

ระบบต้นแบบเพื่อตรวจจับหอยทากบกในแปลงผักทดลอง
โดยใช้การเรียนรู้เชิงลึกโมเดล YOLOv10-X
A Prototype System for Detecting Land Snails in Experimental
Vegetable Plot Using YOLOv10-X Deep Learning Model

อนุมัติ กลิ่นอัม และ วไลลักษณ์ วงษ์รินทร์*

Anumat Klinom and Walailuck Wongruen*

ภาควิชาวิทยาการคอมพิวเตอร์และสารสนเทศ คณะวิทยาศาสตร์และวิศวกรรมศาสตร์

มหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตเฉลิมพระเกียรติ จ.สกลนคร ประเทศไทย

Department of Computer and Information Science, Faculty of Science and Engineering,

Kasetsart University, Chalermphrakiat Sakon Nakhon Province Campus, Sakon Nakhon, Thailand

วันที่ส่งบทความ : 1 เมษายน 2568 วันที่แก้ไขบทความ : 26 พฤษภาคม 2569 วันที่ตอบรับบทความ : 27 พฤษภาคม 2569

Received: 1 April 2025, Revised: 26 May 2026, Accepted: 27 May 2026

บทคัดย่อ

บทความนี้นำเสนอระบบต้นแบบเพื่อตรวจจับหอยทากบกในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึก (Deep learning) ด้วยแบบจำลอง YOLOv10-X ในระบบนี้มีการใช้อินเทอร์เน็ตประสานสรรพสิ่ง (Internet of Things: IoT) ทำงานร่วมกันกับเทคนิคคอมพิวเตอร์วิทัศน์ (Computer vision techniques) และแบบจำลองการเรียนรู้เชิงลึก YOLOv10-X โดยผู้ใช้สามารถดูผลการตรวจจับหอยทากบกแบบเรียลไทม์ (Real-time) อีกทั้งสามารถรายงานการตรวจจับหอยทากบกผ่านแอปพลิเคชัน (Mobile application) และรับการแจ้งเตือนการตรวจจับหอยทากบกผ่านแอปพลิเคชันไลน์ (Line application) ได้ สายพันธุ์หอยทากบกที่ใช้ในงานนี้ คือ หอยทากยักษ์แอฟริกันและหอยทากสยาม จากการสุ่มทดสอบค่าความถูกต้องการตรวจจับในวิดีโอเฟรมจำนวน 100 เฟรมภาพ พบว่า ระบบให้ค่าความถูกต้อง (Accuracy) ในการตรวจจับหอยทากยักษ์แอฟริกันเท่ากับ 74.15% หอยทากสยามเท่ากับ 64.08% และค่าความแม่นยำเฉลี่ย (mAP) ของทั้ง 2 คลาสเท่ากับ 97.31%

คำสำคัญ : หอยทากบก การตรวจจับ การเรียนรู้เชิงลึก YOLOv10-X อินเทอร์เน็ตประสานสรรพสิ่ง

Abstract

This paper presents a prototype system for detecting land snails in an experimental vegetable plot using YOLOv10-X Deep learning model. In this proposed system, (Internet of

*ที่อยู่ติดต่อ E-mail address: walailuck.w@ku.th

<https://doi.org/10.55003/scikmitl.2026.266951>

Things) devices were used in conjunction with computer vision techniques and YOLOv10-X Deep Learning model. Users can view the results of land snail detection in real time, view land snail detection reports via mobile application, and receive land snail detection notifications via the LINE application. The land snail species used in this study were the African giant snail and the Siamese snail. From random testing of the detection accuracy in 100 video image frames, it was found that the proposed system gave an accuracy of 74.15% for detecting African giant snails, 64.08 % for Siamese snails, and mean average precision (mAP) of both classes was 97.31%.

Keywords: Land snails, Detection, Deep learning, YOLOv10-X, Internet of Things

1. บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

หอยทากบก (Land snails) ที่พบในประเทศไทยมีอยู่หลากหลายชนิด แต่ละชนิดจะมีสี ขนาด ลวดลาย รูปทรง และพฤติกรรมการกินอาหารที่หลากหลาย (Panha et al., 2009; Sutcharit & Panha, 2008) หอยทากบกบางชนิดสามารถนำมารับประทานได้ ตัวอย่างเช่น หอยหอมหรือหอยดง (*Cyclophorus fulguratus* หรือ Cyclophorid snail) (Kongim, 2008) แต่บางชนิดถูกจัดอยู่ในกลุ่มของหอยทากศัตรูพืช (Kongim, 2008) เช่น หอยทากยักษ์แอฟริกันหรือหอยลาย (*Achatina fulica* หรือ Giant African snail) หอยทากสยามหรือหอยดักดาน (*Cryptozonia siamensis* หรือ Pfeiffer) หอยเล็บหรือหอยอัมพันหรือ หอยซัคซีเนีย (*Succinea* spp. หรือ Amber snails) เป็นต้น ซึ่งเป็นหอยทากบกที่สามารถพบได้ในหลาย พื้นที่ของประเทศไทย (Sutcharit & Panha, 2008) โดยหอยทากบกในกลุ่มนี้จะเข้าทำลายโดยการกัดกิน ส่วนต่าง ๆ ของพืชผักหลายชนิด นอกจากนี้ยังมีรายงานว่าหอยทากบกบางชนิดเป็นพาหะของพยาธิบาง ประเภท เช่น พยาธิตัวกลมและพยาธิใบไม้ เป็นต้น (Kongim, 2008) เมื่อหอยเหล่านี้เคลื่อนที่ไปตามส่วนต่าง ๆ ของพืช มันอาจจะถ่ายมูลหรือทิ้งเมือกไว้ตามส่วนต่าง ๆ ของพืชที่มันเคลื่อนผ่าน และอาจพบว่ามี พยาธิหรือไข่พยาธิอยู่ในมูลหรือเมือกของหอย ในกรณีที่น่าส่วนต่าง ๆ ของพืชที่มีมูลหรือเมือกหอยมา บริโภคโดยไม่ได้ล้างทำความสะอาดอย่างเพียงพอ อาจจะทำให้ตัวพยาธิหรือไข่พยาธิเข้าสู่ร่างกายของ ผู้บริโภคและก่อให้เกิดอาการเจ็บป่วยได้ (Siriwechviriya, 2020; Dumidae et al., 2020)

ชนิดของหอยทากบกได้ถูกจำแนกตามลักษณะปรากฏภายนอก เช่น ขนาด รูปทรง ลวดลาย สี ขน และรูปแบบการเวียนของเปลือกหอย การมีฝาปิดเปลือก ก้นบุ่ม จำนวนหนวด ฯลฯ และลักษณะภายใน เช่น มีปอด โครงสร้างของระบบสืบพันธุ์ และอวัยวะที่ใช้ในการหายใจ เป็นต้น (Sutcharit & Panha, 2008)

หอยทากบกสามารถขยายพันธุ์และแพร่กระจายได้อย่างรวดเร็ว (Rintarak et al., 2017) สามารถ จำศีลได้ในฤดูแล้ง และเมื่อสภาพแวดล้อมเหมาะสม เช่น ช่วงที่ฝนตก อากาศชื้น หอยจะออกจากการจำศีล เพื่อหากิน (Panha et al., 2009) จากการที่ผู้วิจัยได้ติดตามและสังเกตพฤติกรรมของหอยทากยักษ์แอฟริ กันและหอยทากสยาม ที่แม้ว่าจะอยู่ในช่วงฤดูแล้ง หากหอยเหล่านี้อาศัยอยู่ในบริเวณที่มีแหล่งอาหารอุดม

สมบูรณ์ที่มีสภาพอากาศ ความชื้น และอุณหภูมิที่เหมาะสม เช่น ในแปลงผัก ในสวน แหล่งน้ำ ฯลฯ ก็สามารถพบเจอหอยทากบกในเวลากลางคืนได้ ดังแสดงในรูปที่ 1



(ก)



(ข)

รูปที่ 1. หอยทากบกที่ถูกรู้พบในแปลงผัก : (ก) หอยทากยักษ์แอฟริกันที่ยังไม่โตเต็มวัย (ข) หอยทากสยาม

หมายเหตุ: ภาพนี้ถูกถ่ายในเวลากลางคืนที่ไม่มีฝนตก ในบริเวณแปลงผักที่ถูกรดน้ำเข้าเย็นสม่ำเสมอทุกวัน

ภาพถูกถ่ายเดือนมกราคม พ.ศ. 2567 โดยใช้กล้องสมาร์ตโฟน (Smartphone) และเปิดแฟลช (Flash) ในการถ่ายภาพ

การเฝ้าระวัง ค้นหา และติดตามหอยทากบกศัตรูพืชเป็นงานที่ต้องใช้แรงงานและเวลา เนื่องจากในเวลากลางวันจะค้นหาตัวหอยทากบกได้ยาก เพราะหอยทากบกจะซ่อนตัวอยู่บริเวณที่ร่มหรือบริเวณมีความชื้น เช่น ใต้ใบไม้ กอไม้ ซอกต้นไม้ กองพืชหรือเศษไม้ที่ทับถมกัน ใต้ดิน โปรง และซอกหิน เป็นต้น เมื่อถึงเวลากลางคืนหอยทากบกจึงออกมาหากิน (Kongim, 2008) นอกจากนี้ สีและลวดลายของเปลือกหอยจะกลมกลืนไปกับสีดิน ทราาย ใบไม้ ลำต้นพืช วัชพืช และเศษไม้ที่อยู่ในแปลงผัก ที่ทำให้ยากต่อการค้นหาตัวหอย หากเกษตรกรหรือผู้เพาะปลูกตรวจพบและกำจัดหอยทากบกศัตรูพืชได้ช้าเกินไป หอยเหล่านั้นอาจจะสร้างความเสียหายให้กับพืชผักหรือผลิตผลทางการเกษตรอย่างมาก โดยเฉพาะอย่างยิ่งกับหอยทากยักษ์แอฟริกันที่ถูกจัดว่าเป็นศัตรูที่สำคัญของเกษตรกร ซึ่งในหลายประเทศถือว่าเป็นชนิดพันธุ์รุกราน (Invasive species) โดยมันจะกัดกินยอด ใบ ดอก ผล ต้นอ่อนของพืช รวมถึงมีความสามารถในการปรับตัวและอาศัยอยู่ในสภาพแวดล้อมที่หลากหลายได้ (Panha et al., 2009; Rintarak et al., 2017)

