

DOI:10.19651/j.cnki.emt.2107135

基于改进 YOLOv4 算法的 PCB 缺陷检测*

李澄非 蔡嘉伦 邱世汉 梁辉杰
(五邑大学 智能制造学部 江门 529020)

摘要: 现有印刷电路板(PCB)缺陷检测方法,多采用参考法进行检测,对图片配准要求高,不仅耗时且定位误差大。YOLOv4 速度快,精度高,但应用在 PCB 检测上存在着漏检的情况,对小目标检测效果不佳,现提出了一种基于改进 YOLOv4 算法的 PCB 缺陷检测方法。首先,以 CSPDarknet53 为主干网络,采用单特征层结构,避免了数据不均衡带来的先验框分配问题。然后,将网络中的 5 次卷积改进为 CSP 结构的残差单元,进一步提高特征提取能力。最后,采取 K-means++ 对先验框重新进行聚类,提高模型训练效果。实验部分采取北京大学发布的 PCB 数据集进行训练,结果表明,改进后的算法平均精度均值(mAP)达到 98.71%,在精度上优于其他常见的目标检测算法。

关键词: 电路板;机器视觉;YOLOv4;小目标;目标检测

中图分类号: TP391;TP18 **文献标识码:** A **国家标准学科分类代码:** 520.6040

Defect detection of PCB based on improved YOLOv4 algorithm

Li Chengfei Cai Jialun Qiu Shihan Liang Huijie

(Faculty of Intelligent Manufacturing, Wuyi University, Jiangmen 529020, China)

Abstract: Reference template is used in most methods of PCB defect detection, which is very time consuming and causes a big position error. YOLOv4 is fast but it misses the object easily in PCB detection and its accuracy is not high in detecting the small object. Therefore, the method of PCB defect detection based on improved YOLOv4 algorithm is proposed. Firstly, CSPDarknet53 is used as backbone and the structure of single feature layer is adopted, which avoids the prior boxes assignment problem caused by data imbalance. Then, five convolutions are improved using CSP to increase further the ability of feature extract. Finally, prior boxes are gotten by using K-means++ to improve the training effect. In the experiment, Peking University PCB public dataset is used for training. The result shows that mean average precision of our algorithm achieves 98.71% and it has a better performance compared with other several classical object detection algorithms.

Keywords: circuit board; machine vision; YOLOv4; small object; object detection

0 引言

近年来,基于机器视觉的 PCB 缺陷检测在半导体产业备受关注。PCB 的制作过程十分复杂,工序繁琐,这就导致了 PCB 存在着复杂多样的缺陷(漏孔、缺口、断路、短路、毛刺、余铜等)。机器视觉可以极大地克服人工检测准确率不高,劳动强度大,效率低下等弊端。因此,研究出更加有效的图像处理算法,已经成为 PCB 行业的竞争力所在。

PCB 缺陷检测主要存在着两个问题:1) PCB 类型众多,样式多种多样,设计规则复杂,检测算法很难兼容多种类型的电路板;2) 表面缺陷复杂多样,检测困难。

针对这些问题,很多学者提出了各自的解决方法,Malge 等^[1]采用了形态学二值化对 PCB 进行检测。Kaur 等^[2]

提出了图像差分和基于分割的方法来检测 PCB。Gaidhane 等^[3]通过相似度测量的方法来检测。起初,在特征分类上,检测领域多采用 HOG 和 SIFT 进行分类^[4-9],存在着较大的局限性,对于复杂多样的缺陷很难进行精准分类。近年来,由于深度学习远超传统的性能^[10],越来越多的学者将深度学习应用在缺陷检测领域^[11-13],同样带动了深度学习在 PCB 缺陷检测领域的应用。王永利等^[14]提出了基于卷积神经网络的 PCB 缺陷检测和识别算法,大大提高了识别准确率。孙灿等^[15]提出了基于改进 Inception-ResNet-v2 的 PCB 缺陷检测方法,较经典卷积神经网络更优。刘伟森等^[16]提出了基于多尺度轻量级卷积网络的 PCB 裸板缺陷识别算法,采用多尺度的方法,极大提高了识别准确率。

