

DOI: 10.19650/j.cnki.cjsi.J2108477

基于多注意力 Faster RCNN 的噪声干扰下 印刷电路板缺陷检测*

陈仁祥¹, 詹赞¹, 胡小林², 徐向阳¹, 蔡东吟¹

(1. 重庆交通大学交通工程应用机器人重庆市工程实验室 重庆 400074;

2. 重庆工业大数据创新中心有限公司 重庆 400056)

摘要:针对工业环境中噪声干扰导致的印刷电路板缺陷检测困难的问题,提出基于多注意力 Faster RCNN 的印刷电路板缺陷检测方法,分别于特征提取以及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,提升检测效果。首先使用分离注意力网络提取缺陷特征,使网络自动关注到缺陷特征,以降低噪声干扰的影响;其次,使用平衡特征金字塔融合不同分辨率特征,利用非局部注意力机制对融合特征进行全局感受野内不同区域特征的加权,增强其缺陷表征能力并进一步抑制噪声干扰;最后,依据所获得的特征表示,利用区域建议网络生成缺陷候选框并利用全连接层对其进行位置以及类别的确定以得到检测结果。在不同程度噪声干扰下的印刷电路板缺陷数据集上进行实验验证,平均检测精度达到 92.4%,证明了所提方法的有效性和可行性。

关键词:印刷电路板;缺陷检测;噪声干扰;多注意力

中图分类号: TH39 **文献标识码:** A **国家标准学科分类代码:** 510

Printed circuit board defect detection based on the multi-attentive faster RCNN under noise interference

Chen Renxiang¹, Zhan Zan¹, Hu Xiaolin², Xu Xiangyang¹, Cai Dongyin¹

(1. Chongqing Engineering Laboratory for Transportation Engineering Application Robot, Chongqing Jiaotong University, Chongqing 400074, China; 2. Chongqing Innovation Center of Industrial Big-Data Co., Ltd., Chongqing 400056, China)

Abstract: To address the problem of PCB defect detection caused by noise interference in industrial environment, a PCB defect detection method based on the multi-attention Faster RCNN is proposed. The attention mechanism is introduced into the feature extraction and feature fusion parts to obtain feature representations with anti-interference ability. First, the defective features are extracted by using a split-attention network that automatically focuses on the defective features to reduce the effect of noise interference. Secondly, a balanced feature pyramid is used to fuse different resolution features, and a non-local attention mechanism is utilized to weight the fused features to different regions within the global perceptual field to enhance their defect characterization and further suppress noise interference. Finally, based on the obtained feature representation, the regional proposal network is used to generate defect candidate box. The fully connected layer is utilized to determine defects' position and category to obtain the detection results. Experiments are implemented on the printed circuit board defect data sets under different degrees of noise interference. The average detection accuracy reaches 92.4%, which proves the effectiveness and feasibility of the proposed method.

Keywords: printed circuit board; defect detection; noise interference; multi-attention

0 引言

印刷电路板是组装电子零件用的基板和支撑体,广

泛应用于各种电控产品中^[1]。其质量好坏直接影响着电控产品的性能,因此进行印刷电路板的缺陷准确检测具有重要意义。

目前,基于机器视觉的自动光学检测因其操作简便、

收稿日期:2021-08-26 Received Date: 2021-08-26

* 基金项目:国家自然科学基金(51975079)、国家重点研发项目(2018YFB1306601)、重庆市教委科学技术研究项目(KJQN201900721)、重庆市研究生导师团队项目(JDDSTD2018006)资助

