

DOI:10.3969/j.issn.1003-5060.2024.10.003

# 基于改进 DeepLabv3+ 的铝塑泡罩包装表面缺陷检测方法研究

汪俊峰, 刘明周, 王小巧, 龚宇, 王子若

(合肥工业大学 机械工程学院, 安徽 合肥 230009)

**摘要:**针对传统语义分割模型用于铝塑泡罩包装缺陷检测存在小目标缺陷检测精度低、复杂纹理背景下边缘分割效果差、检测速度慢的问题,文章提出一种改进的铝塑泡罩包装表面缺陷检测方法。主干特征提取网络采用轻量级 MobileNetV2 网络替代原始的 Xception 网络,大幅减少模型参数量;在特征提取模块和空洞空间金字塔池化(atrous spatial pyramid pooling, ASPP)模块中串联高效通道注意力(efficient channel attention, ECA)模块,加快全局特征融合,降低细节信息丢失,从而提高模型对小目标缺陷的分割精度;最后,在 DeepLabv3+ 的解码器中加入边界细化模块,提升模型在铝塑表面复杂纹理背景下对缺陷区域边缘的分割精度。在自建药板图片数据集上进行的验证实验结果表明,所提方法模型与传统 DeepLabv3+、PSPNet、HRNet 等模型相比,平均交并比(mean intersection over union, MIoU)最大提高 14.50%,单图预测时间最大减少 92.71 ms,参数量最大减少 47.67 MiB。文章方法具有较高的识别正确率和效率,可以实现铝塑泡罩包装表面缺陷的快速检测,具有较强的应用性。

**关键词:**铝塑泡罩包装;缺陷检测;语义分割;注意力机制;边界细化

中图分类号:TB487

文献标志码:A

文章编号:1003-5060(2024)10-1314-08

## Research on surface defect detection method of aluminum-plastic blister package based on improved DeepLabv3+

WANG Junfeng, LIU Mingzhou, WANG Xiaoqiao, GONG Yu, WANG Ziruo

(School of Mechanical Engineering, Hefei University of Technology, Hefei 230009, China)

**Abstract:** Aiming at solving the problems of low accuracy of small-scale defect detection, poor edge segmentation effect in complex texture background and slow detection speed of traditional semantic segmentation model for aluminum-plastic blister package defect detection, this paper proposes an improved surface defect detection method for aluminum-plastic blister package. Firstly, the backbone feature extraction network replaces the original Xception network with the lightweight MobileNetV2 network, which significantly reduces the number of model parameters. Secondly, the efficient channel attention(ECA) module is cascaded in the feature extraction module and atrous spatial pyramid pooling(ASPP) module to accelerate the global feature fusion and reduce the loss of detail information, thus improving the segmentation accuracy of the model for small-scale defects. Finally, a boundary refinement module is added to the decoder of DeepLabv3+ to improve the segmentation accuracy of the model on the edges of the defect region under the complex texture background of the aluminum-plastic surface. Experimental verification is carried out on the self-built capsule board image dataset, and the

收稿日期:2022-11-29;修回日期:2022-12-15

基金项目:安徽省科技攻关计划资助项目(JZ2016AKKG0837)

作者简介:汪俊峰(1998—),男,安徽黄山人,合肥工业大学硕士生;

刘明周(1968—),男,安徽六安人,博士,合肥工业大学教授,博士生导师;

王小巧(1989—),男,安徽蚌埠人,博士,合肥工业大学讲师,硕士生导师,通信作者, E-mail:986584163@qq.com.

results show that the proposed method has a maximum improvement of 14.50% in mean intersection over union(MIoU) score, a maximum reduction of 92.71 ms in single-image prediction time, and a maximum reduction of 47.67 MiB in the number of parameters compared with the traditional DeepLabv3+, PSPNet, HRNet and other models. The method in this paper has a high recognition accuracy and efficiency, which can realize the fast detection of aluminum-plastic blister package surface defects and has high applicability.

