

文章编号:1007-2780(2025)10-1545-12

基于改进 YOLO11 的印刷电路板表面缺陷检测算法

杨彦萍^{1,2}, 高军伟^{1,2*}, 刘兆龙^{1,2}, 邢荣鑫^{1,2}

(1. 青岛大学 自动化学院, 山东 青岛 266071;

2. 山东省工业控制技术重点实验室, 山东 青岛 266071)

摘要:针对现有 PCB 缺陷检测算法在处理目标尺寸较小、背景线路复杂和形态不规则等场景时存在的精度不足、误检漏检等问题,本文提出一种基于改进 YOLO11 的 PCB 表面缺陷检测方法。首先,在主干网络中引入多尺度卷积注意力(MSCA)机制,增强对微小缺陷的检测能力。其次,采用高效特征金字塔网络(HS-FPN)替换传统颈部(Neck)结构,通过引入通道注意力机制(CA)和选择性特征融合机制(SFF)提升了模型对不同尺寸缺陷的检测能力。随后,结合 ConvFormer 与卷积门控线性单元(CGLU)改进 C3K2 模块,在降低计算复杂度的同时提升对有效特征的提取能力。最后,采用 UIoU(Unified-IoU)损失函数动态调整候选框权重分配,提升了定位精度与收敛速度。在自建的 6 类 PCB 缺陷图像数据集上的实验表明,改进后模型的 mAP 达 89.1%,相较原始 YOLO11 模型,平均检测精度提升了 5.3%,精确率提升了 2.3%,召回率提升了 6.1%,参数量降低了 28.3%,验证了所提方法在实际 PCB 缺陷检测中的有效性与应用潜力。

关键词:图像处理;PCB 缺陷检测;YOLO11;多尺度卷积注意力机制;高效特征金字塔网络

中图分类号:TP391 文献标识码:A doi:10.37188/CJLCD.2025-0137 CSTR:32172.14.CJLCD.2025-0137

Surface defect detection on printed circuit boards based on improved YOLO11

YANG Yanping^{1,2}, GAO Junwei^{1,2*}, LIU Zhaolong^{1,2}, XING Rongxin^{1,2}

(1. School of Automation, Qingdao University, Qingdao 266071, China;

2. Shandong Key Laboratory of Industrial Control Technology, Qingdao 266071, China)

Abstract: To address the challenges of low accuracy, false detections, and missed detections in PCB defect inspection under scenarios with small defect sizes, complex circuit backgrounds, and irregular defect shapes, this paper proposes a surface defect detection method based on an improved YOLOv11 architecture. First, a multi-scale convolutional attention (MSCA) mechanism is integrated into the backbone to enhance the model's sensitivity to subtle defects. Second, the neck structure is replaced with the high-level screening feature pyramid network (HS-FPN), which improves defect detection across sizes by using channel attention (CA) and selective feature fusion (SFF). Third, the original C3K2 module is enhanced by combining ConvFormer with a convolutional gated linear unit (CGLU), which improves feature representation while reducing computational cost. Furthermore, the unified-IoU (UIoU)

收稿日期:2025-06-26;修订日期:2025-08-17.

基金项目:山东省自然科学基金(No.ZR2019MF063)

Supported by Natural Science Foundation of Shandong Province (No.ZR2019MF063)

*通信联系人, E-mail: qdgao163@163.com

loss function is applied to dynamically adjust the weighting of candidate boxes, enhancing both localization accuracy and convergence speed. Extensive experiments are conducted on a self-constructed PCB dataset with six defect categories. The proposed model achieves a mean average precision (mAP) of 89.1%, surpassing the baseline YOLOv11 by 5.3% in mAP. In addition, the precision and recall are improved by 2.3% and 6.1%, respectively, while the model's parameter count is reduced by 28.3%. The results demonstrate the effectiveness and practical potential of the proposed approach for real-world PCB defect detection tasks.

Key words: image processing; PCB defect detection; YOLO11; multi-scale convolutional attention; HS-FPN

1 引言

印刷电路板(Printed Circuit Board, PCB)是电子设备的基础组成部分,广泛应用于通讯、计算机、汽车电子、医疗设备及工业自动化等多个领域。PCB通过其精密设计的导电路径和多层结构,为电子元件提供了稳定的物理支撑和电气连接,实现了复杂电子系统的集成与功能实现,其质量会直接影响到终端产品的性能和可靠性。

然而,PCB的制造工艺十分复杂,在制作以及焊接的过程中很有可能出现质量缺陷。工业生产中经常出现的缺陷主要有6种类型,包括缺孔、鼠咬、开路、短路、伪铜和杂散^[1]。这些缺陷不仅降低了良品率,也可能导致后期电子系统运行异常甚至故障。

