

Applying Convolutional Neural Networks for Sugarcane Leaf Disease Image
Classification and Integration with LINE Chatbot to Support Smart Agriculture
การประยุกต์ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันสำหรับการจำแนกภาพโรคใบอ้อยและ
การบูรณาการกับไลน์แชทบอตเพื่อสนับสนุนเกษตรกรอัจฉริยะ

Supachai Baipod¹, Charuay Savithi^{2*}, and Jackaphan Sriwongsa³
ศุภชัย ใบปอด¹, จรวย สาวิถี^{2,*}, และ จักรพันธ์ ศรีวงษา³

Received: 15 July 2025;
Revised: 25 August 2025;
Accepted: 26 August 2025;
Published: 27 August 2025;

Abstract

Plant leaf diseases, particularly sugarcane leaf diseases in Thailand, represent a significant problem affecting sugarcane yield and quality. Traditional disease detection methods are often time-consuming and require specialized expertise. Therefore, this research aims to develop a deep learning model for sugarcane leaf disease diagnosis by applying Convolutional Neural Networks (CNN) techniques and integrating them with LINE chatbot to support smart agriculture. This study compared the performance of five CNN architectures to identify the optimal model for sugarcane leaf disease classification, including VGGNet-16, ResNet-50, DenseNet-121, AlexNet, and GoogLeNet, using the Sugarcane Leaf Disease Dataset collected by the researchers from real-world environments. The sugarcane leaf image dataset was collected from four provinces in the central northeastern region, totaling 4,000 images divided into four categories of 1,000 images each, covering four types of sugarcane leaves: red stripe disease, ring spot disease, rust disease, and healthy sugarcane leaves. The data was split into three ratios of 75:25, 80:20, and 90:10 for training and testing sets, respectively. Experimental results showed that the DenseNet-121 model with a 90:10 ratio achieved the highest performance, with a Macro-average of 97.28%. When the best model was developed into a LINE Chatbot system for automated sugarcane leaf disease diagnosis, system testing demonstrated effective user response capabilities. This research demonstrates the potential of deep learning technology to support farmers in quickly and accurately monitoring sugarcane plant health, which is crucial for developing smart agriculture systems in Thailand.

¹ Student, Department of Smart City Management and Digital Innovation, Faculty of Mahasarakham Business School, Mahasarakham University, Thailand; นักศึกษา สาขาวิชาการจัดการสมาร์ตซิตีและนวัตกรรมดิจิทัล คณะการบัญชีและการจัดการ มหาวิทยาลัยมหาสารคาม ประเทศไทย; Email: 65010988001@msu.ac.th

^{2*} Associate Professor, Dr., Department of Smart City Management and Digital Innovation, Faculty of Mahasarakham Business School, Mahasarakham University, Thailand; รองศาสตราจารย์ สาขาวิชาการจัดการสมาร์ตซิตีและนวัตกรรมดิจิทัล คณะการบัญชีและการจัดการ มหาวิทยาลัยมหาสารคาม ประเทศไทย; Email: charuay.s@msu.ac.th

³ Lecturer, Program in Computer Science, Faculty of Science and Technology, Rajabhat Mahasarakham University, Mahasarakham 44000, Thailand; อาจารย์ สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏมหาสารคาม จังหวัดมหาสารคาม 44000 ประเทศไทย; Email: jackaphan@cs.msu.ac.th

*Corresponding authors: Charuay Savithi (charuay.s@msu.ac.th)



Keywords: Convolutional Neural Networks, Leaf Disease Diagnosis, Image Classification, Line Chatbot, Smart Agriculture

บทคัดย่อ

โรคใบในพืช โดยเฉพาะโรคใบอ้อยในประเทศไทย เป็นปัญหาสำคัญที่ส่งผลกระทบต่อผลผลิตและคุณภาพของอ้อย การตรวจสอบโรคด้วยวิธีดั้งเดิมมักใช้เวลานานและต้องอาศัยความเชี่ยวชาญเฉพาะด้าน ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาโมเดลการเรียนรู้เชิงลึกสำหรับการวินิจฉัยโรคใบอ้อย โดยการนำเทคนิคโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) และการบูรณาการกับไลน์แชตบอตเพื่อรองรับการเกษตรอัจฉริยะ โดยงานวิจัยนี้ได้ทำการเปรียบเทียบประสิทธิภาพของโมเดล CNN ทั้ง 5 สถาปัตยกรรม เพื่อหาโมเดลที่ดีที่สุดเหมาะสมกับปัญหาการจำแนกโรคใบอ้อย ประกอบด้วย VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet โดยใช้ชุดข้อมูล Sugarcane Leaf Disease Dataset ที่ดำเนินการจัดเก็บจากสภาพแวดล้อมจริง ชุดข้อมูลภาพใบอ้อยถูกรวบรวมจากกลุ่มพื้นที่จังหวัดในภาคตะวันออกเฉียงเหนือตอนกลาง 4 จังหวัด จำนวน 4,000 ภาพ แบ่งเป็น 4 ประเภทอย่างละ 1,000 ภาพ ประกอบด้วยภาพใบอ้อยครอบคลุม 4 ประเภท ได้แก่ โรคเส้นกลางใบแดง โรคใบจุดวงแหวน โรคราสนิม และใบอ้อยปกติ ข้อมูลถูกแบ่งเป็น 3 อัตราส่วน คือ 75:25, 80:20 และ 90:10 สำหรับชุดฝึกสอนและชุดทดสอบ ตามลำดับ ผลการทดลองแสดงให้เห็นว่าโมเดล DenseNet-121 ด้วยอัตราส่วน 90:10 ให้ประสิทธิภาพสูงสุด โดยมีค่าเฉลี่ยแบบมาโคร (Macro-average) สูงที่สุด 97.28% เมื่อนำโมเดลที่ดีที่สุดไปพัฒนาเป็นระบบ LINE Chatbot สำหรับการวินิจฉัยโรคใบอ้อยแบบอัตโนมัติ ผลการทดสอบระบบแสดงให้เห็นว่าสามารถตอบสนองผู้ใช้งานได้อย่างมีประสิทธิภาพ งานวิจัยนี้แสดงให้เห็นถึงศักยภาพของเทคโนโลยีการเรียนรู้เชิงลึกในการสนับสนุนเกษตรกรให้สามารถตรวจสอบสุขภาพพืชอ้อยได้อย่างรวดเร็วและแม่นยำ ซึ่งเป็นส่วนสำคัญในการพัฒนาระบบเกษตรอัจฉริยะในประเทศไทย

คำสำคัญ: โครงข่ายประสาทเทียมแบบคอนโวลูชัน, การวินิจฉัยโรคใบพืช, การจำแนกภาพ, ไลน์แชตบอต, เกษตรอัจฉริยะ

1. บทนำ (Introduction)

ภาคการเกษตรเป็นภาคการผลิตที่มีความสำคัญอย่างยิ่งต่อการพัฒนาเศรษฐกิจ สังคม และสิ่งแวดล้อมของประเทศไทย โดยมีพื้นที่การเกษตรกว่า 149.25 ล้านไร่ คิดเป็นร้อยละ 46.5 ของพื้นที่ทั้งประเทศ (Office of Agricultural Economics, 2023) ถึงแม้สัดส่วนของภาคเกษตรต่อผลิตภัณฑ์มวลรวมในประเทศ (GDP) จะลดลงอย่างต่อเนื่อง แต่ยังคงมีบทบาทสำคัญในด้านการจ้างงาน การผลิตอาหาร และการส่งออก โดยเฉพาะในช่วง 5 ปีที่ผ่านมา ประเทศไทยมีรายได้จากการส่งออกสินค้าเกษตรและผลิตภัณฑ์เฉลี่ยปีละ 1.39 ล้านล้านบาท และเกินดุลการค้าเฉลี่ย 8.6 แสนล้านบาท (Kasikorn Research Center, 2023) ภาคเกษตรยังทำหน้าที่รองรับแรงงานจากภาคเศรษฐกิจอื่นในช่วงวิกฤต เช่น การแพร่ระบาดของโควิด-19 ได้อย่างมีประสิทธิภาพ จึงเกิดแนวโน้มการพัฒนาเทคโนโลยีเพื่อเพิ่มผลผลิต ลดต้นทุน และยกระดับภาคเกษตรสู่ระบบเกษตรอัจฉริยะ (Smart Agriculture) ที่มีความยั่งยืนในระยะยาว (Farooq et al., 2020)

อ้อยเป็นหนึ่งในพืชเศรษฐกิจที่สำคัญของประเทศไทย โดยเฉพาะในภาคตะวันออกเฉียงเหนือตอนกลาง ซึ่งเป็นแหล่งเพาะปลูกขนาดใหญ่ ในปีการผลิต 2566/2567 พื้นที่เพาะปลูกอ้อยรวมทั้งสิ้น 11.39 ล้านไร่ เพิ่มขึ้นจากปีก่อนหน้ากว่า 376,000 ไร่ โดยกว่าร้อยละ 80 ของพื้นที่เพาะปลูกใช้พันธุ์ขอนแก่น 3 ซึ่งเหมาะสมกับสภาพพื้นที่แห้งแล้ง (Office of The Cane and Sugar Board, 2023) การเพิ่มขึ้นของพื้นที่เพาะปลูกอ้อยในประเทศไทยจากแนวโน้มราคาน้ำตาลในตลาดโลกที่ปรับตัวสูงขึ้น แต่ยังคงประสบปัญหาจากโรคพืชที่แสดงอาการบนใบอ้อย ได้แก่ โรคเส้นกลางใบแดง (Red

Stripe Disease) โรคใบจุดวงแหวน (Ring Spot Disease) โรคราสนิม (Rust Disease) เป็นต้น (Hamaan, 2016) ซึ่งส่งผลกระทบต่อผลผลิตในเชิงเศรษฐกิจอย่างมีนัยสำคัญ การวินิจฉัยโรคพืชที่รวดเร็วและแม่นยำจึงมีความจำเป็นอย่างต่อเนื่องต่อการควบคุมการระบาดและลดความเสียหาย

