




การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยเพื่อรองรับการ
เป็นเกษตรอัจฉริยะ

วิทยานิพนธ์
ของ
ศุภชัย ใบปอด

เสนอต่อมหาวิทยาลัยมหาสารคาม เพื่อเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาการจัดการสมรรถนะดีและนวัตกรรมดิจิทัล
มีนาคม 2567

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม


การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยเพื่อรองรับการ
เป็นเกษตรอัจฉริยะ



มีนาคม 2567

ลิขสิทธิ์เป็นของมหาวิทยาลัยมหาสารคาม

Applying Deep Learning Techniques for Disease Detection and Analysis from
Sugarcane Leaf Images to Support Smart Agriculture



Supachai Baipod

A Thesis Submitted in Partial Fulfillment of Requirements
for Master of Science (Smart City Management and Digital Innovation)

March 2024

Copyright of Mahasarakham University



คณะกรรมการสอบวิทยานิพนธ์ ได้พิจารณาวิทยานิพนธ์ของนายศุภชัย ไบปอด แล้ว
เห็นสมควรรับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาการ
จัดการสารสนเทศซีดีและนวัตกรรมดิจิทัล ของมหาวิทยาลัยมหาสารคาม

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ

(ผศ. ดร. มณีรัตน์ วงษ์ขี้ม)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ผศ. ดร. จรวย สาวีถิ)

.....กรรมการ

(ผศ. ดร. นิพนธ์พัทธ์ เมืองโคตร)

.....กรรมการผู้ทรงคุณวุฒิภายนอก

(ศ. ดร. ระพีพันธ์ ปิตาคะโส)

มหาวิทยาลัยอนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญา วิทยาศาสตรมหาบัณฑิต สาขาวิชาการจัดการสารสนเทศซีดีและนวัตกรรมดิจิทัล ของ
มหาวิทยาลัยมหาสารคาม

.....
(อ. ดร. ชลธิชา ธรรมวิญญู)

คณบดีคณะกรรมการบัญชีและการจัดการ

.....
(รศ. ดร. กริสน์ ชัยมูล)

คณบดีบัณฑิตวิทยาลัย

ชื่อเรื่อง	การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบ อ้อยเพื่อรองรับการเป็นเกษตรอัจฉริยะ		
ผู้วิจัย	ศุภชัย ใบปอด		
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. จรวัย สาวีถิ		
ปริญญา	วิทยาศาสตรมหาบัณฑิต	สาขาวิชา	การจัดการสารสนเทศและนวัตกรรม ดิจิทัล
มหาวิทยาลัย	มหาวิทยาลัยมหาสารคาม	ปีที่พิมพ์	2567

บทคัดย่อ

งานวิจัยฉบับนี้ได้ศึกษาเทคนิคการเรียนรู้เชิงลึกโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน เพื่อใช้ในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยเพื่อรองรับการเป็นเกษตรอัจฉริยะ โดยมีจุดประสงค์เพื่อสร้างโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ภาพใบอ้อยเพื่อตรวจสอบโรค และเปรียบเทียบประสิทธิภาพโมเดลโครงข่ายประสาทแบบคอนโวลูชันจำนวน 5 โครงสร้าง ประกอบด้วย VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet ข้อมูลรูปภาพใบอ้อยที่นำมาใช้ทดสอบมีจำนวน 1 ชุดข้อมูล ที่ผู้วิจัยจัดเก็บขึ้นเอง คือ Sugarcane Leaf Disease Dataset เป็นรูปภาพใบอ้อยที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ มีการแบ่งชุดข้อมูลออกเป็น 3 รูปแบบ คือ 75:25, 80:20, และ 90:10 เป็นข้อมูล Train Data และ Test Data ตามลำดับ จากผลการเปรียบเทียบพบว่าโมเดลที่มีประสิทธิภาพสูงที่สุดในแต่ละชุดข้อมูล ได้แก่ ชุดข้อมูลแบบ 75:25 โมเดล DenseNet-121 มีค่าความแม่นยำโดยรวม อยู่ที่ 96.71% ชุดข้อมูลแบบ 80:20 โมเดล ResNet-50 มีค่าความแม่นยำโดยรวม อยู่ที่ 96.99% และชุดข้อมูลแบบ 90:10 โมเดล DenseNet-121 มีค่าความแม่นยำโดยรวม อยู่ที่ 97.28% ผู้วิจัยจึงเลือกโมเดล DenseNet-121 ในชุดข้อมูลแบบ 90:10 ไปใช้ในการพัฒนาระบบ LINE Chatbot และผลการทดสอบระบบแชทบอท สามารถตอบกลับแบบอัตโนมัติได้อย่างมีประสิทธิภาพ

คำสำคัญ : การเรียนรู้เชิงลึก, โครงข่ายประสาทเทียมแบบคอนโวลูชัน, ไลน์แชทบอท

TITLE	Applying Deep Learning Techniques for Disease Detection and Analysis from Sugarcane Leaf Images to Support Smart Agriculture		
AUTHOR	Supachai Baipod		
ADVISORS	Assistant Professor Charuay Savithi , Ph.D.		
DEGREE	Master of Science	MAJOR	Smart City Management and Digital Innovation
UNIVERSITY	Maharakham University	YEAR	2024

ABSTRACT

This study examines convolutional neural networks as a tool for deep learning approaches. to promote smart agriculture by analyzing and identifying diseases from photos of sugarcane leaves. Developing a deep learning model to examine photos of sugarcane leaves and identify illness is the goal. and contrast the output of five convolutional neural network models: GoogLeNet, AlexNet, ResNet-50, DenseNet-121, and VGGNet-16. The researcher saved one data set of sugarcane leaf picture data for testing purposes. A picture of sugarcane leaves in their natural setting can be found in the Sugarcane Leaf Disease Dataset. The dataset is separated into three formats, namely 75:25, 80:20, and 90:10 as Train Data and Test Data, respectively. The model with the best performances for every dataset is determined by the comparison results to be: The overall accuracy of the DenseNet-121 model on the 75:25 data set is 96.71%; the overall accuracy of the ResNet-50 model on the 80:20 data set is 96.99%; and the overall accuracy of the DenseNet-121 model on the 90:10 data set is 96.71%. 97.28% was the accuracy rate overall. For this reason, the researcher developed the LINE Chatbot system and the chatbot system testing results using the DenseNet-121 model from the 90:10 data set. able to provide efficient automated responses.

Keyword : Deep learning; Convolutional Neural Networks; LINE Chatbot

กิตติกรรมประกาศ

ขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.จรรย สาวิติ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่เสียสละเวลาช่วยเหลือ ให้คำปรึกษา คำแนะนำ แนวคิด ชี้แนะข้อบกพร่อง และติดตามความก้าวหน้าของงานวิจัย รวมทั้งให้ข้อคิดต่างๆ ในการศึกษาวิจัยนี้ เป็นประโยชน์อย่างมากในการพัฒนาตนเอง ทั้งให้ความเอาใจใส่ ทำให้ผู้วิจัยสามารถดำเนินงานวิจัยจนประสบผลสำเร็จลุล่วงไปด้วยดี

ขอขอบพระคุณผู้เชี่ยวชาญทางด้านพืชอ้อย และผู้เชี่ยวชาญทางการพัฒนาระบบงานทางคอมพิวเตอร์ อาจารย์ทินกร คุณาสีทธิ์ อาจารย์ประจำหลักสูตรวิทยาการคอมพิวเตอร์ มหาวิทยาลัยราชภัฏมหาสารคาม และคณาจารย์ทุกท่าน เป็นอย่างสูงยิ่ง ที่ให้คำปรึกษาช่วยในการศึกษาวิจัยครั้งนี้

ขอขอบพระคุณอาจารย์ทุกท่านที่ประสิทธิ์ประสาทวิชาความรู้ให้แก่ผู้วิจัยด้วยความเมตตา ขอขอบพระคุณท่านผู้ทรงคุณวุฒิ และคณะกรรมการสอบวิทยานิพนธ์ทุกท่าน ที่ให้ความรู้ คำแนะนำทำให้วิทยานิพนธ์นี้สมบูรณ์และสำเร็จลุล่วงไปได้ด้วยดี

สุดท้ายนี้ผู้วิจัยขอกราบขอบพระคุณบิดามารดาและครอบครัวของข้าพเจ้าที่ได้ให้ชีวิตและโอกาสทางการศึกษา คอยเป็นกำลังใจ ห่วงใยเสมอมา ตลอดจนญาติมิตรทุกท่าน ที่ได้ให้ความเมตตาและกำลังใจ จนทำให้วิทยานิพนธ์นี้ได้สำเร็จไปได้ด้วยดี คุณค่าและประโยชน์อันพึงได้จากวิทยานิพนธ์ฉบับนี้ ผู้วิจัยขอบมอบแด่ผู้มีพระคุณทุกท่าน

ศุภชัย ใบปอด



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญภาพ.....	ญ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของการวิจัย.....	1
1.2 ความมุ่งหมายและวัตถุประสงค์ของการวิจัย.....	2
1.3 ขอบเขตในการวิจัย.....	3
1.4 ผลที่คาดว่าจะได้รับการวิจัย.....	3
1.5 นิยามศัพท์เฉพาะ.....	4
1.6 ข้อยกเว้นของการวิจัย.....	4
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	6
2.1 อ้อย (Sugar cane).....	6
2.2 คอมพิวเตอร์วิทัศน์ (Computer Vision).....	20
2.3 การเรียนรู้เชิงลึก (Deep Learning).....	22
2.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN).....	25
2.5 การวัดประสิทธิภาพของโมเดล (Performance Measurement).....	32
2.6 เกษตรอัจฉริยะ (Smart Farming).....	34
2.7 ไลน์แชทบอท (LINE Chatbot).....	38

2.8 งานวิจัยที่เกี่ยวข้อง (Literature Review)	39
บทที่ 3 วิธีการดำเนินงานวิจัย	44
3.1 ชุดข้อมูลรูปภาพที่ใช้ในการวิจัย	44
3.2 การทดลองวิเคราะห์ตรวจสอบโรคโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน	48
3.3 การทดสอบประสิทธิภาพ	49
3.4 การออกแบบและพัฒนาระบบ LINE Chatbot	49
บทที่ 4	51
ผลการศึกษา	51
4.1 เครื่องมือและชุดข้อมูลที่ใช้ในการทดลอง	51
4.2 วิธีการทดลอง	53
4.3 ผลการจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก	54
4.4 ผลการเปรียบเทียบประสิทธิภาพของโมเดล	75
4.5 ผลการพัฒนาระบบ LINE Chatbot	78
บทที่ 5	83
สรุปผลและข้อเสนอแนะ	83
5.1 สรุปผลการวิจัย	83
5.2 การอภิปรายผล	84
5.3 ข้อเสนอแนะและงานวิจัยในอนาคต	84
บรรณานุกรม	85
ประวัติผู้เขียน	94

สารบัญตาราง

	หน้า
ตาราง 1 รายงานพื้นเพาะปลูกอ้อยและผลผลิตส่งโรงงานปีการผลิต 2565/2566	11
ตาราง 2 แสดงตาราง Confusion Matrix	32
ตาราง 3 ชุดข้อมูลในการทดลองแบ่งด้วยอัตราส่วนร้อยละ 75:25	52
ตาราง 4 ชุดข้อมูลในการทดลองแบ่งด้วยอัตราส่วนร้อยละ 80:20	52
ตาราง 5 ชุดข้อมูลในการทดลองแบ่งด้วยอัตราส่วนร้อยละ 90:10	52
ตาราง 6 พารามิเตอร์ที่ใช้ในการเตรียมชุดข้อมูล	53
ตาราง 7 พารามิเตอร์ในการกำหนดค่าทดสอบการเรียนรู้เชิงลึก.....	53
ตาราง 8 สรุปผลในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย.....	64
ตาราง 9 ประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล Train Data=75%	75
ตาราง 10 ประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล Train Data=80%.....	76
ตาราง 11 ประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล Train Data=90%.....	77
ตาราง 12 ผลการเปรียบเทียบประสิทธิภาพโมเดล.....	78

พูน ปณ จิต ชีเว

สารบัญภาพ


หน้า

ภาพประกอบ 1 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.ขอนแก่น ปีการผลิต 2565/66 [3]	12
ภาพประกอบ 2 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.กาฬสินธุ์ ปีการผลิต 2565/66 [3]	13
ภาพประกอบ 3 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.ร้อยเอ็ด ปีการผลิต 2565/2566 [3]	14
ภาพประกอบ 4 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.มหาสารคาม ปีการผลิต 2565/66 [3]	15
ภาพประกอบ 5 ลักษณะอ้อยที่เป็นโรคราสนิม	17
ภาพประกอบ 6 ลักษณะอ้อยที่เป็นโรคเส้นกลางใบแดง	18
ภาพประกอบ 7 อาการโรคเส้นกลางใบแดง.....	18
ภาพประกอบ 8 ลักษณะอ้อยที่เป็นโรคใบจุดวงแหวน	19
ภาพประกอบ 9 ความสัมพันธ์ระหว่าง Artificial intelligence, Machine learning และ Deep learning	22
ภาพประกอบ 10 การเปรียบเทียบประสิทธิภาพอัลกอริทึมการเรียนรู้ของเครื่องในรูปแบบต่าง ๆ ตามปริมาณของข้อมูลในการเรียนรู้ [31]	23
ภาพประกอบ 11 การเปรียบเทียบส่วนประกอบเซลล์ประสาทสมองมนุษย์ (ก) และเซลล์ประสาทเทียม (ข) [30]	24
ภาพประกอบ 12 โครงสร้างของอัลกอริทึม CNN [14].....	25
ภาพประกอบ 13 สถาปัตยกรรมของ VGGNet [7].....	27
ภาพประกอบ 14 แนวคิดของ residual learning หรือ residual block ซึ่งเป็นแนวคิดหลักของ ResNet [8].....	28
ภาพประกอบ 15 สถาปัตยกรรมของ DenceNet-121 [9].....	29
ภาพประกอบ 16 สถาปัตยกรรมของ AlexNet [10].....	30
ภาพประกอบ 17 หลักการของ Inception Modules ที่เป็นส่วนสำคัญของ GoogLeNet [11]	32
ภาพประกอบ 18 แผนยุทธศาสตร์เกษตรและสหกรณ์ ระยะ 20 ปี (พ.ศ.2560-2579) [4].....	36

ภาพประกอบ 19 แผนปฏิบัติการเกษตรอัจฉริยะ 2565-2566 [44]	36
ภาพประกอบ 20 งานวิจัยที่ต้องการเพิ่มเติมในพื้นที่กลุ่มภาคตะวันออกเฉียงเหนือตอนกลาง [4] ...	37
ภาพประกอบ 21 Messaging API overview.....	38
ภาพประกอบ 22 ตัวอย่างภาพใบอ้อยที่เป็นโรคเน่าแดง จากฐานข้อมูล Sugar Cane Leaf Disease Dataset.....	45
ภาพประกอบ 23 ตัวอย่างภาพใบอ้อยที่เป็นโรคจุดวงแหวน จากฐานข้อมูล Sugar Cane Leaf Disease Dataset.....	45
ภาพประกอบ 24 ตัวอย่างภาพใบอ้อยที่เป็นโรคราสนิม จากฐานข้อมูล Sugar Cane Leaf Disease Dataset.....	45
ภาพประกอบ 25 ตัวอย่างภาพใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ จากฐานข้อมูล Sugar Cane Leaf Disease Dataset.....	46
ภาพประกอบ 26 ตัวอย่างภาพใบอ้อยที่เป็นโรคเน่าแดง จากฐานข้อมูล Sugar Cane Leaf Disease Dataset ที่ใช้ในการทดสอบประสิทธิภาพ (Test Data)	46
ภาพประกอบ 27 ตัวอย่างภาพใบอ้อยที่เป็นโรคจุดวงแหวน จากฐานข้อมูล Sugar Cane Leaf Disease Dataset ที่ใช้ในการทดสอบประสิทธิภาพ (Test Data).....	47
ภาพประกอบ 28 ตัวอย่างภาพใบอ้อยที่เป็นโรคราสนิม จากฐานข้อมูล Sugar Cane Leaf Disease Dataset ที่ใช้ในการทดสอบประสิทธิภาพ (Test Data)	47
ภาพประกอบ 29 การแบ่งจำนวนรูปภาพสำหรับ Train และ Test	48
ภาพประกอบ 30 LINE Chatbot Architecture	50
ภาพประกอบ 31 Train Data 75% กับโครงสร้าง VGG-16 ที่ epoch=20	54
ภาพประกอบ 32 Train Data 75% กับโครงสร้าง ResNet-50 ที่ epoch=20.....	55
ภาพประกอบ 33 Train Data 75% กับโครงสร้าง DenseNet-121 ที่ epoch=20.....	55
ภาพประกอบ 34 Train Data 75% กับโครงสร้าง AlexNet ที่ epoch=20	56
ภาพประกอบ 35 Train Data 75% กับโครงสร้าง GoogLeNet ที่ epoch=20.....	57
ภาพประกอบ 36 Train Data 80% กับโครงสร้าง VGG-16 ที่ epoch=20	57
ภาพประกอบ 37 Train Data 80% กับโครงสร้าง ResNet-50 ที่ epoch=20	58

ภาพประกอบ 38 Train Data 80% กับโครงสร้าง DenseNet-121 ที่ epoch=20.....	59
ภาพประกอบ 39 Train Data 80% กับโครงสร้าง AlexNet ที่ epoch=20	59
ภาพประกอบ 40 Train Data 80% กับโครงสร้าง GoogLeNet ที่ epoch=20	60
ภาพประกอบ 41 Train Data 90% กับโครงสร้าง VGG-16 ที่ epoch=20	61
ภาพประกอบ 42 Train Data 90% กับโครงสร้าง ResNet-50 ที่ epoch=20	61
ภาพประกอบ 43 Train Data 90% กับโครงสร้าง DenseNet-121 ที่ epoch=20.....	62
ภาพประกอบ 44 Train Data 90% กับโครงสร้าง AlexNet ที่ epoch=20	63
ภาพประกอบ 45 Train Data 90% กับโครงสร้าง GoogLeNet ที่ epoch=20	63
ภาพประกอบ 46 Confusion Matrix Model VGG-16 Train Data 75:25.....	65
ภาพประกอบ 47 Confusion Matrix Model ResNet-50 Train Data 75:25.....	66
ภาพประกอบ 48 Confusion Matrix Model DenseNet-121 Train Data 75:25.....	66
ภาพประกอบ 49 Confusion Matrix Model AlexNet Train Data 75:25.....	67
ภาพประกอบ 50 Confusion Matrix Model GoogLeNet Train Data 75:25	68
ภาพประกอบ 51 Confusion Matrix Model VGG-16 Train Data 80:20.....	68
ภาพประกอบ 52 Confusion Matrix Model ResNet-50 Train Data 80:20.....	69
ภาพประกอบ 53 Confusion Matrix Model DenseNet-121 Train Data 80:20.....	70
ภาพประกอบ 54 Confusion Matrix Model AlexNet Train Data 80:20.....	70
ภาพประกอบ 55 Confusion Matrix Model GoogLeNet Train Data 80:20.....	71
ภาพประกอบ 56 Confusion Matrix Model VGG-16 Train Data 90:10.....	72
ภาพประกอบ 57 Confusion Matrix Model ResNet-50 Train Data 90:10.....	72
ภาพประกอบ 58 Confusion Matrix Model DenseNet-121 Train Data 90:10.....	73
ภาพประกอบ 59 Confusion Matrix Model AlexNet Train Data 90:10.....	74
ภาพประกอบ 60 Confusion Matrix Model GoogLeNet Train Data 90:10	74
ภาพประกอบ 61 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่ไม่เป็นโรคใด ๆ.....	79

ภาพประกอบ 62 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง	80
ภาพประกอบ 63 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน	81
ภาพประกอบ 64 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่เป็นโรคราสนิม	82



บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของการวิจัย

ภาคการเกษตร [1] เป็นภาคการผลิตที่มีความสำคัญต่อการพัฒนาประเทศในทุกมิติทั้งด้านเศรษฐกิจสังคม และสิ่งแวดล้อม พื้นที่ทางการเกษตรในประเทศไทยมีเนื้อที่ 149.25 ล้านไร่ คิดเป็นสัดส่วนร้อยละ 46.5 ของเนื้อที่ทั้งประเทศ และเป็นแหล่งวัตถุดิบหรือต้นน้ำของอุตสาหกรรมต่าง ๆ อีกทั้งยังเป็นแหล่งผลิตอาหารให้กับประชากรทั้งในประเทศและส่งออกไปยังต่างประเทศ ซึ่งสร้างรายได้ให้กับประเทศเป็นมูลค่ามหาศาลในแต่ละปี ในช่วง 5 ปีที่ผ่านมา มูลค่าการส่งออกสินค้าเกษตรและผลิตภัณฑ์เฉลี่ยอยู่ที่ 1.39 ล้านล้านบาทต่อปี และมีดุลการค้าเกินดุลเฉลี่ย 8.6 แสนล้านบาทต่อปี ยังเป็นทางรอดในวิกฤตการณ์ต่าง ๆ ที่ผ่านมา เช่น การแพร่ระบาดของโควิด-19 ที่เกิดขึ้น ซึ่งช่วยรองรับและโอบอุ้มเศรษฐกิจไทย และเป็นแหล่งรองรับแรงงานที่ถูกเลิกจ้างจากภาคเศรษฐกิจอื่น ช่วยบรรเทาผลกระทบทางด้านเศรษฐกิจและสังคมในช่วงประเทศประสบปัญหา และเนื่องมาจากความต้องการอาหารของประชากรสูงขึ้นอย่างต่อเนื่อง และการเพิ่มคุณค่าของผลิตภัณฑ์ทางการเกษตร ภาคเกษตรมุ่งหวังในการดูแลรักษาแปลงเกษตรให้ปลอดจากโรคพืชเพื่อเพิ่มผลผลิตและคุณภาพผลิตภัณฑ์ทางการเกษตร โดยใช้เทคโนโลยีที่ก้าวหน้าเข้ามาช่วยในการเกษตรกรรม เพื่อเพิ่มผลผลิตและทดแทนแรงงานภาคเกษตรที่มีแนวโน้มลดลง และส่งเสริมการเกษตรอัจฉริยะ เพื่อยกระดับสู่เกษตรมูลค่าสูงในอนาคต

อ้อยเป็นพืชที่สำคัญต่อเศรษฐกิจในอุตสาหกรรมน้ำตาลของประเทศไทย แม้จะมีแนวโน้มของการปลูกอ้อยเพิ่มสูงขึ้นเรื่อย ๆ แต่การผลิตอ้อยก็มักมีปัจจัยที่ทำให้ผลผลิตตกต่ำ เช่น พันธุ์ ความแห้งแล้ง แมลง และโรคระบาด [2] สถานการณ์พื้นที่ปลูกอ้อยในปีการผลิต 2565/2566 [3] มีพื้นที่เพาะปลูกรวมทั้งสิ้น 11,398,823 ไร่ เพิ่มขึ้นจากปีการผลิตก่อนหน้าจำนวน 376,475 ไร่ โดยมีการปลูกอ้อยพันธุ์ขอนแก่น 3 กว่า 80% ของพื้นที่ปลูกอ้อยในประเทศไทย [4] ซึ่งอุตสาหกรรมที่มีศักยภาพของกลุ่มภาคตะวันออกเฉียงเหนือตอนกลางก็มีพื้นที่ในการเพาะปลูกอ้อยเพิ่มขึ้น โดยมีเนื้อที่ในการเพาะปลูกอ้อย 1,274,724 ไร่ และผลผลิต 14,184,500 ตัน ในการนำไปแปรรูปเป็นอุตสาหกรรมขั้นต้น คือ น้ำอ้อย น้ำตาลทรายแดง และน้ำตาลทรายขาว จากข้อมูลดังกล่าวเป็นผลสืบเนื่องจากราคาน้ำตาลตลาดโลกที่มีแนวโน้มที่ดีส่งผลให้ราคาอ้อยขยับเพิ่มขึ้น จึงเป็นแรงจูงใจให้เกษตรกรหันกลับมาปลูกอ้อยเพิ่มขึ้น ซึ่งปัญหาการระบาดของโรค แมลงศัตรูอ้อย การปลูกอ้อยเป็นเวลานานจนเกิดสะสมโรค และสาเหตุอื่น ๆ [4], [5] ทำให้อ้อยแสดงอาการผิดปกติที่ส่งผลเสียให้อ้อยไม่สามารถเจริญเติบโตได้อย่างปกติ ส่งผลให้เกษตรกรต้องได้รับความเสียหายจากการที่อ้อยให้

ผลผลิตได้ไม่เต็มศักยภาพเท่าที่ควรจะเป็น ซึ่งการวินิจฉัยอาการผิดปกติโดยแบ่งเป็นกลุ่มอาการผิดปกติ แบ่งออกเป็น 5 กลุ่ม ได้แก่ อาการบนยอด อาการภายในลำต้น อาการที่เหง้าและราก อาการผิดปกติอื่น และอาการบนใบอ้อย ซึ่งอาการผิดปกติที่ปรากฏบนใบอ้อยพันธุ์ขอนแก่น 3 ที่พบมากที่สุด และเป็นปัญหาต่อผลผลิตของเกษตรกรนั้น ได้แก่ โรคใบต่างราสนิม โรคใบจุดวงแหวน และโรคเส้นกลางใบแดง จำเป็นอย่างยิ่งที่เกษตรกรต้องมีความสามารถในการจำแนกชนิดและลักษณะอาการของความผิดปกติที่เกิดขึ้นกับอ้อยได้อย่างถูกต้องและรวดเร็ว สามารถวินิจฉัยอาการผิดปกติของอ้อยในเบื้องต้นเพื่อหาทางในการแก้ไขโรคพืชที่เกิดขึ้นได้

จากปัญหาดังกล่าว ผู้วิจัยมีแนวคิดในการนำเทคโนโลยีมาใช้ในการเกษตร โดยการประยุกต์ใช้ความรู้ทางด้านการเรียนรู้เชิงลึก (Deep Learning) เพื่อวิเคราะห์ภาพใบอ้อยเพื่อตรวจสอบโรคที่เกิดขึ้นบนใบอ้อยอย่างรวดเร็วและแม่นยำ โดยใช้เทคโนโลยีการเรียนรู้เชิงลึกที่เป็นที่นิยมในปัจจุบัน โมเดลมีขนาดเล็ก และประมวลผลได้รวดเร็วแม่นยำ คือ Convolutional Neural Networks (CNN) ในการทำนายและการวินิจฉัยโรคในใบอ้อย งานวิจัยนี้มุ่งหวังพัฒนาระบบวิเคราะห์ภาพใบอ้อยเพื่อตรวจสอบโรคแบบอัตโนมัติ เพื่อเพิ่มประสิทธิภาพและความถูกต้องในการตรวจสอบโรคอ้อย และเป็นการตอบสนองต่อการพัฒนาการเกษตรที่ยั่งยืนอย่างเป็นอัจฉริยะ โดยนำเทคโนโลยีการเรียนรู้เชิงลึกมาประยุกต์ใช้ในการวิเคราะห์ภาพใบอ้อย สามารถนำไปสู่การเป็นเกษตรที่อัตโนมัติและมีความสามารถในการตรวจสอบและจัดการโรคในอ้อย ซึ่งจะช่วยเพิ่มผลผลิตและลดความเสี่ยงของการสูญเสียในการผลิตอ้อยได้ในระยะยาว นอกจากนี้ยังสอดคล้องกับยุทธศาสตร์ในการส่งเสริมและยกระดับด้านเกษตรและอุตสาหกรรมเกษตรที่มีมูลค่าสูง (Smart Agriculture) [4] ในการนำเทคโนโลยีและนวัตกรรมที่ก้าวหน้ามาประยุกต์ใช้ในการพัฒนาการเกษตร เพื่อเพิ่มผลผลิต ยกระดับคุณภาพของผลิตภัณฑ์ทางการเกษตร และส่งเสริมการใช้แรงงานที่มีประสิทธิภาพ ทำให้เกิดการพัฒนากษัตริย์ที่ยั่งยืนและมีประสิทธิภาพในการใช้ทรัพยากร ลดการกระทำที่ทำให้เกิดความเสี่ยงในการผลิตอ้อย และเป็นการเพิ่มประสิทธิภาพในการตรวจสอบและจัดการโรคที่เกิดขึ้นกับอ้อย นำไปสู่การเติบโตอย่างยั่งยืนของอุตสาหกรรมเกษตรที่มีมูลค่าสูงในอนาคต

1.2 ความมุ่งหมายและวัตถุประสงค์ของการวิจัย

1.2.1 เพื่อเปรียบเทียบประสิทธิภาพ และความถูกต้องในการตรวจสอบโรคใบอ้อยในแต่ละสภาพการณ์

1.2.2 เพื่อสร้างโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ภาพใบอ้อยเพื่อตรวจสอบโรค

