

# 基于改进的YOLOv8的PCB瑕疵检测

吕真真, 房立金, 赵乾坤, 万应才  
(东北大学 机器人科学与工程学院, 辽宁 沈阳 110169)

**摘 要:** 由于印刷电路板(PCB)集成度高且线路复杂以及参数量日益增加,其存在的瑕疵直接影响PCB的生产效率,利用计算机视觉技术对PCB瑕疵进行检测对PCB生产具有重要意义.本文在YOLO目标检测算法基础上,提出了一种基于自注意力的PCB瑕疵检测算法.首先,在特征提取阶段引入了极化自注意力机制,对PCB特征的空间与语义特征分别进行提取,并将其与输入原始特征进行结合,增强网络特征的表征能力.然后,在解码阶段加入了一种小目标检测头,该检测头充分利用了YOLO网络Backbone模块提取的低分辨率特征,使网络关注PCB局部细节特征,提高瑕疵区域的定位精度.实验结果表明,所提方法在PCB数据集上精度可达95.5%,与原YOLOv8方法相比提高了4%,mAP0.5:0.95指标与原YOLOv8方法相比提高了2.8%.

**关键词:** YOLOv8;小目标检测头;极化自注意力机制;瑕疵检测;目标检测

中图分类号: TP 391.41 文献标志码: A 文章编号: 1005-3026(2025)10-0001-09

## Defect Detection on PCB Based on Improved YOLOv8

LYU Zhen-zhen, FANG Li-jin, ZHAO Qian-kun, WAN Ying-cai

(School of Robot Science and Engineering, Northeastern University, Shenyang 110169, China. Corresponding author: FANG Li-jin, E-mail: ljfang@mail.neu.edu.cn)

**Abstract:** Due to the high integration, complex circuits, and increasing parameters of printed circuit boards (PCBs), defects in PCBs directly affect production efficiency, making computer vision-based defect detection crucial for PCB manufacturing. A self-attention-based PCB defect detection algorithm was proposed based on the YOLO object detection algorithm. First, a polarized self-attention (PSA) mechanism was introduced in the feature extraction stage to separately extract spatial and semantic features of PCBs, which were combined with input raw features to enhance the network's feature representation capability. Then, a small-object detection head was added in the decoding stage, which fully utilized low-resolution features from the YOLO network Backbone module to enable the network to focus on local details of PCBs and improve defect positioning accuracy. Experiments show that the proposed method achieves 95.5% accuracy on the PCB dataset, 4% higher than the original YOLOv8 method, with the mAP0.5:0.95 metric increased by 2.8%.

**Key words:** YOLOv8; small-object detection head; polarized self-attention mechanism; defect detection; object detection

印刷电路板(printed circuit board, PCB)作为电子产品的核心组件之一,其制造质量直接关系到电路性能和产品可靠性.然而,在PCB的制造过程中,由于设备故障、制造误差或材料问题等原因,往往会导致瑕疵的产生.

传统的PCB瑕疵检测方法主要依赖于人工

目视检查,耗时耗力,并且容易出现人为错误.据统计,人工目测的方式对每100个瑕疵进行检测耗时长达40~45 min<sup>[1]</sup>.该方式的瑕疵检测难以实现大规模生产.早期为了提高PCB瑕疵检测效率,研究者提出了利用图像处理<sup>[2]</sup>和机器视觉技术<sup>[3]</sup>进行自动化检测的方法.这些方法主要基于

收稿日期: 2024-03-04

基金项目: 国家自然科学基金资助项目(62273081).

作者简介: 吕真真(1998—),女,安徽阜阳人,东北大学硕士研究生;房立金(1965—),男,辽宁沈阳人,东北大学教授,博士生导师.

图像处理算法,但受限于瑕疵类型的多样性以及图像处理算法瑕疵检测的准确性较低,适应性较差,难以广泛推广.为了提高检测精度,研究者们开始关注特征提取技术.其中,基于图像处理和数学形态学的特征提取算法,可以通过提取和分析图像中的特征来区分正常区域和瑕疵区域,从而实现瑕疵检测.然而,这些方法对光照、噪声和图像变形等因素比较敏感.随着机器学习方法逐渐成熟,传统的机器学习算法<sup>[4]</sup>,如支持向量机(SVM)<sup>[5]</sup>、决策树和随机森林<sup>[6]</sup>等,被应用于PCB瑕疵检测.但这些方法依赖于手工提取特征,特征表示能力较弱,限制了该方法的应用.近年来,深度学习在计算机视觉领域取得了飞速发展,PCB瑕疵检测技术也取得了突破性发展.例如图像卷积神经网络(convolutional neural network, CNN)能够对PCB图像中的瑕疵特征进行提取,并通过大量标注数据集进行训练,大幅提高了PCB瑕疵检测精度.

