

การพัฒนาระบบควบคุมโรงเรือนใบบัวบกอัตโนมัติโดยใช้เทคโนโลยี IoT และการจำแนกใบบัวบก
โดยการเรียนรู้เชิงลึก

Development of greenhouse control systems *Centella asiatica* (L.) Urb.
Automatically using IoT technology and classification of *Centella asiatica* (L.)
Urb. by deep learning

สิทธิพงษ์ พรอุดมทรัพย์¹ สิทธิพร พรอุดมทรัพย์² รณกร รัตนธรรมมา¹ และ เดิมยศ เสนีวงศ์ ณ อยุธยา¹
Sittiphong Pornudomthap,¹ Sittiporn Pornudomthap,² Ronnagorn Rattanatamma,¹ and Tomeyot
Sanevong Na Ayutaya¹

¹คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏพระนคร

¹Faculty of Science and Technology, Phranakhon Rajabhat University

²คณะวิทยาการจัดการ มหาวิทยาลัยราชภัฏอุดรดิตถ์

²Faculty of Management Science, Uttaradit Rajabhat University

E-mail: sittiphong@pnru.ac.th, varufly@gmail.com

Received: April 30, 2024; Revised August 12, 2024; Accepted August 14, 2024

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อ 1) ส่วนของการพัฒนาระบบควบคุมโรงเรือนอัตโนมัติโดยใช้เทคโนโลยี IoT โดยโรงเรือนประกอบด้วย เซ็นเซอร์ตรวจวัดอุณหภูมิ ความชื้นในดิน เซ็นเซอร์ธาตุ N P K โดยส่งข้อมูลกับ NetPie server ทำงานร่วมกับ ภาพจากกล้องวงจรปิดในโรงเรือน และ AI server เพื่อควบคุมการทำงาน ระบบเครื่องลดน้ำ ระบบพ่นหมอก โดยโรงเรือนสามารถควบคุมได้ทั้งที่โรงเรือนหรือควบคุมผ่านระบบอินเทอร์เน็ตและควบคุมอัตโนมัติผ่านปัญญาประดิษฐ์ 2) ส่วนการเพื่อศึกษาการจำแนกรูปภาพใบบัวบกที่มีขนาดเล็ก ขนาดกลาง ขนาดใหญ่ โดยใช้การเทคนิคการเรียนรู้เชิงลึก เพื่อพัฒนาแบบจำลองการจำแนกโครงสร้างประสาทเทียม Convolutional Neural Network (CNN) โดยใช้ โมเดล VGG16, ResNet50 และ InceptionV3 ร่วมกับการใช้เทคนิคการเรียนรู้แบบถ่าย โดยได้ใช้ชุดข้อมูลที่เก็บรวบรวมเองและภาพจากอินเทอร์เน็ต

ผลการวิจัยพบว่า

1. ระบบควบคุมโรงเรือนอัตโนมัติผู้เชี่ยวชาญและผู้ใช้งานจำนวน 10 คน มีความพึงพอใจอยู่ในระดับพึงพอใจมาก ($\bar{x} = 4.16$, S.D. = 0.74) และระบบปัญญาประดิษฐ์ ประเมินโมเดล VGG16 มีประสิทธิภาพมากที่สุด ค่าความแม่นยำเท่ากับ .82 รองลงมาคือโมเดล InceptionV3 เท่ากับ .73 และ ResNet50 เท่ากับ .60 อยู่ในเกณฑ์ที่ดี

2. สามารถจำแนกใบบัวบกที่ขนาดใบเล็กถูกต้อง 83 ภาพ ทายผิด 19 ภาพ ใบบัวบกที่ขนาดใบกลางถูกต้อง 82 ภาพ ทายผิด 18 ภาพ และใบบัวบกที่ขนาดใบใหญ่ถูกต้อง 80 ภาพ ทายผิด 18 จากข้อมูลทดสอบ 300 รูปภาพ

คำสำคัญ: ใบบัวบก การเรียนรู้เชิงลึก การเรียนรู้แบบถ่ายโอนข้อมูล เทคโนโลยีในทุกสรรพสิ่ง

Abstract

This research aims to develop an automatic *Centella asiatica* (L.) Urb. greenhouse control system using IoT technology and *Centella asiatica* (L.) Urb. leaf classification using deep learning. The objectives are divided into two parts: 1) This part of developing an automatic control system using IoT technology, This involves creating a system using IoT technology to monitor and control various environmental parameters. The system includes temperature sensors, humidity sensors for both air and soil, and N, P, K element sensors. Data from these sensors is sent to the NetPie server, which integrates with images from CCTV cameras in the greenhouse and an AI server to manage the operation of the sprinkler and mist systems. The greenhouse can be controlled locally or via the internet, with automated control provided by artificial intelligence. 2) This part focuses on studying the classification of *Centella asiatica* (L.) Urb leaves of different sizes (small, medium, and large) using deep learning techniques. A classification model is developed using Convolutional Neural Networks (CNNs) with pre-trained models such as VGG16, ResNet50, and InceptionV3, along with transfer learning techniques. The evaluation of the system's efficiency was excellent ($\bar{x} = 4.16$, S.D. = 0.74). The VGG16 model was found to be the most efficient, with an accuracy of 0.82, followed by InceptionV3 at 0.73 and ResNet50 at 0.60. The VGG16 model performed well in classifying 83 small-sized leaves correctly and 19 incorrectly, 82 medium-sized leaves correctly and 18 incorrectly, and 80 large-sized leaves correctly and 18 incorrectly, out of 300 test images.

