

การพัฒนาขั้นตอนวิธีสำหรับจำแนกโรคอ้อยที่พบมากในประเทศไทย



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2564
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Development of an Algorithms for Classifying Common Sugarcane Diseases in
Thailand



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Electrical Engineering

Department of Electrical Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพัฒนาขั้นตอนวิธีสำหรับจำแนกโรคอภัยที่พบมากในประเทศไทย
โดย	น.ส.ณัฐภัค ลาวัลย์วงศ์
สาขาวิชา	วิศวกรรมไฟฟ้า
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.สุรีย์ พุ่มรินทร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(รองศาสตราจารย์ ดร.วันเฉลิม โปธา)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.สุรีย์ พุ่มรินทร์)	
.....	กรรมการภายนอกมหาวิทยาลัย
(ศาสตราจารย์ ดร.สัญญา มิตรเอม)	

มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ณัฐรักษ์ ลาวัลย์วงศ์ : การพัฒนาขั้นตอนวิธีสำหรับจำแนกโรคอ้อยที่พบบ่อยในประเทศไทย. (Development of an Algorithms for Classifying Common Sugarcane Diseases in Thailand) อ.ที่ปรึกษาหลัก : ผศ. ดร.สุรียะ พุ่มรินทร์

สำหรับการจำแนกโรคอ้อยที่พบบ่อยบนพันธุ์ขอนแก่น 3 ซึ่งเป็นพันธุ์อ้อยที่ได้รับความนิยมมากที่สุดในประเทศไทย จะให้ความสำคัญในการวิเคราะห์โรคที่ส่งผลกระทบต่อใบอ้อย เช่น โรคที่เกิดจากแบคทีเรีย เชื้อรา และแมลง จากการตรวจหาและระบุโรคที่เกิดขึ้นในอ้อยซึ่งต้องการผู้เชี่ยวชาญที่มีประสบการณ์และเวลา จึงมีแนวคิดในการสร้างระบบที่ช่วยในการจำแนกโรคอ้อยที่มีความแม่นยำอย่างอัตโนมัติ ซึ่งส่งผลให้การวินิจฉัยโรคทำได้รวดเร็วมากขึ้น เป็นระบบอัจฉริยะสำหรับจำแนกประเภทและลักษณะอาการของโรคอ้อย (Intelligent System Diagnosis Sugarcane Diseases with Deep Convolutional Neural Network) เป็นระบบที่ให้ผู้ใช้งานอัปโหลดรูปภาพใบอ้อย สามารถบ่งบอกโรคอ้อยและระบุสาเหตุพร้อมวิธีการป้องกันหรือควบคุม โดยระบบมีความสามารถในการจำแนกชนิดของโรคอ้อย 5 คลาส ได้แก่ โรคเส้นกลางใบแดง (Red Rot) โรคราสนิม (Rust) โรคใบจุดวงแหวน (Ring Spot) โรคใบขาว (White Leaf) และใบสมบูรณ์ (Normal) ที่มีค่า Mean Average Precision (mAP) สูงถึง 0.8681 หรือร้อยละ 86.81

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิศวกรรมไฟฟ้า
ปีการศึกษา 2564

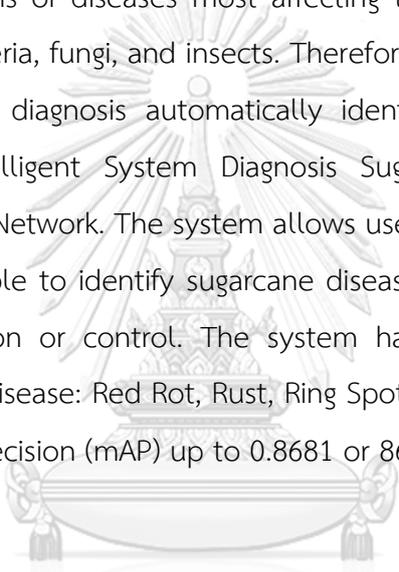
ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6270356321 : MAJOR ELECTRICAL ENGINEERING

KEYWORD: Sugarcane Diseases, convolutional neural network (CNN)

Nattapak Lawanwong : Development of an Algorithms for Classifying Common Sugarcane Diseases in Thailand. Advisor: Asst. Prof. SUREE PUMRIN, Ph.D.

For the classification of sugarcane diseases that are most common on Khon Kaen 3, which is the most popular sugarcane variety in Thailand. The focus will be on the analysis of diseases most affecting the sugarcane leaves such as those caused by bacteria, fungi, and insects. Therefore, there is the idea of creating a system that faster diagnosis automatically identifies sugarcane disease with accuracy, called Intelligent System Diagnosis Sugarcane Diseases with Deep Convolutional Neural Network. The system allows users to upload pictures of sugar cane leaves. It was able to identify sugarcane disease and identify the cause and methods of prevention or control. The system has the ability to classify five classes of sugarcane disease: Red Rot, Rust, Ring Spot, White Leaf, and Normal leaf with mean average precision (mAP) up to 0.8681 or 86.81 percent.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Field of Study: Electrical Engineering

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้มีความตั้งใจที่นำเสนอผลการวิจัยในการพัฒนาระบบสหวิทยาการ ที่นำองค์ความรู้ทางด้านวิศวกรรมมารังสรรค์ระบบที่สามารถช่วยให้มนุษย์ทำงานได้ประสิทธิภาพสูงขึ้น ข้าพเจ้าขอขอบคุณบุคคลผู้มีส่วนเกี่ยวข้องที่ทำให้โครงการนี้สำเร็จได้ ประกอบด้วย ผศ.ดร.สุรีย พุมรินทร์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ รศ.ดร.วันเฉลิม โปรา อาจารย์ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย ศ.ดร.สัญญา มิตรเอม อาจารย์ภาควิชาวิศวกรรมไฟฟ้าและคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยธรรมศาสตร์ ศูนย์ส่งเสริมอุตสาหกรรมอ้อยและน้ำตาลทรายภาคที่ 3 จังหวัดชลบุรี และนายดิเรก แซ่ฮ้อ เกษตรกรชาวไร่อ้อย ที่ให้โอกาสข้าพเจ้าได้ศึกษาวิธีการที่เกี่ยวข้องและปัญหาที่พบในการปฏิบัติงานเพื่อนำมาเป็นที่มาของวิทยานิพนธ์ และบิดา มารดา เพื่อน ๆ พี่ ๆ น้อง ๆ ทั้งที่เป็นนิสิตและผู้ทำงานแล้ว ได้มีส่วนร่วมให้วิทยานิพนธ์นี้สำเร็จลุล่วง

ณัฐภัค ลาวัลย์วงศ์



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์	2
1.3 ขอบเขตงานวิจัย	2
1.4 วิธีการดำเนินงาน	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง.....	5
2.1 การเรียนรู้ของเครื่อง (Machine Learning)	5
2.1.1 กลุ่มปัญหาการเรียนรู้ (Learning Problems).....	5
2.1.2 กลุ่มปัญหาการเรียนรู้แบบไฮบริด (Hybrid Learning Problems).....	7
2.1.3 กลุ่มการอนุมานทางสถิติ (Statistical Inference)	7
2.1.4 กลุ่มกลวิธีการเรียนรู้ (Learning Technique)	8
2.2 โครงข่ายประสาทเทียม (Neural Networks)	8

2.2.1	ชนิดของโครงข่ายประสาทเทียม (Neural Networks)	9
2.2.2	ส่วนประกอบของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)	11
2.2.2.1	ชั้น Conv2D	11
2.2.2.2	ชั้นฟังก์ชันกระตุ้น (Activation Function)	12
2.2.2.2.1	ชั้นฟังก์ชัน Sigmoid	12
2.2.2.2.2	ชั้นฟังก์ชัน ReLU (Rectified Linear Unit)	12
2.2.2.2.3	ชั้นฟังก์ชัน Softmax	13
2.2.2.3	ชั้น Pooling	14
2.2.2.4	ชั้น Flatten	15
2.2.2.5	ชั้น Fully connected	15
2.2.2.6	ชั้น Dropout	15
2.2.3	วิธีการประเมินความแม่นยำของโครงข่ายประสาทเทียม (Confusion Matrix)	15
2.2.3.1	ค่าความแม่นยำ (Accuracy)	16
2.2.3.2	ค่าความเที่ยงตรง (Precision)	16
2.2.3.3	ค่าการเรียกคืน (Recall)	17
2.2.3.4	ค่า F1-Score	17
2.2.3.5	การบ่งบอกความสามารถด้วยค่า Average Precision (AP)	17
2.2.3.6	การบ่งบอกความสามารถด้วยค่า Mean Average Precision (mAP)	18
2.3	สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Architecture of CNN)	18
2.3.1	VGGNet	19
2.3.2	ResNet	20
2.4	โรคอ้อยที่เกิดจากเชื้อรา	20
2.4.1	โรคเน่าแดงหรือโรคเส้นกลางใบแดง (Red rot disease)	20
2.4.2	โรคราสนิม (Rust disease)	21

2.4.3 โรคใบจุดวงแหวน (Ring spot disease).....	22
2.4.4 โรคใบขาว (White leaf disease).....	23
2.5 งานวิจัยที่เกี่ยวข้องกับการจำแนกชนิดและลักษณะอาการของโรคอ้อย.....	23
บทที่ 3 การพัฒนาขั้นตอนวิธีสำหรับจำแนกโรคอ้อย.....	26
3.1 ศึกษาและวิเคราะห์ข้อมูลอาการผิดปกติของใบอ้อยที่เกิดจากโรค.....	26
3.1.1 รวบรวมตัวอย่างใบอ้อยที่ติดเชื้อ.....	26
3.1.2 ออกแบบและสร้างฐานข้อมูลเพื่อจัดเก็บข้อมูลของโรคอ้อย	27
3.2 การพัฒนาระบบเว็บแอปพลิเคชันสำหรับโครงการวิจัย	27
3.3 การออกแบบโครงข่ายประสาทสำหรับจำแนกโรคอ้อย.....	30
3.2.1 การเพิ่มปริมาณข้อมูล (Data Augmentation).....	30
3.2.2 การสร้างชุดข้อมูล (Dataset) และการติดป้าย (Labeling)	31
3.2.3 กรรมวิธีพัฒนาโครงข่ายประสาทเทียมสำหรับการจำแนกโรคอ้อย.....	33
บทที่ 4 ผลการทำงานของระบบ.....	38
4.1 การเพิ่มปริมาณข้อมูลภาพ (Data Augmentation).....	38
4.1.1 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ perfect.....	38
4.1.2 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ red_rot.....	39
4.1.3 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ rust.....	40
4.1.4 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ ring_spot.....	41
4.1.5 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ white_leaf.....	42
4.1.6 พารามิเตอร์ของโมเดลโครงข่ายประสาทเทียมที่ใช้ในระบบ	42
4.2 แบบจำลองการเรียนรู้ของเครื่อง.....	45
4.2.1 ผลลัพธ์การฝึกแบบจำลองแบบไม่ปรับพารามิเตอร์.....	45
4.2.2 ผลลัพธ์การฝึกแบบจำลองแบบปรับพารามิเตอร์แบบที่ 1	47
4.2.3 ผลลัพธ์การฝึกแบบจำลองแบบปรับพารามิเตอร์แบบที่ 2	49

บทที่ 5 สรุปงานวิจัย	52
5.1 สรุปผลวิจัย	52
5.2 แนวทางการพัฒนางานวิจัย.....	53
5.3 ปัญหาและอุปสรรค.....	53
ภาคผนวก ก. บทความวิจัยที่ได้ตีพิมพ์ใน RC-EEE 2021.....	54
บรรณานุกรม.....	58
ประวัติผู้เขียน.....	61



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญตาราง

	หน้า
ตารางที่ 1 ค่าพารามิเตอร์แบบไม่ปรับพารามิเตอร์สำหรับโมเดล.....	44
ตารางที่ 2 ค่าพารามิเตอร์แบบที่ 1 สำหรับฝึกโมเดล	44
ตารางที่ 3 ค่าพารามิเตอร์แบบที่ 2 สำหรับฝึกโมเดล	44



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญรูปภาพ

	หน้า
ภาพที่ 1 ประเภทหลัก ๆ ของ Machine Learning [6]	5
ภาพที่ 2 ชนิดของโครงข่ายประสาทเทียม (Neural Network) ที่ใช้งานในปัจจุบัน	9
ภาพที่ 3 แนวคิดของโครงข่ายประสาทแบบคอนโวลูชัน (CNN).....	11
ภาพที่ 4 Sigmoid Activation Function	12
ภาพที่ 5 ReLU Activation Function (ซ้าย) กราฟแสดงการเปรียบเทียบระหว่างการใช้ ReLU [เส้น ทึบ] และ tanh [เส้นปะ] พบว่า ReLU ลู่เข้าเร็วกว่า 6 เท่า (ขวา).....	13
ภาพที่ 6 ชนิดของ pooling layer	14
ภาพที่ 7 ตาราง Confusion Matrix	15
ภาพที่ 8 สถาปัตยกรรมของ VGGNet [8].....	19
ภาพที่ 9 หลักการของ residual learning หรือ residual block [9].....	20
ภาพที่ 10 ศูนย์ส่งเสริมอุตสาหกรรมอ้อยและน้ำตาลทรายภาคที่ 3 จังหวัดชลบุรี	26
ภาพที่ 11 แปลงไร่อ้อยของเกษตรกร	27
ภาพที่ 12 หน้าเว็บแอปพลิเคชันฝั่งผู้ใช้งานทั่วไป	28
ภาพที่ 13 หน้าเว็บแอปพลิเคชันทำนายโรคอ้อย	28
ภาพที่ 14 หน้าเว็บแอปพลิเคชันฝั่งผู้เชี่ยวชาญ	29
ภาพที่ 15 หน้าเว็บแอปพลิเคชันฝั่งผู้เชี่ยวชาญบันทึกข้อมูล	29
ภาพที่ 18 ใบโรคใบจุดวงแหวน (ring spot disease) ที่ผ่านการเพิ่มปริมาณข้อมูล	31
ภาพที่ 19 ใบอ้อยโรคใบขาว (white leaf disease) ที่ผ่านการเพิ่มปริมาณข้อมูล	31
ภาพที่ 20 ใบอ้อยสมบูรณ์ (perfect) ที่ผ่านการเพิ่มปริมาณข้อมูล	31
ภาพที่ 21 ตัวอย่างใบอ้อยโรคเส้นกลางใบแดง	32
ภาพที่ 22 ตัวอย่างใบอ้อยโรคราสนิม	32

ภาพที่ 23 ตัวอย่างใบอ้อยโรคใบจุดวงแหวน	33
ภาพที่ 24 ตัวอย่างใบอ้อยโรคใบขาว	33
ภาพที่ 25 ตัวอย่างใบอ้อยสมบูรณ์.....	33
ภาพที่ 26 ภาพการจัดป้ายข้อมูลตามคลาส	36
ภาพที่ 27 ตัวอย่างชุดข้อมูลภาพ perfect ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ	38
ภาพที่ 28 ตัวอย่างชุดข้อมูลภาพ perfect หลังได้รับการเพิ่มปริมาณข้อมูลภาพ	39
ภาพที่ 29 ตัวอย่างชุดข้อมูลภาพ red_rot ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ	39
ภาพที่ 30 ตัวอย่างชุดข้อมูลภาพ red_rot หลังได้รับการเพิ่มปริมาณข้อมูลภาพ.....	39
ภาพที่ 31 ตัวอย่างชุดข้อมูลภาพ rust ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ	40
ภาพที่ 32 ตัวอย่างชุดข้อมูลภาพ rust หลังได้รับการเพิ่มปริมาณข้อมูลภาพ	40
ภาพที่ 33 ตัวอย่างชุดข้อมูลภาพ ring_spot ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ.....	41
ภาพที่ 34 ตัวอย่างชุดข้อมูลภาพ ring_spot หลังได้รับการเพิ่มปริมาณข้อมูลภาพ	41
ภาพที่ 35 ตัวอย่างชุดข้อมูลภาพ white_leaf ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ	42
ภาพที่ 36 ตัวอย่างชุดข้อมูลภาพ white_leaf หลังได้รับการเพิ่มปริมาณข้อมูลภาพ	42
ภาพที่ 37 ภาพก่อนการทำ image per-processing	43
ภาพที่ 38 ภาพหลังการทำ image per-processing.....	43
ภาพที่ 39 การวัด Feature Important.....	44
ภาพที่ 40 กระบวนการเรียนรู้ของเครื่อง.....	45
ภาพที่ 41 กราฟแสดงความแม่นยำ mAP ของโมเดลแบบไม่ปรับพารามิเตอร์	46
ภาพที่ 42 กราฟแสดง Training loss และ Validation loss ของโมเดลแบบไม่ปรับพารามิเตอร์... ..	46
ภาพที่ 43 กราฟแสดง Training accuracy และ Validation accuracy ของโมเดลแบบไม่ปรับ.....	47
ภาพที่ 46 กราฟแสดง Training accuracy และ Validation accuracy ของโมเดลปรับพารามิเตอร์ แบบที่ 1	49
ภาพที่ 49 กราฟแสดง Training accuracy และ Validation accuracy ของโมเดลปรับ	51



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บทที่ 1 บทนำ

1.1 ที่มาและความสำคัญของปัญหา

อ้อยจัดเป็นพืชสำคัญทางเศรษฐกิจชนิดหนึ่งของประเทศไทย เป็นพืชให้พลังงานในรูปแบบน้ำตาลที่มีความจำเป็นต่อการดำรงชีวิตของมนุษย์ โดยถูกใช้เป็นส่วนประกอบของอาหารโดยตรงและเป็นวัตถุดิบสำคัญในอุตสาหกรรมต่าง ๆ หลายชนิด อ้อยยังจัดเป็นพืชพลังงานทดแทนอีกชนิดหนึ่ง เนื่องจากถูกนำไปสกัดเป็นแอลกอฮอล์แล้วผสมกับน้ำมันเป็นน้ำมันแก๊สโซฮอล์เพื่อทดแทนน้ำมันปิโตรเลียมที่ใช้อยู่ในปัจจุบัน [1] จากข้อมูลของสำนักงานคณะกรรมการอ้อยและน้ำตาลทราย (OFFICE OF THE CANE AND SUGAR BOARD) ได้จัดทำรายงานผลการสำรวจพื้นที่ปลูกอ้อยประจำปีการผลิต 2563/64 มีพื้นที่เพาะปลูกรวมทั้งสิ้นจำนวน 10,862,610 ไร่ ลดลง จำนวน 1,096,530 ไร่ หรือคิดเป็นร้อยละ 9.17 จากปีก่อนหน้า ผลผลิตเฉลี่ย 7.21 ตันต่อไร่ [2] ถึงแม้จะมีการพัฒนาปรับปรุงพันธุ์อ้อยเพื่อยกระดับผลผลิตและคุณภาพของอ้อย แต่ปัญหาการระบาดของโรคอ้อยในประเทศไทย [3] ถือเป็นปัญหาหนึ่งซึ่งส่งผลให้ผลผลิตอ้อยของเกษตรกรชาวไร่อ้อยลดลง โดยโรคที่เกิดกับอ้อยมีมากกว่า 150 ชนิด มีสาเหตุต่าง ๆ กัน เช่น การขาดธาตุอาหาร เกิดจากเชื้อสาเหตุต่าง ๆ เช่น รา แบคทีเรีย ไวรัส แมลงศัตรูอ้อย ทำให้อ้อยแสดงอาการผิดปกติทั้งที่ ใบ ลำต้น และราก โดยมีอาการใบจุด ใบฉีกแห้ง ใบขาว ใบเหี่ยวใบเปลี่ยนสีรูปทรง ใบไหม้ ลำต้นแคระแกรนแตกกอมากผิดปกติ ลำต้นและรากเน่า เป็นต้น แต่โรคที่นับว่ามีความสำคัญมีเพียง 15-20 ชนิดเท่านั้น ทั้งนี้มีโรคเกิดจากเชื้อราเป็นสาเหตุร่วมอยู่ด้วย โรคอ้อยที่เกิดจากเชื้อรา นั้น ได้แก่ โรคเน่าแดงหรือโรคเส้นกลางใบแดง โรคราสนิม โรคใบจุดวงแหวน โรคใบขาว เป็นต้น [4] อันส่งผลเสียให้อ้อยไม่สามารถเจริญเติบโตได้อย่างปกติ ไม่สามารถให้ผลผลิตได้หรือให้ผลผลิตได้ไม่เต็มศักยภาพเท่าที่ควร ส่งผลเสียต่อเกษตรกรชาวไร่อ้อยที่ต้องได้รับความเสียหายจากต้นทุนการผลิตที่ใช้ไปหรือต้องจ่ายเพิ่มขึ้นเพื่อแก้ไขอาการผิดปกติของอ้อย และไม่อาจทำให้อ้อยสามารถมีผลผลิตได้ตามเดิม ส่งผลเสียต่อโรงงานน้ำตาลที่ไม่มีอ้อยตามเป้าหมายที่วางไว้ รวมถึงผลกระทบต่ออุตสาหกรรมอ้อยและน้ำตาลทรายของประเทศไทยทั้งระบบ

อย่างไรก็ตาม ในปัจจุบัน โดยส่วนมากการเก็บข้อมูลลักษณะอาการของโรคที่ปรากฏของอ้อยนั้น ยังเป็นการเก็บข้อมูลที่ใช้แรงงานคนเป็นหลัก ไม่ว่าจะเป็นการเก็บลักษณะใบ การติดตามการเจริญเติบโตหรือการระบาดของโรค ระยะของโรคที่เกิดขึ้น ซึ่งบางลักษณะอาการของโรคอ้อยจำเป็นที่จะต้องให้ผู้เชี่ยวชาญ

ระบบที่ใช้รูปภาพเป็นพื้นฐานนั้นมีกระบวนการดำเนินการ 3 ขั้นตอน ได้แก่ 1.การเก็บข้อมูล 2.การสกัดคุณลักษณะเฉพาะ (Feature Extraction) 3.การจำแนกชนิดและลักษณะอาการของโรคอ้อย โดยในปัจจุบันโมเดลการเรียนรู้เชิงลึกได้ถูกพัฒนาขึ้น เช่น โครงข่ายประสาทเทียมแบบคอนโวลู

ชั้นเชิงลึก (Deep Convolutional Neural Networks) อัตราความแม่นยำของการระบุวัตถุต่าง ๆ และการจัดหมวดหมู่ข้อมูลอยู่ที่ร้อยละ 99 สามารถตรวจจับและตอบสนองต่อข้อมูลเชิงภาพต่าง ๆ ได้อย่างแม่นยำยิ่งกว่ามนุษย์ ได้ให้ผลลัพธ์ในการทำงานด้านการรู้จำที่ดีมาก เช่น การจำแนกรถ การจำแนกพืช การจำแนกสัตว์ และการจำแนกใบหน้ามนุษย์ [5]

ในวิทยานิพนธ์เล่มนี้จะนำเสนอระบบการจำแนกโรคอ้อย โดยประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันกับอุปกรณ์การถ่ายภาพที่มีบนโทรศัพท์มือถือเข้ามาช่วยเพื่อให้มีความสามารถในการจำแนกโรคอ้อยที่มีความแม่นยำสูงเพียงพอ เพื่อให้ผู้เชี่ยวชาญ เกษตรกรชาวไร่อ้อย เจ้าหน้าที่ฝ่ายไร่ของโรงงานน้ำตาลทราย บุคลากรของสำนักงานคณะกรรมการอ้อยและน้ำตาลทราย และผู้ที่สนใจ มีความเข้าใจเกี่ยวกับระบบที่ใช้ในการจำแนกโรคอ้อยมากยิ่งขึ้น ซึ่งระบบสามารถตรวจจำแนกชนิดและลักษณะอาการของโรคอ้อย โดยแต่ละโรคจะมีวิธีการป้องกันหรือควบคุมที่แตกต่างกัน เพื่อให้เกษตรกรชาวไร่อ้อยสามารถจำแนกชนิดและลักษณะอาการของโรคอ้อย และวางแผนป้องกันการระบาดของโรคได้อย่างถูกต้องด้วยตนเองและทันการณ์ โดยผู้ใช้งานจะสามารถใช้งานผ่านทางระบบซอฟต์แวร์เว็บแอปพลิเคชันแบบออนไลน์บนอุปกรณ์ต่างๆ เช่น คอมพิวเตอร์ แท็บเล็ต สมาร์ทโฟน เป็นต้น

1.2 วัตถุประสงค์

1. ออกแบบและเพิ่มความแม่นยำของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks) ด้วยเครื่องมือแบบ Open Source สำหรับการจำแนกชนิดและลักษณะอาการของโรคอ้อย จำนวน 4 ชนิด ได้แก่ โรคเน่าแดงหรือโรคเส้นกลางใบแดง (Red rot) โรคราสนิม (Rust) โรคใบจุดวงแหวน (Ring spot) และโรคใบขาว (White leaf)
2. เพื่อประยุกต์ใช้การประมวลผลภาพ (Image processing) และการเพิ่มปริมาณข้อมูลภาพ (Data Augmentation) ในการสร้างชุดข้อมูลภาพถ่ายใบอ้อย ออกเป็นชุดสำหรับการฝึก (Training set) ชุดสำหรับทดสอบ (Test set) และชุดตรวจสอบความถูกต้อง (Validation set)
3. พัฒนาโปรแกรมประยุกต์ (Application) ที่อนุญาตให้ผู้ใช้อัพโหลดรูปภาพใบอ้อย แล้วให้ผลลัพธ์เป็นชนิดและลักษณะอาการของโรคอ้อย

1.3 ขอบเขตงานวิจัย

1. สร้างฐานข้อมูลภาพถ่ายใบอ้อยที่เป็นโรคสำคัญและมีความรุนแรงของโรคสูง อย่างน้อย 4 ชนิด ชนิดละไม่น้อยกว่า 300 รูป ภาพ ที่ได้รับการติดป้าย (Labeling) ประกอบด้วย โรคเน่า

แดงหรือโรคเส้นกลางใบแดง (Red rot) โรคราสนิม (Rust) โรคใบจุดวงแหวน (Ring spot) และโรคใบขาว (White leaf)

- 2 พัฒนาขั้นตอนวิธีหรืออัลกอริทึม (Algorithm) สำหรับจำแนกชนิดและลักษณะอาการของโรคด้วยภาษา Python การใช้คลังชุดคำสั่ง OpenCV สำหรับภาพถ่ายใบอ้อยและประมวลผลภาพ การใช้ชุดคำสั่ง TensorFlow และ Keras สำหรับการสร้างแบบจำลองโครงข่ายประสาทเทียม จะต้องมีความแม่นยำไม่น้อยกว่าร้อยละ 80
- 3 สร้างโปรแกรมประยุกต์ให้ผู้ใช้งานทั่วไปสามารถอัปโหลดภาพใบอ้อยโดยกำหนดให้ภาพถ่ายนั้นเห็นโรคที่เกิดขึ้นบนใบอ้อยเพียงใบเดียว โดยให้ผลลัพธ์เป็นชนิดและลักษณะอาการของโรคอ้อย พร้อมทั้งบอกสาเหตุและวิธีการป้องกันหรือควบคุมโรค
- 4 สร้างโปรแกรมประยุกต์ให้ผู้เชี่ยวชาญสามารถอัปโหลดใบอ้อย พร้อมทั้งระบุชนิดและลักษณะอาการของโรคอ้อยด้วย

