

DOI:10.19651/j.cnki.emt.2211285

# 基于 PPLCFaster-YOLOv5 的 PCB 表面缺陷快检模型<sup>\*</sup>

季堂煜 赵倩 赵琰 余文涛 梁爽  
(上海电力大学电子与信息工程学院 上海 201306)

**摘要:** 针对现有 PCB 表面缺陷检测方法精度低、召回率低以及实时性较差等问题,提出 PPLCFaster-YOLOv5 模型。该方法以改进后的 PPLC-Net 作为主干网络,将 Focus 结构作为网络第 0 层,提高特征图对位置信息的表达能力。在深度可分离卷积结构内引入通道混洗机制,使各分组卷积获取的特征对全局特征具有等贡献度;引入 Dropout 机制限制不平衡正则化因子。提出低参数量 G4Head 特征融合网络结构,将更为浅层的信息加入特征融合中,提高模型对缺陷的定位能力;在主干网络与特征融合之间增加残差连接,提高主干网络信息对特征融合的贡献度;采用 SIOU 损失函数,加速回归框收敛。将训练后的模型采用 Flask 服务器框架进行部署。实验表明,部署后的 PPLCFaster-YOLOv5 模型在 DeepPCB 以及北京大学 PCB 表面缺陷检测数据集上检测时间可达 0.009 s,且准确率、召回率等相比于其他主流模型均获得提升。

**关键词:** 目标检测;PCB 表面缺陷;YOLOv5;通道混洗;SIOU;微服务部署

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

## Rapid inspection model of PCB surface defects based on PPLCFaster-YOLOv5

Ji Tangyu Zhao Qian Zhao Yan Yu Wentao Liang Shuang

(College of Electronics and Information Engineering, Shanghai University of Electric Power, Shanghai 201306, China)

**Abstract:** The PPLCFaster-YOLOv5 model is proposed to address the problems of low accuracy, low recall and poor real-time performance of existing PCB surface defect detection methods. The method uses the modified PPLC-Net as the backbone network and the Focus structure as layer 0 of the network to improve the feature map's ability to express location information. A channel blending mechanism is introduced within the depth-separable convolutional structure so that the features obtained by each grouped convolution have equal contribution to the global features; a Dropout mechanism is incorporated to limit the imbalance regularisation factor. A low parametric number G4Head feature fusion network structure is proposed to incorporate more shallow information into the feature fusion to improve the model's ability to locate defects; add residual connections between the backbone network and feature fusion to improve the contribution of backbone network information to feature fusion; and adopt the SIOU loss function to accelerate the convergence of the regression frame. The trained model was deployed using the Flask server framework. Experiments show that the deployed PPLCFaster-YOLOv5 model can detect surface defects on DeepPCB as well as the Peking University PCB surface defect detection dataset in 0.009 s, and the accuracy and recall rates are improved compared with other mainstream models.

**Keywords:** object detection;PCB surface defects;YOLOv5;channel blending;SIOU;microservice deployment

## 0 引言

PCB 表面缺陷检测的主要难点在于:目标较小、分割

难度大以及似然性高<sup>[1]</sup>。现行主流检测方法可分为接触式检测方法与无接触式检测方法。接触式检测方法主要借助探针、针床等设备进行电气特性测量分析<sup>[2-3]</sup>。此方法易因

收稿日期:2022-09-06

\*基金项目:国家自然科学基金(61802250)项目资助

操作不当对 PCB 造成割裂、划伤等不可逆问题。无接触式检测方法可划分为传统计算机视觉<sup>[4]</sup>和深度学习方法<sup>[5]</sup>。传统的计算机视觉处理方法存在计算复杂、泛化性差<sup>[6]</sup>、依赖先验图像<sup>[7]</sup>等缺陷。深度学习算法具有较高的泛化性，对于质量较差图像也可以进行较为准确的检测<sup>[8]</sup>。目前深度学习算法在 PCB 缺陷检测中已经取得了一定成功<sup>[9-10]</sup>。曾凯等<sup>[11]</sup>采用完全改进后的 YOLOv3 算法实现了对于多尺度 PCB 表面缺陷的检测。陈仁祥等<sup>[12]</sup>通过改进 Faster RCNN 进一步提升模型对于 PCB 表面缺陷识别的精度。Zhou 等<sup>[13]</sup>采用注意力机制进一步优化了模型对于局部信息的关注度，提高了模型检测精度。上述方法虽然可以较为精准地进行 PCB 缺陷检测但网络复杂度较高，难以达到工业实时检测需求。

将轻量化网络<sup>[14-15]</sup>作为主干网络，能有效满足工业实时检测需求。王恒涛<sup>[16]</sup>通过剪枝算法去除了网络中的冗余参数量，提高了 PCB 表面缺陷检测的速度。伍济钢<sup>[17]</sup>以低参数量 MobileNetV2 作为主干网络，提升了 PCB 表面缺陷检测的速度；崔昊杨等<sup>[18]</sup>提出的 EF-YOLOv4 模型，能以较快的速度实现对于复杂环境下电力仪表的识别检测。上述成果证明了轻量化网络能有效解决目标检测过程中的速度问题，为本课题研究奠定了基础。

