66.7	88.0	91.7	84.6
Sugarcane (S)	92.1	92.6	94.0	63.3	95.2	95.2	96.2	75.1	93.6	93.9	95.1	68.7

Note: Method 1: RGB (Blue, Green, Red); Method 2: Vis (NDVI, GNDVI, MSI, Cired edge, SAVI, SAREI); Method 3: Vis + SAR (13 Sentinel-2 bands + 6 Vis + VV/VH = 21 features); Method 4: SAR (VV, VH only).

จากการเปรียบเทียบประสิทธิภาพการจำแนกทั้ง 4 รูปแบบ พบว่าวิธีที่ 3 ซึ่งใช้ดัชนีพืชพรรณร่วมกับข้อมูลเรดาร์ ให้ประสิทธิภาพสูงสุดในการจำแนกพื้นที่ปลูกอ้อย โดยมีค่าความถูกต้องโดยรวม (OA) เท่ากับ 88.50% และค่าสัมประสิทธิ์แคปปา (Kappa) เท่ากับ 81.90% ขณะที่พื้นที่ปลูกอ้อยมีค่า Producer's Accuracy (PA) 94.0% ค่า User's Accuracy (UA) 96.2% และค่า F1-Score 95.1% สะท้อนให้เห็นว่าการบูรณาการข้อมูลเชิงสรีรวิทยาจากดัชนีพืชพรรณร่วมกับข้อมูลเชิงโครงสร้างจากเรดาร์สามารถช่วยลดความสับสนระหว่างพื้นที่อ้อยกับพื้นที่เกษตรกรรมอื่นได้อย่างมีประสิทธิภาพ เมื่อเปรียบเทียบกับการใช้ดัชนีพืชพรรณเพียงอย่างเดียว (Vis) ซึ่งให้ค่า PA, UA และ F1-Score ของอ้อยที่ 92.6%, 95.2% และ 93.9% ตามลำดับ แม้ยังสามารถจำแนกอ้อยได้ดีแต่ยังพบความคลาดเคลื่อนบริเวณรอยต่อของพืชพรรณ ส่วนข้อมูล RGB ให้ค่า PA 92.1% ค่า UA 95.2% และค่า F1-Score 93.6% โดยมีข้อจำกัดด้านจุดบกพร่องเชิงพื้นที่ ทำให้เกิดความคลาดเคลื่อนในการจำแนกพื้นที่เกษตรกรรมและอ้อยมากขึ้น ขณะที่การใช้ข้อมูล SAR เพียงอย่างเดียวให้ผลลัพธ์ต่ำที่สุด โดยมีค่า PA 63.3% ค่า UA 75.1% และค่า F1-Score 68.7% เนื่องจากข้อจำกัดของสัญญาณเรดาร์ในการแยกแยะชนิดพืชพรรณเมื่อไม่มีข้อมูลเชิงสเปกตรัมจากช่วงคลื่นแสงมาสนับสนุน

จากการเปรียบเทียบผลการจำแนกสิ่งปกคลุมดินทั้ง 6 ประเภท ด้วยอัลกอริทึมป่าลุ่ม จากชุดข้อมูล 4 รูปแบบ สามารถบรรยายลักษณะความแตกต่างเชิงพื้นที่ได้ดัง Figure 7

**Figure 7** Comparison of land-cover classification maps produced by different methods

(A) Satellite Image (B) RGB (C) VIS (D) VIS+SAR (E) SAR

การจำแนกด้วยข้อมูล RGB เพียงอย่างเดียว โดยการใช้ข้อมูลเชิงแสงแบบการมองเห็นด้วยตาเปล่า (Figure 7B) พบปัญหาการจำแนกแหล่งน้ำปะปนกับพื้นที่ชุมชนค่อนข้างสูง โดยแผนที่ที่มีจุดบกพร่องกระจายตัว ทำให้พื้นที่เกษตรและอ้อยทับซ้อนกันจนแยกไม่ออก ในขณะที่การใช้ข้อมูลเรดาร์ (SAR) เพียงอย่างเดียว (Figure 7E) ให้ผลลัพธ์ต่ำที่สุด โดยภาพมีลักษณะหยาบ ไม่สามารถระบุขอบเขตแปลงพืชพรรณหรือเส้นทางคมนาคมที่ชัดเจนได้ เนื่องจากสัญญาณมีความไวต่อโครงสร้างทางกายภาพที่คล้ายคลึงกันเกินไป

