



การพัฒนาชุดสมองกลอัจฉริยะที่เรียนรู้ด้วยตัวเอง สำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัย การผลิตอ้อยจากภาพถ่ายดาวเทียม

Development of A Self-learning Intelligent Machine For The Geographic Information System (GIS) To Classify and Diagnose Sugarcane Production From Satellite Images

สุวิน ชัยวัง¹ ขาววิทย์ ตั้งสิริวรกุล² ปิติณัตต์ ตริวงศ์³ ชัยพิพัฒน์ ศรีมณีชัย⁴ และปรีสาร รักวาทิน⁵

Suwini Chaiwang¹ Chanwit Tangsiriworakul² Peeteenut Triwong³ Chaipiput Srimechai⁴ and Preesan Rakwatin⁵

- 1 นักวิชาการอุตสาหกรรมชำนาญการพิเศษ สำนักงานคณะกรรมการอ้อยและน้ำตาลทราย กรุงเทพมหานคร
Industrial Technical Officer, Senior Professional Level, Office of The Cane and Sugar Board, Bangkok
- 2 อาจารย์ประจำ ภาควิชาเทคโนโลยีวิศวกรรมอิเล็กทรอนิกส์ วิทยาลัยเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้า พระนครเหนือ กรุงเทพมหานคร
Lecturer, Department of Electronic Engineering Technology, Industrial Technology College, King Mongkut's University of Technology North Bangkok, Bangkok
- 3 อาจารย์ประจำ ภาควิชาเทคโนโลยีวิศวกรรมเครื่องต้นกำลัง วิทยาลัยเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยเทคโนโลยีพระจอมเกล้า พระนครเหนือ กรุงเทพมหานคร
Lecturer, Department of Power Engineering Technology, Industrial Technology College, King Mongkut's University of Technology North Bangkok, Bangkok
- 4 นักวิจัย สำนักพัฒนาเทคนิคศึกษา มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ กรุงเทพมหานคร
Researcher, Institute for Technical Education Development, King Mongkut's University of Technology North Bangkok, Bangkok
- 5 ผู้อำนวยการฝ่ายส่งเสริมและสนับสนุนการพัฒนาการเกษตรสมัยใหม่ สำนักงานส่งเสริมเศรษฐกิจดิจิทัล กรุงเทพมหานคร
Director of the Department of Promotion and Support for Modern Agricultural Development, Digital Economy Promotion Agency, Bangkok

1 Corresponding Author: E-mail: bsdwin@gmail.com

Received: 10 ส.ค. 66 Revised: 2 ก.ย. 66 Accepted: 31 ต.ค. 66

DOI: 10.14416/j.ted.2025.12.009

บทคัดย่อ

อ้อยเป็นหนึ่งในพืชเศรษฐกิจที่สำคัญของประเทศไทย สร้างรายได้ให้ผลิตภัณฑ์มวลรวมให้แก่ประเทศประมาณปีละ 200,000 ล้านบาท อย่างไรก็ตาม อุตสาหกรรมอ้อยและน้ำตาลยังประสบปัญหาอยู่หลายประการ ที่สำคัญคือปัญหาด้านการผลิตที่มีความไม่แน่นอนของปริมาณผลผลิตในแต่ละปี การศึกษาครั้งนี้มีวัตถุประสงค์เพื่อพัฒนาชุดสมองกลอัจฉริยะสำหรับระบบภูมิสารสนเทศสำหรับ 1) จำแนกพื้นที่เพาะปลูกอ้อย และ 2) คาดการณ์ผลผลิตอ้อย การจำแนกจะใช้ภาพถ่ายจากดาวเทียม



บทความวิจัย

การพัฒนาชุดสมองกลอัจฉริยะที่เรียนรู้ด้วยตัวเองสำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการผลิตอ้อยจากภาพถ่ายดาวเทียม

Landsat 9 และ Sentinel-1A ร่วมกับอัลกอริทึมปัญญาประดิษฐ์จำนวน 3 อัลกอริทึม ได้แก่ โครงข่ายประสาทเทียม ป่าสุ่ม และ เกรเดียนต์บูสต์ ในส่วนการคาดการณ์จะใช้ข้อมูลดัชนีพืชพรรณจำนวน 4 ดัชนี ซึ่งสกัดจากข้อมูลภาพถ่ายจากดาวเทียม Landsat 8 และข้อมูลสำรวจผลผลิตภาคสนามร่วมกับอัลกอริทึมปัญญาประดิษฐ์แบบถดถอยจำนวน 5 อัลกอริทึม ได้แก่ การถดถอยเชิงเส้นแบบพหุ ข่ายประสาทเทียม ต้นไม้ตัดสินใจ ป่าสุ่ม และเกาส์เซียน โพรเซส

ผลการจำแนกพบว่าอัลกอริทึมป่าสุ่มให้ประสิทธิภาพในการจำแนกสูงที่สุด โดยมีค่าความถูกต้องโดยรวม 0.76 และความถูกต้องรายคลาสที่ 0.89 ผลจากการคาดการณ์ผลผลิตพบว่าอัลกอริทึมป่าสุ่มให้ประสิทธิภาพในการคาดการณ์สูงที่สุด โดยมีค่าสัมประสิทธิ์การตัดสินใจอยู่ที่ 0.79 และค่าคลาดเคลื่อนเฉลี่ยอยู่ที่ 0.79 ในการประยุกต์ปัญญาประดิษฐ์จำเป็นต้องพิจารณาข้อมูลนำเข้าและการทดสอบไฮเปอร์พารามิเตอร์ให้มีความเหมาะสมเพื่อให้การทำงานมีประสิทธิภาพสูงที่สุด

คำสำคัญ: อ้อย การจำแนกประเภท การทำนายผลผลิต การเรียนรู้ของเครื่อง การสำรวจระยะไกล

Abstract

Sugarcane is an essential economic cultivation of Thailand, obtaining a GDP of approximately 200,000 million Baths annually. However, the sugarcane industry has many crises, especially sugarcane yield and production fluctuations. This project aims to develop a self-learning intelligence kit for a geographic information system to 1) classify the sugarcane area and 2) forecast sugarcane's yield. The location is in Sa Kaew Province. In the classification, Landsat 9 image and Sentinel-1A are acquired and associated with three AI algorithms i.e. artificial neural network, random forest, and gradient boosting. In yield forecasting, four vegetation indices extracting from Landsat 8 imagery are incorporated with five AI regressor algorithms i.e. multiple-linear regressor, multi-layer perceptron, decision tree regressor, random forest regressor, and gaussian process regressor.

Classification result reveals that the random forest provides the highest efficiency, attaining an accuracy of 0.76. The prediction of the sugarcane class reaches 0.89. Yield forecasting result reveals that the random forest regressor also provides the highest efficiency, achieving a coefficient of determination of 0.79. The mean average error reveals 0.79 ton/rai. In the application of AI, input data and hyperparameter testing should be considered for the highest efficiency of models.

Keywords: Sugarcane, Classification, Yield Prediction, Machine Learning, Remote Sensing

1. บทนำ

อ้อยเป็นหนึ่งในพืชเศรษฐกิจสำคัญของประเทศไทยที่สามารถสร้างรายได้ผลิตภัณฑ์มวลรวมให้ประเทศประมาณ 200,000 ล้านบาทต่อปี เป็นวัตถุดิบตั้งต้นของระบบอุตสาหกรรมอ้อยและน้ำตาลทราย อีกทั้งยังก่อให้เกิดอุตสาหกรรมต่อเนื่องอื่น ๆ อีกมาก ทั้งนี้ศักยภาพการผลิตและส่งออกน้ำตาลรวมถึงผลิตภัณฑ์ต่าง ๆ ที่ได้มาจากอ้อยของประเทศไทยอยู่เป็นอันดับ 2 ของโลกรองจากบราซิล และเป็นอันดับ 1 ในแถบเอเชีย-แปซิฟิก จากปัจจัยเอื้อด้านความ

เหมาะสมของพื้นที่เพาะปลูก อาทิ คุณสมบัติของดินและสภาพอากาศ แต่ทั้งนี้อุตสาหกรรมอ้อยและน้ำตาลของไทยก็ยังคงประสบกับปัญหาในด้านต่าง ๆ ในปัจจุบัน อาทิ ปัญหาด้านการผลิตที่มีปริมาณผลผลิตไม่แน่นอนในแต่ละปี ต้นทุนในการผลิตสูง ขาดการวิจัยพันธุ์อ้อยที่เหมาะสม การวิจัยโรคและศัตรูอ้อย ขาดการกำหนดเขตเศรษฐกิจและจดทะเบียนผู้ปลูกอ้อย การบริหารจัดการขนอ้อยและการกำหนดราคาอ้อยขั้นต้นยังไม่เกิดแรงจูงใจ ปัญหาด้านการค้า รวมถึงพื้นที่ปลูกอ้อยลดลงจากปีที่ผ่านมา เป็นต้น การจำแนกพื้นที่เพื่อ



วางแผนการจัดการทรัพยากรอ้อยและการคาดการณ์ผลผลิตอ้อยอย่างแม่นยำและทันการณ์ถือเป็นปัจจัยหนึ่งที่มีนัยสำคัญในการแก้ต้นตอของปัญหาที่กล่าวมาข้างต้น (Root Cause) ซึ่งมีแนวทางมากมายในการคาดการณ์ผลผลิตอ้อยที่มีทั้งข้อดีและข้อเสียแตกต่างกันไป