1.4 วิธีการดำเนินงาน

1. ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์
2. คัดเลือกชนิดและลักษณะอาการของโรคอ้อยสำหรับทำวิจัย
3. ศึกษาลักษณะของภาพและทำการเพิ่มปริมาณข้อมูลภาพ
4. ศึกษาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันแบบต่าง ๆ
5. ฝึกการเรียนรู้ของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน จากภาพใบอ้อยของโรคต่าง ๆ ด้วยการใช้ GPU ในการฝึกสอน
6. ทดสอบความแม่นยำของแบบจำลองโครงข่ายประสาทเทียม ด้วยเทคนิคการเรียนรู้แบบถ่ายโอน การเพิ่มปริมาณข้อมูลภาพ และการปรับแต่งพารามิเตอร์ต่าง ๆ
7. สรุปผลการดำเนินการ และเขียนรายงานวิทยานิพนธ์
8. ตีพิมพ์เผยแพร่วิทยานิพนธ์

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1. ได้โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้รับการฝึกแล้ว และมีความสามารถในการจำแนกชนิดและลักษณะอาการของโรคอ้อยซึ่งมีความแม่นยำไม่ต่ำกว่าร้อยละ 80
2. ได้ชุดข้อมูลภาพใบอ้อยในประเทศไทยรวมถึงการเพิ่มปริมาณข้อมูลภาพ (Data Augmentation) ไม่น้อยกว่า 10,000 ภาพ

3. ได้แอปพลิเคชัน (Application) ที่ผู้เชี่ยวชาญสามารถอัปโหลดรูปใบอ้อยพร้อมระบุชนิดและลักษณะอาการของโรคอ้อย และผู้ใช้ทั่วไปสามารถอัปโหลดรูปใบอ้อยและได้ผลลัพธ์เป็นชนิดและลักษณะอาการของโรคอ้อย พร้อมทั้งบอกสาเหตุและวิธีการป้องกันหรือควบคุมโรค

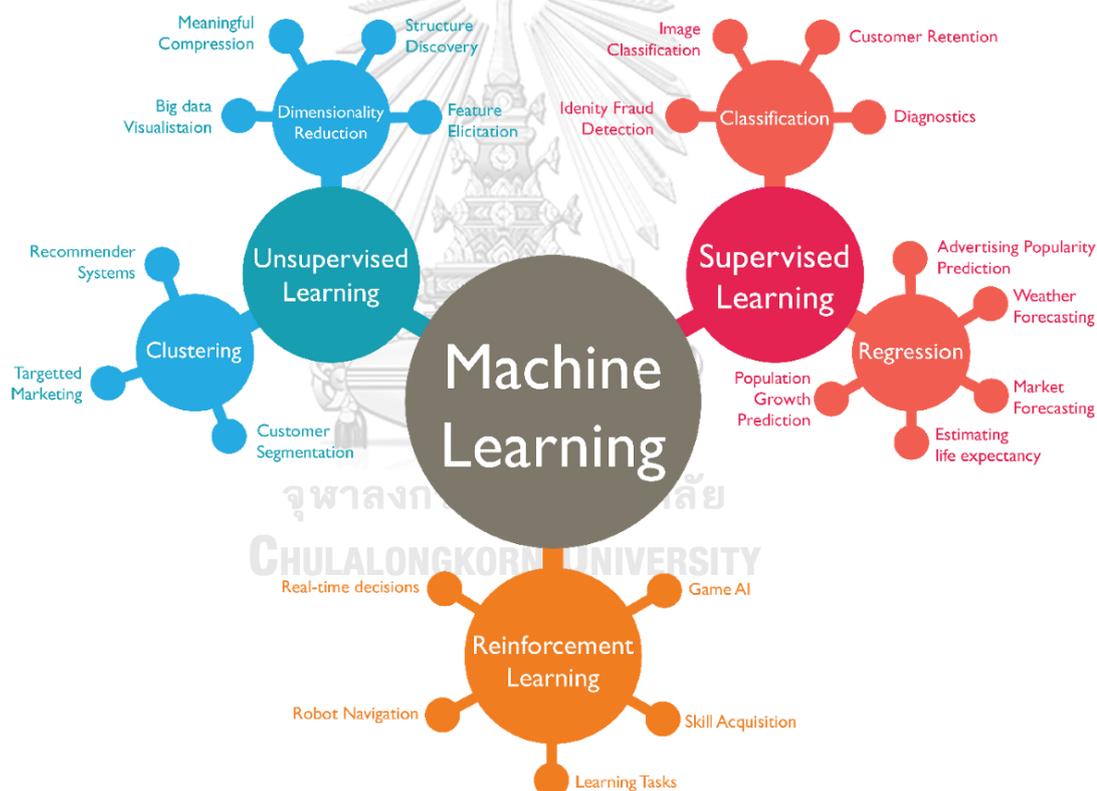


บทที่ 2 หลักการและทฤษฎีที่เกี่ยวข้อง

ทฤษฎีและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์ฉบับนี้ประกอบไปด้วย 4 หัวข้อ ได้แก่ 1.) การเรียนรู้ของเครื่อง 2.) โครงข่ายประสาทเทียม 3.) โรคอ้อยที่เกิดจากเชื้อรา 4.) งานวิจัยที่เกี่ยวข้องกับการจำแนกชนิดและลักษณะอาการของโรคอ้อย

2.1 การเรียนรู้ของเครื่อง (Machine Learning)

การเรียนรู้ของเครื่อง (Machine Learning) เป็นส่วนหนึ่งที่อยู่ในขอบเขตของปัญญาประดิษฐ์ (Artificial Intelligence) รูปแบบหนึ่งที่ใช้วิธีการเรียนรู้จากข้อมูลที่มีมาก่อนหน้า เพื่อให้บรรลุเป้าหมายที่ต้องการ ในการจัดการกับชุดข้อมูลใหม่ได้อย่างเหมาะสม ต่างจากปัญญาประดิษฐ์บางแขนงที่ไม่ได้ใช้วิธีการเรียนรู้ชุดข้อมูลเพื่อให้ประสิทธิภาพการทำงานในอนาคตดียิ่งขึ้น



ภาพที่ 1 ประเภทหลัก ๆ ของ Machine Learning [6]

2.1.1 กลุ่มปัญหาการเรียนรู้ (Learning Problems)

กระบวนการในกลุ่มนี้เรียนรู้จากชุดข้อมูล และสามารถแบ่งเป็นกลุ่มย่อยอีก ได้แก่

1. การเรียนรู้แบบมีผู้สอน (Supervised Learning)

การเรียนรู้แบบมีผู้สอน เป็นการพัฒนาแบบจำลองจากความสัมพันธ์ ระหว่างตัวอย่างที่ป้อนเข้าสู่ แบบจำลอง (Input Examples) กับตัวแปรเป้าหมาย (Target Variable) ชุดข้อมูลที่จะใช้ฝึกกระบวนการในกลุ่มนี้จะต้องมีข้อมูลขาเข้าและผลลัพธ์หรือเรียกอีกอย่างว่าข้อมูลที่ติดป้าย (Labeled) และนำไปใช้ทดสอบประสิทธิภาพกับชุดข้อมูลทดสอบ (Test Set) โดยได้รับเฉพาะข้อมูลขาเข้า (Input) เพียงอย่างเดียวเพื่อสร้างแบบจำลองและนำมาเทียบกับผลลัพธ์จริง ๆ ที่ถูกติดป้ายไว้ว่ามีความถูกต้องมากน้อยเพียงใด การเรียนรู้แบบมีผู้สอนมีวัตถุประสงค์ 2 แบบคือ การแบ่งประเภท (Classification) เป็นการทำนายว่าข้อมูลที่ถูกป้อนเข้าไปจัดอยู่ในกลุ่มใด เช่น การทำนายว่าภาพที่เข้ามาเป็นหมาหรือแมว และการถดถอย (Regression) เป็นการทำนายตัวเลขที่มีความต่อเนื่อง เช่น ราคาของในวันพรุ่งนี้จะลดลงหรือเพิ่มขึ้นเท่าใด ปริมาณของน้ำมันในเดือนหน้าจะขุดได้กี่ลิตร เป็นต้น

2. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

การเรียนรู้แบบไม่มีผู้สอน เป็นการพัฒนาแบบจำลองเพื่อที่จะอธิบาย หรือหาความสัมพันธ์ของข้อมูลและตัวแปรเป้าหมายแต่การเรียนรู้แบบไม่มีผู้สอนจะรับเพียงข้อมูลขาเข้าเพียงอย่างเดียวที่ไม่มีผลลัพธ์หรือการติดป้าย ซึ่งทำให้การเรียนรู้แบบไม่มีผู้สอนนั้นไม่ได้มีข้อมูลขาออกที่จะช่วยปรับแบบจำลองเหมือนกับกรณีของการเรียนรู้แบบมีผู้สอนจะต้องเรียนรู้จากข้อมูลขาเข้าเพียงอย่างเดียว จึงมักใช้เพื่อแบ่งประเภทของข้อมูลเท่านั้น

3. การเรียนรู้แบบกึ่งมีผู้สอน (Semi Supervised Learning)

การเรียนรู้แบบกึ่งมีผู้สอน เป็นการเรียนรู้แบบผสมผสานการเรียนรู้แบบมีผู้สอน (Supervised) และแบบไม่มีผู้สอน (Unsupervised) ซึ่งแบบมีผู้สอนที่ชุดข้อมูลฝึกมีข้อมูลที่ติดป้ายกำกับ (Labeled) เป็นส่วนน้อย และข้อมูลที่ไม่ติดป้ายกำกับ (Unlabeled) เป็นส่วนใหญ่ ซึ่งการเรียนรู้แบบกึ่งมีผู้สอนนี้จะประกอบไปด้วยข้อมูลบางส่วนที่ถูกติดป้ายและข้อมูลบางส่วนที่ไม่ถูกติดป้าย แบบจำลองจะใช้ข้อมูลที่มีการติดป้ายเป็นแนวทางในการเรียนรู้เพื่อที่จะจำแนกชนิดของข้อมูลที่ยังไม่ได้ถูกติดป้าย

4. การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning)

การเรียนรู้แบบเสริมกำลัง (บางครั้งเรียกว่า การเรียนรู้แบบเสริมแรง) เป็นการพัฒนาแบบจำลองที่ใช้งานอยู่แล้วให้มีประสิทธิภาพมากขึ้น แบบจำลองจะถูกใช้งานในสภาพแวดล้อมสถานการณ์และเรียนรู้โดยใช้การป้อนกลับ (Feed Back) การเรียนรู้แบบเสริมแรงจึงไม่มีข้อมูลฝึกที่คงที่ แต่จะใช้เป้าหมาย (Goal) ที่เป็นตัวกำหนดว่าเครื่องต้องทำให้ได้ตามเป้าหมาย การกระทำ (Action) ที่เครื่องจะทำ และ การป้อนกลับเกี่ยวกับ ความสามารถหรือประสิทธิภาพในการเข้าถึงเป้าหมาย มาเป็นข้อมูลสำหรับการเรียนรู้

2.1.2 กลุ่มปัญหาการเรียนรู้แบบไฮบริด (Hybrid Learning Problems)

กระบวนการในกลุ่มนี้จะเป็นกระบวนการที่ใช้เทคนิคต่าง ๆ ผสมผสานกัน และสามารถแบ่งเป็นกลุ่มย่อย ได้แก่

1. การเรียนรู้แบบกึ่งมีผู้สอน (Semi-Supervised Learning)

การเรียนรู้แบบกึ่งมีผู้สอน เป็นการเรียนรู้แบบมีผู้สอนที่ชุดข้อมูลฝึกมีข้อมูลที่มีป้ายกำกับ (Labeled) เป็นส่วนน้อย และข้อมูลที่ไม่มีป้ายกำกับ (Unlabeled) เป็นส่วนใหญ่ ซึ่งการเรียนรู้แบบกึ่งมีผู้สอนนี้จะประกอบไปด้วยข้อมูลบางส่วนที่ถูกติดป้ายและข้อมูลบางส่วนที่ไม่ถูกติดป้าย แบบจำลองจะใช้ข้อมูลที่มีการติดป้ายเป็นแนวทางในการเรียนรู้เพื่อที่จะจำแนกชนิดของข้อมูลที่ยังไม่ได้ถูกติดป้าย

2. การเรียนรู้แบบตัวเองเป็นผู้สอน (Self-Supervised Learning)

การเรียนรู้แบบตัวเองเป็นผู้สอน เป็นการเรียนรู้แบบไม่มีผู้สอนซึ่งทำงานในขอบเขตเหมือนกับการเรียนรู้แบบมีผู้สอน โดยแก้ปัญหาจากงานที่ได้รับมอบหมาย (Pretext Task) ให้กับเครื่อง ตัวอย่างเช่น งานที่ได้รับมอบหมายคือการจัดวางตำแหน่งของชิ้นส่วนรูปที่ถูกต้อง เครื่องจะทำการเรียนรู้และนำชิ้นส่วนรูปที่ไม่มีข้อมูลกำกับมาจัดเรียงในตำแหน่งที่ถูกต้อง

3. การเรียนรู้แบบกลุ่มตัวอย่าง (Multi-Instance Learning)

การเรียนรู้แบบกลุ่มตัวอย่าง เป็นการเรียนรู้แบบมีผู้สอน โดยตัวอย่างแต่ละตัวไม่มีป้ายกำกับ แต่กลุ่มของตัวอย่างจะมีป้ายกำกับ เช่น กลุ่มของกุญแจที่เปิดประตูได้แม้เพียงกุญแจดอกเดียวจะเป็นกลุ่มตัวอย่างบวก และกลุ่มของกุญแจที่ไม่สามารถเปิดประตูได้เลยจะถูกจัดเป็นตัวอย่างลบ การทำงานของวิธีนี้คือเมื่อได้รับกุญแจมาจะสามารถทำนายได้ว่ากุญแจนั้นสามารถเปิดประตูได้หรือไม่

2.1.3 กลุ่มการอนุมานทางสถิติ (Statistical Inference)

กระบวนการในกลุ่มนี้จะเป็นกระบวนการที่ใช้การอนุมานทางสถิติ และสามารถแบ่งเป็นกลุ่มย่อย ได้แก่

1. การเรียนรู้แบบอุปนัย (Inductive Learning)

การเรียนรู้แบบอุปนัย แบบจำลองจะหาข้อสรุปทั่วไปจากข้อมูลฝึก โดยอุปนัยว่าข้อมูลใหม่ที่ได้รับจะยังคงสอดคล้องกับสิ่งที่เรียนมา

2. การเรียนรู้แบบนิรนัย (Deductive Learning)

การเรียนรู้แบบนิรนัย ในบริบทของการเรียนรู้ของเครื่องคือ เมื่อเราใช้การเรียนรู้แบบอุปนัยในการเรียนรู้บนชุดข้อมูลฝึกเพื่อหาแบบจำลอง และแบบจำลองที่ได้นั้นสามารถมีความเหมาะสมที่นำมาใช้ในการทำนายได้ การใช้แบบจำลองในการทำนาย คือ การเรียนรู้แบบนิรนัย

3. การเรียนรู้แบบทรานสดักชัน (Transductive Learning)

การเรียนรู้แบบทรานสดักชัน เป็นการใช้ตัวอย่างเฉพาะในการทำนายผล โดยที่ไม่ได้มีการค้นหาข้อสรุปโดยทั่วไปก่อน

2.1.4 กลุ่มกลวิธีการเรียนรู้ (Learning Technique)

กระบวนการในกลุ่มนี้จะจะเป็นกระบวนการที่ใช้เทคนิควิธีการเรียนรู้ และสามารถแบ่งเป็นกลุ่มย่อย ได้แก่

1. การเรียนรู้แบบหลายภารกิจ (Multi-Task Learning)

การเรียนรู้แบบหลายภารกิจ เป็นการเรียนรู้แบบมีผู้สอนโดยใช้ข้อมูลฝึกเดียวกันในการเรียนรู้งานหลาย ๆ งานที่เกี่ยวข้องกันซึ่งสามารถช่วยเพิ่มประสิทธิภาพการเรียนรู้และความแม่นยำสำหรับการทำนายผลของแบบจำลองเมื่อเทียบกับการฝึกแบบจำลองโดยที่แยกกันฝึก

2. การเรียนรู้เชิงรุก (Active Learning)

การเรียนรู้เชิงรุก แบบจำลองสามารถที่จะร้องขอให้มนุษย์เข้าช่วยในระหว่างกระบวนการเรียนรู้เพื่อแก้ปัญหาที่กำกวมระหว่างกระบวนการฝึก

3. การเรียนรู้แบบออนไลน์ (Online Learning)

การเรียนรู้แบบออนไลน์ เป็นการเรียนรู้โดยใช้ข้อมูลใหม่ ๆ และมีการปรับแบบจำลองโดยตรงก่อนที่จะมีการนำไปใช้ทำนาย

4. การเรียนรู้แบบถ่ายโอน (Transfer Learning)

การเรียนรู้แบบถ่ายโอน เป็นการเรียนรู้จากแบบจำลองที่ถูกฝึกเรียบร้อยแล้วสำหรับงานหนึ่ง ๆ และบางส่วนของหรือทั้งหมดของแบบจำลองนั้นถูกนำมาใช้เป็นจุดเริ่มต้นในงานที่เกี่ยวข้องอื่น ๆ ต่อไป

5. การเรียนรู้แบบร่วมกัน (Ensemble Learning)

การเรียนรู้แบบร่วมกัน เป็นกลวิธีที่ใช้แบบจำลองตั้งแต่ 2 แบบจำลองขึ้นไปในการฝึกบนชุดข้อมูลเดียวกัน และการทำนายจะใช้แบบจำลองทั้งหมดที่ได้มาทำงานร่วมกัน

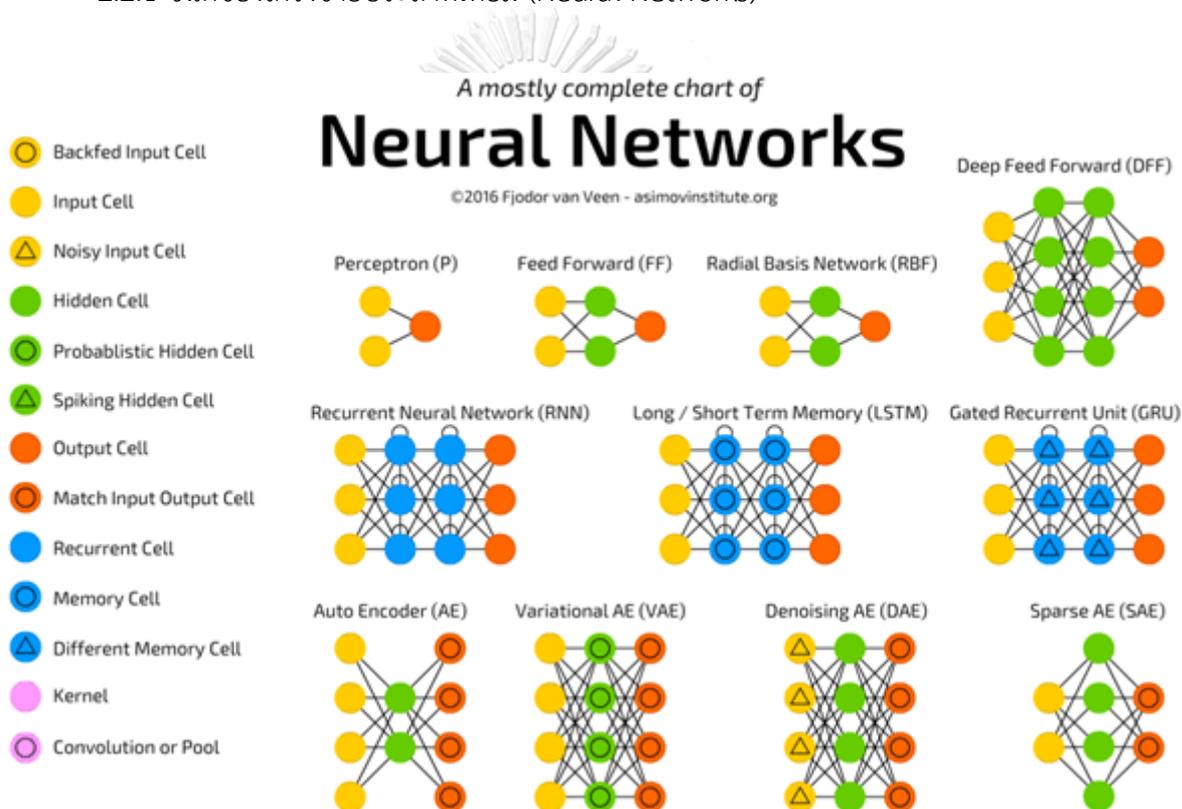
2.2 โครงข่ายประสาทเทียม (Neural Networks)

เป็นระบบการคำนวณที่ได้รับแรงบันดาลใจจาก โครงข่ายประสาทในสมองของสัตว์ โดยโครงข่ายประสาทประกอบไปด้วยเซลล์ประสาท (Neuron) ที่เชื่อมต่อกัน เซลล์ประสาท 1 เซลล์อาจจะเชื่อมต่อกับเซลล์ประสาทอื่น ๆ อีกหลายเซลล์ จำนวนเซลล์ประสาทและการเชื่อมต่อกันในระบบประสาทรุ่นนั้นมีจำนวนมาก การเชื่อมต่อกันของนิวรอนถูกเรียกว่าจุดประสานประสาท

(Synapse) ส่วนมากสัญญาณประสาทถูกส่งจาก โยประสาทนำออก (Axon) ไปยัง โยประสาทนำเข้า (Dendrite)

โครงข่ายประสาทเทียมประกอบไปด้วยเซลล์ประสาทเทียม (Artificial Neuron) ซึ่งจำลองมาจากเซลล์ประสาทในสมอง การเชื่อมต่อกันระหว่างเซลล์ประสาทถูกจำลองด้วย ค่าน้ำหนัก (Weights) ค่าน้ำหนักที่เป็นบวกจำลองการกระตุ้นในสมอง ค่าน้ำหนักที่เป็นลบจำลองสัญญาณการยับยั้งในสมอง ข้อมูลเข้าจะถูกถ่วงด้วยน้ำหนักและความเอนเอียง (Bias) หลังจากนั้นส่งไปยัง ฟังก์ชันกระตุ้น (Activation Function)

2.2.1 ชนิดของโครงข่ายประสาทเทียม (Neural Networks)



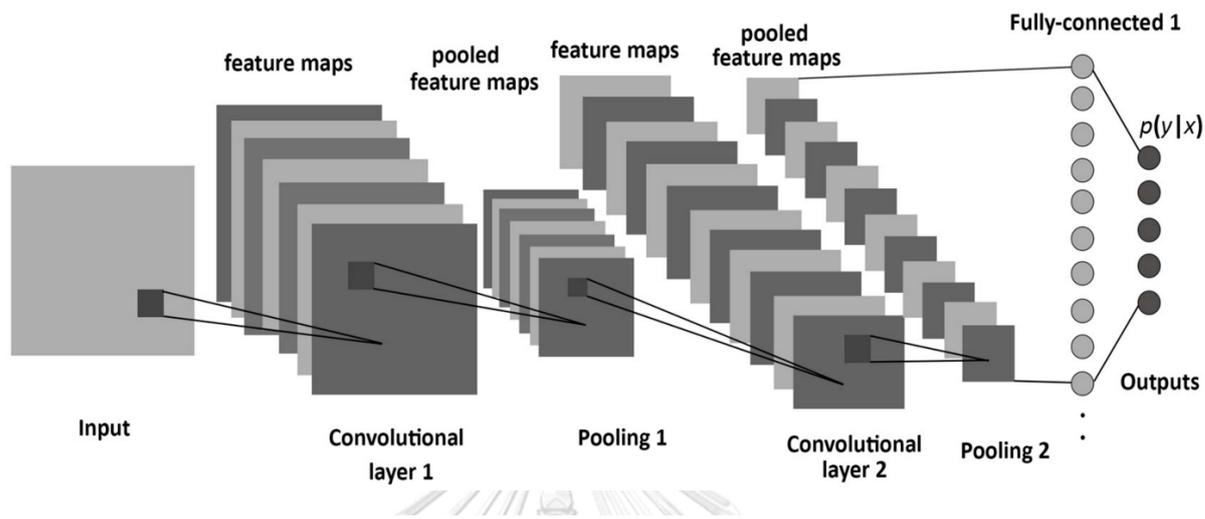
ภาพที่ 2 ชนิดของโครงข่ายประสาทเทียม (Neural Network) ที่ใช้งานในปัจจุบัน

ในส่วนนี้จะเป็นการกล่าวถึงชนิดของโครงข่ายประสาทเทียมที่จะนำไปประยุกต์ใช้กับงานวิจัยชิ้นนี้ โดยจะกล่าวถึง โครงข่ายประสาทเทียมที่พื้นฐานที่สุดคือ Perceptron (P) ซึ่งเป็นพื้นฐานของโครงข่ายเริ่มแรก ทำงานได้เพียงป้อนข้อมูลเข้า Input layer มากกว่า 2 เส้นทาง จากนั้นทำการรวมผลรวมเข้าด้วยกันผ่านฟังก์ชันทางคณิตศาสตร์และให้ผลลัพธ์ออกทาง output layer สำหรับโครงข่ายประสาทเทียมที่มีความซับซ้อนเพิ่มขึ้นมาเป็น โครงข่ายประสาทแบบไปข้างหน้าหรือ Feed forward (FF) ถือเป็นโมเดลที่สามารถอธิบายได้ชัดเจนที่สุด เนื่องจากมีการดำเนินการของ

เส้นทางข้อมูลไปในทิศทางเดียวเหมือนกับ Perception แตกต่างตรงที่จะมีชั้นที่ถูกซ่อน (hidden layer) ระหว่างชั้นข้อมูลขาเข้าและขาออก และอาจจะมีจำนวนชั้นที่มากกว่า 1 ชั้น ขึ้นไป อยู่ในภายใต้โครงข่ายที่ทำให้มีความซับซ้อนในการประมวลผลมากขึ้น โครงข่ายประสาทแบบวนซ้ำ หรือ Recurrent neural network (RNN) เป็นโครงข่ายประสาทแรก ๆ ที่มีการป้อนข้อมูลกลับ (feedback) ภายใน hidden layer ของเส้นทางต่างๆ โดยที่ในแต่ละชั้นจะสามารถคงค่าข้อมูลไว้ในเซลล์ต่าง ๆ ได้ (hold information or store) ส่งผลให้กระบวนการรับข้อมูลทำได้อย่างเป็นลำดับขั้น (data sequences) และให้ผลลัพธ์ทาง output layer อย่างเป็นลำดับเช่นกัน RNN นั้นจะนิยมนำไปใช้ทางด้านข้อมูล เช่น การวิเคราะห์หลักทรัพย์ ความปลอดภัยของข้อมูลทางการเงิน และงานทางด้านลำดับเวลา (time sequences) เช่น วิเคราะห์สัญญาณในแบบโดเมนเวลา (time domain) หรือโดเมนความถี่ (frequency domain) และการวิเคราะห์สัญญาณเสียงต่าง ๆ โครงข่ายประสาทเทียมจะถูกฝึกให้เรียนรู้ผ่านการหาค่าความผิดพลาดด้วยวิธีการแพร่ถอยหลัง (Backward Propagation) เพื่อให้โครงข่ายประสาทเทียมหาความสัมพันธ์ระหว่างข้อมูลขาเข้า และข้อมูลขาออกได้ ส่วนมากโครงข่ายประสาทเทียมแบบไปข้างหน้าจะถูกใช้ร่วมกับโครงข่ายประสาทเทียมอื่น ๆ เพื่อที่จะได้เป็นโครงข่ายประสาทชนิดใหม่

