

โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟ

เพ็ญนภา ภูโคกหาวย¹, นุวีร์ วิวัฒน์วัฒนา²

บทคัดย่อ

ข้อบกพร่องต่าง ๆ ที่เกิดขึ้นกับเมล็ดกาแฟ ส่งผลต่อรสชาติของกาแฟ ดังนั้นเมล็ดกาแฟที่จะนำไปคั่วต้องมีคุณภาพที่ดี ตามมาตรฐาน งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองที่ใช้การเรียนรู้เชิงลึกโดยโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยประกอบไปด้วยความมุ่งหมาย คือ 1) เพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีข้อบกพร่องออกจากกันได้ 2) เพื่อจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดแตก, เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดปกติได้ โดยชุดข้อมูลรูปภาพเมล็ดกาแฟได้จากงานวิจัยเรื่อง การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพด้วยการประมวลผลภาพถ่าย โดยมีการใช้เทคนิคการเสริมข้อมูล และการเติมรูปภาพเพื่อนำมาสร้างแบบจำลองต่างๆ ได้แก่ ResNet50, ResNet101 และ VGG-16 ค่าความแม่นยำ (Accuracy) ที่ได้จากการศึกษาเพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีข้อบกพร่อง คือ 0.88, 0.94 และ 0.96 พบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ VGG-16 ให้ผลลัพธ์ที่ดีที่สุด และในส่วนของงานจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟออกจากเมล็ดปกติ ได้ค่าความแม่นยำ คือ 0.97, 0.96 และ 0.95 พบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 ให้ผลลัพธ์ที่ดีที่สุด

คำสำคัญ : การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การจำแนกประเภทความบกพร่องของเมล็ดกาแฟ

¹ หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

² คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ กรุงเทพฯ 10110

* Corresponding author: Tel.: 088-2444249 E-mail address: pennapa.pkw@g.swu.ac.th

Convolutional Neural Networks for Coffee Bean Defect Classification

Pennapa Phukhokwai^{1*}, Nuwee Wiwatwattana²

Abstract

Various defects that occur in coffee beans will affect the taste of the coffee. Therefore, the coffee beans that will be roasted must be of good quality according to standards. The objective of this research is to develop models that use deep learning's convolutional neural networks. It consists of 2 objectives: 1) to classify between green bean and defective coffee beans 2) to classify defects in coffee beans, divided into 5 categories: black beans, moldy beans, bean fragments, incompletely formed beans, and insect-damaged beans out of green beans. The coffee bean images were obtained from the research on "Coffee Beans Feature Extraction and Selection for Quality Classification using Image Processing", but using data augmentation and image padding techniques. Models built were ResNet50, ResNet101, and VGG-16. The accuracy values obtained from this study to classify between green beans and defective coffee beans were 0.88, 0.94, and 0.96, this respectively model using VGG-16 architecture was found to have the best results. The accuracy values obtained from this study to classify defects in coffee beans into 5 categories out of green beans were 0.97, 0.96, and 0.95, this respectively model using ResNet50 architecture was found to have the best results.

Keywords : Deep Learning, Convolutional Neural Network, Coffee Bean Defect Classification

¹ Data Science, Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

² Faculty of Science, Srinakharinwirot University, Bangkok, 10110, Thailand

* Corresponding author: Tel.: 088-2444249 E-mail address: Pennapa.pkw@g.swu.ac.th

บทนำ

กาแฟเป็นเครื่องดื่มที่เป็นที่ชื่นชอบของทั้งคนไทยและทั่วโลก ซึ่งกว่าจะได้กาแฟรสชาติดีมีคุณภาพ นอกจากสายพันธุ์กาแฟ และพื้นที่การเพาะปลูกที่จะส่งผลต่อรสชาติของกาแฟแล้ว เมล็ดกาแฟที่จะนำไปคั่วนั้นต้องมีคุณภาพที่ดี และผ่านการคัดแยกเมล็ดแล้วเรียบร้อย การคัดแยกเมล็ดกาแฟที่มีข้อบกพร่อง สามารถอ้างอิงได้ตามประกาศสำนักงานมาตรฐานสินค้าเกษตรและอาหารแห่งชาติ กระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดมาตรฐานสินค้าเกษตร : เมล็ดกาแฟอาราบิก้า มาตรฐานเลขที่ มกษ. 5701-2561 ตามพระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551 [1] ซึ่งแบ่งได้เป็น 8 ประเภท คือ เมล็ดดำ (Black beans), เมล็ดขึ้นรา (Moldy beans), ชิ้นเมล็ดแตก (Bean fragments), เมล็ดไม่สมบูรณ์ (Incompletely formed beans), เมล็ดถูกแมลงทำลาย (Insect-damaged beans), ผลกาแฟแห้ง (Dried cherry), สิ่งแปลกปลอม (Foreign matter) และข้อบกพร่องรวม

