

การจำแนกความสุกของปาล์มน้ำมันสดโดยใช้การเรียนรู้เชิงลึก
RIPENESS CLASSIFICATION OF FRESH OIL PALM USING DEEP LEARNING

นนุช สังข์ทอง

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566



การจำแนกความสุขของปาล์มน้ำมันสดโดยใช้การเรียนรู้เชิงลึก



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

RIPENESS CLASSIFICATION OF FRESH OIL PALM USING DEEP LEARNING



NONGNOOT SUNGTHONG

A Master's Project Submitted in Partial Fulfillment of the Requirements

for the Degree of MASTER OF SCIENCE

(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์
เรื่อง
การจำแนกความสุขของปาล์มน้ำมันสดโดยใช้การเรียนรู้เชิงลึก
ของ
นางนุช สังข์ทอง

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)
คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก
(อาจารย์ ดร.วีระ สอึ้ง)

..... ประธาน
(รองศาสตราจารย์ ดร.สุพัฒนา เอื้อทวีเกียรติ)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การจำแนกความสุกของปาล์มน้ำมันสดโดยใช้การเรียนรู้เชิงลึก
ผู้วิจัย	นนุช สังข์ทอง
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	อาจารย์ ดร. วีระ สอิ่ง

จากปัญหาของการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ทำให้ผู้วิจัยสนใจศึกษาปัญหาและวิธีการที่ใช้ในการจำแนกระดับความสุกของผลปาล์มน้ำมันสดจากงานวิจัยในอดีต เพื่อนำเสนอวิธีการจำแนกระดับความสุกของผลปาล์มน้ำมันสด จากภาพถ่ายผลปาล์มน้ำมันโดยใช้การเรียนรู้เชิงลึก โดยผู้วิจัยเลือกใช้แบบจำลองการเรียนรู้เชิงลึกสำหรับการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ที่สามารถพัฒนาไปสู่การใช้งานแบบเรียลไทม์ เพื่อเป็นแนวทางในการประยุกต์วิธีการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ให้สามารถใช้งานได้กับสถานการณ์จริงในอนาคต โดยเลือกแบบจำลองการเรียนรู้เชิงลึกที่นำหลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้แก่ แบบจำลอง You Only Look Once version 8 nano (YOLOv8n) และทำการปรับค่าพารามิเตอร์การเรียนรู้ต่าง ๆ เพื่อให้ได้แบบจำลองการจำแนกระดับความสุกของผลปาล์มน้ำมันสดที่สามารถจำแนกได้อย่างแม่นยำที่สุด จากผลการดำเนินงานวิจัยพบว่า การจำแนกระดับความสุกของผลปาล์มน้ำมันสด ด้วยแบบจำลองการเรียนรู้เชิงลึก ที่ชื่อว่า YOLOv8n ที่มีการปรับปรุงค่าพารามิเตอร์การเรียนรู้ ดังต่อไปนี้ Optimizer = Adam, Learning rate = 0.0001 และ Batch size = 32 แสดงค่าความแม่นยำสูงสุด จากการฝึกสอน (Training) และตรวจสอบ (Validate) ด้วยชุดข้อมูลของการฝึกสอนจำนวน 11,900 ภาพ และชุดข้อมูลประเมินผลจำนวน 1,782 ภาพ หลังจากนั้นทำการทดสอบแบบจำลองด้วยชุดข้อมูลทดสอบ (Testing dataset) จำนวน 795 ภาพ ที่แสดงค่าความถูกต้อง (Precision) 98.8%, ค่าของการทำนายถูกต้อง (Recall) 99.7%, ค่าความเที่ยงตรงเฉลี่ยที่ตรวจพบวัตถุจริงอย่างน้อย 50% (mAP50) 99.5% และ ค่าความเที่ยงตรงเฉลี่ยที่ตรวจพบวัตถุจริงในช่วง 50% ถึง 95% (mAP50-95) 99.5% จากผลลัพธ์ของการทดลอง แสดงให้เห็นว่าโมเดลการเรียนรู้เชิงลึกที่นำเสนอนี้ มีความถูกต้องมากพอที่จะนำไปใช้ในการจำแนกระดับความสุกของปาล์มน้ำมันสดได้

คำสำคัญ : การจำแนกความสุก, ปาล์มน้ำมัน, การวิเคราะห์ภาพ, การเรียนรู้เชิงลึก

Title	RIPENESS CLASSIFICATION OF FRESH OIL PALM USING DEEP LEARNING
Author	NONGNOOT SUNGTHONG
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Dr. Vera Sa-ing

The challenge of accurately classifying the ripeness level from fresh oil palm fruit. This research investigated the problems with and methods used in ripeness level classification. The aim of this research is to propose a method for classifying the ripeness level of oil palm fruit from images using deep learning. This research applies a deep learning model for classifying the ripeness level of fresh oil palm fruit and aiming for real-time application. The proposed model, You Only Look Once version 8 nano (YOLOv8n), adapts principles from convolutional neural networks that were tuned to the learning parameters consisting of the Adam optimizer, a learning rate of 0.0001, and a batch size of 32, and result in the most accurate ripeness level classification model. The research demonstrates the YOLOv8n improved model with optimized parameters to achieve the highest accuracy. There were 11,900 images for training dataset 1,782 images for validation datasets and 795 images for testing dataset represent precision of 98.8%, recall of 99.7%, mean average precision of 50% (mAP50) of 99.5%, and mAP50-95 of 99.5%. These findings confirmed the effectiveness of the models in accurately classifying the ripeness level of oil palm fruit from the images.

Keyword : Ripeness classification, Oil palm fruit, Image analysis, Deep learning

กิตติกรรมประกาศ

รายงานสารนิพนธ์ฉบับนี้สำเร็จสมบูรณ์ไปได้ เนื่องจากได้รับความช่วยเหลือและความเอาใจใส่เป็นอย่างยิ่งจาก ดร.วีระ สอิ่ง อาจารย์ประจำภาควิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และที่ปรึกษาหลักในงานวิจัยนี้ ที่ได้เสียสละเวลาส่วนตัวมาให้ความรู้ให้คำปรึกษาในการทำงานเสมอมา ตลอดจนช่วยแนะนำและแก้ไขข้อบกพร่องต่าง ๆ ในการทำวิจัยครั้งนี้ จนกระทั่งงานวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี ขอกราบขอบพระคุณอย่างสูงมา ณ ที่นี้

ขอขอบคุณคณาจารย์ทุกท่านที่สอนสั่งและให้ความรู้ตามแผนการเรียนรู้อันหลักสูตรของ สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ และให้คำแนะนำต่าง ๆ ในการทำงานที่เกี่ยวข้องกับงานวิจัยครั้งนี้

ขอขอบคุณพี่ ๆ และเพื่อน ๆ นิสิตปริญญาโทร่วมชั้นเรียนทุกท่าน ที่คอยสนับสนุน ให้ความช่วยเหลือ และให้กำลังใจผู้วิจัย ในการทำงานครั้งนี้ตลอดมา

สุดท้ายนี้ ผู้วิจัยหวังเป็นอย่างยิ่งว่า งานวิจัยฉบับนี้จะเป็นประโยชน์แก่ผู้ที่เกี่ยวข้องและสนใจต่อไปไม่มากนักน้อย หากมีข้อผิดพลาดประการใด ผู้วิจัยขออภัยและขออภัยมา ณ ที่นี้ด้วย

นางนุช สังข์ทอง

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของงานวิจัย.....	1
1.2 วัตถุประสงค์ของงานวิจัย	4
1.3 ขอบเขต และกิจกรรมการดำเนินงาน.....	5
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	5
บทที่ 2 ทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง.....	6
2.1 การจำแนกระดับความสุกของปาล์มน้ำมันสด	6
2.1.1 งานวิจัยเรื่อง Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network (Ibrahim et al., 2018)	6
2.1.2 งานวิจัยเรื่อง Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach (Septiarini et al., 2020)	10
2.1.3 งานวิจัยเรื่อง Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet (Herman et al., 2021)	17
2.1.4 งานวิจัยเรื่อง Oil Palm Fruit Ripeness Detection using Deep Learning (Ashari et al., 2022)	19

2.1.5 งานวิจัยเรื่อง Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch (Dambul et al., 2022).....	26
2.1.6 งานวิจัยเรื่อง Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method (Khamis et al., 2022)	30
2.1.7 งานวิจัยเรื่อง Comparison CNN and Mobilenet_v2 Model for Oil Palm FBB Ripeness Classification (Mohtar et al., 2022)	36
2.1.8 งานวิจัยเรื่อง Grading Oil Palm Fruit Bunch using Convolution Neural Network (Azman & Suriani, 2023)	40
2.2 การตรวจจับทะลายปาล์มน้ำมันสด.....	48
2.2.1 งานวิจัยเรื่อง Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer Vision Models (Chen et al., 2022).....	48
2.2.2 งานวิจัยเรื่อง Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4 (Lai et al., 2022).....	53
2.3 การทบทวนงานวิจัยเกี่ยวกับการจำแนกระดับความสุกทะลายปาล์มน้ำมัน.....	59
2.3.1 งานวิจัยเรื่อง Oil Palm Fresh Fruit Bunch Ripeness Detection Methods: A Systematic Review (Lai et al., 2023).....	59
2.4 แบบจำลองการตรวจจับวัตถุ (Object Detection Model) (Patel & Patel, 2020)	61
2.4.1 Two-Stage Detectors.....	62
2.4.2 Single-Stage Detectors	63
2.5 You Only Look Once (YOLO) (soumyadip, 2023)	66
บทที่ 3 กระบวนการ และวิธีการดำเนินการวิจัย	68
3.1 การเก็บรวบรวมข้อมูล (Data Acquisition).....	68
3.2 การเตรียมข้อมูล (Data Preparation)	70
3.2.1 การเตรียมข้อมูล (Data Preprocessing).....	70

3.2.2 การเพิ่มปริมาณข้อมูลภาพสอน (Data Augmentation).....	71
3.2.3 การแบ่งข้อมูล (Split Data).....	71
3.3 การฝึกฝนแบบจำลอง (Training and Validation Model)	72
3.4 การประเมินผลการทดลอง (Model Evaluation)	73
3.4.1 การประเมินความสามารถในการจำแนกวัตถุ	73
บทที่ 4 การทดลอง และผลลัพธ์ของการวิจัย	76
4.1 การปรับแต่งแบบจำลอง YOLOv8n.....	76
4.1.1 Optimizer	76
4.1.2 Learning rate	76
4.1.3. Batch Size.....	77
4.2 ผลการเปรียบเทียบแบบจำลอง.....	77
4.3 การทดสอบแบบจำลองด้วยชุดข้อมูลแหล่งอื่นเพิ่มเติม	80
บทที่ 5 การสรุปผลการวิจัย การอภิปรายผล และข้อเสนอแนะของการวิจัย.....	83
5.1 สรุปผลการวิจัย.....	83
5.2 อภิปรายผลการวิจัย	85
5.2.1 การประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุดในชุดข้อมูล Testing dataset....	85
5.2.2 การประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุดในชุดข้อมูลจากแหล่งอื่นเพิ่มเติม	86
5.3 ข้อเสนอแนะ.....	88
บรรณานุกรม	89
ประวัติผู้เขียน.....	94

สารบัญตาราง

	หน้า
ตาราง 1 แสดงประสิทธิภาพการจำแนกระดับความสุขของผลปาล์มน้ำมันด้วย CNN	8
ตาราง 2 แสดงประสิทธิภาพของการจำแนกระดับความสุขของผลปาล์มน้ำมันด้วย AlexNet	8
ตาราง 3 แสดงประสิทธิภาพของการจำแนกระดับความสุขของปาล์มน้ำมันด้วย Handcrafted Features with SVM	9
ตาราง 4 แสดงตัวอย่างผลการแยกคุณสมบัติในพื้นที่สี L^*A^*B	14
ตาราง 5 สรุปค่า Accuracy ของแต่ละวิธีการใน Color Space ต่าง ๆ	15
ตาราง 6 แสดงจำนวนชุดข้อมูลภาพในแต่ละระดับความสุขทะเลปาล์มน้ำมัน	17
ตาราง 7 แสดงผลจากการทดลอง.....	18
ตาราง 8 แสดงคำอธิบายระดับความสุขของปาล์มน้ำมัน	19
ตาราง 9 แสดง Confusion matrix.....	21
ตาราง 10 แสดง CNN Model Result.....	22
ตาราง 11 แสดงผลลัพธ์ของ Confusion Matrix	24
ตาราง 12 ผลการทดลอง (Test Result).....	24
ตาราง 13 แสดงผลการจำแนกความสุขของทะเลปาล์มน้ำมันด้วยอัลกอริทึมต่าง ๆ	26
ตาราง 14 ผลการเปรียบเทียบ Object detection models	29
ตาราง 15 ไฮเปอร์พารามิเตอร์ของ RESNET50.....	31
ตาราง 16 ไฮเปอร์พารามิเตอร์ของ YOLOV3	32
ตาราง 17 ตัวอย่างภาพสำหรับการฝึกอบรม การทดสอบ และการตรวจสอบความถูกต้อง	32
ตาราง 18 ความถูกต้องแม่นยำของการจำแนกตามประเภทตัวอย่างการทดสอบด้วย ResNet50	33
ตาราง 19 ค่าเฉลี่ยความแม่นยำ (mAP) ในการจำแนกระดับความสุขด้วย YOLOv3	35

ตาราง 20	เปอร์เซ็นต์ของการฝึกอบรมและความถูกต้องของการตรวจสอบตามช่วงเวลา.....	38
ตาราง 21	การจัดหมวดหมู่ผลลัพธ์ของรูปภาพใหม่สำหรับ CNN และ Mobilenet_v2.....	39
ตาราง 22	จำนวนชุดข้อมูลทั้งหมดสำหรับการฝึกอบรม การทดสอบ และการตรวจสอบความถูกต้อง	41
ตาราง 23	จำนวนภาพสำหรับแต่ละชุดข้อมูลสำหรับแบบจำลอง SVM	50
ตาราง 24	จำนวนรูปภาพสำหรับแบบจำลองการเรียนรู้เชิงลึก	51
ตาราง 25	ค่า Weights ที่ดีที่สุดจากการฝึกอบรมแต่ละแบบจำลอง	52
ตาราง 26	ผลการทดสอบแบบจำลอง	52
ตาราง 27	แสดงการแยกภาพสำหรับการฝึกแบบจำลอง YOLOv4.....	55
ตาราง 28	แสดงค่าของพารามิเตอร์ในแบบจำลอง YOLOv4	55
ตาราง 29	แสดงผลการวิเคราะห์แบบจำลอง YOLOv4 ทุก ๆ 1,000 ครั้ง.....	56
ตาราง 30	ขนาดของแบบจำลองรุ่นต่าง ๆ	57
ตาราง 31	การวิเคราะห์แบบจำลอง YOLOv4 รุ่นต่าง ๆ	58
ตาราง 32	การประเมินแบบจำลอง YOLOv4 ณ สถานที่จริง	58
ตาราง 33	เปรียบเทียบแบบจำลองตรวจจับวัตถุแบบ Single-stage และ Two-stage	65
ตาราง 34	ตารางแสดงรายละเอียดอัลกอริทึม YOLO ในแต่ละเวอร์ชัน	66
ตาราง 35	แสดงการกระจายของทะเลาะและรูปภาพ สำหรับแต่ละหมวดหมู่.....	69
ตาราง 36	อัตราส่วนการแบ่งชุดข้อมูลต้นฉบับ	70
ตาราง 37	แสดงจำนวนชุดข้อมูลสำหรับดำเนินงานวิจัย.....	71
ตาราง 38	แสดงค่าความสามารถของแบบจำลอง YOLOv8.....	73
ตาราง 39	ตารางแสดงค่า Confusion Matrix	74
ตาราง 40	แสดงผลการทดสอบประสิทธิภาพแบบจำลอง ด้วยการกำหนดค่าพารามิเตอร์ต่าง ๆ เพื่อเปรียบเทียบค่า Precision Recall mAP50 mAP50-95 และ Training time	77

สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 ภาพสวนปาล์มน้ำมัน	2
ภาพประกอบ 2 ภาพแสดงตัวอย่างทะเลาะปาล์มน้ำมัน	3
ภาพประกอบ 3 ตัวอย่างภาพทะเลาะปาล์มน้ำมัน แบ่งออกเป็น 4 ระดับ ได้แก่ a) สุกพอดี b) กึ่งสุกกึ่งดิบ C) สุกเกินไป และ d) ดิบ.....	7
ภาพประกอบ 4 ตัวอย่างภาพที่มีการตัดกรอบให้เห็นเฉพาะทะเลาะปาล์มน้ำมัน	10
ภาพประกอบ 5 แสดงตัวอย่างชุดข้อมูลภาพ	11
ภาพประกอบ 6 กระบวนการในการจำแนกระดับความสุกของทะเลาะปาล์มน้ำมัน.....	11
ภาพประกอบ 7 ภาพแสดง Features Extraction in L*a*b Color Space	12
ภาพประกอบ 8 ภาพแสดง The Features Extraction in YCbCr Color Space	13
ภาพประกอบ 9 ภาพแสดง The features Extraction in HSV Color Space	13
ภาพประกอบ 10 ภาพแสดง The Features Extraction in YIQ Color Space	13
ภาพประกอบ 11 The features extraction in RGB color space	14
ภาพประกอบ 12 ภาพแสดง Confusion Matrix Multiclass of the Applied Method	16
ภาพประกอบ 13 แสดงตัวอย่างของชุดข้อมูล	17
ภาพประกอบ 14 แสดง Flowchart Training.....	20
ภาพประกอบ 15 แสดงตัวอย่าง Augmentation Process Results	22
ภาพประกอบ 16 แสดง Training Result	23
ภาพประกอบ 17 แสดงตัวอย่างชุดข้อมูล (a) ดิบ (unripe), (b) กึ่งสุกกึ่งดิบ (half-ripe), (c) สุกพอดี (ripe) และ (d) สุกเกินไป (over-ripe bunch).....	28
ภาพประกอบ 18 Confusion Matrix ของ ResNet50.....	34
ภาพประกอบ 19 Mean Average Precision (mAP) ของ YOLOv3	34

ภาพประกอบ 20 แสดงค่า mAP ของแต่ละระดับความสูงของทะเลลายปาล์มน้ำมัน	35
ภาพประกอบ 21 แสดงแผนการดำเนินงาน.....	37
ภาพประกอบ 22 การกำหนดค่าของระบบการจำแนกผลปาล์มน้ำมันโดยใช้สมาร์ทโฟน (Android)	41
ภาพประกอบ 23 Flowchart ของการพัฒนาแอปพลิเคชัน	42
ภาพประกอบ 24 กราฟแสดงค่าความแม่นยำของการฝึกอบรมและการตรวจสอบความถูกต้อง .	44
ภาพประกอบ 25 กราฟแสดงการสูญเสียของการฝึกอบรมและการตรวจสอบความถูกต้อง	45
ภาพประกอบ 26 Confusion matrix ของแบบจำลอง CNN	45
ภาพประกอบ 27 ผลการจำแนกของแบบจำลอง.....	46
ภาพประกอบ 28 ผลลัพธ์ของการจำแนกโดยใช้ Samsung Galaxy S22 ผ่านกล้อง	47
ภาพประกอบ 29 ผลลัพธ์ของการจำแนกโดยใช้ Samsung Galaxy A30 ผ่านกล้อง	47
ภาพประกอบ 30 เปอร์เซ็นต์ความแม่นยำสำหรับภาพจำนวน 90 ภาพ.....	48
ภาพประกอบ 31 พีเจอร์ที่ดึงมาจากภาพ โดยใช้ HOG	49
ภาพประกอบ 32 (a) ผลการตรวจจับของแบบจำลอง SVM + HOG model, (1) the SVM + HOG model ไม่ตรวจจับทะเลลายปาล์มในรูปภาพหญ้า, (2) มี bounding box รวมพื้นที่ของผลที่ร่วงด้วย, (3) แบบจำลองตรวจจับภาพที่มีหลายทะเลลายเป็นทะเลลายเดียว, (b) ผลการตรวจจับของแบบจำลอง Faster R-CNN model, (c) ผลการตรวจจับของแบบจำลอง YOLOv4 model, (d) ผลการตรวจจับของแบบจำลอง YOLOv5 model	53
ภาพประกอบ 33 ความแม่นยำเฉลี่ยของ YOLOv4 ที่ 25 % 50 % และ 75 % IoU thresholds ของชุดการตรวจสอบความถูกต้อง.....	57
ภาพประกอบ 34 จำนวนบทความที่จัดหมวดหมู่ตามแบบจำลอง (Machine Learning Model) 60	
ภาพประกอบ 35 R-CNN: a region-based CNN detector	62
ภาพประกอบ 36 YOLO: a single-stage object detector model	64
ภาพประกอบ 37 A timeline of YOLO versions	66

ภาพประกอบ 38 แผนผังการดำเนินงานวิจัย	68
ภาพประกอบ 39 ตัวอย่างภาพกองทะเลลายปาล์มน้ำมันสด (a) ที่มีระดับความสุกหมวดหมู่เดียวกัน (b) ที่มีระดับความสุกแตกต่างกัน	69
ภาพประกอบ 40 แสดงตัวอย่างการทำ Objects Isolation	71
ภาพประกอบ 41 กราฟแสดงจำนวนข้อมูลที่ใช้ในการฝึกฝนแบบจำลอง	72
ภาพประกอบ 42 กราฟแสดงค่าความสูญเสีย (loss) และค่าความแม่นยำ (mAP) ของ YOLOv8n ที่มีประสิทธิภาพดีที่สุด	79
ภาพประกอบ 43 ภาพรวมการฝึกอบรมและตรวจสอบความถูกต้องของแบบจำลองที่มีประสิทธิภาพดีที่สุด ด้วย YOLOv8n weight และชุดข้อมูลผลปาล์มน้ำมันสด	79
ภาพประกอบ 44 ภาพแสดง Confusion Matrix Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Validation dataset	80
ภาพประกอบ 45 ภาพแสดงการประเมินประสิทธิภาพของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Testing dataset	80
ภาพประกอบ 46 ผลการประเมินแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุดด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม	81
ภาพประกอบ 47 ภาพแสดงตัวอย่างชุดข้อมูลที่ใช้ทดสอบเพิ่มเติม พร้อม Label กำกับ	81
ภาพประกอบ 48 ภาพแสดงตัวอย่างผลการทำนายระดับความสุกของปาล์มน้ำมันสด ด้วยชุดข้อมูลเพิ่มเติมจากแหล่งอื่น	82
ภาพประกอบ 49 ภาพแสดง Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Testing dataset	85
ภาพประกอบ 50 ภาพแสดง Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม	86

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของงานวิจัย

ปาล์มน้ำมัน เป็นพืชตระกูลปาล์ม เช่นเดียวกับตาลโตนด มะพร้าว และอินทผาลัม มีถิ่นกำเนิดดั้งเดิมในแอฟริกาตะวันตก มีการนำเข้าสู่ประเทศไทยครั้งแรกเมื่อปี พ.ศ. 2472 ใช้เป็นปาล์มประดับที่สถานีทดลองยาง จังหวัดสงขลา และสถานีกสิกรรมพลู จังหวัดจันทบุรี ต่อมาหม่อมเจ้าอมรสมานลักษณ์ กิติยากร ทรงริเริ่มปลูกปาล์มน้ำมันเพื่อการค้าเป็นครั้งแรกบนพื้นที่ 1,000 ไร่ ณ ตำบลปริก อำเภอสะเดา จังหวัดสงขลา ปัจจุบัน ปาล์มน้ำมันกลายเป็นพืชเศรษฐกิจสำคัญของไทย ด้วยคุณสมบัติเด่น คือ แหล่งน้ำมันชั้นเยี่ยม สร้างรายได้ให้แก่เกษตรกร และมีผลผลิตต่อพื้นที่สูง เป็นที่ต้องการของตลาดทั้งในและต่างประเทศ (สำนักงานเกษตรและสหกรณ์จังหวัดชุมพร, 2564)

ปัจจุบัน ปาล์มน้ำมันมีบทบาทสำคัญใน ยุทธศาสตร์พลังงานทดแทนและพลังงานทางเลือกของประเทศไทย ส่งผลให้พื้นที่ปลูกปาล์มขยายตัวอย่างต่อเนื่อง โดยเฉพาะในภาคใต้ ซึ่งมีสภาพภูมิอากาศเหมาะสม คิดเป็นสัดส่วน 87.69 เปอร์เซ็นต์ ของพื้นที่ปลูกทั่วประเทศ จังหวัดที่มีพื้นที่ปลูกปาล์มน้ำมันมากที่สุด 3 อันดับแรก ได้แก่ สุราษฎร์ธานี กระบี่ และชุมพร คิดเป็นสัดส่วนรวมกันเกือบ 58 เปอร์เซ็นต์ พื้นที่ที่เหลือกระจายอยู่ตามภาคกลาง ภาคตะวันออกเฉียงเหนือ และภาคเหนือตามลำดับ ในปี 2565 พื้นที่ปลูกปาล์มน้ำมันให้ผลผลิตทั่วประเทศอยู่ที่ 6.15 ล้านไร่ เพิ่มขึ้นจากปี 2564 ร้อยละ 1.99 สะท้อนถึงความสนใจของเกษตรกรที่เพิ่มมากขึ้นต่อพืชเศรษฐกิจชนิดนี้ (กฤตชญา ชนะสิทธิ์ นิศากร รัตนถาวร และ กานต์ทิศา จิตรเอียด, 2566) ทั้งนี้ เกษตรกรหันมาปลูกปาล์มน้ำมันกันมากขึ้น เนื่องด้วยศักยภาพของปาล์มน้ำมันที่หลากหลาย ครอบคลุมทั้งด้านอาหาร พลังงานทดแทน

ปาล์มน้ำมันพืชเศรษฐกิจที่สำคัญของไทย ขับเคลื่อนเศรษฐกิจผ่านการนำไปใช้ประโยชน์อย่างหลากหลาย โดยมีการบริโภคน้ำมันปาล์มภายในประเทศสูงถึง 60 เปอร์เซ็นต์ ของปริมาณน้ำมันปาล์มทั้งหมด นอกจากนี้ ยังมีการใช้ปาล์มน้ำมันในอุตสาหกรรมการผลิตสบู่ คิดเป็น 9.2 เปอร์เซ็นต์ อุตสาหกรรมการผลิตของว่างและขนมขบเคี้ยว 8.6 เปอร์เซ็นต์ อุตสาหกรรมอื่น ๆ เช่น ยางรถยนต์ พลาสติก เครื่องสำอาง น้ำมันหล่อลื่น 7.6 เปอร์เซ็นต์ อุตสาหกรรมบะหมี่กึ่งสำเร็จรูป 5.9 เปอร์เซ็นต์ และอุตสาหกรรมเนย 1.0 เปอร์เซ็นต์ ปาล์มน้ำมันจึงเปรียบเสมือนฟันเฟืองสำคัญที่หล่อเลี้ยงเศรษฐกิจไทย และส่งเสริมการเติบโตของภาคอุตสาหกรรมอย่างยั่งยืน โดยตัวอย่างสวนปาล์มน้ำมันแสดงดังภาพประกอบที่ 1



ภาพประกอบ 1 ภาพสวนปาล์มน้ำมัน

ที่มา : (ธีระพงศ์ จันทรนิยม, 2562)

การขายผลปาล์มน้ำมันสดให้กับโรงงานสกัดน้ำมันปาล์ม คือการขายน้ำมันปาล์มในรูปแบบทะลาย การเก็บเกี่ยวที่ถูกต้องและเหมาะสม จะให้ทะลายปาล์มที่มีคุณภาพและเปอร์เซ็นต์น้ำมันสูง ซึ่งมีผลต่อราคาด้วย เปอร์เซ็นต์น้ำมันหมายถึง น้ำหนักของน้ำมันเมื่อเปรียบเทียบกับน้ำหนักทะลายปาล์มสด ปัจจัยที่กำหนดเปอร์เซ็นต์น้ำมันในทะลายปาล์มประกอบด้วย 3 ปัจจัย ได้แก่ องค์ประกอบของทะลาย องค์ประกอบผล และความสุกของผลในทะลาย ที่สามารถมีผลต่อเปอร์เซ็นต์น้ำมันทั้งสิ้น ปาล์มน้ำมันที่นิยมปลูกสำหรับการค้าโดยทั่วไปมี 3 ลักษณะ ได้แก่ 1) “Virescens” ลักษณะนี้จะมีสีเขียวเมื่อผลดิบและเปลี่ยนเป็นสีส้มเมื่อผลสุก 2) “Nigrescens” ลักษณะนี้จะมีสีดำปลายผลและมีสีงาช้างที่ขั้วผลเมื่อผลดิบ และเปลี่ยนเป็นสีแดงเมื่อผลสุก ดังแสดงในภาพประกอบที่ 2 และ 3) “Albescens” ลักษณะนี้ จะมีสีผิวเปลือกเป็นสีเหลืองซีดเมื่อผลสุก (ลักษณะนี้พบน้อยมาก) (ธีระพงศ์ จันทรนิยม, 2562)



ทะลายปาล์มสุก



ทะลายปาล์มไม่สุก



ทะลายปาล์มสุกมากเกินไป

ภาพประกอบ 2 ภาพแสดงตัวอย่างทะลายปาล์มน้ำมัน

ที่มา : (ประกาศกระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดมาตรฐานสินค้าเกษตร : ทะลายปาล์มน้ำมันตามพระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551, 2562)

ในขั้นตอนการเก็บเกี่ยวผลปาล์มน้ำมันมีความสำคัญอย่างยิ่ง เพราะระดับความสุกของปาล์มน้ำมันมีผลโดยตรงกับคุณภาพและปริมาณของน้ำมันปาล์มที่ผ่านกระบวนการสกัดแล้ว เนื่องจากปาล์มน้ำมันที่มีระดับความสุกพอดีนั้น เมื่อสกัดแล้วจะมีคุณภาพและปริมาณน้ำมันปาล์มสูง ในขณะที่เดียวกับปาล์มน้ำมันที่มีระดับไม่สุกหรือดิบ ระดับกึ่งสุกกึ่งดิบ ระดับสุกมากเกินไป ทะลายผิดปกติเมื่อสกัดแล้วจะมีคุณภาพและปริมาณน้ำมันปาล์มต่ำ จึงไม่เป็นที่ต้องการของโรงงานที่รับซื้อผลปาล์ม

ปัจจุบันในขั้นตอนการเก็บเกี่ยวหรือการคัดแยกคุณภาพผลปาล์มที่โรงงานสกัดน้ำมันปาล์ม เกษตรกรหรือผู้ที่เกี่ยวข้อง จะดำเนินการจำแนกระดับความสุกผลปาล์มน้ำมันสด โดยการประเมินด้วยสายตา ซึ่งการประเมินด้วยสายตามนุษย์ นั้น ทำให้เกิดความผิดพลาดได้ง่าย ด้วยปัจจัยต่าง ๆ เช่น เกษตรกรที่มีประสบการณ์ในการเก็บเกี่ยวน้อย สภาพแสง ระยะเวลาสูงของต้นปาล์ม เป็นต้น จึงอาจทำให้เกิดการสูญเสียรายได้ เพราะหากเก็บเกี่ยวผลปาล์มน้ำมันสดที่ไม่มีคุณภาพเช่น เกษตรกรเก็บเกี่ยวทะลายปาล์มน้ำมันที่ไม่สุกหรือดิบไปขาย อาจทำให้โรงงานสกัดน้ำมันปาล์มปฏิเสธการรับซื้อได้ เพราะระดับความสุกของผลปาล์มน้ำมัน มีผลต่อคุณภาพน้ำมันปาล์มที่สกัดได้นั่นเอง ดังนั้น เกษตรกรควรต้องให้ความสำคัญในขั้นตอนการเก็บเกี่ยวผลปาล์มน้ำมันสดเป็นอย่างยิ่ง

