

เทคนิคการเรียนรู้เชิงลึกสำหรับการตรวจจับและอธิบายข้อบกพร่องในอุตสาหกรรมการผลิตแผ่นวงจรพิมพ์

Advanced Deep Learning for Industrial PCB Defect Detection and Explainability

สุรศักดิ์ สันพระยากุล และ ผศ.ดร.เปี่ยมภูมิ สฤกพฤกษ์

ภาควิชาวิศวกรรมไฟฟ้า คณะวิศวกรรมศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

63601109@kmitl.ac.th, piampoom.sa@kmitl.ac.th

บทคัดย่อ

งานวิจัยนี้นำเสนอการพัฒนากระบวนการตรวจสอบข้อบกพร่องที่พบบนพื้นผิวแผ่นวงจรพิมพ์ (PCB) ที่พัฒนาขึ้น เพื่อเพิ่มสมรรถนะการตรวจสอบด้วยแสงอัตโนมัติแบบดั้งเดิม ซึ่งมีข้อจำกัดเกี่ยวกับความแม่นยำ ความรวดเร็ว และบางครั้งไม่สามารถอธิบายข้อบกพร่องที่พบได้ เนื่องจากการใช้วิธีการเปรียบเทียบภาพจริงกับภาพต้นแบบ การศึกษานี้ได้มีการประยุกต์ใช้อัลกอริทึม YOLOv8n ซึ่งเป็น เทคนิคการเรียนรู้เชิงลึกที่มีประสิทธิภาพสูง ในการจำแนกข้อบกพร่องบน แผ่นวงจรพิมพ์ โดยทำการศึกษา และ ทดสอบจากข้อบกพร่องที่พบบ่อย 6 ประเภทคือ วงจรเปิด การลัดวงจร รอยกัด ดึงโลหะ รูเข็ม และทองแดงส่วนเกิน ผลการทดลองแสดงให้เห็นว่าระบบที่พัฒนาขึ้นมีประสิทธิภาพที่ดีมาก โดยมีเฉลี่ยความแม่นยำ (Mean Average Precision) ที่เกณฑ์ IoU (Intersection over Union) ถึง 96.8% ผลลัพธ์ที่ได้ เหมาะสำหรับการนำไปใช้ในการตรวจสอบและควบคุมคุณภาพในสายการผลิตด้วยระบบอัจฉริยะทำให้ยกระดับกระบวนการผลิตและลดอัตราการเกิดข้อผิดพลาดอย่างมีประสิทธิภาพและยั่งยืน

Abstract

This research presents the development of a Printed Circuit Board (PCB) surface defect inspection system designed to enhance the performance of traditional Automated Optical Inspection (AOI) systems. The AOI systems, relying on image comparison between real and reference images, often face limitations in terms of accuracy, speed, and their inability to provide explainability for detected defects. This study applies the YOLOv8n algorithm, a high-performance deep learning technique, to accurately classify common PCB defects.

The system was studied and tested on six prevalent defect types including open circuit, short circuit, spurious copper, mouse bite, pin-hole, and spur. Experimental results demonstrate excellent performance, with the developed system achieving a Mean Average Precision (MAP) of 96.8% at the Intersection over Union (IoU) threshold. This result is appropriate for intelligent quality control in manufacturing lines, and is expected to significantly improve production processes and sustainably reduce error rates.

Keywords: PCB defect detection, Deep Learning, YOLOv8, Explainable AI (XAI), Feature Visualization, Automatic Optical Inspection, Smart Manufacturing

1. บทนำ

แผ่นวงจรพิมพ์ (Printed Circuit Board: PCB) ถือเป็นองค์ประกอบสำคัญในอุตสาหกรรมอิเล็กทรอนิกส์ยุคปัจจุบันซึ่งมีบทบาทขับเคลื่อนเทคโนโลยีหลากหลายประเภทตั้งแต่อุปกรณ์พกพาขนาดเล็กเช่น โทรศัพท์มือถือ ไปจนถึงระบบอุตสาหกรรมขนาดใหญ่ ด้วยเหตุนี้การตรวจสอบคุณภาพของ PCB จึงมีความสำคัญอย่างยิ่งต่อประสิทธิภาพ และความน่าเชื่อถือทางคุณภาพของผลิตภัณฑ์ โดยปัจจุบันระบบการตรวจสอบด้วยแสงแบบอัตโนมัติ (Automated Optical Inspection: AOI) ที่มีอยู่ดั้งเดิมและใช้กันอย่างแพร่หลาย อาศัยหลักการสแกนภาพและวิเคราะห์ภาพด้วยระบบเปรียบเทียบภาพจริง กับภาพต้นแบบที่มักจะประสบปัญหาด้านความแม่นยำ, ความเร็ว, ข้อจำกัดในการจัดการข้อบกพร่องที่ซับซ้อนและหลากหลาย ซึ่งส่งผลกระทบโดยตรงต่อประสิทธิภาพและต้นทุนในการผลิต จากความต้องการแก้ปัญหาเหล่านี้ทำให้เกิดการพัฒนากระบวนการตรวจสอบ ที่สามารถยกระดับขีดความสามารถในการตรวจสอบคุณภาพ

