

DOI: 10.20271/j.cnki.1673-9833.2026.1013

一种改进 YOLOv8n 的 PCB 板表面缺陷检测算法

朱泽宇¹, 肖满生¹, 徐 萌¹, 王瑶瑶¹, 颜 谨¹, 左国才²

(1. 湖南工业大学 计算机与人工智能学院, 湖南 株洲 412007;

2. 湖南软件职业技术大学 软件与信息工程学院, 湖南 湘潭 411100)

摘 要: 针对 PCB 板表面缺陷检测中存在的检测精度低和微小目标漏检率高的问题, 提出一种改进 YOLOv8n 的 PCB 板缺陷检测算法。首先对 C2f 模块进行了改进, 通过引入 ConvNeXt, 设计了新的 C2XT 模块, 以提高特征提取能力; 然后在主干网络中引入 GAM 注意力机制, 颈部网络采用 CARAFE 上采样技术, 以增强关键特征表达; 此外, 在头部检测模块中引入一个针对微小目标的检测头, 并融入能对特征进行自适应融合的 ASFF 模块, 提高模型对小目标的检测能力; 最后, 通过 DFL 和 μ -IoU 的组合优化损失函数中边界框回归的计算。实验结果表明, 改进的算法在各项指标上都有显著提升, 相比原始 YOLOv8n 算法提升了 3%, 精确度提升了 1.6%。

关键词: 缺陷检测; CARAFE; C2XT; 特征自适应融合; 目标检测

中图分类号: TP391

文献标志码: A

文章编号: 1673-9833(2026)01-0092-10

引文格式: 朱泽宇, 肖满生, 徐 萌, 等. 一种改进 YOLOv8n 的 PCB 板表面缺陷检测算法 [J]. 湖南工业大学学报, 2026, 40(1): 92-101.

An Improved Algorithm for YOLOv8n PCB Surface Defect Detection

ZHU Zeyu¹, XIAO Mansheng¹, XU MENG¹, WANG Yaoyao¹, YAN Jin¹, ZUO Guocai²

(1. School of Computer Science and Artificial Intelligence, Hunan University of Technology, Zhuzhou Hunan 412007, China;

2. School of Software and Information Engineering, Hunan Software Vocational and Technical University, Xiangtan Hunan 411100, China)

Abstract: In view of the flaws of low detection accuracy and high missed detection rate of small targets in PCB surface defect detection, an improved YOLOv8n PCB surface defect detection algorithm has thus been proposed. Firstly, an improvement has been made of C2f modules, followed by an introduction of ConvNeXt as well as a new design of C2XT modules so as to enhance its feature extraction capability. Next, GAM attention mechanism is introduced into the backbone network, with CARAFE upsampling technique adopted in the neck network for an enhancement of the expression of key features. In addition, a detection head for small targets is introduced into the head detection module, with an ASFF module enabling an adaptive feature fusion integrated to improve detection ability of the model for small targets. Finally, the calculation of bounding box regression in the loss function can be optimized by combining DFL with μ -IoU. Experimental results show that the improved algorithm is characterized with a significant improvement in various indicators, with a 3% improvement in efficiency and a 1.6% improvement in accuracy compared to the original YOLOv8n algorithm.

Keywords: defect detection; CARAFE; C2XT; adaptive feature fusion; object detection

收稿日期: 2024-12-12

基金项目: 湖南省自然科学基金资助项目 (2024JJ8055); 湖南省教育厅科研基金资助项目 (21A0607, 22C1027)

作者简介: 朱泽宇, 男, 湖南工业大学硕士生, 主要研究方向为机器视觉, E-mail: m22085400025@stu.hut.edu.cn

通信作者: 肖满生, 男, 湖南工业大学教授, 硕士生导师, 主要研究方向为智能计算和智能信息处理,

E-mail: xiaomansheng@hut.edu.cn

1 研究背景

随着电子工业的迅猛发展, 印刷电路板 (printed circuit board, PCB) 在现代电子设备中起着至关重要的作用。PCB 的生产质量直接影响电子设备的性能和寿命, 因此, 确保 PCB 的高质量制造至关重要。PCB 制造过程中容易出现多种缺陷, 如短路、断路、焊点不良、元件错位等, 这些缺陷在生产早期阶段如果未能被及时检测出并修复, 可能会导致产品返工甚至报废。因此, 探讨高效、准确的 PCB 缺陷检测方法对于提高生产效率和降低成本具有重要意义^[1]。

