

DOI: 10.19650/j.cnki.cjsi.J2513973

# 基于PXD-YOLO11s的陶瓷电路板缺陷检测方法研究\*

杨思念<sup>1</sup>, 曹立佳<sup>2,3,4</sup>, 郭川东<sup>2,3,4</sup>, 刘艳菊<sup>2</sup>, 任帅<sup>1</sup>

(1. 四川轻化工大学计算机科学与工程学院 宜宾 644000; 2. 四川轻化工大学自动化与信息工程学院  
宜宾 644000; 3. 智能感知与控制四川省重点实验室 宜宾 644000; 4. 企业信息化与物联  
网测控技术四川省高校重点实验室 宜宾 644000)

**摘要:**针对工业现场陶瓷电路板(CPCB)缺陷检测中存在的数据集有限、缺陷尺度微小、背景复杂等问题,提出了一种基于PXD-YOLO11s的陶瓷电路板缺陷检测方法。首先构建高质量CPCB缺陷专用数据集,系统设计涵盖深度划痕、砂眼、断路等14类典型缺陷的采集方案,采用工业相机和专业光学设备采集高清缺陷图像,并通过图像预处理与数据增强策略提升样本多样性与泛化能力。其次在YOLO11s网络架构基础上进行改进:引入并行特征提取模块(ParNet),通过多分支卷积结构捕获不同尺度的特征信息,同时优化卷积结构以提升特征提取效率;增加专用小目标检测层(XsHead),强化对微小缺陷的识别能力;后处理阶段引入Soft-NMS机制,通过置信度衰减而非直接抑制的方式处理重叠预测框,有效提升对密集排列缺陷的检测能力;最后调整损失函数,采用DIoU损失替代传统的CIoU损失,使模型更加关注预测框与真实框中心点距离和宽高比例,从而提升复杂背景下的目标定位精度。实验结果表明,在自建CPCB数据集上,改进后的PXD-YOLO11s模型在mAP50和mAP(50~95)指标上较原YOLO11s分别提升了5.2%和8.5%。此外,该方法在公开PKU-Market-PCB数据集上的检测性能优于Faster R-CNN、YOLOv5s等典型算法,展现出其良好的泛化能力与特征提取的有效性。所提出的方法显著提升了陶瓷电路板缺陷检测精度,为工业缺陷智能检测提供了高效、可靠的解决方案。

**关键词:** YOLO11s; 陶瓷电路板; CPCB; 缺陷检测

中图分类号: TP391 TH862 文献标识码: A 国家标准学科分类代码: 520.60

## Research on ceramic circuit board defect detection method based on PXD-YOLO11s

Yang Sinian<sup>1</sup>, Cao Lijia<sup>2,3,4</sup>, Guo Chuandong<sup>2,3,4</sup>, Liu Yanju<sup>2</sup>, Ren Shuai<sup>1</sup>

(1. School of Computer Science and Engineering, Sichuan University of Science & Engineering, Yibin 644000, China;  
2. School of Automation and Information Engineering, Sichuan University of Science & Engineering, Yibin 644000, China;  
3. Intelligent Perception and Control Key Laboratory of Sichuan Province, Yibin 644000, China; 4. Key Laboratory of Higher  
Education of Sichuan Province for Enterprise Informationalization and Internet of Things, Yibin 644000, China)

**Abstract:** To address the issues of limited datasets, tiny defect scales, and complex backgrounds in defect detection for CPCB in industrial settings, a CPCB defect detection method based on PXD-YOLO11s is proposed. Firstly, a high-quality dedicated dataset for CPCB defects is constructed, with a systematically designed acquisition scheme covering 14 types of typical defects such as deep scratches, sand holes, and open circuits. High-resolution defect images are captured using industrial cameras and professional optical equipment, and image preprocessing and data augmentation strategies are employed to enhance sample diversity and generalization. Secondly, improvements are made based on the YOLO11s network architecture: A parallel feature extraction module (ParNet) is introduced, which captures multi-scale feature information through a multi-branch convolutional structure while optimizing the convolution

configuration to improve feature extraction efficiency; A dedicated small target detection layer (XsHead) is added to strengthen the recognition capability for tiny defects; the Soft-NMS mechanism is integrated in the post-processing stage to handle overlapping prediction boxes through confidence decay instead of direct suppression, effectively enhancing the detection performance for densely arranged defects; Finally, the loss function is adjusted by adopting DIoU loss to replace the traditional CIoU loss, enabling the model to focus more on the center distance and aspect ratio between prediction boxes and ground truth boxes, thereby improving target localization accuracy in complex backgrounds. Experimental results show that on the self-built CPCB dataset, the improved PXD-YOLO11s model achieves 5.2% and 8.5% increases in mAP50 and mAP(50~95) compared with the original YOLO11s, respectively. In addition, this method outperforms typical algorithms such as Faster R-CNN and YOLOv5s on the public PKU-Market-PCB dataset, demonstrating its excellent generalization ability and effective feature extraction performance. The proposed method significantly improves the CPCB defect detection accuracy and provides an efficient and reliable solution for intelligent industrial defect detection.

**Keywords:** YOLO11s; ceramic circuit board; CPCB; defect detection

## 0 引言

现代电子技术的快速发展推动了对高速、高精度信号传输需求的不断提升,这对印刷电路板(printed circuit board, PCB)材料的性能提出了更高要求<sup>[1]</sup>。陶瓷电路板(ceramic printed circuit board, CPCB)凭借其低介电损耗(low dielectric loss, Df)、低介电常数(low dielectric constant, Dk)、优异的高频特性、高热导率和良好的热稳定性,在通信、雷达、汽车电子、航空航天等高端领域得到广泛应用。尤其在5G、卫星通信和高频功率放大器等对信号完整性和散热性能要求严苛的应用中,CPCB展现出传统有机基板难以比拟的综合优势,因而被广泛采用为核心材料<sup>[2]</sup>。然而,随着CPCB朝着高密度化、轻量化和高集成度方向发展,其制造工艺相较于传统有机PCB显著复杂化。在生产过程中,CPCB更容易受到机械摩擦、静电干扰、化学腐蚀等因素的影响,从而出现砂眼、划痕、断路等多种缺陷。这些缺陷不仅会降低CPCB的质量和可靠性,还可能严重影响电子设备的正常运行和使用寿命。因此,对CPCB进行高效、精确的缺陷检测,是确保电子产品性能稳定性和长期可靠性的关键。

在缺陷检测领域,技术进步和应用场景的多样化推动了检测方法从传统人工目视检测向视觉检测技术的演变。传统人工目视检测依赖操作人员目测识别缺陷,存在主观性强、效率低、成本高以及数据收集困难等问题,难以满足现代企业对高效、精准检测的需求<sup>[3]</sup>。因此,视觉检测技术逐渐成为半导体行业的主流解决方案<sup>[4]</sup>。视觉检测技术主要包括传统图像处理法、机器学习检测法和深度学习检测法<sup>[5]</sup>。传统图像处理法<sup>[6]</sup>通过提取缺陷的几何或纹理特征进行识别,计算效率较高,但对复杂缺陷的识别能力有限,且对图像质量要求较高。机器学习检测法<sup>[7]</sup>在精度和适应性上有所提升,但其性能依赖特征工程,难以应对复杂背景和多类型缺陷。

