

CID-YOLO:改进的 YOLOv11 PCB 缺陷检测算法

钟长彬 施建平 祝孟洋 杨宏凯

(南京师范大学电气与自动化工程学院 南京 210023)

摘要: 针对印刷电路板(PCB)表面缺陷检测网络存在对小缺陷敏感性低、检测效率低下等难题。提出了一种基于 YOLOv11 改进的 PCB 缺陷检测算法 CID-YOLO。首先,结合 IDWC(inception depthwise convolution)改进 C3k2 模块,通过多分支特征提取机制,减少因网络深度增加而造成 PCB 表面缺陷高位特征信息的丢失,并减少模型参数量;其次,引入动态激活机制 Dynamic Tanh 改进 C2PSA 模块,增强模型非线性表达能力,使模型能更好地适应不同尺度的缺陷特征;接着嵌入 CGBD 下采样模块通过高效的上下文信息提取机制,提高 PCB 表面特殊缺陷的识别能力;最后,替换原分类损失函数,通过动态加权策略抑制数据不平衡导致的梯度偏移,有效提升模型泛化性能。实验结果表明,提出的 CID-YOLO 模型在北京大学公共 PCB 缺陷数据集上的平均精度均值(mAP)mAP50 和 mAP50-95 指标分别达到 96.0%和 52.7%,较基线模型分别提升 2.4%和 1.6%,证明了所提算法的有效性。

关键词: 深度学习;目标检测;电路板检测;YOLOv11n

中图分类号: TP391.4;TN791 **文献标识码:** A **国家标准学科分类代码:** 520.6040

CID-YOLO: Improved YOLOv11 PCB defect detection algorithm

Zhong Changbin Shi Jianping Zhu Mengyang Yang Hongkai

(School of Electrical and Automation Engineering, Nanjing Normal University, Nanjing 210023, China)

Abstract: To address the issues in printed circuit board(PCB)surface defect detection networks, such as low sensitivity to small defects and low detection efficiency, a PCB defect detection algorithm CID-YOLO based on the improved YOLOv11 is proposed. First, the C3k2 module is improved by integrating Inception Depthwise Convolution, which, through a multi-branch feature extraction mechanism, reduces the loss of high-level feature information of PCB surface defects caused by increased network depth and decreases the number of model parameters. Second, a dynamic activation mechanism, Dynamic Tanh, is introduced to improve the C2PSA module, enhancing the model's nonlinear representation capability, allowing it to better adapt to defect features of different scales. Next, the CGBD downsampling module is embedded to improve the recognition capability for special PCB surface defects through an efficient context information extraction mechanism. Finally, the original classification loss function is replaced, and a dynamic weighting strategy is applied to suppress gradient bias caused by data imbalance, effectively improving model generalization performance. Experimental results show that the proposed CID-YOLO model achieves mAP50 and mAP50-95 scores of 96.0% and 52.7%, respectively, on the Peking University public PCB defect dataset, improving 2.4% and 1.6% compared to the baseline model, demonstrating the effectiveness of the proposed algorithm.

Keywords: deep learning;object detection;circuit board detection;YOLOv11n

0 引言

在现代电子制造领域,印刷电路板(printed circuit board,PCB)作为电子产品的核心组件,其质量会直接对电子设备的性能与可靠性产生影响。在 PCB 的制造期间,容易出现缺孔、短路、开路等诸多缺陷,高效、精准的缺陷检测是保障产品质量的关键环节^[1]。传统的检测手段主要依靠

人工目检与自动光学检测(automated optical inspection, AOI)技术,不过人工检测效率较低,还容易受主观因素干扰,而传统 AOI 系统设备复杂、部署成本高,且需针对不同 PCB 型号进行专门编程,难以适应型号快速变化、小批量生产的现代制造需求^[2]。

随着深度学习技术的快速发展,基于神经网络的检测算法为 PCB 缺陷检测提供了新的解决方案。深度学习目

标检测算法主要可划分为两类:一阶段算法(如 YOLO、SSD 系列)^[3-4]和二阶段算法(如 R-CCNN、Faster R-CNN 系列)^[5-6]。二阶段算法虽具备较高的检测精度,但由于流程复杂、推理速度较慢,实时检测性较差;一阶段算法直接在图像上进行目标定位与分类,检测速度更快,更适用于工业实时检测场景。

