

การเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 ในระบบตรวจจับเครื่องบินด้วยการประมวลผลภาพดิจิทัลจากท่าจอดเครื่องบิน

Comparison of YOLOv8 Models for Aircraft Detection in Airport Apron Using Digital Image Processing

นิติภูมิ เวียงคำ*, สมชาติ จิริวิภากร

สาขาวิชาวิศวกรรมป้องกันประเทศ, คณะวิศวกรรมศาสตร์, สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ลาดกระบัง ลาดกระบัง กรุงเทพมหานคร 10520

Nitipoom Wiangkam*, Somchat Jiriwibhakorn

Department of Defence Engineering, School of Engineering, King Mongkut's Institute of Technology Ladkrabang,
Lat Krabang, Lat Krabang, Bangkok, 10520, Thailand.

*Corresponding Author E-mail: 64601225@kmitl.ac.th

Received: May 16, 2024; Revised: Sep 05, 2024; Accepted: Sep 09, 2024

บทคัดย่อ

การจัดการจราจรทางอากาศได้อย่างมีประสิทธิภาพ ช่วยให้สนามบินสามารถเพิ่มความปลอดภัยในการติดตามจุดจอดของเครื่องบินและควบคุมการเคลื่อนที่เข้าจุดจอดได้อย่างมีประสิทธิภาพ ตลอดจนในกรณีเกิดเหตุฉุกเฉินสามารถช่วยในการตรวจสอบพื้นที่ในสนามบินได้อย่างแม่นยำ และสามารถลดต้นทุนในการบริหารจัดการ ลดภาระงานในการใช้บุคลากรในการควบคุม อีกทั้งยังสามารถช่วยจัดการจราจรทางอากาศและภาคพื้นได้ งานวิจัยนี้มุ่งเน้นไปที่การเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 แต่ละรุ่น (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8nl, YOLOv8nx) ในระบบตรวจจับเครื่องบินอัตโนมัติโดยใช้เทคนิคการประมวลผลภาพดิจิทัล วิธีการทำโดยรวบรวมภาพสนามบินที่มีเครื่องบินจอดอยู่จำนวน 1,000 ภาพ ภาพ แบ่งเป็นภาพเทรน 900 ภาพ และภาพทดสอบ 100 ภาพ ฝึกโมเดล YOLOv8 แต่ละรุ่นบนชุดข้อมูลภาพเทรน ประเมินประสิทธิภาพของโมเดลแต่ละรุ่นบนชุดข้อมูลภาพทดสอบโดยใช้ confusion matrix ผลการทดลองพบว่า YOLOv8nx มีค่าเฉลี่ยในการตรวจจับภาพเครื่องบินสูงที่สุด โดยมีค่า precision ที่ 0.94, recall ที่ 0.74 และ f1-score ที่ 0.83 และ YOLOv8n มีความเร็วมากที่สุดที่ 0.95 ms ดังนั้น โมเดล YOLOv8n เหมาะสำหรับการใช้งานที่ต้องการความเร็วในการประมวลผลสูง และโมเดล YOLOv8nx เหมาะสำหรับการใช้งานที่ต้องการประสิทธิภาพสูงสุด

คำสำคัญ: ตรวจจับเครื่องบินอัตโนมัติ, YOLOv8, ประสิทธิภาพ, F1-score

Abstract

Airport safety can be improved by efficient air traffic management, which monitors aircraft parking spots and controls their movement into them more efficiently. In addition to emergency situations, it can assist in accurately inspecting airport areas. Management costs can be reduced by reducing the workload of personnel in controlling and helping manage air and ground traffic. This research focuses on comparing the performance of various YOLOv8 models (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8nl, and YOLOv8nx) in an automated aircraft detection system using digital image processing techniques. The

methodology involves collecting a dataset of 1,000 airport apron images with parked aircraft, dividing them into 900 training images and 100 testing images. The YOLOv8 models are trained on the training dataset, and their performance is evaluated on the testing dataset using confusion matrices. Experimental results reveal that YOLOv8nx achieves the highest average aircraft detection performance, with a precision of 0.94, recall of 0.74, and f1-score of 0.83. Additionally, YOLOv8n demonstrates the highest processing speed at 0.95 milliseconds. Consequently, YOLOv8n is suitable for applications requiring high-speed processing, while YOLOv8nx is ideal for tasks demanding the utmost performance efficiency.

Keywords: Automated aircraft detection, YOLOv8, Performance, F1-score

1. บทนำ

การจัดการจราจรทางอากาศที่มีประสิทธิภาพส่งผลต่อความปลอดภัยและต้นทุนของสนามบิน ระบบตรวจจับเครื่องบินอัตโนมัติมีประโยชน์มากมาย และยังเป็นส่วนสำคัญในระบบการจัดการจราจรทางอากาศ หากไม่มีระบบตรวจจับเครื่องบินอัตโนมัติบนท่าจอดเครื่องบิน อาจเกิดปัญหาต่อไปนี้ เสี่ยงต่อความปลอดภัย การไม่มีการตรวจจับเครื่องบินในพื้นที่ท่าจอดอาจทำให้เกิดความเสี่ยงต่อความปลอดภัย เช่น การชนกันระหว่างเครื่องบินหรือการกระทำไม่ปลอดภัยขณะที่เครื่องบินกำลังเคลื่อนที่ในพื้นที่ท่าจอด การจัดการจราจรที่ไม่มีประสิทธิภาพ การไม่มีระบบตรวจจับเครื่องบินอัตโนมัติอาจทำให้การจัดการจราจรที่ท่าจอดไม่มีประสิทธิภาพ เนื่องจากจะต้องใช้บุคลากรมนุษย์ในการตรวจสอบและควบคุมการจราจรที่มีความเสี่ยงมากขึ้น ความผิดพลาดในการบริหารจัดการ การไม่มีระบบตรวจจับเครื่องบินอัตโนมัติอาจทำให้เกิดความผิดพลาดในการบริหารจัดการที่ท่าจอด เช่น การนับจำนวนเครื่องบินที่จอดไม่ถูกต้องหรือการวางแผนการจัดการที่ไม่เหมาะสม และการใช้ทรัพยากรมากขึ้น การไม่มีระบบตรวจจับเครื่องบินอัตโนมัติอาจทำให้ต้องใช้ทรัพยากรมนุษย์และทรัพยากรอื่น ๆ ในการดูแลและควบคุมการจราจรที่ท่าจอดเครื่องบินมากขึ้น ซึ่งอาจเป็นภาระต่อการดำเนินงานของสนามบินและเสียค่าใช้จ่ายเพิ่มขึ้น

ปัญหาในการตรวจจับเครื่องบินจากภาพถ่ายดิจิทัล Chengjie Ye และคณะ[1] ได้กล่าวถึงปัญหาในการตรวจจับเครื่องบินในภาพเรดาร์สังเคราะห์รูรับแสง (SAR) ซึ่งเป็นเทคโนโลยีที่ใช้คลื่นไมโครเวฟในการสร้างภาพ ซึ่งมักใช้ในการสำรวจทางทหารและพลเรือน การตรวจจับเครื่องบินใน