Keywords: *Centella asiatica* (L.) Urb., Deep learning, Knowledge transfer, IoT

บทนำ

บัวบก (*Centella asiatica* (Linn.) Urban) เป็นผักพื้นบ้านที่พบเห็นได้ทั่วไป คนไทยนิยมปลูกและบริโภค บัวบกมานาน เนื่องจากสามารถเติบโตให้ผลผลิตได้เร็ว (รัชนี พุคชชาติ, 2550) ในสภาพแวดล้อมที่มีดินร่วนปนทราย หรือชื้นแฉะ อุณหภูมิประมาณ 25-30 °C ไม่ชอบแสงแดดจัด มีปริมาณน้ำฝนเฉลี่ย 1,200–2,500 มิลลิเมตรต่อปี และใช้ระยะเวลาเพียง 60 วัน ก็สามารถเก็บเกี่ยวผลผลิตได้ (บุษบา บัวคำ และรักเกียรติ แสนประเสริฐ, 2560) แต่เนื่องด้วยปัจจุบันสภาพภูมิอากาศมีความแปรปรวนอย่างมาก จากผลกระทบของปรากฏการณ์ลานีญา (La Nina) หรือปรากฏการณ์เอลนีโญ (El Niño) ส่งผลให้มีฝนตกต่อเนื่องตั้งแต่ต้นปีจนถึงปัจจุบันหรือบางปีไม่มีฝนตกตั้งแต่ต้นปี จนถึงปัจจุบัน ส่งผลกระทบต่อผลผลิตทางการเกษตรได้รับความเสียหาย ผลผลิตไม่ได้ตามความต้องการ ทำให้เกษตรกร มีค่าใช้จ่ายในการผลิตเพิ่มขึ้น รวมไปถึงปัจจุบันได้รับผลกระทบจากราคาน้ำมันแพงขึ้น ปุ๋ยเคมีและสารเคมีต่าง ๆ ที่มีราคา สูงขึ้น ซึ่งปัจจัยทั้งหมดนี้ มีความสำคัญต่อภาคการเกษตรเป็นอย่างมาก ซึ่งพืชที่ได้รับผลกระทบนั้นมีหลายชนิด รวมไปถึงผักและสมุนไพร ได้แก่ ขมิ้น ขิง ไพร กะเพรา โหระพา พริก ผักชี ขึ้นฉ่าย ใบบัวบก ทำให้มีผลผลิตราคาสูง แต่ผลผลิตไม่เพียงพอต่อความต้องการ จากข้อมูลดังกล่าว พืชที่ปัจจุบันกำลังถูกพัฒนามาใช้ทางด้านเภสัช และเครื่องสำอาง เพื่อเพิ่มขีดความสามารถในการแข่งขันกับตลาด คือ ใบบัวบกจัดเป็นผักพื้นบ้าน ที่มีลักษณะ การเจริญเติบโตแบบเลื้อยไปกับพื้นดิน ขยายพันธุ์โดยใช้ไหล ชอบขึ้นในพื้นที่ที่มีความชื้นแฉะ มีความต้องการ แสงแดดรำไร สามารถเจริญเติบโตได้ดีในฤดูฝน แต่ปัจจุบันมีปัญหาเรื่องการผลิตในช่วงฤดูหนาวและร้อน เพราะปริมาณ ความชื้นสัมพัทธ์ในบรรยากาศต่ำ ส่งผลต่อการเจริญเติบโต ทำให้ใบมีขนาดเล็กลง ในฤดูร้อน มักพบขอบใบไหม้ และแห้งตาย และยังมีผลต่อการสร้างสารสำคัญในกลุ่มสารเอเซียติโคไซด์ (เน้นทวัน บุญยะประภัสร์, 2542)

นอกจากปัจจัยด้านสภาพแวดล้อมแล้ว ถ้ามีการจัดการเตรียมดิน การจัดการผลิตที่เหมาะสมจะทำให้ได้ผลผลิตที่มีคุณภาพ ก็จะทำให้เกษตรกรผู้ปลูกได้รับผลผลิตและประโยชน์จากผลผลิตอย่างเพียงพอ ซึ่งกระบวนการปลูกโดยใช้ระบบการปลูกแบบ Smart Farming ปลูกในโรงเรือนที่ปลูกในระบบเกษตรอินทรีย์จะใช้พื้นที่ในการเพาะปลูกน้อย และสามารถให้ผลผลิตได้อย่างสม่ำเสมอในทุกฤดูกาล สามารถควบคุมสภาพแวดล้อมต่าง ๆ ที่เกี่ยวข้องกับ การเจริญเติบโตได้ เช่น ความชื้นสัมพัทธ์บรรยากาศ ความชื้นดิน การจัดการดินและปุ๋ย การควบคุมปริมาณ ธาตุอาหาร pH โดยต้องการควบคุมโรงเรือนใบบวบแบบอัตโนมัติผ่านเทคโนโลยีการเรียนรู้เชิงลึก สิ่งเหล่านี้จะส่งผลกระทบต่อ การเจริญเติบโต ผลผลิตและคุณภาพของใบบวบ

คณะผู้วิจัยจึงมีแนวคิดในพัฒนาระบบควบคุมโรงเรือนใบบวบอัตโนมัติโดยใช้เทคโนโลยี IoT และการจำแนกใบบวบโดยการเรียนรู้เชิงลึก ประกอบด้วย ส่วนพัฒนาระบบควบคุมโรงเรือนใบบวบโดยใช้เทคโนโลยี IoT ประกอบด้วย เซ็นเซอร์วัดอุณหภูมิ วัดความชื้นในดินและในอากาศด้วยเซ็นเซอร์วัดความชื้น ความแห้งในดิน เซ็นเซอร์วัด Nitrogen (N), Phosphorus (P), Potassium (K) เข้าที่บอร์ด Arduino และเชื่อมต่อกล้องวงจรปิดและควบคุมระบบ เครื่องลดน้ำและระบบพ่นหมอก โดยสามารถทำงานผ่านตู้ในโรงเรือน ควบคุมผ่าน internet หรือควบคุมผ่านปัญญาประดิษฐ์ได้ และส่วนพัฒนาแบบจำลองปัญญาประดิษฐ์ใช้การเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นเครื่องมือสำหรับการพัฒนาและสร้างแบบจำลองในการทำงานโดยไม่ต้องอาศัยความช่วยเหลือจากมนุษย์โดยแสดงโครงข่ายประสาทเทียมแบบ CNN หรือ Convolutional Neural Network (CNN) ในการจำแนกขนาดใบบวบ 3 Class ได้แก่ ขนาดใบเล็ก ขนาดใบกลาง และขนาดใบใหญ่ ในส่วนของข้อมูล dataset ได้นำมาจากอินเทอร์เน็ตและ ผู้วิจัย ถ่ายรูปใบบวบเองคณะผู้วิจัยเลือกวงจรชีวิตของการพัฒนาระบบ SDLC: System Development Life Cycle (Kendal, 2020) เป็นกระบวนการในการพัฒนาระบบเพื่อให้ซอฟต์แวร์ตอบสนองตามความคาดหวังของผู้ใช้ในระหว่างการใช้งานจริงและหลังจากนั้น ระเบียบวิธีการนี้จะแสดงชุดขั้นตอนที่แบ่งกระบวนการพัฒนาซอฟต์แวร์ออกเป็นงาน ที่คุณสามารถมอบหมาย ดำเนินการ และวัดผลได้

วัตถุประสงค์ของการวิจัย

ในการวิจัยครั้งนี้มีวัตถุประสงค์ของงานวิจัยนี้

1. เพื่อออกแบบและพัฒนาระบบควบคุมโรงเรือนใบบวบอัตโนมัติโดยใช้เทคโนโลยี IoT
2. เพื่อออกแบบการพัฒนาปัญญาประดิษฐ์ในการจำแนกใบบวบโดยการเรียนรู้เชิงลึก