基于前述研究，本文提出了一种快速检测网络 PPLCFaster-YOLOv5 模型，以改进后的 PPLCNet<sup>[19]</sup>作为主干网络，平衡模型速度与精度。将 Focus<sup>[20]</sup>结构作为网

络第 0 层，提高通道对于位置信息的表达能力。在深度可分离卷积(depthwise separable convolution, DSC)内引入通道混洗机制，使各组特征图对各通道具有等贡献度，加强了组间信息交互，提高模型的学习能力。并借鉴 EfficientNet 网络<sup>[21]</sup>，通过引入合适比例的 Dropout，平衡网络训练过程中的速度与精度。在网络最深层嵌入高效通道注意力模块(efficient channel attention for convolutional neural networks, ECA-Net)<sup>[22]</sup>，加强模型对于高维语义信息传递能力。在特征融合阶段，提出 G4Head 结构，将更为浅层的信息加入特征融合结构中，提高了浅层位置信息与深层语义信息的传递能力。通过增加同尺度跨越连接，强化特征信息的融合，提高特征通道的表达能力。对特征融合部分的残差结构进行低秩分解<sup>[23]</sup>，去除网络中的冗余参数量，加速模型推理。以 SIOU 损失函数<sup>[24]</sup>作为目标框回归损失函数，改善了模型的收敛速度。PPLCFaster-YOLOv5 模型在 DeepPCB<sup>[25]</sup>以及北京大学 PCB 表面缺陷数据集<sup>[26]</sup>上检测速度可达 0.009 s，且检测效果良好。为方便模型在移动端进行调用，将模型通过 Flask 微服务器框架进行部署。

## 1 PPLCFaster-YOLOv5PCB 表面缺陷检测模型

针对 YOLOv5 网络复杂度较高、实时性差等不足进行改进，提出 PPLCFaster-YOLOv5 模型，其结构如图 1 所示。改进后的算法主要包括两个部分：优化后的 PPLCNet 和 G4Head 特征融合网络。

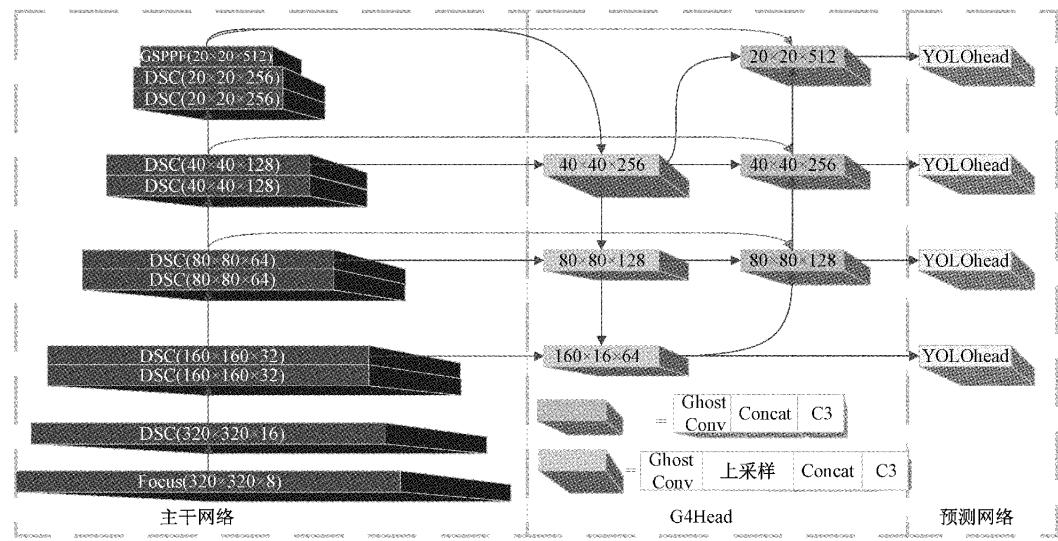


图 1 PPLCFaster-YOLOv5 快速检测网络模型结构

模型的运算过程为：首先将输入为  $640 \times 640 \times 3$  的图像，经过 Focus 层变换为  $320 \times 320 \times 8$  的特征图，再通过连续堆叠的 DSC 模块以及由幻象卷积(GhostConv)<sup>[27]</sup>和快速空间金字塔池化结构模块(faster spatial pyramid pooling, SPPF)<sup>[28]</sup>构成的 GSPPF 模块，获取尺寸为  $160 \times 160 \times 24$ 、 $80 \times 80 \times 48$ 、 $40 \times 40 \times 88$  以及  $20 \times 20 \times 344$  的特征图用于特征融合。在模型特征融合部分，提出了 G4Head 特征融合网络结构。采用

GhostConv 模块控制模型通道的变化，减少模型参数量；借助额外增加的  $160 \times 160 \times 64$  尺度检测头，提高了模型对各类缺陷的定位能力。改进主干网络与特征融合结构间的连接方式，在主干网络与特征融合结构间增加残差连接，提高主干网络各尺度特征信息对特征融合的贡献度。

### 1.1 改进后的 PPLCNet 主干网络

PPLCNet 主干网络虽然能够实现特征的快速提取，但

网络对于 PCB 表面缺陷的特征提取能力较弱。因此从如下 3 个部分对主干网络进行改进:

### 1) 强化网络对浅层位置信息的提取能力

原网络第 0 层通过卷积进行通道升维, 获取的位置信息较为模糊, 降低了模型对缺陷的定位能力。针对上述不足, 可通过将 Focus 结构作为网络第 0 层或引入注意力机制提高模型对目标有用信息的关注度。Focus 模块以隔点采样的方式实现无损压缩, 有效地保留了浅层位置信息。注意力机制通过从指定维度对目标区域赋予权值, 加强对目标有效信息的关注度。其中, 通道注意力与空间注意力结合的卷积注意力模块(convolutional block attention module, CBAM)<sup>[29]</sup> 相比于其他单维注意力, 能更全面地关注图像中有效特征信息。

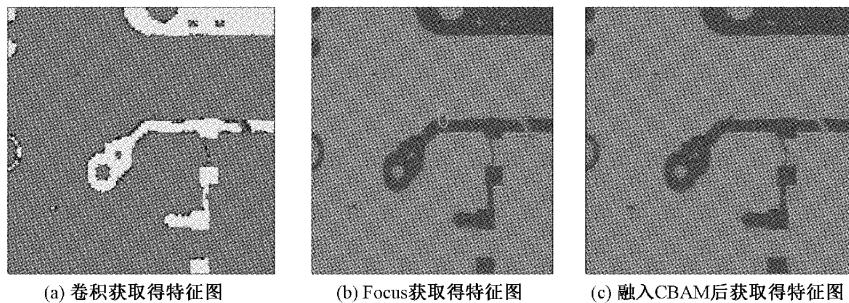


图 2 第 0 层两种方案获取的特征图对比

### 2) 深度可分离卷积结构的改进

深度可分离卷积模块通过分组卷积进行特征提取, 虽降低了模型运算复杂度, 但阻碍了组间信息的交互, 抑制了模型的学习能力。为弥补上述缺陷, 引入通道混洗机制将各组间信息进行随机交互, 使各组信息对全局特征信息具有等贡献度。

随着网络深度的不断加深, 获取的信息逐渐抽象至高维语义信息, 在网络深层添加注意力, 能提高模型对目标语义分割能力。为避免引入过多参数, 以改进后的 ECA-Net 加强高维语义信息的传递能力。ECA-Net 通过 1 维卷积构建通道间的关联度, 但卷积运算过程中易限制网络速度。故本文采用 HardSigmoid 激活函数进行权重赋值, 构建出 HECA 注意力机制。HECA 注意力机制的计算过程为: 对于输入为  $h \times w \times c$  的特征图, 通过池化得到  $1 \times 1 \times c$  的特征图, 然后使用卷积核为 k 的 1 维卷积构建通道间关联, 并通过 HardSigmoid 函数进行快速权重赋值, 将特征图恢复至  $h \times w \times c$ 。HardSigmoid 计算公式如式(1):

$$\sigma(x) = \max\left(0, \min\left(1, \frac{x+1}{2}\right)\right) \quad (1)$$

式中:  $x$  表示模型的输入,  $\sigma(x)$  表示经过激活函数后的输出结果。

以 MemoryEfficientMish 激活函数作为 DSC 模块中分组卷积和  $1 \times 1$  卷积中的激活函数, 提高模型的速度。计算公式如式(2):

分别将上述两种方案应用于网络第 0 层, 并可视化特征图, 如图 2 所示。从特征图对边缘位置信息的表达能力以及网络浮点数运算量两个层面进行分析。如图 2(a)所示, 通过卷积层压缩后, 特征图中边缘位置信息较为模糊, 难以实现较为精准的定位。如图 2(b)所示, 圆圈处所代表的毛刺部分信息比图 2(a)中更为清晰, 并且方框处所代表的断路部分, 细节表达能力更为清晰可见。如图 2(c)中所示, 引入 CBAM 注意力机制后, 对于细节以及小目标也能进行较为精准地表达。但在第 0 层引入 CBAM 注意力机制, 相比于 Focus 作为第 0 层, 浮点数运算量增加了 0.1GFLOPs。所以综合上述分析对比可知, 采用 Focus 作为第 0 层能以更小的计算量, 获取更为清晰的边缘位置信息。

$$\text{MemoryEfficientMish}(x) = x \cdot \tanh(\ln(1 + e^x)) \quad (2)$$

式中:  $x$  表示模型的输入,  $\text{MemoryEfficientMish}(x)$  表示经过激活函数后的输出结果。同时引入 Dropout 机制, 抑制不平衡正则化因子对模型泛化能力的影响<sup>[29]</sup>。改进后的 DSC 模块结构, 如图 3 所示。

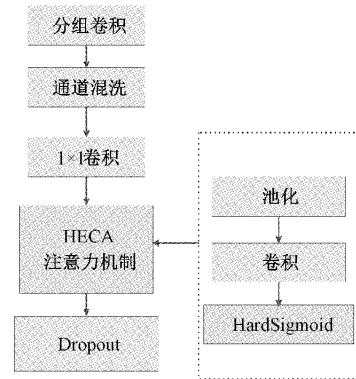


图 3 改进后的 DSC 模块

### 3) GSPPF 轻量化结构

随着卷积神经网络的网络层次加深, 深层特征图的信息高度抽象, 造成小目标检测的精度较差。SPPF 模块对图像进行  $1 \times 1$ 、 $5 \times 5$ 、 $9 \times 9$  和  $13 \times 13$  四尺度池化, 并通过  $1 \times 1$  卷积进行升维拼接, 实现多尺度局部特征和全局特征的融合。丰富特征图的表达能力, 从而提高小目标的检测

