

การเปรียบเทียบคุณภาพมะม่วงพันธุ์น้ำดอกไม้โดยใช้อัลกอริทึม YOLOv11

Comparison of Quality Classification for Barracuda Mango Using YOLOv11 Algorithm

ปาณิสรา หาดขุนทด¹ เกศสุดา โภคานิตย์² และธนากร แสงกุดเลาะ^{3*}

Panisara Hadkhuntod¹ Katesuda Phokanit² and Thanakorn Snagkudluo^{3*}

มหาวิทยาลัยราชภัฏพิบูลสงคราม¹ มหาวิทยาลัยราชภัฏชัยภูมิ² และมหาวิทยาลัยนเรศวร³

Pibulsongkram Rajabhat University¹ Rajabhat Chaiyaphum University² and Naresuan University³

e-mail: Panisara.h@psru.ac.th¹ Kate_2523@windowlive.com² and Thanakorns@nu.ac.th³

Received: December 22, 2024; Revised: March 17, 2025; Accepted: March 25, 2025

บทคัดย่อ

มะม่วงน้ำดอกไม้เป็นพืชเศรษฐกิจที่สำคัญ การคัดแยกคุณภาพก่อนออกสู่ตลาดที่ใช้แรงงานมนุษย์มักเกิดข้อผิดพลาดและล่าช้า ผู้วิจัยจึงนำอัลกอริทึม YOLOv11 มาใช้ตรวจสอบคุณภาพมะม่วงผ่านภาพถ่ายจากสมาร์ทโฟน โดยใช้ภาพถ่าย 950 ภาพ แบ่งเป็น Normal (มะม่วงดี) และ Abnormal (มะม่วงมีตำหนิ) มีการทำ Label A (ระบุทั้งลูก) และ Label B (ระบุเฉพาะจุดตำหนิ) พร้อมแบ่งข้อมูลเป็น Train 80%, Validation 10% และ Test 10% ผลการทดลองพบว่า YOLOv11n และ YOLOv11s ใช้พื้นที่จัดเก็บน้อยกว่าและประมวลผลเร็วกว่า ขณะที่ YOLOv11m มีความแม่นยำสูงขึ้นเล็กน้อย แต่ใช้ทรัพยากรสูงกว่า นอกจากนี้ Label A ให้ผลลัพธ์ที่ดีกว่า Label B ในแง่ของ mAP50-95, Precision, Recall และ F1-Score การเลือกใช้อัลกอริทึมขึ้นอยู่กับข้อจำกัดของทรัพยากร หากต้องการความแม่นยำสูงสุดควรใช้ YOLOv11m หากต้องการความสมดุลเลือก YOLOv11s และหากต้องการความเร็วสูงสุดเลือก YOLOv11n งานวิจัยนี้ช่วยเพิ่มความแม่นยำ ลดเวลาและลดข้อผิดพลาดในการคัดแยกมะม่วง อาจนำไปต่อยอดสู่ระบบคัดแยกผลไม้อัตโนมัติในอนาคต

คำสำคัญ: เปรียบเทียบ มะม่วงพันธุ์น้ำดอกไม้ อัลกอริทึม YOLOv11

Abstract

Nam Dok Mai mangoes are an important economic crop, and manual quality sorting before market distribution often leads to human errors and delays. This study applied the YOLOv11 algorithm to assess mango quality through smartphone images. A total of 950 images were used, categorized into Normal (good quality) and Abnormal (defective) mangoes. Two labeling methods were implemented: Label A (whole-fruit annotation) and Label B (defect-only annotation). The dataset was divided into 80% for training, 10% for validation, and 10% for testing. Experimental results showed that YOLOv11n and YOLOv11s required less storage space and provided faster processing, while YOLOv11m achieved slightly higher accuracy but demanded greater computational resources. Moreover, Label A outperformed Label B in terms of mAP50-95, Precision, Recall, and F1-Score. The choice of algorithm depends on resource constraints: YOLOv11m is suitable for maximum accuracy, YOLOv11s for balanced performance, and YOLOv11n for the highest processing speed. The study demonstrates that using YOLOv11

enhances accuracy, reduces processing time, and minimizes human errors in mango quality classification, paving the way for future development of automated fruit sorting systems.

Keywords: Comparison, Nam Dok Mai Mango, YOLOv11 Algorithm

บทนำ

มะม่วงเป็นหนึ่งในพืชเศรษฐกิจที่สำคัญของประเทศไทย ซึ่งมีบทบาทสำคัญในการสร้างรายได้ให้กับประเทศ เนื่องจากมะม่วงไทยได้รับความนิยมทั้งในประเทศและต่างประเทศ โดยเฉพาะในตลาดส่งออกที่มะม่วงเป็นที่ต้องการอย่างมาก มะม่วงไทยยืน 1 ตลาดเกาหลีใต้ แข่งมาเลเซีย มูลค่าส่งออกปี 2567 ขยายตัวก้าวกระโดด 132.7% ในปี 2567 การส่งออกผลไม้สดของไทย มีมูลค่า 183,823 ล้านบาท โดยไทยส่งออกมะม่วงสด เป็นมูลค่า 4,716 ล้านบาท ขยายตัว 45.68% เมื่อเทียบกับปีก่อนหน้า (“ไทยขึ้นเบอร์ 1,” 2568)

มะม่วงน้ำดอกไม้ (Barracuda Mango) ถือเป็นพันธุ์มะม่วงที่ได้รับความนิยมสูงสุดในประเทศไทย เนื่องจากมีลักษณะผลที่สวยงาม รสชาติหวานฉ่ำ เนื้อในแน่นนุ่ม และมีกลิ่นหอม ซึ่งเป็นที่ต้องการของตลาดทั้งในประเทศและต่างประเทศ มะม่วงน้ำดอกไม้มีลักษณะเด่น คือ ผลมีรูปร่างรี เปลือกบาง และมีสีเขียวในช่วงผลอ่อน เมื่อสุกแล้วจะมีสีเหลืองที่สดใส พร้อมทั้งเนื้อที่มีรสชาติหวาน และมีกลิ่นหอมอย่างชัดเจน (พิระศักดิ์ ฉายประสาท, 2553)

อย่างไรก็ตาม การตรวจสอบคุณภาพมะม่วงน้ำดอกไม้ก่อนนำไปส่งออกยังคงใช้วิธีการคัดแยกด้วยมนุษย์ ซึ่งแบ่งระดับคุณภาพเป็น 2 ระดับหลัก คือ "Normal" สำหรับมะม่วงที่มีคุณภาพดี และ "Abnormal" สำหรับมะม่วงที่มีตำหนิ การคัดคุณภาพด้วยวิธีนี้ยังคงมีข้อจำกัด เนื่องจากต้องอาศัยประสบการณ์และทักษะของผู้ตรวจสอบ ซึ่งบางครั้งอาจเกิดความผิดพลาดในการแยกแยะคุณภาพของผลมะม่วง ทำให้เกิดผลกระทบทั้งในด้านการราคาสินค้าและความน่าเชื่อถือในตลาด