在机器视觉应用于工业质量检测之前, PCB 表面缺陷检测主要是通过人工检测完成的, 这种检测效率低、漏检率高, 已经不能满足现代大规模工业生产的需求^[2]。随着深度学习的兴起, 卷积神经网络 (CNNs) 凭借其强大的特征提取能力被广泛应用于图像分类、目标检测等任务中^[3]。目前, 基于深度学习的 PCB 板缺陷检测算法可以分为两类^[4], 即两阶段检测 (two-stage) 和单阶段检测 (one-stage)。两阶段检测是以 R-CNN、Fast R-CNN 和 Faster R-CNN 为代表的目标检测算法, 是基于深度学习的检测算法的先驱者。如 Fan F. L. 等^[5]提出了一种改进的 Faster R-CNN, 通过引入 EfficientNet-B7 减少计算资源的消耗, 同时提升算法的检测精度, 然而模型的推理时间仍然较长, 难以满足工业场景中的实时检测要求; 朱红艳等^[6]针对 PCB 缺陷较小不易识别且形状多样化不易识别等问题, 在 Faster R-CNN 中引入多尺度特征融合和可变形卷积, 使检测精度达到了 96.60%, 但可变形卷积增加了计算复杂度, 导致模型推理速度进一步下降。这种两阶段检测算法训练过程复杂, 检测速度较慢, 且无法进行实时检测, 并不适用于工业 PCB 缺陷检测。在单阶段检测算法中, YOLO (You Only Look Once) 系列模型因其检测速度快、性能稳定, 成为工业界应用最广泛的检测算法之一^[7]。如 Wang Z. 等^[8]在 YOLOv3 模型中添加了注意力机制, 并将损失函数替换为 GIoU, 使得模型收敛速度加快, 但模型对微小缺陷的检测效果较弱; Liao X. T. 等^[9]在 YOLOv4 模型中, 将 CSPDarknet53 网络替换为 MobileNetV3 轻量级网络, 并通过 PCB 板缺陷检测实验选出了性能最优的 Mish 激活函数, 大幅降低了计算复杂度, 然而模型对部分缺陷目标容易出现漏检的问题; 曾耀等^[10]为了提高目标检测模型在电子元件上的实时检测能力, 对 YOLOv5 网络使用 GhostBlock 模块替换主干的 CSP 模块, 并引入坐标注意力机制来提升模型对目标的定位精度, 然

而模型的检测速度较慢。以上模型都各有优势, 但不能很好地兼顾速度与精度^[11], 难以实际应用到工业检测中。

自 YOLOv1 提出以来, 经过多次迭代, YOLOv8 在精度和速度上均有显著提升, 特别是在小目标检测和高分辨率图像处理方面展现出强大的性能优势^[12]。如吕秀丽等^[13]设计轻量级的多尺度混合卷积, 并结合 C2f (CSP bottleneck with 2 convolutions) 模块增强多尺度特征提取能力, 又在颈部网络中设计改进的双向特征金字塔结构, 从而获取更加丰富的语义信息, 这种方法主要侧重于轻量化的实现, 但是对于检测精度的提升不够理想; 王军等^[14]将 SE 注意力机制融入 C2f 中, 使网络能够根据通道域的信息给图像不同位置赋予不同的权重, 获取更重要的特征信息, 在 SPPF 中引入 Basic RFB 以增强网络感受野, 提升网络的特征提取能力, 同时新增小目标检测尺度, 提升模型对微小缺陷的检测能力, 然而模型对毛刺缺陷的检测效果较弱, 难以有效应对 PCB 缺陷的多样性。

在 PCB 缺陷检测任务中, YOLOv8 在处理复杂的背景、微小缺陷及高密度组件时, 仍面临一些挑战^[15]。为了解决这些问题, 本文提出了一种改进的 YOLOv8n 算法, 通过引入新型 C2XT 模块, 提升细小缺陷的检测能力。引入 GAM (global attention modulation) 注意力机制, 增强了复杂 PCB 缺陷的特征提取。颈部网络采用内容感知特征重组 (CARAFE) 上采样技术, 改善高分辨率特征表达。检测头中引入四头 ASFF (adaptively spatial feature fusion) 模块, 自适应融合多尺度特征, 提升检测鲁棒性和精度。最后, 设计了 μ -IoU 与 DFL (distribution focal loss) 组合, 优化对边界框回归损失的计算, 提高定位准确性。

2 YOLOv8n 算法介绍

YOLOv8 算法模型是 ultralytics 公司在开发 YOLOv5 后的又一新版本, YOLOv8 所使用的网络结构与 YOLOv5 相似, 都是由骨干网络 (Backbone)、颈部网络 (Neck) 和头部网络 (Head) 3 个部分构成。YOLOv8 算法模型有 YOLOv8n、YOLOv8s、YOLOv8m、YOLOv8l、YOLOv8x 共 5 个版本, 模型的体积依次增大, 考虑到轻量化与精度, 本文采用了 YOLOv8n 版本来进行改进。

