

DOI:10.19651/j.cnki.emt.2313270

# 基于改进 YOLOv5 的印刷电路板缺陷检测\*

李大华<sup>1</sup> 徐傲<sup>1</sup> 王笋<sup>2</sup> 李栋<sup>1</sup> 于晓<sup>1</sup>

(1.天津理工大学电气工程与自动化学院 天津 300380; 2.天津鸿磁速保科技有限公司 天津 300400)

**摘要:**为解决印刷电路板缺陷检测中缺陷类别易混淆,缺陷目标微小难以检测的问题,提出了一种改进的 YOLOv5 检测模型。在骨干网络引入 Swin-Transformer 架构,获取局部和全局信息的多尺度特征。增加一个针对小目标的预测特征层,新的多尺度特征融合和检测结构使模型学习更加全面的特征信息。使用 ECIoU\_Loss 作为损失函数,实现电路板缺陷检测速度和准确率协同优化。实验结果表明,改进后的 YOLOv5 模型在 PCB Defect 数据集上的平均准确率为 98.7%,达到了 99.7% 的预测精确率和 97.4% 的召回率,比当前主流的检测模型性能更优越,改进后的 YOLOv5 模型能更有效的对电路板缺陷进行分类和定位。

**关键词:**印刷电路板;Swin Transformer;YOLOv5;ECIoU;缺陷检测

**中图分类号:** TP391.9 **文献标识码:** A **国家标准学科分类代码:** 520.60

## Printed circuit board defect detection based on improved YOLOv5

Li Dahua<sup>1</sup> Xu Ao<sup>1</sup> Wang Sun<sup>2</sup> Li Dong<sup>1</sup> Yu Xiao<sup>1</sup>(1. School of Electrical Engineering and Automation, Tianjin University of Technology, Tianjin 300380, China;  
2. Tianjin Hongci Subao Technology Co., Ltd., Tianjin 300400, China)

**Abstract:** To address the challenges of confusion among defect categories and the difficulty in detecting small defect targets in printed circuit board defect detection, an improved YOLOv5 detection model was proposed. The Swin-Transformer is incorporated into the backbone network to extract multi-scale features, capturing both local and global information. A prediction feature layer is added specifically for small targets, and the new multi-scale feature fusion and detection structure enable the model to learn more comprehensive feature information. The ECIoU\_Loss is employed as the loss function, facilitating collaborative optimization between detection speed and accuracy in circuit board defect detection. Experimental results demonstrate that the improved YOLOv5 model achieves a mean average precision of 98.7% on the PCB Defect dataset, with a precision of 99.7% and a recall of 97.4%. These performance metrics outperform current mainstream detection models, showcasing the improved YOLOv5 model's effectiveness in classifying and localizing circuit board defects.

**Keywords:** printed circuit board; YOLOv5; Swin Transformer; ECIoU; detected defects

## 0 引言

印刷电路板(printed circuit boards, PCB)是组装电子零件用的关键互连件,在绝大多数电子设备及产品中起着至关重要的作用。PCB 及其上焊接的组件的质量与产品性能,保证了电子产品的质量。PCB 的缺陷检测成为了现在电子产品行业中不可或缺的一环<sup>[1]</sup>。

传统的 PCB 缺陷检测方法因其存在诸多局限性,如速度慢、成本高、难推广等,已经不能满足现代化生产的需求。随着深度学习的日益发展,深度学习算法在自动提取特征

和识别方面表现出良好的性能,逐渐被用于 PCB 的缺陷检测中。Ding 等<sup>[2]</sup>提出一种基于 Faster R-CNN 的微小缺陷检测网络(TTD-net),通过 K-means 算法针对缺陷目标设计合理的 anchor(152、252、402、602、802),同时利用特征金字塔网络(feature pyramid network, FPN)从不同层次加强了特征图的关系,实验表明,该方法准确率较高,可移植性较好。Kim 等<sup>[3]</sup>提出了一种基于跳跃连接的卷积编码网络,从缺陷图像中解码出原始图像。然后将其与输入图像进行比较,从而定位缺陷。刘涛等<sup>[4]</sup>提出一种基于 YOLOv4 的 PCB 表面焊点检测算法,采用轻量化网络

收稿日期:2023-04-04

\* 基金项目:国家自然科学基金(61502340)、天津市自然科学基金(18JCQNJC01000)、天津理工大学教学基金(YB20-05)、天津市复杂系统控制理论与应用重点实验室开放基金(TJKL-CATCS-201907)项目资助

