

# การประยุกต์ใช้การประมวลผลภาพร่วมกับการเรียนรู้เครื่องเพื่อจำแนกพันธุ์ข้าว

## An Application of Image Processing and Machine Learning for Rice Varieties Classification

ปิยะนารถ บุญระมาตร<sup>1</sup> และเจษฎา ตันthanuch<sup>1\*</sup>

Piyanart Boonramart<sup>1</sup> and Jessada Tanthanuch<sup>1\*</sup>

<sup>1</sup>สาขาวิชาคณิตศาสตร์และภูมิสารสนเทศ สำนักวิชาวิทยาศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี

<sup>1</sup>School of Mathematical Sciences and Geoinformatics, Institute of Science,  
Suranaree University of Technology

\*Corresponding author: jessada@g.sut.ac.th

Received: November 8, 2024

Revised: December 12, 2024

Accepted: December 18, 2024

### บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของการจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสาร 5 สายพันธุ์ ได้แก่ พันธุ์ข้าวคาราก้าตาก หอมมะลิ ยิปซาลา บาสมาดิ และอาโบริโอ โดยการประยุกต์ใช้การประมวลผลภาพร่วมกับการเรียนรู้เครื่อง การดำเนินการวิจัยเริ่มจากการประมวลผลภาพเพื่อลดสัญญาณรบกวนของภาพเมล็ดข้าวสารสายพันธุ์ต่าง ๆ ที่บันทึกในรูปแบบแฟ้มเจเพ็กซึ่งเป็นภาพสีความละเอียด 250x250 จุดภาพ จำนวนสายพันธุ์ละ 15,000 ภาพ นำภาพที่ถูกลดสัญญาณรบกวนแล้วทั้งหมดมาประมวลผลภาพเพื่อใช้ในการจำแนก ด้วยเทคนิคที่แตกต่างกัน 7 วิธี ได้แก่ การตรวจหาขอบภาพด้วยวิธีแคนนี่ การตรวจหาขอบภาพด้วยวิธีโซเบล การตรวจหาเส้น การตรวจหาลายผิว การเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ การเพิ่มคุณภาพของภาพด้วยการพราเกาส์เซียน และการปรับฮิสโทแกรมให้เท่ากัน จากนั้นทำการสกัดคุณลักษณะด้านรูปร่าง 21 ชนิด และคุณลักษณะด้านลายผิวอีก 11 ชนิด แล้วนำไปจำแนกด้วยวิธีการเรียนรู้เครื่อง 6 วิธี ได้แก่ ต้นไม้ตัดสินใจ นาอ์ฟเบส เพื่อนบ้านใกล้ที่สุดเค โครงข่ายประสาทประดิษฐ์ ซัพพอร์ทเวกเตอร์แมชชีน และเกรเดียนท์บูตทรี ทั้งนี้ใช้วิธีการฝึกเพื่อการจำแนกเป็นการตรวจสอบไขว้โคฟโลดเมื่อเคมีค่าเท่ากับ 10 สำหรับทุกวิธีการเรียนรู้เครื่อง ผลการวิจัยพบว่าการใช้การประมวลผลภาพการตรวจหาขอบด้วยวิธีโซเบลร่วมกับการจำแนกด้วยเทคนิคการเรียนรู้เครื่องซัพพอร์ทเวกเตอร์แมชชีน มีประสิทธิภาพในการจำแนกสูงที่สุด โดยการจำแนกมีความถูกต้องร้อยละ 98.68 ค่าความแม่นยำร้อยละ 98.67 ค่าความไวร้อยละ 98.67 ค่าเอฟหนึ่ง สกอร์ร้อยละ 98.67 และค่าสัมประสิทธิ์แคปปาของโคเฮนเท่ากับ 98.35 โดยใช้เวลาในการจำแนก 136.21 วินาที

**คำสำคัญ:** การประมวลผลภาพ การเรียนรู้เครื่อง การจำแนกพันธุ์ข้าว

## Abstract

This research aims to compare the efficiency of techniques for classifying rice varieties from images of milled rice grains. Five rice varieties were considered: Karacadag, Jasmine, Ipsala, Basmati, and Arborio. Image processing combined with machine learning methods were applied. The procedure started with image processing to reduce noise from the images of rice grains of various varieties, which were color JPEG format images with a resolution of 250x250 pixels, with a total of 15,000 images per variety. All noise-reduced images were then processed for classification using seven different techniques: Canny edge detection, Sobel edge detection, ridge detection, texture detection, image enhancement with Laplacian filters, image enhancement with Gaussian blur, and histogram equalization. Features, including 21 shape features and 11 texture features, were extracted and classified using six machine learning techniques: decision trees, Naïve Bayes, k-Nearest Neighbors, Artificial Neural Network (ANN), Support Vector Machines (SVMs), and gradient boosted trees. Training was conducted with K-fold cross-validation with  $K=10$  for all machine learning techniques. The research findings showed that using image processing with Sobel edge detection combined with classification using SVMs was the most effective method, with classification accuracies of 98.68%, precision of 98.67%, recall of 98.67%, F1-score of 98.67%, and a Cohen's kappa coefficient of 98.35%. The classification process took 136.21 seconds.

**Keywords:** image processing, machine learning, rice variety classification



## บทนำ

ประเทศไทยเป็นประเทศที่ส่งออกข้าวได้เป็นอันดับต้น ๆ ของโลก โดยเพียงแค่สองเดือนแรกของปี พ.ศ. 2567 (มกราคมและกุมภาพันธ์) ประเทศไทยมีการส่งออกข้าวเป็นปริมาณถึง 1,747,966 ตัน คิดเป็นมูลค่า 39,401.09 ล้านบาท (1,126.4 ล้านเหรียญสหรัฐ ฯ) โดยเป็นปริมาณการส่งออกเพิ่มขึ้นร้อยละ 24.4 และมูลค่าส่งออกเพิ่มขึ้นร้อยละ 55.1 เมื่อเทียบกับช่วงเดียวกันในปี 2566 ที่มีการส่งออกปริมาณ 1,405,337 ตัน มูลค่า 25,408.07 ล้านบาท (754.06 ล้านเหรียญสหรัฐ ฯ) ทั้งนี้ประเทศไทยส่งออกข้าวสารหลากหลายชนิดและมีราคาที่แตกต่างกัน เช่น สำหรับการส่งออกในช่วงปีต้น พ.ศ. 2567 ข้าวหอมมะลิไทยชนิดพิเศษ เก็บเกี่ยวในปี 2565/2566 ราคาประมาณตันละ 910-926 เหรียญสหรัฐ ฯ ข้าวหอมมะลิไทยชนิดพิเศษ เก็บเกี่ยวในปี 2566/2567 ราคาประมาณตันละ 868-889 เหรียญสหรัฐ ฯ ข้าวหอมไทย ราคาประมาณตันละ 817-831 เหรียญสหรัฐ ฯ และ ข้าวสาร 100% ชั้นสอง ราคาประมาณ

ตันละ 592-622 เหรียญสหรัฐ ฯ (Thai Rice Exporters Association, 2024) จะเห็นได้ว่า ข้าวสารต่างประเภทกันก็มีราคาที่แตกต่างกันมาก ดังนั้นการจำแนกประเภทของข้าวสารมีความจำเป็นยิ่งเพื่อใช้ในการวางแผนมาตรฐานสำหรับการจัดจำหน่ายและการส่งออก การพัฒนาขั้นตอนวิธีที่ทำให้เกิดการจำแนกข้าวสารได้อย่างมีประสิทธิภาพทั้งทางด้านความเร็วในการจำแนกและการจำแนกด้วยความถูกต้องแม่นยำ จะเป็นการช่วยให้ยกระดับมาตรฐานการดำเนินการเกี่ยวกับการจัดจำหน่ายข้าวสารให้สูงขึ้น

ที่ผ่านมาทีมงานวิจัยหลายชิ้นที่มีการใช้ระบบปัญญาประดิษฐ์ (Artificial Intelligence: AI) เพื่อช่วยในงานที่เกี่ยวข้องกับการจำแนกพันธุ์ข้าว เช่น Aki Güllü and Uçar (2015) จำแนกพันธุ์ข้าวจากภาพถ่ายภาพเมล็ดข้าวสาร 4 สายพันธุ์ ได้แก่ ข้าวพันธุ์บาลโด (Baldo) ข้าวพันธุ์ออสมันซิค (Osmancik) ข้าวพันธุ์ยาเซมิน (Yasemin) และกลุ่มของเมล็ดข้าวหัก (broken) โดยใช้วิธีการประมวลผลภาพ (image processing) ร่วมกับเทคนิคการเรียนรู้

