



การจำแนกโรคใบชาด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน
TEA LEAF DISEASES CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK



ชญญา วิภูษิตบวรวิทย์

การจำแนกโรคเฝ้าระวังด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน



ชัญญา วิชาชีตบริรักษ์

สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2567
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

TEA LEAF DISEASES CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK



CHANYA WIPOOSITBORRIRAK

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
2024
Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การจำแนกโรคไบซาด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน

ของ

ชัญญา วิภูษิตบริษัท

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

วิทยาศาสตรมหาบัณฑิต สาขาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญากุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

..... อาจารย์ที่ปรึกษา
(อาจารย์ ดร.บรรพตวี คมขำ)

..... ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.จันตรี ผลประเสริฐ)

..... กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.ศิริสรพ เหล่าหะเกียรติ)

ชื่อเรื่อง	การจำแนกโรคใบชาด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน
ผู้วิจัย	ชญญา วิภูษิตบริรักษ์
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2567
อาจารย์ที่ปรึกษา	อาจารย์ ดร.บรรพตริ คมขำ

ปัจจุบันการประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน มีบทบาทสำคัญในการวินิจฉัยโรคพืชเพื่อเพิ่มประสิทธิภาพการผลิตทางการเกษตร งานวิจัยนี้จึงมุ่งวิเคราะห์เปรียบเทียบประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน สำหรับการจำแนกโรคใบชา โดยศึกษาผลกระทบของเทคนิคการปรับสีภาพ 4 รูปแบบ ได้แก่ การใช้ภาพต้นฉบับ, การแปลงค่าสีเป็น HSI, การเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement และการปรับคอนทราสต์ด้วย CLAHE เพื่อค้นหาแนวทางที่เหมาะสมที่สุดสำหรับการนำไปใช้งานจริง ทั้งนี้ได้ใช้เทคนิคการถ่ายทอดการเรียนรู้ โดยเลือกแบบจำลอง DenseNet121, VGG16 และ EfficientNetB1 พร้อมปรับค่าพารามิเตอร์เพื่อเพิ่มประสิทธิภาพในการจำแนกโรค การประเมินผลแบบจำลองใช้ตัวชี้วัด Accuracy, Precision, Recall, F1-score และ Confusion Matrix ในการประมวลผลเพื่อนำมาเปรียบเทียบประสิทธิภาพของแต่ละเทคนิค ผลลัพธ์แสดงให้เห็นว่าแบบจำลองที่ใช้การเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement โดยใช้โมเดล VGG16 ให้ผลลัพธ์ดีที่สุด โดยมีค่า Accuracy 95.48%, Precision 95.93%, Recall 95.48% และ F1-score 95.42% ซึ่งเป็นแนวทางสำคัญในการพัฒนาระบบวินิจฉัยโรคใบชาที่มีความแม่นยำและเหมาะสมกับการใช้งานจริงในภาคเกษตรกรรม

คำสำคัญ: โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การจำแนกโรคใบชา, การปรับสีภาพ, การถ่ายทอดการเรียนรู้

Title	TEA LEAF DISEASES CLASSIFICATION USING CONVOLUTIONAL NEURAL NETWORK
Author	CHANYA WIPOOSITBORRIRAK
Degree	MASTER OF SCIENCE
Academic Year	2024
Advisor	Dr. Banphatree Khomkham

The application of artificial intelligence technology, particularly Convolutional Neural Networks, plays a significant role in plant disease diagnosis to enhance agricultural productivity. This research aims to comparatively analyze the performance of CNN models for tea leaf disease classification by studying the effects of four image color adjustment techniques: using original RGB images, converting RGB to HSI, enhancing contrast with Fuzzy Contrast Enhancement, and improving contrast with CLAHE. The goal is to determine the most effective approach for practical implementation. Transfer learning was employed using pre-trained models including DenseNet121, VGG16, and EfficientNetB1, with hyperparameter optimization for enhancing classification performance. The models were evaluated using performance metrics such as Accuracy, Precision, Recall, F1-score, and confusion matrix to compare the effectiveness of each technique. The results demonstrated that the model using Fuzzy Contrast Enhancement with VGG16 achieved the best performance, with an Accuracy of 95.48%, Precision of 95.93%, Recall of 95.48%, and F1-score of 95.42%. These findings highlight a promising approach for developing accurate and practical tea leaf disease diagnosis systems suitable for real-world agricultural applications

Keywords: Convolutional Neural Network, Tea Leaf Disease Classification, Image Color Adjustment, Transfer Learning

กิตติกรรมประกาศ

สารนิพนธ์ฉบับนี้สำเร็จลุล่วงด้วยความอนุเคราะห์และสนับสนุนจากบุคคลหลายท่านที่มีบทบาทสำคัญอย่างยิ่ง ผู้วิจัยขอกราบขอบพระคุณ อาจารย์ ดร.บรรพตริ คมขำ อาจารย์ที่ปรึกษา ซึ่งได้ให้คำปรึกษา แนะนำ และข้อเสนอแนะอันทรงคุณค่าในทุกขั้นตอนของการดำเนินงานวิจัย ตั้งแต่การวางแผน ออกแบบการทดลอง ไปจนถึงการวิเคราะห์และสรุปผล ทำให้ผู้วิจัยสามารถพัฒนาสารนิพนธ์ฉบับนี้ให้บรรลุวัตถุประสงค์ได้ตามที่ตั้งใจไว้

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.จันตรี ผลประเสริฐ และ ผู้ช่วยศาสตราจารย์ ดร.ศิริสรพร เหล่าหะเกียรติ คณะกรรมการสอบสารนิพนธ์ ที่ได้กรุณาใช้เวลาอันมีค่าในการพิจารณา ให้คำแนะนำ และข้อเสนอแนะที่เป็นประโยชน์อย่างยิ่งในการปรับปรุงและพัฒนาคุณภาพของสารนิพนธ์ฉบับนี้ให้มีความสมบูรณ์ยิ่งขึ้น

ในโอกาสนี้ ผู้วิจัยขอแสดงความขอบคุณอย่างสูงต่อ คณะอาจารย์ทุกท่านในสาขาวิชา ที่ได้ถ่ายทอดความรู้และประสบการณ์ในวิชาต่าง ๆ ตลอดระยะเวลาการศึกษา อันเป็นพื้นฐานสำคัญที่ช่วยเสริมสร้างทักษะและความเข้าใจในศาสตร์ที่เกี่ยวข้องกับงานวิจัยนี้

นอกจากนี้ ผู้วิจัยขอขอบคุณ คุณพ่อ คุณแม่ และครอบครัว ที่เป็นกำลังใจและสนับสนุนทั้งทางด้านจิตใจและทรัพยากรตลอดระยะเวลาการศึกษา รวมถึง เพื่อน ๆ และผู้มีส่วนเกี่ยวข้องทุกท่านที่ให้ความช่วยเหลือ ไม่ว่าจะโดยตรงหรือโดยอ้อม ทั้งในการเรียนและการดำเนินงานวิจัย อันเป็นพลังขับเคลื่อนสำคัญที่ทำให้ผู้วิจัยสามารถฝ่าฟันอุปสรรคและความท้าทายต่าง ๆ ได้อย่างสำเร็จลุล่วง

ผู้วิจัยมีความหวังเป็นอย่างยิ่งว่าสารนิพนธ์ฉบับนี้จะเป็นประโยชน์ต่อวงการวิชาการ และผู้ที่สนใจในสาขาที่เกี่ยวข้องไม่มากนักน้อย สำหรับข้อบกพร่องที่อาจเกิดขึ้นในสารนิพนธ์ฉบับนี้ ผู้วิจัยขอน้อมรับไว้แต่เพียงผู้เดียว และยินดีรับฟังความคิดเห็นและข้อเสนอแนะจากทุกท่านเพื่อใช้เป็นแนวทางในการพัฒนางานวิจัยในอนาคตต่อไป

ชญญา วิภูษิตบริรักษ์


สารบัญ

หน้า

บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ	ฉ
สารบัญ	ช
สารบัญตาราง	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตงานวิจัย	3
1.4 สมมติฐานงานวิจัย	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ	3
บทที่ 2 บรรณกรรมและงานวิจัยที่เกี่ยวข้อง	4
2.1 ทฤษฎีเกี่ยวกับโรคใบชา	4
2.2 ทฤษฎีที่เกี่ยวข้อง	8
2.2.1 การเสริมข้อมูล	8
2.2.2 การเรียนรู้ด้วยเครื่อง	9
2.2.3 การเรียนรู้เชิงลึก	10
2.2.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน	11
2.2.5 การถ่ายทอดการเรียนรู้	13

2.2.6 การประเมินผลแบบจำลอง.....	16
2.2.7 ทฤษฎี Fuzzy Logic - Image Contrast Enhancement.....	17
2.2.8 ระบบสี HSI.....	18
2.2.9 ระบบการปรับคอนทราสต์ภาพด้วย CLAHE.....	19
2.3 งานวิจัยที่เกี่ยวข้อง	20
บทที่ 3 วิธีดำเนินงานวิจัย	29
3.1 การออกแบบขั้นตอนในการดำเนินงานวิจัย.....	29
3.2 การได้มาซึ่งข้อมูล.....	31
3.2.1 การสำรวจข้อมูลเบื้องต้น	31
3.2.2 แหล่งที่มาของข้อมูล	32
3.3 การจัดเตรียมข้อมูล.....	32
3.3.1 การทำความสะอาดข้อมูล.....	32
3.3 การจัดการข้อมูล	34
3.3.1 การปรับขนาดภาพ.....	35
3.3.2 การปรับสีภาพ	35
3.3.3 การแบ่งชุดข้อมูล	39
3.3.4 การเพิ่มข้อมูล	39
3.4 การสร้างแบบจำลอง.....	40
3.5 การประเมินผลประสิทธิภาพของแบบจำลอง	41
3.6 สรุปวิธีดำเนินงานวิจัย.....	42
บทที่ 4 ผลการดำเนินงานวิจัย.....	44
4.1 แบบการทดลองที่ใช้ภาพต้นฉบับ	44
4.2 แบบการทดลองที่ใช้เทคนิค Fuzzy Contrast Enhancement.....	49
4.3 แบบการทดลองที่แปลงภาพจาก RGB เป็น HSI	54

4.4 แบบการทดลองที่ใช้เทคนิคการเพิ่มความคมชัดด้วย CLAHE	58
4.4 เปรียบเทียบผลการจำแนกของแต่ละแบบจำลอง	63
บทที่ 5 สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ	65
5.1 สรุปผลการวิจัย	65
5.2 อภิปรายผล	66
5.3 ข้อเสนอแนะ	67
บรรณานุกรม	69



สารบัญตาราง

หน้า

ตาราง 1 ตารางเปรียบเทียบประสิทธิภาพของโมเดลในวิธีต่างๆ.....	21
ตาราง 2 ค่าความแม่นยำต่อจำนวน Epochs ที่แตกต่างกัน.....	22
ตาราง 3 ความแม่นยำในการจำแนกประเภทด้วยการปรับแต่งพารามิเตอร์.....	26
ตาราง 4 การวัดค่าการเรียกคืน ความแม่นยำ และค่า F1-score จากกระบวนการปรับแต่งพารามิเตอร์ของแบบจำลอง.....	26
ตาราง 5 สรุปงานวิจัยที่เกี่ยวข้องในงานวิจัย.....	27
ตาราง 6 แสดงข้อมูลจำนวนใบชา 8 ประเภท	31
ตาราง 7 ข้อมูลแสดงจำนวนรูปภาพใบชาหลังการสำรวจและทำความสะอาดชุดข้อมูล.....	34
ตาราง 8 จำนวนรูปภาพใบชาหลังจากแบ่งข้อมูลสำหรับสร้างแบบจำลอง และทดสอบแบบจำลอง	39
ตาราง 9 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121.....	45
ตาราง 10 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16	46
ตาราง 11 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1.....	48
ตาราง 12 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121.....	49
ตาราง 13 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16	51
ตาราง 14 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1.....	53
ตาราง 15 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121.....	54
ตาราง 16 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16	56

ตาราง 17 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1.....	57
ตาราง 18 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121.....	59
ตาราง 19 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16	60
ตาราง 20 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1.....	62
ตาราง 21 แสดงผลลัพธ์การประเมินประสิทธิภาพของแบบจำลองแต่ละประเภท โดยพิจารณาค่า Accuracy.....	63



สารบัญรูปภาพ

หน้า

ภาพประกอบ 1 ตัวอย่างใบชาที่เป็นโรคใบจุดขาว.....	5
ภาพประกอบ 2 ตัวอย่างใบชาที่เป็นโรคใบจุดสาหร่าย	5
ภาพประกอบ 3 ตัวอย่างใบชาที่เป็นโรคใบจุดตานก.....	6
ภาพประกอบ 4 ตัวอย่างใบชาที่เป็นโรคใบเหา	6
ภาพประกอบ 5 ตัวอย่างใบชาที่เป็นโรคใบไหม้สีน้ำตาล.....	7
ภาพประกอบ 6 ตัวอย่างใบชาที่เป็นโรคใบแอนแทรคโนส.....	7
ภาพประกอบ 7 ตัวอย่างใบชาที่เป็นโรคใบสีแดง.....	8
ภาพประกอบ 8 ตัวอย่างการเสริมข้อมูลในแบบต่างๆ.....	9
ภาพประกอบ 9 ความสัมพันธ์ของปัญญาประดิษฐ์ การเรียนรู้ด้วยเครื่อง และการเรียนรู้เชิงลึก .	10
ภาพประกอบ 10 การเรียนรู้เชิงลึก	11
ภาพประกอบ 11 โครงข่ายประสาทเทียมแบบคอนโวลูชัน	12
ภาพประกอบ 12 สถาปัตยกรรม DenseNet121	13
ภาพประกอบ 13 สถาปัตยกรรม VGG-16.....	14
ภาพประกอบ 14 สถาปัตยกรรม EfficientNetB1	15
ภาพประกอบ 15 Confusion Matrix.....	16
ภาพประกอบ 16 Fussy-based method	18
ภาพประกอบ 17 ภาพผลลัพธ์ Accuracy Analysis และ Loss Analysis.....	24
ภาพประกอบ 18 The training accuracy curves: (a) SE-ResNet50 accuracy curves; (b) Comparison model accuracy curves.	25
ภาพประกอบ 19 แผนภาพแสดงขั้นตอนการทำงานของโมเดล	30
ภาพประกอบ 20 แสดงถึงสัดส่วนรูปภาพของใบชา 8 ประเภท	32
ภาพประกอบ 21 ใบปกติที่ไม่สมบูรณ์.....	33
ภาพประกอบ 22 โรคจุดขาวที่ไม่สมบูรณ์.....	33

ภาพประกอบ 23 โรคแอนแทรกซ์ในสัตว์ที่ไม่สมบูรณ์	33
ภาพประกอบ 24 แสดงถึงสัดส่วนรูปภาพของใบชา 8 ประเภทหลังทำความสะอาดข้อมูล	34
ภาพประกอบ 25 ภาพต้นฉบับตัวอย่างใบชา.....	35
ภาพประกอบ 26 ภาพตัวอย่างใบชาตามประเภทที่ทำการแปลงสีด้วยเทคนิค Fuzzy.....	36
ภาพประกอบ 27 ภาพตัวอย่างใบชาตามประเภทที่ทำการแปลงสีเป็น HSI	37
ภาพประกอบ 28 ภาพตัวอย่างใบชาตามประเภทที่ปรับสีด้วย CLAHE.....	37
ภาพประกอบ 29 แสดงภาพตัวอย่างหลังการปรับแต่งด้วยเทคนิคต่าง ๆ พร้อมกราฟ Histogram ของแต่ละภาพ	38
ภาพประกอบ 30 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121	44
ภาพประกอบ 31 Confusion Matrix ของสถาปัตยกรรม DenseNet121.....	45
ภาพประกอบ 32 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16.....	46
ภาพประกอบ 33 Confusion Matrix ของสถาปัตยกรรม VGG16.....	47
ภาพประกอบ 34 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1	47
ภาพประกอบ 35 Confusion Matrix ของสถาปัตยกรรม InceptionResNetV2.....	48
ภาพประกอบ 36 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121	49
ภาพประกอบ 37 Confusion Matrix ของสถาปัตยกรรม DenseNet121.....	50
ภาพประกอบ 38 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16.....	51
ภาพประกอบ 39 Confusion Matrix ของสถาปัตยกรรม VGG16.....	52
ภาพประกอบ 40 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1	52
ภาพประกอบ 41 Confusion Matrix ของสถาปัตยกรรม EfficientNetB1.....	53
ภาพประกอบ 42 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121	54

ภาพประกอบ 43 Confusion Matrix ของสถาปัตยกรรม DenseNet121.....	55
ภาพประกอบ 44 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16.....	55
ภาพประกอบ 45 Confusion Matrix ของสถาปัตยกรรม VGG 16	56
ภาพประกอบ 46 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1	57
ภาพประกอบ 47 Confusion Matrix ของสถาปัตยกรรม EfficientNetB1.....	58
ภาพประกอบ 48 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121	58
ภาพประกอบ 49 Confusion Matrix ของสถาปัตยกรรม DenseNet121.....	60
ภาพประกอบ 50 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16.....	60
ภาพประกอบ 51 Confusion Matrix ของสถาปัตยกรรม VGG16.....	61
ภาพประกอบ 52 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1	61
ภาพประกอบ 53 Confusion Matrix ของสถาปัตยกรรม EfficientNetB1	62

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ชาามีต้นกำเนิดในจีนเมื่อกว่า 5,000 ปีก่อน โดยตำนานเล่าว่าจักรพรรดิเสินหนง (Shennong) ค้นพบโดยบังเอิญเมื่อไปชาดกลลงในน้ำร้อน จากนั้นชาได้กลายเป็นส่วนหนึ่งของวัฒนธรรมที่เกี่ยวข้องกับสุขภาพและความสงบ ภายหลังแพร่หลายไปยังญี่ปุ่น เกาหลี และอินเดีย โดยแต่ละประเทศพัฒนาเอกลักษณ์เฉพาะ เช่น พิธีชงชาในญี่ปุ่น และ Masala Chai ในอินเดีย ในศตวรรษที่ 16-17 ชาเดินทางสู่ยุโรปโดยเฉพาะอังกฤษ ซึ่งชาได้รับความนิยมและกลายเป็นส่วนสำคัญของ Afternoon Tea เชื่อมโยงกับชนชั้นและวัฒนธรรม ในปัจจุบัน วัฒนธรรมการดื่มชาแพร่หลายทั่วโลกในรูปแบบต่าง ๆ เช่น ชาเขียว ชาดำ และชาอู่หลง ไม่เพียงเพื่อรสชาติ แต่ยังสะท้อนถึงสุขภาพ ความผ่อนคลาย และการมีปฏิสัมพันธ์ทางสังคมที่สืบทอดมาหลายยุคสมัย (Swiggy, 2024)

สำหรับในประเทศไทย การปลูกชาเริ่มต้นอย่างจริงจังในช่วง ศตวรรษที่ 20 เมื่อชาวจีนอพยพเข้ามาตั้งรกรากในภาคเหนือ โดยเฉพาะในพื้นที่ดอยต่าง ๆ เช่น ดอยแม่สลอง จังหวัดเชียงราย ซึ่งเป็นชุมชนของชาวจีนยูนนานที่นำพันธุ์ชาอู่หลง (Oolong) เข้ามาปลูก ชาพันธุ์นี้ได้รับความนิยมเนื่องจากสภาพภูมิอากาศของภาคเหนือเหมาะสมกับการปลูกชา อีกทั้งมีการถ่ายทอดเทคนิคการผลิตชาแบบจีนดั้งเดิม การสนับสนุนจากภาครัฐและความต้องการในตลาดทั้งภายในและต่างประเทศ ส่งผลให้พื้นที่ในภาคเหนือของไทยกลายเป็นศูนย์กลางการปลูกชาอู่หลง ชาเขียว และชาดำ ปัจจุบันการปลูกชาในไทยไม่เพียงมุ่งเน้นที่การบริโภคภายในประเทศ แต่ยังเป็นส่วนหนึ่งของการส่งออก และมีการส่งเสริมการท่องเที่ยวเชิงเกษตร เช่น การเยี่ยมชมไร่ชาและชิมชาตามสถานที่ท่องเที่ยวบนดอยต่าง ๆ (Aseancafeshow, 2021)

ปัจจุบันตลาดชาและผลิตภัณฑ์ของชาไทยยังคงเติบโตอย่างต่อเนื่องตั้งแต่ปี 2022 ซึ่งมียอดการส่งออกอยู่ที่ 119% สำหรับแนวโน้มในอนาคตช่วงปี 2024-2025 การเติบโตของตลาดชาทั้งในและต่างประเทศคาดว่าจะอยู่ที่ 2-2.6% ต่อปี โดยมีการเน้นสุขภาพและการตลาดออนไลน์มากขึ้น ทำให้อุตสาหกรรมการผลิตชาเป็นหนึ่งในธุรกิจสำคัญที่มีบทบาทต่อเศรษฐกิจในหลายประเทศ รวมถึงประเทศไทย ซึ่งการเพาะปลูกใบชาต้องพึ่งพาสภาพแวดล้อมที่เหมาะสมและการดูแลรักษาอย่างใกล้ชิด อย่างไรก็ตาม ปัญหาหลักที่เกษตรกรผู้ปลูกชามักประสบคือโรคใบชาที่มีสาเหตุจากเชื้อรา แบคทีเรีย หรือแมลง ทำให้ผลผลิตลดลงและต้นทุนการผลิตสูงขึ้น (StrategyHelix, 2024)

การตรวจสอบและวินิจฉัยโรคใบชาแบบดั้งเดิมอาศัยแรงงานมนุษย์ ซึ่งต้องใช้เวลาและความเชี่ยวชาญสูง แต่ไม่สามารถรับประกันความถูกต้องได้ในทุกกรณี ปัญหานี้นำไปสู่ความจำเป็นในการใช้เทคโนโลยีเพื่อเพิ่มประสิทธิภาพในการวินิจฉัย ปัญญาประดิษฐ์ (Artificial Intelligence) โดยเฉพาะ โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ได้เข้ามามีบทบาทสำคัญ เนื่องจาก CNN สามารถวิเคราะห์ภาพถ่ายใบชาได้

อย่างแม่นยำ ช่วยให้เกษตรกรสามารถเฝ้าระวังและจัดการกับโรคได้อย่างรวดเร็ว ลดความเสียหายและเพิ่มคุณภาพผลผลิต

