

基于改进 YOLOv12n 的 PCB 缺陷检测算法研究*

王宇^{1,2} 魏利胜¹ 张平改^{1,2,3} 胡保玲²

(1. 安徽工程大学电气工程学院 芜湖 241000; 2. 巢湖学院计算机与人工智能学院 巢湖 238024;

3. 上海大学机电工程与自动化学院 上海 200444)

摘要:针对工业边缘设备计算资源受限环境下印刷电路板缺陷检测模型存在轻量化与检测精度难以兼顾的难题,提出一种基于 YOLOv12n 的轻量化 PCB 缺陷检测算法。首先,设计融合令牌混合器采用深度可分离卷积的 C3K2-CF 模块,在具有更少参数的同时提高对小目标的感知能力;其次,提出一种新的特征融合增强网络(feature fusion enhancement network, FFEN),在跨尺度特征传递中保证目标信息的完整,从而强化模型对目标的关注能力;再次,设计一种特征聚焦融合模块(feature-focused fusion, FFF),实现多尺度上下文信息的充分融合,增强模型对复杂特征提取能力;最后,针对 PCB 缺陷检测中的小目标漏检的问题,引入任务对齐动态检测头(task-aligned dynamic detection head, TADDH),打通定位与分类双检测头的信息交互通道,进而提升模型对小尺寸缺陷的检测精度。实验结果表明,与原始 YOLOv12n 模型相比,改进算法在数据增强的 PKU-Market-PCB 数据集上 mAP@0.5 达到 98.6%,更严格的 mAP@0.5:0.95 指标提升了 7.2%,参数量和计算量分别减少 47.2%和 16.9%。在 Deep PCB 公开数据集上,改进模型的检测精度 mAP@0.5 达到 97.5%,mAP@0.5:0.95 提升了 2.5%。由此可知,改进算法有效地实现了高精度的 PCB 缺陷检测,满足工业场景下的泛化小目标的检测需求。

关键词: 印刷电路板;缺陷检测;计算机视觉;特征提取;多特征融合

中图分类号: TP391;TN912

文献标识码: A

国家标准学科分类代码: 520.20

Research on PCB defect detection algorithm based on improved YOLOv12n

Wang Yu^{1,2} Wei Lisheng¹ Zhang Pinggai^{1,2,3} Hu Baoling²

(1. School of Electrical Engineering, Anhui Polytechnic University, Wuhu 241000, China;

2. School of Computer Science and Artificial Intelligence, Chaohu University, Chaohu 238024, China;

3. School of Mechatronic Engineering and Automation, Shanghai University, Shanghai 200444, China)

Abstract: Aiming at the problem that the defect detection model of printed circuit boards in the environment of limited computing resources of industrial edge devices is difficult to balance lightweight and detection accuracy, a lightweight PCB defect detection algorithm based on YOLOv12n is proposed. Firstly, the design of the fusion token mixer adopts the C3K2-CF module of depthwise separable convolution, which not only reduces the number of parameters but also enhances the perception ability for small targets. Secondly, a new feature fusion enhancement network FFEN is proposed to ensure the integrity of the target information in cross-scale feature transfer, thereby strengthening the model's ability to pay attention to the target. Secondly, a feature-focused fusion module FFF is designed to fully integrate multi-scale context information and enhance the model's ability to extract complex features. Finally, to address the issue of missed detection of small targets in PCB defect detection, the task-aligned dynamic detection head TADDH is introduced. This enabled the information exchange channel between the localization and classification dual detection heads to be established, thereby improving the detection accuracy of the model for small-sized defects. The experimental results show that, compared

收稿日期: 2025-08-13 Received Date: 2025-08-13

* 基金项目: 安徽省自然科学基金项目(2308085QF205)、安徽省高校自然科学研究重点项目(2025AHGXZK30132, 2024AH051323)、安徽省高校中青年教师培养行动项目(YQYB2025032)、安徽省高校理工科教师赴企业挂职实践计划项目(2025jsqygz72)、安徽省高校自然科学优秀科研创新团队(2024AH010022)、电气传动与控制安徽省重点实验室开放基金资助项目(DQKJ202402)、巢湖学院产学研合作项目(hxkt20240009)资助

with the original YOLOv12n model, the improved algorithm achieves an mAP@0.5 of 98.6% on the PKU-Market-PCB dataset with data augmentation. The stricter mAP@0.5:0.95 metric has been improved by 7.2%. The parameter count and computational cost have been reduced by 47.2% and 16.9%, respectively. On the Deep PCB public dataset, the improved model achieved a detection accuracy of 97.5% mAP@0.5, representing a 2.5% improvement over mAP@0.5:0.95. It can be seen from this that the improved algorithm effectively achieves high-precision PCB defect detection and meets the detection requirements of generalized small targets in industrial scenarios.

Keywords: printed circuit board; defect detection; computer vision; feature extraction; multi-feature fusion

0 引言

印刷电路板 (printed circuit board, PCB) 作为电子产品的核心基础部件,其设计精度与制造良率,直接决定了电子设备的运行稳定性与综合性能。随着电子信息技术的高速迭代,PCB 向高密度、精细化、小型化方向快速发展,其设计与生产工艺流程愈发复杂,生产全流程中任意环节的工艺偏差,都可能引发短路、断路、毛刺等各类细微缺陷^[1]。这类缺陷普遍具有尺寸微小、隐蔽性强、特征辨识度低的特点,大幅提升了检测难度;而传统人工目视检测不仅检测效率难以匹配规模化生产线节拍,还易受检测人员主观状态、视觉疲劳等因素影响,出现误检、漏检问题。因此,研发高效、高精度、高鲁棒性的 PCB 缺陷检测技术,对电子制造行业提升产品良品率、降低生产制造成本,具有至关重要的工程应用价值。

