

การผสาน InceptionResNetV2 และ VGG19 สำหรับการจดจำโรคใบอ้อย

Integration of InceptionResNetV2 with VGG19 for sugarcane leaf disease recognition

เอกรัตน์ สุขสุคนธ์^{1*}
Aekkarat Suksukont^{1*}

บทคัดย่อ

การพัฒนาเทคนิคการจดจำโรคใบอ้อยถือเป็นแนวทางที่ท้าทาย เนื่องจากต้องเผชิญกับความหลากหลายของลักษณะโรคที่แสดงออกแตกต่างกันไปตามคุณลักษณะของใบพืช ไม่ว่าจะเป็นสี รูปร่าง พื้นผิว และรูปแบบการกระจายของโรคในเชิงพื้นที่ ซึ่งมีความซับซ้อนและเปลี่ยนแปลงได้ตามสภาวะแวดล้อม การวิเคราะห์ลักษณะดังกล่าวจึงจำเป็นต้องอาศัยเทคนิคขั้นสูงด้านการประมวลผลภาพและการเรียนรู้ของเครื่องเพื่อให้สามารถจดจำโรคได้อย่างแม่นยำ การศึกษานี้นำเสนอการผสานโครงข่าย InceptionResNetV2 และ VGG19 โดยใช้ convolutional layers เป็นองค์ประกอบหลักของสถาปัตยกรรม เนื่องจากข้อได้เปรียบของ inception module ในการวิเคราะห์คุณลักษณะที่หลากหลายของโรคพืชไปพร้อมกับ residual connection ทำให้โครงข่ายลดการสูญเสียข้อมูลโรคพืชในเครือข่ายที่มีความลึกมากยิ่งขึ้น โมเดลที่นำเสนอได้รับการฝึกอบรมและทดสอบด้วยชุดข้อมูลโรคใบอ้อย พร้อมทั้งเปรียบเทียบผลลัพธ์กับก่อนหน้า ผลการทดลองแสดงว่าโมเดลสามารถบรรลุความแม่นยำสูงสุดที่ร้อยละ 99.25 มีผลของ Loss ที่ 0.0263 และสูญเสียเวลาการฝึกอบรมที่ 24.55 นาที ผลการศึกษานี้ไม่เพียงแต่แสดงให้เห็นถึงประสิทธิภาพของโมเดลในการจดจำโรคใบอ้อย แต่ยังเป็นแนวทางสำคัญในการพัฒนาเทคโนโลยีตรวจจับโรคพืชในระดับอุตสาหกรรม

คำสำคัญ: การเรียนรู้เชิงลึก โครงข่ายคอนโวลูชัน การผสานโครงข่าย การจดจำโรคใบอ้อย

Abstract

The development of sugarcane leaf disease recognition techniques is challenging due to the diversity of disease characteristics expressed through variations in leaf color, shape, texture, and spatial distribution patterns, which are complex and influenced by environmental conditions. Therefore, advanced image processing and machine learning techniques are essential for accurately recognizing the sugarcane leaf disease. This study presented an integration of InceptionResNetV2 with VGG19 networks using convolutional layers as the main components of the architecture, due to the advantages of the inception module for diverse feature analysis combined with residual connections to address the issue of data loss in deep networks. The proposed model was trained and tested on sugarcane leaf disease dataset and compared with the previous results. Experimental results showed that the model achieved an accuracy of 99.25%, a loss of 0.0263, and a training time of 24.55 minutes. The results of this study not only demonstrated the model's effectiveness in recognizing sugarcane leaf disease but also provided important guidelines for developing plant disease technologies on an industrial scale.

Keywords: deep learning, convolutional neural network, integrating network, leaf disease recognition

¹ คณะครุศาสตร์อุตสาหกรรม มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ

¹ Faculty of Industrial Education, Rajamangala University of Technology Suvarnabhumi

* Corresponding author. E-mail: aekkarat.s@rmutsb.ac.th

บทนำ

ผลผลิตทางการเกษตรมีบทบาทสำคัญต่อการสร้างรายได้และยกระดับคุณภาพชีวิตของประชากร รวมถึงส่งเสริมการพัฒนาเศรษฐกิจอย่างยั่งยืน (Singh et al., 2023) อย่างไรก็ตาม ผลผลิตที่ได้นั้นต้องเผชิญกับความท้าทายจากการสูญเสียที่เกิดจากโรคพืช (Raza & Bebbber, 2022; Lahlali et al., 2024) ปัญหาที่เกิดจากการติดเชื้อรา ไวรัส รวมถึงปัจจัยทางสิ่งแวดล้อม เช่น ปริมาณน้ำฝน อุณหภูมิ และความชื้น เหล่านี้ส่งผลให้เกิดการกระจายของโรค ซึ่งการจัดการปัญหาต้องอาศัยความชำนาญของเกษตรกรในการจดจำและวินิจฉัย แม้ว่าการตรวจสอบโรคพืชด้วยวิธีดั้งเดิมจะยังคงใช้กันอยู่อย่างแพร่หลาย แต่มีข้อจำกัดด้านความแม่นยำและความเร็ว ในทางกลับกัน เทคนิค deep learning (DL) ได้แสดงศักยภาพในการตรวจจับและจดจำโรคพืชได้อย่างรวดเร็วและแม่นยำยิ่งขึ้น (Moupojou et al., 2023; Hosny et al., 2023)