การพัฒนานวัตกรรมด้าน AI โดยเน้นที่ การเรียนรู้เชิงลึก (Deep Learning) กำลังได้รับความสนใจอย่างมากในภาคการเกษตร เนื่องจากโมเดลเหล่านี้สามารถเรียนรู้และจดจำรายละเอียดในภาพได้อย่างมีประสิทธิภาพ CNN ซึ่งเป็นหนึ่งในโมเดลที่ได้รับความนิยมมากที่สุดในงานด้านการจำแนกรูปภาพ มีความสามารถในการตรวจจับลักษณะสำคัญ เช่น ลักษณะของโรคบนใบชาที่อาจมองเห็นได้ยาก ทำให้ CNN เป็นเครื่องมือที่เหมาะสมอย่างยิ่งสำหรับการวินิจฉัยโรคใบชา

อย่างไรก็ตาม การสร้างโมเดลการเรียนรู้เชิงลึก ที่มีคุณภาพจำเป็นต้องใช้ชุดข้อมูลจำนวนมากเพื่อให้โมเดลเรียนรู้ได้อย่างครอบคลุม การนำเทคนิคการถ่ายทอดการเรียนรู้ (Transfer Learning) เข้ามาช่วย จะช่วยให้สามารถใช้ประโยชน์จากโมเดลสำเร็จรูปที่ผ่านการฝึกด้วยชุดข้อมูลขนาดใหญ่มาแล้ว เช่น VGG-16 โดยไม่จำเป็นต้องเริ่มฝึกโมเดลใหม่ตั้งแต่ต้น ทำให้ลดทั้งเวลาและทรัพยากร อีกทั้ง Data Augmentation ยังเป็นเทคนิคสำคัญที่ใช้สร้างความหลากหลายของข้อมูล เช่น การหมุนภาพและการปรับขนาด เพื่อป้องกันการเกิด overfitting ซึ่งเป็นปัญหาที่พบได้บ่อยในงานที่มีข้อมูลจำกัด

ดังนั้น การศึกษานี้มุ่งเน้นการพัฒนาและปรับปรุงแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน สำหรับการจำแนกโรคใบชา โดยประยุกต์ใช้ทั้ง Transfer Learning และ Data Augmentation เพื่อเพิ่มความแม่นยำในการวินิจฉัย ลดเวลาและภาระงานของเกษตรกร และช่วยเพิ่มผลผลิตอย่างมีประสิทธิภาพ ด้วยการผสานเทคโนโลยีเหล่านี้ เกษตรกรจะสามารถตรวจสอบและแก้ไขปัญหาได้อย่างรวดเร็ว ลดความเสี่ยงจากการสูญเสียผลผลิต และสร้างความยั่งยืนให้กับอุตสาหกรรมชาต่อไปในอนาคต

1.2 วัตถุประสงค์ของงานวิจัย

ในการทดลองผู้วิจัยได้ทำการตั้งความมุ่งหวังไว้ดังนี้

1. เพื่อพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน สำหรับการจำแนกประเภทของโรคใบชาอย่างมีประสิทธิภาพ
2. เพื่อศึกษาผลกระทบของกระบวนการปรับสีภาพในรูปแบบต่าง ๆ ได้แก่ ระบบสี RGB, การแปลงค่าสีเป็น HSI, การเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement และการปรับคอนทราสต์ด้วย CLAHE ต่อประสิทธิภาพของแบบจำลอง CNN ในการจำแนกโรคใบชา
3. เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง CNN ที่ใช้เทคนิคการถ่ายทอดการเรียนรู้จากโมเดล DenseNet121, VGG16 และ EfficientNetB1 ในการจำแนกโรคใบชา
4. เพื่อหาแนวทางที่เหมาะสมที่สุดสำหรับการนำไปพัฒนาระบบวินิจฉัยโรคใบชาในภาคเกษตรกรรมดิจิทัล เพื่อเพิ่มความแม่นยำและความสามารถในการนำไปใช้งานจริง

1.3 ขอบเขตงานวิจัย

งานวิจัยนี้มีขอบเขตในการศึกษาและพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน สำหรับการจำแนกโรคใบชา โดยใช้ชุดข้อมูลภาพถ่ายใบชาที่ประกอบด้วย 8 ประเภท ได้แก่ ใบปกติ (Healthy), โรคจุดขาว (White Spot), โรคใบจุดสาหร่าย (Algal Leaf Spot), โรคใบจุดตานก (Bird Eye Spot), โรคใบเทา (Grey Light), โรคใบไหม้สีน้ำตาล (Brown Blight), โรคแอนแทรคโนส (Anthracnose) และโรคจุดใบสีแดง (Red Leaf Spot) โดยมีการดำเนินการดังนี้:

1. การปรับสีภาพใน 4 รูปแบบ ได้แก่ RGB, HSI, Fuzzy Contrast Enhancement และ CLAHE เพื่อศึกษาผลกระทบต่อประสิทธิภาพของแบบจำลอง
2. การเลือกใช้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ผ่านการฝึกด้วยชุดข้อมูลขนาดใหญ่ (ImageNet) ได้แก่ DenseNet121, VGG16 และ EfficientNetB1 ร่วมกับเทคนิค Transfer Learning และปรับแต่งโครงสร้างเลเยอร์ด้านบน (Top Layers) ให้เหมาะสมกับการจำแนกโรคใบชา
3. การประเมินผลแบบจำลองด้วยตัวชี้วัดทางสถิติ ได้แก่ Accuracy, Precision, Recall, F1-score และ Confusion Matrix เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองในแต่ละรูปแบบ

1.4 สมมติฐานงานวิจัย

1. การปรับสีภาพด้วยเทคนิค HSI, Fuzzy Contrast Enhancement และ CLAHE จะช่วยเพิ่มประสิทธิภาพของแบบจำลอง CNN ในการจำแนกโรคใบชาได้ดีกว่าการใช้ภาพต้นฉบับในระบบสี RGB
2. แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ใช้ EfficientNetB1 ร่วมกับ Transfer Learning จะมีประสิทธิภาพสูงกว่า DenseNet121 และ VGG16 ในการจำแนกโรคใบชา
3. การใช้เทคนิค Data Augmentation จะช่วยเพิ่มความหลากหลายของข้อมูลและลดปัญหา Overfitting ซึ่งส่งผลให้ประสิทธิภาพของแบบจำลองดีขึ้น
4. แบบจำลองที่ได้รับการพัฒนาจากกระบวนการปรับสีภาพและการเลือกโมเดลที่เหมาะสม จะสามารถนำไปประยุกต์ใช้ในระบบวินิจฉัยโรคใบชาในภาคเกษตรกรรมได้อย่างมีประสิทธิภาพและแม่นยำ

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถเพิ่มความแม่นยำในการตรวจสอบโรคและลดภาระในการทำงานของเกษตรกร
2. ช่วยให้การวินิจฉัยโรคเป็นไปอย่างรวดเร็วและลดค่าใช้จ่ายในการจำแนกโรคของใบชา
3. ช่วยลดความสูญเสียจากการระบาดของโรคในใบชา อีกทั้งเพิ่มคุณภาพของใบชา รวมถึงเพิ่มปริมาณผลผลิตให้ได้ตามความต้องการ
4. แบบจำลองที่สร้างขึ้น ที่สามารถนำไปประยุกต์ใช้กับการจำแนกโรคในพืชทางการเกษตรชนิดอื่นๆ ได้ในอนาคต
5. เพื่อเป็นแนวทางในการวิจัยด้านการเกษตรเชิงดิจิทัล

บทที่ 2

วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในการวิจัยครั้งนี้ จะกล่าวถึงองค์ความรู้ งานวิจัย และบทความที่ได้ศึกษาและมีความเกี่ยวข้องกับงานวิจัยดังนี้

1. ทฤษฎีเกี่ยวกับโรคใบชา
2. ทฤษฎีที่เกี่ยวข้อง
 - การเสริมข้อมูล (Data Augmentation)
 - การเรียนรู้ด้วยเครื่อง (Machine Learning)
 - การเรียนรู้เชิงลึก (Deep Learning)
 - โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network, CNN)
 - การถ่ายทอดการเรียนรู้ (Transfer Learning)
 - การประเมินผลแบบจำลอง (Model Evaluation)
 - ทฤษฎี Fuzzy Logic - Image Contrast Enhancement
 - ระบบสี HSI (Hue-Saturation-Intensity)
 - ระบบการปรับคอนทราสต์ภาพด้วย CLAHE (Contrast Limited Adaptive Histogram Equalization)
3. งานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีเกี่ยวกับโรคใบชา

การปลูกชามักประสบปัญหาการระบาดของโรคใบต่าง ๆ ซึ่งส่งผลต่อคุณภาพและปริมาณผลผลิต โดยโรคที่พบบ่อยในใบชา ได้แก่ โรคใบจุดขาว โรคใบจุดสาหร่าย โรคจุดนกพิราบ, โรคใบเทา, โรคใบไหม้สีน้ำตาล, โรคแอนแทรคโนส และ โรคใบจุดแดง ตามภาพประกอบ 1 (Ersenstein et al., 2022; Kilaru & MurthyRaju, 2022; USDA, 2024)

โรคใบจุดขาว

โรคใบจุดขาวเป็นโรคที่เกิดจากเชื้อราหรือจุลินทรีย์บางชนิด ทำให้เกิดจุดสีขาวกระจายอยู่บนผิวใบชา โดยเฉพาะบริเวณผิวด้านบนของใบ จุดที่เกิดขึ้นมักมีขนาดเล็กและอาจขยายใหญ่ขึ้นเมื่อโรครุนแรงขึ้น ใบที่ติดโรคอาจแสดงอาการเหลือง ชีด หรือหลุดร่วงก่อนเวลาอันควร ส่งผลให้ต้นชาอ่อนแอและมีผลกระทบต่อคุณภาพของผลผลิตในระยะยาว ตัวอย่างดังภาพประกอบ 1



ภาพประกอบ 1 ตัวอย่างใบชาที่เป็นโรควุ้นขาว

โรควุ้นสาหร่าย

โรควุ้นสาหร่าย หรือโรคตะไคร้ใบชา มีสาเหตุจากสาหร่ายในกลุ่ม *Cephaleuros* spp. ซึ่งพบได้บ่อยในพื้นที่ที่มีความชื้นสูง ลักษณะของโรคคือการเกิดจุดสีเขียวอมน้ำตาลหรือสีส้มแดงบนใบ บางครั้งพบเป็นแผ่นหรือคราบตะไคร้เกาะอยู่บนใบ โรคนี้มักไม่ทำให้ใบแห้งหรือเน่าโดยตรง แต่การปกคลุมของสาหร่ายทำให้การสังเคราะห์แสงลดลง ต้นชาจึงเติบโตช้าลง ตามภาพประกอบ 2



ภาพประกอบ 2 ตัวอย่างใบชาที่เป็นโรควุ้นสาหร่าย

โรคใบจุดตานก

โรคใบจุดตานกมีลักษณะเฉพาะคือจุดกลมที่มีวงขอบสีเข้มล้อมรอบจุดสีขาวหรือสีอ่อนอยู่ตรงกลาง คล้ายตาของนก ซึ่งเป็นที่มาของชื่อโรค โรคนี้เกิดจากเชื้อราที่เจริญเติบโตได้ดีในสภาพอากาศชื้น ทำให้ใบชามีประสิทธิภาพในการสังเคราะห์แสงลดลง และหากแพร่ระบาดมาก อาจส่งผลต่อปริมาณและคุณภาพของใบชา ตามภาพประกอบ 3



ภาพประกอบ 3 ตัวอย่างใบชาที่เป็นโรคใบจุดตานก

โรคใบเหา

โรคใบเหาเป็นโรคที่แสดงอาการโดยใบจะมีลักษณะซีดหรือเทาอ่อนคล้ายแสงจางกระจายบนผิวใบ อาจเกิดจากความผิดปกติของโครงสร้างใบหรือเชื้อราบางชนิด โรคนี้อาจทำให้ใบแห้งช้า ๆ และลดอัตราการเจริญเติบโตของต้นชาในระยะยาว โดยเฉพาะในสภาพแวดล้อมที่มีแสงน้อยหรือความชื้นสูง ตามภาพประกอบ 4



ภาพประกอบ 4 ตัวอย่างใบชาที่เป็นโรคใบเหา

โรคใบไหม้สีน้ำตาล

โรคใบไหม้สีน้ำตาลมักเกิดจากเชื้อราที่เจริญเติบโตในสภาพอากาศร้อนชื้น ลักษณะเด่นของโรคนี้คือการเกิดจุดสีน้ำตาลเข้มหรือสีคล้ายสนิมบนใบชา จุดอาจขยายใหญ่ขึ้นเรื่อย ๆ และลุกลามจนทำให้ใบแห้งกรอบและหลุดร่วง โรคนี้สามารถทำลายพุ่มใบอย่างรุนแรง และมีผลโดยตรงต่อการเก็บเกี่ยวใบชา ตามภาพประกอบ 5



ภาพประกอบ 5 ตัวอย่างใบชาที่เป็นโรคใบไหม้สีน้ำตาล

โรคแอนแทรคโนส

โรคแอนแทรคโนสเกิดจากเชื้อราในสกุล *Colletotrichum* ซึ่งเป็นเชื้อราที่พบได้ทั่วไปในพืชเกษตร ลักษณะอาการจะเป็นจุดกลมหรือไม่สม่ำเสมอบนใบ มีสีน้ำตาลถึงดำ ตรงกลางแห้ง และอาจมีวงขอบสีเหลืองล้อมรอบ จุดแผลจะค่อย ๆ ขยายและรวมกันกลายเป็นบริเวณกว้าง ทำให้ใบชาแห้งและหลุดร่วงเร็ว โรคนี้สามารถแพร่กระจายได้อย่างรวดเร็วในฤดูฝนหรือสภาพแวดล้อมชื้น ตามภาพประกอบ 6



ภาพประกอบ 6 ตัวอย่างใบชาที่เป็นโรคใบแอนแทรคโนส

โรคจุดใบสีแดง

โรคจุดใบสีแดงเป็นโรคที่แสดงลักษณะอาการเป็นจุดหรือแผลสีแดงอมน้ำตาลบนใบชา จุดอาจมีขนาดต่าง ๆ และกระจายทั่วบริเวณใบ อาจเกิดจากเชื้อราหรือภาวะเครียดจากสิ่งแวดล้อม เช่น ความร้อนหรือแสงแดดจัด ใบที่ได้รับผลกระทบจะสูญเสียประสิทธิภาพในการสังเคราะห์แสง และหากปล่อยไว้นานอาจทำให้ต้นชาทรุดโทรม ตามภาพประกอบ 7



ภาพประกอบ 7 ตัวอย่างใบชาที่เป็นโรคใบสีแดง

2.2 ทฤษฎีที่เกี่ยวข้อง

2.2.1 การเสริมข้อมูล


การเสริมข้อมูล เป็นเทคนิคที่ใช้ในงานประมวลผลภาพและการเรียนรู้ของเครื่อง (Machine Learning) โดยเฉพาะในการฝึกแบบจำลองโครงข่ายประสาทเทียม (Neural Network) ซึ่งต้องใช้ข้อมูลจำนวนมากในการเรียนรู้ การเสริมข้อมูลเป็นกระบวนการเพิ่มจำนวนและความหลากหลายของข้อมูลฝึก (Training Data) โดยการแปลงภาพต้นฉบับให้กลายเป็นภาพใหม่ที่แตกต่างกัน แต่ยังคงรักษาคุณลักษณะสำคัญที่เกี่ยวข้องกับประเภทของข้อมูลไว้ เช่น การหมุนภาพ การพลิกภาพแนวนอนหรือแนวตั้ง การซูมเข้า-ออก การเปลี่ยนความสว่าง การครอบภาพ (Crop) หรือแม้กระทั่งการเพิ่มนอยส์ (Noise) ลงในภาพ

วัตถุประสงค์หลักของการเสริมข้อมูลคือการเพิ่มความสามารถทั่วไป ของแบบจำลอง โดยช่วยลดการเกิด Overfitting ซึ่งเป็นภาวะที่แบบจำลองเรียนรู้เฉพาะรายละเอียดของข้อมูลฝึกมากเกินไปจนไม่สามารถทำนายข้อมูลใหม่ได้ดี การเสริมข้อมูลทำให้แบบจำลองได้เรียนรู้จากข้อมูลในรูปแบบที่หลากหลายมากขึ้น ส่งผลให้มีความสามารถในการจำแนกรูปแบบที่ซับซ้อนในข้อมูลจริงได้ดีขึ้น

ตัวอย่างเช่น ในงานวิจัยที่เกี่ยวข้องกับการจำแนกโรคใบชา การเสริมข้อมูลจะช่วยสร้างภาพใบชาหลากหลายมุมมองหรือสภาพแสงที่แตกต่างกัน ซึ่งช่วยให้แบบจำลองสามารถเรียนรู้

ลักษณะของโรคได้ครอบคลุมยิ่งขึ้น แม้ว่าภาพจะถูกถ่ายจากกล้องหรือสภาพแวดล้อมที่ต่างกันก็ตาม

โดยทั่วไป การเสริมข้อมูลสามารถทำได้ทั้งในขั้นตอนก่อนการฝึก (Pre-processing) หรือแบบเรียลไทม์ระหว่างการฝึกโมเดล ซึ่งเทคนิคนี้มักถูกใช้งานร่วมกับไลบรารีต่าง ๆ เช่น TensorFlow, Keras หรือ PyTorch ที่มีฟังก์ชันการเสริมข้อมูลให้ใช้งานอย่างสะดวกและยืดหยุ่น



ภาพประกอบ 8 ตัวอย่างการเสริมข้อมูลในรูปแบบต่างๆ

ที่มา : <https://www.ibm.com/think/topics/data-augmentation>


2.2.2 การเรียนรู้ด้วยเครื่อง

การเรียนรู้ด้วยเครื่อง เป็นสาขาหนึ่งของปัญญาประดิษฐ์ (Artificial Intelligence – AI) ที่มุ่งเน้นให้คอมพิวเตอร์สามารถเรียนรู้จากข้อมูลได้โดยไม่ต้องถูกเขียนโปรแกรมอย่างชัดเจนในทุกขั้นตอน กล่าวคือ แทนที่โปรแกรมเมอร์จะต้องกำหนดกฎเกณฑ์ในการตัดสินใจต่าง ๆ ให้กับระบบ โปรแกรมจะ "เรียนรู้" กฎเกณฑ์เหล่านั้นจากข้อมูลตัวอย่างที่ป้อนให้ระบบผ่านกระบวนการฝึก (Training)

โดยแบบจำลองที่เรียนรู้แล้วจะสามารถนำไปใช้คาดการณ์หรือตัดสินใจเกี่ยวกับข้อมูลใหม่ได้ ตัวอย่างเช่น การจำแนกประเภทของโรคจากภาพถ่ายใบชา ซึ่งแบบจำลองสามารถวิเคราะห์ลักษณะของโรคจากรูปภาพและจำแนกประเภทได้โดยอัตโนมัติ

ในงานวิจัยนี้ ได้มีการนำแนวคิดของ Machine Learning ตามภาพประกอบ 9 มาใช้ผ่านโครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งเป็นเทคนิคในกลุ่ม Deep Learning ที่ได้รับความนิยมสูงในการวิเคราะห์ภาพ โดย แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน จะช่วย

ให้ระบบสามารถเรียนรู้ลักษณะเฉพาะของโรคที่ปรากฏบนใบชาได้อย่างมีประสิทธิภาพ และสามารถนำไปใช้ประยุกต์ในงานด้านเกษตรอัจฉริยะได้จริง



ภาพประกอบ 9 ความสัมพันธ์ของปัญญาประดิษฐ์ การเรียนรู้ด้วยเครื่อง และการเรียนรู้เชิงลึก

ที่มา : <https://cloud-ace.co.th/blogs/o0v9a6-ai-machine-learning-ml-ai-ml-goog>

2.2.3 การเรียนรู้เชิงลึก


การเรียนรู้เชิงลึก เป็นแขนงหนึ่งของการเรียนรู้ด้วยเครื่อง ที่มีโครงสร้างจำลองมาจากการทำงานของสมองมนุษย์ โดยใช้หน่วยประมวลผลที่เรียกว่า โหนด (Nodes) หรือ นิวรอน (Neurons) ซึ่งเชื่อมต่อกันเป็นชั้น ๆ (Layers) จนเกิดเป็นโครงข่ายประสาทเทียม (Artificial Neural Network – ANN)

สิ่งที่ทำให้ Deep Learning แตกต่างจาก Machine Learning แบบทั่วไป คือ ความลึกของโครงข่าย ซึ่งประกอบด้วยหลายชั้น (เรียกว่า หลายชั้นซ่อน – Hidden Layers) ที่สามารถเรียนรู้คุณลักษณะ (Features) ของข้อมูลได้ในหลายระดับความซับซ้อน โดยไม่จำเป็นต้องให้ผู้ใช้งานระบุคุณลักษณะเหล่านั้นด้วยตนเอง

หนึ่งในสถาปัตยกรรมที่ได้รับความนิยมมากในด้านการประมวลผลภาพคือ โครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งถูกออกแบบมาให้สามารถเรียนรู้ลักษณะสำคัญของภาพได้อย่างมีประสิทธิภาพ โดยใช้กระบวนการกรองภาพ (Convolution), การลดขนาด (Pooling), การแปลงเป็นเวกเตอร์ (Flattening) และการเชื่อมต่อแบบเต็ม (Fully Connected Layers)

ข้อดีของการเรียนรู้เชิงลึกคือความสามารถในการเรียนรู้จากข้อมูลจำนวนมากและทำงานได้ดีในปัญหาที่มีความซับซ้อนสูง อย่างไรก็ตาม ก็ต้องใช้ทรัพยากรในการประมวลผลและข้อมูลสำหรับฝึกในปริมาณมากเช่นกัน

ในงานวิจัยนี้ ได้เลือกใช้เทคนิค Deep Learning ตามภาพประกอบ 10 โดยเฉพาะแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน มาพัฒนาแบบจำลองเพื่อจำแนกประเภทของโรคใบชา ด้วยความสามารถของแบบจำลองที่สามารถเรียนรู้รูปแบบของจุด สี หรือลักษณะของโรคได้โดยอัตโนมัติ จึงเหมาะสมอย่างยิ่งกับการวิเคราะห์ภาพถ่ายใบชาเพื่อวินิจฉัยโรคอย่างแม่นยำ



