

การตรวจจับผีเสื้อหนอนเจาะเมล็ดทุเรียนในสกุล *Mudaria* ด้วยการเรียนรู้เชิงลึกโมเดล YOLOv4-Tiny สำหรับระบบเฝ้าระวังศัตรูพืชอัจฉริยะ

Detection of Durian Seed Borer Moths (*Mudaria* spp.) Using YOLOv4-Tiny Deep Learning Model for Smart Pest Surveillance System

พัชรพร โคกอุ้น¹, พรเทพ เชื่อมสุข¹, อนุสรณ์ เชื้อสามารถ², อิศเรศ กะการดี², สิริวดี พรหมน้อย³, กิรติ ตันเรือน⁴, วรนาถ โคกเย็น⁵, ศุภณัฐ ยุทธะนันท์⁶ และพิสิษฐ์ พูลประเสริฐ^{1*}

Phatcharaphon Khokaun¹, Porntap Chamsuk¹, Anusorn Chueasamat², Isared Kakarndee², Siriwadee Promnoi³, Keerati Tanruean⁴, Woranad Khokyen⁵, Suphanat Yuktanun⁶ and Pisit Poolprasert^{1*}

Received date: 2 มี.ค. 69 Revised date: 16 พ.ค. 69 Accepted date: 2 มิ.ย. 69

DOI: <https://doi.org/10.55003/kmaj.2026.270878>

บทคัดย่อ

ผีเสื้อหนอนเจาะเมล็ดทุเรียน (*Mudaria* spp.) เป็นศัตรูพืชสำคัญที่สร้างความเสียหายรุนแรงต่อการส่งออกทุเรียนไทย เนื่องจากตัวอ่อนกัดกินภายในเมล็ดทำให้ยากต่อการตรวจพบ การพัฒนาระบบเฝ้าระวังตัวเต็มวัยที่แม่นยำจึงเป็นหัวใจสำคัญของการจัดการศัตรูพืชเชิงบูรณาการ งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการเรียนรู้เชิงลึกด้วย YOLOv4-tiny สำหรับตรวจจับผีเสื้อหนอนเจาะเมล็ดทุเรียน เพื่อใช้เป็นเครื่องมือในระบบเฝ้าระวังศัตรูพืชอัจฉริยะ การศึกษาดำเนินการฝึกสอนแบบจำลองด้วยชุดข้อมูลภาพที่ผ่านกระบวนการเพิ่มจำนวนข้อมูล จนมีจำนวนทั้งหมด 6,437 ภาพ และประเมินผลด้วยชุดข้อมูลทดสอบ 332 ภาพ แบ่งเป็น 3 กรณี ได้แก่ (1) ชุดภาพจากสภาพจริง (2) ชุดภาพจากฐานข้อมูล iNaturalist และ (3) ชุดภาพรวมทั้งหมด โดยกำหนดค่าความเชื่อมั่นที่ร้อยละ 85 และประเมินด้วยตัวชี้วัด Accuracy, Precision, Recall และ F1-score ผลการศึกษพบว่าแบบจำลอง YOLOv4-tiny มีประสิทธิภาพสูงยิ่งในการตรวจจับตัวเต็มวัยของ *Mudaria* spp. โดยในการทดสอบทั้ง 3 กรณี ไม่พบการตรวจจับผิดพลาด (False Positive = 0) ส่งผลให้ค่า Precision เท่ากับ 1.000 ในทุกชุดข้อมูล สำหรับชุดภาพจากสภาพจริงให้ค่า Accuracy และ Recall ที่ 0.920 ขณะที่ชุดภาพจาก iNaturalist ให้ประสิทธิภาพสูงสุดสมบูรณ์ในทุกตัวชี้วัด (1.000) ส่วนชุดภาพรวมทั้งหมดมีค่า Accuracy 0.958 และ F1-score 0.979 ผลการวิจัยสรุปได้ว่าแบบจำลองที่พัฒนาขึ้นมีศักยภาพสูงในการจำแนกแมลงเป้าหมายท่ามกลางสภาพแวดล้อมที่แตกต่างกัน และสามารถนำไปบูรณาการร่วมกับแพลตฟอร์มดิจิทัลเพื่อการแจ้งเตือนล่วงหน้าและการจัดการศัตรูพืชเชิงรุกในสวนทุเรียนเชิงพาณิชย์ได้อย่างมีประสิทธิภาพ

คำสำคัญ: ผีเสื้อหนอนเจาะเมล็ดทุเรียน การเรียนรู้เชิงลึก การเฝ้าระวังศัตรูพืช การตรวจจับจากภาพถ่าย

Abstract

The durian seed borer moth (*Mudaria* spp.) is a major insect pest causing significant damage to Thai durian exports. Timely and accurate surveillance is essential for effective integrated pest management. This study developed an image-based detection model using the YOLOv4-tiny deep learning architecture and evaluated its potential for smart surveillance systems across different data sources. The model was trained on 6,437 augmented images and evaluated using a test dataset of 332 images, categorized into three cases: (1) field-collected reference images, (2) images from the iNaturalist database, and (3) a combined dataset. A confidence threshold of over 85% was applied, with performance measured via Accuracy, Precision, Recall, and F1-score. The results demonstrated that YOLOv4-tiny effectively detected adult *Mudaria* spp. moths. Due to the absence of false detections (False Positive = 0), the model achieved a Precision of 1.000 across all cases. The reference dataset yielded an Accuracy and Recall of 0.920, while the iNaturalist dataset achieved perfect

¹ ภาควิชากีฏวิทยา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร 10900

² ภาควิชาเกษตรกลวิธาน คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร 10900

³ สาขาวิชาชีววิทยา คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏอุตรดิตถ์ อุดรดิตถ์ 53000

⁴ สาขาวิชาชีววิทยา คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏพิบูลสงคราม พิษณุโลก 65000

⁵ กองส่งเสริมการอารักขาพืชและจัดการดินปุ๋ย กรมส่งเสริมการเกษตร กรุงเทพมหานคร 10900

⁶ สำนักพัฒนาการเรียนรู้ตลอดชีวิต มหาวิทยาลัยเกษตรศาสตร์ กรุงเทพมหานคร 10900

¹ Department of Entomology, Faculty of Agriculture, Kasetsart University, Bangkok 10900

² Department of Farm Mechanics, Faculty of Agriculture, Kasetsart University, Bangkok 10900

³ Biology Program, Faculty of Science and Technology, Uttaradit Rajabhat University, Uttaradit 53000

⁴ Biology Program, Faculty of Science and Technology, Pibulsongkram Rajabhat University, Phitsanulok 65000

⁵ Plant Protection and Soil Fertility Promotion Division, Department of Agricultural Extension, Bangkok 10900

⁶ Lifelong Learning Development Office, Kasetsart University, Bangkok 10900

* Corresponding author: pisit.pool@ku.th

performance (1.000) across all metrics. The combined dataset reached an Accuracy of 0.958 and an F1-score of 0.979. In conclusion, the YOLOv4-tiny model exhibits high potential as a surveillance tool and can be integrated with digital platforms to support early warning systems and proactive pest management in commercial durian orchards.