เพื่อลดข้อผิดพลาดในการคัดคุณภาพและเพิ่มความแม่นยำในการตรวจสอบ มีกระบวนการพัฒนาเทคโนโลยีใหม่ ๆ เพื่อช่วยในการคัดแยกคุณภาพมะม่วง ซึ่งหนึ่งในนั้น คือ การใช้เทคโนโลยีการประมวลผลภาพ (Image Processing) ในการจำแนกคุณภาพของมะม่วง โดยการใช้เทคนิค YOLO (You Only Look Once) ซึ่งเป็นอัลกอริทึมที่สามารถประมวลผลและตรวจจับวัตถุในภาพได้อย่างรวดเร็วและแม่นยำ YOLOv11 (You Only Look Once Version 11) เป็นอัลกอริทึมตรวจจับวัตถุที่พัฒนาโดย Ultralytics เพื่อเพิ่มประสิทธิภาพในการตรวจจับวัตถุแบบเรียลไทม์ โดยปรับปรุงโครงสร้างของโมเดลให้มีความแม่นยำสูงขึ้นและใช้ทรัพยากรน้อยลง การพัฒนา YOLOv11 ประกอบด้วย C3k2 Block ซึ่งช่วยลดขนาดโครงสร้างของคอนโวลูชันทำให้การดึงคุณลักษณะมีประสิทธิภาพมากขึ้น (Khanam & Hussain, 2024) นอกจากนี้ SPPF (Spatial Pyramid Pooling - Fast) ยังช่วยให้โมเดลสามารถตรวจจับวัตถุที่มีขนาดแตกต่างกันได้ดีขึ้น (Y-T-G et al., 2025) และ C2PSA (Convolutional Block with Parallel Spatial Attention) เพิ่มความสามารถในการโฟกัสไปยังวัตถุขนาดเล็กหรือที่ถูกบดบังบางส่วน ส่งผลให้ความแม่นยำของโมเดลดีขึ้นกว่ารุ่นก่อนหน้า (Ghosh, 2024) ด้วยการพัฒนาเหล่านี้ YOLOv11 ยังคงความเร็วสูงในการประมวลผล ขณะเดียวกันก็เพิ่มความแม่นยำ เหมาะสำหรับการใช้งานที่ต้องการตรวจจับวัตถุอัตโนมัติ เช่น ระบบอุตสาหกรรมและเกษตรกรรมอัจฉริยะ

งานวิจัยด้านการใช้ Deep Learning ในการคัดแยกมะม่วงได้รับความสนใจในระดับนานาชาติ โดยมีการใช้โครงข่ายประสาทเทียมที่แตกต่างกัน เพื่อเพิ่มประสิทธิภาพในการคัดแยกคุณภาพผลไม้ในภาคเกษตรกรรม

จากการวิจัยเรื่อง Automated Mango Classification Using Convolutional Neural Networks (CNN) (Bilal et al., 2024) งานวิจัยนี้ใช้ CNN ในการจำแนกคุณภาพของมะม่วงจากภาพถ่าย ซึ่งให้ผลลัพธ์ที่แม่นยำ แต่ยังมีข้อจำกัดในด้านความเร็วของการประมวลผลเมื่อเทียบกับ YOLOv11 และจากการวิจัยเรื่อง Intelligent Mango Fruit Grade Classification Using Alexnet-SPP with mask R-CNN-based segmentation algorithm (Yeh et al., 2023) งานวิจัยนี้ใช้ AlexNet-SPP + Mask R-CNN ให้ความแม่นยำสูงกว่า เพราะสามารถแยกพื้นหลังและดึงคุณสมบัติของมะม่วงได้ละเอียดกว่า เหมาะกับการจำแนกเกรดผลไม้ YOLOv11 แม้จะเร็วกว่ามาก แต่ไม่ได้ออกแบบมาสำหรับ Segmentation ทำให้การระบุรายละเอียดของผลไม้อาจไม่แม่นยำเท่าวิธีแรก หากเน้นความเร็ว YOLOv11 ดีกว่า แต่หากต้องการความแม่นยำ Mask R-CNN เหมาะสมกว่า YOLOv11 เป็นอัลกอริทึมที่สามารถนำมาใช้คัดแยกมะม่วงได้อย่างมีประสิทธิภาพโดยอาศัยการตรวจจับวัตถุแบบเรียลไทม์ ในขณะที่งานวิจัยอื่น ๆ เช่น การใช้ CNN หรือ Mask R-CNN ให้ผลลัพธ์ที่แม่นยำแต่ต้องแลกกับเวลาในการประมวลผลที่สูงขึ้น ดังนั้น การเลือกใช้อัลกอริทึมขึ้นอยู่กับเงื่อนไขของระบบ เช่น ความเร็วที่ต้องการและข้อจำกัดของทรัพยากรคอมพิวเตอร์

ในการพัฒนาเทคโนโลยีนี้ นักวิจัยได้เก็บข้อมูลภาพมะม่วงน้ำดอกไม้จากสวนมะม่วงในบ้านวังทับไทร อำเภอสากเหล็ก จังหวัดพิจิตร เพื่อนำมาใช้ในการฝึกฝนและพัฒนาาระบบที่สามารถจำลองการมองเห็นของมนุษย์ในคอมพิวเตอร์ ซึ่งจะช่วยให้การตรวจสอบคุณภาพมะม่วงมีความรวดเร็วและแม่นยำยิ่งขึ้น ระบบดังกล่าวจะช่วยให้เกษตรกรสามารถคัดแยกมะม่วงที่มีคุณภาพดีได้อย่างมีประสิทธิภาพมากขึ้น และสามารถส่งมอบสินค้าคุณภาพสูงให้กับตลาดได้ทันเวลา

