

SAC-01-008

การจำแนกระดับความสุกของกล้วยโดยใช้การประมวลผลภาพแบบหลายปริภูมิและการเรียนรู้เชิงลึก เพื่อประเมินความสามารถในการทำงานทั่วไปของโมเดล

Banana Ripeness Classification Using Multi-Color Space Image Processing and Deep Learning for Generalization Evaluation

ณัฐกานต์ ปัจจุสนันท์¹ และ สุภัคพงศ์ จินารัตน์^{2*}

Natthakarn Pujjusanant¹ and Supakpong Jinarat^{2*}

หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาเทคโนโลยีสารสนเทศ วิทยาลัยวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยธุรกิจบัณฑิตย์^{1,2}

Master of Science Program in Information Technology, College of Engineering and Technology, Dhurakij Pundit University^{1,2}

e-mail: 67130043@dpu.ac.th¹, supakpong.jin@dpu.ac.th²

บทคัดย่อ

งานวิจัยนี้นำเสนอระบบวิเคราะห์ระดับความสุกของกล้วยหอมด้วยเทคโนโลยีการประมวลผลภาพและการเรียนรู้เชิงลึก โดยมีวัตถุประสงค์เพื่อศึกษาผลกระทบของรูปแบบสีต่อประสิทธิภาพของโมเดล และประเมินความสามารถในการทำงานกับข้อมูลที่มีความแตกต่างของสภาพแวดล้อมจริง ซึ่งเป็นข้อจำกัดสำคัญของระบบจำแนกระดับความสุกของผลไม้ในปัจจุบัน งานวิจัยใช้ชุดข้อมูล 2 ชุด ได้แก่ Banana Ripeness Classification Dataset และ Banana Images-Real Dataset โดยแบ่งระดับความสุกออกเป็น 4 ระดับ ได้แก่ Unripe, Ripe, Overripe และ Rotten พร้อมเปรียบเทียบรูปแบบสี RGB, RGB+HSV และ Grayscale ร่วมกับโมเดล Machine Learning และ Deep Learning ประกอบด้วย Random Forest, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), CustomCNN และ MobileNetV2

ผลการทดลองพบว่า การใช้ข้อมูล RGB+HSV สามารถเพิ่มประสิทธิภาพในการจำแนกระดับความสุกของกล้วยหอมได้ดีกว่าการใช้ RGB และ Grayscale โดย CustomCNN ร่วมกับ RGB+HSV ให้ค่าความแม่นยำสูงสุดเท่ากับ 98.40% ขณะที่ MobileNetV2 แสดงผลลัพธ์ที่มีความเสถียรในหลายสภาวะการทดลอง นอกจากนี้ การประเมินผลแบบ Cross-Dataset Evaluation พบว่าค่าความแม่นยำของทุกโมเดลลดลงอย่างมีนัยสำคัญเมื่อทดสอบกับข้อมูลที่มีความแตกต่างด้านสภาพแสง ฉากหลัง และคุณภาพของภาพ สะท้อนให้เห็นถึงปัญหา Domain Shift และข้อจำกัดด้านความสามารถในการ Generalization ของโมเดล ผลการศึกษาชี้ให้เห็นว่าการเลือกใช้รูปแบบสีมีผลต่อประสิทธิภาพการจำแนกระดับความสุกอย่างมีนัยสำคัญ และการประเมินผลด้วยข้อมูลต่างสภาพแวดล้อมมีความสำคัญต่อการพัฒนาระบบเกษตรอัจฉริยะที่สามารถประยุกต์ใช้งานได้จริง

คำสำคัญ: การจำแนกระดับความสุกของกล้วยหอม การประมวลผลภาพ Deep Learning, MobileNetV2, Color Space, Cross-Dataset Evaluation

Abstract

This research presents a banana ripeness classification system based on image processing and deep learning. The objectives were to investigate the effect of color representations on model performance and to evaluate model generalization under different real-world imaging conditions. Two datasets were used: the Banana Ripeness Classification Dataset and the Banana Images - Real Dataset. Banana ripeness was classified into four classes: unripe, ripe, overripe, and rotten. Three color representations, namely RGB, RGB+HSV, and Grayscale, were compared using Random Forest, K-Nearest Neighbors, Support Vector Machine, CustomCNN, and MobileNetV2. The results showed that RGB+HSV improved classification performance compared with RGB and Grayscale. CustomCNN with RGB+HSV achieved the highest accuracy of 98.40%, while MobileNetV2 demonstrated stable performance across several experimental conditions. However, the Cross-Dataset Evaluation showed a considerable decrease in accuracy when the models were tested on

images with different illumination, background, and image quality. These findings indicate that color representation directly affects banana ripeness classification performance and that cross-environment evaluation is essential for developing practical smart agriculture systems.

