

การศึกษาประสิทธิภาพเชิงเปรียบเทียบของระบบการตรวจจับวัตถุ: กรณีศึกษาการตรวจจับรอยตำหนิบนตัวถังรถยนต์จำลองหลังการพ่นสี

อนันตา สินไชย¹, ทรงวุฒิ พานิชย์², สุทธิดา ยอดอาษา³

¹คณะเทคโนโลยีวิศวกรรมบูรณาการ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

^{2, 3}วิทยาลัยนวัตกรรมการผลิตขั้นสูง สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

Email: ananta.sin@kmitl.ac.th¹

Received: Mar 18, 2025

Revised: Apr 21, 2025

Accepted: May 02, 2025

บทคัดย่อ

การศึกษานี้มีวัตถุประสงค์เพื่อประเมินประสิทธิภาพของแบบจำลอง โยโลรุ่นสิบสองเอส ในการตรวจจับรอยตำหนิบนพื้นผิวตัวถังรถยนต์หลังการพ่นสี โดยรอยตำหนิที่ใช้ในการศึกษาอ้างอิงจากลักษณะที่เกิดขึ้นจริงในกระบวนการผลิต และจำลองขึ้นในระดับห้องปฏิบัติการจำนวน 75 ชิ้น จากนั้นถ่ายภาพทั้ง 75 ชิ้น และปรับเปลี่ยนรูปร่างหรือการจัดวางเพื่อเพิ่มจำนวนภาพเป็น 150 ภาพ ภาพทั้งหมดถูกทำป้ายกำกับและนำมาใช้สำหรับการฝึกสอนและทดสอบแบบจำลอง โยโลรุ่นสิบสองเอส ซึ่งให้ค่าเฉลี่ยของความเที่ยง ที่ 0.886 นอกจากนี้ การศึกษานี้เปรียบเทียบประสิทธิภาพของ โยโลรุ่นสิบสองเอส กับ โยโลรุ่นห้าเอส และซอฟต์แวร์การเรียนรู้เชิงลึกเชิงพาณิชย์ ได้แก่ ซอฟต์แวร์ซีรา และซอฟต์แวร์ซีราโอโรราวิชชั่น การประเมินผลดำเนินการภายใต้เงื่อนไขเดียวกัน โดยใช้ตัวชี้วัดความแม่นยำ ความเที่ยง ความสามารถในการตอบถูก และ F1-score ผลการทดลองพบว่า โยโลรุ่นสิบสองเอส ให้ค่าความสามารถในการตอบถูก สูงสุดที่ร้อยละ 95.2 และค่า F1-score ที่ร้อยละ 88.9 ซึ่งเป็นค่าที่ดีที่สุดในกลุ่มโอเพ่นซอร์ส และมีประสิทธิภาพใกล้เคียงกับซอฟต์แวร์ซีรา ขณะที่ ซอฟต์แวร์ซีราโอโรราวิชชั่น แสดงประสิทธิภาพโดยรวมที่น่าสนใจ ด้วยค่า F1-score เท่ากับร้อยละ 95.8 อย่างไรก็ตาม แบบจำลองทั้งหมดยังมีข้อจำกัดในการตรวจจับรอยตำหนิที่มีขนาดเล็กหรือถูกบดบังด้วยชิ้นสีเคลือบและสีไม่สม่ำเสมอ การศึกษานี้ชี้ให้เห็นว่า โยโลรุ่นสิบสองเอส มีศักยภาพในการเป็นทางเลือกที่มีต้นทุนต่ำและมีประสิทธิภาพสำหรับการตรวจสอบรอยตำหนิบนพื้นผิวตัวถัง และควรมีการพัฒนาต่อยอดเพื่อรองรับการใช้แบบเวลาจริงในสายการผลิต

คำสำคัญ : การเรียนรู้เชิงลึก, โยโล, การวิเคราะห์ภาพ, การตรวจจับรอยตำหนิ, การตรวจสอบผิวตัวถัง

A Comparative Study of Object Detection Systems: A Case Study on Detecting Surface Defects on Simulated Automotive Bodies after Spray Painting

Ananta Sinchai¹, Songwut Phanit², Suttida Yod-asa³

¹School of Integrated Innovative Technology, King Mongkut's Institute of Technology Ladkrabang

^{2,3}College of Advanced Manufacturing Innovation, King Mongkut's Institute of Technology Ladkrabang

Email: ananta.sin@kmitl.ac.th

Received: Mar 18, 2025

Revised: Apr 21, 2025

Accepted: May 02, 2025

Abstract

This study evaluates the performance of the YOLOv12s model for detecting defects on automotive body surfaces after painting. The defects were based on real production process characteristics and simulated in the lab with 75 pieces, which were photographed and modified to create 150 images for training and testing the model. YOLOv12s achieved an average precision of 0.886. The study also compares YOLOv12s with YOLOv5s and commercial deep learning software like CiRA and Zebra Aurora Vision. The evaluation used precision, recall, accuracy, and F1-score as metrics. YOLOv12s had the highest recall rate of 95.2% and an F1-score of 88.9%, outperforming open-source alternatives and showing performance comparably to CiRA. Zebra Aurora Vision, however, demonstrated an interesting overall performance, with an F1-score of 95.8%. All models showed limitations in detecting small defects or those obscured by the coating or uneven paint. The study concludes that YOLOv12s has strong potential as a cost-effective, efficient alternative for body surface defect detection, with further development needed for real-time production line use.

Keywords : Deep learning, YOLO, Image analysis, Defect detection, Body surface inspection

บทนำ

การตรวจจ็บบรอยตำหนิที่เกิดขึ้นบนผิวตัวถังรถยนต์ในกระบวนการผลิตยานยนต์มีบทบาทสำคัญในการรักษามาตรฐานการผลิตให้มีคุณภาพสูง และเพิ่มประสิทธิภาพโดยรวมของกระบวนการ การตรวจจ็บบรอยตำหนิเช่น รอยขีดหรือความไม่สม่ำเสมอของสีบนผิวตัวถังของรถยนต์นั้นถือเป็นความท้าทายที่สำคัญ เนื่องจากมีความแตกต่างของสีที่เล็กน้อยและละเอียด ทำให้การตรวจจ็บบเป็นไปได้อย่างยากและมีความแม่นยำน้อย หนึ่งในกระบวนการนี้ต้องอาศัยบุคคลที่มีความสามารถในการสังเกตอย่างแม่นยำเพื่อตรวจจ็บบรอยตำหนิ อย่างไรก็ตาม การเพ่งมองเป็นเวลานานทำให้เกิดความเหนื่อยล้า ซึ่งอาจนำไปสู่ข้อผิดพลาดได้ เพื่อเป็นการแก้ไขปัญหาข้อจำกัดของการตรวจจ็บบโดยบุคคล การใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning: DL) และคอมพิวเตอร์วิทัศน์ (Computer Vision: CV) ได้ถูกนำมาใช้ในการตรวจจ็บบรอยตำหนิ ซึ่งไม่เพียงช่วยลดข้อผิดพลาดจากการตรวจสอบด้วยมนุษย์ แต่ยังเพิ่มความแม่นยำและประสิทธิภาพในการควบคุมคุณภาพได้ดียิ่งขึ้น

การนำการเรียนรู้เชิงลึกมาใช้ในการตรวจจ็บบรอยตำหนิช่วยพัฒนากระบวนการตรวจสอบในหลากหลายอุตสาหกรรม ไม่จำกัดเฉพาะอุตสาหกรรมยานยนต์ [1] หนึ่งในเทคนิคการเรียนรู้เชิงลึกที่สำคัญคือ โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNNs) ซึ่งเทคนิคนี้ได้รับการนำมาประยุกต์ใช้ในการจำแนกรอยตำหนิ เช่น รอยขีดข่วน หรือรอยต่างของสีบนผิวตัวถังรถยนต์ ได้อย่างแม่นยำ [2, 3, 4]