การประยุกต์ใช้และพัฒนา DL สำหรับโรคพืช เป็นความก้าวหน้าที่ช่วยให้เกษตรกรสามารถระบุโรคได้อย่างแม่นยำ (Bhargava et al., 2024) พื้นฐานของเทคนิคนี้นำลักษณะเด่นหรือข้อมูลของโรคนั้น ๆ มาวิเคราะห์ เช่น สีของใบ ความผิดปกติบนผิวใบ และลักษณะสัญญาณรบกวน ข้อมูลภาพเหล่านี้ถูกนำมาจัดเตรียมเป็นชุดข้อมูลเพื่อใช้ในการฝึกอบรมโครงข่าย ทำให้ได้ผลลัพธ์ที่มีประสิทธิภาพ (Chouhan et al., 2018; Balafas et al., 2023; Madhurya & Jubilson, 2023; Moupojou et al., 2024) ด้วยความก้าวหน้านี้เป็นเหตุให้มีการนำไปพัฒนาเพื่อเพิ่มผลลัพธ์ในการใช้งานในเวลาจริง (real-time) เช่น การนำโมเดล ResNet50, VGG19 และ MobileNetV3Small มาพัฒนา โดยปรับแต่งการทำงานร่วมกับ explainable AI เพื่อเพิ่มประสิทธิภาพในการจำแนกโรคใบ (Salam et al., 2024) การพัฒนา Lightweight 2D CNN สำหรับแอปพลิเคชัน android โดยใช้การทำงานร่วมกับ Grad-CAM เพื่อแสดงบริเวณที่ตรวจพบโรคผ่าน heatmap (Peyal et al., 2023) การผสมผสาน YOLOv3 และ LSTM เพื่อพัฒนาเทคนิคการจดจำโรคพืชที่ทำงานร่วมกับระบบ internet of things (IoT) สำหรับการแจ้งเตือนและบันทึกข้อมูลแบบออนไลน์ (Chen et al., 2020) การใช้ transfer learning และ vision transformer model ซึ่งรวมข้อดีของทั้งสองแนวทางเพื่อจัดการกับความแตกต่างจากลักษณะโรค (Tabbakh & Barpanda, 2023) การพัฒนาโมเดล MaizeNet ซึ่งใช้ CNNs ร่วมกับ faster-RCNN และ ResNet-50 ที่ปรับปรุงให้โครงข่ายโดยผสมผสาน spatial-channel attention mechanism ไปบนโครงข่ายเพื่อเพิ่มประสิทธิภาพในการดึงคุณลักษณะเชิงลึก (Masood et al., 2023) การออกแบบ gated self-attentive convoluted MobileNetV3 ที่รวม gated mechanisms และ self-attention layers เพื่อแก้ปัญหาการประมวลผลล่าช้าสำหรับการตรวจจับแบบเรียลไทม์ (Begum & Syed, 2024) การผสมผสาน few-shot learning ร่วมกับ EfficientNet เพื่อดึงคุณลักษณะของโรคพืช พร้อมทั้งผสมผสาน attention mechanism เพื่อให้โครงข่ายเน้นคุณลักษณะที่เกิดโรคพืช (Anorboev et al., 2023) หรือการแก้ปัญหาข้อมูลที่จำกัดด้วยการประยุกต์ใช้ VGG19 ร่วมกับการถ่ายโอนการเรียนรู้ (Yead et al., 2024) เทคนิคเหล่านี้มีจุดมุ่งหมายเพื่อเพิ่มประสิทธิภาพและเอาชนะความท้าทายจากลักษณะทางกายภาพที่หลากหลายของพืชในสภาพแวดล้อมจริง ส่งผลให้การพัฒนาสามารถเพิ่มความแม่นยำและความรวดเร็วในการตรวจจับและจดจำโรคพืชได้ แนวทางดังกล่าวนี้นับเป็นความก้าวหน้าที่ช่วยยกระดับอุตสาหกรรมเกษตรในยุคปัญญาประดิษฐ์ (Alharbi et al., 2023; Elfatimi et al., 2022; Altabaji et al., 2024; Ramadan et al., 2024)