จากงานวิจัยต่าง ๆ ทั้งในอดีตและปัจจุบัน ที่เกี่ยวกับการจำแนกระดับความสุขของปาล์มน้ำมันสด พบว่ามีการนำเสนอวิธีการที่ต่างกันอย่างหลายวิธี และวิธีที่ได้รับความนิยมมากที่สุดคือการใช้เทคนิคการมองเห็นด้วยคอมพิวเตอร์ (Computer vision) เพราะการจำแนกระดับความสุขของปาล์มน้ำมันสดนั้น สามารถสังเกตได้จากสีของเปลือกผิวด้านนอก โดยแต่ละระดับความสุขจะมีสีผิวเปลือกนอกที่ต่างกันไป และหนึ่งในอัลกอริทึมที่ใช้ในเทคนิค Computer vision คือโครงข่ายประสาทเทียมแบบคอนโวลูชัน Convolution Neural Network (CNN) โดยจากการทบทวนงานวิจัยพบว่าเทคนิค Computer vision ได้พิสูจน์ให้เห็นว่ามีประสิทธิภาพในการจำแนกความสุขของผลปาล์มน้ำมันสดและมีความแม่นยำสูงเมื่อเทียบกับเทคนิคอื่น ๆ ทั้งนี้ แบบจำลองที่นิยมใช้และมีความแม่นยำในการจำแนกสูง ได้แก่ แบบจำลองการตรวจจับวัตถุ (Object detection model) ซึ่งเป็นแบบจำลองที่สามารถปรับปรุงการตรวจจับและจำแนกระดับความสุขของผลปาล์มน้ำมันสด ณ สถานที่จริงแบบเรียลไทม์ได้ในอนาคต ที่สามารถช่วยให้เกษตรกรหรือผู้ที่เกี่ยวข้องสามารถเก็บเกี่ยวผลปาล์มน้ำมันสด ได้อย่างถูกต้องในเวลาที่เหมาะสมอีกด้วย

จากการศึกษาปัญหาในการจำแนกระดับความสุขของผลปาล์มน้ำมันสด รวมทั้งทฤษฎี และงานวิจัยที่เกี่ยวข้อง ผู้วิจัยจึงได้นำเสนอบทความวิจัย “ การจำแนกความสุขของปาล์มน้ำมันสดโดยใช้การเรียนรู้เชิงลึก ” ที่สามารถจำแนกระดับความสุขของผลปาล์มน้ำมันได้อย่างแม่นยำ และเพื่อเป็นการศึกษาแบบจำลองที่สามารถพัฒนาไปสู่การใช้งานแบบเรียลไทม์ได้ในสถานการณ์จริงในอนาคต และเพื่อเป็นการช่วยเหลือให้เกษตรกร หรือผู้ที่ประกอบอุตสาหกรรมปาล์มน้ำมัน สามารถจำแนกระดับความสุขของผลปาล์มน้ำมันสดได้ถูกต้องและแม่นยำ

1.2 วัตถุประสงค์ของงานวิจัย

1. เพื่อศึกษาปัญหาและวิธีการที่ใช้ในการจำแนกระดับความสุขของผลปาล์มน้ำมันสดจากงานวิจัยในอดีต
2. เพื่อค้นหาวิธีการจำแนกระดับความสุขของผลปาล์มน้ำมันสดจากงานวิจัยในอดีต
3. เพื่อนำเสนอวิธีการจำแนกระดับความสุขของผลปาล์มน้ำมันสดโดยใช้การเรียนรู้เชิงลึก จากภาพถ่ายผลปาล์มน้ำมัน

1.3 ขอบเขต และกิจกรรมการดำเนินงาน

งานวิจัยนี้มีเป้าหมายหลักในการทดสอบและเปรียบเทียบประสิทธิภาพในการจำแนก ระดับความสุกของผลปาล์มน้ำมันสด ด้วยแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ทั้งนี้ แบบจำลองที่ใช้ในการทดลองต้องมีคุณสมบัติที่สามารถพัฒนาไปสู่การใช้งานได้แบบ เรียลไทม์ได้ เพื่อความเหมาะสมกับการใช้งานในสถานการณ์จริง ดังนั้น งานวิจัยนี้จึงได้กำหนด ขอบเขตและกิจกรรมการดำเนินงาน ดังนี้

1. ศึกษาวิธีการที่ใช้ในการจำแนก ระดับความสุกของผลปาล์มน้ำมันสด
2. ค้นหาและเก็บรวบรวมข้อมูลภาพ เพื่อนำมาใช้ในการพัฒนาแบบจำลองสำหรับการจำแนก ระดับความสุกของผลปาล์มน้ำมันสด
3. ทดสอบแบบจำลองการที่สามารถใช้จำแนก ระดับความสุกของทะเลาะปาล์ม น้ำมันสด โดยเขียนบนโปรแกรม Google Collaboratory ด้วยภาษา Python ด้วยแบบจำลองที่มี หลักการโครงข่ายประสาทเทียมในการฝึกฝนรู้จำด้วยชุดข้อมูลที่เก็บรวบรวมได้ เพื่อให้แบบจำลอง สามารถจำแนก ระดับความสุกของผลปาล์มน้ำมันสดได้แม่นยำขึ้นตามที่กำหนด
4. ประเมินประสิทธิภาพแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันด้วย ข้อมูลภาพที่ใช้ในการทดสอบ
5. วิเคราะห์และอภิปรายผลการทดสอบการจำแนก ระดับความสุกของผลปาล์ม น้ำมันสด ของแบบจำลองต่าง ๆ ที่ใช้ในการทดลอง

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้รับผลการทดลองการจำแนก ระดับความสุกของผลปาล์มน้ำมัน พร้อมทั้ง ข้อพิจารณาในการนำเทคนิค Computer vision หรือหลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน มาประยุกต์ใช้ในการจำแนก ระดับความสุกของผลปาล์มน้ำมันสด
2. ได้รับความรู้ความเข้าใจในการเกี่ยวกับการจำแนก ระดับความสุกของผลปาล์ม น้ำมันด้วยเทคนิค Computer vision เพื่อสามารถพัฒนาแบบจำลองอื่น ๆ ต่อไปในอนาคต
3. ได้รับแนวทางในการจำแนก ระดับความสุกของผลปาล์มน้ำมัน ด้วยระบบ คอมพิวเตอร์ เพื่อนำไปใช้ในการช่วยเหลือเกษตรกรที่ปลูกปาล์มน้ำมัน

บทที่ 2

ทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง

สำหรับการศึกษางานวิจัยในครั้งนี้ ผู้วิจัยได้ทำการศึกษาผลงานวิจัยและทฤษฎีที่เกี่ยวข้องกับการจำแนกระดับความสุกของปาล์มน้ำมันสด และการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง โดยนำเสนอหัวข้อ ดังนี้

1. การจำแนกระดับความสุกของปาล์มน้ำมันสด
2. การตรวจจับทะลายปาล์มน้ำมันสด
3. การทบทวนงานวิจัยเกี่ยวกับการจำแนกระดับความสุกทะลายปาล์มน้ำมัน
4. แบบจำลองการตรวจจับวัตถุ (Object Detection Model)
5. You Only Look Once (YOLO)

2.1 การจำแนกระดับความสุกของปาล์มน้ำมันสด

2.1.1 งานวิจัยเรื่อง Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network (Ibrahim et al., 2018)

งานวิจัยนี้มีการศึกษาและใช้ CNN สำหรับการจำแนกระดับความสุกของปาล์ม น้ำมันสด โดยผู้วิจัยชี้แจงว่า CNN ได้กลายเป็นเทคนิคที่ทันสมัยในด้านการมองเห็นของ คอมพิวเตอร์ โดยเฉพาะอย่างยิ่งในการจดจำวัตถุได้อย่างแม่นยำ และแม้ว่า CNN ไม่มีความ จำเป็นในการแยกคุณลักษณะ (Feature extraction) แต่มีข้อจำกัดคือ ต้องการข้อมูลในการ ฝึกอบรมแบบจำลองจำนวนมาก ดังนั้น เพื่อลดข้อจำกัดดังกล่าว ผู้วิจัยได้ใช้แบบจำลอง CNN ที่ ผ่านการฝึกอบรมล่วงหน้า (Pre-trained CNN model) ด้วยการเรียนรู้แบบถ่ายโอน (Transfer Learning) โดยทำการเปรียบเทียบประสิทธิภาพในการจำแนกระดับความสุกของปาล์ม น้ำมันสด โดยแบ่งออกเป็น 4 ระดับ ได้แก่ ดิบ กึ่งสุกกึ่งดิบ สุกพอดี และสุกเกินไป ด้วยวิธีการต่าง ๆ ดังนี้

- 1) Handcrafted feature and classifier ได้แก่ Color moments feature, Fast Retina Keypoint (FREAK) binary feature และ Histogram of Oriented Gradient (HOG) จำแนกโดยใช้วิธีการ Support Vector Machine (SVM) Classifier
- 2) CNN
- 3) Pre-trained CNN (AlexNet)

ในการจัดเตรียมชุดข้อมูล ผู้วิจัยได้สร้างชุดข้อมูลภาพด้วยตัวเอง โดยใช้ภาพทะเลาะปาล์มน้ำมันทั้งหมดจำนวน 120 ภาพ แบ่งออกเป็น 30 ภาพ สำหรับแต่ละระดับความสุก โดยผู้วิจัยเชื่อว่าภาพจำนวน 120 ภาพ เพียงพอที่จะให้ผลลัพธ์ที่ดีสำหรับงานวิจัยนี้ ภาพเหล่านี้ได้ถูกถ่ายในช่วงกลางวัน ไม่มีการตัดกรอบ และไม่มีการตัดวัตถุที่ไม่ต้องการออก เช่น ใบไม้ และภาพพื้นหลังอื่น ๆ ดังภาพประกอบที่ 3



a) สุกพอดี

b) กิ่งสุกกิ่งดิบ

c) สุกเกินไป

d) ดิบ

ภาพประกอบ 3 ตัวอย่างภาพทะเลาะปาล์มน้ำมัน แบ่งออกเป็น 4 ระดับ ได้แก่ a) สุกพอดี b) กิ่งสุกกิ่งดิบ c) สุกเกินไป และ d) ดิบ

ที่ ม า : Ibrahim et al. (2018). Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network

การทดลองนี้ดำเนินการโดยใช้ Matlab 2017a และภาพที่ใช้ในการทำ Handcrafted ได้ถูกปรับลดให้มีขนาดเล็กลงเป็นขนาด 100x100 pixels เนื่องจากข้อจำกัดของหน่วยความจำ ส่วนวิธีการ HOG และ FREAK ภาพสีจะถูกแปลงเป็นระดับสีเทาก่อนกระบวนการแยกคุณลักษณะ ผลลัพธ์ของคุณลักษณะเหล่านี้เป็นขนาดของเวกเตอร์ ดังนี้ HOG มีขนาดเท่ากับ 900 ในขณะที่ FREAK มีขนาดเท่ากับ 64 และ Color moment มีขนาดเท่ากับ 9 โดยที่แต่ละแถวแสดงเวกเตอร์ของภาพ จากนั้นเวกเตอร์จากแต่ละคุณลักษณะถูกนำเข้าสู่ SVM สำหรับการจำแนกระดับความสุก โดยผู้วิจัยแบ่งข้อมูลสำหรับการฝึกฝนแบบจำลองจำนวน 80 เปอร์เซ็นต์ และข้อมูลสำหรับการทดสอบจำนวน 20 เปอร์เซ็นต์ สำหรับการทดลองด้วย CNN และ AlexNet ภาพจะถูกลดขนาดลง โดย CNN เหลือขนาดเท่ากับ 28x28 pixels และ AlexNet เหลือขนาดเท่ากับ 227x227 pixels

ตาราง 1 แสดงประสิทธิภาพการจำแนกระดับความสุกของผลปาล์มน้ำมันด้วย CNN

ขนาดของ Conv Layers	ระยะห่างระหว่าง พิกเซล (Stride)	อัตราการเรียนรู้	เวลาที่ใช้ (s)	ค่าความแม่นยำ (Accuracy) %
9x40	3	0.001	2.376	0.77
5x20	3	0.001	1.857	0.92
5x20	3	0.0001	1.858	0.87
9x40 and 5x20	3	0.001	2.279	0.72
9x40 and 5x20	2	0.001	2.32	0.82
9x40 and 5x20	2	0.001	3.402	0.92

ที่ ม ๑ : Ibrahim et al. (2018). Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network

จากตารางที่ 1 แสดงผลลัพธ์ของ CNN ด้วย 1 layers (1 convolutional layer, 1 Relu layer และ 1 pooling layer) และ 2 layers ตามที่ระบุในคอลัมน์แรก ความแม่นยำถูกคำนวณโดยการนับจำนวนภาพที่รู้จำได้ถูกต้องในข้อมูลการทดสอบ เวลาทั้งหมดคือเวลาที่นับเป็นวินาทีในการคำนวณกระบวนการทั้งหมด จะเห็นได้ว่า CNN ที่มีจำนวน 1 layer มีค่าผลลัพธ์ใกล้เคียงกับ 2 layers เท่ากับ 0.92 เปอร์เซ็นต์ แต่เวลาประมวลผลเพิ่มขึ้นเมื่อจำนวน layers เพิ่มขึ้น และสังเกตได้ว่าอัตราการเรียนรู้ที่เล็กลงจะลดเวลาในการประมวลผลได้อีกด้วย

ตาราง 2 แสดงประสิทธิภาพของการจำแนกระดับความสุกของผลปาล์มน้ำมันด้วย AlexNet

อัตราการเรียนรู้	เวลาที่ใช้ (s)	ค่าความแม่นยำ Accuracy (%)
0.001	84.47	1
0.0001	50.61	1

ที่ ม ๑ : (Ibrahim et al., 2018). Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network

จากตารางที่ 2 แสดงผลลัพธ์ของการจำแนกด้วย AlexNet เนื่องจาก AlexNet เป็นแบบจำลอง CNN ที่ถูกฝึกอบรมไว้ล่วงหน้า จึงไม่สามารถปรับแต่งพารามิเตอร์ได้มากเท่ากับแบบจำลอง CNN และจากผลการวิจัยแสดงให้เห็นว่าการจำแนกด้วย AlexNet มีค่าความแม่นยำเท่ากับ 1.00 เปอร์เซนต์ อย่างไรก็ตาม เนื่องจาก AlexNet มีจำนวน layers มากกว่าแบบจำลอง CNN ที่นำมาใช้ ดังนั้นระยะเวลาที่ใช้ประมวลผลก็จะนานกว่าแบบจำลอง CNN ด้วยเช่นกัน

ตาราง 3 แสดงประสิทธิภาพของการจำแนกระดับความสุกของปาล์มน้ำมันด้วย Handcrafted Features with SVM

คุณลักษณะ (Features)	เวลาที่ใช้ (s)	ค่าความแม่นยำ Accuracy (%)
HOG	78.59	0.75
FREAK	76.94	0.71
Color Moment	70.05	0.67

ที่มา : Ibrahim et al. (2018). Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network

จากตารางที่ 1 และตารางที่ 2 สังเกตได้ว่าการเพิ่มขึ้นของค่าความแม่นยำเกี่ยวกับการเพิ่มความลึกของเครือข่าย แต่ในขณะเดียวกันก็เป็นการเพิ่มระยะเวลาที่ใช้ประมวลผลด้วยจากผลลัพธ์ที่แสดงในตารางทั้ง 3 ตาราง แสดงให้เห็นว่าการใช้แบบจำลอง AlexNet ให้ผลลัพธ์ที่เป็นที่น่าพอใจได้ แม้ว่าข้อมูลที่ใช้สำหรับการฝึกฝนแบบจำลองมีจำนวนน้อยก็ตาม อาจเนื่องมาจาก AlexNet ได้รับการฝึกอบรมด้วยชุดข้อมูลจำนวนมากในกระบวนการฝึกอบรม และพารามิเตอร์การเรียนรู้สามารถถูกถ่ายถอดไปใช้สำหรับวัตถุประสงค์การเรียนรู้อื่น ที่มีจำนวนข้อมูลน้อย ผู้ใช้งานเพียงแค่นำภาพสี่เข้าไป และแบบจำลอง AlexNet จะสกัดคุณลักษณะและดำเนินการจำจำโดยอัตโนมัติ

จากตารางที่ 3 แสดงผลลัพธ์ที่ได้จากวิธีการ Handcrafted ด้วยการใช้ SVM Classifier โดยวิธี HOG จะสร้างขนาดเวกเตอร์ให้กับภาพแต่ละภาพมีขนาดเท่ากับ 900 ได้ค่าความแม่นยำสูงที่สุดเท่ากับ 0.75 เปอร์เซนต์ แต่ใช้ระยะเวลาในการประมวลผลนานกว่าวิธี FREAK และ Color moment แม้ว่าสีจะเป็นคุณลักษณะที่มีประโยชน์ที่สามารถอธิบายระดับความสุกของปาล์มน้ำมันสด แต่ผลลัพธ์ที่ได้จากคุณลักษณะทางสีมีประสิทธิภาพน้อยกว่า

คุณลักษณะอื่น เนื่องจากสีอาจได้รับผลกระทบจากแสงสว่าง ทั้งนี้ อาจปรับปรุงค่าความแม่นยำให้สูงขึ้นได้ ด้วยการตัดเอาเฉพาะภาพของทะลายปาล์มน้ำมันเท่านั้น ดังภาพประกอบที่ 4



ภาพประกอบ 4 ตัวอย่างภาพที่มีการตัดครอบให้เห็นเฉพาะทะลายปาล์มน้ำมัน

ที่มา : Ibrahim et al. (2018). Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network

จากการประเมินประสิทธิภาพของแบบจำลองในด้านความแม่นยำและระยะเวลาที่ใช้ในการประมวลผลพบว่า ประสิทธิภาพของแบบจำลอง CNN ขึ้นอยู่กับจำนวนข้อมูลที่ใช้ในการฝึกฝนแบบจำลอง และจำนวน layers โดยการประยุกต์ใช้แบบจำลอง CNN ต้องใช้ข้อมูลการฝึกสอนเป็นจำนวนมาก และจำนวน layers ที่ลึกขึ้นสามารถทำให้มีผลลัพธ์ที่ดีขึ้นด้วย แต่ในขณะเดียวกันก็ต้องใช้ระยะเวลาการประมวลผลนานขึ้น จะเห็นว่าแบบจำลอง AlexNet มีประสิทธิภาพในการจำแนกระดับความสุกของปาล์มน้ำมันได้ดีกว่าวิธีการอื่น ๆ เนื่องจากมีจำนวน layers มากกว่า ทำให้สามารถสกัดคุณลักษณะได้มากขึ้น แต่ใช้เวลาการประมวลผลค่อนข้างนาน

2.1.2 งานวิจัยเรื่อง Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach (Septiarini et al., 2020)

ผู้วิจัยได้ศึกษาและพัฒนาวิธีการจำแนกระดับความสุกของผลปาล์มน้ำมันสด โดยจำแนกออกเป็น 3 ระดับ ได้แก่ ดิบ สุกพอดี และกึ่งสุกกึ่งดิบ ซึ่งดำเนินการตามกระบวนการแยกคุณลักษณะในพื้นที่สี Lab color space (L^*a^*b) เพื่อสร้างคุณลักษณะ 4 ประการ ได้แก่ ค่าเฉลี่ยของแต่ละช่องสี ค่าเฉลี่ยของสีเทา และการจัดประเภทด้วยวิธีการวิเคราะห์การจำแนกเชิงเส้น (Linear Discriminant Analysis : LDA) โดยที่ L คือพิกัดแทนค่าความสว่างของสี โดยมีค่าตั้งแต่ 0 (ดำ) ถึง 100 (ขาว) a คือพิกัดแทนค่ามิติสีตรงข้ามแดง-เขียว โดยมีค่าลบแทนสีเขียว และค่าบวกแทนสีแดง และ b คือพิกัดแทนค่ามิติสีตรงข้ามเหลือง-น้ำเงิน โดยมีค่าลบแทนสีน้ำเงิน และค่าบวกแทนสีเหลือง

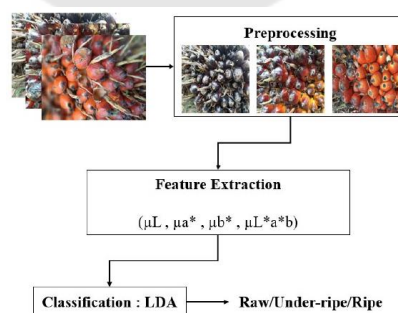
2.1.2.1 การเตรียมข้อมูลและวิธีการทดลอง (Materials and Methods)

ในการทดสอบผู้วิจัยใช้ชุดข้อมูลจำนวน 150 ภาพ ซึ่งแบ่งออกเป็นชุดข้อมูลสำหรับฝึกอบรวมแบบจำลองจำนวน 60 ภาพ (แบ่งเป็น 20 ภาพสำหรับแต่ละระดับความสุก) และชุดข้อมูลสำหรับทดสอบ จำนวน 90 ภาพ (แบ่งเป็น 30 ภาพสำหรับแต่ละระดับความสุก) ภาพแต่ละภาพจะมี labeled กำกับตามระดับความสุก โดยชุดข้อมูลรูปภาพได้ มาจากการถ่ายด้วยกล้องดิจิทัลจากสมาร์ทโฟน (Samsung A50) โดยมีระยะห่างระหว่างทะลายปาล์มน้ำมันและกล้องประมาณ 10 เซนติเมตร ผลลัพธ์ของภาพที่ได้มีขนาด 4032×3024 pixels และถูกบันทึกในรูปแบบ JPEG ดังภาพประกอบที่ 5 และมีกระบวนการในการจำแนกระดับความสุกของปาล์มน้ำมันสด ดังภาพประกอบที่ 6



ภาพประกอบ 5 แสดงตัวอย่างชุดข้อมูลภาพ

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach



ภาพประกอบ 6 กระบวนการในการจำแนกระดับความสุกของทะลายปาล์มน้ำมัน

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach


ผู้วิจัยแบ่งการทดสอบออกเป็น 2 ขั้นตอน ได้แก่ การฝึกอบรวมแบบจำลองและการทดสอบแบบจำลอง โดยทั้งสองกระบวนการประกอบด้วย 3 กระบวนการหลัก ได้แก่ 1) Preprocessing 2) Feature Extraction และ 3) Classification ดังภาพประกอบที่ 6

2.1.2.2 การประมวลผลล่วงหน้า (Preprocessing)

กระบวนการนี้จะทำการปรับขนาดภาพให้เล็กลง ซึ่งในการศึกษานี้ ภาพต้นฉบับมีขนาด 4032x3024 pixels ถูกปรับให้มีขนาดเป็น 500x500 pixels โดยการปรับขนาดรูปภาพมีจุดมุ่งหมายเพื่อลดระยะเวลาในการประมวลผล


2.1.2.3 การสกัดคุณสมบัติ (Feature Extraction)

กระบวนการนี้ดำเนินการเพื่อให้ได้ข้อมูลที่สำคัญโดยการแยกคุณลักษณะของรูปภาพ ดังนั้นจึงสามารถใช้แยกแยะระหว่างวัตถุหนึ่งกับอีกวัตถุหนึ่งได้ คุณลักษณะเหล่านี้ใช้เป็นพารามิเตอร์เพื่ออธิบายวัตถุ ค่าของคุณลักษณะเหล่านี้จะถูกใช้เป็นข้อมูลนำเข้าในกระบวนการจำแนกประเภท โดยระดับความสูงของทะเลาะปลายน้ำมันสามารถรับรู้ได้ง่ายการมองเห็น โดยพิจารณาจากสีผิวของผล และในการศึกษานี้ มีการใช้คุณลักษณะของสีใน Color Space ต่าง ๆ ได้แก่ 1) L^*a^*b 2) YCbCr 3) HSV 4) YIQ และ 5) RGB เพื่อปรับ Color Space ที่เหมาะสมสำหรับการทดลองต่อไป ผลลัพธ์ของการแปลงภาพเป็น Color Space แสดงให้เห็น ดังภาพประกอบที่ 7 – 11




ภาพประกอบ 7 ภาพแสดง Features Extraction in L^*a^*b Color Space

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach




ภาพประกอบ 8 ภาพแสดง The Features Extraction in YCbCr Color Space

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach




ภาพประกอบ 9 ภาพแสดง The features Extraction in HSV Color Space

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach



ภาพประกอบ 10 ภาพแสดง The Features Extraction in YIQ Color Space

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach



ภาพประกอบ 11 The features extraction in RGB color space

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach

คุณสมบัติที่ได้สำหรับแต่ละภาพประกอบด้วยคุณสมบัติ 4 ประการ ตัวอย่างผลการแยกคุณสมบัติในแต่ละคลาส (ดิบ กึ่งสุกกึ่งดิบ และสุกพอดี) และข้อมูลของคลาสจริงแสดงไว้ในตารางที่ 4

ตาราง 4 แสดงตัวอย่างผลการแยกคุณสมบัติในพื้นที่สี L*A*B

ROI image	L*A*B image	Class and color features
		ดิบ $\mu L = 1326.2$ $\mu a = 5.5$ $\mu b = 30.5$ $\mu L * a * b = 4025.8$
		กึ่งสุกกึ่งดิบ $\mu L = 1374.8$ $\mu a = 234.9$ $\mu b = 245.8$ $\mu L * a * b = 752.1$
		สุกพอดี $\mu L = 1324.8$ $\mu a = 511.7$ $\mu b = 530.1$ $\mu L * a * b = 806.3$

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach

2.1.2.4 การจำแนกประเภท (Classification)

กระบวนการนี้ประกอบด้วย 2 ขั้นตอน ได้แก่ การฝึกอบรมแบบจำลองและการทดสอบแบบจำลอง วัตถุประสงค์ของการฝึกอบรมแบบจำลองเพื่อวิเคราะห์ข้อมูลการฝึกอบรมเพื่อให้ได้กฎการจัดประเภท ขั้นตอนที่ 2 คือการทดสอบ ซึ่งในขั้นตอนนี้ ข้อมูลการทดสอบใช้เพื่อประเมินประสิทธิภาพของแบบจำลอง และทำการวัดประสิทธิภาพด้วยความแม่นยำของแบบจำลอง โดยในการศึกษานี้ ใช้วิธีการจำแนกประเภทด้วยอัลกอริทึม LDA ซึ่ง LDA เป็นหนึ่งในอัลกอริทึมยอดนิยมของ Machine learning โดย LDA ใช้เพื่อระบุตัวแปรที่แยกความแตกต่างของคลาสหนึ่งและอีกคลาสหนึ่ง ซึ่งมีคุณลักษณะเฉพาะ อัลกอริทึมนี้จัดอยู่ในประเภท Supervised Learning เนื่องจากอัลกอริทึมนี้ ดำเนินขั้นตอนการฝึกอบรมเพื่อสร้างพารามิเตอร์แบบจำลองที่จำเป็น แบบจำลองนี้ใช้เพื่อคาดการณ์ข้อมูลการทดสอบและจัดอยู่ในประเภทเฉพาะ อัลกอริทึมนี้มีจุดประสงค์เพื่อจำแนกวัตถุออกเป็น 2 คลาส หรือหลายๆ คลาสได้

2.1.2.5 ผลการทดลอง (Testing Model)

ผู้วิจัยได้ทำการทดลองหลายครั้งโดยทำการแยกคุณลักษณะใน Color Space ต่างๆ ด้วย HSV YCbCr YIQ RGB และ L^*a^*b ซึ่งคุณลักษณะเหล่านี้จะถูกใช้เป็นอินพุตสำหรับอัลกอริทึม LDA ค่าความแม่นยำได้มาจาก Color Space ทั้งหมดที่ทดลอง เพื่อให้ได้ผลลัพธ์ที่ดีที่สุดและปรับ Color Space ที่เหมาะสมที่สุด ที่จะใช้ในวิธีนี้ โดยผลการจำแนกประเภทด้วยอัลกอริทึม LDA โดยใช้คุณลักษณะที่สร้างขึ้นจาก Color Space ต่าง ๆ ดังรายละเอียดในตารางที่ 5

ตาราง 5 สรุปค่า Accuracy ของแต่ละวิธีการใน Color Space ต่าง ๆ

รูปภาพ	ค่าความแม่นยำ Accuracy (%)				
	HSV	YCbCr	YIQ	RGB	L^*c^*b
ดิบ	100	100	100	100	100
กิ่งสุกกิ่งดิบ	76.66	93.33	93.33	93.33	96.66
สุกพอดี	83.33	100	100	100	100
ทั้งหมด	86.66	97.77	97.77	97.77	98.88

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach

จากตารางที่ 5 แสดงประสิทธิภาพของวิธีการต่าง ๆ พบว่า HSV มีค่าความแม่นยำต่ำที่สุดเท่ากับ 86.66 เปอร์เซ็นต์ ในขณะที่ L^*a^*b มีค่าความแม่นยำสูงที่สุดเท่ากับ 98.88 เปอร์เซ็นต์ ด้วยผลลัพธ์นี้แสดงให้เห็นว่าค่าความแม่นยำที่ได้รับมีผลมาจากการเลือก Color Space ที่เหมาะสม จากภาพของทะเลาะปาล์มน้ำมันสดที่มีระดับผลดิบ (Raw) และผลสุกพอดี (Ripe) มีค่าความถูกต้อง 100 เปอร์เซ็นต์ ใน Color Space ต่าง ๆ ในขณะที่เดียวกัน การจัดประเภทผิดมักเกิดขึ้นกับภาพที่มีระดับผลกึ่งสุกกึ่งดิบ (Under-ripe) ซึ่งจะถูกจัดให้อยู่ในประเภทผลดิบ (Raw) ทั้งนี้ อาจเป็นผลมาจากสีของผลปาล์มน้ำมันไม่สม่ำเสมอ นอกจากนี้ แสดงผลการประเมิน Confusion Matrix Multiclass ดังแสดงในภาพประกอบที่ 12

		Actual Class			
		Raw	Under-ripe	Ripe	
Prediction Class	Raw	30 33.3%	1 1.1%	0 0.0%	96.8% 3.2%
	Under-ripe	0 0.0%	29 32.2%	0 0.0%	100% 0.0%
	Ripe	0 0.0%	0 0.0%	30 33.3%	100% 0.0%
		100% 0.0%	96.7% 3.3%	100% 0.0%	98.9% 1.1%
		Raw	Under-ripe	Ripe	

ภาพประกอบ 12 ภาพแสดง Confusion Matrix Multiclass of the Applied Method

ที่มา : Septiarini et al. (2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach

2.1.2.6 สรุปผลการทดลอง

งานวิจัยนี้ได้พัฒนาวิธีการจำแนกระดับความสุกของปาล์มน้ำมันสด โดยแบ่งออกเป็น 3 ระดับ ได้แก่ ดิบ กึ่งสุกกึ่งดิบ และสุกพอดี จากการใช้คุณลักษณะเฉลี่ย ของ L^*a^*b Color Space ประกอบกับการใช้อัลกอริทึม LDA โดยในการทดลองนี้ใช้ภาพทั้งหมดจำนวน 150 ภาพ ประกอบด้วยภาพสำหรับการฝึกอบรวมแบบจำลอง จำนวน 60 ภาพ และภาพสำหรับการทดสอบแบบจำลองจำนวน 90 ภาพ ผลการประเมินประสิทธิภาพทำได้ค่าความแม่นยำเท่ากับ 98.88 เปอร์เซ็นต์

2.1.3 งานวิจัยเรื่อง Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet (Herman et al., 2021)

ผู้วิจัยทำการเปรียบเทียบประสิทธิภาพในการจำแนกระดับความสุกของผลปาล์ม น้ำมันสด ด้วยแบบจำลอง AlexNet และแบบจำลอง DenseNet ที่มีจำนวน 121 layers โดยทั้ง 2 แบบจำลอง ถูกฝึกอบรมและทดสอบโดยใช้ชุดข้อมูลที่ประกอบด้วยภาพทะเลาะปาล์มน้ำมัน จำนวน 400 ภาพ ดังภาพประกอบที่ 13 แสดงตัวอย่างของชุดข้อมูลภาพ ซึ่งชุดข้อมูลภาพถูกแบ่ง ออกเป็น 7 ระดับความสุก และเป็นชุดข้อมูลแบบ Imbalance Data ดังรายละเอียดในตารางที่ 6 ทั้งนี้ มีการแบ่งข้อมูลออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลสำหรับการฝึกอบรมจำนวน 60 เปอร์เซ็นต์ ชุด ข้อมูลสำหรับการตรวจสอบความถูกต้องแบบจำลองจำนวน 20 เปอร์เซ็นต์ และชุดสำหรับทดสอบ จำนวน 20 เปอร์เซ็นต์ โดยแบบจำลองมีจำนวนรอบในการฝึกอบรม 50 epochs ด้วยการใช้ Stochastic Gradient Descent (SGD) มีอัตราการเรียนรู้ (Learning rate) เท่ากับ 0.001 และใช้ PyTorch ในการเขียนโค้ด