วิธีดำเนินการวิจัย

1. พัฒนาระบบควบคุมโรงเรือนใบบวบอัตโนมัติโดยใช้เทคโนโลยี IOT
ผู้วิจัยใช้โปรแกรม Arduino ในการเขียนโค้ดเพื่อควบคุมอุปกรณ์ สร้างระบบตามการออกแบบสถาปัตยกรรมของระบบควบคุมฟาร์มอัจฉริยะในโรงเรือนปลูกใบบวบ และออกแบบส่วนของโปรแกรมคอมพิวเตอร์ (GUI) และทำการเชื่อมต่ออุปกรณ์ระบบโดยสถาปัตยกรรมของระบบโรงเรือนอัตโนมัติประกอบด้วย 2 ส่วน

ส่วนที่ 1 On Cloud ประกอบด้วย Server 3 ตัว คือ

- NetPie server จะรับข้อมูล On Ground จาก Arduino ในโรงเรือน

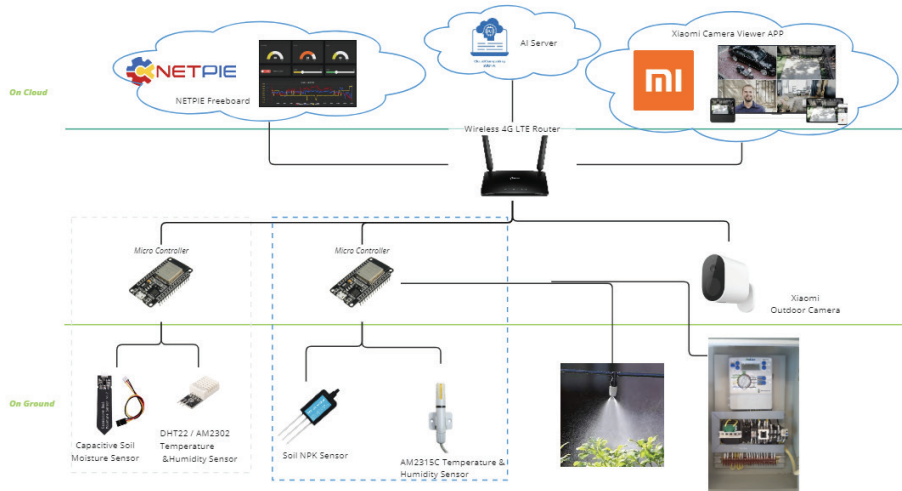
- Xiaomi Camera Server ถ่ายภาพการเติบโตใบบวบในแปลง

- Ai Server ใช้ข้อมูลจาก NetPie server และ Xiaomi Camera Server มาประมวลผลสร้างโมเดล

ปัญญาประดิษฐ์และควบคุมในโรงเรือนใบบวบ

ส่วนที่ 2 On Gound

Arduino ทำการเชื่อมต่ออุปกรณ์ระบบโดย ต่อเซ็นเซอร์วัดอุณหภูมิ วัดความชื้นในดินและในอากาศ ด้วยเซ็นเซอร์วัดความชื้น ความแห้งในดิน เซ็นเซอร์วัด Nitrogen (N), Phosphorus (P), Potassium (K) เข้าที่บอร์ด Arduino และเชื่อมต่อกับวงจรปิดการทำงานของระบบแบบเรียลไทม์ และ Arduino ต่อกับเครื่องพ่นหมอก และเครื่องลดน้ำต้นไม้



ภาพที่ 1 สถาปัตยกรรมของระบบควบคุมโรงเรือนใบบวบกักตุนน้ำอัจฉริยะ

งานวิจัยนี้ ออกแบบ Use Case ของระบบ ตาม Use case คือ 1) Monitor เป็นส่วนที่แสดงผลของสถานะของ อุณหภูมิ ความชื้นความสว่างของแสง และสถานการณ์ทำงานของอุปกรณ์ต่าง ๆ ซึ่งเป็นการแสดงผลแบบ Real Time 2) การควบคุม อัตโนมัติ (Auto Control) เป็นการทำงานได้ด้วยตัวเอง โดยรับค่าจากเซ็นเซอร์และภาพที่ถ่ายมาประมวลผลรวมกันกับปัญญาประดิษฐ์ที่สร้างขึ้น เพื่อสั่งให้อุปกรณ์ต่าง ๆ ทำงาน 3) การควบคุมแมนนวล (Manual) เป็นการควบคุมโดยผู้ใช้งาน เช่น การเปิดหรือปิดระบบ ป้อนน้ำ และระบบหมอก

2. การพัฒนาปัญญาประดิษฐ์ในการจำแนกใบบวบโดยการเรียนรู้เชิงลึก

งานวิจัยนี้สร้างโมเดลปัญญาประดิษฐ์การเรียนรู้เชิงลึก (Deep learning) และโครงสร้างประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Network) หรือ โครงข่ายประสาทแบบคอนโวลูชัน เป็นโครงข่ายประสาทเทียมหนึ่งในกลุ่ม bio-inspired โดยที่ CNN จะจำลองการมองเห็นของมนุษย์ที่มองเห็นที่เป็นที่ย่อย ๆ และนำกลุ่มของพื้นที่ย่อย ๆ มาผสมกัน เพื่อดูว่าสิ่งที่เห็นอยู่เป็นอะไร (Phongchit, 2023) เพื่อทำนายลักษณะการเติบโตของใบบวบ เป็น 3 ระยะการเติบโต ขนาดเล็ก ขนาดกลาง และขนาดใหญ่ ผู้วิจัยเพื่อสกัดคุณลักษณะเฉพาะของข้อมูลรูปภาพ และใช้วิธีการเรียนรู้แบบถ่ายโอนซึ่งเป็นเทคนิคการเรียนรู้ของเครื่องด้วยการนำโครงสร้างของโมเดลที่ฝึกเรียบร้อยแล้วนำมาฝึกกับข้อมูลของงานวิจัยนี้ เพื่อให้ได้ผลลัพธ์ โดยมีขั้นตอนวิธีดำเนินการดังภาพที่ 2



