

DOI:10.19651/j.cnki.emt.2209320

# 基于 GhostNet-YOLOv4 算法的印刷电路板缺陷检测 \*

刘 涛 张 涛

(青岛科技大学自动化与电子工程学院 青岛 266061)

**摘要:** 针对印刷电路板表面面积小而且上面电子器件焊点众多,传统检测方法很难进行有效检测的问题,提出了一种基于 GhostNet-YOLOv4 的印刷电路板表面焊点检测算法。首先,修改了 YOLOv4 算法的主干网络以增强特征提取能力,其次加入注意力机制使网络更注重缺陷特征,用 GhostNet 代替 CSPDarknet53 作为主干网络。此算法相比于传统的印刷电路板检测算法提高了检测精度和检测速度,可以实现对印刷电路板表面常见的断路、漏焊、短路等缺陷的精确检测和迅速分类。通过对印刷电路板数据集的检测结果分析表明,该改进算法具有较好的实用性,在测试集上的平均精度为 86.68%,FPS 达到了 25.43,可以满足印刷电路板实际检测需求。

**关键词:** 印刷电路板;焊点检测;注意力机制;GhostNet

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

## Defect detection of printed circuit board based on GhostNet-YOLOv4 algorithm

Liu Tao Zhang Tao

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

**Abstract:** Aiming at the problem that the area of printed circuit board is small and there are many electronic device solder joints on it, which is difficult to detect effectively by traditional detection methods, a surface solder joint detection algorithm of printed circuit board based on GhostNet-YOLOv4 is proposed. First, the backbone network of YOLOv4 is modified to enhance the feature extraction capability. Secondly, adding attention mechanism makes the network pay more attention to defect features. Finally, use GhostNet instead of CSPDarknet53 as the backbone network. Compared with the traditional PCB detection algorithm, this algorithm improves the detection accuracy and speed, and can realize the accurate detection and rapid classification of common defects such as broken circuit, missing welding and short circuit on the surface of PCB. Experiments on PCB data sets show that: the improved algorithm has good practicability, the accuracy on the test set is 86.68%, FPS reached 25.43, can meet the actual detection requirements of printed circuit boards.

**Keywords:** printed circuit board;solder joint inspection;attention mechanism;GhostNet

## 0 引言

随着工业智能化进程的加快,印刷电路板的需求也进一步加大,印刷电路板的质量对电子器件的安全运行起着至关重要的作用。印刷电路板表面缺陷会导致机器不能正常运作,甚至会造成安全隐患。传统印刷电路板的检测方法主要依靠普通光学检测设备简单的对印刷电路板的漏焊、短路、断路等常见缺陷进行检测,但是印刷电路板表面元器件排列密集,检测精度和速度难以满足实际工业生产的需求。因此印刷电路板质量的实时检测就成为关键问题。

为了对印刷电路板表面缺陷进行快速检测,研究人员提出了各种实时印刷电路板缺陷检测算法,基于神经网络的目标检测算法,在目标检测领域表现出优异的性能,近年来已有一些研究将神经网络应用于印刷电路板的缺陷检测之中。陈仁祥等<sup>[1]</sup>提出基于多注意力 Faster RCNN 的印刷电路板缺陷检测方法,在特征提取以及特征融合部分引入注意力机制以增强抗干扰性;刘小燕等<sup>[2]</sup>采用编码器-解码器结构的卷积神经网络模型解决了复杂光照场景下印刷电路板色环电阻的图像分割问题;何国忠等<sup>[3]</sup>在优化后的网络中加入了基于细粒度空间域的长距离全局注意力机

收稿日期:2022-03-18

\*基金项目:基于机器视觉的服务机器人自助导航关键技术研究项目(ZR2020MF087)资助

制,提高了检测精度;Gang 等<sup>[4]</sup>提出了一种通过构建一个数据集来识别印刷电路板表面器件的方法;Kim 等<sup>[5]</sup>提出一种基于跳跃连接卷积自动编码器的印刷电路板检测方法,从缺陷图像中解码出原始的非缺陷图像,与输入图像进行比较,以确定缺陷位置;通过以上文献分析,基于深度学习的方法可以有效对印刷电路板的缺陷进行实时检测和快速分类。

比较主流的目标检测算法分为两大类,分别是 One stage 的目标检测<sup>[6]</sup> 和 Two stage 的目标检测<sup>[7]</sup>。YOLO 系列算法属于 One stage 检测算法,相比于 Two stage 目标检测算法,不需要产生候选区域,直接通过神经网络提取出的特征进行目标分类和位置检测,检测速度迅速,是目前工业领域中应用较为广泛的目标检测算法。YOLO 系列在工业领域主流的检测算法有 YOLOv2<sup>[8-10]</sup>、YOLOv3<sup>[11-13]</sup>、YOLOv4<sup>[14-16]</sup>。YOLO 系列算法因检测速度快、检测精度高被广泛的应用到工业检测领域,但是对于印刷电路板缺陷等小目标的检测精度较低,许多研究人员对此做出了相应的改进,使其更适用于小物体的目标检测。鞠默然等<sup>[17]</sup>提出对 YOLOv3 输出的 8 倍降采样特征图进行 2 倍上采样,建立输出为 4 倍降采样的特征融合目标检测层;郭璠等<sup>[18]</sup>把注意力机制加入到 YOLOv3 网络中,提出了目标检测的通道注意力方法和基于语义分割引导的空间注意力方法;吴海滨等<sup>[19]</sup>用空洞卷积对 YOLOv4 网络进行改进,加入空洞空间金字塔池化模型,以此增大感受野;罗晖等<sup>[20]</sup>基于 focal loss 改进 YOLOv4 的损失函数,解决了公路路面病害样本不足导致的网络训练过拟合问题。由于 YOLO 算法不用生成候选区域从而对物体进行直接检测,提高了检测速度,满足印刷电路板生产的实时检测需求,因此成为本论文的最佳研究算法。