Keywords: durian seed borer moth, deep learning, pest surveillance, image-based detection

คำนำ

ประเทศไทยเป็นประเทศเกษตรกรรมที่พึ่งพาพืชเศรษฐกิจเป็นแหล่งรายได้หลัก อย่างไรก็ตาม การผลิตทางการเกษตรยังคงประสบปัญหาการสูญเสียผลผลิตจากแมลงศัตรูพืชอย่างมีนัยสำคัญ โดยคิดเป็นร้อยละ 10–30 และในบางกรณีอาจสูงถึงร้อยละ 40 ของผลผลิตทั้งหมด ส่งผลกระทบโดยตรงต่อรายได้ของเกษตรกร ความมั่นคงทางอาหาร และความยั่งยืนของระบบการผลิต (Kongchai and Sombat, 2025; Teixeira et al., 2023) ปัญหาดังกล่าวยิ่งทวีความรุนแรงขึ้นภายใต้แรงกดดันจากการเปลี่ยนแปลงสภาพภูมิอากาศและความจำเป็นในการลดผลกระทบต่อสิ่งแวดล้อมและความหลากหลายทางชีวภาพ (Høye et al., 2021) แม้จะมีการส่งเสริมการจัดการศัตรูพืชแบบแม่นยำและการจัดการศัตรูพืชแบบผสมผสาน แต่ในทางปฏิบัติ เกษตรกรส่วนใหญ่ยังคงอาศัยการสำรวจด้วยสายตาซึ่งมีข้อจำกัดด้านความแม่นยำ ใช้เวลานาน และขึ้นอยู่กับประสบการณ์เฉพาะบุคคล ส่งผลให้เกิดการใช้สารกำจัดศัตรูพืชในวงกว้างเกินความจำเป็น เพิ่มต้นทุนการผลิต ก่อให้เกิดสารตกค้างในสิ่งแวดล้อม และเร่งการพัฒนาความต้านทานของแมลงต่อสารเคมี (Chagkornburee and Chaiklieng, 2026; Supamattra et al., 2023)

ในช่วงไม่กี่ปีที่ผ่านมา เทคโนโลยีปัญญาประดิษฐ์โดยเฉพาะการเรียนรู้เชิงลึก ได้รับการนำมาประยุกต์ใช้อย่างแพร่หลายในการพัฒนาระบบเฝ้าระวังศัตรูพืชอัจฉริยะ โดยแบบจำลองในกลุ่มโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNNs) สามารถเรียนรู้ลักษณะเฉพาะของแมลงจากข้อมูลภาพได้โดยอัตโนมัติ และให้ความแม่นยำสูงกว่าวิธีการประมวลผลภาพแบบดั้งเดิม (Lou et al., 2022; Teixeira et al., 2023; Wang et al., 2020) อย่างไรก็ตาม งานทบทวนล่าสุดชี้ให้เห็นว่ายังคงมีความท้าทายสำคัญในการจำแนกแมลงที่มีลักษณะใกล้เคียงกัน รวมถึงข้อจำกัดด้านการนำแบบจำลองไปใช้งานจริงในภาคสนามซึ่งจำเป็นต้องเลือกใช้แบบจำลองที่มีขนาดเล็ก มีประสิทธิภาพในการประมวลผลแบบเรียลไทม์ และสามารถทำงานบนอุปกรณ์ที่มีทรัพยากรจำกัดได้อย่างเหมาะสม (Akila et al., 2026; Ejaz et al., 2025) แม้เทคโนโลยีการตรวจจับวัตถุจะก้าวหน้าไปมาก แต่ยังไม่ปรากฏงานวิจัยที่มุ่งเน้นกลุ่มเป้าหมายอย่างผีเสื้อในสกุล *Mudaria* spp. หรือมีการพิสูจน์ความแม่นยำท่ามกลางกลุ่มแมลงที่มีลักษณะคล้ายคลึงกันในสภาพธรรมชาติ ข้อจำกัดนี้ถือเป็นช่องว่างสำคัญที่ผู้วิจัยมุ่งหวังจะเติมเต็ม เพื่อสร้างบรรทัดฐานใหม่ในการตรวจวิเคราะห์ศัตรูพืชที่มีความเฉพาะเจาะจงสูง

ทุเรียน (*Durio zibethinus* L.) เป็นพืชเศรษฐกิจที่มีมูลค่าการส่งออกสูงสุดของประเทศไทย โดยเฉพาะในปี พ.ศ. 2568 (Chamsuk et al., 2026; Rukkasikorn et al., 2025) อย่างไรก็ตาม การผลิตทุเรียนยังคงเผชิญกับปัญหาจากผีเสื้อหนอนเจาะเมล็ดทุเรียนในสกุล *Mudaria* ซึ่งเป็นศัตรูพืชสำคัญที่สร้างความเสียหายรุนแรง โดยตัวเต็มวัยจะวางไข่บริเวณผลทุเรียน และเมื่อฟักเป็นตัวหนอนจะเจาะเข้าไปกัดกินสะสมอาหารอยู่ภายในเมล็ดทุเรียนจนกระทั่งเข้าสู่ระยะดักแด้ การเข้าทำลายในลักษณะนี้ส่งผลให้ผลผลิตเสียคุณภาพและไม่สามารถส่งออกได้ เนื่องจากตรวจหาความผิดปกติจากภายนอกได้ยากจนกว่าจะมีการผ่าผล (Chamsuk et al., 2026) ผีเสื้อกลุ่มนี้ยังมีลักษณะสัณฐานวิทยาคล้ายคลึงกับผีเสื้อกลางคืนชนิดอื่นในธรรมชาติ ทำให้การจำแนกชนิดในภาคสนามทำได้ยากและมักเกิดความคลาดเคลื่อน ดังนั้น งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการเรียนรู้เชิงลึก YOLOv4-Tiny สำหรับการตรวจจับผีเสื้อหนอนเจาะเมล็ดทุเรียน (*Mudaria* spp.) จากภาพถ่าย โดยใช้ภาพตัวอย่างอ้างอิงจากพิพิธภัณฑ์แมลงร่วมกับภาพจากฐานข้อมูลออนไลน์ iNaturalist เพื่อเสริมสร้างความสามารถของแบบจำลองในการเรียนรู้ลักษณะทางสัณฐานวิทยาที่ถูกต้องและลดความคลาดเคลื่อนในการจำแนกชนิด แบบจำลองที่พัฒนาขึ้นนี้มียุทธศาสตร์ในการประยุกต์ใช้เป็นเครื่องมือสนับสนุนการตัดสินใจเพื่อเฝ้าระวังศัตรูพืชได้อย่างแม่นยำ ซึ่งจะช่วยให้เกษตรกรทราบสถานะการระบาดที่แท้จริงและกำหนดจังหวะเวลาในการจัดการศัตรูพืชได้อย่างตรงจุด ลดการฉีดพ่นสารเคมีแบบครอบคลุมตามปฏิทิน (calendar spraying) ที่เกินความจำเป็น อันเป็นแนวทางสำคัญของการจัดการศัตรูพืชแบบผสมผสาน (IPM) และนำไปสู่ความยั่งยืนของระบบการผลิตทุเรียนในประเทศไทยได้อย่างเป็นรูปธรรม

วิธีการศึกษา

แหล่งข้อมูลและการรวบรวมข้อมูล

ชุดข้อมูลภาพเริ่มต้นแบ่งออกเป็น 2 แหล่งหลัก ได้แก่ 1) ภาพถ่ายตัวอย่างอ้างอิงจากพิพิธภัณฑ์แมลง จำนวน 175 ภาพ และ 2) ภาพจากฐานข้อมูลสาธารณะ iNaturalist (สัญญาอนุญาต CC-BY-NC) จำนวน 157 ภาพ รวมทั้งสิ้น 332 ภาพ (Figure 1a) นอกจากนี้ได้จัดเตรียมภาพทดสอบอิสระ (independent test set) จำนวน 4 ภาพ เพื่อประเมิน

ประสิทธิภาพของแบบจำลองในสถานการณ์นอกชุดข้อมูลฝึก ทั้งนี้ เพื่อป้องกันความเสี่ยงจากการรั่วไหลของข้อมูล (data leakage) คณะผู้วิจัยได้ดำเนินการแยกชุดข้อมูลภาพต้นฉบับ (original images) ออกเป็นส่วนๆ ก่อนการเพิ่มจำนวนข้อมูล โดยภาพที่นำมาใช้เป็นชุดทดสอบ (test set) จะไม่มีส่วนเกี่ยวข้องหรือถูกนำไปผ่านกระบวนการเพิ่มจำนวนเพื่อใช้เป็นชุดฝึกสอน (training set) โดยเด็ดขาด

