

การจำแนกความสุกของทะเลลายปาล์มสดด้วยการเรียนรู้เชิงลึก

ปัญจวรรณ แซ่เฉิน¹ และ ฐิติรัตน์ ศิริบรรรรัตนกุล^{2*}

สถาบันบัณฑิตพัฒนบริหารศาสตร์ ถ.เสรีไทย แขวงคลองจั่น เขตบางกะปิ กรุงเทพฯ 10240

* Corresponding Author: thitirat@as.nida.ac.th

¹ นักศึกษาระดับบัณฑิตศึกษา คณะสถิติประยุกต์

² อาจารย์ คณะสถิติประยุกต์

ข้อมูลบทความ

บทคัดย่อ

ประวัติบทความ :

รับเพื่อพิจารณา : 8 เมษายน 2565

แก้ไข : 28 มีนาคม 2566

ตอบรับ : 30 มีนาคม 2566

DOI : 10.14456/kmuttrd.2023.6

คำสำคัญ : ปัญญาประดิษฐ์ / คอมพิวเตอร์วิทัศน์ / การเรียนรู้เชิงลึก / การจำแนกรูปภาพ / Grad-CAM

ปัจจุบัน โรงสกัดน้ำมันปาล์มในประเทศไทยว่าจ้างพนักงานให้เป็นผู้ประเมินระดับความสุกของทะเลลายปาล์มสดด้วยสายตา ณ จุดรับซื้อ ซึ่งมักประสบปัญหาการฉ้อโกงพนักงานประเมินความสุกของทะเลลายปาล์มสดผิดพลาด ส่งผลให้โรงสกัดน้ำมันปาล์มมีต้นทุนการรับซื้อทะเลลายปาล์มสูงกว่าปกติ งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อสร้างตัวแบบประเภทการเรียนรู้เชิงลึกในการวิเคราะห์ภาพถ่ายทะเลลายปาล์มสดเพื่อจำแนกประเภทความสุกของทะเลลายปาล์มสดได้อย่างถูกต้อง จากผลการทดลอง พบว่า ตัวแบบ ResNet50(C) เป็นตัวแบบซึ่งให้ Adjusted Accuracy ดีที่สุดที่ 90% โดย F1 score ของแต่ละประเภทความสุกสูงกว่า 80% แต่เป็นตัวแบบซึ่งมีขนาดใหญ่และใช้เวลาเฉลี่ยในการทดสอบนาน (405 MB, 2.48 วินาที (GPU), 3.27 วินาที (CPU)) หากให้ความสำคัญกับขนาดของตัวแบบที่เล็กลงและใช้เวลาเฉลี่ยในการทดสอบที่เร็วขึ้น สามารถพิจารณาเลือกใช้ตัวแบบ DenseNet121 (Train from Scratch) ซึ่งให้ Adjusted Accuracy 86% ซึ่งต่ำกว่าตัวแบบ ResNet50(C) เล็กน้อย แต่ยังคงมี F1 score ของแต่ละ Class สูงกว่า 80% ในขณะที่ตัวแบบมีขนาดเล็กลงและใช้เวลาเฉลี่ยในการทดสอบเร็วขึ้น (100 MB, 1.76 วินาที (GPU), 2.56 วินาที (CPU)) รวมถึงมีความทนทานต่อการเปลี่ยนแปลงค่าความสว่างของภาพถ่ายได้ดี (ช่วง -70 ถึง +70 จากความสว่างของแสงแดดปกติ)

Oil Palm Fresh Fruit Bunch Ripeness Classification by Deep Learning

Panjawat Saechen¹ and Thitirat Siriborvornratanakul^{2*}

National Institute of Development Administration, Seri Thai, Khlong Chan Bangkokpi,
Bangkok 10240

* Corresponding Author: thitirat@as.nida.ac.th

¹ Graduated Student, Graduate School of Applied Statistics.

² Lecturer, Graduate School of Applied Statistics.

Article Info

Abstract

Article History:

Received: April 8, 2022

Revised: March 28, 2023

Accepted: March 30, 2023

DOI : 10.14456/kmuttrd.2023.6

Keywords: Artificial Intel-
ligence / Computer Vision /
Deep Learning / Image
Classification / Grad-CAM

Currently, palm-oil mills in Thailand employ staff to visually assess the ripeness of fresh palm bunches at point of purchase. This practice suffers from some limitations; the staff sometimes misjudges the ripeness of fresh palm bunches. As a result, palm-oil mills have a higher than usual cost of purchasing palm bunches. The present research therefore aimed to develop a deep-learning model that can be used to analyze photographs of oil palm fresh fruit bunches and accurately classify their ripeness. The results showed that the ResNet50(C) model provided the best adjusted accuracy at 90%, where the F1 score of each category was noted to be higher than 80% ripeness. However, it is a large model and requires a longer average testing time (405 MB, 2.48 seconds (GPU), 3.27 seconds (CPU)). If a smaller model size is desired and a faster average testing time is needed, DenseNet121 (Train from Scratch) model can instead be considered. Although the model provided the adjusted accuracy at 86%, slightly less than that of the ResNet50(C) model, its F1 score for each class was as well above 80%; the model is smaller and requires a shorter average testing time (100 MB, 1.76 seconds (GPU), 2.56 seconds (CPU)). The model is also highly robust to changes in the brightness of the photographs (range -70 to +70 from normal sunlight).

1. บทนำ

ประเทศไทยมีผลผลิตน้ำมันปาล์มสูงเป็นอันดับ 3 ของโลก คิดเป็นสัดส่วน 4% ของผลผลิตของโลก [1] โดยมีจุดแข็งจากการมีห่วงโซ่การผลิตที่ครบวงจร ประกอบด้วย 1) เกษตรกรผู้ปลูกปาล์มน้ำมัน (อุตสาหกรรมขั้นต้น) มีจำนวนประมาณ 2.4 แสนครัวเรือนทั่วประเทศ 2) โรงสกัดน้ำมันปาล์มดิบ (อุตสาหกรรมขั้นกลาง) มีจำนวน 149 แห่ง และ 3) โรงกลั่นน้ำมันปาล์มบริสุทธิ์และโรงงานผลิตน้ำมันไบโอดีเซล (อุตสาหกรรมขั้นปลาย) มีจำนวนรวม 31 แห่ง [2] โดยเป็นการผลิตน้ำมันปาล์มเพื่อใช้ในการบริโภคภายในประเทศเป็นหลัก แบ่งออกเป็น 2 ส่วน ได้แก่ 1) ใช้เป็นวัตถุดิบในอุตสาหกรรมไบโอดีเซล B100 (สัดส่วน 54%) และ 2) ใช้กลั่นเป็นน้ำมันปาล์มบริสุทธิ์เพื่อการบริโภคและใช้เป็นวัตถุดิบในอุตสาหกรรมอาหารและอื่น ๆ (สัดส่วน 46%) [3] ดังนั้นจึงเห็นได้ว่าอุตสาหกรรมน้ำมันปาล์มในประเทศไทยมีส่วนสำคัญในการช่วยลดการนำเข้าน้ำมันเชื้อเพลิงและน้ำมันพืชชนิดอื่น รวมถึงมีส่วนสำคัญในการส่งเสริมอาชีพและการจ้างงาน

อย่างไรก็ตาม ปัญหาหนึ่งที่สำคัญของอุตสาหกรรมน้ำมันปาล์มในประเทศไทย คือ การมีกำลังการผลิตส่วนเกินของโรงสกัดน้ำมันปาล์มดิบอยู่ในระดับสูง โดยปัจจุบัน โรงสกัดน้ำมันปาล์มในประเทศไทยมีอัตราการใช้กำลังการผลิตเพียง 43% [2] สาเหตุเนื่องจากในช่วง 10 ปีที่ผ่านมา มีการสร้างโรงงานสกัดน้ำมันปาล์มดิบเพิ่มขึ้นมากกว่าเท่าตัว ดังนั้น จึงทำให้โรงงานสกัดน้ำมันปาล์มต้องเผชิญกับการแข่งขันที่รุนแรง ส่งผลให้ศักยภาพในการทำกำไรของอุตสาหกรรมขั้นกลางทั้งระบบมีแนวโน้มถดถอย โรงสกัดน้ำมันปาล์มบางแห่งถึงขั้นต้องเผชิญกับผลขาดทุนจนต้องตัดสินใจปิดกิจการ

แนวทางหนึ่งในการปรับปรุงผลกำไรของโรงสกัดน้ำมันปาล์มให้ดีขึ้นคือการปรับปรุงกระบวนการรับซื้อทะเลาะปาล์มสดจากเกษตรกรในราคาที่เหมาะสมให้ดีขึ้น ปัจจุบัน ภาครัฐได้กำหนดให้โรงสกัดน้ำมันปาล์มต้องรับซื้อทะเลาะปาล์มสด







ตามเปอร์เซ็นต์น้ำมันในราคาที่เหมาะสมและเป็นธรรม [4] โดยการประเมินเปอร์เซ็นต์น้ำมันจะแปรผันตรงกับระดับความสุกของผลปาล์มสดซึ่งอยู่บนทะเลาะปาล์ม ซึ่งสามารถพิจารณาความสุกได้จากสีของผลปาล์มสดและจำนวนผลปาล์มสดที่หลุดออกจากทะเลาะปาล์ม [5] ในทางปฏิบัติโรงสกัดน้ำมันปาล์มจะว่าจ้างพนักงานให้ทำหน้าที่เป็นผู้ประเมินระดับความสุกของทะเลาะปาล์มสดด้วยสายตา ณ จุดรับซื้อ ซึ่งมีข้อจำกัด ได้แก่ 1) จำนวนพนักงานน้อยและมีเวลาประเมินจำกัด และ 2) ปัจจัยส่วนบุคคล เช่น ความเชี่ยวชาญและสถานะด้านอารมณ์ในระหว่างการทำงาน ทำให้เกิดข้อผิดพลาดในการประเมิน ส่งผลให้โรงงานต้องรับซื้อทะเลาะปาล์มราคาสูงเกินกว่าเปอร์เซ็นต์น้ำมันที่ผลิตได้จริง งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อสร้างตัวแบบประเภทการเรียนรู้เชิงลึก (Deep Learning) ในการวิเคราะห์ภาพถ่ายของทะเลาะปาล์มสดเพื่อจำแนกประเภทความสุกของทะเลาะปาล์มสดได้อย่างแม่นยำ ซึ่งโรงสกัดน้ำมันปาล์มสามารถนำไปประยุกต์ใช้เป็นเครื่องมือในการวิเคราะห์ระดับความสุกของทะเลาะปาล์มสดเพื่อลดความผิดพลาดจากการให้ราคาซื้อทะเลาะปาล์มสูงเกินกว่าเปอร์เซ็นต์น้ำมันที่ผลิตได้จริง และนำไปสู่การลดต้นทุนการผลิตและเพิ่มผลกำไรให้ดีขึ้นได้

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

การประเมินระดับความสุกของทะเลาะปาล์มสดในระดับสากลสามารถพิจารณาได้จากสีและจำนวนผลปาล์มสดที่หลุดจากทะเลาะปาล์ม ซึ่งสามารถแบ่งระดับความสุกได้ออกเป็น 4 ประเภท ตามตารางที่ 1 และ รูปที่ 1 [5],[6] ดังนั้นงานวิจัยที่เกี่ยวข้องจึงมักจะทำการวิเคราะห์จากภาพถ่ายทะเลาะปาล์มสด โดยสามารถแบ่งงานวิจัยที่เกี่ยวข้องตามลักษณะของเทคนิคการวิเคราะห์ที่ได้เป็น 2 กลุ่ม ได้แก่ 1) Traditional Computer Vision & Machine Learning และ 2) Deep Learning

ตารางที่ 1 เกณฑ์การแบ่งประเภทความสุกของทะลายปาล์ม

ประเภทความสุก	เกณฑ์สีของผลปาล์มสด	เกณฑ์จำนวนผลปาล์มสด ที่หลุดออกจากทะลายปาล์ม
ทะลายปาล์มดิบ (Unripe bunch)	ผลปาล์มมีผิวเปลือก สีส้มแดงหรือสีแดงม่วง	ไม่มีผลร่วง
ทะลายปาล์มสุก (Ripe bunch)	ผลปาล์มมีผิวเปลือก สีส้มแดงหรือสีแดงม่วง	จำนวนผลร่วงน้อยกว่า 10 ผลต่อทะลาย ณ จุดรับซื้อ
ทะลายปาล์มสุกเต็มที่ (Fully ripe bunch)	ผลปาล์มมีผิวเปลือก สีส้มหรือสีแดง	จำนวนผลร่วงอย่างน้อย 10 ผลต่อทะลาย ณ จุดรับซื้อ และยังมีผลปาล์มน้ำมันที่ติดอยู่กับ ทะลายมากกว่า 50%
ทะลายปาล์มสุกมากเกินไป (Overripe bunch)	ผลปาล์มมีผิวเปลือก สีแดงเข้ม	จำนวนผลร่วงมากกว่า 50% ของทะลาย ณ จุดรับซื้อ

