

การเพิ่มประสิทธิภาพความแม่นยำในการจำแนกความสุขของทุเรียน ด้วยการตัดภาพพื้นหลังแบบไฮบริด

รติพร จันทร์กลั่น* กิระชาติ สุขสุทธิ เกตุกาญจน์ โพธิจิตติกานต์ พรภัสสร อ่อนเกิด และ
อภิชาติ ติรประเสริฐสิน

คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน

744 ถนนสุนทราราม ตำบลในเมือง อำเภอเมือง จังหวัดนครราชสีมา 30000

รับบทความ 26 มีนาคม 2567 แก้ไขบทความ 17 ธันวาคม 2567 ตอบรับบทความ 23 มกราคม 2568

บทคัดย่อ

ทุเรียนเป็นผลไม้เศรษฐกิจที่สำคัญของประเทศไทย ได้รับความนิยมในการบริโภคทั้งในประเทศและต่างประเทศ ส่งผลให้ทุเรียนมีบทบาทสำคัญในการกระตุ้นเศรษฐกิจทั้งในระดับประเทศและระหว่างประเทศ โดยเฉพาะทุเรียนสายพันธุ์หมอนทองซึ่งได้รับความนิยมเป็นอย่างสูง ซึ่งทุเรียนสามารถบริโภคได้ทั้งการบริโภคแบบสดหรือบริโภคแปรรูปได้ สำหรับการบริโภคทุเรียนแบบสดหรือต้องการซื้อทุเรียนเพื่อทำการแปรรูปโดยมีเงื่อนไขจากระดับความสุขของทุเรียนเข้ามาเกี่ยวข้อง หากไม่มีความเชี่ยวชาญในการจำแนกทุเรียนสุกหรือดิบ อาจส่งผลให้ได้รับทุเรียนที่ไม่ตรงตามความต้องการของตนเอง ซึ่งในปัจจุบันมีการประยุกต์เทคนิคด้านปัญญาประดิษฐ์เข้ามาใช้ในการจำแนกระดับความสุขของผลไม้เพื่อช่วยผู้บริโภคในการเลือกผลไม้ให้ได้ตรงตามที่ต้องการ โดยใช้รูปภาพของผลไม้ซึ่งบางครั้งจะมีภาพพื้นหลังติดไปด้วย เมื่อนำภาพเหล่านั้นไปประมวลผลจะต้องมีการตัดภาพพื้นหลังออกเพื่อให้ประสิทธิภาพในการจำแนกข้อมูลดีขึ้น ในบางครั้งการใช้ความรู้ด้านการประมวลผลภาพที่มีอยู่ในการตัดพื้นหลังของรูปด้วยอัลกอริทึมสำหรับตัดภาพพื้นหลังเพียงชนิดเดียวอาจไม่ดีเพียงพอต่อการใช้งานสำหรับบางข้อมูล ดังนั้นงานวิจัยนี้จึงนำเสนอการเพิ่มประสิทธิภาพการเรียนรู้เชิงลึกในการจำแนกความสุขของทุเรียนด้วยการตัดภาพพื้นหลังแบบไฮบริด ด้วยการใช้อัลกอริทึมโซเบลในการหาขอบของทุเรียนร่วมกับการตัดภาพพื้นหลังด้วยอัลกอริทึมแกรปคัท หลังจากนั้นนำไปสร้างรูปแบบการเรียนรู้ด้วยอัลกอริทึมการเรียนรู้เชิงลึก 4 รูปแบบ เพื่อเปรียบเทียบประสิทธิภาพการจำแนกระดับความสุขของทุเรียนระหว่างการใช้รูปดั้งเดิมกับการใช้รูปภาพที่ตัดพื้นหลัง ผลลัพธ์ที่ได้พบว่าวิธีการตัดภาพพื้นหลังที่นำเสนอส่งผลให้ความแม่นยำในการจำแนกประเภททุเรียนมีความแม่นยำมากยิ่งขึ้น โดยเฉลี่ยทั้ง 4 อัลกอริทึมมีประสิทธิภาพเพิ่มขึ้นที่ร้อยละ 8

คำสำคัญ : การประมวลผลภาพ; การตัดพื้นหลังภาพ; การเรียนรู้เชิงลึก; โครงข่ายประสาทเทียมแบบคอนโวลูชัน;
การจำแนกประเภททุเรียนหมอนทอง

* ผู้นิพนธ์ประสานงาน โทร: +669 9469 6164, ไปรษณีย์อิเล็กทรอนิกส์: ratiporn.ch@rmuti.ac.th

Enhancing the Accuracy of Durian Ripeness Classification using Hybrid Background Removal

Ratiporn Chanklan* Keerachart Suksut Kedkarn Podhijitkarn

Pornpassorn Onkerd and Apichat Terapasirdsin

Faculty of Engineering and Technology, Rajamangala University of Technology Isan

744 Suranarai Road, Nai Mueang, Muang, Nakhon Ratchasima, 30000

Received 26 March 2024; Revised 17 December 2024; Accepted 23 December 2025

Abstract

Durian is an economically important fruit in Thailand. It is widely consumed, both domestically and internationally. As a result, durians play a significant role in stimulating the economy, both nationally and internationally. Among the various varieties, the Monthong durian stands out as the most popular. Durian can be consumed in either fresh or processed forms. For fresh consumption or purchasing durian for processing purposes, the ripeness level of the durian is a critical factor to consider. However, without skilled classification, rip or unrip durians may lead to the acquisition of that does not meet their own needs. Currently, artificial intelligence techniques have been applied to fruit maturity classification to help consumers choose suitable fruits by using fruit images, sometimes having a background image attached to them. When processing these images, it is necessary to remove the background to improve the efficiency of data classification. In some cases, using existing knowledge in image processing to remove the background of an image using a single background removal algorithm may not be sufficient for certain types of data. Therefore, this research presents the enhancement of deep learning efficiency in classifying the ripeness of durians with hybrid background removal, edge detection with Sobel algorithms and Grab Cut algorithms for clipping image background then create model with 4 deep learning algorithms to compare the classification performance between using the original image data and image background clipping, the result shown that the proposed techniques can improve the classification performances with average the 4 algorithms at 8%.

Keywords : Image Processing; Background Clipping; Deep Learning; Convolution Neural Network; Monthong Durian Classification

* *Corresponding Author. Tel.: +669 9469 6164, E-mail Address: ratiporn.ch@rmuti.ac.th*

1. บทนำ

ทุเรียนเป็นผลไม้เศรษฐกิจที่สำคัญของประเทศไทย เนื่องจากได้รับความนิยมในการบริโภคทั้งในประเทศและต่างประเทศ โดยทุเรียนเป็นผลไม้ที่ให้รสชาติหวาน และแต่ละสายพันธุ์ก็จะมีรสสัมผัสที่แตกต่างกัน โดยการบริโภคทุเรียนสามารถบริโภคได้หลากหลายรูปแบบ ไม่ว่าจะเป็นการรับประทานสด หรือผ่านการแปรรูปต่าง ๆ แต่ปัญหาของบุคคลทั่วไปที่ต้องการบริโภคทุเรียน มักจะไม่มีความรู้ว่าทุเรียนลูกใดสุกหรือดิบ หรือพร้อมให้รับประทานหรือไม่ ซึ่งบางครั้งอาจซื้อทุเรียนได้ไม่ตรงตามความต้องการของตนเอง