深度学习基于大规模数据集的训练,能够自动学习和提取图像特征,从而实现PCB图像中各种类型瑕疵的准确检测和分类.通过建立精细标注的PCB图像数据集,研究人员能够训练出基于卷积神经网络的瑕疵检测模型.这些深度学习模型不仅能实现实时检测,还能提高检测准确性,并有效区分真实瑕疵和图像噪声.但是深度学习需要大样本数据对模型进行训练,导致在图像收集上存在一定困难,因此Chang等<sup>[7]</sup>提出基于聚类算法的检测方法,通过图像预处理分区,结合双区域合并策略与三重约束条件,在HSV(色调-饱和度-透明度)颜色空间识别缺陷区域,并建立评价体系.Hu等<sup>[8]</sup>使用改进的RPN(region proposal network)结构实现了PCB瑕疵检测.刘伟森等<sup>[9]</sup>提出了一种多尺度的轻量级卷积神经网络用于PCB裸板瑕疵识别,使得网络的特征提取能力得到加强.Han等<sup>[10]</sup>提出了一种基于YOLOv5模型的PCB瑕疵检测方法,通过将YOLOv5s的损失函数优化为EIOU,引入ECANet注意力机制并调整置信度损失系数,显著提升PCB瑕疵检测精度至96.80%,有效解决定位不准与小目标漏检问题.Li等<sup>[11]</sup>采用SSD(单次多框检测)作为元结构,提出了基于该网络结构的表面瑕疵检测方法,实现了生产线上集装箱密封面的典型瑕疵检测,为优化实际工业生产提供了新思路.An等<sup>[12]</sup>提出了一种新的基于Transformer的LPViT模型及其相应的训练策略,

实现了对PCB图像的瑕疵检测和准确分类,并提高了模型的训练效率和鲁棒性.王永利等<sup>[13]</sup>利用差分模型确定PCB的瑕疵区域后,通过多层CNN进行特征提取和瑕疵分类,证明了深度学习方法相比于传统方法在PCB瑕疵检测领域具有优势.许思昂等<sup>[14]</sup>对YOLOv5模型进行改进,增加特征融合通道提高信息利用率,并利用压缩激励模块获得比原模型更高的检测精度,但其对存在多种瑕疵背景图像进行检测时,有漏检错检情况发生.

在PCB瑕疵检测中,YOLOv1可以准确检测出不同类型的瑕疵,但对小尺寸目标的检测效果有限.为了解决这个问题,YOLOv2通过改进网络结构和训练策略,提高了对小尺寸目标的检测能力.YOLOv3<sup>[15]</sup>进一步改进了YOLOv2,引入多尺度预测和更深的网络结构,提高了检测精度和鲁棒性.YOLOv4<sup>[16]</sup>在YOLOv3的基础上进行了进一步改进,表现出更高的准确性和泛化能力.最近,基于YOLOv5的算法也应用于PCB瑕疵检测中,取得了较好效果.

本文引入了基于YOLOv8的PCB板瑕疵检测算法,提出了一种基于小目标检测头和极化自注意力机制的PCB瑕疵检测方法.该方法的优势主要体现在:首先,引入了小目标检测头,能够有效应对PCB上的微小瑕疵,提高瑕疵检测的精确度;其次,极化自注意力机制能够自动学习特征的重要性,并根据瑕疵区域的不同进行加权处理,进一步提升瑕疵检测的准确性.此外,该方法具备较快的检测速度,能够高效处理大规模PCB样本,提高生产效率.

经过大量的数据集训练和实验验证,本文方法取得了显著的效果.与传统方法相比,本文方法在PCB瑕疵检测的准确率、召回率和mAP0.5:0.95等评价指标上均取得了较好的成绩.并且,该方法能够应对高密度PCB下的小目标检测和定位问题,在检测速度和准确性上实现了更好的平衡.

## 1 YOLO算法

YOLO(you only look once)算法是一种目标检测算法,它的主要优势在于实时性能很高.传统目标检测算法通常将目标检测问题分解为两个子任务:候选区域生成和目标分类,在处理速度上存在瓶颈,因为需要对大量的候选区域进

行分类.相比之下,YOLO算法采用了一种不同的策略.它将目标检测问题视为一个回归问题,通过将CNN应用于整个图像来同时预测目标的边界框和类别,如图1所示.具体来说,YOLO算法将输入图像分为 $S \times S$ 个网格单元,并在每个单元格中预测 $B$ 个边界框.每个边界框由5个要素组成:边界框的位置( $x$ 、 $y$ 、宽度、高度)和置信度分数(表示该边界框包含目标的概率).每个边界框还与一个特定的类别相关联.这样,

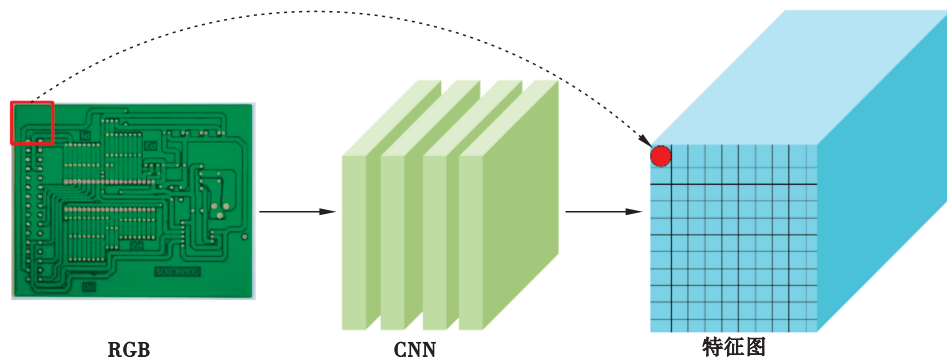


图1 YOLO模型结构

Fig. 1 YOLO model structure

YOLO算法可以一次性地检测出图像中的多个目标.为了训练YOLO模型,需要大量带有标注框和类别的训练图像数据.通过优化损失函数,模型可以学习到目标的位置和类别信息.

