

基于 PMAC-YOLO 的轻量级 PCB 缺陷检测方法^{*}

郑佳丽 董 凌 李 恒 薛晓军 刘 辉

(昆明理工大学信息工程与自动化学院 昆明 650500)

摘 要:针对现有 PCB 缺陷检测方法计算负担重、难以满足实时轻量化需求的问题,设计了一种轻量级印刷电路板缺陷检测模型 PMAC-YOLO。为实现精度与轻量化的高效平衡,模型设计 3 大核心优化模块:首先,通过构建轻量级 C3k2_PMLCA 模块,融合部分卷积 PConv 与混合局部通道注意力 MLCA 机制,增强模型在复杂背景下对小目标特征的提取与感知能力;其次,设计 ADSdown 自适应深度可分离下采样模块,实现轻量化下采样并动态调节信息保留程度;此外,引入跨尺度特征融合 CCFM 模块,融合多尺度特征以增强模型对尺度变化的适应能力,提升小目标缺陷的检测精度。实验在 DeepPCB 数据集及 HRIPCB 增强数据集上进行验证,结果显示,PMAC-YOLO 的 mAP@0.5 分别达到 98.8% 和 99.1%,较基准模型 YOLOv11 提升 0.3% 和 0.4%,同时参数量降低至 1.22×10^{-6} ,计算量降低至 3.4 GFLOPs,模型权重文件尺寸仅为 2.8 MB,分别较基准降低 52.64%、46.03% 和 49.09%。研究表明,PMAC-YOLO 在显著降低模型复杂度与资源占用的同时,保持了优异甚至更优的检测精度,成功实现了精度与轻量化的有效平衡,为 PCB 缺陷实时检测提供了可行的轻量化解决方案。

关键词: PCB 缺陷检测;轻量级模型;部分卷积;MLCA;ADSdown;CCFM

中图分类号: TN41;TP391.41

文献标识码: A

国家标准学科分类代码: 510.4050

The lightweight PCB defect detection method based on PMAC-YOLO

Zheng Jiali Dong Ling Li Heng Xue Xiaojun Liu Hui

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: To address the issues of heavy computational burden and difficulty in meeting real-time lightweight requirements of existing PCB defect detection methods, this study designs a lightweight printed circuit board defect detection model named PMAC-YOLO. To achieve an efficient balance between accuracy and lightweight requirements, the model is designed with three core optimized modules: first, a lightweight C3k2_PMLCA module is constructed by fusing partial convolution with the mixed local channel attention mechanism, enhancing the model's ability to extract and perceive small-target features in complex backgrounds. Second, an ADSdown adaptive depthwise separable downsampling module is proposed to achieve lightweight downsampling while dynamically adjusting the degree of information retention. Additionally, a cross-scale feature fusion module is introduced to fuse multi-scale features, thereby improving the model's adaptability to scale variations and the detection accuracy of small-target defects. Experiments are conducted on the DeepPCB dataset and the HRIPCB enhanced dataset. The results demonstrate that PMAC-YOLO achieves mAP@0.5 of 98.8% and 99.1% respectively, representing an improvement of 0.3% and 0.4% compared to the baseline model YOLOv11. Meanwhile, the number of parameters is reduced to 1.22×10^{-6} , the computational complexity is decreased to 3.4 GFLOPs, and the model weight file size is only 2.8 MB, which are 52.64%, 46.03%, and 49.09% lower than those of the baseline, respectively. These results indicate that PMAC-YOLO significantly reduces model complexity and resource consumption while maintaining excellent or even superior detection accuracy, successfully achieving an effective balance between accuracy and lightweight performance. This study provides a feasible lightweight solution for real-time PCB defect detection.

Keywords: PCB defect detection; lightweight model; partial convolution; MLCA; ADSdown; CCFM

0 引言

随着现代制造业的飞速发展,印刷电路板(printed circuit board, PCB)正朝着高精度、微型化和集成化方向发展,PCB 作为电子产品的核心部分,直接影响产品性能^[1]。由于 PCB 制作过程中任何缺陷都会显著影响其性能,所以高效精准的缺陷检测至关重要^[2]。

早期 PCB 生产主要依靠人工检查表面缺陷,随行业发展,人工检测难以满足大规模生产的高效需求,且不利于数据分析和工艺优化^[3]。传统图像处理方法是最早应用于 PCB 缺陷检测的自动化技术之一^[4],Malge 等^[5]提出了基于形态学图像分割的检测与分类系统,而 Gaidhane 等^[6]提出了无需计算特征值和特征向量的高效检测方法。这些方法提高了检测准确性,但难以应对 PCB 设计的多样性和复杂缺陷,逐渐被机器学习方法取代。传统机器学习方法通过提取特征,结合分类器进行缺陷检测与分类,Li 等^[7]提出了一种结合梯度方向信息熵与局部二值模式特征,并采用支持向量机训练分类器进行缺陷检测与识别的方法。

深度学习方法在图像识别和目标检测领域取得显著成功,广泛应用于 PCB 缺陷检测^[8]。目标检测分为两阶段检测和单阶段检测。两阶段检测方法,如 Faster R-CNN,计算资源需求大且速度较慢,难以满足工业流水线的需求。单阶段检测算法,如单次多框检测器(single shot multibox detector, SSD)和 YOLO(you only look once)系列,通过直接回归预测目标位置和类别,具有较高效率。Kang 等^[9]提出的多层 SSD 和 Shi 等^[10]提出的 SSDT 在 PCB 数据集上均取得较高的平均精度均值(mean average precision, mAP),分别达 95.91% 和 97.85%。与两阶段检测算法相比,YOLO 系列算法由于端到端设计,检测速度更快。Chen 等^[11]提出 Transformer-YOLO 的 PCB 缺陷检测算法,在 HRIPCB 增强数据集上 mAP 为 97.04%,检测速度为 21 fps,模型大小 93.95 MB。Tang 等^[12]提出一种基于 YOLOv5 的改进算法 PCB-YOLO,在同一数据集中 mAP 为 95.97%,模型大小 92.30 MB。杨永跃等^[13]以 YOLOv5 为基础,通过数据增强、增加检测头、引入 CBAM 注意力模块与 Transformer 模块等,提升了 PCB 缺陷检测的 mAP 精度至 90.8%。Shi 等^[14]提出基于 YOLOv8n 的 DVCW-YOLO 算法, mAP 为 99.3%。Lim 等^[15]基于 YOLOv5 提出了一种增强的深度学习网络,实现了 99.17% 的平均精度。Chen 等^[16]提出的 YOLO-DHGC 检测方法在 HRIPCB 数据集上实现了 96.3% 的检测精度。Zhang 等^[17]提出的 SF-YOLO 改进后 mAP@0.5 为 93%,精确率为 97%,模型大小 5.4 MB。Li 等^[18]提出的 EL-PCBNet 在 Deep-PCB 和 HRIPCB 数据