目前,印刷电路板缺陷检测的难点在于两点。首先,印刷电路板表面缺陷微小,难以提取出足够多的缺陷特征进行检测;其次,实现印刷电路板的实时监测需要将神经网络嵌入到现场设备中,因此需要将 YOLO 网络轻量化。针对印刷电路板的检测难点,本文提出了一种基于机器视觉的改进 YOLOv4 实时目标检测算法,基于已有的生产设备,实时传输现场视频信息,实时检测印刷电路板表面缺陷信息。通过训练印刷电路板缺陷图片数据集改进神经网络模型,取得较好的检测结果。本文的主要贡献可以总结如下:

1) 在原算法中,原锚框是在 VOC 数据集上聚类得出,印刷电路板表面的缺陷属于小目标,因此原有的锚框不适用于印刷电路板表面缺陷检测。为解决这一问题,引入 K-means 聚类算法对数据集的标注文件重新聚类,得到适合印刷电路板缺陷的锚框。

2) 印刷电路板表面缺陷微小,进行特征提取的过程中,可供提取的特征非常少。为解决这一问题,在主干特征网络输出的第 3 个和第 5 个特征层之后增加卷积层以增强特征提取能力。

3) 在工业实际生产中,由于电磁干扰和画面抖动等原因,会干扰神经网络对缺陷的提取能力,降低检测精度。为解决这一问题,在 YOLOv4 网络的 3 个有效特征层后加入注意力机制,使网络更有效的关注缺陷特征,减少工业噪声的影响,提高检测精度。

4) YOLOv4 模型在进行训练时需要高性能的 GPU,但是印刷电路板的实时监测需要在内存有限的嵌入式处理器上进行,为解决这一问题,使用 GhostNet 代替 CSPDarknet53 作为主干网络,减少参数训练量,使网络轻量化,以便于嵌入到现场生产设备中,进行实时检测。

## 1 YOLOv4 网络简介

输入图像在主干特征提取网络完成特征提取,然后通过 SPP 和 PANet 完成不同尺度特征图的融合,最后输出 3 个尺度的特征图来预测边界框,最终输出检测目标。YOLOv4 的网络结构如图 1 所示。

YOLOv4 的主干特征提取网络是 CSPDarknet53,在特征提取的部分,特征提取网络对图片不断的进行特征提取,特征层的高和宽不断地被压缩,特征层的通道数不断的得到扩张。YOLOv4 选取 CSPDarknet53 中的三个有效特征层送入了实例分割网络中。在 YOLOv4 的三个有效特征层中使用了 PANet 结构。PANet 通过融合自下向上的特征提取和自上向下的特征提取增强了主干网络的特征提取能力。SPP 结构在对 CSPDarknet53 的最后一个特征层进行三次卷积后,分别利用四个不同尺度最大池化对图像进行池化处理,同时 SPP 结构可以极大的增加感受野,分理处最显著的上下文特征。在 YOLOv4 中使用 Mish 函数作为激活函数。Mish 激活函数是无上界的函数。其次,Mish 激活函数是非单调函数,非单调函数可以使其在负区间里保持负值,从而避免产生 Dead ReLU 现象。Mish 激活函数有较好的泛化能力,可以提高检测的准确性。Mish 激活函数的图像如图 2 所示。

$$Mish = x \times \tanh(\ln(1 + e^x)) \quad (1)$$

## 2 改进的 YOLOv4 算法

### 2.1 基于 PCB 数据集的聚类的改进

YOLOv4 的先验框是在 VOC 数据集上聚类得出,印刷电路板表面焊点的缺陷属于小目标,YOLOv4 的先验框不适用于印刷电路板表面焊点的缺陷检测。为使先验框与真实框更接近,本文采用 K-means 聚类算法<sup>[21]</sup>根据数据集的标注文件重新聚类。K-means 聚类一般来说使用欧氏距离作为样本与中心点之间的距离。两个样本之间的欧氏距离计算公式为:

$$distance = \sqrt{\sum_{k=1}^n (x_k - y_k)^2} \quad (2)$$

先验框要求大框的欧氏距离更大,因此 YOLOv4 使用的是处理后的 IOU 作为欧氏距离。

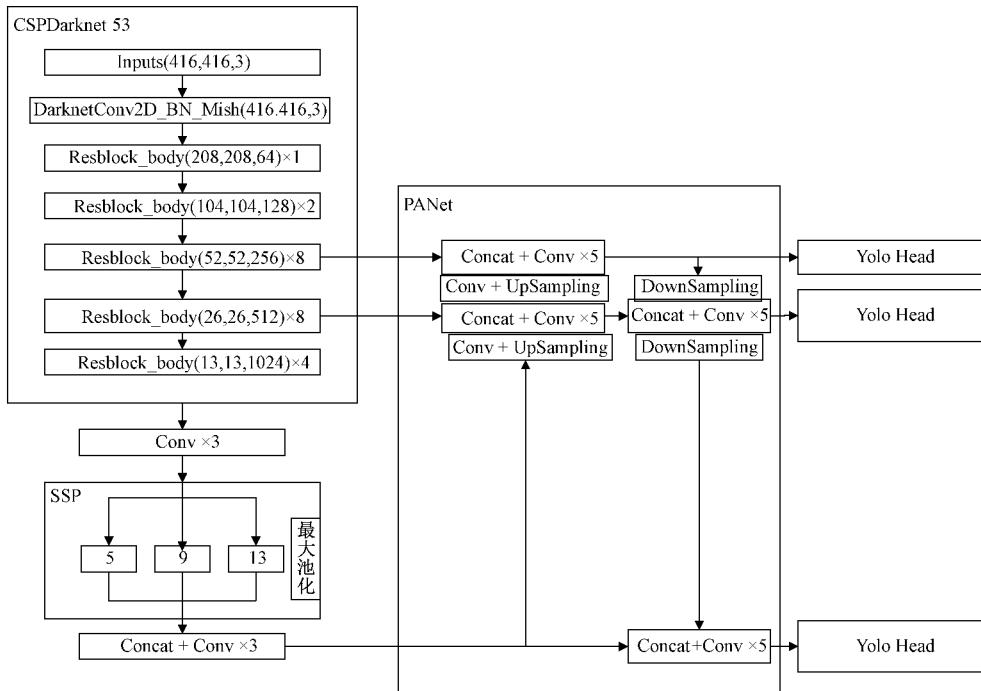


图 1 YOLOv4 的网络结构

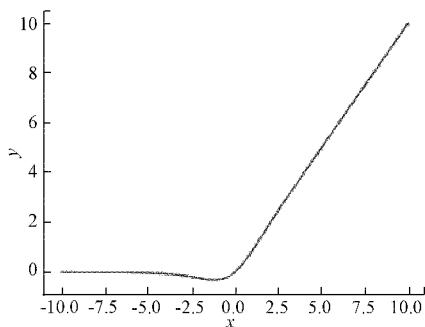


图 2 Mish 激活函数的图像

$$\text{diatance}(i, center) = 1 - \text{IOU} \quad (3)$$

K-means 聚类的步骤如图 3 所示。

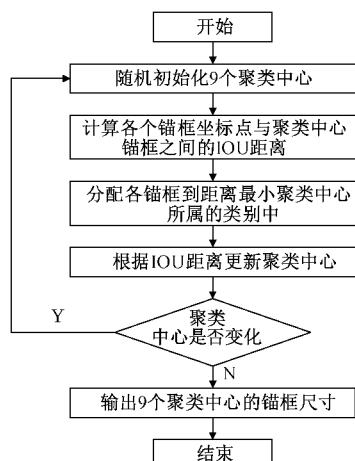


图 3 K-means 算法流程

使用 K-means 聚类算法得到的新的聚类中心更适用于印刷电路板表面焊点检测, 实现印刷电路板表面缺陷的精准检测, 通过 K-means 聚类可以提高先验框的精确度, 加快模型的训练速度。对本文标签文件使用 K-means 聚类后得到的九个聚类中心的数值如表 1 所示。

表 1 锚框的宽度和高度

VOC2007 数据集		电路板数据集	
宽	高	宽	高
12	16	5	14
19	36	6	21
40	28	7	9
36	75	9	12
76	55	10	18
72	146	11	9
142	110	14	12
192	243	17	18
459	401	17	7

## 2.2 使用 GhostNet 作为主干网络

华为诺亚方舟实验室提出了一个轻量级网络, 命名为 GhostNet。GhostNet 网络旨在解决神经网络中存在的特征图冗杂的情况。作者将相似的特征图认为是 Ghost, 使用低计算量的操作去生成这些冗余的特征图, 这样就可以在保证检测效果的同时, 通过减少模型的参数量提高模型的检测速度。

GhostNet 中设计了一个 Ghost Module 模块, 目的是

代替普通卷积。Ghost Module 将普通卷积分为两部分,首先利用  $1 \times 1$  卷积获得输入特征的必要特征浓缩;其次再进行深度可分离卷积,这个深度可分离卷积是逐层卷积,利用上一步获得的特征浓缩生成相似特征图。Ghost Module 模块如图 4 所示。

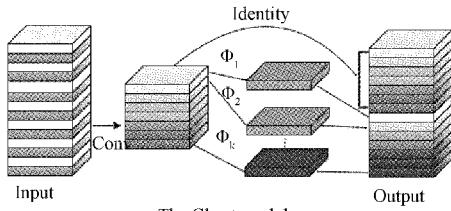


图 4 Ghost Module 模块

Ghost bottlenecks 由两个 Ghost Module 构成,第 1 个 Ghost Module 的作用是扩展特征图的通道数,第 2 个 Ghost Module 的作用是减少特征的通道数。将这两个 Ghost 模块的输入和输出连接起来,在第 2 个 Ghost 模块之后不使用 ReLU 外,每一层之后进行批量归一化和 ReLU 函数激活。Ghost Bottlenecks 有两种,如图所示,需要对特征层的宽高进行压缩的时候,设置这个 Ghost Bottlenecks 的步长为 2。在两个 Ghost Module 中添加一个步长为  $2 \times 2$  的深度可分离卷积进行特征层的宽高压缩。Ghost bottlenecks 结构如图 5 所示。

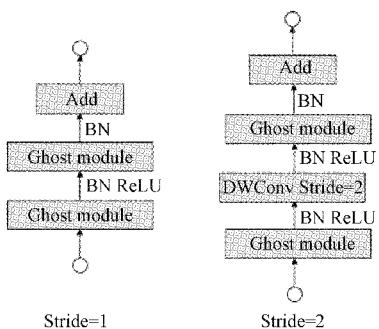


图 5 Ghost bottlenecks 结构

若输入特征图宽为  $w$ ,高为  $h$ ,通道数为  $c$ ,输出特征图的通道数为  $n$ ,卷积核大小为  $k \times k$ ,线性变换核的大小为  $d \times d$ , $s \ll c$ 。普通卷积的计算量为:

$$\text{cost} = h' \times w' \times n \times k \times k \times c \quad (4)$$

Ghost Module 的计算量为:

$$\text{cost} = h' \times w' \times \frac{n}{s} \times k \times k (c + s - 1) \quad (5)$$

普通卷积与 Ghost Module 的计算量之比为:

$$r_e = \frac{n \times c}{\frac{n}{s} (c + s - 1)} = \frac{s \times c}{c + s - 1} \approx s \quad (6)$$

由此可知,Ghost Module 相比于普通卷积有效减少参数计算量,使网络轻量化。GhostNet 是由多个 Ghost bottlenecks 组成的, GhostNet 结构如表 2 所示。

表 2 GhostNet 结构

Input	Operator	exp	out	SE	Stride
$416^2 \times 3$	Conc2d $3 \times 3$	—	3	—	2
$208^2 \times 16$	G-bneck	16	16	—	1
$208^2 \times 16$	G-bneck	48	24	—	2
$104^2 \times 24$	G-bneck	72	24	—	1
$104^2 \times 24$	G-bneck	72	40	1	2
$52^2 \times 40$	G-bneck	120	40	1	1
$52^2 \times 40$	G-bneck	240	80	—	2
$26^2 \times 80$	G-bneck	200	80	—	1
$26^2 \times 80$	G-bneck	184	80	—	1
$26^2 \times 80$	G-bneck	184	80	—	1
$26^2 \times 80$	G-bneck	480	112	1	1
$26^2 \times 112$	G-bneck	672	112	1	1
$26^2 \times 112$	G-bneck	672	160	1	2
$13^2 \times 160$	G-bneck	960	160	—	1
$13^2 \times 160$	G-bneck	960	160	1	1
$13^2 \times 160$	G-bneck	960	160	—	1
$13^2 \times 160$	G-bneck	960	160	1	1
$13^2 \times 160$	G-bneck	960	160	—	1
$13^2 \times 160$	Conc2d $1 \times 1$	—	960	—	1
$13^2 \times 960$	AvgPool $7 \times 7$	—	—	—	—
$1^2 \times 960$	Conc2d $1 \times 1$	—	1 280	—	1
$1^2 \times 1 280$	FC	—	1 000	—	—