工作效率高等特点已成为缺陷检测的主流方向^[2]。但传统的基于机器视觉的检测方法^[3]依赖于手动特征提取的先验知识,检测过程复杂且无法保证良好的鲁棒性。

近些年来,随着以具有强大特征自提取能力的卷积神经网络为代表的深度学习在诸多计算机视觉领域的成功应用,不少基于深度学习的检测算法也被广泛应用于印刷电路板缺陷检测中。Huang等^[2]使用测试图像与模板图像进行差分运算以获取缺陷区域,再利用神经网络对提取到的缺陷区域进行特征提取,实现印刷电路板6种常见缺陷的检测;Tang等^[4]利用共享卷积神经网络分别对测试图像与模板图像进行特征的提取,再对特征进行差分运算,最后利用SSD检测算法实现印刷电路板缺陷的定位及分类。这些方法计算测试图像与模板图像的相似性,并利用神经网络避免人工提取特征,实现了印刷电路板缺陷的检测。但计算相似性方法的有效性依赖于测试图像与模板图像较好的匹配,这在种类繁多、环境复杂的实际生产中往往较难实现。针对该问题,Ding等^[5]联合双阶段检测算法Faster RCNN以及特征金字塔网络(feature pyramid network, FPN)提出了一个端到端的印刷电路板缺陷检测网络TDD-net,实现了缺陷特征自提取,避免了使用模板图像,极大地简化了印刷电路板缺陷的检测流程;Hu等^[6]利用引导锚区域建议网络(guided anchoring region proposal network, GARPN)替换区域建议网络(region proposal network, RPN)以自适应地生成锚框,实现了对印刷电路板微小缺陷的较好检测;Adibhatla等^[7]使用以GoogleNet作为特征提取的Tiny-YOLOV2网络,强化了缺陷特征的表达,实现了印刷电路板常见缺陷的检测。这些方法使用卷积神经网络自动提取印刷电路板图像的缺陷特征,有效实现了印刷电路板常见缺陷的检测。但这些方法未考虑噪声干扰的影响。在实际工程中,由于电磁干扰、镜头抖动等原因,图像在生成和传输过程中难免会受到噪声的污染^[8]。噪声的存在会极大地干扰网络对缺陷特征的提取能力,降低网络对缺陷的检测精度。

注意力机制模拟人类视觉系统提取图像信息的过程,通过对聚焦区域投入更多注意力以获得有效的细节信息,使人类能够对海量的输入信息进行合理的抑制和增强^[9]。在检测网络中引入注意力机制,通过为有效缺陷特征和无效的干扰分别赋予不同的权重,从而达到抑制干扰,增强有效特征的目的。朱江等^[10]利用注意力机制将不同位置的权重映射到特征通道,解决了曲轴瓦盖图像特征不明显的问题;潘云龙等^[11]利用具有特征复用的注意力模块,解决了结构体细微裂纹检测中背景杂质干扰的问题。注意力机制的优点为噪声干扰下印刷电路板缺陷检测提供了新的思路。

针对噪声干扰下印刷电路板缺陷检测困难的问题,提出基于多注意力Faster RCNN的印刷电路板缺陷检测方法(printed circuit board defect detection method based on multi-attention faster RCNN, MAFasrter RCNN)。为获得具有较强抗干扰能力的特征表示,首先在特征提取网络中引入注意力机制,使用基于通道分离注意力机制的分离注意力网络提取缺陷特征,利用其对不同通道特征加权的特点,降低噪声干扰的影响,使网络提取到噪声影响小的缺陷特征;其次,于特征融合中引入非局部注意力机制,在融合不同分辨率特征的基础上,进行全局感受野下区域特征的加权,融合后的特征对缺陷表征能力增强并进一步抑制噪声干扰的影响;最后,依据所获得的特征表示,利用区域建议网络生成缺陷候选框,并用全连接层得到缺陷具体位置以及类别。

1 多注意 Faster RCNN 原理

1.1 多注意力 Faster RCNN 结构

所提出的多注意力Faster RCNN检测网络是一个基于Faster RCNN的两阶段检测网络,其主要结构包括特征提取、特征融合、缺陷候选框生成、类别及位置确定。网络整体结构如图1所示。

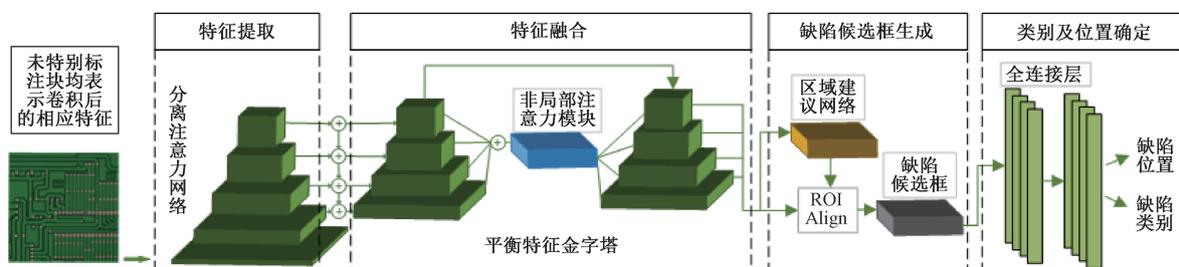


图1 网络整体结构

Fig.1 Network structure

1) 特征提取:使用基于分离注意力机制的分离注意力网络提取输入图像不同分辨率的特征,降低噪声干扰

的影响。

2) 特征融合:使用基于非局部注意力的平衡特征金字塔对不同分辨率特征进行融合以得到具有抗干扰能力的特征表示。

3) 缺陷候选框生成:依据所得到的特征表示,利用区域建议网络生成缺陷候选框,再利用 ROI Align 将缺陷区域特征池化到 7×7 大小。

4) 类别及位置确定:将缺陷候选框特征输入全连接层得到具体的位置信息以及类别信息。

1.2 分离注意力网络

分离注意力网络(split-attention network, Resnest)是一种具有跨通道表示的特征提取网络^[12]。其整体结构分为 4 个部分,每个部分由多个分离注意力残差块组成,分离注意力残差块构成如图 2 所示。首先将输入按通道平均分为 k 组,接着将每组同样按通道拆分为 R 块,每一块单独使用卷积进行特征的提取,图 2 中卷积 1 和 3 分别表示所使用的卷积核大小为 1×1 和 3×3。

