

基于改进 U-Net 网络的 PCB 缺陷检测方法

彭勇^{1†}, 刘慧民², 李伟松¹, 王石³

(1. 东莞职业技术学院电子信息学院, 广东 东莞 523808; 2. 东莞森玛仕格里菲电路有限公司, 广东 东莞 523800;
3. 东莞华信智能技术有限公司, 广东 东莞 523808)

摘要:针对 PCB 表面小尺寸缺陷难以检测的问题, 提出了一种改进的 U-Net 语义分割网络, 实现 PCB 表面缺陷图像的精确检测。首先, 将 U-Net 的四层网络层次修改为三层, 可以减少整体的计算工作量、提升网络模型收敛速度、缩短训练时间; 其次, 在 U-Net 网络中融入 CBAM(Convolutional Block Attention Module)模块来提升图像中缺陷目标的显著度; 然后, 在编码阶段使用混合空洞卷积替换原有卷积块, 增大感受野, 获取更多的上下文信息。结果表明, U-Net 的改进模型能够在提升模型性能的同时减少计算复杂度, 能够增加 PCB 缺陷检测效率。

关键词:缺陷检测; U-Net; 空洞卷积; 注意力机制; 语义分割网络; 轻量级网络; 深度学习; 小目标检测
中图分类号: TP391 **文献标识码:** A

PCB Defect Detection Method Based on Improved U-Net Network

PENG Yong^{1†}, LIU Huimin², LI Weisong¹, WANG Shi³

(1. Electronic Information School, Dongguan Polytechnic, Dongguan, Guangdong 523808, China;
2. Dongguan Somacis Graphic PCB Co., Ltd., Dongguan, Guangdong 523800, China;
3. Dongguan Huaxin Intelligent Technology Co., Ltd., Dongguan, Guangdong 523808, China)

Abstract: Aiming at the low detection efficiency of the small-size defects of PCB surface, which cannot meet the real time detection requirements industrial production, a defect recognition method based on improved U-Net for printed circuit board defect detection is proposed. Firstly, reduce the original four layers of U-Net to three layers to reduce network computation and shorten model training time. Secondly, the convolutional block attention module (CBAM) was integrated into the U-Net network to improve the significance of the defective targets in the image. Finally, in the encoding stage, the hybrid dilated convolution is used to replace the original convolution block to increase the receptive field and obtain more context information. The results show that the improved U-Net model network improves network performance while reducing the computational complexity of the U-Net network and can increase the efficiency of printed circuit board defect detection.

Key words: defect detection; U-Net; dilated convolution; attention mechanism; semantic segmentation network; light-weight network; deep learning; small target detection

印刷电路板(Printed Circuit Board, PCB)在各类电子产品中应用非常广泛, 是电子产品的最核心组件, PCB 板的质量与电子产品的质量密切相关,

对电子产品的寿命、安全性、实用性都起到决定性的作用, PCB 板的缺陷检测是评价电路板质量的有效途径^[1]。

收稿日期: 2023-07-20

基金项目: 广东省教育厅 2023 年度普通高校重点领域项目(2023ZDZX1087); 东莞科技特派员项目(20221800500812); 东莞职业技术学院国家双高计划电子信息工程技术专业群专项政校企项目(ZXD202302)

作者简介: 彭勇(1976—), 男, 湖北黄冈人, 硕士, 副教授, 研究方向: 物联网应用, 人工智能。

† 通信联系人, E-mail: 289593848@qq.com

早期 PCB 缺陷检测方法主要包括人工目检、在线测试、功能测试等^[2],人工目检需要大量的人工,长时间的人工目检对视力要求极高,容易出现视觉疲劳,错检、漏检等情况时有发生,导致产品质量不稳定,甚至影响产品的生存,尤其现在 PCB 板上的线间距和元件体积缩小,这种方法变得越来越不可行;在线测试需要测试夹具、编程和调试时间,夹具制造成本高、使用困难;功能测试需要特殊设备和专门设计的测试程序,编写功能测试很复杂,因此不适合大多数电路板生产线。

