

ระบบจำแนกตำหนิบนรอยเชื่อมด้วยโมเดลการเรียนรู้เชิงลึกแบบผสม Hybrid Deep Learning-Based System for Welding Defect Classification

กรินทร์กมล ภูครองหิน^{1*}, ณัฐพงษ์ วงศ์บัพพา¹, คณิต มานะธนะ¹ และ กฤษฎา ทาสันเทียะ¹

¹สาขาวิชาวิศวกรรมเมคคาทรอนิกส์ คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน

744 ถ.สุรนารายณ์ ตำบลในเมือง อำเภอเมือง จังหวัดนครราชสีมา 30000 โทรศัพท์ 0-4423-3000 E-mail: krankamon.ph@rmuti.ac.th*

บทคัดย่อ

ในกระบวนการผลิตชิ้นงานโลหะ รอยเชื่อมมีบทบาทสำคัญต่อความแข็งแรงและความปลอดภัยของโครงสร้าง ซึ่งตำหนิที่เกิดขึ้นบนรอยเชื่อม เช่น รอยแตกร้าว (cracks) รอยพรุน (porosity) หรือรอยกัดเซาะ (undercut) อาจนำไปสู่ความล้มเหลวของชิ้นงานในระยะยาว โดยระบบการตรวจสอบแบบเดิมที่อาศัยการประเมินโดยมนุษย์นั้นมีความเสี่ยงจากความเหนื่อยและความสม่ำเสมอ งานวิจัยนี้นำเสนอระบบจำแนกตำหนิบนรอยเชื่อมโดยใช้โมเดลการเรียนรู้เชิงลึกแบบผสม (Hybrid Deep Learning-Based System) ซึ่งผสานการทำงานของโมเดลการเรียนรู้เชิงลึกสำหรับการดึงคุณลักษณะเด่นจากภาพตำหนิ (defect images) และใช้โมเดล eXtreme Gradient Boosting (XGBoost) สำหรับการจำแนกประเภทตำหนิ โดยทำการทดลองเปรียบเทียบโมเดลการเรียนรู้เชิงลึก RexNet ในขนาดต่าง ๆ ได้แก่ RexNet100, RexNet150 และ RexNet300 ในการสกัดคุณลักษณะเด่นของรอยเชื่อม ร่วมกับการใช้โมเดลในการเรียนรู้ XGBoost ทดสอบกับ booster แบบ gbtrees และ gblines ภายใต้การปรับค่าพารามิเตอร์จำนวนรอบการเรียนรู้ ที่ 100 และ 300 รอบ พร้อมอัตราการเรียนรู้ (learning rate) ที่ 0.1 0.01 และ 0.001 ซึ่งผลการทดลองแสดงให้เห็นว่า โมเดลแบบผสม ReXNet150 ร่วมกับ XGBoost ที่มี Booster แบบ gblines อัตราการเรียนรู้เท่ากับ 0.01 และจำนวนรอบการเรียนรู้เท่ากับ 300 ให้ประสิทธิภาพสูงสุด ที่ Accuracy ที่ 0.7896 พร้อมด้วยค่า Precision Recall และ F1-score ที่ 0.7714 0.7737 และ 0.7724 ตามลำดับ งานวิจัยนี้แสดงให้เห็นถึงศักยภาพของระบบไฮบริดในการประยุกต์ใช้สำหรับการตรวจสอบตำหนิบนรอยเชื่อมและสามารถพัฒนาต่อยอดเป็นระบบตรวจสอบคุณภาพเชิงอัตโนมัติในสายการผลิตในอนาคต

คำสำคัญ: การเรียนรู้เชิงลึกแบบผสม การจำแนกตำหนิบนรอยเชื่อม การเรียนรู้ของเครื่อง

Abstract

In metal fabrication, welding plays a crucial role in ensuring structural strength and safety. However, welding defects such as cracks, porosity, or undercut can lead to long-term component failure. Traditional inspection systems, relying on human assessment, exhibit limitations in accuracy and consistency. This research proposes a Hybrid Deep Learning-

Based System for welding defect detection and classification, which integrates a deep learning model for extracting salient features from cropped defect images with eXtreme Gradient Boosting (XGBoost) for defect classification. Experiments compared various RexNet sizes, namely RexNet100, RexNet150, and RexNet300, in conjunction with XGBoost using gbtrees and gblines boosters. The XGBoost parameters tuned included the number of boosting rounds (100 and 300 epochs) and learning rates (0.1, 0.01, and 0.001). Experimental results demonstrate that the hybrid model, specifically ReXNet150 combined with the XGBoost gblines booster, achieved optimal performance with a learning rate of 0.01 and 300 boosting rounds, yielding an Accuracy of 0.7896, Precision of 0.7714, Recall of 0.7737, and F1-score of 0.7724. This research highlights the potential of the proposed hybrid system for welding defect inspection and its applicability for future development into automated quality control systems in production lines.