ภาพที่ 2 ขั้นตอนการพัฒนาโมเดลจำแนกใบบวบ

การวิเคราะห์ข้อมูล

การศึกษางานวิจัยนี้เป็นการวิจัยเพื่อการจำแนกรูปภาพ ใบบัวบก โดย จำแนก ขนาดของใบบัวบก ขนาดเล็ก ขนาดกลาง และ ขนาดใหญ่ เพื่อใช้ในการควบคุมระบบการรดน้ำ ระบบหมอก ในโรงเรือน โดยใช้โครงสร้างประสาทเทียมแบบคอนโวลูชัน (Convolution neural network) ใช้เทคนิคการถ่ายโอน 3 โครงสร้าง (Transfer learning) ได้แก่ 1) โครงสร้างการถ่ายโอนโมเดล VGG16 โดยมีสถาปัตยกรรม ของ VGG 16 ลักษณะของมันก็จะประมาณนี้ เนื่องจากมี Hidden Layer 16 ชั้น จึงถูกเรียกว่า VGG 16 นั่นเอง จริง ๆ แล้วมี VGG 19 ด้วยนะ นั่นคือ มี Hidden Layer 19 ชั้น 2) โครงสร้างการถ่ายโอนโมเดล InceptionV3 มีสถาปัตยกรรม เป็น 5 ส่วนหลัก คือ Inception Module A, Grid Size of Reduction step 1, Inception Module B, Grid Size of Reduction Step2 และ Inception Module C ซึ่งแยก Output ได้ 1,000 Classes Inception V3 เป็นโมเดลที่ได้รับการพัฒนา โดย Google ซึ่งได้รับรางวัลรองชนะเลิศสำหรับ Image Classification ใน ILSVR 2015 (78.1% accuracy ใน ImageNet dataset) มีโครงสร้าง Deep Learning Network ทั้งหมด 42 Layers มีจำนวน Parameter ทั้งหมด 21 ล้าน Parameter 3) โครงสร้างสร้างการถ่ายโอนโมเดล ResNet50 มีสถาปัตยกรรม 4 ชั้นตอน ใหญ่ ๆ ชั้นตอนที่หนึ่ง เป็นแปลงข้อมูล โดยใช้วิธีการทำ Convolution (7*7) และ MaxPooling (3*3) ชั้นตอนที่สองและสาม เป็นการทำ Convolution ในระยะต่อ ๆ ไป โดย Skip Connections นั้นจะเกิดขึ้นในทุก ๆ 3 Block ตั้งแต่ Conv2.x ไปจนถึง Conv5.x โดยแต่ละ Layer Stage นั้น ตัวของ Output Size จะมีขนาดที่ลดลงครึ่งหนึ่ง จาก Layer Stage ก่อนหน้า ในขณะที่ชั้นตอนที่สี่จะใช้การ Average Pooling โดยมี Softmax Activation Function ทำหน้าที่ Classify ตัว Final Output วิธีการและขั้นตอนในการดำเนินการวิจัยดังนี้

ขั้นตอนที่ 1 การรวบรวมข้อมูล

ผู้วิจัยเก็บรวบรวมภาพถ่ายใบบัวบกจากเว็บไซต์ และถ่ายรูปลูกใบบัวบกในโรงเรือนด้วยตัวเอง โดยเป็นภาพ ใบบัวบก ขนาดใบเล็ก ขนาดใบกลาง และ ขนาดใบใหญ่พร้อมเก็บเกี่ยว ทำความสะอาดข้อมูลโดยการลบภาพที่ไม่ชัดเจน จากนั้นสร้าง Dataset เป็น train test และ validation อย่างละโฟลเดอร์ ภายในแต่ละ โฟลเดอร์ small Size, Medium Size และ Large Size โดยวัดจากเส้นผ่านศูนย์กลางของใบบัวบก จากพันธุ์นครปฐม โดยจำนวนรูปภาพสรุปได้ดังตารางที่ 1 และตัวอย่างภาพใน Data Set ดังภาพที่ 3

ตารางที่ 1 จำนวนภาพการฝึก (train) การทดสอบ (test) และ การยืนยันการใช้งาน (validation) จำแนกตามคลาส

Class	Train Dataset (จำนวนรูป)	Train Dataset (จำนวนรูป)	Validation Dataset (จำนวนรูป)
Small Size (ขนาด 1-2 ซม)	678	185	100
Medium Size (ขนาด 3-5 ซม)	648	170	100
Large Size (ขนาด 6-7 ซม)	715	274	100
รวม	2041 (69.75%)	629 (21.49%)	300 (10%)

ภาพที่ 3 ตัวอย่างข้อมูลสอนของใบบัวบก



ขั้นตอนที่ 2 การเตรียมข้อมูล (Data preprocessing)

ขั้นตอนการเตรียมข้อมูลจากที่ได้เก็บข้อมูลและแยกโพลเดอร์ train, test และ validation แล้วทำการเตรียมข้อมูลโดย ปรับขนาดรูปภาพ (Target size) ให้มีขนาด 280x280 พิกเซล ในขั้นตอนต่อไปปรับเพิ่มคุณภาพรูปภาพเพื่อเพิ่มประสิทธิภาพของชุดข้อมูลฝึกโดยใช้ โดยใช้ฟังก์ชัน Image data generator ข้อมูลไปตัดแปลงข้อมูลต้นฉบับ (Data augmentation) ดังนี้ นำภาพหมุน 45 องศา ขยายภาพ 20% นำภาพเลื่อนภาพ 20% เงือนภาพ 20% ปรับระดับความสว่าง 20% จะนำข้อมูลไปสกัดคุณลักษณะ (Feature extraction) ต่อไป

ขั้นตอนที่ 3 การสกัดคุณลักษณะ (Feature extraction)

งานวิจัยนี้เลือกใช้การเรียนรู้แบบถ่ายโอน (Transfer Learning) ทั้ง 3 โมเดลเป็นโครงสร้างประสาทเทียมแบบคอนโวลูชัน (Convolution neural network) ได้แก่ VGG16, Resnet50, InceptionV3 ซึ่งใช้ weight ข้อมูลจาก ImageNet (ธนช เบญจอนูอาชา, 2564)


ขั้นตอนที่ 4 ขั้นตอนการจำแนกประเภท (Classification)

เป็นขั้นตอนที่รับข้อมูลจากการสกัดคุณลักษณะ (Feature extraction) ซึ่งเป็นโครงสร้างคอนโวลูชัน (Convolution network) ส่วนนี้จะไม่มีการฝึก ยังใช้ค่า weight ข้อมูลจากฐานข้อมูล ImageNet และใช้การเรียนรู้แบบถ่ายโอน (Transfer Learning) ส่งคุณลักษณะ (Feature extraction) มายังส่วนการจำแนกประเภท (Classification) ซึ่งจะประกอบด้วย 2 ส่วนคือ base model และ head model เดิมมีคำสั่งที่ใช้ในการโหลด base model inceptionV3 เข้ามาใช้งานดังนี้ กรณีเปลี่ยน head model ให้เปลี่ยน include top จาก true โดยผู้วิจัยได้ให้โมเดลได้เรียนรู้ส่วน Custom final layers จากตัวอย่างที่เตรียม