近年来,电子信息技术的快速发展推动了基于深度

学习的检测方法在缺陷检测领域的广泛应用<sup>[8]</sup>。这类方法凭借强大的特征提取能力和高精度性能,逐渐成为主流技术,主要包括2类:以基于区域的卷积神经网络(region-based convolutional neural network, R-CNN)<sup>[9]</sup>系列为代表的二阶段检测算法和以单次多框检测器(single shot multibox detector, SSD)<sup>[10]</sup>、YOLO(you only look once)<sup>[11]</sup>系列为代表的一阶段检测算法。相较于二阶段算法,一阶段检测算法通过端到端的方式直接回归目标框,具有更高的检测速度和计算效率,更适合实时性要求较高的工业场景。其中,YOLO系列算法通过将目标检测问题转化为单次回归任务,显著提升了检测效率,同时兼顾了精度与速度的平衡,因此大量学者针对PCB缺陷检测问题提出了多种基于深度学习的解决方案,并取得了显著成果。例如陈俊英等<sup>[12]</sup>针对PCB缺陷检测中样本难收集导致的数据长尾分布、检测精度低及视觉变换器(vision transformer, ViT)计算复杂度高等问题,提出了一种基于多尺度ViT特征提取与注意力融合的端到端算法,为该领域提供了快速有效的解决方案;Hu等<sup>[13]</sup>则采用知识蒸馏技术构建轻量化模型,在检测精度与计算效率之间取得了良好平衡;此外,针对PCB缺陷检测模型因参数量大、复杂度高而难以部署到工业边缘设备的问题,陈枫赟等<sup>[14]</sup>提出了一种基于STR-DETR的轻量化算法,通过重构主干网络、优化注意力机制模块以及设计新的损失函数,显著提升了模型的轻量化水平和检测准确性;张莹等<sup>[15]</sup>则通过优化YOLOv7网络结构,采用浅层特征融合模块、新型锚框(anchors)匹配等策略,显著提升了PCB小目标缺陷的检测性能。这些方法在特征提取、模型轻量化和多尺度检测等关键技术上取得了突破性进展。

然而,相较于传统的PCB,CPCB在缺陷检测研究领域的相关研究文献较少,主要存在的困难与挑战为:首先,CPCB具有更高的材料硬度与更脆的机械性质,在制造过程中更易受到机械应力、静电干扰和化学腐蚀等外界因素的影响,导致其缺陷类型更为复杂和多样,如砂

眼、油污、擦伤及鼠咬等非结构性缺陷。此外,CPCB多应用于航天、通信等高可靠性场景,其对缺陷检测的精度与鲁棒性要求更高。更重要的是,当前缺乏面向CPCB的公开缺陷图像数据集,这在很大程度上制约了智能检测算法的开发与验证。

为应对上述问题,拟构建一个专门面向CPCB缺陷检测的图像数据集,并提出一种基于PXD(ParNet+XsHead+DIoU-NMS,PXD)-YOLO11s的CPCB缺陷检测方法,以提升模型对多类型、小目标缺陷的识别能力。主要创新点为:

- 1) CPCB缺陷数据集构建:首次系统性构建了CPCB缺陷图像数据集,其涵盖多类常见缺陷,填补了公开数据资源的空白,为相关研究提供了基础数据支撑。

- 2) 特征提取结构优化:针对缺陷类型复杂、背景干扰多的问题,引入ParNet(parallel networks)结构嵌入C3k2模块,构建新的C3k2\_ParNet模块,增强模型对多尺度特征的融合与提取能力,提升对复杂缺陷的表达能力。

- 3) 小目标检测能力增强:为解决极小目标缺陷难以识别的问题,在主干网络中引入160×160小目标检测头,提高模型在高分辨率特征图上的感知能力,从而有效提升对微小缺陷的检测精度。

- 4) 后处理策略优化:针对传统的非极大值抑制(non-maximum suppression,NMS)在边界模糊、小目标密集场景中易漏检的问题,引入Soft-NMS策略,通过动态调整重叠框得分,保留潜在目标,降低误删率,提高最终检测的准确性和鲁棒性。

## 1 数据集构建

在微波通信及相关制造领域中,CPCB作为关键基础材料,其质量控制直接关系到电子产品性能的稳定性与可靠性。然而,当前在CPCB缺陷检测领域面临着公开数据资源匮乏的挑战:一方面,现有研究中缺乏专门针对CPCB的标准缺陷数据集;另一方面,CPCB生产过程

中常见的大面积色差、表面物理损伤、表面多余物残留和金属镀层杂质等典型缺陷尚未被任何公开数据集所覆盖。此外,实际采集数据中各类缺陷样本数量分布极不均衡,导致数据集存在严重的类别不平衡问题,进而影响模型训练的效果和泛化能力。针对这些问题,本研究基于工业场景下的采样数据,自建了一个高质量的CPCB缺陷图像数据集,并采用多种图像增强技术提升数据集的可用性和代表性,为后续模型的开发与优化奠定坚实的数据基础。

### 1.1 数据获取

在图像采集环节,针对CPCB板最小缺陷尺寸可能达到1 mm×1 mm的特性,为确保能够精确捕捉表面微观结构和细节特征,本研究采用高分辨率工业数字相机进行静态图像采集,并配置可调角度光源系统以优化成像质量。高分辨率相机在保证图像整体清晰度的同时,能够捕捉微小目标特征;通过合理调节光源方向和角度,有助于抑制反射干扰、提升目标边缘对比度。具体而言,对于不透明的CPCB基板,采用正上方光源(与镜头同轴)以减少阴影;对于透明或半透明板材,则辅以背透光源以增强缺陷轮廓的显现能力。整体图像采集系统强调图像细节保真度与照明均匀性,为缺陷检测提供了高质量的图像基础。

### 1.2 图像预处理

在图像预处理阶段,依据国家军用标准《GJB 548C-2021微电子器件试验方法和程序》<sup>[16]</sup>中关于缺陷的分类与判定标准,结合CPCB生产线上常见缺陷案例,对采集到的771张图像进行系统性地标注与分类。缺陷类型共计14类,包括深度划痕(deep scratches)、表面磨损(abrasions)、毛刺(deburring)、杂散铜(stray copper)、粘连(adhesions)、砂眼(trachoma)、鼠咬(rat bites)、腐蚀(corrosion)、断路(opening)、纤毛(cilium)、色污(pigment)、油斑(oil spots)、覆铜掉落(copper drops)和起层(stratum ories)。图像标注采用LabelImg工具完成,缺陷种类示意如图1所示。

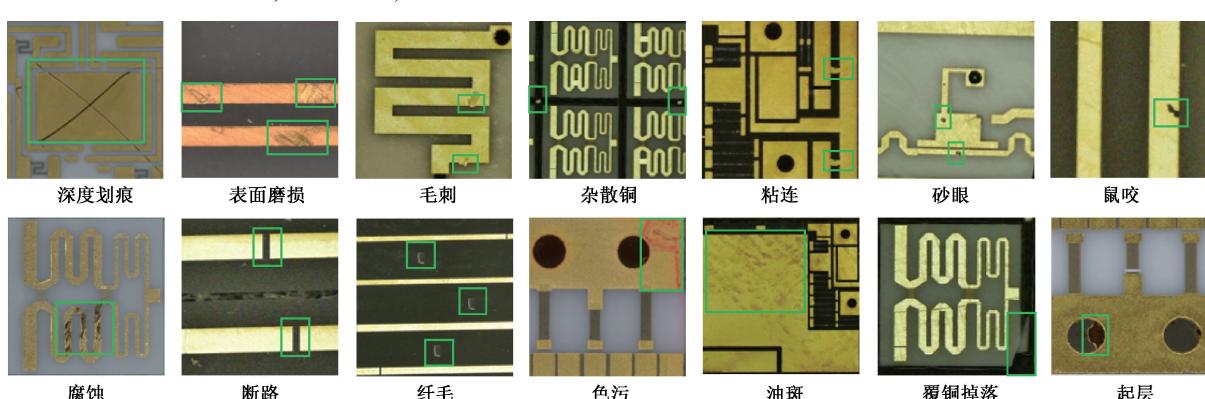


图1 CPCB中常见的缺陷

Fig. 1 Common defects in CPCB

### 1.3 数据增强

为有效缓解类别不平衡对模型训练带来的影响,进一步提升模型的泛化能力,引入了数据增强策略以扩展样本规模和多样性。首先,采用增强工具将原始图像中的目标缺陷区域裁剪并粘贴至新的背景图像中,生成合成图像,并同步更新相应的标注信息,从而提升稀有类别在样本集中的比例。其次,基于 Albumentations 图像增强库,构建了