ถึงแม้ว่าโครงข่ายประสาทเทียมแบบคอนโวลูชันสามารถจำแนกรอยตำหนิได้ดี แต่เพื่อให้การจำแนกและการตรวจจ็บบรอยตำหนิดียิ่งขึ้น จึงได้มีการพัฒนาโครงข่ายประสาทเทียมแบบ

MobileNet-V2 และ ResNet34 ซึ่งพบว่ามีความแม่นยำสูงกว่าร้อยละ 94 [5] อย่างไรก็ตาม เพื่อให้การประมวลผลรวดเร็วขึ้นและยังคงรักษาประสิทธิภาพไว้ จึงได้มีการพัฒนาโครงข่ายประสาทเทียมที่ใช้อัลกอริทึมที่มีน้ำหนักเบา (Lightweight Algorithms) หรืออัลกอริทึมที่ใช้ทรัพยากรน้อย เช่น MobileNet-SSD และ TinyDefectNet แม้อัลกอริทึมเหล่านี้จะใช้ทรัพยากรน้อย แต่ยังคงสามารถตรวจจ็บบรอยตำหนิขนาดเล็กและความไม่สม่ำเสมอของสีที่ละเอียดได้อย่างมีประสิทธิภาพ โดยให้ผลลัพธ์ที่ใกล้เคียงกับการตรวจสอบด้วยบุคคล [6, 7] นอกจากนี้ โครงข่ายประสาทเทียมที่ใช้ทรัพยากรน้อย ร่วมกับระบบการเก็บภาพเฉพาะทาง ยังช่วยให้สามารถนำไปใช้งานได้มีประสิทธิภาพในสายการผลิต [8]

ถึงแม้เทคนิคการแบ่งส่วนภาพในปัจจุบันสามารถระบุรอยขีดข่วนขนาดเล็กบนพื้นผิวที่สะท้อนแสงหรือมีลวดลายได้อย่างมีประสิทธิภาพ แต่การใช้ระบบการเรียนรู้เชิงลึก เช่น โครงข่ายประสาทเทียมแบบ ResNet50 หรือ โยโลรุ่นเจ็ด สามารถตรวจจ็บบรอยขีดข่วนและสิ่งแทรกบนพื้นผิวโลหะ รวมถึงการตรวจจ็บบรอยตำหนิบนพื้นผิวที่มีความซับซ้อนได้อย่างมีประสิทธิภาพ ซึ่งสามารถให้ได้ค่าความแม่นยำมากกว่าร้อยละ 97 [9, 10] นอกจากนี้แล้ว โครงข่ายประสาทเทียมแบบที่ผสมการแปลงแบบเวฟเลต (Wavelets) และกลไกความสนใจ (Attention Mechanism) ยังช่วยให้สามารถตรวจจ็บบรอยตำหนิในสภาพแวดล้อมที่การมองเห็นยากแยะหรือขอบไม่ชัดเจนได้ดียิ่งขึ้น [11, 12]

การใช้การเรียนรู้เชิงลึกมีศักยภาพสูงในการประยุกต์ใช้ในอุตสาหกรรม แต่ยังคงมีปัญหาในด้านการปรับใช้งานในเวลาจริง (Real-time) เนื่องจากการพึ่งพาชุดข้อมูลที่มีการทำป้าย (Labelling) กำกับจำนวนมาก และการตรวจจ็บบ

รอยดำหนที่มีสีไม่สม่ำเสมอ เพื่อแก้ไขข้อจำกัดเหล่านี้ การใช้เทคโนโลยีการถ่ายภาพที่มีความละเอียดสูง การเรียนรู้แบบถ่ายโอน (Transfer Learning: TL) และสถาปัตยกรรมที่ประหยัดพลังงานได้รับการสำรวจเพื่อนำมาปรับใช้ [1]

แม้ว่าโครงข่ายประสาทเทียมการเรียนรู้เชิงลึกแบบ MobileNet-V2 ResNet34 MobileNet-SSD TinyDefectNet ResNet50 หรือ โยโลรุ่นเจ็ด ข้างต้นให้ความแม่นยำสูง แต่โครงข่ายประสาทเทียมการเรียนรู้เชิงลึกเหล่านี้ยังคงใช้สถาปัตยกรรมแบบคอนโวลูชันซึ่งเป็นอุปสรรคต่อการนำไปใช้งานในเวลาจริง อย่างไรก็ตาม โยโลรุ่นห้าเอส สามารถนำไปประยุกต์ใช้ในเวลาจริงได้ แม้จะใช้สถาปัตยกรรมแบบคอนโวลูชัน [13] แต่ยังมีข้อจำกัดด้านความแม่นยำ [14]

เพื่อแก้ไขปัญหานำไปใช้งานในเวลาจริง พร้อมกับการรักษาความแม่นยำ โยโลรุ่นสิบสองเอสได้มีการพัฒนามาอย่างมีนัยสำคัญในตระกูลโยโล โดยการเปลี่ยนแปลงจากสถาปัตยกรรมเครือข่ายประสาทเทียมคอนโวลูชันแบบดั้งเดิมไปสู่การออกแบบที่เน้นการใช้กลไกความสนใจ การเปลี่ยนแปลงนี้มีจุดมุ่งหมายเพื่อเพิ่มทั้งความแม่นยำและประสิทธิภาพในการตรวจจับวัตถุแบบเวลาจริง [15]

งานวิจัยนี้เป็นการศึกษาเชิงเปรียบเทียบประสิทธิภาพของ โยโลรุ่นสิบสองเอส ในการตรวจจับรอยดำหนบนตัวถังรถยนต์หลังการพ่นสี กับโยโลรุ่นห้าเอส และ ซอฟต์แวร์การเรียนรู้เชิงลึกในอุตสาหกรรมเชิงพาณิชย์ ได้แก่ ซอฟต์แวร์ซีร่า [16, 17] และ ซอฟต์แวร์ซีร่าโอโรราวิชั่น ก่อนหน้านี้นี้ คือ อะแดปทีฟวิชันสตูดิโอ (Adaptive Vision Studio) [18, 19] เพื่อใช้เป็นฐานมาตรฐาน (Baselines) ในการเปรียบเทียบประสิทธิภาพโดยซอฟต์แวร์ทั้งสองใช้ใบอนุญาตแบบนักศึกษา (Student License)

ทั้งนี้ ซอฟต์แวร์ซีร่า และ ซอฟต์แวร์ซีร่าโอโรราวิชั่น ไม่ได้จำกัดอยู่แค่ในภาคอุตสาหกรรม แต่ยังถูกนำไปใช้ในทางการแพทย์ [20, 21] การเกษตร [22] และการศึกษา [23] เป็นต้น

ซอฟต์แวร์ซีร่าและซอฟต์แวร์ซีร่าโอโรราวิชั่นเป็นซอฟต์แวร์ที่ใช้การเรียนรู้เชิงลึกในอุตสาหกรรมเชิงพาณิชย์ ซึ่งแตกต่างจากตระกูลโยโลที่เป็นโอเพ่นซอร์ส (Open Source) ทำให้หลักการการทำงานของซอฟต์แวร์เหล่านี้ไม่ได้ถูกเปิดเผยอย่างชัดเจน อย่างไรก็ตาม ซอฟต์แวร์ซีร่ามีตัวบ่งชี้ในตัวซอฟต์แวร์ว่าใช้แบบจำลองตระกูลโยโลในการพัฒนาการตรวจจับและคัดแยก

