

Received: Nov 6, 2025

Revised: Jan 21, 2026

Accepted: Apr 22, 2026

การประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกเพื่อสร้างเว็บแอปพลิเคชันสำหรับวิเคราะห์โรคในใบข้าวโพด

APPLICATION OF DEEP LEARNING TECHNOLOGY TO CREATE A WEB APPLICATION FOR CORN LEAF DISEASE ANALYSIS

อัศมเดช อินทชัย¹, ธนिरัตน์ ยอดดำเนิน², อนัน หยวักว³, ปรีชาภรณ์ ขันบุรี^{4*}

^{1,2}สาขาวิชาเทคโนโลยีคอมพิวเตอร์ คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏกำแพงเพชร

³สาขาวิชาวิศวกรรมวัสดุและอุตสาหกรรม คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏกำแพงเพชร

⁴สาขาวิชาวิศวกรรมสารทกริดและยานยนต์ไฟฟ้า คณะเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยราชภัฏกำแพงเพชร

Autsadech Intachai¹, Thanirat Yoddamnern², Anan Yuakwat³, Preechabhorn Kunburi^{4*}

^{1,2}Computer Technology Program, Faculty of Industrial Technology, Kamphaeng Phet Rajabhat University

³Materials and Industrial Engineering Program, Faculty of Industrial Technology,

Kamphaeng Phet Rajabhat University

^{4*}Smart Grid and Electric Vehicle Engineering Program, Faculty of Industrial Technology,

Kamphaeng Phet Rajabhat University

*Corresponding author, e-mail : prechaporn23pp@gmail.com

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาเว็บแอปพลิเคชันสำหรับการวิเคราะห์โรคในใบข้าวโพด โดยประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกในลักษณะของ การตรวจจับวัตถุ (Object Detection) เพื่อระบุชนิดของโรคจากภาพถ่ายใบข้าวโพด ระบบที่พัฒนาขึ้นใช้สถาปัตยกรรม YOLOv11 สำหรับตรวจจับและจำแนกโรคในใบข้าวโพด 3 ชนิด ได้แก่ โรคราสนิมข้าวโพด โรคราน้ำค้าง และโรคใบไหม้ข้าวโพด ชุดข้อมูลที่ใช้ในการทดลองประกอบด้วยภาพใบข้าวโพดจำนวน 450 ภาพ โดยแบ่งข้อมูลสำหรับฝึกสอนและทดสอบโมเดลในอัตราส่วน 50:50 จาก Dataset มีขนาดจำกัดเน้นการนำไปใช้งานจริงมากกว่าต้องการความแม่นยำ เพื่อลดปัญหาการเกิด Overfitting ในส่วนการประเมินประสิทธิภาพของระบบใช้ตัวชี้วัด ได้แก่ Accuracy, Precision, Recall และ F1-Score

ผลการทดลองพบว่าโมเดลสามารถตรวจจับและจำแนกโรคในใบข้าวโพดได้อย่างมีประสิทธิภาพ โดยมีค่าความแม่นยำเฉลี่ยอยู่ในระดับที่น่าพอใจ และสามารถนำไปประยุกต์ใช้งานจริงผ่านเว็บแอปพลิเคชันได้แบบ Real-time งานวิจัยนี้แสดงให้เห็นถึงศักยภาพของการประยุกต์ใช้เทคโนโลยีการเรียนรู้เชิงลึกด้านการตรวจจับวัตถุในการสนับสนุนการวิเคราะห์โรคพืช และสามารถต่อยอดสู่การพัฒนาเกษตรแม่นยำในอนาคตได้

คำสำคัญ : โรคข้าวโพด, การประมวลผลภาพ, โมเดล YOLO, การเรียนรู้เชิงลึก, เว็บแอปพลิเคชัน

Abstract

This research aims to develop a web application for analyzing corn leaf diseases by applying deep learning techniques based on object detection to identify disease types from corn leaf images. The proposed system employs the YOLOv11 architecture to detect and classify three types of corn leaf diseases: corn common rust, downy mildew, and corn leaf blight. The dataset used in this study consists of 450 corn leaf images, which were divided into training and testing sets at a ratio of 50:50. Due to the limited size of the dataset, the focus is on practical application rather than competing on accuracy, in order to reduce the problem of overfitting. The system performance was evaluated using standard metrics, including accuracy, precision, recall, and F1-score.

Experimental results demonstrate that the proposed model can effectively detect and classify corn leaf diseases with satisfactory accuracy and can be deployed in real-time through a web application. The findings indicate the potential of deep learning-based object detection techniques to support plant disease analysis and contribute to the advancement of precision agriculture in the future.