3 改进的 YOLOv8n 算法结构

YOLOv8n 是 YOLOv8 的轻量化版本, 它在模型大小和检测精度之间提供了良好的平衡, 适合于实际

应用中对资源要求较低的任务^[16]。本文提出了一种改进的 YOLOv8n 网络结构, 主要包括特征提取、特

征融合和目标检测 3 个关键模块。改进的 YOLOv8n 结构如图 1 所示。




图 1 改进的 YOLOv8n 网络结构

Fig. 1 Improved YOLOv8n network architecture

首先, 网络的主干部分通过 CBS (convolution-batchnorm-silu) 块进行初始处理。这个模块包含一个步长为 2、大小为 3 的卷积核, 以及一个批处理和 SILU 激活函数。在初步特征提取之后, 堆叠多个 C2XT 模块与 CBS 块。之后在主干网络的中间添加 GAM 注意力机制, 进一步提升对重要特征的注意, 动态调整网络对不同特征的注意程度。主干网络的最后沿用了原网络的 SPPF (spatial pyramid pooling-fast) 模块, 采用两个 1×1 卷积调整通道数, 然后执行 3 次多尺度池化操作模拟不同感受野的特征响应, 再将原始输入特征和不同尺度池化后的特征图沿通道维度拼接在一起, 形成具有多尺度上下文信息的特征图。为了降低 C2XT 带来的模型冗余, 颈部部分采用了 CARAFE 上采样模块来处理多尺度特征, 通过自适应卷积方式进行特征图重建, 根据输入特征输出相应的上采样特征图, 以减少信息损失。最后用 4 个 C2f 模块对不同层次的特征进行处理, 再把经过特征提取与融合处理的特征图输入到检测头的 ASFF 模块中, 自适应地整合来自不同尺度的特征。

3.1 C2XT 模块

在 PCB 板缺陷检测应用中, 由于缺陷尺寸通常较小, 标准特征图感受野可能无法完全捕获这些细微缺陷的关键信息。为此课题组设计了崭新的 C2XT 模块对不同分支的特征进行拼接, 减轻了基础结构中对 3×3 规则卷积的严重依赖。

C2XT 结构先采用 CBS 模块对输入特征图进行特征转换, 再把特征分别输入到 3 个串行的 ConvNeXt 块中, 并且在每个模块之后进行残差连接, 随后将特征图再次通过 1 个 CBS 结构, 输出模型的有效特征层。C2XT 结构如图 2 所示。




图 2 C2XT 结构

Fig. 2 C2XT structure

ConvNeXt 是一个深度卷积神经网络, 它的设计与 Transformer 有一些相似之处^[17]。ConvNeXt 模块首先执行深度可分离卷积, 采用 9×9 的大核卷积来扩大感受野。接着, 通过 1×1 卷积改变通道数, 再使用 GELU (gaussian error linear unit) 激活函数处理输出。模块还设计了倒置瓶颈结构, 通过扩展通道数增加特征图的维度, 然后通过降维操作恢复到原来的通道数, 从而在保持计算效率的同时, 增强了特征的表达能力。公式表示如下:

$$Y = \sigma \left(LN \left(Conv_{1 \times 1} (X) * W_1 \right) \right) * W_2. \quad (1)$$

式中: X 为输入特征; Y 为输出特征; $Conv_{1 \times 1}$ 为进行 1×1 卷积操作; W_1 和 W_2 分别为扩展和压缩阶段的权重矩阵; $*$ 表示矩阵乘法; σ 为非线性激活函数; LN 为层归一化。

3.2 CARAFE 上采样模块

PCB 数据集中目标缺陷和背景之间的高度相似性, 存在大量噪声干扰现象。为了解决这一问题, Yang J. 等^[18]采用 CARAFE 上采样器在大感受野中

聚合上下文语义信息。CARAFE 具有更大的感受野, 能够有效聚合全局语义信息, 特别适用于 PCB 缺陷

检测等密集目标场景, 本文引入 CARAFE 模块作为上采样模块, 其结构如图 3 所示。




图 3 CARAFE 模块结构

Fig. 3 CARAFE module structure

CARAFE 由上采样核预测和特征重组两部分组成。在上采样核预测过程中, 输入的高级特征图首先通过 1×1 卷积进行通道压缩, 降低维度以提升后续操作的效率。经过 3×3 卷积后, 特征图被重新编码, 生成适应 4 倍上采样需求的上采样核。

特征重组阶段从输入特征图中选取一个 5×5 的局部区域, 每个局部区域的像素点会与生成的上采样核进行运算, 进而完成特征图的重组与放大, 公式表示如下:

$$Y(i, j) = \sum_{(m, n) \in N(i, j)} K_{i, j, m, n} * X(m, n), Y \in \mathbf{R}^{H \times W \times C}. \quad (2)$$