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เป็นการจำลองจากการมองเห็นของมนุษย์ โดยแต่ละเซลล์ประสาทจะมองเห็นเป็นพื้นที่ส่วนย่อย ๆ (Receptive Field) และนำมาประกอบโดยการทับซ้อนบางส่วน (Overlap) [8] เพื่อที่จะรวมเป็นพื้นที่การมองเห็นทั้งหมด โดยจะมีการแยกคุณลักษณะของพื้นที่ย่อยนั้น เช่น เส้นขอบของภาพ สีที่ตัดกันระหว่างวัตถุ ซึ่งมนุษย์จะรับรู้ว่าส่วนไหนที่สีตัดกัน จากความสนใจที่จุดนั้น และบริเวณรอบวัตถุประกอบกัน ในการทำงานของระบบสมองกลฝังตัวจะใช้การคำนวณเชิงคณิตศาสตร์ในการระบุว่าวัตถุนั้นคืออะไร โดยการคำนวณตามแนวคิดนี้ใช้หลักการเดียวกันกับคอนโวลูชันเชิงพื้นที่ (Spatial convolution) จากภาพถ่ายที่ได้และถูกนำมาประมวลผลภาพ เริ่มจากการกำหนดค่าเคอร์เนล (Kernel) ที่ช่วยดึงคุณลักษณะที่ใช้ในการรู้จำวัตถุ ออก การเลื่อนของ Kernel ถูกกำหนดจากค่าของ Stride ที่ถูกกำหนดลงในจุดภาพ (Pixel) แรกของภาพข้อมูล จากนั้นจะถูกเลื่อนไปทาบบนจุดภาพอื่นในภาพจนครบทุกจุดภาพ โดยการทำคอนโวลูชันผลลัพธ์ขนาดของผลลัพธ์ที่ได้จะมี 2 แบบด้วยกัน คือผลลัพธ์มีขนาดเล็กกว่าข้อมูลขาเข้าเนื่องจากการทำคอนโวลูชัน และผลลัพธ์มีขนาดเท่ากับหรือใหญ่กว่าข้อมูลขาเข้าซึ่งเกิดจากการทำ padding โดยอาจจะมีการทำ pooling หลังจากออกจากฟังก์ชันกระตุ้น เพื่อที่จะลดขนาดเชิงพื้นที่ของผลลัพธ์ที่ได้จากการทำคอนโวลูชัน ซึ่งทำให้ลดการใช้พลังงานในการคำนวณให้น้อยลง และใช้ max pooling หาค่าสูงสุดในบริเวณที่ถูกครอบคลุมด้วย kernel อยู่มาเป็นผลลัพธ์ โดยจะเตรียมในลักษณะเดียวกับการทำ Feature extraction มาทาบบนข้อมูลแล้วเลือกค่าที่สูงที่สุดบนตัวกรอนั้น มาเป็นผลลัพธ์ใหม่ และจะเลื่อนตัวกรอนไปตาม Stride ที่กำหนดไว้ โดยขนาดของตัวกรอนของการทำ max pooling จะ

นิยมเรียกว่า pool size กระบวนการทั้งหมดจะใช้กับภาพของใบอ้อย และฝึกให้โครงข่ายประสาทจำแนกชนิดและลักษณะอาการของโรคอ้อย โดยกระบวนการเรียนรู้จะถูกทำซ้ำ เพื่อปรับค่า Weight หลาย ๆ รอบ (Epoch) เพื่อให้ความแม่นยำสูงขึ้น และมีค่าสูญเสีย (Error) ลดลงในแต่ละรอบ



ภาพที่ 3 แนวคิดของโครงข่ายประสาทแบบคอนโวลูชัน (CNN)

2.2.2 ส่วนประกอบของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN)

ในโครงข่ายประสาทเทียมแบบคอนโวลูชันจะมีส่วนประกอบดังนี้

2.2.2.1 ชั้น Conv2D

ชั้น Conv2D เป็นชั้นคอนโวลูชัน 2 มิติ เป็นการทำคอนโวลูชันเชิงพื้นที่ทั่วทั้งภาพ โดยชั้นคอนโวลูชันนี้จะสร้างคอนโวลูชันเคอร์เนลและทำการคอนโวลูชันกับภาพโดยเลื่อนไปยังจุดถัดไปด้วยค่า stride ที่กำหนดไว้ และสามารถกำหนด padding ได้คือ same จะให้ผลลัพธ์ของการทำคอนโวลูชันมีขนาดเท่ากับรูปเดิม และ valid จะเป็นการทำคอนโวลูชันโดยเคอร์เนลจะอยู่บนรูปเดิมนั้น ทำให้ผลลัพธ์มีขนาดที่เล็กลงกว่ารูปเดิม สามารถคำนวณได้จาก สมการดังต่อไปนี้

$$o = \left(\frac{I-K+2P}{s} \right) + 1 \quad (2.1)$$

โดยที่

O คือ ขนาดมิติความกว้างของเมทริกซ์เอาต์พุต (ด้านกว้างยาวเท่ากัน)

I คือ ขนาดมิติความกว้างของเมทริกซ์อินพุต (ด้านกว้างยาวเท่ากัน)

K คือ ขนาดของ Kernel

P คือ ขนาด Padding

S คือ ขนาด Stride

2.2.2.2 ชั้นฟังก์ชันกระตุ้น (Activation Function)

ภายในโครงข่ายประสาทเทียมฟังก์ชันกระตุ้นจะเป็นตัวที่นิยามว่าผลรวมแบบถ่วงน้ำหนัก (Weighted Sum) และบวกด้วยค่าเบี่ยงเบน (Bias) ของข้อมูลขาเข้าจะแปลงไปเป็นข้อมูลออก จาก โหนดในแต่ละชั้นภายในโครงข่ายประสาทเทียมอย่างไร ฟังก์ชันกระตุ้นในโครงข่ายประสาทเทียมที่ นิยมใช้งานจะมีลักษณะที่ไม่เป็นเชิงเส้น (Non-linear) เพื่อที่จะช่วยให้โครงข่ายประสาทเทียม สามารถเรียนรู้ข้อมูลที่ซับซ้อน และได้ผลลัพธ์ที่มีความแม่นยำ โดยฟังก์ชันกระตุ้นมีกระบวนการ ทำงานดังสมการ

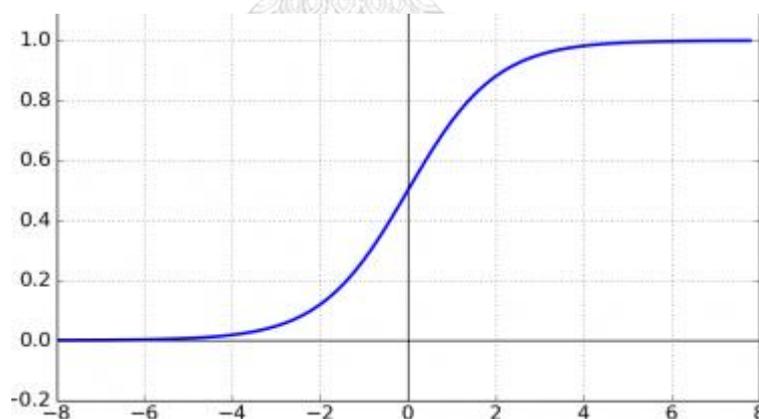
$$Y = \sum(\text{weight} * \text{input}) + \text{bias} \quad (2.2)$$

ชั้นฟังก์ชันกระตุ้นประกอบด้วย

2.2.2.2.1 ชั้นฟังก์ชัน Sigmoid

Sigmoid เป็นฟังก์ชันแบบไม่เป็นเชิงเส้น โดยฟังก์ชันนี้จะแปลงค่าให้อยู่ในช่วง 0 ถึง 1 สามารถอธิบายด้วยสมการ

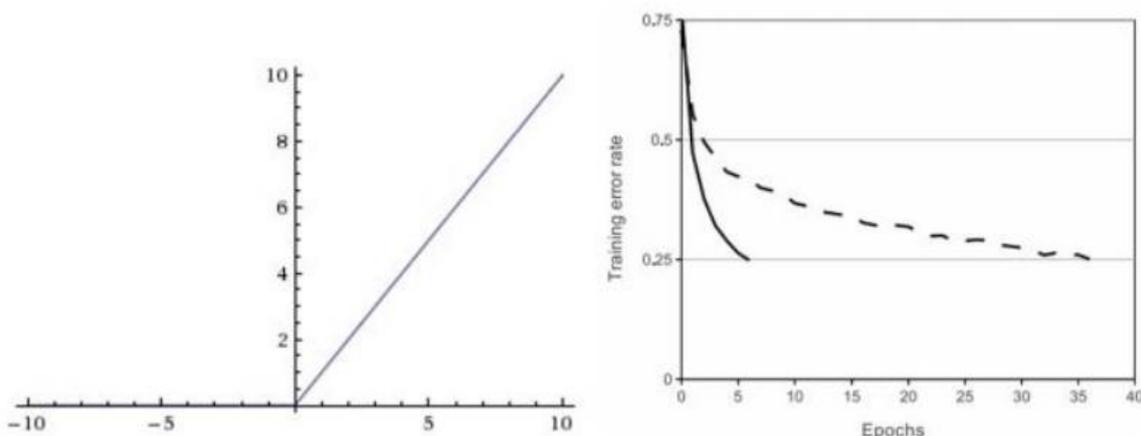
$$S(x) = \frac{1}{1+e^{-x}} \quad (2.3)$$



ภาพที่ 4 Sigmoid Activation Function

2.2.2.2.2 ชั้นฟังก์ชัน ReLU (Rectified Linear Unit)

ฟังก์ชัน ReLU คือการทำ Linear Activation รูปแบบหนึ่งที่มีค่า Threshold อยู่ที่ศูนย์ ซึ่ง ReLU ได้รับความนิยมอย่างมากใน CNN เนื่องด้วยมีงานวิจัยระบุว่าการใช้ ReLU นั้น จะทำให้การฝึก CNN ลู่เข้าเร็วขึ้น และการคำนวณ ReLU หากเทียบกับ tang Sigmoid หรือ Logistic Sigmoid แล้ว สามารถคำนวณได้ง่ายกว่ามาก [7] สามารถอธิบายได้ดังสมการ



$$f(x) = \max(0, x) \quad (2.4)$$

2.2.2.2.3 ชั้นฟังก์ชัน Softmax

ฟังก์ชัน Softmax เป็นฟังก์ชันรูปทั่วไปของฟังก์ชัน sigmoid สามารถใช้ในการจำแนกกลุ่มที่มากกว่า 2 กลุ่ม ซึ่งต่างจากฟังก์ชัน sigmoid ที่สามารถจำแนกได้แค่ 2 กลุ่มเท่านั้น อธิบายได้ดังสมการ

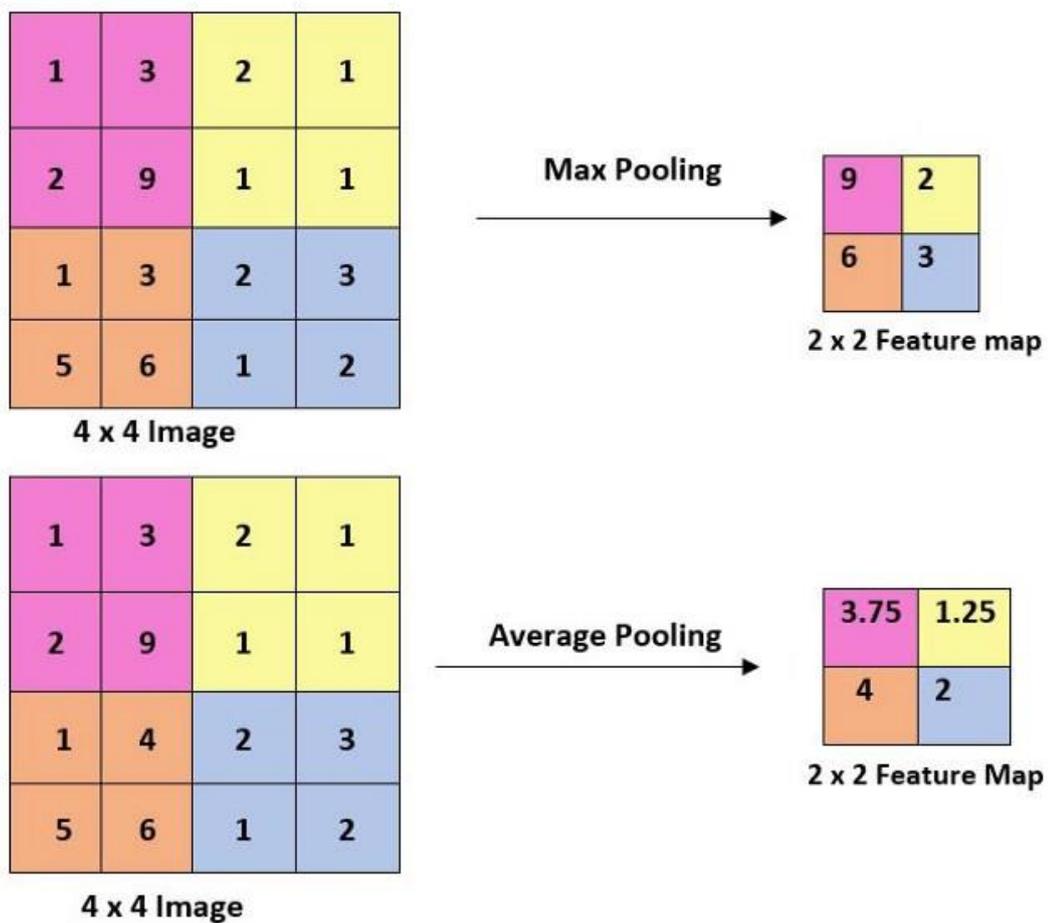
$$\sigma(z)_j = \frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \quad \text{โดยที่ } j = 1, \dots, K \quad (2.5)$$

ภาพที่ 5 ReLU Activation Function (ซ้าย) กราฟแสดงการเปรียบเทียบระหว่างการใช้ ReLU [เส้นทึบ] และ tanh [เส้นปะ] พบว่า ReLU ลู่เข้าเร็วกว่า 6 เท่า (ขวา)

ฟังก์ชัน Softmax จะถูกใช้ในชั้นสุดท้ายของโครงข่ายประสาทเทียมเพื่อใช้ในการจำแนกประเภท

2.2.2.3 ชั้น Pooling

ชั้น Pooling เป็นการลดขนาด (Dimension) ของข้อมูลโดยหลังจากการทำคอนโวลูชันและผ่านฟังก์ชันกระตุ้นเส้นแล้วข้อมูลจะถูกลดขนาด เพื่อลดพลังงานที่ต้องใช้ในการคำนวณ การทำ pooling จะมีอยู่ 2 แบบด้วยกันได้แก่ max pooling และ average pooling โดย max pooling จะเป็นการคืนค่าที่สูงที่สุดของบริเวณที่ถูกครอบคลุมด้วย kernel และ average pooling จะคืนค่าเป็นค่าเฉลี่ยของบริเวณที่ถูกครอบคลุมด้วย kernel



ภาพที่ 6 ชนิดของ pooling layer

2.2.2.4 ชั้น Flatten

เป็นชั้นที่รับ output ที่ได้จากชั้นคอนโวลูชันทำให้ข้อมูลที่อยู่ในหลายมิติ (Dimension) มาเรียงกันให้มีขนาด เพียง 1 มิติ เพื่อส่งต่อไปยังชั้น fully connected layer

2.2.2.5 ชั้น Fully connected

เป็นชั้นที่เชื่อมโยงแต่ละ node ของโครงข่ายประสาทเข้าด้วยกันโดยในชั้นสุดท้ายจะทำการคูณเวกเตอร์ (Dot Product) ของข้อมูลภาพขาเข้า (input) และค่าถ่วงน้ำหนัก (Weight) ของโมเดล

2.2.2.6 ชั้น Dropout

เป็นส่วนที่มีความสำคัญในการปรับแต่งโครงข่ายประสาท เป็นการละทิ้ง node ที่ความสำคัญน้อยหรือไม่มีความจำเป็น เพื่อให้โครงข่ายประสาทมีความแม่นยำสูงขึ้น (Accuracy) และป้องกันการเกิดแบบจำลองเรียนรู้จากข้อมูลขาเข้ามากเกินไป (Overfitting) ในระหว่างการฝึกโครงข่ายประสาทที่สร้างขึ้นได้

2.2.3 วิธีการประเมินความแม่นยำของโครงข่ายประสาทเทียม (Confusion Matrix)

เป็นเครื่องมือในการประเมินผลลัพธ์หรือประเมินประสิทธิภาพของการทำนาย (prediction) หรือการวัดความสามารถของโปรแกรม (machine learning) ในการแก้ปัญหา เปรียบเทียบกับผลลัพธ์จริง

		Actual Value (as confirmed by experiment)	
		positives	negatives
Predicted Value (predicted by the test)	positives	TP True Positive	FP False Positive
	negatives	FN False Negative	TN True Negative

ภาพที่ 7 ตาราง Confusion Matrix

ค่าที่แสดงในตารางประเมินผลลัพธ์ประกอบไปด้วย

1. ค่าจริงเชิงบวก (True Positive; TP) คือกรณีที่โปรแกรมทำนายว่าเป็นบวกและค่าจริงเป็นบวก ตัวอย่างเช่น ความเป็นจริง “ตัดสินใจลงทุน” พบว่า “ราคาหุ้นขึ้น” ผลลัพธ์ “กำไร” แสดงว่าข้อมูลจัดกลุ่มเป็นคลาสบวกอย่างถูกต้อง
2. ค่าจริงเชิงลบ (True Negative; TN) คือกรณีที่โปรแกรมทำนายว่าเป็นลบและค่าจริงเป็นลบ ตัวอย่างเช่น ความเป็นจริง “ตัดสินใจไม่ลงทุน” พบว่า “ราคาหุ้นลง” ผลลัพธ์ “ไม่ขาดทุน” แสดงว่าข้อมูลจัดกลุ่มเป็นคลาสลบอย่างถูกต้อง
3. ค่าเท็จเชิงบวก (False Positive; FP) คือกรณีที่โปรแกรมทำนายว่าเป็นบวกแต่ค่าจริงเป็นลบ ตัวอย่างเช่น ความเป็นจริง “ตัดสินใจลงทุน” พบว่า “ราคาหุ้นลง” ผลลัพธ์ “ขาดทุน” แสดงว่าข้อมูลจัดกลุ่มเป็นคลาสบวกผิด
4. ค่าเท็จเชิงลบ (False Negative; FN) คือกรณีที่โปรแกรมทำนายว่าเป็นลบแต่ค่าจริงคือบวก ตัวอย่างเช่น ความเป็นจริง “ตัดสินใจไม่ลงทุน” พบว่า “ราคาหุ้นขึ้น” ผลลัพธ์ “พลาดโอกาสที่จะได้กำไร” แสดงว่าข้อมูลจัดกลุ่มเป็นคลาสบวกผิด

โดยทั่วไปจะมีตัววัดที่นิยมใช้ในงานวิจัยและการทำงานต่าง ๆ อยู่ 4 ค่า คือ

2.2.3.1 ค่าความแม่นยำ (Accuracy)

ค่าความแม่นยำ (Accuracy) เป็นสัดส่วนที่บอกความสามารถในการทำนายที่ถูกต้องต่อเหตุการณ์ทั้งหมด หากค่า accuracy มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมนั้น ๆ มีความแม่นยำสูง

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad (2.6)$$

2.2.3.2 ค่าความเที่ยงตรง (Precision)

ค่าความเที่ยงตรง (Precision) เป็นสัดส่วนค่าจริงเชิงบวกต่อค่าเชิงบวกทั้งหมด หากค่า precision มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมมีความสามารถในการพยากรณ์ค่าจริงเชิงบวกได้ดี

$$Precision = \frac{TP}{(TP+FP)} \quad (2.7)$$

2.2.3.3 ค่าการเรียกคืน (Recall)

ค่าการเรียกคืน (Recall) เป็นการบ่งบอกความสามารถในการพยากรณ์ได้อย่างถูกต้องเมื่อรู้ภายหลังว่าเหตุการณ์ที่เกิดขึ้นจริงเป็นบวก หากค่า Recall มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมสามารถค้นหาค่าบวกได้ดี เหมาะกับข้อมูลที่มีสัดส่วนข้อมูลที่เป็นบวกน้อย ๆ

$$Recall = \frac{TP}{(TP+FN)} \quad (2.8)$$

2.2.3.4 ค่า F1-Score

ค่า F1 หรือ F-Measure เป็นการบ่งบอกความสามารถของแบบจำลองโครงข่ายประสาทเทียมด้วยการใช้ precision และ recall บางครั้งแบบจำลองที่ได้อาจจะมีความ precision ที่ดีแต่มีค่า recall ที่แย่ และในทางกลับกันแบบจำลองอาจจะมีความ precision ที่แย่แต่มีค่า recall ที่ดี จึงใช้คะแนนทั้งสองในการคำนวณค่า F1 หากค่า F1 มีค่าเข้าใกล้ 1 แสดงว่าแบบจำลองโครงข่ายประสาทเทียมสามารถพยากรณ์ได้ดี

$$F1 \text{ score} = \frac{2*(Precision*Recall)}{(Precision+Recall)} \quad (2.9)$$

2.2.3.5 การบ่งบอกความสามารถด้วยค่า Average Precision (AP)

วิธีการบ่งบอกความสามารถของโมเดลโครงข่ายประสาทที่มีการใช้งานอย่างแพร่หลาย เช่น การตรวจจับวัตถุ (Object detection) ของ PASCAL VOC2015 [7] จะเป็นการบอกด้วยค่า Average Precision (AP) ด้วยการหาพื้นที่ใต้โค้ง (Under curve area) ระหว่าง ค่าความเที่ยงตรง (Precision) และ ค่าการเรียกคืน (Recall) มีค่าอยู่ระหว่าง 0 ถึง 1 หากค่า AP มีค่าเข้าใกล้ 1 แสดงว่าโมเดลโครงข่ายประสาทเทียมนั้นสามารถพยากรณ์ได้อย่างถูกต้องแม่นยำ

$$AP = \int_0^1 p(r)dr = \sum_{i=1}^n P(i)\Delta Re(i) \quad (2.10)$$

$$AP = \sum_{i=1}^n Precision_i(Recall_i - Recall_{i-1}) \quad (2.11)$$

เมื่อ AP คือพื้นที่ใต้โค้งของค่าความเที่ยงกับค่าการเรียกคืน $p(r)dr$ คือฟังก์ชันความสัมพันธ์ระหว่างค่าความเที่ยงกับค่าการเรียกคืน n คือจำนวนจุดตัดข้อมูลในช่วงกราฟ $P(i)$ คือช่วงค่าความเที่ยงตรงในพื้นที่ใต้โค้ง และ $\Delta Re(i)$ คือการเปลี่ยนแปลงของค่าการเรียกคืน

2.2.3.6 การบ่งบอกความสามารถด้วยค่า Mean Average Precision (mAP)

เนื่องจากระบบที่ใช้โครงข่ายประสาทในการจำแนกข้อมูลออกเป็นกลุ่มนั้น จะนิยมแยกออกเป็นมากกว่า 1 คลาส เช่น โรคเส้นกลางใบแดง (Red Rot) โรคราสนิม (Rust) โรคใบจุดวงแหวน (Ring Spot) โรคใบขาว (White Leaf) และใบปกติ (perfect) ในการบ่งบอกว่าโมเดลโครงข่ายประสาทเทียมที่ใช้มีความสามารถในการจำแนกข้อมูลแต่ละคลาสได้แม่นยำแค่ไหน จึงจำเป็นต้องนำค่า Average Precision ของแต่ละคลาสมาค่าเฉลี่ย หากค่า mAP มีค่าเข้าใกล้ 1 แสดงว่าโมเดลโครงข่ายประสาทเทียมนั้นมีความสามารถในการพยากรณ์ได้อย่างถูกต้องแม่นยำในทุกคลาส

$$mAP = \frac{1}{n_{classes}} \sum AP_{classes} \quad (2.12)$$

ในการฝึกโมเดลของโครงข่ายประสาทนั้น นอกจากจะสนใจค่าความแม่นยำแล้ว (Accuracy) อีกสิ่งหนึ่งที่ต้องให้ความสำคัญไม่แพ้กัน คือ ค่าสูญเสีย (Loss) ซึ่งโดยปกติแล้วหากค่าความแม่นยำของโมเดลที่ดีควรเข้าใกล้ร้อยละ 100 และมีค่าสูญเสียต่ำที่สุด (Minimize) หนึ่งในวิธีการสามารถใช้การเรียนรู้ที่ถดถอย (Regression) มาช่วยวัดผลการพยากรณ์อย่างต่อเนื่อง เพื่อดูค่าความคลาดเคลื่อนของการพยากรณ์ (Error) เช่น การสร้างฟังก์ชันการสูญเสีย (Loss function) โดยใช้การถดถอยเชิงเส้น (Linear regression) เพื่อดูค่าความคลาดเคลื่อนระหว่างค่าจริงกับค่าพยากรณ์ เป็นต้น

2.3 สถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Architecture of CNN)

ในงานวิจัยนี้จะกล่าวถึงสถาปัตยกรรมของโครงข่ายประสาทเทียมแบบคอนโวลูชันที่นำไปใช้ได้แก่