กรณีตัวอย่างของการรุกรานและสร้างความเสียหายของหอยทากบก ได้แก่ หอยทากยักษ์แอฟริกันสร้างความเสียหายอย่างรุนแรงแก่ต้นและผลมะละกอในรัฐฮาวาย ประเทศสหรัฐอเมริกา (Nelson, 2012) หลายรัฐในประเทศอินเดียได้รายงาน ว่า หอยทากยักษ์แอฟริกันสร้างความเสียหายต่อพืช ผัก ผลไม้ และดอกไม้หลายชนิด (Kumar, 2020)

จากปัญหาที่กล่าวมาข้างต้น ผู้วิจัยจึงมีแนวคิดในการนำเทคโนโลยีที่เกี่ยวข้องมาสร้างระบบต้นแบบที่ช่วยในการตรวจจับหอยทากบกในแปลงผักทดลอง โดยจำลองแปลงผักเพื่อให้สามารถติดตั้งอุปกรณ์อินเทอร์เน็ตประสาทรพสิ่ง (Internet of Things: IoT) ที่ทำงานร่วมกับเทคนิคคอมพิวเตอร์วิทัศน์ (Computer vision) และแบบจำลองการเรียนรู้เชิงลึก (Deep learning) โดยใช้ YOLOv10-X พร้อมทั้งพัฒนาโมบายล์แอปพลิเคชัน (Mobile application) เพื่ออำนวยความสะดวกในการตรวจสอบ ติดตามดูรายงานการตรวจจับ และรับการแจ้งเตือนการตรวจจับหอยทากบกผ่านแอปพลิเคชันไลน์ (Line) ของผู้ใช้ระบบที่นำเสนอจึงเป็นอีกวิธีการหนึ่งที่จะช่วยแจ้งให้ผู้เพาะปลูกหรือเกษตรกรทราบการบุกรุกของหอยทาก

บกศตรูพีซได้อย่างทันท่วงที เพื่อเร่งจัดการและควบคุมก่อนที่ผลผลิตทางการเกษตรจะเสียหายจนไม่สามารถแก้ไขได้

1.2 การทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้อง

1) การเรียนรู้เชิงลึก เป็นวิธีการที่ใช้โครงข่ายประสาทเทียมเชิงลึก (Deep neural network) หลายชั้น ที่ถูกนำไปใช้ในงานหลายด้าน เช่น การประมวลผลภาพและการจัดหมวดหมู่ข้อความ เป็นต้น โดยโมเดลที่ใช้ในการรู้จำวัตถุ (Object recognition) สามารถแบ่งได้เป็น 2 กลุ่ม ได้แก่ โมเดลที่ใช้โครงข่ายประสาทแบบคอนโวลูชัน (Convolutional Neural Networks: CNN) ที่ประมวลผล 2 ครั้ง (Two-stage detector) เช่น โมเดลในกลุ่ม Region-Based Convolutional Neural Networks (R-CNN) และโมเดลที่ใช้โครงข่ายประสาทแบบคอนโวลูชันที่ประมวลผล 1 ครั้ง (One-stage detector) เช่น โมเดลในกลุ่ม You Only Look Once (YOLO) (Poonkuntran et al., 2022)

2) โมเดล YOLO ถูกพัฒนาและปรับปรุงมาหลายเวอร์ชัน โดยเริ่มตั้งแต่ ค.ศ. 2016 ที่ได้มีการแนะนำ YOLOv1 และ YOLOv2 (หรือ YOLO9000) จากนั้นเป็นต้นมา โมเดล YOLO ได้ถูกพัฒนาและปรับปรุงประสิทธิภาพในการทำงานอย่างต่อเนื่อง (Hussain & Khanam, 2024) จนถึงปัจจุบัน

สถาปัตยกรรมของเครือข่ายโมเดล YOLO (YOLO network architecture) มีการปรับปรุงแนวคิดในการทำงานมาจากโมเดลกูเกิลเน็ต (GoogLeNet) ที่ใช้ในการจำแนกวัตถุในภาพ (Ansari, 2023) โดยโมเดล YOLO ถูกออกแบบมาให้มีการตรวจจับวัตถุ (Object detection) และจำแนกประเภทของวัตถุ (Object classification) ในการประมวลผลเพียงครั้งเดียว (Lu et al., 2020) ด้วยการทำงานตั้งแต่ต้นจนจบกระบวนการ (End-to-End) ในลักษณะนี้จึงทำให้โมเดล YOLO สามารถตรวจจับและระบุตำแหน่งของวัตถุในภาพและวิดีโอ (Video) ในแบบเรียลไทม์ได้อย่างรวดเร็วและมีประสิทธิภาพ

ขั้นตอนการตรวจจับวัตถุของโมเดล YOLO ถูกดำเนินการดังนี้ (Poonkuntran et al., 2022; Sikka, 2021)

- โหลดภาพหรือวิดีโอเฟรมที่เป็นภาพนิ่งแต่ละเฟรมภาพ ครั้งละ 1 ภาพ เข้าสู่การประมวลผล
- แบ่งภาพหรือเฟรมภาพเป็นกริดเซลล์ (Grid cell) ขนาด $S \times S$ โดยทั่วไป S มีค่าเท่ากับ 7 หรือ 13 ซึ่งขึ้นอยู่กับแต่ละเวอร์ชันของโมเดล YOLO (Sikka, 2021)

- ทำการตรวจจับวัตถุเมื่อกริดเซลล์ มีจุดศูนย์กลางของวัตถุอยู่ภายใน
- ทำนายคลาส (Class) ของวัตถุที่ตรวจจับในแต่ละกริดเซลล์
- สร้างกล่องขอบเขต (Bounding box) ที่ระบุตำแหน่งและขนาดของวัตถุ

กระบวนการตรวจจับวัตถุที่กล่าวไว้ข้างต้นถูกดำเนินการโดยใช้เทคนิคโครงข่ายประสาทแบบคอนโวลูชันที่ประมวลผล 1 ครั้ง เพื่อทำนายความน่าจะเป็น (Probability) ของคลาสต่าง ๆ ภายในกล่องขอบเขต และคำนวณคะแนนความเชื่อมั่น (Confidence score) หรือเรียกอีกอย่างหนึ่งว่า คะแนนการทำนายความน่าจะเป็น (Probability prediction score) หรือคะแนนความเป็นวัตถุ (Objectness score) ของวัตถุในกล่องขอบเขต

ในช่วงแรกของการตรวจจับวัตถุ โมเดลอาจจะทำนายวัตถุต่าง ๆ ในภาพได้หลายวัตถุ และสร้างกล่องขอบเขตรอบวัตถุขึ้นมาหลายกล่องขอบเขต ซึ่งแต่ละกล่องขอบเขตอาจจะมีส่วนที่ซ้อนทับกัน

(Intersection) แสดงดังรูปที่ 2(ก) ด้วยเหตุผลนี้ โมเดล YOLO หลายเวอร์ชันจึงนำกระบวนการลดค่าสูงสุดที่ไม่เกี่ยวข้อง (Non-Maximum Suppression: NMS) มาใช้หลังการประมวลผล (Post-processing) เพื่อเลือกเฉพาะกล่องขอบเขตที่มีความเหมาะสม

ในการเลือกกล่องขอบเขตที่เหมาะสมนั้น โมเดลจะคำนวณค่าพื้นที่ทับซ้อน (Intersection over Union: IoU) เพื่อวัดพื้นที่ที่ซ้อนทับกันระหว่างกล่องขอบเขตที่โมเดลทำนายได้และกล่องขอบเขตผลเฉลย (Ground truth bounding box) ที่ถูกสร้างขึ้นรอบวัตถุในภาพสำหรับการฝึกข้อมูล (Poonkuntran et al., 2022) โดยมีเกณฑ์ดังนี้

- หากกล่องขอบเขตที่ทำนายได้มีค่า IoU มากกว่าเกณฑ์ (Threshold) กระบวนการลดค่าสูงสุดที่ไม่เกี่ยวข้องที่ตั้งไว้ กล่องขอบเขตนั้น ๆ จะถูกเก็บไว้พิจารณา

- กรณีที่กล่องขอบเขตที่ทำนายได้มีค่า IoU ต่ำกว่าค่าเกณฑ์กระบวนการลดค่าสูงสุดที่ไม่เกี่ยวข้อง กล่องขอบเขตเหล่านั้นจะถูกกำจัดออกไปและเลือกกล่องขอบเขตที่มีค่าความเชื่อมั่นในการทำนายสูงสุดจากกล่องขอบเขตที่เหลือ แสดงดังรูปที่ 2(ข)

อย่างไรก็ตาม ในกรณีที่มีการกำหนดค่า IoU สูงเกินไปจะทำให้โมเดลตรวจจับวัตถุได้ยากมากขึ้น (Poonkuntran et al., 2022)



รูปที่ 2. การตรวจจับหอยทากในวิดีโอเฟรมโดยใช้โมเดล YOLO ที่กำหนดค่า IoU = 0.5 (ก) ผลการทำนายวัตถุในภาพก่อนใช้เทคนิค NMS ซึ่งโมเดลแสดงกล่องขอบเขตมากกว่า 1 กล่องขอบเขต (ข) หลังการใช้เทคนิค NMS โมเดลจะแสดงกล่องขอบเขตที่เหมาะสมเพียงกล่องขอบเขตเดียว หมายเหตุ: ผู้วิจัยกำหนดให้แสดงชื่อคลาสของวัตถุ (ข้อความ african-snail) และค่าคะแนนความเชื่อมั่น (ตัวเลข 0.67) ที่โมเดลคำนวณได้ไว้ที่ด้านบนของกล่องขอบเขต