YOLO算法检测速度快,具有较高的准确性,能够实时地在视频中进行目标检测.然而,由于在图像上进行密集预测,YOLO在检测小目标时可能存在一些困难.

## 2 改进的YOLOv8算法

### 2.1 模型的整体架构

目前YOLO系列的SOTA模型是Ultralytics公司于2023年发布的YOLOv8.YOLOv8设计快速、准确且易用,是各种目标检测、图像分割和图像分类任务的最佳选择.其网络结构示意图如图2所示.YOLOv8将整个网络结构分为Input, Backbone, Neck和Head 4个模块,其中Backbone模块采用轻量级卷积神经网络结构CSPDarknet来对图像进行初始特征提取,并与特征提取网络(feature pyramid network, FPN)进行特征融合. Neck模块采用特征金字塔PANet结构,通过自顶向下路径结合和自底向上特征传播进行多尺度融合.将FPN得到的特征层传入PANet结构并自底向上进行融合操作,有效传输强定位信息,通过强语义信息和强定位信息的相互作用可有效提高模型对微小缺陷提取的鲁棒性.经过一系列混合和组合图像特征操作,将图像特征传递到预测层.Head模块则由多个卷积层与全连接层构成,通过置信度边界框与候选边界框重叠面积大小进行最后筛选,完成检测步骤.该模块主要对图像特征进行预测,生成边界框并预测类别,输

出预测模型,生成目标检测结果.

本文基于YOLOv8结构,首先在YOLOv8的Neck模块后加入极化自注意力(polarized self-attention, PSA)模块用于增强网络特征提取能力,然后在YOLOv8解码部分加入小目标检测头以实现微小瑕疵目标的识别.其中,PSA模块采用极化自注意力机制,通过引入极化因子来减少需要计算的位置对之间的注意力,从而提高自注意力模型的效率.对YOLOv8检测头的SPP-PANet进行调整,在YOLOv8的基础上增加1/4分辨率检测头,利用较高的分辨率特征来保存更多小目标的信息,提高对小目标的检测准确性.

### 2.2 PSA机制检测模块

PSA机制是一种改进的自注意力机制,旨在提高自注意力模型的效率和准确性.传统的自注意力机制通常需要计算所有位置对所有位置之间的注意力,这会导致计算复杂度增加和模型训练时间延长.PSA机制通过引入极化因子来减少需要计算的位置对数量,从而提高自注意力模型的效率.

在本研究中,将PSA机制融入YOLOv8架构的Neck模块中.该机制作为一个独立模块,专门用于解耦并学习特征图中的空间和语义关联.通过对特征图的极化处理,PSA机制有效地将空间

定位信息与语义特征分离. 然后, 这些解耦的特征重新与原始特征相结合, 以增强模型的代表能力和感知精度. 这种重新结合提升了特征图的代表能力, 使得网络能更加精准地捕捉复杂场景中

的目标特征, 改进了目标的定位和回归能力. 此外, 引入极化自注意力机制还使模型能够更有效地专注于目标周围的关键区域, 从而提高目标检测的准确度.