覆盖几何与光度两类变化的多级增强流程。几何增强包括随机裁剪、旋转反射(D4)、弹性形变、网格扰动与透视变换,模拟实际中位置偏移与目标变形;光度增强包含高斯噪声、图像压缩、亮度对比度扰动与灰度变换,模拟不同照明与成像条件下的图像退化。部分增强效果如图 2 所示。通过上述方法,最终将原始图像扩展至 3 057 张,并按 8:1:1 的比例划分为训练集、验证集与测试集。

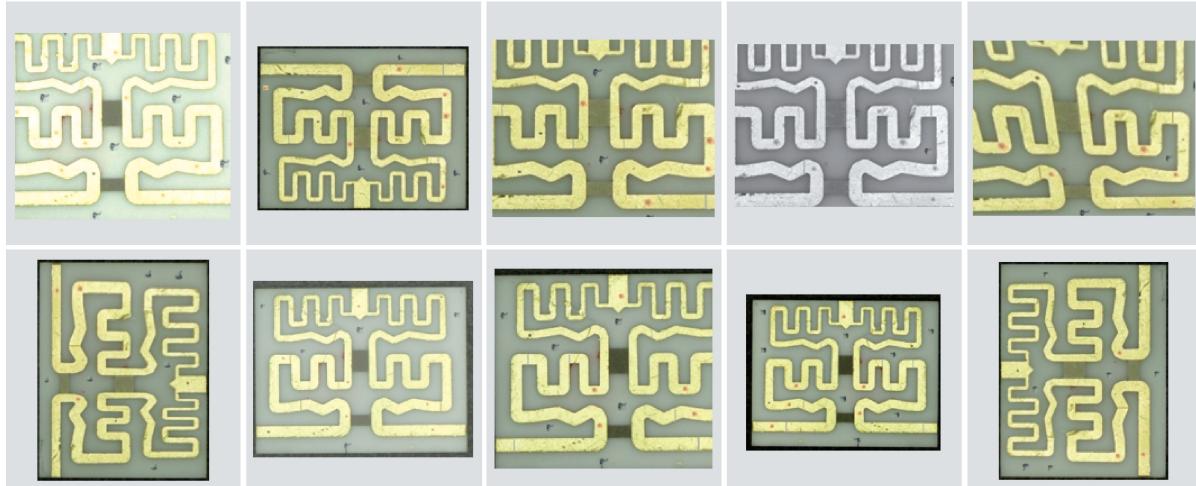


图 2 图像增强结果

Fig. 2 Image enhancement results

### 1.4 数据评估

为了确保目标检测模型在实际应用中具备良好的泛化性和鲁棒性,数据集的划分需保证训练集、验证集与测

试集的目标分布具有一致性。为此,对划分后的数据集开展了多维度可视化分析,绘制了标准化处理后的平滑折线图(如图 3 所示)和缺陷尺寸分布统计图(如图 4 所示)。

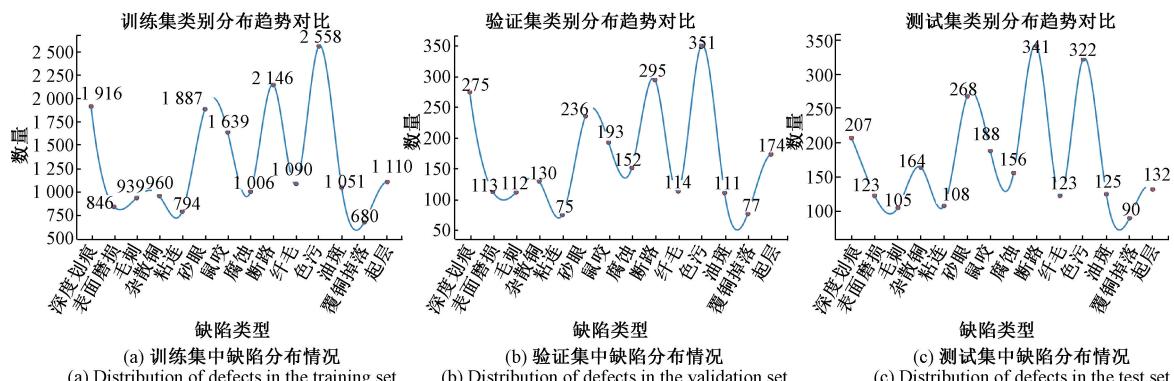


图 3 数据集中缺陷分布情况对比

Fig. 3 Comparison of defect distribution in the dataset

基于训练集、验证集与测试集的缺陷类别分布图可以看出,各类别在不同数据子集中的数量趋势较为一致,整体分布曲线基本重合,说明数据划分在类别维度上实现了良好的均衡性和一致性。从数值来看,“pigment”缺陷数量占比较高,在训练集、测试集、验证集中的占比分别为 13.74%、14.58%、13.13%,三者百分比差异均不超

过 1%,表现出较高的一致性。而“copper drops”缺陷数量相对较少,在 3 个子集中的占比分别为 3.66%、3.20%、3.67%,同样保持了较为稳定的分布比例,进一步体现了数据划分在比例控制上的精确性和合理性。

缺陷面积区间分布对比图显示,3 类子集在  $<16 \text{ px}^2$ 、 $16 \sim 64 \text{ px}^2$ 、 $>64 \text{ px}^2$  这 3 个尺度区间的缺陷数量趋势高

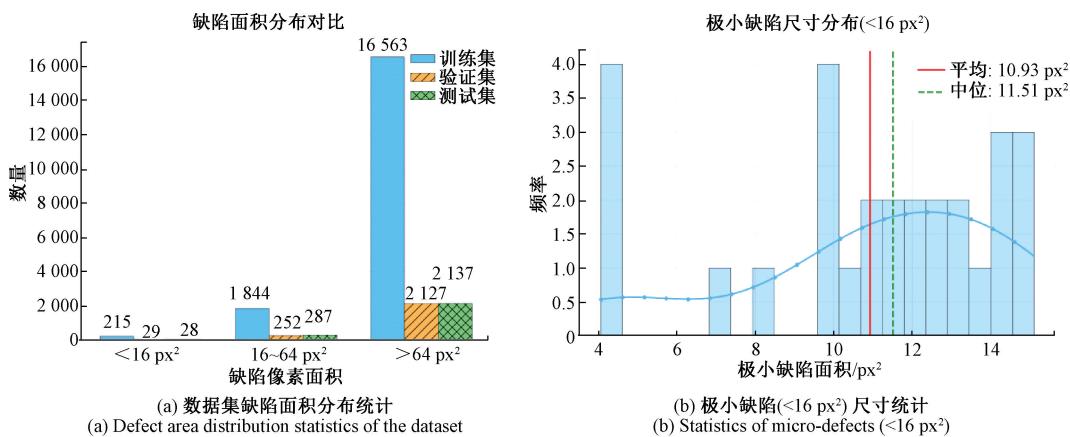


图4 缺陷尺寸分布统计分析  
Fig. 4 Statistical analysis of defect size distribution

度重合,结合数值统计可证明多尺度面积维度分布的均衡性。此外,通过极小缺陷(面积<16 px<sup>2</sup>)尺寸分布的直方图及统计量显示,不同数据集的极小缺陷面积分布形态、尺寸跨度及频率变化趋势相似,平均面积、中位数等统计量差异较小,表明数据集在细粒度尺寸特征维度上也保持高度一致。

