



การศึกษาเปรียบเทียบสถาปัตยกรรม YOLO สำหรับการตรวจจับข้อบกพร่องบนรอยเชื่อม
ที่ซับซ้อนภายใต้ความกำกวมของป้ายกำกับ
Comparative Study of YOLO Architectures for Detecting Complex Weld Defects
under Label Ambiguity

สุรเทพ แป้นเกิด¹ และ ปิยะพงษ์ คำคุณ^{2*}

¹ภาควิชาการจัดการวิศวกรรมและเทคโนโลยี คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ
กรุงเทพมหานคร 10120

²ภาควิชาวิศวกรรมเครื่องกลและอุตสาหกรรม คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลกรุงเทพ
กรุงเทพมหานคร 10120

Suratep Pangerd¹ and Piyapong Kumkoon^{2*}

¹Department of Engineering and Technology Management, Faculty of Engineering, Rajamangala University of
Technology Krungthep, Bangkok 10120

²Department of Mechanical and Industrial Engineering, Faculty of Engineering, Rajamangala University of
Technology Krungthep, Bangkok 10120

*Corresponding author: piyapong.k@mail.rmutk.ac.th

Received: 28 February 2026/ Revised: 29 May 2026/ Accepted: 4 June 2026

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อ 1) พัฒนาแบบจำลองตรวจจับข้อบกพร่องของรอยเชื่อมด้วยสถาปัตยกรรม YOLO จำนวน 3 เวอร์ชัน 2) เปรียบเทียบประสิทธิภาพของแบบจำลอง YOLOv11l, YOLOv12l และ YOLOv26l ภายใต้เงื่อนไขการทดลองเดียวกัน 3) วิเคราะห์ผลการตรวจจับข้อบกพร่องของรอยเชื่อมรายคลาส ได้แก่ รอยแตก (Crack), รูพรุน (Porosity), สะเก็ดเชื่อม (Spatter) และแนวเชื่อม (Weld Line) 4) พัฒนาเว็บแอปพลิเคชันต้นแบบสำหรับการตรวจจับข้อบกพร่องของรอยเชื่อม โดยทำการศึกษาชุดข้อมูลจาก Roboflow Universe จำนวน 5,544 ภาพ และทำการประเมินผลด้วยตัวชี้วัด ผลการทดลองพบว่า YOLOv26l ให้ประสิทธิภาพสูงสุด โดยเฉพาะเมื่อฝึกที่ 300 epochs ซึ่งให้ค่า Precision = 0.91, Recall = 0.876, mAP50 = 0.908, mAP50-95 = 0.773 และ F1-score = 0.89 แสดงถึงความสามารถในการตรวจจับและระบุตำแหน่งข้อบกพร่องได้อย่างแม่นยำเหนือกว่าโมเดลอื่น นอกจากนี้ผลการวิเคราะห์รายคลาสชี้ว่าโมเดลสามารถจำแนก Crack และ Weld Line ได้ดีพอสมควร ขณะที่ Porosity และ Spatter ยังคงมีความท้าทายเนื่องจากความคล้ายคลึงกับพื้นหลัง ทั้งนี้โมเดล YOLOv26l ถูกนำไปประยุกต์ใช้งานบนเว็บแอปพลิเคชันที่พัฒนาขึ้น ซึ่งสามารถใช้ตรวจจับข้อบกพร่องในสภาพแวดล้อมจริงได้อย่างมีประสิทธิภาพ สะท้อนศักยภาพของสถาปัตยกรรม YOLO รุ่นใหม่สำหรับการตรวจสอบคุณภาพรอยเชื่อมในภาคอุตสาหกรรม อย่างไรก็ตามงานวิจัยนี้ยังมีข้อจำกัดจากการใช้ชุดข้อมูลสาธารณะเพียงชุดเดียว จึงอาจยังไม่ครอบคลุมสภาพแวดล้อมจริงทั้งหมด

คำสำคัญ: การตรวจจับข้อบกพร่องรอยเชื่อม การเรียนรู้เชิงลึก การตรวจจับวัตถุ วิทยาศาสตร์คอมพิวเตอร์ โยโล



Abstract

The objectives of this research are 1) to develop a weld defect detection model utilizing the YOLO architecture, specifically three versions 2) to compare the performance of the YOLOv11l, YOLOv12l, and YOLOv26l models under identical experimental conditions; 3) to analyze the class-specific weld defect detection results, which include Crack, Porosity, Spatter, and Weld Line; and 4) to develop a web application prototype for weld defect detection. The study was conducted by examining a dataset of 5,544 annotated images comprising four defect categories: Crack, Porosity, Spatter, and Weld Line. All models were trained with identical configurations and assessed. The results indicate that YOLOv26l achieves the highest overall performance, particularly at 300 epochs, yielding a Precision of 0.91, Recall of 0.876, mAP50 of 0.908, mAP50-95 of 0.773 and F1-score of 0.89. These metrics reflect superior localization accuracy and defect classification capability compared to the other architectures. Class-wise analysis reveals that Crack and Weld Line are consistently well-detected, whereas Porosity and Spatter remain more challenging due to visual similarity with background textures. Despite this, YOLOv26l demonstrates the best balance across all defect classes. Furthermore, the trained model was successfully deployed in a web-based application, enabling prototype demonstration for weld-quality inspection. The findings confirm the potential of modern YOLO architectures, especially YOLOv26l, for accurate and robust automated weld defect detection in industrial environments. However, this research is limited by the use of only a single public dataset, and therefore may not cover all real-world environments.