Keywords : Corn Diseases, Image Processing, YOLO, Deep Learning, Web Application

บทนำ

ประเทศไทยเป็นผู้ผลิตข้าวโพดสำคัญ โดยการวางแผนพัฒนาการผลิตและงานวิจัยระดับประเทศชี้ให้เห็นถึงความสำคัญของข้าวโพดต่อภาคเกษตรและอุตสาหกรรมอาหาร (กรมวิชาการเกษตร, 2566) การระบาดของโรคใบข้าวโพด เช่น โรคราสนิมข้าวโพด (Corn Common Rust) โรคราน้ำค้าง (Downy Mildew) โรคใบไหม้ข้าวโพด (Corn Blight) อีกหนึ่งปัจจัยที่ทำให้ผลผลิตข้าวโพดที่ผลิตได้ไม่เพียงพอต่อความต้องการใช้ ทำให้ต้องมีการนำเข้าทั้งจากประเทศเพื่อนบ้านและนอกอาเซียน ดังนั้นการตรวจพบและจำแนกโรคในระยะต้นเป็นหัวใจของการจัดการโรคพืชที่มีประสิทธิภาพ (Waheed et al., 2020; Fraiwan et al., 2022) ซึ่งสามารถสร้างความเสียหายต่อผลผลิตได้สูงถึง 20-60% หากไม่ได้รับการตรวจจับและจัดการอย่างทันท่วงที (Janruang and Unartngam, 2018) ความสูญเสียดังกล่าวไม่เพียงแต่กระทบต่อรายได้ของเกษตรกรรายย่อย แต่ยังส่งผลต่อเสถียรภาพด้านวัตถุดิบอาหารสัตว์และความมั่นคงทางอาหารโดยรวม วิธีการตรวจจับโรคแบบดั้งเดิมในประเทศไทยยังอาศัยการสังเกตโดยผู้เชี่ยวชาญเกษตร ซึ่งใช้เวลานาน มีข้อจำกัดด้านจำนวนบุคลากร และไม่สามารถรองรับพื้นที่เพาะปลูกที่กว้างขวางได้ทันต่อการระบาด

งานวิจัยของ (Fraiwan et al., 2022) พัฒนาโมเดล Deep Learning บนชุดข้อมูลภาพใบพืชและยืนยันว่าเป็นแนวทางที่มีศักยภาพสูงสำหรับการตรวจจับโรคในระดับไร่นา ในช่วงไม่กี่ปีที่ผ่านมา เทคนิค Deep Learning โดยเฉพาะสถาปัตยกรรม Convolutional Neural Networks และโมเดลตระกูล YOLO ถูกนำมาใช้เพื่อการตรวจจับและจำแนกโรคใบพืชด้วยความแม่นยำสูง (Aldakheel et al., 2024; Alhwaiti et al., 2025) และงานวิจัยด้านการประยุกต์ใช้งานจริงมักรวมทั้งการพัฒนาโมเดลที่มีประสิทธิภาพและการวางระบบเชื่อมต่อ เช่น ระบบเว็บ และ IoT เพื่อให้เกษตรกรสามารถอัปโหลดภาพและรับการวินิจฉัยแบบเรียลไทม์ ซึ่งสอดคล้องกับ (Parez et al., 2023) แนวทางเกษตรแม่นยำ (Precision Agriculture) ที่นำสู่การลดการสูญเสียและการตัดสินใจจัดการเชิงปฏิบัติ

งานวิจัยของ (Zhou, Z., et al., 2021) ได้รื้อฟื้นที่ครอบคลุมแนวทางต่าง ๆ ของการตรวจจับโรคและแมลงบนพืชโดยใช้ deep learning แบ่งตามแนวทาง (classification, detection, segmentation) พร้อมวิจารณ์จุดแข็ง จุดอ่อน และทำ