การใช้เทคโนโลยีในการคัดคุณภาพมะม่วงไม่เพียงแต่ช่วยลดข้อผิดพลาดจากกระบวนการคัดแยกด้วยมือเท่านั้น แต่ยังช่วยเพิ่มประสิทธิภาพในกระบวนการผลิตและส่งออก ทำให้มะม่วงไทยสามารถแข่งขันในตลาดต่างประเทศได้ดีขึ้น และยังเป็นการเพิ่มขีดความสามารถในการผลิตสินค้าเกษตรที่มีคุณภาพสูง ซึ่งเป็นการส่งเสริมเศรษฐกิจของประเทศอย่างยั่งยืน ดังนั้น การประยุกต์ใช้เทคโนโลยีการประมวลผลภาพและอัลกอริทึม YOLO ในการคัดคุณภาพมะม่วง อีกทั้งเปรียบเทียบโมเดล YOLOv11n, YOLOv11s และ YOLOv11m จะส่งผลต่อความเร็วในการประมวลผลและความแม่นยำในการตรวจจับข้อบกพร่องของมะม่วง การประยุกต์ใช้เทคโนโลยีดังกล่าวไม่เพียงแต่ช่วยลดข้อผิดพลาดในการคัดแยกด้วยมือ แต่ยังสามารถเพิ่มประสิทธิภาพในกระบวนการผลิตและส่งออกมะม่วงของไทยได้ ทำให้มะม่วงไทยมีความสามารถในการแข่งขันในตลาดต่างประเทศและช่วยส่งเสริมเศรษฐกิจของประเทศอย่างยั่งยืน

วัตถุประสงค์


เพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึม YOLOv11n, YOLOv11s และ YOLOv11m ในการคัดแยกคุณภาพมะม่วงน้ำดอกไม้

เอกสารที่เกี่ยวข้อง

มะม่วงน้ำดอกไม้เป็นมะม่วงรับประทานสุก ที่สามารถทำให้ออกดอกติดผลนอกฤดูได้ดี ทรงพุ่มค่อนข้างเล็ก ใบค่อนข้างใหญ่ ขอบใบเป็นคลื่น การเรียงตัวของใบเป็นระเบียบ ทนต่อโรคและแมลงได้ดีปานกลาง มีผลขนาดปานกลาง ทรงผลรูปไข่ค่อนข้างยาว ขั้วผลลุ่มและรี ปลายผลแหลม ผิวเรียบ เปลือกค่อนข้างบางประมาณ

0.11 เซนติเมตร บอบช้ำง่าย ผลดิบสีเขียวฉ่ำ รสเปรี้ยวจัด ผลแก่มีสีเขียวอ่อน มีนวลชัดเจนท่อน้ำยางบริเวณผิว เนื้อสีขาวยังมีรสเปรี้ยว เมื่อสุกผิวสีเหลืองอมเขียว เนื้อหนาแน่นและละเอียด ฉ่ำน้ำ ไม่มีเสี้ยน มีกลิ่นหอม เมล็ดบาง อายุเก็บเกี่ยวประมาณ 115-120 วัน เป็นพันธุ์รับประทานสุกที่เป็นที่ต้องการของผู้บริโภคทั้งภายในและต่างประเทศ (พีระศักดิ์ ฉายประสาท, 2553)

YOLOv11 (You Only Look Once Version 11) เป็นอัลกอริทึมตรวจจับวัตถุที่พัฒนาโดย Ultralytics ซึ่งได้รับการปรับปรุงให้มีความแม่นยำสูงขึ้น ใช้ทรัพยากรน้อยลง และประมวลผลได้รวดเร็วขึ้น เมื่อเทียบกับเวอร์ชันก่อนหน้า โดยพัฒนาต่อยอดจาก YOLOv10 และ YOLOv9 ให้สามารถรองรับการใช้งานที่ซับซ้อนขึ้นในอุตสาหกรรมที่ต้องการการตรวจจับวัตถุแบบเรียลไทม์



ภาพที่ 1 สถาปัตยกรรม YOLOv11

ที่มา (Rao, 2024)

การทำงานของ YOLOv11

1. C3k2 Block: การปรับปรุงโครงข่ายคอนโวลูชันให้มีประสิทธิภาพสูงขึ้น Khanam และ Hussain (2024) ได้อธิบายว่า YOLOv11 ใช้ C3k2 Block ซึ่งเป็นการออกแบบ Residual Block แบบใหม่ ที่ช่วยลดจำนวนพารามิเตอร์ของโมเดล โดยยังคงประสิทธิภาพของการตรวจจับวัตถุ โครงสร้างนี้ช่วยให้โมเดลเรียนรู้คุณลักษณะเชิงลึกได้ดีขึ้น ในขณะที่ลดภาระการคำนวณ

2. Spatial Pyramid Pooling-Fast (SPPF): ปรับปรุงการจัดการคุณลักษณะของภาพ หนึ่งในจุดเด่นของ YOLOv11 คือ การนำ Spatial Pyramid Pooling-Fast (SPPF) มาใช้เพื่อลดการสูญเสียข้อมูลและเพิ่ม

ความสามารถในการตรวจจับวัตถุที่มีขนาดแตกต่างกัน โดยมอดูลนี้ช่วยให้โมเดลสามารถดึงข้อมูลจากหลายขนาดได้พร้อมกัน ทำให้มีความแม่นยำสูงขึ้น เมื่อเทียบกับการใช้ Convolutional Layers แบบดั้งเดิม (Y-T-G et al., 2025)

3. Convolutional Block with Parallel Spatial Attention (C2PSA): ปรับปรุงการตรวจจับวัตถุขนาดเล็กและวัตถุที่ถูกบดบัง Ghosh (2024) ได้กล่าวถึงการพัฒนา C2PSA (Convolutional Block with Parallel Spatial Attention) ที่เพิ่มความสามารถในการโฟกัสไปยังวัตถุที่มีขนาดเล็กหรือถูกบดบังบางส่วน โดยใช้เทคนิค Spatial Attention Mechanism ทำให้ YOLOv11 สามารถแยกแยะวัตถุในสภาพแวดล้อมที่ซับซ้อนได้ดียิ่งขึ้น

วิธีดำเนินการวิจัย

1. การเตรียมข้อมูลสำหรับสร้างแบบจำลอง

ขอบเขตงานวิจัยต้องการสร้างแบบจำลองเพื่อคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ โดยถ่ายภาพจากสมาร์ทโฟน เก็บรูปภาพทั้งหมด 950 ภาพ เป็นภาพถ่ายแบบ JPG แบ่งเป็นมะม่วงดี 475 ภาพ และมะม่วงมีตำหนิ 475 ภาพ เท่า ๆ กัน

ดำเนินการเก็บภาพมะม่วงพันธุ์น้ำดอกไม้ โดยแต่ละภาพมีขนาด 4128x1908 พิกเซล จำนวน 950 ภาพ ขั้นตอนการจัดกลุ่มคุณภาพของมะม่วงพันธุ์น้ำดอกไม้ดำเนินการโดยสอบถามการจำแนกคุณภาพของมะม่วงในแต่ละระดับจากผู้เชี่ยวชาญเจ้าของสวนมะม่วงพันธุ์น้ำดอกไม้ โดยมีการจัดกลุ่มไว้ดังนี้ คุณภาพ “Normal” คือ มะม่วงดี และคุณภาพ “Abnormal” คือ มะม่วงมีตำหนิ ดังรูป