Keywords: Banana Ripeness Classification, Image Processing, Deep Learning, MobileNetV2, Color Space, Cross-Dataset Evaluation

บทนำ

กล้วยหอมเป็นผลไม้เศรษฐกิจที่ได้รับความนิยมอย่างแพร่หลายทั้งในด้านการบริโภคภายในประเทศและการส่งออก โดยระดับความสุกของผลกล้วยมีผลโดยตรงต่อคุณภาพ รสชาติ อายุการเก็บรักษา และมูลค่าทางการตลาด การประเมินระดับความสุกในปัจจุบันยังคงอาศัยการสังเกตด้วยสายตามนุษย์เป็นหลัก ซึ่งอาจเกิดความคลาดเคลื่อนจากประสบการณ์ของผู้ประเมิน ส่งผลให้เกิดข้อจำกัดด้านความแม่นยำและประสิทธิภาพในการคัดแยกผลผลิต

ในช่วงหลายปีที่ผ่านมา เทคโนโลยีการประมวลผลภาพ (Computer Vision) และการเรียนรู้เชิงลึก (Deep Learning) ได้ถูกนำมาประยุกต์ใช้ในการจำแนกระดับความสุกของผลไม้มากขึ้น เนื่องจากสามารถเรียนรู้ลักษณะสำคัญจากข้อมูลภาพได้โดยอัตโนมัติ งานวิจัยก่อนหน้านี้พบว่าโมเดลประเภท Convolutional Neural Networks (CNNs) และ MobileNetV2 สามารถให้ผลลัพธ์ที่มีความแม่นยำสูงในการจำแนกระดับความสุกของผลไม้ (Howard et al., 2017; Sandler et al., 2018; Yang et al., 2024) อย่างไรก็ตาม งานวิจัยส่วนใหญ่มุ่งเน้นการประเมินผลภายในชุดข้อมูลเดียว ซึ่งอาจไม่สะท้อนถึงประสิทธิภาพของโมเดลเมื่อถูกนำไปใช้งานจริงภายใต้สภาพแวดล้อมที่มีความแตกต่างของแสง ฉากหลัง มุมกล้อง และคุณภาพของภาพ (Arunima et al., 2024; Chuquimarca et al., 2025)

นอกจากนี้ สีของเปลือกผลไม้เป็นปัจจัยสำคัญที่สัมพันธ์กับระดับความสุกโดยตรง แต่การศึกษาลักษณะของรูปแบบสี (Color Space) ต่อประสิทธิภาพของโมเดลยังมีอยู่อย่างจำกัด โดยเฉพาะการเปรียบเทียบระหว่าง RGB, RGB+HSV และ Grayscale ภายใต้เงื่อนไขการทดลองเดียวกัน (Gonzalez & Woods, 2018; Mazen & Nashat, 2019; Baglat et al., 2023) รวมถึงการประเมินความสามารถของโมเดลในการทำงานกับข้อมูลต่างสภาพแวดล้อมผ่านการทดลองแบบ Cross-Dataset Evaluation ซึ่งเป็นประเด็นสำคัญสำหรับการนำระบบไปประยุกต์ใช้งานจริงในภาคการเกษตร

ดังนั้น งานวิจัยนี้จึงมุ่งศึกษาผลกระทบของรูปแบบสีต่อการจำแนกระดับความสุกของกล้วยหอม โดยเปรียบเทียบประสิทธิภาพของเทคนิค Machine Learning และ Deep Learning ภายใต้รูปแบบสี RGB, RGB+HSV และ Grayscale พร้อมทั้งประเมินความสามารถในการ Generalization ของโมเดลผ่านการทดลองแบบ Cross-Dataset Evaluation เพื่อวิเคราะห์ความแข็งแกร่งของโมเดลและข้อจำกัดที่อาจเกิดขึ้นเมื่อใช้งานกับข้อมูลจากสภาพแวดล้อมที่แตกต่างกัน ผลการศึกษาคาดว่าจะเป็นแนวทางสำคัญในการพัฒนาระบบวิเคราะห์คุณภาพผลผลิตทางการเกษตรที่มีความแม่นยำและสามารถประยุกต์ใช้งานได้จริงในระบบเกษตรอัจฉริยะ (Smart Agriculture)

นอกจากนั้น งานวิจัยนี้ยังมีส่วนสนับสนุนทางวิชาการที่สำคัญ 3 ประการ ได้แก่ (1) การเปรียบเทียบผลกระทบของรูปแบบสี RGB, RGB+HSV และ Grayscale ต่อประสิทธิภาพการจำแนกระดับความสุกของกล้วยหอมภายใต้เงื่อนไขการทดลองเดียวกัน (2) การเปรียบเทียบประสิทธิภาพระหว่างเทคนิค Machine Learning และ Deep Learning ประกอบด้วย Random Forest, K-Nearest Neighbors (KNN), Support Vector Machine (SVM), CustomCNN และ MobileNetV2 และ (3) การประเมินความสามารถในการ Generalization ของโมเดลผ่านการทดลองแบบ Cross-Dataset Evaluation เพื่อวิเคราะห์ผลกระทบของ Domain Shift และศึกษาความเหมาะสมของโมเดลสำหรับการประยุกต์ใช้งานจริงในระบบเกษตรอัจฉริยะ

การประยุกต์ใช้เทคนิคการประมวลผลภาพและการเรียนรู้เชิงลึกในการจำแนกระดับความสุกของผลไม้ได้รับความสนใจอย่างต่อเนื่องในช่วงหลายปีที่ผ่านมา เนื่องจากสามารถช่วยเพิ่มความแม่นยำและลดข้อจำกัดของการประเมินด้วยสายตามนุษย์ งานวิจัยหลายฉบับรายงานว่โมเดลประเภท Convolutional Neural Networks (CNNs) สามารถเรียนรู้ลักษณะสำคัญของผลไม้จากข้อมูลภาพได้อย่างมีประสิทธิภาพ ทั้งในด้านสี พื้นผิว และรูปร่าง ส่งผลให้สามารถจำแนกระดับความสุกได้อย่างแม่นยำ (Howard et al., 2017; Saragih & Emanuel, 2021; Yang et al., 2024) นอกจากนี้ ยังมีการประยุกต์ใช้สถาปัตยกรรมที่ซับซ้อนมากขึ้น เช่น Dual CNN และ Transfer Learning เพื่อเพิ่มประสิทธิภาพในการเรียนรู้และลดข้อจำกัดจากปริมาณข้อมูลที่มีอยู่ (He et al., 2016; Sandler et al., 2018)