收稿日期:2021-07-01

* 基金项目:2017 年广东省科技发展专项(2017A010101019)、2019 年广东省普通高校特色创新类项目(2019KTSCX181)资助




图 2 预测框

其中,

$$Loss_{IoU} = \sum_{i=0}^{s^2} \sum_{j=0}^B I_{ij}^{obj} \left[1 - IoU + \frac{\rho^2(b, b^{gt})}{c^2} + \alpha v \right] \quad (6)$$

$$v = \frac{4}{\pi^2} \left(\arctan \frac{w^{gt}}{h^{gt}} - \arctan \frac{w}{h} \right)^2 \quad (7)$$

$$\alpha = \frac{v}{1 - IoU + v} \quad (8)$$

$$Loss_{conf} = - \sum_{i=0}^{s^2} \sum_{j=0}^H I_{ij}^{obj} \left[\hat{C}_i^j \lg(C_i^j) + (1 - \hat{C}_i^j) \lg(1 - C_i^j) \right] -$$

$$\lambda_{noobj} \sum_{i=0}^{s^2} \sum_{j=0}^B I_{ij}^{noobj} \left[\hat{C}_i^j \lg(C_i^j) + (1 - \hat{C}_i^j) \lg(1 - C_i^j) \right] \quad (9)$$

$$Loss_{class} = - \sum_{i=0}^{s^2} I_{ij}^{obj} \sum_{c \in classes} \left[\hat{P}_i^j \lg(P_i^j) + (1 - \hat{P}_i^j) \lg(1 - P_i^j) \right] \quad (10)$$

式中: s^2 表示特征图的网格数目; B 表示每个网格分配到的先验框数量; $I_{ij}^{obj}, I_{ij}^{noobj}$ 分别表示第 i 个网格第 j 个先验框包含目标和不包含目标的概率, 包含则概率为 1, 否则为 0; $\rho(b, b^{gt})$ 表示预测框与真实框中心点的欧氏距离; c 表示预测框和真实框最小外接矩形的对角线距离; IoU 表示真实框与预测框的交并比; α 是权衡参数; v 是衡量长宽比一致性的参数; w^{gt} 和 h^{gt} 是真实框的宽高; w 和 h 是预测框的宽高; λ_{noobj} 负责调整背景置信度权重; C_i^j 和 \hat{C}_i^j 分别表示第 i 个网格第 j 个真实框和预测框的置信度; P_i^j 和 \hat{P}_i^j 分别表示第 i 个网格第 j 个真实框和预测框的类别概率。

2 改进的 YOLOv4 算法

2.1 单特征层结构

YOLOv4 采用的是 3 个输出特征层的结构, 负责检测小中大 3 种目标, 在进行训练前, 会预先分配给 3 个特征层各 3 个尺度的先验框, 但这就存在着一个问题, 在数据集不均衡的情况, 取不到最好的训练效果。假设数据集中存

在大量小尺度的先验框, 那么聚类结果获得的先验框都是小尺度的, 显然, 3 个特征层都会分配到小尺度的先验框, 进一步分析, 对于小中特征层而言, 由于数据集中基本不存在大的目标, 小中特征层由于降采样次数过多, 捕获的小目标信息较少, 达不到好的训练效果。

PCB 缺陷数据集宽高分布如图 3 所示, 可以看出大部分缺陷的宽高都集中在 30 pixel 以下, 不到图像分辨率的 1/10, 偏小, 而其余缺陷稍大, 但也不超过 70 pixel, 不到图像分辨率的 1/5, 整个数据集宽高都偏小, 属于上述讨论的情况。YOLOv4 分配 3 个尺度先验框的操作并不能达到较优的结果。




图 3 PCB 缺陷数据集宽高分布

针对这种情况, 考虑采取单特征层的结构来解决, 改进后的结构如图 4 所示, 采取的是浅层的特征图作为输出, 刚好能对应数据集中存在大量小缺陷的情况, 解决了原 YOLOv4 存在的先验框分配不当问题, 提高了模型精度。与此同时, 由于是单特征层的结构, 相较于原来 3 层的结构精简了许多, 模型参数减少了许多, 约为 33.5%。

2.2 CSPSingleLayer

为了进一步提升网络的特征提取能力, 引入了 CSP 结构。将 SingleLayer 中的 5 次卷积改进为 CSP 结构的残差单元, 命名为 CSPRes2。改进结构如图 5 所示, 由于将输入分割再合并, 有效地减少了梯度信息的复用, 提高了学习能力, 使得网络拥有更强的特征提取能力。将 SingleLayer 中的 2 个 5 次卷积替换为 CSPRes2 结构, 最终网络结构如图 6 所示。

