[文章编号] 1003－4684(2026)02-0024-06

基于 Ghost-YOLOv5 的 PCB 缺陷检测

刘 航，周先军

（湖北工业大学电气与电子工程学院，湖北 武汉 430068）

[摘 要] 针对现有 PCB 缺陷检测方法存在误检、漏检严重，模型参数量过大的问题，提出一种基于改进 YOLOv5 的 PCB 缺陷检测算法。首先使用轻量级网络 GhostNet 作为 YOLOv5 的主干网络，解决 YOLOv5 参数量过大的问题；其次设计了轻量加权双向特征金字塔网络（Light-BiFPN），对网络提取的深层特征与浅层特征进行有效融合；最后采用 K-means＋＋对 PCB 数据集聚类，解决初始先验框不适合的问题。实验结果显示：Ghost-YOLOv5 与原算法相比 mAP 提升 3%，达到 98.9%，模型参数量减少 47.91%，相比原算法具有一定优势。

[关键词] PCB 缺陷检测；YOLOv5；目标检测；深度学习

[中图分类号] TP391.4 [文献标识码] A

PCB 是印刷电路板的简称，作为电气连接的重要载体，广泛地应用于电子设备中。在生产制作过程中，工艺复杂繁琐且易受环境、设备等因素的影响，造成电路板存在断路、短路、漏孔、缺口、毛刺、余铜等缺陷。在 PCB 缺陷检测中存在着两种主要问题：1）PCB 缺陷多为小缺陷且种类多，检测困难；2）PCB 缺陷部分与非缺陷部分特征通常比较相似，难以分辨[1]。传统的 PCB 缺陷检测通常采用半自动与人工相结合的方式来进行检测，由于印刷电路板线路复杂，经常会出现漏检以及误检，检测的结果和精度与人的情绪和经验高度相关[2]。

随着神经网络的高速发展，研究人员提出各类基于机器视觉的 PCB 缺陷检测算法[3]，具有检测精度高、检测速度快、泛化能力强等优点，很快成为缺陷检测的热点。目前基于神经网络的目标检测主要有两类：一类是基于候选框的 Two-Stage 目标检测算法，包含检测与识别两个阶段[4]，此类算法的代表有 Mask R-CNN[5]、Fast R-CNN[6]、Faster R-CNN[7]等。优点是检测精度高，但网络模型大，检测速度慢，很难用到工业进行实时检测。另一类是 One-Stage 目标检测算法，这类算法将候选区域的特征提取与预测框的定位融合在一起，只需一次提取特征即可实现目标检测，如 YOLOv3[8]、YOLOv4[9]、YOLOv5、SSD[10]等。这类算法具有检测速度快、计算量小等优点，经常被用于实时检测。在双阶段检测算法中，耿朝晖[11]等使用 Res Net50 作为 Faster R-CNN 主干网络，同时将损失函数改为 focal loss，以增强检测效果，提高检测效率。胡江宇[12]等在 Faster RCNN 架构基础上，为能获得各类维度特征，通过 RPN 网络产生 ROI，同时为提升不规则缺陷特征的模仿能力，添加了过滤特征的金字塔网络。在单阶段检测算法中，苏佳[13]等用 Resnet 作为 YOLOv4 的特征提取网络，解决参数太多难以部署在移动端的问题，通过增加自注意力机制和改进 PANet 结构，提高对小目标的特征提取能力。Lan Z[14]等引入 MobileNet 来代替 YOLOv3 的主干网络，以获得轻量级网络，通过通道重组来改进 YOLOv3 的特征金字塔网络以获得更高的精度。

为解决 PCB 缺陷检测难度大，模型过大的问题，提出了一种改进 YOLOv5 的 PCB 缺陷检测算法。为获得更适用于 PCB 缺陷检测的先验框，使用 K-means＋＋聚类算法对标签数据进行聚类，生成符合本实验数据分布的初始 Anchor；为解决模型参数量过大，引入轻量级网络 GhostNet 作为主干网络，同时使用 Ghost 卷积代替普通卷积，以加快训练时间，实现在保证精度的同时减少计算量；提出一种 Light-BiFPN 网络代替 YOLOv5 的路径聚合网络，可以在提升特征提取的同时减轻模型复杂度；使用离线数据增强与在线数据增强来进行数据扩充，提高模型的泛化能力。