อีกหนึ่งปัจจัยสำคัญที่มีผลต่อประสิทธิภาพของการจำแนกระดับความสุกคือรูปแบบสี (Color Space) ที่ใช้ในการนำเสนอข้อมูลภาพ งานวิจัยของ Mazen และ Nashat (2019) รายงานว่า HSV Color Space สามารถช่วยให้โมเดลวิเคราะห์การเปลี่ยนแปลงของสีผลไม้ได้ดีกว่า RGB ในบางกรณี เนื่องจาก HSV สามารถแยกข้อมูลด้านเฉดสี (Hue) ความอิ่มตัวของสี (Saturation) และความสว่าง (Value) ออกจากกันได้อย่างชัดเจน ส่งผลให้โมเดลสามารถเรียนรู้ลักษณะการเปลี่ยนแปลงของสีที่สัมพันธ์กับระดับความสุกได้อย่างมีประสิทธิภาพมากขึ้น (Gonzalez & Woods, 2018; Baglat et al., 2023) อย่างไรก็ตาม งานวิจัยส่วนใหญ่ยังคงมุ่งเน้นการประเมินผลภายในชุดข้อมูลเดียว (Intra-Dataset Evaluation) ซึ่งมักให้ผลลัพธ์ที่มีความแม่นยำสูง แต่ไม่สามารถสะท้อนประสิทธิภาพของโมเดลเมื่อถูกนำไปใช้งานกับข้อมูลจากสภาพแวดล้อมอื่นที่มีความแตกต่างด้านแสง ฉากหลัง มุมกล้อง และคุณภาพของภาพ (Arunima et al., 2024; Chuquimarca et al., 2025)

จากการทบทวนวรรณกรรมพบว่า ยังมีงานวิจัยจำนวนน้อยที่ศึกษาผลกระทบของรูปแบบสีร่วมกับการประเมินความสามารถในการ Generalization ผ่านการทดลองแบบ Cross-Dataset Evaluation โดยเฉพาะในงานด้านการจำแนกระดับความสุกของกล้วยหอม ดังนั้น งานวิจัยนี้จึงมุ่งศึกษาผลของรูปแบบสี RGB, RGB+HSV และ Grayscale ร่วมกับโมเดล Machine Learning และ Deep Learning หลายรูปแบบ ภายใต้ทั้งการประเมินผลภายในชุดข้อมูลเดียวและการประเมินผลข้ามชุดข้อมูล เพื่อวิเคราะห์ความสามารถในการ Generalization ความแข็งแกร่งของโมเดล และความเหมาะสมต่อการประยุกต์ใช้งานจริงในระบบเกษตรอัจฉริยะ

วัตถุประสงค์


- 1) เพื่อเปรียบเทียบประสิทธิภาพของรูปแบบสี RGB, RGB+HSV และ Grayscale ต่อการจำแนกระดับความสุกของกล้วยหอม
- 2) เพื่อเปรียบเทียบประสิทธิภาพของโมเดล Machine Learning และ Deep Learning ได้แก่ Random Forest, KNN, SVM, CustomCNN และ MobileNetV2
- 3) เพื่อประเมินความสามารถในการ Generalization ของโมเดลด้วยการทดลองแบบ Cross-Dataset Evaluation ระหว่างชุดข้อมูลที่มีสภาพแวดล้อมแตกต่างกัน

วิธีดำเนินการวิจัย

งานวิจัยนี้ประกอบด้วยขั้นตอนหลัก ได้แก่ การเตรียมชุดข้อมูล การแปลงรูปแบบสี การพัฒนาโมเดล Machine Learning และ Deep Learning รวมถึงการประเมินประสิทธิภาพของโมเดลภายใต้ทั้ง Intra-Dataset และ Cross-Dataset Evaluation เพื่อวิเคราะห์ความสามารถในการ Generalization ของโมเดลภายใต้สภาพแวดล้อมที่แตกต่างกัน

ชุดข้อมูล (Dataset)

งานวิจัยนี้ใช้ชุดข้อมูลภาพกล้วยหอมจำนวน 2 ชุด ได้แก่ Banana Ripeness Classification Dataset และ Banana Images – Real Dataset ซึ่งประกอบด้วยภาพกล้วยหอมใน 4 ระดับความสุก ได้แก่ Unripe, Ripe, Overripe และ Rotten โดยข้อมูลทั้งหมดถูกแบ่งออกเป็นชุด Training, Validation และ Testing ตามโครงสร้างการแบ่งข้อมูลดั้งเดิมของชุดข้อมูล (Original Dataset Split) ชุดข้อมูลทั้งสองมีความแตกต่างด้านสภาพแสง ฉากหลัง คุณภาพของภาพ และสภาพแวดล้อมในการถ่ายภาพ ทำให้เหมาะสำหรับการประเมินความสามารถในการ Generalization ของโมเดลผ่านการทดลองแบบ Cross-Dataset Evaluation ซึ่งดำเนินการโดยใช้ชุดข้อมูลหนึ่งสำหรับการฝึกสอนและอีกชุดข้อมูลหนึ่งสำหรับการทดสอบ