การศึกษาดังที่กล่าว เป็นการพัฒนาเพื่อเพิ่มผลลัพธ์ในการตรวจจับ จำแนก และจดจำโรคใบพืช แม้ว่าการพัฒนาจะได้รับประสิทธิภาพที่ดีแต่ยังมีข้อจำกัดหลายประการ เช่น ชุดข้อมูลขนาดใหญ่ในการฝึกอบรม ปัญหานี้เป็นอุปสรรคในกรณีที่ข้อมูลมีจำนวนจำกัดและมีความ (Salam et al., 2024) อีกทั้งโมเดลที่ซับซ้อนที่เกิดจากชั้นการทำงานของโครงข่าย เช่น YOLOv3 หรือ MaizeNet ซึ่งเป็นโมเดลขนาดใหญ่ที่ต้องใช้ทรัพยากรประมวลผลสูง รวมถึงการใช้งานในสภาพแวดล้อมที่เกิดแสงตกกระทบใบพืช หรือสัญญาณรบกวนภาพพื้นหลังของใบพืช (Chen et al., 2020; Masood et al., 2023) นอกจากนี้การใช้งานจริงในภาคการเกษตร เช่น การพัฒนาแอปพลิเคชันบนมือถือและระบบ IoT อาจเผชิญปัญหาด้าน

ความเสถียรของเครือข่ายในพื้นที่ชนบท (Chen et al., 2020) รวมถึงข้อจำกัดในการอธิบายถึงผลลัพธ์ (explain ability) ที่เป็นผลมาจากความซับซ้อนของชั้นการทำงานของโมเดล (Begum & Syed, 2024; Salam et al., 2024) หรือ ปัญหาที่มาจากข้อมูลมีความแปรผัน เช่น พื้นหลังของภาพที่ซับซ้อนและไม่สม่ำเสมอ เพื่อเพิ่มผลลัพธ์ของการจดจำโรคใบพืช การศึกษานี้ นำเสนอโครงข่ายที่ผสมผสานกับโครงสร้างเชิงลึก โดย InceptionResNetV2 ถูกเลือกใช้ในการศึกษานี้เนื่องจากมีโครงสร้างที่รวมข้อดีของ inception module และ residual connection ทำให้สามารถเรียนรู้คุณลักษณะที่ซับซ้อนได้อย่างมีประสิทธิภาพ ในขณะที่ VGG19 โดดเด่นในด้านความเรียบง่ายและความสามารถในการจับลักษณะเฉพาะของภาพด้วยโครงสร้างลึก ซึ่งการผสมผสานการทำงานร่วมกันยังโดดเด่นในการดึงคุณลักษณะเชิงลึกได้หลายระดับพร้อมกัน ทำให้โครงข่ายสามารถปรับตัวได้ดีในข้อมูลที่หลากหลาย ส่งผลให้การจดจำโรคพืชมีประสิทธิภาพสูงและเหมาะสมสำหรับการนำไปประยุกต์ใช้ในอุตสาหกรรมการเกษตร

วิธีการศึกษา

การศึกษานี้นำเสนอการผสมผสานการทำงานระหว่าง InceptionResNetV2 และ VGG19 เพื่อเพิ่มประสิทธิภาพในการจดจำโรคใบอ้อยที่มีความซับซ้อน โดย VGG19 มีจุดเด่นในการดึงคุณสมบัติพื้นฐานของภาพอย่างแม่นยำ ในขณะที่ InceptionResNetV2 ใช้ประโยชน์จาก inception module และ residual connection เพื่อลดปัญหา vanishing gradient ที่เกิดจากการเรียนรู้คุณสมบัติที่ซับซ้อนจากข้อมูลภาพหรือลักษณะของการเกิดโรค การผสมผสานโครงข่ายทั้งสองช่วยลดข้อผิดพลาดในการจดจำข้อมูลที่มีความคล้ายคลึงกันและความหลากหลายของลักษณะภาพ ซึ่งแสดงถึงศักยภาพของโครงข่ายและการทำงานที่พัฒนาขึ้น ดัง (Figure 1)




Figure 1 VGG19 with InceptionResNetV2 integration for sugarcane leaf disease recognition.

1. ชุดข้อมูล

จาก (Figure 1) ชุดข้อมูลข้าวโพด (sugarcane leaf disease dataset: SLDD) เป็นชุดข้อมูลที่ถูกเก็บรวบรวมในรัฐมหาราษฏระ ประเทศอินเดีย (Daphal & Koli, 2022) โดยมีวัตถุประสงค์เพื่อใช้ในการฝึกอบรมและทดสอบปัญญาประดิษฐ์ ชุดข้อมูลนี้ประกอบด้วยภาพใบอ้อยทั้งหมด 2,521 ภาพ แบ่งออกเป็น 5 ประเภทหลัก ได้แก่ healthy จำนวน 522 ภาพ, mosaic จำนวน 462 ภาพ, Red rot จำนวน 518 ภาพ, rust จำนวน 514 ภาพ, และ yellow จำนวน 505 ภาพ โดยภาพในชุดข้อมูลมีความหลากหลายทั้งสัญญาณรบกวนพื้นหลัง ตำแหน่งของการเกิดโรค และขนาดของภาพที่แตกต่างกัน ในการศึกษานี้ทดลองโดยแบ่งข้อมูลออกเป็น 3 กลุ่ม ได้แก่ ร้อยละ 60 สำหรับการฝึกอบรม ร้อยละ 20 สำหรับชุดข้อมูลตรวจสอบ และร้อยละ 20 สำหรับชุดข้อมูลทดสอบ ตัวอย่างภาพโรคใบข้าวโพด ดัง (Figure 2)




Figure 2 Sample representation of some sugarcane leaf disease.

