



โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟ
CONVOLUTIONAL NEURAL NETWORKS FOR COFFEE BEAN DEFECT
CLASSIFICATION



เพ็ญนภา ภูโคกหวาย

โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟ



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

CONVOLUTIONAL NEURAL NETWORKS FOR COFFEE BEAN DEFECT
CLASSIFICATION



PENNAPA PHUKHOKWAI

A Master's Project Submitted in Partial Fulfillment of the Requirements
for the Degree of MASTER OF SCIENCE
(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟ

ของ

เพ็ญนภา ภูโคกหวาย

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... ที่ปรึกษาหลัก
(ผู้ช่วยศาสตราจารย์ ดร.นุรีย์ วิวัฒน์วัฒนา)

..... ประธาน
(ผู้ช่วยศาสตราจารย์ ดร.อัครินทร์ ไพญูลย์พานิช)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.นภา แซ่เป้)

ชื่อเรื่อง	โครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟ
ผู้วิจัย	เพ็ญนภา ภูโคกหวาย
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. นุรีย์ วิวัฒน์วัฒนา

ข้อบกพร่องต่าง ๆ ที่เกิดขึ้นกับเมล็ดกาแฟ ส่งผลต่อรสชาติของกาแฟ ดังนั้นเมล็ดกาแฟที่จะนำไปคั่วต้องมีคุณภาพที่ดีตามมาตรฐาน งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองที่ใช้การเรียนรู้เชิงลึกโดยโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยประกอบไปด้วยความมุ่งหมาย คือ 1) เพื่อจำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีข้อบกพร่องออกจากกันได้ 2) เพื่อจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดแตก, เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดปกติได้ 3) เพื่อประเมินผลแบบจำลอง โดยเปรียบเทียบกับแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 โดยใช้เทคนิคการเสริมข้อมูลด้วยชุดข้อมูลเดียวกัน โดยชุดข้อมูลรูปภาพเมล็ดกาแฟได้จากงานวิจัยเรื่อง การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพด้วยการประมวลผลภาพถ่าย โดยมีการใช้เทคนิคการเพิ่มข้อมูลรูปภาพ และการเติมพื้นหลังรูปภาพ เพื่อนำมาสร้างแบบจำลองต่างๆ ได้แก่ ResNet50, ResNet101 และ VGG-16 ค่าความแม่นยำ (Accuracy) ที่ได้จากการศึกษาเพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีข้อบกพร่อง คือ 0.91, 0.89 และ 0.94 พบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ VGG-16 ให้ผลลัพธ์ที่ดีที่สุด และในส่วนของ การจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟออกจากเมล็ดปกติ ได้ค่าความแม่นยำ คือ 0.97, 0.96 และ 0.95 พบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 ให้ผลลัพธ์ที่ดีที่สุด ซึ่งให้ผลลัพธ์ที่ดีกว่าสถาปัตยกรรมแบบ ResNet50 ที่ใช้เทคนิคการเสริมข้อมูลเพียงอย่างเดียว

คำสำคัญ : การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การจำแนกประเภทความบกพร่องของเมล็ดกาแฟ

Title	CONVOLUTIONAL NEURAL NETWORKS FOR COFFEE BEAN DEFECT CLASSIFICATION
Author	PENNAPA PHUKHOKWAI
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Assistant Professor Dr. Nuwee Wiwatwattana

The various defects that occur in coffee beans will affect the taste of the coffee. Therefore, coffee beans for roasting must be of good quality according to standards. The objective of this research is to develop models that use the convolutional neural networks of deep learning. It consisted of three objectives: (1) to classify between green bean and defective coffee beans; (2) to classify defects in coffee beans, divided into five categories: black beans, moldy beans, bean fragments, incompletely formed beans, and insect-damaged beans out of green beans; (3) in order to evaluate the model results, the models were compared by ResNet50 architecture using data augmentation techniques with the same dataset. 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. The built models were ResNet50, ResNet101, and VGG-16. The accuracy values obtained from this study to classify between green beans and defective coffee beans were 0.91, 0.89, and 0.94, this model used VGG-16 architecture was found to have the best results. The accuracy values obtained from this study to classify defects in coffee beans into five 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 and give better results than the ResNet50 architecture using only data augmentation techniques.

Keyword : Deep learning, Convolutional neural networks, Coffee bean defect classification

กิตติกรรมประกาศ

การจัดทำสารนิพนธ์เล่มนี้สำเร็จลุล่วงไปได้ด้วยดี จากการสนับสนุน ให้ความรู้ ความช่วยเหลือ ให้คำแนะนำพร้อมทั้งชี้แนะแนวทางในการทำวิจัยและข้อบกพร่องต่าง ๆ ของผู้ช่วยศาสตราจารย์ ดร. นุรีย์ วิวัฒน์วัฒนา อาจารย์ที่ปรึกษา ผู้วิจัยขอกราบขอบพระคุณด้วยความเคารพอย่างสูงไว้ ณ ที่นี้

ขอขอบคุณ ประธาน คณะกรรมการการสอบสารนิพนธ์ทุกท่านที่ให้ความอนุเคราะห์เป็นกรรมการสอบ และให้คำแนะนำเพื่อปรับปรุงและชี้แนะแนวทางในงานวิจัยจนสำเร็จเป็นสารนิพนธ์นี้

ขอขอบคุณ นางสาว แสงดาว เตือนแจ่ม สำหรับชุดข้อมูลที่ได้นำมาใช้ในงานวิจัยครั้งนี้

ขอขอบคุณ บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ ในการสนับสนุนการนำเสนอผลงานวิจัย

เพ็ญภา ภูโคกหวาย

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1	1
บทนำ.....	1
1.1 ที่มาและความสำคัญของการวิจัย	1
1.2 วัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตของการวิจัย	3
1.4 ประโยชน์ที่คาดว่าจะได้รับจากการวิจัย	4
บทที่ 2	5
วรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....	5
2.1 นิยามข้อบกพร่องของเมล็ดกาแฟอาราบิกา	5
2.2 การเสริมข้อมูล (Data Augmentation).....	8
2.3 การเติมรูปภาพ (Image Padding)	9
2.4 การเรียนรู้ด้วยเครื่อง (Machine Learning)	10
2.5 การเรียนรู้เชิงลึก (Deep Learning).....	11
2.6 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network)	12
2.7 การถ่ายทอดการเรียนรู้ (Transfer Learning)	14

2.7.1 สถาปัตยกรรม ResNet.....	14
2.7.2 สถาปัตยกรรม VGG-16	16
2.8 การประเมินผลแบบจำลอง (Model Evaluation).....	16
2.8.1 Confusion Matrix.....	16
2.9 งานวิจัยที่เกี่ยวข้อง (Literature Review).....	19
2.9.1 บทความวิจัยเรื่อง Classification of Green coffee bean images based on defect types using convolutional neural network (CNN)	19
2.9.2 บทความวิจัยเรื่อง Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network.....	22
2.9.3 บทความเรื่อง USK-COFFEE Dataset: A Multi-Class Green Arabica Coffee Bean Dataset for Deep Learning	24
2.9.4 บทความวิจัยเรื่อง Classification of Cacao Beans Based on their External Physical Features Using Convolutional Neural Network	26
2.9.5 บทความวิจัยเรื่อง Coffee Bean Quality Classification Using Convolutional Neural Network.....	28
บทที่ 3.....	30
การดำเนินการวิจัย	30
3.1 การออกแบบขั้นตอนในการดำเนินงานวิจัย.....	30
3.2 การสำรวจข้อมูลเบื้องต้น.....	31
3.3 การเตรียมข้อมูล	35
3.4 การสร้างแบบจำลอง	38
3.5 การประเมินผลประสิทธิภาพของแบบจำลอง	39
บทที่ 4.....	40
ผลการดำเนินงานวิจัย	40

4.1 สถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความ บกพร่อง	41
4.2 สถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความ บกพร่อง	44
4.3 สถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความ บกพร่อง	47
4.4 สถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	50
4.5 สถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	54
4.6 สถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	58
4.7 เปรียบเทียบประสิทธิภาพแบบจำลอง โดยจำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความ บกพร่อง	62
4.8 เปรียบเทียบประสิทธิภาพแบบจำลอง โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ	62
บทที่ 5	63
สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	63
5.1 สรุปผลการวิจัย	63
5.2 อภิปรายผล	65
5.3 ข้อเสนอแนะ	68
บรรณานุกรม	69
ประวัติผู้เขียน	72

สารบัญตาราง

	หน้า
ตาราง 1 คู่ของการแบ่งข้อมูลและจำนวนของข้อมูล	21
ตาราง 2 จำนวนข้อมูลทดสอบและความแม่นยำในการจำแนกประเภท.....	21
ตาราง 3 รายละเอียดของชุดข้อมูล USK-Coffee.....	25
ตาราง 4 ประสิทธิภาพของแบบจำลอง	28
ตาราง 5 ค่า Accuracy และ Weight Average ของแบบจำลอง.....	29
ตาราง 6 จำนวนรูปภาพเมล็ดกาแฟ แบ่งตามประเภท.....	31
ตาราง 7 จำนวนรูปภาพเมล็ดกาแฟหลังจากใช้เทคนิคการเสริมข้อมูล แบ่งตามประเภท.....	36
ตาราง 8 จำนวนรูปภาพเมล็ดกาแฟหลังจากแบ่งข้อมูล สำหรับสร้างแบบจำลอง และทดสอบแบบจำลอง.....	37
ตาราง 9 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	42
ตาราง 10 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	43
ตาราง 11 Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	45
ตาราง 12 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	46
ตาราง 13 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของสถาปัตยกรรมแบบ VGG16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง.....	48
ตาราง 14 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	49

ตาราง 15 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ สถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออก จากเมล็ดปกติ.....	51
ตาราง 16 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ....	52
ตาราง 17 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ สถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	55
ตาราง 18 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ..	56
ตาราง 19 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ สถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออก จากเมล็ดปกติ.....	59
ตาราง 20 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ VGG- 16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ.....	60
ตาราง 21 ค่า Accuracy และ Weight Average ของแบบจำลองที่จำแนกเมล็ดกาแฟปกติ และ เมล็ดกาแฟที่มีความบกพร่อง.....	64
ตาราง 22 Accuracy และ Weight Average ของแบบจำลองที่จำแนกประเภทความบกพร่องของ เมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ	64

สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 ตัวอย่างเมล็ดกาแฟแต่ละประเภท	1
ภาพประกอบ 2 ตัวอย่างเมล็ดกาแฟปกติ	6
ภาพประกอบ 3 ตัวอย่างเมล็ดดำ	6
ภาพประกอบ 4 ตัวอย่างเมล็ดขึ้นรา	6
ภาพประกอบ 5 ตัวอย่างขึ้นเมล็ดแตก	7
ภาพประกอบ 6 ตัวอย่างเมล็ดไม่สมบูรณ์	7
ภาพประกอบ 7 ตัวอย่างเมล็ดถูกแมลงทำลาย	7
ภาพประกอบ 8 ตัวอย่างผลกาแฟแห้ง	8
ภาพประกอบ 9 ตัวอย่างสิ่งแปลกปลอม	8
ภาพประกอบ 10 ตัวอย่างการเสริมข้อมูลแบบต่าง ๆ	9
ภาพประกอบ 11 ตัวอย่างการเติมรูปภาพ	9
ภาพประกอบ 12 ความสัมพันธ์ของ ปัญญาประดิษฐ์, การเรียนรู้ด้วยเครื่อง และการเรียนรู้เชิงลึก	10
ภาพประกอบ 13 กระบวนการของการเรียนรู้เชิงลึก	11
ภาพประกอบ 14 การเรียนรู้เชิงลึก	11
ภาพประกอบ 15 สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน	13
ภาพประกอบ 16 การเชื่อมโยงสมบูรณ์	14
ภาพประกอบ 17 Residual Block	15
ภาพประกอบ 18 สถาปัตยกรรม ResNet50 และ ResNet101	15
ภาพประกอบ 19 สถาปัตยกรรม VGG-16	16
ภาพประกอบ 20 ตาราง Confusion Matrix	17

ภาพประกอบ 21 สภาพแวดล้อมการถ่ายภาพที่มองจากด้านข้าง	19
ภาพประกอบ 22 ตัวอย่างความบกพร่องของเมล็ดกาแฟประเภทต่าง ๆ	20
ภาพประกอบ 23 ขั้นตอนการเตรียมข้อมูลเพื่อนำไปประมวลผล	23
ภาพประกอบ 24 แสดงค่าประสิทธิภาพความแม่นยำ ค่า Loss และค่าวัดความสามารถของ แบบจำลอง	23
ภาพประกอบ 25 เมล็ดกาแฟอาราบิก้าประเภทต่าง ๆ	24
ภาพประกอบ 26 กราฟเปรียบเทียบค่าความแม่นยำ และค่าการสูญเสีย ของข้อมูลการฝึกสอน ..	26
ภาพประกอบ 27 กราฟเปรียบเทียบค่าความแม่นยำ และค่าการสูญเสีย ของข้อมูลการตรวจสอบ	26
ภาพประกอบ 28 กรอบแนวคิดงานวิจัย	27
ภาพประกอบ 29 ขั้นตอนในการดำเนินงานวิจัย	30
ภาพประกอบ 30 ตัวอย่างรูปภาพเมล็ดกาแฟดำ	32
ภาพประกอบ 31 ตัวอย่างรูปภาพเมล็ดขึ้นรา	32
ภาพประกอบ 32 ตัวอย่างรูปภาพเมล็ดแตก	33
ภาพประกอบ 33 ตัวอย่างรูปภาพเมล็ดไม่สมบูรณ์	33
ภาพประกอบ 34 ตัวอย่างรูปภาพเมล็ดถูกแมลงทำลาย	34
ภาพประกอบ 35 ตัวอย่างรูปภาพเมล็ดปกติ	34
ภาพประกอบ 36 สัดส่วนข้อมูลรูปภาพเมล็ดกาแฟทั้ง 6 ประเภท.....	35
ภาพประกอบ 37 ตัวอย่างรูปภาพก่อน - หลังทำการเสริมข้อมูล.....	36
ภาพประกอบ 38 ตัวอย่างรูปภาพก่อน - หลังทำการเติมรูปภาพ	37
ภาพประกอบ 39 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรม แบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	41
ภาพประกอบ 40 Confusion Matrix ของของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ด กาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	43

ภาพประกอบ 41 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	44
ภาพประกอบ 42 Confusion Matrix ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	46
ภาพประกอบ 43 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	47
ภาพประกอบ 44 Confusion Matrix ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง	49
ภาพประกอบ 45 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	50
ภาพประกอบ 46 Confusion Matrix ของของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ.....	53
ภาพประกอบ 47 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	54
ภาพประกอบ 48 Confusion Matrix ของของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ.....	57
ภาพประกอบ 49 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ	58
ภาพประกอบ 50 Confusion Matrix ของของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ.....	61
ภาพประกอบ 51 ตัวอย่างรูปภาพเมล็ดกาแฟปกติ ที่ถูกทำนายผิดเป็นเมล็ดกาแฟที่มีความบกพร่อง	66
ภาพประกอบ 52 ตัวอย่างรูปภาพเมล็ดขึ้นรา ที่ถูกทำนายผิดเป็นเมล็ดไม่สมบูรณ์.....	66

ภาพประกอบ 53 ตัวอย่างรูปภาพเมล์ดแตก ที่ถูกทำนายผิดเป็นเมล์ดถูกแมลงทำลาย 67

ภาพประกอบ 54 ตัวอย่างรูปภาพเมล์ดไม่สมบูรณ์ ที่ถูกทำนายผิดเป็นเมล์ดขึ้นรา 67



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของการวิจัย

กาแฟเป็นเครื่องดื่มที่เป็นที่ชื่นชอบของทั้งคนไทยและทั่วโลก ซึ่งก่อนที่จะได้กาแฟมีรสชาติดี ได้คุณภาพ ปัจจัยข้อสำคัญที่จะส่งผลกระทบต่อรสชาติของกาแฟ คือสายพันธุ์ของกาแฟ พื้นที่ในการเพาะปลูก และเมล็ดกาแฟที่จะนำไปคั่วนั้นต้องมีคุณภาพที่ดี และผ่านการคัดแยกเมล็ดแล้วเรียบร้อย การคัดแยกเมล็ดกาแฟที่มีความบกพร่อง สามารถอ้างอิงได้ตามประกาศกระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดมาตรฐานสินค้าเกษตร : เมล็ดกาแฟอะราบิกา ตามพระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551 มาตรฐานเลขที่ มกษ. 5701-2561 (พระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551, 2562) ซึ่งแบ่งได้เป็น 8 ประเภท คือ เมล็ดดำ (Black Bean), เมล็ดขึ้นรา (Moldy Bean), ชิ้นเมล็ดแตก (Bean Fragment), เมล็ดไม่สมบูรณ์ (Incompletely Formed Bean), เมล็ดถูกแมลงทำลาย (Insect-Damaged Bean), ผลกาแฟแห้ง (Dried Cherry), สิ่งแปลกปลอม (Foreign Matter) และข้อบกพร่องรวม



เมล็ดกาแฟปกติ



เมล็ดดำ



เมล็ดขึ้นรา



ชิ้นเมล็ดแตก



เมล็ดไม่สมบูรณ์



เมล็ดถูกแมลงทำลาย



ผลกาแฟแห้ง



สิ่งแปลกปลอม

ภาพประกอบ 1 ตัวอย่างเมล็ดกาแฟแต่ละประเภท

ที่มา: (พระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551, 2562)

ปัจจุบันการคัดแยกเมล็ดกาแฟจะใช้วิธีการคัดเมล็ดด้วยเครื่องคัดแยก และมักจะใช้วิธีการคัดแยกด้วยมือโดยแรงงานคนอีกครั้งหนึ่งเพื่อให้ได้เมล็ดกาแฟที่มีคุณภาพดี ซึ่งการคัดแยกด้วยมืออาจใช้ระยะเวลาและไม่แม่นยำเท่าที่ควร เนื่องจากอาศัยประสบการณ์ของแรงงานคนนั้น ๆ ผู้วิจัยเห็นถึงปัญหาของกระบวนการข้างต้น และสนใจที่จะนำองค์ความรู้ที่เกี่ยวกับการเรียนรู้เชิงลึก มาเพื่อใช้จำแนกความบกพร่องของเมล็ดกาแฟ เนื่องจากเป็นองค์ความรู้ที่สามารถวิเคราะห์ข้อมูลได้อย่างมีประสิทธิภาพ เช่น การจำแนกภาพ (Image Classification), การทำนายข้อมูล (Predictive Analytics) และการแปลภาษา (Natural Language Processing) เป็นต้น และยังสามารถประมวลผลข้อมูลที่มีความซับซ้อน และมีจำนวนมากได้ดี ผู้วิจัยจึงจัดทำแบบจำลองการทำนายเพื่อคัดแยกเมล็ดกาแฟแบบอัตโนมัติโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยนำมาจำแนกประเภทเมล็ดกาแฟ 2 รูปแบบ คือ 1) จำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความบกพร่อง 2) จำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ได้แก่ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดไม่สมบูรณ์, เมล็ดแตก และเมล็ดถูกแมลงทำลาย นอกจากนี้เมล็ดกาแฟปกติ โดยภายในงานวิจัยได้นำเสนอการเตรียมข้อมูลเพื่อนำไปสร้างแบบจำลองด้วยการเสริมข้อมูลและการเติมรูปภาพ เพื่อให้แบบจำลองมีประสิทธิภาพในการทำนายข้อมูลมากขึ้น และมีการนำสถาปัตยกรรมแบบ ResNet50, ResNet101 และ VGG-16 มาสร้างแบบจำลองเปรียบเทียบประสิทธิภาพกัน เพื่อนำแบบจำลองที่ประสิทธิภาพดีที่สุดไปใช้ประโยชน์ในการจำแนกเมล็ดกาแฟ