1.2.3 เพื่อพัฒนาระบบวินิจฉัยโรคอ้อยด้วยภาพใบอ้อย แบบอัตโนมัติด้วย Line Chatbot

1.3 ขอบเขตในการวิจัย

1.3.1 รูปภาพที่ใช้ในงานวิจัย เป็นชุดข้อมูลภาพถ่ายใบอ้อยที่ผู้วิจัยรวบรวมจัดเก็บในพื้นที่กลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง [4] ซึ่งประกอบด้วย 4 จังหวัด ได้แก่ จังหวัดมหาสารคาม จังหวัดขอนแก่น จังหวัดกาฬสินธุ์ และจังหวัดร้อยเอ็ด ซึ่งรวบรวมรูปภาพใบอ้อย 1 ชุด ข้อมูล จำนวนทั้งสิ้น 4,000 ภาพ ประกอบด้วย รูปภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง รูปภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน และรูปภาพที่เป็นโรคราสนิม มีจำนวนอย่างละ 1,000 ภาพ รูปภาพที่ใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ มีจำนวน 1,000 ภาพ โดยรูปภาพทั้งหมดเป็นภาพที่อยู่ในสภาพแวดล้อมทางธรรมชาติที่มีลักษณะเด่นในภาพอย่างน้อย 1 อย่าง

1.3.2 สร้างชุดข้อมูลภาพถ่ายใบอ้อย 1 ชุดข้อมูล (Data set) มีการติดป้าย (Labeling) ประกอบไปด้วย โรคเส้นกลางใบแดง (RedRot), โรคใบจุดวงแหวน (RingSpot), โรคราสนิม (Rust), และใบอ้อยปกติไม่เป็นโรคใด ๆ (Healthy) โดยทั้งหมดรวบรวมไว้ในชุดข้อมูล คือ Sugarcane Leaf Disease Dataset

1.3.3 ใช้เทคนิคการเรียนรู้เชิงลึก ด้วยวิธี Convolutional Neural Networks: CNN [6] สำหรับการรู้จำโรคพืชที่ปรากฏบนใบอ้อย ที่เป็นลักษณะอาการของโรคเส้นกลางใบแดง โรคใบจุดวงแหวน โรคราสนิม และใบอ้อยที่ปกติไม่เป็นโรคใด ๆ

1.3.4 นำชุดข้อมูลรูปภาพทั้งหมด เปรียบเทียบประสิทธิภาพของเทคนิค Deep Learning ด้วยสถาปัตยกรรม CNN 5 แบบ ได้แก่ VGGNet-16 [7], ResNet-50 [8], DenseNet121 [9], AlexNet [10] และ GoogLeNet [11] ซึ่งแต่ละแบบมีลักษณะของโครงสร้าง (Architecture) ที่ต่างกัน

1.3.5 ตรวจสอบความถูกต้องโดยใช้ตัววัดประสิทธิภาพ คือ Precision เป็นการวัดความแม่นยำของโมเดล และการวัดประสิทธิภาพค่าความถูกต้องของโมเดล (Accuracy) [12]

1.3.6 พัฒนาระบบ LINE Chatbot เพื่อวินิจฉัยโรคอ้อยด้วยภาพใบอ้อยตอบกลับแบบอัตโนมัติ ที่วินิจฉัยโรคได้จำนวน 3 โรค ด้วย

1.4 ผลที่คาดว่าจะได้รับการวิจัย

1.4.1 ได้โมเดลเทคนิคการเรียนรู้เชิงลึกที่เหมาะสมสำหรับการวิเคราะห์ภาพใบอ้อยเพื่อการตรวจสอบโรค ที่มีความถูกต้องสูงที่สามารถวินิจฉัยและรู้จำโรคพืชที่ปรากฏอาการบนใบอ้อยได้

1.4.2 ได้ระบบ Line Chatbot ในการตรวจวินิจฉัยโรคอ้อยแบบอัตโนมัติ

1.5 นิยามศัพท์เฉพาะ

1.5.1 อ้อย [13] หมายถึง ชื่อไม้ล้มลุกชนิด *Saccharum officinarum* L. ในวงศ์ Gramineae ขึ้นเป็นกอ ลำต้นเป็นปล้อง ข้างในตัน มีหลายพันธุ์ เช่น อ้อยขาไก่ อ้อยตะเภา หีบเอาน้ำหวานทำน้ำตาลทราย หรือใช้ดื่ม หรือเคี้ยวกินแต่น้ำหวาน

1.5.2 อาการผิดปกติของอ้อย [5] คือ อ้อยแสดงอาการผิดปกติไม่สามารถเจริญเติบโต โดยปัญหาเกิดจากโรคระบาดของพืช แมลงศัตรูอ้อย รวมทั้งสาเหตุอย่างอื่น ส่งผลต่อผลผลิตที่ได้ไม่เต็มศักยภาพที่ควรจะเป็น ซึ่งอาการของความผิดปกติที่เกิดขึ้นกับอ้อย โดยเฉพาะทางใบจะสังเกตเห็นได้ง่าย

1.5.5 โรคที่ปรากฏอาการบนใบอ้อย [5] หมายถึง การวินิจฉัยโรคอ้อยผิดปกติเบื้องต้น ระบุอาการผิดปกติที่แสดงอาการบนใบอ้อย

1.5.3 การเรียนรู้เชิงลึก (Deep Learning) [14] คือ ชุดคำสั่งที่สร้างขึ้นเพื่อให้เครื่องคอมพิวเตอร์เรียนรู้โดยชุดคำสั่งนี้จะทำให้เครื่องประมวลผลข้อมูลจำนวนมากที่เครื่องพยายามเรียนรู้วิธีการแทนข้อมูลอย่างมีประสิทธิภาพ โดยหลักการของการเรียนรู้เชิงลึกนั้นจะเป็นโหนดหลาย ๆ ชั้น และประมวลผลแบบขนาน จึงประมวลผลได้ครั้งละจำนวนมากทำให้การเรียนรู้ของเครื่องให้ผลลัพธ์ในการคาดการณ์และตัดสินใจได้ดีมากยิ่งขึ้น ซึ่งการเรียนรู้เชิงลึกมีหลักการมาจากการทำงานของสมองมนุษย์ โดยจะรับข้อมูลเข้ามา แล้วประมวลผลซ้ำ ๆ ในรูปแบบต่าง ๆ จำนวนมาก เพื่อหาจุดที่บอกคุณลักษณะของข้อมูลที่น่าเข้า และแสดงผลลัพธ์ออกมา

1.5.4 เกษตรอัจฉริยะ (Smart Agriculture) [4], [15] คือ การใช้และพัฒนาเทคโนโลยีอิเล็กทรอนิกส์ คอมพิวเตอร์ รวมถึงเทคโนโลยีสารสนเทศ ในการจัดการฟาร์มเกษตรกรรม ที่เรียกว่าระบบฟาร์มอัจฉริยะ สอดคล้องกับ Thailand 4.0 ที่เป็นการประยุกต์ใช้ความรู้ด้านวิทยาศาสตร์และเทคโนโลยีมาช่วยส่งเสริมการเกษตร

1.5.5 แชทบอท (Chatbot) [16], [17] คือ โปรแกรมคอมพิวเตอร์ที่ใช้เทคโนโลยีปัญญาประดิษฐ์ในการสื่อสารและตอบสนองต่อคำถามหรือสถานการณ์เหมือนกับมนุษย์ โดยใช้ข้อความ ภาพ หรือเสียง มักนำไปใช้ในการบริการลูกค้า การแพทย์ การศึกษา และอื่น ๆ โดยการเรียนรู้และปรับปรุงตัวเองจากข้อมูลที่ได้รับมาเป็นสิ่งสำคัญในการพัฒนาโปรแกรมนี้ สามารถโต้ตอบได้แบบ Real Time

1.6 ข้อจำกัดของการวิจัย

1.6.1 ข้อจำกัดของภาพที่ใช้ในการเรียนรู้ และทดสอบนั้น ต้องเป็นภาพใบอ้อย เท่านั้น หากใช้ภาพพืชชนิดอื่น ผลลัพธ์จะเป็นเพียงภาพใบอ้อยเท่านั้น

1.6.2 โรคพืชที่ปรากฏอาการบนใบอ้อยในงานวิจัยนี้นั้น จะวินิจฉัยเพียงโรคเส้นกลางใบแดง โรคจุดวงแหวน และโรคราสนิม เท่านั้น เนื่องจากส่วนใหญ่นิยมปลูกอ้อยพันธุ์ขอนแก่น 3 กว่า 80% ของพื้นที่ปลูกอ้อยในประเทศไทย และโรคดังกล่าวพบมากที่สุดในอ้อยพันธุ์นี้

1.6.3 ข้อจำกัดด้านการประมวลผล เนื่องจากระบวนการเรียนรู้ของเครื่องจักรด้วยเทคนิคการเรียนรู้เชิงลึก (Deep Learning) จะใช้เวลาในการเรียนรู้ (Training) เป็นเวลานาน หากใช้หน่วยประมวลผลกลาง (Central Processing Unit: CPU) จะใช้เวลาในการเรียนรู้นาน ซึ่งหากใช้หน่วยประมวลผลด้านกราฟิกส์ (Graphics Processing Unit: GPU) จะช่วยลดระยะเวลาในการเรียนรู้ได้หลายเท่า ในงานวิจัยนี้จะใช้บริการ Google Colab [18], [19] ในการเรียนรู้และประมวลผล



บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในการวิจัยเรื่อง การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยเพื่อรองรับการเป็นเกษตรอัจฉริยะ ผู้วิจัยได้ดำเนินการศึกษาค้นคว้าเอกสาร ทบทวนทฤษฎีและงานวิจัยที่เกี่ยวข้อง ดังต่อไปนี้

2.1 อ้อย (Sugar cane)

2.1.1 ลักษณะทั่วไปของอ้อย

2.1.1.1 อ้อย เป็นพืชจำพวกหญ้าชนิดหนึ่งที่มีความสำคัญอย่างมากในแง่ของผลผลิต เพราะอ้อยสามารถใช้ปัจจัยสำหรับการเจริญเติบโต เช่น แสงแดด น้ำ อากาศ และธาตุอาหารได้อย่างมีประสิทธิภาพ อ้อยนั้นเป็นพืชที่ปลูกง่ายเมื่อปลูกครั้งหนึ่งแล้วสามารถเก็บเกี่ยวได้หลายครั้ง เป็นพืชที่ชอบอากาศร้อนและชุ่มชื้น ประเทศที่ปลูกอ้อยมีประมาณ 70 ประเทศอยู่ในแถบร้อน ชุ่มชื้น ในระหว่างเส้นรุ้งที่ 35 องศาเหนือ และ 35 องศาใต้ รวมถึงประเทศไทยด้วย การแบ่งชนิด (Species) ของพืชสกุลนี้ที่ยอมรับกันโดยทั่วไปคือ การแบ่งของกราสซีล ซึ่งได้จัดลำดับอ้อยทางพฤกษศาสตร์ให้เป็นวงศ์ (Family) Gramineae ได้แก่ หญ้าที่มีลำต้นเป็นข้อ และ ปล้อง รวมทั้งธัญพืชต่าง ๆ และ ต้นไผ่ เผ่า (Tribe) Andropogoneae สกุล (Genus) Saccharum แบ่งพืชในสกุลนี้ออกเป็น 4 ชนิด [13]

1) อ้อยปลูกดั้งเดิม เป็นอ้อยที่เกิดแถบเกาะนิวกินี ลักษณะสำคัญคือ ลำใหญ่ ใบยาวและกว้าง มีน้ำตาลมาก เปลือกและเนื้อนุ่ม มีสีสวย ซึ่งรู้จักกันในนาม “อ้อยเคี้ยว” เหาที่มีอยู่ในประเทศไทย คือ อ้อยสิงคโปร์ อ้อยมอริเชียส (Mauritius) และอ้อย (Badila) ซึ่งชาวตัทซ์ที่อยู่ชาวสมัยก่อนเรียกอ้อยเหล่านี้ว่า โนเบิลเคน (Noblecane) ต่อมา บรานดิช เรียกว่า เนทิฟ การ์เดน ซูการ์เคน (Native garden sugarcane หรือ Native sugarcane) เพราะชาวเกาะนิวกินีปลูกไว้ในสวนเพื่อใช้รับประทานสด อ้อยชนิดนี้มีบทบาทสำคัญต่ออุตสาหกรรมน้ำตาลทรายของโลกในสมัยเริ่มแรกเป็นอย่างมาก ซึ่งอ้อยที่ปลูกเป็นการค้าในปัจจุบันก็สืบเชื้อสายมาจากอ้อยชนิดนี้ เมื่อกล่าวถึงประวัติและถิ่นฐานเดิมของอ้อย จึงหมายถึงอ้อยชนิดนี้เสมอ [13]

2) อ้อยป่าแถบร้อน เป็นอ้อยป่าที่ขึ้นอยู่ทั่วไปในเขตร้อนและชุ่มชื้น มีอยู่หลายร้อยชนิด แตกต่างกันไปตามแหล่งกำเนิด แต่จะมีลักษณะที่สำคัญคล้ายคลึงกัน คือ มีอายุยืน ขึ้นอยู่เป็นกอ มีลำต้นใต้ดิน ลำต้นผอมและแข็ง ไส้กลวง มีความหวานน้อย ในประเทศไทยเรียกว่า แคมพง หรืออ้อยป่า (Wild cane) [13]

3) อ้อยอินเดีย เป็นอ้อยที่มีถิ่นกำเนิดในอินเดียตอนเหนือ นักวิชาการเชื่อว่าเป็นอ้อยที่เกิดจากการผสมตามธรรมชาติ ระหว่าง *S.officinatum* และ *S.spontaneum* มีลำต้นขนาดเล็ก ใบเล็ก ข้อโป่ง มีความหวานสูง เปลือกและเนื้อนุ่ม [13]

4) อ้อยป่านิวกีนิ เป็นอ้อยป่าแถบเกาะนิวกีนิ เปลือกแข็ง ใส่ฟาม มีลักษณะลำต้นใหญ่ แข็งแรง อาจสูงถึง 10 เมตร มีความหวานต่ำ ชาวเกาะใช้ปลูกทำรั้ว อ้อยชนิดนี้พบว่ามีในประเทศไทย นักวิชาการเชื่อว่าเป็นต้นตระกูลของอ้อยปลูกดั้งเดิม [13]

2.1.1.2 อ้อยได้ถูกนำไปจากเกาะนิวกีนิ โดยการติดต่อค้าขายและการล่าเมืองขึ้นของมนุษย์ ในสมัยก่อนประวัติศาสตร์ บรานดิซ ได้สันนิษฐานการแพร่กระจายของอ้อยจากนิวกีนิไว้ 3 ทาง

1) ไปทางทิศตะวันออกเฉียงใต้สู่หมู่เกาะโซโลมอน นิวเฮบริดิส และนิคาเลโดเนีย เกิดขึ้นนานนับจำนวนหมื่น ๆ ปีก่อนคริสต์ศักราช

2) ไปทางทิศตะวันตกสู่หมู่เกาะชาว ประเทศอินโดนีเซีย แหลมมลายู ฟิลิปปีนส์ อินโดจีน ซึ่งรวมถึงประเทศไทย ตลอดถึงชายฝั่งแถบอ่าวเบงกอล ประเทศอินเดีย การกระจายจากเกาะนิวกีนิไปถึง อินเดียต้องใช้เวลาถึง 3,000 ปี การกระจายตัวทางทิศตะวันตกนี้มีความสำคัญมาก เพราะก่อให้เกิดการพัฒนาอุตสาหกรรมน้ำตาล จนมีความเจริญอย่างที่เห็นในปัจจุบัน

3) ไปทางทิศตะวันออกเฉียงใต้สู่เกาะต่าง ๆ คือ ฟิจิ ตองกา ซามัว คุก มาร์แชลส์ โซโซเอตี อีสเทอร์ และฮาวาย รวมทั้งเกาะอื่น ๆ ในมหาสมุทรแปซิฟิกด้วย การกระจายตัวตามทิศทางดังกล่าว เกิดขึ้นเมื่อประมาณไม่เกิน 500 ปี หลังจากที่อ้อยถึงอ่าวเบงกอลแล้ว [13]

2.2.2 ลักษณะทางพฤกษศาสตร์ของอ้อย [13]

2.2.2.1 ราก (root) จะเป็นรากที่อยู่ใต้ดิน มีขนาดใหญ่กระจายทั่วลำต้น มีความยาวประมาณ 100 เซนติเมตร ทั้งนี้ขึ้นอยู่กับพันธุ์ และสภาพแวดล้อม โดยรากของอ้อยนั้นจะแบ่งออกเป็น 2 ชุด คือ รากของท่อนพันธุ์ (Sett root หรือ Cutting root) อาจเรียกว่า รากชั่วคราว และรากของหน่อ (Shoot root) อาจเรียกว่า รากถาวร

2.2.2.2 ลำต้น (Stalk) เพราะมีลำต้นสูงใหญ่ อ้อยจึงได้ชื่อว่า “หญ้ายักษ์” (Giant grass) ทั้งนี้ขึ้นอยู่กับพันธุ์ สภาพแวดล้อม และการปฏิบัติรักษาของชาวไร่ ลำต้นขนาดใหญ่ของอ้อยนั้นจะประกอบด้วยข้อปล้องจำนวนมาก ทั้งข้อและปล้องรวมเรียกว่า จอยต์ (Joint) ซึ่งเรียกว่า ปล้อง อ้อยที่ตัดเมื่ออายุ 12 เดือน จะมีปล้อง 20-30 ปล้อง ในระยะห่างปล้องอ้อยจะมีปล้องเพิ่มขึ้นโดยเฉลี่ยประมาณเดือนละ 3 ปล้อง แต่ละปล้องเมื่อโตเต็มที่ จะยาวประมาณ 10-15 เซนติเมตร ปล้องนี้จะยาวหรือสั้นก็ขึ้นอยู่กับพันธุ์ และสภาพแวดล้อม โดยเฉพาะปริมาณน้ำที่ได้รับ ปล้องที่เกิดในช่วงที่มีน้ำพอเหมาะจะยาวกว่าปล้องที่เกิดในช่วงที่มีน้ำมากหรือน้อยเกินไป แม้ว่าจะได้รับน้ำเหมาะสม ความยาวของปล้องก็จะแตกต่างกัน คือ ปล้องที่อยู่ตอนโคนต้นจะสั้นมาก และจะค่อย ๆ ยาวขึ้น และจะสั้น

ลงอีกเมื่อใกล้ยอด ลักษณะดังกล่าวปรากฏในอ้อยที่ไม่มีดอก ส่วนอ้อยที่มีดอกปล้องที่รองรับช่อดอก จะมีความยาวที่สุดแล้วลดลงตามลำดับ จนกระทั่งถึงส่วนที่ปล้องมีความยาวไล่เลี่ยกัน

2.2.2.3 รูปร่างของปล้อง (internode patterns) มีรูปร่างแตกต่างกันหลายรูปทรง เช่น เป็นรูปทรงกระบอก (cylindrical) มัดข้าวต้ม (tumescent) กลางคอด (bobbin-shaped) โคนใหญ่ (conoidal) โคนเล็ก (obconoidal) หรือโค้ง (curved) ข้อและปล้องเหล่านี้จะมีส่วนประกอบมากมายกว่าสิบอย่างด้วยกัน เช่น ตา บริเวณเกิดราก (root band หรือ rootring หรือ root zone) หรือที่อยู่ระหว่างรอยกาบ และวงเจริญปุมราก (root primordia หรือ root initials) หรือจุดที่รากจะเจริญออกมา วงเจริญหรือวงแหวน (growth ring) รอยกาบ (leaf scar หรือ sheath scar) เป็นรอยที่เกิดขึ้นหลังจากกาบใบหลุดแล้ว วงไข (wax ring) ส่วนที่มีไขเกาะมากกว่าส่วนอื่น ๆ รอยแตกตื้น หรือ รอยแตกลายงา (corky cracks) รอยแตกเล็ก ๆ บริเวณผิวเปลือก รอยแตกลึก (growth crack หรือ rind crack) รอยแตกขนาดใหญ่ตามความยาวของลำต้นลึกเข้าไปในเนื้ออ้อย รอยตกสะเก็ด (corky patch) ร่องตา (bud furrow หรือ bud groove)

2.2.2.4 สีของลำต้น (Stalk color) สีของลำต้นแตกต่างกันตามพันธุ์และสภาพแวดล้อม โดยทั่วไปมีสีแตกต่างกันตั้งแต่สีเขียวอ่อน จนถึง สีม่วงแก่เกือบดำ สีต่าง ๆ เหล่านี้เกิดจากรงควัตถุ (pigments) ที่เป็นพื้นฐาน 2 ชนิด คือ สีเขียว เกิดจากคลอโรฟิลล์ (Chlorophyll) และสีแดง เกิดจากแอนโทไซยานิน

2.2.2.5 ใบ (Leaves) มีลักษณะคล้ายใบข้าว แต่มีขนาดใหญ่และยาวมากกว่า ประกอบด้วย 2 ส่วนด้วยกัน คือ กาบใบ และแผ่นใบ กาบใบ คือส่วนที่ติดและโอบรอบลำต้นทางด้านที่มีตาสลับซ้ายขวาไปมา จากต้นถึงปลายลำต้น ฐานกาบใบกว้างที่สุดแล้วเรียวยาวลงสู่ปลายแผ่นใบ ได้แก่ ส่วนที่อยู่ต่อกากาบใบขึ้นไป ทั้งสองส่วนแยกกันตรงรอยต่อ (Blade joint) ด้านในของรอยต่อนี้จะมีส่วนยื่นเป็นเยื่อบาง ๆ รูปร่างคล้ายกระจับ เรียกว่า ลิ้นใบ (ligule) ที่ส่วนปลายของกาบใบ จะมีความกว้างมากกว่าฐานของแผ่นใบ จึงทำให้มีส่วนเกิน ซึ่งมักจะยื่นขึ้นไปข้างบน เรียกว่า หูใบ (Auricle) ซึ่งอาจจะมีทั้งสองข้าง ข้างเดียว หรือไม่มีเลยก็ได้ ในกรณีที่มีข้างเดียว มักจะอยู่ด้านในเสมอ ลักษณะและรูปร่างของลิ้นใบ และ หูใบแตกต่างกันตามพันธุ์ กาบใบส่วนมากมักมีสีแตกต่างจากตัวใบ เช่น สีเขียวอ่อน หรือ เขียวอมม่วง เป็นต้น ที่หลังกาบใบอาจมีขน และมีไขมันเกาะ เหล่านี้ล้วนเป็นลักษณะประจำพันธุ์ทั้งสิ้น ถัดจากกาบใบขึ้นไปเป็นแผ่นใบ ซึ่งมีแกนใบ หรือแกนกลางใบแข็ง ทำให้แผ่นใบตั้งอยู่ได้ ความยาวของแผ่นใบแตกต่างกันตามพันธุ์ บางพันธุ์อาจยาวมากกว่า 2 เมตร แผ่นใบ มีฐานแคบแล้วกว้างออกจนถึงกว้างที่สุดแล้วเรียวยาวลงสู่ปลายใบซึ่งแหลม ขอบใบมีลักษณะเป็นฟันเลื่อยคมที่ฐานของแผ่นใบด้านหลังจะพบพื้นที่ลักษณะคล้ายสามเหลี่ยม 2 รูป ซ้อนกันที่แกนกลางใบ เรียกว่า ดิวแล็ป (Dewlap) ขอบของดิวแล็ป มีลักษณะเป็นคลื่น ยึดหยุ่นได้ ซึ่ง ช่วยลดการฉีกขาดของใบเมื่อถูกลม รูปร่างลักษณะและสีแตกต่างกันตามพันธุ์การเจริญเติบโตของใบทั้งหมด เกี่ยวข้องโดยตรงกับ

ปริมาณและคุณภาพของผลผลิตเมื่อเก็บเกี่ยว การวัดความเจริญเติบโตของใบนิยมนวัด โดยวิธีเปรียบเทียบพื้นที่ใบกับพื้นดิน ซึ่งใบเหล่านั้นปกคลุมอยู่ หรืออาจเรียกเป็นอัตราส่วนระหว่างพื้นที่ใบต่อหน่วยของพื้นดิน ซึ่งนิยมเรียกว่าดัชนีพื้นที่ใบ (leaf area index หรือ LAI) จำนวนใบสดแตกต่างกันตามพันธุ์ และอายุ จำนวนใบจะเหลือน้อยลงในสภาพแห้งแล้งหรือหนาวเย็น เมื่อเกิดใบใหม่ที่ยอดใบแก่ที่อยู่ส่วนโคนต้นก็จะเสื่อมโทรมลง และตายไปในที่สุด สาเหตุสำคัญที่ทำให้ใบข้างล่างตาย คือการถูกบังแสงแดดนั่นเอง

2.2.2.6 ช่อดอก (inflorescences) ดอกของอ้อยนั้นจะเกิดเป็นช่อที่ยอดของลำต้น ช่อดอกมีลักษณะคล้ายหัวลูกศร การออกดอกขึ้นอยู่กับปัจจัยหลายอย่าง เช่น พันธุ์ อายุ สภาพแวดล้อม การออกดอกเริ่มต้นด้วยการเปลี่ยนสภาพของตายอด (Vegetative bud) ซึ่งตามปกติจะเจริญเป็นใบ ช่อและปล้องไปเป็นตาดอก (floral bud) การเปลี่ยนแปลงนี้เกิดขึ้นเป็นเวลานานหลายสัปดาห์ก่อนที่จะช่อดอกจะปรากฏ ลักษณะที่เห็นชัดภายหลังการเปลี่ยนแปลงดังกล่าว คือ แผ่นใบจะเริ่มหดสั้นลง จนถึงใบสุดท้ายซึ่งสั้นที่สุด เรียกว่า ใบธง(flag leaf) ในขณะที่แผ่นใบเริ่มหดสั้นลงนั้น กาบใบก็จะยึดตัวยาวเพิ่มขึ้นโดยลำดับ จนกระทั่งยาวที่สุด คือกาบของใบธงนั่นเอง การยึดตัวของปล้องเป็นไปตามองเดียวกันกับกาบใบ

2.2.2.7 ดอก (floral) ดอกอ้อยมีขนาดเล็กมากเกิดเป็นคู่ ๆ ในแต่ละคู่นี้ดอกหนึ่งจะมีก้าน ส่วนอีกดอกไม่มีก้าน ที่รอบฐานของแต่ละดอกมีขนยาว สีขาว คล้ายไหมจำนวนมาก เรียกว่า บริสเทิลหรือ คัลลัสแฮร์ (bristle หรือ callus hair) ก่อนดอกบาน ขนเหล่านี้จะแนบกับตัวดอก เมื่อดอกบานก็จะกางออกโดยรอบเป็นรัศมี ทำให้ดูคล้ายทำด้วยไหมทั้งช่อ แต่ละดอกมีกลีบดอก 3 กลีบ เรียงจากข้างนอกเข้าไป เรียกว่า กาบนอก กาบใน และสเตอร์รายล์เลมมา หรือกาบที่สามตามลำดับ ดอกอ้อยเป็นดอกที่สมบูรณ์ คือ มีทั้งส่วนที่เป็นเพศผู้และเพศเมียอยู่ในดอกเดียวกัน ส่วนของเพศผู้ประกอบด้วยอับเกสร (anther) ซึ่งมีลักษณะยาวรี 3 อับ แต่ละอับมีก้านเกสร เวลาดอกบานก้านนี้จะยึดตัวส่ง อับเกสรออกมาภายนอก และต่อมาอับเกสรก็จะแตกออกปล่อยละอองเกสรออกมาผสมตัวเอง หรือลอยไปตามลม ส่วนของเพศเมีย ประกอบด้วยรังไข่ (ovary) 1 รัง และสติกมา (stigma) ซึ่งปลายแยกออกเป็น 2 แฉก ลักษณะคล้ายขนนก เรียกว่า ฟีทเทอรี สติกมา (feathery stigmas) หลังจากได้รับการผสมรังไข่ก็จะเจริญเป็นเมล็ดต่อไป

2.2.2.8 เมล็ด (fluff) เมล็ดอ้อยมีลักษณะคล้ายเมล็ดข้าวที่มีขนาดเล็กกว่าหลายเท่า ตามปกติเมล็ดอ้อยมักจะติดอยู่กับตัวดอกอย่างแน่น เราจะเรียกเมล็ดอ้อยว่า ฟัชซ์ (fuzz) หรือ ฟลัฟฟ์ (fluff) และเมล็ดเหล่านี้ถ้าเพาะในสภาพแวดล้อมเหมาะสมก็จะงอกเป็นต้นใหม่ต่อไป

2.2.3 สถานการณ์การปลูกอ้อยในประเทศไทย

ในประเทศไทยมีการปลูกอ้อยอย่างแพร่หลายในจังหวัดต่าง ๆ ตามภูมิภาค ภาคเหนือ ภาคกลาง ภาคตะวันออกเฉียงเหนือ และภาคตะวันออก ดังจะเห็นได้จากข้อมูล รายงานสถานการณ์การ

