

การตรวจจับโรคของใบข้าวโดยใช้ Deep Learning

พัฒนisha วานิช

TNII

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

บัณฑิตศึกษา สาขาเทคโนโลยีวิศวกรรม

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

ปีการศึกษา 2566

RICE LEAF DISEASES DETECTION BY DEEP LEARNING

Phannisa Vanich

TNII

A Thesis Submitted in Partial Fulfillment of Requirements
for The Degree of Master of Engineering Program in Engineering Technology

Graduate Studies

Thai-Nichi Institute of Technology

Academic Year 2023

หัวข้อวิทยานิพนธ์

การตรวจจับโรคของใบข้าวโดยใช้ Deep Learning

โดย

พัฒนาศา วานิช

สาขาวิชา

เทคโนโลยีวิศวกรรม

อาจารย์ที่ปรึกษาวิทยานิพนธ์

ดร.อัฒนา เซนโต้ะ

บัณฑิตศึกษา สถาบันเทคโนโลยีไทย-ญี่ปุ่น อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

..... รองอธิการบดีฝ่ายวิชาการ

(รองศาสตราจารย์ ดร.วรากร ศรีเชวงทรัพย์)

วันที่.....เดือน.....พ.ศ.....

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ

(ดร.ณัฐกิตติ์ จิตรเอื้อตระกูล)

..... กรรมการ

(รองศาสตราจารย์ ดร.วรากร ศรีเชวงทรัพย์)

..... กรรมการ

(ดร.ชัชไชย วรรณบุญ)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์

(ดร.อัฒนา เซนโต้ะ)

พัฒนา วาณิช : การตรวจจับโรคของใบข้าวโดยใช้ Deep Learning. อาจารย์ที่ปรึกษา : ดร.
อัทนา เชนโตะ, 79 หน้า.

งานวิจัยฉบับนี้นำเสนอเกี่ยวกับการตรวจจับชนิดของโรคบนใบข้าว โดยที่ผู้วิจัยเลือกการ
จำแนกชนิดของโรคบนใบข้าวเพื่อให้เป็นประโยชน์กับเกษตรกร ให้สามารถจำแนกชนิดของโรคบนใบ
ข้าวได้ สามารถแก้ไขได้ถูกต้องเมื่อทราบว่าเป็นโรคชนิดใด ลดความสูญเสียในกระบวนการ เพื่อลด
ต้นทุนในการผลิตข้าวในแต่ละรอบ โดยที่งานวิจัยนี้จำแนกชนิดของโรคบนใบข้าวทั้งหมดจำนวน 4 ชนิด
คือ โรคใบไหม้ ใบจุดสีน้ำตาล ใบขีดสีน้ำตาล และใบสุขภาพดี โดยใช้ Deep Learning การนำ Model
Deep learning ตรวจจับเป็นวิธีที่มีประสิทธิภาพสูงในการวิเคราะห์ภาพและจำแนกข้อมูลซับซ้อน โดย
ผู้วิจัยเก็บรวบรวมตัวอย่างชุดข้อมูลรูปภาพของโรคแต่ละชนิดที่จำเป็น เพื่อให้โมเดลมีความแม่นยำ
เพิ่มขึ้น โมเดลที่นำเสนอในงานวิจัยอาศัยโครงข่ายประสาทเทียม โดยใช้พื้นฐานโมเดล DenseNet121
และเพิ่มเติม Dense Layer และ Batch Normalization ผู้วิจัยได้ฝึกฝนโมเดล ResNet50,
ResNet50V2, VGG16, VGG19 และ MobileNetV2 เพื่อเปรียบเทียบผลการฝึกฝนและการทำนาย ซึ่ง
ผลค่าความถูกต้อง (Accuracy) ของโมเดลที่นำเสนอในงานวิจัยจากการฝึกฝนอยู่ที่ร้อยละ 91.20

บัณฑิตศึกษา

สาขาวิชา เทคโนโลยีวิศวกรรม

ปีการศึกษา 2566

ลายมือชื่อนักศึกษา

ลายมือชื่ออาจารย์ที่ปรึกษา

PHANNISA VANICH : RICE LEAF DISEASES DETECTION BY DEEP LEARNING. ADVISOR : DR.
ADNA SENTO, 79 PP.

This research presents the detection of rice leaf diseases, aiming to benefit farmers by enabling them to accurately identify disease types on rice leaves. This knowledge facilitates proper intervention to reduce losses and production costs in each cycle. The study classifies four types of rice leaf diseases: blast, brown spot, Narrow Brown and healthy leaves, using Deep Learning. Deep Learning models are efficient in analyzing complex images and data classification. Researchers collected image dataset samples of each disease type to enhance model accuracy. The proposed models in the study rely on neural networks, the researchers trained models using DenseNet121 as the base model and augmented it with additional Dense Layers and Batch Normalization. They also trained ResNet50, ResNet50V2, VGG16, VGG19, and MobileNetV2 to compare training outcomes and predictions. The accuracy of the proposed model in the research, after training, is 91.20%.

Graduate Studies

Field of Engineering of Technology

Academic Year 2023

Student's Signature.....

Advisor's Signature.....

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จสมบูรณ์ได้ด้วยดีเนื่องจากความกรุณา และความช่วยเหลืออย่างดียิ่งจาก ดร.อรรดา เชนโต๊ะ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ท่านได้เสียสละเวลาอันมีค่ายิ่งในการให้ความรู้ ให้คำปรึกษา คอยผลักดัน ตลอดจนได้ตรวจสอบและแก้ไขข้อบกพร่องต่างๆ อันเป็นประโยชน์ในการจัดทำวิทยานิพนธ์ ตั้งแต่เริ่มดำเนินการจนเสร็จสมบูรณ์

ผู้จัดทำขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้ สุดท้านนี้ขอขอบพระคุณบิดา มารดา ครอบครัวของข้าพเจ้าที่ได้ให้กำลังใจ และสนับสนุนเรื่องต่างๆ ในการศึกษาเล่าเรียนครั้งนี้จนสำเร็จ

พัฒนนิศา วานิช



สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ	ฉ
สารบัญ	ช
สารบัญตาราง	ฌ
สารบัญรูป	ญ

บทที่

1	บทนำ.....	1
	1.1 หลักการและเหตุผล.....	1
	1.2 วัตถุประสงค์.....	1
	1.3 ขอบเขตงานวิจัย.....	2
	1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
2	ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	3
	2.1 การทบทวนวรรณกรรม	3
	2.2 ข้อมูลทางด้านเกษตรกรรม	28
	2.3 ทฤษฎีด้านเทคโนโลยี	30
	2.4 การวิเคราะห์ผลการทดลอง.....	33
3	ขั้นตอนการทำวิจัย.....	36
	3.1 การจัดเตรียมชุดข้อมูลสำหรับการฝึกสอน	36
	3.2 การฝึกสอนแบบจำลองในปัจจุบัน.....	36
	3.3 โครงสร้างของแบบจำลองที่นำเสนอ	37
	3.4 รายละเอียดของการดำเนินการทำวิจัยและการเก็บข้อมูล	40

สารบัญ (ต่อ)

บทที่	หน้า
4 ผลการศึกษาและการอภิปรายผล.....	41
4.1 การบันทึกผลในชุดข้อมูลฝึกสอนและชุดข้อมูลการตรวจสอบความถูกต้องโดย กราฟ Train และ Validation	41
4.2 การประเมินโมเดลเพื่อทดสอบการนำไปใช้งานจริงด้วยชุดข้อมูลทดสอบ	55
5 สรุปผลและข้อเสนอแนะ	60
5.1 สรุปผล	60
5.2 ข้อเสนอแนะ	60
บรรณานุกรม	61
ภาคผนวก	64
ภาคผนวก ก. ชุดคำสั่งของระบบ	65
ภาคผนวก ข. บทความการประชุมวิชาการ.....	74
ประวัติย่อผู้วิจัย	79

สารบัญตาราง

ตาราง	หน้า
2.1 การวิเคราะห์เปรียบเทียบของอัลกอริทึม ML/DL ที่โดดเด่นที่สุดสำหรับการระบุโรคใบ ของ O. Sativa.....	9
2.2 การเปรียบเทียบและอธิบายกลยุทธ์หลายอย่างในการใช้เทคโนโลยี Machine Learning และการประมวลผลภาพในการตรวจจับและจัดจำแนกโรคข้าว.....	16
3.1 แสดงจำนวนชุดข้อมูลในงานวิจัย	36
3.2 แสดงข้อมูลของแบบจำลองทั้ง 5 แบบ.....	37



สารบัญรูป

รูป	หน้า
2.1 การเปรียบเทียบประสิทธิภาพของโมเดลย่อยรูปแบบต่างๆ	4
2.2 Confusion matrixes ของโมเดลย่อยรูปแบบต่างๆ ข้อมูล (A) ResNet-50, (B) DenseNet-121, (C) SE-ResNet-50, (D) ResNeXt-50, and (E) ResNeSt-50	5
2.3 ค่า MCC ของโมเดลทั้ง 5 โมเดล.....	5
2.4 Boxplots ของค่า Precision, Recall, และ F1 score ของโมเดลย่อยต่าง ๆ	6
2.5 General architecture for rice disease identification.....	11
2.6 การเปรียบเทียบระดับความแม่นยำของเทคนิคต่าง ๆ ได้แก่ระบบเชี่ยวชาญแบบ Neuro- Fuzzy, SVM ที่ใช้ PCA, CNN ลึก, Faster R-CNN, และ SVM (b) ระบบเชี่ยวชาญ สำหรับ RPD2ฟังก์ชันฐานเชิงรังสี ตัวจำแนกประเภท NN ตัวจำแนกประเภทแบบ PSO	18
2.7 Proposed Scheme	20
2.8 คำอธิบายของโมเดล CNN ที่ใช้เทคโนโลยี Keras ในการเรียนรู้เชิงลึก	21
2.9 การวิเคราะห์ทางสถิติของโมเดล Keras ก่อนการเรียนรู้ล่วงหน้าที่แตกต่างกัน.....	22
2.10 คะแนนประสิทธิภาพสำหรับแต่ละคลาสของโมเดล InceptionResNet-V2.....	22
2.11 Training and Validation Accuracy Graph.....	23
2.12 Confusion Matrix of Inception-ResNet-V2 Model.....	23
2.13 COMPARISON OF PREVIOUS RESEARCH ON PADDY DISEASES	24
2.14 วิธีการพื้นฐานของการถ่ายโอนเรียนรู้เชิงลึกโครงข่ายประสาทเชิงลึก (CNN) สำหรับการจำแนกโรคใบข้าว	27
2.15 การกระจายของภาพใบข้าวที่ใช้ในการฝึกและทดสอบสำหรับโรคข้าวต่างๆ	28
2.16 โรคใบไหม้ (กรมการข้าว).....	29
2.17 โรคใบจุดสีน้ำตาล (กรมการข้าว).....	29
2.18 โรคใบขีดสีน้ำตาล (กรมการข้าว).....	30
2.19 โครงสร้างของการเรียนรู้ของเครื่อง	31
2.20 กระบวนการทำงานของการเรียนรู้เชิงลึก	32
2.21 โครงสร้างของการเรียนรู้เชิงลึก	32
2.22 โครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน	33

สารบัญรูป (ต่อ)

รูป	หน้า
3.1 โครงสร้างของโมเดล DenseNet121	38
3.2 โครงสร้างของโมเดลที่นำเสนอในงานวิจัย	39
4.1 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 25	42
4.2 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 25.....	43
4.3 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG16 ที่ Epoch เท่ากับ 25	43
4.4 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG19 ที่ Epoch เท่ากับ 25	44
4.5 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 25.....	44
4.6 กราฟค่าความถูกต้อง (Accuracy) ของโมเดลที่นำเสนอ ที่ Epoch เท่ากับ 25.....	45
4.7 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 25.....	45
4.8 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 25.....	46
4.9 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG16 ที่ Epoch เท่ากับ 25	46
4.10 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG19 ที่ Epoch เท่ากับ 25.....	47
4.11 กราฟค่าความผิดพลาด (Loss) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 25	47
4.12 กราฟค่าความผิดพลาด (Loss) ของโมเดลที่นำเสนอ ที่ Epoch เท่ากับ 25	48
4.13 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 50	49
4.14 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 50.....	50
4.15 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG16 ที่ Epoch เท่ากับ 50	50
4.16 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG19 ที่ Epoch เท่ากับ 50	51
4.17 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 50	51
4.18 กราฟค่าความถูกต้อง (Accuracy) ของโมเดลที่นำเสนอในงานวิจัย ที่ Epoch เท่ากับ 50 .	52
4.19 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 50.....	52
4.20 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 50.....	53
4.21 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG16 ที่ Epoch เท่ากับ 50.....	53
4.22 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG19 ที่ Epoch เท่ากับ 50.....	54
4.23 กราฟค่าความผิดพลาด (Loss) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 50	54
4.24 กราฟค่าความผิดพลาด (Loss) ของโมเดลที่นำเสนอในงานวิจัย ที่ Epoch เท่ากับ 50.....	55
4.25 ตาราง Confusion Matrix ของ โมเดล ResNet50	56

สารบัญรูป (ต่อ)

รูป	หน้า
4.26 ตาราง Confusion Matrix ของ โมเดล ResNet50V2.....	56
4.27 ตาราง Confusion Matrix ของ โมเดล VGG16	57
4.28 ตาราง Confusion Matrix ของ โมเดล VGG19	57
4.29 ตาราง Confusion Matrix ของ โมเดล MobileNetV2.....	58
4.30 ตาราง Confusion Matrix ของ โมเดลที่นำเสนอในงานวิจัย	58
4.31 กราฟสรุปค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50, ResNet50V2, VGG16, VGG19, MobileNetV2 และโมเดลที่นำเสนอในงานวิจัย	59



บทที่ 1

บทนำ

ข้าวเป็นผลผลิตทางการเกษตร เกษตรกรต้องเฝ้าระวังและป้องกันโรคที่จะเกิดขึ้น ซึ่งโรคชนิดต่างๆทำให้เกิดความเสียหายในการผลิต และส่งผลกระทบต่อกลุ่มของประชากรที่อยู่กับข้าวในฐานะที่ข้าวเป็นอาหารหลัก การตรวจจับโรคบนใบข้าวที่มุ่งเน้นการค้นหาโรคอย่างรวดเร็วและมีประสิทธิภาพ เพื่อลดความเสี่ยงในการสูญเสียผลผลิตและการจัดการโรค โดยเป็นส่วนสำคัญของการจัดการศัตรูพืชอย่างยั่งยืนและป้องกันโรค การตรวจจับโรคบนใบข้าวเป็นกระบวนการที่เกี่ยวข้องกับการวิเคราะห์ภาพถ่ายของใบข้าว เพื่อตรวจสอบสภาพและอาการของโรคที่เป็นอันตรายต่อพืช การใช้เทคโนโลยีภาพการค้นหภาพ (image processing) และการเรียนรู้เชิงลึก Deep learning เป็นเครื่องมือที่มีประสิทธิภาพในการช่วยลดเวลาและความสมบูรณ์ในกระบวนการนี้ เช่น การใช้วิธีการและอัลกอริทึมในการจัดการภาพและการจำแนกลักษณะของโรค นอกจากนี้ การวิจัยด้านการตรวจจับโรคบนใบข้าวยังมีความสำคัญในการพัฒนาเทคโนโลยีที่มีความแม่นยำในการตรวจจับโรคซึ่งสามารถนำไปประยุกต์ใช้ในการสร้างแบบจำลองที่สามารถตรวจจับโรคอย่างรวดเร็วและแม่นยำที่สุด ทำให้เกิดประโยชน์ที่มีค่าต่อการจัดการและป้องกันโรคในอนาคต

ดังนั้น งานวิจัยในด้านการตรวจจับโรคบนใบข้าวมมีความสำคัญในการพัฒนาเครื่องมือและเทคโนโลยีที่สามารถช่วยให้การจัดการโรคในสวนข้าวเป็นไปอย่างมีประสิทธิภาพและทันสมัย เพื่อเพิ่มประสิทธิภาพในการผลิตข้าวและสร้างความมั่นคงในอุตสาหกรรมการเกษตรไทยในระยะยาว

1.1 หลักการและเหตุผล

งานวิจัยเรื่องการตรวจจับชนิดของโรคของใบข้าวโดยใช้ Deep Learning เพื่อให้การระบุชนิดของโรคบนใบข้าวได้ถูกต้องและแม่นยำ โดยเทคโนโลยีภาพถ่ายทำให้บันทึกภาพของใบข้าวอย่างรวดเร็วและง่ายต่อการนำเข้าสู่ข้อมูลเพื่อวิเคราะห์ การเรียนรู้เชิงลึกช่วยให้ระบบสามารถเรียนรู้และประมวลผลข้อมูลเพื่อจำแนกแยกอาการของโรคอย่างมีประสิทธิภาพ การพัฒนาอัลกอริทึมและโมเดลที่มีประสิทธิภาพเพื่อจำแนกแยกอาการของโรคจากภาพถ่ายของใบข้าวเป็นสิ่งสำคัญ การตรวจจับโรคอย่างรวดเร็วและแม่นยำช่วยให้เกิดการปรับปรุงและป้องกันโรคได้อย่างมีประสิทธิภาพ ป้องกันการสูญเสียผลผลิตและลดความเสี่ยงในการเกิดการระบาดของโรคในระยะยาว

1.2 วัตถุประสงค์

1. เพื่อศึกษาและพัฒนาอัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning)
2. เพื่อศึกษาและพัฒนาอัลกอริทึมการคัดแยกชนิดของโรคบนใบข้าว

3. เพื่อนำอัลกอริทึมไปประยุกต์ใช้งานในการคัดแยกโรคบนใบข้าวในการเกษตร

1.3 ขอบเขตงานวิจัย

การวิจัยครั้งนี้ศึกษาเกี่ยวกับการตรวจจับชนิดของโรคบนใบข้าวโดยใช้ Deep Learning การเก็บรวบรวมข้อมูลรูปภาพของใบข้าวที่มีโรค เพื่อใช้ในการฝึกสอนและทดสอบโมเดลการเรียนรู้ในการตรวจจับโรค การออกแบบและพัฒนาโมเดลและอัลกอริทึมที่ใช้ในการตรวจจับโรคบนใบข้าว โดยใช้รูปภาพอย่างมีประสิทธิภาพและแม่นยำ การนำโมเดลและอัลกอริทึมที่พัฒนาขึ้นมาทดสอบและประเมินผลในการตรวจจับโรคบนภาพถ่ายของใบข้าว การทดสอบและประเมินประสิทธิภาพของระบบตรวจจับโรคที่พัฒนาขึ้น โดยการใช้ชุดข้อมูลทดสอบและวิเคราะห์ผลลัพธ์

ตัวแปรต้น: Python Code

ตัวแปรตาม: ระบบสามารถระบุชนิดของโรคได้ถูกต้อง

ตัวแปรควบคุม: ปริมาณและลักษณะของโรคในรูปภาพที่นำมาใช้สอนระบบ

1.4 ประโยชน์ที่คาดว่าจะได้รับ

งานวิจัยนี้จะได้แบบจำลองการตรวจจับชนิดของโรคบนใบข้าว เพื่อช่วยให้ตรวจจับโรคได้ในระยะเร็วและแม่นยำ ช่วยให้สามารถใช้สารป้องกันกำจัดศัตรูพืชได้อย่างมีประสิทธิภาพ เนื่องจากสามารถใช้ประโยชน์จากข้อมูลที่ได้จากการตรวจจับโรค ช่วยลดความเสี่ยงในการสูญเสียผลผลิตของข้าวที่เกิดจากโรค ซึ่งสามารถช่วยให้เกษตรกรลดความเสี่ยงในการสูญเสียรายได้และเพิ่มกำไรในการผลิตข้าว การใช้เทคโนโลยีในการตรวจจับโรคบนใบข้าวช่วยให้เกษตรกรมีความมั่นคงในการผลิตข้าว และสามารถแข่งขันในตลาดโลกได้อย่างมีประสิทธิภาพ

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง


บทนี้ผู้วิจัยอธิบายถึงการศึกษาของความรู้ข้อมูลที่สำคัญ ในการนำไปใช้ในการทำวิจัย โดยผู้วิจัยแบ่งข้อมูลออกเป็น 3 ส่วน คือ หัวข้อ 2.1 วรรณกรรมที่เกี่ยวข้องกับหัวข้อในการทำวิจัย หัวข้อ 2.2 ข้อมูลทางด้านเกษตรกรรม คือ โรคต่างๆในใบข้าวที่จะนำมาทำการวิจัย และหัวข้อที่ 2.3 คือ ข้อมูลด้านเทคโนโลยีที่จะนำมาใช้ในเบื้องต้น เพื่อการประยุกต์ใช้ในแบบจำลอง

2.1 การทบทวนวรรณกรรม

2.1.1 Automatic Diagnosis of Rice Diseases Using Deep Learning [1]


โรคใบข้าวมีผลกระทบที่ร้ายแรงต่อผลผลิต และการวินิจฉัยโรคใบข้าวอย่างถูกต้องเป็นสิ่งสำคัญเพื่อป้องกันผลกระทบเหล่านี้ อย่างไรก็ตามวิธีการวินิจฉัยโรคใบข้าวที่มีอยู่ในปัจจุบันไม่เสถียรและมีประสิทธิภาพไม่สูง และบางครั้งต้องใช้อุปกรณ์พิเศษในการทำนาย ในงานวิจัยนี้ได้พัฒนาวิธีการวินิจฉัยโรคอัตโนมัติและนำมาใช้ในแอปพลิเคชันบนสมาร์ตโฟน วิธีการได้รับการพัฒนาโดยใช้การเรียนรู้เชิงลึกจากชุดข้อมูลขนาดใหญ่ซึ่งประกอบด้วยภาพ 33,026 รูปของโรคใบข้าว 6 ประเภท โรคใบไหม้, โรคดอกกระถิน, เน่าคอรวง , โรคกาบใบแห้ง, โรคแบคทีเรีย Stripe และ ใบจุดสีน้ำตาล ส่วนหลักของวิธีการคือโมเดลการจับรวมซึ่งให้การวินิจฉัยด้วยซัพโมเดลที่ผสมกัน สุดท้ายโมเดลนี้ได้รับการตรวจสอบความถูกต้องโดยใช้ชุดข้อมูลภาพที่แยกออกมาอีกชุดหนึ่ง ผลลัพธ์แสดงให้เห็นว่าโมเดล 3 รุ่น ยอดเยี่ยมที่สุดได้แก่ DenseNet-121, SE-ResNet-50 และ ResNeSt-50 ในทั้งหมดนี้มีความแม่นยำในการจำแนกแยกโรค ดังนั้นโมเดลเหล่านี้ถูกเลือกและรวมเข้ากับโมเดลการจับรวม โมเดล Ensemble ช่วยลดความสับสนในการวินิจฉัยระหว่างโรคที่แตกต่างกัน เช่น การระบาดของโรค โดยใช้โมเดล Ensemble เพื่อวินิจฉัยโรคใบข้าว 6 ประเภท ได้รับความแม่นยำรวม 91% ซึ่งถือว่าดีเพียงพอ โดยคำนึงถึงความคล้ายคลึงในการเปรียบเทียบกับบางประเภทของโรคข้าว แอปพลิเคชันบนสมาร์ตโฟน Ensemble ช่วยให้ผู้ใช้สามารถใช้โมเดล Ensemble ที่เกิดขึ้นบนเซิร์ฟเวอร์เว็บผ่านเครือข่ายได้อย่างสะดวกและมีประสิทธิภาพสำหรับการวินิจฉัยโรคใบไหม้, โรคดอกกระถิน, เน่าคอรวง , โรคกาบใบแห้ง, โรคแบคทีเรีย Stripe และ ใบจุดสีน้ำตาล ผลลัพธ์การฝึกและทดสอบโมเดล หลังจากการปรับและฝึกโมเดล ค่าสูญเสียมีค่าต่ำ สำหรับโมเดลย่อยทั้งห้า และค่าสูญเสียขั้นต่ำของโมเดลย่อยทั้งห้ามีค่าต่ำกว่า 0.002 (ภาพที่ A) อัตราการเรียนรู้เป็นเหมือนกันสำหรับโมเดลย่อยทั้งห้า และอยู่ในช่วงของ 0–0.001 (ภาพที่ B) ความแม่นยำในการวินิจฉัยโรคในชุดการฝึกของภาพโรคข้าวมีค่าสูงสำหรับโมเดลย่อยทั้งห้า ซึ่งหมายความว่าโมเดลย่อยทั้งห้ามีความพร้อมใช้งานกับชุดการฝึกได้ดี แต่โมเดล SE-ResNet-50, DenseNet-121 และ ResNeSt-50 มี

ความแม่นยำที่ดีกว่า (มากกว่า 99%) (ภาพที่ C) เมื่อโมเดลย่อยถูกใช้กับชุดภาพที่มีการตรวจสอบและทดสอบความแม่นยำในการวินิจฉัยโรคมะเร็งสูงสำหรับโมเดลย่อยทั้งห้าโดยเฉพาะสำหรับโมเดลย่อย SE-ResNet-50, DenseNet-121 และ ResNeSt-50 ซึ่งได้รับความแม่นยำมากกว่า 99% (ภาพที่ D)



รูปที่ 2.1 การเปรียบเทียบประสิทธิภาพของโมเดลย่อยรูปแบบต่างๆ [1]