1.2 วัตถุประสงค์ของการวิจัย

ในการทดลองวิจัยครั้งนี้ได้ทำการตั้งความมุ่งหมายไว้ ดังนี้

1. เพื่อสร้างและพัฒนาแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) ที่สามารถจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่องออกจากกันได้
2. เพื่อสร้างและพัฒนาแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) ที่สามารถจำแนกประเภทความบกพร่องของเมล็ดกาแฟ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ (Black Bean), เมล็ดขึ้นรา (Moldy Bean), เมล็ดแตก (Bean Fragment), เมล็ดไม่สมบูรณ์ (Incompletely Formed Bean) และเมล็ดถูกแมลงทำลาย (Insect-Damaged Bean) ออกจากเมล็ดปกติ (Green Bean) ได้อย่างแม่นยำ
3. การประเมินผลแบบจำลองที่ได้ โดยเปรียบเทียบกับงานวิจัยที่เคยทำมาแล้วด้วยชุดข้อมูลเดียวกัน

1.3 ขอบเขตของการวิจัย

งานวิจัยนี้ได้นำชุดข้อมูลจากงานวิจัยเรื่อง “การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพด้วยการประมวลผลภาพถ่าย” (แสงดาว เตือนแจ่ม, 2021) มาใช้ โดยเป็นภาพที่ได้ผ่านกระบวนการลบแสงและเงาออกไปแล้ว และแบ่งประเภทรูปภาพเมล็ดกาแฟเป็น 6 ประเภท คือ เมล็ดกาแฟปกติ (Green Bean), เมล็ดดำ (Black Bean), เมล็ดขึ้นรา (Moldy Bean), เมล็ดไม่สมบูรณ์ (Incompletely Formed Bean), ชิ้นเมล็ดแตก (Bean Fragment) และเมล็ดถูกแมลงทำลาย (Insect-Damaged Bean) นำมาสร้างแบบจำลองโดยใช้การเรียนรู้แบบเครื่องแบบดั้งเดิม

นอกจากนี้ในชุดข้อมูลเดียวกันได้ถูกนำไปวิจัยเรื่อง “การจำแนกคุณภาพของเมล็ดกาแฟโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ” (ชาคริต เสรีพงษ์, 2561) โดยใช้วิธีการจำแนกคุณภาพของเมล็ดกาแฟแบบปกติ และเมล็ดกาแฟจาก 5 นิยามความบกพร่อง นำมาสร้างแบบจำลองโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน ผู้วิจัยใช้สถาปัตยกรรมแบบ ResNet50, ResNet101 และSGDClassifier โดยใช้เทคนิคการเพิ่มข้อมูลรูปภาพ ผลการศึกษาพบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพได้ผลลัพธ์ที่ดีที่สุด ได้ค่า Accuracy เท่ากับ 0.77 และเมื่อพิจารณาค่า Precision, Recall และ F1-Score ของข้อมูลประเภท ชิ้นเมล็ดแตกและเมล็ดไม่สมบูรณ์ ที่ได้จากชุดข้อมูลทดสอบ ได้ค่าน้อยเมื่อเทียบกับเมล็ดกาแฟประเภทอื่น ๆ เนื่องจากจำนวนข้อมูลที่ใช้นั้นยังน้อย

ผู้วิจัยมีความสนใจที่จะนำข้อมูลชุดเดียวกันมาใช้ศึกษาเพื่อจำแนกความบกพร่องของเมล็ดกาแฟโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน ใช้เทคนิคการเสริมข้อมูลให้ได้รูปภาพจำนวนที่มากพอให้แบบจำลองสามารถทำงานได้ดีขึ้น และใช้เทคนิคเติมรูปภาพปรับขนาดของรูปภาพ เพื่อให้รูปภาพมีขนาดเท่ากันแต่ยังคงอัตราส่วนของรูปภาพต้นฉบับไว้ไม่เปลี่ยนแปลง โดยนำมาจำแนกประเภทเมล็ดกาแฟ 2 รูปแบบ คือ 1) จำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความบกพร่อง 2) จำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ได้แก่ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดไม่สมบูรณ์, เมล็ดแตก และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดกาแฟปกติ ผู้วิจัยได้นำแบบจำลองที่ถูกฝึกฝนมาแล้ว (Pre-Trained Model) มาใช้สร้างแบบจำลอง โดยใช้สถาปัตยกรรมแบบ ResNet50, ResNet101 และ VGG-16 เพื่อเปรียบเทียบประสิทธิภาพกัน และวัดผลของแบบจำลองการทำนายโดยใช้ค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score เป็นตัววัดประสิทธิภาพ

1.4 ประโยชน์ที่คาดว่าจะได้รับการวิจัย

ในการทดลองวิจัยครั้งนี้ คาดว่าผลที่ได้จากการวิจัยจะสามารถนำไปเป็นประโยชน์ได้ ดังนี้

1. แบบจำลองที่สร้างช่วยลดเวลาและค่าใช้จ่ายในการคัดแยกความบกพร่องของเมล็ดกาแฟ
2. แบบจำลองที่สร้างสามารถตรวจสอบและคัดแยกความบกพร่องของเมล็ดกาแฟตามลักษณะและความเสียหายได้อย่างถูกต้องแม่นยำ และมีความน่าเชื่อถือ
3. สามารถนำแบบจำลอง หรือองค์ความรู้ต่าง ๆ จากงานวิจัยนี้ไปประยุกต์ใช้ได้กับงานวิจัยอื่น ๆ ได้ เช่น การคัดแยกเมล็ดข้าว, การคัดแยกเมล็ดถั่วชนิดต่าง ๆ และการคัดแยกเมล็ดพันธุ์พืช เป็นต้น



บทที่ 2

วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะการกล่าวถึงองค์ความรู้ บทความ และงานวิจัยต่าง ๆ ที่ได้ศึกษาและมีความเกี่ยวข้องกับการดำเนินการวิจัย

2.1 นิยามข้อบกพร่องของเมล็ดกาแฟอาราบิก้า

ข้อบกพร่องของเมล็ดกาแฟอาราบิก้า อ้างอิงตามประกาศกระทรวงเกษตรและสหกรณ์ เรื่อง กำหนดมาตรฐานสินค้าเกษตร : เมล็ดกาแฟอาราบิก้า ตามพระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551 มาตรฐานเลขที่ มกษ. 5701-2561 (พระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551, 2562) จำแนกออกเป็น

1. เมล็ดดำ (Black Bean) คือ เมล็ดกาแฟที่มีสีดำทั้งภายในและภายนอกเมล็ดมากกว่าครึ่งหนึ่งของเมล็ด
2. เมล็ดขึ้นรา (Moldy Bean) คือ เมล็ดกาแฟที่ถูกเชื้อราเข้าทำลาย
3. ชิ้นเมล็ดแตก (Bean Fragment) คือ เมล็ดกาแฟที่แตกออกเป็นชิ้น ๆ เล็กกว่าครึ่งหนึ่งของกาแฟเต็มเมล็ด
4. เมล็ดไม่สมบูรณ์ (Incompletely Formed Bean) คือ เมล็ดกาแฟที่มีลักษณะเหยี่ยว ย่น ลีบ เบา รวมทั้งเมล็ดอ่อน (Immature Bean) ที่ได้จากผลกาแฟที่เก็บเกี่ยวในช่วงที่สุกไม่เต็มที่ซึ่งมีลักษณะของเมล็ดไม่สมบูรณ์ด้วย
5. เมล็ดถูกแมลงทำลาย (Insect-Damaged Bean) คือ เมล็ดกาแฟที่ถูกมอด กัดแทะ หรือเจาะจนเกิดเป็นรูมากกว่า 1 รู
6. ผลกาแฟแห้ง (Dried Cherry) คือ ผลกาแฟที่ผ่านกรรมวิธีการทำให้แห้งจนได้ผลกาแฟแห้งที่ยังไม่ได้สีเปลือกออก รวมทั้งเมล็ดกาแฟที่มีเปลือกติดบางส่วน
7. สิ่งแปลกปลอม (Foreign Matter) คือ สิ่งแปลกปลอมอื่น ๆ ที่ไม่ใช่เมล็ดกาแฟ เช่น เศษหิน ดิน เศษไม้ ส่วนของเปลือกและกะลา
8. ข้อบกพร่องรวม คือ ข้อบกพร่องตั้งแต่ข้อ 1 – 7 ข้างต้น



ภาพประกอบ 2 ตัวอย่างเมล็ดกาแฟปกติ



ภาพประกอบ 3 ตัวอย่างเมล็ดดำ



ภาพประกอบ 4 ตัวอย่างเมล็ดขึ้นรา



ภาพประกอบ 5 ตัวอย่างขึ้นเมล็ดแตก



ภาพประกอบ 6 ตัวอย่างเมล็ดไม่สมบูรณ์



ภาพประกอบ 7 ตัวอย่างเมล็ดถูกแมลงทำลาย



ภาพประกอบ 8 ตัวอย่างผลกาแฟแห้ง

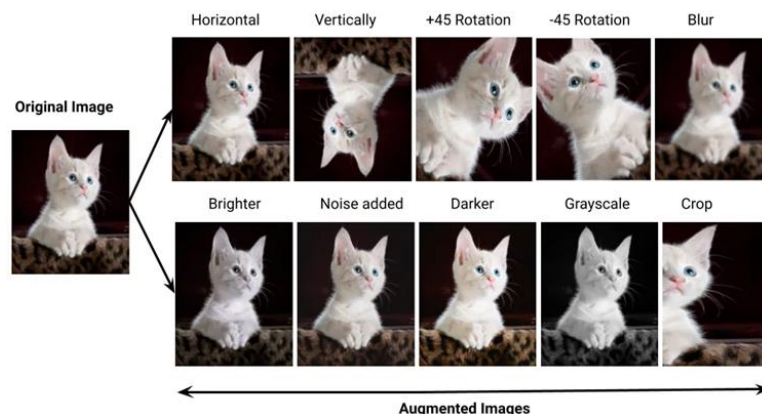


ภาพประกอบ 9 ตัวอย่างสิ่งแปลกปลอม

ที่มา: (พระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551, 2562)

2.2 การเสริมข้อมูล (Data Augmentation)

เป็นเทคนิคการสร้างข้อมูลรูปภาพใหม่จากข้อมูลรูปภาพที่มีอยู่ เพื่อเพิ่มความหลากหลายให้กับชุดข้อมูลรูปภาพ เนื่องจากการเรียนรู้ของโครงข่ายประสาทเทียมแบบคอนโวลูชัน เพื่อการรู้จำและการจำแนกรูปภาพ ประสิทธิภาพความแม่นยำของแบบจำลองจะขึ้นอยู่กับปริมาณข้อมูลเป็นปัจจัยสำคัญ จึงมีความจำเป็นต้องมีรูปภาพที่มีมุมมองหลากหลายมิติเพื่อหลีกเลี่ยงการเกิดปัญหา Overfitting และยังช่วยทำให้แบบจำลองมีความแม่นยำสูงขึ้น โดยการเสริมข้อมูลสามารถทำได้หลายรูปแบบ เช่น การหมุนภาพ (Rotation), การพลิกภาพ (Flip) และการปรับภาพให้เบลอ (Blur) เป็นต้น




ภาพประกอบ 10 ตัวอย่างการเสริมข้อมูลแบบต่าง ๆ

ที่มา: <https://pranjal-ostwal.medium.com/data-augmentation-for-computer-vision-b88b818b6010>

2.3 การเติมรูปภาพ (Image Padding)

เป็นเทคนิคที่ใช้เพื่อปรับขนาดของรูปภาพ เพื่อให้มีขนาดตรงกับขนาดของรูปภาพอื่น ๆ ในชุดข้อมูลสำหรับนำไปใช้สร้างแบบจำลอง โดยจะใช้เทคนิคเติมเส้นขอบของรูปภาพเพื่อเพิ่มขนาดของรูปภาพ แต่ยังคงอัตราส่วนของรูปภาพต้นฉบับไว้ไม่เปลี่ยนแปลง โดยการพิจารณาเพิ่มขนาดเท่าไรหรือนั้นขึ้นอยู่กับ ชั้นคอนโวลูชัน (Convolution Layer) นั้น ๆ มี Mask Size ขนาดใด

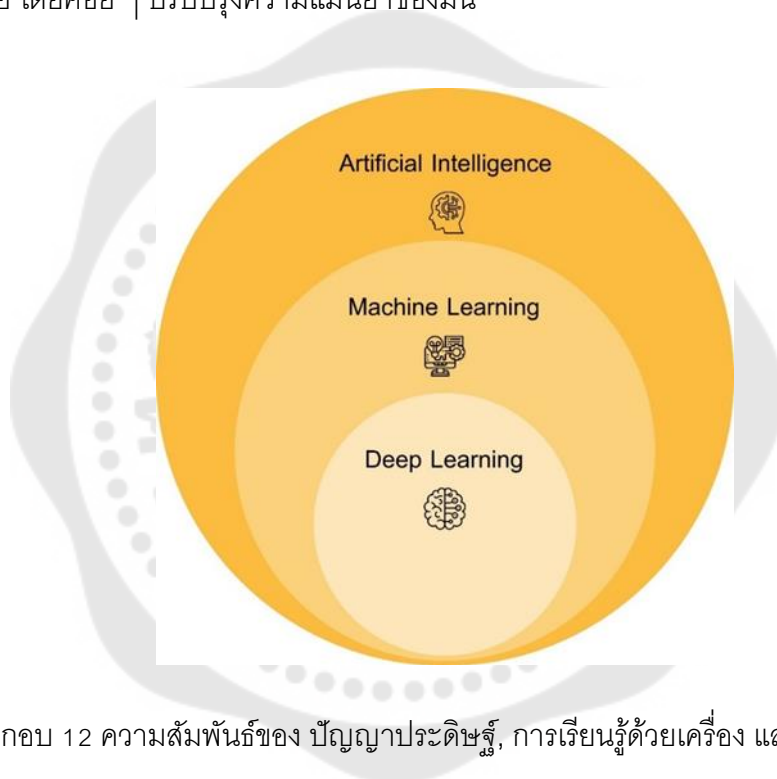


ภาพประกอบ 11 ตัวอย่างการเติมรูปภาพ

2.4 การเรียนรู้ด้วยเครื่อง (Machine Learning)

อาเธอร์ ซามูเอล ผู้เชี่ยวชาญด้านเกมคอมพิวเตอร์ ปัญญาประดิษฐ์ และการเรียนรู้ด้วยเครื่อง ให้คำนิยามว่า การเรียนรู้ด้วยเครื่อง เป็นศาสตร์หนึ่งที่มุ่งเน้นศึกษาการทำให้คอมพิวเตอร์ความสามารถเรียนรู้ได้โดยไม่ต้องเขียนโปรแกรมกำกับไว้อย่างชัดเจน

การเรียนรู้ด้วยเครื่อง เป็นสาขาย่อยของปัญญาประดิษฐ์ (Artificial Intelligence) และวิทยาการคอมพิวเตอร์ เป็นการใช้อัลกอริทึมในการแยกแยะและวิเคราะห์ข้อมูลจากข้อมูลนั้น ๆ เพื่อสร้างแบบจำลองในการตัดสินใจหรือคาดการณ์บางสิ่งบางอย่าง เพื่อเลียนแบบวิธีการเรียนรู้ของมนุษย์ โดยค่อย ๆ ปรับปรุงความแม่นยำของมัน




ภาพประกอบ 12 ความสัมพันธ์ของ ปัญญาประดิษฐ์, การเรียนรู้ด้วยเครื่อง และการเรียนรู้เชิงลึก

ที่มา: <https://www.coursera.org/articles/ai-vs-deep-learning-vs-machine-learning-beginners-guide>


ระบบการเรียนรู้ด้วยเครื่อง (Machine Learning Systems) ถูกเรียนรู้ขึ้นมาจากข้อมูลนำเข้า (Input) และ ข้อมูลส่งออก (Output) ในอดีต เพื่อให้ได้กฎ (Rules) ขึ้นมา โดยส่วนใหญ่เรียกกฎนี้ว่า ML Models หลังจากนั้นจึงนำไปใช้งานกับข้อมูลชุดใหม่ เพื่อคำนวณและได้ข้อมูลส่งออกใหม่ออกมา

2.5 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก เป็นสาขาย่อยของการเรียนรู้ด้วยเครื่อง (Machine Learning) ซึ่งเกี่ยวข้องกับการใช้โครงข่ายประสาทเทียม (Neural Networks) สร้างแบบจำลองและแก้ปัญหาที่มีความซับซ้อน โดยจะถูกจำลองตามโครงสร้างและหน้าที่ของสมองมนุษย์ มีลักษณะเหมือนเซลล์ประสาทหลาย ๆ เซลล์เชื่อมต่อกันเป็นโหนดเชื่อมกัน เรียกโหนดนั้นว่า เพอร์เซปตรอน (Perceptron) ซึ่งเชื่อมต่อกับเส้นประสาทและเซลล์อื่น ๆ หลายเส้นเพื่อประมวลผลและแปลงข้อมูล เครื่องข่ายเหล่านี้สามารถเรียนรู้การแสดงผลข้อมูลที่ซับซ้อนโดยการค้นหารูปแบบลำดับชั้นและคุณสมบัติในข้อมูล อัลกอริทึมการเรียนรู้เชิงลึกสามารถเรียนรู้และปรับปรุงอัลกอริทึมจากข้อมูลได้อัตโนมัติ โดยไม่ต้องทำวิศวกรรมคุณสมบัติข้อมูล (Feature Engineering) เอง



ภาพประกอบ 13 กระบวนการของการเรียนรู้เชิงลึก



ภาพประกอบ 14 การเรียนรู้เชิงลึก

ที่มา: (Xing & Du, 2018)

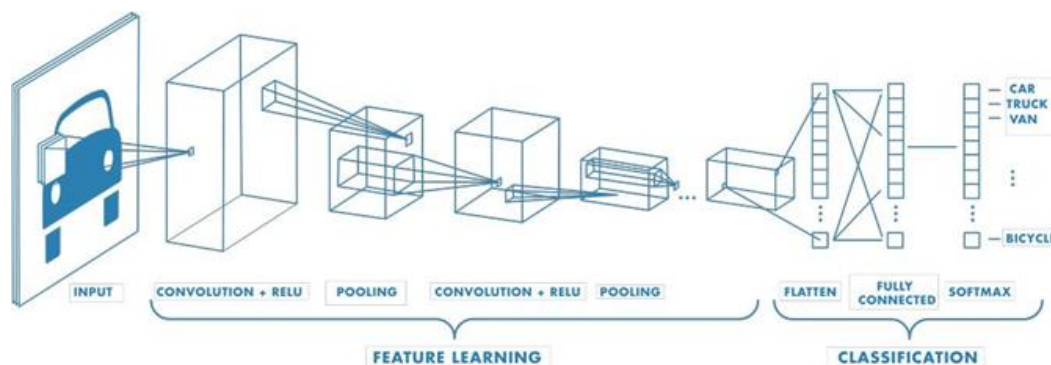
โครงข่ายประสาทเทียมประกอบด้วย 3 ส่วน ดังนี้