ภาพที่ 1 ตัวอย่างภาพกล้วยหอมในแต่ละระดับความสุกที่ใช้ในการทดลอง ประกอบด้วย Unripe, Ripe, Overripe และ Rotten ซึ่งมีลักษณะสีและพื้นผิวแตกต่างกันตามกระบวนการสุกของผลกล้วย


การเตรียมข้อมูลและรูปแบบสี (Data Preparation and Color Representation)

ก่อนนำข้อมูลเข้าสู่กระบวนการฝึกโมเดล ภาพทั้งหมดถูกปรับขนาดเป็น 224×224 พิกเซล และทำการ Normalize ค่าพิกเซลให้อยู่ในช่วง 0–1 เพื่อเพิ่มเสถียรภาพในการเรียนรู้ของโมเดล (Goodfellow et al., 2016) นอกจากนี้ ยังใช้เทคนิค Data Augmentation ได้แก่ การหมุนภาพ (Rotation) การพลิกภาพในแนวนอน (Horizontal Flip) การซูมภาพ (Zoom) และการปรับความสว่าง (Brightness Adjustment) เพื่อเพิ่มความหลากหลายของข้อมูลและลดปัญหา Overfitting (Shorten & Khoshgoftaar, 2019)

งานวิจัยนี้เปรียบเทียบรูปแบบสีจำนวน 3 รูปแบบ ได้แก่ RGB, RGB+HSV และ Grayscale โดย RGB เป็นข้อมูลสีดั้งเดิมของภาพ ขณะที่ RGB+HSV ช่วยให้โมเดลสามารถเรียนรู้ข้อมูลด้านเฉดสีและความสว่างได้ละเอียดมากขึ้น ส่วน Grayscale ถูกนำมาใช้เพื่อศึกษาผลกระทบของการลดข้อมูลสีต่อประสิทธิภาพในการจำแนกระดับความสุกของกล้วยหอม

การพัฒนาโมเดลและการตั้งค่าการฝึก (Model Development and Training Setup)

งานวิจัยนี้เปรียบเทียบโมเดลทั้งหมด 5 รูปแบบ ได้แก่ Random Forest (RF), K-Nearest Neighbors (KNN), Support Vector Machine (SVM), CustomCNN และ MobileNetV2 เพื่อวิเคราะห์ประสิทธิภาพของทั้งเทคนิค Traditional Machine Learning และ Deep Learning ภายใต้เงื่อนไขเดียวกัน โดย MobileNetV2 เป็นสถาปัตยกรรมที่ได้รับการออกแบบให้มีประสิทธิภาพสูงและใช้ทรัพยากรในการประมวลผลต่ำ ผ่านแนวคิด Inverted Residuals และ Linear Bottlenecks (Sandler et al., 2018) จึงได้รับความนิยมอย่างแพร่หลายในงานด้านการจำแนกภาพและอุปกรณ์เคลื่อนที่



ภาพที่ 2 โครงสร้างของโมเดล CustomCNN ที่ใช้ในการทดลองเพื่อจำแนกระดับความสุกของกล้วยหอมทั้ง 4 คลาส

การฝึกโมเดล Deep Learning ใช้ Adam Optimizer ร่วมกับค่า Learning Rate เท่ากับ 0.001 กำหนด Batch Size เท่ากับ 32 และจำนวนรอบการฝึก (Epoch) เท่ากับ 50 รอบ โดยใช้ฟังก์ชัน Categorical Crossentropy สำหรับคำนวณค่าความสูญเสียในการจำแนกข้อมูลหลายคลาส กระบวนการฝึกโมเดลดำเนินการบนแพลตฟอร์ม Google Colab ที่รองรับการประมวลผลด้วย GPU เพื่อเพิ่มประสิทธิภาพและลดระยะเวลาในการฝึกสอนโมเดล


ผลการวิจัย

ผลการทดลองภายในชุดข้อมูล (Intra-Dataset Evaluation)

ผลการทดลองบน Banana Ripeness Classification Dataset และ Banana Images – Real Dataset พบว่าโมเดล Deep Learning ให้ประสิทธิภาพสูงกว่าโมเดล Traditional Machine Learning อย่างชัดเจนในทุกการทดลอง โดย MobileNetV2 ให้ค่าความแม่นยำสูงสุดที่ 97.86% บน Banana Ripeness Classification Dataset และ 97.66% บน Banana Images – Real Dataset ในการทดลองแบบ RGB ขณะที่ CustomCNN ให้ผลลัพธ์ใกล้เคียงกันและสามารถทำงานได้อย่างมีประสิทธิภาพในทั้งสองชุดข้อมูล

เมื่อเพิ่มข้อมูล HSV ร่วมกับ RGB พบว่าประสิทธิภาพของโมเดลเพิ่มขึ้นในหลายกรณี โดย CustomCNN ให้ผลลัพธ์ที่ดีที่สุดของการทดลองทั้งหมดด้วย Accuracy เท่ากับ 98.40% และ Weighted F1-score เท่ากับ 0.9840 ขณะที่ MobileNetV2 ให้ Accuracy สูงถึง 97.95% บนชุดข้อมูล Banana Images – Real Dataset ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าข้อมูล HSV สามารถช่วยให้โมเดลเรียนรู้การเปลี่ยนแปลงของเฉดสีที่สัมพันธ์กับระดับความสุกของกล้วยได้ดียิ่งขึ้น