โรคพืชเป็นปัญหาสำคัญในอุตสาหกรรมเกษตร เนื่องจากส่งผลกระทบต่อผลผลิตและเศรษฐกิจ แนวทางแก้ไขที่ได้รับความสนใจในปัจจุบันคือการจำแนกภาพอาการของโรค โดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ซึ่งความแม่นยำขึ้นอยู่กับปริมาณและคุณภาพของข้อมูล รวมถึงการปรับปรุงภาพเพื่อเพิ่มประสิทธิภาพการจำแนก งานวิจัยโรคพืชที่เกี่ยวข้อง ได้แก่ Wongsarapee & Puangmanee (2025) นำเสนอวิธีเสริมคุณภาพภาพด้วยฮาร์วเฟิลต์เพื่อจำแนกโรคบนใบสตรอเบอร์รี่ พบว่าช่วยเพิ่มความแม่นยำและลดเวลาในการประมวลผล Mekha et al. (2023) ศึกษาการจำแนกโรคใบข้าวโพดด้วยโมเดล InceptionV3, VGG16, Xception และ Custom Vision โดย Custom Vision ให้ความแม่นยำสูงสุด (98.1%) และมีขนาดโมเดล 21.2 MB ประมวลผลภายใน 6.89 วินาที Harshitha et al. (2024) พัฒนาระบบตรวจจับโรคใบพืชอัตโนมัติที่มีความรวดเร็ว ใช้งานง่าย และแนะนำวิธีการรักษาพร้อมลิงก์สั่งซื้อออนไลน์ Ganesh et al. (2025) ใช้เทคนิคการตรวจจับภาพล่วงหน้า การสกัดคุณลักษณะ และอัลกอริทึม ML และ DL ร่วมกับเซ็นเซอร์ เพื่อตรวจจับโรคอย่างแม่นยำตั้งแต่ระยะเริ่มต้น ลดการสูญเสียผลผลิตและการใช้สารเคมี Alias & Mohammed (2022) แนะนำการใช้ SVM และการจัดกลุ่มแบบ K-Means เพื่อตรวจจับโรคจากคุณลักษณะสีและพื้นผิว โดย SVM แสดงประสิทธิภาพสูงในการระบุโรค ขณะที่ Pujari et al. (2015) มุ่งเน้นการประมวลผลภาพเพื่อจำแนกโรคเชื้อราบนพืช เพื่อการตรวจจับตั้งแต่ระยะเริ่มต้น

การประมวลผลภาพ (Image Processing) ถูกนำมาใช้อย่างกว้างขวางในวิธีการวินิจฉัยโรคต่าง ๆ Petrellis (2018) ได้ทบทวนวรรณกรรมเกี่ยวกับการนำการประมวลผลภาพ มาช่วยในการวินิจฉัยโรค ไม่ว่าจะเป็นเกี่ยวข้องกับมนุษย์ สัตว์ และพืช ซึ่งช่วยให้ผู้เชี่ยวชาญเลือกวิธีการรักษาที่เหมาะสมได้ ในการประยุกต์ใช้ในการวินิจฉัยโรคที่อ้างอิงส่วนใหญ่ ภาพจะถูกปรับปรุงด้วยวิธีการกรองข้อมูล (Filtering Methods) ที่หลากหลาย และตามด้วยการแบ่งส่วน (Segmentation) เพื่อแยกส่วนที่ต้องการ และขั้นตอนสุดท้ายจะทำการจำแนกภาพ (Classification) นอกจากนี้การประมวลผลภาพยังมีการนำมาใช้ในงานด้านอื่น เช่น การวิเคราะห์ภาพผลิตภัณฑ์อาหารสำหรับระบบตรวจสอบสถานะฮาลาลสำหรับผู้บริโภค (Petrellis, 2018, Adulyasas et al., 2023)

เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ได้รับความสนใจอย่างกว้างขวางในการวิเคราะห์ภาพถ่ายทางการแพทย์ เนื่องจากมีความสามารถจำแนกภาพซับซ้อนและประมวลผลได้แม่นยำและรวดเร็ว (Ditcharoen et al., 2023) อย่างไรก็ตามยังขาดงานวิจัยที่มุ่งเน้นโรคใบอ้อยในบริบทประเทศไทย โดยเฉพาะการใช้งานจริงผ่านแพลตฟอร์มที่เกษตรกรเข้าถึงได้ เช่น LINE Chatbot จากแนวโน้มดังกล่าว จึงพัฒนาโมเดล CNN สำหรับวินิจฉัยโรคจากภาพใบอ้อย และเปรียบเทียบประสิทธิภาพสถาปัตยกรรม 5 แบบ ได้แก่ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet เพื่อเลือกโมเดลที่เหมาะสมที่สุดก่อนนำไปประยุกต์ในระบบแชตบอตอัตโนมัติบน LINE เพื่อให้ใช้งานจริงในภาคเกษตร ผลลัพธ์แสดงให้เห็นว่าเทคโนโลยีนี้ช่วยเพิ่มความแม่นยำและลดภาระการตรวจด้วยตาเปล่า สนับสนุนเกษตรกรในการจัดการโรคได้มีประสิทธิภาพ และเป็นพื้นฐานต่อยอดสู่ระบบฟาร์มอัจฉริยะในอนาคต สอดคล้องกับทิศทางการพัฒนาเกษตรอัจฉริยะของประเทศ

2. วัตถุประสงค์งานวิจัย (Research Objectives)

1. เพื่อเปรียบเทียบประสิทธิภาพของสถาปัตยกรรมโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) จำนวน 5 สถาปัตยกรรม ได้แก่ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet ในการจำแนกประเภทโรคที่ปรากฏบนใบอ้อยจากภาพถ่าย
2. เพื่อพัฒนาระบบแชตบอตอัตโนมัติบนแพลตฟอร์ม LINE สำหรับการวินิจฉัยโรคใบอ้อยแบบเรียลไทม์ เพื่อรองรับการประยุกต์ใช้ในระบบเกษตรอัจฉริยะ

3. กรอบแนวคิดงานวิจัย (Conceptual Framework)

งานวิจัยนี้เป็นงานวิจัยแบบตัดขวาง (Cross-Sectional Design) โดยใช้ข้อมูลแบบปฐมภูมิ (Primary Data) ที่รวบรวมโดยการลงพื้นที่เก็บรวบรวมข้อมูลภาพ (Image Collection) จากกลุ่มพื้นที่จังหวัดในภาคตะวันออกเฉียงเหนือตอนกลาง 4 จังหวัด ได้แก่ จังหวัดมหาสารคาม ขอนแก่น กาฬสินธุ์ และร้อยเอ็ด ชุดข้อมูลภาพใบอ้อยมีการดำเนินการ

จัดเก็บในช่วงเดือน กุมภาพันธ์ พ.ศ. 2567 ถึง เมษายน พ.ศ. 2567 จำนวน 4,000 ภาพ ซึ่งมีการจำแนกโรคใบอ้อย 4 ประเภท ได้แก่ โรคเส้นกลางใบแดง (Red Stripe Disease: RedRot) โรคใบจุดวงแหวน (Ring Spot Disease: RingSpot) โรคราสนิม (Rust Disease: Rust) และใบอ้อยปกติ (Healthy Leaves: Healthy) โดยการวิจัยนี้นำเสนอกรอบแนวคิดการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกสำหรับการวินิจฉัยโรคใบอ้อย โดยประกอบด้วยขั้นตอนสำคัญ ได้แก่ การเก็บรวบรวมภาพ การประมวลผลเบื้องต้นด้วยการลบภาพที่ไม่เกี่ยวข้อง ปรับขนาด ตัดภาพ และแปลงไฟล์ให้อยู่ในรูปแบบมาตรฐาน จากนั้นทำการแบ่งชุดข้อมูลเพื่อฝึกสอนและทดสอบในสัดส่วนที่เหมาะสม และจัดเก็บอย่างมีโครงสร้าง ขั้นตอนการเรียนรู้ใช้สถาปัตยกรรมโครงข่ายประสาทเทียมเชิงลึก 5 แบบ ได้แก่ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet พร้อมประเมินผลด้วยดัชนี Accuracy, Precision, Recall, F1-Score และวิเคราะห์ด้วยเมตริกซ์ความสับสน เพื่อระบุโมเดลที่มีประสิทธิภาพสูงสุด และนำมาพัฒนาเป็นระบบแชทบอตอัตโนมัติบนแพลตฟอร์ม LINE สำหรับการวินิจฉัยโรคใบอ้อยแบบเรียลไทม์ เพื่อสนับสนุนการเกษตรอัจฉริยะอย่างมีประสิทธิภาพ โดยมีกรอบแนวคิดแสดงดัง Figure 1.




Figure 1. Conceptual Framework.

4. การทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง (Literature Review)

4.1 การประยุกต์ใช้ Deep Learning และ CNN สำหรับการวิเคราะห์โรคพืชด้วยภาพถ่าย

การวินิจฉัยโรคพืชด้วยภาพถ่ายโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) ได้รับความนิยมอย่างแพร่หลาย เนื่องจากสามารถประมวลผลภาพและจำแนกความผิดปกติได้อย่างแม่นยำ งานวิจัยที่เกี่ยวข้องในด้านนี้มีหลากหลายรูปแบบ ทั้งในแง่ของสถาปัตยกรรมที่ใช้ เทคนิคการฝึกสอน การเพิ่มประสิทธิภาพโมเดล รวมถึงการประยุกต์ใช้งานจริงในระบบสนับสนุนการตัดสินใจ

Saisangchan et al. (2022) ได้ศึกษาการจำแนกภาพใบมะนาวที่เป็นโรคและไม่เป็นโรคด้วยเทคนิคการเรียนรู้เชิงลึก โดยใช้สถาปัตยกรรม LeNet-5, VGG16, ResNet-50 และแบบจำลองที่พัฒนาขึ้นเองจากพื้นฐานของ VGGNet ซึ่งปรับลดขนาดของชั้นการเรียนรู้และจำนวนพารามิเตอร์ เพื่อเพิ่มความเร็วในการประมวลผลโดยไม่ลดทอนความแม่นยำ การทดลองใช้ชุดข้อมูลภาพถ่ายใบมะนาวจำนวน 5,710 ภาพ แบ่งชุดข้อมูลเป็นชุดฝึกสอนร้อยละ 80 และชุดทดสอบร้อยละ 20 ผลการวิจัยพบว่าสถาปัตยกรรมที่พัฒนาขึ้นมีความแม่นยำสูงสุดที่ 89.06% ขณะที่ LeNet-5 มีความแม่นยำต่ำสุดที่ 78.90%

Makkawal et al. (2022) ได้พัฒนาเว็บแอปพลิเคชันเพื่อจำแนกสายพันธุ์กล้วยต่างโดยใช้เทคนิค CNN โดยรวบรวมภาพกล้วยต่าง 5 สายพันธุ์จากองค์การสวนพฤกษศาสตร์ และแบ่งข้อมูลเป็นชุดฝึกสอนร้อยละ 70 และชุดทดสอบร้อยละ 30 ผลการวิเคราะห์ด้วยค่า F1-Score แสดงความแม่นยำสูงสุดที่ 83.00%

Jomsri et al. (2021) ได้พัฒนาระบบตรวจวินิจฉัยโรคใบของดาวเรืองโดยใช้เทคโนโลยี IoT ร่วมกับเทคนิคซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) สำหรับการจำแนกโรคใบจุดจากภาพถ่าย โดยได้ผลความ

แม่นยำที่ 86% และระดับความพึงพอใจจากเกษตรกรอยู่ในระดับมากที่สุด ทั้งยังพบว่าการใช้ระบบช่วยลดความผิดพลาดในการวินิจฉัยได้อย่างมีนัยสำคัญ

Enkvetchakul & Surinta (2022) ได้ศึกษาและเปรียบเทียบสถาปัตยกรรม MobileNetV2 และ NASNetMobile ซึ่งออกแบบมาให้เหมาะสมกับการประมวลผลบนอุปกรณ์เคลื่อนที่ โดยใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) ร่วมกับการเรียนรู้ถ่ายทอด (Transfer Learning) ผลการทดลองพบว่า NASNetMobile ให้ผลลัพธ์ที่แม่นยำสูงสุดเมื่อนำเทคนิคการหมุน (Rotation) การเลื่อน (Translation) และการซูม (Zoom) มาประยุกต์ร่วมกันในขั้นตอนการฝึกสอนโมเดล

Amin et al. (2022) ได้ศึกษาการพัฒนาโมเดลการเรียนรู้เชิงลึกแบบ End-to-End สำหรับการจำแนกใบข้าวโพดที่มีสุขภาพดีและไม่ดี โดยมีจุดประสงค์ด้านขนาดของโมเดลในสถาปัตยกรรมทั่วไป ผ่านการรวมคุณลักษณะเชิงลึกจากโครงข่ายที่ผ่านการฝึกอบรมล่วงหน้า ได้แก่ EfficientNetB0 และ DenseNet121 ด้วยเทคนิคการเชื่อมต่อ (Concatenation) พร้อมประยุกต์ใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) เพื่อเพิ่มความหลากหลายของชุดข้อมูลในการฝึกสอน ผลการวิจัยพบว่าโมเดลที่พัฒนาขึ้นแสดงความแม่นยำสูงสุดที่ 98.56% ซึ่งเหนือกว่า ResNet152 และ InceptionV3 ที่มีความแม่นยำ 98.37% และ 96.26% ตามลำดับ

Daphal & Koli (2024) ได้การนำเสนอสถาปัตยกรรมการเรียนรู้เชิงลึกแบบหลายระดับร่วมกับกลไกความสนใจ (Attention-Based Multilevel Architecture) สำหรับการจำแนกโรคในใบอ้อย โดยใช้ทั้ง Spatial Attention และ Channel Attention ในการสกัดข้อมูลสำคัญ ผลการทดลองพบว่า โมเดลสามารถจำแนกโรคได้ด้วยความแม่นยำสูงถึง 86.53% ซึ่งสูงกว่าสถาปัตยกรรมขั้นสูงอื่น ๆ เช่น VGG19, ResNet50, XceptionNet และ EfficientNet-B7 โดยเฉพาะในบริบทของชุดข้อมูลขนาดเล็ก นอกจากนี้ยังมีการประยุกต์ใช้งานจริงผ่านแอปพลิเคชันบนสมาร์ตโฟนระบบ Android เพื่อรองรับการวินิจฉัยโรคใบอ้อยในภาคสนาม

จากการทบทวนงานวิจัยข้างต้น พบว่างานวิจัยมีจุดเด่นและข้อจำกัดที่แตกต่างกัน งานของ Saisangchan et al. (2022) และ Makkawal et al. (2022) แสดงให้เห็นประสิทธิภาพของ CNN ในการจำแนกโรคพืช แต่มีข้อจำกัดในการเข้าถึงของเกษตรกรเนื่องจากต้องใช้ผ่านเว็บแอปพลิเคชัน งานของ Jomsri et al. (2021) ถึงแม้จะมีการประยุกต์ใช้ IoT และได้รับความพึงพอใจสูงจากเกษตรกร แต่ใช้เทคนิค SVM ซึ่งมีประสิทธิภาพต่ำกว่า CNN งานของ Enkvetchakul & Surinta (2022) และ Amin et al. (2022) เน้นการพัฒนาโมเดลที่เหมาะสมกับอุปกรณ์เคลื่อนที่และมีความแม่นยำสูง แต่ยังคงขาดการพัฒนาาระบบที่เกษตรกรสามารถใช้งานได้จริงอย่างสะดวก งานของ Daphal & Koli (2024) ถึงแม้จะมีการพัฒนาแอปพลิเคชันสำหรับใบอ้อยโดยเฉพาะ แต่ยังไม่มีการบูรณาการกับระบบการสื่อสารที่เกษตรกรคุ้นเคยในชีวิตประจำวัน และแม้จะมีงานวิจัยมากมายที่ประยุกต์ใช้เทคนิค Deep Learning และ CNN สำหรับการจำแนกโรคพืช แต่ยังมีส่วนที่ยังขาดการศึกษาวิจัย ได้แก่ (1) งานวิจัยที่เน้นเฉพาะโรคใบอ้อยในบริบทของประเทศไทย (2) การทำระบบที่บูรณาการเทคโนโลยี AI เข้ากับแพลตฟอร์มการสื่อสารที่เกษตรกรใช้ในชีวิตประจำวัน ดังนั้นการวิจัยนี้จึงมีความสำคัญในการพัฒนาโมเดล CNN ที่เฉพาะเจาะจงสำหรับการจำแนกโรคใบอ้อยในบริบทพื้นที่ถิ่นของประเทศไทย และการบูรณาการเข้ากับ LINE Chatbot ซึ่งเป็นแพลตฟอร์มที่เกษตรกรไทยใช้กันอย่างแพร่หลาย

4.2 การประมวลผลภาพ (Image Processing)

การประมวลผลภาพ (Image Processing) หมายถึงกระบวนการทางคอมพิวเตอร์ที่ประยุกต์ใช้เทคนิคต่าง ๆ เพื่อวิเคราะห์และดัดแปลงภาพดิจิทัล โดยประกอบด้วยขั้นตอนหลัก เช่น การปรับปรุงคุณภาพของภาพ (Image Enhancement) การแยกส่วน (Segmentation) การดึงคุณลักษณะเฉพาะ (Feature Extraction) และการจำแนกประเภท (Classification) เพื่อสกัดข้อมูลหรือข้อสรุปที่ต้องการจากภาพ ในบริบทการวิจัยด้านการวินิจฉัยโรคพืช การประมวลผลภาพมีบทบาทสำคัญในการตรวจจับและจำแนกโรคจากภาพถ่ายใบพืชอย่างมีประสิทธิภาพ กระบวนการดังกล่าวมีขั้นตอนการดำเนินงานที่เป็นระบบ ประกอบด้วย การรับภาพ (Image Acquisition) การเตรียมภาพ (Preprocessing) การแบ่งส่วนภาพ (Segmentation) การดึงคุณลักษณะเฉพาะ (Feature Extraction) และการจำแนกโรคโดยใช้อัลกอริทึม Machine Learning หรือ Deep Learning เช่น Convolutional Neural Networks (CNN) การประยุกต์ใช้เทคโนโลยีการประมวลผลภาพในการวินิจฉัยโรคพืชมีประโยชน์หลายประการ ได้แก่ ความสามารถในการตรวจพบโรคในระยะเริ่มต้น การลดการสูญเสียผลผลิต และการสนับสนุนการเกษตรยั่งยืน เทคโนโลยีนี้ช่วยเพิ่มความแม่นยำและความรวดเร็วในการวินิจฉัย ซึ่งเป็นปัจจัยสำคัญต่อการจัดการโรคพืชอย่างมีประสิทธิภาพ (Ganesh et al., 2025; Harshitha et al., 2024)

จากการทบทวนวรรณกรรมพบว่า การประมวลผลภาพ (Image Processing) ได้รับการประยุกต์ใช้อย่างแพร่หลายในการวินิจฉัยโรคในมนุษย์ สัตว์ และพืช เพื่อช่วยผู้เชี่ยวชาญในการเลือกวิธีการรักษาที่เหมาะสม ข้อมูลภาพที่ใช้ในกระบวนการอาจได้จากกล้องถ่ายภาพแสงที่มองเห็นได้ หรือจากอุปกรณ์ที่บันทึกข้อมูลในช่วงความยาวคลื่นที่มองไม่เห็น เช่น เซ็นเซอร์แม่เหล็ก อัลตราโซนิก และกล้องจุลทรรศน์ โดยทั่วไป การวิเคราะห์ภาพจะเริ่มจากการปรับปรุงคุณภาพภาพด้วยวิธีการกรองข้อมูลหลากหลายรูปแบบ ตามด้วยการแบ่งส่วนเพื่อแยกบริเวณที่สนใจ และสิ้นสุดด้วยขั้นตอนการจำแนกประเภทภาพ วิธีการเหล่านี้ถูกนำไปประยุกต์ในกระบวนการทำงานสำหรับการวินิจฉัยโรคพืชที่พัฒนาขึ้นในงานวิจัยนี้ พร้อมทั้งการอ้างอิงถึงตัววัด เงื่อนไขการทดลอง และผลลัพธ์ที่เกี่ยวข้องในงานก่อนหน้า ซึ่งชี้ให้เห็นว่าการวินิจฉัยด้วยเทคนิคการประมวลผลภาพให้ผลลัพธ์ที่มีความแม่นยำสูง และสามารถต่อยอดเพื่อพัฒนาแอปพลิเคชันที่มีลักษณะใกล้เคียงหรือแตกต่างได้อย่างมีประสิทธิภาพ (Petrellis, 2018)