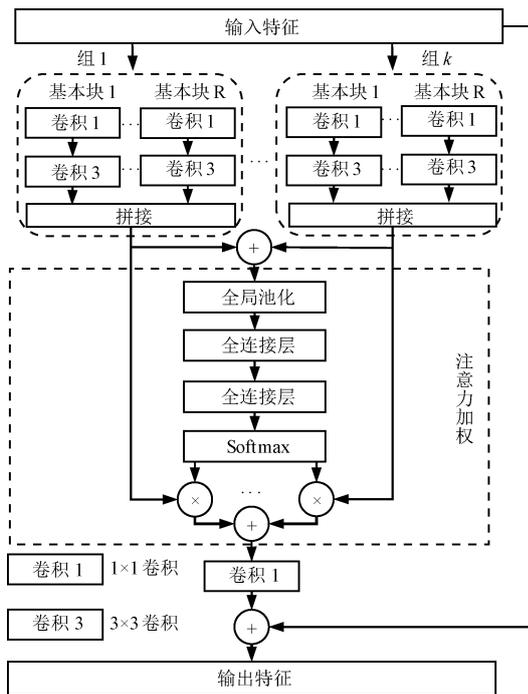


图 2 分离注意力残差块

Fig. 2 Resnest residual block

每一个分离注意力残差块将输入分为 $G = Rk$ 组,使用一系列变换 $\{F_1, F_2, \dots, F_G\}$ 分别作用于每一组的特征,其过程可表示为 $U_i = F_i(X), i \in \{1, 2, \dots, G\}$ 。

使用跨空间维度的全局平均池化来收集具有嵌入式通道统计数据的全局上下文信息,第 c 个通道的计算可

表示为:

$$s_c^k = \frac{1}{HW} \sum_{i=1}^H \sum_{j=1}^W U_c^k(i, j) \quad (1)$$

其中, H, W 分别表示特征图的高和宽, U^k 表示第 k 组

拼接后的特征 $U^k = \sum_{j=R(k-1)+1}^{Rk} U_j$ 。

使用统计的各通道信息作为软注意力权重对不同组特征分段加权,进行有效特征的增强以及无效干扰的抑制。其中第 c 个通道的计算可表示为:

$$V_c^k = \sum_{i=1}^R \alpha_i^k(c) U_{R(k-1)+i} \quad (2)$$

其中, $\alpha_i^k(c)$ 表示分配的权重:

$$\alpha_i^k(c) = \begin{cases} \frac{\exp(\vartheta_i^c(s^k))}{\sum_{j=1}^R \exp(\vartheta_j^c(s^k))}, & R > 1 \\ 1, & R = 1 \\ \frac{1}{1 + \exp(\vartheta_i^c(s^k))}, & R = 1 \end{cases} \quad (3)$$

映射 ϑ_i^c 根据全局上下文表示 s^k 确定第 c 个通道的权重。

1.3 平衡特征金字塔

卷积神经网络在前向传播的过程中,所提取到的特征的语义信息逐渐丰富而细节信息逐渐丢失。Lin 等^[13]在主干网络后添加特征金字塔结构,将具有高语义信息的深层特征与具有丰富细节信息的浅层特征相融合,一方面可以满足检测任务对语义信息以及细节信息的需求,另一方面使用不同分辨率的特征图来预测不同大小的目标,能够在特征层面实现多尺度检测。

但特征金字塔通过简单的特征相加来实现不同特征的融合,这种简单的融合方式不仅会融合各特征图的有效特征,也会将其中的噪声干扰融合进来,加大了噪声的干扰。故本文采用基于非局部注意力机制的平衡特征金字塔^[14]替换传统特征金字塔来进行不同分辨率特征图的融合,对融合得到的特征利用非局部注意力机制计算各特征点的相似性,并以此对特征进行筛选,达到增强有效特征的目的。

如图 1 中所示,平衡特征金字塔网络首先与传统特征金字塔一样在主干网络的基础上添加一条自上而下的线路以融合不同尺度的特征图;其次将所得到的各个特征图融合并通过非局部模块(non-local module)提炼出有效特征;最后将提炼出的特征用于原始特征的增强以达到抑制无效特征、增强有效特征的作用。