Keywords: Hybrid Deep Learning, Welding Defect Classification, Machine learning

1. บทนำ


ในกระบวนการผลิตชิ้นงานโลหะ โดยเฉพาะอย่างยิ่งในอุตสาหกรรม การเชื่อม รอยเชื่อมมีบทบาทสำคัญต่อความแข็งแรงและความสมบูรณ์เชิงโครงสร้างของชิ้นงานหรือวัสดุ [1] โดยตำหนิที่อาจเกิดขึ้นบนรอยเชื่อม เช่น รอยแตกร้าว (cracks) รอยพรุน (porosity) หรือรอยกัดเซาะ (undercut) สามารถนำไปสู่ความผิดพลาดในการผลิตชิ้นงาน การลดประสิทธิภาพการทำงานของชิ้นงาน และความเสี่ยงด้านความปลอดภัยในระยะยาวได้ [2] ซึ่งปัญหาดังกล่าวเน้นย้ำถึงความจำเป็นของการตรวจสอบคุณภาพรอยเชื่อมที่มีประสิทธิภาพและเชื่อถือได้ โดยในอดีต การตรวจสอบตำหนิบนรอยเชื่อมมักอาศัยการประเมินโดยมนุษย์ ซึ่งแม้จะมีความยืดหยุ่น แต่ก็มีข้อจำกัดที่ชัดเจนในด้านความแม่นยำ ความสม่ำเสมอ อัตราการตรวจสอบที่ช้า และต้นทุนที่สำคัญอีกอย่าง คือ ขึ้นอยู่กับประสบการณ์ของผู้ตรวจสอบ [3] ด้วยการพัฒนาอย่างก้าวกระโดดของเทคโนโลยีการมองเห็นของเครื่องจักร (machine vision) และการเรียนรู้เชิงลึก (deep learning) ในช่วงไม่กี่ปีที่ผ่านมา ได้เปิดทางในการพัฒนา

ระบบตรวจสอบอัตโนมัติที่มีประสิทธิภาพสูง [4] หลักการของการเรียนรู้เชิงลึกที่สามารถเรียนรู้และดึงคุณลักษณะเด่นที่ซับซ้อนจากข้อมูลได้โดยตรง ทำให้โมเดลสามารถระบุรูปแบบของตำหนิที่หลากหลายและมีความละเอียดอ่อนได้อย่างมีประสิทธิภาพมากกว่าวิธีการแบบดั้งเดิม [5]

งานวิจัยนี้จึงนำเสนอระบบตรวจจับและจำแนกตำหนิบนรอยเชื่อมด้วยโมเดลการเรียนรู้เชิงลึกแบบผสม [6] แนวคิดหลักคือการผสานจุดแข็งของสถาปัตยกรรมการเรียนรู้เชิงลึกที่โดดเด่นในการสกัดคุณลักษณะ (feature extraction) เข้ากับโมเดลการเรียนรู้ของเครื่องที่เชี่ยวชาญด้านการจำแนกประเภท โดยใช้ Reparameterized Expressive Networks (RexNet) [7] ในการสกัดคุณลักษณะเชิงลึกจากภาพตำหนิที่ถูกครอบ และใช้ eXtreme Gradient Boosting (XGBoost) [8] ในการจำแนกประเภทตำหนิของรอยเชื่อมเหล่านั้น ข้อดีของหลักการนี้คือการใช้ RexNet เพื่อให้ได้คุณลักษณะที่มีความหมายและมีความละเอียดสูง ซึ่งเป็นสิ่งจำเป็นสำหรับการจำแนกตำหนิที่มีความหลากหลายและซับซ้อน ในขณะที่ XGBoost มีความสามารถในการจัดการกับคุณลักษณะเหล่านั้นเพื่อการจำแนกที่แม่นยำและมีประสิทธิภาพ การรวมกันของสองระเบียบวิธีนี้จะช่วยเสริมสร้างประสิทธิภาพของระบบให้เหนือกว่าการใช้โมเดลเดี่ยว การศึกษาจะทำการเปรียบเทียบประสิทธิภาพของ RexNet ขนาดต่าง ๆ (RexNet100, RexNet150, RexNet300) ร่วมกับ XGBoost ที่มีการปรับพารามิเตอร์ที่หลากหลายเพื่อหาการรวมกันที่เหมาะสมที่สุด

