บทความวิจัย (Research Article)

การพัฒนาแบบจำลองการตรวจจับพริกชี้ฟ้าสำหรับเครื่องคัดแยก

Chili Spur Pepper Detection Model Developing for Sorting Machine

วัชรพล หาญทองดี[1] ภูวิศ ศิริรัตนกุลชัย[1] คิรากร องคชื่น[1] และ สุพาพร บรรดาศักดิ์[1*]
Watcharapon Hantongdee[1], Phuvit Sirirattanakulchai[1], Kilakorn ongkhachuen[1] and Supaporn Bundasak[1*]
คณะวิทยาศาสตร์ ศรีราชา มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา
Faculty of Science at Sriracha, Kasetsart University Siracha Campus
[*]Corresponding author email: supaporn.band@ku.th

วันที่รับบทความ (Received)	วันที่ได้รับบทความฉบับแก้ไข (Revised)	วันที่ตอบรับบทความ (Accepted)
6 มีนาคม 2567	23 สิงหาคม 2567	26 สิงหาคม 2567

บทคัดย่อ

คณะวิทยาศาสตร์ ศรีราชา มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตศรีราชา ตั้งอยู่ในเขตอุตสาหกรรมและการเกษตร ต้องการส่งเสริมการพัฒนาอุตสาหกรรมการเกษตรโดยใช้เทคโนโลยีทางคอมพิวเตอร์นำมาพัฒนา ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์ในการปรับปรุงกระบวนการคัดแยกเพื่อคัดแยกพริกชี้ฟ้าตามสีที่เหมาะสม โดยการใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) เช่น YOLO เพื่อพัฒนาโมเดลในการวิเคราะห์สีของพริกชี้ฟ้า สำหรับการคัดแยกสีและการกำหนดระยะเวลาที่เหมาะสมสำหรับการใช้งาน เพื่อนำโมเดลใช้ร่วมกับเครื่องคัดแยกเป็นการปรับปรุงกระบวนการคัดแยกในสายการผลิตและบรรจุภัณฑ์ของพริกชี้ฟ้าในอุตสาหกรรมเกษตร ทางผู้วิจัยจึงได้ประยุกต์ใช้เทคนิค YOLO พัฒนาโมเดลในการคัดแยกพริกชี้ฟ้าที่สามารถคัดแยกพริกชี้ฟ้าตามสีได้อย่างแม่นยำ โดยการเก็บรวบรวมข้อมูลภาพพริกชี้ฟ้าจำนวน 294 ภาพ และใช้สถิติการวัดผล ได้แก่ Precision, Recall และ Mean Average Precision (mAP) เพื่อประเมินผลการทำงานของโมเดล ผลการวิจัยพบว่าโมเดลที่พัฒนามีความแม่นยำสูงโดยมีค่า Precision เฉลี่ย 99.6% การศึกษาความสามารถของแบบจำลองในการนำไปใช้งาน โดยพิจารณาถึงความแม่นยำ ความรวดเร็ว และความคุ้มค่าทางเศรษฐกิจ ซึ่งสามารถนำไปพัฒนาใช้กับเครื่องคัดแยกพริกได้อย่างมีประสิทธิภาพ เพื่อให้การคัดแยกสีของพริกเป็นไปตามความต้องการ นอกจากนี้ผลการวิจัยครั้งนี้ยังสามารถเสนอแนวทางในการพัฒนาต่อยอดและประยุกต์ใช้เทคโนโลยีการตรวจจับด้วยภาพสำหรับการคัดแยกผลิตภัณฑ์เกษตรชนิดอื่น ๆ เพื่อเพิ่มประสิทธิภาพและลดการสูญเสียในกระบวนการผลิตในอุตสาหกรรมการเกษตร

คำสำคัญ; การเรียนรู้เชิงลึก, YOLOv5, การทำนาย, อุตสาหกรรมการคัดแยก

Abstract

Faculty of Science at Sriracha, Kasetsart University Siracha Campus, located in an industrial and agricultural area, aims to advance the agricultural industry through the application of computer technology. This research focuses on improving the sorting process for chili spur peppers by utilizing deep learning

techniques such as YOLO to develop a model that accurately analyzes and sorts of peppers by color. The model is intended to enhance sorting processes in production lines and packaging within the agricultural industry. Researchers applied the YOLO technique, collecting 294 images of chili spur peppers and evaluating the model's performance using metrics such as Precision, Recall, and Mean Average Precision (mAP). The results demonstrated a high accuracy, with an average Precision of 99.6%. The study also eva luated the model's practical application, considering factors like accuracy, speed, and economic efficiency, showing that it could be effectively implemented in chili sorting machines. However, further refinement is needed to improve accuracy in certain environmental conditions. Additionally, the research provides insights for the further development and application of image detection technology for sorting other agricultural products, aiming to increase efficiency and reduce waste in agricultural production processes.

Keywords; Deep learning, YOLOv5, Prediction, Sorting industry

บทนำ

พริกชี้ฟ้าเป็นพืชที่มีคุณค่าทางอาหารและมีความหลากหลายในการใช้งาน ปริมาณสารต่าง ๆ ในพริกแต่ละสีนั้นก็มีความแตกต่างกัน เช่น พริกสีแดงมีสารเบต้าแคโรทีนและวิตามินซีสูงกว่า ซึ่งมีประโยชน์ต่อสุขภาพ ส่วนพริกสีเขียวมีระยะเวลาการเก็บรักษาที่ยาวนานกว่า เหมาะสำหรับการขนส่งไกลและการเก็บสต็อก ดังนั้น การคัดแยกสีของพริกจึงมีความสำคัญต่อผู้ประกอบการในการเพิ่มมูลค่าและประสิทธิภาพในการจัดการสินค้า ในอดีตการคัดแยกพริกโดยใช้แรงงานคนต้องใช้เวลามากและมีความผิดพลาดสูง การประมวลผลภาพแบบดั้งเดิม (Image Processing) ได้ถูกนำมาใช้เพื่อช่วยในการคัดแยก แต่ยังคงมีข้อจำกัดในเรื่องของความแม่นยำและการปรับปรุงประสิทธิภาพ การใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) เข้ามาช่วยในการวิเคราะห์สีของพริกเป็นแนวทางที่สามารถเพิ่มความแม่นยำและประสิทธิภาพในการคัดแยกได้มากขึ้น โดยเฉพาะอย่างยิ่งเทคนิค You Only Look Once (YOLO) ที่เป็นที่รู้จักในเรื่องของความรวดเร็วและความแม่นยำในการตรวจจับวัตถุ งานวิจัยหลายชิ้นยืนยันว่าเทคนิค YOLO มีความแม่นยำสูงและสามารถใช้งานได้หลากหลาย เช่น การตรวจจับวัตถุและการวิเคราะห์ภาพในหลายอุตสาหกรรม การใช้ YOLOv5 ในการคัดแยกดอกดาวเรืองและพบว่ามีความแม่นยำสูง [1] และการนำ YOLOv5 ใช้ในการนับจำนวนนกแอ่นกินรังและยืนยันว่า YOLOv5 มีประสิทธิภาพสูงในการตรวจจับวัตถุ [2] ในงานวิจัยนี้ ได้นำเทคนิค YOLOv5 มาประยุกต์ใช้ เพื่อพัฒนาโมเดลในการคัดแยกพริกชี้ฟ้าทำให้การคัดแยกพริกสะดวกและรวดเร็วมากยิ่งขึ้น การเก็บรวบรวมข้อมูลภาพพริกใช้ YOLOv5 ในการประมวลผลและวิเคราะห์สีของพริก