ปลูกอ้อย ปีการผลิต 2565/66 [3] ของสำนักงานคณะกรรมการอ้อยและน้ำตาลทราย ซึ่งมีการประยุกต์ใช้เทคโนโลยี การสำรวจข้อมูลระยะไกล (Remote Sensing) ในการจำแนกข้อมูลดาวเทียม ด้วยโปรแกรมคอมพิวเตอร์ ในการร่วมสำรวจเพื่อจัดเก็บข้อมูลและจัดทำเป็นรายงานผลสำรวจพื้นที่ปลูกอ้อยประจำปีการผลิต 2565/2566 ดังนี้

1) ภาคเหนือ มีพื้นที่เพาะปลูกอ้อยจำนวน 9 จังหวัด ได้แก่ จังหวัดแพร่ อุตรดิตถ์ สุโขทัย ตาก พิชณุโลก กำแพงเพชร พิจิตร นครสวรรค์ และเพชรบูรณ์ มีพื้นที่ปลูกอ้อย 2,738,031 ไร่ เพิ่มขึ้น จำนวน 32,088 ไร่ คิดเป็นร้อยละ 1.19 โดยจังหวัดที่มีพื้นที่ปลูกอ้อยมากที่สุด 3 จังหวัดแรก ได้แก่ จังหวัดเพชรบูรณ์ นครสวรรค์ และกำแพงเพชร ตามลำดับ

2) ภาคกลาง มีพื้นที่เพาะปลูกอ้อยจำนวน 12 จังหวัด ได้แก่ จังหวัดอุทัยธานี ชัยนาท สิงห์บุรี ลพบุรี สระบุรี อ่างทอง สุพรรณบุรี กาญจนบุรี นครปฐม ราชบุรี เพชรบุรี และประจวบคีรีขันธ์ มีพื้นที่ปลูกอ้อยทั้งหมด 3,039,792 ไร่ เพิ่มขึ้น จำนวน 48,460 ไร่ คิดเป็นร้อยละ 1.62 โดยจังหวัดที่มีพื้นที่ปลูกอ้อยมากที่สุด 3 จังหวัดแรก ได้แก่ จังหวัดกาญจนบุรี ลพบุรี และสุพรรณบุรี ตามลำดับ

3) ภาคตะวันออกเฉียงเหนือ มีพื้นที่เพาะปลูกอ้อยจำนวน 20 จังหวัด ได้แก่ จังหวัดเลย หนองบัวลำภู อุดรธานี หนองคาย บึงกาฬ สกลนคร นครพนม ชัยภูมิ ขอนแก่น มหาสารคาม ร้อยเอ็ด กาฬสินธุ์ มุกดาหาร อำนาจเจริญ ยโสธร นครราชสีมา บุรีรัมย์ สุรินทร์ ศรีสะเกษ และอุบลราชธานี มีพื้นที่ปลูกอ้อยทั้งหมด 4,950,053 ไร่ เพิ่มขึ้นจำนวน 288,258 ไร่ คิดเป็นร้อยละ 6.18 โดยจังหวัดที่มีพื้นที่ปลูกอ้อยมากที่สุด 3 จังหวัดแรก ได้แก่ จังหวัดชัยภูมิ บุรีรัมย์ และนครราชสีมา ตามลำดับ

4) ภาคตะวันออก มีพื้นที่เพาะปลูกอ้อยจำนวน 6 จังหวัด ได้แก่ จังหวัดปราจีนบุรี สระแก้ว ฉะเชิงเทรา ชลบุรี ระยอง และจันทบุรี มีพื้นที่ปลูกอ้อยทั้งหมด 670,947 ไร่ เพิ่มขึ้นจำนวน 7,669 ไร่ คิดเป็นร้อยละ 1.016 โดยจังหวัดที่มีพื้นที่ปลูกอ้อยมากที่สุด 3 จังหวัดแรก ได้แก่ จังหวัดสระแก้ว ชลบุรี และจันทบุรี ตามลำดับ

สรุปสถานการณ์พื้นที่ปลูกอ้อย ปีการผลิต 2565/66 มีพื้นที่เพาะปลูกอ้อยทั่วประเทศในเขตพื้นที่สำรวจรวม 47 จังหวัด จำนวน 11,398,823 ไร่ ซึ่งมีพื้นที่เพิ่มขึ้นจากปีการผลิต 2564/65 จำนวน 376,475 ไร่ หรือคิดเป็นร้อยละ 3.42 โดยแบ่งเป็นพื้นที่ปลูกอ้อยเพิ่มขึ้นโดยจังหวัดที่มีพื้นที่ปลูกอ้อยมากที่สุด 3 จังหวัดคือ จังหวัดชัยภูมิ บุรีรัมย์ และนครราชสีมา เนื่องจากสภาพอากาศเอื้ออำนวยต่อการเพาะปลูกและราคาอ้อยเพิ่มขึ้นจากปีที่ผ่านมา


2.2.3.1 สถานการณ์การปลูกอ้อยของกลุ่มภาคตะวันออกเฉียงเหนือตอนกลาง


พืชเศรษฐกิจสำคัญของกลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง [4] ซึ่งประกอบไปด้วย จังหวัดกาฬสินธุ์ ขอนแก่น ร้อยเอ็ด และมหาสารคาม ที่ทำรายได้หลักให้เกษตรกรอย่างหนึ่ง คือ การเพาะปลูกอ้อย โดยมีสถานการณ์การปลูกอ้อยโรงงานปีการผลิต 2565/2566 [3] ดังตาราง 1 และ

มีพื้นที่เพาะปลูกอ้อยและที่ตั้งโรงงานน้ำตาลในแต่ละจังหวัดดังภาพประกอบ 1, 2, 3 และภาพประกอบ 4


ตาราง 1 รายงานพื้นที่เพาะปลูกอ้อยและผลผลิตส่งโรงงานปีการผลิต 2565/2566

ลำดับที่	จังหวัด	พื้นที่ปลูก อ้อย (ไร่)	ปริมาณอ้อย (ตัน)	พื้นที่เก็บ เกี่ยวอ้อย ส่งโรงงาน (ไร่)	ปริมาณอ้อย ส่งโรงงาน (ตัน)	ผลผลิต ตัน/ไร่
1	ขอนแก่น	651,492	7,003,539	554,221	5,957,877	10.75
2	กาฬสินธุ์	447,058	4,783,521	382,279	4,090,388	10.70
3	ร้อยเอ็ด	169,769	1,808,040	145,193	1,546,306	10.65
4	มหาสารคาม	132,275	1,256,613	112,509	1,068,833	9.50
รวม		1,400,594	14,851,713	1,194,202	12,663,404	41.60







ภาพประกอบ 1 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.ขอนแก่น ปีการผลิต 2565/66 [3]



ภาพประกอบ 2 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.กาฬสินธุ์ ปีการผลิต 2565/66 [3]



ภาพประกอบ 3 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.ร้อยเอ็ด ปีการผลิต 2565/2566 [3]



ภาพประกอบ 4 พื้นที่ปลูกอ้อยและที่ตั้งโรงงานน้ำตาล จ.มหาสารคาม ปีการผลิต 2565/66 [3]

2.2.4 โรคที่สำคัญของอ้อย

ปัญหาการระบาดของโรคและแมลงศัตรูอ้อย นั้นส่งผลเสียต่อการเจริญเติบโตของอ้อย และทำให้ผลผลิตลดลง โดยโรคที่สำคัญของอ้อย ได้แก่ โรคใบจุดเหลือง โรคใบด่าง โรคราสนิม โรคใบชิตน้ำตาล โรคใบจุดสีน้ำตาล โรคใบจุดวงแหวน โรคใบลวก โรคราน้ำค้าง โรคใบขาว โรคฟิจี โรคใบชิตแดง โรคเน่าคออ้อย โรคยอดบิด โรคเส้ดำ โรคเหี่ยวแดง โรคเน่ากลั่นสับปะรด โรคต่อแกระแกร็น โรคกอดตะไคร้ และแมลงศัตรูที่สำคัญ ได้แก่ หนอนซอนใบ แมลงหีข้าว เพลี้ยกระโดดดำ มวนอ้อย ตั๊กแตน ตัวงวงอ้อย หนอนบู่ เพลี้ยแป้ง ไร่อ้อยสีแดง หนอนกอลายจุดเล็ก จึงควรมีการเฝ้าระวัง และตระหนักถึงความสำคัญของโรคอ้อย รวมทั้งการจัดการโรค และแมลงศัตรูอ้อยที่รวดเร็ว และถูกวิธี เพื่อลดความสูญเสียต่อผลผลิตและต้นทุนในการผลิตอ้อยในอนาคต [20] ซึ่งการที่เกษตรกรชาวไร่อ้อยและผู้เกี่ยวข้องจะผลิต ขยายอ้อยให้ได้รับผลผลิตอย่างเต็มศักยภาพตามเป้าหมายที่วางไว้ รวมทั้งได้รับผลกระทบจากปัญหาความผิดปกติของอ้อยอันเกิดจากโรค แมลงศัตรูอ้อย และสาเหตุอื่น ๆ น้อยที่สุด มีความจำเป็นอย่างยิ่งที่ต้องมีความสามารถในการจำแนกชนิดและลักษณะอาการของความผิดปกติที่เกิดขึ้นกับอ้อยให้ได้ถูกต้องและรวดเร็ว การวินิจฉัยอ้อยผิดปกติเบื้องต้นสามารถระบุจากอาการผิดปกติ ที่อาการผิดปกติบนใบ ได้แก่ ใบด่าง ใบจุด ใบด่างเป็นลายชิตขาวหรือเหลือง ใบเป็นหูดปุ่มปม ใบชิตแดงเส้นกลางใบแดง ใบอ้อยสีชิตและแห้ง ใบเว้าแหว่ง มีสีด้าปกคลุมใบอ้อย ใบมีสีแดงหรือม่วงอมแดง [5]

การปลูกอ้อยในประเทศไทย แทบจะ 80% ของพื้นที่ปลูกอ้อยนั้นได้ปลูกอ้อยพันธุ์ขอนแก่น 3 เนื่องด้วย ให้ผลผลิตสูงถึง 15-20 ตันต่อไร่ ให้ความหวาน 12-14 ซีซีเอส ที่สำคัญคือ ทนแล้ง และไวต่อดี แต่พอมิพื้นที่ปลูกมาก และปลูกเป็นเวลานาน ก็ทำให้เกิดโรคสะสมในท่อนพันธุ์ เช่น โรคใบขาว หรือโรคที่เกิดจากสภาพแวดล้อมที่เหมาะสมกับการระบาด เช่น โรคเส้นกลางใบแดง โรคราสนิม และโรคใบจุดวงแหวน เป็นต้น [21] โรคสำคัญดังกล่าวนี้สามารถแยกโรคที่เกิดขึ้นจากอาการที่ปรากฏบนใบอ้อยอย่างชัดเจน และสามารถวินิจฉัยเบื้องต้นได้นั้น ได้แก่ โรคราสนิม โรคเส้นกลางใบแดง และโรคใบจุดวงแหวน ซึ่งแต่ละโรคมีรายละเอียดดังนี้

2.2.4.1 โรคราสนิม (Rust disease) [5], [22] สาเหตุเกิดจากเชื้อรา *Puccinia melanocephala* ลักษณะอาการเชื้อโรคจะเริ่มเข้าทำลายใบอ่อน เห็นเป็นจุดเล็ก ๆ สีแดง ต่อมาจุดแผลจะพัฒนาขึ้นจนเห็นได้ชัดเจนเมื่อใบอ้อยเจริญเป็นใบแก่ แผลจะขยายยาวออก มีขนาดแผลกว้าง 1-3 มิลลิเมตร ยาว 2-10 มิลลิเมตร เปลี่ยนเป็นสีน้ำตาลแดง แผลจะมีลักษณะนูนขึ้นโดยเฉพาะด้านหลังใบ เชื้อราจะมีการสร้างสปอร์ในส่วนของแผลนูนดังกล่าวที่บริเวณใต้ใบ เมื่อแผลแตกออกจะขรุขระ มีผงสปอร์สีน้ำตาลแดงลักษณะคล้ายสนิมจำนวนมาก พบมีแผลหนาแน่นบนใบล่างมากกว่าใบบนของลำ แผลที่เกิดจะกระจายทั่วไป ในพันธุ์ที่อ่อนแอต่อโรค แผลที่เกิดติดต่อกันอาจมองไม่เห็นผิว

ใบ ทำให้อ้อยสูญเสียพื้นที่ในการสังเคราะห์แสง โดยใบอ้อยที่เป็นโรคนั้นจะแห้งโดยที่ใบยังไม่แก่ ทำให้การเจริญเติบโตของอ้อยไม่สมบูรณ์



ภาพประกอบ 5 ลักษณะอ้อยที่เป็นโรคราสนิม

การแพร่ระบาด สปอร์ (teliospore) ของราสนิมจะยังคงอยู่บนใบอ้อยที่เป็นโรคข้ามฤดู และเชื้อสามารถอยู่ในเศษซากอ้อย ทั้งนี้ สปอร์ (uredospore) สามารถแพร่กระจายไปตามสายลม และฝน ได้ โดยที่โรคราสนิมสามารถเกิดขึ้นได้อย่างรุนแรงเมื่ออากาศมีความอบอุ่น และมีความชื้นสูง

การป้องกัน เนื่องจากสปอร์ของเชื้อราสาเหตุที่ทำให้เกิดโรคราสนิมในอ้อยนั้นแพร่กระจายไปตามลมได้ จึงควรหลีกเลี่ยงการปลูกอ้อยพันธุ์ที่อ่อนแอต่อโรคเป็นพื้นที่กว้าง เพื่อไม่ให้เกิดการระบาดรุนแรง เมื่อพบส่วนของอ้อยที่เป็นโรคราสนิมควรมีการเก็บออกจากแปลงอ้อยและทำลายทิ้ง รวมทั้งกำจัดวัชพืชขึ้นอาจเป็นพืชอาศัยสลับของเชื้อสาเหตุโรค

2.2.4.2 โรคเน่าแดง เหี่ยวเน่าแดง และโรคเส้นกลางใบแดง (Red rot diseases) [23] สาเหตุเกิดจากเชื้อรา *Colletotrichum falcatum* เข้าทำลายอ้อยทุกส่วน ตั้งแต่ท่อนพันธุ์ ทำให้ท่อนพันธุ์เน่าไม่งอก ส่วนที่เสียหายมากที่สุดคือ การเข้าทำลายที่ลำต้น โดยบริเวณปล้องที่ติดเชื้อจะเกิดเป็นสีม่วงที่ภายนอกต่อมาจะมีอาการใบเหลืองและแห้งตาย เมื่อผ่าดูตามความยาวของลำเนื่ออ้อยจะมีสีแดง ในพันธุ์ที่อ่อนแอจะมีจุดแต้มสีขาวเป็นจ้ำคั่นในรอยแผลลักษณะดังกล่าวกับความยาวลำอ้อยและสัณฐานเหมือนเปรี๊ยะ รอยแต้มจะมีขนาดไม่แน่นอนจะผันแปรตามความต้านทานของพันธุ์อ้อย ในสภาพธรรมชาติมักพบเชื้อ *Fusarium moniliformeae* ซึ่งเชื่อนี้โดยปกติเป็นสาเหตุของโรคเหี่ยวเข้าร่วมทำลายด้วย จึงเรียกว่าเหี่ยวเน่าแดง



ภาพประกอบ 6 ลักษณะอ้อยที่เป็นโรคเส้นกลางใบแดง

อาการบนใบ จะเริ่มต้นเป็นจุดยาวบนเส้นกลางใบด้านบนของใบ จุดนี้อาจจะมีสีน้ำตาลแดงเข้มแล้วเปลี่ยนเป็นสีฟางที่มีขอบสีม่วง และมีจุดดำเล็ก ๆ ในบางครั้งเชื้ออาจเข้าทำลายใบอ้อย ทำให้เกิดเป็นจุดแดงเล็ก ๆ บนเนื้อใบแต่อาการนี้เกิดขึ้นน้อยมาก อีกอาการที่พบคือ อาการเป็นรอยเปื้อนแดงบนกาบใบ



ภาพประกอบ 7 อาการโรคเส้นกลางใบแดง

การแพร่ระบาด ระบาดไปกับท่อนพันธุ์ และเชื้อรา *Colletotrichum falcatum* เข้าทำลายตามรอยแผลที่เกิดจากหนอน หรือแผลแตกลำ โรคจะระบาดรุนแรงในพื้นที่ที่มีความชื้นสูง เช่น ในเขตชลประทานหรือที่นา

การป้องกัน ไถแปลงอ้อยที่เป็นโรครุนแรงทิ้ง และคราดตออ้อยเก่าออกให้หมด ปลุกพืชหมุนเวียน ยกเว้นพืชอาศัยของเชื้อสาเหตุ เช่น ข้าวฟ่าง ข้าวโพด ถั่วเขียว และการเลือกใช้พันธุ์ที่ต้านทานในพื้นที่ที่เป็นโรค

2.2.4.3 โรคใบจุดวงแหวน (Ring Spot disease) [23] สาเหตุเกิดจากเชื้อรา *Leptosphaeria sacchari* มักจะพบในอ้อยโตในช่วงใกล้เก็บเกี่ยว เชื้อเข้าทำลายใบอ้อย ทำให้เกิดเป็นจุดแผลเล็ก ๆ รูปไข่ สีเขียวเข้มฉ่ำน้ำในระยะแรก ต่อมาเปลี่ยนเป็นสีน้ำตาลขอบแผลสีน้ำตาลเข้ม มีวงสีเหลืองล้อมรอบเมื่อแผลแก่บริเวณกลางแผลจะแห้งเป็นสีฟางข้าวและมี fruiting body ของเชื้อเห็นเป็นจุดสีดำเล็ก ๆ กระจายอยู่กลางแผล แผลมักมีรูปร่างไม่แน่นอน ขึ้นอยู่กับสภาพแวดล้อม อาจรุนแรงแห้งทิ้งไปได้



ภาพประกอบ 8 ลักษณะอ้อยที่เป็นโรคใบจุดวงแหวน

การแพร่ระบาด พบว่าเชื้อสาเหตุของโรคสามารถอยู่ในเศษซากพืชที่อยู่ในแปลงอ้อย สปอร์ปลิวไปตามลมและฝน อาจมีการระบาดได้มากในสภาพที่มีความชื้นสูง [5] คำแนะนำการป้องกัน กำจัดใบที่เป็นโรคออกและเผาทำลาย ทำความสะอาด กำจัดวัชพืชในแปลงปลูก ปลุกอ้อยพันธุ์ต้านทาน หรือเป็นโรคเพียงเล็กน้อย และปลุกพืชหมุนเวียนทุก ๆ 2 ปี

2.2 คอมพิวเตอร์วิทัศน์ (Computer Vision)

คอมพิวเตอร์วิทัศน์ (Computer Vision) เกิดขึ้นในปลายยุค ค.ศ. 1960-1970 โดยเน้นการจำลองระบบการมองเห็นของมนุษย์และเข้าใจแนวคิดเกี่ยวกับกล้องและการถ่ายภาพ ในปี 2010 เทคนิคคอมพิวเตอร์วิทัศน์สามารถทำงานที่ยากลำบาก เช่น การรู้จำวัตถุ การนำทางยานพาหนะอัตโนมัติ การตรวจจับใบหน้า และการประมวลผลภาพด้วยความเร็วสูง เทคนิคคอมพิวเตอร์วิทัศน์เป็นส่วนสำคัญของ AI เช่น Machine learning และ Deep learning ซึ่งการรวมเทคนิคคอมพิวเตอร์วิทัศน์และ AI เป็นส่วนสำคัญของการเปลี่ยนแปลงในอุตสาหกรรม [24] โดยการใช้กล้องถ่ายภาพเป็นหลักการทำงาน คอมพิวเตอร์วิทัศน์ใช้ในอุตสาหกรรมการผลิตที่ต้องการความแม่นยำและประสิทธิภาพสูง โดยการประมวลผลภาพจากกล้องถ่ายภาพดิจิทัล เพื่อค้นหาความเหมือนหรือแยกแยะวัตถุ ระบบคอมพิวเตอร์วิทัศน์ประกอบด้วยหลายขั้นตอน เช่น ทำเทรชโฮลด์ (Thresholding) เพื่อเปลี่ยนภาพสีเทาเป็นภาพขาวดำ การแยกภาพออกเป็นส่วน ๆ (Segmentation) การรู้จำแบบ (Pattern Recognition) การเข้าคู่รูปแบบ (Template Matching) และการหาขอบภาพ (Edge Detection) เป็นต้น ในปัจจุบันมีการนำคอมพิวเตอร์วิทัศน์ มาใช้ในอุตสาหกรรมการผลิตที่มีความสลับซับซ้อน ที่มีความต้องการการทำงานที่มีประสิทธิภาพสูง และต้องการความแม่นยำในการผลิตที่ใช้คอมพิวเตอร์วิทัศน์ในการประมวลผลภาพ (Image Processing) จากกล้องถ่ายภาพแบบดิจิทัล เพื่อให้คอมพิวเตอร์มองเห็นผ่านโปรแกรม เพื่อตัดสินใจทำงานได้ถูกต้องตามคำสั่งที่ต้องการ

2.2.1 หลักการทำงานของคอมพิวเตอร์วิทัศน์ (Computer Vision) [23], [24], [25] เป็นกระบวนการที่คอมพิวเตอร์ใช้เทคนิคและอัลกอริทึมต่าง ๆ เพื่อให้เครื่องคอมพิวเตอร์สามารถรับรู้และเข้าใจภาพหรือวิดีโอได้ ซึ่งการทำงานของ Computer Vision สามารถอธิบายได้ดังนี้

1) การสกัดคุณลักษณะ (Feature Extraction): เป็นขั้นตอนแรกที่คอมพิวเตอร์จะนำภาพหรือวิดีโอเข้ามาประมวลผล เครื่องจะสกัดคุณลักษณะที่สำคัญออกมา เช่น การตรวจจับขอบ (Edge Detection) หรือการหาจุดสังเกต (Interest Point Detection) เพื่อใช้ในขั้นตอนถัดไป

2) การหาความสัมพันธ์ (Relationships): เป็นกระบวนการที่คอมพิวเตอร์จะวิเคราะห์ความสัมพันธ์ระหว่างคุณลักษณะที่สกัดออกมา เช่น การหาเส้นตรง (Line Detection) หรือการหาวงกลม (Circle Detection) เพื่อหาความสัมพันธ์หรือรูปร่างของวัตถุในภาพ

3) การจำแนกและการระบุวัตถุ (Object Classification and Recognition): เป็นขั้นตอนที่คอมพิวเตอร์จะระบุและจำแนกวัตถุในภาพหรือวิดีโอ โดยใช้แนวคิดและเทคนิคต่าง ๆ เช่น การใช้ภาพจิตรกรรม (Histogram of Oriented Gradients, HOG) หรือการใช้โมเดลปัญญาประดิษฐ์ (Deep Learning Models) เพื่อระบุวัตถุและจำแนกออกเป็นกลุ่มต่าง ๆ

4) การติดตามวัตถุ (Object Tracking): เป็นกระบวนการที่คอมพิวเตอร์จะติดตามและติดตามการเคลื่อนไหวของวัตถุในภาพหรือวิดีโอ เพื่อติดตามตำแหน่งและเคลื่อนไหวของวัตถุตลอดเวลา

5) การเชื่อมโยงข้อมูล (Data Association): เป็นขั้นตอนที่คอมพิวเตอร์จะเชื่อมโยงข้อมูลที่ได้จากการติดตามวัตถุในเฟรมต่าง ๆ เพื่อวิเคราะห์และสร้างความเข้าใจในการเคลื่อนไหวของวัตถุในช่วงเวลา

2.2.2 วิธีการประมวลผลภาพ (Image Processing) [28], [29] เป็นกระบวนการที่ใช้เทคนิคและอัลกอริทึมต่าง ๆ เพื่อปรับปรุงและแปลงภาพเพื่อให้ได้ข้อมูลที่เป็นประโยชน์หรือลดสิ่งรบกวนในภาพ สำหรับการประมวลผลภาพ สามารถใช้วิธีและเทคนิคต่าง ๆ ได้คือ

1) การปรับความคมชัด (Image Enhancement): เป็นกระบวนการที่ใช้เพื่อปรับปรุงคุณภาพของภาพ เช่น การปรับความสว่าง (Brightness Adjustment), การปรับความคมชัด (Contrast Enhancement), การลดสัญญาณรบกวน (Noise Reduction) เป็นต้น วิธีการที่นิยมใช้ได้แก่ การใช้การกรองภาพ (Image Filtering) และการใช้ประโยชน์จากฟังก์ชันทางคณิตศาสตร์ เช่น การใช้เครื่องหมายเชิงเส้น (Linear Transformations) หรือการใช้การเทียบภาพ (Histogram Equalization)


2) การตรวจจับและการแยกวัตถุ (Object Detection and Segmentation): เป็นกระบวนการที่ใช้เพื่อตรวจจับวัตถุในภาพและแยกวัตถุออกจากพื้นหลัง เช่น การใช้แนวคิดของการเทียบรูปร่าง (Shape Matching), การใช้การเรียนรู้เชิงลึก (Deep Learning) เพื่อตรวจจับวัตถุ และการใช้วิธีการต่าง ๆ เช่น การใช้การตัดส่วน (Segmentation) และการใช้การกรองภาพ (Image Filtering)

3) การปรับแต่งสี (Color Adjustment): เป็นกระบวนการที่ใช้เพื่อปรับปรุงสีของภาพ หรือเปลี่ยนแปลงสีของภาพ เช่น การปรับสีอย่างเดียว (Color Correction), การปรับสีทั้งหมด (Color Balance), หรือการเปลี่ยนแปลงสีทั้งหมด (Color Transformation) วิธีการที่นิยมใช้ ได้แก่ การใช้แนวคิดของการเปลี่ยนแปลงเชิงเส้น (Linear Transformations) หรือการใช้เทคนิคการสร้างภาพเทียม (Color Mapping)

4) การวิเคราะห์ภาพ (Image Analysis): เป็นกระบวนการที่ใช้เพื่อวิเคราะห์และสกัดข้อมูลที่เป็นประโยชน์จากภาพ เช่น การหาวัตถุในภาพ (Object Detection), การหาลักษณะเด่นของวัตถุ (Feature Extraction), การวัดคุณลักษณะของวัตถุ (Feature Measurement) เป็นต้น วิธีการที่นิยมใช้ ได้แก่ การใช้แนวคิดของการระบุเส้นตรง (Line Detection), การใช้เทคนิคการแยกประเภท (Classification) หรือการใช้การเรียนรู้เชิงลึก (Deep Learning)


2.3 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep learning) เป็นส่วนย่อยของการเรียนรู้ของเครื่อง (Machine learning) การเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องนั้น เป็นส่วนย่อยของปัญญาประดิษฐ์ (Artificial intelligence) [30] ดังภาพประกอบ 9




ภาพประกอบ 9 ความสัมพันธ์ระหว่าง Artificial intelligence, Machine learning และ Deep learning

ความแตกต่างประการหนึ่งที่สำคัญที่สุดของการเรียนรู้เชิงลึกกับการเรียนรู้ของเครื่อง คือ การเรียนรู้เชิงลึกมีความสามารถในการปรับการเรียนรู้เมื่อมีข้อมูลขนาดเล็กนั้นทำงานได้ไม่ดี แต่เมื่อมีข้อมูลเพิ่มขึ้น ประสิทธิภาพจะเพิ่มสูงขึ้นอย่างก้าวกระโดดในการเรียนรู้ทำความเข้าใจและการดำเนินการกับข้อมูล ขณะที่การเรียนรู้ของเครื่องแบบดั้งเดิมไม่ได้ขึ้นอยู่กับปริมาณข้อมูลมากนัก ดังภาพประกอบ 10 แสดงให้เห็นชัดว่าอัลกอริทึมการเรียนรู้เชิงลึก (Deep learning) เมื่อได้รับข้อมูลจำนวนมากจะเจริญเติบโตได้ดีและมีความถูกต้องในการทำนายสูง ในส่วนของการเรียนรู้ของเครื่องแบบดั้งเดิม (Traditional ML) และโครงข่ายประสาทเทียมขนาดเล็ก (Shallow NN) ที่มีการเชื่อมต่อ/เซลล์ประสาทจำนวนน้อย เมื่อมีจำนวนข้อมูลจำกัดจะให้ผลลัพธ์ที่ดี ดังนั้นการออกจากกับดักเรื่องปริมาณข้อมูลที่ใช้ในการเรียนรู้คือการเลือกอัลกอริทึมของเครื่องที่เหมาะสมกับปัญหาและปริมาณข้อมูลที่มีอยู่เป็นวิธีที่ง่ายที่สุด [31]



