



Received: 5 August 2023

Revised: 13 October 2023

Accepted: 24 October 2023

STUDY OF IMPURITIES DETECTION IN FROZEN SPINACH WITH YOLOV4 DEEP LEARNING MODEL

Suwonnakan SUPAMATTRA¹, Supakit SAYASOONTHORN¹ and Anusron CHUEASAMAT^{1*}¹ Faculty of Agriculture, Kasetsart University, Thailand; anusron.c@ku.th (Corresponding Author)

Handling Editor:

Associate Professor Dr.Panee SUANPANG

Suan Dusit University, Thailand

(This article belongs to the Theme 2: Sciences & Technology for Sustainable Development)

Reviewers:

1) Assistant Professor Dr.Chanchai LAOHA

RMUTI Khonkaen Campus, Thailand

2) Assistant Professor Dr.Chutiwan BOONARCHATONG

Suan Dusit University, Thailand

3) Assistant Professor Dr.Siriporn CHIMPHLEE

Suan Dusit University, Thailand

Abstract

Currently, a technology exists that detects impurities in frozen food products. It helps in keeping control of the food safety and quality. The YOLO deep learning model is used combined with a high-resolution camera to develop a real-time impurity detection system for frozen food. It has the ability to locate and detect small objects. Therefore, the objective of this research is to increase food impurity detection. Therefore, the objective of this research is to increase food impurity detection. A data set containing images of plastic, glass, string, glass, wood, and frozen spinach was generated. A YOLOv4 model was trained on the image dataset. The model performance can be tested and evaluated using a multiclass confusion matrix. Results show that the model has an average loss of 5.55 and a mean Average Precision (mAP) of 76%. The model showed that plastic had the highest detection efficiency when used to detect and classify images of frozen spinach combined with only one impurity, followed by string, glass, rock, and wood, respectively. The accuracy score, precision score, recall, and F1-Score of plastic were 52.22%, 52.94%, 55.38%, and 54.14%, respectively.

Keywords: Deep Learning, Detection, Classification, Frozen Spinach, Impurity

Citation Information: Supamattra, S., Sayasoonthorn, S., & Chueasamat, A. (2023). Study of Impurities Detection in Frozen Spinach with YOLOv4 Deep Learning Model. *Thai Interdisciplinary and Sustainability Review*, 12(2), 131-144. <https://doi.org/10.14456/tisr.2023.12>

การศึกษาการตรวจจับสิ่งเจือปนในผักโขมแช่แข็งด้วยการเรียนรู้เชิงลึก โมเดล YOLOv4

สุวรรณกาญจน์ สุพมาตรา¹, ศุภกิตต์ สายสุนทร¹ และ อนุสรณ์ เชื้อสามารถ^{1*}

1 คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์; anusron.c@ku.th (ผู้ประพันธ์บรรณกิจ)

บรรณาธิการผู้รับผิดชอบบทความ:

รองศาสตราจารย์ ดร.พรรณิ สวนเพลง

มหาวิทยาลัยสวนดุสิต

(บทความนี้เป็นส่วนหนึ่งของหัวเรื่องที่ 2: วิทยาศาสตร์และเทคโนโลยีเพื่อการพัฒนาอย่างยั่งยืน)

ผู้ทรงคุณวุฒิผู้พิจารณาบทความ:

1) ผู้ช่วยศาสตราจารย์ ดร.ชาญชัย เหลาหา

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี วิทยาเขตขอนแก่น

2) ผู้ช่วยศาสตราจารย์ ดร.ชูติวรรณ บุญอาชาทอง

มหาวิทยาลัยสวนดุสิต

3) ผู้ช่วยศาสตราจารย์ ดร.ศิริพร นิยมพลี

มหาวิทยาลัยสวนดุสิต

บทคัดย่อ

ปัจจุบันมีการพัฒนาระบบในการตรวจจับสิ่งเจือปนในผลิตภัณฑ์อาหารแช่แข็ง ซึ่งช่วยในการตรวจสอบคุณภาพและความปลอดภัยในอาหาร การนำระบบการเรียนรู้เชิงลึกที่ใช้แบบจำลอง YOLO มาพัฒนาระบบการตรวจจับสิ่งเจือปนในอาหารแช่แข็งแบบเรียลไทม์ร่วมกับกล้องถ่ายภาพความละเอียดสูง สามารถตรวจจับและระบุตำแหน่งของวัตถุขนาดเล็กได้ ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อเพิ่มความแม่นยำในการตรวจจับสิ่งเจือปนในอาหาร โดยมีขั้นตอนการวิจัยคือการเตรียมชุดข้อมูลภาพผักโขม ไม้ แก้ว เชือก พลาสติก และหิน ผีเสื้อแบบจำลอง YOLOv4 ด้วยชุดข้อมูลรูปภาพ และทดสอบและประเมินประสิทธิภาพแบบจำลองด้วย Multiclass confusion matrix ผลการศึกษพบว่าแบบจำลองนี้มีความแม่นยำโดยรวม (mAP) 76% และมีค่าสูญเสียเฉลี่ย 5.55 กรณีการทดสอบการตรวจจับและจำแนกสิ่งเจือปนบนภาพถ่ายผักโขมรวมกับสิ่งเจือปนเพียง 1 ชนิด พบว่า แบบจำลองมีประสิทธิภาพในการตรวจจับพลาสติกสูงที่สุด รองลงมาคือ เชือก แก้ว หิน และไม้ ตามลำดับ โดยแบบจำลองมีประสิทธิภาพในการตรวจจับพลาสติก มีค่าความถูกต้อง, ค่าความแม่นยำ, ค่ารีคอล และค่าเอฟ-1สกอ์ คือ 52.22%, 52.94%, 55.38% และ 54.14% ตามลำดับ

คำสำคัญ: การเรียนรู้เชิงลึก, การตรวจจับ, การจำแนก, ผักโขมแช่แข็ง, สิ่งเจือปน

ข้อมูลการอ้างอิง: สุวรรณกาญจน์ สุพมาตรา, ศุภกิตต์ สายสุนทร และ อนุสรณ์ เชื้อสามารถ. (2566). การศึกษาการตรวจจับสิ่งเจือปนในผักโขมแช่แข็งด้วยการเรียนรู้เชิงลึกโมเดล YOLOv4. *สหวิทยาการและความยั่งยืนปริทรรศน์ไทย*, 12(2), 131-144. <https://doi.org/10.14456/tisr.2023.12>