การประยุกต์ใช้เทคโนโลยีด้านการสำรวจระยะไกล (Remote Sensing, RS) ร่วมกับเทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence, AI) เป็นหนึ่งในเครื่องมือทางระบบภูมิสารสนเทศ ภูมิศาสตร์ (Geographic Information System, GIS) ซึ่งถูกนำมาใช้ในการศึกษาเรื่องที่เกี่ยวข้องอย่างแพร่หลาย [1] จากความสามารถในการประเมินพื้นที่เพาะปลูกได้อย่างมีประสิทธิภาพและทันทั่วถึง รวมถึงสามารถคาดการณ์ผลผลิตในพื้นที่กว้างและใช้ต้นทุนต่ำ ให้ข้อมูลการตัดสินใจเชิงนโยบายที่เป็นประโยชน์ได้อย่างแท้จริง [2] ในด้านการจำแนกพื้นที่เพาะปลูกอ้อย ภาพถ่ายจากดาวเทียมหลากหลายประเภททั้งรายละเอียดปานกลางจนถึงรายละเอียดสูง ได้ถูกนำมาใช้จำแนกพื้นที่เพาะปลูกอ้อยร่วมกับอัลกอริทึมทั้งแบบมาตรฐานจนถึง ML ที่สามารถช่วยปรับปรุงให้ ความถูกต้องในการจำแนกพื้นที่เพาะปลูกอ้อยเพิ่มสูงขึ้น และมีแนวโน้มที่จะถูกนำมาใช้เป็นมาตรฐานในงานด้านการจำแนก วิธีการจำแนกแบบจุดภาพและแบบเชิงวัตถุได้ถูกนำมาประยุกต์กับการจำแนกพื้นที่ปลูกอ้อยและให้ผลลัพธ์เป็นที่น่าพอใจทั้งสองวิธี [3], [4], [5] อย่างไรก็ตามวิธีการจำแนกแบบเชิงวัตถุจะให้ประสิทธิภาพสูงที่สุดเมื่อนำมาประยุกต์กับข้อมูลการสำรวจระยะไกลที่มีความละเอียดสูงหรือข้อมูลจากอากาศยานไร้คนขับ [6] ในขณะที่การใช้ภาพถ่ายจากดาวเทียมรายละเอียดปานกลาง (เช่น Sentinel และ Landsat) นั้นวิธีการจำแนกเชิงจุดภาพยังคงให้ความถูกต้องอยู่ในระดับที่น่าพอใจ [7], [8] นอกจากนี้การพัฒนาการถ่ายภาพของดาวเทียมก็มีแนวโน้มที่จะได้ข้อมูลได้รวดเร็วขึ้น เช่น ดาวเทียม Sentinel 2 ซึ่งมีจำนวน 2 ดวงในระบบสามารถให้ภาพถ่ายของพื้นที่เดิมได้ทุก 5 วัน ในขณะที่ดาวเทียม Landsat-8 เก็บข้อมูลพื้นที่เดิมได้ทุก 16 วัน [9] ซึ่งเป็นประโยชน์สำหรับการติดตามการเจริญเติบโตเพื่อสร้างลักษณะชีพลักษณะ (Phenology) ของอ้อยและนำมาช่วยในการจำแนกพื้นที่เพาะปลูกในลักษณะของข้อมูลอนุกรมเวลา [5]

พื้นฐานในการจำแนกพื้นที่เพาะปลูกอ้อยด้วยข้อมูลการสำรวจระยะไกลใช้ลักษณะการสะท้อนของคลื่นแม่เหล็กไฟฟ้าที่มีลักษณะเฉพาะ ลักษณะเชิงพื้นที่และชีพลักษณะของการเจริญเติบโตในพืชที่มีลักษณะแตกต่างกันไปตามแต่ละชนิด โดยวิธีการจำแนกมีอยู่สองประเภทหลัก ได้แก่ การจำแนกแบบไม่กำกับดูแลและการจำแนกแบบกำกับดูแล จากการทบทวนวรรณกรรมพบว่าแนวโน้มการใช้วิธีการจำแนกในช่วงห้าปีที่ผ่านมานิยมนำอัลกอริทึม ML มาใช้จำแนกพื้นที่เพาะปลูกพืชเนื่องจากเป็นวิธีการที่ให้ความถูกต้องสูงกว่าวิธีการจำแนกแบบมาตรฐาน (เช่น ความน่าจะเป็นสูงสุด) อย่างมีนัยสำคัญ [10] อัลกอริทึม ML ที่นิยมนำมาใช้ในการจำแนกพื้นที่เพาะปลูกอ้อยหลัก ๆ เป็น Ensemble Machine Learning Method ได้แก่ ช่วยประสาทเทียม (ANN) ป่าสุ่ม (RF) ต้นไม้ตัดสินใจ (CART) และซัพพอร์ตเวกเตอร์แมชชีน (SVM) โดยนิยมดำเนินการจำแนกเพื่อตรวจสอบหาวิธีที่มีประสิทธิภาพสูงสุด [3], [5] ซึ่งในการศึกษาส่วนใหญ่ได้ข้อสรุปว่าวิธีการจำแนกด้วย RF เป็นวิธีที่มีประสิทธิภาพและให้ค่าความถูกต้องในการจำแนกพื้นที่เพาะปลูกอ้อยสูงกว่าวิธีการจำแนกประเภทอื่น [7], [8], [11] นอกจากนี้ยังมีการนำช่วยประสาทคอนโวลูชัน ซึ่งเป็นการเรียนรู้เชิงลึกเข้ามาช่วยจำแนกพื้นที่เพาะปลูกอ้อย [12], [13], [14] ซึ่งให้ประสิทธิภาพในการจำแนกสูง อย่างไรก็ตามการสร้างระบบ การสอน และการปรับจูนไฮเปอร์พารามิเตอร์ของโครงข่ายมีความยุ่งยากและใช้เวลานาน

2. วัตถุประสงค์การวิจัย

2.1 เพื่อพัฒนาชุดสมองกลอัจฉริยะที่สามารถเรียนรู้ด้วยตัวเองสำหรับ GIS ในการจำแนกและวินิจฉัยการเพิ่มผลผลิตอ้อยอย่างเหมาะสม

2.2 เพื่อให้ได้โครงสร้างฐานข้อมูลที่เกี่ยวข้องกับอุตสาหกรรมอ้อยและน้ำตาลทรายที่มีความหลากหลาย ครอบคลุมสนับสนุนการตัดสินใจของผู้บริหารอย่างมีประสิทธิภาพและทันการณ์



บทความวิจัย

การพัฒนาชุดสมองกลอัจฉริยะที่เรียนรู้ด้วยตัวเองสำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการพลัดอ้อยจากภาพถ่ายดาวเทียม

3. สมมติฐานการวิจัย

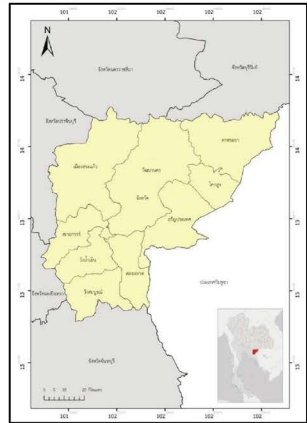
การพัฒนาชุดสมองกลอัจฉริยะที่สามารถเรียนรู้ด้วยตัวเอง สำหรับ GIS ในการจำแนกและวินิจฉัยการเพิ่มผลผลิตอ้อย อย่างเหมาะสม ต้องมีค่าอัลกอริทึมที่ประสิทธิภาพในการ จำแนกจากมีค่าความถูกต้องโดยรวมไม่ต่ำกว่าร้อยละ 70 และความถูกต้องรายคลาสที่ไม่ต่ำกว่าร้อยละ 70

4. วิธีการดำเนินการวิจัย

นำเสนอกระบวนการในการดำเนินการวิจัย อธิบายลักษณะ ของนวัตกรรมที่นำมาใช้ในการวิจัย อธิบายขั้นตอนและ รายละเอียดการสร้างและพัฒนานวัตกรรม อธิบายวิธีการหา คุณภาพก่อนนำนวัตกรรมไปใช้จริง

4.1 พื้นที่ศึกษา จังหวัดสระแก้ว ตั้งอยู่ทางภาคตะวันออก ของประเทศไทย (13.7968° N, 102.1385° E) ภาพที่ 1 ครอบคลุมเนื้อที่ 7,200 ตารางกิโลเมตร โดยประมาณ สามารถแบ่งออกเป็น 9 อำเภอ ตามระบบเขตการปกครอง ของประเทศ ได้แก่ อำเภอเมืองสระแก้ว อรัญประเทศ วัฒนานคร วังน้ำเย็น วังสมบูรณ์ คลองหาด ตาพระยา เขาคันทรง และโคกสูง ลักษณะภูมิประเทศของจังหวัดโดยรวมเป็นพื้นที่ ราบสูงและมีภูเขาสูงสลับซับซ้อน ซึ่งมีความสูงเหนือระดับน้ำ ทะเลประมาณ 74 เมตร โดยมีลุ่มน้ำปราจีนบุรี และลุ่มน้ำ โตนเลสาป เป็นลุ่มน้ำหลักที่สำคัญของจังหวัด เมื่อจำแนก ตามระบบแบ่งเขตภูมิอากาศของเคิปปิน (Köppen climate classification) จังหวัดสระแก้วจัดอยู่ในเขตภูมิอากาศแบบ ทุ่งหญ้าสะวันนา (Aw) โดยมีอุณหภูมิเฉลี่ยตลอดทั้งปี 27.70 องศาเซลเซียสและปริมาณน้ำฝนรวมในพื้นที่ของ จังหวัดส่วนใหญ่มากกว่า 1,200 มิลลิเมตรต่อปี

สภาพการใช้ที่ดินของจังหวัดล้วนเป็นพื้นที่เกษตรกรรม (67.59%) โดยมีข้าว อ้อยโรงงาน มันสำปะหลังและยางพารา เป็นพืชเศรษฐกิจหลักของจังหวัด ส่วนการใช้ประโยชน์ที่ดิน ประเภทอื่นรองลงมา ได้แก่ พื้นที่ป่าไม้ พื้นที่ชุมชนและ สิ่งปลูกสร้าง แหล่งน้ำและเบ็ดเตล็ด คิดเป็นร้อยละ 23.37 2.02 และ 1.26 ของพื้นที่จังหวัด ตามลำดับ



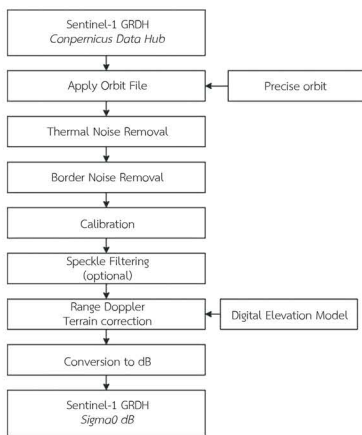
ภาพที่ 1 พื้นที่ศึกษาจังหวัดสระแก้ว

4.2 การเข้าถึงข้อมูลภาพถ่ายจากดาวเทียม Landsat 8/9 Sentinel-1 และข้อมูลอื่น ๆ ที่เกี่ยวข้อง โดยการเขียน จาวาสคริปต์เรียกใช้และประมวลผลข้อมูลภาพถ่ายจาก ดาวเทียมเบื้องต้น (Pre-processing) ของกลุ่มผลิตภัณฑ์ Landsat และ Sentinel จากฐานข้อมูลให้บริการ โดยแพลตฟอร์ม Google Earth Engine (GEE) ใช้ชุดข้อมูล Landsat 9 โดยเลือกภาพที่แสดงรายละเอียดของพื้นที่ เพาะปลูกอ้อยได้ชัดเจนที่สุด (อ้อยระยะเจริญเติบโตเต็มที่ -พร้อมสำหรับเก็บเกี่ยว) หรือใกล้เคียงวันเปิดหีบอ้อย โดยปีการผลิต พ.ศ. 2564/2565 เริ่มวันที่ 7 ธันวาคม พ.ศ. 2564 เป็นต้น และชุดข้อมูล Sentinel-1 ช่วงสัญญาณคลื่น (Polarization) แบบ VV รายเดือน จำนวน 12 เดือนในปี พ.ศ. 2564 (มกราคม-ธันวาคม) สำหรับการศึกษาการจำแนก พื้นที่เพาะปลูกอ้อย และใช้ชุดข้อมูลดาวเทียม Landsat 8 ระยะเวลาดำเนินการ 1 ปี ตั้งแต่เดือนมกราคม 2564 ถึง เดือนธันวาคม 2564 สำหรับการศึกษาการคาดการณ์ผลผลิตอ้อย ครอบคลุม พื้นที่ศึกษาจังหวัดสระแก้ว