近年来,随着深度学习技术的迅猛发展和各种硬件的不断更新换代^[2],传统人工目视检测方法已被逐渐淘汰,各类基于深度学习的自动缺陷检测方法相继被提出。现有目标检测算法大致可分为两类:一种是基于候选区域提取的两阶段算法,如R-CNN(Region with CNN Feature)^[3]、Fast R-CNN^[4]和Faster R-CNN^[5]等;另一种是一阶段检测算法,如YOLO(You Only Look Once)^[6]系列算法和SSD(Single Shot MultiBox Detector)^[7]等。胡冰等人^[8]提出了一种基于Faster R-CNN的PCB缺陷检测方法,采用集成特征金字塔结构的残差网络(ResNet50)作为主干网络,并引入GARPN与ShuffleNetV2模块,有效提升了小缺陷的检测性能。李任鹏等人^[9]提出了一种基于CNN融合多尺度特征的检测方法,并采用迁移学习将浅层特征与深度语义特征融合,改善了传统

CNN方法的性能。彭勇等人^[10]提出一种基于改进U-Net结构的检测方法,通过引入卷积块注意力模块(Convolutional Block Attention Module, CBAM)与空洞卷积(Dilated Convolution, DC)实现检测性能与效率的双提升。

近年来,YOLO系列模型因其端到端结构、较快的推理速度和良好的检测精度,在工业视觉检测的各个领域得到了广泛应用。赵天元等人^[11]提出了一种LED-YOLO方法,通过引入轻量级动态融合模块(Lightweight Dynamic Fusion Module, LDFM)和增强协调注意力模块(Enhanced Coordinate Attention Module, ECAM)提升了对Micro LED缺陷的检测精度。陈名渝等人^[12]提出了一种基于YOLOv5的双侧线光源照明方案,在冷轧钢缺陷检测任务中实现了精度的大幅提升。

针对PCB缺陷检测任务的YOLO改进研究也层出不穷。沈明辉等人^[13]基于YOLOv5架构,在颈部(Neck)结构中引入空间金字塔池化(Spatial Pyramid Pooling, SPP)以增强多尺度特征提取能力,并通过大核卷积扩大感受野,在提升精度的同时降低了计算成本。解琳等人^[14]改进了YOLOv7-tiny中的激活函数,引入集中综合卷积(C3)模块,将深度可分离卷积与C3相结合并引入卷积块注意力模块,以提高模型性能。王汉涵等人^[15]引入GhostNet和HGNetV2作为YOLOv8的主干,同时增加了小目标检测层和坐标注意力机制,使模型有了更高的特征提取效率和更好的检测性能。

针对PCB缺陷检测中目标尺寸较小、背景线路复杂、缺陷形态不规则等挑战,本文基于YOLO11架构从多个结构层面做出改进,以提升

其在 PCB 表面缺陷检测任务中的综合性能。首先,在主干网络中引入多尺度卷积注意力模块(Multi-Scale Convolutional Attention, MSCA),利用其多尺度卷积分支与通道重标定能力,增强模型对复杂背景中微小缺陷的感知能力。其次,针对原始特征融合策略不足的问题,本文将 Neck 结构替换为高效特征金字塔网络(High-level Screening Feature Pyramid Network, HS-FPN),有效提升了模型的特征融合能力,在提升检测精度的同时实现了模型的轻量化。然后,针对主干中 C3K2 模块的计算开销与表达能力不平衡的问题,本文结合 ConvFormer 结构与通道门控线性单元(Conv Gated Linear Unit, CGLU)对 C3K2 模块进行改进,在减少计算复杂度的同时抑制了冗余信息,提高了对有效特征的提取能力。最后,引入 UIoU (Unified-IoU) 损失函数,动态调整训练过程中不同质量候选框的权重分配,使模型在定位准确率和检测精度方面得到有效提升。

2 改进 YOLO11 模型

2.1 YOLO11 算法

YOLO11 是 Ultralytics 公司推出的新一代目标检测模型,在继承 YOLO 系列高效实时检测框架优势的基础上,针对模型的检测精度与计算效

率进行了多方面改进优化,其主要创新体现在几个关键模块的优化上^[16]:

(1)在骨干网络部分,YOLO11 将 YOLOv8 中的 C2f 模块替换为新的 C3K2 模块。C3K2 模块基于 CSP 架构设计,采用了更高效的瓶颈结构,通过两个连续的 3×3 卷积操作代替了大卷积核的使用,有效减小了计算复杂度和参数规模,同时提高了细粒度特征提取和小目标建模的效率。

(2)在骨干网络的 SPPF 模块之后,YOLO11 新增了 C2PSA 模块。利用多头位置敏感注意力机制(Position-Sensitive Attention, PSA)^[17]在特征融合阶段引入空间注意力机制,有效帮助模型在复杂背景下聚焦关键目标区域,提高了模型处理小物体检测与复杂线路背景等场景下的效率。

(3)在检测头设计上,YOLO11 在解耦头内部进一步进行了轻量化设计,新增了两个深度可分离卷积(Depthwise Separable Convolution, DWConv),这种卷积操作显著降低了模型的参数量和计算量。

经过上述一系列改进,YOLO11 模型在小目标检测、复杂背景适应与高效实时检测任务中的综合性能显著提升,尤其契合本文所研究的 PCB 表面缺陷检测任务需求,对任务中常见的缺陷类型具有良好的识别能力。