由于传统 PCB 缺陷检测方法存在较多的弊端,随着机器视觉技术的发展,目前在 PCB 板行业广泛应用以机器视觉技术为核心的自动光学检测系统(Automatic Optical Inspection, AOI),AOI 主要的检测方法有参考法、非参考法和混合法^[3]。参考法主要是比较标准 PCB 板图像和待检 PCB 板图像之间的特征差异,有差异说明有缺陷,再根据缺陷的特征进行分类,确定缺陷类型,这种方法效果较好,但是对待检图像的精度要求非常高;非参考法主要是通过一套预定的判定规则来检测待检 PCB 板是否违反规则,所有不符合预定规则的都认为是缺陷,并根据规则确定缺陷类型,但此方法无法处理未设置判别条件的缺陷,可能存在一些无法判定的情况^[4];混合法综合了参考法和非参考法的优点,混合法利用多种算法和技术,在缺陷检测中具有更全面、准确的能力,然而,由于混合法涉及复杂的算法和技术,其应用相对较少。

深度学习算法在图像领域取得了显著进展,在缺陷检测方面表现出高效和准确的优势。近年来,学者已将深度学习应用到 PCB 缺陷检测领域,深度学习模型可以自动提取 PCB 图像特征,识别和定位焊点缺陷、短路、断路等,它减少人工介入,提高检测准确性和效率,节省成本和时间,深度学习为电子制造业提供智能、高效的质量控制解决方案,未来有望进一步发展和完善。2020年3月,陈灿等^[5]通过区域卷积神经网络(Region-based Convolutional Neural Network, R-CNN)进行特征提取,并使用 Generalized Intersection over Union (GIoU)作为损失函数,可以解决在预测框和实际框不相交时无法优化损失函数的问题,GIoU 考虑了预测框和实际框之间的交并比以及其对边界框坐标的影响,使得模型更好地优化检测目标的定位精度,用 Swish 激活函数代替 Rectified Linear Unit(ReLU)激活函数,也可以提升网络的检测性能,有效地提升 PCB 缺陷的检测精度。2021年3

月,董静毅等^[6]通过使用多尺度图像进行训练,使网络能够学习不同尺度下的目标特征,将 ROI Pooling 替换为 ROI Align 层,以提高检测精度,引入噪声抑制网络改善 Faster R-CNN。该网络能降低图像噪声对目标检测的干扰,提升准确性,可显著提升 Faster R-CNN 对多尺度目标的检测精度,并减少漏检和误检情况。2021年9月,朱宪宇等^[7]提出将 YOLO(You Only Look Once)v4 引入到 PCB 裸板缺陷检测,采用 Canopy+K-means 聚类改进 YOLOv4 中 K-means 聚类获取先验框,其检测精度优于原始 YOLO 算法,但检测速度较慢,难以实现工业应用。2022年7月,陈博源^[8]通过使用基于密度的噪声应用空间聚类(Density-based Spatial Clustering of Applications with Noise, DBSCAN)算法识别 PCB 图像中的高密度区域,即可能存在缺陷的区域,DBSCAN 将数据点划分为核心点、边界点和噪声点,能够有效地找出连续且紧密的聚类,对 DBSCAN 识别的核心点应用 K-means 聚类算法进行进一步的聚类,K-means 根据数据点之间的相似性将它们分为预设的聚类数量,从而获得适用于不同缺陷类型的锚框,通过重新聚类得到的锚框,模型能更好地适应 PCB 缺陷数据集的特征,提高缺陷检测的准确性和鲁棒性。

上述深度学习算法虽然具有很强的泛化性,大多数实验效果还不错,但是对于 PCB 板的小目标缺陷效果不理想,而且普遍检测模型较大,检测速度和检测精度尚不能满足工业级检测的需求。为解决 PCB 板表面细微缺陷的精确快速检出,提出一种基于改进 U-Net 网络的缺陷检测算法,将 U-Net 网络中的四层结构调整三层,以减少网络的计算量、缩短模型的训练和检测时间;在原网络结构中融入轻量的注意力模块,增强细微特征的学习;在网络编码器结构中应用混合空洞卷积,可以使网络更好地理解 PCB 缺陷图像中的细微特征,增大感受野,提高检测准确性和鲁棒性。实验证明,在保持模型性能的同时,改进后的网络获得了更高的平均精确度(mAP),提高了每秒处理帧数(FPS),并缩短了单张图片的检测时间,对 PCB 板细微缺陷检测效果更好。