ชุดข้อมูล Landsat collection 2 level-2 ของ ผลิตภัณฑ์ Landsat 8/9 เป็นข้อมูลภาพถ่ายจากดาวเทียม ที่ได้รับการประมวลผลในขั้นที่ 2 กล่าวคือ ได้รับการปรับแก้เชิงเรขาคณิต (Geometric Correction) และการปรับแก้ ความคลาดเคลื่อนจากสิ่งรบกวนในชั้นบรรยากาศ (Atmospheric Correction) ทำให้สามารถนำข้อมูลดังกล่าว เข้าสู่การประมวลผลขั้นตอนถัดไปได้ทันทีโดยไม่ต้องปรับแก้

ความคลาดเคลื่อนในภาพถ่ายจากดาวเทียม และกำหนดเงื่อนไขเพื่อกรองข้อมูลภาพถ่ายที่มีเมฆปกคลุมน้อยกว่าร้อยละ 20

รหัสข้อมูล COPERNICUS/S1_GRD ถูกใช้เพื่อเข้าถึงข้อมูลภาพถ่ายจากดาวเทียมระบบเรดาร์ (SAR) Sentinel-1 GRD เป็นชุดข้อมูลที่ถูกปรับแก้เบื้องต้นให้อยู่ในหน่วยเดซิเบล (dB) ซึ่งผ่านการปรับแก้ข้อมูลวงโคจร (Apply Orbit File) และขจัดค่าความคลาดเคลื่อนเชิงตำแหน่งที่เกิดขึ้นขณะทำการบันทึกภาพด้วยเทคนิคต่าง ๆ โดยสามารถแสดงกระบวนการปรับแก้เบื้องต้นเป็นแผนภาพ ดังภาพที่ 2



ภาพที่ 2 แผนภาพกระบวนการปรับแก้ข้อมูลภาพถ่าย Sentinel-1 SAR GRD เบื้องต้น จากผู้ให้บริการข้อมูล

ข้อมูลจากภาพตั้งต้นถูกนำค่าคลาดเคลื่อนและข้อมูลที่ไม่มีค่าออกจากภาพ (GRD-Border-Noise and Thermal Noise Removal) จากนั้นปรับค่าคลาดเคลื่อนบริเวณรอยต่อของภาพ เนื่องจากใช้ข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1 มากกว่าสองภาพติดต่อกัน เพื่อให้ครอบคลุมพื้นที่ศึกษา และทำการปรับค่าการกระจายพลังงานกลับ (Backscatter) โดยใช้ค่าพารามิเตอร์ปรับแก้จากเซนเซอร์ซึ่งได้จากข้อมูล GRD (Application of Radiometric Calibration Values) เพื่อส่งข้อมูลไปปรับแก้ค่าคลาดเคลื่อนความสูงที่เกิดจากภูมิประเทศและมุมมองการถ่ายภาพ (Terrain Correction) ด้วยข้อมูลความสูงเชิงเลข (DEM) ในลำดับสุดท้าย การศึกษาวิจัยครั้งนี้ใช้ข้อมูลภาพถ่ายจากดาวเทียมร่วมกับข้อมูลสำรวจ

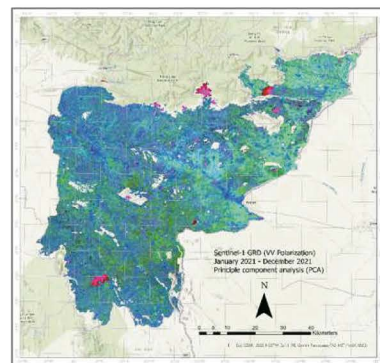
ภาคสนามของผลผลิตข้อมูลเบื้องต้น (ต้นต่อไร่) ในพื้นที่ศึกษา ประจำปี พ.ศ. 2564

4.3 การประมวลผลข้อมูลเบื้องต้นสำหรับการจำแนกพื้นที่เพาะปลูกอ้อย

4.3.1 ภาพถ่ายจากดาวเทียม Landsat 9 เพื่อให้เกิดประสิทธิภาพสูงสุดสำหรับการจำแนก การเน้นข้อมูลคุณภาพเชิงช่วงคลื่นด้วยวิธีดัชนีพืชพรรณแบบผลต่างนอมอลไลซ์ (Normalized Difference Vegetation Index, NDVI) ได้ถูกประยุกต์ใช้สำหรับการศึกษาวิจัยครั้งนี้ ซึ่งเป็นเทคนิคที่ถูกนำมาใช้อย่างแพร่หลายในการศึกษาที่เกี่ยวข้อง อาทิ การจำแนกและติดตามการเจริญเติบโตของพื้นที่ที่เกี่ยวข้องทางด้านเกษตรกรรม [15] สามารถสกัดจากข้อมูลภาพถ่ายจากดาวเทียม Landsat 9 ดังสมการที่ 1 โดย NIR คือ แบนด์ที่ 5 ช่วงคลื่นอินฟราเรดใกล้ (Near Infrared) และ R คือ แบนด์ที่ 4 ช่วงคลื่นสีแดง (Red)

$$NDVI = \frac{NIR - R}{NIR + R} \quad (1)$$

4.3.2 ภาพถ่ายจากดาวเทียม Sentinel-1 ทำการปรับความละเอียดเชิงจุดภาพ (Resampling) ให้มีความละเอียดเชิงจุดภาพ 50 ตารางเมตร จากเดิม 10 ตารางเมตร และใช้ฟิลเตอร์ลี (Lee-filter) ขนาด 7x7 ตารางเมตร ในการปรับลดจุดการสะท้อนรบกวน (Noise) ที่อยู่ภายในภาพ แล้วทำการลดมิติข้อมูลให้เหลือเพียง 4 ชั้นข้อมูล ด้วยเทคนิคการวิเคราะห์องค์ประกอบหลัก (Principal Component Analysis, PCA) ตัวอย่างผลลัพธ์แสดงดังภาพที่ 3



ภาพที่ 3 ภาพถ่ายจากดาวเทียม Sentinel-1 บริเวณจังหวัดสระแก้ว ที่ผ่านกระบวนการ PCA



บทควาณวิจัย

การพัฒนาชุดสมรรถนะการวิจัยที่เรียนรู้ด้วยตัวเองสำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการพลัดออกจากภาพถ่ายดาวเทียม

4.4 การประมวลผลเบื้องต้นสำหรับการคาดการณ์ผลผลิตอ้อยในประเทศไทยได้มีการนำดัชนีพืชพรรณมาประกอบการจำแนกพื้นที่เพาะปลูกอ้อยร่วมกับภาพถ่ายจากดาวเทียม Landsat 8 และ Sentinel 2 โดยใช้อัลกอริทึม ML เป็นตัวจำแนก [16] ซึ่งผลการจำแนกที่ได้แสดงมีความถูกต้องสูงที่สุดในชุดข้อมูลที่มีดัชนีพืชพรรณรวมอยู่ และยังสามารถนำไปใช้เป็นข้อมูลประกอบการคาดการณ์ผลผลิตของอ้อยซึ่งช่วยให้สามารถประเมินผลผลิตได้มีความแม่นยำมากยิ่งขึ้น [17] การศึกษาครั้งนี้ใช้วิธีปรับเน้นข้อมูลภาพเชิงช่วงคลื่น (Spectral Enhancement) ในแต่ละชุดข้อมูล ด้วยวิธีดัชนีพืชพรรณ (Vegetation Index) ประกอบด้วย ดัชนีพืชพรรณแบบผลต่างแบบนอมอลไลซ์ (Normalized Difference Vegetation Index, NDVI) ดัชนีพืชพรรณแบบผลต่างช่วงคลื่นแสงสีเขียวแบบนอมอลไลซ์ (Green Normalized Difference Vegetation Index, GNDVI) ดัชนีพืชพรรณแบบปรับแก้ดิน (Soil-Adjusted Vegetation Index, SAVI) และดัชนีเน้นภาพพืชพรรณ (Enhance Vegetation Index, EVI) ดังแสดงในสมการที่ 2 ถึง 5

$$NDVI = \frac{NIR-R}{NIR+R} \quad (2)$$


$$GNDVI = \frac{NIR-G}{NIR+G} \quad (3)$$

$$SAVI = \frac{NIR-R}{NIR+R+0.5} (1 + 0.5) \quad (4)$$

$$EVI = 2.5 \times \frac{NIR-R}{NIR+(6 \times R)-(7.5 \times B)+1} \quad (5)$$

โดยที่ B คือ แบนด์ที่ 2 แสงสีน้ำเงิน (Blue) G คือ แบนด์ที่ 3 แสงสีเขียว (Green) R คือ แบนด์ที่ 4 แสงสีแดง (Red) NIR คือ แบนด์ที่ 5 อินฟราเรดใกล้ (Near Infrared) ผสมข้อมูลภาพถ่ายจากดาวเทียมต่างช่วงเวลา (Time-series Composite) ที่ผ่านกระบวนการการเน้นข้อมูลภาพแต่ละแบบ ด้วยวิธีการวัดค่ากลางของข้อมูลทางสถิติแบบค่าสูงสุด (Maximum Composite) ด้วยฟังก์ชัน ee.Reducer.max จะได้ชุดข้อมูลสำหรับวิเคราะห์และประมวลผลในขั้นถัดไป (ภาพที่ 4) สกัดข้อมูลจุดภาพในแต่ละแบนด์ตามขอบเขตของแปลงผลผลิต

ตัวอย่าง (Zonal Statistics) โดยเลือกค่าสถิติของขอบเขตแบบค่าสูงสุด (Max) เพื่อนำมาใช้สำหรับวิเคราะห์ความสัมพันธ์ระหว่างค่าการสะท้อนของจุดภาพ (Pixel) และข้อมูลผลผลิตรายแปลงในหน่วยตันต่อไร่ จากนั้นส่งออกผลลัพธ์ (Export) ในรูปแบบของข้อมูลตาราง (.csv) เพื่อใช้ค่าสถิติในการวิเคราะห์ความสัมพันธ์