เครื่อง (machine learning techniques) 13 เทคนิค พบว่าสามารถจำแนกได้แม่นยำสูงสุดที่ร้อยละ 90.5 และในปีถัดมา Zareiforoush et al. (2016) ได้ใช้วิธีการรับรู้ภาพด้วยคอมพิวเตอร์ (computer vision) เพื่อสกัดและคัดเลือกคุณลักษณะ (feature extraction and feature selection) ของเมล็ดข้าวสารที่ได้จากกรรมวิธีในการสีข้าว 4 ประเภทได้แก่ เมล็ดข้าวสารคุณภาพดีที่ได้จากกระบวนการสีที่ดี (high-processed sound grains) เมล็ดข้าวสารหักได้จากกระบวนการสีที่ดี (high-processed broken grains) เมล็ดข้าวสารคุณภาพดีที่ได้จากกระบวนการสีที่คุณภาพไม่ดี (low-processed sound grains) เมล็ดข้าวสารหักได้จากกระบวนการสีที่คุณภาพไม่ดี (low-processed broken grains) แล้วใช้วิธีเมทาฮิวริสติก (metaheuristic method) 4 ชนิดช่วยในการจำแนก วิธีเมทาฮิวริสติกที่ใช้ในงานวิจัยนี้ได้แก่ โครงข่ายประสาทประดิษฐ์ (Artificial Neural Network: ANN) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) ต้นไม้การตัดสินใจ (Decision Trees: DT) และ เครือข่ายเบย์ (Bayesian Network) ซึ่งวิธีโครงข่ายประสาทประดิษฐ์ให้ผลการจำแนกที่มีความถูกต้องสูงที่สุดถึงร้อยละ 98.72 ในปีถัดมา Rexce and Usha Kingsly Devi (2017) ใช้ระบบการรับรู้ภาพด้วยคอมพิวเตอร์ร่วมกับการประมวลผลภาพและวิธีการแบ่งส่วนภาพ (segmentation method) สกัดคุณลักษณะของภาพได้ 57 อย่าง แล้วใช้วิธีเมทาฮิวริสติกทั้ง 4 ชนิดเหมือนกับ Zareiforoush et al. (2016) ในการจำแนกเมล็ดข้าวพบว่าวิธีที่สามารถจำแนกข้าวสารโดยที่มีความถูกต้องสูงที่สุด คือ วิธีโครงข่ายประสาทประดิษฐ์เช่นกัน และมีความถูกต้องในการจำแนก ร้อยละ 92.307% ในช่วงหลังมีงานวิจัยที่เกี่ยวข้องกับการสกัดคุณลักษณะและใช้เทคนิคการเรียนรู้เครื่อง (machine learning) เช่น Tanwong, Suksawang and Punsawad (2019) ได้ใช้การเรียนรู้ของเครื่องมาพัฒนาระบบตรวจสอบคุณภาพของฟีนไทป์ของเมล็ดข้าวเพื่อจำแนกตามเกณฑ์การแบ่งกลุ่มข้าวหอมมะลิกายใต้พระราชบัญญัติการส่งออกสินค้าเกษตร โดยใช้เทคนิคโครงข่ายประสาทประดิษฐ์แบบคอนโวลูชัน โดยให้ค่าความถูกต้องสูงถึงร้อยละ 90.70 นอกจากนี้ยังมีงานวิจัยของ Cinar และ Köklü หลายชิ้น (Cinar & Köklü, 2019; Cinar & Köklü, 2021; Cinar, Köklü & Taspinar, 2021; Cinar & Köklü, 2022) ซึ่งได้ทำวิจัยกับข้าวสารหลากหลายสายพันธุ์ได้แก่ พันธุ์ออสมันซิค (Osmancik) คามิโอ (Cameo) คารากาดาก (Karacadag) หอมมะลิ

(Jasmine) ยิปซาลา (Ipsala) บาสมาติ (Basmati) และอาโบริโอ (Arborio) โดยในงานทั้งหมดที่นักวิจัยเหล่านั้นได้ทำมีความสามารถในการจำแนกเมล็ดข้าวสารถูกต้องสูงถึงร้อยละ 99.91 และงานวิจัยของ Abuelewa and Abu-Naser (2024) ได้ใช้เทคนิคการเรียนรู้เชิงลึก ResNetV2 ทำให้มีความสามารถในการจำแนกเมล็ดข้าวสารแบบเดียวกันถูกต้องสูงถึงร้อยละ 99.96

งานข้างต้นที่กล่าวมาเป็นแรงบันดาลใจในการทำวิจัยนี้ แต่อย่างไรก็ตามงานดังกล่าวมักเน้นไปที่การประยุกต์ใช้เทคนิคต่าง ๆ ของปัญญาประดิษฐ์ที่หลากหลายในการจำแนกข้าว งานวิจัยนี้ต้องการใช้การประมวลผลภาพเพื่อลดความซับซ้อนของภาพเมล็ดข้าวสารก่อนนำไปใช้เทคนิคการเรียนรู้เครื่องแบบต่าง ๆ ทำการจำแนก จากนั้นเปรียบเทียบประสิทธิภาพในการจำแนกโดยพิจารณาทั้งในด้านของความถูกต้องในการจำแนกและระยะเวลาที่ใช้ในการประมวลผล เพื่อเป็นข้อมูลให้ผู้ที่นำไปประยุกต์ใช้งานต่อไปสามารถเลือกขั้นตอนวิธีที่เหมาะสมกับความต้องการได้

## วัตถุประสงค์การวิจัย

ต้องการประยุกต์ใช้เทคนิคการเรียนรู้เครื่องร่วมกับการประมวลผลภาพเพื่อจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสาร 5 สายพันธุ์ได้แก่ พันธุ์ข้าวคารากาดาก หอมมะลิ ยิปซาลา บาสมาติ และอาโบริโอ

เพื่อเปรียบเทียบประสิทธิภาพขั้นตอนวิธีต่าง ๆ ในการจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสาร

## แนวคิดทฤษฎีที่เกี่ยวข้อง

### การประมวลผลภาพดิจิทัล

การประมวลผลภาพดิจิทัล (digital image processing) คือ การจัดการและวิเคราะห์ภาพดิจิทัลโดยใช้เทคนิคหรืออัลกอริทึมต่าง ๆ เพื่อวิเคราะห์ข้อมูลภาพ ปรับปรุงคุณภาพ สกัดคุณสมบัติ และการดำเนินการอื่นทางดิจิทัลเพื่อให้ได้ผลลัพธ์ที่ต้องการ การประมวลผลภาพดิจิทัลที่น่าสนใจเช่น การตรวจหาขอบภาพ การตรวจหาเส้น การตรวจหาลายนิ้ว การค้นคืนภาพ การกำหนดตำแหน่ง และการจัดเรียงภาพ และการปรับปรุงเพื่อเพิ่มคุณภาพของภาพดิจิทัล (Kullimratchai, 2014; Chunwitthayathira, 2014) การประมวลผลภาพดิจิทัลที่ใช้ในงานวิจัยนี้ได้พิจารณาคัดเลือกจากขั้นตอนวิธีที่ไม่ต้องใช้ความสามารถในการประมวลผลสูงมากนักแต่สามารถสกัดจุดเด่นของภาพ

ออกมาได้ง่ายในหลากหลายรูปแบบ ทั้งนี้จะมีประโยชน์หากในอนาคตต้องการนำผลที่ได้จากการวิจัยไปประยุกต์ใช้จริงในระดับอุตสาหกรรมขนาดเล็กที่ไม่จำเป็นต้องใช้เครื่องมือและเครื่องประมวลผลที่มีราคาสูง

#### การตรวจหาขอบภาพด้วยวิธีการโซเบล

การตรวจหาขอบภาพด้วยวิธีการโซเบล (Sobel edge detection) เป็นวิธีที่ใช้ในการจับขอบภาพโดยมีหลักการทำงานโดยการใช้เมทริกซ์เคอร์เนล (kernel matrix) ขนาด  $3 \times 3$  จำนวน 2 เมทริกซ์ มาใช้ในการคำนวณค่าเกรเดียนต์ของความเข้ม (intensity) ของแต่ละจุดภาพ (pixel) ในภาพดิจิทัล โดยเมทริกซ์เคอร์เนล  $G_x$  และ  $G_y$  (แสดงดังภาพ 1) ถูกออกแบบมาเพื่อพิจารณาการเปลี่ยนแปลงในทิศทางแนวนอนและแนวตั้งตามลำดับ (Gonzalez & Woods, 1992)

#### การตรวจหาขอบภาพด้วยวิธีการแคนนี่

การตรวจหาขอบภาพด้วยวิธีการแคนนี่ (Canny edge detection) เป็นหนึ่งในเทคนิคการตรวจขอบภาพโดยมีวิธีดำเนินการหลัก 4 ขั้นตอน ประกอบไปด้วย การกำจัดสัญญาณรบกวนภายในภาพด้วยตัวกรองเกาส์เซียน การหาการไล่ระดับสีของภาพ โดยหาทั้งขนาดและทิศทางของการไล่ระดับสี การพิจารณาขอบที่เป็นไปได้ โดยกำจัดจุดภาพที่ถูกพิจารณาว่าไม่ใช่ส่วนหนึ่งของขอบ และคำนวณหาฮิสเทอรีซิส (hysteresis) เพื่อระบุขอบ (Reddy et al., 2016)