ปัจจุบันเทคโนโลยีปัญญาประดิษฐ์มีบทบาทอย่างมากสู่สังคมมนุษย์ ไม่ว่าจะเป็นช่วยในเรื่องของการจัดการข้อมูลต่าง ๆ การบริหาร การวางแผนการตลาด การจำแนกประเภทของสิ่งของต่าง ๆ การทำนายการเจ็บป่วย รวมไปถึงการใช้ในการจำแนกประเภทข้อมูลเกี่ยวกับภาคเกษตรกรรม ใช้ในการจำแนกโรคพืช การจำแนกศัตรูพืช จำแนกชนิดของพืช หรือผลไม้ รวมไปถึงใช้ในการจำแนกความสุกของผลไม้ แต่ในบางครั้งระบบปัญญาประดิษฐ์ก็ยังมีประสิทธิภาพไม่สูงเพียงพอที่จะเป็นที่ยอมรับ จนนำไปสู่การนำไปประยุกต์ใช้งานได้ เช่น การใช้รูปภาพเพื่อจำแนกความสุกของผลไม้ หากไม่มีการประมวลผลภาพก็จะทำให้ประสิทธิภาพในการจำแนกความสุกของผลไม้ด้อยลงไปด้วย

ในปัจจุบันได้มีการเรียนรู้เชิงลึกนำมาใช้ในการจำแนกทุเรียนมากมายเนื่องจากการจำแนกข้อมูลทุเรียนไม่จะเป็นการจำแนกประเภทหรือระดับความสุกสามารถตรวจสอบได้โดยใช้ผู้เชี่ยวชาญเท่านั้น N. M. Z. Hashim และคณะ [1] เสนอการใช้โครงข่ายประสาทเทียมคอนโวลูชัน (Convolutional Neural Network) หรือที่เรียกว่า CNN) ซึ่งเป็นโครงข่ายที่มีประสิทธิภาพสำหรับงานด้านการจำแนกวัตถุ เพื่อจำแนกประเภททุเรียน 2 พันธุ์ ได้แก่ ทุเรียนกัมปงและทุเรียนมุซังคิงซึ่งเป็นทุเรียนท้องถิ่นในมาเลเซีย โดยมีความแม่นยำในการ

จำแนกประเภททุเรียนร้อยละ 80 J. N. Uy และคณะ [2] เห็นว่าในปัจจุบันทุเรียนมีหลากหลายพันธุ์ซึ่งยากต่อการแยกแยะ จึงต้องการสร้างอุปกรณ์พกพาเพื่อใช้ในการระบุและจำแนกพันธุ์ทุเรียน โดยใช้ข้อมูลรูปภาพทุเรียนที่ผ่านกระบวนการหาขอบแบบ Canny นำเข้า CNN เพื่อสร้างโมเดลที่ใช้ระบุทุเรียน 6 สายพันธุ์ที่มีประสิทธิภาพ J. R. Balbin และคณะ [3] ใช้ Principal Component Analysis (PCA) และอัลกอริทึม Support Vector Machine (SVM) สร้างโมเดลที่ใช้จำแนกระดับความสุกของผลทุเรียนที่มีความแม่นยำร้อยละ 95 และมีอัตราการจำแนกระดับความสุกผิดพลาดร้อยละ 5

นอกจากนี้ยังมีงานวิจัยที่ใช้การวัดระดับความสุกของผลไม้จากการใช้รูปภาพด้วยการใช้เทคนิคประมวลผลภาพร่วมกับอัลกอริทึมต่าง ๆ ดังนี้ A. P. Bhandarkar และคณะ [4] ได้พัฒนาเทคนิคการตรวจสอบความสุกของผลไม้ด้วยภาพถ่าย โดยใช้เทคนิคการประมวลผลภาพและอัลกอริทึม VGG16 ร่วมกับการลดมิติข้อมูลด้วยอัลกอริทึม PCA (Principle Component Analysis) C. C. Olisah และคณะ [5] ได้เสนอวิธีตรวจสอบความสุกของผลแบล็กเบอร์รี่โดยใช้โมเดล VGG16 ด้วยชุดข้อมูล ImageNet S. Lee และคณะ [6] ได้วิเคราะห์ลักษณะภายนอกของผลไม้ด้วยรูปภาพเพื่อสร้างโมเดลการเรียนรู้เชิงลึกด้วยอัลกอริทึม YOLOv8 สำหรับการจำแนกระดับความสุกของผลไม้ Suharjito และคณะ [7] ได้ตรวจสอบระดับความสุกของผลปาล์มเพื่อนำไปใช้ในการปรับปรุงคุณภาพของน้ำมันปาล์มด้วยการใช้อัลกอริทึม YOLOv8 ร่วมกับการประมวลผลภาพ P. K. Mishra และคณะ [8] ได้เสนอวิธีการลดปัญหาการสูญเสียผลผลิตที่เกิดจากการเก็บเกี่ยวล่าช้า หรือก่อนเวลาอันควร ด้วยการใช้รูปภาพผลไม้ร่วมกับอัลกอริทึม CNN (Convolution Neural Network) เพื่อจำแนกระดับความสุกของผลไม้

สำหรับการจำแนกระดับความสุกของทุเรียนด้วยการใช้รูปภาพ มีงานวิจัยที่ได้ดำเนินการวิจัย

ดังต่อไปนี้ S. Sukkasem และคณะ [9] ได้เสนอการใช้ อัลกอริทึมการเรียนรู้เชิงลึกด้วย Inception-v2, Inception-v3, VGGNet16, VGGNet19, ResNet-50, ResNet-101, ResNet-152, MobileNet-v2, MobileNet-v3 สร้างโมเดลเพื่อใช้ในการจำแนกระดับ ความสุขของทุเรียนโดยใช้ภาพถ่ายของทุเรียนพันธุ์ หมอนทองแบ่งออกเป็น 4 ระดับได้แก่ สุกเกินไป กึ่งสุก ดิบ และ สุก โมเดลที่ให้ผลลัพธ์ที่ดีที่สุดคือ MobileNet-v2: ซึ่งมีความแม่นยำสูงสุดที่ร้อยละ 95.50 A. Muthulakshmi และคณะ [10] ได้พัฒนาระบบจำแนก ความสุขของทุเรียนโดยใช้เทคนิคการประมวลผลภาพ และการเรียนรู้ของเครื่องที่ไม่ทำลายตัวอย่าง (Non-Destructive Methods) เพื่อจำแนกระดับความสุขได้ อย่างแม่นยำ โดยใช้การหาขอบภาพและการดึงลักษณะ เเด่นของภาพ และใช้อัลกอริทึม Support Vector Machine (SVM), Random Forest, Gaussian Naive Bayes (GNB) ในการจำแนกข้อมูลพร้อมทั้งเปรียบเทียบ ประสิทธิภาพ สำหรับการจำแนกความสุขอัลกอริทึม SVM ให้ผลลัพธ์ที่ดีที่สุดด้วยความแม่นยำร้อยละ 89.3

จากที่กล่าวมาข้างต้นจะเห็นว่ามีมีการใช้การ เรียนรู้เชิงลึกเพื่อจำแนกข้อมูลทุเรียนสาเหตุเกิดจากการ แยกแยะชนิดทุเรียนหรือการจำแนกระดับความสุขของ ทุเรียนจะต้องอาศัยประสบการณ์และความชำนาญส่วนบุคคล ผู้วิจัยจึงเสนอการใช้การเรียนรู้เชิงลึกในการ จำแนกความสุขของทุเรียนด้วยการตัดภาพพื้นหลังแบบ ไฮบริด ซึ่งเป็นวิธีการที่ใช้เพียงรูปถ่ายลูกทุเรียนเพื่อให้ โมเดลเชิงลึกทำนายความสุขดิบ ในงานวิจัยใช้ กระบวนการเสนอแนวคิดการเพิ่มประสิทธิภาพโมเดล เชิงลึกด้วยกระบวนการตัดพื้นหลังแบบไฮบริดโดยใช้ การหาขอบของภาพด้วยอัลกอริทึมโซเบล (Sobel Algorithm) ในการปรับปรุงการตัดพื้นหลังของ อัลกอริทึมแกรบคัท (Grabcut Algorithm) เพื่อเพิ่ม ประสิทธิภาพโมเดลเชิงลึกที่ใช้ในการจำแนกความสุขดิบ ของทุเรียน