ภาพ SAR นั้นมีความสำคัญมาก แต่ก็เป็นเรื่องที่ท้าทายเนื่องจากความแตกต่างของขนาดเครื่องบินมีขนาดที่แตกต่างกันมาก พื้นที่หลังที่ซับซ้อนเนื่องจากสนามบินมีโครงสร้างที่ซับซ้อนและวัตถุรบกวนมากมาย สัญญารบกวนเนื่องจากภาพ SAR มักมีสัญญาณรบกวนสูง เพื่อแก้ปัญหาดังกล่าว งานวิจัยนี้จึงเสนอวิธีการใหม่ที่เรียกว่า “วิธีการหลายสเกล” โดยใช้โครงข่ายประสาทเทียมชนิดหนึ่งที่เรียกว่า Swin Transformer ซึ่งมีคุณสมบัติเด่นคือการช่วยปรับปรุงการผสมรวมข้อมูลจากหลายระดับของภาพให้เหมาะสมกับงาน Ye, Ziqi และคณะ[2] เสนอเครือข่ายการจัดการฟีเจอร์การกระจายตัว (Convolutional Modulation Scattering Feature Network - CMSF) เพื่อใช้ประโยชน์จากข้อมูลการกระจายตัวในภาพ SAR สำหรับการตรวจจับเครื่องบิน โดยแยกออกเป็น 4 ขั้นตอนหลัก เช่น การดึงฟีเจอร์การกระจายตัวและการหลอมรวมฟีเจอร์ ข้อดีคือการปรับใช้ได้ทุกสภาพอากาศและทุกเวลาแต่ปัญหาคือเส้นขอบของเครื่องบินในภาพ SAR มักไม่ชัดเจนเหมือนภาพถ่ายปกติ และเครื่องบินมักปรากฏเป็นจุด ๆ ทำให้การจำแนกวัตถุทำได้ยาก S. Al Mansoori และคณะ[3] เสนอการพัฒนาแบบตรวจจับเครื่องบินจากภาพถ่ายดาวเทียม โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เรียกว่า YOLOv3 ซึ่งเป็นที่นิยมและมีประสิทธิภาพสูงในการตรวจจับวัตถุในภาพ จุดเด่นของงานวิจัยนี้เน้นไปที่ ความแม่นยำสูง ระบบที่พัฒนาขึ้นสามารถตรวจจับเครื่องบินได้อย่างถูกต้องถึง 97.64% เมื่อทดสอบกับภาพถ่ายดาวเทียม ซึ่งถือว่าเป็นผลลัพธ์ที่ดีมาก ความเร็วในการประมวลผล ซึ่งนอกจากจะแม่นยำแล้ว ระบบยังสามารถทำงานได้อย่างรวดเร็ว ทำให้สามารถนำไปประยุกต์ใช้ในระบบเรียลไทม์ได้ และความเรียบง่าย แม้จะให้ผลลัพธ์ที่ดี แต่โครงสร้างของระบบกลับมี

ความเรียบง่าย ทำให้เข้าใจและปรับปรุงได้ง่าย ปัญหาที่อาจพบการฝึกสอนโมเดลสำหรับงานตรวจจับวัตถุจำเป็นต้องใช้ข้อมูลจำนวนมาก แต่ภาพถ่ายดาวเทียมที่มีคุณภาพสูงมักมีจำนวนจำกัดและมีราคาสูง และความละเอียดของภาพถ่ายดาวเทียมบางภาพอาจมีความละเอียดต่ำ ทำให้การตรวจจับวัตถุขนาดเล็ก เช่น เครื่องบินซึ่งเป็นสิ่งที่ท้าทาย W. Li และคณะ[4] เสนอการพัฒนาในระบบตรวจจับเครื่องบินอัตโนมัติจากภาพถ่ายดาวเทียม โดยใช้เทคนิคการประมวลผลภาพที่เรียกว่า “visual saliency” และ “symmetry detection” จุดเด่นของงานวิจัยนี้คือ ความเสถียร ระบบสามารถตรวจจับเครื่องบินได้อย่างเสถียร ไม่ว่าเครื่องบินจะมีลักษณะ ขนาด หรือท่าทางอย่างไร ประสิทธิภาพในการคำนวณ ระบบคำนวณ “saliency map” และ “symmetry detection” เพียงครั้งเดียว ทำให้ประหยัดเวลาในการประมวลผล ปัญหาที่พบคือ ความซับซ้อนของภาพซึ่งภาพถ่ายดาวเทียมมักมีความซับซ้อน มีวัตถุหลายประเภท และมีการเปลี่ยนแปลงของแสงและเงา ซึ่งอาจทำให้การตรวจจับเครื่องบินมีความท้าทาย

จากการวิเคราะห์งานวิจัยต่าง ๆ เกี่ยวกับการตรวจจับเครื่องบินจากภาพถ่ายดิจิทัล พบว่าปัญหาหลักๆ ที่นักวิจัยต้องเผชิญ ได้แก่ ความหลากหลายของลักษณะเครื่องบิน ทั้งขนาด รูปร่าง และท่าทาง ความซับซ้อนของพื้นหลัง โดยเฉพาะในภาพถ่ายจากดาวเทียมที่มีโครงสร้างและวัตถุรบกวนมากมาย สัญญาณรบกวนในภาพ โดยเฉพาะในภาพเรดาร์ SAR ที่มีสัญญาณรบกวนสูง และความละเอียดของภาพ ที่อาจไม่เพียงพอสำหรับการตรวจจับวัตถุขนาดเล็ก นอกจากนี้ การขาดแคลนข้อมูลที่มีคุณภาพสำหรับการฝึกสอนโมเดลปัญญาประดิษฐ์ก็เป็นอีกหนึ่งอุปสรรคสำคัญในการพัฒนาระบบตรวจจับเครื่องบินให้มีประสิทธิภาพสูงซึ่งจำเป็นต้องมีการพัฒนาวิธีการและเทคนิคที่เหมาะสมเพื่อแก้ไขปัญหาดังกล่าว

1.1 วรรณกรรมที่เกี่ยวข้อง

งานวิจัยที่น่าสนใจในการตรวจจับวัตถุมีอยู่ด้วยกันหลายงานวิจัย อาทิเช่น He, K. และคณะ [5] ได้นำเสนอ Deep Residual Learning (DRL) ซึ่งเป็นเทคนิคการเรียนรู้เชิงลึกสำหรับการรับรู้ภาพ (Image Recognition) โดยเสนอโครงสร้าง Residual Learning ซึ่งช่วยให้เครือข่ายเรียนรู้ฟังก์ชัน “residual”

แทนการเรียนรู้ฟังก์ชันโดยตรง เป็นเทคนิคการเรียนรู้เชิงลึกที่มีประสิทธิภาพสำหรับการรับรู้ภาพ ช่วยให้สร้างเครือข่ายที่ลึกขึ้นและแม่นยำขึ้น Ren, S. และคณะ[6] ได้นำเสนอ Faster R-CNN ซึ่งเป็นอัลกอริทึมตรวจจับวัตถุแบบเรียลไทม์ที่มีประสิทธิภาพโดยใช้ Region Proposal Network (RPN) สำหรับการหา Region ที่น่าจะมีวัตถุ และใช้ Fast R-CNN สำหรับการจำแนกประเภทวัตถุภายใน Region ที่ RPN หาไว้ ผลลัพธ์ที่ได้คือ Faster R-CNN ทำงานได้เร็วกว่า Selective Search มาก และ Faster R-CNN มีความแม่นยำสูง และเป็นอัลกอริทึมตรวจจับวัตถุแบบเรียลไทม์ที่มีประสิทธิภาพและแม่นยำ He, K. และคณะ [7] นำเสนอ Mask R-CNN ซึ่งเป็นโมเดลสำหรับการตรวจจับวัตถุ (Object Detection) และแบ่งส่วนวัตถุ (Instance Segmentation) แบบเรียลไทม์ โดยขยาย Faster R-CNN เพิ่ม branch สำหรับทำนาย Mask ของวัตถุ และใช้ FCN (Fully Convolutional Network) สำหรับการทำนาย Mask Mask R-CNN ทำงานได้เร็วกว่า MaskProp มาก ผลลัพธ์ที่ได้คือ Mask R-CNN มีความแม่นยำใกล้เคียงกับ MaskProp Redmon, X. Mou และคณะ [8] เสนอการพัฒนาในระบบตรวจจับเป้าหมายทางทะเลจากภาพเรดาร์นำทาง PPI โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เรียกว่า Faster R-CNN จุดเด่นของงานวิจัยนี้คือ ระบบใช้โมเดล Faster R-CNN ซึ่งเป็นโมเดลที่นิยมและมีประสิทธิภาพสูงในการตรวจจับวัตถุในภาพ มีการปรับปรุงโมเดล Faster R-CNN เพื่อให้เหมาะสมกับการตรวจจับเป้าหมายทางทะเล และมีการสร้างชุดข้อมูลเฉพาะสำหรับการตรวจจับเป้าหมายทางทะเล เพื่อฝึกสอนโมเดลให้มีความแม่นยำ ผลลัพธ์ที่ได้พบว่าระบบที่พัฒนาขึ้นสามารถตรวจจับเป้าหมายทางทะเลได้อย่างแม่นยำและเชื่อถือได้ประสิทธิภาพดีกว่าวิธีการแบบดั้งเดิม Y. Qian และคณะ [9] เสนอการพัฒนา ระบบตรวจจับเรือในภาพเรดาร์ SAR โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เรียกว่า Mask R-CNN จุดเด่นของงานวิจัยนี้คือ ระบบใช้โมเดล Mask R-CNN ซึ่งเป็นโมเดลที่นิยมและมีประสิทธิภาพสูงในการตรวจจับวัตถุในภาพ การปรับปรุงโมเดล Mask R-CNN เพื่อให้เหมาะสมกับการตรวจจับเรือในภาพ SAR ระบบใช้ชุดข้อมูล SAR SSDD ซึ่งเป็นชุดข้อมูลเฉพาะสำหรับการตรวจจับเรือในภาพ SAR และการใช้เทคนิค Transfer Learning โดยนำน้ำหนัก (weights) ที่