การนำดัชนีพืชพรรณต่าง ๆ (Figure 7C) มาใช้ร่วมกับค่าสีช่วยให้โครงสร้างเชิงพื้นที่เด่นชัดขึ้น โดยเฉพาะโครงข่ายถนนที่เป็นเส้นสายต่อเนื่องและการเกาะกลุ่มของพื้นที่เมือง อย่างไรก็ตาม ในส่วนของพื้นที่เกษตรกรรม (สีเหลือง) ยังคงพบข้อจำกัดสำคัญคือการจำแนกผิดพลาดเป็นพื้นที่ชุมชน (สีแดง) ลงเหลืออยู่หลายบริเวณ เนื่องจากลักษณะการสะท้อนแสงของพื้นที่เกษตรบางช่วงหรือพื้นที่เตรียมปลูกอาจมีความใกล้เคียงกับวัสดุสิ่งปลูกสร้าง

ผลลัพธ์ที่ดีที่สุดจากการรวมข้อมูล Vis และ SAR การจำแนกด้วยวิธีที่ 3 (Figure 7D) คือวิธีที่มีประสิทธิภาพสูงสุด ข้อมูลเรดาร์ช่วยเสริมความแม่นยำในการแยกแยะโครงสร้างทางกายภาพ ทำให้จุดภาพที่เคยจำแนกผิดเป็นชุมชนถูกปรับแก้เป็นพื้นที่เกษตรตามรูปทรงแปลงที่แท้จริง นอกจากนี้ยังช่วยให้ขอบเขตระหว่างพื้นที่ปลูกอ้อยและพื้นที่ป่ามีความคมชัดและลดการปะปนกันของจุดภาพได้ดีกว่าทุกวิธี

จะเห็นได้ว่าชุดข้อมูลการบูรณาการข้อมูลทั้งค่าสะท้อนพืชพรรณ (Vis) และข้อมูลโครงสร้างพื้นผิว (SAR) ช่วยเพิ่มประสิทธิภาพในการจำแนกพื้นที่ปลูกอ้อยมากที่สุด

Discussion

ผลการวิเคราะห์การกระจายข้อมูลจากแผนภูมิกล่อง สะท้อนให้เห็นความแตกต่างของศักยภาพดัชนีพืชพรรณแต่ละกลุ่มในการจำแนกพื้นที่ปลูกอ้อยอย่างชัดเจน ดัชนีกลุ่มความเขียว ได้แก่ NDVI, GNDVI และ SAVI สามารถแยกอ้อยออกจากแหล่งน้ำ ชุมชน และพื้นที่เบ็ดเตล็ดได้ดี เนื่องจากอ้อยมีการสังเคราะห์แสงสูงในช่วงฤดูปลูก อย่างไรก็ตาม ค่าดัชนีดังกล่าวยังคงทับซ้อนกับป่าไม้ ซึ่งเป็นข้อจำกัดที่พบได้ทั่วไปในงานจำแนกพืชพรรณ เนื่องจากดัชนีกลุ่มนี้อาศัยช่วงคลื่นแดงและอินฟราเรดใกล้ (NIR) เป็นหลัก และมีความไวต่อปริมาณใบเขียว (Sonobe et al., 2018) ขณะที่ดัชนีความเครียดน้ำ (MSI) ของอ้อยแสดงค่ามัธยฐานและช่วงการกระจายที่ค่อนข้างเสถียร แต่ยังพบการซ้อนทับกับพื้นที่ป่าบางส่วนที่มีความชุ่มชื้นสูง

