

DOI:10.19651/j.cnki.emt.2417501

改进 YOLOv8n 的轻量化 PCB 缺陷检测算法^{*}

刘 辉 刘 旭 李 校 林 曾 凡 琪 王 鹏 江

(重庆邮电大学通信与信息工程学院 重庆 400065)

摘要: 针对现阶段 PCB 缺陷检测算法在模型参数量和检测精度无法同时兼顾的问题,本文提出改进 YOLOv8n 的轻量化 PCB 检测算法 ST-YOLO。首先,采用轻量化主干网络 StarNet 替换 YOLOv8n 的主干网络,调整网络结构。删除大目标检测层,新增小目标检测层。其次,颈部网络中将 C2f 模块与 Star Block 和 CA 注意力机制结合设计出 C2f-Star-CA 模块,能够更好的融合局部和全局的上下文信息。最后,设计轻量化检测头,通过使用共享卷积减少模型的参数量。实验结果表明:与 YOLOv8n 相比,本文算法模型参数量减少了 45.5%,计算量减少了 56.8%,mAP@0.5 提升了 0.2%,为满足移动端部署的需要提供了新的可能性。

关键词: PCB 检测;轻量化;YOLOv8n;深度学习;目标检测

中图分类号: TN911.73;TN41 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Improved lightweight PCB defect detection algorithm for YOLOv8n

Liu Hui Liu Xu Li Xiaolin Zeng Fanqi Wang Pengjiang

(School of Engineering of Communication and Information, Chongqing University of Posts and Telecommunication,
Chongqing 400065, China)

Abstract: In view of the problem that the current PCB defect detection algorithm cannot simultaneously take into account the number of model parameters and detection accuracy, this paper proposes an improved lightweight PCB detection algorithm ST-YOLO based on YOLOv8n. First, the backbone network of YOLOv8n was replaced by the lightweight backbone network StarNet to adjust the network structure. Delete the large target detection layer and add the small target detection layer. Secondly, C2f module is combined with Star Block and CA attention mechanism to design C2f-Star-CA module, which can better integrate local and global context information. Finally, lightweight detection headers are designed to reduce the number of parameters in the model by using shared convolution. The experimental results show that compared with YOLOv8n, the number of model parameters is reduced by 45.5%, the calculation amount is reduced by 56.8%, and the mAP@0.5 is increased by 0.2%. It provides new possibilities to meet the needs of mobile deployment.

Keywords: PCB detection;light weight;YOLOv8n;deep learning;object detection

0 引言

印刷电路板(printed circuit board,PCB)是电子设备当中用于支撑和连接电子元件的重要组件,几乎所有的电子产品都用到 PCB。由于其制作工艺繁琐,使得在制造过程中容易出现各种缺陷。随着深度学习的发展,使用神经网络算法并把其应用到工业领域越来越引起人们的关注。为了节省资源,使神经网络算法可以部署到嵌入式设备上,在不丢失检测精度的情况下对于模型的轻量化显得至关重要。

早期的 PCB 缺陷检测采用的是人工检测方法^[1],但随

着 PCB 制作的工艺越来越复杂,生产量逐渐加大,人工检测方法耗费大量的人力。之后逐步发展为电气检测,自动光学检测。虽然效果有所提升,但是由于系统复杂也需要投入一定的成本。随着时间推移,机器学习算法也被应用到 PCB 检测算法当中^[2],但与之相比的卷积神经网络(convolutional neural networks,CNN)在目标检测,图像分类上具有更好的性能。

现阶段,基于卷积神经网络的 PCB 检测算法分为两种,基于两阶段的 Fast-RCNN^[3]算法和基于单阶段的 SSD^[4]和 YOLO^[5-6]算法。与 SSD 相比较,YOLO 系列的