集上 mAP 分别达 98.5% 和 97.5%,模型大小为 11.4 MB。Wang 等^[19]提出的轻量级 PCB 缺陷检测算法,在 HRIPCB 数据集上 mAP 为 96.1%,召回率为 94.0%,模型权重为 5.2 MB。然而,由于区域建议阶段的筛选的缺乏,单阶段算法在复杂背景下容易产生误检,且部分轻量化网络导致特征提取能力不足。

在 PCB 缺陷检测中,高密度的缺陷与背景颜色纹理相似,容易导致背景误检,且 PCB 缺陷缺陷占据图像较小且呈现多种形态,增加了检测难度。现有方法虽提高了精度,但增加了计算负担,尤其在资源受限的边缘设备上难以部署。YOLO 系列算法在单阶段检测中相较其他模型具有较高的准确性、速度和部署优势。为解决检测速度与精度的平衡问题,本文基于 YOLOv11 提出了一种新型轻量级 PCB 缺陷检测算法 PMAC-YOLO,旨在保证检测精度的同时降低计算复杂度和参数量,实现网络轻量化。该算法深度整合 C3k2_PMLCA、ADSdown 与 CCFM 3 大核心模块,构建起层次化、自适应的 PCB 缺陷检测框架。具体而言,利用 C3k2_PMLCA 模块中部分卷积(partial convolution, PConv)与混合局部通道注意力(mixed local channel attention, MLCA)模块的混合设计控制参数规模,同时,结合自适应深度可分离下采样模块(adaptive depth-separable downsampling module, ADSdown)对高分辨率特征图自适应下采样,实现跨尺度特征精准对齐,优化细节保留与计算资源分配,对跨尺度特征融合模块(cross-scale feature fusion module, CCFM)输入的多尺度特征图进行精细化处理,强化小目标特征表达,促进特征间信息流通,降低颈部网络计算复杂度,最终提升模型在小目标与复杂场景下的检测性能。通过这种技术协同,模型不仅在小目标召回率上提升显著,同时在复杂光照、纹理干扰等场景下,能够通过多模块间的信息互补,实现检测精度与推理速度的双重优化。

1 YOLOv11 算法概述

YOLOv11 由 Ultralytics 团队于 2024 年发布^[20],是基于经典 YOLO 架构的创新版本,特别适用于实时目标检测。其架构包括输入层(input)、主干网络(backbone)、颈部网络(neck)和检测头(head)4 部分^[21],如图 1 所示,其中主干网络通过 C3k2 模块和跨尺度像素空间注意力(C2PSA)模块增强特征提取能力;颈部网络通过多尺度特征融合提升模型性能。YOLOv11 引入的深度卷积分类头有效减少参数量,并通过多分支设计优化不同尺寸目标的检测能力^[22]。YOLOv11 有多个变体,包括 YOLOv11n、YOLOv11s 等,其中 YOLOv11n 是轻量级变体,专为资源受限的设备设计,具有高效性和实时性,适用于边缘计算和移动设备。YOLOv11 的创新架构使其




图 1 YOLOv11 网络结构

Fig. 1 Network structure diagram of YOLOv11

在轻量级 PCB 缺陷检测场景中具备显著的应用潜力。

2 PMAC-YOLO 算法

本文基于 YOLOv11n 构建了轻量级网络模型 PMAC-YOLO 用于 PCB 缺陷检测。PMAC-YOLO 算法网络结构如图 2 所示。

PMAC-YOLO 算法中,首先,融合 PConv 与 MLCA 设计 C3k2_PMLCA 模块,解决 PCB 缺陷检测中复杂背景干扰导致微小目标关键特征提取困难的问题,提升了微小目标的特征提取能力,减少背景干扰并降低计算冗余。其次,设计 ADSdown 模块解决传统下采样操作因固定的降维策略,常导致微小目标的关键信息丢失问题,通过深度卷积与逐点卷积的分解,自动调整下采样参数,有效保留微小目标的关键特征,避免信息丢失。最后,引入 CCFM 结构借助多层次特征交互机制实现跨尺度特征的深度融合,增强了模型对尺度变化的适应性,且提高了对小尺度目标的检测精度和能力。

2.1 C3k2_PMLCA 模块

在 PCB 缺陷检测中,YOLOv11 能够有效提取全面的特征,但其包含多个瓶颈模块的 C3k2 可能会导致特征图之间出现冗余信息,进而增加计算量和内存消耗,尤其是在前向传播过程中,冗余的特征图并未为有效信息提供额外贡献。在 PCB 缺陷检测中,传统全卷积的高计算复杂度和内存需求无法满足轻量化的要求。为此,本文利用 C3k2 的灵活性,融合 PConv 和 MLCA,构建了 C3k2_PMLCA 模块,如图 3 所示。

PConv 通过选择性处理输入通道的子集,仅对部分通道进行卷积,避免了不必要的计算,从而减少冗余计算并降低计算成本,同时提升空间特征提取能力^[23]。假设输入输出通道相同,PConv 的浮点运算次数(floating point operations, FLOPs)和内存访问量(memory access, MA)如式(1)和(2)所示。

$$FLOPs_{PConv} = h \times w \times k^2 \times c_p^2 \quad (1)$$

$$MA = h \times w \times 2c_p \quad (2)$$

式中: h 和 w 分别为输入特征图的高度和宽度; k 为卷积




图 2 PMAC-YOLO 网络结构

Fig. 2 Network structure diagram of PMAC-YOLO




图 3 C3k2_PMLCA 模块结构

Fig. 3 Structural diagram of the C3k2_PMLCA module

核尺寸; c_p 为实际进行卷积的处理通道数。

PConv 结构如图 4 所示,通过仅对部分通道进行卷积,显著降低计算复杂度和内存消耗,此外,由于只有 c_p 通道参与空间特征的提取,减少特征通道信息的丢失。若 PConv 的通道压缩比例用 r 表示,即 PConv 的输入/输出特征图通道数为传统标准卷积的 r 倍,当 $r = 1/4$ 时, PConv 仅通过原始 $1/4$ 的通道数完成特征提取,其 FLOPs 降至传统卷积的 $1/16$,大幅优化了计算效率,降低了内存访问需求。