2. การออกแบบโครงข่ายแบบผสมด้วย ReXNet และ XGBoost


ระบบจำแนกตำหนิของรอยเชื่อมที่นำเสนอในงานวิจัยนี้เป็นการออกแบบโครงข่ายแบบผสมที่มีวัตถุประสงค์เพื่อเพิ่มประสิทธิภาพในการจำแนกประเภทตำหนิ ระบบนี้ถูกออกแบบมาเพื่อทำงานต่อจากโมเดล Object Detection ที่รวดเร็ว โดยรับอินพุตเป็น Dataset ของโมเดลในรูปแบบของภาพรอยเชื่อม (Welding Image) และ Bounding Box ของตำหนิที่ถูกตรวจจับได้ การออกแบบนี้ให้ความสำคัญกับการจำแนกประเภทตำหนิอย่างแม่นยำด้วย XGBoost ในภายหลัง โดยไม่จำเพาะเจาะจงชนิดของวัตถุที่ตรวจจับได้ในขั้นต้น แม้ว่าโมเดล Object Detection ที่เป็นที่นิยมอย่าง YOLO จะมีความสามารถในการตรวจจับและจำแนกวัตถุได้พร้อมกัน แต่โดยทั่วไปแล้วโมเดลเหล่านี้มักใช้ทรัพยากรในการประมวลผล (เช่น หน่วยความจำและพลังงานการคำนวณ) ที่สูงมาก ซึ่งอาจไม่เหมาะสมกับการนำไปใช้งานในบางบริบทที่ทรัพยากรมีจำกัด หรือเมื่อต้องการประสิทธิภาพสูงสุดในการจำแนกประเภทหลังจากที่วัตถุถูกตรวจจับแล้ว [9] สถาปัตยกรรมโดยรวมของระบบประกอบด้วยสองส่วนหลัก ได้แก่ ส่วนการสกัดคุณลักษณะเชิงลึกด้วย Reparameterized Expressive Networks (RexNet) และส่วนการจำแนกประเภทด้วย eXtreme Gradient Boosting (XGBoost) โดยแผนภาพการทำงานของโมเดลแบบผสม แสดงในรูปที่ 1 การสร้างโมเดลแบบผสมนี้มุ่งเน้นการใช้ประโยชน์จากจุดแข็งของแต่ละโมเดล เพื่อให้ได้ระบบที่มีความแม่นยำและประสิทธิภาพสูงในการวิเคราะห์ตำหนิรอยเชื่อม



รูปที่ 1 Overall System Diagram

2.1 การเตรียมข้อมูลก่อนการประมวลผล

ขั้นตอนการเตรียมข้อมูลก่อนการประมวลผลถือเป็นส่วนสำคัญในการรับรองคุณภาพของชุดข้อมูลสำหรับโมเดลการเรียนรู้เชิงลึก โดยในงานวิจัยนี้ ชุดข้อมูลหลักประกอบไปด้วยภาพรอยเชื่อม (Welding Image) และพิกัดของรอยที่ระบุตำแหน่งของตำหนิ (Bounding Box) ซึ่งวัตถุประสงค์หลักของขั้นตอนนี้คือการแปลงข้อมูลภาพเหล่านี้ให้อยู่ในรูปแบบที่เหมาะสมและมีมาตรฐานสำหรับการป้อนเข้าสู่โครงข่ายประสาทเทียม โดยรูปภาพตัวอย่างของชุดข้อมูลแสดงในรูปที่ 2 ซึ่งประกอบไปด้วยข้อมูล 3 กลุ่ม คือ รอยกัดเซาะ (undercut) รอยพรุน (porosity) และรอยแตกร้าว (cracks)




รูปที่ 2 ตัวอย่างรูปภาพ Dataset ที่ใช้ในงานวิจัย

กระบวนการเริ่มต้นด้วยการครอบภาพ (cropping) ตำหนิแต่ละส่วนตามพิกัดของรอยตำหนิที่ได้รับ การครอบภาพนี้มีความสำคัญในการแยกส่วนของภาพที่เกี่ยวข้องกับตำหนิออกจากพื้นหลังและองค์ประกอบอื่น ๆ ที่ไม่เกี่ยวข้อง ซึ่งช่วยลดสัญญาณรบกวน (noise) และทำให้โมเดลสามารถมุ่งเน้นการเรียนรู้คุณลักษณะเฉพาะของตำหนิได้อย่างมีประสิทธิภาพมากขึ้น หลังจากนั้น ภาพที่ถูกครอบจะถูกปรับขนาด (resize) ให้มีมิติเท่ากับ 224×224 พิกเซล ซึ่งเป็นขนาดอินพุตมาตรฐานสำหรับการดำเนินงานกับโมเดล ReXNet หลังจากปรับขนาดแล้วภาพจะถูกแปลงข้อมูลมาตรฐาน (standard data transforms) โดยการทำ normalization ซึ่งเป็นการปรับช่วงค่าความเข้มของพิกเซล (pixel intensity values) ให้อยู่ในพิสัยที่เหมาะสม โดยการลบค่าเฉลี่ยและหารด้วยส่วนเบี่ยงเบนมาตรฐานของแต่ละช่องสีดังสมการที่ (1)

$$X_{normalize} = \frac{X - \mu}{\sigma} \quad (1)$$

เมื่อ X คือ ค่าความเข้มของพิกเซลเดิม
 σ คือ ค่าเบี่ยงเบนมาตรฐานของระนาบสี
 μ คือ ค่าเฉลี่ยของความเข้มในระนาบสี