Confusion Matrix เป็นตารางที่เฉพาะเจาะจงทำให้ง่ายต่อการเห็นว่าโมเดลมีการตีความในการตรวจจับคลาสหนึ่งเป็นอีกคลาสหนึ่งหรือไม่ ประสิทธิภาพของโมเดลย่อยห้าสามารถแสดงให้เห็นได้ผ่านเมทริกซ์ ภาพที่ 2.2 แสดงเมทริกซ์ความสับสนในชุดภาพการทดสอบแยกของโรคข้าว 6 ประเภท แถวของเมทริกซ์ความสับสนแทนประเภทของโรคจริง ๆ ในขณะที่คอลัมน์แทนประเภทของโรคที่ทำนาย แสดงการรับรองที่ถูกต้องจากโมเดลในกลุ่มของผลบวกจริง (TP) และจริงลบ (TN) ค่าภายนอกแสดงการรับรองที่ไม่ถูกต้องในกลุ่มของเท็จบวก (FP) และเท็จลบ (FN) และค่าน้อยหมายถึงมีการรับรองที่ผิดพลาดน้อยลง ค่าภายในหลักมีค่าใหญ่ และค่าอื่น ๆ มีค่าเล็ก ทำให้เห็นว่าโมเดลทั้งห้ามีประสิทธิภาพในการวินิจฉัยโรคข้าวทุกประเภท ความลึกของสีแสดงสัดส่วนของจำนวนในตำแหน่งนั้นๆ ต่อรวมของแถว ดังนั้นสีบนหลักแทนอัตราความจำได้ของโรค ตามเมทริกซ์ความสับสน โมเดลย่อย DenseNet-121, SE-ResNet-50, และ ResNeSt-50 มีประสิทธิภาพสูงกว่าโมเดลย่อยอื่น ๆ ในการรับรู้ความสับสนของโรคที่แตกต่างกันโดยเฉพาะในโรคใบไหม้ โรคดอกกระถิน และโรคระบาดของแผ่นใบข้าว




รูปที่ 2.2 Confusion matrixes ของโมเดลย่อยรูปแบบต่างๆ ข้อมูล (A) ResNet-50, (B) DenseNet 121, (C) SE-ResNet-50, (D) ResNeXt-50, and (E) ResNeSt-50 [1]

เพื่อยืนยันผลของ Confusion matrixes ค่า MCC ของโรคที่สอดคล้องกับแต่ละโมเดลได้รับการคำนวณด้วย ซึ่งแสดงในตาราง 2 ตามที่แสดงในรูปที่ 2.3 ตามค่า MCC โมเดลย่อย DenseNet-121, SE-ResNet-50, และ ResNeSt-50 มีประสิทธิภาพสูงกว่าโมเดลย่อยอื่น ๆ ในการรับรู้ความสับสนของโรคที่แตกต่างกันโดยเฉพาะในโรคใบไหม้ โรคดอกกระถิน และโรคระบาดของแผ่นใบข้าว

MCC	ResNet-50	DenseNet-121	SE-ResNet-50	ResNeXt-50	ResNeSt-50
Disease name					
Rice leaf blast	0.978	0.995	0.994	0.978	0.995
Rice false blast	0.986	0.996	0.995	0.985	0.996
Rice neck blast	0.977	0.997	0.993	0.976	0.994
Rice sheath blight	0.979	0.996	0.997	0.982	0.990
Rice bacterial stripe	0.989	0.993	0.996	0.983	0.992
Rice brown spot	0.949	0.994	0.988	0.950	0.991

รูปที่ 2.3 ค่า MCC ของโมเดลทั้ง 5 โมเดล [1]

ค่า Precision, Recall, และ F1 score ของแต่ละโมเดลย่อยในการรับรู้ของแต่ละโรคได้รับการกำหนดโดยใช้สมการ (2-4) ภาพที่ 4 ด้านล่างเปรียบเทียบค่า Precision, Recall, และ F1 score ในแบบ boxplots สำหรับแต่ละโมเดล นั่นคือ ResNet-50, DenseNet-121, SE-ResNet-50, ResNeXt-50, และ ResNeSt-50 ภาพที่แสดงให้เห็นว่าโมเดล DenseNet-121 มีประสิทธิภาพมากกว่าโมเดลย่อยอื่น ๆ ทั้งหมดไม่ว่าจะเป็นในเรื่องของ Precision, Recall, หรือ F1 score ยกเว้นโมเดล DenseNet-121, SE-ResNet-50 และ ResNeSt-50 ดีกว่า ResNet-50 และ ResNeXt-50 ในเรื่องของ Precision หรือ Recall และ F1 score โดยรวมโมเดล DenseNet-121, ResNeSt-50, และ SE-ResNet-50 มีประสิทธิภาพที่ดีกว่าโมเดลย่อยอื่นๆ ในทั้งหมดที่ทดสอบ



รูปที่ 2.4 Boxplots ของค่า Precision, Recall, และ F1 score ของโมเดลย่อยต่าง ๆ [1]

ประเภท โรคใบไหม้, โรคดอกกระถิน, โรคเน่าคอรวง , โรคกาบใบแห้ง, โรคแบคทีเรีย Stripe และ ใบจุดสีน้ำตาล เป็นโรคที่พบบ่อยในระหว่างการผลิตข้าว การระบุโรคเหล่านี้มีความสำคัญทางปฏิบัติและสามารถให้ความคิดเห็นเกี่ยวกับการระบุโรคข้าวอื่นๆ ในอนาคตได้ ในงานวิจัยนี้ ชุดข้อมูลถูกแบ่งเป็นชุดการฝึก, ชุดการตรวจสอบความถูกต้อง, และชุดการทดสอบโดยใช้อัตราส่วนของ 7:2:1 จากผลการฝึกฝน อัตราส่วนทำให้ใช้ข้อมูลที่ได้รับจากการสำรวจอย่างเต็มที่และทำให้โมเดลเรียนรู้คุณลักษณะที่สำคัญของแต่ละโรคได้ ดูไปที่ชุดทดสอบที่ได้มาจากการแบ่งชุดข้อมูลนี้มีความคล้ายคลึงกับชุดการฝึก รูปภาพโรคที่แตกต่างกันจากแหล่งที่มาต่างๆ ถูกสะสมเพื่อเป็นชุดทดสอบที่อิสระ ผลการทดสอบของชุดทดสอบอิสระแสดงให้เห็นว่าเครือข่ายที่ออกแบบในงานวิจัยนี้สามารถนำไปใช้ในการปฏิบัติได้ดังนั้นการแบ่งข้อมูลชุดและการเลือกชุดทดสอบเป็นเหตุผลที่เหมาะสมสำหรับงานวิจัยนี้

2.1.2 Techniques for Rice Leaf Disease Detection using Machine Learning Algorithms [2]

ในปัจจุบันทั่วโลกและโดยเฉพาะในประเทศไทยอินเดีย ข้าวถือว่าเป็นแหล่งอาหารที่ดีที่สุด เมื่อเกิดการเพาะปลูกข้าว มักจะเผชิญกับโรคต่างๆ ในระหว่างขั้นตอนต่างๆ ของการเพาะปลูก โดยการตรวจจับโรคเหล่านี้ได้รับการดำเนินการทันทีและการแก้ไขที่ทันเวลา จะช่วยลดความเสียหายให้น้อยลง และสามารถผลิตผลผลิตที่มีปริมาณมากและคุณภาพดีได้ คำแนะนำจากผู้เชี่ยวชาญด้านการเกษตรที่ดีที่สุดไม่สามารถเข้าถึงได้ในพื้นที่ที่ห่างไกล เนื่องจากเวลาไม่เพียงพอที่จะเดินทางไปยังสถานที่ที่ห่างไกล วัตถุประสงค์ของการวิจัยในด้านการเกษตรคือการเพิ่มประสิทธิภาพและคุณภาพของผลผลิตด้วยค่าใช้จ่ายที่น้อยลงและผลผลิตที่ดีขึ้น การจัดการผลผลิตสามารถดำเนินการได้อย่างมีประสิทธิภาพด้วยการตรวจวินิจฉัยโรคที่ทันเวลา และการใช้วิธีการแก้ไขที่เป็นไปได้ภายในเวลาที่เหมาะสมที่สุดเพื่อควบคุมโรคที่มีผลต่อประสิทธิภาพ และคุณภาพของผลผลิตได้อย่างมีประสิทธิภาพ การตรวจวินิจฉัยด้วยวิธีด้วยมือถือมีความยุ่งยากเนื่องจากมีพารามิเตอร์ต่างๆ ที่เกี่ยวข้อง เพราะฉะนั้นการใช้ระบบอัตโนมัติเป็นเรื่องที่จำเป็นสำหรับการช่วยเกษตรกรในการตรวจจับโรคในช่วงแรกๆ ด้วยความแม่นยำที่เพิ่มขึ้น ในขั้นตอนนี้เทคนิคขั้นสูงของการเรียนรู้เครื่องจักรเล่นบทบาทสำคัญในกระบวนการการจำแนกโรค ใบข้าวที่ถูกทำลายด้วยโรค สามารถทำ ความเสียหายต่อพืชได้อย่างมากที่สามารถลดผลผลิตได้ โรคเหล่านี้ส่วนใหญ่เกิดจากแบคทีเรีย, ฟังไจ, และไวรัสโดยการแพร่กระจายของเชื้อโรคเมื่อถูกทำลายจะเกิดอย่างรวดเร็ว ซึ่งจะมีผลต่อการเติบโตของทั้งแปลง หากไม่ได้รับการวินิจฉัยทันที โรคที่มีผลต่อข้าวมีหลากหลายประเภท บางส่วนของโรคที่สำคัญที่มีผลต่อข้าว *O. Sativa* มีรายละเอียดดังต่อไปนี้

โรคจุดน้ำตาล (Brown Spot BS) โรคที่เกิดจากเชื้อราซึ่งติดเชื้อมีผลต่อข้าวทั้งหมดซึ่งสามารถระบุได้ง่ายในช่วงต้น เนื่องจากมีลักษณะเป็นจุดสีน้ำตาลโดยรอบหรือวงกลมบนใบกล้าข้าวเริ่มต้น สาเหตุที่เกิดขึ้นคือเชื้อราชนิดหนึ่งที่ชื่อว่า *Bipolaris Oryzae* ซึ่งไม่เพียงแต่ลดผลผลิตแต่ยังมีผลต่อคุณภาพของเมล็ด มันแพร่กระจายไปทั่วแปลงจากพืชนี้ไปยังพืชอื่นๆ ผ่านทางอากาศ

โรคใบไหม้ (Leaf Blast LB) เกิดจาก *Magnaporthe oryzae* ซึ่งมีผลต่อการเจริญเติบโตของพืชโดยการเป็นแผลบนใบพืชและบริเวณอื่น ๆ ของพืชเช่น เถา ราก เมล็ด เป็นต้น ในขณะที่จุดน้ำตาลคือ จุดที่พบบนใบในกรณีนี้มีรูปร่างเป็นเรียว มีสีเทาตรงกลางพร้อมกับเส้นขอบที่หนาเป็นสีน้ำตาล

โรคระบาดของแผ่นใบ (Sheath Blight SB) อาการที่สังเกตเห็นในระยะเริ่มต้นของโรคระบาดของแผ่นใบสามารถเห็นได้ใกล้ระดับน้ำบนแผ่นใบของใบ จุดสีเทาเขียวบนแผ่นใบที่มีรูปร่างเป็นวงรีได้รับการสร้างขึ้นอย่างไม่เป็นระเบียบ จุดที่ขยายใหญ่ขึ้นจะกลายเป็นสีเทารวมกับสีขาวพร้อมกับเส้นขอบสีม่วงน้ำตาลหรือน้ำตาลดำที่สามารถมองเห็นการติดเชือบนส่วนบนของพืช

แพร่กระจายอย่างรวดเร็วจากเส้นน้ำที่มาถึงปลายธงของใบ ในทำเส้นที่แผ่นภูมิสุทในภายในซึ่งเป็นสาเหตุให้พืชตาย โดยส่วนใหญ่โรคระบาดของแผ่นใบที่กล่าวถึงนี้ สามารถสงสัยได้มากขึ้นในพืชที่มีอายุมากขึ้นและใบอายุห้าถึงหกสัปดาห์ ส่วนใหญ่นี้มีผลต่อการเจริญเติบโตของพืชที่ทำเมล็ดออกมาอย่างไม่แข็งแรง สาเหตุหลักของปัญหาที่กล่าวถึงเป็นเพราะการบริโภคสารอาหารที่มีไนโตรเจนมากเกินไป

โรคไหม้จากแบคทีเรีย (Bacterial Leaf Blight BLB) โรคใบไหม้จากแบคทีเรียเป็นแบคทีเรียที่เจริญได้ผ่านทางของที่เรียกว่าไฮดาโทด ส่งผ่านบาดแผลในปลายของใบทำให้เกิดการตายของต้นอ่อน จะขยายใหญ่ขึ้นพร้อมกับขอบเป็นรูปคลื่นซึ่งทำให้เส้นฝอยเปลี่ยนเป็นสีเหลืองภายในไม่กี่วัน จุดเหล่านี้กลายเป็นสีขาวหรือสีฟางทั้งใบเมื่อโรคก้าวหน้า บาดแผลอาจเห็นได้บนฝักของใบ หยดน้ำคูกับก้อนแบคทีเรียสามารถเห็นได้บนบาดแผลใหม่ตระหนักเข้าแรกในเช้า

โรคขอบใบแห้ง (Sheath Rot SR) การเกิดของจุดเล็กๆ สีดำที่พบบนฝักของใบนอกใกล้เส้นน้ำ ซึ่งกระจายไปยังฝักของใบภายในทำให้เกิดการเน่าของเนื้อเยื่อ เมื่อการเกษตรถูกติดเชื้อโดย SR เราสามารถสังเกตเห็นจุดหลายจุดบนใบ จุดเปลี่ยนไปยังจุดใหญ่ขึ้นเวลาผ่านไปหรือเข้าร่วมหรือเติบโตพร้อมกับการเก็บเกี่ยวปกคลุมทั้งฝักใบเส้นรอบ หัวมืดอาจเล็กน้อยหรือคงความภายในฝัก ใบที่ได้รับผลกระทบอาจมีปริมาณมากของการเจริญเห็ดสีขาวชื่อ mycelium ปรากฏบนพื้นผิวภายนอก

โรคข้าวดอกกระถิน (Leaf Smut LS) สามารถระบุได้จากเนวร่องที่พบบนใบในสีดำเล็กน้อย เนื่องจาก LS แม้จะเปลี่ยนแปลงสโตไลบเป็นสีเทาและเป็นแห้งได้ ในความเป็นจริง มันไม่ใช่โรคที่สำคัญมาก แต่มันสามารถสร้างโอกาสให้เกิดโรคอื่นๆ ด้วยลักษณะการสร้างสภาพแวดล้อมที่สามารถส่งเสริมและสนับสนุนการเจริญของเห็ดได้ บาดแผลของ LS บนใบอาจเป็นรูปร่างได้แก่รูปร่างวงกลมหรือรูปร่างไร้ระเบียบพร้อมกับพื้นผิวที่หยาบ

โรคพืชได้รับการระบุอย่างมีประสิทธิภาพด้วยระบบอัตโนมัติ เทคนิคที่ใช้ในการประมวลผลครอบคลุมตั้งแต่การประยุกต์ใช้การประมวลผลภาพต่างๆ การมองเห็นคอมพิวเตอร์ ตรรกะลอจิก การเรียนรู้เครื่อง (ML), การเรียนรู้เชิงลึก (DL) และอีกมากมาย

วิธีการที่นำเสนอโดยผู้เขียนในใช้สำหรับวินิจฉัย และจำแนกประเภทอย่างถูกต้องของตัวอย่างใบตาม LB, BS, BLB และโรค SR ซึ่งมีประสิทธิภาพสูงขึ้น คุณลักษณะที่สำคัญถูกสกัดจากการประมวลผลของภาพและใช้สำหรับการจำแนกประเภทด้วยความช่วยเหลือของ MDC และ k-NN ซึ่งผลลัพธ์ที่ได้มีความแม่นยำอยู่ที่ 0.89 และ 0.87 ตามลำดับ ผู้เขียน (Gittaly Dhingra¹, Vinay Kumar¹, Hem Dutt Joshi, Study of digital image processing techniques for leaf disease detection and classification, Multimed Tools Appl Nov 2017) วิเคราะห์เปรียบเทียบของเทคนิคต่างๆ เช่น การแบ่งกลุ่ม การจัดกลุ่มและตัวจำแนกโดยใช้ ANN, Naive

Bayes, ตรรกะลอจิก, PSO, ฟังก์ชันสมการตัวจำแนกที่ผสมกัน OPDPA ทฤษฎีการประเมินตามเส้นทางขั้นต่ำ มิติแบบพริกแทน SVM การวิเคราะห์ทางคณิตศาสตร์ ขั้นตอนวิธี AdaBoost และกฎของตัวจำแนกโดยมีความแม่นยำระหว่าง 0.70 ถึง 1.0 โดยใช้การประมวลผลภาพและกลไก ANN เพื่อตรวจจับโรคในพืชที่ปลูกอย่างแพร่หลาย ซึ่งผลลัพธ์ที่ได้มีความแม่นยำอยู่ที่ 0.89 พบว่าวิธีการ Deep Learning แบบ CNN พร้อมกับรูปแบบที่แตกต่างกัน เช่น deep_CNN, CNN_SVM, CNN_High level Fusion, CNN_Transfer Learning, Faster_RCNN มีประสิทธิภาพดีกว่าในด้านความแม่นยำของการทดสอบ เป็นต่อมาพบว่าเทคนิค ML พื้นฐาน ดันไม่การตัดสินใจ มีประสิทธิภาพดีกว่าด้วยความแม่นยำสูงถึง 0.97 ในการตรวจจับโรค LS, BLB

ตารางที่ 2.1 การวิเคราะห์เปรียบเทียบของอัลกอริทึม ML/DL ที่โดดเด่นที่สุดสำหรับการระบุโรคใบของ O. Sativa ในงานวิจัยหัวข้อ Techniques for Rice Leaf Disease Detection using Machine Learning Algorithms [2]

Diseases Identified	ML/DL Technique	Performance Measure and score
BLB, LB, BS, and Tungro	Deep feature based SVM	Accuracy: 0.97 F1 score: 0.98
LB, False smut, BS, Bakanae disease, SB, SR, BLB, Bacterial sheath rot, Seeding blight and Bacterial wil	Deep CNN	Accuracy: 0.95
LB	SVM-SFFS	Mean Accuracy: 0.98
BLB, LB, and SB	CNN model with high level fusion	Accuracy: 1.0
LB, Red blight, Stripe blight, and SB	CNN with SVM	Accuracy: 0.96
a)LS, BLB and BS	Extreme gradient boosting(XGBoost)	Accuracy: 0.86 F1 score: 0.87
LB	Probabilistic Neural Network(PNN)	Accuracy: 0.91 F1 score: 0.92
BS, BLB and LS	AlexNet neural network	Accuracy: 0.99
LS, BLB and BS	Decision Tree(j48)	Accuracy: 0.97 F Score: 0.97

ตารางที่ 2.1 การวิเคราะห์เปรียบเทียบของอัลกอริทึม ML/DL ที่โดดเด่นที่สุดสำหรับการระบุโรคใบของ O. Sativa ในงานวิจัยหัวข้อ Techniques for Rice Leaf Disease Detection using Machine Learning Algorithms [2] (ต่อ)


Diseases Identified	ML/DL Technique	Performance Measure and score
Stackburn, bacterial leaf streak, False smut, LS, Leaf scald, White tip, LB, Stem rot, Sheath spot, SR, Grain spotting and peck, Kernel smut, and SB	Deep_Transfer Learning	Accuracy: 0.98
LB, BLB and BS	CNN_Transfer Learning	Accuracy: 0.92
LS and BS	ANN	Accuracy: 0.79
LB, BS and Hispa	Faster_RCNN	Mean Accuracy: 0.987
SB, LB,False Smut, BS, and Stem Rot	Minimum Distance Classifier(MDC	Accuracy: 0.81
BLB, LB, BS and SR	Deep Neural Network_Jaya Optimization Algorithm(DNN_JOA)	Mean Accuracy: 0.95

2.1.3 A Review on Machine Learning Techniques for Rice Plant Disease Detection in Agricultural Research [3]

การเกษตรเป็นแหล่งรายได้หลักในหลายประเทศในโลก ความสำคัญของการเกษตรเกษตรกรเลือกพืชที่จะปลูก ข้าวนา และสารป้องกันกำจัดศัตรูพืชที่เกี่ยวข้อง เพื่อปรับปรุงการเจริญเติบโตของพืชในเวลาจำกัดข้าวเป็นพืชอาหารหลักในหลายประเทศในปัจจุบันพืชข้าวกำลังเผชิญกับปัญหาที่ร้ายแรงในภาคการเกษตรเนื่องจากโรคที่มีผลต่อคุณภาพและปริมาณของ ผลผลิตขาดความสามารถในการเฉพาะวิชาที่เพียงพอที่เกี่ยวข้องกับการเกษตร การจัดการปุ๋ยที่ไม่เพียงพอ ความไม่ตระหนักเกี่ยวกับโรคและแมลงศัตรูพืช เป็นเหตุผลที่แตกต่างสำหรับอัตราการผลิตที่ต่ำลง โรคในพืชมีส่วนร่วมโดยอ้อมและโดยตรงในการสร้างความเสียหายในสิ่งแวดล้อม โดยที่โรคเหล่านี้กระจายทั่วโลก เข้าสู่ระบบการทำงานทั่วไปของพืชและทำให้เงินทุนลดลงอย่างมีนัยสำคัญโดยลดจำนวนพืชที่ปลูก พืชถูกทำลายด้วยโรคและเชื้อราต่าง ๆ โรคเชื้อราใบกาบ โรคใบบางใบแตก และจุดสีน้ำตาลเป็นโรคที่แตกต่างกันที่เกิดขึ้นบนพืชข้าว ความเสียหายที่มากจากการไหม้แสดงถึงระดับความรุนแรงของโรค โรคข้าวอีกอันที่น่าสังเกตคือจุดสีน้ำตาลที่เกิดขึ้นโดยจุลินทรีย์ *Byopolaris Oryza* ซึ่งมองเห็นได้ตลอดฤดูการเจริญเติบโต จุดสีน้ำตาลมักจะรุนแรงขึ้นเมื่อข้าวเติบโตบนดินที่ขาดซิลิกอน ในเอเชีย มีการทำลายของผลผลิตร้อยละ 10 ถึง 15 เนื่องจากโรคข้าวเร็วที่นักวิชาการในสาขาการเกษตรสนับสนุนการวิเคราะห์และติดตามโรคพืชอย่างแม่นยำด้วยวิธีการแบบดำเนินการและใช้เวลานานมากขึ้น บางครั้งเกษตรกรต้องเผชิญกับความยากลำบากในการระบุโรคซึ่งก่อให้เกิดความ

สูญเสียในผลผลิต หนึ่งในวิธีการที่มีประสิทธิภาพสำหรับเกษตรกรคือการประมวลผลภาพที่ถูกจับไว้ของ "ใบที่ดูเหมือนจะเป็น" โดยระบบอัตโนมัติ ใบพืชที่เปิดเผยอาการของโรคถูกใช้ในการตรวจจับโรค ระบบอัตโนมัติช่วยเกษตรกรในการรับรู้โรคได้อย่างรวดเร็ว พืชบางต้นไม่สามารถผลิตได้เนื่องจากการเลื่อนการตรวจจับโรค ดังนั้น การตรวจจับ ขั้นตอนที่เกี่ยวข้องในการจำแนกและตรวจจับโรคของพืชข้าวได้แก่ดังนี้:

- 1) การเก็บภาพซึ่งจับภาพโรคของพืชข้าวโดยใช้กล้องดิจิทัล
 - 2) กระบวนการก่อนประมวลผลเพื่อเพิ่มคุณสมบัติของภาพที่จับไว้ซึ่งช่วยให้การประมวลผลข้อมูลต่อไปดีขึ้น
 - 3) การแบ่งส่วนภาพที่ผ่านการประมวลผลล่วงหน้าเป็นกลุ่มที่มีลักษณะเดียวกันสำหรับการวิเคราะห์ที่ง่ายขึ้น
 - 4) กระบวนการสกัดคุณสมบัติจากภาพที่แบ่งเป็นกลุ่มโดยขึ้นอยู่กับรูปร่าง สี และพื้นผิว
 - 5) กระบวนการจำแนกประเภทของโรคพืชข้าวต่าง ๆ
- ขั้นตอนที่ใช้ในการระบุโรคข้าวแสดงไว้ในรูปที่ 2.5



รูปที่ 2.5 General architecture for rice disease identification [3]

