

DOI:10.19651/j.cnki.emt.2415797

改进 YOLOv8 的 PCB 表面缺陷检测算法*

吕秀丽 杨昕升 曹志民

(东北石油大学物理与电子工程学院 大庆 163318)

摘要: 针对目前 PCB 表面缺陷检测方法存在复杂度过高、误检、漏检等问题,提出了一种改进 YOLOv8 的轻量化检测算法。由于 YOLOv8 主干网络下采样后的特征图存在一定冗余,设计轻量级的多尺度混合卷积(MSMC),并结合 C2f 模块增强多尺度特征提取能力;在颈部网络中设计改进的双向特征金字塔结构(BiFPN),使用两个跨层连接得到更加丰富的语义信息;使用 C2f-Faster 模块减少特征融合过程中的运算量;引入 CA 注意力机制与 WIoUv2 损失函数,增强对 PCB 小目标缺陷的定位能力。实验结果表明,相较于 YOLOv8n,改进后的算法在 PCB 数据集上检测精度提高了 2.2%,模型参数数量和计算量降低了 36.7%和 18.5%,分别为 1.9 M 和 6.6 G。最终模型大小仅为 3.8 MB,为移动终端设备部署提供了新思路。

关键词: 表面缺陷检测;YOLOv8;轻量化;多尺度特征;小目标缺陷

中图分类号: TP391;TN41 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Improved PCB surface defect detection algorithm for YOLOv8

Lyu Xiuli Yang Xinsheng Cao Zhimin

(College of Physics and Electronic Engineering, Northeast Petroleum University, Daqing 163318, China)

Abstract: A lightweight detection algorithm based on improving YOLOv8 is proposed to address the issues of high complexity, false alarms, and missed detections in current PCB surface defect detection methods. Due to some redundancy in the feature maps of the YOLOv8 backbone network after downsampling, a lightweight multi-scale mixed convolution (MSMC) is designed. This is combined with the C2f module to enhance the capability of extracting features at different scales. Additionally, an improved Bidirectional Feature Pyramid Network (BiFPN) structure is designed in the neck network, using two cross-layer connections to obtain richer semantic information. The C2f-Faster module is employed to reduce computational complexity during the feature fusion process. Moreover, the introduction of the CA attention mechanism and the WIoUv2 loss function strengthens the ability to locate small defects on PCBs. The experimental results show that the improved algorithm compared to YOLOv8n improves the detection accuracy by 2.2% on the PCB dataset, while the number of model parameters and the computation volume are reduced by 36.7% and 18.5% to 1.9 M and 6.6 G. The final model size is only 3.8 MB, providing a new approach for mobile terminal device deployment.

Keywords: surface defect detection; YOLOv8; lightweighting; multi-scale features; minor target defects

0 引言

印刷电路板(printed circuit board, PCB)作为电子工业生产中最重要的元器件之一^[1],几乎应用于每一种电子设备中。为满足当前市场对更加精密、复杂的电子电路需求,PCB 正朝着精密化、多层化和小型化的方向发展^[2]。但 PCB 在制造过程中不可避免会产生缺陷,主要缺陷类型有表面缺陷、焊点缺陷、元件组装缺陷等,其中表面缺陷是导

致 PCB 板性能下降的关键因素之一^[3]。本文主要研究 6 种常见的表面缺陷:漏孔、鼠咬、开路、短路、毛刺、杂铜。这些缺陷存在背景环境复杂、缺陷面积小、缺陷种类多且特征相似等特点,导致在检测过程中易出现误检和漏检等问题。

传统 PCB 表面缺陷检测方法主要包括人工视觉检测法^[4]和电气检测法^[5]。由于人工检测主观因素影响较大、易产生视觉疲劳,且电气检测范围有限、易损伤电路板,传

收稿日期:2024-04-09

* 基金项目:黑龙江省教育科学规划重点课题(GJB1421131)、海南省科技专项(ZDYF2022GXJS222)资助

统检测方法已经逐渐被淘汰。随着图像处理和计算机视觉技术的发展,自动光学检测(automatic optical detection, AOD)技术被广泛应用于 PCB 缺陷检测中^[6]。目前基于图像处理和机器学习的算法已嵌入到 AOI 系统中以实现更高效的检测。Nahar 等^[7]使用图像相减、区域属性提取等方法对 PCB 进行检测;Baygin 等^[8]同时使用霍夫变换和 Canny 算子,对 PCB 图像进行分割,提高了对 PCB 圆孔的检测效果。然而,这些方法都存在获取模板图像困难,严重依赖手工提取特征,无法实时处理大规模数据等问题。