GhostNet 作为主干网络,对印刷电路板表面的常见缺陷进行精确检测和快速分类。Shen 等<sup>[5]</sup>提出了一种 LD-PCB 的缺陷检测模型和一种 CR-PCB 的字符检测模型,结合两种模型实现了工业生产中的缺陷检测和字符识别等功能。实验结果表明,该方法可以有效检测 PCB 组件上的缺陷。陈仁祥等<sup>[6]</sup>提出基于多注意力 Faster RCNN 的印刷电路板缺陷检测方法,在特征提取和特征融合部分引入注意力机制以获得具有抗干扰能力的特征表示,在不同程度噪声干扰下的 PCB 缺陷检测上表现良好。

尽管已经许多先进的模型和算法被提出,但是对于 PCB 的缺陷检测,仍有难以避免的问题:

1)小目标问题;PCB 上的缺陷及一些元器件都是极小的,而当前目标检测算法大多针对大、中目标,对小目标的检测精度不高。

2)缺陷相似;在实际生产中,由于造成不同缺陷产生的生产工艺可能是相同的,导致不同缺陷间的特征相似,导致模型训练困难,泛化性较差。

为此,提出一种基于 YOLOv5 (you only look once version 5)的 YOLOv5-HSTE 的电路板缺陷检测模型:

1)将 Swin-Transformer 引入到 YOLOv5 中的骨干网络中,增强骨干网络对全局信息的提取能力,使其具有准确定位高密度场景中目标的能力;

2)在 YOLOv5 特征提取瓶颈层,新增一个预测特征层,针对小目标进行特征提取;

3)使用 ECIoU 损失函数,在训练过程中自适应调整计算梯度,加快了边界框回归损失的收敛速度。

## 1 相关工作

YOLO 算法作为单阶段目标检测的代表性方法,其直接对锚点框进行分类和回归,具有更快的推理速度。YOLOv2<sup>[7]</sup>、YOLOv3<sup>[8]</sup>、YOLOv4<sup>[9]</sup>和 YOLOv5(<https://github.com/ultralytics/yolov5>)的相继提出,在工业领域广泛应用。苏佳等<sup>[10]</sup>提出了基于改进 YOLOv4 的 YOLO-J 缺陷检测算法,利用注意力机制和 PANet 结构,增强了模型对小目标特征的提取能力。Lu 等<sup>[11]</sup>提出一种 Swin-T-YOLOv5 模型,针对不同成熟期的葡萄进行检测。Xiao 等<sup>[12]</sup>设计了基于 YOLOv5s-GTB 的检测模型,引入 Transformer 和双向特征金字塔网络(Bi-directional feature pyramid network, BiFPN),对桥梁裂缝这种小目标而言在精度方面明显优于原始模型。

YOLOv5 目前在速度和准确性方面具有显著优势,重要模块包括 CSPBottleneck, SPPF 和 PANet。主干网络为 CSPDarknet53,其结构由多个残差网络堆叠在一起,其中卷积层的激活函数是 SiLU<sup>[13]</sup>。YOLOv5 使用 PANet 作为模型的颈部,输入是从主干输出的特征图,利用特征融合丰富语义特征,发送到头部进行检测。在特征提取方面,基于 FPN 对 PANet 结构进行了改进,不仅传达了语义信息,

还传达了位置信息。在 FPN 结构中添加了自下而上的金字塔,以将强定位特征从下层传递到上层,从而实现了 FPN 特征融合的补充。

作为一级探测器的代表性方法,YOLO 系列一直保持着精度和效率的特点。而 YOLOv5 是 YOLO 系列的较新的解决方案,在许多工业场景下都得到了广泛的应用。YOLOv5 有 4 种不同的型号,包括 YOLOv5s, YOLOv5m, YOLOv5l,和 YOLOv5x。YOLOv5s 在兼顾速度和准确性的同时,又是最为轻型的网络,因此,本文最终选择使用 YOLOv5s 作为基准模型构建了 YOLOv5-HSTE。