ในงานวิจัยที่ [3] ได้สรุปผลการวินิจฉัยของแต่ละโรคข้าวของแต่ละงานวิจัยไว้ ดังนี้

T.Daniya and S.Vigneshwari [3] ได้ศึกษาการวินิจฉัยโรคข้าวโดยใช้วิธีการต่าง ๆ ของ Manoj Mukherjee และคณะ ซึ่งได้นำเสนอกรอบการประมวลผลภาพใบข้าวโดยใช้ฮิสโตแกรมเพื่อป้องกันผลกระทบจากโรคพืชของข้าว โดยกรอบงานนี้ช่วยให้สามารถจำแนกโรคในระยะเริ่มต้นโดยการดำเนินการตามเวลาเพื่อลดการสูญเสียในการผลิต ตัวอย่างภาพของใบถูกดึงมาประมวลผลและทำการแปลงภาพจาก RGB เป็นภาพสีเทา จากนั้นถูกสกัดเอาต์เป็นฮิสโตแกรมโดยใช้ฟังก์ชัน MATLAB ภาพที่ได้จะถูกนำมาใช้เป็นข้อมูลนำเข้าสำหรับการจำแนกและการจัดอันดับโรค หลังจากการตรวจจับโรคและขั้นตอนของโรค โดยใช้ความช่วยเหลือจากผู้เชี่ยวชาญด้านการเกษตร จะจัดทำหน่วยการรักษาโรคที่ปรึกษา ถัดมาได้ศึกษางานวิจัยของ N. Mittal และคณะ แนะนำกรอบการเรียกข้อมูลภาพที่เน้นไปที่ผู้ใช้ที่ไม่เข้าใจเทคโนโลยีดิจิทัลโดยเฉพาะเกษตรกร เพื่อความสะดวกในการเรียกข้อมูลผ่านอินเทอร์เน็ต นอกจากนี้ยังช่วยให้เกษตรกรสามารถระบุโรคในพืชของพวกเขา สาเหตุและอาการโรคโดยใช้การรับรู้แบบแผนและการประมวลผลภาพดิจิทัลโดยทันทีโดยไม่ต้องรอให้ผู้เชี่ยวชาญเข้าไปที่ฟาร์มและระบุโรค ผลการทดลองแสดงให้เห็นถึงควมมีประสิทธิภาพของวิธีการนี้ ส่วนการประมวลผลภาพแสดงผลขึ้นอยู่กับวิธีการฝึกอบรมด้วยภาพ 25 ภาพในแต่ละหมวดหมู่ของโรค ผลลัพธ์สามารถปรับปรุงได้ต่อไปโดยการเพิ่มจำนวนภาพที่ใช้สำหรับการฝึกระบบ นอกจากนี้ยังได้ศึกษางานวิจัยของ Gayathri และ Neelamegam ได้แนะนำกรอบการตรวจจับโรคใบอัตโนมัติโดยใช้เทคโนโลยีประมวลผลภาพ เพื่อระบุโรคเหล่านั้น กระบวนการระบุโรคประกอบด้วย การก่อนประมวลผล เก็บภาพ การแบ่งส่วนภาพและการจัดประเภทโรคใบของข้าวโดยใช้วิธีผสมผสานที่เรียกว่า DWT (Discrete Wavelet Transform), GLCM (Gray Level Co-occurrence Matrix) และเทคโนโลยี feature transform ไม่เปลี่ยนแปลง สุดท้าย คุณสมบัติที่สกัดออกมาถูกนำเข้าสู่ตัวจัดประเภทต่าง ๆ เช่น K-Nearest Neighbors (KNN), neural network (NN), backpropagation, multiclass SVM และ Naive Bayesian เพื่อจัดประเภทพืชที่ไม่เป็นโรคและเป็นโรค มีการทดลองการจัดประเภทหลายรูปแบบเพื่อจัดประเภทโรคใบผลลัพธ์แสดงให้เห็นถึง ความแม่นยำที่ดีขึ้นของ 98.63% โดยใช้ multi-class SVM ซึ่งดีกว่า มากไปกว่านั้นยังได้ศึกษางานวิจัยของ W. J. Liang เพิ่มเติมที่ได้แนะนำวิธีการรับรู้ RLB ที่มุ่งเน้นที่ Convolutional NNs (CNNs) ชุดข้อมูลที่มี 2902 ตัวอย่างเชิงลบและ 2906 ตัวอย่างเชิงบวกถูกพิจารณาเพื่อทดสอบและฝึก CNN มีการพัฒนาวิธีการระบุโรคข้าวต่างๆเพื่อใช้วิธีการนี้และการวินิจฉัยโรคข้าวโดยอัตโนมัติได้ผ่านการรวมรูปแบบข้อมูลและความรู้ด้านโรคข้าว นอกจากนี้มีการทำการเปรียบเทียบสำหรับการวิเคราะห์แบบปริมาณและคุณภาพ วิธีการวินิจฉัยอัตโนมัตินี้ได้ผลลัพธ์ที่น่าพอใจ ผลลัพธ์เหล่านี้แสดงให้เห็นว่า เมื่อเปรียบเทียบกับลักษณะเฉพาะที่สร้างด้วยมือด้วยการใช้ Haar-WT (Wavelet Transform) ร่วมกับฮิสโตแกรม LBP (local-binary pattern) คุณสมบัติระดับสูงที่ถูกสกัดออกมาจาก Convolution Neural Network เป็นอย่างมากเป็นเหตุสำคัญและสามารถแยกแยะได้ นอกจากนี้ผลลัพธ์จากการประเมิน

ปริมาณระบุว่า CNN กับ SVM และ CNN กับ Softmax มีประสิทธิภาพและความแม่นยำที่เท่ากัน ดังนั้น CNN เป็นวิธีการที่มีประสิทธิภาพในการรับรู้ RLB สูงสุดและมีความเป็นไปได้ในการนำไปใช้ในงานปฏิบัติ

ถัดมาในงานวิจัยของ Y. Lu และ S. Yi ที่งานวิจัยนี้ได้ศึกษาได้นำเสนอวิธีการเพิ่มประสิทธิภาพของการเรียนรู้ลึกของเครือข่ายประสาทเทียมคอนโวลูชัน ชุดข้อมูลประกอบด้วยชุดของรูปภาพ 500 ภาพของใบและลำต้นที่เป็นสุขภาพและเป็นโรคซึ่งถูกถ่ายทอดมาจากฟาร์มข้าว ผ่านการระบุภาพและนั่นเครือข่ายประสาทเทียมคอนโวลูชันถูกฝึกให้รู้จำโรคข้าวสามารถทำ cross validation ระหว่าง 10-fold ในนั้นมีความแม่นยำสูงสุด อัตราการรวมกันที่เร็วขึ้นและสามารถระบุโรคได้ดีขึ้นกับวิธีการเชิง CNN มากกว่ากรอบการทำงานอื่น ๆ จากงานวิจัยที่ได้กล่าวมา ยังมีงานวิจัยที่ศึกษาเพิ่มเติม คืองานวิจัยของ E. L. Mique, Jr ที่ได้สำรวจแอปพลิเคชันที่ช่วยเกษตรกรในการระบุโรคข้าวและแมลงศัตรูด้วยการประมวลผลภาพและ CNN มันสำรวจว่ามีการควบคุมแมลงศัตรูเท่าไร การเรียนรู้เครื่อง (ML) มีการประยุกต์ใช้หลายแบบอย่างเช่น การจำแนกโจมตี Distributed Denial of Service (DDOS) การจัดจำแนกต้นไม้โดยใช้ต้นไม้ความน่าจะเป็นที่มีข้อมูล A-priori การพยากรณ์โรคทั่วไป การระบุใบหน้า การตรวจจับการปลอมแปลง ฯลฯ จอห์น วิลเลียม โอริลโล และคณะตรวจสอบกรอบการใช้วิธีการประมวลผลสัญญาณเสียงเพื่อตรวจจับ และระบุจุลินทรีย์สามชนิดที่เป็นสาเหตุของโรคในไร่ข้าว ในฟิลิปปินส์สัญญาณเสียงจากตัวอย่างของใบข้าว ที่ได้รับผลกระทบจากแบคทีเรียที่กล่าวถึงข้างต้นถูกบันทึกโดยใช้ห้องเสียงประเมินผ่านไมโครโฟน โคนเดอรัลเล็กตริกถูกประมวลผลด้วยการลบสเปกตรัล เพื่อกำจัดเสียงรบกวน ค่าเฟรควานซีพีริเควนซีเป็นลักษณะของทุกข้อมูลสำหรับอัลกอริทึมเรียนรู้ ANFIS หนังสือนี้ได้ใช้ Fuzzy NN ในการฝึกระบบจากข้อมูลเสียง 450 รายการ (ที่ถูกบันทึก) โดยใช้ 20% เพื่อการทดสอบและ 80% สำหรับการฝึก โปรแกรมถูกนำเสนอเพื่อสร้างรายงานในรูปแบบ PDF เพื่อแสดงการวินิจฉัยและวิธีการรักษาสำหรับตัวอย่างที่ติดเชื้อเพื่อป้องกันการติดเชื้อเพิ่มเติม ในงานวิจัยถัดมาคือ ฮาร์ชัตคุมาร์ และคณะ ได้ตรวจสอบโปรโตไทป์สำหรับการตรวจจับและจัดจำแนกโรคของข้าวที่มีการสนับสนุนจากภาพถ่ายของต้นข้าวที่ติดเชื้อ โรคข้าวที่สนใจคือ BLB ใบเน่าและจุดสีน้ำตาล ภาพถ่ายที่กล่าวถึงข้างต้นถูกบันทึกโดยใช้กล้องดิจิทัลในไร่ข้าว ประเมินวิธีการกำจัดพื้นหลัง 4 วิธี และเทคนิคการแบ่งส่วน 3 วิธี เพื่อสร้างคุณลักษณะที่ถูกต้อง โดยใช้การแบ่งส่วนแบบ centroid feeding centric KMC แนะนำสำหรับการแบ่งส่วนของส่วนที่ติดเชื้อของภาพใบ ผลลัพธ์ของ KMC ได้รับการปรับปรุงโดยการกำจัดพิกเซลสีเขียวในส่วนที่ติดเชื้อ คุณลักษณะที่แตกต่างกันถูกสกัดขึ้นจากสี่ ลักษณะการเรียงลำดับและรูปทรง SVM ถูกใช้สำหรับการจำแนกประเภทหลายประเภท วิธีนี้ได้รับความแม่นยำของ 73.33% ในชุดข้อมูลทดสอบและ 93.33% ในชุดข้อมูลฝึก ทดสอบการตรวจสอบแบบ 10 และ 5 ครั้ง ก็ถูกนำเข้ามาด้วย

ถัดมาจะเป็นการศึกษางานวิจัยของศานตานู ฟาดิการ์ และคณะ ที่ได้ตรวจสอบวิธีการจัดจำแนกโรคของต้นข้าวด้วยการใช้เทคนิคอัตโนมัติ เป้าหมายคือการจัดจำแนกโรคข้าวที่แตกต่างกันด้วยการสกัดคุณลักษณะจากพื้นที่ที่ติดเชื้อของภาพที่พิจารณา โดยเสนอวิธีการแบ่งส่วนจุดปลายพิกซ์มีเนียร์ที่ให้การแยกส่วนที่ติดเชื้อของภาพออกจากพื้นหลัง อาการของส่วนที่ติดเชื้อถูกลักษณะเชิงการความสามารถเช่นสี ตำแหน่ง และรูปร่างซึ่งจะถูกนำมาใช้ในอัลกอริทึม เพื่อลดความซับซ้อนของตัวจำแนกและลดการสูญเสียข้อมูล คุณลักษณะที่สำคัญถูกเลือกโดยใช้ทฤษฎี Rough Set (RST) ยังมีงานวิจัยของ ฮี อัล-ฮิอารี และคณะ ที่ได้นำเสนอวิธีการระบุและจัดจำแนกโรคใบพืชโดยใช้โซลูชันซอฟต์แวร์ซึ่งให้คำตอบอย่างรวดเร็วและแม่นยำ กรอบการประมวลผลนี้ประกอบด้วยขั้นตอนหลัก 4 ขั้นตอนที่เหลือเพิ่มเติมหลังจากการแบ่งส่วน ในขั้นตอนแรก เฉพาะพิกเซลสีเขียวส่วนใหญ่ถูกระบุ จากนั้น พิกเซลสีเขียวเหล่านั้นถูกบังคับใช้ขึ้นโดยใช้ค่าเกณฑ์ที่ระบุซึ่งถูกประเมินโดยใช้วิธี Otsu ขั้นตอนเสริมอื่น ๆ คือพิกเซลที่มีค่า RGB เป็น '0' และพิกเซลบนพื้นที่ย่านนอกของวัตถุ (คลัสเตอร์ที่ติดเชื้อ) ถูกกำจัดทั้งหมด ผลลัพธ์ที่รับจากการทดลองแสดงให้เห็นว่าเทคนิคนี้เป็นเทคนิคที่แข็งแกร่งสำหรับการระบุโรคใบพืช อัลกอริทึมที่พัฒนาไว้สามารถระบุและจัดจำแนกโรคที่ตรวจพบได้อย่างแม่นยำระหว่าง 83% ถึง 94% และสามารถทำให้ความเร็วเพิ่มขึ้นได้ถึง 20% ไม่เพียงแค่งานวิจัยที่ได้กล่าวมา ยังมีงานวิจัยของ M.N. A. Bakar และคณะ ที่ได้อธิบายเกี่ยวกับเฟรมเวิร์กอินทิเกรตสำหรับการรับรู้โรคบนใบข้าวไร่ที่เรียกว่า RLB โดยใช้เฟรมเวิร์กประมวลผลภาพประกอบด้วย การทำการจัดเตรียมก่อนการประมวลผล การแบ่งแยกภาพ และการวิเคราะห์ภาพ โดยใช้พื้นที่สี Hue Saturation Value (HSV) เพื่อหาพื้นที่ของโรค การแบ่งแยกภาพ (ภาระงานที่สำคัญมากในการประมวลผลภาพ) และการรู้จำรูปแบบที่ใช้หลักการแบ่งระดับ Multi-Level Thresholding ออกมา ผลลัพธ์ที่ได้คือความรุนแรงของโรค RLB ถูกจัดอยู่ในสามระดับ คือ ระยะการติดเชื้อ, ระยะเสียหายที่มากที่สุด และ ระยะการกระจายของโรค นอกเหนือจากงานวิจัยที่กล่าวมา ยังมีงานวิจัยของ F. Ghobadifar และคณะ ที่ได้ศึกษาซึ่งจะแนะนำเฟรมเวิร์กในการระบุโรคเชิงแผ่นดินสำหรับการใช้ภาพ SPOT ในฐานะข้อมูลหลัก วิธีนี้ใช้การรับรู้ระยะไกลผ่านการความชัดและเป็นเทคนิคสำหรับควบคุมการใช้ปุ๋ยให้คุ้มค่าขึ้น จำกัดความเสี่ยงทางสิ่งแวดล้อมและปรับปรุงการควบคุมศัตรูพืชธรรมชาติก่อนที่ปัญหาเหล่านี้จะแพร่ กระจาย การวิเคราะห์ถูกดำเนินการโดยใช้ซอฟต์แวร์ SPSS และ ENVI4.8 (Environment for Visualizing Images) ผลลัพธ์ที่ได้คือ ภาพระยะการเจริญเติบโตในช่วงเวลาต่าง ๆ ในภาพแตกต่างกัน ดัชนีภาพที่ระบุได้ เช่น RVI14, SDI24 และ SDI14 ยืนยันเทคนิคที่ดีที่สุดสำหรับการระบุพืชที่เป็นสุขภาพมากกว่าที่เป็นโรค ดัชนีเหล่านี้ถูกพิจารณาว่าเป็นตัวบ่งชี้สำหรับการสร้างเทคนิคในการระบุโรคที่เกิดขึ้นจาก sheath blight ผ่าน RS นอกจากการรับรู้ระยะไกลแล้ว ยังมีงานวิจัยของ T. Kobayashi ที่ได้ประเมินการใช้ภาพพลิกโคมแบบบินในการประเมินความรุนแรงของโรคในพืชในฟิลด์เช่นโรคแผลท้องโกเลน ในภาคเหนือของญี่ปุ่น เพื่อทำภาพ

พริกโหม RS ที่ระยะเวลาที่ข้าวตกเมล็ดสุก อัตราส่วนความชดต่ำ และความชดสูง (R498 ถึง 515) / (R700 ถึง 717) มีความเป็นเอกลักษณ์มากที่สุด มีการเพิ่มขึ้นอย่างมีนัยสำคัญในอัตราส่วนดังกล่าว เนื่องจากการประเมินการเป็นโรคที่ใหไว้ในร้อยละ ($R^2=0.83$) ถัดมางานวิจัยของ E. S. Song ที่ได้ศึกษาได้ นำเสนอเฟรมเวิร์กสามลักษณะ PCR สำหรับการตรวจพบเชื้อโรคที่เกี่ยวข้องกับการแข่งขันของเชื้อโรค (เช่น *Xanthomonas oryzae* pv *Oryzae* (XOO) ของข้าว) โดยสร้างโมเดลตามการเรียงลำดับของเจน (XorII และ hpaA) เพื่อให้สามารถกระทำเพื่อระบุการแข่งขัน K5 และ K3 มีการตรวจหาที่ตำแหน่งพันธุกรรมและการซ่อมแซมส่วนสั้นที่ออกมาแทน AFLP (Amplified Fragment Length Polymorphism) นอกจากนี้ยังมีการพัฒนาแม่แบบเพื่อจะหาเชื้อโรคในละหุดและไม่มีการประมวลผลล่วงหน้า แอมพลีคอนได้รับการส่งออก (ตัวอย่างเช่น การเตรียม DNA ใบที่ติดเชื้อและการเพาะเชื้อแบคทีเรียในภายหลัง) นอกเหนือจากการแข่งขันของเชื้อโรคแล้ว ยังมีงานวิจัยของ A. Kumar และคณะ ที่ได้ทำการทดลองในช่วงฤดูฝนของปี 2013 เพื่อระบุความพร้อมของยีนด้านการเจริญของเชื้อโรคและการเข้าถึงต่อโครงสร้างพันธุกรรมต่อต้านและระดับพายุ BX043 ได้รับการตรวจสอบโดยการคัดเลือกพืชข้าวในธรรมชาติ จากนั้น พัฒนาเส้นความก้าวหน้าโดยใช้ "พื้นที่ใต้โรค" ที่สร้างต้นแบบที่เป็นการควบคุมสำหรับการวิจัย สุดท้ายการวัดความรุนแรงของโรคที่ดำเนินการ ที่สำรวจหลายสิ่งที่แสดงให้เห็นว่าความต้านทานอยู่ในระดับปานกลาง มีการบาดเจ็บเล็กน้อย และมีการเป็นโรคเล็กน้อย รวมทั้งมีความหลากหลายในความถี่พันธุกรรมจาก 00.000 ถึง 45.710% โดยใช้ยีนด้านการเจริญของเชื้อโรคหัวตัว xa5, Xa2 และ Xa4 จากพันธุ์ NKSWR-25 ในขณะที่พันธุ์ NKSWR16, NKSWR32, NKSWR36, NKSWR41, NKSWR42, NKSWR53, NKSWR64, NKSWR97 และ NKSWR99 มียีนด้านการเจริญของโรคสองตัวจาก xa5, Xa2, และ Xa4 ต่อต้านใช้ในพันธุ์ข้าวผลิตสูงที่มีประสิทธิภาพ ไม่เพียงเท่านั้น ในงานวิจัยของ S. K. Mangrauthia และคณะได้นำเสนอเฟรมเวิร์กในการระบุไวรัส RTSV (Rice Tungro Spherical Virus) ในตัวอย่างของเชื้อโรคโดยใช้ตัวจับและตัวประเมินที่เรียงลำดับไวรัส อาการของ RTSV ที่รับรู้ได้คือการหดตัวของปลายใบ เล็กน้อย และการเปลี่ยนสีจากสีเขียวเป็นสีส้ม ใช้วิธี Hybridizations RNA dot-blot และ 2-step RT-PCR (Reverse Transcription-Polymerase Chain Reactions) ในการตรวจสอบ RTSV มีการสร้าง RNA ที่เติมที่จากตัวอย่างใบข้าวที่ไม่มีอาการและมีอาการ และใช้ในการขยายลำดับที่ระบุของ RTSV มีการออกแบบตัวจับสำหรับการระบุไวรัสผ่านการ Hybridization RNA-dot blot ทั้งสองวิธีการวินิจฉัยได้ถูกแสดงให้เห็นเป็นพิเศษในการระบุ RTSV ในตัวอย่างของโรค จาก 26 ตัวอย่างที่เป็น tungro มี 8 ตัวที่สงสัยว่าไม่มีอาการแต่กลับพบว่าตรวจพบไวรัสพบ ได้รับการยืนยันว่าอาการ RTSV ไม่ตรงกับระดับไวรัสเสมอ และสุดท้ายนี้ที่ในงานวิจัยของ T.Daniya and S.Vigneshwari [3] ได้ศึกษางานวิจัยของ C. L. Chung และคณะ แนะนำเฟรมเวิร์ก โดยใช้ฟอสฟาเทียมเพอริโคริเป็นตัวอย่าง การกรองพืชที่ติดเชื้อ (ข้าว) ควรทำเมื่ออยู่ในช่วงการพัฒนาเอง ใช้ภาพในการแยกว่าเป็น

เมล็ดที่สุภาพดีและที่ติดเชื้อที่อายุ 3 สัปดาห์ เพาะเลี้ยงในอากาศที่อุณหภูมิคงที่ ใช้สแกนเนอร์แบบแบทที่อยู่ในตำแหน่งแนวนอนเพื่อหาภาพของต้นกล้าที่สุภาพดีและที่ติดเชื้อเพื่อวัดคุณลักษณะทางรูปร่างและสีของพวกเขา ตัวจำแนก SVM ใช้ GA ในการเลือกคุณลักษณะและพารามิเตอร์ที่จำเป็น ผลงานนี้ส่งผลให้มีความแม่นยำ 87.9% และความเชื่อมั่นบวก 91.8% ในการแยกแยะต้นกล้าที่สุภาพดีและที่ติดเชื้อ

ตารางที่ 2.2 การเปรียบเทียบและอธิบายกลยุทธ์หลายอย่างในการใช้เทคโนโลยี Machine


Learning และการประมวลผลภาพในการตรวจจับและจัดจำแนกโรคข้าวที่งานวิจัยได้รวบรวม [3]

Technique Used	Disease Identified	Accuracy	Merits	Demerits
Neuro-Fuzzy expert system	LBD, BSD, BLB	74.21%.	Recognized the diseases at their early stages.	Issues in tackling the noises and other lighting problems due to external forces.
PCA, Color Grid-centered Moment and GLCM for feature extortion and SVM for classification	Leaf blast, leaf streak, BLB, leaf brown spot	90%	Attained Highest accuracy	This methodology was not applicable for categorization of crop diseases
Deep CNNcentered classification	pests and diseases in rice plants were recognize	95%	Accurately and timely detect the diseases	Deep learning methodology contained several layers for classification. So it took more time to spot the diseases contrasted with others
R-FNN, RCNN, SSD	Diseases and pests of various plants were identified	88%	Ability to compete with complex scenarios and effectively identifies disparate diseases.	Time Consumin
SVM classifier	rice blast diseases, narrow brown spot, BLB, brown spot,	70%	Efficiently classified 4 kinds of diseases in rice	Lowest accuracy when contrasted with others
ESforRPD2 application, Unified Modelling Language and Waterfall Paradigm	8 sorts of diseases and 48 symptoms of the rice plants were recognized	87.50%	Showed GoodReliability	Performance of this method was low compared with other expert system

ตารางที่ 2.2 การเปรียบเทียบและอธิบายกลยุทธ์หลายอย่างในการใช้เทคโนโลยี Machine Learning และการประมวลผลภาพในการตรวจจับและจัดจำแนกโรคข้าวที่งานวิจัยได้รวบรวม [3] (ต่อ)

Technique Used	Disease Identified	Accuracy	Merits	Demerits
Radial basis function network (RBFN) model	Sheath Blight, Panicle Blast, Brown spot, Leaf Blast.	95.50%	Good recognition efficiency and generalization	some of the diseases were not identified accurately
PCA and NN	Rice Blast	95.83%	Identify the disease quickly and efficiently	Limitations exist in the recognition of lesions with similar morphology and color
PSO – centered incremental classifier	Rice blast, Sheath Rot, Leaf brown spot, BB	84.02%	Reduces the computational time	The results are not checked for incremental data and also the system may demand a self-adapted parameter setting scheme.
Hyperspectral data	RLF damage in rice	82%	More accurate than others because of reflectance	Applicable only to specific fields due to the variation of spectra say, stages of growing, species of crop etc
A visual method based on PdNPscatalyzed TMB/H ₂ O ₂ system	blast fungus, Magnaporthe oryzae	85%	Sensitive, and cost-effective methodology for the fast screening and for early diagnosis of M. oryzae in rice plant	Cannot find Other sorts of diseases in rice.

