

การจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสารด้วยวิธีการตรวจหาวัตถุ

วุฒิชัย วัชรารัตน์¹ เจษฎา ตัณฑนุช^{2*}

^{1,2*}สาขาวิชาคณิตศาสตร์ สำนักวิชาวิทยาศาสตร์ มหาวิทยาลัยเทคโนโลยีสุรนารี, นครราชสีมา, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : jessada@g.sut.ac.th

รับต้นฉบับ : 25 เมษายน 2566; รับผิดชอบต่อฉบับแก้ไข : 28 พฤษภาคม 2566; ตอบรับบทความ : 29 พฤษภาคม 2566

เผยแพร่ออนไลน์ : 27 ธันวาคม 2566

บทคัดย่อ

งานวิจัยนี้ได้ประยุกต์ใช้วิธีการตรวจหาวัตถุด้วยตัวแบบ YOLOv5 มาช่วยในการจำแนกพันธุ์ข้าวจากภาพของเมล็ดข้าวสารของพันธุ์ข้าวคาราก้าตาก หอมมะลิ ยิปซาลา บาสมาติ และอาโบริโอ การดำเนินการวิจัยได้แบ่งเป็นสามส่วนหลัก ได้แก่ การดำเนินการด้านวิศวกรรมข้อมูล ซึ่งเป็นการพัฒนาโปรแกรมด้วยภาษาไพทอนเพื่อใช้ในการจัดเตรียมข้อมูลเพื่อให้ระบบปัญญาประดิษฐ์เรียนรู้ การดำเนินการด้านวิทยาการข้อมูลโดยใช้โปรแกรมภาษาไพทอนร่วมกับระบบประมวลผล Google Colaboratory ทำการตรวจหาเมล็ดข้าวสาร และออกแบบการประเมินความแม่นยำของตัวแบบ ในส่วนของการจัดเตรียมข้อมูลได้นำรูปเมล็ดข้าวสารเมล็ดเดี่ยวชนิดเจแปกจาก <https://www.muratkoklu.com/datasets/> มาทำการลดสัญญาณรบกวน กำจัดพื้นหลัง และแปลงเป็นภาพชนิดพีเอ็นจี แล้วนำมาใส่ในภาพขนาด 800 x 800 จุดภาพ จำนวนภาพละ 20-64 เมล็ด โดยมีทั้งรูปแบบไม่มีภาพเมล็ดข้าวสารซ้อนทับกัน มีภาพเมล็ดข้าวสารซ้อนทับกันร้อยละ 5, 10, 15, 20 และ 25 จากนั้นนำภาพที่ไม่มีเมล็ดข้าวสารซ้อนทับกันไปฝึกตัวแบบ YOLOv5 แล้วใช้ตัวแบบดังกล่าวจำแนกพันธุ์ข้าวและระบุตำแหน่งต่าง ๆ ของเมล็ดข้าวสารที่ปรากฏในภาพ ผลการวิจัยพบว่าตัวแบบ YOLOv5 สามารถจำแนกพันธุ์ข้าวของเมล็ดข้าวสารทั้ง 5 สายพันธุ์ได้ดี โดยการประเมินความแม่นยำของตัวแบบที่ค่าขีดแบ่ง 0.6 พบว่าตัวแบบสามารถจำแนกพันธุ์ข้าวที่ปรากฏในภาพที่มีภาพเมล็ดข้าวสารซ้อนทับกันร้อยละ 0, 5, 10, 15, 20 และ 25 ได้ถูกต้องร้อยละ 99.13, 99.00, 98.62, 98.19, 97.56 และ 96.89 ตามลำดับ

คำสำคัญ : การประมวลผลภาพ เมล็ดข้าวสาร การตรวจหาวัตถุ การจำแนกพันธุ์ข้าว

Classification of Rice Varieties from Milled Rice Grain Images by Object Detection Method

Wuttichai Watchararat¹ Jessada Tanthanuch^{2*}

^{1,2*}*School of Mathematics, Institute of Science, Suranaree University of Technology, Nakhon Ratchasima, Thailand*

*Corresponding Author. E-mail address: jessada@g.sut.ac.th

Received: 25 April 2023; Revised: 28 May 2023; Accepted: 29 May 2023

Published online: 27 December 2023

Abstract

This research has applied the YOLOv5 object detection model to help classify rice varieties from images of milled rice grains from the following varieties: Karacadag, Jasmine, Ipsala, Basmati, and Arborio. The research was divided into three main parts: data engineering, which involved developing a Python program to prepare data for artificial intelligence learning; data science operations using Python programming in conjunction with Google Colaboratory for milled rice grain detection; and the development of model accuracy evaluation method. In the data preparation phase, single-grain JPEG images were obtained from <https://www.muratkoklu.com/datasets/>, and noise reduction, background removal, and conversion to PNG format were performed. These images were then placed into 800 x 800 pixels images, each containing 20–64 grains, with varying degrees of overlapping: no overlap, and 5, 10, 15, 20, and 25 percent overlap. The non-overlapping images were used to train the YOLOv5 model, which was then used to classify rice varieties and identify the locations of various milled rice grains in the images. The research results showed that the YOLOv5 model could effectively classify all five rice varieties. Evaluating the model's accuracy at a threshold of 0.6, it was found that the model could correctly classify rice varieties in images with 0, 5, 10, 15, 20, and 25 percent grain overlap, with accuracy rates of 99.13, 99.00, 98.62, 98.19, 97.56, and 96.89 percent, respectively.

Keywords: Image processing, Milled rice grain, Object detection, Rice varieties

1) บทนำ

ในช่วงปี พ.ศ. 2565 ถึง 2566 ประเทศไทยมีการส่งออกข้าวไปยังประเทศต่าง ๆ ในโลกเป็นจำนวนถึง 8.2 ล้านตัน นับว่าเป็นผู้ส่งออกรายใหญ่มากที่สุดเป็นอันดับสองของโลก [1] โดยทั่วไปข้าวที่ส่งออกจะเป็นข้าวหอมมะลิไทย ข้าวหอมไทย ข้าวสาร 5 เเปอร์เซ็นต์ ข้าวสาร 25 เเปอร์เซ็นต์ ข้าวสาร 100 เเปอร์เซ็นต์ ปลายข้าว ข้าวเหนียวขาว 10 เเปอร์เซ็นต์ และ ข้าวนี้ 100 เเปอร์เซ็นต์ [2] ทั้งนี้เพื่อป้องกันการปลอมปนข้าวที่มีมูลค่าต่ำกว่าเข้ากับข้าวที่มีมูลค่าสูงกว่ากระทรวงพาณิชย์ได้กำหนดมาตรฐานของข้าวชนิดต่าง ๆ ไว้โดยพิจารณาหลายองค์ประกอบ เช่น การพิจารณาจากความชื้น ลักษณะโดยทั่วไปของเมล็ดข้าว ขนาดของเมล็ด สีของเมล็ด คุณสมบัติทางเคมี รวมไปถึงร้อยละของการปลอมปนของเมล็ดข้าวชนิดอื่น ๆ [3] อย่างไรก็ตามหากมีการพัฒนาระบบการตรวจสอบคุณภาพของข้าวโดยใช้องค์ความรู้ด้านการประมวลผลภาพและปัญญาประดิษฐ์ จะช่วยให้การตรวจสอบมาตรฐานของข้าวชนิดต่าง ๆ เป็นไปได้โดยมีประสิทธิภาพทั้งในด้านความแม่นยำและความสะดวกรวดเร็วที่มากขึ้น