2.3.1 VGGNet

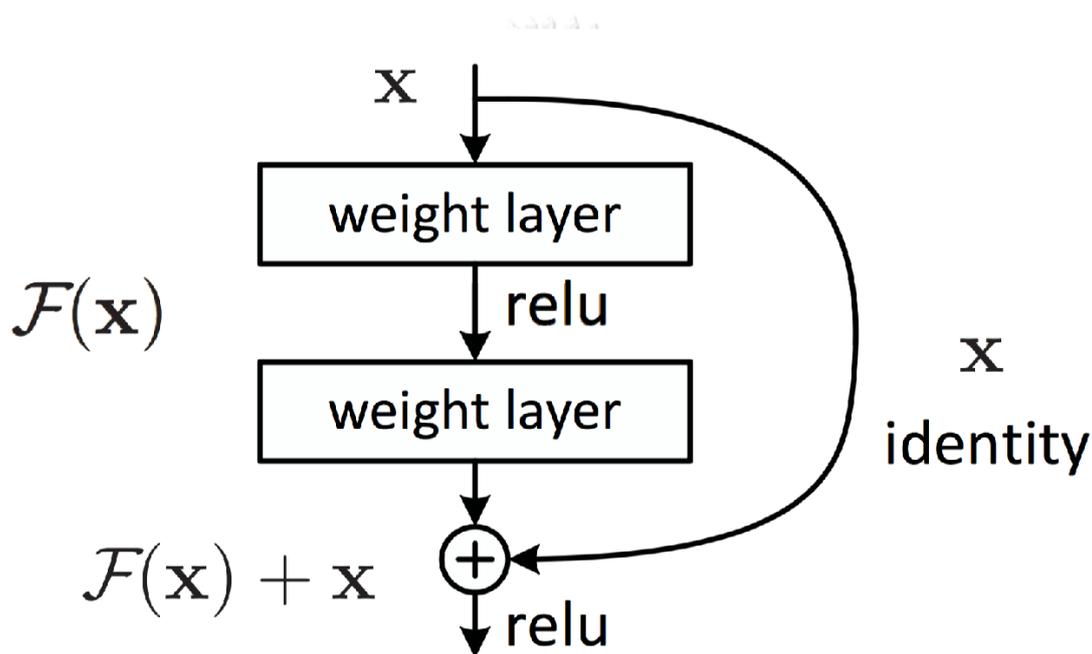
Karen Simonyan [8] ได้วิเคราะห์ความลึกของชั้นคอนโวลูชันหรือการทำโมเดลให้ซับซ้อนมากขึ้น โดยให้พารามิเตอร์อื่น ๆ นอกเหนือจากความลึกเป็นพารามิเตอร์ควบคุม และใช้ฟิลเตอร์คอนโวลูชันขนาด 3×3 ทำให้ได้โครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีความแม่นยำมากขึ้นและได้รับรางวัลรองชนะเลิศในงาน ILSVRC ปี 2014

input (224 × 224 RGB image)					
conv3-64	conv3-64 LRN	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64	conv3-64 conv3-64
maxpool					
conv3-128	conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128	conv3-128 conv3-128
maxpool					
conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256	conv3-256 conv3-256 conv1-256	conv3-256 conv3-256 conv3-256	conv3-256 conv3-256 conv3-256 conv3-256
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512	conv3-512 conv3-512 conv1-512	conv3-512 conv3-512 conv3-512	conv3-512 conv3-512 conv3-512 conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

ภาพที่ 8 สถาปัตยกรรมของ VGGNet [8]

2.3.2 ResNet

Kaiming et al [9] ได้นำเสนอขบวนการเรียนรู้แบบ residual learning หรือ residual block ชั้นของโครงข่ายประสาทเทียมถูกฝึกด้วยการนำข้อมูลขาเข้าของชั้นก่อนหน้ามาเป็นข้อมูลขาเข้าร่วมกับผลลัพธ์ขาออกจากชั้นก่อนหน้าแทนการใช้ผลลัพธ์ขาออกจากชั้นก่อนหน้ามาเป็นข้อมูลขาเข้าเพียงอย่างเดียว ซึ่งช่วยในเรื่องของการรวม feature ในหลายระดับ ทำให้สามารถปรับแต่ง (Optimize) โครงข่ายประสาทเทียมที่มีความซับซ้อนได้ง่ายขึ้นและยังทำให้ได้ความแม่นยำสูงขึ้น ซึ่งได้รับรางวัลชนะเลิศในงาน ILSVRC ปี 2015



ภาพที่ 9 หลักการของ residual learning หรือ residual block [9]

2.4 โรคอ้อยที่เกิดจากเชื้อรา

ในงานวิจัยนี้ได้ทำการนำรูปภาพโรคอ้อยทั้งสิ้น 4 โรค มาใช้สำหรับการฝึก โดยสาเหตุของโรคเกิดจากเชื้อรา ซึ่ง 4 โรคร้ายนี้เกิดขึ้นกับอ้อยพันธุ์ขอนแก่น 3 เป็นพันธุ์อ้อยที่เกษตรกรชาวไร่อ้อยนิยมปลูก แทบจะเป็น 80% ของพื้นที่ปลูกอ้อยในประเทศไทย เหตุผลคือ ขอนแก่น 3 ให้ผลผลิตสูงถึง 15-20 ตันต่อไร่ ให้ความหวาน 12-14 ซีซีเอส ที่สำคัญคือ ทนแล้ง และไว้ต่อดี โรคที่เกิดมาจากการสะสมโรคในท่อนพันธุ์ และเกิดจากสภาพแวดล้อมที่เหมาะสมกับการระบาด ได้แก่

2.4.1 โรคเน่าแดงหรือโรคเส้นกลางใบแดง (Red rot disease)

- สาเหตุของโรค : เชื้อรา *Colletotrichum falcatum*

- การแพร่ระบาด :
 - เชื้อติดไปกับท่อนพันธุ์ที่เป็นโรค สามารถแพร่กระจายเชื้อต่อไปได้ โดยสปอร์สามารถกระจายไปกับลมและน้ำฝน
 - เชื้อรา *Colletotrichum falcatum* เข้าทำลายได้ตามรอยแผลที่เกิดจากหนอนหรือแผลแตกของลำ
 - โรคจะระบาดรุนแรงในพื้นที่ที่มีความชื้นสูง เช่น ในเขตชลประทานหรือที่นา
- ลักษณะอาการ : เชื้อสาเหตุของโรคสามารถเข้าทำลายอ้อยทุกส่วน ตั้งแต่เป็นท่อนพันธุ์ ทำให้ท่อนพันธุ์เน่าไม่งอก ส่วนที่สำคัญและเสียหายมากที่สุด คือ การเข้าทำลายที่ลำต้น สำหรับอาการบนใบ จะเริ่มต้นเป็นจุดยาวบนเส้นกลางใบด้านบนของใบ จุดนี้อาจมีสีน้ำตาลแดงเข้ม แล้วเปลี่ยนเป็นสีฟางที่มีขอบสีม่วง และมีจุดดำเล็ก ๆ ในบางครั้งเชื้ออาจเข้าทำลายใบอ้อยทำให้เกิดเป็นจุดแดงเล็ก ๆ บนเนื้อใบ
- การควบคุมโรค :
 - ไถแปลงอ้อยที่เป็นโรครุนแรงทิ้ง และคราดตออ้อยเก่าออกให้หมด
 - ปลูกพืชหมุนเวียน ยกเว้นพืชอาศัยของเชื้อสาเหตุ เช่น ข้าวฟ่าง ข้าวโพด ถั่วเขียว
 - ตากดินนานเกินกว่า 3 เดือนก่อนปลูกอ้อยใหม่ ปรับปรุงดินกรดด้วยปูนขาว และเตรียมดินให้ระบายน้ำดี
 - ก่อนปลูกอาจมีการแช่ท่อนพันธุ์อ้อยในสารเคมีกำจัดโรคพืช เบนโนมิล 50% ดับบลิวพี อัตรา 20 กรัมต่อน้ำ 20 ลิตร หรือ ไธโอฟาเนตเมธิล 70% ดับบลิวพี อัตรา 15 กรัมต่อน้ำ 20 ลิตร นาน 30 นาทีก่อนปลูก และ 0.1% คาร์เบนดาซิม 15 นาที ก่อนปลูก และพ่นสารดังกล่าวบริเวณโคนกออ้อยเดือนละครั้ง ระหว่างที่อ้อยอายุ 1-5 เดือน
 - แช่ท่อนพันธุ์ ด้วยน้ำร้อน 52 องศาเซลเซียส เป็นเวลา 4-5 ชั่วโมง หรืออบด้วยไอร้อนชั้นที่ 54 องศาเซลเซียสเป็นเวลา 2 ชั่วโมง

2.4.2 โรคราสนิม (Rust disease)

- สาเหตุของโรค : เชื้อรา *Puccinia melanocephala*
- การแพร่ระบาด : สามารถเกิดขึ้นได้อย่างรุนแรงเมื่ออากาศมีความอบอุ่น และมีความชื้นสูง อุณหภูมิที่เหมาะสมต่อการเจริญของสปอร์เชื้ออยู่ระหว่าง 15-30 องศาเซลเซียส เมื่อสภาพอากาศชื้นจะเอื้ออำนวยต่อการสร้างสปอร์การเข้าทำลาย และการแพร่กระจายของโรคมามากขึ้น นอกจากนี้ยังพบว่าดินที่มีค่าความเป็นกรดและมีปริมาณของฟอสฟอรัส โพแทสเซียมสูง จะส่งผลให้เกิดโรคราสนิมมากขึ้น

- ลักษณะอาการ : เป็นโรคสำคัญที่เกิดบริเวณใบของอ้อย เชื้อราจะเข้าทำลายบริเวณใบที่อยู่ล่างๆ จากนั้นจะสร้างกลุ่มสปอร์ใต้ใบอ้อย ในบางพันธุ์อาจพบกลุ่มสปอร์สร้างอยู่บนใบสปอร์ของเชื้อนี้สามารถมีชีวิตเพื่ออยู่ข้ามฤดูได้ อาการระยะแรกเป็นจุดแผลขนาดเล็กมีสีเหลืองทั้งบนใบและใต้ใบ ต่อมาแผลขยายในแนวยาว เปลี่ยนเป็นสีน้ำตาลอมส้มหรือน้ำตาลแดง ขอบแผลมีสีเหลืองล้อมรอบใบ ทำให้อ้อยสูญเสียพื้นที่การสังเคราะห์แสง โดยที่ใบอ้อยที่เป็นโรคจะแห้งกว่าก่อนที่ใบจะแก่ การเจริญของอ้อยไม่สมบูรณ์
- การควบคุมโรค :
 - เนื่องจากสปอร์ของเชื้อราสาเหตุโรคปลิวแพร่กระจายไปตามลม จึงควรหลีกเลี่ยงการปลูกพันธุ์อ้อยที่อ่อนแอต่อโรคเป็นพื้นที่กว้าง เพื่อไม่ให้โรคมีการระบาดรุนแรง
 - ใช้พันธุ์อ้อยที่ต้านทานต่อโรค และหลีกเลี่ยงการใช้พันธุ์อ้อยที่อ่อนแอ และอาจมีการทำแปลงพันธุ์อ้อยที่แยกแตกต่างไว้เป็นต้นพันธุ์
 - เมื่อพบส่วนของอ้อยที่เป็นโรค ควรมีการเก็บออกจากแปลงอ้อยเผาทำลายทิ้งรวมทั้งกำจัดวัชพืช
 - ในกรณีที่เพิ่งพบโรคราสนิม อาจมีการใช้สารเคมีเช่น เพอร์แบมไซแรม ไตรอะไดมีฟอนหรือเมตาแล็กซิล ซึ่งสามารถทำลายเชื้อโรคราสนิมได้แต่หากต้องใช้สารเคมีฉีดพ่นให้ทั่วแปลงนั้นอาจมีการสิ้นเปลืองมาก ไม่คุ้มค่ากับการใช้จ่าย

2.4.3 โรคใบจุดวงแหวน (Ring spot disease)

- สาเหตุของโรค : เชื้อรา *Leptosphaeria sacchari*
- การแพร่ระบาด : สามารถงอกได้เมื่อได้รับความชื้นบนใบที่เพียงพอ และโรคอาจมีการระบาดได้มากในสภาพที่มีความชื้นสูง ซึ่งในต่างประเทศมีการรายงานว่าพบโรคนี้สูงสุดในช่วงฤดูหนาว
- ลักษณะอาการ : เริ่มแรกเป็นจุดสีเขียวขุ่นน้ำ ต่อมาเปลี่ยนเป็นสีเขียวเข้มขอบสีน้ำตาล หรือจุดสีน้ำตาลเล็ก ๆ ตรงกลางมีสีขาวลักษณะคล้ายรูปไข่ ต่อมาแผลเปลี่ยนเป็นสีน้ำตาลแดง และมีสีเหลืองล้อมรอบ (halo) เมื่อแผลขยายใหญ่ขึ้น ภายในแผลก็จะแห้งสีคล้ายสีฟางข้าว และขอบแผลเป็นสีน้ำตาลถึงน้ำตาลเข้ม เมื่อเกิดแผลจำนวนมากติดต่อกันใบจะไหม้เป็นบริเวณกว้าง
- การควบคุมโรค :
 - กำจัดใบที่เป็นโรคออกและเผาทำลายเสีย
 - ทำความสะอาดและกำจัดวัชพืชในแปลงปลูก

- ปลุกพืชหมุนเวียนทุก ๆ 2 ปี โดยใช้ ข้าว ข้าวโพด ถั่ว หรือผักต่าง ๆ

2.4.4 โรคใบขาว (White leaf disease)

- สาเหตุของโรค : เชื้อไฟโตพลาสมา (Phytoplasma)
- การแพร่ระบาด : โรคใบขาวของอ้อยแพร่ระบาดโดยมีเชื้อติดไปกับท่อนพันธุ์อ้อย นอกจากนี้ยังมีเพลี้ยจักจั่นสีน้ำตาลปีกลาย (*Matsumuratettix hiroglyphicus*) เป็นแมลงพาหะถ่ายทอดเชื้อจากกออ้อยที่เป็นโรคไปยังกออ้อยปกติในไร่ พบจำนวนมากในช่วงฤดูฝน ระบาดรุนแรงในเขตพื้นที่ปลูกอ้อยที่เป็นดินทรายภาคตะวันออกเฉียงเหนือ
- ลักษณะอาการ : โรคใบขาวสามารถเกิดขึ้นได้กับทุกระยะการเจริญเติบโตของอ้อย โดยอาการจะปรากฏให้เห็นได้ชัดเจนในระยะกล้าอ้อยแตกกอฝอยมีหน่อเล็ก ๆ ที่มีใบสีขาวจำนวนมาก คล้ายกอหญ้า หน่อไม่เจริญเป็นลำ หากอาการโรครุนแรงอ้อยจะแห้งตายทั้งกอ ในที่สุด หากหน่ออ้อยในกอเจริญเป็นลำได้ ลำอ้อยที่ได้จะไม่สมบูรณ์
- การควบคุมโรค :
 - ไถทำลายแปลงอ้อยต่อที่เป็นโรครุนแรงทิ้งเพื่อไม่ให้เป็นแหล่งระบาดของเชื้อ
 - คราดตอเก่าออกให้หมด ปลูกพืชบำรุงดินหมุนเวียน และไถกลบเป็นปุ๋ยพืชสด ก่อนปลูกอ้อยใหม่
 - เลือกฤดูปลูกให้เหมาะสม (ตุลาคม-ธันวาคม) เพื่อลดการติดเชื้อจากแมลงพาหะที่ระบาดในฤดูฝน [10]

2.5 งานวิจัยที่เกี่ยวข้องกับการจำแนกชนิดและลักษณะอาการของโรคอ้อย

สำหรับการประมวลผลภาพเพื่อใช้ในการวิเคราะห์ และการจำแนกชนิดของวัตถุนั้น มีการใช้เทคนิคต่าง ๆ หลายรูปแบบ โดยมีวัตถุประสงค์ให้การวิเคราะห์ภาพมีความง่ายมากขึ้น วิธีการจำแนกโรคอ้อยในรูปแบบที่ปรากฏจะอาศัยวิธีการประมวลผลภาพด้วยวิธีการทางขั้นตอนวิธีและสมการทางคณิตศาสตร์ เช่น การจำแนกความแตกต่างของรูปร่าง สี และขนาดของใบอ้อย โดยการแบ่งส่วนภาพ (Image segmentation) ด้วยขั้นตอนวิธี Canny edge, Otsu's method, clustering method ตลอดจนการประยุกต์ใช้โครงข่ายประสาท (Neural network) ในการจำแนกรูปร่างและสีของใบอ้อยจากภาพ แต่ละวิธีการจะใช้ขั้นตอนที่คล้ายกัน คือ การแบ่งส่วนภาพ การดึงคุณลักษณะ และการจำแนกประเภท

Evy Kamilah Ratnasari et al. [11] นำเสนอวิธีการการแบ่งส่วนภาพอย่างแม่นยำ (accurate segmentation) จากการวิเคราะห์รูปร่างของใบอ้อย โดยการเตรียม feature จากการทำ

thresholding กับ color space หลังจากนั้นก็จะนำผลลัพธ์ที่ได้ไปแยกประเภทของโรคด้วยเทคนิค classification (วิธีที่ใช้คือ Support Vector Machine (SVM)) การทำ classify ด้วยการ SVM จะต้องใช้ $L^*a^*b^*$ color space ร่วมกับ Gray Level Co-Occurrence Matrix (GLCM) เพื่อทำ feature โดย model ที่ใช้ในการจำแนกจุดของโรคบนใบอ้อยนี้ให้ผล accuracy ถึง 80% การ segmented image ไม่ได้เพียงแต่จะคำนวณหาจุดบนใบอ้อยแต่ยังสามารถหา interest region โรคบนใบอ้อย เพื่อใช้ในการระบุประเภทของโรคด้วย classification technique โดยใช้ co-occurrence texture in $L^*a^*b^*$ color space. สามารถระบุโรคของอ้อยได้โดยการใช้ SVM classifier ร่วมกับ texture and color features extraction ซึ่ง model นี้ให้ผลลัพธ์หรือ accuracy ที่สูง และ error ของ estimation average ที่ต่ำ อาจจะมีข้อจำกัดในวิธีการ segmentation ที่ใช้ในการทำการทดสอบ เราสามารถพัฒนาระบบให้ดีขึ้นได้โดยการทำ pre-processing ให้กับข้อมูลหรือรูปภาพ หรือใช้วิธี segmentation อื่น ๆ ที่มีประสิทธิภาพมากกว่า เพื่อให้ระบบสามารถทำงานได้ดีขึ้น ตรวจสอบได้แม่นยำขึ้น

Swapnil Dadabhau Daphal et al. [12] ได้นำเสนอวิธีการระบุประเภทของโรคอ้อยทางใบ เพราะสามารถคาดการณ์ระยะของโรคหรือความรุนแรงของโรคที่เกิดขึ้นได้ โดยการใช้ deep neural networks (DNN) และการปรับเปลี่ยนสถาปัตยกรรม Convolutional Neural Network ได้แนะนำประสิทธิภาพที่ดีขึ้นในด้านของ recovery rate (RA) และเวลาในการทำงานที่น้อยลง ซึ่งในการทำ feature extraction มีการนำ ResNet-50 เป็น backbone ในการฝึก ได้ค่าความแม่นยำอยู่ที่ 85.39% เปรียบเทียบกับการนำ DenseNet201 ได้ค่าความแม่นยำอยู่ที่ 86.53% จากการใช้รูปภาพของใบอ้อยไม่ต่ำกว่า 2,000 รูป

Artzai Picom et al. [13] นำเสนอวิธีการระบุโรคอ้อยระยะเริ่มต้นแบบอัตโนมัติบนแอปพลิเคชันในโทรศัพท์มือถือ ได้แก่โรค Septoria, Tan Spot และ Rust ซึ่งได้ใช้ Deep Convolutional Neural Networks (CNNs) ซึ่งชุดข้อมูลภาพ input ที่ใช้นั้นได้ถูกปรับขนาดลดลงอยู่ที่ 224×224 พิกเซล มีการทำ crop image เพื่อดึงส่วนเฉพาะที่สนใจ นอกจากนั้นยังมีวิธี Superpixel based tile extraction เป็นการแยกเฉพาะส่วนที่สนใจโดยอาศัยวิธีการ Simple Linear Iterative Clustering (SLIC) ซึ่งจะสนใจจุดที่มีความเป็นเนื้อเดียวกันหรือใกล้เคียงกันมากที่สุด ได้ค่าความแม่นยำอยู่ที่ 87%. จากการใช้รูปภาพของใบอ้อยทั้งหมด 8,178 รูป

Umapathy Eaganathan et al. [14] ในวิจัยฉบับนี้ ได้ทำการแยกอ้อยปกติและอ้อยที่เป็นโรคใบแห้ง (Leaf scorch disease) โดยการใช้วิธี acquisition, filtering, segmentation และ feature extraction โดยการทดลองได้ให้ accuracy อยู่ที่ 95% โดยการทำ feature extraction

นั้น ได้มีการใช้วิธีการ histogram สีของใบอ้อยและทำการ convert ภาพไปในรูปแบบ gray scale โดยกราฟของวิธีการทำนี้ แสดงให้เห็นถึงค่าความแตกต่างของสีที่เกิดจากอาการผิดปกติของใบอ้อยที่เป็นโรคได้อย่างชัดเจน และการทำ segmentation เพื่อแยกรูปใบออกจากพื้นหลังได้มีการนำ K-mean มาช่วยในการแยกภาพ

P. DharaniDevi et al. [15] บทความนี้จะมีความเหมือนกับบทความข้างต้นคือ วิธีการระบุและแยกประเภทและระบุชนิดของโรคที่เกิดขึ้นในอ้อยให้ได้ในระยะเริ่มต้น โดยการใช้วิธี acquisition, filtering, segmentation และ feature extraction แต่สิ่งที่แตกต่างจากบทความก่อนหน้า คือ ได้ทำการขยาย pixels dynamic range ใน RGB colorspace โดยการใช้ image processing algorithms เพื่อให้ได้ภาพหรือรูปที่มีคุณภาพที่ดีขึ้น ต่อด้วยวิธีการทำ feature extraction เพื่อแยกประเภทของใบอ้อยว่าติดโรคหรือไม่ และจำแนกโรคต่าง ๆ ของอ้อยได้ด้วยวิธี classification ผลการทดลองที่ได้ คือ การ classify โดยใช้ K-NN Classifier ให้ผลลัพธ์หรือ accuracy ที่ 98%. จากผลลัพธ์จะเห็นว่าสามารถแยกใบอ้อยที่ปกติออกจากใบอ้อยที่เป็นโรคได้เกือบสมบูรณ์

Anoop G L. [16] ได้มีการทดลองการตรวจโรคจากใบอ้อยด้วยวิธีการ grey scale และ color image processing ซึ่งได้ทำการวิเคราะห์เปรียบเทียบผลลัพธ์จากวิธีการทั้งสอง ใน grey scale ได้ใช้วิธี Gradient Magnitude, Otsu method, Morphological Operations และ Normalization เพื่อให้ได้พื้นที่ของโรคบนใบอ้อยที่สนใจ ในส่วนของ color processing ทำการแปลง RGB ให้เป็น L*a*b format หลังจากที่ได้ L*a*b image แล้ว ใช้ K-means clustering และ edge detection operations เพื่อให้ได้ feature ที่ต้องการ หลังจากได้ feature ที่ต้องการแล้ว จึงนำ feature นี้ไป classify ต่อโดยใช้ระบบ Support Vector Machine (SVM) classifier ระบบนี้จะทำการแยก feature หรือรูปภาพออกเป็น class ต่าง ๆ ตามโรคที่ระบุได้ เช่น ring, rust และ yellow spot sugarcane leaf diseases ผลลัพธ์ที่ได้จากการวิเคราะห์ คือ features ที่ได้จากการทำ color processing ให้ผลลัพธ์ในการจำแนกโรคในใบอ้อยได้ดีกว่าการใช้วิธี grey scale โดย color processing ตรวจจับได้ 100% ในโรคใบเหลือง Yellow leaf disease เพราะความแตกต่างของโรค (สีเหลืองจากโรคบนใบอ้อย) แต่ใน ring และ rust leaf disease การใช้วิธี grey scale และ color processing ให้ผลลัพธ์ที่คล้ายกันคือประมาณ 80-90% เพราะความคล้ายคลึงกันของโรค (สีของโรคหรือลักษณะของโรคมีความคล้ายกันทำให้จำแนกความแตกต่างได้ไม่สมบูรณ์)

บทที่ 3 การพัฒนาขั้นตอนวิธีสำหรับจำแนกโรคอ้อย

ผู้วิจัยทำการศึกษาข้อมูลโรคอ้อยที่เคยพบในพื้นที่ปลูกอ้อยของประเทศไทยจากเอกสารที่เคยมีรายงานไว้ และสำรวจโรคอ้อยในประเทศไทย รวบรวมข้อมูล และประมวลเป็นข้อมูลโรคอ้อยทุกโรคในประเทศไทย จากนั้นพิจารณาคัดเลือกโรคอ้อยที่น่าสนใจ 4 โรค โดยพิจารณาจากลักษณะอาการผิดปกติของอ้อยที่สังเกตพบ การแพร่ระบาดในแปลง ความชัดเจนที่สามารถสังเกตได้ด้วยสายตาของอาการที่ปรากฏบนใบ รวมทั้งรูปร่างหรือรูปทรง และสีของอาการของโรคที่เกิดขึ้น [3] เพื่อนำทั้ง 4 โรค ที่ผ่านการประเมินจากผู้เชี่ยวชาญ ซึ่งได้แก่ โรคเน่าแดงหรือโรคเส้นกลางใบแดง โรคราสนิม โรคใบจุดวงแหวน และโรคใบขาว เป็นข้อมูลให้ทางเกษตรกรชาวไร่อ้อยรับทราบ ชนิดของโรค สาเหตุ ความรุนแรง และวิธีการควบคุม

3.1 ศึกษาและวิเคราะห์ข้อมูลอาการผิดปกติของใบอ้อยที่เกิดจากโรค

3.1.1 รวบรวมตัวอย่างใบอ้อยที่ติดเชื้อ

ลงพื้นที่เก็บข้อมูลภาพถ่ายโรคอ้อยที่ศูนย์ส่งเสริมอุตสาหกรรมอ้อยและน้ำตาลทรายภาคที่ 3 จังหวัดชลบุรีและพื้นที่ไร่อ้อยของเกษตรกร นายดิเรก แซ่ฮ้อ ที่ตั้งหมู่ 6 ตำบลวัดสุวรรณ อำเภอบ่อทอง จังหวัดชลบุรี โดยในพื้นที่นั้นได้มีการใช้อ้อยพันธุ์ขอนแก่น 3 ในการเพาะปลูก โดยข้อมูลภาพนั้นจะถูกเก็บไว้ในรูปแบบ JPG หรือรูปแบบ PNG โดยใช้รูปแบบสี RGB



ภาพที่ 10 ศูนย์ส่งเสริมอุตสาหกรรมอ้อยและน้ำตาลทรายภาคที่ 3 จังหวัดชลบุรี



ภาพที่ 11 แปลงไร่อ้อยของเกษตรกร

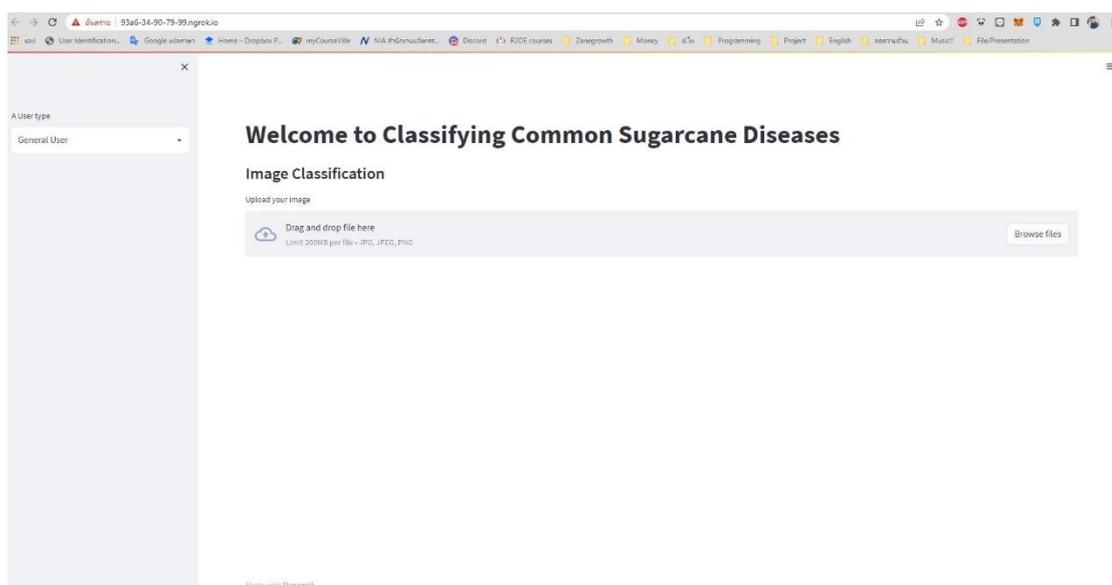
3.1.2 ออกแบบและสร้างฐานข้อมูลเพื่อจัดเก็บข้อมูลของโรคอ้อย