### 2.3 改进的网络结构

为加强神经网络的特征提取能力,本文对 YOLOv4 的主干网络结构做出了改变,首先在主干特征网络输出的第 3 个和第 4 个特征层之后增加 3 个卷积核为  $1 \times 1, 3 \times 3, 1 \times 1$  的卷积层。同时修改 SPP 前面跟后面的 3 个卷积层,修改完的卷积层为五层,卷积核分别为  $1 \times 1, 3 \times 3, 1 \times 1, 3 \times 3, 1 \times 1$ 。特征层经过改进的卷积处理后,可以增加网络深度,更能有效地提取印刷电路板的缺陷特征。

### 2.4 引入注意力机制

SENet<sup>[22]</sup>是一个基于通道的注意力模型,通过关注每一个通道的权重,针对不同目标检测任务,增强或抑制不同的通道。ECANet<sup>[23]</sup>也是通道注意力机制的一种实现,被视为 SENet 的改进版。ECANet 中认为卷积有良好的跨通道信息获取能力,在 SENet 中捕获所有通道的依赖关系是不必要的。

ECANet 具体实现步骤如下:首先对输入进来的特征层进行全局平均池化,把输入维度为  $H \times W \times C$  的输入特征压缩成  $1 \times 1 \times C$  的特征条;其次对全局平均池化产生的特征长条用 1D 卷积进行特征提取,再由 sigmoid 函数激活后,获得每一个特征点的权值。再与输入进来的特征层相乘,得到经过通道注意力机制处理的特征。ECA 模块的结构如图 6 所示。

其中,GAP 代表全局平均池化, $\sigma$  代表 sigmoid 激活函

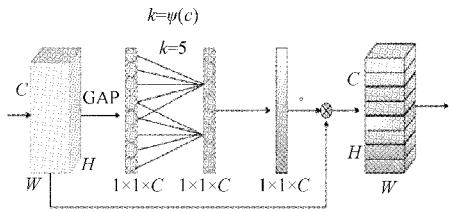


图 6 ECA 模块

数,  $k = \psi(C)$  代表通道维度  $C$  与卷积核大小  $k$  成比例, 其公式为:

$$k = \Psi(c) = \left| \frac{\log_2(c)}{\gamma} + \frac{b}{\gamma} \right|_{\text{odd}} \quad (7)$$

$|t|$  表示距离  $t$  最近的奇数, 在 ECANet 中  $\gamma$

取 2,  $b$  取 1。

注意力机制模块会随机初始化权值, 如果加入到主干网络会破坏主干网络的权值, 降低特征提取能力, 进而影响目标检测的精度。因此, 把注意力机制模块加入到 YOLO 网络的 3 个有效特征层后, 避免破坏主干网络的权值, 使网络更有效的关注印刷电路板表面焊点缺陷特征。改进后的 YOLOv4 网络结构如图 7 所示。在主干特征网络输出的第 3 个和第 4 个特征层之后增加 3 个卷积层并且把 SPP 前面跟后面的卷积层修改为五层, 增强对印刷电路板图片的特征提取能力; 使用 GhostNet 代替 CSPDarknet53 作为主干网络, 减少参数训练量, 使网络轻量化; 加入注意力机制, 使网络更有效的关注缺陷特征。

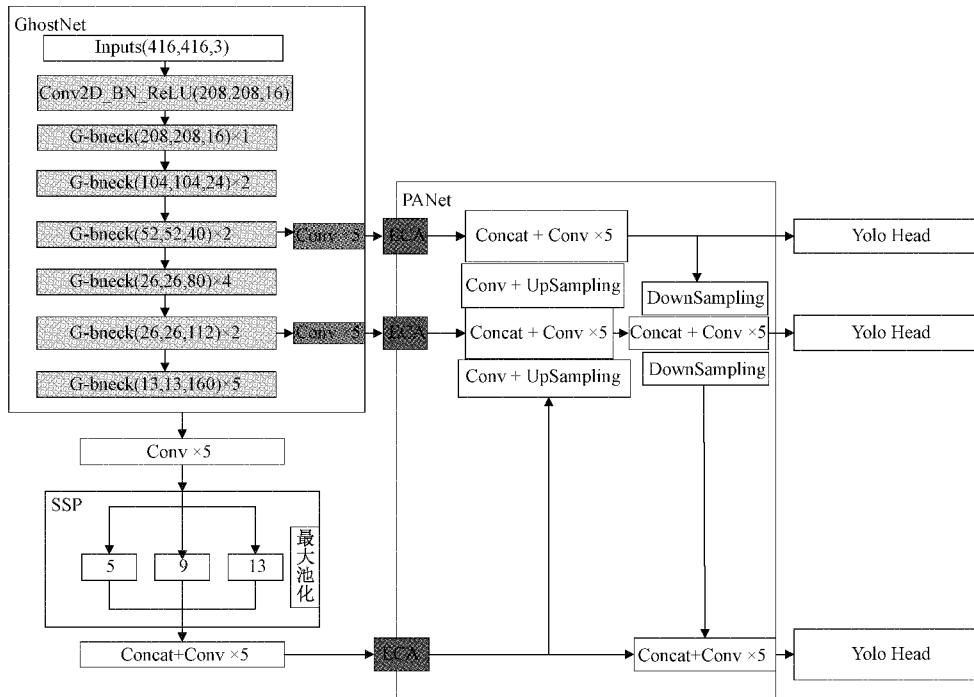


图 7 改进的 YOLOv4 网络结构

### 3 实验与分析

#### 3.1 实验环境

实验环境在 Windows10 下配置, CPU 为 AMD Ryzen5 3600, GPU 为 NVIDIA GeForce RTX 2060, 采用 Python3.6 进行程序编写, 在 Pytorch 框架下搭建模型结构。训练参数设置: 训练 epoch 为 100, 前 50 个 epochs 的学习率为  $1 \times 10^{-3}$ , batch size 为 4; 后 50 个 epochs 的学习率为  $1 \times 10^{-4}$ , batch size 为 2, YOLOv4 模型的输入图像尺寸为  $416 \times 416$ 。表 3 显示了本地计算机的基本配置。