2. โครงข่ายการเรียนรู้เชิงลึก

จาก (Figure 2) ชุดข้อมูลใบอ้อยจะถูกกำหนดขนาดที่แตกต่างที่ 200×200 พิกเซล และ 224×224 พิกเซล เพื่อให้โครงข่ายสามารถเรียนรู้ข้อมูลได้หลายระดับ โดยส่งชุดข้อมูลขนาด 200×200 พิกเซล ไปยัง InceptionResNetV2 (Szegedy et al., 2017) เนื่องจากโครงข่ายรวมแนวคิดของ inception module และ residual connection เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ข้อมูลภาพที่ซับซ้อน โครงสร้างเริ่มต้นด้วย stem block สำหรับการดึงคุณสมบัติพื้นฐาน ตามด้วย inception modules ที่ประกอบด้วย convolutional filters ขนาดต่าง ๆ เช่น 1×1 , 3×3 และ 5×5 ซึ่งช่วยดึงข้อมูลหลายระดับ ดังสมการ (1)

$$O_{i,y}^k = \sum_{C=1}^C \sum_{m,n} W_{m,n,C}^k P_{i+m,j+n}^C + b^k \quad (1)$$

เมื่อ $O_{i,y}^k$ คือ ผลลัพธ์ที่ตำแหน่ง (i, j) ของ feature map ที่ k , $W_{m,n,C}^k$ คือ ค่าน้ำหนัก (kernel) ของตัวกรองที่ตำแหน่ง (m, n) สำหรับ C ในตัวกรองที่ k , $P_{i+m,j+n}^C$ คือ พิกเซลที่ตำแหน่ง $(i+m, j+n)$ ใน channel ที่ C , b^k คือ ไบอัส และ C คือ จำนวน channel ของภาพ โดย patch ที่ได้ถูกหลอมรวมผ่านการ concatenate ในขณะเดียวกัน residual connection ซึ่งจะเชื่อมข้อมูลจากชั้นก่อนหน้าเข้าสู่ผลลัพธ์ของ inception modules เพื่อลดปัญหา vanishing gradient และเร่งกระบวนการฝึกฝน ดังสมการ (2)

$$Y = X + F(X) \quad (2)$$

เมื่อ X คือ input ของ residual block, $F(X)$ คือ output จาก convolution layers ภายใน block และ Y คือ ผลลัพธ์จาก residual block โดยข้อมูลยังถูกผสมการทำงานแบบขนานร่วมกับ VGG19 (Mahum, 2023; Yead et al., 2024) ซึ่งรับชุดข้อมูลขนาด 224×224 พิกเซล โดยโครงข่ายมี Convolutional Layers ดังสมการ (1) โดย VGG19 แตกต่างจาก InceptionResNetV2 จากลำดับชั้น โดยใช้ขนาดคอนโวลูชันที่ 64, 128, 256, 512 และ 512 ร่วมกับตัวกรองขนาด

3×3 เพื่อดึงคุณสมบัติพื้นฐานจากภาพ พร้อมด้วย ReLU Activation เพื่อเพิ่มความไม่เป็นเชิงเส้น (non-linearity) ในการเรียนรู้ข้อมูล ในทุก ๆ 2 หรือ 3 เลเยอร์ จะมี MaxPooling Layers เพื่อลดขนาดพีเจอร์แมพและเพิ่มประสิทธิภาพการประมวลผล ทั้งนี้ convolutional layers ของ InceptionResNetV2 และ VGG19 จะถูกผสมการทำงานและส่ง patch เข้าสู่ fully connected layers (FC layer) โดยกำหนดไว้ที่ 512 โหนด ทำงานควบคู่กับ Dropout ที่ 0.2 และ ฟังก์ชัน SoftMax สำหรับจัดจำ

โครงข่ายที่เสนอทดลองด้วยระบบปฏิบัติการ windows ที่ติดตั้ง Intel Core i5-12400f โดยมี RAM 32 GB พร้อมด้วย NVIDIA RTX 4070 ร่วมกับ VRAM 12 GB โดยมี CUDA core จำนวน 5,888 คอร์ เครื่องมือออกแบบโครงข่ายที่เสนอและทดสอบโครงข่ายถูกออกแบบโดย NumPy และ TensorFlow พารามิเตอร์การฝึกอบรมกำหนดไว้ให้เป็นมาตรฐาน ดัง (Table 1)

Table 1 Parameter for training model.

hyper parameter	value
learning rate	10^{-2} , 10^{-3} , 10^{-4} and 10^{-5}
optimization	Adam
loss function	categorical cross entropy
epoch	50
batch size	32