หายของแต่ละแนวทาง เช่น การหาชุดข้อมูลที่หลากหลาย, การทำงานภาคสนาม, ปัญหาแสงและพื้นหลัง เป็นต้น ในส่วนของ (Li et al., 2022) เสนอสถาปัตยกรรม FL-EfficientNet (Focal loss + EfficientNet) สำหรับจำแนกโรคพืชหลายประเภท พร้อมเทคนิค attention และ loss function แบบ focal เพื่อรับมือกับตัวอย่างที่ยากต่อการจำแนก ผลการทดลองแสดงว่า accuracy สูงถึง 99.72% งานวิจัย (Zhang et al., 2024) นี้รวมโมเดลหลายรุ่น (DenseNet201, EfficientNetB0, InceptionResNetV2 ฯลฯ) เป็น ensemble เพื่อเพิ่มความแม่นยำในการจำแนกโรคพืช ผลงานรายงานว่า ensemble สามารถให้ความแม่นยำอยู่ที่ 99.89% บนชุดข้อมูล PlantVillage งานของ (Kaur & Singh, 2022) ใช้โมเดล CNN ที่ pre-trained (DenseNet-121, ResNet-50, VGG-16, Inception V4) แล้ว fine-tune กับข้อมูลโรคพืช เพื่อให้สามารถจำแนกโรคได้อย่างมีประสิทธิภาพ งานวิจัยนี้พัฒนาโมเดล deep learning เพื่อวินิจฉัยโรคพืชในหลายพืช (multi-crop disease detection) งานของ (Li et al., 2023) ใช้ขั้นตอน preprocessing, augmentation และเลือกโครงสร้างเครือข่ายให้เหมาะสม ผลทดสอบในหลายพืชแสดงผลดี งานวิจัยของ (Wang et al., 2024) ออกแบบ CNN ที่เบา (lightweight) สำหรับจำแนกโรคใบพริก เพื่อให้สามารถประมวลผลบนอุปกรณ์ edge ได้ พบว่าโมเดลยังคงให้ความแม่นยำสูงแม้มีข้อจำกัดทรัพยากร งานวิจัยของ (Hossain et al., 2025) พัฒนาแอปบนมือถือที่ฝังโมเดล CNN (VGG16, AlexNet, ResNet50) สำหรับตรวจจับโรคในใบข้าวโพดแบบเรียลไทม์ พบว่า VGG16 ให้ความแม่นยำ ~95% บนชุดทดสอบ งานวิจัยของ (Cap et al., 2020) เสนอวิธีสร้างภาพเพิ่ม (data augmentation) ด้วย GAN (LeafGAN) ที่เปลี่ยนภาพพืชปกติให้เป็นพืชที่มีอาการโรคเฉพาะเจาะจง โดยเพิ่มความหลากหลายของข้อมูล ทำให้ผลการจำแนกโรคบนชุดข้อมูลทดสอบเพิ่มขึ้น 7.4% งานของ (Thakur et al., 2022) รวมแนวคิด Vision Transformer กับ CNN เพื่อวินิจฉัยโรคพืช พร้อมใส่เทคนิค explainable AI (XAI) เพื่อให้โมเดลมีความอธิบายได้ (interpretability) โดยรายงานผลว่า PlantXViT ให้ความแม่นยำสูงในหลายชุดข้อมูล ชุดทำงานของ (Wang et al., 2022) งานวิจัยนี้สำรวจ 70 งานวิจัยที่ประยุกต์ deep learning กับการวินิจฉัยโรคพืชและแนวโน้มการใช้งาน พบว่าเทคนิคเช่น transfer learning, data augmentation, ensemble models เป็นที่นิยม และมีช่องว่างเรื่อง generalization ข้ามสายพันธุ์พืช จากการทบทวนวรรณกรรมที่เกี่ยวข้องสรุปได้ว่า การวินิจฉัยด้วยสายตายังมีความเสี่ยงต่อความคลาดเคลื่อน โดยเฉพาะในกรณีที่โรคอยู่ในระยะเริ่มต้นหรือมีอาการคล้ายคลึงกับโรคอื่นๆ การประยุกต์ใช้ปัญญาประดิษฐ์ (Artificial Intelligence: AI) และ Deep Learning จึงได้รับความสนใจอย่างกว้างขวางในการวิจัยระดับนานาชาติ

ในบริบทประเทศไทย การสร้างระบบที่สามารถจำแนกโรคข้าวโพดได้ ผ่านเว็บ (Website Platform) ถือเป็นนวัตกรรมที่ช่วยแก้ไขข้อจำกัดเชิงโครงสร้างพื้นฐานด้านเกษตรกร เนื่องจากเกษตรกรส่วนใหญ่สามารถเข้าถึงสมาร์ทโฟนและอินเทอร์เน็ตมากกว่าบุคลากรผู้เชี่ยวชาญ การพัฒนาระบบที่ใช้โมเดล YOLOv11 ซึ่งเป็นอัลกอริทึมการตรวจจับวัตถุที่มีความเร็วและความแม่นยำสูง จะช่วยให้ผู้ใช้สามารถอัปโหลดภาพใบข้าวโพดเข้าสู่ระบบเพื่อวิเคราะห์และรับผลการวินิจฉัยโรคได้ทันที พร้อมค่าความเชื่อมั่น (Confidence Score) ที่ช่วยเพิ่มความน่าเชื่อถือของผลลัพธ์ ดังนั้นงานวิจัยนี้มีความสำคัญในเชิงเศรษฐกิจ สังคม และวิชาการ โดยไม่เพียงแต่ช่วยเกษตรกรไทยลดความสูญเสียจากโรคพืช แต่ยังเป็นรากฐานสู่การพัฒนาแพลตฟอร์มเกษตรอัจฉริยะ (Smart Agriculture Platform) ที่สามารถขยายผลสู่การตรวจจับโรคพืชชนิดอื่นๆ การจำแนกแบบหลายโรคพร้อมกัน (Multi-disease Classification) เพื่อรองรับเกษตรกรแม่นยำในอนาคต

วัตถุประสงค์ของการวิจัย

1. เพื่อพัฒนาระบบจำแนกโรคในใบข้าวโพดด้วยเทคนิคการเรียนรู้เชิงลึก
2. เพื่อออกแบบและพัฒนาเว็บแอปพลิเคชันสำหรับการวิเคราะห์ผลการตรวจจับโรคข้าวโพด