1 网络结构

1.1 语义分割网络 U-Net

U-Net 网络是一种用于图像分割的深度学习模型,其端到端的结构在像素级语义分割任务中表

现出色。它由编码器和解码器组成,通过逐层特征提取和降采样实现图像特征的抽象表示,然后通过上采样和特征融合恢复分辨率,最终生成像素级的分割结果。U-Net 网络对小数据集的训练效果好,并具有较快的推理速度,因此在目标检测任务中得到广泛应用。它在医学影像分割、自然场景分割等领域取得了显著进展,并且不断被改进和扩展。总的来说,U-Net 网络以其简洁有效的结构和强大的语义分割能力,在目标检测中发挥着重要作用。U-Net 网络结构图如图 1 所示。




图 1 U-Net 网络结构图

U-Net 网络^[9]主要由编码器和解码器两个部分组成。编码器结构位于左侧,通过 4 次下采样的过程来提取图像特征信息。每次下采样包括 3×3 卷积层、ReLU 激活层和 2×2 最大池化层,同时特征通道数翻倍。这一过程将图像从具体到抽象的特征表示,但会导致图像分辨率降低。解码器结构位于右侧,通过 4 次上采样的过程将分割图像恢复到原始大小。它使用不同的插值算法进行反卷积操作,使得图像放大并保持相同的尺寸。解码器包括转置卷积(用于图像尺寸扩大)、 3×3 卷积(减少特征通道数)、深层特征与浅层特征的融合、以及 1×1 卷积(映射通道到目标类别数)。通过反卷积和特征图的拼接,实现了分辨率的提升。总体而言,U-Net 网络通过左侧的下采样(编码器)和右侧的上采样(解码器)过程,实现了图像特征的抽象表示和分辨率的恢复,从而完成图像分割任务。

1.2 改进的语义分割网络

主要对原始的 U-Net 网络结构进行三处优化^[10]。首先,减少网络层数:将原先的四层减为三层,可以简化模型结构,加快训练速度,同时在某些情况下不会显著影响性能。其次,使用混合空洞卷积:在编码阶段中,使用混合空洞卷积替代普通卷积,扩大感受野,即增加对输入图像更远处像素的感知能力,从而获取更多上下文信息,提高准确性。最后,引入注意力机制:在每个跳跃连接之间加入

注意力机制,使模型能够重点关注目标区域的特征,抑制冗余特征,以进一步改善分割结果。改进后的 U-Net 可以提取到更精细的特征信息,从而获得更好的检测效果。改进的 U-Net 网络结构图如图 2 所示。




图 2 改进 U-Net 网络结构图

2 具体改进

2.1 混合空洞卷积

空洞卷积通过在卷积核中引入空洞来扩大感受野,从而聚合更多的上下文信息,而不增加模型的参数量。具体而言,空洞率(Dilation Rates)表示用于在原图上进行采样的步长,当 rate 为 1 时,空洞卷积等效于标准的卷积操作,不会进行采样。而当 r 大于 1 时,在原图上每隔 $(r-1)$ 个像素进行采样。通过增大空洞率,空洞卷积能够获得更广阔的上下文信息,在感受野内捕捉到更多全局结构和细节关系。与此同时,由于使用了原有的卷积参数,它不会增加额外的模型参数,避免了计算开销的增加。空洞卷积感受野计算如下:

$$K = k + (k - 1)(r - 1) \quad (1)$$

其中, k 为原始卷积核大小, r 为空洞率。然而当前空洞卷积存在网格效应:空洞卷积采样率相同,只在非零值位置进行采样,导致局部信息丢失。为此,采用 Wang 提出的混合空洞卷积(Hybrid Dilated Convolution, HDC)^[11]来缓解网格效应问题。混合空洞卷积的思想是通过组合多个不同空洞率的卷积操作,综合利用它们在感受野大小和信息密度上的优势。通过使用不同的空洞率,可以同时考虑到更广范围和更丰富的局部信息,并有效缓解网格效应造成的局部信息丢失问题。这种混合的策略可以帮助网络更好地捕捉图像中的细节和全局结构,并改善模型在处理复杂场景时的性能。通过采用一系列不同的空洞率,而不是使用相同的

r ,有效缓解了网格效应,如图3所示。




图3 混合空洞卷积

2.2 注意力机制模块

CBAM^[12] (Convolutional Block Attention Module)是一种双重轻量级注意力机制,可以集成到卷积神经网络(Convolutional Neural Networks, CNN)架构中,通过增强有用的特征并忽略无关紧要的特征来提升网络性能。在U-Net网络中引入CBAM模块可以帮助网络提取更为有效的特征。CBAM注意力模块被设计用于对特征图进行动态调整,以根据每个通道和位置上的特征重要性进行加权。通道注意力模块通过学习每个通道之间的相关性,自适应地选择最具有区分能力的特征通道。而空间注意力模块则通过学习每个像素点上的相对重要性,自适应地调整特征图中不同位置像素的权重。通过引入CBAM模块,U-Net网络可以更好地捕获和利用图像中的关键特征,进一步提高语义分割性能,如图4所示。