收稿日期:2024-12-01

^{*} 基金项目:四川省科技计划项目(2023YFQ0019)资助

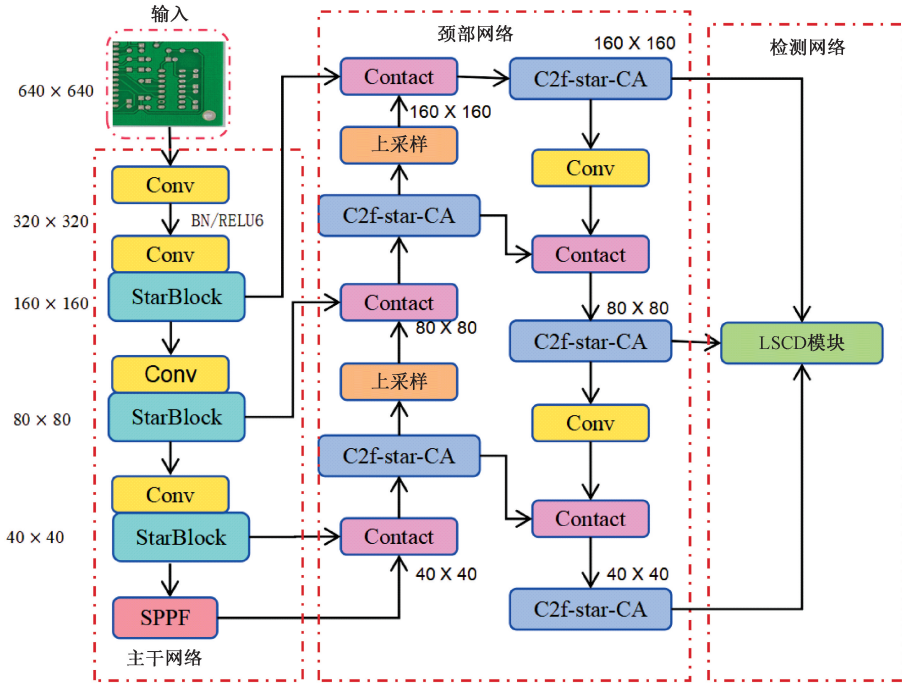


图 2 ST-YOLO 网络结构
Fig. 2 ST-YOLO network structure

2.1 调整网络结构

由于 PCB 缺陷目标都属于小目标范畴,所以调整检测网络的输入部分,提出一种更适合 PCB 小目标检测的网络结构。在 YOLOv8n 检测网络中,输入特征图大小为 20×20 的大目标检测层用于检测大小在 32×32 以上的目标,对小目标的定位效果不佳。同时在 PCB 图像在经过主干网络多次下采样的过程中,对小目标的特征信息保存能力较差。

虽然主干网络末尾的卷积和 C2f 模块含有深层的特征信息,但同时也使得网络参数量较为庞大。所以,删除主干网络中尾部的卷积和 C2f 模块和 20×20 大目标检测层,新增 160×160 的表目标检测层。保留 PCB 图像浅层的特征信息,更有利于提升对 PCB 缺陷这种小目标的感知能力。通过对网络结构的调整,减少冗余的深层特征提取,从而减少网络的参数量和体积,使之成为更适合感知 PCB 缺陷特征的网络。

2.2 StarNet 改进主干网络

Ma 等^[11]在 2024 年提出了一种新的运算名称“星运算”(star operation),其本质是通过元素乘法融合不同子空间特征的操作。且证明了星运算具有将输入映射到超高维,非线性特征空间的能力。并且提出了 StarNet 主干网络结构。YoloV8n 的主干网络采用的是类似 CSPDarknet53^[12]的网络结构,这是一个相对较深的网络。尽管这个网络在多种任务重表现出色,但在资源受限的环境中仍然存在消耗计算资源,内存占用较大,推理速度较

慢等问题。针对以上问题,本文采用更为轻量级的 StarNet 网络作为主干网络。

1) 星运算

单层神经网络中,星运算通常写为 $(W_1^T + B_1) \times (W_2^T + B_2)$,表示通过主元素乘法融合两个线性变换特征。写成矩阵形式为 $(W_1^T X) \times (W_2^T X)$,其中 $W = [W, B]^T, X = [X, 1]^T$ 。定义 $\omega_1, \omega_2, X \in R^{(d+1) \times 1}$,其中 d 是输入通道数,它很容易扩展到多个输出通道 $W_1, W_2 \in R^{(d+1) \times (d+1)}$ 和处理多个特征元素。可将星运算重写为:

$$\omega_1^T x \times \omega_2^T x = \left(\sum_{i=1}^{d+1} \omega_{i1} x^i \right) \times \left(\sum_{j=1}^{d+1} \omega_{j2} x^j \right) = \sum_{i=1}^{d+1} \sum_{j=1}^{d+1} \omega_{i1} \omega_{j2} x^i x^j = \alpha_{(1,1)} x^1 x^1 + \dots + \alpha_{(4,5)} x^4 x^5 + \dots + \alpha_{(d+1,d+1)} x^{d+1} x^{d+1},$$

$$\alpha_{(i,j)} = \begin{cases} \omega_1^i \omega_2^j, & i = j \\ \omega_1^i \omega_2^j + \omega_1^j \omega_2^i, & i \neq j \end{cases} \quad (1)$$

其中, i, j 表示通道索引, α 表示每个项的系数。由式(1)可以将星操扩展为一个由 $\frac{(d+2)(d+1)}{2}$ 个不同项组成的组合,发现除了 $\alpha_{(d+1,d+1)} x^{d+1} x^{d+1}$ 项外,每个项都与 x 表现出非线性关联,表明他们是独立且隐式的维度。因此,可以发现使用计算效率高的星运算在 d 维空间中执行计算,却能在 $\frac{(d+2)(d+1)}{2} \approx \left(\frac{d}{\sqrt{2}}\right)^2$ 隐式维特征空间中实现表示,显著放大了特征维度,而无需在单个层中增加仍和计算开销。