[收稿日期] 2023－05－18

[基金项目] 国家自然科学基金（61901165，61601177）；湖北省自然科学基金（2019CFB530）

[第一作者] 刘 航（1997－），男，河南开封人，湖北工业大学硕士研究生，研究方向为深度学习、目标检测。

[通信作者] 周先军（1970－），男，湖北武汉人，湖北工业大学副教授，研究方向为无线网络、移动通信。

1　YOLOv5 简述

YOLOv5 是一种单阶段目标检测算法，根据网络的深度与宽度可以分为 5 个版本，网络从大到小依次排序分别为 5x、5l、5m、5s、5n。YOLOv5s 网络参数量较少，并且能够在保证一定精度的同时，有非常快的检测速度，因此本文选择 YOLOv5s 作为基础网络进行改进。

YOLOv5s 网络由输入层、骨干网络、颈部网络和预测 4 个部分组成。输入层在 YOLOv5s 网络中负责数据训练前的预处理，具有自适应图片缩放和在线数据增强等功能。骨干网络负责特征提取，由 Focus 结构和跨阶段局部网络(Cross Stage Partial Network，CSPNet)组成。颈部网络主要负责特征的融合，由特征金字塔网络(FPN)和路径聚合网络(PANet)构成，将主干网络提取的深层的语义信息经过上采样与浅层提取的位置信息进行有效融合，以获得更加丰富的特征信息。预测部分由三个检测层构成，分别负责预测不同大小的目标。

2　Ghost-YOLOv5 算法

Ghost-YOLOv5 算法是基于 YOLOv5s 算法改进的，由轻量化的主干、采用 Light-BiFPN 的颈部以及负责预测的 YOLO head 构成，其总体结构如图 1 所示。

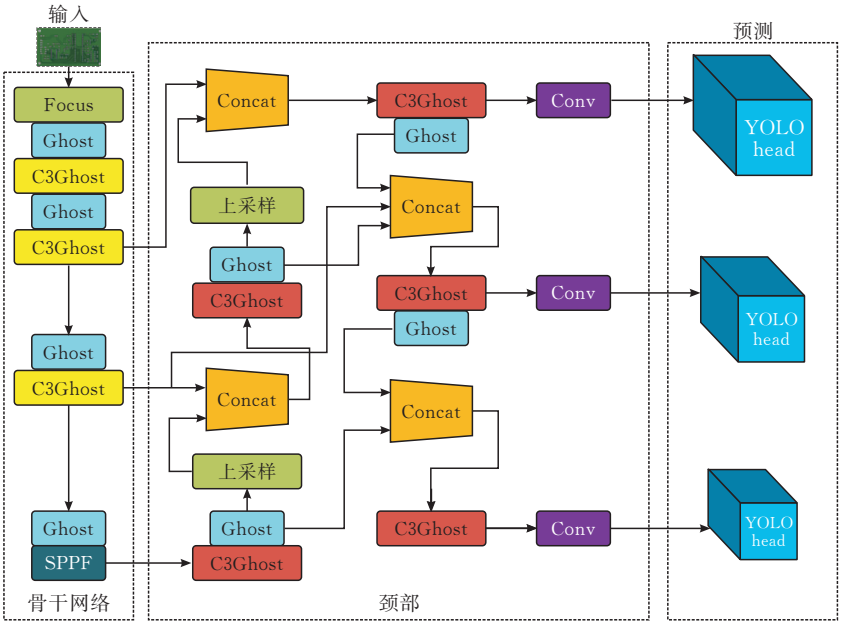


图 1　Ghost-YOLOv5 算法网络结构

2.1　引入 Ghost 模块改进主干网络

YOLOv5s 网络采用大量标准卷积，存在较多冗余特征图，导致计算量和参数量都较大。本文将采用 Ghost 卷积替代网络中的标准卷积，同时使用 GhostNet[15] 网络作为 YOLOv5s 主干网络。Ghost 模块是一种分阶段进行操作的模块，在非线性卷积的基础上进行一次线性卷积，可以使用更少的参数来提取更多的有效特征，从而通过减少模型的参数量来提高模型的检测速度。Ghost 模块将标准卷积分为两部分：

