

DOI:10.19651/j.cnki.emt.2315076

# 基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法<sup>\*</sup>

李忠科 刘小芳

(四川轻化工大学计算机科学与工程学院 宜宾 644000)

**摘要:** 针对 PCB 缺陷检测无法兼顾检测精度与模型体积的问题,提出一种基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法。首先,删除大目标检测层,新增小目标检测层并调整网络结构,使模型轻量化并提高检测精度。其次,将 C2f 模块结合 GhostConv 与 DWConv 设计出 C2f-GhostD 模块替换 C2f 模块,减少模型计算成本。然后,将 PConv 融入 Detect 模块中,设计出 POne-Detect 模块并应用于检测网络,精简网络结构。最后,在颈部网络添加 SimAM 注意力机制,提高信息捕获能力。实验结果表明,在 PCB 数据集中,该算法相较于 YOLOv8n,参数量下降 78.7%,模型体积减小 73.7%,mAP0.5 提升至 98.6%,满足模型硬件部署需求。

**关键词:** PCB;轻量化;缺陷检测;小目标检测;YOLOv8n

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

## PCB defect detection algorithm based on lightweight YOLOv8n network

Li Zhongke Liu Xiaofang

(School of Computer Science and Engineering, Sichuan University of Science &amp; Engineering, Yibin 644000, China)

**Abstract:** A lightweight YOLOv8n-based algorithm for PCB defect detection is proposed to address the trade-off between detection accuracy and model size. Firstly, the large target detection layer is deleted, the small target detection layer is added, and the network structure is adjusted to make the model lightweight and improve detection accuracy. Secondly, the C2f module is combined with GhostConv and DWConv to design the C2f-GhostD module to replace the C2f module, reducing the computational cost of the model. Then, PConv is integrated into the Detect module, resulting in the POne-Detect module, which is applied to the detection network to streamline its structure. Finally, the SimAM attention mechanism is added to the neck network to improve information capture ability. The experimental results show that in the PCB dataset, compared with YOLOv8n, the proposed algorithm reduces the number of parameters by 78.7%, reduces the model size by 73.7%, and improves the mAP0.5 to 98.6%, meeting the hardware deployment requirements of the model.

**Keywords:** PCB; lightweight; defect detection; small object detection; YOLOv8n

## 0 引言

印刷电路板(printed circuit board, PCB)作为电子信息制造业重要电子元件之一,在计算机、通信等行业应用广泛,几乎所有电子设备都需要使用 PCB。随着第四次工业革命到来,对 PCB 制造工业提出集成化、高质量的要求<sup>[1]</sup>。PCB 缺陷检测对提高 PCB 产品质量具有重要意义,而高精度、轻量化对于 PCB 缺陷检测实际应用十分关键。

早期的 PCB 缺陷检测依靠工人目视检测<sup>[2]</sup>,之后逐步发展到电器检测技术、自动光学检测技术<sup>[3]</sup>等利用机器设

备的检测技术,虽然检测效率得到提升,但仍需投入一定人工成本。当前,随着深度学习的发展,深度学习技术广泛应用于 PCB 缺陷检测<sup>[4]</sup>。

目前,基于深度学习的 PCB 缺陷检测主要分为两阶段算法与单阶段算法。其中,两阶段算法以 Faster RCNN 算法为代表。陈仁祥等<sup>[5]</sup>使用多种注意力机制改进 Faster RCNN,进一步提升检测精度。单阶段算法主要包括 SSD 系列算法与 YOLO 系列算法<sup>[6-8]</sup>。Shi 等<sup>[9]</sup>基于 SSD 提出一种针对微小缺陷检测的算法 SSdT,使 PCB 缺陷检测精度有所提升。季堂煜等<sup>[10]</sup>提出 PPLCFaster-YOLOv5 模

收稿日期:2023-11-29

<sup>\*</sup> 基金项目:高层次创新人才培养专项(B12402005)、教育部高等教育司产学合作协同育人项目(202101038016)、四川轻化工大学人才引进项目(2021RC16)资助

型,通过增强特征表达能力和缺陷定位能力,提升检测性能。Lan等<sup>[11]</sup>基于YOLOv8,增加跨尺度融合模块,融合骨干网络相邻特征,增强特征融合能力,进而提升缺陷检测性能。上述算法的缺陷检测精度均有提升,但仍存在模型参数多、体积大等问题,对于PCB缺陷检测模型的轻量化仍有较大改进空间。

