

การออกแบบระบบสมองกลฝังตัวที่ประยุกต์ AI แบบต้นทุนต่ำบน ESP32-CAM สำหรับการวิเคราะห์โรคเชื้อราบนใบพริก: กรณีศึกษาพริกหยวก Design of Low-cost AI-Applied Embedded System on ESP32-CAM for Leaf Fungal Disease Analysis: A Case Study of Bell Pepper

อัฐวุฒิ ไหวพริบ^{1*} ณัฐพร ฤทธิ์นุ่ม² เกษม อุทัยไขฟ้า³ สุภณัท ดันวรรณรักษ์⁴ และ ณัฐฐา พลฤกษ์กานนท์⁵

^{1,4,5}สาขาวิชาวิศวกรรมคอมพิวเตอร์และปัญญาประดิษฐ์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย

^{2,3}สาขาวิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ มหาวิทยาลัยหอการค้าไทย

โทรศัพท์: ¹02-697-6722*, ²089-117-8789, ³02-697-6705

อีเมล: ¹auttawut_wai@utcc.ac.th*, ²anuri_art@yahoo.com, ³kasem_uta@utcc.ac.th

บทคัดย่อ

บทความนี้นำเสนอการออกแบบและพัฒนาระบบสมองกลฝังตัว ต้นทุนต่ำสำหรับตรวจจับโรคเชื้อราบนใบพริก โดยประยุกต์เทคโนโลยีปัญญาประดิษฐ์ (Artificial Intelligence: AI) บนอุปกรณ์ ESP32-CAM ซึ่งมีความสามารถในการประมวลผลภาพในตัว ระบบได้รับการฝึกฝนด้วยโมเดล Convolutional Neural Network (CNN) เพื่อวิเคราะห์ภาพใบพริกหยวกขนาด 64x64 พิกเซลบนรูปแบบ Greyscale โดยจำแนกออกเป็นสองประเภทได้แก่ ใบพริกในสภาพปกติ และ ใบพริกที่มีสภาพการติดเชื้อรา โมเดลได้รับการพัฒนาโดยใช้ภาษา Python และแปลงเป็นรูปแบบ TensorFlow Lite สำหรับใช้งานบน ESP32-CAM ด้วยไลบรารี EloquentTinyML ทำให้ระบบสามารถทำงานได้แบบออฟไลน์โดยไม่ต้องพึ่งพาอินเทอร์เน็ต (Edge-AI) ผลการทดลองแสดงให้เห็นว่าระบบสามารถจำแนกโรคได้อย่างแม่นยำเฉลี่ย 92.5% และใช้เวลาในการประมวลผลโดยเฉลี่ยประมาณ 3 วินาทีต่อภาพ นอกจากนี้ระบบยังสามารถควบคุมรีเลย์สำหรับการพ่นสารกำจัดเชื้อราโดยอัตโนมัติ และแจ้งเตือนผู้ใช้งานเมื่อพบการติดเชื้อ ระบบที่นำเสนอเป็นระบบที่ใช้พลังงานต่ำ สามารถทำงานได้ต่อเนื่องในภาคสนามด้วยแบตเตอรี่สำรอง ต้นทุนการประกอบระบบโดยรวมไม่รวมปั๊มพ่นน้ำอยู่ที่ประมาณ 1,800.- บาท เหมาะสำหรับเกษตรกรรายย่อยหรือพื้นที่ที่มีข้อจำกัดด้านการเชื่อมต่ออินเทอร์เน็ตและงบประมาณ

คำสำคัญ: ปัญญาประดิษฐ์ การตรวจจับโรคพืช ESP32-CAM การเรียนรู้ของเครื่อง โรคเชื้อรา พริกหยวก เกษตรอัจฉริยะ

Abstract


This article presents the design and development of a low-cost embedded system for detecting fungal diseases on leaves by applying Artificial Intelligence (AI) technology on the ESP32-CAM device, which has built-in image processing capabilities. The system is trained with a Convolutional Neural Network (CNN) model to analyze 64x64 pixel bell pepper leaf images in Greyscale format, classifying them into two types: normal leaves and leaves with fungal infections. The model is developed using Python and converted to TensorFlow Lite format for use on