上述分布结果从视觉趋势与数值统计两个层面表明,3个数据子集的各类别分布均衡且差异较小,有效避免了训练偏倚,为模型训练提供了稳定可靠的数据基础。

## 2 改进的PXD-YOLO11s网络

YOLO11<sup>[17]</sup>是由Ultralytics团队推出的一款前沿且先进的SOTA(state-of-the-art)模型,该模型不仅保留了

YOLOv8的核心功能,例如实例分割(instance segmentation)、姿态估计(pose estimation)和定向目标检测(oriented object detection),还提供了从纳米级(nano)到超大型(extra large)的5种可扩展版本,以适应不同的应用场景。该模型在目标检测任务中表现出色,尤其是在复杂场景下的检测性能显著提升。为了平衡检测速度和精度,选择YOLO11s作为CPCB缺陷检测的基线模型。

所提出的PXD-YOLO11s网络结构如图5所示。为提升模型在CPCB缺陷检测中的表现,围绕特征提取、检测结构与后处理3方面进行了针对性改进:在主干网络中引入并行特征融合模块以增强表征能力,增设高分辨率检测头以提升小目标识别效果,并在后处理阶段引入Soft-NMS以优化边界框筛选策略。上述改进相互协同,显著提升了模型在复杂场景下的检测精度与鲁棒性。

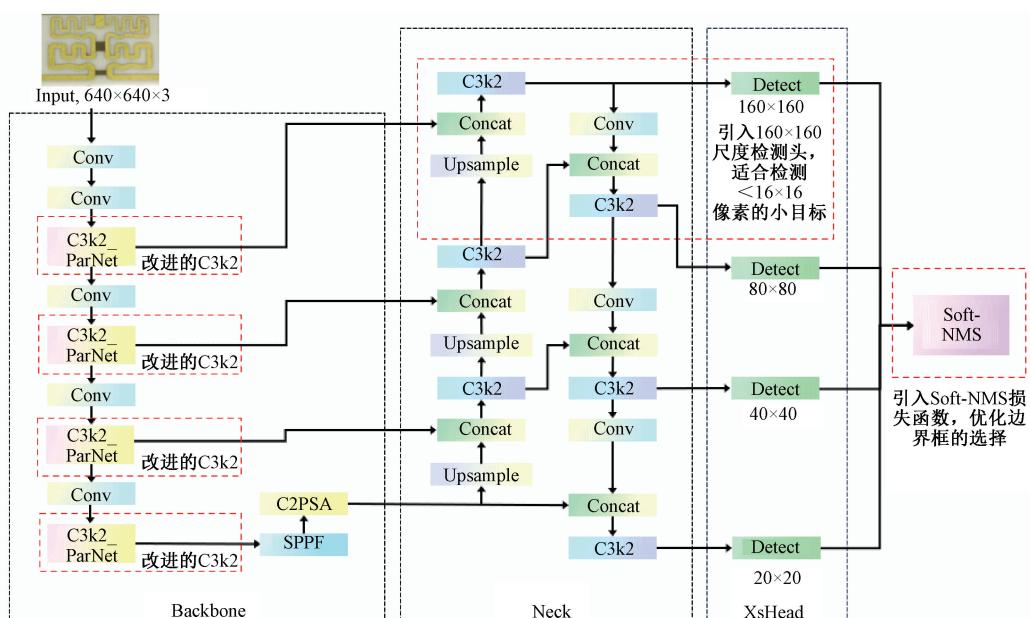


图5 改进的PXD-YOLO11s模型结构  
Fig. 5 Improved PXD-YOLO11s model architecture

## 2.1 卷积层结构优化

在 CPCB 缺陷检测中, YOLO11s 模型的 C3k2 模块因采用顺序堆叠卷积层进行特征提取, 在处理多尺度特征和复杂纹理时表现不足, 尤其是在应对微小缺陷和复杂背景时, 容易导致检测精度的下降。为了解决这一问题, 将 ParNet 模块引入 C3k2 模块, 构建了新的 C3k2\_ParNet 模块, 如图 6 所示。

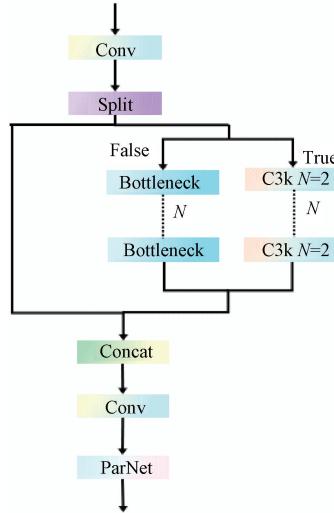


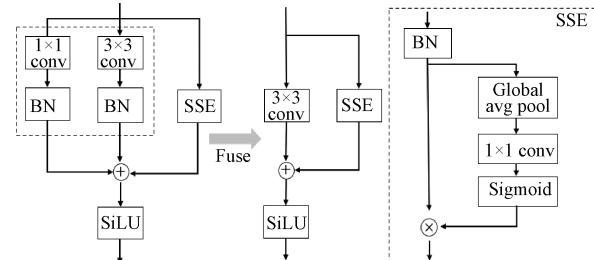
图 6 C3k2\_ParNet 模块网络结构

Fig. 6 C3K2\_ParNet module network architecture diagram

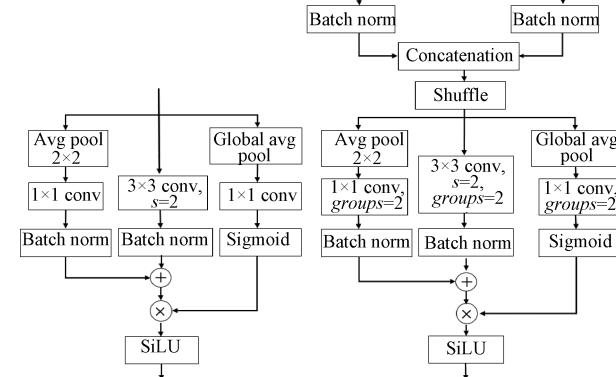
该模块将初始卷积结果拆分为两个分支: 一支直接保留, 另一支通过多个 Bottleneck 或 C3k 模块进一步提取特征。随后将所有分支结果沿通道维度拼接形成多尺度特征, 最后通过最终卷积层和 ParNet 模块调整通道数并增强重要特征, 从而提升模型对多尺度缺陷特征的提取能力。

其中 ParNet<sup>[18]</sup> 是一种采用多支路并行结构的神经网络。与 C3k2 的顺序堆叠不同, 其遵循“极易并行化”的设计理念, 多个子网络除起始和末端外无其他连接, 在降低网络深度的同时保持了较高精度。ParNet 的核心模块包括 RepVGG-SSE 块、融合模块和下采样模块, 如图 7 所示。