当前工业生产场景中,PCB 缺陷检测方法主要分为传统检测方法与基于深度学习的检测方法两大类。传统 PCB 缺陷检测手段以人工目视检查、电气性能测试、超声扫描检测及红外热成像检测为核心代表^[2]。但传统 PCB 缺陷检测方法普遍存在检测精度低、效率差、成本高、易损伤元器件的短板,难以满足现代电子制造的检测需求。

针对传统检测方法的诸多固有局限,基于深度学习的目标检测算法凭借强大的自适应特征学习能力与优秀的泛化性能,有效突破了传统方法的技术瓶颈,现已被广泛应用于各类工业缺陷检测场景。按照检测流程的核心差异,基于深度学习的目标检测算法可分为两阶段检测算法与单阶段检测算法两大类。其中,两阶段检测算法以 R-CNN^[3]、Fast R-CNN^[4]、Faster R-CNN^[5] 等为典型代表。这类算法首先通过区域生成网络筛选出可能包含目标的候选区域,再对候选区域内的目标进行分类识别,同步完成区域类别判定与边界框回归优化。Weerakkody 等^[6]以 Faster R-CNN 为基础,采用 ResNet-50 作为主干网络,通过数据采集、标注和增强提升模型鲁棒性,实现缺陷可视化与检测结果的实时展示,为工业质检提供了实用工具,但该方法存在模型结构冗余、推理速度慢以及硬件部署门槛高等问题。而单阶段检测算法则以 YOLO(you only look once)系列^[7-10]、SSD^[11] 等为代表,这

类算法在检测过程中无需预先生成候选框,而是直接对图像进行密集预测以完成目标检测任务,模型结构更加简单,计算速度更快,所以成为 PCB 缺陷检测的主流算法。苏佳等^[12]基于 YOLOv7 算法,针对下采样环节易丢失细粒度缺陷特征的痛点引入 SPD-Conv 模块完成结构优化,同时借助 BiFPN 融合网络提升多尺度特征交互效果,使得平均精度均值和召回率较原算法显著提升,但模型计算量大,实时检测性稍有不足。胡兰兰等^[13]基于 YOLOv5s 提出多尺度加权通道融合网络,扩增小目标数据,缩减模型体积,设计混合空间金字塔卷积扩大深层特征图感受野,增强语义信息提取能力,但增加了网络计算复杂度,精度和检测速度无法兼顾。王彩霞等^[14]在 YOLOv8 网络中引入小目标检测头,以此增强模型小目标特征的提取能力,并通过并行补丁感知注意模块(parallelized patch-aware, PA)捕获不同尺度的特征,加强模型局部和全局信息提取及融合能力,但模型计算量增加相对较多。Chen 等^[15]提出了一种基于多尺度表征学习的实时检测模型 YOLO-MS,通过 MS-Block 和 HKS 协议,能够增强实时物体探测器的多尺度特征,显著提升模型的检测速度和准确率,但计算成本略微增加。

针对以上研究存在的问题,本文以 YOLOv12n 为基底模型,提出一种轻量化 PCB 缺陷检测算法。首先,通过引入令牌混合器采用深度可分离卷积的 ConvFormer 重构 C3K2 模块,提高模型对微小特征的感知能力;其次,设计一种新的特征融合增强网络(feature fusion enhancement network, FFEN),在跨尺度特征传递中保证目标信息的完整,从而强化模型对目标的关注能力,提高检测精度;再次,提出特征聚焦扩散模块(feature-focused fusion, FFF),打破传统特征融合中高低层信息割裂的问题,实现多尺度上下文信息的充分融合,增强模型对复杂特征提取能力;最后,针对 PCB 缺陷检测中的小目标漏检问题,引入任务动态对齐检测头(task-aligned dynamic detection head, TADDH),促进定位和分类两个检测头之间的信息交互,从而提升对 PCB 缺陷检测的准确率。

1 改进 YOLOv12 算法检测原理

YOLOv12^[16] 是于 2025 年提出的以注意力机制为核

心的高效实时目标检测模型。该模型的主干网络采用残差高效层聚合网络架构,通过对输入图像的五阶段特征提取生成 S_0 、 S_1 、 S_2 、 S_3 、 S_4 5 层特征,这些特征图的空间分辨率逐级递减而通道数递增,为后续特征融合层提供多粒度视觉表征,以支持复杂场景下的高效目标检测任务。动态多尺度特征融合金字塔由区域注意力模块(area attention, A^2)负责对主干网络输出的中高层特征 $S_2 \sim S_4$ 进行尺度内优化,将特征图划分为 K 个区域(默认 $K=4$),通过区域级自注意力在降低计算量的同时增强局部语义关联,残差高效层聚合网络(residual efficient layer aggregation network, R-ELAN)采用单路径瓶颈结构替代传统拆分操作,重构特征聚合路径整合多尺度信息。模型通过动态锚框生成机制根据特征图统计特性自适应调整先验框尺寸,并采用双路径监督策略提

升回归精度。

尽管 YOLOv12 算法在实时目标检测任务中表现优异,目前仍存在以下问题影响检测效果:1)网络结构中采用的大网格设计与深层次预测机制,对小目标的检测能力弱;2)全局感受野受限。模型主干网络以标准卷积层为核心进行特征提取,该方式仅能捕捉局部区域的图像信息,难以获取大范围的全局上下文信息,对复杂背景下的缺陷特征辨识度不足;3)复杂特征捕捉能力有限。YOLOv12n 作为轻量化模型,参数量与网络深度均受到约束,在处理 PCB 缺陷这类背景复杂、特征差异小的图像时,难以充分提取丰富的细节特征与语义信息,进而限制了模型的特征表达能力。为解决上述问题,本文提出了一种基于改进 YOLOv12n 的轻量化 PCB 缺陷检测算法,该模型的网络结构如图 1 所示。




