

การประยุกต์ใช้โมเดลการเรียนรู้เชิงลึกขนาดเล็กในการจำแนกโรคพืชจากภาพถ่ายผ่าน LINE Chatbot

Application of Lightweight Deep Learning Models for Plant Disease Classification via LINE Chatbot

จันทนา ปัญญาวารารณ์

Jantana Panyavaraporn

ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยบูรพา

Department of Electrical Engineering, Faculty of Engineering, Burapha University, Chonburi, Thailand

*Corresponding Author E-mail: Jantanap@eng.buu.ac.th

Received: 31/08/25, Revised: 27/9/25, Accepted 1/10/25

บทคัดย่อ

การเกษตรอัจฉริยะมีบทบาทสำคัญเพิ่มขึ้นในประเทศไทย โดยเฉพาะในยุคที่เทคโนโลยีปัญญาประดิษฐ์มีความก้าวหน้า ซึ่งสามารถช่วยลดการพึ่งพาผู้เชี่ยวชาญและเพิ่มความรวดเร็วในการจำแนกโรคพืชจากภาพถ่ายใบพืช งานวิจัยนี้ได้นำเสนอการเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก ได้แก่ ResNet18, EfficientNet-B0 และ MobileNetV3 สำหรับการจำแนกโรคพืชจากภาพถ่ายโดยใช้ชุดข้อมูลภาพใบมันสำปะหลังจำนวน 5 คลาส และชุดข้อมูลภาพใบมะเขือเทศจำนวน 10 คลาส ผลการทดลองพบว่า EfficientNet-B0 ให้ค่าความถูกต้อง (Accuracy) และค่า F1-score สูงที่สุด รองลงมาคือ MobileNetV3 และ ResNet18 ตามลำดับ หลังจากนั้นได้นำโมเดล EfficientNet-B0 ไปประยุกต์ใช้งานในระบบแบบเรียลไทม์ โดยพัฒนาต้นแบบที่รวมการทำงานของโมเดล EfficientNet-B0 เข้ากับ LINE Chatbot เพื่อให้ผู้ใช้ส่งภาพถ่ายใบมันสำปะหลังหรือใบมะเขือเทศ และรับผลการทำนายโรคแบบอัตโนมัติพร้อมข้อเสนอแนะเบื้องต้นผ่านทาง LINE จากผลการทดลองแสดงให้เห็นว่าระบบสามารถทำงานได้อย่างมีประสิทธิภาพและสามารถนำไปประยุกต์ใช้กับการเกษตรอัจฉริยะต่อไปในอนาคต

คำสำคัญ: การจำแนกโรคพืช การเรียนรู้เชิงลึก LINE Chatbot

Abstract

Smart farming is becoming increasingly important in Thailand, especially with advances in artificial intelligence (AI) technology that help reduce reliance on experts and accelerate plant disease diagnosis through leaf images. Therefore, this paper presents a performance comparison of different deep learning models, namely ResNet18, EfficientNet-B0, and MobileNetV3, in classifying cassava diseases using a five-class cassava leaf image dataset and tomato diseases using a ten-class tomato leaf image dataset. Experimental results show that EfficientNet-B0 achieved the highest accuracy and F1-score, followed by MobileNetV3 and ResNet18, respectively. After, EfficientNet-B0 was applied in real-time system, and a prototype was developed by

integrating the EfficientNet-B0 model with a LINE chatbot. The system allows users to submit cassava or tomato leaf images and receive automated disease predictions with preliminary treatment recommendations via LINE. The results show that the system performs efficiently and has potential for smart agriculture in the future.

Keywords: Plant Disease Classification, Deep Learning, LINE Chatbot

1. บทนำ

การเกษตรเป็นรากฐานสำคัญของเศรษฐกิจไทย โดยเฉพาะการปลูกพืชเศรษฐกิจ เช่น ข้าว ยางพารา อ้อย มันสำปะหลัง และมะเขือเทศ เป็นต้น [1-2] ซึ่งพืชเศรษฐกิจมีบทบาทสำคัญในครัวเรือนและอุตสาหกรรมเกษตร ฉะนั้นการเพิ่มประสิทธิภาพของการปลูกพืชและการจัดการโรคพืชจึงเป็นสิ่งสำคัญที่ส่งผลโดยตรงต่อรายได้ของเกษตรกร และการเข้าถึงอาหารที่ปลอดภัยและเพียงพอของประเทศ โรคพืชเป็นปัจจัยสำคัญที่ทำให้ผลผลิตลดลงโดยทั่วไปมักจะแสดงอาการออกทางใบ อีกทั้งการแพร่ระบาดของโรคเกิดขึ้นอย่างรวดเร็วและยากต่อการควบคุม หากขาดการวินิจฉัยที่แม่นยำอย่างรวดเร็ว โดยวิธีการวินิจฉัยแบบดั้งเดิมต้องอาศัยผู้เชี่ยวชาญด้านพืชศาสตร์ที่มีข้อจำกัดด้านความเร็วและความแม่นยำ