โดยผลลัพธ์ที่โดดเด่นที่สุดคือดัชนีกลุ่มขอบแดง ได้แก่ $CI_{red-edge}$ และ SAREI ซึ่งแสดงการแยกตัวของช่วงควอไทล์ (IQR) ระหว่างอ้อยกับประเภทพื้นที่อื่นได้ชัดเจนที่สุด สะท้อนให้เห็นว่าดัชนีกลุ่มนี้มีความสามารถในการแยกแยะชนิดพืช (Feature Separability) สูงกว่าดัชนีกลุ่มอื่น ทั้งนี้เนื่องจากอ้อยในช่วงก่อนการเปิดทาบ (ธันวาคม) มีปริมาณคลอโรฟิลล์สูงและสม่ำเสมอทั่วแปลง ส่งผลให้ค่า $CI_{red-edge}$ มีการกระจายตัวของข้อมูลต่ำและมีความแม่นยำสูงกว่าพืชประเภทอื่นอย่างชัดเจน ขณะที่พืชเกษตรอื่นและป่าไม้มีการกระจายตัวของข้อมูลสูงกว่า ทำให้เกิดการทับซ้อนระหว่างประเภทมากกว่า ซึ่งสอดคล้องกับ Rekha et al. (2025) ที่รายงานว่า RECI และ NDRE เป็นดัชนีที่มีประสิทธิภาพสูงสุดในการแยกแยะอ้อยจากพืชชนิดอื่น เนื่องจากช่วงคลื่นขอบแดงมีความไวต่อปริมาณคลอโรฟิลล์และสภาพทางสรีรวิทยาของพืชมากกว่าดัชนีความเขียวทั่วไป (Sonobe et al., 2018; Kang et al., 2021) นอกจากนี้ การรวมข้อมูล Spectral Bands ของ Sentinel-2 ร่วมกับข้อมูล SAR จาก Sentinel-1 และดัชนีพืชพรรณ ยังช่วยเพิ่มศักยภาพในการแยกแยะประเภทพื้นที่ได้อย่างครอบคลุม โดยเฉพาะดัชนีกลุ่มคลื่นขอบแดงที่มีบทบาทสำคัญต่อการเพิ่มความแม่นยำของแบบจำลองด้านป่าไม้และพืชเกษตร (Bantchina and Gündoğdu, 2024) สอดคล้องกับ Suwanlee et al. (2025) และ Som-ard et al. (2025a) ที่รายงานว่า การบูรณาการข้อมูลหลายเซนเซอร์ช่วยเพิ่มความแม่นยำในการจำแนกพืชเกษตรในภาคตะวันออกเฉียงเหนือของไทย อย่างไรก็ตาม การศึกษาครั้งนี้ยังมีข้อจำกัด

จากการใช้ข้อมูลเพียงช่วงเวลาเดียวและจำนวนข้อมูลรายแปลงค่อนข้างจำกัด ทำให้ไม่สามารถสะท้อนความแตกต่างของระยะการเจริญเติบโตของอ้อยได้อย่างครบถ้วน เมื่อเปรียบเทียบกับ Som-ard et al. (2025a) ที่ใช้ข้อมูลหลายช่วงเวลาและข้อมูลรายแปลงจำนวนมาก ซึ่งมีส่วนช่วยเพิ่มความแม่นยำของการจำแนกได้มากยิ่งขึ้น

ผลการจำแนกข้อมูลหลายรูปแบบแสดงให้เห็นว่าการบูรณาการข้อมูลจากหลายเซนเซอร์สามารถช่วยเพิ่มประสิทธิภาพในการจำแนกพื้นที่ปลูกอ้อยได้อย่างชัดเจน โดยเฉพาะการผสานข้อมูลดัชนีพืชพรรณร่วมกับข้อมูลเรดาร์ (Vis + SAR) ซึ่งสามารถแยกขอบเขตพื้นที่ปลูกอ้อยออกจากพื้นที่เกษตรกรรมอื่นและพื้นที่ป่าไม้ได้ดีกว่าการใช้ข้อมูลจากเซนเซอร์เดียว มีประสิทธิภาพสูงสุดและเพิ่มความแม่นยำของแบบจำลองด้านป่าไม้และพืชเกษตร (Bantchina and Gündoğdu, 2024)