1. ชั้นข้อมูลนำเข้า (Input Layer) จำนวนของโหนดในชั้นนี้ขึ้นอยู่กับจำนวนของข้อมูลนำเข้าว่ามีข้อมูลอะไรบ้างที่จะนำเข้ามาคิดในแบบจำลอง เช่น ถ้าข้อมูลเข้าประกอบด้วยข้อมูล 3 อย่าง ชั้นข้อมูลเข้าจะมี 3 โหนด ซึ่งปัจจัยที่นำมาวิเคราะห์เหล่านี้เรียกว่าคุณลักษณะ (Feature)
2. ชั้นซ่อน (Hidden Layer) เป็นชั้นที่อยู่ตรงกลาง มีผลอย่างมากต่อประสิทธิภาพการเรียนรู้ของแบบจำลอง ซึ่งชั้นซ่อนจะมีกี่ชั้นก็ได้ และแต่ละชั้นจะมีจำนวนของนิวรอนจำนวนเท่าไรก็ได้
3. ชั้นข้อมูลส่งออก (Output Layer) เป็นชั้นที่จะนำข้อมูลจากการคำนวณไปใช้ และจำนวนของโหนดในชั้นนี้ขึ้นอยู่กับรูปแบบของข้อมูลออกที่จะเอาไปใช้

2.6 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network)

CNN เป็นโครงสร้างโครงข่ายประสาทเทียม (Neural Network) แบบพิเศษ มีความสามารถในการจำแนกข้อมูลประเภทรูปภาพได้ดีกว่าโครงข่ายประสาทเทียมแบบทั่วไป โดยแนวความคิดหลักของ CNN คือการที่ใช้ชั้นชนิดพิเศษที่เรียกว่า ชั้นคอนโวลูชัน (Convolution Layer) ซึ่งทำหน้าที่สกัดเอาส่วน คุณลักษณะต่าง ๆ ของภาพออกมา เช่น เส้นขอบของรูปภาพ หรือวัตถุ เพื่อให้แบบจำลองสามารถเรียนรู้คุณลักษณะของรูปภาพได้อย่างมีประสิทธิภาพและมีความแม่นยำ

โดย CNN จะใช้ชั้นคอนโวลูชันมาประกอบกับชั้นชนิดอื่น เช่น ชั้นพูลลิง (Pooling Layer) แล้วนำกลุ่มชั้นดังกล่าวมาซ้อนต่อ ๆ กัน โดยอาจเปลี่ยนไฮเปอร์พารามิเตอร์ (Hyperparameter) บางอย่าง เช่นขนาดของชั้นกรอง (Filter Layer) และจำนวนแชนเนล (Channel) ของชั้น เป็นต้น

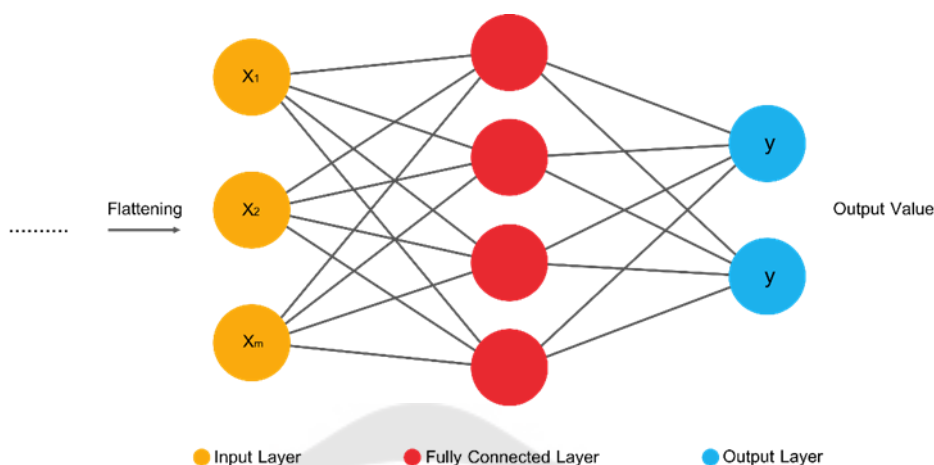


ภาพประกอบ 15 สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน

ที่มา: <https://www.mathworks.com/discovery/convolutional-neural-network-matlab.html>

โครงข่ายประสาทเทียมแบบคอนโวลูชันมีกระบวนการต่าง ๆ ดังนี้

1. การดำเนินการคอนโวลูชัน (Convolution Operation) เป็นการคูณเมทริกซ์ระหว่างข้อมูลนำเข้า กับตัวกรอง (Feature Detector) แล้วหาผลรวมของการคูณกันในแต่ละตำแหน่ง ทำให้ได้แผนที่คุณลักษณะ (Feature Map) จำนวนมาก โดยเรียกทั้งหมดว่าชั้นคอนโวลูชัน
2. Rectified Linear Unit (ReLU) เป็นวิธีการปรับแต่งให้แผนที่คุณลักษณะไม่มีลักษณะเชิงเส้น โดยทำการแทนที่ค่าที่เป็นลบของข้อมูลนำเข้าให้กลายเป็นศูนย์
3. การพูลลิ่ง (Pooling) ทำหน้าที่ช่วยลดมิติแผนที่คุณลักษณะลง แต่ยังคงรักษาคุณลักษณะสำคัญของข้อมูลไว้ ด้วยการหาค่าสูงสุด (Max Pooling), การหาค่าเฉลี่ย (Average Pooling) ซึ่งการพูลลิ่งทำให้ผลลัพธ์ที่ได้มีขนาดเล็ก ช่วยลดจำนวนพารามิเตอร์ และลดการคำนวณที่เกินจำเป็น
4. การแฟลทเทน (Flatten) เป็นการแปลงข้อมูลที่ได้จากการพูลลิ่งให้อยู่ในเมทริกซ์ที่มีแถวเดียว เพื่อความสะดวกในการวิเคราะห์ข้อมูล
5. การเชื่อมต่อสมบูรณ์ (Fully Connected) เป็นการนำผลที่ได้จากการทำแฟลทเทนมาเป็นข้อมูลนำเข้าให้กับชั้นเชื่อมต่อสมบูรณ์ (Fully Connected Layer) เพื่อทำนายผลของแต่ละประเภทที่เป็นไปได้



ภาพประกอบ 16 การเชื่อมโยงสมบูรณ์


ที่มา: <https://www.superdatascience.com/blogs/convolutional-neural-networks-cnn-step-4-full-connection>

2.7 การถ่ายทอดการเรียนรู้ (Transfer Learning)

เป็นการถ่ายทอดความรู้จากแบบจำลองที่ผ่านการฝึกฝนมาแล้ว หรืออาจเรียกว่า Pre-Trained Model นำมาใช้กับแบบจำลองอื่น เพื่อเพิ่มประสิทธิภาพของผลลัพธ์และช่วยลดระยะเวลาในการฝึกฝนแบบจำลอง โดยในงานวิจัยนี้จะเลือกใช้สถาปัตยกรรม 3 แบบ คือ ResNet50, ResNet101 และ VGG-16

2.7.1 สถาปัตยกรรม ResNet

ResNet (Deep Residual Network หรือ Residual Network) ถูกเสนอ ในงานวิจัยเรื่อง “Deep Residual Learning for Image Recognition” (He et al., 2016) ในสถาปัตยกรรม ResNet มีการการใช้ Residual Block โดยเป็นการนำเอาผลลัพธ์ของชั้นก่อนหน้ามารวมกับผลลัพธ์ของชั้นที่กำลังทำการประมวลผลอยู่ เพื่อลดการเกิดปัญหา Vanishing Gradient เนื่องจากภายใน Residual Block มีการใช้ Skip Connection เพื่อช่วยดึงค่า Gradient จากชั้นก่อนหน้ามาใช้ เพื่อช่วยลดเวลาในการเชื่อมต่อกันของแต่ละชั้น ซึ่งสามารถลดเวลาในการคำนวณลงโดยที่ประสิทธิภาพของในการทำงานยังคงเดิม ตามภาพประกอบ 17




ภาพประกอบ 17 Residual Block

ที่มา: (He et al., 2016)

ResNet50 จะประกอบด้วย 4 บล็อกใหญ่ (Stage) มีองค์ประกอบย่อยเป็นแบบ Bottleneck ที่มาเป็นแพ็ค 3 รวม 48 ชั้น + ชั้นคอนโวลูชันที่ติดกับชั้นข้อมูลนำเข้า + ชั้น Dense ที่ติดชั้นข้อมูลที่ส่งออกมา อธิบายขนาดเป็น [3, 4, 6, 3] ซึ่งหมายถึงจำนวนคิวในบล็อกทั้ง 4

ResNet101 จะประกอบด้วย 4 บล็อกใหญ่ (Stage) มีองค์ประกอบย่อยเป็นแบบ Bottleneck ที่มาเป็นแพ็ค 3 รวม 99 ชั้น + ชั้นคอนโวลูชันที่ติดกับชั้นข้อมูลนำเข้า + ชั้น Dense ที่ติดชั้นข้อมูลที่ส่งออกมา อธิบายขนาดเป็น [3, 4, 23, 3] ซึ่งหมายถึงจำนวนคิวในบล็อกทั้ง 4




ภาพประกอบ 18 สถาปัตยกรรม ResNet50 และ ResNet101

ที่มา: <https://blog.devgenius.io/resnet50-6b42934db431>

2.7.2 สถาปัตยกรรม VGG-16

Visual Geometry Group (VGG) เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีหลายชั้น เรียกอีกชื่อว่า VGGNet โดยความลึก (Deep) หมายถึงจำนวนชั้น ซึ่ง VGG-16 ประกอบไปด้วยคอนโวลูชัน 16 ชั้น ถูกเสนอในงานวิจัยเรื่อง “Very Deep Convolutional Networks for Large-Scale Image Recognition” (Simonyan & Zisserman, 2014) โดยแบบจำลองจะแทนที่ตัวกรองเคอร์เนลขนาดใหญ่ ด้วยขนาด 3x3 หลาย ๆ ตัวต่อกัน มีขนาดรูปภาพนำเข้า 224x224 และมีพารามิเตอร์ทั้งหมดประมาณ 138 ล้านพารามิเตอร์



ภาพประกอบ 19 สถาปัตยกรรม VGG-16

ที่มา: (Srikanth Tammina, 2019)

2.8 การประเมินผลแบบจำลอง (Model Evaluation)

เป็นการวัดประสิทธิภาพของแบบจำลองหรือผลลัพธ์ที่ได้ ว่าตรงกับวัตถุประสงค์ที่ตั้งไว้หรือไม่ และแบบจำลองนั้นมีความน่าเชื่อถือมากน้อยเพียงใด

2.8.1 Confusion Matrix

Confusion Matrix เป็นตารางแสดงผลลัพธ์เพื่อดูความแม่นยำจากการทำนายของแบบจำลอง ส่วนที่หนึ่งค่าจะเป็นจริง (True) หรือเท็จ (False) นั้นขึ้นอยู่กับค่าที่แบบจำลองทำนาย (Predicted) นั้นตรงกับค่าจริง (Actual) หรือไม่ เช่น ถ้าแบบจำลองทำนายออกมาเป็น 1 และค่าจริงเป็น 1 จะเรียกว่าเป็นจริง แต่ถ้าค่าที่แบบจำลองทำนายกับค่าจริงเป็นคนละค่ากันจะเรียกว่าเท็จ

ส่วนที่สอง ผลบวก (Positive) และผลลบ (Negative) คือค่าที่ต้องการเมื่อสร้างแบบจำลองเพื่อทำนาย เช่นหากโจทย์คืออยากรู้ว่าลูกค้าคนไหนที่จะกลับมาซื้อสินค้าในครั้งถัดไปบ้าง โดยค่าซื้อเป็นผลบวก และค่าไม่ซื้อเป็นผลลบ อธิบายค่าต่าง ๆ ดังนี้

	Actual 1	Actual 0
Predicted 1	True Positive (TP)	False Positive (FP)
Predicted 0	False Negative (FN)	True Negative (TN)

ภาพประกอบ 20 ตาราง Confusion Matrix

1. True Positive (TP) คือ แบบจำลองทำนายตรงกับสิ่งที่เกิดขึ้นจริง กรณีทำนายว่าจริง และสิ่งที่เกิดขึ้นคือจริง
2. True Negative (TN) คือ แบบจำลองทำนายตรงกับสิ่งที่เกิดขึ้น กรณีทำนายว่าเท็จ และสิ่งที่เกิดขึ้นคือเท็จ
3. False Positive (FP) คือ แบบจำลองทำนายไม่ตรงกับสิ่งที่เกิดขึ้น กรณีทำนายว่าจริง แต่สิ่งที่เกิดขึ้นคือเท็จ
4. False Negative (FN) คือ แบบจำลองทำนายไม่ตรงกับที่ที่เกิดขึ้นจริง กรณีทำนายว่าเท็จ แต่สิ่งที่เกิดขึ้นคือจริง

Confusion Matrix สามารถนำไปคำนวณค่าต่าง ๆ สำหรับบ่งชี้ประสิทธิภาพของแบบจำลองได้ ดังนี้

1. ค่าความแม่นยำ (Accuracy) คืออัตราส่วนของการจำแนกประเภทถูกต้อง ต่อการจำแนกประเภททั้งหมด หากแบบจำลองมีค่าความแม่นยำสูง สามารถอนุมานได้ว่าแบบจำลองทำนายได้ถูกต้องเป็นส่วนใหญ่

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad (1)$$

2. ค่าความผิดพลาดในการจำแนกประเภท (Classification Error) คืออัตราส่วนการจำแนกประเภทผิดพลาด ต่อการจำแนกประเภททั้งหมด

$$\text{Classification Error} = \frac{FP+FN}{TP+FP+TN+FN} \quad (2)$$

3. ค่าความเที่ยงตรง (Precision) คืออัตราส่วนของกลุ่มบวกที่จำแนกประเภทถูกต้อง (True Positive) ต่อจำนวนกลุ่มบวกทั้งหมดที่จำแนกประเภทออกมา

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

4. ค่าความระลึก (Recall) หรือ True Positive Rate คืออัตราส่วนของกลุ่มบวกที่จำแนกประเภทถูกต้อง (True Positive) ต่อจำนวนกลุ่มบวกทั้งหมด

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

5. False Positive Rate (FPR) คืออัตราส่วนของจำนวนกลุ่มลบที่ถูกจำแนกประเภทผิดพลาดเป็นกลุ่มบวก (กลุ่มบวกเท็จ) เทียบกับจำนวนข้อมูลกลุ่มลบทั้งหมด (คือผลรวมของกลุ่มลบจริง และกลุ่มบวกเท็จ)

$$\text{False Positive Rate} = \frac{FP}{TN+FP} \quad (5)$$

6. F1-Score คือค่าเฉลี่ยแบบ Harmonic Mean ระหว่าง Precision กับ Recall เป็น Single Metric ที่วัดความสามารถของแบบจำลอง ไม่ต้องเลือกระหว่าง Precision กับ Recall หากมีค่าสูงสามารถอนุมานได้ว่าแบบจำลองมีประสิทธิภาพดี

$$F1 = \frac{2 \cdot (\text{Precision} \cdot \text{Recall})}{\text{Precision} + \text{Recall}} \quad (6)$$

2.9 งานวิจัยที่เกี่ยวข้อง (Literature Review)

การวิจัยครั้งนี้ได้มีการศึกษาค้นคว้าและทบทวนวรรณกรรมงานวิจัยอื่น ๆ ที่มีความเกี่ยวข้องและเป็นประโยชน์กับงานวิจัย ดังนี้


2.9.1 บทความวิจัยเรื่อง Classification of Green coffee bean images based on defect types using convolutional neural network (CNN)

โดย Carlito Pinto, Junya Furukawa, Hidekazu Fukai และ Satoshi Tamura (Pinto et al., 2017)

ในงานวิจัยนี้ผู้วิจัยได้พัฒนาระบบคัดแยกเมล็ดกาแฟอัตโนมัติโดยใช้โครงข่ายประสาทเทียมเชิงลึกแบบคอนโวลูชัน (Deep Convolutional Neural Networks) เพื่อจำแนกความบกพร่องแต่ละประเภทของเมล็ดกาแฟ

เนื่องจากกาแฟเป็นพืชผลหลักในประเทศติมอร์-เลสเต เป็นสินค้าส่งออกหลัก และเป็นรายได้หลักของประชากร 1 ใน 4 ในประเทศ อย่างไรก็ตามการตรวจสอบคุณภาพของเมล็ดกาแฟจะดำเนินการโดยผู้ที่มีความเชี่ยวชาญ ซึ่งใช้แรงงานมาก ใช้เวลานาน และประสบปัญหาความไม่ถูกต้องในการตรวจสอบ ซึ่งเกิดจากการตัดสินใจของมนุษย์ที่แตกต่างกัน

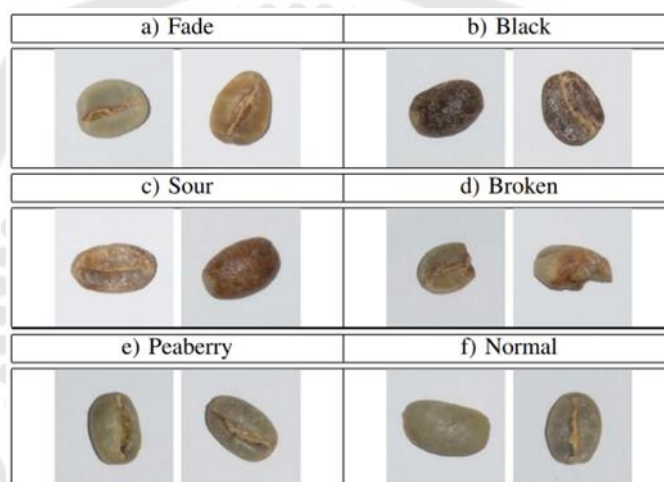
โดยผู้วิจัยได้นำตัวอย่างเมล็ดกาแฟจากประเทศติมอร์-เลสเต มาวางบนกระดาษสีขาวและทำการถ่ายภาพ มีการตั้งค่ากล้องถ่ายภาพด้วยโหมดอัตโนมัติ F/16, ความเร็วชัตเตอร์ 1/60 วินาที, ค่า ISO 200 และค่าการชดเชยแสง 1.3 ตั้งไฟแฟลชอัตโนมัติและวางกล้องเหนือเมล็ดกาแฟ 1 เมตร อีกทั้งยังใช้อุปกรณ์ให้แสงสว่างเพื่อสร้างสภาพแวดล้อม ทำการถ่ายภาพเมล็ดกาแฟทั้งด้านหน้าและด้านหลัง ตามภาพประกอบ 21



ภาพประกอบ 21 สภาพแวดล้อมการถ่ายภาพที่มองจากด้านข้าง

ที่มา: (Pinto et al., 2017)