ESP32-CAM with the EloquentTinyML library, enabling the system to work offline without relying on the Internet (Edge-AI). The experimental results show that the system can classify diseases with an average accuracy of 92.5% and takes an average processing time of about 3 seconds per image. In addition, the system can control a relay for automatic fungicide spraying and alert the user when an infection is detected. The proposed system is a low-power system that can work continuously in the field with a backup battery. The total system assembly cost, excluding the spray pump, is approximately 1,800.- baht, suitable for small farmers or areas with limited internet connectivity and budget.

Keywords: Artificial Intelligence, Plant Disease Detection, ESP32-CAM, Machine Learning, Fungal Disease, Bell Pepper, Smart Agriculture

1. ข้อมูลทั่วไป

การระบาดของโรคพืชโดยเฉพาะโรคเชื้อราบนใบพริก อาทิ พริกหยวก ที่ผ่านมาการตรวจหาโรคเชื้อราของพริกหยวก เกษตรกรยังคงใช้การสังเกตด้วยตาซึ่งอาจเกิดความคลาดเคลื่อนในการวินิจฉัยและนำไปสู่การใช้สาร




รูปที่ 1: ระบบสำหรับการวิเคราะห์โรคเชื้อราบนใบพริกที่นำเสนอ

เคมีเกินความจำเป็น ส่งผลต่อต้นทุนการผลิต การสะสมสารพิษในสภาพแวดล้อม ด้วยเหตุนี้การนำเทคโนโลยีที่มีความแม่นยำมาประยุกต์กับการตรวจโรคพืชจึงสามารถช่วยลดความเสียหายของผลผลิต ลดการใช้สารเคมีตลอดจนต้นทุนทางการเกษตร ปัจจุบันเทคโนโลยี AI โดยเฉพาะ “การเรียนรู้ของเครื่อง” (Machine Learning) และโครงข่ายประสาทเทียมแบบ CNN กำลังได้รับความนิยมด้วยศักยภาพในการวิเคราะห์ภาพถ่ายเพื่อการวินิจฉัยโรคพืช อย่างไรก็ตามการนำเทคโนโลยีเหล่านี้มาใช้งานก็ยังคงต้องเผชิญข้อจำกัดด้านต้นทุนและความซับซ้อนของระบบ