2) StarNet

StarNet 框架如图 3(a)所示。StarNet 由一个 4 阶层次结构构建而成,利用卷积层进行下采样和 Star Block 模块,进行特征提取,如图 3(b)所示。为了满足效率要求,用 Batch Normalization^[13] 替换 Layer Normalization^[14],并将其放置在深度卷积之后。受 MobileNetXt^[15] 的启发,在每个块的末尾加入了深度卷积 DWConv。通道扩展因子始终设置为 4,在每个阶段网络宽度翻倍。在 Star Block 模块中,GELU 激活被替换为 ReLU6,遵循 MobileNetv2 的设计。

其通过星运算实现了高效的特征表示,无需复杂的网络设计和额外的计算开销。其独特的能力在于能够在低维空间中执行计算,但隐式地考虑了高维的特征。其实现高维和非线性特征空间的映射,而无需增加计算复杂度。与传统的内核技巧类似,星运算能够在低维输入中隐式获得高维特征。在紧凑的网络结构和较低的能耗下展示了不错的性能和低延迟。这使得 StarNet 可以作为 YOLO 系列网络的主干,提供高效的计算和更好的特征表示,有助于在资源受限的环境中实现更高的检测性能。

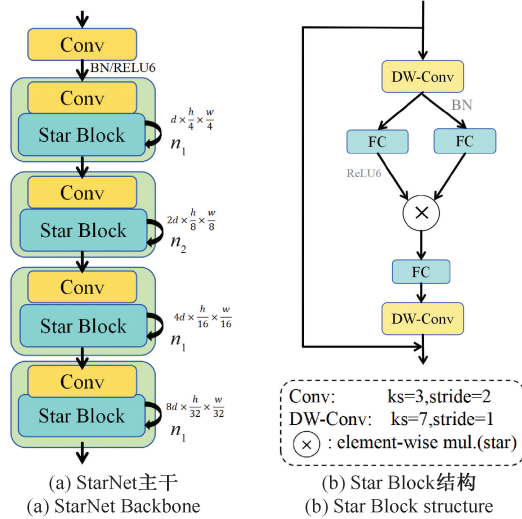


图 3 StarNet 网络结构

Fig. 3 StarNet network structure

2.3 设计 C2f-Star-CA 模块

由元素乘法隐式实现高维特征映射,不需要堆叠网络深度的特点。为了更进一步减小模型的体积,提高 PCB 缺陷检测的实时性,提高模型的表达能力。本文采用 2.2 节中提到的 Star Block 改进原始 C2f 中的 Bottleneck 模块。其首先经过深度可分离卷积和批归一化层(BN),其次分别对两个全连接层的结果进行星运算,因其运算结果可以表征高维特征,故在局部和全局特征提取方面有着不错的效果,相较于原始的 Bottleneck 模块更加简洁。又同时考虑到缺陷图像目标较小,背景特征相似,且在经过若干过星

运算处理之后带来的精度下降问题。在特征融合之后添加 CA 注意力机制,在增强中心特征的同时,掌握远距离像素之间的上下文相互依赖关系。计出 SCBottleneck 模块如图 4 所示,替换掉原始 C2f 中的 Bottleneck。提高复杂场景下的 PCB 缺陷检测效果。改进后的 C2f-Star-CA 模块结构如图 5 所示。




图 4 C2f-Star-CA 网络结构

Fig. 4 C2f-Star-CA network structure




图 5 SCBottleneck 网络结构

Fig. 5 SCBottleneck network structure

1) Star Block 模块

Star Block 的结构如 2.2 节中图 3(b)所示。其中深度可分离卷积(depth-wise convlution, DWConv)是 Sandler 等^[16] 在 2018 年提出,其每个卷积核的深度为 1,每个输出通道仅由一个卷积处理。与传统卷积相比减少了模型的计算量。DWConv 模块如图 6 所示。

相较于传统的特征融合方式,元素乘法可以捕捉特征之间的交互作用,这种操作可以产生新的特征,这些新特征能够表达原始特征之间的非线性关系。与拼接(contact)不同,元素乘法不会增加特征难度。这意味着在保持特征维度不变的情况下,可以更有效地利用参数,减少模型的复杂性。