ภาพประกอบ 13 แสดงตัวอย่างของชุดข้อมูล

ที่ ม า : Herman et al. (2021). Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet

ตาราง 6 แสดงจำนวนชุดข้อมูลภาพในแต่ละระดับความสุกทะเลาะปาล์มน้ำมัน

หมวดหมู่	จำนวนภาพ
กำลังสุก	16
ดิบ	8
สุกเล็กน้อย	64

ตาราง 6 (ต่อ)

หมวดหมู่	จำนวนภาพ
เกือบสุก	16
สุกพอดี	96
สุกเต็มที่	168
สุกเกินไป	32

ที่มา : Herman et al. (2021). Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet

2.1.3.1 ผลการทดลอง

ตาราง 7 แสดงผลจากการทดลอง

Model	ค่า Accuracy	ค่า Precision	ค่า Recall	ค่า F1 Score
AlexNet	77%	78%	77%	77%
DenseNet	86%	87%	86%	86%

ที่มา : Herman et al. (2021). Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet

จากตารางที่ 7 แสดงผลลัพธ์จากการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ซึ่งในงานวิจัยนี้พบว่าแบบจำลอง DenseNet มีค่าความถูกต้องสูงกว่า แบบจำลอง AlexNet ถึงแม้ว่าชุดข้อมูลจะไม่สมดุลกันก็ตาม ซึ่งดูได้จากค่าของ F1 Score รวมทั้ง แบบจำลอง DenseNet ยังมีค่า Precision และค่า Recall แบบจำลอง AlexNet อีกด้วย

2.1.3.2 สรุปผลการทดลอง

จากผลการวิจัยนี้ พิสูจน์ได้ว่าอัลกอริทึมการเรียนรู้เชิงลึก ด้วยแบบจำลอง DenseNet ที่มีจำนวน 121 layers มีประสิทธิภาพในการจำแนกระดับระดับความสุกผลปาล์มน้ำมันสดได้ดีกว่าแบบจำลอง AlexNet แม้ว่าชุดข้อมูลภาพจะไม่สมดุลกัน โดยมีค่า Precision Recall และ F1 score ที่ดีกว่า เมื่อเปรียบเทียบกับแบบจำลอง AlexNet

2.1.4 งานวิจัยเรื่อง Oil Palm Fruit Ripeness Detection using Deep Learning

(Ashari et al., 2022)

งานวิจัยนี้ได้นำเสนอวิธีการจำแนกระดับความสุกของผลปาล์มน้ำมันสด โดยการใช้ภาพดิจิทัลและการประยุกต์ใช้อัลกอริทึมการเรียนรู้เชิงลึก (Deep learning) มีการแบ่งระดับความสุกออกเป็น 3 ระดับ ได้แก่ ดิบ สุกพอดี และเน่า ดังรายละเอียดในตารางที่ 8 โดยผู้วิจัยชี้แจงว่าสาเหตุที่เลือกใช้อัลกอริทึมการเรียนรู้เชิงลึกในการแก้ปัญหา เนื่องจากมีการศึกษามากมายและพิสูจน์แล้วว่าอัลกอริทึมการเรียนรู้เชิงลึกมีความแม่นยำสูง โดยผู้วิจัยเลือกใช้ CNN ซึ่งเป็นหนึ่งในวิธีการของ Deep learning ที่มีชื่อเสียงในการจัดหมวดหมู่ข้อมูลภาพได้เป็นอย่างดี

ตาราง 8 แสดงคำอธิบายระดับความสุกของปาล์มน้ำมัน

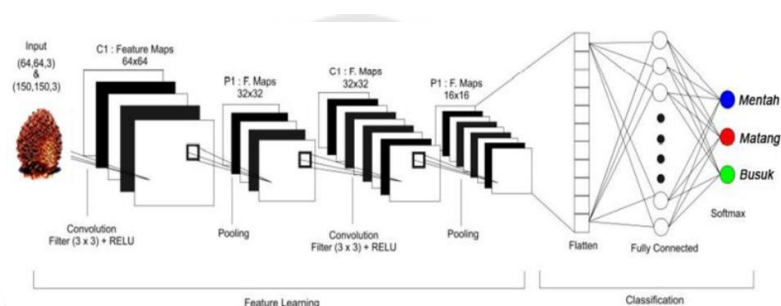
รูปภาพ	ระดับความสุก	คำอธิบาย
	ดิบ	ปาล์มดิบเป็นผลปาล์มน้ำมันประเภทที่ยังไม่พร้อมสำหรับการแปรรูป ลักษณะของผลคือ สีผิวยังเป็นสีดำ
	สุกพอดี	ปาล์มสุกเป็นผลปาล์มน้ำมันที่พร้อมสำหรับการแปรรูป ลักษณะของผลจะมีสีผิวเป็นสีแดงหรือสีส้ม
	เน่า	ปาล์มน้ำมันเน่า คือ ผลปาล์มน้ำมันประเภทหนึ่งที่สุกเข้าเกินไป ลักษณะของมันเป็นสีผิวสีน้ำตาลอมดำ

ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

2.1.4.1 การเตรียมข้อมูล (Data preparation)

ชุดข้อมูลประกอบด้วยภาพทะลายน้ำมันจำนวน 400 ภาพ แบ่งออกเป็นชุดข้อมูลสำหรับการฝึกอบรม 80 เปอร์เซ็นต์ และข้อมูลสำหรับการทดสอบ 20 เปอร์เซ็นต์ โดยภาพทะลายน้ำมันแต่ละภาพจะถูกเปลี่ยนและจัดเก็บด้วยขนาด 128x128 pixels มีขนาด 3 channels โดยมีขนาดรูปร่างอินพุตเท่ากับ 128x128x3 มีขนาด batch size เท่ากับ 16 และจำนวน epoch เท่ากับ 10 epoch หลังจากนั้นมีการทำ Augmentation

2.1.4.2 การออกแบบ CNN (CNN Design)



ภาพประกอบ 14 แสดง Flowchart Training

ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

จากภาพประกอบที่ 14 เริ่มต้นด้วยกระบวนการ Convolution แรก โดยใช้ Filter จำนวน 64 Filters Kernel มีขนาด 3x3 matrix Pooling Process เท่ากับ 2x2 และ Mask Shift มีขนาด 2 Steps จากนั้นในขั้นตอน Convolution ที่สอง ใช้ Filter จำนวน 32 Filters และ Kernel ขนาด 2x2 matrix จากนั้นดำเนินการแปลงรูปแบบการ Convolution ให้เป็นรูปแบบของ Vector ซึ่งเปลี่ยนรูปผลลัพธ์ของกระบวนการ Convolution จาก Matrix เป็น Vector และจะถูกส่งต่อไปยังกระบวนการจำแนก (Classification) โดยใช้ MLP (Multi-Layer Perceptron)

2.1.4.3 ทำการทดสอบแบบจำลอง (Model Testing)

การทดสอบแบบจำลองถูกดำเนินการเพื่อประเมินแบบจำลองที่ได้จาก CNN โดยใช้รูปภาพจำนวน 80 ภาพ แบ่งออกเป็น 26 ภาพ ต่อแต่ละระดับความสุก ในขั้นตอนนี้แบบจำลองจะถูกทดสอบด้วยภาพที่แตกต่างกัน เพื่อทดสอบว่าแบบจำลองได้มีประสิทธิภาพที่ดีในการจำแนกภาพหรือไม่ การประเมินแบบจำลองนี้จะใช้ Feature จาก Tensorflow คือ

model.evaluate และใช้เทคนิค Confusion Matrix ช่วยให้สามารถดูการประเมินผลของแบบจำลองได้อย่างละเอียดมากขึ้น ดังรายละเอียดในตารางที่ 9 เป็นการออกแบบ Confusion Matrix สำหรับงานวิจัยนี้

ตาราง 9 แสดง Confusion matrix

เมทริกซ์ (Matrix)		การทำนายหมวดหมู่		
		ดิบ	สุกพอดี	เน่า
หมวดหมู่จริง	ดิบ			
	สุกพอดี			
	เน่า			


ที่ ม ๑ : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

2.1.4.4 ทำการทดสอบรูปภาพ (Image Testing)

กระบวนการนี้ทำเพื่อนำแบบจำลองมาทดสอบใช้กับชุดข้อมูลภาพ ในกระบวนการนี้ มีขั้นตอนหลายขั้นตอนที่ต้องทำเพื่อให้ได้ค่าความแม่นยำของภาพ ขั้นตอนแรกคือการบ่อนพารามิเตอร์สำหรับข้อมูลภาพ จากนั้นกำหนดตัวแปรเพื่อดูผลลัพธ์ และกำหนดคำอธิบายของข้อมูลที่ต้องการ โดยทำการวิเคราะห์ข้อมูลก่อนที่จะดูผลลัพธ์การทดสอบ กระบวนการก่อนทดสอบนี้จะช่วยให้ข้อมูลมีโครงสร้างที่เป็นระเบียบมากขึ้น จากนั้นโหลดแบบจำลองที่สร้างไว้ก่อนหน้านี้ และบ่อนภาพที่ต้องการทดสอบ และท้ายที่สุดคือการทำนายภาพหรือผลลัพธ์ของกระบวนการทดสอบภาพ

2.2.4.5 ผลการทดลอง (Result)

ผู้วิจัยได้ทำการเตรียมข้อมูล โดยใช้เทคนิคการทำ Augmentation เพื่อให้ข้อมูลมีความหลากหลายมากขึ้น ด้วยวิธีการต่าง ๆ ได้แก่ การหมุนภาพขนาด 15 องศา การปรับขนาดภาพให้มีขนาดเท่ากับ 1/255 การเบียดเอียงภาพด้วยอัตราส่วน 0.2 การพลิกภาพแนวนอน และการเปลี่ยนตำแหน่งความกว้างและความสูงของภาพด้วยช่วงค่า 0.1 เป็นต้น ดังภาพประกอบที่ 15 โดยหลังจากที่กระบวนการ Augmentation เสร็จสิ้น ตัวแปรที่ได้ถูกสร้างไว้ก่อนหน้านี้จะถูกเรียกใช้ใหม่เพื่อดำเนินกระบวนการประมวลผลกับชุดข้อมูล และจากผลการฝึกอบรม จะได้แบบจำลองของสถาปัตยกรรมเครือข่าย CNN ที่ถูกสร้างขึ้น ดังแสดงในตารางที่ 10




ภาพประกอบ 15 แสดงตัวอย่าง Augmentation Process Results

ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

ตาราง 10 แสดง CNN Model Result

พารามิเตอร์	ขนาด	ค่า
Input	128*128*3	0
Conv2d_2	3*3*3+1*128	896
Batch_normalization_1	256+256	512
MaxPool_1	63*63*128	0
dropout_1	63*63*128	0
conv2d_2	3*3*128+1*64	73792
batch_normalization_2	128+128	256
MaxPool_2	30*30*64	0
dropout_2	61*61*64	0
conv2d_3	3*3*64+1*32	18464
MaxPool_3	14*14*32	0
dropout_3	14*14*32	0
flatten	6272	0
dense	6272*512+512	3211776
Dense output	512+1*3	1539
TOTAL		3.312.099

ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning



ภาพประกอบ 16 แสดง Training Result

ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

จากภาพประกอบที่ 16 มีตัวชี้วัดจำนวน 4 ตัวชี้วัด ได้แก่ 1) Training Loss 2) Training Accuracy 3) Validation Loss และ 4) Validation Accuracy โดยตัวชี้วัด Training Loss เป็นผลลัพธ์ที่ได้มาจากการฝึกอบรมแบบจำลอง และใช้ข้อมูลที่ไม่สามารถอ่านค่าได้ ซึ่งหากมีค่าน้อยยิ่งดี ในขณะที่ Training Accuracy เป็นค่าความแม่นยำที่ได้จากกระบวนการฝึกแบบจำลอง หากได้ค่าความแม่นยำที่สูงจะยิ่งดีต่อแบบจำลอง ส่วน Validation Loss เป็นค่าเปรียบเทียบที่มาจากกระบวนการฝึกแบบจำลอง หากค่า Validation Loss น้อยจะยิ่งดีต่อแบบจำลอง ในขณะที่ Validation Accuracy เป็นค่าเปรียบเทียบที่ได้จากกระบวนการฝึกแบบจำลอง หากค่าความแม่นยำการตรวจสอบที่สูงกว่าจะยิ่งดีต่อแบบจำลอง

ซึ่งในกระบวนการฝึกอบรมแบบจำลองนี้ มีค่าความแม่นยำ (Accuracy) ของแบบจำลองสูงถึง 0.98 และมีค่าสูญเสีย (Loss) เท่ากับ 0.04 โดยในกระบวนการฝึกอบรมนี้ใช้อัตราการเรียนรู้ (Learning rate) เท่ากับ 0.001 โดยมีขนาดของภาพที่ป้อนเข้าเป็นขนาด 64x64 pixels ระยะเวลาในการฝึกแบบจำลองที่ใช้เพื่อฝึกอบรมเท่ากับ 10 epochs เป็นเวลา 30 นาที จะเห็นได้ว่ายิ่งเพิ่มรอบการฝึกอบรม (epochs) จำนวนมาก เวลาที่ใช้ในการฝึกแบบจำลองยิ่งเพิ่มขึ้น ในขณะที่ ค่าความแม่นยำของการตรวจสอบข้อมูล (Validation) มีค่าถึงสูงถึง 0.92 และมีค่า loss เท่ากับ 0.21

ตาราง 11 แสดงผลลัพธ์ของ Confusion Matrix

เมทริกซ์ (Matrix)		การทำนายหมวดหมู่		
		ดิบ	สุกพอดี	เน่า
หมวดหมู่จริง	ดิบ	20	2	6
	สุกพอดี	2	23	2
	เน่า	6	1	19




ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

จากตารางที่ 11 แสดงผลการทำนายแบบจำลอง โดยแบบจำลองสามารถทำนายถูกต้องค่อนข้างมาก จากการใช้จำนวนตัวอย่างในการทดสอบทั้งหมด 81 รูปภาพ และได้ค่าความแม่นยำอยู่ที่ 76 เปอร์เซ็นต์ โดยค่าความแม่นยำหมายถึงระดับความถูกต้องระหว่างข้อมูลที่ร้องขอและคำตอบของระบบ และค่าผลลัพธ์ของ Recall เท่ากับ 0.76 ในขณะที่ค่า accuracy/f1-score มีความใกล้เคียงกันระหว่างค่าที่คาดการณ์ไว้กับค่าจริง และผลลัพธ์ของความแม่นยำ f1-score มีค่าเท่ากับ 0.76

ตาราง 12 ผลการทดลอง (Test Result)

รูปภาพ	ค่าความแม่นยำ Accuracy (%)	หมวดหมู่
	0.9372	สุกพอดี
	0.9916	ดิบ
	0.4481	เน่า

ตาราง 12 (ต่อ)

รูปภาพ	ค่าความแม่นยำ Accuracy (%)	หมวดหมู่
	0.7787	สุกพอดี
	0.9576	ดิบ
	0.9752	เน่า

ที่มา : Ashari et al. (2022). Oil Palm Fruit Ripeness Detection using Deep Learning

จากตารางที่ 12 อธิบายได้ดังนี้ 1) การทดสอบภาพทะลายปาล์มน้ำมัน ที่มีระดับผลดิบ แบบมีพื้นหลัง ได้ค่าความแม่นยำเท่ากับ 0.9916 และภาพแบบไม่มีพื้นหลัง ได้ความแม่นยำเท่ากับ 0.9576 ซึ่งหมายความว่าไม่มีความแตกต่างกันมากในการทดสอบ 2) การทดสอบภาพทะลายปาล์มน้ำมันที่มีระดับผลสุกพอดีแบบมีพื้นหลัง ได้ความแม่นยำเท่ากับ 0.9372 และภาพแบบไม่มีพื้นหลัง ได้ความแม่นยำเท่ากับ 0.7787 ซึ่งพบว่ามีค่าความแตกต่างไม่มากนัก 3) การทดสอบภาพทะลายปาล์มน้ำมันที่มีระดับผลเน่าแบบมีพื้นหลัง ได้ความแม่นยำเท่ากับ 0.4481 และแบบไม่มีพื้นหลังได้ความแม่นยำเท่ากับ 0.9752 ซึ่งหมายความว่าในการทดสอบภาพผลปาล์มน้ำมันที่มีระดับผลเน่ามีความแตกต่างกันค่อนข้างมาก อาจเป็นเพราะว่าสีพื้นหลังของผลปาล์มน้ำมันที่เน่า มีสีที่แตกต่างกัน และเกือบจะเท่ากับสีของผลปาล์มน้ำมันที่เน่า

ผลสรุปจากงานวิจัยนี้พบว่าการจำแนกระดับความสุกของผลปาล์มน้ำมันโดยใช้ Deep Learning ได้ค่าความแม่นยำสูงถึง 98 เปอร์เซ็นต์ สำหรับกระบวนการฝึกอบรม และได้ค่าความแม่นยำเท่ากับ 76 เปอร์เซ็นต์ สำหรับกระบวนการทดสอบแบบจำลอง โดยผู้วิจัยชี้แจงว่าการ

ใช้อัลกอริทึม Convolutional Neural Network (CNN) สามารถจำแนกระดับความสุกของทะลายปาล์มน้ำมันได้เป็นอย่างดี

2.1.5 งานวิจัยเรื่อง Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch (Dambul et al., 2022)

ผู้วิจัยได้ทำการทดลองอัลกอริทึมสำหรับการตรวจจับวัตถุที่สามารถจำแนกระดับความสุกของผลปาล์มน้ำมันสด โดยมุ่งเน้นศึกษาเฉพาะอัลกอริทึมที่สามารถนำไปใช้กับอุปกรณ์เคลื่อนที่ได้ ซึ่งช่วยให้มนุษย์สามารถคัดแยกและเก็บเกี่ยวเฉพาะทะลายปาล์มน้ำมันที่สุกได้อย่างถูกต้องเท่านั้น การตรวจจับวัตถุที่ทดสอบได้แก่ 1) MobileNetV2 SSD 2) EfficientDet (Lite0 Lite1 Lite2) และ 3) YOLOv5 (YOLOv5n YOLOv5s YOLOv5m) ซึ่งอัลกอริทึมเหล่านี้ได้รับการออกแบบมาโดยเฉพาะสำหรับการใช้งานบนอุปกรณ์เคลื่อนที่ เช่น โทรศัพท์มือถือ และมีหน่วยความจำสูง โดยอัลกอริทึมทั้งหมดจะถูกทดสอบโดยใช้ชุดข้อมูลที่ประกอบด้วยทะลายปาล์มน้ำมัน ที่มีระดับความสุกที่แตกต่างกัน 4 ระดับ ซึ่งประสิทธิภาพและประสิทธิผลของแต่ละอัลกอริทึมจะถูกประเมินด้วยค่าต่างๆ เหล่านี้ ได้แก่ 1) Mean average precision 2) Recall 3) Precision และ 4) Training time

ทั้งนี้ ผู้วิจัยได้รวบรวมผลงานวิจัยอื่น ๆ ที่เกี่ยวข้องกับการจำแนกความสุกของทะลายปาล์มน้ำมันสดที่ผ่านมา ดังแสดงในตารางที่ 13

ตาราง 13 แสดงผลการจำแนกความสุกของทะลายปาล์มน้ำมันด้วยอัลกอริทึมต่าง ๆ

วิธีการ (อ้างอิง)	จำนวน หมวดหมู่	จำนวนรูปภาพ	ความแม่นยำ Accuracy (%)
CNN (Ibrahim et al., 2018)	4	120	92
CNN (Saleh & Liansitim, 2020)	2	628	97
CNN (Arulnathan et al., 2022)	3	126	96
AlexNet (Ibrahim et al., 2018)	4	120	100
AlexNet (Herman et al., 2020)	7	400	60
AlexNet (Wong et al., 2020)	2	200	85
AlexNet (Herman et al., 2021)	7	400	77
DenseNet (Herman et al., 2021)	7	400	89
DenseNet Sigmoid (Herman et al., 2020)	7	400	69
DenseNet and SE layer (Herman et al., 2020)	7	400	64

ตาราง 13 (ต่อ)

วิธีการ (อ้างอิง)	จำนวน หมวดหมู่	จำนวนรูปภาพ	ความแม่นยำ Accuracy (%)
ResAtt DenseNet (Herman et al., 2020)	7	400	69
Faster R-CNN (Prasetyo et al., 2020)	-	100	86
YOLOv3 (Selvam et al., 2021)	3	4500	mAP=0.91
YOLOv3 (Khamis, 2022)	3	229	mAP=0.84

ที่ ๑ : Dambul et al. (2022). Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch

1) งานวิจัยที่ใช้ CNN ในการจำแนกระดับความสุกของผลปาล์มน้ำมันสด มีค่าความแม่นยำสูงถึง 92 - 97 เปอร์เซ็นต์ อย่างไรก็ตาม แบบจำลองประกอบด้วย CNN ที่มี 1 - 2 layers เท่านั้น และไม่สามารถจับภาพที่มีคุณลักษณะระดับสูงได้ (High - Level Features) ได้ ซึ่งคุณลักษณะระดับต่ำ (Low - Level Features) ที่จับได้จะเป็นตัวแทนของผลปาล์มน้ำมันเพียงบางส่วนเท่านั้น ซึ่งสิ่งนี้ไม่แข็งแกร่งพอ และไม่น่าเชื่อถือได้สำหรับแอปพลิเคชันแบบเรียลไทม์


2) งานวิจัยที่ใช้แบบจำลองที่ได้รับการฝึกฝนล่วงหน้า (Pre - Trained Models) เช่น AlexNet และ DenseNet ก็ได้รับการพัฒนาด้วยเช่นกัน โดยแบบจำลอง AlexNet มีค่าความแม่นยำสูงถึง 100 เปอร์เซ็นต์ จากการทดลองของ (Ibrahim et al., 2018) อย่างไรก็ตาม ด้วยชุดข้อมูลที่ใหญ่กว่า ประสิทธิภาพของ AlexNet กลับลดลงเหลือ 60-85 เปอร์เซ็นต์ เท่านั้น

3) งานวิจัยที่ใช้ Faster R-CNN ซึ่งถูกพัฒนาขึ้นเพื่อตรวจจับและนับทะเลาะของปาล์มน้ำมัน มีความแม่นยำเท่ากับ 86 เปอร์เซ็นต์ แต่อย่างไรก็ตาม Faster R-CNN มีการประมวลผลช้าสำหรับแอปพลิเคชันแบบเรียลไทม์ และต้องใช้เวลาในการคำนวณมากขึ้น ส่วนแบบจำลอง YOLOv3 ก็ได้รับการพัฒนาสำหรับแบบจำลองแบบเรียลไทม์ โดย (Khamis, 2022; Selvam et al., 2021)

2.1.5.1 วิธีการทดลอง (การจัดเก็บชุดข้อมูล)

ผู้วิจัยได้ทำการถ่ายภาพทะเลาะปาล์มน้ำมันที่วางอยู่บนพื้นดินหลังจากผ่านกระบวนการเก็บเกี่ยวเรียบร้อยแล้ว ซึ่งชุดข้อมูลประกอบด้วยภาพผลปาล์มน้ำมันสดที่ถ่ายบนพื้นดินทั้งหมด โดยผู้วิจัยชี้แจงเพิ่มเติมว่า เนื่องจากสถานการณ์การระบาดของโรคโควิด - 19 ทำให้มีข้อจำกัดที่ไม่สามารถเข้าไปในสวนปาล์มน้ำมันได้ จึงทำให้ไม่สามารถถ่ายภาพหลากหลาย

รูปแบบได้ โดยในอนาคตผู้วิจัยจะรวมภาพจากสถานการณ์ต่าง ๆ เช่น ภาพที่มีแสงที่แตกต่างกัน ภาพจากความสูงของต้นที่ต่างกัน และตำแหน่งทะเลสาบที่ต่างกัน โดยชุดข้อมูลประกอบด้วยทะเลสาบ ปาล์มน้ำมัน ที่มีความสุกแตกต่างกัน 4 ระดับ ได้แก่ 1) สุกพอดี 2) ดิบ 3) กึ่งสุกกึ่งดิบ และ 4) สุกเกินไป ตัวอย่าง ดังภาพประกอบที่ 17 โดยจำนวนภาพที่รวบรวมได้มีทั้งหมดจำนวน 328 ภาพ แต่ผู้วิจัยเลือกใช้เพียงจำนวน 304 ภาพ สำหรับการฝึกอบรมแบบจำลองและการทดสอบ เพื่อให้ชุดข้อมูลมีความสมดุลกันในแต่ละคลาส โดยชุดข้อมูลถูกแบ่งออกเป็น 3 ชุด ได้แก่ 1) ชุดข้อมูลสำหรับการฝึกอบรม 2) ชุดข้อมูลสำหรับการตรวจสอบ และ 3) ชุดข้อมูลสำหรับการทดสอบ โดยมีการแบ่งอัตราส่วนออกเป็น ดังนี้ 70 เปอร์เซ็นต์ 20 เปอร์เซ็นต์ และ 10 เปอร์เซ็นต์ อีกทั้งใช้เทคนิคการทำ Augmentation เพื่อทำให้เกิดการเปลี่ยนแปลงในชุดข้อมูล เช่น การพลิกแนวนอน และแนวตั้ง การหมุน การครอบตัด การซูม และการตัดเฉือน เป็นต้น



a) ดิบ

b) กึ่งสุกกึ่งดิบ

c) สุกพอดี

d) สุกเกินไป

ภาพประกอบ 17 แสดงตัวอย่างชุดข้อมูล (a) ดิบ (unripe), (b) กึ่งสุกกึ่งดิบ (half-ripe), (c) สุกพอดี (ripe) และ (d) สุกเกินไป (over-ripe bunch)

ที่ ม ๑ : Dambul et al. (2022). Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch

2.1.5.2 ผลการทดลอง

แบ่งการทดลองออกเป็น 3 อัลกอริทึม หลักๆ ดังนี้ 1) MobileNetV2 SSD 2) EfficientDet-lite และ 3) YOLOv5

1) แบบจำลอง YOLOv5 ได้รับการฝึกอบรมจำนวน 300 epochs ด้วยขนาด batch size เท่ากับ 16 และภาพมีขนาด 640 pixels โดย Hyperparameters และ Weights ที่ใช้

สำหรับการฝึกอบรม เป็น Weight ที่ได้จากแบบจำลองที่ได้รับการฝึกอบรมล่วงหน้า (Pre-Trained Model) ด้วยชุดข้อมูล COCO (Common Object in Context) โดยการใช้ Pytorch

2) แบบจำลอง EfficientNet-lite0 EfficientNet-lite1 EfficientNet-lite2 และแบบจำลอง MobileNetV2 SSD ได้รับการฝึกโดยใช้ TensorFlow backend

ตาราง 14 ผลการเปรียบเทียบ Object detection models

แบบจำลอง	ค่า mApal	เวลาที่ใช้ฝึกฝน (min)	ค่า COCO mAP	จำนวนพารามิเตอร์ (million)
MobileNetv2 SSD	0.478	-	0.222	-
EfficientDet-lite0	0.743	65	0.264	3.2
EfficientDet-lite1	0.803	100	0.315	4.2
EfficientDet-lite2	0.812	140	0.351	5.3
Yolov5n	0.781	43	0.457	1.9
Yolov5s	0.832	90	0.568	7.2
Yolov5m	0.842	235	0.641	21.2

ที่มา : Dambul et al. (2022). Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch

จากตารางที่ 14 พบว่า แบบจำลอง YOLOv5n เป็นรุ่นที่เล็กที่สุดของแบบจำลอง YOLOv5 ในแง่ของจำนวนพารามิเตอร์ โดยจากงานวิจัยใช้ระยะเวลาการฝึกอบรมเร็วที่สุดจำนวน 43 นาที ตามด้วยแบบจำลอง YOLOv5s ใช้ระยะเวลาในการฝึกอบรมจำนวน 90 นาที และแบบจำลอง YOLOv5m ใช้ระยะเวลาในการฝึกอบรมนานที่สุดจำนวน 235 นาที ผู้วิจัยชี้แจงว่าสาเหตุที่ทำให้ YOLOv5m ใช้ระยะเวลาในการฝึกอบรมนานที่สุด เพราะว่าสามารถเรียนรู้ได้ดีกว่าแบบจำลอง YOLOv5n และ YOLOv5s โดยพารามิเตอร์ของความลึกและความกว้างส่งผลต่อขนาดของแบบจำลอง ซึ่งแบบจำลองที่มีระดับความลึกมากกว่าจะสามารถแยกคุณลักษณะได้ดีกว่า ก็จะมีจำนวนพารามิเตอร์ และระยะเวลาการฝึกอบรมก็จะเพิ่มขึ้นด้วยเช่นกัน

ด้วยการประเมินผลด้วยค่าความแม่นยำเฉลี่ย (mAP) ความเร็วในการฝึกอบรม และขนาดของแบบจำลอง จะเห็นได้ว่าประสิทธิภาพของแบบจำลอง EfficientDet-lite มีประสิทธิภาพเป็นอันดับสองรองจากแบบจำลอง YOLOv5 และตามด้วย MobileNetV2 SSD

แบบจำลอง EfficientDet-lite มีขนาดแบบจำลองต่างๆ คล้ายกับ YOLOv5 ตั้งแต่ EfficientDet-lite0 ถึง EfficientDet-lite2 โดยที่ EfficientDet lite2 แสดงค่า mAP ที่สูงกว่า แต่ใช้ระยะเวลาในการฝึกอบรมานขึ้น รวมทั้งพารามิเตอร์ที่มากขึ้นและขนาดแบบจำลองที่ใหญ่ขึ้น ส่วน YOLOv5 ได้รับการออกแบบมาเพื่อให้่ายต่อการใช้งาน และสามารถปรับเปลี่ยนโครงสร้าง layers และพารามิเตอร์ต่างๆ ได้อย่างง่ายดาย จากตารางที่ 14 พบว่าแบบจำลอง YOLOv5 มีประสิทธิภาพเหนือกว่าแบบจำลอง EfficientDet ในแง่ของ mAP

2.1.5.3 สรุปผลการทดลอง

ประสิทธิภาพของอัลกอริทึมการตรวจจับวัตถุ 3 อัลกอริทึม ได้แก่ MobileNetV2 SSD EfficientDet และ YOLOv5 ได้ถูกจำลองขึ้นโดยใช้สถาปัตยกรรมที่แตกต่างกันเพื่อจำแนกระดับความสุกของทะลายปาล์มน้ำมัน สามารถสรุปผลในงานวิจัยได้ดังนี้

- 1) YOLOv5 ได้รับการออกแบบมาสำหรับแอปพลิเคชันแบบเรียลไทม์เป็นหลัก
- 2) EfficientDet เป็นเครื่องตรวจจับวัตถุที่แข็งแกร่ง แต่ประสิทธิภาพยังไม่เทียบเท่ากับ YOLOv5
- 3) MobileNetV2 SSD ใช้ MobileNet ซึ่งออกแบบมาสำหรับแอปพลิเคชันมือถือ แต่ประสิทธิภาพยังไม่ดีนัก เมื่อเทียบกับโมเดลอื่นๆ

โดยสรุป YOLOv5m มีค่าเฉลี่ยความแม่นยำเท่ากับ 0.842 (0.5 :0.95) ซึ่งเป็นแบบจำลองที่มีประสิทธิภาพดีที่สุดในการตรวจจับวัตถุ สำหรับการประยุกต์ใช้ในการจำแนกความทะลายปาล์มน้ำมัน

2.1.6 งานวิจัยเรื่อง Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method (Khamis et al., 2022)

ในงานวิจัยนี้ได้นำเสนอการจำแนกระดับความสุกของผลปาล์มน้ำมันสดโดยใช้เทคนิคการมองเห็นด้วยคอมพิวเตอร์ (Computer Vision) ด้วยแบบจำลอง ResNet50 และแบบจำลองการตรวจจับวัตถุ YOLOv3

2.1.6.1 ลักษณะชุดข้อมูล

ผู้วิจัยได้ใช้ชุดข้อมูลภาพที่รวบรวมได้จากสวนปาล์มน้ำมัน โดยเก็บตัวอย่างภาพทะลายปาล์มน้ำมันจำนวน 299 ภาพ ชุดข้อมูลภาพถูกแบ่งออกเป็น 3 ระดับได้แก่ 1) สุกพอดี จำนวน 100 ภาพ 2) สุกเกินไป จำนวน 100 และ 3) ดิบ จำนวน 99 ภาพ โดยแต่ละภาพมีขนาดเท่ากับ 757x568 pixels

