

基于改进 YOLOv8 模型的 PCB 缺陷检测算法^{*}

熊 伟^{1,2} 黄玉谦¹ 彭鑫旭¹

(1. 湖北工业大学电气与电子工程学院 武汉 430068; 2. 美国南卡罗来纳大学计算机科学与工程系 南卡罗来纳州 29201)

摘 要: 针对现有 PCB 缺陷检测方法存在漏检率高、泛化性差且难以兼顾检测精度和速度的平衡问题,本文提出了一种基于改进 YOLOv8n 模型的 PCB 缺陷检测算法 YOLOv8-CSM。首先,在主干网络末尾添加一个 CoordAtt 注意力模块,抑制复杂背景对 PCB 缺陷区域的影响以提高模型的检测精度;其次,在检测头中引入 3 个 SEAM 模块扩大模型感受野,提高模型对微小缺陷的识别的能力以降低漏检率;最后,使用 MPDIoU 替代传统的 CIoU 损失,优化边界框的回归效果并提高模型的收敛速度。实验数据表明,YOLOv8-CSM 能更好的兼顾检测精度与速度的平衡且泛化性更强,与基础模型相比 Recall、Precision、mAP50、FPS 分别提高了 4.3%、1.8%、2.7%、42.76,显著提高了模型在 PCB 缺陷检测任务中的性能。

关键词: YOLOv8;注意力机制;SEAM 模块;MPDIoU;PCB 缺陷检测

中图分类号: TP391.4; TN41 **文献标识码:** A **国家标准学科分类代码:** 520.6040

PCB defect detection model based on improved YOLOv8 algorithm

Xiong Wei^{1,2} Huang Yuqian¹ Peng Xinxu¹

(1. School of Electrical and Electronic Engineering, Hubei University of Technology, Wuhan 430068, China;

2. Department of Computer Science and Engineering, University of South Carolina, South Carolina 29201, USA)

Abstract: To address the existing PCB defect detection methods with high miss detection rate, poor generalisation and difficulty in balancing detection accuracy and speed, this paper proposes a PCB defect detection algorithm YOLOv8-CSM based on the improved YOLOv8n model. Firstly, a CoordAttention module is added at the end of the backbone network, which suppresses the influence of the complex background on the defective region of the PCB in order to improve the model's detection accuracy; second, three SEAM modules are referenced in the detection header to expand the model receptive field and improve the model's ability to identify small defects to reduce the miss detection rate; finally, MPDIoU is used to replace the traditional CIoU loss to optimise the regression effect of the bounding box and improve the convergence speed of the model. The experimental data show that YOLOv8-CSM can better balance detection accuracy and speed, and it is more generalizable. Compared with the base model, the Recall, Precision, mAP50 and FPS are improved by 4.3%, 1.8%, 2.7% and 42.76, respectively, which significantly enhances the model's performance in PCB defect detection tasks.

Keywords: YOLOv8; attention mechanism; SEAM module; MPDIoU; PCB defect detection

0 引 言

随着电子制造业的快速发展,人们对电子产品质量的要求越来越高^[1]。印刷电路板(printed circuit board, PCB)作为所有电子产品的基础和核心,为各类电子设备提供硬件支持和线路连接,其设计构造越来越精密化,导致 PCB 的制作过程变得十分复杂^[2]。在制造或储存 PCB 的过程中非常容易出现开路、短路、毛刺、鼠咬等微小缺陷^[3]。因此,为了确保电子产品质量的可靠性,在出厂前对 PCB

进行缺陷检测变得尤为重要。

传统的 PCB 缺陷检测主要采用人工目视和电气检测的方法^[4],但这两种检测方法的成本很高且容易受到外界因素影响导致 PCB 的检测效率低下,很难进行大批量的工业化生产。近年来,随着深度学习技术的快速发展,许多学者都尝试将其应用于 PCB 缺陷检测领域,以弥补传统缺陷检测方法的局限性^[5]。例如,陈仁祥等^[6]提出了一种基于多注意力(faster region-based convolutional neural network, Faster RCNN)的印刷电路板缺陷检测方法,在特

收稿日期:2025-02-18

^{*} 基金项目:国家自然科学基金(62202148)、国家留学基金(201808420418)、湖北省自然科学基金(2019CFB530)、湖北省科技厅重大专项(2019ZYYD020)项目资助

征提取和特征融合部分引入注意力机制以增强模型的抗干扰能力。Du 等^[7]提出了一种增强型网络 YOLO-MBBi 来检测 PCB 上的表面缺陷,在 YOLOv5 网络中添加了(convolutional block attention module, CBAM)注意力模块,并使用 SIoU 替换 CIoU,提升了模型的检测精度和速度。Tang 等^[8]引入 EIOU 以替换原始的损失函数,优化了预测框与检测框的回归过程提高了模型对小目标的定位能力。Lan 等^[9]提出一种改进 YOLOv8 模型的 PCB 缺陷检测算法,在骨干网和颈部网络之间增加了一个跨尺度融合模块,加强了颈部网络的特征融合和交互的能力,从而提升了模型的检测性能。严舒等^[10]提出了一种基于特征增强和多尺度融合的 PCB 缺陷检测算法,在特征提取网络中引入上下文注意力模块,有效解决了目标与背景相混淆的问题。Shi 等^[11]提出了一种 DVCW-YOLO 的新型 PCB 缺陷检测算法,在骨干网络中引入了自主设计的 C2fCBAM 模块用于提取特征,并使用 WIoU 损失函数替代传统的 CIoU 损失,解决了模型泛化能力低和检测速度慢的问题。