บทนำ

ผักโขม (*Spinacia oleracea* L.) มีคุณค่าทางโภชนาการสูงและมีการบริโภคกันอย่างแพร่หลาย ในปี 2564 ผักโขมแช่แข็ง ผักโขมสด ผักโขมหนึ่งหรือต้ม เป็นผลิตภัณฑ์ที่มีการซื้อขายมากเป็นอันดับที่ 3287 ของโลก โดยมีมูลค่าการค้ารวม 327 ล้านดอลลาร์ ระหว่างปี 2563 ถึง 2564 การส่งออกผักโขมแช่แข็ง ผักโขมสด ผักโขมหนึ่งหรือต้มเพิ่มขึ้น 0.68% จาก 325 ล้านดอลลาร์เป็น 327 ล้านดอลลาร์ ในทางการค้าผักโขมแช่แข็ง ผักโขมสด ผักโขมหนึ่งหรือต้ม คิดเป็น 0.000016% ของการค้าทั้งหมดของโลก โดยปี 2564 ผู้ส่งออกผักโขมแช่แข็ง ผักโขมสด ผักโขมหนึ่งหรือต้มรายใหญ่ ได้แก่ เบลเยียม (104 ล้านดอลลาร์) จีน (88.9 ล้านดอลลาร์) สเปน (22.8 ล้านดอลลาร์) เนเธอร์แลนด์ (20.9 ล้านดอลลาร์) และเม็กซิโก (20.9 ล้านดอลลาร์) และผู้นำเข้าผักโขมแช่แข็ง ผักโขมสด ผักโขมหนึ่งหรือต้มรายใหญ่ ได้แก่ ญี่ปุ่น (69.8 ล้านดอลลาร์) สหรัฐอเมริกา (40.9 ล้านดอลลาร์) เยอรมนี (37.1 ล้านดอลลาร์) ฝรั่งเศส (21.8 ล้านดอลลาร์) และสหราชอาณาจักร (14 ล้านดอลลาร์) (The Observatory of Economic Complexity, 2021) ผู้บริโภคนิยมนำผักโขมแช่แข็งมาปรุงอาหารมากมาย เนื่องจากหาซื้อได้ง่าย มีอายุการเก็บรักษาที่ยาวนานทำให้สามารถหาซื้อได้ตลอดทั้งปี ในการเก็บรักษาผักโขมแช่แข็งนั้นมีความกังวลเรื่องการเปลี่ยนแปลงอุณหภูมิในห้องเก็บรักษาหรือตู้แช่แข็ง หากผักโขมแช่แข็งเกิดการละลายในระหว่างการเก็บรักษานั้น การจะนำผักโขมกลับมาแช่แข็งอีกครั้ง จะส่งผลต่อเนื้อสัมผัสของผัก ทำให้เกิดการสูญเสียสารอาหารและน้ำหนักของผักโขมไป (Dermesonluoglu et al., 2015) ดังนั้นหลังการเก็บเกี่ยวจึงต้องแช่แข็งผักโขมให้เร็วที่สุด เพื่อรักษาคุณภาพของผักโขม ทำให้มีสิ่งเจือปนติดมากับผักโขมแช่แข็ง ก่อนจะแปรรูปสู่ผู้บริโภคจำเป็นต้องทำการคัดแยกสิ่งเจือปนเหล่านั้นออกเสียก่อน โดยปกติจะใช้แรงงานคนในการคัดแยกสิ่งเจือปน ซึ่งส่งผลให้มีการใช้แรงงานและเวลามาก แต่ในทางกลับกันการจะรักษาคุณภาพของผักโขมแช่แข็งจำเป็นต้องใช้เวลาให้น้อยที่สุดในการคัดแยกสิ่งเจือปน เพื่อไม่ให้กระทบต่อคุณภาพของผลผลิตและข้อปฏิบัติตามมาตรฐานการแปรรูปอาหาร

ปัจจุบันมีการนำระบบการเรียนรู้ของเครื่อง (Machine learning) เข้ามาใช้งานในภาคส่วนต่างๆ รวมถึงภาคอุตสาหกรรม เนื่องด้วยมีประสิทธิภาพและความแม่นยำ สามารถลดต้นทุนค่าแรงงาน และมีประสิทธิภาพมากกว่ามนุษย์ที่จะทำได้ นอกจากนี้ระบบการเรียนรู้ของเครื่องยังสามารถตรวจสอบคุณภาพและความปลอดภัยของอาหาร การคัดเกรดผลผลิตทางการเกษตร และการตรวจจับวัตถุแปลกปลอมในผลิตภัณฑ์ได้อีกด้วย (Zhu et al., 2021) มีการพัฒนาระบบในการตรวจจับสิ่งเจือปน ตรวจสอบคุณภาพและความปลอดภัยในอาหารมากมาย ไม่ว่าจะเป็นการพัฒนาโครงข่ายประสาทเทียม (Convolutional neural network: CNN) ตรวจจับวัตถุแปลกปลอม เช่น เศษใบไม้เนื้อและชิ้นส่วนโลหะที่ปะปนอยู่กับผลวอลนัต (Walnuts) พบว่าสามารถแบ่งส่วนวัตถุแปลกปลอมออกจากผลวอลนัตได้และมีความแม่นยำถึง 99.5% และการจำแนกประเภทถูกต้องถึง 95% (Rong et al., 2019) หรือการพัฒนาระบบการเรียนรู้เชิงลึก (Deep learning) ด้วยแบบจำลอง YOLO (You only look once) ซึ่งเป็นแบบจำลองการตรวจจับวัตถุแบบเรียลไทม์ สามารถตรวจจับและระบุตำแหน่งของวัตถุขนาดเล็กได้ (Zhu & Spachos, 2020)

จากการวิจัยข้างต้นวิธีการตรวจสอบหาสิ่งปลอมปน โดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv4 เหมาะสำหรับการนำมาพัฒนาเพื่อใช้ตรวจจับสิ่งเจือปนในผักโขมแช่แข็งที่มีขนาดเล็ก ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อเพิ่มความแม่นยำในการตรวจจับสิ่งเจือปนในอาหารด้วยการเรียนรู้เชิงลึกโมเดล YOLOv4 ในการตรวจจับและจำแนกสิ่งเจือปน 5 ชนิด ได้แก่ ไม้ ก้อนหิน เศษแก้ว เชือก และพลาสติก ในผักโขมแช่แข็ง