Keywords: Weld defect detection, Deep learning, Object detection, Computer vision, YOLO

บทนำ

กระบวนการเชื่อมเป็นขั้นตอนที่มีความสำคัญอย่างยิ่งในอุตสาหกรรมโครงสร้างโลหะ ระบบท่อส่ง และการผลิตชิ้นส่วนเครื่องจักรกล เนื่องจากคุณภาพของแนวเชื่อมส่งผลโดยตรงต่อความแข็งแรง ความปลอดภัย และอายุการใช้งานของโครงสร้างโดยรวม อย่างไรก็ตามข้อบกพร่องในการเชื่อม (welding defects) สามารถเกิดขึ้นได้จากหลายปัจจัย อาทิ การออกแบบรอยเชื่อมที่ไม่เหมาะสม การกำหนดพารามิเตอร์กระบวนการเชื่อมที่คลาดเคลื่อน การเลือกใช้วัสดุที่ไม่สอดคล้องกัน รวมถึงทักษะและประสบการณ์ของผู้ปฏิบัติงาน ข้อบกพร่องที่พบบ่อย ได้แก่ รอยแตก (crack) ความพรุน (porosity) และสะเก็ดเชื่อม (Spatter) ซึ่งล้วนส่งผลกระทบต่อสมรรถนะเชิงกลของโครงสร้าง และในกรณีรุนแรงอาจนำไปสู่ความเสียหายต่อทรัพย์สินและชีวิตได้ ทั้งนี้การตรวจสอบคุณภาพรอยเชื่อมมักเริ่มต้นด้วยการตรวจสอบด้วยการพินิจ (Visual Testing: VT) ซึ่งเป็นวิธีทดสอบแบบไม่ทำลาย (NDT) [1, 2] ที่พื้นฐานและประหยัดค่าใช้จ่ายที่สุดในการตรวจหาข้อบกพร่องบริเวณพื้นผิว อย่างไรก็ตามการตรวจสอบด้วยสายตา มนุษย์มีข้อจำกัดด้านความเหนื่อยล้าและอาจเกิดความไม่สม่ำเสมอในการประเมินผล โดยการตรวจสอบด้วยสายตา ยังคงเป็นวิธีพื้นฐานที่ใช้กันอย่างแพร่หลายในภาคอุตสาหกรรม โดยครอบคลุมการตรวจสอบก่อนเชื่อม ระหว่างเชื่อม และหลังเชื่อม แม้ว่าจะมีเกณฑ์การประเมินที่กำหนดไว้อย่างชัดเจนตามมาตรฐานที่เกี่ยวข้อง แต่ผลการตรวจสอบยังคงขึ้นอยู่กับประสบการณ์ ความชำนาญ และสถานะแวดล้อมของผู้ตรวจสอบ ส่งผลให้เกิดความแปรปรวนของผลลัพธ์ ความล่าช้าในการประเมิน และความเสี่ยงต่อความผิดพลาดจากมนุษย์ โดยเฉพาะในกรณีที่มีปริมาณชิ้นงานจำนวนมากหรือมีลักษณะพื้นผิวแนวเชื่อมที่ซับซ้อน

ด้วยความก้าวหน้าของเทคโนโลยีปัญญาประดิษฐ์และคอมพิวเตอร์วิชัน (Computer Vision) [3] ซึ่งเป็นแขนงหนึ่งของปัญญาประดิษฐ์ที่มุ่งเน้นการทำความเข้าใจและวิเคราะห์ข้อมูลภาพและวิดีโอ เทคโนโลยีดังกล่าวได้รับการพัฒนาอย่างต่อเนื่องและ



มีความสามารถในการประมวลผลที่รวดเร็วและแม่นยำสูง โดยเฉพาะการประยุกต์ใช้การเรียนรู้เชิงลึก (Deep Learning) ผ่านโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ที่สามารถดำเนินการได้ทั้งการจำแนกประเภท (classification) การตรวจจับวัตถุ (object detection) และการแบ่งส่วนภาพ (segmentation) อย่างมีประสิทธิภาพ ความเร็วและความแม่นยำของระบบขึ้นอยู่กับความซับซ้อนของสถาปัตยกรรมแบบจำลองที่เลือกใช้ ในบรรดาแบบจำลองตรวจจับวัตถุแบบจำลองชนิดหนึ่งขั้นตอน (one-stage detector) ในตระกูล YOLO (You Only Look Once) [3] ได้รับความนิยมอย่างกว้างขวาง เนื่องจากมีจุดเด่นด้านความเร็วในการประมวลผลควบคู่กับประสิทธิภาพการตรวจจับที่เหมาะสมกับการประยุกต์ใช้ในงานที่ต้องการการตอบสนองแบบใกล้เคียงเวลาจริง ที่ผ่านมามีงานวิจัยที่ประยุกต์ใช้ CNN และอัลกอริทึมตระกูล YOLO ในการตรวจจับข้อบกพร่องบนรอยเชื่อมโดยตรง [4, 5] ในสภาพแวดล้อมการผลิตจริง การออกแบบและพัฒนาระบบตรวจจับและระบุตำแหน่งข้อบกพร่องบนแนวเชื่อมบนผิวเหล็ก โดยประยุกต์ใช้อัลกอริทึม YOLOv11, YOLOv12 และ YOLOv26 เพื่อสร้างแบบจำลองสำหรับการตรวจจับและจำแนกข้อบกพร่องของรอยเชื่อมจากภาพ ระบบที่พัฒนาขึ้นสามารถระบุตำแหน่งของข้อบกพร่องในลักษณะกรอบล้อม (bounding box) พร้อมทั้งจำแนกประเภทของรอยบกพร่องได้อย่างอัตโนมัติ


การศึกษานี้มีวัตถุประสงค์หลักเพื่อพัฒนาแบบจำลองสำหรับการตรวจจับข้อบกพร่องของรอยเชื่อม โดยประยุกต์ใช้สถาปัตยกรรม YOLO เวอร์ชันล่าสุด ที่ได้รับความนิยมในงานด้าน Object Detection มีจุดเด่นด้านความเร็วและความแม่นยำ พร้อมทั้งทำการเปรียบเทียบประสิทธิภาพของโมเดลทั้งสามภายใต้เงื่อนไขที่ควบคุมให้เหมือนกันทั้งหมด ไม่ว่าจะเป็นชุดข้อมูลที่ใช้สัดส่วนการแบ่งข้อมูล และค่าพารามิเตอร์สำหรับการฝึกสอน ท้ายที่สุดผู้วิจัยจะทำการคัดเลือกโมเดลที่มีประสิทธิภาพสูงที่สุดจากการทดสอบ เพื่อนำไปต่อยอดและพัฒนาเป็นเว็บแอปพลิเคชันต้นแบบ สำหรับนำไปประยุกต์ใช้ในการตรวจจับข้อบกพร่องของรอยเชื่อมในระดับปฏิบัติการจริงต่อไป