图1 YOLO11 网络结构图

Fig. 1 YOLO11 network architecture diagram

2.2 多尺度卷积注意力机制

在PCB缺陷检测任务中,对细粒度条带状结构以及微小缺陷的有效检测始终是目标检测算法面临的重要挑战。尤其是在检测鼠咬、杂散、伪铜等呈现条带状或不规则几何形态的微小缺陷时,传统YOLO中的卷积骨干或注意力机制往往难以实现有效关注与区分。

为弥补这一不足,本文引入了SegNeXt^[18]中提出的多尺度卷积注意力模块(MSCA)。与传统的自注意力机制或普通卷积核不同,MSCA基于卷积构建注意力路径,结合深度可分离卷积与多分支条带卷积结构,具备较强的感受野适应性与空间建模能力。首先,通过深度可分离卷积(DWConv)对输入特征图进行初步局部信息聚合;随后采用多分支深度可分离条带卷积(Separable Strip Convolution),设计了4个尺度分支(Scale₀-Scale₃)分别对应不同大小感受野:

Scale₀采用恒等映射(Identity)保留原始特征,确保浅层信息不被削弱;Scale₁使用两组7×1与1×7的DWConv条带卷积,等效模拟7×7的大核卷积,从中短距离感受野提取结构特征;Scale₂采用两组11×1与1×11的DWConv条带卷积,进一步增强模型对较大区域上下文信息的感知能力;Scale₃采用两组21×1与1×21的DWConv条带卷积,从更大感受野捕获长距离空间依赖,有效提升模型对远程结构信息的建模能力。

各分支在不同尺度与方向上捕获图像结构特征后,利用1×1逐点卷积进行通道融合生成空间注意力权重图Att,该注意力图通过逐元素乘法与输入特征图进行加权融合,以增强关键区域并抑制背景噪声,最终形成输出特征Out,整体计算过程可表达为:

$$Att = \text{Conv}_{1 \times 1} \left(\sum_{i=0}^3 \text{Scale}_i (\text{DW-Conv}(F)) \right), \quad (1)$$

$$Out = Att \otimes F, \quad (2)$$

其中: F 表示输入特征,Scale _{i} 表示第 i 个多尺度分支, $\otimes$ 表示逐元素乘法操作。MSCA结构如图2所示。

这种条带卷积设计能高效捕捉细长结构和方向性纹理特征,尤其适用于PCB缺陷检测中常见的伪铜、杂散等缺陷形态。值得注意的是,尽




图2 MSCA注意力机制结构图

Fig. 2 Structure of MSCA attention mechanism

管使用较大卷积核可能会增加模型计算量,但在本任务中,这些较大卷积核能够显著扩展感受野,从而帮助模型捕捉更大范围的上下文信息。在检测某些特征不明显的微小缺陷时,大卷积核能够有效捕捉缺陷的全局结构特征,从而更好地理解缺陷与背景线路之间的关系,提高了模型对缺陷的检测能力。

在本文设计中,将MSCA模块嵌入YOLO11的主干网络中,在每个C3k2模块之后均增添一个MSCA分支。通过空间维度的特征增强与通道维度的动态重标定双重机制,MSCA有效强化了模型对复杂线路背景以及细粒度缺陷的特征感知与表达能力,从而提升了整体检测精度。

2.3 高效特征金字塔网络

在PCB缺陷检测任务中,不同类型的缺陷在形状、尺寸等方面具有显著差异。不同缺陷区域展示出不同的特征,这要求模型能够从多个尺度提取并融合有效特征,以实现对各类缺陷的精准识别。

因此,本文引入了高效特征金字塔网络(HS-FPN)结构^[19],以实现高层语义信息与低层细节之间的融合。HS-FPN模块由特征选择模块和特征融合模块两个主要部分组成,其结构图如图3所示。其核心设计思路是引入通道注意力(Channel Attention, CA)机制和选择性特征融合(Selective Feature Fusion, SFF)机制,使得不同尺度的特征能够更加有效地融合,从而提升细粒度缺陷检测的精度,增强模型对多尺度特征的处理能力。

具体而言,在特征选择模块中,模型通过引入通道注意力机制来优化特征图的选择。输入的特征图首先通过全局平均池化(Global Average Pooling)和全局最大池化(Global Max




图 3 HS-FPN 网络结构

Fig. 3 Network structure of HS-FPN

Pooling)操作计算每个通道的平均值和最大值,这样可以提取每个通道的关键信息。然后,利用 Sigmoid 激活函数生成每个通道的注意力权重,并将其与输入特征图逐通道相乘,实现特征加权。通过这种方式,HS-FPN 能够更加关注较为重要的特征,抑制了冗余信息的干扰。