MLCA 模块作为轻量化注意力机制,能够整合通道信息和空间信息,通过结合局部通道和全局通道信息,实现对上下文信息和多尺度特征的全面捕捉^[24]。其结构如图 5 所示,工作原理如下:首先,对输入特征向量进行两步池化操作,利用局部平均池化(local average pooling, LAP)将输入转换为 $C \times k_s \times k_s \times 1$ 的向量,以提取局部空间信息;在此基础上,通过两个分支将输入转换为一维向量;其中,第 1 个分支在 LAP 的基础上进行全局平均池化(global average pooling, GAP),用于提取全局信息,第 2




图4 常规卷积与部分卷积

Fig. 4 Regular convolution and partial convolution




图5 MLCA 模块结构

Fig. 5 Structural diagram of the MLCA module

个分支将特征重新排列为 $C \times ks \times ks \times 1 \times 1$ 的向量,以保存局部空间信息,经过一维卷积(1d convolutional, Conv1d)进行特征提取,后通过反平均池化(un-average pooling, UNAP)操作还原两个向量的原始分辨率;两个分支融合信息后,达成混合注意力的目标。图5中 Conv1d 卷积核大小 k 与通道维度 C 成比例,这意味着在捕捉局部跨通道交互信息时,仅考虑每个通道与其 k 个相邻通道之间的关系。其中, k 的选取如式(3)所示。

$$k = \Phi(C) = \left\lceil \frac{\log_2(C)}{\alpha} + \frac{\beta}{\alpha} \right\rceil_{\text{odd}} \quad (3)$$

式中: α 和 β 均为超参数,默认值取 2;“odd”表示 k 若计算结果为偶数,则需加 1,确保 k 为奇数。

C3k2_PMLCA 模块基于 PConv 和 MLCA 对 Bottleneck 结构进行重新设计,用两个 3×3 的 PConv 卷积层替换传统卷积层,设计 Bottleneck_P 模块,并去除跳跃连接,以此提升运算速度,显著降低计算量。此外,将 MLCA 融入 Bottleneck 得到 Bottleneck_MLCA 模块,并以此构建 C3k_M 模块,通过自适应调整卷积核大小 k ,能够在不同通道数下动态平衡计算量与特征表征能力。

C3k2_PMLCA 模块在减少无效计算的同时,实现了特征的高效增强,通过层级化架构设计,将 PConv 的稀疏计算特性与 MLCA 的跨维度注意力机制深度融合,在保证检测精度的前提下,有效降低计算复杂度和内存需求,满足模型轻量化的应用需求。

2.2 ADSdown 模块

在 YOLOv11 中,跨步卷积的下采样方式因固有信息压缩机制,易造成微小缺陷特征丢失,显著削弱模型对 PCB 细节特征的检测能力。为解决这一问题,本文参考 YOLOv9 的 ADown 模块^[25],将其中的卷积操作替换为深度可分离卷积(depthwise separable convolution, DSConv)^[26],设计 ADSdown 模块以替代部分传统下采样模块,其结构如图 6 所示。

ADSdown 模块采用双分支协同特征压缩架构,通过异构采样策略优化计算量,自动调整下采样参数以保留细节信息,尤其适用于小目标特征提取。具体而言,输入特征图,首先经过平均池化操作(average pooling, avgpool, AvgPool)处理,留存更多的空间细节,从而捕捉到更精细




图 6 ADSdown 模块结构

Fig. 6 Structural diagram of the ADSdown module

的特征,防止小目标特征在降采样中丢失;随后,特征图沿通道维度均分为两部分,使单路通道数减半,既减少通道冗余信息,又降低后续卷积计算量。该模块包含两条并行处理路径:第 1 条路径为细粒度特征学习路径,利用 DSConv 提取局部特征并进行空间下采样,相比传统卷积,深度可分离卷积在压缩计算量的同时,更擅长捕捉空间细节与跨通道特征关联;第 2 条路径为显著性特征增强路径,子特征先经过最大池化(max pooling, MaxPool)突出显著性区域、减少冗余,再通过 DSConv 进一步提取特征并重整通道,强化跨通道信息交互与细节捕捉能力,两条路径通过将传统卷积分解为空间卷积与通道卷积分步执行,在降低计算复杂度的同时,完整保留图像细微特征。最后,将这两部分的子特征图沿着通道维度进行拼接,为后续网络提供更丰富的上下文与细节信息。

传统卷积因需处理高维特征图与大量通道数据,极易造成计算复杂度激增。而 ADSdown 模块通过特征图分割与路径计算优化,显著减少单次卷积的参数量,提升运算速度。深度可分离卷积的引入进一步提升计算效率,将标准卷积操作分解为两步:深度卷积和逐点卷积,前者对各输入通道独立卷积,后者通过 1×1 卷积实现跨通道融合,大幅降低计算量与参数数量。假设 C 为输入特征图通道数, K 为输出通道数, $k\times k$ 为卷积核的大小,则传统卷积与深度可分离卷积计算量分别如式(4)和(5)所示。

传统卷积计算量:

$$C \times K \times k^2 \tag{4}$$

深度可分离卷积计算量:

$$C \times k^2 + C \times K \tag{5}$$

2.3 CCFM 结构

YOLOv11 采用路径聚合网络特征金字塔结构构建多尺度特征,生成大、中、小尺度特征图,经融合后送入检测头完成分类与回归。最后,融合后的特征被发送到检测头执行高精度分类和边界框回归任务,最终输出检测结果。受 RT-DETR 网络模型启发,本文在 YOLOv11 颈

部网络引入轻量化跨尺度特征融合模块 CCFM,旨在增强模型对尺度变化的适应性与小目标检测能力^[27]。

CCFM 是一种基于通道注意力和空间注意力的轻量级特征融合模块,其核心目标是通过融合操作整合不同尺度特征,可有效结合特征图中的细小特征与上下文信息,将多尺度特征转化为一列图像特征,以此增强模型对尺度变化的适应性及小目标缺陷的检测精度与能力,从而提升模型整体性能。如图 7 所示,该模块在跨尺度融合路径中嵌入卷积层,利用 Conv 调整特征通道并投影后实施融合。与原始特征金字塔网络(feature pyramid network, FPN)结构相比,CCFM 在特征拼接前将通道数统一至 256,既减少计算量,又保障输入一致性,有效降低融合信息损失。