ภาพประกอบ 10 การเปรียบเทียบประสิทธิภาพอัลกอริทึมการเรียนรู้ของเครื่องในรูปแบบต่าง ๆ ตามปริมาณของข้อมูลในการเรียนรู้ [31]

การเรียนรู้เชิงลึก (Deep Learning) ถือเป็นส่วนย่อยของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งโครงสร้างและการประมวลผลคล้ายกับสมองมนุษย์ที่เรียกว่า โครงข่ายประสาทเทียม (Artificial Neural Network) อันที่จริง Deep Learning เป็นโครงข่ายประสาทเทียมขนาดใหญ่ ที่มีชั้นในการประมวลผลหลายชั้น การเรียนรู้เชิงลึกได้รับความนิยมและมีงานวิจัยที่เกี่ยวข้องมากขึ้น ในช่วงไม่กี่ปีที่ผ่านมา [32] โดยที่เซลล์ประสาท (Neuron) ถูกเรียกว่า โหนด (Nodes) มีใยประสาท (Nerve fiber) ทำหน้าที่รับสัญญาณประสาท (Input) เรียกว่า เดนไดรต์ (Dendrite) และส่งสัญญาณประสาท (Output) เรียกว่า แอกซอน (Axon) การประมวลผลในเซลล์ประสาทเทียมจะรับข้อมูลหรือสัญญาณที่ส่งจากเซลล์ประสาทชั้นก่อนหน้า มีการประมวลผลเกิดขึ้นในกรอบสี่เหลี่ยม เรียกส่วนนี้ว่า โหนด และส่งกระแสสัญญาณที่ถ่วงน้ำหนักแล้ว (oj) ให้เซลล์ประสาทในชั้นถัดไป ดังภาพประกอบที่ 3 (ข) ซึ่งเป็นการอธิบายการทำงานของเซลล์ประสาทเทียมจำนวน 1 เซลล์เท่านั้น โครงข่ายประสาทเทียมสร้างขึ้นประกอบด้วยชั้นเซลล์ประสาท (Layer) มากกว่า 3 ชั้น และในการเรียนรู้เชิงลึกนั้นจะตั้งชื่อเพื่อสื่อถึง ความลึกของเลเยอร์ในโครงข่ายประสาทเทียม [30]



ภาพประกอบ 11 การเปรียบเทียบส่วนประกอบเซลล์ประสาทสมองมนุษย์ (ก) และเซลล์ประสาทเทียม (ข) [30]


การเรียนรู้เชิงลึก (Deep learning) มีการคิดค้นอัลกอริทึมและโครงสร้างต่าง ๆ ขึ้นมา เพื่อใช้ในการวิเคราะห์รูปแบบต่าง ๆ ให้ตอบสนองต่อความต้องการ โดยมีอัลกอริทึมที่มีประสิทธิภาพในการวิเคราะห์สูง และได้รับความนิยมในปัจจุบัน ยังรวมถึงเทคโนโลยีทางด้านฮาร์ดแวร์ ที่พัฒนาขึ้นอย่างก้าวกระโดด ทั้งหน่วยประมวลผลที่มีประสิทธิภาพสูง รวมถึงการประยุกต์ใช้ Graphic Processing Unit ในการใช้งานการเรียนรู้เชิงลึก ซึ่งประมวลผลได้รวดเร็วกว่าการประมวลผลด้วย Central Processing Unit (CPU) เนื่องจาก CPU ประมวลผลในรูปแบบของ Serial แต่ GPU นั้นประมวลผลในรูปแบบของ Matrix Parallels [33] สามารถอธิบายได้ว่าการเรียนรู้เชิงลึกเป็นการใช้อัลกอริทึมที่เรียนรู้จากหลายระดับเพื่อแสดงถึงความสัมพันธ์ที่ซับซ้อนระหว่างข้อมูลในการสร้างแบบจำลอง [34]

สำหรับหลักการของการเรียนรู้เชิงลึก นั้นได้เริ่มนำมาประยุกต์ใช้กับงานวิจัยทางด้าน Computer Vision และ Image Processing โดยเรียนรู้ภาพจากข้อมูลนำเข้าเป็นพิกเซล (Pixel) ด้วยตัวจำแนกประเภท (Classifier) โดยแต่ละลำดับชั้นการทำงานจะจำแนกคุณลักษณะออกมาเป็น Output ในแต่ละชั้นและนำมาเป็น Input ของลำดับชั้นถัดไป โดยขั้นตอนการเรียนรู้ด้วยการเรียนรู้เชิงลึก โดยทั่วไปแบ่งออกเป็น 3 ประเภท คือ 1) โครงข่ายชั้นลึกแบบมีผู้สอน (Supervised Deep Network) ซึ่งทำงานได้ดีเมื่อจำนวนผลเฉลย (Label) มีขนาดใหญ่ โครงสร้างของโมเดล (Model) มีส่วนสำคัญมาก เช่น โครงสร้างแบบ Convolution ได้แก่ Deep Neural Network (DNN), Convolutional Neural Network (CNN), Recurrent Neural Network (RNN) 2) โครงข่ายชั้นลึกแบบไม่มีผู้สอน (Unsuper-vised Deep Network) เป็นการเรียนรู้จากโครงสร้างทางสถิติหรือขึ้นกับข้อมูลที่ยังไม่มีผลเฉลย เหมาะสมกับกรณีที่จำนวนผลเฉลยมีไม่มากนัก ได้แก่ Deep Autoencoder, Deep Belief Network (DBN), Restricted Boltzmann Machines (RBM) เป็นต้น และ 3) โครงข่ายชั้นลึกแบบผสม (Hybridge Deep Network) เป็นการผสมผสานขั้นตอนการทำงานก่อนการ

สอนในแต่ละชั้นด้วยการใช้ Unsupervised Deep Network ก่อน แล้วจึงใช้การสอนในชั้นต่อมาด้วย Supervised Deep Network ซึ่งปัจจุบันวิธีแบบผสมผสานนี้ได้รับความนิยมขึ้นมาก เช่นการใช้ DBN แล้วตามด้วย DNN หรือ CNN เป็นต้น [35]

2.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เป็นการจำลองการมองเห็นของมนุษย์ ประกอบด้วยชุดของ convolution และ sub-sampling layer ตามด้วยเลเยอร์ที่เชื่อมต่ออย่างสมบูรณ์ [6] เป็นการมองภาพแบบเมตริกซ์ของพิกเซลเรียงต่อกัน และจำลองการมองพื้นที่เป็นพื้นที่ย่อย ๆ ที่มนุษย์มองเห็น นำมาจำแนก (Classification) และนำกลุ่มพื้นที่ย่อย ๆ มาผสานกันเพื่อดูว่าสิ่งที่เห็นอยู่คืออะไร [36] อัลกอริทึม CNN แบ่งการทำงานออกเป็น 2 ส่วน ได้แก่ Feature Extraction และ Classification โดย Feature Extraction เป็นการทำงานเพื่อคัดเลือกคุณลักษณะไปใช้ในการทำนายผลที่ขั้นตอน Classification ซึ่งเป็นขั้นตอนต่อไป การทำ Feature Extraction ของ CNN ใช้ Filter ในการเลือก Feature โดยทำการกำหนดขนาดของ Filter ที่ใช้ในการคัดเลือกข้อมูล ซึ่ง Filter อยู่ในรูปของ Matrix ทำงานโดยวางลงไปบนชุดข้อมูลเพื่อกำหนดบริเวณที่จะใช้วิเคราะห์ และประมวลผลออกมา [37] โครงสร้างของโครงข่ายประสาทเทียมแบบคอนโวลูชัน ดังภาพประกอบ 12



ภาพประกอบ 12 โครงสร้างของอัลกอริทึม CNN [14]

จากภาพประกอบ 12 อัลกอริทึม CNN โดยทั่วไปประกอบด้วย Layer แยกเป็นชั้น ดังนี้

- 1) Input Layer เป็นชั้นแรกของระบบการทำงานโดยทำหน้าที่รับข้อมูลภาพ และอ่านค่า Input Image ที่รับเข้ามา คือ ขนาดความสูง (Height) ความกว้าง (Width) และความลึก (Depth) โดยมีหน่วยเป็นพิกเซล ส่วนความลึกจะเป็นเลขตามสี

2) Convolutional Layer สกัด Features จากระดับพิกเซล ออกจาก Input Image ผลลัพธ์ของชั้นคอนโวลูชันคือ Convolution Feature Map

3) Rectified Linear Unit คือชั้น Non-linear Activation Function

4) Pooling Layer คือการ Subsample Rectified Feature Map เพื่อลดมิติเชิงพื้นที่และสร้าง Feature Representation ขนาดเล็ก

5) SoftMax Layer เป็น Layer สุดท้ายเพื่อให้ Output ออกมาเป็น Multiclass Logistic Classifier

6) Output Layer คือ ชั้นการนำเสนอผลลัพธ์ของ Classification ที่ได้มาจากชั้น SoftMax Layer

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) เป็นโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perception) ซึ่งมีจุดเด่นที่สามารถดึงลักษณะเด่น และทำการจำแนกข้อมูลได้โดยตรงในครั้งเดียว จึงเหมาะที่จะนำมาประยุกต์ใช้ในการจำแนกรูปภาพ ดังนั้นในการวิจัยนี้ จำแนกเสนอการวินิจฉัยโรคพืชที่ปรากฏอาการบนใบอ้อย โดยใช้ CNN เป็นหลักในการประมวลผลข้อมูลของชุดรูปภาพทั้งหมด และเปรียบเทียบโดยใช้ลักษณะโครงสร้าง (Architecture) ที่แตกต่างกัน 4 แบบ ได้แก่ VGGNet, ResNet, DenseNet, AlexNet และ GoogLeNet

2.4.1 VGGNet [7] เป็นหนึ่งในอัลกอริทึมสำคัญที่ใช้ในการปัญญาประดิษฐ์ภาพ (Image Recognition) และภาพวิดีโอ (Video Recognition) ด้วยการสร้างโมเดลเชิงลึก (Deep Learning) ที่มีความลึกมากถึง 19 ชั้น (layer) โดยที่ชื่อ "VGG" มาจากทีมวิจัยที่มหาวิทยาลัย Oxford Visual Geometry Group ที่พัฒนาอัลกอริทึมนี้ขึ้น ซึ่งอัลกอริทึม VGGNet ได้รับความนิยมสูงเนื่องจากความเรียบง่ายและประสิทธิภาพสูงของมันในงานการจำแนกวัตถุในภาพ กระบวนการทำงานของอัลกอริทึม VGGNet เป็นหนึ่งในโมเดลปัญญาประดิษฐ์ที่ใช้ในการจำแนกภาพ (Image Classification) โดยมีลักษณะเด่นคือสถาปัตยกรรมที่ลึกและมีความซับซ้อน ทฤษฎีพื้นฐานและกระบวนการทำงานของ VGGNet สามารถอธิบายได้ดังนี้

1) สถาปัตยกรรมของ VGGNet นั้นใช้สถาปัตยกรรมของโครงข่ายประสาทเทียม (Convolutional Neural Network, CNN) ที่มีความลึก มีความซับซ้อน และใช้คอนโวลูชันเลเยอร์ (Convolutional Layer) ที่มีขนาดคอนโวลูชันเมตริกซ์ (Convolutional Kernel) ขนาดเล็ก โดยทั่วไป VGGNet ใช้คอนโวลูชันเมตริกซ์ขนาด 3×3 ที่มีการสเกลเอาต์ (Stride) เท่ากับ 1 และใช้การสอกรเอาต์ (Padding) เพื่อรักษารูปขนาดของภาพ เช่น padding ขนาดเดียวกับคอนโวลูชันเมตริกซ์ 3×3

2) การสกัดคุณลักษณะ (Feature Extraction) อัลกอริทึม VGGNet มีส่วนของ Convolutional Layer ซึ่งใช้เพื่อสกัดคุณลักษณะของภาพ โดยแต่ละเลเยอร์จะทำการคอนโวลูชัน

และการสเกลเอาต์เพื่อสกัดคุณลักษณะที่สำคัญของภาพออกมา พร้อมกับใช้ฟังก์ชันเป็นประโยชน์ เช่น Rectified Linear Unit (ReLU) เพื่อเพิ่มความเร็วในการประมวลผลและลดปัญหา Gradient Vanishing

3) การลดขนาด (Pooling) เพื่อลดขนาดของภาพและลดการคำนวณ หลังจาก Convolutional Layer แต่ละเลเยอร์ VGGNet ใช้ Max Pooling โดยสร้างสเกลเอาต์ขนาด 2x2 และเคลื่อนที่ด้วย Stride ขนาด 2 เพื่อให้ขนาดของภาพลดลงครึ่งหนึ่ง

4) เลเยอร์ Fully Connected เป็นส่วนที่เชื่อมโยงกับเลเยอร์ Convolutional Layer และมีหน้าที่ในการจำแนกคลาสของภาพ โดยปกติ VGGNet ใช้เลเยอร์ Fully Connected Layer สองเลเยอร์ ซึ่งมีจำนวนโหนดมากและเชื่อมต่อกับทุกโหนดในเลเยอร์ก่อนหน้า เพื่อรับข้อมูลจากคุณลักษณะที่สกัดมาและประมวลผลเพื่อให้ได้ผลลัพธ์การจำแนกที่แม่นยำ

5) การจำแนก (Classification) อัลกอริทึม VGGNet ใช้เลเยอร์ Softmax เป็นที่สุดท้ายของโมเดล เพื่อทำการคำนวณความน่าจะเป็นของแต่ละคลาสของภาพ และเลือกคลาสที่มีความน่าจะเป็นสูงที่สุดให้เป็นผลลัพธ์ของการจำแนก

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

ภาพประกอบ 13 สถาปัตยกรรมของ VGGNet [7]

2.4.2 ResNet [8] อัลกอริทึม ResNet (Residual Neural Network) เป็นหนึ่งในโมเดลปัญญาประดิษฐ์ที่ใช้ในการจำแนกภาพ (Image Classification) โดยมีลักษณะเด่นคือการใช้บล็อกที่มี

การผ่านทางเชื่อมต่อที่ช่วยให้สามารถสร้างโมเดลลึกได้โดยไม่เกิดปัญหา Gradient Vanishing อัลกอริทึม ResNet มีความซับซ้อนสูง ด้วยหลักการของการเชื่อมโยงทางทฤษฎีที่เรียกว่า "Residual Learning" ซึ่งอนุญาตให้สามารถฝึกอบรมและสร้างโมเดลที่มีความลึกได้อย่างปลอดภัยและมีประสิทธิภาพมากขึ้น กระบวนการทำงานของ ResNet สามารถอธิบายได้ดังนี้


1) ResNet ใช้สถาปัตยกรรมของโครงข่ายประสาทเทียม (Convolutional Neural Network, CNN) ที่มีความลึก ซับซ้อน และมีการใช้บล็อกที่เรียกว่า "Residual Block" ที่ช่วยในการสร้างโมเดลลักษณะลึก โดย Residual Block ประกอบด้วยการเชื่อมต่อแบบ "shortcut connection" ที่ช่วยให้ข้อมูลผ่านทางย่อยได้

2) การเชื่อมต่อแบบ "shortcut connection" นี้ใช้เพื่อข้ามบล็อกของโมเดลที่ต้องการปรับปรุง โดยแทนที่การปรับปรุงตรง ๆ บล็อกนั้นด้วยการบวกเพิ่มข้อมูลจากบล็อกก่อนหน้านี้ด้วยความคาดหวังว่าการสะท้อนของข้อมูลจากบล็อกก่อนหน้านี้จะช่วยให้การปรับปรุงประสิทธิภาพของโมเดลได้

3) การสร้าง Residual Block จะประกอบด้วย Convolutional Layer สองชั้น ซึ่งแต่ละชั้นจะมีการใช้คอนโวลูชันเลเยอร์ขนาดเล็ก (เช่น 3×3) ที่มีการ Scaleout และการ SCOUT เพื่อสกัดคุณลักษณะของภาพ และเชื่อมต่อผ่านทาง "shortcut connection" โดยใช้เพิ่มข้อมูลของบล็อกก่อนหน้านี้

4) ResNet มีสถาปัตยกรรมที่ลึกซึ่งมีการเรียกว่า ResNet-50, ResNet-101, หรือ ResNet-152 ซึ่งหมายถึงจำนวนของ Residual Block ในโมเดล เช่น ResNet-50 จะมี Residual Block ทั้งหมด 50 บล็อก


5) การทำนาย (Prediction): เมื่อผ่านการสกัดคุณลักษณะและผ่าน Residual Block ทั้งหมด โมเดล ResNet ใช้เลเยอร์ Fully Connected และเลเยอร์ Softmax เพื่อทำนายคลาสของภาพ เช่นเดียวกับโมเดลอื่น ๆ ในการจำแนกภาพ



ภาพประกอบ 14 แนวคิดของ residual learning หรือ residual block ซึ่งเป็นแนวคิดหลักของ ResNet [8]

2.4.3 DenseNet-121 [9] เป็นโมเดลโครงข่ายประสาทเทียม (neural network) ที่ถูกออกแบบมาเพื่อใช้ในการจำแนกหมวดหมู่ของภาพ (image classification) โดยเฉพาะ โมเดลนี้เป็นส่วนหนึ่งของชุดโมเดลที่เรียกว่า DenseNet ซึ่งเป็นสถาปัตยกรรมที่พัฒนาขึ้นจาก Convolutional Neural Network (CNN) ซึ่งมีลักษณะเด่นคือการเชื่อมต่อเส้นทางที่ชัดเจนระหว่างเลเยอร์ทั้งหมดของโครงข่าย เรียกว่า Dense connectivity โครงสร้างของ DenseNet-121 ประกอบด้วยเลเยอร์ต่าง ๆ ที่ประกอบกันอย่างชัดเจน แต่งแต่งด้วยการใช้บล็อกที่เรียกว่า Dense block ที่ประกอบด้วยเลเยอร์ของ convolutional layer ที่มีการใช้งาน Batch Normalization และ Rectified Linear Unit (ReLU) ระหว่างเลเยอร์ เพื่อเพิ่มประสิทธิภาพในการเรียนรู้และป้องกันปัญหาการติดตาย (vanishing gradient) ที่พบได้ในโมเดล CNN ทั่วไป โดย DenseNet-121 มีจำนวน 121 layers (hence the name) ซึ่งประกอบด้วย 4 เบสิคบล็อก แต่ละเบสิคประกอบด้วย Dense block ที่มีการเชื่อมต่อเส้นทางกับเลเยอร์ก่อนหน้าและเลเยอร์ทุกเลเยอร์ภายหลัง นอกจากนี้ยังมีเลเยอร์ Pooling และ Fully connected layer สำหรับการจำแนกหมวดหมู่ที่มีทั้งหมด 1000 หมวดหมู่ (ในกรณีของ ImageNet dataset)


DenseNet-121 ได้รับความนิยมในงานการจำแนกหมวดหมู่ของภาพ เนื่องจากมีประสิทธิภาพสูงและมีความเสถียรที่ดีในการฝึกสอน นอกจากนี้ยังมีความสามารถในการใช้งานในงานประยุกต์อื่น ๆ ที่เกี่ยวข้องกับการประมวลผลภาพด้วย



ภาพประกอบ 15 สถาปัตยกรรมของ DenseNet-121 [9]

2.4.4 AlexNet [10] เป็นอัลกอริทึมที่มีโครงสร้างลึกและใช้สถาปัตยกรรมพื้นฐานของโครงข่ายประสาทเชื่อมต่อ (Convolutional Neural Network) ในการประมวลผลภาพ ดัดแปลงและพัฒนาโดย Alex Krizhevsky, Ilya Sutskever และ Geoffrey Hinton ในปี 2012 เพื่อแข่งขันในการแข่งขันการจำแนกภาพ ImageNet Large Scale Visual Recognition Challenge (ILSVRC)

ในปี 2012 เช่นเดียวกัน ซึ่งได้รับความสนใจอย่างมากเนื่องจากประสิทธิภาพที่ดีเยี่ยมในการจำแนกภาพหลากหลายหมวดหมู่ ซึ่งสถาปัตยกรรมของ AlexNet นั้นเป็นโมเดลปัญญาประดิษฐ์ที่มีสถาปัตยกรรม Convolutional Neural Network (CNN) ที่ซับซ้อน ประกอบด้วย Convolutional Layer, Pooling Layer, และ Fully Connected Layer



ภาพประกอบ 16 สถาปัตยกรรมของ AlexNet [10]

จากภาพประกอบ 16 เป็นสถาปัตยกรรมของ AlexNet ที่ใช้แนวคิดของ CNN เป็นหลักโดยยังอาศัยหลักการแบบ top-down ที่ใช้ filter ในการสกัด feature ที่ละเอียดขึ้นเรื่อย ๆ โดยสามารถอธิบายแต่ละเลเยอร์ ได้ ดังนี้

- 1) Convolutional Layer ซึ่ง AlexNet ใช้ Convolutional Layer เพื่อสกัดคุณลักษณะของภาพ โดย Convolutional Layer แต่ละชั้นมีตัวกรองหลายตัวที่มีขนาดต่าง ๆ และใช้ฟังก์ชันเป็นประโยชน์ เช่น ReLU (Rectified Linear Unit) เพื่อเพิ่มประสิทธิภาพและลดปัญหา Gradient Vanishing
- 2) Pooling Layer ใช้ Pooling Layer เพื่อลดขนาดของ Feature Map และลดความซับซ้อนของโมเดล โดยส่วนใหญ่ใช้ Max Pooling เพื่อเลือกค่าสูงสุดในแต่ละส่วนของ Feature Map
- 3) Local Response Normalization (LRN) ใช้เทคนิค LRN เพื่อเพิ่มความสำคัญของฟีเจอร์ที่ติดต่อกัน โดยการแก้ไขค่าความกลัวที่เกิดจากข้อมูลภายในคลื่นบน
- 4) Fully Connected Layer ประกอบด้วย Fully Connected Layer ที่มีจำนวนโหนดมากและเชื่อมต่อกับทุกโหนดในชั้นก่อนหน้า โดยใช้ฟังก์ชันเป็นประโยชน์ เช่น ReLU และ Dropout เพื่อลดการเกิด Overfitting
- 5) Softmax Layer เป็นชั้นสุดท้ายที่ใช้ในการคำนวณความน่าจะเป็นของแต่ละคลาส และเลือกคลาสที่มีความน่าจะเป็นสูงที่สุดให้เป็นผลลัพธ์การจำแนก

2.4.5 GoogLeNet [11] เป็นสถาปัตยกรรมโมเดลปัญญาประดิษฐ์แบบ Convolutional Neural Network (CNN) ที่ถูกพัฒนาโดยทีมงานของ Google Research ในการแข่งขัน ImageNet ปี 2014 GoogLeNet มีคุณสมบัติที่น่าสนใจคือการใช้ Inception module ซึ่งประกอบด้วย Convolutional Layer, Pooling Layer, และ Concatenation Layer ที่ทำให้สามารถสกัดคุณลักษณะของภาพได้อย่างเหมาะสม ซึ่งในส่วนของ Inception Module เป็นโครงสร้างหลายชั้นที่มีการใช้งาน Convolutional Layer แบบต่าง ๆ ในขณะเดียวกัน และรวมผลลัพธ์ของชั้นต่าง ๆ เข้าด้วยกันด้วยการเชื่อมต่อแบบ Concatenation เพื่อประกอบภาพผลลัพธ์ที่ได้รับข้อมูลจากทุกชั้น ซึ่งช่วยลดจำนวนพารามิเตอร์ในโมเดลได้และเพิ่มประสิทธิภาพในการคำนวณ การใช้ Pooling Layer นั้น GoogLeNet ใช้ Pooling Layer แบบ Average Pooling หลังจาก Inception Module เพื่อลดขนาดของภาพ และลดความซับซ้อนของโมเดล ในส่วนของ Convolutional Layer ใช้ 1×1 Convolution เพื่อลดความลึกของ Feature Map และลดจำนวนพารามิเตอร์ในโมเดล ซึ่งช่วยลดความซับซ้อนและเพิ่มประสิทธิภาพในการคำนวณ

กระบวนการทำงานของอัลกอริทึม GoogLeNet (หรือ Inception) เป็นการนำเสนอกระบวนการใหม่ ในการออกแบบโครงสร้างของโครงข่ายประสาทเชิงลึก (Deep Neural Network) ที่ใช้งานประมวลผลภาพ โดยมีลักษณะหลักดังนี้

1) สถาปัตยกรรม GoogLeNet มีโครงสร้างที่ลึกและกว้าง ประกอบด้วยหลาย ๆ ชั้นคอนโวลูชัน (Convolutional Layer) ที่มีความลึกต่าง ๆ และช่องทาง (channel) ของคุณลักษณะต่าง ๆ


2) Inception เป็นส่วนประกอบหลักของโมเดล เป็นการเชื่อมต่อหลาย ๆ การกระตุ้น (convolutional branch) ขนาดต่าง ๆ อย่างขนาด 1×1 , 3×3 , 5×5 , และการประมวลผลสูงสุด (max pooling branch) โดยใช้การเชื่อมต่อความลึก (depth-wise concatenation) เพื่อสร้างคุณลักษณะที่มีรายละเอียดต่าง ๆ

3) Reduction Layer เป็นชั้นในการลดขนาดของข้อมูลและจำนวนช่องทาง (channel) ของคุณลักษณะ โมเดล GoogLeNet มีชั้นการลดขนาดเพื่อป้องกันปัญหาการคำนวณที่ซับซ้อน โดยใช้การประมวลผลสูงสุด และการลดขนาดโดยใช้คอนโวลูชันขนาด 1×1

4) Auxiliary Classifiers เป็นเลเยอร์ที่ช่วยในการฝึกสอนและเพิ่มประสิทธิภาพของโมเดล โมเดล GoogLeNet มีชั้นช่วยในการจำแนกที่ตั้งอยู่ในส่วนกลางของโครงสร้าง เพื่อนำผลลัพธ์ระหว่างการประมวลผลในช่วงกลางของโมเดลมาใช้ในการจำแนก

5) Global Average Pooling โมเดล GoogLeNet ใช้เทคนิค Global Average Pooling เพื่อลดขนาดของข้อมูล โดยทำการเฉลี่ยคุณลักษณะในทุก ๆ พิกเซลของแผนภาพ ในที่นี้จะเป็นการลดมิติของข้อมูลและแปลงเป็นเวกเตอร์คุณลักษณะที่มีขนาดคงที่

6) Softmax Layer เป็นเลเยอร์สุดท้ายของโมเดล ใช้ในการคำนวณความน่าจะเป็นของแต่ละคลาสในการจำแนกภาพ



ภาพประกอบ 17 หลักการของ Inception Modules ที่เป็นส่วนสำคัญของ GoogLeNet [11]

2.5 การวัดประสิทธิภาพของโมเดล (Performance Measurement)

Classification [12], [35], [38], [39] เป็นการวัดประสิทธิภาพของโมเดลหรือแบบจำลองที่สร้างขึ้น ซึ่งโมเดลหรือแบบจำลองที่สร้างขึ้นนั้นจำเป็นต้องวัดความสามารถในการทำนายหรือจำแนกกลุ่มของข้อมูล ที่ไม่ได้ใช้ในกระบวนการฝึกแบบจำลอง ที่อยู่ในชุดทดสอบ (Test Set) โดยทั่วไปแล้วเราใช้หลักการของการวัดประสิทธิภาพโดยใช้เมตริกหรือตัวชี้วัดเพื่อประเมินประสิทธิภาพ ซึ่งสามารถแยกแยะความแม่นยำในการทำนายที่ถูกต้องและไม่ถูกต้องของแบบจำลองได้ การจำแนกนั้นมีหลายวิธีที่ใช้ในการวัดประสิทธิภาพ เช่น อัตราการตรวจจับถูกต้อง (True Positive Rate, Recall) อัตราการจำแนกผิดพลาด (False Positive Rate) โดยทั่วไปผลลัพธ์ที่ได้นั้นจะจัดอยู่ในรูปแบบของตาราง Confusion Matrix ซึ่งเป็นการวัดผลตามลักษณะจริงที่ได้จำแนกถูกต้องไว้แล้วและสรุปผลการจำแนกจากการทำนายด้วยอัลกอริทึมหรือเทคนิคต่าง ๆ ที่นำมาใช้งาน ดังตาราง 2 ซึ่งในการวิจัยนี้ก็จะใช้วิธีการวัดประสิทธิภาพดังกล่าวนี้ในการทดสอบประสิทธิภาพของโมเดล

ตาราง 2 แสดงตาราง Confusion Matrix

Predicted/actual	Yes	No
Yes	TN	FP
No	FN	TP

จากตารางอธิบายตัวแปรได้ คือ

TN คือผลการจำแนกถูกต้องเมื่อข้อมูลเป็น Yes (True Negative)

FP คือผลการจำแนกผิดพลาดเมื่อข้อมูลเป็น Yes (False Positive)

FN คือผลการจำแนกผิดพลาดเมื่อข้อมูลเป็น No (False Negative)