近年来,研究者提出了多种改进方法以提升 PCB 缺陷检测的精度与效率^[7-11]。吴葛等^[12]提出基于 YOLOv11 的轻量化算法,采用 HGNetV2 作为骨干网络以实现轻量化,并借鉴 Dynamic 卷积思想增强网络泛化能力,同时在末端引入 DSM(dual-domain selection mechanism)注意力机制以提升小目标检测性能。然而轻量化骨干网络可能削弱模型表征能力,制约了检测性能的进一步提升。张永宏等^[13]多聚焦于检测精度的提升,基于 RT-DETR(real-time detection transformer)模型,通过构建纠缠 Transformer 模块整合频域与空间域信息,并设计了复杂的跨尺度特征融合编码器,在多个 PCB 相关数据集上取得了优异的检测精度的同时也显著增加了模型的复杂度和计算开销,使得模型部署成本较高、难以推广。王彩霞等^[14]基于 YOLOv8n 进行改进,通过引入 160×160 微小目标检测层、并行补丁感知与高效多尺度注意力模块,并采用 NWD-EIoU(normalized wasserstein distance-efficient intersection over union)损失函数,在 PCB 小缺陷检测精度上取得了显著提升。综上所述,当前 PCB 缺陷检测研究虽取得一定进展,但呈现两种不同的技术侧重点:一部分侧重于模型的极致轻量化,但在小缺陷检测精度上提升有限;另一部分则致力于通过复杂结构追求高精度,导致模型复杂度的显著增加,不利于实际工业部署。这一现状凸显了在精度、速度和模型复杂度之间寻求更优平衡的重要性。

随着 YOLO 系列版本的不断迭代,YOLOv11 作为 Ultralytics 团队发布的最新版本算法,在先前版本基础上融合了 C3k2 结构与跨通道金字塔显著注意力机制(C2PSA),在多项视觉任务中实现了精度与速度的良好平衡。然而,在 PCB 表面缺陷检测这一具体应用中,该模型仍面临一些挑战:缺陷尺寸差异大、微小目标与背景差异不明显、存在复杂纹理干扰等。具体而言,C3k2 模块虽增强了梯度流动,但其卷积层的感受野较为固定,对尺度跨度大的缺陷适应性较弱;C2PSA 模块对空间权重分配较为均匀,难以有效聚焦形态不规则的微小缺陷;此外,模型原有的上采样策略在复杂图像背景下易引入噪声,损失函数对边缘模糊的缺陷回归精度有限,影响了整体检测稳定性。基于上述分析,本文以 YOLOv11 为基准框架,从增强多尺度特征提取能力、优化注意力机制、引入上下文感知结构以及改进损失函数 4 个关键维度展开改进,旨在提升对 PCB 表面多种缺陷的识别鲁棒性与定位准确度,更好地满足现代电子制造对检测系统高精度与高实时性的双重需求。

针对 YOLO 模型在 PCB 表面缺陷检测中存在的不足,主要做出以下工作:1)设计 C3k2_IDWC 模块。通过在 C3k2 模块中引入 IDWC(inception depthwise convolution)

下采样模块^[15],强化几何与纹理缺陷特征捕捉能力的同时,显著降低了模型参数量与计算开销;2)引入 DyT(dynamic tanh)^[16]动态激活机制改进 C2PSA 模块,提升模型对不同缺陷特征的适应能力,改善微小缺陷和复杂背景下的检测效果;3)引入 CGBD(context guided block down)^[17]模块代替传统下采样结构,通过引入上下文信息优化下采样过程,保留更多关键边缘与纹理特征,有效改善 PCB 缺陷因微小尺寸、与背景相似且易混淆带来的问题,提高对小目标和模糊目标的检测精度;4)将原分类损失函数替换为 EMASlideLoss^[18](exponential moving average slide loss),降低模型对训练数据的特定依赖,增强模型对未知数据的泛化能力与鲁棒性。

1 YOLOv11

YOLOv11 的网络架构可划分为 4 个核心部分:输入层、骨干网络、颈部网络和检测头^[19]。如图 1 所示,该模型作为一种先进的 CNN 目标检测算法,通过端到端的训练与推理方式,实现了优异的检测性能。