#### การตรวจหาสัน

การตรวจหาสัน (ridge detection) เป็นเทคนิคในการประมวลผลภาพที่มุ่งหาแนวเส้นโดยการพิจารณาสมมาตร (symmetry) ของความเข้มทั้งสองฝั่งของแนวเส้นเป็นหลัก โดยทั่วไปแล้วสัน (ridge) จะเป็นจุดภาพที่มีความเข้มสูงสุดเมื่อเทียบกับความเข้มทั้งสองฝั่ง การตรวจหาสันมุ่งเน้นการหาแนวยาวของสันด้วยสมมาตรคล้ายแนวสันเขาในทางภูมิศาสตร์ แต่การตรวจหาขอบมักจะเป็นการตรวจหาการเปลี่ยนแปลงความเข้มของจุดภาพที่เป็นขอบเขตของวัตถุเป็นหลัก (Shokouh et al., 2021)

#### การตรวจหาลายผิว

การตรวจหาลายผิว (texture detection) เป็นกระบวนการประมวลผลลักษณะเฉพาะของพื้นผิวที่ปรากฏในภาพดิจิทัล โดยทั่วไปแล้วจะมีการใช้เทคนิคต่าง ๆ ในการสกัดคุณลักษณะพื้นผิว เช่น Gray Level Co-occurrence

Matrix: GLCM Local Binary Patterns: LBP และ Statistical Features รวมถึง Gabor filter ซึ่งมีการประยุกต์ใช้ฟังก์ชันคลื่นร่วมกับการกรองความถี่แบนด์พาส (Bandpass Filter) มาตรวจหาลักษณะเฉพาะของพื้นผิว (Armi & Fekri-Ershad, 2019)

#### การเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ

การเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ (image enhancement with Laplacian filter) เป็นเทคนิคที่ใช้ในกระบวนการประมวลผลภาพเพื่อเพิ่มความคมชัดและเน้นรายละเอียดของภาพ โดยเฉพาะอย่างยิ่งในบริเวณที่มีการเปลี่ยนแปลงความเข้มแสงอย่างรวดเร็ว เช่น ขอบหรือเส้นในภาพ โดยการใช้ตัวกรอง Laplacian ซึ่งเป็นการหาค่าของอนุพันธ์อันดับสองของภาพ ซึ่งช่วยให้สามารถตรวจจับขอบของภาพได้อย่างมีประสิทธิภาพโดยไม่ต้องแยกการตรวจจับขอบในแนวนอนและแนวตั้งเหมือนกับตัวกรองอนุพันธ์อันดับหนึ่งที่ปรากฏในการตรวจหาขอบภาพด้วยวิธีการโซเบล (NV5 Geospatial Software, 2023)

#### การเพิ่มคุณภาพของภาพด้วยการพัวเกาส์เซียน

การเพิ่มคุณภาพของภาพด้วยการพัวเกาส์เซียน (image enhancement with Gaussian blur) เป็นการใช้ตัวกรองเกาส์ (Gaussian filter) มาทำการพัว (blur) ซึ่งช่วยในการลดสัญญาณรบกวนบางชนิดที่ปรากฏในภาพ เพราะเป็นการลดการเปลี่ยนแปลงความเข้มอย่างรวดเร็วของจุดภาพที่อยู่ติดกันโดยที่ยังรักษาโครงสร้างทั่วไปของภาพไว้ ทำให้เมื่อพิจารณาด้วยสายตาจะเห็นเป็นภาพที่มีความนุ่มนวลมากขึ้น (Jameel & Mohamed Shanavas, 2015)

#### การปรับฮิสโทแกรมให้เท่ากัน

ฮิสโทแกรม (Histogram) ถูกนำมาใช้เป็นเครื่องมือที่ใช้ในการแสดงการกระจายของจำนวนจุดภาพที่มีความเข้มแตกต่างกัน การปรับฮิสโทแกรมให้เท่ากัน (histogram equalization) เป็นเทคนิคการประมวลผลภาพที่มีเป้าหมายคือ ปรับให้จำนวนของจุดภาพในแต่ละค่าความเข้มมีจำนวนใกล้เคียงกัน การดำเนินการนี้ช่วยให้ภาพที่มีความคมชัดต่ำหรือมีปัญหาจำนวนจุดภาพที่มีความเข้มแตกต่างกันมีการกระจายอย่างสม่ำเสมอให้กลับมีความคมชัดและรายละเอียดที่ชัดเจนยิ่งขึ้นช่วยให้สามารถมองเห็นลักษณะเฉพาะของภาพได้ดีขึ้น (Patel et al., 2013)

$$G_x = \begin{bmatrix} 1 & 0 & -1 \\ 2 & 0 & -2 \\ 1 & 0 & 1 \end{bmatrix} \text{ และ } G_y = \begin{bmatrix} 1 & 2 & 1 \\ 0 & 0 & 0 \\ -1 & -2 & -1 \end{bmatrix}$$

ภาพ 1 เมทริกซ์เคอร์เนล (Kernel Matrix) ขนาด 3x3 จำนวน 2 เมทริกซ์

## วิธีการเรียนรู้เครื่อง

วิธีการเรียนรู้เครื่อง (machine learning methods) เป็นชุดขั้นตอนวิธีที่ใช้เพื่อให้คอมพิวเตอร์สามารถเรียนรู้จากข้อมูลและทำการคาดการณ์หรือการตัดสินใจ โดยแบ่งวิธีการเรียนรู้เครื่องเป็น 4 ประเภทเบื้องต้นได้แก่ (1) การเรียนรู้แบบมีผู้สอน (supervised learning) (2) การเรียนรู้แบบไม่มีผู้สอน (unsupervised learning) (3) การเรียนรู้แบบกึ่งมีผู้สอน (semi-supervised learning) และ (4) การเรียนรู้แบบเสริมแรง (reinforcement learning) ตัวอย่างวิธีการเรียนรู้เครื่องที่น่าสนใจและเป็นที่ยอมรับในการจำแนกได้แก่ ต้นไม้ตัดสินใจ นาอ์ฟเบส์ เพื่อนบ้านใกล้ที่สุด โครงข่ายประสาทประดิษฐ์ ซัพพอร์ทเวกเตอร์แมชชีน และเกรเดียนต์บูตทรี

### ต้นไม้ตัดสินใจ

ต้นไม้ตัดสินใจ (decision trees) เป็นแบบจำลองที่เป็นการเรียนรู้แบบมีผู้สอน เหมาะสำหรับการจำแนกประเภท โดยแบบจำลองนี้มีลักษณะเป็นกราฟรูปต้นไม้ โดยเริ่มจากการรวบรวมบัพ (node) การตัดสินใจที่มีการแสดงคุณลักษณะของข้อมูลที่สัมพันธ์กับตัวแปร แล้วเชื่อมต่อด้วยเส้นเชื่อม (edge) ต่าง ๆ ที่บอกน้ำหนักหรือค่าที่ใช้ในการเลือกบัพถัดไป ทำซ้ำเช่นนี้ไปเรื่อย ๆ จนสิ้นสุดที่บัพใบ (leaf node) ซึ่งเป็นกลุ่มหรือคำตอบที่เราต้องการทำนาย (Siharad & Sookprasert, 2024)

### นาอ์ฟเบส์

แบบจำลองนาอ์ฟเบส์ (Naïve Bayes) เป็นหนึ่งในแบบจำลองการจำแนกประเภทที่ใช้ในการแบ่งกลุ่มหรือเหตุการณ์โดยอิงจากทฤษฎีบทความน่าจะเป็นของ Bayes มาช่วยในการคำนวณว่าจะเกิดเหตุการณ์นั้นหรือไม่ สำหรับการจำแนกประเภทหลายกลุ่มนั้น สามารถคำนวณได้จากสูตรต่อไปนี้ (Farid et al, 2014)

$$P(c_i | x) = \frac{p(c_i) p(x | c_i)}{p(x)} \quad (1)$$

โดย  $P(c_i | x)$  คือ ความน่าจะเป็นที่ข้อมูลที่มีคุณลักษณะ  $c_i$  จะมีคลาส  $x$