2.3 K-means++ 聚类

在 YOLOv4 算法中, 先验框的选取直接影响着模型训练效果的好坏。原 YOLOv4 算法采取的是 K-means 聚类方法来筛选先验框。

采取 K-means 进行聚类的方式, 存在一个问题, 聚类效果的好坏很大程度上决定于初始聚类中心的选取。本文采取 K-means++ 来进行聚类, 能够保证相对较好的聚类效果。一般来说, 初始的聚类中心应当尽可能地远离, 进行 K-means 聚类前, 应对初始聚类中心进行筛选, 可以

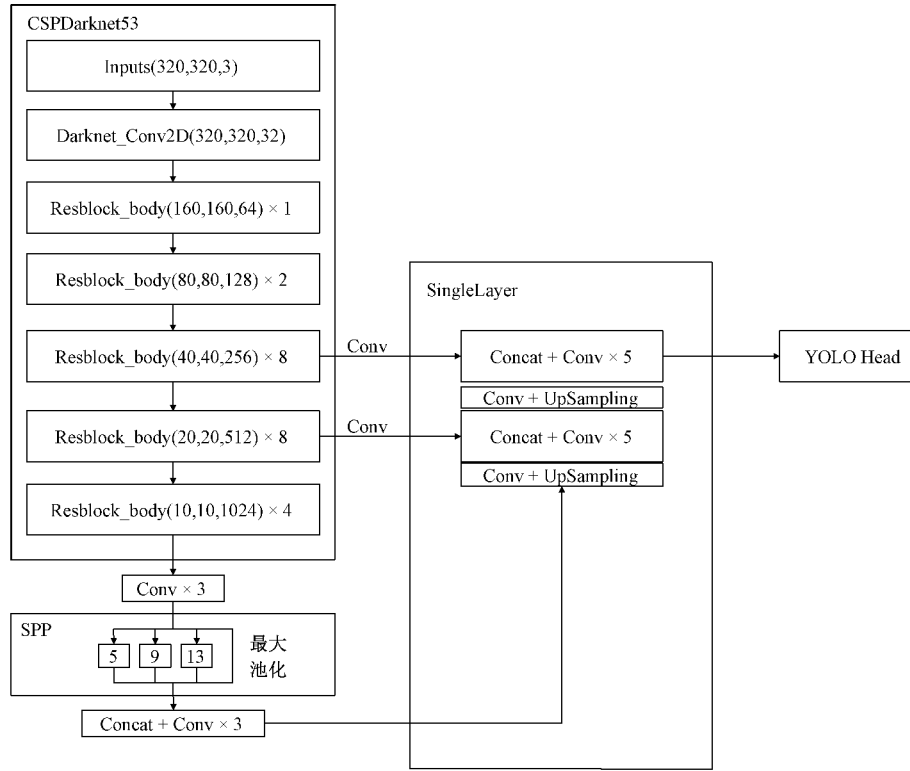


图4 单特征层结构




图5 CSPRes2 结构

很大程度上改进 K-means 的效果。首先,从 PCB 数据集中随机挑选一个样本,设为初始的聚类中心,计算每个样本 x_i 与已有聚类中心的最小距离 $M(x_i)$,如式(11)、(12)所示。其次,计算各个数据样本被选为下个聚类中心的概率 $P(x_i)$,如式(13)所示。最后,按照轮盘法,确定下一个聚类中心。

$$M(x_i) = \min\{D(x_i, cent_j)\} \quad (11)$$

$$D(x_i, cent_j) = 1 - IoU(x_i, cent_j) \quad (12)$$

$$P(x_i) = \frac{M(x_i)^2}{\sum_{x_i \in X} M(x_i)^2} \quad (13)$$

重复上述计算步骤直至选出 K 个聚类中心。至此初始聚类中心的筛选结束,开始进行聚类,将各个样本分配给相距最小的聚类中心 C_k ,并通过式(14)更新聚类中心,重复分配更新步骤直至聚类中心不变。

$$C_k = \frac{1}{|C_k|} \sum_{x_i \in C_k} x_i \quad (14)$$

3 实验与分析

3.1 数据集

本文采用的是北京大学发布的 PCB 数据集来进行实验。数据集中存在着 6 种缺陷,分别为漏孔(Mh)、缺口(Mb)、断路(Oc)、短路(Sh)、毛刺(Sp)、余铜(Sc)。工业上常常存在着数据集较小的问题,PCB 数据集也不例外,考虑于此,对数据集扩充,进行了数据增强,将大分辨率的 PCB 图进行裁剪、旋转、亮度调节等操作。扩充后数据集含有 10 000 张缺陷图片,扩充后的数据集如表 1 所示。数据集按照 8 : 2 分为训练集和测试集。