การเตรียมตัวอย่างและการบันทึกภาพ

ตัวอย่างตัวเต็มวัยของผีเสื้อหนอนเจาะเมล็ดทุเรียน (*Mudaria* spp.) ได้รับความอนุเคราะห์จากภาควิชาชีววิทยา คณะเกษตร มหาวิทยาลัยเกษตรศาสตร์ โดยทำการบันทึกภาพด้วยแอปพลิเคชัน Lumina บนชุดอุปกรณ์ที่ควบคุมสภาวะแสงให้คงที่ (Figure 1b) บันทึกภาพในมุมมองด้านบน (dorsal view) และมุมเอียง (oblique view) เพื่อให้ครอบคลุมลักษณะสัณฐานวิทยาสำคัญที่ใช้ในการระบุชนิด โดยกำหนดค่าการถ่ายภาพคงที่ประกอบด้วย ความยาวโฟกัส 52 มม. ความเร็วชัตเตอร์ 1/200 วินาที ค่าความไวแสง ISO 50 อุณหภูมิสี 5,600 K และระบบโฟกัสอัตโนมัติที่ระดับ 0.6 เพื่อรักษาความสม่ำเสมอของชุดข้อมูล

การเตรียมชุดข้อมูลและการเพิ่มจำนวนข้อมูล

การติดป้ายกำกับภาพ (image annotation) ดำเนินการบนแพลตฟอร์ม CiRA CORE (version 1.9.4) โดยใช้กล่องเครื่องมือ DeepTrain แล็บเครื่องมือ Labeling เพื่อกำหนดขอบเขตวัตถุ (bounding box) และใช้เครื่องมือการเพิ่มข้อมูล (data augmentation) เพื่อเพิ่มความทนทานของแบบจำลองต่อความแปรผันของข้อมูล (Figures 1c-1d) ประกอบด้วยการหมุนภาพ 90 องศา ความเปรียบต่างของภาพ (contrast) สัญญาณรบกวนในภาพ (noise) และการปรับความคมชัด (blur) ส่งผลให้มีจำนวนภาพสำหรับใช้ฝึกสอนรวมทั้งสิ้น 6,437 ภาพ




Figure 1 Overview of the research methodology, a: sample preparation and image sources, including museum reference specimens and images from iNaturalist, b: image acquisition from reference samples using the Lumina application under a fixed lighting control setup, c: dataset preparation and data augmentation procedures, illustrating different augmentation operations (AO) and d: model development and training using the YOLOv4-Tiny architecture on the CiRA CORE platform (version 1.9.4), including data augmentation settings with image rotation at 90° intervals, as well as noise and blur generation, and transfer learning from pre-trained weights.

การพัฒนาแบบจำลองและการฝึกสอน

การพัฒนาแบบจำลองตรวจจับผีเสื้อหนอนเจาะเมล็ดทุเรียนดำเนินการโดยใช้สถาปัตยกรรม YOLOv4-Tiny ภายใต้สภาพแวดล้อมของแพลตฟอร์ม CiRA CORE การฝึกสอนแบบจำลองทั้งหมดดำเนินการบนเครื่องคอมพิวเตอร์ระดับผู้ใช้ทั่วไปที่ใช้หน่วยประมวลผล Intel® Core™ i5 หน่วยความจำหลักขนาด 16 GB และอุปกรณ์จัดเก็บข้อมูลแบบ SSD

ภายใต้ระบบปฏิบัติการ Windows 11 โดยใช้การประมวลผลผ่านหน่วยประมวลผลกลาง (CPU) เป็นหลักเพื่อทดสอบความเป็นไปได้ในการใช้งานบนอุปกรณ์ทั่วไปที่ไม่มีหน่วยประมวลผลกราฟิก (GPU) แยก ซึ่งใช้เวลาในการฝึกสอน (training time) ประมาณ 18-24 ชั่วโมง และมีความเร็วในการพยากรณ์ภาพ (inference time) เฉลี่ย 0.5–1.0 วินาทีต่อภาพ นอกจากนี้ได้ประยุกต์ใช้หลักการถ่ายโอนการเรียนรู้ (transfer learning) จากค่าน้ำหนักที่ผ่านการฝึกสอนล่วงหน้า (pre-trained weights) ดังแสดงใน Figure 1d

กำหนดพารามิเตอร์หลักในการฝึกสอน ได้แก่ อัตราการเรียนรู้ (learning rate) ในช่วง 0.001–0.01 ขนาดกลุ่มข้อมูล (batch size) 64 จำนวนรอบการเรียนรู้ (iterations) มากกว่า 5,000 รอบ ค่าโมเมนตัม (momentum) 0.9 และค่า weight decay เท่ากับ 0.0005 ทั้งนี้ได้มีการกำหนดให้ระบบแสดงค่า Average Loss และตรวจสอบค่าความแม่นยำในระหว่างการฝึกสอนเพื่อทำหน้าที่เป็น Validation Monitoring ในการเฝ้าระวังปัญหาการเรียนรู้เกิน (overfitting) โดยกำหนดค่าความเชื่อมั่น (confidence threshold) ที่ระดับร้อยละ 85 เพื่อเพิ่มความแม่นยำในการตรวจจับแมลงเป้าหมาย

การประเมินประสิทธิภาพและการวิเคราะห์ผล

การประเมินประสิทธิภาพของแบบจำลองจำแนกผีเสื้อกลางคืนสกุล *Mudaria* ดำเนินการทดสอบใน 3 กรณี เพื่อครอบคลุมความหลากหลายของข้อมูลและทดสอบความสามารถในการขยายผลของแบบจำลอง (generalization) ได้แก่ 1) ชุดภาพตัวอย่างอ้างอิง (reference images), 2) ชุดภาพจากฐานข้อมูลสาธารณะ inaturalist และ 3) ชุดภาพรวมทั้งชุดคณะผู้วิจัยตระหนักถึงข้อจำกัดของชุดทดสอบหลักที่ประกอบด้วยภาพแมลงเป้าหมาย (positive samples) เป็นสำคัญ ซึ่งอาจทำให้ค่า Accuracy และ Recall มีความสัมพันธ์เชิงคณิตศาสตร์ที่ใกล้เคียงกัน อย่างไรก็ตาม ได้มีการเสริมความน่าเชื่อถือด้วยการทดสอบภาพอิสระภายนอกและภาพแมลงที่มีลักษณะทางสัณฐานวิทยาใกล้เคียงกัน (morphologically similar species) เพื่อประเมินค่าผลบวกหลวง (false positive)

ตัวชี้วัดที่ใช้ประเมินเป็นตัวชี้วัดมาตรฐานที่ได้รับการยอมรับในระดับสากล (Grandini et al., 2020) ประกอบด้วย ค่า Accuracy (Eq. 1), Precision (Eq. 2), Recall (Eq. 3) และ F1-score (Eq. 4) โดยวิเคราะห์ผ่าน confusion matrix เพื่อจำแนกรายละเอียดการพยากรณ์ในแต่ละคลาส (Sokolova and Lapalme, 2009) และได้ทำการวิเคราะห์ค่าการสูญเสียเฉลี่ย (average loss) เพื่อประเมินเสถียรภาพในการเรียนรู้ รวมถึงทดสอบเพื่อพิสูจน์ขีดความสามารถของแบบจำลองในการจำแนกความแตกต่างเชิงสัณฐานในระดับละเอียด (fine-grained classification) ซึ่งเป็นหัวใจสำคัญในการระบุชนิดแมลงศัตรูพืชทางการเกษตร

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

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

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

$$F1 - score = \frac{2(Precision \times Recall)}{Precision + Recall} \quad (Eq.4)$$

โดยที่

TP (True Positive) คือ ภาพที่มีแมลงเป้าหมายและแบบจำลองตรวจจับได้ถูกต้อง

FP (False Positive) คือ ภาพที่ไม่มีแมลงเป้าหมายแต่แบบจำลองตรวจจับผิดว่าเป็นแมลงเป้าหมาย