ภาพประกอบ 10 การเรียนรู้เชิงลึก

ที่มา : <https://stackpython.medium.com/deep-learning-ep-1-introduction>

2.2.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

โครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นสถาปัตยกรรมของการเรียนรู้เชิงลึก (Deep Learning Architecture) ที่ได้รับการออกแบบมาโดยเฉพาะสำหรับการประมวลผลภาพ และข้อมูลในรูปแบบที่มีโครงสร้างเป็นตาราง เช่น ภาพถ่าย (2D Matrix) หรือข้อมูลวิดีโอ โดยมีจุดเด่นอยู่ที่ความสามารถในการเรียนรู้ลักษณะเฉพาะของภาพ (Image Features) โดยอัตโนมัติ โดยไม่จำเป็นต้องสร้างคุณลักษณะ (Features) ด้วยมือ

โครงสร้างพื้นฐานของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ประกอบด้วยชั้นหลัก ๆ ดังนี้:


1. ชั้นคอนโวลูชัน (Convolution Layer):
ทำหน้าที่ดึงคุณลักษณะสำคัญจากภาพ เช่น ขอบ สี ลวดลาย หรือรูปร่าง โดยใช้ตัวกรอง (Filters หรือ Kernels) เลื่อนผ่านภาพและคำนวณค่าการตอบสนอง (Feature Map)
2. ชั้นลดขนาด (Pooling Layer):
ทำหน้าที่ลดขนาดของข้อมูล (Dimensionality Reduction) เพื่อลดจำนวนพารามิเตอร์และเวลาในการประมวลผล โดยไม่สูญเสียคุณลักษณะสำคัญ เช่น การใช้ Max Pooling เพื่อเลือกค่าที่มากที่สุดในแต่ละบริเวณ
3. ชั้นแปลงข้อมูล (Flatten Layer):
แปลงข้อมูลจากรูปแบบภาพ (2 มิติ) ให้อยู่ในรูปเวกเตอร์ 1 มิติ เพื่อเตรียมข้อมูลสำหรับการประมวลผลในขั้นถัดไป
4. ชั้นเชื่อมต่อแบบเต็ม (Fully Connected Layer):

เป็นชั้นที่ใช้ในการตัดสินใจ โดยนำข้อมูลจากเวกเตอร์ที่ได้มาเชื่อมโยงกับโหนดทั้งหมด แล้วใช้ฟังก์ชัน Softmax หรือ Sigmoid ในการคำนวณผลลัพธ์สุดท้าย เช่น การจำแนกประเภทของโรคใบชา

5. ฟังก์ชันการเปิดใช้งาน (Activation Function):

เช่น ReLU (Rectified Linear Unit) ซึ่งถูกใช้เพื่อเพิ่มความไม่เชิงเส้นให้กับระบบ ทำให้โมเดลสามารถเรียนรู้ข้อมูลที่ซับซ้อนได้ดีขึ้น

แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันได้รับความนิยมอย่างสูงในงานด้านการรู้จำภาพ (Image Recognition), การวิเคราะห์วัตถุ (Object Detection), การรู้จำใบหน้า และโดยเฉพาะอย่างยิ่งในงานวิจัยนี้คือ การจำแนกประเภทของโรคจากภาพถ่ายใบชา



ภาพประกอบ 11 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

ที่มา : <https://www.linkedin.com/pulse/what-convolutional-neural-network-cnn-deep-learning-nafiz-shahriar>

ข้อดีของ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันคือ:

1. สามารถเรียนรู้ลักษณะของภาพได้โดยอัตโนมัติ
2. มีประสิทธิภาพสูงในการประมวลผลข้อมูลภาพ
3. ลดปัญหา Overfitting เมื่อใช้ร่วมกับเทคนิคอื่น ๆ เช่น Data Augmentation, Dropout และ Batch Normalization

ในงานวิจัยนี้ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันถูกนำมาใช้สร้างแบบจำลองสำหรับจำแนกโรคใบชาทั้ง 7 ชนิด พร้อมใบปกติ (Healthy) รวมเป็น 8 ประเภท เพื่อให้ได้ระบบที่สามารถช่วยเกษตรกรในการตรวจสอบโรคได้อย่างรวดเร็วและแม่นยำในภาคสนาม

2.2.5 การถ่ายทอดการเรียนรู้

การถ่ายทอดการเรียนรู้ เป็นเทคนิคหนึ่งในกระบวนการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก ที่ช่วยให้โมเดลสามารถใช้ความรู้ที่เคยเรียนรู้จากงานหนึ่ง ไปประยุกต์ใช้กับงานอื่นที่มีลักษณะคล้ายกันได้ โดยไม่จำเป็นต้องเริ่มการเรียนรู้ใหม่ทั้งหมดจากศูนย์


หลักการของการถ่ายทอดการเรียนรู้ คือ การใช้แบบจำลองที่ผ่านการฝึกมาแล้ว (Pre-trained Model) บนชุดข้อมูลขนาดใหญ่และหลากหลาย เช่น DenseNet121 และ MobileNetV2 โดยในงานวิจัยนี้เลือกใช้สถาปัตยกรรม DenseNet121, VGG16 และ EfficientNetB1

สถาปัตยกรรม DenseNet121

DenseNet121 เป็นหนึ่งในสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่พัฒนาโดยมหาวิทยาลัยคอร์เนล โดยออกแบบมาเพื่อลดปัญหา vanishing gradient ที่พบในโมเดลลึก โดยใช้แนวคิดการเชื่อมโยงเลเยอร์แบบ “หนาแน่น” (Dense Connectivity) ซึ่งแต่ละเลเยอร์จะรับข้อมูลจากทุกเลเยอร์ก่อนหน้า ทำให้การเรียนรู้มีประสิทธิภาพสูงขึ้นและไม่สูญเสียรายละเอียดของภาพ

โครงสร้างของ DenseNet121 ตามภาพประกอบ 12 ประกอบด้วย 121 เลเยอร์ โดยมีการจัดวางเป็น Dense Block สลับกับ Transition Layer การเชื่อมโยงภายใน Dense Block ช่วยให้โมเดลสามารถรวมคุณลักษณะจากทั้งระดับต้นและลึกได้ดี และใช้พารามิเตอร์น้อยกว่าสถาปัตยกรรมแบบเดิม เช่น VGG หรือ ResNet จึงช่วยลดปัญหา overfitting ได้เมื่อใช้กับข้อมูลจำกัด

ในงานวิจัยนี้ DenseNet121 ถูกนำมาใช้งานผ่านเทคนิค Transfer Learning โดยนำแบบจำลองที่ฝึกจากชุดข้อมูลขนาดใหญ่อย่าง ImageNet มาปรับใช้กับข้อมูลโรคเบาหวาน เพื่อเพิ่มความแม่นยำในการจำแนกลักษณะของโรคแต่ละประเภทได้อย่างมีประสิทธิภาพ



ภาพประกอบ 12 สถาปัตยกรรม DenseNet121


ที่มา : <https://www.linkedin.com/pulse/what-convolutional-neural-network-cnn-deep-learning-nafiz-shahriar>

สถาปัตยกรรม VGG-16

VGG16 เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่พัฒนาโดยทีม Visual Geometry Group (VGG) จากมหาวิทยาลัยอ็อกซ์ฟอร์ด และเปิดตัวในการแข่งขัน ImageNet ปี 2014 โครงสร้างของ VGG16 เน้นความเรียบง่าย โดยใช้ convolutional filter ขนาดเล็ก 3×3 ซ้อนกันหลายชั้น เพื่อเพิ่มความลึกและสามารถเรียนรู้คุณลักษณะที่ซับซ้อนจากภาพได้อย่างมีประสิทธิภาพ ในขณะที่ควบคุมจำนวนพารามิเตอร์ให้อยู่ในระดับที่เหมาะสม

ตามภาพประกอบ 13 โมเดลประกอบด้วย 13 convolutional layers และ 3 fully connected layers รวม 16 ชั้น ข้อมูลภาพขนาด $224 \times 224 \times 3$ ถูกประมวลผลผ่าน convolution blocks พร้อมฟังก์ชัน ReLU และ MaxPooling ขนาด 2×2 เป็นระยะ จากนั้นข้อมูลจะถูกแปลงเป็นเวกเตอร์และส่งผ่าน fully connected layers ก่อนจบด้วย Softmax สำหรับจำแนกภาพ ซึ่งในงานวิจัยนี้กำหนดไว้ 8 คลาสตามประเภทโรคปอด

ข้อดีของ VGG-16 คือโครงสร้างที่เข้าใจง่าย เหมาะสำหรับการนำไปใช้งาน Transfer Learning โดยเฉพาะการใช้ convolutional layers เป็นตัวดึงคุณลักษณะของภาพ แม้จะมีข้อจำกัดด้านจำนวนพารามิเตอร์ที่สูง (มากกว่า 138 ล้านพารามิเตอร์) ส่งผลให้ใช้ทรัพยากรระบบสูง VGG16 จึงเป็นโมเดลที่สมดุลระหว่างประสิทธิภาพและความยืดหยุ่น เหมาะสำหรับงานที่ต้องการความแม่นยำสูงในงานจำแนกภาพเฉพาะทาง



ภาพประกอบ 13 สถาปัตยกรรม VGG-16

ที่มา:

https://www.researchgate.net/publication/353494880_A_comparative_study_of_multiple_neural_network_for_detection_of_COVID-19_on_chest_X-ray/figures?lo=1

สถาปัตยกรรม EfficientNetB1

EfficientNetB1 เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน ที่ได้รับการพัฒนาโดย Google AI และถูกออกแบบให้มีประสิทธิภาพสูงทั้งด้านความแม่นยำและการใช้ทรัพยากรคำนวณ โดยเป็นหนึ่งในโมเดลตระกูล EfficientNet ซึ่งใช้เทคนิค Compound Scaling เพื่อปรับขนาดของโมเดลอย่างสมดุลทั้งในด้านความลึก


(Depth), ความกว้าง (Width) และความละเอียดของภาพ (Resolution) พร้อมกัน ซึ่งต่างจากการขยายโมเดลแบบดั้งเดิมที่ขยายเพียงมิติเชิงเดียว

ตามภาพประกอบ 14 โมเดล EfficientNetB1 ใช้ความละเอียดของภาพขาเข้าเป็น $240 \times 240 \times 3$ และประกอบด้วย MBConv blocks หลายชุด ซึ่งเป็นโครงสร้างของ convolutional layer ที่ได้รับการออกแบบมาอย่างมีประสิทธิภาพ โดยแต่ละ MBConv จะใช้ Depthwise Separable Convolution และ Squeeze-and-Excitation (SE) blocks เพื่อดึงคุณลักษณะที่สำคัญของภาพและลดจำนวนพารามิเตอร์ พร้อมทั้งใช้ Swish เป็นฟังก์ชันกระตุ้น (activation function) แทน ReLU เพื่อเพิ่มความสามารถในการเรียนรู้ของโมเดล

ข้อมูลจากภาพจะถูกประมวลผลผ่านหลายขั้นตอนของ MBConv ก่อนเข้าสู่ชั้น Global Average Pooling ที่ทำหน้าที่ย่อขนาด Feature Map และเชื่อมต่อกับ Fully Connected Layer สุดท้าย พร้อมฟังก์ชัน Softmax สำหรับการจำแนกประเภทภาพ ซึ่งในงานวิจัยนี้กำหนดไว้ 8 คลาสตามประเภทของโรคเบาหวาน

ข้อดีของ EfficientNetB1 คือสามารถให้ความแม่นยำที่สูงได้เทียบเท่าหรือดีกว่าโมเดลขนาดใหญ่ เช่น ResNet หรือ Inception แต่ใช้จำนวนพารามิเตอร์และการคำนวณที่น้อยกว่าอย่างมีนัยสำคัญ ทำให้เหมาะสำหรับงานที่ต้องการทั้งประสิทธิภาพและความคุ้มค่าทางทรัพยากร โดยเฉพาะเมื่อใช้งานร่วมกับเทคนิค Transfer Learning ซึ่งสามารถนำ convolutional layers ที่ฝึกไว้ล่วงหน้าบน ImageNet มาใช้ดึงคุณลักษณะของภาพ แล้วปรับเฉพาะชั้นด้านบน (top layers) ให้เหมาะกับงานจำแนกโรคเบาหวาน

EfficientNetB1 จึงเป็นอีกหนึ่งสถาปัตยกรรมที่สมดุลระหว่างความแม่นยำ ความเร็ว และประหยัดทรัพยากร เหมาะอย่างยิ่งสำหรับนำไปประยุกต์ใช้ในงานจำแนกภาพเฉพาะทางทางด้านเกษตรกรรม เช่น การวิเคราะห์และตรวจวินิจฉัยโรคเบาหวานในงานวิจัยนี้



ภาพประกอบ 14 สถาปัตยกรรม EfficientNetB1

ที่มา: https://www.researchgate.net/publication/351998710_EffUnet-SpaGen_An_Efficient_and_Spatial_Generative_Approach_to_Glaucoma_Detection/figures?lo=1

2.2.6 การประเมินผลแบบจำลอง

การประเมินผลแบบจำลอง เป็นขั้นตอนที่สำคัญในกระบวนการพัฒนาโมเดลการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก เพื่อใช้วัดประสิทธิภาพของโมเดลว่า สามารถทำงานได้ดีเพียงใดเมื่อประมวลผลกับข้อมูลที่ไม่เคยเห็นมาก่อน (ข้อมูลทดสอบ)

การประเมินผลที่ดีจะช่วยให้ผู้วิจัยสามารถทราบถึงจุดแข็ง จุดอ่อน และความแม่นยำของแบบจำลอง ตลอดจนสามารถนำไปปรับปรุงหรือเลือกโมเดลที่เหมาะสมที่สุดสำหรับใช้งานจริง

เกณฑ์และตัวชี้วัดที่นิยมใช้ในการประเมินผลแบบจำลอง ได้แก่:

Confusion Matrix

Confusion Matrix เป็นตารางที่แสดงผลการทำนายของโมเดลเปรียบเทียบกับค่าจริง ประกอบด้วย 4 ค่าในกรณีสองคลาส (Binary Classification):

		True Class	
		Positive	Negative
Predicated Class	Positive	TP	FP
	Negative	FN	TN

ภาพประกอบ 15 Confusion Matrix

ที่มา : <https://www.datacamp.com/tutorial/what-is-a-confusion-matrix-in-machine-learning>

- True Positive (TP): แบบจำลองทำนายว่าข้อมูลเป็นกลุ่มเป้าหมาย และเป็นจริง
- False Positive (FP): แบบจำลองทำนายว่าข้อมูลเป็นกลุ่มเป้าหมาย แต่ความจริงไม่ใช่ (ผิดพลาดแบบเกิน)
- False Negative (FN): แบบจำลองทำนายว่าข้อมูลไม่ใช่กลุ่มเป้าหมาย แต่ความจริงคือใช่ (ผิดพลาดแบบขาด)
- True Negative (TN): แบบจำลองทำนายว่าข้อมูลไม่ใช่กลุ่มเป้าหมาย และเป็นจริง

กรณีที่มีหลายคลาส (Multiclass Classification) เช่น การจำแนกโรคใบชา 8 ประเภท จะมีการขยาย Confusion Matrix เป็นตาราง NxN (ตามจำนวนคลาส)

ตัวชี้วัดที่ได้จาก Confusion Matrix จากค่าทั้ง 4 นี้ สามารถคำนวณตัวชี้วัดที่สำคัญได้ เช่น:

1. Accuracy (ความแม่นยำโดยรวม)

Accuracy คือสัดส่วนของจำนวนข้อมูลที่ทำนายถูกต้องทั้งหมดเมื่อเทียบกับจำนวนข้อมูลทั้งหมดเหมาะกับการที่ข้อมูลมีการกระจายอย่างสมดุลในแต่ละคลาส

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN}$$

2. Precision (ความแม่นยำของการทำนายว่าเป็น)

Precision คือสัดส่วนของข้อมูลที่ทำนายว่าเป็นคลาสเป้าหมายแล้วถูกต้องจริง

$$Precision = \frac{TP}{TP + FP}$$

3. Recall (ความสามารถในการตรวจพบ)

Recall หรือ Sensitivity คือสัดส่วนของข้อมูลที่เป็นคลาสเป้าหมายจริง แล้วโมเดลสามารถทำนายได้ถูกต้อง

$$Recall = \frac{TP}{TP + FN}$$

4. F1-Score (ค่าเฉลี่ยของ Precision และ Recall)

F1-Score เป็นค่าเฉลี่ยแบบฮาร์โมนิกของ Precision และ Recall ซึ่งใช้ในกรณีที่ข้อมูลไม่สมดุล


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

2.2.7 ทฤษฎี Fuzzy Logic - Image Contrast Enhancement

การเพิ่มความคมชัดของภาพ เป็นกระบวนการที่สำคัญในงานประมวลผลภาพ โดยเฉพาะในงานด้านการวิเคราะห์ภาพทางการแพทย์ การเกษตร หรือแม้แต่ระบบอัตโนมัติที่ต้องอาศัยการตรวจจับลักษณะสำคัญของภาพอย่างแม่นยำ ซึ่งการเพิ่มความคมชัดจะช่วยให้คุณลักษณะของวัตถุภายในภาพมีความเด่นชัดมากยิ่งขึ้น ช่วยให้กระบวนการตรวจจับและจำแนกเป็นไปอย่างมีประสิทธิภาพ

หนึ่งในวิธีการเพิ่มความคมชัดที่ได้รับความนิยมมากในช่วงหลังคือการใช้ ลอจิกฟัซซี ตามภาพประกอบ 16 ซึ่งเป็นแนวคิดทางคณิตศาสตร์ที่สามารถจัดการกับความไม่แน่นอน ความคลุมเครือ และข้อมูลที่มีลักษณะไม่ชัดเจน ซึ่งแตกต่างจากตรรกะดั้งเดิมที่มีเพียงค่าจริงหรือเท็จ (0 หรือ 1)

Fuzzy Logic เป็นระบบที่สามารถแทนค่าความเป็นจริงในรูปแบบของ “ระดับของความเป็นไปได้” แทนที่จะใช้ค่าที่ชัดเจน กล่าวคือ ข้อมูลจะถูกแปลงให้อยู่ในช่วงระหว่าง 0 ถึง 1 เพื่อแทนค่าความเป็น “น้อย” ไปจนถึง “มาก” โดยไม่จำเป็นต้องระบุค่าชัดเจนอย่างเด็ดขาด



ภาพประกอบ 16 Fussy-based method

ที่มา : <https://www.kaggle.com/code/nguyenvlm/fuzzy-logic-image-contrast-enhancement>

2.2.8 ระบบสี HSI

ระบบสี HSI (Hue-Saturation-Intensity) เป็นหนึ่งในโมเดลสีที่ถูกพัฒนาขึ้นเพื่อเลียนแบบการรับรู้สีของสายตามนุษย์ โดยเฉพาะในบริบทของการประมวลผลภาพดิจิทัล ซึ่งระบบสีนี้มีข้อได้เปรียบเหนือกว่าระบบสีแบบ RGB (Red-Green-Blue) ตรงที่สามารถแยกแยะข้อมูลเกี่ยวกับ "สี" (Hue), "ความสดของสี" (Saturation) และ "ความสว่าง" (Intensity) ออกจากกันได้อย่างชัดเจน

องค์ประกอบของระบบสี HSI

1) Hue (H) – เฉดสี:

Hue เป็นตัวแทนของลักษณะของสี เช่น สีแดง, ส้ม, เหลือง, น้ำเงิน ฯลฯ โดยปกติจะแสดงเป็น “องศา” บนวงล้อสี (Color Wheel) ซึ่งมีค่าอยู่ในช่วง 0–360 องศา

- 0° = แดง
- 120° = เหลือง
- 240° = น้ำเงิน

$$H = \cos^{-1} \left(\frac{1}{2} [(R - G) + (R - B)] / \sqrt{(R - G)^2 + (R - B)(G - B)} \right)$$

โดยค่าของ H จะอยู่ในช่วง 0° ถึง 360° ซึ่งสามารถแปลงเป็นช่วง $[0, 1]$ ได้ในกรณีที่ต้อง Normalize

2) Saturation (S) – ความอิ่มตัวของสี:

เป็นตัวบอกระดับของ “ความบริสุทธิ์” ของสี ยิ่งค่าสูง สีจะยิ่งสดและชัดเจน ส่วนค่าที่ต่ำ หมายถึงสีซีดหรือจาง จนถึงขนาดที่ไม่มีสี (กลายเป็นสีเทา)

$$S = 1 - \frac{3}{R + G + B} \cdot \min(R, G, B)$$

โดยที่

กรณี $R + G + B = 0$ หรือมีการ Normalize แล้ว ต้องตรวจสอบเพื่อไม่ให้หารด้วย ศูนย์

3) Intensity (I) – ความเข้มของแสง:

เป็นค่าความสว่างของพิกเซลในภาพ โดยคำนวณจากค่าเฉลี่ยของ R, G และ B ใช้เพื่อวัดว่าพิกเซลนั้นมีความมืดหรือสว่างเพียงใด

$$I = \frac{1}{3} (R + G + B)$$

โดยที่

R, G, B คือค่าความเข้มของสีแดง เขียว และน้ำเงิน ตามลำดับ (ค่าตั้งแต่ 0 ถึง 255 หรืออาจ Normalize ให้อยู่ในช่วง $[0, 1]$)

2.2.9 ระบบการปรับคอนทราสต์ภาพด้วย CLAHE

CLAHE (Contrast Limited Adaptive Histogram Equalization) เป็นเทคนิคการปรับปรุงคุณภาพของภาพในด้านความคมชัด (Contrast Enhancement) ซึ่งได้รับการพัฒนาต่อยอดจากวิธี Histogram Equalization (HE) และ Adaptive Histogram Equalization (AHE) โดยมีจุดประสงค์เพื่อเพิ่มความชัดเจนของรายละเอียดในภาพโดยเฉพาะในบริเวณที่มีความแตกต่างของความสว่างต่ำ เช่น พื้นที่เงา หรือพื้นที่ที่มีความเข้มของสีใกล้เคียงกัน โดยไม่ทำให้เกิดการขยายความแตกต่างของแสง (Contrast) มากเกินไปในบริเวณที่ไม่จำเป็น

เทคนิค CLAHE ทำงานโดยการแบ่งภาพออกเป็นหลาย ๆ ส่วนเล็ก ๆ ที่เรียกว่า tiles จากนั้นทำการ Histogram Equalization ภายในแต่ละ tile แยกกัน เพื่อเพิ่มคอนทราสต์ในแต่ละ

บริเวณของภาพ วิธีนี้ช่วยให้การปรับปรุงคอนทราสต์กระจายตัวอย่างเหมาะสมทั่วทั้งภาพ แทนที่จะกระทำต่อภาพทั้งหมดในคราวเดียวเหมือนวิธี HE ปกติ