งานวิจัยนี้ต้องการพัฒนาและประยุกต์ระบบการตรวจหาวัตถุเพื่อจำแนกพันธุ์ข้าวและระบุตำแหน่งเมล็ดพันธุ์ข้าวนั้น ๆ จากรูปที่ปรากฏเมล็ดข้าวสารของพันธุ์ข้าวชนิดต่าง ๆ ที่หลากหลายแต่เนื่องด้วยไม่มีข้อมูลภาพของเมล็ดข้าวสารที่เป็นที่นิยมหรือจำหน่ายในประเทศไทยเป็นจำนวนมากพอ จึงต้องใช้ข้อมูลภาพเมล็ดสารที่เป็นข้อมูลเปิดมาใช้ในการทำวิจัยเพื่อใช้เป็นต้นแบบในการทำวิจัยเกี่ยวกับการจำแนกเมล็ดข้าวสารอื่น ๆ ต่อไป ซึ่งงานวิจัยนี้แตกต่างจากงานวิจัยอื่น ๆ ที่ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) โดยทั่วไป เช่น Logistic Regression, Support Vector Machine, Decision Trees หรือ K-Nearest Neighborhood เพื่อจำแนกประเภทของเมล็ดข้าว ซึ่งทั้งหมดเป็นการจำแนกเมล็ดข้าวสารเมล็ดเดียวเท่านั้น แต่การดำเนินการวิจัยดังกล่าวไม่สอดคล้องกับลักษณะความเป็นจริงที่เราต้องการตรวจหาการปลอมปนของเมล็ดข้าวอื่นในภาพถ่ายที่มีรูปของเมล็ดข้าวสารที่เราพิจารณา และการใช้ระบบตรวจหาวัตถุนี้จะสามารถนำไปต่อยอดได้ในอนาคตเนื่องจากเมื่อทราบข้อมูลของตำแหน่งเมล็ดข้าวในอนาคตอาจสามารถพัฒนาเครื่องมือเพื่อใช้ในการแยกเมล็ดข้าวที่ปลอมปนนั้นได้ ทั้งนี้ในการวิจัยที่นำเสนอได้พยายามจำลองเงื่อนไขการตรวจหาเมล็ดข้าวสารทั้งในกรณีที่มีเมล็ดข้าวสารกระจายอยู่ทั่วไปรวมถึงถึงกรณีการเกิดภาพของเมล็ดข้าวสารซ้อนทับกัน เพื่อให้ใกล้เคียงกับสถานการณ์จริงที่

อาจจะเกิดขึ้นในธรรมชาติได้ และทำการวัดประสิทธิภาพระบบการตรวจหาเมล็ดข้าวสารที่สร้างขึ้น

2) ทบทวนวรรณกรรม

2.1) ทฤษฎีที่เกี่ยวข้อง

เนื้อหาในส่วนทฤษฎีที่เกี่ยวข้องนี้จะแบ่งเป็น 3 ส่วนหลัก ได้แก่ ทฤษฎีที่เกี่ยวกับการประมวลผลภาพดิจิทัล ตัวแบบตรวจหาวัตถุ และตัวแบบ YOLOv5

2.1.1) ทฤษฎีที่เกี่ยวกับการประมวลผลภาพดิจิทัล ภาพถ่ายดิจิทัลในที่นี้จะหมายถึงภาพที่บันทึกในรูปแบบข้อมูลดิจิทัล ซึ่งในงานวิจัยนี้ได้พิจารณาภาพถ่ายที่บันทึกในรูปแบบเจเพ็ก (Joint Photographic Experts Group: JPEG) และรูปแบบพีเอ็นจี (Portable Network Graphics: PNG) เป็นหลัก โดยภาพเจเพ็กจะเป็นภาพที่เป็นที่นิยมเนื่องจากโดยทั่วไปมีขนาดของไฟล์ภาพเล็กกว่าไฟล์ภาพชนิดอื่น ๆ เนื่องจากมีการบีบอัดข้อมูลที่มีการสูญเสียรายละเอียดของภาพในบางส่วน (lossy compression) แต่ก็ยังคงคุณภาพของภาพที่ยอมรับได้ ขณะที่ไฟล์ภาพรูปแบบพีเอ็นจีมีการบีบอัดข้อมูลแบบไม่เสียคุณภาพของภาพต้นฉบับ (loss less compression) และมีจุดเด่นในการสร้างภาพที่มีลักษณะพื้นหลังโปร่งใส (transparent background) เหมาะกับการนำภาพมาซ้อนทับกับภาพอื่น ๆ [4] ทั้งนี้เพื่อให้การดำเนินการที่เกี่ยวข้องกับการประมวลผลภาพ (image processing) เป็นไปได้อย่างมีประสิทธิภาพ เราสามารถประยุกต์ใช้ความรู้ด้าน Morphology ซึ่งเป็นแนวความคิดในการใช้ทฤษฎีเซต (set theory) ทางคณิตศาสตร์มาช่วยให้คอมพิวเตอร์พิจารณารูปเป็นวัตถุ แล้วดำเนินการด้านรูปร่างและขนาดของรูปโดยใช้ตัวดำเนินการ Morphological (morphological operation) [5]

ตัวอย่างการดำเนินการดังกล่าว เช่น

Erosion: ลดขนาดของวัตถุในภาพด้วยการลดจุดภาพบริเวณขอบของวัตถุ

Dilation: เพิ่มขนาดของวัตถุในภาพด้วยการเพิ่มจุดภาพบริเวณขอบของวัตถุ

Opening: ทำการ Erosion แล้วตามด้วย Dilation ช่วยให้สามารถลบสิ่งรบกวน (noise) บางชนิดออกได้

Closing: ทำการ Dilation แล้วตามด้วย Erosion ช่วยในการเติมเต็มจุดภาพที่ขาดหายไปบางส่วนของรูปภาพ

Contour: เป็นกระบวนการหาขอบเขตของวัตถุในภาพโดยการพิจารณาเส้น contour ของขอบภาพของวัตถุ

การนำตัวดำเนินการ Morphological มาใช้ในการกำจัดสัญญาณรบกวนและการเลือกวัตถุ มีผลต่อการจัดเตรียมภาพดิจิทัลเพื่อให้ระบบการตรวจหาวัตถุ YOLO ทำงานได้อย่างมีประสิทธิภาพต่อไป

2.1.2) *ตัวแบบตรวจหาวัตถุ (Object Detectors)* เป็นตัวแบบ (model) ทางด้านปัญญาประดิษฐ์ (Artificial Intelligence: AI) ที่ใช้ในงานทางด้านวิธีการรับรู้ภาพด้วยคอมพิวเตอร์ (computer vision) ซึ่งสามารถจำแนกและตรวจหาวัตถุที่อยู่ในภาพ รวมทั้งการบอกถึงตำแหน่งของวัตถุที่อยู่ในภาพนั้น ๆ โดยทั่วไปเราสามารถแบ่งตัวแบบตรวจหาวัตถุเป็น 3 ประเภทเบื้องต้นได้แก่ ประเภท single stage detector ประเภท two stage detector และประเภท transformer-based detector โดยตัวแบบตรวจหาวัตถุประเภท single stage detector และประเภท two stage detector มักใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolution Neural Network: CNN) เป็นโครงสร้างหลักในการตรวจหา เนื่องจาก CNN เป็นตัวแบบที่มีความสามารถในการจำแนกข้อมูลประเภทรูปภาพได้ดี ตัวแบบ CNN ที่ถูกใช้ในตัวแบบตรวจหาวัตถุประเภท single และ two stage detector มักมีความซับซ้อนและจำนวนพารามิเตอร์ที่น้อยกว่าตัวแบบ transformer ซึ่งถูกใช้ในตัวแบบตรวจหาวัตถุประเภท transformer-based ทำให้ใช้เวลาในการตรวจหาวัตถุที่น้อยแต่ก็มีความแม่นยำที่น้อยกว่าด้วย