TP คือผลการจำแนกถูกต้องเมื่อข้อมูลเป็น No (True Positive)

ซึ่งค่าจากตาราง Confusion Matrix สามารถนำมาคำนวณเพื่อวัดประสิทธิภาพในการจำแนกผลการทำนายความแม่นยำของโมเดล คือการวัดความถูกต้องของแบบจำลอง ซึ่งกำหนดเป็นอัตราส่วนระหว่างจำนวนการคาดการณ์ที่ถูกต้องและจำนวนการคาดการณ์ทั้งหมด ได้ดังนี้

1) Accuracy คือ ค่าความถูกต้องของการจำแนก สัดส่วนของผลการทำนายที่ถูกต้องจากข้อมูลภาพทั้งหมดที่ใช้ในการทดสอบ คำนวณได้ดังสมการ 2.1

$$Accuracy = \frac{TP+TN}{TN+FN+FP+TP} \quad (2.1)$$

2) Recall คือ อัตราการจำแนกถูกต้องเมื่อข้อมูลเป็นจริง เป็นสัดส่วนของผลการจำแนกกลุ่มได้ถูกต้อง ซึ่งค่า Recall นี้เป็นการวัดประสิทธิภาพเพื่อบ่งบอกว่าสามารถวิเคราะห์ภาพได้ถูกต้องมากน้อยแค่ไหน ซึ่งคำนวณได้จากสมการ 2.2

$$Recall = \frac{TP}{TP+FN} \quad (2.2)$$

3) Precision คือ ค่าความแม่นยำของโมเดล โดยพิจารณาแยกทีละคลาส คำนวณได้จากสมการ 2.3

$$Precision = \frac{TP}{TP+FP} \quad (2.3)$$

4) F1 score คือ ค่าเฉลี่ยแบบ harmonic mean มีหลักการคำนวณแบบ single metric เพื่อคำนวณความสมดุลระหว่างค่า precision และ recall ดังสมการ 2.4

$$F1 \text{ Score} = \frac{2x(Precision \times Recall)}{Precision+Recall} \quad (2.4)$$

5) การหาค่า average f1-scores ด้วยวิธี Macro-average method

$$\text{Macro F1 Score} = \frac{\sum_{i=1}^n \text{F1 Score}_i}{n} \quad (2.5)$$

2.6 เกษตรอัจฉริยะ (Smart Farming)

เกษตรอัจฉริยะ (Smart Farming) [40], [41] เป็นแนวคิดและการประยุกต์ใช้เทคโนโลยีในการพัฒนาและดูแลการเกษตรเพื่อเพิ่มประสิทธิภาพและยั่งยืนในการผลิตอาหาร โดยการใช้ข้อมูลและการวิเคราะห์ข้อมูลที่เป็นระบบ เพื่อช่วยให้การบริหารจัดการและการผลิตในเกษตรกรรมเป็นไปอย่างมีประสิทธิภาพ และยั่งยืน นอกจากนี้ เกษตรอัจฉริยะยังเน้นการใช้เทคโนโลยีที่เป็นมิตรต่อสิ่งแวดล้อมและการอนุรักษ์ทรัพยากรธรรมชาติ ซึ่งการประยุกต์ใช้เทคโนโลยีในเกษตรอัจฉริยะนั้นมีหลายแง่มุมหมาย เช่น การใช้เซ็นเซอร์ตรวจวัดสภาพแวดล้อม เพื่อควบคุมและปรับการให้น้ำและปุ๋ยให้ตรงตามความต้องการของพืช ระบบเฝ้าระวังโรคและแมลงศัตรูพืชด้วยระบบอัตโนมัติ การใช้ระบบอินเทอร์เน็ตของสรรพสิ่ง (IoT) เพื่อติดตามและควบคุมระบบการผลิตในเวลาจริง การใช้ระบบประมวลผลภาพและปัญญาประดิษฐ์เพื่อตรวจสอบสภาพของพื้นที่เพาะปลูก และการตรวจสอบสุขภาพของพืชและสัตว์เลี้ยง รวมถึงการใช้ระบบหุ่นยนต์และอุปกรณ์อัตโนมัติในกระบวนการเก็บเกี่ยวผลผลิต เพื่อลดการใช้แรงงานและเพิ่มประสิทธิภาพในการผลิต

การประยุกต์ใช้เกษตรอัจฉริยะมีความสำคัญอย่างมากในการเพิ่มผลผลิตในเกษตรกรรม ลดการใช้สารเคมีและทรัพยากรธรรมชาติ ลดความสูญเสียในการผลิต ป้องกันการระบาดของโรคและศัตรูพืช ลดการใช้น้ำและพลังงานในกระบวนการผลิต และเพิ่มประสิทธิภาพในการจัดการสิ่งแวดล้อม นอกจากนี้ เกษตรอัจฉริยะยังช่วยให้เกษตรกรมีความเข้าข่ายกับตลาดและผู้บริโภคได้อย่างเหมาะสม และสามารถตอบสนองต่อความต้องการของตลาดได้อย่างรวดเร็ว อย่างไรก็ตาม เพื่อให้เกิดการเปลี่ยนแปลงในเกษตรกรรมใหญ่ที่ยั่งยืน การประยุกต์ใช้เทคโนโลยีในเกษตรอัจฉริยะควรรับรู้ถึงความต้องการและประสิทธิภาพของเทคโนโลยี พร้อมทั้งให้การสนับสนุนทางเทคนิคและการฝึกอบรมให้แก่เกษตรกร และต้องพิจารณาเรื่องความเป็นส่วนตัวและความปลอดภัยของข้อมูลที่เกี่ยวข้องกับการประยุกต์ใช้เทคโนโลยีในเกษตรอัจฉริยะ

ในบริบทของประเทศไทย เกษตรอัจฉริยะ [42], [43] กลายเป็นแนวทางที่สำคัญในการแก้ไขปัญหาทางเกษตรและอาหารของประเทศ โดยเฉพาะอย่างยิ่งเมื่อพบว่าเกษตรกรที่เป็นไปในรูปแบบที่เก่าแก่ไม่สามารถตอบสนองความต้องการเพิ่มขึ้นของประชากรได้ และการเผชิญหน้ากับปัญหาที่เกี่ยวข้องกับการเปลี่ยนแปลงสภาพภูมิอากาศที่ทำให้เกิดสภาวะภัยและการเสื่อมโทรมทางดินและทรัพยากรธรรมชาติ เกษตรอัจฉริยะในประเทศไทยมุ่งเน้นการใช้เทคโนโลยีและนวัตกรรมที่สอดคล้อง


กับสภาวะภูมิอากาศและระบบทรัพยากรธรรมชาติที่จำกัด ซึ่งมีการปรับใช้ทั้งในการผลิตพืชและสัตว์ เพื่อให้สามารถทำเกษตรได้อย่างมีประสิทธิภาพและยั่งยืน ตัวอย่างเทคโนโลยีและนวัตกรรมที่มีการใช้งานในเกษตรอัจฉริยะของไทย ได้แก่

1) ระบบการเพาะเลี้ยงแบบอัตโนมัติ เป็นการใช้เทคโนโลยีอัตโนมัติเช่น การควบคุมอุณหภูมิ และการให้ปุ๋ยในระบบเพาะเลี้ยงพืชแบบปิดเพื่อเพิ่มประสิทธิภาพในการผลิตพืชและลดการใช้น้ำและปุ๋ยที่ต้องใช้

2) การใช้สมาร์ทฟาร์มและเทคโนโลยี IoT เป็นการนำเอาเทคโนโลยีอินเทอร์เน็ตของสรรพสิ่ง (IoT) มาใช้ในการควบคุมและจัดการฟาร์มให้สามารถตรวจสอบสภาพแวดล้อม เช่น อุณหภูมิ ความชื้น ระดับน้ำ และสถานะของสัตว์ผ่านอุปกรณ์สมาร์ทฟาร์ม ทำให้เกษตรกรสามารถปรับปรุงและประหยัดทรัพยากรได้อย่างมีประสิทธิภาพ

3) การนำเทคโนโลยีหุ่นยนต์มาใช้ในการเก็บเกี่ยวและดูแลพืช เป็นการใช้หุ่นยนต์สำหรับการเก็บเกี่ยวและปลูกพืช เช่น หุ่นยนต์ตัดหญ้า หุ่นยนต์ในการรดน้ำ หรือหุ่นยนต์ที่ช่วยในกระบวนการปลูกปรับปรุงคุณภาพดิน สามารถลดความเสี่ยงและอำนวยความสะดวกให้แก่เกษตรกร

เกษตรอัจฉริยะ [4] ในประเทศไทยมีการรับรองและสนับสนุนจากหน่วยงานราชการและองค์กรที่เกี่ยวข้อง เช่น กรมวิชาการเกษตร กระทรวงเกษตรและสหกรณ์ และมีการสร้างศูนย์วิจัยและศูนย์นวัตกรรมทางการเกษตรเพื่อส่งเสริมให้เกษตรกรได้รับทราบและใช้เทคโนโลยีและนวัตกรรมในการปรับปรุงการผลิตอาหารในประเทศไทยอย่างเหมาะสมและมีประสิทธิภาพ ซึ่งได้กำหนดแผนยุทธศาสตร์เกษตรและสหกรณ์ ระยะ 20 ปี (พ.ศ.2560-2579) ดังภาพประกอบ 18 และยังมีแผนปฏิบัติการเกษตรอัจฉริยะ 2565 – 2566 ดังภาพประกอบ 19 ที่กระทรวงเกษตรและสหกรณ์ได้จัดทำขึ้น ซึ่งจะเป็นแผนปฏิบัติการที่ช่วยกำหนดทิศทางการเกษตรอัจฉริยะและเป็นการวางรากฐานการเกษตรอัจฉริยะของประเทศอย่างเป็นระบบ โดยหน่วยงานที่เกี่ยวข้องของกระทรวงเกษตรและสหกรณ์ และหน่วยงานอื่น ๆ ทั้งภาครัฐ ภาคเอกชน และเกษตรกร สามารถนำกรอบข้อเสนอโครงการที่จัดทำไว้ ภายใต้แผนปฏิบัติการเกษตรอัจฉริยะฉบับนี้ไปปรับใช้เป็นข้อเสนอโครงการในหน่วยงาน เพื่อขับเคลื่อนการเกษตรอัจฉริยะของประเทศ โดยมุ่งเน้นทั้ง Smart Farmer และ Young Smart Farmer ตลอดจนผู้นำเกษตรกรของ ศพก. และแปลงใหญ่ ทั้งนี้ มุ่งหวังให้เกิดการพัฒนาแปลงใหญ่เกษตรอัจฉริยะให้เกิดขึ้นเป็นรูปธรรมในทุก ๆ จังหวัดของประเทศ และให้เข้าถึงทุกอำเภอภายใน 3 ปี เพื่อให้เกิดผลอย่างเป็นรูปธรรม ตามเป้าหมายของยุทธศาสตร์ชาติด้านการเกษตรต่อไป



ภาพประกอบ 18 แผนยุทธศาสตร์เกษตรและสหกรณ์ ระยะ 20 ปี (พ.ศ.2560-2579) [4]



ภาพประกอบ 19 แผนปฏิบัติการเกษตรอัจฉริยะ 2565-2566 [44]

จากแผนยุทธศาสตร์การพัฒนากลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง [4] ซึ่งประกอบด้วยจังหวัดกาฬสินธุ์ ขอนแก่น ร้อยเอ็ด และมหาสารคาม ได้กำหนดเป้าหมายร่วมกันในระยะเวลา 20 ปี (พ.ศ.2560-2579) ที่มุ่งเน้นทำให้รายได้ประชากรต่อหัวต่อปีของกลุ่มจังหวัดหลุดพ้นจาก

กับดักรายได้ปานกลาง (Middle Income Trap: MIT) โดยยุทธศาสตร์ที่ 4 เป็นการส่งเสริมและยกระดับด้านเกษตรและอุตสาหกรรมเกษตรที่มีมูลค่าสูง (Smart Agriculture) โดยเน้นการนำเทคโนโลยีและนวัตกรรมมาประยุกต์ใช้ในการพัฒนาการเกษตร เพื่อเพิ่มผลผลิตและมูลค่าของสินค้าทางการเกษตรและอุตสาหกรรมเกษตร การวิจัยนี้ได้นำเสนอเรื่องที่เกี่ยวข้องกับการนำเทคโนโลยีและนวัตกรรมมาประยุกต์ใช้ในการเกษตร โดยมุ่งเน้นในการศึกษาและวิจัยเกี่ยวกับวิธีการใช้เทคโนโลยีในการพัฒนาการเกษตรอัจฉริยะ (Smart Agriculture) เพื่อเพิ่มผลผลิตและมูลค่าของสินค้าทางการเกษตรและอุตสาหกรรมเกษตร การศึกษาวิจัยนี้จะเป็นประโยชน์ในการเสริมสร้างความเข้าใจและความรู้ในการนำเทคโนโลยีเข้ามาใช้ในการพัฒนาและยกระดับเกษตรภายในกลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง

และจากความต้องการหรือข้อเสนอเชิงนโยบาย และยังเป็นการสอดคล้องกับความต้องการในพื้นที่กลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง ในการวิจัยเพื่อการพัฒนาเกษตรกรรมแนวใหม่ให้กับภาคเกษตรกรรมในพื้นที่ ดังภาพประกอบ ในการนำเทคโนโลยีสมัยใหม่มาช่วยเพิ่มประสิทธิภาพและประสิทธิผลในการทำเกษตรกรรม เพื่อเป็นการตอบโจทย์ในการพัฒนาส่งเสริมประชากรในพื้นที่ให้มีความเป็นอยู่อย่างยั่งยืน

7

ประเด็น

งานวิจัยที่พื้นที่ต้องการเพิ่มเติม

เพื่อตอบสนองต่อปัญหาสำคัญ





มิติเศรษฐกิจ

1).งานวิจัยเพื่อการพัฒนาเกษตรกรรมแนวใหม่ที่เพิ่มมูลค่าให้กับภาคการเกษตรในพื้นที่ โดยเฉพาะการนำเทคโนโลยีสมัยใหม่มาช่วยเพิ่มประสิทธิภาพและประสิทธิผลในการทำเกษตรกรรมให้กับเกษตรกร [SDG2, SDG8]

2).งานวิจัยเพื่อพัฒนาต้นแบบเศรษฐกิจหมุนเวียน เศรษฐกิจชีวภาพ และ เศรษฐกิจสีเขียว (bio circular economy) สำหรับบริบทภาคตะวันออกเฉียงเหนือ [SDG8, SDG12]

3).งานวิจัยด้านเศรษฐกิจฐานรากซึ่งมีชุมชนเป็นตัวหลักในการขับเคลื่อนวงจรของเศรษฐกิจท้องถิ่นเพื่อยกระดับเศรษฐกิจชุมชนให้ดีขึ้น [SDG8]

มิติสังคม

1).งานวิจัยเพื่อการพัฒนาศักยภาพทรัพยากรมนุษย์ทุกช่วงวัย ในบริบทของภาคตะวันออกเฉียงเหนือ [SDG4]

2).งานวิจัยเพื่อลดความเหลื่อมล้ำทางการศึกษาของภาคตะวันออกเฉียงเหนือ ในมิติต่าง ๆ อย่างรอบด้าน [SDG4, SDG10]

3).งานวิจัยเพื่อหาทางออกของปัญหาสังคมที่เกิดจากเงื่อนไขครอบครัว เช่น ปัญหาท้องไม่พร้อม คุณแม่วัยใส [SDG3, SDG5]

มิติสิ่งแวดล้อม

1).งานวิจัยด้านการเปลี่ยนแปลงของสภาพภูมิอากาศ (climate change) ผลกระทบที่เกิดขึ้นกับพื้นที่ภาคตะวันออกเฉียงเหนือ และการตั้งรับปรับตัวกับสถานการณ์ที่เกิดขึ้นโดยเฉพาะกับภาคเกษตรกรรม [SDG2, SDG13]

ภาพประกอบ 20 งานวิจัยที่ต้องการเพิ่มเติมในพื้นที่กลุ่มภาคตะวันออกเฉียงเหนือตอนกลาง [4]

2.7 ไลน์แชทบอท (LINE Chatbot)

แชทบอท (Chatbot) [16], [17] คือ โปรแกรมคอมพิวเตอร์ที่ใช้เทคโนโลยีปัญญาประดิษฐ์ในการสื่อสารและตอบสนองต่อคำถามหรือสถานการณ์เหมือนกับมนุษย์ โดยใช้ข้อความ ภาพ หรือเสียง มักนำไปใช้ในการบริการลูกค้า การแพทย์ การศึกษา และอื่น ๆ โดยการเรียนรู้และปรับปรุงตัวเองจากข้อมูลที่ได้รับมาเป็นสิ่งสำคัญในการพัฒนาโปรแกรมนี้ แชทบอทสามารถโต้ตอบได้แบบ Real Time และตอบกลับได้แบบอัตโนมัติ

ไลน์แชทบอท (LINE Chatbot) เป็นการส่งข้อความ และโต้ตอบกับแชทบอท ดำเนินการผ่าน Line Messaging API มี 2 รูปแบบ ได้แก่ Push Messaging คือ การส่งข้อความจากแชทบอทไปยังผู้ใช้งาน และ Reply Message คือ การโต้ตอบจริงๆ ระหว่างผู้ใช้งานกับแชทบอท สามารถเป็นได้ทั้ง ข้อความ รูปภาพ สติกเกอร์ เสียง และอื่นๆ ซึ่งในงานวิจัยนี้จะให้บริการ Line Chatbot เพื่อพัฒนาเป็นระบบวิเคราะห์ตรวจสอบโรคอ้อยแบบอัตโนมัติ จากรูปภาพใบอ้อยที่ส่งมายัง LINE Official Account ของผู้วิจัยที่ได้สร้างบัญชีนี้ขึ้นมาเพื่อพัฒนาเป็นระบบดังกล่าว

LINE Messaging API [45] เป็นบริการที่ LINE เปิดให้ใช้บริการ รับ-ส่ง ข้อมูลจากแอปพลิเคชัน LINE โดยข้อมูลที่ใช้ในการรับ-ส่ง ตามข้อกำหนดของ คืออยู่ในรูปแบบเอกสาร JSON ซึ่งทำหน้าที่เป็นตัวกลางในการเชื่อมต่อ Server เข้ากับ LINE Official Account ผู้ใช้บริการสามารถพัฒนาโปรแกรมเพื่อรับส่งข้อมูลที่ส่งเข้ามายัง LINE แล้วนำไปประมวลผลต่อ จึงเหมาะกับการนำไปประยุกต์ใช้กับการทำงานของ Chatbot ที่จะรับข้อความจากผู้ใช้งานได้ทันทีที่ผู้ใช้งานส่งข้อความเข้ามา และสามารถตอบกลับได้หลายรูปแบบ เช่น ข้อความตัวอักษร สติกเกอร์ รูปภาพ วิดีโอ ไฟล์เสียง โลเคชั่น เป็นต้น โดยบริการ Messaging API เซิร์ฟเวอร์บอทสามารถส่งและรับข้อมูลเข้าและออกจากแพลตฟอร์ม LINE ได้ คำขอจะถูกส่งผ่าน HTTPS ใน JSON ขั้นตอนการสื่อสารระหว่างบอทเซิร์ฟเวอร์และแพลตฟอร์ม LINE คือ ผู้ใช้ส่งข้อความไปยังบัญชีทางการของ LINE แพลตฟอร์ม LINE จะส่งเหตุการณ์ webhook ไปยัง URL ของ webhook ของเซิร์ฟเวอร์บอท และเซิร์ฟเวอร์บอทจะตรวจสอบเหตุการณ์ webhook และตอบสนองต่อผู้ใช้งานผ่านแพลตฟอร์ม LINE ดังภาพประกอบ 21



ภาพประกอบ 21 Messaging API overview

2.8 งานวิจัยที่เกี่ยวข้อง (Literature Review)

อุมารณ สายแสงจันทร์ และคณะ [35] ได้ศึกษาวิธีการวิเคราะห์ความเป็นโรคจากใบมะนาว โดยอาศัยการเรียนรู้เชิงลึก โดยเทคนิคที่ใช้คือการจำแนกใบมะนาวโดยใช้คอนโวลูชันนิวรอลเน็ตเวิร์ค ซึ่งสถาปัตยกรรมที่ศึกษาในที่นี้ ได้แก่ LeNet-5 VGG16 ResNet-50 และสถาปัตยกรรมที่นำเสนอ บนพื้นฐานของ VGGNet โดยการปรับปรุง Hyperparameter การปรับปรุงสถาปัตยกรรมนี้เป็นการลดขนาดของชั้นการเรียนรู้ และช่วยลดจำนวนพารามิเตอร์ของโครงข่าย ซึ่งจะทำให้การประมวลผลเร็วขึ้นแต่ประสิทธิภาพยังคงเดิม จากการทดลองเก็บรวบรวมข้อมูลภาพถ่ายใบมะนาวเดี่ยว จำนวน 5,710 ภาพ เป็นภาพสี RGB โดยแบ่งเป็นใบมะนาวที่เป็นโรคและไม่เป็นโรคเท่ากัน และทำการแบ่งชุดข้อมูลเป็นชุดสอนร้อยละ 80 และชุดทดสอบร้อยละ 20 พบว่าประสิทธิภาพการวิเคราะห์ด้วย LeNet-5 มีความถูกต้องร้อยละ 78.90 ซึ่งมีประสิทธิภาพต่ำสุด ในขณะที่สถาปัตยกรรมที่นำเสนอมีความถูกต้องร้อยละ 89.06 ซึ่งมีค่าสูงสุด แต่ไม่แตกต่างกับ ResNet-50 มากนัก

เตชินท์ วรสิทธิ์ และคณะ [46] ได้ประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกสำหรับการรู้จำโรคขอบใบแห้งและโรคไหม้ของข้าวและพัฒนาระบบจำแนกชนิดโรคทั้งสองจากภาพถ่าย อาการของโรคในสภาพแปลงนา ผลการทดสอบพบว่าเทคนิคการเรียนรู้เชิงลึก YOLOv3 มีประสิทธิภาพสูงสุดในการรู้จำโรคทั้งสอง ซึ่งมีค่าเฉลี่ยความถูกต้องในการจำแนกของโรคขอบใบแห้งและโรคไหม้อยู่ที่ 90.33% และ 86.46% ตามลำดับ อย่างไรก็ตามเมื่อทวนสอบความถูกต้องของระบบที่พัฒนาขึ้นกับภาพถ่ายที่ไม่เคยนำมาใช้ในการพัฒนาระบบ พบว่าความถูกต้องในการจำแนกโรคขอบใบแห้งและโรคไหม้ลดลงเหลือ 87.5% และ 74.0% ตามลำดับ การศึกษานี้มีค่าเฉลี่ยความถูกต้องของระบบ (mean average precision ,mAP) ในการวินิจฉัยทั้งสองโรคอยู่ที่ 79.19% เมื่อเทียบกับงานวิจัยก่อนหน้านี้ ถือว่า YOLOv3 มีประสิทธิภาพสูงกว่าในการวินิจฉัยภาพอาการของโรคในสภาพแปลงนา และพบว่าหากเพิ่มชนิดโรคในการพัฒนาระบบจะทำให้ค่าความถูกต้องเฉลี่ยของระบบรู้จำลดน้อยลง ซึ่งเป็นผลมาจากคุณภาพของภาพถ่ายลักษณะอาการ รวมถึงความคล้ายกันของลักษณะอาการในหลาย ๆ โรค งานวิจัยนี้แสดงให้เห็นถึงความสำเร็จในการพัฒนาระบบรู้จำด้วยเทคนิคการเรียนรู้เชิงลึกในการจำแนกชนิดของโรคข้าวด้วยภาพที่มีความถูกต้อง ซึ่งจะนำมาพัฒนาแอปพลิเคชันในโทรศัพท์มือถือในการจำแนกโรคข้าวด้วยภาพถ่ายควบคู่กับคำแนะนำจากนักโรคพืชที่จะรองรับการใช้งานจริงของเกษตรกรได้อย่างรวดเร็วมีประสิทธิภาพทันต่อการระบาดของโรค

ธนภัทร มัชวาท และคณะ [47] ได้พัฒนาเว็บแอปพลิเคชันเพื่อจำแนกกล้วยต่างด้วยเทคนิคการเรียนรู้ของเครื่อง โดยได้นำเทคนิคการเรียนรู้ของเครื่องแบบการเรียนรู้เชิงลึกด้วยอัลกอริทึมคอนโวลูชันนิวรอนเน็ตเวิร์ค มาพัฒนาแบบจำลองการจำแนกและหาความสัมพันธ์ของกล้วยต่าง โดยมีวัตถุประสงค์เพื่อ 1) หาแบบจำลองการเรียนรู้ของเครื่อง (Model of Machine Learning) มา

ประยุกต์ใช้กับการจำแนกสายพันธุ์กล้วยต่าง 2) พัฒนาเว็บแอปพลิเคชันเพื่อจำแนกกล้วยต่างด้วยเทคนิคการเรียนรู้ของเครื่อง และ 3) หาประสิทธิภาพด้านความด้านความถูกต้องของแบบจำลองการเรียนรู้ ได้ดำเนินการเก็บรวบรวมข้อมูลภาพใบกล้วยต่างจากฐานข้อมูลขององค์การสวนพฤกษศาสตร์จำนวน 5 สายพันธุ์ ได้แก่ 1) กล้วยฟอรัดต่าง 2) กล้วยน้ำหว้าต่าง 3) กล้วยตานีต่าง 4) กล้วยเทพพนมต่าง และ 5) กล้วยแดงอินโดต่าง โดยแบ่งชุดข้อมูลสำหรับการสอนร้อยละ 70 และข้อมูลสำหรับทดสอบร้อยละ 30 จากนั้นใช้วิธีการเรียนรู้เชิงลึกด้วยอัลกอริทึมคอนโวลูชันนิวรอนเน็ตเวิร์คในการประมวลผลภาพเพื่อสร้างแบบจำลอง แล้วนำไปพัฒนาเว็บแอปพลิเคชันด้วยภาษาไพธอน โดยการวิจัยพบว่า 1) ได้แบบจำลองการเรียนรู้ของเครื่อง (Model of Machine Learning) มาประยุกต์ใช้กับการจำแนกสายพันธุ์กล้วยต่าง และ 2) ประสิทธิภาพด้านความด้านความถูกต้องของแบบจำลองการเรียนรู้ วัดด้วยวิธี F1 score ได้รับค่าความถูกต้องสูงสุดที่ 83.00

ศรัญญา กาญจนวัฒนา และคณะ [48] ได้พัฒนาวิธีการจำแนกระดับความหวานของสับปะรดโดยพิจารณาจากลักษณะทางกายภาพที่ปรากฏให้เห็นบนรูปภาพด้วยวิธีการวิเคราะห์ทางการเรียนรู้เชิงลึกชื่อว่า AlexNet ซึ่งทำงานร่วมกับข้อมูลรูปภาพสับปะรดที่มีผลสีเหลือง ได้ทำการแบ่งข้อมูลออกเป็น 4 คลาส ตั้งแต่ M1 ถึง M4 เรียงตามระดับความหวานจากน้อยไปมาก และแบ่งข้อมูลออกเป็นข้อมูลฝึกสอนร้อยละ 80 และข้อมูลทดสอบร้อยละ 20 การทดลองในงานวิจัยนี้แบ่งออกเป็น 5 การทดลองที่มีจำนวน epoch ต่างกันทำงานร่วมกับข้อมูลที่เตรียมไว้ จากผลการทดลองสามารถสรุปได้ว่าโมเดล AlexNet ที่ให้ผลลัพธ์ที่ดีที่สุดคือโมเดลที่มีการฝึกสอน 10 epoch ทำงานร่วมกับข้อมูลที่สมดุลและมีขนาด 120 รูปต่อคลาสโมเดลสามารถให้ความถูกต้อง 91.78% และได้ค่า F1 score อยู่ที่ 92.31%