图4 CBAM 结构示意图

CBAM包含通道注意力模块(Channel Attention Module, CAM)和空间注意力模块(Spatial Attention Module, SAM),CBAM的通道注意力模块中,首先对输入特征图 F 进行全局平均池化(Average Pooling)和全局最大池化(Global Max Pooling)操作,得到两个特征描述向量。然后,这两个向量被传入一个共享网络,该网络由含有隐含层的多层感知器组成。这些向量经过感知器叠加,并通过Sigmoid函数进行激活,得到通道注意力输出权值 M_c 。这些权值用于对输入特征图的每个通道进行加权,以增强有用的特征并抑制无关紧要的特征,如图5所示。其计算公式为:

$$M_c(F) = \sigma(\text{MLP}(\text{AvgPool}(F)) +$$

$$\text{MLP}(\text{Max Pool}(f))) =$$

$$\sigma(W_1(W_0(F_{\text{avg}})) + W_1(W_0(F_{\text{max}}))) \quad (2)$$

其中, σ 是Sigmoid函数,MLP权值 $W_0 \in R^{C/r \times C}$ 和 $W_1 \in R^{C/r \times C}$ 为两个共享输入, r 为减少率。




图5 通道注意力模块结构示意图

在空间注意力模块内^[13],通过通道注意力加权得到的特征图 F_c ,在通道轴上分别进行全局平均池化和全局最大值池化运算。将池化结果串联起来,并进行卷积降维操作后,经过Sigmoid函数激活生成空间注意力图 M_s ,最后,将 M_s 与 F_c 相乘得到CBAM输出的显著特征图 F_{cs} ,如图6所示。这样的设计能够综合利用全局平均信息和全局最大值信息,从而增强空间特征的表示能力,空间注意力模块如(3)式所示:

$$M_s(F_c) = \sigma\{f^{7 \times 7} \{[\text{avg Pool}(F_c); \text{Max Pool}(F_c)]\} \} \quad (3)$$

式中: σ 是Sigmoid函数, $f^{7 \times 7}$ 表示卷积核为 7×7 的卷积运算。




图6 空间注意力模块结构示意图

CBAM整体计算过程可以概括为:

$$F_c = M_c(F) \otimes F \quad (4)$$

$$F_{cs} = M_s(F_c) \otimes F_c \quad (5)$$

其中, \otimes 为逐元素相乘, F_{cs} 为最终精炼输出。

3 实验结果与分析

3.1 缺陷数据集

以北京大学智能机器人开放实验室的开源PCB作为数据集进行网络训练。该数据集包含1386张标注过的图片,使用LabelImg软件以VOC格式标注,涵盖了漏孔、缺口、断路、短路、毛刺和余铜等6类缺陷。由于图片分辨率不同,需要对图像进行分割处理,并扩充数据集至11000

张^[14]。按 8 : 1 : 1 的比例划分为训练集、验证集和测试集。

3.2 实验环境及参数配置

为了保证算法的高效运行,本实验基于 GPU 硬件设备进行, GPU 拥有强大的并行计算能力,可以加速训练过程。实验环境配置如表 1 所示。

表 1 实验环境

项目	品牌型号
CPU	Intel (R) i9-10900X CPU 3.70 GHz
显卡	NVIDIA GeForce RTX 2080Ti
内存	32 G
Python 版本	Python3.7

3.3 实验设计与结果分析

为验证改进算法的有效性,可以从以下几个方面对比改进算法与原始 U-Net 算法及其他算法:精度(AP):计算两种算法在相同测试数据集上的平均精度(Average Precision),评估改进算法是否在目标检测中更准确。平均精度(mAP):计算两种算法在相同测试数据集上的平均精度,综合考虑多个类别的精度表现,对比两者的性能。图像刷新频率(FPS):通过性能测试,测量两种算法在相同硬件设备上的图像处理速度,确定改进算法是否具有更高的实时性能。单张图片检测时间:测量两种算法处理单张图片所需的时间,对比它们的检测效率。通过以上对比分析,可以评估改进算法在精度、实时性能和效率方面的优势和改进之处。