ภาพที่ 4 ข้อมูลภาพถ่ายจากดาวเทียมแบนด์ MaxNDVI และ shapefile ผลผลิตอ้อยรายแปลงสำหรับประมวลผล

4.5 การจำแนกพื้นที่เพาะปลูกอ้อยแบบกำกับดูแลร่วมกับอัลกอริทึมการเรียนรู้เครื่องนำภาพที่ผ่านขั้นตอนก่อนการประมวลผล (Pre-processing) จัดทำข้อมูลสำหรับฝึกสอน (Training Data) ด้วยการสร้างกลุ่มพื้นที่สนใจ (Region of Interest, ROI) หรือ Shapefile ประเภท Polygon ร่วมกับการพิจารณาภาพถ่ายจากดาวเทียมรายละเอียดสูงและภาพถ่ายบนบก ผ่านซอฟต์แวร์ Google Earth Pro ในกรณีที่ไม่สามารถตีความผ่านภาพถ่ายที่ผ่านการประมวลผลได้อย่างแน่ชัด บนตำแหน่งภาพของแต่ละประเภทการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดินที่ได้รับการสุ่มจุดตัวอย่าง (Random Sampling) จำนวน 8 ประเภท ได้แก่ พื้นที่ปลูกอ้อย (Sugarcane) นาข้าว (Paddy field) มันสำปะหลัง (Cassava) ยางพารา (Para Rubber) ยูคาลิปตัส (Eucalyptus) ปาล์มน้ำมัน (Palm Oil) สิ่งปลูกสร้าง (Built-up Area) และแหล่งน้ำ (Water Body) แสดงดังตารางที่ 1



ตารางที่ 1 ประเภทการใช้ประโยชน์ที่ดินและสิ่งปกคลุมดิน

LULC	Landsat 8 FCC 5-4-3	Street view	LULC	Landsat 8 FCC 5-4-3	Street view
อ้อย			แหล่งน้ำ		
มันสำปะหลัง			ยางพารา		
ยูคาลิปตัส			นาข้าว		
ปาล์มน้ำมัน					

ใช้อัลกอริทึมการเรียนรู้เครื่อง (ML) 3 ชนิด ได้แก่ อัลกอริทึมโครงข่ายประสาทเทียม (Artificial Neuron Network, ANN) อัลกอริทึมป่าสุ่ม (Random Forest, RF) และอัลกอริทึมการเดียนบูสท์ (Gradient Boosting, GB) อย่างไรก็ตาม การสร้างแบบจำลองการเรียนรู้เครื่องให้มีความแม่นยำและมีประสิทธิภาพสูงสุด สามารถทำงานได้ตรงตามวัตถุประสงค์ของผู้ศึกษา จำเป็นอย่างยิ่งในการทดสอบแบบจำลอง เพื่อค้นหาไฮเปอร์พารามิเตอร์ (Hyperparameter) ที่เหมาะสมต่อการจำแนกชุดข้อมูลแต่ละชุดโดยเฉพาะ ดังนั้นจึงทำการสุ่มแบ่งชุดข้อมูลฝึกสอน (Training Data) ด้วยอัตราส่วนร้อยละ

70 และ 30 ออกเป็นชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ (Testing Data) ตามลำดับ เพื่อใช้สำหรับฝึกสอนและทดสอบแบบจำลองการจำแนกพื้นที่เพาะปลูกอ้อย

ในการศึกษาครั้งนี้ผู้วิจัยได้ใช้วิธี 10-fold cross-validation สำหรับทดสอบค่าไฮเปอร์พารามิเตอร์ที่ส่งผลต่อประสิทธิภาพของแบบจำลอง เพื่อจับคู่พารามิเตอร์ที่เหมาะสมที่สุดของแบบจำลองในแต่ละชุดข้อมูล โดยการกำหนดค่าไฮเปอร์พารามิเตอร์ในการทดสอบของแต่ละอัลกอริทึม อ้างอิงและถอดค่าจากสมการในบทของการทบทวนวรรณกรรม สามารถแสดงค่าทดสอบไฮเปอร์พารามิเตอร์ได้ดังตารางต่อไปนี้

ตารางที่ 2 ค่าการทดสอบไฮเปอร์พารามิเตอร์ของอัลกอริทึมโครงข่ายประสาทเทียม (ANN)

ชนิดของไฮเปอร์พารามิเตอร์	ค่าไฮเปอร์พารามิเตอร์สำหรับทดสอบ
Hidden layer	(100,100), (1024,1024)
Activation	TANH, RELU
Solver	SGD, ADAM
Learning rate	Constant, Adaptive



บทควาณวิจัย

การพัฒนาระบบมอนอกลอิอาณริชที่เรีณรู้ด้ว้ตัวเองสำหรัระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการพลิตอ้อยจากภาพถ่ายดาวเทียม

ตารางที่ 3 ค่าการทดสอบไฮเปอร์พารามิเตอร์ของอัลกอริทึมป่าสุ่ม (RF)

ชนิดของไฮเปอร์พารามิเตอร์	ค่าไฮเปอร์พารามิเตอร์สำหรัทดสอบ
Number of tree depth	10, 20, 50, 100, 200, 300, 400, 500, 600, 700, 800, 900, 1000
Min number of sample node	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 100, 500, 1000
Max number of trees	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 100, 500, 1000

ตารางที่ 4 ค่าการทดสอบไฮเปอร์พารามิเตอร์ของอัลกอริทึมการเคีณบูสท์ (GB)

ชนิดของไฮเปอร์พารามิเตอร์	ค่าไฮเปอร์พารามิเตอร์สำหรัทดสอบ
Number of estimators	100, 200, 300, 400, 500, 600, 700, 800, 900, 1000
Max depth	10, 20, 30, 100
Min samples split	2, 5, 10, 20, 50
Min samples leaf	1, 2, 3, 4, 5
Learning rate	0.0001, 0.05

4.6 การตรวจสอบความถูกต้องของการจำแนกนำผลการจำแนกของแต่ละแบบจำลอง เข้าสู่กระบวนการประเมินความถูกต้องของการจำแนก (Accuracy Assessment) ด้วยวิธีการสร้างเมทริกซ์ความคลาดเคลื่อน (Confusion Matrix) และค่าสัมประสิทธิ์โคเฮน แคปปา (Kohen's kappa) เพื่อทดสอบความแม่นยำของการจำแนก ระดับการยอมรับของผลการจำแนก จากนั้นนำข้อมูลที่ได้จากการตรวจสอบความถูกต้องของแต่ละผลการจำแนกมาวิเคราะห์ประสิทธิภาพของแบบจำลองในการจำแนกพื้นที่เพาะปลูกอ้อยด้วยการพิจารณาเปรียบเทียบจากค่าความถูกต้องโดยรวม (Overall Accuracy, OA) ค่าความถูกต้องในการจำแนกรายประเภท (F1-Score) และค่าคะแนนมาตรฐาน Z (Z-test) ที่ระดับความเชื่อมั่นร้อยละ 95 จัดกลุ่มผลการจำแนกจาก 8 ประเภทให้เหลือเพียง 2 ประเภท ได้แก่ (1) พื้นที่เพาะปลูกอ้อย และ (2) การใช้ประโยชน์ที่ดินอื่น ๆ จากนั้นแปลงข้อมูลภาพราสเตอร์ของพื้นที่เพาะปลูกอ้อยให้อยู่ในรูปแบบของเวกเตอร์ (Shapefile) และนำเสนอในรูปแบบของแผนที่การจำแนกพื้นที่เพาะปลูกอ้อย

4.7 การพัฒนาแบบจำลองสำหรัการคาดการณ์ผลผลิตอ้อย

นำข้อมูลซึ่งผ่านขั้นตอนก่อนการประมวลผล (Pre-processing) ป้อนเข้าสู่กระบวนการสร้างแบบจำลองคาดการณ์ผลผลิตอ้อย เพื่อวิเคราะห์ค่าความสัมพันธ์ด้วยเทคนิคการวิเคราะห์การถดถอยแบบต่าง ๆ ประกอบด้วย

- 1) การวิเคราะห์การถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression, MLR)
- 2) การเรีณรู้เชิงลึกแบบเพอร์เซ็ปตรอนหลายชั้น (Multiple Layer Perceptron, MLP)
- 3) การเรีณรู้ด้ว้อัลกอริทึมต้นไม้ตัดสินใจ (Decision Tree Regression, DTR)
- 4) การเรีณรู้ด้ว้อัลกอริทึมป่าสุ่ม (Random Forest Regression, RFR)
- 5) การวิเคราะห์การถดถอยกระบวนการเกาส์เซียน (Gaussian Process Regression, GPR) โดยเทคนิควิเคราะห์การถดถอยแบบ MLP DTR และ RFR จำเป็นต้องเข้าสู่กระบวนการทดสอบไฮเปอร์พารามิเตอร์ด้ว้วิธี 10-fold cross-validation เพื่อให้ได้ค่าไฮเปอร์พารามิเตอร์ที่เหมาะสม

ต่อชุดข้อมูลและแบบจำลอง รายละเอียดแสดงดังตารางที่ 5 ถึง 7



ตารางที่ 5 ค่าการทดสอบไฮเปอร์พารามิเตอร์ของวิธีการเรียนรู้เชิงลึกแบบเพอร์เซ็ปตรอนหลายชั้น (MLP)

ชนิดของไฮเปอร์พารามิเตอร์	ค่าไฮเปอร์พารามิเตอร์สำหรับทดสอบ
Hidden layer	(100,100), (1024,1024)
Activation	LOGISTIC, TANH, RELU
Solver	SGD, ADAM
Learning rate	Constant, Adaptive

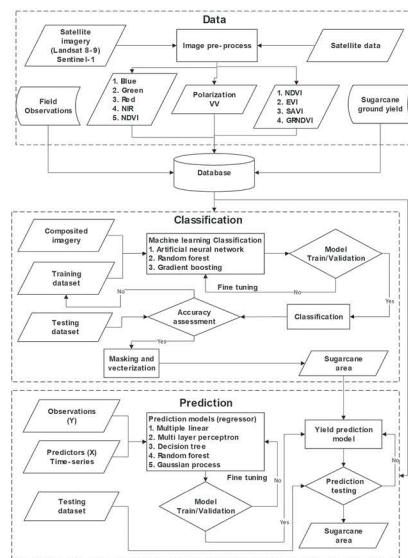
ตารางที่ 6 ค่าการทดสอบไฮเปอร์พารามิเตอร์ของอัลกอริทึมต้นไม้ตัดสินใจ (DTR)