ออกแบบและสร้างฐานข้อมูลเพื่อจัดเก็บข้อมูลของโรคอ้อย เพื่อเป็นฐานข้อมูลสนับสนุนการจำแนกชนิดและลักษณะอาการของโรคอ้อยด้วยระบบคอมพิวเตอร์ โดยจะมุ่งเน้นไปที่การเก็บข้อมูลเพื่อจำแนกชนิดและลักษณะอาการของโรคอ้อยที่คัดเลือก

3.2 การพัฒนาระบบเว็บแอปพลิเคชันสำหรับโครงการวิจัย

ซอฟต์แวร์ที่ใช้ในการพัฒนาระบบจำแนกโรคอ้อยเป็นรูปแบบเว็บแอปพลิเคชัน (Web Application) ทำงานบนเว็บไซต์โดยเรียกใช้งานผ่านทางออนไลน์ทั้งระบบอินเทอร์เน็ต (Internet) ไม่ต้องติดตั้งซอฟต์แวร์บนอุปกรณ์ของผู้ใช้ลดการใช้จ่ายงานทรัพยากรที่ไม่จำเป็น เพื่อให้ผู้ใช้งานสามารถใช้งานได้ง่ายผ่านเบราว์เซอร์ (Browser) เช่น Safari Firefox Google Chrome บนอุปกรณ์ต่างๆ เช่น คอมพิวเตอร์ แท็บเล็ต สมาร์ทโฟน เป็นต้น ซึ่งส่วนใหญ่การทำ Web Application ที่ทำงานร่วมกับ Machine learning model ที่ไม่ซับซ้อนจะเขียนด้วยภาษา HTML แต่พอดึงใช้งานกับ Machine learning model ที่มีความซับซ้อนมากขึ้น เช่น การทำ Features engineer การจัดการเรื่อง Imputation รวมไปถึงการ Training model ที่มีความซับซ้อนทำให้ทักษะ HTML ที่มีไม่เพียงพอ [17]

ดังนั้นในวิจัยฉบับนี้จึงเลือกใช้ Streamlit ซึ่งเป็นไลบรารี Python ที่มีการ Implement ง่ายกว่าการเขียน HTML ร่วมกับ Machine learning model เพราะ Streamlit ไม่จำเป็นต้องใช้ไลบรารี API เช่น Flask เป็นตัวช่วยในการติดต่อ ทำให้สามารถเขียน Web Application ได้โดยตรง ยิ่งเป็นภาษา Python เหมือนกันทำให้การทำงานกับ Object อื่นๆ ไม่ว่าจะเป็น Pandas DataFrame หรือ Figure จาก Matplotlib ก็เป็นเรื่องง่ายเช่นกัน ดังนั้นการ Integrate ML Model จาก Tensorflow หรือ Scikit-learn ย่อมทำได้ง่ายกว่า HTML

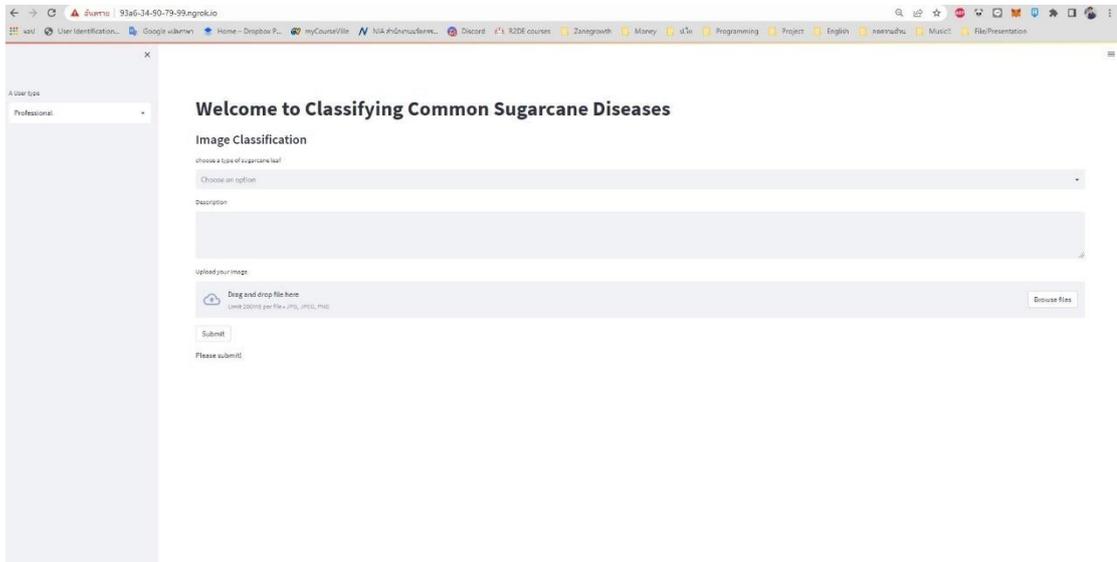


ภาพที่ 12 หน้าเว็บแอปพลิเคชันฝั่งผู้ใช้งานทั่วไป

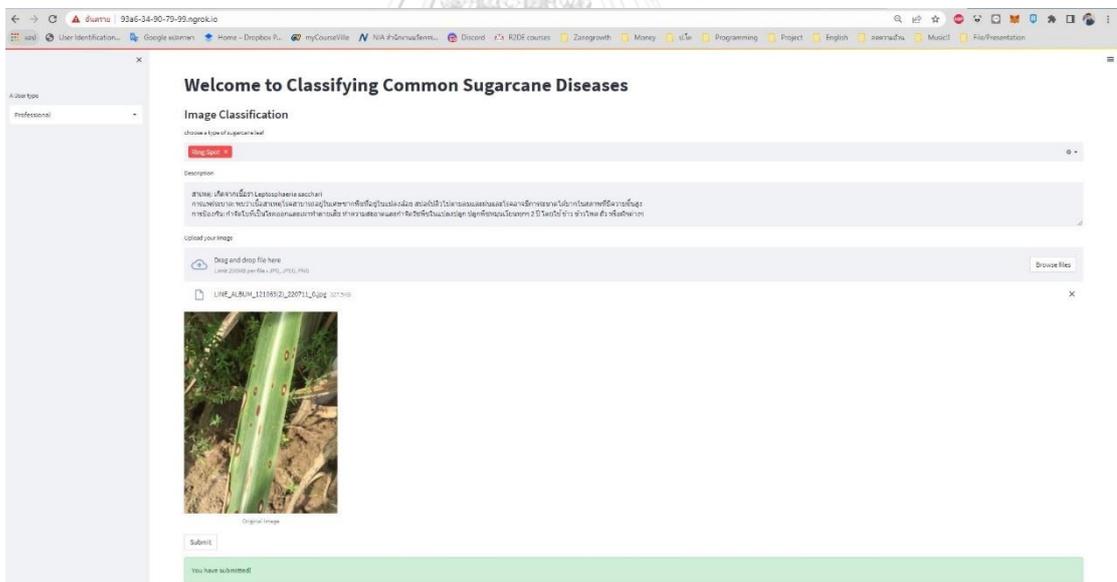


ภาพที่ 13 หน้าเว็บแอปพลิเคชันทำนายโรคอ้อย

ในภาพที่ 13 จะเห็นหน้าเว็บแอปพลิเคชันสำหรับการใช้งานของผู้ใช้งานทั่วไป ซึ่งสามารถอัปโหลดไฟล์ภาพใบอ้อยที่ต้องการ และระบบจะทำการทำนายโรคที่เกิดขึ้นบนใบอ้อย พร้อมทั้งระบุสาเหตุและวิธีการป้องกัน



ภาพที่ 14 หน้าเว็บแอปพลิเคชันฝั่งผู้เชี่ยวชาญ



ภาพที่ 15 หน้าเว็บแอปพลิเคชันฝั่งผู้เชี่ยวชาญบันทึกข้อมูล

ในภาพที่ 15 จะเห็นหน้าเว็บแอปพลิเคชันสำหรับการใช้งานของผู้เชี่ยวชาญ ซึ่งสามารถอัปโหลดไฟล์ภาพใบอ้อยที่มี เลือกรูปภาพของโรคที่เกิดขึ้น พร้อมทั้งระบุสาเหตุและวิธีการป้องกัน เพื่อให้ระบบสามารถจัดเก็บเป็นฐานข้อมูลได้

3.3 การออกแบบโครงข่ายประสาทสำหรับจำแนกโรคอ้อย

3.2.1 การเพิ่มปริมาณข้อมูล (Data Augmentation)

การฝึกความสามารถในการจดจำของโครงข่ายประสาท เพื่อนำมาใช้ตรวจจับหรือคัดแยก วัตถุที่ต้องการออกจากภาพนั้น จะต้องอาศัยชุดข้อมูลภาพที่ถูกติดป้ายแล้วมาใช้ในการฝึก ซึ่ง ประสิทธิภาพในการทำงานและความแม่นยำในการคัดแยกวัตถุของโมเดล จะขึ้นอยู่กับปริมาณข้อมูล ที่ใช้ในการฝึก เนื่องจากรูปที่มีอยู่นั้นมีจำนวนจำกัดจึงจำเป็นต้องมีการเพิ่มจำนวนชุดข้อมูลขึ้นเพื่อให้ โครงข่ายประสาทเทียมสามารถเรียนรู้ที่จะแยกแยะคุณลักษณะของโรคอ้อยได้ดีขึ้น โดยการเลือกใช้ ชุดคำสั่ง (Library) imgaug สำหรับนำมาใช้เป็นชุดข้อมูลสำหรับฝึกโครงข่ายประสาท ซึ่ง imgaug นี้ มีการสนับสนุนกรรมวิธีการขยายชุดภาพ (image augmentation) ที่หลากหลาย [18] มาใช้ในการ เพิ่มปริมาณข้อมูลภาพโดยการดัดแปลงจากรูปภาพเดิมที่มีอยู่ แต่ต้องไม่เปลี่ยนแปลงจนคุณลักษณะ ภาพเปลี่ยนแปลงไปจากเดิมมากเกินไป อาจส่งผลให้ประสิทธิภาพในการฝึกโมเดลโครงข่าย ประสาท และความแม่นยำลดลงนอกจากนั้นการขยายชุดภาพจะช่วยลดการเกิด Overfitting ของ โมเดล หรือการตอบสนองต่อการรบกวนจำนวนมาก อาจทำให้นำการรบกวนที่ทำให้เกิดข้อมูลไม่ ถูกต้องไปเป็นผลในการเรียนรู้ ส่งผลให้ประสิทธิภาพในการตรวจจับลดลงไปจากเดิม



ภาพที่ 16 ใบอ้อยโรคเส้นกลางใบแดง (red rot disease) ที่ผ่านการเพิ่มปริมาณข้อมูล



ภาพที่ 17 ใบอ้อยโรคราสนิม (rust disease) ที่ผ่านการเพิ่มปริมาณข้อมูล



ภาพที่ 16 ไบโรคใบจุดวงแหวน (ring spot disease) ที่ผ่านการเพิ่มปริมาณข้อมูล



ภาพที่ 17 ไบอ้อยโรคใบขาว (white leaf disease) ที่ผ่านการเพิ่มปริมาณข้อมูล



ภาพที่ 18 ไบอ้อยสมบูรณ์ (perfect) ที่ผ่านการเพิ่มปริมาณข้อมูล

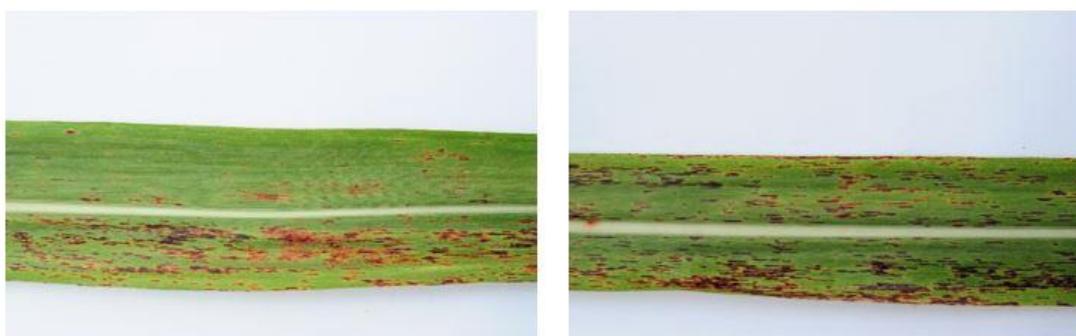
3.2.2 การสร้างชุดข้อมูล (Dataset) และการติดป้าย (Labeling)

ระบบการจำแนกชนิดและลักษณะอาการของโรคอ้อย มีการออกแบบให้ทำงานด้วยการเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นการนำข้อมูลรูปภาพได้จากการเพิ่มปริมาณข้อมูล ประกอบไปด้วยชุดข้อมูลที่ไว้สำหรับฝึก (Training set) จำนวนทั้งสิ้น 7,000 รูป คิดเป็นร้อยละ 70 และข้อมูลสำหรับทดสอบ (Test) จำนวน 2,000 รูป คิดเป็นร้อยละ 20 และมาแยกประเภทผลลัพธ์ด้วยการติดป้าย (Labeling) แล้วจึงนำข้อมูลที่ติดป้ายแล้ว (Pre-labeled training data) ไปใช้ใน

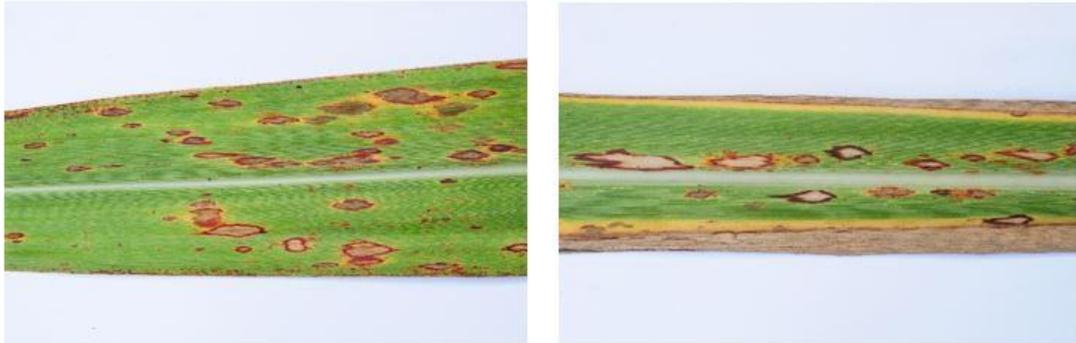
การฝึกโมเดลต่อไป โดยการแบ่งเป็นกลุ่มทั้งหมด 5 กลุ่ม ประกอบด้วย ใบอ้อยสมบูรณ์ (perfect) ใบอ้อยโรคเส้นกลางใบแดง (red_rot) ใบอ้อยโรคราสนิม (rust) ใบอ้อยโรคใบจุดวงแหวน (ring_spot) และใบอ้อยโรคใบขาว (white_leaf) หลังจากนั้นนำตัวอย่างที่ได้มาทำการถ่ายรูปโดยเปลี่ยนลักษณะท่าทาง มุม และความเข้มแสง เป็นจำนวน 3 ถึง 5 ครั้งต่อหนึ่งรูปจนได้รูปภาพของใบอ้อยแต่ละกลุ่ม ประมาณ 1,000 รูป เพื่อใช้สำหรับเป็นชุดตรวจสอบความถูกต้อง (Validation set) คิดเป็นร้อยละ 10



ภาพที่ 19 ตัวอย่างใบอ้อยโรคเส้นกลางใบแดง



ภาพที่ 20 ตัวอย่างใบอ้อยโรคราสนิม



ภาพที่ 21 ตัวอย่างใบอ้อยโรคใบจุดวงแหวน



ภาพที่ 22 ตัวอย่างใบอ้อยโรคใบขาว



ภาพที่ 23 ตัวอย่างใบอ้อยสมบูรณ

3.2.3 กรรมวิธีพัฒนาโครงข่ายประสาทเทียมสำหรับการจำแนกโรคอ้อย

การจำแนกวัตถุด้วยโครงข่ายประสาทเทียมเป็นการทำให้คอมพิวเตอร์สามารถรับรู้และประมวลผลเพื่อจำแนกว่าสิ่งที่ได้รับว่าเป็นอะไร โดยหลักการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชันมี หลักการทำงานคล้ายกับการมองเห็นของมนุษย์ผ่านทางารมองเห็นภาพด้วยตา

เรียกว่า คอมพิวเตอร์วิทัศน์ (Computer vision) ประเภทงานทางคอมพิวเตอร์วิทัศน์แบ่งออกเป็น 4 ด้าน

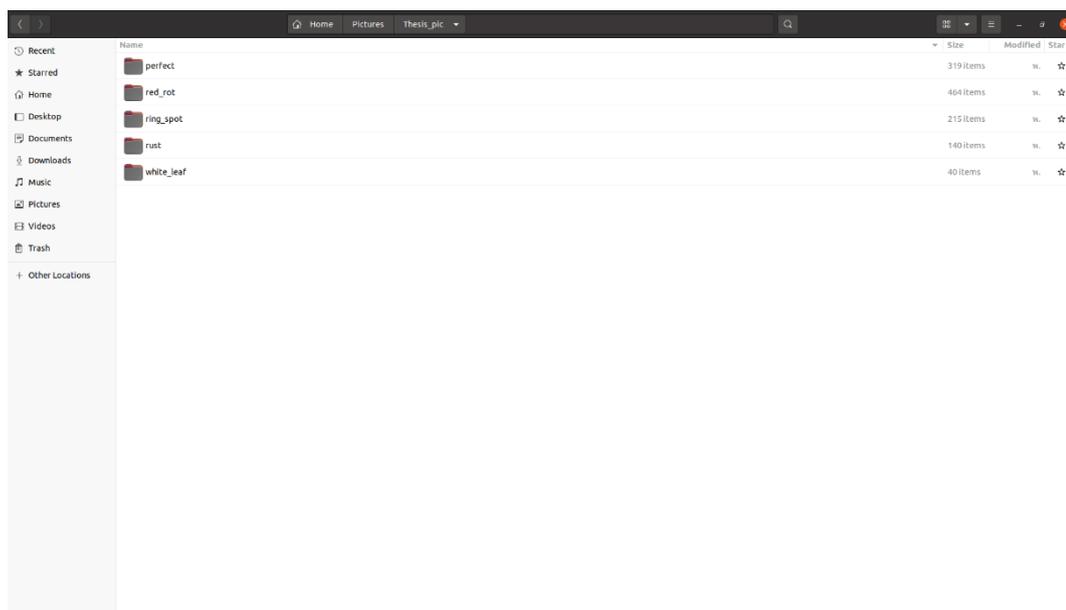
- 1.) การจัดหมวดหมู่วัตถุ (Object classification) เป็นการจำแนกวัตถุจากภาพว่าเป็นวัตถุชนิดใดในภาพนั้น ๆ ซึ่งจะระบุเป็นคลาสโดยภาพรวมเพียงคลาสเดียว
- 2.) การจัดหมวดหมู่วัตถุและระบุตำแหน่ง (Classification and localization) เป็นการจำแนกวัตถุจากภาพ พร้อมระบุตำแหน่งว่าเป็นวัตถุชนิดใด ซึ่งจะระบุเป็นคลาสเดียวในภาพ
- 3.) การตรวจหาวัตถุ (Object detection) เป็นการจำแนกวัตถุมากกว่าหนึ่งคลาสจากภาพ พร้อมระบุตำแหน่งของแต่ละคลาสในภาพนั้น ๆ อาจเป็นคลาสเดียวกันหรือคลาสต่างกัน
- 4.) การแบ่งส่วนภาพ (Image segmentation) เป็นการจำแนกวัตถุมากกว่าหนึ่งคลาสในภาพ พร้อมระบุตำแหน่งของแต่ละคลาสในภาพนั้น ๆ

นอกจากนี้การหาคุณลักษณะของวัตถุนั้น ๆ เพื่อที่จะบอกว่าวัตถุนั้นคืออะไรโดยมีพื้นฐานมาจากความรู้เดิมที่เคยเรียนรู้มา ในปี 2012 ในการแข่งขัน Large Scale Visual Recognition Challenge 2012 (ILSVRC 2012) เป็นการแข่งขันการจำแนกวัตถุโดย มีข้อมูลชุดภาพ (Image Dataset) มากกว่า 1.4 ล้านภาพ และวัตถุที่ได้รับการติดป้ายมีจำนวนทั้งหมด 1,000 คลาส ซึ่งทุกภาพจะมีการระบุคลาสที่ถูกต้องไว้ว่าวัตถุนั้นคืออะไร ชุด ข้อมูลภาพนี้เรียกว่า ImageNet เพื่อที่จะหาแบบจำลองที่มีประสิทธิภาพสูงสุด โดยโครงข่ายประสาทเทียมแบบคอนโวลูชันได้ถูกพัฒนาขึ้นและได้รับรางวัลชนะเลิศในการแข่งขันจำแนกวัตถุ โครงข่ายประสาทเทียมแบบคอนโวลูชันรูปแบบต่าง ๆ เช่น VGG Net, R-CNN, Fast-RCNN, Faster-RCNN, GoogleNet หรือ Inception, ResNet, RetinaNet เป็นต้น จากงานวิจัย Deep Residual Learning for Image Recognition [9] ถูกอ้างอิงในฐานข้อมูล Scopus 3,700 ครั้ง และใน Google scholar 47,481 ครั้ง ช่วงมกราคม พ.ศ. 2559 จนถึง มิถุนายน พ.ศ.2563 นำเสนอการแก้ปัญหา Vanishing gradient คือ ปัญหาที่เกิดขึ้นในระหว่างการฝึกโมเดลโครงข่ายประสาท เมื่อขนาดของความลาด (Gradient) ลดลงเรื่อย ๆ จนเท่ากับ 0 จะส่งผลให้ค่าน้ำหนัก (Weight) ไม่ถูกปรับเป็นค่าปัจจุบัน และโมเดลไม่ถูกฝึกต่อ มักเกิดกับโครงข่ายประสาทที่มีลำดับชั้นลึกมาก แก้ไขได้โดยการทางลัด (Shortcut) ข้ามลำดับชั้นภายในของโครงข่ายประสาท เช่น การใส่ฟังก์ชันกระตุ้น (Activation function) ReLU แทน Sigmoid เป็นต้น เรียกโครงข่าย ประสาทชนิดนี้ว่า Residual Network (ResNet) จึงได้รับความนิยมและถูกนำมาใช้ในงานด้านจำแนกวัตถุมากขึ้นแทนที่แบบจำลองที่ใช้การหาคุณลักษณะแบบดั้งเดิม โดยใช้โครงข่ายประสาทเทียมที่มีประสิทธิภาพสูงจากการแข่งขันในงาน ILSVRC มาเป็น backbone ในการฝึก

การฝึกของผู้วิจัยจะทำการฝึกโครงข่ายประสาทเทียมแบบคอนโวลูชันโดยใช้ชุดคำสั่ง Keras ซึ่งเป็นชุดคำสั่งที่อยู่ภายใน TENSORFLOW 1.15 โดยชุดคำสั่ง Keras สามารถสร้างโครงข่าย

ประสาทเทียมขึ้นมาใหม่ด้วยคำสั่งต่าง ๆ เช่น Dense, Conv2D, MaxPool2D, Flatten และอื่น ๆ โดยสามารถกำหนดค่าพารามิเตอร์ใน Arguments ต่าง ๆ ของคำสั่งได้ตามต้องการ แต่ข้อมูลที่ใช้ในการฝึกสำหรับงานวิจัยนี้มีขนาดเล็ก ผู้วิจัยจึงเลือกใช้โครงข่ายประสาทเทียมที่มีอยู่ภายในชุดคำสั่ง Keras เช่น VGG-16 ResNet-50 และ ResNet-101 นอกจากนี้ยังสามารถใช้วิธีการเรียนรู้แบบถ่ายโอน (Transfer Learning) โดยใช้น้ำหนัก (weight) เริ่มต้นของโครงข่ายประสาทเทียมที่ถูกฝึกบนชุดข้อมูล โดยผู้วิจัยได้ทำการเลือกใช้โครงข่ายประสาทเทียมที่ได้รับการฝึกบนชุดข้อมูล ImageNet ซึ่งเป็นชุดข้อมูลฝึกที่มีขนาดใหญ่ (ประมาณ 1.4 ล้านภาพ) และ PlantVillage ซึ่งเป็นชุดข้อมูลฝึกทางด้านพืชขนาดใหญ่ (ประมาณ 54,306 ภาพ) มาเป็นน้ำหนักเริ่มต้นก่อนการฝึกได้ เพื่อช่วยในการเรียนรู้คุณลักษณะระดับต่ำ เช่น ขอบ มุม ของโครงข่ายประสาทเทียมได้ดียิ่งขึ้น โดยผู้วิจัยได้ทำการเลือกใช้โครงข่ายประสาทเทียมที่ได้รับการฝึกบนชุดข้อมูล ImageNet และ PlantVillage มาเป็น backbone สำหรับการฝึกบนข้อมูลที่ใช้ในงานวิจัย โดยหลังจากตั้งค่าให้โครงข่ายประสาทเทียมมีน้ำหนักเริ่มต้นจากการเรียนรู้แบบถ่ายโอนแล้วทำการปรับแต่ง (Fine-tuning) โครงข่ายประสาทเทียมเพื่อให้ได้ประสิทธิภาพในการจำแนกโรคอ้อยที่สูงขึ้น

ขั้นตอนสำหรับการฝึกโครงข่ายประสาทเทียม จะนำข้อมูลภาพถ่ายใบอ้อยที่ผ่านการเพิ่มปริมาณชุดข้อมูล และติดป้ายบ่งบอกคลาสของใบอ้อย จำนวน 5 คลาส ประกอบด้วยชื่อคลาส perfect, ชื่อคลาส red_rot, ชื่อคลาส rust, ชื่อคลาส ring_spot, และ ชื่อคลาส white_leaf โดยแบ่งเป็นชุดสำหรับการฝึก (Training Set) ร้อยละ 70 ชุดสำหรับทดสอบ (Test Set) ร้อยละ 20 และชุดตรวจสอบความถูกต้อง (Validation set) ร้อยละ 10 โดยที่ชุดสำหรับการฝึกและชุดสำหรับทดสอบจะถูกนำไปใช้ในขั้นตอนการฝึกโมเดลโครงข่ายประสาทเทียมผ่าน Tensorflow ด้วย GPU โดยชุดตรวจสอบความถูกต้องจะเป็นชุดที่ประเมินผลสำหรับการฝึกในแต่ละ epoch หากค่า Mean Average Precision (mAP) หรือความแม่นยำในการทำนายทั้ง 5 คลาสมีค่าน้อยกว่า ร้อยละ 80 จะต้องปรับแต่งและฝึกใหม่ให้มีค่าน้ำหนักที่เหมาะสมต่อชุดข้อมูลภาพถ่ายใบอ้อย และ ทำการฝึกโมเดลใหม่ซ้ำจนกว่าความแม่นยำในการทำนายทั้ง 5 คลาสมีค่ามากกว่าร้อยละ 80 จึงจะสามารถนำโมเดลโครงข่ายประสาทไปใช้งานได้