为解决PCB缺陷检测模型不能兼顾检测精度和模型体积的问题,本文提出一种基于轻量级YOLOv8n网络的PCB缺陷检测算法,通过删除大目标检测层,新增小目标检测层,调整主干网络与颈部网络结构;使用C2f-GhostD模块与POne-Detect模块;添加SimAM注意力机制,提升缺陷检测精度,降低计算量、参数量,减小模型体积。

## 1 YOLOv8n 算法

YOLOv8是ultralytics公司于2023年发布的YOLO系列最新算法,具有YOLOv8n、YOLOv8s、YOLOv8m等不同尺度的版本。本文选择YOLOv8n进行改进。

YOLOv8n采用C2f模块替换YOLOv5的C3模块,主干网络使用CSP结构<sup>[12]</sup>,将特征提取分为两部分,分别进行卷积和连接,末尾采用SPPF模块提高模型计算速度<sup>[13]</sup>。颈部网络采用PAN-FPN<sup>[14]</sup>网络结构进行特征多尺度融合。检测网络采取Anchor-Free<sup>[15]</sup>检测方式, Detect模块使用解耦头结构<sup>[16]</sup>,损失函数使用CIoU<sup>[17]</sup>。YOLOv8n网络结构如图1所示。

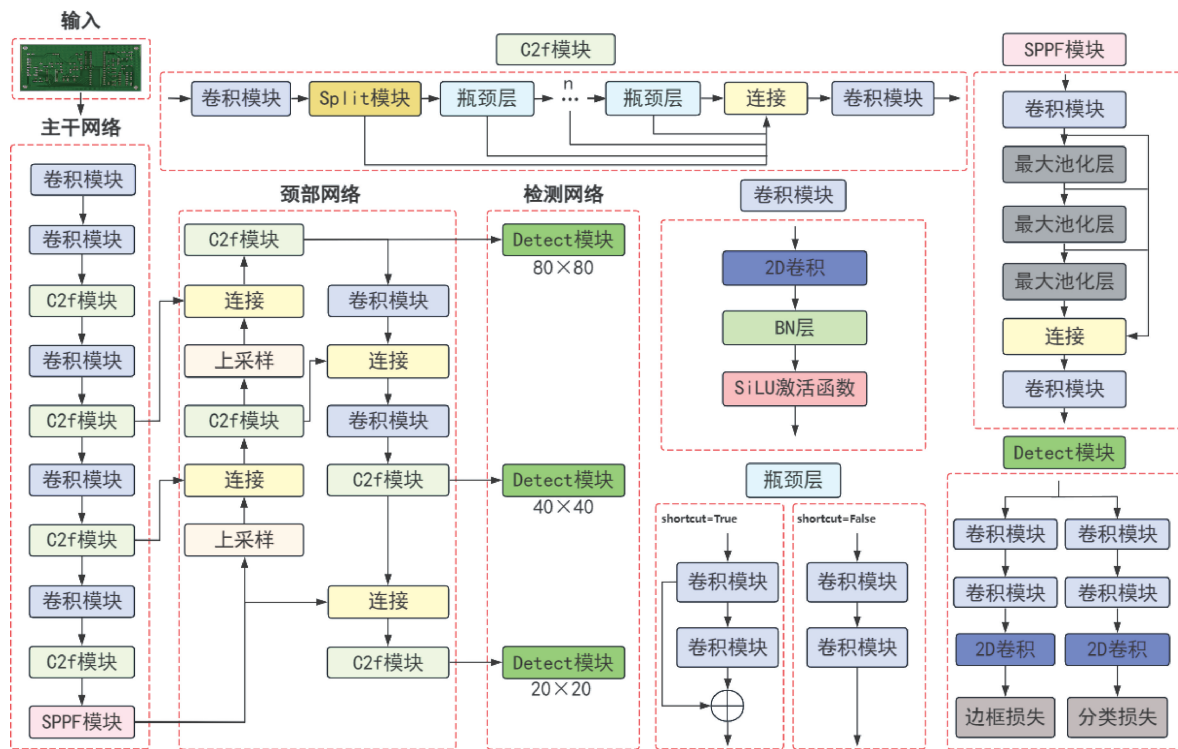


图1 YOLOv8n网络结构

## 2 改进YOLOv8n网络

针对PCB缺陷多数为小目标缺陷的特点,删除大目标检测层以及主干网络末尾的卷积模块与C2f模块,新增小目标检测层,并调整对应网络结构,使模型轻量化,提升小目标缺陷检测能力;在颈部网络使用C2f-GhostD模块,进一步降低计算量与参数量;在检测网络使用POne-Detect模块,减少检测网络复杂度,在颈部网络添加SimAM注意力机制,提高缺陷检测精度。改进的YOLOv8n网络结构如图2所示。

### 2.1 调整网络结构

针对PCB缺陷大多数属于小目标缺陷的特点,提出一种更适合PCB缺陷检测的网络结构。检测网络的 $20 \times 20$