表 1 数据集

缺陷	漏孔	缺口	断路	短路	毛刺	余铜
数量	1 714	1 735	1 641	1 634	1 619	1 657

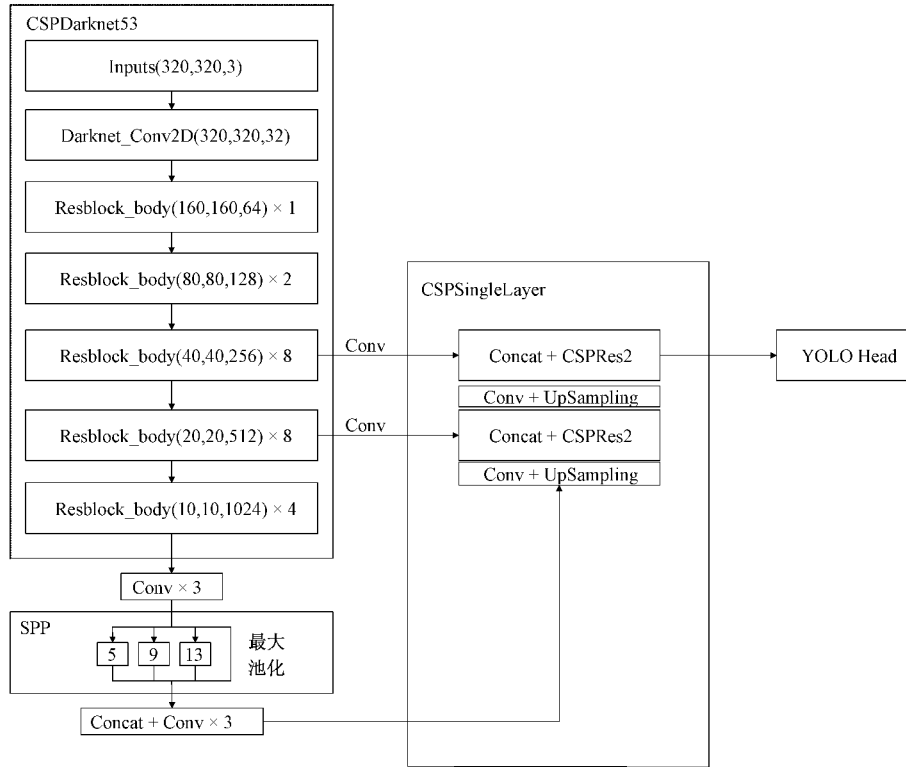


图 6 改进后 YOLOv4 网络结构

3.2 先验框聚类

采用 K-means 和 K-means++ 算法对训练数据集重新进行聚类,生成先验框。由于本文网络采取的是单特征层的结构,因此所有尺度的先验框都分配给同一层,即降采样倍数为 8 的特征层,聚类结果如表 2 所示。

表 2 先验框聚类结果

算法	先验框
K-means	(9,8), (10,11), (18,9), (13,12), (10,17), (16,16), (12,25), (25,13), (21,22)
K-means++	(10,10), (13,12), (10,18), (19,10), (15,15), (13,26), (26,13), (20,20), (27,26)

3.3 评价指标

目标检测分为两个任务,即定位和分类。为了能够同时衡量这两个任务的准确率,采取了平均精度均值(mAP)作为评价指标,mAP 指的是各类缺陷平均精度(AP)的平均值。整体计算如式(15)~(18)所示。

$$P = \frac{TP}{TP + FP} \tag{15}$$

$$R = \frac{TP}{TP + FN} \tag{16}$$

$$AP = \int_0^1 P(R) dR = \sum_{k=1}^N P(k) \Delta R(k) \tag{17}$$

$$mAP = \frac{\sum_{i=0}^n AP(i)}{n} \tag{18}$$

式中: P 、 R 分别表示精确率和召回率,精确率可以很好表示检测的准确率,召回率反映漏检情况; TP 、 FP 、 FN 分别表示真正例(检测和真实都为正例)、假正例(检测为正例,真实为负例)以及假负例(检测为负例,真实为正例); n 表示缺陷类别数。