3) โมเดล YOLOv10 ถูกนำเสนอในเดือนพฤษภาคม ค.ศ. 2024 โดย Wang et al. (2024) โมเดล YOLO เวอร์ชันนี้ถูกออกแบบให้ลดภาระในการคำนวณ เพิ่มความเร็ว ความแม่นยำและประสิทธิภาพในการตรวจจับวัตถุ อีกทั้งได้รับการพิสูจน์ว่า มีความแม่นยำในการตรวจจับสูงและใช้พารามิเตอร์ในการประมวลผลน้อยกว่าโมเดล YOLO หลายเวอร์ชันที่มีมาก่อนหน้า (Hussain & Khanam, 2024)


สถาปัตยกรรมของโมเดล YOLOv10 มีส่วนประกอบดังแสดงในรูปที่ 3 โดยในแต่ละส่วนมีการทำงานดังนี้ (Wang et al., 2024)

- แกนหลัก (Backbone) เป็นส่วนที่ใช้โครงข่ายประสาทแบบคอนโวลูชันทำหน้าที่สกัดคุณลักษณะ (Feature extraction) ของอินพุต (Input) ที่เป็นภาพหรือวิดีโอเฟรม

- โครงข่ายการรวมเส้นทาง (Path Aggregation Network: PAN) ทำหน้าที่เป็นส่วนคอ (Neck) ตามสถาปัตยกรรมมาตรฐานของการตรวจจับวัตถุที่ประมวลผล 1 ครั้ง (Bento et al., 2025) เพื่อทำหน้าที่รวบรวมคุณลักษณะในระดับต่าง ๆ และส่งต่อไปยังส่วนถัดไป

- การกำหนดป้ายกำกับแบบคู่ (Dual label assignment) ทำหน้าที่เป็นส่วนหัว (Head) ตามสถาปัตยกรรมมาตรฐานของโมเดลที่ใช้โครงข่ายประสาทแบบคอนโวลูชันประมวลผล 1 ครั้ง (Bento et al., 2025) โดยที่โมเดลสามารถทำนายคลาสของวัตถุได้ในแบบหนึ่งต่อหนึ่ง (One-to-One) และแบบหนึ่งต่อกลุ่ม (One-to-Many) เพื่อให้สามารถดำเนินการถดถอย (Regression) สำหรับการทำงานของกล่องขอบเขตและทำการจำแนก (Classification) วัตถุได้ การกำหนดป้ายกำกับแบบคู่จะช่วยให้แก้ไขปัญหาของโมเดล YOLO เวอร์ชันก่อนหน้าที่ใช้วิธีกำหนดป้ายกำกับแบบหนึ่งต่อหนึ่ง จึงทำให้ไม่จำเป็นต้องใช้กระบวนการลดค่าสูงสุดที่ไม่เกี่ยวข้อง ซึ่งเป็นกระบวนการที่ใช้เวลาและทรัพยากรในการประมวลผลอย่างมาก (Hussain & Khanam, 2024) ด้วยการทำงานของโครงข่ายการกำหนดป้ายกำกับแบบคู่จึงทำให้โมเดล YOLOv10 มีประสิทธิภาพและความเร็วในการตรวจจับวัตถุมากกว่าโมเดล YOLO เวอร์ชันก่อนหน้า

- เมตริกการจับคู่ที่สอดคล้องกัน (Consistent matching metric) เป็นส่วนที่ถูกใช้เพื่อให้การกำหนดป้ายกำกับมีความเหมาะสม และช่วยเพิ่มความแม่นยำในการตรวจจับวัตถุ โดยที่ m ในรูปที่ 3 หมายถึงค่าที่ระบุความสอดคล้องกันระหว่างค่าของการทำนายวัตถุจากภาพอินพุตกับค่าจากข้อมูลที่ใช้ในการฝึก (Wang et al., 2024)



รูปที่ 3. ภาพรวมสถาปัตยกรรมโมเดล YOLOv10

โมเดล YOLOv10 มีเวอร์ชันย่อยจำนวน 6 เวอร์ชัน โดยแต่ละเวอร์ชันย่อย มีขนาดและวัตถุประสงค์การใช้งาน และจำนวนพารามิเตอร์ที่ใช้แตกต่างกัน ดังแสดงในตารางที่ 1 (Wang et al., 2024)

ตารางที่ 1. โมเดล YOLO เวอร์ชันย่อยต่าง ๆ ขนาดและวัตถุประสงค์การใช้งาน และจำนวนพารามิเตอร์ที่ใช้

เวอร์ชันย่อย	ขนาดและวัตถุประสงค์การใช้งาน	จำนวนพารามิเตอร์ที่ใช้
YOLOv10N (N เป็นอักษรย่อของ Nano)	เวอร์ชันขนาดเล็กมาก เหมาะสำหรับเครื่องคอมพิวเตอร์ที่มีทรัพยากรการคำนวณที่จำกัด	2.3 ล้าน
YOLOv10S (S เป็นอักษรย่อของ Small)	เวอร์ชันขนาดเล็ก ที่มีการปรับสมดุลความเร็วและความแม่นยำในการทำงาน	7.2 ล้าน
YOLOv10M (M เป็นอักษรย่อของ Medium)	เวอร์ชันขนาดกลาง เหมาะสำหรับการใช้งานทั่วไป	15.4 ล้าน
YOLOv10B (B เป็นอักษรย่อของ Balanced)	เวอร์ชันที่ปรับสมดุลเพื่อเพิ่มความแม่นยำมากกว่าเวอร์ชัน YOLOv10N, YOLOv10S และ YOLOv10M	19.1 ล้าน
YOLOv10L (L เป็นอักษรย่อของ Large)	เวอร์ชันขนาดใหญ่ เพื่อเพิ่มความแม่นยำมากขึ้นกว่าเวอร์ชัน YOLOv10N, YOLOv10S, YOLOv10M และ YOLOv10B แต่ใช้ทรัพยากรการคำนวณมากขึ้น	24.4 ล้าน
YOLOv10X (X เป็นอักษรย่อของ Extra-large)	เวอร์ชันขนาดใหญ่มาก เหมาะสำหรับงานที่ต้องการความแม่นยำและประสิทธิภาพสูงสุดในการตรวจจับและจำแนกวัตถุ	29.5 ล้าน

เมื่อพิจารณาความแตกต่างของเวอร์ชันย่อยของโมเดล YOLOv10 จากข้อมูลในตารางที่ 1 จึงเป็นสาเหตุที่ทำให้ผู้วิจัยเลือกใช้โมเดล YOLOv10-X เนื่องจากต้องการให้ระบบสามารถตรวจจับหอยทากบกทั้ง 2 ชนิด ได้อย่างแม่นยำที่สุดเท่าที่ทรัพยากรที่ใช้ในงานวิจัยจะสามารถดำเนินการได้

4) งานวิจัยที่เกี่ยวข้องกับการระบุ ตรวจจับ หรือจำแนกหอยทากโดยการใช้การเรียนรู้เชิงลึก ผู้วิจัยพบว่า มีงานที่เกี่ยวข้องดังนี้

Wang et al. (2018) ทำการออกแบบและพัฒนาระบบตรวจจับและติดตามหอยทากในพื้นที่จริง โดยใช้อัลกอริทึม Faster R-CNN และใช้ตัวกรองคาลมานเชิงเส้น (Linear kalman filter) เพื่อติดตามการเคลื่อนที่ของหอยทากแต่ละตัว สร้างชุดข้อมูลวิดีโอด้วยการตั้งกล้องไว้ในฟาร์มเพื่อบันทึกหอยทากในทุก ๆ 30 วินาที และเลือกข้อมูลที่แสดงภาพหอยทากที่เหมาะสมมาแปลงเป็นภาพ และนำภาพมาทำการระบุ (Image labelling) ตัวหอยทากในภาพ จากนั้นชุดข้อมูลภาพถูกแบ่งเป็น 2 ส่วน เพื่อใช้สำหรับการฝึกโมเดลและใช้สำหรับการทดสอบค่าความแม่นยำเฉลี่ย (Average Precision: AP) การตรวจจับหอยทากของระบบที่นำเสนอถูกแบ่งตามชุดสเกล โดยโมเดล VGG16 ให้ค่า AP ใน 3 ชุดสเกลเท่ากับ 68.2%, 71.5% และ 71.9% อย่างไรก็ตาม ในบทความไม่ได้ระบุสายพันธุ์หอยทากที่ทำการตรวจจับ

Ahmad et al. (2022) ใช้โมเดล YOLOv5x เพื่อระบุศัตรูพืชจำนวน 23 ชนิด ที่รวมถึงหอยทากบกด้วย โดยมีการรวบรวมข้อมูลภาพศัตรูพืชจากอินเทอร์เน็ต จากนั้นนำภาพมาทำการให้ความหมายวัตถุในภาพ (Data annotation) โดยใช้ซอฟต์แวร์ Labellmg และทำการเสริมข้อมูลภาพ (Image augmentation) ข้อมูลภาพถูกใช้ในการฝึกโมเดล และใช้ทดสอบการระบุศัตรูพืชด้วยกล้องไอพี (IP camera) ค่าความแม่นยำเฉลี่ยสำหรับทุกคลาส (Mean Average Precision: mAP) เท่ากับ 98.3% และ

ค่า F1-score เท่ากับ 96% อย่างไรก็ตาม ผู้แต่งไม่ได้รายงานค่าความแม่นยำในการระบุหอยทากและศัตรูพืชชนิดอื่นแยกเป็นรายคลาส และไม่ได้กล่าวถึงสายพันธุ์หอยทากที่ใช้ในการทดลอง