#### 3.2 数据集

本文数据集包含 578 张包含各种缺陷的印刷电路板图片。其中漏焊图片 115 张, 缺损图片 115 张, 开路图片 116 张, 短路图片 116 张, 假铜图片 116 张。数据集划分为两

表 3 本地计算机的基本配置

电脑配置	具体参数/版本
操作系统	Windows 10
CPU	AMD Ryzen5 3600
RAM	16GB
GPU	NVIDIA RTX 2060
Python	3.6
Pytorch	1.9.0
CUDA	11.1

部分,一部分为训练集,用于训练网络模型;一部分为测试集,用于测试网络模型性能,本文划分比例为 9 : 1。该数据集包含开路 (broken circuit)、缺损 (defect)、漏焊 (missing welding)、假铜 (over etch) 和短路 (short circuit)

这五类缺陷。截取印刷电路板的部分图片如图 8 所示。

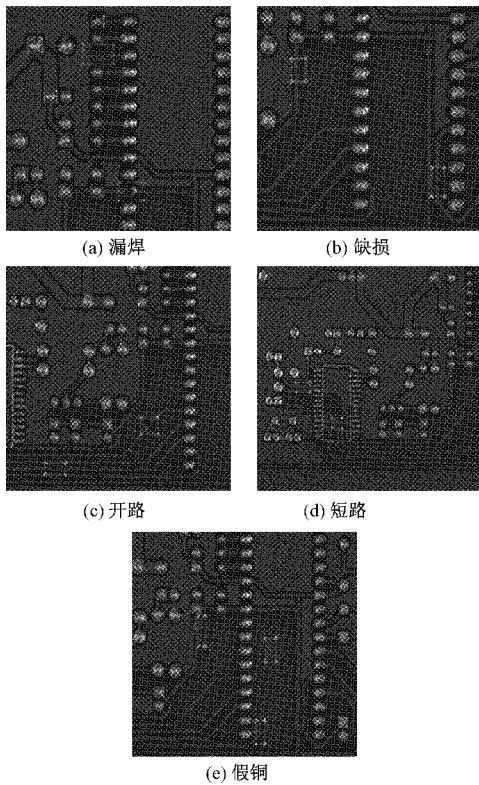


图 8 数据集 5 种缺陷

### 1) 数据集的扩充

数据集样本较少,会导致神经网络训练中出现过拟合的现象,因此采用数据增强的方法扩充数据集。常用的数据增强的方法有图像修剪、图像扭曲、图像缩放、图像拼接等。在印刷电路板数据集中,主要对印刷电路板图片进行旋转拼接得到新的图片。

### 2) 数据集的标注

本实验采用 labelImg 工具对数据集的 PCB 图像进行标注,labelImg 操作界面如图 9 所示,利用该标记工具进行标记,在 PCB 图片中标记出自定义的各种印刷电路板缺陷类别,该软件就可以自动生成相应的标签文件。

### 3.3 实验结果及分析

损失曲线显示了训练期间训练集上的误差,在前 10 次训练迭代期间,误差急剧下降。迭代 10 次之后,损失曲

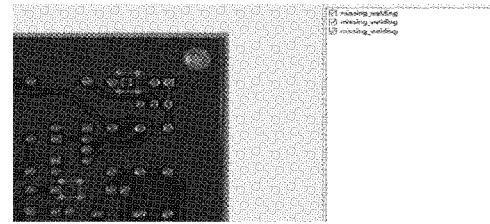


图 9 labelImg 工具进行 PCB 图片标记

线趋于稳定,最终稳定在 2.5 附近,如图 10 所示。

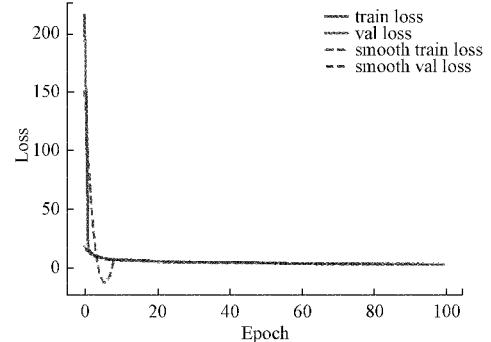


图 10 损失曲线

为了验证本文提出的改进 YOLOv4 模型的优越性,本文将其与 YOLOv3、YOLOv4、SSD、Faster R-CNN 进行了比较。实验过程中选取同一份测试数据集且各项参数保持相同,选取常用的精确率(Precision)、召回率(Recall)、检测速度(fps)、精度(AP)、平均精度(mAP)、F1 作为指标评价。精确率就是正确分类的正样本占所有预测成正样本的比例;召回率就是正确分类的正样本占所有确实是正样本的比例。精确率计算公式如式(8)所示;召回率计算公式如式(9)所示。

$$Precision = \frac{TP}{TP + FP} \quad (8)$$

$$Recall = \frac{TP}{TP + FN} \quad (9)$$

TP 代表该样本是正样本,且被正确的预测成正样本;FP 代表该样本是负样本,但被错误的预测成正样本;FN 代表某个样本是正样本,但却被错误的预测成负样本。改进 YOLOv4 算法的精确率变化曲线如图 11 所示;改进 YOLOv4 算法的召回率变化曲线如图 12 所示。