图 1 改进 YOLOv12n 模型整体结构

Fig. 1 Improved overall structure diagram of YOLOv12n model

1.1 C3K2-CF 模块

原模型中 C3K2 模块所采用的 Bottleneck 结构的特征交互能力受其纯卷积操作难以建模长距离依赖,在 PCB 缺陷密集小目标检测场景下易出现微小特征丢失与目标混淆的问题,而且感受野固定且缺乏自适应聚焦机制,对尺度微小、分布密集的检测对象鲁棒性不足,同时标准卷积参数量相对较大,不利于模型在轻量化场景下部署。为针对性解决上述问题,提高模型对微小特征的感知能力,减少参数量,引入了一种令牌混合器采用深度可分离卷积的 ConvFormer 模块重构 C3K2 模块,ConvFormer Block 模块结构如图 2 所示。

ConvFormer 作为 MetaFormer^[17] 体系中纯卷积范式

的实例化模型,其核心创新在于完全摒弃计算昂贵的注意力机制,仅依靠卷积操作即可实现全局特征交互,在保持 CNN 结构简洁性与推理高效性的同时,弥补了传统卷积长依赖建模能力弱的缺陷。其中作为核心算子的 SConv (Separable convolution) 由逐深度卷积 (depthwise convolution, DWConv) 和逐点卷积 (pointwise convolution, PWConv) 两部分组成,如图 3 所示。

对于普通卷积来说,当输入特征图的尺寸为 $H \times W \times C$ (其中 H 为高度、 W 为宽度、 C 为通道数),卷积步长设置为 1,若要输出尺寸为 $H \times W \times N$ (N 为输出通道数)的特征图,需要 N 个尺寸为 $K \times K \times C$ 的卷积核完成运算。标准卷积的参数量与计算量可分别表示为:




图 2 ConvFormer 结构

Fig. 2 ConvFormer structure




图 3 SConv 结构

Fig. 3 SConv structure

$$Parmconv = N \times K^2 \times C \quad (1)$$

$$Calconv = N \times K^2 \times W \times H \times C \quad (2)$$

与标准卷积相比, SConv 先通过 DWConv 对输入特征图的每个通道单独进行空间特征提取, 再通过 PWConv 对所有通道的特征进行通道维度的融合与变换, 同时完成输出通道数的调整。在 DWConv 中, 输入特征图的每个通道仅对应 1 个尺寸为 $K \times K$ 的二维卷积核, 即当输入特征图尺寸为 $H \times W \times C$ 时, 仅需 C 个 $K \times K$ 的卷积核即可完成空间特征提取; 在 PWConv 中, 通过 N 个尺寸为 $1 \times 1 \times C$ 的卷积核完成通道维度的运算, 实现输出通道数的调整。因此, SConv 的参数量与计算量可表示为:

$$Parmdsc = K^2 \times C + C \times N \quad (3)$$

$$Calcdsc = K^2 \times W \times H \times C + W \times H \times C \times N \quad (4)$$

进一步推导可知, SConv 与标准卷积的参数量、计算量上的比例关系如式(5)所示。

$$\frac{Parmdsc}{Parmconv} = \frac{Calcdsc}{Calconv} = \frac{1}{N} + \frac{1}{K^2} \quad (5)$$

在实际应用中, 通道数 N 通常大于卷积核尺寸 K , 因此采用 SConv 替换标准卷积, 可大幅降低网络的参数量与计算量, 同时减少冗余卷积操作对 PCB 小目标缺陷弱特征的干扰, 在实现模型轻量化的同时, 保障小目标特征的完整传递。

1.2 特征融合增强网络 FFEN

目标检测颈部网络的核心任务, 是平衡“浅层高分辨率特征(适合小目标)”与“深层低分辨率特征(适合大目标)”的融合。特征图作为目标检测中的核心信息载体, 其尺度特性(分辨率与语义信息)随网络深度呈现显著差异, 如图 4 所示。小目标检测依赖浅层高分辨率特征保留完整的目标空间位置与边缘细节, 但颈部在将深层语义特征上采样至浅层时, 因上采样算法的局限性会导致细节信息的丢失, 高低层特征间存在语义鸿沟与尺度错位, 导致小目标因语义信息不足、细节特征弱化而出现漏检与定位偏差。


(a) 浅层特征图
(a) Shallow feature maps(b) 深层特征图
(b) Deep feature maps

图 4 特征图可视化

Fig. 4 Visualization of feature maps

为解决传统颈部网络跨尺度特征传递不完整、高低层特征融合不充分、小目标细节易丢失的问题, 本文面向 PCB 微小缺陷检测场景, 提出特征融合增强网络 FFEN, 其结构如图 5 所示。

FFEN 网络通过接收来自主干网络输出的 3 组不同尺度的输入特征实现对目标信息的增强。通过尺度归一化与逐通道卷积完成特征分辨率与维度的对齐, 消除跨尺度融合的错位干扰; 随后将对齐后的多尺度特征进行拼接, 充分保留各层特征的独有信息; 在此基础上, 采用多尺度深度可分离卷积构建多感受野特征提取分支, 自适应捕捉不同尺度目标的特征响应; 最后引入残差连接通路, 强化梯度反向传播效率, 抑制特征在多层传递过程中的衰减与丢失, 保证小目标弱特征的完整保留。

此外, FFEN 网络中包含的 FFF 模块能够有效促进高层次语义信息与低层次细节信息的互补融合, 高层次




图5 颈部结构改进

Fig. 5 Improvement of neck structure




图6 FFF 模块

Fig. 6 FFF module

语义信息可提供目标的全局上下文,低层次细节信息能补充目标的局部特征,二者结合显著提升了模型对 PCB 缺陷的检测能力。

1.3 特征聚焦融合模块 FFF

传统的 FPN 算法^[18]在特征融合过程中,主要通过上采样、下采样与横向连接实现多层次特征的聚合,但其融合机制存在对高层语义特征过度依赖、低层细节特征利用不足的缺陷。尽管高层特征蕴含丰富的语义信息(如目标类别与整体轮廓),但经过多次下采样后分辨率急剧降低,难以保留微小目标的精细位置细节,而浅层高分辨率特征所携带的细节线索在融合过程中被不断稀释,无法得到有效传递与利用。