近年来,深度学习在目标检测领域日益成熟。目前,基于深度学习的目标检测算法主要分为单阶段和二阶段检测算法。二阶段检测算法主要以 Mask R-CNN、Fast-RCNN、Faster-RCNN 算法为代表,但存在训练过程复杂、检测速度慢、无法进行实时检测等问题,并不适用于工业 PCB 缺陷检测。单阶段算法主要以 SSD、YOLO 系列为代表,具有检测速度快、计算量少等优点,能够满足工业检测的基本需求。刘涛等^[9]在 YOLOv4 模型中采用 GhostNet 作为主干网络以增强特征提取能力,并引入通道注意力机制使网络更专注于缺陷特征。张果等^[10]在 YOLOv4-tiny 模型中采用优化后的聚类方法处理缺陷数据集,同时在主干网络下采样过程中引入切片操作,在特征融合网络中采用了软池化卷积结构,并改进交叉熵损失函数提高了模型整体性能。王淑青等^[11]基于 YOLOv5 模型框架,采用 EfficientNetV2 主干网络,引入坐标注意力机制和 α -IoU 损失函数提高模型精度,改进后网络平均精度(mean average precision, mAP)达到 97.4%。王素琴等^[12]提出了一种基

于 YOLOv5 的差异化检测网络 YOLO-Differ,该网络结合频率线索和细粒度分类网络(vision transformer, ViT)的方法来增强背景与缺陷的差异性特征。改进后网络在 PCB 数据集上 mAP 达到 96.5%。沈萍等^[13]在 YOLOv8 模型中采用轻量化网络 MobileViT 替换主干,并引入三重注意力机制和 MPDIoU(minimum point distance based IoU)损失函数来提高检测精度。改进后网络 mAP 达到 95.9%,参数量和计算量分别为 1.18 M 为 5.3 G。姜媛媛等^[14]设计了多交叉残差(multi-cross residual YOLO, Multi-CR YOLO)缺陷检测模型,有效解决了 PCB 缺陷目标较小而导致的特征提取较难的问题。上述研究虽然在一定程度上对模型进行了轻量化处理并提升了模型的检测精度,但在 PCB 缺陷检测需要更高精度、更低内存、更轻量化的要求下仍有改进的空间。

本文以 YOLOv8n 网络模型作为基础,提出了一种更加轻量化的模型。设计多尺度混合卷积(multi-scale mixed convolutional, MSMC),并结合 C2f 模块,增强主干网络的多尺度特征提取能力;改进双向特征金字塔结构(bi-directional feature pyramid network, BiFPN),有效减少模型参数量和计算量;设计 C2f-Faster 模块,融入部分卷积,减少特征融合过程中的运算量;引入坐标注意力机制,增强模型空间识别能力;改进回归损失函数算法,提高边界框的质量。

1 YOLOv8 模型

YOLOv8 网络结构如图 1 所示,由特征提取网络(Backbone)、特征融合网络(Neck)和检测头(Head)3 部分组成。

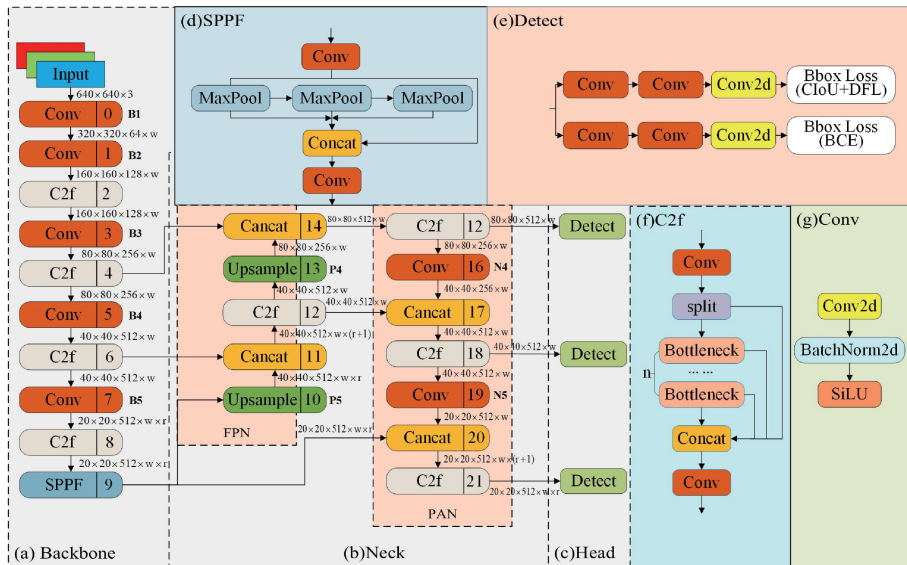


图 1 YOLOv8 网络结构

Fig. 1 YOLOv8 network structure

Backbone 网络如图 1(a)所示,输入图像通过 5 次连续下采样,获得 5 个不同尺度的特征(B1~B5);使用梯度流更加丰富的 C2f 模块,如图 1(f)所示,采用梯度分流连接,