精度。为了进一步轻量化网络,提出将图 4 中 SPPF 的  $1 \times 1$  卷积改为幻象卷积,如虚线圆圈部分所示。GhostConv 以线性变化取代卷积运算得到数量相同的特征图,在确保了模块能力的前提下,减小了模型的参数量。改进后的模块,本文称为 GSPPF 结构。

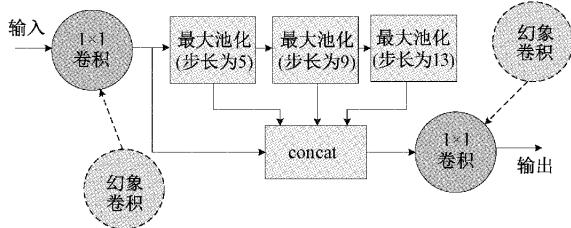


图 4 GSPPF 模块结构

## 1.2 G4Head 特征融合结构

为实现以较小计算量提高模型对各尺度 PCB 表面缺陷信息的有效表达,提出 G4Head 特征融合网络。相比于原始特征融合结构,其改进点可概括为如下 3 部分:

### 1) 结构改进

YOLOv5 使用尺度大小为  $20 \times 20$ 、 $40 \times 40$  与  $80 \times 80$  进行检测。这种检测尺度适用于检测目标较大且检测对象主要依靠深层语义信息区分的情况。PCB 表面缺陷的形态各异、目标往往较小且表层信息丰富,忽视浅层信息会导致漏检与错检。为了解决上述问题,在检测层中增加

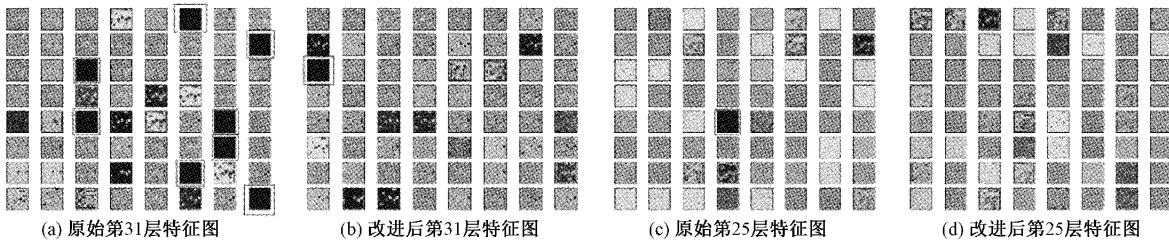


图 5 改变结构前后特征图对比

### 3) 低秩分解

针对高参数残差结构,采用低秩分解,降低模型冗余参数量。低秩分解主要通过采用卷积核为  $1 \times k$  和  $k \times 1$  的两个卷积替换步长为  $k \times k$  的单步卷积核<sup>[22]</sup>。对于残差网络中的  $3 \times 3$  结构采用  $1 \times 3$  和  $3 \times 1$  两个卷积核进行低秩分解。经过低秩分解后,模型的浮点数运算量降低 0.01GFLOPs,加速了模型的运算速度。

## 1.3 SIOU 损失函数

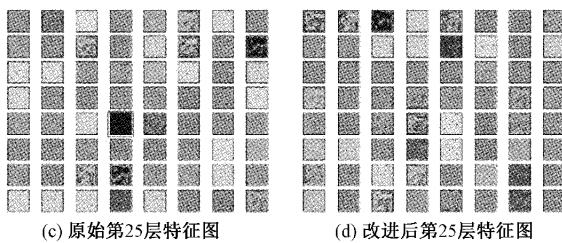
SIOU 损失函数从预测框与背景框之间的 IOU、距离、形状以及匹配方向 4 个角度进行回归。通过增加角度损失函数,降低了目标框回归过程中的自由度,加速模型平滑收敛。SIOU 损失函数示意图,如图 6 所示,其中:  $B$ 、 $B^{GT}$  分别代表:预测框和真实框的中心点,  $\sigma$  为预测框和真实框中心点的距离,  $c_h$ 、 $c_w$  为以两个框中心点构成的矩形的长和宽;  $\alpha$ 、 $\beta$  为矩形边与对角线构成的互余角。SIOU

$160 \times 160$  检测尺度。改进方法为:在特征提融合结构增加幻象卷积层与上采样层,然后主干网络第 3 层与  $160 \times 160$  特征层进行融合。以此来提高低层语义与深层语义的连接与融合,提高对目标的定位能力。通过轻量化 GhostConv 模块改变各阶段特征图的尺寸,有效减少了模型的参数量。

### 2) 融合策略改进

为加强特征融合各阶段对有效信息的表达,可通过限制通道数、增加注意力机制以及增加有效信息源等方式进行弥补。删减通道数容易造成模型因缺乏足够的信息,导致检测效果较弱。增加注意力机制虽然能加强有效信息的传递,但易引入较多参数量,降低模型推理速度。针对上述两种方法的不足,本文通过增加主干网络与特征融合检测尺寸相同部分的残差连接,丰富各阶段特征融合的信息源。