เอกสารและทฤษฎีที่เกี่ยวข้อง

พริกสามารถเติบโตได้ในดินแทบทุกชนิด ชอบดินร่วนปนทรายจะเจริญได้ดี พริกจะให้ผลผลิตประมาณ 2 เดือน หลังย้ายปลูกในแปลง ผลดิบมีสีเขียวอ่อนผลสุกมีสีแดง ในพริกมีสารที่ช่วยป้องกันโรคต่าง ๆ [3] เช่น สาร Capsaicin ในพริกจะช่วยลดปริมาณสารที่ขัดขวางระบบการหายใจ และลดการอุดตันของเส้นเลือด นอกจากนี้ยังมีสารเบต้าแคโรทีนที่ช่วยบำรุงสายตา ลด

อัตราการเสี่ยงของโรคมะเร็งในปอด [4] การทำ Deep Learning หรือการเรียนรู้เชิงลึก เป็นการฝึกฝนคอมพิวเตอร์ให้สามารถทำงานได้เหมือนมนุษย์ เช่น การจดจำคำพูด การระบุภาพ หรือการคาดการณ์ [5] โดยมีการจำลองเซลล์ประสาทของมนุษย์ออกมาเป็น Artificial Neural Network หรือ ANN [6] สามารถจำลองได้ทั้งหมด 3 ส่วน คือ รับข้อมูล ประมวลผล และผลลัพธ์ที่ได้ซึ่ง Deep Learning จะจำลองได้ออกมาหลายชั้นการเรียนรู้เชิงลึก การเรียนรู้เชิงลึกซึ่งเป็นสาขาหนึ่งของการเรียนรู้ของเครื่อง (ML) และปัญญาประดิษฐ์ (AI) ในปัจจุบันถือเป็นเทคโนโลยีหลักของการปฏิวัติอุตสาหกรรมครั้งที่สี่ในปัจจุบัน [7] ซึ่งจะต่างจากการทำ Image Processing ซึ่งมักจะมุ่งเน้นการปรับปรุงหรือประมวลผลภาพโดยใช้เทคนิคทางคณิตศาสตร์และกระบวนการต่าง ๆ เช่น การทำฟิลเตอร์, การแปลงภาพหรือการลบสัญญาณรบกวน การทำโมเดลการวิเคราะห์ภาพเพื่อใช้กับเครื่องคัดแยก จำเป็นต้องมีส่วนของการประมวลภาพ เพราะเป็นขั้นตอนการวิเคราะห์ภาพของวัตถุ เพื่อหาลักษณะเด่นของวัตถุที่อยู่ในภาพ ซึ่งแสงและความละเอียดของกล้องมีผลต่อการตรวจจับ [1]

การตรวจจับวัตถุ (Object Detection) คือ การสอนให้คอมพิวเตอร์ทำหน้าที่เสมือนดวงตา ที่สามารถรับรู้ได้ว่าในรูปภาพที่แสดงอยู่ มีวัตถุอะไรบ้างที่เราสนใจ และบอกตำแหน่งของวัตถุต่าง ๆ เหล่านั้น ว่าตั้งอยู่ตรงไหนของภาพ [8] โดยใช้ AI ตรวจจับวัตถุชนิดที่กำหนด เช่น มนุษย์ รถยนต์ อาคาร ที่อยู่ในรูปภาพ หรือวิดีโอ สามารถประยุกต์ใช้ได้หลากหลาย เช่น ใช้ในงานรักษาความปลอดภัย และรถยนต์ไร้คนขับ เป็นต้น [9]

“You Only Look Once” (YOLO) คืออัลกอริทึมสำหรับตรวจจับวัตถุได้แบบตามเวลาจริง โดยมีระดับความแม่นยำ 0.709 ระดับการเรียกคืน 0.634 และ MAP50 ความแม่นยำเฉลี่ย 0.713 และ ใช้กันอย่างแพร่หลายในปัจจุบัน ซึ่งเวอร์ชั่น V5 เขียนด้วย PyTorch ซึ่งข้อดีคือมันมีความเร็ว 140 เฟรมต่อวินาทีโดยมีความแม่นยำและมีขนาดเล็กกว่า YOLO v4 ถึง 90% ซึ่งนั่นหมายความว่าจะสามารถนำไปฝังหรือประยุกต์กับอุปกรณ์ขนาดเล็กได้ดีกว่า [10] อัลกอริทึม YOLO เป็น Object Detection Model ตัวหนึ่งที่มีความโดดเด่นอย่างมากในด่านของความเร็ว ตลอดจนการปรับปรุงบางอย่างในขั้นตอนการคาดคะเนกรอบขอบเขตที่แตกต่างกันเพื่อแยกคุณสมบัติ [11] ตัวอย่างเช่นการนำมาใช้ในงานวิจัย การพัฒนาระบบนับจำนวนนกแอ่นกินรังด้วย YOLO Object Detection ผ่านกล้องถ่ายภาพความร้อน ที่ได้ใช้กล้องตรวจจับความร้อนนับจำนวนนกแบบเรียลไทม์ และทำการนำภาพของนกที่ได้เข้าอัลกอริทึม YOLO [2]

การติดป้ายกำกับข้อมูล (Data Labeling) คือกระบวนการให้ป้ายกำกับหรือระบุข้อมูลเฉพาะกับข้อมูลดิบ (Raw Data) เพื่อให้เครื่องจักรหรืออัลกอริทึมการเรียนรู้ของเครื่องสามารถใช้ข้อมูลนั้นในการฝึกฝนและเรียนรู้ได้อย่างถูกต้อง ตัวอย่างเช่น การติดป้ายกำกับรูปภาพของแมวและสุนัขว่าเป็นแมวหรือสุนัข หรือการระบุข้อความในเอกสารว่าเป็นประเภทใด เช่น ข่าวสาร บทวิจารณ์ หรือข้อความโฆษณา การติดป้ายกำกับข้อมูลเป็นกระบวนการที่สำคัญในโครงการการเรียนรู้ของเครื่อง แบบมีผู้สอน (Supervised Learning) เพราะโมเดลการเรียนรู้ของเครื่องต้องการข้อมูลที่ถูกติดป้ายกำกับอย่างถูกต้องเพื่อเรียนรู้และทำการทำนายได้อย่างแม่นยำ การติดป้ายกำกับสามารถทำได้หลายวิธี เช่น