ได้รับการฝึกสอนจากชุดข้อมูล ImageNet มาใช้เป็นจุดเริ่มต้นในการฝึกสอนโมเดล ผลลัพธ์ที่ได้คือ ระบบที่พัฒนาขึ้นสามารถตรวจจับเรือในภาพ SAR ได้อย่างแม่นยำถึง 96.8% และสามารถประมวลผลได้อย่างรวดเร็ว โดยใช้เวลาเพียง 116ms ต่อภาพ ผลลัพธ์ที่ได้แสดงให้เห็นถึงศักยภาพของ Mask R-CNN ในการแก้ไขปัญหาได้อย่างดี J. Redmon และคณะ [10] ได้เสนอ Faster R-CNN ซึ่งเป็นระบบตรวจจับวัตถุที่มีความสามารถในการทำงานแบบเรียลไทม์ โดยมีแนวทางที่รวมกันเป็นหนึ่งเดียวในการตรวจจับวัตถุ ระบบนี้ใช้โครงสร้างแบบ convolutional neural network (CNN) ที่ทำให้สามารถตรวจจับวัตถุในภาพได้อย่างรวดเร็วและมีประสิทธิภาพ YOLO เป็นการปฏิวัติวงการการตรวจจับวัตถุด้วยการลดเวลาการประมวลผล และยังสามารถรักษาความแม่นยำในการตรวจจับได้ในระดับที่ดี พิศณุ ก. [11] นำเสนอการตรวจจับใบหน้านुकคนโดยใช้โมเดล YOLOv4 และเปรียบเทียบกับอัลกอริทึมอื่น ๆ ที่ใช้ในงานวิจัยตรวจจับใบหน้า โดยใช้ชุดข้อมูลรูปภาพจำนวนมากกว่า 3 สภาวะแวดล้อมที่แตกต่างกันอย่างมีนัยสำคัญ โดย 4 อัลกอริทึมที่ถูกใช้ในการเปรียบเทียบคือ Viola-Jones Face Detection Algorithm, DeepFace, FaceNet, และ MTCNN ผลการทดลองพบว่า YOLOv4 เป็นอัลกอริทึมที่มีความสามารถในการตรวจจับใบหน้านुकคนได้ดีที่สุดในงานวิจัยนี้ Pisanu, K. [12] ได้นำเสนอการตรวจจับยานพาหนะ โดยอัลกอริทึมในการตรวจจับภาพวัตถุ ประกอบไปด้วย YOLOv4, Faster R-CNN, และ SSD ผลลัพธ์พบว่า YOLO เป็นโมเดล deep learning ที่มีศักยภาพสูงในการตรวจจับยานพาหนะแบบเรียลไทม์ M. Jindal และคณะ [13] ได้เสนอการพัฒนาระบบตรวจจับเครื่องบินจากภาพถ่ายดาวเทียม โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เรียกว่า YOLO (You Only Look Once) จุดเด่นของงานวิจัยนี้คือ ระบบใช้โมเดล YOLO ซึ่งเป็นโมเดลที่นิยมและมีประสิทธิภาพสูงในการตรวจจับวัตถุในภาพ การปรับปรุงโมเดล YOLO เพื่อให้เหมาะสมกับการตรวจจับเครื่องบินจากภาพถ่ายดาวเทียม และการสร้างชุดข้อมูลเฉพาะสำหรับการตรวจจับเครื่องบินจากภาพถ่ายดาวเทียม ผลลัพธ์ที่ได้พบว่าระบบที่พัฒนาขึ้นสามารถตรวจจับเครื่องบินได้อย่างแม่นยำ โดยมีค่า Mean Average Precision (mAP) สูงกว่าโมเดล

อื่น ๆ และระบบสามารถประมวลผลได้อย่างรวดเร็ว โดยใช้เวลาในการประมวลผลต่อภาพน้อยกว่าโมเดลอื่น ๆ A. Afidhal คณะ [14] ได้เสนอการประเมินประสิทธิภาพของโมเดล YOLOv8 ในการตรวจจับวัตถุแบบเรียลไทม์สำหรับรถยนต์ขับเคลื่อนอัตโนมัติในสภาพแวดล้อมการจราจรที่หลากหลาย จุดเด่นของงานวิจัยนี้คือ การใช้โมเดล YOLOv8 ซึ่งเป็นโมเดลที่ทันสมัยและมีประสิทธิภาพสูงในการตรวจจับวัตถุ การทดสอบถูกดำเนินการในสภาพแวดล้อมการจราจรจริง เพื่อประเมินความสามารถของโมเดลในการใช้งานจริงโดยใช้เมตริกต่างๆ เช่น ความแม่นยำ (accuracy) และ F-Measure ผลลัพธ์ที่ได้พบว่าโมเดล YOLOv8 มีประสิทธิภาพดีในการตรวจจับวัตถุในสภาพแสงกลางวัน โดยมีค่าความแม่นยำอยู่ระหว่าง 0.60 ถึง 0.80 และค่า F-Measure อยู่ระหว่าง 0.75 ถึง 0.87 แต่จะมีประสิทธิภาพต่ำในการตรวจจับวัตถุในสภาพแสงน้อย โดยมีค่าความแม่นยำอยู่ระหว่าง 0.15 ถึง 0.25 และค่า F-Measure อยู่ระหว่าง 0.27 ถึง 0.46 งานวิจัยนี้แสดงให้เห็นว่าโมเดล YOLOv8 สามารถตรวจจับวัตถุได้อย่างมีประสิทธิภาพในสภาพแสงกลางวัน แต่ยังมีข้อจำกัดในการตรวจจับวัตถุในสภาพแสงน้อย ซึ่งเป็นหนึ่งในความท้าทายหลักในการพัฒนาระบบตรวจจับวัตถุสำหรับรถยนต์ขับเคลื่อนอัตโนมัติ Sriram, S. และคณะ [15] เสนอการพัฒนาระบบตรวจจับและจดจำสัญญาณไฟจราจรโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เรียกว่า YOLOv8 โดยจุดเด่นของงานวิจัยนี้คือ ระบบใช้โมเดล YOLOv8 ซึ่งเป็นโมเดลที่ทันสมัยและมีประสิทธิภาพสูงในการตรวจจับวัตถุ การปรับปรุงโมเดล YOLOv8 เพื่อให้เหมาะสมกับการตรวจจับสัญญาณไฟจราจร ผลลัพธ์แม้จะมีข้อจำกัดของวิธีการที่มีอยู่ เช่น ความแม่นยำต่ำและเวลาในการตรวจจับที่ยาวนาน แต่ YOLOv8 ก็มีความก้าวหน้าที่มีแนวโน้มดี การปรับปรุง YOLO ที่แนะนำในการวิจัยนี้จะช่วยเพิ่มความแม่นยำในขณะที่ลดเวลาในการตรวจจับได้ R. Bawankule และคณะ [16] เสนอการพัฒนาระบบคัดแยกขยะอัตโนมัติโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เรียกว่า YOLOv8 จุดเด่นของงานวิจัยนี้คือ ระบบใช้โมเดล YOLOv8 ซึ่งเป็นโมเดลที่ทันสมัยและมีประสิทธิภาพสูงในการตรวจจับวัตถุ ระบบมีเป้าหมายในการแก้ไขปัญหาต่างๆ ที่เกี่ยวข้องกับการคัดแยกขยะ เช่น การ