## 2 YOLOv5\_STE 的网络结构模型

### 2.1 改进 YOLOv5 整体结构

为了提高语义可分辨性和缓解全局类别混淆,可以从更大的邻域中收集和关联场景信息,来学习不同缺陷类型之间的差别。而对于卷积神经网络而言,卷积操作的局限性限制了模型获取全局上下文信息的能力。相比之下,Transformer 模型能够从全局的角度关注图像特征之间的依赖性。另一方面,在工业检测过程中,检测的准确性占据十分重要的地位。通过增加一个针对微小缺陷检测的预测头,结合网络其他的预测头,在多尺度特征融合方法实下缓解由于缺陷尺度变化带来的负面影响。最后使用 ECIoU\_Loss (enhanced-competioIoU Loss),取代单独使用 CIoU\_Loss 因为纵横比是相对值导致的模型优化困难,以及单独使用 EIoU 时 transformer 架构前期收敛困难的局限。改进后的 YOLOv5-HSTE 的结构如图 1 所示。

### 2.2 Swin-Transformer

由于卷积神经网络通常难以学习到背景和小目标缺陷之间的关联,导致在复杂背景中更难以识别缺陷特征。受 Transformer<sup>[14]</sup>的启发,在 YOLOv5 的骨干网络中引入 Swin-Transformer<sup>[15]</sup>架构,利用其学习全局和部分特征关联的能力突出小目标的缺陷特征,同时结合 CNNs 在提取潜在视觉特征方面的优势,在更大的邻域内收集与缺陷特征相关的信息,提高检测的准确性。

Swin-Transformer 基于具有全局信息建模能力的 Transformer 层次化构建特征图,同时借鉴 locality 思想将自注意力计算限制在不重合的窗口区域内并进行跨窗口的特征交互,保证了对图像大小的线性计算复杂度,可以灵活对全局、局部或上下文信息进行编码,图 2 所示为 Swin-Transformer 整体结构,图 3 所示为 Swin-Transformer block 结构。

将原始 YOLOv5 中骨干网络的第 6、8 层的 C3 结构替换为 Swin-Transformer,形成新的特征提取网络。由于替换的 C3 结构输出特征图的大小分别为  $40 \times 40$  和  $20 \times 20$ ,在此分辨率上应用 Swin-Transformer 可以减少将整个骨干网络替换的计算量,这种集成方式弥补了单一使用 CNN