ทั้งนี้ เนื่องจากข้อมูลเชิงแสงเพียงอย่างเดียว เช่น RGB ยังมีข้อจำกัดด้านความคล้อยคลึงเชิงคลื่นระหว่างพื้นที่เกษตรกรรม ชุมชน และแหล่งน้ำ ขณะที่ข้อมูล SAR เพียงอย่างเดียวมีความไวต่อโครงสร้างทางกายภาพที่ใกล้เคียงกัน จึงทำให้เกิดความสับสนระหว่างพื้นที่เกษตรและป่าไม้ และไม่สามารถระบุขอบเขตแปลงได้ชัดเจน ซึ่งสอดคล้องกับ Vizzari et al. (2025) ที่รายงานว่าการใช้ข้อมูลเรดาร์เพียงประเภทเดียวมีข้อจำกัดในการแยกประเภทการใช้ที่ดินที่มีโครงสร้างคล้ายคลึงกัน นอกจากนี้ การผสานข้อมูล Vis และ SAR ยังช่วยลดความคลุมเครือเชิงคลื่นในบริเวณรอยต่อระหว่างอ้อยกับพื้นที่เกษตรกรรมอื่น เนื่องจากข้อมูล SAR สามารถสะท้อนลักษณะโครงสร้างพื้นผิวและรูปทรงของแปลงพืชได้ดีขึ้น ส่งผลให้ขอบเขตพื้นที่ปลูกอ้อยมีความคมชัดมากขึ้น ซึ่งสอดคล้องกับ Jensch et al. (2025) อย่างไรก็ตาม ยังพบข้อจำกัดด้านการจำแนกผิดพลาดระหว่างอ้อยกับพืชไร่อื่น โดยเฉพาะในช่วงต้นฤดูปลูกที่อ้อยยังมีลักษณะการสะท้อนคลื่นใกล้เคียงกับพืชชนิดอื่น สอดคล้องกับ Som-ard et al. (2025a) ที่ระบุว่าความคลาดเคลื่อนส่วนใหญ่มักเกิดขึ้นในช่วงรอยต่อของฤดูกาลเพาะปลูก โดยเฉพาะในพื้นที่เกษตรกรรมที่มีการใช้ที่ดินหลากหลายประเภทในประเทศไทย เมื่อเปรียบเทียบกับงานของ Som-ard et al. (2025b) ซึ่งใช้ข้อมูลหลายเซนเซอร์หลายช่วงเวลาร่วมกับอัลกอริทึม RF เพื่อจำแนกพืชเกษตรหลายชนิดในจังหวัดชัยภูมิ พบว่าผลการศึกษาดังนี้ยังสามารถให้ความแม่นยำในระดับใกล้เคียงกัน แม้จะใช้ข้อมูลเพียงช่วงเวลาเดียวและจำนวนจุดอ้างอิงที่จำกัด สะท้อนให้เห็นว่าดัชนีกลุ่มคลื่นขอบแดงมีศักยภาพในการช่วยชดเชยข้อจำกัดด้านข้อมูลหลายช่วงเวลาได้บางส่วน ทั้งนี้ ในอนาคตควรมีการวิเคราะห์รูปแบบ Misclassification เชิงพื้นที่เพิ่มเติมในบริบทการใช้ที่ดินที่หลากหลาย เช่น บริเวณรอยต่อระหว่างอ้อยกับนาข้าวหรือพื้นที่ป่าไม้ เพื่อพัฒนาแนวทางการจำแนกที่มีความแม่นยำและเสถียรมากยิ่งขึ้น

การศึกษาในอนาคตควรพิจารณาใช้ข้อมูลหลายช่วงเวลาเพื่อจับความแตกต่างของชีพลัทธิอ้อยในแต่ละระยะการเจริญเติบโต เช่น วิธีการหอนุพันธ์การบิดเบือนเวลาแบบไดนามิก (Derivative Dynamic Time Warping: DDTW) (Ye et al., 2023) นอกจากนี้ควรดำเนินการวิเคราะห์ Feature Importance จากแบบจำลองโดยตรง เพื่อยืนยันบทบาทของแต่ละช่วงคลื่นในเชิงปริมาณและระบุได้อย่างแม่นยำว่าดัชนีใดมีอิทธิพลสูงสุดต่อการจำแนกพื้นที่ปลูกอ้อย นอกจากนี้ควรพิจารณาใช้ Edge-preserving filter เช่น Refined Lee Filter แทน Focal Mean ในการลด Speckle noise ของข้อมูล SAR เนื่องจาก Focal Mean เป็นการหาค่าเฉลี่ยในพื้นที่สี่เหลี่ยมคางหมูที่ซึ่งอาจทำให้รายละเอียดบริเวณขอบแปลงถูกลดทอน ในขณะที่ Edge-preserving Filter สามารถลด Speckle Noise ได้โดยยังคงรักษาความคมชัดของขอบเขตแปลงไว้ ส่งผลให้ความแม่นยำในการจำแนกพื้นที่ปลูกอ้อยในระดับแปลงเพิ่มขึ้น (Shamsoddini & Trinder, 2011) และควรพิจารณาคัดเลือกภาพถ่ายดาวเทียม Sentinel-2 ในช่วงเดือนพฤศจิกายนซึ่งเป็นช่วงที่อ้อยมีการเจริญเติบโตสูงสุด หากสภาพอากาศเอื้ออำนวยและมีภาพที่ผ่านเกณฑ์เมฆปกคลุมน้อยกว่าร้อยละ 10 เพื่อให้ข้อมูลสะท้อนสภาพพืชพรรณในระยะที่มีความแตกต่างเชิงคลื่นชัดเจนที่สุด หรืออาจพิจารณาใช้ข้อมูลจากดาวเทียมที่มีความละเอียดเชิงเวลาสูงและมีช่วงคลื่นที่หลากหลายมากขึ้น เพื่อเพิ่มโอกาสในการได้ภาพปลอดเมฆในช่วงฤดูมรสุม และช่วยขยายขอบเขตการวิเคราะห์ลักษณะทางสรีรวิทยาและการเจริญเติบโตของอ้อยได้ครอบคลุมยิ่งขึ้น นอกจากนี้ควรออกแบบการเก็บข้อมูลภาคสนามให้สอดคล้องกับวันบันทึกภาพถ่ายดาวเทียมในช่วงเวลา