大目标检测层感受野大小为 $32 \times 32$ ,难以获取宽高值小于 $32 \times 32$ 的小目标信息,对小目标缺陷定位能力较弱。同时,在特征提取阶段,PCB图像经过数次下采样后,深度特征图对于小目标缺陷特征信息保存能力较差,而主干网络末尾进行特征提取的卷积模块与C2f模块,虽然包含丰富的深层特征信息,但同时也带来庞大的参数量,对PCB小目标缺陷检测效率较低。因此,删除 $20 \times 20$ 大目标检测层与主干网络末尾进行特征提取的卷积模块与C2f模块可以减少参数量,减小模型体积。而浅层特征图会保留更多小目标信息,新增 $160 \times 160$ 小目标检测层可以捕捉更多图像浅层特征,提升感受野对小目标的感知能力。此外,在特征融合阶段,将浅层特征信息与深层特征信息结合,充分利用提取浅层特征与特征融合的优势,提高小目标缺陷检

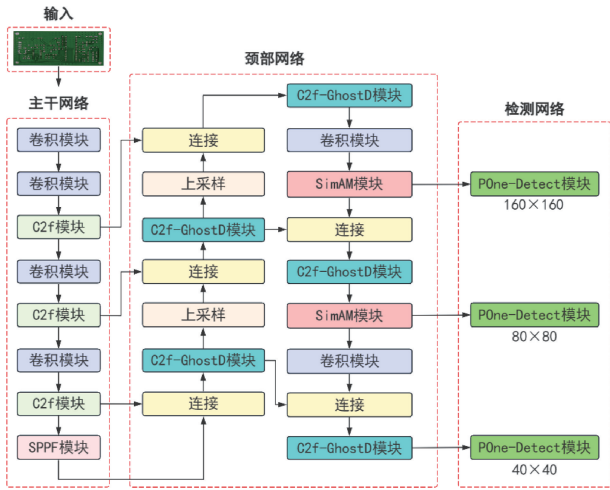


图 2 改进的 YOLOv8n 网络结构

测能力。

通过调整 YOLOv8n 网络结构,减少冗余深层特征信息,进而减少参数量,减小模型体积,并获取更多浅层特征信息,提升小目标缺陷检测性能,更适用于 PCB 缺陷检测。

### 2.2 C2f-GhostD 模块

华为诺亚方舟实验室<sup>[18]</sup>于 2020 年提出 GhostNet 网络结构,仅通过极小的代价获取更多特征图。GhostNet 的核心 GhostConv 模块如图 3 所示。




图 3 GhostConv 模块

设输入数据大小  $X = c \times h \times w$ ,  $c$  表示输入通道数,  $h$  和  $w$  表示输入特征图的高和宽,输出数据大小  $Y = c' \times h' \times w'$ ,  $n$  表示输出通道数,  $h'$  和  $w'$  表示输出特征图的高和宽,卷积核大小为  $k \times k$ , 常规卷积计算量  $C_1$  为:

$$C_1 = n \times h' \times w' \times c \times k \times k \quad (1)$$

设线性运算次数为  $s$ , 线性运算卷积核大小为  $d \times d$ , GhostConv 计算量  $C_g$  为:

$$C_g = \frac{n}{s} \times h' \times w' \times c \times k \times k + (s - 1) \times \frac{n}{s} \times h' \times w' \times d \times d \quad (2)$$