ภาพที่ 2 Normal คือ มะม่วงดี



ภาพที่ 3 Abnormal คือ มะม่วงมีตำหนิ

ตารางที่ 1

คุณลักษณะภายนอกของมะม่วง

เกรดของมะม่วง	คุณลักษณะภายนอก
Normal	ผิวเรียบเนียน ไม่มีรอยแตก
Abnormal	ผิวมีสีดําเป็นบางส่วน มีรอยแตก

2. การฝึกฝนแบบจำลอง

งานวิจัยนี้ใช้โครงข่ายประสาทเทียมของแบบจำลอง YOLOv11 ซึ่งมีโครงข่ายทั้งหมด 3 แบบ คือ 1) Nano 2) Small และ 3) Medium โดยการฝึกฝนครั้งนี้เลือกใช้แบบจำลอง YOLOv11n, YOLOv11s และ YOLOv11m เปรียบเทียบกัน โดยมีขั้นตอนดังนี้

2.1 ถ่ายภาพจากสมาร์ทโฟนในแบบ JPG ขนาด 4128x1908 จำนวน 950 รูป แบ่งเป็น 2 กลุ่ม ได้แก่ Normal = มะม่วงดี และ Abnormal = มะม่วงมีตำหนิ

2.2 นำภาพที่ถ่ายไปยัง Roboflow แบ่งข้อมูลออกเป็นสองชุด

2.2.1 A = Normal และ Abnormal Label ทั้งคู่

2.2.2 B = Normal Label ทั้งคู่ และ Abnormal Label เฉพาะจุด

2.3 ทำการปรับภาพด้วยวิธีต่าง ๆ ดังนี้

2.3.1 ปรับทิศทางอัตโนมัติ

2.3.2 ลดขนาดรูปภาพเป็น 640x640

2.3.3 พลิกรูปภาพในแนวนอน

2.3.4 หมุนรูปภาพ 90 องศา

2.3.5 จะได้รูปภาพรวม 1990 รูป

2.4 สร้างชุดข้อมูลโดยแบ่งเป็น

2.4.1 Train set = 80%


2.4.2 Valid set = 10%

2.4.3 Test set = 10%

2.5 นำข้อมูลไปฝึกฝนและทดสอบใน Google Colab จำนวน 100 epoch

2.6 เปรียบเทียบประสิทธิภาพระหว่าง A และ B

การฝึกฝน (Training) จะใช้ Roboflow ในการติดกรอบภาพ และใช้ Google Colab ในการเขียนภาษา Python หลังจากทำการฝึกอบรมเสร็จ จะได้แบบจำลองพร้อมใช้สำหรับการคัดแยกคุณภาพของมะม่วงพันธุ์น้ำดอกไม้ ดังภาพที่ 4



ภาพที่ 4 Flow Chart แสดงขั้นตอนการประมวลผลภาพที่ใช้ในการวิจัยครั้งนี้

3. การประเมินประสิทธิภาพของแบบจำลอง

การประเมินประสิทธิภาพของแบบจำลองหลังการฝึกอบรม (Training) (กษิตติ์ สดางค์มงคล, 2566) พิจารณาจากพารามิเตอร์ทั้งหมด 3 ค่า คือ ค่าความแม่นยำ (Precision) ค่าเรียกคืน (Recall) และค่าการประเมินผลแบบจำลอง (F1-Score) โดยมีรายละเอียด ดังนี้

3.1 ค่าความแม่นยำ (Precision) คือ ค่าที่ใช้เพื่อดูความถูกต้องของการทำนายผลและระดับของการระบุคำอธิบายประกอบที่ทำนายได้ถูกต้องเทียบกับการระบุคำอธิบายที่ทำนายทั้งหมด ซึ่งพารามิเตอร์นี้คำนวณโดยใช้ True Positive (TP) และ False Positive (FP) ดังสมการที่ (1)

$$\text{Precision} = \text{Precision} = \text{TP} / \text{TP} + \text{FP} \quad (1)$$

3.2 ค่าเรียกคืน (Recall) คือ ค่าสัดส่วนของการระบุคำอธิบายประกอบที่ทำนายได้ถูกต้องเมื่อเทียบกับคำอธิบายประกอบทั้งหมด ซึ่งพารามิเตอร์นี้คำนวณโดยใช้ True Positive (TP) และ False Negative (FN) ดังสมการที่ (2)

$$\text{Recall} = \text{TP} / \text{TP} + \text{FN} \quad (2)$$

3.3 ค่าการประเมินผลแบบจำลอง (F1-Score) คือ ค่าที่ใช้เพื่อวัดค่าการประเมินผลแบบจำลอง ซึ่งพารามิเตอร์นี้คำนวณโดยใช้ค่า Precision และค่า Recall ดังสมการที่ (3)

$$\text{F-Measure} / \text{F1-Score} = 2 \times \text{Precision} \times \text{Recall} / \text{Precision} + \text{Recall} \quad (3)$$

เมื่อ	TP (True Positive) = อัตราผลบวกจริง
	TN (True negative) = อัตราผลลบปลอม
	FP (False Positive) = อัตราผลลบจริง
	FN (False Negative) = อัตราผลลบปลอม
	Precision = ค่าความแม่นยำ
	Recall = ค่าความไว
	F-Measure = ค่าถ่วงดุล

ผลการวิจัย

ผลการทดลองนำภาพถ่ายมะม่วงพันธุ์น้ำดอกไม้จำนวน 1990 ภาพ ขนาด 640x640 พิกเซล ที่ผ่านการปรับมาประมวลผลด้วยอัลกอริทึม YOLOv11n, s และ m จำนวน 100 epoch แล้ว ผลปรากฏดังนี้

ตารางที่ 2

Label A

Parameter	Params (M)	Total Time	FPS	mAP 50-95	Precision	Recall	F1- Score	พื้นที่ จัดเก็บ บนดิสก์ (MB)
YOLOv11n	2.6	0.775	1.04	0.974	0.963	0.989	0.948	3.9
YOLOv11s	9.4	0.883	1.34	0.971	0.947	0.992	0.968	14.4
YOLOv11m	20.1	1.418	1.08	0.976	0.965	0.978	0.971	42.2