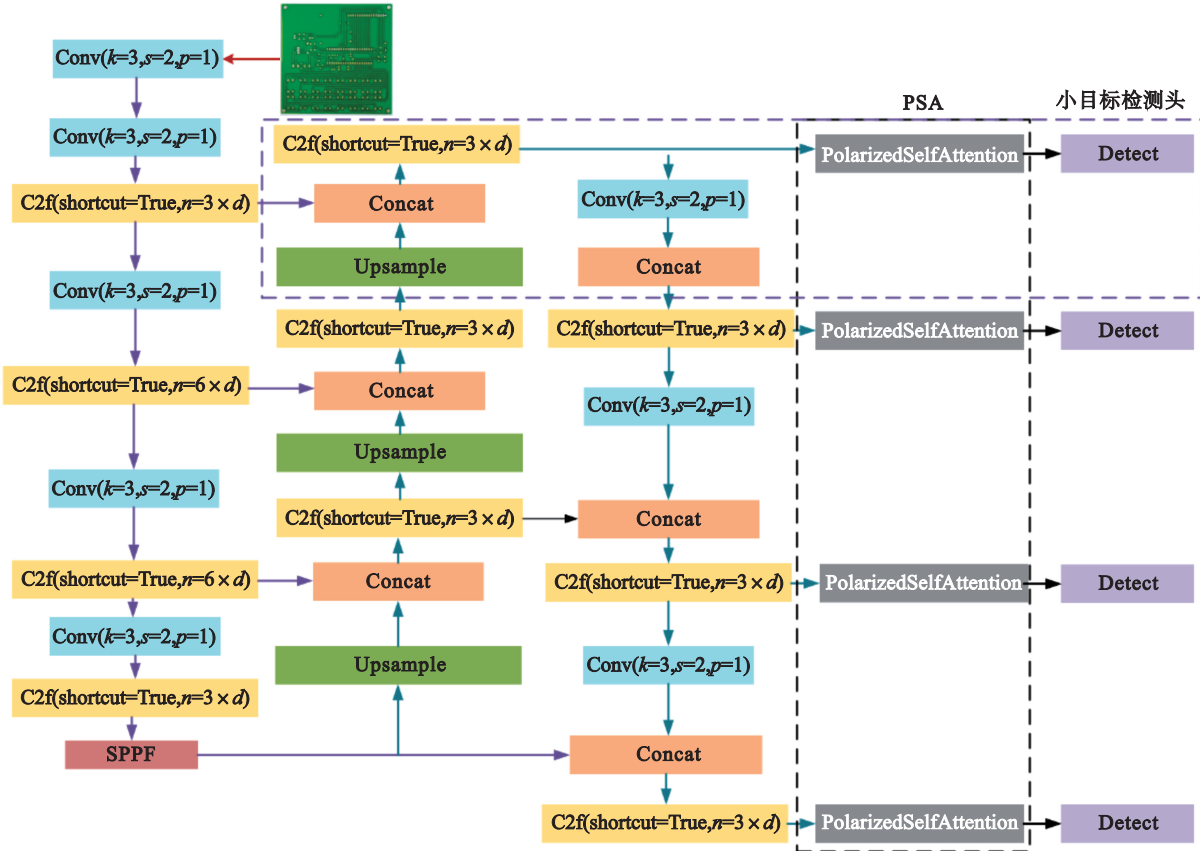


图2 改进的YOLOv8网络结构

Fig. 2 Improved YOLOv8 network structure

本文的PSA机制结合了第一极化滤波和高动态范围两个关键设计, 以实现PCB特征的提取. 通过极化滤波设计在PCB特征的通道和空间注意力方向计算中保持内部高分辨率, 将输入特征转换为对应维度, 使得网络可以同时特征进行空间和通道注意力计算, 降低了计算复杂度. 在PCB瑕疵检测中, 通过高动态范围对注意力模块中最小的特征张量进行Softmax归一化, 可以拓宽注意力范围并进行信息增强, 从而有效地捕获关键的瑕疵特征. 这种操作有助于将注意力集中在重要区域, 突出瑕疵部分并抑制背景噪声, 提高了检测的准确性和鲁棒性. 随后, 使用Sigmoid函数进行投影映射, 使得模型输出更加细腻, 更接近真实输出, 从而能够更准确地识别PCB图像中的各种微小和复杂的瑕疵, 提升瑕疵检测的精度和效果. 这种高动态范围的处理方式在PSA机制中的应用有效地增强了模型对PCB瑕疵的处理能力, 使得检测结果更加细致和精确.

如图3所示, 先用 $1 \times 1$ 卷积将输入特征 $X$ 转换为 $W_q$ 和 $W_v$ , 其中 $W_q$ 的通道被完全压缩, 而 $W_v$ 的通道维度保持在一个比较高的水平( $C/2$ ). 因为 $W_q$ 的通道维度被压缩, 需要通过HDR进行信息增强, 因此采用Softmax对 $W_q$ 进行信息增强. 然后将 $W_q$ 和 $W_v$ 进行矩阵乘法, 并在后面接上 $1 \times 1$ 卷积, LN将通道维度从 $C/2$ 提升为 $C$ . 最后用Sigmoid函数使得所有参数都保持在0~1之间.

PSA机制通过2个分支的输出在并行布局下组成:

$$\begin{aligned} \text{PSA}_p(X) &= Z^{\text{ch}} + Z^{\text{sp}} = \\ &A^{\text{ch}}(X) \odot^{\text{ch}} X + A^{\text{sp}}(X) \odot^{\text{sp}} X. \end{aligned} \quad (1)$$

其中 $A^{\text{ch}}(X) \in \mathbf{R}^{C \times 1 \times 1}$ 是通道注意力机制表达式:

$$A^{\text{ch}}(X) = F_{\text{SG}}[W_{z\theta_1}((\sigma_1(W_v(X)))) \times F_{\text{SM}}(\sigma_2(W_q(X)))] \quad (2)$$

其中: $F_{\text{SG}}$ 是Sigmoid激活函数; $Z$ 是输出特征; $\theta_1$ 表示通道卷积之间的参数; $W_q, W_v$ 是 $1 \times 1$ 卷积层; $\sigma_1, \sigma_2$ 是重塑操作(reshape operator); $F_{\text{SM}}$ 是

Softmax 算子;  $\times$  是矩阵点积运算;  $\odot^h$  是通道乘法 运算操作符;  $\odot^{sp}$  是空间乘法运算操作符.