ในตารางที่ 2.2 จะสรุปวิธีการต่าง ๆ ที่ใช้ในการระบุโรคข้าว โดยใช้วิธีการประมวลผลภาพ และ Machine Learning ที่แตกต่างกันอย่างละเอียด โรคข้าวต่าง ๆ เช่นโรคกระเปิดข้าว, จุดสีน้ำตาลใบข้าว, การเน่าของฝักและ BB ถูกระบุโดยใช้ตัวจำแนกประเภทที่แตกต่างกัน แต่ละเทคนิคจะมีข้อได้เปรียบของตัวเอง วิธีการจำแนกประเภทต่าง ๆ และเทคโนโลยีประมวลผลภาพอื่น ๆ ที่ใช้งานวิจัยต่าง ๆ ถูกตรวจสอบ และเปรียบเทียบประสิทธิภาพของเครื่องมือที่ใช้ในการวิเคราะห์ภาพตามมาตรฐานความแม่นยำ แผนภูมิเปรียบเทียบประสิทธิภาพของวิธีการต่าง ๆ ที่ได้รับการสำรวจในตาราง 3 จะถูกอธิบายโดยละเอียดในภาพที่ 2.6



รูปที่ 2.6 การเปรียบเทียบระดับความแม่นยำของเทคนิคต่าง ๆ ได้แก่ระบบเชี่ยวชาญแบบ Neuro Fuzzy, SVM ที่ใช้ PCA, CNN ลึก, Faster R-CNN, และ SVM (b) ระบบเชี่ยวชาญสำหรับ RPD2 ฟังก์ชันฐานเชิงรังสี ตัวจำแนกประเภท NN ตัวจำแนกประเภทแบบ PSO [3]

ภาพที่ 2.6 อธิบายระดับความแม่นยำของตัวจำแนกประเภทต่าง ๆ และวิธีการอื่น ๆ ที่ใช้ในการระบุโรคข้าว มีการใช้เทคนิค Machine Learning หลายวิธีเพื่อระบุโรคข้าวหลายประเภท ตัวจำแนกประเภทที่ใช้ Neural Network ได้ผลลัพธ์ที่ดีกว่าเมื่อเปรียบเทียบกับเทคนิคอื่น ๆ ตัวอย่างเช่น ตัวจำแนกประเภท Neural Network ได้รับความแม่นยำสูงสุด (95.8%) ในขณะที่โมเดล RBFN ได้รับความแม่นยำ 95.5% ส่วนตัวจำแนกประเภท SVM ได้รับความแม่นยำต่ำที่สุดเมื่อเปรียบเทียบกับเทคนิคทั้งหมดที่ใช้

ระบบการรับรู้โรคของพืชข้าวมุ่งเน้นในการพยากรณ์โรคให้ได้รวดเร็วและแม่นยำ ในการจัดการโรคพืชเพาะปลูก เพื่อให้การรับรู้โรคของพืชข้าวในระยะต้นสนับสนุนนักวิจัยด้านการปลูกข้าวและเกษตรกรในการดำเนินการที่รวดเร็วเพื่อป้องกันพืชได้ทันเวลา การศึกษานี้เน้นที่การสำรวจและสรุปข้อมูลเกี่ยวกับการตรวจจับโรคของพืชข้าวโดยใช้วิธีการประมวลผลภาพและ เทคโนโลยีการ


เรียนรู้ของเครื่อง ภาพของใบพืชข้าวที่ถูกผลิตจากการใช้เทคนิคการแบ่งเซ็กเมนต์แตกต่างกัน ๑ วิธีการที่ถูกต้องทบทวนในบทความนี้ช่วยให้นักวิจัยสามารถเอาชนะปัญหาที่แต่กระเปียบได้อย่างมีประสิทธิภาพ สำหรับงานที่จะมาถึง จะมีการแนะนำวิธีการที่จะทำงานกับปัญหาการวิจัยปัจจุบันที่ได้ถูกกล่าวถึงข้างต้น และการสำรวจวิธีการทำ Machine Learning และการแบ่งเซ็กเมนต์ที่มีศักยภาพที่จะทำให้การรับรู้โรคในพืชเป็นเรื่องง่ายขึ้น ในอนาคต การประสิทธิผลและความต้องการในการคำนวณอาจจะถูกเปรียบเทียบกับอัลกอริทึมแบบเดิม

2.1.4 An Automated Convolutional Neural Network Based Approach for Paddy Leaf Disease Detection (2021) [4]

ตั้งแต่เริ่มต้นของศตวรรษที่ 21 ข้าวนา (*Oryza sativa* species) ยังคงเป็นธัญพืชหลักในระบบอาหารของมนุษย์และเป็นแหล่งพลังงานและโปรตีนสำคัญที่สุดที่ถูกบริโภค โดยประมาณสามพันล้านคน มากกว่า 90% ของข้าวในโลกถูกผลิตในภูมิภาคเอเชียแปซิฟิก ในประเทศบังกลาเทศ ข้าวเป็นพืชผลที่สำคัญ ประมาณ 75% ของพื้นที่เพาะปลูกทั้งหมดและมากกว่า 80% ของพื้นที่รดน้ำทั้งหมดถูกปลูกข้าว ดังนั้น ข้าวมีความสำคัญในการอาศัยอยู่ของคนในประเทศบังกลาเทศ ส่วนใหญ่เกษตรกรต้องเผชิญกับปัญหาต่างๆ ในการเพาะปลูกข้าว เช่น ความเสียหายต่อพื้นที่เพาะปลูก การเพิ่มจำนวนประชากร การเปลี่ยนแปลงสภาพอากาศ แมลงศัตรู และโรคต่างๆ เนื่องจากปัญหาต่างๆ เหล่านี้ เกษตรกรกำลังสูญเสียความสนใจในการเพาะปลูกข้าวในปัจจุบัน บทความนี้ได้เน้นเฉพาะการระบาดของแมลงศัตรูและโรคต่างๆ ที่มีต่อการเพาะปลูกข้าว มีโรคข้าวสามประเภทหลักคือ โรคจุดเชื้อรา, โรคจุดเชื้อแบคทีเรีย, และโรคอื่นๆ ซึ่งรวมถึงโรคโรคจุดเชื้อแบคทีเรีย, โรคจุดใบเหลือง, โรคใบไหม้, โรคเหี่ยวยืนใบ, โรครอยลึก, โรคเปลือกตายของเมล็ด เป็นต้น ความรุนแรงของโรคเพิ่มมากขึ้นเมื่อเร็ว ๆ นี้เนื่องจากผลกระทบที่ไม่พึงประสงค์จากการเปลี่ยนแปลงสภาพอากาศ โดยเฉพาะการเพิ่มขึ้นของอุณหภูมิ (IPCC, 2007) ประมาณ 4-14% ของผลผลิตข้าวในประเทศบังกลาเทศสูญเสียทุกปีโดยสาเหตุจากแมลงศัตรูและโรคต่างๆ โรคใบแบคทีเรีย (BLB) และโรคจุดสีน้ำตาลเป็นโรคที่ร้ายแรงในข้าวในปัจจุบัน แต่เทคโนโลยีนวัตกรรมสำหรับแมลงศัตรูและโรคต่างๆ ยังคงถูกจำกัดอยู่ โดยทั่วไปการรับรู้โรคข้าวด้วยวิธีการธรรมดาคือการรับรู้ด้วยตาโดยนักเชี่ยวชาญซึ่งใช้เวลานาน และมีค่าใช้จ่ายสูงในระบบที่ใหญ่ ๆ มั่นยากที่จะวัดและบางครั้งก็สร้างข้อผิดพลาดในการระบุชนิดของโรค เนื่องจากขาดความรู้ในการบริหารโรคใบข้าวอย่างเหมาะสม การผลิตข้าวลดลงในช่วงไม่นานมานี้ เพื่อที่จะเอาชนะปัญหานี้ การรับรู้ที่เหมาะสมและรวดเร็วเป็นสิ่งจำเป็นสำหรับการวินิจฉัยโรคใบข้าว งานนี้เน้นไปที่โรคใบข้าว 5 โรคที่พบบ่อยที่สุดคือ จุดสีน้ำตาล, ใบสุภาพดี, ไร่ใบไหม้, โรคใบแบคทีเรีย, และ โรคข้าวดอกกระถิน การปฏิวัติของปัญญาประดิษฐ์ทำให้ง่ายขึ้นในการรักษาระดับการดำรงชีวิต ไม่มีขาดแคลนของการมีส่วนร่วมของ AI

ในภาคเกษตรเช่นเดียวกับภาคอื่น ๆ เทคโนโลยีได้ทำให้ง่ายมากขึ้นในการแก้ไขปัญหาในการเกษตร โรคพืชก็เป็นหนึ่งในนั้น ในปัจจุบัน มันสามารถทำการตรวจจับโรคมากมายโดยใช้การเรียนรู้ เครื่องจักรและการเรียนรู้เชิงลึก แม้จะมีข้อจำกัดบางอย่าง แต่มันได้ประสบความสำเร็จอย่างมาก ผลกระทบจากนี้ ส่วนเกษตรกรเองสามารถตรวจจับโรคข้าวในที่ดินของตนเองได้โดยไม่ต้องไปขอความช่วยเหลือจากผู้เชี่ยวชาญ เทคโนโลยีกำลังจะนำมากมายขึ้นในภาคเกษตรในอนาคต ตามการสำรวจที่ดำเนินการในช่วง ค.ศ. 1979-1981 พบว่ามีโรคข้าวทั้งหมด 20 โรคที่รายงานว่าเป็นโรคใบข้าวในประเทศไทย โดยในนั้นมีโรคที่สำคัญทั้งหมด 13 โรค ในปี 2019 ตามฐานความรู้เกี่ยวกับข้าวของประเทศไทย โรคใบราบากที่เกิดจากแบคทีเรียถือเป็นหนึ่งในโรคที่มีอันตรายมากที่สุด ในประเทศไทย โรคใบราบ, ใบเน่าเขียว, จุดสีน้ำตาล เป็นโรคที่พบได้บ่อยในการเพาะปลูกข้าว ในบทความนี้ได้เน้นไปที่โรคข้าว 4 โรค ได้แก่ จุดสีน้ำตาล, ใบเน่า, แบคทีเรีย, โรคดอกกระถิน และใบสุขภาพดี มีการเลือกใช้โมเดล Deep Convolutional Neural Network และฝึกข้อมูลซึ่งมีอยู่บนโมเดลที่ฟรี-เทรนชื่อ VGG-19, Xception, Inception-Resnet-V2, และ Resnet-101

ก่อนหน้านี้ ได้มีงานวิจัยมากมายเกี่ยวกับการตรวจจับโรคของข้าวโดยใช้แนวคิดของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกโดยใช้ระบบที่แตกต่างกัน งานวิจัยนี้ปฏิบัติตามวิธีการเปรียบเทียบที่มีมาตรฐานด้วยโมเดลการเรียนรู้เชิงลึกที่ปรับแต่งแล้วที่แสดงในแผนภาพการไหล (รูปที่ 2.7) หลังจากได้รับภาพใบข้าวที่ติดเชื่อมมาแล้ว กระบวนการประมวลผลภาพภาพเข้าร่วมด้วย ภาพที่ประมวลผลแล้วจะผ่านระบบประสานของเครือข่ายประสาทคอนโวลูชันลึก บล็อกการประมวลผลคอนโวลูชันของโมเดลจะสกัดคุณลักษณะหลักจากภาพนำเข้า โดยขึ้นอยู่กับคุณลักษณะของภาพ โมเดล DNN จะเริ่มต้นน้ำหนักของแต่ละโหนด ขั้นสุดท้ายของโมเดลประกอบด้วยโหนดประสาทห้าตัว และฟังก์ชันการกระตุ้นเช่น softmax จะช่วยในการพยากรณ์ชนิดของข้อมูลที่กำหนด เครื่องป้อนภาพจากชุดข้อมูล ประมวลผลภาพเช่นหมุน, ขยาย, พลิก, สลับ, ปรับขนาดภาพ นี้จะใช้รูปแบบที่สร้างลักษณะหลักและการจำแนกประเภท การพยากรณ์ผลด้วยโมเดลที่ดีที่สุด



รูปที่ 2.7 Proposed Scheme [4]

Deep Convolutional Neural Network (Deep CNN) เป็นรูปแบบของเครือข่ายประสาทเชิงลึกที่ใช้ในการปรับพารามิเตอร์ของเครือข่ายเพื่อลดค่าของฟังก์ชันต้นทุน โมเดลเหล่านี้มีผลการทำงานอย่างมากในการวิเคราะห์ภาพเคลื่อนไหวทางภาพหรือวิดีโอ การจำแนกหรือการตรวจจำวัตถุ การประมวลผลภาษาธรรมชาติ ยึดตัวอย่างจากเครือข่ายประสาทคอนโวลูชันซึ่งประกอบด้วยจำนวนชั้นที่มากกว่าโมเดล CNN ทั่วไป โมเดลมักประกอบด้วยชั้นคอนโวลูชัน ชั้นการกระตุ้น ชั้นการรวมข้อมูล ชั้นแปลน การใช้ Dropout และชั้นการปรับแก้ค่ากลุ่ม รวมทั้งชั้นเดนส์ Dropout ถูกใช้เพื่อป้องกันการเกิดการ overfitting ฟังก์ชันการกระตุ้นเช่น ReLu, Softmax ถูกเพิ่มเข้าไปในชั้นของเครือข่ายเพื่อช่วยในการระบุรูปแบบที่ซับซ้อนในข้อมูล โมเดล Deep CNN ต่างๆได้แสดงในรูปที่ 2.8 ว่า โมเดล Deep CNN มีประสิทธิภาพที่ดีสำหรับการจำแนกและตรวจจำ สี่โมเดลถูกเลือกขึ้นโดยขึ้นจากการออกแบบและความลึกของเครือข่าย ความแม่นยำในการตรวจสอบกับชุดข้อมูลการตรวจสอบ ImageNet และความลึกทางเทคโนโลยีของเครือข่าย

Model Name	Top 5 Accuracy	Parameters	Depth
VGG-19	0.900	143,667,240	26
ResNet-101	0.928	44,707,176	101
Xception	0.945	22,910,480	126
Inception-ResNet-V2[32]	0.953	55,873,736	572

รูปที่ 2.8 คำอธิบายของโมเดล CNN ที่ใช้เทคโนโลยี Keras ในการเรียนรู้เชิงลึก [4]

การศึกษานี้ได้ทำงานกับอัลกอริทึมการเรียนรู้เชิงลึกที่ได้รับการเตรียมการล่วงหน้าด้วย Keras ทั้งหมด 4 รูปแบบตามที่ไดกล่าวถึงในรูป 2.9 เพื่อจำแนกและตรวจจำโรคในใบข้าว ในขณะที่วิเคราะห์อัลกอริทึมเหล่านี้ การศึกษาพบว่า Inception-ResNet-V2 ได้รับความแม่นยำสูงสุดระหว่างพวกเขาซึ่งมีค่าเท่ากับ 0.9286 และเช่นเดียวกัน สำหรับความแม่นยำ ความจำเพาะของเคล็ดลับ และคะแนน F1 Inception-ResNet-V2 นำหน้าทั้งหมดหลังจาก Inception-ResNet-V2 Resnet-101 ได้แสดงความแม่นยำเป็น 0.9152 รูปแบบ Xception ได้รับความแม่นยำ 0.8942 และ VGG-19 มีความแม่นยำต่ำสุดเป็น 0.8143 ไม่เพียงแต่ความแม่นยำแต่ยังในส่วนของความแม่นยำ ความจำเพาะ และคะแนน F1 มีผลลัพธ์ต่ำสุด จำนวนที่พิจารณา คือ 100 สำหรับกระบวนการฝึกฝนทั้งหมด ข้อมูลทั้งหมดนี้นำเสนอในรูปที่ 2.10 ซึ่งประกอบด้วยการวิเคราะห์ทางสถิติของรูปแบบต่างๆ พารามิเตอร์การประเมิน (ความแม่นยำ ความสามารถในการคาดการณ์ ความจำเพาะ คะแนน F1) ถูกกำหนดเป็นดังต่อไปนี้ ความแม่นยำถูกคำนวณจาก Confusion Matrix ความแม่นยำเป็นการวัดประสิทธิภาพที่สามารถคาดการณ์ได้ง่ายที่สุด และเป็นอัตราส่วนทั่วไปของข้อมูลที่ทำนายได้อย่าง

ถูกต้องต่อข้อมูลทั้งหมดในชุดข้อมูลและมีความแม่นยำที่ดีขึ้น เป็นไปได้เฉพาะเมื่อค่าของเท็จบวก และเท็จลบมีค่าเท่ากันในชุดข้อมูล เนื่องจากโมเดล Inception-ResNet-V2 ได้รับความแม่นยำสูงที่สุด เมื่อเปรียบเทียบกับโมเดลสามรูปแบบอื่น ๆ แล้ว การศึกษาได้สร้างตารางประสิทธิภาพสำหรับ อัลกอริทึมนี้เฉพาะสำหรับแต่ละคลาสในชุดข้อมูล และบันทึกความแม่นยำ ความจำเพาะ และ คะแนน F1 ของแต่ละคลาส ดังที่เห็นในตาราง IV สำหรับความแม่นยำ ในคลาส Brown Spot, Leaf Blast, Leaf Blight, Leaf Smut ได้รับมากกว่า 0.90 แต่สำหรับภาพใบสุขภาพ มันลดลงเหลือเพียง 0.78 สำหรับการเรียกคืน สำหรับคลาสใบไหม้มีค่าเท่ากับ 0.71 และสำหรับคลาสอื่น ๆ มีค่าเกิน 0.90 ในท้ายที่สุด สำหรับคะแนน F1 คลาสใบไหม้เป็นต่ำสุดที่ 0.82 และสำหรับคลาสโรคดอกกระถิน ความแม่นยำ การเรียกคืน และคะแนน F1 มีค่าเป็น 1.0 ข้อมูลทั้งหมดนี้และรายละเอียดอื่น ๆ นำเสนอรูปที่ 2.10


Models	Accuracy	Precision	Recall	F1 Score
VGG19	0.8143	0.8176	0.8035	0.8041
ResNet-101	0.9152	0.9215	0.9056	0.9056
Inception-ResNet-V2	0.9286	0.9371	0.9262	0.9286
Xception	0.8942	0.8963	0.8865	0.8823

รูปที่ 2.9 การวิเคราะห์ทางสถิติของโมเดล Keras ก่อนการเรียนรู้ล่วงหน้าที่แตกต่างกัน [4]

Classes	Brown Spot	Healthy Leaf	Leaf Blast	Leaf Blight	Leaf Smut
Precision	1.00	0.78	0.95	0.91	1.00
Recall	0.93	1.00	0.71	1.00	1.00
F1 Score	0.96	0.88	0.82	0.98	1


รูปที่ 2.10 คะแนนประสิทธิภาพสำหรับแต่ละคลาสของโมเดล InceptionResNet-V2 [4]

รูปที่ 2.11 แสดงกราฟของความแม่นยำในการฝึกและการตรวจสอบความแม่นยำของโมเดล สามารถเห็นได้ว่าสำหรับความแม่นยำในการฝึก ด้วยเส้นสีน้ำเงิน ได้ถึงประมาณ 1.0 และในความแม่นยำในการตรวจสอบ ซึ่งเป็นเส้นสีส้ม มีการเคลื่อนไหวในช่วงประมาณ 0.80 ถึง 0.90



รูปที่ 2.11 Training and Validation Accuracy Graph [4]

แม้ว่าจะมีความยากลำบากในการตรวจจับโรค แต่เทคโนโลยีได้ทำให้งานนี้ง่ายขึ้นมากสำหรับเรา แต่แม้กระนั้นเทคโนโลยีก็ไม่สามารถให้ผลลัพธ์ที่เสมอไปเหมือนมนุษย์ บางครั้งยังคงมีข้อจำกัดอยู่ เครื่องมักจะสับสนเกี่ยวกับการตรวจจับโรค หลังจากที่เราเลือกโมเดลที่ดีที่สุด มีข้อผิดพลาดบางอย่างเกิดขึ้น ในภาพที่ 2.12 สามารถเห็นได้ว่ามีข้อมูลที่ขัดแย้งกันระหว่าง Leaf Blast กับ Healthy Leaf มีทั้งหมด 8 ข้อมูล และ 2 ข้อมูลของ Brown Spot กับ Leaf Blast และ Leaf Blight ถึงแม้จะมีจำนวนน้อยลง แต่ก็ยังมีอยู่



รูปที่ 2.12 Confusion Matrix of Inception-ResNet-V2 Model [4]

ในส่วนนี้จะพูดถึงวิธีการต่าง ๆ ในการระบุและจำแนกโรคของข้าวและใบข้าว ซึ่งสามารถวินิจฉัยข้าวในรูปแบบต่าง ๆ โดยใช้เครื่องมือและเทคโนโลยีที่แตกต่างกันของ Machine Learning และ Deep Learning มีการวิจัยมากมายในหัวข้อนี้ก่อนหน้านี้และกำลังดำเนินการต่อไปอย่างต่อเนื่อง การเปรียบเทียบบางส่วนของงานวิจัยที่ผ่านมาแสดงในภาพที่ 2.13 ในงานวิจัยที่ผ่านมา เห็นว่ามีผู้วิจัยหลายคนทำงานกับหนึ่งหรือสองหรือสามหรือสี่โรคของข้าวโดยใช้อัลกอริทึม Machine Learning หรือโมเดล Deep Learning หรือแนวความคิดเชิงคำนวณอัตโนมัติ งานวิจัยนี้ได้ทำงานกับโรคสี่ชนิดที่แตกต่างกัน (Leaf Smut, Leaf Blast, Bacterial Leaf Blight, และ Brown Spot) และใบข้าวหนึ่งใบที่เป็นสุขภาพด้วยการใช้โมเดล Deep CNN ที่ใช้การเรียนรู้โอนย้ายขั้นสูง

Diseases	Tools Technologies	Accuracy
Leaf smut, bacterial blight, brown spot	KNN, J48, Naive Bayes, Logistic Regression, Decision Tree, 10-fold cross-validation	97%
Leaf blast	CNN, IoT, spore germination	89.4%
Rice blast, bacterial leaf blast, sheath blight	Deep CNN, SVM, transfer learning, MatConvNet toolbox, AlexNet, NVIDIA GeForce 940M GPU	91.37%
Rice sheath blight, rice stem borer, brown spot	deep CNN, faster-RNN, confusion matrix, VGG16, ResNet-50, ResNet-101, YOLOv3, custom DCNN	The better result from custom DCNN
Leaf blast	KNN, ANN	99%
Brown spot, bacterial blight, leaf scald, leaf blast	Fuzzy logic, computational intelligence, SVM, K-means	86.35%

รูปที่ 2.13 Comparison of previous research on paddy diseases [4]

การดำเนินการศึกษานี้ได้ประเมินประสิทธิภาพของสี่โครงสร้างเครือข่ายลึกในการเรียนรู้แบบลึกและวิเคราะห์โดยใช้มาตรการสถิติต่าง ๆ โดยการวิเคราะห์ความแม่นยำของอัลกอริทึม, ความแม่นยำ, การคืนค่า, และ F1 score ได้รับคะแนนสูงสุดในการทดสอบความแม่นยำถึง 92.68% ใน Inception-ResNet-V2 ในงานวิจัยนี้ ข้อมูลที่ใช้ในการฝึกและทดสอบโมเดลเก็บมาจากแหล่งข้อมูลบนอินเทอร์เน็ตและบริษัทข้าวในพื้นที่ ชุดข้อมูลประกอบด้วยห้าชั้นที่มีรูปภาพใบของข้าวที่เป็นโรคสี่ชนิดแตกต่างกันและหนึ่งชั้นของรูปภาพใบที่เป็นสุขภาพ โครงสร้างเครือข่ายที่ไม่เหมือนกัน


ของ Inception-ResNet-V2 ประกอบด้วยบล็อกต่าง ๆ ที่มีผลกระทบเล็กน้อยถึง 571 จากที่มากกว่าเครือข่ายอื่น ๆ เพื่อให้เข้ากันได้กับชุดข้อมูล โครงสร้างเครือข่าย ResNet-101 ได้รับความแม่นยำในการทดสอบที่สูงสุดอันดับสองถึง 91.52% เพื่อให้ได้การพยากรณ์ที่แม่นยำมากขึ้นเกี่ยวกับโรคใบของข้าว ได้ใช้การเรียนรู้โอนเรียนรู้วิธีการนี้ช่วยเพิ่มความแม่นยำและลดความซับซ้อนในการฝึกโมเดล

2.1.5 Deep Learning Utilization in Agriculture: Detection of Rice Plant Diseases Using an Improved CNN Model [5]

ข้าวเป็นหนึ่งในอาหารที่มีการบริโภคมากที่สุดในโลก เนื่องจากเป็นแหล่งโภชนาการหลักสำหรับหลายประเทศ รวมถึงประเทศที่มีประชากรมากที่สุดเช่น จีน อินเดีย และปากีสถาน การจำแนกประเภทของข้าวอยู่ภายใต้วงจรประเภท Orza ซึ่งรวมถึงอาหารธัญพืชอื่น ๆ เช่น ข้าวโพด และธัญพืช เหตุผลที่ทำให้ข้าวเป็นที่นิยมคือมันอุดมไปด้วยวิตามิน แร่ธาตุ และโภชนาการ โดยประมาณว่าเป็นตัวเลือกของอาหารหลักสำหรับมากกว่าสามพันล้านคนขึ้นไป ข้าวเป็นค่าทั่วไปที่มีหลายชนิดทั่วโลกและวิธีการปลูกก็แตกต่างกันไป อย่างไรก็ตาม ควรให้ทราบว่าพืชข้าวทุกชนิดมีความเหมือนกันในการเจริญเติบโต เนื่องด้วยมีระยะเวลาการเจริญเติบโตทั้งหมดสามระยะก่อนการเก็บเกี่ยว มีพื้นที่เกษตรกรรมทั่วโลกประมาณ 15% ถูกใช้ในการปลูกข้าว การผลิตข้าวหลักๆ อยู่ทางตะวันออกของอินเดียและปากีสถาน เมื่อเร็วๆ นี้มีการลดลงของการผลิตข้าวที่เห็นได้ชัดเจนเนื่องจากเหตุผลต่างๆ หนึ่งในเหตุผลหลักคือโรคหรือภัยที่มักจะเกิดขึ้นกับพืชข้าว ซึ่งเป็นระยะหรืออาการไม่พึงประสงค์มากที่สุดคือ โรคกาเนดลำใบ ใบไหม้ และจุดสีน้ำตาล เนื่องจากมีผลกระทบอย่างมากต่อการผลิตข้าวหรือคุณภาพของเมล็ดข้าว อย่างไรก็ตาม อาการโรคแต่ละอย่างแตกต่างกัน แต่มีข้อความร่วมมือกันในการมีจุดบนใบพืช ดังนั้นการตรวจจับโรคตั้งแต่เริ่มแรกสามารถลดหรือป้องกันความเสียหายที่เกี่ยวข้องได้ ปัญหาหลักคือขาดการสังเกตของพืชอย่างต่อเนื่อง ปัจจัยอื่น ๆ อาจเป็นว่าเกษตรกรที่เข้ามาใหม่ในสนามไม่สนใจและมองเห็นโรคที่อาจเกิดขึ้นกับพืชและฤดูกาลของพวกเขา โรคแม้จะสามารถติดเชื้อพืชได้ตลอดเวลา แต่การสังเกตพืชและช่วงเวลาการเจริญเติบโตของพวกเขาตลอดเวลาสามารถหยุดการติดเชื้อโรคได้ การตรวจสอบพื้นที่ขนาดใหญ่ของทุ่งข้าวอย่างประจำวันโดยเกษตรกรเป็นงานที่เป็นไปได้ยาก เนื่องจากขนาดของไร่ทุ่งใหญ่และแม้จะเป็นไปได้ มนุษย์ก็ไม่สามารถมองในแต่ละต้นพืชและตรวจสอบได้ การให้เกษตรกรตรวจสอบพืชข้าวอย่างเป็นประจำทุกวัน แม้จะเป็นไปได้ ก็จะเป็นงานที่ใช้ทรัพยากรมาก อาจจะมีข้อผิดพลาดของมนุษย์ เกิดความเสียหายต่อพืชข้าวในเส้นทางของพวกเขา และปัจจัยอื่น ๆ ที่จะสิ้นสุดลงเป็นผลทำให้เกิดความเสียหายมากกว่าดี การจำแนกหรือวินิจฉัยปัญหาเป็นงานที่ทำหายมากที่จะทำได้โดยการ physically เนื่องจากต้องการพารามิเตอร์ต่าง ๆ ที่จะต้องสังเกต เช่น เงื่อนไข สภาพแวดล้อม และอื่น ๆ ด้วยความก้าวหน้าของเทคโนโลยี หนึ่งในแนวโน้มที่ใหม่ล่าสุดที่นักวิจัยกำลังสนใจคือการใช้