Li & Qiu (2024) ทำการปรับปรุงโมเดล YOLOv7 ร่วมกับเทคนิคทางคอมพิวเตอร์วิทัศน์เพื่อระบุหอยทาก 9 สายพันธุ์ โดยมีวัตถุประสงค์เพื่อช่วยระบุว่าหอยทากที่ถูกวางจำหน่ายนั้นมนุษย์จะสามารถบริโภคได้อย่างปลอดภัยหรือไม่ ภาพที่ใช้ในงานวิจัยนี้ถูกรวบรวมจากการถ่ายภาพหอยทากที่วางจำหน่ายในตลาดหรือซูเปอร์มาร์เก็ตโดยใช้กล้องถ่ายภาพหรือใช้สมาร์ทโฟน (Smartphone) และรวบรวมภาพที่ถูกเผยแพร่ไว้ในอินเทอร์เน็ต จากนั้นใช้ซอฟต์แวร์ Labelimg เพื่อให้ความหมายวัตถุในภาพ ชุดข้อมูลภาพถูกใช้ในการฝึกโมเดลและใช้ทดสอบโมเดล ผลการระบุหอยทากทั้ง 9 สายพันธุ์ มีค่าความแม่นยำเฉลี่ยสำหรับทุกคลาสเท่ากับ 93.2% และค่า F1-score เท่ากับ 89.7% อย่างไรก็ตาม ในการระบุชนิดของหอยทากไม่ได้ถูกดำเนินการโดยใช้ภาพจากสภาพแวดล้อมในธรรมชาติจริง

จากงานวิจัยข้างต้นผู้วิจัยพบว่า มีหลายบทความที่นำเสนอการระบุ ตรวจจับ หรือจำแนกสายพันธุ์หอยทากโดยใช้การเรียนรู้เชิงลึก อย่างไรก็ตาม งานวิจัยที่นำเสนอ ยังไม่ได้นำเสนอระบบที่ผู้ใช้สามารถดูผลการตรวจจับหอยทากบกในแบบเรียลไทม์ ดูรายงานการตรวจจับหอยทากบก และรับการแจ้งเตือนการตรวจจับหอยทากบกผ่านแอปพลิเคชันไลน์ได้อย่างสมบูรณ์

1.3 วัตถุประสงค์ของงานวิจัย

- 1) เพื่อพัฒนาระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลอง โดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X
- 2) เพื่อค้นหาค่าความถูกต้องและความแม่นยำในการตรวจจับหอยทากบกของระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X

2. วิธีดำเนินการวิจัย


การออกแบบและพัฒนาระบบเพื่อตรวจจับหอยทากบกในแปลงผักทดลอง โดยให้มีการทำงานร่วมกันระหว่างอุปกรณ์ไอโอที เทคนิคคอมพิวเตอร์วิทัศน์ โมบายล์แอปพลิเคชัน และแอปพลิเคชันไลน์ มีรายละเอียดดังนี้

2.1 ทรัพยากรที่ใช้

1) หอยทากบก ได้แก่ หอยทากยักษ์แอฟริกันและหอยทากสยาม หอยทากบกเหล่านี้ถูกนำมาจากพื้นที่ต่าง ๆ ภายในมหาวิทยาลัยเกษตรศาสตร์ วิทยาเขตเฉลิมพระเกียรติ จังหวัดสกลนคร สาเหตุที่ในงานวิจัยนี้ใช้หอยทากบกเพียง 2 สายพันธุ์ เนื่องจากผู้วิจัยได้ทำการสำรวจในพื้นที่ในการเก็บตัวอย่าง เช่น ฟาร์มพืช ขยายป่า สวนดอกไม้ ฯลฯ พบเพียงหอยทากบกเพียง 2 สายพันธุ์นี้เท่านั้น

2) แปลงผักทดลอง ใช้กระบะปลูกผักสำเร็จรูปที่มีวางจำหน่ายในร้านขายอุปกรณ์ปลูกผักที่มีขนาดกว้าง 35 ซม. ยาว 55 ซม. และใส่ดินสำหรับการเพาะปลูกไว้ในกระบะ แสดงดังรูปที่ 4(ก)

3) ผักที่ใช้ในแปลงผักทดลอง ได้แก่ กรีนโอ๊ค (Green Oak) เรดคอส (Red Cos) และผักกาดหอม (Green Coral lettuce) แสดงดังรูปที่ 4(ข)



(ก)



(ข)

รูปที่ 4. แปลงผักทดลองและผักที่ใช้ในงานวิจัยนี้ (ก) ภาพจำลองการออกแบบแปลงผักทดลองของระบบ (ข) ผักที่ใช้ในการทดลอง 3 ชนิด ได้แก่ กรีนโอ๊ค (บน) เรดคอส (กลาง) และผักกาดหอม (ล่าง) ที่ถูกปลูกไว้ในแปลงผัก โดยมีหอยทากยักษ์แอฟริกันและหอยทากสยามอยู่ภายในแปลงผัก เพื่อแสดงให้เห็นขนาด รูปร่าง สี และลวดลายของหอยทากบกทั้ง 2 สายพันธุ์


4) อุปกรณ์ไอโอที ประกอบด้วยอุปกรณ์ฮาร์ดแวร์ (Hardware) ต่าง ๆ ได้แก่ บอร์ดราสเบอร์รี่พาย (Raspberry Pi) 3 โมเดล B+ ไมโครคอนโทรลเลอร์ ESP32 พัดลมระบายความร้อน (Cooling fan) กล้องเว็บแคม (Webcam) Logitech B525 ความละเอียด 1280 x 720 พิกเซล (Pixel) และไฟแอลอีดี (LED) โดยอุปกรณ์ต่าง ๆ ถูกติดตั้งไว้ที่โครงท่อพีวีซี (PVC) แสดงดังรูปที่ 4(ก)

5) ซอฟต์แวร์ ประกอบด้วย Roboflow, Django Rest Framework, Flutter Framework, LINE Notify API, MySQL และ YOLOv10 Detect

6) ภาษาที่ใช้ในการพัฒนา ได้แก่ Python v.3.1.3 และ Dart v3.4

2.2 ขั้นตอนการทดลอง

ขั้นตอนการทดลองในการพัฒนาระบบในงานวิจัยนี้ ถูกแบ่งเป็น 5 ขั้นตอน แสดงดังรูปที่ 5



รูปที่ 5. ขั้นตอนการทดลองในการพัฒนาระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลอง โดยใช้การเรียนรู้เชิงลึกโมเดล YOLOv10-X

- 1) จัดเตรียมข้อมูล จัดเตรียมชุดข้อมูลภาพและวิดีโอหอยทากบกที่ใช้ในงานวิจัยนี้
- 2) ฝึกโมเดล การฝึกโมเดล YOLO จากข้อมูลที่เตรียมไว้ในขั้นตอนที่ 1

- 3) ออกแบบและพัฒนาระบบ ที่ประกอบด้วย การออกแบบระบบฝังตัว การออกแบบฐานข้อมูล การออกแบบการทำงานของระบบ การตรวจจับหอยทากบก และการออกแบบโมไบล์แอปพลิเคชัน
- 4) วัดประสิทธิภาพของระบบ โดยมีรายละเอียดของเครื่องมือที่ใช้ การวัดค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) ค่าเฉลี่ยของความแม่นยำและค่าความระลึก (F1-score) และค่าความแม่นยำเฉลี่ย (mAP)
- 5) วิเคราะห์ผลการทำงานของระบบ โดยมีผลการวัดประสิทธิภาพของระบบการตรวจจับหอยทากบก

2.3 การเตรียมข้อมูล

- 1) ชุดข้อมูลหอยทากบกที่ใช้สำหรับการฝึกโมเดลในงานวิจัยนี้มีรายละเอียดดังนี้
 - ข้อมูลภาพ ประกอบด้วย
 - ภาพถ่ายจากสภาพจริงในธรรมชาติโดยใช้กล้องสมาร์ทโฟน ซึ่งถ่ายในช่วงกลางวันโดยไม่ใช้แฟลชในการถ่ายภาพ และช่วงกลางคืนโดยใช้แฟลชในระหว่างการถ่ายภาพ
 - ภาพถ่ายจากแปลงผักทดลองที่จัดเตรียมไว้โดยใช้กล้องสมาร์ทโฟน ซึ่งถ่ายในช่วงกลางวันโดยไม่ใช้แฟลชในการถ่ายภาพ และช่วงกลางคืนโดยใช้แฟลชในระหว่างการถ่ายภาพ
 - ภาพที่ถูกเผยแพร่ในอินเทอร์เน็ต ซึ่งเป็นภาพที่ถูกถ่ายในช่วงกลางวัน
 - ข้อมูลวิดีโอ ประกอบด้วย
 - วิดีโอถ่ายจากสภาพจริงในธรรมชาติโดยใช้กล้องสมาร์ทโฟน ซึ่งถ่ายในช่วงกลางวันโดยไม่ใช้แฟลชในการถ่ายวิดีโอ และช่วงกลางคืนโดยใช้แฟลชในระหว่างการถ่ายวิดีโอ
 - วิดีโอถ่ายจากแปลงผักทดลองที่จัดเตรียมไว้โดยใช้กล้องสมาร์ทโฟน ซึ่งถ่ายในช่วงกลางวันโดยไม่ใช้แฟลชในการถ่ายวิดีโอ และช่วงกลางคืนโดยใช้แฟลชในระหว่างการถ่ายวิดีโอ
- จำนวนของภาพและวิดีโอที่ใช้ในการฝึกด้วยแบบจำลอง YOLOv10-X ถูกแสดงดังตารางที่ 2


ตารางที่ 2. รายละเอียดชุดข้อมูลหอยทากบกที่ใช้สำหรับการฝึกโมเดล YOLOv10-X

สายพันธุ์	ภาพ		วิดีโอ		รวม
	ถ่ายโดยกล้อง สมาร์ทโฟน	อินเทอร์เน็ต	ถ่ายโดยกล้อง สมาร์ทโฟน	อินเทอร์เน็ต	
ทากยักษ์แอฟริกัน (ตัว)	940	260	83	-	1,283
ทากสยาม (ตัว)	2,703	353	34	-	3,090
รวม	3,643	613	117	-	4,373


- 2) การเสริมข้อมูล (Data augmentation) เป็นกระบวนการที่ถูกใช้ในการเพิ่มจำนวนข้อมูลในชุดข้อมูลฝึกเพื่อเพิ่มความแม่นยำในการตรวจจับหอยทากบก ซึ่งกระบวนการเสริมข้อมูลในงานวิจัยนี้ ได้แก่ การหมุนภาพ การกลับด้านภาพ การเพิ่มสัญญาณรบกวน (Noise) ในภาพ เป็นต้น