常规卷积与 GhostConv 计算量之比  $r_s$  为:

$$r_s = \frac{c \times k \times k}{\frac{1}{s} \times c \times k \times k + \frac{s-1}{s} \times d \times d} \approx \frac{s \times c}{s + c - 1} \approx s \quad (3)$$

式中:  $k$  与  $d$  相似, 而  $s \ll c$ , 结果近似等于  $s$ , 因此 GhostConv 相较于常规卷积更轻量化。

Sandler 等<sup>[19]</sup>在 2018 年提出 MobileNetV2 网络结构,其核心为深度可分离卷积 (depth-wise convolution, DWConv)。DWConv 每个卷积核深度都为 1,相较于常规卷积,其计算成本更低,DWConv 模块如图 4 所示。




图 4 DWConv 模块

基于 GhostConv 模块与 DWConv 模块,结合残差连接思想,组成 GhostD 瓶颈层。其中, GhostConv 模块与 DWConv 模块可以减少模型计算量与参数量,同时结合另一通道的 DWConv 模块与  $1 \times 1$  卷积模块获得的特征图,在保持网络轻量化的前提下,提高特征信息提取能力, GhostD 瓶颈层结构如图 5 所示。

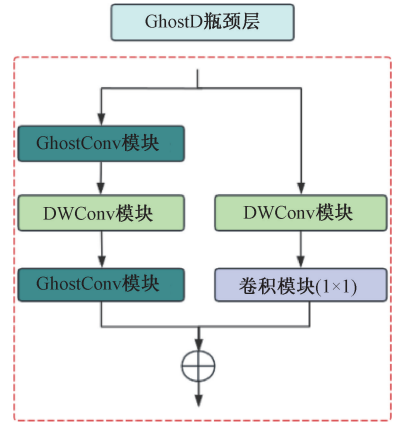


图 5 GhostD 瓶颈层结构

将 C2f 模块的瓶颈层替换为 GhostD 瓶颈层组成 C2f-GhostD 模块,使网络获得丰富的特征信息,并减少计算成本,从而提高检测精度并降低参数量与计算量,C2f-GhostD 模块结构如图 6 所示。

### 2.3 P0ne-Detect 模块

Chen 等<sup>[20]</sup>于 2023 年提出一种轻量级卷积技术,部分卷积 (partial convolution, PConv), PConv 通过减少冗余计算和内存访问,有效减少网络计算负担,提高特征提取效率,并且不会改变输入输出通道尺度。

相较于常规卷积, PConv 仅对部分输入通道进行空间特征提取,而保持其余输入通道不变,进行恒等映射,再将两部分通道进行拼接, PConv 模块如图 7 所示。

当输入输出通道数、图像尺寸均相同时,设  $c$  表示输入通道数,  $h$  和  $w$  表示输入特征图的高和宽,卷积核大小为  $k \times k$ , 常规卷积计算量  $C_2$  为:

$$C_2 = h \times w \times k^2 \times c^2 \quad (4)$$

设  $c_p$  表示进行部分卷积的输入输出通道数,则 PConv

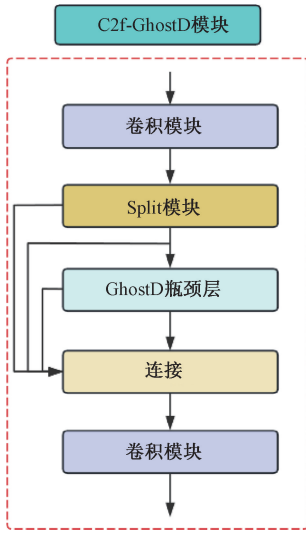


图6 C2f-GhostD模块结构

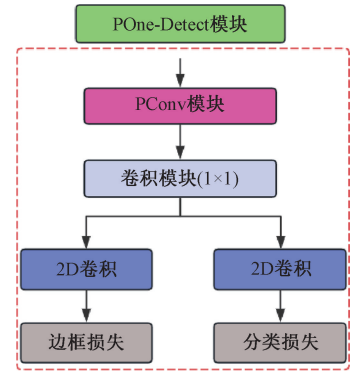


图8 POne-Detect模块结构




图7 PConv模块

计算量  $C_p$  为:

$$C_p = h \times w \times k^2 \times c_p^2 \quad (5)$$

常规卷积内存访问量  $V$  为:

$$V = h \times w \times 2c + k^2 + c^2 \approx h \times w \times 2c \quad (6)$$

PConv内存访问量  $V_p$  为:

$$V_p = h \times w \times 2c_p + k^2 + c_p^2 \approx h \times w \times 2c_p \quad (7)$$