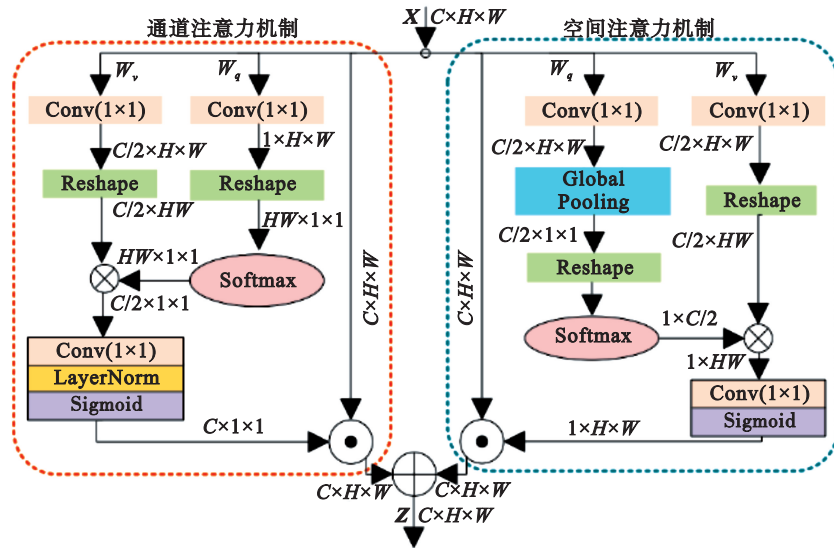


图3 PSA机制并行分布结构

Fig. 3 Parallel distributed structure of PSA mechanism

$A^{sp}(X) \in \mathbf{R}^{1 \times H \times W}$  是空间注意力机制, 其表达式:  
 $A^{sp}(X) = F_{SG}[\sigma_3(F_{SM}(\sigma_1(F_{GP}(W_g(X)))) \times \sigma_2(W_v(X)))]$ .  
 (3)

其中:  $\sigma_1, \sigma_2, \sigma_3$  是 3 个重塑操作;  $F_{GP}(\cdot)$  表示全局平均池化操作.

### 2.3 小尺寸目标检测头

为了增强对小目标瑕疵的识别精度, 本文引入了小目标特征检测头. 小目标检测头包含空间金字塔池化 (spatial pyramid pooling, SPP) 和层级预测聚合网络 (predictive aggregation network, PANet). 检测头的缩放倍数由参数  $s$  控制, 在本文中设置为  $1/4$ , 用以增强对小尺寸瑕疵的检测性能. YOLOv8 默认使用  $1/8, 1/16$  和  $1/32$  分辨率的特征图进行目标检测, 在大多数情况下这是有效的. 然而, 瑕疵数据集中的缺陷通常较小, 分辨率较低, 使用这些较低分辨率的特征图可能无法充分捕捉到小目标的特征, 从而影响检测性能. 因此, 本文在  $1/4$  分辨率的特征图上加入了一个额外的检测头, 利用更高分辨率的特征图来保留更多小目标信息, 提高对小目标的检测精度.

## 3 实验结果及分析

### 3.1 数据集简介以及实验设置

本文使用的印刷电路板瑕疵数据集来源于 HRI 实验室 PKU-Market 提供的开源数据集 (<https://robotics.pkusz.edu.cn/resources/dataset/>). 它是一个公共合成 PCB 数据集, 包含 693 张图片, 6 种缺陷分别为漏孔 (Missing\_hole, MH), 鼠

咬 (Mouse\_bite, MB), 开路 (Open\_circuit, OC), 短路 (Short, SH), 杂散 (Spur, SP) 和杂铜 (Spurious\_copper, SC), 用于图像检测、分类和配准任务. 本实验 PCB 训练时图片分辨率为  $1024 \times 1024$ , PCB 板缺陷数据集共 693 张图片, 其中 593 张图片用于构建训练集, 100 张图片用于构建验证集, PCB 缺陷如图 4 所示.

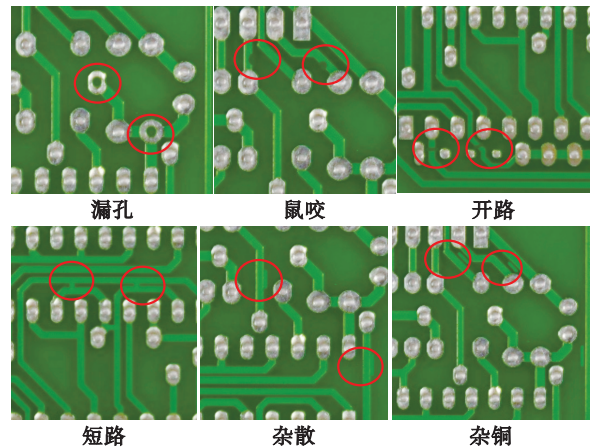


图4 PCB缺陷展示

Fig. 4 Defect display of PCB

本次实验运行环境的操作系统为 Ubuntu 20.04, GPU 为 NVIDIA RTX4090, 显存 24 GB, Python 版本为 3.10, PyTorch 版本为 2.0.1, 为保证实验公平性, 所有对比实验都使用相同的硬件.