งานวิจัยนี้จึงนำเสนอการ พัฒนาระบบตรวจจับข้อบกพร่องบนพื้นผิว PCB ที่มีประสิทธิภาพสูง โดยการประยุกต์ใช้ เทคโนโลยีการเรียนรู้เชิงลึก (Deep Learning) และเลือกใช้โมเดล YOLOv8n ซึ่งเป็นปัญญาประดิษฐ์ ประเภทหนึ่งที่มีจุดเด่นคือ การตรวจจับวัตถุด้วยความเร็วสูง และการประมวลผลที่แม่นยำและนำระบบนี้มา ทำการเรียนรู้และจำแนก ข้อบกพร่องบนพื้นผิวของ PCB ที่พบบ่อย 6 ประเภทได้แก่ วงจรเปิด, การลัดวงจร, รอยกัด, ดึงโลหะ, รูเข็ม และทองแดงส่วนเกิน

การฝึกสอน และ ทดสอบแบบจำลองได้เลือกใช้ ชุดข้อมูลสาธารณะ Deep PCB ซึ่งเป็นฐานข้อมูลสาธารณะ ซึ่งจะช่วยให้มั่นใจได้ถึงความปลอดภัย และความน่าเชื่อถือของผลลัพธ์สำหรับการนำไปใช้งานจริงในภาคอุตสาหกรรมการผลิต นอกจากนี้เพื่อเพิ่มความมั่นใจและลดความซับซ้อนของผลลัพธ์ งานวิจัยนี้ได้ นำ เทคนิคปัญญาประดิษฐ์ที่สามารถอธิบายได้ (Explainable AI: XAI) มาปรับใช้ โดยจะแสดงภาพคุณลักษณะของบริเวณที่เกิดจุดบกพร่องผ่านการสร้างภาพในอุดมคติและแผนภาพความร้อนขึ้นมา เพื่อช่วยให้สามารถอธิบายและตรวจสอบ รวมถึงวิเคราะห์พฤติกรรมการตัดสินใจของโมเดลได้โดยใช้เหตุผลประกอบ และอธิบายได้ว่าโมเดลให้ความสำคัญกับลักษณะเฉพาะของข้อบกพร่องแต่ละประเภทอย่างไร

ผลการทดลองแสดงให้เห็นถึงประสิทธิภาพที่โดดเด่นของแบบจำลองที่ทำการศึกษาและพัฒนาขึ้นมา โดยสามารถทำค่าความแม่นยำเฉลี่ย Mean Average Precision (MAP) โดยใช้ เกณฑ์ Intersection over Union (IoU) ได้สูงถึง 96.8% จึงเป็นการประสานรวมระหว่างเทคโนโลยีการตรวจจับข้อบกพร่องที่มีความแม่นยำสูงเข้ากับเทคนิคการอธิบายผลลัพธ์ที่โปร่งใส จึงนับเป็นแนวทางการแก้ไขปัญหาที่สามารถอธิบายเหตุและผลของข้อบกพร่องที่เกิดขึ้นได้ และเป็นประโยชน์ต่อการปรับปรุงกระบวนการผลิต และลดอัตราการเกิดข้อผิดพลาดได้อย่างยั่งยืนในอนาคต