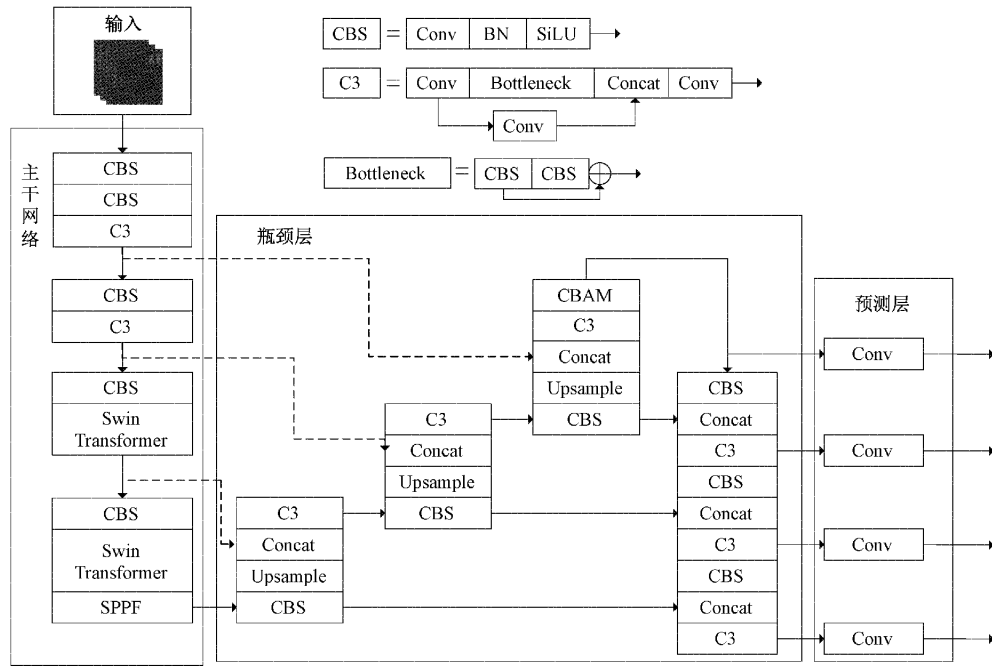


图 1 改进的 YOLOv5-HSTE 整体结构




图 2 Swin-Transformer 结构

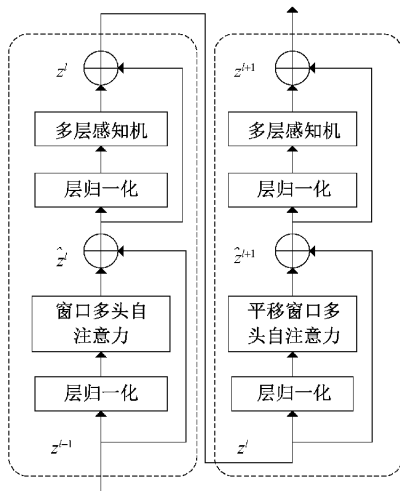


图 3 Swin-Transformer block 结构

提取特征时由于感受野的限制而难以捕获全局信息的缺点。本文提出的新的骨干网络结合了 YOLOv5s 和 Swin-Transformer,使其同时具有保留全局和局部特征的优点,

这种结合对 PCB 表面缺陷的提取更为有效,同时自注意力机制也一定程度上提高了模型的检测精度。

### 2.3 小目标预测特征层

对于 PCB 表面可能产生的不同种类的缺陷,它包含许多非常小的目标,原始 YOLOv5 使用 3 个不同尺度的预测特征图检测目标,对于 PCB 的表面缺陷而言,不能充分利用网络的浅层信息,导致部分目标缺陷的特征信息丢失,因此本文增加了一个预测头来检测微小物体。利用从主干网络中提取浅层信息,并利用双向金字塔结构将其和深层特征信息进行特征融合,在原 YOLOv5s 的特征金字塔中,增加一个 CBS+C3+CBAM 组成的特征融合层,从而得到一个新的预测头的输出。新的四检测结构可以缓解由于尺度变化带来的负面影响,改进后的多尺度融合能够从浅层网络中学习更好的位置特征信息。本文添加的预测头(head No. 1)是从 backbone 中的浅层网络中提取的分辨率更高特征图,由于其拥有更大的感受野,因此对微小物体的检测更敏感。增加一个额外的检测头后,虽然计算量和内存成本增加了,但微小物体检测的性能得到了很大的提升<sup>[16]</sup>。

## 2.4 改进的损失函数

在YOLOv5中,使用CIoU(complete-IoU Loss)作为模型的损失函数,公式如下:

$$CIoU\_Loss = 1 - IoU + \frac{\rho^2(b^{gt}, b)}{c^2} + \alpha\nu \quad (1)$$

$$IoU = \frac{A \cap B}{A \cup B} \quad (2)$$

$$\alpha = \frac{\nu}{(1 - IoU) + \nu} \quad (3)$$

$$\nu = \frac{4}{\pi^2} \left( \arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (4)$$

其中,  $IoU$  表示预测框与真实框之间面积的交并比。 $\frac{\rho^2(b^{gt}, b)}{c^2}$  表示预测框和真实框中心点之间的距离,  $\alpha$  是用于平衡比例的权重函数,  $\nu$  用于衡量宽高比的一致性。

由公式中  $\alpha$  的定义可以看出, 损失函数更倾向于往重叠区域增多的方向优化<sup>[17]</sup>, 且预测框的宽度和高度不能在回归期间同时增加或者减少, 这就导致一旦预测框和边界框是等比缩放的时候, CIoU 有时会阻止模型的优化。损失函数 EIoU 在 CIoU 的基础上拆分了  $\alpha$ , 计算预测框和真实框的长度和宽度, 解决 CIoU 存在的问题。EIoU\_Loss 公式如下:

$$EIoU\_Loss = 1 - IoU + \frac{\rho^2(b^{gt}, b)}{c^2} + \frac{\rho^2(h^{gt}, h)}{c_h^2} + \frac{\rho^2(w^{gt}, w)}{c_w^2} \quad (5)$$

其中,  $\frac{\rho^2(h^{gt}, h)}{c_h^2}$  表示预测框和真实框的高度之差,  $\frac{\rho^2(w^{gt}, w)}{c_w^2}$  表示预测框和真实框的宽度之差。

当待检测目标存在距离相对远的边缘时, 只使用 EIoU 计算损失函数不仅没有早期收敛, 还会使得计算变慢。因此本文提出使用 ECIoU\_Loss 作为损失函数, 先使用 CIoU 损失函数进行计算, 当它收敛到合适的范围时, 再利用 EIoU 损失函数对缺陷边缘进行细微调整<sup>[18]</sup>。ECIoU\_Loss 公式如下:

$$ECIoU\_Loss = 1 - IoU + \alpha\nu + \frac{\rho^2(b^{gt}, b)}{c^2} + \frac{\rho^2(h^{gt}, h)}{c_h^2} + \frac{\rho^2(w^{gt}, w)}{c_w^2} \quad (6)$$