因为  $c_p < c$ , PConv 相较于常规卷积, 具有更低的计算量与内存访问量。

在YOLOv8n检测网络的Detect模块中, 总共使用4个 $3 \times 3$ 卷积模块以及2个2D卷积, 虽然进一步提高了深层特征信息捕获能力, 但同时也使网络结构更加复杂。

根据上述特点, 结合权值共享思想, 将4个 $3 \times 3$ 卷积模块简化为1个PConv模块与 $1 \times 1$ 卷积模块, 组成POne-Detect模块。合并Detect模块前半部分模块以及使用PConv模块, 可以显著减少网络复杂度, 同时 $1 \times 1$ 卷积模块可以充分利用所有通道信息进而提高特征捕获能力并且保持精简的网络结构。虽然删除检测网络中多个 $3 \times 3$ 卷积模块对深层特征捕获能力有一定影响, 但由于PCB缺陷较小, 深层特征作用有限, 对检测网络捕获特征信息的影响较小。POne-Detect模块可以有效降低网络复杂度, 从而减少计算量与参数量, POne-Detect模块结构如图8所示。

## 2.4 SimAM注意力机制

Yang等<sup>[21]</sup>在2021年提出SimAM注意力机制。该注意力机制来源于视觉神经科学空间抑制理论, 活跃神经元会抑制周边神经元的活动, 应赋予活跃神经元更高的优先级。优先级使用能量函数  $e_i(\omega_i, b_i, y, x_i)$  表示:

$$e_i(\omega_i, b_i, y, x_i) = (y_i - \hat{t})^2 + \frac{1}{M-1} \sum_{i=1}^{M-1} (y_o - \hat{x}_i)^2 \quad (8)$$

在式(8)中  $\hat{t} = \omega_i t + b_i$  与  $\hat{x}_i = \omega_i x_i + b_i$  分别表示目标神经元  $t$  和其他神经元  $x_i$  的线性变换,  $i$  表示空间维度索引,  $M$  表示神经元个数,  $\omega_i$  与  $b_i$  分别表示权重与偏差。

将标量  $y_i$  与  $y_o$  分别用  $-1$  和  $1$  表示, 并引入正则项  $\lambda$ , 则能量函数表示为:

$$e_i(\omega_i, b_i, y, x_i) = \frac{1}{M-1} \sum_{i=1}^{M-1} (-1 - (\omega_i x_i + b_i))^2 + (1 - (\omega_i t + b_i))^2 + \lambda \omega_i^2 \quad (9)$$

由式(9)解得权重  $\omega_i$  与偏差  $b_i$  为:

$$\omega_i = -\frac{2(t - \mu_i)}{(t - \mu_i)^2 + 2\sigma_i^2 + 2\lambda} \quad (10)$$

$$b_i = -\frac{1}{2}(t + \mu_i)\omega_i \quad (11)$$

式中:  $\mu_i$  与  $\sigma_i$  分别表示该通道中除  $t$  以外所有神经元的均值和方差。

最终得到最小能量  $e_i^*$  公式为:

$$e_i^* = \frac{4(\hat{\sigma}^2 + \lambda)}{(t - \mu^2) + 2\hat{\sigma}^2 + 2\lambda} \quad (12)$$

式(12)表明, 最小能量  $e_i^*$  越低, 该神经元与周边神经元区别越大, 重要性越高。

基于注意力机制定义,  $X$  表示输入特征,  $E$  表示最小能量, 使用Sigmoid函数过滤  $E$  中过大的值, 则SimAM如式(13)所示, SimAM注意力机制如图9所示。

$$\tilde{X} = \text{Sigmoid}\left(\frac{1}{E}\right) \odot X \quad (13)$$

针对PCB图像背景复杂、噪声干扰较强的特点, 以及避免模型轻量化后检测精度下降, 在颈部网络增加






图 9 SimAM 注意力机制

SimAM 注意力机制并连接到  $160 \times 160$  与  $80 \times 80$  两个对微小目标信息捕获能力较强的检测层,结合空间位置特征与通道信息,重点关注包含重要信息的神经元,增强对小目标缺陷特征的定位能力。SimAM 注意力机制不会增加额外参数量,保证模型轻量化的同时,增强模型对小目标缺陷信息捕获能力。