RepVGG-SSE 块基于 Rep-VGG<sup>[19]</sup> 初始块改进, 通过  $1 \times 1$  卷积分支、 $3 \times 3$  卷积分支及跳过连接分支上的激励 (stream-specific enhancement, SSE)<sup>[20]</sup> 实现了多尺度特征融合。SSE 分支在不增加网络深度的情况下扩大了感受野, 增强了细粒度特征提取能力。此外, 采用 SiLU (sigmoid linear unit) 激活函数替代 ReLU (rectified linear unit), 进一步增强了模型的非线性表达能力。下采样模块用于降低特征图的分辨率并提升通道宽度, 以促进多尺度特征处理。融合模块用于整合来自不同分辨率支路的特征信息, 其结构与下采样模块类似, 但额外增加了 Concat 操作, 以融合多尺度特征。



(a) RepVGG-SSE 结构  
(a) RepVGG-SSE architecture diagram



(b) 训练下采样(左)和融合(右)模块示意图  
(b) Dow nsam-ping (left) and schematic diagram of the fusion (right) modules

图 7 ParNet 核心模块

Fig. 7 Core module of ParNet

## 2.2 小目标检测优化

在 CPCB 缺陷数据集中, 多数缺陷为极小的微米级缺陷。YOLO11 原模型的检测头网格划分为  $80 \times 80$ 、 $40 \times 40$  及  $20 \times 20$  这 3 个尺度, 虽实现了对不同大小目标的检测, 但在实际应用中,  $80 \times 80$  网格大小的特征层对小于  $16 \text{ pixels} \times 16 \text{ pixels}$  的目标可能存在漏检问题, 从而影响算法对小目标的检测精度。

针对这一问题, 增设了  $160 \times 160$  尺度的检测头, 命名为 XsHead, 进一步优化了模型对小目标的检测能力。 $160 \times 160$  尺度的特征层具有更高的分辨率, 能够更精细地捕捉小于  $16 \text{ pixels} \times 16 \text{ pixels}$  的小目标特征, 从而有效减少小目标的漏检情况。相比于  $80 \times 80$  尺度,  $160 \times 160$  尺度在特征提取过程中保留了更多细节信息, 显著提升了小目标的检测效果。通过引入  $160 \times 160$  检测尺度, 模型的多尺度检测能力得到了进一步增强。这种改进不仅提高了算法对小目标的适应性, 还通过多尺度特征的互补融合, 提升了整体检测精度和鲁棒性, 使其能够更好地应对复杂场景下的目标检测需求。

## 2.3 非极大值抑制改进

在目标检测的后处理阶段, 传统的 NMS 算法<sup>[21]</sup> 通过设定重叠阈值来抑制冗余检测框。然而, 当某个检测框与最高得分的检测框 M 具有较大重叠时, 其得分会被

直接置为0,可能导致目标遗漏,降低检测的平均精度(average precision, AP)。为了解决这一问题,采用Soft-NMS算法<sup>[22]</sup>对传统NMS进行改进。其核心在于通过平滑的得分衰减策略代替直接剔除,动态调整重叠框置信度得分,从而避免对潜在目标的过度抑制,有效提升召回率与检测精度,尤其适合目标密集或遮挡场景。

Soft-NMS提出线性与高斯2种衰减策略:其中,式(1)为线性衰减函数,在候选框与最高得分框的交并比(intersection over union, IoU)超过阈值 $N_t$ 时,按重叠比例线性降低其得分;式(2)为高斯衰减函数,使用指数函数对得分进行柔和衰减,并由参数 $\sigma$ 控制衰减速率。

$$s_i = \begin{cases} s_i, & IoU(M, b_i) < N_t \\ s_i(1 - IoU(M, b_i)), & IoU(M, b_i) \geq N_t \end{cases} \quad (1)$$

$$s_i = s_i e^{-\frac{IoU(M, b_i)^2}{\sigma}}, \quad \forall b_i \notin D \quad (2)$$

式中: $s_i$ 表示候选框 $b_i$ 的置信度得分,用于衡量该框为真实目标的可能性; $b_i$ 表示第*i*个候选框; $M$ 表示当前得分最高的候选框;函数 $IoU(M, b_i)$ 表示候选框 $b_i$ 与最大得分框 $M$ 之间的IoU,用于度量重叠程度; $N_t$ 表示一个设定的IoU阈值,用于判断是否对候选框的得分进行抑制;集合 $D$ 表示已经被选中的最终检测框集合; $\sigma$ 是控制高斯衰减幅度的超参数。

### 3 实验与分析

#### 3.1 实验配置与评价指标

实验配置如表1所示,环境参数batchsize、epoch、学习率和动量分别为32、300、0.01和0.937。

表1 实验配置与参数

Table 1 Experimental configuration and parameters

名称	配置
操作系统	Ubuntu 18.04 LTS
CPU	Intel Xeon(R) Gold 6254 CPU @ 3.10 GHz
GPU	Quadro RTX 8000 48 Gx2
CUDNN	10.2
Python	3.6.15
Pytorch	1.10.0

表2 不同模块的消融实验对比

Table 2 Comparison of ablation experiments of different modules

方法	ParNet	XsHead	Soft-NMS	mAP50/%	mAP(50~95)/%	precision/%	recall/%	FPS
1				84.00	59.50	89.10	76.70	<b>108.70</b>
2	√			85.20	62.30	90.30	77.80	84.75
3	√	√		<b>89.30</b>	67.60	92.00	83.50	66.67
4	√	√	√	89.20	<b>68.00</b>	<b>92.20</b>	<b>84.10</b>	67.57

采用多个指标对CPCB缺陷检测模型的性能进行评估,包括精度(precision)、召回率(recall)、平均精确率(mean average precision, mAP)、每秒帧数(frames per second, FPS)和计算量(giga floating-point operations per second, GFLOPs)。具体公式如式(3)~(6)所示。

$$P = \frac{TP}{TP + FP} \quad (3)$$

$$R = \frac{TP}{TP + FN} \quad (4)$$

$$AP = \int_0^1 P(R) dR \quad (5)$$

$$mAP = \frac{\sum_{j=1}^C AP_j}{C} \quad (6)$$

其中,mAP主要衡量模型的检测精度,包含mAP@50(mAP50)和mAP@50~95(mAP(50~95))。mAP@50计算IoU阈值为0.5时的平均精度,用于衡量模型在标准检测条件下的表现,而mAP@50~95则在IoU阈值为0.50~0.95(步长为0.05)计算平均精度,能够更全面反映模型的检测能力。precision衡量检测结果中正确预测的比例,即预测为目标的框中有多少是正确的,而recall则衡量所有真实目标中被正确检测出的比例,表示模型对目标的检出能力。FPS用来衡量模型在实时检测任务中的处理速度,表示每秒钟模型可以处理多少帧图像。GFLOPs用于衡量模型的计算复杂度,数值越大表明模型对计算资源的需求越高,通常与推理速度、硬件部署成本直接相关。

#### 3.2 消融实验

为了验证改进后模型各模块的有效性,以YOLO11s为基准方法,设计了一组消融实验。实验中逐步引入ParNet、XsHead及Soft-NMS这3个关键模块,并在本地自制数据集上进行了对比分析。实验结果如表2所示,其中“√”表示模型含有该模块。