มีการใช้เทคนิคการจัดการรูปภาพ (Image Preprocessing Techniques) เพื่อแยกเมล็ดกาแฟแต่ละเมล็ด ได้รูปภาพทั้งหมด 13,000 ภาพ จากเมล็ดกาแฟ 6,500 เมล็ด ขนาดของภาพคือ 256 x 256 พิกเซล แต่ละภาพมีการระบุว่าเป็นเมล็ดประเภทใด โดยแบ่งเป็น 6 ประเภท คือ เมล็ดสีจาง (Fade), เมล็ดดำ (Black), เมล็ดเปรี้ยว (Sour), เมล็ดแตก (Broken), เมล็ดกาแฟโทน (Peaberry) และเมล็ดปกติ (Normal) โดยหนึ่งรูปภาพอาจจะการระบุประเภทมากกว่าหนึ่งประเภท เช่น เป็นเมล็ดที่แตกและเป็นเมล็ดกาแฟโทน ตามภาพประกอบ 22 หลังจากนั้นรูปภาพถูกแบ่งออกเป็นสามกลุ่มคือ ชุดข้อมูลสำหรับฝึกสอน (Training Data), ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Data) และชุดข้อมูลสำหรับทดสอบ (Test Data) อัตราส่วนอยู่ที่ 10:2:1



ภาพประกอบ 22 ตัวอย่างความบกพร่องของเมล็ดกาแฟประเภทต่าง ๆ

ที่มา: (Pinto et al., 2017)

ผู้วิจัยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network) และเพื่อคำนวณความแม่นยำในการจำแนกประเภทความบกพร่องแต่ละประเภท ผู้วิจัยใช้วิธีการจับคู่รูปภาพเมล็ดที่มีความบกพร่องคู่กับรูปภาพเมล็ดปกติ สำหรับการฝึกสอน ตามตาราง 1

ตาราง 1 คู่ของการแบ่งข้อมูลและจำนวนของข้อมูล

Class 1 Name	Class 1 Data	Class 2 Name	Class 2 Data
เมล็ดสีจาง (Fade)	3,080	No defect	2,030
เมล็ดดำ (Black)	560	No defect	2,030
เมล็ดเปรี้ยว (Sour)	2,940	No defect	2,030
เมล็ดแตก (Broken)	140	No defect	2,030
เมล็ดกาแพโทน (Peaberry)	910	No defect	2,030

ที่มา: (Pinto et al., 2017)

ข้อมูลใช้ทดสอบ แบ่งเป็น 2 คลาส 7 ประเภท โดยที่เมล็ดแตกและเมล็ดกาแพโทน เป็นประเภทเมล็ดที่มีความบกพร่องทางด้านรูปร่าง จึงใช้ภาพโทนสีเทาจำแนกประเภทเมล็ด

ผลการวิจัยพบว่าความแม่นยำในการจำแนกประเภทเมล็ดดำมีความแม่นยำสูงสุด (98.75%) รองลงมาคือเมล็ดเปรี้ยว (92.93%) ส่วนเมล็ดแตก (รูปภาพสีเทา) มีความแม่นยำต่ำสุด (67.50%) ตามตาราง 2 จากผลลัพธ์ไม่สามารถสรุปได้แน่ชัดว่าพารามิเตอร์หรือคุณลักษณะใดมีส่วนทำให้ความแม่นยำการจำแนกประเภทลดลง

ตาราง 2 จำนวนข้อมูลทดสอบและความแม่นยำในการจำแนกประเภท

Pair (X & No defect)	Test data	Test Acc.
เมล็ดสีจาง (Fade)	580	0.724138
เมล็ดดำ (Black)	160	0.987500
เมล็ดเปรี้ยว (Sour)	580	0.929310
เมล็ดแตก, สี (Broken, Color)	40	0.725000
เมล็ดแตก, สีเทา (Broken, Gray)	40	0.675000
เมล็ดกาแพโทน, สี (Peaberry, Color)	260	0.807692
เมล็ดกาแพโทน, สีเทา (Peaberry, Gray)	260	0.780769

ที่มา: (Pinto et al., 2017)

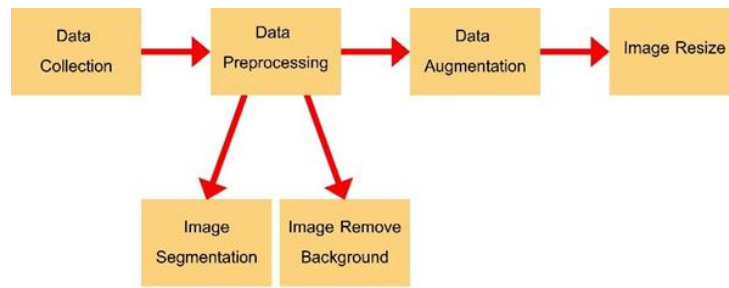
2.9.2 บทความวิจัยเรื่อง Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network

โดย Nen-Fu Huang, Dong-Lin Chou และ Chia-An Lee (Huang et al., 2019)

ในงานวิจัยนี้ผู้วิจัยต้องการแก้ปัญหาทางนาคัดเลือกเมล็ดกาแฟ (Green Coffee Beans) ที่มักผสมกับสิ่งเจอปนอื่น ซึ่งใช้แรงงานและเวลาในการคัดเลือกลาน และเพื่อพัฒนาระบบเครื่องเก็บเมล็ดกาแฟอัตโนมัติ โดยใช้เทคโนโลยีการประมวลผลภาพ (Image Processing) และการเสริมข้อมูล (Data Augmentation) เพื่อจัดการกับข้อมูล จากนั้นใช้การเรียนรู้เชิงลึกโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อวิเคราะห์ข้อมูลภาพ และใช้แบบจำลองมาเชื่อมต่อกับกล้องเว็บแคมเพื่อใช้สำหรับการจดจำผ่านสตรีมวิดีโอ (Video Streaming Recognition)

เนื่องจากระบบการคัดแยกด้วยภาพที่มีอยู่ตามท้องตลาดสามารถแยกแยะความแตกต่างของสินค้าที่ดีและไม่ดี เช่น ถั่วลิสง เมล็ดพีช ข้าว และเมล็ดกาแฟ โดยพิจารณาจากสีเป็นหลัก ซึ่งระบบเหล่านั้นต้องตั้งค่าช่วงของสี และใช้แขนหุ่นยนต์ (Robotic Arm) หยิบของพวกนั้นซึ่งช้าและไม่มีประสิทธิภาพ ดังนั้นผู้วิจัยจึงเสนอวิธีการที่ใช้เทคโนโลยีการเรียนรู้เชิงลึกเพื่อกำหนดมาตรฐานของสินค้าที่ดีและไม่ดี เพื่อเพิ่มความเร็วและความแม่นยำของการระบุเมล็ดกาแฟผ่านปัญญาประดิษฐ์

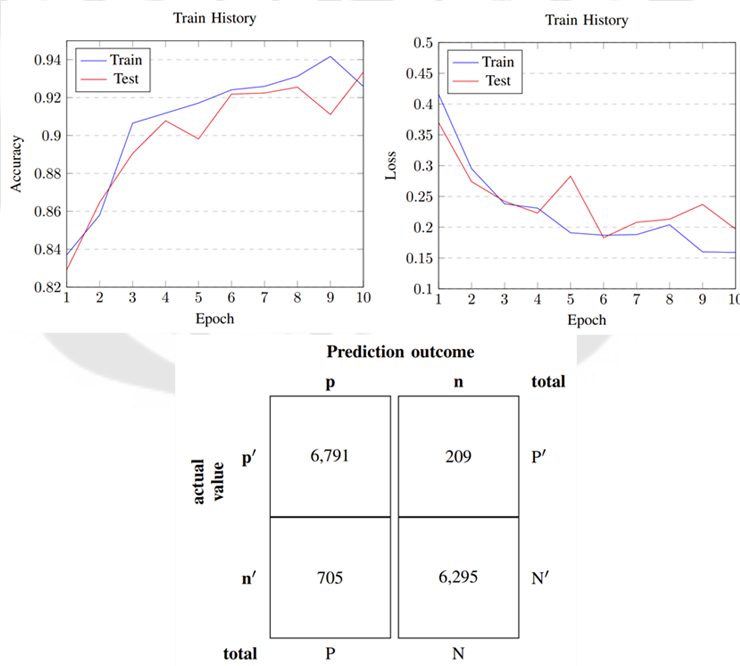
โดยกระบวนการสำหรับการสร้างชุดข้อมูลแบ่งย่อยออกเป็น 5 ขั้นตอนคือ ขั้นตอนแรกเป็นการรวบรวมข้อมูลโดยผู้วิจัยได้ใช้กล้องถ่ายภาพเมล็ดกาแฟเอง แบ่งออกเป็นเมล็ดดี 1,000 เมล็ด และเมล็ดที่ไม่ดี 1,000 เมล็ด ขั้นตอนที่สองเป็นการเตรียมข้อมูลเพื่อจะนำไปประมวลผลแบ่งออกเป็นสองกระบวนการย่อยคือ การแบ่งภาพออกเป็นส่วน ๆ ผ่านโปรแกรมอัตโนมัติโดยแปลงเป็นภาพสีเทา และการลบพื้นหลังรูปภาพ ขั้นตอนที่สามเป็นการเสริมข้อมูลเนื่องจากข้อมูลที่มียังไม่เพียงพอต่อโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้การหมุนและการพลิก ได้ทั้งหมด 72,000 ภาพ แบ่งออกเป็นเมล็ดดี 36,000 ภาพ และเมล็ดที่ไม่ดี 36,000 ภาพ ขั้นตอนที่สี่เป็นการปรับขนาดรูปภาพ โดยปรับเป็น 180×180 พิกเซล ขั้นตอนที่ 5 สถาปัตยกรรมแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ผู้วิจัยได้ใช้ฟังก์ชัน ReLU เป็นหลักในคอนโวลูชันเลเยอร์



ภาพประกอบ 23 ขั้นตอนการเตรียมข้อมูลเพื่อนำไปประมวลผล

ที่มา: (Huang et al., 2019)

ผลการทดลองพบว่าทำให้ภาพเป็นสีเทาเพื่อใช้ในแบบจำลองเครือข่ายประสาทเทียม ส่งผลให้การทดสอบมีความแม่นยำประมาณ 93.34% ค่า loss ประมาณ 0.19 และได้ค่า FPR 0.1007 ตามภาพประกอบที่ 24 อย่างไรก็ตามการทดลองยังต้องมีการปรับสภาพแวดล้อมของแสงให้สามารถนำภาพมาใช้ในการเตรียมข้อมูลเพื่อนำไปประมวลผลต่อไปได้



ภาพประกอบ 24 แสดงค่าประสิทธิภาพความแม่นยำ ค่า Loss และค่าวัดความสามารถของแบบจำลอง

ที่มา: (Huang et al., 2019)


2.9.3 บทความเรื่อง USK-COFFEE Dataset: A Multi-Class Green Arabica Coffee Bean Dataset for Deep Learning

โดย Alifya Febriana, Kahlil Muchtar, Rahmad Dawood และ Chih-Yang Lin (Febriana et al., 2022)

ในงานวิจัยนี้ผู้วิจัยต้องการนำเสนอระบบการคัดแยกเมล็ดกาแฟอัจฉริยะเพื่อช่วยเหลือเกษตรกรที่ใช้การคัดแยกเมล็ดกาแฟด้วยสายตาที่ใช้เวลานานและใช้แรงงานมาก ซึ่งอาจส่งผลให้ได้กาแฟคุณภาพต่ำเนื่องจากความเครียดและความเหนื่อยล้า โดยการนำการเรียนรู้เชิงลึกแบบคอนโวลูชัน ด้วยแบบจำลอง MobileNetV2 และ ResNet18

โดยผู้วิจัยใช้ชุดข้อมูล "USK-Coffee" มีจำนวนรูปภาพทั้งหมด 8,000 ภาพ แบ่งเป็น 2,000 ภาพ ตามประเภท คือ เมล็ดกาแฟลองเบอร์รี่ (Longberry), เมล็ดกาแฟโทน (Peaberry), เมล็ดกาแฟพรีเมียม (Premium) และเมล็ดกาแฟที่มีความบกพร่อง (Defect) ตามภาพประกอบ

25



Images of coffee beans from USK-Coffee: (a) longberry, (b) peaberry, (c) premium, and (d) defect, respectively.

ภาพประกอบ 25 เมล็ดกาแฟอะราบิกาประเภทต่าง ๆ

ที่มา: (Febriana et al., 2022)

ผู้วิจัยใช้สามเทคนิคในการแปลงข้อมูล โดยใช้ torchvision.transforms ซึ่งจะช่วยให้เสริมข้อมูล และเพิ่มขนาดของชุดข้อมูล วิธีการดังกล่าวประกอบด้วย RandomHorizontalFlip, ToTensor (แก้ไขจากรูปภาพ PIL เป็น PyTorch Tensor), และ Normalize โดยใช้ค่า std ที่คำนวณได้และค่าเฉลี่ย มีการปรับขนาดรูปภาพเป็น 256 x256 พิกเซล รูปภาพจะถูกใช้เป็นชุด

ข้อมูลสำหรับฝึกสอน (Training Data), ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Data) และชุดข้อมูลสำหรับทดสอบ (Test Data) ในอัตราส่วน 55:25:20


ตาราง 3 รายละเอียดของชุดข้อมูล USK-Coffee

Class	Training	Validation	Test
เมล็ดกาแฟโทน (Peaberry)	1,200	400	400
เมล็ดกาแฟลองเบอร์รี่ (Longberry)	1,200	400	400
เมล็ดกาแฟพรีเมียม (Premium)	1,200	400	400
เมล็ดกาแฟที่มีความบกพร่อง (Defect)	1,200	400	400
Total	4,800	1,600	1,600
Total Data		8,000	

ที่มา: (Febriana et al., 2022)

แบบจำลองที่ผู้วิจัยใช้สร้างขึ้นโดยโครงข่ายประสาทเทียมแบบคอนโวลูชัน ผู้วิจัยใช้สถาปัตยกรรมสองแบบคือ ResNet-18 และ MobileNetV2 สำหรับ ResNet-18 มีการเปลี่ยนเลเยอร์สุดท้ายของแบบจำลองเป็น 4 Fully Connected Layers สำหรับ MobileNetV2 ผู้วิจัยได้ตรึงน้ำหนักเลเยอร์แรกไว้ และเพิ่ม Dropout Layer ด้วยอัตรา 0.2 เพื่อปรับปรุงความสามารถของแบบจำลองและลดการโอเวอร์ฟิตติง และยังทำการเปลี่ยน Fully Connected Layers เพื่อแบ่งชุดข้อมูลออกเป็น 4 คลาส

ผลลัพธ์ที่ได้พบว่า MobileNetV2 สามารถทำงานได้ดีกว่า ResNet-18 และถึงจะเป็นชุดข้อมูลขนาดเล็ก แต่แบบจำลองที่ผู้วิจัยใช้สามารถจำแนกเมล็ดกาแฟ 4 ประเภทได้อย่างแม่นยำ ค่าความแม่นยำของ ResNet-18 ในการฝึกสอน (Training) ที่ 98.81% และการตรวจสอบ (Validation) ที่ 95.06% ด้วยเวลาทำงาน 5930 วินาที ขณะที่ MobileNetV2 มีค่าความแม่นยำในการฝึกสอน ที่ 85.88% และการตรวจสอบ ที่ 81.18% ด้วยเวลาทำงาน 1948 วินาที



ภาพประกอบ 26 กราฟเปรียบเทียบค่าความแม่นยำ และค่าการสูญเสีย ของข้อมูลการฝึกสอน



ภาพประกอบ 27 กราฟเปรียบเทียบค่าความแม่นยำ และค่าการสูญเสีย ของข้อมูลการตรวจสอบ

ที่มา: (Febriana et al., 2022)

2.9.4 บทควมวิจัยเรื่อง Classification of Cacao Beans Based on their External Physical Features Using Convolutional Neural Network

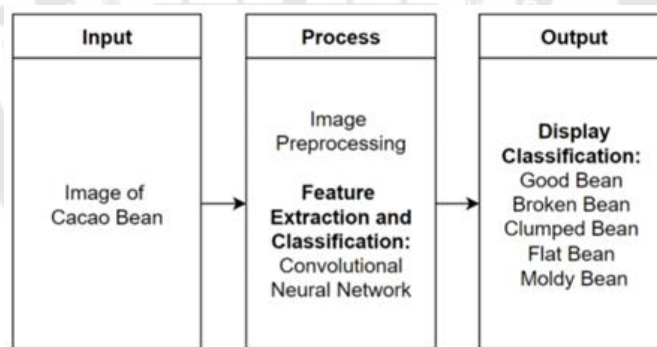
โดย Carlos C. Hortinela และ Kathleen Joy R. Tupas (Hortinela & Tupas, 2022)

ในงานวิจัยนี้ผู้วิจัยต้องการแก้ปัญหาการคัดแยกเมล็ดโกโก้ที่มีมักจะทำโดยการตรวจสอบด้วยสายตา โดยเกษตรกรจะคัดเมล็ดด้วยมือ ด้วยการใช้การประมวลผลรูปภาพและโครงข่ายประสาทที่ได้รับการฝึกฝนมาก่อนแล้ว (Pretrained Neural Network) โดยผู้วิจัยได้จำแนกประเภทออกเป็นเมล็ดที่ดี (Good Beans), เมล็ดแตก (Broken Beans), เมล็ดที่จับตัวเป็นก้อน (Clumped Beans), เมล็ดแบน (Flat Beans) และ เมล็ดขึ้นรา (Moldy Beans)

เนื่องจากการแยกเมล็ดโกโก้ที่มีความบกพร่องออกจากเมล็ดที่มีคุณภาพดีมีความสำคัญอย่างมาก เพราะจะส่งผลต่อคุณภาพของการแปรรูปไปเป็นช็อคโกแลตได้ แต่

เกษตรกรรมมักจะคัดแยกความบกพร่องเหล่านั้นด้วยการตรวจสอบด้วยสายตา ซึ่งทำให้เกิดความไม่ถูกต้องเมื่อต้องคัดแยกเมล็ดจำนวนมาก จากการศึกษาที่ผู้วิจัยได้นำมาอ้างอิงมีการใช้อัลกอริทึมการมองเห็นด้วยคอมพิวเตอร์ (Computer Vision Algorithms) เพื่อตรวจจับและจำแนกความบกพร่องกระบวนการทางการเกษตรต่าง ๆ รวมทั้งการประเมินคุณภาพเมล็ดข้าวโพด มะม่วงคาราบาว และเมล็ดโกโก้ เพื่อให้ได้การประเมินที่รวดเร็วและแม่นยำ โดยรวมโครงข่ายประสาทเทียมแบบคอนโวลูชัน และ ตารางแสดงความแตกต่างระหว่างพิกเซลโดยใช้ความสว่างในระดับสีเทา (Grey Level Co-occurrence Matrix) ด้วยตัวแยกประเภทสองตัว ได้แก่ SVM และ XGBoost เพื่อตรวจหาความบกพร่อง 7 ประเภทของเมล็ดโกโก้ ซึ่งการศึกษานี้ยังขาดการศึกษาโดยใช้แบบจำลอง VGG-16 ซึ่งถือว่าเป็นสถาปัตยกรรมที่ดี ผู้วิจัยจึงมีวัตถุประสงค์เพื่อพัฒนาระบบที่สามารถตรวจจับความบกพร่องของเมล็ดโกโก้โดยใช้โครงข่ายประสาทเทียม VGG-16

การสร้างกรอบแนวคิดของงานวิจัยแบ่งออกเป็นสามส่วน คือ ข้อมูลที่ป้อนเข้า (Input), กระบวนการ (Process) และข้อมูลที่ส่งออกมา (Output) อธิบายคือรูปภาพเมล็ดโกโก้จะผ่านกระบวนการประมวลผลภาพล่วงหน้าที่จะช่วยเพิ่มคุณภาพของรูปภาพ การแยกคุณลักษณะ และอัลกอริทึมการจำแนกประเภท



ภาพประกอบ 28 กรอบแนวคิดงานวิจัย

ที่มา: (Hortinela & Tupas, 2022)