การทบทวนวรรณกรรม

การตรวจจับวัตถุ (Object detection) เป็นการตรวจจับและระบุวัตถุภายในภาพหนึ่งหรือวิดีโอซึ่งทำการวิเคราะห์ผ่านคอมพิวเตอร์ ในยุคปัจจุบันด้วยความทันสมัยของเทคโนโลยีที่มากขึ้น ทำให้มีการหันมาเลือกใช้เทคนิคที่ใช้การเรียนรู้เชิงลึกเพื่อให้รวดเร็วและแม่นยำมากยิ่งขึ้น ซึ่งกระบวนการของการตรวจจับจะเริ่มจากการนำเข้าข้อมูลและทำการดึง

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

เอาคุณลักษณะที่สำคัญของชุดข้อมูลฝึกฝนมาประมวลผลเพื่อนำไปแยกประเภทของวัตถุแล้วก็นำมาผลลัพธ์สุดท้ายออกมาจัดอยู่ในคลาสชนิดใด โดยเทคนิคที่ใช้สำหรับตรวจจับวัตถุจะสามารถแบ่งออกเป็น 2 ประเภท ได้แก่

1) One-stage object detection ซึ่งมีจุดเด่นในเรื่องของความเร็วที่ใช้ในการประมวลผล ปัจจุบันมีการพัฒนานวัตกรรมใหม่ออกมามากขึ้น ซึ่งเพิ่มความแม่นยำที่สูงขึ้นและสามารถนำไปใช้งานจริงได้

2) Two-stage object detection เป็นกระบวนการแรกๆ ที่ได้มีการใช้และเป็นที่นิยมก่อนที่จะ One-Stage จะถูกคิดค้นขึ้นมา โดยจะใช้ Region Proposal ซึ่งจะมีจุดเด่นในเรื่องของความแม่นยำที่สูงแต่จะไม่รวดเร็วเนื่องจากมีกระบวนการทำงานหลายขั้นตอน (พุตพงศ์ จันทรแจ่ม, 2563)

YOLO เป็นอัลกอริทึมสำหรับการตรวจจับวัตถุจัดอยู่ในประเภท One-stage object detection ซึ่งมีแนวคิดในการมองปัญหาทั้งหมดเป็นปัญหาเดียวในรูปของการวิเคราะห์การถดถอย (Regression) ในการทำนายขอบเขตของกล่อง (Bounding box) ที่ล้อมวัตถุในภาพและความน่าจะเป็นของวัตถุที่อยู่ในกรอบนั้นออกมาพร้อมกันทีเดียว ทำให้มีจุดเด่นในเรื่องของความเร็วมากกว่าอัลกอริทึมอื่นๆ (Swiezewski, 2020) นอกจากนี้ YOLO ยังเป็นเทคโนโลยีการเรียนรู้จำวัตถุแบบเรียลไทม์ที่มีชื่อเสียงมากซึ่งสามารถจดจำวัตถุหลายชิ้นในเฟรมเดียวได้ มีรายงานว่า YOLOv4 ได้รับการออกแบบให้มีประสิทธิภาพในการระบุวัตถุด้วยความแม่นยำและความเร็วที่มากกว่าระบบอื่นๆ ที่มีอยู่ในตลาด เช่น Google TensorFlow, RetinaNet/MaskRCNN, EfficientDet และ FaceBook Pytorch/Detectron, Yolov3-ASFF บนชุดข้อมูล Microsoft COCO นอกจากนี้ YOLOv4 ยังสามารถจดจำคลาสมากกว่า 9000 คลาส พร้อมกับคลาสที่ตรวจไม่พบ สามารถระบุกล่องขอบเขตรอบวัตถุ และมีความยืดหยุ่นสูงที่ปรับใช้ได้ง่ายในสภาพแวดล้อมการผลิตต่างๆ (Bochkovskiy et al., 2020)

วิธีการวิจัย

การเตรียมชุดข้อมูลรูปภาพ

ถ่ายภาพผักโขม และสิ่งเจือปน 5 ชนิด ได้แก่ ไม้ ก้อนหิน เศษแก้ว เชือก และพลาสติก (ภาพที่ 1) ด้วยกล้อง IDS UI-3590CP-C-HQ Rev.2 ที่ติดตั้งอยู่สูงจากสายพานลำเลียง 107 เซนติเมตร (ภาพที่ 2) ขนาดภาพที่ถ่ายได้คือ 1,224*920 พิกเซล ภายใต้สภาพแสง LED สีขาวที่ความเข้มแสงที่ตกกระทบบนสายพานลำเลียง ที่ 1,056-1,702 ลักซ์ (วัดด้วยเครื่องวัดความเข้มแสงรุ่น UT383BT Mini Light Meters) (ภาพที่ 3) ทำการถ่ายภาพผักโขม ไม้ แก้ว เชือก และพลาสติก อย่างละ 1,000 ภาพ หิน 666 ภาพ (เนื่องจากใน 1 ภาพ หินมีขนาดเล็กและจำนวนมากว่าสิ่งเจือปนอื่น และลักษณะของหินที่ถ่ายได้มีลักษณะที่คล้ายคลึงกัน การถ่ายเพียง 666 ภาพ จึงเพียงพอสำหรับการทำชุดข้อมูล) ใน 1 ภาพ จะทำการครอบตัดรูปให้มีขนาด 352*480 พิกเซล จำนวน 9 ภาพ นำภาพที่ได้ทั้งหมดจากการครอบตัดรูปมาทำการ label ข้อมูลด้วยโปรแกรม Labellmg v1.8.0 โดยวิธีการ label จะเป็นการสร้าง Bounding box เป็นกล่องสี่เหลี่ยมที่คลุมวัตถุที่สนใจ (Solawetz, 2020) (ภาพที่ 4 (ก)) หลังจากนั้นจะได้ผลลัพธ์มาอีกหนึ่งไฟล์ในรูปแบบของ text file (.txt) โดยในไฟล์นี้จะระบุว่ามีวัตถุอะไรบ้างในภาพถ่ายและวัตถุนั้นอยู่ที่ตำแหน่งพิกัดของภาพที่เท่าใด (ภาพที่ 4 (ข))



(ก)

(ข)


(ค)

(ง)

(จ)

ภาพที่ 1 สิ่งเจือปน 5 ชนิด ได้แก่ (ก) ไม้, (ข) หิน, (ค) แก้ว, (ง) เชือก, (จ) พลาสติก


ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)



ภาพที่ 2 อุปกรณ์ ประกอบด้วย (ก) กล่องไฟ (Light Box), (ข) สายพานลำเลียง (Conveyor), (ค) กล้องและไฟ LED