ปัญญาประดิษฐ์ (AI) และ Machine Learning (ML) เพื่อช่วยเกษตรกรและนักวิจัยในต่าง ๆ สาขาของเกษตรกรรมในการตรวจจับโรคพืชข้าวในระยะต้นโดยไม่มีการแทรกแซงของมนุษย์ การปรับปรุงต่อเนื่องในการประมวลผลภาพดิจิทัลและเมทอดการจดจำทำให้เป็นไปได้และง่ายขึ้นในการตรวจจับพืชที่ติดเชื้อและจำแนกโรคที่พืชติดเชื้อ อย่างไรก็ตาม AI และ ML เพียงอย่างเดียวอาจไม่เพียงพอ ดังนั้นบางนักวิจัยมีความเสนอแนะให้ใช้เทคโนโลยีเช่นเทคโนโลยีเชื่อมต่อของโดรน Internet of Things (IoT) และคลาวด์คอมพิวเตอร์ รวมถึงอื่น ๆ เพื่อให้ได้ระบบที่สมบูรณ์ที่สามารถช่วยเกษตรกรให้ได้ผลลัพธ์ที่ดีและลดต้นทุน อย่างไรก็ตาม ส่วนประกอบหลักยังคงเป็นอัลกอริทึม ML ที่มีประสิทธิภาพอย่างสูงเพื่อตรวจจับและวินิจฉัยโรคพืชข้าวอย่างถูกต้อง ดังนั้น นักวิจัยยังคงค้นหาวิธีการ ML ที่เหมาะสมที่สุดสำหรับการตรวจจับและวินิจฉัยโรคพืช แม้ว่าการศึกษาในด้านนี้จะได้รับการดำเนินการเร็วขึ้นเมื่อเร็วที่สุด อย่างไรก็ตาม การหาวิธีที่แม่นยำและดีที่สุดยังคงเป็นหัวข้อวิจัยที่ยังไม่ปิดหรือนักวิจัยกำลังทำงานอย่างต่อเนื่องเพื่อเป้าหมายนี้ นักวิจัยในสาขาการเกษตรกำลังมองหาวิธีการใช้เรียนรู้ของเครื่องในการปรับปรุงพันธุ์พืชในวิทยาศาสตร์การเพาะเลี้ยงในวัตถุเลื้อยเช่น เครื่องช่วยแสดงอาการเครื่องในวิทยาศาสตร์การทำลายโดยความเครียด เครื่องวิทยาศาสตร์การทำลายโดยความเครียด เครื่องช่วยในวิทยาศาสตร์การทำลายโดยความเครียด เครื่องช่วยในการประยุกต์ใช้ในวิทยาศาสตร์ของพืช และการระบุพืชในการสำรวจ แรงจูงใจสำหรับระบบที่สามารถช่วยเกษตรกรข้าวในการตรวจจับโรคพืชข้าวตั้งแต่เริ่มต้นเป็นชัดเจนจากข้างบนที่จะเพิ่มการผลิตและคุณภาพ และลดต้นทุนซึ่งจะเป็นประโยชน์ทั้งสองของเกษตรกรและผู้บริโภค การวิจัยในด้านเทคโนโลยีในวงการเกษตรมักเน้นการปรับปรุงการผลิตและคุณภาพ การให้ความสำคัญเหตุให้ข้าวขึ้นอยู่กับความพิเศษของมันในวงการเกษตรซึ่งต้องการความสนใจเฉพาะจากนักวิจัยเพื่อการป้องกันการตรวจจับโรคพืชข้าวตั้งแต่เริ่มต้น การวิจัยในสาขานี้เป็นสิ่งจำเป็นไม่ว่าจะเป็นเมล็ดข้าวที่บริโภคโดยสามพันล้านคนหรือผลิตภัณฑ์เกษตรอื่น ๆ ที่มีความสำคัญเท่าๆ กันหรืออาจมีความสำคัญมากกว่านั้น จุดมุ่งหมายหลักของงานนี้คือการพัฒนาระบบโดยใช้เทคนิค ML และ Deep Learning (DL) ที่ถูกปรับแต่งใหม่ ๆ ที่จะตรวจจับ จำแนก และวินิจฉัยโรคพืชข้าวโดยอัตโนมัติโดยไม่มีการแทรกแซงของมนุษย์ เป้าหมายสุดท้ายคือการเสนอวิธีใหม่ ๆ ที่สามารถทำให้ได้ความแม่นยำในการวินิจฉัยที่สูงกว่าเทคนิคอื่น ๆ ในวรรณกรรมที่มีชุดข้อมูลที่เหมือนหรือใช้ชุดข้อมูลขนาดเท่ากัน ส่วนที่เหลือของงานนี้จัดแสดงรายละเอียดของวรรณกรรมเกี่ยวกับ machine learning และ deep learning ในสาขาเกษตรกรรม โดยเฉพาะโรคพืชข้าว และพื้นที่อื่น ๆ ที่ใช้ machine learning ในงานวิจัยนี้เราเสนอโมเดลใหม่สำหรับการจำแนกโรคใบข้าว ระบบที่เสนอมีความสามารถในการตรวจจับและจำแนกหกชนิดที่แตกต่างกันได้แก่ สุขภาพดี ใบขีดสีน้ำตาล ใบวงสีน้ำตาล ใบไหม้ ใบจุดน้ำตาล และโรคใบแบคทีเรีย ระบบที่เสนอเป็นหนึ่งในหลายๆ ระบบในวรรณคดีที่สามารถจำแนก 6 ชนิดที่แตกต่างกันได้ วิธีการถ่ายโอนเรียนรู้ของ CNN แบบลึกที่เสนอภาพจะผ่านขั้นตอนการประมวลผลก่อน โดยที่ภาพจะถูก

นำเข้าสู่การลบพื้นหลังการปรับขนาด และการเพิ่มความชัดเจน การเพิ่มขนาดข้อมูลก็ถูกดำเนินการเพื่อเพิ่มขนาดของชุดข้อมูล ส่วนใหญ่ของงานวิจัยใช้ชุดข้อมูลขนาดเล็ก ซึ่งอาจทำให้เกิดการ overfitting แม้ว่าผู้เขียนจะไม่ได้กล่าวถึงปัญหาการ overfitting ที่อาจเกิดขึ้นได้ ในงานวิจัยนี้เราใช้การเพิ่มข้อมูล เพื่อสร้างภาพใหม่ที่แตกต่างกัน ข้อมูลใหม่ที่เราสร้างขึ้นอาจการหมุน การเพิ่มขนาด การลดขนาด และการย้ายภาพ จากนั้น ข้อมูลจะถูกดึงข้อมูลลักษณะด้วย VGG19 การลดขนาดลักษณะทำได้โดยใช้ flatten, dense และ softmax layers ใน VGG19 ชั้นสุดท้ายของ VGG19 จะทำการจำแนกประเภท ในการประเมินวิธีการที่เสนอใช้ metric ต่อไปนี้ความแม่นยำ และ F1-measure วิธีการถ่ายโอนเรียนรู้ของ CNN แบบลึกที่เสนอได้ถูกแสดงด้านล่าง



รูปที่ 2.14 วิธีการพื้นฐานของการถ่ายโอนเรียนรู้เชิงลึกโครงข่ายประสาทเชิงเชิงลึก (CNN) สำหรับการจำแนกโรคใบข้าว [5]

ชุดข้อมูลที่ใช้ในการวิจัยนี้ประกอบด้วยโรคใบข้าวห้าประเภทคือ ใบขีดสีน้ำตาล ใบวงสีน้ำตาล ใบไหม้ ใบจุดน้ำตาล โรคใบแบคทีเรีย รวมถึงใบข้าวที่สุขภาพดีด้วย รูปที่ 2.15 แสดงการกระจายของภาพใบข้าวในชุดฝึกและทดสอบสำหรับโรคใบข้าวที่แตกต่างกัน ป้ายชื่อชุดข้อมูลแรกแทนหนึ่งในโรคที่เป็นอันตรายมากที่สุดที่สามารถทำให้เกิดผลกระทบทำลายต่อข้าวที่เจริญเติบโตได้ ซึ่งคือโรคใบจุดสีน้ำตาล โรคนี้เกิดจากเชื้อราชื่อ "Bipolaris oryzae" โดยเริ่มต้นด้วยการปรากฏของจุดสีน้ำตาลถึงสีเทาในส่วนของกลางของใบ ซึ่งรอบๆ ด้วยสีเหลือง โดยเมื่อโรคก้าวหน้าไปข้างหน้า สีและขนาดของจุดอาจเปลี่ยนแปลงไปตามไปด้วย อย่างไรก็ตาม รูปร่างของมันจะเป็นรูปกลมๆ ในส่วนมาก



รูปที่ 2.15 การกระจายของภาพใบข้าวที่ใช้ในการฝึกและทดสอบสำหรับโรคข้าวต่างๆ [5]

ดังนั้นโรคสามารถพัฒนาไปถึงขั้นตอนสุดท้ายของมันได้โดยที่สีของใบทั้งหมดนี้จะเปลี่ยน เป็นสีเหลืองและตาย ดังนั้นโรคจะทำให้เกิดการสูญเสียทั้งปริมาณและคุณภาพในการเกษตรผลิตภัณฑ์ ในอีกด้านหนึ่ง ชุดข้อมูลที่ถูกต้องป้ายสุขภาพแสดงข้าวที่สุขภาพดีโดยไม่มีการตรวจจับโรคใดๆ ในเบื้องต้นการทดลองถูกดำเนินการโดยใช้โมเดล CNN ที่มีชื่อเสียงเพื่อชุดข้อมูลที่ไม่ได้ปรับมาตรฐาน ชุดข้อมูลที่ปรับมาตรฐานและขยายข้อมูล และชุดข้อมูลที่ไม่ได้ปรับมาตรฐานแต่มีการขยายข้อมูล โมเดล CNN ที่มีชื่อเสียงที่ได้รับการสำรวจได้แก่ GoogleNet, VGG16, VGG19, DenseNet201, และ AlexNet โมเดล DenseNet201 ได้รับความแม่นยำที่ดีที่สุดหมวดหมู่นี้ DenseNet201 ได้รับความแม่นยำเฉลี่ยอยู่ที่ 89.86% สำหรับชุดข้อมูลที่ปรับมาตรฐานและขยายข้อมูล DenseNet201 ได้รับความแม่นยำเฉลี่ยอยู่ที่ 88.33% และสำหรับชุดข้อมูลที่ไม่ได้ปรับมาตรฐานแต่มีการขยายข้อมูล DenseNet201 ได้รับความแม่นยำเฉลี่ยอยู่ที่ 83.41% สำหรับชุดข้อมูลที่ไม่ได้ปรับมาตรฐาน GoogleNet ได้รับความแม่นยำเฉลี่ยต่ำสุดที่ 83.87% ในขณะเดียวกันในชุดข้อมูลที่ปรับมาตรฐานและขยายข้อมูลและชุดข้อมูลที่ไม่ได้ปรับมาตรฐานแต่มีการขยายข้อมูล AlexNet ได้รับความแม่นยำเฉลี่ยต่ำสุดที่ 82.38% และ 79.72% ตามลำดับ

2.2 ข้อมูลทางด้านเกษตรกรรม

2.2.1 โรคใบไหม้ (Rice Blast Disease) [6]


ใบของข้าวจะมีลักษณะเป็นจุดสีน้ำตาลคล้ายรูปตามีสีเทาอยู่บริเวณตรงกลาง ความยาวของแผลประมาณ 10-15 มิลลิเมตรความกว้างประมาณ 2-5 มิลลิเมตร ในระยะต้นกล้า รอยแผลสามารถขยายลุกลามได้ทั่วไป



รูปที่ 2.16 โรควุ้น (กรมการข้าว) [6]

2.2.2 โรควุ้นจุดสีน้ำตาล (Brown Spot Disease) [6]

โรควุ้นจุดสีน้ำตาลลักษณะเป็นจุดสีน้ำตาลรูปกลมหรือรูปไข่ขอบนอกสุดของแผลมีสีออกเหลืองมีเส้นผ่านศูนย์กลาง 0.5-1 มิลลิเมตร แผลที่มีการพัฒนาเต็มที่ มีขนาด 1-2 คูณกับ 4-10 มิลลิเมตร บางทีพบรอยม้วนรูปกลมไข่ แต่จะเป็นรอยคล้ายสนิม



รูปที่ 2.17 โรควุ้นจุดสีน้ำตาล (กรมการข้าว) [6]

2.2.3 โรควุ้นขีดสีน้ำตาล (Narrow Brown Spot Disease) [6]

ลักษณะรอยที่ใบมีสีน้ำตาลเป็นขีดๆขนานไปกับเส้นของใบข้าวมักพบในระยะข้าวแตกกอ รอยแผลไม่กว้างตรงกลางเล็กไม่มีรอยชำต่อมาแผลจะขยายติดกัน ข้าวที่เป็นโรครุนแรงจะมีแผลสีน้ำตาลที่ข้อต่อใบได้



รูปที่ 2.18 โรคใบขีดสีน้ำตาล (กรรมกรข้าว) [6]

2.3 ทฤษฎีด้านเทคโนโลยี

2.3.1 อัลกอริทึม [7]

อัลกอริทึมคือชุดลำดับที่ใช้ในการแก้ลำดับชั้นปัญหาอย่างใดอย่างหนึ่งเป็นกระบวนการแก้ไข้ปัญหาที่สามารถอธิบายออกมาได้เป็นขั้นตอนที่ชัดเจนเมื่อนำเข้าอะไรแล้วจะต้อง ได้ผลลัพธ์อย่างไรอัลกอริทึมที่ตรงมีความชัดเจนอัลกอริทึมสามารถใช้ในการเขียนโปรแกรมเพื่อสั่งการคอมพิวเตอร์ให้ทำงานที่มอบหมายให้สำเร็จอัลกอริทึมเป็นวิธีการที่มีประสิทธิภาพการเขียนอัลกอริทึมสามารถเขียน ออกมาได้เป็นภาษาทางการเพื่อที่จะคำนวณฟังก์ชัน อย่างใดอย่างหนึ่ง เริ่มจากข้อความเริ่มต้นและอินพุตเริ่มต้นชุดคำสั่ง และพ่วงผ่านขั้นตอนคำสั่งที่เรียงลำดับไว้ จะสามารถให้เอาต์พุตที่ต้องการได้ โดยทั่วไป


อัลกอริทึมประกอบด้วยวิธีการที่เป็นขั้นตอนและมีส่วนที่ต้องทำแบบวนซ้ำ ในระบบคอมพิวเตอร์อัลกอริทึมคือการเขียนระบบในซอฟต์แวร์ที่เขียน โดยนักพัฒนาซอฟต์แวร์เพื่อให้มีประสิทธิภาพในการส่งออกเอาต์พุตจากอินพุตที่คอมพิวเตอร์ได้รับอัลกอริทึมจึง ถูกนับเป็นเทคโนโลยี รูปแบบหนึ่ง

2.3.2 การเรียนรู้ของเครื่อง (Machine learning) [8]

การเรียนรู้ของเครื่อง คือระบบที่สามารถเรียนรู้ได้จากตัวอย่างด้วยตนเองโดยปราศจากการป้อนคำสั่ง การเรียนรู้ของเครื่องประกอบไปด้วยข้อมูลและเครื่องมือทางสถิติเพื่อทำนายผลลัพธ์ การเรียนรู้ทั้งหมดที่เกิดขึ้น วิธีที่เครื่องเรียนรู้เหมือนกับมนุษย์ มนุษย์เรียนรู้จากประสบการณ์ ยิ่งมนุษย์รู้มาก ยิ่งง่ายต่อการพยากรณ์ว่าสิ่งต่อไปอะไรที่จะเกิดขึ้น โดยเปรียบเทียบ

เครื่องสามารถถูกฝึกได้ในรูปแบบเดียวกัน เพื่อที่จะเพิ่มความแม่นยำในการพยากรณ์ เครื่องสามารถมองเห็นตัวอย่างที่เราต้องการเห็นได้ เมื่อพวกเราให้ตัวอย่างที่เหมือนกันให้เครื่องดู เครื่องจะสามารถหาผลลัพธ์นั้นจนกว่าจะพบได้ เครื่องจะเรียนรู้ผ่านการค้นพบรูปแบบ หรือแบบแผนซ้ำๆ เดิม ๆ การค้นพบต้องขอบคุณถึงการมีข้อมูลส่วนสำคัญจะเป็นการเลือกอย่างระมัดระวังว่าข้อมูลไหนสนับสนุนกับเครื่อง คุณสมบัติต่างๆ ที่ถูกให้เพื่อแก้ไขปัญหาถูกเรียกว่า Feature vector ซึ่งเป็นซับเซตย่อยของข้อมูลทั้งหมดที่ถูกใช้ในการแก้ปัญหา

การเรียนรู้ของเครื่องสามารถถูกแบ่งออกเป็นการเรียนรู้ได้ 2 แบบ ได้แก่การเรียนรู้แบบมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน ซึ่งมีอัลกอริทึมแบบอื่นอยู่อีก การเรียนรู้แบบมีผู้สอน อัลกอริทึมจำเป็นต้องใช้ ข้อมูลในส่วนสำหรับฝึกฝน และส่วนที่รับกลับมาเพื่อปรับปรุงจากมนุษย์ เพื่อที่จะเรียนรู้ความสัมพันธ์ระหว่างข้อมูลที่ถูกป้อนเข้ามาสู่ข้อมูลที่ออกไป ซึ่งการเรียนรู้แบบมีผู้สอนแบ่งออกเป็น 2 ประเภท คือการแบ่งแยกประเภท (Classification) และการถดถอย (Regression) ถัดไปเป็นการเรียนรู้แบบไม่มีผู้สอน อัลกอริทึมจะตรวจสอบเฉพาะข้อมูลที่ป้อนเข้ามาเท่านั้นโดยปราศจากการให้ผลลัพธ์ที่จะเกิดขึ้น




รูปที่ 2.19 โครงสร้างของการเรียนรู้ของเครื่อง [9]


2.3.3 การเรียนรู้เชิงลึก (Deep Learning) [10], [11]

การเรียนรู้เชิงลึกคือซอฟต์แวร์คอมพิวเตอร์ที่สามารถลอกเลียนแบบ การทำงานของระบบโครงข่ายประสาทในสมองมนุษย์ถือเป็นซับเซตของ Machine Learning อัลกอริทึมของ Deep Learning ถูกสร้างขึ้นจากการนำเอา neural network หลายๆ ชั้นมาต่อกันโดยชั้นแรกสุดจะทำหน้าที่ในการรับข้อมูล และชั้นสุดท้ายจะทำหน้าที่ส่งผลลัพธ์การประมวลผลออกมา ส่วนชั้นระหว่างชั้นแรกและชั้นสุดท้ายจะถูกเรียกว่า Hidden layer เนื่องจากชั้นเหล่านี้เป็นโครงสร้างที่ถูกจัดเก็บแบบเป็นกองซ้อน จึงเปรียบได้ว่าชั้นจำนวนเยอะๆ ก็จะทำให้มีโครงสร้างที่ลึกยิ่งขึ้นนั่นเอง โดย Hidden Layer ของแต่ละชั้นจะเปรียบเสมือนว่าประกอบด้วยเซลล์ประสาทจำนวนมาก ซึ่งมีหน้าที่ในการประมวลผล รับข้อมูลจากชั้นที่อยู่เหนือกว่าและส่งข้อมูลที่ประมวลผลเสร็จแล้วไปยังชั้น

ที่อยู่ต่ำกว่า ข้อดีของการส่งข้อมูลแบบนี้คือ ชั้นแต่ละชั้นสามารถมีค่าถ่วงน้ำหนัก ค่าความเอนเอียงของข้อมูล และวิธีการประมวลผลทางคณิตศาสตร์ที่เป็นอิสระต่อกันได้ ยิ่งเราป้อนข้อมูลให้กับแบบจำลองมากขึ้นเท่าไร ชั้นแต่ละชั้นก็จะสามารถสกัดคุณลักษณะที่มีความซับซ้อนมากยิ่งขึ้น กระบวนการทำงานของการเรียนรู้เชิงลึก แบบจำลองที่ให้การเรียนรู้เชิงลึกให้ความแม่นยำที่สูงๆ ในหลายๆปัญหา ตั้งแต่การตรวจจับวัตถุไปจนถึงการจดจำเสียงพูด โดยเราไม่จำเป็นต้องให้ความรู้พื้นฐานใดๆกับแบบจำลองไว้ล่วงหน้า เพียงแค่ให้ข้อมูลตัวอย่าง แบบจำลองก็จะทำการเรียนรู้จากข้อมูลและสังเคราะห์เป็นองค์ความรู้ออกมาได้อย่างอัตโนมัติ



รูปที่ 2.20 กระบวนการทำงานของการเรียนรู้เชิงลึก [12]




รูปที่ 2.21 โครงสร้างของการเรียนรู้เชิงลึก [9]

การเรียนรู้มันเกิดขึ้นจาก 2 เฟส เฟสแรกคือการประยุกต์ใช้การเปลี่ยนแปลงแบบไม่เชิงเส้นกับข้อมูลที่ได้รับ ได้ผลลัพธ์ออกมาอยู่ในรูปของแบบจำลองทางสถิติ เฟสที่สองคือ การนำแบบจำลองมาผ่านวิธีการทางคณิตศาสตร์ อย่าง Derivative หรือ การดิฟ โดยทั้ง 2 เฟสนี้จะถูกทำซ้ำแล้วซ้ำเล่าจนกว่าจะได้แบบจำลองที่มีความแม่นยำในระดับที่น่าพึงพอใจ

Classification ของ Neural Network มีโครงข่ายประสาทเทียมแบบตื้น (Shallow neural network) มี Hidden layer แค่ 1 ชั้น แต่ยังมีชั้นอินพุต และชั้นเอาต์พุตเหมือนเดิม โครงข่ายประสาทเทียมแบบลึก มี Hidden Layer มากกว่า 1 ชั้น

ชนิดของโครงข่ายประสาทเทียมของการเรียนรู้เชิงลึก โครงข่ายประสาทแบบป้อนไปข้างหน้า คือเป็นแบบจำลองที่มีโครงสร้างเรียบง่ายที่สุด เพราะว่าการดำเนินการของข้อมูลจะเป็นไปในทิศทางเดียวกัน ก็คือรับข้อมูลจากอินพุตแล้วส่งต่อไปยังเอาต์พุตก็จะหยุด โครงข่ายประสาทเทียมแบบวนซ้ำ คือ neural network หลายๆชั้นที่สามารถเก็บข้อมูลไว้ที่โหนด จึงทำให้สามารถรับข้อมูลเป็นแบบลำดับ และให้ผลลัพธ์ออกเป็นลำดับของข้อมูลได้ ดังนั้นโครงข่ายประสาทเทียมแบบวนซ้ำจึงเหมาะสมในการประมวลผลข้อมูลที่เป็นลำดับ

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional neural network: CNN) คือ neural network หลายชั้นที่มีโครงสร้างเฉพาะตัว โดยถูกออกแบบมาเพื่อการเพิ่มความสามารถในการสกัดเอาคุณลักษณะที่มีความซับซ้อนมากยิ่งขึ้นจากข้อมูล CNN มักถูกใช้กับข้อมูลที่ไม่ค่อยเป็นระเบียบ ไม่มีโครงสร้างเป็นรูปแบบเฉพาะตัว เช่น รูปภาพ



รูปที่ 2.22 โครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน [10]

2.3.4 การวิเคราะห์ผลการทดลอง [13]

การทดลองเป็นวิธีดำเนินการอย่างเป็นระเบียบเพื่อพิสูจน์ยืนยันหักล้าง หรือสร้างความ สมเหตุสมผลหรือพัฒนาสิ่งใหม่ดังนั้นเครื่องมือที่จะนำมาวิเคราะห์ผลการทดลองจึงมีความ สำคัญ ในงาน วิจัยฉบับนี้ ผู้วิจัยได้เลือกเครื่องมือหรือหลักการที่จะนำมาวิเคราะห์ตาม รายละเอียดในข้อถัดไป

2.3.4.1 ค่าความแม่นยำ (Precision) [13]

ความสามารถของอุปกรณ์ที่จะอ่านค่าๆเดียวภายใต้สภาพการทำงานเดียวกัน ซ้ำกันหลายๆครั้งทำให้เราสามารถทราบความแม่นยำของอัลกอริทึมที่นำมาประยุกต์ใช้แสดงผลโดยค่า Standard Deviation การทดลองเป็นวิธีดำเนินการอย่างเป็นระเบียบเพื่อพิสูจน์ยืนยันหักล้าง หรือสร้างความสมเหตุสมผลหรือพัฒนาสิ่งใหม่ดังนั้นเครื่องมือที่จะนำมาวิเคราะห์ผลการทดลองจึงมีความสำคัญ ในงานวิจัยฉบับนี้ ผู้วิจัยได้เลือกเครื่องมือหรือหลักการที่จะนำมาวิเคราะห์ตามรายละเอียดในข้อถัดไป

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

2.3.4.2 ค่าความถูกต้อง (Accuracy) [13]

ผลการวิเคราะห์ที่มีค่าใกล้เคียงระหว่างค่าทดสอบกับค่าจริงแสดงในรูปของเปอร์เซ็นต์

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

2.3.4.3 ความไว (Recall) [13]