ใกล้เคียงกันมากที่สุด เพื่อลดความคลาดเคลื่อนเชิงเวลาระหว่างข้อมูลอ้างอิงภาคสนามและภาพถ่ายดาวเทียม ซึ่งจะช่วยเพิ่มความน่าเชื่อถือของการประเมินความถูกต้องและสะท้อนสภาพพื้นที่จริง ณ วันที่บันทึกข้อมูลได้อย่างแม่นยำยิ่งขึ้น

Conclusion

การศึกษานี้แสดงให้เห็นว่าการบูรณาการข้อมูลดาวเทียม Sentinel-1 และ Sentinel-2 จำนวน 21 features ร่วมกับอัลกอริทึมป่าสุ่มบนแพลตฟอร์ม Google Earth Engine สามารถจำแนกพื้นที่ปลูกอ้อยในอำเภอภูเขียว จังหวัดชัยภูมิ ได้อย่างมีประสิทธิภาพ โดยชุดข้อมูลที่บูรณาการดัชนีพืชพรรณกลุ่มคลื่นขอบแดง (Red-edge) ร่วมกับข้อมูลเรดาร์ (Vis + SAR) ให้ค่าความถูกต้องโดยรวมสูงสุดที่ 88.50% ค่า Kappa 81.90% และค่าความถูกต้องของผู้ผลิตสำหรับพื้นที่ปลูกอ้อยที่ 94.0% ผลลัพธ์ดังกล่าวยืนยันว่าดัชนีกลุ่มคลื่นขอบแดงมีบทบาทสำคัญในการลดความสับสนเชิงคลื่นระหว่างอ้อยกับพืชพรรณประเภทอื่น อันเนื่องมาจากความไวสูงต่อปริมาณคลอโรฟิลล์ในระดับเซลล์พืชที่ดัชนีความเขียวทั่วไปไม่สามารถตรวจวัดได้ในระดับเดียวกัน อย่างไรก็ตาม การศึกษานี้มีข้อจำกัดในด้านการจำแนกเชิงเวลา เนื่องจากใช้ข้อมูลภาพถ่ายเพียงช่วงเวลาเดียว ซึ่งอาจไม่เพียงพอในการระบุระยะการเจริญเติบโตและอายุของอ้อยในแต่ละแปลงได้อย่างแม่นยำ รวมถึงความคลาดเคลื่อนเชิงเวลาระหว่างการเก็บข้อมูลภาคสนามและวันถ่ายภาพดาวเทียมที่อาจส่งผลกระทบต่อความสอดคล้องของข้อมูลอ้างอิง ข้อค้นพบจากการศึกษานี้เป็นประโยชน์สำหรับหน่วยงานที่เกี่ยวข้องในการนำไปประยุกต์ใช้เป็นต้นแบบสำหรับการติดตามพื้นที่ปลูกอ้อยในระดับอำเภอ เพื่อสนับสนุนการวางแผนการผลิต การบริหารจัดการโรงงานน้ำตาล และการทำเกษตรแม่นยำในระดับประเทศต่อไป

Reference

- Ayhan, B., & Kwan, C. (2020). Tree, shrub, and grass classification using only RGB images. *Remote Sensing*, 12(8), 1333. Form <https://doi.org/10.3390/rs12081333>
- Badruzzaman, A., Wulandari, P., Sainal, S., Ashley, M., Jobling, S., Austen, M. C., & Praptiwi, R. A. (2025). Satellite imagery pre-processing and feature extraction for the mapping of coastal ecosystems using Google Earth Engine: A workflow for practitioners. *MethodsX*, 103516. Form <https://doi.org/10.1016/j.mex.2025.103516>
- Bantchina, B. B., & Gündoğdu, K. S. (2024). Crop type classification using Sentinel 2A-derived normalized difference red edge index (NDRE) and machine learning approach. *Bursa Uludağ Üniversitesi Ziraat Fakültesi Dergisi*, 38(1), 89–105.
- Chabalala, Y., Adam, E., & Ali, K. A. (2022). Machine learning classification of fused Sentinel-1 and Sentinel-2 image data towards mapping fruit plantations in highly heterogenous landscapes. *Remote Sensing*, 14(11), 2621. Form <https://doi.org/10.3390/rs14112621>
- Dagne, S. S., Hirpha, H. H., Tekoye, A. T., Dessie, Y. B., & Endeshaw, A. A. (2023). Fusion of Sentinel-1 SAR and Sentinel-2 MSI data for accurate urban land use-land cover classification in Gondar City, Ethiopia. *Environmental Systems Research*, 12(1), 40. Form <https://doi.org/10.1186/s40068-023-00324-5>
- De Swaef, T., Maes, W. H., Aper, J., Baert, J., Coughnon, M., Reheul, D., ... & Lootens, P. (2021). Applying RGB- and thermal-based vegetation indices from UAVs for high-throughput field phenotyping of drought tolerance in forage grasses. *Remote Sensing*, 13(1), 147. Form <https://doi.org/10.3390/rs13142702>