3) การให้ความหมายวัตถุในชุดข้อมูล ข้อมูลที่ใช้ในงานวิจัยนี้ถูกนำมาให้ความหมายโดยการกำหนดขอบเขตวัตถุที่สนใจในภาพ โดยใช้เว็บแอปพลิเคชัน Roboflow (<https://app.roboflow.com>) ซึ่งเป็นเครื่องมือในการระบุขอบเขตของวัตถุที่สนใจในภาพและวิดีโอ โดยทำการกำหนดคลาสจำนวน 2 คลาส คือ คลาสหอยทากยักษ์แอฟริกันและคลาสหอยทากสยาม แสดงดังรูปที่ 6(ก) การกำหนดขอบเขตวัตถุในงานสำหรับการฝึกจะเลือกเฉพาะส่วนเปลือกหอย เนื่องจากพิสูจน์แล้วว่าเป็นบริเวณที่สามารถระบุชนิดของหอยทากบ่งได้แม่นยำว่าการรวมตัวหอยเข้าไปในการให้ความหมายด้วย ตัวอย่างการให้ความหมายของหอยทากบ่งทั้ง 2 คลาสโดยใช้ Roboflow แสดงดังรูปที่ 6(ข)

จำนวนหอยทากยักษ์แอฟริกันที่ถูกให้ความหมายมีทั้งหมด 1,283 ตัว และจำนวนหอยทากสยามที่ถูกให้ความหมายมีทั้งหมด 3,090 ตัว รวมทั้ง 2 คลาสมีจำนวนเท่ากับ 4,373 ตัว แสดงรายละเอียดดังตารางที่ 2 และรูปที่ 6(ก) เหตุผลที่ผู้วิจัยให้ความหมายหอยทากสยามมากกว่าหอยทากยักษ์แอฟริกันเนื่องจากหอยทากยักษ์แอฟริกันมีขนาดใหญ่ มีลวดลายที่เปลือกหอยชัดเจน และมีรูปร่างที่ตรงจวบได้ง่าย แต่หอยทากสยามมีขนาดเล็ก ลวดลายบนเปลือกหอยไม่ชัดเจน มีรูปร่างกลมกลืนกับก้อนหินหรือมีสีและลวดลายของเปลือกหอยที่กลมกลืนกับดินหรือทรายในแปลงผัก จากการทดสอบระบบ พบว่า ความแม่นยำในการตรวจจับหอยทากสยามมีค่าต่ำอย่างมาก จึงต้องมีการใช้ข้อมูลของหอยทากสยามในการฝึกโมเดลมากกว่าหอยทากยักษ์แอฟริกัน



(ก)



(ข)

รูปที่ 6. การกำหนดคลาสและการให้ความหมายวัตถุในชุดข้อมูลสำหรับการฝึกโดยใช้เว็บแอปพลิเคชัน Roboflow

(ก) การกำหนดคลาสหอยทากบ่ง ที่ประกอบด้วย คลาสหอยทากยักษ์แอฟริกันและคลาสหอยทากสยาม

(ข) ตัวอย่างบางส่วนของการให้ความหมายวัตถุในชุดข้อมูลหอยทากบ่งที่ใช้ในงานวิจัยนี้


2.4 การฝึกโมเดล

ในช่วงแรกของการฝึกโมเดลของระบบ ผู้วิจัยได้จัดเตรียมจำนวนข้อมูลที่ใช้ในกระบวนการฝึกเพียง 800 ภาพ กำหนดค่า Epoch = 50 Batch size = 8 และ IoU = 0.5 ในการฝึกโมเดล YOLOv10-X โดยที่ Epoch คือ รอบที่ทำการปรับน้ำหนักเพื่อให้ได้ค่าใกล้เคียงกับเป้าหมายหรือเพื่อให้โมเดลสามารถตรวจจับวัตถุได้ถูกต้องในทุก ๆ วัตถุ และ Batch size คือ ขนาดในการแบ่งข้อมูลการฝึกเป็นส่วน ๆ เนื่องจากข้อจำกัดของทรัพยากรในการประมวลผล ทำให้ไม่สามารถนำข้อมูลภาพทั้งหมดประมวลผลได้ในครั้งเดียว

เมื่อพิจารณาจากเส้นโค้งความแม่นยำ-ความระลึก (Precision-Recall curve) ที่ได้รับการฝึกพบว่า โมเดลที่ฝึกในช่วงแรกให้ค่าความแม่นยำในการตรวจจับต่ำมาก โดยมีค่าความแม่นยำเฉลี่ย (mAP) ในการตรวจจับหอยทากบกของทั้ง 2 คลาส เพียง 37% และมีค่าคลาดเคลื่อน (Loss) หรือค่าผิดพลาด (Error) เท่ากับ 68% ซึ่งถือว่ามีความผิดพลาดสูง (หากค่า Loss มีค่าน้อยมากหรือเข้าใกล้ 0 ยิ่งส่งผลดี) ที่มีความเป็นไปได้ว่าจะมีสาเหตุจากข้อมูลที่ใช้ในการฝึกไม่เพียงพอและ/หรือจำนวนรอบของ Epoch น้อยเกินไป

จากค่าความแม่นยำเฉลี่ยและค่าคลาดเคลื่อนที่กล่าวไว้ข้างต้น ทำให้ผู้วิจัยเพิ่มข้อมูลสำหรับการฝึกโมเดลและทำการปรับค่า Epoch เพิ่มขึ้นจาก 50 เป็น 80, 100 และ 128 ตามลำดับ โดยพิจารณาจากค่าความคลาดเคลื่อนที่ลดลงเรื่อย ๆ ไปจนกระทั่งค่าความคลาดเคลื่อนไม่ลดลงอีก นอกจากนี้ยังได้ทดลองปรับค่าของ Batch size เป็น 16 และ 32 และจากการทดลองพบว่า Batch size = 8 มีความเหมาะสมกับทรัพยากรการประมวลผลของเครื่องคอมพิวเตอร์ของผู้วิจัยที่ใช้ในการฝึกโมเดล


จากการปรับค่า Epoch และ Batch size ในการฝึกโมเดลตามที่อธิบายไว้ข้างต้น พบว่า ค่า Epoch = 128 Batch size = 8 และ IoU = 0.5 ทำให้โมเดลมีค่าความคลาดเคลื่อนลดลงในแบบคงที่และไม่ลดต่ำลงอีก ซึ่งหมายความว่า โมเดลมีความเหมาะสมต่อการนำไปใช้งาน โดยแสดงบันทึกการฝึกโมเดล YOLOv10-X ดังรูปที่ 7



รูปที่ 7. บันทึกการฝึกโมเดล YOLOv10-X ของระบบโดยใช้ข้อมูลหอยทากบก

2.5 การออกแบบระบบฝังตัว

ผู้วิจัยได้ออกแบบระบบการตรวจจับหอยทากให้มีความทำงานที่นำเทคโนโลยีคอมพิวเตอร์ขนาดเล็ก โดยใช้ Raspberry Pi 3 model B+ สำหรับประมวลผลที่ทำงานร่วมกันกับกล้องเว็บแคมสำหรับเก็บภาพอย่างต่อเนื่อง รวมถึงใช้ไฟแอลอีดีในการให้แสงสว่างเพื่อให้สามารถตรวจจับตัวหอยทากในแปลงผักช่วงเวลา กลางคืน เนื่องจากส่วนใหญ่หอยทากจะออกหากินในเวลากลางคืน นอกจากนี้ได้ติดตั้งพัดลมเพื่อรักษา อุณหภูมิให้เหมาะสมต่อการทำงานของอุปกรณ์ในระยะเวลาที่ยาวนานได้ รายละเอียดการเชื่อมโยงส่วนต่าง ๆ ของระบบร่วมกับส่วนของอุปกรณ์ไอโอทีที่แสดงไว้ในส่วน Hardware ดังรูปที่ 8




รูปที่ 8. การออกแบบระบบฝังตัวของระบบต้นแบบเพื่อตรวจจับหอยทากในแปลงผักทดลอง โดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X ที่แสดงการเชื่อมโยงการทำงานร่วมกันกับส่วนของเซิร์ฟเวอร์ ฐานข้อมูล โมบายล์แอปพลิเคชัน และแอปพลิเคชันไลน์

2.6 การออกแบบฐานข้อมูล

ข้อมูลของระบบต้นแบบการตรวจจับหอยทากถูกออกแบบให้เก็บข้อมูลไว้ใน 5 ตาราง ที่ประกอบด้วย ตารางข้อมูลผู้ใช้งานระบบ (User profile) ตารางตั้งค่าการตรวจจับหอยทาก (System preference) ตารางชนิดหอยทาก (Land snail species) ตารางข้อมูลการตรวจจับ (Frame detected lists) และตารางข้อมูลรายการหอยทากที่ตรวจพบแต่ละเฟรมภาพ (Land snail detected lists) แสดง

รายละเอียดของแอตทริบิวต์ (Attribute) ของตารางต่าง ๆ ของระบบโดยแผนภาพความสัมพันธ์ระหว่างเอนทิตี (Entity-Relationship diagram) แสดงดังรูปที่ 9




รูปที่ 9. แผนภาพความสัมพันธ์ระหว่างเอนทิตี (Entity-Relationship diagram) ของระบบต้นแบบเพื่อตรวจจับหอยทากบกในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึกโมเดล YOLOv10-X

2.7 การออกแบบการทำงานของระบบ

ขั้นตอนการทำงานของระบบต้นแบบการตรวจจับหอยทากที่น่าเสนอ ถูกออกแบบให้สอดคล้องกับส่วนต่าง ๆ ดังนี้