การรวบรวมชุดข้อมูล ผู้วิจัยใช้กล้องเว็บแคม Logitech C922 ถ่ายภาพ ได้ภาพทั้งหมด 500 ภาพ แต่ละประเภทความบกพร่องมี 100 ภาพ 70% ใช้เป็นชุดฝึกฝน และ 30% ถูกแบ่งเป็นชุดทดสอบ จากนั้นใช้วิธีการเสริมข้อมูลโดยการหมุนภาพและพลิกภาพ

การเตรียมข้อมูลเพื่อจะนำไปประมวลผล โดยการแปลงรูปภาพเป็นโทนสีเทา การทำให้ขอบของภาพเรียบขึ้นโดยใช้ Gaussian blur และการปรับภาพแยกวัตถุออกจากพื้นหลัง ในส่วนของการสร้างโครงข่ายประสาทเทียม ผู้วิจัยใช้ VGG-16

ผลการทดลองพบว่าการฝึกฝนของแบบจำลองได้คะแนนความแม่นยำ 98.67% สำหรับเมล็ดที่ดีและเมล็ดที่จับตัวเป็นก้อน, 97.33% สำหรับเมล็ดขึ้นรา และ 93.33% สำหรับเมล็ดแตกและเมล็ดแบน พบว่าเมล็ดแตกและเมล็ดแบนมีเปอร์เซ็นต์ความแม่นยำต่ำสุด อาจมาจากลักษณะสีที่ค่อนข้างคล้ายกัน ในส่วนของค่า F1-score แบบจำลองทำงานได้ดีในการจำแนกเมล็ดที่ดี, เมล็ดที่จับตัวเป็นก้อน และเมล็ดขึ้นรา มีค่าคะแนนตั้งแต่ 0.93 ถึง 0.97 ในทางกลับกัน การตรวจจับเมล็ดแตกและเมล็ดแบนทำได้ไม่ค่อยดี เนื่องจากได้คะแนนต่ำสุดที่ 0.84 และ 0.83 อย่างไรก็ตามผู้วิจัยได้ขอเสนอแนะในการปรับปรุงให้ดีขึ้นด้วยการเสริมชุดข้อมูลเมล็ดแตกและเมล็ดแบน

ตาราง 4 ประสิทธิภาพของแบบจำลอง

Classification	Accuracy (%)	Precision	Recall	F1 Score
Good Bean	98.67 %	0.93	1.0	0.97
Broken Bean	93.33 %	0.87	0.81	0.84
Clumped Bean	98.67 %	1.0	0.94	0.97
Flat Bean	93.33 %	0.80	0.86	0.83
Moldy Bean	97.33 %	0.93	0.93	0.93

ที่มา: (Hortinela & Tupas, 2022)

2.9.5 บทความวิจัยเรื่อง Coffee Bean Quality Classification Using Convolutional Neural Network

โดย ชาคกริต เสรีพงษ์ (ชาคกริต เสรีพงษ์, 2561)

ในงานวิจัยนี้ผู้วิจัยต้องการจำแนกคุณภาพของเมล็ดกาแฟ ซึ่งประกอบด้วยเมล็ดกาแฟที่มีความบกร่อง 5 ชนิด ได้แก่ เมล็ดดำ, เมล็ดขึ้นรา, ขึ้นเมล็ดแตก, เมล็ดไม่สมบูรณ์ และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดกาแฟแบบปกติ โดยพัฒนาแบบจำลองที่ใช้การเรียนรู้เชิงลึก

โดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน เปรียบเทียบกับแบบจำลองที่ใช้การเรียนรู้ด้วยเครื่องแบบดั้งเดิม

รูปภาพเมล็ดกาแฟที่ผู้วิจัยนำมาใช้ศึกษา ได้ทำการนำแสงเงาออกไปเรียบร้อยแล้ว มีจำนวนทั้งหมด 5,696 รูป ประกอบไปด้วย เมล็ดถูกแมลงทำลาย 700 รูป, เมล็ดดำ 1,002 รูป, ขึ้นเมล็ดแตก 781 รูป, เมล็ดขึ้นรา 944 รูป, เมล็ดไม่สมบูรณ์ 969 รูป และเมล็ดปกติ 1,300 รูป

ผู้วิจัยสร้างแบบจำลองการทำนายทั้งหมด 6 แบบจำลอง ใช้การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน 5 แบบจำลอง ได้แก่

1. สถาปัตยกรรมแบบ ResNet50
2. สถาปัตยกรรมแบบ ResNet101
3. สถาปัตยกรรมแบบ ResNet50 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ
4. สถาปัตยกรรมแบบ ResNet101 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ

5. สถาปัตยกรรมแบบ ResNet50 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ และจำแนกเฉพาะเมล็ดที่มีความบกพร่องกับเมล็ดกาแฟแบบปกติ

ซึ่งชั้นของผลลัพธ์แบ่งเป็น 6 ประเภท ตามชนิดเมล็ดกาแฟ และยังใช้แบบจำลองของ SGDClassifier โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลของรูปภาพ ซึ่งเป็นการเรียนรู้ด้วยเครื่องแบบดั้งเดิม จากการศึกษาพบว่าแบบจำลองที่มีค่า Accuracy สูงที่สุดคือแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 โดยใช้การปรับแต่งเพื่อเพิ่มข้อมูลรูปภาพ และเมื่อเปรียบเทียบกับแบบจำลองอื่น SGDClassifier ซึ่งเป็นแบบจำลองที่ไม่ใช่การเรียนรู้เชิงลึกนั้น จะมีค่า Accuracy ที่น้อยมากอย่างเห็นได้ชัดเมื่อเปรียบเทียบกับแบบจำลองอื่น

ตาราง 5 ค่า Accuracy และ Weight Average ของแบบจำลอง

Model	Weight Average	Weight Average	Weight Average	Accuracy
	Precision	Recall	F1-Score	
ResNet50	0.74	0.74	0.73	0.74
ResNet101	0.73	0.75	0.73	0.75
ResNet50 with image augmentation	0.76	0.77	0.76	0.77
ResNet101 with image augmentation	0.78	0.74	0.75	0.74
SGDClassifier with image augmentation	0.61	0.61	0.60	0.61

ที่มา: (ชาคริต เสรีพงษ์, 2561)

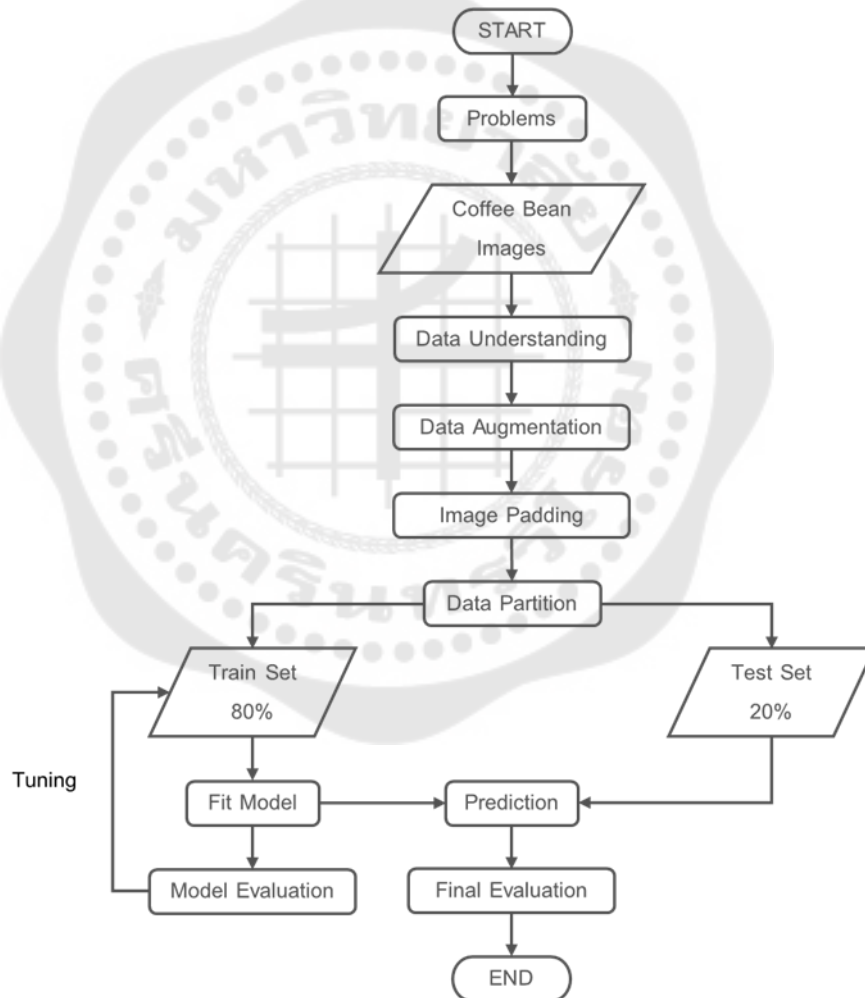
บทที่ 3

การดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้มีการวางแผนขั้นตอนในการดำเนินงานวิจัยซึ่งมีรายละเอียดดังนี้

3.1 การออกแบบขั้นตอนในการดำเนินงานวิจัย

มีรายละเอียดตามภาพประกอบ 29



ภาพประกอบ 29 ขั้นตอนในการดำเนินงานวิจัย

ตามภาพประกอบ 29 แสดงขั้นตอนในการดำเนินงานวิจัย เริ่มต้นด้วยการศึกษาปัญหาที่เกิดขึ้นในกระบวนการคัดแยกเมล็ดกาแฟ และนำเข้าสู่ชุดข้อมูลรูปภาพเมล็ดกาแฟซึ่งแบ่งออกเป็น

6 ประเภทตามคุณลักษณะ จากนั้นเตรียมข้อมูลรูปภาพเพื่อนำไปสร้างแบบจำลองโดยการเสริมข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายให้กับชุดข้อมูล และการเติมรูปภาพ (Image Padding) เพื่อปรับขนาดรูปภาพให้ได้ขนาดที่เท่ากัน แต่ยังคงอัตราส่วนภาพต้นฉบับไว้ จากนั้นทำการแบ่งชุดข้อมูลสำหรับนำไปสร้างแบบจำลองเป็นจำนวน 80% และสำหรับทดสอบแบบจำลองเป็นจำนวน 20% แล้ว หลังจากนั้นนำข้อมูลที่เตรียมไว้มา Fit กับแบบจำลองที่ถูกฝึกฝนมาแล้ว (Pre-Trained) หลังจากสร้างแบบจำลองทั้งหมดแล้ว ถัดไปคือการสำรวจผลลัพธ์ของแบบจำลองเบื้องต้นว่าประสิทธิภาพเป็นอย่างไร สามารถเพิ่มประสิทธิภาพได้อีกหรือไม่ หากแบบจำลองได้ผลลัพธ์ที่น่าพอใจแล้ว จึงแบบจำลองที่ได้ทั้งหมดไปทำนายกับข้อมูลทดสอบ เมื่อได้ผลลัพธ์ของการทำนายครบทุกแบบจำลองแล้ว ขั้นตอนสุดท้ายคือการนำผลลัพธ์ที่ได้ไปวัดผลด้วยค่าประเมิน Precision, Recall, F1-Score และ Accuracy เพื่อนำค่าประเมินได้ไปเปรียบเทียบกันในแต่ละแบบจำลองการทำนายเพื่อสรุปผลการทดลอง

3.2 การสำรวจข้อมูลเบื้องต้น


ชุดข้อมูลที่นำมาใช้ในการวิจัยเป็นชุดข้อมูลจากงานวิจัยเรื่อง การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพด้วยการประมวลผลภาพถ่าย (แสงดาว เตือนแจ่ม, 2021) โดยเป็นภาพที่ได้ผ่านกระบวนการลบแสงและเงาออกไปแล้ว ประกอบด้วยรูปภาพเมล็ดกาแฟจำนวน 5,839 ภาพ แบ่งออกเป็น 6 ประเภท ตามตาราง 6

ตาราง 6 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

เมล็ดดำ (Black Bean)


ตามภาพประกอบ 30 แสดงตัวอย่างรูปภาพเมล็ดดำ คุณลักษณะที่เห็นได้อย่างชัดเจนคือรูปภาพจะมีพื้นที่สีดำ ทึบ มากกว่ารูปภาพเมล็ดกาแฟประเภทอื่น สังเกตรูปร่างเมล็ดได้ค่อนข้างยาก



ภาพประกอบ 30 ตัวอย่างรูปภาพเมล็ดกาแฟดำ

เมล็ดขึ้นรา (Moldy Bean)


ตามภาพประกอบ 31 แสดงตัวอย่างรูปภาพเมล็ดขึ้นรา คุณลักษณะที่เห็นได้อย่างชัดเจนคือมีจุดราสีดำขึ้นอยู่ทั่วเมล็ดกาแฟ



ภาพประกอบ 31 ตัวอย่างรูปภาพเมล็ดขึ้นรา

เมล็ดแตก (Bean Fragment)


ตามภาพประกอบ 32 แสดงตัวอย่างรูปภาพขึ้นเมล็ดแตก คุณลักษณะที่เห็นได้อย่างชัดเจนคือตัวเมล็ดจะมีรอยแตก มีขนาดเล็กกว่าเมล็ดกาแฟปกติ มีขนาดไม่เต็มเมล็ด



ภาพประกอบ 32 ตัวอย่างรูปภาพเมล็ดแตก

เมล็ดไม่สมบูรณ์ (Incompletely Formed Bean)


ตามภาพประกอบ 33 แสดงตัวอย่างรูปภาพเมล็ดไม่สมบูรณ์ คุณลักษณะที่เห็นได้อย่างชัดเจนคือตัวเมล็ดมีความเหี่ยวยุบ และลีบ



ภาพประกอบ 33 ตัวอย่างรูปภาพเมล็ดไม่สมบูรณ์

เมล็ดถั่วแมลงทำลาย (Insect-Damaged Bean)


ตามภาพประกอบ 34 แสดงตัวอย่างรูปภาพเมล็ดถั่วแมลงทำลาย คุณลักษณะที่เห็นได้อย่างชัดเจนคือตัวเมล็ดจะมีร่องรอยการถูกกัด ทะแะ หรือเจาะจนเป็นรู



ภาพประกอบ 34 ตัวอย่างรูปภาพเมล็ดถั่วแมลงทำลาย

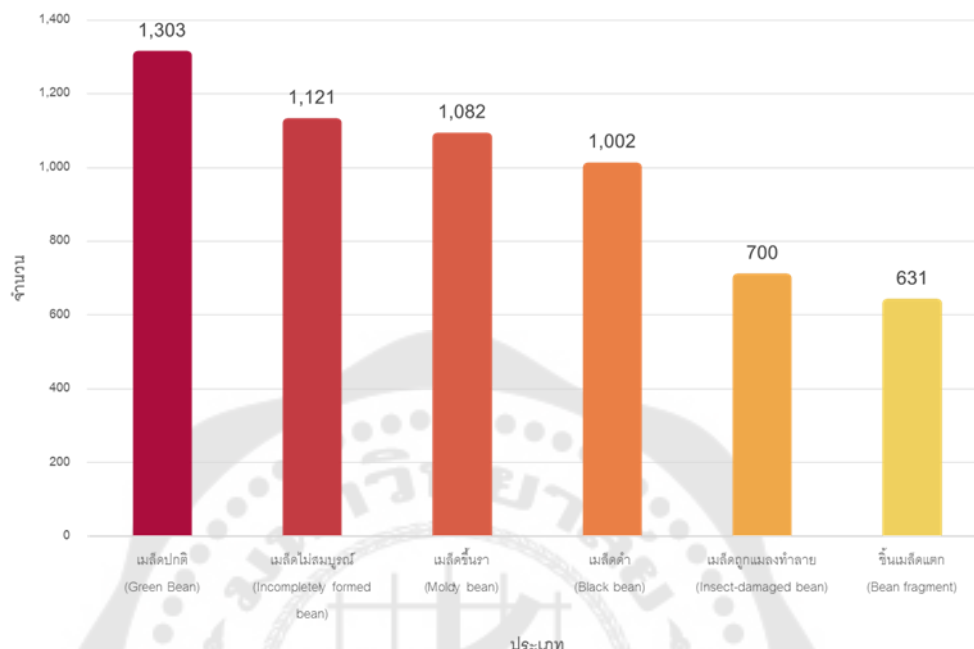
เมล็ดปกติ (Green Bean)

ตามภาพประกอบ 35 แสดงตัวอย่างรูปภาพเมล็ดปกติ คุณลักษณะที่เห็นได้อย่างชัดเจนคือตัวเมล็ดมีความสมบูรณ์มากที่สุด ไม่มีรอยแตก รอยแมลงกัด ทะแะ หรือเจาะ มีรูปทรงกลมรี สีเขียวอ่อน



ภาพประกอบ 35 ตัวอย่างรูปภาพเมล็ดปกติ

ภาพประกอบ 36 แสดงถึงสัดส่วนข้อมูลรูปภาพของเมล็ดกาแฟทั้งหมด 6 ประเภท โดยเรียงจากประเภทของเมล็ดกาแฟที่มีจำนวนมากที่สุดไปจนถึงจำนวนน้อยที่สุด



ภาพประกอบ 36 สัดส่วนข้อมูลรูปภาพเมล็ดกาแฟทั้ง 6 ประเภท

3.3 การเตรียมข้อมูล

การเตรียมข้อมูลรูปภาพเพื่อนำไปสร้างแบบจำลองแบ่งได้เป็น 3 ขั้นตอน ดังนี้

1. การเสริมข้อมูล (Data Augmentation)

เพื่อเพิ่มความหลากหลายให้กับชุดข้อมูล โดยการการพลิกภาพ (Flip) แบ่งเป็นส้อมพลิกภาพแบบแนวนอน (Horizontal Flip) และส้อมพลิกภาพแบบแนวตั้ง (Vertical Flip) ตามภาพประกอบ 37 โดยเพิ่มจำนวนจากเดิมประเภทละ 50 เปอร์เซ็นต์ได้จำนวนทั้งหมด 8,770 ภาพ แบ่งออกเป็น 6 ประเภท ตามตาราง 7




ภาพประกอบ 37 ตัวอย่างรูปภาพก่อน - หลังทำการเสริมข้อมูล

ตาราง 7 จำนวนรูปภาพเมล็ดกาแฟหลังจากใช้เทคนิคการเสริมข้อมูล 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 ตามภาพประกอบ 38



ภาพประกอบ 38 ตัวอย่างรูปภาพก่อน - หลังทำการเติมรูปภาพ

3. การแบ่งข้อมูล (Data Partition)

ข้อมูลรูปภาพแบ่งออกเป็น 2 ส่วน คือ ข้อมูลสำหรับสร้างแบบจำลองการทำนาย (Test Set) และข้อมูลสำหรับทดสอบแบบจำลองการทำนาย (Train Set) ในสัดส่วน 80/20 ในแต่ละประเภทเมล็ดกาแฟ ตามตาราง 8

ตาราง 8 จำนวนรูปภาพเมล็ดกาแฟหลังจากแบ่งข้อมูล สำหรับสร้างแบบจำลอง และทดสอบแบบจำลอง

ลำดับที่	ประเภท	Train	Test
1	เมล็ดดำ (Black bean)	1,201	302
2	เมล็ดขึ้นรา (Moldy bean)	1,299	324
3	เมล็ดแตก (Bean fragment)	757	190
4	เมล็ดไม่สมบูรณ์ (Incompletely formed bean)	1,344	338
5	เมล็ดถูกแมลงทำลาย (Insect-damaged bean)	848	212
6	เมล็ดปกติ (Green Bean)	1,564	391