- Jena, J., Misra, S. R., & Tripathi, K. P. (2019). Normalized difference vegetation index (NDVI) and its role in agriculture. *Agriculture and Food: E-Newsletter*, 1(12), 387–389.
- Jensch, K., Ghazaryan, G., Ernst, S., Hostert, P., & Nendel, C. (2025). Integrating Landsat, Sentinel-2 and Sentinel-1 time series for mapping intermediate crops. *European Journal of Remote Sensing*, 58(1), 2507738. Form <https://doi.org/10.1080/22797254.2025.2507738>
- Kang, Y., Meng, Q., Liu, M., Zou, Y., & Wang, X. (2021). Crop classification based on red edge features analysis of GF-6 WFV data. *Sensors*, 21(13), 4328. Form <https://doi.org/10.3390/s21134328>
- Kareem, H. H., Attiae, M. H., & Omran, Z. A. (2023). Evaluation the soil-adjusted vegetation indices SAVI and MSAVI for Bristol city, United Kingdom using Landsat 8-OLI through geospatial technology. *Ecological Engineering & Environmental Technology*, 24. Form <https://doi.org/10.12912/27197050/169749>
- Keawtungmuang, S., Srisombat, I., & Bothisarn, W. (2017). Study of life-way of cane farm community in Bannongdindum, Phukieow District, Chaiyaphum Province. *Academic MCU Buriram Journal*, 2(2), 108–118. (in Thai)
- Kwang Jhone Subdistrict Administrative Organization. (n.d.). Economic conditions of Kwang Jhone Subdistrict, Phu Khiao District, Chaiyaphum Province. Form https://www.kwangjhong.go.th/data.php?content_id=3
- Laohapattanalert, K., Jamjamroon, K., & Kobpuleaw, L. (2016). Ethanol production from cassava pulp using diluted acid and alkaline solution pretreatment and simultaneous saccharification and fermentation. In *Proceedings of the RSU National Research Conference 2016* (p. 281). Rangsit University. (in Thai)
- Li, N., Guo, Y., Wang, L., Wang, Q., Yan, D., Zhao, S., & Lei, T. (2024). Evaluation and quantitative characterization for the ecological environment impact of open pit mining on vegetation destruction from Landsat time series: A case study of Wulishan limestone mine. *Ecological Indicators*, 158, 111371. Form <https://doi.org/10.1016/j.ecolind.2024.111371>
- Liu, M., Zhan, Y., Li, J., Kang, Y., Sun, X., Gu, X., ... & Yang, J. (2024). Validation of red-edge vegetation indices in vegetation classification in tropical monsoon region—a case study in Wenchang, Hainan, China. *Remote Sensing*, 16(11), 1865. Form <https://doi.org/10.3390/rs16101865>
- Magidi, J., Nhamo, L., Mpandeli, S., & Mabhaudhi, T. (2021). Application of the random forest classifier to map irrigated areas using Google Earth Engine. *Remote Sensing*, 13(5), 876. Form <https://doi.org/10.3390/rs13071376>
- Mitr Phol Modern Farm. (2025, August 22). Precise water management to enhance sustainable sugarcane productivity. Form <https://www.mitrpholmodernfarm.com/news/2025/08/>
- Mullissa, A., Vollrath, A., Odongo-Braun, C., Slagter, B., Balling, J., Gou, Y., Gorelick, N., & Reiche, J. (2021). Sentinel-1 SAR backscatter analysis ready data preparation in Google Earth Engine. *Remote Sensing*, 13(10), 1954. Form <https://doi.org/10.3390/rs13101954>