1. **การติดป้ายกำกับด้วยตนเอง (Manual Labeling)**: ผู้เชี่ยวชาญหรือผู้ใช้มนุษย์ทำการติดป้ายกำกับข้อมูลด้วยตนเอง
2. **Crowdsourcing**: การใช้แพลตฟอร์มออนไลน์เพื่อให้คนทั่วไปช่วยติดป้ายกำกับข้อมูล
3. **Active Learning**: การให้โมเดลการเรียนรู้ของเครื่องเลือกข้อมูลที่ต้องการให้ผู้ใช้มนุษย์ช่วยติดป้ายกำกับ

4. **Semi-Supervised Learning**: การใช้ข้อมูลที่ถูกติดป้ายกำกับบางส่วนร่วมกับข้อมูลที่ไม่ได้ติดป้ายกำกับเพื่อฝึกฝนโมเดล

การติดป้ายกำกับข้อมูลที่ถูกต้องและเชื่อถือได้เป็นสิ่งสำคัญสำหรับการพัฒนาโมเดลการเรียนรู้ของเครื่องที่มีประสิทธิภาพและแม่นยำ ดังนั้นการติดป้ายกำกับข้อมูลเป็นหัวใจสำคัญของการเรียนรู้ของเครื่องแบบมีผู้สอน อย่างไรก็ตามในการใช้งานในอุตสาหกรรม ข้อมูลมักไม่มีการติดป้ายกำกับ ซึ่งทำให้การใช้ข้อมูลนี้กับการเรียนรู้ของเครื่องมีความซับซ้อน แม้ว่าจะมีเทคนิคการติดป้ายกำกับที่เป็นที่รู้จักดี เช่น crowdsourcing, active learning, และ semi-supervised learning แต่ก็ยังไม่สามารถให้ป้ายกำกับที่แม่นยำและเชื่อถือได้สำหรับทุกกรณีการใช้งานในอุตสาหกรรม ด้วยเหตุนี้ อุตสาหกรรมยังคงพึ่งพาการติดป้ายกำกับและการตั้งชื่อข้อมูลด้วยตนเองเป็นหลัก จึงได้มีการศึกษาสำรวจปัญหาที่บริษัทต่าง ๆ เผชิญเมื่อต้องติดป้ายกำกับและตั้งชื่อข้อมูลของตน โดยได้ดำเนินการศึกษากรณีด้วยการสัมภาษณ์แบบกึ่งโครงสร้างกับนักวิทยาศาสตร์ข้อมูลที่สองบริษัทเพื่อสำรวจปัญหาที่พวกเขาเผชิญในการติดป้ายกำกับและการตั้งชื่อข้อมูล ระบุปัญหาที่อุตสาหกรรมเผชิญในกระบวนการติดป้ายกำกับ และเสนอแนวทางแก้ไขสำหรับปัญหาเหล่านี้ [12]

สำหรับโปรแกรม Code Editor สำหรับแก้ไขและปรับแต่งโค้ดในครั้งนี้ ได้เลือก Visual Studio Code เป็นโปรแกรม Code Editor สำหรับแก้ไขและปรับแต่งโค้ด การศึกษานี้ใช้ Convolutional Neural Network (CNN) ในการตรวจจับพริกและใบในภาพต้นพริก ซึ่งมีความสำคัญต่อการพัฒนาเทคโนโลยีการมองเห็นของหุ่นยนต์และการเฝ้าติดตามการเจริญเติบโตของพืช งานวิจัยนี้มุ่งพัฒนาระบบที่สามารถเฝ้าติดตามและระบุต้นพริกขี้หนูโดยใช้เทคนิคการเรียนรู้ของเครื่อง โดยข้อมูลภาพถูกแบ่งเป็นชุดฝึกฝน ชุดตรวจสอบ และชุดทดสอบในอัตราส่วน 70:20:10% และใช้ YOLO V4 Darknet ในการฝึกฝนโมเดล หลังการทดลองพบว่า YOLO V4 Darknet มีค่า mAP สูงสุดที่ 76.54% ตามด้วย EfficientDet ที่ 73.66% แสดงให้เห็นว่า YOLO V4 Darknet มีประสิทธิภาพสูงสุดในการตรวจจับพริกและใบ [13] การวิจัยนี้พัฒนาโมเดลตรวจจับแมลงศัตรูพืชสำหรับพริกแดงอินโดนีเซียโดยใช้ YOLOv5 ที่ปรับแต่งข้อมูลจากแปลงปลูกพริกในจังหวัดเบงกูลู อินโดนีเซีย มีภาพรวม 4,994 ภาพ ครอบคลุม 4 คลาสและแมลงศัตรูพืช 10,683 ตัว โมเดลฝึกด้วยการปรับค่าพารามิเตอร์ patience ที่ 100, 200 และ 300 โดยมีค่า mAP@0.5 ที่ดีที่สุดที่ 81.3% และความเร็วในการประมวลผลที่ 20 มิลลิวินาทีต่อภาพ หรือ 50 fps บน NVIDIA P100 GPU ผลการทดลองชี้ว่า YOLOv5 สามารถตรวจจับแมลงศัตรูพืชได้อย่างแม่นยำและรวดเร็ว [14]

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาแบบจำลองการตรวจจับและคัดแยกพริกชี้ฟ้าตามสี โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก โดยเฉพาะอย่างยิ่งโมเดล YOLO เพื่อเพิ่มความแม่นยำและประสิทธิภาพในการคัดแยกพริกในกระบวนการผลิตเชิงอุตสาหกรรม
2. เพื่อสร้างและรวบรวมชุดข้อมูลภาพพริกชี้ฟ้าที่มีความหลากหลายของสีและลักษณะเฉพาะสำหรับการฝึกและทดสอบโมเดล ซึ่งจะสนับสนุนการพัฒนาระบบตรวจจับที่มีความทนทานและแม่นยำสูง
3. เพื่อศึกษาความสามารถของแบบจำลองในการนำไปใช้งานจริงในสายการผลิตและบรรจุภัณฑ์ของพริกชี้ฟ้าในอุตสาหกรรมเกษตร โดยพิจารณาถึงความแม่นยำ ความรวดเร็ว และความคุ้มค่าทางเศรษฐกิจ
4. เพื่อเสนอแนวทางในการพัฒนาต่อยอดและประยุกต์ใช้เทคโนโลยีการตรวจจับด้วยภาพสำหรับการคัดแยกผลิตภัณฑ์เกษตรชนิดอื่น ๆ เพื่อเพิ่มประสิทธิภาพและลดการสูญเสียในกระบวนการผลิตในอุตสาหกรรมการเกษตร

วิธีดำเนินการวิจัย

ในการพัฒนาโมเดลการวิเคราะห์ ได้มีการเก็บรวบรวมรูปภาพข้อพริกทั้งหมด 2 สี ได้แก่ สีแดง และสีเขียว เพื่อนำมาใช้ในการทำ Object Detection โดยได้เลือกใช้การเทรนภาพด้วยอัลกอริทึม YOLOv5 ในการดำเนินงาน