由表2中数据可以看出,基准模型的mAP50和mAP(50~95)分别为84.00%和59.50%,推理速度为108.7fps,但其precision和recall相对较低。引入ParNet模块后,模型的mAP50提升至85.20%,mAP(50~95)显著提升了2.8%,precision和recall分别提升至90.30%和77.80%,说明ParNet增强了模型的特征提取能力。在进

一步加入小目标检测头 XsHead 后,模型性能大幅提升, mAP50 和 mAP(50~95) 分别达到 89.30% 和 67.60%, recall 提升了 5.7%, 表明 XsHead 有效减少了小目标的漏检, 使检测效果大大提升。最后, 通过引入 Soft-NMS 进行后处理优化, 模型在保持高 mAP50(89.20%) 的同时, mAP(50~95) 进一步提升至 68.00%, recall 提升至 84.10%, 且推理速度稳定在 67.57 fps, 说明 Soft-NMS 在提升检测质量的同时, 对计算效率影响较小。

总体而言, 这 3 个模块的协同优化使得最终模型的 mAP50 和 mAP(50~95) 分别提升了 5.2% 和 8.5%, precision 和 recall 分别提高了 3.1% 和 7.4%。最终推理速度为 67.57 fps, 满足工业实时检测的需求<sup>[23]</sup>。其中, XsHead 对检测性能的提升最为显著。以上实验结果充分验证了所提出的改进策略在提升 CPCB 缺陷检测精度的同时, 仍具备良好的实际应用价值。

为了充分发挥改进的损失函数的优势, 将多种改进的 IoU 计算方法, 与 Soft-NMS 相结合, 分别构建了 CIoU-NMS、GIoU-NMS、DIoU-NMS 和 EIIoU-NMS 算法。为了验证不同 IoU 变体在 Soft-NMS 中的性能差异, 设计了消融实验, 实验结果如表 3 所示。

由表 3 中数据可知, DIoU-NMS 在 mAP50 和 mAP(50~95) 上表现最优, 分别达到 89.2% 和 68.0%, 同时召

表 3 损失函数消融实验对比

Table 3 Comparison of loss function ablation experiments

(%)

损失函数	mAP50	mAP(50~95)	precision	recall
CIoUNMS	89.20	67.40	92.50	83.70
GIoUNMS	88.90	67.20	<b>93.70</b>	82.70
DIoUNMS	<b>89.20</b>	<b>68.00</b>	92.20	<b>84.10</b>
EIoUNMS	88.90	66.80	93.30	82.30

回率也最高, 为 84.1%。由此可见, 改进的 DIoU-NMS 损失函数在综合性能上表现最佳, 有助于模型在处理重叠框和复杂场景时表现更佳。

为探究检测头配置对模型性能的影响, 在其他改进保持不变的前提下设计 3 组消融实验: 第 1 组采用原始 YOLOv1s 检测头作为基线, 确立性能参考; 第 2 组在基线基础上新增 160×160 分辨率检测头(XsHead), 可覆盖 8~16 pixels 小目标; 第 3 组进一步引入 320×320 分辨率检测头(UsHead), 以覆盖 4~8 pixels 超小缺陷。通过对不同配置下的模型表现, 系统验证检测头尺度对亚毫米级缺陷检测能力的提升效果, 实验结果如表 4 所示, 其中“√”表示模型含有该模块。

表 4 检测头消融实验对比

Table 4 Ablation experiment comparison of detection heads

方法	XsHead	UsHead	mAP50/%	mAP(50~95)/%	precision/%	recall/%	GFLOPs
1			85.50	62.80	89.70	77.60	<b>42.50</b>
2	√		89.20	68.00	<b>92.20</b>	<b>84.10</b>	49.80
3	√	√	<b>89.60</b>	<b>72.80</b>	91.30	80.80	76.50

从表 4 中数据来看, 仅引入 XsHead 检测头时, 模型性能表现优异。相比基线模型, 其 mAP50 从 85.50% 提升至 89.20%, mAP(50~95) 从 62.80% 提升至 68.00%, 精确率和召回率也分别提升至 92.20% 和 84.10%, 显著增强了对小目标的检测能力。计算效率方面, GFLOPs 从 42.50 增至 49.80, 虽略有增长, 但相较于性能的提升幅度, 计算开销仍处于可接受范围内。

进一步加入 UsHead 后, mAP(50~95) 虽略有提升, 但 GFLOPs 飙升至 76.50, 较仅引入 XsHead 时增加了 26.70%, 显著提高了计算成本, 降低了模型的推理速度, 不利于实际部署。同时, precision 下降 0.90%, recall 下降 3.30%, 说明虽然模型对部分极小缺陷的敏感性增强, 但整体检测的稳定性和准确性反而有所下降。因此, 仅引入 XsHead 检测头在检测精度、计算效率和工程实用性之间达到了最优平衡, 既能有效识别亚毫米级缺陷, 又避免了计算资源的浪费, 具备更强的实际应用价值。

### 3.3 对比实验

为全面验证所提出的算法相较于现有主流算法的优越性, 将所提出的模型与 Faster R-CNN、SSD、RT-DETR (real-time detection transformer)<sup>[24]</sup>、YOLOv5s、YOLOv7-tiny、YOLOv8s、YOLOv9s 和 YOLOv10s 等具有代表性的目标检测模型基于相同数据集与训练环境进行了对比实验, 结果如表 5 所示。

Faster R-CNN 作为典型的两阶段检测框架, 其在小目标检测任务中表现存在明显不足。具体而已, 其 mAP50 和 mAP(50~95) 分别为 70.90% 和 44.50%, precision 仅有 34.30%, 说明其在复杂背景下容易产生较多的误检。SSD 作为早期经典的单阶段网络, 在本地数据集上的整体表现偏弱, mAP50 仅为 25.20%, mAP(50~95) 为 12.50%, precision 仅为 14.80%, 说明其特征提取与多尺度融合能力已难以满足当前检测任务的精度需求。RT-DETR 作为近年基于 Transformer 结构的代表性

表5 各算法对比实验结果

Table 5 Comparative results of different algorithms

(%)

方法	<i>mAP50</i>	<i>mAP(50~95)</i>	<i>precision</i>	<i>recall</i>
Faster R-CNN	70.90	44.50	34.30	76.30
SSD	25.20	12.50	14.80	37.00
RT-DETR	70.00	43.70	71.70	64.00
YOLOv5s	86.60	59.00	91.90	82.10
YOLOv7-tiny	76.30	46.20	82.20	76.30
YOLOv8s	84.70	60.80	90.30	77.70
YOLOv9s	82.00	55.70	87.80	73.80
YOLOv10s	82.10	58.70	89.60	74.00
PXD-YOLO11s	<b>89.20</b>	<b>68.00</b>	<b>92.20</b>	<b>84.10</b>

检测模型,其在 *mAP50* 和 *mAP(50~95)* 分别达到 70.00% 和 43.70%, *precision* 为 71.70%, 虽然优于传统方法,但在小目标和高重叠场景下仍存在一定局限性。

在 YOLO 系列中, YOLOv5s 作为较早期的轻量化检测模型,已实现较高的检测性能, *mAP* 为 86.60%, *mAP(50~95)* 为 59.00%, *precision* 达到 91.90%, 表现稳定, 具有较好的实际部署价值。然而其特征提取结构相对传统, 面对复杂背景或小目标仍存在性能瓶颈。YOLOv7-tiny 作为超轻量部署模型, 虽然在速度方面具备优势, 但其 *mAP(50~95)* 仅为 46.20%, *precision* 为 82.20%, 难以兼顾检测精度需求。YOLOv8s 引入 RepConv 结构以增强