วัตถุประสงค์ของการวิจัย

1. เพื่อศึกษารูปแบบของรอยดำหนบนตัวถังรถยนต์หลังการพ่นสีและทำรอยดำหนบนตัวถังรถยนต์จำลองในระดับห้องปฏิบัติการ
2. เพื่อนำ โยโลรุ่นสิบสองเอส มาใช้ในการตรวจจับรอยดำหนบนตัวถังรถยนต์ที่จำลองขึ้น โดยมุ่งเน้นการประเมินเฉพาะประสิทธิภาพในการตรวจจับเท่านั้น ทั้งนี้ ยังไม่ครอบคลุมถึงการพัฒนาให้สามารถทำงานแบบอัตโนมัติในเวลาจริง
3. เพื่อเปรียบเทียบประสิทธิภาพการตรวจจับของ โยโลรุ่นสิบสองเอส กับ โยโลรุ่นห้าเอส และซอฟต์แวร์การเรียนรู้เชิงลึกในอุตสาหกรรมเชิงพาณิชย์ที่เลือกใช้เป็นแบบจำลองพื้นฐาน โดยที่โยโลรุ่นห้าเอสเป็นพื้นฐานในการพัฒนารุ่นสิบสอง

ระเบียบวิธีวิจัย

งานวิจัยนี้ดำเนินการในลักษณะของการทดลอง (Empirical Manner) โดยทำการจำลองรอยดำหนบนแผ่นโลหะแผ่นสี่เหลี่ยมมุมฉากซึ่งจัดเตรียมขึ้นให้เสมือนเป็นพื้นผิวของตัวถังรถยนต์ในระดับห้องปฏิบัติการ และนำแบบจำลอง โยโลรุ่นสิบสองเอส ซึ่งเป็นแบบจำลองการเรียนรู้เชิงลึกประเภทการตรวจจับวัตถุ (Object Detection)

มาใช้ในการตรวจจับภาพรอยตำหนิ โดยมุ่งเน้นการประเมินประสิทธิภาพของแบบจำลองในด้าน การตรวจจับเป็นหลัก พร้อมทั้งเปรียบเทียบกับแบบจำลอง โยโลรุ่นห้าเอส และซอฟต์แวร์การเรียนรู้เชิงลึกในอุตสาหกรรมเชิงพาณิชย์ เพื่อพิจารณาความเป็นไปได้ในการนำไปประยุกต์ใช้ในภาคอุตสาหกรรมเชิงพาณิชย์ เพื่อพิจารณาความเป็นไปได้ในการนำไปประยุกต์ใช้ในภาคอุตสาหกรรม

ภาพรวมของระเบียบวิธีวิจัยที่ใช้ในงานวิจัยนี้แสดงดังรูปที่ 1 ซึ่งแสดงถึงกระบวนการวิจัยตั้งแต่การเตรียมการ การประมวลผลข้อมูล การฝึกและทดสอบแบบจำลอง ไปจนถึงการประเมินประสิทธิภาพ โดยกระบวนการข้างต้นถูกแจกแจงรายละเอียดตามแต่ละขั้นตอน ซึ่งประกอบด้วยรูปแบบการวิจัยที่เน้นการทดลองเชิงปริมาณ ประชากรและกลุ่มตัวอย่างที่เป็นภาพถ่ายรอยตำหนิจำลอง เครื่องมือที่ใช้ในงานวิจัยทั้งฮาร์ดแวร์และซอฟต์แวร์ ขั้นตอนการดำเนินการวิจัยอย่างเป็นระบบ และการวิเคราะห์ข้อมูลด้วยตัวชี้วัดประสิทธิภาพที่เหมาะสม

1. รูปแบบการวิจัย

การวิจัยนี้เป็นการวิจัยเชิงทดลองที่มีลักษณะเชิงปริมาณ เนื่องจากมุ่งเน้นการใช้ข้อมูลที่ได้จากการทดลองเพื่อประเมินประสิทธิภาพของแบบจำลองการตรวจจับรอยตำหนิ โดยใช้ตัวชี้วัดเชิงปริมาณ เช่น ค่าเฉลี่ยของความเที่ยง ความแม่นยำ และ F1-Score เป็นต้น ในการประเมินผล ทั้งนี้เพื่อให้ได้ผลลัพธ์ที่สามารถวัดรวมทั้งเปรียบเทียบได้และน่าเชื่อถือ

2. ประชากรและกลุ่มตัวอย่าง

กลุ่มตัวอย่างในการวิจัยนี้คือ ภาพถ่ายของรอยตำหนิที่จำลองขึ้นบนแผ่นโลหะที่เตรียมขึ้นเพื่อจำลองเป็นพื้นผิวของตัวถังรถยนต์จำนวน

150 ภาพ โดยรอยตำหนิที่เกิดขึ้นจะถูกทำป้ายกำกับเพื่อใช้เป็นข้อมูลในการฝึกและทดสอบแบบจำลองการเรียนรู้เชิงลึก ทั้งนี้ จำนวนตัวอย่าง 150 ภาพ ได้รับการกำหนดโดยพิจารณาจากความหลากหลายของประเภทและลักษณะของรอยตำหนิที่ต้องการครอบคลุม ตลอดจนข้อจำกัดด้านทรัพยากร งบประมาณ และเวลาในการจัดเตรียมข้อมูล การบริหารจัดการปริมาณข้อมูลและทรัพยากรอย่างเหมาะสมมีบทบาทสำคัญในการส่งเสริมประสิทธิภาพของกระบวนการวิเคราะห์ข้อมูลและการเรียนรู้ของเครื่อง [24] รวมถึงแนวคิดในงานวิจัยด้านการเรียนรู้ของเครื่องที่ว่าเมื่อชุดข้อมูลมีความหลากหลายและครอบคลุมลักษณะสำคัญแล้ว การเพิ่มจำนวนข้อมูลเพิ่มเติมในปริมาณมากอาจไม่ได้เพิ่มประสิทธิภาพของแบบจำลองอย่างมีนัยสำคัญ [25, 26] นอกจากนี้แล้ว งานวิจัยก่อนหน้านี้ในการประมวลผลภาพมักใช้จำนวนตัวอย่างในช่วงประมาณ 100–300 ภาพ สำหรับการฝึกและทดสอบแบบจำลองเช่นกัน [27]

3. เครื่องมือที่ใช้ในงานวิจัย

งานวิจัยนี้ใช้กล้องถ่ายภาพความละเอียด 6 ล้านพิกเซล (HIKROBOT MV-CU060-10GC) และใช้เลนส์ขนาด 2/3 นิ้ว พร้อมรับแสงกว้างสุดที่ f1/4 เหมาะสำหรับการใช้งานในสภาวะแสงน้อย และให้ระยะชัดตื้นที่เหมาะสมสำหรับการแยกวัตถุจากพื้นหลัง สำหรับบันทึกรอยตำหนิบนแผ่นโลหะ ร่วมกับแบบจำลอง โยโลรุ่นสิบสองเอส และ โยโลรุ่นห้าเอส ผ่านกูเกิลโคแล็บ (Google Colab) สำหรับการตรวจจับรอยตำหนิบนพื้นผิวโลหะ นอกจากนี้ ยังมีการใช้ซอฟต์แวร์การเรียนรู้เชิงลึกในระดับอุตสาหกรรม ได้แก่ แก่ ซอฟต์แวร์ชีรา และซอฟต์แวร์ชีบร้าโอโรราวิชัน เพื่อเปรียบเทียบประสิทธิภาพในการตรวจจับรอยตำหนิ

สำหรับการใส่คำอธิบายประกอบข้อมูล (Data Annotation) และการกำกับป้ายข้อมูล ได้ใช้เครื่องมือโรโบฟลว์ (RoboFlow) สำหรับแบบจำลอง โยโลรุ่นสิบสองเอส และรุ่นห้าเอส ในขณะที่ ซอฟต์แวร์ซีร่า และซอฟต์แวร์ซีร่าโอโรราวิชัน มีเครื่องมือสำหรับการใส่คำอธิบายประกอบข้อมูลภายในตัวโปรแกรม