การศึกษานี้ประยุกต์ใช้ accuracy, precision, และ recall เป็นเกณฑ์วัดผล เพื่อประเมินประสิทธิภาพของการเรียนรู้ของโมเดล โดยอาศัยการเปรียบเทียบกับจำนวนข้อมูลที่ไม่เคยสามารถพยากรณ์ได้อย่างถูกต้อง ดังสมการ (3)-(5)

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

เมื่อ true positive (TP) คือกรณีที่ใบพืชมีโรค และโมเดลสามารถระบุโรคได้อย่างถูกต้อง, true negative (TN) คือกรณีที่ใบพืชไม่มีโรค และโมเดลพยากรณ์ว่าเป็นใบพืชไม่มีโรคได้อย่างถูกต้อง, false positive (FP) คือกรณีที่ใบพืชที่ไม่มีโรคและถูกโมเดลพยากรณ์ผิดว่าเป็นใบที่มีโรค และ false negative (FN) คือกรณีที่ใบพืชที่มีโรคและถูกโมเดลพยากรณ์ผิดว่าเป็นใบพืชไม่มีโรค

ผลการศึกษาและอภิปรายผล

เมื่อนำโครงข่ายมาฝึกอบรมด้วยชุดข้อมูลโรคใบอ้อย ดัง (Figure 3) ผลการฝึกอบรมแสดงความสัมพันธ์ระหว่างอัตราการเรียนรู้ (learning rate) และรอบการฝึกอบรม (epoch) โดยผลของ learning rate ที่ 10^{-3} และ 10^{-5} ให้ผลลัพธ์ที่ดีที่สุด

ทั้งในแง่ของ accuracy และ loss ซึ่งมีค่า accuracy สูงสุดที่ร้อยละ 99.14 และร้อยละ 99.25 โดยมีผลของ loss ต่ำสุดที่ 0.0291 และ 0.0263 ตามลำดับ ในทางกลับกัน learning rate ที่ 10^{-2} มีผล accuracy ต่ำสุดที่ร้อยละ 96.83 ผลของ loss ที่ 0.1172 ซึ่งสะท้อนถึงการเรียนรู้ที่ไม่เสถียร เนื่องจากความเร็วในการปรับน้ำหนักที่มากเกินไปทำให้โครงข่ายไม่สามารถตรวจจับลักษณะข้อมูลได้ และผลของ 10^{-4} มีประสิทธิภาพใกล้เคียง 10^{-5} แต่ยังด้อยกว่าในแง่ของ accuracy และ loss




Figure 3 Result of training model.




Figure 4 Precision and recall of training model.

(Figure 4) แสดงผล precision และ recall ของการฝึกอบรมโมเดลในช่วง 50 epochs สำหรับค่า learning rate ต่างๆ พบว่าค่า learning rate 10^{-2} มีผลลัพธ์ที่ดีที่สุดในด้าน precision ด้วยค่าเฉลี่ยสุดท้ายที่ร้อยละ 99.70 ในขณะที่ค่า 10^{-3} , 10^{-4} และ 10^{-5} มีค่า precision อยู่ที่ร้อยละ 98.68, 98.43, และ 99.09 ตามลำดับ ส่วน recall ค่า 10^{-5} มีค่าที่ดีที่สุดที่ร้อยละ 99.04 แสดงถึงความสามารถของโมเดลในการดึงข้อมูลที่เกี่ยวข้องได้อย่างแม่นยำ ในขณะที่ 10^{-2} และ 10^{-3} มีค่า recall อยู่ที่ร้อยละ 99.70 และร้อยละ 97.94 ตามลำดับ ทั้งนี้ กราฟแสดงลักษณะการเรียนรู้ที่รวดเร็วในช่วง 10 รอบแรก

และค่อย ๆ ราบเรียบ แสดงถึงความเร็วของการปรับค่าพารามิเตอร์อย่างมีประสิทธิภาพในระหว่างเรียนรู้ของโครงข่าย แต่พบว่า ใน (Figure 4)(a) และ (b) การทดลองด้วย 10^{-2} เส้นโค้งแสดงความผันผวนในรอบที่ 10 ถึงรอบที่ 20 ซึ่งเกิดจาก learning rate ที่สูงเกินไปทำให้การเรียนรู้ข้อมูลในแต่ละรอบเกิดผันผวนในชั่วขณะ