ประเทศไทยต้องเผชิญกับความสูญเสียทางเศรษฐกิจจากโรคพืชอย่างต่อเนื่องโดยเฉพาะมะเขือเทศ [2] และมันสำปะหลัง [3] ที่มีการเพาะปลูกอย่างแพร่หลาย จึงมีงานวิจัยที่ใช้ปัญญาประดิษฐ์จำแนกโรคพืช เช่น F. Naveed [4] ใช้ ResNet18 ในการจำแนกโรคพืชแบบ Few-shot Learning เพื่อแก้ปัญหาการขาดแคลนข้อมูลฝึกสอน ซึ่งเป็นปัญหาสำคัญในการพัฒนาระบบตรวจจับโรคพืช และ T. Devi [5] พัฒนาสถาปัตยกรรม Enhanced EfficientNet เพื่อตรวจจับโรคพืชและวิเคราะห์ระดับความรุนแรงของโรคในใบพืช นอกจากนี้ U. Atila [6] ได้ใช้ EfficientNet สำหรับการจำแนกโรคพืช และ J. Feng [7] ได้นำเสนอการรวม EfficientNet กับ Transformer เพื่อการจำแนกโรคพืชที่มีประสิทธิภาพมากขึ้น อีกทั้ง S. B. S. [8] ได้ใช้ MobileNetV3 ร่วมกับ Wavelet Kernel Extreme Learning Machine (WKELM) สำหรับการตรวจจับและจำแนกโรคใบพืช

งานวิจัยนี้ได้นำเทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะการเรียนรู้เชิงลึก (Deep Learning) เข้ามาช่วยในการจำแนกโรคจากภาพถ่ายใบพืชอย่างมีประสิทธิภาพ และทำการเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก ได้แก่ ResNet18, EfficientNet-B0 และ MobileNetV3 อีกทั้งได้นำเสนอแนวทางการประยุกต์ใช้โมเดลการเรียนรู้เชิงลึกกับ LINE Chatbot เพื่อให้ง่ายต่อการเข้าถึงของผู้ใช้งาน รวมถึงการจำแนกโรคที่มุ่งเน้นเฉพาะอาการที่แสดงบนใบพืช โดยไม่ครอบคลุมส่วนอื่น เช่น ลำต้นหรือผล เป็นต้น ซึ่งอาจส่งผลให้ความแม่นยำของการจำแนกโรคลดลง หากมีส่วนอื่นของพืชปรากฏอยู่ในภาพถ่าย

2. ทฤษฎีที่เกี่ยวข้อง

Convolutional Neural Network (CNN) เป็นหนึ่งในโครงข่ายประสาทเทียมที่ใช้ในการเรียนรู้เชิงลึก (Deep Learning) ที่มีประสิทธิภาพสูงเหมาะสำหรับการเรียนรู้คุณลักษณะจากภาพ (Image)

2.1 Residual Network

Residual Network (ResNet) เป็นหนึ่งในสถาปัตยกรรมของ CNN ที่จัดอยู่ในการเรียนรู้เชิงลึก พัฒนาโดย Microsoft Research ในค.ศ. 2015 [9] ResNet เป็นโครงข่ายประสาทเทียมที่ออกแบบมาโดยเฉพาะสำหรับการประมวลผลภาพโดยใช้ชั้นคอนโวลูชัน (Convolutional) เพื่อจัดการคุณลักษณะสำคัญจากภาพ เช่น ขอบและรูปร่าง เป็นต้น โครงสร้างของ CNN ทำให้สามารถเรียนรู้ลักษณะเชิงพื้นที่ที่ซับซ้อนได้อย่างมีประสิทธิภาพ

ResNet ได้เพิ่มแนวคิดของ Residual Connections หรือ Skip Connections เข้าในโครงข่ายเพื่อช่วยให้การฝึกโมเดลลึกหลายชั้นทำได้ง่ายขึ้น และลดปัญหา Gradient Vanishing ที่เกิดขึ้นในโครงข่ายจึงทำให้ ResNet ได้รับความนิยมในการจำแนกภาพ

2.2 EfficientNet

EfficientNet เป็นหนึ่งในสถาปัตยกรรมของ CNN ที่พัฒนาโดยทีมวิจัยของ Google Brain ในปี 2019 [10] โดยมีแนวคิดหลักในการเพิ่มประสิทธิภาพของโมเดลผ่านเทคนิคที่เรียกว่า “Compound Scaling” ซึ่งเป็นการเพิ่มขนาดของโมเดลทั้งความลึก (Depth) ความกว้าง (Width) และความละเอียดของภาพ (Resolution) แทนที่จะเพิ่มเพียงด้านใดด้านหนึ่ง ผลลัพธ์ที่ได้คือโมเดลที่มีความแม่นยำสูง ขณะเดียวกันก็ใช้ทรัพยากรในการประมวลผลน้อยลง เมื่อเทียบกับโมเดลที่มีประสิทธิภาพใกล้เคียงกัน