非局部模块借鉴图像降噪的非局部操作,分别通过 3 个 1×1 卷积,在全局感受野的情况下计算各特征点之间的相似性并作用于输入特征以达到对特征进行筛选的目的。其表示为:

$$y_i = \frac{1}{C(x)} \sum_{x_j} f(x_i + x_j) g(x_j) \quad (4)$$

其中, x 表示特征图上的不同特征点, f 用于计算特征点之间的相似度, g 表示映射函数即每一个输出的特征点需要与其他所有特征点计算相似性以达到全局感受野的目的。 f 可表示为 $f(x_i + x_j) = e^{\theta(x_i)^T \phi(x_j)}$, C 可表示为 $C(x) = \sum_{j'} f(x_i + x_j)$ 。

2 基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测流程

所提出的基于多注意力 Faster RCNN 的噪声干扰下印刷电路板缺陷检测方法流程如图 3 所示, 具体步骤如下:

- 1) 通过裁剪、旋转以及 cutout 等方法对原始数据集进行数据增强以扩充样本容量, 并划分数据集。
- 2) 构建 MA Faster RCNN 缺陷检测网络并初始化网络参数。
- 3) 以批量的方式将训练集数据以及验证集数据输入到 MA Faster RCNN 检测网络中, 计算损失, 反向传播以更新网络参数并保存最终模型参数。
- 4) 调用训练完成的模型, 将测试集数据输入, 得到缺陷区域候选框以及缺陷类别。
- 5) 利用非极大值抑制删除重复的预测目标, 得到检测结果。

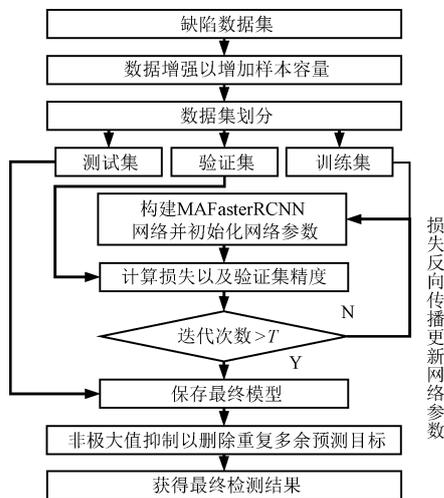


图3 总体检测流程

Fig. 3 Overall flowchart of detection

3 数据分析与处理

3.1 缺陷数据集

所使用的实验数据集来自于北京大学智能机器人开放实验室公开的印刷电路板瑕疵数据集^[2]。该数据集共

包含缺孔、鼠咬、开路、短路、骨刺和假铜等 6 种印刷电路板常见缺陷共包含 693 张图片, 如图 4 所示。缺陷区域均采用矩形框进行标注, 每张图片的标签为包含图片大小、缺陷位置以及类别的 xml 文件。

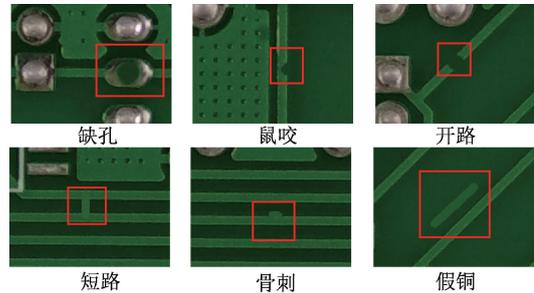


图4 6种常见缺陷

Fig. 4 Six common defects

3.2 噪声缺陷数据的生成

原始缺陷数据集为无干扰情况下的数据, 为模拟工业实际中所采集的噪声数据, 在原始数据集上添加噪声以得到噪声数据集。所添加的噪声为工业生产中常见的因电磁干扰造成的高斯噪声, 为充分模拟工业生产实际情况, 分别设置不同程度高斯噪声的干扰。将添加的高斯噪声的方差由 0.01 至 0.09 平均划分为 5 组, 分别用 $V_{0.01}$ 、 $V_{0.03}$ 、 $V_{0.05}$ 、 $V_{0.07}$ 、 $V_{0.09}$ 表示, 数据加噪前后对比结果如图 5 所示。其中, 实线矩形框标注部分为缺陷区域。由图 5 可知, 在无干扰情况下, 缺陷区域特征明显, 但随着噪声干扰的不断加大, 印刷电路板缺陷区域特征逐渐被噪声所淹没, 特别是在噪声方差大于 0.05 后, 缺陷区域已无法仅凭肉眼辨别出来, 这极大地增加了缺陷检测的难度。