ข้อได้เปรียบที่สำคัญของ CLAHE คือการใช้ขีดจำกัดความคมชัด (Contrast Limiting) เพื่อควบคุมไม่ให้เกิดการขยายคอนทราสต์มากเกินไปในแต่ละ tile โดยกำหนดค่าความเข้มขั้นสูงสุดของ histogram (clip limit) ที่ยอมให้ขยายความต่างของแสงและสีในแต่ละ tile วิธีนี้ช่วยป้องกันไม่ให้เกิดบริเวณใดบริเวณหนึ่งในภาพมีความสว่างหรือมืดจนเกินไป และยังช่วยลด noise ที่อาจเกิดจากการเพิ่มคอนทราสต์ในบริเวณที่มีความสว่างน้อย

หลังจากทำการปรับ histogram ภายในแต่ละ tile แล้ว จะทำการ interpolate (เชื่อมต่อ) ระหว่าง tiles ต่าง ๆ เพื่อให้ภาพมีความต่อเนื่องและลื่นไหล ไม่เกิดขอบหรือความแตกต่างระหว่างพื้นที่ที่ถูกปรับคอนทราสต์

2.3 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องสำหรับงานวิจัยนี้ ผู้วิจัยได้ทำการศึกษาค้นคว้า งานวิจัยที่เกี่ยวข้องกับการจำแนกโรคบนใบของพืช โดยเฉพาะใบชา โดยงานวิจัยที่เกี่ยวข้องมีรายละเอียดดังนี้

1. บทความวิจัยเรื่อง A new AI-based approach for automatic identification of tea leaf disease using deep neural network based on hybrid pooling

การตรวจจับและจำแนกโรคในใบชาเป็นหัวข้อสำคัญในด้านการเกษตร เนื่องจากโรคที่เกิดขึ้นสามารถส่งผลกระทบต่อคุณภาพและผลผลิตของชาได้อย่างมาก งานวิจัยหลายชิ้นที่ผ่านมาได้ประยุกต์ใช้เทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันในการวินิจฉัยโรคจากภาพใบชา ตัวอย่างเช่น โมเดล LeNet ซึ่งประกอบด้วยเลเยอร์คอนโวลูชัน 3 ชั้นและ Max Pooling ถูกใช้ในการจำแนกโรค 4 ประเภท แต่ประสิทธิภาพของโมเดลยังมีข้อจำกัดในเรื่องความแม่นยำและจำนวนประเภทของโรค (Gayathri et al., 2020) นอกจากนี้ โมเดล LeafNet ซึ่งมีคอนโวลูชัน 5 ชั้นและ Max Pooling 3 ชั้น ได้รับการประยุกต์ใช้ในการจำแนกโรคหลายประเภท แต่พบปัญหา Overfitting เนื่องจากการใช้ Max Pooling มากเกินไป ทำให้เกิดการสูญเสียคุณลักษณะที่สำคัญ (Chen et al., 2019)

วิธีการอื่น ๆ เช่น Support Vector Machine (SVM) และ Bag-of-Visual-Words (BOVW) ก็ถูกนำมาใช้ในการจำแนกโรคในใบชา โดยใช้เทคนิคการดึงคุณลักษณะและการจัดกลุ่มข้อมูล อย่างไรก็ตาม ประสิทธิภาพของวิธีเหล่านี้ยังด้อยกว่า แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้รับการปรับแต่งอย่างเหมาะสม งานวิจัยในช่วงหลังจึงมุ่งเน้นไปที่การพัฒนาโมเดลที่สามารถลดข้อจำกัดดังกล่าวและเพิ่มความแม่นยำในการจำแนกโรค

งานวิจัยนี้นำเสนอการประยุกต์ใช้ Hybrid Pooling ในแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งเป็นการรวมข้อดีของ Max Pooling และ Average Pooling เข้าด้วยกัน โดยการสุ่มใช้ Max หรือ Average Pooling ตามความน่าจะเป็นที่กำหนดในระหว่างการฝึกโมเดล วิธีนี้ช่วยลดปัญหา Overfitting และเพิ่ม Generalization ของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันให้สามารถเรียนรู้และดึงคุณลักษณะที่เกี่ยวข้องกับโรคได้ดียิ่งขึ้น

ในการจำแนกประเภทโรคที่ซับซ้อนยิ่งขึ้น งานวิจัยนี้ได้ใช้ Weighted Random Forest (WRF) ซึ่งเป็นโมเดลที่ผสมผสานหลายต้นไม้การตัดสินใจ (Decision Trees) และกำหนดน้ำหนักให้กับแต่ละต้นไม้โดยใช้ Cuckoo Search Optimization (CSO) เทคนิค CSO ช่วยหาน้ำหนักที่เหมาะสมที่สุดสำหรับต้นไม้แต่ละต้นใน Random Forest เพื่อลดข้อผิดพลาดในการฝึกอบรมและเพิ่มความแม่นยำของการจำแนก

ตาราง 1 ตารางเปรียบเทียบประสิทธิภาพของโมเดลในวิธีต่างๆ

Method	Accuracy	F-mean	Recall	Precision
Proposed (HybPool _ WRF)	92.4691	92.3005	92.3492	92.2636
MaxPool + WRF	90.1235	89.9268	89.9400	89.9512
AvgPool + WRF	89.0123	88.8830	88.9126	88.9569
HybPool + WRF	89.3827	89.3309	89.5125	89.2071
LeafNet	90.1235	89.9975	90.2006	89.9206
Mukhipadhyay et al	82.9630	82.7447	82.9971	82.7118

ผลการทดลองตามตาราง 1 แสดงให้เห็นว่า การใช้ Hybrid Pooling ใน แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันสามารถเพิ่มความแม่นยำในการจำแนกโรคได้น้อย 2.35% เมื่อเทียบกับวิธีแบบเดิม นอกจากนี้ การใช้งาน WRF ที่ปรับปรุงด้วย CSO ยังช่วยเพิ่มความแม่นยำในการทำนายได้อีก 3.08% เมื่อเทียบกับการใช้ Random Forest แบบดั้งเดิม แสดงให้เห็นถึงประสิทธิภาพของวิธีการนี้ในการตรวจจับโรคใบชาได้อย่างแม่นยำ

แม้ว่าโมเดลที่นำเสนอจะมีประสิทธิภาพสูง แต่การเพิ่มประเภทของโรคและจำนวนตัวอย่างในฐานะข้อมูลสามารถช่วยเพิ่มความแม่นยำได้อีก ในอนาคต งานวิจัยสามารถขยายการประยุกต์ใช้เทคนิคนี้กับผลิตภัณฑ์การเกษตรอื่นๆ เพื่อเพิ่มขอบเขตการใช้งานให้กว้างขึ้น ผลลัพธ์จากงานวิจัยนี้ชี้ให้เห็นถึงศักยภาพของการใช้ Deep Learning และ Ensemble Learning ที่ปรับปรุงอย่างละเอียดในการตรวจจับโรค ซึ่งไม่เพียงแต่เพิ่มคุณภาพของผลผลิต แต่ยังลดภาระการวินิจฉัยด้วยกระบวนการอัตโนมัติที่รวดเร็วและแม่นยำ

2. บทความวิจัยเรื่อง Revolutionising Tea Cultivation: A Novel DCNN Approach for High Precision Leaf Disease Classification

การตรวจจับโรคในพืชโดยใช้เทคนิค Deep Learning (DL) มีความก้าวหน้าอย่างรวดเร็วในช่วงไม่กี่ปีที่ผ่านมา งานวิจัยหลายชิ้นมุ่งเน้นพัฒนาสถาปัตยกรรมโครงข่ายประสาทเทียม (Neural Networks) เพื่อเพิ่มความแม่นยำในการจำแนกโรคจากภาพใบพืช งานวิจัยหนึ่งสร้างโมเดล DCNN (Deep Convolutional Neural Network) ที่สามารถบรรลุความแม่นยำ 96.56% บนชุดข้อมูลจำนวน 5,867 ภาพ แสดงให้เห็นถึงความเหมาะสมสำหรับการประยุกต์ใช้กับระบบ Internet of Things (IoT) และสามารถขยายไปยังพืชชนิดอื่นได้อย่างยืดหยุ่น (Datta & Gupta, 2023) ในอีกงานหนึ่ง การพัฒนา CNN-based system ที่มีความแม่นยำสูงถึง 100% บน

ชุดข้อมูลการฝึก การทดสอบ และการตรวจสอบความถูกต้อง โดยผนวกรวมการใช้งานกับกล้องสมาร์ทโฟนและระบบคลาวด์แบบ PaaS (Platform-as-a-Service) ทำให้ระบบมีประสิทธิภาพและใช้งานได้จริงในสภาพแวดล้อมภาคสนาม (Lanjewar & Panchbhai, 2023)

อีกเทคนิคหนึ่งที่น่าสนใจคือการใช้ ACO-CNN ซึ่งนำหลักการ Ant Colony Optimization มาปรับปรุงความแม่นยำในการวินิจฉัยโรคใบพื้ช ขณะที่ CapsNet ซึ่งมีความสามารถโดดเด่นในการตรวจจับตำแหน่งเชิงพื้นที่ ได้ถูกใช้ในงานวิจัยด้านการจำแนกโรคใบมะเขือเทศ ช่วยให้การจำแนกโรคเป็นไปอย่างมีประสิทธิภาพมากขึ้น (Abouelmagd et al., 2024) สำหรับการจำแนกพื้ชและวัชพื้ช นักวิจัยได้พัฒนาโมเดล Vision Transformer (ViT) โดยปรับจูนด้วยชุดข้อมูล ImageNet-1k และทดสอบบนชุดข้อมูล DeepWeed แสดงให้เห็นว่าระบบมีประสิทธิภาพสูงในการจำแนกพื้ชและวัชพื้ชจากภาพถ่าย (Sharma & Vardhan, 2023)

นอกจากนี้ การพัฒนาโมเดลด้วยการใช้ CycleGAN ร่วมกับ ResNet-based classifier ถูกเสนอเพื่อแก้ปัญหาการขาดแคลนข้อมูลและการกระจายคลาสที่ไม่สมดุล ซึ่งเป็นปัญหาที่พบบ่อยในงานด้านเกษตรกรรม งานวิจัยนี้แสดงให้เห็นว่าโมเดลดังกล่าวสามารถแก้ไขปัญหาดังกล่าวได้อย่างมีประสิทธิภาพ (Chen et al., 2023) ขณะเดียวกัน การใช้ YOLOv7 เพื่อตรวจจับโรคใบชาจากไร่ในบังกลาเทศได้พิสูจน์ว่ามีประสิทธิภาพเหนือกว่าโมเดลที่เคยใช้ก่อนหน้านี้ (Soeb et al., 2023)

งานวิจัยปัจจุบันนำเสนอแนวทางใหม่ในการจำแนกโรคใบชาโดยการพัฒนา DCNN ที่ออกแบบมาเฉพาะ สำหรับการรับมือกับข้อมูลที่มีความซับซ้อนสูง โมเดลนี้ใช้ Depthwise Separable Convolutions และ Global Average Pooling (GAP) เพื่อลดการใช้ทรัพยากรการคำนวณ ขณะเดียวกันยังคงรักษาความสามารถในการดึงคุณลักษณะสำคัญจากภาพที่มีความละเอียดสูง นอกจากนี้ การเพิ่ม Dropout Layer และ Residual Connections ช่วยลดปัญหาการ Overfitting และเพิ่มความสามารถในการใช้งานจริงในสภาพแวดล้อมที่มีความหลากหลาย

ตาราง 2 ค่าความแม่นยำต่อจำนวน Epochs ที่แตกต่างกัน

Number of Epochs	Training Accuracy (%)	Testing Accuracy (%)	Number of Correct Predictions	Number of Wrong Predictions
10	72.6	65.5	116	61
30	85.2	78.5	139	38
50	92.1	88.1	156	21
70	96.3	94.9	168	9
100	98.9	99.4	176	1

ผลการทดลองตามตาราง 2 แสดงให้เห็นว่า โมเดลที่นำเสนอสามารถบรรลุความแม่นยำสูงสุดที่ 99.4% ซึ่งถือเป็นความก้าวหน้าสำคัญในด้านการตรวจจับโรคใบชา โมเดลนี้ไม่เพียงแต่ช่วยเพิ่มผลผลิตทางการเกษตร แต่ยังช่วยลดความเสียหายจากโรคด้วยการตรวจจับและ

วินิจัยที่รวดเร็วและแม่นยำ ผลลัพธ์นี้แสดงให้เห็นถึงศักยภาพของเทคโนโลยี AI ในการปฏิวัติระบบการเกษตรให้มีความยั่งยืนและตอบสนองต่อปัญหาภาคเกษตรกรรมในปัจจุบันอย่างมีประสิทธิภาพ


3. Automatic Detection of Tea Leaf Diseases using Deep Convolution Neural Network

การตรวจจับโรคใบชาด้วยเทคโนโลยี Deep Learning เป็นหนึ่งในหัวข้อที่ได้รับความสนใจในด้านการเกษตร เนื่องจากโรคที่เกิดขึ้นสามารถส่งผลกระทบต่อผลผลิตและคุณภาพของชาชั้นนำทั่วโลก งานวิจัยที่ผ่านมาชี้ให้เห็นว่าการใช้ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันมีศักยภาพสูงในการวินิจฉัยโรคพืชอย่างมีประสิทธิภาพ ตัวอย่างเช่น แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันถูกใช้ในการจำแนกโรคหลายประเภทของพืชจากภาพถ่าย ด้วยโครงสร้างที่สามารถดึงคุณลักษณะสำคัญจากข้อมูลภาพได้อย่างแม่นยำ (Ferentinos, 2018) นอกจากนี้ Zhang et al. (2019) ได้เสนอวิธีการแบ่งสีของภาพด้วยเทคนิคการแบ่งกลุ่ม (Segmentation) เพื่อเพิ่มความแม่นยำในการจำแนกโรค

อย่างไรก็ตาม การใช้เทคนิคแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันเพียงอย่างเดียวมักเผชิญปัญหากับชุดข้อมูลที่ไม่สมดุลและการสูญเสียข้อมูลที่สำคัญจากเลเยอร์ Pooling ในการวิจัยที่เกี่ยวข้อง พบว่าการประยุกต์ใช้การเรียนรู้เชิงลึกสามารถปรับปรุงประสิทธิภาพได้ โดยการใช้ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน หลายเลเยอร์ที่ประกอบด้วยเลเยอร์คอนโวลูชัน เลเยอร์ Pooling และเลเยอร์ Fully Connected การฝึกอบรมที่เหมาะสมสามารถทำให้โมเดลบรรลุความแม่นยำสูงในการจำแนกประเภทของโรคในพืช เช่น ใบชา

งานวิจัยในปัจจุบันนี้ได้เสนอแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ประกอบด้วย 1 เลเยอร์อินพุต, 4 เลเยอร์คอนโวลูชัน, และ 2 เลเยอร์ Fully Connected โมเดลนี้ได้รับการออกแบบเพื่อจำแนกโรคใบชาออกเป็น 8 ประเภท เช่น จุดตะไคร่น้ำ, ใบติดโรคสีเทา, ใบขาว, ใบติดโรคสีน้ำตาล, แผลแดง, ใบเน่าที่ดอก, และใบติดเชื้อราสีเทา แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่เสนอในงานนี้ถูกพัฒนาให้สามารถลดปัญหาการสูญเสียคุณลักษณะผ่านการใช้เลเยอร์ Pooling ที่มีประสิทธิภาพ และเลเยอร์ Flattening ที่ช่วยในการแปลงข้อมูลภาพให้พร้อมสำหรับการทำนาย

ขั้นตอนการประมวลผลภาพเริ่มต้นด้วยการปรับขนาดภาพให้เป็นมาตรฐาน (100x100x3) และผ่านกระบวนการ Convolution เพื่อดึงคุณลักษณะจากภาพ การใช้ ReLU ในเลเยอร์คอนโวลูชันช่วยลดปัญหา Vanishing Gradient และเพิ่มประสิทธิภาพของการเรียนรู้เชิงลึก ในขณะที่เลเยอร์สุดท้ายใช้ Softmax เพื่อแปลงผลลัพธ์เป็นความน่าจะเป็น ซึ่งช่วยให้สามารถจำแนกโรคได้อย่างแม่นยำ นอกจากนี้ โมเดลยังใช้เทคนิค Data Augmentation เพื่อเพิ่มจำนวนตัวอย่างในการฝึก ช่วยให้โมเดลสามารถจัดการกับข้อมูลที่มีความหลากหลายได้ดีขึ้น



ภาพประกอบ 17 ภาพผลลัพธ์ Accuracy Analysis และ Loss Analysis

ผลลัพธ์ของการทดลองจากภาพประกอบ 17 ซึ่งให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันนี้สามารถบรรลุความแม่นยำสูงถึง 94.4%

ในการจำแนกประเภทโรคใบชา ซึ่งเป็นการพัฒนาอย่างสำคัญในด้านการประยุกต์ใช้ AI ในภาคเกษตรกรรม นอกจากนี้ ยังแสดงให้เห็นว่าโมเดลสามารถนำไปประยุกต์ใช้ในระบบตรวจจับโรคแบบเรียลไทม์ได้ ทำให้เกษตรกรสามารถตรวจสอบและจัดการโรคได้อย่างมีประสิทธิภาพ ลดการใช้สารเคมีอย่างไม่จำเป็น และเพิ่มผลผลิตที่มีคุณภาพ


4. Tomato Leaf Disease Diagnosis Based on Improved Convolution Neural Network by Attention Module

งานวิจัยด้านการตรวจจับโรคพืชโดยใช้เทคโนโลยี Deep Learning ได้รับความสนใจอย่างมากในช่วงไม่กี่ปีที่ผ่านมา เนื่องจากความสามารถในการช่วยเกษตรกรในการจัดการโรคได้อย่างรวดเร็วและมีประสิทธิภาพ งานวิจัยส่วนใหญ่เน้นไปที่การพัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อลดความซับซ้อนในการวิเคราะห์ภาพและเพิ่มความแม่นยำในการจำแนกโรค เช่นเดียวกับการประยุกต์ใช้ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันในการจำแนกโรคพืชหลายประเภทในสภาพแวดล้อมธรรมชาติ ทำให้การวินิจฉัยมีความแม่นยำยิ่งขึ้นและลดต้นทุนการใช้งา

แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันได้รับการพิสูจน์ว่ามีความแม่นยำมากกว่าวิธีการแยกคุณลักษณะแบบดั้งเดิม เช่น SVM หรือการวิเคราะห์เนื้อสัมผัสและสี ตัวอย่างเช่น He et al. (2016) เสนอโมเดล ResNet ที่สามารถแก้ปัญหา Gradient Vanishing และลดจำนวนพารามิเตอร์ได้อย่างมีประสิทธิภาพ โมเดลนี้ได้รับรางวัลใน ImageNet Large-Scale Visual Recognition Challenge 2015 ซึ่งแสดงให้เห็นถึงศักยภาพของ Residual Networks ในการตรวจจับโรคพืชอย่างแม่นยำ

อย่างไรก็ตาม การวิจัยในปัจจุบันได้ขยายไปสู่การเพิ่มโมดูล Attention Mechanism เข้าในโครงสร้างของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันเพื่อเพิ่มประสิทธิภาพการแยกคุณลักษณะในพื้นที่ที่สำคัญ งานวิจัยของ Hu et al. (2018) เสนอโมดูล Squeeze-and-

Excitation (SE) ที่ช่วยในการเน้นช่องสัญญาณที่สำคัญและลดสัญญาณที่ไม่จำเป็น ทำให้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน สามารถจำแนกโรคได้ดีขึ้นในสภาพแวดล้อมที่มีความซับซ้อน งานวิจัยนี้ประยุกต์ใช้ SE-ResNet50 ซึ่งเป็นโครงข่ายที่ผสมผสานโมดูล SE เข้ากับ ResNet-50 ทำให้การเรียนรู้มีประสิทธิภาพมากขึ้น



ภาพประกอบ 18 The training accuracy curves: (a) SE-ResNet50 accuracy curves; (b) Comparison model accuracy curves.

