



Pest Insect Classification from Photographic Images Using Pre-Trained Deep Learning Models: A Case Study in Ubon Ratchathani Province

Phaichayon Kongchai¹ and Wichit Sombat^{1*}

¹*Department of Mathematics, Statistics and Computer, Faculty of Science, Ubon Ratchathani University, Ubon Ratchathani*

**Email: wicit.s@ubu.ac.th*

Received <18 December 2024>; Revised <10 February 2025>; Accepted <17 February 2025>

Abstract

This research aims to compare the performance of pre-trained deep learning models, namely MobileNetV2, ResNet50, and VGG19, with traditional machine learning algorithms, including Random Forest, Support Vector Machine (SVM), and Logistic Regression (LR), in classifying images of 10 pest insect species that impact key economic crops in Ubon Ratchathani Province. A dataset consisting of 4,875 images was utilized for this study. The research methodology involved feature extraction using pre-trained deep learning models, followed by training traditional algorithms with the extracted features. The experiments were conducted under a supervised learning framework, with parameter settings kept constant to ensure fair comparisons. The results showed that feature extraction with MobileNetV2 combined with Logistic Regression achieved the best performance, yielding the highest accuracy of 0.898 and an F1-Score of 0.869. This study highlights the potential of integrating deep learning techniques with traditional algorithms as an effective approach for improving classification tasks. Such integration can play a pivotal role in enhancing agricultural sustainability and efficiency in the future.

Keywords: Deep Learning; Image Classification; Pre-trained Models; Pest Insects; Sustainable Agriculture

การจำแนกแมลงศัตรูพืชจากภาพถ่าย โดยใช้แบบจำลองที่ผ่านการฝึกสอนล่วงหน้าด้วยการเรียนรู้เชิงลึก : กรณีศึกษาในจังหวัดอุบลราชธานี

ไพชยนต์ คงไชย¹ และ วิชิต สมบัติ^{1,*}

¹ภาควิชาคณิตศาสตร์ สถิติ และคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี จังหวัดอุบลราชธานี

*Email: wichit.s@ubu.ac.th

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกที่ผ่านการฝึกสอนล่วงหน้า ได้แก่ อัลกอริทึม MobileNetV2 อัลกอริทึม ResNet50 และอัลกอริทึม VGG19 กับอัลกอริทึมการเรียนรู้แบบดั้งเดิม ได้แก่ อัลกอริทึม Random Forest อัลกอริทึม Support Vector Machine และอัลกอริทึม Logistic Regression ในการจำแนกภาพถ่ายแมลงศัตรูพืช 10 ชนิด ซึ่งส่งผลกระทบต่อพืชเศรษฐกิจหลักในจังหวัดอุบลราชธานี โดยใช้ข้อมูลภาพจำนวน 4,875 ภาพ กระบวนการวิจัยประกอบด้วยการสกัดคุณลักษณะจากแบบจำลองที่ผ่านการฝึกสอนล่วงหน้า เพื่อนำไปฝึกกับอัลกอริทึมแบบดั้งเดิม การทดลองดำเนินการภายใต้กรอบการเรียนรู้แบบมีผู้สอน พร้อมการควบคุมค่าพารามิเตอร์ให้คงที่เพื่อความยุติธรรมในการเปรียบเทียบ ผลการวิจัยพบว่าการสกัดคุณลักษณะด้วยอัลกอริทึม MobileNetV2 แล้วนำไปสร้างแบบจำลองจำแนกประเภทข้อมูลด้วยอัลกอริทึม Logistic Regression ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่าความถูกต้องสูงสุดที่ 0.898 และ F1-Score สูงสุดที่ 0.869 การศึกษานี้เน้นให้เห็นถึงศักยภาพของการผสานเทคนิคการเรียนรู้เชิงลึกกับอัลกอริทึมแบบดั้งเดิม ซึ่งเป็นแนวทางสำคัญในการเพิ่มประสิทธิภาพและความยั่งยืนของการเกษตรในอนาคต

คำสำคัญ: การเรียนรู้เชิงลึก; การจำแนกภาพ; การฝึกสอนล่วงหน้า; แมลงศัตรูพืช; การเกษตรยั่งยืน

บทนำ

จังหวัดอุบลราชธานีเป็นหนึ่งในพื้นที่สำคัญด้านการเกษตรของประเทศไทยที่มีการเพาะปลูกพืชเศรษฐกิจหลายชนิด เช่น ข้าว มันสำปะหลัง ข้าวโพด มะพร้าว และยางพารา ผลผลิตทางการเกษตรในพื้นที่มักประสบปัญหาจากแมลงศัตรูพืชที่สร้างความเสียหายอย่างมาก (The Government Public Relations Department, 2024) ทั้งในแง่ปริมาณและคุณภาพ ตัวอย่างของความเสียหายได้แก่ การกัดกินใบพืชจนเสียรูป การทำลายลำต้นที่ส่งผลต่อกระบวนการดูดซึมน้ำอาหาร และการขัดขวางกระบวนการสังเคราะห์แสงผ่านการทำลายเนื้อเยื่อใบ ซึ่งทั้งหมดนี้ล้วนเป็นอุปสรรคต่อการเพิ่มผลผลิต การจัดการแมลงศัตรูพืชด้วยสารเคมีเป็นวิธีที่ได้รับความนิยมในหมู่เกษตรกรเนื่องจากความสะดวกรวดเร็วและประสิทธิภาพสูง แต่การใช้สารเคมีก่อให้เกิดปัญหาด้านสุขภาพหลายประการ เช่น การลดจำนวนแมลงที่เป็นประโยชน์ การสะสมของสารเคมีในดินและแหล่งน้ำ ซึ่งส่งผลกระทบต่อสุขภาพของผู้ปฏิบัติงานและผู้บริโภค (Chagkornburee and Chaiklieng, 2024) ดังนั้น แนวทางการควบคุมแมลงศัตรูพืชที่เป็นมิตรต่อสิ่งแวดล้อมจึงเป็นที่ต้องการมากขึ้น แม้ว่าจะมีข้อจำกัดในด้านประสิทธิภาพ ตัวอย่างหนึ่งของแนวคิดนี้คือการใช้ศัตรูธรรมชาติ ซึ่งได้รับการยอมรับว่าเป็นแนวทางที่ช่วยลดการใช้สารเคมีอย่างมีประสิทธิภาพ และการปลูกพืชหมุนเวียนยังช่วยลดประชากรแมลงศัตรูพืชในระยะยาว (Plodkornburee, 2021) อย่างไรก็ตาม เกษตรกรจำนวนมากยังคงพึ่งพาสารเคมี เนื่องจากผลลัพธ์ที่รวดเร็วและชัดเจน และต้นทุนที่ต่ำเมื่อเปรียบเทียบกับวิธีการอื่น ๆ แต่จะเป็นปัญหากับสิ่งแวดล้อมในระยะยาว