2. ระเบียบวิธีวิจัย

2.1 ลักษณะและแหล่งที่มาของข้อมูล

สำหรับข้อมูลในการทำวิจัย ผู้วิจัยได้เก็บ รวบรวมข้อมูลรูปภาพทุเรียนสายพันธุ์หมอนทอง จาก 2 แหล่ง ได้แก่ร้านขายทุเรียน และจากสวนทุเรียน โดย ข้อมูลมีทั้งหมด 378 ภาพ แสดงตัวอย่างดังรูปที่ 1




รูปที่ 1 ตัวอย่างรูปภาพทุเรียนที่ใช้ในการวิจัย

การเก็บรวบรวมข้อมูล ผู้วิจัยได้ดำเนินการเก็บ ข้อมูลจากการถ่ายภาพด้วยการควบคุมปัจจัยกระทบต่อ ข้อมูลต่าง ๆ ดังต่อไปนี้ สำหรับความละเอียดของ ภาพถ่าย ผู้วิจัยกำหนดความละเอียดไว้ที่ 920 x 1020 พิกเซล โดยกำหนดการจัดองค์ประกอบภายในภาพให้ เห็นบริเวณของผลทุเรียนอย่างชัดเจน

สำหรับการวิจัย เพื่อไม่ให้เกิดความเอนเอียงของ ข้อมูล ผู้วิจัยได้เลือกแบ่งข้อมูลรูปภาพออกเป็น 2 ชุด ข้อมูล โดยชุดข้อมูลแรกใช้สำหรับการเรียนรู้ (Training Set) เพื่อสร้างโมเดลจำแนกระหว่างทุเรียนสุกและ ทุเรียนดิบ โดยใช้รูปภาพทั้งสิ้น 265 ภาพ แบ่งเป็นรูป ทุเรียนดิบ 134 ภาพและภาพทุเรียนสุก 131 ภาพ และ ภาพที่เหลืออีกจำนวน 113 ภาพ แบ่งเป็นภาพทุเรียน ดิบ 58 ภาพและภาพทุเรียนสุก 55 ภาพ จะถูกจำลอง เป็นชุดข้อมูลทดสอบ (Testing Set) เพื่อจำลอง สถานการณ์ว่าภาพทุเรียนดังกล่าวเป็นข้อมูลที่ระบบยังไม่เคยเรียนรู้มาก่อน เปรียบเสมือนข้อมูลในอนาคตเพื่อ ใช้สำหรับการประเมินประสิทธิภาพของโมเดล นอกจากนี้ผู้วิจัยได้ใช้ข้อมูลยืนยัน (Validation Set) จำนวน 100 ภาพ โดยแบ่งเป็นภาพทุเรียนดิบจำนวน 52 ภาพ และทุเรียนสุก จำนวน 48 ภาพ เพื่อใช้ยืนยัน ผลการทดลอง

2.2 อัลกอริทึมแกรบคัท (Grabcut Algorithm)

อัลกอริทึมแกรบคัท [11], [12] มีแนวคิดมาจากการให้ผู้สร้างกรอบพื้นที่สีเหลี่ยมที่จะทำหน้าที่เป็นพื้นหน้า (Foreground) คือ วัตถุหลัก หรือวัตถุที่สนใจในภาพ ซึ่งส่งผลให้วัตถุหรือสิ่งใดที่อยู่พื้นที่นอกกรอบที่สร้างขึ้นจะเป็นพื้นหลัง (Background) คือ ส่วนของภาพที่ไม่ใช่วัตถุหลัก และภาพพื้นหลังนั้นจะถูกนำมาเปรียบเทียบกับภาพพื้นหน้า ซึ่งจะใช้วิธีการเปรียบเทียบกับวิธีการจัดกลุ่มแบบจำลองการผสมแบบเกาส์ (Gaussian Mixture Model : GMM) โดยพิจารณาที่ความคล้ายของสี สีที่คล้ายกับสีภายนอกกรอบจะถือเป็นพื้นหลัง และสีที่ต่างจากนอกกรอบจะถือเป็นพื้นหน้า โดยกระบวนการของการประมวลผลภาพพื้นฐานจะประกอบไปด้วยพิกเซลทุก ๆ พิกเซลจะมีการเชื่อมต่อกันด้วยการไล่ระดับสี ดังนั้นอัลกอริทึมแกรบคัทจะกำหนดให้พิกเซลที่อยู่ติดกันจะมีการกระจายสีที่ใกล้เคียงกัน แสดงตัวอย่างการไล่ระดับสีได้ดังรูปที่ 2



รูปที่ 2 การไล่ระดับสีเพื่อแยกพื้นหน้าและพื้นหลัง

หลังจากนั้นจะสร้างกราฟเริ่มต้นด้วยค่าน้ำหนัก ซึ่งจะปรับค่าน้ำหนักด้วยอัลกอริทึม Min-Cut เพื่อสร้างจุดยอดของทั้งพื้นหน้าและพื้นหลัง จากนั้นจะสร้างกราฟจำนวน n จุด (n หมายถึงจำนวนจุดพิกเซล) และเชื่อมต่อไปยังจุดที่อยู่ติดกันโดยค่าน้ำหนักนั้นถูกกำหนดด้วยความคล้ายคลึงกันของระดับสี หลังจากนั้นจะสร้างจุดยอดเพิ่ม 2 จุด (ป้ายกำกับกับพื้นหน้าและพื้นหลัง) ซึ่งแต่ละจุดจะเชื่อมโยงไปยังจุดอื่น ๆ ตามความน่าจะเป็นของพิกเซลที่ตรงกับการกระจายสีของพื้นหน้าหรือพื้นหลัง

โดยอัลกอริทึมแกรบคัทมีประสิทธิภาพในการแยกวัตถุออกจากพื้นหลังที่สูง โดยอาศัยวิธีการจัดกลุ่มแบบจำลองการผสมแบบเกาส์ ซึ่งช่วยจำแนกสีของพื้นหน้า และพื้นหลังของวัตถุได้อย่างแม่นยำ อย่างไรก็ตาม อัลกอริทึมแกรบคัท จำเป็นที่จะต้องมีการกำหนดกรอบพื้นที่สีเหลี่ยมในการทำงาน หากกำหนดกรอบพื้นที่ดังกล่าวไม่เหมาะสมจะทำให้ผลลัพธ์ที่ได้ไม่ดี รวมไปถึงการใช้เวลาในการประมวลผลที่มากขึ้นสำหรับรูปภาพขนาดใหญ่

2.3 อัลกอริทึมโซเบล (Sobel Algorithm)