在输入端将 PCB 图像输入网络。Backbone 部分基于 Darknet53 构建,使用 C3k2 模块替换原 C2f 模块,实现多尺度特征的提取与融合。接着,在 SPPF 模块后引入基于多头注意力机制的 C2PSA 模块,以提升对关键区域的感知能力。Neck 部分采用路径聚合网络与特征金字塔网络相结合的双向结构,充分融合来自不同层级的浅层细节与深层语义信息,增强模型对复杂缺陷的识别能力。检测头采用解耦头设计,将定位与分类任务分离,使各分支更专注于自身职能,从而提升整体检测性能。

2 本文算法

针对 YOLOv11n 模型在 PCB 缺陷检测中存在的不足,本文基于 YOLOv11n 模型提出 CID-YOLO 检测算法。通过 4 个核心方面的优化,旨在显著提升对 PCB 缺陷的识别精度与模型鲁棒性。

首先引入 IDWC 重构 C3k 模块得到 C3k2_IDWC,减少一定参数量的同时通过增大感受野加强网络对 PCB 缺陷关键特征的利用;然后提出一种 C2PSA-DyT 注意力机制,提升对微小缺陷的检测能力;其次在 Backbone 和 Neck 网络中的一部分传统卷积模块替换为上下文引导模块 CGBD,通过学习上下文的联合特征并进一步优化;最后,引入 EMASlideLoss 损失函数替换原分类损失函数。CID-YOLO 网络结构如图 2 所示。

2.1 C3k2_IDWC 模块

在 YOLO11 的架构中,常规卷积虽是特征提取的基础组件,能够有效地捕捉图像中的局部细节与细微纹理,但其计算开销较大,尤其面对高分辨率 PCB 图像时易形成性能




图1 YOLOv11n网络结构

Fig. 1 YOLOv11n network structure




图2 CID-YOLO网络结构

Fig. 2 CID-YOLO network structure

瓶颈。此外,单一卷积核的感受野有限,为获取全局表征往往需堆叠多层结构,导致网络深度与计算资源同步上升。针对 PCB 表面存在的划痕、铜箔破损、虚焊等缺陷尺度不一、与背景差异微弱的特点,传统卷积在方向感知与多尺度建模方面存在局限,制约了检测模型的精度与稳健性。

为此,本文引入 IDWC 替换 C3k2 中 bottleneck 的标准卷积,利用其多分支特征提取结构,较传统卷积而言, IDWC 进一步提升了计算效率和特征建模能力, IDWC 结构如图 3 所示,其核心包括一个 3×3 深度卷积 DWConv (depthwise convolutions)^[20]用于捕捉局部邻域特征;一个 1×11 的水平带状深度卷积,有效增强对 PCB 走线横向断裂或划痕的特征提取能力;一个 11×1 垂直带状深度卷积,用于建模纵向电路纹理特征;以及一个 Identity 恒等映射分支;用于保留原始特征信息。这种设计使得 IDWC 能够同时融合局部细节与全局语义信息,其方向性卷积对特定走向的线状缺陷提取具有独特优势。在复杂工业背景下能更有效地区分外观相似、纹理结构不同的缺陷类型。




图 3 IDWC 模块

Fig. 3 IDWC module

本文使用 IDWC 模块替代 C3k2 模块 bottleneck 中的 3×3 标准卷积,构建了 C3k2_IDWC 特征提取模块,其架构设计如图 4 所示。该模块旨在实现高效的多尺度特征提取与方向感知增强。在 YOLOv11 的骨干网络中, C3k2_IDWC 通过堆叠 Bottleneck_IDWC 与 C3k_IDWC 作为基本构建单元,结合 IDWC 的多分支特性进行特征融合,逐层捕获丰富的方向与尺度特征。

2.2 C2PSA-DyT 模块

尽管 C2PSA 模块通过使用注意力机制提高了模型的性能,但由于传统激活函数在特征变换方面的局限性,导致模型在面对尺度多变的缺陷时,表现出较差的尺度鲁棒性。为此,在 C2PSA 模块中引入动态 Tanh (dynamic Tanh, DyT) 激活机制,构建了改进的 C2PSA-DyT 模块。在每个 PSABlock 单元注意力分支和前馈网络分支前均集成了 DynamicTanh 激活函数。这种动态激活机制能够根据输入特征自适应调整激活函数的形状和参数,增强了模型表征非线性关系的能力。对于 PCB 表面细微划痕、失