EfficientNet มีหลายเวอร์ชันโดยเรียงลำดับจาก B0 ถึง B7 ซึ่ง B0 เป็นเวอร์ชันเริ่มต้นที่ใช้สำหรับการปรับสเกล และเวอร์ชัน B1-B7 เป็นผลจากการขยายแบบ Compound โมเดล EfficientNet-B0 จึงได้รับความนิยมในงานวิจัยที่ต้องการขนาดเล็ก (Lightweight) และประสิทธิภาพสูง

2.3 MobileNetV3

MobileNetV3 เป็นหนึ่งในสถาปัตยกรรมของ CNN ที่ออกแบบให้มีขนาดเล็กและสามารถทำงานได้อย่างมีประสิทธิภาพบนอุปกรณ์ที่มี

ทรัพยากรจำกัด พัฒนาโดยทีม Google ในปี 2019 [11] MobileNetV3 ได้รวมข้อดีของ MobileNetV1 และ MobileNetV2 เข้ากับเทคนิคใหม่ เช่น ใช้ Squeeze-and-Excitation Modules ออกแบบด้วย Neural Architecture Search (NAS) และใช้ฟังก์ชันกระตุ้น (Activation Function) แบบ Hard-Swish ทำให้โมเดลมีประสิทธิภาพดีขึ้นทั้งความแม่นยำและความเร็วในการประมวลผล

MobileNetV3 มีสองเวอร์ชันหลักคือ MobileNetV3-Large และ MobileNetV3-Small โดยที่เวอร์ชันขนาดเล็กออกแบบมาโดยเฉพาะสำหรับงานที่สถานะแวดล้อมมีข้อจำกัดทางด้านทรัพยากร เช่น การใช้งานบนสมาร์ตโฟน หรือการประมวลผลที่ขอบเครือข่าย (Edge Computing)

ตารางที่ 1 การเปรียบเทียบคุณลักษณะของโมเดลขนาดเล็ก

โมเดล	ขนาดโมเดล	ความเร็ว	ความเหมาะสมกับระบบเรียลไทม์
ResNet18	~11M	เร็ว	เหมาะสม
EfficientNet-B0	~5.3M	กลาง	ขึ้นอยู่กับฮาร์ดแวร์
MobileNetV3-Large	~5.4M	เร็ว	เหมาะสม

ตารางที่ 1 เปรียบเทียบคุณลักษณะของโมเดลขนาดเล็ก (Lightweight Models) ได้แก่ ResNet18, EfficientNet-B0 และ MobileNetV3-Large ซึ่งทั้งหมดเป็นโครงข่ายประสาทเทียมแบบ CNN ที่นิยมใช้งานจำแนกจากภาพ โดยที่ ResNet18 และ MobileNetV3-Large มีความเหมาะสมต่อการนำไปใช้ในระบบแบบเรียลไทม์ ในขณะที่ EfficientNet-B0 ให้ความแม่นยำที่ดี แต่ขึ้นอยู่กับฮาร์ดแวร์ที่ใช้ประมวลผล

2.4 LINE Messaging API

LINE Messaging API เป็นแพลตฟอร์มที่ให้ผู้พัฒนาสามารถสร้าง Chatbot หรือระบบอัตโนมัติที่สามารถโต้ตอบกับผู้ใช้ผ่านทาง LINE ได้ โดย API สามารถรองรับการรับส่งข้อความ รูปภาพ และวีดิทัศน์ รวมถึงการจัดการผู้ใช้และสถานะการสนทนา ทำให้สามารถสร้างระบบตอบกลับได้อย่างมีประสิทธิภาพเหมาะสำหรับการประยุกต์ใช้งานด้านต่าง ๆ เช่น บริการลูกค้า การตลาด และระบบสนับสนุนการตัดสินใจ เป็นต้น


3. การออกแบบระบบจำแนกโรคพืช

วิธีการวิจัยแบ่งเป็น 3 ส่วนหลัก ได้แก่ (1) การเตรียมชุดข้อมูลภาพใบมะเขือเทศ (2) ภาพรวมของระบบจำแนกโรคจากใบพืชเบื้องต้น ซึ่งพัฒนาต้นแบบที่เชื่อมต่อโมเดลกับ LINE Chatbot สำหรับทดสอบการใช้งานระบบแบบเรียลไทม์ และ (3) การประเมินผลการจำแนกโรคพืช

3.1 การเตรียมชุดข้อมูล

งานวิจัยนี้แบ่งชุดข้อมูลแบบสุ่ม (Random Split) ออกเป็น 3 ส่วน ได้แก่ ชุดฝึกจำนวน 70 เปอร์เซ็นต์ ชุดตรวจสอบความถูกต้อง (Validation) จำนวน 20 เปอร์เซ็นต์ และชุดทดสอบจำนวน 10 เปอร์เซ็นต์ โดยภาพในแต่ละชุดไม่ซ้ำกัน การสุ่มลักษณะนี้เป็นการแบ่งจากภาพทั้งหมด