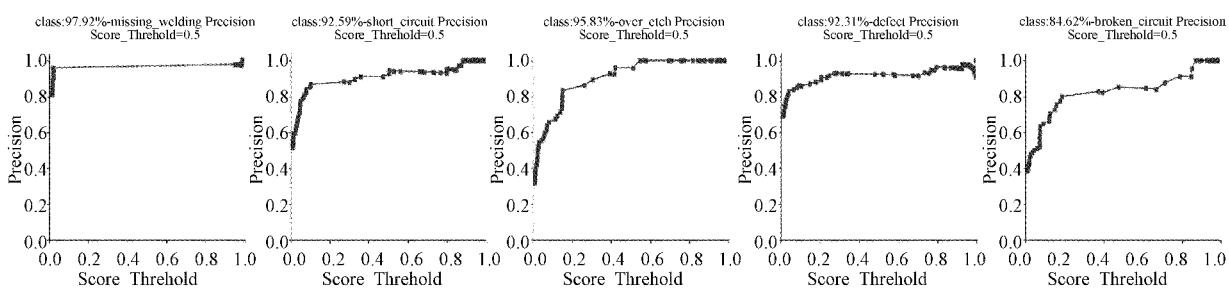


图 11 改进 YOLOv4 算法的精确率变化曲线

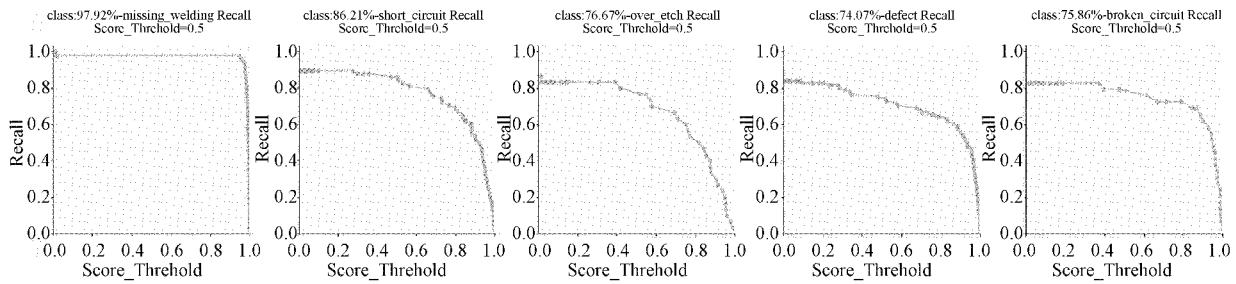


图 12 改进 YOLOv4 算法的召回率变化曲线

通过表 4 和表 5 精确率和召回率的对比可以看出,在这 5 种算法中,改进的 YOLOv4 算法由于加入注意力机制,使网络更有效的关注印刷电路板瑕疵特征,相比于 YOLOv4、YOLOv3、SSD 和 Faster R-CNN 在精确率和召回率这两种评价指标上取得了更好的检测效果;进一步分析其他四种算法,YOLOv4 算法在短路这类缺陷的精确率比改进的 YOLOv4 仅提高 1.39%,但是召回率却低了 3.3%;YOLOv3 算法在开路和假铜这两类缺陷的检测精度上表现一般,但是召回率却大幅下降;SSD 算法在缺损这类缺陷的检测精度仅比 YOLOv3 高

了 0.17%,但是召回率却下降了 42%;Faster R-CNN 在缺损这类缺陷的精确率比 YOLOv3 仅低 1.1%,但是召回率却低了 17.37%。通过以上分析可以看出,精确率增加并不导致召回率也相应增加,在某些缺陷上出现精确率较高但召回率较低的问题。因此引入 F1 值作为评价指标,F1 值是基于 Precision 和 Recall 的调和平均值。F1 计算公式如式(10)所示,改进 YOLOv4 算法的 F1 值如图 13 所示。

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (10)$$

表 4 不同算法精确率对比

算法	missing welding	short circuit	over etch	defect	broken circuit	%
改进的 YOLOv4	97.92	92.59	95.83	92.31	84.62	
YOLOv4	96.84	93.98	87.30	86.17	87.93	
YOLOv3	94.73	90.36	84.13	84.04	86.21	
SSD	86.79	90.92	76.67	84.21	77.42	
Faster R-CNN	92.63	89.16	80.95	82.98	84.48	

表 5 不同算法召回率对比

算法	missing welding	short circuit	over etch	defect	broken circuit	%
改进 YOLOv4	97.92	86.21	76.67	74.07	75.86	
YOLOv4	89.32	82.98	63.22	69.23	72.86	
YOLOv3	87.38	79.79	60.92	84.04	67.52	
SSD	73.02	70.73	40.35	42.11	58.54	
Faster R-CNN	85.44	78.73	58.62	66.67	70.00	

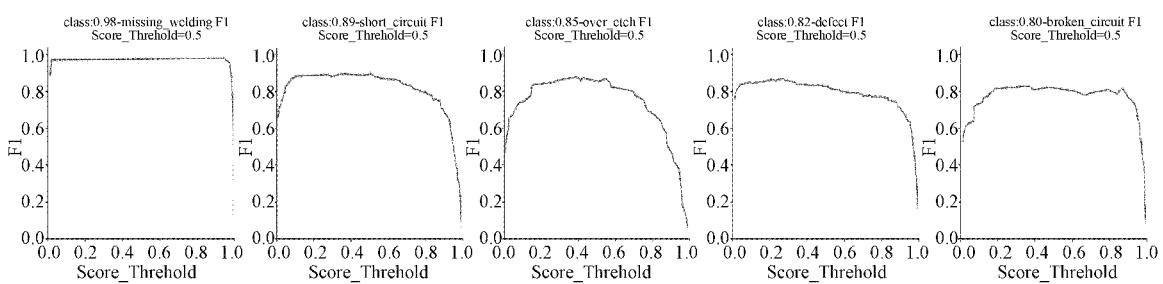


图 13 改进 YOLOv4 算法的 F1 值

表 6 不同算法 F1 值

算法	missing welding	short circuit	over etch	defect	broken circuit
改进 YOLOv4	0.98	0.89	0.85	0.82	0.80
YOLOv4	0.93	0.88	0.73	0.77	0.79
YOLOv3	0.91	0.85	0.71	0.75	0.78
SSD	0.79	0.80	0.53	0.56	0.67
Faster R-CNN	0.89	0.84	0.68	0.74	0.77

图 12 所示为改进 YOLOv4 算法的 F1 值曲线变化。从曲线变化可以看出,改进后的网络波动较小,曲线变化比较平稳,表明改进后的网络性能稳定。表 6 是不同算法 F1 值,由于 SSD 算法在缺损和假铜两类缺陷的精确率较高,但是召回率出现大幅降低,因此 F1 值明显低于其他四类算法。改进的 YOLOv4 算法五种缺陷的 F1 值均优于 YOLOv4、YOLOv3、SSD 和 Faster R-CNN,这表明改进后的 YOLOv4 算法更适合于印刷电路板表面的缺陷检测。