虽然上述学者为 PCB 缺陷检测领域做出了重要贡献,但现有方法在面对复杂工业场景时仍存在一定的局限性,随着电子工业的快速发展,出现了一些新型的缺陷类型,如细微的划痕和针孔缺陷,这对 PCB 缺陷检测算法提出了更高的检测要求,然而现有方法通常只能针对特定的缺陷类型进行检测,在面对这些新型缺陷时,可能存在漏检或不合理的扩展现象。因此,PCB 缺陷检测领域仍面临巨大挑战,尤其是在小目标缺陷的快速识别与定位方面。基于此,本文提出一种改进 YOLOv8n 算法的 PCB 缺陷检测模型 YOLOv8-CSM。首先,在 YOLOv8n 的主干网络末尾添加一个 CoordAtt 模块^[12],帮助模型更准确地定位 PCB 上的细微缺陷,以提高模型的检测精度;其次,为了解决 PCB 中各类缺陷目标相互遮挡的问题,在检测头中添加 3 个(spatially enhanced attention module, SEAM)模块^[13]以扩大模型感受野,提高模型对微小缺陷的识别能力;最后,将默认的 CIoU 损失替换为 MPDIoU^[14],提高模型在回归任务中的精度,同时加快模型的收敛速度。

1 YOLOv8 概述

YOLOv8 是由 Ultralytics 公司创建和维护的新型目标检测模型,凭借其在检测精度和速度方面的优异表现,现已成为目标检测领域的热门选择。YOLOv8 系列包括 5 个版本:YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l 和 YOLOv8x,以满足各种应用场景的需求。由于 YOLOv8n 模型结构紧凑,资源利用率高且运行速度快,适合小目标检测,所以本文选择以 YOLOv8n 作为基线模型。

YOLOv8n 网络由主干网络(Backbone)、特征增强网络(Neck)和检测头(Head)三部分构成。主干网络主要负责提取输入图像的多尺度特征,通过引入 C2f 模块,能够丰富梯度信息,提升模型对目标细节的捕捉能力。特征增强

网络负责融合来自不同尺度的特征信息,采用 PANet 结构以实现自上而下和自下而上的双向特征融合^[15],增强模型对不同尺度目标的检测效果。检测头采用解耦设计,将分类与边界框回归任务分离,以加快模型收敛并提高边界框的回归精度。

虽然 YOLOv8n 算法是当前最先进的目标检测算法之一,然而其未对 PCB 缺陷的复杂特征做专门优化,因此如果直接将其用于 PCB 的缺陷检测任务会存在诸多问题。首先,由于 PCB 的缺陷区域和背景融为一体且极为相似,导致模型很难准确定位 PCB 上的细微缺陷;其次,PCB 表面的电路布局非常复杂且待检测的缺陷类型众多,容易产生类遮挡问题,导致模型的漏检问题严重;最后,由于原始 YOLOv8n 算法的 CIoU 损失在复杂场景中存在收敛速度慢、对特定目标形状和位置不够敏感等问题,导致模型的检测精度和速度受到了一定的限制。因此对 YOLOv8n 模型改进是非常有必要的。

2 改进 YOLOv8n 模型

2.1 改进的 YOLOv8-CSM 模型

针对 YOLOv8n 算法在 PCB 缺陷检测任务中的不足,本文提出了一种改进的 YOLOv8-CSM 模型,它结合了 3 种关键的改进技术,其中 CSM 代表 CoordAtt-SEAM-MPDIoU。模型框架如图 1 所示。首先,在主干网络末尾添加一个 CoordAtt 注意力模块,抑制复杂背景对 PCB 缺陷区域的影响,增强模型对 PCB 缺陷部位的特征表达能力。其次,在检测头中添加 3 个 SEAM 模块,扩大模型感受野以解决 PCB 中各类缺陷相互遮挡的问题,减少模型的漏检率。最后,将原始 YOLOv8n 算法的 CIoU 损失替换为 MPDIoU,优化 IoU 的计算方式,使模型能更快速准确的定位 PCB 上的细微缺陷,进一步提高模型的检测性能。

2.2 CoordAtt 注意力模块

注意力机制在深度学习中发挥着关键作用,其核心思想是动态地分配不同的权重给输入的不同部分,增强神经网络对关键特征的关注能力,从而提升对输入数据的理解和表达。在 PCB 缺陷检测中,由于缺陷区域通常较小且与背景融合,导致模型难以准确定位细微缺陷,为了解决这一问题,本文在 PCB 缺陷检测算法中引入了坐标注意力机制(coordinate attention, CA),CA 模块结构如图 2 所示。