ขอบเขตของการวิจัย

1. ขอบเขตของข้อมูล

ข้อมูลภาพของโรคในใบข้าวโพดที่ใช้ในการตรวจจำแนก จำนวน 3 ชนิด ได้แก่ โรคราสนิม ข้าวโพด (Corn Common Rust) โรคราน้ำค้าง (Downy mildew) โรคใบไหม้ข้าวโพด (corn blight) โดยข้อมูลภาพที่ใช้ทั้งหมด จำนวน 450 ภาพ ซึ่งแบ่งออกเป็นชุดฝึก (Training Set) จำนวน 225 ภาพ และชุดทดสอบ (Testing Set) จำนวน 225 ภาพ

2. ขอบเขตด้านเทคโนโลยีและเครื่องมือ

2.1 ใช้โมเดล YOLOv11 สำหรับจำแนกโรค

2.2 พัฒนาแอปพลิเคชันด้วยเทคโนโลยีเว็บ โดยสามารถอัปโหลดภาพและรับผลการวิเคราะห์ผ่านเว็บไซต์


วิธีดำเนินการวิจัย

1. ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับระบบตรวจจำแนกโรคพืช

โดยมุ่งเน้นไปที่การใช้เทคนิคการประมวลผลภาพและปัญญาประดิษฐ์ (AI) เพื่อวิเคราะห์ปัญหาที่เกิดขึ้นในกลุ่มชาวไร่ที่ปลูกข้าวโพด และกำหนดแนวทางการแก้ไข คือ การออกแบบระบบที่สามารถตรวจจำแนกและวิเคราะห์ได้โดยอัตโนมัติ

2. การเก็บรวบรวมข้อมูล


การเก็บรวบรวมข้อมูลสำหรับการฝึกสอนโมเดลดำเนินการโดยรวบรวม ภาพใบข้าวโพดที่มีอาการของโรคต่างๆ จากแหล่งข้อมูลต่างๆ ได้แก่ ศูนย์วิจัยพืชพรรณสวนหลวง ร.9 กรุงเทพมหานคร (ศูนย์วิจัยข้าวโพดนครสวรรค์, 2566) โดยเลือกภาพที่ขนาดภาพ 640x640 และระบุโรคได้ชัดเจน



ภาพที่ 1 แสดงข้อมูลภาพโรคในใบข้าวโพด

3. การจัดเตรียมข้อมูลภาพและการทำ Label


หลังจากได้ไฟล์ภาพภาพที่ผ่านการคัดเลือกแล้วดำเนินการทำ Label บนเว็บไซต์ Roboflow โดยกำหนดชื่อคลาสเป็น Common Rust, Downy Mildew และ Corn Blight



ภาพที่ 2 แสดงการทำ Label ภาพ

4. การสร้างโมเดลสำหรับการตรวจจับโรคใบข้าวโพดและการทดลอง

กระบวนการทดลองแบ่งออกเป็น 2 ขั้นตอนหลัก ได้แก่ การฝึกสอนโมเดล (Training Phase) ผู้วิจัยได้ใช้สถาปัตยกรรม YOLOV11 ในการสร้างโมเดลสำหรับตรวจจับโรคใบข้าวโพด โดยกำหนดคลาสทั้งหมด 3 ประเภท ได้แก่ Common Rust, Downy Mildew และ Corn Blight สำหรับชุดข้อมูลภาพที่ใช้ทั้งหมดจำนวนภาพรวม 450 ภาพ โดยแบ่งข้อมูลเป็น 50:50 โดยหลักวิชาการสัดส่วน 70:30 และ 80:20 เหมาะสมกับงานที่มีชุดข้อมูลขนาดกลางถึงขนาดใหญ่ และมุ่งเน้นการเพิ่มประสิทธิภาพของโมเดลเป็นหลัก ชุดข้อมูลมีขนาดจำกัดและมีความหลากหลายสูง การแบ่งข้อมูลในอัตราส่วน 50:50 สามารถเพิ่มความน่าเชื่อถือของผลการประเมินได้ดีกว่า เนื่องจากมีชุดทดสอบที่เพียงพอในการสะท้อนความสามารถของโมเดลต่อข้อมูล ซึ่งเป็นภาพสำหรับการฝึกสอน (Training Set) จำนวน 225 ภาพ เมื่อการฝึกสอนเสร็จสิ้น โมเดลที่ได้จะถูกนำไปทดสอบด้วยชุดข้อมูลทดสอบ (Testing Set) จำนวน 225 ภาพ ซึ่งมีการแบ่งภาพออกตามคลาสเช่นเดียวกับชุดฝึกสอน โดยผลการทดสอบถูกประเมินด้วยเกณฑ์ด้านความแม่นยำ (Accuracy) และประสิทธิภาพ (Performance) ในการตรวจจับโรคของแต่ละคลาส ดังภาพที่ 3



ภาพที่ 3 การจำลองโมเดล

5. การประเมินประสิทธิภาพของโมเดลและผลลัพธ์

การทำนายจะใช้ Confusion Matrix และหลักการในการประเมิน Machine Learning Model เพื่อทดสอบความแม่นยำและความถูกต้องของโมเดลตามข้อมูลที่ได้รับการประเมิน จากชุดทดสอบจำนวน 225 ภาพ แบ่งเป็น 3 คลาสๆ ละ 75 ภาพ โดยมีรายละเอียดดังนี้