## 3 实验及结果分析

### 3.1 实验环境及数据

本实验在 Windows10 操作系统下, 硬件配置为 Intel(R) Core(TM) i5-11260H@2.60 GHz, 机带 RAM 为 16 GB, Nvidia Geforce RTX 3060, 显存 8 GB 的笔记本电脑上进行, 所使用的 Pytorch 版本为 1.12.1, CUDA 版本为 11.3。

实验所使用的数据集是北京大学智能机器人开放实验室公开的印刷电路板 (PCB) 瑕疵数据集 [https://robotics.pkusz.edu.cn/resources/dataset/], 其 6 种缺陷类型分别为: 漏孔 (missing hole)、鼠咬 (mouse bite)、开路 (open circuit)、短路 (short)、杂散 (spur)、余铜 (spurious copper), 共包含 1 386 张图片, 其中每张图片均由 xml 文件给出其图片大小、缺陷位置和类别。为了模型训练后更好的泛化性, 对数据集进行扩充, 并按照 8:2 的比例随机划分训练集+验证集。扩充后划分数据集的结果如表 1 所示。

表 1 数据集划分

缺陷类型	训练集	验证集	总和
漏孔	924	232	1 156
鼠咬	926	231	1 157
开路	923	230	1 153
短路	922	231	1 153
杂散	924	234	1 158
余铜	925	228	1 153
总和	5 544	1 386	6 930

在本实验中, 模型使用随机梯度下降 (stochastic gradient descent, SGD) 作为优化器对进行训练, 默认权重衰减系数为 0.000 5, 动量为 0.937, 设置 batchsize 为 8。使用预热方法来初始化学率。在模型训练的初始阶段, 进行 3 个 epoch 的预热训练, SGD 优化器的动量设置为 0.8。在预热阶段结束后, 初始学习率为 0.01, 并采用余弦退火的方法更新学习率。最后, 模型一共进行 300 个 epoch 训练。

### 3.2 评价标准

在本实验中, 采用精度 (precision, P)、召回率 (recall, R) 和平均精度均值 (mean average precision, mAP@0.5) 和 mAP@0.5:0.95 等客观评价标准来评估训练后的 PCB 缺陷检测模型的性能。计算公式如下:

$$P = \frac{TP}{TP + FP} \quad (7)$$

$$R = \frac{TP}{TP + FN} \quad (8)$$

$$mAP = \frac{\sum AP}{C} \quad (9)$$

其中,  $TP$  表示正确识别的缺陷的数量;  $FP$  表示为错误识别缺陷的数量;  $FN$  表示未识别到缺陷的数量;  $C$  表示缺陷的类别数目。AP 是平均精确度 (average precision), 其值为 P-R 曲线下方的面积。mAP@0.5 是指将 IoU 设为 0.5 时, 求得的所有类别的平均精确度, mAP@0.5:0.95 是指在不同的 IoU 阈值 (从 0.5~0.95, 步长为 0.05) 上的平均 mAP。

### 3.3 实验结果

实验结果如表 2 和图 4 所示,使用相同的数据集和超参数训练 YOLOv5s 和 YOLOv5-HSTE,使用训练期间存储的数据进行计算。可以看出改进后的模型从准确率、召回率和 mAP@0.5 都有不同程度的增加,分别为 2.8%、5%和 5.9%,由于 mAP@0.5:0.95 有着较高的 IOU 阈值要求,常被用来表示模型的定位和边界回归的能力,而改进后模型增加了 10.9%,这表明了改进后的模型极大增强了网络回归到目标边界的能力。从表 2 可以看出, YOLOv5-HSTE 的参数和模型大小都有小幅度增加,计算量 GFLOPs 增大了 3 倍,但是检测速度只相差了 6.5 fps,表明虽然改进措施增加了网络的计算量,但是并不会严重影响模型的检测速度,改进后模型仍然能实现检测的实时性。

表 2 模型复杂度比较

模型	参数量	运算能力	大小	FPS
YOLOv5s	7 026 307	15.8	14.2	71.4
YOLOv5-HSTE	7 890 094	48.7	16.6	64.9