 ทะลายปาล์มที่มีผลปาล์ม มีผิวเปลือกสีส้ม	 ทะลายปาล์มที่มีผลปาล์ม มีผิวเปลือกสีส้มแดง	 ทะลายปาล์มสุกมากเกินไป
 ทะลายปาล์มที่มีผลปาล์ม มีผิวเปลือกสีแดง (ทะลายปาล์มสุกเต็มที่)	 ทะลายปาล์มที่มีผลปาล์ม มีผิวเปลือกสีส้มแดงม่วง (ทะลายปาล์มสุก)	 ทะลายปาล์มดิบ (ทะลายปาล์มสุกมากเกินไป และทะลายปาล์มดิบ)

รูปที่ 1 ตัวอย่างทะลายปาล์มแบ่งตามประเภทความสุก

2.1 Computer Vision & Traditional Machine Learning

งานวิจัยที่เกี่ยวข้องกับการจำแนกประเภทความสุกของทะลายปาล์มสดส่วนใหญ่จะมีการประมวลผลภาพ (Image Processing) เพื่อช่วยดึงคุณลักษณะสำคัญของภาพถ่ายออกมา (Handcraft Feature Extraction) ได้แก่ สี เพื่อนำคุณลักษณะดังกล่าวมาวิเคราะห์และใช้เป็นตัวแปรสำหรับการสร้างตัวแบบจำแนกประเภทด้วย Computer Vision &

Traditional Machine Learning ตัวอย่างเช่น การใช้ค่าเฉลี่ยของตัวแบบสี RGB เป็นเกณฑ์ในการจำแนกความสุกของทะลายปาล์มสด [7] การใช้ค่าเฉลี่ยของตัวแบบสี RGB ร่วมกับ Neuro-Fuzzy Algorithm เพื่อจำแนกทะลายปาล์มสด [8] การใช้ตัวแบบสี RGB ร่วมกับ PCA และ Multi-Layer Perceptron (MLP) [9] การใช้ค่า HUE ของตัวแบบสี HIS ร่วมกับ PCA หรือ SDA และ Multi-Layer Perceptron (MLP) [10] การใช้ค่า Reflectance จากภาพถ่ายแบบ

Hyperspectral ร่วมกับ MLP [11] แม้ผลลัพธ์จากการศึกษาข้างต้นจะให้ค่าความถูกต้องในระดับที่น่าพอใจประมาณ 73-99% แต่เนื่องจากตัวแบบได้ถูกสร้างขึ้นมาจากการดึงคุณลักษณะสำคัญของภาพถ่ายตามที่ผู้วิจัยได้กำหนดขึ้น จึงทำให้มีความยืดหยุ่นในการนำไปใช้งานต่ำ กล่าวคือ ต้องมีการกำหนดค่าของกล่อง เช่น ระดับแสงหรือมุมกล้อง หรือต้องใช้เครื่องถ่ายภาพชนิดพิเศษ เพื่อให้ตัวแบบสามารถดึงคุณลักษณะสำคัญของภาพถ่ายออกมาได้ตรงตามที่ตัวแบบต้องการ ซึ่งโดยทั่วไปมักจะไม่มี ความยืดหยุ่นในการนำไปใช้งานจริง

2.2 Deep Learning

Deep Learning หรือ การเรียนรู้เชิงลึก เป็นเทคนิคการวิเคราะห์ข้อมูลสมัยใหม่ซึ่งเริ่มเป็นที่นิยมอย่างแพร่หลาย หลังจากการเอาชนะการแข่งขัน ImageNet Large Scale Visual Recognition Challenge (ILSVRC) ในปี ค.ศ. 2012 ส่งผลให้การวิเคราะห์รูปภาพได้รับการพัฒนาอย่างต่อเนื่อง สิ่งสำคัญอย่างหนึ่งที่ทำให้ Deep Learning ให้ผลลัพธ์ที่เหนือกว่าเทคนิคการวิเคราะห์แบบดั้งเดิมคือ เป็นเทคนิคที่มีการสร้างวิธีดึงคุณลักษณะสำคัญของรูปภาพให้โดยอัตโนมัติ (Automatic Feature Extraction) ทำให้ตัวแบบสามารถเรียนรู้คุณลักษณะต่าง ๆ ของรูปภาพได้หลากหลาย ส่งผลให้ตัวแบบมีความยืดหยุ่นในการนำไปใช้งานจริงได้มากกว่าเทคนิคการวิเคราะห์แบบดั้งเดิม สำหรับงานวิจัยที่เกี่ยวข้องกับการจำแนกประเภทความสุขของทะเลสาบปาล์มสดโดยใช้ Deep Learning เริ่มต้นขึ้นในปี ค.ศ. 2018 จากงานวิจัยซึ่งใช้ Convolutional Neural Network (CNN) ด้วยตัวแบบประเภท Pre-trained CNN ได้แก่ AlexNet โดยใช้เทคนิคการเรียนรู้แบบ Trained from Scratch เปรียบเทียบกับตัวแบบซึ่งใช้เทคนิคการวิเคราะห์แบบดั้งเดิม ได้แก่ Support Vector Machines

(SVM) โดยใช้ Histogram of Oriented Gradient (HOG), Fast Retina Keypoint (FAST) และ Color Moment ในการทำ Feature Extraction พบว่าตัวแบบ AlexNet ให้ผลลัพธ์ดีกว่าโดยให้ความถูกต้อง 100% ในขณะที่ใช้เวลาเรียนรู้ไม่แตกต่างจากตัวแบบซึ่งใช้เทคนิคการวิเคราะห์แบบดั้งเดิม [12] สอดคล้องกับงานวิจัยซึ่งใช้ Convolutional Neural Network (CNN) โดยใช้เทคนิคการเรียนรู้แบบ trained from scratch เท่านั้นในการจำแนกประเภทความสุขของทะเลสาบปาล์มสดซึ่งให้ความถูกต้อง 98% [13] นอกจากนี้ ยังมีงานวิจัยเปรียบเทียบระหว่าง Pre-trained CNN ประเภทต่าง ๆ ได้แก่ การเปรียบเทียบระหว่าง 1) AlexNet 2) DenseNet+SE layer 3) ResAtt DenseNet และ 4) DenseNet Sigmoid พบว่า ResAtt DenseNet ให้ผลลัพธ์ดีกว่าโดยมี F1 score 69.29% [14] การเปรียบเทียบระหว่าง AlexNet กับ DenseNet พบว่า DenseNet ให้ผลลัพธ์ดีกว่าโดยให้ความถูกต้อง 86% [15]

จากงานวิจัยข้างต้น แม้จะให้ผลลัพธ์ที่น่าพอใจ แต่ยังมีข้อจำกัดเนื่องจากการใช้ภาพถ่ายต่อประเภทความสุขจำนวนน้อยจำนวนภาพถ่ายของแต่ละประเภทมีความแตกต่างกันมาก เช่น ใช้ภาพปาล์มดิบเพียง 8 ภาพ และปาล์มกำลังสุก 16 ภาพ ในขณะที่ใช้ปาล์มสุกเต็มที่ 168 ภาพ โดยไม่มีการทำ Data Augmentation รวมถึงการแบ่งประเภทความสุขมีจำนวนแตกต่างกัน โดยบางงานวิจัยมีการแบ่งประเภทความสุขในจำนวนที่ต่ำเกินไป เช่น แบ่งเป็นประเภทสุกและดิบเท่านั้น (รายละเอียดแสดงในตารางที่ 2) นอกจากนี้ การพัฒนาสายพันธุ์ปาล์มของแต่ละประเทศมีความแตกต่างกัน ทำให้ผลลัพธ์ของแต่ละงานวิจัยอาจมีความคลาดเคลื่อนและอาจไม่สามารถนำตัวแบบดังกล่าวมาใช้งานในประเทศไทยได้จริง

ตารางที่ 2 เปรียบเทียบตัวแบบ Deep learning และรายละเอียดของข้อมูลภาพถ่ายทะเลาะปาล์มของแต่ละงานวิจัย

ผู้วิจัย	ประเภทตัวแบบ Deep learning	ประเภทการเรียนรู้ของตัวแบบ Deep Learning	จำนวนภาพถ่ายทั้งหมดที่ใช้ศึกษา	จำนวนประเภทความสุก	ค่าเฉลี่ยจำนวนภาพถ่ายต่อประเภท	ค่าต่ำสุด-สูงสุดของจำนวนภาพถ่ายต่อประเภท
Ibrahim และคณะ [12]	CNN	Trained from scratch	120	4	30	30
	AlexNet	Pre-trained จากชุดข้อมูล ImageNet (ILSVRC-2010)				
Saleh และคณะ [13]	CNN	Trained from scratch	628	2	314	ไม่มีข้อมูล
Herman และคณะ [14]	AlexNet, DenseNet+SE, ResAtt DenseNet, DenseNet Sigmoid	Pre-trained จากชุดข้อมูล ImageNet (ILSVRC-2010)	400	7	57	8 - 168
Herman และคณะ [15]	AlexNet, DenseNet	Pre-trained จากชุดข้อมูล ImageNet (ILSVRC-2010)	400	7	57	3 - 168

3. ขั้นตอนการดำเนินงาน

3.1 ลักษณะของข้อมูล


ข้อมูลที่ใช้ในการศึกษา คือ ชุดของภาพถ่ายทะเลาะปาล์มซึ่งเกษตรกรได้ตัดออกจากต้นปาล์มและนำมาส่งให้โรงงานสกัดน้ำมันปาล์ม โดยสามารถแบ่งประเภทของภาพถ่ายได้จากระดับความสุกของทะเลาะปาล์มทั้งทะเลาะตามเกณฑ์ของโรงงานสกัดน้ำมันปาล์มตามจริง ได้แก่ 1) ทะเลาะปาล์มดิบ (Unripe bunch) 2) ทะเลาะปาล์มกำลังสุก (Underripe bunch) 3) ทะเลาะปาล์มสุกเต็มที่ (Fully ripe bunch) และ 4) ทะเลาะปาล์มสุกมากเกินไป (Overripe bunch) เป็นต้น ข้อมูลดังกล่าวไม่ได้แบ่งแยกตามสายพันธุ์ปาล์ม สอดคล้องกับกระบวนการรับซื้อของโรงงานตามปกติ จะไม่มีการรับซื้อทะเลาะปาล์มแยกตามสายพันธุ์เช่นเดียวกัน เนื่องจากสายพันธุ์ปาล์มที่ใช้ปลูกเพื่อการพาณิชย์ส่วนใหญ่อยู่ในตระกูลเดียวกันคือ สายพันธุ์เทเนรา (TENERA) จึงมีลักษณะคล้ายกัน ยกเว้นสายพันธุ์ปาล์มสุราษฎร์ธานี 1 ซึ่งมีลักษณะของสีและลักษณะพื้นผิวแตกต่างจากสายพันธุ์อื่น แต่พอรับได้เนื่องจากเป็นสายพันธุ์ที่พบได้น้อยในประเทศไทย ดังนั้นงานวิจัยนี้จึงไม่ได้รวบรวมภาพถ่ายทะเลาะปาล์มสายพันธุ์ดังกล่าวไว้ในชุดข้อมูล โดยลักษณะของภาพถ่าย 1 ภาพ จะประกอบด้วยภาพทะเลาะปาล์มเต็มใบ

1 ทะเลาะ ซึ่งสะท้อนคุณลักษณะของสี (Color) และลักษณะพื้นผิว (Texture) แต่ไม่ได้สะท้อนถึงจำนวนผลที่ร่วงบริเวณรอบ ๆ ทะเลาะ หรือจำนวนผลที่หลุดออกจากทะเลาะ เนื่องจากผู้รวบรวมมีข้อจำกัดไม่สามารถระบุได้ชัดว่าผลร่วงรอบ ๆ นั้นเป็นของทะเลาะปาล์มใด และทะเลาะปาล์มมีน้ำหนักค่อนข้างมาก ผู้รวบรวมจึงไม่สามารถยกทะเลาะปาล์มเพื่อพิจารณาจำนวนผลที่หลุดร่วงได้ ซึ่งเป็นข้อจำกัดเดียวกันของพนักงานผู้ประเมินเช่นเดียวกัน นอกจากนี้ ภาพถ่ายดังกล่าวจะไม่มีการควบคุมลักษณะของพื้นหลังของทะเลาะปาล์มแต่อย่างใด เพื่อสร้างตัวแบบที่สามารถจำแนกทะเลาะปาล์มได้โดยไม่ขึ้นอยู่กับพื้นหลัง ตัวอย่างตามรูปที่ 2