图 7 CCFM 网络结构

Fig. 7 Network structure diagram of CCFM

3 实验结果与分析

3.1 数据集

本文使用两个公开数据集,分别为上海交通大学图像处理与模式识别研究所发布的 DeepPCB 数据集^[28]以及北京大学智能机器人开放实验室发布的 HRIPCB 数据集^[29]。

DeepPCB 数据集中标注了开路、短路、鼠咬、毛刺、漏孔和余铜 6 种常见 PCB 缺陷类型,如图 8 所示。该数据集共包含 1 500 组图像对,每张图像包含 3~12 个缺陷实例,将数据集按 8 : 1 : 1 的比例随机划分为训练集、验证集和测试集,各类缺陷的具体分布情况如表 1 所示。

表 1 DeepPCB 数据集各类缺陷数

Table 1 Number of defects by type in the DeepPCB dataset

缺陷类型	训练集缺陷数	验证集缺陷数	测试集缺陷数	总类缺陷数
open_circuit	1 373	283	286	1 942
short	1 069	229	208	1 506
mouse_bite	1 365	224	308	1 897
spur	1 132	232	236	1 600
spurious_copper	1 029	292	228	1 549
missing_hole	1 049	257	213	1 519




图 8 DeepPCB 数据集 6 种缺陷图

Fig. 8 Six types of defects in the DeepPCB dataset

HRIPCB 数据集包含 693 张 PCB 图像,同样覆盖开路、短路、鼠咬、毛刺、漏孔和余铜 6 类缺陷。由于原始数据集训练样本量有限,从而导致泛化性能差、参数估计偏差以及网络复杂度增加等问题。本研究参考文献[30],对原始 693 张图像进行了数据增强,将数据集规模扩展至 10 668 张

图像,作为 HRIPCB 数据集的增强版本,其缺陷类型如图 9 所示。该数据集同样按 8 : 1 : 1 的比例随机划分为训练集、验证集和测试集,其中各类缺陷数量如表 2 所示。数据增强显著提升了模型性能,其 mAP@0.5 从原始数据集的 87.8% 提升至增强后数据集的 98.7%,具体数据如表 3 所示。




图 9 HRIPCB 增强数据集 6 种缺陷图

Fig. 9 Six types of defects in the HRIPCB enhanced dataset

表 2 HRIPCB 增强数据集各类缺陷数

Table 2 Number of defects by type in the HRIPCB enhanced dataset

缺陷类型	训练集缺陷数	验证集缺陷数	测试集缺陷数	总类缺陷数
open_circuit	2 406	544	536	3 486
short	2 451	540	546	3 537
mouse_bite	2 585	560	513	3 658
spur	2 579	545	582	3 706
spurious_copper	2 585	562	537	3 684
missing_hole	2 514	520	559	3 593

表 3 HRIPCB 数据集增强前后对比

Table 3 Comparison of HRIPCB dataset before and after enhancement

类别	原始数据集	增强数据集
图像数量	693	10 668
缺陷数量	2 901	21 664
mAP@ 0. 5	87. 8%	98. 7%

3.2 实验环境和评估指标

本研究使用的操作系统为 Linux Ubuntu22. 04, 处理器为 Intel(R) Xeon(R) CPU E7-4809 v3 @ 2. 00 GHz, 显卡型号为 NVIDIA GeForce RTX3090, 24 GB 显存, GPU 加速库为 CUDA11. 2, 程序环境为 Python3. 10, 使用的深度学习框架为 PyTorch2. 5. 1。模型每次训练 300 次迭代, 批量大小为 8, 优化算法采用随机梯度下降, 初始学习率

为 0. 01, 最终学习率为 0. 001, 动量为 0. 937, 权重衰减为 0. 000 5, 使用图像马赛克增强(mosaic augmentation)概率为 1. 0, 输入图像分辨率为 640×640。

实验评估指标有精确度 (precision, P)^[31]、召回率 (recall, R)^[32]、mAP^[33]、FLOPs、模型参数量 (model parameters, Params) 和帧率 (frames per second, FPS) 等。计算公式如(6)~(8)所示。

$$P = \frac{TP}{TP + FP} \tag{6}$$

$$R = \frac{TP}{TP + FN} \tag{7}$$

$$mAP = \frac{1}{N} \sum_{i=1}^N \left(\int_0^1 P(R) dR \right)_i \tag{8}$$

式中: TP 为真正例; FP 为假正例; FN 为假反例; $\int_0^1 P(R) dR$ 是单类别下 Precision-Recall 曲线与坐标轴围成的面积; N 表示类别总数; i 表示第 i 个类别。

3.3 消融实验与分析

为验证本文所提出的 PMAC-YOLO 模型中各模块对 PCB 缺陷检测的有效性, 以 YOLO11 作为基线模型, 逐步引入 C3k2_PMLCA 模块、ADSdown 模块和 CCFM 结构, 分别在 DeepPCB 和 HRIPCB 增强数据集上进行消融实验, 以评估 PMAC-YOLO 的鲁棒性与泛化能力。DeepPCB 数据集的消融实验结果如表 4 所示, HRIPCB 增强数据集的消融实验结果如表 5 所示。

表 4 DeepPCB 数据集消融实验结果

Table 4 Ablation study results of the deepPCB dataset

模型	YOLOv11	C3k2_PMLCA	ADSdown	CCFM	P/%	R/%	mAP@ 0. 5/%	GFLOPs	Params/(×10 ⁻⁶)	模型权重/MB
Model_1	✓	×	×	×	97. 9	96. 2	98. 5	6. 3	2. 58	5. 5
Model_2	✓	✓	×	×	96. 9	95. 9	98. 8	5. 6	2. 41	5. 2
Model_3	✓	×	✓	×	97. 9	96. 2	98. 6	4. 8	1. 96	4. 3
Model_4	✓	×	×	✓	97. 5	95. 6	98. 6	5. 3	1. 83	4
Model_5	✓	✓	✓	×	97. 6	96	98. 5	4. 1	1. 78	3. 9
Model_6	✓	✓	×	✓	97. 1	95. 2	98. 3	4. 8	1. 75	3. 8
Model_7	✓	×	✓	✓	97. 7	96. 1	98. 7	3. 8	1. 31	3
PMAC-YOLO(本文)	✓	✓	✓	✓	97. 8	96. 2	98. 8	3. 4	1. 22	2. 8