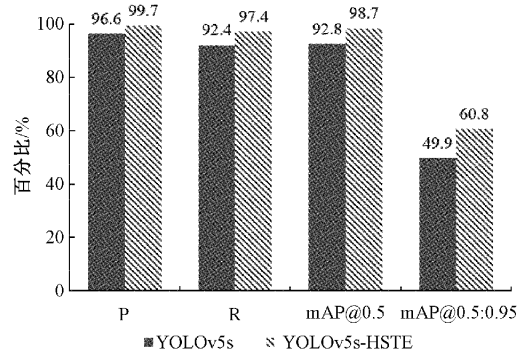


图 4 模型精度比较

### 3.4 消融实验


基于 YOLOv5 设置 4 组消融实验,每组实验都采用相同的超参数和训练方法,进一步验证每种方法的有效性,确认本文提出的方法的检测性能。模型 1 是未改动的 YOLOv5s 模型。模型 2(YOLOv5\_H)在原始网络中增加了一个预测特征层。模型 3(YOLOv5\_HST)基于模型 2 在骨干网络中引入 Swin-Transformer 架构。模型 4 (YOLOv5-HSTE)在模型 3 的基础上使用 ECIoU 损失函数。消融实验结果如表 3 和图 5 所示。

表 3 消融实验结果


模型	改进方法 1	改进方法 2	改进方法 3	精确率	召回率	平均精度均值@0.5	平均精度均值@0.5:0.95
模型 1	—	—	—	0.969	0.924	0.928	0.499
模型 2	✓	—	—	0.963	0.953	0.963	0.531
模型 3	✓	✓	—	0.981	0.958	0.977	0.544
模型 4	✓	✓	✓	0.997	0.974	0.987	0.608

根据表 3 和图 5 的数据可以看出,在模型 2 中新增一个预测特征层后,R 和 mAP 都有较为明显的提升,但是 P 下降了 0.6%,证明了新增预测特征层,对缺陷特征的检测起到积极作用。在模型 3 中引入 Swin-Transformer 架构后,P 提高了约 1%,并在模型 2 的基础上小幅提高了 R 和 mAP,证明了 Swin-Transformer

对缺陷目标的特征提取更清晰,但网络收敛速度较慢,在网络训练前期出现收敛困难的情况。YOLOv5-HSTE 在改变损失函数后,mAP 提高了 1%,召回率也达到了 97.4%,证明 ECIoU\_Loss 成功增强了网络的学习能力,加速了模型前期的收敛速度,充分应用了改进后损失函数的优势。