### 3.2 实验结果对比

#### 3.2.1 不同数据集各模型的指标对比实验

实验结果如表 1 所示, 在 PCB 数据集上对比了 YOLOv6, YOLOv8, 加入小目标检测头的

YOLOv8 (YOLOv8\_p2), 加入 PSA 机制的 YOLOv8 (YOLOv8\_psa) 和加入 PSA 机制和小目标检测头的 YOLOv8 (YOLOv8\_p2\_psa) 算法的

精度 (precision)、召回率 (recall)、平均精度均值 (mean average precision, mAP) 以及每个模型的参数量。

表 1 PCB 瑕疵检测各模型指标  
Table 1 Various model metrics for PCB defect detection

模型	精度	召回率	mAP0.5:0.95	参数量
YOLOv6	0.942	0.770	0.471	4 234 338
YOLOv8	0.915	0.829	0.481	3 006 818
YOLOv8_p2	0.926	0.839	0.498	2 921 832
YOLOv8_psa	0.935	0.867	0.491	3 181 317
YOLOv8_p2_psa	0.955	0.812	0.509	3 098 556

从表 1 中可以看到, YOLOv8 系列相对于 YOLOv6 在精度、召回率和 mAP 等指标上都有所提升, 这表明 YOLOv8 系列模型在物体检测任务上具有更好的性能表现。另外, YOLOv8 系列模型的数量相对较少, 但性能却有所提升, 这显示了模型在参数利用效率方面的改进。其次, 由表 1 可以得出: 在 PCB 瑕疵检测上, YOLOv8\_p2\_psa 相比 YOLOv8 其 mAP 提高了 2.8%; 在绝缘子的瑕疵检测上, YOLOv8\_p2\_psa 相比 YOLOv8 其 mAP 提高了 1.9%。加入小目标检测和 PSA 机制效果有明显提高。对比 YOLOv8\_p2, YOLOv8\_psa 与 YOLOv8\_p2\_psa 模型的指标可以发现, YOLOv8\_p2\_psa 在 precision 和 mAP 等指标上表现稍好, 这表明 YOLOv8\_p2\_psa 模型有着更好的性能。

根据实验结果可以得出结论: YOLOv8 系列相较于 YOLOv6 在目标检测任务上表现出更好的精度、召回率和 mAP, 并且具有更高的参数利用效率, 而 YOLOv8\_p2\_psa 模型在特定数据集上展现出了更好的性能。由参数量可知, 本文改进后的模型参数量相比原始 YOLOv8 没有过多增加, 可见其检测速度没有降低。

### 3.2.2 不同瑕疵检测效果的对比实验

根据表 2 中的数值可以看到, 各模型在不同瑕疵类别上具有不同的性能表现。由 mAP 0.5:0.95 指标可以看出, 在漏孔、鼠咬、短路和杂散瑕疵上, 本文改进的 YOLOv8\_p2\_psa 相较于其他模型性能更好; 而在开路 and 杂铜瑕疵上则略逊于只加入小目标检测头的 YOLOv8\_p2。

表 2 模型 PCB 各瑕疵检测 mAP0.5:0.95 指标  
Table 2 mAP0.5:0.95 metric for detection of various defects on model PCB

瑕疵类别	YOLOv6	YOLOv8	YOLOv8_p2	YOLOv8_psa	YOLOv8_p2_psa
漏孔	0.667	0.626	0.661	0.657	0.667
鼠咬	0.406	0.464	0.422	0.448	0.464
开路	0.491	0.490	0.512	0.493	0.508
短路	0.467	0.507	0.511	0.520	0.529
杂散	0.376	0.386	0.442	0.379	0.439
杂铜	0.421	0.414	0.440	0.448	0.449

改进后的 YOLOv8\_p2\_psa 算法实验结果的 PCB 瑕疵检测混淆矩阵图见图 5, 反映了该算法分类检测的结果。由图可知, 该算法对 PCB 的杂铜瑕疵有着更好的判断, 但是对于鼠咬和开路瑕疵则容易误判。

实验曲线如图 6 所示。精度表示模型检测出的缺陷区域中真正的缺陷面积占检测出的缺陷面积的比例, 召回率表示模型能够检测出的真正存在的缺陷面积占总体存在的缺陷面积的比例。

由图 6 可以看出, 本实验改进后的模型对于 PCB 的漏孔、短路、开路缺陷检测精度较高, 尤其对于漏孔其精度可达到 100%; 对于杂散则有较多的噪声, 缺陷检测精度较低。

### 3.2.3 改进后模型检测结果

图 7 是 YOLOv8 与引入小目标检测头 YOLOv8\_p2 的检测结果对比, 同一张图片在没有引入小目标检测头时会出现漏检的情况。因为有些瑕疵在 PCB 上的像素很小, 如果小目标的尺寸超

出了训练阶段设定的尺度范围,模型可能无法适应这些小目标的检测需求,从而导致漏检的发生.

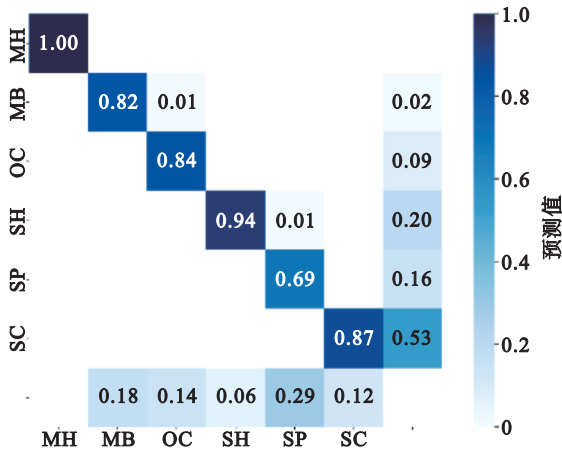


图5 混淆矩阵

Fig. 5 Confusion matrix




图6 精度-召回率曲线

Fig. 6 Precision-recall curves

图8是YOLOv8与引入PSA机制YOLOv8\_psa的检测结果对比.在PCB瑕疵检测中,瑕疵通常分布在不同的区域,而PSA机制能够帮助模型关注瑕疵附近的局部细节信息,并同时捕捉全局上下文信息.这样,模型可以更准确地理解瑕疵的位置、形状和上下文关系,从而提高对瑕疵的判断能力.