减少了一个卷积层,并充分利用 Bottleneck 模块来增强梯度分支;输出特征图由 SPPF(spatial pyramid pooling with features)模块处理,如图 1(d)所示,该模块通过 3 个最大

池化层将输入特征图自适应生成固定尺寸的输出,减少了计算量并具有更低的延迟。Neck 网络采用 FPN-PAN (feature pyramid network-pixel aggregation network) 结构增强模型的特征融合能力,如图 1(b)所示,其中 P4-P5 和 N4-N5 分别表示 FPN 和 PAN 结构中不同尺度的特征。FPN-PAN 构建了自下而上和自上而下的网络结构,通过特征融合实现位置信息和深层语义信息的互补,从而产生特征的多样性。Head 网络中探测头 Detect 采用目前主流的解耦头结构,如图 1(e)所示, Detect 将分类头和检测头分离。对于回归任务,采用分布焦点损失 (distribution

focal loss, DFL) 和 CIoU (complete-IoU); 对于分类任务,采用二元交叉熵损失 (BCE Loss)。

2 改进算法设计

本文提出改进的 YOLOv8 结构如图 2 所示。首先在 Backbone 第 6 层和第 8 层添加轻量化 C2f-MSMC 模块来增强多尺度特征提取能力。在 Neck 中,通过 3 层卷积(11~13 层)统一输入通道数,采用改进 BiFPN,实现多尺度特征融合,并在小目标探测头上引入 CA 注意力机制,添加 C2f-Faster 模块降低模型复杂度。

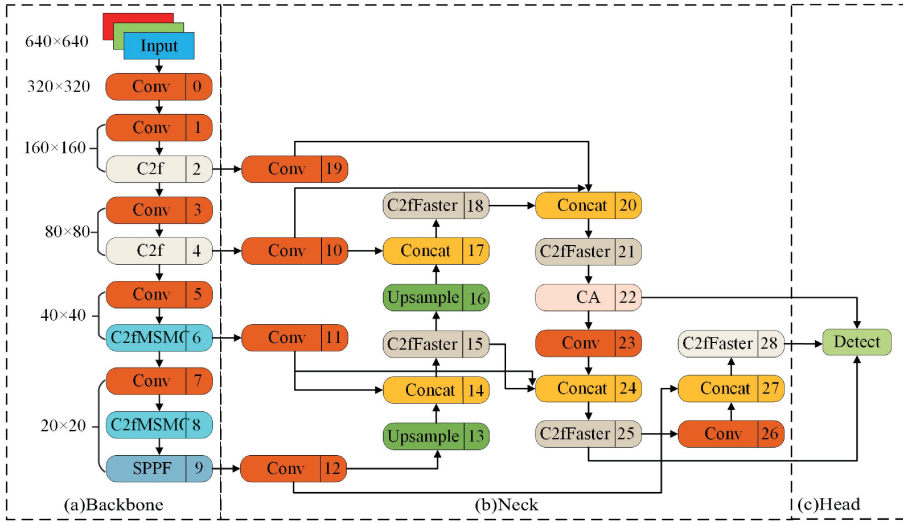


图 2 改进 YOLOv8 网络结构

Fig. 2 Improvement of YOLOv8 network structure

2.1 设计 C2f-MSMC 模块

主干网络经过多次下采样对输入图像进行特征提取,能够得到丰富的语义信息。但随着网络层数加深,特征图通道数也越来越大,多个通道的特征图携带了相似或相同的信息,会造成特征图的冗余^[15]。本文设计的多尺度混合卷积 MSMC,通过引入不同尺度的卷积核,使其能够跨多个尺度捕获各种空间特征,提高模型的准确率。MSMC 结构如图 3(a)所示,首先将输入通道分成 4 组,每组分别使用大小为 1、3、5、7 的卷积核进行特征提取。通过执行 4 个通道分割操作获得多尺度信息,同时减少模型参数量和计算量。然后使用 1×1 逐点卷积对多尺度特征图进行扫描,实现跨通道融合,同时保证输入和输出通道数一致。