第 1 部分：先进行一次标准卷积，生成通道数较少的本征特征图(intrinsic feature maps)，目的是减少计算量，同时获取必要特征。

第 2 部分：将上一步得到的特征图经过深度可分离卷积得到 Ghost 特征图。最后将普通卷积生成的本征特征图与 Ghost 特征图进行拼接，得到输出特征图。Ghost 模块结构如图 2 所示。

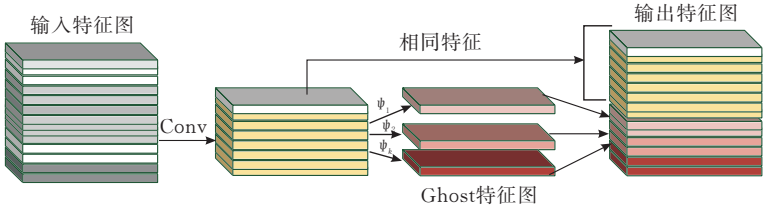


图 2　Ghost 模块

当输入特征图为 $h \times w$，通道数为 c，卷积核的大小为 $k \times k$，若输出特征图的尺寸为 $H \times W \times N$ 时，普通卷积的计算量为：

$$Y1 = k \times k \times c \times H \times W \times N \tag{1}$$

Ghost 模块的计算量为：

$$Y2 = H \times W \times c \times \frac{N}{S} \times k \times k + (S-1) \times H \times W \times \frac{N}{S} \times d \times d \tag{2}$$

两种卷积的计算量之比为：

$$Y3 = \frac{Y1}{Y2} = \frac{k \times k \times c}{c \times \frac{1}{S} \times k \times k + \frac{S-1}{c} \times d \times d} \approx \frac{S \times c}{S + c - 1} \approx S \tag{3}$$

式(2)中 S 表示线性变换操作的数量；d 表示深度可分离卷积的卷积核大小。由上式(3)得出，Ghost 模块与普通卷积相比可以有效实现计算量的减少与模型大小的压缩，使网络轻量化。

2.2 Light-BiFPN 网络

随着网络的不断加深，特征信息会出现一定的丢失。为提高网络模型的性能，多尺度特征融合经常被用在目标检测网络中。目前常用的多尺度特征融合网络包括特征金字塔网络(FPN)[16]、路径聚合网络(PANet)[17]、加权双向特征金字塔网络 BiFPN[18]等。FPN 引入了一条自顶向下的通道，融合深浅层的尺度特征；PANet 在 FPN 的基础上增加了一条自底向上的通道，如图 3a 所示；BiFPN 是一种加权的双向特征金字塔网络，如图 3b 所示，去掉了对跨尺度特征融合贡献小且只有一条输入的节点，简化了双向网络；在同尺度特征层中，原始节点和输出节点之间添加一条额外的边，以减轻在网络的深层容易造成特征丢失的问题，同时改变传统的叠加融合方式，引入一种加权融合机制，可以实现高效的双向跨尺度和加权特征融合。

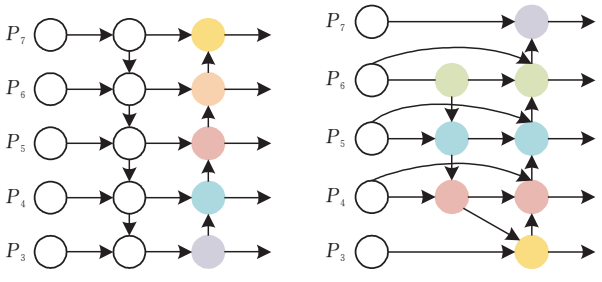


图 3 PANnet 与 BiFPN 网络

YOLOv5s 采用路径聚合网络(PANet)来实现上下层语义传递及融合，融合方式较为简单，仅仅是将不同层次的特征转化后相加，并不能很好地进行特征融合。本文针对 PCB 缺陷特征，提出一种基于 PANet 的 Light-BiFPN 网络，融合 BiFPN 的思想，删除没有参与特征融合的单输入节点，并在同一级别的输入与输出节点之间添加一条跳跃连接，在不增加计算成本的情况下，实现更多的特征融合，同时也可以更好地匹配 YOLO Head 的三个特征层。Light-BiFPN 网络不仅可以减少网络参数量，还能加速模型推理，有效提升小目标的表征能力。