ปัจจุบันการคัดแยกเมล็ดกาแฟจะใช้วิธีการคัดเมล็ดด้วยเครื่องคัดแยก และมักจะใช้วิธีการคัดแยกด้วยมือโดยแรงงานคนอีกครั้งหนึ่งเพื่อให้ได้เมล็ดกาแฟที่มีคุณภาพดี ซึ่งการคัดแยกด้วยมืออาจใช้ระยะเวลาอันยาวนานและไม่แม่นยำเท่าที่ควร เนื่องจากอาศัยประสบการณ์ของแรงงานคนนั้นๆ ผู้วิจัยได้เล็งเห็นถึงปัญหาของกระบวนการข้างต้น และสนใจที่จะนำองค์ความรู้เกี่ยวกับการเรียนรู้เชิงลึก (Deep learning) มาใช้จำแนกข้อบกพร่องของเมล็ดกาแฟ เนื่องจากเป็นองค์ความรู้ที่สามารถวิเคราะห์ข้อมูลได้อย่างมีประสิทธิภาพ เช่น การจำแนกภาพ (Image classification), การแปลภาษา (Natural language processing) และการทำนายข้อมูล (Predictive analytics) เป็นต้น และยังสามารถประมวลผลข้อมูลที่ซับซ้อนและมีจำนวนมากได้ดี ผู้วิจัยจึงได้จัดทำแบบจำลองการทำนายเพื่อคัดแยกเมล็ดกาแฟแบบอัตโนมัติโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยนำมาจำแนกประเภทเมล็ดกาแฟ 2 รูปแบบ คือ 1) จำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความบกพร่อง 2) จำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ได้แก่ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดแตก, เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดกาแฟปกติ โดยในงานวิจัยได้นำเสนอการเตรียมข้อมูลด้วยการเสริมข้อมูลและการเติมรูปภาพ เพื่อให้แบบจำลองมีประสิทธิภาพในการทำนายข้อมูลมากขึ้น และมีการนำสถาปัตยกรรมแบบ ResNet50, ResNet101 และ VGG-16 มาสร้างแบบจำลองเปรียบเทียบประสิทธิภาพกัน เพื่อนำแบบจำลองที่ประสิทธิภาพดีที่สุดไปใช้ประโยชน์ในการจำแนกเมล็ดกาแฟ

งานวิจัยที่เกี่ยวข้อง

บทความวิจัยที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันมาแก้ปัญหา มีตัวอย่างดังต่อไปนี้ Pinto และคณะ [2] ได้ทำการพัฒนาระบบคัดแยกเมล็ดกาแฟอัตโนมัติโดยใช้โครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชัน มีการใช้เทคนิคการจัดการรูปภาพเพื่อแยกเมล็ดกาแฟแต่ละประเภท และเพื่อคำนวณความแม่นยำในการจำแนกประเภทข้อบกพร่องแต่ละประเภท ผู้วิจัยใช้วิธีจับคู่ภาพเมล็ดที่มีความบกพร่องกับเมล็ดปกติ สำหรับการฝึกสอน สำหรับข้อมูลทดสอบ ผู้วิจัยมีการใช้ภาพโทนสีเทาในประเภทกาแฟที่มีข้อบกพร่องทางด้านรูปร่างเพิ่มเข้าไปด้วย ได้ค่าความแม่นยำในการจำแนกประเภทเมล็ดดำสูงสุด อยู่ที่ 0.98 ส่วนเมล็ดแตกที่ใช้ภาพโทนสีเทา ได้ค่าความแม่นยำต่ำที่สุด คือ 0.67 ทำให้ไม่สามารถสรุปได้แน่ชัดว่าคุณลักษณะใดมีส่วนทำให้ความแม่นยำในการจำแนกลดลง บทความวิจัยถัดไป Huang และคณะ [3] ผู้วิจัยต้องการพัฒนาระบบเครื่องเก็บเมล็ดกาแฟอัตโนมัติ โดยใช้การเสริมข้อมูลรูปใช้การเรียนรู้เชิงลึกของโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อวิเคราะห์ข้อมูล และใช้แบบจำลองมาเชื่อมต่อกับกล้องเว็บแคมเพื่อประมวลผลรูปภาพที่ผ่านเข้ามา ผู้วิจัยมีการแปลงรูปภาพเป็นสีเทา และลบพื้นหลังรูปภาพออก ผลการทดลองพบว่าทำให้