การทดลองจำแนกโรคพืชจากภาพใบของพืชเศรษฐกิจ 2 ประเภท ได้แก่ มันสำปะหลัง และมะเขือเทศ ซึ่งเป็นชุดข้อมูลจากฐานข้อมูล www.kaggle.com โดยที่ชุดข้อมูลใบมันสำปะหลัง 21,397 ภาพ ดังรูปที่ 1 แบ่งออกเป็น 5 คลาส [12] ได้แก่ โรคใบไหม้แบคทีเรีย (Bacterial Blight) รูปที่ 1 (ก) โรคเส้นสีน้ำตาล (Brown Streak Disease) รูปที่ 1 (ข) โรคจุดเขียวกระพือม (Green Mottle) รูปที่ 1 (ค) โรคใบด่าง (Mosaic Disease) รูปที่ 1 (ง) และใบปกติ/ไม่มีโรค (Healthy) รูปที่ 1 (ฉ)




รูปที่ 1 ตัวอย่างชุดข้อมูลภาพใบมันสำปะหลัง

(ก) โรคใบไหม้แบคทีเรีย (Bacterial Blight) (ข) โรคเส้นสีน้ำตาล (Brown Streak Disease) (ค) โรคจุดเขียวกระพือม (Green Mottle) (ง) โรคใบด่าง (Mosaic Disease)

ชุดข้อมูลใบมะเขือเทศ 16,011 ภาพ ดังรูปที่ 2 แบ่งเป็น 10 กลุ่ม [13] ได้แก่ จุดแผลแบคทีเรีย (Bacterial Spot) รูปที่ 2 (ก) โรคราน้ำฝนระยะเริ่มต้น (Early Blight) รูปที่ 2 (ข) โรคราน้ำฝนระยะท้าย (Late Blight) รูปที่ 2 (ค) โรคราใบมะเขือเทศ (Leaf Mold) รูปที่ 2 (ง) โรคใบจุดเซปโตเรีย (Septoria Leaf Spot) รูปที่ 2 (จ) โรคจุดเป้า (Target Spot) รูปที่ 2 (ฉ) ไรแมงมุม/ไรสองจุด (Spider Mites Two Spotted Spider Mite) รูปที่ 2 (ช) โรคไวรัสใบหงิกเหลือง (Tomato Yellow Leaf Curl Virus) รูปที่ 2 (ซ) โรคไวรัสใบด่างมะเขือเทศ (Tomato Mosaic Virus) รูปที่ 2 (ฅ) และปกติ/ไม่มีโรค (Healthy) รูปที่ 2 (ฉ)



(ก) (ข) (ค) (ง) (จ) (ฉ) (ช) (ซ) (ฅ) (ฉ)




รูปที่ 2 ตัวอย่างชุดข้อมูลภาพใบมะเขือเทศ


(ก) จุดแผลแบคทีเรีย (Bacterial Spot) (ข) โรคราน้ำฝนระยะเริ่มต้น (Early Blight) (ค) โรคราน้ำฝนระยะท้าย (Late Blight) (ง) โรคราใบมะเขือเทศ (Leaf Mold) (จ) โรคใบจุดเซปโตเรีย (Septoria Leaf Spot) (ฉ) โรคจุดเป้า (Target Spot) (ช) ไรแมงมุม/ไรสองจุด (Spider Mites Two Spotted Spider Mite) (ซ) โรคไวรัสใบหงิกเหลือง (Tomato Yellow Leaf Curl Virus) (ฅ) โรคไวรัสใบด่างมะเขือเทศ (Tomato Mosaic Virus)

3.2 ภาพรวมของระบบจำแนกโรคพืชเบื้องต้น

การเปรียบเทียบโมเดล ดังรูปที่ 3 เริ่มต้นจากการนำภาพใบพืชโดยพิจารณา 2 ประเภท ได้แก่ มันสำปะหลังและมะเขือเทศ ซึ่งแบ่งเป็น 5 คลาสสำหรับมันสำปะหลัง และ 10 คลาสสำหรับมะเขือเทศ หลังจากนั้น เปรียบเทียบผลจากโมเดล CNN ที่ประกอบด้วย ResNet18, EfficientNet-B0 และ MobileNetV3-Large ขึ้น ต่อ น สุด ท้าย เป็น การประเมินประสิทธิภาพของแต่ละโมเดลโดยวิเคราะห์จากค่าความถูกต้อง (Accuracy) ความแม่นยำ (Precision) การเรียกคืน (Recall) และ ค่า F1-score หลังจากประเมินโมเดลเสร็จแล้ว ทำการเลือกโมเดลที่ให้ผลดีที่สุด (Best Model) มาใช้งานร่วมกับระบบ LINE Chatbot เพื่อแสดงผลการวินิจฉัยโรคเบื้องต้น ได้แก่ ชื่อโรคที่วิเคราะห์ได้จากโมเดล พร้อมแนวทางการดูแลเบื้องต้นในรูปแบบข้อความตอบกลับไปยังผู้ใช้งาน