จากผลการทดลองตามภาพประกอบ 18 โมเดล SE-ResNet50 สามารถบรรลุความแม่นยำในการวินิจฉัยโรคใบมะเขือเทศได้ถึง 96.81% ซึ่งสูงกว่ารุ่นพื้นฐานของ ResNet-50 ถึง 4.25% การเพิ่มโมดูล Attention ยังช่วยลดเวลาการวินิจฉัยต่อภาพลงเหลือเพียง 31.68 มิลลิวินาที ซึ่งเหมาะสำหรับการประยุกต์ใช้ในงานเกษตรแบบเรียลไทม์ นอกจากนี้ การทดสอบกับชุดข้อมูลโรคใบองุ่นแสดงให้เห็นว่าประสิทธิภาพของโมเดลสามารถขยายไปสู่พืชชนิดอื่นได้ โดยมีความแม่นยำถึง 99.24%

โดยสรุป การผสมผสานเทคนิค Attention เข้ากับโครงข่ายประสาทเทียมแบบคอนโวลูชัน ไม่เพียงเพิ่มความแม่นยำ แต่ยังช่วยให้โมเดลสามารถทำงานได้เร็วขึ้นและมีความยืดหยุ่นมากขึ้น โมเดลนี้ไม่เพียงช่วยให้เกษตรกรตรวจจับโรคได้อย่างมีประสิทธิภาพ แต่ยังช่วยลดการใช้สารเคมีอย่างไม่จำเป็นและเพิ่มผลผลิตในระยะยาว งานวิจัยนี้มีศักยภาพในการประยุกต์ใช้กับหุ่นยนต์ตรวจสอบภาคสนาม และเปิดโอกาสในการพัฒนาเทคโนโลยีด้านการเกษตรอัจฉริยะในอนาคต

5. Optimizing Pretrained Convolutional Neural Networks for Tomato Leaf Disease Detection

งานวิจัยเกี่ยวกับการตรวจจับโรคพืชโดยใช้โครงข่ายประสาทเทียม (Neural Networks) โดยเฉพาะอย่างยิ่ง แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันมีความสำคัญ

ในการช่วยลดความเสียหายที่เกิดจากโรคและเพิ่มประสิทธิภาพในภาคเกษตรกรรม งานวิจัยนี้ได้เน้นไปที่การตรวจจับโรคในใบมะเขือเทศ โดยใช้งานสถาปัตยกรรมที่มีอยู่ เช่น VGG-16, VGG-19, ResNet, และ Inception V3 เพื่อทดสอบความแม่นยำในการจำแนกโรคพืชจากข้อมูลภาพ (Ahmad et al., 2020)

ในงานวิจัยก่อนหน้านี้ Durmuş et al. (2017) ใช้ AlexNet และ SqueezeNet กับชุดข้อมูล PlantVillage ในการตรวจจับโรคใบมะเขือเทศ แต่พบข้อจำกัดในด้านการวัดผลที่ไม่ได้พิจารณาตัวชี้วัดมาตรฐาน เช่น Precision, Recall และ F1-score นอกจากนี้ Tm et al. (2018) ได้เสนอ LeNet ในการตรวจจับโรคพืช และ Mohanty et al. (2016) ใช้ AlexNet และ GoogLeNet ในการพัฒนาระบบตรวจจับ ซึ่งสามารถบรรลุความแม่นยำได้สูงถึง 99.35% จากชุดข้อมูลที่เก็บในสภาพแวดล้อมที่มีการควบคุม อย่างไรก็ตาม ปัญหาที่พบในงานวิจัยหลายชิ้นคือ การพึ่งพาชุดข้อมูลที่ควบคุมอย่างเข้มงวด ซึ่งไม่ได้สะท้อนสภาพแวดล้อมจริงในภาคสนาม

งานวิจัยนี้ได้พัฒนาต่อยอดโดยใช้ ชุดข้อมูลสองประเภท ได้แก่ ชุดข้อมูลที่เก็บในห้องปฏิบัติการและชุดข้อมูลที่เก็บจากภาคสนาม ซึ่งช่วยให้การวัดประสิทธิภาพมีความสมจริงมากขึ้น การใช้เทคนิค Data Augmentation ในการเพิ่มจำนวนข้อมูลยังช่วยแก้ปัญหการขาดแคลนข้อมูลในภาคสนามได้อย่างมีประสิทธิภาพ ผลการทดลองชี้ให้เห็นว่า Inception V3 เป็นโมเดลที่มีประสิทธิภาพสูงสุด โดยมีความแม่นยำถึง 99.6% บนชุดข้อมูลจากห้องปฏิบัติการ และ 93.7% บนชุดข้อมูลภาคสนาม ซึ่งแสดงถึงความสามารถในการจัดการกับความซับซ้อนและความหลากหลายของข้อมูลที่เก็บจากสภาพแวดล้อมจริง

ตาราง 3 ความแม่นยำในการจำแนกประเภทด้วยการปรับแต่งพารามิเตอร์

Model	Laboratory dataset (%)	Field dataset (%)
VGG-16	98.50	84.10
VGG-19	98.50	86.30
ResNet	99.40	91.30
Inception V3	99.60	93.70

ตาราง 4 การวัดค่าการเรียกคืน ความแม่นยำ และค่า F1-score จากกระบวนการปรับแต่งพารามิเตอร์ของแบบจำลอง

Model	Recall		Precision		F1-score	
	Laboratory	Field	Laboratory	Field	Laboratory	Field
VGG-16	0.991	0.792	0.99	0.758	0.99	0.776
VGG-19	0.991	0.847	0.989	0.811	0.989	0.828
ResNet	0.995	0.883	0.994	0.841	0.994	0.861
Inception V3	0.996	0.906	0.996	0.845	0.995	0.876

นอกจากนี้ ผลการทดลอง ตาราง 3, ตาราง 4 ยังแสดงให้เห็นว่า การปรับพารามิเตอร์ (Parameter Tuning) ช่วยเพิ่มประสิทธิภาพของโมเดลได้มากกว่าการใช้ฟังก์ชันการดึงคุณลักษณะเพียงอย่างเดียว โดยการปรับพารามิเตอร์ในเลเยอร์ความหนาแน่นสูง (High-dimensional Layers) ของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันช่วยให้ระบบสามารถเรียนรู้คุณลักษณะเฉพาะของโรคใบมะเขือเทศได้อย่างแม่นยำ

สรุปได้ว่า การใช้ แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ปรับแต่งด้วยข้อมูลจากภาคสนาม เป็นแนวทางสำคัญในการเพิ่มประสิทธิภาพของการตรวจจับโรคพืชในสภาพแวดล้อมที่หลากหลาย งานวิจัยนี้เน้นย้ำถึงความสำคัญของการใช้งานโมเดลที่สามารถรองรับความท้าทายจากการเก็บข้อมูลภาคสนาม และแสดงถึงศักยภาพของ Inception V3 ในการเป็นโซลูชันที่มีประสิทธิภาพสูงสำหรับการตรวจจับโรคพืชอย่างอัตโนมัติ

ตาราง 5 สรุปงานวิจัยที่เกี่ยวข้องในงานวิจัย

ปี	งานวิจัย	โมเดล	ผลลัพธ์
2024	A new AI-based approach for Automatic Identification of Tea Leaf Disease using Deep Neural Network based on Hybrid Pooling (Heng & Yu & Zhang, 2024)	- โมเดล CNN ที่ใช้ Hybrid Pooling สำหรับการดึงลักษณะภาพโดยเฉพาะสำหรับโรคใบชา - โมเดล WRF ที่ถูกถ่วงน้ำหนักด้วยอัลกอริทึม CSO	ผลการทดลอง: โมเดลได้ค่า Accuracy 92.47% ซึ่งสูงกว่าวิธีการอื่นๆ เช่น Max Pooling + WRF (90.12%) และ Average Pooling + WRF (89.01%)
2024	Revolutionising Tea Cultivation: A Novel DCNN Approach for HighPrecision Leaf Disease Classification (Subbarao, 2024)	- โมเดล DCNN ที่ประกอบด้วยหลาย Convolutional layers และ Dropout layers เพื่อป้องกันการ overfitting โดยใช้การเชื่อมต่อแบบ residual เพื่อเพิ่มความมั่นคงในการเทรนโมเดล ชั้นสุดท้ายของโมเดลคือ softmax ที่ใช้ในการจำแนกโรคใบชาหลายชนิด	ผลการทดลอง: - โมเดล DCNN ได้ Accuracy 99.4% ในการจำแนกโรคใบชา - DenseNet121 ได้ Accuracy 97.2% เทียบประสิทธิภาพ Epoch: - 10 epochs: 65.5% - 100 epochs: 99.4%
2021	Automatic Detection of Tea Leaf Diseases using Deep Convolution Neural Network (Latha & Kongu, 2021)	- โมเดล CNN ถูกใช้เพื่อดึงลักษณะเฉพาะของภาพใบชา โดยมี 1 input layer, 4 convolution layers, และ 2 fully connected layers - การดึงลักษณะภาพ: convolution layers ถูกใช้เพื่อดึงข้อมูลคุณลักษณะจากภาพ และการจำแนกประเภทของใบชาจะทำในชั้น output ด้วยการใช้ฟังก์ชัน Softmax เพื่อจำแนกเป็น 8 ประเภทของโรคใบชา	ผลการทดลอง: โมเดล CNN ได้ค่า Accuracy 94.45%
2021	Tomato Leaf Disease Diagnosis Based on Improved	- การพัฒนาโมเดล CNN ที่ผสมผสาน Squeeze-and-Excitation Networks เข้าไปใน ResNet-50	ผลการทดลอง: โมเดล SE-ResNet50 ได้ค่า Accuracy 96.81%

	Convolution Neural Network by Attention Module (Shengyi & Yun & Jizhan, 2021)	- ใช้ Squeeze-and-Excitation เพื่อลดขนาดข้อมูลและเพิ่มความสามารถในการจำแนกลักษณะเฉพาะจากภาพ	
2020	Optimizing Pretrained Convolutional Neural Networks for Tomato Leaf Disease Detection (Irfan, 2020)	- ใช้ Pretrained Convolutional Neural Networks เช่น VGG-16, VGG-19, ResNet และ Inception V3 - โดยมีการปรับพารามิเตอร์ของเลเยอร์สูงในโมเดลเหล่านี้เพื่อให้เหมาะสมกับข้อมูลใบมะเขือเทศ และทำการเทรนและทดสอบด้วย 10-fold cross-validation	ผลการทดลอง: โมเดล Inception V3 ได้ค่า Accuracy ที่สูงที่สุดในชุดข้อมูลทั้งสอง คือ - ชุดข้อมูลห้องทดลอง ได้ Accuracy 99.6% - ชุดข้อมูลภาคสนาม ได้ Accuracy 93.7%



บทที่ 3


วิธีดำเนินงานวิจัย

ผู้วิจัยได้ศึกษา และนำเสนอการจำแนกโรคใบชาด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยใช้ชุดข้อมูล Tea Sickness Dataset ซึ่งดำเนินการวิจัยตามขั้นตอนดังต่อไปนี้

1. กระบวนการสร้างแบบจำลอง
2. การได้มาซึ่งข้อมูล (Data Acquisition)
3. การจัดเตรียมและรวบรวมข้อมูล (Data Preparation)
4. การจัดการข้อมูล (Data Preprocessing)
5. การพัฒนาแบบจำลอง (Model Development)
6. การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)
7. สรุปผลการดำเนินงาน

3.1 การออกแบบขั้นตอนในการดำเนินงานวิจัย

การดำเนินการวิจัยนี้ได้รับการออกแบบอย่างเป็นระบบเพื่อให้สามารถนำเทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน มาใช้ในการจำแนกโรคใบชาได้อย่างมีประสิทธิภาพ



ภาพประกอบ 19 แผนภาพแสดงขั้นตอนการทำงานของโมเดล

จากภาพประกอบ 19 โดยเริ่มต้นจากการสำรวจและรวบรวมชุดข้อมูลภาพถ่ายใบชาที่มีลักษณะของโรคแตกต่างกันทั้งหมด 8 ประเภท ซึ่งประกอบด้วยใบปกติ, โรคใบจุดขาว, โรคใบจุดสาหร่าย, โรคใบจุดตานก, โรคใบเทา, โรคใบไหม้สีน้ำตาล, โรคแอนแทรคโนส และโรคจุดใบสีแดง และทำการตรวจสอบรูปภาพที่ว่างเปล่า จากนั้นทำการจัดเตรียมข้อมูลให้อยู่ในรูปแบบที่เหมาะสมกับการประมวลผลด้วยโครงข่ายประสาทเทียมโดยผ่านกระบวนการแปลงขนาดภาพให้เท่ากันทั้งหมด และการปรับสีภาพออกเป็น 4 แบบด้วยกันคือ 1) ภาพต้นฉบับ RGB 2) ปรับสีโดยใช้เทคนิค Fuzzy Contrast Enhancement 3) แปลงภาพจาก RGB เป็น HIS และ 4) การปรับสีภาพด้วย CLAHE และใช้เทคนิคการเสริมข้อมูล เพื่อให้โมเดลสามารถเรียนรู้จากข้อมูลได้หลากหลายยิ่งขึ้น ต่อมาคือการออกแบบโครงสร้างของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีความเหมาะสมกับลักษณะของภาพใบชา และใช้การฝึกสอนโมเดลด้วยข้อมูลที่เตรียมไว้ โดยแบ่งข้อมูลออกเป็นชุดฝึกและชุดตรวจสอบ จากนั้นประเมินผลโมเดลด้วยตัวชี้วัดทางสถิติ เช่น

Accuracy, Precision, Recall, F1-score และ Confusion Matrix เพื่อตรวจสอบความแม่นยำและความสามารถในการจำแนกประเภทของโรค

3.2 การได้มาซึ่งข้อมูล

ข้อมูลที่ใช้ในงานวิจัยนี้ได้มาจากชุดข้อมูลภาพถ่ายใบชาที่ถูกรวบรวมไว้ในโฟลเดอร์ชื่อ Tea Sickness Dataset ซึ่งภายในประกอบด้วยโฟลเดอร์ย่อยทั้งหมด 8 โฟลเดอร์ แสดงถึงแต่ละประเภทของโรคใบชา โดยใช้ชื่อโฟลเดอร์ตามชื่อของโรคนั้น ๆ ภายในแต่ละโฟลเดอร์มีภาพถ่ายใบชาที่แสดงลักษณะเฉพาะของโรคแต่ละชนิด โดยภาพทั้งหมดอยู่ในรูปแบบไฟล์ .jpg ซึ่งสามารถนำไปใช้ประมวลผลและฝึกโมเดลได้ทันที ภาพเหล่านี้ได้มาจากแหล่งข้อมูลจริงทั้งในแหล่งเพาะปลูกของเกษตรกรและแหล่งข้อมูลเปิดบนอินเทอร์เน็ต ซึ่งผ่านการอนุญาตให้ใช้งานในทางวิชาการอย่างถูกต้อง การได้มาซึ่งข้อมูลจึงถือเป็นขั้นตอนสำคัญในการวางรากฐานของการวิจัยเพื่อให้ได้ข้อมูลที่ครบถ้วน ครอบคลุม และเหมาะสมสำหรับการฝึกสอนโมเดลจำแนกโรค


3.2.1 การสำรวจข้อมูลเบื้องต้น

ข้อมูลที่นำมาใช้ในงานวิจัย เป็นชุดข้อมูลจากงานวิจัยเรื่อง A new AI-based approach for automatic identification of tea leaf disease using deep neural network based on hybrid pooling เพื่อจำแนกประเภทโรคที่เกิดบนใบชา ประกอบด้วยรูปภาพใบชาจำนวน แบ่งออกเป็น 8 ประเภทตามตาราง 6

ตาราง 6 แสดงข้อมูลจำนวนใบชา 8 ประเภท

ลำดับที่	ประเภท	จำนวน (ภาพ)
1	ใบปกติ (Healthy)	74
2	โรคจุดขาว (White Spot)	142
3	โรคใบจุดสาหร่าย (Algal Leaf)	113
4	โรคใบจุดตานก (Bird Eye Spot)	100
5	โรคใบเทา (Grey Light)	100
6	โรคใบไหม้สีน้ำตาล (Brown Blight)	113
7	โรคแอนแทรคโนส (Anthracnose)	100
8	โรคจุดใบสีแดง (Red Leaf Spot)	143

ภาพประกอบ 20 แสดงถึงสัดส่วนรูปภาพของใบชาที่เป็นโรคแต่ละประเภท ทั้งหมด 8 ประเภทก่อนทำการจัดการข้อมูล



ภาพประกอบ 20 แสดงถึงสัดส่วนรูปภาพของใบชา 8 ประเภท

3.2.2 แหล่งที่มาของข้อมูล

ข้อมูลที่นำมาใช้ในงานวิจัย เป็นภาพจากแหล่งข้อมูลเปิด (Open Access Sources): ได้แก่ เว็บไซต์เผยแพร่ข้อมูลวิชาการ เช่น Kaggle, Mendeley ที่มีการอนุญาตให้ใช้เพื่อการวิจัย โดยผ่านการคัดเลือกและตรวจสอบสิทธิการใช้งานอย่างถูกต้องตามหลักจริยธรรมทางวิชาการ

3.3 การจัดเตรียมข้อมูล

ก่อนเริ่มกระบวนการประมวลผลข้อมูล ผู้วิจัยได้ดำเนินการจัดเตรียมและรวบรวมข้อมูลให้เหมาะสมสำหรับนำเข้าไปในกระบวนการฝึกโมเดล โดยเริ่มจากการตรวจสอบความถูกต้องของข้อมูลภาพ เช่น ตรวจสอบว่าไม่มีไฟล์ที่เสียหายหรือว่างเปล่า ชื่อไฟล์ตรงกับชื่อของโรคที่ต้องการจำแนกอย่างถูกต้อง นอกจากนี้ยังมีการแยกภาพแต่ละประเภทออกจากกันเพื่อความสะดวกในการนำข้อมูลผ่านฟังก์ชันของ TensorFlow ซึ่งต้องอาศัยโครงสร้างโฟลเดอร์ที่เป็นระเบียบ โดยแต่ละภาพต้องอยู่ในโฟลเดอร์ของคลาสที่ระบุไว้ จากนั้นจึงตรวจนับจำนวนภาพในแต่ละประเภทเพื่อประเมินความสมดุลของข้อมูล ทั้งนี้เพื่อหลีกเลี่ยงปัญหาโมเดลลำเอียงไปยังคลาสใดคลาสหนึ่งหากมีจำนวนภาพแตกต่างกันมาก

3.3.1 การทำความสะอาดข้อมูล

ข้อมูลที่นำมาใช้ในงานวิจัยในชุดข้อมูลของภาพใบชาบางประเภทของโรค มีชุดของข้อมูลที่ไม่สมบูรณ์ จึงต้องทำการลบข้อมูลที่ไม่สมบูรณ์ ซึ่งมีข้อมูลดังนี้

ใบปกติ



ภาพประกอบ 21 ใบปกติที่ไม่สมบูรณ์

โรคจุดขาว



ภาพประกอบ 22 โรคจุดขาวที่ไม่สมบูรณ์

โรคแอนแทรคโนส




ภาพประกอบ 23 โรคแอนแทรคโนสที่ไม่สมบูรณ์

ดังนั้น ขนาดของจำนวนรูปภาพจะมีการเปลี่ยนแปลงดังตาราง

ตาราง 7 ข้อมูลแสดงจำนวนรูปภาพใบชาหลังการสำรวจและทำความสะอาดชุดข้อมูล

ลำดับที่	ประเภท	จำนวน (ภาพ)
1	ใบปกติ (Healthy)	73
2	โรคจุดขาว (White Spot)	140
3	โรคใบจุดสาก (Algal Leaf)	113
4	โรคใบจุดตานก (Bird Eye Spot)	100
5	โรคใบเทา (Grey Light)	100
6	โรคใบไหม้สีน้ำตาล (Brown Blight)	113
7	โรคแอนแทรคโนส (Anthracnose)	99
8	โรคจุดใบสีแดง (Red Leaf Spot)	143

สัดส่วนของกราฟจะเปลี่ยนไปตามภาพประกอบ 24



ภาพประกอบ 24 แสดงถึงสัดส่วนรูปภาพของใบชา 8 ประเภทหลังทำความสะอาดชุดข้อมูล

3.3 การจัดการข้อมูล

เมื่อได้ข้อมูลที่มีคุณภาพและโครงสร้างที่เหมาะสมแล้ว ขั้นตอนถัดไปคือการจัดการข้อมูล ซึ่งถือเป็นกระบวนการสำคัญในการเตรียมข้อมูลก่อนเข้าสู่การฝึกแบบจำลอง ในงานวิจัยนี้ ผู้วิจัยได้ดำเนินการปรับขนาดภาพทั้งหมดให้มีขนาดมาตรฐานเดียวกันที่ 224x224 พิกเซล เพื่อให้สามารถประมวลผลได้อย่างมีประสิทธิภาพโดยโครงข่ายประสาทเทียมแบบคอนโวลูชัน ซึ่งการกำหนดขนาดภาพให้เหมาะสมนี้ช่วยลดภาระของการคำนวณและช่วยให้แบบจำลองสามารถเรียนรู้ข้อมูลได้รวดเร็วและเสถียรมากขึ้น

จากนั้น ได้ทำการแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ ชุดข้อมูลฝึก (Training set) ร้อยละ 80 และ ชุดข้อมูลตรวจสอบ (Validation set) ร้อยละ 20 ซึ่งสอดคล้องกับแนวทางทางวิทยาศาสตร์ที่ช่วยให้สามารถประเมินผลแบบจำลองได้อย่างแม่นยำและหลีกเลี่ยงปัญหา Overfitting ที่อาจเกิดขึ้นระหว่างการฝึกแบบจำลอง

เพื่อเพิ่มความหลากหลายของข้อมูลและช่วยให้แบบจำลองสามารถเรียนรู้ได้ดีขึ้นในสถานการณ์ที่แตกต่างกัน ผู้วิจัยได้นำเทคนิค Data Augmentation มาใช้ ซึ่งประกอบด้วยการสุ่มหมุนภาพ การซูมภาพ การพลิกภาพในแนวตั้งและแนวนอน และการสุ่มเปลี่ยนมุมมองของภาพ วิธีนี้ช่วยจำลองสภาพแวดล้อมที่หลากหลายและช่วยลดปัญหา overfitting ได้อย่างมีประสิทธิภาพ โดยได้มีการทำจัดเตรียมข้อมูลดังนี้


3.3.1 การปรับขนาดภาพ

เพื่อให้สามารถนำภาพเข้าสู่แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันได้อย่างเหมาะสม ผู้วิจัยได้ทำการปรับขนาดของภาพทั้งหมดในชุดข้อมูลให้มีความกว้างและความสูงเท่ากัน คือ 224×224 พิกเซล ซึ่งเป็นขนาดที่นิยมใช้ในงานวิจัยด้านการเรียนรู้เชิงลึก เนื่องจากสามารถรักษาคูณลักษณะที่สำคัญของภาพไว้ได้ ขณะเดียวกันก็ไม่ทำให้การคำนวณใช้ทรัพยากรมากเกินไป ขั้นตอนนี้ช่วยให้ข้อมูลมีมาตรฐานเดียวกัน และสามารถประมวลผลได้อย่างมีประสิทธิภาพในขั้นตอนถัดไป

3.3.2 การปรับสีภาพ

3.3.2.1 ภาพต้นฉบับ (Original RGB)


ภาพในชุดข้อมูลต้นฉบับถูกใช้โดยไม่มีการปรับสี อยู่ในรูปแบบ RGB (Red, Green, Blue) ซึ่งเป็นรูปแบบมาตรฐานของภาพดิจิทัล การใช้ภาพต้นฉบับนี้เป็นฐานสำหรับเปรียบเทียบกับวิธีการปรับสีแบบอื่น เพื่อประเมินว่าเทคนิคการแปลงสีช่วยให้โมเดลเรียนรู้ได้ดีขึ้นหรือไม่ ตามภาพประกอบ 25



ภาพประกอบ 25 ภาพต้นฉบับตัวอย่างใบชา

3.3.2.2 การปรับสีโดยใช้เทคนิค Fuzzy Enhancement

เทคนิค Fuzzy Contrast Enhancement เป็นการประมวลผลภาพด้วยตรรกะฟัซซี (Fuzzy Logic) เพื่อเพิ่มความคมชัดและปรับค่าความเปรียบต่างของภาพให้เหมาะสมโดยอัตโนมัติ เทคนิคนี้จะคำนวณระดับความสว่างของแต่ละพิกเซลและปรับค่าตามฟังก์ชันฟัซซีที่กำหนดไว้ ทำให้ลักษณะของโรคในภาพมีความโดดเด่นมากยิ่งขึ้น เช่น จุดรอยโรคจะคมชัดขึ้นหรือมีสีที่ตัดกับพื้นใบอย่างชัดเจน ซึ่งช่วยลดผลกระทบจากภาพที่มีแสงน้อยหรือแสงจ้าเกินไป ตามภาพประกอบ 26 ด้านล่าง