อัลกอริทึมโซเบล [13], [14] เป็นอัลกอริทึมสำหรับการหาขอบภาพ ใช้หลักการคำนวณการไล่ระดับความเข้มแสงของภาพในแต่ละพิกเซลภายในรูปภาพ โดยจะค้นหาทิศทางของการเพิ่มขึ้นของความเข้มแสงของภาพจากสว่างไปมืด โดยขอบจะเกิดจากความแตกต่างของความเข้มแสงระหว่างพิกเซลหนึ่งกับพิกเซลข้างเคียง หากความเข้มแสงแตกต่างมากขอบของภาพก็จะชัดขึ้น สำหรับการหาขอบภาพด้วยอัลกอริทึมโซเบลจะใช้ฟิลเตอร์ (Filter) เพื่อให้ค่าน้ำหนักของพิกเซลที่ใกล้เคียงกับพิกเซลเป้าหมาย (Target Pixel) มากกว่าจุดอื่น ๆ ในงานวิจัยนี้ใช้หาการขอบในทิศทางแนวนอนและแนวตั้ง จึงมีการใช้งานฟิลเตอร์ 2 แบบ ฟิลเตอร์ในแนวแนวนอน (G_x) และแนวแกนตั้ง (G_y) ดังนี้

-1	0	1
-2	0	2
-1	0	1

G_x

1	2	1
0	0	0
-1	-2	-1

G_y

รูปที่ 3 ฟิลเตอร์แนวแกนแนวนอน (G_x) และแกนตั้ง (G_y)

ในการคำนวณ Sobel gradient จะนำ G_x และ G_y ไปทำการเลื่อนหน้าต่างฟิลเตอร์บนภาพข้อมูล เพื่อคำนวณค่าของพิกเซลนั้น จากนั้นจะเลื่อนหน้าต่างไปทางพิกเซลด้านขวาจนกระทั่งสิ้นสุดแถว หลังจากนั้นจะ

เลื่อนลงไปจุดเริ่มต้นของแถวถัดไป ตัวอย่างตัวอย่าง
การวางฟิลเตอร์ไปบนภาพแสดงดังรูปที่ 4

A ₁₁	A ₁₂	A ₁₃	A ₁₄
A ₂₁	A ₂₂	A ₂₃	A ₂₄
A ₃₁	A ₃₂	A ₃₃	A ₃₄
A ₄₁	A ₄₂	A ₄₃	A ₄₄

 $\times$

-1	0	1
-2	0	2
-1	0	1

 $=$

B ₁₁	B ₁₂	B ₁₃	B ₁₄
B ₂₁	B ₂₂	B ₂₃	B ₂₄
B ₃₁	B ₃₂	B ₃₃	B ₃₄
B ₄₁	B ₄₂	B ₄₃	B ₄₄

Input image Gx Output Image

รูปที่ 4 ตัวอย่างการวางฟิลเตอร์ไปบนภาพ

คำนวณหาผลลัพธ์ในแต่ละพิกเซลโดยการคูณ
ค่าของแต่ละพิกเซลในพื้นที่ที่ฟิลเตอร์ทับกับค่าใน
ฟิลเตอร์ และหลังจากนั้นรวมผลลัพธ์ทั้งหมดเข้าด้วยกัน
เพื่อให้ได้ผลลัพธ์ จากนั้นจะทำการเลื่อนฟิลเตอร์แล้ว
คำนวณหาผลลัพธ์ในพิกเซลถัดไป

เช่น คำนวณหาค่าของพิกเซลที่ B₁₁ ได้ดังนี้

$$B_{11} = -A_{11} + A_{13} - 2A_{21} + 2A_{23} - A_{31} + A_{33} \quad (1)$$

โดยที่

A_{nm} คือ รูปดั้งเดิมที่พิกเซลแถว n คอลัมน์ m

B_{nm} คือ รูปที่ผ่านฟิลเตอร์ที่จุดพิกเซลแถว n คอลัมน์ m

เมื่อรูปภาพจะถูกผ่านฟิลเตอร์ G_x และ G_y เพื่อหา
การเปลี่ยนแปลงของค่าพิกเซลในแนวนอนและแนวตั้ง
แล้ว จะนำผลลัพธ์ไปหาค่าแรงขอบ (edge magnitude)
ได้โดยใช้สมการที่ 2

$$\text{Edge Magnitude} = \sqrt{G_x^2 + G_y^2} \quad (2)$$

โดยที่


G_x คือ ค่าพิกเซลในรูปที่ผ่านฟิลเตอร์ G_x

G_y คือ ค่าพิกเซลในรูปที่ผ่านฟิลเตอร์ G_y

โดยอัลกอริทึมโซเบลสามารถใช้งานได้ง่าย มีการ
คำนวณไม่ซับซ้อน สามารถทนทานต่อข้อมูลรบกวน
(Noise) ได้เล็กน้อยจึงไม่เหมาะสมกับข้อมูลรูปภาพที่มี

สิ่งรบกวนในภาพเป็นจำนวนมาก รวมไปถึงความแม่นยำ
ต่ำสำหรับภาพที่มีขอบของวัตถุไม่ชัดเจน และความ
สว่างในภาพมีผลต่อประสิทธิภาพของอัลกอริทึมโซเบล

2.4 อัลกอริทึมโครงข่ายประสาทเทียมแบบ คอนโวลูชัน (Convolutional Neural Network: CNN)



รูปที่ 5 โครงสร้างการทำงานของโครงข่ายประสาท
เทียมแบบคอนโวลูชัน [15]

โครงข่ายประสาทเทียมแบบคอนโวลูชัน [15],
[16], [17] เป็นโครงข่ายประสาทเทียมแบบหนึ่งที่มีการ
จำลองการมองเห็นของมนุษย์โดยจะมองพื้นที่ที่เป็น
บริเวณขนาดเล็กไปรอบ ๆ รูปภาพ ร่วมกับการมองพื้นที่
ขนาดใหญ่โดยรอบ จึงจะสามารถวิเคราะห์ภาพที่เห็นได้
CNN ถูกออกแบบมาเพื่อการประมวลผลภาพมี
ความสามารถในการระบุลักษณะของภาพอย่างอัตโนมัติ
ผ่านการเรียนรู้จากข้อมูล แสดงโครงสร้างการทำงานของ
ของโครงข่ายประสาทเทียมแบบคอนโวลูชันได้ดังรูปที่ 5

โครงสร้างการทำงานของโครงข่ายประสาท
เทียมแบบคอนโวลูชันมีส่วนประกอบที่สำคัญดังต่อไปนี้

ส่วนที่หนึ่ง คอนโวลูชัน (Convolution) กับพูล
ลิงเลเยอร์ (Pooling Layer) ทำหน้าที่รับข้อมูลรูปภาพ
เข้า (Image Input) หลังจากนั้นจะใช้ตัวกรอง (Filter)
ทำหน้าที่ในการเลื่อนภาพ โดยจะเลื่อนไปที่ขั้นตอน
(Step) ขึ้นอยู่กับสไตรด์ (Stride) ซึ่งจะทำให้การเลื่อนไป
จนครบทุกพิกเซล (Pixels) ของภาพ ทำให้ได้ผัง
คุณลักษณะ (Feature Map) ที่มีขนาดเล็กลง (ภาพถูก
ย่อขนาดลง) โดยจะดึงคุณลักษณะเด่นบริเวณต่าง ๆ
ออกมาด้วย ซึ่งเป็นการสกัดข้อมูลที่สำคัญออกมาจาก

ภาพ ในบางครั้งอาจจะใช้การเพิ่มแพดดิ้ง (Padding) ให้กับรูปภาพ

ส่วนที่สอง ฟูลลี คอนเนคเทด (Fully Connected Layer) จะนำเอาคุณลักษณะจากฟังก์ชันคุณลักษณะที่ถูกดึงมาจากรูปภาพไปเรียนรู้ โดยจะมีการตัดสินใจเกิดขึ้น