3.2 กระบวนการรวบรวมข้อมูล

ชุดของภาพถ่ายทะเลาะปาล์มได้รับความอนุเคราะห์จาก บริษัท ไทยทาโลว์ แอนด์ ออยล์ จำกัด สาขาบางสวรรค์ จังหวัดสุราษฎร์ธานี โดยกระบวนการรวบรวมข้อมูลมีการควบคุมองค์ประกอบต่าง ๆ ดังนี้

1) กล้องถ่ายภาพ จำนวน 4 เครื่อง แบ่งเป็น กล้องจากโทรศัพท์เคลื่อนที่จำนวน 2 เครื่อง (ระบบ ANDROID และ IOS) และ กล้องถ่ายรูป Mirrorless จำนวน 2 เครื่อง (ยี่ห้อ FUJI และ SONY) โดยแต่ละเครื่องมีข้อจำกัด คือ การตั้งค่า



รูปที่ 2 ตัวอย่างทะลายปาล์มแบ่งตามประเภทความสุกของโรงสกัดน้ำมันปาล์ม

ภาพถ่ายมีขนาดไม่เท่ากัน จึงกำหนดขนาดให้ใกล้เคียงกันที่สุด โดยกำหนดช่วงความกว้าง 2,800-3,700 pixels และความยาว 2,800-5,500 pixels ทั้งนี้ มีจำนวน 3 เครื่องที่สามารถตั้งค่าภาพถ่ายให้มีรูปทรงสี่เหลี่ยมจัตุรัสได้ ยกเว้นกล้องถ่ายภาพ Mirrorless ยี่ห้อ SONY ซึ่งไม่สามารถตั้งค่าดังกล่าวได้ จำเป็นต้องถ่ายภาพด้วยรูปทรงสี่เหลี่ยมผืนผ้า โดยควบคุมการถ่ายให้ทะลายปาล์มอยู่กึ่งกลางของภาพแล้ว ขั้นตอนการเตรียมข้อมูลถัดไปจะนำภาพถ่ายดังกล่าวมาตัดส่วนของแนวยาวออกทั้ง 2 ข้าง (Crop) เพื่อให้ได้ภาพถ่ายรูปทรงสี่เหลี่ยมจัตุรัสซึ่งครอบคลุมภาพถ่ายของทะลายปาล์มเต็มใบ ส่วนการตั้งค่าอื่น ๆ กำหนดให้เป็นค่าเริ่มต้นของแต่ละเครื่อง

2) ผู้รวบรวมข้อมูล จำนวน 4 คน โดยกำหนดให้ทุกคนได้ถ่ายภาพทะลายปาล์มทุกประเภทในจำนวนเท่า ๆ กัน โดยใช้กล้องถ่ายภาพทุกเครื่อง ตามตารางที่ 3 เพื่อให้ชุดของภาพถ่ายทะลายปาล์มมีความหลากหลายโดยไม่เอนเอียงไปให้ผู้รวบรวมคนใดคนหนึ่งหรือกล้องเครื่องใดเครื่องหนึ่ง

3) ผู้ประเมินระดับความสุก จำนวน 5-10 คน โดยเป็นพนักงานของโรงงานซึ่งทำหน้าที่คัดแยกทะลายปาล์มดิบ

ออกมาเพื่อส่งกลับคืนแก่ผู้ขาย เนื่องจากโรงงานมีนโยบายไม่รับซื้อทะลายปาล์มดิบ โดยพนักงานจะเป็นผู้ให้ความรู้ในการแบ่งประเภททะลายปาล์มตามระดับความสุกให้ผู้รวบรวมข้อมูลมีความเข้าใจในเบื้องต้นก่อน หลังจากนั้นระหว่างการรวบรวมข้อมูล พนักงานดังกล่าวจะทำหน้าที่แนะนำให้ผู้รวบรวมข้อมูลทราบว่าแต่ละทะลายปาล์มมีความสุกระดับใด

4) ระยะเวลารวบรวมข้อมูล ตั้งแต่ 08.30 น. ถึง 16.30 น. วันที่ 21-22 ตุลาคม พ.ศ.2564 จำนวน 2 วัน โดยวันที่หนึ่งมีแสงแดดจ้า และวันที่สองมีเมฆครึ้ม ส่งผลให้ชุดของภาพถ่ายทะลายปาล์มมีความหลากหลายในด้านแสงมากขึ้น

ตารางที่ 3 หลักเกณฑ์การถ่ายภาพของผู้รวบรวมข้อมูล

ผู้ถ่ายภาพ	ประเภททะลายปาล์ม			
	ดิบ	กำลังสุก	สุกเต็มที่	สุกมากเกินไป
A	FUJI	SONY	ANDROID	IOS
B	IOS	FUJI	SONY	ANDROID
C	ANDROID	IOS	FUJI	SONY
D	SONY	ANDROID	IOS	FUJI

3.3 การเตรียมข้อมูล

นำชุดของภาพถ่ายหลายปาล์มมาดำเนินการตรวจสอบและแก้ไขข้อมูลที่ด้อยคุณภาพ (Data Cleansing) ได้แก่ 1) คัดเลือกรูปภาพที่ไม่ได้คุณภาพออกไป 2) ตรวจสอบความถูกต้องของประเภทความสุกอีกครั้งกับพนักงานของบริษัทอีกครั้งหนึ่ง โดยหลายปาล์มแต่ละหลายจะได้รับการประเมินโดยพนักงานซึ่งมีเวลาในการตัดสินใจมากกว่าเมื่อเปรียบเทียบกับช่วงเวลาทำงานจริง จึงทำให้มั่นใจได้ว่าข้อมูลที่รวบรวมมีความถูกต้อง หลังจากนั้นจึงนำภาพถ่ายรูปทรงสี่เหลี่ยมผืนผ้าซึ่งถูกถ่ายจากกล้องถ่ายรูป Mirrorless ยี่ห้อ SONY มาตัดส่วนของแนวยาวออกทั้ง 2 ข้าง (Crop) เพื่อให้ได้ภาพถ่ายรูปทรงสี่เหลี่ยมจัตุรัสซึ่งครอบคลุมภาพถ่ายของหลายปาล์มเต็มใบ และนำภาพถ่ายทั้งหมดมาปรับขนาดภาพถ่าย (Resize) ให้เท่ากับ 500x500 pixels แล้วจึงทำการแบ่งชุดของภาพถ่ายด้วยวิธีการสุ่มออกเป็น ชุดข้อมูลเรียนรู้ (Training set) 70% ชุดข้อมูลประเมิน (Validation set) 15% และ ชุดข้อมูลทดสอบ (Test set) 15% เพื่อใช้สำหรับการเรียนรู้ของตัวแบบประเภทการเรียนรู้เชิงลึก (Deep Learning) ต่อไป โดยแสดงจำนวนภาพถ่ายหลายปาล์มแต่ละประเภทความสุกได้ดังนี้

ตารางที่ 4 จำนวนภาพถ่ายหลายปาล์มแต่ละประเภท

Class ที่	ประเภทความสุกของหลายปาล์ม	รวม	ชุดข้อมูลเรียนรู้	ชุดข้อมูลประเมิน	ชุดข้อมูลทดสอบ
1	ดิบ	800	560	120	120
2	กำลังสุก	484	338	73	73
3	สุกเต็มที่	800	560	120	120
4	สุกมากเกินไป	800	560	120	120
	รวม	2,884	2,018	433	433
	สัดส่วน	100%	70%	15%	15%

ตารางที่ 5 การกำหนดค่าพารามิเตอร์ของการทำ Data Augmentation

พารามิเตอร์	ค่าที่กำหนด	พารามิเตอร์	ค่าที่กำหนด
Rotation range	45	Zoom range	0.5-1.5
Width shift	0.5	Brightness range	0.7-1.3
Height shift	0.5	Horizontal flip	True
Shear range	0.5	Vertical flip	True

จากตารางที่ 4 หลายปาล์มประเภทกำลังสุกมีจำนวนภาพถ่ายต่ำกว่าประเภทอื่น ส่งผลให้ชุดของข้อมูลมีลักษณะไม่สมดุล (Imbalanced data) ดังนั้นเพื่อลดผลกระทบต่อการเรียนรู้ของตัวแบบซึ่งอาจเกิดปัญหาความเอนเอียงของการทำนายประเภทความสุกในส่วนของการเตรียมข้อมูลจึงมีการทำ Data Augmentation กับชุดข้อมูลเรียนรู้ เพื่อให้ตัวแบบเรียนรู้จากชุดข้อมูลที่มีความหลากหลาย ส่วนชุดข้อมูลประเมินและชุดข้อมูลทดสอบจะไม่มีการทำ Data Augmentation เพื่อให้ตัวแบบทดสอบกับข้อมูลจริง โดยมีการปรับไฮเปอร์พารามิเตอร์ (Hyperparameter tuning) ตามตารางที่ 5

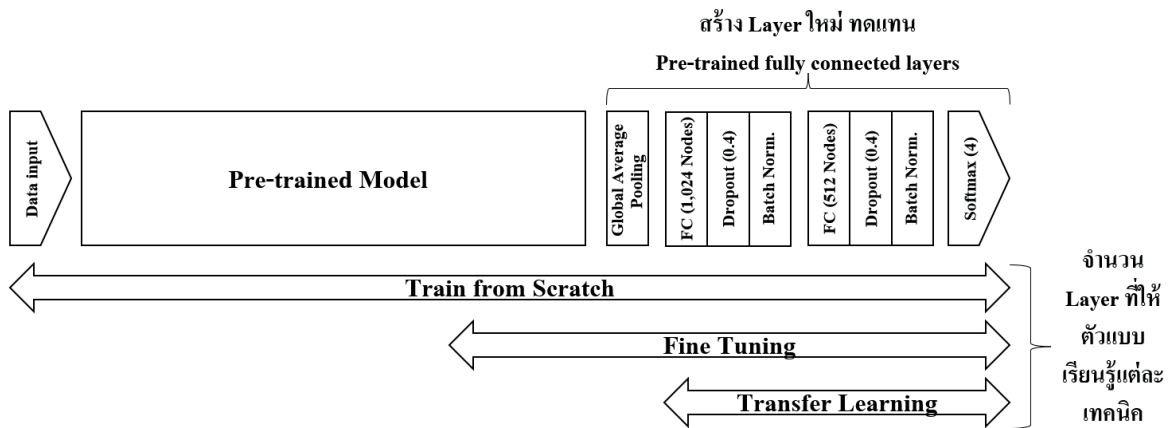
วิธีการดังกล่าว นอกจากจะช่วยลดปัญหาความแตกต่างของจำนวนภาพถ่ายแต่ละประเภทได้แล้ว ยังช่วยทำให้มีชุดข้อมูลเรียนรู้ (Training set) มีความหลากหลายของภาพถ่ายจำนวนมากขึ้น ซึ่งจะช่วยลดปัญหา Overfitting และทำให้ตัวแบบสามารถนำไปใช้งานในสถานการณ์จริงได้ดี (Generalization)

3.4 ตัวแบบ

งานวิจัยนี้เลือกใช้ตัวแบบประเภทการเรียนรู้เชิงลึก (Deep Learning) ได้แก่ VGG16 [16], ResNet50 [17],

EfficientNetB5 [18], DenseNet121 [19], InceptionV3 [20], Xception [21] และ MobileNetV3 [22] เป็นต้น และใช้เทคนิคการเรียนรู้ได้แก่ Train from Scratch, Fine Tuning และ Transfer Learning เป็นต้น โดยสำหรับตัวแบบทุกประเภทและทุกเทคนิคการเรียนรู้ จะทำการตัด Pre-trained fully connected layers จนถึง layer สุดท้ายของตัวแบบเดิมออก แล้วจึงทำการเพิ่ม Global Average Pooling 2D

และต่อด้วย Fully Connected Layers, Dropout, Batch Normalization ตามลำดับ จำนวน 2 ชุด และให้ Layer สุดท้ายเป็น Softmax Function เพื่อแสดงผลลัพธ์เป็นประเภทความสุขของทะเลสาบปาล์ม โดยสามารถแสดงรายละเอียดการสร้างตัวแบบได้ตามรูปที่ 3 และสามารถสรุปจำนวนพารามิเตอร์ของตัวแบบแต่ละประเภทได้ตามตารางที่ 6



รูปที่ 3 การสร้างตัวแบบจาก Pre-trained Model และลักษณะของเทคนิคการเรียนรู้แต่ละแบบ