2.3 先验框的优化设计

在 YOLOv5s 算法中，原先验框是在 COCO 数据集中使用 K-means 聚类算法得到的。而 COCO 数据集中包含三种尺度的目标，而本文所需检测的 PCB 缺陷微小，并不能很好地适配检测需求，需要重新聚类。由于 K-means 算法随机选取初始值，初始聚类中心的选取直接影响着聚类效果与稳定性。因此使用 K-means＋＋算法[19]对 PCB 缺陷数据集标签进行聚类，获得最适合的先验框。生成 9 组不同宽高比的先验框如表 1 所示，聚类结果显示：与原先验框相比，该算法聚类生成的先验框更接近数据集实际大小分布。

表 1 修改前后的先验框的长宽

原先验框	K-means＋＋聚类
(10,13)(16,30)(33,23)	(9,9)(9,21)(12,13)
(30,61)(62,45)(59,119)	(14,28)(16,16)(18,9)
(116,90)(156,198)(373,326)	(22,21)(27,12)(31,30)

3 实验结果与分析

3.1 实验数据集

本文采用的 PKU-Market-PCB 是由北京大学制作的印刷电路板(PCB)瑕疵数据集，包含 6 种常见的 PCB 缺陷。该数据集共包含 693 张 3034×1568 分辨率的图片。由于原始图片分辨率较高，直接用于训练对硬件设备要求较高，并且 PCB 缺陷多为小目标(标注框的平均高宽与原图的高宽比例小于 0.04)，因此采用切图的方式进行训练可以达到更好的效果。

在训练开始前，使用 SAHI(Slicing Aided Hyper Inference)工具将图片裁剪为 600×600 分辨率，同时通过离线数据增强对数据集进行扩充，包括水平翻转、镜像、图像亮度调节等操作。扩充后得到 10 395 张图片，数据集详细分布如表 2 所示。最后将 10 395 张图片按照 8∶1∶1 的比例随机分配为训练集、验证集和测试集。

表 2　数据划分

缺陷类型	原图片数量	增强后图片数量
漏孔	115	1725
开路	116	1740
短路	116	1740
缺口	115	1725
余铜	116	1740
毛刺	115	1725

3.2　评价指标

本文采用精准率(P)、召回率(R)、均值平均精度(mAP)3 个评价指标来对模型进行评估。计算公式如下：

$$P = \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FP}} \tag{4}$$

$$R = \frac{\mathrm{TP}}{\mathrm{TP}+\mathrm{FN}} \tag{5}$$

$$\mathrm{AP} = \int_0^1 p(R)\,\mathrm{d}R \tag{6}$$

$$\mathrm{mAP} = \frac{\sum_{i=0}^{n}\mathrm{AP}(i)}{n} \tag{7}$$

上式中，P 为准确率，表示检测的准确性；R 为召回率，反应漏检的情况；TP 为正样本，代表检测和真实都为正例；FP 为负样本，表示检测为正例，真实为负例；FN 为假反例，表示检测为负样本但实际为正样本；AP 表示精准度，是 PR 曲线所围成的面积；mAP 为均值平均精度，是由所有类别 AP 值求和后除以类别数所得到。

3.3　实验结果与分析

本实验采用中国移动九天毕昇云服务器进行训练，硬件配置为双核处理器，显卡为 TeslaV100S-PCIE-8GB 显存。软件环境为 CUDA10.2，网络模型基于 Pytorch 框架搭建，在训练过程中 batch_size 设置为 16，epoch 设置为 100。