表 2 改进算法与原始算法的 AP 对比 %

算法	漏孔	余铜	短路	鼠咬	毛刺	断路
原始 U-Net	94.36	93.40	97.92	90.12	85.12	91.20
改进 U-Net	94.24	96.18	98.36	94.09	88.25	88.78
Faster R-CNN	93.17	94.08	95.51	92.13	84.75	90.24
YOLO-v5	96.12	95.67	97.95	94.74	87.46	86.77

由表 2 可知,在检测鼠咬、毛刺两种小目标缺陷时,引入注意力机制的 U-Net 算法较原始 U-Net 算法的 AP 分别提升 3.97%、3.13%,相较于 Faster R-CNN 算法的 AP 分别提升 1.96%、3.5%,与 YOLO-v5 算法的 AP 基本相当。检测余铜和短路这两种难以检测的缺陷方面,改进的 U-Net 算法较原始 U-Net 算法的 AP 提升了 2.78% 和 0.44%,相较于 Faster R-CNN 算法的 AP 分别提升 2.1%、2.85%,与 YOLO-v5 算法的 AP 相比也

有一定的提升。实验证明,注意力机制的引入确实可以提升 U-Net 算法对于一些具有微小、复杂特征的缺陷的检测性能。通过注意力机制,网络可以学习到哪些特征对于缺陷检测更为重要,并将更多关注度放在这些有效特征上,同时忽略无效特征。对于余铜、短路、鼠咬和毛刺等缺陷类型,由于它们通常具有微小且复杂的特征,传统的算法可能难以准确检测出来,而改进的 U-Net 算法引入了注意力机制后,在处理这些具有微小、复杂特征的缺陷时表现出更好的性能。这进一步验证了改进的 U-Net 算法在处理小目标缺陷和难以检测缺陷时的有效性,通过注意力机制帮助网络集中关注对缺陷检测更有价值的特征,从而提升了检测性能。

表 3 为融合注意力机制后的 U-Net 算法与原始 U-Net 在相同硬件条件下,对比 mAP、FPS、单张图片检测时间的数据。基于改进 U-Net 算法进行 PCB 缺陷检测的平均精度(mAP)为 94.22%,相较于原始 U-Net 算法,提升了 2.58%,相较于 Faster R-CNN 算法,提升了 2.6%,与 YOLO-v5 算法基本相当,这表明改进算法在准确性上取得了提升。在 FPS、单张图片检测时间的数据等反映检测速度数据方面,由于引入了注意力机制增加了计算量,改进 U-Net 算法检测速度略有下降,但不会对单张图片检测时间造成明显影响,仍能满足实际生产过程中的检测需求,可以保持较高的实时性能,而 YOLO-v5 算法由于模型最大,检测速度最慢。

表 3 改进算法与原始算法的性能对比

算法	mAP/%	FPS	检测时间/s
原始 U-Net	91.64	5.236	0.191
改进 U-Net	94.22	4.753	0.21
Faster R-CNN	91.62	5.758	0.174
YOLO-v5	93.96	3.67	0.272

通过上述性能评价指标可以说明改进 U-Net 算法对 PCB 缺陷的检测性能优于标准 U-Net 算法和 Faster R-CNN 算法,与 YOLO-v5 算法基本相当,但在检测速度上优于 YOLO-v5 算法。为了更直观地体现改进 U-Net 算法的检测性能,下面将从实际检测效果进行对比分析。选取 PCB 缺陷中毛刺、鼠咬两种小目标缺陷进行可视化检测的对比分析。

图 7 为针对 PCB 毛刺缺陷的实际检测效果,用不同算法对同一块 PCB 毛刺缺陷板进行检测,其中图 7(a)是采用标准 U-Net 算法的检测效果,图 7(b)是采取改进 U-Net 算法的检测效果。由对

比图 7(a)(b)可知,在检测到的微小复杂的毛刺缺陷中,采用改进 U-Net 算法检测 PCB 缺陷的准确率分别为 85%、92%、97%、86%、90%,相较于标准 U-Net 算法的 68%、79%、77%、79%、72%,分别提升了 7%、13%、20%、7%、18%。实验结果表明,改进 U-Net 算法对毛刺缺陷的检测性能优于标准 U-Net 算法,验证了基于改进 U-Net 算法的 PCB 缺陷检测算法的有效性。