การประยุกต์ AI กับระบบสมองกลฝังตัวเพื่อการวิเคราะห์ข้อมูลภาพจากกล้องหรือเซ็นเซอร์แบบเวลาจริงโดยไม่พึ่งพาเซิร์ฟเวอร์ภายใต้กรอบเทคโนโลยี Edge-AI สำหรับการตรวจโรคพืช ได้รับการวิจัยและพัฒนาอย่างต่อเนื่อง ปี 2018 Rizk และคณะ ได้พัฒนาหุ่นยนต์ตรวจสอบสุขภาพพืชในระยะเริ่มต้นโดยใช้กล้องวิเคราะห์ภาพแบบอัตโนมัติ สามารถเคลื่อนที่ในแปลงเพาะปลูกและตรวจจับลักษณะผิดปกติของใบพืช งานวิจัยนี้ถือเป็นจุดเริ่มต้นของการนำ AI มาประยุกต์ในระบบสมองกลฝังตัวสำหรับการเกษตร [1] ปี 2019 Militante และคณะ ได้นำเสนอการประยุกต์ Deep Learning โดยเฉพาะ CNN สำหรับการจำแนกโรคบนใบพืชโดยใช้ชุดข้อมูลภาพใบพืชแบบหลากหลาย ผลลัพธ์แสดงให้เห็นว่าโมเดลสามารถจำแนกโรคพืชได้อย่างมีประสิทธิภาพและแสดงถึงศักยภาพของ Deep Learning ในการวิเคราะห์ภาพทางการเกษตร [2] ปีเดียวกัน Too และคณะ ได้ศึกษาเปรียบเทียบประสิทธิภาพของโมเดล Deep Learning หลายประเภทในการจำแนกโรคพืชจากภาพถ่ายโดยใช้ชุดข้อมูล PlantVillage พบว่าโมเดล ResNet-50 มีความแม่นยำสูงสุด งานวิจัยนี้เป็นพื้นฐานสำคัญสำหรับการเลือกโมเดลที่เหมาะสมกับขีดจำกัดของอุปกรณ์ฝังตัว [3] ปี 2021 Abdade และคณะ ได้นำเสนอการสำรวจเชิงลึกเกี่ยวกับ TinyML ซึ่งเป็นแนวทางของการประมวลผล AI บนอุปกรณ์ฝังตัวขนาดเล็ก อาทิ ไมโครคอนโทรลเลอร์ที่มีทรัพยากรจำกัด เน้นการประยุกต์ในด้านต่างๆ รวมถึง Smart Agriculture ที่ใช้ Edge-AI สำหรับการวิเคราะห์ภาพใบพืช [4] ล่าสุด ปี 2024 Joshi ได้นำเสนอการพัฒนาโมเดล Lightweight CNN และ Vision Transformer สำหรับการตรวจโรคพืชในสภาพแวดล้อมที่จำกัดทรัพยากร เน้นการ Deploy บนอุปกรณ์ Edge อาทิ Raspberry Pi และ Jetson Nano ผลลัพธ์แสดงความแม่นยำสูงกว่า 95% และใช้เวลาตอบสนองต่ำซึ่งแสดงให้เห็นว่าเทคโนโลยี Edge-AI มีความพร้อมใช้งานจริงในภาคเกษตร [5] งานวิจัยที่ได้กล่าวมานี้แสดงให้เห็นถึงความก้าวหน้าทางเทคโนโลยี AI ที่ผสมเข้ากับระบบสมองกลฝังตัว Edge-AI เพื่อประยุกต์กับการวิเคราะห์โรคพืชโดยตรงโดยไม่ต้องพึ่งพาระบบคลาวด์

งานวิจัยนี้จึงมีแนวคิดในการออกแบบและพัฒนากระบวนการวิเคราะห์โรคพืชแบบออฟไลน์ด้วยอุปกรณ์ต้นแบบอย่าง ESP32-CAM ที่สามารถประมวลผลภาพใบพืชที่หยกผ่านโมเดล CNN โดยสามารถฝังตัวอยู่ในอุปกรณ์ได้โดยตรง จึงสามารถลดข้อจำกัดในเรื่องการเชื่อมต่ออินเทอร์เน็ต มีความแม่นยำในการวิเคราะห์ สามารถประยุกต์ได้จริง ใช้งานไม่ยาก เข้าถึงได้ ราคาไม่สูง และใช้งานได้ในระยะยาว ระบบต้นแบบที่นำเสนอแสดงได้ดังรูปที่ 1