วิธีดำเนินการวิจัย

1. ศึกษาข้อมูลที่เกี่ยวข้อง

1.1 การประยุกต์ใช้ในภาคอุตสาหกรรมของชุดอัลกอริทึมตรวจจับวัตถุ YOLO


ในระยะเริ่มต้นงานตรวจจับวัตถุด้วย YOLO ถูกพัฒนาเพื่อแก้ข้อจำกัดของกระบวนการตรวจจับแบบหลายขั้นตอน (multi-stage detection pipelines) โดยเปลี่ยนแนวคิดจากการจำแนกภาพเฉพาะบริเวณมาเป็นการตรวจจับแบบขั้นตอนเดียว (single-stage detection framework) ทำให้สามารถระบุตำแหน่งและจำแนกวัตถุได้ภายในกระบวนการเดียว ส่งผลให้ YOLO มีความเร็วสูงและเหมาะสมกับงานตรวจจับแบบเวลาจริง ต่อมา YOLO ได้รับการพัฒนาอย่างต่อเนื่อง โดยมีการปรับปรุงแนวคิดด้านการทำนายตำแหน่งวัตถุผ่าน anchor boxes เพื่อช่วยให้ระบุตำแหน่งวัตถุได้แม่นยำขึ้น ซึ่งถือเป็นพื้นฐานสำคัญของ YOLOv2 ในระยะถัดมา YOLOv3 ถึง YOLOv8 [3] ได้รับการพัฒนาให้มีความสามารถในการตรวจจับวัตถุที่มีขนาดแตกต่างกันมากขึ้น โดยอาศัยแนวคิดการทำนายหลายระดับ (multi-scale prediction) และการปรับปรุงโครงสร้างส่วนหัวของโมเดล เช่น feature pyramid และ anchor-free heads เพื่อเพิ่มความสามารถในการตรวจจับวัตถุขนาดเล็กและเพิ่มประสิทธิภาพการประมวลผล ขณะเดียวกัน YOLOv9 และ YOLOv10 [6, 7] ได้มุ่งเน้นการออกแบบโมเดลให้มีประสิทธิภาพสูงขึ้นผ่านแนวทาง lightweight design เพื่อลดภาระการประมวลผลและรองรับการใช้งานบนอุปกรณ์ปลายทาง (edge devices) สำหรับ YOLOv11 และ YOLOv12 แนวทางการพัฒนาเริ่มเปลี่ยนจากการเพิ่มความซับซ้อนของโครงข่ายไปสู่การปรับปรุงองค์ประกอบภายในโมเดลให้มีประสิทธิภาพมากขึ้น เช่น การใช้ convolutional design ที่มีประสิทธิภาพสูงขึ้น และการนำกลไก attention เข้ามาช่วยเพิ่มความสามารถในการเรียนรู้คุณลักษณะสำคัญของวัตถุ โดย YOLOv11 มีการเปลี่ยนแปลงโครงสร้างสำคัญ เช่น การใช้ C3k2 แทน C2f และการเพิ่ม C2PSA เพื่อเพิ่มความสามารถในการสกัดคุณลักษณะเชิงพื้นที่ [8, 9] ขณะที่ YOLOv12 นำกลไก attention มาปรับใช้ในโครงสร้างของโมเดล [10 - 14] เพื่อเพิ่มประสิทธิภาพในการเรียนรู้บริเวณสำคัญของภาพและปรับปรุงความแม่นยำในการตรวจจับวัตถุ โดยกลไกการตรวจจับวัตถุของอัลกอริทึมตระกูล YOLO แสดงดังภาพที่ 1



ภาพที่ 1 กลไกการตรวจจับวัตถุของอัลกอริทึมตระกูล YOLO

1.2 รอยบกพร่องของรอยเชื่อม

ข้อบกพร่องในการเชื่อมภายใต้พารามิเตอร์ที่ไม่เหมาะสม ข้อบกพร่องเหล่านี้มักเกิดจากความเร็วในการป้อนลวดเชื่อมที่ไม่เหมาะสม ระยะห่างระหว่างลวดเชื่อมและแหล่งความร้อน ข้อบกพร่องที่แสดงในภาพที่ 2 ปัญหาการหลอมละลายของลวดเชื่อมไม่เพียงพอ มักเกิดขึ้นเมื่อความเร็วในการป้อนลวดเชื่อมสูงเกินไป หรือระยะห่างระหว่างลวดเชื่อมกับแหล่งความร้อนมากเกินไป โดยจะมีสรุปข้อบกพร่องในการเชื่อมที่พบได้ทั่วไป สาเหตุหลัก และผลกระทบที่เป็นอันตรายต่อชิ้นส่วนที่ผลิตขึ้นดังตารางที่ 1




ภาพที่ 2 รอยบกพร่องของรอยเชื่อม

1.3 การวัดผลประสิทธิภาพโมเดล

การวัดประสิทธิภาพโมเดลในการการตรวจจับวัตถุ (Object Detection) Intersection over Union (IoU) เพื่อประเมินความเกี่ยวข้องกันระหว่างผลการทำนาย (Predict) Bounding box กับผลเฉลย (Ground truth) ซึ่งหาได้จากพื้นที่ที่มีการทับซ้อนกันของ Bounding box กับ Ground truth หรือเรียกพื้นที่ Intersection ทหารด้วยพื้นที่รวมของทั้งสอง หากผลลัพธ์ IoU มีค่าเข้าใกล้ 1 แสดงว่าโมเดลทำนาย (Precision) ได้แม่นยำ แสดงถึงพื้นที่ทำนายตรงหรือใกล้เคียงกับพื้นที่ผลเฉลย หากผลลัพธ์ไม่ถึง 0.5 แสดงว่าโมเดลทำนายพื้นที่ที่ต่างจากผลเฉลยมากถือว่ายอมรับไม่ได้จะเป็นค่า False Positive ดังภาพที่ 3 โดยคำนวณได้จากสมการ (1) Mean Average Precision (mAP) คือ ค่าเฉลี่ยของค่า Average Precision (AP) ของแต่ละคลาสแล้วนำค่า AP ทุกคลาส