图 6 DWConv 结构

Fig. 6 DWConv structure

2)CA 注意力机制

Hou 等^[17]在 2021 年提出坐标注意力机制(coordinate attention,CA)。一个坐标注意力可以被视为一个计算单元,它可以接受任何中间特征张量 $\mathbf{X}=[x_1, x_2, \dots, x_c] \in \mathbf{R}^{C \times W \times H}$ 作为输入,并输出一个尺寸与 \mathbf{X} 相同的转换张量,其中包含增强的表示 $\mathbf{Y}=[y_1, y_2, \dots, y_c]$ 。其网络结构如图 7 所示。对于输入特征图大小为 $C \times H \times W$, C 是通道数, H 和 W 分别是高度和宽度,沿水平坐标和垂直坐标使用两个空间范围为 $(H, 1)$ 或 $(1, W)$ 的池化核对每个通道进行编码。第 c 个通道在高度 h 处的输出和宽度为 w 的第 c 个通道的输出分别可表示为:

$$z_c^h(h) = \frac{1}{W} \sum_{0 \leq i < W} X_c(i, h) \quad (2)$$

$$z_c^w(w) = \frac{1}{H} \sum_{0 \leq j < H} X_c(j, w) \quad (3)$$

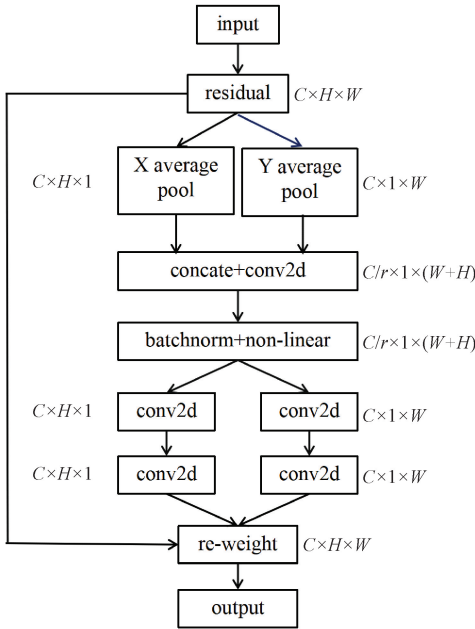


图 7 CA 注意力机制结构

Fig. 7 Structure of CA attention mechanism

上述两个转换分别沿着两个空间方向聚合特征,得到一对方向感知的特征图。把式(2)和(3)产生的聚合特征图拼接,然后通过一个共享的 1×1 卷积函数 F_1 ,从而产生

$$f = \delta(F_1([\mathbf{z}^h, \mathbf{z}^w])) \quad (4)$$

其中, $[\cdot, \cdot]$ 表示沿空间维度的连接操作, δ 是非线性激活函数, $f \in \mathbf{R}^{C/r \times (H+W)}$ 是中间特征图。 R 是控制块大小的比例。然后沿着空间维度将 f 分割成两个独立的张量 $f^h \in \mathbf{R}^{C/r \times H}$ 和 $f^w \in \mathbf{R}^{C/r \times W}$ 。另外两个 1×1 卷积变换 F_h 和 F_w 将 f^h 和 f^w 转换为与输入 \mathbf{X} 具有相同通道数的张量。

$$g^h = \sigma(F_h(f^h)) \quad (5)$$

$$g^w = \sigma(F_w(f^w)) \quad (6)$$

坐标注意力块的输出可以表示为:

$$Y_c(i, j) = X_c(i, j) \times g^h(i) \times g^w(j) \quad (7)$$

不同于只关注不同通道重要性的通道注意力,坐标注意力块还考虑对空间信息进行编码。

2.4 设计轻量化检测头 LSCD

在 YOLOv8n 检测网络的 Detect 模块中,总共使用 4 个 3×3 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。为了减少 Detect 模块的模型体积和计算量,且在精简结构的同时尽可能维持模型的精度,因此本文设计出一种轻量化检测头模块(lightweight shared convolutional detection head, LSCD)。其采用计算量更小,效率更高的分组归一(GN)化改进 Detect 模块中的卷积为 Conv_GN。使用 1×1 的卷积可以学习不同通道的权重,且减少计算量。其次利用权值共享的思想,使用两个 3×3 的 Conv_GN 作为共享卷积,使得模型结构更加精简。为了应对每个检测头所检测的目标尺度不一致的问题,使用 Scale 层对特征进行缩放。其网络结构如图 8 所示。虽然删除了多个 3×3 的卷积,对目标特征的提取会减弱,但是考虑到 PCB 缺陷的目标较小,高维特征有限,故删除多余的卷积对精确度的下降影响较小。