ปัจจุบันมีงานวิจัยที่นำเทคโนโลยีปัญญาประดิษฐ์ (AI) เข้ามาช่วยในการจัดการแมลงศัตรูพืช โดยเฉพาะการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) และการวิเคราะห์ภาพถ่ายเพื่อจำแนกประเภทแมลงอย่างแม่นยำ ตัวอย่างเช่น งานวิจัยของ Praharsha, Poulouse and Badgujar (2024) งานวิจัยนี้ใช้อัลกอริทึม Convolutional Neural Networks (CNN) ในการจำแนกภาพแมลงศัตรูพืชของมะเขือเทศ โดยเปรียบเทียบประสิทธิภาพของตัวปรับค่าต่าง ๆ โดย RMSprop (Optimizer) ให้ความแม่นยำสูงถึง 0.89 อัลกอริทึม CNN ที่ปรับค่าเหล่านี้ยังถูกเปรียบเทียบกับอัลกอริทึมที่ล้ำสมัยอื่น ๆ เช่น อัลกอริทึม ResNet และอัลกอริทึม MobileNet เพื่อพัฒนาระบบตรวจจับแมลงศัตรูพืชแบบอัตโนมัติ นอกจากนี้ งานวิจัยของ Chen *et al.* (2020) ได้รวม AI กับอุปกรณ์ IoT เพื่อพัฒนาระบบติดตามและคาดการณ์การระบาดของแมลงศัตรูพืชในแปลงเกษตร ซึ่งช่วยให้เกษตรกรสามารถวางแผนการจัดการได้อย่างมีประสิทธิภาพ ลดการใช้สารเคมีที่เกินความจำเป็น และลดผลกระทบต่อสิ่งแวดล้อมในระยะยาว นอกจากนี้การประยุกต์ใช้แบบจำลองปัญญาประดิษฐ์ผ่านการฝึกสอนล่วงหน้า (Pre-trained Models) เช่น อัลกอริทึม MobileNetV2 อัลกอริทึม ResNet50 และอัลกอริทึม VGG19 ได้รับการพิสูจน์ว่าเหมาะสมอย่างยิ่งสำหรับการประมวลผลภาพ เนื่องจากความสามารถในการวิเคราะห์และเรียนรู้คุณลักษณะสำคัญของภาพได้อย่างมีประสิทธิภาพ (Bansal *et al.*, 2024; Ahsan *et al.*, 2023) อย่างไรก็ตาม แบบจำลองเหล่านี้ยังมีข้อจำกัดที่สำคัญ เช่น ความไวต่อการเปลี่ยนแปลงของแสงและมุมมองของภาพ ซึ่งอาจส่งผลกระทบต่อความแม่นยำในการจำแนกแมลง นอกจากนี้ การปรับแต่งแบบจำลองให้เหมาะสมกับข้อมูลเฉพาะกลุ่มยังต้องการทรัพยากรในการประมวลผลที่สูง และการฝึกสอนแบบจำลองซ้ำอาจใช้เวลาและต้นทุนมาก (Chen *et al.*, 2022; Mazzawi *et al.*, 2024)

งานวิจัยนี้มุ่งเน้นการพัฒนาเทคโนโลยีการจำแนกแมลงศัตรูพืช 10 ชนิดที่ส่งผลกระทบต่อเกษตรกรในพื้นที่จังหวัดอุบลราชธานี โดยการทดสอบและเปรียบเทียบประสิทธิภาพของอัลกอริทึม MobileNetV2 อัลกอริทึม ResNet50 และอัลกอริทึม VGG19 รวมถึงอัลกอริทึมการจำแนกแบบดั้งเดิม อัลกอริทึม Random Forest อัลกอริทึม Support Vector Machine และอัลกอริทึม Logistic Regression เพื่อศึกษาความเหมาะสมของเทคโนโลยีสำหรับการนำไปประยุกต์ใช้งานจริง ผลลัพธ์ที่ได้จากงานวิจัยนี้สามารถนำไปพัฒนาแอปพลิเคชันหรืออุปกรณ์ที่สามารถจำแนกแมลงศัตรูพืช ลดการใช้สารเคมีในการจัดการศัตรูพืช และสนับสนุนแนวทางการเกษตรที่ยั่งยืนในระยะยาว เทคโนโลยีนี้ยังสามารถขยายผลไปสู่การพัฒนาแบบอัตโนมัติ เช่น หุ่นยนต์สำหรับการจัดการแมลงในพื้นที่เพาะปลูก ช่วยเสริมสร้างความสามารถในการแข่งขันของเกษตรกรในยุคดิจิทัล (Papakie, 2023)

วัตถุประสงค์การวิจัย

การศึกษารั้วนี้มีวัตถุประสงค์เพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้เชิงลึกที่ผ่านการฝึกสอนล่วงหน้ากับอัลกอริทึมการเรียนรู้แบบดั้งเดิม ในการจำแนกภาพแมลงศัตรูพืชที่พบในพืชเศรษฐกิจของจังหวัดอุบลราชธานี

ทฤษฎีที่เกี่ยวข้อง

การเรียนรู้ของเครื่อง (Machine Learning) เป็นสาขาวิชาที่สำคัญของปัญญาประดิษฐ์ (Artificial Intelligence) ซึ่งมุ่งเน้นการพัฒนาอัลกอริทึมที่สามารถเรียนรู้และปรับตัวจากข้อมูล เพื่อสร้างแบบจำลองที่มีความสามารถในการวิเคราะห์

การคำนวณ และแก้ปัญหาที่ซับซ้อนได้อย่างมีประสิทธิภาพ โดยหนึ่งในกระบวนการที่สำคัญที่สุดของการเรียนรู้ของเครื่อง คือ การจำแนกประเภท (Classification) ซึ่งเป็นการวิเคราะห์ข้อมูลเพื่อจัดกลุ่มหรือคาดการณ์คลาสของข้อมูลใหม่ที่ยังไม่ทราบล่วงหน้า กระบวนการนี้มีบทบาทสำคัญในการวิจัยด้านต่าง ๆ ที่ต้องจัดการกับข้อมูลขนาดใหญ่และซับซ้อน เช่น การวินิจฉัยโรค การวิเคราะห์พฤติกรรมผู้บริโภค และการตรวจสอบความผิดปกติในระบบต่าง ๆ งานวิจัยนี้มุ่งเน้นในการเปรียบเทียบประสิทธิภาพของอัลกอริทึมที่หลากหลาย โดยเลือกใช้อัลกอริทึมดั้งเดิมที่ได้รับความนิยมในด้านความแม่นยำและความน่าเชื่อถือ เช่น อัลกอริทึมการถดถอยแบบโลจิสติก อัลกอริทึมเรandomดอมฟอเรส และอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน ควบคู่กับการประยุกต์ใช้อัลกอริทึมด้านการเรียนรู้เชิงลึกที่ทันสมัย เช่น อัลกอริทึม MobileNetV2 อัลกอริทึม ResNet50 และอัลกอริทึม VGG19 ซึ่งถูกปรับแต่งในรูปแบบฝึกสอนล่วงหน้า เพื่อเพิ่มศักยภาพในการดึงลักษณะเด่นเชิงลึกจากข้อมูล (Feature Extraction) งานวิจัยนี้เน้นการผสมผสานการทำงานระหว่างการเรียนรู้เชิงลึกและอัลกอริทึมดั้งเดิม เพื่อค้นหาแนวทางที่เหมาะสมในการจำแนกประเภท โดยมีรายละเอียดของแต่ละอัลกอริทึมดังต่อไปนี้