ตารางที่ 6 จำนวนพารามิเตอร์ของตัวแบบแต่ละประเภท

ตัวแบบ	เทคนิคการเรียนรู้	จำนวนพารามิเตอร์ ที่เรียนรู้	จำนวนพารามิเตอร์ ที่ไม่ได้เรียนรู้	จำนวนพารามิเตอร์ ทั้งหมด
VGG16	Train from Scratch	15,769,924	3,072	15,772,996
	Fine Tuning (block5_conv1)*	8,134,660	7,638,336	15,772,996
	Transfer Learning	1,055,236	14,717,760	15,772,996
ResNet50	Train from Scratch	26,162,692	56,192	26,218,884
	Fine Tuning (conv5_block1_1_conv)*	17,604,100	8,614,784	26,218,884
	Transfer Learning	2,628,100	23,590,784	26,218,884
EfficientNetB5	Train from Scratch	30,968,884	175,815	31,144,699
	Fine Tuning (block7a_expand_conv)*	13,425,680	17,719,019	31,144,699
	Transfer Learning	2,628,100	28,516,599	31,144,699
DenseNet121	Train from Scratch	8,533,380	86,720	8,620,100
	Fine Tuning (conv5_block1_1_conv)*	3,739,652	4,880,448	8,620,100
	Transfer Learning	1,579,524	7,040,576	8,620,100
InceptionV3	Train from Scratch	24,396,452	37,504	24,433,956
	Fine Tuning (conv2d_89)*	8,701,636	15,732,320	24,433,956
	Transfer Learning	2,628,100	21,805,856	24,433,956
Xception	Train from Scratch	23,435,052	57,600	23,492,652
	Fine Tuning (block13_sepconv1)*	9,416,484	14,076,168	23,492,652
	Transfer Learning	2,628,100	20,864,552	23,492,652
MobileNetV3	Train from Scratch	3,097,380	15,184	3,112,564
	Fine Tuning (expanded_conv_10)*	2,448,916	663,648	3,112,564
	Transfer Learning	1,579,524	1,533,040	3,112,564

* หมายถึง Layer ของตัวแบบที่เริ่มทำการเรียนรู้สำหรับเทคนิคการเรียนรู้แบบ Fine Tuning

ตัวแบบทุกประเภทจะใช้ภาษา Python โดยใช้ Keras Library บน TensorFlow version 2.7.0 และใช้ GPU รุ่น Tesla V100-SXM2-16GB ในการเรียนรู้ โดยมีจำนวนรอบการเรียนรู้ 50 epochs แต่ละ epoch กำหนด Batch size = 32 และใช้ Adam optimizer ในการเรียนรู้พารามิเตอร์ โดยกำหนด Learning rate = 0.0001 และ Loss function คือ Categorical Focal Loss [23] โดยกำหนดค่า $\alpha=0.25$, $\gamma=2.0$ (คือ ค่าสัมประสิทธิ์ที่ใช้สำหรับการปรับน้ำหนักของข้อมูลในแต่ละ Class โดยจะให้ค่าสัมประสิทธิ์ α มากกับ Class ที่มีจำนวนตัวอย่างน้อย และ γ มากกับ Class ที่มีความยากในการจำแนก ส่งผลให้ Class ดังกล่าวจะมี Categorical Focal Loss สูง และตัวแบบจะเรียนรู้ในการจำแนก Class ดังกล่าวมากกว่า Class อื่น) ซึ่งช่วยลดปัญหาของข้อมูลที่มีลักษณะไม่สมดุล (Imbalanced data)

3.5 การประเมินผลลัพธ์

3.5.1 Confusion Matrix

ประเมินผลลัพธ์ของตัวแบบด้วย Confusion Matrix ซึ่งเหมาะสมกับตัวแบบการจำแนกประเภท (Classification model) โดยทดสอบกับ Validation set และ Test set โดยมีตัวชี้วัดประสิทธิภาพที่สามารถคำนวณได้จาก Confusion Matrix ได้แก่ Accuracy, Precision, Recall และ F1 score ซึ่งสามารถแสดงการคำนวณได้ ดังนี้

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad [1]$$

$$Precision = \frac{TP}{TP+FP} \quad [2]$$

$$Recall = \frac{TP}{TP+FN} \quad [3]$$

$$F1 \text{ score} = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad [4]$$

โดยที่

TP (True Positive) คือ จำนวนข้อมูลที่เป็น Class i และถูกตัวแบบจำแนกว่าเป็น Class i

FP (False Positive) คือ จำนวนข้อมูลที่ไม่ใช่ Class i แต่ถูกตัวแบบจำแนกว่าเป็น Class i

TN (True Negative) คือ จำนวนข้อมูลที่ไม่ใช่ Class i และถูกตัวแบบจำแนกว่าไม่ใช่ Class i

FN (False Negative) คือ จำนวนข้อมูลที่เป็น Class i แต่ถูกตัวแบบจำแนกว่าไม่ใช่ Class i

โดยที่ i คือ 1, 2, 3 และ 4

(1) ค่าความถูกต้อง (Accuracy) คือ ความถูกต้องในการจำแนกข้อมูลของทั้งตัวแบบ

(2) ค่าความแม่นยำ (Precision) คือ ความแม่นยำในการจำแนกข้อมูลว่าเป็น Class i ได้ถูกต้องเทียบกับข้อมูลทั้งหมดที่จำแนกเป็น Class i

(3) ค่าความระลึก (Recall) คือ ความสามารถของตัวแบบในการจำแนกข้อมูลที่เป็น Class i เมื่อเทียบกับข้อมูลที่เป็น Class i ทั้งหมด

(4) ค่าความถ่วงดุล (F1 score) หรือ ค่าเฉลี่ยฮาร์โมนิกของตัวชี้วัดค่าความแม่นยำและค่าความระลึก คือ ตัวชี้วัดที่คำนวณจากค่า Precision และ Recall เพื่อให้สามารถวัดค่าทั้งสองได้พร้อมกันด้วยตัวชี้วัดเดียว

สำหรับงานวิจัยนี้ เลือกพิจารณาค่าความถูกต้อง (Accuracy) เพื่อชี้วัดความถูกต้องของตัวแบบโดยรวม และพิจารณา F1 score กรณีพิจารณาความถูกต้องของแต่ละ Class เนื่องจากต้องการตัวแบบซึ่งสามารถจำแนกความสูงของทะเลสาบปาล์มได้ถูกต้องทุก Class ทั้งในมุมมองค่าความแม่นยำ (Precision) และค่าความระลึก (Recall) ซึ่งจะสร้างความสมดุลทั้งในมุมมองของผู้ซื้อและผู้ขาย

สำหรับ Adjusted accuracy คือ ค่าความถูกต้อง (Accuracy) ที่สะท้อนว่าตัวแบบสามารถจำแนกข้อมูลทดสอบได้ถูกต้องเป็นจำนวนเท่าใดเมื่อเปรียบเทียบกับจำนวนข้อมูลทดสอบทั้งหมด โดยข้อมูลทดสอบที่จำแนกได้ถูกต้อง จะหมายถึง ข้อมูลที่ตัวแบบสามารถจำแนกตาม Class ที่ระบุไว้ได้ถูกต้อง และเป็นข้อมูลที่ตัวแบบได้พิจารณาจากบริเวณทะเลสาบปาล์มที่ถูกต้องจาก Heatmap ของ Grad-CAM

3.5.2 Grad-CAM

Grad-CAM [24] หรือ Gradient-weighted Class Activation Map เป็นเทคนิคในการทำ Visualization ของตัวแบบการเรียนรู้เชิงลึก (Deep Learning) ประเภท CNN เพื่อตรวจสอบว่าตัวแบบจำแนกประเภทของภาพจากองค์ประกอบใดของภาพ หลักการทำงานของ Grad-CAM คือ หา Gradient ของค่าที่ทำนายได้เป็นประเภทใด ๆ ก่อนที่จะทำการ Normalize ใน Softmax กับผลลัพธ์ของ Convolutional Layer ชั้นสุดท้ายแต่ละแผ่น (Feature Map Activation) แล้วจึงนำ Gradient ดังกล่าวมาหา Global Aver-

age Pooling จะได้ค่า α เพื่อนำไปหาผลรวมเชิงเส้น (Linear Combination) ระหว่างค่า α กับ Feature Map Activation และเมื่อนำผลรวมเชิงเส้นผ่านฟังก์ชัน ReLU จะได้ค่า Grad-CAM ซึ่งสามารถ Visualize เป็นแผนภูมิความร้อน (Heat-map) บนภาพเพื่อแสดงตำแหน่งสำคัญที่ตัวแบบใช้จำแนกประเภทของภาพ

4. ผลการทดลอง

4.1 ตัวแบบประเภทการเรียนรู้เชิงลึก

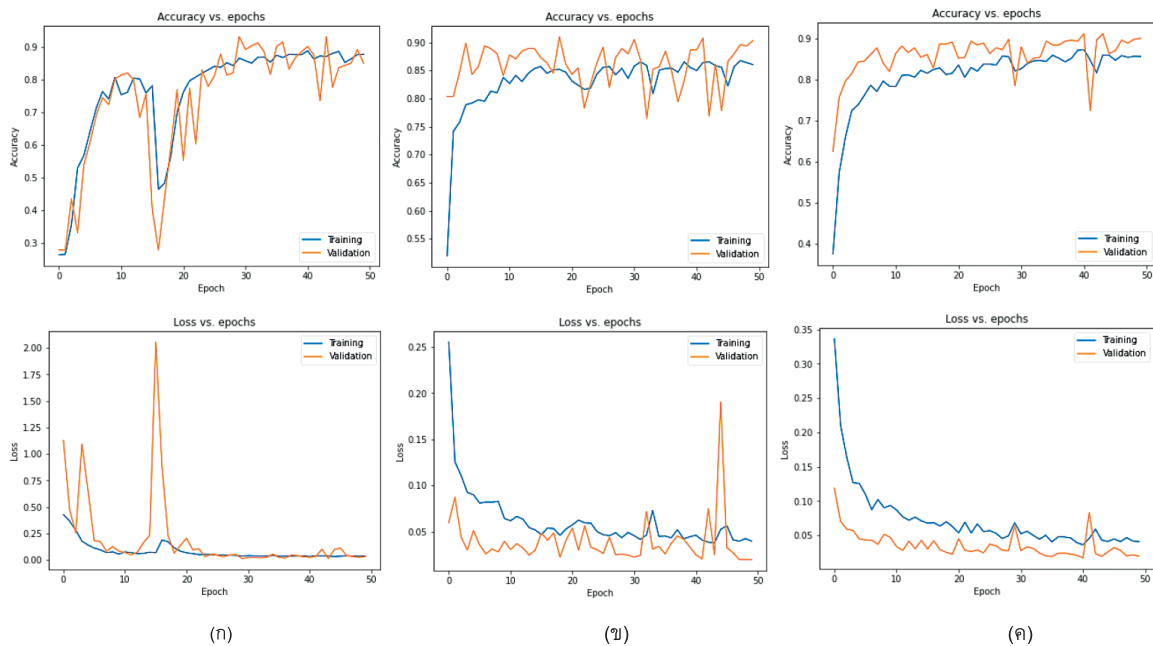
ตารางที่ 7 ผลลัพธ์ความถูกต้อง เวลาทดสอบ และขนาดของตัวแบบแต่ละประเภท โดยสัญลักษณ์ * ด้านหน้าตัวแบบและเทคนิคการเรียนรู้ คือ ตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) สูงกว่า 85% ของชุดข้อมูลประเมินและชุดข้อมูลทดสอบ

ตัวแบบ	เทคนิคการเรียนรู้	ชุดข้อมูลประเมิน					ชุดข้อมูลทดสอบ					เวลาทดสอบเฉลี่ยต่อ 1 ภาพ (วินาที)		ขนาดตัวแบบ (MB)
		Accuracy	F1 score				Accuracy	F1 score				GPU	CPU	
			Class1	Class2	Class3	Class4		Class1	Class2	Class3	Class4			
*VGG16	Train from Scratch	62%	64%	8%	80%	60%	64%	62%	17%	81%	62%	0.19	1.45	181
	*Fine Tuning	87%	97%	74%	85%	86%	88%	97%	77%	88%	85%	0.19	1.46	122
	Transfer Learning	83%	93%	70%	78%	88%	80%	90%	65%	74%	87%	0.18	1.46	68
*ResNet50	Train from Scratch	81%	89%	64%	76%	87%	80%	88%	66%	75%	86%	0.90	1.44	301
	*Fine Tuning	89%	95%	66%	85%	97%	89%	95%	71%	87%	94%	0.88	1.40	235
	Transfer Learning	84%	95%	53%	80%	89%	84%	95%	56%	81%	86%	1.13	1.43	121
EfficientNetB5	Train from Scratch	29%	2%	0%	45%	8%	31%	2%	7%	46%	15%	3.15	3.96	358
	Fine Tuning	77%	81%	55%	79%	87%	77%	79%	50%	78%	91%	2.84	3.93	223
	Transfer Learning	73%	84%	20%	73%	82%	71%	82%	29%	71%	79%	3.02	4.13	140
*DenseNet121	*Train from Scratch	90%	94%	81%	90%	94%	92%	94%	84%	92%	96%	1.76	2.56	100
	Fine Tuning	47%	60%	12%	62%	6%	48%	61%	20%	62%	6%	1.67	2.40	63
	Transfer Learning	37%	68%	25%	5%	14%	36%	69%	25%	3%	5%	1.68	2.36	46
InceptionV3	Train from Scratch	67%	73%	22%	58%	85%	67%	75%	31%	53%	84%	1.58	2.01	281
	Fine Tuning	27%	43%	5%	0%	0%	27%	42%	3%	2%	0%	1.78	1.93	161
	Transfer Learning	29%	36%	4%	38%	3%	29%	40%	8%	35%	3%	1.20	1.95	114
Xception	Train from Scratch	80%	86%	54%	78%	86%	82%	86%	55%	83%	90%	0.76	1.38	269
	Fine Tuning	27%	31%	33%	27%	6%	29%	33%	35%	27%	14%	0.70	1.42	162
	Transfer Learning	31%	46%	15%	15%	5%	29%	43%	19%	4%	6%	0.84	1.42	110
MobileNetV3	Train from Scratch	73%	88%	52%	50%	92%	75%	89%	54%	55%	92%	0.91	1.14	37
	Fine Tuning	75%	90%	60%	73%	71%	76%	86%	58%	74%	81%	0.80	1.06	31
	Transfer Learning	69%	91%	20%	67%	71%	70%	85%	13%	69%	78%	0.82	1.10	25