ตารางที่ 1 ค่า Confusion Matrix ของโมเดล

ผล	Predicted			
	Corn Common Rust	Downy mildew	Corn blight	
จากตารางที่ 1 แสดงโรคราสนิม (Corn Common Rust) จำนวนถูกต้องทั้งหมด 75 ครั้ง ไม่สับสนกับโรคอื่นเลย โรคราน้ำค้าง (Downy Mildew) จำนวนถูกต้องทั้งหมด 73 ครั้ง ไม่สับสนกับโรคอื่นเลย โรคไหม้ (Corn Blight) จำนวนถูกต้องทั้งหมด 73 ครั้ง ไม่สับสนกับโรคอื่นเลย	75	0	0	
ขั้นตอนประเมินประสิทธิภาพของโมเดล				
ขั้นตอนที่ 1 หาจำนวนทั้งหมด N โดยใช้สัญลักษณ์: A = Corn Common Rust, B = Corn Downy Mildew, C = Corn Blight	75	73	73	
N = จำนวน A + จำนวน B + จำนวน C = 75 + 75 + 75 = 225	0	2	73	
ขั้นตอนที่ 2 หา TP ต่อคลาส				

$$TP_A = 75, TP_B = 73, TP_C = 73$$

ขั้นตอนที่ 3 คำนวณ Precision / Recall / F1 ต่อคลาส

สูตรพื้นฐาน

$$Precision_i = \frac{TP_i}{TP_i + FP_i}$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i}$$

$$F1_i = 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i}$$

ขั้นตอนที่ 4 หาค่า Accuracy และค่าเฉลี่ย Precision / Recall / F1 ของโมเดล

$$Accuracy = \frac{TP_A + TP_B + TP_C}{N} = \frac{75 + 73 + 73}{225} = \frac{221}{225} = 0.9822$$

$$Precision = \frac{TP_i}{TP_i + FP_i} = 221/225 = 0.9822$$

$$Recall = \frac{TP_i}{TP_i + FN_i} = 221/225 = 0.9822$$

$$F1\text{-score} = 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} = 2 \times \frac{0.9822 \times 0.9822}{0.9822 + 0.9822} = 0.9822$$

ตารางที่ 2 ค่าประสิทธิภาพ Precision, Recall และ F1-Score ของโมเดลจำแนกโรคข้าวโพด


คลาส	Precision	Recall	F1 Score
Corn Common Rust	1.00	1.00	1.00
Downy mildew	0.973	0.973	0.973
corn blight	0.973	0.973	0.973
ค่าเฉลี่ยทุกคลาส	Accuracy = 98.22%		

จากตารางที่ 2 ผลของโมเดลตรวจจับโรคในใบข้าวโพดทั้ง 3 ชนิดได้อย่างมีประสิทธิภาพ โดยเมื่อพิจารณาทีละคลาส พบว่า โรคราสนิมข้าวโพด (Corn Common Rust) โมเดลตรวจจับได้ถูกต้องทั้งหมด ไม่มีข้อผิดพลาดเลย ค่า Precision, Recall และ F1 Score = 1.00 (หรือ 100%) แสดงว่าโมเดลสามารถแยกโรคราสนิมได้อย่างแม่นยำที่สุด โรคราน้ำค้าง (Downy Mildew) มีค่า Precision = 0.973, Recall = 0.973, F1 Score = 0.973 โรคใบไหม้ข้าวโพด (Corn Blight) มีค่า Precision = 0.973, Recall = 0.973, F1 Score = 0.973 ค่าเฉลี่ยทุกคลาสความแม่นยำ เท่ากับ 98.22%



ภาพที่ 4 แสดงผลลัพธ์การใช้โมเดลการตรวจจับโรคในข้าวโพด

จากภาพที่ 4 ผลของโมเดลตรวจจับโรคในใบข้าวโพดที่ถูกฝึกด้วยสถาปัตยกรรม YOLOv11 โดยภาพเหล่านี้แสดงผลการจำแนกประเภทของโรคต่างๆ ที่พบในใบข้าวโพด ภาพแต่ละภาพมีกรอบบอกตำแหน่งของโรค พร้อมชื่อโรคและค่าความมั่นใจ (Confidence score) เช่น corn blight 0.9 ลักษณะใบไม้มีความหลากหลาย ทั้งแสงและมุมกล้อง แสดงให้เห็นว่าโมเดลสามารถรองรับความหลากหลายของข้อมูล (robustness) ได้