针对上述问题,在面向 PCB 微小缺陷目标检测场景时,传统 FPN 会直接导致两个问题:1) PCB 的表面特征(如边缘、纹理)被严重弱化,细节利用率低;2)模型对小目标的空间位置感知能力不足,易出现漏检现象。为此,本文提出特征聚焦融合模块 FFF,其目的是打破高层语义信息与低层细节信息的割裂状态,通过分层差异化处理与多感受野协同增强实现二者的深度互补,结构如图6所示。

FFF 模块首先接收来自 P3、P4、P5 特征层的输入($x_1 \in R^{B \times C_1 \times H \times W}$, $x_2 \in R^{B \times C_2 \times H/2 \times W/2}$, $x_3 \in R^{B \times C_3 \times H/4 \times W/4}$),并根据各层特征属性进行差异化处理,最大程度保留各层独有信息:P3 层特征先经过 Adown 模块进行降采样,在统一尺度的同时,通过专用特征提取策略保留小目标与 PCB 缺陷的边缘、纹理等关键细节,避免低层位置信息丢失;P4 层特征直接通过卷积层提取中等尺度目标的语义特征,强化对中等大小目标的类别与轮廓信息表达;P5 层低分辨率特征,先通过上采样恢复其空间分辨率,再经

卷积层强化高层语义与上下文信息,弥补其高层特征的细节缺失。

将经过预处理后的 3 层尺度特征进行融合,形成包含多层次信息的聚合特征 x_{cat} :

$$x_{cat} = \text{torch.cat}(x_1', x_2', x_3') \in R^{B \times 3Ch \times H/2 \times W/2} \quad (6)$$

其中, x_{cat} 的通道数为 $hdc \times 3$,空间尺寸与 x_2 一致。随后,对 x_{cat} 进行多卷积核特征提取,通过 DWConv 与恒等映射 (Identity) 机制进行精细化增强,1x1 卷积专注于捕获局部细腻特征,通过通道维度的精细化调整,强化对小目标局部细节(如微小缺陷的边缘纹理)的感知能力,而 7x7 卷积侧重提取大范围上下文信息,通过扩大感受野捕捉目标与周围环境的关联特征,增强模型对场景全局的理解,两种卷积操作与恒等映射的结合,实现了局部细节与全局上下文的双重增强,避免单一尺度特征的信息局限。最后融合后的特征经上述卷积处理后,得到多感受野融合特征 f_{dw} :

$$f_{dw} = x_{cat} + \sum_{k \in \text{kernel_sizes}} dw_convk(x_{cat}) \quad (7)$$

其中, dw_convk 表示卷积核尺寸为 K 的深度卷积层,通过加和、点卷积 (Pwconv) 等操作得到最终输出特征 Y ,如式(8)所示。

$$Y = x_{cat} + Pwconv(f_{dw}) \in R^{B \times 3Ch \times H/2 \times W/2} \quad (8)$$

FFF 模块使低层次细节信息、中层次语义特征与高层次上下文信息在不同尺度的检测任务间实现有机扩散与传递,打破了传统特征融合中高低层信息割裂的、对小目标不友好的问题。经 FFF 模块处理的特征同时具备丰富的位置细节与语义属性,显著提升了模型对微小缺陷

的感知与定位能力。

1.4 任务对齐动态检测头 TADDH

原模型中的检测头采用分类与回归双分支独立结构,虽可实现任务解耦优化,但在面向 PCB 微小缺陷检测场景时存在两点缺陷:分类分支与定位分支的预测结

果在空间位置上存在错位偏差,易导致小目标锚框匹配错误;双分支完全独立运算,分支间缺乏特征交互与任务协同,易出现分类与定位结果不一致的问题。为解决上述问题,本文设计任务对齐动态检测头 TADDH,结构如图 7 所示。




图 7 TADDH 模块结构

Fig. 7 TADDH module structure

TADDH 在借鉴 Feng 等^[19]提出的 TOOD (task-aligned one-stage detection) 思想基础上,通过全新的头部结构与任务对齐学习方法,实现分类与定位任务的精准协同,其核心设计包括共享卷积与轻量化设计和任务交互特征学习。首先,采用共享卷积层替代传统双分支独立卷积,在保证特征表达能力的前提下,减少冗余参数与计算开销,使其更适配资源受限的工业检测场景。同时,针对 PCB 缺陷尺度分布不均、不同检测头对应目标尺度差异的问题,引入 Scale 层对多尺度特征进行动态缩放,确保不同大小缺陷的特征表达适配其检测需求。在此基础上,通过特征提取器构建任务交互特征学习机制,并引入可变形卷积(DCNv2)通过多层偏移学习实现灵活的空间采样,通过调制机制动态调整采样点位置与特征权重,增强模型对微小缺陷的定位适应性,实现分类与定位任务的特征共享与深度交互。

在定位优化方面,传统检测头仅通过常规卷积直接回归边界框,对小目标空间细节感知不足。TADDH 通过任务分解模块(Task decomposition),从交互特征中分离出更利于边界框回归的关键空间特征,并利用空间卷积生成偏移量和掩码,再通过动态可变形卷积相关模块根据预测偏移量和掩码实现回归特征的空间对齐,使分类与定位任务能够相互感知、协同优化,从源头缓解预测错位问题。

考虑到单一分支设计可能因两个任务的目标差异(分类侧重语义特征,定位侧重空间特征)引入特征冲突(如不同层次、感受野的特征需求矛盾)。为此,本文

在任务对齐学习模块(task alignment learning)中引入层注意力机制,在特征层级维度动态计算任务专属特征,实现任务分解。其计算过程如下。

对于分类和定位任务其 task-specific 特征:

$$X_k^{task} = \sum_{k=1}^N w_k \cdot X_{inter}^k, \forall k \in \{1, 2, \dots, N\} \quad (9)$$