พิจิตรา จอมศรี และคณะ [49] ได้พัฒนาระบบตรวจวินิจฉัยโรคใบของดาวเรืองด้วยเทคโนโลยีไอโอทีเพื่อรองรับการเป็นเกษตรอัจฉริยะ โดยได้พัฒนาอัลกอริทึมสำหรับตรวจวินิจฉัยโรคใบของดาวเรืองด้วยเทคโนโลยีไอโอที และเพิ่มประสิทธิภาพการพิจารณาโรคใบจุดด้วยเทคโนโลยีไอโอที ซึ่งเป็นการตรวจวัดและประเมินผลการระบาดของโรคพืชเพื่อป้องกันผลผลิตลดลงได้เป็นอย่างดี โดยใช้ข้อมูลภาพถ่าย และได้นำเทคนิคซัพพอร์ตเวกเตอร์แมชชีนมาช่วยในการพิจารณาโรคใบจุดดาวเรือง ทั้งนี้ในการทดสอบประสิทธิภาพโมเดล พบว่าเทคนิคซัพพอร์ตเวกเตอร์แมชชีนให้ผลลัพธ์ที่ 86 เปอร์เซ็นต์ นอกจากนี้ผลการประเมินความพึงพอใจต่อเทคนิคการวินิจฉัยโรคใบจุดของดาวเรืองด้วยเทคโนโลยีไอโอทีจากเกษตรกรกลุ่มตัวอย่างจำนวน 30 คน ได้ระดับความพึงพอใจในระดับมากที่สุด ที่ระดับค่าเฉลี่ย 4.46 ค่าส่วนเบี่ยงเบนมาตรฐานเท่ากับ 0.53 รวมทั้งผลการทดสอบประสิทธิภาพการวินิจฉัยโรคใบจุดก่อนและหลังมีการใช้งานระบบไอโอที พบว่ามีความแตกต่างอย่างมีนัยสำคัญ ดังนั้นเทคนิคการวินิจฉัยโรคใบของดาวเรืองด้วยเทคโนโลยีไอโอที สามารถสนับสนุนเกษตรกรด้านการตรวจเช็คโรคของใบได้อย่างมีประสิทธิภาพ

จักรินทร์ สุนุกแสน และคณะ [50] ได้ศึกษาโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึก (Deep Convolutional Neural Network: Deep CNN) เพื่อใช้จำแนกพรรณไม้ที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ โดยมีจุดประสงค์เพื่อเปรียบเทียบ โครงข่ายประสาทเทียมแบบคอนโวลูชัน จำนวน 4 โครงสร้าง ประกอบด้วย LeNet-5, AlexNet, GoogLeNet และ VGGNet ข้อมูลพรรณไม้ที่นำมาใช้ในการทดสอบมีจำนวนทั้งสิ้น 3 ชุดข้อมูลคือ PNE, 102 Flower และ Folio ทั้งนี้ชุดข้อมูล PNE และ 102 Flower เป็นรูปภาพที่อยู่ในสิ่งแวดล้อมทางธรรมชาติทำให้ที่มีพื้นหลังที่ซับซ้อน สำหรับข้อมูลชุด Folio เป็นรูปภาพใบไม้ที่ถ่ายในห้องทดลองโดยกำหนดให้พื้นหลังของภาพเป็นสีขาว จากผลเปรียบเทียบระหว่างโครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกโดยใช้โครงสร้าง GoogLeNet และ VGGNet พบว่าโครงสร้างแบบ GoogLeNet มีประสิทธิภาพสูงที่สุดในชุดข้อมูล PNE และ 102 Flower และยังใช้เวลาในการเรียนรู้ที่เร็วกว่าเมื่อเทียบกับโครงสร้างแบบ VGGNet โดยใช้จำนวนรอบในการเรียนรู้ 10,000 รอบ แต่ทั้งนี้โครงสร้างแบบ VGGNet มีอัตราความถูกต้องสูงที่สุดในชุดข้อมูล Folio ซึ่งเป็นรูปภาพที่ถ่ายในห้องทดลองที่มีพื้นหลังเป็นสีขาว และใช้จำนวนรอบในการเรียนรู้เพียง 1,000 รอบ จึงสรุปได้ว่าหากต้องการที่จะสร้างโมเดลเพื่อนำไปใช้ในการจำแนกพรรณไม้ที่อยู่ในสิ่งแวดล้อมทางธรรมชาติควรจะใช้โครงสร้างแบบ GoogLeNet

อภิชัย ตระหง่าศรี [17] ได้นำเสนอการพัฒนาระบบสนทนาอัตโนมัติเพื่อแสดงผลข้อมูลการเรียนรู้ผ่านไลน์แชทบอท เพื่อหาประสิทธิภาพของระบบ และหาความพึงพอใจของนักศึกษาที่มีต่อระบบสนทนาอัตโนมัติ โดยได้นำเทคโนโลยี LINE Messaging API, Google Chat API และ Google Apps Script ประยุกต์ใช้งานกับการประมวลผลภาษาธรรมชาติ เก็บข้อมูลลงใน Google Sheet เพื่อรองรับบทสนทนาของผู้ใช้ผ่านคลาวด์ กระบวนการทำงานหลักของระบบสนทนาอัตโนมัตินี้ ประกอบด้วย การสอบถามข้อมูลคะแนนงาน ข้อมูลการมาเรียน คะแนนรวม และแสดงวิดีโอการสอนย้อนหลัง ซึ่งกลุ่มตัวอย่างในงานวิจัยนี้คือ นักศึกษาในรายวิชา การประยุกต์เทคโนโลยีบิกดาต้า จำนวน 50 คน ผลการวิจัยพบว่า ระบบสนทนาอัตโนมัติเพื่อแสดงผลข้อมูลการเรียนรู้ผ่านไลน์แชทบอท ดำเนินการอย่างมีคุณภาพตามหลักการ และกระบวนการพัฒนาระบบ มีผลการประเมินประสิทธิภาพของระบบโดยผู้เชี่ยวชาญอยู่ในระดับมาก และความพึงพอใจของนักศึกษาที่มีต่อระบบอยู่ในระดับมากเช่นกัน

ศุภพงศ์ สุกุลคุ และคณะ [51] ได้นำเสนอระบบคำนวณคุณค่าโภชนาการอาหารรายบุคคลจากภาพถ่ายอาหารผ่านไลน์แชทบอท ระบบแบ่งเป็น 2 ส่วน คือ ส่วนแรกเป็นการพัฒนาตัวแบบในการรู้จำภาพอาหารไทย ผีอกสอนด้วยอัลกอริทึม YOLOv5 และ Faster RCNN ทำการเปรียบเทียบประสิทธิภาพของตัวแบบที่ฝึกสอน การฝึกสอนตัวแบบใช้ข้อมูลรูปภาพอาหารไทยจำนวนทั้งสิ้น 3,329 ภาพ แบ่งเป็น 20 คลาส พบว่า YOLOv5 ใช้เวลาในการฝึกสอนน้อยกว่า Faster RCNN เป็น 2 เท่า และด้านความถูกต้องแม่นยำของตัวแบบนั้น YOLOv5 มีค่า Averag Precision (AP) เท่ากับ

0.85 ซึ่งมากกว่าตัวแบบที่ฝึกสอนด้วย Faster RCNN ที่มีค่า AP เพียง 0.79 เท่านั้น จึงทำให้เลือกตัวแบบที่ดีที่สุดมาพัฒนาระบบคือตัวแบบที่ฝึกด้วย YOLOv5 และส่วนที่ 2 เป็นการเก็บรวบรวมข้อมูลโภชนาการวัตถุดิบด้วยภาพถ่ายอาหารจากผู้ใช้ เพื่อนำมาช่วยในการประมาณแคลอรีจากฐานข้อมูลสูตรอาหาร เพื่อหาปริมาณแคลอรีในร่างกายได้รับต่อวัน

Prem Enkvetchakul et al. [52] ได้นำเสนอระบบการจดจำโรคใบพืชโดยใช้ 2 สถาปัตยกรรม คือ MobileNetV2 และ NasNetMobile สถาปัตยกรรม CNN เหล่านี้ได้รับการออกแบบให้เหมาะกับสมาร์ตโฟน เนื่องจากมีขนาดเล็ก งานวิจัยนี้ได้ทดลองเทคนิคการ Training แบบออนไลน์ ออฟไลน์ และเทคนิคการฝึกอบรมโรคใบพืช 2 ชนิดแบบผสมผสาน สำหรับเทคนิคการเพิ่มข้อมูล พบว่าการผสมผสานระหว่างเทคนิคการหมุน การเลื่อน และการซูมเพิ่มประสิทธิภาพของสถาปัตยกรรม CNN อย่างมีนัยสำคัญ ผลการทดลองแสดงให้เห็นว่าอัลกอริทึมที่แม่นยำที่สุดสำหรับการจดจำโรคใบพืชคือสถาปัตยกรรม NASNetMobile โดยการใช้การเรียนรู้แบบ Transfer Learning นอกจากนี้ จะได้ผลลัพธ์ที่แม่นยำที่สุดเมื่อรวมเทคนิคการฝึกอบรมออฟไลน์เข้ากับเทคนิค Data Augmentation

Hammad Saleem et al. [53] ได้นำเสนอวิธีการระบุโรคพืช ด้วยเทคนิคคอมพิวเตอร์วิทัศน์ (Computer Vision) และเทคนิคการเรียนรู้เชิงลึก (Deep Learning: DL) ซึ่งใช้ 3 สถาปัตยกรรม ได้แก่ Single Shot MultiBox Detector (SSD), Faster Region-based Convolutional Neural Network (RCNN) และ Region-based Fully Convolutional Networks (RFCN) โดยใช้ TensorFlow object detection framework เพื่อใช้สอนและทดสอบโมเดล DL บนชุดข้อมูลสภาพแวดล้อมที่ควบคุม ทำการปรับปรุงความแม่นยำเฉลี่ยของแต่ละสถาปัตยกรรม deep learning ที่ดีที่สุด โดยใช้ตัวปรับปรุงการเรียนรู้ของ deep learning อันทันสมัยที่แตกต่างกัน โดยโมเดล SSD ที่ฝึกด้วยตัวปรับปรุง Adam มีค่าความแม่นยำเฉลี่ยสูงสุด (mAP) ที่ 73.07% เป็นการระบุโรคใบพืชที่มีข้อบกพร่อง 26 ชนิด และใบพืชที่เป็นปกติ 12 ชนิด ในเฟรมเวิร์กเดียว

Arsenovic et al. [54] ได้นำเสนอวิธีการเรียนรู้เชิงลึก ในการตรวจจำโรคพืช ซึ่งงานวิจัยนี้ นำเสนอข้อจำกัดและข้อบกพร่องของโมเดลตรวจจำโรคพืชที่มีอยู่ในปัจจุบัน นอกจากนี้ยังมีการนำเสนอชุดข้อมูลใหม่ที่ประกอบด้วยภาพ 79,265 ภาพ โดยมีเป้าหมายเพื่อเป็นชุดข้อมูลภาพใบไม้ที่ใหญ่ที่สุดในปัจจุบัน ภาพถ่ายถูกสร้างขึ้นในสภาพอากาศต่าง ๆ มุมมองที่แตกต่างกัน และเวลากลางวัน พร้อมกับพื้นหลังที่ไม่สม่ำเสมอเพื่อจำลองสถานการณ์ทางปฏิบัติ ในการเพิ่มจำนวนภาพในชุดข้อมูลได้ใช้วิธีการเพิ่มความหลากหลายแบบดั้งเดิมและเครือข่ายสร้างภาพที่ทันสมัยที่สุดแบบสร้างภาพในแบบฝึกหัด (generative adversarial networks) นอกจากนี้ยังมีการทดลองหลายรอบเพื่อทดสอบผลกระทบของการฝึกอบรมในสภาพแวดล้อมที่ควบคุมและการทำงานในสถานการณ์ทางปฏิบัติเพื่อตรวจจำโรคพืชได้อย่างแม่นยำในพื้นที่ที่ซับซ้อนและเงื่อนไขต่าง ๆ รวมถึงการตรวจจำ

โรคหลาย ๆ โรคบนใบเดียวกัน และได้นำเสนอโครงสร้างเครือข่ายประสาทสองชั้นใหม่สำหรับการจำแนกโรคพืชในสภาพแวดล้อมจริง เมื่อทดลองฝึกอบรมเสร็จสิ้น โมเดลสามารถทำนายได้อย่างแม่นยำถึง 93.67%

Adedaja et al. [55] นำเสนอการศึกษาเกี่ยวกับการใช้การเรียนรู้เชิงลึกเพื่อระบุพืชที่เป็นโรคโดยใช้ภาพใบพืชผ่านการ transfer learning งานวิจัยนี้ใช้โครงสร้างของ NASNet สำหรับเครือข่ายประสาทเชิงลึก (CNN) จากนั้นถูกฝึกสอนและทดสอบโดยใช้ชุดข้อมูลจากโครงการ PlantVillage ที่สาธารณะซึ่งประกอบด้วยภาพใบพืชที่หลากหลายทั้งในสถานะการติดเชื้อและตำแหน่งในพืช โดยใช้โมเดลนี้ได้รับอัตราความถูกต้องอยู่ที่ 93.82% การนำเทคนิคการเรียนรู้เชิงลึกและการ transfer learning มาใช้ได้ช่วยให้การตรวจสอบและการจัดการโรคพืชก้าวหน้าขึ้น ผลลัพธ์ที่ได้แสดงให้เห็นถึงศักยภาพในการใช้เครือข่ายประสาทลึก นั้นสามารถนำมาปรับปรุงกระบวนการเกษตร และเพิ่มความปลอดภัยให้กับพืชต่าง ๆ ได้

Temniranrat et al. [56] ได้นำเสนอการพัฒนาระบบ LINE Bot เพื่อวินิจฉัยโรคข้าวจากภาพข้าวนาจริง เพื่อช่วยเกษตรกรข้าวในการปรับปรุงผลผลิตและคุณภาพข้าว ซึ่งเป็นภาพถ่ายจากสภาพแวดล้อมนาข้าวจริง โดยใช้เทคนิค Deep Learning Neural networks เพื่อตรวจจับโรคข้าวจากภาพ มีการพัฒนากระบวนการฝึก และปรับปรุงโมเดลในการตรวจจับ เพื่อปรับปรุงประสิทธิภาพเน้นการวิเคราะห์ผลลัพธ์การพยากรณ์ของโมเดล ซึ่งมีการปรับปรุงชุดข้อมูลในการฝึกฝนให้มีประสิทธิภาพเพิ่มขึ้นจากงานวิจัยครั้งก่อน จาก Average True Positive Point อยู่ที่ 91.1% เป็น 95.6% และนำโมเดลที่ดีที่สุดคือ YOLOv3 ไปพัฒนาเป็นระบบ LINE Bot ในการตรวจจับโรคข้าวแบบอัตโนมัติ และแสดงผลวินิจฉัยแบบเรียลไทม์ ซึ่งในการใช้งานจริงของ LINE Bot ระบบมีการตอบกลับแบบรวดเร็วโดยใช้เวลาในการประมวลผลใน server 2-3 วินาที และมีประสิทธิภาพของโมเดลวัดด้วยการหา True Positive เฉลี่ยอยู่ที่ 78.86%

บทที่ 3

วิธีการดำเนินงานวิจัย

ในบทนี้กล่าวถึงการออกแบบของการใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN) ที่มีโครงสร้างที่ต่างกัน (Architecture) จำนวน 5 แบบ [57] ได้แก่ VGGNet-16 [7], ResNet-50 [8], DenseNet-121 [9], AlexNet [10] และ GoogLeNet [11] โดยมีเป้าหมายที่จะทดสอบเพื่อเปรียบเทียบประสิทธิภาพของโมเดลดังกล่าว โดยใช้ชุดข้อมูลรูปภาพที่สร้างขึ้นเองจำนวน 1 ชุด คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset และทดสอบประสิทธิภาพของวิธี CNN ทั้ง 5 รูปแบบด้วยวิธี Classification [12], [33], [58] เพื่อให้การเปรียบเทียบผลลัพธ์ที่เชื่อถือได้ วิธีการดำเนินการวิจัยถูกแบ่งออกเป็น 3 ส่วน ดังนี้

- 3.1 ชุดข้อมูลรูปภาพที่ใช้ในการวิจัย
- 3.2 การทดลองวิเคราะห์ตรวจสอบโรคโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน
- 3.3 การทดสอบประสิทธิภาพ
- 3.4 การออกแบบและพัฒนาระบบ LINE Chatbot

3.1 ชุดข้อมูลรูปภาพที่ใช้ในการวิจัย

จากการศึกษา [35], [46], [50], [59] ได้มีการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ข้อมูลรูปภาพจากใบพืชต่าง ๆ โดยจำนวนรูปภาพในแต่ละคลาสมีจำนวนใกล้เคียงกับงานวิจัยนี้ ซึ่งงานวิจัยนี้ได้เก็บรวบรวมรูปภาพ 1 ชุดข้อมูล คือ Sugarcane Leaf Disease Dataset ซึ่งมีจำนวนรูปภาพทั้งหมด 4,000 ภาพ แบ่งออกเป็น 2 ชุดข้อมูล คือ ชุดข้อมูลรูปภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง รูปภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน และรูปภาพใบอ้อยที่เป็นโรคราสนิม มีจำนวนอย่างละ 1,000 ภาพ และชุดข้อมูลรูปภาพที่ใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ มีจำนวน 1,000 ภาพ โดยรูปภาพทั้งหมดเป็นภาพที่อยู่ในสภาพแวดล้อมทางธรรมชาติที่มีลักษณะเด่นในภาพอย่างน้อย 1 อย่าง และมีจำนวนรูปภาพเพียงพอต่อการดำเนินการวิจัยนี้ ในการเก็บข้อมูลนี้ผู้วิจัยได้ลงพื้นที่เพื่อจัดเก็บภาพถ่ายใบอ้อยในพื้นที่กลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง [4] ประกอบด้วย 4 จังหวัด ได้แก่ จังหวัดมหาสารคาม จังหวัดขอนแก่น จังหวัดกาฬสินธุ์ และจังหวัดร้อยเอ็ด

การแบ่งออกข้อมูลภาพได้ทำการแบ่งด้วยอัตราส่วน 3 แบบ [60], [61], [62] คือ 75:25, 80:20 และ 90:10 ซึ่งหมายความว่าชุดข้อมูลภาพถูกแบ่งออกเป็น 2 ส่วนคือ ชุดข้อมูลฝึกสอน (Train Data) ซึ่งมีจำนวนรูปภาพเป็น 75%, 80%, 90% และชุดข้อมูลในการทดสอบ (Test Data) ซึ่งมี

จำนวนรูปภาพเป็น 25%, 20%, และ 10% ตามลำดับ โดยในแต่ละชุดข้อมูลจะมีตัวอย่างข้อมูลรูปภาพในชุดข้อมูลดังนี้

3.1.1 รูปภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง



ภาพประกอบ 22 ตัวอย่างภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง จากฐานข้อมูล Sugar Cane Leaf Disease Dataset

3.1.2 รูปภาพใบอ้อยที่เป็นโรคจุดวงแหวน



ภาพประกอบ 23 ตัวอย่างภาพใบอ้อยที่เป็นโรคจุดวงแหวน จากฐานข้อมูล Sugar Cane Leaf Disease Dataset

3.1.3 รูปภาพใบอ้อยที่เป็นโรคคราสนิม



ภาพประกอบ 24 ตัวอย่างภาพใบอ้อยที่เป็นโรคคราสนิม จากฐานข้อมูล Sugar Cane Leaf Disease Dataset

3.1.4 รูปภาพที่ใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ มีจำนวน 1,000 ภาพ



ภาพประกอบ 25 ตัวอย่างภาพใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ จากฐานข้อมูล *Sugar Cane Leaf Disease Dataset*

3.1.5 รูปภาพใบอ้อยที่ใช้ในการทดสอบประสิทธิภาพ

ชุดข้อมูลรูปภาพใบอ้อยที่ใช้ในการทดสอบประสิทธิภาพในงานวิจัยนี้จะใช้ชุดข้อมูลในการทดสอบ 20% (Test Data) โดยประกอบด้วย รูปภาพใบอ้อยที่เป็นโรคกลางใบแดง โรคจุดวงแหวน โรคราสนิม และรูปภาพใบอ้อยที่ปกติหรือไม่เป็นโรค ดังตัวอย่างภาพประกอบด้านล่างนี้



ภาพประกอบ 26 ตัวอย่างภาพใบอ้อยที่เป็นโรคเน่าแดง จากฐานข้อมูล *Sugar Cane Leaf Disease Dataset* ที่ใช้ในการทดสอบประสิทธิภาพ (Test Data)



ภาพประกอบ 27 ตัวอย่างภาพใบอ้อยที่เป็นโรคจุดวงแหวน จากฐานข้อมูล Sugar Cane Leaf Disease Dataset ที่ใช้ในการทดสอบประสิทธิภาพ (Test Data)



ภาพประกอบ 28 ตัวอย่างภาพใบอ้อยที่เป็นโรคคราสนิม จากฐานข้อมูล Sugar Cane Leaf Disease Dataset ที่ใช้ในการทดสอบประสิทธิภาพ (Test Data)

3.1.6 การแบ่งจำนวนรูปภาพสำหรับ Train และ Test

ในการวิจัยนี้มีชุดข้อมูลจำนวน 4 คลาส ได้แก่ ใบอ้อยที่เป็นโรคเส้นกลางใบแดง ตั้งชื่อคลาสว่า RedRot มีจำนวน 1,000 รูปภาพ ใบอ้อยที่เป็นโรคใบจุดวงแหวน ตั้งชื่อคลาสว่า RingSpot มีจำนวน 1,000 รูปภาพ ใบอ้อยที่เป็นโรคราสนิม ตั้งชื่อคลาสว่า Rust มีจำนวน 1,000 รูปภาพ และใบอ้อยปกติที่ไม่เป็นโรค ตั้งชื่อคลาสว่า Healthy มีจำนวน 1,000 รูปภาพ รวมรูปภาพทั้งสิ้น 4,000 รูปภาพ โดยแบ่งด้วยอัตราส่วน 3 แบบ คือ 75:25, 80:20 และ 90:10 ซึ่งหมายความว่าชุดข้อมูลภาพถูกแบ่งออกเป็น 2 ส่วนด้วยวิธีการเขียนโปรแกรมเลือกรูปภาพแบบสุ่ม คือ ชุดข้อมูลฝึกสอน (Train Data) ซึ่งมีจำนวนรูปภาพเป็น 75%, 80%, 90% และชุดข้อมูลในการทดสอบ (Test Data) ซึ่งมีจำนวนรูปภาพเป็น 25%, 20%, และ 10% ตามลำดับ ซึ่งมีรายละเอียดดังภาพประกอบ

27

Class	Data set	Train Data			Test Data		
		75%	80%	90%	25%	20%	10%
Healthy	1000	750	800	900	250	200	100
RedRot	1000	750	800	900	250	200	100
RingSpot	1000	750	800	900	250	200	100
Rust	1000	750	800	900	250	200	100
Total	4000	3000	3200	3600	1000	800	400

ภาพประกอบ 29 การแบ่งจำนวนรูปภาพสำหรับ Train และ Test

3.2 การทดลองวิเคราะห์ตรวจสอบโรคโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน

ในการวิจัยนี้ได้ทำการทดลองวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันบน Google Colab [18], [19] ซึ่งประมวลผลด้วยหน่วยประมวลผลภาพ (Graphic Processing Unit: GPU) ช่วยในการประมวลผลชุดข้อมูลรูปภาพ การประมวลผลข้อมูลทางด้านรูปภาพด้วย GPU จะมีความรวดเร็วเพิ่มขึ้นจากการที่ใช้หน่วยประมวลผลกลาง (Central Processing Unit: CPU) ในการประมวลผลเพียงอย่างเดียว ซึ่ง GPU ที่สามารถประมวลผลแบบขนาน Parallel Computer ทำให้สามารถประมวลผลข้อมูลพร้อม ๆ กันได้ในเวลาเดียวกัน โดยการศึกษาการใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยด้วยชุดข้อมูลขนาดเล็ก เพื่อสร้างโมเดลนั้น มีขั้นตอนการทดลองตามลำดับดังต่อไปนี้

- 1) ทำการแบ่งชุดข้อมูลออกเป็น 75:25, 80:20 และ 90:10 โดยเป็นชุดสอน (Training Data) และชุดทดสอบ (Test Data) ตามลำดับ
- 2) นำชุดข้อมูลรูปภาพดังกล่าว มาทดสอบประสิทธิภาพของเทคนิค Deep Learning ด้วยวิธี CNNs ที่มีลักษณะโครงสร้าง (Architecture) ที่ต่างกัน 5 แบบ ได้แก่ VGGNet-16 [7], ResNet-50 [8], DenseNet-121 [9], AlexNet [10] และ GoogLeNet [11]
- 3) ทำการทดลองกับชุดข้อมูลรูปภาพ จากนั้นก็นำไปหาประสิทธิภาพของโมเดล โดยจะทำการวัดประสิทธิภาพเพื่อหาค่า Recall, Precision และ Accuracy
- 4) นำโมเดลที่ได้ผลดีที่สุดไปใช้พัฒนาระบบ Line Chatbot ในการวิเคราะห์ภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง โรคจุดวงแหวน และโรคราสนิม


3.3 การทดสอบประสิทธิภาพ

ในการวิจัยนี้มีความมุ่งหมายคือการเปรียบเทียบประสิทธิภาพการทำงานของโมเดล CNN สำหรับการวิเคราะห์ภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง โรคจุดวงแหวน และโรคราสนิม ซึ่งในการวิจัยนี้จะใช้วิธี Classification [12], [35] เพื่อวัดประสิทธิภาพโดยการใช้ค่าความถูกต้อง (Accuracy) อัตราการจำแนกถูกต้อง (Recall) และค่าความแม่นยำของโมเดล (Precision) ที่ได้จากการทดสอบการจำแนกประเภทของแต่ละโมเดล บนชุดข้อมูลที่เตรียมไว้เพื่อทำการทดสอบ (Test) และนำผลลัพธ์หรือค่า Accuracy มาทำการเปรียบเทียบกันเพื่อหาว่าแบบจำลองใดให้ค่า Accuracy ในการจำแนกประเภทของใบอ้อยได้ผลลัพธ์สูงสุด ด้วยการหาค่าเฉลี่ยความสามารถของโมเดล (f1-Score) และคำนวณค่าเฉลี่ยของ f1- score (average f1-scores) โดยวิธีการหาค่า average f1-scores ด้วยวิธี Macro-average method [38], [39] เพื่อที่จะหาโมเดลในการจำแนกประเภทของใบอ้อยที่ได้ผลลัพธ์ดีที่สุด ในแต่ละรูปแบบของชุดข้อมูลการจำแนกทั้ง 3 แบบ

3.4 การออกแบบและพัฒนาระบบ LINE Chatbot


การออกแบบและพัฒนาระบบ LINE Chatbot ในงานวิจัยนี้ ใช้บริการ Messaging API ของ LINE เป็นตัวกลางระหว่าง ผู้ใช้ (User) กับ Model API ที่ผู้วิจัยได้เปรียบเทียบประสิทธิภาพของโมเดลในงานวิจัยนี้ เพื่อหาโมเดลที่ดีที่สุด มาใช้ในการตรวจวินิจฉัยหรือทำนายโรคอ้อยจากภาพใบอ้อย ได้จำนวน 3 โรค คือ โรคเส้นกลางใบแดง โรคจุดวงแหวน โรคราสนิม และสามารถบอกได้ว่าใบอ้อยมีความปกติดี หรือไม่โรคใด ๆ โดยกรอบแนวคิดนี้เริ่มจากการที่ผู้ใช้ ต้องการติดต่อสอบถามเพื่อวินิจฉัยโรคอ้อยจากรูปภาพใบอ้อย โดยต้องใช้บริการแพลตฟอร์มในการติดต่อคือ LINE และทำการเพิ่มเพื่อนกับบัญชี LINE Official ที่ผู้วิจัยได้เปิดให้บริการในชื่อ Sugarcane Disease ซึ่งจะบัญชี

สำหรับรับส่งข้อมูลจากผู้ใช้งาน กับเซิร์ฟเวอร์ เพื่อให้ผู้ใช้งานสามารถส่งรูปภาพใบอ้อยเพื่อวินิจฉัยโรคอ้อย และมีการตอบกลับแบบอัตโนมัติ โดยผู้วิจัยได้ออกแบบและพัฒนาระบบ LINE Chatbot ดังภาพประกอบ



ภาพประกอบ 30 LINE Chatbot Architecture

หลังจากที่ผู้วิจัยนั้นได้ทำการเปรียบเทียบประสิทธิภาพของโมเดลในแต่ละโมเดลแล้วนั้น ก็ จะทำการเลือกโมเดลที่ดีที่สุดมาใช้ในการพัฒนาเป็น Bot API ซึ่งจะถูกเก็บและสร้างไว้ใน Server Bot ของผู้วิจัยเอง เพื่อใช้เป็น Server ในการวิเคราะห์ภาพใบอ้อยที่ผู้ใช้งาน (User) ส่งเข้ามายัง LINE Messaging API แล้วก็จะส่งข้อมูลรูปภาพนั้นไปทำนาย (Predict) ในชุดคำสั่งที่ผู้วิจัยได้สร้างไว้คือ Bot API ซึ่งพัฒนาด้วยภาษา Python เมื่อรูปภาพที่รับเข้ามานั้นได้ถูกทำนายแล้ว ก็จะส่งข้อมูลเป็น ข้อความตัวอักษร และรูปภาพเดิมที่ถูกส่งเข้า กลับไปยังผู้ใช้งานแบบอัตโนมัติ เพื่อให้ผู้ใช้งานทราบคำตอบ