นอกจากนี้ จากการวิเคราะห์ผลการจำแนกรายคลาสพบว่าโมเดลสามารถจำแนกคลาส unripe และ overripe ได้อย่างแม่นยำ ขณะที่ยังคงเกิดความสับสนบางส่วนระหว่างคลาส ripe และ rotten เนื่องจากมีลักษณะสีใกล้เคียงกันในบางช่วงของกระบวนการสุก



ภาพที่ 3 Confusion Matrix ของโมเดล MobileNetV2 ภายใต้รูปแบบสี RGB+HSV บนชุดข้อมูล Banana Images – Real Dataset แสดงให้เห็นว่าโมเดลสามารถจำแนกคลาส unripe และ overripe ได้อย่างแม่นยำ

ตารางที่ 1

ผลการทดลองแบบ RGB บน Banana Ripeness Classification Dataset

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0.978648	0.978904	0.978648	0.978601
CustomCNN	0.969751	0.970048	0.969751	0.969749
RF_RGB	0.882562	0.886206	0.882562	0.882770
KNN_RGB	0.855872	0.859192	0.855872	0.856453
SVM_RGB	0.829181	0.832359	0.829181	0.830233

ตารางที่ 2

ผลการทดลองแบบ RGB บน Banana Images - Real Dataset

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0.976574	0.977189	0.976574	0.976645
CustomCNN	0.937042	0.936607	0.937042	0.936562
RF_RGB	0.907760	0.906902	0.907760	0.907004
KNN_RGB	0.885798	0.887140	0.885798	0.886434
SVM_RGB	0.866764	0.868283	0.866764	0.867002

ตารางที่ 3

ผลการทดลองแบบ RGB+HSV บน Banana Ripeness Classification Dataset

Model	Accuracy
MobileNetV2	0.9733
CustomCNN	0.9840

ตารางที่ 4

ผลการทดลองแบบ RGB+HSV บน Banana Images - Real Dataset

Model	Accuracy
MobileNetV2	0.9795
CustomCNN	0.9649

ผลการทดลองภายใต้รูปแบบสี RGB+HSV แสดงให้เห็นว่าการเพิ่มข้อมูล HSV สามารถช่วยเพิ่มประสิทธิภาพของโมเดลในหลายกรณี โดยเฉพาะ CustomCNN ซึ่งให้ผลลัพธ์ที่ดีที่สุดของการทดลองทั้งหมดด้วย Accuracy เท่ากับ 98.40% ขณะที่ MobileNetV2 ยังคงแสดงประสิทธิภาพที่สูงและมีความเสถียร การเพิ่มข้อมูล HSV ช่วยให้โมเดลสามารถเรียนรู้ความแตกต่างของเฉดสี ความอึมัวของสี และความสว่างที่สัมพันธ์กับกระบวนการสุกของกล้วยได้ดียิ่งขึ้น (Gonzalez & Woods, 2018; Mazen & Nashat, 2019)

ตารางที่ 5

ผลการทดลองแบบ Grayscale บน Banana Ripeness Classification Dataset

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0.9466	0.9467	0.9466	0.9465
CustomCNN	0.8310	0.8504	0.8310	0.8256
Random Forest	0.9395	0.9400	0.9395	0.9395
KNN	0.9004	0.9015	0.9004	0.9005
SVM	0.8594	0.8594	0.8594	0.8592

ตารางที่ 6

ผลการทดลองแบบ Grayscale บน Banana Images - Real Dataset

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0.9619	0.9627	0.9619	0.9622
CustomCNN	0.8346	0.8273	0.8346	0.8283
Random Forest	0.9414	0.9412	0.9414	0.9413
KNN	0.8946	0.8977	0.8946	0.8958
SVM	0.8565	0.8596	0.8565	0.8573

ผลการทดลองแบบ Grayscale พบว่าค่าความแม่นยำของทุกโมเดลลดลงเมื่อเปรียบเทียบกับการใช้ RGB และ RGB+HSV โดย MobileNetV2 ยังคงให้ผลลัพธ์ที่ดีที่สุดในกลุ่ม Deep Learning ขณะที่ Random Forest ให้ผลลัพธ์ใกล้เคียงกับ MobileNetV2 ในบางชุดข้อมูล อย่างไรก็ตาม ค่าประสิทธิภาพโดยรวมของโมเดลภายใต้รูปแบบสี Grayscale ต่ำกว่าการใช้ข้อมูลสี

ผลการทดลองแบบ Cross-Dataset Evaluation

ตารางที่ 7

ผลการทดลองแบบ Cross-Dataset บน Banana Ripeness Classification Dataset

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0.4250	0.4455	0.4250	0.4186
CustomCNN	0.5425	0.4789	0.5425	0.4726
Random Forest	0.3475	0.5007	0.3475	0.2857
KNN	0.4025	0.3610	0.4025	0.3144
SVM	0.3575	0.5059	0.3575	0.3250

ตารางที่ 8

ผลการทดลองแบบ Cross-Dataset บน Banana Images - Real Dataset

Model	Accuracy	Precision	Recall	F1-score
MobileNetV2	0.3750	0.4648	0.3750	0.4109
CustomCNN	0.2500	0.0625	0.2500	0.1000
Random Forest	0.2475	0.3863	0.2475	0.2213
KNN	0.3525	0.4559	0.3525	0.3162
SVM	0.3775	0.5174	0.3775	0.3281