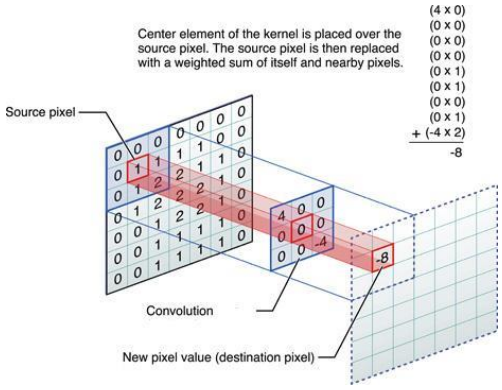

ภาพที่ 1 แสดงกระบวนการทำงานของ Yolo Convolution Layer

จากภาพที่ 1 เป็นการแสดงการทำงานของ Yolo ที่ในแต่ละเวอร์ชั่นจะมีการกำหนด convolution box การคำนวณแต่ละรูปแบบของ Convolution Box YOLO ได้นำเอา Neural Network แบบต่าง ๆ มา ต่อออกจาก Convolution Kernel โดย YOLO มีขั้นตอนในการตรวจจับวัตถุในภาพ คือ แบ่งภาพออกเป็น Grid Cell ขนาดเล็ก และนำ Grid Cell ไปทดสอบความเหมือนกับลำดับโมเดลภาพที่ต้องการเปรียบเทียบ [5]

ภาพที่ 2 เครื่องคัดแยกจำลอง

จากภาพที่ 2 คือเครื่องสำหรับคัดแยกจำลอง ที่จะนำโมเดลในการวิเคราะห์พริกชี้ฟ้ามาใช้ตรวจจับเพื่อคัดแยกพริกในอุตสาหกรรมการคัดแยกที่จะนำมาใช้ร่วมกับโมเดลคัดแยกที่ได้ทำการวิจัยครั้งนี้ดังแสดงกระบวนการทำงานที่ได้ประยุกต์ใช้โมเดลกับเครื่องคัดแยกพริกชี้ฟ้าเพื่อเป็นต้นแบบการวิจัยในการประยุกต์สำหรับคัดแยกผลิตภัณฑ์ในอุตสากรรมการเกษตรในภาพที่ 3

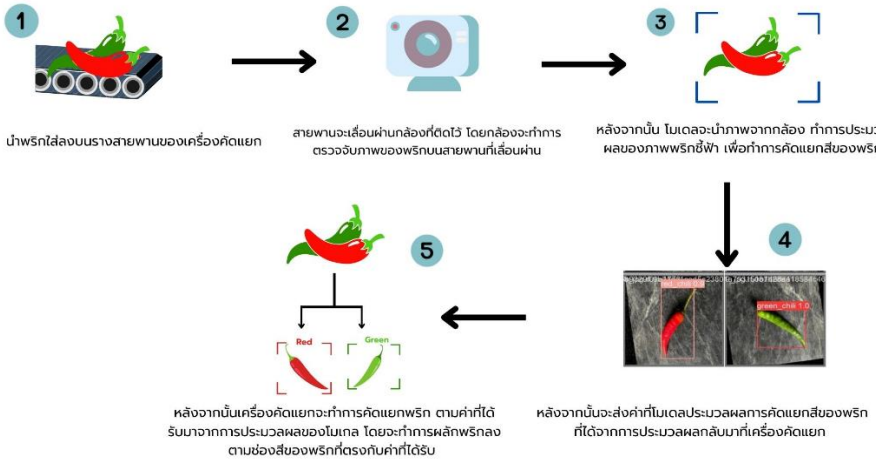

ภาพที่ 3 ขั้นตอนกระบวนการคัดแยกพริกชี้ฟ้า

1. ขั้นตอนการเตรียมข้อมูล

Annotation คือ กระบวนการที่ใช้เพื่อเพิ่มข้อมูลหรือความหมายให้กับข้อมูลดิบ โดยการนำรูปภาพพริกชี้ฟ้าสีเขียวและสีแดง ที่ได้ทำการรวบรวมมา เข้าไปทำการ Annotation ภาพ โดยทำบนเว็บไซต์ Roboflow.com เพื่อความแม่นยำในการคัดแยก จึงมีการทำ Annotation ดังภาพที่ 3 ที่มีการกำหนดรูปร่างลักษณะของพริก และสร้าง Class ตามสีของพริก เพื่อการใช้ในกระบวนการฝึก

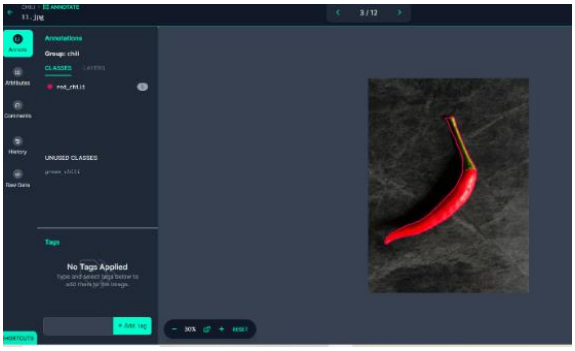

ภาพที่ 4 การทำ Labelling

จากภาพที่ 4 เป็นการทำ Labelling เพื่อทำ Annotation ซึ่งจะได้ ไฟล์ Text ออกมา เพื่อที่ใช้ในการทำ Dataset

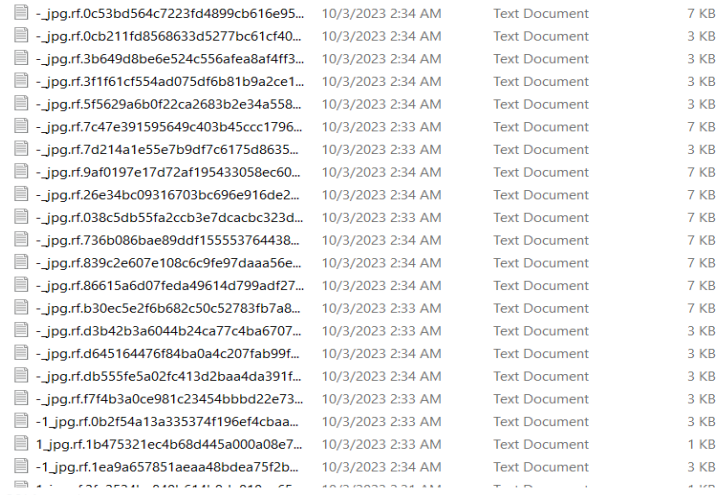

ภาพที่ 5 ผลจากการทำ Annotation

จากภาพ 4 จะเป็นผลของการแปลงข้อมูลเพื่อจะนำข้อมูลไปใช้งานสำหรับการฝึก

2. กระบวนการฝึก (Training)

เป็นขั้นตอนการนำข้อมูลที่ทำ dataset แล้ว เข้ามาทำการฝึก เพื่อให้เรียนรู้ภาพของพริก จากนั้นจะได้ตัวโมเดลออกมาเพื่อใช้ในการทำนายข้อมูลที่จะรับเข้ามาใหม่

```
mary: 157 layers, 7018216 parameters, 0 gradients, 15.8 GFLOP
        Class     Images  Instances          P          R
          all        294        315      0.997          1
  green_chili        294        147      0.999          1
    not_chili        294         21      0.991          1
    red_chili        294        147          1      0.999
```