2.วิธีดำเนินการวิจัย


ระบบการตรวจสอบด้วยแสงอัตโนมัติ (AOI) แบบดั้งเดิม [1] แม้จะถูกนำมาใช้อย่างแพร่หลาย แต่มักอาศัยอัลกอริทึมตามกฎเกณฑ์ที่ตายตัวซึ่งประสบปัญหา ในการรับมือกับความหลากหลายของสภาพแวดล้อมการผลิตจริง นำไปสู่อัตราผลบกพร่องที่สูงและต้องใช้เวลาตรวจสอบด้วยตนเองซึ่งมีค่าใช้จ่ายสูง [2] ข้อจำกัดของวิธีการมองเห็นของเครื่องจักรแบบดั้งเดิมเหล่านี้ชี้ให้เห็นถึงความจำเป็นของเทคนิคการตรวจสอบที่ทนทานและปรับตัวได้ดีกว่า [3]

เพื่อเอาชนะข้อจำกัดเหล่านี้ แนวทางที่ใช้การเรียนรู้เชิงลึก โดยเฉพาะแบบจำลองการตรวจจับวัตถุ ได้กลายเป็นทางเลือกที่เหมาะสม ซึ่งแบบจำลองเหล่านี้สามารถเรียนรู้คุณลักษณะที่ซับซ้อนของข้อบกพร่องได้โดยอัตโนมัติจากข้อมูล ทำให้มีความสามารถในการปรับตัวและความแม่นยำที่เหนือกว่า การศึกษานี้ใช้แบบจำลอง YOLOv8n ซึ่งเป็นแบบจำลองที่ทันสมัยและเป็นที่รู้จักในด้านความสมดุลที่ยอดเยี่ยมระหว่างความเร็วและประสิทธิภาพ ทำให้เหมาะสมอย่างยิ่งสำหรับการใช้งานในภาคอุตสาหกรรม [4], [5] วิวัฒนาการจากเวอร์ชันก่อนหน้าเช่น YOLOv3 และ YOLOv4 ได้ผลักดันขอบเขตของการตรวจจับวัตถุแบบเรียลไทม์อย่างต่อเนื่อง ทำให้เป็นตัวเลือกหลักสำหรับการนำไปใช้ในอุตสาหกรรม [6], [7]

อย่างไรก็ตาม การนำแบบจำลองที่เป็นเสมือน "กล่องดำ" มาใช้ในงานที่มีความสำคัญสูงมักถูกขัดขวาง ด้วยการขาดความโปร่งใส [8] เพื่อแก้ไขปัญหานี้ งานวิจัยของเราจึงได้ผนวกเครื่องมือการของปัญญาประดิษฐ์ที่อธิบายได้ (XAI) เข้าไว้ด้วย แทนที่เราจะรายงานเพียงแค่ความแม่นยำในการตรวจจับ เราได้ตรวจสอบว่า แบบจำลองได้เรียนรู้อะไร โดยใช้เทคนิค Feature Visualization เราสามารถมองเข้าไปในโครงสร้างภายใน ของแบบจำลอง และสร้างภาพของคุณลักษณะ "ในอุดมคติ" ที่มันได้เรียนรู้ที่จะเชื่อมโยงกับข้อบกพร่องต่างๆ [9], [10] วิธีการนี้ให้ระดับความไว้วางใจและความเข้าใจที่ลึกซึ้งกว่าตัวชี้วัดประสิทธิภาพแบบเดิมเพียงอย่างเดียว

2.1. ชุดข้อมูลสำหรับงานวิจัย

โดยงานวิจัยนี้ใช้ชุดข้อมูลสาธารณะ DeepPCB [11] ที่ถูกออกแบบมาโดยเฉพาะสำหรับงานตรวจจับข้อบกพร่องบน PCB



รูปที่ 1. ตัวอย่างของชุดข้อมูลจาก Deep PCB ประกอบด้วยภาพที่สมบูรณ์ และภาพที่มี Defect ที่ต้องการตรวจจับความผิดปกติ

โดยชุดข้อมูลนี้ประกอบด้วยรูปภาพ 1,500 คู่ แต่ละคู่จะมีภาพต้นแบบที่สมบูรณ์และภาพทดสอบที่มีการระบุตำแหน่ง และชนิดของข้อบกพร่องไว้ 6 ประเภท ได้แก่ วงจรเปิด, การลัดวงจร, รอยกัด, ดึงโลหะ, ทองแดงส่วนเกิน และรูเข็ม โดยแต่ละภาพของเส้นลายวงจรจะมี Defect ที่หลากหลายและไม่ซ้ำกัน ซึ่งเป็นปัญหาจริงที่พบในการผลิต PCB โดยงานวิจัยนี้ได้แบ่งชุดข้อมูลตามที่ผู้สร้างกำหนดไว้ คือ 1,000 ภาพสำหรับฝึกสอน และ 500 ภาพสำหรับตรวจสอบความถูกต้อง เพื่อให้ผลลัพธ์สามารถนำไปเปรียบเทียบกับงานวิจัยอื่นๆที่ใช้ชุดข้อมูลเดียวกันได้ [12]