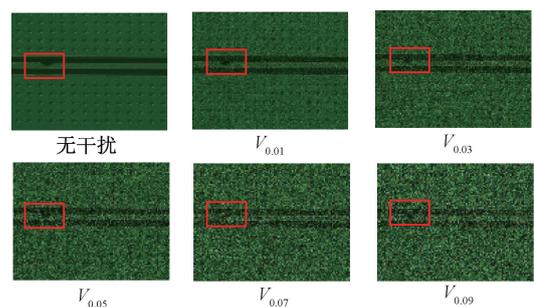


图5 数据加噪前后对比

Fig. 5 Data before and after noise addition

4 实验结果分析

4.1 数据增强

所获取的原始缺陷数据集共包含 693 张图片, 共 2 953 处缺陷, 数据相对较少, 而数据的缺少极易导致训

练的过拟合、检测精度不高以及泛化能力差等问题,为解决该问题,本文采用裁剪、旋转以及 cutout 等方法对原始数据进行增强。

增强后的数据共包含 2 772 张图片,11 812 处缺陷,数据量提升为原来的 4 倍。按照 6:2:2 的比例将数据集划分为训练集、验证集以及测试集。训练集数据用于网络的训练,验证集用于训练过程中可视化训练过程,而测试集用训练好后的网络的测试以证明网络的准确性和泛化性。同时为避免训练集、验证集以及测试集中由于数据增强而导致的高度相似性影响最终结果的准确性,先将原始数据集划分后再分别进行数据增强操作。

4.2 评价指标

由于预测的检测框无法完全和人工标注的真实标签框一致,因此在检测网络输出检测结果时需要将预测框和真实标签框对比,根据预测框和真实标签框的交并比(intersection over union, IOU)来确定所预测的框和真实标签框是否匹配。根据匹配结果将检测结果分为真正例(true positive, TP),真反例(true negative, TN),假正例(false positive, FP)以及假反例(false negative, FN)。

查准率(Precision)表示正确检测到的样本数占总检出样本的比例,反映的是模型对目标的分类能力,通过计算检测结果中预测正确的样本数和所有预测样本数的比例得到,其计算表达式为:

$$Precision = \frac{TP}{TP + FP} \quad (5)$$

查全率(Recall)表示正确检测到的样本数占真实样本数的比例,反映的是模型对目标的检测能力,通过计算检测结果中预测正确的样本数和所有真实样本数的比例得到,其计算表达式为:

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

为了综合比较网络的性能,联合查准率和查全率,以查准率为横坐标,查全率为纵坐标绘制 P-R 曲线,计算各类别 P-R 曲线下所围成的面积作为平均精度(average precision, AP),利用各类别平均精度的均值平均精度均值(mean average precision, mAP)表示网络的性能。

$$AP = \int_0^1 p(r) dr \quad (7)$$

$$mAP = \frac{\sum_{i=1}^C AP_i}{C} \quad (8)$$

其中, $p(r)$ 表示 P-R 曲线, C 表示缺陷类别数。

4.3 实验环境与超参数

本文实验在 Ubuntu18.04 系统环境下,使用 4 张显存为 11 G 的 Nvidia 1080Ti 显卡,以及基于 Pytorch 的 mmdetection 目标检测框架。

基于前期实验,网络参数如下,网络训练中使用随机梯度下降(stochastic gradient descent, SGD)算法作为优化算法,初始学习率设置为 0.01,动量为 0.9,权值衰减为 0.000 1,迭代轮数为 20 轮,采用自定义学习率衰减策略,分别于第 10、15 轮进行衰减,衰减倍率为 0.1。

4.4 实验结果对比

为验证所提方法的优势以及有效性,分别将所提方法与现有检测方法 TDD-net、以 resnet50 为主干网络的 Faster RCNN、YOLOv3、SSD 等方法进行比较,如表 1 所示。由表 1 可知,在无噪声工况下,所提方法对缺陷的检测 mAP 达到了 97.9%,优于其他对比方法;在噪声干扰下,随着噪声干扰程度的不断加大,各方法的检测精度均有不同程度的下降,这说明了噪声的干扰确实会影响到最终的检测精度。所提方法在 5 组噪声干扰下的平均 mAP 达到 92.4%,相较于对比方法,检测的平均精度更高,稳定性更好,对不同程度噪声的抗干扰能力更强。

表 1 不同方法的平均检测精度

Table 1 Average detection accuracy of different methods

方法	无噪声	$V_{0.01}$	$V_{0.03}$	$V_{0.05}$	$V_{0.07}$	$V_{0.09}$	噪声下平均值
TDD-net	96.4	93.9	90.7	83.3	82.3	80.3	86.1
Faster RCNN	93.6	92.0	87.3	83.2	80.3	74.3	83.4
SSD	89.3	72.8	54.2	39.0	29.7	25.8	44.3
YOLOv3	96.5	92.9	88.6	84.5	79.9	74.5	84.1
MAFaster RCNN	97.9	96.7	94.9	92.9	90.4	87.2	92.4