图 4 C3k2_IDWC 模块

Fig. 4 C3k2_IDWC module

孔、鼠咬等低对比度缺陷能更好的适应增强特征对比度, C2PSA-DyT 结构如图 5 所示。




图 5 C2PSA-DyT 模块

Fig. 5 C2PSA-DyT module

DyT 的核心原理是利用可学习的缩放因子 α 与 $\tanh$ 函数的结合,模拟归一化层对输入的缩放和极端值挤压。具体而言, DyT 定义为:

$$\text{DyT}(x) = \gamma \cdot \tanh(\alpha x) + \beta \quad (1)$$

其中, α 是可学习的标量参数,能够根据输入的范围对其进行不同的缩放,从而用于自适应调整输入的缩放范围; γ 和 β 是可学习的逐通道参数,类似归一化层中的仿射变换,确保输出范围灵活可调。 $\tanh$ 函数的 S 型曲线能将极端值压缩至有限区间,而 α 的动态调整则对应归一化层中对输入标准差的适应,从而在无需计算激活统计量的情况下,代替归一化层且不会改变原始架构中激活函数的任何部分。

2.3 上下文引导模块 CGBD

特征图的有效提取是 PCB 缺陷检测的核心环节。缺陷通常表现为细小的微观瑕疵,并混杂于复杂的背景干扰信号中。传统卷积操作通过调整步长来调控特征图分辨率,能够有效提取局部特征,但这会导致严重的上下文特

征丢失问题。上下文信息在小目标的检索和识别中起着重要作用,它提供位置信息、背景信息、尺度比例和语义关联等,弥补了小目标检测中局部特征的不足。为克服传统卷积感受野有限、上下文信息利用不足的局限,本文引入上下文引导模块CGBD,其结构如图6所示。该模块包含4个核心组件:局部特征提取器 f_{loc} (3×3 标准卷积)负责捕捉细微缺陷特征;周围上下文提取器 f_{sur} (3×3 深度卷

积)用于扩大感受野,获取邻近上下文;联合特征提取器 f_{joi} 通过拼接、批归一化(batch normalization, BN)与PReLU 激活函数融合前述特征;全局下文提取器 f_{glo} 则通过全局平均池化(global average pooling, GAP)与全连接层(fully connected layer, FC)聚合图像级语义。CGBD 通过协同利用局部细节与多尺度上下文,有效提升了复杂背景下缺陷的鉴别能力与检测精度。




图6 CGBD 模块
Fig. 6 CGBD module

2.4 损失函数优化

YOLOv11 结合 Sigmoid 函数与二元交叉熵损失 (BCEWithLogitsLoss) 来计算分类损失。不过, BCEWithLogitsLoss 容易受到正负样本不均衡的影响。当正样本数量明显少于负样本时,模型在训练过程中可能更倾向于优化负样本的损失,从而削弱对正样本的学习。这种情况可能导致模型对负样本过拟合,影响其整体泛化能力和检测准确率。为克服二元交叉熵损失在应对正负样本不平衡时的不足,本文采用 EMASlideLoss 作为改进 YOLOv11 模型的损失函数,旨在改善训练过程的稳定性与模型整体性能。以进一步提高训练稳定性和模型性能。该损失函数涉及的滑动加权机制和指数移动平均策略分别如式(2)和(3)所示。

的均值; μ_{n-1} 对应前一个周期中该统计量的取值; β_0 为初始指数移动权重衰减系数; β 表示滑动平均的衰减因子; n 是当前损失计算的更新轮次; τ 是调节时间衰减速率的时间常数。

EMASlideLoss 在 SlideLoss 基础上引入了对困难样本的加权聚焦机制,从而有效缓解样本不平衡问题。指数移动平均函数的加入使决策阈值能在迭代过程中平滑演化,减小由异常样本引发的参数波动,同时降低训练时的震荡与噪声。使得模型在处理复杂背景和多尺度目标检测任务中的定位与分类精度,进一步改善整体网络的收敛稳定性与泛化能力。

3 实验结果与分析

3.1 实验环境

本文实验全部基于 Linux20.04 操作系统,处理器为 Inter Xeon (R) Gold 6258R, 图形处理器为 NVIDIA GeForce RTX 3090 GPU,采用 Python3.9.20 和 Pytorch1.9.0 构建深度学习模型。并通过 CUDA 11.1 实现 GPU 加速,模型训练参数设置如表 1 所示。