2.2.ระบบการตรวจจับข้อบกพร่อง

โดยระบบของงานวิจัยได้เลือกใช้แบบจำลอง YOLOv8n ซึ่งเป็นเวอร์ชันนาโนในตระกูล YOLOv8 เนื่องจากมีประสิทธิภาพสูงและใช้ทรัพยากรน้อย โดยแบบจำลองนี้ได้รับการฝึกสอนล่วงหน้าบนชุดข้อมูล COCO มาก่อนแล้ว หลังจากนั้นจึงนำมาปรับเข้ากับชุดข้อมูล DeepPCB เป็นจำนวน 50 epochs ซึ่งกระบวนการฝึกสอนจะทำการปรับปรุงฟังก์ชันความสูญเสียแบบผสมผสาน ซึ่งคำนึงถึงความผิดพลาดในการระบุกรอบวัตถุ เช่น CIOU loss, การจำแนกประเภท และคะแนนความน่าจะเป็นของการมีอยู่ของวัตถุ [13]

2.3.ตัวชี้วัดประสิทธิภาพ

เพื่อประเมินประสิทธิภาพของแบบจำลอง ผู้วิจัยได้ใช้ตัวชี้วัดมาตรฐานสำหรับการตรวจจับวัตถุ ได้แก่ Precision, Recall และ Mean Average Precision (MAP) โดยที่ค่า Mean Average Precision (MAP) เป็นตัวชี้วัดมาตรฐานสากลที่ใช้ประเมินประสิทธิภาพของแบบจำลองการตรวจจับวัตถุ (Object Detection) โดยให้ภาพรวมของความสามารถของแบบจำลองทั้งในด้านความแม่นยำ (Precision) และความครบถ้วนในการตรวจจับ (Recall) กระบวนการคำนวณ mAP ประกอบด้วย 4 ขั้นตอนหลักดังนี้


ขั้นตอนที่ 1: Intersection over Union (IoU)

ขั้นตอนแรกสุดคือการตัดสินใจว่ากรอบสี่เหลี่ยมที่ AI ทำนายมานั้นถูกต้อง โดยการเปรียบเทียบกับกรอบสี่เหลี่ยมของเฉลย (Ground Truth) เราจะใช้ค่าที่เรียกว่า Intersection over Union (IoU) เป็นการวัดระดับการซ้อนทับกันของกรอบทั้งสอง โดยที่ IoU คำนวณจากพื้นที่ส่วนที่ซ้อนทับกัน (Area of Overlap) หารด้วยพื้นที่ทั้งหมดของกรอบทั้งสองรวมกัน (Area of Union) ดังสมการที่ (1)

$$IoU = \frac{\text{Area of Overlap}}{\text{Area of Union}} \quad (1)$$

โดยที่ **Area of Overlap** คือพื้นที่ที่กรอบคาดการณ์ และกรอบจริงซ้อนทับกัน **Area of Union** คือพื้นที่รวมทั้งหมดของทั้งสองกรอบโดยไม่ซ้ำกัน

IoU (Intersection over Union) — PCB Defect Bounding Boxes



รูปที่ 2. ตัวอย่างการคำนวณค่า IoU ในการตรวจจับตำแหน่งความบกพร่องของ PCB

ขั้นตอนที่ 2: Precision และ Recall หลังจากใช้เกณฑ์ IoU แล้ว เราจะสามารถนับจำนวน True Positives (TP), False Positives (FP), และ False Negatives (FN) เพื่อนำมาคำนวณค่า Precision และ Recall โดย

Precision สะท้อนถึงสัดส่วนของการตรวจจับที่ถูกต้องในบรรดาการตรวจจับทั้งหมดที่แบบจำลองทำนายสามารถคำนวณได้ดังสมการที่ (2)