ปนเปื้อน มลพิษ และความไม่สะดวก ผลลัพธ์ที่ได้พบว่าระบบที่พัฒนาขึ้นสามารถตรวจจับและคัดแยกขยะได้อย่างแม่นยำและมีประสิทธิภาพสูงกว่าวิธีการเดิม

1.2 งานวิจัยที่เกี่ยวข้อง

โมเดล DRL, Faster R-CNN, Mask R-CNN, YOLO, YOLOv4, YOLO-Fastest ล้วนเป็นโมเดลการตรวจจับวัตถุที่ถูกใช้งานอย่างแพร่หลาย YOLOv4 ถูกนำไปใช้สำหรับการตรวจจับใบหน้าบุคคลและยานพาหนะ ผลการทดลองพบว่าสามารถใช้งานได้เป็นอย่างดี YOLOv5 ถูกนำไปใช้สำหรับการตรวจจับและติดตามเครื่องบินบนภาพถ่ายทางอากาศ ผลการทดลองพบว่าสามารถใช้งานได้ดีเช่นกัน และYOLOv8 ถูกนำไปใช้สำหรับการตรวจจับวัตถุบนถนน ป้ายจราจร และขยะ ผลการทดลองพบว่าได้ผลลัพธ์ที่ดีและมีความแม่นยำสูง จากงานวิจัยที่ศึกษา พบว่า YOLOv8 เป็นโมเดลการตรวจจับวัตถุที่มีความสามารถในการปฏิบัติการสูง จึงเหมาะสำหรับงานตรวจจับวัตถุแบบเรียลไทม์ งานวิจัยนี้มุ่งเน้นไปที่การเปรียบเทียบการทำงานของโมเดลย่อย YOLOv8 ทั้ง 5 รุ่น ได้แก่ YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l และ YOLOv8x โดยเปรียบเทียบทั้งความเร็วในการประมวลผลและความแม่นยำในการตรวจจับวัตถุ เป้าหมายคือเพื่อเลือกโมเดลที่เหมาะสมที่สุดสำหรับงานเฉพาะที่ต้องการ

1.3 วัตถุประสงค์

เพื่อเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 แต่ละรุ่น (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8x) ในระบบตรวจจับเครื่องบินอัตโนมัติ หาโมเดล YOLOv8 ที่มีประสิทธิภาพสูงสุด เหมาะสำหรับการใช้งานในระบบตรวจจับเครื่องบิน โดยมีขอบเขตคือ งานวิจัยนี้มุ่งเน้นไปที่การตรวจจับเครื่องบินจอดบนพื้น โดยไม่ได้พิจารณาการตรวจจับเครื่องบินที่กำลังบินอยู่ งานวิจัยนี้ใช้ชุดข้อมูลภาพถ่ายสนามบินที่มีเครื่องบินจอดอยู่ ไม่ได้ใช้ข้อมูลวิดีโอ และงานวิจัยนี้ใช้วิธีการประเมินประสิทธิภาพโมเดลด้วย Confusion matrix ไม่ได้ใช้วิธีการประเมินอื่น ๆ ผลลัพธ์ที่คาดหวังคือเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 แต่ละรุ่น ในแง่ของความแม่นยำ ความเร็ว และการใช้ทรัพยากร เลือกโมเดล YOLOv8 ที่เหมาะสมที่สุด สำหรับการใช้งานในระบบตรวจจับเครื่องบิน

2. วิธีวิจัย

งานวิจัยนี้ใช้ YOLOv8 ในการตรวจจับเครื่องบินในภาพถ่ายสนามบิน โดยเปรียบเทียบประสิทธิภาพของ YOLOv8 แต่ละรุ่น ฝึกโมเดลด้วยชุดข้อมูลภาพถ่าย และประเมินผลด้วย Confusion matrix, Precision, Recall, และ f1-score เพื่อหาโมเดลที่ดีที่สุดสำหรับงาน อัลกอริทึมที่ใช้งานรวมไปถึงทฤษฎีต่าง ๆ ดังนี้

2.1 ข้อมูล

ประกอบไปด้วยความหลากหลาย ประเภทเครื่องบิน เช่น เครื่องบินโดยสาร เครื่องบินไอพ่น เครื่องบินรบ เครื่องบินขนส่ง ฯลฯ ขนาดเครื่องบินที่มีขนาดเล็ก กลาง ใหญ่ สีเครื่องบิน ขาว เทา น้ำเงิน ฯลฯ มุมมองจากด้านบน สภาพมีแสงแดด สภาพอากาศปกติ ภาพมีความคมชัด มีความละเอียดสูง ไฟกัศจาดเจน ไม่มีภาพเบลอ รูปแบบรูปแบบ JPEG แหล่งข้อมูลภาพจาก google earth

2.2 โมเดลที่ใช้


งานวิจัยนี้ใช้การเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 แต่ละรุ่น (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8nx)

2.2.1 ทฤษฎีของ YOLO

Y. Lu และ W. Xie [17] ทฤษฎีของ YOLO (You Only Look Once) มีแนวคิดหลักคือ YOLO เป็น โมเดลการตรวจจับวัตถุที่ใช้แนวทางการประมวลผลภาพแบบ end-to-end ซึ่งหมายความว่าโมเดลสามารถทำการตรวจจับวัตถุในภาพได้ในครั้งเดียว โดยไม่ต้องแบ่งขั้นตอนการตรวจจับ และการจำแนกประเภทออกจากกัน ในส่วนของโครงสร้างของ YOLO แบ่งภาพออกเป็นกริดขนาด $n \times n$ โดยแต่ละเซลล์ในกริดจะรับผิดชอบในการตรวจจับวัตถุที่อยู่ในเซลล์นั้น Bounding Box สำหรับแต่ละเซลล์ YOLO จะคาดการณ์ bounding box (กรอบที่ล้อมรอบวัตถุ) และความมั่นใจ (confidence score) ว่าวัตถุอยู่ในกรอบนั้น และ Class Probability การคาดการณ์ความน่าจะเป็นของแต่ละประเภทวัตถุในกรอบที่คาดการณ์ การคำนวณ YOLO จะใช้ฟังก์ชันการสูญเสีย (loss function) ที่รวมความผิดพลาดของ bounding box ความมั่นใจ และความน่าจะเป็นของประเภทวัตถุ เพื่อปรับปรุงการเรียนรู้ของโมเดล และโมเดล

ถูกฝึกด้วยข้อมูลที่มีการติดป้ายกำกับ (labeled data) เพื่อให้สามารถเรียนรู้ลักษณะของวัตถุและวิธีการตรวจจับได้อย่างมีประสิทธิภาพ ในส่วนของข้อดีและข้อเสีย ข้อดีคือมีความเร็วสูงในการประมวลผลภาพ ทำให้เหมาะสำหรับการใช้งานในเวลาจริง สามารถการตรวจจับวัตถุในหลายประเภทในภาพเดียว แต่มีข้อเสียคือ อาจมีความแม่นยำน้อยกว่าระบบตรวจจับแบบสองขั้นตอน (เช่น R-CNN) ในบางกรณี และอาจมีปัญหาในการตรวจจับวัตถุขนาดเล็กหรือวัตถุที่อยู่ใกล้กัน สุดท้ายในส่วนของการพัฒนา YOLO ได้มีการพัฒนาอย่างต่อเนื่อง โดยมีเวอร์ชันต่าง ๆ เช่น YOLOv2, YOLOv3 และ YOLO-compact ซึ่งมุ่งเน้นการปรับปรุงความแม่นยำและลดขนาดโมเดลเพื่อให้เหมาะสมกับการใช้งานในสภาพแวดล้อมที่หลากหลาย ทฤษฎีของ YOLO จึงเป็นพื้นฐานสำคัญในการพัฒนาเทคโนโลยีการตรวจจับวัตถุในปัจจุบัน โดยเฉพาะในแอปพลิเคชันที่ต้องการความเร็วและประสิทธิภาพสูง