式中: $Y(i, j)$ 为上采样特征图在位置 (i, j) 处的值; $N(i, j)$ 为原特征图在位置 (i, j) 处的邻域像素; $K_{i, j, m, n}$ 为上采样核在 (i, j) 位置对应于邻域 (m, n) 的权重; $X(m, n)$ 是输入特征图中每个像素或特征点的值; $Y \in \mathbf{R}^{H \times W \times C}$ 表示输出张量的高度和宽度是输入特征图的 σ 倍, 通道数为 C 。

3.3 四头 ASFF 检测头

为了准确识别 PCB 板中的微小缺陷, 本文新增了能够提取 160×160 大小特征图的检测头, 专门针对 4×4 大小的目标进行检测。传统目标检测网络通常只使用单一层次的特征图, 而通过融入 ASFF 模块, 检测头能够对不同尺度的特征图进行自适应融合。改进后的 ASFF 模块如图 4 所示。

特征缩放阶段使用上下采样以及不同尺寸的卷积来保证特征融合时的特征图的尺度和通道数一致。在自适应融合阶段, ASFF 的 l 特征层在 (i, j) 处的融合计算式为

$$y_{ij}^l = x_{ij}^{1 \rightarrow l} * \alpha_{ij}^l + x_{ij}^{2 \rightarrow l} * \beta_{ij}^l + x_{ij}^{3 \rightarrow l} * \gamma_{ij}^l + x_{ij}^{4 \rightarrow l} * \delta_{ij}^l. \quad (3)$$

式中: $x_{ij}^{1 \rightarrow l}$ 、 $x_{ij}^{2 \rightarrow l}$ 、 $x_{ij}^{3 \rightarrow l}$ 、 $x_{ij}^{4 \rightarrow l}$ 为 4 个特征层在 l 特征层 (i, j) 处的特征映射; α_{ij}^l 、 β_{ij}^l 、 γ_{ij}^l 、 δ_{ij}^l 为权重系数, 此权重系数是通过网络进行自适应学习得到的。




图 4 四头 ASFF 模块结构

Fig. 4 Four-head ASFF module structure

3.4 GAM 注意力机制

在 PCB 板缺陷检测中, 由于缺陷目标形状的多样性, 检测精度要求极高, 引入 GAM (global attention modulation) 注意力机制能够有效整合全局上下文信息, 增强空间和通道之间的内在关联。

在缺陷形状多样、边缘模糊或背景噪声复杂的情况下, GAM 的全局维度交互机制使模型能够更准确地区分出微小但关键的模式差异, 进而提升整体检测精度和鲁棒性^[19]。给定输入特征图 $F_1 \in \mathbf{R}^{C \times H \times W}$, GAM 的最终输出特征图 F 为

$$F = (M_c(F_1) \otimes F_1) \otimes M_s(M_c(F_1) \otimes F_1). \quad (4)$$

式中: M_s 、 M_c 分别是空间注意力和通道注意力; F_1 为输入特征图; $\otimes$ 为逐元素乘法。

GAM 采用了顺序的通道-空间注意力机制, 并对子模块进行了重新设计。通道注意力模块通过三维

排列维护输入的三维特征,并利用全局平均池化和全局最大池化技术提取通道特征的全局信息。此后,通过多层感知器(MLP)增强跨通道维度间的依赖关系,从而动态调整各特征通道的权重,确保关键特征在后续处理中的优先级得以强化。空间注意力模块采用两个 7×7 的卷积核,旨在融合空间特征并有效捕捉局部区域内的空间信息。在这一过程中,特意去除了最大池化层,以防止可能丢失的有用特征,从而维护特征信息的完整性。GAM的全过程如图5所示:




图5 GAM注意力机制全过程

Fig. 5 GAM attention mechanism process

3.5 改进损失函数

对于目标检测任务,不同的损失函数对模型的性能和训练收敛速度有很大影响,本文提出了将DFL与 μ -IoU结合的损失计算方案。

Wise-IoUv3通过动态调整焦点系数^[20],减少了低质量样本对梯度计算的负面影响,在Wise-IoUv3基础上,本文设计了 μ -IoU,通过引入一个小于1的超参数 μ 来限制动态参数的波动,避免因噪声导致的

过拟合问题。计算公式如下:

$$L_{\mu\text{-IoU}} = \frac{\beta}{\delta \alpha^{\beta-\delta}} \exp \left(\frac{(X_b - X_{b^{\text{gt}}})^2 + (Y_b - Y_{b^{\text{gt}}})^2}{(h^c)^2 + (w^c)^2} \right) (1 - \text{IoU})^\mu. \quad (5)$$