ตัวแบบตรวจหาวัตถุประเภท two stage detector มีการแยกกระบวนการตรวจหาวัตถุออกเป็นสองขั้นตอนหลัก คือการสกัดคุณลักษณะ (feature extraction) และการทำนายพื้นที่ที่น่าจะเป็นบริเวณของวัตถุที่สนใจ (region proposals) ในขั้นตอนแรก จากนั้นทำการตรวจหาวัตถุจากบริเวณที่สนใจในขั้นตอนที่สอง ในขณะที่ตัวแบบตรวจหาวัตถุประเภท single stage detector ทำการรวบรวมทั้งกระบวนการสกัดคุณลักษณะ การทำนายพื้นที่ และการตรวจหาวัตถุ ให้อยู่ในขั้นตอนเดียวเท่านั้น ซึ่งวิธีการนี้ทำให้มีความเร็วในการประมวลผลสูง สามารถตรวจหาวัตถุได้อย่างรวดเร็ว เหมาะสำหรับการตรวจหาวัตถุแบบเวลาจริง (real time)

ในปัจจุบันมีการปรับปรุงตัวแบบตรวจหาวัตถุประเภท single stage detector ให้มีความเร็วและความแม่นยำในการตรวจหาวัตถุมากขึ้น ตัวอย่างตัวแบบประเภทนี้ที่ถูกพัฒนา ได้แก่ ตัวแบบ Single Shot MultiBox Detector (SSD), RetinaNet, CenterNet,

EfficientDet และ YOLO แต่ตัวแบบที่เป็นที่นิยมมากที่สุดและมีการพัฒนาอย่างต่อเนื่องได้แก่ตัวแบบ YOLO [6]

2.1.3) *ตัวแบบ YOLOv5* ในปี ค.ศ. 2015 Joseph Redmon *et al.* ได้พัฒนาระบบตรวจหาวัตถุที่มีความรวดเร็วในการทำงานสูงกว่าระบบแบบเดิมและมีความแม่นยำที่ดี เนื่องด้วยใช้การประมวลผลโครงข่ายประสาทเทียมเดี่ยว (single neural network) ในการพยายามจำแนกวัตถุในภาพทั้งหมดในครั้งเดียว โดยตั้งชื่อขั้นตอนวิธีดังกล่าวว่า You Only Look Once Algorithm หรือ เป็นที่รู้จักในชื่อว่า YOLO algorithm ในภายหลังได้มีการพัฒนา YOLO algorithm อีกหลายครั้งจนกระทั่ง Glenn Jocher และคณะ ได้พัฒนาระบบตรวจหาวัตถุ YOLOv5 ขึ้นในปี ค.ศ. 2020 โดยต่อยอดแนวคิดมาจาก YOLO algorithm ซึ่ง YOLOv5 นี้มีประสิทธิภาพที่ดีกว่าเดิมเป็นอย่างมาก จนทำให้เป็นที่นิยมในการใช้ระบบดังกล่าวในการตรวจหาวัตถุทั้งจากภาพนิ่งและภาพเคลื่อนไหว [7]

YOLOv5 มีขั้นตอนในการทำงานเบื้องต้นดังนี้

1) การแบ่งภาพเป็นหลายส่วนย่อย (Dividing an Image into Multiple Segments) ในขั้นตอนนี้ระบบจะทำการแบ่งภาพออกเป็นส่วนย่อยที่เรียกว่า grid cells แล้วทำการตรวจหาวัตถุในแต่ละส่วนย่อยด้วยขั้นตอนวิธีโครงข่ายประสาทเทียมแบบ CNN

2) การสกัดคุณลักษณะของวัตถุ (Feature Extraction) ในขั้นตอนนี้จะใช้ CNN ในการสกัดคุณลักษณะของวัตถุที่ปรากฏอยู่ในส่วนย่อยจากขั้นตอนที่ 1

3) การคาดเดาแบบชั้น (Class Prediction) ในการใช้ CNN จะมีชั้นเชื่อมโยงแบบสมบูรณ์ (fully-connected layer) ซึ่งชั้นนี้จะนำคุณลักษณะของวัตถุที่สกัดได้ในขั้นตอนที่ 2 ไปดำเนินการสร้างผลลัพธ์ให้เป็นเวกเตอร์ (vector) ของความน่าจะเป็นจำนวน K มิติ ตามจำนวนชั้น K ชั้น ที่ CNN ต้องการทำนาย

4) การคาดเดาดำเนินการของวัตถุ (Bounding Box Prediction) ในขั้นตอนนี้ตัวแบบ YOLOv5 ใช้ชั้นเชื่อมโยงแบบสมบูรณ์คาดเดาดำเนินการของวัตถุ

5) การปรับปรุงผลลัพธ์ (Result Improvement) หลังจากที่ได้โมเดล YOLOv5 ได้ทำการคาดเดาดำเนินการของวัตถุแล้ว ขั้นตอนต่อไปคือการดำเนินการเพื่อลดข้อผิดพลาดที่อาจเกิดขึ้นในการตรวจหาวัตถุ เช่น ปรับลดข้อมูลวัตถุที่ถูกตรวจหาที่มีความน่าจะเป็นต่ำ การลบข้อมูลรบกวน เช่น ตัวอักษรที่ไม่เกี่ยวข้อง การรวม (merging) กลุ่มวัตถุที่อยู่ใกล้เคียงกันเป็นวัตถุชิ้นเดียวกัน

6) การค้นหาวัตถุในรูปภาพ (Object Searching) ขั้นตอนนี้เป็นขั้นตอนในการตรวจหาวัตถุและระบุตำแหน่ง โดยการสร้าง

กรอบสี่เหลี่ยม (bounding box) รอบวัตถุที่ตรวจพบ นอกจากนี้ยังสามารถแสดงข้อมูลที่เกี่ยวข้องกับวัตถุดังกล่าวตามต้องการ เช่น ชื่อของวัตถุ หรือคะแนนความเชื่อมั่นที่พบ (confidence score)