จากตารางที่ 7 ตัวแบบที่ให้ค่าความถูกต้อง (Accuracy) ดีที่สุดอันดับที่ 1 ถึง 3 ได้แก่ DenseNet121 (Train from Scratch), ResNet50 (Fine Tuning) และ VGG16 (Fine Tuning) ตามลำดับ โดยให้ค่าความถูกต้องจากการทดสอบกับชุดข้อมูลประเมินเท่ากับ 90%, 89% และ 87% ตามลำดับ และจากการทดสอบกับชุดข้อมูลทดสอบเท่ากับ 92%, 89% และ 88% ตามลำดับ โดย DenseNet121 (Train from Scratch) มีขนาดเล็กที่สุดเท่ากับ 100 MB และ VGG16 (Fine Tuning) เป็นตัวแบบที่ใช้เวลาทดสอบต่อ 1 ภาพน้อยที่สุดเฉลี่ย 0.19 วินาที เมื่อใช้ GPU ในการประมวลผล ส่วน ResNet50 (Fine Tuning) เป็นตัวแบบที่ใช้เวลาทดสอบต่อ 1 ภาพน้อยที่สุดเฉลี่ย 1.40 วินาที เมื่อใช้ CPU ในการประมวลผล

จากรูปที่ 4 การเรียนรู้ของ DenseNet121 (Train from Scratch) และ ResNet50 (Fine Tuning) ยังคง Underfitting เล็กน้อย แต่แนวโน้มของค่า Accuracy และ Loss ไม่ผันผวนมากนัก ในขณะที่ VGG16 (Fine Tuning) ค่อนข้าง Good fit แต่แนวโน้มของค่า Accuracy และ Loss ค่อนข้างผันผวน คาดว่าสาเหตุส่วนหนึ่งเกิดจากความแตกต่างของ

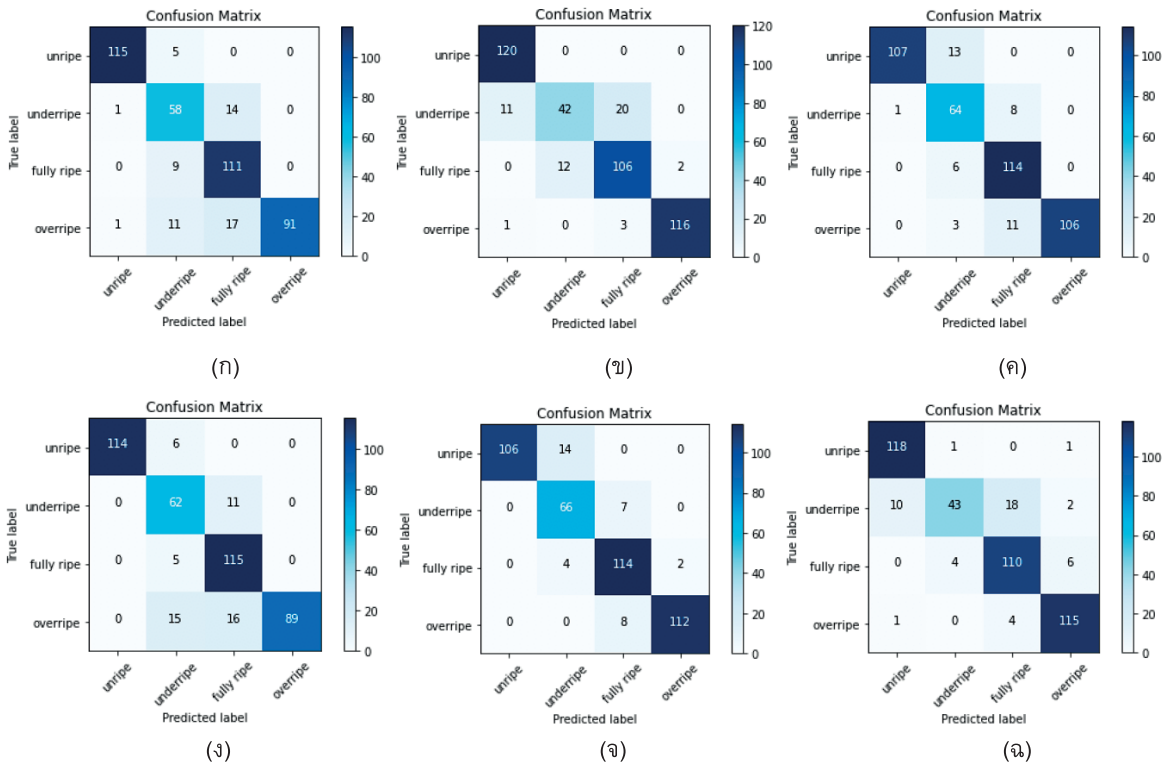
โครงสร้างของตัวแบบ โดยโครงสร้างของ DenseNet121 และ ResNet50 จะมี Batch Normalization ซึ่งทำหน้าที่เป็น Regularization เพื่อลดปัญหา Overfitting แต่เนื่องจากมีการใช้ Batch Normalization กับทุก Convolutional Layer จึงอาจส่งผลให้เกิดปัญหา Underfitting แทน อย่างไรก็ตาม จากการทดสอบกับชุดข้อมูลทดสอบยังให้ค่า Accuracy อยู่ในระดับเดียวกันกับการทดสอบกับชุดข้อมูลประเมิน จึงคาดว่าปัญหา Underfitting เพียงเล็กน้อยของตัวแบบดังกล่าวจะไม่ส่งผลเสียต่อการใช้งานจริงมากนัก นอกจากนี้ ยังมี Skip connection เพื่อลดปัญหา Vanishing Gradient ทำให้สามารถปรับค่าน้ำหนักการเรียนรู้ (Weight) ในแต่ละ epoch ได้โดยมีแนวโน้มของค่า Accuracy และ Loss ไม่ผันผวนมากนัก ในขณะที่โครงสร้างของ VGG16 เป็นตัวแบบที่ไม่มีทั้ง Batch Normalization และ Skip connection ทำให้ตัวแบบดังกล่าวมีโอกาสเกิดปัญหา Underfitting ได้น้อยกว่า แต่อาจส่งผลต่อการปรับค่าน้ำหนักการเรียนรู้ ทำให้แนวโน้มของค่า Accuracy และ Loss มีความผันผวนสูงกว่า เมื่อเปรียบเทียบกับตัวแบบอื่น



รูปที่ 4 Accuracy และ Loss ของการเรียนรู้ของตัวแบบ (ก) VGG16 (Fine Tuning), (ข) ResNet50 (Fine Tuning) และ (ค) DenseNet121 (Train from Scratch)

อย่างไรก็ตาม หากพิจารณาค่า F1 score ของการจำแนกความสุกของทะลายปาล์มแต่ละประเภทแล้ว จะสังเกตว่าแต่ละตัวแบบสามารถจำแนก Class1 (Unripe) และ Class4 (Overripe) ได้ดี โดยเฉลี่ยมีค่า F1 score อยู่ในช่วง 85-97% สูงกว่าค่าความถูกต้องของแต่ละตัวแบบ แต่ยังไม่

สามารถจำแนก Class2 (Underripe bunch) และ Class3 (Fully ripe bunch) ได้ดีมีค่านัก โดยเฉลี่ยมีค่า F1 score อยู่ในช่วง 66-92% ต่ำกว่าค่าความถูกต้องของแต่ละตัวแบบ โดยสามารถแสดงจำนวนภาพของการจำแนกประเภทของแต่ละตัวแบบจาก Confusion Matrix ได้ตามรูปที่ 5



รูปที่ 5 Confusion Matrix ของการทดสอบกับชุดข้อมูลประเมินของตัวแบบ (ก) VGG16 (Fine Tuning) (ข) ResNet50 (Fine Tuning) (ค) DenseNet121 (Train from Scratch) และของชุดข้อมูลทดสอบของตัวแบบ (ง) VGG16 (Fine Tuning) (จ) ResNet50 (Fine Tuning) (ฉ) DenseNet121 (Train from Scratch)

สาเหตุที่ตัวแบบไม่สามารถจำแนก Class2 (Underripe bunch) และ Class3 (Fully ripe bunch) ได้ดี คาดว่าเกิดจากทั้ง 2 Class มีคุณลักษณะด้านสีของทะลายปาล์มที่ใกล้เคียงกัน กล่าวคือ Class2 (Underripe bunch) จะมีผลปาล์มสีม่วงเป็นส่วนใหญ่บนทะลายปาล์มและเริ่มมีสีแดงให้เห็น ในขณะที่ Class3 (Fully ripe bunch) จะมีผลปาล์มสีแดงเป็นส่วนใหญ่บนทะลายปาล์มโดยอาจจะยังมีสีม่วงอ่อนปนอยู่บ้าง รวมถึงปัญหาจำนวนข้อมูลของ Class2 มีน้อยกว่า Class อื่น ๆ ขณะที่ Class1 (Unripe bunch) จะมีผลปาล์มสีม่วงอมดำเกือบทั้งทะลาย และ Class4 (Overripe bunch) มีผล

ปาล์มสีส้มออกเหลืองและลักษณะของทะลายปาล์มเริ่มแก่ จึงทำให้ตัวแบบส่วนใหญ่สามารถจำแนก 2 Class ดังกล่าวได้ดี ตัวอย่างตามรูปที่ 6

ทั้งนี้ เพื่อยืนยันว่าตัวแบบแต่ละประเภทสามารถจำแนกได้ถูกต้องจากการพิจารณาบริเวณทะลายปาล์มที่ถูกต้องจริง จึงนำตัวแบบข้างต้นมาทดสอบด้วยวิธี Grad-CAM เพื่อแสดง Heatmap บนภาพ โดยบริเวณที่เป็นสีส้มจนถึงแดงเข้มจะแสดงความน่าจะเป็นในระดับสูงซึ่งบ่งชี้ว่าเป็นบริเวณที่ตัวแบบใช้พิจารณาเพื่อจำแนกประเภท ส่วนการพิจารณาว่าเป็นบริเวณที่ถูกต้องหรือไม่ จากผลการทดสอบตามตารางที่ 8

พบว่าแต่ละตัวแบบพิจารณาบริเวณทะเลสาบหลักจริง เป็นส่วนใหญ่ มีเพียงส่วนน้อยที่ตัวแบบพิจารณาบริเวณอื่น ซึ่งมักจะเกิดขึ้นเมื่อมีทะเลสาบอื่นอยู่เป็นพื้นหลัง (ตาม ตัวอย่างรูปที่ 7) โดยหากพิจารณาค่า Adjusted Accuracy จากจำนวนภาพซึ่งตัวแบบสามารถจำแนกและแสดง Heatmap ถูกต้อง จะพบว่าค่า Adjusted accuracy ปรับลดลง เล็กน้อยจากเดิมประมาณ 2-6% คงเหลือประมาณ 86-88% โดยตัวแบบ ResNet50 (Fine Tuning) ให้ Adjusted Accuracy ดีที่สุดที่ 88% อย่างไรก็ตาม หากพิจารณาจาก F1 score ของแต่ละ Class ด้วย ตัวแบบ DenseNet121 (Train from Scratch) ยังคงเป็นตัวแบบที่ดีที่สุด โดยมี Adjusted


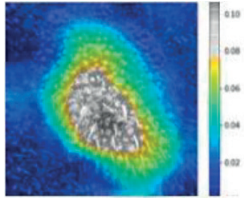
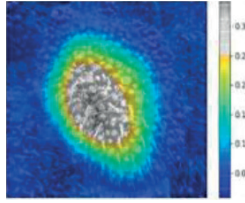
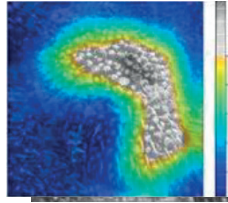