$P(x | c_i)$  คือ ความน่าจะเป็นที่ข้อมูลที่มีคลาส  $x$

จะมีคุณลักษณะ  $c_i$

$P(c_i)$  คือ ความน่าจะเป็นของคลาส  $c_i$

$P(x)$  คือ จำนวนคุณลักษณะทั้งหมด

## เพื่อนบ้านใกล้ที่สุด

แบบจำลองเพื่อนบ้านใกล้ที่สุด (nearest neighbors) เป็นวิธีการที่ใช้สำหรับการทำนายและการประมาณค่า ซึ่งมักพบในการจำแนกประเภท (classification) และการถดถอย (regression) โดยเป็นวิธีที่เป็นไปได้ทั้งการเรียนรู้แบบมีผู้สอนหรือแบบไม่มีผู้สอนขึ้นอยู่กับการประยุกต์ใช้งาน แบบจำลองนี้ทำงานโดยการเปรียบเทียบข้อมูลที่ต้องการทำนายกับชุดข้อมูลที่มีอยู่ โดยพิจารณาข้อมูลที่ใกล้เคียงที่สุด (neighbors) ในเชิงระยะทาง (distance) ความคล้ายคลึงกันระหว่างข้อมูลจะถูกวัดโดยใช้ฟังก์ชันระยะทาง (distance metric) เช่น Euclidean distance Manhattan distance Minkowski distance หรือ Hamming distance สำหรับการตัดสินใจจะพิจารณาว่าหากข้อมูลที่สนใจอยู่ใกล้กับข้อมูลใดมากที่สุด ระบบจะให้คำตอบเป็นผลลัพธ์ที่เกิดจากข้อมูลเพื่อนบ้านใกล้ที่สุด โดยอาจใช้วิธีการลงคะแนนเสียง (voting) สำหรับการจำแนกประเภท หรือเฉลี่ยค่าของเพื่อนบ้านสำหรับการถดถอย (Sinsomboonthong, 2017)

## โครงข่ายประสาทประดิษฐ์

โครงข่ายประสาทประดิษฐ์ (artificial neural network) เป็นแบบจำลองที่เลียนแบบมาจากโครงข่ายประสาทที่ช่วยจดจำการเรียนรู้ที่ซับซ้อนของสัตว์ โดยข้อมูลนำเข้า (input data) แสดงถึง โยประสาทที่รวบรวมข้อมูลจากเซลล์ประสาทต้นทาง และนำค่าข้อมูลเข้ามาคูณกับค่าถ่วงน้ำหนักของแต่ละเส้นทางของข้อมูลเข้า ผลที่ได้นั้นจะถูกนำเข้าสู่เซลล์ประสาทสำหรับรวมค่าข้อมูลเข้าผ่านทางฟังก์ชันการรวมกัน ทำให้ข้อมูลเข้าเกิดการตอบสนองกับฟังก์ชันส่งผ่าน (transfer function) เพื่อเกิดผลลัพธ์เป็นข้อมูลนำออก (output data) ของเซลล์ประสาทที่เชื่อมต่อกับเซลล์ประสาทอื่น ๆ (Sinsomboonthong, 2017)


## ซัพพอร์ทเวกเตอร์แมชชีน

ซัพพอร์ทเวกเตอร์แมชชีน (support vector machine) เป็นหนึ่งในขั้นตอนการเรียนรู้โดยอาศัยการสร้างเส้นแบ่ง ขึ้นมาแบ่งกลุ่มข้อมูลออกจากกัน โดยมีจุดมุ่งหมายในการหาเส้นแบ่งที่เหมาะสมที่สุดที่เป็นไปได้ สำหรับการจำแนกประเภทที่มีหลายกลุ่มกับซัพพอร์ทเวกเตอร์แมชชีน นั้นมีวิธีการมากมาย โดยหนึ่งวิธีการที่ได้รับความนิยม คือ วิธี One-vs-All มีหลักการ คือ ข้อมูลหลายชุดจะถูกสร้างขึ้น แต่ละชุดจะมีกลุ่มที่สนใจจำแนกประเภทกับกลุ่มที่เหลือ เช่น แบ่งกลุ่ม A กับกลุ่มอื่นทั้งหมดที่ไม่ใช่กลุ่ม A แบ่งกลุ่ม B กับกลุ่มอื่นทั้งหมดที่ไม่ใช่กลุ่ม B เป็นต้น โดยในการทำนายผล จะเลือกจากกลุ่มที่ได้คะแนนสูงสุดจากการสร้างแบบจำลองทั้งหมด (Microsoft, 2024)

## เกรเดียนท์บูตทรี

เกรเดียนท์บูตทรี (gradient boosted trees) เป็นการเรียนรู้เครื่องสำหรับการจำแนกประเภทและการถดถอยที่ผลิตแบบจำลองการเรียนรู้ที่แข็งแกร่งจากการรวมกันของแบบจำลองการเรียนรู้ที่อ่อน โดยทั่วไปเป็นแบบจำลองต้นไม้ตัดสินใจ โดยต้นไม้ตัดสินใจแต่ละต้นจะเชื่อมต่อกัน โดยแต่ละต้นจะพยายามลดข้อผิดพลาดหรือสิ่งตกค้างของต้นไม้ต้นก่อนหน้า แบบจำลองตัวสุดท้ายจะใช้ผลลัพธ์ของแต่ละขั้นตอนเพื่อเกิดแบบจำลองการเรียนรู้ที่มีประสิทธิภาพ และมีความแม่นยำสูง (Natekin & Knoll, 2013)

## กรอบแนวคิดการวิจัย



ภาพ 2 กรอบแนวคิดการวิจัย

## สมมติฐานการวิจัย

การประยุกต์ใช้เทคนิคการเรียนรู้เครื่องร่วมกับการประมวลผลภาพเพื่อจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสาร 5 สายพันธุ์ มีประสิทธิภาพในการจำแนกถูกต้องมากกว่าร้อยละ 85

## เครื่องมือที่ใช้ในการวิจัย

ในการดำเนินการวิจัยครั้งนี้ได้พัฒนาซอฟต์แวร์ขึ้นมาเองภายในภาษา Python รุ่น 3.1.11 ทำงานภายใต้ระบบปฏิบัติการ Microsoft Windows 11 บนเครื่อง HP Probook 440 G8 Notebook PC ที่ใช้หน่วยประมวลผล 11th Intel(R) Core(TM) i5-1135G7 @ 2.40GHz หน่วยความจำ 8GB

## เครื่องมือที่ใช้ในการวิเคราะห์ข้อมูล

สำหรับเครื่องมือที่ใช้ในการวิเคราะห์ข้อมูลครั้งนี้ได้แก่

### ค่าความถูกต้อง (accuracy)

ค่าความถูกต้องเป็นเครื่องมือที่ใช้วัดภาพรวมความถูกต้องในการทำนาย โดยสูตรคำนวณอัตราร้อยละค่าความถูกต้อง (percentage accuracy) คือ (Grandini et al., 2020)

$$\text{percentage accuracy} = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \times 100 \quad (2)$$

เมื่อ  $T_p$  สิ่งที่ทำนายว่า “จริง” และ มีค่าเป็น “จริง”

$T_n$  สิ่งที่ทำนายว่า “ไม่จริง” และ มีค่าเป็น “ไม่จริง”

สิ่งที่ทำนายว่า “จริง” และ มีค่าเป็น “ไม่จริง”

$F_n$  สิ่งที่ทำนายว่า “ไม่จริง” และ มีค่าเป็น “จริง”

### ค่าความแม่นยำ (precision)

ค่าความแม่นยำเป็นเครื่องมือที่ใช้วัดอัตราส่วนของการทำนายสิ่งที่ต้องการได้ถูกต้องกับการทำนายสิ่งต้องการทั้งหมด (รวมทั้งการทำนายถูกและผิด) สูตรคำนวณอัตราร้อยละค่าความแม่นยำ (percentage precision)

คือ (Grandini et al., 2020)

$$\text{percentage precision} = \frac{T_p}{T_p + F_p} \times 100 \quad (3)$$

### ค่าความไว (recall)

ค่าความไวเป็นเครื่องมือที่ใช้วัดอัตราส่วนของการทำนายสิ่งที่ต้องการได้ถูกต้องกับจำนวนของสิ่งที่ต้องการทำนายทั้งหมด ค่าความไวจะมีความสำคัญมากในกรณีที่เราคิดว่าสิ่งที่เราคาดการณ์ผิดพลาดไปมีความหมายยิ่ง เช่น หากทำนายว่าไม่เกิดไฟไหม้แต่เกิดไฟไหม้ขึ้นมา มีความเสียหายมากกว่าทำนายว่าเกิดไฟไหม้แต่ไม่เกิดเหตุขึ้น สูตรคำนวณอัตราร้อยละค่าความไว (percentage recall) คือ (Kumyaito, Tamee & Sittijuk, 2023)

$$\text{percentage recall} = \frac{T_p}{T_p + F_n} \times 100 \quad (4)$$

### ค่า F1-Score

ค่า F1-Score หรือบางครั้งอาจเรียกว่า ค่า F-Measure เป็นค่าเฉลี่ยฮาร์โมนิก (Harmonic mean) ของค่าความแม่นยำและค่าความไว สูตรคำนวณอัตราร้อยละค่า F1-Score (percentage F1-Score) คือ (Grandini et al., 2020)

$$\text{percentage F1-Score} = \frac{2 \times \text{perc. of precision} \times \text{perc. of recall}}{\text{perc. of precision} + \text{perc. of recall}} \quad (5)$$