รูปที่ 3 การเปรียบเทียบ โมเดล CNN



รูปที่ 4 ภาพรวมของการประยุกต์ใช้งานผ่านทาง LINE Chatbot

ภาพรวมของการประยุกต์ใช้งานผ่านทาง LINE Chatbot ดังรูปที่ 4 สามารถอธิบายขั้นตอนได้ ดังนี้

1. ผู้ใช้ส่งภาพใบพืชทาง LINE Chatbot
2. LINE Bot รับภาพและส่งผ่าน API ที่พัฒนาด้วย Flask ไปที่ เซิร์ฟเวอร์
3. เลือกใช้โมเดลที่ดีที่สุดจาก ResNet18, EfficientNet-B0 หรือ MobileNetV3-Large เพื่อประมวลผลภาพและจำแนกว่าเป็นโรคใด
4. หลังจากประมวลผลเสร็จ ระบบส่งผลกลับไปยังผู้ใช้ผ่านข้อความตอบกลับทาง LINE พร้อมข้อความคำแนะนำเบื้องต้นเพื่อเป็นแนวทางการรักษาโรคพืช เช่น การใช้สารเคมี การตัดใบ หรือการแยกต้น เป็นต้น

การทำงานของระบบวินิจฉัยโรคจากใบพืชนี้จะช่วยให้เกษตรกรหรือผู้ใช้งานทั่วไปสามารถรับรู้ปัญหาโรคพืชจากภาพถ่ายใบพืชได้อย่างสะดวกและรวดเร็ว โดยไม่จำเป็นต้องใช้ผู้เชี่ยวชาญเฉพาะทาง

3.3 การประเมินผล

การประเมินผลจากค่าความถูกต้อง (Accuracy) ความแม่นยำ (Precision) การเรียกคืน (Recall) และค่า F1-score

ความถูกต้อง (Accuracy) นิยมใช้กับชุดข้อมูลที่มีจำนวนข้อมูลในแต่ละคลาสใกล้เคียงกันหรือเรียกว่าเป็น “ชุดข้อมูลที่ไม่มีปัญหาความไม่สมดุลของคลาส (Imbalanced Class)” ดังสมการที่ (1)

$$\text{Accuracy} = \frac{TP + TN}{N} \quad (1)$$

ความแม่นยำ (Precision) เป็นการวัดสัดส่วนของการทำนายที่ถูกต้อง (True Positive) เทียบกับจำนวนทั้งหมดของการทำนายว่าเป็นบวกดังสมการที่ (2)

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

การเรียกคืน (Recall) เป็นการวัดสัดส่วนของการทำนายที่ถูกต้อง (True Positive) เทียบกับจำนวนของกรณีที่เป็นบวกจริงทั้งหมด (Ground Truth) ดังสมการที่ (3)

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

ค่า F1-score เป็นค่าเฉลี่ยฮาร์โมนิกระหว่างความแม่นยำและการเรียกคืน ซึ่งเป็นค่าที่ให้ความสมดุลระหว่างความแม่นยำและการเรียกคืน โดยเฉพาะอย่างยิ่งในกรณีที่ข้อมูลไม่สมดุลของคลาส (Imbalanced Class)” คำนวณได้ตามสมการที่ (4)

$$F1 - \text{score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (4)$$

โดยที่

True Positive (TP) คือจำนวนการทำนายว่าเป็นกลุ่มบวกที่ถูกต้อง

False Positive (FP) คือจำนวนการทำนายว่าเป็นกลุ่มบวกที่ผิด

False Negative (FN) คือจำนวนการทำนายว่าเป็นกลุ่มลบที่ผิด

True Negative (TN) คือจำนวนการทำนายว่าเป็นกลุ่มลบที่ถูกต้อง

4. ผลการทดลอง


งานวิจัยนี้มุ่งเน้นที่โมเดลการเรียนรู้เชิงลึกขนาดเล็กเพื่อนำไปใช้กับระบบแบบเรียลไทม์ จึงเลือกใช้โมเดลที่เหมาะสมกับงาน ได้แก่ ResNet18, EfficientNet-B0 และ MobileNetV3-Large ซึ่งเป็น โมเดลขนาดเล็กที่มีจำนวนพารามิเตอร์และความลึกของโครงข่ายน้อยกว่าโมเดลขนาดใหญ่ และเรียนรู้ได้เร็ว

การตั้งค่าการฝึกโมเดล (Training Settings) โดยระบุค่าพารามิเตอร์ ดังนี้


- จำนวนรอบการฝึก (Epochs): 20 รอบ
- ขนาดชุดข้อมูลย่อย (Batch Size): 32
- ตัวปรับค่า (Optimizer): Adam
- อัตราการเรียนรู้ (Learning Rate): 0.0001
- ฟังก์ชันสูญเสีย (Loss Function): CrossEntropyLoss