ทั้งแบบจำลอง โยโลรุ่นสิบสองเอส โยโลรุ่นห้าเอสและซอฟต์แวร์ซีร่าใช้วิธีการ กำหนดกรอบวัตถุ (Bounding Box) ในการตรวจจ็บรอยดำหนิ ส่วน ซอฟต์แวร์ซีร่าโอโรราวิชันใช้วิธีการ ติดป้ายกำกับในระดับพิกเซล (Pixel-level Labelling) เพื่อเพิ่มความแม่นยำในการระบุรอยดำหนิ

สำหรับแบบจำลอง โยโลรุ่นสิบสองเอส และรุ่นห้าเอส รวมไปถึง ซอฟต์แวร์ซีร่า ใช้วิธีการ กำหนดกรอบวัตถุ ในขณะที่ซอฟต์แวร์ซีร่าโอโรราวิชันใช้วิธีการติดป้ายกำกับในระดับพิกเซล

สำหรับการประเมินผลการทำงานของแบบจำลอง ใช้ตัวชี้วัด ได้แก่ ตารางเมทริกซ์ความสับสน (Confusion Matrix) ความแม่นยำ ความเที่ยง ความสามารถในการตอบถูก F1-Score และ ค่าเฉลี่ยของความเที่ยง เป็นต้น

4. ขั้นตอนการดำเนินการวิจัย


ขั้นตอนการดำเนินการวิจัยในงานวิจัยนี้ ประกอบด้วย การสร้างรอยดำหนิเสมือนจริงบนพื้นผิวโลหะ การตั้งค่าสภาพแวดล้อมในการถ่ายภาพ การใส่คำอธิบายประกอบข้อมูลและการกำกับป้ายข้อมูล การฝึกแบบจำลองการตรวจจ็บรอยดำหนิ และการทดสอบประสิทธิภาพของแบบจำลอง โดยมีรายละเอียดดังต่อไปนี้

4.1 การวิจัยเริ่มต้นด้วยการสร้างรอยดำหนิเสมือนจริงบนพื้นผิวโลหะแผ่นสี่เหลี่ยมมุมฉากขนาด ความกว้าง 213 มิลลิเมตร ความยาว 153 มิลลิเมตร และความหนา 1 มิลลิเมตร เพื่อเลียนแบบลักษณะของตัวถังรถยนต์ ลักษณะของ

รอยดำหนิที่ใช้ในการสร้างแบบจำลองอ้างอิงจากข้อมูลจริงที่พบในกระบวนการผลิต ซึ่งได้จากการสัมภาษณ์บุคลากรในโรงงานผลิตยานยนต์แห่งหนึ่งในประเทศไทย การสัมภาษณ์ดังกล่าว ดำเนินการโดยหนึ่งในทีมวิจัยระหว่างช่วงฝึกงานในสถานประกอบการนั้น โดยที่ข้อมูลรอยดำหนิที่จำลองขึ้นนี้ถูกนำไปใช้ในการฝึกแบบจำลองสำหรับตรวจจ็บรอยดำหนิ กระบวนการดังกล่าว รวมถึงการพ่นสีลงบนพื้นผิวโลหะด้วย ซึ่งเลือกใช้สีแบบสุม และผลลัพธ์ที่ได้คือสีแดง อย่างไรก็ตาม การสร้างรอยดำหนิจำลองนี้ทำในระดับห้องปฏิบัติการ

4.2 การทดลองนี้ได้ออกแบบและจัดเตรียมสภาพแวดล้อมสำหรับการถ่ายภาพรอยดำหนิบนชิ้นงานให้เหมาะสมกับการเก็บข้อมูลภาพที่ใช้ในการฝึกแบบจำลองการตรวจจ็บรอยดำหนิ โดยติดตั้งกล้องพร้อมเลนส์ในตำแหน่งด้านบนเพื่อให้มุมมองตั้งฉากกับพื้นผิวของชิ้นงาน โดยมีระยะห่างระหว่างกล้องและชิ้นงานประมาณ 28 เซนติเมตร นอกจากนี้ ได้ติดตั้งแถบไฟ (Light Bar) ชนิดไดโอดเปล่งแสงได้ (Light-Emitting Diode: LED) สองชุดไว้ด้านข้างของแท่นวางชิ้นงาน เพื่อให้แสงส่องเฉียงตกกระทบบนพื้นผิว ช่วยเน้นลักษณะของรอยดำหนิที่มีความแตกต่างของแสงและเงาดังรูปที่ 2 โดยแถบไฟสามารถปรับความสว่างผ่านกระแสไฟฟ้าได้ตั้งแต่ 0 ถึง 8.4 แอมแปร์ และในการวิจัยนี้ปรับความสว่างที่ประมาณ 3.3 แอมแปร์

ทั้งนี้สภาพแวดล้อมทั้งหมดถูกควบคุมแสงจากการรบกวนจากภายนอก เพื่อให้ลดอิทธิพลจากแสงภายนอกและเพิ่มความแม่นยำของข้อมูลภาพถ่ายที่ได้



รูปที่ 2 ชุดทดสอบสำหรับถ่ายภาพ

4.3 การทดลองในงานวิจัยนี้มุ่งเน้นไปที่การประเมินประสิทธิภาพของแบบจำลอง โดยกระบวนการเก็บข้อมูลภาพถ่ายดำเนินการด้วยตนเอง กล่าวคือ ผู้วิจัยเป็นผู้วางชิ้นงานลงบนแท่นถ่ายภาพและดำเนินการถ่ายภาพในแต่ละช่วงเวลา รวมทั้งหมดจำนวน 75 ภาพ โดยภาพที่ถ่ายมามีขนาด ความกว้าง 640 พิกเซล และความยาว 640 พิกเซล จากนั้นได้นำภาพต้นฉบับไปผ่านกระบวนการปรับแต่งด้วยเทคนิคการหมุน (Rotation) และการพลิกกลับ (Flip) เพื่อสร้างภาพใหม่เพิ่มเติมอีก 75 ภาพ ส่งผลให้ได้ชุดข้อมูลภาพทั้งหมด 150 ภาพ สำหรับการฝึกและทดสอบแบบจำลอง โดยแบ่งข้อมูลออกเป็นสองชุด คือ ชุดฝึกสอน (Training set) จำนวน 120 ภาพ และชุดทดสอบ (Testing set) จำนวน 30 ภาพ ตามสัดส่วน 80 ต่อ 20 เพื่อใช้ในการประเมินแบบจำลองทั้ง 4 แบบตามที่กล่าวไว้ข้างต้น

4.4 การใส่คำอธิบายประกอบข้อมูลและการกำกับป้ายข้อมูลบนภาพตัวอย่าง การกำหนดชุดลักษณะ (Features) ถูกแบ่งเป็น 3 คลาส (Class) ในการทำป้ายกำกับ ได้แก่ “DT1” “SK” และ “good” โดยที่ “DT1” และ “SK” หมายถึงรอยตำหนิ อาจจะเป็นรอยขีดข่วนหรือบริเวณที่สีไม่สม่ำเสมอ และ “good” หมายถึงไม่มีรอยตำหนิ โดยการกำหนดลักษณะนั้นใช้วิธีการ

กำหนดกรอบวัตถุ และวิธีการติดป้ายกำกับในระดับพิกเซล ตามที่กล่าวไว้ในหัวข้อเครื่องมือที่ใช้ในการวิจัย