(Figure 5) เมื่อนำโครงข่ายที่ได้รับการฝึกอบรมด้วย 10^{-5} ดังในรูปที่ 3(a) มาทดสอบจากชุดข้อมูลการทดสอบ (testing set) เพื่อแสดงผลการจดจำโรคใบอ้อย ผลลัพธ์ของการจดจำโรคใบอ้อย ได้แก่ healthy, mosaic, Red rot, rust และ yellow ตัวอย่างการทดสอบจำนวน 10 ตัวอย่าง (ภาพโรคใบอ้อย) โมเดลที่เสนอสามารถจดจำได้อย่างแม่นยำ โดยมีความถูกต้องมากกว่าร้อยละ 80 จำนวน 8 ตัวอย่าง และมีผลการจดจำมากกว่าร้อยละ 90 จำนวน 7 ตัวอย่าง ในขณะที่ผลการจดจำใน healthy และ mosaic มีความแม่นยำต่ำในบางตัวอย่าง โดยมีผลร้อยละ 41.64 และ 73.90 แสดงให้เห็นถึงความผิดพลาดซึ่งอาจเกิดจากความคล้ายคลึงจากลักษณะข้อมูลโรคใบพืชที่นำมาทดสอบ สัญญาณรบกวนภาพใบพืชหรือภาพพื้นหลัง และปัญหาการเรียนรู้ของโครงข่ายซึ่งสะท้อนจากการเรียนรู้ที่เกิดความผันผวนในขณะฝึกอบรม เหล่านี้ซึ่งสำคัญถึงข้อจำกัดของโครงข่ายในการจดจำภาพโรคพืช อย่างไรก็ตาม ภาพรวมของโมเดลยังแสดงผลได้แม่นยำและสามารถจดจำโรคที่มีลักษณะชัดเจน เช่น Red rot และ rust ซึ่งมีประสิทธิภาพสูงถึงร้อยละ 99.72 และ 96.57



Figure 5 Sample image results of recognition performance.

การเปรียบเทียบผลการทดลองกับวิธีก่อนหน้านี้
การศึกษานี้เปรียบเทียบผลการทดลองของวิธีที่เสนอกับการทดลองก่อนหน้านี้ที่เกี่ยวข้องกับการพัฒนา DL ที่นำชุดข้อมูลโรคพิษมาทดลอง โดยคำนึงถึงตัวชี้วัดที่สำคัญ ได้แก่ accuracy, precision และ time ตามลำดับ ดัง (Table 2)

Table 2 Performance comparison with the previous published models.

reference	method	accuracy (%)	precision (%)	time (minute)
Daphal & Koli, 2023	a general approach called attention-based multi-level residual convolutional neural network	86.53	86.34	-
Daphal & Koli, 2024	MobileNet-V2 with transfer learning	86.53	-	-
Yead et al., 2024	VGG with transfer learning	93.26	-	-
	InceptionV3 with transfer learning	74.88	-	-
Bao et al., 2024	spectral-spatial attention deep neural networks	95.94	-	-
Proposed	VGG19 with InceptionResNetV2 integration	99.25	99.70	24.55

จาก (Table 2) แสดงผลการเปรียบเทียบประสิทธิภาพของวิธีที่เสนอกับการศึกษาก่อนหน้า โดยผลการทดลองสูงสุดที่ร้อยละ 99.25, และ 99.70 สำหรับ accuracy และ precision และสูญเสียเวลาการฝึกอบรมเพียง 24.55 นาที ผลลัพธ์นี้ยังมีผลลัพธ์ที่ดีกว่า VGG19 และ inceptionV3 (Yead et al., 2024) ที่ใช้โมเดลเดิมในการถ่ายโอนข้อมูลสำหรับฝึกอบรม แสดงให้เห็นว่าวิธีที่เสนอมีความสามารถในการเรียนรู้ข้อมูลโรคใบอ่อนและจดจำได้อย่างมีประสิทธิภาพ

สรุป

การศึกษานี้เสนอการการผสมผสานโครงข่าย InceptionResNetV2 และ VGG19 เพื่อเพิ่มประสิทธิภาพในการจดจำโรคใบอ่อน โครงข่ายใช้ประโยชน์จาก inception module ร่วมกับ residual connection เพื่อแก้ปัญหา vanishing gradient และเรียนรู้คุณสมบัติของข้อมูลภาพที่ซับซ้อนและ convolutional layers ที่มีขนาดที่แตกต่างเพื่อรวบรวมคุณลักษณะหลายระดับเพื่อดึงคุณสมบัติของโรคใบอ่อน ซึ่งถูกผสมผสานไปบนโครงข่ายเพื่อเพิ่มประสิทธิภาพการทำงานของชั้นการสกัดคุณลักษณะ

ผลการทดลองแสดงให้เห็นว่าวิธีที่เสนอมีประสิทธิภาพที่ดีที่สุดถึงร้อยละ 99.25 มีผล loss น้อยสุดที่ 0.0263 และสูญเสียเวลาในการฝึกอบรมโมเดลที่ 24.55 นาที ผลลัพธ์เหล่านี้ชี้ให้เห็นว่าโมเดลที่นำเสนอสามารถเรียนรู้ข้อมูลภาพโรคใบอ่อนได้อย่างมีประสิทธิภาพและเสถียรสูง การศึกษานี้เน้นย้ำถึงความสำคัญของการผสมผสานโมเดลและการปรับค่า parameter ที่เหมาะสมเพื่อพัฒนาโครงข่ายที่ตอบสนองต่อความต้องการในงานประยุกต์ด้านเกษตรกรรมอย่างมีประสิทธิภาพ