在特征融合模块中,HS-FPN 通过选择性特征融合(SFF)机制进一步优化多尺度特征的融合过程。首先,高层特征图通过转置卷积(T-Conv)进行上采样,使其尺寸与低层特征一致。接着,使用双线性插值(Bilinear Interpolation)对高层特征进行尺寸调整,使其与低层特征的空间维度对齐。然后,采用通道注意力机制对低层特征进行加权,确保低层特征中最有意义的部分得到加强。最终,经过加权的低层特征与调整后的高层特征进行融合,生成最终的融合特征图。公式(3)、(4)说明了特征选择的融合过程:

$$f_{att} = BL(T - \text{Conv}(f_{high})), \quad (3)$$

$$f_{out} = f_{low} \times CA(f_{att}) + f_{att}, \quad (4)$$

其中: f_{high} 、 f_{low} 分别为高层特征和低层特征, f_{att} 为采样后的特征, f_{out} 为输出特征。

通过这种加权融合方式,HS-FPN 能够高效地结合低层特征的精确定位能力和高层特征的语义信息,从而能够在 PCB 缺陷检测任务中更加精准地处理不同类型的缺陷,进一步提升了检测精度。同时,这种精确的加权融合策略也避免了冗余计算和不必要的特征传递,显著降低了模型的参数量和计算复杂度,在提高检测精度的同时实现了一定的轻量化效果。

2.4 改进的 C3K2 模块

在 YOLO11 网络中,C3K2 模块作为主干结

构的重要组成部分,承担着多尺度特征提取与局部上下文建模的关键任务。该模块采用堆叠的 3×3 卷积结构,能够有效提升模型的空间感知能力,特别适用于细节特征提取。然而,随着 MSCA 注意力机制的引入,模型对特征表达的要求显著提高,原有 C3K2 模块在跨通道交互、长距离依赖建模等方面的能力显得相对不足,难以充分利用 MSCA 增强的上下文信息,从而限制了整体检测性能的进一步提升。

为此,本文提出将模型中的 C3K2 模块替换为融合了 ConvFormer 结构与通道门控线性单元(CGLU)的 C3K2-ConvFormer-CGLU 模块。ConvFormer 模块基于 MetaFormer 架构设计,通过将传统的卷积神经网络 CNN 与深度可分离卷积(DWConv)结合,替代了传统 Transformer 中的自注意力机制,引入了更轻量化的 Token Mixing 机制^[20]。作为 MetaFormer 框架下的一种实现,DWConv 构成的 Token Mixer 有效模拟 Transformer 中的跨空间交互能力,同时避免了传统自注意力机制中的高计算成本,降低了计算复杂度。在空间信息交互后,卷积前馈网络(Convolutional Feed-Forward Network, CFFN)通过逐点卷积与非线性激活进一步重构通道特征,配合归一化操作提升模块整体特征表达能力与训练稳定性。

在 ConvFormer 完成空间与通道特征建模后,本文继续引入 CGLU 激活单元,实现通道动态加权与非线性增强。具体而言,CGLU 将输入特征 X 映射为主特征 A 与门控权重 B ,后通过逐元素门控激活实现通道自适应加权^[21],其计算过程如式(5)和式(6)所示:

$$A = W_a * X, B = W_b * X, \quad (5)$$

$$\text{CGLU}(X) = A \otimes \sigma(B), \quad (6)$$

其中: W_a 与 W_b 为两组卷积权重, $*$ 表示卷积操作, σ 表示 Sigmoid 激活函数, $\otimes$ 表示逐元素乘法操作。与传统的激活函数(如 ReLU 或 Swish)相比, CGLU 采用门控机制对不同通道特征进行选择增强, 能够有效抑制冗余信息、突出关键特征, 在提升通道动态建模能力的同时增强整体非线性表达能力。

在整体结构实现中, C3K2-ConvFormer-CGLU 模块仍沿用 CSP 跨阶段分支框架, 在残差路径中

堆叠多个子模块。在具体实现中, 根据控制参数 C3K 设定不同的子模块类型: 当 C3K=True 时, 残差分支中堆叠 C3K_ConvFormerCGLU 模块, 每个模块内部融合了 ConvFormer 与 CGLU 结构, 形成基于 CSP 结构的更深层次特征建模; 当 C3K=False 时, 残差分支则采用更轻量的 MetaFormerCGLUBlock 作为基础单元, 直接堆叠 ConvFormer 与 CGLU 融合结构以降低计算开销, 如图 4 所示。该设计使模型表现出了更优的特征建模能力, 同时也兼顾了推理速度与模型轻量化需求。




图 4 C3K2-ConvFormer-CGLU 结构图

Fig. 4 Structure of C3K2-ConvFormer-CGLU

2.5 损失函数改进

在本研究的 PCB 缺陷检测任务中, 目标通常具有小尺寸、不规则结构等特点, 这对边界定位精度提出了极高要求。现有的 IoU 类边界框回归损失函数, 如 GIoU (Generalized IoU)^[22]、DIoU (Distance IoU) 以及 CIoU (Complete IoU)^[23] 等, 尽管在考虑几何误差方面表现出色, 但这些方法普遍默认训练过程中所有预测框的重要性相等, 而忽视了不同质量的预测框在训练过程中的差异性贡献。尤其在检测目标较小和数量较多的检测场景下, 当低质量预测框数量较多或占比较大时, 容易在训练过程中对模型产生过多干扰, 从而影响模型的整体检测性能。

为此, 本文使用了一种基于预测框质量动态赋权的 IoU 回归损失函数 UIoU (Unified-IoU), 以更好地适应 PCB 缺陷检测中高精度定位的需求。UIoU 的核心思想在于: 通过调整预测框的权重分配, 使模型在训练不同阶段合理地聚焦于不同质量的预测框。具体而言, UIoU 通过设计