FN (False Negative) คือ ภาพที่มีแมลงเป้าหมายแต่แบบจำลองไม่สามารถตรวจจับได้

TN (True Negative) คือ ภาพที่ไม่มีแมลงเป้าหมายและแบบจำลองพยากรณ์ได้ถูกต้อง

นอกจากนี้ ได้ทำการวิเคราะห์ค่าการสูญเสียเฉลี่ย (Average loss) เพื่อประเมินเสถียรภาพในการเรียนรู้ และทดสอบกับกลุ่มภาพแมลงที่มีลักษณะทางสัณฐานวิทยาใกล้เคียงกัน (Morphologically similar species) เพื่อพิสูจน์ขีดความสามารถของแบบจำลองในการจำแนกความแตกต่างเชิงสัณฐานในระดับละเอียด (Fine-grained classification) ซึ่งเป็นหัวใจสำคัญในการระบุชนิดแมลงศัตรูพืชทางการเกษตร

จริยธรรมการวิจัย

การศึกษาวิจัยครั้งนี้ดำเนินการตามหลักจริยธรรมสากลอย่างเคร่งครัด โดยใช้ข้อมูลภาพจาก 2 แหล่งหลัก ได้แก่ ภาพถ่ายจากตัวอย่างอ้างอิงในพิพิธภัณฑ์ และชุดข้อมูลภาพสาธารณะจากฐานข้อมูล iNaturalist (2025) (<https://www.inaturalist.org/>) ซึ่งใช้งานภายใต้สัญญาอนุญาตแบบ creative commons (CC-BY-NC) ที่ถูกต้องตามกฎหมายลิขสิทธิ์ คณะผู้วิจัยขอรับรองว่าการดำเนินงานไม่มีการทดลองหรือกระทำการใดๆ ที่ก่อให้เกิดอันตรายต่อ

สิ่งมีชีวิตโดยตรง ตลอดจนได้ยึดถือหลักความโปร่งใสในการให้เครดิตแหล่งที่มาของข้อมูล (Data attribution) และตั้งอยู่บนพื้นฐานความเป็นธรรมในการใช้ข้อมูลเพื่อประโยชน์เชิงวิชาการและการพัฒนาเทคโนโลยีการเกษตร เพื่อให้บรรลุวัตถุประสงค์ในการปกป้องและจัดการศัตรูพืชอย่างมีประสิทธิภาพ

ผลการศึกษาและวิจารณ์

ประสิทธิภาพของชุดข้อมูลต่อการเรียนรู้พื้นฐานวิทยาแมลง

จากการพัฒนาแบบจำลอง YOLOv4-Tiny ด้วยชุดข้อมูลภาพผีเสื้อหนอนเจาะเมล็ดทุเรียน (*Mudaria* spp.) จำนวนรวม 332 ภาพ ซึ่งประกอบด้วยภาพถ่ายอ้างอิงจากพิพิธภัณฑ์และภาพจากฐานข้อมูลสาธารณะ iNaturalist พบว่าแบบจำลองสามารถเรียนรู้ลักษณะทางสัณฐานวิทยาของแมลงเป้าหมายได้อย่างมีประสิทธิภาพ เมื่อพิจารณาจากกราฟการฝึกฝน พบว่าที่ รอบการทำซ้ำ (iteration) ที่ 5,222 ค่าการสูญเสียเฉลี่ย (average loss) ลดลงและคงที่อยู่ที่ 0.1942 ซึ่งแสดงถึงความแม่นยำและความเสถียรในการระบุตำแหน่ง (localization) และการจำแนกชนิดแมลง (classification) ทั้งนี้ แม้ในการศึกษานี้จะไม่ได้แสดงแผนภูมิเส้นความสูญเสีย (training loss curve) เป็นรูปภาพประกอบ แต่จากบันทึกการฝึกสอนพบว่า ค่าความสูญเสียมีแนวโน้มลดลงอย่างรวดเร็วในช่วง 1,000 รอบแรก และเริ่มเข้าสู่จุดอิ่มตัว (convergence) ตั้งแต่ช่วงรอบการเรียนรู้ที่ 4,500 จนกระทั่งคงที่ในระดับต่ำสุดที่รอบที่ 5,222 สภาวะการเรียนรู้ที่ราบเรียบและไม่มีการแกว่งตัวรุนแรงในช่วงท้ายนี้ ยืนยันได้ว่าแบบจำลองไม่มีปัญหาการเรียนรู้เกิน (overfitting) นอกจากนี้ เมื่อทดสอบบนหน่วยประมวลผลกลาง (CPU) ระดับผู้ใช้ทั่วไป พบว่ามีระยะเวลาในการพยากรณ์ภาพ (inference time) เฉลี่ยเพียง 0.5–1.0 วินาทีต่อภาพ ซึ่งแสดงให้เห็นถึงประสิทธิภาพเชิงคำนวณ (computational feasibility) ที่เหมาะสมกับการใช้งานจริงจากการทดสอบแสดงให้เห็นว่าโมเดล YOLOv4-Tiny สามารถตรวจจับผีเสื้อหนอนเจาะเมล็ดทุเรียน (*Mudaria* spp.) ได้อย่างถูกต้อง โดยผลการตรวจจับจากแบบจำลองแสดงให้เห็นว่า YOLOv4-Tiny สามารถระบุชนิดผีเสื้อหนอนเจาะเมล็ดทุเรียนจากแหล่งข้อมูลที่แตกต่างกันได้อย่างมีประสิทธิภาพ ดังแสดงใน Figure 2 โดยแบบจำลองสามารถตรวจจับตัวอย่างอ้างอิงจากพิพิธภัณฑ์ชนิด *Mudaria stahlgrestchae* ได้ด้วยค่าความเชื่อมั่นร้อยละ 98 (Figure 2a) และตรวจจับตัวอย่างภาคสนามจากฐานข้อมูล iNaturalist ในระดับชนิด (*Mudaria* spp.) ได้ด้วยค่าความเชื่อมั่นร้อยละ 99 (Figure 2b) สะท้อนถึงความสามารถของแบบจำลองในการเรียนรู้ลักษณะทางสัณฐานวิทยาที่คงที่แม้ข้อมูลมาจากบริบทที่ต่างกัน ผลดังกล่าวสอดคล้องกับรายงานของ Teixeira et al. (2023) และ Lou et al. (2022) ที่ระบุว่าแบบจำลองในกลุ่ม YOLO เมื่อได้รับข้อมูลที่มีคุณภาพและมีความหลากหลายเชิงสัณฐาน สามารถเรียนรู้ลักษณะเชิงลึกของแมลงได้อย่างมีประสิทธิภาพ แม้ใช้สถาปัตยกรรมแบบน้ำหนักเบา (Lightweight model) ผลการศึกษานี้สนับสนุนแนวทางของ Wan and Wang (2025) ที่ในการใช้โมเดลน้ำหนักเบาเพื่อลดภาระการประมวลผลแต่ยังคงรักษาความแม่นยำไว้ได้ ซึ่งจำเป็นต่อการใช้งานในอุปกรณ์ที่มีทรัพยากรจำกัด ประสิทธิภาพที่แข็งแกร่ง (robustness) ในสภาพแวดล้อมที่ซับซ้อนนี้ยังสอดคล้องกับงานของ Pang et al. (2022) และ Song et al. (2023) โดยมีกลไกสำคัญคือการบูรณาการคุณลักษณะหลายมาตราส่วน (Multi-scale feature integration) ตามที่ Deng et al. (2025) ได้นำเสนอไว้ ส่งผลให้ YOLOv4-Tiny มีความทนทานต่อการจำแนกเป้าหมายที่มีความแปรผันของข้อมูลสูงได้เป็นอย่างดี