CA 是一种轻量级且高效的注意力机制,它通过结合各个通道间的关联信息和不同空间的位置信息以提升模型对关键特征区域的聚焦能力。首先将输入特征图分别沿水平和垂直方向进行全局池化操作,生成水平和垂直两个方向的特征图,其中水平池化提取宽度方向的信息,垂直池化提取高度方向的信息,再将两个方向的特征图拼接在一起进行卷积操作得到一个具有方向感知的新特征图,随后经过批量归一化(BatchNorm)和非线性激活函数(Non-linear)

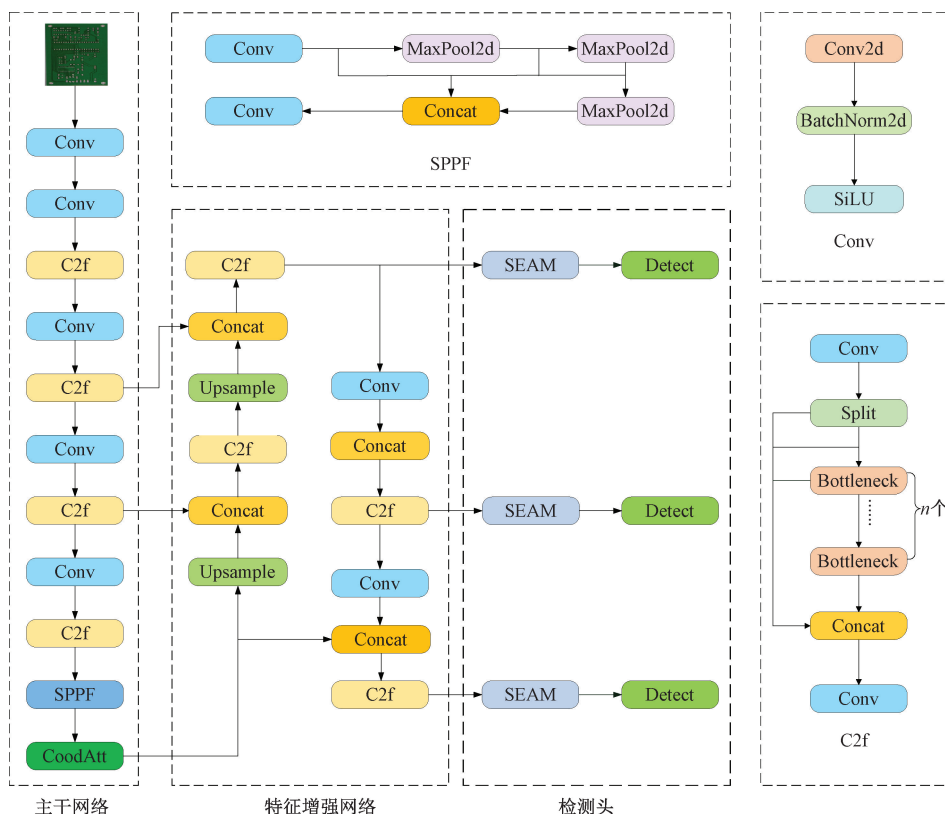


图 1 YOLOv8-CSM 网络结构

Fig. 1 YOLOv8-CSM network structure

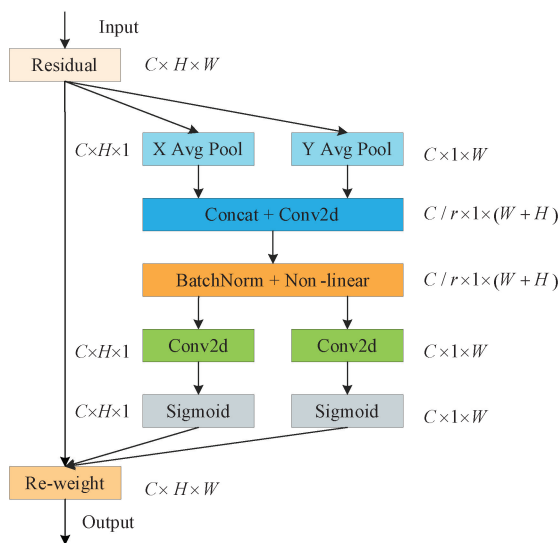


图 2 CA 注意力机制结构

Fig. 2 Structure diagram of CA mechanism

网络模型更加专注于 PCB 缺陷区域,同时抑制不相关的背景信息,提升模型对 PCB 缺陷的检测能力。

2.3 SEAM 模块

在 PCB 缺陷检测任务中,由于 PCB 表面的电路布局非常复杂且待检测的缺陷类型众多,各类缺陷之间会相互遮挡,造成局部信息混叠和一些细粒度信息的丢失,进而导致模型漏检率上升。为了解决这一问题,本文决定在 YOLOv8n 模型的基础上再引入 3 个 SEAM 模块以解决类遮挡问题,提高模型对微小缺陷的识别能力。SEAM 模块结构如图 3 所示。

SEAM 模块由两部分构成,第一部分采用了深度可分离卷积,这种卷积以逐通道的方式进行,可以有效减少参数量并学习各个通道的重要特征,然而,深度可分离卷积可能会忽略各个通道之间的关联信息,为了弥补这一不足,在 SEAM 模块的基础上进一步引入残差连接,确保通道之间的信息可以充分交互,避免了重要信息的丢失,在卷积操作之后,SEAM 模块继续引入一个两层全连接网络,聚合来自不同通道的信息,以增强各个通道之间的关联性,确保模型在面对复杂 PCB 缺陷场景时,依然能保持较高的检测精度。第二部分是对全连接网络的输出结果进行指数归一化处理,将输出值从 $[0,1]$ 扩展到 $[1,e]$,其目的是增强模型对位置信息的鲁棒性,最后,将 SEAM 模块的输出作为注意力权重与原始特征图相乘,使模型能更加