อัลกอริทึมการถดถอยแบบโลจิสติก (Logistic Regression : LR) เป็นอัลกอริทึมพื้นฐานที่ได้รับการยอมรับอย่างแพร่หลายในงานจำแนกประเภททั้งในรูปแบบ Binary Classification และ Multiclass Classification โดยแบบจำลองนี้มีพื้นฐานอยู่บนหลักการคำนวณความน่าจะเป็น (Probability) ซึ่งช่วยให้สามารถคาดการณ์ได้อย่างแม่นยำว่าวัตถุหรือข้อมูลที่กำหนดจะจัดอยู่ในประเภทใด ภายใต้เงื่อนไขหรือคุณลักษณะที่มีอยู่ จุดเด่นของการถดถอยแบบโลจิสติก คือ ความสามารถในการแสดงผลลัพธ์เป็นค่าความน่าจะเป็นที่ตีความได้ง่าย ซึ่งทำให้เหมาะสำหรับงานที่ต้องการวิเคราะห์ความสัมพันธ์เชิงสถิติระหว่างตัวแปรอิสระ (Independent Variables) และตัวแปรเป้าหมาย (Dependent Variable) นอกจากนี้ แบบจำลองยังรองรับการขยายไปสู่ Multinomial Logistic Regression สำหรับกรณีที่ตัวแปรเป้าหมายมีมากกว่าสองคลาส (Multiclass) โดยใช้แนวทางการคำนวณเชิงสถิติ โดยมีสมการดังสมการที่ (1) (Bourel and Segura, 2018)

$$\ln\left(\frac{p_c(x)}{p_0(x)}\right) = \beta_0^{(c)} + \sum_{i=1}^d \beta_i^{(c)} x^{(i)}, \quad \forall c = 1, \dots, C-1 \quad (1)$$

$p_k(x)$: ความน่าจะเป็นของ x ที่จะอยู่ในคลาส c

$p_0(x)$: ความน่าจะเป็นของ x สำหรับหมวดหมู่ฐาน (reference category)

$\beta_0^{(c)}$: ค่าคงที่ของหมวดหมู่ c

$\beta_i^{(c)}$: ค่าสัมประสิทธิ์ของตัวแปรอิสระ $x^{(i)}$ สำหรับหมวดหมู่ c

C : จำนวนหมวดหมู่ทั้งหมด

d : จำนวนตัวแปรอิสระ

อัลกอริทึมเรandomดอมฟอเรส (Random Forest : RF) ใช้หลักการของต้นไม้ตัดสินใจ (Decision Tree) เป็นพื้นฐานในการสร้างแบบจำลอง โดยกระบวนการทำงานของอัลกอริทึมประกอบด้วยการสร้างต้นไม้ตัดสินใจจำนวน N ต้น โดยในแต่ละต้นไม้จะถูกสร้างขึ้นจากการสุ่มตัวอย่างข้อมูล (Bootstrap Sampling) และการสุ่มเลือกตัวแปรอิสระบางส่วนในแต่ละโหนด (Feature Subset Selection) เพื่อเพิ่มความหลากหลาย (Diversity) และลดความเสี่ยงจากการเกิด Overfitting ในกระบวนการสร้างโหนดของต้นไม้แต่ละต้น จะใช้มาตรวัด Gini Index เป็นเกณฑ์ในการตัดสินใจเลือกตัวแปรและเกณฑ์การแยกข้อมูล (Splitting Criterion) โดย Gini Index มีนิยามดังสมการที่ (2) (Kongchai, Hiranpongsin and Ditcharoen, 2024)

$$\text{Gini}(t) = 1 - \sum_{i=1}^C p_i^2 \quad (2)$$

t : โหนดใด ๆ ในต้นไม้ตัดสินใจ

C : จำนวนคลาสทั้งหมดในข้อมูล

p : สัดส่วนของข้อมูลในคลาสที่ i ในโหนดนั้น

อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine : SVM) เป็นอัลกอริทึมการเรียนรู้แบบมีผู้สอน (Supervised Learning) ที่ถูกออกแบบมาเพื่อแก้ปัญหาการจำแนกประเภท (Classification) โดยใช้หลักการค้นหาไฮเปอร์เพลน (Hyperplane) ที่เหมาะสมที่สุดในเชิงเรขาคณิต เพื่อแยกข้อมูลของคลาสต่าง ๆ ออกจากกัน โดยการเพิ่ม Margin ระหว่างคลาสให้มากที่สุด ซึ่งตัวอย่างข้อมูลที่อยู่ใกล้ไฮเปอร์เพลน ที่สุดจะเรียกว่า เวกเตอร์สนับสนุน สามารถจัดการกับข้อมูลที่ไม่สามารถแยกได้แบบเส้นตรงได้ผ่าน Kernel Trick ซึ่งช่วยเปลี่ยนข้อมูลไปยังมิติที่สูงขึ้น เพื่อให้ข้อมูลในมิติใหม่นั้นสามารถแยก

ออกได้ง่ายขึ้น โดย Kernel Function ที่นิยมใช้ ได้แก่ Linear Kernel, Polynomial Kernel, Radial Basis Function (RBF) และ Sigmoid Kernel อัลกอริทึม SVM มีความสามารถในการควบคุมความสมดุลระหว่างการพอดีกับข้อมูล (Fitting) และการหลีกเลี่ยง Overfitting ผ่านพารามิเตอร์สำคัญ เช่น C ซึ่งควบคุมความยืดหยุ่นของการแยกข้อมูล และ gamma ซึ่งกำหนดลักษณะความโค้งของไฮเปอร์เพลน โดยสมการพื้นฐานของ S ถูกนิยามในรูปของการแก้ปัญหาการเพิ่มประสิทธิภาพ (Optimization Problem) ดังสมการที่ (3) (Cortes and Vapnik, 1995)

$$\begin{aligned} \text{minimize} \quad & \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i \\ \text{เมื่อ} \quad & y_i(w \cdot x_i + b) \geq 1 - \xi_i, \quad \forall i \end{aligned} \quad (3)$$