ขั้นตอนที่ 5 การทำ Fine tune

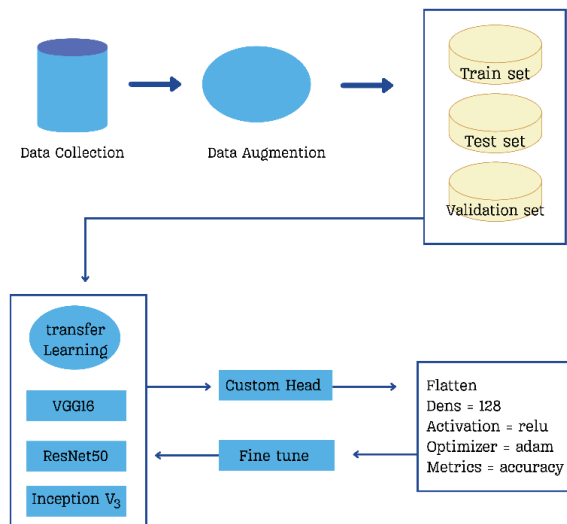
ในขั้นตอนนี้หลังจากได้ผลลัพธ์ทุกโมเดลแล้ว ผู้วิจัยได้ทำ fine tune เพื่อทดลองปรับประสิทธิภาพโมเดลโดยนำข้อมูล (data set) เข้าไปสอนใช้ชั้นท้าย ๆ ของ Convolution network ทั้ง 3 โมเดล ส่วนดังภาพที่ 4 custom head และทำการ flatten โดยเพิ่มชั้น Dense 128 โดยใช้ activation = relu และกำหนดชั้นสุดท้ายเป็น dense 3 เพื่อกำหนด output และ compile model โดยใช้ optimizer= adam และ batch size = 64 ฝึกแต่ละรอบโดยใช้ metrics = accuracy และ learning rate ที่ 0.001 และ ทำการฝึก 50 epochs

ภาพที่ 4 ขั้นตอน Fine tune (Ruman, 2023)



ขั้นตอนการวิจัยสรุปดังภาพที่ 5 ซึ่งหลังจากขั้นตอนที่ 4 การจำแนกประเภท(Classification) แล้ว วัดผล ประสิทธิภาพแต่ละโมเดลหลังจากนั้นดำเนินการ Fine Tuning ในขั้นตอนที่ 5 เพื่อปรับปรุงประสิทธิภาพของโมเดล

ภาพที่ 5 ขั้นตอนการสร้างโมเดลและปรับปรุง



สรุปผลการวิจัย


การวิจัยเรื่อง การพัฒนาระบบควบคุมโรงเรือนใบบัวบกอัตโนมัติโดยใช้เทคโนโลยี IoT และการจำแนกใบ บัวบกโดยการเรียนรู้เชิงลึก คณะผู้วิจัยได้นำเสนอผลการวิจัย ซึ่งแบ่งออกเป็น 2 ตอนดังนี้

1. เพื่อออกแบบและพัฒนาระบบควบคุมโรงเรือนใบบัวบกอัตโนมัติโดยใช้เทคโนโลยี IoT

ผลการออกแบบระบบควบคุม การปลูกใบบัวบกด้วย อินเทอร์เน็ตเพื่อทุกสรรพสิ่งแสดงข้อมูลจากเซ็นเซอร์ และควบคุมโรงเรือนโดยกำหนด เปิด ปิด บำบัดน้ำ ระบบหมอก และควบคุมผ่านโมเดลปัญญาประดิษฐ์ที่พัฒนาขึ้น

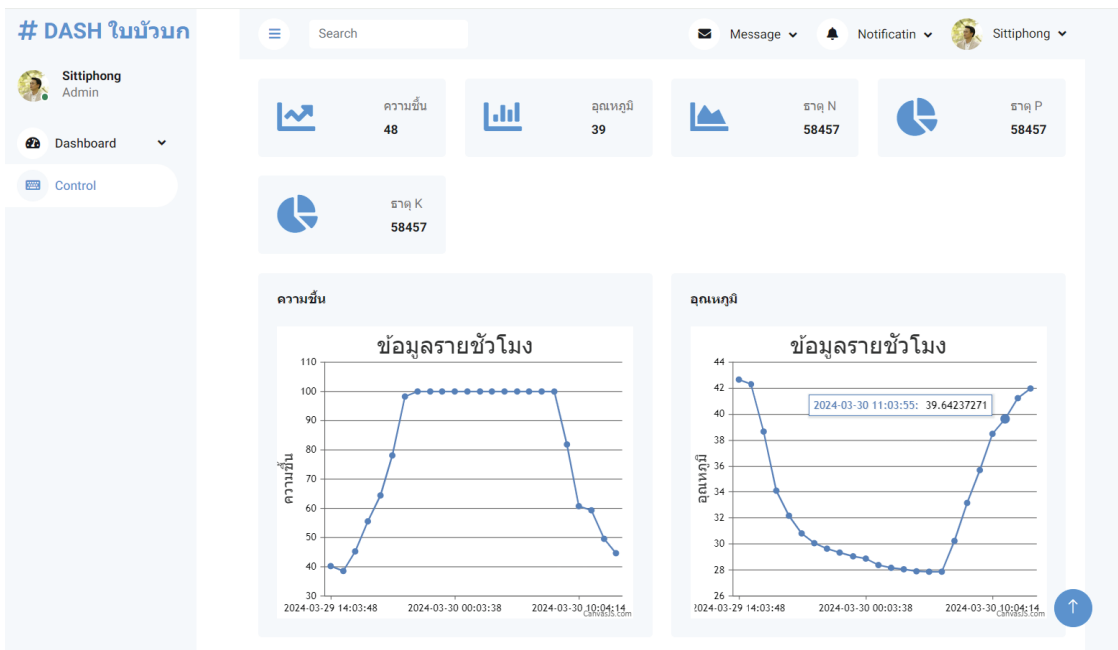
1) โดยขนาดโรงเรือน ขนาด 4 x 12 เมตร มีความสูงรวมถึงยอดโดมประมาณ 4 เมตร ชุดเซนเซอร์ ที่วัดในโรงเรือน ประกอบด้วยเซนเซอร์วัดแสงความเข้มแสง Ambient Light lux Sensor(BH1750FVI) จำนวน 3 ชุด, เซนเซอร์วัดอุณหภูมิและความชื้น(AM2302) จำนวน 3 ชุด,เซนเซอร์วัดอุณหภูมิและความชื้น Capacitive Soil Moisture Sensor V1.2 จำนวน 3 ชุด,เซนเซอร์ Soil N-P-K Modbus RTU จำนวน 3 ชุด วัดความถี่ ทุก 1 นาที วัด ทั้งหมด 3 จุด ดังภาพที่ 6