(a) 训练集损失对比



(b) 验证集损失对比

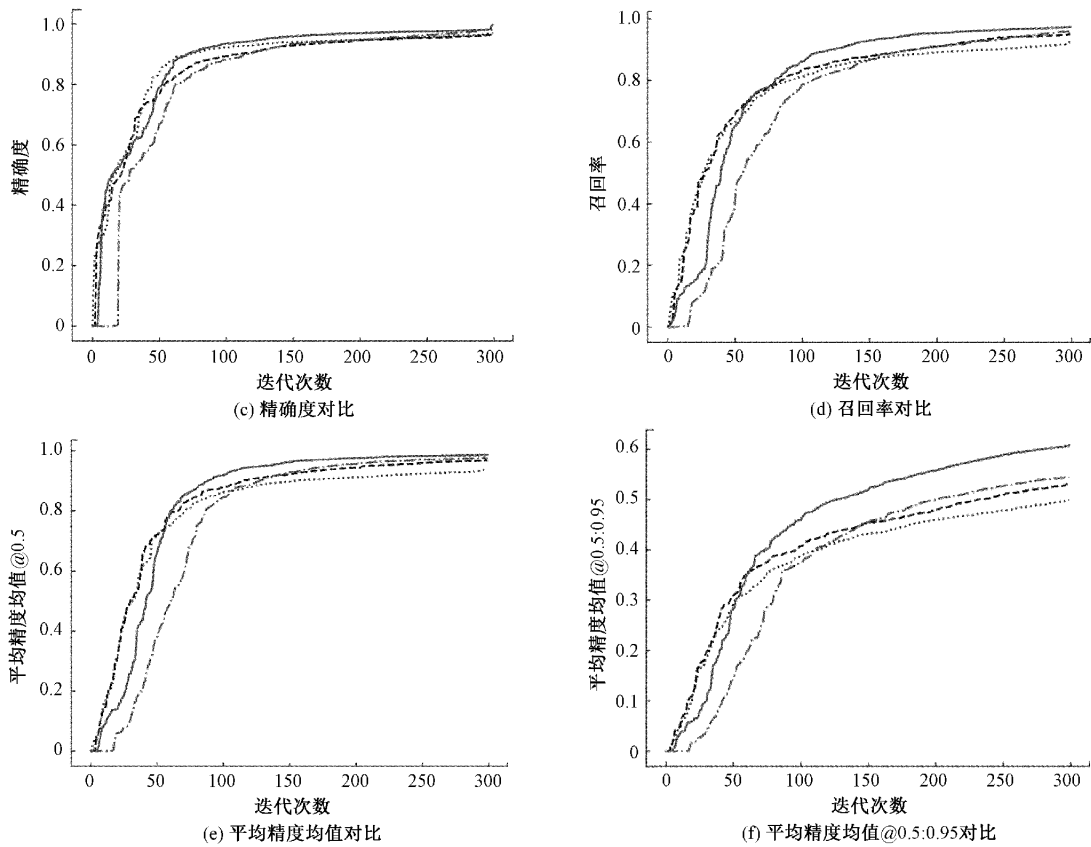


图5 消融实验中不同模型损失及精度对比

### 3.5 结果对比

将本文的方法与其他目标检测网络的平均精度均值(mAP@0.5)进行比较,结果如表4所示。

表4 文中算法和不同网络模型检测精度对比

算法	平均精度均值@0.5
Faster RCNN <sup>[19]</sup>	0.812
TDD-Net <sup>[2]</sup>	0.942
SSD <sup>[20]</sup>	0.803
YOLOv3	0.758
YOLOv4 <sup>[21]</sup>	0.796
YOLOv5s	0.928
CenterNet <sup>[22]</sup>	0.915
本文方法	0.987

将本文的方法与文献[23-25]使用的算法的平均精度均值(mAP@0.5)进行对比,结果如表5所示。


由表4可以看出,本文提出的方法相较于常用的目标检测网络具有更好的检测精度,表明本文提出的方案符合预期。由表5可以看出,与其他研究者提出的方案相比,本文提出的模型在检测精度上依然存在一定优势。

表5 本文方法和文献方法精度对比

算法	平均精度均值@0.5
文献[23]	0.967
文献[24]	0.966
文献[25]	0.983
本文方法	0.987

### 3.6 预测结果可视化

除了通过P、R以及mAP对YOLOv5-HSTE的检测效果进行定量比较外,还需比较每种缺陷类型的检测效果。其中,预测结果的可视化示例如图6所示,每种类别缺陷的检测精度如图7所示。如图6(a)所示,对于漏孔这种缺陷,模型可以精确地检测到。如图6(b)、(c)、(d)和(f)所示,虽然在不同缺陷间存在较为相似的特征,但是也成功检测到了所有的缺陷位置,实验结果表明,本方法具有较好的精度和鲁棒性。



(a) 漏孔

(b) 鼠咬

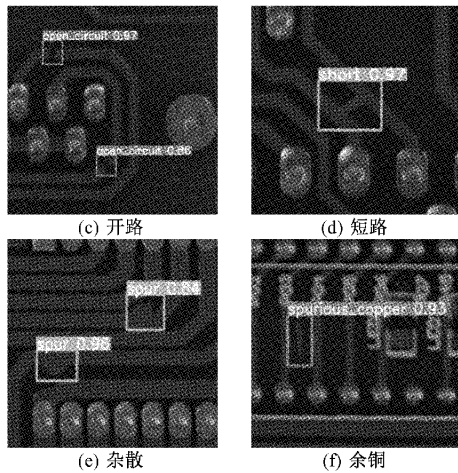


图 6 YOLOv5-HSTE 的检测性能




图 7 YOLO-HSTE 各类缺陷检测精度

#### 4 结 论

针对传统印刷电路板缺陷检测方法存在的漏检误检率高的特点,提出一种基于 YOLOv5-HSTE 的 PCB 缺陷检测方法。在设计网络架构时,利用 Transformer 捕获全局信息和丰富的上下文信息方面的优势,在骨干网络中加入 Swin-Transformer,在更大的邻域内收集与缺陷特征相关的信息。为了更好的检测微小的缺陷目标,引入一个新的预测特征层,利用更大的感受野更好地获取小目标的特征。使用 ECIUO<sub>L</sub>Loss 作为模型的损失函数,提高了模型的回归和定位能力。实验结果表明,所提出的 YOLOv5-HSTE 可以有效地实现对 PCB 板的缺陷识别与定位。在 PCB Defect 数据集上 mAP 达到了 98.7%,召回率达到 97.4%,检测速度为 65FPS。YOLOv5-HSTE 泛化能力强,检测精度高,检测速度快,相较于其他算法有一定优势,在工业应用领域也具有一定的实用价值。

#### 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.  
 [2] 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.