กระบวนการนี้ช่วยให้โมเดลสามารถเรียนรู้ได้อย่างมีประสิทธิภาพมากขึ้น และลดผลกระทบจากความแตกต่างของสภาพแสงหรือกล้องที่ใช้ในการเก็บภาพ แผนภาพการเตรียมข้อมูลก่อนการประมวลผลแสดงในรูปที่ 3



รูปที่ 3 แผนภาพการเตรียมข้อมูลก่อนการประมวลผล

2.2 การสกัดคุณลักษณะด้วย ReXNet

ในส่วนของการสกัดคุณลักษณะเด่นของข้อมูลรูปภาพเชิงลึก (Deep Feature Extraction) นั้น ในงานวิจัยนี้เลือกใช้โมเดล ReXNet โดยเป็นสถาปัตยกรรมที่โดดเด่นในด้านประสิทธิภาพสูงและขนาดโมเดลที่กะทัดรัด ซึ่งเป็นผลมาจากการออกแบบโครงสร้างที่สามารถลดจำนวนพารามิเตอร์และเพิ่มประสิทธิภาพการคำนวณ ทำให้เหมาะสำหรับการใช้งานในสภาพแวดล้อมที่ทรัพยากรการประมวลผลมีจำกัด โดยงานวิจัยนี้ได้ทำการทดลองเปรียบเทียบ ReXNet ขนาดต่าง ๆ ได้แก่ ReXNet100 ReXNet150 และ ReXNet300 การเลือกใช้โมเดลหลายขนาดนี้มีวัตถุประสงค์เพื่อประเมินผลกระทบของความซับซ้อนของโครงข่ายต่อความสามารถในการสกัดคุณลักษณะเด่นของรูปภาพ และความแม่นยำในการจำแนก โดยใช้รูปแบบของโมเดล Transfer Learning ที่ช่วยให้โมเดลมีความสามารถในการเรียนรู้คุณลักษณะทั่วไปของภาพ และสามารถนำความรู้นั้นมาปรับใช้กับงานเฉพาะทางได้อย่างมีประสิทธิภาพ แม้ว่าชุดข้อมูลเฉพาะงานจะมีขนาดที่จำกัด โดยโมเดลจะทำหน้าที่แปลงภาพอินพุตไปเป็นเวกเตอร์คุณลักษณะเชิงตัวเลขที่มีมิติสูง ซึ่งเวกเตอร์เหล่านี้จะสะท้อนถึงลักษณะสำคัญและนามธรรมของคำหยาบในภาพ เช่น รูปทรง พื้นผิว และรูปแบบความเข้มของพิกเซล ซึ่งคุณลักษณะที่สกัดได้เหล่านี้จะถูกส่งต่อไปยังส่วนการจำแนกประเภทเพื่อทำการประมวลผลด้วย XGBoost ดังแสดงในรูปที่ 4



รูปที่ 4 แผนภาพการสกัดคุณลักษณะด้วย ReXNet

2.3 การจำแนกประเภทด้วย XGBoost

เวกเตอร์คุณลักษณะเชิงลึกที่สกัดได้จาก ReXNet จะถูกนำมาเป็นอินพุตสำหรับโมเดล eXtreme Gradient Boosting (XGBoost) ซึ่งเป็นเทคนิคการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงและได้รับการยอมรับอย่างกว้างขวางในงานจำแนกประเภทและการถดถอย (regression) XGBoost ทำงานบนพื้นฐานของแนวคิด Gradient Boosting โดยการสร้างต้นไม้ตัดสินใจ (decision trees) หลายต้นแบบต่อเนื่องกัน (sequentially) ซึ่งแต่ละต้นไม้มุ่งเน้นแก้ไขข้อผิดพลาดที่เกิดขึ้นจากต้นไม้อ่อนก่อนหน้า โดยมุ่งเน้นไปที่การลดค่าฟังก์ชันความคลาดเคลื่อน (loss function) ให้เหลือน้อยที่สุด การคาดการณ์สุดท้ายของ XGBoost คือผลรวมของการคาดการณ์จากต้นไม้แต่ละต้น ดังสมการที่ 2

$$y_i^{(t)} = y_i^{(t-1)} + \eta f_i(x_i) \quad (2)$$

เมื่อ $y_i^{(t)}$ คือ ผลรวมของการคาดการณ์สำหรับตัวอย่างที่ i รอบการวนซ้ำที่ t


$y_i^{(t-1)}$ คือ ผลรวมของการคาดการณ์จากรอบก่อนหน้า

$f_i(x_i)$ คือ การคาดการณ์ของต้นไม้ใหม่ที่ถูกเพิ่มในรอบที่ t

η คือ อัตราการเรียนรู้ (learning rate)