- Nodthaisong, C., Saengprachathanarug, K., Chea, C., Posom, J., Wongpichet, S., Konyai, S., & Wongphati, M. (2019). Feasibility study of sugarcane yield prediction using NDVI and CI red-edge indices associated with volume of digital surface model (DSM). *Khon Kaen Agriculture Journal*, 47(4), 679–694. Form <https://doi.org/10.14456/kaj.2019.65> (in Thai)
- Nsiah, R. A., Mantey, S., & Ziggah, Y. Y. (2024). Assessing the contribution of RGB VIs in improving building extraction from RGB–UAV images. *Mersin Photogrammetry Journal*, 6(1), 9–21. Form <https://doi.org/10.53093/mephoj.1399083>
- Nyamekye, C., Ghansah, B., Agyapong, E., Obuobie, E., Awuah, A., & Kwofie, S. (2021). Examining the performances of true color RGB bands from Landsat–8, Sentinel–2 and UAV as stand-alone data for mapping artisanal and small-scale mining (ASM). *Remote Sensing Applications: Society and Environment*, 24, 100655. Form <https://doi.org/10.1016/j.rsase.2021.100655>
- Office of Agricultural Research and Development Region 5. (2017). *Knowledge management: Management of sugarcane white leaf disease in the central and western regions using clean planting materials*. Department of Agriculture, Ministry of Agriculture and Cooperatives. (in Thai)
- Office of the Cane and Sugar Board. (2025). *Report on sugarcane cultivation status for the 2024/2025 production year*. Office of the Cane and Sugar Board, Ministry of Industry, Thailand. (in Thai)
- Pflumm, L., Kang, H., Wilting, A., & Niedballa, J. (n.d.). GEE–PICX: Generating cloud-free Sentinel–2 and Landsat image composites and spectral indices for custom areas and time frames—A Google Earth Engine web application. *EarthArXiv*. (preprint).
- Phan, T. N., Kuch, V., & Lehnert, L. W. (2020). Land cover classification using Google Earth Engine and random forest classifier—The role of image composition. *Remote Sensing*, 12(15), 2411. Form <https://doi.org/10.3390/rs12152411>
- Rekha, B. U., Desai, V. V., Kuri, S., Ajawan, P. S., Jha, S. K., & Patil, V. C. (2025). Field-level sugarcane yield estimation utilizing Sentinel–2 time-series and machine learning. *Indonesian Journal of Electrical Engineering and Computer Science*, 37(1), 475–487. Form [https://doi.org/10.11591/ijeecs.v37.i1.pp475–487](https://doi.org/10.11591/ijeecs.v37.i1.pp475-487)
- Ruenrom, S., Ket-ord, R., & Iamchuen, N. (2024). Multi-scenario satellite drought assessment using moisture stress index (MSI) in Mae Suk Watershed, Mae Chai District, Phayao Province. *Journal of Spatial Innovation Development (JSID)*, 5(3), 93–105. (in Thai)
- Sanchez, A., Barboza, L. A., Watson, D., & Alfaro, E. J. (2023). Machine learning techniques applied to atmospheric sciences: a systematic review. *Frontiers in Climate*, 5, 1250605.
- Selvaraj, S., Bargiel, D., Htitiou, A., & Gerighausen, H. (2024). Analyzing temporal characteristics of winter catch crops using Sentinel–1 time series. *Remote Sensing*, 16(19), 3737. Form <https://doi.org/10.3390/rs16193737>
- Shamsoddini, A., & Trinder, J. C. (2011). Edge-detection-based filter for SAR speckle noise reduction. *International Journal of Remote Sensing*, 33(8), 2296–2320. Form <https://doi.org/10.1080/01431161.2011.614286>