可视化第 31、25 层 C3 结构中前 64 通道特征图,如图 5 所示。如图 5(a)所示:第 31 层在改变结构方式前获取的特征图中存在着 8 张表达能力较低下的特征图,图中红色方框处所示。如图 5(d)所示:改进连接方式后 64 张特征图中仅存在 1 张表达信息能力较差的特征图。如图 5(c)和(f)所示:通过在增加该尺度主干网络与特征融合结构间的残差连接,改善了该尺度唯一表达能力较弱的通道。



计算公式如式(3):

$$\begin{aligned} L &= 1 - IOU + \frac{\Delta + \Omega}{2} \\ \Delta &= \sum_{t=x,y} (1 - e^{-\gamma p_t}) \\ \Omega &= \sum_{t=w,h} (1 - e^{-\omega_t})^\theta \end{aligned} \quad (3)$$

式中:  $IOU$  表示真实框与预测框的交并比;  $\Delta$  表示距离损失,  $\Omega$  表示形状损失。 $p_t$  表示预测框与目标框中心距离之间的平方,  $w_t$  表示预测框与目标框形状归一化后的误差,  $\theta$  以及  $\gamma$  为权重系数。

可视化引入 SIOU 前后模型迭代过程中的损失函数收敛情况。由图 7 可知,引入 SIOU 损失函数后,在验证集上模型在训练过程中收敛更为平滑。模型收敛的最终数值略微低于改进前。

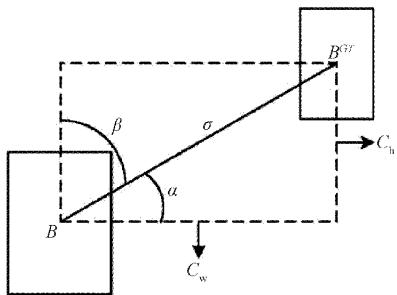


图 6 SIOU 损失函数示意图

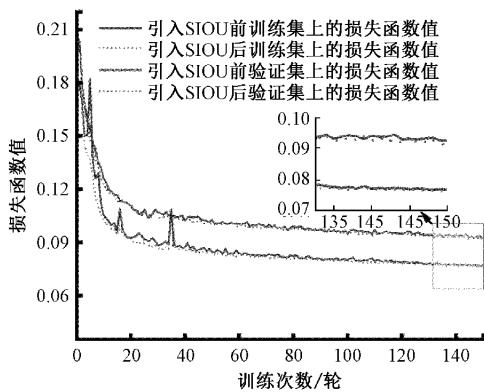


图 7 改变损失函数前后模型训练过程中的收敛情况

## 2 实验结果与分析

### 2.1 实验配置以及数据集

本实验平台为: 联想拯救者刃 7000K, 操作系统为 Windows11, CPU: Intel i7-12700F, 内存: 16 GB, 显卡: NVIDIA RTX3060Ti 8 G, 深度学习框架: pytorch1.11.0。实验数据集采用北京大学开源 PCB 表面缺陷数据集和 DeepPCB 数据集, 各类别标签数量如图 8 和 9 中所示。训练过程中将数据集按照 8 : 1 : 1 的比例划分训练集、验证集与测试集, 图片输入大小调整为 640×640, 设置初始学习率为 0.01, 采用 Adam 优化器进行模型训练, 迭代 150 轮。

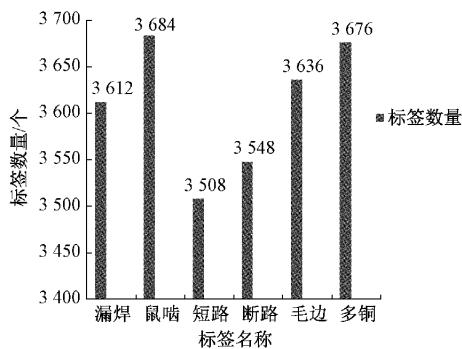


图 8 北京大学开源数据集各类别缺陷的数量标签

### 2.2 评价指标与结果对比

为综合检验模型的效果, 采用多类评价指标, 包括: 准

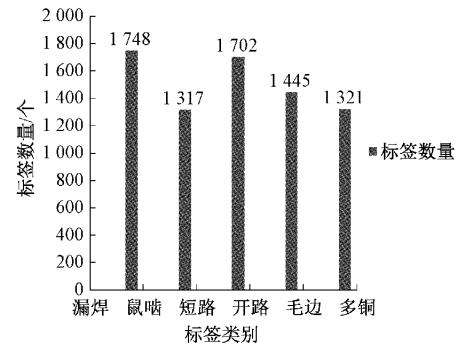


图 9 DeepPCB 各类别缺陷的数量标签

确率 (precision, P)、召回率 (recall, R)、平均精度 (mean average precision, mAP)、浮点数运算量 (G) 以及模型的检测时间 (T) 进行多指标评价。

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

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

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

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

其中,  $TP$  为检测正确的正样本;  $FP$  为检测错误的正样本;  $FN$  为检测错误的负样本;  $N$  为类别总数;  $AP_i$  是  $i$  个平均精确度 (即 PR 曲线下的面积)。准确率、召回率、mAP0.5 是指 IOU 设为 0.5 时所有类别的平均 AP, 用于验证模型的综合性能; 模型浮点数运算量用于衡量模型的轻量化与否; 模型的检测时间用于判断模型是否适应工业化快速检测。