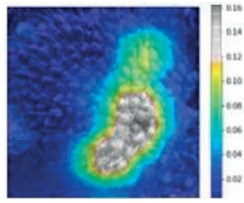
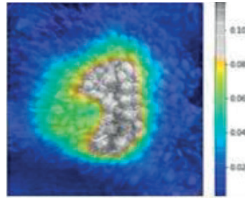
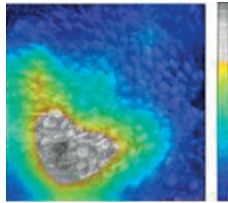
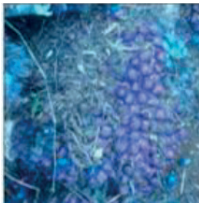
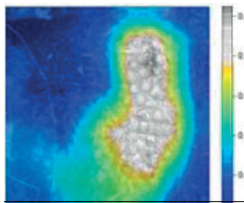
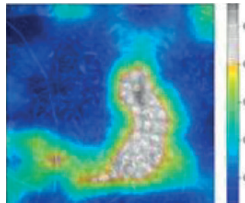
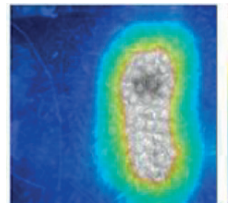
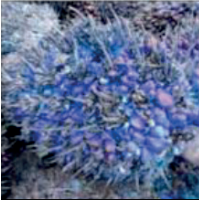
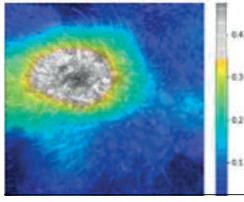
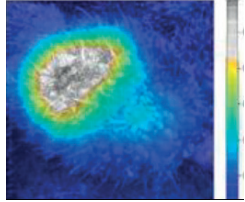
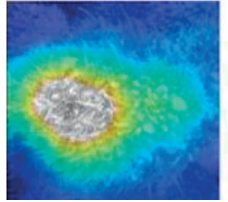
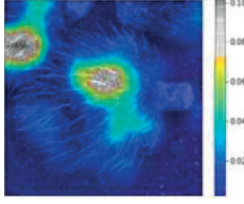
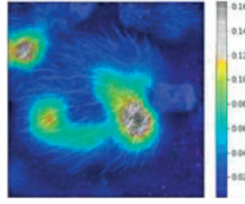
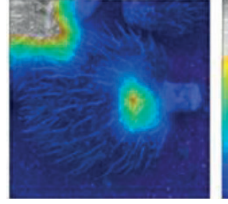
Accuracy 86% และ F1 score สูงกว่า 80% สำหรับทุก Class นอกจากนี้ ตัวแบบดังกล่าวยังมีความทนทานต่อการเปลี่ยนแปลงของค่าความสว่างของภาพถ่าย (Brightness) ได้ดี โดยยังสามารถจำแนกความสูงของทะเลสาบได้ถูกต้อง เทียบเท่ากับค่าความสว่างของแสงแดดปกติเมื่อปรับค่าความ สว่างลดลงหรือเพิ่มขึ้นในช่วง -70 ถึง +70 จากความสว่าง ของแสงแดดปกติ ในขณะที่ ResNet50 (Fine Tuning) สามารถจำแนกความสูงของทะเลสาบได้ถูกต้องเทียบ เท่ากับค่าความสว่างของแสงแดดปกติ เมื่อปรับค่าความสว่าง ลดลงหรือเพิ่มขึ้นในช่วง -30 ถึง +70 เท่านั้น



รูปที่ 6 (ก), (ข) แสดงตัวอย่างภาพ Class2 และ 3 ซึ่งตัวแบบ ResNet50 จำแนกว่าเป็น Class3 และ 2 ตามลำดับ และ (ค), (ง) แสดงตัวอย่างภาพ Class1 และ 4 ซึ่งตัวแบบ ResNet50 สามารถจำแนกได้ถูกต้อง

ตารางที่ 8 แสดงจำนวนภาพของข้อมูลทดสอบที่ตัวแบบจำแนกประเภทโดยพิจารณาบริเวณทะเลสาบได้ถูกต้อง และ เปรียบเทียบค่า Accuracy เดิม และ Adjusted accuracy (*)

Class	VGG16 (Fine Tuning)		ResNet50 (Fine Tuning)		DenseNet121 (Train from Scratch)	
	จำแนกถูก	จำแนกถูก และ Heatmap ถูก	จำแนกถูก	จำแนกถูก และ Heatmap ถูก	จำแนกถูก	จำแนกถูก และ Heatmap ถูก
1	114	113	118	118	106	99
2	62	60	43	42	66	64
3	115	113	110	105	114	111
4	89	86	115	114	112	98
Accuracy	88%	*86%	89%	*88%	92%	*86%


Class	Original Image	VGG16 (Fine Tuning)	ResNet50 (Fine Tuning)	DenseNet121 (Train from Scratch)
1				
2				
3				
4				
	ตัวอย่างภาพที่ตัวแบบ พิจารณาบริเวณอื่นซึ่งอยู่ นอกทะเลสาบปาล์มหลัก			

รูปที่ 7 แสดงตัวอย่าง Heatmap บนตำแหน่งของภาพซึ่งตัวแบบนำไปพิจารณาในการจำแนก

4.2 การปรับปรุงตัวแบบ

จากปัญหาตัวแบบเดิมยังไม่สามารถจำแนก Class2 (Underripe bunch) และ Class3 (Fully ripe bunch) ได้ดีนัก เนื่องจากคุณลักษณะด้านสีของ Class ดังกล่าว มีความใกล้เคียงกัน จึงทำการทดลองสร้างตัวแบบขึ้นมา 2 ตัวแบบ (ต่อไปนี้เรียกว่า “ตัวแบบ Combine” หรือ “(C)”) โดยตัวแบบที่ 1 ทดลองใช้ 3 ตัวแบบ ได้แก่ VGG16 (Fine Tuning), ResNet50 (Fine Tuning) และ

DenseNet121 (Train from Scratch) โดยจะเรียนรู้การจำแนกภาพ 3 ประเภท ได้แก่ Class1 (Underripe bunch), Class2&3 (Underripe และ Fully ripe bunch) และ Class4 (Overripe bunch) และตัวแบบที่ 2 ได้แก่ ResNet50 (Fine Tuning) จะเรียนรู้การจำแนกภาพ 2 ประเภท ได้แก่ Class2 และ Class3 เพื่อให้โดยรวมสามารถจำแนก Class2 และ Class3 ได้ดีขึ้น โดยสามารถแสดงขั้นตอนการทดสอบและผลลัพธ์การทดลอง ได้ตามรูปที่ 8



รูปที่ 8 แสดงขั้นตอนการจำแนกประเภทของตัวแบบ Combine

ตารางที่ 9 ผลลัพธ์ความถูกต้อง เวลาทดสอบ และขนาดของตัวแบบที่ปรับปรุงแต่ละประเภท

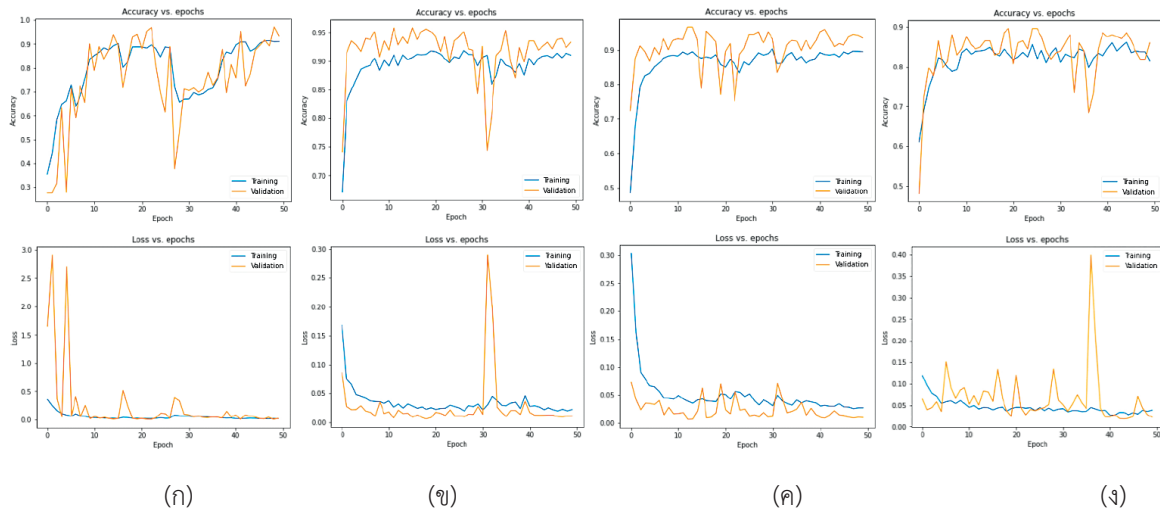
ตัวแบบ Combine	เทคนิค การเรียนรู้	ชุดข้อมูลประเมิน				ชุดข้อมูลทดสอบ				เวลาทดสอบ เฉลี่ยต่อ 1 ภาพ (วินาที)		ขนาด ตัว แบบ (MB)		
		Accu racy	F1 score				Accu racy	F1 score					GPU	CPU
			Class 1	Class 2	Class 3	Class 4		Class 1	Class 2	Class 3	Class 4			
VGG16(C)	Fine Tuning	87%	98%	83%	83%	81%	87%	96%	82%	84%	83%	1.22	3.22	236
ResNet50(C)	Fine Tuning	91%	95%	81%	89%	94%	92%	98%	85%	88%	94%	2.48	3.27	405
DenseNet121(C)	Train from Scratch	93%	99%	87%	89%	93%	93%	98%	86%	90%	94%	2.55	4.47	194

(C) คือ ตัวแบบ Combine โดยใช้ตัวแบบที่ 1 ได้แก่ VGG16, ResNet50 และ DenseNet121 และตัวแบบที่ 2 คือ ResNet50 (Fine Tuning)

จากตารางที่ 9 ตัวแบบ Combine ทั้ง 3 ประเภท ได้แก่ VGG16(C), ResNet50(C) และ DenseNet121(C) ให้ค่าความถูกต้อง (Accuracy) จากการทดสอบกับชุดข้อมูลประเมินเท่ากับ 87%, 91% และ 93% ตามลำดับ และจากการทดสอบกับชุดข้อมูลทดสอบเท่ากับ 87%, 92% และ 93% ตามลำดับ โดยตัวแบบ ResNet50(C) และ DenseNet121(C) ให้ค่าความถูกต้องสูงขึ้นเมื่อเปรียบเทียบกับตัวแบบดั้งเดิม ในขณะที่ตัวแบบ VGG16(C) ให้ค่าความถูกต้องใกล้เคียงเดิม อย่างไรก็ตามแม้ตัวแบบดังกล่าวจะให้ค่าความถูกต้องสูงขึ้น แต่ต้อง Trade-off กับการมีขนาดตัวแบบและเวลาในการทดสอบที่มากขึ้น เช่น DenseNet121(C) มีขนาดเล็กที่สุดเท่ากับ 194 MB เปรียบเทียบกับตัวแบบ

DenseNet121 (Train from Scratch) เดิมเท่ากับ 100 MB และใช้เวลาในการทดสอบเฉลี่ยต่อ 1 ภาพเท่ากับ 2.55 วินาที เปรียบเทียบกับตัวแบบ DenseNet121 (Train from Scratch) เดิมเท่ากับ 1.76 วินาที

จากรูปที่ 9 การเรียนรู้ของแต่ละตัวแบบมีลักษณะใกล้เคียงกับตัวแบบเดิมที่ได้จากการทดลองข้อ 4.1 ตามภาพที่ 5 แต่การเรียนรู้ของ ResNet50 (Fine Tuning) ของทั้งตัวแบบที่ 1 และ 2 มีแนวโน้มของค่า Accuracy และ Loss ผันผวนขึ้นจากเดิมเล็กน้อย อย่างไรก็ตาม จากการทดสอบกับชุดข้อมูลทดสอบยังให้ค่า Accuracy อยู่ในระดับเดียวกันกับการทดสอบกับชุดข้อมูลประเมิน โดยรวมตัวแบบยังสามารถใช้งานจริงได้ดี



รูปที่ 9 Accuracy และ Loss ของการเรียนรู้ของตัวแบบที่ 1 (a) VGG16 (Fine Tuning) (b) ResNet50 (Fine Tuning) (c) DenseNet121 (Train from Scratch) และตัวแบบที่ 2 (d) ResNet50 (Fine Tuning)