表 5 HRIPCB 增强数据集消融实验结果

Table 5 Ablation study results of the HRIPCB enhanced dataset

模型	YOLOv11	C3k2_PMLCA	ADSdown	CCFM	P/%	R/%	mAP@ 0. 5/%	GFLOPs	Params/(×10 ⁻⁶)	模型权重/MB
Model_1	✓	×	×	×	97. 7	98. 7	98. 7	6. 3	2. 58	5. 5
Model_2	✓	✓	×	×	98. 3	98. 3	99. 0	5. 6	2. 41	5. 2
Model_3	✓	×	✓	×	98. 3	98. 7	98. 9	4. 8	1. 96	4. 3
Model_4	✓	×	×	✓	97. 9	98. 7	98. 7	5. 3	1. 83	4
Model_5	✓	✓	✓	×	97. 8	98. 5	99. 0	4. 1	1. 78	3. 9
Model_6	✓	✓	×	✓	97. 8	98. 5	98. 9	4. 8	1. 75	3. 8
Model_7	✓	×	✓	✓	98. 0	98. 3	98. 7	3. 8	1. 31	3
PMAC-YOLO(本文)	✓	✓	✓	✓	98. 1	99. 1	99. 1	3. 4	1. 22	2. 8

由表 4 可知,在 DeepPCB 数据集中,仅使用基线模型时, mAP @ 0.5 为 98.5%, 计算量为 6.3 GFLOPs, Params 为 2.58×10^{-6} , 模型权重为 5.5 MB。分别添加 C3k2_PMLCA 模块、ADSdown 模块和 CCFM 结构后, mAP @ 0.5 分别为 98.8%、98.6%和 98.6%, 同时, 计算量相比于基线模型分别下降 11.11%、23.81%和 15.87%, Params 较基线模型分别下降 6.71%、24.13%和 29.16%, 模型权重较基线模型分别下降 5.45%、21.82%和 27.27%。最终, PMAC-YOLO 模型在 DeepPCB 数据集缺陷检测中的 mAP@0.5 为 98.8%, 相比于基线模型提升了 0.3%; 其计算量、Params 和模型权重分别为 3.4 GFLOPs、 1.22×10^{-6} 和 2.8 MB, 较 YOLOv11 分别下降 46.03%、52.77%和 49.09%。

由表 5 可知,在 HRIPCB 增强数据集中,仅使用基线模型时, mAP @ 0.5 为 98.7%, 计算量为 6.3 GFLOPs, Params 为 2.58×10^{-6} , 模型权重为 5.5 MB。分别添加 C3k2_PMLCA 模块、ADSdown 模块和 CCFM 结构后, mAP @ 0.5 分别达 99%、98.9%和 98.7%, 同时, 计算量相比于基线模型分别下降 11.11%、23.81%和 15.87%, Params 较基线模型分别下降 6.71%、24.13%和 29.16%,

表 6 DeepPCB 数据集对比实验结果

Table 6 Comparative experiment results of the DeepPCB dataset

模型	P/%	R/%	mAP@0.5/%	mAP@0.5:9.5/%	GFLOPs	Params/ $\times 10^{-6}$	模型权重/MB	FPS
Faster-R-CNN	91.3	92.8	92.2		134.5	41.4	478.5	22
YOLOv3	98.3	95.7	98.9	70.5	261.8	98.45	197.4	27
YOLOv5n	96.2	96.3	98.4	76.9	5.8	2.18	4.7	26
YOLOv6n	97.8	95.4	98.5	77.1	11.5	4.16	8.6	36
YOLOv8n	98.3	96	98.9	74.3	6.8	2.69	5.7	35
YOLOv9s	97.1	92.8	97.8	72.9	22.1	6.20	13.3	17
YOLOv10n	97.9	94.7	98.7	75.2	8.2	2.70	5.8	30
YOLO11n	97.9	96.2	98.5	76.8	6.3	2.58	5.5	29
LW-YOLO	96.7	95.7	95.2				6.5	
YOLO-BFRV			98.6			2.90		
PMAC-YOLO(本文)	97.8	96.2	98.8	78.3	3.4	1.22	2.8	21

在 HRIPCB 增强数据集缺陷检测中,也进行了类似的比较,涉及 Faster-R-CNN^[37]、SDD^[37]、RT-EDTR^[27]、YOLOv3、YOLOv5n、YOLOv6n、YOLOv8n、YOLOv9s、YOLOv10n、YOLO11n、YOLO-MBBi^[38]和 GESC-YOLO^[37]等算法,如表 7 所示。

实验结果表明, PMAC-YOLO 模型在两个数据集上均表现出较好的检测效果。

由表 6 可知,在 DeepPCB 数据集中, PMAC-YOLO 的 mAP@0.5 : 9.5 为 78.3%, 比基线模型高出 1.5%; 帧率为 21 fps, 高于 YOLOv9s; PMAC-YOLO 的召回率仅比 YOLOv5n 低 0.1%, 但其精度比后者高 1.6%; 尽管 YOLOv3 和 YOLOv8n 的 mAP@0.5 较高, 但它们的参数 Params 和计算量也较大, 不适合计算资源有限的边缘设

模型权重较基线模型分别下降 5.45%、21.82%和 27.27%。最终, PMAC-YOLO 模型在 HRIPCB 增强数据集缺陷检测中的 mAP@0.5 为 99.1%, 比基线模型高 0.4%, 计算量、Params 和模型权重分别为 3.4 GFLOPs、 1.22×10^{-6} 和 2.8 MB, 与 DeepPCB 数据集中实验结果相同, 较 YOLOv11 分别下降 46.03%、52.77%和 49.09%。

总体而言, 每个模块的添加均使得检测精度保持稳定, 同时浮点运算量、参数数量和模型权重均显著降低, 有效实现了模型的轻量化。

3.4 对比实验与分析

为了进一步验证提出的模型的有效性与可行性, 分别在两个数据集上进行了对比实验。这些实验不仅展示了 PMAC-YOLO 模型在不同数据集上的性能, 还凸显了其在检测精度、运算速度和模型复杂度方面的优势。