在模型建立过程中, 首先需选择合适的 Dropout 率, 以此调节网络训练过程中速度与精度的平衡。分别设置 Dropout 率为 5% (模型 1)、10% (模型 2)、20% (模型 3) 以及 30% (模型 4), 训练 10 轮观察模型的性能与训练速度, 对比结果如图 10 所示。

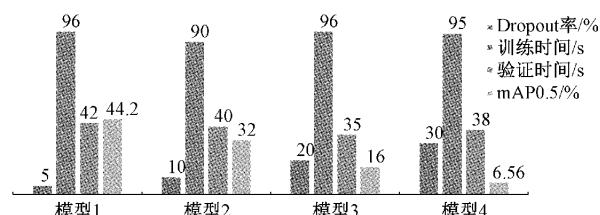


图 10 Dropout 率对模型平衡性的影响

从图 10 中可以看到, 将模型中 Dropout 率设置为 10%。模型的训练时间比设置为其他学习率的情况下明显下降了 3 s 左右, 同时网络的性能较好。因此, 将各阶段模型的 Dropout 设置为 10% 可以较好地实现网络速度与精度间的平衡。

为验证本文算法的优劣性,将模型与多个主流模型进行对比分析,各项指标数值如表 1 所示。

表 1 多模型性能对比表

| 模型                           | P/%  | R/%  | mAP0.5/% | G/GFLOPs | T/s   |
|------------------------------|------|------|----------|----------|-------|
| YOLOv3tiny <sup>[30]</sup>   | 96.5 | 96.0 | 97.1     | 13.0     | 0.020 |
| YOLOv5s                      | 97.4 | 97.1 | 98.2     | 16.5     | 0.017 |
| YOLOv4tiny <sup>[31]</sup>   | 95.8 | 90.7 | 95.8     | 8.0      | 0.034 |
| FasterRCNN <sup>[32]</sup>   | 92.3 | 92.4 | 92.4     | 50.1     | 0.096 |
| ShuffleNetV2 <sup>[33]</sup> | 96.3 | 97.5 | 97.7     | 40.5     | 0.017 |
| PPLCNet                      | 96.5 | 96.6 | 96.6     | 4.6      | 0.010 |
| 本文                           | 97.2 | 94.7 | 97.4     | 6.7      | 0.009 |

进一步分析表 1 可知:1)与 YOLOv3-tiny 模型相比,模型浮点数运算量降低了 6.3 GFLOPs,模型推理速度更快,可以更好地满足 PCB 表面缺陷实时检测需求;2)本模型相比于 YOLOv5s 模型,浮点数运算量减少了 9.8 GFLOPs,模型 mAP0.5 下降了 0.8%。本文方法在速度与检测性能之间获得更好的平衡;3)YOLOv4-tiny 模型特征融合结构能力较弱,导致信息表达能力较差,限制了模型检测的精度与召回率;4)双阶段 Faster RCNN 检测算法相比于本文模型不仅模型复杂度较高且模型的检测效果较差,无法满足 PCB 表面缺陷快速检测需求;5)ShuffleNetV2 模型因提高了网络的并行性,具有较快的推理速度。但模型浮点数运算量偏高,提高了模型对算力的依赖,ShuffleNetV2 模型对于精度与速度的平衡较差;6)相比于原始的 PPLCNet 而言,本文虽然稍微提高了模型的复杂度,但模型的检测速度没有过多的降低且效果更为优良。

### 2.3 消融实验

本文模型的改进点主要在于改进后的 PPLCNet 主干网络模型、G4Head 高耦合特征融合结构以及 SIOU 损失函数。为评估算法改进点的效果,采用 DeepPCB 数据集进行消融实验。

表 2 消融实验结果表

| DSC | HECA | G4Head | Focus | SIOU | P/%  | R/%  |
|-----|------|--------|-------|------|------|------|
| ✓   |      |        |       |      | 90.2 | 87.5 |
| ✓   | ✓    |        |       |      | 88.3 | 87.9 |
| ✓   | ✓    | ✓      |       |      | 88.5 | 88.7 |
| ✓   | ✓    | ✓      | ✓     |      | 88.6 | 89.3 |
| ✓   | ✓    | ✓      | ✓     | ✓    | 91.1 | 92.1 |
| ✓   | ✓    | ✓      | ✓     | ✓    | 91.5 | 92.3 |

由表 2 可知:1)将特征提取中的 DSC 模块引入 Dropout 机制后,提高了模型的全局特征学习能力,故召回率提高了 0.4%;2)在主干网络最深层引入注意力机制后,加强了模型对高维语义信息的关注度,模型召回率进一步提升至 0.887;3)四尺度耦合特征融合网络强化了模型的定位能力,且提高了主干网络对特征融合的贡献度,准确率提高了 0.2%、召回率提高了 0.8%;4)采用 Focus 作为网络第 0 层,有效保留了边缘位置信息和小目标细节信息,提高了定位能力,因此模型的确率提高了 2.5%,召回率提高了 2.8%;5)以 SIOU 损失函数作为目标框回归函数,降低了网络在训练过程中的自由度,网络收敛效果更好,准确率提升至 0.915,消融实验证明了本文提出的改进点可以有效地解决 PCB 表面缺陷检测过程中定位难、检测速度慢、精度差等不足。