ภาพที่ 6 ระบบควบคุมพร้อมเซ็นเซอร์ในโรงเรือน

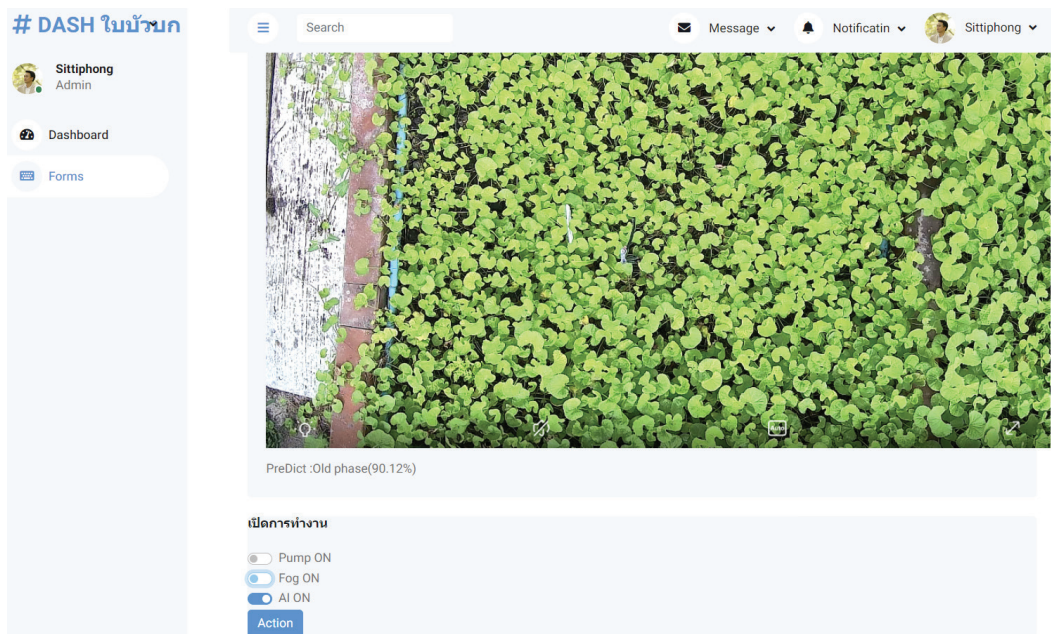


2) ระบบที่พัฒนาขึ้นเชื่อมต่อกับ NetPie server เชื่อมต่อสื่อสารในรูปแบบอินเทอร์เน็ตเพื่อทุกสรรพสิ่ง ซึ่งพัฒนาโดยศูนย์อิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ (NECTEC) และผู้วิจัยได้ทำการดึงข้อมูลจาก NetPie server มาแสดงที่ AI server ดังภาพที่ 7 และภาพที่ 8 AI server ทำงานร่วมกับ Xiaomi Camera Server นำภาพจากใบบวบกในโรงเรือน ให้โมเดลปัญญาประดิษฐ์ที่ผู้วิจัยพัฒนาขึ้น พยากรณ์ภาพใบบวบก ขนาดใบเล็ก ใบกลาง และใบใหญ่ เพื่อกำหนด Profile ในการกำหนดอุณหภูมิ ความชื้นที่เหมาะสมกับใบบวบก โดยสามารถกำหนดการทำงานให้อัตโนมัติ หรือผู้ใช้สามารถสั่งการควบคุมปั้มน้ำและระบบหมอก เมื่ออุณหภูมิภายในโรงเรือนสูงกว่ากำหนด จะทำการสั่งให้ระบบหมอกทำงาน หรือเมื่อความชื้นในดินต่ำกว่า จะทำการสั่งให้ระบบปั้มน้ำทำงาน

ภาพที่ 7 สถานะข้อมูลของโรงเรือน



ภาพที่ 8 กำหนดการทำงานของระบบโรงเรือนใบบวบก



ผู้วิจัยได้ติดตั้งระบบและทดลองใช้ในแปลงบัวบกของเกษตรกร หลังจากนั้นได้ทำแบบทดสอบความพึงพอใจของเกษตรกรผู้ใช้งาน จำนวน 20 คน โดยใช้แบบสอบถามความพึงพอใจที่พัฒนาขึ้น โดยมีกรอบการประเมิน 2 ด้าน ได้แก่ ความพึงพอใจด้านความถูกต้องและตรงตามความต้องการของผู้ใช้งานโรงเรียน (Functional Requirement Test) และ ความพึงพอใจด้านการทำงานของระบบโรงเรียน (Functional Test) (อุไร ทองหัวไม้, 2558) ดังแสดงรายละเอียดในตารางที่ 2

ตารางที่ 2 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานความพึงพอใจของผู้ใช้โรงเรียน

ความพึงพอใจของผู้ใช้โรงเรียน	\bar{x}	S	ผลการประเมิน
1. ความพึงพอใจด้านความถูกต้องและตรงตามความต้องการของผู้ใช้งานโรงเรียน (Functional Requirement Test)			
1.1 ความถูกต้องของการรดน้ำและระบบหมอกในโรงเรียน	4.05	.73	พึงพอใจมาก
1.2 ความถูกต้องของข้อมูลเซนเซอร์ในโรงเรียนผ่านเว็บไซต์	4.18	.12	พึงพอใจมาก
1.3 ความถูกต้องของการรดน้ำและระบบหมอกผ่านเว็บไซต์	4.20	.36	พึงพอใจมาก
1.4 ความถูกต้องของการรดน้ำและระบบหมอกผ่านปัญญาประดิษฐ์	4.05	.84	พึงพอใจมาก
1.5 พีเจอร์ที่มีอยู่ในซอฟต์แวร์ตอบสนองความต้องการ	4.40	.76	พึงพอใจมาก
เฉลี่ย	4.18	.56	พึงพอใจมาก
2. ความพึงพอใจด้านการทำงานของระบบโรงเรียน (Functional Test)			
2.1 ความทนทานของเซนเซอร์ในโรงเรียน	3.98	.79	พึงพอใจมาก

ตารางที่ 2 ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐานความพึงพอใจของผู้ใช้โรงเรียน (ต่อ)