2.2) งานวิจัยที่เกี่ยวข้อง

ที่ผ่านมา มีงานวิจัยหลากหลายที่ประยุกต์ใช้ระบบปัญญาประดิษฐ์เพื่อช่วยในงานที่เกี่ยวข้องกับการจำแนกพันธุ์ข้าว เช่น ในปี ค.ศ. 2015 Aki *et al.* ใช้วิธีการประมวลผลภาพร่วมกับเทคนิคการเรียนรู้เครื่อง (machine learning techniques) เพื่อจำแนกพันธุ์ข้าวจากรูปถ่ายภาพเมล็ดข้าวสาร 4 ชนิด ได้แก่ ข้าวพันธุ์บาลโด (Baldo) ข้าวพันธุ์ออสมันซิค (Osmancik) ข้าวพันธุ์ยาเซมิน (Yasemin) และกลุ่มของเมล็ดข้าวหัก (broken) [8] และในปีเดียวกัน Zareiforoush *et al.* ได้ใช้วิธีการรับรู้ภาพด้วยคอมพิวเตอร์ ร่วมกับ เทคนิคเมตาฮีริสติก (Metaheuristic Method) 4 อย่าง ได้แก่ เครือข่ายโครงประสาทประดิษฐ์ (Artificial Neural Network: ANN) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) ต้นไม้การตัดสินใจ (Decision Trees: DT) และ เครือข่ายเบย์เซียน (Bayesian Network) ในการวิเคราะห์เมล็ดข้าวสารที่ได้จากกรรมวิธีในการสีข้าว 4 ประเภท ได้แก่ เมล็ดข้าวสารคุณภาพดีได้จากกระบวนการสีที่ดี (high-processed sound grains) เมล็ดข้าวสารหักได้จากกระบวนการสีที่ดี (high-processed broken grains) เมล็ดข้าวสารคุณภาพดีได้จากกระบวนการสีที่คุณภาพไม่ดี (low-processed sound grains) เมล็ดข้าวสารหักได้จากกระบวนการสีที่คุณภาพไม่ดี (low-processed broken grains) [9] ในปี ค.ศ. 2019 Cinar และ Koklu ใช้เทคนิคการเรียนรู้เครื่อง 7 อย่าง ได้แก่ 1) การถดถอยโลจิสติก (Logistic Regression: LR) 2) การรับรู้หลายชั้น (Multilayer Perceptron: MP) 3) ซัพพอร์ตเวกเตอร์แมชชีน 4) ต้นไม้การตัดสินใจ 5) ป่าสุ่ม (Random Forest: RF) 6) นาอิวเบส (Naïve Bayes: NB) และ 7) เพื่อนบ้านใกล้เคียงสุด k (k-Nearest Neighbor: kNN) ในการจำแนกข้าวสาร 2 สายพันธุ์คือ สายพันธุ์ออสมันซิคและสายพันธุ์คามีโอ (Cameo) จากรูปถ่าย 3,810 รูป โดยพิจารณาจากคุณลักษณะสัณฐาน (morphological feature) 7 อย่าง ได้แก่ พื้นที่ของรูปเมล็ดข้าวสารที่ปรากฏในภาพถ่าย (area) เส้นรอบรูปเมล็ดข้าวสาร (perimeter) ความยาวของแกนหลัก (major axis length) ความยาวของแกนรอง (minor axis length) ความบิดเบี้ยวของส่วนผิวเมล็ดข้าวสาร (eccentricity) พื้นที่ส่วนจุกข้าว (convex area) และอัตรา

ส่วนของพื้นที่รูปข้าวกับกรอบของภาพที่พิจารณา [10] และอีก 2 ปีถัดมา Cinar และ Koklu ได้พิจารณาข้าวเพิ่มเป็น 5 สายพันธุ์ ได้แก่ คารากาดาก (Karacadag) หอมมะลิ (Jasmine) ยิปซาลา (Ipsala) บาสมาติ (Basmati) และอาโบริโอ (Arborio) โดยเป็นข้อมูลรูปภาพเพิ่มเป็นสายพันธุ์ละ 15,000 รูป (รวม 75,000 รูป) คุณลักษณะเพิ่มขึ้นเป็น 106 คุณลักษณะโดยเป็นคุณลักษณะสัณฐาน 12 อย่าง คุณลักษณะรูปร่าง (shape feature) 4 อย่าง และคุณลักษณะด้านสี (color feature) 90 อย่าง และใช้เทคนิคการสกัดคุณลักษณะ (feature extraction) เพื่อเพิ่มประสิทธิภาพในการจำแนกพันธุ์เมล็ดข้าวสารจากรูปภาพ และเปรียบเทียบการจำแนกพันธุ์เมล็ดข้าวสารด้วย 3 ขั้นตอนวิธี ได้แก่ วิธีการวิเคราะห์ความแปรปรวน (Analysis of Variance: ANOVA) วิธีไคกำลังสอง (Chi-square) และวิธีอัตราส่วนอัตราขยาย (gain ratio) [11] และในปีเดียวกัน Koklu *et al.* ได้พัฒนาโปรแกรมภาษาไพทอน (Python) เพื่อใช้ขั้นตอนวิธี ANN และเครือข่ายโครงประสาทเชิงลึก (Deep Neural Network: DNN) ในส่วนการจำแนกพันธุ์ข้าวจากคุณลักษณะ 106 คุณลักษณะของชุดข้อมูล เปรียบเทียบกับการใช้วิธีเครือข่ายโครงประสาทสังวัตนาการ (Convolution Neural Network: CNN) ในส่วนของการพิจารณาคุณลักษณะและจำแนกเมล็ดข้าวสารของข้อมูลข้าวจากภาพ ซึ่งพบว่าการใช้ CNN ให้ประสิทธิภาพที่สูงกว่า [12] และในปี ค.ศ. 2022 Cinar และ Koklu ใช้เทคนิคการเรียนรู้เครื่อง 7 อย่าง ได้แก่ LR, MP, SVM, DT, RF, NB และ kNN โดยเป็นทำงานภายใต้โปรแกรม MATLAB ในการจำแนกพันธุ์ข้าวจากข้อมูลคุณลักษณะ 106 คุณลักษณะ ของข้าวทั้ง 5 สายพันธุ์ที่ได้กล่าวถึงในงานวิจัยก่อนหน้านี้ [13]

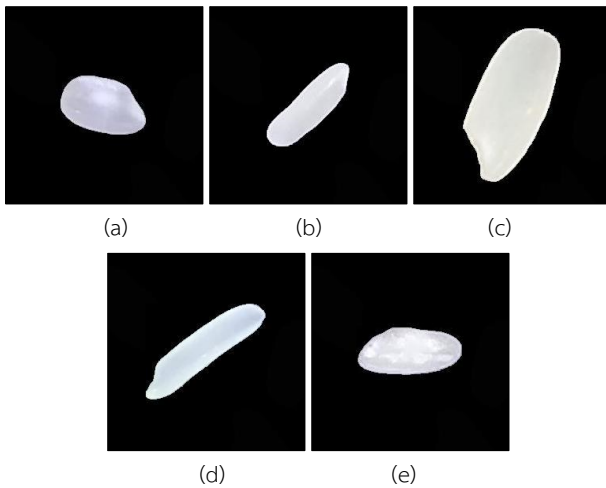
3) วิธีดำเนินการวิจัย

3.1) ข้อมูล ซอฟต์แวร์ และอุปกรณ์ที่ใช้ในการทำวิจัย

ข้อมูลภาพเมล็ดข้าวสารที่ใช้ในงานวิจัยนี้ได้มาจาก “murat koklu” ซึ่งเป็นข้อมูลสาธารณะของ Dr.Murat KÖKLÜ ซึ่งมีอยู่ในฐานข้อมูล <https://www.muratkoklu.com/datasets> ชุดข้อมูลประกอบด้วยภาพเมล็ดข้าวสารของพันธุ์ข้าวคารากาดาก หอมมะลิ ยิปซาลา บาสมาติ และอาโบริโอจำนวน 15,000 ภาพในแต่ละพันธุ์ รวมเป็นจำนวนภาพทั้งหมด 75,000 ภาพ โดยเป็นภาพชนิดเจฟีกขนาด 250 x 250 จุดภาพ ดังแสดงในรูปที่ 1