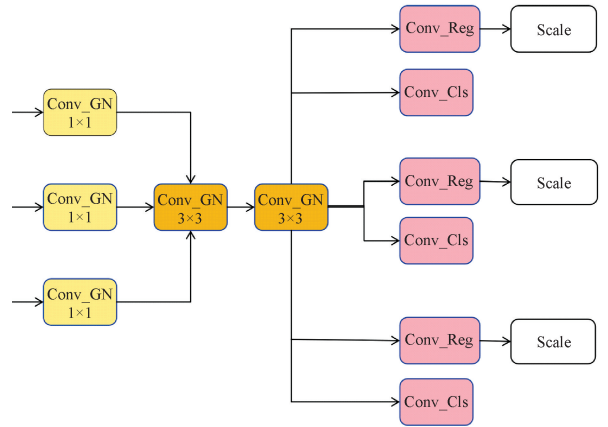


图 8 LSCD 模块网络结构

Fig. 8 LSCD module network structure

Wu 等^[18]在 2018 年提出分组归一化(group normalization, GN)相较于批量归一化(batch normalization, BN),在批量大小较小的情况下 GN 仍然保持着较低的错误率。分组归一化(GN)是针对批归一化算法对批次大小依赖性强这一弱点而提出的改进算法。它把输入通道分成多个组,并在每个组内进行卷积操作。这种结构可以减少计算量,并提高模型的效率。且在 Tian 等^[19]在 2022 发表的 FCOS 中已经证实 GN 可以提升检测头定位和分类的性能。

归一化的公式如下:

$$\mu_i = \frac{1}{m} \sum_{k \in S_i} x_k \quad (8)$$

$$\sigma_i = \sqrt{\frac{1}{m} \sum_{k \in S_i} (x_k - \mu_i)^2 + \epsilon} \quad (9)$$

其中, ϵ 是一个常数, x 是上一层的输出, S_i 是均值和方差的计算区域, m 是该集合的大小, ϵ 是一个非常小的量, β, γ 是两个可训练的参数。

$$Y_i = \frac{X_i - \mu_i}{\sqrt{\sigma_i + \epsilon}} \times \gamma + \beta \quad (10)$$

分组归一化(GN)的结构图如图 9 所示。设某层输出得到 X , 沿通道方向均分成 num_groups 份, 分别对每一份计算均值和方差。

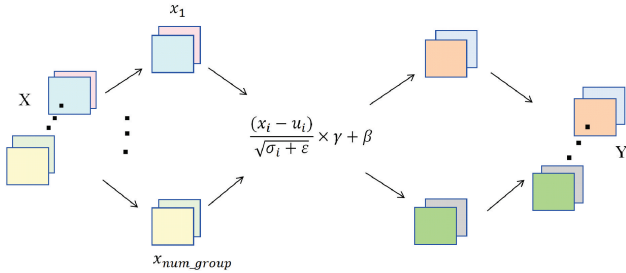


图 9 分组归一化(GN)结构图

Fig. 9 Group normalized (GN) structure diagram

综合以上, 可以让检测头做到参数量更少、计算量更少的情况下, 尽可能减少精度的损失。

3 实验分析与结果

3.1 数据集

实验数据集采用北京大学智能机器人开放实验室发布的公开数据集, 一共包含 1 386 张图片。数据集有 6 种缺陷(缺孔、鼠咬、开路、短路、刺、假铜)。该数据集存在类别和尺寸不平衡, 以及数据集数量不足的问题, 故采用数据增强, 旋转, 亮度调整等方式将数据集扩充到 10 668 张。PCB 数据集各标签图片如图 10 所示。

3.2 实验环境

实验环境的配置如表 1 所示, 训练时选择图像输入大小为 640×640 , batch_size 为 16, epochs 为 300, 优化器为 SGD。模型的初始权重为 COCO 数据集训练的权重。学习率设置为 0.01, 实验数据集按照 8:2 分为训练集和验证集。

3.3 评价指标

针对模型的轻量化改进, 本文实验采用计算量(GFLOPs), 参数量(Params), 平均精度(mean average precision, mAP), 考虑到实际工程当中的应用还将每秒处理图片的数量(frames per second, FPS)作为评价指标。

设 TP 和 TN 分别为正样本被正确检测和错误检测的数量, FP 和 FN 分别为负样本被正确检测和错误检测的数量。由以上参数可分别依次计算出准确率 P , 召回率 R ,

平均精度 AP, 平均精度均值 mAP。计算公式如下:




图 10 PCB 缺陷种类

Fig. 10 PCB defect types

表 1 实验环境配置

Table 1 Experimental environment configuration

名称	参数
操作系统	Windows10
CPU	Intel Core i9-10980XE
GPU	NVIDIA GeForce RTX3080, 10 GB
编程语言框架	Python3.9 Pytorch2.0.1+CUDA11.7