บทที่ 4

ผลการศึกษา

ในบทนี้จะกล่าวถึงการทดลองการใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN) ตามขั้นตอนในการทดลองที่กล่าวไว้ในบทที่ 3 โดยในการทดลองนั้นใช้โมเดล CNN ที่มีโครงสร้างที่ต่างกัน (Architecture) จำนวน 5 แบบ ได้แก่ VGGNet-16 [7], ResNet-50 [8], DenseNet-121 (Jee et al., 2023), AlexNet (Krizhevsky et al., 2012) และ GoogLeNet (Christian Szegedy et al., 2015) กับข้อมูลจำนวน 1 ชุดข้อมูล ที่ผู้ศึกษาวิจัยได้เก็บรวบรวมไว้ ทำการเปรียบเทียบผลการทดลองและประสิทธิภาพของโมเดล สุดท้ายเลือกโมเดลที่มีประสิทธิภาพดีที่สุดไปพัฒนาระบบวิเคราะห์ภาพใบอ้อยเพื่อตรวจสอบโรคแบบอัตโนมัติ (Line Chatbot) ซึ่งในบทนี้จะแสดงรายละเอียดผลการศึกษาในการดำเนินการวิจัยดังนี้

- 4.1 เครื่องมือและชุดข้อมูลที่ใช้ในการทดลอง
- 4.2 วิธีการทดลอง
- 4.3 ผลการจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก
- 4.4 ผลการเปรียบเทียบประสิทธิภาพของโมเดล
- 4.5 ผลการพัฒนาระบบ LINE Chatbot

4.1 เครื่องมือและชุดข้อมูลที่ใช้ในการทดลอง

การทดลองนี้ได้ใช้เครื่องมือได้แก่ Google Colaboratory (Google Colab) เป็นบริการ Software as a Service (SaaS) บน Cloud ซึ่งใช้เป็นเครื่องมือในการทดสอบการเรียนรู้เชิงลึก โดยใช้การประมวลผลแบบ GPU รุ่น Nvidia Tesla T4 เพื่อทำการทดลองกับชุดข้อมูลที่ใช้ในการวิจัยนี้ ชุดข้อมูลที่ใช้ในการทดลองได้แก่ ชุดข้อมูล Sugarcane Leaf Disease Dataset ซึ่งรวบรวมรูปภาพใบอ้อยจำนวน 1 ชุดข้อมูล มีจำนวนทั้งสิ้น 4,000 ภาพ ประกอบด้วย รูปภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง รูปภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน รูปภาพที่เป็นโรคราสนิม มีจำนวนอย่างละ 1,000 ภาพ และรูปภาพที่ใบอ้อยปกติหรือไม่เป็นโรคใดๆ มีจำนวน 1,000 ภาพ โดยรูปภาพทั้งหมดเป็นภาพที่อยู่ในสภาพแวดล้อมทางธรรมชาติที่มีลักษณะเด่นในภาพอย่างน้อย 1 อย่าง โดยจะทำการแบ่งภาพโดยการสุ่มเลือกรูปภาพด้วยอัตราส่วน 3 แบบ คือ 75:25, 80:20, 90:10 ซึ่งหมายความว่าชุดข้อมูลจะถูกแบ่งออกเป็น 2 ส่วน คือ ชุดข้อมูลที่ใช้ในการเรียนรู้ (Train Data) และชุดข้อมูลที่ใช้ในการทดสอบ (Test Data) ตามลำดับ เพื่อหาประสิทธิภาพที่ดีที่สุดสำหรับชุดข้อมูลนี้

โดยในการทดลองจะทำการแบ่งรูปภาพในชุดข้อมูลออกเป็น 3 แบบ ได้แก่ แบบที่ 1 แบบ 75:25 คือ ร้อยละ 75 เป็นชุดข้อมูลที่ใช้ในการเรียนรู้ (Train Data) และร้อยละ 25 เป็นชุดข้อมูลที่ใช้ในการทดสอบ (Test Data) ดังตาราง 3 การแบ่งชุดข้อมูลแบบที่ 2 แบบ 80:20 คือ ร้อยละ 80 เป็นชุดข้อมูลที่ใช้ในการเรียนรู้ (Train Data) และร้อยละ 20 เป็นชุดข้อมูลที่ใช้ในการทดสอบ (Test Data) ดังตาราง 4 และแบ่งชุดข้อมูลแบบที่ 3 แบบ 90:10 คือ ร้อยละ 90 เป็นชุดข้อมูลที่ใช้ในการเรียนรู้ (Train Data) และร้อยละ 10 เป็นชุดข้อมูลที่ใช้ในการทดสอบ (Test Data) ดังตาราง 5

ตาราง 3 ชุดข้อมูลในการทดลองแบ่งด้วยอัตราส่วนร้อยละ 75:25

ชุดข้อมูล	ภาพทั้งหมด	ภาพที่ใช้เรียนรู้	ภาพที่ใช้ทดสอบ
Healthy	1,000	750	250
RedRot	1,000	750	250
Rust	1,000	750	250
RingSpot	1,000	750	250

ตาราง 4 ชุดข้อมูลในการทดลองแบ่งด้วยอัตราส่วนร้อยละ 80:20

ชุดข้อมูล	ภาพทั้งหมด	ภาพที่ใช้เรียนรู้	ภาพที่ใช้ทดสอบ
Healthy	1,000	800	200
RedRot	1,000	800	200
Rust	1,000	800	200
RingSpot	1,000	800	200

ตาราง 5 ชุดข้อมูลในการทดลองแบ่งด้วยอัตราส่วนร้อยละ 90:10

ชุดข้อมูล	ภาพทั้งหมด	ภาพที่ใช้เรียนรู้	ภาพที่ใช้ทดสอบ
Healthy	1,000	800	200
RedRot	1,000	800	200
Rust	1,000	800	200
RingSpot	1,000	800	200

4.2 วิธีการทดลอง

ในขั้นตอนการทดลองนี้จะนำชุดข้อมูลที่ได้จัดเตรียมไว้มาทดลองกับวิธีการที่ออกแบบไว้ โดยใช้โมเดล CNN ที่มีโครงสร้างที่ต่างกัน 5 แบบ คือ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet ซึ่งใช้ Google Colab รันใหม่แบบ Python 3 ใช้เร่งฮาร์ดแวร์แบบ T4GPU เป็นเครื่องมือในการทดลองการเรียนรู้เชิงลึก โดยมีการตั้งค่าพารามิเตอร์ในการทดลองดังนี้

ขั้นที่ 1 กำหนดพารามิเตอร์ในขั้นตอนของการเตรียมชุดข้อมูลรูปภาพ เพื่อใช้สำหรับเรียนรู้ (Train Data) และชุดข้อมูลตรวจสอบการเรียนรู้ (Validation) โดยทำการปรับลดขนาดรูปภาพให้มีขนาด 256x256 พิกเซล ซึ่งภาพทั้งหมดเป็นภาพสีแบบ RGB และมีการแบ่งข้อมูลเพื่อทำ Validation 20% จากชุดข้อมูลสำหรับเรียนรู้ ดังตาราง 6

ตาราง 6 พารามิเตอร์ที่ใช้ในการเตรียมชุดข้อมูล

Name	Parameter
Image Type	Color (RGB)
Image size (Width x Height)	256x256
% for validation	20
Image Encoding	jpg

ขั้นที่ 2 กำหนดค่าพารามิเตอร์สำหรับให้คอมพิวเตอร์ทำการเรียนรู้จำโดยทำการเลือกชุดข้อมูลรูปภาพที่ได้เตรียมไว้ ซึ่งในงานวิจัยนี้ได้แบ่งชุดข้อมูลทั้ง 3 แบบ ตามตาราง 3, 4, และ 5 ตามลำดับ โดยมีการกำหนดค่าพารามิเตอร์ ดังตาราง 7

ตาราง 7 พารามิเตอร์ในการกำหนดค่าทดสอบการเรียนรู้เชิงลึก


Name	Parameter
Dataset	Healthy RedRot Rust RingSpot
Solver Options	
Training epochs	4 10 20
Batch size	64

4.3 ผลการจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก

งานวิจัยนี้ได้ทำการแบ่งชุดข้อมูลด้วยสัดส่วนแบบร้อยละ จำนวน 3 แบบ คือ 75:25, 80:20, 90:10 เพื่อใช้เป็นชุดในการเรียนรู้ของเครื่อง และชุดข้อมูลที่ใช้ในการทดสอบประสิทธิภาพ โดยรูปภาพทั้งหมดมีขนาด 256x256 พิกเซล โดยมีผลการทดลองในแต่ละแบบของชุดข้อมูล ดังนี้


4.3.1 จำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก ในชุดข้อมูลแบบร้อยละ 75:25

1) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 75:25 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,000 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ VGG-16 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 89.33%, 95.33% และ 96.50% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 96.50% ใช้เวลาในการเรียนรู้ 18 นาที 4 วินาที ดังภาพประกอบ 31




ภาพประกอบ 31 Train Data 75% กับโครงสร้าง VGG-16 ที่ epoch=20

2) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 75:25 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,000 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ ResNet-50 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 90.33%, 93.66% และ 96.66% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 96.66% ใช้เวลาในการเรียนรู้ 10 นาที 50 วินาที ดังภาพประกอบ 32




ภาพประกอบ 32 Train Data 75% กับโครงสร้าง ResNet-50 ที่ epoch=20

3) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 75:25 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,000 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ DenseNet-121 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 89.83%, 96.33% และ 97.83% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 97.83% ใช้เวลาในการเรียนรู้ 11 นาที 36 วินาที ดังภาพประกอบ 33




ภาพประกอบ 33 Train Data 75% กับโครงสร้าง DenseNet-121 ที่ epoch=20

4) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 75:25 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,000 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ AlexNet โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 89.16%, 93.50% และ 95.50% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 95.50% ใช้เวลาในการเรียนรู้ 5 นาที 7 วินาที ดังภาพประกอบ 34



ภาพประกอบ 34 Train Data 75% กับโครงสร้าง AlexNet ที่ epoch=20


5) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 75:25 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,000 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ GoogLeNet โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 88.83%, 92.66% และ 95.33% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 95.33% ใช้เวลาในการเรียนรู้ 6 นาที 10 วินาที ดังภาพประกอบ 35



ภาพประกอบ 35 Train Data 75% กับโครงสร้าง GoogLeNet ที่ epoch=20


4.3.2 จำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก ในชุดข้อมูลแบบร้อยละ 80:20

1) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 80:20 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,200 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ VGG-16 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 89.06%, 95.31% และ 97.50% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 97.50% ใช้เวลาในการเรียนรู้ 19 นาที 50 วินาที ดังภาพประกอบ 36




ภาพประกอบ 36 Train Data 80% กับโครงสร้าง VGG-16 ที่ epoch=20

2) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 80:20 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,200 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ ResNet-50 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 83.75%, 92.03% และ 97.34% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 97.34% ใช้เวลาในการเรียนรู้ 11 นาที 55 วินาที ดังภาพประกอบ 37




ภาพประกอบ 37 Train Data 80% กับโครงสร้าง ResNet-50 ที่ epoch=20

3) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 80:20 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,200 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ DenseNet-121 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 91.87%, 95.31% และ 97.18% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 97.18% ใช้เวลาในการเรียนรู้ 12 นาที 16 วินาที ดังภาพประกอบ 38




ภาพประกอบ 38 Train Data 80% กับโครงสร้าง DenseNet-121 ที่ epoch=20

4) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 80:20 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,200 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ AlexNet โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 88.43%, 93.12% และ 96.40% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 96.40% ใช้เวลาในการเรียนรู้ 5 นาที 32 วินาที ดังภาพประกอบ 39



ภาพประกอบ 39 Train Data 80% กับโครงสร้าง AlexNet ที่ epoch=20


5) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 80:20 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,200 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ GoogLeNet โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 85.46%, 85.62% และ 95.62% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 95.62% ใช้เวลาในการเรียนรู้ 6 นาที 15 วินาที ดังภาพประกอบ 40



ภาพประกอบ 40 Train Data 80% กับโครงสร้าง GoogLeNet ที่ epoch=20


4.3.3 จำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก ในชุดข้อมูลแบบร้อยละ 90:10

1) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 90:10 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,600 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ VGG-16 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 90.97%, 96.80% และ 97.50% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 97.50% ใช้เวลาในการเรียนรู้ 21 นาที 41 วินาที ดังภาพประกอบ 41




ภาพประกอบ 41 Train Data 90% กับโครงสร้าง VGG-16 ที่ epoch=20

2) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 90:10 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,600 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ ResNet-50 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 89.44%, 96.52% และ 96.80%ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 96.80% ใช้เวลาในการเรียนรู้ 12 นาที 38 วินาที ดังภาพประกอบ 42




ภาพประกอบ 42 Train Data 90% กับโครงสร้าง ResNet-50 ที่ epoch=20

3) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 90:10 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,600 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ DenseNet-121 โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 90.83%, 96.11% และ 97.91% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 97.91% ใช้เวลาในการเรียนรู้ 13 นาที 47 วินาที ดังภาพประกอบ 43




ภาพประกอบ 43 Train Data 90% กับโครงสร้าง DenseNet-121 ที่ epoch=20

4) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 90:10 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,600 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ AlexNet โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 89.16%, 93.88% และ 95.55% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 95.55% ใช้เวลาในการเรียนรู้ 5 นาที 42 วินาที ดังภาพประกอบ 44



ภาพประกอบ 44 Train Data 90% กับโครงสร้าง AlexNet ที่ epoch=20

5) การจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึกในชุดข้อมูลแบบร้อยละ 90:10 โดยใช้ข้อมูลรูปภาพในชุดข้อมูลที่ได้เตรียมไว้คือ ชุดข้อมูล Sugarcane Leaf Disease Dataset จำนวน 3,600 รูปภาพ ในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย โดยใช้เทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน โครงสร้างแบบ GoogLeNet โดยปรับจูนไฮเปอร์พารามิเตอร์ (epoch) แบบ 4, 10 และ 20 โดยมีอัตราความถูกต้อง คือ 87.50%, 90.97% และ 94.16% ตามลำดับ ซึ่งอัตราความถูกต้องสูงสุด ได้แก่ epoch=20 มีอัตราความถูกต้องอยู่ที่ 94.16% ใช้เวลาในการเรียนรู้ 7 นาที 4 วินาที ดังภาพประกอบ 45



ภาพประกอบ 45 Train Data 90% กับโครงสร้าง GoogLeNet ที่ epoch=20


จากผลการจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก ด้วยสัดส่วนแบบร้อยละ จำนวน 3 แบบ คือ 75:25, 80:20, 90:10 เพื่อใช้เป็นชุดในการเรียนรู้ของเครื่อง และชุดข้อมูลที่ใช้ในการทดสอบประสิทธิภาพ โดยในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย ด้วยชุดข้อมูล 3 ชุด ประกอบด้วยข้อมูลสำหรับเรียนรู้ (Train Data) 75%, 80% และ 90% นั้นพบว่า การปรับจูนไฮเปอร์พารามิเตอร์ (epoch) เท่ากับ 20 นั้นมีอัตราความถูกต้องสูงที่สุดในทุกชุดข้อมูล ดังตาราง 8 ซึ่งในงานวิจัย ผู้วิจัยก็นำโมเดลดังตาราง 8 ไปทดสอบการจำแนกโรคจากภาพใบอ้อย จากชุดข้อมูลที่ใช้ในการทดสอบ (Test Data) เพื่อหาโมเดลที่มีประสิทธิภาพดีที่สุด ดังที่จะนำเสนอผลการทดสอบจำแนกโรคจากภาพใบอ้อย ในส่วนถัดไป

ตาราง 8 สรุปผลในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย

Model	train_data	epoch	time_train	train_loss	valid_loss	accuracy
VGG-16	75%	20	18.04m	0.0027	0.2577	0.9650
	80%	20	19.50m	0.0107	0.1105	0.9750
	90%	20	21.41m	0.2540	0.2677	0.9097
ResNet-50	75%	20	10.50m	0.0013	0.2822	0.9666
	80%	20	11.55m	0.0161	0.1159	0.9734
	90%	20	12.38m	0.0011	0.1903	0.9680
DenseNet-121	75%	20	11.36m	0.0021	0.1707	0.9783
	80%	20	12.16m	0.0031	0.1454	0.9718
	90%	20	13.47m	0.0019	0.1135	0.9791
AlexNet	75%	20	5.07m	0.0026	0.2467	0.9550
	80%	20	5.32m	0.0396	0.1206	0.9640
	90%	20	5.42m	0.0054	0.2594	0.9555
GoogLeNet	75%	20	6.10m	0.0075	0.2912	0.9533
	80%	20	6.15m	0.1149	0.1548	0.9562
	90%	20	7.04m	0.0038	0.3189	0.9416


4.3.4 การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล (train_data=75%)

1) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล VGG-16 (train_data=75%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 250 รูปภาพ รวมทั้งหมด 1,000 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล VGG-16 โดยรวมอยู่ที่ 96.30% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส Rust มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 46




ภาพประกอบ 46 Confusion Matrix Model VGG-16 Train Data 75:25

2) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล ResNet-50 (train_data=75%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 250 รูปภาพ รวมทั้งหมด 1,000 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล ResNet-50 โดยรวมอยู่ที่ 96.50% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส Rust มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 47




ภาพประกอบ 47 Confusion Matrix Model ResNet-50 Train Data 75:25

3) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล DenseNet-121 (train_data=75%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 250 รูปภาพ รวมทั้งหมด 1,000 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล DenseNet-121 โดยรวมอยู่ที่ 96.70% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และ คลาส Rust มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 48




ภาพประกอบ 48 Confusion Matrix Model DenseNet-121 Train Data 75:25

4) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล AlexNet (train_data=75%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 250 รูปภาพ รวมทั้งหมด 1,000 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล AlexNet โดยรวมอยู่ที่ 95.70% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส Rust มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 49



ภาพประกอบ 49 Confusion Matrix Model AlexNet Train Data 75:25


5) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล GoogLeNet (train_data=75%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 250 รูปภาพ รวมทั้งหมด 1,000 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล GoogLeNet โดยรวมอยู่ที่ 94.70% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส Rust มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 50



ภาพประกอบ 50 Confusion Matrix Model GoogLeNet Train Data 75:25


4.3.5 การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล (train_data=80%)

1) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล VGG-16 (train_data=80%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 200 รูปภาพ รวมทั้งหมด 200 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล VGG-16 โดยรวมอยู่ที่ 96.62% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส RingSpot มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 51




ภาพประกอบ 51 Confusion Matrix Model VGG-16 Train Data 80:20

2) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล ResNet-50 (train_data=80%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 200 รูปภาพ รวมทั้งหมด 800 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล ResNet-50 โดยรวมอยู่ที่ 97.00% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส Rust มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 52




ภาพประกอบ 52 Confusion Matrix Model ResNet-50 Train Data 80:20

3) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล DenseNet-121 (train_data=80%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 200 รูปภาพ รวมทั้งหมด 800 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล DenseNet-121 โดยรวมอยู่ที่ 96.75% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส RingSpot มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 53




ภาพประกอบ 53 Confusion Matrix Model DenseNet-121 Train Data 80:20

4) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล AlexNet (train_data=80%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 200 รูปภาพ รวมทั้งหมด 800 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล AlexNet โดยรวมอยู่ที่ 94.62% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส RingSpot มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 54



ภาพประกอบ 54 Confusion Matrix Model AlexNet Train Data 80:20


5) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล GoogLeNet (train_data=80%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 200 รูปภาพ รวมทั้งหมด 800 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล GoogLeNet โดยรวมอยู่ที่ 94.25% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส RingSpot มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 55



ภาพประกอบ 55 Confusion Matrix Model GoogLeNet Train Data 80:20


4.3.6 การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล (train_data=90%)

1) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล VGG-16 (train_data=90%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 100 รูปภาพ รวมทั้งหมด 400 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล VGG-16 โดยรวมอยู่ที่ 96.00% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส RingSpot มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 56




ภาพประกอบ 56 Confusion Matrix Model VGG-16 Train Data 90:10

2) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล ResNet-50 (train_data=90%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 100 รูปภาพ รวมทั้งหมด 400 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล ResNet-50 โดยรวมอยู่ที่ 95.50% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด ซึ่งคลาส RedRot และคลาส Rust มีความแม่นยำน้อยที่สุดเท่ากัน ดังภาพประกอบ 57




ภาพประกอบ 57 Confusion Matrix Model ResNet-50 Train Data 90:10

3) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล DenseNet-121 (train_data=90%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 100 รูปภาพ รวมทั้งหมด 400 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล DenseNet-121 โดยรวมอยู่ที่ 97.25% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด ซึ่งคลาส RingSpot และคลาส Rust มีความแม่นยำน้อยที่สุดเท่ากัน ดังภาพประกอบ 58




ภาพประกอบ 58 Confusion Matrix Model DenseNet-121 Train Data 90:10

4) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล AlexNet (train_data=90%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 100 รูปภาพ รวมทั้งหมด 400 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล AlexNet โดยรวมอยู่ที่ 95.70% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด และคลาส RingSpot มีความแม่นยำน้อยที่สุด ดังภาพประกอบ 59



ภาพประกอบ 59 Confusion Matrix Model AlexNet Train Data 90:10

5) การทดสอบจำแนกโรคใบอ้อยด้วยโมเดล GoogLeNet (train_data=90%) โดยใช้ชุดข้อมูลรูปภาพ 4 คลาส ได้แก่ Healthy, RedRot, Rust และ RingSpot จำนวนคลาสละ 100 รูปภาพ รวมทั้งหมด 400 รูปภาพ เป็นข้อมูลในการทดสอบ (Test Data) ผลการทดสอบพบว่า อัตราความถูกต้องในการจำแนกโรคใบอ้อยด้วยโมเดล GoogLeNet โดยรวมอยู่ที่ 91.25% เมื่อพิจารณาความแม่นยำของโมเดลแยกทีละคลาส พบว่า คลาส Healthy มีความแม่นยำมากที่สุด ซึ่งคลาส RedRot, RingSpot และคลาส Rust มีความแม่นยำน้อยที่สุดเท่ากัน ดังภาพประกอบ 60



ภาพประกอบ 60 Confusion Matrix Model GoogLeNet Train Data 90:10

4.4 ผลการเปรียบเทียบประสิทธิภาพของโมเดล

จากผลการจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก โดยในการทดลองสำหรับเรียนรู้ (Train Data) จำโรคใบอ้อย ด้วยชุดข้อมูล 3 ชุด ประกอบด้วยข้อมูลสำหรับเรียนรู้ (Train Data) 75%, 80% และ 90% นั้นพบว่า การปรับจูนไฮเปอร์พารามิเตอร์ (epoch) เท่ากับ 20 นั้นมีอัตราความถูกต้องสูงที่สุดในทุกชุดข้อมูล ดังตาราง 8 ซึ่งในงานวิจัยนี้ ผู้วิจัยจึงนำโมเดลดังตาราง 8 ไปทดสอบการจำแนกโรคจากภาพใบอ้อย จากชุดข้อมูลที่ใช้ในการทดสอบ (Test Data) เพื่อวัดประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล ซึ่งประกอบไปด้วย ความถูกต้อง (Accuracy) อัตราการจำแนกถูกต้อง (Recall) ค่าความแม่นยำของโมเดล (Precision) และค่าเฉลี่ยความสามารถของโมเดล (f1-Score) ในการจำแนกประเภทของใบอ้อยที่ได้ผลลัพธ์สูงสุด ในแต่ละรูปแบบของชุดข้อมูล ผลการจำแนกทั้ง 3 แบบตามการแบ่งชุดข้อมูล 75%, 80% และ 90% ตาราง 9, 10 และ 11 ตามลำดับ

ตาราง 9 ประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล Train Data=75%

Model	Class	Accuracy	Precision	Recall	f1-score
VGG-16	Healthy	0.998	0.9960	0.996	0.9960
	RedRot	0.987	0.9759	0.972	0.9739
	RingSpot	0.971	0.9299	0.956	0.9428
	Rust	0.970	0.9508	0.928	0.9392
ResNet-50	Healthy	0.996	0.992	0.992	0.992
	RedRot	0.987	0.9836	0.964	0.9737
	RingSpot	0.974	0.9274	0.972	0.9492
	Rust	0.973	0.9588	0.932	0.9452
DenseNet-121	Healthy	0.995	0.9880	0.992	0.990
	RedRot	0.986	0.9796	0.964	0.9717
	RingSpot	0.977	0.9416	0.968	0.9546
	Rust	0.976	0.9593	0.944	0.9516
AlexNet	Healthy	0.993	0.9802	0.992	0.9860
	RedRot	0.984	0.9834	0.952	0.9674
	RingSpot	0.971	0.9266	0.960	0.9430
	Rust	0.966	0.9390	0.924	0.9314

GoogLeNet	Healthy	0.979	0.9598	0.956	0.9579
	RedRot	0.977	0.9595	0.948	0.9537
	RingSpot	0.974	0.9274	0.972	0.9492
	Rust	0.964	0.9421	0.912	0.9268

ตาราง 10 ประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล Train Data=80%

Model	Class	Accuracy	Precision	Recall	f1-score
VGG-16	Healthy	1.0	1.0	1.0	1.0
	RedRot	0.9825	0.9603	0.97	0.9651
	RingSpot	0.9712	0.9402	0.945	0.9426
	Rust	0.9787	0.9644	0.95	0.9571
ResNet-50	Healthy	0.9962	0.990	0.995	0.9925
	RedRot	0.98	0.96	0.96	0.96
	RingSpot	0.9825	0.9603	0.97	0.9651
	Rust	0.9812	0.9695	0.955	0.9622
DenseNet-121	Healthy	0.9962	0.9852	1.0	0.9925
	RedRot	0.9812	0.9556	0.97	0.9627
	RingSpot	0.9787	0.9692	0.945	0.9569
	Rust	0.9787	0.9597	0.955	0.9573
AlexNet	Healthy	0.9937	0.9850	0.99	0.9875
	RedRot	0.9775	0.9375	0.975	0.9558
	RingSpot	0.9587	0.9371	0.895	0.9156
	Rust	0.9625	0.925	0.925	0.925
GoogLeNet	Healthy	0.985	0.9653	0.975	0.9701
	RedRot	0.9687	0.9268	0.95	0.9382
	RingSpot	0.9662	0.9435	0.92	0.9316
	Rust	0.965	0.9343	0.925	0.9296

ตาราง 11 ประสิทธิภาพโดยการหาค่าผลลัพธ์ของการทำนายจากโมเดล Train Data=90%

Model	Class	Accuracy	Precision	Recall	f1-score
VGG-16	Healthy	1.0	1.0	1.0	1.0
	RedRot	0.98	0.9509	0.97	0.9603
	RingSpot	0.9675	0.9677	0.9	0.9326
	Rust	0.9725	0.9238	0.97	0.9463
ResNet-50	Healthy	0.9975	1.0	0.99	0.9949
	RedRot	0.97	0.9489	0.93	0.9393
	RingSpot	0.9675	0.9393	0.93	0.9346
	Rust	0.975	0.9326	0.97	0.9509
DenseNet-121	Healthy	0.9925	0.9708	1.0	0.9852
	RedRot	0.985	0.97	0.97	0.97
	RingSpot	0.99	1.0	0.96	0.9795
	Rust	0.9775	0.9504	0.96	0.9552
AlexNet	Healthy	0.995	0.99	0.99	0.99
	RedRot	0.9675	0.9142	0.96	0.9365
	RingSpot	0.9725	0.9684	0.92	0.9435
	Rust	0.975	0.95	0.95	0.950
GoogLeNet	Healthy	0.9825	0.9514	0.98	0.9655
	RedRot	0.9375	0.8640	0.89	0.8768
	RingSpot	0.95	0.9081	0.89	0.8989
	Rust	0.955	0.9270	0.89	0.9081

คำนวณค่าเฉลี่ยของ f1- score (average f1-scores) โดยวิธีการหาค่า average f1-scores ด้วยวิธี Macro-average method (Gowda et al., 2021; Yap et al., 2021) เพื่อที่จะหาโมเดลในการจำแนกประเภทของใบอ้อยที่ได้ผลลัพธ์ดีที่สุด ในแต่ละรูปแบบของชุดข้อมูลการจำแนกทั้ง 3 แบบ ซึ่งผลการจำแนกโรคใบอ้อยด้วยวิธีการเรียนรู้เชิงลึก ดังตาราง 12 ซึ่งพบว่าโมเดล DenseNet-121 ใช้ Train data=90% นั้น มีค่าความแม่นยำโดยรวม (Average Precision) สูงที่สุด


อยู่ที่ 97.28% และค่า macro-average สูงที่สุดอยู่ที่ 97.25% จึงทำให้ผู้วิจัยนำโมเดลนี้ไปใช้ในการพัฒนาระบบวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยเพื่อรองรับการเป็นเกษตรอัจฉริยะ ในลำดับต่อไป