วัดความน่าจะเป็นที่โมเดลทำนายชนิดของโรคบนใบข้าวได้ถูกต้องกับความเป็นจริงกับโรคของใบข้าวที่นำมาใช้ในการวิเคราะห์

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

2.3.4.4 ความสามารถของโมเดล (F1-Score) [13]

เป็นค่าเฉลี่ยของความแม่นยำและการเรียกคืน ดังนั้นจึงสามารถแสดงทั้งความแม่นยำและการเรียกคืนค่าของ F-Score ที่เป็นไปได้สูงสุดคือ 1.0 ซึ่งแสดงความแม่นยำและการเรียกคืน ที่สมบูรณ์แบบและค่าต่ำที่สุดคือ 0 หากความแม่นยำหรือการเรียกคืนเป็นศูนย์

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

True Positive (TP) คือ สิ่งที่ระบบทำนายว่า จริงและมีค่าเป็นจริง

True Negative (TN) คือ สิ่งที่ระบบทำนายว่า ไม่จริงและมีค่าเป็นไม่จริง

False Positive (FP) คือ สิ่งที่ระบบทำนายว่า จริงแต่มีค่าเป็นไม่จริง

False Negative (FN) คือ สิ่งที่ระบบทำนายว่า ไม่จริงแต่มีค่าเป็นจริง



บทที่ 3

ขั้นตอนการทำวิจัย

ในบทนี้ ผู้วิจัยได้อธิบายโครงสร้างของแบบจำลองที่นำเสนอ รวมถึงขั้นตอนและวิธีการทดสอบประสิทธิภาพความถูกต้องของโมเดลกับชุดข้อมูลที่ได้จัดเตรียมไว้ โดยได้แบ่งหัวข้อในการทำวิจัยออกเป็นดังนี้ คือ 3.1 การจัดเตรียมชุดข้อมูลสำหรับการฝึกสอนและชุดข้อมูลสำหรับการตรวจสอบความถูกต้อง 3.2 การฝึกสอนแบบจำลองในปัจจุบัน 3.3 โครงสร้างของโมเดลที่นำเสนอในงานวิจัย และ 3.4 รายละเอียดของการดำเนินการทำวิจัยและการเก็บข้อมูลรวมถึงการบันทึกผลลัพธ์ในการศึกษาครั้งนี้

3.1 การจัดเตรียมชุดข้อมูลสำหรับการฝึกสอน

การจัดเตรียมชุดข้อมูลการฝึกสอนและชุดข้อมูลสำหรับการตรวจสอบความถูกต้อง โดยจัดเตรียมไว้ทั้งหมด 4 คลาสด้วยกันคือ โรคใบไหม้ โรคใบจุดสีน้ำตาล โรคใบขีดสีน้ำตาล และชนิดใบสุขภาพดี คือไม่เป็นโรคใดๆ โดยโรคใบจุดสีน้ำตาล และ โรคใบขีดสีน้ำตาลใช้เทคนิคการเพิ่มรูป เพื่อให้มีจำนวนเท่ากับคลาสนี้ โดยใช้คำสั่ง flip และ rotate บนโปรแกรม Jupyter Notebook และดาวน์โหลดชุดข้อมูลออกมาเก็บไว้ การแบ่งสัดส่วนของชุดข้อมูลฝึกสอน และ ชุดข้อมูลสำหรับการตรวจสอบความถูกต้อง โดยที่ใช้คือสัดส่วน 80:20 โดยชุดข้อมูลที่ใช้สำหรับการฝึกสอน คือ ร้อยละ 80 จากชุดข้อมูลทั้งหมด และ ชุดข้อมูลสำหรับการตรวจสอบความถูกต้อง อีกร้อยละ 20 จากชุดข้อมูลทั้งหมด โดยชุดข้อมูลทั้ง 2 นี้ได้ถูกแยกออกจากกัน แสดงปริมาณชุดข้อมูลดังตารางที่ 3.1 ด้านล่าง

ตารางที่ 3.1 แสดงจำนวนชุดข้อมูลในงานวิจัย

ชนิด	Train	Validation	Total
โรคใบไหม้	1,440	360	1,800
โรคใบจุดสีน้ำตาล	1,440	360	1,800
โรคใบขีดสีน้ำตาล	1,440	360	1,800
ใบสุขภาพดี	1,440	360	1,800

3.2 การฝึกสอนแบบจำลองในปัจจุบัน

การฝึกสอนแบบจำลองที่มีอยู่ในปัจจุบันโดยในงานวิจัยนี้เลือกมาจะมีทั้งหมด 5 แบบจำลอง คือ ResNet50, ResNet50V2, VGG16, VGG19 และแบบจำลองสุดท้ายคือ MobilenetV2 โดยแต่ละแบบจำลองมีค่าความถูกต้อง (Accuracy) ที่สูง โดยที่มากกว่าร้อยละ 90 ทุกแบบจำลองแสดงดัง

Model	Size (MB)	Top-1 Accuracy	Top-5 Accuracy	Parameters	Depth	Time (ms) per inference step (CPU)	Time (ms) per inference step (GPU)
VGG16	528	71.30%	90.10%	138.4M	16	69.5	4.2
VGG19	549	71.30%	90.00%	143.7M	19	84.8	4.4
ResNet50	98	74.90%	92.10%	25.6M	107	58.2	4.6
ResNet50V2	98	76.00%	93.00%	25.6M	103	45.6	4.4
MobileNetV2	14	71.30%	90.10%	3.5M	105	25.9	3.8


ตารางที่ 3.2 ด้านล่าง [14] โดยฝึกฝนกับชุดข้อมูลที่เตรียมไว้ในหัวข้อที่ 3.1

ตารางที่ 3.2 แสดงข้อมูลของแบบจำลองทั้ง 5 แบบ [14]


3.3 โครงสร้างของแบบจำลองที่นำเสนอ

ในงานวิจัยครั้งนี้ ผู้วิจัยได้กำหนดโครงสร้างของโมเดลที่นำเสนอโดยอาศัยโครงข่ายประสาทเทียม ใช้พื้นฐานของโมเดล DenseNet121 ต่อด้วยส่วนประกอบเพิ่มเติม โดยที่เลือกใช้โมเดล DenseNet121 เนื่องจากสถาปัตยกรรมของโมเดลนี้เป็นโครงข่ายประสาทเทียมที่ลึก ซึ่งใช้บล็อกหนาแน่นเพื่อเชื่อมต่อชั้นของโครงข่าย แต่ละบล็อกประกอบด้วยชั้น Bottleneck หลายชั้นที่เชื่อมต่อเข้าด้วยกันในรูปแบบการส่งข้อมูลเชิงเส้น โครงสร้างของโครงข่ายรับอาร์กิวเมนต์ที่ประกอบด้วย Block, nblock, Growth_rate, reduction และ num_class โดยอาร์กิวเมนต์ block ระบุประเภทของบล็อกที่จะใช้ในโครงข่าย อาร์กิวเมนต์ nblock เป็นรายการที่ระบุจำนวนบล็อกในแต่ละบล็อก อาร์กิวเมนต์ growth_rate ระบุจำนวนของแผนที่คุณลักษณะเอาต์พุตของแต่ละชั้นคอนโวลูชันในบล็อก อาร์กิวเมนต์ reduction ระบุตัวกระทำการบีบอัดของแต่ละชั้นการเปลี่ยนแปลง ในส่วนที่เพิ่มเติมจาก DenseNet121 คือ Dense Layer อีกจำนวน 3 ชุด และ BatchNormalization จำนวน

2 ชุด ในส่วนของ Dense Layer เป็นชั้นเชื่อมต่อแบบเต็ม (Fully Connected Layer) ที่มีจำนวน โหนด 256 โหนด จะมีการเชื่อมโยงกับโหนดทุกโหนดในชั้นก่อนหน้า โดยฟังก์ชันการกระตุ้นแบบ ReLU (Rectified Linear Activation) ที่ช่วยให้โมเดลเรียนรู้ได้ดีขึ้น และอีกชั้นของ Dense ต่างกัน ที่จำนวนโหนด และต่อด้วย Dropout เพื่อลดโอกาสการเกิด Overfitting และช่วยให้ Model มี ประสิทธิภาพมากขึ้นในการทำนายชุดข้อมูลที่ไม่เคยพบมาก่อน ชั้นสุดท้ายของ Dense คือชั้น เชื่อมต่อแบบเต็มสุดท้ายที่มีจำนวนโหนดเท่ากับจำนวนคลาสที่ต้องการจำแนก โดยใช้ Activation เป็น Softmax เพื่อทำนายความน่าจะเป็นในแต่ละคลาส ในส่วนของชั้น BatchNormalization เพิ่ม เข้าเพื่อปรับให้ Activation ที่อยู่ภายใน Hidden layer ของ Deep Neural Network ให้มีขนาด เหมาะสม เพื่อเพิ่มความเสถียรและประสิทธิภาพให้กับโมเดล



รูปที่ 3.1 โครงสร้างของโมเดล DenseNet121 [15]



รูปที่ 3.2 โครงสร้างของโมเดลที่นำเสนอในงานวิจัย

3.4 รายละเอียดของการดำเนินการทำวิจัยและการเก็บข้อมูล

งานวิจัยนี้ผู้วิจัยเลือกใช้ Python ในการพัฒนาแบบจำลองโดยอ้างอิงโครงสร้างพื้นฐานของ CNN โดยเลือกใช้ Jupyter notebook ในการพัฒนา ซึ่ง Jupyter notebook เป็นแอปพลิเคชันที่ใช้ในการสร้างและแชร์เอกสารที่มีโค้ดและข้อความรวมกันในรูปแบบที่เรียกว่า "notebook" ซึ่งสามารถทำงานได้ในเว็บเบราว์เซอร์ โดยสามารถรันโค้ด Python และภาษาโปรแกรมอื่น ๆ โดยเฉพาะได้ และแสดงผลลัพธ์ทันที นอกจากนี้ยังสามารถเขียนข้อความเสริม แสดงภาพ และการสร้างสมการทางคณิตศาสตร์ในเอกสารเดียวกันได้ โดยปกติ Jupyter Notebook ใช้งานในงานเกี่ยวกับการวิเคราะห์ข้อมูล, การเรียนรู้ของเครื่อง (Machine Learning), การวิเคราะห์ทางสถิติ, การวิเคราะห์ข้อความ และงานอื่น ๆ ที่ต้องการนำเสนอผลลัพธ์ที่สามารถติดตามการทำงานของโค้ดและการวิเคราะห์ที่ได้ในทีเดียว โดยผู้วิจัยใช้ Jupyter notebook บนคอมพิวเตอร์โน้ตบุ๊กที่มีสเปก CPU Intel Core i7-1165g7 ทำงานแบบ 4 คอร์ 8 เธรด GPU แบบ Geforce MX450 แรม 8GB DDR4 Bus 3200 MHz ความจุ 512GB ในเครื่องแรก และ CPU Intel Core i5-11400H Processor มี Graphic Card NVIDIA GeForce RTX™ 3060 6GB GDDR6 มี RAM 16 GB ในเครื่องที่ 2 เพื่อเป็นเครื่องมือที่ใช้ในการทำเคิณการทําวิจัย ในส่วนถัดไปผู้วิจัยอธิบายขั้นตอนการทําวิจัย โดยงานวิจัยนี้เริ่มจากขั้นตอนการเตรียมชุดข้อมูลที่ใช้สำหรับการฝึกฝน และแบ่งสัดส่วนของชุดข้อมูล ที่อัตราส่วนเท่ากับ 80:20 โดยที่ 80 คือชุดข้อมูลที่ใช้ในการฝึกฝน และอีก 20 คือชุดข้อมูลที่ใช้ในการตรวจสอบความถูกต้อง เมื่อจัดเตรียมชุดโดยแบ่งตามสัดส่วนเรียบร้อยแล้ว จึงนำชุดข้อมูลเข้าฝึกสอนในแบบจำลองที่มีอยู่ในปัจจุบันตามที่แสดงในหัวข้อที่ 3.2 โดยที่ทางผู้วิจัยเลือกการปรับ Epoch จาก 25 และ 50 ตามลำดับ ให้ผลลัพธ์ออกมาเป็นกราฟ ของชุดข้อมูลการฝึกฝน และการทำนายผลชุดข้อมูลสำหรับการตรวจสอบความถูกต้อง เพื่อวิเคราะห์ Trend ของกราฟทั้งในส่วนค่าของความถูกต้อง (Accuracy) และค่าความสูญเสีย (Loss) หลังจากที่แบบจำลองถูกฝึกฝนตามรอบต่างๆเสร็จจะเข้าสู่ขั้นตอนของการทำนายผลลัพธ์ โดยพิจารณาค่าความถูกต้อง (Accuracy) และค่า F1-score เมื่อเรียนรู้และวิเคราะห์กราฟของโมเดลที่มีอยู่ในปัจจุบันจบ ถัดมาจะเป็นในส่วนของการออกแบบโครงสร้างโมเดลที่นำเสนอในงานวิจัย เข้าสู่กระบวนการฝึกฝนตามรอบต่างๆ เพื่อวิเคราะห์ผลลัพธ์ของกราฟในส่วนของการฝึกฝนและการตรวจสอบความถูกต้อง แล้วบันทึกผลลัพธ์เช่นเดียวกับแบบจำลองที่มีอยู่ในปัจจุบัน

บทที่ 4

ผลการศึกษาและการอภิปรายผล


4.1 การบันทึกผลในชุดข้อมูลฝึกสอนและชุดข้อมูลการตรวจสอบความถูกต้องโดยกราฟ Train และ Validation

งานวิจัยนี้มุ่งเปรียบเทียบประสิทธิภาพโมเดล Convolutional Neural Networks (CNNs) ที่ใช้กันทั่วไปในปัจจุบัน ได้แก่ ResNet50, ResNet50V2, VGG16, VGG19, MobileNetV2, กับ โมเดล CNN ที่นำเสนอโดยผู้วิจัย โมเดลเหล่านี้ถูกนำมาใช้สำหรับการจำแนกชนิดของโรคบนใบข้าว จากการฝึกฝนที่ Epoch 25 และ 50 สามารถวิเคราะห์ประสิทธิภาพจากกราฟได้เป็น 2 ส่วนดังนี้คือการวิเคราะห์จากกราฟค่าความถูกต้อง (Accuracy) และการวิเคราะห์กราฟจากค่าความผิดพลาด (Loss)


โดยการวิเคราะห์กราฟค่าความถูกต้อง (Accuracy) ที่ Epoch เท่ากับ 25 ของโมเดล ResNet50: ค่าความถูกต้อง (Accuracy) ของชุดข้อมูลฝึกฝนและชุดข้อมูลตรวจสอบความถูกต้อง ขยับสูงขึ้นเมื่อรอบการฝึกฝนเพิ่มขึ้น โดยค่าอยู่ที่ประมาณร้อยละ 57 จากกราฟ และยังพบความไม่คงที่ในการฝึกฝน แสดงในรูปที่ 4.1 ถัดไปโมเดล ResNet50V2: ค่าความถูกต้อง (Accuracy) ของ ทั้ง 2 ชุดข้อมูลสูงขึ้นเมื่อรอบเพิ่มขึ้น ค่าอยู่ที่มากกว่าร้อยละ 85 จากรูปที่ 4.2 ในโมเดล VGG16: ค่าความถูกต้อง (Accuracy) ของทั้ง 2 ชุดข้อมูลค่อยๆสูงขึ้นเมื่อเข้าสู่รอบการฝึกฝนที่มากขึ้น โดยค่าจากกราฟมากกว่าร้อยละ 80 แสดงในรูปที่ 4.3 โมเดลต่อไป VGG19: ค่าความถูกต้อง (Accuracy) ของ ทั้ง 2 ชุดข้อมูลมีขยับสูงขึ้นเช่นเดียวกันเมื่อรอบการฝึกฝนเพิ่มขึ้น โดยค่าอยู่ที่ประมาณร้อยละ 75 จากภาพที่ 4.4 ในส่วนของโมเดล MobileNetV2: ค่าความถูกต้อง (Accuracy) ของชุดข้อมูลฝึกฝน ค่อนข้างสูงโดยอยู่ที่ร้อยละ 85 แต่ส่วนชุดข้อมูลตรวจสอบความถูกต้องพบความไม่คงที่ตลอดการฝึก และค่าความถูกต้อง (Accuracy) จากกราฟอยู่ที่ประมาณร้อยละ 80 แสดงในรูปที่ 4.5 และโมเดลสุดท้ายคือโมเดลที่นำเสนอในงานวิจัย: ค่าความถูกต้อง (Accuracy) ของทั้ง 2 ชุดข้อมูลค่อยๆเพิ่มขึ้น เมื่อเข้าสู่รอบการฝึกฝนที่มากขึ้น โดยค่าของชุดข้อมูลฝึกฝนอยู่ที่ประมาณร้อยละ 95 และค่าของชุดข้อมูลตรวจสอบความถูกต้องอยู่ที่ประมาณร้อยละ 90 แสดงในรูปที่ 4.6

การวิเคราะห์ค่ากราฟค่าความผิดพลาด (Loss) เริ่มที่โมเดล ResNet50 กราฟลดลงเมื่อรอบ เพิ่มขึ้น โดยค่าอยู่ที่ต่ำกว่า 1.5 ในช่วงสุดท้ายของการฝึก แสดงในรูปที่ 4.7 โมเดล ResNet50V2: ค่าความผิดพลาด (Loss) ในชุดข้อมูลฝึกฝนมีค่าต่ำ ในส่วนชุดข้อมูลตรวจสอบความถูกต้องกราฟยังคง ห่างจากชุดข้อมูลฝึกฝนอยู่ แสดงในรูปที่ 4.8 ถัดไปจะเป็นโมเดล VGG16 : ค่าความผิดพลาด (Loss) ในชุดข้อมูลฝึกฝนค่อยๆลดลงเมื่อเข้าสู่รอบการฝึกที่เพิ่มขึ้น ในส่วนของชุดข้อมูลตรวจสอบความถูกต้องกราฟลดลงเช่นเดียวกัน โดยค่าอยู่ที่มากกว่า 1.2 ในช่วงจบการฝึกฝน แสดงในรูปที่ 4.9 ใน


ส่วนของโมเดล VGG19: ค่าความผิดพลาด (Loss) ในชุดข้อมูลการฝึกฝนลดลงเมื่อเข้าสู่รอบการฝึกที่มากขึ้น ในส่วนชุดข้อมูลตรวจสอบความถูกต้องกราฟไม่คงที่โดยจบที่ค่าประมาณ 1.4 จากกราฟแสดงในรูปที่ 4.10 ถัดไปจะเป็นโมเดล MobileNetV2: ค่าความผิดพลาด (Loss) ของชุดข้อมูลการฝึกมีค่าต่ำ ส่วนชุดข้อมูลตรวจสอบความถูกต้องมีค่าไม่คงที่ตลอดการฝึกโดยจบอยู่ที่ค่าประมาณ 4 จากกราฟแสดงในรูปที่ 4.11 และโมเดลสุดท้ายคือโมเดลที่นำเสนอในงานวิจัย: ค่าความผิดพลาด (Loss) ในชุดข้อมูลฝึกฝนค่อยๆลดลงเมื่อรอบการฝึกเพิ่มขึ้น ในส่วนชุดข้อมูลตรวจสอบความถูกต้องลดลงเช่นเดียวกันเมื่อรอบเพิ่มขึ้นโดยค่าอยู่ที่ประมาณ 0.35 จากกราฟในช่วงจบของการฝึกฝน แสดงในรูปที่ 4.12




รูปที่ 4.1 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 25




รูปที่ 4.2 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 25




รูปที่ 4.3 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG16 ที่ Epoch เท่ากับ 25




รูปที่ 4.4 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG19 ที่ Epoch เท่ากับ 25




รูปที่ 4.5 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 25




รูปที่ 4.6 กราฟค่าความถูกต้อง (Accuracy) ของโมเดลที่นำเสนอ ที่ Epoch เท่ากับ 25




รูปที่ 4.7 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 25




รูปที่ 4.8 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 25




รูปที่ 4.9 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG16 ที่ Epoch เท่ากับ 25



รูปที่ 4.10 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG19 ที่ Epoch เท่ากับ 25



รูปที่ 4.11 กราฟค่าความผิดพลาด (Loss) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 25




รูปที่ 4.12 กราฟค่าความผิดพลาด (Loss) ของโมเดลที่นำเสนอ ที่ Epoch เท่ากับ 25


การวิเคราะห์กราฟ ที่ Epoch เท่ากับ 50 เริ่มที่กราฟค่าความถูกต้อง (Accuracy) โมเดล ResNet50: ค่าความถูกต้อง (Accuracy) ในชุดข้อมูลการฝึกฝนและชุดข้อมูลตรวจสอบความถูกต้อง กราฟสูงขึ้นเมื่อรอบเพิ่มขึ้นโดยจบอยู่ที่ประมาณร้อยละ 80 แสดงในรูปที่ 4.13 ถัดไปจะเป็นโมเดล ResNet50V2: ค่าความถูกต้อง (Accuracy) ในชุดข้อมูลการฝึกมีค่าสูงขึ้น แต่ยังไม่เท่ากับ ResNet50 และในส่วนชุดข้อมูลตรวจสอบความถูกต้องมีค่าไม่คงที่ แสดงในรูปที่ 4.14 โมเดล VGG16: ค่าความถูกต้อง (Accuracy) ในทั้ง 2 ชุดข้อมูลกราฟเพิ่มขึ้นเมื่อรอบการฝึกฝนเพิ่มขึ้น โดยจบอยู่ที่ประมาณร้อยละ 80 แสดงในรูปที่ 4.15 ต่อไปโมเดล VGG19: ค่าความถูกต้อง (Accuracy) ในทั้ง 2 ชุดข้อมูลกราฟเพิ่มขึ้นเมื่อรอบการฝึกฝนเพิ่ม โดยค่าในช่วงจบอยู่ที่ประมาณร้อยละ 80 จากกราฟ แสดงในรูปที่ 4.16 สำหรับโมเดล MobileNetV2: ค่าความถูกต้อง (Accuracy) ในชุดข้อมูลฝึกฝนค่อนข้างสูง ส่วนชุดข้อมูลตรวจสอบความถูกต้องค่าเพิ่มสูงขึ้นเมื่อรอบเพิ่มขึ้นโดยจบอยู่ที่ประมาณร้อยละ 80 แสดงในรูปที่ 4.17 โมเดลสุดท้ายคือโมเดลที่นำเสนอในงานวิจัย: ค่าความถูกต้อง (Accuracy) ใน 2 ชุดข้อมูลเพิ่มขึ้นเมื่อรอบการฝึกมากขึ้นโดยจบอยู่ที่มากกว่าร้อยละ 90 ทั้ง 2 ชุดข้อมูล แสดงในรูปที่ 4.18

การวิเคราะห์กราฟความผิดพลาด (Loss) เริ่มที่โมเดล ResNet50: ค่าความผิดพลาด (Loss) ของชุดข้อมูลการฝึกและชุดข้อมูลตรวจสอบความถูกต้องลดลงเมื่อรอบเพิ่ม โดยจบอยู่ที่ประมาณ 1.0


จากกราฟ แสดงในรูปที่ 4.19 ถัดไปโมเดล ResNet50V2: ค่าความผิดพลาด (Loss) ในทั้ง 2 ชุดข้อมูล มีค่าลดลงเมื่อรอบเพิ่มขึ้น แสดงในรูปที่ 4.20 ต่อไปโมเดล VGG16: ค่าความผิดพลาด (Loss) ของทั้ง 2 ชุดข้อมูลลดลง โดยจบอยู่ที่ค่าน้อยกว่า 1 แสดงในรูปที่ 4.21 โมเดล VGG19: ค่าความผิดพลาด (Loss) ลดลงเช่นเดียวกับโมเดลอื่นๆ โดยช่วงจบของชุดข้อมูลตรวจสอบความถูกต้องค่าอยู่ที่ประมาณ 1 แสดงในรูปที่ 4.22 โมเดล MobileNetV2: ค่าความผิดพลาด (Loss) ของชุดข้อมูลการฝึกกราฟลดลง แต่ชุดข้อมูลการตรวจสอบความถูกต้องกราฟเพิ่มขึ้นเมื่อรอบเพิ่ม โดยค่าในช่วงจบอยู่ที่ประมาณ 5 จากกราฟแสดงในรูปที่ 4.23 โมเดลสุดท้ายคือโมเดลที่นำเสนอในงานวิจัย: ค่าความผิดพลาด (Loss) ในชุดข้อมูลฝึกฝนลดลงเมื่อรอบมากขึ้น และในชุดข้อมูลตรวจสอบความถูกต้องค่าลดลงเช่นเดียวกันโดยค่าในช่วงจบอยู่ที่ประมาณ 0.3 จากกราฟ แสดงในรูปที่ 4.24




รูปที่ 4.13 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 50




รูปที่ 4.14 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 50




รูปที่ 4.15 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG16 ที่ Epoch เท่ากับ 50




รูปที่ 4.16 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล VGG19 ที่ Epoch เท่ากับ 50




รูปที่ 4.17 กราฟค่าความถูกต้อง (Accuracy) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 50




รูปที่ 4.18 กราฟค่าความถูกต้อง (Accuracy) ของโมเดลที่นำเสนอในงานวิจัย ที่ Epoch เท่ากับ 50




รูปที่ 4.19 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50 ที่ Epoch เท่ากับ 50




รูปที่ 4.20 กราฟค่าความผิดพลาด (Loss) ของโมเดล ResNet50V2 ที่ Epoch เท่ากับ 50




รูปที่ 4.21 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG16 ที่ Epoch เท่ากับ 50



รูปที่ 4.22 กราฟค่าความผิดพลาด (Loss) ของโมเดล VGG19 ที่ Epoch เท่ากับ 50




รูปที่ 4.23 กราฟค่าความผิดพลาด (Loss) ของโมเดล MobileNetV2 ที่ Epoch เท่ากับ 50




รูปที่ 4.24 กราฟค่าความผิดพลาด (Loss) ของโมเดลที่นำเสนอในงานวิจัย ที่ Epoch เท่ากับ 50