3.4 实验分析

实验所用硬件配置为 Intel(R) Core(TM) i9-10850K CPU@3.60 GHz, NVIDIA GeForce RTX 3080。软件环境为 CUDA 11.1, cuDNN v8.0.4。训练过程中, batch_size 设置为 4, 初始学习率为 0.0001, 采取学习率衰减的方式, 最终学习率为 0.000001, 迭代轮次设置为 100。采取 320 分辨率的输入来进行训练, 检测阈值设置为 0.5。本文算法是基于 YOLOv4 进行改进的, 改进前后, 训练过程中损失函数的变化情况及 AP 对比分别如图 7、8 所示。从损失函数可以看出, 在迭代轮次为 100 时, 网络基本收敛, 原 YOLOv4 算法损失值为 1.944, 而改进后的 YOLOv4 算法损失值为 1.443。从 AP 对比上可以看出, 改进后的算法, 各个缺陷的 AP 都得到了提升, mAP 达到 98.71%, 提升了 1.6%。可见, 改进后的算法在精度上得到了提升, 优于原 YOLOv4 算法。

为了直观地看到检测算法对缺陷的检测效果, 从测试集中挑选样例, 分别使用 YOLOv4 算法和本文算法进行检

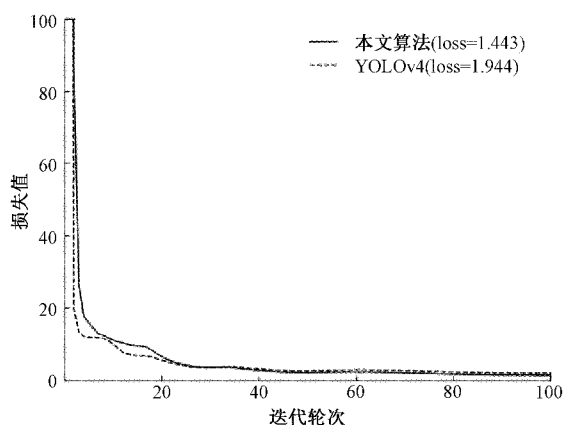


图7 损失函数变化曲线

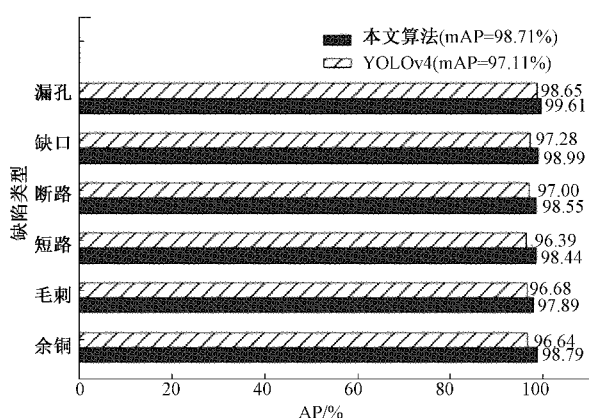


图8 改进前后 AP 对比

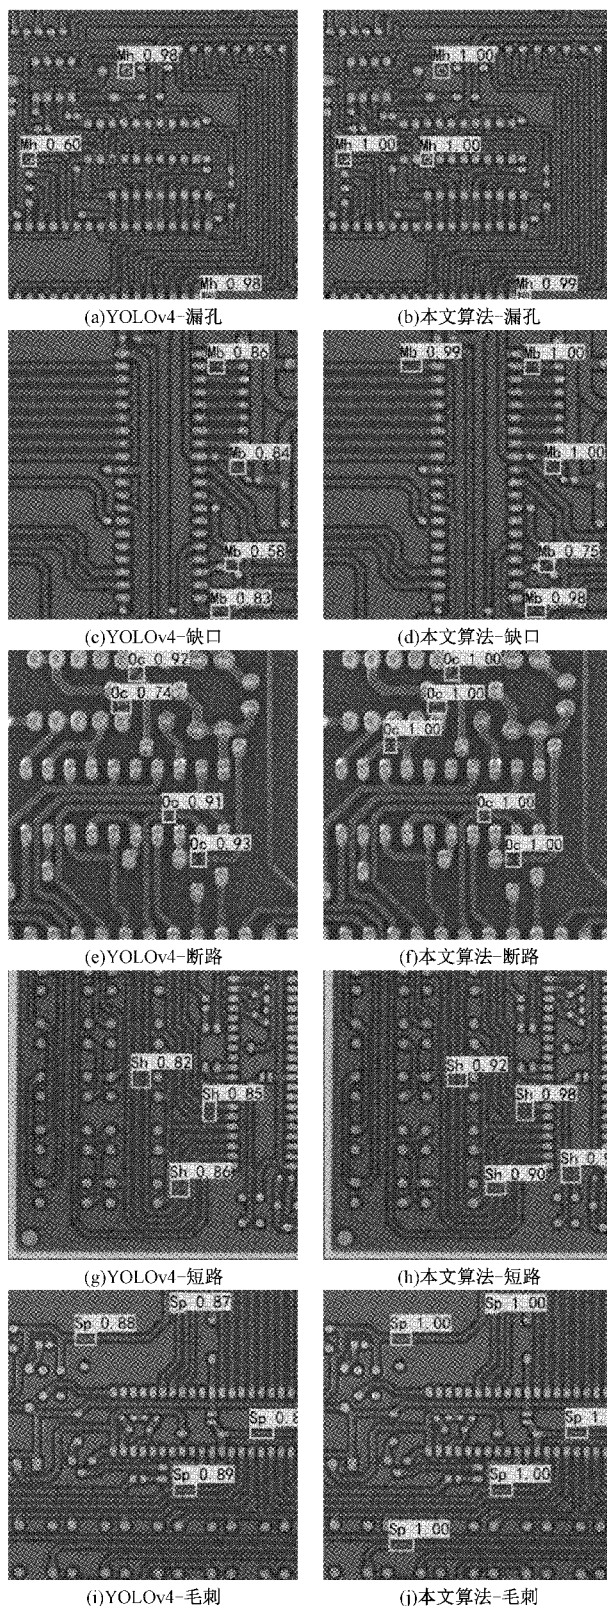