- 1) บอร์ดเริ่มต้นการทำงานตามเวลาที่กำหนด เปิดไฟแอลอีดีเพื่อให้แสงเพียงพอ และเริ่มต้นการทำงานของโปรแกรมการตรวจจับที่กำหนดไว้
- 2) เมื่อหอยทากเข้ามาในพื้นที่ของแปลงผักในขณะที่อุปกรณ์ตรวจจับทำงาน ระบบจะตรวจจับหอยทากโดยทำการประมวลผลข้อมูลในแบบเรียลไทม์ผ่านโมเดลการตรวจจับ YOLOv10-X ที่ถูกฝึกมาแล้ว
- 3) กรณีที่ระบบตรวจจับไม่พบหอยทาก ระบบจะทำการตรวจจับต่อไปเรื่อย ๆ ผ่านกล้อง
- 4) กรณีที่ระบบตรวจจับพบตัวหอยทาก ระบบจะดำเนินการดังนี้
 - ระบุตรวจสอบจำนวนที่พบภายในเฟรมภาพและสรุปจำนวนหอยทากที่ตรวจพบ
 - เตรียมชุดข้อมูลเพื่อบันทึกหลักฐานข้อมูล
 - ส่งข้อมูลที่เตรียมไว้ไปบันทึกลงในตารางที่เกี่ยวข้อง
 - ส่งข้อมูลเพื่อใช้บริการแจ้งเตือนไปยัง Line Notify API เพื่อให้ส่งการแจ้งเตือนไปยังแอปพลิเคชันไลน์ของผู้ใช้
- 5) ผู้ใช้สามารถดูข้อมูลการตรวจจับแบบเรียลไทม์ ดูรายงานการตรวจจับหอยทากย้อนหลังผ่านโมบายล์แอปพลิเคชันได้
- 6) กรณีที่ผู้ใช้ได้รับข้อมูลการแจ้งเตือนผ่านแอปพลิเคชันไลน์แล้ว ผู้ใช้สามารถดูข้อมูลการแจ้งเตือนการตรวจจับหอยทากผ่านแอปพลิเคชันไลน์ได้

แผนภาพกิจกรรม (Activity diagram) เพื่อแสดงขั้นตอนการทำงานของระบบที่อธิบายมาข้างต้น
ถูกแสดงไว้ในรูปที่ 10



รูปที่ 10. แผนภาพกิจกรรมที่แสดงการทำงานของระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลอง
โดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X

2.8 การตรวจจับหอยทากบก

มีขั้นตอนที่เชื่อมโยงกับขั้นตอนการทำงานที่แสดงไว้ในแผนภาพกิจกรรมในรูปที่ 10 ดังนี้

1) การตรวจจับภาพ ในทุก ๆ หน่วยเวลาที่ตั้งค่าไว้ ระบบจะเก็บเฟรมภาพจากวิดีโอเข้าไปทำการประมวลผล จากนั้นเฟรมที่ได้รับจะถูกส่งไปตรวจสอบโดยแบบจำลอง YOLOv10-X ที่ถูกฝึกมาแล้ว เมื่อโมเดลการตรวจจับทำงานเสร็จสิ้นจะส่งผลลัพธ์การตรวจจับกลับมายังระบบ ผลลัพธ์แบ่งเป็น 2 รูปแบบ คือ ไม่พบหอยทากบกและพบหอยทากบก โดยโมเดลจะระบุบริเวณและจำนวนหอยทากบกที่ตรวจพบในเฟรมภาพ

2) กรณีที่ตรวจพบหอยทากบก ระบบจะทำการตรวจสอบความถี่ของการแจ้งเตือน หากการแจ้งเตือนก่อนหน้าที่มีความถี่เวลาไม่เกินที่กำหนดไว้ ระบบจะไม่ทำการใด ๆ แต่หากพบว่า ความถี่มากกว่าหรือ

เท่ากับเวลาที่ตั้งค่าไว้ ระบบจะทำการบันทึกข้อมูลในฐานข้อมูล จากนั้นส่งการแจ้งเตือนไปที่แอปพลิเคชันไลน์ของผู้ใช้ และตรวจจับหอยทากในเฟรมข้อมูลถัดไป

3) กรณีที่ตรวจไม่พบหอยทากบก ระบบจะทำการกลับไปประมวลผลเฟรมถัดไป

2.9 การออกแบบโมบิลแอปพลิเคชัน

การออกแบบการทำงานของโมบิลแอปพลิเคชันของระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึกแบบจำลอง YOLOv10-X มีรายละเอียดดังนี้

- 1) ผู้ใช้แอปพลิเคชันจะต้องลงชื่อเข้าใช้งานระบบ
- 2) หน้าจอหลักของระบบจะต้องมีปุ่มเพื่อให้ผู้ใช้เลือกการทำงาน ที่ประกอบด้วยปุ่มต่าง ๆ ได้แก่
 - Real Time Detection เพื่อให้ผู้ใช้ดูการตรวจจับหอยทากบกในแปลงผักทดลองแบบเรียลไทม์
 - History Detections เพื่อให้ผู้ใช้ดูประวัติการตรวจจับหอยทากบกในแปลงผักทดลอง
 - User Profile เพื่อแสดงผลข้อมูลผู้ใช้
 - System Preferences เพื่อให้ผู้ใช้ตั้งค่าต่าง ๆ ในการจับหอยทากบกของระบบ
 - System Requirements เพื่อแสดงความต้องการของระบบ
 - About Application เพื่อเป็นปุ่มแสดงข้อมูลผู้พัฒนาระบบ

2.10 การวัดประสิทธิภาพของระบบ

ในการวัดประสิทธิภาพของระบบ ผู้วิจัยกำหนดให้ทำการสุ่มจำนวนเฟรมที่ได้จากการตรวจจับแบบเรียลไทม์ผ่านกล้องเว็บแคมโดยใช้วิดีโอเฟรมจำนวน 100 เฟรม และเปรียบเทียบการตรวจจับหอยทากบกจากระบบที่พัฒนาขึ้นกับการตรวจสอบโดยมนุษย์

จากนั้นเมทริกซ์ความสับสน (Confusion matrix) ถูกใช้เป็นเครื่องมือเพื่อวัดประสิทธิภาพการตรวจจับหอยทากบกทั้ง 2 สายพันธุ์ โดยแบ่งผลการตรวจจับวัตถุเป็น 4 ส่วน ได้แก่ True Positive (TP) False Positive (FP) False Negative (FN) และ True Negative (TN) แสดงดังตารางที่ 3

ตารางที่ 3. เมทริกซ์ความสับสนที่ใช้เป็นเครื่องมือในการวัดประสิทธิภาพการตรวจจับหอยทากบกของระบบ

		คลาสที่แท้จริง (Actual class)	
		ใช่	ไม่ใช่
คลาสที่ระบบทำนาย (Predicted class)	ใช่	True Positive (TP)	False Positive (FP)
	ไม่ใช่	False Negative (FN)	True Negative (TN)

ในการตรวจจับหอยทากยักษ์แอฟริกัน

TP หมายถึง มนุษย์ระบุว่า เป็นหอยทากยักษ์แอฟริกัน และระบบระบุว่าวัตถุที่ตรวจจับได้เป็นหอยทากยักษ์แอฟริกัน

FP หมายถึง มนุษย์ระบุว่า เป็นวัตถุที่ไม่ใช่หอยทากยักษ์แอฟริกัน แต่ระบบระบุว่า เป็นหอยทากยักษ์แอฟริกัน

TN หมายถึง มนุษย์ระบุว่าเป็นวัตถุที่ไม่ใช่หอยทากยักษ์แอฟริกัน และระบบระบุว่าเป็นหอยทากยักษ์แอฟริกัน

FN หมายถึง มนุษย์ระบุว่าเป็นหอยทากยักษ์แอฟริกัน แต่ระบบระบุว่าเป็นหอยทากยักษ์แอฟริกัน

ในการตรวจจับหอยทากสยาม

TP หมายถึง มนุษย์ระบุว่าเป็นหอยทากสยาม และระบบระบุว่าเป็นวัตถุที่ตรวจจับได้เป็นหอยทากสยาม

FP หมายถึง มนุษย์ระบุว่าเป็นวัตถุที่ไม่ใช่หอยทากสยาม แต่ระบบระบุว่าเป็นหอยทากสยาม

TN หมายถึง มนุษย์ระบุว่าเป็นวัตถุที่ไม่ใช่หอยทากสยาม และระบบระบุว่าเป็นหอยทากสยาม

FN หมายถึง มนุษย์ระบุว่าเป็นหอยทากสยาม แต่ระบบระบุว่าเป็นหอยทากสยาม

เมื่อได้รับค่า *TP*, *FP*, *TN* และ *FN* จากการตรวจจับและระบุ (หรือทำนาย) คลาสจากระบบและเปรียบเทียบกับผลการตรวจสอบโดยมนุษย์แล้ว ค่าที่ได้รับมาจะถูกใช้ในการคำนวณค่าความถูกต้อง (Accuracy) ดังสมการที่ (1) ค่าความแม่นยำ (Precision) ดังสมการที่ (2) ค่าความระลึก (Recall) ดังสมการที่ (3) ค่าเฉลี่ยของความแม่นยำและค่าความระลึก (F1-score) ดังสมการที่ (4) และค่าความแม่นยำเฉลี่ย (mAP) ดังสมการที่ (5)

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

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

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

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

$$\text{mAP} = \frac{AP(1) + AP(2)}{\text{Class}} \quad (5)$$

โดยที่ *mAP* คือ ค่าเฉลี่ยความแม่นยำของทุกคลาส
AP(1) คือ ค่าเฉลี่ยความแม่นยำ (Average precision) ของคลาสหอยทากยักษ์แอฟริกัน
AP(2) คือ ค่าเฉลี่ยความแม่นยำของคลาสหอยทากสยาม
Class คือ จำนวนคลาสที่กำหนดให้ระบบทำการตรวจจับในงานวิจัยนี้ซึ่งมีจำนวน 2 คลาส ได้แก่ 1) คลาสหอยทากยักษ์แอฟริกัน และ 2) คลาสหอยทากสยาม

3. ผลการวิจัยและอภิปรายผล

จากการออกแบบและพัฒนาระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X มีผลการดำเนินงานดังนี้