4.5 ขั้นตอนนี้ทำการเปรียบเทียบประสิทธิภาพของแบบจำลอง โยโลรุ่นสิบสองเอส และโยโลรุ่นห้าเอส ซึ่งเป็นแบบจำลองการเรียนรู้เชิงลึกแบบโอเพ่นซอร์ส กับความสามารถในการตรวจจับวัตถุของซอฟต์แวร์เชิงพาณิชย์ ได้แก่ ซอฟต์แวร์ซีรา และซอฟต์แวร์ซีบร้าโอโรราวิชชัน โดยมุ่งเน้นเฉพาะฟังก์ชันการตรวจจับวัตถุ ไม่ได้เปรียบเทียบระบบของแพลตฟอร์มโดยรวม ซอฟต์แวร์เชิงพาณิชย์ทั้งสองรองรับการฝึกสอนและทดสอบแบบจำลองจากชุดข้อมูลที่ผู้วิจัยจัดเตรียมขึ้นเอง จึงสามารถดำเนินการประเมินผลภายใต้เงื่อนไขที่เทียบเคียงกับการใช้งานแบบจำลองโยโลได้อย่างเหมาะสม การประเมินผลดำเนินการภายใต้เงื่อนไขเดียวกัน โดยใช้ชุดข้อมูลเดียวกัน รูปแบบการแบ่งข้อมูลชุดฝึกสอนและชุดทดสอบ (Training/Testing Split) ที่เหมือนกัน และใช้เกณฑ์วัดผลเดียวกันเพื่อให้การเปรียบเทียบผลลัพธ์มีความเป็นธรรม

นอกจากนี้ การตั้งค่าการใช้งานของซอฟต์แวร์ซีรา และซอฟต์แวร์ซีบร้าโอโรราวิชชันนั้นได้ตั้งค่าพารามิเตอร์พื้นฐานให้ใกล้เคียงกับที่ใช้ในแบบจำลองโยโลมากที่สุดเท่าที่ซอฟต์แวร์อนุญาตให้ปรับแต่งได้ เนื่องจากไม่สามารถระบุคุณสมบัติของคอมพิวเตอร์ในกูเกิลคอลลैปได้อย่างชัดเจน การบันทึกและเปรียบเทียบระยะเวลาในการประมวลผลกับคอมพิวเตอร์ที่ใช้ซอฟต์แวร์ซีรา และซอฟต์แวร์ซีบร้าโอโรราวิชชันอาจไม่เท่าเทียมกัน ดังนั้นในงานวิจัยนี้จึงไม่ได้ดำเนินการทดสอบระยะเวลาในการประมวลผล

4.6 การฝึกสอนและทดสอบสำหรับโยโลรุ่นสิบสองเอส และโยโลรุ่นห้าเอส ดำเนินการผ่านกูเกิลคอลลैป ในขณะที่ซอฟต์แวร์ซีราและซอฟต์แวร์ซีบร้าโอโรราวิชชันดำเนินการผ่าน

คอมพิวเตอร์โดยใช้การ์ดประมวลผลภาพ NVIDIA RTX 3050 GPU พร้อม RAM 16GB

5. การวิเคราะห์ข้อมูล

สำหรับการวิเคราะห์การประเมินผลแบบจำลองจะใช้ตารางเมตริกซ์ความสับสนซึ่งเป็นเครื่องมือสำคัญในการประเมินประสิทธิภาพของแบบจำลองการตรวจจับ (Detection) โดยเปรียบเทียบผลลัพธ์ที่แบบจำลองทำนายกับค่าจริง ตัวชี้วัดหลักที่ใช้คือค่าตัวชี้วัด True Positive (TP) False Positive (FP) True Negative (TN) และ False Negative (FN) เป็นพื้นฐานในการประเมินประสิทธิภาพของโมเดลในงานจำแนกประเภทแบบสองกลุ่ม โดยทั่วไปจะถูกนำเสนอในรูปแบบของตารางเมตริกซ์ความสับสน [28]

ตัวชี้วัดประสิทธิภาพที่ใช้ในการประเมินแบบจำลองในการตรวจจับรอยตำหนิ ได้แก่ ความแม่นยำ ความเที่ยง ความสามารถในการตอบถูก F1-Score และค่าเฉลี่ยของความเที่ยงซึ่งใช้ในการประเมินความแม่นยำและประสิทธิภาพในการตรวจจับวัตถุ

ผลลัพธ์ที่ได้จากการตรวจจับรอยตำหนิจะถูกนำมาประเมินและเปรียบเทียบกับแบบจำลองโยโลรุ่นห้าเอส ซอฟต์แวร์ซีราและซอฟต์แวร์ซีบีร่าโอโรราวิชั่น เพื่อวิเคราะห์ประสิทธิภาพของโยโลรุ่นสิบสองเอส และศึกษาความเหมาะสมของแบบจำลองนี้สำหรับการประยุกต์ใช้งานในบริบทการใช้งานจริง


ผลการวิจัย

ผลการวิจัยนี้จะนำเสนอการประเมินประสิทธิภาพของแบบจำลองการตรวจจับรอยตำหนิบนตัวถังรถยนต์ โดยเริ่มจากการศึกษารูปแบบรอยตำหนิที่ได้จากการสัมภาษณ์ตามที่กล่าวไว้ในหัวข้อระเบียบวิธีวิจัย และการจำลองรอยตำหนิในห้องปฏิบัติการ ผลการทดสอบจะ

นำเสนอประสิทธิภาพการตรวจจับรอยตำหนิของโยโลรุ่นสิบสองเอส โดยใช้ตัวชี้วัดที่กล่าวไว้ในหัวข้อระเบียบวิธีวิจัยในการประเมินประสิทธิภาพ นอกจากนี้ ยังมีการเปรียบเทียบประสิทธิภาพการตรวจจับระหว่าง โยโลรุ่นสิบสองเอส โยโลรุ่นห้าเอส และ ซอฟต์แวร์การเรียนรู้เชิงลึกในอุตสาหกรรมเชิงพาณิชย์ โดยใช้ตัวชี้วัดเดียวกันเพื่อแสดงให้เห็นถึงประสิทธิภาพการตรวจจับรอยตำหนิ

1. ผลการศึกษาการตรวจจับและจำลองรวมทั้งการทำป้ายกำกับ


จากการสัมภาษณ์ผู้เชี่ยวชาญ ได้มีการเตรียมเหล็กและตัดให้ได้ขนาดตามที่ระบุไว้ก่อนหน้านี้ หลังจากนั้นทำการทำความสะอาดเพื่อขจัดฝุ่นและเศษวัสดุที่อาจตกค้างก่อนจะพ่นน้ำยาเคลือบป้องกันสนิม จากนั้นสร้างรอยตำหนิจำลอง และดำเนินการพ่นสีตามขั้นตอนสุดท้ายดังรูปที่ 3




รูปที่ 3 การตัด ทำสี และจำลองรอยตำหนิ

เมื่อได้ชิ้นงานจำลองรอยตำหนิทั้งหมด 75 ชิ้นแล้ว จึงนำชิ้นงานทั้ง 75 ชิ้นไปถ่ายภาพในสภาพแวดล้อมที่กำหนดและใส่คำอธิบายประกอบข้อมูลพร้อมกับติดป้ายกำกับข้อมูลดังรูปที่ 4


รูปที่ 4(ก) เป็นรูปตัวอย่างการทำป้ายกำกับสำหรับแบบจำลองโยโลรุ่นสิบสองเอส และโยโลรุ่นห้าเอส ในขณะที่ รูปที่ 4(ข) และ รูปที่ 4(ค) เป็นตัวอย่างการทำป้ายกำกับสำหรับซอฟต์แวร์ซีบีร่า และซอฟต์แวร์ซีบีร่าโอโรราวิชั่น ตามลำดับ



(ก) โยโลรุ่นสิบสองเอส และโยโลรุ่นห้าเอส



(ข) ซอฟต์แวร์ซีร่า



(ค) ซอฟต์แวร์ซีร่าโอโรราวิชั่น

รูปที่ 4 ตัวอย่างการทำป้ายกำกับข้อมูล

2. ผลการตรวจจับรอยดำหนิด้วยโยโลรุ่นสิบสองเอส


การประเมินประสิทธิภาพของแบบจำลองโยโลรุ่นสิบสองเอส ดำเนินการภายใต้ 5 จำนวนรอบการฝึกสอน ได้แก่ 1) การฝึกสอนแบบจำลองจำนวน 20 รอบ 2) 30 รอบ 3) 40 รอบ 4) 80 รอบ และ 5) 120 รอบ โดยในทุกสภาวะกำหนดค่าแบตช์ไซส์ (Batch Size) เท่ากับ 8 และตั้งค่าขีดเริ่มในการทำนาย (Confidence Threshold) ไว้ที่ 50 รวมทั้งกำหนดค่าอัตราการเรียนรู้ (Learning Rate) ที่ 0.01