ตารางที่ 1 รอยบกพร่องของรอยเชื่อมและเกณฑ์การยอมรับ

ประเภทของรอยบกพร่อง	ลักษณะของข้อบกพร่อง	ผลกระทบต่อชิ้นส่วนที่ผลิตขึ้น
a. รอยแตก (Crack) [15]	สังเกตได้จากรอยแตกตามยาว ขว้าง หรือเป็น ร้างแห ซึ่งบ่งบอกถึงความไม่ต่อเนื่องในเนื้อโลหะ	ลดความแข็งแรงทางโครงสร้าง ขาด ความเสถียร
b. รูพรุน (Porosity) [16]	ลักษณะเป็นรูพรุนขนาดเล็กจำนวนมากที่กระจาย อยู่บนผิวหน้าหรือภายในเนื้อเชื่อม เกิดจากก๊าซที่ เกิดขึ้นระหว่างกระบวนการเชื่อมที่ไม่สามารถ แทรกตัวจากแนวเชื่อมที่กำลังแข็งตัวได้ ทำให้เกิด ช่องว่าง	อายุการใช้งานลดลง ความแข็งแรงทาง กลดลดลง อาจเกิดการกัดกร่อนและการ รั่วซึม
c. สะเก็ดเชื่อม (Spatter) [17]	เป็นเม็ดโลหะเล็กๆ ที่กระเด็นออกมาจากบริเวณที่ ทำการเชื่อมและเกาะติดอยู่บนผิวชิ้นงานรอบๆ แนวเชื่อม	ผิวชิ้นงานไม่สมบูรณ์ อาจเป็นจุดเริ่มต้น ของรอยร้าวขนาดเล็กและการกัดกร่อน เฉพาะจุด
d. แนวเชื่อม (welding line)	แนวเชื่อม หรือแนวรอยต่อที่เกิดจากการหลอม ละลายเนื้อโลหะสองชิ้นให้ติดกัน	



ภาพที่ 3 การหาค่า IoU

มาเฉลี่ยเข้าด้วยกันเพื่อให้ได้ค่า mAP ที่เป็นตัวบ่งชี้ความสามารถของโมเดลในการทำนายคลาสหรือวัตถุที่แตกต่างกันในภาพ โดยมี กระบวนการหาค่า mAP ดังนี้ 1. คำนวณค่า Precision และ Recall ของโมเดลที่ตรวจจับวัตถุในแต่ละคลาส (2) , (3) , (4) 2. คำนวณค่า AP ของแต่ละคลาสจาก Precision และ Recall ที่ได้ (5) 3. คำนวณค่า mAP โดยเอาค่า AP ของแต่ละคลาสมา เฉลี่ย (6) คำนวณได้จากสมการดังนี้

$$IoU = \frac{A \cap B}{A \cup B} \quad (1)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$Recall = \frac{TP}{TP + FN} \quad (4)$$

$$AP = \int_0^1 p(r) dr \quad (5)$$

$$mAP = \frac{1}{k} \sum_{i=1}^k AP_i \quad (6)$$




2. รูปแบบและวิธีการศึกษา

2.1 พัฒนาแบบจำลองด้วยอัลกอริทึมโครงข่ายประสาทเทียม โดยใช้โมเดล YOLOv11l, YOLOv12l และ YOLOv26l เป็นแม่แบบดังภาพที่ 4 เพื่อทำการตรวจจับและจำแนกข้อบกพร่องของรอยเชื่อมจากภาพถ่าย โดยชุดข้อมูลที่ใช้ในการศึกษานี้รวบรวมจาก Roboflow Universe (WDA Fissures) [18] ซึ่งประกอบด้วยภาพรอยเชื่อมจำนวนทั้งสิ้น 5,544 ภาพ โดยทุกภาพมีความละเอียด 640×640 พิกเซล ชุดข้อมูลดังกล่าวได้รับการกำหนดป้ายกำกับสำหรับการตรวจจับวัตถุจำนวน 4 ประเภท โดยข้อมูลรายคลาส (class distribution) ของชุดข้อมูล ได้แก่ รอยแตก (Crack), รูพรุน (Porosity), สะเก็ดเชื่อม (Spatter) และ แนวเชื่อม (Weld Line) ทั้งนี้ตัวอย่างภาพและป้ายกำกับจริง (ground truth annotations) ชุดข้อมูลนี้ครอบคลุมลักษณะข้อบกพร่องในการเชื่อมที่พบได้บ่อยในงานอุตสาหกรรม และมีการระบุขอบเขตวัตถุอย่างละเอียด ซึ่งช่วยสนับสนุนการฝึกสอนแบบจำลองให้เรียนรู้ลักษณะเชิงพื้นที่ของข้อบกพร่องได้อย่างเหมาะสม นอกจากนี้ความหลากหลายของตัวอย่างภาพยังช่วยเพิ่มความสามารถในการนำแบบจำลองไปประยุกต์ใช้กับสถานการณ์จริง สำหรับการฝึกและประเมินประสิทธิภาพของแบบจำลองชุดข้อมูลถูกแบ่งออกเป็น 3 ส่วน ได้แก่ ชุดฝึก (training set) 4,230 ภาพ (76%), ชุดตรวจสอบ (validation set) 660 ภาพ (12%) และ ชุดทดสอบ (test set) 654 ภาพ (12%) การแบ่งข้อมูลในลักษณะนี้ช่วยให้มีข้อมูลเพียงพอสำหรับการเรียนรู้ของแบบจำลอง ขณะเดียวกันยังรักษาความน่าเชื่อถือของการประเมินผลผ่านชุด validation และ test ที่เป็นอิสระจากกัน โดยมีการแสดงการกระจายตัวของข้อมูลรายคลาสในชุดข้อมูล WDA Fissures รายงานเป็นจำนวนป้ายกำกับวัตถุหรือกรอบล้อมวัตถุ (annotation/bounding box) ของแต่ละคลาส เนื่องจากงานวิจัยนี้เป็นงานตรวจจับวัตถุ ซึ่งภาพหนึ่งภาพสามารถประกอบด้วยข้อบกพร่องได้มากกว่าหนึ่งตำแหน่ง ดังนั้น จำนวน annotation จึงมีมากกว่าจำนวนภาพทั้งหมด ผลของชุดข้อมูลมี annotation รวมทั้งสิ้น 92,093 รายการ แบ่งเป็นชุดฝึก 72,143 รายการ ชุดตรวจสอบ 12,675 รายการ และชุดทดสอบ 7,275 รายการ