ภาพเป็นสีเทาเพื่อใช้ในแบบจำลอง ส่งผลให้การทดสอบมีความแม่นยำประมาณ 93.34% ค่า loss ประมาณ 0.19 และได้ค่า FPR 0.1007 บทความวิจัยถัดไป Febriana และคณะ [4] ผู้วิจัยได้นำเสนอระบบคัดแยกเมล็ดกาแฟ โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน ด้วยสถาปัตยกรรมสองแบบคือ ResNet-18 และ MobileNetV2 สำหรับ ResNet-18 มีการเปลี่ยนเลเยอร์สุดท้ายของแบบจำลองเป็น 4 Fully Connected Layers สำหรับ MobileNetV2 ผู้วิจัยได้ตั้งอัตราเลเยอร์แรกไว้ และเพิ่ม Dropout Layer ด้วยอัตรา 0.2 เพื่อปรับปรุงความสามารถของแบบจำลองและลดการโอเวอร์ฟิตติ้ง และยังทำการเปลี่ยน Fully Connected Layers เพื่อแบ่งชุดข้อมูลออกเป็น 4 คลาส ผลลัพธ์ที่ได้พบว่า MobileNetV2 สามารถทำงานได้ดีกว่า ResNet-18 บทความวิจัยถัดไป Hortinela และคณะ [5] ผู้วิจัยได้พัฒนาระบบที่ใช้โครงข่ายประสาทเทียม VGG-16 เพื่อตรวจจับข้อบกพร่องของเมล็ดโกโก้ ผลการทดลองแสดงให้เห็นว่าโมเดลมีความแม่นยำสูงสุดที่ประมาณ 98.67% สำหรับเมล็ดที่ดีและเมล็ดที่จับตัวเป็นก้อน และความแม่นยำต่ำสุดที่ประมาณ 93.33% สำหรับเมล็ดแตกและเมล็ดแบน อย่างไรก็ตาม การตรวจจับเมล็ดแตกและเมล็ดแบนยังมีความแม่นยำที่ไม่สูงเท่าที่ควร โดยเฉพาะเมล็ดแตกและเมล็ดแบน ผู้วิจัยได้แนะนำให้ปรับปรุงโดยการเพิ่มชุดข้อมูลของเมล็ดแตกและเมล็ดแบนเพิ่มขึ้นเพื่อปรับปรุงความแม่นยำของโมเดลได้ดียิ่งขึ้นในอนาคต สรุปได้ว่า การใช้โครงข่ายประสาทเทียม VGG-16 สามารถช่วยในการตรวจจับข้อบกพร่องของเมล็ดโกโก้ได้อย่างมีประสิทธิภาพและมีความแม่นยำสูงในการจำแนกประเภทต่างๆ ของเมล็ดโกโก้ บทความวิจัยถัดไป เสรีพงษ์ [6] ผู้วิจัยต้องการจำแนกคุณภาพเมล็ดกาแฟ โดยใช้การเรียนรู้เชิงลึกโดยโครงข่ายประสาทเทียมแบบคอนโวลูชัน เปรียบเทียบกับแบบจำลองที่ใช้การเรียนรู้ด้วยเครื่องแบบดั้งเดิม จากผลลัพธ์ที่ได้สรุปได้ว่าโมเดล ResNet50 และ ResNet101 ที่ใช้มีประสิทธิภาพในการจำแนกประเภทของเมล็ดกาแฟ ที่ดีกว่าแบบจำลองที่ใช้การเรียนรู้ด้วยเครื่องแบบดั้งเดิมที่ใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพ เนื่องจากการเรียนรู้ด้วยเครื่องแบบดั้งเดิม มีแนวโน้มที่จะเกิด Overfitting มากกว่า ในขณะที่โมเดลที่ใช้ ResNet50 หรือ ResNet101 ยังคงสามารถลด Overfitting ได้ดีกว่า โดยค่า Accuracy ที่ได้สูงถึง 95 % ซึ่งเป็นผลลัพธ์ที่น่าพอใจ