ภาพที่ 5 กราฟเปรียบเทียบค่า Precision กับ Recall ของโมเดล

จากภาพที่ 5 กราฟ Precision-Recall Curve แสดงให้เห็นว่าโมเดล YOLOv11 สามารถตรวจจับและจำแนกโรคในใบข้าวโพดทั้ง 3 ชนิดได้อย่างมีประสิทธิภาพสูง โดยมีความสมดุลระหว่าง Precision และ Recall ซึ่งสะท้อนถึงความสามารถในการตรวจพบโรคได้ครบถ้วนพร้อมกับการทำนายที่มีความถูกต้องสูง สนับสนุนความเหมาะสมของโมเดลสำหรับการประยุกต์ใช้งานจริงผ่านเว็บแอปพลิเคชันด้านการวิเคราะห์โรคพืช

ผลการวิจัย


1. ผลการประเมินโมเดลโรคข้าวโพดด้วย Confusion Matrix และค่าชี้วัดต่างๆ แสดงให้เห็นว่าโมเดล YOLOv11 มีประสิทธิภาพสูงในการจำแนกโรค โดยเฉพาะคลาส Corn Common Rust ทำนายได้ถูกต้อง 100% (Precision และ Recall เท่ากับ 1.00) สำหรับคลาส Downy mildew และ corn blight โมเดลก็มีประสิทธิภาพที่น่าพอใจ โดยมีค่า F1-Score อยู่ที่ 0.97 และ 0.97 ตามลำดับ โดยรวมแล้วผลลัพธ์ที่ได้ยืนยันว่าโมเดลนี้มีความแม่นยำและน่าเชื่อถือในการนำไปใช้งานเพื่อตรวจจับและจำแนกโรคข้าวโพด เมื่อเปรียบเทียบโมเดลต่าง ๆ สำหรับการคัดเลือกโมเดลให้มีประสิทธิภาพด้านความแม่นยำและความเร็วที่เหมาะสมกับงานได้ดังนี้

ตารางที่ 3 เปรียบเทียบสถาปัตยกรรมแต่ละโมเดลการจำแนกโรคข้าวโพด

Model	accuracy	Precision	Recall	F1-Score	Inference Time (ms/img)
YOLOv5n	94.8%	95.1%	94.5%	94.8%	8.3
YOLOv8n	96.3%	96.9%	95.6%	96.2%	7.5
YOLOv11n	98.2%	98.2%	98.2%	98.2%	6.9
ResNet-50	91.2%	92.0%	90.4%	91.2%	58.4
MobileNetV2	88.6%	89.1%	87.8%	88.4%	5.9

จากการเปรียบเทียบสถาปัตยกรรมแต่ละโมเดลผลปรากฏว่า ด้านความแม่นยำสูงที่สุดได้แก่ YOLOv11n ทางด้านความเร็วสูงที่สุดได้แก่ MobileNetV2 แต่เมื่อเปรียบเทียบทั้งสองโมเดลนี้ทั้งด้านความแม่นยำและความเร็วสรุปได้ว่า โมเดล YOLOv11n มีความเหมาะสมกับงานมากที่สุด คือ ความแม่นยำที่ 98.2% ความเร็วที่ 6.9 ms/img ในขณะที่ MobileNetV2 ความแม่นยำเพียง 88.6% ความเร็วที่ 5.9 ms/img ซึ่งความเร็วไม่ต่างกันมากนักแต่ความแม่นยำต่างกันเกือบ 10%

2. ผลลัพธ์จากการทดสอบโมเดลในการใช้งานจริงบนเว็บแอปพลิเคชัน โดยการอัปโหลดรูปภาพให้กับระบบได้วิเคราะห์ตรวจจับโรคข้าวโพดและวิธีการรักษา ทางแอดเดรส <https://dfbbdaf0f325.ngrok-free.app/> (ซึ่งการใช้งาน ngrok หากปิดเครื่องเว็บจะใช้ไม่ได้ โดยที่แอดเดรสเว็บจะเปลี่ยนไป เมื่อทำการเปิดระบบให้ใช้งาน)



ภาพที่ 6 แสดงผลการทดสอบโมเดลบนเว็บแอปพลิเคชัน

จากภาพที่ 6 เป็นการแสดงวิธีใช้งานจริงบนเว็บแอปพลิเคชัน ด้วยวิธีการอัปโหลดภาพไปยังเซิร์ฟเวอร์ โดยเรียกข้อมูลในเครื่องและส่งเพื่อวิเคราะห์ ในตัวอย่างรองรับไฟล์ภาพนามสกุล JPG, JPEG, PNG



ภาพที่ 7 ผลการทดสอบโมเดลในการใช้งานจริงบนเว็บแอปพลิเคชัน

จากภาพที่ 7 ผลของการทดสอบความถูกต้องและความแม่นยำของโมเดลในการตรวจจับโรคข้าวโพดและวิธีการรักษา ในตัวอย่างตรวจพบเป็น โรคใบไหม้ข้าวโพด (Corn blight) ผลการตรวจจับบนภาพ ที่ค่าความเชื่อมั่น (Confidence) 0.55 พร้อมแสดงสาเหตุ วิธีแก้ และป้องกัน



ภาพที่ 8 แสดงตัวอย่างผลการวิเคราะห์ไม่พบโรค

จากภาพที่ 8 ผลของการทดสอบเมื่อไม่มีโรคในข้าวโพดได้อย่างความถูกต้องและความแม่นยำอีกทั้งยังแสดงการให้คำแนะนำป้องกันการเกิดโรค