โดยที่

w : เวกเตอร์น้ำหนักของไฮเปอร์เพลน

b : Bias สำหรับปรับตำแหน่งไฮเปอร์เพลน

ξ_i : ค่า Slack Variable ซึ่งอนุญาตให้ข้อมูลบางตัวอย่าง อยู่ผิดด้านของไฮเปอร์เพลนในกรณีที่มีข้อมูลซับซ้อน

C : ควบคุมค่าปรับ (Penalty) สำหรับข้อมูลที่ไม่สามารถแยกได้สมบูรณ์

การเรียนรู้เชิงลึก (Deep Learning) เป็นเทคนิคที่ช่วยสร้างลำดับชั้นของคุณลักษณะ (Feature Hierarchy) จากข้อมูลนำเข้าโดยใช้โครงข่ายประสาทเทียมหลายชั้น (Multi-layer Neural Networks) ซึ่งเป็นวิธีที่ได้รับความนิยม เนื่องจากแตกต่างจากการสกัดคุณลักษณะด้วยมือในระบบการเรียนรู้ของเครื่องแบบดั้งเดิม (Traditional Machine Learning) โดยวิธีนี้สามารถสกัดคุณลักษณะจากภาพได้โดยอัตโนมัติ เทคนิคการเรียนรู้เชิงลึกหลากหลายอัลกอริทึมถูกนำมาใช้เพื่อบรรลุเป้าหมายที่กำหนด โครงข่ายประสาทเทียมแบบคอนโวลูชัน เป็นวิธีการเรียนรู้เชิงลึกที่ถูกใช้บ่อยในการจำแนกประเภทและแบ่งส่วนภาพ (Image Classification and Segmentation) และยังเป็นโครงสร้างพื้นฐานของอัลกอริทึมทางการเรียนรู้เชิงลึกที่นำมาทดลองในงานวิจัยนี้ อีกทั้ง CNN ยังมีความสามารถในการสกัดคุณลักษณะจากภาพโดยอัตโนมัติ โครงสร้างพื้นฐานของ CNN ประกอบด้วยชั้นการคอนโวลูชัน (Convolution) ชั้นการดึงคุณลักษณะ (Pooling) ชั้นการกระตุ้น (Activation) และชั้นเชื่อมโยงแบบสมบูรณ์ (Fully-Connected) (Anwar *et al.*, 2018) ในกระบวนการทำงานของ CNN จะรับข้อมูลที่ถูกจัดประเภทไว้แล้วตามคลาส เพื่อนำไปใช้ปรับปรุงค่าพารามิเตอร์ที่สามารถฝึกสอนได้ (Trainable Parameters) เพื่อเพิ่มความแม่นยำในการจำแนก นอกจากนี้ยังนำไปใช้ในการถ่ายทอดการเรียนรู้ (Transfer Learning) คือกระบวนการถ่ายโอนค่าน้ำหนัก (Weights) จากแบบจำลองที่ได้รับการฝึกสอนไว้ล่วงหน้า (Pre-Trained Model) ซึ่งผ่านการฝึกสอนอย่างเข้มข้นด้วยข้อมูลจำนวนมาก แล้วทำการถ่ายโอนน้ำหนักไปยังแบบจำลองอื่นที่ถูกออกแบบมาเพื่อแก้ปัญหาที่เกี่ยวข้องกัน การถ่ายทอดการเรียนรู้มีประโยชน์อย่างยิ่งในงานวิเคราะห์ภาพทางการแพทย์ที่มีจำนวนภาพจำกัด เช่น ในงานวิจัยของ Krishnapriya and Karuna (2023) ได้ใช้แบบจำลองถ่ายทอดการเรียนรู้ที่ผ่านการฝึกสอนมาแล้ว ได้แก่ อัลกอริทึม VGG19 อัลกอริทึม ResNet50 และอัลกอริทึม Inception V3 เพื่อจำแนกภาพ MRI ของสมอง ผลการศึกษาแสดงให้เห็นถึงผลลัพธ์ที่มีประสิทธิภาพสูงในการจำแนกประเภท ดังนั้นงานวิจัยนี้จึงได้ทำการทดลองกับอัลกอริทึม VGG19 อัลกอริทึม ResNet50 และอัลกอริทึม MobileNetV2 โดยมีรายละเอียดของแต่ละอัลกอริทึมดังต่อไปนี้

อัลกอริทึมวีจีจี19 (Visual Geometry Group : VGG19) เป็นโครงข่ายประสาทเทียมแบบ CNN ที่ได้รับการพัฒนาเพื่อใช้ในงานการจำแนกประเภทภาพและการจดจำวัตถุในภาพ โครงสร้างของอัลกอริทึม VGG19 ถูกออกแบบมาให้เรียบง่ายแต่มีความลึก โดยมีทั้งหมด 19 เลเยอร์ ประกอบด้วย 16 Convolutional Layers และ 3 Fully Connected Layers จุดเด่นของอัลกอริทึม VGG19 คือ การใช้ Convolutional Filters ขนาดเล็ก 3×3 ที่มี Padding และ Stride คงที่ ทำให้สามารถจับลักษณะเด่นเชิงพื้นที่ในภาพได้อย่างละเอียด อีกทั้งยังใช้โครงสร้างแบบลำดับขั้น (Sequential) ที่เลเยอร์จะต่อกันเป็นชั้น ๆ ซึ่งช่วยให้การคำนวณมีความเป็นระบบและง่ายต่อการนำไปใช้งาน อัลกอริทึม VGG19 ได้รับการฝึกสอนบนชุดข้อมูล ImageNet และกลายเป็นหนึ่งในแบบจำลองพื้นฐานที่ได้รับความนิยมในงานวิจัยด้านคอมพิวเตอร์วิทัศน์ในการจำแนกประเภทภาพ การตรวจจับวัตถุ และการแยกส่วนภาพโดยยังคงถูกใช้งานในหลายบริบททั้งในรูปแบบดั้งเดิมและแบบ Pretrained Models ที่นำไปปรับใช้ในงานเฉพาะทาง (Simonyan and Zisserman, 2015)

อัลกอริทึมเรสเน็ต50 (Residual Network 50 : ResNet50) เป็นโครงข่ายประสาทเทียมเชิงลึกที่มีโครงสร้างทั้งหมด 50 เลเยอร์ ซึ่งออกแบบมาเพื่อเพิ่มประสิทธิภาพในการเรียนรู้ข้อมูลที่ซับซ้อนโดยใช้แนวคิด Residual Learning โครงสร้างของ ResNet50 ประกอบด้วย ชั้น Convolutional Layers ชั้น Batch Normalization และ ชั้น Fully Connected Layers พร้อมการใช้ Bottleneck Architecture ที่ช่วยลดจำนวนพารามิเตอร์และเพิ่มความเร็วในการคำนวณ Skip Connections หรือเส้นทางลัดระหว่างเลเยอร์ ถูกนำมาใช้เพื่อให้ข้อมูลและกราเดียนสามารถไหลผ่านโครงข่ายได้โดยตรง ช่วย