ส่วนที่สาม การทำนาย (Prediction) จะเป็นการทำนายผลลัพธ์ที่ได้จากการเรียนรู้ในขั้นตอนของส่วนที่สอง

สำหรับโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน จะถูกสร้างและเรียนรู้จากข้อมูลภาพที่มีอยู่ หลังจากนั้นจะนำโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้รับการเรียนรู้มาก่อนหน้านี้มาใช้ในการจำแนกประเภทภาพ หรือใช้ในการตรวจจับวัตถุได้โดยที่ไม่จำเป็นต้องสร้างโครงสร้างใหม่ทุกครั้งที่มีการจำแนกใหม่ การใช้โครงสร้างโครงข่ายประสาทเทียมแบบคอนโวลูชันที่เรียนรู้แล้วมีประสิทธิภาพและเชื่อถือได้ในการทำงานประมวลผลภาพ

การสร้างโมเดลด้วยโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชันจะต้องเตรียมข้อมูลให้เหมาะสมกับโครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชันแต่ละประเภท ซึ่งการนำข้อมูลเข้าสู่โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อสร้างโมเดลจะเรียกว่าการฝึกโมเดล (Model Training) สำหรับการฝึกโมเดลจะเรียนรู้จากข้อมูลเข้า โดยโมเดลจะปรับค่าพารามิเตอร์ให้เหมาะสมกับข้อมูลเพื่อใช้ในการแก้ไขปัญหาที่ต้องการ ซึ่งข้อมูลที่ใช้ในกระบวนการฝึกจะประกอบด้วยข้อมูลนำเข้า (Input Data) และป้ายชื่อหรือคลาสที่ใช้ในการจำแนกข้อมูล (Labels) ซึ่งใช้ในการตรวจสอบความถูกต้องของผลลัพธ์ที่โมเดลทำนายขึ้นมา

2.5 ขั้นตอนการดำเนินงาน

งานวิจัยนี้เป็นการวิจัยเพื่อประยุกต์ใช้เทคนิคการประมวลผลภาพเพื่อเพิ่มประสิทธิภาพให้อัลกอริทึมการเรียนรู้เชิงลึกสำหรับจำแนกทุเรียนสุกและดิบ โดยมีกรอบแนวคิดการวิจัย แสดงดังรูปที่ 6



รูปที่ 6 กรอบแนวคิดการวิจัย


จากรูปที่ 6 สามารถอธิบายกรอบแนวคิดการวิจัยได้โดยแบ่งเป็นสองส่วนได้แก่ ในส่วนแรกของกระบวนการวิจัย จะเป็นการเตรียมข้อมูลก่อนสร้างโมเดลด้วยการตัดพื้นหลังของรูปทุเรียนออกจากกระบวนการตัดพื้นหลังแบบไฮบริด หลังจากนั้นจะทำ

การย่อขนาดรูปภาพให้เหมาะกับโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ต้องการใช้เพื่อแก้ปัญหาการจำแนกระดับความสุกของทุเรียน สำหรับส่วนที่สองของกระบวนการวิจัยได้แก่การสร้างโมเดลเพื่อจำแนกว่ารูปทุเรียนที่นำมาใช้เป็นรูปทุเรียนสุกหรือทุเรียนดิบ

2.5.1 กระบวนการตัดพื้นหลังแบบไฮบริด

งานวิจัยนี้ใช้กระบวนการตัดพื้นหลังแบบไฮบริด ซึ่งเป็นการเพิ่มประสิทธิภาพในการตัดภาพพื้นหลังที่

งานวิจัยได้นำเสนอ โดยใช้การกระบวนการหาขอบภาพแบบโซเบลร่วมกับอัลกอริทึมแกรบคัทในการตัดพื้นหลังของภาพ โดยแสดงกรอบแนวคิดได้ดังรูปที่ 7



รูปที่ 7 กรอบแนวคิดการเพิ่มประสิทธิภาพในการตัดพื้นหลังแบบไฮบริด

จากรูปที่ 7 เริ่มต้นโดยการนำรูปทุเรียนต้นฉบับมาแปลงเป็นภาพระดับสีเทาเพื่อลดขนาดมิติของข้อมูลภาพ ทำให้เห็นค่าความเข้มแสงได้ชัดเจนเนื่องจากภาพระดับสีเทามีสิ่งรบกวน (Noise) น้อยกว่าภาพสี แล้วนำไปเบลอภาพเพื่อลดสิ่งรบกวนในภาพลง จากนั้นใช้การเบลอภาพเพื่อตัดรายละเอียดที่ไม่จำเป็นในภาพออก การเบลอภาพจะทำให้ขอบของวัตถุในภาพเรียบขึ้นช่วยให้อัลกอริทึมหาขอบภาพสามารถทำงานได้อย่างมีประสิทธิภาพมากยิ่งขึ้น หลังจากนั้นใช้อัลกอริทึมโซเบล (Sobel) เพื่อกำหนดขอบของวัตถุขึ้น การหาขอบแบบโซเบลในภาพทุเรียนจะทำให้ได้ลักษณะหรือลวดลายจากหนามทุเรียน ถ้าภาพมีพื้นหลัง แสงหรือเงา การหาขอบแบบโซเบลจะทำให้ช่วยแสดงลวดลายของสิ่งเหล่านั้นออกได้ชัดเจน เมื่อนำภาพการหาขอบไปสร้างแมสก์ (Mask) ขึ้นมาเพื่อกำหนดพื้นที่ของทุเรียน ซึ่งเป็นการกำหนดพื้นที่ที่สนใจ (Regions of Interest) ในรูปซึ่งจะช่วยให้สามารถกำหนดพื้นที่ของทุเรียนได้อย่างแม่นยำ โดยที่ส่วนของพื้นหลังหรือสิ่งที่ไม่ใช่ทุเรียนจะไม่ถูกพิจารณา เนื่องจากมีค่าความเข้มที่ต่ำทำให้พื้นที่นั้นไม่ถูกนับเข้าไปใน Regions of Interest ที่สนใจ ดังนั้นการตัดพื้นด้วยอัลกอริทึมแกรบคัทที่ถูกระบุการตัดภาพในพื้นที่นั้น จะทำให้สามารถตัดภาพพื้นหลังของทุเรียนได้แม่นยำมากยิ่งขึ้น

2.5.2 การสร้างโมเดลที่ใช้ในการจำแนกทุเรียน

ในงานวิจัยนี้ใช้อัลกอริทึมที่มีโครงสร้างพื้นฐานจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4 แบบในการทดลองสร้างโมเดลที่ใช้ในการจำแนกทุเรียนสุกดิบ ได้แก่อัลกอริทึม VGG16, VGG19, AlexNet และ ResNet50 แต่ก่อนการนำข้อมูลเข้าโครงสร้างเหล่านี้จะต้องมีการปรับขนาดรูปภาพให้เหมาะสมกับโครงสร้างโครงข่ายประสาทเทียมแต่ละแบบ เมื่อนำข้อมูลเข้าโครงข่ายเพื่อทำให้โครงข่ายเรียนรู้ฟีเจอร์หรือคุณลักษณะของข้อมูลภาพ จะทำให้ได้โมเดลที่สามารถจำแนกหรือทำนายได้ตามเป้าหมายที่กำหนด ในที่นี้คือโมเดลในการจำแนกความสุกของทุเรียนสายพันธุ์หมอนทอง ซึ่งงานวิจัยนี้สร้างโมเดลที่จำแนกทุเรียนเป็น 2 เป้าหมายหรือ 2 คลาสได้แก่ ทุเรียนดิบ (Unripe) และทุเรียนสุก (Ripe) โดยมีรายละเอียดของแต่ละโครงข่ายประสาทเทียม ที่ทดลองใช้ดังนี้