提高模型对特征图的表达能力和泛化能力,此时的特征图会再经过一系列的卷积生成水平方向和垂直方向的两个注意力权重,并通过 Sigmoid 激活函数进行归一化处理,最后生成的注意力权重会应用于原始特征图中,对不同空间位置及通道的重要性进行重新加权。这一加权过程使得

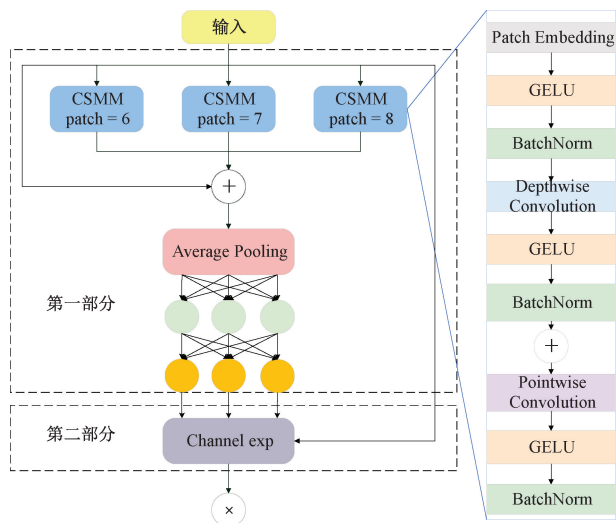


图 3 SEAM 模块结构

Fig. 3 SEAM module structure

准确的聚焦于被遮挡的缺陷区域,使模型能更好地处理由于类遮挡导致重要特征丢失的问题,从而进一步提升模型的检测性能。

2.4 损失函数改进

YOLOv8n 网络模型的损失函数主要由两部分组成,分别是分类损失和回归损失,分类损失用于评估模型预测 PCB 缺陷类型的准确性,而回归损失用于衡量模型预测 PCB 缺陷边界框位置的精度。其中 YOLOv8n 网络模型采用的回归损失是 CIoU,CIoU 示意图如图 4 所示。




图 4 CIoU 示意图

Fig. 4 Schematic diagram of CIoU

A 表示真实框,B 表示预测框,C 表示能同时容纳真实框和预测框的最小外接矩形,D 为 A 与 B 的交集,A 的中心点为 b_{gt} ,宽为 w_{gt} ,高为 h_{gt} ,B 的中心点为 b ,宽为 w ,高为 h ,C 的宽和高分别为 W_g 和 H_g ,CIoU 损失函数计算公式如下:

$$CIoU = IoU - \frac{\rho^2(b, b_{gt})}{c^2} - \alpha v \quad (1)$$

$$IoU = \frac{A \cap B}{A \cup B} \quad (2)$$

$$\alpha = \frac{\nu}{1 - IoU + \nu} \quad (3)$$

$$\nu = \frac{4}{\pi^2} (\arctan \frac{w_{gt}}{h_{gt}} - \arctan \frac{w}{h})^2 \quad (4)$$

$$LOSS_{CIoU} = 1 - IoU + \frac{\rho^2(b, b_{gt})}{c^2} + \alpha v \quad (5)$$

其中, $\rho(b, b_{gt})$ 表示两个中心点之间的欧氏距离, c 表示 C 的对角线长度, α 表示权重系数, ν 表示预测框与真实框之间宽高比的相似度。CIoU 损失考虑了边界框的重叠面积、中心点的距离以及宽高比的相似性,使得模型能较为全面的反映预测框和真实框之间的差异。然而在面对复杂场景时,CIoU 损失仍然存在以下不足:首先,CIoU 损失中用于衡量预测框与真实框之间宽高比相似性的参数 ν 是一个相对值,并不能真实反映预测框与真实框之间宽度和高度的实际关系,导致模型检测精度受限,无法准确优化预测结果;其次,CIoU 损失的计算复杂度较高,导致模型收敛速度较慢;最后,CIoU 损失会优先考虑减少两个中心点之间的距离,容易忽视边界框尺寸的大小,造成预测框不合理的扩展,进而导致模型检测结果不准确。

基于此,本文提出将 MPDIoU 作为 YOLOv8n 算法的回归损失,替换原有的 CIoU 损失以弥补 CIoU 损失的不足,MPDIoU 损失函数计算公式如下:

$$MPDIoU = IoU - \frac{d_1^2}{h^2 + w^2} - \frac{d_2^2}{h^2 + w^2} \quad (6)$$

$$LOSS_{MPDIoU} = 1 - IoU + \frac{d_1^2}{h^2 + w^2} + \frac{d_2^2}{h^2 + w^2} \quad (7)$$