在 DeepPCB 数据集缺陷检测中, 将 PMAC-YOLO 模型与几种广泛使用的目标检测算法进行了比较, 包括 Faster-R-CNN^[34]、YOLOv3、YOLOv5n、YOLOv6n、YOLOv8n、YOLOv9s、YOLOv10n、YOLO11n、LW-YOLO^[35]和 YOLO-BFRV^[36], 结果如表 6 所示。

备。另外, 与 LW-YOLO 和 YOLO-BFRV 等轻量级算法相比, PMAC-YOLO 模型性能也更出色, 其 P、R 和 mAP@0.5 分别高于 LW-YOLO 算法 1.1%、0.5%和 3.6%; PMAC-YOLO 模型的 Params 比 YOLO-BFRV 算法低 57.93%。

由表 7 可知,在 HRIPCB 增强数据集检测中, PMAC-YOLO 的 mAP@0.5 达 99.1%, 高于基线模型 0.4%, mAP@0.5:9.5 比基线模型高 1.3%, 帧率达 28 fps 满足检测的实时性需求。虽然 YOLOv3 的 P、R 和 mAP 都较高, 但其计算量和 Params 分别为 261.8 GFLOPs 和 98.45×10^{-6} , 而 PMAC-YOLO 的计算量、Params 和模型大小在两个数据集上均为相同, 分别为 3.4 GFLOPs、 1.22×10^{-6} 和 2.8 MB, 轻量化程度远高于 YOLOv3。与

表 7 HRIPCB 增强数据集对比实验结果

Table 7 Comparative experiment results of the HRIPCB enhanced dataset

模型	P/%	R/%	mAP@ 0. 5/%	mAP@ 0. 5;9. 5/%	GFLOPs	Params/(×10 ⁻⁶)	模型权重/MB	FPS
Faster-R-CNN	97. 2	92. 9	96. 3	62. 3	205. 1	46. 76	178. 5	
SDD	82. 7	90. 9	88. 9	57. 5	85. 7	25. 57	97. 6	
RT-EDTR	96. 8	94. 6	96. 5			19. 88		
YOLOv3	98. 6	99. 7	99. 1	81. 3	261. 8	98. 45	197. 4	20
YOLOv5n	98. 0	99. 0	98. 8	65. 9	5. 8	2. 18	4. 7	32
YOLOv6n	98. 1	98. 6	98. 6	61. 3	11. 5	4. 16	8. 6	33
YOLOv8n	98. 1	98. 9	99. 0	65. 9	6. 8	2. 69	5. 7	33
YOLOv9s	98. 6	99. 0	99. 1	72. 7	22. 1	6. 20	13. 3	22
YOLOv10n	97. 9	98. 2	98. 8	65. 8	8. 2	2. 70	5. 8	29
YOLO11n	97. 7	98. 7	98. 7	66. 1	6. 3	2. 58	5. 5	28
YOLO-MBBI	95. 8	94. 6	95. 3	52. 5	12. 8	8. 80		
GESC-YOLO	98. 3	98. 1	99. 0	64. 3	6	2. 15	4. 7	
PMAC-YOLO(本文)	98. 1	99. 1	99. 1	67. 4	3. 4	1. 22	2. 8	28

YOLO-MBBI 算法相比,改进模型的 mAP@ 0. 5 和 mAP@ 0. 5;9. 5 分别高 3. 8% 和 14. 9%;改进模型的计算量、Params 和模型大小分别低于 GESC-YOLO 算法 43. 33%、43. 26% 和 40. 43%。

总体而言,以上所有对比实验结果表明,PMAC-YOLO 模型在 PCB 缺陷检测中展现出显著的性能。该模型不仅在保证检测精度的前提下大幅度降低了

计算复杂度和参数量,而且实现了网络模型的轻量化,有利于边缘设备的部署。PMAC-YOLO 在两个公共数据集上的优异表现,验证了其良好的泛化能力。

3. 5 各类 PCB 缺陷的 AP 指标对比

改进前后各类 PCB 缺陷的平均精度值对比结果如表 8 所示。

表 8 改进前后各类 PCB 缺陷的 AP 值对比

Table 8 AP value comparison of various PCB defects before and after improvement

数据集	模型	AP/%						mAP@ 0. 5/%
		漏孔	鼠咬	开路	短路	毛刺	余铜	
DeepPCB	YOLO11n	98. 2	97. 8	98. 8	99. 2	99. 3	98. 1	98. 5
	本文	98. 4	98. 5	98. 3	99. 2	99. 2	99. 0	98. 8
	增减	0. 2	0. 7	-0. 5	0	-0. 1	0. 9	0. 3
HRIPCB	YOLO11n	99. 7	98. 9	99. 5	97. 0	99. 0	98. 7	98. 7
	本文	99. 5	99. 1	99. 5	98. 5	98. 9	99. 1	99. 1
	增减	-0. 2	0. 2	0	1. 5	-0. 1	0. 4	0. 4

在 DeepPCB 数据集中,PMAC-YOLO 模型与 YOLOv11n 在短路缺陷的 AP 值相同。对于断裂缝隙极小、边缘模糊或与背景对比度低的开路缺陷,其视觉特征本身就不显著,本研究引入的注意力机制在聚焦过程中,会优先加权那些高对比度、形状规则的显著区域,因此,对于上述不显著的开路缺陷,注意力机制难以生成足够强的激活响应,导致模型在特征提取与融合阶段未能充分强化其关键判别特征,这一现象使得部分细微开路缺陷易被漏检或误检,拉低了 PMAC-YOLO 模型在该类别上的整体检测精度,导致其 AP 值下降 0. 5%。毛刺缺陷的形态和尺度多变,部分尺度较大、形态圆润的毛刺与小

尺寸的余铜缺陷在视觉特征上高度相似,导致了类间混淆,尽管 PMAC-YOLO 模型增强了多尺度感知能力,但对于这些处于类别决策边界的模糊案例,模型依然存在误判风险,因此造成了毛刺缺陷 AP 值小幅下降 0. 1%。PMAC-YOLO 模型在漏孔、鼠咬和余铜缺陷的检测上分别取得了 0. 2%、0. 7% 和 0. 9% 的 AP 值提升,尽管在开路和毛刺缺陷上出现了 0. 5% 和 0. 1% 的小幅下降,但模型在多数缺陷类别上表现更优,其 mAP@ 0. 5 相比基线模型提升了 0. 3%,证明了改进的有效性。