VGG16 – เป็นอัลกอริทึมการเรียนรู้เชิงลึกที่เน้นไปที่การออกแบบชั้น (Layer) ในโครงข่ายประสาทเทียม โดยจะกำหนดชั้นซ่อนเร้น (Hidden Layer) ไว้เป็นจำนวน 16 ชั้น [18]

VGG19 – เป็นอัลกอริทึมการเรียนรู้เชิงลึกที่มีหลักการทำงานเช่นเดียวกับ VGG16 เพียงแต่กำหนดชั้นซ่อนเร้นเพิ่มขึ้นเป็น 19 ชั้น [19]

AlexNet - เป็นอัลกอริทึมการเรียนรู้เชิงลึกที่ประกอบไปด้วยชั้นคอนโวลูชันจำนวน 5 ชั้น ภายในแต่ละชั้นจะมีขนาดของฟังก์ชันลักษณะ (Feature Map) และตัวกรอง (Filter) ซึ่งมีขนาดของฟังก์ชันลักษณะและตัวกรองแตกต่างกัน และทำการเลื่อน (Stride) ตัวกรองครั้งละ 2 พิกเซล โดยชั้นที่ 1 จะประกอบไปด้วย 96 ฟังก์ชันลักษณะ โดยใช้ตัวกรอง (Filter) ขนาด 11x11 และชั้นที่ 2 ประกอบไปด้วย 256 ฟังก์ชันลักษณะ และใช้ตัวกรองขนาด 5x5 สำหรับชั้นที่ 3, 4 และ 5 จะใช้ 384, 384 และ 256 ฟังก์ชันลักษณะตามลำดับ และใช้ตัวกรองขนาด 3x3 [20]

RestNet50 - เป็นอัลกอริทึมการเรียนรู้เชิงลึกที่แก้ปัญหาเรื่องการไล่ระดับสีที่ขาดหายไป โดยจะเกิดขึ้นกับโครงข่ายที่มีความลึกค่อนข้างมาก โดย RestNet50 จะประกอบไปด้วย 4 บล็อก (4 Block) โดยจำนวนพารามิเตอร์สำหรับฝึกทั้งหมดจะประกอบไปด้วย [3, 4, 6, 3] ซึ่งจะประกอบไปด้วยจำนวนชั้นทั้งหมดคือ $(3+4+6+3) \times 3 = 48$ ชั้น + 2 ชั้น = 50 ชั้น [19]


3. ผลการศึกษาและอภิปรายผล

ในงานวิจัยนี้นำเสนอการตัดภาพพื้นหลังด้วยวิธีการไฮบริดโดยการใช้อัลกอริทึมการตัดภาพพื้นหลังด้วยอัลกอริทึมแกรปคัทร่วมกับอัลกอริทึมโซเบลในขั้นตอนการประมวลผลภาพ หลังจากนั้นจะนำข้อมูลที่ได้ผ่านการประมวลผลภาพไปสร้างโมเดลสำหรับการจำแนกระดับความสุกของทุเรียนสายพันธุ์หมอนทอง โดยผลการศึกษาแต่ละขั้นตอนแสดงดังต่อไปนี้


3.1 ผลการตัดภาพพื้นหลัง

ในงานวิจัยนี้จะเตรียมข้อมูลก่อนการสร้างโมเดลในการจำแนกความสุกดิบของทุเรียนโดยใช้กระบวนการตัดภาพพื้นหลังของรูปทุเรียน แสดงตัวอย่างของผลการตัดภาพพื้นหลังของรูปทุเรียนโดยใช้

อัลกอริทึมแกรปคัทดังรูปที่ 8 และใช้โซเบลร่วมกับแกรปคัทแสดงดังรูปที่ 9



รูปที่ 8 ผลการตัดพื้นหลังด้วยอัลกอริทึมแกรปคัท



รูปที่ 9 ผลการตัดภาพพื้นหลังด้วยเทคนิคที่นำเสนอ

จากรูปที่ 8 ทั้ง 5 รูปภาพตัวอย่าง จะเห็นได้ว่าการใช้เฉพาะอัลกอริทึมแกรปคัทจะยังไม่สามารถตัดส่วนพื้นหลังที่ไม่ต้องการออกไปได้ทั้งหมด ทำให้ข้อมูลที่นำไปเรียนรู้มีภาพพื้นหลังบางส่วนอยู่ด้วย เนื่องจากภาพทุเรียนที่มีพื้นหลังของบางรูปมีความซับซ้อนและบางรูปมีเงาทำให้แกรปคัทยังไม่สามารถตัดพื้นหลังได้ เนื่องจากตัวอัลกอริทึมยังแยกวัตถุจากพื้นหลังไม่ได้ เพราะกระบวนการหาขอบแบบดั้งเดิมจะใช้แค่การกำหนดบริเวณส่วนที่สนใจให้แก่อัลกอริทึมแกรปคัท

เมื่อนำกระบวนการหาขอบภาพด้วยอัลกอริทึมโซเบลกำหนดเป็นแมสก์เริ่มต้น สามารถช่วยให้แกรปคัทแบ่งวัตถุกับพื้นหลังได้ดีขึ้นเนื่องจากการหาขอบแบบโซเบลให้ข้อมูลแบบระดับสีเทาซึ่งเป็นรูปแบบค่าการเปลี่ยนแปลงของความเข้มสี (Gradient) และขอบที่ได้มีความหนา เส้นมีความต่อเนื่อง และคลุมพื้นที่ของวัตถุ ทำให้แกรปคัทสามารถใช้ข้อมูลนี้เพื่อระบุวัตถุและพื้นหลังได้ดี แสดงผลการตัดพื้นหลังด้วยโซเบลร่วมกับแกรปคัทในรูปที่ 9 ทั้ง 5 รูปภาพตัวอย่างจะเห็นว่าภาพทุเรียนที่ผ่านการตัดพื้นหลังด้วยเทคนิคที่นำเสนอผลลัพธ์ของการตัดภาพหลังจากออกจากลูกทุเรียน

ได้ดีกว่าการใช้การใช้เพียงอัลกอริทึมแกรปกติเพียงอย่างเดียว

3.2 ผลการสร้างโมเดลที่ใช้ในการจำแนก


ทุเรียนสุกดิบ

ในงานวิจัยนี้ใช้อัลกอริทึมที่มีโครงสร้างพื้นฐานจากโครงข่ายประสาทเทียมแบบคอนโวลูชัน 4 แบบในการทดลอง ได้แก่ VGG16, VGG19, AlexNet และ ResNet50 เพื่อสร้างโมเดลที่ใช้ในการจำแนกทุเรียนสุกดิบ การทดลองจะเปรียบเทียบประสิทธิภาพโมเดลที่สร้างขึ้นระหว่างการใช้อัลกอริทึมเดิมกับการใช้รูปภาพที่ผ่านการประมวลผลภาพด้วยวิธีที่นำเสนอ พร้อมทั้งเปรียบเทียบกับการใช้ชุดข้อมูลยืนยันแสดงผลการเปรียบเทียบดังตารางที่ 1


ตารางที่ 1 ค่าความถูกต้องในการจำแนกทุเรียน

อัลกอริทึม	%Accuracy ภาพดั้งเดิม	%Accuracy ภาพตัดพื้นหลัง (Test)	%Accuracy ภาพตัดพื้นหลัง (Validation)
VGG 16	64.60%	72.57%	68.00%
VGG 19	81.42%	88.50%	82.00%
AlexNet	73.45%	76.11%	76.00%
ResNet50	83.19%	89.38%	86.00%