ภาพที่ 24 ภาพการจัดป้ายข้อมูลตามคลาส

กระบวนการฝึกโมเดลโครงข่ายประสาทนั้น จะต้องเตรียมระบบปฏิบัติการให้พร้อมต่อการใช้งาน จะต้องมีการติดตั้งชุดคำสั่งองค์ประกอบที่เกี่ยวข้อง และติดตั้งองค์ประกอบพื้นฐานที่ทำให้เข้าถึงการใช้งาน GPU ได้แก่ ชุดคำสั่งติดตั้ง CUDA TOOLKIT และ CUDNN ชุดคำสั่งติดตั้ง OPENCV และ TENSORFLOW 1.15 จากนั้นจึงเข้าสู่ขั้นตอนการฝึกโมเดลโครงข่ายประสาทเทียม ในการปรับปรุงลำดับชั้นภายในโครงข่ายประสาท สามารถใช้ชุดคำสั่งที่อยู่ภายใน Tensorflow และ Keras ที่สามารถปรับปรุงได้ทั้ง VGG16, VGG19, Inception v3, Keras และอื่น ๆ จากส่วนหนึ่งของชุดคำสั่งที่ใช้ในการสร้างโมเดลโครงข่ายประสาทจาก ResNet50 ในการดึงคุณลักษณะของภาพ จากชั้น feedforward และพยากรณ์ตำแหน่งของคลาส

คอมพิวเตอร์ที่ใช้ประกอบด้วยระบบปฏิบัติการ : Ubuntu 20.04 LTS และ Microsoft Windows 10 หน่วยประมวลผลกลาง CPU AMD Ryzen 3 Series 3200x 3.6GHz 4 cores 4 threads หน่วยประมวลผลกราฟิก GPU NVIDIA GeForce GTX 1080Ti 11GB บอร์ดหลัก Motherboard Asus 1200 PRIME B560-PLUS หน่วยความจำหลัก RAM Hyper-X DDR3 1600MHz ความจุ 8 GB หน่วยความจำสำรอง ฮาร์ดดิสก์ WD Black ความจุ 500 GB

คลังชุดคำสั่งสำหรับฝึกโมเดลโครงข่ายประสาทจะประกอบด้วย 3 ส่วน ได้แก่ ชุดคำสั่งสำหรับ ฝึก train.py ตาม ด้วย arguments สำหรับกำหนดพารามิเตอร์เฉพาะประกอบด้วย -- weights ./models/sugarcane_model.h5 กำหนดตำแหน่งของโมเดลภายในแฟ้มที่ต้องการนำมาฝึก -- tensorboard-dir ./tensorboard กำหนดตำแหน่งแฟ้มเก็บเหตุการณ์ที่เกิดขึ้นระหว่างการฝึก (Log files) --freeze-backbone กำหนดให้ฝึกเจาะจงไปที่ backbone ของโครงข่ายประสาทในที่นี้

จะเป็น ResNet50 --random-transform กำหนดให้เข้าถึงตำแหน่งไฟล์ภาพที่เก็บในแฟ้ม กำหนดจำนวนรอบการฝึกของข้อมูลที่นำมาฝึกโมเดลจนครบ --steps XXX กำหนดจำนวนขั้นย่อยของรอบการฝึก --weighted-average กำหนดให้คำนวณค่า mAP จากการเฉลี่ยค่าน้ำหนักของความเที่ยงตรงในแต่ละคลาส --compute-val-loss กำหนดให้คำนวณ validation loss ในระหว่างการฝึก นอกจากนี้ยังมี arguments เพิ่มเติมสำหรับการเข้าถึงการฝึกด้วย GPU ที่มีในคอมพิวเตอร์ ซึ่งจะต้องตรงกันกับจำนวนที่แสดงในชุดคำสั่ง nvidia-smi ใช้แสดงข้อมูลของหน่วยประมวลผลกราฟิก กำหนดให้ Tensorflow ใช้ GPU ในการฝึก --batch-size X กำหนดการแบ่งกลุ่มชุดข้อมูลสำหรับการฝึกมีจำนวนเท่ากับ GPU

ส่วนถัดมาชุดคำสั่งสำหรับแปลงโมเดลโครงข่ายประสาทให้เป็นโมเดลอนุมาน (Inference model) ที่สามารถนำไปใช้พยากรณ์ข้อมูลที่ไม่เคยเจอในการฝึกมาก่อนได้ convert_model.py ตามด้วย arguments สำหรับกำหนดพารามิเตอร์ประกอบด้วย ./model/sugarcane_model_{จำนวน epoch}.h5 กำหนดตำแหน่งของโมเดลภายในแฟ้มที่ถูกฝึกเสร็จตามรอบ epoch และ ./model/sugarcane_model_inference.h5 กำหนดตำแหน่งที่ต้องการบันทึกโมเดลอนุมานสำหรับนำไปใช้ในระบบ สุดท้ายชุดคำสั่งประเมินความสามารถของโมเดลอนุมานกับชุดตรวจสอบความถูกต้อง (Validation set) เพื่อดูค่า Mean Average Precision (mAP) หรือความแม่นยำในการพยากรณ์ของทั้ง 5 คลาส evaluate.py ตามด้วย arguments สำหรับกำหนดพารามิเตอร์ กำหนดตำแหน่งของชุดตรวจสอบความถูกต้อง และ ./model/sugarcane_model_inference.h5 กำหนดตำแหน่งที่ต้องการบันทึกโมเดลอนุมาน

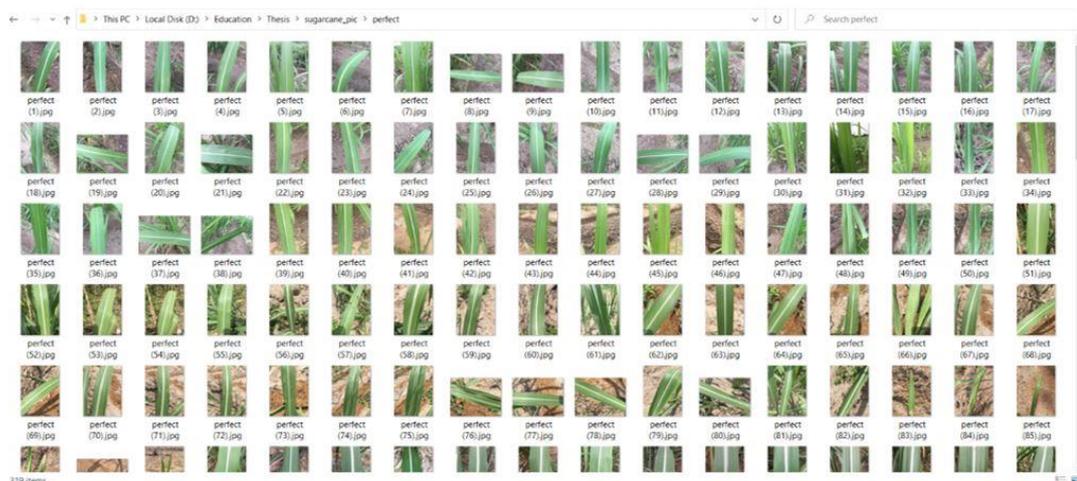
บทที่ 4 ผลการทำงานของระบบ

4.1 การเพิ่มปริมาณข้อมูลภาพ (Data Augmentation)

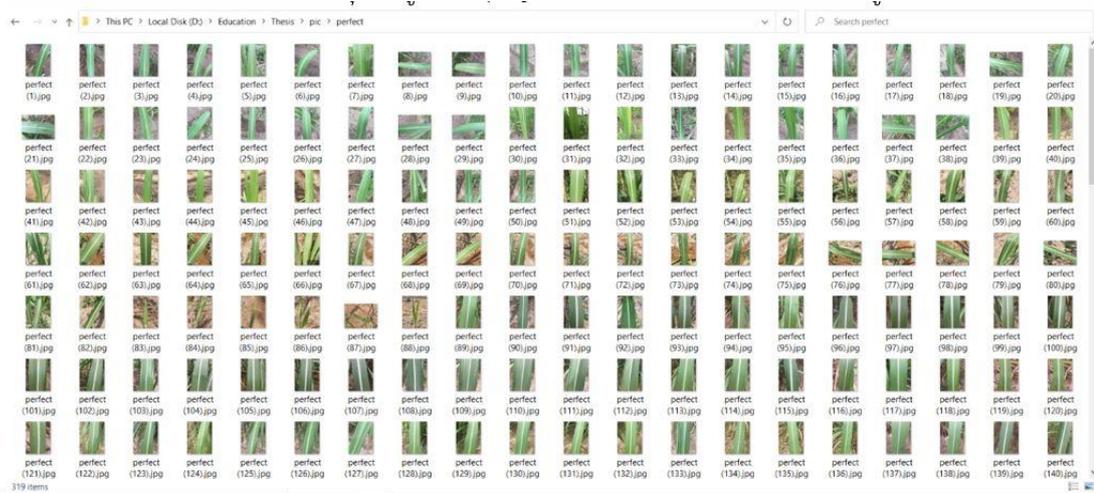
การเพิ่มปริมาณข้อมูลภาพจากการใช้ชุดคำสั่ง `imgaug` มาใช้สร้างชุดข้อมูลภาพถ่ายใบอ้อย จากกล้องโทรศัพท์มือถือ โดยการตัดแปลงจากภาพเดิมที่มีอยู่จากการติดป้าย (Labeling) ทำการกำหนดแฟ้มที่เก็บไฟล์ภาพต้นฉบับและแฟ้มสำหรับผลลัพธ์ที่ได้จากการเพิ่มปริมาณข้อมูล จากนั้นทำการกำหนดจำนวนรอบสำหรับการเพิ่มปริมาณข้อมูลภาพแต่ละภาพ โดยภาพ 1 ภาพ จะทำการเพิ่มปริมาณข้อมูลเท่ากับจำนวนรอบที่ได้กำหนดไว้ และทำการเพิ่มปริมาณข้อมูลภาพแต่ละภาพจะถูกดำเนินการทุกฟังก์ชันแบบเป็นลำดับขึ้นจากคำสั่ง `iaa.Sequential` เช่นภาพที่เกิดจาก `augmentation` ด้วยฟังก์ชัน `GaussianBlur` `MultiplyBrightness` `LinearContrast` และ `AdditiveGaussianNoise` เป็นต้น

สำหรับการเพิ่มปริมาณข้อมูลภาพและบันทึกไฟล์อัตโนมัติ ผู้ใช้สามารถกำหนดจำนวนรอบในตัวแปร `augment_loop` เช่น 5 รอบ หากชุดข้อมูลภาพมี 100 ภาพ ชุดข้อมูลที่ถูกขยายจะมีทั้งหมด 500 ภาพ ถูกบันทึกไว้ในแฟ้ม `sugarcane_pic` ผลลัพธ์ของการใช้ชุดคำสั่งดังกล่าวจะอยู่ในหัวข้อผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ `perfect` (ใบอ้อยสมบูรณ์) `red_rot` (ใบอ้อยโรคเส้นกลางใบแดง) `rust` (ใบอ้อยโรคราสนิม) `ring_spot` (ใบอ้อยโรคใบจุดวงแหวน) และ `white_leaf` (ใบอ้อยโรคใบขาว) แสดงผลในภาพที่ 26 ถึง 35

4.1.1 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ perfect

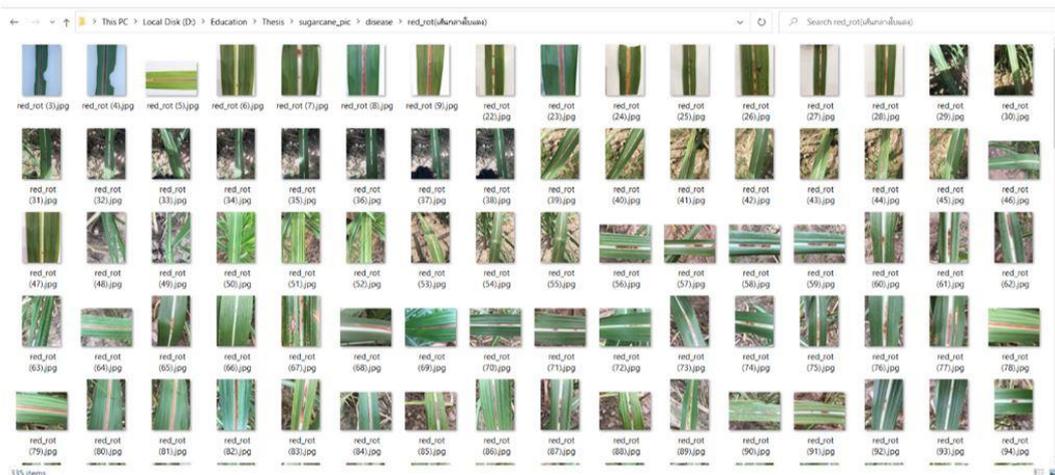


ภาพที่ 25 ตัวอย่างชุดข้อมูลภาพ `perfect` ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ

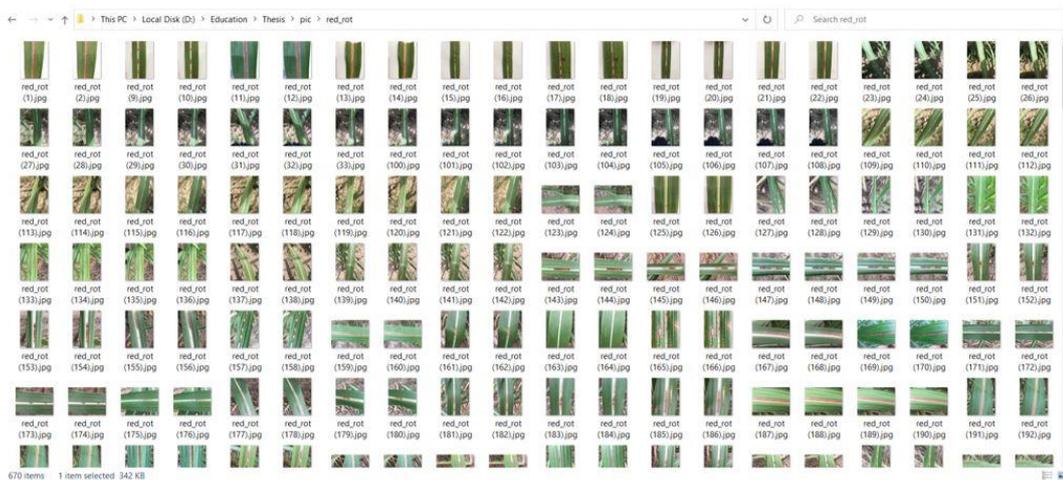


ภาพที่ 26 ตัวอย่างชุดข้อมูลภาพ perfect หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

4.1.2 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ red_rot



ภาพที่ 27 ตัวอย่างชุดข้อมูลภาพ red_rot ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ

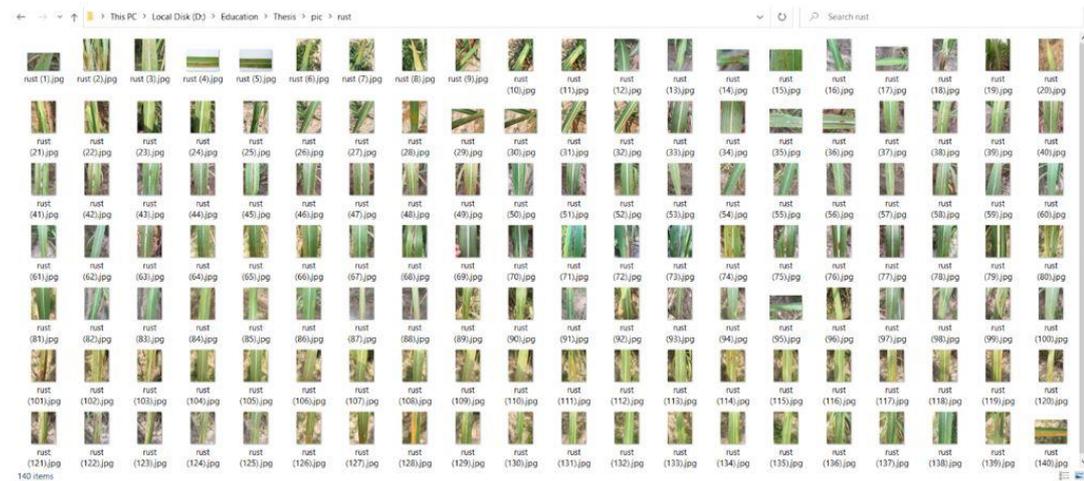


ภาพที่ 28 ตัวอย่างชุดข้อมูลภาพ red_rot หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

4.1.3 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ rust

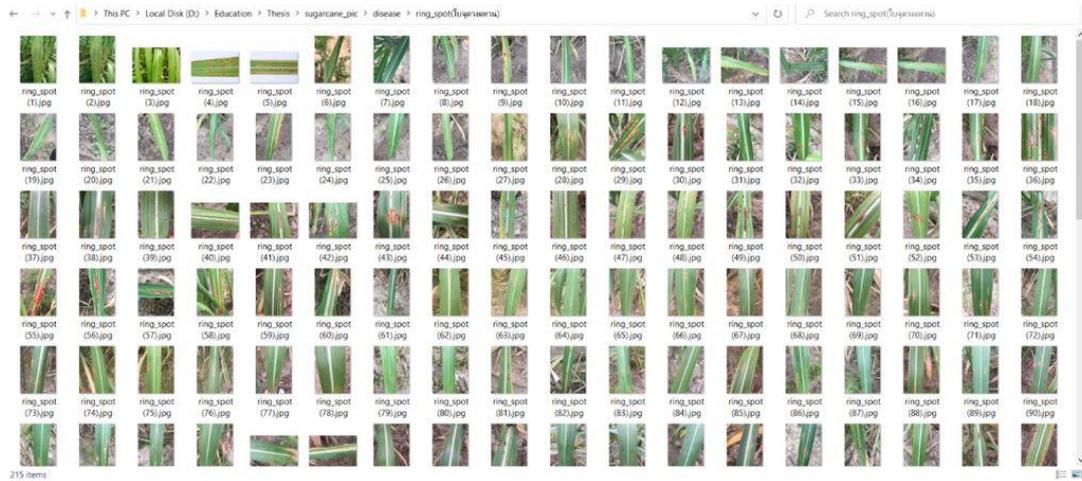


ภาพที่ 29 ตัวอย่างชุดข้อมูลภาพ rust ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ

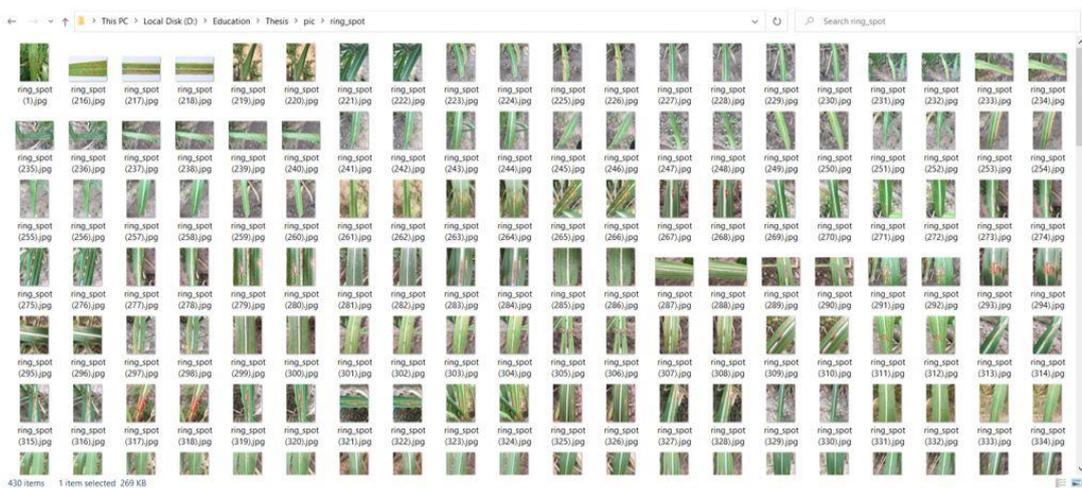


ภาพที่ 30 ตัวอย่างชุดข้อมูลภาพ rust หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

4.1.4 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ ring_spot

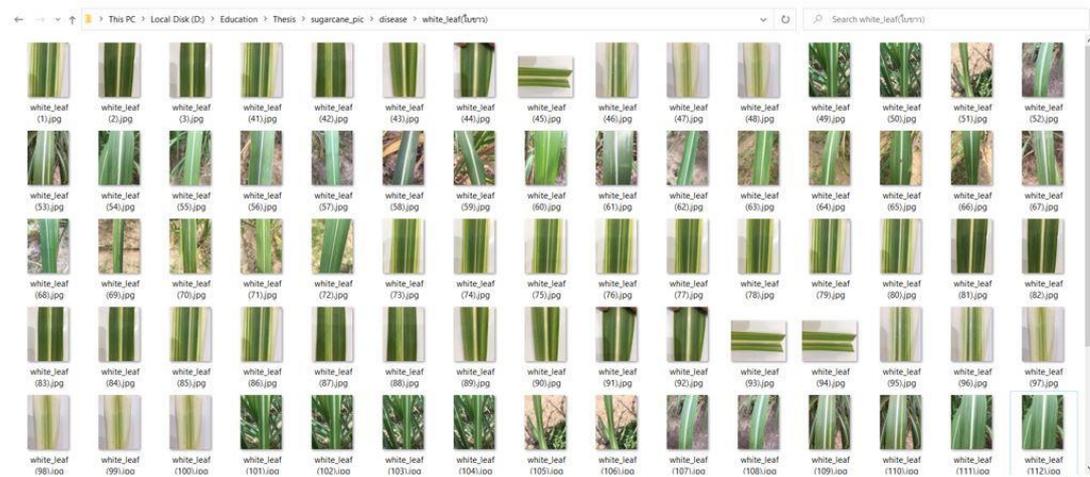


ภาพที่ 31 ตัวอย่างชุดข้อมูลภาพ ring_spot ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ

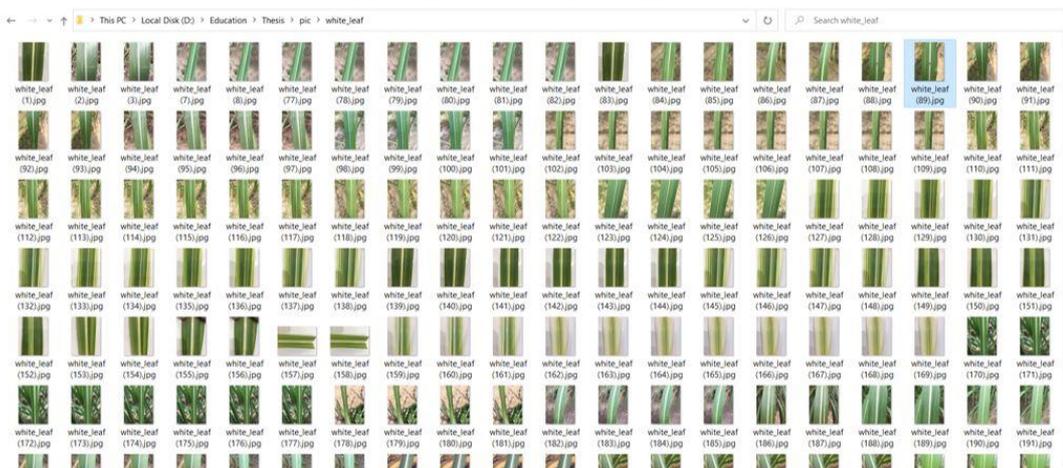


ภาพที่ 32 ตัวอย่างชุดข้อมูลภาพ ring_spot หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

4.1.5 ผลลัพธ์การเพิ่มปริมาณข้อมูลภาพ white_leaf



ภาพที่ 33 ตัวอย่างชุดข้อมูลภาพ white_leaf ก่อนได้รับการเพิ่มปริมาณข้อมูลภาพ



ภาพที่ 34 ตัวอย่างชุดข้อมูลภาพ white_leaf หลังได้รับการเพิ่มปริมาณข้อมูลภาพ

4.1.6 พารามิเตอร์ของโมเดลโครงข่ายประสาทเทียมที่ใช้ในระบบ

การทำงานของโมเดลโครงข่ายประสาทเทียมที่ประกอบด้วย Residual Network 50 (ResNet-50) จากการพัฒนาโครงข่ายประสาทเทียมภายในระบบจำแนกโรคอ้อย ด้วยการนำ Transfer learning นอกจากการฝึกด้วยชุดข้อมูลภาพใหม่ที่ยังไม่ได้รับการฝึกมาก่อนด้วยชุดข้อมูลภาพถ่ายใบอ้อยจากกล้องโทรศัพท์มือถือ ยังมีการปรับพารามิเตอร์ภายในชั้นคอนโวลูชัน (Convolution) ใน ResNet50 เพื่อให้การแยกคุณลักษณะ (Feature Extraction) โดยการใช้ตัวกรองจำแนกและดึงลักษณะเฉพาะที่สนใจออกมา ด้วยกระบวนการก่อนประมวลผลภาพ (image pre-processing) เช่น การปรับขนาดของภาพ หมุนภาพ พลิกและเลื่อนภาพในแนวนอนและแนวตั้ง เพื่อให้ได้จุดที่สนใจของภาพที่มีขนาด 224x224 ซึ่งในแต่ละภาพใช้การแยกสีโดยใช้ระบบสี HSV (Hue Saturation และ Value) ในการแบ่งส่วนและเส้นขอบ ส่งผลให้ได้เฉพาะวัตถุที่สนใจแบบที่ไม่มี

พื้นหลัง นอกจากนี้แบบจำลองยังวัดค่าต่ำสุด สูงสุด และค่าเฉลี่ย (Min, Max, Mean) ของสีที่จะแยกออกมาเป็นคุณลักษณะของรูปภาพ