รูปที่ 2: ขั้นตอนการประมวลผลบนโมเดล CNN

2. แนวความคิดพื้นฐาน ทฤษฎี และโครงสร้างระบบ

2.1 แนวความคิดพื้นฐาน

การวิเคราะห์ภาพถ่ายโดยโครงข่ายประสาทเทียมแบบ CNN ได้รับความนิยมในการนำมาประมวลผลภาพสี RGB งานวิจัยนี้ได้เลือกใช้ภาพใบพืชในแบบ Greyscale ขนาด 64x64 พิกเซล (ไม่พิจารณา Data Augmentation บางกรณี อาทิ การหมุน การพลิกภาพ) ซึ่งแม้จะไม่มีข้อมูลสี แต่ก็ยังสามารถนำมาใช้ฝึกฝนโมเดล CNN ได้ ขั้นตอนการประมวลผลบนโมเดล CNN แสดงดังรูปที่ 2 ภาพ Greyscale แสดงข้อมูลในรูประดับความเข้มแสง (Intensity) เพียงมิติเดียวตั้งแต่ 0 (ดำสนิท) ถึง 255 (ขาว) โดยไม่มีแกนแนสแบบ RGB ภาพลักษณะนี้เน้นสวดลายพื้นผิว (Texture) และขอบเขตของวัตถุเป็นหลัก CNN จึงสามารถเรียนรู้ความแตกต่างของรูปแบบพิกเซลและความผิดปกติของพื้นผิวบนใบพืช อาทิ จุดด่าง เส้นรอยโรค หรือขอบใบที่เสียหายได้แม้ภาพไม่มีสี โรคใบพืชจากเชื้อรา ลักษณะของใบที่ติดโรคมักมีจุดสีเข้ม เส้นลายแตกต่าง หรือรูปทรงของใบที่ผิดปกติ ซึ่งแม้จะถูกแปลงเป็นแบบ Greyscale แล้ว ข้อมูลเหล่านี้ก็ยังคงปรากฏในรูปความแตกต่างของระดับความเข้มแสงและสวดลายในระดับพิกเซลโดย CNN จะทำหน้าที่สกัดพีเจอร์ผ่าน Convolutional Layers และใช้ Layer สุดท้ายเพื่อจำแนกภาพว่าอยู่ในกลุ่ม “ใบปกติ” หรือ “ใบที่ติดเชื้อรา” ดังนั้นการเลือกใช้ภาพ Greyscale ที่มีขนาดเล็กขนาด 64x64 พิกเซล จึงมีข้อดีในการลดภาระการประมวลผลและการใช้หน่วยความจำ เหมาะกับการใช้งานกับอุปกรณ์ฝังตัว อาทิ ESP32-CAM ที่มีข้อจำกัดด้านทรัพยากรจัดเก็บข้อมูลโดยไม่ส่งผลกระทบต่อความสามารถในการตรวจจับโรคพืช ขั้นตอนและวิธีการแปลงโมเดล CNN ไปสู่ Edge-AI แสดงดังรูปที่ 3 ดังนั้นแม้ไม่มีการใช้ข้อมูลสี ระบบก็ยังสามารถแยกแยะโรคพืชจากใบพืชได้อย่างแม่นยำด้วยพื้นฐานการเรียนรู้รูปแบบเชิงลึกผ่านข้อมูล Greyscale เพียงแกนแนลเดียว



รูปที่ 3: กระบวนการแปลงไฟล์แบบโมเดล CNN ไปสู่ Edge-AI



รูปที่ 4: การเทียบน้ำหนักระหว่าง RGB กับ Greyscale


2.2 หลักการแปลงรูปแบบ RGB เป็น Greyscale

การแปลงภาพสีรูปแบบ RGB เป็น Greyscale จะใช้ค่าน้ำหนัก Weighted Average โดยพิจารณาความสำคัญของแต่ละช่องสีตามการรับรู้ของตาดังสมการ Weighted Method (1)


Greyscale Intensity

$$= (0.299 \times R) + (0.587 \times G) + (0.114 \times B) \dots \dots \dots (1)$$

เหตุผลของน้ำหนัก; 0.587 (G): ตาเห็นสีเขียวได้ชัดเจนที่สุด จึงมีน้ำหนักมากที่สุด; 0.299 (R): สีแดงมีน้ำหนักรองลงมา; 0.114 (B): สีน้ำเงินมีน้ำหนักน้อยที่สุด เพราะตารับรู้ได้ต่ำสุด จากรูปที่ 4 ค่าที่ได้จะอยู่ในช่วง 0 – 255 และใช้แทนค่าพิกเซลในภาพ Greyscale สมมติถ้าค่า Red = 0, Green = 0, Blue = 0 ผลที่ได้คือ “สีดำ”; Red = 255, Green = 255, Blue = 255 ผลที่ได้คือ “สีขาว”; Red = 128, Green = 128,



รูปที่ 5: ตัวอย่างการแปลงภาพรูปแบบ RGB ไปสู่ Greyscale



รูปที่ 6: กราฟแสดงความแม่นยำของโมเดล CNN ระหว่างการฝึกฝน


Blue = 128 ผลที่ได้คือ “สีเทา”