ทั้งนี้ การกำหนดจำนวนรอบการฝึกและค่าแบตช์ไซส์ดังกล่าวเป็นผลมาจากข้อจำกัดของแพลตฟอร์มกูเกิลคอลลैป (รุ่นใช้งานฟรี) ซึ่งจำกัดเวลาใช้งานต่อเนื่องในแต่ละรอบการประมวลผล (Session Runtime) และมีการจัดสรรทรัพยากรระบบ เช่น การ์ดประมวลผลภาพ และหน่วยความจำการออกแบบการทดลองจึงยึดหลักการบริหาร


จัดการทรัพยากรอย่างมีประสิทธิภาพ โดยยังคงสามารถประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองได้อย่างเป็นระบบ

สำหรับผลการประเมินแบบจำลองในแต่ละสภาวะ รายงานในรูปของค่าเฉลี่ยของความเที่ยงซึ่งคำนวณจากผลการทำนายโดยรวมทั้งในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบดังรูปที่ 5 และตัวอย่างการตรวจจับรอยดำหนิด้วยแบบจำลองโยโลรุ่นสิบสองเอสดังรูปที่ 6


ประสิทธิภาพของแบบจำลองโยโลรุ่นสิบสองเอส ภายใต้จำนวนรอบการฝึกสอนที่แตกต่างกัน (20 รอบ 30 รอบ 40 รอบ 80 รอบ และ 120 รอบ) ดังรูปที่ 5 โดยพบว่าค่าเฉลี่ยของความเที่ยงเพิ่มขึ้นอย่างต่อเนื่องจาก 0.819 ไปจนถึงค่าสูงสุดที่ 0.886 ที่ 120 รอบ อย่างไรก็ตาม ค่าความแม่นยำเฉลี่ยระหว่าง 80 และ 120 รอบเพิ่มขึ้นในอัตราที่ชะลอลง



รูปที่ 5 ผลการประเมินแบบจำลอง



(ก) การตรวจจับชิ้นงานที่มีรอยดำหนึบนพื้นผิว



(ข) การตรวจจับชิ้นงานที่ไม่มีรอยดำหนึบนพื้นผิว

รูปที่ 6 ตัวอย่างผลการตรวจจับรอยดำหนึด้วยแบบจำลองโยโลรุ่นสิบสองเอส

แบบจำลองโยโลรุ่นสิบสองเอสแสดงให้เห็นถึงความสามารถในการตรวจจับ โดยสามารถตรวจพบรอยดำหนึบนพื้นผิวได้อย่างถูกต้องในตัวอย่างภาพแรกดังรูปที่ 6 (ก) ขณะที่ในอีกกรณีหนึ่งดังรูปที่ 6 (ข) แบบจำลองสามารถจำแนกชิ้นงานที่ไม่มีรอยดำหนึได้อย่างแม่นยำ สะท้อนให้เห็นถึงศักยภาพของแบบจำลองในการแยกแยะระหว่างชิ้นงานที่มีดำหนึกับชิ้นงานที่ไม่มีดำหนึได้อย่างมีประสิทธิภาพ


3. ผลการตรวจจับรอยดำหนึด้วยโยโลรุ่นห้าเอส และซอฟต์แวร์การเรียนรู้เชิงลึกเชิงพาณิชย์

สำหรับหัวข้อนี้เป็นการทดลองเปรียบเทียบประสิทธิภาพระหว่างโยโลรุ่นสิบสองเอส กับโยโลรุ่นห้าเอส และซอฟต์แวร์การเรียนรู้เชิงลึกเชิงพาณิชย์ โดยการตั้งค่าการทดลองสำหรับโยโลรุ่นห้าเอสจะเหมือนกับโยโลรุ่นสิบสองเอส ขณะที่การตั้งค่าการทดลองสำหรับซอฟต์แวร์ซีร่าเป็นดังนี้ ค่าเบตซ์ไชส์เท่ากับ 8 และกำหนดค่าการ

เรียนรู้ที่ 0.001 สำหรับซอฟต์แวร์ซีร่าโอโรราวิชั่น การตั้งค่าที่สามารถกำหนดได้คือ Network Depth และ Patch Size ซึ่งในการทดลองนี้ได้กำหนดตามค่าตัวเลือกอัตโนมัติ (Default Value) คือ 3 และ 96 ตามลำดับ

ในขณะที่จำนวนรอบการฝึกสอนของแบบจำลองไม่สามารถกำหนดได้ สามารถหยุดกระบวนการฝึกสอนได้ในทุกช่วงเวลา สำหรับทั้งสองซอฟต์แวร์ โดยการหยุดกระบวนการฝึกสอนสามารถใช้ค่า Validation Accuracy หรือ Validation Loss เป็นเกณฑ์ในการหยุดได้

การทดลองนี้ใช้ภาพตัวอย่างจำนวน 30 ภาพ ซึ่งคิดเป็นร้อยละ 20 ของภาพทั้งหมด 150 ภาพ ตามที่ได้ระบุไว้ในขั้นตอนการดำเนินการวิจัยในหัวข้อระเบียบวิธีวิจัย เพื่อทดสอบกับแบบจำลองโยโลรุ่นสิบสองเอส โยโลรุ่นห้าเอส และซอฟต์แวร์การเรียนรู้เชิงลึกเชิงพาณิชย์ทั้งสอง หลังจากการทดลอง ผลการตรวจจับรอยดำหนึได้ถูกรวบรวมและนำเสนอ ดังรูปที่ 7



รูปที่ 7 แผนภูมิแท่งแสดงค่าประสิทธิภาพการตรวจจับรอยตำหนิของแบบจำลองการเรียนรู้เชิงลึกและซอฟต์แวร์การเรียนรู้เชิงลึกซึ่งคำนวณจากตารางเมตริกซ์ความสับสน

ทั้งนี้ เพื่อความกระชับ ข้อมูลดิบที่อยู่ในรูปแบบตารางเมตริกซ์ความสับสนของแต่ละแบบจำลองและซอฟต์แวร์ไม่ได้ถูกแสดงโดยตรง แต่จะถูกสรุปและแสดงเป็นตัวชี้วัดที่ปรากฏในรูปที่ 7

ผลการทดลองแสดงให้เห็นว่า โยโลรุ่นสิบสองเอส มีประสิทธิภาพเหนือกว่า โยโลรุ่นห้าเอส ในการตรวจจับรอยตำหนิบนพื้นผิวตัวถังรถยนต์จำลองหลังการพ่นสี โดยมีค่า F1-Score สูงกว่า (ร้อยละ 88.9 เทียบกับร้อยละ 87.5) และมีค่า Recall ที่ดีกว่าอย่างมีนัยสำคัญ (ร้อยละ 95.2 เทียบกับ ร้อยละ 84.0) ซึ่งเป็นปัจจัยสำคัญในการควบคุมคุณภาพ นอกจากนี้แล้ว โยโลรุ่นสิบสองเอสแสดงประสิทธิภาพที่แข่งขันได้เมื่อเทียบกับซอฟต์แวร์เชิงพาณิชย์อย่างซอฟต์แวร์ซีรา และซอฟต์แวร์ซีราโอโรราวิช แม้ว่าค่า F1-Score ของ โยโลรุ่นสิบสองเอส จะสูงกว่าซอฟต์แวร์ซีรา เล็กน้อย (ร้อยละ 88.9 เทียบกับ ร้อยละ 88.0) แต่ความแตกต่างนี้ไม่ได้ยืนยันว่า โยโลรุ่นสิบสองเอส เหนือกว่า ซอฟต์แวร์ซีรา เนื่องจากข้อมูลเกี่ยวกับสถาปัตยกรรมภายในของซอฟต์แวร์ซีรายังไม่เพียงพอที่จะทำให้สามารถเปรียบเทียบ