缩放机制对预测框与真实框进行比例缩放, 间接放大或抑制高低质量预测框的回归损失: 在训练初期, 由于高质量预测框数量较少, 为加快收敛速度, 采用放大策略, 使模型关注低质量预测框, 快速学习整体目标分布特征; 在训练后期, 随着模型逐步收敛, 切换为缩小策略, 放大高质量预测框的回归损失, 引导模型进一步优化边界定位精度。

在实际训练中, 为适应不同阶段模型学习需求, UIoU 引入了动态缩放因子 ratio, 对缩放倍率进行动态调整。ratio 的更新策略采用余弦退火 (Cosine Annealing) 形式:

$$\text{ratio} = 0.75 \cdot \cos\left(\frac{\pi \cdot \text{epoch}}{T}\right) + 1.25, \quad (7)$$

其中: epoch 为当前训练轮数, T 为训练总轮数。在训练早期, $\text{ratio} > 1$, 模型更多地关注低质量预测框; 在训练后期, $\text{ratio} < 1$, 模型逐渐聚焦高质量预测框, 从而实现训练速度与检测精度的动态平衡。改进后的 YOLO11 模型结构如图 5 所示。




图 5 改进后的 YOLO11 网络结构图

Fig. 5 Improved YOLO11 network structure diagram

3 实验与结果分析

3.1 实验环境

实验在服务器上进行,其操作系统版本为 Ubuntu16.04,配置了 4 张 3090 显卡与主频为 2.10 GHz 的 Intel Xeon Silver4216 处理器。深度学习框架选用了 Pytorch2.0.0, CUDA 版本为 11.8。模型训练过程中,最大迭代轮数设置为 300, batch-size 设置为 32, img-size 设置为 640×640 , 初始学习率设为 0.01, 权重衰减系数设为 0.0005。

3.2 数据集的准备

本文收集了多个实习项目和竞赛活动中手

工焊接的电路板,并通过人工拍摄的方式获取了多种典型缺陷的图像样本。为了提升数据的多样性与模型的泛化能力,采用多种图像增强策略对原始样本进行扩展,包括水平翻转、目标区域裁剪、对比度调整以及旋转缩放等方法。然后利用 LabelImg 标注工具对增强后的缺陷图像进行标注,标注内容覆盖了 6 类常见的 PCB 表面缺陷。最终构建的数据集共包含 4 263 张图像, 23 797 个目标实例。表 1 对各类别目标的数量分布做了详细统计,图 6 展示了部分图像中表面缺陷的局部放大效果,从左到右每一列缺陷分别为缺孔 (Missing_hole)、鼠咬 (Mouse_bite)、开路 (Open_circuit)、短路 (Short)、伪铜 (Spurious) 和




图 6 数据集图片示例

Fig. 6 Example of dataset images

表 1 数据集中目标分类及数量

Tab. 1 Classification and number of targets in the dataset

Defect type	Training set	Validation set	Total
Missing_hole	10 049	2 341	12 390
Mouse_bite	1 819	549	2 368
Open_circuit	1 976	436	2 412
Short	1 784	392	2 176
Spur	1 753	426	2 179
Spurious	1 751	521	2 272

杂散(Spur)。

3.3 实验评估指标

为全面评估改进的 YOLO11 模型在 PCB 表面缺陷检测任务中的性能表现,本文从检测精度与模型复杂度两个维度对模型进行评估。具体地,使用平均精度均值(mean Average Precision, mAP)、精确率(Precision, P)、召回率(Recall, R)来评价模型检测效果;同时,使用参数量(Params)和浮点运算次数(GFLOPs)来评估模型的计算复杂度。其计算公式分别如式(8)~式(10)所示:

$$P = \frac{T_p}{T_p + F_p}, \tag{8}$$

$$R = \frac{T_p}{T_p + F_N}, \tag{9}$$

$$mAP = \frac{\sum_0^1 P(R) dR}{N}, \tag{10}$$

其中: T_p 表示模型正确检测为某类缺陷的样本数, F_p 指模型将非该类缺陷误判为该类的数量, F_N 表示模型未能识别出实际为该类缺陷的样本数; P 衡量模型在预测为某一类缺陷中,实际为真值的占比; R 则反映了模型从全部真实缺陷中识别出的比例; mAP 是所有类别在不同置信度阈值下绘制 Precision-Recall 曲线后计算各类别 AP 的平均值,是衡量多类别目标检测综合性能的重要指标。

在评估模型计算复杂程度方面,参数量反映了网络中可学习权重的规模,是模型存储成本的重要体现;而 GFLOPs 表示单次前向传播的浮点运算次数,能直观反映模型推理过程的计算强度。在保证检测精度的前提下,参数量与 GFLOPs 越小,说明模型越具备轻量化和高效