ความพึงพอใจของผู้ใช้โรงเรียน	\bar{x}	S	ผลการประเมิน
2.2 ความเสถียรของซอฟต์แวร์ในโรงเรียน	4.10	.85	พึงพอใจมาก
2.3 ความรวดเร็วของซอฟต์แวร์ในโรงเรียน	4.15	.05	พึงพอใจมาก
2.4 ความง่ายในการตั้งค่าและติดตั้งระบบ	4.06	.82	พึงพอใจมาก
2.5 ความรวดเร็วของระบบในการตอบสนองต่อคำสั่งและการแจ้งเตือน	4.21	.64	พึงพอใจมาก
2.6 ความรวดเร็วของระบบในการตอบสนองต่อคำสั่งและการแจ้งเตือน	4.05	.96	พึงพอใจมาก
2.7 เป็นประโยชน์ของรายงานและการวิเคราะห์ที่ระบบให้	4.10	.75	พึงพอใจมาก
2.8 การเปลี่ยนแปลงในด้านการจัดการและผลผลิตหลังจากใช้ระบบ	4.20	.74	พึงพอใจมาก
2.9 ความคุ้มค่าในการลงทุนในโรงเรียนในการประหยัดน้ำ	4.50	.94	พึงพอใจมาก
เฉลี่ย	4.15	.84	พึงพอใจมาก
โดยรวม	4.16	.74	พึงพอใจมาก

จากตารางที่ 2 พบว่า ความพึงพอใจของเกษตรกรผู้ใช้งานที่มีต่อระบบควบคุมโรงเรือนใบบัวบกอัตโนมัติ โดยใช้เทคโนโลยี IoT โดยรวมอยู่ในระดับพึงพอใจมาก ($\bar{x} = 4.16$, S.D. = 0.74) เมื่อพิจารณาทางด้านพบว่า ความพึงพอใจด้านความถูกต้องและตรงตามความต้องการของผู้ใช้งานโรงเรียน (Functional Requirement Test) อยู่ในระดับพึงพอใจมาก ($\bar{x} = 4.18$, S.D. = 0.56) และด้านความพึงพอใจด้านการทำงานของระบบโรงเรือน (Functional Test) อยู่ในระดับพึงพอใจมาก ($\bar{x} = 4.15$, S.D. = 0.84)

2. ผลการทำงานปัญญาประดิษฐ์ในการจำแนกใบบัวบกโดยการเรียนรู้เชิงลึก

จากการทดลองเทรนโมเดลทั้งสิ้น 3 โมเดล และทำการเปรียบเทียบผลลัพธ์ประสิทธิภาพโมเดล ได้ผลการทดลองดังต่อไปนี้

ผลเปรียบเทียบผลลัพธ์ประสิทธิภาพของแต่ละโมเดล

จากตารางที่ 3 นั้นได้แสดงให้เห็นว่า โมเดล VGG16 มีประสิทธิภาพที่ดีที่สุดสำหรับข้อมูลชุดนี้ และรองลงมาคือ InceptionV3 และ Resnet50 ตามลำดับ โดยมี accuracy 0.80 0.75 และ 0.62 ตามลำดับ โดยทุกโมเดลกำหนดรอบการเรียนรู้ที่ 50 รอบ (epoch)

ตารางที่ 3 เปรียบเทียบผลลัพธ์ประสิทธิภาพของแต่ละโมเดล

Model	Accuracy	Precision	Recall	Epoch
VGG16	0.80	0.80	0.80	50
InceptionV3	0.75	0.76	0.75	50
Resnet50	0.62	0.63	0.62	50


ผลเปรียบเทียบผลลัพธ์ประสิทธิภาพของแต่ละโมเดลหลังจากการทำลอง fine tune

ผลการทดลอง fine tune โดยใช้คำสั่ง Early Stopping ให้สิ้นสุดการฝึก โดยกำหนดที่ค่า loss หาก loss ไม่เปลี่ยนแปลง 2 epoch โมเดลจะหยุดการฝึกลง จากตารางที่ 3 นั้นได้แสดงให้เห็นว่า โมเดล VGG16 จำนวน 26 epoch มีประสิทธิภาพดีที่สุดสำหรับข้อมูลชุดนี้ และรองลงมาคือ InceptionV3 จำนวน 48 epoch และ Resnet50 จำนวน 13 epoch โดยมี accuracy 0.82 0.73 และ 0.60 ตามลำดับ ดังตารางที่ 4


ตารางที่ 4 เปรียบเทียบผลลัพธ์ประสิทธิภาพของแต่ละโมเดล

Model	Accuracy	Precision	Recall	Epoch
VGG16	0.82	0.82	0.82	26
InceptionV3	0.73	0.74	0.73	48
Resnet50	0.60	0.61	0.60	13


ผลลัพธ์ confusion matrix ในแต่ละโมเดลแสดงในภาพที่ 9 ดังนี้
VGG16 82%



InceptionV3 73%





ResNet50 60%





ภาพที่ 9 confusion matrix ทั้งสามโมดูล


VGG16



InceptionV3



ResNet50



ภาพที่ 10 ความสัมพันธ์ระหว่าง accuracy และ loss กับ epochs ของโมเดล fine tune ทั้ง 3 โมเดล

อภิปรายผลการวิจัย

งานวิจัยการพัฒนากระบวนการควบคุมโรงเรือนใบข้าวบักอ้อมมิติโดยใช้เทคโนโลยี IoT และการจำแนกใบข้าวบัก โดยการเรียนรู้เชิงลึกสามารถนำไปใช้ประโยชน์ในการปลูกใบข้าวบัก สามารถดูข้อมูลจากโรงเรือน ผ่านเซ็นเซอร์ อุณหภูมิ และความชื้นในดินและอากาศ และธาตุ N P K สามารถกำหนด เปิด ปิด ป้อนน้ำ ระบบหมอก และควบคุมผ่านโมเดล ปัญญาประดิษฐ์ งานวิจัยที่เกี่ยวข้องในด้านฮาร์ดแวร์ โดยเลือกใช้เทคโนโลยีอินเทอร์เน็ตเพื่อทุกสรรพสิ่งสอดคล้องกับ งานวิจัยของ (รัตติกานต์ วิบูลย์พานิช, 2560) โมดูลควบคุมการให้น้ำโดยใช้ปั้มน้ำ เป็นส่วนงานที่ทำงานโดยอัตโนมัติ ผ่านระบบคลาวด์ สามารถใช้ในการปลูกพืชได้ดี ผู้ใช้ประเมินความพึงพอใจ เหมาะสมอยู่ในระดับพึงพอใจมาก ($\bar{x} = 4.16$, S.D. = 0.74)