图9是PCB和绝缘子部分检测结果对比.检




图7 小目标检测头结果对比

Fig. 7 Comparison of results with small-object detection head





图8 PSA结果对比图

Fig. 8 Comparison of PSA results

测框的数值代表该框中包含缺陷的置信度,也可以称作检测分数或置信分数.这个数值越大,表示框内存在瑕疵的概率越高,模型也会更加自信地认为该区域是缺陷.可以看出,本文改进后的YOLOv8\_p2\_psa算法检测效果更好,因为PCB表面有很多走线和焊盘,对于一些高精度多层布线的板子,其结构更为复杂,加入小目标检测头可以提高对小目标的感知能力,尤其是对于小尺寸的缺陷区域,这有助于减少对小缺陷的漏检情况,提高检测的准确性.再加入极化自注意力机制,能够增强对关键特征的关注,提升特征表达能力以及抑制背景干扰,从而提高整体检测性能和目标检测的准确性.



YOLOv6

YOLOv8

YOLOv8\_p2

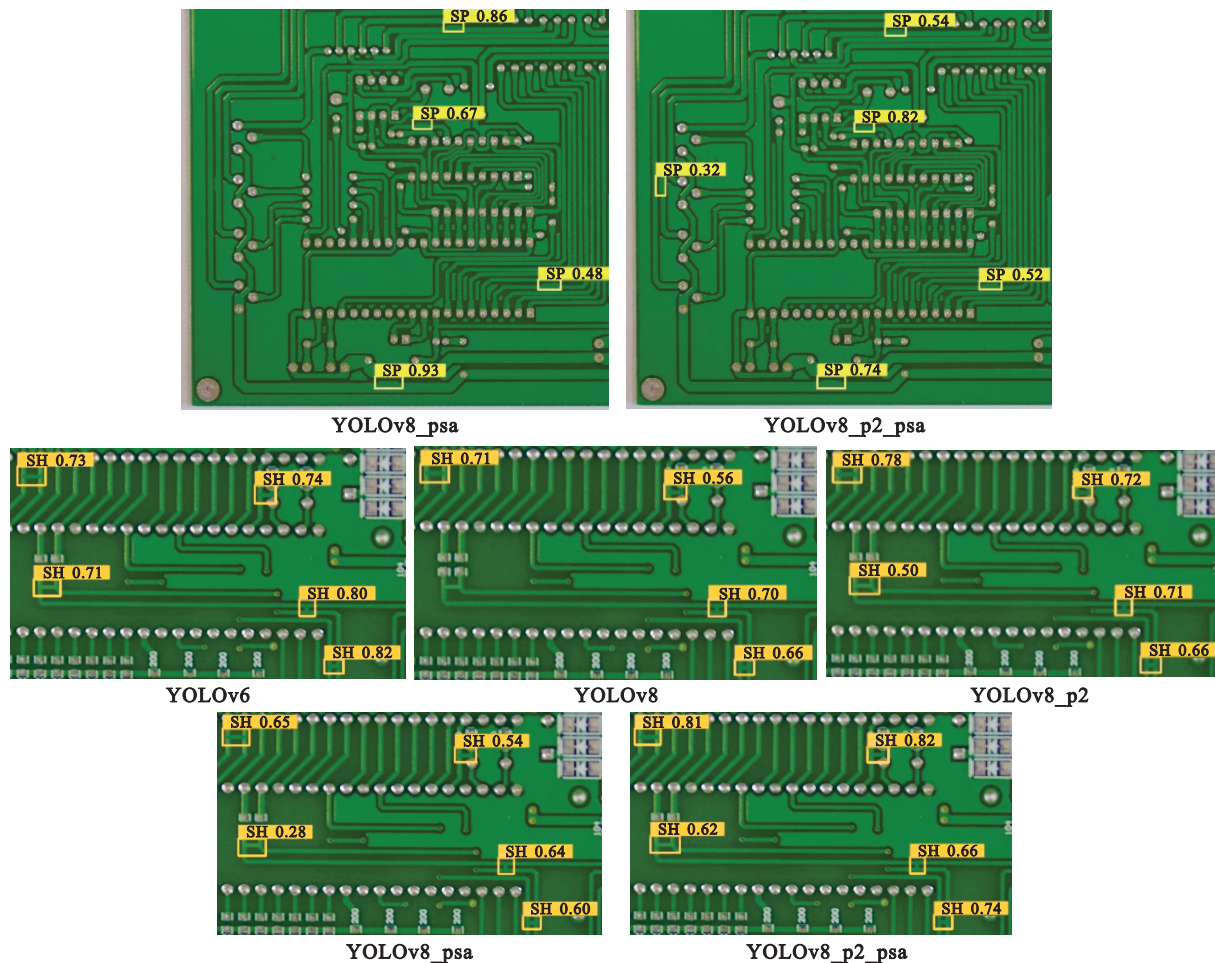


图9 不同模型检测结果

Fig. 9 Detection results of different models

## 4 结 语

本文利用YOLOv8目标检测框架提出了一种新的缺陷检测方法.基于YOLO目标检测框架,提出了一种结合极化自注意力机制的PCB瑕疵检测方法.该方法在特征提取阶段,通过极化自注意力机制分离并强化空间与语义信息,与原始特征融合以增强网络的表征能力.另外,引入小目标检测头,专注于高分辨率特征图,以提高对PCB微小瑕疵的定位精度,有效提升检测性能.本文在HRI实验室PKU-Market提供的开源数据集上进行了定性和定量分析,实验结果显示该方法精度达到95.5%,召回率达到81.2%,mAP0.5:0.95达到0.509,相比其他瑕疵检测方法均有显著提高.

### 参考文献:

[1] Zheng X Q, Zheng S, Kong Y G, et al. Recent advances in surface defect inspection of industrial products using deep

learning techniques [J]. *The International Journal of Advanced Manufacturing Technology*, 2021, 113(1): 35-58.

[2] Anitha D B, Rao M. A survey on defect detection in bare PCB and assembled PCB using image processing techniques[C]// *International Conference on Wireless Communications, Signal Processing and Networking (WiSPNET)*. Chennai, 2017: 39-43.

[3] Ma J J. Defect detection and recognition of bare PCB based on computer vision[C]// *36th Chinese Control Conference (CCC)*. Dalian, 2017: 11023-11028.

[4] 邹华东. 基于机器学习的PCB孔位信息在线光学检测[J]. *辽宁工程技术大学学报(自然科学版)*, 2012, 31(1): 93-97.

(Zou Hua-dong. Online optical inspection of PCB hole position information based on machine learning[J]. *Journal of Liaoning Technical University (Natural Science Edition)*, 2012, 31(1): 93-97.)

[5] Zhang Z Q, Wang X D, Liu S, et al. An automatic recognition method for PCB visual defects [C]// *2018 International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*. Xi'an, 2018: 138-142.

[6] Wang N, Wang B, Huang J M, et al. PCB characteristic impedance prediction based on an error compensated random forest regression model[C]// *34th Chinese Control and Decision Conference (CCDC)*. Hefei, 2022: 3999-4004.