ระหว่างการศึกษาฝึกสอนโมเดลจะถูกบันทึกเมื่อได้ค่าความแม่นยำของชุดตรวจสอบความถูกต้อง (Validation Accuracy) สูงที่สุด เพื่อให้มั่นใจว่าโมเดลที่ได้นำไปใช้งานเป็นโมเดลที่มีประสิทธิภาพสูงสุด การประเมินขั้นสุดท้ายดำเนินการบนชุดข้อมูลสำหรับการทดสอบ เพื่อหลีกเลี่ยงปัญหา Overfitting และเพื่อให้ผลการประเมินสะท้อนถึงความสามารถที่แท้จริงของโมเดลมากที่สุด


จากผลการฝึกสอนโมเดลในรูปที่ 5-7 พบว่าโมเดล EfficientNet-B0 มีความเสถียรและประสิทธิภาพดีที่สุดทั้งชุดข้อมูลใบมันสำปะหลังและใบมะเขือเทศ โดยมี Training Loss ลดลงต่อเนื่อง ค่าความถูกต้องของการฝึกสอนและการตรวจสอบความถูกต้องอยู่ในระดับสูงและมีค่าใกล้เคียงกัน ส่วน ResNet18 และ MobileNetV3-Large มีแนวโน้ม Overfitting โดยเฉพาะในข้อมูลใบมันสำปะหลัง ซึ่งเห็นได้จากค่าความถูกต้องของการฝึกสอนที่สูง แต่ความถูกต้องของชุดตรวจสอบความถูกต้องผันผวน



รูปที่ 5 กราฟ Loss และ Accuracy ระหว่างการฝึก (training) ของโมเดล ResNet18
(ก) มันสำปะหลัง (ข) มะเขือเทศ




(ก)




(ข)

รูปที่ 6 กราฟ Loss และ Accuracy ระหว่างการฝึก (training) ของโมเดล EfficientNet-B0

(ก) มันสำปะหลัง (ข) มะเขือเทศ



(ก)



(ข)

รูปที่ 7 กราฟ Loss และ Accuracy ระหว่างการฝึก (training) ของโมเดล MobileNetV3-

Large (ก) มันสำปะหลัง (ข) มะเขือเทศ

ตารางที่ 2 การเปรียบเทียบประสิทธิภาพของโมเดลขนาดเล็ก

โมเดล	Accuracy (เฉลี่ย)	Precision (เฉลี่ย)	Recall (เฉลี่ย)	F1-score (เฉลี่ย)	เวลา* (เฉลี่ย)
มันสำปะหลัง					
ResNet18	0.8150	0.8143	0.8150	0.8136	139.88
EfficientNet-B0	0.8454	0.8429	0.8454	0.8415	144.77
MobileNetV3- Large	0.8384	0.8446	0.8384	0.8396	138.35
มะเขือเทศ					
ResNet18	0.9925	0.9926	0.9925	0.9925	44.65
EfficientNet-B0	0.9981	0.9981	0.9981	0.9981	63.35
MobileNetV3- Large	0.9950	0.9950	0.9950	0.9950	46.48

จากผลการลองในตารางที่ 2-4 และรูปที่ 8-9 แสดงให้เห็นว่าโมเดล EfficientNet-B0 ให้ผลลัพธ์ที่ดีที่สุด โดยเฉพาะใบมะเขือเทศที่ให้ค่าความถูกต้อง (Accuracy) ความแม่นยำ (Precision) การเรียกคืน (Recall) และค่า F1-score เฉลี่ยสูงถึง 100% แสดงให้เห็นว่าชุดข้อมูลของมะเขือเทศมีลักษณะของโรคที่สามารถจำแนกได้อย่างชัดเจน ในขณะที่ชุดข้อมูลของใบมันสำปะหลังมีความยากกว่า เนื่องจากภาพในชุดข้อมูลมีทั้งส่วนของลำต้นและใบ ซึ่งต่างจากใบมะเขือเทศที่มีเพียงใบเท่านั้น ส่งผลให้โมเดลมีความแม่นยำของการจำแนกลดลงเล็กน้อย อย่างไรก็ตาม EfficientNet-B0 ยังให้ผลลัพธ์ที่ดีที่สุด แม้ว่า MobileNetV3-Large จะใช้เวลาฝึกต่อน้อยกว่าเล็กน้อยก็ตาม จากการวิเคราะห์ผลการจำแนกตามคลาสในตารางที่ 3-4 พบว่าโรคที่มีลักษณะเด่นชัด ยกตัวอย่างเช่น Mosaic Disease สามารถจำแนกโรคได้ถูกต้องที่สุด ในขณะที่บางโรค เช่น Bacterial Blight ของมันสำปะหลัง มีค่าความแม่นยำและการเรียกคืนต่ำกว่าค่าเฉลี่ย