12 px	212 px	412 px	612 px	812 px	1012 px	1212 px
1262 lx	1439 lx	1592 lx	1595 lx	1442 lx	1244 lx	1056 lx
1261 lx	1420 lx	1515 lx	1500 lx	1383 lx	1185 lx	1083 lx
1320 lx	1560 lx	1541 lx	1526 lx	1412 lx	1239 lx	1090 lx
1316 lx	1526 lx	1622 lx	1599 lx	1480 lx	1295 lx	1108 lx
1378 lx	1614 lx	1702 lx	1634 lx	1486 lx	1264 lx	1094 lx

ภาพที่ 3 ค่าความเข้มแสงของแต่ละตำแหน่งบนสายพานลำเลียง



ภาพที่ 4 การสร้างชุดข้อมูลของรูปภาพ คือ (ก) กระบวนการติดฉลากวัตถุ, (ข) ไฟล์ในรูปแบบของไฟล์ข้อความ (text file)

โดยใน ภาพที่ 4 (ข) โดยแต่ละแถวคือแต่ละวัตถุในรูปภาพนั้นๆ ซึ่งแต่ละแถวจะแบ่งแต่ละค่าด้วยช่องว่าง โดย ค่าในตำแหน่งที่ 1 คือ ประเภทของวัตถุ ได้แก่ 0 คือ ผักโขม 1 คือ ไม้ 2 คือ หิน 3 คือ แก้ว 4 คือ เชือก และ 5 คือ พลาสติก ค่าในตำแหน่งที่ 2 กับ 3 คือตำแหน่งตรงกลางของ Bounding box ว่าอยู่จุดใดของรูปภาพในรูปแบบของ X และ Y ตามลำดับ และค่าในตำแหน่งที่ 4 กับ 5 คือความกว้างและความสูงของ Bounding box


นำไฟล์รูปภาพและไฟล์ที่ได้จากการ Label มาทำการเพิ่มจำนวนรูปภาพ โดยการปรับแต่งรูปภาพด้วยโปรแกรมภาษา Python ร่วมกับไลบรารี OpenCV ซึ่งได้ทำการปรับแต่งภาพ โดยการหมุนภาพ (Rotate) ทำการหมุน 3 แบบ คือ หมุน 90, 180 และ 270 องศา และรูปภาพต้นฉบับ (Original image) ปรับความชัดของรูปภาพ (Blur) 2 ระดับ คือ (5,5) และ (11,11) ปรับความสว่างของรูปภาพ (Brightness) 2 ระดับ คือ -20 และ 20 พลิกรูปภาพ (Flip) 3 แบบ คือ พลิกแนวตั้ง, พลิกแนวนอน, และพลิกทั้งแนวตั้งและแนวนอน ดังนั้นรูปที่ใช้ในการฝึกสอนแบบจำลองครั้งนี้ประกอบไปด้วยภาพ

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

ผักโขม ไม่ เศษแก้ว เชือก และพลาสติก อย่างละ 99,000 ภาพ และภาพหิน 12,062 ภาพ รวมรูปภาพที่ใช้ในการฝึกสอนทั้งหมด 507,062 ภาพ ทำการเปลี่ยนชื่อไฟล์เดอร์เป็น obj และทำการ zip ไฟล์ เตรียมไว้สำหรับการนำชุดข้อมูลรูปภาพไปฝึกสอนแบบจำลอง YOLOv4



ภาพที่ 5 ขั้นตอนการทำชุดข้อมูล



ภาพที่ 6 แผนการตรวจจับสิ่งเจือปน

การฝึกสอนแบบจำลอง YOLOv4

นำชุดข้อมูลรูปภาพ 507,062 ภาพ ที่จัดทำขึ้นมาฝึกสอนแบบจำลอง YOLOv4 บนคอมพิวเตอร์ CPU: 12th Gen Intel(R) Core(TM) i5-12400F 2.50 GHz RAM: 32.0 GB GPU: NVIDIA GeForce RTX 3070 8 GB GDDR6 (LHR) ด้วยโปรแกรม Darknet กำหนดจำนวนรอบในการฝึกฝนเท่ากับ 600,000 รอบ ฝึกสอนแบบจำลองไปจนได้ average loss โดยค่าที่ดีที่สุดจะต้องต่ำกว่า 0.05 หรืออย่างน้อยต่ำกว่า 0.3 หรือจนกระทั่งค่า average loss คงที่ จึงหยุดการฝึกสอนแบบจำลองแล้วจะได้ไฟล์ yolov4-custom_dest.weights ที่จะนำมาใช้สำหรับการประเมินประสิทธิภาพต่อไป

การประเมินประสิทธิภาพของแบบจำลอง

นำไฟล์ที่ได้จากขั้นตอนการฝึกสอนแบบจำลองมาทดสอบตรวจจับสิ่งเจือปนในผักโขมบนภาพถ่าย ซึ่งชุดข้อมูลรูปภาพสำหรับการทดสอบจะเป็นภาพที่ถ่ายด้วยกล้องถ่ายภาพชนิดเดียวกัน สภาพแสงและระดับติดตั้งเป็นตำแหน่งเดียวกัน โดยใน 1 ภาพถ่าย จะทำการครอบตัดรูปให้มีให้มีขนาด 352*480 พิกเซล จำนวน 9 ภาพ หลังจากนั้นจึงนำมาประเมินประสิทธิภาพของแบบจำลอง บนภาพถ่าย 6 รูปแบบ (ตารางที่ 1)

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

ตารางที่ 1 การทดสอบประสิทธิภาพ

รูปแบบที่	ลักษณะรูปภาพที่นำมาทดสอบ	จำนวนภาพทดสอบ (ภาพ)
1	ภาพผักโขม 10 ชั้น รวมกับแก้ว 10 ชั้น	90
2	ภาพผักโขม 10 ชั้น รวมกับพลาสติก 10 ชั้น	90
3	ภาพผักโขม 10 ชั้น รวมกับหิน 10 ชั้น	90
4	ภาพผักโขม 10 ชั้น รวมกับเชือก 10 ชั้น	90
5	ภาพผักโขม 10 ชั้น รวมกับไม้ 10 ชั้น	90
6	ภาพผักโขม 10 ชั้น รวมกับสิ่งเจือปนชนิดละ 10 ชั้น	90

การประเมินประสิทธิภาพแบบจำลองจะใช้การทดสอบตรวจจับวัตถุบนภาพถ่ายและนำผลลัพธ์ที่ผ่านการทดสอบแล้ว
ทำเป็นตาราง Confusion matrix (ตารางที่ 2) โดย