ผลการทดลองแบบ Cross-Dataset Evaluation พบว่าค่าความแม่นยำของทุกโมเดลลดลงอย่างชัดเจนเมื่อทดสอบกับข้อมูลที่มีสภาพแวดล้อมแตกต่างจากชุดข้อมูลที่ใช้ในการฝึกสอน สะท้อนให้เห็นถึงปัญหา Domain Shift ระหว่างชุดข้อมูลทั้งสองชุดอย่างชัดเจน แม้ว่าโมเดลจะสามารถเรียนรู้และให้ผลลัพธ์ที่ดีภายในชุดข้อมูลเดิมได้ แต่เมื่อเผชิญกับข้อมูลใหม่ที่มีลักษณะต่างออกไป ประสิทธิภาพของโมเดลกลับลดลงอย่างมีนัยสำคัญ

ในการทดลองแบบ RGB พบว่า CustomCNN ให้ผลลัพธ์ที่ดีที่สุดเมื่อฝึกด้วย Banana Ripeness Classification Dataset และทดสอบด้วย Banana Images – Real Dataset โดยมี Accuracy เท่ากับ 54.25% ขณะที่ MobileNetV2 ให้ Accuracy เท่ากับ 42.50% ส่วนการฝึกด้วย Banana Images – Real Dataset และทดสอบด้วย Banana Ripeness Classification Dataset ให้ผลลัพธ์ลดลงเพิ่มเติม โดย MobileNetV2 ให้ Accuracy สูงสุดที่ 37.50% ผลลัพธ์ดังกล่าวแสดงให้เห็นว่าแม้โมเดล Deep Learning จะสามารถเรียนรู้คุณลักษณะภายในชุดข้อมูลต้นทางได้อย่างมีประสิทธิภาพ แต่ยังมีข้อจำกัดด้านความสามารถในการ Generalization เมื่อต้องทำงานกับข้อมูลที่มีความแตกต่างของสภาพแวดล้อม เช่น สภาพแสง ฉากหลัง มุมกล้อง และคุณภาพของภาพ

นอกจากนี้ แม้การใช้ RGB+HSV จะช่วยเพิ่มประสิทธิภาพภายในชุดข้อมูลเดิมได้ดี แต่กลับมีแนวโน้มลดประสิทธิภาพในการทดลองแบบ Cross-Dataset ซึ่งอาจเกิดจากความไวของคุณลักษณะ HSV ต่อความแตกต่างของสภาพแสงและการกระจายของสีในแต่ละชุดข้อมูล ผลลัพธ์ทั้งหมดชี้ให้เห็นว่าการประเมินผลภายในชุดข้อมูลเดียวอาจไม่เพียงพอต่อการสะท้อนศักยภาพของโมเดลสำหรับการใช้งานจริง และการประเมินแบบ Cross-Dataset ควรถูกนำมาใช้เป็นส่วนหนึ่งของกระบวนการพัฒนาโมเดลสำหรับระบบเกษตรอัจฉริยะที่ต้องทำงานภายใต้สภาพแวดล้อมที่หลากหลาย

ผลลัพธ์ดังกล่าวสอดคล้องกับการศึกษาของ Chuquimarca และคณะ (2025) ซึ่งรายงานว่าความแตกต่างของสภาพแสงและสภาพแวดล้อมในการเก็บข้อมูลสามารถส่งผลกระทบต่อความสามารถในการ Generalization ของโมเดล Deep Learning อย่างมีนัยสำคัญ โดยเฉพาะในงานจำแนกระดับความสุกของกล้วยที่อาศัยข้อมูลสีเป็นปัจจัยหลักในการตัดสินใจ

สรุปผลการวิจัย

งานวิจัยนี้นำเสนอการวิเคราะห์ระดับความสุกของกล้วยหอมด้วยเทคนิคการประมวลผลภาพร่วมกับ Machine Learning และ Deep Learning โดยมีวัตถุประสงค์เพื่อศึกษาผลกระทบของรูปแบบสีต่อประสิทธิภาพของโมเดล และประเมินความสามารถในการ Generalization ภายใต้ข้อมูลที่มีความแตกต่างของสภาพแวดล้อมผ่านการทดลองแบบ Cross-Dataset Evaluation

ผลการทดลองพบว่าโมเดล Deep Learning โดยเฉพาะ MobileNetV2 และ CustomCNN มีประสิทธิภาพสูงกว่าโมเดล Traditional Machine Learning อย่างชัดเจน และ การใช้ข้อมูล RGB+HSV สามารถช่วยเพิ่มประสิทธิภาพในการจำแนกระดับความสุกได้ดีกว่าการใช้ RGB และ Grayscale เนื่องจากช่วยให้โมเดลสามารถเรียนรู้การเปลี่ยนแปลงของเฉดสีที่สัมพันธ์กับกระบวนการสุกของกล้วยได้อย่างมีประสิทธิภาพมากขึ้น

อย่างไรก็ตาม ผลการทดลองแบบ Cross-Dataset Evaluation แสดงให้เห็นว่าค่าความแม่นยำของทุกโมเดลลดลงอย่างมีนัยสำคัญเมื่อทดสอบกับข้อมูลจากสภาพแวดล้อมที่ต่างกัน สะท้อนให้เห็นถึงปัญหา Domain Shift และข้อจำกัดด้านความสามารถในการ Generalization ของโมเดล ผลลัพธ์ดังกล่าวชี้ให้เห็นว่าการประเมินผลภายในชุดข้อมูลเดียวอาจไม่เพียงพอสำหรับการสะท้อนศักยภาพของโมเดลในการใช้งานจริง และการประเมินผลด้วยข้อมูลต่างสภาพแวดล้อมควรถูกนำมาใช้เป็นส่วนหนึ่งของกระบวนการพัฒนาโมเดลในงานด้านเกษตรอัจฉริยะ