จากตารางที่ 2 YOLOv11n มีพารามิเตอร์ 2.6 M มีเวลาโดยรวม (Total Time) ที่ 0.775 วินาทีที่สามารถประมวลผลได้ 1.04 เฟรมต่อวินาที (FPS) และมีความแม่นยำเฉลี่ย (mAP 50-95) เท่ากับ 0.974 มีความแม่นยำ (Precision) ที่ 0.963 การดึงคืน (Recall) ที่ 0.989 และคะแนน F1 (F1-Score) ที่ 0.948 ใช้พื้นที่จัดเก็บบนดิสก์ (MB) เท่ากับ 3.9 เมกะไบต์ YOLOv11s มีพารามิเตอร์ 9.4 M มีเวลาโดยรวม (Total Time) ที่ 0.883 วินาที สามารถประมวลผลได้ 1.34 เฟรมต่อวินาที (FPS) และมีความแม่นยำเฉลี่ย (mAP 50-95) เท่ากับ 0.971 มีความแม่นยำ (Precision) ที่ 0.947 การดึงคืน (Recall) ที่ 0.992 และคะแนน F1 (F1-Score) ที่ 0.968 ใช้พื้นที่จัดเก็บบนดิสก์ (MB) เท่ากับ 14.4 เมกะไบต์ YOLOv11m มีพารามิเตอร์ 20.1 M มีเวลาโดยรวม (Total Time) ที่ 1.418 วินาที สามารถประมวลผลได้ 1.08 เฟรมต่อวินาที (FPS) และมีความแม่นยำเฉลี่ย (mAP 50-95) เท่ากับ 0.976 มีความแม่นยำ (Precision) ที่ 0.965 การดึงคืน (Recall) ที่ 0.978 และคะแนน F1 (F1-Score) ที่ 0.971 ใช้พื้นที่จัดเก็บบนดิสก์ (MB) เท่ากับ 42.2 เมกะไบต์


จากข้อมูลนี้สามารถเห็นได้ว่า แต่ละรุ่นของ YOLOv11 มีการเปรียบเทียบในด้านต่าง ๆ ที่แตกต่างกัน โดยรุ่นที่เล็กกว่า เช่น YOLOv11n และ YOLOv11s ใช้พื้นที่จัดเก็บน้อยกว่า และมีความเร็วในการประมวลผลที่สูงกว่า ในขณะที่รุ่นที่ใหญ่กว่าอย่าง YOLOv11m มีความแม่นยำสูงกว่าเล็กน้อย แต่ใช้เวลาในการประมวลผลนานกว่า และใช้พื้นที่จัดเก็บมากกว่า

ตารางที่ 3

Label B

Parameter	Params (M)	Total Time	FPS	mAP 50-95	Precision	Recall	F1- Score	พื้นที่ จัดเก็บ บนดิสก์ (MB)
YOLOv11n	2.6	0.841	1.24	0.676	0.887	0.846	0.866	3.9
YOLOv11s	9.4	0.886	1.54	0.687	0.839	0.895	0.866	14.4
YOLOv11m	20.1	1.422	1.20	0.683	0.909	0.844	0.875	42.2

จากตารางที่ 3 YOLOv11n มีพารามิเตอร์ 2.6 M มีเวลาโดยรวม (Total Time) ที่ 0.841 วินาที สามารถประมวลผลได้ 1.24 เฟรมต่อวินาที (FPS) และมีความแม่นยำเฉลี่ย (mAP 50-95) เท่ากับ 0.676 มีความแม่นยำ (Precision) ที่ 0.887 การดึงคืน (Recall) ที่ 0.846 และคะแนน F1 (F1-Score) ที่ 0.866 ใช้พื้นที่จัดเก็บบนดิสก์ (MB) เท่ากับ 3.9 เมกะไบต์ YOLOv11s มีพารามิเตอร์ 9.4 M มีเวลาโดยรวม (Total Time) ที่ 0.886 วินาที สามารถประมวลผลได้ 1.54 เฟรมต่อวินาที (FPS) และมีความแม่นยำเฉลี่ย (mAP 50-95) เท่ากับ 0.687 มีความแม่นยำ (Precision) ที่ 0.839 การดึงคืน (Recall) ที่ 0.895 และคะแนน F1 (F1-Score) ที่ 0.866 ใช้พื้นที่จัดเก็บบนดิสก์ (MB) เท่ากับ 14.4 เมกะไบต์ YOLOv11m มีพารามิเตอร์ 20.1 M มีเวลาโดยรวม (Total Time) ที่ 1.422 วินาที สามารถประมวลผลได้ 1.20 เฟรมต่อวินาที (FPS) และมีความแม่นยำเฉลี่ย (mAP 50-95) เท่ากับ 0.683 มีความแม่นยำ (Precision) ที่ 0.909 การดึงคืน (Recall) ที่ 0.844 และคะแนน F1 (F1-Score) ที่ 0.875 ใช้พื้นที่จัดเก็บบนดิสก์ (MB) เท่ากับ 42.2 เมกะไบต์



ภาพที่ 5 เปรียบเทียบภาพที่ได้จากการประมวลผลอัลกอริทึม YOLOv11

ทั้งสามโมเดล ได้แก่ YOLOv11n, YOLOv11s และ YOLOv11m สามารถตรวจจับสภาพที่มีตำหนิได้ (Abnormal) แต่มีค่าความมั่นใจ (Confidence Score) ที่แตกต่างกัน

YOLOv11m มีค่าความมั่นใจสูงสุดในการตรวจจับตำหนิทั้งสองประเภท (Label A และ Label B) แสดงถึงประสิทธิภาพในการตรวจจับที่สูงกว่าเมื่อเทียบกับอีกสองโมเดล

YOLOv11n มีค่าความมั่นใจต่ำที่สุดในการตรวจจับตำหนิประเภท Label A (0.06) ซึ่งอาจแสดงถึงประสิทธิภาพที่ต่ำกว่าในการตรวจจับตำหนิขนาดเล็กหรือมีรายละเอียดน้อย

สรุปได้ว่า Label A คือ Label ที่สูง ให้ประสิทธิภาพสูงกว่า Label B คือ Label เฉพาะจุด ทั้งสามอัลกอริทึม YOLOv11n, s และ m