นอกจากนี้ ผลการประเมินประสิทธิภาพ (Table 1) แสดงให้เห็นว่าแบบจำลองมีค่า Recall สูงถึง 0.958 สำหรับชุดข้อมูลรวม และ 1.000 สำหรับชุดข้อมูลจาก iNaturalist โดยมีค่า Precision เท่ากับ 1.000 ในทุกชุดข้อมูล ผลลัพธ์ดังกล่าวชี้ให้เห็นว่าการบูรณาการภาพตัวอย่างอ้างอิงที่มีความคมชัดและควบคุมสภาพการถ่ายภาพ ร่วมกับภาพจากสภาพแวดล้อมจริงที่มีความหลากหลาย ช่วยเสริมศักยภาพของแบบจำลองในการเรียนรู้ความแปรผันของลักษณะสัณฐานวิทยาได้อย่างครอบคลุม ซึ่งเป็นประเด็นสำคัญที่ Høye et al. (2021) และ Wang et al. (2020) ระบุว่าเป็นหัวใจของการพัฒนาแบบจำลองตรวจจับแมลงในสภาพจริง




Figure 2 Examples of *Mudaria* detection results using the YOLOv4-Tiny model, a: reference specimen of *Mudaria stahlgretschae* obtained from a museum collection, correctly detected with a confidence score of 98% and b: field image of *Mudaria* spp. sourced from the iNaturalist database, detected with a confidence score of 99%

Table 1 Performance metrics of the model evaluated on three image datasets

Dataset	TP	FP	FN	TN	Accuracy	Precision	Recall	F1-Score
Reference images (175 images)	161	0	14	0	0.920	1.000	0.920	0.958
iNaturalist images (157 images)	157	0	0	0	1.000	1.000	1.000	1.000
Combined dataset (332 images)	318	0	14	0	0.958	1.000	0.958	0.979

TP (True Positive): Images that contain the target insect and were correctly detected by the model, **FP (False Positive):** Images that do not contain the target insect but were incorrectly predicted as positive by the model, **FN (False Negative):** Images that contain the target insect but were not detected by the model and **TN (True Negative):** Images that do not contain the target insect and were correctly predicted as negative by the model.

การวิเคราะห์ประสิทธิภาพเปรียบเทียบและขีดความสามารถเชิงคำนวณ

เมื่อพิจารณาประสิทธิภาพของแบบจำลอง YOLOv4-Tiny ที่พัฒนาขึ้นเปรียบเทียบกับงานวิจัยที่เกี่ยวข้องและสถาปัตยกรรมโครงข่ายอื่น (Table 2) พบว่าแบบจำลองในการศึกษานี้ให้ค่าความแม่นยำ (Accuracy) ที่ร้อยละ 95.8 ซึ่งอยู่ในระดับที่สูงกว่างานวิจัยของ Teixeira et al. (2023) และ Wang et al. (2020) ที่ศึกษาในแมลงเกษตรชนิดอื่น นอกจากนี้เมื่อเปรียบเทียบในแง่ของทรัพยากรที่ใช้ในการประมวลผล พบว่า YOLOv4-Tiny มีความโดดเด่นด้านประสิทธิภาพเชิงคำนวณ (computational feasibility) โดยสามารถทำความเร็วในการพยากรณ์ภาพ (inference speed) บนหน่วยประมวลผลกลาง (CPU) ได้อย่างรวดเร็ว (0.5–1.0 วินาที) เมื่อเทียบกับแบบจำลองขนาดใหญ่อย่าง YOLOv4 (Full) ที่ต้องใช้ทรัพยากรสูงกว่า 3–5 เท่า ผลลัพธ์นี้ยืนยันว่าสถาปัตยกรรมที่เลือกใช้มีความสมดุล (trade-off) ระหว่างความแม่นยำและความคล่องตัวในการใช้งานจริงภาคสนามได้ดีที่สุด

Table 2 Comparative analysis of model performance and computational requirements against related studies and alternative architecture

Research Study / Model	Target Group	Accuracy (%)	F1-Score	Inference Speed (CPU)	Hardware Requirement
This Study (YOLOv4-Tiny)	<i>Mudaria</i> spp.	95.8	0.979	0.5–1.0 sec	Low (CPU Friendly)
Teixeira et al. (2023) / YOLOv4	General Pests	92.5	0.910	>2.5 sec	High (Requires GPU)
Wang et al. (2020) / SSD MobileNet	Field Insects	89.4	0.880	<0.5 sec	Very Low
Yang et al. (2023) / Maize-YOLO	Maize Pests	94.1	0.935	0.8–1.2 sec	Moderate

Inference speed for the proposed model was evaluated on an Intel® Core™ i5 processor with 16 GB RAM without GPU acceleration. Performance data for other studies are based on reported benchmarks in their respective agricultural monitoring contexts.

ผลการประเมินประสิทธิภาพด้วยชุดข้อมูลอิสระและการประยุกต์ใช้ในงานอารักขาพืช

เพื่อให้ทราบถึงขีดความสามารถของแบบจำลองในการประเมินสถานะจริงที่ไม่เคยปรากฏในชุดฝึกสอน (unseen data) คณะผู้วิจัยได้ทำการทดสอบด้วยชุดข้อมูลอิสระจำนวน 4 ภาพ ประกอบด้วยภาพตัวอย่างอ้างอิงจริงของแมลงในสกุล *Mudaria* spp. (Figures 3a-3b) และภาพแมลงชนิดใกล้เคียงที่มีลักษณะคล้ายคลึงกัน (non-target lookalikes) ในวงศ์ Drepanidae (Figures 3c-3d)

จากการวิเคราะห์ผลผ่าน Confusion Matrix และตัวชี้วัดประสิทธิภาพ พบว่าแบบจำลองสามารถจำแนกแมลงเป้าหมายได้ถูกต้องทั้งหมด (TP = 2) และไม่มีความผิดพลาดในการปล่อยปลະเลยแมลงเป้าหมาย (FN = 0) ดังแสดงใน Table 3 ส่งผลให้ค่า Recall มีค่าเท่ากับ 1.000 อย่างไรก็ตาม ในกลุ่มแมลงชนิดใกล้เคียง แบบจำลองสามารถปฏิเสธภาพที่ไม่ใช่เป้าหมายได้ถูกต้อง 1 ภาพ (TN = 1) แต่มีการจำแนกผิดพลาดว่าเป็นแมลงเป้าหมาย 1 ภาพ (FP = 1) ส่งผลให้ค่า Precision อยู่ที่ 0.667 และค่า F1-score อยู่ที่ 0.800 ตามลำดับ ค่า Recall ที่สูงและเสถียรภาพในการระบุตำแหน่งสอดคล้องกับผลการศึกษาของ Yang et al. (2023) ในการพัฒนา *Maize-YOLO* ที่ระบุว่าแบบจำลองตระกูล YOLO มีความโดดเด่นในการตรวจจับศัตรูพืชแบบเรียลไทม์ (real-time detection) แม้ในสถานะที่มีปัจจัยรบกวนในแปลงปลูกจริง ซึ่งยืนยันศักยภาพของ YOLOv4-Tiny ในฐานะเครื่องมือเฝ้าระวังศัตรูพืชเชิงรุก แม้จะมีค่า Recall ที่สมบูรณ์ แต่การเกิดผลบวกปลอม (false positive) ในกลุ่มแมลงที่มีลักษณะคล้ายคลึงกัน (lookalikes) สะท้อนถึงความท้าทายสำคัญของการจำแนกในระดับชนิด (species-level identification) ประเด็นนี้สอดคล้องกับข้อสังเกตของ Ejaz et al. (2025) และ Feng et al. (2025) ที่ชี้ว่าลวดลายปีกและโครงสร้างร่างกายที่ใกล้เคียงกันในกลุ่มแมลงขนาดเล็กมักก่อให้เกิดความสับสนต่อแบบจำลองได้ง่าย การลดลงของค่า Precision และ F1-score เมื่อเผชิญกับข้อมูลที่ไม่เคยเห็นมาก่อน (Unseen Data) สอดคล้องกับงานของ Grandini et al. (2020) และ Powers (2011) ที่ระบุว่าตัวชี้วัดเหล่านี้มีความไวต่อความผิดพลาดแบบ false positive ในชุดข้อมูลที่มีความยากสูง เพื่อแก้ไขข้อจำกัดดังกล่าว จึงจำเป็นต้องอาศัยการเพิ่มข้อมูลภาพกลุ่ม non-target ในการฝึกฝน เพื่อยกระดับความสามารถในการจำแนกรายละเอียดเชิงลึก (fine-grained classification) ตามแนวทางที่ Wu et al. (2019) ได้เสนอไว้ในชุดข้อมูลมาตรฐาน IP102