วิธีดำเนินการ


จำแนกตามจุดประสงค์ทั้งสอง มีทั้งหมด 4 ขั้นตอน ดังนี้

ขั้นตอนที่ 1 : แนะนำชุดข้อมูลที่ใช้ในการศึกษา

ชุดข้อมูลที่นำมาใช้ในการศึกษาเป็นชุดข้อมูลจากงานวิจัยเรื่อง การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพด้วยการประมวลผลภาพถ่าย (เดือนแจ่ม, 2020) โดยเป็นภาพที่ได้ผ่านกระบวนการลบแสงและเงาออกไปแล้ว ประกอบด้วยรูปภาพเมล็ดกาแฟจำนวน 5,840 ภาพ แบ่งออกเป็น 6 ประเภท ตามตารางที่ 1 และตัวอย่างรูปภาพเมล็ดกาแฟทั้ง 6 ประเภท ตามภาพที่ 1

ตารางที่ 1 จำนวนรูปภาพเมล็ดกาแฟ แบ่งตามประเภท

ลำดับที่	ประเภท	จำนวน (ภาพ)
1	เมล็ดดำ (Black bean)	1,003
2	เมล็ดขึ้นรา (Moldy bean)	1,082
3	เมล็ดแตก (Bean fragment)	631
4	เมล็ดไม่สมบูรณ์ (Incompletely formed bean)	1,121
5	เมล็ดถูกแมลงทำลาย (Insect-damaged bean)	700
6	เมล็ดปกติ (Green Bean)	1,303



ภาพที่ 1 ตัวอย่างรูปภาพเมล็ดกาแฟทั้ง 6 ประเภท

ขั้นตอนที่ 2 : การเตรียมข้อมูล

การเตรียมข้อมูลรูปภาพเพื่อนำไปสร้างแบบจำลองแบ่งได้เป็น 3 ขั้นตอน ดังนี้

1. การเสริมข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายให้กับชุดข้อมูล โดยการการพลิกภาพ (Flip) แบ่งเป็นสุมพลิกภาพแบบแนวนอน (Horizontal Flip) และสุมพลิกภาพแบบแนวตั้ง (Vertical Flip) โดยเพิ่มจำนวนจากเดิมประเภทละ 50 เปอร์เซ็นต์ ได้จำนวนทั้งหมด 8,770 ภาพ แบ่งออกเป็น 6 ประเภท ตามตารางที่ 2

ตารางที่ 2 จำนวนรูปภาพเมล็ดกาแฟหลังจากเพิ่มข้อมูล แบ่งตามประเภท

ลำดับที่	ประเภท	จำนวน (ภาพ)
1	เมล็ดดำ (Black bean)	1,503
2	เมล็ดขึ้นรา (Moldy bean)	1,623
3	เมล็ดแตก (Bean fragment)	947
4	เมล็ดไม่สมบูรณ์ (Incompletely formed bean)	1,682
5	เมล็ดถูกแมลงทำลาย (Insect-damaged bean)	1,060
6	เมล็ดปกติ (Green Bean)	1,955

2. การเติมรูปภาพ (Image Padding) เนื่องจากรูปภาพที่ได้มามีขนาดอัตราส่วนของภาพที่ไม่เท่ากันจึงจะดำเนินการเติมเส้นขอบให้รูปภาพเพื่อปรับขนาดรูปภาพให้ได้ขนาดที่เท่ากัน แต่ยังคงอัตราส่วนภาพต้นฉบับไว้ไม่เปลี่ยนแปลง

3. การแบ่งข้อมูล ข้อมูลรูปภาพที่ใช้ในจะถูกแบ่งออกเป็น 2 ส่วน คือ ข้อมูลสำหรับสร้างแบบจำลองการทำนาย และข้อมูลที่เก็บไว้สำหรับทดสอบแบบจำลองการทำนาย ในสัดส่วน 80/20 ในแต่ละประเภทเมล็ดกาแฟ

ขั้นตอนที่ 3 : การสร้างแบบจำลอง

การศึกษานี้ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) ในการสร้างแบบจำลอง ได้แก่ ResNet50, ResNet101 และ VGG-16 สร้างแบบจำลองทั้งหมด 6 แบบจำลอง ดังนี้

1. สถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง
2. สถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง
3. สถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง
4. สถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ
5. สถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ
6. สถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ

ในส่วนของแบบจำลองที่ 1,2 และ 3 แบ่งชั้นผลลัพธ์เป็น 2 คลาส คือ เมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง โดยปรับขนาดรูปภาพเป็น 224×224 พิกเซล มีชั้น Flatten เพื่อแปลงข้อมูลจากรูปภาพที่เป็นเมทริกซ์หลายมิติ เป็นเวกเตอร์เดียว เพื่อเตรียมข้อมูลส่งผ่านไปยังชั้น Dense ต่อไป นั่นคือชั้น Dense ที่มี 256 ยูนิต ในชั้นนี้มี Activation function เป็น ReLU (Rectified Linear Activation) มีการเพิ่มมีการเพิ่มชั้น Dropout เพื่อลดโอกาสของการ Overfitting โดยกำหนดค่าเป็น 0.5 ในชั้น

Dense สุดท้ายที่มี 1 ยูนิต มี Activation function เป็น Sigmoid เพื่อการทำนาย Binary classification เนื่องจากมีแค่ 2 คลาสที่ต้องการทำนาย กำหนด Learning rate เป็น 0.0001 รอบการฝึกสอนข้อมูลกำหนดไว้ที่ 30 รอบ และกำหนด Batch size ไว้เป็นจำนวน 32

ในส่วนของแบบจำลองที่ 4,5 และ 6 แบ่งชั้นผลลัพธ์เป็น 6 คลาส คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดแตก, เมล็ดไม่สมบูรณ์ เมล็ดถูกแมลงทำลาย และเมล็ดปกติ โดยปรับขนาดรูปภาพเป็น 224 x 224 พิกเซล มีชั้น Flatten เพื่อแปลงข้อมูลจากรูปภาพที่เป็นเมทริกซ์หลายมิติ เป็นเวกเตอร์เดียว เพื่อเตรียมข้อมูลส่งผ่านไปยังชั้น Dense ต่อไป นั่นคือชั้น Dense ที่มี 256 ยูนิตในชั้นนี้มี Activation function เป็น ReLU (Rectified Linear Activation) มีการเพิ่มมีการเพิ่มชั้น Dropout เพื่อลดโอกาสของการ Overfitting โดยกำหนดค่าเป็น 0.5 ในชั้น Dense สุดท้ายที่มี 6 ยูนิต มี Activation function เป็น Softmax เนื่องจากมีข้อมูลหลายคลาส กำหนด Learning rate เป็น 0.0001 รอบการฝึกสอนข้อมูลกำหนดไว้ที่ 30 รอบ และกำหนด Batch size ไว้เป็นจำนวน 64

ขั้นตอนที่ 4 : การวัดผลของแบบจำลอง

ในการศึกษานี้ ผู้วิจัยวัดผลของแบบจำลองทั้ง 6 แบบจำลอง โดยใช้ค่าประมาณ Precision, Recall, F1-Score และ Accuracy โดยมีการคำนวณค่า Weighted Average ของค่า Precision, Recall และ F1-Score ด้วย

ผลการวิจัยและอภิปรายผลการวิจัย

1. เปรียบเทียบประสิทธิภาพโมเดล โดยจำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความบกพร่อง

ผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรม ResNet50, ResNet101 และ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ด้วยค่าประมาณ Precision, Recall, F1-Score และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบ พบว่าแบบจำลอง VGG-16 ได้ค่า Accuracy สูงที่สุด คือ 0.96 รองลงมาคือ ResNet101 ได้ค่า Accuracy 0.94 และลำดับสุดท้ายคือ ResNet50 ได้ค่า Accuracy 0.88

แบบจำลอง VGG-16 ได้ค่า Precision, Recall, และ F1-score สูงที่สุดสำหรับการจำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความบกพร่อง เมื่อเปรียบเทียบกับ ResNet50 และ ResNet101 ดังนั้นแบบจำลอง VGG-16 อาจเหมาะสำหรับงานที่ต้องการความแม่นยำและประสิทธิภาพในการจำแนกประเภทข้อมูลเมล็ดกาแฟทั้งสองประเภท

ตารางที่ 3 คะแนนการวัดผลจากแบบจำลองของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ด้วยชุดข้อมูลทดสอบ

	precision	recall	f1-score	accuracy
เมล็ดกาแฟปกติ	1.00	0.75	0.85	
เมล็ดกาแฟที่มีความบกพร่อง	0.80	1.00	0.89	
				0.88
weighted avg	0.90	0.88	0.87	