ภาพประกอบ 26 ภาพตัวอย่างใบชาตามประเภทที่ทำการแปลงสีด้วยเทคนิค Fuzzy

3.3.2.3 การแปลงค่าสีจาก RGB เป็น HSI

การแปลงค่าสีจาก RGB เป็น HSI (Hue, Saturation, Intensity) มีจุดมุ่งหมายเพื่อให้โมเดลสามารถเข้าใจองค์ประกอบของสีที่มนุษย์มองเห็นได้ดีกว่า โดย HSI แยกองค์ประกอบของสีออกเป็น:

- Hue (H): แสดงเฉดสี เช่น แดง เขียว น้ำเงิน
- Saturation (S): ความเข้มของสี
- Intensity (I): ความสว่างของสี


การแปลงนี้ช่วยให้ลักษณะของโรค เช่น จุดสี รอยไหม้ หรือความชื้นของใบ สามารถถูกจับได้เด่นชัดขึ้นจากข้อมูลเชิงสีที่แยกออกจากกัน ตามภาพประกอบ 27



ภาพประกอบ 27 ภาพตัวอย่างใบชาตามประเภทที่ทำการแปลงสีเป็น HSI

3.3.2.4 การปรับสีภาพด้วย CLAHE (Contrast Limited Adaptive Histogram Equalization)

เป็นการเพิ่มความคมชัดของภาพโดยการปรับปรุงค่าความเปรียบต่างของภาพในระดับท้องถิ่น (Local Contrast Enhancement) ซึ่งช่วยเน้นรายละเอียดของโรคในบริเวณที่มีความแตกต่างของความสว่างต่ำ เช่น บริเวณจุดสีหรือรอยโรคที่มีความเข้มของสีใกล้เคียงกัน วิธีนี้จะแบ่งภาพออกเป็นหลายส่วนย่อย (Tiles) และทำการปรับ histogram ในแต่ละส่วนแยกจากกัน พร้อมใช้ขีดจำกัดคอนทราสต์ (Clip Limit) เพื่อป้องกันไม่ให้อายุคอนทราสต์มากเกินไป CLAHE ช่วยให้รายละเอียดของรอยโรคในภาพโดดเด่นขึ้นโดยไม่ทำให้เกิดการเปลี่ยนแปลงคอนทราสต์มากเกินไปจนความจำเป็น ส่งผลให้โมเดลสามารถเรียนรู้ลักษณะเฉพาะของโรคใบชาได้ดีขึ้น แม้ในกรณีที่ภาพมีแสงไม่สม่ำเสมอหรือรายละเอียดจาง ตามภาพประกอบ



ภาพประกอบ 28 ภาพตัวอย่างใบชาตามประเภทที่ปรับสีด้วย CLAHE


3.3.2.5 เปรียบเทียบค่าความสว่างของภาพด้วย Histogram

จากภาพประกอบ 29 แสดงตัวอย่างภาพใบชาหลังการประมวลผลด้วยเทคนิคการปรับปรุงความเปรียบต่างที่แตกต่างกัน ได้แก่ ภาพต้นฉบับ, การแปลงค่าสีจากระบบ RGB ไปยังระบบ HSI, การปรับ contrast ด้วยวิธี CLAHE และการปรับ contrast โดยใช้แนวคิดฟัซซีลอจิก ซึ่งแต่ละเทคนิคมีจุดมุ่งหมายในการเพิ่มคุณภาพของภาพให้เหมาะสมต่อการนำไปใช้งานด้านการจำแนกโรคใบชาในลำดับต่อไป

ในภาพด้านบนของแต่ละชุด แสดงผลลัพธ์ของภาพหลังผ่านกระบวนการปรับปรุงด้วยเทคนิคนั้น ๆ ส่วนภาพด้านล่างแสดงกราฟฮิสโตแกรมของค่าความเข้มแสง หรือความสว่างของพิกเซลในภาพ ซึ่งเป็นตัวบ่งชี้สำคัญในการประเมินการกระจายของค่าสีภายในภาพ

จากฮิสโตแกรมสามารถสังเกตได้ว่า:

- 1) ภาพต้นฉบับมีการกระจุกตัวของค่าสีอยู่ในช่วงค่าความสว่างสูง
- 2) การแปลงเป็น HSI ส่งผลให้เกิดการกระจายค่าความสว่างที่ต่างออกไป โดยเฉพาะในช่องความเข้มแสง
- 3) CLAHE ช่วยกระจายค่าสีให้ครอบคลุมมากขึ้น ลดการกระจุกของค่าสีในช่วงใดช่วงหนึ่ง
- 4) เทคนิค Fuzzy Contrast Enhancement แสดงให้เห็นถึงการกระจายที่ยืดหยุ่นและมีลักษณะเฉพาะ อันเป็นผลจากกระบวนการเสริม contrast แบบไม่เชิงเส้นตามหลักฟัซซี



ภาพประกอบ 29 ตัวอย่างภาพใบชาหลังผ่านกระบวนการปรับปรุงความเปรียบต่างด้วยเทคนิคต่าง ๆ ได้แก่ Original, HSI, CLAHE และ Fuzzy พร้อมแสดงฮิสโตแกรมของค่าความสว่าง

3.3.3 การแบ่งชุดข้อมูล

หลังจากการปรับขนาดภาพแล้ว ผู้วิจัยได้ทำการแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่

- 1) ชุดข้อมูลฝึก (Training Set) คิดเป็น ร้อยละ 80 ของจำนวนภาพทั้งหมด ใช้สำหรับฝึกแบบจำลองให้เรียนรู้ลักษณะของโรคต่าง ๆ
- 2) ชุดข้อมูลตรวจสอบ (Validation Set) คิดเป็น ร้อยละ 20 ใช้สำหรับประเมินความสามารถของแบบจำลองในขณะฝึก เพื่อวิเคราะห์ว่าโมเดลสามารถเรียนรู้และทั่วไปข้อมูลได้ดีเพียงใด

การแบ่งข้อมูลในสัดส่วนที่เหมาะสมช่วยให้สามารถประเมินประสิทธิภาพของโมเดลได้อย่างแม่นยำ และลดโอกาสการเกิด overfitting

ตาราง 8 จำนวนรูปภาพใบชาหลังจากแบ่งข้อมูลสำหรับสร้างแบบจำลอง และทดสอบแบบจำลอง

ลำดับที่	ประเภท	Train	Test	Total
1	ใบปกติ (Healthy)	59	14	73
2	โรคจุดขาว (White Spot)	112	28	140
3	โรคใบจุดสาหร่าย (Algal Leaf)	90	23	113
4	โรคใบจุดตานก (Bird Eye Spot)	80	20	100
5	โรคใบเทา (Grey Light)	80	20	100
6	โรคใบไหม้สีน้ำตาล (Brown Blight)	90	23	113
7	โรคแอนแทรคโนส (Anthracnose)	79	20	99
8	โรคจุดใบสีแดง (Red Leaf Spot)	114	29	143

3.3.4 การเพิ่มข้อมูล

เพื่อให้โมเดลสามารถเรียนรู้จากข้อมูลได้ดียิ่งขึ้น และลดปัญหา Overfitting ผู้วิจัยได้นำเทคนิค Data Augmentation มาใช้ในการเพิ่มความหลากหลายให้กับชุดข้อมูลฝึก โดยการแปลงภาพด้วยวิธีต่าง ๆ เช่น:

- 1) การหมุนภาพ (Rotation) เพื่อเลียนแบบการเปลี่ยนทิศทางของใบชาในสภาพแวดล้อมจริง
- 2) การซูมเข้า/ออก (Zooming) เพื่อให้โมเดลสามารถจดจำลักษณะโรคได้ในมุมมองที่แตกต่าง
- 3) การพลิกภาพในแนวดิ่งและแนวนอน (Vertical & Horizontal Flipping) เพื่อจำลองภาพในลักษณะที่หลากหลาย
- 4) การเลื่อนตำแหน่งภาพในแนวนอน (Width Shift): เลื่อนตำแหน่งของภาพในแนวนอนสูงสุด 20% ของความกว้างภาพ เพื่อจำลองกรณีที่ใบชาไม่ได้อยู่ตรงกลางของภาพ

- 5) การเลื่อนตำแหน่งภาพในแนวตั้ง (Height Shift): เลื่อนตำแหน่งของภาพในแนวตั้งสูงสุด 20% ของความสูงภาพ เพื่อจำลองกรณีที่ตำแหน่งของใบชาเปลี่ยนไปในแนวตั้ง
- 6) การบิดภาพ (Shear): บิดภาพด้วยมุมสูงสุด 20 องศา เพื่อจำลองการเปลี่ยนแปลงของรูปทรงใบชา ซึ่งอาจเกิดจากมุมกล้องหรือการเคลื่อนที่ของใบชาในสภาพแวดล้อมจริง
- 7) การปรับความสว่างของภาพ (Brightness Adjustment): ปรับระดับความสว่างของภาพในช่วง 90% ถึง 110% ของความสว่างเดิม เพื่อช่วยให้โมเดลสามารถรับมือกับสภาพแสงที่แตกต่างกัน เช่น แสงจ้าในเวลากลางวันหรือแสงน้อยในช่วงเย็น

การเพิ่มข้อมูลด้วยวิธีเหล่านี้ช่วยให้โมเดลมีความสามารถในการจำแนกลักษณะของโรคที่ปรากฏในลักษณะต่าง ๆ ได้ดียิ่งขึ้น และทำให้แบบจำลองมีความยืดหยุ่นและสามารถใช้งานได้ในสถานการณ์จริงมากขึ้น

3.4 การสร้างแบบจำลอง

ในงานวิจัยนี้ ผู้วิจัยได้ออกแบบและสร้างแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยมีเป้าหมายในการจำแนกประเภทของโรคใบชาออกจากกันได้อย่างแม่นยำ ซึ่งในขั้นตอนนี้ได้แบ่งการสร้างแบบทดสอบออกเป็น 4 รูปแบบหลัก โดยอิงจากลักษณะการปรับสีของภาพที่แตกต่างกัน ได้แก่:

1. แบบการทดลองที่ใช้ภาพต้นฉบับ (Original RGB)
2. แบบการทดลองที่ใช้เทคนิคการเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement
3. แบบการทดลองที่แปลงภาพจาก RGB เป็น HSI (Hue-Saturation-Intensity)
4. แบบการทดลองที่ใช้เทคนิคการเพิ่มความคมชัดด้วย CLAHE (Contrast Limited Adaptive Histogram Equalization)

ก่อนนำข้อมูลเข้าแบบจำลอง จะมีการปรับขนาดภาพทั้งหมดให้มีขนาดมาตรฐาน 224x224 พิกเซล และแบ่งข้อมูลออกเป็นชุดฝึกและชุดตรวจสอบ ด้วยอัตราส่วน 80:20 (validation_split = 0.2) โดยใช้ค่า batch_size เท่ากับ 32

ต่อจากนั้น ได้นำข้อมูลเข้าสู่ขั้นตอนการเพิ่มข้อมูล เพื่อเพิ่มความหลากหลายของข้อมูล และช่วยลดปัญหา overfitting ซึ่งอาจเกิดขึ้นจากจำนวนข้อมูลที่จำกัด โดยใช้เทคนิค ได้แก่ การพลิกภาพในแนวนอน, การหมุนภาพแบบสุ่ม และการซูมภาพแบบสุ่ม, การเลื่อนภาพในแนวนอนและแนวตั้ง, การบิดภาพ, การปรับความสว่าง

สำหรับ โครงสร้างของแบบจำลอง (Model Architecture) ผู้วิจัยได้เลือกใช้แบบจำลองโครงข่ายประสาทเทียมที่ผ่านการฝึกไว้ล่วงหน้า (Pre-trained Model) โดยในที่นี้ใช้ 3 รูปแบบ ได้แก่ DenseNet121, VGG16 และ EfficientNetB1 โดยนำมาใช้เป็น base model และทำการ

fine-tuning บางส่วนของเลเยอร์ในโมเดลนี้เพื่อให้เหมาะสมกับงานจำแนกโรคใบชา โดยมีการกำหนดดังนี้:

- 1) เลเยอร์ก่อนหน้า 50 เลเยอร์สุดท้ายของ base model ถูกแช่แข็ง (freeze) เพื่อคงค่าพารามิเตอร์เดิมที่ได้จากการฝึกบน ImageNet
- 2) 50 เลเยอร์สุดท้ายของ base model ถูกปลดล็อก (unfreeze) เพื่อให้สามารถฝึกต่อได้สำหรับการเรียนรู้คุณลักษณะเฉพาะของใบชา

ส่วน Top layers ที่นำมาต่อท้าย base model ประกอบด้วย:

- 1) Global Average Pooling 2D: เพื่อย่อขนาดของ feature maps ให้เหลือเพียงค่าเฉลี่ยในแต่ละแผนที่ลักษณะ (feature map)
- 2) Dropout layer (อัตรา 0.3): เพื่อป้องกัน overfitting โดยการสุ่มปิดบางนิวรอนระหว่างการฝึก
- 3) Batch Normalization: เพื่อปรับค่าอินพุตในแต่ละชั้นให้มีความเสถียร เพิ่มความเร็วในการฝึกโมเดล
- 4) Dense layer: จำนวน 1 ชั้น มีจำนวน output เท่ากับจำนวนคลาส (8 คลาส) พร้อมฟังก์ชัน Softmax สำหรับการจำแนกประเภท

การคอมไพล์แบบจำลอง (Model Compilation) ใช้:

- 1) Optimizer: Adam โดยกำหนด learning rate = 0.0001, beta_1 = 0.9, beta_2 = 0.999, epsilon = 1e-07
- 2) Loss function: categorical_crossentropy (ใช้กับ one-hot encoded labels)
- 3) Metrics: accuracy

การฝึกแบบจำลอง ดำเนินการเป็นเวลา 50 รอบ (epochs = 50) โดยใช้ชุดข้อมูลที่เตรียมไว้ล่วงหน้า (train_ds และ val_ds) และเก็บผลลัพธ์การเรียนรู้ในแต่ละ epoch ไว้ในตัวแปร history เพื่อใช้ในการวิเคราะห์ผลการฝึกต่อไป

หลังจากการฝึกแบบจำลองเสร็จสิ้น ผลลัพธ์ของแต่ละแบบจำลองจะถูกนำมาประเมินและเปรียบเทียบประสิทธิภาพ โดยใช้ตัวชี้วัดทางสถิติ ได้แก่ Accuracy, Precision, Recall, F1-score และ Confusion Matrix เพื่อระบุว่าการปรับแต่งภาพในรูปแบบใดสามารถช่วยเพิ่มประสิทธิภาพของแบบจำลองในการจำแนกโรคใบชาได้ดีที่สุด

3.5 การประเมินผลประสิทธิภาพของแบบจำลอง

หลังจากการฝึกแบบจำลองทั้ง 4 รูปแบบเรียบร้อยแล้ว ได้แก่ แบบจำลองที่ใช้ภาพต้นฉบับ, แบบจำลองที่ผ่านการปรับคอนทราสต์ด้วย Fuzzy Contrast Enhancement, แบบจำลองที่แปลงภาพเป็น HIS และแบบจำลองใช้เทคนิคการเพิ่มความคมชัดด้วย CLAHE ผู้วิจัยได้ทำการประเมินประสิทธิภาพของแบบจำลองแต่ละรูปแบบโดยใช้ชุดข้อมูลตรวจสอบ (Validation Set) ซึ่งถูกแบ่งออกมาจากชุดข้อมูลทั้งหมดในสัดส่วนร้อยละ 20

การประเมินผลใช้ตัวชี้วัดทางสถิติที่ใช้ได้แก่:

- 1) Accuracy: ความถูกต้องโดยรวมของแบบจำลอง
- 2) Precision: ความแม่นยำในการจำแนกแต่ละประเภทโรค
- 3) Recall (Sensitivity): ความสามารถของแบบจำลองในการตรวจพบโรคในแต่ละคลาส
- 4) F1-Score: ค่าเฉลี่ยถ่วงน้ำหนักของ Precision และ Recall
- 5) Confusion Matrix: แสดงจำนวนการจำแนกถูกและผิดในแต่ละประเภท โดยจัดเป็นตารางเพื่อแสดงความสัมพันธ์ระหว่างค่าที่แท้จริงและค่าที่แบบจำลองพยากรณ์

การประเมินใช้การเปรียบเทียบผลลัพธ์จากการทำนายกับค่าจริง (Ground Truth) ของแต่ละภาพ เพื่อคำนวณตัวชี้วัดข้างต้น โดยผลลัพธ์ของแต่ละแบบจำลองจะแสดงในรูปของกราฟความแม่นยำและค่าความสูญเสีย (Loss) ทั้งในชุดฝึกและชุดตรวจสอบในแต่ละ epoch เพื่อดูแนวโน้มของการเรียนรู้ว่าโมเดลมีเสถียรภาพหรือเกิด overfitting หรือไม่

นอกจากนี้ ยังมีการแสดง Confusion Matrix แบบ Visualized ด้วย Heatmap เพื่อวิเคราะห์หาว่าการจำแนกคลาสใดผิดพลาดบ่อย หรือคลาสใดที่จำแนกได้แม่นยำเป็นพิเศษ ซึ่งข้อมูลเหล่านี้สามารถใช้วิเคราะห์จุดอ่อนของโมเดลในเชิงลึก

ผลจากการประเมินจะถูกนำมาเปรียบเทียบกับระหว่างทั้งสามรูปแบบ เพื่อหาว่าแนวทางการปรับสีภาพใดส่งผลให้โมเดลมีความแม่นยำในการจำแนกโรคใบชาดีที่สุด และเหมาะสมสำหรับนำไปใช้งานจริงในบริบทของเกษตรกรรมดิจิทัล

3.6 สรุปวิธีดำเนินงานวิจัย

การเปรียบเทียบประสิทธิภาพและกระบวนการสร้างแบบจำลองในงานวิจัยนี้ได้ดำเนินการผ่านขั้นตอนการพัฒนาและทดสอบแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันสำหรับการจำแนกโรคใบชา โดยแบ่งรูปแบบการทดลองออกเป็น 4 ประเภทหลักตามเทคนิคการปรับสีภาพ ได้แก่ ภาพต้นฉบับ, การแปลงสีเป็น HSI, การเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement และการปรับปรุงคอนทราสต์ด้วย CLAHE ทั้งหมดนี้นำมาประยุกต์ใช้ร่วมกับแบบจำลองโครงข่ายที่ผ่านการฝึกไว้ล่วงหน้า 3 แบบ ได้แก่ DenseNet121, VGG16 และ EfficientNetB1

กระบวนการสร้างแบบจำลองดำเนินการในแพลตฟอร์ม Google Colab Pro โดยกำหนดขนาดภาพที่ 224x224 พิกเซล ใช้เทคนิค Data Augmentation เพื่อเพิ่มความหลากหลายของข้อมูล และฝึกแบบจำลองด้วย Optimizer: Adam และ Loss function: categorical_crossentropy การฝึกแบบจำลองทำในจำนวน 50 epochs สำหรับแต่ละรูปแบบการทดลอง

การประเมินประสิทธิภาพของแบบจำลองดำเนินการผ่าน ตัวชี้วัดทางสถิติ ได้แก่ Accuracy, Precision, Recall, F1-score และ Confusion Matrix เพื่อเปรียบเทียบความสามารถในการจำแนกโรคใบชาของแต่ละรูปแบบการปรับสีและแต่ละโมเดล พร้อมทั้งวัด เวลาในการประมวลผล ของแต่ละแบบจำลอง เพื่อพิจารณาความเหมาะสมในการนำไปประยุกต์ใช้งานจริง

เป้าหมายของการทดลองนี้คือการค้นหา แนวทางการปรับสีภาพและโครงสร้างแบบจำลองที่มีประสิทธิภาพดีที่สุด ในการจำแนกประเภทของโรคเบาหวาน โดยอิงจากผลลัพธ์ที่ได้จากการประเมิน เพื่อพัฒนาระบบช่วยวิเคราะห์โรคเบาหวานให้สามารถนำไปใช้งานจริงในบริบทของเกษตรกรรมดิจิทัลได้อย่างเหมาะสม



บทที่ 4

ผลการดำเนินงานวิจัย

จากการดำเนินการวิจัยที่กล่าวไว้ในบทที่ 3 ซึ่งผู้วิจัยได้พัฒนาและเปรียบเทียบแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน โดยอาศัยข้อมูลภาพถ่ายใบชาที่มีลักษณะของโรคแตกต่างกันทั้งหมด 8 ประเภท ได้แก่ ใบปกติ, โรคใบจุดขาว, โรคใบจุดสาหร่าย, โรคใบจุดตานก, โรคใบเทา, โรคใบไหม้สีน้ำตาล, โรคแอนแทรคโนส และโรคจุดใบสีแดง ทั้งนี้ได้ทำการแปลงและปรับปรุงคุณภาพของภาพในรูปแบบต่าง ๆ รวมทั้งหมด 4 ลักษณะ คือ


1. แบบการทดลองที่ใช้ภาพต้นฉบับ (Original RGB)
2. แบบการทดลองที่ใช้เทคนิคการเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement
3. แบบการทดลองที่แปลงภาพจาก RGB เป็น HSI (Hue-Saturation-Intensity)
4. แบบการทดลองที่ใช้เทคนิคการเพิ่มความคมชัดด้วย CLAHE (Contrast Limited Adaptive Histogram Equalization)

4.1 แบบการทดลองที่ใช้ภาพต้นฉบับ

ภาพต้นฉบับในระบบ RGB ถูกนำมาใช้งานโดยตรง โดยไม่ผ่านการแปลงหรือปรับปรุงคุณภาพของภาพ ภาพเหล่านี้ถูกนำเข้าสู่แบบจำลอง Pretrained ทั้ง 3 แบบตามลำดับ

4.1.1 สถาปัตยกรรม DenseNet121

จากภาพประกอบ 30 และตาราง 9 ค่าประสิทธิภาพของแบบจำลองนี้ พบว่าค่า Accuracy โดยรวมอยู่ที่ 0.8927 และได้ค่า Precision, Recall และ F1-score อยู่ที่ 0.9128, 0.8926 และ 0.8914 ตามลำดับ




ภาพประกอบ 30 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121

ตาราง 9 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.9231	0.8571	0.8889
Algal Leaf	0.9167	0.9565	0.9362
Bird Eye Spot	0.8947	0.8500	0.8717
Gray Light	1.0000	0.5500	0.7097
Brown Blight	0.9167	0.9565	0.9362
Anthracoese	0.6333	0.9500	0.7600
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.8927	0.8927	0.8927
Weighted avg	0.9128	0.8926	0.8914