Figure 3 Examples of images used for independent validation, a: *M. stahlgretschae* (Actual Positive - Corrected detected), b: *M. minor* (Actual Positive - Corrected detected), c: *Thyatira batis* (Actual Negative - Incorrectly predicted as *Mudaria* due to similar wing patterns characterized by light-colored circular spots on a dark brownish background, which mimics the key morphological features of the target species), and d: *Horithyatira decorata* (Actual Negative - Corrected rejected)

Table 3 Confusion matrix of the YOLOv4-Tiny model evaluated using an independent validation dataset

Ground truth	Predicted Positive	Predicted Negative
Actual Positive	TP = 2	FN = 0
Actual Negative	FP = 1	TN = 1

TP (true positive): Images that contain the target insect and were correctly detected by the model, FP (false positive): Images that do not contain the target insect but were incorrectly predicted as positive by the model, FN (false negative): Images that contain the target insect but were not detected by the model and TN (true negative): Images that do not contain the target insect and were correctly predicted as negative by the model.

การวิเคราะห์เชิงสัณฐานวิทยาของกรณีผลบวกปลอม (Figure 3c) พบว่าแมลงนอกกลุ่มเป้าหมายมีรูปร่างปีกและลวดลายสีที่ใกล้เคียงกับ *Mudaria* spp. ซึ่งเป็นข้อจำกัดที่พบได้ทั่วไปในการตรวจจับแมลงกลุ่ม Lepidoptera โดยเฉพาะชนิดที่มีการปรับตัวด้านการพรางตัวสูง อย่างไรก็ตาม จากการตรวจสอบเชิงอนุกรมวิธานพบว่าแมลงดังกล่าวเป็น *Thyatira batis* ซึ่งจัดอยู่ในวงศ์ Drepanidae โดยมีลักษณะบางประการที่แตกต่างจาก *Mudaria* spp. ได้แก่ รูปร่างปีกคู่หน้าที่แคบกว่า ลวดลายปีกที่มีความคมชัดของเส้นสีขาวต่ำกว่า และท่าทางการพักรงที่ไม่ปรากฏลักษณะเป็นรูปสามเหลี่ยมกระชับอย่างเด่นชัด เช่นเดียวกับ *Horithyatira decorata* ซึ่งแม้จะมีลวดลายปีกคล้ายคลึงกัน แต่ขาดเส้นสีขาวที่ตัดกับพื้นหลังสีเข้มอย่างชัดเจนเมื่อเทียบกับ *Mudaria* spp. ความท้าทายดังกล่าวสอดคล้องกับข้อสังเกตจากงานทบทวนของ Ejaz et al. (2025) ซึ่งระบุถึงความคล้ายคลึงของลวดลายปีกและโครงสร้างร่างกายเป็นหนึ่งในอุปสรรคหลักของการจำแนกศัตรูพืชด้วยเทคนิคการเรียนรู้เชิงลึก โดยเฉพาะในกรณีของแมลงขนาดเล็กและชุดข้อมูลฝึกสอนที่มีความหลากหลายจำกัด นอกจากนี้ ผลการศึกษายังสอดคล้องกับรายงานของ Akila et al. (2026) ที่ชี้ให้เห็นว่าการเพิ่มความหลากหลายของข้อมูลภาพในด้านมุมมอง ท่าทางของปีก และสภาพแสง มีบทบาทสำคัญในการลดความสับสนระหว่างชนิดที่มีความใกล้เคียงทางสัณฐานวิทยา และสามารถช่วยเพิ่มความแม่นยำของแบบจำลองเมื่อนำไปประยุกต์ใช้ในสภาพแวดล้อมจริง

อย่างไรก็ตาม ในบริบทของการจัดการศัตรูพืช (pest management) การที่แบบจำลองแสดงค่า Recall สูงถึง 1.000 มีนัยสำคัญอย่างยิ่งต่อ ระบบเฝ้าระวังล่วงหน้า (early warning system) เนื่องจากการตรวจพบที่เกินมา (over-detection) ยังมีความเสี่ยงและความเสียหายน้อยกว่าการตรวจไม่พบศัตรูพืชจริง (under-detection) ซึ่งอาจนำไปสู่การระบาดรุนแรงได้ ผลการศึกษานี้สอดคล้องกับแนวคิดของ Kongchai and Sombat (2025) และ Supamattra et al. (2023) ที่ชี้ว่าการใช้เทคโนโลยี deep learning สามารถลดความคลาดเคลื่อนจากการสำรวจด้วยสายตามนุษย์ และช่วยสนับสนุนการตัดสินใจเชิงรุกในงานอารักขาพืชได้อย่างมีประสิทธิภาพ ยิ่งไปกว่านั้น การเลือกใช้สถาปัตยกรรม YOLOv4-Tiny ที่ซึ่งมีความเร็วในการประมวลผลและใช้ทรัพยากรต่ำ ยังเอื้อต่อการนำไปประยุกต์ใช้ร่วมกับอุปกรณ์ปลายทางหรือระบบกับดักอัจฉริยะในภาคสนามได้จริง ซึ่งเป็นองค์ประกอบสำคัญของการจัดการศัตรูพืชเชิงแม่นยำ (precision pest management) ผลลัพธ์ดังกล่าวสนับสนุนการเปลี่ยนผ่านจากการฉีดพ่นสารเคมีแบบครอบคลุมตามรอบเวลา (calendar spraying) ไปสู่การจัดการศัตรูพืชตามข้อมูลการตรวจพบจริง ซึ่งช่วยลดต้นทุน ลดผลกระทบต่อสิ่งแวดล้อม และสอดคล้องกับแนวทางการผลิตตามมาตรฐานการปฏิบัติทางการเกษตรที่ดี (GAP) และการเกษตรอย่างยั่งยืนในระยะยาวตามรายงานของ Chagkornburee and Chaiklieng (2026) ตอกย้ำถึงทิศทางที่ Høye et al. (2021) ได้ทำนายไว้ว่า การประมวลผลเรขาคณิตภาพ (computer vision; CV) จะกลายเป็นเครื่องมือหลักในการปฏิบัติงานด้านกีฏวิทยาและยกระดับการเกษตรอัจฉริยะในอนาคต การยกระดับโครงสร้างพื้นฐานด้านการอารักขาพืชนี้ สอดคล้องกับแนวคิดของ Deng et al. (2025) ที่ระบุหัวใจสำคัญของ "การป้องกันพืชอัจฉริยะ" (intelligent plant protection) คือความสามารถในการบูรณาการข้อมูลเพื่อการบริหารจัดการเชิงพื้นที่ ซึ่งสอดคล้องกับแนวทางการพัฒนาของ Yang et al. (2023) และ Wan and Wang (2025) ที่ให้ความสำคัญกับการลดช่องว่างระหว่างงานวิจัยในห้องปฏิบัติการกับการนำไปใช้จริงในภาคเกษตรกรรมยุคใหม่ ในระยะยาว การสะสมข้อมูลการตรวจพบผ่านระบบอัตโนมัติเช่นนี้จะนำไปสู่การสร้าง "ฐานข้อมูลขนาดใหญ่ด้านศัตรูพืช" (pest big data) ที่ช่วยให้สามารถพยากรณ์ช่วงเวลาการระบาดล่วงหน้าได้อย่างแม่นยำภายใต้สภาวะภูมิอากาศที่เปลี่ยนแปลงท้ายที่สุด นวัตกรรมนี้จะเป็นพื้นฐานสำคัญในการยกระดับขีดความสามารถในการแข่งขันของผลไม้ไทยในตลาดโลกผ่านการใช้เทคโนโลยีที่ยั่งยืนและตรวจสอบได้ ซึ่งถือเป็นการขับเคลื่อนอุตสาหกรรมการเกษตรไทยสู่ยุคเกษตรกรรม 4.0 อย่างเป็นรูปธรรม