ลดปัญหา Gradient Vanishing และเพิ่มความสามารถในการฝึกสอนโครงข่ายที่มีความลึกสูง ResNet50 มีความสามารถในการทำงานในหลากหลายงาน เช่น การจำแนกประเภทภาพ การตรวจจับวัตถุ และการแยกส่วนภาพ โดยมีจุดเด่นในการรองรับการประมวลผลข้อมูลขนาดใหญ่และซับซ้อนอย่างมีประสิทธิภาพ ทำให้เป็นหนึ่งในแบบจำลองมาตรฐานที่ถูกนำไปใช้อย่างกว้างขวางในงานด้านคอมพิวเตอร์วิทัศน์ (He *et al.*, 2016)

อัลกอริทึมโมบายเน็ตวี2 (MobileNetV2) เป็นโครงข่ายประสาทเทียมเชิงลึกที่ออกแบบมาเพื่อใช้งานบนอุปกรณ์ที่มีทรัพยากรจำกัด เช่น สมาร์ทโฟนและอุปกรณ์ IoT โดยมุ่งเน้นการลดจำนวนพารามิเตอร์และความซับซ้อนของการคำนวณ โครงสร้างของอัลกอริทึม MobileNetV2 ใช้แนวคิด Depthwise Separable Convolution ซึ่งแบ่งกระบวนการ Convolution ออกเป็นสองขั้นตอน ได้แก่ Depthwise Convolution ที่กรองข้อมูลแยกตามช่อง (Channel) และ Pointwise Convolution ที่รวมข้อมูลจากทุกช่องผ่านการคำนวณแบบ 1x1 Convolution พร้อมทั้งเพิ่มแนวคิด Inverted Residual Block ซึ่งแตกต่างจาก Residual Block แบบดั้งเดิม โดยการใช้การขยายมิติข้อมูล (Expansion) ก่อนที่จะลดมิติลง (Projection) ทำให้โครงสร้างมีประสิทธิภาพในการเก็บรักษาข้อมูลเชิงลึกพร้อมลดการสูญเสียข้อมูล และใช้ Linear Bottleneck แทน ReLU Activation ในบางขั้นตอนเพื่อป้องกันการสูญเสียข้อมูลในมิติที่ต่ำ จุดเด่นของอัลกอริทึม MobileNetV2 คือ ความสามารถในการรักษาความแม่นยำของแบบจำลองในขณะที่ลดการใช้หน่วยความจำและพลังงาน ทำให้เหมาะสำหรับการประมวลผลข้อมูลภาพในงานที่ต้องการความเร็วและประสิทธิภาพสูงภายใต้ข้อจำกัดของทรัพยากร (Sandler *et al.*, 2018)

วิธีดำเนินการวิจัย

วิธีดำเนินการวิจัยการจำแนกแมลงศัตรูพืชจากภาพถ่าย โดยใช้แบบจำลองที่ผ่านการฝึกสอนล่วงหน้าด้วยการเรียนรู้เชิงลึก : กรณีศึกษาในจังหวัดอุบลราชธานี ประกอบด้วย การเก็บรวบรวมข้อมูล การเตรียมข้อมูล การเลือกแบบจำลองและการฝึกสอนแบบจำลอง โดยมีรายละเอียดดังนี้

การเก็บรวบรวมข้อมูล การวิจัยนี้ใช้ชุดข้อมูลภาพถ่ายแมลงศัตรูพืช 10 ชนิด ได้จากเว็บไซต์ iNaturalist (2024) ซึ่งเป็นแพลตฟอร์มชุมชนออนไลน์สำหรับการบันทึกและแบ่งปันข้อมูลความหลากหลายทางชีวภาพ โดยข้อมูลที้นำมาใช้ในงานวิจัยมีจำนวนทั้งหมด 4,875 ภาพ ภาพที่นำมาใช้งานเป็นภาพที่ไม่ติดลิขสิทธิ์หรือข้อจำกัดในการใช้งาน งานวิจัยนี้ใช้ข้อมูลภาพถ่ายแมลงศัตรูพืชที่สำคัญต่อพืชเศรษฐกิจในจังหวัดอุบลราชธานี ซึ่งสรุปได้ในตารางที่ 1

การเตรียมข้อมูล การเตรียมข้อมูลเริ่มต้นด้วยการกำหนดพารามิเตอร์ของชุดข้อมูล (data path) ซึ่งจัดโครงสร้างเป็นโฟลเดอร์ย่อยแยกตามคลาส (Class) เช่น class1/ และ class2/ โดยใช้ ImageDataGenerator เพื่อโหลดและแปลงข้อมูลภาพ พร้อมทั้งปรับค่าสเกลของพิกเซลให้อยู่ในช่วง [0, 1] และแบ่งข้อมูลเป็นชุดสำหรับการฝึก (ร้อยละ 80) และชุดสำหรับการตรวจสอบ (ร้อยละ 20) ด้วย validation_split=0.2 และ stratify=y เพื่อให้สัดส่วนของแต่ละคลาสเท่ากัน ภาพทั้งหมดถูกปรับขนาดให้ตรงกับอินพุตของแบบจำลอง (224x224 พิกเซล) และจัดการในรูปแบบแบตช์ (batch_size=32) นอกจากนี้ ยังใช้การตั้งค่า seed (seed_value=42) เพื่อให้ผลลัพธ์การแบ่งข้อมูลมีความคงที่และสามารถทำซ้ำได้ในทุกครั้งที่รันโปรแกรม ในการดึงคุณลักษณะ (Feature Extraction) ใช้ส่วนของแบบจำลองที่ผ่านการเทรนล่วงหน้า (Pre-Trained model) เพื่อแปลงภาพในชุดข้อมูลให้เป็นเวกเตอร์คุณลักษณะ ซึ่งจะถูกใช้ในแบบจำลอง RF SVM และ LR เพื่อสร้างแบบจำลอง


การเลือกแบบจำลองและการฝึกสอนแบบจำลอง การวิจัยนี้มุ่งเน้นการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกร่วมกับเทคนิคการจำแนกประเภทข้อมูล โดยดำเนินการผ่านโปรแกรม Jupyter Notebook เพื่อวิเคราะห์และประเมินประสิทธิภาพของแบบจำลองที่เลือก โดยแบ่งการศึกษาออกเป็นสองส่วนหลัก ดังนี้

เทคนิคการจำแนกประเภทข้อมูล ในขั้นตอนการจำแนกประเภทข้อมูล ผู้วิจัยได้ใช้อัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) แบบ Supervised Learning เพื่อตรวจสอบประสิทธิภาพของการสกัดคุณลักษณะ (Feature Extraction) จากแบบจำลองการเรียนรู้เชิงลึก ซึ่งประกอบด้วย อัลกอริทึม RF อัลกอริทึม SVM และ อัลกอริทึม LR การทดลองนี้ดำเนินการผ่านไลบรารี scikit-learn โดยตั้งค่าพารามิเตอร์เป็นค่าเริ่มต้น (Default Parameters) สำหรับทุกอัลกอริทึม เพื่อรักษายุติธรรมในการเปรียบเทียบผลลัพธ์