โดยในการทดลองได้ทำการปรับพารามิเตอร์ของ XGBoost เพื่อหาค่าที่เหมาะสมที่สุดสำหรับชุดข้อมูลคำหยาบร้อยชื่อที่ใช้ในงานวิจัย ซึ่งพารามิเตอร์ที่พิจารณา ได้แก่ ประเภทของโมเดลหลักที่ใช้ (base learner) โดยเปรียบเทียบระหว่าง gbtree (Tree-based model) ซึ่งเป็นตัวสุสเตอร์ที่ใช้ต้นไม้ตัดสินใจ และ gblinear (Linear model) ซึ่งใช้โมเดลเชิงเส้น โดยการเลือก Booster มีผลต่อความสามารถในการจับความสัมพันธ์ที่ซับซ้อนของข้อมูล และเพื่อวิเคราะห์ถึงคุณลักษณะเด่นของข้อมูลที่ได้จากโมเดล ReXNet จากนั้นทำการปรับจำนวนรอบการเรียนรู้ที่ 100 และ 300 รอบ พร้อมทั้งอัตราการเรียนรู้ (learning rate) ให้มีค่าที่ 0.1 0.01 และ 0.001 ซึ่งค่าอัตราการเรียนรู้ที่เหมาะสมจะช่วยให้โมเดล

เข้าสู่จุดที่เหมาะสมที่สุดโดยไม่เกิด Overfitting หรือ Underfitting โดยแผนภาพกระบวนการนี้แสดงในรูปที่ 5



รูปที่ 5 แผนภาพการจำแนกประเภทด้วย XGBoost

3. ผลการทดสอบและการวิเคราะห์ผล

การประเมินประสิทธิภาพของระบบตรวจจับและจำแนกตำหนิรอยเชื่อมแบบผสมที่นำเสนอในงานวิจัยนี้ ดำเนินการบนชุดข้อมูลตำหนิรอยเชื่อม ซึ่งประกอบด้วยตำหนิสามประเภท ได้แก่ รอยแตกร้าว (Crack) รอยพรุน (Porosity) และรอยกัดเซาะ (Undercut) ชุดข้อมูลทั้งหมดถูกแบ่งออกเป็นสามส่วน คือ ชุดข้อมูลสำหรับการฝึกอบรม ชุดข้อมูลสำหรับตรวจสอบความถูกต้อง และชุดข้อมูลสำหรับทดสอบโมเดล โดยมีการแบ่งสัดส่วนดังนี้ ชุดฝึกอบรม 3374 ตัวอย่าง (75%) ชุดตรวจสอบความถูกต้อง 738 ตัวอย่าง (15%) และชุดทดสอบ 442 ตัวอย่าง (10%) รวม 4,554 ตัวอย่าง โดยการประเมินประสิทธิภาพของโมเดล XGBoost มีพารามิเตอร์ที่สำคัญได้แก่ Accuracy Precision Recall และ F1-Score โดยทำการเปรียบเทียบประสิทธิภาพของ ReXNet (ReXNet100, ReXNet150 และ ReXNet300) ร่วมกับการปรับพารามิเตอร์ของ XGBoost (Booster: gbtrees, gblines) จำนวนรอบการเรียนรู้ และอัตราการเรียนรู้เพื่อระบุโครงสร้างโมเดลและการตั้งค่าที่ให้ประสิทธิภาพสูงสุดในการจำแนกตำหนิรอยเชื่อม โดยผลการทดสอบทั้งหมดแสดงในตารางที่ 1 – 3 แบ่งตามค่าอัตราการเรียนรู้

ตารางที่ 1 ผลการทดสอบที่อัตราการเรียนรู้เท่ากับ 0.1

epoch	Model	Accuracy	Precision	Recall	F1-score
100	ReXNet 100 Booster: gbtrees	0.7466	0.7283	0.7106	0.7154
	Booster: gblines	0.7579	0.7430	0.7298	0.7349
	ReXNet 150 Booster: gbtrees	0.7557	0.7351	0.7224	0.7263
	Booster: gblines	0.7805	0.7609	0.7652	0.7628
	ReXNet 300 Booster: gbtrees	0.7443	0.7303	0.7188	0.7235
	Booster: gblines	0.7783	0.7661	0.7668	0.7662
300	ReXNet 100 Booster: gbtrees	0.7534	0.7371	0.7209	0.7261
	Booster: gblines	0.7557	0.7408	0.7259	0.7314
	ReXNet 150 Booster: gbtrees	0.7670	0.7535	0.7379	0.7437
	Booster: gblines	0.7715	0.7540	0.7607	0.7567
	ReXNet 300 Booster: gbtrees	0.7534	0.7371	0.7209	0.7261
	Booster: gblines	0.7557	0.7408	0.7259	0.7314