性,更适用于资源受限的实际工业环境。

3.4 实验结果与分析

3.4.1 消融实验

为了验证本文提出的针对 PCB 表面缺陷检测的改进 YOLO11 模型方法的有效性,在相同的实验环境和数据集下进行了消融实验,通过逐一添加不同的改进模块,观察其对模型性能的贡献,具体方法包括:增添 MSCA 注意力机制、更换 HS-FPN 高效特征金字塔网络、结合 ConvFormer 和 CGLU 改进 C3K2 模块以及引用 UIoU 损失函数,表 2 展示了不同方法组合下的实验结果。

从表 2 可见,原始 YOLO11 模型作为基准模型,其平均精度(mAP)为 83.8%,精确率(P)为 89.1%,召回率(R)为 78.1%。在单独引入 MSCA 注意力机制后,模型对表面细节与小目标的感知能力得到增强,mAP 达到 85.3%,精度提升了 1.5%,但模型的浮点运算量从 6.4G 增加到 7.4G,计算开销略有增加。单独采用 HS-FPN 替换原有的特征融合网络后,模型的 mAP 提升至 85.8%,比基准模型高出 2.0%,同时参数量降低了 29.5%,GFLOPs 降低了 0.8G,达到了轻量化的效果。将 C3K2 模块替换为 C3K2-ConvFormer-CGLU 结构后,改进的特征建模方式有效提升了模型对小目标和边界复杂区域的检测能力,mAP 达到了 85.6%,较原模型提升了 1.8%;同时模型参数量减少 0.27M,GFLOPs 降低了 0.3G,体现出更高的计算效率。单独引入 UIoU 损失函数后,通过对预测框质量进行动态加权,增强了模型对高质量边界框的关注,mAP 提升至 85.0%,且实验过程中目标定位精度及模型训练收敛速度都有相应提升。

在多项改进中,当同时引入 MSCA 注意力机制和 HS-FPN 网络后,模型的 mAP 提升至 86.4%,精度上涨效果优于单独引入 MSCA 或 HS-FPN 结构进行改进,较原模型提升了 2.6%,同时精确率与召回率也实现了同步提高。继续引入改进后的 C3K2-ConvFormer-CGLU 模块后,mAP 进一步提升至 86.9%,且参数量降低了 0.14M,GFLOPs 降低了 0.2G,这一改进使模型在精度和计算效率上达到了更好的平衡。在此基础上改用 UIoU 损失函数后,模型的平均检测精度达到了 89.1%,精确率达到 91.4%,召回率

表 2 消融实验
Tab. 2 Ablation experiments

MSCA	HS-FPN	C3k2-ConvFormer- CGLU	Unified-IoU	mAP/%	P/%	R/%	Params/M	GFLOPs/G
✓	✓	✓	✓	83.8	89.1	78.1	2.58	6.4
				85.3	88.8	79.2	2.75	7.4
				85.8	92.3	79.1	1.82	5.6
				85.6	89.6	79.6	2.31	6.1
✓	✓			85.0	88.8	79.1	2.58	6.3
✓	✓			86.4	91.2	80.6	1.99	6.7
✓	✓	✓		86.9	90.4	82.1	1.85	6.5
✓	✓	✓	✓	89.1	91.4	84.2	1.85	6.5

提升至 84.2%。在多模块协同作用下,改进后的 YOLO11 模型较原模型的平均检测精度上涨了 5.3%,精确率上涨了 2.3%,召回率上涨了 6.1%,这一结果证明了各个改进方法在实际应用中的有效性与协同效应。

3.4.2 多种模型检测结果对比

在消融实验的基础上,为进一步验证本文所提改进方法的有效性和综合性能,将改进后的 YOLO11 模型与其他主流 YOLO 系列模型在相同实验配置和统一数据集上进行了对比实验。仍然采用 mAP、Precision、Recall、Params 以及 GFLOPs 作为模型评价指标,实验结果如表 3 所示。可以看到,我们选取的基准模型 YOLO11 在平均精度方面高于其他大部分模型,仅次于 YOLOv9t 模型。然而,YOLOv9t 模型取得的较好效果很大程度上依赖于其高浮点运算量,在实际运行中,其运行时间与计算开销均远高于 YOLO11,无法兼

顾精度与效率的平衡。而改进后模型的平均精度、精确率和召回率均得到了有效提升,最终效果明显优于 YOLO 系列其他模型。值得注意的是,改进后模型在引入多模块后,GFLOPs 基本没有增加,且整体参数量下降至 1.85M,是所有对比模型中最小的。这一结果表明,改进后的 YOLO11 模型在模型精度、运算效率与模型复杂度之间实现了更优的平衡。

为了更加全面地观察不同算法模型在本文数据集上的表现,我们选取了部分缺陷样本图片在上述算法模型上进行了检测,图 7 展示了不同算法对同一样本的检测结果示例图。

可以看到,部分算法出现了一定程度的漏检或误检问题,尤其是在某些微小且特征相近的缺陷类别上。而改进后的 YOLO11 模型在正确识别缺陷类型方面表现更加优异,进一步验证了改进后模型在提高检测精度方面的优势。