การประมวลผลภาพ (Image Processing) เป็นกระบวนการใช้เทคนิคและอัลกอริทึมเพื่อแปลงภาพดิจิทัลให้มีคุณภาพดีขึ้นและสกัดข้อมูลที่มีประโยชน์ โดยแบ่งออกเป็น 4 กระบวนการหลักดังนี้

1. การปรับปรุงคุณภาพภาพ (Image Enhancement) เป็นกระบวนการปรับปรุงภาพให้เหมาะสมต่อการรับรู้ของมนุษย์หรือการประมวลผลต่อไป โดยใช้เทคนิค Point Operations สำหรับการปรับความสว่างและความคมชัด การกรองเชิงพื้นที่ (Spatial Filtering) สำหรับการลดสัญญาณรบกวน และ Histogram Equalization เพื่อปรับการกระจายค่าความเข้มแสง

2. การแยกส่วนภาพ (Image Segmentation) เป็นกระบวนการแบ่งภาพออกเป็นหลายบริเวณที่มีคุณลักษณะคล้ายคลึงกัน โดยใช้เทคนิค Threshold-based Segmentation, Edge-based Segmentation และ Region-based Segmentation เพื่อแยกวัตถุออกจากพื้นหลัง

3. การแปลงสีและพื้นที่สี (Color Space Transformation) เป็นการแปลงระบบสีจาก RGB ไปยังพื้นที่สีอื่น ๆ เช่น HSV, LAB หรือ YUV เพื่อให้การวิเคราะห์มีประสิทธิภาพมากขึ้น รวมถึงการปรับแต่งสี (Color Correction) และการปรับสมดุลสี (Color Balance)

4. การสกัดลักษณะเด่น (Feature Extraction) เป็นกระบวนการสกัดข้อมูลสำคัญจากภาพ เช่น Edge Detection โดยใช้ Sobel, Canny หรือ Laplacian operators, Corner Detection สำหรับจุดสำคัญ และ Texture Analysis เพื่อวิเคราะห์ลวดลายผิวของวัตถุในภาพ (Archana & Jeevaraj, 2024)

4.3 การเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep learning) เป็นส่วนย่อยของการเรียนรู้ของเครื่อง (Machine learning) การเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องนั้น เป็นส่วนย่อยของปัญญาประดิษฐ์ (Artificial intelligence: AI) (Koedsri, 2021) ความแตกต่างสำคัญระหว่างการเรียนรู้เชิงลึก (Deep Learning) กับการเรียนรู้ของเครื่องแบบดั้งเดิม (Traditional Machine Learning) คือ ความสามารถในการพัฒนาประสิทธิภาพตามขนาดของข้อมูล โดยโมเดลแบบ Deep Learning มักให้ผลลัพธ์ที่แม่นยำยิ่งขึ้นเมื่อได้รับข้อมูลจำนวนมาก ขณะที่อัลกอริทึมแบบดั้งเดิมและโครงข่ายประสาทเทียมขนาดเล็กมักเหมาะสมกับชุดข้อมูลขนาดเล็ก การเลือกใช้อัลกอริทึมให้สอดคล้องกับลักษณะปัญหาและขนาดข้อมูลจึงเป็นแนวทางสำคัญในการเพิ่มประสิทธิภาพของแบบจำลองโดยไม่จำเป็นต้องพึ่งพาปริมาณข้อมูลที่มากเสมอไป (Vento & Fanfarillo, 2019)

การเรียนรู้เชิงลึก (Deep Learning) เป็นเทคนิคที่ได้รับความนิยมอย่างแพร่หลายในงานประมวลผลภาพ (Image Processing) และการรู้จำภาพ (Computer Vision) โดยอาศัยโครงข่ายประสาทเทียมหลายชั้นในการสกัดและถ่ายทอดคุณลักษณะจากระดับพิกเซลเพื่อนำไปใช้ในการจำแนกประเภท โดยทั่วไปสามารถแบ่งออกเป็น 3 ประเภทหลัก ได้แก่ (1) โครงข่ายแบบมีผู้สอน เช่น DNN, CNN และ RNN ซึ่งเหมาะกับข้อมูลที่มีการระบุผลเฉลยจำนวนมาก (2) โครงข่ายแบบไม่มีผู้สอน เช่น Deep Autoencoder, DBN และ RBM ที่ใช้เรียนรู้จากข้อมูลโดยไม่ต้องพึ่งผลเฉลย และ (3) โครงข่ายแบบผสมที่ใช้การเรียนรู้แบบไม่มีผู้สอนในขั้นต้นก่อนนำไปปรับด้วยแบบมีผู้สอน เช่น DBN ร่วมกับ DNN หรือ CNN ซึ่งได้รับความนิยมเพิ่มขึ้นเนื่องจากสามารถปรับใช้ได้แม้มีข้อมูลจำนวนน้อย (Saisangchan et al., 2022)

4.4 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN)

โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) จำลองการมองเห็นของมนุษย์ประกอบด้วยชุดของ Convolution และ Sub-Sampling Layer ตามด้วยเลเยอร์เชื่อมต่ออย่างสมบูรณ์ (Shrestha & Mahmood, 2019) โดยทำงานกับภาพในรูปเมทริกซ์พิกเซลและจำลองการมองเป็นพื้นที่ย่อย ๆ เพื่อนำมาจำแนก

(Classification) และผสมผสานข้อมูลย่อยเหล่านั้นในการระบุสิ่งที่เห็น อัลกอริทึม CNN แบ่งการทำงานออกเป็นสองส่วนหลัก ได้แก่ Feature Extraction และ Classification โดย Feature Extraction ใช้ฟิลเตอร์ (Filter) ในการคัดเลือกคุณลักษณะสำคัญจากข้อมูลเพื่อใช้ในการทำนายผลที่ขั้นตอน Classification ฟิลเตอร์จะถูกกำหนดขนาดและวางลงบนข้อมูลเพื่อระบุบริเวณที่ต้องวิเคราะห์และประมวลผลออกมา CNN เป็นโครงข่ายประสาทเทียมหลายชั้น (Multilayer Perceptron) ที่สามารถดึงลักษณะเด่นของข้อมูลและจำแนกผลได้โดยตรง จึงเหมาะสำหรับการจำแนกรูปภาพ (Hongboonmee & Kanyaprasit, 2021)

ดังนั้นในการวิจัยนี้ จึงนำเสนอการวินิจฉัยโรคพืชที่ปรากฏอาการบนใบอ้อย โดยใช้ CNN เป็นหลักในการประมวลผลข้อมูลของชุดรูปภาพทั้งหมด และเปรียบเทียบโดยใช้ลักษณะโครงสร้าง (Architecture) ที่แตกต่างกัน 5 สถาปัตยกรรม

4.5 การวัดประสิทธิภาพของโมเดล (Performance Measurement)

การจำแนกประเภท (Classification) เป็นกระบวนการประเมินประสิทธิภาพของแบบจำลองที่ถูกฝึกขึ้นเพื่อใช้ในการจำแนกกลุ่มของข้อมูล (Hongboonmee & Sitthichokchaisiri, 2021) โดยเฉพาะอย่างยิ่งกับข้อมูลที่ไม่เคยถูกใช้ในการระหว่างการฝึกสอน (Training Set) การประเมินนี้มีวัตถุประสงค์เพื่อวัดความสามารถของแบบจำลองในการพยากรณ์ผลลัพธ์อย่างถูกต้องผ่านเมตริกซ์ (Metrics) หรือตัวชี้วัดที่ได้มาตรฐาน (Saisangchan et al., 2022) โดยหนึ่งในวิธีการพื้นฐานที่นิยมใช้คือ Confusion Matrix ซึ่งเป็นสรุปผลการจำแนกที่แสดงให้เห็นจำนวนการทำนายที่ถูกต้องและผิดพลาดในแต่ละกลุ่มเป้าหมายของโมเดล โดยในงานวิจัยนี้มีการใช้ Confusion Matrix เพื่อเป็นพื้นฐานในการคำนวณค่าต่าง ๆ เพื่อประเมินประสิทธิภาพของแบบจำลอง (Yap et al., 2021) ได้แก่ ความแม่นยำ (Accuracy) ความเที่ยงตรง (Precision) ค่าการเรียกคืน (Recall หรือ Sensitivity) F1-Score และค่าเฉลี่ยแบบมาโคร (Macro-average) ซึ่งการวัดผลดังกล่าวช่วยให้สามารถประเมินความสามารถในการจำแนกของโมเดลได้อย่างครอบคลุมในหลากหลายมิติ และเป็นพื้นฐานสำคัญในการเปรียบเทียบประสิทธิภาพของแบบจำลองต่าง ๆ ที่นำมาใช้ในการวิจัย

5. วิธีดำเนินงานวิจัย (Research Methodology)

งานวิจัยนี้ออกแบบและดำเนินการทดลองโดยประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน 5 สถาปัตยกรรม ได้แก่ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet เพื่อวิเคราะห์และเปรียบเทียบประสิทธิภาพในการจำแนกโรคจากภาพใบอ้อยบนชุดข้อมูลที่สร้างขึ้นเอง พร้อมทั้งพัฒนาระบบ LINE Chatbot เพื่อรองรับการใช้งานจริงในบริบทของเกษตรกรอัจฉริยะ โดยขั้นตอนการดำเนินการวิจัยดังต่อไปนี้

5.1 เก็บข้อมูลรูปภาพที่ใช้ในการวิจัย

การเก็บรวบรวมข้อมูลภาพใบอ้อยสำหรับการวิจัยนี้ได้สร้างชุดข้อมูล Sugarcane Leaf Disease Dataset ที่ประกอบด้วยภาพถ่ายใบอ้อยจำนวน 4,000 ภาพ โดยแบ่งเป็น 4 กลุ่มย่อยตามสภาพของใบอ้อยในสัดส่วนที่เท่ากัน ได้แก่ โรคเส้นกลางใบแดง (RedRot) โรคใบจุดวงแหวน (RingSpot) โรคราสนิม (Rust) และใบอ้อยสุขภาพดี (Healthy) ที่ไม่แสดงอาการของโรค กลุ่มละ 1,000 ภาพ ดังแสดงใน Figure 2. (a) - (d) ตามลำดับ ทั้งหมดเก็บรวบรวมจากสภาพแวดล้อมจริงในแปลงเพาะปลูกอ้อยเพื่อให้ได้ข้อมูลที่สะท้อนลักษณะอาการของโรคที่แท้จริงและมีความหลากหลายในด้านสภาพแสง มุมมอง และระยะการถ่ายภาพ




Figure 2. Images of diseased sugarcane leave (a) RedRot, (b) RingSpot, (c) Rust, and (d) Healthy.