- True Positive (TP) คือ ผลการทำนายถูกต้องตามค่าที่คาดหวัง (หรือ ข้อมูลที่ทำนายตรงกับข้อมูลจริงในคลาสที่กำลังพิจารณา)

- True Negative (TN) คือ ผลการทำนายถูกต้อง สำหรับความจริงที่ข้อมูลไม่อยู่ในคลาส และผลทำนายว่าไม่อยู่ในคลาส (หรือ ข้อมูลที่ทำนายผิดเป็นคลาสที่ไม่ได้พิจารณา)

- False Positive (FP) คือ ผลทำนายไม่ถูกต้อง เนื่องจากข้อมูลจริงที่ไม่อยู่ในคลาส แต่ผลทำนายว่าอยู่ในคลาส (หรือ ข้อมูลที่ทำนายผิดเป็นคลาสที่กำลังพิจารณา)

- False Negative (FN) คือ ผลการทำนายไม่ถูกต้อง ซึ่งความเป็นจริงข้อมูลอยู่ในคลาส แต่ในขณะที่ผลทำนายว่าไม่อยู่ในคลาส (หรือ ข้อมูลที่ทำนายตรงกับข้อมูลจริงในคลาสที่ไม่ได้พิจารณา)

ตารางที่ 2 Confusion Matrix

		Predicted	
		Positive	Negative
Actual	Positive	TP	FN
	Negative	FP	TN

หลังจากนั้นจะทำการประเมินการทดสอบ (Luque et al., 2019) โดยการคำนวณ

1) Accuracy Score คือ สัดส่วนเปอร์เซ็นต์ความถูกต้อง คือ จำนวนที่ทำนายถูก/จำนวนทั้งหมด ตามสมการ 1

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

2) Precision Score คือ ความแม่นยำของผลทำนายจะสนใจผลทำนายหรือ Prediction คำนวณเป็นค่าสัดส่วนที่ % ตามสมการ 2

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

3) Recall คือ การวัดค่าความแม่นยำอีกมิติหนึ่ง ที่สนใจผลลัพธ์กับที่เป็นของจริงด้วย เช่น มองว่าโมเดลนั้นทำนายถูกต้องกี่ % เมื่อเทียบกับของจริง ตามสมการ 3


$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

4) F1-Score คือ ค่าที่แสดงประสิทธิภาพ โดยการนำค่า Precision และ Recall มาคำนวณหาค่าเฉลี่ย หรือ เรียกว่า Harmonic Mean ซึ่งค่าสูงๆ ถือว่า Model มีประสิทธิภาพดี ตามสมการ 4


$$\text{F1-Score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

ผลการวิจัย

ผลการฝึกสอนแบบจำลอง YOLOv4 พบว่าความแม่นยำโดยรวม (mean Average Precision; mAP) เท่ากับ 76% และมีค่าสูญเสียเฉลี่ย (average loss) เท่ากับ 5.55 โดยพบว่า การฝึกสอนในช่วงก่อน 60,000 รอบ ค่าสูญเสีย (loss) ลดลงอย่างรวดเร็ว จากนั้นเมื่อมีการวนซ้ำเพิ่มขึ้น ค่าสูญเสียค่อยๆ ลดลงและมีแนวโน้มที่จะคงที่ (ภาพที่ 8)



ภาพที่ 7 การทำนายแบบจำลองในการทดสอบทั้ง 6 รูปแบบ



ภาพที่ 8 ผลของการฝึกสอนแบบจำลอง YOLOv4

นำผลของการฝึกสอนแบบจำลอง มาทดสอบประสิทธิภาพบนภาพถ่าย 6 รูปแบบ โดยการนำผลการทดสอบที่ได้ในแต่ละรูปแบบไปใส่ลงในตาราง Confusion Matrix และประเมินผลการทดสอบ ได้ดังต่อไปนี้

การทดสอบแบบที่ 1 คลาสผักโขมและแก้ว

แบบจำลองนี้สามารถทำนายแก้วได้ถูกต้อง 108 ครั้ง ทำนายแก้วผิดพลาดเป็นวัตถุอื่นทั้งหมด 108 ครั้ง ประกอบด้วย ผักโขม 105 ครั้ง เชือก 1 ครั้ง และพลาสติก 2 ครั้ง และไม่สามารถทำนายแก้วได้ 18 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบในการทดสอบประสิทธิภาพในครั้งนี้ของคลาสแก้ว พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 52.15%, 47.50%, 53.07% และ 50.13% ตามลำดับ แบบจำลองนี้สามารถทำนายแก้วได้ 95.72% และไม่สามารถทำนายแก้วได้ 4.28% (ตารางที่ 4)

การทดสอบแบบที่ 2 คลาสผักโขมและพลาสติก

แบบจำลองนี้สามารถทำนายพลาสติกได้ถูกต้อง 108 ครั้ง ทำนายพลาสติกผิดพลาดเป็นวัตถุอื่นทั้งหมด 87 ครั้ง ประกอบด้วย ผักโขม 86 ครั้ง และแก้ว 1 ครั้ง และไม่สามารถทำนายพลาสติกได้ 5 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบประสิทธิภาพในครั้งนี้ของคลาสพลาสติก พบว่าค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 52.22%, 52.94%, 55.38% และ 54.14% ตามลำดับ แบบจำลองสามารถทำนายพลาสติกได้ 97.50% และไม่สามารถทำนายพลาสติกได้ 2.50% (ตารางที่ 4)

การทดสอบแบบที่ 3 คลาสผักโขมและหิน

แบบจำลองสามารถทำนายหินได้ถูกต้อง 28 ครั้ง ทำนายหินผิดพลาดเป็นวัตถุอื่นทั้งหมด 163 ครั้ง ประกอบด้วย ผักโขม 82 ครั้ง และพลาสติก 81 ครั้ง และไม่สามารถทำนายหินได้ 25 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบประสิทธิภาพในครั้งนี้ของคลาสหิน พบว่าค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 51.10%, 65.12%, 14.66% และ 23.93% ตามลำดับ แบบจำลองสามารถทำนายหินได้ 88.43% และไม่สามารถทำนายหินได้ 11.57% (ตารางที่ 4)