ตารางที่ 3 ประสิทธิภาพของ EfficientNet-B0 และ MobileNetV3-Large


ของโรคมันสำปะหลัง

class	EfficientNet-B0			MobileNetV3-Large		
	Precision	Recall	F1-score	Precision	Recall	F1-score
Bacterial Blight	0.4731	0.4444	0.4583	0.5045	0.5657	0.5333
Brown Streak	0.8013	0.5961	0.6836	0.7702	0.6108	0.6813
Green Mottle	0.8296	0.7061	0.7629	0.7737	0.7176	0.7446
Mosaic Disease	0.9189	0.9687	0.9431	0.9424	0.9366	0.9395
Healthy	0.6519	0.7154	0.6821	0.6173	0.7491	0.6768


ตารางที่ 4 ประสิทธิภาพของ EfficientNet-B0 และ MobileNetV3-Large

ของโรคมะเขือเทศ

class	EfficientNet-B0			MobileNetV3-Large		
	Precision	Recall	F1-score	Precision	Recall	F1-score
Bacterial Spot	0.9958	1.0000	0.9979	0.9958	0.9958	0.9958
Early Blight	1.0000	0.9780	0.9889	0.9775	0.9560	0.9667
Late Blight	0.9949	1.0000	0.9974	0.9897	0.9948	0.9923
Leaf Mold	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Target Spot	1.0000	1.0000	1.0000	0.9928	0.9928	0.9928
Mosaic Virus	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000
Septoria Leaf Spot	1.0000	1.0000	1.0000	0.9880	1.0000	0.9939
Spider Mites Two						
Spotted Spider Mite	0.9936	1.0000	0.9968	1.0000	0.9936	0.9968
Yellow Leaf Cur Virus	1.0000	0.9970	0.9985	1.0000	1.0000	1.0000
Healthy	1.0000	1.0000	1.0000	1.0000	1.0000	1.0000



(ก)



(ข)

รูปที่ 8 Confusion Matrix จากโมเดล EfficientNet-B0 ของชุดข้อมูล

(ก) ใบมันสำปะหลัง (ข) ใบมะเขือเทศ



(ก)



(ข)

รูปที่ 9 ตัวอย่างผลการจำแนกโรคพืชเมื่อใช้โมเดล EfficientNet-B0
(ก) ใบมันสำปะหลัง (ข) ใบมะเขือเทศ


จากผลการทดลองการจำแนกโรคจากใบมันสำปะหลังและมะเขือเทศสรุปได้ว่า EfficientNet-B0 เหมาะสมที่สุดสำหรับงานจำแนกโรคพืช ทั้งความแม่นยำและความเสถียรระหว่างการฝึกโมเดล Confusion Matrix จากโมเดล EfficientNet-B0 ในรูปที่ 8(ข) แสดงให้เห็นว่าการจำแนกโรค

จากใบมะเขือเทศได้ค่าความถูกต้องสูง ขณะที่ใบมันสำปะหลังยังมีการจำแนกผิดในบางคลาสดังแสดงในรูปที่ 8(ก) อีกทั้งรูปที่ 9 แสดงตัวอย่างผลการจำแนกโรคมันสำปะหลังและมะเขือเทศเมื่อใช้โมเดล EfficientNet-B0

การประยุกต์ใช้งานผ่านทาง LINE Chatbot ดังรูปที่ 10 แสดงให้เห็นว่าเป็นการสื่อสารแบบสองทาง เริ่มจากผู้ใช้ทักทายก่อน ระบบจะถามกลับว่า “กรุณาคัดเลือก 1 (มะเขือเทศ) หรือ 2 (มันสำปะหลัง)” และให้ผู้ใช้ตอบกลับ หลังจากนั้นระบบจะแจ้งให้ผู้ใช้ส่งภาพ เมื่อส่งภาพเรียบร้อยแล้ว ระบบจะทำการวิเคราะห์ผลจากโมเดล EfficientNet-B0 ที่ผ่านการฝึกสอนแล้ว ขึ้นตอนสุดท้ายระบบจะตอบกลับผลการทำนายโรคและแนวทางการรักษา



(ก)



(ข)

รูปที่ 10 ตัวอย่างการใช้งานผ่าน LINE Chatbot
(ก) มันสำปะหลัง (ข) มะเขือเทศ

งานวิจัยนี้เป็นการนำเสนอแนวทางในการพัฒนาระบบที่ช่วยให้ผู้ใช้ทั่วไป ซึ่งไม่มีความรู้ด้านโรคพืช สามารถจำแนกโรคพืชเบื้องต้นได้ง่ายและรวดเร็ว รวมถึงช่วยให้เกษตรกรหรือเจ้าหน้าที่ภาคสนามสามารถตรวจสอบโรคพืชจากใบไม้ได้ทันที โดยไม่ต้องรอฟruitจากผู้เชี่ยวชาญ