3. ผลการทดลองและวิเคราะห์


ผลการทดลองและวิเคราะห์จำแนกได้เป็น 2 ส่วน: 1. การทดสอบความแม่นยำของโมเดล (Accuracy) ด้วย Python; 2. การทดสอบระบบโดยจำลองระบบกับอุปกรณ์ที่ประยุกต์เสมือนจริงเพื่อดูผลการตอบสนองของระบบ Edge-AI & CNN ด้วย ESP32-CAM

การทดสอบความแม่นยำของโมเดลดำเนินการด้วยภาษา Python โดยใช้ชุดข้อมูลภาพใบพริกหยวก ที่แบ่งเป็นสองประเภท ได้แก่ ใบปกติและใบที่ติดเชื้อรา จำนวนทั้งสิ้น 200 ภาพ โดยใช้ 160 ภาพในการฝึกฝนโมเดล และอีก 40 ภาพในการทดสอบประสิทธิภาพของระบบ ใช้โมเดล CNN ฝึกฝนภาพใบพริกหยวกแบบ Greyscale ขนาด 64x64 พิกเซลดังรูปที่ 5 จำนวน 10 Epoch ได้ผลการทดสอบดังรูปที่ 6 ซึ่งพบว่าโมเดล CNN ที่ฝึกฝน สามารถจำแนกใบปกติ-ติดเชื้อราได้อย่างแม่นยำจากผลการทดสอบโดยชุดข้อมูลทดสอบ 40 ภาพพบว่า Accuracy: 92.5%

การทดสอบระบบโดยจำลองระบบกับอุปกรณ์ที่ใช้เสมือนจริงของ Edge-AI & CNN ดังรูปที่ 7 และอัลกอริทึมดังรูปที่ 8 โดยกำหนดให้ ESP32-CAM ทำการถ่ายภาพใบพืชจริงทุก 20 วินาที ช่วงการทดสอบแบ่งออกเป็น 2 ช่วง ทดสอบช่วงเช้าเวลา 07:00–07:30 น. และช่วงบ่ายเวลา 13:00 – 13:30 น. เพื่อดูผลการตอบสนองต่อค่าความเข้มแสงที่ต่างกันแล้วประมวลผลด้วยโมเดล CNN บนอุปกรณ์ ผลการทดสอบพบว่าระบบสามารถวิเคราะห์ภาพและตัดสินใจได้อย่างต่อเนื่องเมื่อตรวจพบใบที่ติด



รูปที่ 7: การจำลองระบบจริงด้วย ESP32-CAM ที่เชื่อมต่อกับวงจรพ่นยาอัตโนมัติ



รูปที่ 8: โฟลว์ชาร์ตการทำงานของระบบสมองกลฝังตัว

โรคเชื้อรา แม้มีค่าความเข้มแสงที่แตกต่างกันบ้างไม่มากนัก และสามารถควบคุมโซลิตัสเตท-รีเลย์เพื่อเปิดปั๊มซึ่งเป็นเสมือนการสั่งการพ่นสารอัตโนมัติได้ภายในเวลาไม่เกิน 1 วินาทีภายหลังการวิเคราะห์ กรณีตรวจพบใบที่มีสภาพปกติในชุดทดสอบ ระบบจะใช้เวลาโดยเฉลี่ยประมาณ 3 วินาทีต่อภาพในการทำ Inference ซึ่งรวดเร็วเพียงพอสำหรับการใช้งานจริงในการตรวจจับโรคพืชแบบเวลาจริง ผลการทดสอบระบบที่น่าเสนอเปรียบเทียบกับผลงานวิจัยและพัฒนาที่ผ่านมาแสดงดังตารางที่ 1

4. สรุปและข้อเสนอแนะ

การออกแบบและพัฒนาระบบวิเคราะห์โรคเชื้อราบนใบพืช: กรณีศึกษาพริกหยวกที่มีต้นทุนต่ำโดยประยุกต์ AI บนระบบสมองกลฝังตัว ESP32-CAM ด้วยอัลกอริทึมที่ออกแบบ ระบบสามารถประมวลผลภาพใบพริกหยวกแบบ Edge-AI ด้วยโมเดล CNN โดยไม่ต้องพึ่งพาการเชื่อมต่ออินเทอร์เน็ต ใช้ข้อมูลภาพใบพริกแบบ Grey Scale ขนาด 64x64 พิกเซล