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

การทดสอบแบบที่ 4 คลาสผักโขมและเชือก

แบบจำลองนี้สามารถทำนายเชือกได้ถูกต้อง 94 ครั้ง ทำนายเชือกผิดพลาดเป็นผักโขม 83 ครั้ง และไม่สามารถทำนายเชือกได้ 15 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสเชือก พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 53.56%, 54.02%, 53.11% และ 53.56% ตามลำดับ แบบจำลองสามารถทำนายเชือกได้ 92.19% และไม่สามารถทำนายเชือกได้ 7.81% (ตารางที่ 4)

การทดสอบแบบที่ 5 คลาสผักโขมและไม้

แบบจำลองสามารถทำนายไม้ได้ถูกต้อง 15 ครั้ง ทำนายไม้ผิดพลาดเป็นวัตถุดิบทั้งหมด 123 ครั้ง ประกอบด้วย ผักโขม 55 ครั้ง เชือก 60 ครั้ง และพลาสติก 8 ครั้ง และไม่สามารถทำนายไม้ได้ 44 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสไม้ พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 54.57%, 41.67%, 10.87% และ 17.24% ตามลำดับ แบบจำลองสามารถทำนายไม้ได้ 75.82% และไม่สามารถทำนายไม้ได้ 24.18% (ตารางที่ 4)

การทดสอบแบบที่ 6 คลาสผักโขมและสิ่งเจือปนทั้ง 5 ชนิด

แบบจำลองนี้สามารถทำนายไม้ได้ถูกต้อง 5 ครั้ง ทำนายไม้ผิดพลาดเป็นวัตถุดิบทั้งหมด 128 ครั้ง ประกอบด้วย ผักโขม 46 ครั้ง หิน 4 ครั้ง แก้ว 4 ครั้ง เชือก 28 ครั้ง และพลาสติก 46 ครั้ง และไม่สามารถทำนายไม้ได้ 50 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสไม้ พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 85.62%, 14.29%, 3.76% และ 5.95% ตามลำดับ แบบจำลองสามารถทำนายไม้ได้ 72.68% และไม่สามารถทำนายไม้ได้ 27.32% (ตารางที่ 4) ทำนายหินได้ถูกต้อง 3 ครั้ง ทำนายหินผิดพลาดเป็นวัตถุดิบทั้งหมด 156 ครั้ง ประกอบด้วย ผักโขม 60 ครั้ง ไม้ 6 ครั้ง แก้ว 5 ครั้ง เชือก 20 ครั้ง และพลาสติก 65 ครั้ง และไม่สามารถทำนายหินได้ 33 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสหิน พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 84.71%, 20.00%, 1.89% และ 3.45% ตามลำดับ แบบจำลองสามารถทำนายหินได้ 82.81% และไม่สามารถทำนายหินได้ 17.19% (ตารางที่ 4)

ทำนายแก้วได้ถูกต้อง 6 ครั้ง ทำนายแก้วผิดพลาดเป็นวัตถุดิบทั้งหมด 123 ครั้ง ประกอบด้วย ผักโขม 45 ครั้ง ไม้ 5 ครั้ง หิน 2 ครั้ง เชือก 16 ครั้ง และพลาสติก 55 ครั้ง และไม่สามารถทำนายแก้วได้ 57 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบในการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสแก้ว พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 85.90%, 15.79%, 4.65% และ 7.19% ตามลำดับ แบบจำลองสามารถทำนายแก้วได้ 69.35% และไม่สามารถทำนายแก้วได้ 30.65% (ตารางที่ 4) ทำนายเชือกได้ถูกต้อง 44 ครั้ง ทำนายเชือกผิดพลาดเป็นวัตถุดิบทั้งหมด 155 ครั้ง ประกอบด้วย ผักโขม 72 ครั้ง ไม้ 4 ครั้ง หิน 3 ครั้ง แก้ว 5 ครั้ง และพลาสติก 71 ครั้ง และไม่สามารถทำนายเชือกได้ 41 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบในการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสเชือก พบว่าค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 72.98%, 23.53%, 22.11% และ 22.80% ตามลำดับ แบบจำลองสามารถทำนายเชือกได้ 82.92% และไม่สามารถทำนายเชือกได้ 17.08% (ตารางที่ 4) ทำนายพลาสติกได้ถูกต้อง 88 ครั้ง ทำนายพลาสติกผิดพลาดเป็นวัตถุดิบทั้งหมด 129 ครั้ง ประกอบด้วย ผักโขม 77 ครั้ง ไม้ 5 ครั้ง หิน 2 ครั้ง แก้ว 5 ครั้ง และเชือก 40 ครั้ง และไม่สามารถทำนายพลาสติกได้ 13 ครั้ง (ตารางที่ 3) เมื่อทำการประเมินการทดสอบในการทดสอบประสิทธิภาพในครั้งนี้นี้ของคลาสพลาสติก พบว่า ค่าความถูกต้อง (Accuracy Score), ค่าความแม่นยำ (Precision Score), ค่ารีคอล (Recall) และค่าเอฟ-1สกอร์ (F1-Score) คือ 58.05%, 20.95%, 40.55% และ 27.63% ตามลำดับ แบบจำลองสามารถทำนายพลาสติกได้ 94.35% และไม่สามารถทำนายพลาสติกได้ 5.65% (ตารางที่ 4)

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

ตารางที่ 3 ผลการทดสอบประสิทธิภาพบนภาพถ่าย 6 รูปแบบ

การทดสอบแบบที่ 1 คลาสผักโขมและแก้ว

		Predicted						Unpredicted
		spinach	wood	rock	glass	string	plastic	
Actual	spinach	95	0	0	81	1	2	8
	wood	0	0	0	0	0	0	0
	rock	0	0	0	0	0	0	0
	glass	105	0	0	108	1	2	18
	string	0	0	0	0	0	0	0
	plastic	0	0	0	0	0	0	0

การทดสอบแบบที่ 2 คลาสผักโขมและพลาสติก

		Predicted						Unpredicted
		spinach	wood	rock	glass	string	plastic	
Actual	spinach	91	0	0	1	0	96	2
	wood	0	0	0	0	0	0	0
	rock	0	0	0	0	0	0	0
	glass	0	0	0	0	0	0	0
	string	0	0	0	0	0	0	0
	plastic	86	0	0	1	0	108	5

การทดสอบแบบที่ 3 คลาสผักโขมและหิน

		Predicted						Unpredicted
		spinach	wood	rock	glass	string	plastic	
Actual	spinach	90	0	15	0	0	68	19
	wood	0	0	0	0	0	0	0
	rock	82	0	28	0	0	81	25
	glass	0	0	0	0	0	0	0
	string	0	0	0	0	0	0	0
	plastic	0	0	0	0	0	0	0