### 2.4 微服务部署以及模型检测结果

本文采用 Flask 微服务方式进行封装。通过物联网设备进行数据采集,将采集到的被检测对象通过无线网传输至后端,当后端收到请求时,调用本地模型进行计算。在计算完成后,响应请求并返回结果。此方法避免了本地设备同时进行采集、检测,对于检测速度的限制。根据统计,本文设计的前后端分析系统平均检测时间可达 0.012 s,能较好地满足工业检测所需实时性。微服务系统本地端界面如图 11(a)所示,图 11(b)为 DeepPCB 数据检测效果图,图 11(c)为北京大学 PCB 表面缺陷检测效果图。从图中可以看到,模型对于多类别 PCB 表面缺陷可以实现较为精准地检测。

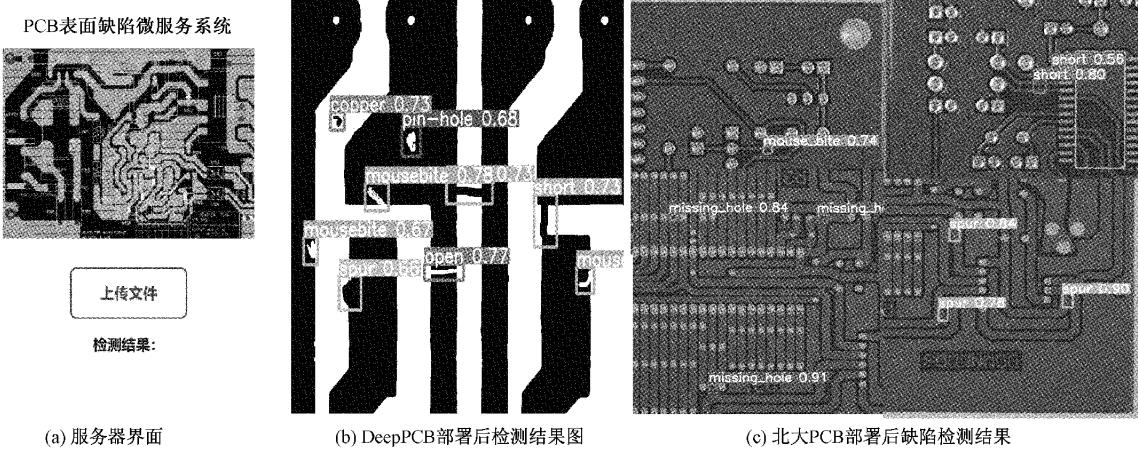


图 11 微服务界面以及检测结果

### 3 结 论

针对现行 PCB 表面缺陷检测方法检测速度慢、精度差等问题,本文提出了一种新的网络 PPLCFaster-YOLOv5。该模型的主干网络结合 ShuffleNetV2、EfficientNet 等轻量化网络的核心思想进行优化,有效提高网络训练速度与学习能力间的平衡。提出低参数量残差特征融合网络 G4Head,将更为浅层的信息加入特征融合中,提高了模型对各类缺陷的定位能力;通过残差连接,提高了主干网络各阶段信息对特征融合结构的贡献度。以 SIOU 作为目标框回归函数避免了模型在训练过程中出现发散等情况,加速了模型的收敛。实验证明,本文模型相比多个主流模型在速度与精度上取得了更好地平衡,且改进后的模型有效解决了 PCB 表面缺陷检测速度慢、精度差等问题。将模型采用 Flask 微服务方式进行部署后,将数据采集与目标检测拆进行分离,便于模型在边缘设备被调用。后续工作将继续收集更多 PCB 相关缺陷,强化模型的检测能力,并尝试进行 DSP、FPGA 等边缘设备进行部署,进一步降低离线检测的成本。