式中: N 为跨层交互特征的层数; X_{inter}^k 表示第 k 层的跨层交互特征; w_k 是任务中的第 k 层注意力权重; w 是基于跨层交互特征的全局信息学习得到,能够捕获层间交互关系,其计算公式为:

$$w = \sigma(fc2(\sigma_1(fc1(x_{inter})))) \quad (10)$$

式中: $fc1$ 为第 1 全连接层,用于特征降维; σ_1 为中间激活函数,引入非线性变换; $fc2$ 为第 2 全连接层,将降维后的特征映射至 N 维,输出与层数匹配的权重向量; σ 为 sigmoid 激活函数,将权重约束在 $[0, 1]$ 。

该动态层级加权机制可根据任务特征自适应分配特征权重,使分类分支更聚焦高层语义信息,提升缺陷类别判别能力;定位分支更侧重低层空间细节,提升微小缺陷的定位精度,有效缓解单分支结构下的任务特征冲突,有效降低 PCB 缺陷小目标的误检与漏检率,提升检测性能。

2 实验与分析

2.1 实验数据集

本文首个实验数据集采用北京大学智能机器人实验

室公开发布的 PCB 缺陷数据集 (PKU-Market-PCB)^[20], 该数据集共包含 693 张原始 PCB 图像, 涵盖电子制造生产中常见的 6 类 PCB 缺陷, 分别为缺孔、开路、短路、鼠咬、余铜及毛刺, 各类别缺陷的可视化示例如图 8 所示。




图 8 PCB 表面缺陷示例

Fig. 8 Examples of PCB surface defects

为避免模型训练过程中因数据量不足导致过拟合, 通过数据增强将原始数据集扩展至 10 668 张图片, 各类别缺陷数量如表 1 所示, 并且缺陷在图片中的分布位置也较为均匀 (如图 9 所示, 颜色越深表示该区域的缺陷分布数量越多)。这种均匀的分布特性有助于提升模型对不同位置缺陷的识别适应性, 从而提高模型的泛化能力。本文将预处理后的数据集按照 8 : 1 : 1 的比例随机划分为训练集、验证集、测试集。

表 1 PCB 数据集缺陷数量

Table 1 Number of PCB defect datasets

缺陷类型	原始图片数量	原始缺陷数量	增强缺陷数量
Mouse bite	115	492	3 684
Missing hole	115	497	3 612
Open circuit	116	482	3 548
Short	116	491	3 508
Spur	115	488	3 636
Spurious copper	116	503	3 676




图 9 缺陷位置分布

Fig. 9 Defect location distribution

2.2 实验环境与参数配置

实验在 Windows 11 系统下开展, 用 Python3. 11. 4 搭配 Pytorch2. 0. 0 搭建深度学习模型。训练时采用 NVIDIA GeForce RTX 3060 GPU 作为硬件平台, 并通过 CUDA11. 8 进行加速, 统一采用 640×640 的输入尺寸。具体参数设置如表 2 所示。

表 2 实验参数

Table 2 Experimental parameter table

名称	参数
学习率	0. 01
动量	0. 937
权重衰减	0. 000 5
批次大小	16
迭代次数	200
优化器	SGD

为保证消融实验结果的准确性与可比性, 消融实验中所有实验组均采用上述完全一致的超参数配置, 并且均未使用预训练权重, 以排除参数差异对实验结果的干扰, 而在不同算法的对比实验中, 各对比算法均采用其原生适配的超参数设置, 确保各算法在最适配自身网络结构的条件下完成性能测试, 确保各模型能在最适配自身结构的条件下进行性能比拼, 从而使对比结果更具客观性与参考价值。

2.3 评估指标

实验中用准确率 (precision, P)、召回率 (recall, R) 和平均精度均值 (mean average precision, mAP) 来衡量模型的检测效果。其中, mAP@ 0. 5 指的是当所有类别的交并比 (IoU) 阈值设为 0. 5 时的平均检测精度; mAP@ 0. 5 : 0. 95 则是在 IoU 阈值从 0. 5 到 0. 95、以 5 为步长的多个阈值下, 所有类别平均检测精度的综合结果。具体计算公式如式 (11) ~ (14) 所示。

$$P = \frac{TP}{TP + FP}$$
 (11)

$$R = \frac{TP}{TP + FN}$$
 (12)

$$AP = \int_0^1 P(r) dr$$
 (13)

$$mAP = \frac{1}{K} \sum_{j=1}^K AP_j$$
 (14)

式中: n 代表数据集中类别的总数; TP (true positive) 表示模型把实际为正样本的对象正确识别为正样本的数量; FP (false positive) 表示模型误将实际为负样本的对象识别成正样本的数量; FN (false negative) 表示模型误把实际为正样本的对象判定为负样本的数量。此外, 引入参数量 (Params) 和计算量 (GFLOPs) 来评价模型复杂度, 指标数值越大代表模型复杂程度越高。

为量化评估模型的实时检测能力,采用每秒可处理的图像帧数(frames per second, FPS)作为模型实时性能的评价指标,FPS 的计算公式如式(15)所示。

$$FPS = \frac{framNum}{elapsedTime} \tag{15}$$

式中:framNum 表示固定时间内模型处理的图像数量;elapsedTime 表示模型处理单张图像所采用的时间。

2.4 消融实验

为直观体现改进方法相较于原始模型的性能优势,在原始模型中逐步添加不同的改进点,并在数据增强后的 PKU-Market-PCB 数据集上开展消融实验,实验结果如表 3 所示。