การทดสอบแบบที่ 4 คลาสผักโขมและเชือก

		Predicted						Unpredicted
		spinach	wood	rock	glass	string	plastic	
Actual	spinach	92	1	0	0	80	0	3
	wood	0	0	0	0	0	0	0
	rock	0	0	0	0	0	0	0
	glass	0	0	0	0	0	0	0
	string	83	0	0	0	94	0	15
	plastic	0	0	0	0	0	0	0

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

การทดสอบแบบที่ 5 คลาสผักโขมและไม้

		Predicted						Unpredicted
		spinach	wood	rock	glass	string	plastic	
Actual	spinach	95	21	0	0	51	12	10
	wood	55	15	0	0	60	8	44
	rock	0	0	0	0	0	0	0
	glass	0	0	0	0	0	0	0
	string	0	0	0	0	0	0	0
	plastic	0	0	0	0	0	0	0

การทดสอบแบบที่ 6 คลาสผักโขมและสิ่งเจือปนทั้ง 5 ชนิด

		Predicted						Unpredicted
		spinach	wood	rock	glass	string	plastic	
Actual	spinach	104	10	1	13	39	95	3
	wood	46	5	4	4	28	46	50
	rock	60	6	3	5	20	65	33
	glass	45	5	2	6	16	55	57
	string	72	4	3	5	44	71	41
	plastic	77	5	2	5	40	88	13

ตารางที่ 4 สรุปผลการทดสอบ

Assessment	Class	Accuracy (%)	Precision (%)	Recall (%)	F1-Score (%)	Predicted (%)	Unpredicted (%)
1 st time	spinach	52.15	47.50	53.07	50.13	95.72	4.28
	glass	52.15	57.14	50.00	53.33	92.31	7.69
2 nd time	spinach	51.41	51.41	48.40	49.86	98.95	1.05
	plastic	52.22	52.94	55.38	54.14	97.50	2.50
3 rd time	spinach	54.67	52.33	52.02	52.17	90.10	9.90
	rock	51.10	65.12	14.66	23.93	88.43	11.57
4 th time	spinach	53.14	52.57	53.18	52.87	98.30	1.70
	string	53.56	54.02	53.11	53.56	92.19	7.81
5 th time	spinach	56.15	63.33	53.07	57.75	94.71	5.29
	wood	54.57	41.67	10.87	17.24	75.82	24.18
6 th time	spinach	58.33	25.74	39.68	31.23	98.87	1.13
	wood	85.62	14.29	3.76	5.95	72.68	27.32
	rock	84.71	20.00	1.89	3.45	82.81	17.19
	glass	85.90	15.79	4.65	7.19	69.35	30.65
	string	72.98	23.53	22.11	22.80	82.92	17.08
	plastic	58.05	20.95	40.55	27.63	94.35	5.65

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

สรุปและอภิปรายผลการวิจัย

ผลการศึกษาพบว่าแบบจำลองนี้มีความแม่นยำโดยรวม (mAP) 76% และมีค่าสูญเสียเฉลี่ย (average loss) 5.55 ซึ่งแตกต่างกับการทดลองของ Wu et al. (2020) ที่ศึกษาการตรวจจับดอกแอปเปิ้ลสามสายพันธุ์ ได้แก่ Fuji, Red Love และ Gala แบบเรียลไทม์ โดยใช้อัลกอริธึมการเรียนรู้เชิงลึก YOLOv4 พบว่าแบบจำลองมีความแม่นยำโดยรวม (mAP) 97.31% และความเร็วในการตรวจจับอาจสูงถึง 72.33 f/s ซึ่งตรงตามข้อกำหนดแบบเรียลไทม์ และมีการตรวจจับดอกแอปเปิ้ลที่รวดเร็วและแม่นยำ และการทดลองของ Zhu & Spachos (2020) ที่พัฒนาการคัดกรองกล้วยและตรวจจับจุดบกพร่องบนเปลือกกล้วย โดยใช้แบบจำลอง YOLOv3 พบว่าแบบจำลองมีความแม่นยำโดยรวม (mAP) 96.4% และรายงานว่แบบจำลอง YOLO เป็นแบบจำลองการตรวจจับวัตถุแบบ Real-time ซึ่งสามารถตรวจจับและระบุตำแหน่งของวัตถุขนาดเล็กด้วยความเร็วสูงได้ อาจเป็นเพราะความแตกต่างในขั้นตอนการเตรียมชุดข้อมูลรูปภาพของทั้งการทดลองของ Wu et al. (2020) และ Zhu & Spachos (2020) ที่พบว่า ทั้งสองการทดลองใช้ชุดข้อมูลรูปภาพมีรายละเอียดภาพที่ชัดเจน และใช้ระยะห่างระหว่างกล้องถ่ายภาพและวัตถุเพียง 30-50 เซนติเมตร มีความแตกต่างกับการศึกษาในครั้งนี้ที่มีระยะห่างกล้องถ่ายภาพและวัตถุถึง 107 เซนติเมตร จึงทำให้ชุดข้อมูลรูปภาพที่ได้มีรายละเอียดภาพที่ไม่ชัดเจน เกิดจากระยะห่างระหว่างกล้องถ่ายภาพและวัตถุอยู่ห่างกันมากเกินไป ส่งผลให้วัตถุที่ปรากฏในภาพถ่ายมีขนาดเล็ก รายละเอียดไม่ชัดเจน และภาพถ่ายชุดข้อมูลรูปภาพของผักโขมแซ่แข็งและสิ่งเจือปนทั้ง 5 ชนิดบางชิ้นส่วนมีลักษณะรูปร่าง สี ขนาดที่ใกล้เคียงกัน ซึ่งยากต่อการจำแนก