สำหรับซอฟต์แวร์ที่ใช้ในการดำเนินการวิจัยจะประกอบไปด้วยโปรแกรมภาษาไพทอน Version 3.7 ร่วมกับระบบประมวลผล

แพลตฟอร์ม Google Colaboratory และดำเนินการในส่วนพัฒนาซอฟต์แวร์และประเมินประสิทธิภาพบนเครื่องคอมพิวเตอร์รุ่น ASUS-TUF Gaming FX505DU-AL052T หน่วยประมวลผล AMD Ryzen 7 3750H หน่วยประมวลผลกราฟิก Radeon Vega Mobile Gfx 2.30 GHz หน่วยความจำ RAM ความจุ 16GB ทำงานบนระบบปฏิบัติการ Microsoft Windows 11




รูปที่ 1 : ตัวอย่างภาพเมล็ดข้าวสาร 5 สายพันธุ์

(a) คาราก้าตาก (b) หอมมะลิ (c) ยิชาลา (d) บาสมาติ และ (e) อาโบริโอ

สำหรับขั้นตอนการดำเนินงานวิจัยแบ่งออกเป็น 3 ส่วนหลัก ได้แก่ 1) วิศวกรรมข้อมูล 2) การสร้างตัวแบบ และ 3) การวัดประสิทธิภาพของตัวแบบ

3.2) วิศวกรรมข้อมูล

จากการวิเคราะห์ภาพที่ได้ในการนำเข้าข้อมูล พบว่าบริเวณพื้นหลังของภาพเมล็ดข้าวสารไม่ได้มีสีดำสนิท มีการเชื่อมของสีบางส่วนอยู่ดังแสดงในรูปที่ 2



รูปที่ 2 : ตัวอย่างภาพเมล็ดข้าวสารที่ใช้ในการทำวิจัย (ซ้าย) และภาพแสดงให้เห็นว่าภาพหลังของภาพเมล็ดข้าวสารไม่เป็นสีดำสนิท (ขวา)

จากกรณีข้างต้นคณะผู้วิจัยได้ดำเนินการแก้ปัญหาด้วยการพัฒนาโปรแกรมภาษาไพทอนเพื่อใช้ตัวดำเนินการ morphological ทั้ง opening และ closing ในการกำจัดสิ่งรบกวนที่ปรากฏบนภาพและเติมเต็มในบางส่วนของภาพที่เสียหาย และใช้การดำเนินการ contour เพื่อคัดเลือกวัตถุที่มีขนาดใหญ่ที่สุดในภาพ นั่นคือภาพเฉพาะส่วนเมล็ดข้าวสารออกมา จากนั้นทำการกำจัดส่วนของพื้นหลังของภาพทำให้ได้ภาพที่มีพื้นหลังโปร่งใส แล้วทำการบันทึกภาพที่ได้ให้เป็นภาพชนิดพีเอ็นจี ดังแสดงในรูปที่ 3



รูปที่ 3 : ภาพเมล็ดข้าวสารที่ลดสิ่งรบกวนและกำจัดพื้นหลัง

จากนั้นนำภาพเมล็ดข้าวสารที่พื้นหลังโปร่งใสมาซ้อนทับลงบนภาพพื้นหลังสีดำขนาด 800 x 800 จุดภาพ ซึ่งการดำเนินการดังกล่าวจะแบ่งการดำเนินการเป็น 2 ส่วนได้แก่ การสร้างชุดข้อมูลสำหรับการฝึก (training data set) และชุดข้อมูลสำหรับการทดสอบ (test data set)

ในส่วนการสร้างข้อมูลชุดสำหรับการฝึก จะซ้อนทับภาพเมล็ดข้าวสารจำนวนสุ่มระหว่าง 20 ถึง 35 เมล็ด ลงบนภาพสีดำที่เตรียมไว้ และภาพเมล็ดข้าวสารดังกล่าวได้จากการสุ่มภาพเมล็ดข้าวสาร 5 สายพันธุ์ จากจำนวนภาพข้าวสายพันธุ์ละ 6,000 ภาพ (รวม 30,000 ภาพ) ลงบนตำแหน่งต่าง ๆ แบบสุ่ม โดยต้องไม่มีภาพเมล็ดข้าวสารซ้อนทับกัน โดยดำเนินการสร้างข้อมูลชุดฝึกจำนวน 7,000 ภาพ รวมทั้งสร้างไฟล์ข้อมูลสำหรับชุดฝึกแต่ละภาพซึ่งมีรายละเอียดว่าในภาพข้อมูลชุดฝึกจะมีตำแหน่งเมล็ดข้าวสารชนิดใด อยู่ ณ ตำแหน่งไหน มีบริเวณที่ภาพเมล็ดข้าวสารนั้นครอบคลุมพื้นที่ที่อยู่กว้างและยาวกี่จุดภาพ โดยเรียกไฟล์ข้อมูลดังกล่าวว่าไฟล์ข้อมูลติดฉลาก (labeled data file)



รูปที่ 4 : ภาพข้อมูลชุดฝึก



รูปที่ 6 : ภาพข้อมูลชุดทดสอบที่มีภาพเมล็ดข้าวสารซ้อนทับกัน

```


4 0.353125 0.174375 0.09125 0.14875
0 0.864375 0.47875 0.15625 0.12
0 0.468125 0.28 0.13875 0.125
4 0.160625 0.94625 0.12625 0.105
0 0.153125 0.26 0.18375 0.1025
0 0.79 0.8575 0.1425 0.155
2 0.89375 0.159375 0.155 0.25375
3 0.31125 0.7775 0.18 0.0675
3 0.525 0.64875 0.15 0.1175
1 0.454375 0.909375 0.21125 0.17625
4 0.10875 0.63875 0.145 0.0975
0 0.2975 0.439375 0.17 0.08625
4 0.491875 0.088125 0.09625 0.13625
1 0.7125 0.454375 0.0925 0.25375
3 0.446875 0.555625 0.19125 0.05875
2 0.150625 0.06625 0.22875 0.1225
2 0.72125 0.22625 0.1675 0.1775
0 0.514375 0.42125 0.16875 0.1
0 0.64625 0.708125 0.09 0.17125
1 0.263125 0.604375 0.13875 0.24375
3 0.12875 0.38 0.15 0.1075
2 0.874375 0.644375 0.22625 0.13625
4 0.935625 0.776875 0.10625 0.12875
2 0.69625 0.071875 0.25 0.11125
    
```

รูปที่ 5 : ภาพแสดงรายละเอียดไฟล์ข้อมูลติดฉลาก
ของภาพข้อมูลชุดฝึกจากรูปที่ 4

สำหรับในส่วนการสร้างข้อมูลชุดสำหรับการทดสอบ ได้ทำการสร้างข้อมูลในรูปแบบที่คล้ายกันกับข้อมูลชุดสำหรับการฝึก แต่เพิ่มจำนวนเมล็ดข้าวสารที่ปรากฏลงบนภาพชุดทดสอบเป็นจำนวนสุ่มตั้งแต่ 44 ถึง 64 เมล็ด และแบ่งชุดทดสอบเป็นกลุ่มชุดทดสอบที่มีภาพเมล็ดข้าวสารไม่ซ้อนทับกันเลย (ซ้อนทับกันร้อยละ 0) และกลุ่มชุดทดสอบที่อนุญาตให้มีภาพเมล็ดข้าวสารซ้อนทับกันได้ไม่เกินร้อยละ 5, 10, 15, 20 และ 25 แต่ละกลุ่มมีจำนวนข้อมูลทดสอบกลุ่มละ 500 ภาพ รวมชุดทดสอบทั้งหมดเป็น 3,000 ภาพ