**Key words:** aluminum-plastic blister package; defect detection; semantic segmentation; attention mechanism; boundary refinement

目前,制药企业大多采用铝塑泡罩包装药品<sup>[1]</sup>,但在铝塑机进行包装密封时,药板表面难免出现缺陷,从而导致药品质量与外观出现问题,容易出现药板横纹、药板压粉、药片缺损、药片硌泡缺陷。同时,由于药板表面复杂纹理背景的干扰及药片缺损缺陷尺度小,使得缺陷检测的难度提升。因此,急需研究一种在药板表面复杂纹理背景干扰条件下的细微缺陷检测方法。

使用传统的人工检测方式进行药板表面缺陷检测的效率低,检测结果受工人主观判断影响大,且成本高、检测精度低。近年来,随着基于机器视觉的图像处理技术<sup>[2]</sup>的发展,研究者们也将其应用于铝塑泡罩表面缺陷检测。文献[3]使用浅层分割网络,然后使用分水岭算法将药板分割成单个药片进行缺陷检测,提高了缺陷检测准确率,但算法适应性差;文献[4]针对铝塑泡罩穿泡缺陷问题提出基于搜索子图像灰度差算法粗定位缺陷,阈值分割采用分块迭代阈值法定位缺陷,准确率较高,但算法复杂;文献[5]使用快速鲁棒特征(speeded up robust feature, SURF)算法和单分类支持向量机模型用于铝塑泡罩缺陷检测,检测准确率较高,但是检测效果受环境背景限制。

近年来深度学习技术<sup>[6]</sup>发展迅速,已经广泛应用于图像处理领域。深度学习图像处理算法分为基于语义分割的算法和基于目标检测的算法。基于语义分割的算法能对图像进行像素级分割,更加准确定位缺陷区域。以全卷积神经网络(fully convolutional network, FCN)<sup>[7]</sup>为代表的语义分割网络可以输入任意尺寸的图片,输出结果通过上采样操作,保留了原始图像的空间特征,能完成对图像像素级端到端的预测;文献[8]利用融合自注意力机制的 FCN 网络实现混凝土裂隙识别,输出高精度的二值图,算法运行效率及识别效果优于传统算法;文献[9]利用协同 YOLOv3 和 FCN 的二阶段方法实现绝缘子故障检测,并在 FCN 模型中加入跳跃结构实现准确且完整地分

割绝缘子,检测精度提升明显。以上研究虽然对于缺陷检测做出了一定贡献,但是边缘识别效果和检测精度等方面还有不足之处。

DeepLab 系列模型引入空洞空间金字塔池化(atrous spatial pyramid pooling, ASPP)<sup>[10]</sup>,在卷积特征层输入不同采样率的滤波器,实现了多尺度特征的融合,增强了对目标边界的划分效果。DeepLabv3+添加解码器模块恢复空间信息,从而获得更加清晰的目标边界,优化分割结果。文献[11]在 DeepLabv3+编码器中串联密集空洞空间金字塔池化(dense atrous spatial pyramid pooling, DASPP)与通道注意力机制,并加入特征图加权模块以提取临床 HIFU 治疗目标区域,分割精度较高;文献[12]在 DeepLabv3+的 ASPP 结构中加入多层级联结构增加特征图的特征信息,并在模型内融入自注意力机制进行航空发动机损伤检测,提高了分割精度及算法检测效率。

由上述研究可知,DeepLabv3+比 FCN 的分割效果更好,但是对于铝塑泡罩包装表面缺陷检测,存在以下 3 个方面不足。

1) 训练和预测效率低。其主干特征提取网络较为复杂,导致模型训练及预测效率低,无法满足生产需求。

2) 小目标缺陷检测精度低。模型对于小目标特征的敏感度低,容易出现误判和漏判。

3) 检测效果受背景影响。当存在复杂纹理背景干扰时,目标区域边缘分割效果差。

基于上述问题,本文提出一种改进的 DeepLabv3+模型,用于铝塑泡罩包装表面缺陷检测。拍摄铝塑泡罩药板图片用于制作图片数据集,之后通过实验进行验证,实现缺陷区域高效准确的分割。