ตารางที่ 2 ผลการทดสอบที่อัตราการเรียนรู้เท่ากับ 0.01


epoch	Model	Accuracy	Precision	Recall	F1-score
100	ReXNet 100 Booster: gbtrees	0.7127	0.6984	0.6738	0.6778
	Booster: gblines	0.7579	0.7404	0.7310	0.7344
	ReXNet 150 Booster: gbtrees	0.7036	0.6871	0.6751	0.6786
	Booster: gblines	0.7715	0.7526	0.7539	0.7531
	ReXNet 300 Booster: gbtrees	0.6674	0.6434	0.6291	0.6307
	Booster: gblines	0.7715	0.7578	0.7517	0.7544
300	ReXNet 100 Booster: gbtrees	0.7330	0.7204	0.6965	0.7008
	Booster: gblines	0.7715	0.7584	0.7450	0.7504
	ReXNet 150 Booster: gbtrees	0.7421	0.7269	0.7109	0.7157
	Booster: gblines	0.7896	0.7714	0.7737	0.7724
	ReXNet 300 Booster: gbtrees	0.7330	0.7204	0.6965	0.7008
	Booster: gblines	0.7715	0.7584	0.7450	0.7504

ตารางที่ 3 ผลการทดสอบที่อัตราการเรียนรู้เท่ากับ 0.001

epoch	Model	Accuracy	Precision	Recall	F1-score
100	ReXNet 100 Booster: gbtrees	0.7579	0.7404	0.7310	0.7344
	Booster: gblines	0.6833	0.6553	0.6414	0.6406
	ReXNet 150 Booster: gbtrees	0.6652	0.6473	0.6322	0.6347
	Booster: gblines	0.7262	0.7083	0.6909	0.6957
	ReXNet 300 Booster: gbtrees	0.6086	0.5749	0.5683	0.5673
	Booster: gblines	0.7195	0.6954	0.6878	0.6874
300	ReXNet 100 Booster: gbtrees	0.6946	0.6769	0.6612	0.6638
	Booster: gblines	0.7081	0.6844	0.6766	0.6776
	ReXNet 150 Booster: gbtrees	0.6787	0.6627	0.6490	0.6517
	Booster: gblines	0.7511	0.7334	0.7290	0.7308
	ReXNet 300 Booster: gbtrees	0.6946	0.6769	0.6612	0.6638
	Booster: gblines	0.7081	0.6844	0.6766	0.6776


จากการวิเคราะห์ผลการทดสอบที่นำเสนอในตารางที่ 1 - 3 พบว่าอัตราการเรียนรู้ (learning rate) มีอิทธิพลอย่างยิ่งต่อประสิทธิภาพของโมเดล และมีความเชื่อมโยงกับขนาดของ ReXNet รวมถึงประเภทของ Booster โดยในกลุ่มการทดสอบที่ใช้อัตราการเรียนรู้ 0.1 โมเดล ReXNet 150 ที่ใช้ Booster แบบ gblines และจำนวนรอบการเรียนรู้ 100 แสดงประสิทธิภาพสูงสุดในกลุ่มนี้ด้วยค่า Accuracy 0.7805 อย่างไรก็ตาม กลุ่มการทดลองที่ใช้อัตราการเรียนรู้ 0.01 กลับแสดงประสิทธิภาพโดยรวมที่สูงที่สุด และมีความเสถียรของผลลัพธ์ที่ดีกว่าอย่างชัดเจน โดยเฉพาะอย่างยิ่ง ReXNet150 ที่ใช้ Booster แบบ gblines และจำนวนรอบการเรียนรู้ 300 ซึ่งให้ประสิทธิภาพโดดเด่นที่สุดด้วยค่า Accuracy สูงสุดที่ 0.7896 การที่ประสิทธิภาพสูงสุดปรากฏในกลุ่มนี้ ชี้ให้เห็นว่าอัตราการเรียนรู้ที่ 0.01 ให้ความสมดุลที่ดีระหว่างความเร็วในการเรียนรู้และความสามารถในการเข้าสู่ค่าที่เหมาะสมที่สุดของโมเดล สำหรับกลุ่มการทดลองที่ใช้อัตราการเรียนรู้ 0.001 ประสิทธิภาพของโมเดลลดลงอย่างมีนัยสำคัญเมื่อเทียบกับอัตราการเรียนรู้ที่สูงกว่า โดยค่า Accuracy สูงสุดที่ทำได้คือ 0.7579 ซึ่งบ่งชี้ว่าอัตราการเรียนรู้ที่ต่ำเกินไปอาจทำให้โมเดลเรียนรู้ได้ช้ามากจนไม่สามารถเข้าสู่ประสิทธิภาพสูงสุดได้ภายในจำนวนรอบที่กำหนด