- Shi, L., Fan, H., Yang, L., Jiang, Y., Sun, Z., & Zhang, Y. (2023). NDVI-based spatial and temporal vegetation trends and their response to precipitation and temperature changes in the Mu Us Desert from 2000 to 2019. *Water Science & Technology*, 88(2), 430–442. Form <https://doi.org/10.2166/wst.2023.212>
- Som-ard, J., Suwanlee, S. R., Pinasu, D., Keawsomsee, S., Kasa, K., Seesanhao, N., ... & Immitzer, M. (2022). Monitoring three decades of crop type dynamics in Thailand using multi-temporal satellite imagery and random forest classifier. *Computers and Electronics in Agriculture*, 198, 107083. Form <https://doi.org/10.1016/j.compag.2022.107083>
- Som-ard, J., Suwanlee, S. R., Pinasu, D., Keawsomsee, S., Kasa, K., Seesanhao, N., ... & 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. Form <https://doi.org/10.3390/land13091481>
- Som-ard, J., Suwanlee, S. R., Keawsomsee, S., Kasa, K., Seesanhao, N., Izquierdo-Verdiguier, E., Moreno-Martínez, Á., Ninsawat, S., & Atzberger, C. (2025a). Mapping sugarcane plantations in Northeast Thailand using multi-temporal data from multi-sensors and machine-learning algorithms. *Big Earth Data*, 9(2), 187–216. Form <https://doi.org/10.1080/20964471.2025.2463730>
- Som-ard, J., Hossain, M. D., Keawsomsee, S., Suwanlee, S. R., Veerachitt, V., Heawchaiyaphum, P., Puntura, A., Izquierdo-Verdiguier, E., Immitzer, M., & Atzberger, C. (2025b). Integrating multi-temporal satellite data and machine learning approaches for crop rotation pattern mapping in Thailand. *Remote Sensing*, 17(18), 3156. Form <https://doi.org/10.3390/rs17183156>
- Sonobe, R., Sano, T., & Horie, H. (2018). Using spectral reflectance to estimate leaf chlorophyll content of tea with shading treatments. *Biosystems Engineering*, 175, 168–182. Form <https://doi.org/10.1016/j.biosystemseng.2018.09.018>
- Suwanlee, S. R., Keawsomsee, S., Izquierdo-Verdiguier, E., Moreno-Martínez, Á., Ninsawat, S., & Som-ard, J. (2025). Synergistic use of multi-sensor satellite data for mapping crop types and land cover dynamics from 2021 to 2023 in Northeast Thailand. *International Journal of Applied Earth Observation and Geoinformation*, 141, 104673. Form <https://doi.org/10.1016/j.jag.2025.104673>
- Thaicharoen, K., & Majandang, J. (2022). The development of an equation for sugarcane yield prediction using vegetation indices from Sentinel-2 satellite imagery: A case study in Chaiwan District, Udon Thani Province. *Journal of Science and Technology Mahasarakham University*, 41(6), 317–324. (in Thai)
- Tomppo, E., Ronoud, G., Antropov, O., Hytönen, H., & Praks, J. (2021). Detection of forest windstorm damages with multitemporal SAR data—A case study: Finland. *Remote Sensing*, 13(3), 383. Form <https://doi.org/10.3390/rs13020383>
- Tsuchiya, Y., & Sonobe, R. (2025). Crop classification using time-series Sentinel-1 SAR data: A comparison of LSTM, GRU, and TCN with attention. *Remote Sensing*, 17(12), 2095. Form <https://doi.org/10.3390/rs17122095>

- Vera–Esmeraldas, A., Pizarro–Oteíza, S., Labbé, M., Rojo, F., & Salazar, F. (2025). UAV–based spectral and thermal indices in precision viticulture: A review of NDVI, NDRE, SAVI, GNDVI, and CWSI. *Agronomy*, 15(11), 2569. Form <https://doi.org/10.3390/agronomy15112569>
- Vizzari, M., Antonielli, F., Bonciarelli, L., Grohmann, D., & Menconi, M. E. (2025). Urban greenery mapping using object–based classification and multi–sensor data fusion in Google Earth Engine. *Urban Forestry & Urban Greening*, 105, 128697. Form <https://doi.org/10.1016/j.ufug.2025.125697>
- Vora, A. P., Dudhagara, R. C., Kathiriya, D. R., & Pundir, R. S. (2023). Applications of Google Earth Engine for big data analytics. *The Pharma Innovation Journal*, 12(3), 2054–2062.
- Wijitthanasarn, P., & Obpaet, A. (2023). *Evaluation of harvest status in sugarcane fields in Khon Kaen Province, Thailand using Sentinel–1 SAR data*. In *Proceedings of the 28th National Convention on Civil Engineering (NCE28)*, May 24–26, 2023, Phuket, Thailand. (in Thai).
- Wolfe, J. D. (2017). *Using ENVI for agriculture research: Optical remote sensing of sugarcane development*. NV5 Geospatial Software. Form <https://www.nv5geospatialsoftware.com/Learn/Whitepapers/Whitepaper–Detail/using–envi–for–agriculture–research–optical–remote–sensing–of–sugarcane–development>
- Xu, L., Zhang, H., Wang, C., Zhang, B., & Liu, M. (2019). Crop classification based on temporal information using Sentinel–1 SAR time–series data. *Remote Sensing*, 11(1), 53. Form <https://doi.org/10.3390/rs11010053>
- Ye, J., Bao, W., Liao, C., Chen, D., & Hu, H. (2023). Corn phenology detection using the derivative dynamic time warping method and Sentinel–2 time series. *Remote Sensing*, 15(14), 3456. Form <https://doi.org/10.3390/rs15143456>
- Yuan, X., Shi, J., & Gu, L. (2023). A review of deep learning methods for semantic segmentation of remote sensing imagery. *Expert Systems with Applications*, 169, 114417.
- Zhao, C., Pan, Y., Ren, S., Gao, Y., Wu, H., & Ma, G. (2024). Accurate vegetation destruction detection using remote sensing imagery based on the three–band difference vegetation index (TBDVI) and dual–temporal detection method. *International Journal of Applied Earth Observation and Geoinformation*, 127, 103669. Form <https://doi.org/10.1016/j.jag.2024.103669>