### 3 实验分析

#### 3.1 实验环境

实验环境配置如表 1 所示,实验使用 COCO 数据集权重作为初始权重,输入图片大小为  $640 \times 640$ ,初始学习率为 0.01,优化器选择 SGD,训练轮次 epochs 为 300 次,训练批次 batch 为 32,数据集按照 6 : 2 : 2 划分训练集、验证集、测试集。

表 1 实验环境配置

名称	参数
操作系统	Ubuntu18.04
CPU	Intel(R) Xeon(R) Platinum 8255C CPU@2.50 GHz
GPU	NVIDIA GeForce RTX 3080, 10 GB
编程语言	Python3.9.18
框架	Pytorch2.0.1+CUDA11.7

#### 3.2 数据集

实验数据集来源于北京大学智能机器人开放实验室发布的 PCB 数据集,数据集包含 6 类缺陷: 穿孔、余铜、短路、鼠咬、开路和毛刺,共计 693 张图片,由于样本图片与缺

陷数量较少,本文通过调整亮度、旋转等数据增强方式将数据集扩增到 2 772 张图片,PCB 数据集图片数量如图 10 所示。




图 10 PCB 数据集图片数量

#### 3.3 评价指标

实验采用计算量、参数量、模型体积、平均精度均值 (mean average precision, mAP) 和 F1 分值作为评价指标。

设  $TP$ 、 $FP$  表示预测为真的正负样本,  $FN$  表示预测为非真的正样本,可得精确率 (precision,  $P$ ) 与召回率 (recall,  $R$ ), PR 曲线所围面积为平均精度 (average precision, AP)。设  $N$  表示类别总数,  $AP_i$  表示各类别平均精度,最终可得 mAP。

$$P = \frac{TP}{TP + FP} \quad (14)$$

$$R = \frac{TP}{TP + FN} \quad (15)$$

$$AP = \int_0^1 P(R) dR \quad (16)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (17)$$

F1 分值表示精准率  $P$  与召回率  $R$  的谐波平均值,如式(18)所示。

$$F1 = 2 \frac{PR}{P + R} \quad (18)$$

#### 3.4 消融实验

为验证每个改进模块有效性,本实验采取逐步增添改进模块的方法进行消融实验,选择阈值设为 0.5 时的平均精度均值 mAP0.5、参数量和模型体积作为评判标准,消融实验结果如表 2 所示。

表 2 消融实验结果

YOLOv8n	调整网络	C2f-GhostD 模块	POne-Detect 模块	SimAM 注意力机制	参数量/ M	模型体积/ MB	mAP0.5/ %
✓					3.01	6.24	98.4
✓	✓				1.12	2.62	98.5
✓	✓	✓			0.93	2.23	98.5
✓	✓	✓	✓		0.64	1.64	98.3
✓	✓	✓	✓	✓	0.64	1.64	98.6

从表2可知调整网络结构后参数量下降62.8%,模型体积减小58.0%,mAP0.5提高0.1%,验证了调整后的网络结构更适合PCB缺陷检测,实现模型轻量化与检测精度的双重优化。在此基础上,将颈部网络C2f模块替换为C2f-GhostD模块,减少计算成本的同时,提升特征提取效率,使模型在调整后网络基础上,模型参数量减少至0.93M,模型体积减小至2.23MB。然后,将检测网络的Detect检测模块替换为POne-Detect模块,使检测网络更加精简,显著降低参数量,从而极大减少网络计算负担,模型参数量减少至0.64M,模型体积减小至1.64MB。最后,在颈部网络添加SimAM注意力机制并连接到中小检

测层,保持模型轻量化的同时,关注通道与空间信息,提高缺陷特征信息捕获能力,mAP0.5达到98.6%。

本文算法相较于YOLOv8n,参数量下降78.7%,模型体积减小73.7%,仅有1.64MB,同时mAP0.5提升至98.6%,使模型轻量化并且提高检测精度,有利于PCB缺陷检测模型的硬件部署。