3.4 การสร้างแบบจำลอง

ในการวิจัยนี้ได้เลือกใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน จำนวน 3 รูปแบบ ได้แก่ ResNet50, ResNet101 และ VGG-16 สำหรับการเรียนรู้เพื่อจำแนกประเภทความบกพร่องของเมล็ดกาแฟ โดยสร้างแบบจำลองทั้งหมดจำนวน 6 แบบจำลอง ดังนี้

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

ในส่วนของแบบจำลองที่ 1, 2 และ 3 แบ่งชั้นผลลัพธ์เป็น 2 คลาส คือ เมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง โดยปรับขนาดรูปภาพเป็น 224×224 พิกเซล มีชั้น Flatten เพื่อแปลงข้อมูลจากรูปภาพที่เป็นเมตริกซ์หลายมิติ 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, เมล็ดไม่สมบูรณ์, เมล็ดแตก, เมล็ดถูกแมลงทำลาย และเมล็ดปกติ โดยปรับขนาดรูปภาพเป็น 224×224 พิกเซล มีชั้น Flatten เพื่อแปลงข้อมูลจากรูปภาพที่เป็นเมตริกซ์หลายมิติ 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

3.5 การประเมินผลประสิทธิภาพของแบบจำลอง

การวัดประสิทธิภาพของแบบจำลองที่สร้างขึ้นด้วยเทคนิคต่างๆ เพื่อดูประสิทธิภาพในการจำแนกประเภท ได้กำหนดเกณฑ์ในการประเมินประสิทธิภาพโดยใช้ ค่าความแม่นยำ (Accuracy), Precision, Recall และ F1-Score



บทที่ 4

ผลการดำเนินงานวิจัย

ในการวิจัยเรื่องโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟครั้งนี้ ผู้วิจัยดำเนินการวิจัยโดยศึกษาตามขั้นตอนและกระบวนการต่าง ๆ และได้มีการประเมินประสิทธิภาพของแบบจำลอง เพื่อให้เป็นไปตามวัตถุประสงค์ของการวิจัยตามที่ตั้งเป้าหมายไว้ โดยมีแบบจำลองทั้งหมด 6 แบบจำลอง ได้แก่


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

4.1 สถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

จากภาพประกอบ 39 และ ตาราง 9 ที่แสดงค่า Accuracy และ Loss ระหว่างการสร้างแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรมแบบ ResNet50 เพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ในแต่ละรอบ ผลที่ได้พบว่าค่า Accuracy ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.8729 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.5088 เปรียบเทียบกับค่า Accuracy ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.9943 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.9925

ค่า Loss ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.4014 และบนชุดข้อมูลตรวจสอบ เท่ากับ 2.2223 เปรียบเทียบกับค่า Loss ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.0171 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.0214

ดังนั้น จากค่า Accuracy และ Loss ที่ได้ในแต่ละรอบการเรียนรู้ แสดงให้เห็นว่าแบบจำลองนี้มีแนวโน้มการเรียนรู้ที่ดีขึ้น มีการปรับปรุงความแม่นยำของแบบจำลองและลดความผิดพลาดในขณะเดียวกัน ตามค่า Accuracy บนชุดข้อมูลตรวจสอบที่เพิ่มสูงขึ้น และค่า Loss บนชุดข้อมูลตรวจสอบที่ลดลง



ภาพประกอบ 39 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

ตาราง 9 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

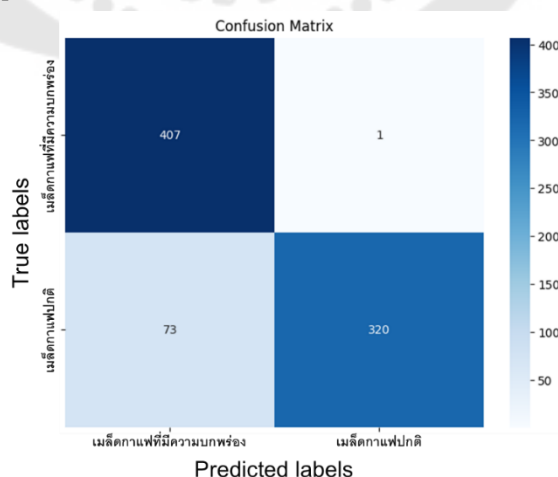
Epoch	Model Loss	Model Accuracy	Validation Loss	Validation Accuracy
1	0.4014	0.8729	2.2223	0.5088
2	0.1250	0.9524	2.2070	0.5088
3	0.0944	0.9656	1.8352	0.5100
4	0.1149	0.9596	3.1987	0.5088
5	0.0867	0.9713	1.5700	0.5100
6	0.1040	0.9675	1.1921	0.5362
7	0.0797	0.9754	0.6134	0.7088
8	0.0570	0.9801	3.0810	0.5525
9	0.0368	0.9871	3.7727	0.5950
10	0.1750	0.9584	144.7864	0.5250
11	0.0938	0.9678	10.8312	0.5800
12	0.0473	0.9823	2.5008	0.7175
13	0.0457	0.9864	0.6350	0.8763
14	0.0432	0.9877	0.1362	0.9613
15	0.0451	0.9855	0.0469	0.9825
16	0.0379	0.9868	0.0267	0.9937
17	0.0292	0.9877	0.0248	0.9912
18	0.0409	0.9864	0.0242	0.9900
19	0.0279	0.9899	0.0401	0.9875
20	0.0234	0.9918	0.0338	0.9887
21	0.0243	0.9924	0.0196	0.9950
22	0.0214	0.9921	0.0240	0.9925
23	0.0229	0.9915	0.0298	0.9900
24	0.0209	0.9927	0.0267	0.9912
25	0.0231	0.9934	0.0288	0.9887
26	0.0172	0.9953	0.0176	0.9950
27	0.0218	0.9921	0.0188	0.9937
28	0.0203	0.9915	0.0194	0.9937
29	0.0188	0.9943	0.0299	0.9850
30	0.0171	0.9943	0.0214	0.9925

จากตาราง 10 ซึ่งแสดงคะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร่อง สามารถสรุปได้ว่าแบบจำลองนี้มีค่า Accuracy อยู่ที่ 0.91 และสามารถจำแนกเมล็ดกาแฟที่มีความบดพร่องได้ดีมากกว่าเมล็ดกาแฟปกติ

ตาราง 10 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร่อง

	precision	recall	f1-score	accuracy
เมล็ดกาแฟปกติ	1.00	0.81	0.90	
เมล็ดกาแฟที่มีความบดพร่อง	0.85	1.00	0.92	
weighted avg	0.92	0.91	0.91	0.91

จากภาพประกอบ 40 แสดงผลลัพธ์ซึ่งได้มาจากการทำนายชุดข้อมูลทดสอบในรูปแบบ Confusion Matrix ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร่อง ทายเมล็ดกาแฟปกติถูกต้อง 320 ภาพ ทายผิด 73 ภาพ และทายเมล็ดกาแฟที่มีความบดพร่องถูก 407 ภาพ ทายผิด 1 ภาพ




ภาพประกอบ 40 Confusion Matrix ของของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร่อง

4.2 สถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

จากภาพประกอบ 41 และ ตาราง 11 ซึ่งแสดงค่า Accuracy และ Loss ระหว่างการสร้างแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรมแบบ ResNet101 เพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ในแต่ละรอบ ผลที่ได้พบว่าค่า Accuracy ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.8975 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.4913 เปรียบเทียบกับค่า Accuracy ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.9836 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.9887

ค่า Loss ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.3829 และบนชุดข้อมูลตรวจสอบ เท่ากับ 1.0838 เปรียบเทียบกับค่า Loss ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.0405 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.0367

ดังนั้น จากค่า Accuracy และ Loss ที่ได้ในแต่ละรอบการเรียนรู้ แสดงให้เห็นว่าแบบจำลองนี้มีแนวโน้มการเรียนรู้ที่ดีขึ้น มีการปรับปรุงความแม่นยำของแบบจำลองและลดความผิดพลาดในขณะเดียวกัน ตามค่า Accuracy บนชุดข้อมูลตรวจสอบที่เพิ่มสูงขึ้น และค่า Loss บนชุดข้อมูลตรวจสอบที่ลดลง



ภาพประกอบ 41 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

ตาราง 11 Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง


Epoch	Model Loss	Model Accuracy	Validation Loss	Validation Accuracy
1	0.3829	0.8975	1.0838	0.4913
2	0.1134	0.9581	3.5908	0.4913
3	0.0740	0.9757	3.9682	0.4913
4	0.1134	0.9612	109.9390	0.5100
5	0.2777	0.9467	0.8565	0.3063
6	0.1437	0.9571	1.2871	0.4913
7	0.1454	0.9445	1.4405	0.4913
8	0.0910	0.9625	2.8401	0.4900
9	0.0937	0.9694	1.6309	0.5150
10	0.5399	0.9599	1.9240	0.4938
11	0.0920	0.9688	0.9644	0.6425
12	0.0942	0.9726	0.5767	0.8075
13	0.1038	0.9732	0.2939	0.9025
14	0.0630	0.9776	0.1432	0.9500
15	0.0846	0.9710	0.0797	0.9725
16	0.0746	0.9751	0.0664	0.9762
17	0.0760	0.9722	0.0561	0.9812
18	0.0551	0.9804	0.0408	0.9850
19	0.0707	0.9823	0.0477	0.9825
20	0.0496	0.9833	0.0518	0.9812
21	0.0365	0.9871	0.0578	0.9762
22	0.0399	0.9871	0.0637	0.9750
23	0.0527	0.9820	0.0445	0.9850
24	0.0422	0.9858	0.0456	0.9800
25	0.0361	0.9877	0.0367	0.9887
26	0.0392	0.9861	0.0538	0.9800
27	0.0330	0.9890	0.0388	0.9875
28	0.0466	0.9830	0.0616	0.9787
29	0.0570	0.9804	0.0459	0.9812
30	0.0405	0.9836	0.0367	0.9887

จากตาราง 12 ซึ่งแสดงคะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง สามารถสรุปได้ว่า แบบจำลองนี้มีค่า Accuracy อยู่ที่ 0.89 และสามารถจำแนกเมล็ดกาแฟที่มีความบกพร่องได้ดีมากกว่าเมล็ดกาแฟปกติ

ตาราง 12 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

	precision	recall	f1-score	accuracy
เมล็ดกาแฟปกติ	1.00	0.77	0.87	
เมล็ดกาแฟที่มีความบกพร่อง	0.82	1.00	0.90	
weighted avg	0.91	0.89	0.88	0.89

จากภาพประกอบ 42 แสดงผลลัพธ์ซึ่งได้มาจากการทำนายชุดข้อมูลทดสอบในรูปแบบ Confusion Matrix ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ทายเมล็ดกาแฟปกติถูกต้อง 302 ภาพ ทายผิด 91 ภาพ และทายเมล็ดกาแฟที่มีความบกพร่องถูก 407 ภาพ ทายผิด 1 ภาพ




ภาพประกอบ 42 Confusion Matrix ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

4.3 สถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

จากภาพประกอบ 43 และ ตาราง 13 ซึ่งแสดงค่า Accuracy และ Loss ระหว่างการสร้างแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรมแบบ VGG-16 เพื่อจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ในแต่ละรอบ ผลที่ได้พบว่าค่า Accuracy ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.7168 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.8125 เปรียบเทียบกับค่า Accuracy ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.9934 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.9787

ค่า Loss ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.5668 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.4118 เปรียบเทียบกับค่า Loss ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.0216 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.0594

ดังนั้น จากค่า Accuracy และ Loss ที่ได้ในแต่ละรอบการเรียนรู้ แสดงให้เห็นว่าแบบจำลองนี้มีแนวโน้มการเรียนรู้ที่ดีขึ้น มีการปรับปรุงความแม่นยำของแบบจำลองและลดความผิดพลาดในขณะเดียวกัน ตามค่า Accuracy บนชุดข้อมูลตรวจสอบที่เพิ่มสูงขึ้น และค่า Loss บนชุดข้อมูลตรวจสอบที่ลดลง



ภาพประกอบ 43 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

ตาราง 13 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ
สถาปัตยกรรมแบบ VGG16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

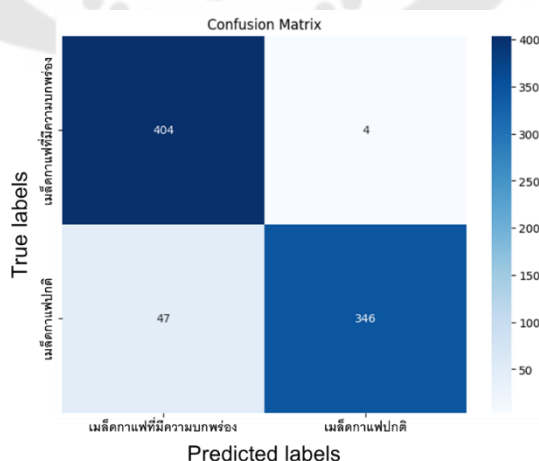
Epoch	Model Loss	Model Accuracy	Validation Loss	Validation Accuracy
1	0.5668	0.7168	0.4118	0.8125
2	0.3599	0.8423	0.1982	0.9150
3	0.3272	0.8650	0.2047	0.9312
4	0.2074	0.9199	0.1523	0.9362
5	0.1930	0.9259	0.2430	0.8888
6	0.1764	0.9306	0.1672	0.9275
7	0.1688	0.9379	0.2073	0.9237
8	0.1620	0.9385	0.2098	0.9388
9	0.1301	0.9549	0.3607	0.8525
10	0.1039	0.9603	0.1634	0.9300
11	0.0626	0.9786	0.0854	0.9688
12	0.0604	0.9808	0.0648	0.9762
13	0.0498	0.9820	0.0696	0.9800
14	0.0498	0.9839	0.0647	0.9762
15	0.0506	0.9820	0.0850	0.9663
16	0.0405	0.9861	0.0571	0.9800
17	0.0361	0.9880	0.0727	0.9762
18	0.0398	0.9855	0.0551	0.9800
19	0.0337	0.9874	0.0626	0.9800
20	0.0289	0.9886	0.0684	0.9700
21	0.0270	0.9899	0.0578	0.9762
22	0.0313	0.9886	0.0625	0.9800
23	0.0276	0.9896	0.0616	0.9775
24	0.0249	0.9921	0.0546	0.9787
25	0.0255	0.9924	0.0632	0.9812
26	0.0293	0.9899	0.0614	0.9787
27	0.0257	0.9912	0.0656	0.9762
28	0.0252	0.9924	0.0789	0.9800
29	0.0261	0.9909	0.0585	0.9787
30	0.0216	0.9934	0.0594	0.9787

จากตาราง 14 ซึ่งแสดงคะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง สามารถสรุปได้ว่าแบบจำลองนี้มีค่า Accuracy อยู่ที่ 0.94 และสามารถจำแนกเมล็ดกาแฟที่มีความบกพร่องได้ดีมากกว่าเมล็ดกาแฟปกติ

ตาราง 14 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

	precision	recall	f1-score	accuracy
เมล็ดกาแฟปกติ	0.99	0.88	0.93	
เมล็ดกาแฟที่มีความบกพร่อง	0.90	0.99	0.94	
weighted avg	0.94	0.94	0.94	0.94

จากภาพประกอบ 44 แสดงผลลัพธ์ซึ่งได้มาจากการทำนายชุดข้อมูลทดสอบในรูปแบบ Confusion Matrix ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ทายเมล็ดกาแฟปกติถูกต้อง 346 ภาพ ทายผิด 47 ภาพ และทายเมล็ดกาแฟที่มีความบกพร่องถูก 404 ภาพ ทายผิด 4 ภาพ




ภาพประกอบ 44 Confusion Matrix ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง

4.4 สถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

จากภาพประกอบ 45 และ ตาราง 15 ซึ่งแสดงค่า Accuracy และ Loss ระหว่างการสร้างแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรมแบบ ResNet50 เพื่อจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ ในแต่ละรอบ ผลที่ได้พบว่าค่า Accuracy ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.7790 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.1748 เปรียบเทียบกับค่า Accuracy ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.9912 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.9659

ค่า Loss ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 7.8722 และบนชุดข้อมูลตรวจสอบ เท่ากับ 7.8722 เปรียบเทียบกับค่า Loss ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.0285 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.1277

ดังนั้น จากค่า Accuracy และ Loss ที่ได้ในแต่ละรอบการเรียนรู้ แสดงให้เห็นว่าแบบจำลองนี้มีการเรียนรู้ที่ดีขึ้นตามค่า Accuracy บนชุดข้อมูลตรวจสอบที่เพิ่มขึ้น และค่า Loss บนชุดข้อมูลตรวจสอบที่ลดลง ถึงแม้ว่าค่า Accuracy ของชุดข้อมูลฝึกสอนจะมีค่าสูงกว่าชุดข้อมูลตรวจสอบ แต่ไม่มีความแตกต่างกันมากนัก และ ค่า Loss ของชุดข้อมูลฝึกสอนมีค่าต่ำกว่าชุดข้อมูลตรวจสอบ แต่ก็ไม่มีความแตกต่างกันมากเช่นเดียวกัน หมายความว่าแบบจำลองนี้ไม่เกิดการ Overfitting



ภาพประกอบ 45 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

ตาราง 15 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ
สถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออก
จากเมล็ดปกติ

Epoch	Model Loss	Model Accuracy	Validation Loss	Validation Accuracy
1	0.7535	0.7790	7.8722	0.1748
2	0.2763	0.9046	4.0589	0.1748
3	0.2036	0.9273	6.0680	0.2257
4	0.1718	0.9397	3.3848	0.1748
5	0.1331	0.9529	4.6376	0.2378
6	0.1272	0.9567	4.5329	0.3721
7	0.1166	0.9606	4.3407	0.4178
8	0.1106	0.9652	5.8480	0.4693
9	0.1088	0.9652	11.1010	0.4149
10	0.1627	0.9626	5.0844	0.4543
11	0.1046	0.9693	2.4863	0.6806
12	0.0598	0.9790	1.1485	0.8166
13	0.0508	0.9829	0.2910	0.9242
14	0.0449	0.9845	0.1200	0.9566
15	0.0435	0.9852	0.1254	0.9624
16	0.0425	0.9868	0.1293	0.9595
17	0.0332	0.9885	0.1378	0.9601
18	0.0332	0.9883	0.1358	0.9601
19	0.0376	0.9868	0.1383	0.9601
20	0.0275	0.9899	0.1459	0.9589
21	0.0274	0.9902	0.1344	0.9635
22	0.0283	0.9914	0.1290	0.9641
23	0.0287	0.9904	0.1207	0.9659
24	0.0218	0.9921	0.1220	0.9653
25	0.0244	0.9911	0.1157	0.9659
26	0.0280	0.9917	0.1172	0.9659
27	0.0309	0.9902	0.1196	0.9653
28	0.0243	0.9938	0.1187	0.9647
29	0.0237	0.9928	0.1225	0.9653
30	0.0285	0.9912	0.1277	0.9659

จากตาราง 16 ซึ่งแสดงคะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ สามารถสรุปได้ว่า แบบจำลองนี้มีค่า Accuracy อยู่ที่ 0.97 และสามารถจำแนกเมล็ดดำ, เมล็ดปกติ และเมล็ดถูกแมลงทำลาย ได้ดีที่สุดตามลำดับ