ประสิทธิภาพได้อย่างชัดเจน ในขณะที่ซอฟต์แวร์ซีราโอโรราวิช ยังคงมีประสิทธิภาพสูงสุดในทุกมิติ การประเมินเชิงเปรียบเทียบประสิทธิภาพนี้ถือเป็นความก้าวหน้าที่สำคัญของโยโลรุ่นสิบสองเอสในตระกูลโยโลที่แสดงให้เห็นถึงความสามารถในการแข่งขันกับระบบเชิงพาณิชย์เฉพาะทางภายใต้บริบทของการประเมินนี้

เนื่องจากขาดข้อมูลที่ใช้ในการคำนวณค่าเฉลี่ยของความเที่ยงจึงไม่ได้ทำการวิเคราะห์ค่าเฉลี่ยของความเที่ยงสำหรับซอฟต์แวร์การเรียนรู้เชิงลึกทั้งสอง และเพื่อความกระชับในการนำเสนอผลการวิจัย จึงไม่นำเสนอผลค่าเฉลี่ยของความเที่ยง สำหรับโยโลรุ่นห้าเอสด้วยเช่นกัน และทำการวิเคราะห์เฉพาะตัวชี้วัดดังรูปที่ 7

โดยรวมแล้วค่าตัวชี้วัดทั้ง 4 ของ โยโลรุ่นสิบสองเอส อยู่ในเกณฑ์ที่ยอมรับได้ [29] อย่างไรก็ตาม การศึกษาต่อเนื่องในการปรับแต่งพารามิเตอร์ที่มีผลต่อตัวชี้วัดทั้ง 4 เพื่อให้ผลลัพธ์ดีขึ้นยังคงเป็นสิ่งที่จำเป็น

สรุปและอภิปรายผล

งานศึกษานี้ได้สร้างรอยดำหนิจำลองจากข้อมูลจริงเพื่อประเมินประสิทธิภาพของแบบจำลองโยโลรุ่นสิบสองเอสในการตรวจจับรอยดำหนิบนตัวถังรถยนต์หลังการพ่นสี โดยเปรียบเทียบกับ โยโลรุ่นห้าเอส ซอฟต์แวร์ซีรา และ ซอฟต์แวร์ซีราโอโรราวิชัน

ผลการทดลองพบว่า โยโลรุ่นสิบสองเอส ให้ค่าค่าเฉลี่ยของความเที่ยงสูงสุด 0.886 ที่ 120 รอบการฝึกสอนแบบจำลอง อย่างไรก็ตาม การเพิ่มรอบการฝึกสอนมีแนวโน้มที่ค่าค่าเฉลี่ยของความเที่ยงจะชะลอตัวภายใต้กรอบเงื่อนไขการศึกษานี้ นอกจากนี้ ผลการทดลองพบว่า โยโลรุ่นสิบสองเอส มีค่า Recall สูงสุด (ร้อยละ 95.2) และ F1-Score ดีที่สุดในกลุ่มโอเพ่นซอร์ส (ร้อยละ 88.9) สะท้อนศักยภาพในการลดการพลาดรอยดำหนิจังหวะที่ ซอฟต์แวร์ซีรา มีค่า Precision สูงกว่า (ร้อยละ 91.7 เทียบกับร้อยละ 83.3) แสดงถึงความสามารถในการลดการตรวจผิดพลาดแบบเกินจริงได้ดีกว่า ส่วน ซอฟต์แวร์ซีราโอโรราวิชัน ยังคงแสดงผลลัพธ์โดยรวมดีที่สุดในทุกมิติ แต่ โยโลรุ่นสิบสองเอสก็มีแนวโน้มผลลัพธ์ที่ใกล้เคียงและสามารถแข่งขันได้ภายใต้ทรัพยากรที่จำกัด

การเลือกใช้ซอฟต์แวร์ซีราและซอฟต์แวร์ซีราโอโรราวิชันในการศึกษาเพื่อเปรียบเทียบกับแบบจำลองโยโล นั้นมีเหตุผลจากความพร้อมใช้งานและความน่าเชื่อถือในการใช้งานเชิงอุตสาหกรรมทั้งในด้านประสิทธิภาพและความเสถียรในสภาพแวดล้อมการผลิตจริง ซึ่งทำให้เหมาะสมในการใช้เป็นฐานในการประเมินประสิทธิภาพของแบบจำลองโยโลรุ่นต่าง ๆ ในบริบทนี้ แม้ว่าอาจมีข้อสังเกตเกี่ยวกับความแตกต่างในบริบทการใช้งานระหว่างแบบจำลองในงานวิจัยและซอฟต์แวร์เชิงอุตสาหกรรม แต่การเลือกใช้งานเหล่านี้ยังคงมีความสำคัญในการประเมินความสามารถของโมเดลในการใช้งานจริง

นอกจากนี้ การเปรียบเทียบแบบจำลองในกลุ่มเดียวกัน เช่น SSD, EfficientDet, Faster R-CNN หรือ RetinaNet ยังคงเป็นประเด็นที่ควรพิจารณา ซึ่งจะเป็นทิศทางสำคัญในการศึกษาวิจัยในอนาคต เพื่อขยายขอบเขตการทดสอบและการเปรียบเทียบระหว่างแบบจำลองที่มีเทคโนโลยีใกล้เคียงกัน การเปรียบเทียบในลักษณะนี้จะช่วยให้ได้ผลลัพธ์ที่สมบูรณ์และสะท้อนประสิทธิภาพได้อย่างชัดเจนยิ่งขึ้น

อย่างไรก็ตาม รอยดำหนิบนพื้นผิวขนาดเล็กที่ถูกบดบังด้วยชิ้นสีเคลือบและสีไม่สม่ำเสมอเพียงเล็กน้อย ยังคงเป็นความท้าทายร่วมของทุกแบบจำลองและซอฟต์แวร์ โดยเฉพาะเมื่อเกิดบนพื้นผิวสะท้อนแสงหรือมันวาว ซึ่งส่งผลกระทบต่อความแม่นยำในการตรวจจับ

ดังนั้น การพัฒนาในอนาคตควรมุ่งเสริมศักยภาพด้านการแยกแยะเฉดสีที่ใกล้เคียง รวมทั้งรอยดำหนิขนาดเล็ก และขยายการประเมินให้ครอบคลุมการทำงานในสภาพแวดล้อมจริงหรือสายการผลิตจริง ตลอดจนศึกษาผลกระทบของการปรับค่าพารามิเตอร์ของแบบจำลอง เช่น การลดค่าอัตราการเรียนรู้ (Learning Rate) หรือเพิ่มแบตช์ไซส์ (Batch Size) หรือเพิ่มรอบการฝึกสอน (Epoch) ภายใต้สภาพแวดล้อมที่ใช้ฮาร์ดแวร์ประสิทธิภาพสูงกว่าระบบปฏิบัติการที่มีข้อจำกัดด้านระยะเวลาการทำงานต่อรอบ และกำลังประมวลผลที่จำกัด นอกจากนี้ การเพิ่มจำนวนภาพตัวอย่างให้มากกว่า 300 ภาพ และสร้างรอยดำหนิจำลองจากหลายแหล่งข้อมูล ไม่จำกัดเพียงการสัมภาษณ์จากแหล่งเดียว เช่นในงานวิจัยนี้ จะช่วยเพิ่มความหลากหลายของลักษณะดำหนิ และเพิ่มความสามารถของแบบจำลองให้แม่นยำและครอบคลุมมากยิ่งขึ้น แม้ว่าแบบจำลองและซอฟต์แวร์ที่ใช้ในการศึกษานี้จะมีคุณสมบัติที่สามารถรองรับการทำงานแบบเวลาจริงได้ แต่การศึกษารุ่นนี้ได้จำกัดขอบเขตไว้