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

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

$$AP = \int_0^1 P(R) dR \quad (13)$$

$$mAP = \frac{1}{N} \sum_{i=1}^N AP_i \quad (14)$$

其中, AP 是由 P-R 曲线与坐标围成的面积, N 代表样本总数, 把每个类别的 AP 值求平均。

3.4 消融实验

为了验证本文算法中每个模块改进的有效性, 对每个模块进行消融实验。为了研究每个改进模块对模型轻量化的改进故选用模型计算量, 参数量, mAP%0.5, FPS 作为评价指标。实验结果如表 2 所示。

表 2 消融实验结果

Table 2 Ablation results

实验	YOLOv8n	调整网络	C2f-Star-CA	LSCD 检测头	计算量/G	参数量/M	mAP%0.5	FPS
1	✓				8.1	3.01	98.4	95.7
2	✓	✓			7.2	2.36	98.2	100.2
3	✓	✓	✓		6.8	2.16	98.7	117.4
4	✓	✓	✓	✓	4.5	1.37	98.6	124.3

根据表 2 可知,调整网络结构后,模型参数量减少了 21.6%,计算量减少了 11.1%,mAP%0.5 下降了 0.2%。可以发现主干网络中通过星运算实现的高效的特征表示明显减少了模型的参数量和计算量。但是在轻量化的同时 mAP%0.5 下降了 0.2%。在此基础上,将颈部网络的 C2f 模块替换为 C2f-star-CA 后,模型参数量减少了 8%,计算量减少了 5%,虽然参数量下降不明显但是 mAP%0.5 提升了 0.5%。减少参数量的同时提高了特征提取的效率。最后将 LSCD 模块作为网络的 Detect 部分,使用共享卷积使模型进一步轻量化,模型参数量进一步下降了 36.6%,计算量减少了 32%,mAP%0.5 仅仅下降了 1%。与 YOLOv8n 相比,本文算法模型参数量减少了 45.5%,计算量减少了 56.8%,mAP%0.5 提升了 0.2%。本文算法是更加适用于部署到资源有限硬件设备上的 PCB 缺陷检测算法。

3.5 对比实验

为了体现本文算法的性能和优越性,将本文算法与一些主流的算法 Faster RCNN, SSD, YOLOv5s, PCB-YOLO^[20], RT-DETR, YOLOv8n 进行比较,在相同的实验环境下使用本文的增强数据集进行实验,得到的结果如表 3 所示。Faster RCNN、SSD、RT-DETR 算法相较于

YOLO 系列算法参数量较大,FPS 较低。可以发现相较于其他算法,本文算法模型参数量最小,为 1.37 M,约为其中 YOLOv8n 模型的一半。FPS 和 mAP%0.5 最高,分别为 124.3、98.6。可知本文的算法模型更加轻量化,检测速率更快更准确。

此外本文还与不同轻量级 PCB 缺陷检测算法, YOLOv7-tiny、YOLO-MCG^[21]、文献[22]、文献[23]、文献[9]的检测精度,参数量,FPS 进行对比,结果如表 4 所示。可以发现本文算法的参数量低于其他算法,且 FPS 远大于其他算法。也说明了在保持精度的同时本文算法在检测速度方面的优势。适合于在资源受限的环境下运行。在移动端设备场景下所需要的算力和内存需求。

3.6 实验效果图

为了更加直观的感受本文算法的提升,把 YOLOv8n 与 ST-YOLO 对鼠咬(mouse_bite),毛刺(spur),缺口(missing_hole),短路(short),开路(open_circuit),假铜(spurious_copper),的检测结果进行对比。YOLOv8n 的检测结果如图 11(a)所示,ST-YOLO 如图 11(b)所示。在缺口,短路,假铜类别的检测中,本文算法检测结果的置信度有所提升。在鼠咬和毛刺的检测中本文算法检测正确,而 YOLOv8n 存在漏检和误检的情况。