AP 是指利用不同的 Precision 和 Recall 的点,所画出来的曲线下面的面积;mAP 是所有类的 AP 值的平均值。AP 计算公式如式(11)所示;mAP 计算公式如式(12)所示。

$$AP = \int_0^1 p(t)d(r) \quad (11)$$

$$mAP = \frac{1}{n} \sum_{i=1}^n AP_i \quad (12)$$

表 7 不同模型 AP 以及 mAP 值对比

算法	missing welding	short circuit	over etch	defect	broken circuit	mAP	FPS
改进 YOLOv4	98%	88%	84%	81%	81%	86.68%	25.43
YOLOv4	94%	89%	69%	71%	79%	80.47%	20.51
YOLOv3	92%	84%	75%	69%	68%	77.66%	25.71
SSD	83%	83%	65%	53%	44%	65.48%	29.37
Faster R-CNN	89%	82%	70%	68%	60%	73.82%	18.35

YOLOv3、YOLOv4、SSD、Faster R-CNN 和本文使用的改进 YOLOv4 算法的平均精度以及 FPS 如表 7 所示。可以看出,本文使用的改进 YOLOv4 算法在平均精度以及 FPS 比起 YOLOv4 都得到了显著的提升。改进 YOLOv4 算法跟 YOLOv3 相比,虽然 FPS 没有较大变化,但是 mAP 却提高了 9.02%;改进 YOLOv4 算法与 SSD 算法相比,FPS 降低了 3.94,但 mAP 提高了 21.20%;改进 YOLOv4 算法与 Faster R-CNN 算法相比,mAP 提高了 12.86%,FPS 提高了 7.08。

印刷电路板数据集的 5 个类别的 AP 值以及它们的平均精度如图 14 所示。在印刷电路板的 5 种缺陷中,漏焊识别的准确率是最高的,达到 0.99;其余 4 种缺陷识别的准确率均在 0.8 到 0.9 之间,断路和缺损这两种缺陷,识别的准确率只有 0.81。这两类缺陷识别准确率低的原因是这两类焊点过于小,颜色也与印刷电路板的颜色相似。

实验过程中随机抽取 1 张不同类别的缺陷图片输入 5 类算法模型进行检测,检测结果截取的部分图片如图 15 所示。

在这 5 类算法中,漏焊(missing welding)的识别率都达到了 90% 以上,有较好的识别效果;在短路(short circuit)和假铜(over etch)这两类缺陷上,YOLOv3 算法和

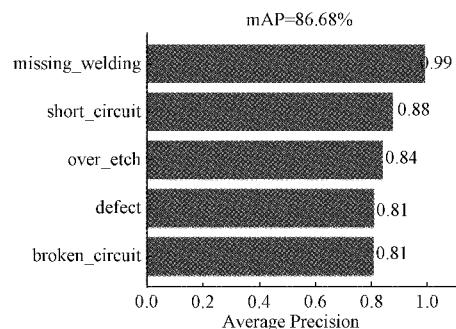


图 14 印刷电路板的 mAP 值

SSD 算法均出现漏检现象,仅检测到一个缺陷,其余 3 种算法检测到全部缺陷;在缺损(defect)这类缺陷上,除 SSD 算法以外,各算法均准确检测到缺陷,但是只有改进 YOLOv4 算法和 YOLOv4 算法的检测精度达到 80%,YOLOv3 算法和 Faster R-CNN 算法的检测精度只有 60%,而 SSD 算法出现缺陷错误检测现象,把缺损识别成开路;在开路(broken circuit)这类缺陷上,SSD 算法出现错误检测现象,把开路识别成缺损,其余 4 种算法检测精度均达到 90%。通过对比 5 种算法检测结果可以看出,改进的 YOLOv4 算法加入注意力机制,使网络更注重缺陷特