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2)$$

Recall บ่งชี้ถึงสัดส่วนของข้อบกพร่องจริงทั้งหมดที่แบบจำลองสามารถตรวจจับได้สำเร็จสามารถคำนวณได้ดังสมการที่ (3)

$$\text{Recall} = \frac{TP}{TP + FN} \quad (3)$$

โดยที่ TP คือ True Positives (ทายถูกว่าเป็น Defect), FP คือ False Positives (ทายผิดว่าเป็น Defect) และ FN คือ False Negatives (ทาย Defect ไม่เจอ)

ขั้นตอนที่ 3: Average Precision (AP)

โมเดลจะให้ค่าระดับความมั่นใจ (Confidence Score) ร่วมกับผลการทำนายแต่ละครั้ง เพื่อหาจุดสมดุลระหว่าง Precision และ Recall สามารถสร้างเส้นโค้ง Precision-Recall (PR Curve) ที่ความมั่นใจหลายระดับ และหาค่า Average Precision (AP) ซึ่งคือพื้นที่ใต้กราฟ PR Curve (สมการที่ 4) โดยคำนวณแยกสำหรับ defect แต่ละประเภท เช่น AP_{open} , AP_{short} , $AP_{mousebite}$ เป็นต้น

$$AP = \int_0^1 P(R) dR \quad (4)$$

ขั้นตอนที่ 4: Mean Average Precision (MAP)

ค่า Mean Average Precision (MAP) คือค่าเฉลี่ยของ AP จาก defect ทุกประเภท (สมการที่ 5) ซึ่งใช้เป็นตัวชี้วัดประสิทธิภาพรวมของโมเดล

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (5)$$


เช่น ค่า $mAP@0.50 = 96.8\%$ หมายถึง ค่าเฉลี่ยของ AP สำหรับ defect ทั้ง 6 ประเภท เมื่อใช้เกณฑ์ IoU > 0.5 เท่ากับ 96.8% แสดงให้เห็นว่าโมเดลมีประสิทธิภาพสูงในการตรวจจับ defect และจะสรุปค่ารวมของประสิทธิภาพของแบบจำลองในตัวเลขเดียว [13]

3. การทดลองและผลการทดลอง

ระบบการตรวจจับข้อผิดพลาดถูกฝึกสอนบน Google Colab โดยใช้ Tesla T4 GPU ในการประมวลผล เป็นการนำชุดข้อมูล Deep PCB มาทำการฝึกสอนและเขียนเป็นสคริปต์เดียวกันเพื่อรับประกันความสามารถในการทำซ้ำ

3.1 การวิเคราะห์กระบวนการฝึกสอน

ความคืบหน้าในการเรียนรู้ของแบบจำลองถูกติดตามตลอด 50 epochs โดยรูปที่ 1 แสดงเส้นโค้งค่าความผิดพลาด (loss curves) ของชุดข้อมูลฝึกสอนและชุดข้อมูลตรวจสอบความถูกต้อง ทั้งค่าความผิดพลาดของกรอบล้อมรอบ (box_loss) และค่าความผิดพลาดของการจำแนกประเภท (cls_loss) สำหรับข้อมูลทั้งชุดที่ผ่านการเรียนรู้จากระบบมีแนวโน้มของความผิดพลาดลดลงอย่างต่อเนื่องจนเข้าสู่สภาวะคงที่ ซึ่งแสดงให้เห็นว่าแบบจำลองได้เรียนรู้คุณลักษณะที่สามารถนำไปใช้กับข้อมูลใหม่ได้โดยไม่มีการเกิด Overfitting อย่างมีนัยสำคัญ และตัวชี้วัดสำหรับ precision, recall และ MAP ก็แสดงให้เห็นถึงแนวโน้มการปรับปรุงที่ดีขึ้นจนเข้าสู่สภาวะคงที่เช่นกัน




รูปที่ 3. ตัวชี้วัดระหว่างการฝึกสอนและตรวจสอบความถูกต้องตลอด 50 epochs แสดงค่าของ loss, precision, recall และ MAP

3.2. ประสิทธิภาพเชิงปริมาณ


หลังจากทำการฝึกสอน 50 epochs แบบจำลองก็ได้แสดงประสิทธิภาพที่ดีบนชุดข้อมูลตรวจสอบ ความถูกต้องโดยแบบจำลองสามารถทำค่าความแม่นยำเฉลี่ย ($mAP@.50$) ได้ถึง 96.8% ซึ่งบ่งชี้ถึงระดับความแม่นยำที่สูงมาก