特征表达能力, *mAP(50~95)* 提升至 60.80%, *precision* 也达到 90.30%, 性能较为均衡。YOLOv9s 通过引入动态感受野机制增强上下文建模能力, 虽 *mAP50* 达 82.00%, 但 *mAP(50~95)* 为 55.70%, 在复杂场景中的稳定性仍有待提升。YOLOv10s 在结构上进一步优化, 整体表现较为平衡, *mAP(50~95)* 为 58.70%, *precision* 为 89.60%。

相较上述方法, 所提出的 PXD-YOLO11s 在多个关键性能指标上均实现领先。具体而言, 模型在 *mAP50* 和 *mAP(50~95)* 方面分别达到 89.20% 和 68.00%, *precision* 和 *recall* 分别提升至 92.20% 与 84.10%。该方法在保证良好部署能力的同时, 进一步提升了小目标检测性能与对复杂背景的适应能力, 较 YOLOv5s、YOLOv8s 等主流轻量化模型展现出更优的性能平衡与更强的实际应用潜力。

### 3.4 可视化对比

为验证所提方法和基线模型在数据集上的性能差异, 采用 YOLO11s 模型与 PXD-YOLO11s 对数据集中的缺陷类别进行定性分析, 并通过可视化展示检测效果(如图 8 所示)。从图 8 中可以看出, 原始 YOLO11s 算法在部分缺陷类别上存在一定程度的漏检、误检现象, 且检测置信度普遍偏低。相比之下, 所提模型不仅降低了漏检率和误检率, 特别对于砂眼、杂散铜等细小缺陷的检测准确率有所提升。此外, 在多目标密集分布场景下, 模型依然保持了良好的检测性能, 能够有效区分相邻或重叠的缺陷目标。

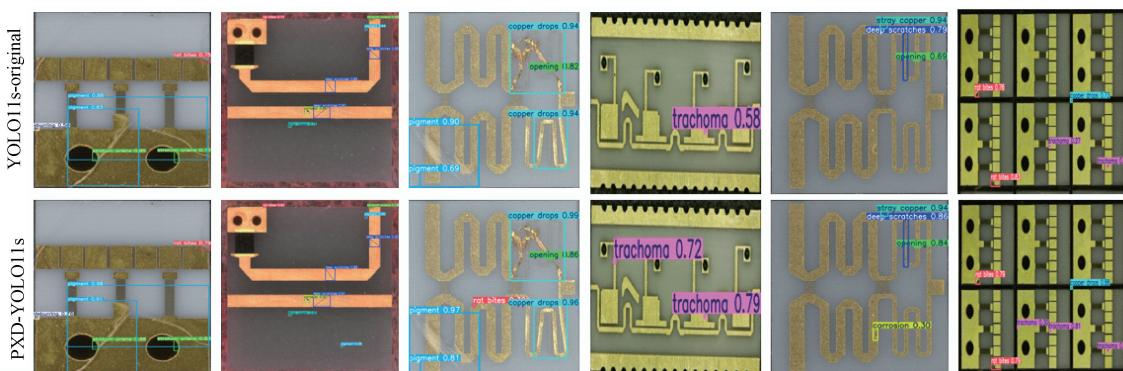


图 8 PXD-YOLO11s 与 YOLO11s 检测结果可视化对比

Fig. 8 Visual comparison of detection results between PXD-YOLO11s and YOLO11s

改进前后的模型在多个关键性能指标上的对比如图 9 所示, 展示了原始 YOLO11s 模型与改进后的 PXD-YOLO11s 模型在 *mAP50*、*mAP(50~95)*、召回率以及边界框损失等指标上的训练曲线对比。

如图 9 所示, 图 9(a) 和 (b) 分别展示了 YOLO11s 原始模型与改进后的 PXD-YOLO11s 在 *mAP50* 和 *mAP(50~95)* 两个指标上的对比曲线。从图 9(a) 和 (b)

中可以明显看出, PXD-YOLO11s 在整个训练过程中均优于原始模型, 并且在训练后期保持了更高的稳定性。具体来说, *mAP50* 快速上升并趋于平稳, 表明 PXD-YOLO11s 在定位准确性方面得到了显著提升; 而 *mAP(50~95)* 持续增长, 也反映出其在不同 IoU 阈值下的检测能力更强, 整体识别精度更高。图 9(c) 展示了召回率在训练过程中的变化情况, 从图 9(c) 中可以看出,

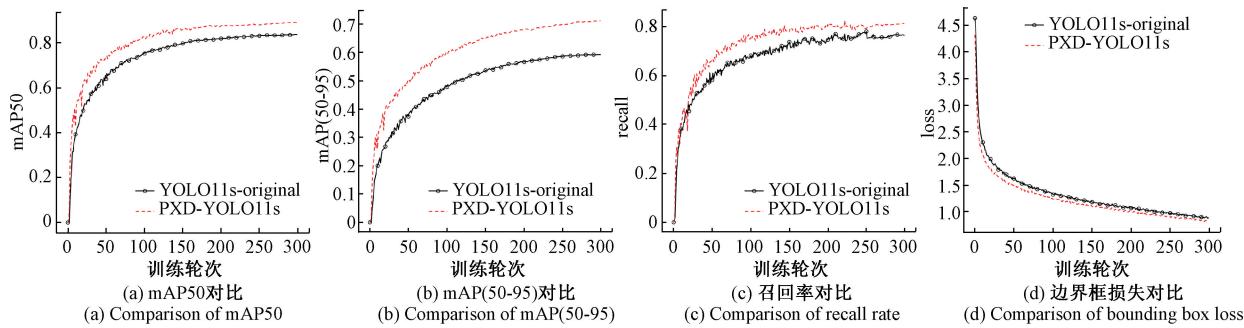


图 9 改进前后性能指标结果对比

Fig. 9 Performance metrics comparison before and after improvement

PXD-YOLO11s 在召回能力上始终优于原始模型, 尤其是在训练初期提升较快, 后期趋于稳定, 表明其对于各类缺陷目标的识别更加全面。图 9(d)展示了 bounding box 损失值的变化情况, 可以看到, PXD-YOLO11s 在训练初期损失值下降较快, 后期整体保持在更低水平, 表明其在边界框回归任务上具有更好的收敛速度和精度, 从而验证了所引入改进模块的有效性。

### 3.5 泛化性对比

鉴于国内 CPCB 缺陷检测领域缺乏公开可用的数据集, 面向该应用场景开展了缺陷检测算法研究。为验证所提模型的泛化性, 选用公开的 PKU-Market-PCB 印刷电路板数据集<sup>[25]</sup>载入模型进行训练, 并与典型的目标检测模型进行对比, 结果如表 6 所示。

表 6 公开数据集上各算法对比实验结果

Table 6 Comparison of experimental results of various algorithms on public datasets (%)

方法	<i>mAP</i> 50	<i>mAP</i> (50~95)
Faster R-CNN	50.10	25.00
SSD	44.30	19.00
YOLOv5s	50.90	23.70
YOLOv7-tiny	15.60	6.54
YOLOv8s	61.00	32.20
YOLOv9s	61.80	33.40
YOLOv10s	64.20	33.40
PXD-YOLO11s	<b>71.80</b>	<b>41.70</b>