จากผลการประเมินโมเดลด้วย Confusion Matrix ตามภาพประกอบ 31 พบว่าโมเดลสามารถจำแนกโรคใบชาได้อย่างแม่นยำโดยมีค่า Accuracy อยู่ที่ 89.27% โดยเฉพาะในกลุ่ม healthy และ red leaf spot ที่จำแนกได้ถูกต้องทั้งหมด อย่างไรก็ตามยังพบความสับสนระหว่างกลุ่ม gray light กับ anthracnose ซึ่งส่งผลต่ออัตราการจำแนกผิด (Misclassification rate) อยู่ที่ 10.73% โดยรวมแสดงให้เห็นว่าโมเดลมีประสิทธิภาพในระดับที่น่าพอใจแต่ยังมีโอกาสในการปรับปรุงเพิ่มเติมในบางกลุ่มโรค



ภาพประกอบ 31 Confusion Matrix ของสถาปัตยกรรม DenseNet121

4.1.2 สถาปัตยกรรม VGG16

จากภาพประกอบ 32 และตาราง 10 ค่าประสิทธิภาพของแบบจำลองนี้ ได้แก่ Accuracy อยู่ที่ 0.9266, Precision อยู่ที่ 0.9310, Recall อยู่ที่ 0.9266 และ F1-score เท่ากับ 0.9265




ภาพประกอบ 32 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16

ตาราง 10 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.8965	0.9285	0.9123
Algal Leaf	0.9583	1.0000	0.9787
Bird Eye Spot	0.9375	0.7500	0.8333
Gray Light	0.9500	0.9500	0.9500
Brown Blight	0.9523	0.869565	0.9090
Anthracoese	0.7500	0.900000	0.818182
Red Leaf Spot	1.0000	1.000000	1.000000
Accuracy	0.9266	0.9266	0.9266
Weighted avg	0.9310	0.9266	0.9265

จากผล Confusion Matrix ของโมเดล ตามภาพประกอบ 33 พบว่ามีค่า Accuracy เท่ากับ 92.66% และ Misclassification rate อยู่ที่ 7.34% แสดงให้เห็นถึงประสิทธิภาพที่ดีของโมเดลในการจำแนกโรคใบชา โดยเฉพาะในกลุ่ม red leaf spot, healthy และ algal leaf ที่สามารถจำแนกได้อย่างแม่นยำสูง อย่างไรก็ตาม ยังคงมีความสับสนเล็กน้อยระหว่างกลุ่ม bird_eye_spot


กับ anthracnose รวมถึง brown_blight กับ white_spot ซึ่งเป็นโอกาสในการปรับปรุงโมเดลเพิ่มเติมเพื่อเพิ่มความแม่นยำในกลุ่มที่มีลักษณะคล้ายคลึงกัน



ภาพประกอบ 33 Confusion Matrix ของสถาปัตยกรรม VGG16

4.1.3 สถาปัตยกรรม EfficientNetB1

จากภาพประกอบ 34 และตาราง 11 ค่าประสิทธิภาพของแบบจำลองนี้ ได้แก่ Accuracy เท่ากับ 0.8927, Precision เท่ากับ 0.8932, Recall เท่ากับ 0.8927 และ F1-score อยู่ที่ 0.8914




ภาพประกอบ 34 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1

ตาราง 11 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.8846	0.8214	0.8518
Algal Leaf	0.9200	1.0000	0.9583
Bird Eye Spot	0.8823	0.7500	0.8108
Gray Light	0.8260	0.9500	0.8837
Brown Blight	0.8695	0.8695	0.8695
Anthracoese	0.7500	0.7500	0.7500
Red Leaf Spot	0.8926	0.8926	0.8926
Accuracy	0.8927	0.8927	0.8927
Weighted avg	0.8932	0.8927	0.8914

จากผลการประเมินโมเดลด้วย Confusion Matrix ตามภาพประกอบ 35 พบว่าโมเดลมีความสามารถในการจำแนกโรคใบชาได้ในระดับที่ดี ด้วยค่า Accuracy เท่ากับ 89.27% และค่า Misclassification rate เท่ากับ 10.73% โดยกลุ่มที่จำแนกได้ถูกต้องทั้งหมด ได้แก่ red_leaf_spot และ healthy ในขณะที่ยังมีความสับสนระหว่างกลุ่ม anthracnose กับ bird_eye_spot และกลุ่ม white_spot กับ brown_blight ซึ่งควรได้รับการพิจารณาเพิ่มเติมเพื่อเพิ่มความแม่นยำในการจำแนกโรคที่มีลักษณะใกล้เคียงกัน




ภาพประกอบ 35 Confusion Matrix ของสถาปัตยกรรม InceptionResNetV2

4.2 แบบการทดลองที่ใช้เทคนิค Fuzzy Contrast Enhancement

แบบจำลองสุดท้ายใช้ภาพที่ผ่านการปรับคอนทราสต์ด้วยเทคนิค Fuzzy ซึ่งช่วยเพิ่มความคมชัดของลักษณะอาการโรคบนใบชาได้อย่างมีประสิทธิภาพ โดยเฉพาะในกรณีที่ภาพมีแสงไม่สม่ำเสมอ หรือโรคมีลักษณะรอยแตก ลายสีไม่ชัดเจน ภาพเหล่านี้ถูกนำเข้าสู่แบบจำลอง Pretrained ทั้ง 3 แบบตามลำดับ

4.2.1 สถาปัตยกรรม DenseNet121

จากภาพประกอบ 36 และ ตาราง 12 ผลการวัดค่าทางสถิติ ได้แก่ Accuracy เท่ากับ 0.8814, Precision เท่ากับ 0.8872, Recall เท่ากับ 0.8814 และ F1-score อยู่ที่ 0.8811




ภาพประกอบ 36 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121

ตาราง 12 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.9583	0.8214	0.8846
Algal Leaf	0.9583	1.0000	0.9787
Bird Eye Spot	0.8421	0.8000	0.8205
Gray Light	0.8125	0.6500	0.7222
Brown Blight	0.8800	0.9565	0.9166
Anthracoese	0.6400	0.8000	0.7111
Red Leaf Spot	0.9666	1.000000	0.9830
Accuracy	0.8814	0.8814	0.8814
Weighted avg	0.8872	0.8814	0.8811


จากผลการประเมินโมเดลด้วย Confusion Matrix ตามภาพประกอบ 37 พบว่า โมเดลมีค่า Accuracy เท่ากับ 88.14% และค่า Misclassification rate เท่ากับ 11.86% ซึ่งสะท้อนถึงประสิทธิภาพในระดับปานกลาง โดยกลุ่ม red leaf spot และ algal leaf สามารถจำแนกได้อย่างแม่นยำสูง อย่างไรก็ตาม ยังพบความสับสนระหว่างกลุ่ม gray light กับ anthracnose และ white spot กับ brown blight ซึ่งแสดงให้เห็นว่าแม้การใช้ FCE จะช่วยเพิ่มความคมชัดของภาพ แต่ยังมีข้อจำกัดในการแยกแยะโรคที่มีลักษณะใกล้เคียงกันได้อย่างสมบูรณ์



ภาพประกอบ 37 Confusion Matrix ของสถาปัตยกรรม DenseNet121

4.2.2 สถาปัตยกรรม VGG16

จากภาพประกอบ 38 และ ตาราง 13 ผลการวัดค่าทางสถิติ ได้แก่ Accuracy เท่ากับ 0.9548, Precision เท่ากับ 0.9593, Recall เท่ากับ 0.9548 และ F1-score อยู่ที่ 0.9542




ภาพประกอบ 38 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16

ตาราง 13 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	1.0000	0.9642	0.9818
Algal Leaf	1.0000	1.0000	1.0000
Bird Eye Spot	1.0000	0.7500	0.8571
Gray Light	0.8695	1.0000	0.9302
Brown Blight	0.9583	1.0000	0.9787
Anthracoese	0.8181	0.9000	0.8571
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.9548	0.9548	0.9548
Weighted avg	0.9593	0.9548	0.9542


จากผล Confusion Matrix ของโมเดล ตามภาพประกอบ 39 พบว่ามีค่า Accuracy เท่ากับ 95.48% และ Misclassification rate อยู่ที่เพียง 4.52% แสดงถึงประสิทธิภาพที่ดีเยี่ยมของโมเดลในการจำแนกโรคใบชา โดยเฉพาะกลุ่ม algal leaf, brown blight, gray light, healthy, และ red leaf spot ที่สามารถจำแนกได้ถูกต้องทั้งหมด อย่างไรก็ตาม ยังคงมีความสับสนเล็กน้อยระหว่าง anthracnose กับ white spot และ bird eye spot กับ anthracnose ซึ่งอาจพิจารณาเพิ่มเติมเพื่อปรับปรุงความแม่นยำในกลุ่มที่มีลักษณะคล้ายกัน



ภาพประกอบ 39 Confusion Matrix ของสถาปัตยกรรม VGG16

4.2.3 สถาปัตยกรรม EfficientNetB1

จากภาพประกอบ 40 และ ตาราง 14 ผลการวัดค่าทางสถิติ ได้แก่ Accuracy เท่ากับ 0.8531, Precision เท่ากับ 0.8608, Recall เท่ากับ 0.8531 และ F1-score อยู่ที่ 0.8500




ภาพประกอบ 40 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1

ตาราง 14 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.9523	0.7142	0.8163
Algal Leaf	0.7666	1.0000	0.8679
Bird Eye Spot	0.6956	0.8000	0.7441
Gray Light	0.8181	0.9000	0.8571
Brown Blight	0.8750	0.9130	0.8936
Anthrachnose	0.7333	0.5500	0.6285
Red Leaf Spot	1.0000	0.9655	0.9824
Accuracy	0.8531	0.8531	0.8531
Weighted avg	0.8608	0.8531	0.8500

จากผลการประเมินโมเดลด้วย Confusion Matrix ตามภาพประกอบ 41 พบว่า โมเดลมีค่า Accuracy เท่ากับ 85.31% และ Misclassification rate อยู่ที่ 14.69% ซึ่งถือว่า ประสิทธิภาพลดลงเมื่อเทียบกับโมเดลอื่น โดยกลุ่ม algal leaf และ healthy ยังสามารถจำแนกได้ดี แต่พบปัญหาความสับสนอย่างชัดเจนในกลุ่ม anthracnose ที่จำแนกผิดเป็น bird eye spot และ gray light รวมถึงกลุ่ม white spot ที่สับสนกับ algal leaf และ brown blight แสดงให้เห็นว่า โมเดลยังมีข้อจำกัดในการจำแนกกลุ่มโรคที่มีลักษณะใกล้เคียงกันหลังใช้ FCE ซึ่งควรพิจารณาปรับปรุงเพิ่มเติม




ภาพประกอบ 41 Confusion Matrix ของสถาปัตยกรรม EfficientNetB1

4.3 แบบการทดลองที่แปลงภาพจาก RGB เป็น HSI

ในการทดลองนี้ ผู้วิจัยแปลงภาพจาก RGB ไปเป็น HSI เพื่อแยกเฉดสีและความสว่าง ซึ่งช่วยให้โมเดลเรียนรู้ลักษณะเฉพาะของโรคได้ชัดเจนขึ้น ภาพเหล่านี้ถูกนำเข้าสู่แบบจำลอง Pretrained ทั้ง 3 แบบตามลำดับ

4.3.1 สถาปัตยกรรม DenseNet121

จากภาพประกอบ 42 และ ตาราง 15 ผลการวัดค่าทางสถิติ ได้แก่ Accuracy เท่ากับ 0.8305, Precision เท่ากับ 0.8414, Recall เท่ากับ 0.8305 และ F1-score อยู่ที่ 0.8300




ภาพประกอบ 42 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121

ตาราง 15 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.8333	0.7142	0.7692
Algal Leaf	0.7419	1.0000	0.8518
Bird Eye Spot	0.6250	0.7500	0.6818
Gray Light	0.7500	0.7500	0.7500
Brown Blight	0.9473	0.7826	0.8571
Anthracoise	0.8125	0.6500	0.7222
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.8305	0.8305	0.8305
Weighted avg	0.8414	0.8305	0.8300


จากผล Confusion Matrix ของโมเดล ตามภาพประกอบ 43 พบว่าโมเดลมีค่า Accuracy เท่ากับ 83.05% และ Misclassification rate เท่ากับ 16.95% ซึ่งถือว่าประสิทธิภาพลดลงเมื่อเทียบกับการประมวลผลด้วยเทคนิคอื่น โดยกลุ่ม red leaf spot และ healthy ยังคงสามารถจำแนกได้แม่นยำ แต่มีความสับสนสูงในกลุ่ม white spot กับ algal leaf และ gray light กับ anthracnose ซึ่งสะท้อนให้เห็นว่าการแปลงสีเป็น HSI อาจไม่เพียงพอในการเพิ่มประสิทธิภาพของโมเดลสำหรับโรคที่มีลักษณะสีหรือพื้นผิวคล้ายกัน



ภาพประกอบ 43 Confusion Matrix ของสถาปัตยกรรม DenseNet121

4.3.2 สถาปัตยกรรม VGG16

จากภาพประกอบ 44 และ ตาราง 16 ผลการวัดค่าทางสถิติ ได้แก่ Accuracy เท่ากับ 0.9266, Precision เท่ากับ 0.9283, Recall เท่ากับ 0.9266 และ F1-score อยู่ที่ 0.9268




ภาพประกอบ 44 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16

ตาราง 16 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.8965	0.9285	0.9122
Algal Leaf	0.9565	0.9565	0.9565
Bird Eye Spot	0.8181	0.9000	0.8571
Gray Light	0.8500	0.8500	0.8500
Brown Blight	0.9545	0.9130	0.9333
Anthracoese	0.9444	0.8500	0.8947
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.9266	0.9266	0.9266
Weighted avg	0.9283	0.9266	0.9268


จากผล Confusion Matrix ของโมเดลตามภาพประกอบ 45 พบว่าโมเดลมีค่า Accuracy เท่ากับ 92.66% และ Misclassification rate อยู่ที่ 7.34% แสดงให้เห็นว่าโมเดลมีประสิทธิภาพในการจำแนกโรคใบชาในระดับที่ดี โดยเฉพาะในกลุ่ม red leaf spot และ healthy ที่สามารถจำแนกได้อย่างแม่นยำ อย่างไรก็ตาม ยังพบความสับสนเล็กน้อยระหว่างกลุ่ม anthracnose กับ bird eye spot และกลุ่ม gray light กับ bird eye spot ซึ่งควรได้รับการพิจารณาปรับปรุงเพิ่มเติมเพื่อเพิ่มความแม่นยำในการจำแนกกลุ่มโรคที่มีลักษณะคล้ายคลึงกัน



ภาพประกอบ 45 Confusion Matrix ของสถาปัตยกรรม VGG 16

4.3.3 สถาปัตยกรรม EfficientNetB1

จากภาพประกอบ 46 และ ตาราง 17 ผลการวัดค่าทางสถิติ ได้แก่ Accuracy เท่ากับ 0.8701, Precision เท่ากับ 0.8889, Recall เท่ากับ 0.8700 และ F1-score อยู่ที่ 0.8696




ภาพประกอบ 46 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1

ตาราง 17 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1

ประเภท	precision	recall	F1-score
Healthy	0.9333	1.0000	0.9655
White Spot	0.8965	0.9285	0.9122
Algal Leaf	0.8461	0.9565	0.8979
Bird Eye Spot	0.9285	0.6500	0.7647
Gray Light	0.8571	0.6000	0.7058
Brown Blight	1.0000	0.8695	0.9302
Anthracoese	0.6000	0.9000	0.7200
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.8701	0.8701	0.8701
Weighted avg	0.8889	0.8700	0.8696

จากผล Confusion Matrix ของโมเดล ตามภาพประกอบ 47 ที่ พบว่าโมเดลมีค่า Accuracy เท่ากับ 87.01% และ Misclassification rate เท่ากับ 12.99% แสดงถึงประสิทธิภาพในระดับที่ดี โดยกลุ่ม red leaf spot, healthy และ algal leaf สามารถจำแนกได้แม่นยำค่อนข้างสูง อย่างไรก็ตามยังพบความสับสนระหว่างกลุ่ม gray light กับ anthracnose และ bird eye spot กับ

anthracnose ซึ่งส่งผลต่ออัตราการจำแนกผิด โดยเฉพาะกลุ่มโรคที่มีลักษณะคล้ายคลึงกันในด้านสีหรือพื้นผิว




ภาพประกอบ 47 Confusion Matrix ของสถาปัตยกรรม EfficientNetB1

4.4 แบบการทดลองที่ใช้เทคนิคการเพิ่มความคมชัดด้วย CLAHE

ภาพต้นฉบับในระบบ RGB ถูกนำมาใช้งานโดยตรง โดยไม่ผ่านการแปลงหรือปรับปรุงคุณภาพของภาพ ภาพเหล่านี้ถูกนำเข้าสู่แบบจำลอง Pretrained ทั้ง 6 แบบตามลำดับ

4.4.1 สถาปัตยกรรม DenseNet121

จากภาพประกอบ 48 และตาราง 18 ค่าประสิทธิภาพของแบบจำลองนี้ พบว่าค่า Accuracy โดยรวมอยู่ที่ 0.8475 และได้ค่า Precision, Recall และ F1-score อยู่ที่ 0.8785, 0.8475 และ 0.8456




ภาพประกอบ 48 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ DenseNet121

ตาราง 18 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ DenseNet121

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	1.0000	0.8928	0.9433
Algal Leaf	0.8518	1.0000	0.9200
Bird Eye Spot	0.7058	0.6000	0.6486
Gray Light	0.8888	0.4000	0.5517
Brown Blight	1.0000	0.9565	0.9777
Anthrachnose	0.5000	0.8500	0.6296
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.8475	0.8475	0.8475
Weighted avg	0.8785	0.8475	0.8456


จากผล Confusion Matrix ของโมเดลตามภาพประกอบ 49 พบว่าโมเดลมีค่า Accuracy เท่ากับ 84.75% และ Misclassification rate อยู่ที่ 15.25% ซึ่งถือว่ามีประสิทธิภาพในระดับปานกลาง โดยกลุ่ม red leaf spot, healthy และ algal leaf มีความแม่นยำสูง อย่างไรก็ตามยังพบปัญหาความสับสนระหว่างกลุ่ม gray light กับ anthracnose และ bird eye spot รวมถึงกลุ่ม white spot ที่มีการจำแนกผิดเป็น algal leaf ซึ่งแสดงให้เห็นว่าการใช้ CLAHE แม้จะช่วยเพิ่มความคมชัดของภาพ แต่ยังมีข้อจำกัดในการแยกแยะกลุ่มโรคที่มีลักษณะคล้ายคลึงกันได้อย่างชัดเจน



ภาพประกอบ 49 Confusion Matrix ของสถาปัตยกรรม DenseNet121

4.4.2 สถาปัตยกรรม VGG16

จากภาพประกอบ 50 และตาราง 19 ค่าประสิทธิภาพของแบบจำลองนี้ ได้แก่ Accuracy อยู่ที่ 0.9209, Precision อยู่ที่ 0.9271, Recall อยู่ที่ 0.9209 และ F1-score เท่ากับ 0.9203




ภาพประกอบ 50 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ VGG16

ตาราง 19 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ VGG16

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	0.9583	0.8214	0.8846
Algal Leaf	0.8518	1.0000	0.9200
Bird Eye Spot	1.0000	0.8000	0.8888
Gray Light	0.8333	1.0000	0.9090
Brown Blight	0.9130	0.9130	0.9130
Anthrachnose	0.8500	0.8500	0.8500
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.9209	0.9209	0.9209
Weighted avg	0.9271	0.9209	0.9203

จากผล Confusion Matrix ของโมเดลตามภาพประกอบ 51 พบว่าโมเดลมีค่า Accuracy เท่ากับ 92.09% และ Misclassification rate อยู่ที่ 7.91% ซึ่งสะท้อนให้เห็นว่าโมเดลมี


ประสิทธิภาพในการจำแนกโรคใบชาในระดับสูง โดยเฉพาะกลุ่ม red leaf spot, gray light, healthy, และ algal leaf ที่จำแนกได้อย่างแม่นยำ อย่างไรก็ตาม ยังคงมีความสับสนระหว่างกลุ่ม anthracnose กับ white spot และ bird eye spot ในระดับเล็กน้อย



ภาพประกอบ 51 Confusion Matrix ของสถาปัตยกรรม VGG16

4.4.3 สถาปัตยกรรม EfficientNetB1

จากภาพประกอบ 52 และตาราง 20 ค่าประสิทธิภาพของแบบจำลองนี้ ได้แก่ Accuracy เท่ากับ 0.8644, Precision เท่ากับ 0.8702, Recall เท่ากับ 0.8644 และ F1-score อยู่ที่ 0.8640




ภาพประกอบ 52 กราฟแสดงค่า Loss และค่า Accuracy ของสถาปัตยกรรมแบบ EfficientNetB1

ตาราง 20 คะแนนจากการวัดผลแบบจำลองด้วยชุดข้อมูลทดสอบของสถาปัตยกรรมแบบ EfficientNetB1

ประเภท	precision	recall	F1-score
Healthy	1.0000	1.0000	1.0000
White Spot	1.0000	0.8214	0.9019
Algal Leaf	0.8148	0.9565	0.8800
Bird Eye Spot	0.7083	0.8500	0.7727
Gray Light	0.8000	0.8000	0.8000
Brown Blight	0.8695	0.8695	0.8695
Anthrachnose	0.7058	0.6000	0.6486
Red Leaf Spot	1.0000	1.0000	1.0000
Accuracy	0.8644	0.8644	0.8644
Weighted avg	0.8702	0.8644	0.8640

จากผล Confusion Matrix ของโมเดล ตามภาพประกอบ 53 พบว่าโมเดลมีค่า Accuracy เท่ากับ 86.44% และ Misclassification rate อยู่ที่ 13.56% ซึ่งถือว่ามีประสิทธิภาพในระดับปานกลาง โดยกลุ่ม red leaf spot, healthy และ bird eye spot จำแนกได้ค่อนข้างดี แต่ยังพบปัญหาความสับสนในกลุ่ม anthracnose กับ gray light และ white spot กับ brown blight ซึ่งส่งผลต่ออัตราการจำแนกผิด โดยเฉพาะกลุ่มโรคที่มีลักษณะภาพใกล้เคียงกัน