นอกจากนี้ หากพิจารณาค่า F1 score ของการจำแนก ความสุขของทะเลสาบปาล์มแต่ละประเภท โดยเฉพาะตัวแบบ ResNet50(C) และ DenseNet121(C) จะสังเกตว่าตัวแบบ Combine สามารถจำแนก Class2 (Underripe bunch) และ Class3 (Fully ripe bunch) ได้ดีขึ้นเมื่อเปรียบเทียบกับตัวแบบดั้งเดิม โดยเฉพาะมีค่า F1 score อยู่ในช่วง 80-90% พิจารณาแล้วอยู่ในเกณฑ์ที่ดีขึ้น โดยสามารถแสดงตัวชี้วัดของ Confusion Matrix และจำนวนภาพของการจำแนก

ประเภทของแต่ละตัวแบบจาก Confusion Matrix ได้ตาม ตารางที่ 10 และรูปที่ 10 โดยหากเปรียบเทียบกับรูปที่ 5 สังเกตได้ว่าตัวแบบ Combine สามารถจำแนก Class 2 ผิดเป็น Class 3 ได้น้อยกว่าตัวแบบดั้งเดิม ซึ่งช่วยให้โรงงานสกัดน้ำมันปาล์มสามารถป้องกันไม่ให้เกิดการรับซื้อทะเลสาบปาล์มที่มีเปอร์เซ็นต์น้ำมันต่ำกว่าเกณฑ์ได้ ทั้งนี้ สามารถแสดงตัวอย่างของการจำแนก Class 2 และ 3 ของตัวแบบ Combine ได้ดีขึ้นเมื่อเปรียบเทียบกับตัวแบบดั้งเดิม ตามรูปที่ 11

ตารางที่ 10 ตัวชี้วัดจาก Confusion Matrix ของตัวแบบ (ก) VGG16(C) (ข) ResNet50(C) และ (ค) DenseNet121(C) จากการทดสอบกับชุดข้อมูลทดสอบ

Class	Precision	Recall	F1 score	Support
1	92%	99%	96%	120
2	80%	84%	82%	73
3	78%	93%	84%	120
4	100%	71%	83%	120

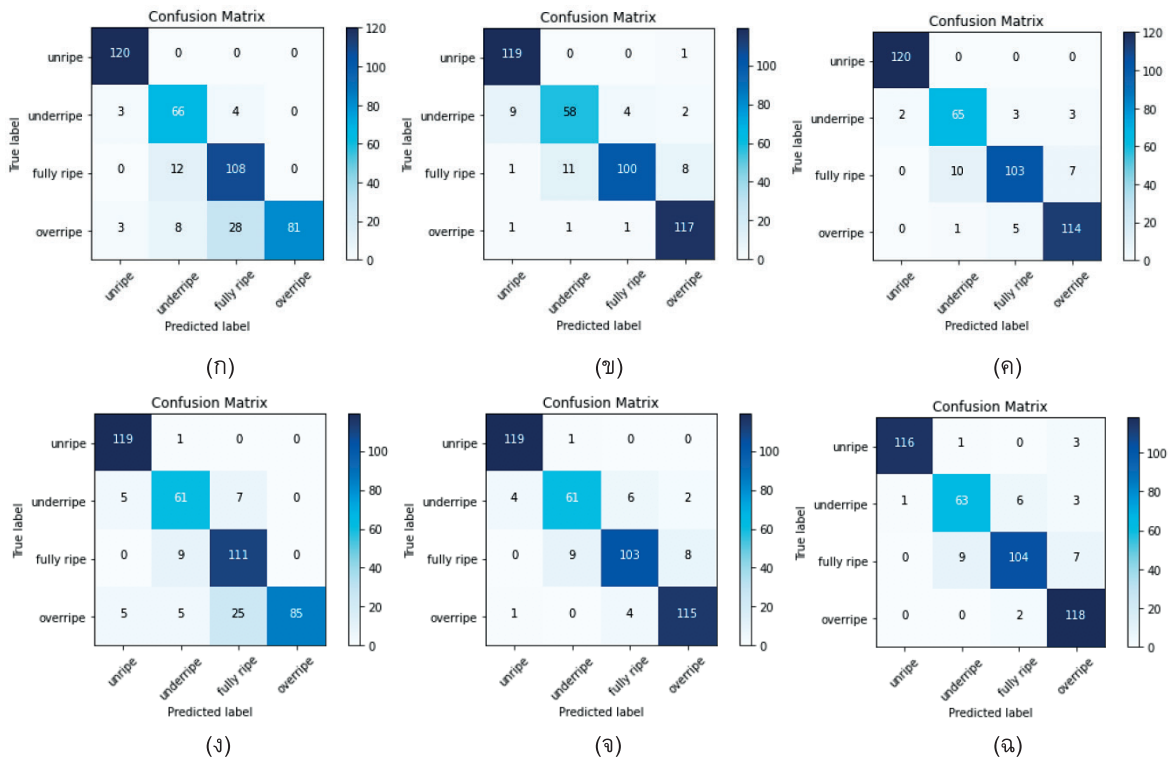
Class	Precision	Recall	F1 score	Support
1	92%	99%	96%	120
2	80%	84%	82%	73
3	78%	93%	84%	120
4	100%	71%	83%	120

Class	Precision	Recall	F1 score	Support
1	92%	99%	96%	120
2	80%	84%	82%	73
3	78%	93%	84%	120
4	100%	71%	83%	120

(ก)

(ข)

(ค)



รูปที่ 10 Confusion Matrix ของการทดสอบชุดข้อมูลประเมินของตัวแบบ (ก) VGG16(C) (ข) ResNet50(C) (ค) DenseNet121(C) และของชุดข้อมูลทดสอบของตัวแบบ (ง) VGG16(C) (จ) ResNet50(C) (ฉ) DenseNet121(C)

Class	Original Image	ResNet50 (Fine Tuning) แบบเดิม	ResNet50 (Fine Tuning) ตัวแบบที่ 2
2			
3			


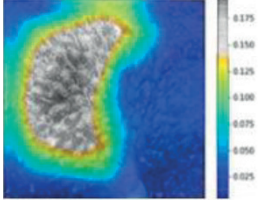
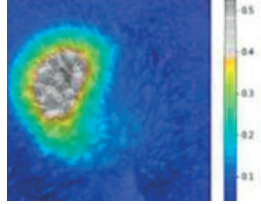
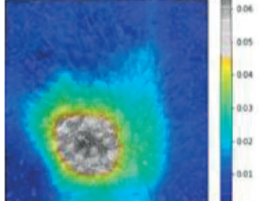
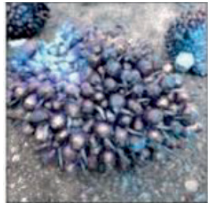
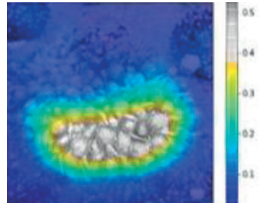
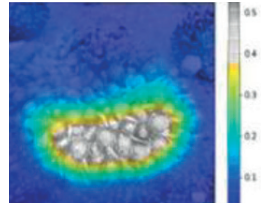
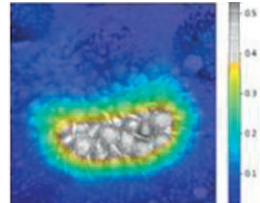
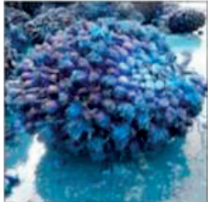
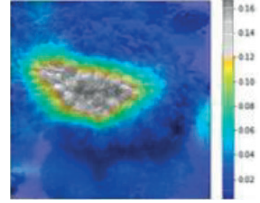
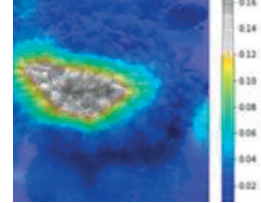
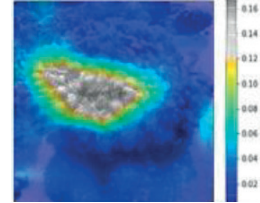

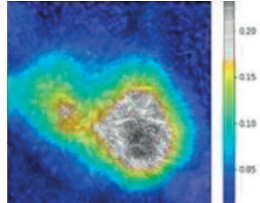
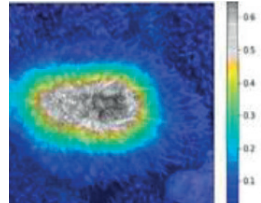
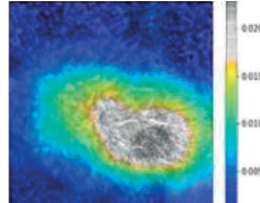
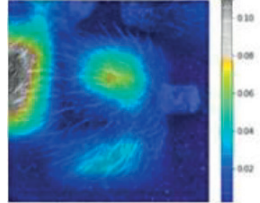
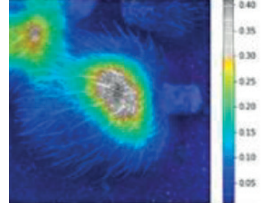
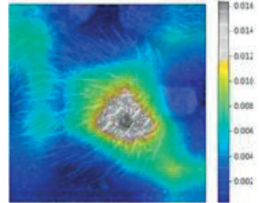
รูปที่ 11 ตัวอย่างเปรียบเทียบ Heatmap บนทะเลยาปาล์ม Class2 และ 3 ของตัวแบบ ResNet50 (Fine Tuning) แบบเดิม กับ ResNet50 (Fine Tuning) ของตัวแบบที่ 2

ทั้งนี้ เพื่อยืนยันว่าตัวแบบแต่ละประเภทสามารถจำแนกได้ถูกต้องจากการพิจารณาบริเวณทะเลลายปาล์มที่ถูกต้องจริง จึงนำตัวแบบข้างต้นมาทดสอบด้วยวิธี Grad-CAM จากผลการทดสอบตามตารางที่ 11 พบว่าแต่ละตัวแบบพิจารณาบริเวณทะเลลายปาล์มหลักจริงเป็นส่วนใหญ่ มีเพียงส่วนน้อยที่ตัวแบบพิจารณาบริเวณอื่น ซึ่งมักจะเกิดขึ้นเมื่อมีทะเลลายปาล์มอื่นอยู่เป็นพื้นหลัง (ตามตัวอย่างรูปที่ 12) โดยหากพิจารณาค่า Adjusted Accuracy จากจำนวนภาพซึ่งตัวแบบสามารถจำแนกและแสดง Heatmap ถูกต้อง จะพบว่าค่า Adjusted accuracy ปรับลดลงเล็กน้อยจากเดิมประมาณ 2-5% คงเหลือประมาณ 84-90% โดยตัวแบบ ResNet50(C) ให้ Adjusted Accuracy ดีที่สุดที่ 90% เปรียบเทียบกับตัว

แบบเดิมดีขึ้น 2% อย่างไรก็ตาม สำหรับตัวแบบ DenseNet121(C) จะมี Adjusted Accuracy 88% ต่ำกว่าตัวแบบ ResNet50(C) เล็กน้อย แต่มีความทนทานต่อการเปลี่ยนแปลงของค่าความสว่างของภาพถ่าย (Brightness) ได้ดีกว่า ResNet50(C) โดยตัวแบบ DenseNet121(C) ยังสามารถจำแนกความสูงของทะเลลายปาล์มได้ถูกต้องเทียบเท่ากับค่าความสว่างของแสงแดดปกติเมื่อปรับค่าความสว่างลดลงหรือเพิ่มขึ้นในช่วง -70 ถึง +70 จากความสว่างของแสงแดดปกติ ในขณะที่ ResNet50(C) สามารถจำแนกความสูงของทะเลลายปาล์มได้ถูกต้องเทียบเท่ากับค่าความสว่างของแสงแดดปกติเมื่อปรับค่าความสว่างลดลงหรือเพิ่มขึ้นในช่วง -30 ถึง +70 จากความสว่างของแสงแดดปกติเท่านั้น

ตารางที่ 11 แสดงจำนวนภาพของข้อมูลทดสอบที่ตัวแบบจำแนกประเภทโดยพิจารณาบริเวณทะเลลายปาล์มได้ถูกต้อง และเปรียบเทียบค่า Accuracy เดิม และ Adjusted Accuracy (*)

Class	VGG16(C)		ResNet50(C)		DenseNet121(C)	
	จำแนกถูก	จำแนกถูก และ Heatmap ถูก	จำแนกถูก	จำแนกถูก และ Heatmap ถูก	จำแนกถูก	จำแนกถูก และ Heatmap ถูก
1	119	119	119	119	116	113
2	61	59	61	59	63	61
3	111	105	103	97	104	98
4	85	81	115	113	118	108
Accuracy	87%	*84%	92%	*90%	93%	*88%

Class	Original Image	VGG16(C)	ResNet50(C)	DenseNet121(C)
1				
2				
3				
4				
	ตัวอย่างภาพที่ตัวแบบ พิจารณาริเวณอื่นซึ่งอยู่ นอกทะเลสาบปาล์มหลัก			