表 3 不同目标检测算法对比分析结果

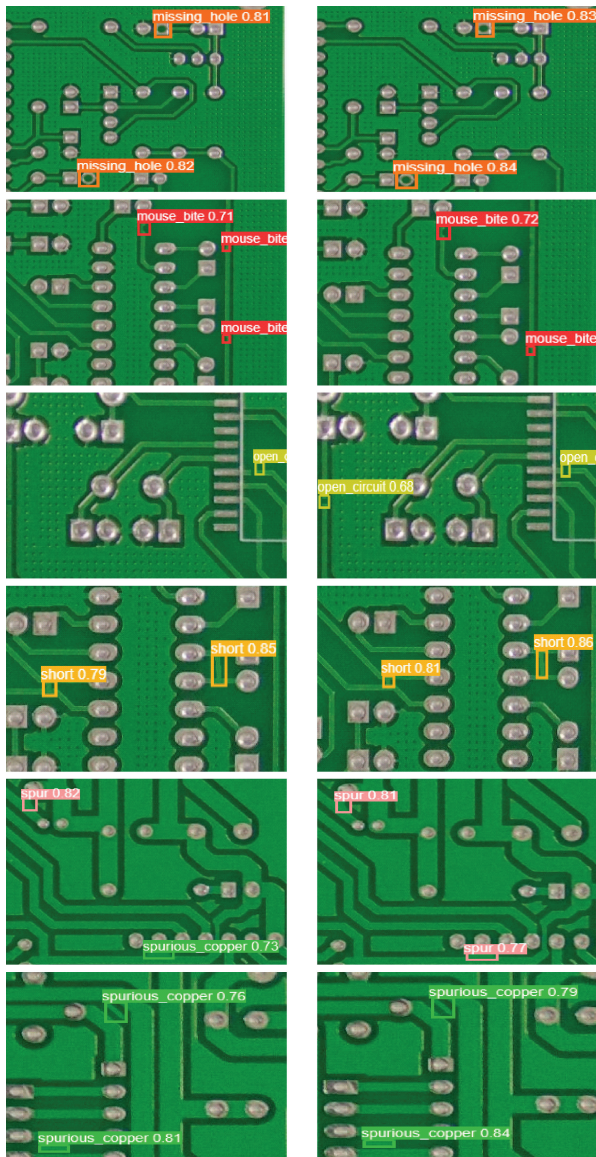
Table 3 Comparative analysis results of different target detection algorithms

模型	鼠咬	毛刺	缺口	短路	开路	假铜	mAP%0.5	参数量/M	FPS
Faster RCNN	68.7	70.2	70.6	68.8	70.1	69.2	69.5	108.60	18.1
SSD	97.3	98.2	98.8	96.9	98.1	96.7	97.6	24.28	58.7
YOLOv5s	96.0	96.7	97.5	95.9	97.2	95.4	96.4	7.00	80.4
PCB-YOLO	96.2	96.4	97.1	95.4	98.1	95.7	96.6	21.36	55.3
RT-DETR	97.6	98.3	98.9	97.3	98.0	96.5	97.8	17.00	56.2
YOLOv8n	98.2	99.0	99.1	97.8	98.7	97.2	98.4	3.01	95.7
本文算法	98.3	98.9	99.5	98.1	99.1	97.1	98.6	1.37	124.3

表 4 不同轻量级 PCB 缺陷检测算法对比分析结果

Table 4 Comparative analysis results of different lightweight PCB defect detection algorithms

模型	鼠咬	毛刺	缺口	短路	开路	假铜	mAP%0.5	参数量/M	FPS
YOLOv7-tiny	97.4	98.1	98.5	97.0	98.2	96.4	97.5	6.20	82.5
文献[23]	98.0	98.2	98.7	96.8	98.5	97.1	98.5	10.60	42.9
YOLO-MCG	97.2	98.3	98.1	97.3	98.0	96.1	97.2	8.13	67.8
文献[22]	98.4	98.5	98.2	97.7	98.8	97.2	98.4	2.50	85.4
文献[9]	97.8	98.2	98.5	96.9	98.4	96.3	97.7	1.90	88.3
本文算法	98.3	98.9	99.5	98.1	99.1	97.1	98.6	1.37	124.3



(a) YOLOv8n算法 (b) ST-YOLO算法
(a) YOLOv8n algorithm (b) ST-YOLO algorithm

图 11 检测效果对比

Fig. 11 Comparison of detection results

4 结 论

为了解决 PCB 缺陷检测算法在识别精度和轻量化难以平衡的问题,提出了一种基于 YOLOv8n 改进的算法 ST-YOLO。使用 StarNet 作为网络的主干,并调整颈部网络结构,去掉大目标检测层,新增小目标检测层减小模型体积。提出 C2f-star-CA 模块,轻量化的同时使用全新的方法作为特征提取手段。设计轻量化检测头 LSCD,使用卷积共享参数的思想进一步减小模型参数量。ST-YOLO 算法在保证检测性能的同时大幅减小了模型参数量,并对改进部分做消融实验和与主流的轻量化目标检测算法作对比,验证了网络的有效性。为实时性要求较高的检测场

景提供了新的方法和轻量化的思路。虽然该算法在保持高精度的同时实现了轻量化,但网络中的星运算对于硬件平台来说属于新颖的算子,需要开发者在边缘设备部署的过程中为其单独实现 GPU 算子程序。