เทคนิคการเรียนรู้เชิงลึก ในส่วนของการเรียนรู้เชิงลึก ผู้วิจัยได้ประยุกต์ใช้เทคนิค Transfer Learning ผ่านสถาปัตยกรรมโครงข่ายประสาทเทียมที่ผ่านการฝึกฝนบนชุดข้อมูล ImageNet ซึ่งประกอบด้วย อัลกอริทึม MobileNetV2 อัลกอริทึม ResNet50 และ อัลกอริทึม VGG19 การทดลองนี้ได้ดำเนินการผ่านไลบรารี Keras และกระบวนการฝึกสอนโมเดลถูกตั้งค่าตามกรอบการทดลองอย่างเป็นระบบ ดังภาพที่ 1 โดยผลลัพธ์จากการถ่ายทอดการเรียนรู้มาเสนอในรูปแบบกราฟดังภาพที่ 2 ซึ่งแสดงถึงประสิทธิภาพและแนวโน้มการเรียนรู้ของแต่ละอัลกอริทึม โดยแกน x แสดงจำนวนรอบ (Epochs) ส่วนแกน Y แสดงผลค่าความถูกต้อง (Accuracy) ส่วนเส้นสีทึบ คือ Training Accuracy และเส้นสีนวล คือ Validation Accuracy

ผลการฝึกทำให้เห็นว่าอัลกอริทึม VGG เป็นตัวเลือกที่ดีที่สุด เนื่องจากมีค่า Training และ Validation Accuracy ใกล้เคียงกัน มีความผันผวนน้อย ขณะที่อัลกอริทึม MobileNetV2 อาจเกิด Overfitting และอัลกอริทึม ResNet มีความผันผวนสูง

ตารางที่ 1 รายละเอียดแมลงศัตรูพืชที่นำมาใช้ในงานวิจัยนี้


ชื่อ	ชื่อวิทยาศาสตร์	ภาพ	จำนวนภาพ
หนอนร่านกินใบ	<i>Parasa lepida</i>		256
ด้วงวงมะพร้าว	<i>Rhynchophorus ferrugineus</i>		769
ด้วงแรดมะพร้าว	<i>Oryctes rhinoceros</i>		390
แมลงค่อมทอง	<i>Hypomeces squamosus fabricius</i>		548
แมลงวันทอง	<i>Bactrocera dorsalis</i>		93
ผีเสื้อหนอนกระทู้ผัก	<i>Spodoptera litura</i>		769
แมลงสี	<i>Leptocorisa acuta</i>		680
ผีเสื้อกลางคืน	<i>Conogethes punctiferalis</i>		762
ด้วงบ่าหนามจุดนูนดำ	<i>Batocera rufomaculata</i>		462
ตั๊กแตนป่าทั้งกา	<i>Patanga succincta</i>		146

```


11 # Define a pretrained model
12 base_model = tf.keras.applications.VGG19(weights='imagenet', include_top=False, input_shape=(img_height, img_width, 3))
13 #base_model = tf.keras.applications.ResNet50(weights='imagenet', include_top=False, input_shape=(img_height, img_width, 3))
14 #base_model = tf.keras.applications.MobileNetV2(weights='imagenet', include_top=False, input_shape=(img_height, img_width, 3))
15
16 base_model.trainable = False # Freeze the pretrained layers
17
18 # Add a custom classification head
19 model = tf.keras.Sequential([
20     base_model,
21     tf.keras.layers.GlobalAveragePooling2D(),
22     tf.keras.layers.Dense(train_data.num_classes, activation='softmax')
23 ])
24
25 model.compile(optimizer='adam', loss='categorical_crossentropy', metrics=['accuracy', Precision(name='precision'), Recall(name='recall')])
26
27 # Train the model and store the history
28 history = model.fit(train_data, validation_data=val_data, epochs=10)
29
30 # Extract features for comparison with another algorithm
31 feature_extractor = tf.keras.Model(inputs=base_model.input, outputs=base_model.output)
32
33 def extract_features(data):
34     features, labels, image_data = [], [], []
35     for images, label_batch in data:
36         extracted_features = feature_extractor.predict(images)
37         features.append(extracted_features.reshape(extracted_features.shape[0], -1))
38         labels.append(label_batch)
39         image_data.append(images)
40     if len(features) * batch_size >= len(data.filenames):
41         break
42     return np.vstack(image_data), np.vstack(features), np.argmax(np.vstack(labels), axis=1)
43
44 train_images, train_features, train_labels = extract_features(train_data)
45 val_images, val_features, val_labels = extract_features(val_data)
46

```


ภาพที่ 1 คำสั่งตั้งค่าการฝึกสอนและสั่งการสกัดคุณลักษณะ



(ก) ผลการฝึกสอนของอัลกอริทึม ResNet50



(ข) ผลการฝึกสอนของอัลกอริทึม VGG19



(ค) ผลการฝึกสอนของอัลกอริทึม MobileNetV2

ภาพที่ 2 กราฟแสดงค่าความถูกต้องของอัลกอริทึม ResNet50 (ก) อัลกอริทึม VGG19 (ข) และอัลกอริทึม MobileNetV2 (ค)

ผลการวิจัยและอภิปรายผล

การทดลองนี้ดำเนินการเพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึมการเรียนรู้เชิงลึกที่ผ่านการฝึกสอนล่วงหน้า ได้แก่ อัลกอริทึม MobileNetV2 อัลกอริทึม ResNet50 และอัลกอริทึม VGG19 ร่วมกับอัลกอริทึมการจำแนกแบบดั้งเดิม อัลกอริทึม RF อัลกอริทึม SVM และอัลกอริทึม LR ในการจำแนกภาพถ่ายแมลงศัตรูพืช 10 ชนิด ซึ่งมีจำนวนรวม 4,875 ภาพ ข้อมูลได้มาจากเว็บไซต์ iNaturalist.org ดังภาพตัวอย่างตารางที่ 1 โดยแบ่งข้อมูลเป็นชุดการฝึกร้อยละ 80 และชุดการตรวจสอบร้อยละ 20 หลังจากเตรียมข้อมูลและทำ Feature Extraction ด้วยการเรียนรู้เชิงลึก แต่ละอัลกอริทึมถูกทดสอบผ่านกระบวนการเรียนรู้แบบ Supervised Learning ภายใต้เงื่อนไขที่ควบคุมด้วยค่าพารามิเตอร์เริ่มต้น (Default Parameters) การวัดประสิทธิภาพจะพิจารณาผลลัพธ์เชิงสถิติที่มีค่าตั้งแต่ 0 ถึง 1 (เลข 0 หมายถึงน้อยที่สุด ส่วนเลข 1 หมายถึงมากที่สุด) ได้แก่ ค่า Accuracy ค่า Precision ค่า Recall และค่า F1-Score (Sombat *et al.*, 2024) โดยมีผลการทดลองดังตารางที่ 2