表 1 模型训练参数
Table 1 Model training parameters

参数	设置	参数	设置
类别数	6	学习率	0.01
图像大小	640	批次大小	32
Warm up	True	训练轮次	300

其中, x 为预测框和真实框的交并比(intersection over union, IoU); μ 为基于指数移动平均动态更新的参数阈值,用于区分不同难易程度的样本。具体而言,当 IoU 值低于或等于 $\mu - 0.1$ 时,划分为简单样本;若 IoU 值不低于 μ , 代表困难样本;对于以上两者之间的样本,则通过滑动加权函数赋予相应权重。该策略使模型能够更好地关注到分类难度较高地样本,从而改善少数类目标的检测能力。

$$\begin{cases} \mu_n = \beta\mu_{n-1} + (1-\beta)\mu_n \\ \beta = \beta_0(1 - e^{-\frac{n}{\tau}}) \end{cases} \quad (3)$$

其中, μ_n 表示当前迭代中所有预测框与真实框叫冰壁

3.2 实验数据集

本实验采用的 PCB 表面缺陷公开数据集出自北京大学智能机器人开放实验室。该数据集含有以下 6 种缺陷类型:漏孔(missing_hole)、鼠咬(mouse_bite)、开路(open_circuit)、短路(short)、毛刺(spur)及余铜(spurious_copper)。将数据集随机分割为训练集、验证集和测试集,比例设置为 7:2:1。原始数据集仅包含 693 张缺陷图像,为改善过拟合问题,本文综合采用了水平翻转、垂直翻转、随机旋转、高斯模糊及缩放等多种数据增强技术,将数据集规模扩增至 5 799 张图像。数据增强后各缺陷类别的具体实例分布情况如表 2 所示。

表 2 数据集实例分布

Table 2 Distribution of instances in the dataset		
缺陷类型	实例数量	实例占比/%
漏孔	4 277	17.32
鼠咬	4 029	16.32
开路	4 129	16.72
短路	3 865	15.65
毛刺	3 980	16.12
余铜	4 414	17.87

3.3 评价指标

为系统评估本文改进模型在 PCB 缺陷检测任务中的性能,本研究选取了准确率(precision, P)、召回率(recall, R)、以及两种平均精度均值(mean average precision, mAP)作为评价指标,具体包括在 IoU 阈值为 0.5 时的 mAP(记为 mAP50),在 IoU 从 0.5~0.95 范围内以 0.05

为步长所计算 mAP 的平均值(记为 mAP50-95)、每秒十亿次浮点运算次数(GFLOPs)、模型参数量(parameters)其中,mAP50 与 mAP50-95 是衡量检测精度的核心指标。通常,P、R 与 mAP 值越接近 1,表明模型的检测性能越优。各指标计算公式如式(4)~(6)所示。

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

(4)

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

(5)

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i$$

(6)

其中,TP 为真值正例且被正确预测的数量;FP 为真值负例但被错误预测为正的数 量;FN 为真值正例但被预测为负的数量。mAP 被定义为所有类别平均精度(AP,即 P-R 曲线下面积)的算术均值。

3.4 消融实验

基于 mAP50 mAP50-95、模型参数量与复杂度等指标,本文通过消融实验验证了各模块贡献。如表 3 所示,基线模型在保持轻量化的同时,取得了 mAP50 为 93.6%和 mAP50-95 为 51.1%的基准性能。加入 C3k2_IDWC 模块后,参数量和计算量下降的同时检测精度有所提升,mAP50 和 mAP50-95 分别提高了 0.5%和 0.8%。接着加入 C2PSA-DyT 模块后,mAP50 和 mAP50-95 分别提高了 0.7%和 1.1%,且参数量和计算量保持不变。引入 CGBD 下采样模块后,虽模型参数量和计算量稍有增加,但检测精度进一步提升,mAP50 和 mAP50-95 分别提高了 1.5%和 1.4%。当采用 EMASlideLoss 作为损失函数时,模型性能得到进一步优化,mAP50 和 mAP50-95 分别提高了 2.4%和 1.6%。

表 3 消融实验

Table 3 Ablation study					mAP50/ %	mAP50-95/ %	参数量/ (×10 ⁶)	计算量/ GFLOPs
YOLOv11n	C3k2_IDWC	C2PSA-DyT	CGBD	EMASlideLoss				
✓					93.6	51.1	2.58	6.3
✓	✓				94.1	51.9	2.40	6.1
✓	✓	✓			94.3	52.2	2.40	6.1
✓	✓	✓	✓		95.1	52.5	3.34	8.8
✓	✓	✓	✓	✓	96.0	52.7	3.34	8.8