2.2 การฝึกสอนโมเดล การฝึกและเปรียบเทียบแบบจำลองตรวจจับวัตถุ 3 แบบ ได้แก่ YOLOv11l YOLOv12l และ YOLOv26l ซึ่งมีความแตกต่างด้านความซับซ้อนของสถาปัตยกรรม อันส่งผลต่อความแม่นยำและความเร็วในการประมวลผล โดยการทดลองทั้งหมดดำเนินการภายใต้สภาพแวดล้อมเดียวกันเพื่อให้เปรียบเทียบได้อย่างเป็นธรรม ใช้ภาษา Python ที่ติดตั้ง Jupyter Notebook ซึ่งในการฝึกสอนโมเดล ผู้วิจัยกำหนดค่าพารามิเตอร์ให้เหมือนกันทุกโมเดลเพื่อความเป็นธรรมในการเปรียบเทียบ โดยใช้ขนาดภาพอินพุต 640×640 พิกเซล กำหนด batch เท่ากับ 12 และทดลองฝึกสอนที่ 100, 200 และ 300 epochs เพื่อศึกษาผลของจำนวนรอบการเรียนรู้ต่อประสิทธิภาพของโมเดล นอกจากนี้กำหนดค่า patience เท่ากับ 50 สำหรับ Early Stopping และใช้ AdamW เป็น optimizer เพื่อช่วยปรับค่าน้ำหนักของโมเดลให้มีประสิทธิภาพ พร้อมกำหนดค่า seed เท่ากับ 42 เพื่อให้สามารถทำการทดลองซ้ำได้ อีกทั้งกำหนดค่า NMS IoU threshold เท่ากับ 0.7 เพื่อลดการตรวจจับวัตถุซ้ำซ้อนและเพิ่มความแม่นยำในการตรวจจับข้อบกพร่องของรอยเชื่อม

2.3 การนำโมเดลไปใช้งาน ในการศึกษาเริ่มจากการประเมินประสิทธิภาพของโมเดลตรวจจับวัตถุด้วยตัวชี้วัดมาตรฐาน ได้แก่ Accuracy, Precision, Recall และ mAP โดยค่า Accuracy ใช้แสดงสัดส่วนของจำนวนตัวอย่างที่โมเดลทำนายถูกต้องเมื่อเทียบกับจำนวนตัวอย่างทั้งหมดในชุดทดสอบ ส่วนค่า Precision ใช้ประเมินความแม่นยำของการทำนายว่าเป็นวัตถุ (สัดส่วนของวัตถุที่ตรวจจับถูกต้องต่อจำนวนที่โมเดลทำนายว่าเป็นวัตถุ) และค่า Recall ใช้ประเมินความครบถ้วนของการตรวจจับ (สัดส่วนของวัตถุที่ตรวจจับถูกต้องต่อจำนวนวัตถุจริงทั้งหมด) ซึ่งทั้งสองค่ายังมีค่าเข้าใกล้ 1 ยิ่งสะท้อนถึงประสิทธิภาพของโมเดลที่สูงขึ้น นอกจากนี้ยังใช้ค่า mAP@0.5 เป็นตัวชี้วัดหลัก โดยคำนวณจากค่าเฉลี่ยของ Average Precision (AP) ของทุกคลาสนำไปหารค่า IoU เท่ากับ 0.5 ซึ่งผลการทำนายจะถือว่าถูกต้องเมื่อกรอบทำนาย (bounding box) มีค่า IoU กับกรอบคำตอบจริง (ground truth) ตั้งแต่ 0.5 ขึ้นไป หลังจากฝึกสอนโมเดล YOLOv11l, YOLOv12l และ YOLOv26l เสร็จสิ้นแล้ว จึงทำการติดตั้งและเตรียมความพร้อมสำหรับการใช้งานจริง โดยนำไฟล์โมเดลที่ผ่านการฝึกสอนแล้ว (best.pt) จากเครื่องคอมพิวเตอร์ไปโหลดและวางไว้ในระบบเว็บไซต์ เพื่อใช้ในการทดสอบและประมวลผลการตรวจจับข้อบกพร่องบนสภาพแวดล้อมการใช้งานจริง



ภาพที่ 4 block diagram

2.4 การวิจัยนี้พัฒนาระบบสำหรับการตรวจจับข้อบกพร่องรอยเชื่อมในรูปแบบเว็บแอปพลิเคชัน โดยเขียนโปรแกรมด้วยภาษา PHP และออกแบบโครงสร้างซอฟต์แวร์ตามแนวคิดการเขียนโปรแกรมเชิงวัตถุ (Object-Oriented Programming: OOP) เพื่อให้ระบบมีความเป็นระเบียบ สามารถแยกส่วนการทำงาน เช่น ส่วนรับภาพเข้า ส่วนประมวลผลโมเดล ส่วนแสดงผล และส่วนจัดการข้อมูล ได้อย่างชัดเจน อีกทั้งยังสะดวกต่อการปรับปรุงและขยายระบบในอนาคต เว็บแอปพลิเคชันที่พัฒนาขึ้นรองรับการนำโมเดลตรวจจับที่ผ่านการฝึกสอนแล้วมาใช้งานจริงสำหรับการทดสอบและสาธิตผลการตรวจจับผ่านหน้าเว็บ โดยเผยแพร่ในรูปแบบออนไลน์เพื่อให้สามารถเข้าถึงและใช้งานได้สะดวกผ่านลิงก์ <http://btech-rmutk.com/welding/> ซึ่งช่วยให้สามารถประเมินการทำงานของระบบในบริบทการใช้งานจริงได้