งานวิจัยนี้ดำเนินการวิจัยด้วยการออกแบบกรอบแนวคิดแบบตัดขวาง (Cross-Sectional Design) โดยใช้ข้อมูลแบบปฐมภูมิ (Primary Data) ที่รวบรวมภาพทั้งหมดถ่ายจากแปลงเกษตรในสภาพแวดล้อมจริง โดยลงพื้นที่เก็บข้อมูลในกลุ่มจังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง 4 จังหวัด ได้แก่ จังหวัดมหาสารคาม ขอนแก่น กาฬสินธุ์ และร้อยเอ็ด ชุดข้อมูลภาพใบอ้อยมีการดำเนินการจัดเก็บในช่วงเดือน กุมภาพันธ์ พ.ศ. 2567 ถึง เมษายน พ.ศ. 2567 จำนวน 4,000 ภาพ กระบวนการรวบรวมข้อมูลได้ควบคุมวิธีการ สภาพแวดล้อม และตัวแปรตามอื่น ๆ ที่อาจส่งผลกระทบต่อคุณภาพของรูปดังนี้

1. สภาพแวดล้อม (Environment) ภาพที่จัดเก็บจะอยู่ในสภาพแวดล้อมที่มีลักษณะเดียวกัน คือ ช่วงเวลา 08.00 - 12.00 น. ซึ่งเป็นช่วงเวลาที่ให้แสงที่มีความเหมาะสมเพียงพอกับการถ่ายภาพ
2. ลักษณะเด่นในภาพ (Features) ในการถ่ายภาพจะถ่ายภาพใบอ้อยที่มีลักษณะเด่นที่เห็นได้ชัดเจน เช่น ใบที่ติดเชื้อปรากฏลักษณะของโรคใบอ้อยชัดเจน และใบอ้อยปกติที่ไม่มีปรากฏอาการของโรคต่าง ๆ
3. อุปกรณ์ถ่ายภาพ (Camera) ดำเนินการถ่ายภาพด้วยกล้องชนิดเดียวกันทุกภาพ กล้องความเยียด 12MP (Mega Pixels) ค่ารูรับแสง (f-stop) ขนาด f/1.8 - f/2.4 ชุมออกแบบออปติคัล (Optical) 2 เท่า ชุมดิจิทัล (Digital) 5 เท่า

5.2 การจัดเตรียมชุดข้อมูลสำหรับพัฒนาแบบจำลองการเรียนรู้เชิงลึก

การเตรียมข้อมูลสำหรับงานวิจัยนี้ดำเนินการโดยแบ่งชุดภาพใบอ้อยออกเป็นชุดฝึกสอน (Training Data) และชุดทดสอบ (Test Data) ด้วยเทคนิคการสุ่มตัวอย่าง (Random Sampling) ในสามอัตราส่วน ได้แก่ 75:25, 80:20 และ 90:10 เพื่อวิเคราะห์ผลกระทบของขนาดข้อมูลฝึกสอนต่อประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก การแบ่งข้อมูลทุกอัตราส่วนคงความสมดุลของแต่ละคลาส (Class Balance) ทั้ง 4 ประเภท ได้แก่ RedRot, RingSpot, Rust และ Healthy พร้อมปรับขนาดภาพให้เท่ากันที่ 256x256 พิกเซล เพื่อให้เหมาะสมกับการประมวลผลของแบบจำลอง CNN

5.3 การพัฒนาแบบจำลองการเรียนรู้เชิงลึก

งานวิจัยนี้พัฒนาแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) สำหรับวิเคราะห์และตรวจสอบโรคใบอ้อยจากภาพถ่าย โดยดำเนินการบนแพลตฟอร์ม Google Colaboratory (Google Colab) ใช้ Python 3 และ Runtime ที่รองรับการประมวลผลแบบขนานด้วย GPU T4 พร้อมไลบรารี PyTorch สำหรับพัฒนาและฝึกสอนโมเดล โดยเฉพาะในบริบทของชุดข้อมูลขนาดเล็ก กระบวนการพัฒนาประกอบด้วย 4 ขั้นตอนหลัก ได้แก่ (1) การแบ่งชุดข้อมูลใบอ้อยในสัดส่วน 75:25, 80:20 และ 90:10 สำหรับชุดฝึกสอนและชุดทดสอบ ดังแสดงรายละเอียดใน Table 1. (2) การฝึกสอนและทดสอบแบบจำลองด้วยสถาปัตยกรรม CNN ทั้ง 5 สถาปัตยกรรม ได้แก่ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet (3) การประเมินประสิทธิภาพของแต่ละแบบจำลองด้วยตัวชี้วัดมาตรฐาน ได้แก่ ความแม่นยำ (Accuracy) ความเที่ยงตรง (Precision) และค่าการเรียกคืน (Recall) และ (4) การนำแบบจำลองที่มีประสิทธิภาพสูงสุดไปพัฒนาเป็นระบบแชตบอตอัตโนมัติบนแพลตฟอร์ม LINE เพื่อการวินิจฉัยโรคใบอ้อยจากภาพถ่ายแบบเรียลไทม์

Table 1. Partitioning the dataset into training and testing sets.

Class No.	Class Name	Number of images	Train/Test (75:25)	Train/Test (80:20)	Train/Test (90:10)
1	RedRot	1,000	750/250	800/200	900/100
2	RingSpot	1,000	750/250	800/200	900/100
3	Rust	1,000	750/250	800/200	900/100
4	Healthy	1,000	750/250	800/200	900/100
Total		4,000	3,000/1000	3,200/800	3,600/400

5.4 การทดสอบประสิทธิภาพ

การดำเนินการวิจัยในส่วนนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ในการวิเคราะห์และจำแนกภาพใบอ้อยที่แสดงอาการของโรคเส้นกลางใบแดง (RedRot), โรคใบจุดวงแหวน (RingSpot) และโรคราสนิม (Rust) การประเมินผลดำเนินการบนชุดข้อมูลทดสอบโดยใช้ตัวชี้วัดมาตรฐาน ได้แก่ Accuracy, Precision, Recall และ F1-Score ซึ่งคำนวณค่าเฉลี่ยแบบ Macro-average เพื่อสะท้อนประสิทธิภาพของแบบจำลองในกลุ่มข้อมูลที่มีจำนวนตัวอย่างเท่ากัน ผลลัพธ์จากการทดสอบถูกเปรียบเทียบตามอัตราส่วนการแบ่งข้อมูล

75:25, 80:20 และ 90:10 เพื่อระบุสถาปัตยกรรมที่เหมาะสมที่สุดสำหรับการจำแนกโรคใบอ้อยจากภาพถ่าย ในการทดลองนี้มีการตั้งค่าไฮเปอร์พารามิเตอร์ (Hyperparameters) โดยแสดงรายละเอียดดัง Table 2.

Table 2. Hyperparameter Settings

Parameter	Value
Image Type	Color (RGB)
Image size (Width x Height)	256x256
Percentage for Validation (%)	20
Image Encoding	jpg
Dataset	Healthy, RedRot, Rust and RingSpot
Training epochs	4, 10 and 20
Batch size	64

5.5 การออกแบบและพัฒนาระบบ LINE Chatbot

งานวิจัยนี้ได้ออกแบบและพัฒนาระบบ LINE Chatbot โดยใช้ LINE Messaging API เป็นตัวกลางระหว่างผู้ใช้งานกับแบบจำลองการเรียนรู้เชิงลึก (CNN) ที่มีประสิทธิภาพสูงสุดจากการทดลอง สำหรับวินิจฉัยโรคใบอ้อยจากภาพถ่าย ผู้ใช้สามารถส่งภาพผ่านบัญชี LINE Official ชื่อ “Sugarcane Disease” ซึ่งระบบจะประมวลผลและจำแนกโรค ได้แก่ โรคเส้นกลางใบแดง (RedRot), โรคใบจุดวงแหวน (RingSpot), โรคราสนิม (Rust) และใบอ้อยปกติ (Healthy) จากนั้นส่งผลลัพธ์พร้อมภาพต้นฉบับกลับไปยังผู้ใช้โดยอัตโนมัติ ช่วยอำนวยความสะดวกต่อการใช้งานจริงในภาคเกษตรกรรม สถาปัตยกรรมของระบบแสดงรายละเอียดใน Figure 3.