3.5 对比实验

1)C3k2 改进对比实验

为更好地评估改进模块 C3k2_IDWC 的优化效果,本文对比使用不同的卷积(Fconv^[21]、DyConv^[22]、Pconv^[23])模块对 C3k2 重构。实验结果如表 4 所示。结果表明,相比其他卷积模块,IDWC 在轻量化和检测精度上都有显著的提升。弥补了深度卷积在特征融合上的不足,从而实现了比标准卷积和其他变体更高的精度。

表 4 不同卷积改进 C3k2 对比

Table 4 Comparison of different convolutions improved C3k2				
卷积模块	mAP50/ %	mAP50-95/ %	参数量/ (×10 ⁶)	计算量/ GFLOPs
baseline	93.6	51.1	2.58	6.3
C3k2_Fconv	92.9	50.0	4.21	5.5
C3k2_DyConv	94.0	50.3	3.46	6.2
C3k2_Pconv	93.9	50.4	2.19	5.6
C3k2_IDWC	94.1	51.9	2.40	6.1

2)不同损失函数对比

为进一步验证 EMASlideLoss 的优越性,本文在改进后的 YOLOv11 网络上对 FocalLoss、SlideLoss 等主流损失函数进行对比实验,实验结果如表 5 所示。结果表明,相比 FocalLoss、SlideLoss 等主流损失函数,EMASlideLoss 表现出更好的鲁棒性,mAP50 达到 96.0%、mAP50-95 达到 52.7%、召回率达到 93.4%。验证了改进的损失函数能更好地改善检测不均衡的缺陷样本。

表 5 不同损失函数对比

Table 5 Comparison of different loss functions (%)			
损失函数	mAP50	mAP50-95	R
baseline	95.1	52.5	92.9
FocalLoss	91.4	48.4	84.7
SlideLoss	94.9	52.4	92.3
EMASlideloss	96.0	52.7	93.4

3)与其他算法对比

为评估 CID-YOLO 模型的性能,本研究将其与当前主流目标检测算法进行了消融实验,所有对比实验均在统一的数据集和实验设置下进行,如表 6 所示。本文算法在与其他 YOLO 系列算法的对比中展现出显著优势。在检测精度方面,本文算法取得了最高的 mAP50 和 mAP50-95,表明其整体

检测性能优于其他模型。同时,召回率达到最高水平,能够有效减少漏检。尽管参数量和计算量略高于部分轻量模型如 YOLOv5n,但相对于性能的显著提升,模型复杂度控制在合理范围内,实现了精度与效率的良好平衡。

表 6 不同算法实验对比

Table 6 Comparison of different algorithm experiments					
算法	mAP50/ %	mAP50-95/ %	R/ %	参数量/ ($\times 10^6$)	计算量/ GFLOPs
YOLOv3t	91.7	49.9	81.4	9.52	14.3
YOLOv5n	93.5	51.2	88.4	2.18	5.8
YOLOv6n	94.9	52.1	90.8	4.15	11.5
YOLOv8n	93.7	51.3	89.5	2.68	6.8
YOLOv12n	92.7	50.7	87.3	2.56	6.3
文献[24]	94.5	52.5	92.2	2.09	22.6
文献[9]	94.4	52.1	88.4	2.60	6.3
YOLOv11n	93.6	51.1	88.7	2.58	6.3
本文	96.0	52.7	93.4	3.34	8.8

改进算法与基线模型的 P-R 曲线对比结果如图 7 所示。相较于原始 YOLOv11n,改进算法的 P-R 曲线下面积(AUC)更大,表明其在 PCB 缺陷检测任务中实现了更高的检测精度与召回率,整体性能得到有效提升。





图 7 P-R 曲线对比

Fig. 7 P-R curve comparison

3.6 检测结果可视化

为进一步验证本文改进后的模型对于 PCB 缺陷的检测性能,采用测试集中的各类型 PCB 缺陷图像对基线模型和改进模型进行对比实验,实验检测结果如图 8 所示。由图 8(a)~(c)可知,与基线模型相比较,本文所提出的 CID-YOLO 模型在不同 PCB 缺陷类别检测时均表现出更高的

检测精度及置信度。具体而言,对于图 8(b)所示的开路缺陷,其特征细节较为细微,这导致在网络训练过程中容易丢失关键的轮廓信息,从而引发漏检;对于其余类型,本文算法均具有更高的置信度。综上,本文算法有效地减少了误检和漏检的情况,显著提升了 YOLOv11n 算法在 PCB 缺陷检测方面的性能。