## 1 研究方法

### 1.1 本文方法框架

本文方法框架如图 1 所示。首先,使用图像

标注工具对采集到的铝塑泡罩药板图像进行标注,将所有像素都标注上其对应的标签;其次,使用图像旋转、图像左右镜像和图像缩放 3 种数据增强方式对样本数量进行扩充,防止网络训练发生过拟合;再次,使用等比例缩放,用灰色边缘填充,将图像尺寸调整为  $512 \times 512$  大小,并输入改进 DeepLabv3+ 模型的主干特征提取网络提取特征获得特征图,将特征图输入高效通道注意力 (efficient channel attention, ECA) 模块,然后输入 ASPP 中引入 ECA 的加强特征提取网络;最后,特征图经过  $1 \times 1$  卷积调整通道,将通道数调整为需要预测的类数,之后输入边界细化模块,再进行上采样操作,得到与输入图像大小一致的预测图。

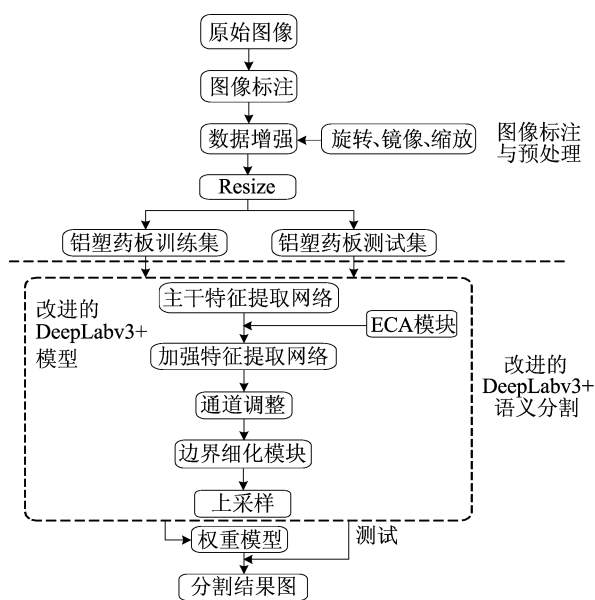


图 1 本文方法框架

## 1.2 图像标注与预处理

图像标注方式为人工进行像素级标注,使得图像中每个像素都有一个语义标签。经过标注后的图像样本具有大量局部特征和细节信息,能够提高网络分割精确度和训练效率。DeepLabv3+ 模型在训练时利用标注后的图像中丰富的语义信息和视觉特征对图像像素分类。

原始铝塑泡罩药板图片数据集的缺陷数据较少,且类别不均衡。为了增加训练样本的多样性,防止网络训练发生过拟合,提高模型鲁棒性,使用数据增强技术对样本数量扩充<sup>[13]</sup>。数据增强分为在线增强和离线增强。在线增强即增强待输入神经网络的 batch 数据,包含平移、旋转、镜像等方式,在不增加原始数据样本量的情况下增加训

练图像的多样性,且训练中不同 Epoch 的增强方式随机变化,进一步增加训练图像的多样性,提升模型的稳健性和泛化性,此方法多应用于样本量大的数据集。离线增强即对原始数据进行增强,包含旋转、镜像、缩放等方式,然后将增强后的新数据集存入硬盘,使用新数据集输入网络进行训练,此方法适用于小样本量数据集。本文样本量小,故使用离线增强,对图像进行旋转、左右镜像和缩放操作。

## 1.3 改进的 DeepLabv3+ 网络结构

改进的 DeepLabv3+<sup>[14]</sup> 网络结构如图 2 所示。首先,主干特征提取网络采用轻量级 MobileNetV2<sup>[15]</sup> 网络替代原始的 Xception<sup>[16]</sup> 网络,并根据迁移学习方法在模型训练时使用基于 VOC 数据集训练后的预训练权重,既减少了模型参数量,提高了模型计算速度,又提升了模型分割性能;其次,在特征提取模块和 ASPP 模块中串联 ECA 模块,加快全局特征融合,使像素特征间的语义关联性增加,降低细节信息丢失,从而提高模型对小目标缺陷的分割效果,提高分割精度;最后,在网络的解码器中加入边界细化模块,使模型在铝塑表面复杂纹理背景下对缺陷区域边缘的分割精度得以提升。