Figure 3. LINE Chatbot Architecture

6. ผลการวิจัย (Results)

งานวิจัยนี้ได้ประเมินประสิทธิภาพของแบบจำลอง CNN ที่เลือกสำหรับการวินิจฉัยโรคใบอ้อย โดยทำการทดลองกับการแบ่งชุดข้อมูลในสามอัตราส่วน ได้แก่ 75:25, 80:20 และ 90:10 เพื่อศึกษาผลของขนาดข้อมูลฝึกสอนต่อประสิทธิภาพของแบบจำลอง ผลการทดสอบและการเปรียบเทียบสามารถสรุปได้ดังนี้

6.1 ผลการทดสอบและเปรียบเทียบประสิทธิภาพของแบบจำลองในการจำแนกโรคใบอ้อย

การทดลองใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) สำหรับจำแนกโรคใบอ้อยบนชุดข้อมูลที่แบ่งเป็นอัตราส่วน 75:25, 80:20 และ 90:10 แสดงให้เห็นว่าระดับประสิทธิภาพของแต่ละโมเดลแตกต่างกัน โดยประเมินจากตัวชี้วัดสำคัญ ได้แก่ Accuracy, Recall, Precision และ F1-Score ผลการเปรียบเทียบสรุปไว้ใน Table 3., 4, และ 5 เพื่อวิเคราะห์ความเหมาะสมของแบบจำลองภายใต้เงื่อนไขของขนาดชุดข้อมูลฝึกสอนที่ต่างกัน ค่าที่ปรากฏในตารางเป็นผลการประเมินจากตัวชี้วัด Accuracy, Recall, Precision และ F1-Score โดยมีค่ากำหนดให้อยู่ในช่วง [0, 1] ซึ่งค่าที่มีค่าเท่ากับ 1 หมายถึงประสิทธิภาพสูงสุดหรือคิดเป็น 100% ตัวอย่างเช่น ค่า 0.9960 สอดคล้องกับประสิทธิภาพ 99.60%

Table 3. Evaluation of model performance based on prediction outcomes using a 75:25 training-to-testing data split.

Model	Class	Accuracy	Precision	Recall	F1-Score
VGG-16	Healthy	0.9980	0.9960	0.9960	0.9960
	RedRot	0.9870	0.9759	0.9720	0.9739
	RingSpot	0.9710	0.9299	0.9560	0.9428
	Rust	0.9700	0.9508	0.9280	0.9392
ResNet-50	Healthy	0.9960	0.9920	0.9920	0.9920
	RedRot	0.9870	0.9836	0.9640	0.9737
	RingSpot	0.9740	0.9274	0.9720	0.9492
	Rust	0.9730	0.9588	0.9320	0.9452
DenseNet-121	Healthy	0.9950	0.9880	0.9920	0.9900
	RedRot	0.9860	0.9796	0.9640	0.9717
	RingSpot	0.9770	0.9416	0.9680	0.9546
	Rust	0.9760	0.9593	0.9440	0.9516
AlexNet	Healthy	0.9930	0.9802	0.9920	0.9860
	RedRot	0.9840	0.9834	0.9520	0.9674
	RingSpot	0.9710	0.9266	0.9600	0.9430
	Rust	0.9660	0.9390	0.9240	0.9314
Table GoogLeNet	Healthy	0.9790	0.9598	0.9560	0.9579
	RedRot	0.9770	0.9595	0.9480	0.9537
	RingSpot	0.9740	0.9274	0.9720	0.9492
	Rust	0.9640	0.9421	0.9120	0.9268

จาก Table 3. พบว่า ผลการเปรียบเทียบประสิทธิภาพด้วยชุดข้อมูลแบบ 75:25 พบว่า DenseNet-121 มีประสิทธิภาพสูงสุดในการจำแนกโรคใบอ้อย เฉพาะโรคใบจุดวงแหวน (RingSpot) ให้ค่า F1-Score เฉลี่ยคิดเป็น 95.46% และโรคราสนิม (Rust) ให้ค่า F1-Score เฉลี่ยคิดเป็น 95.16% โดยภาพรวมให้ค่า F1-Score เฉลี่ยสูงกว่าทุกโมเดล และผลการเปรียบเทียบประสิทธิภาพด้วยชุดข้อมูลทดสอบ (Test Data) มีความแม่นยำในการจำแนกภาพใบอ้อยสูงสุด โดยรวมคิดเป็น 96.70% ดัง Figure 4. (a) ขณะที่ VGG-16 ให้ผลดีกว่าในกลุ่มโรคเส้นกลางใบแดง (RedRot) และใบอ้อยปกติ (Healthy) ส่วน AlexNet และ GoogLeNet มีประสิทธิภาพต่ำกว่าเล็กน้อยในทุกคลาส

Table 4. Evaluation of model performance based on prediction outcomes using a 80:20 training-to-testing data split.

Model	Class	Accuracy	Precision	Recall	F1-Score
VGG-16	Healthy	1.0	1.0	1.0	1.0
	RedRot	0.9825	0.9603	0.9700	0.9651
	RingSpot	0.9712	0.9402	0.9450	0.9426
	Rust	0.9787	0.9644	0.9500	0.9571
ResNet-50	Healthy	0.9962	0.9900	0.9950	0.9925
	RedRot	0.9800	0.9600	0.9600	0.9600
	RingSpot	0.9825	0.9603	0.9700	0.9651
	Rust	0.9812	0.9695	0.9550	0.9622

Table 4. Evaluation of model performance based on prediction outcomes using a 80:20 training-to-testing data split (Cont.)

Model	Class	Accuracy	Precision	Recall	F1-Score
DenseNet-121	Healthy	0.9962	0.9852	1.0	0.9925
	RedRot	0.9812	0.9556	0.9700	0.9627
	RingSpot	0.9787	0.9692	0.9450	0.9569
	Rust	0.9787	0.9597	0.9550	0.9573
AlexNet	Healthy	0.9937	0.9850	0.9900	0.9875
	RedRot	0.9775	0.9375	0.9750	0.9558
	RingSpot	0.9587	0.9371	0.8950	0.9156
	Rust	0.9625	0.9250	0.9250	0.9250
GoogLeNet	Healthy	0.9850	0.9653	0.9750	0.9701
	RedRot	0.9687	0.9268	0.9500	0.9382
	RingSpot	0.9662	0.9435	0.9200	0.9316
	Rust	0.9650	0.9343	0.9250	0.9296

จาก Table 4. ผลการทดสอบด้วยชุดข้อมูลแบบ 80:20 พบว่า VGG-16 ให้ค่า F1-Score สูงที่สุดในกลุ่มโรคเส้นกลางใบแดง (RedRot) และใบอ้อยปกติ (Healthy) และ ResNet-50 ให้ค่า F1-Score สูงที่สุดในกลุ่มโรคใบจุดวงแหวน (RingSpot) และโรคราสนิม (Rust) และผลการเปรียบเทียบประสิทธิภาพด้วยชุดข้อมูลทดสอบ (Test Data) มีความแม่นยำในการจำแนกภาพใบอ้อยสูงสุด โดยรวมคิดเป็น 97.00% ดัง Figure 4. (b) ขณะที่ AlexNet และ GoogLeNet มีประสิทธิภาพต่ำกว่าชัดเจน โดยเฉพาะในคลาส RingSpot และ Rust

Table 5. Evaluation of model performance based on prediction outcomes using a 90:10 training-to-testing data split.

Model	Class	Accuracy	Precision	Recall	F1-Score
VGG-16	Healthy	1.0	1.0	1.0	1.0
	RedRot	0.9800	0.9509	0.9700	0.9603
	RingSpot	0.9675	0.9677	0.9000	0.9326
	Rust	0.9725	0.9238	0.9700	0.9463
ResNet-50	Healthy	0.9975	1.0	0.9900	0.9949
	RedRot	0.9700	0.9489	0.9300	0.9393
	RingSpot	0.9675	0.9393	0.9300	0.9346
	Rust	0.9750	0.9326	0.9700	0.9509
DenseNet-121	Healthy	0.9925	0.9708	1.0	0.9852
	RedRot	0.9850	0.9700	0.9700	0.9700
	RingSpot	0.9900	1.0	0.9600	0.9795
	Rust	0.9775	0.9504	0.9600	0.9552
AlexNet	Healthy	0.9950	0.9900	0.9900	0.9900
	RedRot	0.9675	0.9142	0.9600	0.9365
	RingSpot	0.9725	0.9684	0.9200	0.9435
	Rust	0.9750	0.9500	0.9500	0.9500

Table 5. Evaluation of model performance based on prediction outcomes using a 90:10 training-to-testing data split (Cont.)

Model	Class	Accuracy	Precision	Recall	F1-Score
GoogLeNet	Healthy	0.9825	0.9514	0.9800	0.9655
	RedRot	0.9375	0.8640	0.8900	0.8768
	RingSpot	0.9500	0.9081	0.8900	0.8989
	Rust	0.9550	0.9270	0.8900	0.9081

จาก Table 5. ผลการทดสอบด้วยชุดข้อมูลแบบ 90:10 พบว่า DenseNet-121 ให้ค่า F1-Score สูงที่สุด ในกลุ่มโรคเส้นกลางใบแดง (RedRot) โรคใบจุดวงแหวน (RingSpot) และโรคราสนิม (Rust) ในขณะที่ VGG-16 ให้ค่า F1-Score สูงที่สุด ในกลุ่มใบอ้อยปกติ (Healthy) ขณะที่ AlexNet และ GoogLeNet แสดงผลลัพธ์ต่ำที่สุดในทุกคลาส โดยเฉพาะคลาส RedRot และ RingSpot และผลการเปรียบเทียบประสิทธิภาพด้วยชุดข้อมูลทดสอบ (Test Data) มีความแม่นยำในการจำแนกภาพใบอ้อยสูงสุด โดยรวมคิดเป็น 97.25% ดัง Figure 4. (c)




Figure 4. Confusion Matrix Model (a) DenseNet-121 Train Data 75:25 (b) ResNet-50 Train Data 80:20 (c) DenseNet-121 Train Data 90:10.

ในการประเมินประสิทธิภาพโดยรวมของแบบจำลอง ได้ดำเนินการคำนวณค่าเฉลี่ยของค่า F1-Score โดยใช้วิธี Macro-average Method เพื่อระบุแบบจำลองที่ให้ผลการจำแนกประเภทใบอ้อยที่มีประสิทธิภาพสูงสุดในแต่ละรูปแบบของชุดข้อมูลทั้งสามแบบ ผลการจำแนกโรคใบอ้อยด้วยเทคนิคการเรียนรู้เชิงลึกแสดงรายละเอียดดัง Table 6.