本文将 MSMC 与 C2f 模块相结合,设计了 C2f-MSMC 模块,将 C2f 中 Bottleneck 模块的第 2 个卷积替换为 MSMC,组成 BottleneckEMSC,如图 3(b)所示。C2f-MSMC 模块能够获得更加丰富的多尺度特征,提高了主干网络的特征提取能力,并有效减少参数量和计算量。

2.2 改进 BiFPN 模块

BiFPN^[16]结构如图 4 所示,是在 FPN 和 PANet 基础上改进的,能够简单快速地融合多尺度特征。通过构造双




图 3 C2f-MSMC 中部分模块结构

Fig. 3 Partial module structure in C2f-MSMC

向通道实现跨尺度连接,保留了更浅的语义信息,而不会丢失太多的深层语义信息。




图 4 BiFPN 结构

Fig. 4 BiFPN structure

本文基于 BiFPN 的思想,在上采样过程中对尺寸为 40×40 、 80×80 的特征图跨层连接,并将尺寸为 160×160 的大规模特征图与上一层特征图进行特征融合,通过较少的操作可以获得更加丰富的特征,在保持参数成本的同时,提高了对 PCB 小目标缺陷的检测效果,改进的 BiFPN 网络结构如图 5 所示。该模块不仅通过特征层间的跨尺度连接,丰富了特征层的语义信息和底层信息,而且能够自动学习不同分辨率的特征层对多尺度融合的权重系数,提高模型对 PCB 小目标缺陷的检测性能。




图 5 改进 BiFPN 结构

Fig. 5 Improvement of BiFPN structure

2.3 设计 C2f-Faster 模块

本文使用 FasterNet^[17] 中部分卷积的思想设计了 Faster Block 结构,用来替换 C2f 的 Bottleneck 模块,并将改进后的 C2f 模块记为 C2f-Faster,如图 6 所示。其中 PConv(partial convolution)只选用 $1/4$ 的输入通道进行卷积操作,并将剩余的 $3/4$ 的通道保持不变,输出这两部分通道拼接后的特征图。因此,PConv 层并不改变输入通道数和特征图的尺度。接着使用 1×1 逐点卷积操作中把上层的输出特征图通道数扩张为原来的 2 倍,同时也利用了部分卷积层中未处理的通道,避免了通道信息的浪费。最后使用 1×1 卷积层将上层的输出还原回扩张前的通道数,保证捷径分支的 X 与经过主干路径处理后的特征图有着相同的维度和大小。

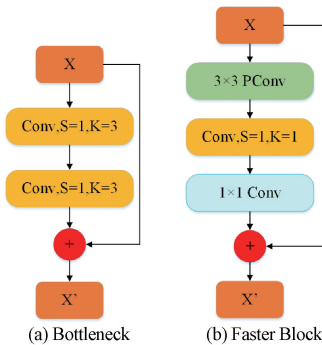


图 6 Faster Block 模块结构

Fig. 6 Faster Block module structure

2.4 引入 CA 注意力机制

在 PCB 缺陷图像中,由于缺陷目标所占像素小且容易受到背景因素影响,YOLOv8 网络在进行特征融合时容易造成特征信息丢失,因此本文提出在小目标探测头引入坐

标注意力机制(coordinate attention,CA)^[18]进行局部特征增强,使网络更加精准地定位和识别图像中的重要信息。

与传统注意力机制 SE (squeeze-and-excitation networks)和 CBAM(convolutional block attention module)等相比,CA 是针对通道注意力提出的一种新的注意力模块。CA 模块将位置信息融合到通道信息中,在捕获通道特征的同时进行方向和位置的信息捕捉。其结构如图 7 所示,首先将输入特征图分别沿垂直和水平两个方向进行全局平均池化。然后将两个方向的特征信息合并到特征图中,提高特征表达能力。接着关注水平和垂直方向,特征图进行分割和卷积。模块输出的两部分特征图精确指向感兴趣目标对象的行和列。

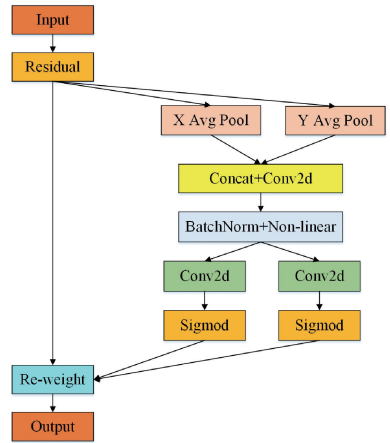


图 7 CA 注意力机制结构

Fig. 7 Structure of the CA attention mechanism

2.5 更换损失函数

YOLOv8 使用 DFL 和 CIoU 来计算边界框的回归损失。然而 CIoU 仅考虑 IoU 和中心之间的距离以及真实框和预测框之间的长宽比等因素,并没有考虑样本难易程度对损失函数影响。