3.1 ผลการตรวจจับหอยทากบก

- 1) ข้อมูลที่ใช้ในการประเมินประสิทธิภาพของระบบ แสดงในตารางที่ 4

ตารางที่ 4. ข้อมูลที่ใช้ในการประเมินประสิทธิภาพของระบบ

รายการ	จำนวน
จำนวนเฟรมภาพที่สุ่มการตรวจจับจากกล้องเว็บแคม (เฟรมภาพ)	100
จำนวนหอยทากยักษ์แอฟริกันที่ปรากฏในเฟรมภาพ (ตัว)	385
จำนวนหอยทากสยามที่ปรากฏในเฟรมภาพ (ตัว)	381

จำนวนของหอยทากบกทั้ง 2 สายพันธุ์ที่ปรากฏในเฟรมภาพที่สุ่มมา 100 เฟรมภาพ ในขณะตรวจจับมีรายละเอียดดังตารางที่ 5

ตารางที่ 5. สรุปจำนวนหอยทากบกจากเฟรมภาพที่ถูกสุ่ม 100 เฟรมภาพ

จำนวนหอยทากที่ตรวจจับได้จากมนุษย์		จำนวนหอยทากที่ตรวจจับได้จากระบบ	
หอยทากยักษ์แอฟริกัน	หอยทากสยาม	หอยทากยักษ์แอฟริกัน	หอยทากสยาม
385 ตัว	381 ตัว	281 ตัว	153 ตัว

ผลการตรวจจับหอยทากยักษ์แอฟริกันและหอยทากสยามจากการสุ่ม 100 เฟรมภาพ ถูกแสดงโดยใช้ค่า TP , FP , TN และ FN โดยมีรายละเอียดในตารางที่ 6

ตารางที่ 6. ค่า TP , FP , TN และ FN จากการสุ่มตรวจจับหอยทากบก 100 เฟรมภาพ

สายพันธุ์	TP	FP	TN	FN
ทากยักษ์แอฟริกัน (ตัว)	263	13	156	133
ทากสยาม (ตัว)	151	1	263	231

- 2) ผลลัพธ์การคำนวณประสิทธิภาพจากการใช้สมการที่ (1) - (5) ที่ประกอบด้วยค่า Accuracy, Precision, Recall, F1-score และ mAP ในการตรวจจับหอยทากบกทั้ง 2 สายพันธุ์ ถูกแสดงรายละเอียดในตารางที่ 7

ตารางที่ 7. ค่า Accuracy, Precision, Recall, F1-score และ mAP ของการตรวจจับหอยทากบกทั้ง 2 สายพันธุ์ จากการสุ่มตรวจจับหอยทากบก 100 เฟรมภาพโดยใช้แบบจำลอง YOLOv10-X

ค่า	ทากยักษ์แอฟริกัน (%)	ทากสยาม (%)	เฉลี่ยทั้ง 2 คลาส (%)
Accuracy	74.15	64.08	69.11
Precision	95.28	99.34	97.31
Recall	66.41	39.52	52.96
F1-score	78.26	56.54	67.4
mAP	-	-	97.31

3.2 ผลการออกแบบโมไบล์แอปพลิเคชันของระบบ

โมไบล์แอปพลิเคชันของระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X ที่ถูกพัฒนาขึ้นนี้ มีรายละเอียดการทำงานดังนี้

- 1) ผู้ใช้สามารถเข้าสู่ระบบโดยใช้ชื่อผู้ใช้และรหัสผ่าน แสดงดังรูปที่ 12(ก)
- 2) หน้าจอหลักของระบบที่ปรากฏดังรูปที่ 12(ข) จะปรากฏเมื่อผู้ใช้ป้อนชื่อผู้ใช้และรหัสผ่านได้ถูกต้อง โดยที่หน้าจอนี้จะปรากฏปุ่มต่าง ๆ เพื่อให้ผู้ใช้เลือก ที่ประกอบด้วย
 - Real Time Detection เป็นปุ่มที่ผู้ใช้สามารถดูการตรวจจับหอยทากบกในแปลงผักทดลองแบบเรียลไทม์ได้
 - History Detections เป็นปุ่มที่ผู้ใช้สามารถดูประวัติการตรวจจับหอยทากบกในแปลงผักทดลอง
 - User Profile เป็นปุ่มที่ผู้ใช้สามารถดูข้อมูลผู้ใช้ได้
 - System Preferences เป็นปุ่มที่ผู้ใช้สามารถตั้งค่าต่าง ๆ ที่จำเป็นต่อการตรวจจับหอยทากบกของระบบ ได้แก่ การตั้งค่าความถี่ของการบันทึกข้อมูลการตรวจจับ การตั้งค่าความถี่ข้อมูลการตรวจจับของการแจ้งเตือนทางแอปพลิเคชันไลน์
 - System Requirements เป็นปุ่มที่ผู้ใช้ดูข้อมูลความต้องการของระบบที่เกี่ยวข้องกับการประมวลผล
 - About Application เป็นปุ่มที่ผู้ใช้สามารถดูข้อมูลผู้พัฒนาระบบได้
- 3) เมื่อผู้ใช้เลือกปุ่ม Real Time Detection จะปรากฏหน้าจอการตรวจจับหอยทากในแปลงผักทดลองแบบเรียลไทม์

จากรูปที่ 12(ค) แสดงรายละเอียดในหน้าจอที่ถูกแบ่งเป็น 2 ส่วน ได้แก่ ส่วนด้านบนที่แสดงการตรวจจับหอยทากบกในแบบเรียลไทม์ ส่วนด้านล่างเป็นส่วนที่นับจำนวนหอยทากบกที่ตรวจพบในแต่ละช่วงเวลา โดยที่

- กรอบสีแดง หมายถึง ระบบตรวจพบหอยทากสยามที่แสดงชื่อสายพันธุ์ และแท็กตัวเลขเพื่อให้ระบบแสดงเลขที่ระบุ (Identification number) สำหรับการติดตามหอยทากสยามแต่ละตัว
- กรอบสีม่วง หมายถึง ระบบตรวจพบหอยทากยักษ์แอฟริกันที่แสดงชื่อสายพันธุ์และแท็กตัวเลขเพื่อให้ระบบแสดงเลขที่ระบุ เพื่อติดตามหอยทากยักษ์แอฟริกันแต่ละตัว แสดงรายละเอียดดังรูปที่ 11



รูปที่ 11. การตรวจจับหอยทากบกที่แสดงชื่อสายพันธุ์และแท็กตัวเลขที่ใช้ในการติดตามหอยทากแต่ละตัว โดยที่กรอบสีแดงหมายถึงระบบตรวจจับหอยทากสยามได้ และกรอบสีม่วงหมายถึงระบบตรวจจับหอยทากยักษ์แอฟริกันได้
หมายเหตุ ภาพนี้ถูกสุ่มจากกล้องเว็บแคมที่ใช้ในงานวิจัยจึงทำให้สังเกตเห็นหอยทากสยามบางตัวไม่ชัดเจน

4) เมื่อผู้ใช้เลือกปุ่ม History Detections จะปรากฏหน้าจอแสดงดังรูปที่ 12(ง) จากหน้าจอนี้ ผู้ใช้สามารถเลือกช่วงเวลาที่ต้องการดูได้โดยการคลิกปุ่ม “Choose date” จะปรากฏหน้าจอเพื่อเลือกวันที่ ต้องการดูข้อมูลการตรวจจับดังแสดงในรูปที่ 12(จ) หลังจากผู้ใช้เลือกวันที่ที่ต้องการแล้ว จะปรากฏหน้าจอ ที่แสดงการตรวจจับหอยทากของวันที่เลือก


5) เมื่อผู้ใช้เลือกปุ่ม System Preferences จะปรากฏหน้าจอเพื่อให้ผู้ใช้ตั้งค่าความถี่การบันทึก ข้อมูลการตรวจจับและการแจ้งเตือนทางแอปพลิเคชันไลน์ แสดงดังรูปที่ 12(ฉ)

6) กรณีที่ระบบตรวจจับได้ว่ามีหอยทากในแปลงผักจะปรากฏการแจ้งเตือนจาก Line notify ที่ ด้านบนของอุปกรณ์ผู้ใช้ดังรูปที่ 12(ซ)

7) จากรูปที่ 12(ซ) เมื่อผู้ใช้ดูข้อมูลการแจ้งเตือนการตรวจจับ แอปพลิเคชันไลน์จะแสดงข้อมูลการ ตรวจจับดังรูปที่ 12(ซ)

3.3 อภิปรายผล

จากผลการตรวจจับหอยทากที่สุ่มจากการตรวจจับแบบเรียลไทม์โดยการสุ่มเลือกวิดีโอเฟรมจำนวน 100 เฟรมภาพ พบว่า ค่าความถูกต้องในการตรวจจับหอยทากยักษ์แอฟริกันมีค่าเท่ากับ 74.15% ค่าความถูกต้องในการตรวจจับหอยทากสยามมีค่าเท่ากับ 64.08% ค่าเฉลี่ยของความถูกต้องของทั้งสองคลาสมีค่าเท่ากับ 69.11% และค่าความแม่นยำเฉลี่ยเท่ากับ 97.31% จากการวิเคราะห์สาเหตุที่ทำให้ค่าความถูกต้อง ในการตรวจจับยังมีไม่มากเพียงพอ ผู้วิจัยคาดว่าสาเหตุดังนี้



รูปที่ 12. หน้าจอการทำงานบางส่วนของโมบายล์แอปพลิเคชันระบบต้นแบบการตรวจจับหอยทากบกในแปลงผักทดลอง โดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X

1) ภาพที่ใช้ในการฝึกที่นำมาจากอินเทอร์เน็ตมีความคมชัด เห็นลวดลายและรูปแบบการเวียนของเปลือกหอยอย่างชัดเจน แต่ในการทดสอบกับสถานการณ์จริง เปลือกหอยหาคายามอาจจะถูกปกคลุมด้วยดินหรือทราย แสดงดังรูปที่ 1(ข) โดยเฉพาะอย่างยิ่งกับหอยหาคายามตัวเล็กที่เป็นสาเหตุทำให้ระบบไม่สามารถตรวจจับได้ แสดงดังหอยหาคายามตัวที่อยู่ด้านบนสุดของรูปที่ 13