### 3.5 对比实验

为充分验证本文算法的优越性,将本文算法与文献[5]、SSD、YOLOv3-tiny、YOLOv5n、文献[10]、YOLOX-tiny、YOLOv7-tiny以及YOLOv8n进行对比实验。对比实验结果如表3所示。

表3 对比实验结果

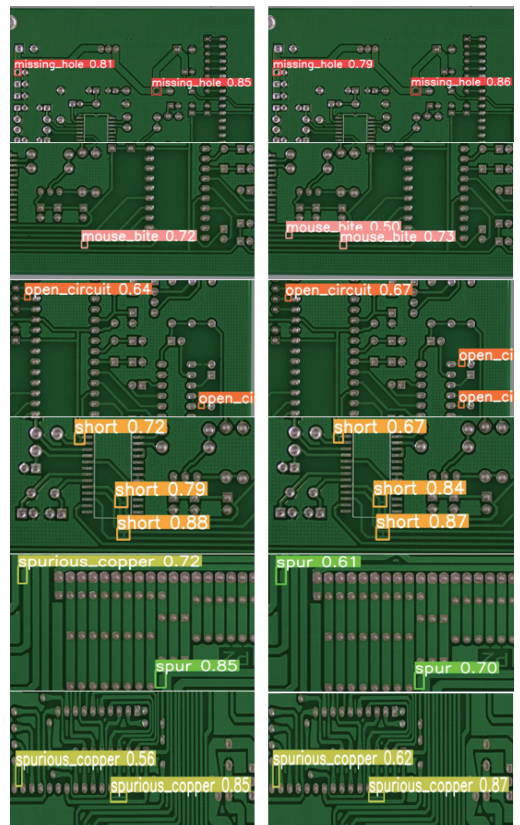
算法	计算量/G	参数量/M	模型体积/MB	mAP0.5/%	F1分值/%
文献[5]	—	—	—	92.9	—
SSD	61.3	24.28	93.20	97.7	36.9
YOLOv3-tiny	12.9	8.68	17.46	97.0	95.9
YOLOv5n	4.2	1.77	3.92	96.1	95.8
文献[10]	6.7	—	—	97.4	95.9
YOLOX-tiny	155.7	54.15	34.40	98.2	97.4
YOLOv7-tiny	13.1	6.20	12.31	97.5	96.6
YOLOv8n	8.1	3.01	6.24	98.4	97.6
本文	4.3	0.64	1.64	98.6	97.6

从表3可知,文献[5]在Faster RCNN基础上,结合多种注意力机制,mAP0.5提升至92.9%,但仍然有提升空间。SSD因其算法特点,对小目标检测能力较弱,且模型体积过大。YOLOv3-tiny、文献[10]、YOLOX-tiny和YOLOv7-tiny,上述4种算法虽然检测精度较高,但模型轻量化不足。YOLOv5n相较其他算法,虽然模型体积具有优势,计算量仅有4.2G,但mAP0.5仅有96.1%、F1分值仅有95.8%,检测精度相对较低。本文算法的参数量仅有0.64M、模型体积仅有1.64MB、mAP0.5达到98.6%、F1分值达到97.6%,在上述各类算法对比中表现均是最优,同时计算量仅有4.3G,在计算量对比中也表现突出。本文算法的优势在于显著降低计算量、参数量和模型体积后,仍然能够保持较高的检测精度。

### 3.6 实验效果展示

为直观展示本文算法对PCB包含缺孔(missing\_hole)、余铜(spurious\_copper)、短路(short)、鼠咬(mouse\_bite)、开路(open\_circuit)和毛刺(spur),共6种缺陷的检测性能,将YOLOv8n与本文算法进行PCB缺陷检测,YOLOv8n模型检测结果如图11(a)所示,本文模型检测结果如图11(b)所示。

由图11可知,YOLOv8n漏检鼠咬与开路缺陷,误检毛刺为余铜缺陷,本文算法均检测正确,两种算法对其余缺陷检测能力相近,而本文算法经过轻量化之后仍具有较高检测性能。