ตารางที่ 2 ผลการทดสอบประสิทธิภาพของการเรียนรู้เชิงลึกและอัลกอริทึมการจำแนกประเภท


Feature Extraction	Classification Model	Accuracy	Precision	Recall	F1-Score
MobileNetV2		0.880	0.909	0.861	0.885
ResNet50		0.290	0.600	0.003	0.006
VGG19		0.607	0.926*	0.311	0.465
ไม่มี	RF	0.134	0.096	0.099	0.097
	SVM	0.404	0.297	0.286	0.266
	LR	0.390	0.308	0.310	0.307
MobileNetV2	RF	0.804	0.772	0.651	0.660
	SVM	0.871	0.909	0.809	0.841
	LR	0.898*	0.894	0.853*	0.869*
ResNet50	RF	0.386	0.259	0.271	0.250
	SVM	0.236	0.148	0.152	0.101
	LR	0.422	0.346	0.328	0.324
VGG19	RF	0.583	0.635	0.418	0.399
	SVM	0.647	0.648	0.493	0.493
	LR	0.752	0.711	0.678	0.690

จากตารางที่ 2 ผลการทดสอบประสิทธิภาพของการเรียนรู้เชิงลึกและอัลกอริทึมการจำแนกประเภท แสดงให้เห็นว่า อัลกอริทึม MobileNetV2 เป็นแบบจำลองที่มีประสิทธิภาพดีที่สุดเมื่อเทียบกับแบบจำลองอื่น โดยเฉพาะเมื่อนำไปใช้ร่วมกับอัลกอริทึม LR ซึ่งได้ Accuracy สูงสุดถึง 0.898 และ F1-Score สูงสุดที่ 0.869 แสดงให้เห็นถึงความสมดุลในการจำแนกข้อมูลทั้งด้าน Precision และ Recall นอกจากนี้ การจับคู่กับ SVM ให้ค่า Precision สูงสุด (0.909) ซึ่งเหมาะสมสำหรับงานที่ให้ความสำคัญกับความแม่นยำในการจำแนกประเภท โดยมีผลลัพธ์จากการทำ Confusion Matrix แสดงดังภาพที่ 3 ซึ่งเป็นผลที่น่าพึงพอใจ แต่มีบางคลาสที่ยังมีความถูกต้องในการจำแนกไม่มาก เช่น แมลงวันทอง และ ตั๊กแตนปาทังกา ที่มีความถูกต้องในการจำแนกคลาสร้อยละ 61.11 และ 74.07 ตามลำดับ เนื่องจากแบบจำลองเรียนรู้ไม่ดีพอในคลาสที่มีตัวอย่างน้อยหรือมีลักษณะคล้ายคลึงกัน ทำให้เกิดความสับสน

อัลกอริทึม ResNet50 มีผลลัพธ์ที่ต่ำกว่ามาตรฐานอย่างชัดเจน โดยเฉพาะเมื่อทำงานแบบ Standalone ที่ให้ค่า Recall เพียง 0.003 และ F1-Score 0.006 ซึ่งสะท้อนว่าแบบจำลองนี้ไม่เหมาะสมสำหรับข้อมูลที่ใช้ในการทดลองแต่เมื่อนำ ResNet50 มาใช้ร่วมกับ LR ได้ผลลัพธ์ที่ดีที่สุดในกลุ่ม ResNet50 (Accuracy 0.422, F1-Score 0.324) แต่ยังคงต่ำกว่า MobileNetV2 และ VGG19

อัลกอริทึม VGG19 มีความโดดเด่นในด้าน Precision โดยได้ค่า Precision สูงสุดในแบบ Standalone (0.926) อย่างไรก็ตาม Recall และ F1-Score ยังต่ำ (Recall 0.311 และ F1-Score 0.465) ซึ่งแสดงถึงปัญหาความไม่สมดุลของการจำแนก แต่เมื่อนำอัลกอริทึม VGG19 มาร่วมกับอัลกอริทึม LR พบว่าได้ผลลัพธ์ที่ดีขึ้น (Accuracy 0.752 และ F1-Score 0.690) แต่ยังไม่ดีกว่าอัลกอริทึม MobileNetV2

อัลกอริทึมที่ไม่มีการทำ Feature Extraction ประกอบด้วย อัลกอริทึม RF อัลกอริทึม SVM และอัลกอริทึม LR โดยไม่มีการทำการสกัดคุณลักษณะด้วยแบบจำลอง Pre-trained ให้ผลลัพธ์ต่ำที่สุดในทุกด้าน โดยเฉพาะ Accuracy ต่ำสุดเพียง 0.134 และอัลกอริทึม RF ค่า F1-Score ต่ำสุดอยู่ที่ 0.097 แสดงให้เห็นว่าการใช้ Feature Extraction ด้วย Pre-trained Model ช่วยเพิ่มประสิทธิภาพของแบบจำลองได้อย่างชัดเจน



ภาพที่ 3 Confusion Matrix ของ อัลกอริทึม MobileNetV2 (Feature Extraction) ร่วมกับอัลกอริทึม LR (Classification Model)

สรุปผลการวิจัยและข้อเสนอแนะจากการวิจัย

ผลการวิจัยแสดงให้เห็นว่าอัลกอริทึม MobileNetV2 ร่วมกับอัลกอริทึม LR ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า Accuracy สูงสุดที่ 0.898 และ F1-Score สูงสุดที่ 0.869 ซึ่งสะท้อนถึงความสามารถในการจำแนกภาพแมลงศัตรูพืชได้อย่างมีประสิทธิภาพ ในขณะที่แบบจำลอง ResNet50 ให้ผลลัพธ์ต่ำสุด โดยเฉพาะเมื่อใช้งานแบบ Standalone เนื่องจากปัญหาความไม่สมดุลของข้อมูลและความซับซ้อนของโมเดล (He and Garcia, 2009) ในทางกลับกัน VGG19 มีความโดดเด่นในด้าน Precision แต่ยังคงขาดสมดุลใน Recall การวิจัยนี้ชี้ให้เห็นว่า การผสมผสานการเรียนรู้เชิงลึกกับอัลกอริทึมแบบดั้งเดิมช่วยเพิ่มความแม่นยำในการจำแนกประเภทข้อมูลได้อย่างชัดเจน ดังนั้น จึงแนะนำให้ใช้แบบจำลอง MobileNetV2 ในรูปแบบผสมผสานกับ LR ไปพัฒนาเป็นระบบตรวจจับแมลงศัตรูพืชเชิงปฏิบัติการ เช่น แอปพลิเคชันสำหรับเกษตรกรหรืออุปกรณ์ IoT เพื่อลดการใช้สารเคมีที่ไม่จำเป็น สนับสนุนการเกษตรแบบยั่งยืน และเพิ่มขีดความสามารถในการจัดการศัตรูพืชอย่างมีประสิทธิภาพในอนาคต