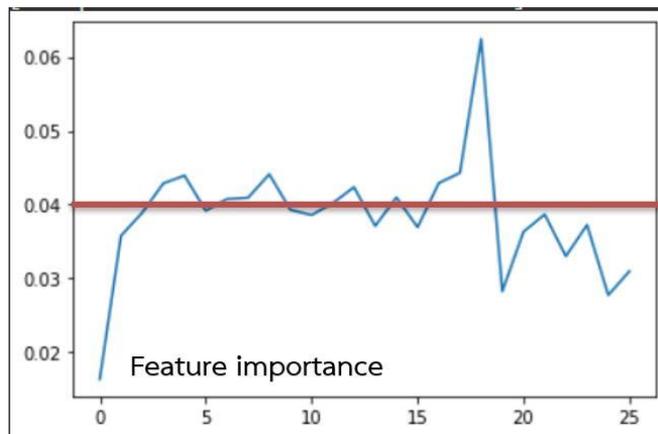


ภาพที่ 35 ภาพก่อนการทำ image per-processing



ภาพที่ 36 ภาพหลังการทำ image per-processing

การแยกคุณลักษณะของข้อมูล (Feature extraction) คัดเลือกคุณลักษณะเฉพาะที่มีประสิทธิภาพสูงสุด โดยทดสอบคุณลักษณะเฉพาะเพื่อให้ทราบว่าคุณลักษณะเฉพาะใดมีอิทธิพลต่อการจำแนกโรคอ้อย ด้วยวิธี ROC (Receiver Operating Characteristic) Curve เป็นเส้นที่ใช้วัดถึงประสิทธิภาพของโมเดลแบบ Classification ว่าสามารถทำนายประเด็นที่สนใจได้อย่างแม่นยำขนาดไหน (โดยทั่วไปนิยมวัดประสิทธิภาพของโมเดลแบบ Binary) ส่วน AUC ก็คือ Area Under ROC Curve หรือพื้นที่ใต้กราฟ ROC เส้นโค้ง ROC เป็นเส้นโค้งที่พล็อตกราฟระหว่างค่า Sensitivity และ 1-specificity โดยแกน y แทน Sensitivity และ แกน x แทน 1-specificity ที่จุดตัดต่างๆ เพื่อแบ่งผลลัพธ์ของการทำนายออกเป็นกลุ่มเหตุการณ์ที่สนใจและเหตุการณ์ที่ไม่ได้สนใจ



ภาพที่ 37 การวัด Feature Important

ผู้วิจัยได้ทดสอบ Feature ทั้งหมด 6 ค่า ได้แก่ ค่า Histogram of Oriented Gradients (HOG), ค่า Min Max Mean และ Standard, ค่าความต่าง (Contrast) และค่าความเหมือนกันของภาพ (Homogeneity) ซึ่งการฝึกโมเดลโครงข่ายประสาทจะถูกแบ่งออกเป็น 3 แบบ ได้แก่ การฝึกโมเดลแบบไม่ปรับพารามิเตอร์ การฝึกโมเดลแบบปรับพารามิเตอร์แบบที่ 1 และการฝึกโมเดลปรับพารามิเตอร์แบบที่ 2

Sizes	32	64	128	256	512
Strides	8	16	32	64	128
Ratio	0.5	1	2	3	

ตารางที่ 1 ค่าพารามิเตอร์แบบไม่ปรับพารามิเตอร์สำหรับโมเดล

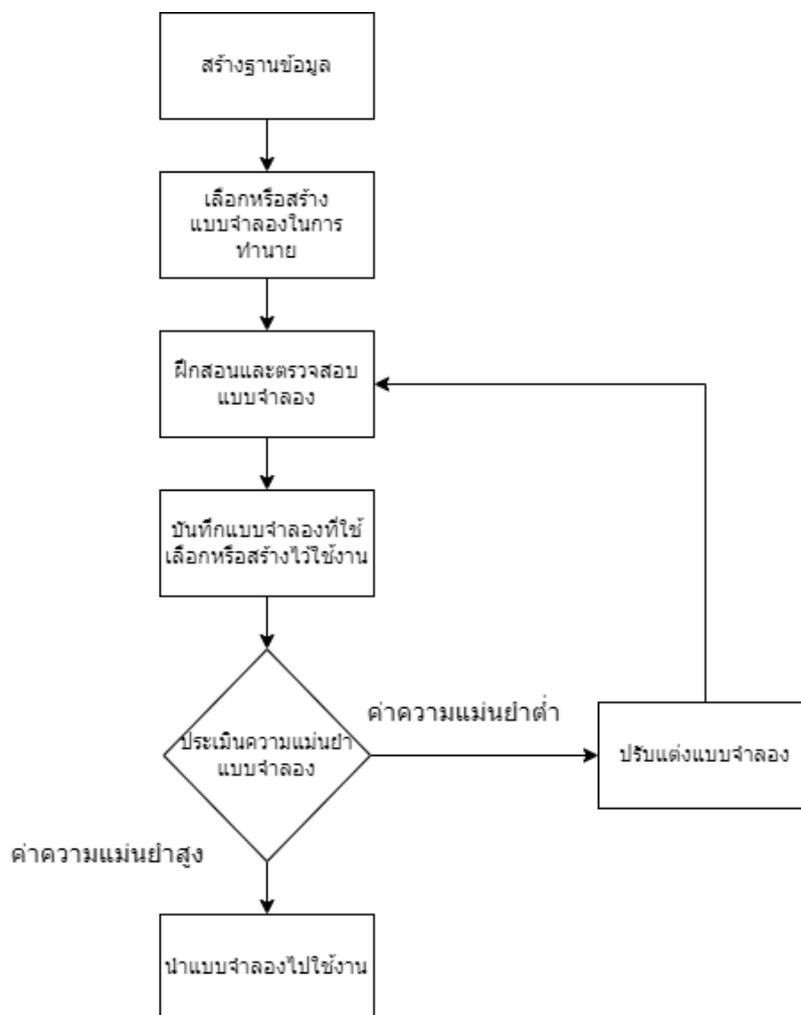
Sizes	16	32	64	128	256
Strides	8	16	32	64	128
Ratio	0.5	1	2	3	

ตารางที่ 2 ค่าพารามิเตอร์แบบที่ 1 สำหรับฝึกโมเดล

Sizes	8	16	32	64	128
Strides	4	8	16	32	64
Ratio	0.5	1	2	3	

ตารางที่ 3 ค่าพารามิเตอร์แบบที่ 2 สำหรับฝึกโมเดล

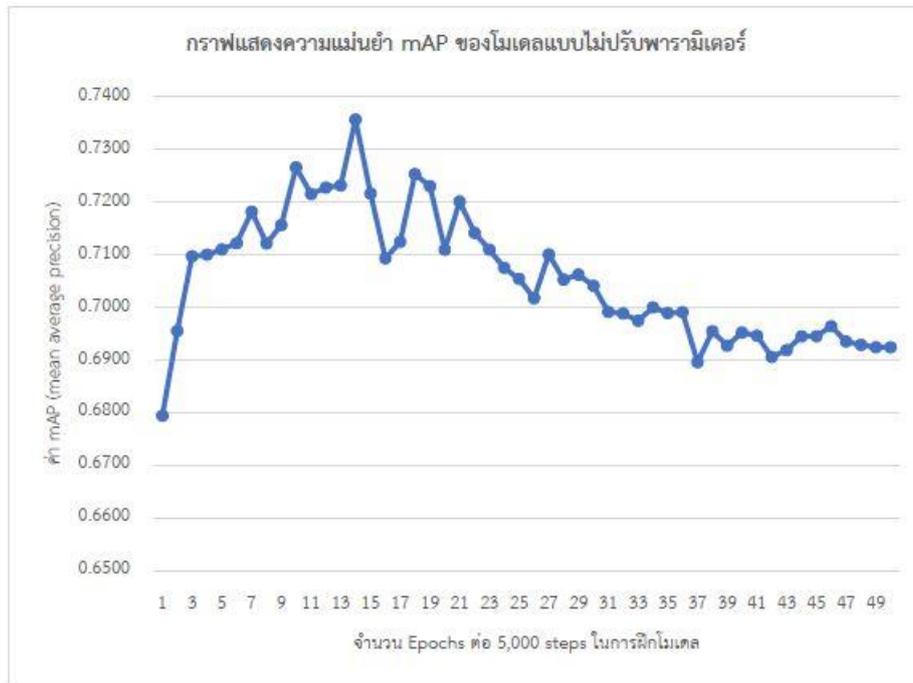
4.2 แบบจำลองการเรียนรู้ของเครื่อง



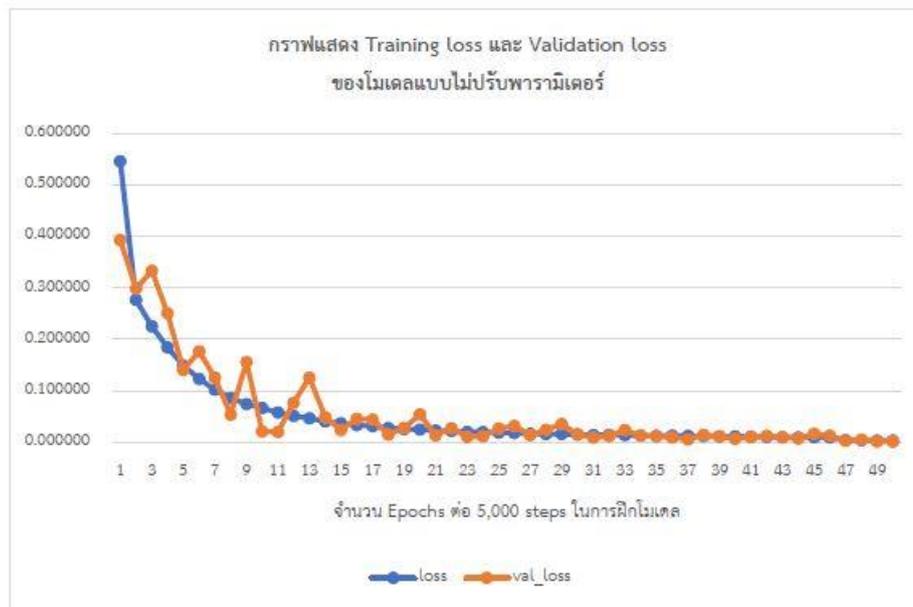
ภาพที่ 38 กระบวนการเรียนรู้ของเครื่อง

4.2.1 ผลลัพธ์การฝึกแบบจำลองแบบไม่ปรับพารามิเตอร์

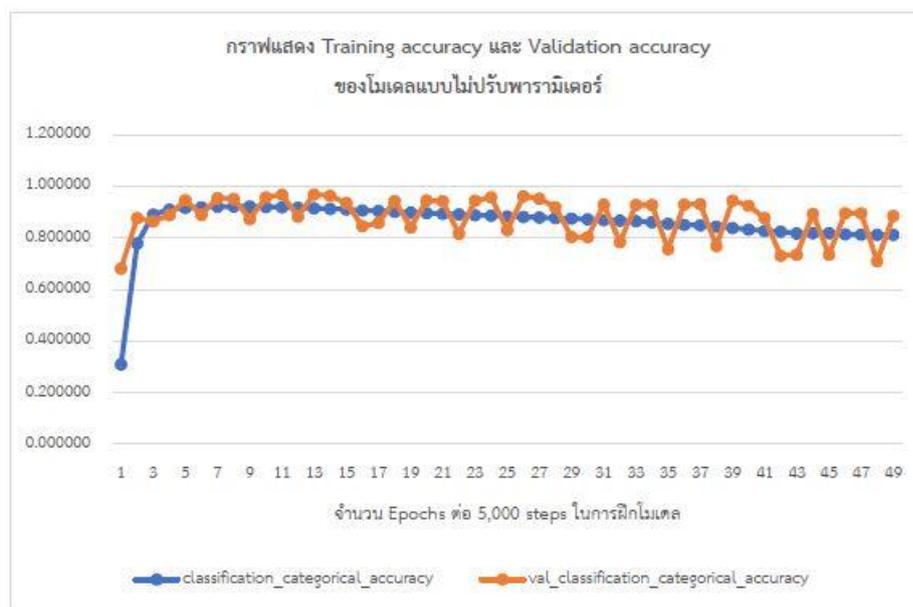
จากการฝึกโมเดลโครงข่ายประสาทแบบไม่ปรับพารามิเตอร์ตามค่าในตารางที่ 1 ครบจำนวน 50 Epochs แล้วนั้น จากกราฟแสดงค่า mAP (mean average precision) ของ 5 คลาส ได้แก่ ใบอ้อยสมบูรณ์ (perfect) ใบอ้อยโรคเส้นกลางใบแดง (red_rot) ใบอ้อยโรคราสนิม (rust) ใบอ้อยโรคใบจุดวงแหวน (ring_spot) และใบอ้อยโรคใบขาว (white_leaf) มีค่าสูงสุดที่ 0.7356 และมีค่าต่ำสุดที่ 0.6794 ซึ่งความแม่นยำในการพยากรณ์ทั้ง 5 คลาสมีค่าน้อยกว่า 0.8000 หรือร้อยละ 80



ภาพที่ 39 กราฟแสดงความแม่นยำ mAP ของโมเดลแบบไม่ปรับพารามิเตอร์



ภาพที่ 40 กราฟแสดง Training loss และ Validation loss ของโมเดลแบบไม่ปรับพารามิเตอร์



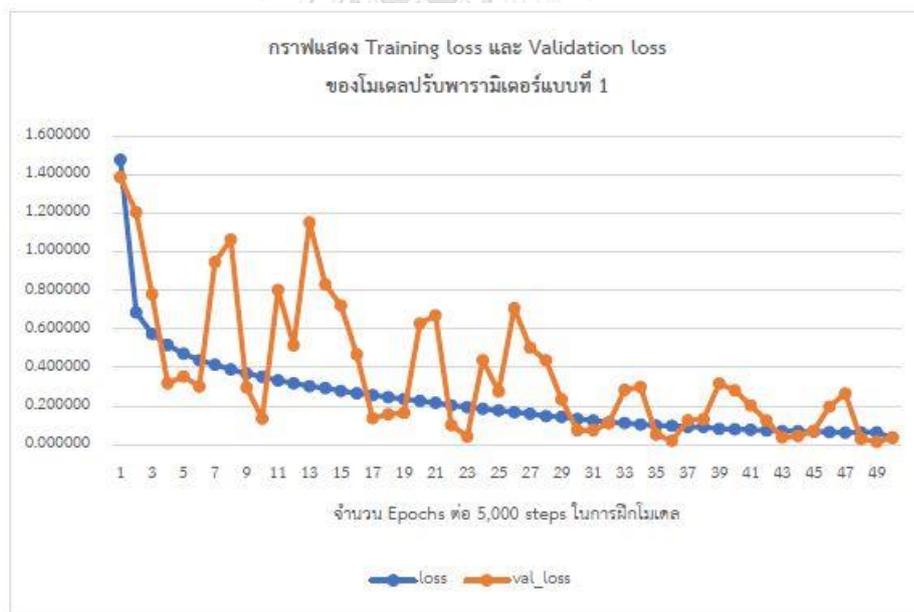
ภาพที่ 41 กราฟแสดง Training accuracy และ Validation accuracy ของโมเดลแบบไม่ปรับ

4.2.2 ผลลัพธ์การฝึกแบบจำลองแบบปรับพารามิเตอร์แบบที่ 1

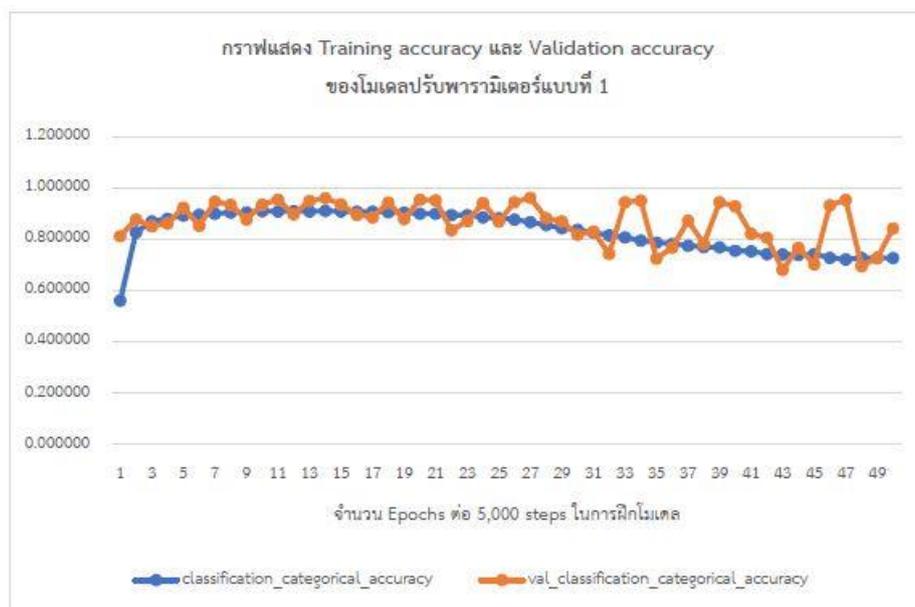
ในการฝึกโมเดลแบบไม่ปรับพารามิเตอร์ความแม่นยำในการพยากรณ์ทั้ง 5 คลาสมีค่าน้อยกว่า 0.8000 หรือร้อยละ 80 จึงมีความจำเป็นต้องปรับปรุงโมเดลโครงข่ายประสาทให้สามารถตรวจจับและนับจำนวนได้ครบทั้ง 5 คลาส ด้วยการปรับให้เหมาะสมกับขนาดป้ายของวัตถุในภาพจนได้ผังคุณลักษณะที่จำแนกวัตถุออกได้ จากค่าพารามิเตอร์ในตารางที่ 1 จะพบว่า Sizes เป็นขนาดของพื้นที่จุดภาพที่ต้องการแยกคุณลักษณะของ ข้อมูลตามจำนวนชั้นคุณลักษณะที่เล็กที่สุดมีค่า 32 จะมีขนาดเป็น 32×32 จุดภาพ ทำให้วัตถุที่ติดป้ายที่มีขนาดเล็กกว่า 32×32 จุดภาพ จะไม่ถูกสร้างผังคุณลักษณะทำให้ไม่สามารถตรวจจับได้ ผู้วิจัยจึงปรับค่าพารามิเตอร์แบบที่ 1 สำหรับฝึกโมเดลโครงข่ายประสาท แสดงในตารางที่ 2 จากนั้นจึงเริ่มการฝึกโมเดลใหม่จนครบจำนวน 50 Epochs จากกราฟแสดงค่า mAP (mean average precision) ของ 5 คลาส มีค่าสูงสุดที่ 0.8681 และมีค่าต่ำสุดที่ 0.7305 ซึ่งความแม่นยำในการทำนายทั้ง 5 คลาสมีค่าสูงขึ้นกว่าครั้งก่อน มีค่ามากกว่า 0.8000 หรือร้อยละ 80



ภาพที่ 44 กราฟแสดงความแม่นยำ mAP ของโมเดลปรับพารามิเตอร์แบบที่ 1



ภาพที่ 45 กราฟแสดง Training loss และ Validation loss ของโมเดลปรับพารามิเตอร์แบบที่ 1



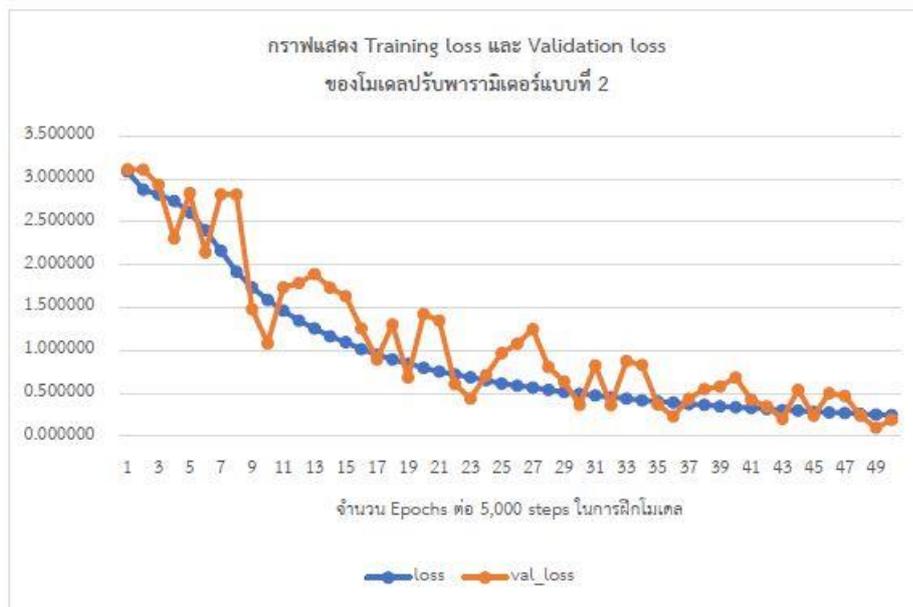
ภาพที่ 42 กราฟแสดง Training accuracy และ Validation accuracy ของโมเดลปรับพารามิเตอร์แบบที่ 1

4.2.3 ผลลัพธ์การฝึกแบบจำลองแบบปรับพารามิเตอร์แบบที่ 2

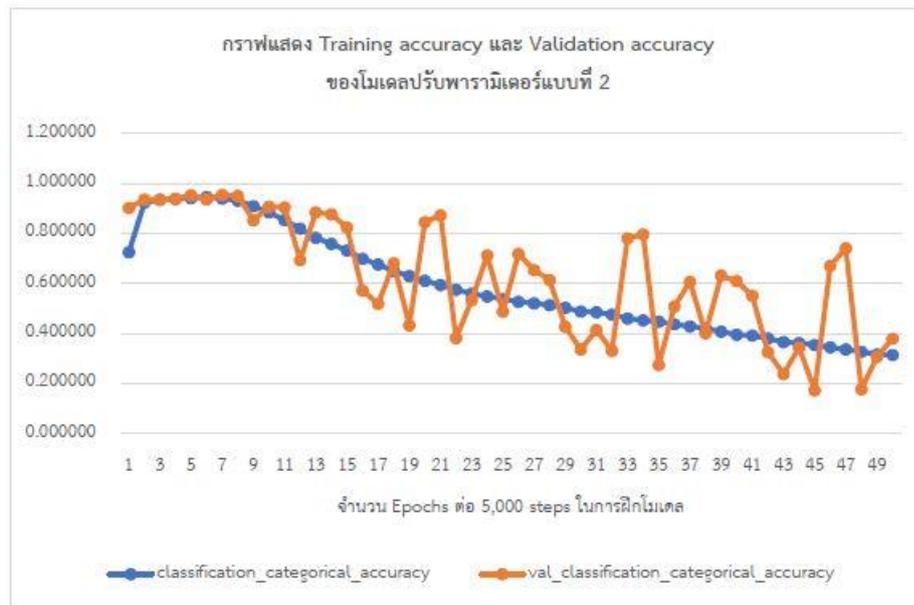
เนื่องด้วยการฝึกโมเดลแบบปรับพารามิเตอร์แบบที่ 1 ส่งผลให้ความแม่นยำ (mAP) ในการ พยากรณ์ทั้ง 5 คลาสเพิ่มขึ้นจากเดิม ผู้วิจัยจึงปรับพารามิเตอร์ให้มีขนาดเล็กกว่าเดิม เพื่อให้พารามิเตอร์ในชั้นคอนโวลูชัน (CONV) สามารถแยกคุณลักษณะของข้อมูล (Feature extraction) ได้ละเอียดมากยิ่งขึ้น ค่าพารามิเตอร์ในตารางที่ 1 จะพบว่า Sizes เป็นขนาดของพื้นที่จุดภาพที่ต้องการแยกคุณลักษณะของข้อมูลตามจำนวนชั้นคุณลักษณะที่เล็กที่สุดมีค่า 32 จะมีขนาดเป็น 32×32 จุดภาพ ผู้วิจัยจึงปรับค่าพารามิเตอร์แบบที่ 2 สำหรับฝึกโมเดล โครงข่ายประสาทแสดงในตารางที่ 3 จากนั้นจึงเริ่มการฝึกโมเดล ใหม่จนครบจำนวน 50 Epochs จากกราฟแสดงค่า mAP (mean average precision) ของ 5 คลาส มีค่าสูงสุดที่ 0.2293 และมีค่าต่ำสุดที่ 0.0037 ซึ่งความแม่นยำในการ พยากรณ์ทั้ง 5 คลาสมีค่าน้อยกว่า 0.8000 หรือร้อยละ 80 และน้อยกว่าการฝึกโมเดลปรับพารามิเตอร์แบบที่ 1 จะเห็นได้ว่า โมเดลโครงข่ายประสาทนี้ไม่สามารถตรวจจับได้ครบทุกคลาสและไม่สามารถระบุโรคได้อย่าง



ภาพที่ 47 กราฟแสดงความแม่นยำ mAP ของโมเดลปรับพารามิเตอร์แบบที่ 2



ภาพที่ 48 กราฟแสดง Training loss และ Validation loss ของโมเดลปรับพารามิเตอร์แบบที่ 2



ภาพที่ 43 กราฟแสดง Training accuracy และ Validation accuracy ของ
โมเดลปรับ



บทที่ 5 สรุปงานวิจัย

5.1 สรุปผลวิจัย

วิทยานิพนธ์ฉบับนี้ ได้นำเสนอการสร้างระบบจำแนกชนิดและลักษณะอาการของโรคอ้อยแบบอัตโนมัติที่มีความแม่นยำ ซึ่งส่งผลให้การวินิจฉัยโรคอ้อยทำได้รวดเร็วมากขึ้น สำหรับจำแนกชนิดและลักษณะอาการของโรคอ้อยด้วยโครงข่ายประสาท เป็นระบบบนเว็บแอปพลิเคชันที่สามารถบ่งบอกชนิดของโรค พร้อมทั้งระบุสาเหตุและวิธีการป้องกัน และยังเก็บข้อมูลจากการเพิ่มข้อมูลภาพและชนิดของโรคผ่านหน้าเว็บแอปพลิเคชัน เพื่อจัดเก็บข้อมูลลงในฐานข้อมูลสำหรับการนำมาทำเป็นชุดฝึกข้อมูลโมเดลโครงข่ายประสาทต่อไปได้

ในส่วนของการการเพิ่มปริมาณชุดข้อมูลภาพมาใช้สร้างชุดข้อมูลภาพถ่ายใบอ้อยจากกล้องโทรศัพท์มือถือ ผู้วิจัยได้พัฒนาชุดคำสั่งในการบันทึกไฟล์ให้เท่ากับจำนวนชุดภาพที่ถูกเพิ่ม เพื่อสามารถนำชุดข้อมูลไปใช้ฝึกโครงข่ายประสาทใน TensorFlow นอกเหนือจากการฝึกในวิทยานิพนธ์ฉบับนี้ ถัดมาการพัฒนาโครงข่ายประสาทภายในระบบการจำแนกชนิดและลักษณะอาการของโรคอ้อย จากการฝึกด้วยชุดข้อมูลภาพใหม่ที่ยังไม่ได้รับการฝึกมาก่อนด้วยชุดข้อมูลภาพถ่ายใบอ้อยจากกล้องโทรศัพท์มือถือด้วยการปรับพารามิเตอร์แบ่งการฝึกโมเดลโครงข่ายประสาท จะถูกแบ่งออกเป็น 3 แบบ ได้แก่ การฝึกโมเดลแบบไม่มีการปรับพารามิเตอร์ การฝึกโมเดลปรับพารามิเตอร์แบบที่ 1 และการฝึกโมเดลปรับพารามิเตอร์แบบที่ 2 พบว่าการฝึกโมเดลปรับพารามิเตอร์แบบที่ 1 มีผลลัพธ์ในการจำแนกคลาส ใบอ้อยสมบูรณ์ (perfect) ใบอ้อยโรคเส้นกลางใบแดง (red_rot) ใบอ้อยโรคราสนิม (rust) ใบอ้อยโรคใบจุดวงแหวน (ring_spot) และใบอ้อยโรคใบขาว (white_leaf) มีค่า mAP สูงสุดที่ 0.8681 สามารถจำแนกใบอ้อยได้ครบทุกคลาส ในขณะที่การฝึกโมเดลแบบไม่ปรับพารามิเตอร์มีผลลัพธ์ค่า mAP สูงสุดที่ 0.7356 และการฝึกโมเดลปรับพารามิเตอร์แบบที่ 2 มีผลลัพธ์ค่า mAP สูงสุดที่ 0.2239 โดยที่ไม่สามารถระบุโรคอ้อยได้ จึงทำให้การฝึกโมเดลปรับพารามิเตอร์แบบที่ 1 ในรูปแบบโมเดลอนุมาน (Inference model) สามารถนำไปใช้กับระบบการจำแนกชนิดและลักษณะอาการของโรคอ้อยบนเว็บแอปพลิเคชันได้โดยตรง