表 3 消融实验结果

Table 3 The results of the ablation test

模型	组 1	组 2	组 3	组 4	组 5	组 6
原始模型	√	√	√	√	√	√
C3K2-CF		√				√
FFEN			√		√	√
FFF			√		√	√
TADDH				√	√	√
P/%	97.6	97.8	98.1	97.5	97.6	97.8
R/%	97.2	98.5	97.9	97.5	98.4	98.3
mAP@0.5/%	98.3	99.0	98.4	98.5	98.7	98.6
mAP@0.5:0.95/%	57.5	62.3	61.3	57.8	61.4	64.7
Params/(×10 ⁶)	2.52	2.01	2.21	1.99	1.94	1.33
GFLOPs	5.9	5.6	5.8	5.3	5.1	4.9

表 4 不同缺陷类型提升结果

Table 4 Improvement results for different defect types (%)

模型	mAP@0.5:0.95	mAP@0.5:0.95					
		鼠咬	毛刺	缺孔	短路	开路	余铜
YOLOv12n	57.5	59.5	55.7	63.5	56.5	53.6	56.2
YOLOv12n+C3k2-CF	62.3	64.1	60.1	66.8	62.2	59.1	61.5
YOLOv12n+FFEN+FFF	61.3	62.9	59.3	65.7	60.4	58.8	60.3
YOLOv12n+TADDH	57.8	59.3	54.8	63.4	57.4	55.3	56.3
YOLOv12n+FFEN+FFF+TADDH	61.4	61.4	59.8	65.8	61.9	58.7	59.8
YOLOv12n+C3k2-CF +FFEN+FFF+TADDH	64.7	67.3	61.9	67.4	66.2	63.8	61.6

由表 4 可知,对比原模型,改进模型中各类 PCB 缺陷类别的平均检测精度均有较大提升,6 种缺陷类别分别提升:鼠咬(7.8%)、毛刺(6.2%)、缺孔(3.9%)、短路(9.7%)、开路(10.2%)、余铜(5.4%),显著减少了误检和漏检率。为更直观清晰地呈现本文改进模型对不同类型 PCB 缺陷的检测效果,如图 10 所示,本文选取 6 类典型缺陷的 PCB 图像作为测试输入,开展对比检测实验,以充分验证改进模型对缺陷特征提取的有效性。通过对比原模型与改进模型的热力图可知,原模型对缺陷目标的聚焦能力不足,无法充分提取缺陷的有效特征信息,对毛刺类缺陷存在明显漏检现象,整体缺陷识别精度

对比实验组 1 和 2 可知,在引入 C2K2-CF 模块后,模型参数量下降 20.2%,同时 mAP@0.5 与 mAP@0.5:0.95 分别提升 0.7%和 4.8%,实现了参数量和特征提取能力的双向优化;对比实验组 1 与 3 可知,FFEN 特征融合增强网络可有效保障跨尺度特征传递与融合过程中目标有效信息的完整性,同时 FFF 特征聚焦融合模块通过深度融合不同层次的尺度信息,实现了局部特征与全局上下文语义信息的双重增强,显著提升了模型对小目标缺陷的上下文信息表达能力,在二者协同作用下,模型参数量减少 12.3%,mAP@0.5:0.95 提升 3.8%;对比实验组 1 和 4 可以发现,TADDH 任务动态对齐检测头通过优化检测头结构与分类-定位任务协同机制,有效促进了定位与分类两个检测分支之间的信息交互。该模块使模型参数量与计算量分别减少 21%、10%,同时 mAP@0.5:0.95 提升至 57.8%,进一步提高了检测精度;对比实验组 1 与 6 可知,相较于原始基线模型,改进模型的参数量和计算量分别减少 47.2%和 16.9%,同时 mAP@0.5 达到 98.6%,mAP@0.5:0.95 大幅提升 7.2%。这一结果充分表明,改进模型在实现轻量化的同时实现了高精度检测。

此外,为进一步分析改进模块对不同缺陷类别检测能力的提升,本文对比了不同改进模块各类缺陷的 mAP@0.5:0.95,结果如表 4 所示。

不足。而改进模型对 PCB 缺陷的特征提取能力明显增强,能够捕捉缺陷集中区域,更直观展示了关键缺陷点,便于快速识别和定位缺陷。

2.5 对比实验

为全面评估本文算法相较于其他算法的优势,将所提出的改进模型与 PCES-YOLO^[21]、YOLO-FGD^[22]、YOLO-MS^[23]、RT-DETR^[24]、YOLOv5n^[25]、YOLOv8n、YOLOv10n、YOLOv11n、YOLOv12n 等算法在数据增强后的 PKU-Market-PCB 数据集上开展对比实验,实验结果如表 5 所示。

由表 5 可知,YOLO-FGD、YOLOv5n、YOLOv8n、




图 10 特征提取效果对比

Fig. 10 Comparison of feature extraction effects

表 5 对比实验结果

Table 5 Comparison experimental results					
模型	mAP@ 0. 5/%	mAP@ 0. 5; Params/		GFLOPs	帧率/ FPS
		0. 95/%	($\times 10^6$)		
YOLOv5n	98. 7	57. 4	1. 77	4. 2	154. 2
YOLOv8n	98. 0	57. 2	3. 01	8. 1	148. 9
YOLOv10n	97. 7	56. 4	2. 70	8. 2	130. 4
YOLOv11n	98. 4	57. 9	2. 58	6. 3	121. 2
YOLOv12n	98. 3	57. 5	2. 51	5. 9	95. 3
YOLO-MS	98. 5	62. 7	15. 30	36. 9	87. 4
PCES-YOLO	97. 3	61. 2	2. 60	8. 5	133. 0
YOLO-FGD	98. 8	57. 2	6. 08	11. 5	104. 8
RT-DETR	98. 8	64. 8	19. 88	57. 0	88. 6
本文方法	98. 6	64. 7	1. 33	4. 9	78. 4