ตารางที่ 4 ผลการทดสอบโมเดลในการใช้งานจริง

การทดสอบโมเดลในการใช้งานจริง			
ชื่อโรค	จำนวนครั้งทั้งหมด	จำนวนครั้งที่ถูกต้อง	ความถูกต้องร้อยละ
โรคราสนิมข้าวโพด	30	29	96.00
โรคราน้ำค้าง	30	26	86.00
โรคใบไหม้ข้าวโพด	30	27	90.00
รวมทั้งหมด	90	82	91.11

จากตารางที่ 4 เป็นผลการทดสอบโมเดลในการใช้งานจริงเพื่อหาความถูกต้องและความแม่นยำของโมเดลจากการทดสอบทั้งหมด 90 ครั้ง โรคละ 30 ครั้ง มีผลดังนี้ 1) โรคราสนิมข้าวโพด ถูกต้อง 29 ครั้ง คิดเป็นร้อยละ 96.00, 2) โรคราน้ำค้าง ถูกต้อง 26 ครั้ง คิดเป็นร้อยละ 86.00, 3) โรคราน้ำค้าง ถูกต้อง 27 ครั้ง คิดเป็น ร้อยละ 90.00, เฉลี่ยความถูกต้องโดยรวมเท่ากับร้อยละ 91.11

ผลการวิจัยนี้แสดงให้เห็นว่า โมเดลที่พัฒนาขึ้นมีความสามารถในการตรวจจับโรคข้าวโพดได้อย่างมีประสิทธิภาพสูง การประยุกต์ใช้เทคนิค YOLOv11 ซึ่งเป็นเทคโนโลยีที่โดดเด่นสำหรับงานตรวจจับวัตถุแบบเรียลไทม์ ทำให้ระบบสามารถประมวลผลได้อย่างรวดเร็วและแม่นยำ ส่งผลโดยตรงต่อการเพิ่มประสิทธิภาพในการวินิจฉัยและระบุสาเหตุของโรคข้าวโพดในระยะเริ่มต้นได้อย่างดียิ่ง

ข้อเสนอแนะเพิ่มเติม ควรมีการทดสอบเพิ่มเติมในสถานการณ์ที่มีความหลากหลายและซับซ้อน เช่น การเปลี่ยนแปลงของสภาพแสงที่ต่างกัน หรือการตรวจจับวัตถุในกรณีที่มีการบังบางส่วน การทดสอบในสภาพแวดล้อมจริงจะช่วยประเมินขีด ถือเป็นเครื่องมือสำคัญที่ช่วยแก้ปัญหาให้แก่เกษตรกรผู้ปลูกข้าวโพด และเป็นตัวอย่างที่ชัดเจนในการส่งเสริมให้มีการนำนวัตกรรมมาใช้เพื่อยกระดับคุณภาพชีวิตและสร้างความยั่งยืนในภาคเกษตรกรรมต่อไป

สรุปผลและอภิปรายผล

จากผลการทดลองพบว่าโมเดล YOLOv11n ให้ความแม่นยำสูงสุดในการจำแนกโรคของข้าวโพดโดยมีความแม่นยำ เท่ากับ 98.2% รองลงมาคือ YOLOv8n เท่ากับ 96.3%) และ YOLOv5s เท่ากับ 94.8% ขณะที่ ResNet-50 และ MobileNetV2 มีความแม่นยำลดลงอย่างชัดเจน เนื่องจากสถาปัตยกรรมทั้งสองเน้นการตรวจจับวัตถุทั่วไปในเชิงภาพนิ่งมากกว่าการตรวจจับเชิงเรียลไทม์ ซึ่งต้องอาศัยการประมวลผลที่รวดเร็วและสามารถจับลักษณะสีและพื้นผิว (texture) ได้ อย่างมีประสิทธิภาพ สาเหตุที่ YOLOv11n ให้ผลดีกว่าโมเดลอื่น สามารถอธิบายได้ด้วยหลักการของ Convolutional Neural Network (CNN) ที่มุ่งเน้นการเรียนรู้คุณลักษณะเชิงพื้นที่ (spatial features) จากภาพ เช่น สี ลวดลาย และพื้นผิว ซึ่งมีความสัมพันธ์โดยตรงกับโรคของผลไม้ (Zhou et al., 2021) โดย YOLOv11 มีการพัฒนาโครงสร้างแบบ Hybrid Backbone (RT-DETR) และใช้กลไก Anchor-free Detection ที่ช่วยให้ตรวจจับวัตถุขนาดเล็กและความซับซ้อนได้แม่นยำกว่าแบบดั้งเดิม ทั้งยังลดปัญหา overfitting ในข้อมูลชุดเล็ก (Li et al., 2023; Zhang et al., 2024)