ถึงแม้แบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชันจะมีความแม่นยำสูงบนชุดข้อมูลทดสอบ แต่ยังคงต้องการข้อมูลเพิ่มเติมเรื่อย ๆ เพื่อใช้ในการฝึกใหม่ (Retraining) เพื่อให้ได้แบบจำลองที่มีความคงทนต่อข้อมูลขาเข้าที่อาจจะมีความแตกต่างไปจากสิ่งที่แบบจำลองได้เคยเรียนรู้มา เช่น สภาพแวดล้อมขณะถ่ายภาพใบอ้อย อาจจะทำให้ภาพที่ถ่ายออกมามืดหรือมีเงาใด ๆ มาบดบังรูปใบอ้อย จะทำให้ภาพถ่ายที่ได้มีความสมบูรณ์น้อยกว่าการถ่ายรูปที่มีพื้นหลังตัดกับใบอ้อย อาจส่งผลให้แบบจำลองทำนายโรคเกิดการคลาดเคลื่อนผิดไปจากที่ควรจะเป็น

5.2 แนวทางการพัฒนางานวิจัย

แผนการดำเนินงานต่อไปที่มีการใช้โครงข่ายประสาทสถาปัตยกรรมอื่น ๆ ในฝึกด้วยชุดข้อมูลภาพเดียวกัน เช่น Inception, VGG, DenseNets, YOLO, ResNet ด้วย Keras เพื่อทดสอบหาความสามารถในการจำแนกชนิดและลักษณะอาการของโรคอ้อยที่พบมากในประเทศไทยจากภาพถ่ายที่ได้จากกล้องโทรศัพท์มือถือดูจากผลลัพธ์ mAP (mean Accuracy Precision) ต่อไป และความสามารถในการจำแนกระยะของโรค ได้แก่ ระยะเริ่มต้นของโรคจนถึงระยะรุนแรงของโรค รวมถึงการตรวจจำแนกโรคอ้อยมากขึ้น เช่น โรคใบเหลือง โรคใบขีด โรคใบต่าง โรคใบlovak เป็นต้น สำหรับระบบจำแนกชนิดและลักษณะอาการของโรคอ้อย คาดว่าจะปรับปรุงในส่วนของการทำกระบวนการก่อนประมวลผลภาพ (image pre-processing) ให้สามารถจำแนกขนาดของรูปภาพได้หลากหลายมากยิ่งขึ้น

5.3 ปัญหาและอุปสรรค

เนื่องจากโครงข่ายประสาทที่กำลังพัฒนาอยู่มีความแม่นยำ (Accuracy) ประมาณร้อยละ 80 ถึง 90 จึงทำให้ผลการจำแนกชนิดและลักษณะอาการของโรคอ้อยก่อให้เกิดความคลาดเคลื่อนจากกรณี เช่น โรคเกิดขึ้นซ้อนทับกันมากกว่า 1 โรค (Object overlapping) จึงมีความจำเป็นที่ต้องพัฒนาโครงข่ายประสาทให้มีขีดความสามารถมากขึ้น เช่น การเพิ่มปริมาณชุดข้อมูลภาพเพิ่มเติม การปรับแต่งโมเดลโครงข่ายประสาทให้มีประสิทธิภาพมากขึ้น หรืออาจเลือกต้นแบบโมเดลที่เหมาะสมต่อการทำงานภายใต้ทรัพยากรของระบบที่จำกัด และการเตรียมชุดข้อมูลที่เหมาะสมถ่ายภาพได้อย่างชัดเจน และพัฒนาปรับปรุงกระบวนการ Pre-processing ก่อนเข้าสู่การฝึก รวมถึงการเพิ่มจำนวน Epochs ให้มากขึ้นกว่าเดิม

ภาคผนวก ก. บทความวิจัยที่ได้ตีพิมพ์ใน RC-EEE 2021

RC-EEE 2021 January 6-7, 2022, Bangkok, Thailand

Development of an Algorithm for Classifying Common Sugarcane Diseases in Thailand

Nattapak Lawanwong and Suree Pumrin

Department of Electrical Engineering, Chulalongkorn University, Bangkok, Thailand.

Email: muknattapak@gmail.com, suree.p@chula.ac.th

Abstract—Crop disease is a major problem that affects the economy in Thailand. Sugarcane is one of the important crops in manufacture as well as the economy of Thai products. Khon Kaen 3 sugarcane is the most popular sugarcane variety in Thailand. It is resistant to environmental conditions, can grow normally in different terrain, and use less water for cultivation. Sugarcane disease is one of the major problems that causes a decrease in agricultural productivity. About 50-65% diseases identified in sugarcane leaves are cultivated from fungal including white leaf disease, rust disease, ring spot disease, and red midline disease or red rot disease. These diseases cause farmers to suffer in productivity, time, labor, and costs loss, as well as affect the industrial sector.

In this paper, Convolutional Neural Networks (CNNs) are applied for analyzing and detecting diseases in sugarcane leaf by Open-Source tools. ResNet-50 (Residual Neural Network) is used as backbone. CNNs are set to do transfer learning by weighting data. Then fine-tuning is added to increase the analytic process using Tensorflow. Sugarcane contains the diseases and normal sugarcane are classified by data collection, data augmentation, feature extraction and classification. They are labeled and separated into five classes. Data augmentation process includes GaussianBlur, LinearContrast, MultiplyBrightness, and AdditiveGaussianNoise. Feature histogram along with the segmentation method is used to separate sugarcane leaf from the background. Our model on ResNet-50 transfer learning with data augmentation and fine-tuning steps yields a promising result at 81.70% accuracy.

Keyword—convolution neural network, fine-tuning, transfer learning, sugarcane diseases, Resnet-50

I. INTRODUCTION

Sugarcane is one of the important economic plants in Thailand. It is a kind of nutrient that is necessary for humans and other creatures. Sugar is a product from sugarcane contained in many foods manufacturers such as bakeries, beverages, sweets, cosmetics, and renewable energy (in form of gasohol) [1]. OFFICE OF THE CANE AND SUGAR BOARD shows that cultivation of sugarcane and sugarcane fields in 2020 to 2021 is about 10,862,610 acres. It decreases about 9.17% [2] from the previous year. Even there is development in genetic and plant breeding; however, agricultural products from sugarcane are still weaken [3]. The various diseases infecting the sugarcane lead to a decrease in the quality and quantity of sugarcane production. These problems cause by bacteria, fungi, and insects. There are more than 150 types of diseases that occur in sugarcane [4].

Sugarcane abnormal symptoms show in leaves, stems, and roots which occur as leaf spots, dry torn leaves, white leaves, shriveled, deformed leaves, burnt leaves, stunted stems, lots of tillering more than normal, stems, and roots rot [5]. Manpower is still the main source to detect and identify diseases that occur in sugarcane, which needs experience and time.

Image processing is one of the various methods that have been used for detecting diseases in agricultural plants. Image processing usually includes 4 steps: 1. Data collection, 2. Data Augmentation, 3. Feature Extraction, and 4. Classification. It helps cultivator or farmer to analyze and detect at early stage of diseases. We collected pictures of normal sugarcane (healthy crops) and infected sugarcane (sugarcane leaf diseases) at Cane and Sugar Industry Promoting Center, Chonburi and Sugarcane plot located at Moo 6, WatSuwan, Borthong, Chonburi. Image dataset is processed as JPEG or PNG file using RGB color. Over a year, a number of image analysis-based methodologies have been proposed for automatic image identification of various matters such as disease identification and classify plant [6]. Deep Convolutional Neural Networks is one of the most successful techniques for differentiating visual disease in crops [7].

In this paper, Deep Convolutional Neural Networks along with the mobile application are applied to automatically identify the disease at its early stage. The application will assist farmers to identify the disease and provide the prevention method to control infected crops. Our tool is easy to use online through the mobile application.

II. RELATED WORKS

Image analysis-based methodologies aim to identify and analyze objects. There are different techniques provided with the aim of simplifying the analysis of images. Methods for identifying sugarcane disease are based on algorithmic image processing and mathematical equations, identifying the shape and color of sugarcane leaf from the pictures. Each method applies a similar section, namely image segmentation, feature extraction, and classification

Evy Kamilah Ratnasari et al. [8] represented accurate segmentation method. This method results from analysing sugarcane leaves by thresholding in color space. The classification results process features in Support Vector Machine (SVM). SVM was done in $L^*a^*b^*$ (L^* : Lightness, a^* : Red/Green Value, and b^* : Blue/Yellow Value) color space along with Gray Level Co-Occurrence Matrix

(GLCM). Identification of model, which runs by this feature, yields accuracy of 80%. Swapnil Dadabhau Daphal et al. [9] identify disease on sugarcane leaves because it can be recognized. Besides, the stage of disease was easy to identify. Deep neural networks (DNN) and Convolutional Neural Network (CNN) were used. Their techniques improve in recovery rate (RA) and reduce predicting time. For feature extraction, ResNet-50 as backbone was introduced to this model. More than 2,000 images were used as database. This model yields accuracy of 85.39%. DenseNet201 (Dense Convolution Network – is a convolutional neural network that is 201 layers deep) as backbone yields accuracy of 86.53%. Artzai Picono et al. [10] presented mobile application to identify disease on sugarcane leaves using Deep Convolutional Neural Networks (CNNs). Input images were reduced to 224x224 pixel and cropped only the interest part. Superpixel, a perceptual group of pixels, based tile extraction by Simple Linear Iterative Clustering (SLIC) was used as well. Images of 8,178 as database were used which yield accuracy of 87%. Umapathy Eaganathan et al. [11] applied acquisition, filtering, segmentation, and feature extraction methods to identify Leaf scorch disease on sugarcane leaves. Feature extraction method including histogram color of cane leaf image was converted to gray scale. Segmentation method was proposed to separate background from interest object using K-mean, which is a method of vector quantization that aims to partition n observations into k clusters. This model yields accuracy of 95%. Result of grey scale and color image processing was compared for identify disease on sugarcane leaves in Anoop G L. [12] Grey scale was used to get the interest object of disease image including various processes such as Gradient Magnitude, Otsu method, which is a global adaptive binarization threshold image segmentation algorithm, Morphological Operations, and Normalization. In color image process, RGB was converted into L*a*b format and applied to K-means clustering and edge detection operations resulted in proper feature. Support Vector Machine (SVM) classifier was used in classification step. A color image accuracy result is better than gray scale. Color processing for yellow leaf disease contributes accuracy of 100%. However, in ring and rust leaf diseases yield accuracy of 80-90% both in grey scale and color processing.

III. OVERVIEW OF CLASSIFYING COMMON SUGARCANE DISEASES

Based on the review articles above, the methods described by Swapnil Dadabhau Daphal et al. [9] and Artzai Picono et al. [10] are modified for our sugarcane diseases classification. Our paper presents a transfer learning from ResNet-50 [13-14]. The proposed architecture is shown in Fig. 2. Reduced input images are applied to develop an algorithm for classifying common sugarcane diseases. The ResNet-50 contains a 7×7 convolution layer with 64 kernels, a 3×3 max pooling layer with stride 2, 16 residual building blocks, a 7×7 average pooling layer with stride 7, and a new fully connected layer before the softmax output layer.

An experimental design through a workflow diagram presents whether the sugarcane plant is infected or not. The diseases identified through leaf images is shown in Fig. 1.

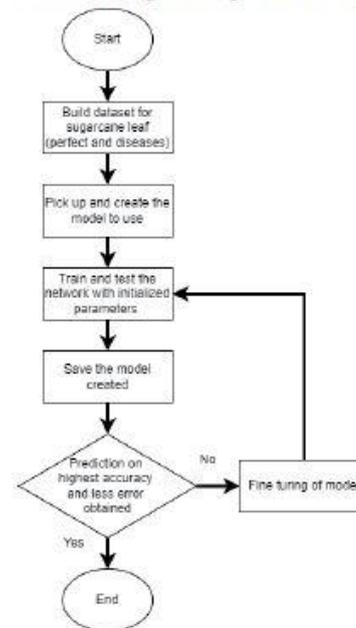


Figure 1. Workflow diagram of an algorithm for classifying sugarcane diseases

A. Image dataset acquisition

Image of sugarcane leaf is acquired using mobile phone. These input images are saved in a folder separated into different classes of disease images and a healthy image of sugarcane leaves. Each image is collected as JPEG or PNG file using RGB format. There are shown in Fig. 2.

B. Image data augmentation

Data augmentation method is applied to increase the amount of image data by modifying the existing image. Based on an assumption that the image characteristics must not change too much. Augmentation is done by applying library imgaug including various processes such as GaussianBlur, LinearContrast, MultiplyBrightness and AdditiveGaussianNoise.

C. Pre-processing of images

Pre-processing techniques are used to reduce image size, cropped image, and enhanced image. Each image applies color isolation using HSV (Hue, Saturation, and Value) segmentation and contour, resulted in interested object without background. Also, our algorithm measures the min, max, and mean values of colors to extract as an image feature.

In this model, 256x256 resolution of image is used for future processing.

D. Feature extraction

The convolutional layer obtains from pre-processing step of image (after resized process). Each convolutional layer has M maps of equal size, M_x and M_y , and a kernel of size K_x , and K_y , is shifted over the certain region of the input image. The skipping factors, S_x and S_y , define how many pixels the filter-kernel skips in x - and y - direction between subsequent convolutions [15]. The size of the output map could be defined as

$$M_x^n = \frac{M_x^{n-1} - K_x^n}{S_x^n} + 1, \quad (1)$$

$$M_y^n = \frac{M_y^{n-1} - K_y^n}{S_y^n} + 1, \quad (2)$$

where n indicates the layer. Each map in layer, L^n , is connected to most M^{n-1} maps in layer L^{n-1} .

Various steps of convolutional and different types of pooling like max pooling and average pooling are applied, which act as filter to produce features [16]. Rectified non-linear activation function (ReLU) is also applied to the output of every convolutional and fully connected layer [17] for increase efficiency of the model. ReLU are used as substitute for saturating nonlinearities. This activation function adaptively learns the parameters of rectifiers and improves accuracy at negligible extra computational cost [15]. It is defined as

$$f(z_i) = \max(0, z_i), \quad (3)$$

where z_i represents the input of the nonlinear activation function f on the i th channel.

E. Classification

Final step, classification is performed in a fully connected layer. The normal (healthy) or abnormal (infected) of sugarcane leaf is identified and classified into four different types of diseases in this layer.

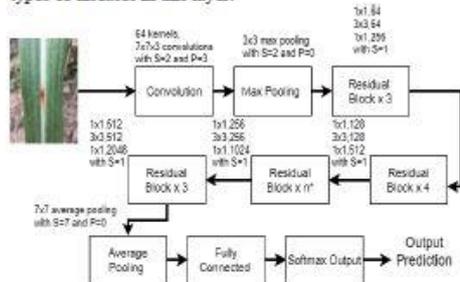


Figure 2. Our proposed transfer learning architecture with modified ResNet-50 (n^* =6, S – Stride, and P – Padding).

Our system specification consists of OS Ubuntu 20.04 LTS and Microsoft Windows 10, CPU AMD Ryzen 3 Series 3200x 3.6GHz 4 cores 4 threads, GPU NVIDIA GeForce GTX 1080Ti 11Gb, Motherboard Asus 1200 PRIME B560-PLUS,

RAM Hyper-X DDR3 1600MHz 8GB, Storage WD BLACK WD1003FZEX 512GB.



Figure 3. Sample sugarcane leaf images with (a) perfect and (b-d) abnormal diseases

IV. RESULT AND CONCLUSION

Model ResNet-50 learning without data augmentation and feature extraction steps yields accuracy of 73.20%. There are shown in Fig. 4. For the model that runs on ResNet-50 learning with data augmentation and feature extraction steps yields better result at 81.70% accuracy. There are shown in Fig. 5. The first model is set at 30 epochs, 32 batch and learning rate of 0.001. The second model is set at 50 epochs, 32 batch and learning rate of 0.3.

The experimental results show that Convolutional Neural Networks (CNNs) assist in detection. Besides, they also can classify whether the sugarcane leaf is diseased or healthy. The system reduces human error and prevents an outbreak of serious diseases. Our automatic classification technique provides abundant of benefit to farmers. The trained model has high competence in image recognition, but it still needs to be taught or inputs varieties of image data based on leave patterns. In the future, combination techniques of pre-processing and feature extraction should be explored. We would compare multiple neural network models for comprehensive accuracy evaluation. Mobile application will be applied in LINE official account, which is easy for everyone to use. It could automatically reply to the user with message such as stage of disease, source of disease, severity of disease, and treatment guideline.

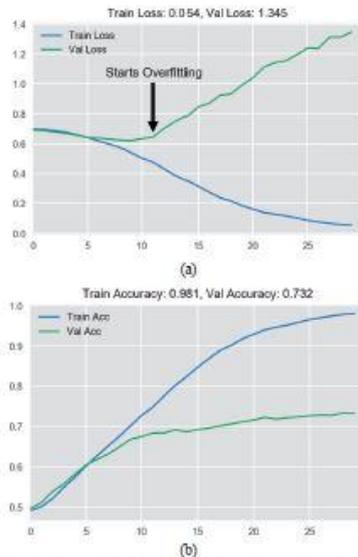


Figure 4. Transfer learning without data augmentation and feature extraction show (a) the loss result and (b) accuracy during model training

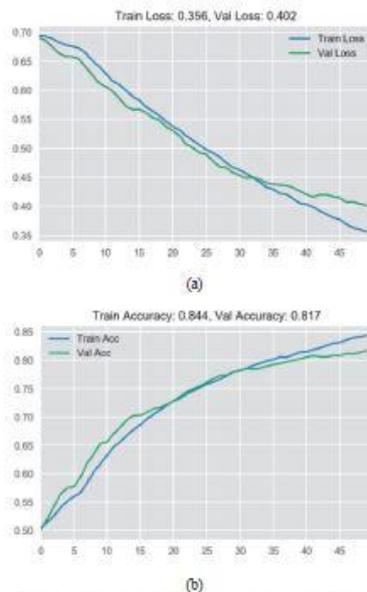


Figure 5. Transfer learning with data augmentation and feature extraction show (a) the loss result and (b) accuracy during model training

ACKNOWLEDGMENT

The research could not be completed without the support of the Embedded System and IC Design Research Laboratory, Department of Electrical Engineering, Chulalongkorn University. Thanks to an advisor, specialists from the Office of the Cane and Sugar Board, and sugarcane farmers who have contributed to this research and achieved its goals.

REFERENCES

- [1] Energy Policy and planning Office-Thailand, *Bio-energy*, 28 June 2016.
- [2] Office of Cane and Sugar Board, *Sugarcane cultivation report of 2020-21*, May 2021.
- [3] (NSTDA), N., *Sugarcane breeding for marker-assisted selection*, 12 March 2021.
- [4] Hamam, *Sugarcane Diagnosis Manual*, ed. 2, March 2019.
- [5] Sensor Profession Agriculture Research, et al., *Sugarcane disease and prevention*, 1985.
- [6] A. Krizhevsky, I. S., and G. E. Hinton, *Imagenet classification with deep convolutional neural networks*. Advances in neural information processing systems, 2012, 25.
- [7] H. Park, J. S. Eun and S. H. Kim, *Image-based disease diagnosing and predicting of the crops through the deep learning mechanism*, In Information and Communication Technology Convergence (ICTC), IEEE 2017 International Conference on, pp. 129-131, 2017.
- [8] Evy Kamilah Ratnasari, M.M., Ratih Kartika Dewi, R. V. Hari Gnaridi, *sugarcane leaf disease detection and severity estimation based on segmented spots image*. International Conference on Information, Communication Technology and System, 2014.
- [9] Swapnil Dadabhau Daphal, S.M.K., *Identification of Sugarcane Foliar Diseases: Methods and Datasets*. International Journal of Engineering and Advanced Technology (IJEA), February, 2020.
- [10] Artzai Picono, A.A.-G., Maximilian Seitz, d. Amalia Ortiz-Barredo, Jone Echazarra, and A. Johannesd, *Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild*. Computers and Electronics in Agriculture, 2019.
- [11] Unapathy Eganathan, D.J.S., Vinukumar Luckose, Feroze Jacob Benjamin, *Identification of Sugarcane Leaf Scorch Diseases using K-means Clustering Segmentation and K-NN based Classification*. International Journal of Advances in Computer Science and Technology (IJACST), 2014 - Held on 22nd December 2014.
- [12] Anoop G L, C.N., *Detection and Classification of Ring, Rust and Yellow Sugarcane Leaf Diseases*. International Journal of Engineering and Advanced Technology (IJEA), August 2019.
- [13] Too, E.C., Yujian, L., Njuki, S., Yingchun, L., 2018. *A comparative study of fine-tuning deep learning models for plant disease identification*. Comput. Electron. Agric. 161, 272-279.
- [14] R. Manavalan, *Efficient Detection of Sugarcane Diseases through Intelligent Approaches: A Review*. Asian Journal of Research and Review in Agriculture, 2021, pp.27-37.
- [15] D. C. Cireşan, U. Meier, J. Masci, L. M. Gambardella, and J. Schmidhuber, *Flexible, high performance convolutional neural networks for image classification*. in Proceedings of the 22nd International Joint Conference on Artificial Intelligence, vol. 2, pp. 1237-1242, 2011.
- [16] D. G. Tsolakidis, D. I. Kosmopoulos, and G. Papadourakis, *Plant leaf recognition using semite moments and histogram of oriented gradients*. in Hellenic Conference on Artificial Intelligence. Springer, 2014, pp. 406-417.
- [17] S. Sladojevic, M. Arsenovic, A. Anderla, D. Culibrk, and D. Stefanovic, *Deep Neural Networks Based Recognition of Plant Diseases by Leaf Image Classification*. Computer Intelligence Neuroscience, vol. 2016, 2016.

บรรณานุกรม

1. สำนักงานนโยบายและแผนพลังงานกระทรวงแรงงาน, พลังงานชีวภาพ. 28 มิถุนายน 2559.
2. สำนักงานคณะกรรมการอ้อยและน้ำตาลทราย, ก.ก., รายงานสถานการณ์การปลูกอ้อยปีการผลิต 2563/64. พฤษภาคม 2564.
3. (สวทช), ส., การปรับปรุงพันธุ์อ้อยแบบบูรณาการเพื่อเพิ่มผลผลิตน้ำตาล. 12 มีนาคม 2564.
4. ทะหมาน, น., คู่มือวินิจฉัยโรคอ้อย. มีนาคม 2559.
5. A. Krizhevsky, I.S., and G. E. Hinton,, *Imagenet classification with deep convolutional neural networks*. Advances in neural information processing systems, 2012. 25.
6. ประดุษณม์, จ.ไ.อ.จ., เรียนรู้และทำความเข้าใจเรื่อง *Convolutional Neural Network (CNN)* คืออะไร. 2019.
7. Mark Everingham, S.M.A.E., Luc Van Gool, Christopher K. I. Williams, John Winn, Andrew Zisserman, *The PASCAL Visual Object Classes Challenge: A Retrospective*. International Journal of Computer Vision (Int J Comput Vis) (2015), 2015. **111:98-136**.
8. K Simonyan, A.Z., *VERY DEEP CONVOLUTIONAL NETWORKS FOR LARGE-SCALE IMAGE RECOGNITION*, in *3rd International Conference on Learning Representations (ICLR 2015)*. 2015: San Diego, CA, USA.
9. Kaiming He, X.Z., Shaoqing Ren, Jian Sun, *Deep Residual Learning for Image Recognition*. IEEE Conference on Computer Vision and Pattern Recognition, 2016.
10. นักวิชาการเกษตรชานาญการพิเศษ, น.ศ., et al., โรคอ้อยและการป้องกันกำจัด. 2528.
11. Evy Kamilah Ratnasari, M.M., Ratih Kartika Dewi, R. V. Hari Ginardi, *sugarcane leaf disease detection and severity estimation based on segmented spots image*. International Conference on Information, Communication Technology and System, 2014.
12. Swapnil Dadabhau Daphal, S.M.K., *Identification of Sugarcane Foliar Diseases: Methods and Datasets*. International Journal of Engineering and Advanced Technology (IJEAT), February, 2020.

13. Artzai Picon, A.A.-G., Maximilian Seitz, Amaia Ortiz-Barreda, Jone Echazarra, and A. Johannes, *Deep convolutional neural networks for mobile capture device-based crop disease classification in the wild*. Computers and Electronics in Agriculture, 2019.
14. Umapathy Eaganathan, D.J.S., Vinukumar Luckose, Feroze Jacob Benjamin, *Identification of Sugarcane Leaf Scorch Diseases using K-means Clustering Segmentation and K-NN based Classification*. International Journal of Advances in Computer Science and Technology (IJACST), 2014 - Held on 22nd December 2014.
15. P.DharaniDevi, S.L., *fuzzy logic based sugarcane leaf disease identification and classification using k-means clustering and neural network*. IJMTEs | International Journal of Modern Trends in Engineering and Science, 2016.
16. Anoop G L, C.N., *Detection and Classification of Ring, Rust and Yellow Sugarcane Leaf Diseases*. International Journal of Engineering and Advanced Technology (IJEAT), August 2019.
17. Chaiyadecha, S., *สร้าง Web Application พร้อม Deploy ไปที่ Heroku ด้วย Streamlit*. 2021..
18. Jung, A.B., et al. *imgaug*. [Image augmentation for machine learning experiments] Feb 2020; Available from: <https://github.com/aleju/imgaug>.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	ณัฐภัค ลาวัลย์วงศ์
วัน เดือน ปี เกิด	28 มีนาคม 2540
สถานที่เกิด	รพ.สมเด็จพระนางเจ้าสิริกิติ์
วุฒิการศึกษา	ปริญญาตรี สาขาวิชาวิศวกรรมระบบสมองกลฝังตัว คณะวิศวกรรมศาสตร์ มหาวิทยาลัยบูรพา
ที่อยู่ปัจจุบัน	131/60-61 ม.12 ต.หนองปรือ อ.บางละมุง จ.ชลบุรี 20150
ผลงานตีพิมพ์	N. Lawanwong and S.Pumrin, "Development of an Algorithm for Classifying Common Sugarcane Diseases in Thailand," RC-EEE 2021, January 6-7, 2022, Bangkok, Thailand.