YOLOv10n、YOLOv11n 由于主干网络层数较深,获取的深层语义信息较多,对目标位置细节的浅层特征关注度不足,特征提取存在结构性偏差,导致在检测时效果欠佳;而 YOLO-MS、PCES-YOLO、RT-DETR 等检测模型,虽检测精度与本文改进模型较为接近,但综合性能对比来看,改进模型在轻量化的同时 mAP@ 0. 5 增至 98. 6%,其中更严格的指标 mAP@ 0. 5:0. 95 达到 64. 7%,较基线模型提升 7. 2%,推理帧率可达 78. 4 FPS,整体综合性能更优。综上所述,本文提出的改进模型在轻量化的同时检测精度显著提升,适用于实时性与高精度并重的工业检测场景。

2.6 泛化实验

为进一步验证本文改进模型的跨数据集泛化性能,选取公开的 Deep PCB^[26]数据集开展泛化性验证实验,该数据集共包含 1 500 张由线阵 CCD 扫描采集的 PCB 图像,覆盖开路、短路、鼠咬、毛刺、余铜和针孔 6 种常见 PCB 缺陷。由于数据集未严格标注某类缺陷的对应样本

个数,只有缺陷总数,因此本文将数据集按照 8 : 1 : 1 的比例随机划分为训练集、验证集和测试集。将改进模型与 RT-DETR、YOLOv5n、YOLOv8n、YOLOv10n、YOLOv11n、YOLOv12n 等主流算法进行对比实验,实验结果如表 6 所示。

表 6 Deep PCB 对比实验结果

Table 6 Comparison experimental results of the Deep PCB					
模型	P/%	R/%	mAP@ 0. 5/%	Params/	
				($\times 10^6$)	GFLOPs
RT-DETR	98. 1	97. 1	98. 7	19. 88	57. 0
YOLOv5n	91. 9	90. 1	95. 3	1. 77	4. 2
YOLOv8n	91. 6	81. 4	92. 6	3. 01	8. 1
YOLOv10n	92. 7	85. 4	94. 6	2. 70	8. 2
YOLOv11n	96. 1	94. 9	98. 1	2. 58	6. 3
YOLOv12n	95. 6	92. 0	97. 4	2. 51	5. 9
本文方法	97. 2	93. 1	97. 5	1. 33	4. 9

实验结果表明,改进模型的精确率达到 97. 2%,检测精度 mAP @ 0. 5 达到 97. 5%,同时模型计算量仅为 4. 9 GFLOPs,参数量低至 $1. 33 \times 10^6$ 。与其他主流目标检测算法相比,本文改进模型在轻量化与检测精度上实现了更好的平衡,综合性能更优。相较于原始 YOLOv12n 基线模型,改进模型的精确率与召回率分别提升了 1. 6% 和 1. 1%,充分验证了其在 PCB 缺陷检测任务中的显著优越性。

此外,为进一步量化分析改进模型对不同缺陷类别检测能力的提升效果,本文对比了改进模型与各主流目标检测算法在各类 PCB 缺陷上的 mAP@ 0. 5:0. 95,对比结果如表 7 所示。

由表 7 可知,YOLOv12n 在短路缺陷类别的检测精

度相对较低,其 $mAP@0.5:0.95$ 仅为 60.4%,全类别缺陷的 $mAP@0.5:0.95$ 为 72.4%。相较于原模型,改进模型中短路缺陷类别的 $mAP@0.5:0.95$ 提升最为明显,增加了 4.3%,全类别缺陷检测精度 $mAP@0.5:0.95$ 达到了 74.9%,提高了 2.5%。实验结果充分验证了改进模型在 PCB 缺陷检测方面的优越性。

表 7 不同缺陷类型提升结果

Table 7 Improvement results for different defect types

(%)

模型	$mAP@0.5:0.95$	$mAP@0.5:0.95$					
		余铜	鼠咬	开路	针孔	短路	毛刺
RT-DETR	76.7	84.5	75.5	73.3	84.7	69.0	72.9
YOLOv5n	66.7	80.0	67.4	60.8	75.6	53.3	63.7
YOLOv8n	61.1	72.3	60.7	56.8	69.3	49.5	57.9
YOLOv10n	69.7	88.2	69.0	64.6	79.8	56.5	65.7
YOLOv11n	73.9	85.7	73.9	66.6	82.6	62.9	71.8
YOLOv12n	72.4	85.2	72.9	63.9	82.8	60.4	69.5
本文方法	74.9	89.2	71.3	66.5	86.3	64.7	71.4




图 11 Deep PCB 检测效果对比

Fig. 11 Comparison of deep PCB detection effects

本文选取 4 张不同的 PCB 缺陷图像,将原始模型与改进模型的检测结果进行可视化对比,结果如图 11 所示。从缺陷检测结果图可以清晰看出,原始 YOLOv12n 模型存在少量漏检与误检现象,而本文改进模型在 PCB 缺陷检测中展现出显著优势,改进模型不仅能够有效识别并精准定位那些视觉上难以分辨的细微缺陷,还有效减少了误检与漏检的情况,充分验证了改进模型在 PCB 缺陷检测方面的有效性与优越性。

3 结 论

为解决实际工业场景中 PCB 缺陷检测模型轻量化与检测精度难以兼顾的问题,本文提出一种基于 YOLOv12n 的轻量化 PCB 缺陷检测算法。首先,通过在 C3K2 中引入带有 SConv 的 ConvFormer 模块,在具有更少

参数量的同时提高目标的检测精度。其次,设计一种新的特征融合增强网络 FFEN,在跨尺度特征传递中保证目标信息的完整,从而强化模型对目标的关注能力。再次,提出特征聚焦融合模块 FFF 融合不同层次的尺度信息,实现了局部细节与全局上下文的双重增强,避免单一尺度特征的信息局限,有效增强了模型对小目标的上下文表达能力与检测鲁棒性。最后,通过 TADDH 检测头优化检测头结构与任务协同机制,打通分类与定位双检测头的信息交互通道,实现两个任务的协同优化,进一步提升模型对 PCB 小尺寸缺陷的检测精度。实验结果表明,改进算法在轻量化的同时实现了高精度检测,适用于实时性与高精度并重的工业检测场景,更满足实际工业的需求。未来将深度研究更为复杂的缺陷类型、小样本学习问题,提升模型在复杂环境中检测 PCB 表面缺陷的性能,使其能更妥善地应对实际场景中的各类干扰。