หมายเหตุ *perc.* ในที่นี้หมายถึง *percentage*

### ค่าสัมประสิทธิ์แคปปา (Cohen Kappa's Coefficient)

ค่าสัมประสิทธิ์แคปปาหรือบางครั้งอาจเรียกว่าค่าแคปปาเป็นวิธีที่ใช้ในการวัดความสอดคล้องระหว่างค่าที่ทำนายจากสองผู้ประเมิน (หรือมากกว่า) เหมาะสมสำหรับงานที่เกี่ยวข้องกับการจำแนกประเภท (classification) สำหรับอัตราร้อยละค่าสัมประสิทธิ์แคปปา (percentage of Cohen Kappa's coefficient) มีค่าตั้งแต่ -100 ไปจนถึง 100 โดยมีความหมายว่า หากค่าดังกล่าวมีค่าใกล้ -100 แสดงว่าค่าที่ทำนายจากสองผู้ประเมินไม่สอดคล้องกัน หากค่าดังกล่าวมีค่าใกล้ 0 แสดงว่าค่าที่ทำนายจากสองผู้ประเมินสอดคล้องโดยบังเอิญ แต่หากค่าดังกล่าว

เข้าใกล้ 100 แสดงว่าค่าที่ทำนายทั้งคู่มีความสอดคล้องกัน สูตรคำนวณอัตราร้อยละค่าสัมประสิทธิ์แคปปา คือ

$$\text{percentage } \kappa = \frac{P_o - P_e}{1 - P_e} \times 100 \quad (6)$$

เมื่อ  $P_o$  คือ ความสัมพันธ์จากการทำนายที่เกิดขึ้นจริง (observed agreement) และ  $P_e$  คือ ความสัมพันธ์จากการทำนายที่คาดหวัง (expected agreement) และ  $\kappa$  คือ ค่าสัมประสิทธิ์แคปปา (Cohen, 1960)

### ข้อมูลในการทำวิจัย

ข้อมูลในการทำวิจัยเป็นรูปภาพของเมล็ดข้าวสาร 5 สายพันธุ์ จำนวนสายพันธุ์ละ 15,000 ภาพ รวม 75,000 ภาพ โดยเป็นภาพข้าวสารเมล็ดเดี่ยวพื้นหลังสีดำที่บันทึกในรูปแบบ JPEG สี ความละเอียด 250x250 จุดภาพ (pixels) โดยเป็นข้อมูลสาธารณะสามารถดาวน์โหลดได้จาก <https://www.muratkoklu.com>

### วิธีดำเนินการวิจัย

1. ทำการพัฒนาซอฟต์แวร์ภายในภาษา Python เพื่อลดสัญญาณรบกวนที่ปรากฏในภาพถ่ายเมล็ดข้าวสาร
2. ทำการพัฒนาซอฟต์แวร์ภายในภาษา Python เพื่อประมวลผลภาพเมล็ดข้าวสารด้วยการตรวจหาขอบ

ภาพด้วยวิธีแค่นี้ การตรวจหาขอบภาพด้วยวิธีโซเบล การตรวจหาสัน การตรวจหาลายผิว การปรับฮิสโทแกรมให้เท่ากัน เพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ และเพิ่มคุณภาพของภาพด้วยการพราเอาส์เซียน

3. ทำการพัฒนาซอฟต์แวร์ภายในภาษา Python เพื่อสร้างตัวแบบเทคนิคการเรียนรู้เครื่อง 6 เทคนิค ได้แก่ ต้นไม้ตัดสินใจ นาอ์ฟเบส เพื่อนบ้านใกล้ที่สุด โครงข่ายประสาทประดิษฐ์ เกรเดียนท์บูตทรี และซัพพอร์ตเวกเตอร์แมชชีน

4. ทดสอบเบื้องต้นเพื่อหาค่าเคที่เหมาะสมสำหรับการตรวจสอบไขว้เคโพลด์ โดยพิจารณาจากค่าเคเท่ากับ 5 10 15 และ 20 ด้วยเทคนิคการเรียนรู้เครื่องที่ไม่ใช้เวลาสูงนักได้แก่ ต้นไม้ตัดสินใจและนาอ์ฟเบส

5. ทำการฝึกเทคนิคการเรียนรู้เครื่องทั้ง 6 เทคนิคด้วยภาพที่มีการลดสัญญาณรบกวนและภาพที่ผ่านการประมวลผลภาพแบบต่าง ๆ ทั้ง 7 วิธี (รวมตัวแบบที่ใช้ในการจำแนกพันธุ์ข้าว 48 ตัวแบบ) เพื่อการจำแนกพันธุ์ข้าวจากภาพถ่ายเมล็ดข้าวสารโดยใช้วิธีการฝึกแบบการตรวจสอบไขว้เคโพลด์เมื่อเคมีค่าเท่ากับ 10 สำหรับทุกวิธีการเรียนรู้เครื่อง โดยมีการตั้งพารามิเตอร์สำหรับเทคนิคการเรียนรู้เครื่องทั้ง 6 ดังตาราง 1

6. ทดสอบประสิทธิภาพในการจำแนกพันธุ์ข้าวของตัวแบบการจำแนกทั้ง 48 ตัวแบบ



(ก)

(ข)

(ค)

(ง)

(จ)

ภาพ 3 ตัวอย่างภาพเมล็ดข้าวสารที่ใช้ในงานวิจัย (ก) คาราก้าดาก (ข) หอมมะลิ (ค) ยิปชาลา (ง) บาสมาทิ (จ) อาโบริโอ

## ตาราง 1

การกำหนดค่าพารามิเตอร์ของเทคนิคการเรียนรู้เครื่อง

| การเรียนรู้เครื่อง     | พารามิเตอร์        |            |
|------------------------|--------------------|------------|
| ต้นไม้ตัดสินใจ         | criterion          | Gain ratio |
|                        | confidence         | 0.3        |
|                        | maximal depth      | 10         |
| นาอ็อฟเบสส์            | Laplace correction |            |
| เพื่อนบ้านใกล้ที่สุด   | K                  | 5          |
| โครงข่ายประสาทประดิษฐ์ | epochs             | 10         |
|                        | batch_size         | 32         |
|                        | verbose            | 1          |
| เกรเดียนท์บูตทรี       | number of trees    | 50         |
|                        | maximal depth      | 5          |
|                        | learning rate      | 0.1        |
| ซัพพอร์ทเวกเตอร์       | svm type           | C-SVC      |
| แมชชีน                 | kernel             | linear     |

## ผลการวิจัย

### ส่วนที่ 1 ขั้นตอนการลดสัญญาณรบกวนที่ปรากฏในภาพเมล็ดข้าวสาร

ผลการวิจัยในส่วนนี้ทำให้ได้ภาพที่มีพื้นหลังสีดำสนิท ช่วยให้การฝึกตัวแบบเพื่อการจำแนกมีประสิทธิภาพที่ดีมากขึ้น ดังภาพ 4

### ส่วนที่ 2 ขั้นตอนการประมวลผลภาพ

2.1 ผลการประมวลผลภาพด้วยการตรวจหาขอบภาพด้วยวิธีแคนนี่ ดังภาพ 5

2.2 ผลการประมวลผลภาพด้วยวิธีโซเบล ดังภาพ 6


2.3 ผลการประมวลผลภาพด้วยการตรวจหาเส้นดังภาพ 7

2.4 ผลการประมวลผลภาพด้วยการตรวจหาลายผิว ดังภาพ 8

2.5 ผลการประมวลผลภาพด้วยการปรับฮิสโทแกรมให้เท่ากัน ดังภาพ 9

2.6 ผลการประมวลผลภาพด้วยการเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ ดังภาพ 10


2.7 ผลการประมวลผลภาพด้วยการเพิ่มคุณภาพของภาพด้วยการพรา่เกาส์เซียน ดังภาพ 11




(ก)

(ข)


ภาพ 4 ตัวอย่างภาพเมล็ดข้าวสาร (ก) ภาพเมล็ดข้าวสารต้นฉบับ (ข) การตรวจพบสัญญาณรบกวนที่ภาพพื้นหลัง