แม้แบบจำลองจะแสดงประสิทธิภาพในระดับที่น่าพึงพอใจ แต่ข้อจำกัดสำคัญที่พบคือการระบุผิดพลาดในลักษณะผลบวกปลอม (false positive) โดยเฉพาะในกลุ่มแมลงที่มี สัณฐานวิทยาภายนอก (external morphology) ใกล้เคียงกับแมลงเป้าหมาย ซึ่งถือเป็นจุดวิกฤตที่ต้องได้รับการพัฒนาต่ออย่างอดผ่านแนวทางหลัก 2 ประการ ได้แก่ ประการแรก คือการเสริมสร้างความทนทานของแบบจำลอง (enhancing model robustness) โดยการเพิ่มชุดข้อมูลภาพในกลุ่มแมลงลักษณะคล้ายคลึง (lookalike species) และภาพถ่ายจากกับดักแสงไฟ (light trap) ในสภาพแวดล้อมจริง เพื่อฝึกฝนให้แบบจำลองมีความทนทานต่อความแปรผันของสภาวะแสง สี และมุมมองที่ซับซ้อนในภาคสนาม และประการที่สอง คือ

การปรับใช้ในระดับพกพาผ่านเทคโนโลยีประมวลผลปลายทาง (edge computing) โดยแนวทางในอนาคตควรเน้นการติดตั้งแบบจำลองบนอุปกรณ์ edge devices เพื่อให้เกษตรกรสามารถติดตามสถานการณ์การระบาดของผีเสื้อหนอนเจาะเมล็ดทุเรียนได้แบบเรียลไทม์ผ่านสมาร์ทโฟน ซึ่งจะเป็นการยกระดับนวัตกรรมการอารักขาพืชสู่ระบบ เกษตรอัจฉริยะ (smart farming) อย่างเป็นรูปธรรมและยั่งยืน

อย่างไรก็ตาม คณะผู้วิจัยขอระบุข้อจำกัดสำคัญของการประเมินประสิทธิภาพด้วยชุดข้อมูลอิสระ (independent validation) ในการศึกษา ซึ่งประกอบด้วยภาพทดสอบจำนวน 4 ภาพ แม้ผลการทดสอบเบื้องต้นจะแสดงค่า Recall ที่สมบูรณ์ แต่จำนวนกลุ่มตัวอย่างที่จำกัดนี้ยังไม่มีนัยสำคัญทางสถิติเพียงพอที่จะนำไปสรุปผลครอบคลุมประสิทธิภาพของแบบจำลองในภาพรวมหรือสภาวะประชากรแมลงในธรรมชาติที่มีความแปรผันสูงได้ ความผิดพลาดแบบผลบวกปลอม (false positive) ที่พบเพียงหนึ่งรายการส่งผลกระทบต่อค่า Precision และ F1-score อย่างมากในเชิงสัดส่วน ดังนั้น ผลการประเมินในส่วนนี้จึงเป็นเพียงการทดสอบความเป็นไปได้ (feasibility test) และการวิเคราะห์แนวโน้มความผิดพลาดเชิงสถิติฐานวิทยาในเบื้องต้นเพื่อเป็นแนวทางในการปรับปรุงแบบจำลองเท่านั้น โดยในงานวิจัยขั้นต่อไปจำเป็นต้องมีการขยายขนาดชุดข้อมูลทดสอบให้มีความหลากหลายและจำนวนที่มากขึ้น เพื่อยืนยันเสถียรภาพและความแม่นยำของแบบจำลองตามหลักสถิติที่เข้มงวดยิ่งขึ้น

สรุปผลการศึกษา

การศึกษานี้ประสบความสำเร็จในการพัฒนาแบบจำลอง YOLOv4-Tiny เพื่อตรวจจับผีเสื้อหนอนเจาะเมล็ดทุเรียน (*Mudaria* spp.) โดยแบบจำลองที่ฝึกฝนด้วยชุดข้อมูลบูรณาการให้ค่าความแม่นยำ (Accuracy) และความระลึก (Recall) สูงถึง 0.958 ซึ่งพิสูจน์ให้เห็นว่าสถาปัตยกรรมนำหนักเบาสามารถเรียนรู้ลักษณะสัญญาณวิทยาที่ซับซ้อนได้อย่างมีประสิทธิภาพภายใต้ข้อจำกัดด้านปริมาณข้อมูล จุดเด่นของงานวิจัยนี้คือค่า Recall ที่สมบูรณ์ (1.000) จากการทดสอบด้วยชุดข้อมูลอิสระ ซึ่งเป็นกลไกสำคัญสำหรับระบบเฝ้าระวังศัตรูพืชล่วงหน้า (early warning system) เพื่อลดความเสี่ยงจากการระบาดได้อย่างแม่นยำ นอกจากนี้ แบบจำลองดังกล่าวยังมีศักยภาพในการขยายผลเพื่อใช้เป็นต้นแบบในการตรวจจับแมลงศัตรูพืชชนิดอื่นที่มีลักษณะสัญญาณวิทยาใกล้เคียงกัน หรือแมลงในกลุ่ม Lepidoptera ที่มีความสำคัญทางเศรษฐกิจชนิดอื่น ๆ ต่อไป

แม้จะมีข้อจำกัดเรื่องผลบวกปลอม (false positive) ในกลุ่มแมลงที่มีลักษณะคล้ายคลึงกันและข้อจำกัดด้านนัยสำคัญทางสถิติจากชุดข้อมูลทดสอบที่มีขนาดเล็ก คณะผู้วิจัยได้วางแนวทางการพัฒนาในอนาคต (future work) ไว้อย่างเป็นรูปธรรมได้แก่ 1) การเพิ่มชุดข้อมูลภาพแมลงกลุ่มใกล้เคียง (negative samples) เพื่อฝึกฝนให้แบบจำลองมีความสามารถในการจำแนกรายละเอียดเชิงลึก (fine-grained classification) ที่ดียิ่งขึ้น 2) การทดสอบและปรับปรุงแบบจำลองในสภาพแวดล้อมภาคสนามจริงที่มีความแปรผันของแสงและสภาพพื้นที่ในสวนทุเรียน (field-testing under diverse lighting conditions) และ 3) การพัฒนาต่อยอดโดยใช้สถาปัตยกรรมตรวจจับวัตถุรุ่นที่ทันสมัยกว่า เช่น YOLOv8 หรือรุ่นที่ใหม่กว่า เพื่อเปรียบเทียบประสิทธิภาพและความเร็วในการประมวลผลบนอุปกรณ์พกพา

กิตติกรรมประกาศ

การวิจัยนี้ได้รับทุนสนับสนุนส่วนหนึ่งจาก สำนักงานการวิจัยแห่งชาติ (วช.) ประจำปีงบประมาณ 2569 สัญญาเลขที่ N21A690684 คณะผู้วิจัยขอขอบพระคุณเจ้าหน้าที่พิพิธภัณฑสถานแห่งชาติ ภาควิชากีฏวิทยา คณะเกษตรมหาวิทยาลัยเกษตรศาสตร์ และผู้เชี่ยวชาญทุกท่านที่ให้ความอนุเคราะห์ข้อมูลภาพถ่ายและตัวอย่างอ้างอิง ตลอดจนผู้ที่มีส่วนเกี่ยวข้องทุกท่านที่ช่วยให้งานวิจัยและการจัดเตรียมเอกสารสำเร็จลุล่วงด้วยดี