ขั้นตอนการตรวจจับภาพวัตถุด้วย YOLO [18] ประกอบไปด้วยขั้นตอนต่าง ๆ ดังนี้ 1) เตรียมชุดข้อมูล ชุดข้อมูลควรมีรูปภาพที่มีวัตถุที่คุณต้องการตรวจจับแต่ละรูปภาพควรมี bounding box ที่ล้อมรอบวัตถุ 2) ฝึกโมเดล YOLO โมเดล YOLO สามารถฝึกอบรมได้โดยใช้ TensorFlow หรือ PyTorch 3) ทดสอบโมเดล สามารถทดสอบโมเดล YOLO บนรูปภาพใหม่โมเดลจะทำนาย Bounding boxes และคะแนนความน่าจะเป็นว่า bounding box นั้นมีวัตถุอยู่ และ 4) ปรับแต่งโมเดล สามารถปรับแต่งโมเดล YOLO เพื่อให้ทำงานได้ดีขึ้นกับชุดข้อมูล และสามารถปรับแต่ง hyperparameters ของโมเดล หรือใช้สถาปัตยกรรมโมเดลอื่น ตามที่แสดงดังรูปที่ 1



รูปที่ 1 แสดงสถาปัตยกรรมโมเดล YOLO

รูปที่ 1 แสดงสถาปัตยกรรมโมเดล YOLO ซึ่งประกอบด้วย 4 ส่วนหลักคือ 1) Backbone ใช้โมเดล CNN ทำหน้าที่สกัดคุณลักษณะจากภาพโมเดล CNN ที่นิยมใช้ได้แก่ Darknet, CSPNet, EfficientNet 2) Neck ประมวลผลฟีเจอร์แม็พจาก Backbone ผสมผสานฟีเจอร์แม็พจากหลายระดับ และเพิ่มข้อมูลเชิงบริบท (Contextual information) 3) Head ทำนาย Bounding Boxes และคะแนนความน่าจะเป็น ใช้ Anchor Boxes คะแนนความน่าจะเป็นแสดงโอกาสที่วัตถุจะปรากฏใน Bounding Box และ 4) Loss Function คำนวณค่าความสูญเสียเพื่อปรับโมเดล ประกอบด้วย 2 องค์ประกอบคือ Classification loss คำนวณความสูญเสียจากการจำแนกประเภท และ Localization loss คำนวณความสูญเสียจากตำแหน่ง Bounding Box

2.2.2 ทฤษฎีของ YOLOv8

YOLOv8 [19],[20] YOLOv8 เป็นอัลกอริทึมการตรวจจับวัตถุแบบเรียลไทม์ที่พัฒนาต่อยอดมาจาก YOLOv7 โมเดลนี้ได้รับการออกแบบมาให้ความรวดเร็ว แม่นยำ และใช้งานง่าย YOLOv8 มีสถาปัตยกรรมแบบ Darknet-based CNN (Convolutional Neural Network) มีหลักการทำงานดังนี้ การแบ่งภาพ ภาพจะถูกแบ่งออกเป็นกริด (Grid) แต่ละเซลล์ในกริดจะทำหน้าที่คาดการณ์วัตถุและคลาสของวัตถุที่ปรากฏในเซลล์นั้น การดึงคุณลักษณะ CNN จะดึงคุณลักษณะจากภาพ YOLOv8 ใช้เทคนิค Path Aggregation Network (PANet) ในการดึงคุณลักษณะจากหลายระดับความละเอียด ช่วยให้โมเดลสามารถจับภาพวัตถุที่มีขนาดแตกต่างกันได้ และการทำนาย โมเดลจะทำนายคลาสและขอบเขต (bounding box) ของวัตถุในแต่ละเซลล์ของกริด มีจุดเด่นคือ ความรวดเร็ว YOLOv8 สามารถทำงานได้อย่างรวดเร็ว เหมาะสำหรับการใช้งานแบบเรียลไทม์ ความแม่นยำ YOLOv8 มีความแม่นยำสูงในการตรวจจับวัตถุ และใช้งานง่าย YOLOv8 เป็นโมเดลที่ใช้งานง่าย ผู้ใช้สามารถปรับแต่งโมเดลให้เหมาะกับงานของตนได้โดยไม่ต้องมีความรู้ด้านการเรียนรู้เชิงลึกมากนัก

สถาปัตยกรรมของ YOLOv8 ประกอบไปด้วยส่วนหลัก 4 ส่วน ดังนี้ 1) Backbone เป็นส่วนที่รับภาพเข้ามาและดึงคุณลักษณะของภาพ YOLOv8 ใช้ Backbone แบบ

CSPDarknet53 2) Neck เป็นส่วนที่รวมคุณลักษณะจาก Backbone หลายระดับความละเอียดเข้าด้วยกัน YOLOv8 ใช้ Neck แบบ Path Aggregation Network (PANet) 3) Head เป็นส่วนที่ทำนายคลาสและขอบเขต (bounding box) ของวัตถุ YOLOv8 ใช้ Head แบบ YOLO Head และ 4) Detection เป็นส่วนที่แปลงผลลัพธ์จาก Head ให้เป็นรูปแบบที่เข้าใจได้ง่าย YOLOv8 ใช้ Detection แบบ Non-Maximum Suppression (NMS)

ข้อดี ความรวดเร็ว สถาปัตยกรรมของ YOLOv8 ช่วยให้โมเดลทำงานได้อย่างรวดเร็ว ความแม่นยำ ดังแสดงใน **รูปที่ 2** สถาปัตยกรรมของ YOLOv8 ช่วยให้โมเดลมีความแม่นยำสูง และการตรวจจับวัตถุหลายขนาด สถาปัตยกรรมของ YOLOv8 ช่วยให้โมเดลสามารถตรวจจับวัตถุที่มีขนาดแตกต่างกันได้

ข้อเสียการใช้ทรัพยากร สถาปัตยกรรมของ YOLOv8 ใช้ทรัพยากรคอมพิวเตอร์ค่อนข้างมาก และการตรวจจับวัตถุซ้อนทับ สถาปัตยกรรมของ YOLOv8 อาจมีปัญหาในการตรวจจับวัตถุที่ซ้อนทับกัน




รูปที่ 2 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8

รูปที่ 2 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8 ที่ระดับความเชื่อมั่นที่ 0.55 และ 0.77 ตามลำดับ

2.3 วิธีการทดลอง

วิธีการทดลองแบ่งออกเป็นขั้นตอนต่างๆ แสดงใน **รูปที่ 3**



รูปที่ 3 แสดงขั้นตอนการทดลอง

ขั้นที่ 1 เตรียมชุดข้อมูล เก็บภาพสนามบินที่มีเครื่องบินจอดอยู่ 1,000 ภาพ แบ่งเป็น 900 ภาพสำหรับฝึกโมเดล และ 100 ภาพสำหรับทดสอบปรับขนาดภาพให้เท่ากัน กำหนด bounding boxes รอบเครื่องบินในแต่ละภาพ


ขั้นที่ 2 ฝึกโมเดล ฝึกโมเดล YOLO บนชุดข้อมูล 900 ภาพ ปรับ hyperparameters ของ โมเดลแต่ละตัวให้เหมาะสม

ขั้นที่ 3 ทดสอบโมเดล ทดสอบโมเดลแต่ละตัวบนชุดข้อมูล 100 ภาพ เปรียบเทียบความแม่นยำของโมเดลแต่ละตัวเปรียบเทียบความเร็วของโมเดลแต่ละตัว

ขั้นที่ 4 วิเคราะห์ผลลัพธ์ วิเคราะห์ว่าโมเดลตัวใดมีประสิทธิภาพสูงสุด และวิเคราะห์ว่าโมเดลตัวใดทำงานได้เร็วที่สุด