ภาพที่ 6 ผลการฝึกของโมเดล

ในการ Train Model จะทำการแบ่งข้อมูล โดยแบ่ง Class เป็น 3 Class ได้แก่ Green คือ 0, Red คือ 1, No chili คือ 2, โดยที่ข้อมูลรูปภาพของการฝึกจะมี 294 ภาพ โดยมีการทำ Augmentation รูปภาพ เพื่อให้รูปภาพของพริกมีหลากหลายลักษณะหลายเหตุการณ์ เช่น รูปพริกมีการเอียง เพื่อให้โมเดลที่ทำการฝึกเรียนรู้ลักษณะต่าง ๆ ได้ แบ่งเป็นภาพ พริกสีเขียว 126 ภาพ และพริกสีแดง 126 ภาพ และภาพที่ไม่ใช่พริกทั้งหมด 42 ภาพ และการทดลองครั้งนี้ได้มีการกำหนดให้มีจำนวนในการฝึกทั้งหมด 1,500 ครั้ง

ตารางที่ 1 ผลจากการ train Model

จำนวนคลาส	จำนวนวัตถุอ้างอิงที่จับได้	Precision	Recall
พริกเขียว	147	0.999	1.0
พริกแดง	147	1.0	0.999
วัตถุอื่น ๆ	21	0.991	1.0

จากตารางที่ 1 ผลจากการฝึกตัวโมเดล พบว่ามีการแบ่ง Class เป็น 3 Class ได้แก่ Green chili, Red chili และ Not chili ซึ่งมีค่าความแม่นยำในแต่ละคลาส ได้แก่ Red chili ได้ค่า Precision ที่ 1.0 หรือคิดเป็น 100% และ ค่าrecall 0.999 คลาส Green chili ค่า Precision อยู่ที่ 0.999 หรือคิดเป็น 99.99% และ recall 1.0 และ Not chili ค่า Precision อยู่ที่ 0.991 หรือคิดเป็น 99.91% และ recall เท่ากับ 1.0

ตารางที่ 2 ผลการทดสอบของโมเดล

ผลการทดสอบโมเดล	ผลลัพธ์ที่ได้
recall	0.999
Metrics mAP:0.5	0.995
Metrics mAp:0.5:0.95	0.975
Metrics precision	0.996

จากตารางที่ 2 ค่าผลรวมของโมเดล ซึ่งได้ค่า recall คือ ความสามารถของ Model ในการ Predict หรือระบุสิ่งที่เราสนใจ มีค่าเท่ากับ 0.999 หรือคิดเป็น 99.9% ค่า Metrics mAP:0.5 เท่ากับ 0.995 หรือคิดเป็น 99.5% และค่า Metrics mAp:0.5:0.95 มีค่าเป็น 0.975 หรือคิดเป็น 97.5% ซึ่งค่า mAp คือค่าที่สามารถบอกความแม่นยำโดยเฉลี่ย และมีค่า Precision หรือค่าความแม่นยำ อยู่ที่0.996 หรือคิดเป็น 99.6%

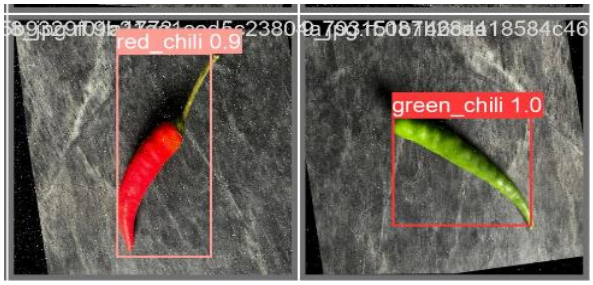

ภาพที่ 7 ผลจากการtrain Model

จากภาพที่ 7 เป็นภาพที่แสดงค่าของการตรวจจับในโมเดล ซึ่งจะเห็นว่าค่าความแม่นยำในแต่ละรูป สูงถึง 1.0 หรือ คิดเป็น100%

ผลการวิจัย

จากการพัฒนาโมเดลได้มีการตรวจสอบการพัฒนาในกระบวนการทดสอบ (Test) เป็นการทดสอบการตรวจจับวัตถุคือการนำข้อมูลมาเข้าสู่โปรแกรมเพื่อทำการทดสอบและโปรแกรมจะทำนายข้อมูลที่นำมาทดสอบว่าข้อมูลนั้นตรงกับค่าที่เคยทำการเรียนรู้หรือไม่ โดยจะทำการทดสอบภาพของพริกชี้ฟ้าด้วยสถานการณ์ต่าง ๆ เพื่อทำการทดสอบความแม่นยำของโมเดลจำนวน 10 ภาพ 10 ครั้ง เพื่อเป็นการทดสอบว่าโมเดลมีความแม่นยำในการวิเคราะห์พริกในสถานการณ์ต่าง ๆ มากน้อยแค่ไหน และปัจจัยที่จะเป็นข้อจำกัดที่ส่งผลต่อค่าความแม่นยำของโมเดล

ภาพที่ 8 แสดงผลของการ test พริกสีเขียวด้วยสภาพแวดล้อมมีแสงน้อย

กรณีที่ 1 การทดสอบโมเดลโดยตรวจจับพริกสีเขียวในกรณีสภาพแวดล้อมมีแสงน้อย จากภาพที่ 8 ตัวอย่างผลการทดสอบจากการทดสอบจำนวนทั้งหมด 10 ภาพ 10 ครั้ง พบว่าผลลัพธ์ที่ได้ สามารถตรวจพบว่าเป็นพริกสีเขียวถูกทั้งหมด ซึ่งมีความมั่นใจเฉลี่ย 0.64 หรือคิดเป็น 64%

ภาพที่ 9 แสดงผลของการ test พริกสีแดง ด้วยสภาพแวดล้อมมีแสงน้อย

กรณีที่ 2 การทดสอบโมเดลโดยตรวจจับพริกสีแดงในกรณีสภาพแวดล้อมมีแสงน้อยจากภาพที่ 9 ตัวอย่างผลการทดสอบจากจำนวน 10 ภาพ 10 ครั้งพบว่าผลลัพธ์ที่ได้สามารถตรวจพบว่าเป็นพริกสีแดงถูกต้องทั้งหมดซึ่งมีความมั่นใจเฉลี่ย 0.49 หรือคิดเป็น 49%

ภาพที่ 10 แสดงผลของการ test พริกสีแดงด้วยสภาพแวดล้อมที่มีแสงมากเกินไป

กรณีที่ 3 การทดสอบโมเดลโดยตรวจจับพริกสีแดงในกรณีสภาพแวดล้อมที่มีแสงมากเกินไปจากภาพที่ 10 ตัวอย่างผลการทดสอบจากจำนวน 10 ภาพ 10 ครั้ง พบว่าผลลัพธ์ที่ได้สามารถตรวจพบว่าเป็นพริกสีแดงถูกต้องทั้งหมด ซึ่งมีความมั่นใจเฉลี่ยอยู่ที่ 0.86 หรือคิดเป็น 86%