เฉพาะการประเมินประสิทธิภาพในการตรวจจับ
เท่านั้น

References

- [1] A. Saberironaghi, J. Ren, and M. El-Gindy, "Defect detection methods for industrial products using deep learning techniques: a review," *Algorithms*, vol. 16, no. 2, p. 95, February. 2023.
- [2] W. Liqun, W. Jiansheng, and W. Dingjin, "Research on vehicle parts defect detection based on deep learning," in 2nd International Symposium on Big Data and Applied Statistics (ISBDAS2019), Dalian, 2019, pp. 1-11.
- [3] H.-I. Lin and F. S. Wibowo, "Image data assessment approach for deep learning-based metal surface defect-detection systems," *IEEE Access*, vol. 9, pp. 47621-47638, March. 2021.
- [4] Y.-T. Chang, W. K. T. M. Gunarathne, and T. K. Shih, "Deep learning approaches for dynamic object understanding and defect detection," *Journal of Internet Technology*, vol. 21, no. 3, pp. 783-790, May. 2020.
- [5] Z. Jiang, X. Hu, and S. Wang, "Image classification of car paint defect detection based on convolutional neural networks," in the 2nd International Conference on Robotics, Automation and Intelligent Control (ICRAIC 2022), Changsha, 2022, pp. 1-8.
- [6] J. Zhang, J. Xu, L. Zhu, K. Zhang, T. Liu, D. Wang, and X. Wang, "An improved MobileNet-SSD algorithm for automatic defect detection on vehicle body paint," *Multimedia Tools and Applications*, vol. 79, pp. 23367-23385, June. 2020.
- [7] F. Chang, M. Liu, M. Dong, and Y. Duan, "A mobile vision inspection system for tiny defect detection on smooth car-body surfaces based on deep ensemble learning," *Measurement Science and Technology*, vol. 30, no. 12, p. 125905, September. 2019.
- [8] F. Chang, M. Dong, M. Liu, L. Wang, and Y. Duan, "A lightweight appearance quality assessment system based on parallel deep learning for painted car body," *IEEE Transactions on Instrumentation and Measurement*, vol. 69, no. 8, pp. 5298-5307, August. 2020.
- [9] I. Konovalenko, P. Maruschak, V. Brevus, and O. Prentkovskis, "Recognition of scratches and abrasions on metal surfaces using a classifier based on a convolutional neural network," *Metals*, vol. 11, no. 4, p. 549, March. 2021.
- [10] H. Huang and K. Zhu, "Automotive parts defect detection based on YOLOv7," *Electronics*, vol. 13, no. 10, p. 1817, May. 2024.

- [11] X. Tao, D. Zhang, W. Hou, W. Ma, and D. Xu, "Industrial weak scratches inspection based on multifeature fusion network," *IEEE Transactions on Instrumentation and Measurement*, vol. 70, p. 5000514, September. 2020.
- [12] L. Yao, Y. Wan, M. Yao, and B. Xu, "Detecting fine scratches on smooth surfaces with multiscale wavelet representation," *Measurement Science and Technology*, vol. 23, no. 8, p. 085603, June. 2012.
- [13] H. Marko, L. Jelečević, and G. Gledec, "A comparative study of YOLOv5 models performance for image localization and classification," in *Proceedings of the Central European Conference on Information and Intelligent Systems*, Dubrovnik, 2022, pp. 349-356.
- [14] R. Usamentiaga, D. G. Lema, O. D. Pedrayes, and D. F. Garcia, "Automated surface defect detection in metals: a comparative review of object detection and semantic segmentation using deep learning," *IEEE Transactions on Industry Applications*, vol. 58, no. 3, pp. 4203-4213, May-June. 2022.
- [15] Y. Tian, Q. Ye, and D. Doermann, "YOLOv12: Attention-centric real-time object detectors," 2025, arXiv: 2502.12524.
- [16] C C. K. Loo, S. Boonsang, T. Sasisaowapak, S. Chuwongin, T. Tongloy, S. Nahavandi, and K. W. Wong, "CiRA CORE: a low code platform that makes AI work for industry 4.0," in *2024 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*, Sarawak, 2024, pp. 1187-1188.
- [17] C. Chousangsuntorn, T. Tongloy, S. Chuwongin, and S. Boonsang, "Classification model of optical character recognition failures in unrecovered slider serial numbers in hard disk drive manufacturing and image capture processes," in *Thirteenth International Conference on Signal Processing Systems (ICSPS 2021)*, Shanghai, 2022.
- [18] R. Alonso, G. Noce, V. Cutrona, and D. R. Recupero, "Extending asset lifespan through data augmentation-assisted quality control," *IFAC-PapersOnLine*, vol. 58, no. 8, pp. 73-78, September. 2024.
- [19] P. Prusaczyk, W. Kaczmarek, J. Panasiuk, and K. Besseghieur, "Integration of robotic arm and vision system with processing software using TCP/IP protocol in industrial sorting application," in *Proceedings of the 15th Conference on Computational Technologies in Engineering*, Jora Wielka, 2019, pp. 020032-1-020032-8.

- [20] A. Boonrod, P. Piyaprapaphan, N. Kittipongphat, D. Theerakulpisut, and A. Boonrod, "Deep learning for osteoporosis screening using an anteroposterior hip radiograph image," *European Journal of Orthopaedic Surgery & Traumatology*, vol. 34, pp. 3045-3051, August. 2024.
- [21] J. Nalepa, M. Czardybon, and M. Walczak, "Real-time lung segmentation from whole-body CT scans using Adaptive Vision Studio: a visual programming software suite," in *Real-Time Image and Video Processing 2018*, Orlando, 2018.
- [22] S. Jantawong, K. Saninjak, T. Tikapunya, and J. Jomfong, "Image detection of GT pesticide test kit results in organic agricultural products using the CiRACORE deep learning model," *International Journal of Science and Innovative Technology*, vol. 7, no. 2, pp. 86-99, October. 2024.
- [23] K. Radlak, M. Frackiewicz, M. Szczepanski, M. Kawulok, and M. Czardybon, "Adaptive Vision Studio – Educational tool for image processing learning," in *2015 IEEE Frontiers in Education Conference (FIE)*, El Paso, 2015, pp. 1-8.
- [24] P. Domingos, "A few useful things to know about machine learning," *Communications of the ACM*, vol. 55, no. 10, pp. 78-87, October. 2012.
- [25] I. Goodfellow, B. Yoshua, and A. Courville, *Deep Learning*, Cambridge, MA, USA: MIT Press, 2016.
- [26] C. Sun, A. Shrivastava, S. Singh, and A. Gupta, "Revisiting unreasonable effectiveness of data in deep learning era," in *2017 IEEE International Conference on Computer Vision (ICCV)*, Venice, 2017, pp. 843-852.
- [27] P. Bergmann, M. Fauser, D. Sattlegger, and C. Steger, "MVTec AD — A comprehensive real-world dataset for unsupervised anomaly detection," in *2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*, Long Beach, 2019, pp. 9584-9592.
- [28] D. Krstinić, M. Braović, L. Šerić and D. Božić-Štulić, "Multi-label classifier performance evaluation with confusion matrix," in *International Conference on Soft Computing, Artificial Intelligence and Machine Learning (SAIM 2020)*, Copenhagen, 2020, pp. 1-14.
- [29] R. Islam, Z. H. Zamil, E. Rayed, M. Kabir, M. F. Mridha, S. Nishimura, and J. Shin, "Deep learning and computer vision techniques for enhanced quality control in manufacturing processes," *IEEE Access*, vol. 12, pp. 121449-121479, September. 2024.