รูปที่ 12 แสดงตัวอย่าง Heatmap บนตำแหน่งของภาพซึ่งตัวแบบนำไปพิจารณาในการจำแนก

5. บทสรุป

จากการทดลองทั้งหมด ตัวแบบ ResNet50(C) เป็นตัวแบบซึ่งให้ Adjusted Accuracy ดีที่สุดที่ 90% โดย F1 score ของแต่ละ Class สูงกว่า 80% อย่างไรก็ตาม ค่าความถูกต้องดังกล่าวต้อง Trade-off กับการมีตัวแบบซึ่งมีขนาดใหญ่และใช้เวลาเฉลี่ยในการทดสอบนานขึ้น (405 MB, 2.48 วินาที (GPU), 3.27 วินาที (CPU)) แต่หากผู้ใช้ให้ความสำคัญกับขนาดของตัวแบบที่เล็กลงและใช้เวลาเฉลี่ยในการทดสอบที่เร็วขึ้นด้วย สามารถพิจารณาเลือกใช้ตัวแบบ DenseNet121 (Train from Scratch) ซึ่งให้ Adjusted Accuracy 86% น้อยกว่าตัวแบบ ResNet50(C) เล็กน้อย แต่ยังคงมี F1 score ของแต่ละ Class สูงกว่า 80% เช่นเดียวกัน ในขณะที่ตัวแบบมีขนาดเล็กลงและใช้เวลาเฉลี่ยในการทดสอบได้เร็วขึ้น (100 MB, 1.76 วินาที (GPU), 2.56 วินาที (CPU)) รวมถึงมีความทนทานต่อการเปลี่ยนแปลงของค่าความสว่างของภาพถ่าย (Brightness) ได้ดี (ช่วง -70 ถึง +70 จากความสว่างของแสงแดดปกติ)

อย่างไรก็ตาม ตัวแบบของงานวิจัยนี้ยังมีข้อจำกัดบางประการ ได้แก่

- ตัวแบบไม่สามารถใช้จำแนกทะเลลายปาล์มสายพันธุ์สุราษฎร์ธานี 1 ได้ เนื่องจากเป็นสายพันธุ์ที่มีลักษณะของสีแตกต่างกันสายพันธุ์อื่นและพบได้น้อยในประเทศไทย จึงไม่ได้รับรวบรวมภาพถ่ายทะเลลายปาล์มสายพันธุ์ดังกล่าวไว้ในชุดข้อมูลสำหรับงานวิจัยนี้

- ชุดข้อมูลมีการระบุประเภทความสูงของทะเลลายปาล์มโดยคน ไม่ได้ระบุตามการวัดระดับเปอร์เซ็นต์น้ำมันปาล์มที่ได้จริง ดังนั้นการแบ่งประเภทความสูงของตัวแบบในงานวิจัยนี้จึงอาจได้รับผลกระทบจากความเอนเอียงของคน และไม่ได้สะท้อนถึงเปอร์เซ็นต์น้ำมันจริง

- เนื่องจากตัวแบบได้เรียนรู้จากทะเลลายปาล์มเต็มใบต่อ 1 ภาพถ่าย โดยสามารถมีทะเลลายประเภทอื่นเป็นพื้นหลังได้บ้าง ตัวแบบจึงมีข้อจำกัดไม่สามารถจำแนกความสูงจากภาพถ่ายของทะเลลายปาล์มซึ่งมีจำนวนมากกว่า 1 ทะลาย รวมถึงภาพถ่ายซึ่งมีพื้นหลังเป็นทะเลลายปาล์มทะเลลายอื่นโดยมีพื้นที่ของพื้นหลังต่อพื้นที่ภาพถ่ายทั้งหมดเป็นสัดส่วนที่สูง

สำหรับข้อเสนอแนะการนำตัวแบบของงานวิจัยนี้ไปใช้งาน และการศึกษาต่อยอดในอนาคต สรุปได้ดังนี้

- กรณีโรงงานสกัดน้ำมันปาล์มต้องการนำตัวแบบไปใช้ในการจำแนกความสูงของทะเลลายปาล์ม สามารถประยุกต์ใช้ได้หลายวิธี ได้แก่ 1) ให้นักงานใช้เป็นเครื่องมือช่วยในการจำแนกความสูงของทะเลลายปาล์ม ณ จุดรับซื้อ และ 2) ใช้กับระบบสายพานอัตโนมัติ โดยติดตั้งกล้องในตำแหน่งด้านบนของสายพาน เพื่อถ่ายภาพของทะเลลายปาล์มที่เข้ามาตามสายพานซึ่งอยู่ด้านล่าง ซึ่งจะทำให้ได้ภาพถ่ายด้านข้างของทะเลลายปาล์มซึ่งเป็นมุมที่สามารถเห็นผลปาล์มได้ชัดเจน เนื่องจากรูปทรงตามธรรมชาติของทะเลลายปาล์มจะบังคับให้ทะเลลายปาล์มต้องล้มลงทางด้านข้างเสมอ และควรพิจารณาเลือกใช้ตัวแบบที่มีความทนทานต่อการเปลี่ยนแปลงของค่าความสว่างของภาพถ่าย (Brightness) ได้ดีสำหรับกรณีที่อยู่ในระบบสายพานมีข้อจำกัดด้านปริมาณแสงสว่าง

- การระบุประเภทความสูงของทะเลลายปาล์มโดยการวัดระดับเปอร์เซ็นต์น้ำมันปาล์มที่ได้จริงตามกระบวนการทางวิทยาศาสตร์ จะช่วยให้สามารถสร้างตัวแบบซึ่งสามารถจำแนกความสูงของทะเลลายปาล์มตามเปอร์เซ็นต์น้ำมันจริงได้โดยไม่มีผลกระทบจากความเอนเอียงของคน

- ข้อจำกัดของตัวแบบซึ่งไม่สามารถจำแนกความสูงจากภาพถ่ายของทะเลลายปาล์มซึ่งมีจำนวนมากกว่า 1 ทะลาย รวมถึงภาพถ่ายซึ่งมีพื้นหลังเป็นทะเลลายปาล์มทะเลลายอื่น สามารถแก้ไขได้ด้วยการพัฒนาตัวแบบการเรียนรู้เชิงลึกประเภทอื่น ได้แก่ Object Detector หรือ Segmentation

- แนวคิดของงานวิจัยนี้ สามารถนำไปประยุกต์ใช้กับการศึกษาผลิตภัณฑ์ทางการเกษตรอื่น ๆ ได้เช่นเดียวกัน โดยเฉพาะการจำแนกโดยใช้สายตาในการสังเกตคุณลักษณะของพื้นผิว เช่น การจำแนกความสูงของขนุนหรือทุเรียนด้วยการสังเกตจากลักษณะของหนาม

7. เอกสารอ้างอิง

1. U.S. Department of Agriculture, 2020, World Production of Palm Oil 2020 [Online], Available: https://ipad.fas.usda.gov/cropexplorer/cropview/commodityView.aspx?cropid=4243000&sel_year=2020&startrow=1. [29 July 2021]

2. Krungsri Research, 2020, Industry Outlook 2020-2022: Palm Oil Industry [Online], Available:

[https://www.krungsri.com/en/research/industry/industry-outlook/agriculture/sugar-\(1\)/IO/io-oil-palm-20-th](https://www.krungsri.com/en/research/industry/industry-outlook/agriculture/sugar-(1)/IO/io-oil-palm-20-th).

3. The Department of Internal Trade, 2020, Public Information: Palm oil [Online], Available: https://agri.dit.go.th/index.php/department_sub/3/ปาล์มน้ำมัน/28. [29 July 2021]

4. The Department of Internal Trade, 2018, Announcement of the Office of the Central Committee on Prices of Goods and Services No. 13 (2018) Regarding the Purchase Price of Crude Palm Oil (2nd time) [Online], Available: <https://www.dit.go.th/Content.aspx?m=12&c=14486>. [29 July 2021]

5. National Bureau of Agricultural Commodity and Food Standards, 2019, Thai Agriculture Standard: Oil Palm Bunch [Online], Available: <https://www.opsmoac.go.th/krabi-dwl-files-421591791812>. [29 July 2021]

6. Malaysian Palm Oil Board (MPOB), 2003, MPOB Grading Manual [Online], Available: https://dokumen.tips/download/link/mpob-grading-manualnew2.html#google_vignette. [29 July 2021]

7. Alfatni, M.S.M., Shariff, A.R.M., Shafri, H.Z.M., Saaed, O.M.B. and Eshanta, O.M., 2008, "Oil Palm Fruit Bunch Grading System using Red, Green and Blue Digital Number," *Journal of Applied Sciences*, 8 (8), pp. 1444-1452.

8. Jamil, N., Mohamed, A. and Abdullah, S., 2009, "Automated Grading of Palm Oil Fresh Fruit Bunches (FFB) using Neuro-fuzzy Technique," *2009 International Conference of Soft Computing and Pattern Recognition*, pp. 245-249.

9. Fadilah, N. Mohamad-Saleh, J., Halim, Z.A., Ibrahim, H. and Ali, S.S.S., 2012, "Intelligent Color Vision System for Ripeness Classification of Oil Palm Fresh Fruit Bunch," *Sensors (Basel, Switzerland)*, 12 (10), pp. 14179-14195.

10. Fadilah, N. and Mohamad-Saleh, J., 2014, "Color Feature Extraction of Oil Palm Fresh Fruit Bunch Image for Ripeness Classification," *International Conference on Applied Computer and Applied Computational Science (ACACOS)*, 23-25 April 2014, Kuala Lumpur, Malaysia, pp. 51-55.

11. Bensaheed, O.M., Shariff, A.M., Mahmud, A.B., Shafri, H. and Alfatni, M., 2014, "Oil Palm Fruit Grading using a Hyperspectral Device and Machine Learning Algorithm," *IOP Conference Series: Earth and Environmental Science*, 7th IGRSM International Remote Sensing & GIS Conference and Exhibition, 22-23 April 2014, Kuala Lumpur, Malaysia.

12. Ibrahim, Z., Sabri, N. and Isa, D., 2018, "Palm Oil Fresh Fruit Bunch Ripeness Grading Recognition using Convolutional Neural Network," *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 10 (3-2), pp. 109-113.

13. Saleh, A. and Liansitim, E., 2020, "Palm Oil Classification using Deep Learning," *Science in Information Technology Letters*, 1 (1), pp. 1-8.

14. Herman, H. Susanto, A., Cenggoro, T.W., Suharjito, S. and Pardamean, B., 2020, "Oil Palm Fruit Image Ripeness Classification with Computer Vision using Deep Learning and Visual Attention," *Journal of Telecommunication, Electronic and Computer Engineering (JTEC)*, 12 (2), pp. 21-27.

15. Herman, H., Cenggoro, T.W., Susanto, A. and Pardamean, B., 2021, "Deep Learning for Oil Palm Fruit Ripeness Classification with DenseNet," *IEEE International Conference on Information Management and Technology (ICIMTech)*, 19-20 August 2021, Jakarta, Indonesia.

16. Simonyan, K. and Zisserman, A., 2015, "Very Deep Convolutional Networks for Large-Scale Image Recognition," *International Conference on Learning Representations (ICLR)*, 7-9 May 2015, San Diego,

CA, USA, pp. 1-14.

17. He, K., Zhang, X., Ren, S. and Sun, J., 2016, "Deep Residual Learning for Image Recognition," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 27-30 June 2016, Las Vegas, NV, USA.

18. Tan, M. and Le, Q.V., 2019, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *International Conference on Machine Learning (ICML)*, 9-15 June 2019, Long Beach, CA, USA, pp. 6105-6114.

19. Huang, G., Liu, Z., Maaten, L. and Weinberger, K.Q., 2017, "Densely Connected Convolutional Networks," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 21-26 July 2017, Honolulu, HI, USA.

20. Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J. and Wojna, Z., 2016, "Rethinking the Inception Architecture for Computer Vision," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 27-30 June 2016, Las Vegas, NV, USA.

21. Chollet, F., 2017, "Xception: Deep Learning with Depthwise Separable Convolutions," *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 21-26 July 2017, Honolulu, HI, USA.

22. Howard, A., Sandler, M., Chen, B., Wang, W., Chen, L., Tan, M., Chu, G., Vasudevan, V., Zhu, Y., Pang, R., Adam, H. and Le, Q., 2019, "Searching for MobileNetV3," *IEEE/CVF International Conference on Computer Vision (ICCV)*, 27 October-2 November 2019, Seoul, South Korea.

23. Lin, T., Goyal, P., Girshick, R., He, K. and Dollár, P., 2017, "Focal Loss for Dense Object Detection," *IEEE International Conference on Computer Vision (ICCV)*, 22-29 October 2017, Venice, Italy.

24. Selvaraju, R.R., Cogswell, M., Das, A., Vedantam, R., Parikh, D. and Batra, D., 2017, "Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization," *IEEE International Conference on Computer Vision (ICCV)*, 22-29 October 2017, Venice, Italy.