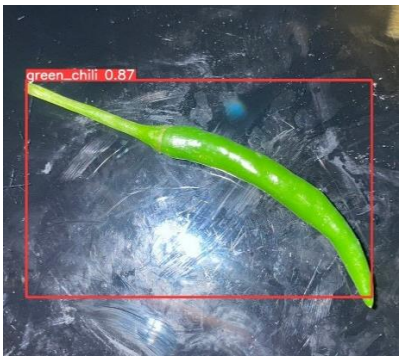

ภาพที่ 11 แสดงผลของการ test พริกสีเขียวด้วยสภาพแวดล้อมที่มีแสงมากเกินไป

กรณีที่ 4 การทดสอบโมเดลโดยตรวจจับพริกสีเขียวในกรณีสภาพแวดล้อมที่มีแสงมากเกินไป จากภาพที่ 11 ตัวอย่างผลการทดสอบจากจำนวน 10 ภาพ 10 ครั้ง พบว่าผลลัพธ์ที่ได้ สามารถตรวจพบว่าเป็นพริกสีเขียวถูกทั้งหมด ซึ่งมีความมั่นใจเฉลี่ย 0.80 หรือคิดเป็น 80%

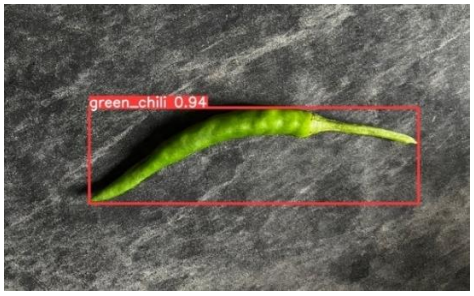

ภาพที่ 12 แสดงผลของการ test พริกสีเขียวด้วยสภาพแวดล้อมที่มีแสงปกติ

กรณีที่ 5 การทดสอบโมเดลโดยตรวจจับพริกสีเขียวในกรณีสภาพแวดล้อมที่มีแสงปกติ จากภาพที่ 12 ตัวอย่างผลการทดสอบจากจำนวน 10 ภาพ 10 ครั้ง พบว่าผลลัพธ์ที่ได้ สามารถตรวจพบว่าเป็นพริกสีเขียวถูกทั้งหมด ซึ่งมีความมั่นใจเฉลี่ยอยู่ที่ 0.88 หรือคิดเป็น 88%

ภาพที่ 13 แสดงผลของการ test พริกสีแดงกรณีสภาพแวดล้อมที่มีแสงปกติ

กรณีที่ 6 การทดสอบโมเดลโดยตรวจจับพริกสีแดงในกรณีสภาพแวดล้อมที่มีแสงปกติ จากภาพที่ 13 ตัวอย่างผลการทดสอบจากจำนวน 10 ภาพ 10 ครั้ง พบว่าผลลัพธ์ที่ได้ สามารถตรวจพบว่าเป็นพริกสีแดงถูกต้องทั้งหมด ซึ่งมีความมั่นใจเฉลี่ย 0.85 หรือคิดเป็น 85%

ภาพที่ 14 แสดงผลของการ test วัตถุอื่น

กรณีที่ 7 การทดสอบโมเดลโดยตรวจจับวัตถุอื่น ๆ จากภาพที่ 14 ตัวอย่างผลการทดสอบจาก จำนวน 10 ภาพ 10 ครั้ง พบว่าผลลัพธ์ที่ได้ สามารถตรวจจับได้ว่าวัตถุไม่ใช่พริกถูกต้องทั้งหมด ซึ่งมีความมั่นใจเฉลี่ยอยู่ที่ 0.57 หรือคิดเป็น 57%

จากผลการทดสอบโมเดลที่พัฒนามานั้น เป็นการทดสอบประสิทธิภาพของโมเดลกรณีภาพนิ่งในกรณีสภาพแวดล้อมต่าง ๆ ได้เป็นอย่างดี แต่การใช้งานโมเดลนำไปประยุกต์ใช้ในเครื่องคัดแยกโดยพริกจะเลื่อนผ่านกล้องตามสายพานการผลิตนำไปสู่อุปกรณ์การคัดแยกของตัวเครื่อง จึงทำการทดสอบโมเดลใช้ผ่านการตรวจจับทดสอบเบื้องต้นด้วยกล้องจากมือถือได้ผลดังภาพที่ 14 และผลการทดสอบภาพเคลื่อนไว้ดังตารางที่ 4 ซึ่งจากภาพที่ 15 ผลการทดสอบโมเดลโดยใช้ภาพเคลื่อนไหวที่มีการปะปนของสีพริกของพริก ทำการทดสอบจำนวน 5 ครั้ง ด้วยกล้องโทรศัพท์มือถือรุ่น Iphone 6 พบว่าผลลัพธ์ที่ได้โมเดลมีการตรวจจับพริกสีต่าง ๆ ได้ถูกต้องสำหรับพริกที่ตรวจจับพบ แต่ก็ยังมีค่าความผิดพลาดในบ้างครั้งยังไม่สามารถตรวจจับวัตถุที่อยู่ชิดกันได้สำหรับความเร็วการเคลื่อนไหวของภาพทำให้ภาพซ้อนชิดกันซึ่งกรณีนี้อาจจะต้องปรับปรุงโมเดลและ ขั้นตอนการทดสอบในสภาวะ

ความเร็วที่เหมาะสมสำหรับเครื่องคัดแยกอีกในอนาคต ดังนั้นผลที่ได้จึงเป็นแนวทางในการพัฒนาปรับปรุงต่อยอดและการประยุกต์ใช้เทคโนโลยีและอุปกรณ์ในการตรวจจับภาพเคลื่อนไหวสำหรับคัดแยกพริกหรือผลิตภัณฑ์การเกษตรชนิดอื่น ๆ ต่อไป

ภาพที่ 15 แสดงผลของการ test พริกด้วยภาพเคลื่อนไหว

ตารางที่ 3 ตารางสรุปผลการทดสอบภาพ

การทดสอบภาพพริกในสภาวะต่าง ๆ	ค่าเฉลี่ยผลการทดสอบทั้งหมด10 ครั้ง (ร้อยละ)
ภาพพริกสีเขียว ในแสงปกติ	0.88
ภาพพริกสีแดง ในแสงปกติ	0.85
ภาพพริกสีเขียว ในที่แสงจ้า	0.80
ภาพพริกสีแดง ในที่แสงจ้า	0.86
ภาพพริกสีเขียว ในแสงน้อย	0.64
ภาพพริกสีแดง ในแสงน้อย	0.49
ภาพวัตถุอื่น	0.57

ตารางที่ 4 ตารางสรุปผลการทดสอบภาพเคลื่อนไหว

การตรวจจับพริกในภาพเคลื่อนไหว	ผลการทดสอบความแม่นยำจำนวน 5 ครั้ง (ร้อยละ)
พริกสีแดง	0.51
พริกสีเขียว	0.43