2.4 การเปรียบเทียบ

ดึงข้อมูลภาพ ขั้นตอนแรกของการกระบวนการคือการดึงข้อมูลภาพจากฐานข้อมูลภาพ ภาพที่ดึงมาจะต้องผ่านการตรวจสอบคุณภาพเบื้องต้น เพื่อกำจัดภาพที่มี Noise หรือภาพที่ไม่เกี่ยวข้อง ต่อมาทำการแปลงภาพเป็นข้อมูล ภาพที่ดึงมาจะถูกแปลงเป็นข้อมูลดิจิทัลโดยใช้เทคนิคการประมวลผลภาพดิจิทัล ข้อมูลดิจิทัลนี้จะถูกใช้เป็นข้อมูลป้อนเข้าสำหรับโมเดล YOLO จากนั้นจะประมวลผลภาพด้วยโมเดล YOLO โมเดล YOLO แต่ละรุ่นจะถูกนำมาประมวลผลภาพ โมเดลจะทำการตรวจจับวัตถุในภาพ และระบุตำแหน่งของวัตถุ ผลลัพธ์จากโมเดล YOLO แต่ละรุ่นจะถูกบันทึกไว้ สุดท้ายจะเปรียบเทียบประสิทธิภาพโมเดลจากผลลัพธ์จากโมเดล YOLO แต่ละรุ่นจะถูกนำมาเปรียบเทียบกัน การเปรียบเทียบจะทำได้โดยใช้ Confusion matrix ค่า Precision, Recall, และ f1-score จะถูกคำนวณสำหรับโมเดลแต่ละรุ่น โมเดลที่มีประสิทธิภาพสูงสุดจะถูกเลือกสำหรับงานวิจัยดังแสดงใน **รูปที่ 4**



รูปที่ 4 แสดงขั้นตอนการทำงานของอัลกอริทึม

รูปที่ 4 แสดงให้เห็นกระบวนการทำงานของ YOLO ตั้งแต่เริ่มต้นจนจบกระบวนการ ดังนี้

- 1) รับรูปภาพ (Get pictures)
ขั้นตอนแรก YOLO จะรับรูปภาพที่ต้องการตรวจจับวัตถุ รูปภาพนี้สามารถเป็นไฟล์ภาพบนดิสก์ หรือเฟรมจากวิดีโอ
- 2) สกัดคุณสมบัติของภาพด้วย CNN (CNN: Image Feature Extraction)

ในขั้นตอนนี้ YOLO จะใช้ Convolutional Neural Network (CNN) เพื่อสกัดคุณสมบัติของภาพ CNN เป็นโครงข่ายประสาทเทียมประเภทหนึ่งที่ออกแบบมาเพื่อวิเคราะห์ข้อมูลภาพ CNN จะแบ่งภาพออกเป็นส่วนย่อยๆ ที่เรียกว่า “ฟิลเตอร์” แต่ละฟิลเตอร์จะตรวจจับคุณสมบัติเฉพาะของภาพ เช่น ขอบ เส้น หรือสี ผลลัพธ์ของขั้นตอนนี้คือแผนที่คุณสมบัติของภาพ ซึ่งแสดงตำแหน่งและความสำคัญของคุณสมบัติต่างๆ ในภาพ

3) แบ่งภาพออกเป็นเซลล์ตาราง (Split the image into grid cells)

YOLO จะแบ่งภาพออกเป็นเซลล์ตารางโดยทั่วไปขนาด 7×7 หรือ 13×13 แต่ละเซลล์ตารางจะครอบคลุมพื้นที่ส่วนหนึ่งของภาพ

4) ทำนายกรอบวัตถุและคะแนนความน่าจะเป็นสำหรับแต่ละเซลล์ตาราง (Predict Bounding Boxes and Probability Score for each Grid Cell)

สำหรับแต่ละเซลล์ตาราง YOLO จะทำนายกรอบวัตถุและคะแนนความน่าจะเป็น กรอบวัตถุคือสี่เหลี่ยมผืนผ้าที่ล้อมรอบวัตถุในภาพ คะแนนความน่าจะเป็นคือค่าระหว่าง 0 ถึง 1 ซึ่งแสดงความมั่นใจของ YOLO ว่ามีวัตถุอยู่ในเซลล์ตารางหรือไม่

5) ลบกรอบวัตถุที่ทับซ้อนกัน (Remove overlapping Bounding Boxes)

ในบางกรณี เซลล์ตารางที่อยู่ใกล้เคียงกันอาจทำนายกรอบวัตถุสำหรับวัตถุเดียวกัน ในขั้นตอนนี้ YOLO จะลบกรอบวัตถุที่ทับซ้อนกันโดยใช้เทคนิคที่เรียกว่า “Non-Maximum Suppression” (NMS) NMS จะเก็บเฉพาะกรอบวัตถุที่มีคะแนนความน่าจะเป็นสูงสุด

3. ผลการทดลอง

3.1 Confusion Matrix

Confusion Matrix [21] เป็นเครื่องมือที่ใช้ประเมินประสิทธิภาพของโมเดลการจำแนกประเภท โดยแสดงจำนวนตัวอย่างที่โมเดลจำแนกได้ถูกต้อง และจำนวนตัวอย่างที่โมเดลจำแนกผิด Confusion Matrix ประกอบด้วย 4 เซลล์หลัก ดังแสดงดังตารางที่ 1

ตารางที่ 1 คำอธิบาย Confusion Matrix 4 เซลล์หลัก

เซลล์	คำอธิบาย
TP (True Positive)	จำนวนภาพที่โมเดลจัดเป็นเครื่องบิน และ เป็นเครื่องบินจริง แสดงว่าโมเดลตรวจจับภาพเครื่องบินได้ถูกต้อง
TN (True Negative)	จำนวนภาพที่โมเดลจัดเป็นไม่ใช่เครื่องบิน และ ไม่ได้เป็นเครื่องบินจริง แสดงว่าโมเดลแยกแยะภาพที่ไม่ใช่เครื่องบินได้ถูกต้อง
FP (False Positive)	จำนวนภาพที่โมเดลจัดเป็นเครื่องบิน แต่ ไม่ได้เป็นเครื่องบินจริง แสดงว่าโมเดลตรวจจับภาพที่ไม่ใช่เครื่องบินเป็นเครื่องบินโดยผิดพลาด
FN (False Negative)	จำนวนภาพที่โมเดลจัดเป็นไม่ใช่เครื่องบิน แต่ เป็นเครื่องบินจริง แสดงว่าโมเดลพลาดการตรวจจับภาพเครื่องบิน

เมื่อคำนวณได้ค่า TP, FP, FN, และ TN แล้ว สามารถใช้ค่าเหล่านี้ในการคำนวณค่าประสิทธิภาพของระบบ โดยมีสูตรสำคัญดังสมการที่ (1)–(3)

$$precision = \frac{TP}{TP+FP} \quad (1)$$

$$recall = \frac{TP}{TP+FN} \quad (2)$$

$$F1score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (3)$$

การคำนวณค่าประสิทธิภาพจาก Confusion Matrix สามารถคำนวณค่าประสิทธิภาพโมเดลได้ดังนี้ Precision ค่าร้อยละของตัวอย่างที่โมเดลจำแนกเป็นคลาสใดคลาสหนึ่ง และเป็นคลาสที่ถูกต้อง Recall ค่าร้อยละของตัวอย่างที่แท้จริงอยู่ในคลาสใดคลาสหนึ่ง และโมเดลจำแนกได้ถูกต้อง และ F1-score ค่าเฉลี่ยฮาร์โมนิกของ Precision และ Recall

3.2 ผลการประเมินประสิทธิภาพ

งานวิจัยนี้เสนอระบบตรวจจับเครื่องบินอัตโนมัติโดยใช้เทคนิคการประมวลผลภาพดิจิทัลจากภาพถ่ายทำจดเครื่องบิน ระบบนี้ใช้การเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 แต่ละรุ่น (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8nl, YOLOv8nx) มีผลการทดลองแสดงดังตารางที่ 2 ประเมินประสิทธิภาพความแม่นยำดังแสดงในตารางที่ 3