上述结果表明, 尽管所提方法面向陶瓷电路板设计, 但其在印刷电路板数据集上仍展现出优异的检测性能, 其 *mAP*50 和 *mAP*(50~95) 指标均优于 Faster R-CNN、SSD、YOLOv5s 等一系列主流目标检测模型, 展现出了良好的泛化性, 验证了多分支并行架构与细粒度特征提取策略的普适性。

## 4 结 论

针对 CPCB 生产中的实际检测需求, 首先制定了 14 类典型缺陷的分类标准, 构建了包含 3 057 张图像的 CPCB 缺陷数据集, 为模型训练与评估提供了可靠的数据支持。在此基础上, 以 YOLO11s 为基础框架, 融合 ParNet 模块以增强特征提取能力, 新增小目标检测头(XsHead)以提升对微小缺陷的识别效果, 并引入 Soft-NMS 机制优化后处理阶段的边界框筛选策略, 构建了改进模型 PXD-YOLO11s。最后, 在自建数据集和公共数据集上的实验结果表明, PXD-YOLO11s 在检测精度和鲁棒性方面均优于传统检测模型和主流 YOLO 系列模型, 充分证明了所提改进策略的有效性和模型的实用价值。

## 参考文献

- [1] LING Q, ISA N A M. Printed circuit board defect detection methods based on image processing, machine learning and deep learning: A survey[J]. IEEE Access, 2023, 11: 15921-15944.
- [2] ZHANG G M, YU ZH H, SONG D S, et al. Directly printed standing ceramic circuit boards for rapid prototyping of miniaturization and high-power of electronics[J]. Nature Communications, 2025, 16(1): 5258.
- [3] CHEN I C, HWANG R C, HUANG H C. PCB defect detection based on deep learning algorithm [J]. Processes, 2023, 11(3): 775.
- [4] ZHAO Y, JIANG ZH D. YOLO-WWB: An optimized YOLO11 algorithm for PCB defect detection[J]. IEEE Access, 2025, 13: 74288-74297.
- [5] CHEN X, WU Y L, HE X Y, et al. A comprehensive review of deep learning-based PCB defect detection[J]. IEEE Access, 2023, 11: 139017-139038.

- [ 6 ] PARK J H, KIM Y S, SEO H, et al. Analysis of training deep learning models for PCB defect detection [ J ]. Sensors, 2023, 23(5): 2766.
- [ 7 ] YU X Y, LI H X, YANG H D. Collaborative learning classification model for PCBs defect detection against image and label uncertainty [ J ]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 3235461.
- [ 8 ] 熊炜, 黄玉谦, 彭鑫旭. 基于改进YOLOv8模型的PCB缺陷检测算法 [ J/OL ]. 电子测量技术, 1-9 [2025-07-02].  
XIONG W, HUANG Y Q, PENG X X. PCB defect detection model based on improved YOLOv8 algorithm [ J/OL ]. Electronic Measurement Technology, 1-9 [2025-07-02].
- [ 9 ] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [ C ]. 2014 IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [ 10 ] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector [ C ]. Computer Vision-ECCV 2016, 2016: 21-37.
- [ 11 ] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [ C ]. 29th IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [ 12 ] 陈俊英, 李朝阳, 席月芸, 等. ViT和注意力融合的类别不均衡PCB缺陷检测方法 [ J ]. 仪器仪表学报, 2024, 45(4): 294-306.  
CHEN J Y, LI Z H Y, XI Y Y, et al. ViT and attention fusion for class-imbalanced PCB defect detection [ J ]. Chinese Journal of Scientific Instrument, 2024, 45(4): 294-306.
- [ 13 ] HU ZH L, ZHANG ZH, LIU SH B, et al. ASTKD-PCB-LDD: High-performance PCB defect detection model with align soft-target knowledge distillation and lightweight network design [ J ]. The Journal of Supercomputing, 2025, 81(4): 531.
- [ 14 ] 陈枫赟, 李鹏. 基于STR-DETR的轻量化PCB缺陷检测算法 [ J ]. 电子测量与仪器学报, 2025, 39(6): 30-40.  
CHEN F Y, LI P. Lightweight PCB defect detection algorithm based on STR-DETR [ J ]. Journal of Electronic Measurement and Instrumentation, 2025, 39(6): 30-40.
- [ 15 ] 张莹, 邓华宣, 王耀南, 等. 基于多通道特征融合学习的印制电路板小目标缺陷检测 [ J ]. 仪器仪表学报, 2024, 45(5): 10-19.  
ZHANG Y, DENG H X, WANG Y N, et al. Small defects detection of PCB based on multi-channel feature fusion learning [ J ]. Chinese Journal of Scientific Instrument, 2024, 45(5): 10-19.
- [ 16 ] 中央军委装备发展部. 微电子器件试验方法和程序: GJB 548C-2021 [ S ]. 军用标准, 2021.  
Equipment Development Department of the Central Military Commission. Test methods and procedures for microelectronic devices: GJB 548C-2021 [ S ]. Military Standard, 2021.
- [ 17 ] RASHEED A F, ZARKOOSH M. YOLOv11 optimization for efficient resource utilization [ J ]. The Journal of Supercomputing, 2025, 81(9): 1085.
- [ 18 ] GOYAL A, BOCHKOVSKIY A, DENG J, et al. Non-deep networks [ J ]. Advances in Neural Information Processing Systems, 2022, 35: 6789-6801.
- [ 19 ] DING X H, ZHANG X Y, MA N N, et al. RepVGG: Making vgg-style convnets great again [ C ]. 2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13733-13742.
- [ 20 ] HU J, SHEN L, SUN G. Squeeze-and-excitation networks [ C ]. 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018: 7132-7141.
- [ 21 ] SINGH K, KHARCHE S, CHAUHAN A, et al. PCB defect detection methods: A review of existing methods and potential enhancements [ J ]. Journal of Engineering Science and Technology Review, 2024, 17(1): 156-167.
- [ 22 ] BODLA N, SINGH B, CHELLAPPA R, et al. Soft-NMS-improving object detection with one line of code [ C ]. 2017 IEEE International Conference on Computer Vision. 2017: 5562-5570.
- [ 23 ] CHEN I C, HWANG R C, HUANG H C. PCB defect detection based on deep learning algorithm [ J ]. Processes, 2023, 11(3): 775.
- [ 24 ] ZHAO Y AN, LYU W Y, XU SH L, et al. DETRs beat YOLOs on real-time object detection [ C ]. 2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 16965-16974.

- [25] 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.

### 作者简介



杨思念,2022 年于西南石油大学获得学士学位,现为四川轻化工大学计算机科学与工程学院硕士研究生,主要研究方向为目标识别。

E-mail:ysn1903437825@163.com

**Yang Sinian** received her B. Sc. degree from SouthWest Petroleum University in 2022. She is currently a M. Sc. candidate in the School of Computer Science and Engineering at Sichuan University of Science & Engineering. Her main research interest includes target recognition.



曹立佳(通信作者),2005 年于第二炮兵工程学院获得学士学位,2008 年于第二炮兵工程学院获得硕士学位,2012 年于第二炮兵工程大学获得博士学位,现为四川轻化工大学教授,主要研究方向为无人系统导航与控制、智能目标检测技术等。

E-mail:caolj@suse.edu.cn

**Cao Lijia** ( Corresponding author ) received his B. Sc. , M. Sc. , and Ph. D. degrees all from Second Artillery Engineering College in 2005, 2008 and 2012, respectively. Now he is a professor at Sichuan University of Science & Engineering. His main research interests include unmanned system navigation and control, intelligent object detection technology, etc.