ในอนาคต ควรเพิ่มความหลากหลายของข้อมูลจากสภาพแวดล้อมจริง รวมถึงศึกษาการประยุกต์ใช้เทคนิค Domain Adaptation หรือ Domain Generalization เพื่อเพิ่มความสามารถในการทำงานกับข้อมูลที่ไม่เคยพบมาก่อน และยกระดับความแม่นยำและความเสถียรของระบบสำหรับการนำไปใช้งานจริงในภาคการเกษตร

การอภิปรายผล

ผลการทดลองสนับสนุนแนวคิดที่ว่าข้อมูลสีมีบทบาทสำคัญต่อการจำแนกระดับความสุกของกล้วยหอม เนื่องจากการเปลี่ยนแปลงของสีเปลือกกล้วยเป็นสัญญาณหลักที่สัมพันธ์กับกระบวนการสุก การใช้ RGB+HSV จึงช่วยเพิ่มข้อมูลเชิงสีให้กับโมเดลและทำให้เกิดผลลัพธ์ที่ดีภายในชุดข้อมูลเดิม ซึ่งสอดคล้องกับงานของ Mazen และ Nashat (2019) และการอธิบายเชิงทฤษฎีด้าน Color Space ของ Gonzalez และ Woods (2018) ในทางกลับกัน ผลการทดลองข้ามชุดข้อมูลแสดงให้เห็นว่าการเพิ่ม HSV ไม่ได้ช่วยให้โมเดลทนทานต่อข้อมูลต่างสภาพแวดล้อมเสมอไป เนื่องจาก HSV มีความไวต่อความแตกต่างของสภาพแสงและการกระจายของสีระหว่างชุดข้อมูล ผลลัพธ์นี้สอดคล้องกับ Chuquimarca และคณะ (2025) และ Baglat และคณะ (2023) ที่ชี้ว่าความแตกต่างของสภาพแสงส่งผลต่อความแข็งแกร่งของโมเดล Deep Learning ในงานจำแนกระดับความสุกของกล้วย

นอกจากนี้ ผลการทดลองยังแสดงให้เห็นว่าการผสานข้อมูล RGB ร่วมกับ HSV สามารถช่วยเพิ่มประสิทธิภาพของโมเดลได้ดีกว่าการใช้ RGB เพียงอย่างเดียว เนื่องจาก HSV สามารถแยกองค์ประกอบของสีออกเป็นเฉดสี (Hue) ความอิ่มตัวของสี (Saturation) และความสว่าง (Value) ได้อย่างอิสระ ทำให้โมเดลสามารถเรียนรู้การเปลี่ยนแปลงของสีเปลือกกล้วยที่เกิดขึ้นตามกระบวนการสุกได้ละเอียดมากขึ้น โดยเฉพาะการเปลี่ยนแปลงจากสีเขียวไปสู่สีเหลืองและสีน้ำตาล ซึ่งเป็นลักษณะสำคัญของการจำแนกระดับความสุก ผลลัพธ์ดังกล่าวสอดคล้องกับแนวคิดด้านการประมวลผลภาพของ Gonzalez และ Woods (2018) และงานวิจัยของ Mazen และ Nashat (2019) ที่รายงานว่าการใช้ข้อมูลสีที่สามารถแยกองค์ประกอบของสีได้อย่างชัดเจนมีส่วนช่วยเพิ่มประสิทธิภาพในการจำแนกระดับความสุกของผลไม้

อย่างไรก็ตาม แม้โมเดลจะให้ผลลัพธ์ที่ดีมากภายใต้การประเมินผลภายในชุดข้อมูลเดียว แต่ประสิทธิภาพกลับลดลงอย่างชัดเจนในการทดลองแบบ Cross-Dataset Evaluation สะท้อนให้เห็นถึงปัญหา Domain Shift ซึ่งเกิดจากความแตกต่างของสภาพแสง ฉากหลัง คุณภาพของภาพ และลักษณะการเก็บข้อมูลระหว่างชุดข้อมูลต้นทางและชุดข้อมูลปลายทาง ส่งผลให้คุณลักษณะที่โมเดลเรียนรู้จากข้อมูลฝึกสอนไม่สามารถนำไปประยุกต์ใช้กับข้อมูลใหม่ได้อย่างมีประสิทธิภาพ นอกจากนี้ ผลลัพธ์ดังกล่าวยังบ่งชี้ถึงความเป็นไปได้ที่โมเดลจะเกิด Overfitting ต่อรูปแบบเฉพาะของชุดข้อมูลที่ใช้ฝึกสอน แม้ว่าจะมีค่าความแม่นยำสูงในการทดสอบภายในชุดข้อมูลเดิมก็ตาม ดังนั้น การประเมินความสามารถในการ Generalization ผ่านการทดลองแบบ Cross-Dataset จึงมีความสำคัญอย่างยิ่งต่อการพัฒนาระบบวิเคราะห์ระดับความสุกที่สามารถนำไปใช้งานจริงในสภาพแวดล้อมที่หลากหลาย ซึ่งสอดคล้องกับข้อค้นพบของ Chuquimarca และคณะ (2025) และ Baglat และคณะ (2023)