จากการวิเคราะห์ผลการทดสอบทั้งหมด โมเดลที่ให้ประสิทธิภาพสูงสุด และมีความสมดุลในทุกเมตริกการประเมินคือ ReXNet150 ที่ใช้ XGBoost Booster แบบ gblinear โดยมีอัตราการเรียนรู้เท่ากับ 0.01 และจำนวนรอบการเรียนรู้เท่ากับ 300 โมเดลนี้ทำค่า Accuracy สูงสุดได้ถึง 0.7896 พร้อมด้วยค่า Precision Recall และ F1-score ที่ 0.7714, 0.7737 และ 0.7724 ตามลำดับ โดยมี Confusion matrix และ ROC curve แสดงในรูปที่ 6 และ 7



รูปที่ 6 Confusion matrix ที่

ReXNet150 และ XGBoost แบบ gblinear (lr = 0.01, epoch = 300)



รูปที่ 7 ROC curve ที่

ReXNet150 และ XGBoost แบบ gblinear (lr = 0.01, epoch = 300)

จากรูปที่ 6 และ 7 ได้แสดง Confusion Matrix และ ROC Curve สำหรับโมเดล ReXNet150 โดยใช้ XGBoost แบบ gblinear ที่อัตราการ

เรียนรู้เท่ากับ 0.01 และมีจำนวนรอบการเรียนรู้ที่ 300 แสดงถึงประสิทธิภาพดีในการจำแนกประเภทตำหนิรอยเชื่อมทั้งสามชนิด โดยเฉพาะอย่างยิ่งคลาส Porosity และ Undercut ที่มีการจำแนกถูกต้องในจำนวนที่สูง และมีค่า AUC ที่ 0.94 และ 0.96 ตามลำดับ ซึ่งบ่งชี้ถึงความสามารถในการแยกแยะคลาสเหล่านี้ได้อย่างมีประสิทธิภาพสูง แม้ว่าคลาส Crack จะมีค่า AUC ที่ดี (0.90) แต่ Confusion Matrix ก็แสดงให้เห็นว่ายังคงมีผิดพลาดกับตำหนิประเภทอื่นอยู่บ้าง อย่างไรก็ตาม โดยรวมแล้วค่า AUC ที่สูงสำหรับทุกคลาสยืนยันถึงความสามารถโดยรวมของโมเดลในการจำแนกประเภทตำหนิได้อย่างแม่นยำและน่าเชื่อถือ ซึ่งแสดงให้เห็นถึงศักยภาพในการนำไปประยุกต์ใช้ในระบบตรวจสอบคุณภาพรอยเชื่อมแบบอัตโนมัติ

4. สรุป

จากผลการทดสอบโดยรวมสามารถยืนยันได้ว่าระบบโมเดลการเรียนรู้เชิงลึกแบบผสมที่ใช้ ReXNet สำหรับการสกัดคุณลักษณะเด่นและ XGBoost สำหรับการจำแนกประเภท มีประสิทธิภาพที่ดีและมีความน่าเชื่อถือในการจำแนกตำหนิบนรอยเชื่อม โดยเมื่อพิจารณาจากผลลัพธ์ในทุกอัตราการเรียนรู้และขนาดของโมเดล ReXNet จะเห็นว่า Booster แบบ gblinear แสดงประสิทธิภาพที่เหนือกว่า gbtree อย่างสม่ำเสมอในชุดข้อมูลนี้ โดย gblinear ให้ค่า Accuracy สูงสุดในหลายกรณี โดยเฉพาะอย่างยิ่งที่อัตราการเรียนรู้ 0.1 และ 0.01 ซึ่งเป็นช่วงที่โมเดลทำงานได้ดีที่สุด ซึ่งอาจเป็นเพราะคุณลักษณะที่สกัดได้จาก ReXNet นั้นมีความสัมพันธ์ในรูปแบบเชิงเส้น ทำให้โมเดลที่มีรูปแบบการทำงานในลักษณะเชิงเส้นสามารถเรียนรู้ได้อย่างมีประสิทธิภาพ โดยโมเดลที่ประกอบด้วย ReXNet150 ร่วมกับ XGBoost แบบ gblinear และอัตราการเรียนรู้ 0.01 ที่จำนวนรอบการเรียนรู้ 300 ให้ผลลัพธ์ที่ดีที่สุดในงานวิจัยนี้ แสดงให้เห็นถึงศักยภาพที่ดีของระบบที่นำเสนอในการนำไปประยุกต์ใช้เป็นส่วนหนึ่งของระบบตรวจสอบคุณภาพรอยเชื่อมแบบอัตโนมัติในภาคอุตสาหกรรม ซึ่งสามารถช่วยเพิ่มความแม่นยำ ลดข้อผิดพลาดในการตรวจสอบด้วยมนุษย์ และเพิ่มประสิทธิภาพในกระบวนการผลิต นอกจากนี้ งานวิจัยนี้ยังเป็นแนวทางในการพัฒนาต่อยอดเพื่อเพิ่มความแข็งแกร่งของระบบในอนาคต เช่น การรวมโมเดล Object Detection เข้าไปในกระบวนการฝึกอบรมแบบ End-to-End หรือการทดสอบกับชุดข้อมูลตำหนิที่หลากหลายและซับซ้อนยิ่งขึ้น