为更加全面地分析 Ghost-YOLOv5 算法中改进的各模块对 PCB 缺陷检测性能的影响，本文以 YOLOv5s 为基础模型进行实验分析。

通过对比第 1 组与第 2 组实验(表 3)，采用轻量级网络 GhostNet 作为 YOLOv5 的主干网络，参数量降低48.75%，网络轻量化的同时 mAP 值也损失 0.7%。结果表明采用 GhostNet 网络，可以有效地减少运算量，提高模型的训练速度。

第 2 组和第 3 组实验对比显示，采用 L-BIPFN 网络后，mAP 从 94.4%提高到 96.2%，提升 1.8 个百分点。使用 L-BiFPN 网络进行多尺度特征融合，可以获得更多浅层的微小缺陷特征信息，提高检测精度。

第 3 组和第 4 组实验对比显示，采用 K-means＋＋重新聚类先验框后，mAP 值从 97.5%提升到 98.9%，提高 1.3 个百分点，同时准确率与召回率分别提升 1.3 个百分点和 3.1 个百分点。

通过对比第 1 组和第 4 组实验，结果表明：在 PCB 缺陷数据集上，本文所提出的 Ghost-YOLOv5 算法相对于原来的 YOLOv5s，mAP 值提升 3 个百分点，达到 98.9%，准确率与召回率也分别提升 3.4 个百分点和 6.2 个百分点，达到 97.5%和99.1%。在参数量方面，Ghost-YOLOv5 算法与原算法相比降低 47.91%。

表 3　Ghost-YOLOv5 算法消融实验

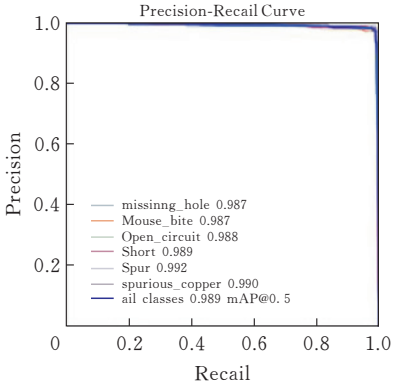
Method	Ghost	L-BiFPN	K-means＋＋	P	R	mAP	Parameters(M)
1	—	—	—	0.941	0.929	0.959	7.2
2	√	—	—	0.944	0.914	0.952	3.69
3	√	√	—	0.962	0.96	0.975	3.75
4	√	√	√	0.975	0.991	0.989	3.75

Ghost-YOLOv5 算法与 YOLOv5s 算法在 6 类缺陷上的检测结果对比如表 4 所示。

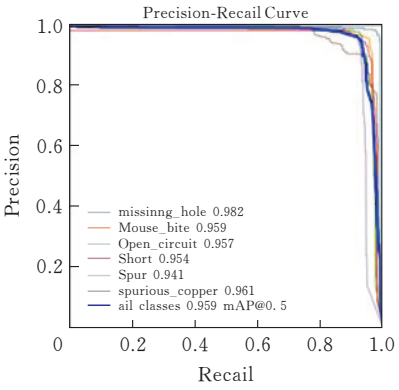
表 4　YOLOv5s 与 Ghost-YOLOv5 各项缺陷检测结果

算法	漏孔	缺口	短路	断路	毛刺	余铜
YOLOv5s	98.2	95.9	95.7	95.4	94.1	96.1
Ghost-YOLOv5	98.7	98.7	98.8	98.9	99.2	99

Ghost-YOLOv5 算法在 6 种缺陷上均有所提升，其中毛刺类和断路类缺陷提升最为明显，分别提高 5.1 个百分点和 3.5 个百分点。YOLOv5s 与 Ghost-YOLOv5 算法的 PR 曲线如图 4 所示。可以看出图中曲线所围成的面积明显增大，这表明改进后的模型在保证精度的同时，召回率也明显提高。