测,结果如图9所示。原YOLOv4算法对于6类缺陷的检测效果分别如图9(a)、(c)、(e)、(g)、(i)和(k)所示,可以看出,原算法预测置信度不高,当预测置信度低于阈值时,就会出现漏检的情况。而本文算法对于6种缺陷的检测效果分别如图9(b)、(d)、(f)、(h)、(j)和(l)所示,可见,相比原算法,改进后的算法预测置信度高,能够检测出原算法漏检的缺陷。

召回率可以很好地衡量漏检程度,为了进一步量化,采取召回率来评价,如图10所示,改进后各类缺陷的召回率都有了明显地提升,说明本文算法针对YOLOv4进行改进,确实有效地提高了算法的召回率,减少了漏检的情况。

为了测试改进网络结构以及K-means++聚类算法在PCB缺陷数据集中的检测效果,设置了4组实验对检测效果进行评估,消融实验结果如表3所示。实验1为原始YOLOv4算法,采取原网络结构以及K-means聚类算法来进行实验,以获取基准值。实验2仍采取K-means聚类,但改进了网络,使用了单特征层结构(SingleLayer)。实验3在实验2的基础上改进了网络的特征提取能力,使用了CSPSingleLayer结构。实验4则在实验3的基础上采取K-means++聚类进行实验。

对比实验1和2,采取单特征层结构后,各类缺陷的

AP均获得了提高,FPS也由原来的33.49提高到39.03。这是因为采取了单特征层结构后,聚类获得的先验框都分配到了同一个特征层上,原先由于数据不均衡导致的先验框尺寸分配不当问题也就不存在了,且单特征层采取的是