### 参考文献

- [1] 李闻,李小春,闫昊雷. 基于改进 YOLO v3 的 PCB 缺陷检测[J]. 电光与控制,2022,29(4):106-111.
- [2] LI W T, YANG J J, LYU X J, et al. A new path planning method for flying probe test arms[C]. 2020 Chinese Control And Decision Conference (CCDC), 2020: 1552-1556.
- [3] 李小敏,陈铸,李恒,等. PCB 基板玻璃表面缺陷检测设备控制系统设计[J]. 现代制造工程,2022(2):124-128.
- [4] 陈艳丽,刘静,杨树蔚,等. 小型 PCB 焊接图像采集系统设计[J]. 国外电子测量技术,2022,41(4):106-111.
- [5] 李澄非,蔡嘉伦,邱世汉,等. 基于改进 YOLOv4 算法的 PCB 缺陷检测[J]. 电子测量技术,2021,44(17):146-153.
- [6] 董静毅,吕文涛,包晓敏,等. 基于机器视觉的 PCB 板表面缺陷检测方法研究进展[J]. 浙江理工大学学报(自然科学版),2021,45(3):379-389.
- [7] ARDHY F, HARIADI F I. Development of SBC based machine-vision system for PCB board assembly Automatic Optical Inspection[C]. 2016 International Symposium on Electronics and Smart Devices (ISESD), 2016:386-393.
- [8] WANG X Y, ZHANG Z, XU Y F, et al. Real-time minor defect recognition of pseudo-terahertz images via the improved YOLO network[C]. 2021 International Conference on Sensing, Measurement & Data Analytics in the era of Artificial Intelligence(ICSMD), 2021:1-6.
- [9] RAN G Z, LEI X, LI D S, et al. Research on PCB defect detection using deep convolutional neural network[C]. 2020 5th International Conference on Mechanical, Control and Computer Engineering (ICMCCE), 2020:1310-1314.
- [10] YOU S S. PCB defect detection based on generative adversarial network [C]. 2022 2nd International Conference on Consumer Electronics and Computer Engineering(ICCECE), 2022:557-560.
- [11] 曾凯,李响,贾建梅,等. 基于 YOLOv3-spp 的缺陷检测优化模型[J]. 计算机系统应用,2022,31(2):213-219.
- [12] 陈仁祥,詹贊,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.
- [13] ZHOU L J, LING X F, ZHU S, et al. An self-supervised learning & self-attention based method for defects classification on PCB surface images[C]. 2021 2nd International Conference on Electronics, Communications and Information Technology (CECIT), 2021:229-234.
- [14] 刘钊,孙洁婷,温江涛. 基于多层面压缩深度神经网络的轴承故障诊断[J]. 电子测量与仪器学报,2022,36(7):189-198.
- [15] 万伟彤,李长峰,朱华波,等. 轻量化 CenterNet 网络的二维条码定位算法[J]. 电子测量与仪器学报,2022,36(5):128-135.
- [16] 王恒涛,张上,张朝阳,等. 基于 YOLOv5 的轻量化 PCB 缺陷检测[J]. 无线电工程, 2022, 52(11):2094-2100.
- [17] 伍济钢,成远,邵俊,等. 基于改进 YOLOv4 算法的 PCB 缺陷检测研究[J]. 仪器仪表学报,2021,42(10):171-178.
- [18] 崔昊杨,张雨阁,张驯,等. 基于边缘轻量级网络的电力仪表设备检测方法[J]. 电网技术,2022,46(3):1186-1193.
- [19] CUI C, GAO T Q, WEI S Y, et al. PP\_LCNet: A lightweight CPU convolutional neural network [J]. ArXiv Preprint,2021,ArXiv:2109.15099.
- [20] JOCHER G. YOLOV5, 2020. [J/OL]. Available: <https://github.com/ultralytics/yolov5>, DOI: 10.5281/zenodo.4154370.
- [21] TAN M X, PANG R M, LE Q V. EfficientNet: Rethinking model scaling for convolutional neural networks[C]. Proceedings of the 36<sup>th</sup> International Conference on Machine Learning,2020:10778-10787.
- [22] WANG Q, WU B G, ZHU P F, et al. ECA-Net:

- Efficient channel attention for deep convolutional neural networks[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 11531-11539.
- [23] 陈晓乐,杨瑞峰,郭晨霞. 基于改进低秩表示模型的光纤环缺陷检测[J]. 激光与光电子学进展, 2022, 59(22):8, DOI:10.3788/LOP202259.2215008.
- [24] GEVORGYAN Z. SIOU loss: More powerful learning for bounding box regression[J]. Arxiv Preprint, 2022, Arxiv: 2205.12740.
- [25] TANG S L, HE F, HUANG X L, et al. Online PCB defect detector on a new PCB defect dataset[J]. Arxiv Preprint, 2019, Arxiv: 1902.06197.
- [26] 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): 110-116.
- [27] HAN K, WANG Y, TIAN Q, et al. GhostNet: More features from cheap operations[C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2020:1580-1589.
- [28] HE K, ZHANG X, REN S, et al. Spatial pyramid pooling in deep convolutional networks for visual recognition[J]. IEEE Transcations on Pattern Analysis and Machine Intelligence, 2015, 37(9):1904-1916.
- [29] WOO S, PARKA J, LEE J, et al. CBAM: Convolutional block attention module[J]. European Conference on Computer Vision, 2018, 11211:3-19.
- [30] REDMON J, FARHADI A. Yolov3: An incremental improvement [J]. ArXiv Preprint, 2018, Arxiv: 1804.02767.
- [31] BOCHKOVSKIY A, WANG C Y, LIAO H. YOLOv4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, ArXiv: 2204.10934.
- [32] REN S, HE K, GIRSHICK R, et al. Faster R-CNN: Towards real-timeobject detection with region proposal networks[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2016, 39(6):1137-1149.
- [33] MA N, ZHANG X, H, ZHENG H T, et al. ShuffleNet V2: Practical guidelines for efficient CNN architecture design[C]. Proceedings of the European Conference on Computer Vision(ECCV), 2018:116-131.

### 作者简介

**季堂煜**,硕士研究生,主要研究方向为缺陷检测、电路设计等。

E-mail:2114708489@qq.com

**赵倩**(通信作者),博士,副教授,主要研究方向为图像检测与识别、视频图像、基于 FPGA 数字系统设计。

E-mail: zhaoqian@shiep.edu.cn

**赵琰**,博士,副教授,主要研究方向为数字图像处理,信息安全。

E-mail: yanzhao79@hotmail.com

**余文涛**,硕士研究生,主要研究方向为行人重识别。

E-mail:3107865834@qq.com

**梁爽**,硕士研究生,主要研究方向为电力目标巡检。

E-mail:2315410760@qq.com