- [7] Chang Q T, Zhang Y, Sun Z. Research on surface defect detection algorithm of ice-cream bars based on clustering [C]// IEEE 3rd Information Technology, Networking, Electronic and Automation Control Conference (ITNEC). Chengdu, 2019: 537-541.
- [8] Hu B, Wang J H. Detection of PCB surface defects with improved faster-RCNN and feature pyramid network [J]. *IEEE Access*, 2020, 8: 108335-108345.
- [9] 刘伟森, 方亦建. 基于多尺度轻量级卷积网络的 PCB 裸板缺陷识别算法[J]. 自动化与信息工程, 2020, 41(5): 20-25.  
(Liu Wei-sen, Fang Yi-jian. PCB bare board defect recognition algorithm based on multi-scale lightweight convolutional network [J]. *Automation & Information Engineering*, 2020, 41(5): 20-25.)
- [10] Han W, Ren H W, Zhu X J, et al. Research and implementation of PCB defect detection based on improved YOLOv5 algorithm [C]// IEEE 3rd International Conference on Information Technology, Big Data and Artificial Intelligence (ICIBA). Chongqing, 2023: 1475-1478.
- [11] Li Y T, Huang H S, Xie Q S, et al. Research on a surface defect detection algorithm based on MobileNet-SSD [J]. *Applied Sciences*, 2018, 8(9): 1678.
- [12] An K, Zhang Y P. LPViT: a transformer based model for PCB image classification and defect detection [J]. *IEEE Access*, 2022, 10(5): 42-53.
- [13] 王永利, 曹江涛, 姬晓飞. 基于卷积神经网络的 PCB 缺陷检测与识别算法[J]. 电子测量与仪器学报, 2019, 33(8): 78-84.  
(Wang Yong-li, Cao Jiang-tao, Ji Xiao-fei. PCB defect detection and recognition algorithm based on convolutional neural network [J]. *Journal of Electronic Measurement and Instrumentation*, 2019, 33(8): 78-84.)
- [14] 许思昂, 李艺杰, 梁桥康, 等. 基于改进YOLOv5算法的 PCB 裸板缺陷检测[J]. 包装工程, 2022, 43(15): 33-41.  
(Xu Si-ang, Li Yi-jie, Liang Qiao-kang, et al. PCB bare board defect detection based on improved YOLOv5 algorithm [J]. *Packaging Engineering*, 2022, 43(15): 33-41.)
- [15] Susa J A B, Mariquina E, Tria M L, et al. Cap-Eye-citor: a machine vision inference approach of capacitor detection for PCB automatic optical inspection [C]// IEEE 7th International Conference on Engineering Technologies and Applied Sciences (ICETAS). Kuala Lumpur, 2020: 1-5.
- [16] Xu S Y, Chen X L, Huang Y R, et al. Defect detection of substation instrumentation equipment based on improved YOLOv4 algorithm [C]// 2023 China Automation Congress (CAC). Chongqing, 2023: 9091-9096.