ภาพ 5 การประมวลผลภาพเมล็ดข้าวสารด้วยการตรวจหาขอบภาพด้วยวิธีแคนนี่




ภาพ 6 การประมวลผลภาพเมล็ดข้าวสารด้วยการตรวจหาขอบภาพด้วยวิธีโซเบล




ภาพ 7 การประมวลผลภาพเมล็ดข้าวสารด้วยการตรวจหาเส้น




ภาพ 8 การประมวลผลภาพเมล็ดข้าวสารด้วยการตรวจหาลายผิว



ภาพ 9 การประมวลผลภาพเมล็ดข้าวสารด้วยการปรับฮิสโทแกรมให้เท่ากัน



ภาพ 10 การประมวลผลภาพเมล็ดข้าวสารด้วยการเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ



ภาพ 11 การประมวลผลภาพเมล็ดข้าวสารด้วยการเพิ่มคุณภาพของภาพด้วยตัวกรองพราเอาส์เซียน

### ส่วนที่ 3 การหาค่าเคที่เหมาะสมสำหรับการตรวจสอบไขว้เคโฟลด์

ผลการวิจัยในส่วนนี้ต้องการทดสอบเบื้องต้นเพื่อหาค่าเคที่เหมาะสมสำหรับการตรวจสอบไขว้เคโฟลด์ โดยพิจารณาทั้งในด้านความถูกต้องและเวลาที่ใช้ในการประมวลผล ทั้งนี้ ต้องการพิจารณาค่าเคที่ทำให้ได้ค่าความถูกต้องสูงแต่ต้องไม่ใช้เวลาสูงเกินไป เพราะแบบจำลองการเรียนรู้เครื่องเพื่อการจำแนกประเภทบางเทคนิคใช้เวลาในการประมวลผลมาก การทดลองจะดำเนินการเบื้องต้นด้วยวิธีการเรียนรู้เครื่องที่ใช้เวลาในการประมวลผลไม่ได้สูงมากได้แก่ขั้นตอนวิธีต้นไม้ตัดสินใจและนาอิวเบสทำการจำแนกประเภทจากภาพถ่ายเมล็ดข้าวที่มีการลดสัญญาณ

รบกวนในตาราง 2

จากตาราง 2 พบว่า เมื่อเพิ่มค่าเคจะทำให้ความถูกต้องในการจำแนกประเภทจากภาพถ่ายเมล็ดข้าวที่มีการลดสัญญาณรบกวนในภาพสูงขึ้นทั้งสองวิธีการเรียนรู้เครื่อง แต่ก็ใช้เวลาในการจำแนกมากขึ้นตามมา ผลที่ได้แสดงให้เห็นว่าเมื่อค่าเคเพิ่มจาก 5 เป็น 10 ความถูกต้องในการจำแนกของเทคนิคการเรียนรู้เครื่องทั้งสองวิธี เพิ่มขึ้นเป็นสัดส่วนที่มากกว่าเมื่อเทียบกับกรณีที่ค่าเคเพิ่มจาก 10 เป็น 15 และ จาก 15 เป็น 20 แต่เวลาที่ใช้ในการจำแนกเพิ่มขึ้นในสัดส่วนที่ใกล้เคียงกัน ดังนั้นเพื่อความเหมาะสมในการดำเนินการวิจัยจะเลือกค่าเคเท่ากับ 10 ในการตรวจสอบไขว้เคโฟลด์

## ส่วนที่ 4 ขั้นตอนการจำแนกภาพ

ในการใช้โปรแกรมที่พัฒนาขึ้นมาเพื่อจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสารโดยประยุกต์ใช้เทคนิคการเรียนรู้เครื่อง 6 เทคนิคได้แก่ ต้นไม้ตัดสินใจ นาอ็ฟเบส เพื่อนบ้านใกล้ที่สุด โครงข่ายประสาทประดิษฐ์ เกรเดียนท์บูตทรี และซัพพอร์ตเวกเตอร์แมชชีน รวมกับภาพที่ไม่ผ่านการประมวลผลภาพและผ่านการประมวลผลภาพ 7 วิธี ได้แก่

การตรวจหาขอบภาพด้วยวิธีแคนนี่ การตรวจหาขอบภาพด้วยวิธีโซเบล การตรวจหาเส้น การตรวจหาลายผิว การปรับฮิสโทแกรมให้เท่ากัน การเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ และการเพิ่มคุณภาพของภาพด้วยการพราเกาส์เซียน ได้ผลลัพธ์ในการจำแนกดังแสดงในตาราง 3-ตาราง 10

### ตาราง 2

การหาค่า เค ที่เหมาะสมด้วยเทคนิคการเรียนรู้เครื่องต้นไม้ตัดสินใจและนาอ็ฟเบส

| การเรียนรู้เครื่อง | เค | ความถูกต้อง | เวลา(วินาที) |
|--------------------|----|-------------|--------------|
| ต้นไม้ตัดสินใจ     | 5  | 94.61%      | 11.86        |
|                    | 10 | 95.06%      | 25.64        |
|                    | 15 | 95.07%      | 39.24        |
|                    | 20 | 95.20%      | 61.86        |
| นาอ็ฟเบส           | 5  | 88.38%      | 3.78         |
|                    | 10 | 89.41%      | 4.61         |
|                    | 15 | 89.74%      | 5.47         |
|                    | 20 | 89.98%      | 5.95         |

### ตาราง 3

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ที่จำแนกประเภทจากภาพถ่ายเมล็ดข้าวที่มีการลดสัญญาณรบกวนในภาพ

| แบบจำลองการจำแนกประเภท | ความถูกต้อง | ความแม่นยำ | ความไว | F1-Score | สัมประสิทธิ์แคปปา | เวลา (วินาที) |
|------------------------|-------------|------------|--------|----------|-------------------|---------------|
| ต้นไม้ตัดสินใจ         | 95.09%      | 95.09%     | 95.09% | 95.09%   | 93.86%            | 35.14         |
| นาอ็ฟเบส               | 89.41%      | 89.47%     | 89.41% | 89.37%   | 86.76%            | 4.29          |
| เพื่อนบ้านใกล้ที่สุด   | 95.09%      | 95.11%     | 95.09% | 95.08%   | 93.86%            | 10.14         |
| โครงข่ายประสาทประดิษฐ์ | 97.65%      | 97.65%     | 97.65% | 97.65%   | 97.06%            | 456.78        |
| เกรเดียนท์บูตทรี       | 97.20%      | 97.20%     | 97.20% | 97.20%   | 96.50%            | 3256.41       |
| ซัพพอร์ตเวกเตอร์แมชชีน | 97.51%      | 97.51%     | 97.51% | 97.51%   | 96.89%            | 141.10        |

#### ตาราง 4

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการตรวจหาขอบภาพด้วยวิธีแคนนี่

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์<br>แคปปา | เวลา<br>(วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-----------------------|------------------|
| ต้นไม้ตัดสินใจ         | 95.15%        | 95.15%        | 95.15%        | 95.14%        | 93.93%                | 168.97           |
| นาอ์ฟเบส์              | 88.13%        | 88.04%        | 88.13%        | 87.94%        | 85.16%                | <b>3.68</b>      |
| เพื่อนบ้านใกล้ที่สุด   | 96.92%        | 96.93%        | 96.92%        | 96.92%        | 96.15%                | 32.05            |
| โครงข่ายประสาทประดิษฐ์ | <b>97.72%</b> | <b>97.72%</b> | <b>97.72%</b> | <b>97.72%</b> | <b>97.15%</b>         | 738.87           |
| เกรเดียนท์บูตทรี       | 97.15%        | 97.15%        | 97.15%        | 97.15%        | 96.44%                | 5886.94          |
| ซัพพอร์ตเวกเตอร์แมชชีน | 97.61%        | 97.61%        | 97.61%        | 97.61%        | 97.02%                | 413.03           |

#### ตาราง 5

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการตรวจหาขอบภาพด้วยวิธีโซเบล

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์<br>แคปปา | เวลา<br>(วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-----------------------|------------------|
| ต้นไม้ตัดสินใจ         | 95.55%        | 95.55%        | 95.55%        | 95.54%        | 94.44%                | 60.29            |
| นาอ์ฟเบส์              | 84.76%        | 84.85%        | 84.76%        | 84.40%        | 80.95%                | <b>4.91</b>      |
| เพื่อนบ้านใกล้ที่สุด   | 96.30%        | 96.32%        | 96.30%        | 96.29%        | 95.37%                | 13.15            |
| โครงข่ายประสาทประดิษฐ์ | 98.56%        | 98.56%        | 98.56%        | 98.56%        | 98.20%                | 722.48           |
| เกรเดียนท์บูตทรี       | 97.76%        | 97.76%        | 97.75%        | 97.75%        | 97.20%                | 9168.98          |
| ซัพพอร์ตเวกเตอร์แมชชีน | <b>98.68%</b> | <b>98.68%</b> | <b>98.68%</b> | <b>98.68%</b> | <b>98.35%</b>         | 136.21           |