式中: β 为动态参数; δ 和 μ 为超参数; X 和 Y 分别为 x 和 y 坐标; b 和 b^{gt} 分别为预测框和目标框的中心点; $\exp \frac{(X_b - X_{b^{\text{gt}}})^2 + (Y_b - Y_{b^{\text{gt}}})^2}{(h^c)^2 + (w^c)^2}$ 为计算中的惩罚

项; $1 - \text{IoU}$ 为计算预测框和目标框的交并比; h^c 和 w^c 分别为包含预测框和目标框的最小高和宽; α 为权重函数,计算公式为

$$\alpha = \frac{v}{(1 - \text{IoU}) + v}, \quad (6)$$

其中 v 为长宽比相似性因子,计算公式为

$$v = \frac{4}{\pi^2} \left(\tan^{-1} \frac{w^{\text{gt}}}{h^{\text{gt}}} - \tan^{-1} \frac{w}{h} \right)^2. \quad (7)$$

式中: h 和 h^{gt} 分别为预测框和目标框的高; w 和 w^{gt} 分别为预测框和目标框的宽。

4 PCB板检测算法流程

本文提出的PCB板缺陷检测算法框架如图6所示,整体流程可以划分为3个主要步骤:数据处理、网络训练以及模型评估。




图6 缺陷检测算法流程图

Fig. 6 Defect detection algorithm flowchart

本文采用旋转、翻转、缩放等离线增强和 YOLOv8 自带的 Mosaic、Mixup 等在线增强技术, 构建多样化数据集以提升泛化能力。改进的 YOLOv8 网络结合 AdamP^[21] 优化器进行训练, 优化模型参数。评估阶段综合检测指标、混淆矩阵及分类、边界框损失, 全面分析模型在 PCB 缺陷检测中的性能, 为优化提供依据。

5 实验与结果分析

5.1 数据预处理

本文使用的数据集是由北京大学发布的一个公共的合成 PCB 数据集, 数据集中有漏孔 (Missing_hole)、鼠咬 (Mouse_bite)、开路 (Open_circuit)、短路 (Short)、杂散 (Spur)、杂铜 (Spurious_copper) 6 种缺陷的图像, 共 693 张。由于数据集较小, 可能导致模型的泛化能力弱, 出现过拟合的情况^[22], 本文对数据集使用了旋转、翻转、缩放、亮度以及对比度调节等数据增强的操作, 将数据集拓展为 2 772 张图像, 按照 8:1:1 的比例随机划分为训练集、验证集和测试集。数据增强后的图片和原图的对比如图 7 所示。




图 7 原图与数据增强后图片对比

Fig. 7 Comparison between original and augmented images

5.2 实验平台与参数设置

本文实验在 Windows11 操作系统下进行, 使用了 python-3.8.17 和 pytorch1.8.0 深度学习框架, 使用 Pycharm 作为开发环境, 使用 CUDA10.2 加速 GPU, CPU 为 Intel(R) Core(TM) i5-9400F, GPU 为 NVIDIA GeForce GTX 1660 SUPER。

网络训练使用的参数: 学习率控制每次更新权重时步长的大小, 为确保训练过程的稳定性, 将其设置为较小值 0.001; 动量值控制了梯度对当前梯度的影响程度, 为有效解决梯度爆炸问题, 本实验将动量值设置为 0.937; 网络总共训练 400 次迭代, 确保

模型能在训练集上充分学习; 批大小的设置与训练速度、内存限制和模型的稳定性有关, 在尝试 4, 8, 16, 32 共 4 个值后, 发现设置为 16 时速度与稳定性最好。

5.3 评价指标

为评估模型整体性能, 实验使用精确率 (P)、召回率 (R)、平均精度均值 (mAP)、 F_1 分数 ($F_{1-Score}$) 评估模型检测性能, 用参数量 (Params) 评估模型大小, 每秒帧率 (FPS) 评估模型检测速度。其中 P 、 R 、 AP 、 mAP 、 $F_{1-Score}$ 和 FPS 的表达式分别如下:

$$P = \frac{TP}{TP + FP}, \quad (8)$$

$$R = \frac{TP}{TP + FN}, \quad (9)$$

$$AP = \int_0^1 P(r) dr, \quad (10)$$

$$mAP = \frac{\sum_{i=1}^C AP_i}{C}, \quad (11)$$

$$F_{1-Score} = 2 \times \frac{P \times R}{P + R}, \quad (12)$$

$$FPS = \frac{1}{T_p}. \quad (13)$$

式 (8) ~ (13) 中: TP 为预测与实际都为正类的样本数; FP 为预测为正实际为负的样本数; FN 为预测为负实际为正的样本数; C 为总类别数目; $P(r)$ 为以 r 为参数的 P - R 曲线函数; AP_i 为第 i 类的平均精度值; T_p 为每张图片处理时间。