สำหรับการเตรียมข้อมูลเพื่อฝึกแบบจำลองระหว่าง ResNet50 และ YOLOv3 จะมีความแตกต่างกันเล็กน้อย โดยแบบจำลอง ResNet50 รูปภาพจะถูกจัดเรียงในโฟลเดอร์ต่าง ๆ ตามหมวดหมู่ของแต่ละคลาสเช่น สุก สุกเกินไป และดิบ เป็นต้น ในขณะที่แบบจำลอง YOLOv3 ตำแหน่งของวัตถุจะต้องมี labeled กำกับ ซึ่งรูปภาพถูก labeled ด้วย ClassifAI ซึ่งเป็นแพลตฟอร์มคำอธิบายประกอบข้อมูลแบบ Open-Source

2.1.6.2 ResNet50

ResNet50 หรือที่รู้จักในชื่อ Residual Neural Network เป็นแบบจำลอง Deep Learning ที่ได้รับการฝึกอบรมล่วงหน้าจากฐานข้อมูล ImageNet ที่สามารถจำแนกรูปภาพออกเป็นหมวดหมู่วัตถุ 1,000 หมวดหมู่ ผู้วิจัยได้ลดความละเอียดของภาพลงเหลือ 224x224 pixels เพื่อให้เหมาะสมกับหน่วยความจำ โดยมีรายละเอียดของไฮเปอร์พารามิเตอร์ที่ใช้ในแบบจำลองนี้ ดังรายละเอียดในตารางที่ 15

ตาราง 15 ไฮเปอร์พารามิเตอร์ของ RESNET50

ไฮเปอร์พารามิเตอร์	ค่า
ขนาดภาพ	224
ขนาดแบทช์	32
ช่อง (Channels)	3
อัตราการเรียนรู้	0.00001
จำนวนรอบการเรียนรู้	50

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

2.1.6.3 YOLOv3

YOLO มักใช้ในการตรวจจับวัตถุ แต่ในงานวิจัยนี้ YOLOv3 ได้รับการทดสอบเพื่อจำกัดพิกัดของวัตถุ (ทะลายปาล์มน้ำมัน) จากภาพ และจำแนกตามหมวดหมู่ที่ถูกต้อง แต่ละกรอบมีการสร้างค่าการคาดคะเน 5 ค่าได้แก่ (x, y, w, h, c) ซึ่งได้แก่ พิกัด (x, y) ของวัตถุที่ตรวจพบจากรูปภาพ ความกว้าง (w) และความสูง (h) ถูกทำนายโดยสัมพันธ์กับรูปภาพทั้งหมด และ

สุดท้ายคือระดับความเชื่อมั่น (c) โดยมีรายละเอียดของไฮเปอร์พารามิเตอร์ที่ใช้ในแบบจำลองนี้ ดังรายละเอียดในตารางที่ 16

ตาราง 16 ไฮเปอร์พารามิเตอร์ของ YOLOV3

ไฮเปอร์พารามิเตอร์	ค่า
ขนาดภาพ	416
ขนาดแบทช์	1
ช่อง (Channels)	3
อัตราการเรียนรู้	0.00001
จำนวนรอบการเรียนรู้	200

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

2.1.6.4 การฝึกอบรมแบบจำลอง

ในการประเมินประสิทธิภาพของแบบจำลอง การฝึกอบรม ResNet50 และ YOLOv3 ด้วยชุดข้อมูลจำนวน 299 ภาพ แบ่งออกเป็น 3 ส่วนดังนี้ 1) สำหรับการฝึกอบรม 2) สำหรับการตรวจสอบความถูกต้อง และ 3) สำหรับการทดสอบ ดังมีรายละเอียดในตารางที่ 17

ตาราง 17 ตัวอย่างภาพสำหรับการฝึกอบรม การทดสอบ และการตรวจสอบความถูกต้อง

ชุดข้อมูล	หมวดหมู่	จำนวนภาพ
สำหรับการฝึกอบรม	สุกเกินไป	68
	สุกพอดี	69
	ดิบ	72
สำหรับการตรวจสอบความถูกต้อง	สุกเกินไป	18
	สุกพอดี	19
	ดิบ	22

ตาราง 17 (ต่อ)

ชุดข้อมูล	หมวดหมู่	จำนวนภาพ
สำหรับการทดสอบ	สุกเกินไป	10
	สุกพอดี	8
	ดิบ	11

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

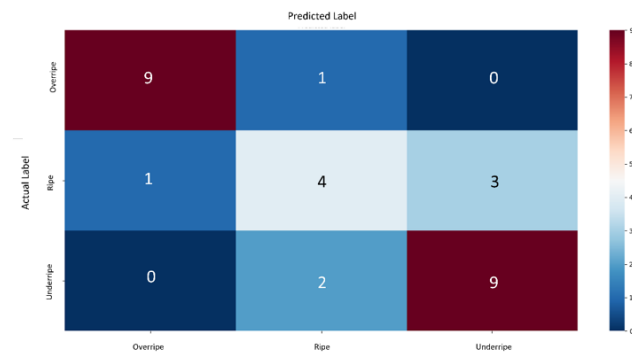
2.1.6.5 ผลลัพธ์และการวิเคราะห์

แบบจำลอง ResNet50 ได้รับการฝึกฝนเป็นเวลา 50 รอบการเรียนรู้โดยใช้ไฮเปอร์พารามิเตอร์ตามที่อธิบายไว้ในตารางที่ 18 และแสดงค่า Confusion Matrix ดังภาพประกอบที่ 18

ตาราง 18 ความถูกต้องแม่นยำของการจำแนกตามประเภทตัวอย่างการทดสอบด้วย ResNet50

หมวดหมู่	ค่า Precision	ค่า Recall	ค่า F1-Score
สุกเกินไป	0.90	0.90	0.90
สุกพอดี	0.57	0.50	0.53
ดิบ	0.75	0.82	0.78
ค่าความแม่นยำ (% Accuracy)			0.76

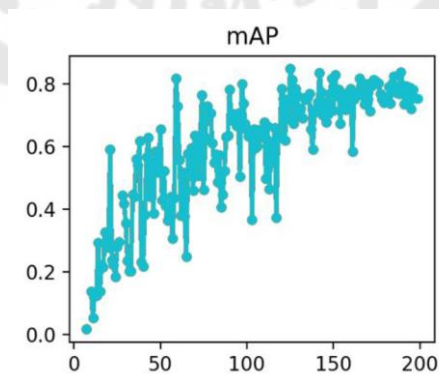
ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method



ภาพประกอบ 18 Confusion Matrix ของ ResNet50

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

จากการทดลองใช้แบบจำลอง ResNet50 มีค่าความแม่นยำของการจำแนกทะลายที่สุกเกินไปมีค่าเท่ากับ 90 เปอร์เซ็นต์ โดยจำแนกได้ถูกต้อง 9 ตัวอย่าง และจำแนกผิด 1 ตัวอย่าง และสามารถจำแนกประเภทของทะลายดิบ มีค่าความแม่นยำเท่ากับ 78 เปอร์เซ็นต์ ในขณะที่เดียวกันสำหรับทะลายสุก มีความแม่นยำเท่ากับ 53 เปอร์เซ็นต์ ทั้งนี้ ผู้วิจัยชี้แจงว่าการจัดประเภทที่ไม่ถูกต้องเกิดจากการรวมภาพพื้นหลังเป็นฟีเจอร์ในการฝึกแบบจำลอง เพื่อลดปัญหานี้ ผู้วิจัยจึงมีการนำเสนอแบบจำลองการตรวจจับวัตถุ YOLOv3 ในงานวิจัยนี้



ภาพประกอบ 19 Mean Average Precision (mAP) ของ YOLOv3

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

ตาราง 19 ค่าเฉลี่ยความแม่นยำ (mAP) ในการจำแนกระดับความสุกด้วย YOLOv3

หมวดหมู่	ค่าความเที่ยงตรงเฉลี่ย Mean Average Precision (mAP)
สุกเกินไป	0.92
สุกพอดี	0.73
กึ่งสุกกึ่งดิบ	0.89
ค่า mAP ที่ดีที่สุด	0.84

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

แบบจำลอง YOLOv3 จะใช้เฉพาะ Localized Region ในการฝึกแบบจำลองโดยไม่รวมพีเจอร์ที่ไม่ต้องการ แบบจำลองจะทำนายตำแหน่งของทะลายปาล์มน้ำมัน จากภาพและจำแนกความสุกตามหมวดหมู่ โดยคะแนนความเที่ยงตรงเฉลี่ย (mAP) ดังภาพประกอบที่ 19 และตารางประกอบที่ 19 คือค่าที่ใช้ประเมินความแม่นยำสำหรับแต่ละหมวดหมู่ โดยแบบจำลองได้รับการฝึกอบรมเป็นจำนวน 200 epochs และได้ค่า mAP ที่ดีที่สุดมีค่าเท่ากับ 84.70 เปอร์เซ็นต์ที่ epochs เท่ากับ 126 แสดงตัวอย่างดังภาพประกอบที่ 20



a) สุกเกินไป

mAP 97%

b) สุกพอดี

mAP 92%

c) ดิบ

mAP 81%

ภาพประกอบ 20 แสดงค่า mAP ของแต่ละระดับความสุกของทะลายปาล์มน้ำมัน

ที่มา : Khamis et al. (2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method

2.1.6.6 บทสรุป

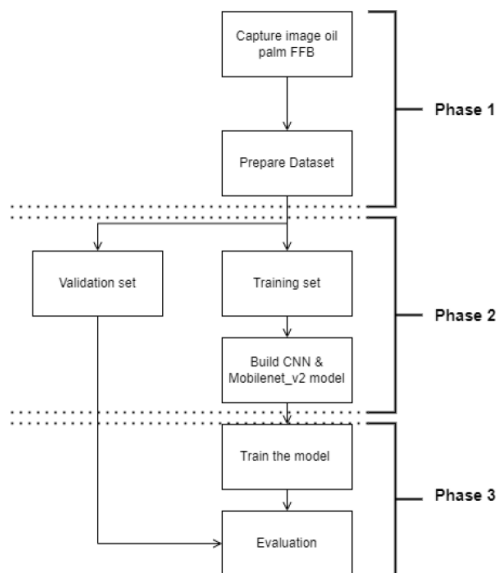
ใน Deep Learning มีแบบจำลองที่ใช้สำหรับการจำแนกรูปภาพหรือวัตถุ ได้แก่ แบบจำลองการจำแนกรูปภาพ (ResNet50) และแบบจำลองการตรวจจับวัตถุ (YOLOv3) ซึ่งความแตกต่างระหว่างแบบจำลองทั้งสองนี้คือ ในการจำแนกรูปภาพ (ResNet50) ใช้คุณสมบัติทั้งหมดในรูปภาพในการฝึกแบบจำลอง ในขณะที่การตรวจจับวัตถุ (YOLOv3) โดยพื้นฐานแล้วจะตรวจจับวัตถุจากรูปภาพและใช้ในการฝึกแบบจำลอง

แบบจำลอง YOLOv3 แสดงให้เห็นอย่างชัดเจนว่าการสกัดคุณลักษณะในระดับ Granular และ Regional โดยการแปลวัตุนั้น ส่งผลต่อความแม่นยำของการจำแนกประเภทจากการทดลองสำหรับการจำแนกความสุกของผลปาล์มน้ำมันสด มีค่าความแม่นยำเพิ่มขึ้น 2 เปอร์เซ็นต์ สำหรับประเภททะเลาะที่สุกเกินไป เพิ่มขึ้น 27 เปอร์เซ็นต์ สำหรับสำหรับประเภททะเลาะที่สุกพอดี และเพิ่มขึ้น 12 เปอร์เซ็นต์ สำหรับประเภททะเลาะดิบ ตามลำดับ สำหรับแผนในอนาคตผู้วิจัยชี้แจงว่าจะต้องพิจารณาการปรับแต่งไฮเปอร์พารามิเตอร์อย่างละเอียดถี่ถ้วน

2.1.7 งานวิจัยเรื่อง Comparison CNN and Mobilenet_v2 Model for Oil Palm FBB Ripeness Classification (Mohtar et al., 2022)

ในงานวิจัยนี้ได้ทดลองเปรียบเทียบประสิทธิภาพของ CNN และแบบจำลอง mobilenet_v2 เพื่อแก้ปัญหาการจำแนกความสุกของผลปาล์มน้ำมันสดตามหมวดหมู่ต่าง ๆ แบ่งออกเป็น 9 หมวดหมู่ ได้แก่ 1) ทะละาะดิบ 2) ทะละาะกึ่งสุกกึ่งดิบ 3) ทะละาะสุก 4) ทะละาะสุกมากเกินไป 5) ทะละาะที่มีผลร่วง 6) ทะละาะเน่า 7) ทะละาะสกปรก 8) ทะละาะเล็ก 9) ทะละาะที่มีความเสียหาย โดยมีแผนการดำเนินงานวิจัย ดังภาพประกอบที่ 21

2.1.7.1 วิธีการทดลอง (Methodology)



ภาพประกอบ 21 แสดงแผนการดำเนินงาน

ที่มา : Mohtar et al. (2022). Comparison CNN and Mobilenet_v2 Model for Oil Palm FFB Ripeness Classification

1) ระยะเวลาที่ 1

ในขั้นตอนนี้กล่าวถึงการรวบรวมและการเตรียมชุดข้อมูลก่อนสร้างแบบจำลองการเรียนรู้เชิงลึก กระบวนการหลักในระยะเวลาที่ 1 คือการถ่ายภาพทะเลาะลายปาล์มในสวนปาล์มน้ำมัน รูปภาพถูกถ่ายโดยใช้สมาร์ทโฟน Asus Zenfone 5z และจัดเก็บในรูปแบบ .jpeg การเก็บภาพทะเลาะลายปาล์มน้ำมันดำเนินการในช่วงเช้า เวลา 07.30-12.00 น. และช่วงเย็น จำนวนภาพปาล์มน้ำมันที่ถ่ายสำเร็จทั้งหมดจำนวน 1542 ภาพ แบ่งออกเป็น 9 หมวดหมู่ เมื่อเสร็จสิ้นกระบวนการรวบรวม รูปภาพจะถูกจัดเก็บไว้ในคอมพิวเตอร์โดยมีชื่อไฟล์เป็นชุดข้อมูล ไฟล์จะถูกอัปโหลดไปยัง Google Drive จากนั้นเชื่อมต่อ Google Drive กับแพลตฟอร์ม google Colab เพื่อดำเนินการต่อไป

2) ระยะเวลาที่ 2

เมื่อเตรียมชุดข้อมูลเสร็จแล้วจะแบ่งข้อมูลออกเป็น 2 ชุด คือชุดข้อมูลสำหรับการฝึกอบรวมแบบจำลองจำนวน 80 เปอร์เซ็นต์ และชุดข้อมูลสำหรับการตรวจสอบจำนวน 20

เปอร์เซ็นต์ หลังจากนั้น รูปภาพทั้งหมดจะถูกปรับให้มีขนาด 180x180x3 โดยมีขนาดกลุ่มเท่ากับ 32 หลังจากนั้นชุดข้อมูลจะถูกเข้ารหัส (Encoding) และ Dropout เพื่อป้องกันการเกิด Overfitting Effects

3) ระยะเวลาที่ 3

เป็นการฝึกอบรมแบบจำลองและการตรวจสอบความถูกต้องแบบจำลอง ในการทดลองผู้วิจัยใช้จำนวน epoch เท่ากับ 10 20 และ 30 epoch ตามลำดับ สำหรับกระบวนการฝึกอบรม แบบจำลองการเรียนรู้เชิงลึก การใช้ค่า epoch ที่แตกต่างกันเพื่อให้ได้ระดับประสิทธิภาพที่เหมาะสมที่สุด นอกจากนี้ การทดลองนี้ยังใช้ค่า epoch ที่แตกต่างกัน 3 ค่า เพื่อระบุว่าค่า epoch เหล่านี้สามารถทำให้แบบจำลอง CNN และ MobileNet_v2 บรรลุประสิทธิภาพสูงสุดในกระบวนการฝึกอบรมและการตรวจสอบได้หรือไม่ กระบวนการประเมินผล จะดำเนินการหลังจากการฝึกอบรมและกระบวนการตรวจสอบความถูกต้องของแบบจำลองเสร็จสิ้น เพื่อหาค่าความแม่นยำสำหรับของแบบจำลอง CNN และ Mobilenet_v2 ซึ่งในการคำนวณประสิทธิภาพความแม่นยำของแบบจำลอง โดยใช้ค่าความแม่นยำ (Accuracy)

2.1.7.2 ผลลัพธ์และการอภิปราย (Results and Discussion)

1) ผลลัพธ์จากการอ้างอิงด้วยค่า epochs

ตาราง 20 เปอร์เซ็นต์ของการฝึกอบรมและความถูกต้องของการตรวจสอบตามช่วงเวลา

แบบจำลอง	รอบการเรียนรู้	ความแม่นยำในการฝึกฝน	ความแม่นยำในการตรวจสอบ
CNN	10	59.92%	53.57%
Mobilenet_v2	10	56.29%	35.08%
CNN	20	77.47%	62.99%
Mobilenet_v2	20	68.68%	37.38%
CNN	30	89.95%	61.84%
Mobilenet_v2	30	67.19%	37.38%

ที่ มา : Mohtar et al. (2022). Comparison CNN and Mobilenet_v2 Model for Oil Palm FBB Ripeness Classification

จากตารางที่ 20 ค่าความแม่นยำในการฝึกอบรมและค่าความแม่นยำในการตรวจสอบความถูกต้องสำหรับแบบจำลองทั้ง 2 แบบจำลองนั้น แสดงให้เห็นว่ามีค่าสูงขึ้นตามค่า

ของ epochs ที่ใช้ ที่ค่า epochs เท่ากับ 30 แบบจำลองของ CNN มีความแม่นยำในระหว่างกระบวนการฝึกอบรมเท่า 89.95 เปอร์เซ็นต์ แต่ในกระบวนการตรวจสอบความถูกต้องค่าความแม่นยำมีค่าเท่ากับ 61.84 เปอร์เซ็นต์ ในขณะที่ความแม่นยำของ Mobilenet_v2 ค่าความแม่นยำในกระบวนการตรวจสอบความถูกต้อง มีค่าไม่เกิน 50 เปอร์เซ็นต์

2) ผลลัพธ์จากการสุ่มภาพจำนวน 30 ภาพ

หลังจากบันทึกผลความแม่นยำและการสูญเสียสำหรับแบบจำลอง CNN และ Mobilenet_v2 สำเร็จแล้ว แบบจำลองได้รับการทดสอบโดยใช้ภาพสุ่มจำนวน 30 ภาพ ที่ได้จากการสุ่มตรวจสอบเพื่อจำแนกทะลายปาล์มน้ำมันตามหมวดหมู่จริงของ จากการทดลองแสดงให้เห็นว่าแบบจำลองของ CNN ประสบความสำเร็จในการจำแนกทะลายปาล์มตามประเภทของภาพได้ดีกว่า ในขณะที่แบบจำลอง Mobilenet_v2 จัดจำแนกภาพทะลายปาล์มน้ำมันได้ถูกต้องเพียงจำนวน 7/30 ภาพ เท่านั้น

3) ผลลัพธ์สำหรับรูปภาพใหม่

ในส่วนนี้ผู้วิจัยได้ทดสอบการการจำแนกระดับความสุกของปาล์มน้ำมันสดและความแม่นยำของแบบจำลองทั้ง CNN และ Mobilenet_v2 กับรูปภาพใหม่ที่สุ่มจากเว็บไซต์ Google จากการทดลองพบว่าแบบจำลอง CNN มีค่าความแม่นยำในการจำแนกเพิ่มขึ้นเป็น 99.99 เปอร์เซ็นต์ และ สำหรับแบบจำลอง Mobilenet_v2 ไม่ประสบความสำเร็จในการจำแนกรูปภาพใหม่ โดยมีค่าความแม่นยำต่ำกว่า 20 เปอร์เซ็นต์ ดังแสดงในตารางที่ 21

ตาราง 21 การจัดหมวดหมู่ผลลัพธ์ของรูปภาพใหม่สำหรับ CNN และ Mobilenet_v2

แบบจำลอง	รอบการเรียนรู้	เปอร์เซ็นต์ความแม่นยำ	การจำแนก
CNN	10	89.73%	ถูก
Mobilenet_v2	10	14.38%	ผิด
CNN	20	99.65%	ถูก
Mobilenet_v2	20	18.28%	ผิด
CNN	30	99.99%	ถูก
Mobilenet_v2	30	14.89%	ผิด

ที่มา : Mohtar et al. (2022). Comparison CNN and Mobilenet_v2 Model for Oil Palm FBB Ripeness Classification

2.1.7.3 บทสรุป (Conclusion)

การศึกษานี้แสดงให้เห็นว่าแบบจำลอง CNN มีประสิทธิภาพดีกว่าแบบจำลอง Mobilenet_v2 ทั้งนี้ เพื่อสร้างการเรียนรู้เชิงลึกที่มีประสิทธิภาพดีขึ้น ชุดข้อมูลสำหรับการฝึกอบรมและการตรวจสอบความถูกต้องควรมีจำนวนภาพที่เท่ากัน เพื่อป้องกันการเกิด Overfitting

2.1.8 งานวิจัยเรื่อง Grading Oil Palm Fruit Bunch using Convolution Neural Network (Azman & Suriani, 2023)

ผู้วิจัยได้นำเสนอระบบการตรวจจับและประเมินคุณภาพผลปาล์มน้ำมันสด สำหรับใช้กับสมาร์ทโฟน เพื่อช่วยปรับปรุงประสิทธิภาพและความแม่นยำในการเก็บเกี่ยวผลปาล์มน้ำมัน ซึ่งจำเป็นต่อการผลิตน้ำมันปาล์มคุณภาพสูง ระบบที่นำเสนอยังสามารถกำหนดคุณภาพได้โดยตรงผ่านสมาร์ทโฟนที่มีระบบปฏิบัติการ Android ด้วยโครงข่ายประสาทเทียม CNN ที่สามารถจำแนกระดับความสุกของปาล์มน้ำมันสดได้อย่างแม่นยำ

2.1.8.1 ภาพรวมของชุดข้อมูลและระบบ (Datasets and System Overview)

1) ชุดข้อมูล (datasets)

ชุดข้อมูลทะเลาะปาล์มน้ำมันถูกถ่ายโดยใช้กล้อง Samsung S22 ความละเอียด 50 mega pixels มีอัตราส่วน 1:1 ชุดข้อมูลถูกแยกออกเป็น 3 ส่วน ได้แก่ 1) การฝึกอบรม 2) การทดสอบ และ 3) การตรวจสอบความถูกต้อง โดยมีอัตราส่วน 70:20:10 ตามลำดับ กระบวนการแบ่งชุดข้อมูลนี้ได้ดำเนินการบน Jupyter Notebook และจัดเก็บไว้ในรูปแบบไฟล์เดออร์ โดยรูปภาพอินพุตถูกปรับให้มีขนาดเท่ากับ 512 pixels ก่อนที่จะใช้สำหรับการเรียนรู้ของแบบจำลอง โดยจำนวนชุดข้อมูลที่ถูกจำแนกแสดงดังตารางที่ 22

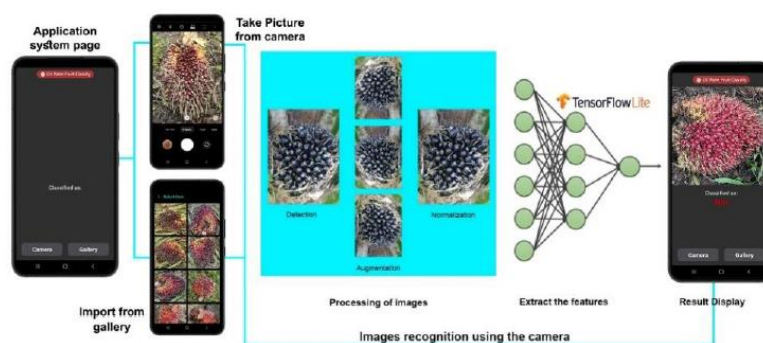
ตาราง 22 จำนวนชุดข้อมูลทั้งหมดสำหรับการฝึกอบรม การทดสอบ และการตรวจสอบความถูกต้อง

หมวดหมู่	จำนวนภาพ	ชุดข้อมูลสำหรับฝึกฝน	ชุดข้อมูลสำหรับทดสอบ	ชุดข้อมูลสำหรับตรวจสอบความถูกต้อง
สุกเกินไป	2148	1503	216	429
สุกพอดี	2150	1505	215	430
กึ่งสุกกึ่งดิบ	2151	1505	216	430
ดิบ	2149	1504	216	429

ที่ ม ๑ : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution work

2) ภาพรวมของระบบ (System Overview)

ประกอบด้วย 2 ส่วน ได้แก่ 1) การพัฒนาระบบและการพัฒนาแอปพลิเคชัน ดังภาพประกอบที่ 31 การพัฒนาระบบใช้แบบจำลอง Convolution Neural Network เพื่อจำแนกประเภทของทะลายปาล์มน้ำมัน 4 ประเภท ในขณะที่ใช้ TensorFlow Lite ในการพัฒนาแอปพลิเคชันเพื่อปรับใช้ แบบจำลอง CNN บนสมาร์ตโฟน Android เพื่อแสดงผล



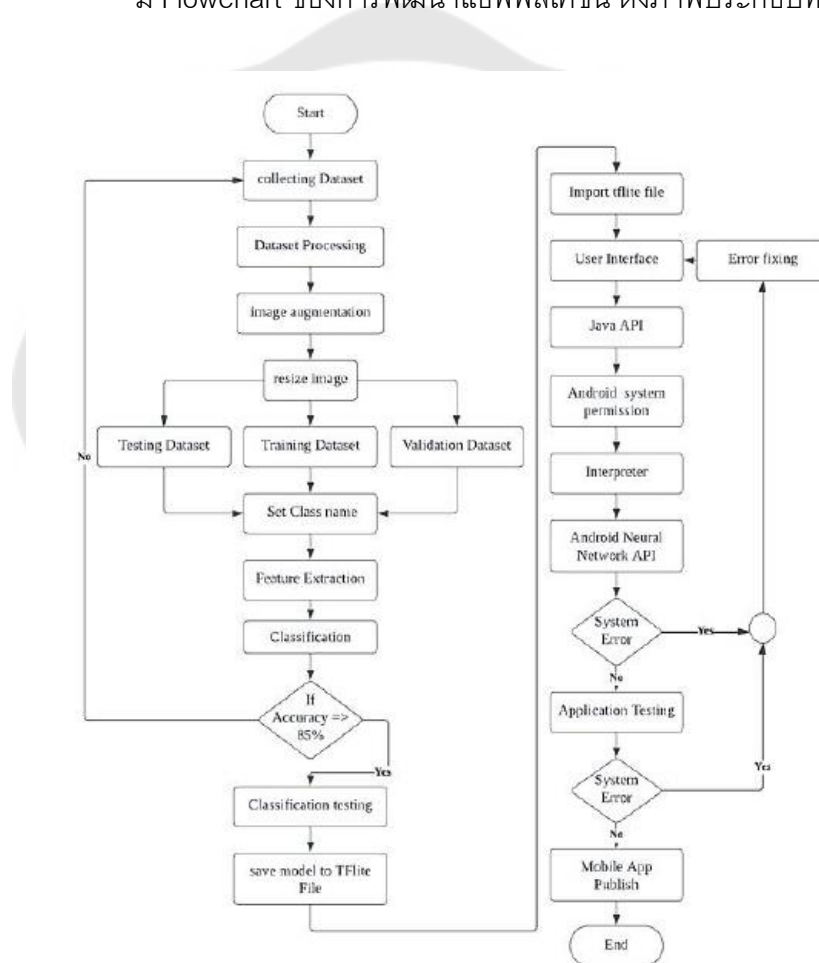
ภาพประกอบ 22 การกำหนดค่าของระบบการจำแนกผลปาล์มน้ำมันโดยใช้สมาร์ตโฟน (Android)

ที่ ม ๑ : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

จากภาพประกอบที่ 22 แสดงภาพรวมระบบการจำแนกผลปาล์มน้ำมันสดที่ประกอบด้วย 2 ส่วน ได้แก่ การพัฒนาระบบและการพัฒนาโปรแกรมประยุกต์ โดยระบบเริ่มต้นจากใช้สมาร์ทโฟนถ่ายภาพ ทั้งนี้ ข้อมูลรูปภาพจะต้องได้รับการประมวลผลล่วงหน้าเพื่อพัฒนาในกระบวนการเรียนรู้เชิงลึก ภาพที่มีการประมวลผลล่วงหน้าประกอบด้วย การปรับขนาด (Resizing) การเพิ่มข้อมูล (Augmentation) การแยกข้อมูล (Data Splitting) และการทำให้เป็นมาตรฐาน (Normalization) และรูปภาพถูกปรับขนาดเป็น 512x512x3 pixels

3) การพัฒนาซอฟต์แวร์ (Software Development)

มี Flowchart ของการพัฒนาแอปพลิเคชัน ดังภาพประกอบที่ 23



ภาพประกอบ 23 Flowchart ของการพัฒนาแอปพลิเคชัน

ที่ ม ๑ : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

3.1) การประมวลผลข้อมูลล่วงหน้า (Data Preprocessing)

ชุดข้อมูลแบ่งออกเป็นสาม 3 ชุด ได้แก่ 1) การฝึกอบรมแบบจำลอง 2) การตรวจสอบความถูกต้องแบบจำลอง และ 3) การทดสอบแบบจำลอง โดยรูปภาพทั้งหมดในชุดข้อมูลจะถูกปรับขนาดเป็นความละเอียด 512 pixels ทั้งความกว้างและความสูง โดยชุดข้อมูลสำหรับการฝึกอบรมประกอบด้วย 4 หมวดหมู่ ได้แก่ 1) สุกเกินไป 2) สุก 3) กึ่งสุกกึ่งดิบ และ 4) ไม่สุก ในส่วนของ TensorFlow มีโมดูลที่เรียกว่า layer ซึ่งมีคลาสที่แสดงถึง layer ของโครงข่ายประสาทเทียม แต่ละชั้นแสดงถึงหน่วยของการคำนวณในโครงข่ายประสาทเทียม layer ที่ใช้ในระบบโครงข่ายประสาทเทียมนี้ประกอบด้วย Convolution layer 2 มิติ และ layer ที่เชื่อมต่ออย่างสมบูรณ์

3.2) แปลงแบบจำลอง TensorFlow Lite (Convert TensorFlow Lite Model)

ตัวแปลง TensorFlow Lite ใช้เพื่อปรับแบบจำลอง TensorFlow ที่ผ่านการฝึกอบรมให้เหมาะสมสำหรับการปรับใช้บนอุปกรณ์พกพาและการสร้างแอปพลิเคชัน Android สามารถดาวน์โหลดแบบจำลอง TensorFlow Lite หรือแบบจำลอง TFlite ที่แปลงแล้วได้บนแพลตฟอร์ม Google Colab ตัวแปลง TensorFlow Lite เป็นเครื่องมือที่มีประสิทธิภาพที่ช่วยให้สามารถแปลงแบบจำลอง TensorFlow เป็นเวอร์ชันที่เล็กกว่าและเร็วกว่าซึ่งสามารถติดตั้งได้ง่ายบนอุปกรณ์เคลื่อนที่

3.3) การจำแนก (Classification)

Layer เหล่านี้จะซ้อนกันเพื่อสร้างสถาปัตยกรรม CNN พารามิเตอร์ที่สำคัญ 2 อย่างใน CNN คือ Activation Function และ Dropout Layer (layer) ที่เชื่อมต่ออย่างสมบูรณ์ใช้ผลลัพธ์ของ Convolution later เพื่อทำนายคลาสของรูปภาพตามคุณสมบัติที่แยกออกมาในขั้นตอนก่อนหน้า Convolutional Layer จะแยกและระบุลักษณะเฉพาะของภาพสำหรับการวิเคราะห์ในกระบวนการที่เรียกว่าการแยกคุณลักษณะ โดย CNN คาดการณ์โดยการวิเคราะห์ภาพและพิจารณาว่ามีลักษณะเฉพาะหรือไม่ จากนั้นจึงจำแนกภาพตามนั้น