图 8 YOLO11 与 CID-YOLO 检测效果对比

Fig. 8 Comparison of detection performance between YOLO11 and CID-YOLO

4 结 论

为进一步提高 PCB 缺陷检测的综合性能,提出了一种基于 CID-YOLO 的 PCB 缺陷检测方法。引入 IDWC 重构 c3k 模块得到 C3k2_IDWC,减少一定参数的同时增大感受野提高网络对 PCB 缺陷关键特征的利用;在 C2PSA 模块中引入 DyT 动态激活机制,提升对微小缺陷的检测能力;在 Backbone 与 Neck 网络中,本文以上下文引导模块 CGBD 替代原有卷积块,该模块能够有效融合多层次上下文信息,通过联合建模局部特征与全局语义关系,进一步提升特征表征的质量与判别能力;最后引入 EMASlideLoss 损失函数替换分类交叉熵损失函数,有效提升模型泛化性能。实验结果表明,CID-YOLO 在精度提升与复杂度控制间取得了良好平衡,其检测精度、泛化性及稳健性均优于原模型及其他主流对比算法,为工业质检提供了一种精度与效率兼顾的解决方案。后续研究将在保持现有性能均衡的基础上,进一步优化模型结构,持续提升算法的工业适用性。

参考文献

[1] Cheni C H, Hwang R C H, Huang C. PCB defect detection based on deep learning algorithm [J]. Processes, 2023, 11(3):775.
[2] Zhou Y B, Yuan M H, Zhang J, et al. Review of vision-based defect detection research and its perspectives for printedcircuit board[J]. Journal of Manufacturing Systems, 2023, 70:557-578.
[3] Redmon J, Divvala S, Girshick R, et al. You only look once: unified, real-time object detection [C]//

2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Los Alamitos, CA: IEEE Computer Society, 2016:779-788.
[4] Liu W, Anguelov D, Erhan D, et al. SSD: Single shot multibox detector [C]//Computer Vision-ECCV 2016: LNCSVolume 9905. Cham: Springer International Publishing AG, 2016: 21-37.
[5] Girshick R, Donahue J, Darrell T, et al. Richfeature hierarchies for accurate object detection andsemantic segmentation [C]//IEEE Conference On Computer Vision And Pattern Recognition, Columbus: IEEE, 2014: 580-587.
[6] Ren S Q, He K M, 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, 2017, 39(6): 1137-1149.
[7] 李澄非,蔡嘉伦,邱世汉,等. 基于改进 YOLOv4 算法的 PCB 缺陷检测 [J]. 电子测量技术, 2021, 44 (17): 146-153.
Li Chengfei, Cai Jialun, Qiu Shiha, et al. PCB defect detection based on improved YOLOv4 algorithm[J]. Electronic Measurement Technology, 2021, 44(17): 146-153.
[8] 陈枫赞,李鹏,张翔凯,等. 基于 ARS-YOLOv9s 的 PCB 缺陷检测算法 [J]. 电子测量技术, 2025, 48(14): 86-95.
Chen Fengyun, Li Peng, Zhang Xiangkai, et al. PCB defect detection algorithm based on ARS-YOLOv9s[J]. Electronic Measurement Technology, 2025, 48(14): 86-95.