Table 6. Performance Comparison of Models Using Macro-average Method.

Model	Train data	Average Precision	Macro average
VGG-16	75%	0.9631	0.9630
	80%	0.9662	0.9662
	90%	0.9606	0.9598
ResNet-50	75%	0.9655	0.9650
	80%	0.9699	0.9699
	90%	0.9552	0.9550
DenseNet-121	75%	0.9671	0.9670
	80%	0.9674	0.9674
	90%	0.9728	0.9725

Table 6. Performance Comparison of Models Using Macro-average Method. (Cont.)

Model	Train data	Average Precision	Macro average
AlexNet	75%	0.9573	0.9570
	80%	0.9461	0.9460
	90%	0.9556	0.9550
GoogLeNet	75%	0.9472	0.9469
	80%	0.9425	0.9424
	90%	0.9126	0.9123

ผลการจำแนกโรคใบอ้อยด้วยเทคนิคการเรียนรู้เชิงลึกแสดงไว้ใน Table 6. ซึ่งพบว่าแบบจำลอง DenseNet-121 ที่ใช้ข้อมูลฝึกสอนร้อยละ 90:10 มีค่าความแม่นยำโดยรวม (Average Precision) สูงที่สุดที่ร้อยละ 97.28 และค่า Macro-average สูงที่สุดที่ร้อยละ 97.25 ดังนั้น งานวิจัยนี้จึงเลือกใช้แบบจำลองนี้ในการพัฒนาระบบวิเคราะห์และตรวจสอบโรคจากภาพใบอ้อยเพื่อรองรับการเกษตรอัจฉริยะในขั้นตอนต่อไป

6.2 ผลการพัฒนาระบบ LINE Chatbot

ผลการพัฒนาระบบ LINE Chatbot พบว่า สามารถวิเคราะห์และทำนายโรคอ้อยได้ 4 ประเภท ได้แก่ โรคเส้นกลางใบแดง (RedRot) โรคใบจุดวงแหวน (RingSpot) โรคราสนิม (Rust) และใบอ้อยปกติ (Healthy) ดัง Figure 5. (a) - (d)




Figure 5. Prediction Results: (a) Red Rot, (b) Ring Spot, (c) Rust, (d) Healthy.

7. สรุปผลการวิจัย (Conclusion)

งานวิจัยนี้ได้ประยุกต์ใช้แบบจำลอง Convolutional Neural Networks (CNN) จำนวน 5 สถาปัตยกรรม ได้แก่ VGGNet-16, ResNet-50, DenseNet-121, AlexNet และ GoogLeNet สำหรับการจำแนกและตรวจสอบโรคจากภาพใบอ้อย โดยดำเนินการบนแพลตฟอร์ม Google Colab ด้วย Python 3 Runtime และใช้ T4 GPU เป็นเครื่องมือเร่งการประมวลผล ชุดข้อมูลที่ใช้ในการทดลองคือ Sugarcane Leaf Disease Dataset จำนวน 4,000 ภาพ แบ่งเป็น 4 ประเภท ได้แก่ โรคเส้นกลางใบแดง โรคใบจุดวงแหวน โรคราสนิม และใบอ้อยปกติ กลุ่มละ 1,000 ภาพ เก็บรวบรวมจากสภาพแวดล้อมจริงตามธรรมชาติ

ผลการทดลองพบว่า การแบ่งชุดข้อมูลฝึกสอนและทดสอบในอัตราส่วน 75:25, 80:20 และ 90:10 ส่งผลต่อประสิทธิภาพของแบบจำลอง โดย DenseNet-121 ให้ค่าความแม่นยำสูงสุดเมื่อใช้สัดส่วนฝึกสอน 90% โดยมี ค่า Macro-average สูงถึง 97.25% ซึ่งเหนือกว่าโมเดลอื่น ๆ ทั้งนี้ สาเหตุสำคัญมาจากการเชื่อมโยงแบบหนาแน่น (Dense Connections) ของ

DenseNet-121 ทำให้สามารถรักษาคุณลักษณะเชิงลึกของภาพใบอ้อยที่ซับซ้อน เช่น จุดวงแหวนและความผิดปกติของเนื้อเยื่อใบ ได้ดีกว่าโมเดลสถาปัตยกรรมอื่น

สรุปได้ว่า การประยุกต์ใช้เทคนิค Deep Learning ด้วย CNN โดยเฉพาะ DenseNet-121 เหมาะสมสำหรับการวิเคราะห์และตรวจสอบโรคใบอ้อยในสภาพแวดล้อมธรรมชาติ ผลลัพธ์นี้ชี้ให้เห็นถึงความเป็นไปได้ในการพัฒนา ระบบวินิจฉัยโรคอ้อยอัตโนมัติ ที่สามารถบูรณาการเข้ากับแพลตฟอร์ม LINE Chatbot เพื่อสนับสนุนเกษตรกรอัจฉริยะ และยังสามารถต่อยอดสู่การศึกษาและประยุกต์ใช้กับพืชชนิดอื่น ๆ ในอนาคต

8. อภิปรายผลการวิจัย (Discussion)

เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) โดยเฉพาะ โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ได้รับความสนใจอย่างกว้างขวางในการประยุกต์ใช้กับการวิเคราะห์ภาพถ่ายทางการแพทย์ เนื่องจากมีความสามารถในการจำแนกภาพที่ซับซ้อนและประมวลผลได้อย่างรวดเร็วและแม่นยำสูง (Ditcharoen et al., 2023) การประยุกต์ใช้เทคโนโลยีการประมวลผลภาพในการวินิจฉัยโรคพืชมีประโยชน์หลายประการ ได้แก่ การตรวจพบโรคในระยะเริ่มต้น การลดการสูญเสียผลผลิต และการสนับสนุนการเกษตรยั่งยืน (Ganesh et al., 2025; Harshitha et al., 2024) นอกจากนี้ CNN ยังได้รับความนิยมเพิ่มขึ้นเนื่องจากสามารถปรับใช้ได้แม้มีข้อมูลจำนวนน้อย (Saisangchan et al., 2022)

ผลการวิจัยของงานนี้ชี้ให้เห็นว่า DenseNet-121 ให้ค่าความแม่นยำสูงสุด 97.28% ในการจำแนกโรคใบอ้อย โดยเฉพาะเมื่อใช้สัดส่วนการแบ่งข้อมูลฝึกสอน 90:10 ผลลัพธ์นี้สอดคล้องกับแนวโน้มของงานวิจัยที่เกี่ยวข้องซึ่งยืนยันว่า โมเดลที่มีการเชื่อมต่อแบบหนาแน่น (Dense Connections) สามารถลดการสูญเสียข้อมูลระหว่างชั้นและช่วยปรับปรุงประสิทธิภาพการเรียนรู้ (Amin et al., 2022) สาเหตุสำคัญที่ DenseNet-121 มีประสิทธิภาพสูงกว่าโมเดลอื่น ๆ มาจากการส่งต่อคุณลักษณะ (Feature Maps) จากทุกเลเยอร์ไปยังเลเยอร์ถัดไปอย่างครบถ้วน ซึ่งช่วยรักษาคุณลักษณะเชิงลึกของภาพใบอ้อยที่ซับซ้อน เช่น โรคใบจุดวงแหวน ทำให้โมเดลสามารถจำแนกโรคได้แม่นยำกว่า ResNet-50 และ VGG16 ซึ่งมีลักษณะการเชื่อมโยงภายในและความซับซ้อนของชั้นแตกต่างกัน

เมื่อเปรียบเทียบกับงานวิจัยที่ศึกษาในลักษณะใกล้เคียงกัน เช่น Daphal & Koli (2024) ที่ใช้สถาปัตยกรรมการเรียนรู้เชิงลึกแบบหลายระดับร่วมกับกลไกความสนใจ สำหรับการจำแนกโรคใบอ้อย โดยใช้ทั้ง Spatial Attention และ Channel Attention ในการสกัดข้อมูลสำคัญ ผลการทดลองพบว่า โมเดลสามารถจำแนกโรคได้ด้วยค่าความแม่นยำสูงถึง 86.53% ต่ำกว่าผลลัพธ์ของงานวิจัยนี้ นอกจากนี้ Saisangchan et al. (2022) ใช้ ResNet50 สำหรับจำแนกโรคใบมะนาว รายงานความแม่นยำสูงสุด 89.06% แม้ใกล้เคียงแต่ยังต่ำกว่า DenseNet-121 แสดงให้เห็นว่าการเลือกสถาปัตยกรรมและลักษณะการเชื่อมโยงภายในมีผลต่อประสิทธิภาพอย่างมีนัยสำคัญ อย่างไรก็ตาม งานวิจัยนี้มีข้อจำกัดบางประการ ได้แก่ ชุดข้อมูลถูกเก็บจาก 4 จังหวัดภาคตะวันออกเฉียงเหนือตอนกลาง เพียงอย่างเดียว ทำให้ความหลากหลายของสภาพดินฟ้าอากาศและพันธุ์อ้อยมีจำกัด ซึ่งอาจส่งผลต่อความสามารถในการประยุกต์ใช้ในพื้นที่อื่น ๆ ที่มีสภาพแวดล้อมแตกต่างกัน นอกจากนี้ แม้ว่าจะระบบสามารถบูรณาการกับ LINE Chatbot เพื่อสนับสนุนเกษตรกรได้ แต่ยังคงต้องพิจารณาปัจจัยด้านความเร็วอินเทอร์เน็ต ความรู้พื้นฐานด้านเทคโนโลยี และการรองรับภาษา เพื่อให้ใช้งานได้จริงในบริบทเกษตรกรอัจฉริยะ

จากการเปรียบเทียบเชิงวิพากษ์กับงานวิจัยก่อนหน้า งานวิจัยนี้มีความโดดเด่นทั้งในด้าน ความแม่นยำของแบบจำลอง และ การบูรณาการระบบสนับสนุนผู้ใช้จริงผ่านแชตบอต ซึ่งยังพบได้น้อยในงานวิจัยที่เกี่ยวข้อง อย่างไรก็ตาม ยังมีความท้าทายที่ต้องพัฒนาเพิ่มเติมในอนาคต เช่น การเพิ่มความหลากหลายของชุดข้อมูล การทดสอบประสิทธิภาพภายใต้สภาพแวดล้อมจริง และการปรับปรุงประสบการณ์ผู้ใช้แชตบอตให้เหมาะสมกับกลุ่มเกษตรกรไทย