สรุปผลการวิจัย

YOLO ใช้ Grid-Based Object Detection ซึ่งหมายความว่า แต่ละเซลล์ในกริดของภาพต้องทำนาย Bounding Box และค่าความมั่นใจ (Confidence Score) สำหรับวัตถุที่อยู่ภายในเซลล์นั้น เมื่อใช้ Label A ซึ่งครอบคลุมทั้งลูกมะม่วง โมเดลสามารถเรียนรู้ลักษณะโดยรวมของมะม่วงได้ดีขึ้น และให้ค่าความมั่นใจสูง เนื่องจาก Bounding Box มีขนาดใหญ่พอให้ YOLO ใช้ IoU (Intersection Over Union) อย่างมีประสิทธิภาพ ในการระบุวัตถุ ในขณะที่ Label B ซึ่งกำหนด Bounding Box เฉพาะจุดตำหนิ ทำให้ Bounding Box มีขนาดเล็ก YOLO อาจประสบปัญหา False Negative หรือค่า Confidence Score ต่ำ เนื่องจาก Bounding Box เล็กเกินไปและไม่ครอบคลุมบริเวณที่สำคัญพอ

นอกจากนี้ YOLOv11 ใช้มอดูล SPPF (Spatial Pyramid Pooling-Fast) และ C2PSA (Convolutional Block with Parallel Spatial Attention) ซึ่งช่วยให้โมเดลสามารถโฟกัสไปยังบริเวณที่สำคัญของภาพได้ดีขึ้น โดยเฉพาะกับวัตถุที่มีขนาดใหญ่และมีรูปร่างชัดเจน การใช้ Label A ทำให้โมเดลสามารถใช้ประโยชน์จากกลไกเหล่านี้ได้อย่างเต็มที่ ในขณะที่ Label B ทำให้โมเดลต้องพยายามเรียนรู้จากพื้นที่เล็ก ๆ ซึ่งอาจไม่มีข้อมูลเพียงพอ

เมื่อพิจารณาพร้อมกับโครงสร้างของ YOLOv11 แต่ละเวอร์ชันพบว่า YOLOv11m ให้ความแม่นยำสูงที่สุด เนื่องจากมีจำนวนพารามิเตอร์มากขึ้นและใช้ Multi-Scale Feature Extraction และ Self-Attention Mechanism ทำให้สามารถเรียนรู้คุณลักษณะของภาพได้ดีขึ้น แต่ก็ต้องแลกมากับเวลาในการประมวลผลที่นานขึ้น ส่วน YOLOv11n และ YOLOv11s แม้จะมีความเร็วสูงกว่า แต่ก็มีความแม่นยำต่ำกว่าบ้าง

ดังนั้น จึงสามารถสรุปได้ว่า การใช้ Label A เหมาะสมกว่าการใช้ Label B เนื่องจากช่วยให้โมเดล YOLOv11 สามารถเรียนรู้โครงสร้างของมะม่วงได้อย่างครบถ้วนและสอดคล้องกับหลักการทำงานของ YOLO ที่มุ่งเน้นการตรวจจับวัตถุเป็น Bounding Box ขนาดใหญ่ มากกว่าการตรวจจับตำหนิขนาดเล็ก ซึ่งช่วยให้โมเดลสามารถทำงานได้อย่างมีประสิทธิภาพมากขึ้น และให้ผลลัพธ์ที่แม่นยำกว่าการใช้ Label B

การอภิปรายผล

จากผลการทดลองที่ใช้ภาพถ่ายมะม่วงพันธุ์น้ำดอกไม้จำนวน 1,990 ภาพ ขนาด 640x640 พิกเซล โดยการประมวลผลผ่านอัลกอริทึม YOLOv11n, YOLOv11s และ YOLOv11m เป็นเวลา 100 epoch พบว่า ทั้งสามอัลกอริทึมมีข้อดีและข้อเสียที่แตกต่างกัน YOLOv11n และ YOLOv11s ใช้พื้นที่จัดเก็บน้อยกว่า และมีความเร็วใน

การประมวลผลที่สูงกว่า ในขณะที่ YOLOv11m แม้จะให้ความแม่นยำสูงขึ้น แต่ก็ต้องใช้เวลาประมวลผลนานกว่า และต้องการพื้นที่จัดเก็บมากขึ้น เนื่องจากมีจำนวนชั้นเครือข่ายและพารามิเตอร์มากกว่า

เมื่อเปรียบเทียบผลลัพธ์ของ Label A (Bounding Box ครอบคลุมทั้งลูกมะม่วง) กับ Label B (Bounding Box เฉพาะตำแหน่งของมะม่วง) พบว่า Label A ให้ผลลัพธ์ที่ดีกว่าในแง่ของความแม่นยำ (Accuracy), ค่า IoU (Intersection Over Union), Recall และ F1-Score ซึ่งเป็นตัวชี้วัดสำคัญของการตรวจจับวัตถุ ผลลัพธ์นี้สอดคล้องกับโครงสร้างของ YOLO ที่ออกแบบมาเพื่อทำงานกับ Bounding Box ขนาดใหญ่ มากกว่าการตรวจจับจุดเล็ก ๆ ภายในภาพ

หลักการทำงานของ YOLO คือ การแบ่งภาพออกเป็น Grid-Based Object Detection Model ซึ่งแต่ละเซลล์ในกริดต้องคาดการณ์ Bounding Box ของวัตถุที่อยู่ภายในเซลล์นั้น ดังนั้นการใช้ Label A ซึ่งมี Bounding Box ครอบคลุมทั้งมะม่วง ช่วยให้โมเดลสามารถใช้ Feature Map ที่มีความละเอียดสูงขึ้นในการเรียนรู้ และสามารถให้ IoU (Intersection Over Union) ได้อย่างมีประสิทธิภาพ เมื่อ Bounding Box มีขนาดใหญ่พอ YOLO สามารถทำนายค่าความมั่นใจ (Confidence Score) ได้ดีขึ้น และลดข้อผิดพลาดจาก False Negatives

ในทางตรงกันข้าม การใช้ Label B ซึ่งระบุ Bounding Box เฉพาะจุดตำแหน่งของมะม่วง ทำให้โมเดลต้องพยายามตรวจจับ Bounding Box ที่เล็กมาก ซึ่งเป็นข้อจำกัดของ YOLO ระบบของ YOLO ใช้ Anchor-Based Detection หรือ Anchor-Free Mechanism เพื่อคาดการณ์ Bounding Box และให้คะแนนความมั่นใจ (Confidence Score) แต่เมื่อ Bounding Box มีขนาดเล็ก โอกาสที่โมเดลจะให้ค่าความมั่นใจต่ำลง และเกิด False Negative สูงขึ้น ก็เพิ่มขึ้น เนื่องจากตำแหน่งของมะม่วงมักมีขนาดเล็กมาก และอาจไม่ได้รับการตรวจจับอย่างถูกต้อง