从表 1 可知,SSD 在无噪声的情况下的检测 mAP 为 89.3%,低于其他对比方法,同时在 5 种不同的高斯噪声干扰下的平均检测 mAP 仅有 44.3%,说明 SSD 对噪声的干扰极其敏感。这是由于:1) SSD 虽然使用了多尺度特征图进行检测,但浅层特征与深层特征所包含的信息各

有侧重,浅层特征包含益于定位的细节信息而益于分类的语义信息较少,深层特征则恰恰相反,单单使用浅层特征或是深层特征都会导致最后的检测效果不好;2) SSD 作为一种典型的单阶段检测方法,直接对原图提取的特征进行目标的位置回归以及分类,导致过多不包含目标的

候选框参与到网络的训练中来,极大地影响网络的检测精度。YOLOv3 在单阶段检测的基础上使用特征金字塔结构来进行深层特征与浅层特征的融合,使每层特征既包含足够用于分类的语义信息也包含足够用于定位的细节信息。相较于未利用不同尺度特征融合的 SSD 检测结果更好,这证明了融合不同尺度特征对噪声干扰下的缺陷检测的重要性。Faster RCNN 将检测过程分为两步,1)对生成的候选框进行一次粗筛选,2)对筛选过的候选框进行精确的分类以及位置回归,避免了过多的无效候选框的干扰。Faster RCNN 在噪声干扰下的平均检测 mAP 为 83.4%,对比单阶段的 SSD 检测结果更好,从侧面证明了在噪声干扰下两阶段检测方法优于单阶段检测算法。

TDD-net 是在 Faster RCNN 的基础上利用特征金字塔以融合深层特征以及浅层特征,对比 Faster RCNN,不仅在无噪声情况下的检测精度提升,在噪声干扰下也有着较大的提升。但 TDD-net 在方差为 0.09 的噪声干扰下检测精度由无噪声干扰下的 96.4% 骤降至 80.3%,各强度噪声下的平均检测精度在 86.1%,相较于无噪声情况下平均检测精度下降了 10.68%,说明其对噪声的抗干扰能力不强。所提方法在方差为 0.09 的噪声干扰下检测精度仍保持在 85% 以上,各强度噪声下的平均检测精度为 92.4%,相较于无噪声条件下的平均检测精度仅降低约 5.61%,特别是方差为 0.01 的低强度噪声,检测精度仅有 1.2% 的差别,相较于 TDD-net 抗噪能力更强。这是因为所提方法一方面使用分离注意力网络来将输入分组,分别提取有效特征并利用注意力机制进行对特征进行加权,使网络自动关注到缺陷特征,可以有效减小噪声干扰的影响;另一方面,利用非局部注意力对融合特征进行全局感受野内不同区域特征的加权,增强了融合后特征对缺陷的表征能力,并进一步减小噪声干扰,使网络提取到有效且抗噪能力强的特征。

为说明所提方法在噪声干扰下的训练效率,以方差为 0.05 的噪声干扰数据为例,比较训练过程中各方法的迭代速度,以验证集的 mAP 为纵坐标、迭代轮数为横坐标作迭代精度图,如图 6 所示。YOLOv3 方法在训练的前 5 轮 mAP 增长优于 Faster RCNN、TDD-net 以及 SSD 等方法,但在第 5~15 轮期间浮动较大,且在训练的第 17 轮左右网络才逐渐开始稳定,说明 YOLOv3 的效果虽优于这些方法但训练效率较差。SSD、Faster RCNN、TDD-net 以及所提方法等均在第 11 轮左右逐渐稳定下来,但在训练的第 5 轮,所提方法的检测精度已达到 87.3%,明显优于对比方法。同时,所提方法的整体训练过程更加平滑,且最终稳定的检测精度均优于对比方法,证明了所提方法在噪声干扰下仍能保持较好的训练效率。

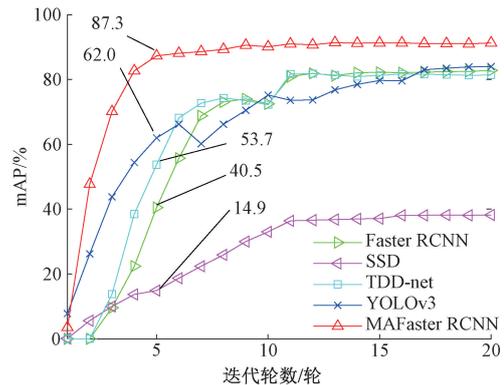


图6 不同方法的迭代精度结果

Fig. 6 Iterative accuracy results of different methods

为分析所提方法对特征提取及特征融合分别采用注意力机制的有效性,针对两部分是否使用注意力机制进行消融实验,同样以方差为 0.05 的噪声干扰数据为例,结果如表 2 所示。可以看出在特征提取与特征融合部分分别添加注意力机制后,最终的检测精度分别提升了 6.7% 以及 9.7%;在同时使用注意力机制时,最终检测精度提升了 11.5%。说明所提方法成功提升了对噪声的抗干扰能力。