9. ข้อเสนอแนะงานวิจัย (Recommendation)

9.1 ข้อเสนอแนะในการวิจัยต่อยอด

ควรขยายขนาดและความหลากหลายของชุดข้อมูลจากหลายพื้นที่และช่วงเวลา เพื่อให้โมเดลสามารถปรับตัวต่อความแตกต่างของสภาพแวดล้อมและพันธุ์อ้อยได้ดีขึ้น, ประยุกต์ใช้เทคนิคการเพิ่มปริมาณข้อมูล (Data Augmentation) และการถ่ายทอดการเรียนรู้ (Transfer Learning) เพื่อลดเวลาในการฝึกสอนและเพิ่มประสิทธิภาพในการจำแนกโรค, ขยายการศึกษารอบคลุม โรคใบอ้อยชนิดอื่น ๆ และระยะโรคที่แตกต่างกัน รวมถึงการทดสอบโมเดลกับ พืชเศรษฐกิจอื่น ๆ เพื่อ

ตรวจสอบความสามารถในการปรับใช้โมเดล CNN ในบริบทหลากหลาย, และพัฒนาโมเดลและระบบให้สามารถบันทึกข้อมูลเชิงลึก เช่น ประวัติการเกิดโรค การวิเคราะห์ความรุนแรง และแนวโน้มการแพร่ระบาดเพื่อสนับสนุนงานวิจัยต่อยอด

9.1 ข้อเสนอแนะเชิงการประยุกต์ใช้

ควรพัฒนาระบบให้สมบูรณ์ยิ่งขึ้นด้วยฟังก์ชันการให้คำแนะนำการป้องกันและรักษาโรค พร้อมเชื่อมต่อกับฐานข้อมูลพยากรณ์อากาศ เพื่อให้เกษตรกรสามารถจัดการโรคพืชได้อย่างมีประสิทธิภาพ, ปรับปรุงการบูรณาการกับ LINE Chatbot ให้รองรับผู้ใช้งานหลากหลายกลุ่มเกษตรกร ทั้งในด้านภาษาและอินเทอร์เน็ต เพื่อให้อัปโหลดรูปภาพแนบได้จริงได้ดี และขยายการประยุกต์ใช้โมเดลไปยังพืชชนิดอื่น ๆ เพื่อสร้างแพลตฟอร์มสนับสนุนการวินิจฉัยโรคพืชแบบหลายชนิด ซึ่งสามารถช่วยเกษตรกรในหลายสาขาอาชีพ และสนับสนุนเกษตรอัจฉริยะอย่างยั่งยืน

10. กิตติกรรมประกาศ

ขอขอบคุณนักวิชาการเกษตร สำนักงานเกษตรจังหวัดมหาสารคาม และเกษตรกรไร่อ้อยทุกท่านที่ให้ความอนุเคราะห์และช่วยเหลือด้านข้อมูล บทความวิจัยนี้ใช้ Generative AI เพื่อปรับปรุงความชัดเจนและภาษาเท่านั้น

11. เอกสารอ้างอิง (References)

- Adulyasas, A., Baka, A., & Muninnoppamas, J. (2023). The Halal Qualified Product Searching System Using Image Processing. *Maejo Information Technology and Innovation Journal*, 9(2), 34-46. (In Thai)
- Alyas, R. M., & Mohammed, A. S. (2022, July 15-16). Detection of Plant Diseases Using Image Processing with Machine Learning. *2022 2nd International Conference on Computing and Machine Intelligence*, 1-6. Institute of Electrical and Electronics Engineers.
<https://doi.org/10.1109/ICMI55296.2022.9873793>.
- Amin, H., Darwish, A., Hassanien, A. E., & Soliman, M. (2022). End-to-End Deep Learning Model for Corn Leaf Disease Classification. *IEEE Access*, 10, 31103-31115. <https://doi.org/10.1109/access.2022.3159678>.
- Archana, R., & Jeevaraj, P. S. E. (2024). Deep Learning Models for Digital Image Processing: A Review. *Artificial Intelligence Review*, 57(1), 11. <https://doi.org/10.1007/s10462-023-10631-z>.
- 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>.
- Ditcharoen, S., Sirisomboon, P., Saengprachatanarug, K., Phuphaphud, A., Rittiron, R., Terdwongworakul, A., Malai, C., Saenphon, C., Panduangnate, L., & Posom, J. (2023). Improving the Non-destructive Maturity Classification Model for Durian Fruit Using Near-infrared Spectroscopy. *Artificial Intelligence in Agriculture*, 7, 35-43. <https://doi.org/10.1016/j.aiia.2023.02.002>.
- Enkvetchakul, P., & Surinta, O. (2022). Effective Data Augmentation and Training Techniques for Improving Deep Learning in Plant Leaf Disease Recognition. *Applied Science and Engineering Progress*, 15(3), 3810. <https://doi.org/10.14416/j.asep.2021.01.003>.
- Farooq, M. S., Riaz, S., Abid, A., Umer, T., & Zikria, Y. B. (2020). Role of IoT Technology in Agriculture: A Systematic Literature Review. *Electronics*, 9(2), 319. <https://doi.org/10.3390/electronics9020319>.
- Ganesh, N. B., Ayyappa, M., & Deepthi, K. (2025). Plant Disease Detection by Image Processing. *International Journal of Scientific Research in Engineering and Management*, 9(1), 1-4.
<https://doi.org/10.55041/ijsem40956>.
- Hamaan, T. (2016). *Sugarcane Disease Diagnosis Guide*. Office of The Cane and Sugar Board. (In Thai)
- Harshitha, H. S., Nagaraja, J., & Pruthiraja, D. (2024, July 24-27). Plant Disease Detection Using Image Processing. *2024 Second International Conference on Advances in Information Technology*, 1-6. Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICAIT61638.2024.10690485>.



- Hongboonmee, N., & Kanyaprasit, J. (2021). Health Problem Analysis from Nail Image using Deep Learning Technique. *Journal of Information Science and Technology*, 11(2), 10-20. <https://doi.org/10.14456/jist.2021.12>. (In Thai)
- Hongboonmee, N., & Sitthichokchaisiri, T. (2021). The Development of Application for Analysis of Eye Health with Image Recognition Using Deep Learning Technique. *Sripatum Review of Science and Technology*, 13(1), 7-21. (In Thai)
- Jomsri, P., Prangchumpol, D., & Eaimtanakul, B. (2021). Development of Automatic Marigold Leaf Disease Diagnosis System Using IoT Technology for Support Smart Farmer. *Journal of Academic Information and Technology*, 2(2), 15-24. (In Thai)
- Kasikorn Research Center. (2023). *Trends in Thai Agricultural Export in 2023*. Kasikorn Bank. (In Thai)
- Koedsri, A. (2021). Analysis of Learning Behavior in Massive Open Online Courses (MOOCs): An Application of Machine Learning and Deep Learning. *Journal of Social Sciences in Measurement Evaluation Statistics and Research*, 2(2), 14-28. (In Thai)
- Makkawal, T., Duangsupa, S., & Panthong, R. (2022). Development of Web Application for Classification of Variegated Banana with Machine Learning. *Journal of Applied Information Technology*, 8(2), 56-66. (In Thai)
- Mekha, P., Musikong, P., Palakong, N., Pramokchon, P., & Kasemsumran, P. (2023). Performance Comparison of Image Classification Models for Corn Leaf Disease. *Maejo Information Technology and Innovation Journal*, 9(2), 1-16. (In Thai)
- Office of Agricultural Economics. (2023). *Statistics on Major Economic Crop Cultivation Areas and Yields of Thailand in 2023*. Ministry of Agriculture and Cooperatives. (In Thai)
- Office of The Cane and Sugar Board. (2023). *Report on Sugarcane and Sugar Industry Situation, Crop Year 2022/2023*. Information and Communication Technology Division. (In Thai)
- Petrellis, N. (2018). A Review of Image Processing Techniques Common in Human and Plant Disease Diagnosis. *Symmetry*, 10(7), 270. <https://doi.org/10.3390/sym10070270>.
- Pujari, J. D., Yakkundimath, R., & Byadgi, A. S. (2015). Image Processing Based Detection of Fungal Diseases in Plants. *Procedia Computer Science*, 46, 1802-1808. <https://doi.org/10.1016/j.procs.2015.02.137>.
- Saisangchan, U., Chamchong, R., & Suwannasa, A. (2022). Analysis of Lime Leaf Disease using Deep Learning. *Journal of Applied Informatics and Technology*, 4(1), 71-86. <https://doi.org/10.14456/jait.2022.6>. (In Thai)
- Shrestha, A., & Mahmood, A. (2019). Review of Deep Learning Algorithms and Architectures. *IEEE Access*, 7, 53040-53065. <https://doi.org/10.1109/access.2019.2912200>.
- Vento, D. D., & Fanfarillo, A. (2019, July 28 - August 1). Traps, Pitfalls and Misconceptions of Machine Learning Applied to Scientific Disciplines. *PEARC '19: Practice and Experience in Advanced Research Computing 2019: Rise of the Machines (Learning)*, 75. <https://doi.org/10.1145/3332186.3332209>.
- Wongsarapee, S., & Puangmanee, W. (2025). Image Enhancement Using Haar Wavelet for Image Classification of Diseases on Strawberry Leaves with Convolutional Neural Networks. *Maejo Information Technology and Innovation Journal*, 11(1), 174-192. (In Thai)
- Yap, M. H., Cassidy, B., Pappachan, J. M., O'Shea, C., Gillespie, D., & Reeves, N. (2021). *Analysis Towards Classification of Infection and Ischaemia of Diabetic Foot Ulcers*. arXiv. <https://doi.org/10.48550/arXiv.2104.03068>.