本文在回归损失中引入 WIOU(wise-IoU)^[19]中的第 2 个版本 WIOUv2。WIOUv2 不仅考虑了位置、质心距离和重叠面积,而且通过构造单调聚焦函数,有效降低了损失函数中低质量样本权重,提高模型的检测性能。WIOUv2 构造单调聚焦系数 L_{IoU}^* ,引入 L_{IoU} 的均值对 L_{IoU}^* 进行归一化。WIOUv2 公式如下:

$$L_{WIOUv2} = \left(\frac{L_{IoU}^*}{L_{IoU}} \right)^\gamma L_{WIOUv1}, \gamma > 0 \quad (1)$$

$$L_{WIOUv1} = R_{WIOU} \times L_{IoU} \quad (2)$$

$$R_{WIOU} = \exp\left(\frac{(x - x_{gt})^2 + (y - y_{gt})^2}{(W_g^2 + H_g^2)} \right) \quad (3)$$

式中: R_{WIOU} 为高质量锚框的丢失; L_{IoU} 为预测框和实际框之间的重叠程度; x 和 y 为预测框的中心坐标值; x_{gt} 和 y_{gt} 为人工标注框的中心坐标值; W_g 和 H_g 为最小闭合框的宽和高。

3 实验及结果分析

3.1 实验环境

实验环境建立在 AutoDL 服务器上,使用 ubuntu20.0.4 操作系统,40 GB 内存,配备 RTX3080 GPU、Intel Xeon Platinum 8255C CPU,在 PyTorch2.0.0、Python3.8 和 Cuda11.8 下进行实验,训练参数如表 1 所示。

表 1 训练基本参数

Table 1 Basic parameters of training

参数名	参数值
学习率	0.01
权重衰减系数	0.000 5
动量	0.937
优化器	SGD
批量大小	32
训练轮数	300

3.2 数据集及扩充

实验采用北京大学开放实验室发布的 PCB 缺陷数据集^[20],共包含 693 张图像,缺陷类型包括漏孔(Mh)、鼠咬(Mb)、开路(Oc)、短路(Sh)、毛刺(Sp)和杂铜(Sc),6 类缺陷如图 8 所示。为还原 PCB 在检测过程中可能出现的复杂情况,通过随机亮度调整、添加椒盐噪声、运动模糊、随机缩放、随机旋转等图像处理方法,将原始数据集扩充到 4 158 张图像。扩充数据集各种缺陷分布如表 2 所示。训练集、验证集和测试集按 7 : 2 : 1 的比例划分。




图 8 6 种缺陷类型

Fig. 8 Six types of defects

表 2 各类缺陷分布

Table 2 Distribution of various defects

缺陷类型	图像数量	缺陷数量	缺陷尺寸/pixel		
			≤10×10	≤16×16	≤32×32
漏孔	690	2 889	2	962	1 875
开路	690	2 804	380	1 740	682
鼠咬	696	2 886	92	1 255	1 508
短路	696	2 868	11	384	2 209
毛刺	690	2 863	36	672	2 095
杂铜	696	2 947	10	485	2 389

3.3 评价指标

为了评估模型的整体性能,实验使用精确率 (precision, P)、召回率 (recall, R)、平均准确率 (average precision, AP)、mAP 来评估模型检测性能,使用模型参数量 (Params) 来衡量模型的空间复杂度,使用模型计算量 (FLOPs) 来评估模型的计算资源消耗情况,使用 FPS 来评估模型检测速度。其中 P、R 和 mAP 表达式分别为:

$$P = \frac{TP}{TP + FP} \quad (4)$$

$$R = \frac{TP}{TP + FN} \quad (5)$$

式中: TP 为真正例; FN 为假反例; FP 为假正例。

$$AP = \int_0^1 P(R) dR \quad (6)$$

$$mAP = \frac{\sum_{i=1}^N AP_i}{N} \quad (7)$$

式中: AP 为单类标签的平均准确率; N 为所有类别的数量。

3.4 损失函数对比实验

为了验证引入 WIoUv2 损失函数的优越性,将其与几种主流损失函数进行对比实验,在保证其他训练条件不变的情况下,仅改变损失函数,实验结果如图 9 所示。由于 CIoU、EIoU (efficient-IoU)^[21]、SIoU (simplified-IoU)^[22]、MPDIoU^[23] 都采用静态聚焦机制,无法动态调整梯度增益,导致训练效果较差。WIoUv1 仅构建距离注意力,无法有效降低回归损失。WIoUv3 采用动态非单调聚焦机制,拥有最快的收敛速度,但回归损失并不稳定。WIoUv2 采用交叉熵的单调聚焦机制,使得模型能够更多的聚焦在困难样本上,提高网络的检测性能。