3.3) สร้างตัวแบบตรวจหาวัตถุ

นำข้อมูลภาพข้อมูลชุดสำหรับการฝึก 7,000 ภาพ และไฟล์ข้อมูลติดฉลาก ไปฝึกระบบตรวจหาวัตถุ YOLOv5 บนระบบประมวลผลแพลตฟอร์ม Google Colaboratory โดยตั้งค่าพารามิเตอร์โดยปริยาย (default) ดังนี้ ค่าอัตราการเรียนรู้ (learning rate) ที่ 0.01 ค่า batch_size = 16 (จำนวนข้อมูลที่ส่งฝึกสอนในหนึ่งครั้ง) ค่า epoch = 5 (จำนวนรอบของการฝึกสอน)



รูปที่ 7 : ภาพการฝึกเพื่อสร้างตัวแบบตรวจหาวัตถุ


ทั้งนี้เมื่อสร้างตัวแบบตรวจหาวัตถุเป็นที่เรียบร้อยแล้ว ตัวแบบดังกล่าวจะสามารถตรวจหาชนิดของเมล็ดข้าวสารและตำแหน่งในภาพข้อมูลชุดทดสอบ โดยตัวแบบจะดำเนินการสร้างไฟล์ข้อมูลติดฉลาก ซึ่งมีข้อมูลของสายพันธุ์ ตำแหน่ง และขนาดของเมล็ดข้าวสารแต่ละเมล็ดที่ปรากฏในภาพข้อมูลชุดทดสอบ

```

1 0.9625 0.718125 0.075 0.21375
3 0.94 0.9075 0.0675 0.175
0 0.4975 0.858125 0.165 0.08625
1 0.56375 0.9475 0.21 0.0675
0 0.219375 0.94875 0.15875 0.085
4 0.081875 0.299375 0.12875 0.11375
1 0.515 0.421875 0.235 0.07125
3 0.796875 0.798125 0.16875 0.07875
4 0.72125 0.939375 0.115 0.11375
0 0.25625 0.061875 0.175 0.09875
0 0.094375 0.5925 0.14875 0.115
0 0.088125 0.430625 0.14625 0.13125
2 0.734375 0.220625 0.16375 0.21375
0 0.39125 0.1575 0.165 0.115
4 0.821875 0.599375 0.13625 0.10875
0 0.3075 0.62125 0.1675 0.0875
2 0.63 0.059375 0.22 0.10875


```

รูปที่ 8 : ตัวอย่างข้อมูลบางส่วนของการตรวจหาเมล็ดข้าวสารด้วยตัวแบบ




รูปที่ 10 : ภาพเดิมเต็ม

นอกจากนี้ ยังสามารถให้ตัวแบบแสดงการตรวจหาเมล็ดข้าวสารของภาพข้อมูลชุดทดสอบ โดยสามารถระบุสายพันธุ์ ตำแหน่ง ขนาด และความเชื่อมั่นที่พบ ดังแสดงในรูปที่ 9



รูปที่ 9 : แสดงการตรวจหาเมล็ดข้าวสารโดยตัวแบบตรวจหาวัตถุที่สร้างขึ้น

จากนั้น นำภาพข้อมูลชุดทดสอบซึ่งแสดงเมล็ดข้าวสารพันธุ์ต่าง ๆ แปลงเป็นภาพไบนารีโดยให้พื้นหลังมีค่า 0 และบริเวณที่เป็นส่วนแสดงเมล็ดข้าวสารให้มีค่าไม่เท่ากับ 0 เพื่อแยกแหว่งพื้นหลังกับส่วนที่เป็นวัตถุ ดังแสดงในรูปที่ 11



รูปที่ 11 : ภาพไบนารีของข้อมูลชุดทดสอบแสดงตำแหน่งเมล็ดข้าวสาร

3.4) การวัดประสิทธิภาพของตัวแบบตรวจหาวัตถุ

ในการวัดประสิทธิภาพของตัวแบบตรวจหาวัตถุคณะผู้วิจัยได้ออกแบบการวัดประสิทธิภาพโดยนำข้อมูลจากไฟล์ข้อมูลติดฉลากของชุดทดสอบแต่ละภาพมาสร้างภาพเดิมเต็มจากข้อมูลของสายพันธุ์ข้าวสาร ตำแหน่ง และบริเวณที่ภาพเมล็ดข้าวสารแต่ละเมล็ดนั้นครอบคลุม โดยทำการเติมเต็มบริเวณกรอบสี่เหลี่ยมผืนผ้าที่ระบุตำแหน่งของเมล็ดข้าวสารชนิดนั้น ให้แต่ละจุดภาพทั้งหมดในกรอบดังกล่าวมีค่าเป็นข้อมูลสายพันธุ์ของเมล็ดข้าวสารนั้น ๆ ที่ละเมล็ด ดังแสดงในรูปที่ 10

ในส่วนถัดมานำข้อมูลภาพเดิมเต็มและภาพไบนารีมาประมวลผล โดยสร้างภาพสำหรับการใช้วัดประสิทธิภาพตัวแบบโดยกำหนดให้ตำแหน่งพื้นหลังเป็น 0 และตำแหน่งที่แสดงเมล็ดข้าวสารเป็นค่าตามสายพันธุ์ของข้าวตามที่กำหนด


$$w(x,y) = \begin{cases} 0, & \text{if } g(x,y) = 0 \\ h(x,y), & \text{if } g(x,y) \neq 0 \end{cases} \quad (1)$$

เมื่อ $w(x,y)$ คือ ค่าข้อมูลของภาพสำหรับวัดประสิทธิภาพ


$g(x,y)$ คือ ค่าข้อมูลของภาพไบนารี และ

$h(x,y)$ คือ ค่าข้อมูลของภาพเดิมเต็ม

โดยค่าต่าง ๆ พิจารณา ณ ตำแหน่งจุดภาพ (x,y)



รูปที่ 12 : ภาพสำหรับการใช้วัดประสิทธิภาพตัวแบบ



รูปที่ 13 : ตัวอย่างภาพย่อยจากภาพสำหรับการใช้วัดประสิทธิภาพตัวแบบ

สำหรับการวัดประสิทธิภาพของตัวแบบทำได้โดยการนำข้อมูลจากไฟล์ข้อมูลติดฉลากที่เป็นผลจากที่ตัวแบบทำการตรวจหาเมล็ดข้าวสาร ซึ่งมีข้อมูลพันธุ์ข้าวและบริเวณที่ตรวจหาได้บนภาพจากข้อมูลชุดทดสอบ มาทำการพิจารณาภาพย่อยจากภาพสำหรับการใช้วัดประสิทธิภาพตัวแบบซึ่งอยู่บริเวณเดียวกันดังแสดงตัวอย่างในรูปที่ 13