3.4.3 不同数据集结果对比

为进一步验证所提模型的泛化能力,本文另外选取北京大学实验室公开发布的印刷电路板缺陷数据集 PKU-Market-PCB 以及 GitHub 平台上的 DeepPCB 数据集,对模型进行补充评估。考虑到这两个数据集原始样本较少,难以全面反映模型性能,本文对其进行了数据增强处理后再进行实验,实验结果如表 4 所示。可以看到,在与本文自建数据集特征相近且无焊接痕迹的 PKU-Market-PCB 数据集上,平均精度得到了 6.4% 的大幅提升;而在已通过线性扫描转为黑白像素形式的 DeepPCB 数据集上,尽管缺乏颜色和纹理信息,其平均精度仍实现了 2.6% 的提升。该部

表 3 不同算法模型的检测结果
Tab. 3 Detection results of different algorithm models

Model	mAP/ %	P/ %	R/ %	Params/ M	GFLOPs/ G
YOLOv5	83.6	89.4	78.7	1.77	4.2
YOLOv6	83.5	90.5	77.7	4.23	11.8
YOLOv7-tiny	67.9	83.7	62.9	6.03	13.2
YOLOv8	82.9	88.4	78.3	3.01	8.1
YOLOv9t	85.0	88.2	80.8	2.66	11.0
YOLOv10n	82.1	89.3	76.1	2.70	8.2
YOLO11n (Original)	83.8	89.1	78.1	2.58	6.4
YOLO11n (Improved)	89.1	91.4	84.2	1.85	6.5




图 7 不同算法检测结果示例图

Fig. 7 Example diagram of different algorithm detection results

表 4 不同数据集的检测结果

Tab. 4 Detection results of different datasets

Datasets	Models	mAP/%	P/%	R/%	Params/M	GFLOPs/G
Ours	YOLO11n(Original)	83.8	89.1	78.1	2.58	6.4
Ours	YOLO11n(Improved)	89.1	91.4	84.2	1.85	6.5
PKU-Market-PCB	YOLO11n(Original)	74.4	86.1	66.8	2.58	6.4
PKU-Market-PCB	YOLO11n(Improved)	81.2	89.0	75.4	1.85	6.5
DeepPCB	YOLO11n(Original)	91.5	90.3	85.1	2.58	6.4
DeepPCB	YOLO11n(Improved)	94.1	93.6	84.8	1.85	6.5

分实验结果进一步验证了改进后模型在不同数据分布和图像特征条件下的良好泛化能力。

4 结 论

针对 PCB 表面缺陷检测中存在的微小目标难以识别、形态不规则、线路背景复杂等问题,本文提出了一种基于改进 YOLO11 的目标检测模型。首先,在主干网络中引入了多尺度卷积注意力机制(MSCA),通过多分支条带卷积结构对不同尺度和方向的细节特征进行建模,有效提升了模型对微小缺陷区域的感知能力。其次,针对传统特征金字塔结构在多尺度信息融合中的局限性,本文将模型的颈部(Neck)结构替换为高效特征金字塔网络(HS-FPN),能够有效融合高低层之间的特征信息,提升模型的检测性能,也使得

模型更加轻量。为了进一步降低模型计算复杂度并增强特征表达能力,本文提出将主干中的 C3K2 模块替换为更轻量化的 C3K2-ConvFormer-CGLU 模块,在提高检测精度的同时压缩了模型参数量与运算量。最后,针对目标检测中常见的边框回归不稳定问题,本文引入了 UIoU 损失函数,引导模型动态关注不同质量的候选框,从而提高边界回归的准确性与训练过程中的收敛速度。

实验结果表明,改进后的 YOLO11 模型在我们制作的 PCB 缺陷数据集上取得了 89.1% 的 mAP,较原始模型提升 5.3%;同时在精确率和召回率上分别提升了 2.3% 和 6.1%,参数量降低了 28.3%,实现了检测精度与推理效率的良好平衡,为实际生产环境中的 PCB 缺陷检测任务提供了具有实用价值的技术路径与模型优化方案。

参 考 文 献:

[1] XIAO G S, HOU S L, ZHOU H Y. PCB defect detection algorithm based on CDI-YOLO [J]. *Scientific Reports*,