- [3] KIM J, KO J, CHOI H, et al. Defect detection using deep learning via a skip-connected convolutional autoencoder[J]. Sensors, 2021, 21(15):4968.  
 [4] 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.  
 [5] SHEN J Q, LIU N Z, SUN H. Defect detection of printed circuit board based on lightweight deep convolution network [J]. IET Image Processing, 2021, 18(2): 3932-3940.  
 [6] 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.  
 [7] REDMON J, FARHAD A. YOLO9000: Better, faster, stronger[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.  
 [8] REDMON J, FARHAD A. YOLOv3: An incremental improvement [J]. ArXiv Preprint, 2018, ArXiv: 1804. 02767.  
 [9] YU J, ZHANG W. Face mask wearing detection algorithm based on improved YOLO-v4[J]. Sensors, 2021, 21(9): 3263.  
 [10] 苏佳,贾欣雨,侯卫民. 基于 YOLO-J 的 PCB 缺陷检测算法[J]. 计算机集成制造系统, 2022(3): 1-20.  
 [11] LU S, LIU X, HE Z, et al. Swin-transformer-YOLOv5 for real-time wine grape bunch detection[J]. ArXiv Preprint, 2022, ArXiv: 2208. 14508.  
 [12] XIAO R Q. YOLOv5s-GTB: Light-weighted and improved YOLOv5s for bridge crack detection [J]. ArXiv Preprint, 2022, ArXiv: 2206. 01498.  
 [13] GUO Z, WANG C, YANG G, et al. MSFT-YOLO: Improved YOLOv5 based on transformer for detecting defects of steel surface[J]. Sensors, 2022, 22(9): 3467.  
 [14] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. Advances in Neural Information Processing Systems, 2017, 30.  
 [15] LIU Z, LIN Y, CAO Y, et al. Swin transformer: Hierarchical vision transformer using shifted windows[C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 10012-10022.  
 [16] ZHU X K, LYU S C, XU W, et al. TPH-YOLOv5: Improved YOLOv5 based on transformer prediction head for object detection on drone-captured scenarios [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2021: 2778-2788.  
 [17] 浦东,陈瑞,孔小红,等. 基于深度卷积网络的工程车辆

- 检测算法[J]. 南京工程学院学报(自然科学版), 2021,19(2):13-19.
- [18] CHEN X, LIAN Q, CHEN X, et al. Surface crack detection method for coal rock based on improved YOLOv5[J]. Applied Sciences, 2022, 12(19): 9695.
- [19] ZHU Y, SALAKHUTDINOV R, et al. Faster R-CNN: Towards real-time object detection with region proposal networks [C]. International Conference on Neural Information Processing Systems, 2015: 91-99.
- [20] ZHU Y, SALAKHUTDINOV R, et al. SegDeepM: Exploiting segmentation and context in deep neural networks for object detection[C]. IEEE Conference on Computer Vision and Pattern Recognition, 2015: 4703-4711.
- [21] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. YOLOv4: Optimal speed and accuracy of object detection[J]. Arxiv Preprint,2020, Arxiv: 2004. 10934.
- [22] LAW H, DENG J. CornerNet: Detecting objects as paired keypoints [J]. International Journal of Computer Vision, 2020, 128(3): 642-656.
- [23] 贺贤珍. 基于深度学习的焊点缺陷图像检测研究[D]. 绵阳:西南科技大学,2021.
- [24] 耿朝晖,龚涛. 基于改进 Faster R-CNN 的 PCB 板表面缺陷检测[J]. 现代计算机,2021(19): 89-93.
- [25] 钱万明,朱红萍,朱泓知,等. 基于自适应加权特征融合的 PCB 裸板缺陷检测研究[J]. 电子测量与仪器学报, 2022,36(10):92-99.

#### 作者简介

李大华,教授,硕士生导师,主要研究方向为图形图像处理、综合能源控制。

E-mail:lidah2005@163.com

徐傲(通信作者),硕士研究生,主要研究方向为目标检测、人工智能算法等。

E-mail:jszxza123@163.com