จะเห็นว่าภาพย่อยดังกล่าวอาจมีภาพเมล็ดข้าวสารที่ตัวแบบตรวจหาวัตถุตรวจเจอและภาพบางส่วนจากเมล็ดข้าวสารเมล็ดอื่นร่วมอยู่ด้วย ดังนั้นเพื่อที่จะตรวจสอบว่า ณ ตำแหน่งดังกล่าว ตัวแบบได้ทำการตรวจหาพันธุ์ข้าวได้ถูกต้องหรือไม่ จะใช้วิธีพิจารณาอัตราส่วนของจำนวนจุดภาพในภาพย่อยของเมล็ดข้าวสารพันธุ์ที่ตัวแบบตรวจหาเทียบกับจำนวนจุดภาพที่อยู่บนตำแหน่งที่ปรากฏเมล็ดข้าวสารทั้งหมดที่ไม่ใช่ส่วนของพื้นหลังว่ามากกว่าหรือเท่ากับค่าขีดแบ่ง (threshold) ที่กำหนดหรือไม่ หากใช่จะถือว่าตัวแบบได้ตรวจหาพันธุ์เมล็ดข้าวสาร ณ ตำแหน่งดังกล่าวได้ถูกต้อง (correct)

$$\text{การตรวจหา} = \begin{cases} \text{correct} , & \text{if } \frac{r}{t} \geq \theta \\ \text{incorrect} , & \text{if } \frac{r}{t} < \theta \end{cases} \quad (2)$$

เมื่อ r คือ จำนวนจุดภาพในภาพย่อยของเมล็ดข้าวสารพันธุ์ที่ตัวแบบตรวจหา

t คือ จำนวนจุดภาพทั้งหมดในภาพย่อยที่ไม่ใช่พื้นหลัง

θ คือ ค่าขีดแบ่งที่กำหนด

ทั้งนี้ค่าความแม่นยำ (accuracy) ของตัวแบบถูกนิยามโดย

$$\text{ความแม่นยำ} = \frac{\text{จำนวน correct}}{\text{จำนวน correct} + \text{จำนวน incorrect}} \quad (3)$$

4) ผลการวิจัยและอภิปรายผล

ในการสร้างข้อมูลชุดทดสอบจำนวน 3,000 ภาพ มีข้อมูลจำนวนภาพเมล็ดข้าวสารสายพันธุ์ต่าง ๆ แบ่งตามกลุ่มชุดทดสอบที่อนุญาตให้มีภาพเมล็ดข้าวสารซ้อนทับกันได้ไม่เกินร้อยละ 0 (ไม่มีภาพเมล็ดข้าวสารซ้อนทับกันเลย), 5, 10, 15, 20 และ 25 ดังแสดงในตารางที่ 1 และตัวแบบตรวจหาวัตถุที่ได้ฝึกเพื่อตรวจหาเมล็ดข้าวสารสามารถตรวจพบเมล็ดข้าวสารได้ดังแสดงในตารางที่ 2

ตารางที่ 1 : จำนวนรวมเมล็ดข้าวสารในภาพข้อมูลชุดทดสอบทั้งหมด

	การทับซ้อน (ร้อยละ)					
	0	5	10	15	20	25
คาราก้าดาก	4,221	4,630	4,868	4,827	5,145	5,396
หอมมะลิ	4,010	4,580	4,516	4,725	5,105	5,135
ยิปซาลา	2,474	2,584	2,771	2,893	3,027	3,140
บาสมาติ	3,009	3,448	3,571	3,759	3,875	3,930
อาโบริโอ	3,799	4,145	4,295	4,348	4,637	4,882

ตารางที่ 2 : จำนวนเมล็ดข้าวสารที่ตรวจจับได้ในภาพข้อมูลชุดทดสอบทั้งหมด

	การทับซ้อน (ร้อยละ)					
	0	5	10	15	20	25
คาราก้าดาก	4,208	4,602	4,830	4,778	5,084	5,302
หอมมะลิ	4,047	4,630	4,568	4,792	5,179	5,214
ยิปซาลา	2,473	2,585	2,772	2,894	3,029	3,142
บาสมาติ	3,011	3,443	3,588	3,774	3,914	3,968
อาโบริโอ	3,889	4,259	4,447	4,562	4,877	5,194

ทั้งนี้เพื่อประเมินค่าขีดแบ่งที่เหมาะสมในการวัดความแม่นยำของตัวแบบ จะทดสอบโดยใช้ค่าขีดแบ่งทั้งหมด 6 ค่าได้แก่ 0.75, 0.70, 0.65, 0.60 และ 0.55 และผลการตรวจวัดความแม่นยำเรียงตามค่าขีดแบ่งทั้ง 6 ได้แสดงดังปรากฏในตารางที่ 3 ถึงตารางที่ 7 ตามลำดับ

ตารางที่ 3 : การวัดความแม่นยำของตัวแบบด้วยค่าขีดแบ่งเท่ากับ 0.75

การทับซ้อน (ร้อยละ)	จำนวน correct	จำนวน incorrect	ความแม่นยำ
0	17,418	210	0.9881
5	19,117	402	0.9794
10	19,579	626	0.9690
15	19,940	860	0.9586
20	20,805	1,278	0.9421
25	21,176	1,644	0.9280

ตารางที่ 4 : การวัดความแม่นยำของตัวแบบด้วยค่าขีดแบ่งเท่ากับ 0.70

การทับซ้อน (ร้อยละ)	จำนวน correct	จำนวน incorrect	ความแม่นยำ
0	17,459	169	0.9904
5	19,229	290	0.9851
10	19,757	448	0.9778
15	20,170	630	0.9697
20	21,145	938	0.9575
25	21,612	1,208	0.9471

ตารางที่ 5 : การวัดความแม่นยำของตัวแบบด้วยค่าขีดแบ่งเท่ากับ 0.65

การทับซ้อน (ร้อยละ)	จำนวน correct	จำนวน incorrect	ความแม่นยำ
0	17,471	157	0.9911
5	19,294	225	0.9885
10	19,859	346	0.9829
15	20,326	474	0.9772
20	21,390	693	0.9686
25	21,933	887	0.9611

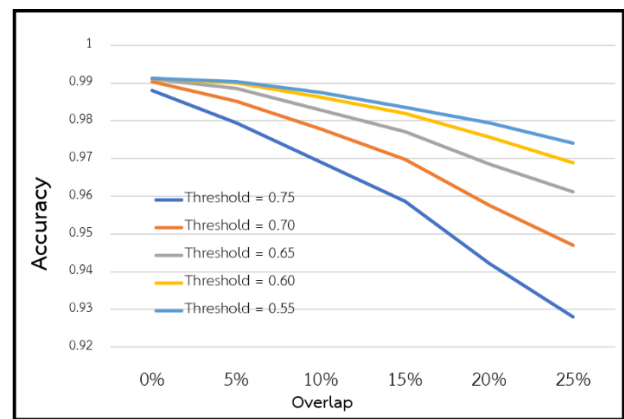
ตารางที่ 6 : การวัดความแม่นยำของตัวแบบด้วยค่าขีดแบ่งเท่ากับ 0.60

การทับซ้อน (ร้อยละ)	จำนวน correct	จำนวน incorrect	ความแม่นยำ
0	17,475	153	0.9913
5	19,324	195	0.9900
10	19,926	279	0.9862
15	20,423	377	0.9819
20	21,545	538	0.9756
25	22,111	709	0.9689

ตารางที่ 7 : การวัดความแม่นยำของตัวแบบด้วยค่าขีดแบ่งเท่ากับ 0.55

การทับซ้อน (ร้อยละ)	จำนวน correct	จำนวน incorrect	ความแม่นยำ
0	17,475	153	0.9913
5	19,332	187	0.9904
10	19,952	253	0.9875
15	20,460	340	0.9836
20	21,630	453	0.9795
25	22,228	592	0.9740