รูปที่ 13. ตัวอย่างขนาดของหอยหาคายามที่มีขนาดยังไม่โตเต็มวัยทางด้านซ้ายของภาพจำนวน 2 ตัว ซึ่งเกาะอยู่บนใบไม้แห้ง เปรียบเทียบกับหอยหาคายามที่โตเต็มวัยทางด้านขวาของภาพที่แสดงให้เห็นรูปแบบการเวียนของเปลือกหอยอย่างชัดเจน หมายเหตุ ภาพนี้ถูกถ่ายในเวลาประมาณ 17.30 น. โดยใช้สมาร์ทโฟนที่มีความละเอียดในการเก็บภาพมากกว่ากล้องเว็บแคมที่ใช้ในงานวิจัยนี้ และปรับแสงในการถ่ายภาพเพื่อให้สามารถสังเกตเห็นหอยหาคายามตัวเล็กที่อยู่ด้านซ้ายของภาพ

2) สถานการณ์จริงในแปลงผักทดลอง สีของหอยหาคายามกลืนกับสีของผัก หรือหอยหาคายามบางตัวอาจจะเกาะอยู่ตามซอกหลืบหรือร่องของใบผักที่ทำให้กล้องไม่สามารถตรวจจับตัวหอยได้ แสดงดังรูปที่ 11 โดยเฉพาะหอยหาคายามที่ยังไม่โตเต็มวัยซึ่งมีขนาดเล็กและมีรูปแบบการเวียนของเปลือกหอยไม่ชัดเจน แสดงดังรูปที่ 13

3) กล้องที่ใช้ในระบบเป็นกล้องเว็บแคมที่มีความละเอียดเท่ากับ $1,280 \times 720$ พิกเซล เมื่อนำมาใช้งานจริงในแปลงผักทดลองที่ระยะความสูงระหว่างตัวหอยกับความสูงของกล้องประมาณ 50-60 ซม. ทำให้ภาพที่ได้รับจากกล้องเว็บแคมที่ใช้ในระบบมีความคมชัดไม่ดีเท่ากับภาพที่ใช้ในการฝึกโมเดล แสดงภาพที่ได้จากกล้องเว็บแคมดังรูปที่ 11

4) เมื่อทำการทดสอบระบบในช่วงกลางวันที่มีแสงน้อยที่ไม่มีแสงจ้าจากดวงอาทิตย์ และไม่มีฝนตกในแปลงผัก (เนื่องจากผู้วิจัยต้องป้องกันอุปกรณ์ไอโอทีไม่ให้โดนน้ำฝนเพื่อป้องกันอุปกรณ์เสียหาย) โดยไม่ได้เปิดไฟแอลอีดี พบว่า ระบบสามารถตรวจจับหอยหาคายามได้เฉพาะหอยหาคายามแอฟริกัน อย่างไรก็ตามเนื่องจากกรณีเช่นนี้จะเกิดขึ้นไม่บ่อยเนื่องจากหอยหาคายามเป็นสัตว์ที่หากินในช่วงกลางคืนหรือในช่วงฝนตก (Panha et al., 2009) ทำให้ผู้วิจัยมีข้อมูลเพื่อสรุปผลการตรวจจับแยกตามสภาพแสงไม่เพียงพอ

4. สรุปผลการวิจัย

ในงานวิจัยนี้ผู้วิจัยนำเสนอระบบต้นแบบเพื่อตรวจจับหอยหาคายามในแปลงผักทดลองโดยใช้การเรียนรู้เชิงลึกด้วยแบบจำลอง YOLOv10-X ผลการวิจัยแสดงให้เห็นว่า ระบบตรวจจับที่นำเสนอในงานวิจัย

นี้ให้ค่าความถูกต้องในการตรวจจับหอยทากยักษ์แอฟริกันเท่ากับ 74.15% ค่าความถูกต้องในการตรวจจับหอยทากสยามเท่ากับ 64.08% ค่าเฉลี่ยของความถูกต้องของทั้งสองคลาสมีค่าเท่ากับ 69.11% และค่าความแม่นยำเฉลี่ยในการตรวจจับของทั้ง 2 คลาสเท่ากับ 97.31%

งานวิจัยนี้ผู้วิจัยเลือกใช้แบบจำลอง YOLOv10-X ที่มีเอกสารสนับสนุนว่าเป็นโมเดลสำหรับการตรวจจับวัตถุในแบบเรียลไทม์ที่ให้ความแม่นยำสูง และใช้พารามิเตอร์น้อยกว่าแบบจำลอง YOLO หลายเวอร์ชันก่อนหน้านี้

ในอนาคตผู้วิจัยจะปรับปรุงกล้องที่ใช้ในการตรวจจับให้มีความละเอียดและคมชัดมากขึ้น รวมถึงปรับปรุงกระบวนการต่าง ๆ เช่น การเตรียมข้อมูลให้มากขึ้นเพื่อให้ได้โมเดลที่แม่นยำ เพื่อให้ได้รับค่าความถูกต้องในการตรวจจับเพิ่มขึ้น ผู้วิจัยคาดหวังว่าระบบต้นแบบเพื่อตรวจจับหอยทากบกในแปลงผักทดลองที่นำเสนอthisจะเป็นประโยชน์สำหรับผู้สนใจ โดยเฉพาะอย่างยิ่งในการทำฟาร์มอัจฉริยะ (Smart farm) ที่กำลังเป็นที่นิยมเพิ่มมากขึ้นในปัจจุบัน

เอกสารอ้างอิง (References)

- Ahmad, I., Yang, Y., Yue, Y., Ye, C., Hassan, M., Cheng, X., Wu, Y., & Zhang, Y. (2022). Deep learning based detector YOLOv5 for identifying insect pests. *Applied Sciences*, 12(19), Article 10167. <https://doi.org/10.3390/app121910167>
- Ansari, S. (2023). *Building computer vision applications using artificial neural networks: With examples in OpenCV and TensorFlow with Python* (2nd ed.). Apress.
- Bento, J., Paixão, T., & Alvarez, A. B. (2025). Performance evaluation of YOLOv8, YOLOv9, YOLOv10, and YOLOv11 for stamp detection in scanned documents. *Applied Sciences*, 15(6), Article 3154. <https://doi.org/10.3390/app15063154>
- Dumidae, A., Janthu, P., Subkrasae, C., Pumidonming, W., Dekumyoy, P., Thanwisai, A., & Vitta, A. (2020). Genetic analysis of *Cryptozonia Siamensis* (stylommatophora, ariophantidae) populations in Thailand using the mitochondrial 16S rRNA and COI sequences. *PLOS ONE*, 15(9), Article e0239264. <https://doi.org/10.1371/journal.pone.0239264>
- Hussain, M., & Khanam, R. (2024). In-depth review of YOLOv1 to YOLOv10 variants for enhanced photovoltaic defect detection. *Solar*, 4(3), 351-386. <https://doi.org/10.3390/solar4030016>
- Kongim, B. (2008). Land snails: invertebrates that play a role in human life. *Advanced Science Journal*, 2, 1-6. (in Thai)
- Kumar, P. (2020). A review-on molluscs as an agricultural pest and their control. *International Journal of Food Science and Agriculture*, 4(4), 383-389. <https://doi.org/10.26855/ijfsa.2020.12.004>

- Li, Q., & Qiu, L. (2024). A snail species identification method based on deep learning in food safety. *Mathematical Biosciences and Engineering*, 21(3), 3652-3667.
<https://doi.org/10.3934/mbe.2024161>
- Lu, Y., Zhang, L., & Xie, W. (2020). YOLO-compact: An efficient YOLO network for single category real-time object detection. *Proceedings of the 2020 Chinese Control and Decision Conference (CCDC)* (pp. 1931-1936). IEEE.
<https://doi.org/10.1109/CCDC49329.2020.9164580>
- Nelson, S. (2012). *Injuries caused by the giant African snail to papaya* [Report No. MP-6]. University of Hawaii, College of Tropical Agriculture and Human Resources.
<https://www.ctahr.hawaii.edu/oc/freepubs/pdf/MP-6.pdf>
- Panha, S., Sutcharit, C., Tongkerd, P., & Naggs, F. (2009, June). *An illustrated guide to Thai land snails*. NSTDA. <https://www.nstda.or.th/brt/images/book/146.pdf> (in Thai)
- Poonkuntran, S., Dhanraj, R. K., & Balusamy, B. (2022). *Object detection with deep learning models: Principles and applications* (1st ed.). Chapman & Hall/CRC Press.
- Rintarak, D., Karnchananitipat, N., Iamsuwansuk, A., & Kaewta, S. (2017). *Species diversity of terrestrial pest snails in agricultural ecosystem and environment in Thailand* [Annual Research Report]. Plant Protection Research and Development Office, Department of Agriculture. (in Thai)
- Sikka, B. (2021). *Elements of deep learning for computer vision* (1st ed.). BPB Publications.
- Siriwechviriya, P. (2020). The application of loop-mediated isothermal amplification technique for epidemic detection of *angiostrongylus cantonensis* in land snails. *Thai Journal of Public Health*, 50(1), 37-46.
- Sutcharit C., & Panha S. (2008). *Land snails in Khao Nan National Park* (1st ed.). Biodiversity Research and Training Program (BRT Project), Bangkok. (in Thai)
- Wang, A., Chen, H., Liu, L., Chen, K., Lin, Z., Han, J., & Ding, G. (2024). YOLOv10: Real-time end-to-end object detection. *arXiv*, Article 2405.14458.
<https://arxiv.org/abs/2405.14458>
- Wang, Z., Lee, I., Tie, Y., Cai, J., & Qi, L. (2018). Real-world field snail detection and tracking. *Proceedings of the 2018 15th International Conference on Control, Automation, Robotics and Vision (ICARCV)* (pp. 1703-1708). IEEE.
<https://doi.org/10.1109/ICARCV.2018.8581271>