ตารางที่ 4 คะแนนการวัดผลจากแบบจำลองของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ด้วยชุดข้อมูลทดสอบ

	precision	recall	f1-score	accuracy
เมล็ดกาแฟปกติ	1.00	0.87	0.93	
เมล็ดกาแฟที่มีความบกพร่อง	0.89	1.00	0.94	
				0.94
weighted avg	0.94	0.94	0.94	

ตารางที่ 5 คะแนนการวัดผลจากแบบจำลองของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ด้วยชุดข้อมูลทดสอบ

	precision	recall	f1-score	accuracy
เมล็ดกาแฟปกติ	0.99	0.92	0.95	
เมล็ดกาแฟที่มีความบกพร่อง	0.92	0.99	0.96	
				0.96
weighted avg	0.96	0.96	0.95	

2. เปรียบเทียบประสิทธิภาพโมเดล โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ

ผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรม ResNet50, ResNet101 และ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ ด้วยค่าประมาณ Precision, Recall, F1-Score และ Accuracy ที่วัดผลจากชุดข้อมูลทดสอบ พบว่าแบบจำลอง ResNet50 ได้ค่า Accuracy สูงที่สุด คือ 0.97 รองลงมาคือ ResNet101 ได้ค่า Accuracy 0.96 และลำดับสุดท้ายคือ VGG-16 ได้ค่า Accuracy 0.95

สำหรับการจำแนกประเภท เมล็ดดำ และเมล็ดปกติ ทั้ง 3 แบบจำลอง ได้ค่า Precision, Recall, และ F1-score สูง เมื่อเปรียบเทียบกับเมล็ดกาแฟประเภทอื่น ๆ

สำหรับแบบจำลอง VGG-16 ได้ค่า Precision, Recall, และ F1-score ที่ต่ำกว่าสองแบบจำลองเมื่อใช้จำแนกประเภท เมล็ดแตก, เมล็ดขึ้นรา และ เมล็ดไม่สมบูรณ์

ดังนั้นแบบจำลอง ResNet50 อาจเป็นตัวเลือกที่ดีที่สุดสำหรับการจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ เนื่องจากมีค่า Accuracy สูงสุดและค่า Precision, Recall, และ F1-score ที่ดีสำหรับการจำแนกประเภททั้งหมด

ตารางที่ 6 คะแนนการวัดผลจากแบบจำลองของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ ด้วยชุดข้อมูลทดสอบ

	precision	recall	f1-score	accuracy
เมล็ดดำ	1.00	0.99	0.99	
เมล็ดขึ้นรา	0.92	0.98	0.95	
เมล็ดแตก	0.95	0.95	0.95	
เมล็ดไม่สมบูรณ์	0.97	0.94	0.95	
เมล็ดถูกแมลงทำลาย	0.96	0.96	0.96	
เมล็ดปกติ	0.99	0.97	0.98	
				0.97
weighted avg	0.97	0.97	0.97	

ตารางที่ 7 คะแนนการวัดผลจากแบบจำลองของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ ด้วยชุดข้อมูลทดสอบ

	precision	recall	f1-score	accuracy
เมล็ดดำ	1.00	0.99	0.99	
เมล็ดขี้นรา	0.93	0.98	0.95	
เมล็ดแตก	0.94	0.93	0.93	
เมล็ดไม่สมบูรณ์	0.97	0.95	0.96	
เมล็ดถูกแมลงทำลาย	0.96	0.94	0.95	
เมล็ดปกติ	0.97	0.97	0.97	
				0.96
weighted avg	0.96	0.96	0.96	

ตารางที่ 8 คะแนนการวัดผลจากแบบจำลองของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ ด้วยชุดข้อมูลทดสอบ

	precision	recall	f1-score	accuracy
เมล็ดดำ	0.99	0.96	0.97	
เมล็ดขี้นรา	0.94	0.94	0.94	
เมล็ดแตก	0.89	0.93	0.91	
เมล็ดไม่สมบูรณ์	0.93	0.95	0.94	
เมล็ดถูกแมลงทำลาย	0.95	0.94	0.95	
เมล็ดปกติ	0.96	0.94	0.95	
				0.95
weighted avg	0.95	0.95	0.95	