ภาพประกอบ 53 Confusion Matrix ของสถาปัตยกรรม EfficientNetB1

4.4 เปรียบเทียบผลการจำแนกของแต่ละแบบจำลอง

จากผลการทดลองใช้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ได้แก่ DenseNet121, VGG16 และ EfficientNetB1 ในการจำแนกโรคบนใบชาด้วยภาพที่ผ่านการประมวลผลล่วงหน้าด้วยเทคนิคต่าง ๆ ได้แก่ RGB, Fuzzy Contrast Enhancement (Fuzzy), HSI Color Space Transformation (HSI) และ CLAHE พบว่าค่าความแม่นยำ (Accuracy) ของแต่ละแบบจำลองมีความแตกต่างกันดังแสดงในตารางที่ 21

โดยรวมแล้ว VGG16 ที่ประมวลผลภาพด้วยเทคนิค Fuzzy Contrast Enhancement ให้ค่า Accuracy สูงที่สุดคือ 0.9548 รองลงมาคือ VGG16 ที่ใช้ภาพ RGB และ HSI ซึ่งได้ค่า Accuracy เท่ากับ 0.9266 เท่ากัน สำหรับแบบจำลอง DenseNet121 และ EfficientNetB1 เมื่อใช้ภาพ RGB ให้ค่า Accuracy เท่ากันที่ 0.8927 ในขณะที่การประมวลผลภาพด้วยเทคนิค Fuzzy และ CLAHE ส่วนใหญ่ทำให้ Accuracy ลดลงเล็กน้อย ยกเว้นในกรณีของ VGG16 ที่การใช้ Fuzzy สามารถเพิ่มประสิทธิภาพได้อย่างชัดเจน

ตาราง 21 แสดงผลลัพธ์การประเมินประสิทธิภาพของแบบจำลองแต่ละประเภท โดยพิจารณาว่า Accuracy

Model	RGB	Fuzzy	HSI	CLAHE	Size (MB)
DenseNet121	0.8927	0.8814	0.8305	0.8475	26.89
VGG16	0.9266	0.9548	0.9266	0.9209	56.16
EfficientNetB1	0.8927	0.8531	0.8701	0.8644	25.14

จากตารางข้างต้น แสดงให้เห็นว่า การปรับภาพด้วยเทคนิค Fuzzy Contrast Enhancement และ HSI สามารถช่วยเพิ่มหรือรักษาระดับประสิทธิภาพของโมเดลในบางกรณี แต่ไม่สามารถทำได้อย่างสม่ำเสมอในทุกแบบจำลอง ซึ่งอาจเกิดจากคุณสมบัติของภาพต้นฉบับที่มีความแตกต่างกันในเรื่องของ ความคมชัด สี และความสว่าง ดังนั้น แม้การประมวลผลล่วงหน้าจะมีส่วนช่วยในการเน้นลักษณะของโรคให้ชัดเจนขึ้น แต่ก็ไม่ได้ส่งผลต่อการเพิ่มประสิทธิภาพของการจำแนกเสมอไป

จากการทดลองพบว่า แบบจำลองที่มีขนาดใหญ่กว่า เช่น InceptionResNetV2 และ NASNet สามารถให้ผลลัพธ์ที่แม่นยำในระดับสูงได้ แต่ไม่ได้เหนือกว่าแบบจำลองที่มีโครงสร้างเรียบง่ายกว่าเสมอไป เช่น VGG16 ที่เมื่อใช้ร่วมกับการปรับสีภาพด้วย Fuzzy Contrast Enhancement สามารถให้ผลลัพธ์สูงสุดที่ Accuracy 95.48% ซึ่งแสดงให้เห็นว่า การปรับภาพล่วงหน้า (Preprocessing) ที่เหมาะสมสามารถมีอิทธิพลต่อผลลัพธ์ได้มากพอ ๆ กับความซับซ้อนของโมเดล ดังนั้นโมเดลที่เล็กกว่าแต่ได้รับการปรับข้อมูลอย่างเหมาะสมก็สามารถทำงานได้อย่างมีประสิทธิภาพ

ผลการทดลองนี้ชี้ให้เห็นว่า สถาปัตยกรรมของโมเดล มีผลต่อการตอบสนองต่อเทคนิคการประมวลผลภาพล่วงหน้า โดยเฉพาะ VGG16 ซึ่งมีโครงสร้างที่เหมาะสมกับการทำงานร่วมกับภาพที่ผ่าน Fuzzy Contrast Enhancement ในขณะที่ DenseNet1 21 และ EfficientNetB1 ตอบสนองได้ดีในภาพสี RGB ซึ่งยังคงเป็นพื้นฐานที่ช่วยให้โมเดลสามารถเรียนรู้ลักษณะของโรคได้อย่างมีประสิทธิภาพ



บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

ระบบจำแนกโรคใบชา ด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นระบบที่ช่วยในการตรวจสอบและจำแนกประเภทของโรคที่เกิดบนใบชาโดยอาศัยข้อมูลภาพถ่ายของใบชา ซึ่งมีความสำคัญอย่างยิ่งในด้านเกษตรกรรม เพื่อช่วยลดความเสียหายที่เกิดจากโรคและเพิ่มประสิทธิภาพในการดูแลรักษาแปลงชา

ผู้วิจัยได้นำเสนอการวิเคราะห์เชิงเปรียบเทียบแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ใช้ร่วมกับเทคนิคการปรับคุณสมบัติของภาพในรูปแบบต่าง ๆ ได้แก่ ภาพต้นฉบับ, การเพิ่มความคมชัดด้วย Fuzzy Contrast Enhancement, การแปลงภาพเป็น HSI (Hue, Saturation, Intensity) และเพิ่มความคมชัดด้วย CLAHE เพื่อศึกษาผลกระทบต่อประสิทธิภาพของแบบจำลองในการจำแนกโรคใบชา โดยทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง Pretrained ที่ได้รับความนิยม ได้แก่ DenseNet121, VGG16 และ EfficientNetB1

การสรุปผลการวิจัยแบ่งออกเป็น 3 ส่วนหลัก ได้แก่:

1. สรุปผลการวิจัย
2. อภิปรายผลการวิจัย
3. ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยฉบับนี้มีจุดมุ่งหมายเพื่อพัฒนาและประเมินประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน ในการจำแนกประเภทโรคใบชา โดยเน้นศึกษาผลกระทบของเทคนิคการประมวลผลภาพล่วงหน้าที่หลากหลายร่วมกับการประยุกต์ใช้แบบจำลองที่ผ่านการฝึกมาแล้ว เพื่อเสริมสร้างศักยภาพในการจำแนกโรคให้มีความแม่นยำและประสิทธิภาพสูงสุด การทดลองนี้ได้เลือกใช้สถาปัตยกรรมโครงข่ายประสาทเทียม 3 รูปแบบ ได้แก่ DenseNet121, VGG16 และ EfficientNetB1 ซึ่งเป็นโมเดลที่ได้รับการยอมรับในวงการวิจัยด้านการเรียนรู้เชิงลึกสำหรับการวิเคราะห์และประมวลผลภาพในระดับสูง

แบบจำลองที่ใช้ในงานวิจัยนี้ถูก Pre-trained บนชุดข้อมูล ImageNet ซึ่งเป็นข้อมูลภาพทั่วไป ไม่ใช่ภาพพืชหรือเกษตร ดังนั้นบางลักษณะเฉพาะของโรคใบชาอาจไม่ได้ถูกเรียนรู้จากต้นแบบเดิม ผู้วิจัยแนะนำว่าการสร้าง Pretrained Model เฉพาะทาง (Domain-Specific Pretraining) จากภาพพืชจำนวนมาก เช่นชุดภาพจากเกษตรกรหลายแหล่ง อาจช่วยให้แบบจำลองมีความสามารถในการแยกแยะลักษณะที่มีความใกล้เคียงกันมากได้ดียิ่งขึ้น

ในการเตรียมข้อมูลภาพใบชาสำหรับการฝึกและทดสอบแบบจำลอง มีการประยุกต์ใช้เทคนิคการประมวลผลภาพล่วงหน้า 4 รูปแบบ ได้แก่ ภาพต้นฉบับ, Fuzzy Contrast Enhancement ซึ่งเป็นเทคนิคการเพิ่มคอนทราสต์โดยใช้หลักการของตรรกะฟัซซี, HSI Color Space Transformation ที่แปลงค่าพิกเซลจากระบบสี RGB ไปเป็น Hue, Saturation และ Intensity เพื่อแยกองค์ประกอบของสีและความสว่างออกจากกัน และ CLAHE (Contrast Limited

Adaptive Histogram Equalization) ซึ่งเป็นเทคนิคเพิ่มความคมชัดเฉพาะพื้นที่โดยจำกัดระดับคอนทราสต์เพื่อหลีกเลี่ยงการขยายความแตกต่างของสีมากเกินไป

ผลการทดลองแสดงให้เห็นว่า VGG16 ร่วมกับภาพที่ผ่าน Fuzzy Contrast Enhancement ให้ผลลัพธ์สูงสุดโดยมีค่าความแม่นยำ เท่ากับ 0.9548 รองลงมาคือ VGG16 ที่ใช้ภาพ RGB และ HSI ซึ่งมีค่าความแม่นยำเท่ากับ 0.9266 เท่ากัน ขณะที่แบบจำลอง DenseNet121 และ EfficientNetB1 เมื่อใช้ภาพ RGB ต่างมีค่าความแม่นยำเท่ากันที่ 0.8927 ส่วนการประมวลผลภาพด้วยเทคนิค HSI และ CLAHE แม้จะมีศักยภาพในการปรับปรุงคุณภาพของภาพ แต่ก็ไม่ได้ช่วยเพิ่มประสิทธิภาพในทุกกรณีของแบบจำลอง โดยเฉพาะในโมเดล EfficientNetB1 ที่ใช้ภาพ Fuzzy Contrast Enhancement ซึ่งให้ค่าความแม่นยำต่ำสุดที่ 0.8531

จากผลการวิเคราะห์ดังกล่าว สามารถสรุปได้ว่า โครงสร้างของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันและเทคนิคการประมวลผลภาพล่วงหน้า มีผลกระทบต่อความสามารถในการจำแนกโรคใบชาอย่างมีนัยสำคัญ โดยเฉพาะ VGG16 ที่แสดงศักยภาพสูงสุดเมื่อทำงานร่วมกับภาพที่ผ่าน Fuzzy Contrast Enhancement ขณะที่ RGB ดั้งเดิม ยังคงเป็นมาตรฐานของภาพที่ให้ผลลัพธ์ดีในหลายแบบจำลองอย่างสม่ำเสมอ

5.2 อภิปรายผล

จากผลการทดลองในงานวิจัยนี้สามารถอภิปรายได้ว่า การเลือกใช้สถาปัตยกรรมของแบบจำลองโครงข่ายประสาทเทียม และเทคนิคการประมวลผลภาพล่วงหน้า มีอิทธิพลอย่างมากต่อประสิทธิภาพในการจำแนกโรคใบชา ซึ่งเป็นข้อมูลที่มีความซับซ้อนและมีความคล้ายคลึงกันในแง่ของสีและลักษณะพื้นผิวของโรค การศึกษาเปรียบเทียบสถาปัตยกรรมของโมเดลแสดงให้เห็นว่า VGG16 ซึ่งเป็นโครงข่ายที่มีโครงสร้างแบบลำดับชั้นของ convolutional layers หลายชั้น มีความสามารถในการจับคุณลักษณะเฉพาะของโรคใบชาได้ดี โดยเฉพาะเมื่อทำงานร่วมกับภาพที่ผ่านการปรับคอนทราสต์ด้วย Fuzzy Contrast Enhancement ซึ่งเน้นลักษณะเด่นของโรคได้ชัดเจนยิ่งขึ้น

ในทางตรงกันข้าม DenseNet121 และ EfficientNetB1 ซึ่งมีโครงสร้างที่ซับซ้อนกว่า เช่น Dense Connectivity ใน DenseNet121 และ Compound Scaling ใน EfficientNetB1 แม้จะมีศักยภาพในการเรียนรู้ข้อมูลที่มีความซับซ้อนในระดับสูง แต่กลับพบว่าเมื่อทำงานร่วมกับภาพที่ผ่าน Fuzzy Contrast Enhancement อาจไม่ได้แสดงศักยภาพที่ดีที่สุด ทั้งนี้อาจเกิดจากการที่เทคนิค Fuzzy Contrast Enhancement มีแนวโน้มที่จะเพิ่มคอนทราสต์ของภาพในระดับที่สูงจนทำให้ ลักษณะพื้นผิวหรือสีบางส่วนของโรคเกิดความผิดเพี้ยน ซึ่งมีผลกระทบต่อกระบวนการเรียนรู้ของโมเดลโดยเฉพาะโมเดลที่มีความไวต่อการเปลี่ยนแปลงของคุณลักษณะภาพ เช่น EfficientNetB1

ในกรณีของ HSI Color Space Transformation ซึ่งเป็นการแปลงระบบสีจาก RGB ไปเป็น Hue, Saturation และ Intensity มีข้อดีในการแยกเฉดสีและความเข้มแสงออกจากกัน แต่จากผลการทดลองพบว่า โมเดลบางส่วนไม่สามารถนำคุณลักษณะของ HSI ไปใช้ได้อย่างมีประสิทธิภาพ โดยเฉพาะเมื่อโรคใบชามีความคล้ายคลึงกันในแง่ของสี เช่น gray light และ

anthracnose ที่มีเฉดสีใกล้เคียงกัน ซึ่งส่งผลต่อความสามารถของโมเดลในการแยกแยะโรค ในขณะที่ CLAHE ที่มีจุดเด่นในการเพิ่มคอนทราสต์แบบจำกัดในแต่ละพื้นที่ ช่วยเพิ่มประสิทธิภาพของบางโมเดล เช่น VGG16 แต่ไม่ได้ส่งผลให้ประสิทธิภาพดีขึ้นในทุกกรณี

การวิเคราะห์ Confusion Matrix ในแต่ละกรณีของการทดลองพบว่า ภาพ RGB ดั้งเดิมยังคงเป็นรูปแบบที่ช่วยลดความสับสนระหว่างโรคที่มีลักษณะใกล้เคียงกันได้ดีกว่าเทคนิคการประมวลผลภาพอื่น ๆ โดยเฉพาะในกลุ่มโรค gray light และ anthracnose ซึ่งมีความใกล้เคียงกันทั้งในด้านสีและรูปแบบของโรค นอกจากนี้ เทคนิค Data Augmentation ที่นำมาใช้ เช่น การหมุนภาพ การพลิกภาพ และการซูม ช่วยเพิ่มความหลากหลายของข้อมูลและลดโอกาสเกิด overfitting ซึ่งมีส่วนช่วยเสริมสร้างความสามารถของโมเดลในการจำแนกโรคภายใต้สภาพแวดล้อมจริงที่มีความหลากหลายของแสงและมุมมอง

5.3 ข้อเสนอแนะ

1. ข้อมูลที่นำมาใช้ในการวิจัยครั้งนี้อาจมีขนาดไม่มากนัก ซึ่งอาจส่งผลต่อความสามารถของแบบจำลองในการเรียนรู้ลักษณะของโรคใบชาได้อย่างครบถ้วน จึงแนะนำให้มีการ รวบรวมข้อมูลเพิ่มเติมในอนาคต เพื่อเพิ่มความหลากหลายและปริมาณของข้อมูลภาพใบชา ทั้งในด้านประเภทของโรค สภาพแวดล้อมในการถ่ายภาพ (เช่น แสง, มุมมอง, ฤดูกาล) รวมถึงแหล่งเพาะปลูกที่แตกต่างกัน การเพิ่มขนาดของชุดข้อมูลจะช่วยให้แบบจำลองสามารถเรียนรู้คุณลักษณะของโรคได้หลากหลายและลดปัญหาการ overfitting ที่อาจเกิดขึ้นจากการฝึกด้วยข้อมูลขนาดเล็กได้ดียิ่งขึ้น

2. ให้ความสำคัญกับการแบ่งชุดข้อมูลออกเป็น Training, Validation และ Test Set อย่างชัดเจนก่อนทำ Data Augmentation เพื่อหลีกเลี่ยงปัญหา Data Leakage ที่อาจทำให้ผลการประเมินแบบจำลองไม่สอดคล้องกับความเป็นจริง นอกจากนี้ ควรตรวจสอบความสมดุลของข้อมูลในแต่ละคลาสอย่างละเอียด และอาจใช้เทคนิค Oversampling หรือ Undersampling เพื่อปรับสมดุลของข้อมูล ช่วยลดความลำเอียงของแบบจำลองในการจำแนกกลุ่มโรคที่มีข้อมูลน้อย

3. พิจารณานำ โมเดลที่ทันสมัยกว่า เช่น Vision Transformer (ViT) หรือ Swin Transformer ซึ่งใช้กลไก attention ที่สามารถเรียนรู้ลักษณะที่ซับซ้อนของข้อมูลได้ดี มาทดลองเปรียบเทียบประสิทธิภาพในการจำแนกโรคใบชาเพิ่มเติม นอกจากนี้ การใช้ Ensemble Learning โดยการรวมผลลัพธ์จากหลายโมเดลเข้าด้วยกัน อาจช่วยเพิ่มความแม่นยำและลดข้อผิดพลาดในการจำแนก ควรให้ความสำคัญกับการปรับแต่ง Hyperparameters เช่น learning rate, batch size, optimizer และจำนวน epochs เพื่อเพิ่มประสิทธิภาพสูงสุดในการเรียนรู้ของโมเดล

4. นำแบบจำลองที่พัฒนาขึ้นไปทดลองใช้ใน สภาพแวดล้อมจริง เช่น ในไร่ชาหรือแหล่งเพาะปลูก เพื่อประเมินประสิทธิภาพของแบบจำลองภายใต้เงื่อนไขที่แตกต่างจากการทดลองในห้องปฏิบัติการ ทั้งนี้เพื่อตรวจสอบความสามารถในการปรับตัวของแบบจำลองในสภาพแวดล้อมที่แท้จริง รวมถึงพัฒนา แอปพลิเคชันบนอุปกรณ์พกพา เช่น สมาร์ทโฟนหรือแท็บเล็ต เพื่อให้เกษตรกรสามารถตรวจสอบและวินิจฉัยโรคใบชาได้อย่างรวดเร็วและสะดวกในภาคสนาม

5. นำเทคนิคการจำแนกภาพไปหาไป ประยุกต์ใช้กับพืชชนิดอื่น ๆ หรือปัญหาด้านเกษตรกรรมอื่น ๆ เช่น การจำแนกศัตรูพืชหรือโรคในพืชชนิดอื่น เพื่อขยายขอบเขตของงานวิจัย และเพิ่มความหลากหลายในการประยุกต์ใช้ นอกจากนี้ควรศึกษาผลกระทบของ ขนาดและความละเอียดของภาพ ต่อประสิทธิภาพของแบบจำลอง เพื่อค้นหาแนวทางที่เหมาะสมในแง่ของ ความแม่นยำและความเร็วในการประมวลผล โดยเฉพาะในกรณีที่ต้องนำไปใช้ในอุปกรณ์พกพาที่มีข้อจำกัดด้านทรัพยากร และสุดท้ายควรพิจารณาใช้เทคนิค Explainable AI เพื่อช่วยอธิบายการทำงานของแบบจำลองว่าใช้ข้อมูลส่วนใดของภาพในการตัดสินใจ ซึ่งจะช่วยให้เพิ่มความน่าเชื่อถือและความเข้าใจให้กับผู้ใช้งานในภาคเกษตรกรรม

6. ในการจำแนกบางคลาส เช่น Grey Light และ Bird Eye Spot โมเดล VGG16 ยังพบปัญหา Misclassification เนื่องจากลักษณะของโรคมีความใกล้เคียงกัน ผู้วิจัยเสนอว่า อาจใช้เทคนิค Attention Mechanism เพิ่มเติมในสถาปัตยกรรมเพื่อช่วยให้โมเดลโฟกัสเฉพาะบริเวณที่มีความสำคัญ (เช่น จุดกลางใบหรือบริเวณขอบ) และอาจเพิ่มการเรียนรู้เชิงลำดับ (Sequential Learning) ด้วยการนำ LSTM ต่อท้าย CNN เพื่อให้โมเดลสามารถเรียนรู้ลักษณะภาพในบริบทที่ต่อเนื่อง

7. เพื่อเสริมประสิทธิภาพการจำแนกโรคในอนาคต ควรพิจารณาใช้เทคนิค Clustering เช่น K-Means หรือ DBSCAN เพื่อจำแนกกลุ่มของลักษณะโรคที่คล้ายกันก่อนทำ Classification ซึ่งจะช่วยลดภาระของโมเดลในการแยกกลุ่มที่ใกล้เคียง นอกจากนี้ การใช้เทคนิค Feature Selection เช่น Recursive Feature Elimination (RFE), Principal Component Analysis (PCA) หรือ Mutual Information Gain อาจช่วยลดมิติข้อมูลและเน้นคุณลักษณะที่สำคัญต่อการจำแนกโรค ทำให้โมเดลมีความแม่นยำและรวดเร็วในการเรียนรู้มากยิ่งขึ้น

บรรณานุกรม

- AI, machine learning (ML) คืออะไร? ทำความรู้จักกับบริการ AI และ ML จาก Google Cloud. (n.d.). Cloud-Ace.Co.Th. Retrieved April 24, 2025, from <https://cloud-ace.co.th/blogs/o0v9a6-ai-machine-learning-ml-ai-ml-goog>
- Haque, K. N. (2023, April 3). What is convolutional neural network — CNN (deep learning). LinkedIn.com. <https://www.linkedin.com/pulse/what-convolutional-neural-network-cnn-deep-learning-nafiz-shahriar>
- Heng, Q., Yu, S., & Zhang, Y. (2024). A new AI-based approach for automatic identification of tea leaf disease using deep neural network based on hybrid pooling. Heliyon, 10(5), e26465. <https://doi.org/10.1016/j.heliyon.2024.e26465>
- Kavlakoglu, E. (2025, April 17). What is data augmentation? IBM.com. <https://www.ibm.com/think/topics/data-augmentation>
- Keras applications. (n.d.). Keras.io. Retrieved April 27, 2025, from <https://keras.io/api/applications/>
- Latha, R. S., Sreekanth, G. R., Suganthe, R. C., Rajadevi, R., Karthikeyan, S., Kanivel, S., & Inbaraj, B. (2021). Automatic detection of tea leaf diseases using deep convolution neural network. 2021 International Conference on Computer Communication and Informatics (ICCCI), 1–6.
- Medium. (n.d.). Medium. Retrieved April 24, 2025, from <https://stackpython.medium.com/deep-learning-ep-1-introduction>
- Mukherjee, S. (2022, August 18). The annotated ResNet-50 - TDS archive - medium. TDS Archive. <https://medium.com/data-science/the-annotated-resnet-50-a6c536034758>