图 7 毛刺缺陷检测效果对比

图 8 为针对难以检测的 PCB 鼠咬缺陷的实际检测效果,用不同算法对同一块 PCB 鼠咬缺陷板进行检测,其中图 8(a)是采用标准 U-Net 算法的检测效果,图 8(b)是采取改进 U-Net 算法的检测效果。由对比图 8(a)(b)可知,改进 U-Net 算法检测 PCB 鼠咬缺陷的平均准确率为 84%,相较于标准 U-Net 算法的 77%提升了 7%。




图 8 鼠咬缺陷检测效果对比

从客观性能指标以及实际检测效果的对比可以看出,改进 U-Net 算法可以提升对小目标缺陷和难检测缺陷的检测精度,进一步提升检测性能,有效满足 PCB 实际生产中的检测需求。

4 结论

为了进一步提升 U-Net 算法对 PCB 缺陷的检测精度,强化对微小、复杂的 PCB 缺陷的检测性能,提出一种结合 CBAM 注意力机制的 U-Net 算法。首先,引入能缓解网格效应的混合空洞卷积,实现感受野的指数级增长,从而聚合更多的上下文信息。

其次,采用 CBAM 双重轻量级注意力机制,高效获取有效信息,提高 PCB 缺陷特征的提取效率,改进 U-Net 算法中有效特征层的融合方式,可以更好地利用多尺度特征提取的优势。最后,在 mAP(平均精度均值)方面,改进的 U-Net 算法表现更好,能够更精准地检测微小、复杂的缺陷,改进的 U-Net 算法具有更快的处理速度,通过实验中的 FPS(每秒处理帧数)和单张图片检测时间可以观察到这一点,这意味着基于改进的 U-Net 算法的 PCB 缺陷检测算法可能更适合大规模应用。

综上所述,改进的 U-Net 算法在 PCB 缺陷检测方面具有显著优势,该算法具有较高的 mAP 和更快的处理速度。尤其对于微小、复杂的缺陷检测,其准确性更高。因此,将改进的 U-Net 算法应用于 PCB 缺陷检测领域可以更好地满足实际需求。

参考文献

- [1] 王淑青,鲁濠,鲁东林,等.基于轻量化人工神经网络的 PCB 板缺陷检测[J].仪表技术与传感器,2022,(5):98-104.
- [2] 马宇峰,羊铁涛,马佳明,等.基于深度学习的 PCB 板元件检测与识别系统设计[J].电子世界,2021,(8):192-193.
- [3] 黄璇.PCB 元器件自动光学检测技术研究[J].华东科技,2022,(9):51-53.
- [4] 曹珩.机器视觉技术在 PCB 自动检测中的应用[J].集成电路应用,2022,39(12):258-259.
- [5] 陈灿,王亚龙,王福鑫,等.基于区域卷积神经网络的 PCB 板检测与识别系统[J].电脑编程技巧与维护,2020(3):119-120.
- [6] 董静毅,吕文涛,包晓敏,等.基于机器视觉的 PCB 板表面缺陷检测方法研究进展[J].浙江理工大学学报(自然科学版),2021,45(3):379-389.
- [7] 朱宪宇,熊婕,王柠莎,等.基于改进 YOLOv4 的 PCB 裸板缺陷检测方法研究[J].工业控制计算机,2021,34(9):39-40.
- [8] 陈博源.基于 YOLOv5 的印制电路板缺陷智能检测[J].电子测试,2022,36(7):62-65.
- [9] 王一,龚肖,杰苏皓.基于改进 U-Net 的金属工件表面缺陷图像分割方法[J].应用光学,2023,44(1):86-92.
- [10] 李秀华,朱水成.一种基于改进 U-Net 的肝脏肿瘤分割方法[J].计算机技术与发展,2023,33(2):72-74.
- [11] WANG P Q, CHEN P F, YUAN Y, et al. Understanding convolution for semantic segmentation[C]//2018 IEEE winter conference on applications of computer vision (WACV). Nevada: IEEE, 2018:1451-1460.
- [12] FU H X, SONG G Q, WANG Y C, et al. Improved YOLOv4 marine target detection combined with CBAM[J]. Symmetry, 2021,13(4):623-635.
- [13] 赵鹤,杨晓洪,杨奇,等.融合注意力机制的金属缺陷图像分割方法[J].光电子激光,2021,32(4):403-408.
- [14] 舒军,李灵,邓明舟,等.基于 NCC 的 PCB 图像配准算法研究[J].湖北工业大学学报,2022,37(2):48-54.