สรุปผลการวิจัย

จากผลลัพธ์ของค่าประมาณ Precision, Recall, F1-score และ Accuracy ของแบบจำลองโดยใช้โดยใช้สถาปัตยกรรม ResNet50, ResNet101 และ VGG-16 ในการศึกษา โดยแบ่งเป็น 1) เพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีข้อบกพร่องออกจากกัน พบว่าโมเดล VGG-16 ได้ค่าความแม่นยำของโมเดลสูงที่สุด คือ 0.96 และมีความสามารถในการจำแนกประเภทเมล็ดกาแฟที่มีข้อบกพร่องได้ดี ซึ่งอาจมีประโยชน์ในการช่วยจำแนก ตรวจสอบความผิดปกติของเมล็ดกาแฟอย่างมีประสิทธิภาพ และควบคุมคุณภาพของเมล็ดกาแฟได้ดี 2) เพื่อจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดแตก, เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดปกติ พบว่า ResNet50 ได้ค่าความแม่นยำสูงที่สุด คือ 0.97 และสังเกตได้ว่าค่า Precision, Recall, และ F1-score ประเภทเมล็ดดำ และเมล็ดปกติ ของทั้ง 3 โมเดลสูง เมื่อเปรียบเทียบกับเมล็ดกาแฟประเภทอื่น ๆ ผู้วิจัยคาดว่าอาจเพราะคุณลักษณะของรูปภาพที่นำมาใช้สร้างแบบจำลอง มีคุณลักษณะที่โดดเด่นสามารถจำแนกได้ง่าย คือ เมล็ดสีดำจะมีพื้นที่สีดำในเมล็ดที่ค่อนข้างเยอะกว่าประเภทอื่นๆ และเมล็ดปกติจะเป็นเมล็ดที่มีความสมบูรณ์ ไม่มีตำหนิแบบประเภทอื่น ทำให้ผลการจำแนกออกมาดี ในส่วนของประเภทอื่นๆ ผู้วิจัยคาดว่าคุณลักษณะของรูปอาจมีความคล้ายคลึงกันอยู่บ้าง เช่น เมล็ดแตกกับเมล็ดถูกแมลงทำลาย เนื่องจากบางส่วนของเมล็ดที่ไว้แห้งหายไป จึงทำให้เกิดการจำแนกผิดพลาดประเภท ผลลัพธ์นี้เชื่อมั่นได้ว่าโมเดล ResNet50 เหมาะสมที่สุดสำหรับการจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ โดยจะสามารถช่วยในการควบคุมคุณภาพของเมล็ดกาแฟได้อย่างมีประสิทธิภาพ

กิตติกรรมประกาศ

การจัดทำวิจัยครั้งนี้สำเร็จผลโดยได้รับการสนับสนุนจาก ผศ.ดร.นุรีย์ วิวัฒน์วัฒนา อาจารย์ที่ปรึกษาที่ให้คำแนะนำและช่วยเหลือในหลาย ๆ ด้าน

ขอขอบคุณ ประธาน คณะกรรมการการสอบสารนิพนธ์และอาจารย์ทุกท่านที่ให้คำแนะนำในการแก้ไขปัญหาและชี้แนะแนวทางในการทำวิจัย

ขอขอบคุณ น.ส. แสงดาว เตือนแจ่ม สำหรับชุดข้อมูลที่ได้นำมาใช้ในงานวิจัยครั้งนี้ จากงานวิจัยที่ได้ทำไว้ก่อนหน้านี้

ขอขอบคุณ บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการสนับสนุนการนำเสนอผลงานวิจัย

เอกสารอ้างอิง

- [1] กระทรวงเกษตรและสหกรณ์, ส. (2018). กำหนดมาตรฐานสินค้าเกษตร มกษ. 5701-2561
https://www.acfs.go.th/standard/download/Arabica_coffee_bean_2561.pdf
- [2] C. Pinto, J. Furukawa, H. Fukai and S. Tamura, Classification of Green coffee bean images based on defect types using convolutional neural network (CNN); 2017: IEEE.
- [3] N. -F. Huang, D. -L. Chou and C. -A. Lee, Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network; 2019: IEEE.
- [4] A. Febriana, K. Muchtar, R. Dawood and C. -Y. Lin, USK-COFFEE Dataset: A Multi-Class Green Arabica Coffee Bean Dataset for Deep Learning; 2022: IEEE
- [5] C. C. Hortinela and K. J. R. Tupas, Classification of Cacao Beans Based on their External Physical Features Using Convolutional Neural Network; 2022: IEEE
- [6] C. Sereepong, Coffee Bean Quality Classification using Convolutional Neural Network; 2021