ชนิดของไฮเปอร์พารามิเตอร์	ค่าไฮเปอร์พารามิเตอร์สำหรับทดสอบ
Max number of tree depth	30, 50, 100, 500, 1000
Min simple leaf	1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 100, 500, 1000

ตารางที่ 7 ค่าการทดสอบไฮเปอร์พารามิเตอร์ของอัลกอริทึมป่าสุ่ม (RFR)

ชนิดของไฮเปอร์พารามิเตอร์	ค่าไฮเปอร์พารามิเตอร์สำหรับทดสอบ
Number of estimators	100, 200, 300, 400, 500
Min number of sample node	1, 2, 3, 4, 5
Max number of trees depth	30, 50, 100, 500, 1000

4.8 การประเมินแบบจำลองคาดการณ์ผลผลิตอ้อย ตรวจสอบความถูกต้องของแบบจำลองการคาดการณ์ผลผลิตอ้อยโดยวัดประสิทธิภาพและเปรียบเทียบผลลัพธ์ของแบบจำลองที่มีประสิทธิภาพสูงสุดจากการทดสอบด้วยเทคนิควิเคราะห์คุณลักษณะสำคัญที่มีผลต่อแบบจำลอง (Feature Importance) และเมตริกซ์วัดประสิทธิภาพพื้นฐาน ซึ่งสามารถประเมินความแม่นยำของการทำนายกับค่าที่วัดได้จริง ได้แก่ ค่าความคลาดเคลื่อนเฉลี่ย (Mean Absolute Error, MAE) ค่ารากที่สองของค่าคลาดเคลื่อนกำลังสอง (Root Mean Square Error, RMSE) และค่าสัมประสิทธิ์แสดงการตัดสินใจ (Coefficient of Determination หรือ R-square, R^2) และนำเสนอในรูปแบบของแผนที่คาดการณ์ผลผลิตจากวัสดุอุปกรณ์และวิธีการวิจัยที่กล่าวไปข้างต้น สามารถสรุปเป็นแผนผังการทำงานวิจัยดังแสดงในภาพที่ 5



ภาพที่ 5 แผนผังการทำงานวิจัย



บทควาณวิจัย

การพัฒนาชุดสมอณการวิจัยที่เรียนรูด้ว้ตนเองสำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการพลัดอ้อยจากภาพถ่ายดาวเทียม

5. ผลการวิจัย

5.1 ผลการทดสอบไฮเพอร์พารามิเตอร์และประสิทธิภาพของแบบจำลอง

5.1.1 แบบจำลองการจำแนกพื้นที่เพาะปลูกอ้อยด้ว้ภาพถ่ายจากดาวเทียม Landsat 9 และ Sentinel-1 การทดสอบไฮเพอร์พารามิเตอร์ที่ใช้ในตัวจำแนกสำหรับการจำแนกพื้นที่เพาะปลูกอ้อย เป็นการหาชุดไฮเพอร์พารามิเตอร์ของแบบจำลองมาจัดกลุ่มเพื่อให้แบบจำลองดังกล่าวมีประสิทธิภาพในการจำแนกข้อมูลสูงที่สุดด้ว้วิธี 10-fold cross-validation เพื่อหาค่าความถูกต้องจากการจำแนกของแบบจำลองแต่ละแบบ ผลการทดสอบไฮเพอร์พารามิเตอร์ของแต่ละตัวจำแนกร่วมกับข้อมูลภาพถ่ายจากดาวเทียม Landsat 9 และ Sentinel-1 ประกอบด้วยผลการทดสอบไฮเพอร์พารามิเตอร์ของการจำแนกด้ว้ภาพถ่ายจากดาวเทียม Landsat 9 พบว่า กลุ่มไฮเพอร์พารามิเตอร์ของตัวจำแนก ANN ที่ให้ประสิทธิภาพสูงที่สุดในการจำแนก ได้แก่ activation = Relu perceptron = (1024, 1024) learning = Adaptive และ solver = Adam ตัวจำแนก RF ที่ให้ประสิทธิภาพสูงที่สุดในการจำแนก ได้แก่ maximum tree depth = 30 minimum leaf = 1 และ number of trees = 200 และตัวจำแนก GB ที่ให้ประสิทธิภาพสูงที่สุดในการจำแนก ได้แก่ learning rate = 0.05 maximum depth = 10 minimum sample leaf = 1 minimum samples split = 5 และ number of trees = 400 เมื่อทดสอบไฮเพอร์พารามิเตอร์ของการจำแนกพื้นที่เพาะปลูกอ้อยด้ว้ภาพถ่ายจากดาวเทียม Sentinel-1 พบว่า ตัวจำแนก ANN RF และ GB ให้ค่าความถูกต้องโดยรวม 0.712 0.774 และ 0.766 เมื่อใช้ค่ากลุ่มไฮเพอร์พารามิเตอร์ ประกอบด้วย ตัวจำแนก ANN ให้ค่า activation = Tanh perceptron = (100, 100) learning = Adaptive และ solver = Adam ตัวจำแนก RF ให้ค่า maximum tree depth = 2000 minimum leaf = 5 และ number of trees = 2000 และตัวจำแนก GB เมื่อให้ค่า learning rate = 0.05 maximum depth = 20 minimum sample leaf = 4 minimum samples split = 10 และ number of trees = 300

5.1.2 แบบจำลองการคาดการณ์ผลผลิตอ้อย ใช้วิธี 10-fold cross-validation เช่นเดียวกับการทดสอบไฮเพอร์พารามิเตอร์ที่ใช้ในตัวจำแนกสำหรับการจำแนกพื้นที่เพาะปลูกอ้อย เพื่อให้ได้ไฮเพอร์พารามิเตอร์ที่เหมาะสมต่อกระบวนการทำงานของแบบจำลองมากที่สุด (Best Parameters Matching) โดยแบบจำลองที่จำเป็นสำหรับการทดสอบประกอบด้วย แบบจำลองบนพื้นฐานการเรียนรู้เชิงลึกแบบเพอร์เซ็ปตรอนหลายชั้น (MLP) แบบจำลองบนพื้นฐานวิธีการเรียนรู้ด้ว้อัลกอริทึมต้นไม้ตัดสินใจ (DTR) และอัลกอริทึมป่าสุ่ม (RFR) โดยกลุ่มไฮเพอร์พารามิเตอร์ของแบบจำลอง MLP ที่ให้ประสิทธิภาพสูงที่สุดสำหรับการคาดการณ์ได้แก่ activation = Relu perceptron = (100, 100) learning = Constant และ solver = Adam แบบจำลอง DTR ได้แก่ maximum tree depth = 1,000 และ minimum leaf = 5 ในขณะที่แบบจำลอง RFR ให้ผลทดสอบค่าไฮเพอร์พารามิเตอร์ maximum tree depth = 30 minimum leaf = 5 และ number of trees = 100 ทั้งสามแบบจำลองให้ค่าความถูกต้อง (accuracy) เท่ากับ 0.874 0.941 และ 0.937 ตามลำดับ เมื่อวัดประสิทธิภาพของแบบจำลองคาดการณ์ผลผลิตบนพื้นฐานของเทคนิคการวิเคราะห์การถดถอย ได้แก่ การวิเคราะห์การถดถอยพหุคูณ (MLR) การเรียนรู้เชิงลึกแบบเพอร์เซ็ปตรอนหลายชั้น (MLP) วิธีเรียนรู้ด้ว้อัลกอริทึมต้นไม้ตัดสินใจ (DTR) อัลกอริทึมป่าสุ่ม (RFR) และการวิเคราะห์การถดถอย กระบวนการเกาส์เซียน (GPR) ด้วยเมทริกซ์พื้นฐานสำหรับทดสอบแบบจำลองเทคนิควิเคราะห์การถดถอย ประกอบด้วยค่าสัมประสิทธิ์แสดงการตัดสินใจ (R^2) ค่าความคลาดเคลื่อนเฉลี่ย (MAE) และค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสอง (RMSE)



ตารางที่ 8 ค่าเมตริกซ์พื้นฐานของแบบจำลอง

แบบจำลอง	R ²	MAE	RMSE
MLR	0.75	0.93	1.41
MLP	0.77	0.87	1.13
DTR	0.72	0.88	1.25
RFR	0.79	0.79	1.07
GPR	0.76	0.88	1.15

จากตารางที่ 8 แบบจำลอง RFR มีประสิทธิภาพสูงสุดในการคาดการณ์ผลผลิตอ้อย ให้ความแม่นยำในการคาดการณ์ร้อยละ 79 ซึ่งสูงที่สุดจากทั้งหมด 5 แบบจำลอง โดยมีความคลาดเคลื่อนในการคาดการณ์เท่ากับ 0.79 และ 1.07 ต้น/ไร่ (คำนวณจาก MAE และ RMSE ตามลำดับ) เมื่อใช้แบบจำลองดังกล่าวในการคาดการณ์ผลผลิตอ้อยในพื้นที่จังหวัดสระแก้ว

5.2 ผลการจำแนกพื้นที่เพาะปลูกอ้อย

5.2.1 ความถูกต้องของการจำแนกพื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้วด้วยภาพถ่ายจากดาวเทียม Landsat

9 แสดงดังตารางที่ 9 เป็นการทดสอบค่า precision recall และ f1-score เพื่อทดสอบความถูกต้องของการจำแนกรายคลาสโดยเน้นที่คลาสของอ้อยตามแต่ละตัวจำแนก ได้แก่ ANN RF และ GB ตามลำดับ เนื่องจากผลลัพธ์สุดท้ายของการจำแนกจะถูกแทนค่าใหม่ให้เหลือเพียงสองคลาสคือพื้นที่เพาะปลูกอ้อยและพื้นที่อื่น ๆ ผลจากการทดสอบพบว่าตัวจำแนกแบบ ANN RF และ GB เมื่อพิจารณาจากค่า precision ให้ผลการจำแนกรายคลาสเฉพาะพื้นที่เพาะปลูกอ้อยอยู่ที่ 0.84 0.95 และ 0.95 ตามลำดับ

ตารางที่ 9 ผลการจำแนกคลาสพื้นที่เพาะปลูกอ้อยของจังหวัดสระแก้วด้วยตัวจำแนก ANN RF และ GB จากภาพถ่ายจากดาวเทียม Landsat 9

Classifier	Precision	Recall	F1-score
ANN	0.84	0.86	0.85
RF	0.95	0.84	0.89
GB	0.95	0.83	0.89

5.2.2 ความถูกต้องของการจำแนกพื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้ว ด้วยภาพถ่ายจากดาวเทียม Sentinel-1 เมื่อพิจารณาจากค่า precision พบว่าตัวจำแนกแบบ ANN RF