เมื่อพิจารณากรณีการทดสอบแบบที่ 1-5 ที่เป็นการทดสอบการตรวจจับและจำแนกบนภาพถ่ายผักโขมรวมกับสิ่งเจือปนเพียง 1 ชนิด พบว่าภาพถ่ายผักโขมอยู่รวมกับพลาสติกมีประสิทธิภาพในการตรวจจับสิ่งเจือปนสูงที่สุด รองลงมาคือเชือก แก้ว หิน และไม้ ตามลำดับ เมื่อทดสอบบนภาพถ่ายผักโขมรวมกับสิ่งเจือปนทั้ง 5 ชนิด ในการทดสอบแบบที่ 6 ยังคงพบว่า พลาสติกมีประสิทธิภาพในการตรวจจับสิ่งเจือปนสูงที่สุด รองลงมาคือเชือก แก้ว ไม้ และหิน ตามลำดับ แต่พบว่าการทดสอบในแบบที่ 6 มีประสิทธิภาพการตรวจจับสิ่งเจือปนต่ำกว่าการทดสอบแบบที่ 1-5 ทั้งนี้อาจเป็นเพราะในขั้นตอนการเตรียมชุดข้อมูลรูปภาพสำหรับการฝึกสอนแบบจำลอง เป็นการเตรียมชุดข้อมูลรูปภาพแบบแยกกันในแต่ละคลาส โดยไม่มีการเตรียมชุดข้อมูลรูปภาพที่หลายคลาสรวมอยู่ด้วยกันเพิ่มเข้าไปสำหรับฝึกสอนแบบจำลองนี้ด้วย จึงทำให้เมื่อนำมาทดสอบบนภาพถ่ายที่มีผักโขมและสิ่งเจือปนรวมอยู่ในภาพเดียวกันเกิดการทำนายที่ผิดพลาดขึ้น สอดคล้องกับการทดลองของ เตชินท์ วรสิทธิ์ และคณะ (2565) ที่พัฒนาระบบจำแนกชนิดโรคขอบใบแห้งและโรคไหม้ของข้าวจากภาพถ่ายอาการของโรคในสภาพแปลงนา โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep learning) ประกอบ Faster R-CNN Inception V2, Faster R-CNN ResNet 101, RetinaNet ResNet 50, RetinaNet ResNet 101, YOLOv3, และ Mask R-CNN และประเมินประสิทธิภาพ พบว่า YOLOv3 มีประสิทธิภาพสูงสุดในการจำโรคทั้งสอง ซึ่งมีค่าเฉลี่ยความถูกต้องในการจำแนกของโรคขอบใบแห้งและโรคไหม้ 90.33% และ 86.46% ตามลำดับ อย่างไรก็ตาม เมื่อทวนสอบความถูกต้องของระบบที่พัฒนาขึ้นกับภาพถ่ายที่ไม่เคยนำมาใช้ในการพัฒนาระบบ พบว่า ความความถูกต้องในการจำแนกโรคขอบใบแห้งและโรคไหม้ลดลงเหลือ 87.5% และ 74.0% ตามลำดับ ระบบนี้มีความแม่นยำโดยรวม (mAP) ในการวินิจฉัยทั้งสองโรคอยู่ที่ 79.19% และพบว่าหากเพิ่มชนิดโรคในการพัฒนาระบบจะทำให้ค่าความถูกต้องเฉลี่ยของระบบรู้จำลดน้อยลง ซึ่งเป็นผลมาจากคุณภาพของภาพถ่ายลักษณะอาการ รวมถึงความคล้ายกันของลักษณะอาการในหลายๆ โรคได้

เอกสารอ้างอิง

เตชินท์ วรสิทธิ์, ชีระ ภัทราพรนันท์, ชีรยุทธ ตูจินดา, วสิน สินธุภิญโญ, กรรณทิพย์ กิรติรัตนพฤษ, พิษณุกาญจน์ เต็มนิรันดร์, อภิชน กิจวิมลรัตน์, จินตนา อันอาดมงาม และ สุจินต์ ภัทรภูวดล. (2565). การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกสำหรับการรู้จำโรคขอบใบแห้งและโรคไหม้ของข้าว. *วารสารแก่นเกษตร*, 50(1), 216-228.

ปีที่ 12 ฉบับที่ 2 (กรกฎาคม - ธันวาคม 2566)

พุ่มพงษ์ จันท์แจ่ม. (2563). การปรับปรุงประสิทธิภาพของกระบวนการบริการลูกค้าโดยใช้การวิเคราะห์จากกล้องวงจรปิด. การค้นคว้าอิสระ วิทยาศาสตร์มหาบัณฑิต, สถาบันบัณฑิตพัฒนบริหารศาสตร์.

Bochkovskiy, A., Wang, C., & Liao, H. (2020). *Yolov4: Optimal Speed and Accuracy of Object Detection*. Retrieved from https://arxiv.org/pdf/2004.10934.pdf?fbclid=IwAR0TyLXaKDLIrotdQX5Pd_nRJPGESQNOZj--RG1ob5aS8GdLRWCFm37ylo4.

Dermesonluoglu, E., Katsaros, G., Tsevdou, M., Giannakourou, M., & Taoukis, P. (2015). Kinetic Study of Quality Indices and Shelf Life Modelling of Frozen Spinach Under Dynamic Conditions of the Cold Chain. *Journal of Food Engineering*, 148, 13-23.

Luque, A., Carrasco, A., Martín, A., & Heras, A. (2019). The Impact of Class Imbalance in Classification Performance Metrics Based on the Binary Confusion Matrix. *Pattern Recognition*, 91, 216-231.

Rong, D., Xie, L., & Ying, Y. (2019). Computer Vision Detection of Foreign Objects in Walnuts Using Deep Learning. *Computers and Electronics in Agriculture*, 162, 1001-1010.

Solawetz, J. (2020). *What are Anchor Boxes in Object Detection?*. Retrieved from <https://blog.roboflow.com/what-is-an-anchor-box/>.

Swiezewski, J. (2020). *YOLO Algorithm and YOLO Object Detection*. Retrieved from <https://appsilon.com/object-detection-yolo-algorithm/>.

The Observatory of Economic Complexity. (2021). *Spinach, Frozen, Uncook Steamed or Boiled*. Retrieved from https://oec.world/en/visualize/tree_map/hs92/export/show/all/2071030/2021/.

Wu, D., Lv, S., Jiang, M., & Song, H. (2020). Using Channel Pruning-Based YOLOv4 Deep Learning Algorithm for the Real-Time and Accurate Detection of Apple Flowers in Natural Environments. *Computers and Electronics in Agriculture*, 178, 105742.

Zhu, L., & Spachos, P. (2020). *Food Grading System using Support Vector Machine and YOLOv3 Methods*. A paper presented at the 2020 IEEE Symposium on Computers and Communications, Rennes, France.

Zhu, L., Spachos, P., Pensini, E., & Plataniotis, K. (2021). Deep Learning and Machine Vision for Food Processing: A Survey. *Current Research in Food Science*, 4, 233-249.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Conflicts of Interest: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's Note: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.



Copyright: © 2023 by the authors. This is a fully open-access article distributed under the terms of the Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0).