การมีส่วนร่วมในการเขียนบทความของผู้เขียน

ความคิดริเริ่ม (Idea) และสมมติฐาน: พิสิษฐ์ พูลประเสริฐ, พัทธพร โคกอุ่น. การปฏิบัติการวิจัย การมีส่วนร่วมในการออกแบบ การทดลอง การทดสอบ เครื่องมือวัด วิธีการเก็บข้อมูล และ criteria: พัทธพร โคกอุ่น, พรเทพ เชื่อมสุข, อนุสรณ์ เชื้อสามารถ, อิศเรศ กะการดี, สิริวิดี พรหมน้อย, กิรติ ต้นเรือน การจัดเก็บข้อมูล การวิเคราะห์ข้อมูล และการแปลผล: พัทธพร โคกอุ่น, พิสิษฐ์ พูลประเสริฐ การวิพากษ์วิจารณ์ผล การแสดง การเปรียบเทียบกับข้อสรุปหรือองค์ความรู้หรือทฤษฎีเดิม: พัทธพร โคกอุ่น, พิสิษฐ์ พูลประเสริฐ, อิศเรศ กะการดี, สิริวิดี พรหมน้อย การมีส่วนร่วมในการเขียน Manuscript ผลงานสร้างสรรค์ นวัตกรรม สิ่งประดิษฐ์: พัทธพร โคกอุ่น, พรเทพ เชื่อมสุข, อนุสรณ์ เชื้อสามารถ, อิศเรศ กะการดี, สิริวิดี พรหมน้อย, กิรติ ต้นเรือน, วรนาฏ โคกเย็น, ศุภณัฐ ยุกตะนันท์, พิสิษฐ์ พูลประเสริฐ

ผลประโยชน์ทับซ้อน

ผู้เขียนขอประกาศว่าบทความนี้ไม่มีผลประโยชน์ทับซ้อน

เอกสารอ้างอิง

- Akila, M., Kumar, N. K., & Vishnu, K. (2026). Real-time pest detection and identification system using deep learning. **International Journal of Advanced Research in Science, Communication and Technology**, 6(5), 8–15. <https://doi.org/10.48175/IJARSCT-31902>.
- Chagkornburee, C., & Chaiklieng, S. (2026). Pesticide poisoning linked to PPE usage among pesticide sprayers in Northeastern Thailand. **Journal of Applied Toxicology**, 46(7), 2544–2555. <https://doi.org/10.1002/jat.70042>.
- Chamsuk, P., Wannachart, K., Khokyen, W., Pudchinnun, K., Klangpahol, P., Klinpet, A., Sangtongpraow, B., & Poolprasert, P. (2026). Integrative taxonomy, seasonal phenology, and sex pheromone profiling of the durian seed borer (*Mudaria stahlgretschae*) for enhanced pest monitoring. **Diversity**, 18(5), 284. <https://doi.org/10.3390/d18050284>.
- Deng, L., Fang, D., Ullah, A., Hou, Q., & Yu, H. (2025). AMS-YOLO: multi-scale feature integration for intelligent plant protection against maize pests. **Frontiers in Plant Science**, 16(1), 1640405. <https://doi.org/10.3389/fpls.2025.1640405>.
- Ejaz, M. H., Bilal, M., Habib, U., Attique, M., & Chung, T. S. (2025). **Crop Pest Classification using Deep Learning Techniques: A Review**. Retrieved from: <https://doi.org/10.48550/arXiv.2507.01494>.
- Feng, Z., Shi, R., Jiang, Y., Han, Y., Ma, Z., & Ren, Y. (2025). SPD-YOLO: A Method for Detecting Maize Disease Pests Using Improved YOLOv7. **Computers, Materials & Continua**, 84(2), 3559–3575. <https://doi.org/10.32604/cmc.2025.065152>.
- Grandini, M., Bagli, E., & Visani, G. (2020). **Metrics for Multi-class Classification: An Overview (Version 1)**. Retrieved from: <https://arxiv.org/abs/2008.05756>.
- Høye, T. T., Årje, J., Bjerre, K., Hansen, O. L. P., Iosifidis, A., Leese, F., Mann, H. M. R., Meissner, K., Melvad, C., & Raitoharju, J. (2021). Deep learning and computer vision will transform entomology. **Proceedings of the National Academy of Sciences of the United States of America**, 118(2), e2002545117. <https://doi.org/10.1073/pnas.2002545117>.
- iNaturalist. (2025). **Connection with Nature**. Retrieved from: <https://www.inaturalist.org>.
- Kongchai, P., & Sombat, W. (2025). Pest classification from photographs using deep learning pre-trained models: A case study in Ubon Ratchathani province. **Journal of Science and Science Education (JSSE)**, 8(1), 168–179. (in Thai).
- Lou, L., Liu, J., Yang, Z., Zhou, X., & Yin, Z. (2022). Agricultural pest detection based on improved yolov5. In **Proceedings of the 2022 6th International Conference on Computer Science and Artificial Intelligence**, pp. 7–12. Association for Computing Machinery. <https://doi.org/10.1145/3577530.3577532>.
- Pang, H., Zhang, Y., Cai, W., Li, B., & Song, R. (2022). A real-time object detection model for orchard pests based on improved YOLOv4 algorithm. **Scientific Reports**, 12(1), 13783. <https://doi.org/10.1038/s41598-022-17826-4>.
- Powers, D. M. W. (2011). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness and correlation. **International Journal of Machine Learning Technology**, 2(1), 37–63. <https://doi.org/10.48550/arXiv.2010.16061>.
- Rukkasikorn, A., Chaovalit, S., Dokchan, P., Ratanamahamaneekorn, K., Ruangsuk, K., & Poolprasert, P. (2025). Diversity of moths in the genus *Mudaria* Moore, 1893 (Lepidoptera: Noctuidae) and their impact on durian production in Thailand. In **Proceedings of the 16th National Plant Protection Conference**, pp. 49–66. Chiang Mai, Thailand. (in Thai).
- Sokolova, M., & Lapalme, G. (2009). A systematic analysis of performance measures for classification tasks. **Information Processing & Management**, 45(4), 427–437. <https://doi.org/10.1016/j.ipm.2009.03.002>.
- Song, L., Liu, M., Liu, S., Wang, H., & Luo, J. (2023). Pest species identification algorithm based on improved YOLOv4 network. **Signal, Image and Video Processing**, 17(1), 3127–3134. <https://doi.org/10.1007/s11760-023-02534-x>.
- Supamattra, S., Sayasoonthorn, S., & Chueasamat, A. (2023). Study of impurities detection in frozen spinach with YOLOv4 deep learning model. **Thai Interdisciplinary and Sustainability Review**, 12(2), 131–144. <https://doi.org/10.14456/tisr.2023.12>. (in Thai).
- Teixeira, A. C., Ribeiro, J., Morais, R., Sousa, J. J., & Cunha, A. (2023). A systematic review on automatic insect detection using deep learning. **Agriculture**, 13(3), 713. <https://doi.org/10.3390/agriculture13030713>.
- Wan, H., & Wang, S. (2025). Weed detection in cornfields based on improved lightweight neural network model. **Alexandria Engineering Journal**, 122(1), 334–343. <https://doi.org/10.1016/j.aej.2025.03.016>.
- Wang, Q. J., Zhang, S. Y., Dong, S. F., Zhang, G. C., Yang, J., Li, R., & Wang, H. Q. (2020). Pest24: A large-scale very small object data set of agricultural pests for multi-target detection. **Computers and Electronics in Agriculture**, 175(1), 105585. <https://doi.org/10.1016/j.compag.2020.105585>.
- Wu, X., Zhan, C., Lai, Y. K., Cheng, M. M., & Yang, J. (2019). IP102: A large-scale benchmark dataset for insect pest recognition. In **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**, pp. 8779–8788.
- Yang, S., Xing, Z., Wang, H., Dong, X., Gao, X., Liu, Z., Zhang, X., Li, S., & Zhao, Y. (2023). Maize-YOLO: A new high-precision and real-time method for maize pest detection. **Insects**, 14(3), 278. <https://doi.org/10.3390/insects14030278>.