และ GB ให้ผลการจำแนกรายคลาสเฉพาะพื้นที่เพาะปลูกอ้อยอยู่ที่ 0.76 0.77 และ 0.77 ตามลำดับ (ตารางที่ 10) ซึ่งให้ค่าความถูกต้องอยู่ในระดับใกล้เคียงกัน

ตารางที่ 10 ผลการจำแนกคลาสพื้นที่ปลูกอ้อยของจังหวัดสระแก้วด้วยตัวจำแนก ANN RF และ GB จากภาพถ่ายจากดาวเทียม Sentinel-1

Classifier	Precision	Recall	F1-score
ANN	0.76	0.83	0.79
RF	0.77	0.80	0.78
GB	0.77	0.80	0.78



บทควาณวิจัย

การพัฒนาชุดสมอภคอาจรยชที่เรยนรูด้วยตัวเองสำหรับระบบภคภคสารสนเทศ (GIS) ในการจำแนกและวณารพคภคออยจากภคภคถ่ายดาวเทียม

5.2.3 การทดสอบโคเชนแคบปาและค่าสถิต Z ของ ผลลัพธ์ที่ได้จากการจำแนก การจำแนกพื้นที่เพาะปลูกอ้อย ที่ดำเนินงานในงานวิจัยนี้ได้ใช้วิธีการจำแนกจำนวน 3 วิธี ได้แก่ ANN RF และ GB ซึ่งแต่ละวิธีมีความเป็นอิสระต่อกัน และให้ผลลัพธ์ที่มีความแตกต่างกันร่วมกับภคภคถ่ายจาก ดาวเทียม Landsat การทดสอบเพื่อยืนยันถึงประสิทธิภค ในการจำแนกแต่ละวิธีจำเป็นต้องมีการตั้งสมมติฐาน

เปรียบเทียบวิธีการจำแนกในแต่ละคู่และทดสอบความ แตกต่าง การทดสอบจะใช้วิธีค่าคะแนนมาตรฐาน Z (Z-test) โดยกำหนดให้ช่วงความเชื่อมั่นอยู่ระหว่าง -1.96 ถึง 1.96 ที่ระดับนัยสำคัญ 0.05 การทดสอบจะดำเนินการที่ละคู่วิ การจำแนก โดยตั้งสมมติฐาน H_0 = ผลการจำแนกทั้งสอง วิธีไม่แตกต่างกัน และ H_A = ผลการจำแนกทั้งสองวิธี การมีความแตกต่างกัน ผลการทดสอบแสดงดังตารางที่ 11

ตารางที่ 11 การทดสอบความแตกต่างของผลการจำแนกพื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้วด้วยภคภคถ่ายจากดาวเทียม Landsat 9

Paired test		Kappa		Z value	Result
A	B	A	B		
ANN	RF	0.71	0.73	3.60	H_A
ANN	GB	0.71	0.73	2.42	H_A
RF	GB	0.73	0.73	1.18	H_0

ANN เมื่อทดสอบความแตกต่างกับวิธี RF และ GB พบว่า มีค่าคะแนนมาตรฐาน Z อยู่ที่ 3.60 และ 2.42 ตามลำดับ ซึ่งอยู่นอกช่วงความเชื่อมั่นที่ระดับนัยสำคัญ 0.05 การทดสอบ สมมติฐานปฏิเสธ H_0 แสดงให้เห็นว่าวิธีการจำแนกแบบ ANN ให้ผลการจำแนกที่ดีกว่าวิธีการจำแนกแบบอื่น ๆ อย่างมีนัยสำคัญ ส่วนวิธีการจำแนกแบบ RF และ GB ผลการทดสอบสมมติฐาน

ไม่สามารถปฏิเสธ H_0 ได้ แสดงให้เห็นว่าผลจากวิธีการจำแนก ทั้ง 2 วิธีให้ค่าความถูกต้องไม่แตกต่างกันอย่างมีนัยสำคัญ ในส่วนของการทดสอบความแตกต่างของผลการจำแนก พื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้ว ที่ได้จากภคภคถ่ายจาก ดาวเทียม Sentinel-1 ดำเนินการทดสอบเช่นเดียวกัน

ตารางที่ 12 การทดสอบความแตกต่างของผลการจำแนกพื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้วด้วยภคภคถ่ายจากดาวเทียม Sentinel-1

Paired test		Kappa		Z value	Result
A	B	A	B		
ANN	RF	0.52	0.55	3.05	H_A
ANN	GB	0.52	0.54	2.22	H_A
RF	GB	0.55	0.54	0.83	H_0

จากตารางที่ 12 ในการจำแนกพื้นที่เพาะปลูกอ้อยจังหวัด สระแก้ว ผลการจำแนกจากวิธี ANN เมื่อทดสอบความ แตกต่างกับวิธี RF และ GB พบว่ามีค่าคะแนนมาตรฐาน Z อยู่ที่ 3.05 และ 2.22 ตามลำดับซึ่งอยู่นอกช่วงความเชื่อมั่นที่

ระดับนัยสำคัญ 0.05 การทดสอบสมมติฐานปฏิเสธ H_0 แสดง ให้เห็นว่าวิธีการจำแนกแบบ ANN ให้ผลการจำแนกที่ดีกว่า วิธีการจำแนกแบบอื่น ๆ อย่างมีนัยสำคัญ ส่วนวิธีการจำแนก แบบ RF และ GB ผลการทดสอบสมมติฐานไม่สามารถปฏิเสธ



H₀ ได้ แสดงให้เห็นว่าผลจากวิธีการจำแนกทั้ง 2 วิธีให้ค่าความถูกต้องไม่แตกต่างกันอย่างมีนัยสำคัญ

5.2.4 ผลการเปรียบเทียบพื้นที่เพาะปลูกอ้อยที่แสดงในตารางที่ 13

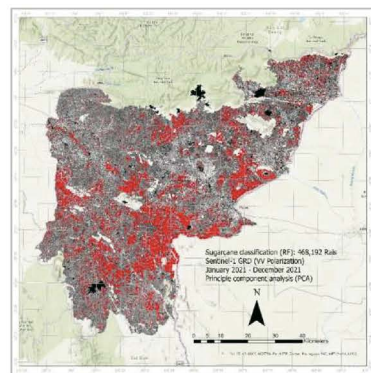
ตารางที่ 13 พื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้วที่ได้จากการจำแนกภาพถ่ายจากดาวเทียม Landsat 9 และ Sentinel-1 โดยใช้วิธี ANN RF และ GB

ภาพถ่ายจากดาวเทียม	วิธีการจำแนก	พื้นที่เพาะปลูกอ้อย (ไร่)
Landsat 9	ANN	268,994
	RF	301,817
	GB	308,704
Sentinel-1	ANN	521,650
	RF	468,192
	GB	453,192

จากตารางที่ 13 การจำแนกพื้นที่เพาะปลูกอ้อยในงานวิจัยนี้ได้ดำเนินการในช่วงปี พ.ศ. 2564 ซึ่งข้อมูลจำนวนพื้นที่เพาะปลูกอ้อยของจังหวัดสระแก้วจากสำนักงานอ้อยและน้ำตาลพบว่ามีเนื้อที่รวมทั้งสิ้น 459,446 ไร่ ผลจากการจำแนกด้วยดาวเทียม Landsat 9 พบปัญหาเรื่องของปริมาณเมฆที่ครอบคลุมพื้นที่ศึกษาตลอดทั้งปี มีเพียงภาพถ่ายจากดาวเทียมวันที่ 7 ธันวาคม 2564 เพียงภาพเดียวเท่านั้นที่ปราศจากเมฆในพื้นที่ศึกษาซึ่งเป็นช่วงที่เปิดหีบอ้อยของโรงงานน้ำตาล มีพื้นที่บางส่วนได้เก็บเกี่ยวผลผลิตเพื่อเตรียมส่งเข้าสู่โรงงาน ส่งผลให้การจำแนกพื้นที่เพาะปลูกอ้อยจากภาพถ่ายจากดาวเทียม Landsat 9 มีขนาดพื้นที่คลาดเคลื่อนจากความเป็นจริง ซึ่งอยู่ระหว่าง 268,000-309,000 ไร่ เท่านั้นเมื่อใช้ตัวจำแนก ANN RF และ GB

ปัญหาดังกล่าวได้มีการแก้ไขโดยการนำข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1 ซึ่งเป็นข้อมูลจากดาวเทียมแบบ synthetic aperture radar (SAR) สามารถสร้างพลังงานได้เองโดยไม่ต้องพึ่งพาแสงอาทิตย์ พลังงานที่สร้างจากดาวเทียมอยู่ในช่วงคลื่นไมโครเวฟซึ่งเป็นช่วงคลื่นยาวและสามารถเดินทางผ่านเมฆได้ ทำให้สามารถได้ข้อมูลในพื้นที่ขณะที่มีเมฆปกคลุม อย่างไรก็ตามจากการสะท้อนของสัญญาณที่กลับมาในลักษณะกระเจิงแสง ส่งผลให้เกิดสัญญาณรบกวนภายใน

ภาพเป็นจำนวนมาก การจำแนกโดยใช้ภาพจากดาวเทียมดังกล่าวมีอุปสรรคในการลดสัญญาณรบกวน จำเป็นต้องมีการประมวลผลทั้งก่อนและหลังการวิเคราะห์ภาพจำนวนมาก เพื่อช่วยให้ได้ภาพที่มีคุณภาพพอที่จะใช้สำหรับแยกแยะข้อมูลผลจากการจำแนกภาพถ่ายจากดาวเทียม Sentinel-1 (polarization VV) ด้วยตัวจำแนก RF ซึ่งเป็นตัวจำแนกที่ให้ค่าความแม่นยำสูงสุด (77%) ให้ขนาดพื้นที่เพาะปลูกอ้อยในจังหวัดสระแก้ว 468,192 ไร่ เป็นขนาดพื้นที่ที่ใกล้เคียงกับข้อมูลจากสำนักงานอ้อยและน้ำตาล (ภาพที่ 6)



ภาพที่ 6 ผลการจำแนกพื้นที่เพาะปลูกอ้อย (สีแดง) จังหวัดสระแก้ว ด้วยตัวจำแนก RF ร่วมกับภาพถ่ายจากดาวเทียม Sentinel-1



และ 11.74-12.98 ต้น/ไร่ (แสดงด้วยสีเขียวเข้ม) ตามลำดับ ในภาพที่ 4-17 ค่าการคาดการณ์ผลผลิตอ้อยจังหวัดสระแก้ว มีช่วงอยู่ระหว่าง 5.50-12.98 ต้น/ไร่ โดยมีค่าเฉลี่ย ค่ามัธยฐาน และส่วนเบี่ยงเบนมาตรฐานอยู่ที่ 10.65 10.91 และ 0.68 ต้น/ไร่ ตามลำดับ