图 9 不同损失函数对比

Fig. 9 Comparison plot of different loss functions

3.5 消融实验

为验证本文提出的各种模块的有效性,设计了消融实验,如表 3 所示。A 表示将 YOLOv8n 主干网络最后两层 C2f 替换为 C2f-MSMC, B 表示在 A 基础上将特征融合网络替换为改进的 BiFPN 模块, C 表示在 B 的基础上增加

C2-faster 模块,D表示在C的基础上增加CA注意力机制,E表示在D的基础上将损失函数变为WIoUv2。在引入C2f-MSMC模块(A)后,模型召回率提升了2.5%,mAP提升了1.4%,验证了该模块具有良好的多尺度特征提取能力。引入改进BiFPN模块(B)后,模型参数量和计算量分别降低了约1%。引入C2f-Faster模块(C)后进一步实现模型轻量化,并且检测精度有一定提升。引入CA注意力模块(D)后,只增加了少量参数量,有效提高了检测精度。引入WIoUv2损失函数(E)后,使得mAP实现了最大化。最终模型P、R和mAP相较原算法分别提升了1.6%、3.1%和2.2%,模型参数量仅为1.863M,计算量仅为6.6G,有效降低模型了在移动终端部署难度。

3.6 对比实验

如图10所示,本文通过可视化改进前后两种模型的

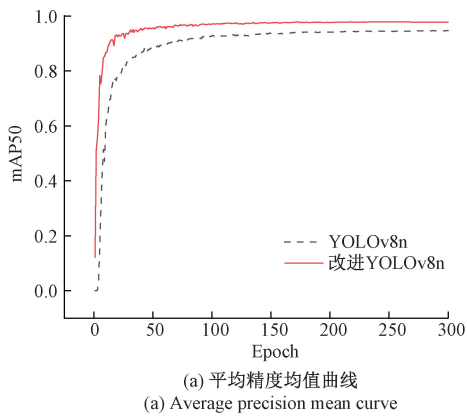


表3 消融实验
Table 3 Ablation experiment

算法	P%	R%	mAP	Params/M	FLOPs/G
YOLOv8n	97.0	91.8	95.5	3.007	8.1
A	97.9	94.3	96.9	2.940	8.0
B	98.0	93.6	96.6	1.925	7.0
C	98.2	93.7	97.0	1.856	6.6
D	98.5	94.0	97.3	1.863	6.6
E	98.6	94.9	97.7	1.863	6.6

mAP和总损失函数曲线来进一步分析模型的性能变化。图10(a)显示改进算法在mAP方面显著提升,图10(b)显示改进算法总损失表现更低,并拥有更快的收敛速度,验证了改进算法的有效性。




图10 模型改进前后mAP和总Loss曲线对比

Fig. 10 Comparison of mAP and total Loss curves before and after model improvement

本文与现阶段主流的检测算法:Faster R-CNN、SSD、RT-DETR-L、YOLO系列、先进的改进算法进行了对比实验,实验结果如表4所示。与Faster R-CNN和SSD、RT-DETR-L、YOLOv3相比,改进算法在处理鼠咬、开路、毛刺和杂铜4种缺陷类型时,分别实现了约6%、10%、10%和8%的显著性能提升,同时大大降低了模型的复杂度和大小。与YOLO系列轻量级网络YOLOv5n、YOLOv7tiny、YOLOv8n相比,改进算法在保证运行速度的前提下,mAP分别提升2.5%、3.2%、2.2%。与YOLO系列大尺度模型YOLOv5s和YOLOv8s相比,改进算法的参数量分别下降73%和83%,计算量分别下降58%和77%,并且检测精度达到最高。文献[12]中改进算法的参数量和计算量达到最低,但本文改进算法的mAP提升了2.5%,且模型体积减少了5.9M。相较于文献[13],本文的改进算法在检测精度和模型轻量化方面表现更优,同时在多个缺陷类别上平均精确率达到了最高水平。以最小的模型体积达到了最高的检测精度,使用成本更低、部署更加简单,具有高效性和优越性。