นอกจากนี้ YOLOv11 ได้รับการพัฒนาให้สามารถประมวลผลภาพด้วยมอดูล SPPF (Spatial Pyramid Pooling-Fast) และ C2PSA (Convolutional Block with Parallel Spatial Attention) ซึ่งทำให้โมเดลสามารถโฟกัสไปยังบริเวณที่สำคัญของภาพได้ดีขึ้น อย่างไรก็ตาม โมเดล YOLO ยังคงถูกออกแบบมาเพื่อ Object Detection เป็นหลัก ไม่ใช่ Defect Detection ดังนั้น การใช้ Label A ที่ช่วยให้โมเดลสามารถเรียนรู้โครงสร้างโดยรวมของมะม่วง และใช้ Bounding Box ที่ใหญ่ขึ้น ทำให้การตรวจจับตำแหน่งสามารถทำได้ง่ายและแม่นยำกว่า

ข้อจำกัดของการใช้ Label B นอกจากจะเกิด False Negative สูงแล้ว ยังอาจได้รับผลกระทบจากปัจจัยแวดล้อม เช่น เงา, แสงสะท้อน, สัญญาณรบกวนในภาพ และความคล้ายคลึงของสีพื้นหลัง ซึ่งอาจทำให้โมเดลสับสน และตรวจจับตำแหน่งผิดพลาด นอกจากนี้ YOLO ใช้การทำนาย Bounding Box แบบ Single-Shot Detection ซึ่งต้องทำนาย Bounding Box, Class Score และ Confidence Score ภายในการประมวลผลเพียงครั้งเดียว สิ่งนี้ทำให้โมเดล YOLO ไม่เหมาะกับการตรวจจับตำแหน่งขนาดเล็กที่ต้องการความละเอียดสูง

จากการพิจารณาผลลัพธ์ของ YOLOv11n, YOLOv11s และ YOLOv11m พบว่า YOLOv11m มีความแม่นยำสูงที่สุด เนื่องจากมีจำนวนพารามิเตอร์มากขึ้น และใช้ Multi-Scale Feature Extraction และ Self-Attention Mechanism ทำให้สามารถเรียนรู้คุณลักษณะของภาพได้ดีขึ้น แต่ก็ต้องแลกมากับเวลาในการประมวลผลที่นานขึ้น ส่วน YOLOv11s มีความสมดุลระหว่างความเร็วและความแม่นยำ และ YOLOv11n ให้ความเร็วสูงสุดแต่มีความแม่นยำน้อยที่สุด ดังนั้น การเลือกใช้โมเดล YOLOv11 ควรพิจารณาตามเงื่อนไขของ

การใช้งานจริง เช่น หากต้องการความเร็วสูง YOLOv11s หรือ YOLOv11n อาจเป็นตัวเลือกที่ดีกว่า ในขณะที่หากต้องการความแม่นยำสูงสุด และมีทรัพยากรเพียงพอ YOLOv11m จะเป็นตัวเลือกที่เหมาะสม

จากการวิเคราะห์ผลลัพธ์ของการใช้ Label A และ Label B สามารถสรุปได้ว่า Label A ให้ผลลัพธ์ที่มีประสิทธิภาพสูงกว่า Label B เนื่องจาก

1. Bounding Box ขนาดใหญ่ช่วยให้โมเดลสามารถใช้ Feature Map ที่มีความละเอียดสูงขึ้นในการเรียนรู้

2. โมเดล YOLO ถูกออกแบบมาเพื่อทำงานกับ Bounding Box ที่มีขนาดใหญ่และชัดเจนมากกว่าการตรวจจับตำแหน่งขนาดเล็ก

3. การตรวจจับตำแหน่งขนาดเล็กต้องการเทคนิคที่ซับซ้อนขึ้น เช่น Instance Segmentation หรือ Attention Mechanism ที่เน้นเฉพาะจุด ซึ่ง YOLO ไม่ได้ออกแบบมาให้เหมาะสมกับการทำงานประเภทนี้

จากการศึกษาวิจัยเกี่ยวกับการประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) ในการตรวจจับและจำแนกคุณภาพของผลไม้พบว่า งานวิจัยหลายชิ้นสนับสนุนแนวทางการใช้ YOLO และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในการประมวลผลภาพ เพื่อคัดแยกและจำแนกคุณภาพของผลไม้ได้อย่างแม่นยำ

ทีมงานวิจัยของ นพรุจ พัฒนสาร และณัฐภูมิ ศรีวิบูลย์ (2563) ได้นำเทคโนโลยีการประมวลผลภาพด้วยวิธีการเรียนรู้เชิงลึกที่สามารถจำลองการมองเห็นของมนุษย์พัฒนาแบบจำลองสำหรับตรวจสอบและจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์ โดยดำเนินการเก็บรวบรวมข้อมูลภาพถ่ายมะม่วงพันธุ์โชคอนันต์ และเก็บข้อมูลการจำแนกคุณภาพ กำหนดระดับคุณภาพออกเป็น 4 ระดับ ประกอบด้วย คุณภาพระดับเกรด A, คุณภาพระดับเกรด B, คุณภาพระดับเกรด C และคุณภาพระดับเกรด D คือ มะม่วงเน่า ผลของการวิจัยแสดงให้เห็นว่า การใช้วิธีการเรียนรู้เชิงลึกด้วยอัลกอริทึมโครงข่ายประสาทเทียมแบบสังวัตนาการ (Convolutional Neural Network: CNN) ในการประมวลผลภาพ เพื่อสร้างแบบจำลองแสดงค่าความแม่นยำสูงสุด คือ 99.79% จากนั้นนำแบบจำลองพัฒนาเป็นระบบต้นแบบสำหรับจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์พบว่า อัตราความสำเร็จในการจำแนก คือ 100%

Liu และคณะ (2023) งานวิจัยนี้เสนอโมเดล ATC-YOLOv5 ที่ปรับปรุงจาก YOLOv5 เพื่อใช้ในการตรวจจับและคัดแยกคุณภาพของเสาวรส โดยมุ่งเน้นการปรับปรุงความแม่นยำและประสิทธิภาพในการจำแนกเกรดของผลไม้

Zhu และ Spachos (2021) งานวิจัยนี้พัฒนาระบบคัดแยกอาหารบนอุปกรณ์เคลื่อนที่โดยใช้การผสมผสานระหว่าง SVM และ YOLOv3 เพื่อประเมินคุณภาพของกล้วย โดยระบบสามารถจำแนกและระบุตำแหน่งของข้อบกพร่องบนผิวกล้วยได้อย่างมีประสิทธิภาพ

Sapkota และคณะ (2025) งานวิจัยนี้ประเมินประสิทธิภาพของอัลกอริทึม YOLO เวอร์ชันต่าง ๆ ในการตรวจจับและนับจำนวนผลไม้เล็ก ๆ ในสวนผลไม้ที่มีสภาพแวดล้อมซับซ้อน เพื่อหาโมเดลที่เหมาะสมที่สุดสำหรับการประยุกต์ใช้ในสภาพแวดล้อมจริง