5.4 对比实验

为验证本研究提出的算法在 PCB 电路板缺陷检测领域的有效性, 本研究选取了若干具有代表性的网络结构作为对照, 包括 YOLOv5n、YOLOv7-tiny 和 YOLOv8n 等。在保持实验条件和数据集一致性的前提下, 各模型的性能评估结果如表 1 所示。

表 1 不同模型对 PCB 缺陷检测的实验结果

Table 1 Experimental results of different models on PCB defect detection

模型	P	R	mAP	$F_{1-Score}$	Params/M	FPS
YOLOv3-tiny	0.902	0.887	0.921	0.894	12.1	32
SSD-ResNet50	0.692	0.687	0.712	0.689	-	23
YOLOv5n	0.919	0.904	0.946	0.911	1.8	54
YOLOv7-tiny	0.838	0.764	0.788	0.799	6.0	37
YOLOv8n	0.963	0.930	0.956	0.946	3.0	63
改进 YOLOv8n	0.979	0.951	0.986	0.964	5.9	57

从表 1 的对比结果可以看出, 改进后的 YOLOv8n 模型在 PCB 缺陷检测中的各项指标均表现优异, 精确度和召回率分别达到了 0.979 和 0.951,

平均精度均值为 0.986, $F_{1-Score}$ 提升到 0.964。与其他模型相比,改进后的 YOLOv8n 在性能上有显著提升。对比模型中, SSD-ResNet50 模型在各项指标上均明显低于其他对比模型,可能是默认结构不适合进行 PCB 表面缺陷检测。在与 YOLOv3-tiny 模型的对比中,改进 YOLOv8n 在精确度和 $F_{1-Score}$ 上分别提升了 7.7% 和 7.0%。在与 YOLOv7-tiny 和 YOLOv5n 的结果对比中,改进 YOLOv8n 在 mAP 上高出了 4% 以上。同时,改进模型的参数量保持在较低范围内,在关键指标上表现突出,能够实现优异的检测性能。尽管模型的每秒帧率 (FPS) 从 63 降低到 57,但该模型依然优于大多数对比模型,在性能和速度上实现了有效的平衡,仍能满足工业生产检测对实时性的要求。

图 8 和图 9 分别为原 YOLOv8n 算法和改进算法训练结果,按顺序分别为训练损失、精确度、召回率和平均精度均值,对比图中曲线可以看出,改进算法能用更少的 epoch 达到更高的模型性能。




图 8 原 YOLOv8n 算法训练结果

Fig. 8 Training results of the original YOLOv8n





图 9 改进 YOLOv8n 算法训练结果

Fig. 9 Training results of the improved YOLOv8n

图 10 和图 11 分别为原 YOLOv8n 算法和改进算法的 PR 曲线图。可以看出改进算法相对于原算法有更好的检测效果,尤其是对杂散和杂铜缺陷的检测,精度值相对于原算法分别有 6.8% 和 4% 的提升。




图 10 YOLOv8n 算法的 PR 曲线图

Fig. 10 PR curves of the YOLOv8n algorithm




图 11 改进 YOLOv8n 算法的 PR 曲线图

Fig. 11 PR curves of the improved YOLOv8n algorithm

图 12 和图 13 分别为改进前后的模型缺陷检测效果图,可以明显看出,优化后的网络模型能够更加准

确识别 PCB 上的各种缺陷位置。




图 12 YOLOv8n 缺陷检测效果
Fig. 12 Defect detection results of YOLOv8n




图 13 改进 YOLOv8n 缺陷检测效果
Fig. 13 Defect detection results of improved YOLOv8n

5.5 消融实验

本文以 YOLOv8n 作为基准模型，设计了 DFL 和改进 Wise-IoU 组合对损失进行计算，并且在骨干网络中引入 GAM 注意力机制来提高模型对特征提取的能力，此外还设计了一个融合了微小目标检测头和四头 ASFF 模块的检测头，以提高对 PCB 表面微小缺陷的检测精度。本文针对模型设计了消融实验，来验证本文几种改进方法的有效性，以及不同改进方法间的相互作用，实验结果如表 2 所示。

改进 1 通过在基准模型中引入 μ -IoU 与 GAM 注意力机制，尽管召回率略有下降，但 mAP 从 0.956 提升至 0.969，表明改进方法能改善定位精度。在此基础上，改进 2 通过加入 CARAFE 模块，进一步提升模型性能， mAP 达到 0.973，召回率提升至 0.938，显示出 CARAFE 对目标特征的显著增强效果。