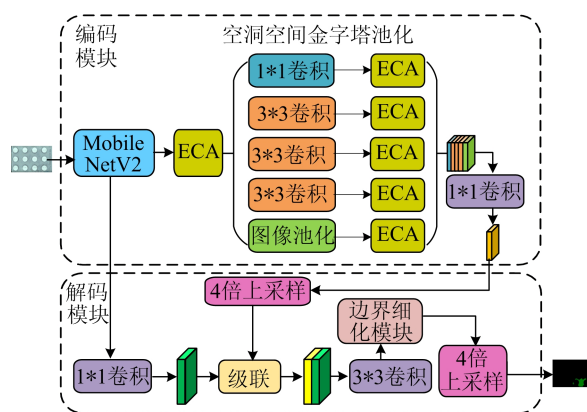


图 2 改进的 DeepLabv3+ 网络结构

## 1.4 特征提取模块

用轻量级 MobileNetV2 网络替换原始 DeepLabv3+ 的 Xception 网络作为特征提取模块。为了进一步加快模型学习效率,模型使用基于 PASCAL VOC 2012 数据集训练后的 MobileNetV2 预训练权重进行训练。MobileNetV2 由 Google 公司在 2018 年提出,相较于 Xception 网络,其网络参数少、网络层数浅、模型复杂度低,解决了深度学习模型训练时的网络参数量大、对硬

件要求高等问题。

MobileNetV2 网络结构见表 1 所列。表 1 中:conv2d 为二维卷积操作;bottleneck 为反向残差块组成的瓶颈块;avgpool 为全局池化操作; $t$  为扩展因子; $c$  为输出通道数; $n$  为 bottleneck 的重复次数; $s$  为步距。

表 1 MobileNetV2 网络结构

输入	操作	$t$	$c$	$n$	$s$
$224^2 \times 3$	conv2d		32	1	2
$112^2 \times 32$	bottleneck	1	16	1	1
$112^2 \times 16$	bottleneck	6	24	2	2
$56^2 \times 24$	bottleneck	6	32	3	2
$28^2 \times 32$	bottleneck	6	64	4	2
$14^2 \times 64$	bottleneck	6	96	3	1
$14^2 \times 96$	bottleneck	6	160	3	2
$7^2 \times 160$	bottleneck	6	320	1	1
$7^2 \times 320$	conv2d $1 \times 1$		1 280	1	1
$7^2 \times 1 280$	avgpool $7 \times 7$			1	
$1 \times 1 \times 1 280$	conv2d $1 \times 1$		$k$		

### 1.5 ECA 注意力机制

由于铝塑泡罩表面存在小目标缺陷,其在图像中所占像素数少,分辨率低,特征表达能力弱,进而影响模型对小目标缺陷特征的学习。而注意力机制能加快全局特征融合,使像素特征间的语义关联性增加,降低细节信息损失,从而提高模型对小目标缺陷的分割效果,提高分割精度<sup>[17]</sup>。

ECA 作为改进版的通道注意力机制模块,在各通道间使用一维卷积实现滑动滤波,在进行跨通道交互的同时防止了通道削减,还节省了参数。ECA 具体结构如图 3 所示。




图 3 ECA 结构

从图 3 可以看出,首先利用全局平均池化层对输入维度为  $H \times W \times C$  的特征图  $F$  进行特征压缩;然后通过一个自适应大小为  $z$  的一维卷积核进行特征权重提取;之后通过 Sigmoid 激活函数进行归一化;最后各通道权重和原特征图相应

元素进行相乘,输出最终特征图  $F'$ 。自适应一维卷积的大小  $z$  与输入通道数  $C$  的关系为:

$$z = \varphi(C) = \left\lfloor \frac{\lg C}{\lambda} + \frac{b}{\lambda} \right\rfloor_{\text{odd}} \quad (1)$$

其中: $\lfloor m \rfloor_{\text{odd}}$  表示最接近  $m$  的奇数; $\lambda, b$  为用户自定义的超参数。

### 1.6 边界细化模块

在使用 DeepLabv3+ 对铝塑泡罩进行目标区域分割时,由于存在背景纹理干扰,会导致错误分割缺陷边缘。为了保证背景和目标区域的边缘被精确分割,本文提出了一种边界细化模块。