参考文献

- [1] 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.
WU Y Q, ZHAO L Y, YUAN Y B, et al. Research status and prospect of PCB defect detection algorithm based on machine vision [J]. Chinese Journal of Scientific Instrument, 2022, 43(8):1-17.
- [2] 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.
- [3] REN SH Q, HE K M, GIRSHICK R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6): 1137-1149.
- [4] LIU W, ANGUOLOV D, ERHAN D, et al. SSD: Single shot multibox detector [C]. Computer Vision-ECCV, 2016:21-37.
- [5] 徐彦威,李军,董元方,等. YOLO 系列目标检测算法综述[J]. 计算机科学与探索, 2024, 18(9):2221-2238.
XU Y W, LI J, DONG Y F, et al. Overview of YOLO series target detection algorithms [J]. Journal of Frontiers of Computer Science and Technology, 2024, 18(9):2221-2238.
- [6] VARGHESE R, SAMBATH M. YOLOv8: A novel object detection algorithm with enhanced performance and robustness [C]. 2024 International Conference on Advances in Data Engineering and Intelligent Computing Systems (ADICS). IEEE, 2024: 1-6.
- [7] 任金霞,吴吉林,王金荣. 基于 ECA 和 BiFPN 改进 YOLOv5s 的 PCB 缺陷检测 [J]. 制造技术与机床, 2024(8):78-83.
REN J X, WU J L, WANG J R. Improved PCB defect detection of YOLOv5s based on ECA and BiFPN [J]. Manufacturing Technology and Machine Tool, 2024(8):78-83.
- [8] YUAN M, ZHOU Y, REN X. YOLO-HMC: An improved method for PCB surface defect detection [J]. IEEE Transactions on Instrumentation and Measurement, 2024, 73:1-11.
- [9] 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.
- LYU X L, YANG X SH, CAO ZH M. PCB surface defect detection algorithm of YOLOv8[J]. Electronic Measurement Technology, 2024, 47(12): 100-108.
- [10] 高杨, 曹仰杰, 段鹏松. 神经网络模型轻量化方法综述[J]. 计算机科学, 2024, 51(S1): 23-33.
- GAO Y, CAO Y J, DUAN P S. A review of lightweight methods for neural network models[J]. Computer Science, 2024, 51(S1): 23-33.
- [11] MA X, DAI X, BAI Y, et al. Rewrite the stars[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2024: 5694-5703.
- [12] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection [J]. ArXiv preprint arXiv:2004.10934, 2020.
- [13] LOFFE S. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. ArXiv preprint arXiv:1502.03167, 2015.
- [14] XU J J, SUN X, ZHANG ZH Y, et al. Understanding and improving layer normalization[J]. ArXiv preprint arXiv:1911.07013, 2019.
- [15] ZHOU D Q, HOU Q B, CHEN Y P, et al. Rethinking bottleneck structure for efficient mobile network design [C]. Computer Vision-ECCV, 2020: 680-697.
- [16] SANDLER M, HOWARD A, ZHU M L, et al. Mobilenetv2: Inverted residuals and linear bottlenecks[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2018: 4510-4520.
- [17] HOU Q B, ZHOU D Q, FENG J SH. Coordinate attention for efficient mobile network design [C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 13713-13722.
- [18] WU Y X, HE K M. Group normalization [C]. European Conference on Computer Vision (ECCV), 2018: 3-19.
- [19] TIAN ZH, SHEN CH H, CHEN H, et al. Fcos: A simple and strong anchor-free object detector [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2022, 44(4): 69-76.
- [20] TANG J L, LIU SH B, ZHAO D X, et al. PCB-YOLO: An improved detection algorithm of PCB surface defects based on YOLOv5[J]. Sustainability, 2023, 15: 5963.
- [21] 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): 10.
- HU L L, DENG CH. PCB defect detection algorithm based on YOLO-MCG[J]. Instrument Technique and Sensor, 2024(4): 10.
- [22] 胡琪涛, 邹启杰. 基于轻量化 ADS-YOLOv8n 的印刷电路板缺陷检测[J]. 激光与光电子学进展, 2025, 62(8): 123-135.
- HU Q T, ZOU Q J. Defect detection of printed circuit board based on lightweight ADS-YOLOv8n[J]. Laser and Optoelectronics Progress, 2025, 62(8): 123-135.
- [23] 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 J, WU Y, CHEN ZH CH. Research on PCB defect detection based on SMT-YOLOv8 [J]. Electronic Measurement Technology, 2024, 47(11): 131-137.

作者简介

刘辉, 正高级工程师, 硕士生导师, 主要研究方向为通信网络新技术、目标检测等。

E-mail: liuhui@cqcqyit.com

刘旭(通信作者), 硕士研究生, 主要研究方向为目标检测。

E-mail: 2632210442@qq.com

李校林, 正高级工程师, 硕士生导师, 主要研究方向为数字孪生。

曾凡琪, 硕士研究生, 主要研究方向为智能反射面。

王鹏江, 硕士研究生, 主要研究方向为目标检测。