式中: IoU 表示预测框与真实框面积的交并比, d_1 表示预测框与真实框左上角之间的距离, d_2 表示表示预测框与真实框右下角之间的距离, w 和 h 分别表示输入图片的宽和高。MPDIoU 损失全面考虑了现有损失函数中的各种相关因素,它基于最小点距离来衡量边界框的相似度,通过最小化预测框与真实框之间关键点的距离来计算回归损失,与其他传统损失函数相比,MPDIoU 损失不仅简化了边界框相似性的比较,还优化了边界框的定位和尺寸精度,从而提高了模型在 PCB 缺陷检测任务中的检测性能。

3 实验结果及分析

3.1 实验环境及参数配置

为了确保本次实验数据的可靠性与可重复性,所有的消融实验和对比实验均在相同的计算环境中完成。本次实验使用的计算机操作系统为 Windows 10,配备 NVIDIA GeForce RTX 3060 Ti GPU 及 Intel Core i7-10700k 处理器,主频为 2.90 GHz。实验环境方面,采用了 CUDA 12.2 版本,Python 3.11.5,深度学习框架使用了 Pytorch 2.0.0。输入图像尺寸统一为 640×640 ,模型训练的初始学习率设定为 0.01,batch size 为 32,训练周期为 600 轮。

3.2 评价指标

在目标检测领域,模型的性能通常会用多个评价指标

来去衡量,考虑到实际工业生产场景中,检测精度和速度是工业厂商最为关注的关键因素,直接影响 PCB 产品的生产效率 and 产品质量,因此,本文选取了查准率(Precision)、召回率(Recall)、平均类别精度(mean average precision, mAP)以及每秒帧数(frames per second, FPS)作为核心评价指标,以更全面地反映模型在工业应用中的实际性能,具体的计算公式如下:

$$Precision = \frac{TP}{TP + FN} \times 100\% \quad (8)$$

$$Recall = \frac{TP}{TP + FP} \times 100\% \quad (9)$$

$$AP = \int_0^1 P(R) dR \quad (10)$$

$$mAP = \frac{\sum_{i=0}^n AP(i)}{n} \quad (11)$$

$$FPS = \frac{1}{t_{avg}} \quad (12)$$

式中: TP 和 FP 分别表示正确检测和错误检测 PCB 缺陷类别的数量,而 FN 表示未被检测的数量,查全率(Precision)表示模型检测到的 PCB 缺陷中有多少是实际存在的缺陷,召回率(Recall)表示实际存在的 PCB 缺陷中有多少被模型成功检测出来。mAP 是综合性的精度评价指标,表示 n 个类别的平均检测精度。 t_{avg} 表示平均检测一张图片所花费的时间,FPS 表示每秒处理图片的帧数,反映了模型的实时检测能力。

3.3 数据集构建

现有常见的公开数据集中,2019 年北京大学发布的(Tiny Defect Detection Printed Circuit Board, TDD_PCB)数据集是 PCB 缺陷检测领域的重要基准数据集^[16]。TDD_PCB 数据集包含 693 张原始图片,分辨率为 $2\,777 \times 2\,138$,涵盖了 6 种缺陷类别,分别为缺孔、鼠咬、开路、短路、毛刺和杂铜。该数据集为 PCB 缺陷检测领域提供了重要的研究基础,并在很大程度上推动了 PCB 缺陷检测算法的发展。然而,该数据集也存在一些局限性:首先,其图像分辨率较高,虽然有助于捕获更丰富的细节信息,但也会显著增加模型的计算负担,导致训练速度变慢;其次,样本数量有限,难以满足深度学习模型对大规模数据的需求,可能导致模型在训练过程中出现过拟合现象,影响模型的泛化能力;此外,该数据集的缺陷类别覆盖不全面,仅涵盖 6 类缺陷,缺乏针孔和划痕等工业场景中常见的缺陷类型,这严重限制了模型的泛化能力和实际应用价值。

为了解决上述问题,本文自主构建了一个更全面、更具代表性的 PCB 缺陷检测数据集,涵盖了 8 种常见类别,分别为假铜(false copper)、缺孔(missing hole)、鼠咬(mouse bite)、开路(open circuit)、针孔(pin hole)、划痕(scratch)、短路(short circuit)和毛刺(spur)等类别,共计 3 725 张图片,分辨率均统一为 640×640 。考虑到数据集

规模较小可能导致模型过拟合,本文采用了多种数据增强方法包括随机旋转、饱和度调整、上下翻转、平移和镜像等操作,将数据集扩充至 9 669 张图片,以提高模型的泛化能力。此外,使用 Labelme 标注工具对数据集进行精确标注,并统计各类缺陷标签数量,其分布如图 5 所示,最后,将数据集按照 7:2:1 的比例随机划分为训练集、验证集和测试集。




图 5 各类缺陷数量

Fig. 5 Number of defects in each category

相比于 TDD_PCB 数据集,本文构建的数据集在缺陷类别和数据规模上更具优势,能更全面地覆盖工业场景中的常见缺陷,尤其是针孔和划痕等新型缺陷目标,这为 PCB 缺陷检测模型在实际工业场景中的应用提供了更可靠的测试环境,同时也为模型的性能提升和实际部署奠定了重要基础。