4.2 การประเมินโมเดลเพื่อทดสอบการนำไปใช้งานจริงด้วยชุดข้อมูลทดสอบ


งานวิจัยนี้นำชุดข้อมูลรูปภาพทั้ง 4 คลาส คือโรคใบไหม้ ใบจุดสีน้ำตาล ใบขีดสีน้ำตาล และชนิดใบสุขภาพดี ของชุดข้อมูลการฝึกฝนและชุดข้อมูลการตรวจสอบความถูกต้องโดยรูปภาพทั้ง 2 ชุดข้อมูลไม่เหมือนกัน ใช้อัตราส่วนอยู่ที่ 80:20 สรุปการทำนายโดยใช้ตาราง Confusion Matrix โดยข้อมูลในตารางมาจากการฝึกฝนที่ Epoch เท่ากับ 50 และค่าความถูกต้อง (Accuracy) โดยที่โมเดล ResNet50 ทำนายโรคชนิดใบไหม้ถูกมากที่สุดจากทั้งหมด 4 ชนิด แสดงในรูปที่ 4.25 โมเดล ResNet50V2 ทำนายชนิดใบสุขภาพดีถูกต้องมากกว่าชนิดอื่นๆ แสดงในรูปที่ 4.26 ถัดไปโมเดล VGG16 ทำนายชนิดใบไหม้ถูกต้องมากกว่าชนิดอื่น แสดงในรูปที่ 4.27 โมเดล VGG19 ทำนายชนิดใบสุขภาพดีถูกต้องมากกว่าการทำนายในชนิดอื่นๆ แสดงในรูปที่ 4.28 ถัดไปในส่วนของโมเดล MobileNetV2 ทำนายได้ถูกต้องในชนิดใบสุขภาพดี แสดงในรูปที่ 4.29 และโมเดลสุดท้ายคือโมเดลที่นำเสนอในงานวิจัย ทำนายได้ถูกต้องมากในชนิดใบขีดสีน้ำตาล แสดงในรูปที่ 4.30




รูปที่ 4.25 ตาราง Confusion Matrix ของ โมเดล ResNet50




รูปที่ 4.26 ตาราง Confusion Matrix ของ โมเดล ResNet50V2




รูปที่ 4.27 ตาราง Confusion Matrix ของ โมเดล VGG16



รูปที่ 4.28 ตาราง Confusion Matrix ของ โมเดล VGG19




รูปที่ 4.29 ตาราง Confusion Matrix ของ โมเดล MobileNetV2



รูปที่ 4.30 ตาราง Confusion Matrix ของ โมเดลที่นำเสนอในงานวิจัย

จากกราฟแสดงค่าความถูกต้อง (Accuracy) ในรูปที่ 4.31 จากการฝึกฝนโมเดลที่ Epoch เท่ากับ 25 และ 50 โดยพบว่าโมเดล ResNet50 ค่าความถูกต้องเพิ่มขึ้นจาก Epoch 25 มาอยู่ที่ร้อยละ 80.66 ในที่ epoch เท่ากับ 50 สำหรับโมเดล ResNet50V2 ค่าความถูกต้องลดลงเมื่อ Epoch เพิ่มขึ้นโดยจบอยู่ที่ร้อยละ 64.84 โมเดล VGG16, VGG19 และ MobileNetV2 ค่าความถูกต้อง (Accuracy) เพิ่มขึ้น เมื่อรอบการฝึกเพิ่ม โดยค่าอยู่ที่ร้อยละ 80.47, 75.59 และ 74.80 ตามลำดับ โมเดลที่นำเสนอในงานวิจัยค่าความถูกต้อง (Accuracy) เพิ่มขึ้นเช่นเดียวกับโมเดลอื่นๆ โดยค่าอยู่ที่ร้อยละ 91.02 ในรอบที่ Epoch เท่ากับ 50 ซึ่งสูงกว่าโมเดลอื่นๆที่นำมาทดลองในงานวิจัยครั้งนี้ แสดงในรูปที่ 4.31



รูปที่ 4.31 กราฟสรุปค่าความถูกต้อง (Accuracy) ของโมเดล ResNet50, ResNet50V2, VGG16, VGG19, MobileNetV2 และโมเดลที่นำเสนอในงานวิจัย

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผล

จากงานวิจัยนี้ได้มุ่งเน้นไปที่การคัดแยกชนิดของโรคบนใบข้าว ในขั้นตอนการทดสอบโมเดล จะมีภาพที่ไม่อยู่รวมกับขั้นตอนการฝึกฝน รูปภาพชนิดของโรคบนใบข้าวจะแบ่งเป็นจำนวน 4 ชนิด คือโรคใบไหม้ ใบขีดสีน้ำตาล ใบจุดสีน้ำตาล และใบสุขภาพดี ที่ใช้ในการฝึกฝนแบบจำลอง โดยผู้วิจัยได้ทำการทดลองผ่านโครงข่ายประสาทเทียมแบบคอนโวลูชัน เข้ามาสร้างแบบโมเดลเพื่อให้โมเดลนี้สามารถจำแนกชนิดของโรคบนใบข้าวได้ ชุดข้อมูลรูปภาพถูกทำให้มีขนาดเท่ากันโดยใช้วิธีการหมุนภาพที่องศาต่างๆ ผู้วิจัยฝึกฝนโมเดลโดยเน้นจุดที่น่าสนใจ โดยใช้พื้นฐานโมเดลของ DenseNet121 และนำมาเพิ่ม Dense Layer และชั้น Batch Normalization เพื่อให้โมเดลเรียนรู้และโฟกัสที่ลักษณะที่สำคัญของภาพเพิ่มขึ้น โดยเชื่อมต่อกันในชั้นแต่ละชั้นของโมเดล ซึ่งเป็นส่วนของการทำนายผลลัพธ์ในภายหลัง การโฟกัสที่พื้นที่รูปภาพ มักจะมีประสิทธิภาพในการแยกแยะวัตถุหรือลักษณะที่สำคัญในรูปภาพ จึงทำให้โมเดลได้เรียนรู้ และสร้างลักษณะเชิงลึกในข้อมูลเหล่านี้ได้ดี และมี Pooling layer เพื่อลดความซับซ้อนของข้อมูล โดยผู้วิจัยสรุปผลการทดลองโดยใช้ค่าความถูกต้อง (Accuracy) โมเดลที่นำเสนอในงานวิจัยมีค่าสูงถึงร้อยละ 91.02

5.2 ข้อเสนอแนะ

5.2.1 การเพิ่มประสิทธิภาพของโมเดลโดยการเพิ่มข้อมูลการฝึกฝนสามารถช่วยให้โมเดลมีประสิทธิภาพมากขึ้น โดยเพิ่มรูปภาพของโรคใบข้าวในเงื่อนไขสภาพแวดล้อมที่หลากหลาย เช่น แสงสว่างต่าง ๆ หรือการเปลี่ยนแปลงของเงื่อนไขอากาศ เพื่อเพิ่มความสามารถในการจำแนกโรคใบข้าวในสภาพสิ่งแวดล้อมที่หลากหลาย

5.2.2 การปรับพารามิเตอร์ของโมเดลหรือการเปลี่ยนแปลงโครงสร้างของโมเดลเองอาจช่วยเพิ่มประสิทธิภาพของการจำแนกโรคใบข้าวได้ เช่น การเพิ่มหรือลดจำนวนชั้น Convolutional Layer, การใช้ Dropout เพื่อลด Overfitting, หรือการใช้ Batch Normalization เพื่อเพิ่มความเร็วในการฝึกฝน

5.2.3 การปรับปรุงข้อมูลก่อนนำเข้าโมเดลอาจช่วยเพิ่มประสิทธิภาพของโมเดล โดยการใช้เทคนิคเช่น Data Augmentation เพื่อสร้างข้อมูลเสริมในกรณีที่ข้อมูลไม่เพียงพอ

5.2.4 งานวิจัยนี้สามารถนำไปต่อยอดโดยทำเป็นแอปพลิเคชัน เพื่อให้ผู้ใช้งานสามารถใช้ได้สะดวก เนื่องจากงานวิจัยในปัจจุบันเป็นการถ่ายรูปแบบ และนำรูปภาพเข้าสู่คอมพิวเตอร์ และเข้า Program สำหรับการใช้ Python หลังจากนั้นจึงสามารถนำข้อมูลเข้ามาทำนาย

บรรณานุกรม



บรรณานุกรม

- [1] R. Deng et al., “Automatic diagnosis of rice diseases using deep learning,” *Frontiers in Plant Science Journal*, vol. 12, no. 1, pp. 1-15, August 2021.
- [2] S. V. Vasantha et al., “Techniques for rice leaf disease detection using machine learning algorithms,” *International Journal of Engineering Research and Technology (IJERT) ICACT – 2021*, vol. 9, no. 8, pp.162-166, June 2021.
- [3] T.Daniya and S.Vigneshwari, “A review on machine learning techniques for rice plant disease detection in agricultural research,” *International Journal of Advanced Science and Technology*, vol. 28, no. 13, pp. 49-62, October 2019.
- [4] M. A. Islam et al., “An automated convolutional neural network based approach for paddy leaf disease detection,” *International Journal of Advanced Computer Science and Applications*, vol. 12, no. 1, pp. 280-288, January 2021.
- [5] G. Latif et al., “Deep learning utilization in agriculture: Detection of rice plant diseases using an improved CNN model,” *MDPI Plants Journal*, vol. 11, no. 17, pp.2230, August 2022.
- [6] ดารา เจตนะจิตร และคณะ, *โรคข้าวและการป้องกันกำจัด*, กรุงเทพฯ: สำนักวิจัยและพัฒนาข้าว กรมการข้าว, 2550.
- [7] Apple, “Algorithm,” [Online]. Available: <https://en.wikipedia.org/wiki/Algorithm>. [Accessed: August 19, 2023].
- [8] Apple, “อะไรคือ การเรียนรู้ของเครื่อง (Machine Learning)? (ฉบับมือใหม่),” สมาคมโปรแกรมเมอร์ไทย [Online]. Available: <https://www.thaiprogrammer.org/2018/12/อะไรคือ-การเรียนรู้ของเครื่อง/>. [Accessed: 19 สิงหาคม 2566].
- [9] Mr.P L, “Deep Learning แบบฉบับคนสามัญ EP 1 : Neural Network History,” medium.com [Online]. Available: <https://medium.com/mmp-li/deep-learning-ep-1-neural-network-history-f7789236a9a3>. [Accessed: 19 สิงหาคม 2566].
- [10] Apple, “การเรียนรู้เชิงลึก,” สมาคมโปรแกรมเมอร์ไทย [Online]. Available: <https://www.thaiprogrammer.org/2018/12/deep-learning>. [Accessed: 19 สิงหาคม 2566].

- [11] Apple, “*What is Deep Learning?*,” oracle.com [Online]. Available: <https://www.oracle.com/th/artificial-intelligence/machine-learning/what-is-deep-learning/>. [Accessed: 19 สิงหาคม 2566].
- [12] Apple, “*What is Deep Learning?*,” Logimojo.com [Online]. Available: <https://logicmojo.com/what-is-deep-learning>. [Accessed: August 19, 2023].
- [13] Apple, “*ทำความเข้าใจ Accuracy, Precision, Recall, f1-Score*,” [Online]. Available: <https://www.ninenox.com/2020/09/24-accuracyprecisionrecallf1-score/>. [Accessed: 19 สิงหาคม 2566].
- [14] Apple, “*Keras Applications*,” [Online]. Available: <https://keras.io/api/applications>. [Accessed: Aug. 19, 2023].
- [15] Apple, “*รายละเอียดโมเดล DenseNet121, Implementing DenseNet-121 in Pytorch: A Step-by-Step Guide*,” medium.com [Online]. Available: <https://medium.com/deepkapha-notes/implementing-densenet-121-in-pytorch-a-step-by-step-guide-c0c2625c2a60>. [Accessed: August 19, 2023].
- [16] พันธิตา วานิช และ อัดนา เซนโตะ, “*การตรวจจับโรคของใบข้าวโดยใช้ Deep Learning*,” [Online]. Available: <https://tniac.tni.ac.th/>. [Accessed: 29 เมษายน 2564].





ภาคผนวก

TNI



ตารางที่ ก.1 คำสั่งสำหรับการสอนแบบจำลองการตรวจจับโรคของใบข้าวโดยใช้ Deep Learning

ชุดคำสั่ง
<pre> # Importing Libraries %matplotlib inline import os import glob import pathlib import itertools import requests import datetime import numpy as np import pandas as pd import tensorflow as tf import seaborn as sns import matplotlib.image as mpimg import matplotlib.pyplot as plt from struct import unpack from keras import Sequential from sklearn.utils.multiclass import unique_labels from sklearn.metrics import confusion_matrix, classification_report from sklearn.model_selection import train_test_split from keras.preprocessing.image import ImageDataGenerator from keras.layers import Flatten, Dense, BatchNormalization, Activation, Dropout from tensorflow.keras.optimizers import Adam, SGD # ----- Deep Learning model ----- from tensorflow.keras.applications.resnet50 import ResNet50 from tensorflow.keras.applications.resnet_v2 import ResNet50V2 from tensorflow.keras.applications.vgg16 import VGG16 </pre>

```
from tensorflow.keras.applications.vgg19 import VGG19
from tensorflow.keras.applications.mobilenet_v2 import MobileNetV2
from tensorflow.keras.applications.xception import Xception
from tensorflow.keras.applications import EfficientNetB4
from tensorflow.keras.applications import DenseNet121
tf.__version__

data_dir = "./new_datasets2/train2"
data_dir_val = './new_datasets2/test'

IMAGE_SIZE = [256, 256]
SEED = 42
CLASSES = 4
BATCH_SIZE = 50

train_datagen = ImageDataGenerator(
    rescale = 1./255,
    rotation_range=30,
    width_shift_range=0.2,
    height_shift_range=0.2,
    shear_range=0.2,
    zoom_range=0.2,
    horizontal_flip=True,
    vertical_flip=True)

test_datagen = ImageDataGenerator(rescale = 1./255)
val_datagen = ImageDataGenerator(rescale = 1./255)

train_generator = train_datagen.flow_from_directory(data_dir ,
    class_mode='categorical',
    batch_size = 32,
```

```

target_size = (256, 256),
    )

test_generator = test_datagen.flow_from_directory(data_dir_val,
    class_mode='categorical',
    batch_size = 32,
    target_size = (256, 256),shuffle=False)

val_generator= val_datagen.flow_from_directory(data_dir,
    class_mode='categorical',
    batch_size = 32,
    target_size = (256, 256),
    shuffle = False
    )

MODELS = [MobileNetV2]
model_name = 'model_totraining_inLoop'
model_ = ['MobileNetV2']

for i in range(0,len(MODELS),1):
    model_name = model_[i]
    print(model_name)
    base_model = MODELS[i](include_top=False, weights="imagenet",
    input_shape=(IMAGE_SIZE[0],IMAGE_SIZE[1],3))
    base_model.trainable = False
    model= Sequential()
    model.add(base_model)
    model.add(BatchNormalization())
    model.add(Flatten())
    if model_name != 'ProposedModel':
        model.add(Dense(CLASSES,activation=('softmax'))))

```

```

else:
    model.add(Dense(256,activation=('relu')))
    model.add(BatchNormalization())
    model.add(Dense(64,activation=('relu')))
    model.add(BatchNormalization())
    model.add(Dropout(.2))
    model.add(Dense(CLASSES,activation=('softmax')))

model.summary()

EPOCHS = 50
INIT_LR = 0.001
opt = Adam(learning_rate=INIT_LR, decay=INIT_LR / EPOCHS)
model.compile(loss="categorical_crossentropy", optimizer=opt,metrics=["accuracy"])

history = model.fit(
    train_generator,
    epochs = EPOCHS,
    steps_per_epoch = train_generator.samples//BATCH_SIZE,
    validation_data = test_generator,
    validation_steps = test_generator.samples//BATCH_SIZE,
    verbose = 1
)
now = datetime.datetime.now()
custom_format = now.strftime("%Y-%m-%d__%H-%M")

plt.figure(0)
plt.plot(history.history['accuracy'], label='accuracy')
plt.plot(history.history['val_accuracy'], label='val_accuracy')
plt.xlabel('Epoch')
plt.ylabel('Accuracy')

```

```

plt.title(f'{model_name}_{EPOCHS}_Accuracy')
plt.legend()
plt.savefig(f'./graph/{model_name}_custom_format_accuracy.png')
plt.show()

plt.figure(1)
plt.plot(history.history['loss'], label='loss')
plt.plot(history.history['val_loss'], label='val_loss')
plt.xlabel('Epoch')
plt.ylabel('Loss')
plt.title(f'{model_name}_{EPOCHS}_Loss')
plt.legend()
plt.savefig(f'./graph/{model_name}_custom_format_loss.png')
plt.show()

test_score = model.evaluate_generator(test_generator, BATCH_SIZE)
print("[INFO] accuracy: {:.2f}%".format(test_score[1] * 100))
print("[INFO] Loss: ",test_score[0])

if not os.path.exists('acc_evaluate'):
    os.makedirs('acc_evaluate')

custom_format1 = now.strftime("%Y-%m-%d__")
file_path = f'./acc_evaluate/acc-{custom_format1}.csv'

if not os.path.exists('acc_evaluate'):
    os.makedirs('acc_evaluate')

custom_format1 = now.strftime("%Y-%m-%d__")
file_path = f'./acc_evaluate/acc-{custom_format1}.csv'
if not os.path.exists(file_path):

```

```

with open(file_path, 'w') as f:
    f.write('Date,Model,Accuracy,loss,Epoch\n')

Model = model_name
Accuracy = test_score[1] * 100
Loss = test_score[0]
Epoch = EPOCHS
Date = now.strftime("%Y-%m-%d__%H-")
df = pd.DataFrame(columns=['Date', 'Model', 'Accuracy', 'Loss', 'Epoch'])
if os.path.exists(file_path):
    df = pd.read_csv(file_path)
    if Model in df['Model'].values:
        # Find the index of the existing model
        index = df[df['Model'] == Model].index[0]
        # Update the existing row with new data
        df.loc[index] = [Date, Model, Accuracy, Loss, Epoch]
    else:
        new_data = pd.DataFrame({'Date': [Date], 'Model': [Model], 'Accuracy':
            [Accuracy], 'Loss': [Loss], 'Epoch': [Epoch]})
        df = df.append(new_data, ignore_index=True)
        df.to_csv(file_path, mode='a', header=False, index=False)
print(df)

def plot_confusion_matrix(cm, classes, normalize=True, title='Confusion matrix',
    cmap=plt.cm.Blues):
    """
    This function prints and plots the confusion matrix.
    Normalization can be applied by setting `normalize=True`.
    """
    plt.figure(figsize=(15,15))
    plt.imshow(cm, interpolation='nearest', cmap=cmap)
    plt.title(title)

```

```

plt.colorbar()

tick_marks = np.arange(len(classes))
plt.xticks(tick_marks, classes, rotation=45)
plt.yticks(tick_marks, classes)

if normalize:
    cm = cm.astype('float') / cm.sum(axis=1)[:, np.newaxis]
    cm = np.around(cm, decimals=2)
    cm[np.isnan(cm)] = 0.0
    print("Normalized confusion matrix")
else:
    print('Confusion matrix, without normalization')

thresh = cm.max() / 2.
for i, j in itertools.product(range(cm.shape[0]), range(cm.shape[1])):
    plt.text(j, i, cm[i, j],
             horizontalalignment="center",
             color="white" if cm[i, j] > thresh else "black")

plt.tight_layout()
plt.ylabel('True label')
plt.xlabel('Predicted label')
cm_data = target_names = []

for key in train_generator.class_indices:
    target_names.append(key)

print(target_names)
Y_pred = model.predict(test_generator)
y_pred = np.argmax(Y_pred, axis=1)

```


```
print('Confusion Matrix')

cm = confusion_matrix(test_generator.classes, y_pred)
plot_confusion_matrix(cm, target_names, title='Confusion Matrix', normalize=False)

plt.savefig(f'./confusionmatrix/{model_name}_{custom_format}_cm.png')

model.save(f'./trained_model/{model_name}_{custom_format}_{EPOCHS}_epoch.hdf5")

model.save(f'./trained_model/{model_name}_{custom_format}_{EPOCHS}_epoch.h5")
model.save(f'./trained_model/{model_name}_{custom_format}_{EPOCHS}_epoch.hdf5")
model.save(f'./trained_model/{model_name}_{custom_format}_{EPOCHS}_epoch.h5")
```



ภาคผนวก ข.
บทความการประชุมวิชาการ



การตรวจจับโรคของใบข้าวโดยใช้ Deep Learning Rice Leaf Diseases Detection by Deep Learning

พัฒนวิศา วาณิช

วิศวกรรมศาสตรบัณฑิต สาขา เทคโนโลยีวิศวกรรม

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

กรุงเทพมหานคร

Va.phannisa_s@thai.ac.th

ดร. อัดนา เชนใต้

คณะวิศวกรรมศาสตร์ | วศ.บ. วิศวกรรมคอมพิวเตอร์และ

ปัญญาประดิษฐ์ (CE) ผู้อำนวยการหลักสูตรเทคโนโลยีวิศวกรรม

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

กรุงเทพมหานคร

adna@thai.ac.th

บทคัดย่อ – งานวิจัยฉบับนี้นำเสนอเกี่ยวกับการตรวจจับโรคของโรคบนใบข้าว จำแนกทั้งหมดจำนวน 3 ชนิดมี โรคใบไหม้ ใบจุดสีน้ำตาล และใบขีดสีน้ำตาล โดยใช้ Deep Learning การนำ Model Deep learning ตรวจจับเป็นวิธีที่มีประสิทธิภาพสูงในการวิเคราะห์ภาพและจำแนกข้อมูลซับซ้อน โดยผู้วิจัยเก็บรวบรวมตัวอย่างรูปภาพของโรคข้าวเป็นที่จะต้องมีการจำแนกประเภทแต่ละชนิดจำนวน 500 รูปขึ้นไป เพื่อให้ระบบมีความแม่นยำเพิ่มขึ้น ผู้วิจัยทดลองให้ระบบระบุชนิดของโรคบนใบข้าวผ่าน Model ResNET 50, Model อื่นๆ และ Model ของผู้วิจัย โดยที่ผู้วิจัยเลือกการจำแนกชนิดของโรคที่พบในใบแล้วเพื่อให้เป็นประโยชน์กับการเกษตร ให้สามารถจำแนกชนิดของโรคได้ชัดเจนเพื่อให้สามารถแก้ไขได้ถูกต้อง ลดความสูญเสียในกระบวนการผลิตพันธุ์ข้าวในแปลงนา ซึ่ง Model ที่ผู้วิจัยประยุกต์ใช้เพื่อให้มีความแม่นยำที่สูง ความแม่นยำอยู่ที่ 98.4%

การตรวจจับชนิดของโรคบนใบข้าว, ประสิทธิภาพสูง, จำแนกข้อมูลซับซ้อน

This research presents the detection and classification of rice leaf diseases, encompassing three types: blast disease, brown spot, and brown streaks. Deep Learning, utilizing models for detection, proves to be a highly efficient method for image analysis and complex data classification. The researchers collected a dataset of disease images, requiring a minimum of 500 images for each disease type to enhance the system's accuracy.