3.7 检测效果及分析

实验在PCB数据集中随机选取了6种不同缺陷类型的图像进行测试,每张图像存在多个缺陷,检测结果如图11所示,其中图11(a)~(f)上方为YOLOv8n算法的检测结果,下方为改进后算法的检测结果。在图11(f)中由于毛刺和杂铜两种缺陷类型相似,导致YOLOv8n算法的检测结果中出现了误检的问题,将杂铜类型错误的识别为毛刺类型,而且使用YOLOv8n算法的部分缺陷的检测准确率低于80%。本文改进的算法对6种缺陷类型均进行了正确的识别,不存在误检问题。而且6种类型的检测准确率均接近90%,相较于YOLOv8n六类缺陷平均检测精度分别提升了约7.8%、6.0%、14.2%、8.4%、5.8%、6.0%。为进一步验证本文改进算法的效果,实验还采用通过线性扫描CCD获得的PCB缺陷数据对改进算法进行验证,验证结果如图12所示,其中上方为YOLOv8n算法的检测结果,下方为改进后算法的检测结果。与原始算法相比本文改进算法检测精度更高,同时没有出现误检情况,证明本文改进算法有效降低了误检率,提高了检测准确率,有着更好的检测性能和更强的泛化能力。

表 4 对比实验

Table 4 Comparison experiment

算法	AP/%						mAP/ %	Params/ M	FLOPs/ G	FPS/ 帧	体积/ MB
	漏孔	鼠咬	开路	短路	毛刺	杂铜					
Faster-RCNN	98.0	91.8	86.4	97.3	85.2	90.1	90.9	41.4	205.1	22	158
SSD	97.3	90.7	82.5	97.1	83.7	89.5	88.9	24.4	85.7	36	93.1
RT-DETR-L	98.4	90.4	82.5	97.9	83.9	89.9	90.3	32.8	110.4	28	125
YOLOv3tiny	98.2	89.3	84.2	98.1	84.1	90.2	90.7	12.1	18.9	134	92.7
YOLOv5n	99.2	96.7	91.3	98.1	90.8	95.5	95.2	1.8	4.2	122	3.8
YOLOv5s	99.3	97.4	97.1	98.3	94.3	97.8	97.5	7.0	15.8	102	13.7
YOLOv7tiny	99.2	94.5	95.8	96.7	89.3	91.5	94.5	6.0	13.1	140	46.4
YOLOv8n	99.4	93.8	95.5	97.9	91.7	94.2	95.5	3.0	8.1	132	6.0
YOLOv8s	99.4	98.1	96.7	98.1	95.3	98.0	97.5	11.1	28.4	93	21.4
文献[12]	98.5	95.4	95.3	96.5	90.3	95.5	95.2	1.2	5.9	112	9.7
文献[13]	99.0	97.5	96.4	98.0	94.4	98.1	97.4	3.8	9.8	115	12.4
本文	99.5	98.1	96.5	98.9	94.9	98.4	97.7	1.9	6.6	88	3.8




图 11 不同缺陷检测效果对比

Fig. 11 Comparison chart of different defect detection effects




图 12 线性扫描 CCD 缺陷检测效果

Fig. 12 Linear scanning CCD defect detection effect diagram

4 结 论

本文提出了一种轻量化且性能较好的改进 YOLOv8n 算法,使用 C2f-MSMC 模块增强主干网络的多尺度特征提取能力,设计改进 BiFPN 结构使模型更加轻量化,采用 C2f-Faster 模块降低模型复杂度,引入 CA 注意力机制和 WIoUv2 损失函数增强 PCB 小目标定位能力。实验结果

表明,改进后的算法具有参数量更少、计算量更低、检测精度更高等优点。与现有模型相比,该方法具有较高检测精度的同时降低了对平台计算和储存能力的要求,易于部署在资源受限的设备上。

参考文献

- [1] ZHANG Q, LIU H. Multi-scale defect detection of printed circuit board based on feature pyramid network[C]. IEEE