3.4) การพัฒนาแอปพลิเคชันแอนดรอยด์ (Android Application Development)

จากภาพประกอบที่ 34 แสดงการออกแบบแอปพลิเคชัน Android โดย TensorFlow Lite เป็นเครื่องมือที่ใช้ในการเพิ่ม machine learning ให้กับ Android ซึ่งแบบจำลองที่ผ่านการฝึกอบรมจะได้รับการบันทึกและแปลงเป็นไฟล์รูปแบบ TensorFlow Lite (.tflite) จาก


Google Colab จากนั้นโหลดลงใน Android Studio และดำเนินการโดยใช้ล่าม Java โดย Java จะทำงานร่วมกับ kernel สำหรับการดำเนินการ

2.1.8.2 ผลลัพธ์และการอภิปราย (Results and Discussion)

ประสิทธิภาพของแอปพลิเคชันจำแนกทะลายปาล์มน้ำมันที่ใช้ CNN ได้รับการประเมินบนสมาร์ทโฟนสองรุ่น ได้แก่ Samsung S22 ระดับไฮเอนด์ และ Samsung A30 ระดับกลาง เพื่อตรวจสอบประสิทธิภาพของข้อมูลจำเพาะของแอปพลิเคชันบนสมาร์ทโฟน


1) กราฟการเรียนรู้ของแบบจำลอง

ระบบโครงข่ายประสาทเทียมแบบ Convolutional ในขั้นตอนการฝึกอบรมแบบจำลองมีค่าความแม่นยำ (Accuracy) สูง โดยมีค่าสูงสุดเท่ากับ 1.0 และความแม่นยำในการตรวจสอบเท่ากับ 0.93 ดังภาพประกอบที่ 24 และจากภาพประกอบที่ 25 แสดงค่าการสูญเสีย (Loss) โดยค่า Loss การฝึกอบรมแบบจำลองขั้นสุดท้ายที่บันทึกมีค่าเท่ากับ 0.0051 และค่า Loss ในขั้นตอนการตรวจสอบแบบจำลองมีค่าเท่ากับ 0.2001 จากกราฟแสดงให้เห็นว่าเมื่อจำนวน epochs เพิ่มขึ้น ทั้งความแม่นยำและการสูญเสียก็จะดีขึ้น โดยแบบจำลองนี้ออกแบบมาสำหรับการจำแนกผลปาล์มน้ำมันสดบนแอปพลิเคชันสมาร์ทโฟน Android มีความแม่นยำมากกว่า 85 เปอร์เซ็นต์



ภาพประกอบ 24 กราฟแสดงค่าความแม่นยำของการฝึกอบรมและการตรวจสอบความถูกต้อง

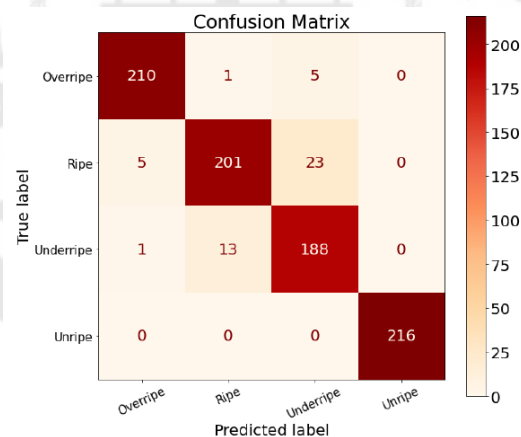
ที่มา : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network



ภาพประกอบ 25 กราฟแสดงการสูญเสียของการฝึกอบรมและการตรวจสอบความถูกต้อง

ที่ ม ๑ : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

2) Confusion matrix



ภาพประกอบ 26 Confusion matrix ของแบบจำลอง CNN

ที่ ม ๑ : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

Confusion Matrix ในภาพประกอบที่ 26 แบ่งระดับความสุกของผลปาล์มน้ำมันสด ออกเป็น 4 ประเภท ได้แก่ 1) สุกเกินไป 2) สุก 3) กึ่งสุกกึ่งดิบ และ 4) ดิบ โดย Confusion Matrix แสดงจำนวนการทำนายที่แม่นยำและไม่ถูกต้อง และจาก Confusion Matrix

แสดงให้เห็นว่าแบบจำลองมีค่าความแม่นยำเท่ากับ 97.22 เปอร์เซ็นต์ สำหรับประเภทที่สูงเกินไป 88.94 เปอร์เซ็นต์ สำหรับประเภทสูง 93.07 เปอร์เซ็นต์ สำหรับประเภทกึ่งสูงกึ่งดิบ และ 100 เปอร์เซ็นต์ สำหรับประเภทที่ยังไม่สุก และมีค่าความแม่นยำโดยรวมของแบบจำลองซึ่งเป็นสัดส่วนของการคาดคะเนทั้งหมดที่ถูกต้องมีค่าเท่ากับ 93.19 เปอร์เซ็นต์

3) การประเมินผลแบบจำลอง (Performance Evaluation)

ผลการจำแนกประเภทสำหรับแบบจำลอง โดยการจัดประเภทจะเปรียบเทียบกับคลาสที่คาดคะเนกับคลาสจริงแสดงดังภาพประกอบที่ 27

```
[ ] #get classification report
print(classification_report(y_pred, test_y))
```


	precision	recall	f1-score	support
0	0.97	0.97	0.97	216
1	0.93	0.88	0.91	229
2	0.87	0.93	0.90	202
3	1.00	1.00	1.00	216
accuracy			0.94	863
macro avg	0.94	0.95	0.94	863
weighted avg	0.95	0.94	0.94	863

ภาพประกอบ 27 ผลการจำแนกของแบบจำลอง

ที่มา : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

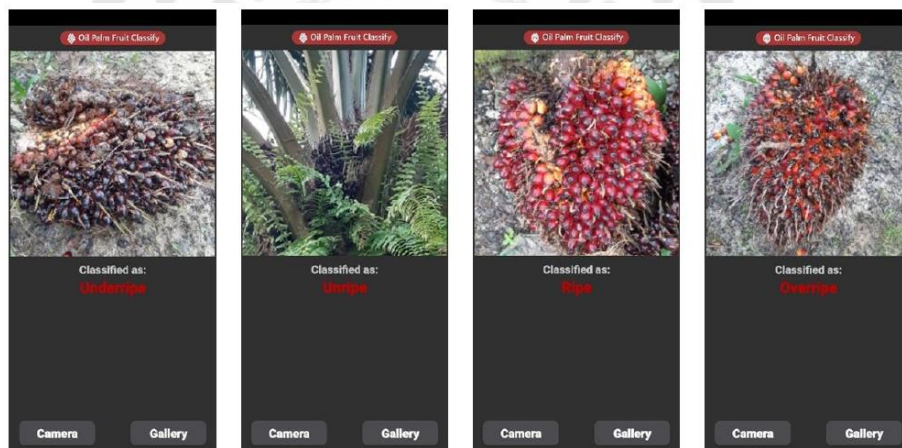
4) ผลลัพธ์ของแอปพลิเคชัน (Application result)

จากภาพประกอบที่ 28-29 แสดงผลการจำแนกระดับความสุกของผลปาล์ม น้ำมันสด โดยใช้สมาร์ตโฟน Android 2 รุ่น ได้แก่ Samsung Galaxy S22 (SM-S901E) และ Samsung Galaxy A30 (SM-A305F)



ภาพประกอบ 28 ผลลัพธ์ของการจำแนกโดยใช้ Samsung Galaxy S22 ผ่านกล้อง

ที่ ม ก : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network




ภาพประกอบ 29 ผลลัพธ์ของการจำแนกโดยใช้ Samsung Galaxy A30 ผ่านกล้อง

ที่ ม ก : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

5) เปอร์เซ็นต์ความเชื่อมั่น (Confidence Percentages)

ความแตกต่างของความแม่นยำขึ้นอยู่กับการประมวลผลภาพในโทรศัพท์
สมาร์ตโฟน (Android) แต่ละรุ่นหลังจากถ่ายภาพตัวอย่าง ดังภาพประกอบที่ 30



ภาพประกอบ 30 เปอร์เซ็นต์ความแม่นยำสำหรับภาพจำนวน 90 ภาพ

ที่ ม า : Azman and Suriani (2023). Grading Oil Palm Fruit Bunch using Convolution Neural Network

2.1.8.3 บทสรุป (Conclusion)

ประสิทธิภาพของการใช้ CNN สำหรับงานการจำแนกระดับความสุกของปาล์มน้ำมันสด แบบจำลองมีความแม่นยำโดยรวมเท่ากับ 93.19 เปอร์เซ็นต์ และประสบความสำเร็จในการพัฒนาแอปพลิเคชัน Android ที่ช่วยให้ผู้ใช้สามารถจำแนกระดับความสุกปาล์มน้ำมันสดได้ โดยใช้สมาร์ทโฟน

2.2 การตรวจจับทะเลาะปาล์มน้ำมันสด

2.2.1 งานวิจัยเรื่อง Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer Vision Models (Chen et al., 2022)

งานวิจัยนี้ได้ทำการเปรียบเทียบประสิทธิภาพในการตรวจจับทะเลาะปาล์มน้ำมันสด เพื่อช่วยในการเก็บเกี่ยวทะเลาะปาล์มที่สุกแบบอัตโนมัติ ระหว่างแบบจำลองต่าง ๆ จำนวน 4 แบบจำลอง ได้แก่ 1) Support Vector Machine (SVM) ซึ่งใช้กับ Histogram of Gradients (HOG) 2) Faster R-CNN 3) YOLOv4 และ 4) YOLOv5 และทำการประเมินแบบจำลองโดยใช้ดัชนีชี้วัดต่าง ๆ ดังนี้ 1) เมตริกของค่าเฉลี่ยความแม่นยำเฉลี่ย (mAP) 2) precision 3) recall 4) F1 score และ 5) ความเร็วในการตรวจจับ

2.2.1.1 การได้มาของข้อมูล (Data Acquisition)

ผู้วิจัยได้รวบรวมชุดข้อมูลภาพจากการค้นหาจาก www.kaggle.com และ Google Images searching ซึ่งชุดข้อมูลภาพมีทั้งหมดประมาณ 200 ภาพ จากแหล่งต่าง ๆ ซึ่งมีเพียง 169 ภาพ เท่านั้นที่เหมาะสมสำหรับการฝึกอบรม ซึ่งภาพเหล่านั้นไม่พรมัวหรือแอ๊ดจนเกินไป และไม่มีลายน้ำที่บดบังภาพ

2.2.1.2 การประมวลผลล่วงหน้า (Pre-Processing)

ข้อมูลของแบบจำลอง SVM + HOG จะทำการประมวลผลล่วงหน้าแตกต่างกับแบบจำลอง Deep Learning ดังนั้น เพื่อให้เหมาะสมกับการใช้งานกับ HOG ผู้วิจัยได้ใช้แบบจำลอง SVM เป็นตัวแยกประเภทที่สามารถระบุว่ามีทะเลลายปาล์มอยู่ในรูปภาพหรือไม่ และใช้ HOG เป็นวิธีการแยกคุณลักษณะ HOG จัดกลุ่มพิกเซลของภาพเป็นเซลล์ขนาดเล็ก สำหรับแต่ละเซลล์ จะคำนวณทิศทางการไล่ระดับสีทั้งหมดและจัดกลุ่มลงในช่องการวางแนวจำนวนหนึ่ง จากนั้นจึงสรุปค่าความไล่ระดับสีในแต่ละตัวอย่าง การไล่ระดับสีที่เข้มข้นช่วยให้ถึงขยะมีน้ำหนักมากขึ้น และผลจากการวางแนวแบบสุ่มขนาดเล็กเนื่องจากเสียงรบกวนจะลดลง

ฮิสโตแกรมทำให้เห็นภาพของการวางแนวที่โดดเด่นของเซลล์นั้น การทำเช่นนี้สำหรับเซลล์ทั้งหมดทำให้เราเป็นตัวแทนของโครงสร้างของภาพ คุณลักษณะ HOG ช่วยให้การแสดงวัตถุแตกต่างออกไป แต่ยังคงอนุญาตให้มีการเปลี่ยนแปลงรูปร่างบางอย่าง ดังภาพประกอบที่ 31 แสดงรูปภาพของทะเลลายปาล์มหลังจากที่ HOG แยกคุณสมบัติของมันออกแล้ว



ภาพประกอบ 31 เฟเจอร์ที่ดึงมาจากภาพ โดยใช้ HOG

ที่มา : Chen et al. (2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer

ตัวแยกประเภท SVM ต้องการอย่างน้อย 2 คลาสสำหรับการฝึกอบรม ดังนั้น ชุดข้อมูลรูปภาพของทะลายปาล์มน้ำมันสดและหญ้า จะถูกแบ่งออกเป็น 2 ชุด ได้แก่ ภาพเชิงบวก และภาพเชิงลบ รูปภาพเชิงบวกคือรูปภาพที่มีทะลายปาล์มน้ำมัน และรูปภาพเชิงลบคือรูปภาพที่ไม่มีทะลายปาล์มน้ำมัน

จากนั้นรูปภาพจะถูกปรับขนาดเป็น 96x64 และแปลงเป็นโทนสีเทา และ HOG ถูกนำไปใช้กับรูปภาพเหล่านั้นเพื่อดึงคุณสมบัติต่าง ๆ ออกมา HOG ใช้กับพารามิเตอร์ 9 Orientation Bin ขนาด 16x16 pixels/cells และขนาด 2x2 cells/block โดยรูปภาพถูกแบ่งด้วยอัตราส่วน 80:20 สำหรับการฝึกอบรมและการทดสอบแบบจำลอง ตามลำดับ ดังตัวอย่างในตารางที่ 23 แสดงจำนวนภาพในแต่ละชุดข้อมูล

ตาราง 23 จำนวนภาพสำหรับแต่ละชุดข้อมูลสำหรับแบบจำลอง SVM

ชุดข้อมูล	จำนวนภาพ
ภาพ Positive	169
ภาพ Negative	145
ชุดสำหรับฝึกฝน	274
ชุดสำหรับทดสอบ	69

ที่มา : Chen et al. (2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer

สำหรับแบบจำลอง Deep Learning มีกระบวนการก่อนการประมวลผลที่คล้ายคลึงกัน รูปภาพจะได้รับคำอธิบายประกอบ โดยใช้เครื่องมือออนไลน์ โดยทุกภาพในชุดข้อมูลมีกรอบล้อมรอบ ในกระบวนการใส่คำอธิบายประกอบ มีเพียงคลาสที่จำเป็นสำหรับการติดฉลากเท่านั้น ซึ่งก็คือทะลายปาล์มน้ำมันสด (FFB) เพื่อฝึกแบบจำลอง การปรับทิศทางอัตโนมัติถูกนำมาใช้กับรูปภาพเพื่อให้แน่ใจว่าอยู่ในทิศทางที่ถูกต้องของวัตถุ และลดขนาดลงเหลือ 416x416 เพื่อการฝึกที่รวดเร็วขึ้น จากนั้นชุดข้อมูลจะถูกแบ่งออกเป็นชุดข้อมูลการฝึกอบรม ชุดข้อมูลการตรวจสอบ และชุดข้อมูลการทดสอบ ดังตารางที่ 24 แสดงจำนวนภาพในแต่ละชุดข้อมูล ชุดข้อมูลที่มีคำอธิบายประกอบถูกดาวน์โหลดในรูปแบบต่าง ๆ เพื่อให้เหมาะกับแบบจำลองรุ่นต่าง ๆ Fast R-CNN ใช้รูปแบบ JSON และ YOLO ใช้รูปแบบข้อความ

ตาราง 24 จำนวนรูปภาพสำหรับแบบจำลองการเรียนรู้เชิงลึก

ชุดข้อมูล	จำนวนภาพ
Training	117
Validation	32
Testing	20

ที่มา : Chen et al. (2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer

ผู้วิจัยได้ทำการ Augmentation เพื่อใช้สำหรับการฝึกแบบจำลอง Faster R-CNN เท่านั้น รูปภาพถูกปรับขนาดเป็น 600x600 โดยการพลิกแนวนอนและแนวตั้งที่ค่า 0.3 และค่าคอนทราสต์ของความสว่างแบบสุ่มมีค่าเท่ากับ 0.1

2.2.1.3 การฝึกอบรม (training)

แบบจำลอง SVM ถูกสร้างขึ้นโดยใช้ฟังก์ชันในตัว SVC() ในแพ็คเกจ sklearn ใน Python โดย RBF kernel ถูกนำมาใช้เพื่อรวมข้อดีของอัลกอริทึม K-Nearest Neighbor เพื่อเอาชนะปัญหาความซับซ้อนของพื้นที่

สำหรับแบบจำลอง Deep Learning มีการใช้แบบจำลองที่ผ่านการฝึกอบรมล่วงหน้า พร้อมกับการปรับเปลี่ยนไฟล์ การกำหนดค่าเพื่อประหยัดเวลาในการฝึกอบรมแบบจำลองตั้งแต่เริ่มต้นและเพื่อรองรับชุดข้อมูลขนาดเล็ก ขั้นตอนการฝึกโดยทั่วไปมีดังนี้ 1) โคลนที่เก็บ Git ที่มีโค้ดของแบบจำลองที่ฝึกไว้ล่วงหน้า 2) ติดตั้งและนำเข้าไลบรารีที่จำเป็น เช่น PyTorch และ numPy 3) อัปโหลดชุดข้อมูลที่มีป้ายกำกับ (Labelled) แบบกำหนดเองในรูปแบบที่ถูกต้อง 4) ทำการเปลี่ยนแปลงที่จำเป็นในไฟล์ เช่น Batch Size จำนวนการวนซ้ำ (epochs) 5) เริ่มกระบวนการฝึกอบรมโดยส่งรูปภาพผ่านแบบจำลอง 6) ตรวจสอบประสิทธิภาพ และ 7) ทดสอบแบบจำลองโดยใช้การตรวจสอบความถูกต้องและชุดข้อมูลการทดสอบ โดยแสดงค่า Weights ที่ดีที่สุดจากการฝึกอบรมแต่ละแบบจำลอง ดังตารางที่ 25

ตาราง 25 ค่า Weights ที่ดีที่สุดจากการฝึกอบรมแต่ละแบบจำลอง

แบบจำลอง	จำนวน Iterations	ขนาดแบทช์	จำนวน Epochs	ระยะเวลาการฝึกฝน
SVM + HOG	N/A	N/A	N/A	102ms
YOLOv5	N/A	32	400	15m 36s
Faster R-CNN	N/A	4	10	23m 51s
YOLOv4	1000	32	N/A	3hrs 46m

ที่มา : Chen et al. (2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer

2.2.1.4 ผลลัพธ์และการอภิปราย (Result and discussion)

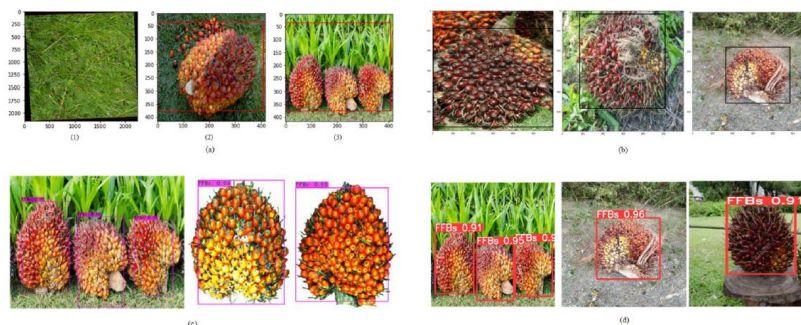
1) ประสิทธิภาพการฝึกอบรม (Training Performance)

ตาราง 26 ผลการทดสอบแบบจำลอง

แบบจำลอง	mAP	Precision	Recall	F1 Score	Detection Speed (ms)
SVM + HOG	89%	77%	87%	0.82%	1280
YOLOv5	96.4%	90.9%	90.9%	0.90%	11.4
Faster R-CNN	97%	82%	92%	0.87%	568
YOLOv4	98.5%	84%	94%	0.89%	31.8

ที่มา : Chen et al. (2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer

ผลลัพธ์ในตารางที่ 26 แสดงให้เห็นว่าแบบจำลอง YOLOv4 ทำงานได้ดีที่สุด และแบบจำลอง SVM + HOG ทำงานได้แย่ที่สุดในแง่ของ mAP นอกจากนี้ แบบจำลองที่ใช้เวลาในการตรวจจับนานที่สุดคือแบบจำลอง SVM + HOG ในขณะที่แบบจำลองที่เร็วที่สุดคือแบบจำลอง YOLOv5 โดยมีตัวอย่างแสดงผลการตรวจจับของแต่ละแบบจำลองดังภาพประกอบที่



ภาพประกอบ 32 (a) ผลการตรวจจับของแบบจำลอง SVM + HOG model, (1) the SVM + HOG model ไม่ตรวจจับทะลายปาล์มในรูปภาพหญ้า, (2) มี bounding box รวมพื้นที่ของผลที่ร่วงด้วย, (3) แบบจำลองตรวจจับภาพที่มีหลายทะลายเป็นทะลายเดียว, (b) ผลการตรวจจับของแบบจำลอง Faster R-CNN model, (c) ผลการตรวจจับของแบบจำลอง YOLOv4 model, (d) ผลการตรวจจับของแบบจำลอง YOLOv5 model

ที่มา : Chen et al. (2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer

2.2.1.5 บทสรุป

ผลลัพธ์แสดงให้เห็นว่าในแง่ของ mAP แบบจำลอง SVM + HOG ทำงานได้แย่มากที่สุดด้วยค่า mAP เท่ากับ 89 เปอร์เซ็นต์ ในขณะที่แบบจำลอง YOLOv4 ทำงานได้ดีที่สุดด้วยค่า mAP 98.5 เปอร์เซ็นต์ อย่างไรก็ตาม ในแง่ของความเร็ว แบบจำลอง YOLOv5 ทำงานได้ดีที่สุดด้วยความเร็วในการตรวจจับ 11.4 ms ทำให้ YOLOv5 เหมาะสมที่สุดสำหรับการตรวจจับแบบเรียลไทม์ แม้ว่าคะแนนความแม่นยำจะน้อยกว่าแบบจำลอง YOLOv4 เล็กน้อยก็ตาม

2.2.2 งานวิจัยเรื่อง Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4 (Lai et al., 2022)

งานวิจัยนี้ได้นำเสนอระบบตรวจจับทะลายปาล์มน้ำมันที่สุกพอดีแบบเรียลไทม์ (Real-Time) โดยการป้อนกล้องเข้าสู่แบบจำลอง CNN ด้วยแบบจำลอง YOLOv4 เพื่อตรวจหาทะลายปาล์มน้ำมันที่สุกพอดีบนต้นปาล์ม เมื่อตรวจพบ สัญญาณจะถูกส่งผ่าน ROS ไปยังกลไกการเก็บเกี่ยวด้วยหุ่นยนต์ ซึ่งในการฝึกแบบจำลอง YOLOv4 นี้ ชุดข้อมูลภาพทะลายปาล์มน้ำมัน

ที่ใช้ในการทดลองถูกรวบรวมโดยใช้กล้อง Intel Realsense D435 ที่มีความละเอียดเท่ากับ 1920x1080 โดยมีผู้เชี่ยวชาญช่วยในการจำแนกว่าทะเลาะปาล์มน้ำมันสุกหรือไม่

ในระหว่างขั้นตอนการทดสอบ ผลลัพธ์ของค่าเฉลี่ยความแม่นยำ (mAP) และการเรียกคืนคือ 87.9 เปอร์เซ็นต์ และ 82 เปอร์เซ็นต์ เนื่องจากการตรวจจับเต็มพิกัด Intersect over Union (IoU) ที่มากกว่า 0.5 หลังจากการทำซ้ำ 2,000 ครั้ง และระบบดำเนินการจริง - ความเร็วโดยประมาณ 21 เฟรมต่อวินาที (FPS)

2.2.2.1 การได้มาของข้อมูล (Data Acquisition)

ต้นปาล์มน้ำมันที่เลือกใช้ในการเก็บข้อมูลมีอายุตั้งแต่ 8-13 ปี เพราะเป็นช่วงที่ต้นปาล์มผลิตผลปาล์มน้ำมันมากที่สุด ข้อมูลตัวอย่างบันทึกตั้งแต่เดือนพฤศจิกายน-ธันวาคม พ.ศ. 2564 ที่สวนปาล์มน้ำมันในรัฐ Selangor ประเทศมาเลเซีย

2.2.2.2 การเตรียมข้อมูลและการฝึกอบรม (Data Preparation and Training)

ในขั้นตอนการเตรียมข้อมูลการฝึกอบรม วิดีโอที่บันทึกต้นปาล์มน้ำมันจะถูกดึงออกมาเป็นรูปภาพก่อน ภาพเหล่านี้สามารถแบ่งออกเป็นภาพเชิงบวก (Positive Images) และภาพเชิงลบ (Negative Image) ภาพเชิงบวกคือภาพต้นปาล์มที่มีวัตถุที่ต้องการตรวจจับ ซึ่งก็คือทะเลาะปาล์มสุก ในทางตรงกันข้าม ภาพเชิงลบคือภาพต้นปาล์มที่ไม่มีทะเลาะปาล์มสุก ซึ่งมีภาพเชิงบวกทั้งหมดจำนวน 240 ภาพ และภาพเชิงลบจำนวน 250 ภาพ

จากนั้น ภาพเชิงบวกจะถูกติดฉลากแบบแมนนวล (Manual) โดยใช้ซอฟต์แวร์ labellmg ภาพเชิงบวกและเชิงลบจะถูกแยกออกเป็นสองชุดข้อมูลคือชุดข้อมูลสำหรับฝึกอบรมแบบจำลอง และสำหรับตรวจสอบแบบจำลอง สำหรับภาพเชิงบวกถูกแบ่งออกเป็น 210 ภาพ และ 30 ภาพ ส่วนภาพเชิงลบแบ่งเป็น 220 ภาพ และ 30 ดังแสดงในตารางที่ 27 โดยมีการกำหนดพารามิเตอร์ดังตารางที่ 28 และแสดงผลการวิเคราะห์ ดังตารางที่ 29

ตาราง 27 แสดงการแยกภาพสำหรับการฝึกแบบจำลอง YOLOv4

ชุดข้อมูล	ชุดสำหรับฝึกฝน	ชุดสำหรับตรวจสอบ	จำนวนภาพ
Positive	210	30	240
Negative	220	30	250
รวม	430	60	490

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

ตาราง 28 แสดงค่าของพารามิเตอร์ในแบบจำลอง YOLOv4

พารามิเตอร์	ค่า
ความกว้าง	608
ความสูง	608
ค่า Momentum	0.949
ค่า Decay	0.005
ค่า Angle	0
ค่า Saturate	1.5
ค่า Exposure	1.5
ค่า Hue	0.1
อัตราการเรียนรู้	0.001
ขนาดแบทช์ (Maximum)	3000

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

ตาราง 29 แสดงผลการวิเคราะห์แบบจำลอง YOLOv4 ทุก ๆ 1,000 ครั้ง

จำนวนรอบ (Iteration)	1000	2000	3000
Precision	86%	100%	100%
Recall	80%	97%	100%
F1-score	83%	98%	100%
Average IoU	64.24%	77.93%	79.75%
mAp	87.88%	99.89%	100%

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

2.2.2.3 ผลลัพธ์และการอภิปราย

1) ประสิทธิภาพการฝึกอบรมของรุ่น YOLOV4

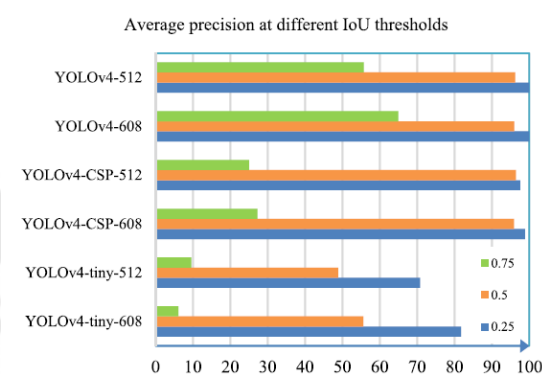
หลังจากฝึกอบรมแบบจำลอง YOLOv4 แล้ว ประสิทธิภาพของแบบจำลอง จะได้รับการวิเคราะห์ทุก ๆ 1,000 ครั้ง จากตารางที่ 30 แสดงการวิเคราะห์ประสิทธิภาพของแบบจำลอง YOLOv4 ซึ่งพบว่าประสิทธิภาพการตรวจจับเป็นสัดส่วนโดยตรงกับจำนวนการฝึกซ้ำ มีค่าความแม่นยำถึง 86 เปอร์เซ็นต์ เมื่อมีการทำซ้ำ 1,000 ครั้ง และจะเพิ่มเป็น 100 เปอร์เซ็นต์ เมื่อจำนวนการวนซ้ำ 2,000 ครั้ง ขึ้นไป

ผลลัพธ์ของ IoU เฉลี่ย ในการตรวจจับผลปาล์มที่สูง ซึ่งแสดงถึงความครอบคลุมของกล่องขอบเขตบนวัตถุเป้าหมาย จะเพิ่มขึ้นทุก ๆ 1,000 ครั้ง อย่างไรก็ตาม ประสิทธิภาพที่ของการใช้แบบจำลองด้วยการวนซ้ำ 3,000 ครั้ง นั้น เกิดจากการ Overfitting เนื่องจากแบบจำลองนี้ ตรวจพบข้อมูลเฉพาะเจาะจงที่ได้รับการฝึกอบรมมา และอาจไม่สามารถคาดการณ์ในอนาคตได้อย่างน่าเชื่อถือ ดังนั้น อัลกอริทึมที่ผ่านการฝึกอบรมด้วยการวนซ้ำ 2,000 ครั้ง สำหรับแบบจำลอง YOLOv4 จึงเหมาะสำหรับระบบตรวจจับที่เสนอนี้ด้วยชุดข้อมูลจำนวน 490 ภาพ

2) การเปรียบเทียบกับแบบจำลอง YOLOV4 ที่แตกต่างกัน

แบบจำลอง YOLOv4 รุ่นดั้งเดิมมีประสิทธิภาพสูงสุดในมุมมองที่แตกต่างกัน ค่า Precision Recall และ F1-score มีค่าสูงถึง 97 เปอร์เซ็นต์ รวมถึงค่า IoU และค่า mAP โดยเฉลี่ยทำได้สูงกว่า 75 เปอร์เซ็นต์ และ 96 เปอร์เซ็นต์ ดังภาพประกอบที่ 33 ทั้งขนาดเครือข่าย อินพุตทั้ง 512x512 และ 608x608 เมื่อวิเคราะห์แบบจำลอง YOLOv4-CSP ค่า mAP จะมีความ

แม่นยำใกล้เคียงกับแบบจำลอง YOLOv4 ดั้งเดิม อย่างไรก็ตาม แม้ว่าแบบจำลอง YOLOv4-CSP จะมี mAP สูงกว่า YOLOv4 แต่ก็มีการคาดการณ์และละเอียดอ่อนน้อยกว่า เนื่องจากผลลัพธ์ที่ได้แสดงให้เห็นว่าค่า Precision Recall F1-score และค่าเฉลี่ย IoU นั้นมีค่าต่ำกว่า YOLOv4 เล็กน้อย และค่าต่ำมากใน YOLOv4-tiny ทั้งนี้ มีการแสดงขนาดของแบบจำลองรุ่นต่าง ๆ ดังตารางที่ 30 และมีการวิเคราะห์แบบจำลอง YOLOv4 รุ่นต่าง ๆ ดังตารางที่ 31



ภาพประกอบ 33 ความแม่นยำเฉลี่ยของ YOLOv4 ที่ 25 % 50 % และ 75 % IoU thresholds ของชุดการตรวจสอบความถูกต้อง

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

ตาราง 30 ขนาดของแบบจำลองรุ่นต่าง ๆ

แบบจำลอง	ขนาดของค่า Weight (MB)
YOLOv4-512	256.0
YOLOv4-608	256.0
YOLOv4-CSP-512	210.2
YOLOv4-CSP-608	210.2
YOLOv4-tiny-512	23.5
YOLOv4-tiny-608	23.5