ดังนั้น สามารถสรุปได้ว่า YOLOv11n เป็นสถาปัตยกรรมที่มีประสิทธิภาพสูงสุด สำหรับการจำแนกโรคของข้าวโพด เนื่องจากสามารถเรียนรู้ฟีเจอร์เชิงลึกของสีและพื้นผิวได้อย่างแม่นยำ มีความเร็วในการประมวลผลสูง และลดความคลาดเคลื่อนของการจำแนกได้ดีกว่าโมเดลอื่น นอกจากนี้ยังเป็นตัวอย่างของการนำนวัตกรรมมาใช้เพื่อยกระดับคุณภาพชีวิตและสร้างความยั่งยืนในภาคเกษตรกรรมต่อไป

เอกสารอ้างอิง

- Ahmad A., Saraswat D. & Gamal E A. (2022). A survey on using deep learning techniques for plant disease diagnosis and recommendations for development of appropriate tools. *Computers an Electronics in Agriculture*.<https://www.sciencedirect.com/science/article/pii/S277237552200048X>
- Aldakheel, E. A., Zakariah, M., & Alabdallal, A. H. (2024). Detection and identification of plant leaf diseases using YOLOv4. *Frontiers in Plant Science*, 15, 1355941. doi: 10.3389/fpls.2024.1355941

- Alhwaiti, Y., Khan, M., Asim, M., Siddiqi, M. H., Ishaq, M., & Alruwaili, M. (2025). Leveraging YOLO deep learning models to enhance plant disease identification. *Scientific Reports*, 15, 7969. doi: 10.1038/s41598-025-92143-0
- Andrew, J., Eunice J., Popescu D., Chowdary, M., & Hemanth, J. (2022). Deep Learning-Based Leaf Disease Detection in Crops Using Pre-trained Models. *Agronomy*. 12, 2395. <https://www.mdpi.com/2073-4395/12/10/2395>
- Askale, G.T., Yibel, A.B., Taye, B.M., & Wubneh, G.D. (2025). Mobile based deep CNN model for maize leaf disease detection and classification. *Plant Methods*, 21(72). <https://doi.org/10.1186/s13007-025-01386-5>
- Cap, Q. H., Uga, H., Kagiwada, S., & Iyatomi, H. (2020). LeafGAN: An Effective Data Augmentation Method for Practical Plant Disease Diagnosis. *arXiv*. doi: 10.48550/arXiv.2002.10100
- Fraivan, M., Esraa, F., and Khasawneh, N. (2022). Classification of Corn Diseases from Leaf Images Using Deep Transfer Learning. *Plants*, 11(20), 2668. doi: 10.3390/plants11202668
- Fu, Y., Gou, L., & Hung, F. (2024). A lightweight CNN model for pepper leaf disease recognition in a human palm background. *Journal of Plant Protection and Resources*. <https://www.sciencedirect.com/science/article/pii/S2405844024094787>
- Janruang, N., and Unartngam, P. (2018). Morphological and Molecular Based Identification of Corn Downy Mildew Distributed in Thailand. *International Journal of Agricultural Technology*, 14(6), 845–860. <https://www.thaiscience.info/Journals/Article/IJAT/10992417.pdf>
- Jung, M., Song, J.S., Shin, A.Y., Choi, B., Go, S., Kwon, S., Park J., & Kim, Y.M. (2023). Construction of deep learning-based disease detection model in multiple crops. *Scientific Reports*. 13(7331). <https://www.nature.com/articles/s41598-023-34549-2>
- Parez, S., Dilshad, N., Alghamdi, N. S., Alanazi, T. M., and Lee, J. W. (2023). Visual intelligence in precision agriculture: exploring plant disease detection via efficient vision transformers. *Sensors*, 23(15), 6949. <https://doi.org/10.3390/s23156949>
- Sun, X., Li, G., Qu, P., Xie, X., Pan, X., & Zang, W. (2022). Research on plant disease identification based on CNN. *Cognitive Robotics*, (2), 155–163. doi: 10.1016/j.cogr.2022.07.001
- Thakur, P. S., Khanna, P., Sheorey, T., & Ojha, A. (2022). Explainable vision transformer enabled convolutional neural network for plant disease identification: PlantXViT. *arXiv*. <https://arxiv.org/abs/2207.07919>
- Zhang, Y., et al. (2024). An ensemble of deep learning architectures for accurate plant leaf disease classification. *Computers and Electronics in Agriculture*. <https://doi.org/10.37936/ecti-cit.2024181.254501>
- Zhou, Z., et al. (2021). Plant diseases and pests detection based on deep learning: a review. *Plant Methods*. 17(22), <https://doi.org/10.1186/s13007-021-00722-9>
- ศูนย์วิจัยข้าวโพดนครสวรรค์. (ม.ป.ป). (2567, 15 สิงหาคม). องค์ความรู้ข้าวโพดเลี้ยงสัตว์. https://www.doa.go.th/fc/nakhonsawan/?page_id=2321

Translated Thai References

- Nakhon Sawan Field Crops Research Center. (2024, August 15). *Knowledge on feed corn*. Retrieved from https://www.doa.go.th/fc/nakhonsawan/?page_id=2321