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] 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 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.
- [3] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2014: 580-587.
- [4] GIRSHICK R. Fast R-CNN [C]. Proceedings of the IEEE International Conference on Computer Vision, 2015: 1440-1448.
- [5] 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 & Machine Intelligence, 2017, 39(6): 1137-1149.
- [6] WEERAKKODY K D, BALASUNDARAM R, OSAGIE E, et al. Automated defect identification system in printed circuit boards using region-based convolutional neural networks [J]. Electronics, 2025, 14(8): 1542-1566.
- [7] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 779-788.
- [8] YASEEN M. What is YOLOv8: An in-depth exploration of the internal features of the next-generation object detector [J]. ArXiv preprint arXiv:2408.15857, 2024.
- [9] WANG A, CHEN H, LIU L, et al. YOLOv10: Real-time end-to-end object detection [J]. Advances in Neural Information Processing Systems, 2024, 37: 107984-108011.
- [10] LEI M, LI S, WU Y, et al. YOLOv13: Real-time object detection with hypergraph-enhanced adaptive visual perception [J]. ArXiv preprint arXiv: 2506.17733, 2025.
- [11] WEI L, DRAGOMIR A, DUMITRU E, et al. SSD: Single shot multibox detector [C]. Proceedings of the European Conference on Computer Vision. 2016: 21-37.
- [12] 苏佳, 罗都, 贾欣雨, 等. 基于 YOLO-G 的 PCB 缺陷检测算法 [J]. 微电子学与计算机, 2024, 41(10): 35-44.
- SU J, LUO D, JIA X Y, et al. PCB defect detection algorithm based on OLOO-G [J]. Microelectronics and Computer, 24, 41(10): 35-44.
- [13] 胡兰兰, 邓超. 基于 YOLO-MCG 的 PCB 缺陷检测算法 [J]. 仪表技术与传感器, 2024(4): 100-106.
- HU L L, DENG CH. PCB defect detection algorithm based on OLOO-MCG [J]. Instrument Technology and Sensors, 2024(4): 100-106.
- [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 C X, GUO X P, LIU P. Improve the circuit board defect detection algorithm of YOLOv8n [J]. Journal of Electronic Measurement and Instrumentation, 2023, 39(8): 65-78.
- [15] CHEN Y, YUAN X, WANG J, et al. YOLO-MS: Rethinking multi-scale representation learning for real-time object detection [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2025, 47(6): 4240-4252.
- [16] TIAN Y, YE Q, DOERMANN D. YOLOv12: Attention-centric real-time object detectors [J]. ArXiv preprint arXiv:2502.12524, 2025.
- [17] YU W, SI C, ZHOU P, et al. Metaformer baselines for vision [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2023, 46(2): 896-912.
- [18] GHIASI G, LIN T Y, LE Q V. Nas-fpn: Learning scalable feature pyramid architecture for object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2019: 7036-7045.
- [19] FENG C, ZHONG Y, GAO Y, et al. TOOD: Task-aligned one-stage detection [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE Press, 2021: 3490-3499.
- [20] HUANG W, WEI P, ZHANG M, et al. HRIPCB: A challenging dataset for PCB defects detection and classification [J]. Journal of Engineering, 2020, 2020(13): 303-309.
- [21] YANG H, DONG J, WANG C, et al. PCES-YOLO: High-Precision PCB detection via pre-convolution receptive field enhancement and geometry-perception

- feature fusion[J]. Applied Sciences, 2025, 15(13): 7588-7588.
- [22] QIN C, ZHOU Z. YOLO-FGD: A fast lightweight PCB defect method based on FasterNet and the gather-and-distribute mechanism[J]. Journal of Real-Time Image Processing, 2024, 21(4): 122-134.
- [23] XIE Y, ZHANG L, YU X, et al. YOLO-MS: Multispectral object detection via feature interaction and self-attention guided fusion[J]. IEEE Transactions on Cognitive and Developmental Systems, 2023, 15(4): 2132-2143.
- [24] 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.
- [25] WANG X, ZHANG X, ZHOU N. Improved YOLOv5 with BiFPN on PCB defect detection[C]. 2021 2nd International Conference on Artificial Intelligence and Computer Engineering (ICAICE). IEEE, 2021: 196-199.
- [26] HE F, TANG S, MEHRKANOON S, et al. A real-time PCB defect detector based on supervised and semi-supervised learning[C]. ESANN, 2020: 527-532.

作者简介



王宇, 2024 年于大连民族大学获得学士学位, 现为安徽工程大学硕士研究生, 主要研究方向为深度学习、缺陷检测。

E-mail: 481728892@qq.com

Wang Yu received his B. Sc. degree from Dalian Minzu University in 2024. Now he is a M. Sc. candidate at Anhui Polytechnic University. His main research interests include deep learning and defect detection.



魏利胜(通信作者), 2001 年于安徽工程大学获得学士学位, 2004 年于中国航天科工集团 061 基地获得硕士学位, 2009 年于上海大学获得博士学位, 现为安徽工程大学教授, 硕士生导师, 主要研究方向为图像识别与应用、智能化网路控制系统与仿真。

E-mail: lshwei_11@163.com

Wei Lisheng (Corresponding author) received his B. Sc. degree from Anhui Polytechnic University in 2001, M. Sc. degree from China Aerospace Science and Industry Corporation 061 Base in 2004, and Ph. D. degree from Shanghai University in 2009. Now he is a professor and M. Sc. supervisor at Anhui Polytechnic University. His main research interests include image recognition and application, intelligent network control system and simulation.