- [9] 苏佳, 赵泽宇, 李佳曦. 基于改进 YOLOv10n 的 PCB 表面小目标缺陷检测算法[J]. 计算机工程与设计, 2026, 47(5): 1451-1458.
Su Jia, Zhao Zeyu, Li Jiaxi. Improved YOLOv10n-based algorithm for detecting small object defects on PCB surface[J]. Computer Engineering and Design, 2026, 47(5): 1451-1458.
- [10] 陈俊英, 李朝阳, 席月芸, 等. ViT 和注意力融合的分类不均衡 PCB 缺陷检测方法[J]. 仪器仪表学报, 2024, 45(4): 294-306.
Chen Junying, Li Zhaoyang, Xi Yueyun, et al. ViT and attention fusion for class-imbalanced PCB defect detection[J]. Chinese Journal of Scientific Instrument, 2024, 45(4): 294-306.
- [11] 陈枫赞, 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 Fengyun, Li Peng. Lightweight PCB defect detection algorithm based on STR-DETR[J]. Chinese Journal of Scientific Instrument, 2025, 39(6): 30-40.
- [12] 吴葛, 朱宇凡, 贾泽宁. 改进 YOLO11 的 PCB 表面缺陷检测方法[J]. 电子测量技术, 2025, 48(14): 136-145.
Wu Ge, Zhu Yufan, Jia Zening. Improved YOLO11 method for PCB surface defect detection [J]. Electronic Measurement Technology, 2025, 48(14): 136-145.
- [13] 张永宏, 许鑫豪, 尹贺峰, 等. MFSF-DETR: 一种基于多尺度特征移位融合的 PCB 缺陷与元件检测算法[J]. 仪器仪表学报, 2025, 46(8): 266-285.
Zhang Yonghong, Xu Xinhao, Yin Hefeng, et al. MFSF-DETR: A PCB defect and component detection algorithm based on multi-scale feature shift fusion[J]. Chinese Journal of Scientific Instrument, 2025, 46(8): 266-285.
- [14] 王彩霞, 郭鑫鹏, 刘鹏. 改进 YOLOv8n 的电路板缺陷检测算法[J]. 电子测量与仪器学报, 2025, 39(8): 65-78.
Wang Caixia, Guo Xinpeng, Liu Peng. Improved YOLOv8n algorithm for circuit board defect detection[J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(8): 65-78.
- [15] Yu W H, Zhou P, Yan S C, et al. InceptionNeXt: When inception meets ConvNeXt [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2024. 5672-5683.
- [16] Ni Y H, Guo Y X, Jia J L. On the nonlinearity of layer normalization [C]//41st International Conference on Machine Learning (ICML) 2024. American: Proceedings of Machine Learning Research, 2024: 37957-37998.
- [17] Wu T Y, Tang S, Zhang R, et al. CGNet: A lightweight context guided network for semantic segmentation [J]. IEEE Transactions on Image Processing, 2020, 30: 1169-1179.
- [18] Jiang T, Zhou J, Xie B B, et al. Improved YOLOv8 model for lightweight pigeon egg detection[J]. Animals, 2024, 14(8): 1226. MDPI. <https://doi.org/10.3390/ani14081226>.
- [19] Khanam R, Hussain M. YOLOv11: An overview of the key architectural enhancements [PP/OL]. V1. (2024-10-23). <https://arxiv.org/abs/2410.17725>.
- [20] Chollet F. Xception: Deep learning with depthwise separable convolutions [C]//IEEE Conference on Computer Vision and Pattern Recognition. Honolulu: IEEE, 2017: 1251-1258.
- [21] Sun H Z, Li Y Z, Li Z S, et al. Fourier convolution block with global receptive field for MRI reconstruction [J]. Medical Image Analysis, 2025, 99: 103349.
- [22] Han K, Wang Y H, Guo J Y, et al. ParameterNet: Parameters are all you need for large-scale visual pretraining of mobile networks [C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle: IEEE, 2024: 15751-15760.
- [23] Chen J R, Kao S H, He H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks [C]//IEEE/CVF Conference on Computer Vision and Pattern Recognition. Vancouver: IEEE, 2023: 12021-12031.
- [24] 王天洋, 刘路, 王太勇, 等. 基于改进 YOLOv8s 的轻量级 PCB 缺陷检测算法[J]. 电子测量与仪器学报, 2025, 39(3): 44-52.
Wang Tianyang, Liu Lu, Wang Taiyong, et al. Lightweight PCB defect detection algorithm based on improved YOLOv8s [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(3): 44-52.
- [25] 熊炜, 黄玉谦, 彭鑫旭. 基于改进 YOLOv8 模型的 PCB 缺陷检测算法[J]. 电子测量技术, 2025, 48(18): 159-167.
Xiong Wei, Huang Yuqian, Peng Xinxu. PCB defect detection algorithm based on improved YOLOv8 model [J]. Electronic Measurement Technology, 2025, 48(18): 159-167.

作者简介

钟长彬, 硕士研究生, 主要研究方向为机器视觉、图像处理。

E-mail: changbin_zhong@163.com

施建平 (通信作者), 副教授, 硕士生导师, 主要研究方向为机器学习、智能器件 3D 打印技术。

E-mail: jpshi@njnu.edu.cn

祝孟洋, 硕士研究生, 主要研究方向为人体活动识别。

E-mail: 1461029733@qq.com

杨宏凯, 硕士研究生, 主要研究方向为嵌入式控制系统。

E-mail: 15116153533@163.com