จากตารางที่ 1 สามารถอธิบายผลการทดลองได้ดังนี้ การจำแนกด้วยอัลกอริทึม VGG 16 ด้วยการใช้อัลกอริทึมเดิม มีความแม่นยำในการจำแนกอยู่ที่ร้อยละ 64.60 ส่วนการใช้วิธีการประมวลผลภาพเพื่อตัดพื้นหลังด้วยวิธีการไฮบริดที่นำเสนอ ช่วยเพิ่มความแม่นยำในการจำแนกให้อัลกอริทึม VGG 16 ซึ่งมีความแม่นยำอยู่ที่ร้อยละ 72.57 เมื่อใช้ข้อมูลยืนยัน (Validation Set) ร่วมกับการใช้การตัดภาพพื้นหลังด้วยวิธีการไฮบริดพบว่ามีความแม่นยำอยู่ที่ร้อยละ 68.00 สำหรับอัลกอริทึม VGG 19 กับรูปภาพดั้งเดิมมีประสิทธิภาพที่ร้อยละ 81.42 เมื่อใช้การประมวลผลภาพร่วมด้วยจะให้ความแม่นยำที่ร้อยละ 88.50 และค่าความแม่นยำสำหรับการใช้ข้อมูลยืนยันอยู่ที่ร้อยละ 82.00 ในขณะที่อัลกอริทึม AlexNet การใช้รูปภาพดั้งเดิมมีความแม่นยำที่ร้อยละ 73.45 เมื่อใช้การประมวลผลภาพด้วยการตัดพื้นหลังที่นำเสนอ ส่งผลให้ประสิทธิภาพการจำแนกมีความแม่นยำเพิ่มขึ้นเป็นร้อยละ 76.11 และมีค่าความแม่นยำที่ร้อยละ 76.00 สำหรับข้อมูลยืนยัน และสำหรับอัลกอริทึม ResNet50 การใช้รูปภาพดั้งเดิมมีความแม่นยำที่ร้อยละ 83.19 เมื่อใช้การตัดพื้นหลังด้วยวิธีที่นำเสนอ มีค่าความแม่นยำร้อยละ 89.38 โดยผลประสิทธิภาพความแม่นยำจากการใช้ชุดข้อมูลยืนยันอยู่ที่ร้อยละ 86.00 แสดงผลการจำแนกข้อมูลแต่ละอัลกอริทึมดังรูปที่ 10, 11, 12 และ 13




รูปที่ 10 ผลการจำแนกแต่ละคลาสด้วยอัลกอริทึม VGG16



รูปที่ 11 ผลการจำแนกแต่ละคลาสด้วยอัลกอริทึม VGG19



รูปที่ 12 ผลการจำแนกแต่ละคลาสด้วยอัลกอริทึม AlexNet



รูปที่ 13 ผลการจำแนกแต่ละคลาสด้วยอัลกอริทึม ResNet50

จากรูปที่ 10 แสดงการจำแนกข้อมูลของแต่ละคลาสสำหรับอัลกอริทึม VGG16 โดยใช้ตารางคอนฟิวชันเมทริกซ์ (Confusion Matrix) จะเห็นว่าอัลกอริทึม

VGG16 กับข้อมูลภาพดั้งเดิม (รูปที่ 10 (ก.)) ยังทำนายข้อมูลทุเรียนดิบได้ไม่ดีพอ แต่เมื่อใช้อัลกอริทึม VGG16 ร่วมกับภาพตัดพื้นหลังในการทำนายข้อมูลทุเรียนดิบมี

จำนวนที่ทำนายถูกมากขึ้น (รูปที่ 10 (ข.)) เมื่อใช้ชุดข้อมูลยืนยัน (รูปที่ 10 (ค.)) ทดสอบ พบว่าโมเดลสามารถทำนายทุเรียนดิบได้แม่นยำจำนวน 24 รูป จาก 52 รูป และทุเรียนสุกได้แม่นยำจำนวน 44 รูป จาก 48 รูป ในส่วนของอัลกอริทึม VGG19 จากรูปที่ 11 (ก.) เป็นโมเดลที่มีประสิทธิภาพความแม่นยำในการทำนายค่อนข้างสูง โดยจะเห็นว่าตัวเลขของข้อมูลที่ทำนายแม่นยำมีจำนวน 92 รูป จาก 113 รูป และผลลัพธ์ที่ VGG 19 กับภาพตัดพื้นหลัง (รูปที่ 11 (ข.)) จำนวนข้อมูลที่ทำนายได้แม่นยำจำนวน 100 รูป จาก 113 รูป การใช้ชุดข้อมูลยืนยันในการทดสอบ (รูปที่ 13(ค.)) จะเห็นได้ว่าจำนวนรูปที่ทำนายแม่นยำจำนวน 82 รูปจาก 100 รูป ในขณะที่โมเดล AlexNet กับภาพดั้งเดิมในรูปที่ 12 (ก.) จะเห็นว่าโมเดลทำนายภาพทุเรียนสุกได้ไม่แม่นยำ สามารถทำนายทุเรียนสุกได้ถูกต้องเพียง 29 รูปจาก 55 รูป และเมื่อนำโมเดล AlexNet มาใช้ร่วมกับการตัดภาพพื้นหลัง (รูปที่ 12 (ข.)) สามารถทำนายภาพทุเรียนสุกได้ถูกต้องมากขึ้น โดยทำนายได้แม่นยำที่ 35 รูป จาก 55 รูป สอดคล้องกับการใช้ชุดข้อมูลยืนยันในการทดสอบ (รูปที่ 12 (ค.)) ที่สามารถทำนายคลาสทุเรียนสุกได้แม่นยำที่ 34 รูป จาก 48 รูป ส่วนอัลกอริทึม ResNet50 กับการใช้ภาพดั้งเดิมในรูปที่ 13 (ก.) เป็นโมเดลที่มีการทำนายภาพทุเรียนได้แม่นยำถึง 94 รูปจาก 113 รูป และเมื่อพิจารณาประสิทธิภาพของอัลกอริทึม ResNet50 กับภาพตัดพื้นหลัง (รูปที่ 13 (ข.)) จะเห็นว่าการทำนายภาพทุเรียนมีความแม่นยำเพิ่มมากขึ้นถึง 101 รูปจาก 113 รูป และเมื่อใช้ข้อมูลยืนยันในการทดสอบ พบว่าสามารถทำนายได้แม่นยำถึง 86 รูปจาก 100 รูป (รูปที่ 13 (ค.))