ในอนาคตผู้วิจัยเสนอการพัฒนาโครงข่ายแบบ lightweight เพื่อรองรับชุดข้อมูลที่หลากหลาย และลดข้อจำกัดด้านทรัพยากรสำหรับพัฒนาแอปพลิเคชันแบบเรียลไทม์ในการใช้งานบนโทรศัพท์มือถือ และการถ่ายโอนการเรียนรู้ (transfer learning) เพื่อแก้ปัญหาข้อมูลโรคพืช ซึ่งเป็นการต่อยอดที่เป็นประโยชน์ต่อการพัฒนาเทคโนโลยีการเกษตรอัจฉริยะ สำหรับช่วยเหลือเกษตรกรในการจัดการโรคพืชได้อย่างรวดเร็วและแม่นยำ

คำขอบคุณ

บทความวิจัยฉบับนี้เป็นส่วนหนึ่งของโครงการวิจัยเรื่อง การพัฒนาเทคนิคโครงข่ายการเรียนรู้เชิงลึกสำหรับการจดจำโรคใบด่าง ซึ่งได้รับการสนับสนุนจากสถาบันวิจัยและพัฒนา มหาวิทยาลัยเทคโนโลยีราชมงคลสุวรรณภูมิ ภายใต้งบกองทุนส่งเสริมงานวิจัย ประจำปีงบประมาณ พ.ศ. 2568 ประเภททุนพัฒนานักวิจัยรุ่นใหม่

เอกสารอ้างอิง

- Alharbi, A., Khan, M., & Tayyaba, B. (2023). Wheat disease classification using continual learning. *IEEE Access*, 11, 90016-90026. <https://doi.org/10.1109/ACCESS.2023.3304358>
- Altabaji, W., Umair, M., Tan, W. H., Foo, L. Y., & Ooi, C. P. (2024). Comparative analysis of transfer learning, LeafNet, and modified LeafNet models for accurate rice leaf diseases classification. *IEEE Access*, 12, 36622-36635. <https://doi.org/10.1109/ACCESS.2024.3373000>
- Anorboev, A. Musae, J., Hwang, D. S., Seo, Y. S., & Hong, J. K. (2023). MICL-UNet: Multi-input cross-layer UNet model for classification of diseases in agriculture. *IEEE Access*, 11, 117685-117697. <https://doi.org/10.1109/ACCESS.2023.3325375>
- Balafas, V., Karantoumanis, E., Louta, M., & Ploskas, N. (2023). Machine learning and deep learning for plant disease classification and detection. *IEEE Access*, 11, 114352-114377. <https://doi.org/10.1109/ACCESS.2023.3324722>
- Bao, D., Zhou, J., Bhuiyan, S. A., Adhikari, P., Tuxworth, G., Ford, R., & Gao, Y. S. (2024). Early detection of sugarcane smut and mosaic diseases via hyperspectral imaging and spectral-spatial attention deep neural networks. *Journal of Agriculture and Food Research*, 18, 101369. <https://doi.org/10.1016/j.jafr.2024.101369>
- Begum, S., & Syed, H. (2024). GSAtt-CMNetV3: Pepper leaf disease classification using osprey optimization. *IEEE Access*, 12, 32493-32506. <https://doi.org/10.1109/ACCESS.2024.3358833>
- Bhargava, A., Shukla, A., Goswami, O. P., Alsharif, M. H., Uthansakul, P., & Uthansakul, M. (2024). Plant leaf disease detection, classification, and diagnosis using computer vision and artificial intelligence: A review. *IEEE Access*, 12, 37443-37469. <https://doi.org/10.1109/ACCESS.2024.3373001>
- Chen, C. J., Huang, Y. Y., Li, Y. S., Chang, C. Y., & Huang, Y. M. (2020). An AIoT-based smart agricultural system for pests detection. *IEEE Access*, 8, 180750-180761. <https://doi.org/10.1109/ACCESS.2020.3024891>
- Chouhan, S. S., Kaul, A., Singh, U. P., & Jain, S. (2018). Bacterial foraging optimization-based radial basis function neural network (BRBFNN) for identification and classification of plant leaf diseases: An automatic approach towards plant pathology. *IEEE Access*, 6, 8852-8863. DOI: 10.1109/ACCESS.2018.2800685
- Daphal, S., & Koli, S. (2022). Sugarcane leaf disease dataset. *Mendeley Data*, 1. <https://doi.org/10.17632/9424skmnrk.1>
- Daphal, S. D., & Koli, S. M. (2023). Enhancing sugarcane disease classification with ensemble deep learning: A comparative study with transfer learning techniques. *Heliyon*, 9(8), e18261. <https://doi.org/10.1016/j.heliyon.2023.e18261>