3.4 消融实验

为了验证本文所提算法在 PCB 缺陷检测任务中的有效性,并探究各个改进点对原网络模型的独立贡献,本文决定在原网络模型的基础上逐一添加改进点,进行消融实验。实验数据如表 1 所示,表中“√”表示在网络中添加了该改进点。

实验 1 表示原始 YOLOv8n 模型的实验结果,是与其他模型比较的基准。

实验 2 是在实验 1 的基础上添了加一个 CA 模块,使得基础模型的 Recall、Precision、mAP50 分别提高了 2.1%、0.4%、1.2%,说明 CA 模块可以有效抑制复杂背景对 PCB 缺陷区域的影响以提高模型的检测精度,尽管向基础模型中添加了新的 CA 模块会导致模型参数量有所增加,但是 FPS 仍有所提升,说明 CA 注意力模块确实可以优化模型的特征提取过程,减少对冗余区域的计算,一定程度上抵消了模块引入带来的额外计算开销,提高了模型的检测效率。

实验 3 是在实验 1 的基础上引入了 SEAM 模块,基础模型的 Recall 和 mAP50 分别提高了 2.7% 和 1%,由表 1 中数据可知,该模块使基础模型的 Recall 提升最为显著,

表 1 消融实验比较
Table 1 Ablation experimental

实验	CA	SEAM	MPDIoU	Recall/%	Precision/%	mAP50/%	FPS
1				90.0	93.2	94.0	298.26
2	✓			92.1	93.6	95.2	307.67
3		✓		92.7	93.3	95.0	278.14
4			✓	92.2	93.9	95.6	362.54
5		✓	✓	94.9	94.0	95.7	322.65
6	✓		✓	93.1	94.2	96.2	332.53
7	✓	✓	✓	94.3	95.0	96.7	341.02

说明 SEAM 模块可以有效解决 PCB 中各类缺陷相互遮挡导致重要特征丢失的问题,减少了模型的漏检率。

实验 4 表示将原网络模型中的 CIoU 替换为 MPDIoU,基础模型的 Recall、Precision、mAP50 分别提高了 2.2%、0.7%、1.6%,同时 FPS 大幅增加至 362.54。为了更直观地体现 MPDIoU 损失函数的优越性,本文决定在原网络模型的基础上再引入 EIoU^[17]和 WIoU^[18]两种损失函数进行对比实验,迭代次数设置为 600 轮。在对比各类损失函数的 mAP50 曲线时发现,前 100 轮的 mAP50 曲线较为接近,难以有效区分各类损失函数的性能,因此决定重点展示 100 轮以后的 mAP50 曲线,如图 6 所示,从图中可以清晰的看到 MPDIoU 损失函数的 mAP50 值明显高于其他损失函数且收敛速度更快,说明 MPDIoU 损失函数不仅可以更全面的反映预测框与真实框之间的差异以优化边界框回归,还能简化计算提高模型的检测效率。

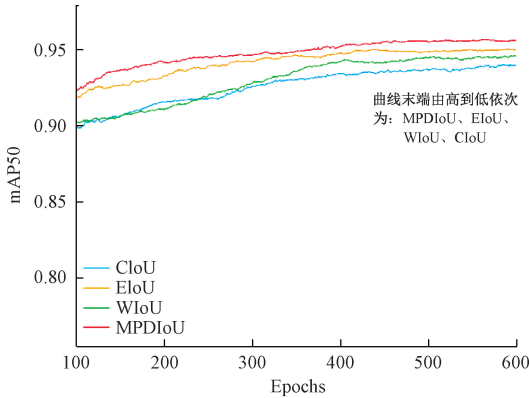


图 6 不同损失函数下的 mAP50 数据曲线

Fig. 6 Data curves of mAP50 with different loss functions

实验 5 是在实验 4 的基础上接着引入了 SEAM 模块,与基础模型相比 Recall、Precision、mAP50 分别提高了 4.9%、0.8%、1.7%,FPS 也提高了 24.39,这种组合使得基础模型的 Recall 提升最多,说明该组合在减少模型漏检率方面最有效。

实验 6 是在实验 4 的基础上再引入一个 CA 模块,与基础模型相比 Recall、Precision、mAP50 分别提高了 3.1%、1%、2.2%,FPS 提高了 34.27,说明 CA 模块可以有效增强

模型对重要特征的关注能力,MPDIoU 弥补了 CIoU 损失的不足,该组合进一步增强了模型的综合检测性能。

实验 7 综合应用了所有的改进点,与基础模型相比 Recall、Precision、mAP50 分别提高了 4.3%、1.8%、2.7%,FPS 也提高了 42.76,这不仅进一步验证了各个改进点的有效性,还证明了这些改进点在联合应用时,兼顾了检测精度和速度的平衡,可以最大限度的提升模型在 PCB 缺陷检测任务中的综合性能。

3.5 对比实验

为了更全面地评估和验证本文所提算法的有效性和优越性,本文在相同的实验环境下,将改进后的算法与多种现阶段常用的目标检测算法进行对比实验,具体对比算法包括:YOLOv3-tiny、YOLOv5n、YOLO-MBBi、PCB-YOLO、YOLOv7-tiny 以及 YOLOv8n。其中,YOLO-MBBi 和 PCB-YOLO 是近年来发表在高水平 SCI 期刊上的改进 YOLO 算法,在 PCB 缺陷检测领域具有较高的认可度和代表性,而 YOLOv3-tiny、YOLOv5n、YOLOv7-tiny 和 YOLOv8n 则是 YOLO 系列中的经典模型,通过将这些经典模型纳入对比实验,能够更全面地展示本文算法在检测精度和检测速度上的优势,各个算法在 PCB 缺陷检测任务中的性能数据如表 2 所示。