The researchers experimented with the system's disease classification using the ResNet 50 model, other models, and their own developed model. The researchers specifically chose to classify plant diseases on rice leaves to benefit agriculture. The clear classification of disease types aims to facilitate accurate corrections, reduce losses in the production process, and lower costs in each rice cultivation cycle. The accuracy of the researcher's model is reported to be at XX%.

detection and classification of rice leaf diseases, highly efficient method, and complex data classification

1. บทนำ

ข้าวเป็นผลผลิตทางการเกษตรที่สำคัญของประเทศไทย มีการส่งออก และยังเป็นอาหารหลักของคนไทยอีกด้วย เกษตรกรที่หา

การเกษตรเกี่ยวกับข้าว พบปัญหาแมลงและศัตรูพืชซึ่งสร้างความเสียหายต่อผลผลิตทางการเกษตร หากเกษตรกรตรวจพบด้งข้าว หรือตรวจพบแล้ว ไม่สามารถระบุได้ชัดเจนว่าสิ่งที่เป็นศัตรูพืชชนิดใด จะส่งผลต่อการแก้ไขที่ล่าช้า หรืออาจจะผิดพลาด เมื่อพบเหตุดังกล่าว ส่งผลต่อต้นทุนที่เกษตรกรนำมาใช้เพื่อกำจัดแมลงและศัตรูพืชสูงขึ้น อีกทั้งผลผลิตทางการเกษตรก็ลดลงตามไปด้วย ยังช่วยให้ผู้เริ่มทำเกษตรใหม่ๆ สามารถระบุชนิด และจัดการแก้ไขได้ถูกต้อง ผู้วิจัยจึงเลือกทำวิจัยเรื่องการตรวจจับโรคของใบข้าวโดยใช้ Deep Learning เนื่องจาก Deep Learning เป็นวิธีที่มีประสิทธิภาพสูง สามารถจำแนกข้อมูลที่ซับซ้อนได้

ก่อนหน้านี้มีทีมวิจัยต่างๆ ได้ทดลองนำข้อมูลรูปภาพ Training ระบบและตรวจหอบ ได้แก่ทีม [1] คุณ Ruoling Deng, Ming Tao, Hang Xing, Xuji Yang, Chuang Liu และ Kai Feng Luo โดยใช้ข้อมูลรูปภาพจำนวน 33,028 รูป แบ่งภาพจำแนกออกเป็น 6 ชนิด คือ โรคใบไหม้, false smut, โรคลำคอแตก, โรคกล้าเน่าจากการมีสปากติ, โรคแฉกเขี้ยวแบบถี่เรียว, และโรคจุดสีน้ำตาล โดยใช้ Deep Learning ผลที่ดีที่สุด 3 Model คือ DenseNet-121, SE-ResNet-50, และ ResNeSt-50 โดยผลความแม่นยำทั่วไปคือ 91 % [2] Dr. Sandhya Venu Vasanth, Dr. Bejiam Kiranmai และ Dr. S. Rama Krishna โดยทีมวิจัยเปรียบเทียบ Model ต่างๆ โดยอ้างอิงจากงานวิจัยอื่น ที่ใช้ Deep feature based SVM, Deep CNN, SVM-SFFS, CNN model with high level fusion, CNN with SVM, Extreme gradient boosting(XGBoost), Probabilistic Neural Network(PNN), AlexNet neural network, Decision Tree[48], Deep_Transfer Learning, ANN, Faster_RCNN, Minimum Distance Classifier(MDC) และ Deep Neural Network, Jaya Optimization Algorithm(DNN_JOA) ทีมวิจัยพบว่าวิธี Deep Learning ด้วย CNN และรูปแบบอื่นๆ เช่น deep_CNN, CNN_SVM, CNN_High level Fusion, CNN_Transfer Learning, Faster_RCNN มีประสิทธิภาพดีกว่าจากมุมมองของความแม่นยำในการทดสอบและนอกจากนี้ยังสังเกตเห็นว่าเทคนิคพื้นฐานของ Machine Learning, Decision Tree มีประสิทธิภาพดีกว่าด้วยความแม่นยำที่ 0.97 ในการตรวจจับโรค LS, BLB, และ BS เทคนิคของ Deep CNN และ Deep_Transfer Learning มีความแม่นยำมากที่สุดคือ 0.95 และ 0.98 ตามลำดับ เทคนิค Deep featurebased SVM มี F1-Score ดีกว่าแบบอื่นๆ คือ 0.98 [3] T.Daniya และ Dr.S.Vigneshwari เปรียบเทียบ

เทคนิคที่นำมาใช้จำแนกชนิดของโรคบนใบข้าวทั้งหมด 11 Model โดยจะมี Neuro-Fuzzy expert system, PCA, Color Grid-centered Moment and GLCM for feature extorion and SVM for classification, Deep CNNcentered classification, R-FNN, RCNN, SSD, SVM classifier, ESforRPD2 application, Unified Modelling Language and Waterfall Paradigm, Radial basis function network (RBFN) model, PCA and NN, PSO – centered incremental, Hyperspectral data, A visual method based on PdNPs catalyzed TMB/H₂O₂ system จาก Model ที่กล่าวมาข้างต้นนั้นที่มีวิจัยสรุปผลได้ว่า วิธีการอื่น ๆ ที่ใช้ในการรู้จำโรคข้าว มีการใช้เทคนิค ML หลายแบบเพื่อรู้จำโรคข้าวหลายประเภท ตัวจัดประเภทที่ใช้ NN ได้รับความนิยมที่ต่ำกว่าเมื่อเทียบกับเทคนิคอื่น ตัวจัดประเภท NN ได้รับความนิยมสูงสุด (95.8%), ในขณะที่โมเดล RBFN ได้รับความนิยมต่ำระดับ 95.5% ส่วนการจัดประเภท SVM ได้รับความนิยมต่ำที่สุดเมื่อเทียบกับทุกเทคนิคอื่น ๆ [4] Md. Ashiqul Islam, Md. Nymur Rahman Shuvo, Muhammad Shamsujjaman, Shazid Hasan, Md. Shahadat Hossain และ Tania Khatun งานวิจัยนี้คือการให้ผลลัพธ์ที่ดีที่สุดสำหรับการตรวจค้นโรคใบข้าวผ่านวิธีการตรวจค้นอัตโนมัติด้วยโมเดล CNN ที่ใช้เทคนิค Deep Learning ที่สามารถบ่งชี้ความแม่นยำสูงสุด เมื่อเปรียบเทียบกับกระบวนการตรวจค้นโรคแบบด้วยมือที่ยาวนานที่แม่นยำไม่น่าเชื่อถือมากนัก ที่มีวิจัยได้ทดสอบ 4 โมเดลได้แก่ VGG-19, Inception-Resnet-V2, ResNet-101, Xception และ ได้รับความนิยมมากที่สุดจาก Inception-ResNet-V2 ที่ 92.88% [5] Ghazanfar Laif, Sherif E. Abdelhamid, Roxane Elias Mafouhy, Jaafar Alghazo , และ Zafar Abbas Kazimi ที่วิจัยใช้ IoT, Deep Convolutional Neural Network (DCNN) และ VGG19 ที่ได้รับการปรับปรุง ระบบที่นี้สามารถตรวจค้นและวินิจฉัยอย่างแม่นยำสำหรับ 6 ชนิดที่แตกต่างกันได้แก่ ใบที่มีสุขภาพดี, จุดสีน้ำตาลแคบ, รอยเหี่ยวใบ, ระเบิดใบ, จุดสีน้ำตาล และโรคใบแคบที่เรีย ค่าความแม่นยำเฉลี่ยสูงสุดคือ 98.08% โดยใช้ชุดข้อมูลที่ไม่ได้ปรับค่า ค่า Precision, Recall, Specificity, และ F1-score ที่เกี่ยวข้องมีค่าเป็น 0.9620, 0.9617, 0.9921 และ 0.9818 ตามลำดับ [6] โรคใบไหม้ (Rice Blast Disease) ใบของข้าวจะมีลักษณะเป็นจุดสีน้ำตาล คล้ายรูปตา มีสีเทาอยู่บริเวณตรงกลาง ความยาวของแผลประมาณ 10-15 มิลลิเมตร ความกว้างประมาณ 2-5 มิลลิเมตร ในระยะต้นกล้า รอยแผลสามารถขยายลุกลามได้ทั่วใบ โรคใบจุดสีน้ำตาล (Brown Spot Disease) โรคใบจุดสีน้ำตาล ลักษณะเป็นจุดสีน้ำตาล รูปกลมหรือรูปไข่ขอบนอกสุดของแผลมีสีเหลือง มีเส้นผ่านศูนย์กลาง 0.5-1 มิลลิเมตร แผลที่มีการพัฒนาเต็มที่มีขนาด 1-2 คู่กับ 4-10 มิลลิเมตร บางที่พบรอยไม่เข้ารูปไข่ แต่จะเป็นรอยคล้ายด้ามมี โรคใบขีดสีน้ำตาล (Narrow Brown Spot Disease) ลักษณะรอยที่ไม่มีสีน้ำตาลเป็นขีดๆ ขนานไปกับเส้นของใบข้าว มักพบในระยะข้าวแตกกอ รอยแผลไม่กว้างตรงกลางเล็กไม่มีรอยขีด ต่อมาแผลจะขยายมาติดกัน ข้าวที่เป็นโรครุนแรงจะมีผลสีน้ำตาลที่ร่วงต่อไปได้

II เครื่องมือและวิธีการ

ผู้วิจัยได้อธิบายเกี่ยวกับการศึกษาองค์ความรู้ และงานวิจัยที่มีความสำคัญในการดำเนินการวิจัยในครั้งนี้ โดยแบ่งออกเป็น

II.I อธิบายถึง ขั้นตอนสำคัญที่นำมาใช้ในการแก้ปัญหาอย่างเป็นขั้นตอนอย่างเป็นระบบการแก้ปัญหาที่สามารถอธิบายออกมาได้เป็นขั้นตอนที่ชัดเจน เมื่อนำรายชื่อโรคมาจะต้องได้ผลลัพธ์อย่างไร อธิบายถึงขั้นตอนที่มีความชัดเจน อธิบายถึงขั้นตอนที่ใช้ในการเขียนโปรแกรมเพื่อทำการคอมพิวเตอร์ให้ทำงานที่มอบหมายให้สำเร็จ อธิบายถึงเป็นวิธีการที่มีประสิทธิภาพ การเขียนอธิบายวิธีที่สามารถเขียนออกมาได้เป็นภาพทางการเพื่อที่จะทำนองทั้งที่ขึ้นอย่างใดอย่างหนึ่ง เริ่มจากข้อความเริ่มต้น และขั้นตอนเริ่มต้นชุดคำสั่ง และพอผ่านขั้นตอนคำสั่งที่เริ่มต้นไว้จะสามารถให้เอาต์พุตที่ต้องการได้ โดยทั่วไป อธิบายถึงขั้นตอนการเขียนที่เป็นขั้นตอนและมีขั้นตอนที่แน่นอนแบบวนซ้ำ ในระบบคอมพิวเตอร์ อธิบายถึงขั้นตอนการเขียนระบบในซอฟต์แวร์ที่เขียนโดยนักพัฒนาซอฟต์แวร์ เพื่อให้มีประสิทธิภาพในการส่งออกเอาต์พุต จากอินพุตที่คอมพิวเตอร์ได้รับ อธิบายถึงขั้นตอนที่เป็นเทคโนโลยีรูปแบบหนึ่ง

II.II Machine learning การเรียนรู้ของเครื่องเป็นอรรถวิทย์ของคอมพิวเตอร์ที่มีการพัฒนา การเรียนรู้ของเครื่องเป็นส่วนหนึ่งของปัญญาประดิษฐ์ โดยอรรถวิทย์ที่สร้างแบบจำลองทางคณิตศาสตร์จากข้อมูลตัวอย่าง (ข้อมูลผู้สอน) เพื่อที่จะทำการค้นหรือตัดสินใจได้ชัดเจน การเรียนรู้ของเครื่องพัฒนามาจากการศึกษาการรู้จำแบบ การสร้างอรรถวิทย์ที่สามารถเรียนรู้ข้อมูลและทำนายข้อมูล อรรถวิทย์นั้นจะทำงานโดยอาศัยโมเดลที่สร้างมาจากชุดข้อมูลตัวอย่างที่เราให้ทำนาย หรือ จัดสินใจภายหลัง แทนที่จะทำงานตามลำดับของคำสั่งของโปรแกรมในคอมพิวเตอร์ การเรียนรู้ของเครื่องเกี่ยวข้องกับสถิติศาสตร์ เนื่องจากทั้งสองการศึกษาการวิเคราะห์ข้อมูลเกี่ยวกับทำนายเช่นเดียวกัน

ความสำคัญของการเรียนรู้ของเครื่องคือ การทำให้โมเดลมีความครอบคลุมมากขึ้นจากประสบการณ์ที่ได้รับมา การทำให้ข้อมูลทั่วไปมากขึ้นทำให้เครื่องสามารถพยากรณ์หรือทำงานกับข้อมูลตัวอย่างที่ไม่เคยพบมาก่อนได้มีความแม่นยำมากขึ้น โหมดการเรียนรู้ของเครื่องจากการสุ่ม

II.III Deep Learning การเรียนรู้เชิงลึกเป็นส่วนหนึ่งของวิธีการเรียนรู้ของเครื่องมีพื้นฐานของโครงข่ายประสาทเทียมและการเรียนรู้เชิงคุณลักษณะ การเรียนรู้สามารถแบ่งออกเป็น 3 ประเภทคือ การเรียนรู้แบบมีผู้สอน การเรียนรู้แบบกึ่งมีผู้สอน และการเรียนรู้แบบไม่มีผู้สอน พื้นฐานของการเรียนรู้เชิงลึกคืออรรถวิทย์ที่พยายามจะสร้างแบบจำลองแทนความหมายของข้อมูล ประกอบไปด้วยโครงสร้างย่อยๆ หลายๆ อัน การเรียนรู้เชิงลึกอาจมองได้ว่าเป็นวิธีการหนึ่งของการเรียนรู้ของเครื่องที่พยายามเรียนรู้วิธีการแทนข้อมูลอย่างมีประสิทธิภาพ

สถาปัตยกรรมของโครงข่ายการเรียนรู้เชิงลึกมักจะสร้างเป็นชั้นๆ ด้วยวิธี Greedy Method ซึ่งการหาสิ่งที่ดีที่สุดมากขึ้นไป โหมดการเรียนรู้เชิงลึกมีประสิทธิภาพมาก

II.IV การวิเคราะห์ผลการทดลอง การทดลองเป็นวิธีดำเนินการอย่างเป็นระบบเพื่อพิสูจน์ยืนยัน หักล้างหรือสร้างความสงสัยหรือพัฒนาสิ่งใหม่ ดังนั้นเครื่องมือที่จะนำมาวิเคราะห์ผลการทดลองจึงมีความสำคัญ โหมดการเรียนรู้เชิงลึกมีผู้วิจัยได้เลือกเครื่องมือ หรือ หลักการที่จะนำมาวิเคราะห์ตามรายละเอียดในข้อถัดไป

ค่าความแม่นยำ (Precision) ความสามารถของอุปกรณ์ที่จะอ่านค่าๆเดียวภายใต้สภาพการทำงานเดียวกัน ซ้ำกันหลายครั้ง ทำให้เราสามารถทราบความแม่นยำของอัลกอริทึมที่นำมาประยุกต์ใช้ แสดงผลโดยค่า Standard Deviation

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

ค่าความถูกต้อง (Accuracy) ผลการวิเคราะห์ที่มีค่าใกล้เคียงระหว่างค่าทดสอบกับค่าจริง แสดงในรูปของเปอร์เซ็นต์

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

ความไว (Recall) วัดความน่าจะเป็นที่โมเดลทำนายชนิดของโรคในใบข้าว ได้ถูกต้องกับความเป็นจริงกับโรคของใบข้าวที่นำมาใช้ในการวิเคราะห์

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


ความสามารถของโมเดล (F1-Score) เป็นค่าเฉลี่ยของความแม่นยำและการเรียกคืน ดังนั้นจึงแสดงทั้งความแม่นยำและการเรียกคืน ค่า F-Score ที่เป็นไปได้สูงสุดคือ 1.0 ซึ่งแสดงความแม่นยำและการเรียกคืนที่สมบูรณ์แบบและค่าต่ำสุดคือ 0 หากความแม่นยำหรือการเรียกคืนเป็นศูนย์

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

III. ขั้นตอนการทรวิจัย

อัลกอริทึมที่นำมาใช้ในการทดลองจะแบ่งเป็น 2 ประเภทด้วยกันคือ อัลกอริทึมในการสอนระบบการระบุชนิดของโรคบนใบข้าว และอัลกอริทึมในการระบุชนิดของโรคบนใบข้าว เมื่อป้อนรูปภาพเข้าสู่ระบบ ตาม Flow Diagram ด้านล่าง

III.1 แผนผังขั้นตอนการทรวิจัย



รูปที่ 1. แผนผังการทำงานของระบบการตรวจใบโรคของใบข้าวโดยใช้ Deep Learning

MLN เครื่องมือที่ใช้ในการทรวิจัย

ชุดข้อมูลรูปภาพที่นำมาใช้ในการสอนระบบ ลักษณะของรูปภาพในการสอนระบบ ปริมาณรูปภาพที่เหมาะสมในการสอนระบบเพื่อให้มีความแม่นยำ และเที่ยงตรง และรูปอ้างอิงชนิดของโรคในใบข้าวโดยอ้างอิงลักษณะของโรคจากกรมการข้าว นำอัลกอริทึมสอนงานชุดข้อมูลรูปภาพเกี่ยวกับชนิดของโรคบนใบข้าว เมื่อสอนระบบนำโรคในใบข้าวมาลงใช้งาน ระบบสามารถระบุชนิดของโรคได้ถูกต้องแม่นยำแค่ไหน อุปกรณ์ที่ใช้ในการวิจัย มี รูปภาพแต่ละโรค, อัลกอริทึมที่นำมาใช้สอน, อัลกอริทึมที่นำมาใช้ตัดสิน และ Computer ที่ใช้สำหรับการ Training และประมวลผล

ตารางที่ 1 จำนวนชุดข้อมูลรูปภาพ

ประเภทรูปภาพ	ชุดข้อมูลฝึกสอน (Data Set)	ข้อมูลทดสอบ (Test Data)	จำนวนรูปภาพทั้งหมด (Total data)
โรคใบไหม้	1,878	29	1,907
โรคใบจุดสีน้ำตาล	1,630	24	1,654
โรคใบขีดสีน้ำตาล	533	30	563

รูปภาพโรคใบไหม้ ใบจุดสีน้ำตาล และใบขีดสีน้ำตาลนำมาจาก 9 แหล่งข้อมูล [7], [8], [9], [10], [11], [12], [13], [14], [15]

IV. ผลการทดลอง

ผู้วิจัยได้เปรียบเทียบผลการทดลองโดยเปรียบเทียบ Model ที่มีอยู่ในปัจจุบัน คือ ResNet50 และ Model ที่ประยุกต์โดยผู้วิจัย โดยนำชุดข้อมูลรูปภาพของโรคบนใบข้าวทั้ง 3 ชนิด จำนวนทั้งหมด 83 รูปภาพ มาเข้าทดสอบความแม่นยำ สรุปผลได้ตามตารางตารางที่ 2 ผลการทดลอง ResNet50

ชนิดโรค	Model Accuracy (ชุด)	Recall (ชุด)	Precision (ชุด)	Recall (ชุด)	Accuracy (ชุด)	F1-Score (ชุด)
Blast	29	29	0	1.000	1.000	1.000
Brown	24	0	24	0.000	0.000	0.422
Narrow	30	0	30	0.000	0.000	0.277
All	83	29	54	0.349	0.349	0.349

ตารางที่ 3 ผลการทดลอง Model ประยุกต์

ชนิดโรค	Model Accuracy (ชุด)	Recall (ชุด)	Precision (ชุด)	Recall (ชุด)	Accuracy (ชุด)	F1-Score (ชุด)
Blast	29	29	0	1.000	1.000	1.000
Brown	24	22	2	0.917	0.917	0.917
Narrow	30	29	1	0.967	0.967	0.967
All	83	80	3	0.964	0.964	0.964

จากตารางสามารถสรุปได้ว่า โรคใบไหม้ทั้ง 2 ไม่เคยมีผลสัมฤทธิ์เท่ากัน ในโรคใบจุดสีน้ำตาลพบว่าโมเดลประเภทที่มีความแม่นยำอยู่ที่ 0.917 และโรคใบขีดสีน้ำตาลมีความแม่นยำอยู่ที่ 0.967

V. สรุปผลการทดลอง

จากงานวิจัยนี้ได้มุ่งเน้นไปที่การคัดแยกชนิดของโรคบนใบข้าว ในขั้นตอนการทดลองแบบจำลอง จะมีภาพที่ไม่อยู่รวมกันขั้นตอนการฝึกฝนแบบจำลอง รูปภาพชนิดของโรคบนใบข้าวจะแบ่งเป็นจำนวน 3 ชนิด คือโรคใบไหม้ โรคใบขีดสีน้ำตาล และโรคใบจุดสีน้ำตาล ที่ใช้ในการฝึกฝนแบบจำลอง โดยผู้วิจัยได้ทำการทดลองผ่านโครงข่ายประสาทเทียมแบบคอนโวลูชัน เข้ามาสร้างแบบจำลองเพื่อให้แบบจำลองนี้สามารถจำแนกชนิดของโรคบนใบข้าวได้ ผู้วิจัยฝึกฝนโมเดลโดยเน้นจุดที่น่าสนใจ ให้อยู่บริเวณกึ่งกลางของรูปภาพ ดังนั้นการเพิ่ม Convolutional Layer จะทำให้โมเดลเรียนรู้และโฟกัสที่ลักษณะที่สำคัญของภาพ ซึ่งเชื่อมต่อกันในชั้นแรกของโมเดล ซึ่งเป็นส่วนของการทำนอในภายหลัง การโฟกัสที่พื้นที่กลางของรูปภาพ มักจะมีประสิทธิภาพในการแยกแยะวัตถุหรือลักษณะที่สำคัญในรูปภาพ จึงทำให้โมเดลได้เรียนรู้ และสร้างลักษณะเชิงลึกในข้อมูลเหล่านี้ได้ดี การปรับ Conv2D มีผลต่อการค้นหาลักษณะเด่นในรูปภาพ เช่น เส้นขอบ และรูปร่าง เป็นต้น โดยผู้วิจัยสรุปผลการทดลองประสิทธิภาพทั้งความแม่นยำ ความถูกต้อง ผลการทดลองในจำนวนวิจัยครั้งนี้ พบว่าโมเดลที่ประยุกต์มีความแม่นยำภาพรวมอยู่ที่ 0.964 โดยที่โรคใบไหม้มีความแม่นยำถึง 0.100 โรคใบขีดสีน้ำตาลผลมีความแม่นยำอยู่ที่ 0.967 และโรคใบจุดสีน้ำตาลมีความแม่นยำอยู่ที่ 0.917 ในงานวิจัยครั้งนี้ผู้วิจัยมีข้อเสนอแนะเพื่อเป็นแนวทางในการพัฒนาต่อไป คืองานวิจัยนี้รูปภาพมาฝึกฝนผ่านโครงข่ายประสาทเทียม และทำนายผ่านคอมพิวเตอร์ สามารถนำมาพัฒนาให้ตรวจจับชนิดของโรคบนใบข้าวในนาข้าว เนื่องจากการใช้ภาพในการตรวจจับโรคสามารถช่วยลดเวลา และความล่าช้าในการตรวจจับโรคได้ โดยเฉพาะในการตรวจจับโรคใบข้าวที่มีรายละเอียดซับซ้อนและมีการเปลี่ยนแปลง โดยใช้ระบบตรวจจับอัตโนมัติในสภาพภูมิอากาศและสภาพสิ่งแวดล้อมของนาข้าว

กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จสมบูรณ์ได้ด้วยพลังและความกรุณา และความช่วยเหลืออย่างดียิ่งจาก ดร. อัทธนา เชนโค๊ะ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ท่านได้เสียสละเวลาอันมีค่ายิ่งในการให้ให้ความรู้ ให้คำปรึกษา ตลอดจนได้ตรวจตอบและแก้ไขข้อบกพร่องต่างๆ อันเป็นประโยชน์ในการจัดทำวิทยานิพนธ์ ตั้งแต่เริ่มดำเนินการจนกระทั่งดำเนินการเสร็จสมบูรณ์

ผู้จัดทำขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้ หวังว่าขอขอบพระคุณบิดา มารดา ครอบครัวของข้าพเจ้าที่ได้ให้กำลังใจ และสนับสนุนเรื่องต่างๆ ในการศึกษานี้ด้วยดีจนสำเร็จ

บรรณานุกรม

- [1] Ruoling Deng, Ming Tao, Hang Xing, Xiuli Yang,

Chuang Liu and Kaifeng Liao, Automatic Diagnosis of Rice Diseases Using Deep Learning, Journal, China 2021

- [2] Dr. Sandhya Venu Vasantha, Dr. Bejjam Kiranmai and Dr. S. Rama Krishna, Techniques for Rice Leaf Disease Detection using Machine Learning Algorithms, (IJERT) Journal, India 2021

- [3] T.Daniya and Dr.S.Vigneshwari, A Review on Machine Learning Techniques for Rice Plant Disease Detection in Agricultural Research, International Journal of Advanced Science and Technology Vol. 28, No. 13, (2019), pp. 49-62, India 2019

- [4] Md. Ashique Islam, Md. Nymur Rahman Shuvo, Muhammad Shamsujjaman, Shazid Hasan, Md. Shahadat Hossain and Tania Khatun, An Automated Convolutional Neural Network Based Approach for Paddy Leaf Disease Detection, (IJACSA) Journal, Bangladesh 2021

- [5] Ghazantaf Latif, Sherif E. Abdelhamid, Roxane Elias Malouhy, Jaafar Alghazo, and Zafar Abbas Kazimi, Deep Learning Utilization in Agriculture: Detection of Rice Plant Diseases Using an Improved CNN Model, 28 August 2022

- [6] โรคใบไหม้, โรคใบขีดสีน้ำตาล และโรคใบจุดสีน้ำตาล, โรคข้าวและการป้องกันกำจัด, สำนักวิจัยและพัฒนาข้าว กรมการข้าว, Thailand 2007

- [7] Blast and Brown spot image, sethy, prabira Kumar (2020), "Rice Leaf Disease Image Samples", Mendeley Data, V1, doi: 10.17632/twq7s1b8r.1

- [8] Brown spot image, Rice Leaf Diseases Dataset (Images of disease infected rice plant leaves)

- [9] Rice disease Computer Vision Project, 2022 Sep

- [10] Rice leaf disease detection Computer Vision Project, 2023 Jul

- [11] โรคใบจุดสีน้ำตาล, UNILIFE ได้ใช้วิธีเกษตรกร

- [12] โรคใบจุดสีน้ำตาล, ศูนย์วิทยบริการเพื่อส่งเสริมการเกษตร

- [13] โรคใบจุดสีน้ำตาล, เอราวัณ, 2023

- [14] โรคใบไหม้, ช่วงนี้ชาวนาจะระวังโรคใบจุดสีน้ำตาล ระบบนาข้าว ๓๖๕๕๕, 2016

- [15] โรคใบไหม้, "โรคไหม้ข้าว" ระบบนาแปลงกล้า, เชียงใหม่ นิวส์, 2016

ประวัติย่อผู้วิจัย



ชื่อ – สกุล

นางสาวพนนิศา วานิช

วัน – เดือน – ปี เกิด

7 ตุลาคม 2536

ที่อยู่ปัจจุบัน

199/104 คอนโดมี นวนคร ตึก B

ถนนพหลโยธิน ตำบลเชียงรากน้อย อำเภอบางปะอิน

พระนครศรีอยุธยา 13180

โทรศัพท์มือถือ : 064-251-3513

E-mail : va.phannisa_st@tni.ac.th

ประวัติการศึกษา

พ.ศ. 2566

วิศวกรรมศาสตรมหาบัณฑิต สาขาเทคโนโลยีวิศวกรรม

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

พ.ศ. 2559

วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมผลิต

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

ประวัติการทำงาน

พ.ศ. 2559 – ปัจจุบัน

Production Engineer (Automotive Product and BLDC)

บริษัทเอ็นเอ็มบี-มินิแปไทย จำกัด (โรงงานบางปะอิน)