- 2024, 14(1): 7351.
- [2] SITU G. Deep holography [J]. *Light: Advanced Manufacturing*, 2022, 3(2): 278-300.
- [3] AGRAWAL P, GIRSHICK R, MALIK J. Analyzing the performance of multilayer neural networks for object recognition [C]//*Proceedings of the 13th European Conference on Computer Vision*. Zurich, Switzerland: Springer, 2014: 329-344.
- [4] GIRSHICK R. Fast R-CNN [C]//*Proceedings of 2015 IEEE International Conference on Computer Vision*. Santiago: IEEE, 2015: 1440-1448.
- [5] REN S Q, HE K M, GIRSHICK R, *et al.* Faster R-CNN: towards real-time object detection with region proposal networks [C]//*Proceedings of the 29th International Conference on Neural Information Processing Systems*. Montreal: MIT Press, 2015: 91-99.
- [6] REDMON J, FARHADI A. YOLO9000: better, faster, stronger [C]//*Proceedings of 2017 IEEE Conference on computer Vision and Pattern Recognition*. Honolulu: IEEE, 2017: 6517-6525.
- [7] LIU W, ANGUELOV D, ERHAN D, *et al.* SSD: single shot MultiBox detector [C]//*Proceedings of the 14th European Conference on Computer Vision-ECCV 2016*. Amsterdam: Springer, 2016: 21-37.
- [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] 李任鹏, 李云峰. CNN融合多尺度特征的PCB裸板缺陷识别[J]. *智能计算机与应用*, 2023, 13(10): 65-72.
- LI R P, LI Y F. PCB bare board defect identification based on multi-scale CNN [J]. *Intelligent Computer and Applications*, 2023, 13(10): 65-72. (in Chinese)
- [10] 彭勇, 刘慧民, 李伟松, 等. 基于改进 U-Net 网络的 PCB 缺陷检测方法[J]. *计算技术与自动化*, 2025, 44(1): 183-188.
- PENG Y, LIU H M, LI W S, *et al.* PCB defect detection method based on improved U-Net network [J]. *Computing Technology and Automation*, 2025, 44(1): 183-188. (in Chinese)
- [11] 赵天元, 董登峰, 王国名, 等. Micro LED 表面缺陷的快速高精度检测[J]. *光学精密工程*, 2025, 33(9): 1434-1445.
- ZHAO T Y, DONG D F, WANG G M, *et al.* Rapid and high-precision detection on surface defects of Micro LED [J]. *Optics and Precision Engineering*, 2025, 33(9): 1434-1445. (in Chinese)
- [12] 陈名渝, 谢玥辰, 吕雄涛, 等. 冷轧钢表面与内部缺陷检测研究[J]. *中国光学*, 2024, 17(4): 823-833.
- CHEN M Y, XIE Y C, LV X T, *et al.* Detection of surface and internal defects in cold rolled steel [J]. *Chinese Optics*, 2024, 17(4): 823-833. (in Chinese)
- [13] SHEN M H, LIU Y J, CHEN J, *et al.* Defect detection of printed circuit board assembly based on YOLOv5 [J]. *Scientific Reports*, 2024, 14(1): 19287.
- [14] 解琳, 韩跃平, 翟倩, 等. 基于改进 YOLOv7-tiny 的 PCB 表面缺陷检测[J]. *测试技术学报*, 2025, 39(1): 81-87.
- XIE L, HAN Y P, ZHAI Q, *et al.* PCB surface defect detection based on improved YOLOv7-tiny [J]. *Journal of Test and Measurement Technology*, 2025, 39(1): 81-87. (in Chinese)
- [15] WANG H H, SHEN S H, LI M Z. PCB defect detection algorithm based on improved YOLOv8 [C]//*Proceedings of 2024 5th International Conference on Electronic Communication and Artificial Intelligence (ICECAI)*. Shenzhen, China: IEEE, 2024: 323-327.
- [16] 张志豪, 厉小润, 陈淑涵. 基于改进 YOLO11 的无人机航拍图像小目标检测算法[J]. *液晶与显示*, 2025, 40(6): 915-930.
- ZHANG Z H, LI X R, CHEN S H. Small object detection algorithm in UAV aerial images based on improved YOLO11 [J]. *Chinese Journal of Liquid Crystals and Displays*, 2025, 40(6): 915-930. (in Chinese)
- [17] ZHAO H S, ZHANG Y, LIU S, *et al.* PSANet: point-wise spatial attention network for scene parsing [C]//*Proceedings of the 15th European Conference on Computer Vision*. Munich: Springer, 2018: 270-286.
- [18] GUO M H, LU C Z, HOU Q B, *et al.* SegNeXt: Rethinking convolutional attention design for semantic segmentation [C]//*Proceedings of the 36th International Conference on Neural Information Processing Systems*. New Orleans: Curran Associates Inc., 2022: 84.

- [19] SHI Z C, HU J, REN J, *et al.* HS-FPN: high frequency and spatial perception FPN for tiny object detection [C]// *Proceedings of the 39th AAAI Conference on Artificial Intelligence*. Philadelphia: AAAI Press, 2025: 6896-6904.
- [20] YU W H, SI C Y, ZHOU P, *et al.* MetaFormer baselines for vision [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2024, 46(2): 896-912.
- [21] DAUPHIN Y N, FAN A, AULI M, *et al.* Language modeling with gated convolutional networks [C]// *Proceedings of the 34th International Conference on Machine Learning*. Sydney: PMLR, 2017: 933-941.
- [22] REZATOFIGHI H, TSOI N, GWAK J Y, *et al.* Generalized intersection over union: a metric and a loss for bounding box regression [C]// *Proceedings of 2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Long Beach: IEEE, 2019: 658-666.
- [23] ZHENG Z H, WANG P, LIU W, *et al.* Distance-IoU loss: faster and better learning for bounding box regression [C]// *Proceedings of the 34th AAAI Conference on Artificial Intelligence*. New York: AAAI Press, 2020: 12993-13000.

作者简介:



杨彦萍,女,硕士研究生,2023年于青岛大学获得学士学位,主要从事计算机视觉与模式识别方面的研究。E-mail: 826376139@qq.com



高军伟,男,博士,教授,2003年于中国铁道科学研究院获得博士学位,主要从事模式识别及智能控制方面的研究。E-mail: qdgao163@163.com