อภิปรายผลการวิจัย

การวิจัยในครั้งนี้มุ่งเน้นไปที่การพัฒนาแบบจำลองการตรวจจับพริกชี้ฟ้าสำหรับเครื่องคัดแยกเพื่อนำไปประยุกต์ใช้ในด้านอุตสาหกรรม เพื่อลดปัญหาในการคัดแยกพริกที่แต่เดิมใช้แรงงานมนุษย์ในการคัดแยกพริกโดยการคัดแยกพริกด้วยมือเป็นกระบวนการที่ใช้เวลาค่อนข้างมาก และใช้ต้นทุนทางด้านแรงงานอย่างมาก จึงได้ทำการศึกษาการเรียนรู้เชิงลึกเพื่อสร้างโมเดลในการวิเคราะห์พริกและการทดลองครั้งนี้ได้มีการกำหนดให้มีจำนวนในการฝึกทั้งหมด 1,500 ครั้ง ในการวิเคราะห์ ซึ่งจากการวิเคราะห์ในครั้งนี้พบว่าค่าความแม่ยำของโมเดลการวิเคราะห์ภาพ หรือค่า Metrics precision อยู่ที่ 99.96% และผลจากการ

ทดสอบพบว่าในที่แสงปกติที่แสงสว่างคงที่จะสามารถตรวจจับภาพได้อย่างแม่นยำ แต่ในสภาวะสภาพแวดล้อมที่มีแสงจ้าจนเกินไป พบว่าประสิทธิภาพการตรวจจับมีค่าลดลงแต่ยังแม่นยำอยู่ในระดับที่สูง แต่ในสภาวะสภาพแวดล้อมที่แสงน้อยจะทำให้ค่าความแม่นยำต่ำอยู่ที่ 58% และในสภาวะสภาพแวดล้อมที่แสงน้อยและมีพริกหลายสี พบว่า การตรวจจับพริกยังมีค่าที่ผิดพลาดจากผลของแสงทำให้การตรวจจับสีมีปัญหา และการทดสอบโมเดลการคัดแยกวัตถุโดยภาพอื่นที่ไม่ใช่พริกนั้นมีผลการทดสอบความแม่นยำเฉลี่ยอยู่ที่ 57% ซึ่งได้มีการทดสอบภาพที่ไม่ใช่พริก โดยได้ใช้ภาพผักผลไม้ที่มีสีเขียวและสีแดงในการสร้างโมเดล ตัวอย่างเช่น ภาพของตะไคร้ที่มีสีเขียวได้ผลความแม่นยำ อยู่ที่ 60% และภาพของมะเขือเทศสีแดงอยู่ที่ 64% และภาพที่มีพริกสีแดงปนเขียวผลการทดสอบออกมาพบว่า โมเดลวิเคราะห์ภาพมีพริกสีแดงปนเขียวออกมายังไม่แม่นยำ ในบางครั้งหากภาพนั้นมีสีแดงมากกว่าสีเขียว ผลการทดสอบพบว่า จะถูกจัดให้เป็นพริกสีแดงซึ่งค่าความแม่นยำอยู่ที่ 54% หรือในบางครั้งผลที่ได้ออกมาถูกจัดอยู่ในวัตถุอื่นอื่นซึ่งค่าความแม่นยำอยู่ที่ 48% ซึ่งต้องมีการเพิ่มการจำแนกภาพของพริกที่มีสีแดงปนเขียว แยกออกมาอีกหนึ่งประเภท เพื่อให้การวิเคราะห์ภาพได้ผลออกมาที่ดีขึ้น สำหรับภาพที่พริกมีสีที่ปนกัน และการตรวจจับด้วยวิดีโอภาพเคลื่อนไหว ยังไม่สามารถตรวจจับได้ถูกต้องทั้งหมดเนื่องมาจากแสง และด้านข้อจำกัดของอุปกรณ์กล้องถ่ายภาพ อาจส่งผลต่อความคมชัดของวิดีโอภาพเคลื่อนไหว อาจทำให้ภาพเคลื่อนไหวที่ใช้ในการทดสอบไม่คมชัดเพียงพอจึงส่งผลให้ผลการทดสอบมีค่าที่น้อย รวมไปถึงความเร็วของการเคลื่อนไหวอาจส่งผลต่อการตรวจจับ แต่ยังมีในบางครั้งที่ตรวจจับได้ถูกต้อง ดังภาพที่ 14 ซึ่งยังต้องมีการปรับปรุงว่าการวิเคราะห์ภาพเคลื่อนไหวให้ดีกว่าเดิมโดยการเพิ่มจำนวนรอบในการฝึกของโมเดล และมีการเพิ่มจำนวนรูปภาพที่ใช้ในการฝึกให้มากขึ้น และการใช้จำนวนรูปภาพที่แบ่งสัดส่วนเท่ากันทั้งพริกสีแดง พริกสีเขียว และ วัตถุอื่น เพื่อจัดการปัญหาด้าน Imbalance Data เพื่อให้ได้ความแม่นยำที่ดี และเพิ่มการคัดแยกในกรณีที่พริกมีสีปนกัน เพื่อให้มีค่าความแม่นยำในการวิเคราะห์ของโมเดลที่ดีขึ้น

จากศึกษาและพัฒนาโมเดล การทำการทดสอบโมเดลในการวิเคราะห์สีของพริกชี้ฟ้าในการวิจัยครั้งนี้ยังมีข้อจำกัดอยู่ดังต่อไปนี้ ซึ่งปัจจุบันยังทำได้แค่พริกที่มีสีเขียวและแดง ในการพัฒนาวิจัยอาจมีการเพิ่มเติมให้สามารถคัดแยกสีอื่น ๆ เพิ่มขึ้นในอนาคต หรือแม้กระทั่งการคัดแยกพริกแห้งออกจากพริกที่ปกติ เนื่องจากการเก็บข้อมูลรูปภาพของพริกในการทำ Dataset นั้นค่อนข้างใช้เวลานาน เพราะนักวิจัยได้ดำเนินการเก็บข้อมูลด้วยตนเอง และค่าความถูกต้องของโมเดลในช่วงแรกพบว่ามีค่าที่น้อย เนื่องจากข้อมูลที่นำมาใช้ในการ train ยังมีปริมาณน้อย ต้องปรับปรุงขั้นตอนการวิจัยอย่างต่อเนื่อง แต่ปัจจุบันได้มีการปรับเพิ่มและปรับปรุงในบางภาพจึงทำให้ค่าความถูกต้องเพิ่มขึ้น แต่ยังมีข้อจำกัดอื่น ๆ อีกคือเรื่องแสงและอุปกรณ์กล้องถ่ายภาพ หากแสงของภาพที่ทำการตรวจจับไม่คงที่และแสงสว่างน้อยจนเกินไปอาจทำให้ค่าความถูกต้องที่ในการตรวจจับนั้นอาจเป็นค่าที่ต่ำ ซึ่งเกิดจากการผิดพลาดได้ รวมถึงกล้องที่ใช้มีความคมชัดต่ำซึ่งจะทำให้ภาพมีความมืดและอีกข้อหนึ่งคือการที่พริกมีการทับซ้อนกันจนมากเกินไป อาจจะทำให้ค่าที่ตรวจจับได้ผิดพลาด และการตรวจจับด้วยภาพเคลื่อไหวยังมีการผิดเพี้ยนอยู่บ้างในบางครั้ง เนื่องจากปัจจัยเรื่องความเร็วของการเคลื่อนไหวส่งผลต่อการตรวจจับ ในบางครั้งจะสามารถจับวัตถุพริกและแยกสีได้อย่างถูกต้อง แต่บางครั้งก็ยังไม่สามารถตรวจจับได้