ตารางการประเมินประสิทธิภาพของแบบจำลอง YOLOv8n


โดยเส้นโค้ง Precision-Recall (PR) ในรูปที่ 4 แสดงให้เห็นถึงประสิทธิภาพที่โดดเด่นของแบบจำลองเพิ่มเติม วัดได้จากพื้นที่ใต้เส้นโค้งสำหรับทุกตัวอย่างมีค่าสูง ซึ่งยืนยันความสามารถของแบบจำลองในการรักษาทั้งค่า precision และ recall ที่ค่อนข้างสูงในระดับความเชื่อมั่นที่แตกต่างกัน โดยจะเห็นว่าประสิทธิภาพในการตรวจจับมีความเข้าใจในทุกประเภทของข้อบกพร่อง เช่น short (0.914) , copper (0.982) และ pinhole (0.983)



รูปที่ 4. เส้นโค้ง Precision-Recall สำหรับทุกคลาสของข้อบกพร่อง ซึ่งได้ค่า mAP@0.5 โดยรวมที่ 0.968




เมทริกซ์ normalized confusion matrix ในรูปที่ 5 ให้รายละเอียดการจำแนกประเภทของแบบจำลองสำหรับ แต่ละชนิดของข้อบกพร่อง ค่าในแนวทแยงที่สูง (ส่วนใหญ่ ≥ 0.95) บ่งชี้ถึงความแม่นยำสูงสำหรับทุกคลาส พบความสัมพันธ์เล็กน้อยระหว่างข้อบกพร่องประเภท 'short' กับ 'background' (0.13) ซึ่งชี้ให้เห็นว่าข้อบกพร่องประเภท 'short' บางครั้งอาจมีลักษณะทางภาพที่ละเอียดอ่อนและแยกแยะได้ยากกว่า [14]




รูปที่ 5. เมทริกซ์แสดงประสิทธิภาพการจำแนกประเภทสำหรับแต่ละชนิดของข้อบกพร่อง

3.3.ผลลัพธ์เชิงคุณภาพและการในการอธิบายผล


เพื่อประเมินประสิทธิภาพของแบบจำลองในเชิงภาพ ได้มีการใช้ภาพตัวอย่างจากชุดข้อมูล ตรวจสอบความถูกต้องในการทำนาย รูปที่ 6.1 ถึง 6. แสดงให้เห็นว่าแบบจำลองสามารถระบุข้อบกพร่องหลายประเภทได้อย่างสำเร็จพร้อมคะแนนความเชื่อมั่น ที่ระบบให้ค่าไว้ตามความมั่นใจในการตรวจสอบ



รูปที่ 6.1 ตัวอย่างผลลัพธ์การตรวจจับข้อบกพร่องบนภาพทดสอบที่มี Defect หลายประเภท พบว่าโมเดลสามารถตรวจจับข้อผิดพลาดได้ครบทุกจุดและแยกประเภทของ Defect ได้ตรงตามประเภท




รูปที่ 6.2 ตัวอย่างผลลัพธ์การตรวจจับข้อบกพร่องบนภาพทดสอบที่มี Defect หลายประเภท และกระจายตัวจึงทำให้โมเดลตัดสินใจตรวจสอบและแยกประเภทได้อย่างมีประสิทธิภาพ



รูปที่ 6.3 ตัวอย่างผลลัพธ์การตรวจจับข้อบกพร่องบนภาพทดสอบที่มี Defect ขนาดเล็กและมีความไม่ชัดเจนว่ามีการแตะกันของเส้นวงจร (Short circuit) หรือไม่ทำให้ค่าความมั่นใจต่ำและต้องใช้ในการตรวจสอบด้วยสายตาอีกครั้งจึงจะสามารถตัดสินใจได้ว่าเป็น Defect หรือไม่



รูปที่ 6.4 ตัวอย่างผลลัพธ์การตรวจจับข้อบกพร่องบนภาพทดสอบที่มี Defect ที่เกิดใกล้กัน หรือชิดติดกันทำให้โมเดลมีความมั่นใจต่ำและต้องใช้ในการตรวจสอบด้วยสายตาอีกครั้งจึงจะสามารถตัดสินใจได้ว่าเป็น Defect หรือไม่