2.5 การเชื่อมโมเดลกับหน้าเว็บแอปพลิเคชัน งานวิจัยนี้ดำเนินการโดยนำโมเดลที่ผ่านการฝึกสอนแล้วมาเตรียมให้อยู่ในรูปแบบที่เหมาะสมต่อการใช้งานบนเว็บแอปพลิเคชัน (.onnx) และเชื่อมต่อเข้ากับหน้าเว็บที่พัฒนาด้วย PHP โดยโครงสร้างการทำงานแบ่งเป็น 2 ส่วนสำคัญ ได้แก่ ส่วนแสดงผลหน้าเว็บ (frontend) และส่วนจัดการคำขอ/ฐานข้อมูล (backend) ในส่วนหน้าเว็บ มีการออกแบบหน้าทดสอบโมเดลให้ผู้ใช้สามารถอัปโหลดภาพ กำหนดค่า threshold และดูผลการตรวจจับได้แบบโต้ตอบ (interactive) ขณะเดียวกันหน้าเว็บจะเรียกใช้สคริปต์สำหรับโหลดโมเดลและประมวลผลภาพ จากนั้นจึงนำผลลัพธ์การตรวจจับ เช่น ชื่อคลาส ค่าความเชื่อมั่น และพิกัดกรอบวัตถุ มาแสดงผลบนภาพโดยตรง สำหรับส่วนหลังบ้าน PHP ทำหน้าที่รับข้อมูลผลการตรวจจับจากหน้าเว็บในรูปแบบข้อมูล JSON แล้วบันทึกลงฐานข้อมูลเพื่อใช้งานในหน้ารายงานผล (Dashboard) โดยการออกแบบหน้าเว็บ

ผลการวิจัย

การวิจัยนี้มุ่งประเมินประสิทธิภาพของแบบจำลองตรวจจับวัตถุสำหรับงานตรวจจับข้อบกพร่องรอยเชื่อม โดยเปรียบเทียบแบบจำลอง YOLOv11l , YOLOv12l และ YOLOv26l ภายใต้สภาพแวดล้อมการทดลองเดียวกันทั้งหมด ทั้งในด้านความแม่นยำในการตรวจจับและความเร็วในการประมวลผล ผลการทดลองจากชุดข้อมูลรอยเชื่อมจำนวน 5,544 ภาพ



ซึ่งประกอบด้วย 4 คลาส ได้แก่ Crack (รอยแตก), Porosity (รูพรุน), Spatter (เศษโลหะกระเด็น) และ Weld Line (แนวเชื่อม) แสดงให้เห็นว่าแบบจำลองทั้งสองสามารถตรวจจับข้อบกพร่องได้อย่างมีประสิทธิภาพ โดยมีการเปรียบเทียบผลการทดลองของโมเดล ดังนี้

1. ผลการเปรียบเทียบประสิทธิภาพของโมเดล

ทำการเปรียบเทียบประสิทธิภาพโมเดล YOLOv11l, YOLOv12l และ YOLOv26l พบว่าค่าผลการประเมินประสิทธิภาพของโมเดลทั้ง 3 เวอร์ชัน ประสิทธิภาพในการตรวจจับและใช้เวลาในการตรวจจับอยู่ในเกณฑ์ที่เหมาะสม ดังตารางที่ 2 และ ตารางเปรียบเทียบ Per-class Average Precision (AP) ดังตารางที่ 3 แสดงผลการเปรียบเทียบพบว่า YOLOv26l ให้ประสิทธิภาพสูงสุด โดยเฉพาะที่ 300 epochs แสดงถึงความแม่นยำและความครอบคลุมที่ดีที่สุดโดยรวมแนวโน้มทุกโมเดลมีประสิทธิภาพเพิ่มขึ้นเมื่อจำนวน epochs มากขึ้น แต่หลัง 200 epochs การเพิ่มขึ้นเริ่มชะลอตัว ดังนั้น YOLOv26l ที่ 300 epochs เป็นค่าที่เหมาะสมที่สุดสำหรับงานตรวจจับตำหนิในชุดข้อมูลนี้


ตารางที่ 2 ผลการเปรียบเทียบประสิทธิภาพโดยรวมที่จำนวนรอบการฝึกต่างกัน

Model	Epochs	Precision	Recall	mAP50	mAP50-95	F1-score
YOLOv11l	100	0.885	0.850	0.883	0.696	0.86
	200	0.895	0.870	0.885	0.721	0.88
	300	0.884	0.866	0.883	0.728	0.87
YOLOv12l	100	0.889	0.845	0.884	0.699	0.86
	200	0.905	0.863	0.899	0.735	0.88
	300	0.884	0.852	0.891	0.735	0.86
YOLOv26l	100	0.891	0.853	0.887	0.711	0.87
	200	0.902	0.875	0.902	0.751	0.88
	300	0.91	0.876	0.908	0.773	0.89


ตารางที่ 3 ตารางเปรียบเทียบ Per-class Average Precision (AP)

Model	Epochs	Crack	Porosity	Spatters	Welding line
YOLOv11l	100	0.939	0.788	0.832	0.975
	200	0.889	0.815	0.862	0.977
	300	0.896	0.809	0.851	0.974
YOLOv12l	100	0.953	0.780	0.823	0.978
	200	0.961	0.804	0.854	0.974
	300	0.942	0.800	0.849	0.973
YOLOv26l	100	0.954	0.777	0.844	0.971
	200	0.965	0.801	0.870	0.971
	300	0.960	0.819	0.879	0.976


จากตารางที่ 3 แสดงให้เห็นว่าผลจาก Per-class Average Precision (AP) แสดงว่า YOLOv26 ที่ 300 epochs ให้ค่า AP สูงสุดในหลายคลาส โดยเฉพาะ Porosity (0.819) และ Spatters (0.879) ขณะที่ Crack และ Welding line ให้ค่าสูงสม่ำเสมอทุกโมเดล (0.95–0.97) แนวโน้มโดยรวมพบว่าการเพิ่ม epochs ช่วยเพิ่มประสิทธิภาพ โดยเฉพาะในคลาสที่จำแนกยาก เช่น Porosity และ Spatters ดังนั้น YOLOv26 (300 epochs) แสดงสมรรถนะโดยรวมดีที่สุดและมีความสมดุลระหว่างทุกคลาสมากที่สุด