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

ตาราง 31 การวิเคราะห์แบบจำลอง YOLOv4 รุ่นต่าง ๆ

แบบจำลอง	ค่า Precision	ค่า Recall	ค่า F1-score	ค่า Average	ค่า mAP
YOLOv4-512	97%	97%	97%	75.85%	96.00%
YOLOv4-608	97%	97%	97%	77.13%	96.22%
YOLOv4-CSP-512	90%	87%	88%	67.48%	95.89%
YOLOv4-CSP-608	84%	90%	87%	63.24%	96.43%
YOLOv4-tiny-512	57%	57%	57%	38.74%	55.60%
YOLOv4-tiny-608	48%	77%	59%	33.76%	48.89%

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

ตาราง 32 การประเมินแบบจำลอง YOLOv4 ณ สถานที่จริง

การประเมินแบบจำลอง (Evaluation)	เปอร์เซ็นต์ (%)
Precision	95%
Recall	82%
F1-score	88%
Average IoU	70.19%
mAP	87.90%

ที่มา : Lai et al. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4

3) การทดสอบในสถานที่จริงของแบบจำลอง YOLOV4

จากตารางที่ 32 เป้าหมายของการทดสอบคือเพื่อประเมินประสิทธิภาพของระบบตรวจจับทะลายปาล์มที่สุกพอดี แบบจำลองที่เลือกใช้คือ YOLOv4 เนื่องจากผลการวิจัยระหว่างการฝึกอบรมพบว่ามีค่าความแม่นยำเฉลี่ยสูงสุดเมื่อเทียบกับ YOLOv4-tiny และ YOLOv4-CSP

ผู้วิจัยได้ทำการทดสอบเมื่อเวลาประมาณ 09.00 น. ขณะที่ อากาศแจ่มใส และอุณหภูมิอยู่ที่ประมาณ 32 °C มีต้นปาล์มทั้งหมด 20 ต้น สำหรับการทดสอบ โดยมี 10 ต้น ที่มี ทะลายปาล์มน้ำมันที่ยังไม่สุกเท่านั้น และมี 10 ต้น ที่มีทะลายปาล์มน้ำมันสุกอย่างน้อย 1 ทะลาย ซึ่งต้นปาล์มที่ทดสอบมีอายุและความสูงใกล้เคียงกับต้นปาล์มที่ใช้ในการฝึกแบบจำลอง ในตาราง ที่ 21 แสดงการประเมินแบบจำลอง YOLOv4 จากการทดสอบในสถานที่จริง การศึกษานี้ยืนยันว่า ระบบตรวจจับอัตโนมัติสามารถตรวจจับทะลายปาล์มสุกได้

2.3.2.4 บทสรุป

แม้ว่างานวิจัยนี้จะไม่มีการเปลี่ยนแปลงใด ๆ กับสถาปัตยกรรมของ แบบจำลอง แต่ก็แสดงให้เห็นว่าด้วยวิธีการที่เลือกและไฮเปอร์พารามิเตอร์สำหรับการฝึกอบรม ผลลัพธ์การตรวจจับก็เป็นที่น่าพอใจอย่างมาก จากการวิเคราะห์พบว่าแบบจำลอง YOLOv4 ที่ ผ่านการฝึกอบรมมีค่า mAP เท่ากับ 87.9 เปอร์เซ็นต์ ในการตรวจจับทะลายปาล์มน้ำมันสุก ผลลัพธ์ของ recall และ F1-score มีค่าเท่ากับ 82 เปอร์เซ็นต์ และ 88 เปอร์เซ็นต์ ตามลำดับ โดย ประสิทธิภาพอาจปรับปรุงให้ดียิ่งขึ้นด้วยการปรับปรุงข้อมูลการฝึกอบรม สถาปัตยกรรม แบบจำลอง และการเพิ่มประสิทธิภาพไฮเปอร์พารามิเตอร์

2.3 การทบทวนงานวิจัยเกี่ยวกับการจำแนกระดับความสุกทะลายปาล์มน้ำมัน


2.3.1 งานวิจัยเรื่อง Oil Palm Fresh Fruit Bunch Ripeness Detection Methods: A Systematic Review (Lai et al., 2023)

ในบทความนี้ได้มีการทบทวนงานวิจัยต่าง ๆ ทั้งในอดีตและปัจจุบัน ที่เกี่ยวกับการ จำแนกระดับความสุกของทะลายปาล์มน้ำมันสด เพื่อทำการเปรียบเทียบวิธีการต่าง ๆ ผู้วิจัยได้ ทำการศึกษาอย่างครอบคลุม โดยเน้นวิธีการที่เป็นไปได้และความพร้อมของระบบที่พัฒนาขึ้นเพื่อ ใช้ในภาคสนามหรือในสวนปาล์มได้ เนื่องจากเป็นประเด็นที่อยู่ในความสนใจของ ภาคอุตสาหกรรมเกษตร ที่จะแก้ไขปัญหาการขาดแคลนแรงงาน ด้วยเทคโนโลยีสมัยใหม่โดยเร็ว ที่สุด โดยผู้วิจัยได้ทบทวนบทความวิจัยทั้งหมดจำนวน 51 ฉบับ พบว่ามีวิธีการที่ไม่ซ้ำกันทั้งหมด จำนวน 11 วิธี ด้วยกัน ทั้งนี้ พบว่าวิธีการที่เป็นไปได้มากที่สุดสำหรับการตรวจจับผลปาล์มน้ำมัน สดในภาคสนามหรือในสวนปาล์ม คือการผสมผสานระหว่างการมองเห็นด้วยคอมพิวเตอร์และการ เรียนรู้เชิงลึก(Computer Vision and Deep Learning) เพราะมีข้อดีตรงที่เป็นแบบ Noncontact Approach ที่มีต้นทุนต่ำในขณะเดียวกันก็สามารถทำงานได้แบบเรียลไทม์และมีความแม่นยำสูง ซึ่งเกณฑ์การคัดเลือกบทความวิจัยสำหรับการทบทวนเอกสารได้แก่

1) เป็นผลงานวิจัยที่เผยแพร่ระหว่างปี 2012 ถึง 2022
 2) ภาษาเขียนเป็นภาษาอังกฤษเท่านั้น
 3) พบโดยใช้คำหลักต่อไปนี้ร่วมกันใน Google Scholar: oil palm, fresh fruit bunch, freshness, mature, maturity ripeness, grading, assessment, classification detection, identification.

4) เป็นบทความที่ผ่านกระบวนการกรองขั้นสุดท้ายแล้ว โดยเลือกเฉพาะบทความที่นำเสนอผลลัพธ์ของวิธีการตรวจสอบความสุกของผลปาล์มสดเท่านั้น

จากบทความต่าง ๆ จะเห็นได้ว่าเกือบครึ่งหนึ่งของบทความทั้งหมดใช้วิธีการมองเห็นของสี (Color Vision) เพื่อเก็บข้อมูลจากทะเลาะปาล์มน้ำมันสดเพื่อพิจารณาระดับความสุก ทำให้วิธีนี้เป็นวิธีที่ได้รับความนิยมมากที่สุด อาจเนื่องมาจากข้อจำกัดด้านฮาร์ดแวร์ แต่สำหรับวิธีนี้มีต้นทุนค่อนข้างต่ำ อย่างไรก็ตาม ความท้าทายหลักประการหนึ่งในการใช้ Color Vision ในการตรวจจับคือ ไม่สามารถระบุภาวะความสุกบางส่วนได้ ในบางกรณี ส่วนต่าง ๆ ของทะเลาะปาล์มน้ำมันจะสุกในช่วงเวลาที่ต่างกัน อาจหมายความว่าทะเลาะปาล์มดูเหมือนจะสุกด้านหนึ่ง แต่จริง ๆ แล้วยังไม่สุกในส่วนอื่น ๆ



ภาพประกอบ 34 จำนวนบทความที่จัดหมวดหมู่ตามแบบจำลอง (Machine Learning Model)

ที่มา : Lai et al. (2023). Oil Palm Fresh Fruit Bunch Ripeness Detection Methods: A Systematic Review

จากการวิเคราะห์ในภาพประกอบที่ 34 แสดงให้เห็นว่าการศึกษาร้อยละส่วนใหญ่ใช้โครงข่ายประสาทเทียม (ANN) ในการจำแนกระดับความสุกของทะเลาะปาล์มน้ำมัน

เพราะว่าแบบจำลอง ANN เป็นเครื่องมือที่ใช้งานได้และน่าเชื่อถือ แบบจำลอง ANN ถูกนำมาใช้อย่างแพร่หลายในคุณลักษณะต่าง ๆ ที่แยกออกมา เช่น ภาพจากระบบที่ใช้ดี ระบบที่ใช้ความร้อน และระบบไฮเปอร์สเปกตรัม ในขณะที่เดียวกัน แบบจำลองของ CNN และ SVM เป็นเป็นที่นิยมใช้กันมากเป็นอันดับ 2 และ 3 ตามลำดับ

อย่างไรก็ตาม จากมุมมองของผู้วิจัยมีข้อสังเกตว่า แบบจำลอง CNN มีประโยชน์สูงสุดในการตรวจจับและจำแนกระดับความสูงของป่าลัมน์น้ำมันสด เมื่อเปรียบเทียบกับแบบจำลอง Machine Learning อื่น ๆ โดยจากแนวทางการวิจัยในปัจจุบัน ระบบตรวจจับที่เป็นไปได้มากที่สุดและใกล้เคียงกับความพร้อมสำหรับการใช้งานในสวนป่าลัมน์มากที่สุด คือระบบที่รวมการตรวจจับการมองเห็นของสีเข้ากับตัวแยกประเภท CNN การตรวจจับด้วยภาพสีมีข้อดีตรงที่ต้นทุนต่ำเมื่อเทียบกับวิธีการตรวจจับแบบ LiDAR เนื่องจากกล้องทั่วไปมีราคาถูก ในขณะที่ LiDAR มักมีราคาแพง นอกจากนี้ กล้องยังไม่จำเป็นต้องตั้งค่าเพิ่มเติมใด ๆ ซึ่งแตกต่างจากเซนเซอร์แบบเหนี่ยวนำ และยังสามารถทำงานได้จากระยะไกลอีกด้วย และนี่คือเหตุผลที่มีการรวมและทำงานได้ดีกับอัลกอริทึมของ CNN เช่น YOLO ที่สามารถประมวลผลภาพด้วยความเร็วที่น่าประทับใจ ทำให้เหมาะสำหรับการทำงานแบบเรียลไทม์ ผู้วิจัยได้ขอแนะนำแบบจำลอง YOLO เนื่องจากสามารถทำงานได้อย่างแม่นยำภายใต้การตรวจจับตามเวลา และในงานวิจัยบางงานได้มีการใช้แบบจำลอง YOLOv3 เพื่อทดสอบการจำแนกระดับความสูงของทะเลสาบป่าลัมน์น้ำมันสดแล้ว ดังนั้น ในอนาคตผู้วิจัยจึงได้แนะนำให้ทดสอบประสิทธิภาพของแบบจำลอง YOLO v4

2.4 แบบจำลองการตรวจจับวัตถุ (Object Detection Model) (Patel & Patel, 2020)


แบบจำลองการตรวจจับวัตถุ หรือ Object Detection Model มีทั้งการตรวจจับวัตถุเพียงชนิดเดียว (Single-class object detection) โดยที่มีวัตถุเพียงตัวเดียวที่ตรวจพบในภาพนั้น ๆ และการตรวจจับวัตถุหลายชนิด (Multi-class object detection) โดยที่ต้องการตรวจจับวัตถุหลายชนิดที่เป็นของกลุ่มต่าง ๆ โครงสร้างที่ใช้ในการตรวจจับวัตถุสามารถแบ่งเป็น 2 ประเภทคือ Region proposal networks และ Unified networks แบบจำลองที่ใช้ระบบ Region proposal networks เรียกว่า Multi-stage หรือ Two-stage models ส่วน Unified models เรียกว่า Single-stage model โดยแบบจำลอง Two-stage มีการทำงาน 2 ขั้นตอน คือ 1) สร้างพื้นที่ที่น่าสนใจ (ROI) และ 2) การจำแนกคลาส ทั้งนี้ การตรวจจับวัตถุแบบ Two-stage มีความแม่นยำสูงแต่มีการประมวลผลช้า และการตรวจจับวัตถุแบบ Single-stage มีการประมวลผลที่เร็วกว่า เนื่องจากมีขั้นตอนการทำงานที่น้อยกว่าในเรื่องของการคำนวณ โดยแบบจำลองการตรวจจับวัตถุแบบ Two-stage ได้แก่ Mask R-CNN R-CNN Fast R-CNN และ Faster R-CNN และแบบจำลอง

ตรวจจับวัตถุแบบ Single-stage ได้แก่ YOLO และ SSD ทั้งนี้ ผลลัพธ์จากการตรวจจับวัตถุจะมีกล่องสี่เหลี่ยมรอบวัตถุพร้อมกับระดับความมั่นใจในการตรวจจับ

2.4.1 Two-Stage Detectors

2.4.1.1 Region-Based Convolutional Neural Network (R-CNN)

R-CNN เป็นหนึ่งในแบบจำลองตรวจจับวัตถุที่นิยมใช้กันมาก โดยจัดอยู่ในประเภทแบบจำลอง 2 ขั้นตอน (Two-stage object detectors) นำเสนอโดย (Girshick et al., 2014) โดย R-CNN เป็นแบบจำลองตรวจจับวัตถุแรกที่ใช้ CNN แบบแบ่งพื้นที่ (Region-based) ตามภาพประกอบที่ 1 R-CNN ใช้ Selective Search ในการสร้าง Region of Interest (ROI) หรือบริเวณที่น่าจะมีวัตถุ ประมาณ 2,000 บริเวณ จากนั้นป้อนข้อมูลเหล่านี้เข้าสู่ CNN เพื่อสร้าง Feature Vector ขนาด 4,096 มิติ จากนั้นนำ Feature Vector ที่ได้ไปใช้กับ Support Vector Machine (SVM) เพื่อจำแนกประเภทของวัตถุ นอกจากนี้ ยังวาดกรอบล้อมรอบวัตถุที่ตรวจพบอีกด้วย ดังภาพประกอบที่ 35



ภาพประกอบ 35 R-CNN: a region-based CNN detector

ที่ มา : (Girshick et al., 2014). R-CNN: Rich feature hierarchies for accurate object detection and semantic segmentation

2.4.1.2 Fast R-CNN

หลังจากระบบ R-CNN ถูกเผยแพร่เพียงปีเดียว (Girshick, 2015) ก็ปล่อย R-CNN เวอร์ชันที่เร็วกว่าออกมา ชื่อว่า Fast R-CNN ปัญหาของ R-CNN คือใช้เวลาประมวลผลนาน เนื่องจากใช้การ Convolution กับแต่ละ Region of Interest (ROI) ที่คาดว่าจะมีวัตถุ ทำให้ช้า Fast R-CNN จึงนำแนวคิดของ ROI มาลดเวลาการทำงาน โดยใช้ขั้น ROI pooling เพื่อลดขนาด Feature map จากแต่ละ ROI ให้เป็นขนาดเดียวกัน ไม่ว่าขนาดของ ROI เดิมจะต่างกัน จากนั้นใช้เทคนิค Max pooling แบ่งพื้นที่ ROI เป็นช่องตารางเล็ก ๆ แล้วเลือกค่าพิกเซลที่มีค่าสูงสุดในแต่ละช่อง ผลลัพธ์คือ Fast R-CNN ทำงานเร็วกว่า R-CNN เล็กน้อย (mAP 66.9% vs 66.0%) โดย

ทดสอบบนชุดข้อมูล PASCAL VOC 2007 สำหรับการจำแนกประเภทวัตถุและปรับกรอบวัตถุสรุปแล้ว Fast R-CNN พัฒนาต่อยอดจาก R-CNN โดยเน้นประมวลผลเฉพาะบริเวณที่น่าจะมีวัตถุ ผสานเทคนิคหลายอย่างให้ทำงานเร็วขึ้นและแม่นยำขึ้น

2.4.1.3 Faster R-CNN

Faster R-CNN พัฒนาต่อยอดจาก R-CNN โดยนำเสนอแนวคิด Region Proposal Network (RPN) ที่ Ren et al., (2015) ได้นำเสนอในปี 2016 โดย RPN จะเข้ามาแทนที่ Selective Search ซึ่งเป็นอัลกอริทึมที่ซ้ำใน Fast R-CNN RPN เป็นเครือข่าย CNN เต็มรูปแบบที่ทำหน้าที่คาดการณ์บริเวณที่น่าจะมีวัตถุ (Region Proposal) ขั้นตอนการทำงานเริ่มจากการสร้าง Anchor Box ซึ่งเป็นกล่องสี่เหลี่ยมรอบ ๆ บริเวณที่คาดว่าจะมีวัตถุ จากนั้นใช้ฟังก์ชันการสูญเสีย (Loss Function) เพื่อคำนวณความน่าจะเป็นของข้อผิดพลาด สุดท้าย เครือข่ายหลัก (Backbone Network) จะสร้าง Feature map และ RPN จะคาดการณ์ชุดของ Region Proposal เหล่านี้จะถูกส่งต่อไปยังขั้นถัดไป นั่นคือ Roi Pooling Layer ขั้นนี้จะแปลง Feature ที่ได้จาก CNN ที่ผ่านการปรับแต่ง ให้เป็น Feature map ขนาดคงที่ สุดท้าย ขั้นการจำแนก (Classification Layer) จะทำนายประเภทของวัตถุ ส่วน Bounding Box Regression จะสร้างกล่องสี่เหลี่ยมล้อมรอบวัตถุเพื่อระบุตำแหน่ง ผลลัพธ์ที่ได้คือ คะแนน mAP 69.9% บนชุดข้อมูลทดสอบ PASCAL VOC 2007 ซึ่งถือเป็นการปรับปรุงที่สำคัญเหนือกว่า Fast R-CNN ทั้งในด้านประสิทธิภาพการตรวจจับและการคาดการณ์

2.4.1.4 Mask R-CNN


ต่อยอดจาก Faster R-CNN คือ Mask R-CNN ที่ (He et al., 2017) นำเสนอ โดยมุ่งเน้นที่การแบ่งส่วนวัตถุ (instance segmentation) จากภาพ Mask R-CNN เป็นแบบจำลองต่อยอดจาก Faster R-CNN ที่นอกเหนือจากการระบุประเภทและกรอบวัตถุแล้ว ยังสามารถสร้าง Mask ของวัตถุด้วย การแบ่งส่วนวัตถุอย่างแม่นยำเป็นสิ่งสำคัญสำหรับงานนี้ ดังนั้น Mask R-CNN จึงผสมผสานสองแง่มุมสำคัญของ Computer vision นั่นคือ การตรวจจับวัตถุ (object detection) เพื่อจำแนกและระบุตำแหน่งวัตถุในภาพ และการแบ่งส่วนความหมาย (semantic segmentation) เพื่อจำแนกและกำหนดแต่ละพิกเซลให้เป็นหมวดหมู่ที่กำหนดไว้ Mask R-CNN นำเสนอ RoIAlign layer ที่ช่วยแก้ปัญหาความไม่ตรงกันของตำแหน่ง

2.4.2 Single-Stage Detectors

2.4.2.1 You Only Look Once (YOLO)

YOLO เป็นอีกหนึ่งแบบจำลองตรวจจับวัตถุประเภท Single-stage และนิยมใช้สำหรับงานตรวจจับวัตถุแบบเรียลไทม์ โดย แบบจำลองนี้มีความโดดเด่นที่การทำนายกรอบวัตถุ (Bounding box) และประเภทของวัตถุพร้อมกันภายในครั้งเดียว เรียกได้ว่าเป็นเครือข่ายแบบ Unified และมีความเร็วสูงเมื่อเทียบกับ Faster R-CNN โดย YOLO ใช้เครือข่ายประสาทเทียมชนิด CNN แบบเดียว ทั้งนี้ CNN ที่ใช้ใน YOLO เดิมสร้างจากโมเดล GoogLeNet และรุ่นอัปเดตเรียกว่า DarkNet ซึ่งอิงจาก VGG ตามภาพประกอบที่ 40 YOLO จะแบ่งภาพที่ป้อนเข้าเป็นตารางกริด โดยแต่ละเซลล์จะทำนายประเภทของวัตถุและกรอบวัตถุโดยตรง ส่งผลให้มีการสร้างกรอบวัตถุจำนวนมากก่อนที่จะรวมเป็นผลลัพธ์สุดท้าย (Redmon et al., 2016) โดยมีโครงสร้างแบบจำลองดังภาพประกอบที่ 36

YOLO มีหลายเวอร์ชัน จุดเด่นของ YOLO คือ ความเร็ว เหมาะสำหรับงานตรวจจับวัตถุแบบเรียลไทม์ นอกจากนี้ ยังสามารถฝึกแบบจำลองแบบ end-to-end เพื่อปรับปรุงความแม่นยำ เนื่องจากใช้ CNN เดียวในการทำนาย ผลลัพธ์จึงมีความทั่วไป (Generalized) และทำงานได้ดีกับภาพจริงและภาพวาด



ภาพประกอบ 36 YOLO: a single-stage object detector model

ที่มา : (Redmon et al., 2016). You only look once: Unified, real-time object detection

2.4.4.2 Single-Shot Detector (SSD)

SSD เป็นอีกหนึ่งแบบจำลองตรวจจับวัตถุประเภท Single-stage เหมือนกับ YOLO ที่ (Liu et al., 2016) พัฒนา โดยใช้การประมวลผลเพียงครั้งเดียว (single shot) เพื่อตรวจจับวัตถุหลายๆ อย่างภายในภาพ ทั้งการระบุตำแหน่งและประเภทของวัตถุทำพร้อมกันในรอบเดียว

SSD ใช้โมเดล VGG-16 ที่ผ่านการฝึกอบรมบนชุดข้อมูล ImageNet เป็นโมเดลพื้นฐานในการดึง Feature ที่สำคัญของภาพ ปลายโมเดลจะมีเลเยอร์ Convolutional เพิ่มเติมสำหรับการตรวจจับวัตถุ ขณะทำนาย จะมีการสร้างคะแนนความน่าจะเป็นสำหรับแต่ละประเภท

ของวัตถุในภาพโดยใช้กรอบเริ่มต้น (Default box) นอกจากนี้ ยังปรับกรอบเหล่านั้นให้เข้ากับรูปร่างของวัตถุมากขึ้น เครือข่ายของ SSD ยังรวมเอาผลลัพธ์ที่ได้จาก Feature map หลายความละเอียด ช่วยให้เราสามารถจัดการกับวัตถุที่มีขนาดแตกต่างกันได้

ตารางที่ 33 ด้านล่างแสดงคุณสมบัติและข้อจำกัดของแบบจำลองตรวจจับวัตถุที่เป็นที่นิยม ได้แก่ R-CNN Fast R-CNN Faster R-CNN YOLO SSD และ Mask R-CNN

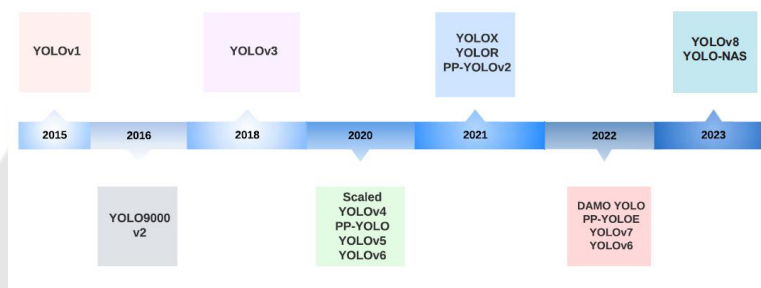
ตาราง 33 เปรียบเทียบแบบจำลองตรวจจับวัตถุแบบ Single-stage และ Two-stage

แบบจำลอง	คุณสมบัติ	ข้อจำกัด
R-CNN	ใช้ Selective Search algorithm ค้นหา แยกประเภท และระบุตำแหน่งวัตถุบนภาพด้วยกรอบสี่เหลี่ยม (bounding box)	ค้นหาตำแหน่งวัตถุ (Region proposals) ในภาพได้ถึง 2,000 ตำแหน่ง แต่ใช้เวลานานมากในการฝึกแบบจำลอง จึงไม่สามารถใช้งานจริงแบบ Real-time เพราะการทดสอบช้ามาก
Fast R-CNN	มีการพัฒนาเลเยอร์ ROI pooling ที่กำหนดพื้นที่ ROI ขนาดคงที่ ผสมผสานแบบจำลอง 3 แบบจำลอง จาก R-CNN และใช้ Softmax แทน SVM ในการจำแนกประเภท ทำให้มีความแม่นยำและรวดเร็วกว่า R-CNN เดิม	อัลกอริทึม Selective Search ที่ใช้หา Region Proposal ทำให้การประมวลผลช้าและใช้ระยะเวลา
Faster R-CNN	ใช้ "Region Proposal Network (RPN)" แทน Selective Search ทำให้การตรวจจับวัตถุแม่นยำ รวดเร็ว และมีประสิทธิภาพดีกว่า Fast R-CNN มาก	การทำ Region Proposal ใช้เวลานาน ต้องผ่านหลายรอบกว่าจะเสร็จสิ้นกระบวนการทั้งหมด
YOLO	เมื่อเปรียบเทียบกับอัลกอริทึมตระกูล R-CNN แล้ว YOLO มีความเร็วอย่างมาก โดยใช้ CNN เพียงตัวเดียวทั้งสำหรับการระบุตำแหน่ง (localization) และจำแนกประเภท (classification) เหมาะสำหรับการตรวจจับวัตถุแบบเรียลไทม์ และมีประสิทธิภาพในการแสดงลักษณะของวัตถุที่ดีกว่า	มีข้อจำกัดในการตรวจจับวัตถุขนาดเล็กที่อยู่รวมกัน โดยมีข้อผิดพลาดหลักเกิดจากการระบุตำแหน่งที่ไม่ถูกต้อง และมีปัญหาเกี่ยวกับการแสดงลักษณะของวัตถุที่มีอัตราส่วนภาพไม่ปกติ
SSD	สามารถฝึกแบบ End-to-end ได้ โดยใช้ CNN filters ขนาดเล็กสำหรับการคาดการณ์ประเภทของวัตถุ	มีความแม่นยำมากกว่า YOLO แต่ช้ากว่าเล็กน้อย แต่เร็วกว่า Faster R-CNN และค่าความแม่นยำดีกว่า
Mask R-CNN	ใช้สำหรับ Instance Segmentation และมีการใช้ RoIAlign layer เพื่อเพิ่มความแม่นยำในการแบ่งส่วนวัตถุ	การจำแนกประเภทวัตถุขึ้นอยู่กับกระบวนการแบ่งส่วนวัตถุที่ถูกต้อง

ที่มา : (Patel & Patel, 2020). Object Detection with Convolutional Neural Networks

2.5 You Only Look Once (YOLO) (soumyadip, 2023)

อัลกอริทึม YOLO หรือ "You Only Look Once" เปรียบเสมือนผู้บุกเบิกที่พลิกโฉมหน้าวงการตรวจจับวัตถุ ด้วยวิธีการอันเป็นเอกลักษณ์ ซึ่งต่างจากวิธีดั้งเดิมที่ยุ่งยากและซับซ้อน ที่มีแบ่งเป็นหลายขั้นตอน เริ่มต้นด้วยการหาตำแหน่งวัตถุ (Region proposals) และตามด้วยการจำแนกประเภท แต่ YOLO ทำงานด้วยความรวดเร็วเพียงรอบเดียว (Single forward pass) โดยแบ่งภาพเป็นตาราง และคาดการณ์ทั้งกล่อง (Bounding boxes) และประเภทของวัตถุพร้อมกันภายในแต่ละช่อง ส่งผลให้ทำงานได้อย่างรวดเร็วและมีความแม่นยำสูง โดยแบบจำลอง YOLO ถูกพัฒนา และปรับปรุง ทำให้มีหลายเวอร์ชัน ดังภาพประกอบที่ 37 ตารางแสดงรายละเอียดอัลกอริทึม YOLO ในแต่ละเวอร์ชัน ดังตารางที่ 34



ภาพประกอบ 37 A timeline of YOLO versions

ที่ ม ๑ : (Terven & Cordova-Esparza, 2023). A comprehensive review of YOLO: From YOLOv1 to YOLOv8 and beyond

ตาราง 34 ตารางแสดงรายละเอียดอัลกอริทึม YOLO ในแต่ละเวอร์ชัน

เวอร์ชัน	รายละเอียด
YOLOv1	YOLOv1 เปิดตัวครั้งแรก ถือเป็นก้าวปฏิวัติวงการตรวจจับวัตถุ ด้วยแนวคิดใหม่ของแบบจำลองการตรวจจับแบบ Single - stage ซึ่งแตกต่างจากวิธีเดิมที่ต้องผ่านหลายขั้นตอน YOLOv1 ไม่ต้องใช้กลไกการเสนอพื้นที่ (Region proposal) ทำให้สามารถวิเคราะห์ภาพทั้งหมดได้ในครั้งเดียว ได้อย่างมีประสิทธิภาพ
YOLOv2 และ YOLOv3	YOLOv2 และ YOLOv3 พัฒนามาต่อยอดจาก YOLOv1 ด้วยเทคนิคที่ล้ำสมัย เช่น โครงสร้าง Feature Pyramid Networks (FPN) การฝึกแบบจำลองแบบหลายขนาด และกล่อง Anchor boxes ส่งผลให้สามารถตรวจจับวัตถุได้แม่นยำและหลากหลายขึ้น โดย FPN ช่วยให้แบบจำลองเรียนรู้รายละเอียดวัตถุได้หลายขนาด การฝึกโมเดลแบบหลายขนาดช่วยให้โมเดลตรวจจับวัตถุได้หลากหลายขนาด และกล่อง Anchor boxes ช่วยให้แบบจำลองคาดการณ์ตำแหน่งวัตถุได้แม่นยำขึ้น

ตาราง 34 (ต่อ)