สรุปผลการวิจัย

การวิจัยครั้งนี้ได้พัฒนาแบบจำลองการตรวจจับและคัดแยกพริกชี้ฟ้าตามสีคือสีแดงและสีเขียว โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก มีประสิทธิภาพและแม่นยำในสภาพแสงปกติมีความสามารถในการคัดแยกพริกในกระบวนการผลิตเชิงอุตสาหกรรม จากการวิจัยและพัฒนาโมเดลทำให้ผู้วิจัยสร้างและเก็บรวบรวมชุดข้อมูลภาพพริกชี้ฟ้าเป็น dataset สำหรับฝึกฝน

โมเดลที่มีความหลากหลายของภาพแยกสีเขียวสีแดงและภาพ ที่ไม่ใช่พริกแต่ลักษณะและสีใกล้เคียงเพื่อพัฒนาเรียนรู้ลักษณะเฉพาะสำหรับการฝึกและทดสอบโมเดล ให้ได้โมเดลที่มีความทนทานและความแม่นยำสูง และจากการศึกษาเพื่อนำโมเดลไปประยุกต์งานจริงในสายการผลิตและบรรจุภัณฑ์ของพริกชี้ฟ้าในอุตสาหกรรมเกษตรโดยจำลองการตรวจจับผ่านเครื่องคัดแยกจำลองกรณีพริกชี้ฟ้าเคลื่อนที่บนสายพานโดยศึกษาการตรวจจับผ่านภาพเคลื่อนไหวได้ศึกษาโดยพิจารณาถึงความแม่นยำในการตรวจจับสำหรับการใช้งานซึ่งผลการศึกษานี้สามารเสนอแนวทางในการพัฒนาต่อยอดและประยุกต์ใช้เทคโนโลยีการตรวจจับด้วยภาพสำหรับการคัดแยกในกระบวนการผลิตในอุตสาหกรรมการเกษตรซึ่งอาจจะต้องปรับปรุงโมเดลตามผลที่ได้ศึกษาให้ได้โมเดลที่มีประสิทธิภาพที่ดียิ่งขึ้นต่อไป

เอกสารอ้างอิง

1 ภูมินทร์ ต้นอุตม์ และณัฐกร ขำสุวรรณ. “การพัฒนาเครื่องต้นแบบคัดแยกดอกดาวเรืองโดยใช้วิธีการประมวล”. วารสารวิชาการวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏนครสวรรค์ ปีที่ 11 ฉบับที่ 13 มกราคม –มิถุนายน 2562,หน้า 79-92.

2 สิริทัศน์ เลิศตระกูลถาวร “การพัฒนาระบบนับจำนวนนกแอ่นกินรังด้วย YOLO Object Detection ผ่านกล้องถ่ายภาพความร้อน” วิทยานิพนธ์หลักสูตรปริญญาวิทยาศาสตร์มหาบัณฑิต บัณฑิตวิทยาลัยสาขาวิชาเทคโนโลยี สารสนเทศ สถาบันเทคโนโลยีไทย-ญี่ปุ่น ปีการศึกษา 2563 หน้า 13 และ 23

3 THAI-THAIFOOD.COM [ออนไลน์] พริกชี้ฟ้า. 2559. สืบค้นเมื่อ 15 กันยายน 2566, จาก https://shorturl.asia/Qijrb

4 รักชัย คุรุบรรเจิดจิต และคณะ. “การทดสอบพันธุ์พริก ชี้ฟ้าต้านทานต่อโรคแอนแทรคโนส”. แบบรายงานวิจัยกรมวิชาการเกษตร 9 หน้า.

5 Vithan Minaphinant [ออนไลน์] deep learningคืออะไร. 2561. สืบค้นเมื่อ 15 กันยายน 2566, จาก https://shorturl.asia/zx0Q3

6 การเรียนรู้เชิงลึกคืออะไร สำคัญอย่างไร [ออนไลน์] การเรียนรู้เชิงลึกคืออะไร. 2561. สืบค้นเมื่อ 15 กันยายน 2566, จาก https://shorturl.asia/dxh2p

7 Iqbal H. Sarker (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. SN Computer Science. Volume 2, number 420 (2021). https://doi.org/10.1007/s42979-021-00815-1, https://shorturl.asia/yh8Td, pp 1-20

8 Jirat Boonphun [ออนไลน์] Object Detection คืออะไร. 2564. สืบค้นเมื่อ 16 กันยายน 2566, จาก https://shorturl.asia/sNS1B

9 Surapong Kanoktipsatharpong [ออนไลน์] Object Detection คืออะไร. 2563. สืบค้นเมื่อ16 กันยายน 2566, จาก https://shorturl.asia/twFLQ

10 TIPA [ออนไลน์] yolo v5 คืออะไร. 2565. สืบค้นเมื่อ 18 กันยายน 2566, จาก https://shorturl.asia/FQeMi

11 ชวิศ ภูริพัฒน์ “ประสิทธิภาพของระบบตรวจจับวัตถุเคลื่อนที่ กรณีศึกษา ฟาร์มนกแอ่นกินรัง” วิทยานิพนธ์หลักสูตรปริญญาวิทยาศาสตร์มหาบัณฑิต บัณฑิตวิทยาลัยสาขาวิชาเทคโนโลยีสารสนเทศ สถาบันเทคโนโลยีไทย-ญี่ปุ่น ปีการศึกษา 2563. หน้า 20-21

12 T. Fredriksson,D. I. Mattos,J. Bosch, H. H. Olsson (2020), Data Labeling: An Empirical Investigation into Industrial Challenges and Mitigation Strategies, In book: Product-Focused Software Process Improvement ,November 2020, DOI: 10.1007/978-3-030-64148-1_13,16 pages.

13 Shapiee, M.N.A., Abdul Manan, A.A., Mohd Razman, M.A., Mohd Khairuddin, I., P. P. Abdul Majeed, A. (2022). Chili Plant Classification Using Transfer Learning Models Through Object Detection. In: Khairuddin, I.M., *et al.* Enabling Industry 4.0 through Advances in Mechatronics. Lecture Notes in Electrical Engineering, vol 900. Springer, Singapore. https://doi.org/10.1007/978-981-19-2095-0_46 First Online: 15 May 2022, pp. 541–551

14 I. Agustian , R. Faurina , S. I. Ishak , F.P. Utama ,K. Dinata , N. Daratha (2023), Deep learning pest detection on Indonesian red chili pepper plant based on fine-tuned YOLOv5, International Journal of Advances in Intelligent Informatics ,Vol. 9, No. 3, November 2023, pp. 383-401, ISSN 2442-6571, DOI: 10.26555/ijain.v9i3.864