#### ตาราง 6

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการตรวจหาเส้น

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์<br>แคปปา | เวลา<br>(วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-----------------------|------------------|
| ต้นไม้ตัดสินใจ         | 94.79%        | 94.78%        | 94.78%        | 94.78%        | 93.48%                | 35.72            |
| นาอ์ฟเบส์              | 88.81%        | 88.73%        | 88.81%        | 88.69%        | 86.01%                | <b>5.24</b>      |
| เพื่อนบ้านใกล้ที่สุด   | 95.52%        | 95.53%        | 95.52%        | 95.52%        | 94.40%                | 11.21            |
| โครงข่ายประสาทประดิษฐ์ | <b>97.26%</b> | <b>97.26%</b> | <b>97.26%</b> | <b>97.26%</b> | <b>96.57%</b>         | 740.49           |
| เกรเดียนท์บูตทรี       | 96.81%        | 96.81%        | 96.81%        | 96.81%        | 96.01%                | 2639.67          |
| ซัพพอร์ตเวกเตอร์แมชชีน | 96.45%        | 96.45%        | 96.44%        | 96.44%        | 95.56%                | 207.60           |

## ตาราง 7

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการตรวจหาลายนิ้ว

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์<br>แคปปา | เวลา<br>(วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-----------------------|------------------|
| ต้นไม้ตัดสินใจ         | 92.94%        | 92.93%        | 92.93%        | 92.93%        | 91.17%                | 42.02            |
| นาอ็อฟเบสส์            | 85.53%        | 85.50%        | 85.53%        | 85.41%        | 81.92%                | <b>4.16</b>      |
| เพื่อนบ้านใกล้ที่สุด   | 94.39%        | 94.45%        | 94.39%        | 94.37%        | 92.98%                | 9.64             |
| โครงข่ายประสาทประดิษฐ์ | <b>96.95%</b> | <b>96.96%</b> | <b>96.95%</b> | <b>96.94%</b> | <b>96.18%</b>         | 692.81           |
| เกรเดียนท์บูตทรี       | 96.24%        | 96.24%        | 96.24%        | 96.23%        | 95.30%                | 4845.29          |
| ซัพพอร์ตเวกเตอร์แมชชีน | 95.42%        | 95.42%        | 95.42%        | 95.41%        | 94.28%                | 276.62           |

## ตาราง 8

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการปรับฮิสโทแกรมให้เท่ากัน

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์<br>แคปปา | เวลา<br>(วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-----------------------|------------------|
| ต้นไม้ตัดสินใจ         | 93.47%        | 93.46%        | 93.46%        | 93.45%        | 91.83%                | 60.40            |
| นาอ็อฟเบสส์            | 87.04%        | 87.10%        | 87.04%        | 86.98%        | 83.80%                | <b>4.25</b>      |
| เพื่อนบ้านใกล้ที่สุด   | 95.47%        | 95.65%        | 95.57%        | 95.57%        | 93.22%                | 9.77             |
| โครงข่ายประสาทประดิษฐ์ | <b>98.06%</b> | <b>98.06%</b> | <b>98.06%</b> | <b>98.06%</b> | <b>97.57%</b>         | 507.44           |
| เกรเดียนท์บูตทรี       | 96.79%        | 96.79%        | 96.79%        | 96.79%        | 95.99%                | 4869.08          |
| ซัพพอร์ตเวกเตอร์แมชชีน | 96.12%        | 96.12%        | 96.12%        | 96.12%        | 95.16%                | 258.16           |

## ตาราง 9

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์<br>แคปปา | เวลา<br>(วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-----------------------|------------------|
| ต้นไม้ตัดสินใจ         | 93.74%        | 93.74%        | 93.73%        | 93.73%        | 92.18%                | 60.86            |
| นาอ็อฟเบสส์            | 87.39%        | 87.44%        | 87.39%        | 87.32%        | 84.23%                | <b>4.21</b>      |
| เพื่อนบ้านใกล้ที่สุด   | 95.25%        | 95.32%        | 95.25%        | 95.24%        | 94.06%                | 9.25             |
| โครงข่ายประสาทประดิษฐ์ | <b>97.47%</b> | <b>97.47%</b> | <b>97.47%</b> | <b>97.47%</b> | <b>96.84%</b>         | 402.98           |
| เกรเดียนท์บูตทรี       | 96.88%        | 96.88%        | 96.88%        | 96.87%        | 96.10%                | 5177.58          |
| ซัพพอร์ตเวกเตอร์แมชชีน | 95.65%        | 95.66%        | 95.70%        | 95.65%        | 94.56%                | 256.39           |

## ตาราง 10

ผลการทดสอบประสิทธิภาพของแบบจำลองต่าง ๆ ร่วมกับการประมวลผลภาพการเพิ่มคุณภาพของภาพด้วยการพราวด์เกาส์เซียน

| แบบจำลองการจำแนกประเภท | ความถูกต้อง   | ความแม่นยำ    | ความไว        | F1-Score      | สัมประสิทธิ์แคปปา | เวลา (วินาที) |
|------------------------|---------------|---------------|---------------|---------------|-------------------|---------------|
| ต้นไม้ตัดสินใจ         | 93.53%        | 93.51%        | 93.52%        | 93.52%        | 91.92%            | 49.53         |
| นาอ์ฟเบสส์             | 85.63%        | 85.94%        | 85.63%        | 85.63%        | 82.03%            | <b>3.99</b>   |
| เพื่อนบ้านใกล้ที่สุด   | 82.54%        | 82.91%        | 82.54%        | 82.65%        | 78.17%            | 9.45          |
| โครงข่ายประสาทประดิษฐ์ | 89.77%        | 89.79%        | 89.77%        | 89.69%        | 87.21%            | 448.66        |
| เกรเดียนท์บูตทรี       | 96.83%        | 96.82%        | 96.82%        | 96.82%        | 96.03%            | 4992.54       |
| ซัพพอร์ตเวกเตอร์แมชชีน | <b>97.03%</b> | <b>97.03%</b> | <b>97.03%</b> | <b>97.03%</b> | <b>96.29%</b>     | 213.79        |

หมายเหตุ: ข้อความที่เป็น ตัวหนา แสดงถึงค่าที่สูงที่สุดของความถูกต้อง (accuracy) ความแม่นยำ (precision) ความไว (recall) ค่า F1-score และสัมประสิทธิ์แคปปา พร้อมกับเวลาที่ใช้ในการจำแนกที่เร็วที่สุด (วินาที)

### การอภิปรายผล

งานวิจัยนี้ได้วัดประสิทธิภาพของหลายแบบจำลองในการประยุกต์ใช้การประมวลผลภาพร่วมกับวิธีการเรียนรู้เครื่องเพื่อจำแนกประเภทพันธุ์ข้าวจากภาพถ่ายขนาด 250x250 พิกเซล ของเมล็ดข้าว 5 ชนิด พบว่า แบบจำลองการจำแนกประเภทที่ให้ผลประสิทธิภาพดีที่สุด คือ การใช้การประมวลผลภาพแบบการตรวจจับขอบด้วยวิธีการโซเบลร่วมกับเทคนิคการจำแนกประเภทซัพพอร์ตเวกเตอร์แมชชีน โดยให้ค่าความถูกต้องถึงร้อยละ 98.68 ค่าความแม่นยำร้อยละ 98.67 ค่าความไวร้อยละ 98.67 ค่าเอฟ-หนึ่ง สกอร์ร้อยละ 98.67 ค่าสัมประสิทธิ์แคปปา ร้อยละ 98.35 ซึ่งสอดคล้องกับงานวิจัยที่เกี่ยวข้องของ Zareiforush et al. (2016) ที่ให้ค่าความถูกต้อง ร้อยละ 98.72 ในการจำแนกประเภทพันธุ์ข้าว 4 ชนิด และงานวิจัยของ Cinar and Köklü (2022) ที่ได้ค่าความถูกต้องถึงร้อยละ 99.91 ในการจำแนกประเภทพันธุ์ข้าว 5 ชนิด โดยใช้จำนวนคุณลักษณะที่มากกว่าในการจำแนก (106 คุณลักษณะเทียบกับ 32 คุณลักษณะในงานวิจัยนี้) ซึ่งชี้ให้เห็นว่าคุณลักษณะหลักในการจำแนกพันธุ์ข้าวจากภาพถ่ายคือรูปร่างของเมล็ดข้าวสาร ทั้งนี้หากต้องการให้ความแม่นยำในการจำแนกสูงขึ้นการปรับพารามิเตอร์ของแบบจำลองอาจช่วยในการเพิ่มประสิทธิภาพในการจำแนก