表 2 消融实验结果

Table 2 Ablation study results

算法	GAM+ μ -IoU	CARAFE	C2XT	ASFF Detect	P	R	mAP
基准模型	×	×	×	×	0.963	0.910	0.956
改进 1	✓	×	×	×	0.955	0.935	0.969
改进 2	✓	✓	×	×	0.963	0.938	0.973
改进 3	✓	×	✓	×	0.961	0.933	0.969
改进 4	✓	×	×	✓	0.968	0.950	0.975
本文方法	✓	✓	✓	✓	0.979	0.951	0.986

改进 3 在引入 C2XT 模块后，尽管精度和 mAP 保持在较高水平，召回率却略有下降， mAP 稳定在 0.969，说明该模块改善了模型定位精度。最后，改进 4 通过加入 ASFF 检测头模块，显著提高了各项指标，召回率提升至 0.950， mAP 增至 0.975，证实了 ASFF 模块在多尺度特征融合方面的有效性。综合所

有改进,本文提出的方法在 PCB 板缺陷检测任务中表现卓越,各项指标达到了最优状态,充分证明了所提方法的有效性和鲁棒性。

6 结语

为解决 PCB 板表面缺陷检测中存在的微小目标漏检率高、检测准确率低等问题,本文提出了一种改进的 YOLOv8n 算法,通过优化网络结构与损失计算,提升了检测性能。在主干网络中, GAM 注意力机制的引入增强了关键特征聚焦能力, C2XT 模块的设计有效减少了细微目标的漏检问题,颈部通过 CARAFE 上采样技术改善了高分辨率特征的表达,而 ASFF 模块有效融合了多尺度信息,提升了多尺度特征的整体表现, DFL 与 μ -IoU 的组合进一步优化了边界框回归精度。实验结果表明,改进后的算法在检测精度、mAP 等关键指标上实现了显著提升。与现有模型相比,该方法在提升检测精度的同时降低了微小目标的漏检率,这一成果不仅满足了 PCB 板工业生产对高精度检测的需求,更为后续的研究工作奠定了坚实的基础。

参考文献:

- [1] 何国忠, 梁宇. 基于卷积神经网络的 PCB 缺陷检测[J]. 图学学报, 2022, 43(1): 21-27.
HE Guozhong, LIANG Yu. PCB Defect Detection Based on Convolutional Neural Network[J]. Journal of Graphics, 2022, 43(1): 21-27.
- [2] 罗东亮, 蔡雨萱, 杨子豪, 等. 工业缺陷检测深度学习综述[J]. 中国科学: 信息科学, 2022, 52(6): 1002-1039.
LUO Dongliang, CAI Yuxuan, YANG Zihao, et al. Survey on Industrial Defect Detection with Deep Learning[J]. Scientia Sinica (Informationis), 2022, 52(6): 1002-1039.
- [3] 高航, 祁云嵩. 基于 YOLOv8n 改进的太阳能电池板缺陷检测[J/OL]. 红外技术, 2024: 1-7. (2024-09-23). <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=HWJS20240920001&dbname=CJFD&dbcode=CJFQ>.
GAO Hang, QI Yunsong. Improved Defect Detection of Solar Panels Based on YOLOv8n[J/OL]. China Industrial Economics, 2024: 1-7. (2024-09-23). <http://kns.cnki.net/KCMS/detail/detail.aspx?filename=HWJS20240920001&dbname=CJFD&dbcode=CJFQ>.
- [4] 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.
- [5] FAN F L, WANG B Y, ZHU G L, et al. Efficient Faster R-CNN: Used in PCB Solder Joint Defects and Components Detection[C]//2021 IEEE 4th International Conference on Computer and Communication Engineering Technology (CCET). Beijing: IEEE, 2021: 1-5.
- [6] 朱红艳, 李泽平, 赵勇, 等. 基于多尺度融合和可变形卷积 PCB 缺陷检测算法[J]. 计算机工程与设计, 2022, 43(8): 2188-2196.
ZHU Hongyan, LI Zeping, ZHAO Yong, et al. PCB Defect Detection Algorithm Based on Multi-Scale Fusion and Deformable Convolution[J]. Computer Engineering and Design, 2022, 43(8): 2188-2196.
- [7] 李冰, 张易牧, 魏乐涛, 等. 基于改进 YOLOv8 的风机桨叶缺陷检测算法[J]. 电子测量技术, 2024, 47(13): 89-99.
LI Bing, ZHANG Yimu, WEI Letao, et al. Defect Detection Algorithm of Fan Blades Based on Improved YOLOv8[J]. China Industrial Economics, 2024, 47(13): 89-99.
- [8] WANG Z, CHEN W B, LI T F, et al. Improved YOLOv3 Detection Method for PCB Plug-in Solder Joint Defects Based on Ordered Probability Density Weighting and Attention Mechanism[J]. AI Communications, 35(3): 171-186.
- [9] LIAO X T, Lü S P, LI D H, et al. YOLOv4-MN3 for PCB Surface Defect Detection[J]. Applied Sciences, 2021, 11(24): 11701.
- [10] 曾耀, 高法钦. 基于改进 YOLOv5 的电子元件表面缺陷检测算法[J]. 浙江大学学报(工学版), 2023, 57(3): 455-465.
ZENG Yao, GAO Faqin. Surface Defect Detection Algorithm of Electronic Components Based on Improved YOLOv5[J]. Journal of Zhejiang University (Engineering Science), 2023, 57(3): 455-465.
- [11] 许德刚, 王露, 李凡. 深度学习的典型目标检测算法研究综述[J]. 计算机工程与应用, 2021, 57(8): 10-25.
XU Degang, WANG Lu, LI Fan. Review of Typical Object Detection Algorithms for Deep Learning[J]. Computer Engineering and Applications, 2021, 57(8): 10-25.
- [12] 杜昌都, 徐雷, 陈俊, 等. 基于轻量化 YOLOv8 网络的贴片芯片引脚缺陷检测[J]. 组合机床与自动化加工技术, 2024(9): 113-117.
DU Changdu, XU Lei, CHEN Jun, et al. Chip Pin Defect Detection Based on Lightweight YOLOv8 Network[J]. Modular Machine Tool & Automatic