(a) YOLOv5s 算法的 PR 曲线



(b)Ghost-YOLOv5 算法的 PR 曲线

图 4 YOLOv5 与 Ghost-YOLOv5 算法 PR 曲线

3.4 对比实验

为证明 Ghost-YOLOv5 算法在 PCB 缺陷数据集上的优势,将其与几种先进的目标检测算法进行对比,如 YOLOv3、改进 YOLOv4、SSD、Faster-RCNN、YOLOv5s。由表 5 可知,本文所改进的算法 mAP 值达到 98.9%、召回率达到 99.1%,相比于 YOLOv5s 模型减少 47.51%,召回率与平均精度分别提高 6.2 个百分点和 3 个百分点;同改进 YOLOv4 相对比,平均精度降低 0.2 个百分点,主要原因是 Ghost-YOLOv5 主干网络是轻量级网络 GhostNet,参数量远低于 YOLOv4 的主干网络;与 YOLOv3 相对比召回率提高 6.8 个百分点,且模型大小仅为其 1/16;相比于 SSD 和 Faster-RCNN,不仅模型更小,平均精度也分别提升 6.9 个百分点和 5.6 个百分点。实验表明,Ghost-YOLOv5 算法在处理 PCB 缺陷检测任务时比其他算法更具优势。

表 5 6 种算法性能指标对比

算法	准确率/%	召回率/%	平均精度	模型大小/MB
SSD[20]	0.929	0.961	0.920	93.1
Faster R-CNN[21]	0.753	0.861	0.803	108
YOLOv3	0.963	0.923	0.956	117.7
YOLOv4[1]	—	—	99.10	53.2
YOLOv5s	0.941	0.929	0.959	14.1
本文算法	0.975	0.991	0.989	7.4

图 5 为 Ghost-YOLOv5 算法在测试集上的各项缺陷检测结果,图 6 为实测 PCB 板缺陷检测结果。从图中可以看出,Ghost-YOLOv5 算法在测试集验证和实际测试中,对 6 种缺陷都能精准识别,并准确定位缺陷位置。实验结果表明,改进后的算法综合性能优越,对各类缺陷均有较好的检测效果,能够满足工业生产中的检测需求,具有较高的应用价值。

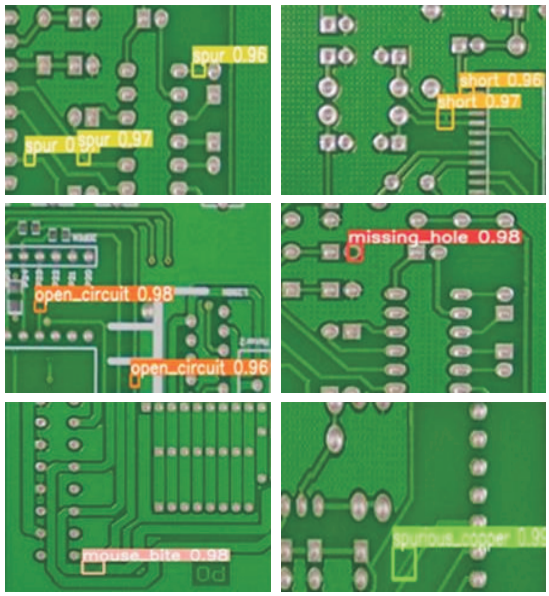


图 5 各类缺陷检测结果

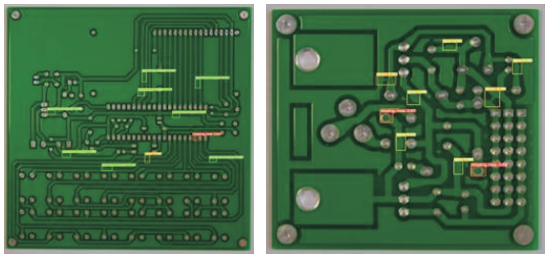


图 6 实测 PCB 板缺陷检测结果

4 结论

本文提出了一种改进的 Ghost-YOLOv5 算法。该算法首先采用 GhostNet 网络作为主干网络,减少了模型的参数量;其次提出 L-BiFPN 网络用于改进特征融合,提高了特征融合能力;最后使用 K-means++算法对锚框聚类,提升了小目标检测性能。实验结果表明:Ghost-YOLOv5 算法的性能在 6 种常见的 PCB 缺陷上 mAP 值均高于 98%,且模型大小减少 47.51%。总体而言,改进后的 Ghost-YOLOv5 算法在检测效率和检测精度方面,相比其他算法具有一定优势。

[参 考 文 献]

[1] XUAN W, JIAN G, BO H, et al. A lightweight modified YOLOX network using coordinate attention mechanism for PCB surface defect detection[J]. IEEE Sensors Journal, 2022, 22(21): 20910-20920.