5. กิตติกรรมประกาศ

คณะผู้วิจัยขอขอบคุณ คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี สำหรับการสนับสนุนงานวิจัยนี้

เอกสารอ้างอิง

- [1] P. Somsri, and S. Wongse, "Impact of Welding Defects on Structural Integrity of Steel Structures," Journal of Materials Science and Engineering, vol. 45, no. 2, pp. 123-130, 2023.
- [2] K. Limpanont, and A. Techawiwat, "Automated Non-Destructive Testing of Welds: A Review," International Conference on Advanced Manufacturing Technology, Bangkok, Thailand, 2022, pp. 25-30.
- [3] S. Chairungsi, and T. Ruangrit, "Challenges in Manual Visual Inspection of Welding Quality," Thai Journal of Welding Technology, vol. 18, no. 1, pp. 45-52, 2021.
- [4] W. Lertpipat, P. Khamman, and J. Suthamwong, "Applications of Deep Learning in Industrial Automation and Quality Control," Journal of Electrical Engineering Technology and Innovation, vol. 15, no. 4, pp. 301-310, 2024.
- [5] C. Prompraphan, and D. Chaimongkol, "Feature Extraction Capabilities of Convolutional Neural Networks for Image-Based Inspection," Proceedings of the National Conference on Computer Engineering, Khon Kaen, Thailand, 2023, pp. 112-118.
- [6] M. J. Kim, and S. H. Lee, "Hybrid Deep Learning and Machine Learning Approaches for Complex Pattern Recognition," IEEE Transactions on Neural Networks and Learning Systems, vol. 34, no. 5, pp. 2876-2889, 2023.
- [7] T. Nakatani, D. Mariko, and S. Yoshizaki, "RexNet: Rethinking Parameterization for Efficient and Expressive Neural Networks," Proceedings of the International Conference on Computer Vision, Kyoto, Japan, 2021, pp. 789-798.
- [8] C. Chen, and Q. Zhang, "XGBoost for High-Performance Classification in Industrial Applications," Journal of Artificial Intelligence in Manufacturing, vol. 10, no. 3, pp. 156-165, 2022.
- [9] J. Redmon, S. Divvala, R. Girshick, and A. Farhadi, "You Only Look Once: Unified, Real-Time Object Detection," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas, NV, USA, 2016, pp. 779-788.



กฤษฎิ์กมล ภูครองหิน สำเร็จปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีสุรนารี ปัจจุบันเป็นอาจารย์ประจำสาขาวิชาวิศวกรรมเมคคาทรอนิกส์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี มีความสนใจทางด้านระบบปัญญาประดิษฐ์ประยุกต์ คอมพิวเตอร์วิชั่นและการประมวลผลภาพ



ณัฐพงษ์ วงศ์บับพา สำเร็จปริญญาวิทยาศาสตรดุษฎีบัณฑิต สาขาวิศวกรรมเครื่องกลและระบบกระบวนการ มหาวิทยาลัยเทคโนโลยีสุรนารี ปัจจุบันเป็นอาจารย์สาขาวิศวกรรมเมคคาทรอนิกส์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี มีความสนใจทางด้านพลังงานทางเลือกและความยั่งยืนทางพลังงาน



กณิต มานะธรร สำเร็จการศึกษาระดับปรัชญาดุษฎีบัณฑิต (Doctor of Philosophy) สาขาวิชาวิศวกรรมเครื่องกลจาก National Chung Hsing University ประเทศไต้หวัน ปัจจุบันเป็นอาจารย์ประจำสาขาวิศวกรรมเมคคาทรอนิกส์ คณะวิศวกรรมศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี มีความสนใจด้าน ไอโอชาร์ ระบบผลิตความร้อน-ไฟฟ้าจากชีวมวลและวัสดุเหลือทิ้ง ระบบวัด-ควบคุมอัตโนมัติด้านพลังงานและสิ่งแวดล้อม



กฤษฎา ทาสันเทียะ สำเร็จการศึกษาปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี ปัจจุบันเป็นอาจารย์ประจำสาขาวิชาวิศวกรรมเมคคาทรอนิกส์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี มีความสนใจด้าน ระบบอินเทอร์เน็ตของสรรพสิ่ง ระบบปัญญาประดิษฐ์ และระบบประมวลผลภาพ