表2 不同模块的消融实验对比

Table 2 Comparison of ablation experiments of different modules

modules			mAP	%
特征提取	特征融合			
×	×	83.3		
×	√	88.9	6.7 ↑	
√	×	91.4	9.7 ↑	
√	√	92.9	11.5 ↑	

为证明所提方法提取特征的有效性,参考 score-cam^[15]方法对 RPN 基于特征图预测的前景分数进行可视化并映射到原图,同样以方差为 0.05 的噪声干扰为例,如图 7 所示。其中,以 JET 格式色彩表示得分大小,得分越高表示网络判断该区域越可能包含缺陷。同时,为易于观察,分别使用不同样式的框将检测正确区域、漏检区域以及误检区域表示出来。检测正确区域表示网络准确识别出该处的缺陷,漏检区域表示该处包含缺陷网络却未能识别出来,误检区域表示该处没有缺陷网络却判断此处存在缺陷。根据图 7,在无噪声干扰下,无论是否使用注意力机制,网络都能准确地检测到缺陷区域。在噪声干扰下,未使用注意力机制时,由于噪声的干扰,导致较多误检区域的产生,且存在一处漏检区域;当分别在特征提取和特征融合时使用注意力机制后,3 处缺陷

区域均成功检测出,同时误检区域明显减少,说明添加注意力机制能够使网络关注到缺陷区域,减小了噪声干扰的影响,但仍无法完全排除噪声干扰的影响;在特征提取及融合部分均使用注意力机制后,检测结果与无噪声干

扰下一致,说明同时在特征提取以及特征融合部分使用注意力机制能够有效抑制噪声干扰的影响,得到抗噪能力强的特征表示,进一步证明了所提方法对噪声干扰下缺陷检测的有效性与其可行性。

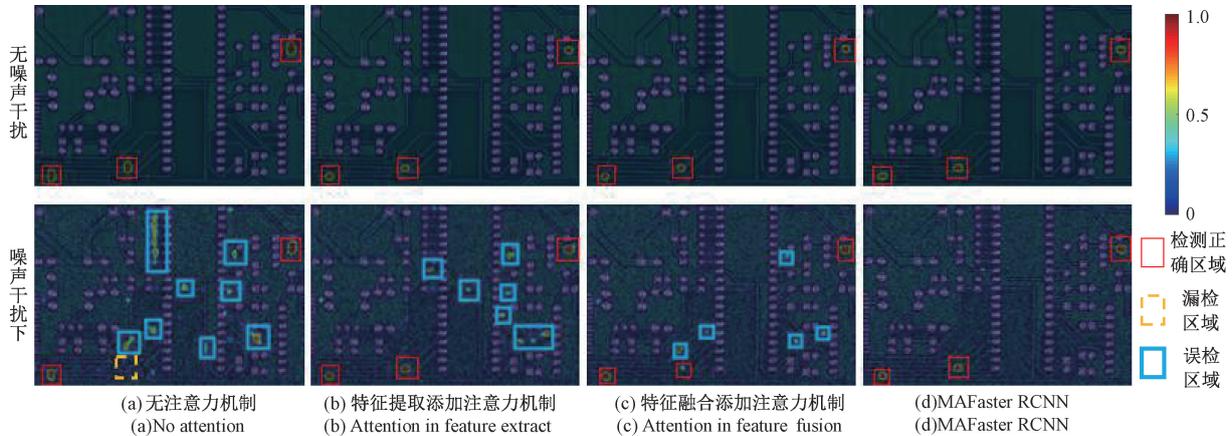


图 7 前景得分热力图

Fig. 7 Foreground scores heat map

5 结 论

在实际工业生产环境中,由于噪声的干扰,获取高质量、无干扰的印刷电路板图像十分困难。因此,实现噪声干扰下的印刷电路板缺陷检测以保证产品质量十分重要。针对该问题,提出基于多注意 Faster RCNN 的印刷电路板缺陷检测方法,于特征提取以及特征融合中融入注意力机制,使网络自动关注到缺陷特征,抑制噪声干扰并增强特征的缺陷表征能力,提取了具有更好抗干扰能力的特征。与其他方法相比,所提方法的主要优势在于:

1) 特征提取中使用分离注意力机制,利用其对不同通道特征加权的特点,使网络自动关注到缺陷特征,降低噪声干扰的影响。

2) 融合不同分辨率特征并利用非局部注意力机制对其全局感受野内不同区域特征加权,以增强特征对缺陷表征能力并进一步抑制噪声干扰的影响。

参考文献

- [1] LI Y, LI S. Defect detection of bare printed circuit boards based on gradient direction information entropy and uniform local binary patterns [J]. *Circuit World*, 2017, 43(6): 145- 151.
- [2] HUANG W B, WEI P, ZHANG M H, et al. Hripcb: A challenging dataset for PCB defects detection and classification [J]. *The Journal of Engineering*, 2020, 2020(13): 303- 309.
- [3] 苑玮琦, 李德健, 李绍丽. 基于局部马尔科夫模式的 FPC 薄浆缺陷检测 [J]. *仪器仪表学报*, 2018, 39(6): 207- 214.
YUAN W Q, LI D J, LI SH L. FPC grout defect detection based on local Markov mode [J]. *Chinese Journal of Scientific Instrument*, 2018, 39(6): 207- 214.
- [4] TANG S, HE F, HUANG X, et al. Online PCB defect detector on a new PCB defect dataset [J]. *ArXiv Preprint*, 2019, arXiv: 1902. 06197.
- [5] 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(2): 110- 116.
- [6] HU B, WANG J. Detection of PCB surface defects with improved Faster-RCNN and feature pyramid network [J]. *IEEE Access*, 2020, 8: 108335-108345.
- [7] ADIBHATLA V A, CHIH H C, HSU C, et al. Defect detection in printed circuit boards using you-only-look-once convolutional neural networks [J]. *Electronics*, 2020, 9(9): 1547.
- [8] TIAN C W, FEI L K, ZHENG W X, et al. Deep learning on image denoising: An overview [J]. *Neural Networks*, 2020, 131: 251- 275.
- [9] 郭璠, 张泳祥, 唐璠, 等. YOLOv3-A: 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.
GUO F, ZHANG Y X, TANG J, et al. YOLOv3-A: Traffic sign detection network based on attention mechanism [J]. *Journal on Communications*, 2021,

42(1):87-99.

- [10] 朱江, 杜瑞, 李建奇, 等. 基于注意力机制的曲轴瓦盖上料机器人视觉定位和检测方法[J]. 仪器仪表学报, 2021, 42(5):140-150.

ZHU J, DU R, LI J Q, et al. Visual positioning and detection method of crankshaft cover feeding robot based on attention mechanism[J]. Chinese Journal of Scientific Instrument, 2021, 42(5):140-150.

- [11] 潘云龙, 王森, 张印辉, 等. 结合特征复用注意力与精细化分层残差的细微裂纹密集连续检测[J]. 仪器仪表学报, 2021, 42(2):285-296.

PAN Y L, WANG S, ZHANG Y H, et al. Dense continuous detection of micro cracks combining feature reuse attention and refined layered residuals[J]. Chinese Journal of Scientific Instrument, 2021, 42(2):285-296.

- [12] ZHANG H, WU C, ZHANG Z, et al. Resnest: Split-attention networks [J]. ArXiv Preprint, 2020, arXiv: 2004.08955.

- [13] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection [C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2117-2125.

- [14] PANG J, CHEN K, SHI J, et al. Libra r-cnn: Towards balanced learning for object detection [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2019: 821-830.

- [15] WANG H F, WANG Z F, DU M N, et al. Score-CAM: Score-weighted visual explanations for convolutional neural networks [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops, 2020: 24-25.

作者简介



陈仁祥, 分别于2007年和2012年在重庆大学获得学士学位和博士学位, 现为重庆交通大学教授、博士生导师, 主要研究方向为智能测试技术与信号处理。

E-mail: manlou.yue@126.com

Chen Renxiang received his B. Sc. degree and Ph. D. degree both from Chongqing University in 2007 and 2012, respectively. He is currently a professor and a master advisor at Chongqing Jiaotong University. His main research interests include intelligent testing technology and signal processing.



詹赞, 2019年于重庆科技学院获得学士学位, 现为重庆交通大学硕士研究生, 主要研究方向为机器视觉与缺陷检测。

E-mail: 497428633@qq.com

Zhan Zan received his B. Sc. degree from Chongqing University of Science and Technology in 2019. He is currently a postgraduate at Chongqing Jiaotong University. His main research interests include machine vision and defect detection.



胡小林 (通信作者), 2010年于重庆大学获得硕士学位, 现为重庆工业大数据创新中心有限公司高级工程师, 主要研究方向为装备故障诊断。

E-mail: huxl0918@163.com

Hu Xiaolin (Corresponding author) received his master degree in Chongqing University in 2010. He is currently a senior engineer at Chongqing Innovation Center of Industrial Big-Data Co., Ltd. His main research interest is fault diagnosis.