[2] 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.

[3] 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

(09):1-18.

[4] ZENG N, WU P, WANG Z, et al. A small-sized object detection oriented multi-scale feature fusion approach with application to defect detection[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-14.

[5] HE K, GKIOXARI G, DOLLAR P, et al. Mask R-CNN[C]. 2017 IEEE International Conference on Computer Vision (ICCV), 2017: 2980-2988.

[6] GIRSHICK R. Fast R-CNN [C]. International Conference on Computer Vision (ICCV), 2015: 1440-1448.

[7] REN S, HE K, 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, 2017, 39(6): 1137-1149.

[8] REDMON J, FARHADI A. Yolov3: An incremental improvement[J]. ArXiv Preprint, 2018, arXiv: 1804.02767.

[9] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[J]. ArXiv Preprint, 2020, arXiv: 2004.10934.

[10] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multibox detector[C]. European Conference on Computer Vision (ECCV), 2016: 21-37.

[11] 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.

[12] 胡江宇,贾树林,马双宝.基于改进级联 Faster RCNN 的 PCB 表面缺陷检测算法[J].仪表技术与传感器,2022(07):106-110.

[13] 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,2022,28(06):1-20.

[14] ZHUO L, YANG H, YUAN L. An improved YOLOv3 method for PCB surface defect detection[C]. 2021 IEEE International Conference on Power Electronics, Computer Applications (ICPECA), 2021: 1009-1015.

[15] HAN K, WANG Y, TIAN Q, et al. GhostNet: More Features From Cheap Operations[C]. 2020 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2020: 1577-1586.

[16] HE K, ZHANG X, REN S, et al. Spatial Pyramid Pooling in Deep Convolutional Networks for Visual Recognition[J]. Pattern Analysis & Machine Intelligence IEEE Transactions on, 2015, 37(9):1904-1916.

[17] LIN T Y, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017: 2117-2125.

[18] GHIASI G, LIN T Y, LE Q V, et al. NAS-FPN: Learning Scalable Feature Pyramid Architecture for Object Detection[C]. 2019 IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2019: 7029-7038.

[19] WANG H, WU B, WU Y, et al. An Improved YOLO-v3Algorithm for Ship Detection in SAR Image Based on K-means++ with Focal Loss[C]//2022 3rd China International SAR Symposium (CISS). IEEE, 2022: 1-5.

[20] 李俊.基于 SSD 模型的 PCB 外观缺陷检测[J].现代计算机,2022,28(07):79-82.

[21] 朱红艳,李泽平,赵勇,等.基于多尺度融合和可变形卷积 PCB 缺陷检测算法[J].计算机工程与设计,2022,43(08):2188-2196.

Optimization of YOLOv5 PCB Defect Detection Based on Ghost

LIU Hang, ZHOU Xianjun

(*School of Electrical and Electronic Engineering, Hubei Univ. of Tech., Wuhan* 430068, *China*)

Abstract: To address the problems of false detection, serious leakage, and an excessive number of model parameters in existing PCB defect detection methods, a PCB defect detection algorithm based on improved YOLOv5 is proposed. To begin, GhostNet, a lightweight network, is used as the backbone network of YOLOv5 to solve the problem of an excessive number of YOLOv5 parameters; second, a lightweight weighted bi-directional feature pyramid network (Light-BiFPN) is designed to effectively fuse the network's deep features with the shallow features; and finally, K means++ is used to cluster the PCB data set to solve the problem of the initial priori issue of inappropriate frames. The experimental results show that Ghost-YOLOv5 improves mAP by 3% over the original algorithm, reaching 98.9%, and the number of model parameters is reduced by 47.91%, giving it some advantages over the original algorithm.

Keywords: PCB board defect detection; YOLOv5; target detection; deep learning

[责任编校: 赵　瞳]