4. สรุป

งานวิจัยนี้นำเสนอการตัดภาพพื้นหลังด้วยวิธีการไฮบริดเพื่อเพิ่มประสิทธิภาพในการจำแนกความสุกของทุเรียนสายพันธุ์หมอนทอง โดยงานวิจัยแบ่งการทดลองออกเป็นสองส่วน ได้แก่ ส่วนแรกกล่าวถึง

กระบวนการตัดพื้นหลังเพื่อแสดงให้เห็นว่าการตัดภาพพื้นหลังโดยใช้อัลกอริทึมพื้นฐานคือแกรปคัทจะสามารถตัดพื้นหลังได้ดีกับข้อมูลวัตถุที่อยู่ในรูปต่างกับพื้นหลังชัดเจน ดังนั้นจึงเสนอวิธีการในการตัดภาพพื้นหลังแบบไฮบริดด้วยการใช้อัลกอริทึมโซเบลในการหาขอบร่วมกับใช้อัลกอริทึมแกรปคัทในการตัดภาพพื้นหลังเพื่อแก้ปัญหาการตัดภาพพื้นหลังของอัลกอริทึมแกรปคัทกับภาพที่มีพื้นหลังซับซ้อน ทำให้ประสิทธิภาพการตัดพื้นหลังดีขึ้น การหาขอบที่จะสามารถช่วยให้ผลลัพธ์การตัดภาพพื้นหลังของอัลกอริทึมแกรปคัทมีประสิทธิภาพจะต้องเป็นการหาขอบภาพที่ให้ผลลัพธ์ระดับสีเทาซึ่งจะใช้แสดงค่าการเปลี่ยนแปลงของความเข้มสี (Gradient) ทำให้ซึ่งเมื่อแกรปคัทนำข้อมูลสร้างเป็นโหนด (Node) ซึ่งโหนดแต่ละโหนดจะเชื่อมกันด้วยค่าถ่วงน้ำหนัก (Weights) โดยค่าถ่วงน้ำหนักสามารถคำนวณได้จากความคล้ายคลึงของสีหรือความเข้ม ทำให้แกรปคัทสามารถแบ่งวัตถุและพื้นหลังได้ดี

ส่วนที่สองกล่าวถึงการเพิ่มประสิทธิภาพความแม่นยำโดยใช้การประมวลผลภาพด้วยการตัดภาพพื้นหลังแบบไฮบริดรวมกับการเรียนรู้เชิงลึก ในขั้นตอนการสร้างโมเดลที่ใช้สำหรับการหาค่าความสุกดิบของทุเรียน โดยทดลองสร้างโมเดลจากอัลกอริทึมการเรียนรู้เชิงลึกทั้ง 4 อัลกอริทึม ได้แก่ VGG16, VGG19, AlexNet และ ResNet50 จะเห็นว่าเมื่อนำข้อมูลที่ตัดพื้นหลังด้วยวิธีการไฮบริดไปสร้างโมเดลที่ใช้ในการจำแนกข้อมูลรูปทุเรียนสามารถเพิ่มประสิทธิภาพความแม่นยำในการทำนายภาพทุเรียนเพื่อจำแนกระดับความสุก-ดิบได้ดียิ่งขึ้น

5. เอกสารอ้างอิง

- [1] N. M. Z. Hashim, M. H. A. K. Bahri, S. M. Abd Ghani, M. D. Sulistiyo, K. A. M. Kassim, and N. A. H. Zahri, "An Introduction to A Smart Durian Musang King and Durian Kampung

- Classification”, in *2022 2nd International Conference on Intelligent Technologies (CONIT)*, IEEE, 2022, pp. 1-6.
- [2] J. N. Uy and J. F. Villaverde “A durian variety identifier using canny edge and CNN”, in *2021 IEEE 7th International Conference on Control Science and Systems Engineering (ICCSSE)*, IEEE, 2021, pp. 293-297.
- [3] J. R. Balbin, J. A. I. Alday, C. O. Aquino, and M. F. G. Quintana, “Durio Zibethinus ripeness determination and variety identification using principal component analysis and support vector machine”, in *10th International Conference on Graphics and Image Processing (ICGIP)*, Chengdu, PEOPLES R CHINA, 2018, pp. 475-480.
- [4] A. P. Bhandarkar, A. N. Alaguraj, and S. S. Madhugiri, "Detection of fruit ripeness using image processing," *International Journal of Computer Vision and Image Processing*, vol. 12, no. 3, pp. 1–15, 2021.
- [5] C. C. Olisah, B. Trehwella, B. Li, M. L. Smith, B. Winstone, E. C. Whitfield, F. Fernandez Fernandez, and H. Duncalfe, "Convolutional neural network ensemble learning for hyperspectral imaging-based blackberry fruit ripeness detection in uncontrolled farm environment," *Engineering Applications of Artificial Intelligence*, vol. 132, no. 107945, Jun 2024.
- [6] B. Xiao, M. Nguyen, and W. Q. Yan, "Fruit ripeness classification using YOLOv8 model," *Multimedia Tools and Applications*, vol. 83, no. 2, pp. 28039–28056, Aug. 2023.
- [7] Suharjito, F. A. Junior, Y. P. Koeswandy, D. Pratiwi, W. Nurhayati, M. Asrol, and Marimin, "Annotated datasets of oil palm fruit bunch piles for ripeness grading using deep learning," *Scientific Data*, vol. 10, article no. 72, Feb. 2023.
- [8] P. K. Mishra, R. Jain, and D. Singh, "Fruit ripeness detection using convolutional neural networks," *Journal of Emerging Trends in Information Research (JETIR)*, vol. 5, no. 7, pp. 573–580, Apr. 2023.
- [9] S. Sukkasem, W. Jitsakul, and P. Meesad, "Durian ripeness classification using deep transfer learning," in *Proceedings of the 20th International Conference on Computing and Information Technology*, (IC2IT 2024), 2024, pp. 150–161.
- [10] A. Muthulakshmi and P. N. Renjith, "Durian ripeness classification using machine learning," in *Proceedings of the 2020 5th International Conference on Intelligent Information Technology*, 2020, pp. 190–195.
- [11] F. Yi and I. Moon, “Image segmentation: A survey of graph-cut methods,” in *2012 International Conference on Systems and Informatics*, (ICSAI2012), Yantai, China, 2012, pp. 1936-1941.
- [12] C. Rother, V. Kolmogorov, and A. Blake, “GrabCut interactive foreground extraction using iterated graph cuts,” *ACM transactions on graphics (TOG)*, vol. 23, no. 3, pp. 309-314, Aug. 2004.
- [13] O. R. Vincent and O. Folorunso, “A descriptive algorithm for Sobel image edge

- detection,” in *Proceedings of Informing Science & IT Education Conference*, (InSITE), 2009, pp. 97-107.
- [14] L. Han, Y. Tian, and Q. Qi, “Research on edge detection algorithm based on improved sobel operator”. in *2019 International Conference on Computer Science Communication and Network Security*, (CSCNS2019), MATEC Web of Conferences, 2020.
- [15] A. Shervine, “Cheatsheet: Convolutional Neural Networks,” [Online]. Available: <https://stanford.edu/~shervine/teaching/cs-230/cheatsheet-convolutional-neural-networks>. [Accessed: Mar., 26, 2024].
- [16] Z. Li, F. Liu, W. Yang, S. Peng, and J. Zhou, "A survey of convolutional neural networks: analysis, applications, and prospects," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 33, no. 12, pp. 6999-7019, Jun. 2021.
- [17] N. Ketkar and J. Moolayil, "Convolutional neural networks," in *Deep Learning with Python: Learn Best Practices of Deep Learning Models with PyTorch*, 2021, pp. 197-242.
- [18] D. Theckedath and R. R. Sedamkar, "Detecting affect states using VGG16, ResNet50 and SE-ResNet50 networks," *SN Computer Science*, vol. 1, p. 79, Mar. 2020.
- [19] S. Mascarenhas and M. Agarwal, "A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification," in *2021 International Conference on Disruptive Technologies for Multi-Disciplinary Research and Applications*, (CENTCON), Bengaluru, India, 2021, pp. 96-99.
- [20] M. Z. Alom, T. M. Taha, C. Yakopcic, S. Westberg, P. Sidike, M. S. Nasrin, and V. K. Asari, "The history began from AlexNet: A comprehensive survey on deep learning approaches," arXiv preprint, arXiv:1803.01164, 2018.