รูปที่ 6.5 ตัวอย่างผลลัพธ์การตรวจจับข้อบกพร่องบนภาพทดสอบที่มี Defect ที่เกิดขึ้นแบบไม่ชัดเจน เช่นเส้นวงจรที่บางและยากในการตัดสินใจว่าเป็น Defect แบบ Open หรือไม่ทำให้โมเดลมีความมั่นใจต่ำและต้องใช้ในการตรวจสอบด้วยสายตาอีกครั้งจึงจะสามารถตัดสินใจได้ว่าเป็น Defect หรือไม่

เพื่อตีความการเรียนรู้ภายในของแบบจำลอง ได้มีการใช้เทคนิค Feature Visualization โดยเทคนิค XAI นี้จะสร้างภาพสังเคราะห์ที่สามารถกระตุ้นเซลล์ประสาท (Channel) เฉพาะทางในชั้นที่เลือกของโครงข่ายได้สูงสุด [14] โดยรูปที่ 5 แสดงรูปแบบภาพแบบอุดมคติ ที่เรียนรู้โดย Channel ที่แตกต่างกันสี่ตัวในชั้น SPPF ของแบบจำลอง โดยภาพเหล่านี้แสดงให้เห็น

ว่าแบบจำลองได้พัฒนา ตัวตรวจจับที่มีคุณลักษณะเฉพาะทางขึ้นมา ตัวอย่างเช่น บาง Channel ตอบสนองต่อโครงสร้างคล้ายขอบ (Channel 50) ในขณะที่บาง Channel ถูกปรับให้ตรวจจับรูปแบบคล้ายจุดหรือพื้นผิว (Channel 150) สิ่งนี้เป็นเครื่องยืนยันว่าแบบจำลองกำลังเรียนรู้คุณลักษณะเชิงลำดับชั้นที่เกี่ยวข้องกับองค์ประกอบของ PCB แทนที่จะอาศัยความสัมพันธ์ที่ไม่มีเหตุผล [15], [16]

4.สรุป

รูปที่ 7. การแสดงภาพคุณลักษณะของ 4 Channel ที่แตกต่างกัน เผยให้เห็นรูปแบบนามธรรมที่แบบจำลองได้เรียนรู้ที่จะตรวจจับ ตัวอย่างเช่น Channel 50 และ Channel 150 ตอบสนองต่อโครงสร้างคล้ายขอบและเส้น ซึ่งเป็นองค์ประกอบสำคัญบนแผ่นวงจรพิมพ์ ในขณะที่ Channel 10 และ Channel 100 แสดงการตอบสนองต่อรูปแบบพื้นผิว (texture) หรือกลุ่มก้อนที่ซับซ้อน ซึ่งบ่งชี้ว่าแบบจำลองได้พัฒนาตัวตรวจจับคุณลักษณะเชิงลำดับชั้นที่หลากหลาย

งานวิจัยนี้ได้นำเสนอการพัฒนาประสิทธิภาพ ของระบบการตรวจจับข้อบกพร่องบน PCB ด้วยระบบอัตโนมัติ โดยใช้แบบจำลอง YOLOv8n ที่มีความสามารถตรวจจับด้วยความแม่นยำสูงถึง 96.8% (mAP@.50) และ

การผสมผสานเทคนิค Feature Visualization ด้วยการอธิบายแบบ XAI ซึ่งให้ข้อมูลเชิงลึกเกี่ยวกับการเรียนรู้คุณลักษณะภายในของแบบจำลอง ช่วยเพิ่มความน่าเชื่อถือและนำไปสู่การนำเสนอ แนวทางแก้ไขปัญหามีประสิทธิภาพ และสามารถวิเคราะห์ปัญหาพร้อมทั้งอธิบายข้อผิดพลาดที่เกิดขึ้นได้เหมาะสำหรับการนำไปใช้ในขั้นตอนการผลิต และการควบคุมคุณภาพในงานอุตสาหกรรม โดยการวิจัยในอนาคตจะสามารถมุ่งเน้นไปที่การเปรียบเทียบ ประสิทธิภาพของแบบจำลองอื่นๆ และการขยายชุดข้อมูลฝึกสอนด้วยข้อมูล จากการผลิตจริงเพื่อประยุกต์ และเพิ่มขีดความสามารถของระบบการตรวจจับต่อไป

5.กิตติกรรมประกาศ

ผู้วิจัยขอแสดงความขอบคุณ รอง ศจ.ดร.เปี่ยมภูมิ สฤกพฤกษ์ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบังที่ให้คำแนะนำ และข้อเสนอแนะที่เป็นประโยชน์ประกอบการทำวิจัย และ คณะผู้จัดทำชุดข้อมูล Deep PCB โดยทีมวิจัยจาก Southern University of science and Technology (SUSTech), Shenzhen, China

เอกสารอ้างอิง

[1] Q. Ling and N. A. M. Isa, "Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey," *IEEE Access*, vol. 11, pp. 15921-15944, 2023, doi: 10.1109/ACCESS.2023.3245093.