- Daphal, S. D., & Koli, S. M. (2024). Enhanced deep learning technique for sugarcane leaf disease classification and mobile application integration. *Heliyon*, 10(8), e29438. <https://doi.org/10.1016/j.heliyon.2024.e29438>
- Elfatimi, E., Eryigit, R., & Elfatimi, L. (2022). Beans leaf diseases classification using MobileNet models. *IEEE Access*, 10, 9471-9482. <https://doi.org/10.1109/ACCESS.2022.3142817>
- Hosny, K. M., El-Hady, W., Samy, F. M., Vrochidou, E., & Papakostas, G. A. (2023). Multi-class classification of plant leaf diseases using feature fusion of deep convolutional neural network and local binary pattern. *IEEE Access*, 11, 62307-62317. DOI:10.1109/ACCESS.2023.328673
- Lahlali, R., Taoussi, M., Laasli, S. E., Gachara, G., Ezzougari, R., Belabessf, Z., Aberkani, K., Assouguem, A., Meddich, A., El Jarroudi, M. & Barka, E. A. (2024). Effects of climate change on plant pathogens and host-pathogen interactions. *Crop and Environment*, 3(3), 159-170. <https://doi.org/10.1016/j.crope.2024.05.003>
- Madhurya, C., & Jubilson, E. A. (2023). YR2S: Efficient deep learning technique for detecting and classifying plant leaf diseases. *IEEE Access*, 12, 3790-3804. <https://doi.org/10.1109/ACCESS.2023.3343450>
- Mahum, R., Irtaza, A., & Javed, A. (2023). EDL-Det: A robust TTS synthesis detector using VGG19-based YAMNet and ensemble learning block. *IEEE Access*, 11, 134701-134716. <https://doi.org/10.1109/ACCESS.2023.3332561>
- Masood, M., Nawaz, M., Nazir, T., Javed, A., Alkanhel, R., & Elmann, H. (2023). MaizeNet: A deep learning approach for effective recognition of maize plant leaf diseases. *IEEE Access*, 11, 52862-52876. <https://doi.org/10.1109/ACCESS.2023.3280260>
- Moupojou, E., Tagne, A., Retraint, F., Tadonkemwa, A., Wilfried, D., Tapamo, H., & Nkenlifack, M. (2023). FieldPlant: A dataset of field plant images for plant disease detection and classification with deep learning. *IEEE Access*, 11, 35398-35410. <https://doi.org/10.1109/ACCESS.2023.3263042>
- Moupojou, E., Retraint, F., Tapamo, H., Nkenlifack, M., Kacfar, C., & Tagne, A. (2024). Segment anything model and fully convolutional data description for plant multi-disease detection on field images. *IEEE Access*, 12, 102592-102605. <https://doi.org/10.1109/ACCESS.2024.3433495>
- Peyal, H. I., Nahiduzzaman, M., Pramanik, A. H., Syfullah, K., Shahriar, S. M., & Sultana, A. (2023). Plant disease classifier: Detection of dual-crop diseases using lightweight 2D CNN architecture. *IEEE Access*, 11, 110627-110643. <https://doi.org/10.1109/ACCESS.2023.3320686>
- Ramadan, S., Sakib, T., Al Farid, F., Islam, S., Abdullah, J. B., & Bhuiyan, R. (2024). Improving wheat leaf disease classification: Evaluating augmentation strategies and CNN-based models with limited dataset. *IEEE Access*, 12, 69853-69874. <https://doi.org/10.1109/ACCESS.2024.3397570>
- Raza, M. M., & Bebbler, D. P. (2022). Climate change and plant pathogens. *Current Opinion in Microbiology*, 70, 102233. <https://doi.org/10.1016/j.mib.2022.102233>
- Salam, A., Naznine, M., Jahan, N., Nahid, E., Nahiduzzaman, Chowdhury, M. (2024). Mulberry leaf disease detection using CNN-based smart Android application. *IEEE Access*, 12, 83575-83588. <https://doi.org/10.1109/ACCESS.2024.3407153>

- Singh, B. K., Delgado-Baquerizo, M., Egidi, E., Guirado, E., Leach, J. E., Liu, H. W., & Trivedi, P. (2023). Climate change impacts on plant pathogens, food security and paths forward. *Nature Reviews Microbiology*, 21, 640-656. <https://doi.org/10.1038/s41579-023-00900-7>
- Szegedy, C., Ioffe, S., Vanhoucke, V., & Alemi, A. A. (2017). Inception-v4, Inception-ResNet and the impact of residual connections on learning. *Proceedings of the 31st AAAI Conference on Artificial Intelligence*. USA. (pp. 1-7). <https://doi.org/10.1609/aaai.v31i1.11231>
- Tabbakh, A., & Barpanda, S. S. (2023). A deep features extraction model based on the transfer learning model and vision transformer 'TLMViT' for plant disease classification. *IEEE Access*, 11, 45377-45392. DOI: 10.1109/ACCESS.2023.3273317
- Yead, A. R., Rukhsara, L., Rabeya, T., & Jahan, I. (2024). Deep learning-based classification of sugarcane leaf disease. *Proceedings of the 6th International Conference on Electrical Engineering and Information & Communication Technology (ICEEICT)*. Bangladesh. (pp. 818-823). <https://doi.org/10.1109/ICEEICT62016.2024.10534551>