(a) YOLOv8n模型检测结果

(b) 本文模型检测结果

图11 检测结果对比

## 4 结 论

为解决 PCB 缺陷检测无法兼顾检测精度与模型体积的问题,提出一种基于轻量级 YOLOv8n 网络的 PCB 缺陷检测算法。通过删除大目标检测层,新增小目标检测层并调整网络结构,显著减小模型体积;将颈部网络 C2f 模块替换为 C2f-GhostD 模块,提升特征提取效率;在检测网络使用 POne-Detect 模块,提升网络精简度;添加 SimAM 注意力机制,提升检测精度。本文算法具有极低的参数量、计算量与较小的模型体积,并保持较高检测精度。后续将继续提升模型检测能力,并尝试部署模型在硬件设备上。

## 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] LING Q, ISA N A M, ASAARI M S M. Precise detection for dense PCB components based on modified YOLOv8 [J]. IEEE Access, 2023, 11, 116545-116560.
- [3] ZHENG J, SUN X, ZHOU H, et al. Printed circuit boards defect detection method based on improved fully convolutional networks[J]. IEEE Access, 2022, 10: 109908-109918.
- [4] 吴一全, 赵朗月, 苑玉彬, 等. 基于机器视觉的 PCB 缺陷检测算法研究现状及展望[J]. 仪器仪表学报, 2022, 43(8): 1-17.
- [5] 陈仁祥, 詹赞, 胡小林, 等. 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 167-174.
- [6] CHEN W, HUANG Z, MU Q, et al. PCB defect detection method based on Transformer-YOLO [J]. IEEE Access, 2022, 10: 129480-129489.
- [7] 时造雄, 茅正冲. 基于改进 YOLOv5 的 PCB 缺陷检测方法[J]. 电子测量技术, 2023, 46(14): 123-130.
- [8] 虞冰, 黄丽雯, 唐鑫, 等. 基于 YOLOX-WSC 的 PCB 缺陷检测算法研究[J]. 计算机工程与应用, 2023, 59(10): 236-243.
- [9] SHI W, LU Z, WU W, et al. Single-shot detector with enriched semantics for PCB tiny defect detection[J]. The Journal of Engineering, 2020, 2020(13): 366-372.
- [10] 季堂煜, 赵倩, 赵琰, 等. 基于 PPLCFaster-YOLOv5 的 PCB 表面缺陷快检模型[J]. 电子测量技术, 2023, 46(11): 115-122.
- [11] LAN H, ZHU H, LUO R, et al. PCB defect detection algorithm of improved YOLOv8 [C]. 2023 8th International Conference on Image, Vision and Computing(ICIVC), 2023: 178-183.
- [12] 刘瑞锦, 何章鸣. 基于 YOLOv8 的卫星遥感图像快速目标检测方法[J]. 空间控制技术与应用, 2023, 49(5): 89-97.
- [13] ZHU Y, DONG E, TONG J, et al. Deep neural network based object detection algorithm with optimized detection head for small targets [C]. 2023 IEEE International Conference on Mechatronics and Automation(ICMA), 2023: 2378-2382.
- [14] HUANG Z, LI L, KRIZEK G C, et al. Research on traffic sign detection based on improved YOLOv8 [J]. Journal of Computer and Communications, 2023, 11(7): 226-232.
- [15] TALAAT F M, ZAINELDIN H. An improved fire detection approach based on YOLO-v8 for smart cities [J]. Neural Computing and Applications, 2023, 35(28): 20939-20954.
- [16] 王晨灿, 李明. 基于 YOLOv8 的火灾烟雾检测算法研究 [J]. 北京联合大学学报, 2023, 37(5): 69-77.
- [17] ZHENG Z, WANG P, LIU W, et al. Distance-IoU loss: Faster and better learning for bounding box regression [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(7): 12993-13000.
- [18] HAN 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(CVPR), 2020: 1580-1589.
- [19] SANDLER M, HOWARDA, ZHU M, et al. MobileNetV2: Inverted residuals and linear bottlenecks [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2018: 4510-4520.
- [20] CHEN 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 (CVPR), 2023: 12021-12031.
- [21] YANG L, ZHANG R Y, LI L D, et al. SimAM: A simple, parameter-free attention module for convolutional neural networks [C]. International Conference on Machine Learning, 2021: 11863-11874.

## 作者简介

李忠科, 硕士研究生。主要研究方向为目标检测。

E-mail: 3501192603@qq.com

刘小芳(通信作者), 博士, 教授。主要研究方向为智能信息处理、模式识别和数据挖掘等。

E-mail: lxf1969@163.com