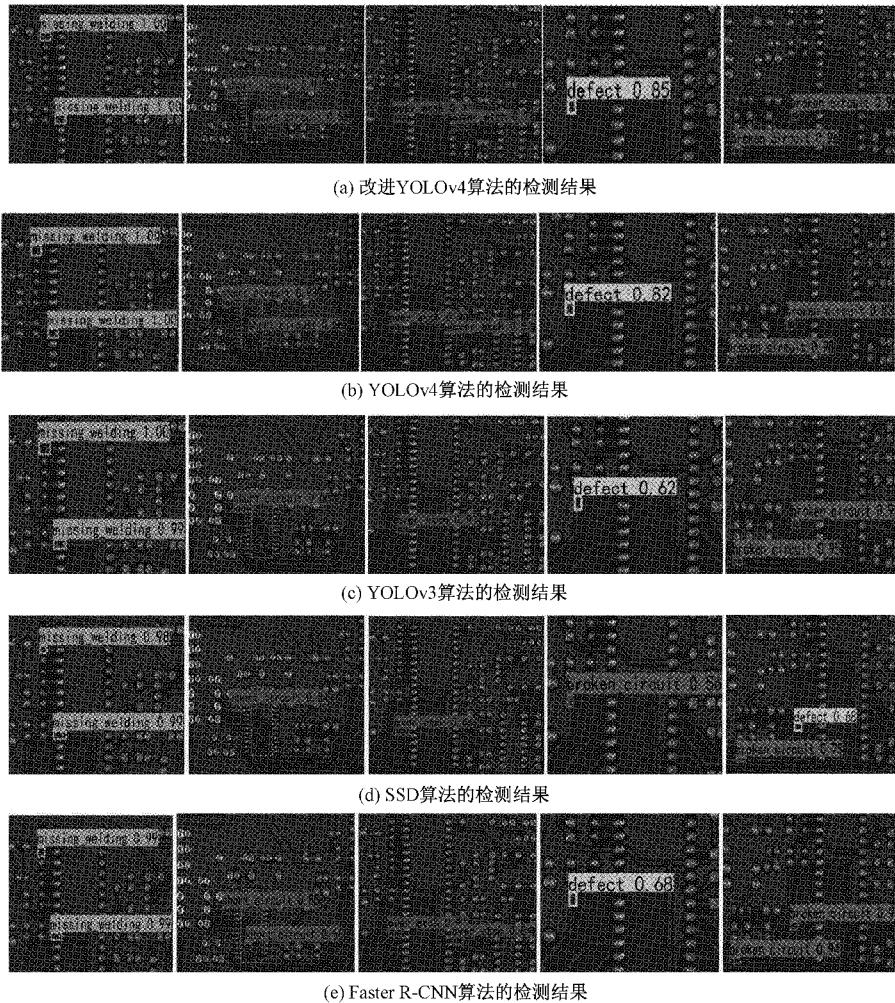


图 15 5 类算法模型的检测结果

征,与其他算法相比,实现了对印刷电路板表面缺陷的精确检测。

#### 4 结 论

为实现对印刷电路板表面缺陷这一复杂场景进行实时检测,本文自行构建印刷电路板数据集,针对印刷电路板数据集图片少这一问题,使用数据增强方法扩充数据集。针对 YOLOv4 的先验框不适用于小目标检测这一问题,对本文标签文件使用 K-means 聚类后得到新的聚类中心,以此来加快训练的速度和提高训练的精度。为增强特征提取能力,修改了 YOLOv4 的主干网络以增强特征提取能力,而且在 YOLO 网络的 3 个有效特征层后加入注意力机制使网络更有效的关注印刷电路板瑕疵特征。为使网络嵌入到现场生产设备中,用 GhostNet 代替 CSPDarknet53 作为主干网络,使网络轻量化。最终的实验结果表明,使用 YOLOv4 对印刷电路板进行检测后,取得了 86.68% 的 mAP 以及 25.43 的 FPS。因此本方法可以在工业生产中得到应用。不足之处在于对印刷电路板

上特别小的缺陷检测精度还有待提高。此外,针对暗光环境下导致的检测精度过低没有很好的解决办法,后续尝试加入生成对抗网络提高图片分辨率,改善各类网络指标。

#### 参考文献

- [1] 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,DOI:10.19650/j.cnki.cjsi.J2108477.
- [2] 刘小燕,李照明,段嘉旭,等.基于卷积神经网络的印刷电路板环电阻检测与定位方法[J].电子与信息学报,2020,42(9):2302-2311.
- [3] 何国忠,梁宇.基于卷积神经网络的 PCB 缺陷检测[J].图学学报,2022,43(1):21-27.
- [4] GANG S, FABRICE N, CHUNG D, et al. Character recognition of components mounted on printed circuit board using deep learning [J]. Sensors, 2021, 21: 2921.
- [5] KIM J, KO J, CHOI H, et al. Printed circuit board

- defect detection using deep learning via A skip-connected convolutional autoencoder [J]. Sensors, 2021, 21, DOI:10.3390/s21154968.
- [6] 陈晓芳,李季.基于One-Stage目标检测的路面损害检测算法对比分析[J].计算机应用,2021,41(S2):81-85.
- [7] 段仲静,李少波,胡建军,等.深度学习目标检测方法及其主流框架综述[J].激光与光电子学进展,2020,57(12):59-74.
- [8] 方梓锋,张锋.基于K210和YOLOv2的智能垃圾分类平台[J].自动化与仪表,2021,36(8):102-106.
- [9] 冉险生,陈卓,张禾.改进YOLOv2算法的道路摩托车头盔检测[J].电子测量技术,2021,44(24):105-115.
- [10] 徐乐,蔡永华,庞智恒,等.一种基于YOLOv2的目标车辆跟踪算法[J].数字制造科学,2018,16(4):275-281.
- [11] 王启明,何梓林,张栋林,等.基于YOLOv3的雾天场景行人车辆检测方法研究[J/OL].控制工程:1-8[2022-08-09].<https://doi.org/10.14107/j.cnki.kzgc.20211118>.
- [12] 邵海见,严晨旭,邓星.基于YOLOv3模型的高阶目标检测方法[J].山东大学学报:理学版,2022,57(3):11.
- [13] 孟晓龙,任正非.基于改进YOLOv3的震后遥感图像倒塌建筑物检测[J/OL].激光与光电子学进展:1-14[2022-08-09].<http://kns.cnki.net/kcms/detail/31.1690.TN.20220211.1846.024.html>.
- [14] 孙永鹏,钟佩思,刘梅,等.基于YOLOv4算法的冲压件缺陷检测[J].锻压技术,2022,47(1):222-228.
- [15] 党宏社,薛萌,郭琴.基于改进的YOLOv4绝缘子掉片故障检测方法[J].陶瓷避雷器,2022(1):211-218.
- [16] 杨文静,陈明,冯国富.基于图像增强的水下视频鱼类识别方法[J].激光与光电子学进展,2021,58(22):294-303.
- [17] 鞠默然,罗海波,王仲博,等.改进的YOLO V3算法及其在小目标检测中的应用[J].光学学报,2019,39(7):253-260.
- [18] 郭璠,张泳祥,唐璇,等.YOLOv3-Λ:基于注意力机制的交通标志检测网络[J].通信学报,2021,42(1):87-99.
- [19] 吴海滨,魏喜盈,刘美红,等.结合空洞卷积和迁移学习改进YOLOv4的X光安检危险品检测[J].中国光学,2021,14(6):1417-1425.
- [20] 罗晖,贾晨,李健.基于改进YOLOv4的公路路面病害检测算法[J].激光与光电子学进展,2021,58(14):336-344.
- [21] 李佳益,高亚静,刘丹丹,等.基于K-means聚类算法的生鲜食品安全预警研究[J].产业与科技论坛,2021,20(24):31-33.
- [22] HU J, SHEN L, SUN G. Squeeze and excitation networks[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition,2018: 7132-7141.
- [23] WANG Q, WU B, ZHU P, et al. ECA-Net: Efficient channel attention for deep convolutional neural networks [C]. 2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), IEEE, 2020.

### 作者简介

刘涛,硕士,主要研究方向为目标检测、图像识别等。

E-mail: liutao199901@163.com

张涛(通信作者),副教授,博士,主要研究方向为视频处理、图像处理等相关理论与应用方面的研究。

E-mail: tzhang@qust.edu.cn