- Manufacturing Technique, 2024(9): 113–117.
- [13] 吕秀丽, 杨昕升, 曹志民. 改进 YOLOv8 的 PCB 表面缺陷检测算法 [J]. 电子测量技术, 2024, 47(12): 100–108.
- LÜ Xiuli, YANG Xinsheng, CAO Zhimin. Improved PCB Surface Defect Detection Algorithm for YOLOv8[J]. Electronic Measurement Technology, 2024, 47(12): 100–108.
- [14] 王 军, 伍 毅, 陈正超. 基于 SMT-YOLOv8 的 PCB 缺陷检测研究 [J]. 电子测量技术, 2024, 47(11): 131–137.
- WANG Jun, WU Yi, CHEN Zhengchao. Research on PCB Defect Detection Based on SMT-YOLOv8[J]. Electronic Measurement Technology, 2024, 47(11): 131–137.
- [15] 李相垚, 侯红玲, 杨 澳, 等. 面向钢材表面缺陷检测的 DCS-YOLOv8 算法研究 [J/OL]. 机械科学与技术. [2024–10–16]. <https://link.cnki.net/doi/10.13433/j.cnki.1003-8728.20240128>.
- LI Xiangyao, HOU Hongling, YANG Ao, et al. Research on DCS-YOLOv8 Algorithm for Steel Surface Defect Detection[J/OL]. Mechanical Science and Technology. [2024–10–16]. <https://link.cnki.net/doi/10.13433/j.cnki.1003-8728.20240128>.
- [16] 徐一奇, 肖金球, 汪俞成, 等. 基于机器视觉的 PCB 表面缺陷检测研究综述 [J]. 微电子学与计算机, 2025, 42(4): 1–15.
- XU Yiqi, XIAO Jinqiu, WANG Yucheng, et al. A Review of PCB Surface Defect Detection Based on Machine Vision[J]. Microelectronics and Computer, 2025, 42(4): 1–15.
- [17] ZHANG Y H, WANG H X, YANG G, et al. CSNet: A ConvNeXt-Based Siamese Network for RGB-D Salient Object Detection[J]. The Visual Computer, 2024, 40(3): 1805–1823.
- [18] YANG J, LIU Z X, DU W N, et al. A PCB Defect Detector Based on Coordinate Feature Refinement[J]. IEEE Transactions on Instrumentation and Measurement, 2023, 72: 5029410.
- [19] LIU Y, SHAO Z, HOFFMANN N. Global Attention Mechanism: Retain Information to Enhance Channel-Spatial Interactions[J]. ArXiv, 2021: 2112.05561.
- [20] TONG Z J, CHEN Y H, XU Z W, et al. Wise-IoU: Bounding Box Regression Loss with Dynamic Focusing Mechanism[J]. ArXiv, 2023: 2301.10051.
- [21] HEO B, CHUN S, OH S J, et al. AdamP: Slowing Down the Slowdown for Momentum Optimizers on Scale-Invariant Weights[J]. ArXiv, 2021: 2006.08217.
- [22] 杨 波, 梁宇倩, 孙小明. 基于深度学习的小样本墙壁缺陷目标检测及分类 [J]. 山西大学学报 (自然科学版), 2022, 45(5): 1157–1166.
- YANG Bo, LIANG Yuqian, SUN Xiaoming. Object Detection and Classification of Small Sample Wall Defect Based on Deep Learning[J]. Journal of Shanxi University (Natural Science Edition), 2022, 45(5): 1157–1166.

(责任编辑: 申 剑)