Yoon และคณะ (2024) งานวิจัยนี้ใช้การเพิ่มข้อมูลภาพด้วย AI เชิงสร้างสรรค์ร่วมกับอัลกอริทึม YOLOv9 เพื่อปรับปรุงการตรวจจับและประเมินคุณภาพของเมลอน โดยใช้ภาพที่สร้างขึ้นเพื่อเพิ่มประสิทธิภาพของโมเดลในการจำแนกคุณภาพของผลไม้

Nagpal และคณะ (2023) งานวิจัยนี้ประยุกต์ใช้ YOLOv3 ในการตรวจจับและนับจำนวนเชอร์รี่หวาน เพื่อช่วยในการประเมินลักษณะทางฟิโนไทป์ของผลไม้ ลดความจำเป็นในการนับด้วยมือ และเพิ่มความแม่นยำในการประเมิน

ดังนั้น งานวิจัยที่กล่าวมาทั้งหมดนี้ สอดคล้องกับผลการทดลองของ YOLOv11 ในการตรวจจับมะม่วงน้ำดอกไม้ โดยแสดงให้เห็นว่า YOLO เหมาะสมกับงานที่ต้องการความเร็วและความแม่นยำในการตรวจจับผลไม้แบบเรียลไทม์

ดังนั้น การเลือก Label A ช่วยให้โมเดลสามารถใช้ข้อได้เปรียบของ YOLO ได้อย่างเต็มที่ ส่งผลให้มีความแม่นยำสูงกว่า Label B ในการคัดแยกคุณภาพของมะม่วงน้ำดอกไม้ ซึ่งเป็นประโยชน์ต่อการพัฒนาเทคโนโลยีคัดแยกผลไม้ในอุตสาหกรรมเกษตรอัจฉริยะต่อไป

ข้อเสนอแนะ

1. สามารถพัฒนาและปรับปรุงโมเดลต่อไปในอนาคต เช่น การใช้ YOLO V11 ในการคัดแยกผลไม้ชนิดอื่น ๆ ได้
2. สามารถนำเทคโนโลยี AI ไปประยุกต์ใช้ในกระบวนการผลิตทางการเกษตรอื่น ๆ ได้

เอกสารอ้างอิง

กษิต ศตางค์มงคล. (2566, 17 มกราคม). Confusion matrix คืออะไร พร้อมวิธีคำนวณค่าสถิติง่ายๆ.

DataRockie. <https://datarockie.com/blog/confusion-matrix-explained/>

ไทยเซ็นเบอร์ 1 ส่งออกมะม่วง ตลาดเกาหลีใต้ ปี 2567. (2568, 3 มีนาคม). *ไทยรัฐออนไลน์*.

<https://www.thairath.co.th/scoop/infographic/2844988>

นพรุจ พัฒนสาร และณัฐวุฒิ ศรีวิบูลย์. (2563). การประมวลผลภาพสำหรับการจำแนกคุณภาพมะม่วงพันธุ์โชคอนันต์โดยการจำลองการมองเห็นของมนุษย์ด้วยวิธีการเรียนรู้เชิงลึก. *วารสารวิทยาการและเทคโนโลยีสารสนเทศ*, 10(1), 24-29. <https://doi.org/10.14456/jist.2020.3>

พีระศักดิ์ ฉายประสาท. (2553). *การปลูกมะม่วงน้ำดอกไม้สีทอง*. ภารกิจโครงการและประสานงานวิจัย สำนักงานคณะกรรมการวิจัยแห่งชาติ.

Bilal, M. M., Shivandappa, Sanju, H. K., Kumar, N. S., & Kaipa, V. K. (2024). Automated mango classification using convolutional neural networks (CNN). *International Journal of Innovative Science and Research Technology*, 9(9), 269-275. <https://doi.org/10.38124/ijisrt/IJSRT24SEP163>

Ghosh, A. (2024, October 8). YOLO11: Redefining real-time object detection. *LearnOpenCV*. <https://learnopencv.com/yolo11/>

Khanam, R., & Hussain, M. (2024). *YOLOv11: An overview of the key architectural enhancements*. arXiv. <https://doi.org/10.48550/arXiv.2410.17725>

- Liu, C., Lin, W., Feng, Y., Guo, Z., & Xie, Z. (2023). ATC-YOLOv5: Fruit appearance quality classification algorithm based on the improved YOLOv5 model for passion fruits. *Mathematics*, 11(16), Article 3615. <https://doi.org/10.3390/math11163615>
- Nagpal, R., Long, S., Jahagirdar, S., Liu, W., Fazackerley, S., Lawrence, R., & Singh, A. (2023). *An application of deep learning for sweet cherry phenotyping using YOLO object detection*. arXiv. <https://doi.org/10.48550/arXiv.2302.06698>
- Rao, S. N. (2024, October 23). YOLOv11 architecture explained: Next-level object detection with enhanced speed and accuracy. *Medium*. <https://medium.com/@nikhil-rao-20/yolov11-explained-next-level-object-detection-with-enhanced-speed-and-accuracy-2dbe2d376f71>
- Sapkota, R., Meng, Z., Churuvija, M., Du, X., Mab, Z., & Karkee, M. (2025). *Comprehensive performance evaluation of YOLOv12, YOLOv11, YOLOv10, YOLOv9 and YOLOv8 on detecting and counting fruitlet in complex orchard environments*. arXiv. <https://doi.org/10.48550/arXiv.2407.12040>
- Yeh, J.-F., Lin, K.-M., Lin, C.-Y., & Kang, J.-C. (2023). Intelligent mango fruit grade classification using AlexNet-SPP with mask R-CNN-based segmentation algorithm. *IEEE Transactions on AgriFood Electronics*, 1(1), 41–49. <https://doi.org/10.1109/TAFE.2023.3267617>
- Yoon, S., Cho, Y., & Ahn, T. I. (2024). *Melon fruit detection and quality assessment using generative AI-based image data augmentation*. arXiv. <https://doi.org/10.48550/arXiv.2407.10413>
- Y-T-G, glenn-jocher, Laughing-q, RizwanMunawar, pderrenger, & ambitious-octopus. (2025, February 26). Ultralytics YOLO11. *Ultralytics*. <https://docs.ultralytics.com/models/yolo11/>
- Zhu, L., & Spachos, P. (2021). Support vector machine and YOLO for a mobile food grading system. *Internet of Things*, 13, Article 100359. <https://doi.org/10.1016/j.iot.2021.100359>