ตาราง 12 ผลการเปรียบเทียบประสิทธิภาพโมเดล


Model	Train data	Training_Time	Average Precision	Macro average
VGG-16	75%	18.04m	0.9631	0.9630
	80%	19.50m	0.9662	0.9662
	90%	21.41m	0.9606	0.9598
ResNet-50	75%	10.50m	0.9655	0.9650
	80%	11.55m	0.9699	0.9699
	90%	12.38m	0.9552	0.9550
DenseNet-121	75%	11.36m	0.9671	0.9670
	80%	12.16m	0.9674	0.9674
	90%	13.47m	0.9728	0.9725
AlexNet	75%	5.07m	0.9573	0.9570
	80%	5.32m	0.9461	0.9460
	90%	5.42m	0.9556	0.9550
GoogLeNet	75%	6.10m	0.9472	0.9469
	80%	6.15m	0.9425	0.9424
	90%	7.04m	0.9126	0.9123

4.5 ผลการพัฒนาระบบ LINE Chatbot


ระบบ LINE Chatbot ในการวิเคราะห์ตรวจสอบโรคอ้อย ด้วยภาพถ่ายใบอ้อยที่ผู้วิจัยได้พัฒนาขึ้นด้วยโมเดล DenseNet-121 ซึ่ง Train data=90% นั้น วิเคราะห์หรือทำนายโรคอ้อย ได้คือ โรคเส้นกลางใบแดง โรคใบจุดวงแหวน โรคราสนิม และใบอ้อยที่ไม่เป็นโรคใด ๆ ซึ่งระบบสามารถวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อย และตอบกลับผู้ใช้แบบอัตโนมัติได้อย่างมีประสิทธิภาพ ดังภาพประกอบ 61 – 64




ภาพประกอบ 61 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่ไม่เป็นโรคใด ๆ



ภาพประกอบ 62 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง



ภาพประกอบ 63 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน



ภาพประกอบ 64 ทดสอบ LINE Chatbot ด้วยภาพใบอ้อยที่เป็นโรคราสนิม

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ในขั้นตอนการทดลองนี้จะนำชุดข้อมูลที่ได้จัดเตรียมไว้มาทดลองกับวิธีการที่ออกแบบไว้ โดยใช้โมเดล CNN ที่มีโครงสร้างที่ต่างกัน 5 แบบ คือ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet ซึ่งใช้ Google Colab รันไทม์แบบ Python 3 ใช้เร่งฮาร์ดแวร์แบบ T4GPU เป็นเครื่องมือในการทดลองการเรียนรู้เชิงลึก ทำให้สามารถประมวลผลได้บนหน่วยประมวลผลด้านกราฟิก (Graphics Processing Unit: GPU) เพื่อใช้สำหรับการจำแนกตรวจสอบโรคจากภาพใบอ้อย โดยทดสอบกับชุดข้อมูล 1 ชุดข้อมูลคือ Sugarcane Leaf Disease Dataset ซึ่งมีจำนวนรูปภาพทั้งหมด 4,000 ภาพ คือ ชุดข้อมูลรูปภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง รูปภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน และรูปภาพใบอ้อยที่เป็นโรคราสนิม มีจำนวนอย่างละ 1,000 ภาพ และชุดข้อมูลรูปภาพที่ใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ มีจำนวน 1,000 ภาพ โดยรูปภาพทั้งหมดเป็นภาพที่อยู่ในสภาพแวดล้อมทางธรรมชาติที่มีลักษณะเด่นในภาพอย่างน้อย 1 อย่าง ซึ่งทำการแบ่งชุดข้อมูลออกเป็น 3 แบบ คือ 75:25, 80:20 และ 90:10 เพื่อใช้เป็นข้อมูลในการ Train Data และ Test Data ตามลำดับ

การทดลองเปรียบเทียบประสิทธิภาพของโมเดล พบว่า ชุดข้อมูลที่ Train Data 75% ทำการทดสอบด้วยชุดข้อมูลในการทดสอบ (Test Data) แล้วนั้น โมเดล DenseNet-121 มีค่าความแม่นยำโดยรวม (Average Precision) อยู่ที่ 96.71% และมีค่า macro-average อยู่ที่ 96.70% ชุดข้อมูลที่ Train Data 80% นั้น โมเดล ResNet-50 ค่าความแม่นยำโดยรวม (Average Precision) อยู่ที่ 96.99% และมีค่า macro-average อยู่ที่ 96.99% และชุดข้อมูลที่ Train Data 90% นั้น โมเดล DenseNet-121 ค่าความแม่นยำโดยรวม (Average Precision) อยู่ที่ 97.28% และมีค่า macro-average อยู่ที่ 97.25%

จากผลการทดลองการวิจัยสามารถสรุปได้ว่าการใช้เทคนิคการเรียนรู้เชิงลึกใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network: CNN) โดยใช้โครงสร้างแบบ DenseNet-121 เหมาะสมสำหรับนำไปใช้ในการวิเคราะห์ตรวจสอบโรคจากภาพใบอ้อยที่อยู่ในสิ่งแวดล้อมทางธรรมชาติ เนื่องจากมีอัตราความแม่นยำโดยรวมมากที่สุด

5.2 การอภิปรายผล


งานวิจัยฉบับนี้ รูปภาพที่ใช้ในงานวิจัย เป็นชุดข้อมูลภาพถ่ายใบอ้อยที่ผู้วิจัยรวบรวมจัดเก็บในพื้นที่กลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง ซึ่งประกอบด้วย 4 จังหวัด ได้แก่ จังหวัดมหาสารคาม จังหวัดขอนแก่น จังหวัดกาฬสินธุ์ และจังหวัดร้อยเอ็ด ซึ่งรวบรวมรูปภาพใบอ้อย 1 ชุด ข้อมูล จำนวนทั้งสิ้น 4,000 ภาพ ประกอบด้วย รูปภาพใบอ้อยที่เป็นโรคเส้นกลางใบแดง รูปภาพใบอ้อยที่เป็นโรคใบจุดวงแหวน และรูปภาพที่เป็นโรคราสนิม มีจำนวนอย่างละ 1,000 ภาพ รูปภาพที่ใบอ้อยปกติ หรือไม่เป็นโรคใด ๆ มีจำนวน 1,000 ภาพ โดยรูปภาพทั้งหมดเป็นภาพที่อยู่ในสภาพแวดล้อมทางธรรมชาติที่มีลักษณะเด่นในภาพอย่างน้อย 1 อย่าง ในการวิจัยนี้นั้นได้ทำการปรับขนาดรูปภาพให้มีขนาด 256x256 พิกเซล โดยชุดข้อมูลจะถูกแบ่งด้วยสัดส่วน 3 แบบ คือ ร้อยละ 75:25, 80:20 และ 90:10 ใช้โมเดล CNN ที่มีโครงสร้างที่ต่างกัน 5 แบบ คือ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet ซึ่งใช้ Google Colab รันไทม์แบบ Python 3 ใช้เร่งฮาร์ดแวร์แบบ T4GPU เป็นเครื่องมือในการทดลองการเรียนรู้เชิงลึก ทำให้สามารถประมวลผลได้บนหน่วยประมวลผลด้านกราฟฟิก (Graphics Processing Unit: GPU) เพื่อใช้สำหรับการจำแนกตรวจสอบโรคจากภาพใบอ้อย

ข้อมูลที่น่ามาทดสอบในการรู้จำนี้เป็นข้อมูลที่ถูกสุ่มแยกออกมาจากชุดข้อมูลทั้งหมด เพื่อใช้เป็นข้อมูลที่ใช้ในการทดสอบ (Test Set) เพื่อนำผลที่ได้มาใช้สำหรับทดสอบหา Metrics หลังจาก Train Data เสร็จ ว่า โมเดลจะทำงานได้ดีแค่ไหนกับข้อมูลที่ไม่เคยเห็นมาก่อน เพื่อหาโมเดลที่ได้ผลการจำแนกที่ดีที่สุด โดยพิจารณาจากอัตราความแม่นยำโดยรวมของโมเดล และอัตราความถูกต้องของโมเดลที่ดีที่สุด

5.3 ข้อเสนอแนะและงานวิจัยในอนาคต

การเรียนรู้เชิงลึก (Deep Learning) จำเป็นต้องใช้ชุดข้อมูลรูปภาพจำนวนมากในการเรียนรู้ เพื่อให้มีอัตราการรู้จำเพิ่มมากขึ้น และควรมีลักษณะของรูปภาพที่หลากหลายแบบ งานวิจัยครั้งถัดไป จะมีการประยุกต์ใช้เทคนิคการเพิ่มจำนวนของชุดข้อมูลเรียนรู้ (Data Augmentation) ซึ่งจะทำให้มีข้อมูลสำหรับการเรียนรู้เพิ่มขึ้น และใช้เทคนิคการถ่ายโอนความรู้ (Transfer Learning) ซึ่งจะช่วยลดระยะเวลาในการเรียนรู้ของเครื่อง ซึ่งอาจจะส่งผลให้ประสิทธิภาพในการเรียนรู้เพิ่มขึ้น

บรรณานุกรม



- [1] สำนักงานเศรษฐกิจการเกษตร กระทรวงเกษตรและสหกรณ์, “วารสารเศรษฐกิจการเกษตร,” 2566. [Online]. Available: www.oae.go.th
- [2] เสวตฉัตร เศษโถ, จริยา นามวงษา, นันทวุฒิ จงรังกลาง, และ พัชริน ส่งศรี, “ผลของการปลูก ร่วมกันสองพันธุ์ต่อการให้ผลผลิตและองค์ประกอบผลผลิตของอ้อย,” *วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม*, vol. 39, no. 2, pp. 182–189, 2020.
- [3] สำนักงานคณะกรรมการอ้อยและน้ำตาลทราย, “รายงานสถานการณ์การปลูกอ้อย ปีการผลิต 2565/66,” 2566.
- [4] สถาบันยุทธศาสตร์และประสานความร่วมมือเพื่อพัฒนาภาคตะวันออกเฉียงเหนือ มหาวิทยาลัยขอนแก่น, “โครงการจัดทำแผนยุทธศาสตร์การพัฒนากลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง ระยะ 20 ปี (พ.ศ.2560-2579),” 2561.
- [5] ธวัช หะหมาน, “คู่มือวินิจฉัยโรคอ้อย,” 2559.
- [6] A. Shrestha and A. Mahmood, “Review of deep learning algorithms and architectures,” *IEEE Access*, vol. 7. Institute of Electrical and Electronics Engineers Inc., pp. 53040–53065, 2019. doi: 10.1109/ACCESS.2019.2912200.
- [7] K. Simonyan and A. Zisserman, “Very Deep Convolutional Networks for Large-Scale Image Recognition,” pp. 1–15, Sep. 2015, [Online]. Available: <http://arxiv.org/abs/1409.1556>
- [8] K. He, X. Zhang, S. Ren, and J. Sun, “Deep residual learning for image recognition,” in *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, IEEE Computer Society, Dec. 2016, pp. 770–778. doi: 10.1109/CVPR.2016.90.
- [9] G. Jee, H. Gm, M. K. Gourisaria, V. Singh, S. S. Rautaray, and M. Pandey, “Efficacy Determination of Various Base Networks in Single Shot Detector for Automatic Mask Localisation in a Post COVID Setup,” *Journal of Experimental and Theoretical Artificial Intelligence*, vol. 35, no. 3, pp. 345–364, 2023, doi: 10.1080/0952813X.2021.1960638.

- [10] A. Krizhevsky, I. Sutskever, and G. E. Hinton, “ImageNet Classification with Deep Convolutional Neural Networks,” 2012. [Online]. Available: <http://code.google.com/p/cuda-convnet/>
- [11] Christian Szegedy *et al.*, “Going Deeper with Convolutions,” *IEEE Computer Society*, pp. 1–9, 2015.
- [12] ณัฐวดี หงษ์บุญมี และ ธนวัฒน์ สิทธิโชคชัยศิริ, “การพัฒนาโปรแกรมประยุกต์วิเคราะห์สุขภาพดวงตาด้วยการรู้จำภาพและการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก,” *วารสารศรีปทุมปริทัศน์ ฉบับวิทยาศาสตร์และเทคโนโลยี*, vol. 13, 2564.
- [13] อภิวัฒน์ คุณธรรมรัตน์, “ต้นทุนจากการปลูกอ้อย การเก็บเกี่ยว การบำรุงรักษาอ้อยหลังเก็บเกี่ยว และผลตอบแทนของธุรกิจปลูกอ้อย อำเภอเก้าเลี้ยว จังหวัดนครสวรรค์,” มหาวิทยาลัยเทคโนโลยีราชมงคลรัตนโกสินทร์, 2559.
- [14] ณัฐวดี หงษ์บุญมี และ ณัฐพงศ์ จันทะวงศ์, “การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกเพื่อวัดระดับความหวานของแตงโมผ่านสมาร์ตโฟน,” *วารสารวิทยาการและเทคโนโลยีสารสนเทศ*, vol. 10, no. 1, pp. 59–69, 2020.
- [15] จิตศักดิ์ โพธิ์ทอง, ประสิทธิ์ เมฆอรุณ, และ สิทธิชัย ชูสำโรง, “การพัฒนาระบบฟาร์มอัจฉริยะสำหรับเกษตรกรยุคใหม่ด้วยซอฟต์แวร์รหัสเปิดและอินเทอร์เน็ตของสรรพสิ่ง,” *เกษตรนเรศวร*, vol. 16, no. 2, pp. 10–17, 2562.
- [16] เขาวรรณ พุทธรักษา, ไกรรุ่ง เสงพะพรหม, และ สุพจน์ เสงพะพรหม, “การพัฒนาแซททอปต้นแบบสำหรับตอบคำถามอัตโนมัติและการพยากรณ์ค่า PM2.5,” in *การประชุมวิชาการระดับชาติ ครั้งที่ 15 มหาวิทยาลัยราชภัฏนครปฐม*, มหาวิทยาลัยราชภัฏนครปฐม, 2023, pp. 586–599.
- [17] อภิชัย ตระหง่าศรี, “การพัฒนาระบบสนทนาอัตโนมัติเพื่อแสดงผลข้อมูลการเรียนรู้ผ่านไลน์แซททอป,” *วารสารสหวิทยาการสังคมศาสตร์และการสื่อสาร*, vol. 2, no. 6, pp. 127–138, 2566.
- [18] T. Carneiro, R. V. M. Da Nobrega, T. Nepomuceno, G. Bin Bian, V. H. C. De Albuquerque, and P. P. R. Filho, “Performance Analysis of Google Colaboratory

- as a Tool for Accelerating Deep Learning Applications,” *IEEE Access*, vol. 6, pp. 61677–61685, 2018, doi: 10.1109/ACCESS.2018.2874767.
- [19] M. Canesche, L. Bragança, O. P. V. Neto, J. A. Nacif, and R. Ferreira, “Google Colab CAD4U: Hands-on cloud laboratories for digital design,” in *Proceedings - IEEE International Symposium on Circuits and Systems*, Institute of Electrical and Electronics Engineers Inc., 2021. doi: 10.1109/ISCAS51556.2021.9401151.
- [20] จนประสงค์ อยู่พิศิษฐ์ไตรวัตติ, “การประยุกต์ใช้ระบบสารสนเทศภูมิศาสตร์ในการศึกษาการระบาดของโรคสัปดาห์ที่ 1 ในอำเภอศรีนครินทร์ จังหวัดสระแก้ว,” *มหาวิทยาลัยธรรมศาสตร์*, 2562.
- [21] มิตรพลโมเดิร์นฟาร์ม, “4 โรคภัยที่เกิดกับอ้อยพันธุ์ขอนแก่น 3.” Accessed: Mar. 14, 2023. [Online]. Available: <https://www.mitrpholmodernfarm.com/news/2018/04/4-โรคภัยที่เกิดกับอ้อยพันธุ์ขอนแก่น-3>
- [22] ธวัช หะหมาน, “โรคและแมลงศัตรูอ้อยที่สำคัญ.”
- [23] ศุภชัยชัยพิชไรสุพรรณบุรี, “การป้องกันกำจัดศัตรูอ้อยแบบผสมผสาน.”
- [24] V. Kakani, V. H. Nguyen, B. P. Kumar, H. Kim, and V. R. Pasupuleti, “A critical review on computer vision and artificial intelligence in food industry,” *Journal of Agriculture and Food Research*, vol. 2. Elsevier B.V., Dec. 01, 2020. doi: 10.1016/j.jafr.2020.100033.
- [25] R. Szeliski, “Computer Vision: Algorithms and Applications,” 2010. [Online]. Available: <http://szeliski.org/Book/>.
- [26] R. Dal'nevostochnyi federal'nyi universitet (Vladivostok and Institute of Electrical and Electronics Engineers, “Boundary Detection in Images in Intelligent Systems of Autonomous Vehicles Using Wavelet Transform,” *2020 International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon)*, 2020.


- [27] J. G. Shanahan and L. Dai, "Introduction to Computer Vision and Real Time Deep Learning-based Object Detection," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Association for Computing Machinery, Aug. 2020, pp. 3523–3524. doi: 10.1145/3394486.3406713.
- [28] R. C. Gonzalez, R. E. Woods, and P. Prentice Hall, "Digital Image Processing Third Edition Pearson International Edition prepared by Pearson Education," 2008.
- [29] Milan Sonka, Vaclav Hlavac, and Roger Boyle, "Image Processing, Analysis, and Machine Vision," 2014.
- [30] อนุสรณ์ เกิดศรี, "การวิเคราะห์พฤติกรรมการเรียนรู้ในหลักสูตรออนไลน์ระบบเปิด: การประยุกต์ใช้การเรียนรู้ด้วยเครื่องและการเรียนรู้เชิงลึก," *วารสารการวัด ประเมินผล สถิติ และการวิจัยทางสังคมศาสตร์*, vol. 2, no. 2, pp. 14–28, 2564.
- [31] D. Del Vento and A. Fanfarillo, "Traps, pitfalls and misconceptions of machine learning applied to scientific disciplines," in *ACM International Conference Proceeding Series*, Association for Computing Machinery, Jul. 2019. doi: 10.1145/3332186.3332209.
- [32] นพรัตน์ มาน้อย, อำพล บุญจันดา, และ ชูพันธุ์ รัตนโกศา, "ระบบแบ่งปันสูตรการทำอาหารและค้นหาสูตรการทำอาหารจากภาพวัตถุดิบด้วยเทคนิคการเรียนรู้เชิงลึก," *วารสารวิชาการเทคโนโลยีอุตสาหกรรม*, vol. 15, no. 2, pp. 97–111, 2562.
- [33] J. Dean et al., "Large Scale Distributed Deep Networks," *Adv Neural Inf Process Syst*, vol. 25, pp. 1–9, 2012.
- [34] A. B. Nassif, I. Shahin, I. Attili, M. Azzeh, and K. Shaalan, "Speech Recognition Using Deep Neural Networks: A Systematic Review," *IEEE Access*, vol. 7, pp. 19143–19165, 2019, doi: 10.1109/ACCESS.2019.2896880.

- [35] อุมารณณ์ สายแสงจันทร์, รพีพร ชำชอง, และ อรรถพล สุวรรณษา, “การเปรียบเทียบวิธีการวิเคราะห์โรคใบมะนาวด้วยการเรียนรู้เชิงลึก,” *วารสารวิทยาการสารสนเทศและเทคโนโลยีประยุกต์*, vol. 4, no. 1, pp. 71–86, 2565.
- [36] ณัฐวดี หงษ์บุญมี และ จุฑามาศ กันยาประสิทธิ์, “การวิเคราะห์ปัญหาสุขภาพจากภาพถ่ายเล็บด้วยเทคนิคการเรียนรู้เชิงลึก,” *วารสารวิทยาการและเทคโนโลยีสารสนเทศ*, vol. 11, no. 2, pp. 10–20, 2564.
- [37] ภูมิรพี ภูมิคำ, “เทคนิคการเรียนรู้เชิงลึกเพื่อวิเคราะห์ความรู้สึกจากผู้ใช้ผลิตภัณฑ์,” มหาวิทยาลัยเทคโนโลยีสุรนารี, นครราชสีมา, 2562.
- [38] T. Gowda, W. You, C. Lignos, and J. May, “Macro-Average: Rare Types Are Important Too,” 2021. [Online]. Available: <https://github.com/isi-nlp/sacrebleu/tree/>
- [39] M. H. Yap, B. Cassidy, J. M. Pappachan, C. O’Shea, D. Gillespie, and N. D. Reeves, “Analysis towards classification of infection and ischaemia of diabetic foot ulcers,” in *BHI 2021 - 2021 IEEE EMBS International Conference on Biomedical and Health Informatics, Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2021. doi: 10.1109/BHI50953.2021.9508563.
- [40] B. D. Thakare and D. V. Rojatkhar, “A Review on Smart Agriculture using IoT,” in *Proceedings of the 6th International Conference on Communication and Electronics Systems, ICCES 2021*, Institute of Electrical and Electronics Engineers Inc., Jul. 2021, pp. 500–502. doi: 10.1109/ICCES51350.2021.9489109.
- [41] M. Dhanaraju, P. Chenniappan, K. Ramalingam, S. Pazhanivelan, and R. Kaliaperumal, “Smart Farming: Internet of Things (IoT)-Based Sustainable Agriculture,” *Agriculture (Switzerland)*, vol. 12, no. 10. MDPI, Oct. 01, 2022. doi: 10.3390/agriculture12101745.
- [42] MICE Interlligence Center, “เกษตรอัจฉริยะนำไปสู่การผลิตพืชผลอย่างยั่งยืนเพื่ออนาคตของประเทศไทย,” 2018.

- [43] สำนักงานพัฒนาการวิจัยการเกษตร (องค์การมหาชน), “เกษตรอัจฉริยะความหวังใหม่ของภาคการเกษตรไทย.” Accessed: May 24, 2023. [Online]. Available: https://www.arda.or.th/knowledge_detail.php?id=7
- [44] สำนักข่าว กรมประชาสัมพันธ์, “เข้ารับนโยบายเปิดตัวแผนปฏิบัติการเกษตรอัจฉริยะ ปี 65-65 จากรัฐมนตรีว่าการกระทรวงเกษตรและสหกรณ์ (ดร.เฉลิมชัย ศรีอ่อน) ผ่านระบบการประชุมทางไกลออนไลน์ Zoom meeting.” Accessed: May 24, 2023. [Online]. Available: <https://thainews.prd.go.th/th/news/detail/TCATG211007214531318>
- [45] LINE Developers, “Messaging API.” Accessed: Jan. 15, 2024. [Online]. Available: <https://developers.line.biz/en/services/messaging-api/>
- [46] เตชินท์ วรสิทธิ์ และคณะ, “การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกสำหรับการรู้จำโรคขอบใบแห้งและโรคไหม้ของข้าว,” *วารสารแก่นเกษตร* 50, vol. 1, pp. 216–228, 2565, doi: 10.14456/kaj.2022.18.
- [47] ธนภัทร มัชฌาฬ, สุทธิพงษ์ ดวงสุภา, และ รัตนาวดี พานทอง, “การพัฒนาเว็บแอปพลิเคชันเพื่อจำแนกกล้วยต่างด้วยเทคนิคการเรียนรู้ของเครื่อง,” *วารสารวิชาการการประยุกต์ใช้เทคโนโลยีสารสนเทศ*, vol. 8, no. 2, pp. 56–66, 2565.
- [48] ศรัญญา กาญจนวัฒนา, วรวิทย์ ตีรวัดนประภา, ปัญญชลี ปราณีตพลกรัง, และ กัญจน์ รักดีสงคราม, “การจำแนกระดับความหวานของสับปะรดโดยใช้การเรียนรู้เชิงลึก,” *วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏศรีสะเกษ*, vol. 2, no. 1, pp. 53–63, 2565.
- [49] พิจิตรา จอมศรี, ดุลยวิทย์ ปรางชุมพล, และ บุศรินทร์ เอี่ยมธนากุล, “การพัฒนาระบบตรวจวินิจฉัยโรคใบของดาวเรืองด้วยเทคโนโลยีไอโอทีเพื่อรองรับการเป็นเกษตรอัจฉริยะ,” *วารสารวิทยาสารสนเทศและเทคโนโลยี*, vol. 2, no. 2, pp. 15–24, 2564.
- [50] จักรินทร์ สนุกแสน และ โอฟาริก สุรินตะ, “โครงข่ายประสาทเทียมแบบคอนโวลูชันเชิงลึกสำหรับการจำแนกพรรณไม้,” *วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม*, vol. 38, no. 2, pp. 113–124, 2562.

- [51] ศุภพงศ์ สกุลคุ, จุฑามาศ ภูยวงศ์, และ ธนพล ตั้งชูพงศ์, “การรู้จำอาหารไทยและคำนวณคุณค่าโภชนาการผ่านไลน์แชทบอทด้วยกระบวนการเรียนรู้เชิงลึก,” *Rattanakosin Journal of Science and Technology: RJST*, vol. 4, no. 2, pp. 19–31, 2022.
- [52] Prem Enkvetchakul and Olarik Surinta, “Effective data augmentation and training techniques for improving deep learning in plant leaf disease recognition,” 2022.
- [53] M. Hammad Saleem, S. Khanchi, J. Potgieter, and K. Mahmood Arif, “Image-based plant disease identification by deep learning meta-architectures,” *Plants*, vol. 9, no. 11, pp. 1–23, Nov. 2020, doi: 10.3390/plants9111451.
- [54] M. Arsenovic, M. Karanovic, S. Sladojevic, A. Anderla, and D. Stefanovic, “Solving current limitations of deep learning based approaches for plant disease detection,” *Symmetry (Basel)*, vol. 11, no. 7, Jul. 2019, doi: 10.3390/sym11070939.
- [55] A. Adedaja, & Pius, A. Owolawi, and T. Mapayi, “Deep Learning Based on NASNet for Plant Disease Recognition Using Leave Images,” 2019.
- [56] P. Temniranrat, K. Kiratiratanapruk, A. Kitvimonrat, W. Sinthupinyo, and S. Patarapuwadol, “A system for automatic rice disease detection from rice paddy images serviced via a Chatbot,” *Comput Electron Agric*, vol. 185, Jun. 2021, doi: 10.1016/j.compag.2021.106156.
- [57] L. Falaschetti, L. Manoni, D. Di Leo, D. Pau, V. Tomaselli, and C. Turchetti, “A CNN-based image detector for plant leaf diseases classification,” 2022, doi: 10.17605/OSF.IO/UCM8D.
- [58] ทรงกรด พิมพิศาล และ ณัฐวุฒิ ศรีวิบูลย์, “การประมวลผลภาพสำหรับการจำแนกรูปภาพพันธุ์สโดยใช้การเรียนรู้เชิงลึก,” *Journal of Information Science and Technology*, vol. 10, no. 2, pp. 19–25, 2020.

- [59] T. Chompookham and O. Surinta, "Ensemble methods with deep convolutional neural networks for plant leaf recognition," *ICIC Express Letters*, vol. 15, no. 6, pp. 553–565, Jun. 2021, doi: 10.24507/icicel.15.06.553.
- [60] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, "Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer," in *Procedia Computer Science*, Elsevier B.V., 2021, pp. 423–431. doi: 10.1016/j.procs.2021.01.025.
- [61] R. J. S. Raj, S. J. Shobana, I. V. Pustokhina, D. A. Pustokhin, D. Gupta, and K. Shankar, "Optimal feature selection-based medical image classification using deep learning model in internet of medical things," *IEEE Access*, vol. 8, pp. 58006–58017, 2020, doi: 10.1109/ACCESS.2020.2981337.
- [62] V. Madaan *et al.*, "XCOVNet: Chest X-ray Image Classification for COVID-19 Early Detection Using Convolutional Neural Networks," *New Gener Comput*, vol. 39, no. 3–4, pp. 583–597, Nov. 2021, doi: 10.1007/s00354-021-00121-7.



ประวัติผู้เขียน

ชื่อ	ศุภชัย ใบปอด
วันเกิด	26 กุมภาพันธ์ 2536
สถานที่เกิด	อำเภอโกสุมพิสัย จังหวัดมหาสารคาม
สถานที่อยู่ปัจจุบัน	326/32 หมู่ 8 ตำบลเกิ้ง อำเภอเมืองมหาสารคาม จังหวัดมหาสารคาม 44000
ตำแหน่งหน้าที่การงาน	นักวิชาการคอมพิวเตอร์ปฏิบัติการ
สถานที่ทำงานปัจจุบัน	สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏมหาสารคาม
ประวัติการศึกษา	2549-2554 มัธยมศึกษาตอนต้น-ตอนปลาย โรงเรียนโกสุมวิทยาสรรค์ 2555-2559 วิทยาศาสตร์บัณฑิต (วท.บ.) สาขาวิศวกรรมซอฟต์แวร์ คณะ วิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏมหาสารคาม

พูน ปณ จิตโต ชีเว