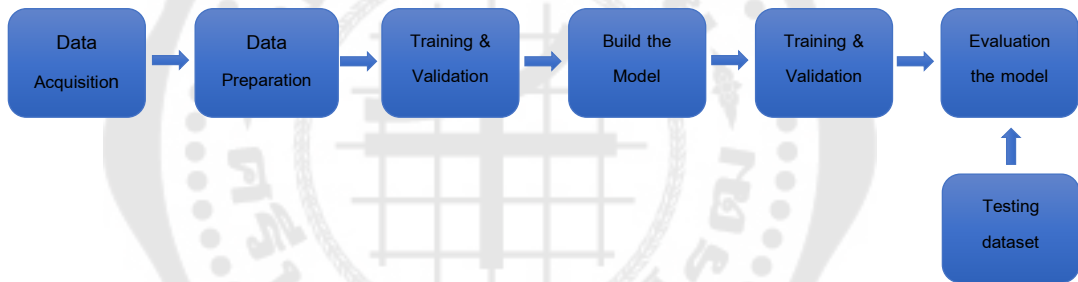
เวอร์ชัน	รายละเอียด
YOLOv4	ผู้พัฒนาได้ทุ่มเทอย่างจริงจังในการพัฒนา YOLOv4 เพื่อนำการเปลี่ยนแปลงที่ล้ำสมัยมาสู่ YOLO โดยได้มีการนำเสนอการเปลี่ยนแปลงในสถาปัตยกรรม Darknet53 ซึ่งกลายเป็น CSPDarknet53-PANet-SPP เทคนิคต่างๆ เช่น bag of specials and freebies อัลกอริทึมวิวัฒนาการทางพันธุกรรม โมดูล Attention และอื่นๆ
YOLOv5	YOLOv5 แม้จะพัฒนาต่อยอดจาก YOLOv4 ด้วยการเปลี่ยนแปลงเพียงเล็กน้อยและยังคงเทคนิคส่วนใหญ่ไว้ แต่สิ่งที่ทำให้ YOLOv5 โดดเด่นคือการใช้งาน PyTorch ทำให้การใช้งานและฝึกแบบจำลองได้อย่างง่ายดายยิ่งขึ้น โดย Ultralytics ได้ออกแบบ YOLOv5 ให้มีการใช้งานที่ง่าย การติดตั้งที่สะดวก และมีคำแนะนำการใช้งานอย่างชัดเจน
YOLO-R	ใน YOLO-R ผู้พัฒนาได้ทดลองใช้วิธีการใหม่และมุ่งพัฒนาแบบจำลองเพื่อรองรับการเรียนรู้แบบหลายงาน (Multi-task learning) เป้าหมายหลักคือเพื่อขยายขีดความสามารถของโมเดล YOLO ให้สามารถทำงานได้หลากหลายมากขึ้น โดยไม่ต้องพึ่งพาแบบจำลองแยกต่างหากสำหรับงานแต่ละประเภท
YOLO-X	YOLO-X เป็นแบบจำลองตรวจจับวัตถุที่พัฒนาต่อยอดจาก YOLOv3 โดยนำเทคนิคใหม่ๆ มาผสมรวมเข้าด้วยกัน เช่น Anchor-free, Decoupled heads, Label assignment และ strong augmentations ช่วยให้ YOLO-X มีประสิทธิภาพและความแม่นยำในการตรวจจับวัตถุที่ดีขึ้น
YOLOv6 และ YOLOv7	ใน YOLOv7 และ YOLOv6 ผู้เขียนได้ทำการทดลองกับโครงสร้างของแบบจำลอง โดยใน YOLOv7 มีการนำเสนอแนวคิดใหม่เกี่ยวกับการปรับพารามิเตอร์ใน YOLO และการปรับขนาดของแบบจำลองเป็นครั้งแรก ในขณะที่ YOLOv6 มีการเพิ่มเทคนิคของการกลั่น (Distillation) และการควอนไทเซชัน (Quantization) เข้าไปในแบบจำลองด้วย โดยแบบจำลอง YOLOv6 เหมาะสำหรับการใช้งานแบบ Real-time บนอุปกรณ์ที่มีทรัพยากรจำกัด ต้องการความเร็ว และ YOLOv7 เหมาะกับงานที่ต้องการความแม่นยำสูง บนอุปกรณ์ที่มีทรัพยากรสูง
YOLOv8	YOLOv8 นั้นมีประสิทธิภาพที่ดีกว่า เมื่อเทียบกับแบบจำลองรุ่นก่อนๆ อย่าง YOLOv3 หรือ YOLOv5 อาจดูเหมือนว่าแบบจำลองรุ่นก่อนๆ นั้นออกแบบมาซับซ้อนเกินความจำเป็น เพราะ YOLOv8 นั้นพัฒนาต่อยอดจาก YOLOv5 โดยมีการเปลี่ยนแปลงโครงสร้างเพียงเล็กน้อย แต่กลับมีประสิทธิภาพที่เหนือกว่าสาเหตุหลักๆ ที่ทำให้ YOLOv8 มีประสิทธิภาพที่ดีกว่า เนื่องจากการเปลี่ยนแปลง 2 ประการ ได้แก่ 1) การแทนที่ CSPLayer ด้วยโมดูล C2f: CSPLayer นั้นเป็นเลเยอร์หลักใน YOLOv5 ที่ทำหน้าที่เพิ่มประสิทธิภาพและลดขนาดของแบบจำลอง แต่โมดูล C2f นั้นมีประสิทธิภาพที่เหนือกว่า CSPLayer จึงทำให้ YOLOv8 ทำงานได้เร็วขึ้นและแม่นยำยิ่งขึ้น 2) การเพิ่มฟังก์ชันการสูญเสียที่ดีกว่า ฟังก์ชันการสูญเสียมีหน้าที่ในการคำนวณความแตกต่างระหว่างผลลัพธ์ที่คาดหวังกับผลลัพธ์ที่ได้จริงของแบบจำลอง การเพิ่มฟังก์ชันการสูญเสียที่ดีกว่า ช่วยให้โมเดลเรียนรู้ได้ดีขึ้น และสามารถตรวจจับวัตถุขนาดเล็กได้แม่นยำยิ่งขึ้น โดยสรุป YOLOv8 นั้นเป็นแบบจำลองตรวจจับวัตถุที่มีประสิทธิภาพสูง ใช้งานง่าย และมีขนาดเล็ก เหมาะสำหรับใช้งานบนอุปกรณ์ที่มีทรัพยากรจำกัด เช่น โทรศัพท์มือถือ หรือกล้องวงจรปิด
YOLOv-NAS	YOLO-NAS เป็นแบบจำลองตรวจจับวัตถุที่มีจุดเด่นคือ Quantization Blocks เป็นเทคโนโลยีที่ล้ำสมัยที่ช่วยเพิ่มความเร็วและความแม่นยำ ทั้งนี้ เทคโนโลยี Quantization Blocks ช่วยให้ YOLO-NAS ประหยัดพลังงาน

ที่มา : (soumyadip, 2023). Mastering All YOLO Models from YOLOv1 to YOLO-NAS: Papers Explained (2024)

บทที่ 3

กระบวนการ และวิธีการดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยมุ่งเน้นศึกษาวิธีการจำแนกความสุกของปาล์มน้ำมันสด เพื่อช่วยให้สามารถจำแนกความสุกของปาล์มน้ำมันสดได้อย่างถูกต้องแม่นยำ ทั้งนี้ เพื่อป้องกันความผิดพลาดในขั้นตอนเก็บเกี่ยว หรือขั้นตอนการคัดแยกผลปาล์ม ณ โรงงานสกัดน้ำมันปาล์ม เป็นต้น โดยผู้วิจัยเลือกใช้อัลกอริทึมที่สามารถพัฒนาไปสู่การใช้งานแบบเรียลไทม์ เพื่อนำไปสู่การประยุกต์ใช้งานได้ในสถานการณ์จริงในอนาคต ผู้วิจัยได้เลือกใช้หลักการโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ที่มีพื้นฐานจากวิธีการเรียนรู้เชิงลึก และมีประสิทธิภาพและสามารถนำมาประยุกต์ใช้ในงานวิจัยนี้ได้ ทั้งนี้ ผู้วิจัยได้ออกแบบขั้นตอนในการดำเนินงานวิจัยโดยแบ่งออกเป็นขั้นตอน ดังภาพประกอบที่ 38



ภาพประกอบ 38 แผนผังการดำเนินงานวิจัย

3.1 การเก็บรวบรวมข้อมูล (Data Acquisition)

ข้อมูลที่ใช้ในงานวิจัยนี้ เป็นข้อมูลที่อยู่ในรูปแบบของข้อมูลรูปภาพผลปาล์มน้ำมันสด โดยผู้วิจัยได้นำชุดข้อมูลดังกล่าวมาจากเว็บไซต์ Science Data Bank (Suharjito, 2023) ซึ่งเป็นชุดข้อมูลที่ถูกสร้างและจัดเก็บไว้เพื่อให้ผู้ที่สนใจนำข้อมูลไปใช้ประโยชน์ในการพัฒนาแบบจำลองที่สามารถใช้สร้างแอปพลิเคชันบนสมาร์ตโฟน หรือแอปพลิเคชันที่ฝังอยู่ในหุ่นยนต์หรืออุปกรณ์อื่น ๆ ได้ เพื่อช่วยให้การจำแนกระดับความสุกของผลปาล์มน้ำมันสดมีความอย่างแม่นยำ และถูกต้อง โดยชุดข้อมูลต้นฉบับมีระดับความสุกของปาล์มน้ำมัน จำนวน 6 หมวดหมู่ ได้แก่ ดิบ (Unripe) กึ่งสุกกึ่งดิบ (Under-ripe) สุกพอดี (Ripe) สุกเกินไป (Over-ripe) ทะลายเปล่า (Empty bunch) และทะลายผิดปกติ (Abnormal FFB)

โดยชุดข้อมูลเป็นรูปภาพต่อเนื่องที่ถูกแยกเฟรมมาจากวิดีโอของทะลายปาล์มน้ำมันสด มีจำนวนทั้งหมด 4,160 ภาพ มีความละเอียดเท่ากับ 416x416 และเป็นรูปภาพที่ผ่านการกำหนดป้ายชื่อประเภทระดับความสุก หรือการทำ Labelling เรียบร้อยแล้ว โดยข้อมูลภาพจะมี 2 ลักษณะ ได้แก่ ภาพของทะลายปาล์มน้ำมันสดที่มีระดับความสุกหมวดหมู่เดียวกัน ดังตัวอย่างภาพประกอบที่ 39(a) และจากภาพที่ 39(b) แสดงภาพของทะลายปาล์มน้ำมันสดที่มีระดับความสุกแตกต่างกัน และข้อมูลของรูปภาพที่ได้รับมาทั้งหมด ดังแสดงในตารางที่ 35



ภาพประกอบ 39 ตัวอย่างภาพของทะลายปาล์มน้ำมันสด (a) ที่มีระดับความสุกหมวดหมู่เดียวกัน (b) ที่มีระดับความสุกแตกต่างกัน

ที่มา : (Suharjito et al., 2023). Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning

ตาราง 35 แสดงการกระจายของทะลายและรูปภาพ สำหรับแต่ละหมวดหมู่

หมวดหมู่	จำนวนทะลาย	จำนวนภาพ
ดิบ	2,913	1,130
กึ่งสุกกึ่งดิบ	2,575	1,289
สุกพอดี	2,973	1,880
สุกเกินไป	2,641	1,162
ทะลายเปล่า	857	473
ทะลายผิดปกติ	2,599	1,237
รวม	14,558	7,171

ที่มา : (Suharjito et al., 2023). Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning

ชุดข้อมูลต้นฉบับได้ถูกแบ่งออกเป็น ชุดข้อมูลสำหรับฝึกอบรมแบบจำลอง (Training dataset) ข้อมูลสำหรับตรวจสอบความถูกต้องแบบจำลอง (Validation dataset) และชุดข้อมูลสำหรับการทดสอบแบบจำลอง (Testing dataset) มีอัตราส่วน 70:20:10 ดังตารางที่ 36

ตาราง 36 อัตราส่วนการแบ่งชุดข้อมูลต้นฉบับ

ชุดข้อมูล	จำนวน (ภาพ)	อัตราส่วน (เปอร์เซ็นต์)
สำหรับฝึกอบรม	2,908	70
สำหรับตรวจสอบความถูกต้อง	835	20
สำหรับการทดสอบ	417	10
Total	4,160	100

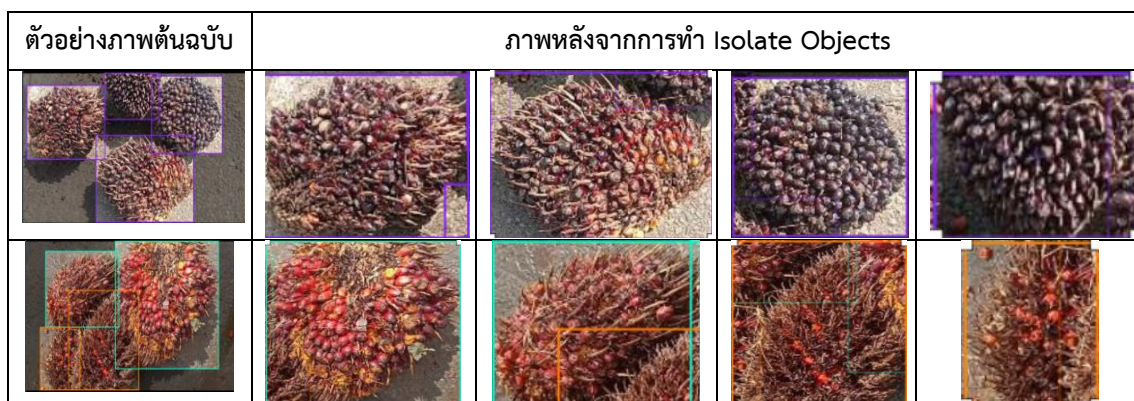
ที่มา : (Suharjito et al., 2023). Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning

3.2 การเตรียมข้อมูล (Data Preparation)

ผู้วิจัยใช้รูปภาพกองทะลายปาล์มน้ำมันสดที่ผ่านการทำ Labelling เรียบร้อยแล้ว ซึ่งเป็นข้อมูลภาพต้นฉบับ มาทำ Data preparation ด้วยเครื่องมือ Roboflow ซึ่ง Roboflow เป็นเครื่องมือที่ช่วยในการจัดการและปรับปรุงข้อมูลภาพ (Image data) สำหรับการฝึกอบรมแบบจำลองทางด้าน Computer vision โดย Roboflow มีฟีเจอร์ต่าง ๆ ที่ช่วยให้ง่ายต่อการเตรียมข้อมูลสำหรับการฝึกอบรมแบบจำลอง โดยมีขั้นตอน ดังนี้

3.2.1 การเตรียมข้อมูล (Data Preprocessing)

เพื่อให้การฝึกอบรมแบบจำลองมีความแม่นยำและมีประสิทธิภาพ ผู้วิจัยได้ใช้วิธีการทำ Isolate objects เพื่อคัดแยกภาพทะลายปาล์มน้ำมันออกเป็น 1 ทะลาย ต่อ 1 ภาพ จากเดิมเป็นรูปภาพกองทะลายปาล์มน้ำมันสด ซึ่งมีปาล์มน้ำมันหลายทะลาย ใน 1 ภาพ ดังภาพที่ 40 และทำการปรับปรุงหมวดหมู่โดยเลือกใช้หมวดหมู่ระดับความสุกของปาล์มน้ำมัน สำหรับการดำเนินการวิจัย เพียง 3 หมวดหมู่ จากทั้งหมด 6 หมวดหมู่ ได้แก่ ไม่สุกหรือดิบ (Unripe) สุกพอดี (Ripe) และ สุกเกินไป (Over-ripe) ทั้งนี้ สาเหตุที่เลือกใช้ 3 หมวดหมู่ดังกล่าว เนื่องจากเป็นหมวดหมู่ที่เกิดความผิดพลาดในการจำแนกระดับความสุกด้วยสายตาของมนุษย์ได้ง่าย



ภาพประกอบ 40 แสดงตัวอย่างการทำ Objects Isolation

3.2.2 การเพิ่มปริมาณข้อมูลภาพสอน (Data Augmentation)


การเพิ่มปริมาณข้อมูลภาพสอน (Data augmentation) เป็นการสร้างข้อมูลรูปภาพให้มีความหลากหลายและมีจำนวนเพิ่มขึ้น ผู้วิจัยได้เลือกใช้วิธีการต่าง ๆ ได้แก่ เพื่อการกลับด้านรูปภาพ (Flip) เพื่อการตัดบางส่วนของรูปภาพ (Crop) เพื่อการหมุนรูปภาพ (Rotation) เพื่อการปรับแสงสว่าง (Brightness) และเพื่อการเพิ่มสิ่งรบกวนลงในรูปภาพ (Noise)

3.2.3 การแบ่งข้อมูล (Split Data)

ผลจากการทำ Data preparation ทำให้ชุดข้อมูลที่ใช้สำหรับดำเนินงานวิจัยมีรูปภาพทั้งหมดจำนวน 14,477 ภาพ โดยชุดข้อมูลจะถูกแบ่งออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลสำหรับฝึกอบรมแบบจำลอง (Training dataset) จำนวน 11,900 ภาพ ชุดข้อมูลสำหรับตรวจสอบความถูกต้องแบบจำลอง (Validation dataset) จำนวน 1,782 ภาพ และชุดข้อมูลสำหรับการทดสอบแบบจำลอง (Testing dataset) จำนวน 795 ภาพ ดังตารางที่ 37 และแสดงดังภาพประกอบที่ 41

ตาราง 37 แสดงจำนวนชุดข้อมูลสำหรับดำเนินงานวิจัย

หมวดหมู่	ชุดข้อมูลสำหรับฝึกอบรม	ชุดข้อมูลสำหรับตรวจสอบความถูกต้อง	ชุดข้อมูลสำหรับการทดสอบ	รวม
ดิบ	4,010	642	266	4,918
สุกพอดี	4,284	585	246	5,115
สุกเกินไป	3,606	555	283	4,444
รวม	11,900	1,782	795	14,477



ภาพประกอบ 41 กราฟแสดงจำนวนข้อมูลที่ใช้ในการฝึกฝนแบบจำลอง

3.3 การฝึกฝนแบบจำลอง (Training and Validation Model)

สำหรับขั้นตอนการฝึกฝนแบบจำลอง ผู้วิจัยได้เลือกใช้แบบจำลองที่สามารถพัฒนาไปสู่การใช้งานแบบเรียลไทม์ได้ในอนาคต โดยเลือกใช้แบบจำลอง You Only Look Once หรือ YOLO ผู้วิจัยได้เลือกใช้แบบจำลอง YOLOv8 ซึ่งเป็นเวอร์ชันใหม่ล่าสุดที่ถูกพัฒนาขึ้นมาในปี พ.ศ. 2566 โดย YOLOv8 มีแบบจำลองต่าง ๆ ได้แก่ YOLOv8n (nano), YOLOv8s (small), YOLOv8m (medium), YOLOv8l (large), YOLOv8x ดังตารางที่ 38 แสดงค่า mAP และค่า FPS ของ YOLOv8 แต่ละแบบจำลอง ทั้งนี้ ผู้วิจัยเลือกใช้แบบจำลองที่มีขนาดเล็กอย่าง YOLOv8n (nano) เนื่องจากมีจำนวนพารามิเตอร์น้อย ประมวลผลเร็ว และใช้พื้นที่หน่วยความจำในการประมวลผลน้อย และมีความแม่นยำสูง ด้วยเหตุผลดังกล่าวข้างต้น จึงทำให้แบบจำลองขนาดเล็กอย่าง YOLOv8n เหมาะสำหรับแอปพลิเคชันที่ต้องใช้การประมวลผลแบบเรียลไทม์ และเหมาะกับอุปกรณ์ที่มีทรัพยากรจำกัด โดยแบบจำลองดังกล่าวได้รับการฝึกฝนด้วยชุดข้อมูล Common Objects in Context หรือ COCO โดย COCO เป็นชุดข้อมูลภาพขนาดใหญ่สำหรับการฝึกอบรมแบบจำลองการรู้จำวัตถุ และการตรวจจับวัตถุ ชุดข้อมูลประกอบด้วยภาพมากกว่า 330,000 ภาพ แบ่งออกเป็น 80 คลาส ของวัตถุ (Ultralytics, 2024) ดังนั้นเพื่อปรับปรุงประสิทธิภาพของแบบจำลองดังกล่าว เพื่อใช้ในการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ผู้วิจัยจึงต้องฝึกฝนแบบจำลองด้วยชุดข้อมูลที่ได้เตรียมไว้สำหรับงานวิจัยนี้ เพื่อให้แบบจำลองสามารถทำนายระดับความสุกของผลปาล์มน้ำมันสดได้ตามที่กำหนด

ตาราง 38 แสดงค่าความสามารถของแบบจำลอง YOLOv8

Model	Size (pixel)	mAPval 50-95	Speed	Speed	Params (M)	FLOPs (B)
			CPU ONNX (ms)	A100 TensorRT (ms)		
YOLOv8n	640	37.3	80.4	0.99	3.2	8.7
YOLOv8s	640	44.9	128.4	1.20	11.2	28.6
YOLOv8m	640	50.2	234.7	1.83	25.9	78.9
YOLOv8l	640	52.9	375.2	2.39	43.7	165.2
YOLOv8x	640	53.9	479.1	3.53	68.2	257.8

*mAPval values are for single-model single-scale on COCO val2017 dataset. Reproduce by yolo val detect data=coco.yaml device=0

*Speed averaged over COCO val images using an Amazon EC2 P4d instance. Reproduce by yolo val detect data=coco128.yaml batch=1 device=0|cpu

ที่มา : (Ultralytics, 2024). Ultralytics YOLOv8 Docs

3.4 การประเมินผลการทดลอง (Model Evaluation)

การประเมินประสิทธิภาพของแบบจำลองตรวจจับวัตถุ แบ่งออกเป็น 2 ส่วน ดังนี้

3.4.1 การประเมินความสามารถในการจำแนกวัตถุ

การประเมินความสามารถในการจำแนกวัตถุ สามารถประเมินได้จากตัวชี้วัดต่าง ๆ ดังนี้

1) Confusion Matrix ใช้ในการประเมินผลการทำนาย หรือ Prediction ที่ทำนายจากแบบจำลองที่สร้างขึ้น เพื่อแสดงผลลัพธ์ของการทำนายว่าตรงกับค่าจริงมากน้อยเพียงใด ดังแสดงในตารางที่ 39 ที่ประกอบด้วยค่าต่าง ๆ ดังนี้ True Positive (TP): แบบจำลองทำนายถูก ว่าข้อมูลเป็นคลาส Positive และข้อมูลนั้นเป็นคลาส Positive False Positive (FP): แบบจำลองทำนายผิด ว่าข้อมูลเป็นคลาส Positive แต่ข้อมูลนั้นเป็นคลาส Negative True Negative (TN): แบบจำลองทำนายถูก ว่าข้อมูลเป็นคลาส Negative และข้อมูลนั้นเป็นคลาส Negative False Negative (FN): แบบจำลองทำนายผิด ว่าข้อมูลเป็นคลาส Negative แต่ข้อมูลนั้นเป็นคลาส Positive

ตาราง 39 ตารางแสดงค่า Confusion Matrix

	Actual Positive (1)	Actual Negative (0)
Predicted Positive (1)	True Positive	False Positive
Predicted Negative (0)	False Negative	True Negative

ที่มา : (B.V., 2024). Confusion Matrix

2) Precision เป็นหนึ่งในตัวชี้วัดความแม่นยำของแบบจำลองในงานจำแนกวัตถุ (Object Classification) โดยค่า Precision จะวัดความแม่นยำของการทำนายว่าเป็นคลาสบวก (Positive class) โดยการนับจำนวน True Positives (TP) และ False Positives (FP) ทั้งนี้ ค่า Precision มีค่าอยู่ในช่วง $[0, 1]$ โดยค่าที่มากขึ้นแสดงว่าการทำนายว่าเป็นคลาสบวกของแบบจำลองมีความแม่นยำมากขึ้น

$$\text{Precision} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Positive}}$$

3) Recall เป็นตัวชี้วัดที่ใช้วัดสัดส่วนของค่า Positive จริงทั้งหมดที่ทำนายถูกต้อง คือ True Positivesหารด้วยทั้งหมดของ Ground truths (ค่าจริงทั้งหมด) เพื่อประเมินว่าแบบจำลองสามารถระบุข้อมูลที่เป็นค่าบวก (Positive) ได้ทั้งหมดมากเพียงใด มีค่าอยู่ในช่วง $[0, 1]$ โดยค่าที่มากขึ้นแสดงว่าแบบจำลองมีความสามารถในการตรวจจับคลาสบวกมีประสิทธิภาพมากขึ้น


$$\text{Recall} = \frac{\text{True Positive}}{\text{True Positive} + \text{False Negative}}$$

4) Average Precision (AP) เป็นหนึ่งในตัวชี้วัดที่ใช้ในการประเมินความแม่นยำของแบบจำลองในงานตรวจจับวัตถุ (Object detection) ค่านี้ใช้ในการวัดประสิทธิภาพของโมเดลในการตรวจจับและจำแนกวัตถุที่มีหลายหมวดหมู่ คำนวณจาก Precision-Recall Curve ซึ่งเป็นกราฟที่แสดงความสัมพันธ์ระหว่าง Precision และ Recall ที่เปลี่ยนแปลงตามการปรับค่าความเชื่อมั่น (Confidence threshold) ของแบบจำลอง มีค่าอยู่ในช่วง $[0, 1]$ โดยค่าที่สูงกว่าแสดงถึงประสิทธิภาพที่ดีขึ้นในการตรวจจับและจำแนกวัตถุ

$$AP = \int_0^1 p(r)dr$$

5) Mean Average Precision (mAP) เป็นตัวชี้วัดที่ใช้ในการประเมินประสิทธิภาพของโมเดลในงานตรวจจับวัตถุ (Object detection) ที่มีหลายหมวดหมู่ โดยการคำนวณค่า Average Precision (AP) ของแต่ละคลาสแยกต่างหาก แล้วนำมาหาค่าเฉลี่ย ซึ่งสะท้อนถึงประสิทธิภาพโดยรวมของแบบจำลองในการตรวจจับวัตถุจากคลาสต่าง ๆ ตัวอย่างเช่น ถ้าแบบจำลองสามารถตรวจจับคลาส "คน" ได้ด้วย AP = 0.8 และคลาส "รถ" ได้ด้วย AP = 0.7 ดังนั้น ค่า mAP ของแบบจำลองจะเท่ากับ $(0.8 + 0.7) / 2 = 0.75$

$$mAP = \frac{1}{n} * \text{sum}(AP)$$



บทที่ 4

การทดลอง และผลลัพธ์ของการวิจัย

งานวิจัยนี้ได้ดำเนินการโดยใช้ภาษา Python และ ultralytics libraries โดยใช้ GPU T4 ด้วย Google Colab โดยผู้วิจัยได้ทำการฝึกฝนแบบจำลอง YOLOv8n (Pretrained Weight) ซึ่งเป็น Weight ที่ได้จากการฝึกฝนด้วยชุดข้อมูล COCO test-dev 2017 โดยมีการกำหนดค่าพารามิเตอร์ต่าง ๆ สำหรับปรับแต่งแบบจำลอง

4.1 การปรับแต่งแบบจำลอง YOLOv8n

ในงานวิจัยนี้ได้ทำการปรับแต่งแบบจำลองโดยการกำหนดค่าพารามิเตอร์ต่าง ๆ เพื่อหาแบบจำลอง YOLOv8n ที่ดีที่สุดสำหรับการจำแนกระดับความสูงของปาล์มน้ำมันสด

4.1.1 Optimizer

เป็นอัลกอริทึมที่ใช้ในกระบวนการการฝึก (Training) แบบจำลอง เป้าหมายหลักของ Optimizer คือการปรับค่าพารามิเตอร์ของแบบจำลองเพื่อลดค่าฟังก์ชันความสูญเสีย (Loss function) หรือเพื่อให้แบบจำลองทำนายผลลัพธ์ที่ถูกต้องมากขึ้น นอกจากนี้ยังมีผลต่อความเร็วและประสิทธิภาพในการฝึกแบบจำลองอีกด้วย โดยในงานวิจัยนี้ใช้ Optimizer ที่แตกต่างกัน 2 ชนิด เพื่อเปรียบเทียบกัน ได้แก่

- 1) Stochastic Gradient Descent (SGD)
- 2) Adaptive Moment Estimation (Adam)

4.1.2 Learning rate

Learning rate คือค่าที่กำหนดขนาดของการเปลี่ยนแปลงพารามิเตอร์ (Weight) ของแบบจำลองในการเรียนรู้แต่ละรอบ เปรียบเสมือนความเร็วในการปรับตัวของแบบจำลอง หน้าที่หลักของ Learning rate คือการควบคุมขนาดของการเปลี่ยนแปลงพารามิเตอร์ของแบบจำลองตามผลลัพธ์ที่ได้จากการฝึกฝน หาก Learning rate มีค่าสูง แบบจำลองก็จะปรับตัวเร็วขึ้น แต่เสี่ยงที่จะกระโดดข้ามจุดที่เป็นคำตอบที่ดีที่สุด (Global minimum) ได้ ในทางกลับกัน ถ้า Learning rate มีค่าต่ำ แบบจำลองจะปรับตัวช้าลง ใช้เวลานานในการฝึกฝนนาน และอาจติดอยู่ในหลุมคำตอบที่ไม่ดี (Local minimum) ได้ โดยในงานวิจัยนี้ได้ทดลองใช้ Learning rate ด้วยค่าที่แตกต่างกัน ได้แก่ 0.01 0.001 และ 0.0001

4.1.3. Batch Size

Batch size คือ จำนวนตัวอย่างข้อมูล (รูปภาพ) ที่แบบจำลองจะใช้ในการปรับพารามิเตอร์แต่ละรอบของการเรียนรู้ ทั้งนี้ ขนาดของ Batch size ส่งผลต่อการเรียนรู้ของแบบจำลองในด้านต่าง ๆ ได้แก่ ความเร็วในการเรียนรู้ ความเสถียรของการเรียนรู้ การใช้หน่วยความจำ เป็นต้น โดยในงานวิจัยนี้ได้เลือกใช้ Batch size จำนวน 4 ขนาด ได้แก่ 16 32 64 และ 128

4.2 ผลการเปรียบเทียบแบบจำลอง

ในงานวิจัยนี้ได้ทำการปรับแต่งแบบจำลอง YOLOv8n ด้วยการกำหนดค่าพารามิเตอร์ต่าง ๆ ได้แก่ Optimizer จำนวน 2 ชนิด Learning rate จำนวน 3 ค่า และ Batch Size จำนวน 4 ขนาด และ กำหนดจำนวนรอบในการฝึกฝนแบบจำลองเท่ากับ 80 Epochs ดังนั้น ทำให้ได้แบบจำลองเพื่อทำการเปรียบเทียบประสิทธิภาพทั้งหมดจำนวน 24 แบบจำลอง ดังแสดงผลลัพธ์ในตารางที่ 40

ตาราง 40 แสดงผลการทดสอบประสิทธิภาพแบบจำลอง ด้วยการกำหนดค่าพารามิเตอร์ต่าง ๆ เพื่อเปรียบเทียบค่า Precision Recall mAP50 mAP50-95 และ Training time

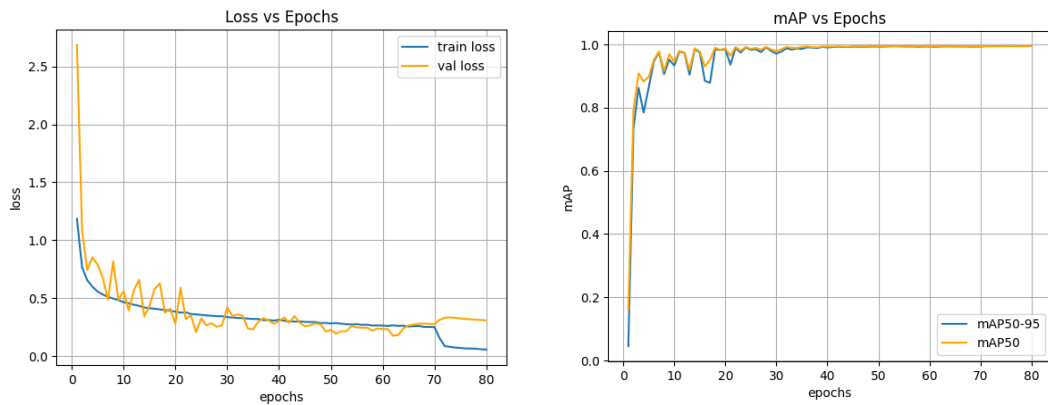
Parameter			Result				
Optimizer	Learning rate	Batch size	Precision	Recall	mAP50	mAP50-95	Training time (hrs)
SGD	0.01	16	0.995	0.997	0.995	0.994	1.643
SGD	0.01	32	0.995	0.997	0.995	0.995	1.229
SGD	0.01	64	0.997	0.996	0.995	0.995	1.000
SGD	0.01	128	0.997	0.997	0.995	0.995	0.942
SGD	0.001	16	0.995	0.995	0.993	0.993	1.730
SGD	0.001	32	0.995	0.995	0.994	0.994	1.122
SGD	0.001	64	0.996	0.995	0.995	0.995	1.074
SGD	0.001	128	0.994	0.995	0.994	0.994	0.953
SGD	0.0001	16	0.960	0.966	0.988	0.988	1.664
SGD	0.0001	32	0.948	0.967	0.986	0.986	1.225
SGD	0.0001	64	0.956	0.940	0.983	0.983	1.093
SGD	0.0001	128	0.944	0.937	0.975	0.975	1.082

ตาราง 40 (ต่อ)

Parameter			Result				
Optimizer	Learning rate	Batch size	Precision	Recall	mAP50	mAP50-95	Training time (hrs)
Adam	0.01	16	0.972	0.973	0.991	0.984	1.757
Adam	0.01	32	0.928	0.945	0.979	0.968	1.261
Adam	0.01	64	0.962	0.943	0.984	0.969	1.638
Adam	0.01	128	0.942	0.946	0.986	0.979	1.478
Adam	0.001	16	0.993	0.994	0.995	0.995	1.739
Adam	0.001	32	0.998	0.996	0.995	0.995	1.189
Adam	0.001	64	0.995	0.996	0.995	0.995	1.649
Adam	0.001	128	0.997	0.996	0.995	0.995	1.478
Adam	0.0001	16	0.993	0.997	0.994	0.994	1.827
Adam	0.0001	32	0.998	0.997	0.995	0.995	1.900
Adam	0.0001	64	0.990	0.994	0.995	0.995	1.601
Adam	0.0001	128	0.992	0.990	0.994	0.994	1.431