ตารางที่ 1: การเปรียบเทียบคุณลักษณะของระบบที่พัฒนากับระบบอื่นในผลงานวิจัยที่ผ่านมา

System	Devices	Accuracy (%)	Approx. Cost (THB)	Speed (sec)	Offline
This Research	ESP32-CAM + CNN	92.5%	1,800.-	3.0	Yes
Refer to [3]	Jetson Nano	95.0%	4,500.-	1.0	No
Refer to [5]	Raspberry Pi + Camera	> 95.0%	5,500.-	5.0	Yes

โดยแปลงด้วย TensorFlow Lite เพื่อให้ได้ข้อมูลที่เหมาะกับการทำงานบนอุปกรณ์สมองกลฝังตัว แล้วฝังโมเดลดังกล่าวลงบน ESP32-CAM ด้วยไลบรารี EloquentTinyML ระบบสามารถวิเคราะห์และจำแนกใบพืชที่ติดโรคเชื้อราได้อย่างแม่นยำด้วยค่าเฉลี่ย 92.5% โดยใช้เวลาประมวลผลเพียงประมาณ 3 วินาทีต่อภาพ ระบบสามารถเชื่อมต่อกับรีเลย์ควบคุมระบบพ่นสารฆ่าเชื้อได้แบบอัตโนมัติได้ พร้อมการแจ้งเตือนผ่านอุปกรณ์ภายนอกรองรับการใช้งานโดยเกษตรกรรายย่อยได้ด้วยต้นทุนไม่สูง ประมาณ 1,800.- บาท นอกจากนี้ยังสามารถนำไปประยุกต์กับการวิเคราะห์โรคเชื้อรากับพืชชนิดอื่น หรือพัฒนากับระบบที่ใช้การประมวลผลแบบออนไลน์ (Cloud-based AI) แทนการประมวลผลแบบ Edge-AI บนระบบคลาวด์ (มีค่าใช้จ่าย) ทำให้สามารถประมวลผลข้อมูลที่มีปริมาณมากได้หากต้องการวิเคราะห์โรคพืชที่ซับซ้อนมากขึ้น และใช้ Data Augmentation เพื่อเพิ่มความหลากหลายของข้อมูล ลดโอกาสการเกิด Overfitting ได้ แต่ในกรณีพื้นที่เพาะปลูกที่ทุรกันดารปราศจากสัญญาณอินเทอร์เน็ต อาจใช้งานระบบไม่ได้และมีค่าใช้จ่ายเพิ่มเติม

5. กิตติกรรมประกาศ

คณะผู้วิจัย ขอแสดงความขอบพระคุณ คณะวิศวกรรมศาสตรมหาวิทยาลัหอการค้าไทย ที่ให้การสนับสนุนปฏิบัติการวิจัยนี้

เอกสารอ้างอิง

- [1] H. Rizk, and M. K. Habib, "Robotized Early Plant Health Monitoring System," in IECON 2018 - 44th Annual Conference of the IEEE Industrial Electronics Society, Washington, DC, USA, 2018, pp. 3795 - 3800.
- [2] S. V. Militante, B. D. Gerardo, and N. V. Dionisio, "Plant Leaf Detection and Disease Recognition Using Deep Learning," in 2019 IEEE Eurasia Conference on IoT, Communication and Engineering (ECICE), Yunlin, Taiwan, 2019, pp. 579 - 582.
- [3] E. Too, L. Yujian, S. Njuki, and L. Yingchun, "A Comparative Study of Fine Tuning Deep Learning Models for Plant Disease Identification," Applied Sciences, vol. 9, no. 14, p. 2859, 2019.
- [4] Y. Abdade, A. Temouden, H. Bamoumen, N. Benamar, and Y. Chtouki, "A Comprehensive Survey on TinyML," IEEE Access, 2021.
- [5] H. Joshi, "Edge AI for Agriculture: Lightweight Vision Models for Disease Detection in Resource Limited Settings," arXiv, Dec 2024.