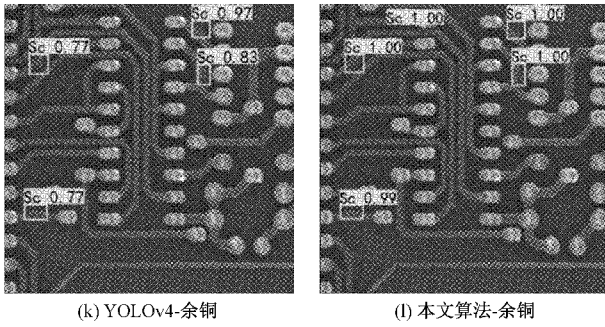


图 9 检测效果对比




图 10 改进前后召回率对比

降低采样的特征层,对小目标的检测有利,精度自然提高,同时由于网络的简化,检测速度加快。对比实验 2 和 3,改进网络中的 5 次卷积模块,引入 CSP 结构后,mAP 获得了提高,速度基本不变。主要是因为采取了 CSP 结构,将输入部分进行分割,最后再进行合并,能够有效减少梯度信息的重复,更利于网络的学习,从而提高了特征提取能力。

表 4 不同算法检测性能的对比

算法	FPS	mAP/ %	AP/%					
			漏孔	缺口	断路	短路	毛刺	余铜
Faster R-CNN(VGG16)	1.02	71.55	88.90	81.51	77.91	69.40	51.13	60.45
Faster R-CNN(ResNet101)	0.56	85.30	90.04	87.45	87.92	89.30	78.27	78.81
Efficientdet(D0) ^[22]	25.59	71.93	96.84	67.86	54.30	85.84	61.26	65.45
SSD ^[23]	53.39	91.28	96.14	90.93	79.84	94.41	92.23	94.13
YOLOv4	33.49	97.11	98.65	97.28	97.00	96.39	96.68	96.64
本文算法	38.21	98.71	99.61	98.99	98.55	98.44	97.89	98.79

4 结 论

本文提出了一种基于改进 YOLOv4 算法的 PCB 缺陷检测方法,该方法在原有 YOLOv4 算法的基础上进行了改进,首先针对数据集不均衡的问题,将网络改进为单特征层结构,其次为了进一步提高网络的特征提取能力,在 5 次卷积模块中引入了 CSP 进行改进,最后,采取 K-means++ 对数据集重新聚类,获取更优的先验框。实验结果表明,本

对比实验 3 和 4,采取 K-means++ 进行先验框的重新聚类,mAP 上升。主要是因为 K-means++ 聚类出了更加能代表数据集的先验框,有效提高了模型的训练效果,更好的先验框带来的是模型精度的提升。

表 3 消融实验

实验 编号	FPS	mAP/ %	AP/%					
			漏孔	缺口	断路	短路	毛刺	余铜
1	33.49	97.11	98.65	97.28	97.00	96.39	96.68	96.64
2	39.03	98.28	99.86	97.82	97.91	97.76	97.76	98.54
3	37.45	98.48	99.73	99.45	97.96	97.41	97.24	99.13
4	38.21	98.71	99.61	98.99	98.55	98.44	97.89	98.79

为了验证本文算法相比其他目标检测算法的优劣,进行了对比实验,结果如表 4 所示。Faster R-CNN 是典型的二阶段检测算法,主干网络常用 VGG16 和 ResNet101。Efficientdet、SSD 以及 YOLOv4 都是目前常用的一阶段检测算法。对比各个算法在数据集上的表现可以发现:SSD 和 YOLOv4 算法性能较好,而 Faster R-CNN 和 Efficientdet 算法性能较差。Faster R-CNN 属于二阶段算法,速度远慢于一阶段算法,在 PCB 数据集上检测效果不佳,主要是由于网络感受野过大,不利于小目标的检测,且先验框的比例是固定的,无法自由调整。而 Efficientdet 表现差是由于主干网络降采样倍数过大,存在太多底层无用信息,不利于 PCB 缺陷的检测。本文算法在 PCB 缺陷检测上具有更好的精度,mAP 达到了 98.71%,和原 YOLOv4 相比,各类缺陷的 AP 都获得了提高,mAP 提高了 1.6%。而在检测速度上,本文算法 FPS 为 38.21,速度不及 SSD,可以满足工业检测速度的要求。

文提出的检测算法在 PCB 数据集上 mAP 达到了 98.71%,FPS 达到 38.21,相比其他常见检测算法,具有较好的精度和检测速度,能够满足工业检测的需求。

参考文献

[1] MALGE P S, NADAF R S. PCB defect detection, classification and localization using mathematical morphology and image processing tools [J]. International Journal of Computer Applications, 2014,