เมื่อนำแบบจำลองคาดการณ์ผลผลิตอ้อยบนพื้นฐานของเทคนิคการวิเคราะห์การถดถอย ด้วยอัลกอริทึมป่าสุ่ม (RFR) ซึ่งมีประสิทธิภาพสูงสุดในการคาดการณ์ผลผลิตมาประยุกต์ใช้ในการคาดการณ์ผลผลิตอ้อยของพื้นที่ปลูกอ้อยจังหวัดสระแก้วที่ได้จากการจำแนกด้วยตัวจำแนก RF ร่วมกับข้อมูลภาพถ่ายจากดาวเทียม Sentinel-1A แบบอนุกรมเวลา (เดือนมกราคม-เดือนธันวาคม พ.ศ. 2564) พบว่าปริมาณผลผลิตที่จากการคาดการณ์โดยแบบจำลองดังกล่าวเท่ากับ 4,986,244 ต้น เมื่อพิจารณาจากค่าเฉลี่ยของแบบจำลอง (10.65 ต้น/ไร่) สามารถอนุมานได้ว่า ภายในปี พ.ศ. 2564 จังหวัดสระแก้วจะมีปริมาณผลผลิตอ้อย 4,986,000 ต้น โดยประมาณ

6. สรุปผลการวิจัย อภิปรายผลและข้อเสนอแนะ

6.1 สรุปผล อภิปรายผล

การศึกษานี้ให้ความสนใจหลักในสองประเด็น ได้แก่ 1) การจำแนกพื้นที่เพาะปลูกอ้อย และ 2) การคาดการณ์ผลผลิตอ้อย โดยนำอัลกอริทึมด้านปัญญาประดิษฐ์มาประยุกต์ในการทำงาน ในประเด็นแรกได้เน้นไปที่การจำแนกพื้นที่เพาะปลูกอ้อยโดยใช้พื้นที่ศึกษาที่จังหวัดสระแก้ว อัลกอริทึมด้านปัญญาประดิษฐ์ที่เลือกใช้ ได้แก่ ANN RF และ GB ซึ่งเป็นอัลกอริทึมที่จัดอยู่ในกลุ่ม Multi-Layer Perceptron (ANN) และ Ensemble Algorithm (RF และ GB) ผลการจำแนกโดยรวมให้ความถูกต้องอยู่ในระดับที่น่าพอใจ ในขณะที่ผลการจำแนกเฉพาะคลาสของอ้อยที่พิจารณาจาก F1-score อัลกอริทึม RF และ GB ให้ค่าความถูกต้องสูงแสดงถึงประสิทธิภาพในการนำอัลกอริทึมด้านปัญญาประดิษฐ์มาใช้ในการจำแนกพื้นที่เพาะปลูกอ้อยในประเด็นที่สองได้เน้นไปที่การคาดการณ์ผลผลิตอ้อยอัลกอริทึมด้านปัญญาประดิษฐ์จำนวน 5 อัลกอริทึม ได้แก่ MLR MLP DTR RFR และ GPR ถูกนำ

มาประยุกต์เพื่อทดสอบประสิทธิภาพของแต่ละอัลกอริทึม และคาดการณ์ผลผลิตอ้อยจากข้อมูลตัวอย่างที่ได้จากการเก็บข้อมูลภาคสนามร่วมกับดัชนีพืชพรรณที่ใช้เป็นตัวแปรสำหรับคาดการณ์ผลผลิต ผลที่ได้จากการคาดการณ์แสดงให้เห็นว่าอัลกอริทึม RFR มีประสิทธิภาพการคาดการณ์ผลผลิตอ้อยสูงกว่าอัลกอริทึมอื่น ๆ โดยพิจารณาจากค่าความถูกต้องของแบบจำลองและค่าคลาดเคลื่อนจากการทำนาย

ประสิทธิภาพของอัลกอริทึมด้านปัญญาประดิษฐ์สามารถนำมาใช้ในงานด้านการจำแนกและคาดการณ์ผลผลิตอ้อย ช่วยให้การดำเนินงานมีความแม่นยำสูงขึ้น การจำแนกพื้นที่เพาะปลูกอ้อยด้วยอัลกอริทึมการเรียนรู้เครื่องด้วยตัวจำแนก ANN RF และ GB บนพื้นฐานของวิธีการจำแนกเชิงจุดภาพร่วมกับภาพถ่ายจากดาวเทียมรายละเอียดปานกลาง Landsat 9 ให้ความถูกต้องอยู่ในระดับที่น่าพอใจ [7], [8] อย่างไรก็ตาม เมื่อพิจารณาความสอดคล้องของระหว่างขนาดพื้นที่ที่ได้จากการจำแนกและขนาดพื้นที่จริงจากแหล่งอ้างอิง พบว่ามีพื้นที่จากการจำแนกมีขนาดคลาดเคลื่อนจากความเป็นจริง เป็นผลมาจากข้อจำกัดของการรวบรวมข้อมูลภาพถ่ายจากดาวเทียมจากปัญหาของเมฆปกคลุมพื้นที่ศึกษาตลอดทั้งปี ภาพถ่ายจากดาวเทียม Sentinel-1 จึงถูกนำมาแก้ไขข้อจำกัดที่เกิดขึ้น [18] ร่วมกับตัวจำแนกข้างต้น เมื่อพิจารณาค่าความถูกต้องเฉพาะคลาสพื้นที่ปลูกอ้อย อัลกอริทึม RF ให้ความถูกต้องการจำแนกสูงกว่าอัลกอริทึมอื่น ๆ และสามารถจำแนกพื้นที่เพาะปลูกอ้อยให้มีขนาดพื้นที่ใกล้เคียงกับข้อมูลอ้างอิงมากที่สุด ซึ่งมีความสอดคล้องกับการศึกษาของ Virnodkar, S. [15] Reungsang, P. [16] แสดงให้เห็นถึงการพัฒนาระบบสมองกลอัจฉริยะที่สามารถเรียนรู้ด้วยตัวเองสำหรับระบบภูมิสารสนเทศมาประยุกต์ในการจำแนกพื้นที่เพาะปลูกอ้อยจากข้อมูลภาพถ่ายจากดาวเทียมได้อย่างมีประสิทธิภาพ เมื่อทดสอบค่าคะแนนมาตรฐาน Z ที่ระดับความเชื่อมั่นร้อยละ 95 พบว่า อัลกอริทึม RF และ GB ให้ความถูกต้องการจำแนกไม่แตกต่างกันอย่างมีนัยสำคัญ ในกรณีพบข้อจำกัดในการใช้อัลกอริทึม ผู้ศึกษาสามารถเลือกใช้อัลกอริทึมตัวใดตัวหนึ่งทดแทน

วิธีการจำแนกพื้นที่เพาะปลูกอ้อยด้วยอัลกอริทึมการเรียนรู้แบบเอนเซมเบิลไม่จำเป็นต้องอาศัยตัวแปรทางสถิติ



บทความวิจัย

การพัฒนาชุดสมรรถนะการเรียนรู้ด้วยตัวเองสำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการผลัดอ้อยจากภาพถ่ายดาวเทียม

สำหรับการแยกประเภทของข้อมูล เหมาะกับการทำงานร่วมกับ ข้อมูลภูมิสารสนเทศและงานทางด้าน การสำรวจระยะไกล ซึ่งมีลักษณะการกระจายเชิงสถิติที่แตกต่างกัน (Free Distribution) [19] อย่างไรก็ตาม จำเป็นต้องทดสอบไฮเพอร์-พารามิเตอร์ของอัลกอริทึมเพื่อปรับพารามิเตอร์ให้เหมาะสม ต่อการทำงานกับชุดข้อมูลโดยเฉพาะ มีส่วนช่วยให้การ จำแนกมีความแม่นยำและประสิทธิภาพมากยิ่งขึ้น [10] ลดโอกาสการเกิดปัญหา Overfitting ของแบบจำลอง

การคาดการณ์ผลผลิตอ้อยโดยใช้แบบจำลองบน พื้นฐานของเทคนิคการวิเคราะห์การถดถอยต่าง ๆ อาทิ MLR MLP DTR RFR และ GPR ร่วมกับข้อมูลภาพถ่ายจากดาวเทียม Landsat-8 แบบอนุกรมเวลาที่ผ่านกระบวนการเน้นภาพ เชิงช่วงคลื่นด้วยวิธีดัชนีพืชพรรณ NDVI GNDVI EVI และ SAVI เมื่อวัดประสิทธิภาพในการคาดการณ์ผลผลิตอ้อย แบบจำลอง RFR สามารถคาดการณ์ผลผลิตอ้อยได้แม่นยำสูงสุด (ร้อยละ 79) ให้ความคลาดเคลื่อนของการทำนาย = 0.79 ตัน/ไร่ จากทั้งหมด 5 แบบจำลอง แต่อย่างไรก็ตามแบบจำลองอื่น ๆ ให้ค่าความแม่นยำและความคลาดเคลื่อนในการคาดการณ์ อยู่ในระดับที่ใกล้เคียงกับแบบจำลองที่มีประสิทธิภาพสูงสุด (ระหว่างร้อยละ 72-77 และร้อยละ 0.87-0.93 ตัน/ไร่ ตามลำดับ)

แม้ว่าการใช้ข้อมูลภาพถ่ายจากดาวเทียมหลายช่วง เวลาสามารถนำมาใช้เป็นข้อมูลประกอบการจำแนกและ คาดการณ์ผลผลิตของอ้อย จากการวิเคราะห์ข้อมูลซีฟลักซ์ ที่เป็นลักษณะเฉพาะ ช่วยให้สามารถประเมินผลผลิตได้มี ความแม่นยำมากยิ่งขึ้น [17] อย่างไรก็ตาม การสร้างแบบ จำลองคาดการณ์ผลผลิตอ้อยยังคงมีข้อจำกัดของภาพถ่าย จากดาวเทียมที่นำมาใช้ จากเงื่อนไขของสภาพอากาศขณะ ดาวเทียมบันทึกภาพ หรือเงื่อนไขการคัดกรองเพื่อลดความ ผิดเพี้ยนของข้อมูลตั้งต้น เช่น ครอบคลุมพื้นที่ศึกษาและ ภาพถ่ายต้องถูกปกคลุมด้วยเมฆน้อยกว่าร้อยละ 20 จาก เงื่อนไขดังกล่าว ทำให้ได้ข้อมูลภาพถ่ายจากดาวเทียมบาง ช่วงเวลา ซึ่งไม่ครบถ้วนทุกเดือนในรอบปี ส่งผลให้ขั้นตอน การทำนายมีประสิทธิภาพต่ำ งานวิจัยนี้ได้แก้ไขข้อบกพร่อง ดังกล่าว โดยการเลือกใช้ข้อมูลภาพถ่ายจากดาวเทียมตาม ช่วงเวลาที่สามารถแยกแยะความแตกต่างของพื้นที่ปลูกอ้อย