จากตารางที่ 40 ผลการประเมินประสิทธิภาพแบบจำลองด้วยชุดข้อมูล Testing dataset จะเห็นได้ว่า YOLOv8n มีประสิทธิภาพดีที่สุด ด้วยค่าพารามิเตอร์ต่าง ๆ ดังนี้ Adam Optimizer, Learning rate = 0.0001, Batch size = 32 ทั้งนี้ ผลลัพธ์จากการประเมินแบบจำลอง มีค่า Precision = 0.998, Recall = 0.997, mAP50 = 0.995 และ mAP50-95 = 0.995

นอกจากนี้ จากการฝึกอบรมของแบบจำลองที่มีประสิทธิภาพดีที่สุด แสดงกราฟค่าความสูญเสียและค่าความแม่นยำระหว่างการฝึกอบรมแบบจำลอง ดังภาพประกอบที่ 42 และแสดงภาพรวมการฝึกอบรมและตรวจสอบความถูกต้องของแบบจำลอง ดังภาพประกอบที่ 43 รวมทั้งแสดงค่า Confusion Matrix ของแบบจำลองที่ประเมินด้วยชุดข้อมูล Validation dataset ดังภาพประกอบที่ 44



ภาพประกอบ 42 กราฟแสดงค่าความสูญเสีย (loss) และค่าความแม่นยำ (mAP) ของ YOLOv8n ที่มีประสิทธิภาพดีที่สุด

```

80 epochs completed in 1.900 hours.
Optimizer stripped from /content/drive/MyDrive/IS/IS_Yolov8n_Result/Adam/Batch size 32/0.0001lr/Train-Adam80e32b0.0001lr/weights/last.pt, 6.2MB
Optimizer stripped from /content/drive/MyDrive/IS/IS_Yolov8n_Result/Adam/Batch size 32/0.0001lr/Train-Adam80e32b0.0001lr/weights/best.pt, 6.2MB

Validating /content/drive/MyDrive/IS/IS_Yolov8n_Result/Adam/Batch size 32/0.0001lr/Train-Adam80e32b0.0001lr/weights/best.pt...
Ultralytics YOLOv8.1.1 Python-3.10.12 torch-2.1.0+cu121 CUDA:0 (Tesla T4, 15102MiB)
Model summary (fused): 168 layers, 3006233 parameters, 0 gradients, 8.1 GFLOPs

```


Class	Images	Instances	Box(P)	R	mAP50	mAP50-95
all	1782	1782	0.991	0.996	0.994	0.994
Over Ripe	1782	555	0.998	0.997	0.995	0.995
Ripe	1782	585	0.981	0.995	0.994	0.994
Unripe	1782	642	0.994	0.997	0.993	0.993

```

Speed: 0.0ms preprocess, 0.5ms inference, 0.0ms loss, 1.6ms postprocess per image
Results saved to /content/drive/MyDrive/IS/IS_Yolov8n_Result/Adam/Batch size 32/0.0001lr/Train-Adam80e32b0.0001lr

```

ภาพประกอบ 43 ภาพรวมการฝึกอบรมและตรวจสอบความถูกต้องของแบบจำลองที่มีประสิทธิภาพดีที่สุด ด้วย YOLOv8n weight และชุดข้อมูลผลปาล์มน้ำมันสด



ภาพประกอบ 44 ภาพแสดง Confusion Matrix Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Validation dataset

ทั้งนี้ การประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Testing dataset จำนวน 795 ภาพ แสดงผลลัพธ์ดังภาพประกอบที่ 45

```

Ultralytics YOLOv8.2.5 Python-3.10.12 torch-2.2.1+cu121 CUDA:0 (Tesla T4, 15102MiB)
Model summary (fused): 168 layers, 3006233 parameters, 0 gradients, 8.1 GFLOPs
Downloading https://ultralytics.com/assets/Arial.ttf to /root/.config/Ultralytics/Arial.ttf...
100%|██████████| 755k/755k [00:00<00:00, 18.3MB/s]
val: Scanning /content/drive/MyDrive/IS/Dataset/IS.v3i.yolov8/test/labels.cache... 795 images, 0 backgrounds, 0 corrupt: 100%|██████████| 795/795 [00:00<?, ?it/s]
Class Images Instances Box(P R mAP50 mAP50-95): 100%|██████████| 50/50 [00:24<00:00, 2.04it/s]
  all 795 795 0.998 0.997 0.995 0.995
  Over Ripe 795 283 1 1 0.995 0.995
  Ripe 795 246 0.995 0.996 0.995 0.995
  Unripe 795 266 0.998 0.996 0.995 0.995
Speed: 0.1ms preprocess, 2.2ms inference, 0.0ms loss, 4.8ms postprocess per image
Results saved to /content/drive/MyDrive/IS/IS_Yolov8n_Result/Adam/Batch size 32/0.0001lr/Test-Adam80e32b0.0001lr2

```

ภาพประกอบ 45 ภาพแสดงการประเมินประสิทธิภาพของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Testing dataset

4.3 การทดสอบแบบจำลองด้วยชุดข้อมูลแหล่งอื่นเพิ่มเติม

จากการเปรียบเทียบแบบจำลองทั้งหมดจำนวน 24 แบบจำลอง ตามข้อ 4.2 พบว่าแบบจำลองที่มีประสิทธิภาพดีที่สุด ด้วยค่าพารามิเตอร์ต่าง ๆ ได้แก่ Adam Optimizer, Learning rate = 0.0001, Batch size = 32 ทั้งนี้ ผู้วิจัยได้ดำเนินการทดสอบแบบจำลองดังกล่าวเพิ่มเติมด้วยชุดข้อมูลจากแหล่งอื่น โดยชุดข้อมูลภาพที่นำมาทดสอบเพิ่มเติม เป็นชุดข้อมูลภาพทะเล

ปาล์มน้ำมันจากอินเทอร์เน็ต จำนวน 317 ภาพ โดยแบ่งออกเป็น ระดับสุกเกินไป (Over-ripe) จำนวน 96 ภาพ ระดับสุกพอดี (Ripe) จำนวน 102 ภาพ และระดับไม่สุกหรือดิบ (Unripe) จำนวน 119 ภาพ


ผลลัพธ์จากการประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุด ด้วยชุดข้อมูลจากแหล่งอื่น มี ค่า Precision = 0.969, Recall = 0.965, mAP50 = 0.993 และ mAP50-95 = 0.669 ดึงภาพประกอบที่ 46 และแสดงตัวอย่างชุดข้อมูลพร้อมตัวอย่างผลการทำนาย ดึงภาพประกอบที่ 47 – 48

```

Ultralytics YOLOv8.2.4 Python-3.10.12 torch-2.2.1+cu121 CUDA:0 (Tesla T4, 15102MiB)
val: Scanning /content/drive/MyDrive/IS/Dataset/Add.v11.yolov8/test/labels... 317 images, 0 backgrounds, 0 corrupt: 100% ██████████ 317/317 [01:21<00:00, 3.90It/s]
val: New cache created: /content/drive/MyDrive/IS/Dataset/Add.v11.yolov8/test/labels.cache
/usr/lib/python3.10/multiprocessing/popen_fork.py:66: RuntimeWarning: os.fork() was called. os.fork() is incompatible with multithreaded code, and JAX is multithreaded, so this will likely lead to a deadlock.
self.pid = os.fork()
Class  Images  Instances  Box(P  R  mAP50  mAP50-95): 100% ██████████ 20/20 [00:03<00:00, 5.85It/s]
all    317    317    0.969  0.965  0.993  0.669
Over Ripe  317    96    0.992  0.927  0.993  0.655
Ripe     317    102   0.94   0.971  0.991  0.65
Unripe   317    119   0.975  0.997  0.994  0.701
Speed: 0.1ms preprocess, 3.7ms inference, 0.0ms loss, 2.3ms postprocess per image
Results saved to /content/drive/MyDrive/IS/IS_Yolov8n_Result/Adam/Batch size 32/0.0001lr/Test-Adam80e32b0.0001lrAdd10

```

ภาพประกอบ 46 ผลการประเมินแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุดด้วย
ด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม



ภาพประกอบ 47 ภาพแสดงตัวอย่างชุดข้อมูลที่ใช้ทดสอบเพิ่มเติม พร้อม Label กำกับ



ภาพประกอบ 48 ภาพแสดงตัวอย่างผลการทำนายระดับความสุกของปาล์มน้ำมันสด
ด้วยชุดข้อมูลเพิ่มเติมจากแหล่งอื่น

บทที่ 5

การสรุปผลการวิจัย การอภิปรายผล และข้อเสนอแนะของการวิจัย

จากงานวิจัยนี้ ผู้วิจัยได้ประเมินประสิทธิภาพของแบบจำลองแต่ละแบบจำลองเพื่อนำมาเปรียบเทียบและสรุปผล โดยสามารถแบ่งหัวข้อในการสรุปผลได้ดังต่อไปนี้

- 5.1 สรุปผลการวิจัย
- 5.2 อภิปรายผลการวิจัย
- 5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ระดับความสุกของผลปาล์มน้ำมัน มีผลโดยตรงต่อคุณภาพของน้ำมันปาล์ม เพราะผลปาล์มน้ำมันที่มีระดับความสุกพอดีเมื่อถูกสกัดแล้วจะทำให้ได้น้ำมันปาล์มที่มีคุณภาพสูง ดังนั้นหากเกิดความผิดพลาดในขั้นตอนการจำแนกระดับความสุกของปาล์มน้ำมันสดและเก็บเกี่ยวไม่ถูกต้อง ส่งผลให้เกิดความเสียหายและสูญเสียรายได้ต่อเกษตรกรได้ เพราะหากเก็บเกี่ยวผลปาล์มน้ำมันสดที่ไม่มีคุณภาพเช่น เกษตรกรเก็บเกี่ยวทะลายปาล์มน้ำมันที่ไม่สุกหรือดิบไปขาย อาจทำให้โรงงานสกัดน้ำมันปาล์มปฏิเสธการรับซื้อได้ โดยปัจจุบันในขั้นตอนการเก็บเกี่ยวหรือการตัดแยกคุณภาพผลปาล์มที่โรงงานสกัดน้ำมันปาล์ม เกษตรกรหรือผู้ที่เกี่ยวข้องจะดำเนินการจำแนกระดับความสุกผลปาล์มน้ำมันสด โดยการตรวจสอบด้วยสายตา (สังเกตจากสีของเปลือกผิว) ซึ่งการตรวจสอบด้วยสายตามนุษย์นั้น อาจทำให้เกิดความผิดพลาดได้ง่าย ด้วยปัจจัยต่าง ๆ เช่น เกษตรกรที่มีประสบการณ์ในการเก็บเกี่ยวน้อย สภาพแสง ระยะเวลาสูงของต้นปาล์ม เป็นต้น

งานวิจัยนี้จึงนำเสนอวิธีการจำแนกระดับความสุกของปาล์มน้ำมันสด โดยใช้การเรียนรู้เชิงลึก ผู้วิจัยเลือกใช้แบบจำลองการเรียนรู้เชิงลึกสำหรับการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ที่สามารถพัฒนาไปสู่การใช้งานแบบเรียลไทม์ เพื่อเป็นแนวทางในการประยุกต์วิธีการจำแนกระดับความสุกของผลปาล์มน้ำมันสด ให้สามารถใช้งานได้กับสถานการณ์จริงในอนาคต โดยเลือกแบบจำลองการเรียนรู้เชิงลึกที่มีหลักการของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้แก่ แบบจำลอง You Only Look Once version 8 nano (YOLOv8n) ซึ่งเป็นเวอร์ชันที่ถูกพัฒนาขึ้นมาใน ปี พ.ศ. 2566 โดยผู้วิจัยเลือกใช้แบบจำลองที่มีขนาดเล็กอย่าง YOLOv8n เนื่องจากมีจำนวนพารามิเตอร์น้อย ประมวลผลเร็ว และใช้พื้นที่หน่วยความจำในการประมวลผลน้อย และมีความแม่นยำสูง ด้วยเหตุผลดังกล่าวข้างต้น จึงทำให้แบบจำลองขนาดเล็กอย่าง

YOLOv8n น่าจะเหมาะสำหรับแอปพลิเคชันที่ต้องการประมวลผลแบบเรียลไทม์ และเหมาะกับอุปกรณ์ที่มีทรัพยากรจำกัด

ชุดข้อมูลรูปภาพที่ใช้สำหรับการวิจัย ได้รับมาจากเว็บไซต์ Science Data Bank (Public dataset) ซึ่งเป็นรูปภาพผลปาล์มน้ำมันลักษณะ “Nigrescens” โดยผลดิบจะมีสีดำปลายผลและมีสีงาช้างที่ขั้วผล และจะเปลี่ยนเป็นสีแดงเมื่อผลสุก สำหรับขั้นตอนการเตรียมข้อมูล ผู้วิจัยได้นำข้อมูลภาพต้นฉบับมาทำ Data preparation ด้วยเครื่องมือ Roboflow เพื่อให้การฝึกอบรมแบบจำลองมีความแม่นยำและมีประสิทธิภาพ ผู้วิจัยได้ใช้วิธีการทำ Isolate objects เพื่อคัดแยกภาพทะเลาะปาล์มน้ำมันออกเป็น 1 ทะละย ต่อ 1 ภาพ จากเดิมเป็นรูปภาพของทะเลาะปาล์มน้ำมันสด ซึ่งมีปาล์มน้ำมันหลายทะละย ใน 1 ภาพ และทำการปรับปรุงหมวดหมู่โดยเลือกใช้หมวดหมู่ระดับความสุกของปาล์มน้ำมัน สำหรับการดำเนินการวิจัย เพียง 3 หมวดหมู่ จากทั้งหมด 6 หมวดหมู่ ได้แก่ ไม่สุกหรือดิบ (Unripe) สุกพอดี (Ripe) และ สุกเกินไป (Over-ripe) ทั้งนี้ สาเหตุที่เลือกใช้ 3 หมวดหมู่ดังกล่าว เนื่องจากเป็นหมวดหมู่ที่เกิดความผิดพลาดในการจำแนกระดับความสุกด้วยสายตาของมนุษย์ได้ง่าย หลังจากนั้นได้ทำการเพิ่มปริมาณข้อมูลภาพสอน (Data augmentation) เพื่อสร้างข้อมูลรูปภาพให้มีความหลากหลายและมีจำนวนเพิ่มขึ้น ผู้วิจัยได้เลือกใช้วิธีการต่าง ๆ ได้แก่ เพื่อการกลับด้านรูปภาพ (Flip) เพื่อการตัดบางส่วนของรูปภาพ (Crop) เพื่อการหมุนรูปภาพ (Rotation) เพื่อการปรับแสงสว่าง (Brightness) และเพื่อการเพิ่มสิ่งรบกวนลงในรูปภาพ (Noise) ทำให้มีรูปภาพที่ใช้สำหรับการวิจัยมีทั้งหมดจำนวน 14,477 ภาพ โดยชุดข้อมูลจะถูกแบ่งออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลสำหรับฝึกอบรมแบบจำลอง (Training dataset) จำนวน 11,900 ภาพ ชุดข้อมูลสำหรับตรวจสอบความถูกต้องแบบจำลอง (Validation dataset) จำนวน 1,782 ภาพ และชุดข้อมูลสำหรับการทดสอบแบบจำลอง (Testing dataset) จำนวน 975 ภาพ


ในงานวิจัยนี้ ได้ทำการปรับแต่งแบบจำลอง YOLOv8n ด้วยการกำหนดค่าพารามิเตอร์ต่าง ๆ ได้แก่ Optimizer จำนวน 2 ชนิด ได้แก่ 1) Stochastic Gradient Descent (SGD) 2) Adaptive Moment Estimation (Adam) Learning rate จำนวน 3 ค่า ได้แก่ 0.01 0.001 และ 0.0001 และ Batch Size จำนวน 4 ขนาด 16 32 64 128 โดยกำหนดจำนวนรอบในการฝึกฝนแบบจำลองเท่ากับ 80 Epochs ดังนั้น ทำให้ได้แบบจำลองเพื่อทำการเปรียบเทียบประสิทธิภาพทั้งหมดจำนวน 24 แบบจำลอง จากการทดลองและผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง YOLOv8n ด้วยการปรับแต่งแบบจำลองโดยการกำหนดค่าพารามิเตอร์ต่าง ๆ ซึ่งผลลัพธ์จากการทดลองแสดงให้เห็นว่าแบบจำลองที่มีประสิทธิภาพดีที่สุดสำหรับการจำแนกระดับ

ความสุกของปาล์มน้ำมันสด ด้วยแบบจำลอง YOLOv8n ที่มีค่าพารามิเตอร์ต่าง ๆ ดังนี้ Adam Optimizer, Learning rate = 0.0001, Batch size = 32 ทั้งนี้ ผลลัพธ์จากการประเมินแบบจำลอง ด้วยชุดข้อมูล Testing dataset มีค่า Precision = 0.998, Recall = 0.997, mAP50 = 0.995 และ mAP50-95 = 0.995

นอกจากนี้ ผู้วิจัยได้ทำการประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุดเพิ่มเติม โดยใช้ชุดข้อมูลจากแหล่งอื่น โดยเป็นชุดข้อมูลภาพถ่ายลายปาล์มน้ำมันจากอินเทอร์เน็ต จำนวน 317 ภาพ แบ่งออกเป็น ระดับสุกเกินไป (Over-ripe) จำนวน 96 ภาพ ระดับสุกพอดี (Ripe) จำนวน 102 ภาพ และระดับไม่สุกหรือดิบ (Unripe) จำนวน 119 ภาพ ซึ่งให้ค่าผลลัพธ์ ดังนี้ Precision = 0.969, Recall = 0.965, mAP50 = 0.993 และ mAP50-95 = 0.669

5.2 อภิปรายผลการวิจัย

5.2.1 การประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุดด้วยชุดข้อมูล Testing dataset



ภาพประกอบ 49 ภาพแสดง Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Testing dataset


จาก Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูล Testing dataset ดังแสดงในภาพประกอบที่ 49 สามารถอธิบายได้ดังนี้

1) คลาสที่สุกเกินไป (Over-ripe) มีจำนวนรูปภาพสำหรับการทดสอบทั้งหมดจำนวน 283 ภาพ ค่าความแม่นยำในการทำนายของคลาสนี้มีค่าเท่ากับ 99.29 เปอร์เซ็นต์ โดยทำนายถูกต้องจำนวน 281 ภาพ และทำนายผิดพลาดเป็นคลาสสุกพอดี (Ripe) จำนวน 2 ภาพ

2) คลาสที่สุกพอดี (Ripe) มีจำนวนรูปภาพสำหรับการทดสอบทั้งหมดจำนวน 246 ภาพ ค่าความแม่นยำในการทำนายของคลาสนี้มีค่าเท่ากับ 99.59 เปอร์เซ็นต์ โดยทำนายถูกต้องจำนวน 245 ภาพ และทำนายผิดพลาดเป็นคลาสดิบ (Unripe) จำนวน 1 ภาพ

3) คลาสที่ไม่สุกหรือดิบ (Unripe) มีจำนวนรูปภาพสำหรับการทดสอบทั้งหมดจำนวน 266 ภาพ ค่าความแม่นยำในการทำนายของคลาสนี้มีค่าเท่ากับ 99.62 เปอร์เซ็นต์ โดยทำนายถูกต้องจำนวน 265 ภาพ และทำนายผิดพลาดเป็นคลาสสุกพอดี (Ripe) จำนวน 1 ภาพ

5.2.2 การประเมินแบบจำลองที่มีประสิทธิภาพดีที่สุดด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม



ภาพประกอบ 50 ภาพแสดง Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม

จาก Confusion Matrix ของแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม ดังแสดงในภาพประกอบที่ 50 สามารถอธิบายได้ดังนี้

1) คลาสที่สุกเกินไป (Over-ripe) มีจำนวนรูปภาพสำหรับการทดสอบทั้งหมดจำนวน 96 ภาพ ค่าความแม่นยำในการทำนายของคลาสนี้มีค่าเท่ากับ 93.75 เปอร์เซ็นต์ โดยทำนายถูกต้องจำนวน 90 ภาพ และทำนายผิดพลาดเป็นคลาสสุกพอดี (Ripe) จำนวน 6 ภาพ

2) คลาสที่สุกพอดี (Ripe) มีจำนวนรูปภาพสำหรับการทดสอบทั้งหมดจำนวน 102 ภาพ ค่าความแม่นยำในการทำนายของคลาสนี้มีค่าเท่ากับ 98.04 เปอร์เซ็นต์ โดยทำนายถูกต้องจำนวน 100 ภาพ และทำนายผิดพลาดเป็นคลาสดิบ (Unripe) จำนวน 2 ภาพ

3) คลาสที่ไม่สุกหรือดิบ (Unripe) มีจำนวนรูปภาพสำหรับการทดสอบทั้งหมดจำนวน 119 ภาพ ค่าความแม่นยำในการทำนายของคลาสนี้มีค่าเท่ากับ 99.16 เปอร์เซ็นต์ โดยทำนายถูกต้องจำนวน 118 ภาพ และทำนายผิดพลาดเป็นคลาสสุกพอดี (Ripe) จำนวน 1 ภาพ

จากการประเมินแบบจำลอง YOLOv8n ที่มีประสิทธิภาพดีที่สุด ประเมินด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติมข้างต้น แสดงให้เห็นว่ามีค่าความแม่นยำต่ำกว่าการประเมินแบบจำลองด้วยชุดข้อมูล Testing dataset เพียงเล็กน้อย ทั้งนี้ อาจเป็นเพราะความแตกต่างของชุดข้อมูลเช่น สภาพแสง หรือสีของภาพที่ใช้ทดสอบเพิ่มเติม มีความแตกต่างจากชุดข้อมูล Testing dataset ซึ่งเป็นชุดข้อมูลเดียวกันกับชุดข้อมูลที่ใช้ฝึกอบรมแบบจำลอง ทำให้การประเมินแบบจำลองด้วยชุดข้อมูล Testing dataset มีความแม่นยำสูงกว่า

นอกจากนี้ จากผลการประเมินแบบจำลองด้วยชุดข้อมูลจากแหล่งอื่นเพิ่มเติม พบว่า คลาสที่สุกเกินไปทำนายผิดเยอะที่สุด โดยทำนายผิดพลาดเป็นคลาสสุกพอดี จำนวน 6 ภาพ ทั้งนี้ อาจเป็นเพราะว่าสีของผลปาล์มน้ำมันสด ที่มีระดับความสุกเกินไปและสุกพอดีนั้น มีความใกล้เคียงกันมาก และทำให้แบบจำลองทำนายผิดพลาดได้ง่าย ในขณะที่เดียวกันผลการทำนายในคลาสนี้ไม่สุก และสุกพอดี นั้น แบบจำลองทำนายผิดพลาดเพียงแค่ 1 และ 2 ภาพ เท่านั้น อาจเป็นเพราะคลาสนี้มีสีที่ชัดเจน

อย่างไรก็ตามจากผลการทดลองแสดงให้เห็นว่าแบบจำลองการเรียนรู้เชิงลึกที่นำเสนอ มีความถูกต้องมากพอที่จะนำไปใช้ในการจำแนกระดับความสุกของปาล์มน้ำมันสดได้ เนื่องจากมีความแม่นยำค่อนข้างสูง จากผลการประเมินแบบจำลองด้วยชุดข้อมูล Testing dataset และชุดข้อมูลจากแหล่งอื่นเพิ่มเติม

5.3 ข้อเสนอแนะ

1. เพื่อความแม่นยำในการจำแนกระดับความสุกของปาล์มน้ำมันสดด้วยแบบจำลองที่นำเสนอในงานวิจัยนี้ ควรประเมินแบบจำลองด้วยรูปภาพที่มีลักษณะเดียวกับรูปภาพที่ใช้ในการฝึกอบรมแบบจำลอง เช่น ภาพที่มีผลปาล์มน้ำมันสด 1 ทะลาย ต่อ 1 ภาพ

2. แบบจำลองที่นำเสนอนี้เหมาะสำหรับการจำแนกระดับความสุกของผลปาล์มน้ำมันสดที่มีลักษณะ Nigrescens เท่านั้น โดยจะมีลักษณะสีดำปลายผลและมีสิ่งข้างที่ขั้วผล ขณะที่ผลดิบ และเปลี่ยนเป็นสีแดงเมื่อผลสุก

3. เพื่อให้การจำแนกระดับความสุกของปาล์มน้ำมันสดมีประสิทธิภาพที่ดีขึ้น ควรทำการทดลองกับแบบจำลอง Pre-Trained อื่น ๆ หรือปรับแต่งค่าพารามิเตอร์เพิ่มเติม

4. ควรเพิ่มข้อมูลภาพให้มีความหลากหลายมากขึ้น เช่น ชุดข้อมูลที่เก็บเอง ที่มีความใกล้เคียงกับสถานการณ์จริง เช่น รูปภาพที่มีพื้นหลัง หรือรูปภาพที่ถ่ายจากต้นปาล์มน้ำมัน เพื่อให้แบบจำลองเรียนรู้ได้ดียิ่งขึ้น

5. เพื่อให้เกิดประโยชน์ในการจำแนกระดับความสุกของปาล์มน้ำมันสดโดยแท้จริงในอนาคต ควรนำแบบจำลองที่ทดสอบไปประยุกต์ใช้กับอุปกรณ์ที่สามารถใช้งานแบบเรียลไทม์ได้

บรรณานุกรม

- Ashari, S., Yanris, G. J., & Purnama, I. (2022, 05/02). Oil Palm Fruit Ripeness Detection using Deep Learning. *Sinkron : jurnal dan penelitian teknik informatika*, 7(2), 649-656. <https://doi.org/10.33395/sinkron.v7i2.11420>
- Azman, H., & Suriani, N. S. (2023, 05/03). Grading Oil Palm Fruit Bunch using Convolution Neural Network. *Evolution in Electrical and Electronic Engineering*, 4(1), 185-194. <https://penerbit.uthm.edu.my/periodicals/index.php/eeee/article/view/10589>
- B.V., E. (2024). Confusion Matrix. <https://www.sciencedirect.com/topics/engineering/confusion-matrix>
- Chen, Z., Elsaid, S., Sim, D. Y. Y., Maul, T., & Liao, I. Y. (2022, 16-18 Dec. 2022). Detection of Oil Palm Fresh Fruit Bunches (FFBS) with Computer Vision Models. 2022 International Conference on Mechanical, Automation and Electrical Engineering (CMAEE),
- Dambul, K. D., Choo, K. Y., & Mansour, M. Y. M. A. (2022, 2022/11/03). Object Detection Algorithms for Ripeness Classification of Oil Palm Fresh Fruit Bunch. *International Journal of Technology*, 13(6), 291-319. <https://doi.org/https://doi.org/10.14716/ijtech.v13i6.5932>
- Girshick, R. (2015). Fast r-cnn. Proceedings of the IEEE international conference on computer vision,
- Girshick, R., Donahue, J., Darrell, T., & Malik, J. (2014). Rich feature hierarchies for accurate object detection and semantic segmentation. Proceedings of the IEEE conference on computer vision and pattern recognition,
- He, K., Gkioxari, G., Dollár, P., & Girshick, R. (2017). Mask r-cnn. Proceedings of the IEEE International Conference on Computer,

- Herman, H., Cenggoro, T. W., Susanto, A., & Pardamean, B. (2021, 19-20 Aug. 2021). Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet. 2021 International Conference on Information Management and Technology (ICIMTech),
- Ibrahim, Z., Sabri, N., & Isa, D. (2018, 09/26). Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition Using Convolutional Neural Network. *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 10(3-2), 109-113. <https://jtec.utm.edu.my/jtec/article/view/4720>
- Khamis, N., Selamat, H., Ghazalli, S., Saleh, N. I. M., & Yusoff, N. (2022, 4-7 May 2022). Comparison of Palm Oil Fresh Fruit Bunches (FFB) Ripeness Classification Technique using Deep Learning Method. 2022 13th Asian Control Conference (ASCC),
- Lai, J. W., Ramli, H. R., Ismail, L. I., & Hasan, W. Z. W. (2022). Real-Time Detection of Ripe Oil Palm Fresh Fruit Bunch Based on YOLOv4. *IEEE Access*, 10, 95763-95770. <https://doi.org/10.1109/ACCESS.2022.3204762>
- Lai, J. W., Ramli, H. R., Ismail, L. I., & Wan Hasan, W. Z. (2023). Oil Palm Fresh Fruit Bunch Ripeness Detection Methods: A Systematic Review. *Agriculture*, 13(1).
- Liu, W., Anguelov, D., Erhan, D., Szegedy, C., Reed, S., Fu, C.-Y., & Berg, A. C. (2016, 2016//). SSD: Single Shot MultiBox Detector. *Computer Vision – ECCV 2016*, Cham.
- Mohtar, L., Muhammad, H., & Ab Rahman, M. (2022, 11/14). Comparison CNN and Mobilenet_v2 Model for Oil Palm FBB Ripeness Classification. *Evolution in Electrical and Electronic Engineering*, 3(2), 146-154. <https://publisher.uthm.edu.my/periodicals/index.php/eeee/article/view/8591>
- Patel, S., & Patel, A. (2020). Object Detection with Convolutional Neural Networks. In (pp. 529-539). https://doi.org/10.1007/978-981-15-7106-0_52
- Redmon, J., Divvala, S., Girshick, R., & Farhadi, A. (2016). You only look once: Unified,

real-time object detection. Proceedings of the IEEE conference on computer vision and pattern recognition,

Septiarini, A., Hatta, H. R., Hamdani, H., Oktavia, A., Kasim, A. A., & Suyanto, S. (2020, 3-4 Nov. 2020). Maturity Grading of Oil Palm Fresh Fruit Bunches Based on a Machine Learning Approach. 2020 Fifth International Conference on Informatics and Computing (ICIC),

soumyadip. (2023). *Mastering All YOLO Models from YOLOv1 to YOLO-NAS: Papers Explained* (2024). <https://learnopencv.com/mastering-all-YOLO-models/>

Suharjito. (2023). Annotated Video Dataset of Oil Palm Fruit Bunch Piles for Ripeness Grading. <https://www.scidb.cn/en/detail?dataSetId=7f2dfbed88c5484195d4217814b21542&version=V2>

Suharjito, Junior, F. A., Koeswandy, Y. P., Debi, Nurhayati, P. W., Asrol, M., & Marimin. (2023, 2023/02/04). Annotated Datasets of Oil Palm Fruit Bunch Piles for Ripeness Grading Using Deep Learning. *Scientific Data*, 10(1), 72. <https://doi.org/10.1038/s41597-023-01958-x>

Terven, J., & Cordova-Esparza, D. (2023). A comprehensive review of YOLO: From YOLOv1 to YOLOv8 and beyond. *arXiv preprint arXiv:2304.00501*.

Ultralytics. (2024). *Ultralytics YOLOv8 Docs*. <https://docs.ultralytics.com/>

กฤตชญา ชนะสิทธิ์ นิสากกร รัตนถาวร และ กานต์ทิศา จิตรเอียด. (2566). สถานการณ์การผลิตและการตลาดปาล์มน้ำมันและน้ำมันปาล์มของประเทศไทย ปี 2565/66. รายงานสถานการณ์การผลิตและการตลาดปาล์มน้ำมันและน้ำมันปาล์มของประเทศไทย, 1-5. <https://drive.google.com/file/d/1RRCVCRtQE8aW7l656h6zYF6W3DmaC1YM/view>

ธีระพงศ์ จันทอนิยม. (2562). คู่มือเกษตรกรการผลิตปาล์มน้ำมันอย่างมีประสิทธิภาพ (พิมพ์ครั้งที่ 4 ed.). ศูนย์วิจัยและพัฒนาการผลิตปาล์มน้ำมันคณะทรัพยากรธรรมชาติ มหาวิทยาลัยสงขลานครินทร์ อ.หาดใหญ่ จ.สงขลา.

ประกาศกระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดมาตรฐานสินค้าเกษตร : ทะลายปาล์มน้ำมันตาม
พระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551. (2562). ราชกิจจานุเบกษา (เล่ม 137
ตอนพิเศษ 12 ง, น. 10). <https://www.opsmoac.go.th/krabi-dwl-files-441391791011>

สำนักงานเกษตรและสหกรณ์จังหวัดชุมพร. (2564). ข้อมูลเพื่อการวางแผนพัฒนาการเกษตรราย
สินค้า ปี 2564 จังหวัดชุมพร (ปาล์มน้ำมัน). <https://www.opsmoac.go.th/chumphon-performance-preview-431391791827>



ประวัติผู้เขียน