### ประเภทพันธุ์ข้าวได้

อย่างไรก็ตามแม้ว่าแบบจำลองการจำแนกประเภทด้วยเทคนิคดังกล่าวจะให้ผลลัพธ์ที่มีประสิทธิภาพสูงสุด แต่ยังคงมีข้อจำกัดด้านการใช้เวลาในการประมวล ซึ่งใช้เวลาสูงถึง 136.21 วินาที ในขณะที่แบบจำลองที่มีการใช้เทคนิคการจำแนกประเภทแบบเพื่อนบ้านใกล้ที่สุดร่วมกับการประมวลผลภาพไม่ว่าจะเป็นการตรวจหาขอบภาพด้วยวิธีโซเบล การตรวจหาเส้น การตรวจหาลายผิว การปรับฮิสโทแกรมให้เท่ากัน และการเพิ่มคุณภาพของภาพด้วยตัวกรองลาปลาซ ให้ความแม่นยำในการจำแนกต่ำกว่าเล็กน้อย แต่ใช้เวลาน้อยกว่ามาก เพียงประมาณ 9.25 ถึง 13.15 วินาทีเท่านั้น ทั้งนี้ในการเลือกแบบจำลองที่เหมาะสมเพื่อดำเนินการจำแนกขึ้นอยู่กับเงื่อนไขในการพิจารณาว่าสนใจประสิทธิภาพหรือเวลาเป็นหลัก

### ข้อเสนอแนะ

ในการเพิ่มประสิทธิภาพการจำแนกประเภทของเมล็ดข้าวในอนาคต อาจเลือกใช้วิธีการประมวลผลภาพอื่นที่เกี่ยวข้องกับรูปร่างหรือการใช้การประมวลผลภาพหลายเทคนิครวมกัน ร่วมกับการปรับแต่งพารามิเตอร์ของวิธีการเรียนรู้เครื่องอย่างละเอียดเพื่อเพิ่มประสิทธิภาพทั้งในด้าน

ความแม่นยำในการจำแนกและความรวดเร็วในการประมวลผล และหากได้ข้อมูลที่เป็นภาพถ่ายของเมล็ดข้าวสารของสายพันธุ์ที่เป็นที่นิยมบริโภคในประเทศไทย การทำการวิจัย

ในลักษณะนี้เพิ่มเติมอาจจะมีประโยชน์กับท้องถิ่นมากขึ้นในอนาคต



## References

- Abuelelwa, M. H., & Abu-Naser, S. S. (2024). Classification of rice using deep learning. *International Journal of Academic Information Systems Research (IJAIRS)*, 8(4), 26–36. Retrieved from <http://ijeais.org/wp-content/uploads/2024/4/IJAISR240404.pdf>
- Aki, O., Güllü, A., & Uçar, E. (2015). Classification of rice grains using image processing and machine learning techniques. *Proceeding of International Scientific Conference* (pp. 352-354). Gabrovo: Technical University of Gabrovo.
- Armi, L., & Fekri-Ershad, S. (2019). Texture image analysis and texture classification methods - A Review. *International Online Journal of Image Processing and Pattern Recognition*, 2(1), 1-29. Retrieved from <https://arxiv.org/pdf/1904.06554#:~:text=This%20article%20has%20been%20compiled,vector%20machines%2C%20and%20so%20on.>
- Chunwitthayathira, S. (2014). Image registration and arrangement techniques. *EAU Heritage Journal Science and Technology*, 6(2), 24–29. retrieved from <https://he01.tci-thaijo.org/index.php/EAUHJSci/article/view/25719> (in Thai)
- Cinar, I., & Köklü, M. (2019). Classification of rice varieties using artificial intelligence methods. *International Journal of Intelligent Systems and Applications in Engineering (IJISAE)*, 7(3), 188–194. <https://doi.org/10.18201/ijisae.2019355381>
- Cinar, I., & Köklü, M. (2021). Determination of effective and specific physical features of rice varieties by computer vision in exterior quality inspection. *Selcuk Journal of Agriculture and Food Sciences (SJAFS)*, 35(3), 229-243. <https://doi.org/10.15316/SJAFS.2021.252>
- Cinar, I., Köklü, M., & Taspinar, Y. S. (2021). Classification of Rice Varieties with Deep Learning Methods. *Computer and Electronics in Agriculture*, 187, 16285. <https://doi.org/10.1016/j.compag.2021.106285>
- Cinar, I., & Köklü, M. (2022). Identification of rice varieties using machine learning algorithms. *Journal of Agricultural Sciences (Tarim Bilimleri Dergisi)*, 28(2), 307-325. <https://doi.org/10.15832/ankutbd.862482>
- Cohen, J. (1960). A coefficient of agreement for nominal scales. *Educational and psychological measurement*, 20(1), 37-46. <https://doi.org/10.1177/001316446002000104>

- Farid, D., Rahman, M. & Al-Mamun, M. (2014). Efficient and scalable multi-class classification using naïve Bayes tree. *Proceeding of 2014 International Conference on Informatics, Electronics and Vision (ICIEV 2014)* (pp. 1-4). Dhaka: IEEE.
- Gonzalez, R. C., & Woods, R. E. (1992). *Digital image processing*. USA: Addison-Wesley Publishing Company.
- Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for multi-class classification: An overview. *arXiv*, 2008, 05756v1, Retrieved from <https://arxiv.org/abs/2008.05756>.
- Jameel, S. A., & Mohamed Shanavas, A. R. (2015). Implementation of improved gaussian filter algorithm for retinal fundus images. *International Journal of Computer Applications*, 132(8), 1-4. <https://doi.org/10.5120/ijca2015907489>.
- Kullimratchai, P. (2014). Image retrieval fundamentals. *EAU Heritage Journal Science and Technology*, 7(2), 40–46. retrieved from <https://he01.tci-thaijo.org/index.php/EAUHJSci/article/view/25546> (in Thai)
- Kumyaito, N., Tamee, K., & Sittijuk, P. (2023). Artificial intelligence platform on semantic knowledge base for recommending elderly with chronic diseases care. *EAU Heritage Journal Science and Technology*, 17(2), 120–137. retrieved from <https://he01.tci-thaijo.org/index.php/EAUHJSci/article/view/259516> (in Thai)
- Microsoft. (2024). *One-vs-All Multiclass*. *Azure machine learning*. Retrieved from <https://learn.microsoft.com/en-us/azure/machine-learning/component-reference/one-vs-all-multiclass?view=azureml-api-2>.
- Natekin, A., & Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in Neurorobotics*, 7, 21. <https://doi.org/10.3389/fnbot.2013.00021>
- NV5 Geospatial Software. (2023). *Apply laplacian filters*. Retrieved from <https://www.nv5geospatialsoftware.com/docs/LaplacianFilters.html>.
- Patel, O., Maravi, Y. P. S., & Sharma, S. (2013). A comparative study of histogram equalization based image enhancement techniques for brightness preservation and contrast enhancement. *Signal & Image Processing: An International Journal*, 4, 11-25. <https://doi.org/10.5121/sipij.2013.4502>.
- Reddy, R. P. K., Nagaraju, C., & Reddy, I. R. (2016). Canny scale edge detection. *International Journal of Engineering Trends and Technology*, x(y), 1-4. <https://doi.org/10.14445/22315381/IJETT-ICGTETM-N3/ICGTETM-P121>
- Rexce, J., & Usha Kingsly Devi, K. (2017). Classification of milled rice using image processing. *International Journal of Scientific & Engineering Research*, 8(2), 10-14.

- Siharad, D., & Sookprasert, A. (2024). Improving performance of using machine learning techniques and application for perceiving tourists' hotel staying behaviors. *EAU Heritage Journal Science and Technology (Online)*, 18(1), 161–175. retrieved from <https://he01.tci-thaijo.org/index.php/EAUHJSci/article/view/264174> (in Thai)
- Sinsomboonthong, S. (2017). *Data mining 1: Discovering knowledge in data* (2nd ed.). Bangkok: Chamchuree Products Co., Ltd. (in Thai)
- Shokouh, G. S., Baptiste, M., Xu, B., & Montesinos, P. (2021). Ridge detection by image filtering techniques: A review and an objective analysis. *Pattern Recognition and Image Analysis*, 31, 551-570. <https://doi.org/10.1134/S1054661821030226>
- Tanwong, K., Suksawang, P., & Punsawad, Y. (2019). Development of rice grain phenotype quality verification Ssystem using machine learning. *EAU Heritage Journal Science and Technology*, 13(1), 76–94. retrieved from <https://he01.tci-thaijo.org/index.php/EAUHJSci/article/view/177478> (in Thai)
- Thai Rice Exporters Association. (2024). *F.O.B. Prices*. Retrieved from <http://www.thairiceexporters.or.th/> (in Thai)
- Zareiforush, H., Minaei, S., Alizadeh, M. R., & Banaka, A. (2016). Qualitative classification of milled rice grains using computer vision and metaheuristic techniques. *Journal of Food Science Technology*, 53(1), 118-131. <https://doi.org/10.1007/s13197-015-1947-4>