(a1) YOLOv11 epoch 100




(a2) YOLOv11 epoch 200




(a3) YOLOv11 epoch 300




(b1) YOLOv12 epoch 100




(b2) YOLOv12 epoch 200




(b3) YOLOv12 epoch 300



(c1) YOLOv26 epoch 100



(c2) YOLOv26 epoch 200



(c3) YOLOv26 epoch 300

ภาพที่ 5 ค่า Confusion Matrix

2. ผลวิเคราะห์ผลลัพธ์ตาราง Confusion Matrix

จากภาพที่ 5 แสดง Confusion Matrix ของโมเดล YOLOv11, YOLOv12 และ YOLOv26 ที่จำนวนรอบการฝึก 100, 200 และ 300 epochs พบว่าค่าบนแนวทแยงหลักมีค่าสูงอย่างสม่ำเสมอ โดยเฉพาะคลาส Crack และ Welding line ซึ่งสะท้อนว่าโมเดลสามารถจำแนกคลาสดังกล่าวได้อย่างแม่นยำ ในขณะที่คลาส Porosity และ Spatters ยังคงมีความสับสนกับคลาสพื้นหลังมากกว่าคลาสนั้น เนื่องจากลักษณะพื้นผิวของข้อบกพร่องมีความคล้ายคลึงกับบริเวณรอยเชื่อมและพื้นหลังโดยรอบ เมื่อพิจารณาผลในแต่ละจำนวนรอบการฝึก พบว่าการเพิ่ม epochs ช่วยปรับปรุงค่าการจำแนกบางคลาสดูได้เล็กน้อย อย่างไรก็ตาม แนวโน้มโดยรวมเริ่มเข้าใกล้จุดอิ่มตัวของประสิทธิภาพ โดยโมเดล YOLOv26 ที่ 300 epochs ให้ผลการจำแนกที่สมดุลที่สุดเมื่อเทียบกับเงื่อนไขอื่น



3. ผลการพัฒนาระบบ

การพัฒนาเว็บแอปพลิเคชัน โดยการรวมโมเดลที่ให้ค่าที่ดีที่สุดในแต่ละคลาส ผลการเปรียบเทียบทั้ง 3 โมเดลบนภาพทดสอบเดียวกันพบว่า YOLOv26 (Epoch 200 และ 300) ให้ความเร็วสูงกว่า YOLOv12 (Epoch 100) เล็กน้อย โดยมี FPS 0.28 และ Latency 3.53–3.55 วินาที/ภาพ ขณะที่ YOLOv12 ได้ FPS 0.25 และ Latency 4.04 วินาที/ภาพ แสดงว่า YOLOv26 ตอบสนองเร็วขึ้นประมาณ 0.5 วินาที/ภาพ เหมาะสำหรับการใช้งานเชิงปฏิบัติการมากกว่าในบริบทระบบเว็บดังกล่าวที่ 6 และ รายงานผลการบันทึกการเปรียบเทียบเพื่อใช้สำหรับตรวจสอบ ดังภาพที่ 7



ต้นฉบับ



Yolov12epoch100 FPS: 0.25, Latency: 4038.30 ms, Objects: 14

สรุปรอยข้อบกพร่องที่ตรวจพบ Porosity: 7 , Spatter: 4 , Weld Line: 2, Crack: 1



Yolov26 epoch200 FPS: 0.28, Latency: 3552.10 ms, Objects: 11

สรุปรอยข้อบกพร่องที่ตรวจพบ Porosity: 6 , Weld Line: 2, Spatter: 2, Crack: 1




Yolov26 epoch300 FPS: 0.28, Latency: 3533.20 ms, Objects: 17

สรุปรอยข้อบกพร่องที่ตรวจพบ Porosity: 10, Spatter: 4, Weld Line: 2, Crack: 1

ภาพที่ 6 ผลการเปรียบเทียบ 3 โมเดล

อภิปรายและสรุปผลการวิจัย

จากการเปรียบเทียบสถาปัตยกรรม YOLOv11l, YOLOv12l และ YOLOv26l สำหรับการตรวจจับข้อบกพร่องบนรอยเชื่อม พบว่า YOLOv26l ให้ประสิทธิภาพสูงที่สุด โดยเฉพาะที่ 300 epochs ซึ่งให้ค่า Precision = 0.91, Recall = 0.876, F1-score = 0.89, mAP50 = 0.908 และ mAP50-95 = 0.773 แสดงให้เห็นว่าโมเดลดังกล่าวสามารถตรวจจับและระบุตำแหน่งข้อบกพร่องได้ดีกว่าโมเดลอื่นภายใต้เงื่อนไขการทดลองเดียวกัน ทั้งนี้การเพิ่มจำนวน epochs ช่วยปรับปรุงประสิทธิภาพของโมเดลได้ แต่หลัง 200 epochs เป็นต้นไป ผลลัพธ์มีแนวโน้มเพิ่มขึ้นเพียงเล็กน้อย ในระดับรายการคลาส โมเดลสามารถตรวจจับ Crack และ Welding line



ภาพที่ 7 รายงานผลการบันทึกการเปรียบเทียบ

ได้อย่างสม่ำเสมอ ขณะที่ Porosity และ Spatters ยังคงเป็นคลาสที่ทำหาย เนื่องจากมีลักษณะคล้ายพื้นหลังและมีขอบเขตไม่ชัดเจน ซึ่งสอดคล้องกับงานของ Ling และคณะ [5] ที่ระบุว่าภาพรอยเชื่อมมีพื้นหลังซับซ้อน และขอบกพร่องบางประเภทมีลักษณะใกล้เคียงกับพื้นผิวโลหะ อีกทั้งสอดคล้องกับ Zhang และคณะ [19] ที่เน้นการจัดการตำหนิที่มีขอบเขตกำกวมด้วยการผสานคุณลักษณะหลายระดับ