表 2 对比实验结果
Table 2 Comparison of experimental results

算法	Recall/%	Precision/%	mAP50/%	FPS
YOLOv3-tiny	78.5	86.2	85.3	278.14
YOLOv5n	90.2	92.2	93.8	288.54
YOLO-MBBi	92.4	93.8	95.8	331.34
PCB-YOLO	93.7	94.8	96.2	333.40
YOLOv7-tiny	91.8	95.8	95.0	248.77
YOLOv8n	90.0	93.2	94.0	298.26
Ours	94.3	95.0	96.7	341.02

实验结果表明,本文算法在 Recall、mAP50 和 FPS 等关键指标上均优于对比模型,虽然 Precision 略低于

YOLOv7-tiny,但是本文算法的 Recall、mAP50 和 FPS 值均是最高,表现出更强的综合性能和实际应用价值。

为了直观对比各类算法的检测性能和收敛速度,本文将展示不同算法的 mAP50 对比曲线,如图 7 所示。图 7(a)展示了模型完整训练过程中 mAP50 的变化趋势,从图中可以看出前 100 轮内,本文算法的 mAP50 曲线上

升速度最快,并在较早的阶段趋于稳定,说明本文算法具有更快的收敛速度。图 7(b)是 100 轮以后 mAP50 曲线的局部放大图,从图中可以看出,本文算法的 mAP50 曲线始终高于其他算法,说明本文算法在整体性能上优于其他对比算法,进一步验证了其在 PCB 缺陷检测任务中的有效性和优越性。

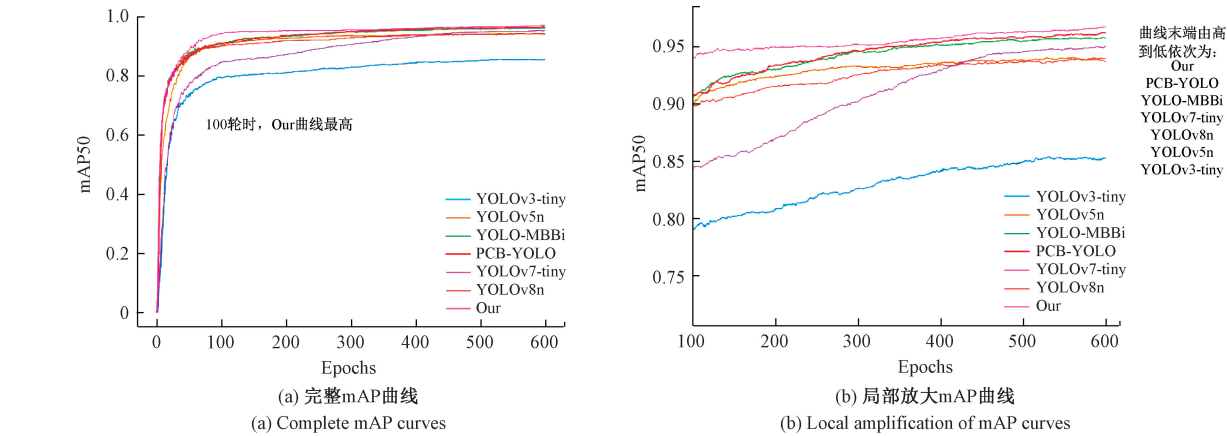


图 7 不同算法下的 mAP50 数据曲线
Fig. 7 mAP50 data curves under different algorithms

为了进一步验证本文算法的泛化性和鲁棒性,本文在测试集中特意挑选了一些背景复杂且缺陷特征不明显的 PCB 图片进行对比实验,实验结果如图 8 所示。通过对比分析可以发现,在复杂背景下检测微小缺陷时,其他算法均存在不同程度的漏检现象,尤其是在检测划痕缺陷时,不合理的扩展现

象较为严重导致检测精度下降。相比之下,本文算法能够更准确地定位划痕缺陷,减少不必要的扩展,同时显著降低漏检率,表现出更高的检测精度和稳定性。这一结果表明,本文算法在处理复杂背景和微小缺陷时具有更强的适应性和鲁棒性,更适用于实际的 PCB 缺陷检测任务。




图 8 不同模型可视化对比结果
Fig. 8 Comparison results of different model visualisations

4 结 论

本文提出了一种基于改进 YOLOv8n 算法的 YOLOv8-CSM 模型用于 PCB 缺陷检测,首先,在基础模型中添加 CA 注意力模块,抑制复杂背景对 PCB 缺陷部位的影响以提高模型的检测精度;其次,在检测头中引入 SEAM 模块扩大模型感受野,提高模型对微小缺陷的识别能力以降低漏检率;最后,采用 MPDIoU 损失函数作为模型的回归损失,简化计算过程,同时优化边界框的定位与尺寸精度,进一步提高了模型的检测性能。