กิตติกรรมประกาศ

ขอขอบคุณ คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี สำหรับการสนับสนุนการดำเนินงานวิจัยในครั้งนี้

จริยธรรมการวิจัย

การวิจัยเรื่อง "การจำแนกแมลงศัตรูพืชจากภาพถ่ายโดยใช้แบบจำลองที่ผ่านการฝึกสอนล่วงหน้าด้วยการเรียนรู้เชิงลึก: กรณีศึกษาในจังหวัดอุบลราชธานี" ใช้ข้อมูลภาพถ่ายแมลงจากเว็บไซต์ iNaturalist (<https://www.inaturalist.org>) ซึ่งเผยแพร่ภายใต้สัญญาอนุญาตแบบ Creative Commons Attribution-NonCommercial (CC-BY-NC) ที่อนุญาตให้ใช้เพื่อการศึกษาและวิจัยโดยไม่แสวงหาผลกำไร การดำเนินงานวิจัยนี้ไม่มีการทดลองในมนุษย์หรือสัตว์ และไม่ก่อให้เกิดความเสี่ยงหรือผลกระทบทางลบต่อบุคคล สัตว์ หรือสิ่งแวดล้อม โดยปฏิบัติตามหลักจริยธรรมการวิจัยอย่างเคร่งครัด ได้แก่ หลักความเคารพในบุคคล (Respect for Person) ผ่านการใช้ข้อมูลจากแหล่งที่อนุญาตและให้เครดิตอย่างถูกต้อง หลักคุณประโยชน์ ไม่ก่ออันตราย (Beneficence) มุ่งเน้นสร้างองค์ความรู้ที่เป็นประโยชน์ต่อภาคการเกษตร และหลักความยุติธรรม (Justice) โดยใช้ข้อมูลที่เข้าถึงได้อย่างเท่าเทียมและเหมาะสมตามหลักจริยธรรมการวิจัยสากล

References

- Ahsan, M. M., Uddin, M. R., Ali, M. S., Islam, M. K., Farjana, M., Sakib, A. N. and Luna, S. A. (2023). Deep transfer learning approaches for Monkeypox disease diagnosis. **Expert Systems with Applications**, 216, 119483.
- Anwar, S. M., Majid, M., Qayyum, A., Awais, M., Alnowami, M. and Khan, M. K. (2018). Medical image analysis using convolutional neural networks: a review. **Journal of medical systems**, 42, 1-13.
- Bansal, M., Kumar, M., Sachdeva, M. and Mittal, A. (2023). Transfer learning for image classification using VGG19: Caltech-101 image data set. **Journal of ambient intelligence and humanized computing**, 1-12.
- Bourel, M. and Segura, A. M. (2018). Multiclass classification methods in ecology. **Ecological Indicators**, 85, 1012-1021.
- Chagkornburee, C. and Chaiklieng, S. (2024). The prevalence of symptoms from pesticide exposure among agriculturists: A systematic review and meta-analysis (in Thai). **Safety and Environment Review**, 7(1), 1–12.
- Chen, C., Yin, Y., Shang, L., Jiang, X., Qin, Y., Wang, F., Wang, Z., Chen, X., Liu, Z. and Liu, Q. (2022). bert2BERT: Towards reusable pretrained language models. **Proceedings of the 60th Annual Meeting of the Association for Computational Linguistics** (pp. 2134–2148).
- Chen, C. J., Huang, Y. Y., Li, Y. S., Chang, C. Y. and Huang, Y. M. (2020). An AIoT based smart agricultural system for pests detection. **IEEE access**, 8, 180750-180761.
- Cortes, C. and Vapnik, V. (1995). Support-vector networks. **Machine learning**, 20(3), 273-297.
- He, H. and Garcia, E. A. (2009). Learning from imbalanced data. **IEEE Transactions on knowledge and data engineering**, 21(9), 1263-1284.
- He, K., Zhang, X., Ren, S. and Sun, J. (2016). Deep residual learning for image recognition. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)** (pp. 770–778). Las Vegas: IEEE.
- iNaturalist. Connect with nature. Retrieved 10 December 2024, from **iNaturalist**: <https://www.inaturalist.org>.
- Kongchai, P., Hiranpongsin, S. and Ditcharoen, N. (2024). Creating a prediction model for prospective university student admissions during the COVID-19 pandemic situation: A case study of the faculty of science at Ubon Ratchathani university (in Thai). **The Journal of King Mongkut's University of Technology North Bangkok**, 34(2), 1–10.
- Krishnapriya, S. and Karuna, Y. (2023). Pre-trained deep learning models for brain MRI image classification. **Frontiers in Human Neuroscience**, 17, 1150120.
- Mazzawi, H., Gonzalvo, X., Wunder, M., Jerome, S. and Dherin, B. (2024). Deep fusion: Efficient network training via pre-trained initializations. **Proceedings of Machine Learning Research**. 235:35225-35239.
- Papakie, K. (2023). CMU team develops autonomous robot to stave off spotted lanternflies. Retrieved 17 December 2024, from **Carnegie Mellon University**: <https://www.cs.cmu.edu/news/2023/tartan-pest>.
- Plodkornburee, W. (2021). Integrated pest management for improving production of economic crops. Department of Agriculture. Retrieved 17 December 2024, from **Department of Agriculture**: <https://www.doa.go.th/plan/wp-content/uploads/2023/08/54-1.pdf>.

- Praharsha, C. H., Poullose, A. and Badgujar, C. (2024). Comprehensive Investigation of Machine Learning and Deep Learning Networks for Identifying Multispecies Tomato Insect Images. **Sensors**, 24(23), 7858.
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A. and Chen, L. C. (2018). MobileNetV2: Inverted residuals and linear bottlenecks. **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)** (pp. 4510-4520). Salt Lake City: IEEE.
- Simonyan, K. and Zisserman, A. (2015). Very deep convolutional networks for large-scale image recognition. **Proceedings of the International Conference on Learning Representations (ICLR)** (pp. 1–14).
- Sombat, W., Kaensar, C., Hiranpongsin, S. and Baokham, S. (2024). A student graduation prediction system using random forest technique (in Thai). **Journal of Science and Science Education**, 7(2), 245-259.
- The Government Public Relations Department. (2024). Warns farmers to monitor and prevent major crop diseases and pests such as rice and vegetables. Retrieved 10 February 2025, from **Ubon Ratchathani.prd.go.th**: <https://ubonratchathani.prd.go.th/th/content/category/detail/id/9/iid/343404>.