5. สรุปผลและข้อเสนอแนะ

งานวิจัยนี้เป็นการเปรียบเทียบประสิทธิภาพของโมเดลเชิงลึกขนาดเล็กคือ ResNet18, EfficientNet-B0 และ MobileNetV3 เพื่อจำแนกโรคจากภาพใบมันสำปะหลังและใบมะเขือเทศ ผลการทดลองพบว่า EfficientNet-B0 มีประสิทธิภาพสูงทั้งค่าความถูกต้องและความเสถียรระหว่างการฝึกสอน โดยค่าความถูกต้องของการจำแนกโรคจากใบมะเขือเทศอยู่ที่ 99.81% และใบมันสำปะหลังอยู่ที่ 84.54% นอกจากนี้ ได้พัฒนาระบบต้นแบบที่นำโมเดล EfficientNet-B0 ไปใช้งานผ่านทาง LINE Chatbot ที่สามารถถ่ายรูปใบพืชแล้วส่งมาถามได้ว่าพืชเป็นโรคใด โดยระบบจะตอบกลับแบบอัตโนมัติ

ข้อเสนอแนะสำหรับการพัฒนางานวิจัยในอนาคต ควรเพิ่มจำนวนชนิดของพืชและโรคที่ใช้ในการทดลอง เพื่อให้ระบบสามารถจำแนกโรคได้ครอบคลุมขึ้นและรองรับการใช้งานกับพืชเศรษฐกิจทั้งหมด นอกจากนี้ ควรทดลองระบบกับภาพถ่ายที่ได้จากสภาพแวดล้อมจริงของแปลงเกษตรกร เพื่อประเมินประสิทธิภาพของโมเดลภายใต้สภาพแสงและพื้นหลังที่แตกต่างกัน อีกทั้งพิจารณาใช้เทคนิค Data Augmentation และ Regularization เพื่อช่วยลดปัญหา Overfitting ซึ่งจะช่วยให้ระบบมีความแม่นยำและสามารถนำไปประยุกต์ใช้ได้จริง

เอกสารอ้างอิง

- [1] สำนักงานพัฒนาการวิจัยการเกษตร (องค์การมหาชน), “พืชเศรษฐกิจ สินค้าสร้างรายได้ในครัวเรือนและประเทศ.” [Online]. Available: <https://www.arda.or.th/detail/6166>. [Accessed: Jul. 15, 2025].
- [2] สำนักงานพัฒนาการวิจัยการเกษตร (องค์การมหาชน), “มะเขือเทศ: นิยาม ประวัติศาสตร์ และการเดินทางสู่ครัวโลก.” [Online]. Available: <https://www.arda.or.th/detail/6367>.
- [3] สันติ พรหมคำ, “โรคและแมลงศัตรูของมันสำปะหลัง,” การจัดการความรู้เทคโนโลยีการผลิตมันสำปะหลังในพื้นที่ภาคกลางและภาคตะวันตก, pp. 64–86. [Online]. Available: <https://www.doa.go.th/share/attachment.php?aid=2912>.
- [4] F. Naveed *et al.*, “Sustainable AI for Plant Disease Classification using ResNet18 in Few-shot Learning,” *Array*, vol. 26, 2025.
- [5] T. Devi, K. Alice and N. Deepa, “Plant Disease Detection Using Enhanced EfficientNet Architecture in Comparison with DenseNet to Analyze the Severity in Leaves with Performance Measures,” in *Proc. Int. Conf. on Data Science, Agents & Artificial Intelligence*, pp. 1–5, 2022.
- [6] Ü. Atila, M. Uçar, K. Akyol and E. Uçar, “Plant Leaf Disease Classification using EfficientNet Deep Learning Model,” *Ecological Informatics*, vol. 61, 2021.

- [7] J. Feng, W. E. Ong, W. C. Teh and R. Zhang, "Enhanced Crop Disease Detection with EfficientNet Convolutional Group-Wise Transformer," *IEEE Access*, vol. 12, pp. 44147–44162, 2024.
- [8] S. B. S. *et al.*, "Plant Leaf Disease Detection and Classification using MobileNetV3 and Wavelet Kernel Extreme Learning Machine," in *Proc. Int. Conf. on Distributed Computing and Electrical Circuits and Electronics*, pp. 1–6, 2024.
- [9] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," in *Proc. Int. Conf. on Computer Vision and Pattern Recognition*, pp. 770–778, 2016.
- [10] M. Tan and Q. Le. (2019). "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," in *Proc. Int. Conf. on Machine Learning*, pp. 6105–6114, 2019.
- [11] A. Howard *et al.*, "Searching for MobileNetV3," in *Proc. Int. Conf. on Computer Vision*, pp. 1314–1324, 2019.
- [12] N. Sankalana, "Cassava Leaf Disease Classification Dataset." [Online]. Available: <https://www.kaggle.com/datasets/nirmalsankalana/cassava-leaf-disease-classification>. [Accessed: Jul. 15, 2024].
- [13] T. O. i Emmanuel, "Plant Disease Dataset." [Online]. Available: <https://www.kaggle.com/datasets/emmarex/plantdisease>.