本文算法较基础模型而言,检测精度和速度均有大幅提升。与现阶段常用的小目标检测算法 YOLOv3-tiny、YOLOv5n、YOLO-MBBi、PCB-YOLO、YOLOv7-tiny 相比,本文算法不仅能够更好地兼顾检测精度和速度的平衡,还在鲁棒性和泛化性上表现出明显优势,尤其是在面对划痕这类细微缺陷时,能够显著降低漏检率并减少不合理扩展现象,而其他算法往往表现不佳。因此,本文算法不仅具有较高的理论价值,还具备广泛的实际应用前景,能够为 PCB 缺陷检测领域的工业化应用提供有力支持。

参考文献

- [1] ZHOU W, LI CH Y, YE ZH W, et al. An efficient tiny defect detection method for PCB with improved YOLO through a compression training strategy[J]. IEEE Transactions on Instrumentation and Measurement, 2024,73:1-14.
- [2] TANG J L, LIU SH B, ZHAO D X, et al. PCB-YOLO: An improved detection algorithm of PCB surface defects based on YOLOv5[J]. Sustainability, 2023, 15(7): 5963.
- [3] 朱瑞,齐元胜,张勇斌.融合部分卷积和无参数注意力机制的轻量级印刷电路板缺陷检测算法[J/OL].计算机集成制造系统,1-18[2025-04-09]. <https://doi.org/10.13196/j.cims.2023.0407>.
ZHU R, QI Y SH, ZHANG Y B. A lightweight printed circuit board defect detection algorithm incorporating partial convolution and parameter-free attention mechanism [J/OL]. Computer Integrated Manufacturing Systems, 1-18 [2025-04-09]. <https://doi.org/10.13196/j.cims.2023.0407>.
- [4] LING Q, ISA N A M, ASAARI M SH M. Precise detection for dense PCB components based on modified YOLOv8[C]. IEEE Access, 2023.
- [5] 吴一全,赵朗月,苑玉彬,等.基于机器视觉的 PCB 缺陷检测算法研究现状及展望[J].仪器仪表学报,2022, 43(8):1-17.
WU Y Q, ZHAO L Y, YUAN Y B, et al. Research status and prospect of PCB defect detection algorithm

based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022,43(8):1-17.

- [6] 陈仁祥,詹赞,胡小林,等.基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J].仪器仪表学报,2021,42(12):167-174.
CHEN R X, ZHAN Z, HU X L, et al. Defect detection of printed circuit boards under noise interference based on multi-attention Faster RCNN[J]. Chinese Journal of Scientific Instrument, 2021,42(12):167-174.
- [7] DU B W, WAN F, LEI G B, et al. YOLO-MBBi: PCB surface defect detection method based on enhanced YOLOv5[J]. Electronics, 2023,12(13):2821.
- [8] TANG J L, LIU SH B, ZHAO D X, et al. PCB-YOLO: An improved detection algorithm of PCB surface defects based on YOLOv5[J]. Sustainability, 2023, 15(7): 5963.
- [9] LAN H, ZHU H SH, LUO R, et al. PCB defect detection algorithm of improved YOLOv8[C]. 2023 8th International Conference on Image, Vision and Computing(ICIVC). IEEE, 2023: 178-183.
- [10] 严舒,郭颖,黄骏. FCM-YOLO: 一种基于特征增强和多尺度融合的 PCB 缺陷检测方法[J]. 控制与决策, 2024,39(10):3181-3189.
YAN SH, GUO Y, HUANG J. FCM-YOLO: A PCB defect detection method based on feature enhancement and multi-scale fusion [J]. Control and Decision Making, 2024,39(10):3181-3189.
- [11] SHI P, ZHANG Y Y, CAO Y Q, et al. DVCW-YOLO for printed circuit board surface defect detection[J]. Applied Sciences, 2024, 15(1): 327.
- [12] HOU Q B, ZHOU D Q, FENG J SH. Coordinate attention for efficient mobile network design [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [13] YU Z P, HUANG H B, CHEN W J, et al. YOLO-facev2: A scale and occlusion aware face detector[J]. Pattern Recognition, 2024, 155: 110714.
- [14] MA S L, XU Y. MPDIoU: A loss for efficient and accurate bounding box regression[J]. ArXiv preprint arXiv:2307. 07662, 2023.
- [15] HUANG ZH J, LI L T, KRIZEK G CH, et al. Research on traffic sign detection based on improved YOLOv8[J]. Journal of Computer and Communications, 2023, 11(7): 226-232.
- [16] DING R W, DAI L H, LI G P, et al. TDD-net: A tiny defect detection network for printed circuit boards[J]. CAAI Transactions on Intelligence Technology, 2019, 4(2): 110-116.

- [17] ZHANG Y F, REN W Q, ZHANG ZH, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [18] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism [J]. ArXiv preprint arXiv: 2301.10051, 2023.

作者简介

熊炜,博士,副教授,硕士生导师,主要研究方向为数字图像处理与计算机视觉。

E-mail: xw@mail. hbut. edu. cn

黄玉谦(通信作者),硕士研究生,主要研究方向为计算机视觉、目标检测等。

E-mail: 2607584693@qq. com