- International Conference on Artificial Intelligence and Computer Applications(ICAICA), 2020.
- [2] GOTO K, KATO K, SAITO T, et al. Adversarial autoencoder for detecting anomalies in soldered joints on printed circuit boards [J]. *Journal of Electronic Imaging*, 2020, DOI: 10.1117/1.JEI.29.4.041013.
- [3] 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.
- [4] WE X, YANG Z, LIU Y, et al. Railway track fastener defect detection based on image processing and deep learning techniques: A comparative study [J]. *Engineering Applications of Artificial Intelligence*, 2019, 80: 66-81.
- [5] SUNDARAJ K. PCB inspection for missing or misaligned components using background subtraction [J]. *WSEAS Transactions on Information Science and Applications*, 2009, 6(5): 778-787.
- [6] ANITHA D B, RAO M. A survey on defect detection in bare PCB and assembled PCB using image processing techniques [C]. *International Conference on Wireless Communications, Signal Processing and Networking(WISPNET)*, 2017.
- [7] NAHAR J A, PHADKE A C. Computer aided system for inspection of assembled PCB [C]. *International Conference on Intelligent Computing and Control Systems(ICCS)*, 2019.
- [8] BAYGIN M, KARAKOSE M, SARIMADEN A, et al. Machine vision based defect detection approach using image processing [C]. *International Artificial Intelligence and Data Processing Symposium(IDAP)*, 2017.
- [9] 刘涛, 张涛. 基于 GhostNet-YOLOv4 算法的印刷电路板缺陷检测 [J]. *电子测量技术*, 2022, 45(16): 61-70.
- LIU T, ZHANG T. Defect detection of printed circuit board based on GhostNet-YOLOv4 algorithm [J]. *Electronic Measurement Technology*, 2022, 45(16): 61-70.
- [10] 张果, 陈逃, 王剑平, 等. 轻量化的 PCB 表面缺陷检测算法 [J]. *北京邮电大学学报*, 2024, 47(2): 38-44.
- ZHANG G, CHEN T, WANG J P, et al. Lightweight detection algorithm for detecting surface defects in PCB [J]. *Journal of Beijing University of Posts and Telecommunications*, 2024, 47(2): 38-44.
- [11] 王淑青, 张子言, 朱文鑫, 等. 基于改进 YOLOv5 的 PCB 板表面缺陷检测 [J]. *仪表技术与传感器*, 2023, (5): 106-111.
- WANG SH Q, ZHANG Z Y, ZHU W X, et al. Surface defect detection of PCB based on improved YOLOv5 [J]. *Instrument Technique and Sensor*, 2023, (5): 106-111.
- [12] 王素琴, 程成, 石敏, 等. 结合频率和 ViT 的工业产品表面相似特征缺陷检测方法 [J]. *图象图形学报*, 2024, DOI: 10.11834/jig.230532.
- WANG S Q, CHEN CH, SHI M, et al. A defect detection method for industrial product surfaces with similar features by combining frequency and ViT [J]. *Journal of Image and Graphics*, 2024. DOI: 10.11834/jig.230532.
- [13] 沈萍, 李想, 杨宁, 等. 基于三重注意力的轻量级 YOLOv8 印刷电路板缺陷检测算法 [J]. *微电子学与计算机*, 2024, 41(4): 20-30.
- SHEN P, LI X, YANG N, et al. Lightweight YOLOv8 PCB defect detection algorithm based on triple attention [J]. *Journal of Image and Graphics*, 2024, 41(4): 20-30.
- [14] 姜媛媛, 蔡梦南. 轻量化的印刷电路板缺陷检测网络 Multi-CR YOLO [J]. *电子测量与仪器学报*, 2023, 37(11): 217-224.
- JIANG Y Y, CAI M N. Lightweight PCB defect detection network Multi-CR YOLO [J]. *Journal of Electronic Measurement and Instrument*, 2023, 37(11): 217-224.
- [15] HA K, WANG Y, TIAN Q, et al. Ghostnet: More features from cheap operations [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020.
- [16] TAN M, PANG R, LE Q V. Efficientdet: Scalable and efficient object detection [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020.
- [17] CHE 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.
- [18] HOU Q, ZHOU D, FENG J. Coordinate attention for efficient mobile network design [C]. *Proceedings of*

- the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021.
- [19] TONG Z, CHEN Y, XU Z, et al. Wise-IoU: Bounding box regression loss with dynamic focusing mechanism[J]. ArXiv preprint arXiv: 2301.10051, 2023.
- [20] DING R, DAI L, LI G, et al. TDD-net: A tiny defect detection network for printed circuit boards[J]. CAAI Transactions on Intelligence Technology, 2019, 4(2): 110-116.
- [21] ZHANG Y F, REN W, ZHANG Z, et al. Focal and efficient IOU loss for accurate bounding box regression[J]. Neurocomputing, 2022, 506: 146-157.
- [22] GEVORGYAN Z. SIoU loss: More powerful learning for bounding box regression [J]. ArXiv preprint arXiv:2205.12740, 2022.
- [23] SILIANG M, YONG X. MPDIoU: A loss for efficient and accurate bounding box regression [J]. Arxiv preprint arXiv:2307.07662, 2023.

作者简介

吕秀丽(通信作者), 教授, 主要研究方向为数字图像处理、生物特征识别技术、数字水印与信息隐藏。

E-mail: lxl_20041231@163.com

杨昕升, 硕士研究生, 主要研究方向为目标检测、图像处理。

E-mail: 18993811435@163.com

曹志民, 副教授, 主要研究方向为工业大数据信息挖掘与人工智能应用技术。