在 HRIPCB 增强数据集中,PMAC-YOLO 模型与 YOLOv11n 在开路缺陷的 AP 值相同。漏孔缺陷的尺度

已接近模型感知的物理极限,其特征极其微弱,PMAC-YOLO 模型改进更侧重于通用性能与轻量化设计,这种架构上的优化在边际上轻微降低了对此类极致微小特征的提取敏感性;而基线模型 YOLOv11n 在此类别上的性能 99.7% 已逼近上限,从而共同导致了 PMAC-YOLO 模型对该缺陷的 AP 值出现 0.2% 的边际性下降。HRIPCB 增强数据集中存在大量尺度极小、边缘圆润的毛刺,其外观与正常焊盘纹理难以区分,尽管 PMAC-YOLO 模型通过增强多尺度感知能力提升了对典型毛刺的识别效果,但对于这些处于类别决策边界的模糊案例,模型仍表现出判别不确定性,导致在毛刺和正常焊盘之间产生误判,从而拉低了该类别的整体检测精度,造成了毛刺缺陷 AP 值小幅下降 0.1%。PMAC-YOLO 模型在鼠咬、短路和余铜缺陷的检测上分别取得了 0.2%、1.5% 和 0.4% 的 AP 值提升,尽管在漏孔和毛刺缺陷上出现了 0.2% 和 0.1% 的小幅下降,但模型在多数关键缺陷类别上表现更优,其 mAP@0.5 相比基线模型提升了 0.4%,证明了模型改进的有效性与综合优势。

以上结果表明,PMAC-YOLO 模型在多数细微缺陷

检测上均表现出显著提升,例如 DeepPCB 数据集的余铜缺陷和 HRIPCB 增强数据集的短路缺陷 AP 值分别提升了 0.9% 和 1.5%。尽管在部分缺陷类型上存在小幅波动,清晰地勾勒出模型当前的能力边界,但模型在整体检测性能上稳定优于 YOLOv11n,验证了其更强的有效性与综合实用性。

3.6 实验结果展示

在两个数据集中随机选取图片进行测试,测试结果如图 10 和 11 所示。检测结果显示,YOLOv11n 在部分缺陷检测中存在漏检,而 PMAC-YOLO 模型能有效检测到缺陷,且大部分检测框的置信度高于基线模型。在 DeepPCB 数据集中,漏孔和余铜缺陷与正常焊点相似,基线模型出现漏检、误检,而 PMAC-YOLO 能有效区分并检测这些缺陷,证明改进后的模型能高效提取微小目标的关键特征,提升检测精度。在 HRIPCB 增强数据集中,PMAC-YOLO 解决了基线模型在开路 and 毛刺缺陷检测中的漏检问题,并在其他缺陷上表现优异。与基线模型相比,改进后的模型检测精度更高,误检率大幅降低,验证了其更强的检测性能和泛化能力。




图 10 DeepPCB 数据集缺陷检测结果对比

Fig. 10 Comparison of defect detection results on the DeepPCB dataset




图 11 HRIPCB 增强数据集缺陷检测结果对比

Fig. 11 Comparison of defect detection results on the HRIPCB enhanced dataset

4 结 论

本文提出一种轻量级 PCB 缺陷检测模型 PMAC-YOLO,旨在解决现有检测模型体积庞大、计算资源和时间消耗较高的问题,满足实时检测场景的需求。总体而言,PMAC-YOLO 模型中,利用轻量级 C3k2_PMLCA 模块,结合 PConv 和 MLCA,增强模型对复杂背景下目标的感知能力,并有效提取微小目标的关键特征;ADsdown 模块实现轻量级下采样,动态调整信息保留程度,最大限度地保留微小目标的关键特征信息;CCFM 结构通过融合不同尺度的特征,提升模型对尺度变化的适应性和小目标缺陷的检测精度和能力。大量实验表明,PMAC-YOLO 在检测精度和轻量化方面优于其他先进模型,其轻量级特征支持边缘设备部署。在 DeepPCB 和 HRIPCB 增强数据集上的表现也非常出色,mAP@0.5 分别提升了 0.3%和 0.4%,分别达到 98.8%和 99.1%。同时,模型参数量减少 52.64%,计算复杂度降低 46.03%,模型尺寸缩小 49.09%。消融实验验证了每个模块的可行性和有效性,提升了检测精度并最大程度地实现了轻量化。未来的工作将进一步探索模型优化方向,提升检测速度,以满足工业检测需求,并扩展至其他微小目标缺陷检测任务。

参考文献

- [1] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进展[J]. 仪器仪表学报, 2022, 43(1):

198-219.

ZHAO L Y, WU Y Q. Research progress of surface defect detection methods based on machine vision[J]. Chinese Journal of Scientific Instrument, 2022, 43(1): 198-219.

- [2] 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.
- [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] 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 Y L, CAO J T, JI X F. Convolutional neural network-based PCB defect detection and recognition algorithm[J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(8): 78-84.
- [5] MALGE P S, NADAF R S. PCB defect detection, classification and localization using mathematical morphology and image processing tools[J]. International Journal of Computer Applications, 2014, 87(9): 40-45.
- [6] GAIDHANE V H, HOTE Y V, SINGH V. An efficient similarity measure approach for PCB surface defect detection[J]. Pattern Analysis and Applications, 2018,