ผลการวิจัยนี้สนับสนุนแนวโน้มการใช้แบบจำลองเชิงลึกสำหรับการตรวจสอบคุณภาพรอยเชื่อมอัตโนมัติ โดยสอดคล้องกับ Cheng และคณะ [20] ที่ประยุกต์ใช้วิธีตรวจจับรอยบกพร่องในการเชื่อมแบบหลายขนาด โดยอาศัยการปรับปรุงภาพแบบปรับตัวตามสภาพและ Gui และคณะ [9] ที่เสนอแนวทางเพิ่มความสามารถของ YOLO ในการตรวจจับวัตถุขนาดเล็ก ดังนั้น YOLOv26 [21] จึงมีศักยภาพสำหรับการพัฒนาเป็นระบบต้นแบบตรวจจับข้อบกพร่องรอยเชื่อมผ่านเว็บแอปพลิเคชัน อย่างไรก็ตามงานวิจัยนี้ยังมีข้อจำกัดจากการใช้ชุดข้อมูลสาธารณะเพียงชุดเดียว ความไม่สมดุลของข้อมูลรายคลาส และการยังไม่ได้ทดสอบกับสายการผลิตจริงแบบต่อเนื่อง ในอนาคตควรเพิ่มชุดข้อมูลจากสภาพแวดล้อมอุตสาหกรรมจริง ทดสอบระบบแบบวิดีโอเรียลไทม์เปรียบเทียบกับโมเดลนอกกลุ่ม YOLO และประเมินผลร่วมกับผู้เชี่ยวชาญด้านงานเชื่อม เพื่อยืนยันความเหมาะสมต่อการใช้งานจริง

เอกสารอ้างอิง

1. Deepak JR, Bupesh Raja VK, Srikanth D, Surendran H, Nickolas MM. Non-destructive testing (NDT) techniques for low carbon steel welded joints: A review and experimental study. Mater Today Proc 2021;44:3732-7.
2. He G, Gao X, Zhang Y. Magneto optical imaging non-destructive testing of welding defects with controlled rotationally excited magnetic field based on improved NSCT-GWO-PCNN image fusion. Opt Lasers Eng 2026;201:109718.
3. Hussain M. YOLO-v1 to YOLO-v8, the Rise of YOLO and Its Complementary Nature toward Digital Manufacturing and Industrial Defect Detection. Machines 2023;11(7):677.



4. Mendieta EE, Quintero H, Pinzon-Acosta C. Application of convolutional neural networks for surface discontinuities detection in shielded metal arc welding process. *Front Robot AI* 2025;12:1632417.
5. Ling L, Wei G, Liu Y, Xu S, Wei L, Hong B. RBPSD-YOLOv8: weld surface defect detection based on improved YOLOv8. *J Real Time Image Process* 2025;22(4):152.
6. Wang CY, Yeh IH, Liao HYM. YOLOv9: Learning what you want to learn using programmable gradient information. In: proceedings of the 18th European Conference on Computer Vision (ECCV), September 29-October 4, 2024; Milan, Italy; 2024. p. 1-21.
7. Chairunisa YA, Kosala G. Performance comparison of YOLOv9, YOLOv10, and YOLOv11 for detecting highway potholes. In: proceedings of the 2025 International Conference on Data Science and Its Applications (ICoDSA), July 3-5, 2025; Jakarta, Indonesia; 2025. p. 7-12.
8. He L, Zhou Y, Liu L, Ma J. Research and application of YOLOv11-based object segmentation in intelligent recognition at construction sites. *Buildings* 2024;14(12):3777.
9. Gui Y, Xiao X, Fu Y, Yao M. A local training paradigm for YOLO models to enhance tiny object detection. *Results Eng* 2026;29:109835.
10. Redmon J, Farhadi A. YOLO9000: Better, faster, stronger. In: proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), July 21-26, 2017; Honolulu, HI, USA; 2017. p. 6517-25.
11. Kang S, Hu Z, Liu L, Zhang K, Cao Z. Object detection YOLO algorithms and their industrial applications: Overview and comparative analysis. *Electronics* 2025;14(6):1104.
12. Wang CY, Bochkovskiy A, Liao HYM. YOLOv7: trainable bag-of-freebies sets new state-of-the-art for real-time object detectors. In: proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 17-24, 2023; Vancouver, BC, Canada; 2023. p. 7464-75.
13. Wang A, Chen H, Liu L, Chen K, Lin Z, Han J, et al. Yolov10: Real-time end-to-end object detection. *Adv Neural Inf Process Syst* 2024;37: 107984-8011.
14. Yang C, Huang Z, Wang N. QueryDet: Cascaded sparse query for accelerating high-resolution small object detection. In: proceedings of the 2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), June 18-24, 2022; New Orleans, LA, USA; 2022. p. 13668-77.
15. Tomków J, Rogalski G, Fydrych D, Łabanowski J. Improvement of S355G10+N steel weldability in water environment by Temper Bead Welding. *J Mater Process Technol* 2018;262:372-81.
16. Kam DH, Lee TH, Kim DY, Kim J, Kang M. Weld quality improvement and porosity reduction mechanism of zinc coated steel using tandem gas metal arc welding (GMAW). *J Mater Process Technol* 2021;294:117127.
17. Omoniyi PO, Mahamood RM, Akinlabi ET. Impact of process parameters of laser welding on the mechanical properties of Ti6Al4V: a review. *J Chem Technol Metall* 2021;56:1074-81.
18. Aminerealm. WDA fissures Dataset. Roboflow Universe [Internet]. 2025 [cited 2025 May 16]. Available from: <https://universe.roboflow.com/aminerealm/wda-fissures/dataset/2>



19. Zhang M, Hu Y, Xu B, Luo L, Wang S. DSF-YOLO for weld defect detection in X-ray images with dynamic staged fusion. *Sci Rep* 2025;15(1):23305.
20. Cheng H, Jiang H, Jing D, Huang L, Gao J, Zhang Y, et al. Multiscale welding defect detection method based on image adaptive enhancement. *Knowl-Based Syst* 2025;327:114174.
21. Anusree R, Hareendranathan RA, Suhail CPM. Nodule detection in breast ultrasound using deep learning-based instance segmentation. In: *proceedings of the 2026 International Conference on Future and Advanced Computing Technologies (ICFACT)*, March 26-27, 2026; Krishnankoil, Tamil Nadu, India; 2026. p. 1-6.