กับการใช้ประโยชน์ที่ดินอื่นได้อย่างชัดเจน ร่วมกับวิธีการเน้น ภาพแบบดัชนีพืชพรรณต่าง ๆ เพื่อเพิ่มประสิทธิภาพในการ จำแนกและคาดการณ์ผลผลิตของพื้นที่ปลูกอ้อย

การศึกษาค้นคว้านี้มีการประยุกต์ซอฟต์แวร์ที่สเปคในการ สร้างแบบจำลองการจำแนกและคาดการณ์ผลผลิตพื้นที่ เพาะปลูกอ้อย อาทิ แพลตฟอร์ม Google Earth Engine และ Python ทำงานร่วมกับไลบรารีประมวลผลข้อมูลเชิง พื้นที่ (Geospatial Data) ผู้ใช้สามารถเข้าถึงการทำงานโดย มีจำเป็นต้องเสียค่าบริการสำหรับซอฟต์แวร์ประมวลผล (Commercial Software) และสามารถปรับเปลี่ยนหลัก การทำงานของแบบจำลองเพียงบางส่วน เพื่อให้สอดคล้องกับ ข้อมูลต่าง ๆ ได้อยู่ตลอดเวลา จากลักษณะการทำงานที่ อยู่บนพื้นฐานของการป้อนคำสั่งผ่านภาษาคอมพิวเตอร์ (Programming Language) ถือเป็นการลดต้นทุนทางด้าน ทรัพยากรและเวลาในการประมวลผลข้อมูล เหมาะสมกับ การทำงานร่วมกับข้อมูลเชิงพื้นที่ (Geospatial Data) ที่มีความ ซับซ้อนและปริมาณข้อมูลมาก สอดคล้องกับสมมติฐาน ที่ตั้งไว้ได้ชุดประมวลผลที่มีความสามารถในการเรียนรู้ปรับตัว และทันสมัยอย่างเพียงพอ เกิดความคล่องตัวและสะดวกต่อ การใช้งาน นอกจากนี้ยังถือเป็นการบูรณาการข้อมูลภายใน และนอกหน่วยงานอย่างเป็นระบบ จากการรวบรวมข้อมูล จากแหล่งต่าง ๆ เพื่อเป็นส่วนประกอบในการพัฒนาแบบ จำลองดังกล่าวขึ้น

การศึกษาค้นคว้าครั้งนี้มีการเปรียบเทียบประสิทธิภาพ ของแบบจำลองที่ได้จากวิธีต่าง ๆ ที่ได้ถูกนำมาใช้มากขึ้น ณ ช่วงเวลานี้ [19] อาทิ แบบจำลองการจำแนกพื้นที่เพาะปลูกอ้อย จากอัลกอริทึมการเรียนรู้เครื่อง ได้แก่ อัลกอริทึม ANN, RF, และ GB และแบบจำลองคาดการณ์ผลผลิตอ้อยทำงานผ่านเทคนิค การวิเคราะห์การถดถอย MLP, DTR และ RFR พบว่า อัลกอริทึม GB RF ให้ประสิทธิภาพสูงที่สุดในการจำแนกพื้นที่เพาะปลูกอ้อย ในส่วนการคาดการณ์ผลผลิตอ้อย แบบจำลอง RFR มีประสิทธิภาพ ในการคาดการณ์ผลผลิตสูงที่สุด การเปรียบเทียบข้างต้นทำให้ ทราบถึงแบบจำลองที่มีประสิทธิภาพซึ่งมีความสอดคล้องกับ วัตถุประสงค์ของงานวิจัย ทำให้ได้โครงสร้างฐานข้อมูลที่เกี่ยวข้องกับอุตสาหกรรมอ้อยและน้ำตาลที่มีความหลากหลาย ครอบคลุม มีความคล่องตัว สามารถสนับสนุนการตัดสินใจ



ของผู้บริหารได้อย่างมีประสิทธิภาพ

6.2 ข้อเสนอแนะ

1) ในการใช้งานปัญญาประดิษฐ์จำเป็นต้องคำนึงถึงการเตรียมข้อมูลนำเข้าซึ่งเป็นขั้นตอนที่สำคัญ หากข้อมูลมีความแม่นยำจะช่วยให้อัลกอริทึมทำงานได้อย่างมีประสิทธิภาพ

2) รูปแบบของข้อมูล (Format) จำเป็นต้องเตรียมให้ตรงกับที่ใช้ในแบบจำลองเพื่อให้แบบจำลองสามารถเรียนรู้ข้อมูลได้ตรงกับข้อมูลที่ใช้สร้างแบบจำลอง

3) ควรมีการนำข้อมูลที่ได้สำรวจเพิ่มเติมในอนาคตมาต่อยอดกับแบบจำลองที่มีอยู่จะช่วยให้แบบจำลองทำงานได้มีประสิทธิภาพสูงขึ้นและสามารถขยายการทำงานไปยังพื้นที่อื่น ๆ เพิ่มเติมได้

เอกสารอ้างอิง

- [1] Ennouri, Karim & Kallel, Abdelaziz. (2019). Remote Sensing: An Advanced Technique for Crop Condition Assessment. *Mathematical Problems in Engineering*. 2019. 1-8. 10.1155/2019/9404565.
- [2] FAO. (2017). The future of food and agriculture: trends and challenges. [Retrieved August 3, 2022]. from <https://www.fao.org/3/i6583e/i6583e.pdf>.
- [3] Luciano, A. C. d. S., Campagnuci, B. C. G., & le Maire, G. (2022). Mapping 33 years of sugarcane evolution in São Paulo state, Brazil, using landsat imagery and generalized space-time classifiers. *Remote Sensing Applications: Society and Environment*. 26.100749. doi:<https://doi.org/10.1016/j.rsase.2022.10074>
- [4] Luciano, A. C. d. S., Picoli, M. C. A., Rocha, J. V., Duft, D. G., Lamparelli, R. A. C., Leal, M. R. L. V., & Le Maire, G. (2019). A generalized space-time OBIA classification scheme to map sugarcane areas at regional scale, using Landsat images time-series and the random forest algorithm. *International Journal of Applied Earth Observation and*
- Geoinformation. 80. 127-136. doi: 10.1016/j.jag.2019.04.013
- [5] Singh, R., Patel, N. R., & Danodia, A. (2020). Mapping of sugarcane crop types from multi-date IRS-Resourcesat satellite data by various classification methods and field-level GPS survey. *Remote Sensing Applications: Society and Environment*. 19. 100340. doi:10.1016/j.rsase.2020.10034
- [6] Akbarian, S., Xu, C., Wang, W., Ginns, S., & Lim, S. (2022). An investigation on the best-fit models for sugarcane biomass estimation by linear mixed-effect modelling on unmanned aerial vehicle-based multispectral images: A case study of Australia. *Information Processing in Agriculture*.
- [7] Nihar, A., Patel, N. R., Pokhariyal, S., & Danodia, A.. (2022). Sugarcane Crop Type Discrimination and Area Mapping at Field Scale Using Sentinel 1 images and Machine Learning Methods. *Journal of the Indian Society of Remote Sensing*. 50(2). 217-225. doi:10.1007/s12524-021-01444-0
- [8] Singla, S. K., Garg, R. D., & Dubey, O. P.. (2021). Ensemble machine learning methods for spatiooral data analysis of plant and ratoon sugarcane. *Intelligent Data Analysis*. 25(5). 1291-1322. doi:10.3233/IDA-205302
- [9] Dimov, D., Uhl, J. H., Löw, F., & Seboka, G. N. (2022). Sugarcane yield estimation through remote sensing time series and phenology metrics. *Smart Agricultural Technology*. 2. 100046.
- [10] Intarat, K., & Sillaparat, S. (2019). Tropical Mangrove Species Classification Using Random Forest Algorithm and Very High-Resolution Satellite Imagery. *Burapha Science Journal*. 24(2). 742-753.



บทควาณวิจัย

การพัฒนาชุดสมอณกลอาาริชะที่เรียนรู้ด้วยตัวเองสำหรับระบบภูมิสารสนเทศ (GIS) ในการจำแนกและวินิจฉัยการพลิตอ้อยจากภาพถ่ายดาวเทียม

- [11] Som-Ard, J., Atzberger, C., Izquierdo-Verdiguier, E., Vuolo, F., & Immitzer, M. (2021). Remote sensing applications in sugarcane cultivation: A review. *Remote Sensing*. 13(20). doi:10.3390/rs13204040
- [12] Bhosle, K., & Musande, V. (2019). Evaluation of deep learning convolutional neural network for crop classification. *International Journal of Recent Technology and Engineering*. 8(2). 3960-3963. doi:10.35940/ijrte.B2872.078219
- [13] Cobeña Cevallos, J. P., Atiencia Villagomez, J. M., & Andryshchenko, I. S. (2019). Convolutional neural network in the recognition of spatial images of sugarcane crops in the troncal region of the coast of Ecuador.
- [14] Poortinga, A., Thwal, N. S., Khanal, N., Mayer, T., Bhandari, B., Markert, K., . Saah, D. (2021). Mapping sugarcane in Thailand using transfer learning, a lightweight convolutional neural network, NICFI high resolution satellite imagery and Google Earth Engine. *ISPRS Open Journal of Photogrammetry and Remote Sensing*. 1. 100003.
- [15] Virnodkar, S., Pachghare, V. K., & Murade, S. (2021). A Technique to Classify Sugarcane Crop from Sentinel-2 Satellite Imagery Using U-Net Architecture. Springer Science and Business Media Deutschland GmbH. 1199. 322-330.
- [16] Reungsang, P. & Butkhot, T. (2021). Assessment of machine learning on sugarcane classification using Landsat-8and Sentinel-2satellite imagery. *Asia-Pacific Journal of Science and Technology*. 26(4), 1-11.
- [17] Dela Torre, D. M. G., & Perez, G. J. P. (2014). Phenology-based classification of major crops areas in Central Luzon, Philippines from 2001-2013.
- [18] Jiang, H., Li, D., Jing, W., Xu, J., Huang, J., Yang, J., & Chen, S. (2019). Early Season Mapping of Sugarcane by Applying Machine Learning Algorithms to Sentinel-1A/2 Time Series Data: A Case Study in Zhanjiang City. China. *Remote Sensing*. 11. 861. doi: 10.3390/rs11070861.
- [19] Maxwell, Aaron & Warner, Timothy & Fang, Fang. (2018). Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*. 39. 9. 39. 2784-2817. doi:10.1080/01431161.2018.1433343.