- 21: 277-289.
- [7] LI Y, LI S. Defect detection of bare printed circuit boards based on gradient direction information entropy and uniform local binary patterns [J]. *Circuit World*, 2017, 43(4): 145-151.
- [8] 侯学良, 单腾飞, 薛靖国. 深度学习的目标检测典型算法及其应用现状分析 [J]. *国外电子测量技术*, 2022, 41(6): 165-174.
- HOU X L, SHAN T F, XUE J G. Analysis of typical deep learning-based object detection algorithms and their application status [J]. *Foreign Electronic Measurement Technology*, 2022, 41(6): 165-174.
- [9] KANG L, GE Y, HUANG H, et al. Research on PCB defect detection based on SSD [C]. 2022 IEEE 4th International Conference on Civil Aviation Safety and Information Technology (ICCASIT). IEEE, 2022: 1315-1319.
- [10] SHI W, LU Z, WU W, et al. Single-shot detector with enriched semantics for PCB tiny defect detection [J]. *The Journal of Engineering*, 2020(13): 366-372.
- [11] CHEN W, HUANG Z, MU Q, et al. PCB defect detection method based on transformer-YOLO [J]. *IEEE Access*, 2022, 10: 129480-129489.
- [12] TANG J, LIU S, ZHAO D, et al. PCB-YOLO: An improved detection algorithm of PCB surface defects based on YOLOv5 [J]. *Sustainability*, 2023, 15(7): 5963.
- [13] 杨永跃, 夏远超. PCB 缺陷检测深度学习算法的精度改进 [J]. *电子测量与仪器学报*, 2023, 37(5): 11-19.
- YANG Y Y, XIA Y CH. Accuracy improvement of deep learning algorithm for PCB defect detection [J]. *Journal of Electronic Measurement and Instrumentation*, 2023, 37(5): 11-19.
- [14] SHI P, ZHANG Y, CAO Y, et al. DVCW-YOLO for printed circuit board surface defect detection [J]. *Applied Sciences*, 2024, 15(1): 327.
- [15] LIM J Y, LIM J Y, BASKARAN V M, et al. A deep context learning based PCB defect detection model with anomalous trend alarming system [J]. *Results in Engineering*, 2023, 17: 100968.
- [16] CHEN L, SU L, CHEN W, et al. YOLO-DHGC: Small object detection using two-stream structure with dense connections [J]. *Sensors*, 2024, 24(21): 6902.
- [17] ZHANG K, WANG Y, SHI S, et al. SF-YOLO: Designed based on tiny feature for PCB surface defect detection and deployment in embedded systems [J]. *Signal, Image and Video Processing*, 2025, 19(3): 263.
- [18] LI D, BAI F, LI S, et al. EL-PCBNet: An efficient and lightweight network for PCB defect detection [J]. *Measurement*, 2025: 117719.
- [19] WANG J, XIE X, LIU G, et al. A lightweight PCB defect detection algorithm based on improved YOLOv8-PCB [J]. *Symmetry*, 2025, 17(2): 309.
- [20] KHANAM R, HUSSAIN M. YOLOv11: An overview of the key architectural enhancements [J]. *ArXiv preprint arXiv:2410.17725*, 2024.
- [21] ALI M L, ZHANG Z. The YOLO framework: A comprehensive review of evolution, applications, and benchmarks in object detection [J]. *Computers*, 2024, 13(12): 336.
- [22] JI Y, ZHANG D, HE Y, et al. Improved YOLO11 algorithm for insulator defect detection in power distribution lines [J]. *Electronics*, 2025, 14(6): 1201.
- [23] CHEN J, KAO S, HE H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]. *Proceedings of the IEEE, CVF Conference on Computer Vision and Pattern Recognition*, 2023: 12021-12031.
- [24] WAN D, LU R, SHEN S, et al. Mixed local channel attention for object detection [J]. *Engineering Applications of Artificial Intelligence*, 2023, 123: 106442.
- [25] WANG C Y, YE H I, MARK LIAO H Y. YOLOv9: Learning what you want to learn using programmable gradient information [C]. *European conference on computer vision*. Cham: Springer Nature Switzerland, 2024: 1-21.
- [26] CHOLLET F. XCEPTION: Deep learning with depthwise separable convolutions [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017: 1251-1258.
- [27] ZHAO Y, LYU W, XU S, et al. Detrs beat YOLOs on real-time object detection [C]. *Proceedings of the IEEE, CVF Conference on Computer Vision and Pattern Recognition*. 2024: 16965-16974.
- [28] TANG S, HE F, HUANG X, et al. Online PCB defect detector on a new PCB defect dataset [J]. *ArXiv preprint arXiv:1902.06197*, 2019.
- [29] HUANG W, WEI P, ZHANG M, et al. HRIPCB: A challenging dataset for PCB defects detection and classification [J]. *The Journal of Engineering*, 2020, 2020(13): 303-309.
- [30] NAVEED H, ANWAR S, HAYAT M, et al. Survey: Image mixing and deleting for data augmentation [J]. *Engineering Applications of Artificial Intelligence*, 2024, 131: 107791.
- [31] FARADY I, KUO C C, NG H F, et al. Hierarchical

- image transformation and multi-level features for anomaly defect detection[J]. *Sensors*, 2023, 23(2): 988.
- [32] HE Y, SU Y, WANG X, et al. An improved method MSS-YOLOv5 for object detection with balancing speed-accuracy[J]. *Frontiers in Physics*, 2023, 10: 1101923.
- [33] HENDERSON P, FERRARI V. End-to-end training of object class detectors for mean average precision[C]. *Computer Vision-ACCV 2016: 13th Asian Conference on Computer Vision*, Taipei, Taiwan, November 20-24, 2016, Revised Selected Papers, Part V 13. Springer International Publishing, 2017: 198-213.
- [34] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2016, 39(6): 1137-1149.
- [35] YUAN Z, TANG X, NING H, et al. Lw-YOLO: Lightweight deep learning model for fast and precise defect detection in printed circuit boards[J]. *Symmetry*, 2024, 16(4): 418.
- [36] LIU J, KANG B, LIU C, et al. YOLO-BFRV: An efficient model for detecting printed circuit board defects [J]. *Sensors*, 2024, 24(18): 6055.
- [37] KONG X, LIU G, GAO Y. GESC-YOLO: Improved lightweight printed circuit board defect detection based algorithm[J]. *Sensors*, 2025, 25(10): 3052.

- [38] DU B, WAN F, LEI G, et al. YOLO-MBBi: PCB surface defect detection method based on enhanced YOLOv5[J]. *Electronics*, 2023, 12(13): 2821.

作者简介



郑佳丽, 2023 年于云南民族大学获得学士学位, 现为昆明理工大学的硕士研究生, 主要研究方向为缺陷检测。

E-mail: 327342035@qq.com

Zheng Jiali received her B. Sc. degree from Yunnan Minzu University in 2023. Now she is a M. Sc. candidate at Kunming University of Science and Technology. Her main research interest includes defect detection.



董凌(通信作者), 2007 年于北京理工大学获学士学位, 2009 年于北京理工大学获硕士学位, 现为昆明理工大学的实验师, 主要研究方向为自然语言处理、语音识别、多模态。

E-mail: 46761956@qq.com

Dong Ling (Corresponding author) received his B. Sc. degree from Beijing Institute of Technology in 2007, M. Sc. degree from Beijing Institute of Technology in 2009 respectively. Now he is an experimenter at Kunming University of Science and Technology. His main research interests include natural language processing, speech recognition, and multimodal learning.