ข้อมูลความแม่นยำของตัวแบบ เมื่อประเมินด้วยค่าขีดแบ่งต่าง ๆ ที่แสดงในตารางที่ 3 ถึงตารางที่ 7 สามารถแสดงเป็นกราฟความแม่นยำได้ดังแสดงในรูปที่ 14



รูปที่ 14 : กราฟความแม่นยำของตัวแบบเมื่อตรวจวัดด้วยค่าขีดแบ่ง 0.75, 0.70, 0.65, 0.60 และ 0.55

5) สรุปผล

ในงานวิจัยนี้สามารถประยุกต์ใช้วิธีการตรวจหาวัตถุด้วยตัวแบบ YOLOv5 เพื่อใช้ในการจำแนกสายพันธุ์และตำแหน่งของเมล็ดข้าวสารที่อยู่ในภาพที่มีเมล็ดข้าวสารหลากหลายปรากฏอยู่ในภาพได้ ไม่ว่าจะทั้งในแบบที่ไม่มีภาพของเมล็ดข้าวสารซ้อนทับกันเลย หรือกรณีที่มีภาพเมล็ดข้าวสารซ้อนทับกันอยู่ตั้งแต่ไม่เกินร้อยละ 5, 10, 15, 20 และ 25 และเนื่องด้วยการระบุตำแหน่งของวัตถุอยู่ในรูปแบบของกรอบสี่เหลี่ยมผืนผ้า และมีเมล็ดข้าวสารที่ทับซ้อนกัน ทำให้ต้องออกแบบการประเมินประสิทธิภาพความแม่นยำใหม่ โดยพิจารณาจากอัตราส่วนจุดภาพของเมล็ดข้าวสารที่ตรวจได้เทียบกับจำนวนจุดภาพต่าง ๆ ที่ไม่ใช่ภาพพื้นหลัง ดังนั้นการหาขีดแบ่งที่เหมาะสมเพื่อระบุว่าอัตราส่วนดังกล่าวเป็นการตรวจหาที่ถูกต้องหรือไม่ ต้องพิจารณาจากผลการวัดความ

แม่นยำของตัวแบบด้วยค่าขีดแบ่งค่าต่าง ๆ เมื่อพิจารณาจากกราฟความแม่นยำของตัวแบบที่มีค่าขีดแบ่งต่าง ๆ จะพบว่าค่าขีดแบ่งที่ 0.60 มีความเหมาะสมที่จะใช้ในการประเมินความแม่นยำ เนื่องจากเมื่อพิจารณาข้อมูลชุดทดสอบที่ไม่มีภาพเมล็ดข้าวสารซ้อนทับกันเลย (ซ้อนทับร้อยละ 0) เมื่อวัดความถูกต้องของตัวแบบโดยใช้ค่าขีดแบ่งที่ลดลง ค่าความถูกต้องก็มากขึ้น และพบว่าที่ค่าขีดแบ่ง 0.60 และ 0.55 ตัวแบบ YOLOv5 ให้ผลการตรวจหาเมล็ดข้าวสารที่มีความถูกต้องเท่ากันถือว่า 0.60 เป็นค่าขีดแบ่งที่มีค่าสูงกว่าที่ไม่ทำให้ผลการตรวจหาพันธุ์เมล็ดข้าวสารที่ไม่มีภาพซ้อนทับกันเปลี่ยนแปลง และที่ค่าขีดแบ่งดังกล่าวจะถือว่าตัวแบบ YOLOv5 สามารถจำแนกพันธุ์ข้าวที่ปรากฏในภาพที่มีภาพเมล็ดข้าวสารซ้อนทับกันร้อยละ 0, 5, 10, 15, 20 และ 25 ได้ถูกต้องร้อยละ 99.13, 99.00, 98.62, 98.19, 97.56 และ 96.89 ตามลำดับ

6) ข้อเสนอแนะ

จากผลการวิจัยจะเห็นว่าวิธีการจำแนกเมล็ดข้าวสารด้วยวิธีการตรวจหาวัตถุ ที่ได้นำเสนอขึ้นมา ทำงานได้ด้วยความแม่นยำสูง ทั้งนี้หากนำไปประยุกต์ใช้กับเมล็ดข้าวสารพันธุ์ต่าง ๆ ที่มีจำหน่ายในท้องตลาดของประเทศไทย ผลที่ได้จะสามารถนำไปต่อยอดในการตรวจสอบคุณภาพของข้าวที่จะส่งออกของประเทศไทยได้ในอนาคต

REFERENCES

- [1] M. Shahbandeh. "Principal rice exporting countries worldwide 2022/2023." STATISTA.com. <https://www.statista.com/statistics/255947/top-rice-exporting-countries-worldwide-2011/> (accessed Apr. 10, 2023).
- [2] Thai Rice Exporters Association. "F.O.B. Prices." THAIRICEEXPO RTERS.or.th. <http://www.thairiceexporters.or.th/> (accessed Apr. 10, 2023).
- [3] *Notifications of the Ministry of Commerce: Prescribe Thai Hom Mali Rice as a Standard Product and Thai Hom Mali Rice Product Standard (no. 3), B.E. 2559*, Thai Government Gazette 133(243D), Ministry of Commerce, Oct. 21, 2016.
- [4] R. Chityala and S. Pudipeddi, *Image Processing and Acquisition Using Python*. New York, NY, USA: CRC Press, 2014.
- [5] R. C. Gonzalez and R. E. Woods, *Digital Image Processing*, 3rd ed. Upper Saddle River, NJ, USA: Pearson Prentice Hall, 2008.
- [6] S. S. A. Zaidi, S. Ansari, A. Aslam, N. Kanwal, M. Asghar, and B. Lee, "A survey of modern deep learning based object detection models," *Digit. Signal Process.*, vol. 126, 2022, Art. no. 103514, doi: 10.1016/j.dsp.2022.103514.
- [7] D. Thuan, "Evolution of YOLO algorithm and YOLOV5: The state-of-the-art object detection algorithm," B.S. thesis, Dept. Inform. Technol., Oulu Univ. Appl. Sci., Oulum, Finland, 2021.
- [8] O. Aki, A. Güllü, and E. Uçar, "Classification of rice grains using image processing and machine learning techniques," in *Proc. Int. Sci. Conf. "UNITECH 2015"*, Gabrovo, Bulgaria, Nov. 2015, pp. 352–354.
- [9] H. Zareiforush, S. Minaei, M. R. Alizadeh, and A. Banaka, "Qualitative classification of milled rice grains using computer vision and metaheuristic techniques," *J. Food Sci. Technol.*, vol. 53, no. 1, pp. 118–131, Jan. 2016.
- [10] I. Cinar and M. Koklu, "Classification of rice varieties using artificial intelligence methods," *Int. J. Intell. Syst. Appl. Eng.*, vol. 7, no. 3, pp. 188–194, 2019.
- [11] I. Cinar and M. Koklu, "Determination of effective and specific physical features of rice varieties by computer vision in exterior quality inspection," *Selcuk J. Agriculture Food Sci.*, vol. 35, no. 3, pp. 229–243, 2021.
- [12] M. Koklu, I. Cinar, and Y. S. Taspinar, "Classification of rice varieties with deep learning methods," *Comp. Electron. Agriculture*, vol. 187, 2021, Art. no. 106285, doi: 10.1016/j.compag.2021.106285.
- [13] I. Cinar and M. Koklu, "Identification of rice varieties using machine learning algorithms," *J. Agricultural Sci. (Tarim Bilimleri Dergisi)*, vol. 28, no. 2, pp. 307–325, 2022.