ผลการออกแบบปัญญาประดิษฐ์ในการจำแนกใบข้าวบักโดยการเรียนรู้เชิงลึก สอดคล้องกับงานวิจัยของ (รัฐศิลป์ รานอกภานุวัชร, 2561) มีการสร้างการเรียนรู้เครื่องเชิงลึกหรือที่เรียกว่า Deep learning เพื่อช่วยวิเคราะห์ การเจริญเติบโตของต้นผัก โดยใช้การเรียนรู้ของเครื่องประเภท Convolutional Neural Network (CNNs) ซึ่งจะมีส่วน Convolutional Layer เพิ่มขึ้นเป็นส่วนที่ใช้สกัดลักษณะสำคัญของภาพออกจากรูปภาพผักออกมาได้ และปัจจุบันนิยมใช้สำหรับงานที่ไม่ต้องการความซับซ้อนมากนัก สอดคล้องกับงานของ Madhav (2019) พัฒนาการเรียนรู้ของเครื่องใช้วิธี SVN&ANN โดยใช้ในการควบคุมน้ำ ผู้วิจัยได้ทำการปรับปรุงโมเดลการเรียนรู้เชิงลึก (Fine tune) เพื่อให้สามารถทำงานได้ถูกต้องมากขึ้น โดยโมเดล VGG16 มีความถูกต้องมากที่สุด สอดคล้องกับงานของ (ธนัช เบญจอนุชา, 2564) ได้ทำการพัฒนาการจำแนกความเสียหายรถยนต์โดยการเรียนรู้เชิงลึก โดยใช้ Knowledge transfer จาก 3 โมเดล คือ VGG16 InceptionV3 และ ResNet50 และทำ Fine tune พบว่าความถูกต้องของโมเดล สูงขึ้น โดยโมเดล VGG16 มีประสิทธิภาพมากที่สุด วัดค่าความแม่นยำ (Accuracy) เท่ากับ 0.83 ตามมาด้วยโมเดล InceptionV3 เท่ากับ 0.81 และ ResNet50 เท่ากับ 0.68 ตามลำดับ

ข้อเสนอแนะ

จากผลการวิจัย การพัฒนากระบวนการควบคุมโรงเรือนใบข้าวบักอ้อมมิติโดยใช้เทคโนโลยี IoT และการจำแนก ใบข้าวบักโดยการเรียนรู้เชิงลึกมีข้อเสนอแนะงานวิจัยดังนี้

1. ควรปรับปรุงโรงเรียนให้มีเซนเซอร์ วัดค่าอื่น ๆ และศึกษาส่งผลต่อการเติบโตของใบบักบกและสารสำคัญของใบบักบก
2. ควรทดลองพัฒนาโมเดลปัญญาประดิษฐ์ไปใช้ในการปลูกพืชชนิดอื่น ๆ และศึกษาผลต่อการเติบโตของใบบักบก
3. ควรทดลองเปรียบเทียบกับวิธีรดน้ำธรรมดากับการใช้เทคโนโลยี IoT เพื่อดูว่าวิธีใดง่ายกว่า เหมาะสมกว่า ประหยัดกว่า และ เปรียบเทียบการเจริญเติบโตของใบบักบกด้วย

กิตติกรรมประกาศ

รายงานวิจัยฉบับนี้ได้รับทุนสนับสนุนจาก สำนักงานพัฒนาการวิจัยการเกษตร (สวก) ประจำปีงบประมาณ 2566 คณะผู้วิจัยขอขอบคุณสำนักงานพัฒนาการวิจัยการเกษตร ที่ได้ส่งเสริมและสนับสนุนการทำวิจัย ที่ได้ให้คำแนะนำ คำปรึกษา ข้อเสนอแนะ และให้ข้อมูลที่เป็นประโยชน์ต่อการพัฒนามาระบบควบคุมโรงเรือนใบบักบกอัตโนมัติโดยใช้เทคโนโลยี IoT และการจำแนกใบบักบกโดยการเรียนรู้เชิงลึกเป็นอย่างดี ตลอดจนอำนวยความสะดวกให้ในทุกด้าน จนทำให้งานวิจัยครั้งนี้สำเร็จลุล่วงได้เป็นอย่างดี

เอกสารอ้างอิง

- ธนัช เบญจอนุอาษา. การจำแนกความเสียหายรถยนต์โดยการเรียนรู้เชิงลึก. กรุงเทพฯ: บัณฑิตวิทยาลัย มหาวิทยาลัย ศรีนครินทรวิโรฒ, 2564.
- นันทวัน บุญยะประภัสร์. สมุนไพรไม้พื้นบ้าน. กรุงเทพฯ: ประชาชน, 2542.
- บุษบา บัวคำ และรักเกียรติ แสนประเสริฐ. 2560. “การเปรียบเทียบการเจริญเติบโตและผลผลิตบักบก (*Centella asiatica* (L.) Urb.) ที่ปลูกโดยใช้ปุ๋ยเคมีและปุ๋ยอินทรีย์,” วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัย อุบลราชธานี. 19, 1 (มกราคม-เมษายน 2560): 101-110.
- รักษ์ พงษ์ชาติ. “บักบก ปลูกในนาที่นครศรีธรรมราช” ในผักพื้นบ้านคู่มือการปลูกเชิงการค้า. กรุงเทพฯ : นีออน บั๊กมีเดีย, 2550.
- รัฐศิลป์ รานอกภาณุวัชร. ระบบควบคุมโรงเรือนผักไฮโดรโปนิกส์อัตโนมัติโดยใช้เทคโนโลยี IoT และเครื่องมือ การเรียนรู้เชิงลึก. กรุงเทพฯ: วิทยาลัยนวัตกรรมการด้านเทคโนโลยีและวิศวกรรมศาสตร์ มหาวิทยาลัยธุรกิจ บัณฑิตย, 2561.
- รัตติกานต์ วิบูลย์พานิช. การออกแบบตัวต้นแบบระบบโรงเรือนอัจฉริยะเพื่อส่งเสริมความสะดวกรสบายให้กับ ผู้สูงอายุโดยใช้เทคโนโลยีอินเทอร์เน็ตเพื่อทุกสรรพสิ่ง. กรุงเทพฯ: มหาวิทยาลัยนอร์ทกรุงเทพ, 2560.
- อุไร ทองหัวไม้. “การทดสอบซอฟต์แวร์,” วารสารเกษมบัณฑิต. 16, 2 (กรกฎาคม 2558): 140-154.
- Lela, Madhav K. Machine Learning Approach for Agriculture IoT using SVM&ANN. *International Journal of Engineering Research & Technology*. 2019.
- Phongchit, Natthawat. Convolutional Neural Network (CNN) คืออะไร. (ออนไลน์) 2023 (อ้างเมื่อ 15 เมษายน 2567). จาก <https://medium.com/@natthawatphongchit>
- Kendal, Kenneth E. *Systems Analysis and Design*. New Jersey: Prentice Hall, 2020.