ตารางที่ 2 ประเมินประสิทธิภาพ Confusion matrix

	TP	FP	FN	TN
YOLOv8n	55	9	25	11
YOLOv8s	43	14	37	6
YOLOv8m	47	12	33	8
YOLOv8nl	49	10	31	10
YOLOv8nx	59	4	21	16


ตารางที่ 3 ประเมินประสิทธิภาพความแม่นยำ

Measure	YOLOv8n	YOLOv8s	YOLOv8m	YOLOv8nl	YOLOv8nx
Size (pixels)	640	640	640	640	640
Precision	0.75	0.80	0.83	0.86	0.94
Recall	0.54	0.59	0.61	0.69	0.74
F1-score	0.63	0.68	0.71	0.76	0.83
Time (ms)	0.95	1.17	1.74	2.26	3.43


แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8nx ที่ระดับความเชื่อมั่นที่แตกต่างกันดังแสดงในรูปที่ 5–8



รูปที่ 5 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8



รูปที่ 6 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8



รูปที่ 7 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8



รูปที่ 8 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8

รูปที่ 5-8 แสดงผลการตรวจจับภาพวัตถุด้วย YOLOv8nx ที่ระดับความเชื่อมั่นที่แตกต่างกัน ถ้าคะแนนสูง เช่น 90% ขึ้นไป แสดงว่าโมเดลมั่นใจว่าวัตถุนั้นเป็นสิ่งที่คาดไว้ แต่ถ้าคะแนนต่ำ เช่น 50% หรือต่ำกว่า แสดงว่าโมเดลไม่แน่ใจว่าวัตถุนั้นเป็นสิ่งที่คาดไว้ หรืออาจเป็นวัตถุอื่นก็ได้

4. อภิปรายและสรุปผล

4.1 สรุปผล

จากตารางผลการทดลองเปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 แต่ละรุ่น (YOLOv8n, YOLOv8s, YOLOv8m, YOLOv8l, YOLOv8nx) ในการตรวจจับภาพเครื่องบิน จากการทดลองพบว่า อัลกอริทึม YOLOv8nx มีประสิทธิภาพสูงสุดในการตรวจจับภาพเครื่องบินจากลานจอดเครื่องบิน อัลกอริทึม YOLOv8nx มีค่า Precision, Recall, F1-score สูงที่สุด อัลกอริทึม YOLOv8n มีประสิทธิภาพต่ำสุดในการตรวจจับภาพเครื่องบินจากลานจอดเครื่องบิน อัลกอริทึม YOLOv8n มีค่า Precision, Recall, F1-score ต่ำที่สุดในด้านการประมวลผล YOLOv8nx ใช้เวลานานที่สุดในการประมวลผลภาพหนึ่งภาพ แสดงว่าโมเดลนี้มีความซับซ้อนสูง

YOLOv8n ใช้เวลาน้อยที่สุดในการประมวลผลภาพหนึ่งภาพ แสดงว่าโมเดลนี้มีความซับซ้อนต่ำ YOLOv8s ใช้เวลาประมวลผลภาพนานกว่า YOLOv8n YOLOv8m ใช้เวลาประมวลผลภาพนานกว่า YOLOv8s และ YOLOv8l ใช้เวลาประมวลผลภาพนานกว่า YOLOv8m สำหรับการเลือกโมเดลที่เหมาะสม หากต้องการโมเดลที่มีประสิทธิภาพสูงสุด ควรเลือก YOLOv8nx หากต้องการโมเดลที่ใช้เวลาประมวลผลภาพน้อยควรเลือก YOLOv8n หรือ YOLOv8s และต้องการโมเดลที่มีสมดุลระหว่างประสิทธิภาพและเวลาประมวลผลควรเลือก YOLOv8s, YOLOv8m, หรือ YOLOv8nl ทั้งนี้ขึ้นอยู่กับความต้องการในการนำไปใช้งานจริง

4.2 บทสรุป

โมเดล YOLOv8 เป็นโมเดลการตรวจจับวัตถุที่มีประสิทธิภาพสูง สามารถใช้ตรวจจับภาพเครื่องบินได้อย่างแม่นยำ โมเดล YOLOv8n เหมาะสำหรับการใช้งานที่ต้องการความเร็วในการประมวลผลสูง โมเดล YOLOv8nx เหมาะสำหรับการใช้งานที่ต้องการประสิทธิภาพสูงสุด

4.3 การอภิปรายผล

YOLOv8nx มีประสิทธิภาพการตรวจจับสูงสุด แต่ใช้เวลาประมวลผลนาน เหมาะสำหรับงานที่ต้องการความแม่นยำสูงสุด โดยไม่คำนึงถึงความเร็ว YOLOv8n มีประสิทธิภาพการตรวจจับต่ำสุด แต่ใช้เวลาประมวลผลเร็ว เหมาะสำหรับงานที่ต้องการความเร็ว YOLOv8s, YOLOv8m, และ YOLOv8nl อยู่ตรงกลางระหว่าง YOLOv8nx และ YOLOv8n เหมาะสำหรับงานที่ต้องการทั้งความแม่นยำและความเร็วในระดับปานกลาง

โมเดลที่มีโครงสร้างโมเดลซับซ้อน จำนวนพารามิเตอร์มาก และความละเอียดของ Feature Map สูง จะมีประสิทธิภาพการตรวจจับสูง แต่ใช้เวลาประมวลผลนาน โมเดลที่มีโครงสร้างโมเดลเรียบง่าย จำนวนพารามิเตอร์น้อย และความละเอียดของ Feature Map ต่ำ จะมีประสิทธิภาพการตรวจจับต่ำ แต่ใช้เวลาประมวลผลเร็ว และโมเดลที่มีโครงสร้างโมเดลปานกลาง จำนวนพารามิเตอร์ปานกลาง และความละเอียดของ Feature Map ปานกลาง จะมีประสิทธิภาพการตรวจจับปานกลาง และใช้เวลาประมวลผล

5. ข้อเสนอแนะ

จากผลการทดลองและการวิเคราะห์ข้างต้น งานวิจัยนี้มีจุดแข็งหลายประการ แต่ยังมีช่องทางการพัฒนาเพิ่มเติมดังนี้ 1) ขยายชุดข้อมูล เพิ่มจำนวนภาพเครื่องบินในชุดข้อมูลให้หลากหลายมากขึ้น เพิ่มภาพเครื่องบินในสถานะแสงที่แตกต่างกัน สภาพอากาศที่แตกต่างกัน และมุมมองที่แตกต่างกัน เพิ่มภาพเครื่องบินที่มีขนาดและประเภทแตกต่างกัน 2) ปรับแต่งไฮเปอร์พารามิเตอร์ ปรับแต่งไฮเปอร์พารามิเตอร์ของโมเดล YOLOv8 แต่ละรุ่นให้เหมาะสมกับชุดข้อมูล ศึกษาเทคนิคการปรับแต่งไฮเปอร์พารามิเตอร์ เช่น Grid Search, Random Search, Bayesian Optimization 3) เปรียบเทียบโมเดล YOLOv8 กับโมเดลการตรวจจับวัตถุอื่น ๆ เปรียบเทียบประสิทธิภาพของโมเดล YOLOv8 กับโมเดลการตรวจจับวัตถุอื่น ๆ เช่น Faster R-CNN, SSD วิเคราะห์จุดแข็งและจุดอ่อนของโมเดล YOLOv8 เมื่อเปรียบเทียบกับโมเดลอื่น ๆ 4) ทดสอบโมเดลบนระบบจริง ทดสอบประสิทธิภาพของโมเดล YOLOv8 บนระบบจริง เช่น กล้อง CCTV ประเมินประสิทธิภาพของโมเดลในสภาพแวดล้อมจริง และ 5) พัฒนาระบบตรวจจับเครื่องบินแบบเรียลไทม์ พัฒนาระบบตรวจจับเครื่องบินแบบเรียลไทม์โดยใช้โมเดล YOLOv8 วิเคราะห์ประสิทธิภาพของระบบในแง่ของความเร็วและความแม่นยำ