ข้อจำกัดของการวิจัย

ข้อจำกัดสำคัญของงานวิจัยนี้คือความแตกต่างระหว่างชุดข้อมูลทั้งสองด้านสภาพแสง ฉากหลัง ระยะเวลาการถ่ายภาพ และคุณภาพของภาพ ซึ่งส่งผลต่อการกระจายของค่าสีและลักษณะภาพที่โมเดลเรียนรู้ แม้ว่าการประเมินผลภายในชุดข้อมูลจะให้ค่าความแม่นยำสูง แต่ผลลัพธ์ดังกล่าวอาจสะท้อนการเรียนรู้รูปแบบเฉพาะของชุดข้อมูลมากกว่าความสามารถในการใช้งานจริงในทุกสภาพแวดล้อม

อีกข้อจำกัดหนึ่งคือจำนวนชุดข้อมูลภายนอกที่ใช้ในการทดสอบยังมีจำกัด การใช้เพียงสองชุดข้อมูลสามารถแสดงแนวโน้มของ Domain Shift ได้ แต่ยังไม่เพียงพอสำหรับสรุปความทนทานของโมเดลในสถานการณ์จริงทั้งหมด เช่น ภาพจากกล้องโทรศัพท์หลายรุ่น ภาพจากโรงคัดแยกผลผลิต หรือภาพจากพื้นที่เพาะปลูกที่มีแสงธรรมชาติแตกต่างกัน

นอกจากนี้ งานวิจัยนี้มุ่งเน้นการเปรียบเทียบผลของรูปแบบสีและโมเดลเป็นหลัก ยังไม่ได้วิเคราะห์เชิงลึกเกี่ยวกับเทคนิคการปรับสมดุลข้อมูล การปรับแต่ง Hyperparameter หลายรูปแบบ หรือการใช้ Explainable AI เพื่ออธิบายบริเวณภาพที่โมเดลใช้ตัดสินใจ ซึ่งเป็นประเด็นที่ควรศึกษาเพิ่มเติมเพื่อเพิ่มความน่าเชื่อถือและความสามารถในการตีความผลลัพธ์

ข้อเสนอแนะ

- 1) ควรเพิ่มจำนวนและความหลากหลายของภาพจากสภาพแวดล้อมจริง เช่น แสงธรรมชาติหลายช่วงเวลา ฉากหลังหลายรูปแบบ และอุปกรณ์ถ่ายภาพต่างชนิด
- 2) ควรศึกษาการใช้เทคนิค Domain Adaptation หรือ Domain Generalization เพื่อลดผลกระทบจาก Domain Shift และเพิ่มความสามารถในการใช้งานกับข้อมูลที่ไม่เคยพบมาก่อน
- 3) ควรเพิ่มการประเมินผลด้วยชุดข้อมูลภายนอกและการทดลองซ้ำหลายรอบ เพื่อเพิ่มความน่าเชื่อถือของผลลัพธ์สำหรับการตีพิมพ์ในระดับวิชาการ

เอกสารอ้างอิง

- Arunima, P. L., Gopinath, P. P., Lekshmi, P. R. G., & Esakkimuthu, M. (2024). Digital assessment of post-harvest Nendran banana for faster grading: CNN-based ripeness classification model. *Postharvest Biology and Technology*, 214, Article 112972. <https://doi.org/10.1016/j.postharvbio.2024.112972>
- Baglat, P., Hayat, A., Mendonça, F., Gupta, A., Mostafa, S. S., & Morgado-Dias, F. (2023). Non-destructive banana ripeness detection using shallow and deep learning: A systematic review. *Sensors*, 23(2), 738. <https://doi.org/10.3390/s23020738>
- Chuquimarca, L. E., Vintimilla, B. X., & Velastin, S. A. (2025). Assessing deep learning model robustness for banana ripeness classification under varying illumination conditions. *Smart Agricultural Technology*, 12, Article 101333.
- Goodfellow, I., Bengio, Y., & Courville, A. (2016). *Deep Learning*. MIT Press. <https://www.deeplearningbook.org>
- Gonzalez, R. C., & Woods, R. E. (2018). *Digital image processing* (4th ed.). Pearson.
- He, K., Zhang, X., Ren, S., & Sun, J. (2016). Deep residual learning for image recognition. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 770-778). <https://doi.org/10.1109/CVPR.2016.90>
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., Andreetto, M., & Adam, H. (2017). MobileNets: Efficient convolutional neural networks for mobile vision applications. arXiv.
- Mazen, F. M. A., & Nashat, A. A. (2019). Ripeness classification of bananas using an artificial neural network. *Arabian Journal for Science and Engineering*, 44, 6901-6910.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., & Chen, L.-C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition* (pp. 4510-4520). <https://doi.org/10.1109/CVPR.2018.00474>
- Saragih, R. E., & Emanuel, A. W. R. (2021). Banana ripeness classification based on deep learning using convolutional neural network. In *Proceedings of the 3rd East Indonesia Conference on Computer and Information Technology (EIConCIT)* (pp. 85-89). IEEE. <https://doi.org/10.1109/EIConCIT50028.2021.9431928>
- Shorten, C., & Khoshgoftaar, T. M. (2019). A survey on image data augmentation for deep learning. *Journal of Big Data*, 6(1), 60. <https://doi.org/10.1186/s40537-019-0197-0>
- Yang, L., Cui, B., Wu, J., et al. (2024). Automatic detection of banana maturity: Application of image recognition in agricultural production. *Processes*, 12(4), 799. <https://doi.org/10.3390/pr12040799>