- 87(9): 40-45.
- [2] KAUR B, KAUR G, KAUR A. Detection and classification of printed circuit board defects using image subtraction method[C]. 2014 Recent Advances in Engineering and Computational Sciences(RAECS), IEEE, 2014:1-5.
- [3] GAIDHANE V H, HOTE Y V, SINGH V. An efficient similarity measure approach for PCB surface defect detection[J]. Pattern Analysis and Applications, 2018, 21(1): 277-289.
- [4] 陈寿宏,赵爽,马峻,等.基于多特征的SVM多分类PCB焊点缺陷检测方法[J].激光杂志,2019,40(6): 21-26.
- [5] LI Y F, LI S Y. Defect detection of bare printed circuit boards based on gradient direction information entropy and uniform local binary patterns[J]. Circuit World,2017, 43(4): 145-151.
- [6] 张松松,詹智财.基于SIFT特征与支持向量机的车辆分类系统研究[J].电脑知识与技术,2012,8(17): 4277-4280.
- [7] CHAUDHARY V, DAVE I R, UPLA K P. Automatic visual inspection of printed circuit board for defect detection and classification[C]. International Conference on Wireless Communications, Signal Processing and Networking, 2017: 732-737.
- [8] 马浩,景军锋,苏泽斌,等.基于LBP和HOG特征的图案织物缺陷检测[J].电子测量与仪器学报,2018, 32(4):95-102.
- [9] 魏利胜,丁坤,段志达,等.融合单应性约束SIFT特征匹配的轴承滚子检测[J].电子测量与仪器学报,2019, 33(9):107-113.
- [10] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks [J]. Advances in Neural Information Processing Systems, 2012, 25: 1097-1105.
- [11] 李辉,钟平,戴玉静,等.基于深度学习的输电线路锈蚀检测方法的研究[J].电子测量技术,2018,41(22):54-59.
- [12] 向宽,李松松,栾明慧,等.基于改进Faster RCNN的铝材表面缺陷检测方法[J].仪器仪表学报,2021, 42(1):191-198.
- [13] 赵志勇,叶林,桑红石,等.深度学习在布匹缺陷检测中的应用[J].国外电子测量技术,2019,38(8):110-116.
- [14] 王永利,曹江涛,姬晓飞.基于卷积神经网络的PCB缺陷检测与识别算法[J].电子测量与仪器学报,2019, 33(8): 78-84.
- [15] 孙灿,邓小颖,李扬,等.基于改进Inception-ResNet-v2的PCB缺陷检测[J].信息技术,2020,44(9): 33-36.
- [16] 刘伟森,方亦建.基于多尺度轻量级卷积网络的PCB裸板缺陷识别算法[J].自动化与信息工程,2020, 41(5): 20-25,41.
- [17] REDMON J, DIVVALA S, GIRSHICK R, et al. You only look once: Unified, real-time object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2016: 779-788.
- [18] REDMON J, FARHADI A. YOLO9000: Better, faster, stronger [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 7263-7271.
- [19] REDMON J, FARHADI A. Yolov3: An incremental improvement [C]. Proceedings of 2018 IEEE Conference on Computer Vision and Pattern Recognition, 2018:1-6.
- [20] BOCHKOVSKIY A, WANG C Y, LIAO H Y M. Yolov4: Optimal speed and accuracy of object detection[C]. IEEE conference on Computer Vision and Pattern Recognition, 2020.
- [21] REN S 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.
- [22] TAN M X, PANG R M, LE Q V. EfficientDet: Scalable and efficient object detection[C]. IEEE/CVF Conference on Computer Vision and Pattern Recognition(CVPR), 2020: 10778-10787.
- [23] LIU W, ANGUELOV D, ERHAN D, et al. Ssd:Single shot multibox detector [C]. European Conference on Computer Vision, Springer, Cham, 2016: 21-37.

作者简介

李澄非,工学博士,副教授,主要研究方向为图像信息处理、机器视觉、复杂工业过程故障诊断及检测等。

E-mail:Car1234566@sina.com

蔡嘉伦,硕士研究生,主要研究方向为机器视觉、深度学习。

E-mail:604562212@qq.com

邱世汉,硕士研究生,主要研究方向为机器视觉、深度学习。

E-mail:523186919@qq.com

梁辉杰,硕士研究生,主要研究方向为机器视觉、深度学习。

E-mail:1194158012@qq.com