[2] M. Moganti, F. Ercal, C. H. Dagli, and S. Tsunekawa, "Automatic PCB inspection algorithms: A survey," *Computer Vision and Image Understanding*, vol. 63, no. 2, pp. 287-313, Mar. 1996, doi: 10.1006/cviu.1996.0020.

[3] A. F. M. Hani, A. S. Malik, R. Kamil, and C.-M. Thong, "A review of SMD-PCB defects and detection algorithms," in *Proc. SPIE*, vol. 8350, pp. 373-379, Jan. 2012, doi: 10.1117/12.920531

[4] G. Jocher, A. Chaurasia, and J. Qiu, *YOLO by Ultralytics*, 2023. [Online]. Available: <https://github.com/ultralytics/ultralytics>

[5] Z.-Q. Zhao, P. Zheng, S.-T. Xu, and X. Wu, "Object detection with deep learning: A review," *IEEE Trans. Neural*

Netw. Learn. Syst., vol. 30, no. 11, pp. 3212-3232, Nov. 2019, doi: 10.1109/TNNLS.2018.2876865.

[6] J. Redmon and A. Farhadi, "YOLOv3: An incremental improvement," 2018, arXiv:1804.02767.

[7] A. Bochkovskiy, C.-Y. Wang, and H.-Y. M. Liao, "YOLOv4: Optimal speed and accuracy of object detection," 2020, arXiv:2004.10934.

[8] R. Guidotti, A. Monreale, S. Ruggieri, F. Turini, F. Giannotti, and D. Pedreschi, "A survey of methods for explaining black box models," *ACM Comput. Surv.*, vol. 51, no. 5, pp. 1-42, Aug. 2018, doi: 10.1145/3236009.

[9] C. Olah, A. Mordvintsev, and L. Schubert, "Feature Visualization," *Distill*, 2017. [Online]. Available: <https://distill.pub/2017/feature-visualization/>

[10] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: Visual explanations from deep networks via gradient-based localization," in *Proc. IEEE Int. Conf. Comput. Vis. (ICCV)*, 2017, pp. 618-626, doi: 10.1109/ICCV.2017.74.

[11] T. Adib, S. S. Shomaji, and S. M. H. Hasheminejad, "Deep-PCB: A new dataset for developing deep learning-based approaches for printed circuit board defect detection," *Journal of Intelligent & Fuzzy Systems*, vol. 41, no. 5, pp. 5629-5641, 2021, doi: 10.3233/JIFS-210190.

[12] R. Ding, L. Dai, G. Li, and H. Liu, "TDD-Net: A tiny defect detection network for printed circuit boards," *CAAI Trans. Intell. Technol.*, vol. 4, no. 2, pp. 110-116, Jun. 2019, doi: 10.1049/trit.2019.0019.

[13] M. Everingham, L. Van Gool, C. K. I. Williams, J. Winn, and A. Zisserman, "The PASCAL visual object classes (VOC) challenge," *Int. J. Comput. Vis.*, vol. 88, no. 2, pp. 303-338, Jun. 2010, doi: 10.1007/s11263-009-0275-4.

[14] B. Hu and J. Wang, "Detection of PCB surface defects with improved faster-RCNN and feature pyramid network," *IEEE Access*, vol. 8, pp. 108335-108345, 2020, doi: 10.1109/ACCESS.2020.3001349.

[15] A. Saadallah, J. Büscher, O. Abdulaaty, T. Panusch, J. Deuse, and K. Morik, "Explainable Predictive Quality Inspection using Deep Learning in Electronics Manufacturing," *Procedia CIRP*, vol. 107, pp. 594-599, 2022, doi: 10.1016/j.procir.2022.05.031.

[16] X. Chen, Y. Wu, X. He, and W. Ming, "A Comprehensive Review of Deep Learning-Based PCB Defect Detection," *IEEE Access*, vol. 11, pp. 139017-139038, 2023, doi: 10.1109/ACCESS.2023.3339561.