6. กิตติกรรมประกาศ

ขอกราบขอบพระคุณ รศ. ดร. สมชาติ จิริวิภากร อาจารย์ที่ปรึกษาเป็นอย่างสูง ที่ให้คำปรึกษา แนะนำแนวทาง และช่วยแก้ไขปัญหาดังกล่าว ที่เกิดขึ้นตลอดระยะเวลาการทำวิจัยและขอขอบคุณ น.ท.ศ.ดร.พิศณุ ภูมิชัย อาจารย์กองวิชาวิศวกรรมศาสตร์ ฝายศึกษาโรงเรียนนายเรือ ที่เอื้อเฟื้ออุปกรณ์เครื่องมือในการวิจัย แนะนำการเขียนโปรแกรม และให้คำปรึกษาจนงานวิจัยนี้สำเร็จลุล่วงไปด้วยดี การสนับสนุนจากอาจารย์ทั้งสองท่าน มีความสำคัญอย่างยิ่งต่อความสำเร็จของงานวิจัยนี้ หวังว่างานวิจัยนี้จะเป็นประโยชน์ต่อผู้สนใจ และสามารถนำไปต่อยอดเพื่อพัฒนาผลงานต่อไปได้

เอกสารอ้างอิง

- [1] C. Ye, J. Tian and T. Tian, "Multi Scale SAR Aircraft Detection Based on Swin Transformer and Adaptive Feature Fusion Network," in *IGARSS 2023 - 2023 IEEE International Geoscience and Remote Sensing Symposium*, Pasadena, CA, USA, 2023, pp. 7058–7061, doi: 10.1109/IGARSS52108.2023.10283111.
- [2] Z. Ye, X. Xiao and H. Wang, "Convolutional modulated scattering feature network for aircraft classification in SAR images," in *2024 IEEE International Geoscience and Remote Sensing Symposium (IGARSS)*, Athens, Greece, Jul. 7–12, 2024, doi: 10.1109/IGARSS53475.2024.10641325.
- [3] S. Al Mansoori, A. Kunhu and A. AlHammadi, "Effective Airplane Detection in High Resolution Satellite Images using YOLOv3 Model," in *Proc. 2021 4th International Conference on Signal Processing and Information Security (ICSPIS)*, Nov. 24–25, 2021, pp. 57–60, doi: 10.1109/ICSPIS53734.2021.9652416.
- [4] W. Li, S. Xiang, H. Wang and C. Pan, "Robust airplane detection in satellite images," in *2011 18th IEEE International Conference on Image Processing (ICIP)*, Sep. 11–14, 2011, pp. 2821–2824, doi: 10.1109/ICIP.2011.6116259.
- [5] K. He, X. Zhang, S. Ren and J. Sun, "Deep Residual Learning for Image Recognition," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, Jun. 27–30, 2016, pp. 770–778, doi: 10.1109/CVPR.2016.90.
- [6] S. Ren, K. He, R. Girshick and J. Sun, "Faster R-CNN: Towards Real-Time Object Detection with Region Proposal Networks," *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 39, no. 6, pp. 1137–1149, 2017, doi: 10.1109/TPAMI.2016.2577031.
- [7] K. He, G. Gkioxari, P. Dollár and R. Girshick, "Mask R-CNN," in *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, Italy, Oct. 22–29, 2017, pp. 2980–2988, doi: 10.1109/ICCV.2017.322.
- [8] X. Mou, X. Chen, J. Guan, B. Chen and Y. Dong, "Marine Target Detection Based on Improved Faster R-CNN for Navigation Radar PPI Images," in *2019 International Conference on Control, Automation and Information Sciences (ICCAIS)*, Oct. 23–26, 2019, pp. 1–5, doi: 10.1109/ICCAIS46528.2019.9074588.
- [9] Y. Qian, Q. Liu, H. Zhu, H. Fan, B. Du and S. Liu, "Mask R-CNN for object detection in multitemporal SAR images," in *2019 10th International Workshop on the Analysis of Multitemporal Remote Sensing Images (MultiTemp)*, Aug. 5–7, 2019, pp. 1–4, doi: 10.1109/Multi-Temp.2019.8866949.
- [10] J. Redmon, S. Divvala, R. Girshick and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," in *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, NV, USA, Jun. 27–30, 2016, pp. 779–788, doi: 10.1109/CVPR.2016.91.
- [11] P. Khumeechai, "Detecting Human Faces in Three Different Environmental Conditions using YOLOv4," *Thai Science and Technology Journal.*, vol. 32, no. 2, pp. 99–114, 2024, doi: 10.14456/tstj.2024.16.
- [12] P. Kumeechai, "Real-time vehicle detection system on the highway," *Journal of Applied Research on Science and Technology (JARST)*, vol. 22, no. 3, 2023, Art. no. 254011, doi: 10.60101/jarst.2023.254011.
- [13] M. Jindal, N. Raj, P. Saranya and S. V, "Aircraft Detection from Remote Sensing Images using YOLOv5 Architecture," in *2022 6th International Conference on Devices, Circuits and Systems (ICDCS)*, Coimbatore, India, Apr. 21–22, 2022, pp. 332–336, doi: 10.1109/ICDCS54290.2022.9780777.
- [14] A. Afdhal, K. Saddami, S. Sugiarto, Z. Fuadi and N. Nasaruddin, "Real-Time Object Detection Performance

- of YOLOv8 Models for Self-Driving Cars in a Mixed Traffic Environment,” in *2023 2nd International Conference on Computer System, Information Technology, and Electrical Engineering (COSITE)*, Banda Aceh, Indonesia, Aug. 2–3, 2023, pp. 260–265, doi: 10.1109/COSITE60233.2023.10249521.
- [15] S. S. Sriram, V. Parisha, B. U. K. Varma and C. Srinivasulu, “Traffic Light Detection and Recognition using YOLOv8,” in *2024 3rd International Conference on Applied Artificial Intelligence and Computing (ICAAIC)*, Jun. 5–7, 2024, pp. 1227–1233, doi: 10.1109/ICAAIC60222.2024.10575768.
- [16] R. Bawankule, V. Gaikwad, I. Kulkarni, S. Kulkarni, A. Jadhav and N. Ranjan, “Visual Detection of Waste using YOLOv8,” in *2023 International Conference on Sustainable Computing and Smart Systems (ICSCSS)*, Coimbatore, India, Jun. 14–16, 2023, pp. 869–873, doi: 10.1109/ICSCSS57650.2023.10169688.
- [17] Y. Lu, L. Zhang and W. Xie, “YOLO-compact: An Efficient YOLO Network for Single Category Real-Time Object Detection,” in *2020 Chinese Control And Decision Conference (CCDC)*, Hefei, China, Aug. 22–24, 2020, pp. 1931–1936, doi: 10.1109/CCDC49329.2020.9164580.
- [18] A. Anish, R. Sharan, A. Malini and T. Archana, “Enhancing Surveillance Systems with YOLO Algorithm for Real-Time Object Detection and Tracking,” in *2023 2nd International Conference on Automation, Computing and Renewable Systems (ICACRS)*, Pudukkottai, India, Dec. 11–13, pp. 1254–1257, doi: 10.1109/ICACRS58579.2023.10404710.
- [19] Q. B. Phan and T. T. Nguyen, “A Novel Approach for PV Cell Fault Detection Using YOLOv8 and Particle Swarm Optimization,” in *2023 IEEE 66th International Midwest Symposium on Circuits and Systems (MWSCAS)*, Tempe, AZ, USA, Aug. 6–9, 2023, pp. 634–638, doi: 10.1109/MWSCAS57524.2023.10406139.
- [20] C. You and H. Kong, “Improved Steel Surface Defect Detection Algorithm Based on YOLOv8,” *IEEE Access*, vol. 12, pp. 99570–99577, 2024, doi: 10.1109/ACCESS.2024.3429555.
- [21] D. B. Walther, “Using Confusion Matrices to Estimate Mutual Information between Two Categorical Measurements,” in *2013 International Workshop on Pattern Recognition in Neuroimaging*, Philadelphia, PA, USA, Jun. 22–24, 2013, pp. 220–224, 10.1109/PRNI.2013.63.