ตาราง 16 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ


	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	
weighted avg	0.97	0.97	0.97	0.97

จากภาพประกอบ 46 แสดงผลลัพธ์ซึ่งได้มาจากการทำนายชุดข้อมูลทดสอบในรูปแบบ Confusion Matrix ของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ แบ่งออกเป็น

- เมล็ดดำ ทายถูกต้อง 298 ภาพ ทายผิดเป็นเมล็ดขึ้นรา 4 ภาพ
- เมล็ดขึ้นรา ทายถูกต้อง 319 ภาพ ทายผิดเป็นเมล็ดดำ 1 ภาพ และเมล็ดไม่สมบูรณ์ 4 ภาพ
- เมล็ดแตก ทายถูกต้อง 181 ภาพ ทายผิดเป็นเมล็ดถูกแมลงทำลาย 8 ภาพ และเมล็ดขึ้นรา 1 ภาพ
- เมล็ดไม่สมบูรณ์ ทายถูกต้อง 318 ภาพ ทายผิดเป็นเมล็ดปกติ 5 ภาพ และเมล็ดขึ้นรา 15 ภาพ
- เมล็ดถูกแมลงทำลาย ทายถูกต้อง 203 ภาพ ทายผิดเป็นเมล็ดแตก 9 ภาพ

- เมล็ดปกติ ทายถูกต้อง 378 ภาพ ทายผิดเป็นเมล็ดไม่สมบูรณ์ 7 ภาพ และเมล็ดขึ้น

รา 6 ภาพ




ภาพประกอบ 46 Confusion Matrix ของของสถาปัตยกรรมแบบ ResNet50 โดยจำแนกประเภท ความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

4.5 สถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

จากภาพประกอบ 47 และ ตาราง 17 ซึ่งแสดงค่า Accuracy และ Loss ระหว่างการสร้างแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรมแบบ ResNet101 เพื่อจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ ในแต่ละรอบ ผลที่ได้พบว่าค่า Accuracy ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.7653 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.1748 เปรียบเทียบกับค่า Accuracy ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.9942 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.9635

ค่า Loss ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.7786 และบนชุดข้อมูลตรวจสอบ เท่ากับ 7.5802 เปรียบเทียบกับค่า Loss ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.0173 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.1516

ดังนั้น จากค่า Accuracy และ Loss ที่ได้ในแต่ละรอบการเรียนรู้ แสดงให้เห็นว่าในช่วงแรกของรอบการเรียนรู้ ค่า Accuracy บนชุดข้อมูลตรวจสอบอยู่ในระดับน้อยมากแต่เมื่อเข้าสู่รอบการเรียนรู้ที่ 9 เป็นต้นไปค่าเริ่มเพิ่มขึ้น ส่วนค่า Loss ในช่วงแรกของรอบการเรียนรู้บนชุดข้อมูลตรวจสอบมีค่าที่สูง แต่เมื่อเข้าสู่รอบการเรียนรู้ที่ 9 เป็นต้นไปค่าเริ่มลดลงเช่นเดียวกัน แสดงให้เห็นว่าแบบจำลองนี้มีแนวโน้มของเรียนรู้ที่ดีขึ้น



ภาพประกอบ 47 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

ตาราง 17 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ
สถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท
ออกจากเมล็ดปกติ

Epoch	Model Loss	Model Accuracy	Validation Loss	Validation Accuracy
1	0.7786	0.7653	7.5802	0.1748
2	0.2894	0.9036	11.4981	0.1748
3	0.1908	0.9328	26.3238	0.1748
4	0.1789	0.9404	24.3179	0.1748
5	0.1616	0.9506	147.3353	0.1748
6	0.1472	0.9521	12.8104	0.1753
7	0.1699	0.9512	774.0162	0.1753
8	0.1957	0.9407	104.8293	0.2263
9	0.1267	0.9557	8.5872	0.4300
10	0.0905	0.9688	5.2864	0.5446
11	0.0624	0.9776	4.3855	0.6256
12	0.0525	0.9832	2.5243	0.7025
13	0.0441	0.9845	0.7368	0.8495
14	0.0425	0.9858	0.2555	0.9334
15	0.0355	0.9870	0.1669	0.9520
16	0.0356	0.9881	0.1463	0.9589
17	0.0299	0.9902	0.1519	0.9560
18	0.0270	0.9912	0.1620	0.9520
19	0.0249	0.9915	0.1572	0.9560
20	0.0230	0.9921	0.1780	0.9497
21	0.0241	0.9923	0.1509	0.9601
22	0.0191	0.9932	0.1473	0.9601
23	0.0205	0.9934	0.1462	0.9583
24	0.0213	0.9931	0.1464	0.9612
25	0.0195	0.9931	0.1472	0.9601
26	0.0193	0.9929	0.1471	0.9601
27	0.0180	0.9941	0.1486	0.9601
28	0.0200	0.9931	0.1486	0.9606
29	0.0180	0.9942	0.1469	0.9624
30	0.0173	0.9942	0.1516	0.9635

จากตาราง 18 ซึ่งแสดงคะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ สามารถสรุปได้ว่า แบบจำลองนี้มีค่า Accuracy อยู่ที่ 0.96 และสามารถจำแนกเมล็ดดำ, เมล็ดปกติ และเมล็ดไม่สมบูรณ์ ได้ดีที่สุดในลำดับ ในทางกลับกันเมล็ดแตก เป็นประเภทที่แบบจำลองยังจำแนกได้ไม่ดีเมื่อเทียบกับเมล็ดประเภทอื่น ๆ

ตาราง 18 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

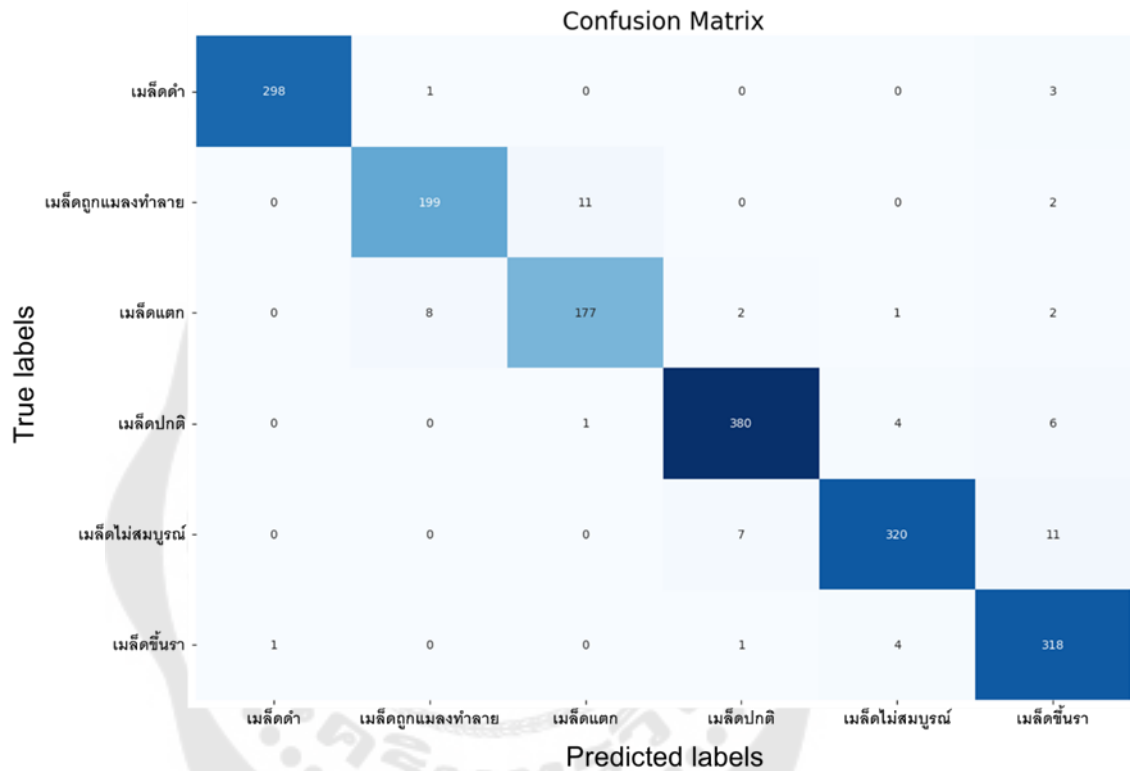
	precision	recall	f1-score	accuracy
เมล็ดดำ	1.00	0.99	0.99	
เมล็ดขึ้นรา	0.93	0.98	0.95	
เมล็ดแตก	0.94	0.93	0.93	
เมล็ดไม่สมบูรณ์	0.97	0.95	0.96	
เมล็ดถูกแมลงทำลาย	0.96	0.94	0.95	
เมล็ดปกติ	0.97	0.97	0.97	
				0.96
weighted avg	0.96	0.96	0.96	

จากภาพประกอบ 48 แสดงผลลัพธ์ซึ่งได้มาจากการทำนายชุดข้อมูลทดสอบในรูปแบบ Confusion Matrix ของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ แบ่งออกเป็น

- เมล็ดดำ ทายถูกต้อง 298 ภาพ ทายผิดเป็นเมล็ดถูกแมลงทำลาย 1 ภาพ และเมล็ดขึ้นรา 3 ภาพ
- เมล็ดขึ้นรา ทายถูกต้อง 318 ภาพ ทายผิดเป็นเมล็ดดำ 1 ภาพ เมล็ดปกติ 1 ภาพ และเมล็ดไม่สมบูรณ์ 4 ภาพ
- เมล็ดแตก ทายถูกต้อง 177 ภาพ ทายผิดเป็นเมล็ดถูกแมลงทำลาย 8 ภาพ เมล็ดปกติ 2 ภาพ เมล็ดไม่สมบูรณ์ 1 ภาพ และเมล็ดขึ้นรา 2 ภาพ
- เมล็ดไม่สมบูรณ์ ทายถูกต้อง 318 ภาพ ทายผิดเป็นเมล็ดปกติ 5 ภาพ และเมล็ดขึ้นรา 15 ภาพ

- เมล็ดถูกแมลงทำลาย ทายถูกต้อง 199 ภาพ ทายผิดเป็นเมล็ดแตก 11 ภาพ และ เมล็ดขึ้นรา 2 ภาพ

- เมล็ดปกติ ทายถูกต้อง 380 ภาพ ทายผิดเป็นเมล็ดแตก 1 ภาพ เมล็ดไม่สมบูรณ์ 4 ภาพ และเมล็ดขึ้นรา 6 ภาพ




ภาพประกอบ 48 Confusion Matrix ของของสถาปัตยกรรมแบบ ResNet101 โดยจำแนกประเภท ความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

4.6 สถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

จากภาพประกอบ 49 และ ตาราง 19 ซึ่งแสดงค่า Accuracy และ Loss ระหว่างการ สร้างแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรมแบบ VGG-16 เพื่อจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ ในแต่ละรอบ ผล ที่ได้พบว่าค่า Accuracy ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 0.5268 และบนชุด ข้อมูลตรวจสอบ เท่ากับ 0.6927 เปรียบเทียบกับค่า Accuracy ในการเรียนรู้รอบที่ 30 บนชุด ข้อมูลฝึกสอน เท่ากับ 0.9740 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.9398

ค่า Loss ในการเรียนรู้รอบที่ 1 บนชุดข้อมูลฝึกสอน เท่ากับ 1.1471 และบนชุดข้อมูล ตรวจสอบ เท่ากับ 0.7624 เปรียบเทียบกับค่า Loss ในการเรียนรู้รอบที่ 30 บนชุดข้อมูลฝึกสอน เท่ากับ 0.0761 และบนชุดข้อมูลตรวจสอบ เท่ากับ 0.1689

ดังนั้น จากค่า Accuracy และ Loss ที่ได้ในแต่ละรอบการเรียนรู้ แสดงให้เห็นว่า แบบจำลองนี้มีการเรียนรู้ที่ดีขึ้นตามค่า Accuracy บนชุดข้อมูลตรวจสอบที่เพิ่มขึ้น และค่า Loss บนชุดข้อมูลตรวจสอบที่ลดลง



ภาพประกอบ 49 กราฟแสดงค่า Loss และ ค่า Accuracy ระหว่างการเรียนรู้ของสถาปัตยกรรม แบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

ตาราง 19 ค่า Loss และ ค่า Accuracy ของแบบจำลอง และชุดข้อมูลตรวจสอบของ
สถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออก
จากเมล็ดปกติ

Epoch	Model Loss	Model Accuracy	Validation Loss	Validation Accuracy
1	1.1471	0.5268	0.7624	0.6927
2	0.7374	0.7207	0.6133	0.7807
3	0.5214	0.8152	0.3940	0.8571
4	0.3867	0.8650	0.3385	0.8709
5	0.3480	0.8725	0.3407	0.8750
6	0.3198	0.8846	0.2607	0.9057
7	0.2849	0.8954	0.2983	0.8918
8	0.2635	0.9066	0.2134	0.9242
9	0.2527	0.9069	0.2245	0.9144
10	0.2369	0.9171	0.2455	0.9161
11	0.1501	0.9468	0.1973	0.9282
12	0.1335	0.9518	0.1895	0.9300
13	0.1277	0.9540	0.1726	0.9387
14	0.1169	0.9590	0.1911	0.9352
15	0.1085	0.9626	0.1782	0.9421
16	0.1145	0.9596	0.1785	0.9381
17	0.1006	0.9643	0.1765	0.9369
18	0.0990	0.9640	0.1728	0.9369
19	0.0941	0.9675	0.1696	0.9392
20	0.0936	0.9659	0.1804	0.9381
21	0.0820	0.9714	0.1641	0.9421
22	0.0815	0.9722	0.1591	0.9439
23	0.0819	0.9718	0.1594	0.9444
24	0.0797	0.9721	0.1643	0.9421
25	0.0778	0.9717	0.1651	0.9450
26	0.0734	0.9722	0.1653	0.9421
27	0.0796	0.9725	0.1639	0.9462
28	0.0765	0.9728	0.1723	0.9473
29	0.0776	0.9725	0.1687	0.9410
30	0.0761	0.9740	0.1689	0.9398

จากตาราง 20 ซึ่งแสดงคะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ สามารถสรุปได้ว่า แบบจำลองนี้มีค่า Accuracy อยู่ที่ 0.95 และสามารถจำแนกเมล็ดดำ, เมล็ดปกติ และเมล็ดถูกแมลงทำลายได้ดีที่สุดตามลำดับ ในทางกลับกันเมล็ดแตก เป็นประเภทที่แบบจำลองยังจำแนกได้ไม่ดีเมื่อเทียบกับเมล็ดประเภทอื่น ๆ

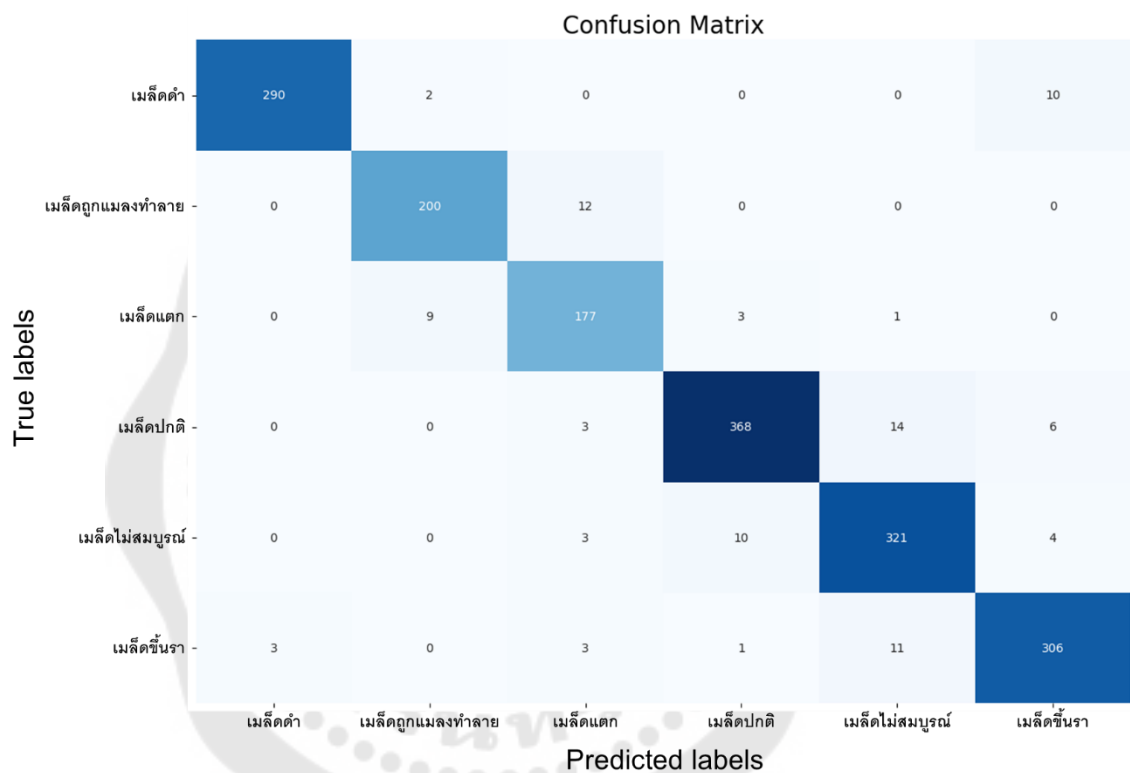
ตาราง 20 คะแนนการวัดผลจากแบบจำลองด้วยชุดข้อมูลทดสอบ ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

	precision	recall	f1-score	accuracy
เมล็ดดำ	0.99	0.96	0.97	
เมล็ดขึ้นรา	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	

จากภาพประกอบ 50 แสดงผลลัพธ์ซึ่งได้มาจากการทำนายชุดข้อมูลทดสอบในรูปแบบ Confusion Matrix ของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ แบ่งออกเป็น

- เมล็ดดำ ทายถูกต้อง 290 ภาพ ทายผิดเป็นเมล็ดถูกแมลงทำลาย 2 ภาพ และเมล็ดขึ้นรา 10 ภาพ
- เมล็ดขึ้นรา ทายถูกต้อง 306 ภาพ ทายผิดเป็นเมล็ดดำ 3 ภาพ เมล็ดแตก 3 ภาพ เมล็ดปกติ 1 ภาพ และเมล็ดไม่สมบูรณ์ 11 ภาพ
- เมล็ดแตก ทายถูกต้อง 177 ภาพ ทายผิดเป็นเมล็ดถูกแมลงทำลาย 9 ภาพ เมล็ดปกติ 3 ภาพ และเมล็ดไม่สมบูรณ์ 1 ภาพ

- เมล็ดไม่สมบูรณ์ ทายถูกต้อง 321 ภาพ ทายผิดเป็นเมล็ดแตก 3 ภาพ เมล็ดปกติ 10 ภาพ และเมล็ดขึ้นรา 4 ภาพ
- เมล็ดถูกแมลงทำลาย ทายถูกต้อง 200 ภาพ ทายผิดเป็นเมล็ดแตก 12 ภาพ
- เมล็ดปกติ ทายถูกต้อง 368 ภาพ ทายผิดเป็นเมล็ดแตก 3 ภาพ เมล็ดไม่สมบูรณ์ 14 ภาพ และเมล็ดขึ้นรา 6 ภาพ



ภาพประกอบ 50 Confusion Matrix ของของสถาปัตยกรรมแบบ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดปกติ

4.7 เปรียบเทียบประสิทธิภาพแบบจำลอง โดยจำแนกเมล็ดกาแฟปกติและเมล็ดกาแฟที่มีความบกพร่อง

ผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรม ResNet50, ResNet101 และ VGG-16 โดยจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบกพร่อง ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ที่วัดผลจากชุดข้อมูลทดสอบ พบว่าแบบจำลอง VGG-16 ได้ค่า Accuracy สูงที่สุด คือ 0.94 รองลงมาคือ ResNet50 ได้ค่า Accuracy 0.91 และลำดับสุดท้ายคือ ResNet101 ได้ค่า Accuracy 0.89

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

4.8 เปรียบเทียบประสิทธิภาพแบบจำลอง โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ

ผลของแบบจำลองที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้สถาปัตยกรรม ResNet50, ResNet101 และ VGG-16 โดยจำแนกประเภทความบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ ด้วยค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score 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 ที่ต่ำกว่าสองแบบจำลองเมื่อใช้จำแนกประเภทเมล็ดแตก, เมล็ดขึ้นรา และ เมล็ดไม่สมบูรณ์

ดังนั้นแบบจำลอง ResNet50 อาจเป็นตัวเลือกที่ดีที่สุดสำหรับการจำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ เนื่องจากมีค่า Accuracy สูงสุด และค่า Precision, Recall, และ F1-Score ที่ดีสำหรับการจำแนกประเภททั้งหมด

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

ในการวิจัยเรื่องโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อการจำแนกประเภทความบกพร่องของเมล็ดกาแฟครั้งนี้ ผู้วิจัยได้ดำเนินการวิจัยโดยสร้างแบบจำลองสำหรับทำนายผลของการจำแนกประเภทความบกพร่อง โดยมีการใช้วิธีการเตรียมข้อมูลด้วยการเสริมข้อมูลรูปภาพและการเติมรูปภาพ โดยใช้สถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้แก่ สถาปัตยกรรมแบบ ResNet50, สถาปัตยกรรมแบบ ResNet101 และสถาปัตยกรรมแบบ VGG-16 จากนั้นได้มีการประเมินผลและนำประสิทธิภาพของแบบจำลองต่าง ๆ มาเปรียบเทียบกัน โดยสามารถแบ่งหัวข้อสรุปผลได้ดังนี้

5.1 สรุปผลการวิจัย

ในงานวิจัยนี้มีการสร้างแบบจำลองเพื่อจำแนกประเภทความบกพร่องของเมล็ดกาแฟทั้งหมด 6 แบบจำลอง ได้แก่

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

โดยในแต่ละแบบจำลองใช้การเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน มีการใช้เทคนิคการเสริมข้อมูลและการเติมรูปภาพเพื่อเพิ่มประสิทธิภาพให้กับแบบจำลอง และมีการตั้งค่าพารามิเตอร์แต่ละค่าให้เหมือนกันเพื่อนำมาเปรียบเทียบประสิทธิภาพของแบบจำลอง

แบ่งออกเป็น 2 รูปแบบ คือ 1) จำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร้อม 2) จำแนกประเภทความบดพร้อมของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ โดยแบบจำลองที่มีค่า Accuracy สูงที่สุดในการจำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร้อม คือแบบจำลองที่ใช้สถาปัตยกรรมแบบ VGG-16 ส่วนแบบจำลองที่มีค่า Accuracy สูงที่สุดในการจำแนกประเภทความบดพร้อมของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ คือแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 ดังตาราง 21 และ 22 เปรียบเทียบค่า Accuracy และ Weight Average ของแบบจำลอง

ตาราง 21 ค่า Accuracy และ Weight Average ของแบบจำลองที่จำแนกเมล็ดกาแฟปกติ และเมล็ดกาแฟที่มีความบดพร้อม

Model	Weight Average	Weight Average	Weight Average	Accuracy
	Precision	Recall	F1-Score	
ResNet50	0.92	0.91	0.91	0.91
ResNet101	0.91	0.89	0.88	0.89
VGG-16	0.94	0.94	0.94	0.94

ตาราง 22 Accuracy และ Weight Average ของแบบจำลองที่จำแนกประเภทความบดพร้อมของเมล็ดกาแฟ 5 ประเภท ออกจากเมล็ดกาแฟปกติ

Model	Weight Average	Weight Average	Weight Average	Accuracy
	Precision	Recall	F1-Score	
ResNet50	0.97	0.97	0.97	0.97
ResNet101	0.96	0.96	0.96	0.96
VGG-16	0.95	0.95	0.95	0.95

5.2 อภิปรายผล

ในงานวิจัยนี้จากผลลัพธ์ที่ได้ของค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ของแบบจำลองทั้งหมด โดยแบ่งออกเป็น 2 รูปแบบ คือ 1) จำแนกเมล็ดกาแพปกติ และเมล็ดกาแพที่มีความบกพร่อง พบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ VGG-16 ได้ประสิทธิภาพในการทำนายที่ดีมากกว่า ResNet50 และ ResNet101 อาจด้วยหลายปัจจัยที่ทำให้ VGG-16 มีประสิทธิภาพดีที่สุดในครั้งแรกคือ ค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ที่ได้ค่าสูงสุดในทุกประเภท หมายความว่า VGG-16 มีความแม่นยำในการจำแนกประเภทได้ดีที่สุดในกรณีนี้ อย่างไรก็ตามด้วยโครงสร้างของ VGG-16 ที่มีชั้นคอนโวลูชัน ลึกมากถึง 16 ชั้น ซึ่งช่วยให้แบบจำลองมีความสามารถในการเรียนรู้ลักษณะของภาพได้อย่างละเอียด และสามารถจำแนกคุณลักษณะของรูปภาพได้อย่างมีประสิทธิภาพ 2) จำแนกประเภทข้อบกพร่องของเมล็ดกาแพ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดไม่สมบูรณ์, เมล็ดแตก และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดปกติ พบว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ ResNet50 มีประสิทธิภาพในการทำนายที่ดีกว่า ResNet101 และ VGG-16 ปัจจัยที่อาจทำให้ ResNet50 มีประสิทธิภาพดีที่สุดในครั้งแรกคือ ค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ที่ได้ค่าสูงสุดในทุกประเภท หมายความว่า ResNet50 มีความแม่นยำในการจำแนกประเภทได้ดีที่สุดในกรณีนี้ และเนื่องจาก ResNet ใช้ Residual connections ที่ช่วยให้สามารถฝึกแบบจำลองที่มีความลึกได้มากขึ้น จึงทำให้ ResNet50 จำแนกประเภทได้อย่างมีประสิทธิภาพ

หากพิจารณาจากรูปภาพเมล็ดกาแพโดยแบ่งตามรูปแบบการศึกษา คือ

1. จำแนกเมล็ดกาแพปกติ และเมล็ดกาแพที่มีความบกพร่อง ที่สถาปัตยกรรมแบบ VGG-16 ได้ประสิทธิภาพดีที่สุดในครั้งแรก พบว่าแบบจำลองมีความสามารถในการจำแนกเมล็ดกาแพที่มีความบกพร่องได้ดีกว่าเมล็ดกาแพปกติ เนื่องจากรูปภาพเมล็ดกาแพปกติที่ถูกทำนายผิดมีการเว้นแหว่งของรูปภาพ หรือมีรูสีดำบนรูปภาพ เนื่องจากภาพต้นฉบับที่ได้มานั้นมีการลบแสงและเงาของรูปภาพออกไป ทำให้บางส่วนที่เป็นพื้นที่สีเข้ม มีดของเมล็ดกาแพปกตินั้นโดนลบออกไปด้วยตามภาพประกอบ 51 ดังนั้นอาจทำให้เป็นสาเหตุหนึ่งที่แบบจำลองจำแนกรูปภาพเมล็ดกาแพที่มีความบกพร่องได้ดีกว่า



ภาพประกอบ 51 ตัวอย่างรูปภาพเมล็ดกาแฟปกติ ที่ถูกทำนายผิดเป็นเมล็ดกาแฟที่มีความ
บกร่อง

2. จำแนกประเภทข้อบกพร่องของเมล็ดกาแฟ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดไม่สมบูรณ์, เมล็ดแตก และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดปกติ ที่สถาปัตยกรรมแบบ ResNet50 ได้ประสิทธิภาพดีที่สุด พบว่าแบบจำลองมีความสามารถจำแนกประเภทเมล็ดดำได้ดีที่สุด รองลงมาเป็นประเภทเมล็ดปกติ ผู้วิจัยคาดว่าอาจเพราะคุณลักษณะของรูปภาพที่นำมาสร้างแบบจำลอง ที่มีความโดดเด่นคือ เมล็ดดำที่มีสีดำ ทึบมากกว่ารูปภาพประเภทอื่น ๆ และเมล็ดปกติที่มีความสมบูรณ์ของเมล็ดมากที่สุด ไม่มีรอยแตก รอยแมลงกัดแทะ หรือเจาะ ส่วนประเภทที่แบบจำลองยังจำแนกประเภทได้ไม่ดี คือ เมล็ดขึ้นรา เมล็ดแตก และเมล็ดไม่สมบูรณ์ โดยเมล็ดขึ้นราทำผิดเป็นเมล็ดไม่สมบูรณ์ ตามภาพประกอบ 52 อาจเพราะรูปภาพที่ถูกทำนายผิดมีส่วนที่เงาแห้งไปบริเวณขอบของเมล็ด เนื่องจากภาพต้นฉบับที่ได้มานั้นมีการลบแสงและเงาของรูปภาพออกไป ทำให้บางส่วนที่เป็นพื้นที่สีเข้ม มีดของเมล็ดกาแฟปกตินั้นโดนลบออกไปด้วย จึงดูเหมือนเป็นเมล็ดไม่สมบูรณ์



ภาพประกอบ 52 ตัวอย่างรูปภาพเมล็ดขึ้นรา ที่ถูกทำนายผิดเป็นเมล็ดไม่สมบูรณ์

ในส่วนของเมล็ดแตกที่ทำนายผิดเป็นเมล็ดถูกแมลงทำลาย ตามภาพประกอบ 53 อาจเพราะรูปภาพที่ถูกทำนายผิดมีส่วนที่เป็นรูสีดำเล็ก ๆ เนื่องจากภาพต้นฉบับที่ได้มานั้นมีการลบแสงและเงาของรูปภาพออกไป ทำให้มีลักษณะคล้ายกับเมล็ดถูกแมลงทำลาย



ภาพประกอบ 53 ตัวอย่างรูปภาพเมล็ดแตก ที่ถูกทำนายผิดเป็นเมล็ดถูกแมลงทำลาย

ในส่วนของเมล็ดไม่สมบูรณ์ที่ถูกทำนายผิดเป็นเมล็ดขึ้นรา ตามภาพประกอบ 54 อาจเพราะรูปภาพมีจุดเล็ก ๆ บนเมล็ดทำให้มีลักษณะคล้ายเมล็ดขึ้นรา



ภาพประกอบ 54 ตัวอย่างรูปภาพเมล็ดไม่สมบูรณ์ ที่ถูกทำนายผิดเป็นเมล็ดขึ้นรา

จากการวิจัยพบว่าการจำแนกประเภทเมล็ดกาแฟออกเป็น 6 ประเภท ได้ประสิทธิภาพที่ดีกว่าการจำแนกประเภทเมล็ดกาแฟออกเป็น 2 ประเภท เมื่อเปรียบเทียบ ค่าความแม่นยำ (Accuracy), ค่าประมาณ Precision, Recall และ F1-Score ผู้วิจัยมีความคิดเห็นว่าการจำแนกประเภทออกเป็น 6 ประเภททำให้มีความหลากหลายของลักษณะมากกว่า อาจช่วยให้แบบจำลองจำแนกประเภทได้แม่นยำมากขึ้น เนื่องจากสามารถเรียนรู้ลักษณะที่สำคัญของแต่ละประเภทได้ดีและละเอียดขึ้น

ดังนั้นหากต้องการนำแบบจำลองที่สร้างไปใช้เพื่อจำแนกเมล็ดกาแฟจริง ผู้วิจัยมีความเห็นว่าแบบจำลองที่ใช้สถาปัตยกรรมแบบ VGG-16 มีความสามารถในการจำแนกเมล็ด

กาแพปกติ และเมล็ดกาแพที่มีความบกพร่อง หรือเมล็ดกาแพที่ต้องการจำแนกออกเป็น 2 ประเภทได้ดี ส่วนสถาปัตยกรรมแบบ ResNet50 มีความสามารถในการจำแนกประเภท ข้อบกพร่องของเมล็ดกาแพ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดไม่สมบูรณ์, เมล็ดแตก และเมล็ดถูกแมลงทำลาย ออกจากเมล็ดปกติมากกว่าสถาปัตยกรรมแบบอื่น ๆ ซึ่งได้ผลลัพธ์เป็นที่น่าพอใจ ได้ค่า Accuracy เท่ากับ 0.97 ซึ่งพบว่าได้ค่า Accuracy ที่มากกว่า งานวิจัยเรื่อง การจำแนกคุณภาพของเมล็ดกาแพโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (ชาคริต เสรีพงษ์, 2561) โดยจำแนกประเภทเมล็ดกาแพออกเป็น 6 ประเภทเช่นเดียวกัน และใช้เทคนิคการเสริมข้อมูล ซึ่งผลลัพธ์ของงานวิจัยนี้พบว่าสถาปัตยกรรมแบบ ResNet50 ได้ประสิทธิภาพในการจำแนกประเภทที่ดีที่สุด โดยค่า Accuracy เท่ากับ 0.77 ผู้วิจัยมีความคิดเห็นว่าการนำเทคนิคเติมรูปภาพเข้ามาช่วยสามารถทำให้แบบจำลองมีประสิทธิภาพในการจำแนกประเภทความบกพร่องของเมล็ดกาแพได้ดีขึ้น เนื่องจากรูปภาพทุกรูปถูกปรับให้มีขนาดที่เท่ากัน ช่วยให้แบบจำลองเรียนรู้คุณลักษณะของรูปภาพแต่ละประเภทได้ง่ายขึ้น

5.3 ข้อเสนอแนะ

แนวทางสำหรับการพัฒนาประสิทธิภาพของแบบจำลองในอนาคต มีดังนี้

1. ควรแบ่งข้อมูล Train และ Test ก่อนทำ Data Augmentation เพื่อป้องกันการเกิดปัญหา Data Leakage คือทำให้รูปภาพที่ใช้ในการประเมินแบบจำลองมีลักษณะคล้ายกันหรือมีความเชื่อมโยงกันระหว่าง Train Set และ Test Set ผลลัพธ์ของแบบจำลองอาจมีความแม่นยำมากเกินไปหรือไม่ถูกต้อง เนื่องจากแบบจำลองอาจได้รับข้อมูลที่เคยเห็นมาก่อนหน้าแล้ว ดังนั้นการแบ่งข้อมูลก่อนจะช่วยทำให้ความน่าเชื่อถือในการทดสอบแบบจำลองเพิ่มขึ้น และช่วยเพิ่มความถูกต้องของการประเมินประสิทธิภาพของแบบจำลอง

2. ในงานวิจัยนี้เนื่องจากสถาปัตยกรรมแบบ ResNet50 ได้ประสิทธิภาพการจำแนกประเภทข้อบกพร่องของเมล็ดกาแพ ซึ่งแบ่งออกเป็น 5 ประเภท คือ เมล็ดดำ, เมล็ดขึ้นรา, เมล็ดไม่สมบูรณ์, เมล็ดแตก และเมล็ดถูกแมลงทำลายได้ดีที่สุด แต่เมื่อพิจารณากราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรม VGG-16 ก็พบว่าแนวโน้มการเรียนรู้ของแบบจำลองนี้ มีการเรียนรู้ที่ค่อนข้างดี หากมีการนำแบบจำลองมาลองปรับพารามิเตอร์บางตัว เช่น Learning Rate หรือ Optimizer อาจทำให้ประสิทธิภาพของ VGG-16 ดีมากขึ้นได้

บรรณานุกรม

- Febriana, A., Muchtar, K., Dawood, R., & Lin, C. Y. (2022, 16-18 June 2022). USK-COFFEE Dataset: A Multi-Class Green Arabica Coffee Bean Dataset for Deep Learning. 2022 IEEE International Conference on Cybernetics and Computational Intelligence (CyberneticsCom),
- He, K., Zhang, X., Ren, S., & Sun, J. (2016, 27-30 June 2016). Deep Residual Learning for Image Recognition. 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR),
- Hortinela, C. C., & Tupas, K. J. R. (2022, 1-3 July 2022). Classification of Cacao Beans Based on their External Physical Features Using Convolutional Neural Network. 2022 IEEE Region 10 Symposium (TENSymp),
- Huang, N. F., Chou, D. L., & Lee, C. A. (2019, 27-29 July 2019). Real-Time Classification of Green Coffee Beans by Using a Convolutional Neural Network. 2019 3rd International Conference on Imaging, Signal Processing and Communication (ICISPC),
- Pinto, C., Furukawa, J., Fukai, H., & Tamura, S. (2017, 16-18 Aug. 2017). Classification of Green coffee bean images basec on defect types using convolutional neural network (CNN). 2017 International Conference on Advanced Informatics, Concepts, Theory, and Applications (ICAICTA),
- Simonyan, K., & Zisserman, A. (2014). Very deep convolutional networks for large-scale image recognition. *arXiv preprint arXiv:1409.1556*.
- Srikanth Tammina. (2019). Transfer learning using VGG-16 with Deep Convolutional Neural Network for Classifying Images. *International Journal of Scientific and Research Publications (IJSRP)*, 9(10), 143-150.
<https://doi.org/http://dx.doi.org/10.29322/IJSRP.9.10.2019.p9420>
- Xing, W., & Du, D. (2018, 03/15). Dropout Prediction in MOOCs: Using Deep Learning for

Personalized Intervention. *Journal of Educational Computing Research*, 57, 073563311875701. <https://doi.org/10.1177/0735633118757015>

แสงดาว เตือนแจ่ม. (2021). การสกัดและคัดเลือกคุณลักษณะของเมล็ดกาแฟเพื่อจำแนกประเภทตามคุณภาพ ด้วยการประมวลผลภาพถ่าย (สารนิพนธ์ปริญญาโทมหาบัณฑิต, มหาวิทยาลัยศรีนครินทรวิโรฒ, กรุงเทพฯ). สืบค้นจาก [http://ir-](http://ir-thesis.swu.ac.th/dspace/bitstream/123456789/1165/1/gs601130299.pdf)

[thesis.swu.ac.th/dspace/bitstream/123456789/1165/1/gs601130299.pdf](http://ir-thesis.swu.ac.th/dspace/bitstream/123456789/1165/1/gs601130299.pdf)

ชาคริต เสรีพงษ์. (2561). การจำแนกคุณภาพของเมล็ดกาแฟโดยใช้โครงข่ายประสาทเทียมแบบสังวัตนาการ (สารนิพนธ์ปริญญาโทมหาบัณฑิต, มหาวิทยาลัยศรีนครินทรวิโรฒ, กรุงเทพฯ).

สืบค้นจาก https://msds.science.swu.ac.th/wp-content/uploads/2021/08/9_Chakrit-Paper_74_85.pdf

พระราชบัญญัติมาตรฐานสินค้าเกษตร พ.ศ. 2551. (2562). ราชกิจจานุเบกษา (เล่ม 136 ตอนพิเศษ 6 ง, น. 5-17). สืบค้นจาก <https://ratchakitcha.soc.go.th/documents/17069467.pdf>

ประวัติผู้เขียน