边界细化模块结构如图 4 所示。边界细化模块的输入为解码器  $3 \times 3$  卷积特征提取操作后获得的特征图,边界细化模块由数量为  $C/2, C/4, 1$  的 3 层  $1 \times 1$  卷积组合而成,  $1 \times 1$  卷积可以实现多通道特征图融合,增加网络的特征表达能力,从而得到精确的边缘信息。卷积层使用 ReLU 激活函数,提升非线性映射能力。输入特征图与经过 3 层  $1 \times 1$  卷积输出的特征图相乘,即获得输出特征图。




图 4 边界细化模块结构

## 2 实验结果与分析

### 2.1 缺陷检测系统

本文提出的缺陷检测系统由彩色面阵工业相机、镜头、光源、电脑组成,可以实现图像采集和缺陷检测功能,如图 5 所示。其中:相机采用意大利 Datalogic 公司生产的 959931011 相机,分辨率为  $2 592 \times 1 944$ ,使用 CMOS 传感器,最大帧率为 14 帧/s,该相机功耗低、帧率高、价格低,满足本文的要求;光源选用环形光源,能够提供不同照射角度的光,突出泡罩的三维信息,避免照射阴影。相机通过千兆以太网连接到基于 Windows 操作系统的电脑,电脑上运行缺陷检测软件对药板进

行实时缺陷检测。该软件以 PyCharm 作为开发平台,利用 Qt Designer 设计软件界面,通过 Python 语言实现各个功能模块的开发,可以实现调整相机参数、显示图像、统计合格率、存储数据等功能。




图 5 缺陷检测系统

## 2.2 铝塑泡罩表面缺陷数据集

使用搭建的缺陷检测系统采集数据集图像,数据集包含 237 张具有不同缺陷的铝塑泡罩表面图像。其中:只含药片单缺陷的图像 7 张;只含药板单缺陷的图像 123 张;含药片和药板双缺陷的图像 7 张。缺陷包含药板横纹、药板压粉、药片缺损、药片砾泡 4 种表面缺陷,如图 6 所示。




图 6 4 种表面缺陷

采用 js-segment-annotator 工具进行图像标注,该工具基于超像素标注,并且通过由粗到细的交互式分割解决超像素边界不准确的问题。标注时将药板横纹、药板压粉缺陷统一标注为药板缺陷类,将药片缺损、药片砾泡缺陷统一标注为药片缺陷类。具体做法是先使用大超像素分辨率进行粗标记,然后使用小超像素分辨率进行精细标记,

再将标记区域生成对应缺陷的掩码。

数据增强后得到含药片缺陷的图像 1 000 张,只含药板缺陷的图像 1 000 张,共计 2 000 张图像。数据集拆分为训练集 1 800 张,验证集 200 张,训练集与验证集之比为 9 : 1。

## 2.3 模型训练环境与模型参数选择

本实验模型训练硬件环境为: Intel(R) Xeon (R) Silver 4210R CPU @ 2.40 GHz 处理器; GeForce RTX 3090 的显卡。软件环境为: 基于 Ubuntu 18.04.5 LTS 操作系统; 基于 PyTorch 深度学习框架; 基于 CUDA11.1 及 PyCharm 集成开发环境。图像下采样倍数为 16,输入模型图像尺寸为  $512 \times 512$  像素。模型训练分为冻结阶段和解冻阶段: 冻结阶段训练进行 50 次迭代,批量大小为 8,学习率为 0.000 1; 解冻阶段训练进行 50 次迭代,批量大小为 8,学习率为 0.000 01。

## 2.4 评价指标

本文采用平均交并比 (mean intersection over union, MIoU) 作为网络分割性能评价指标。MIoU 为所有类别交并比的均值,交并比 (intersection over union, IoU) 为真实值与预测值两集合的交集比并集,计算公式为:

$$M_{\text{IoU}} = \frac{1}{k+1} \frac{T_P}{F_P + T_P + F_N} \quad (2)$$

其中:  $k$  为类别的数量;  $F_P$  为误分割的像素数;  $F_N$  为漏分割的像素数;  $T_P$  为正确分割的像素数。

对于小目标的定义<sup>[18]</sup>通常有 2 种: ① 长宽小于原图像长宽 1/10 的目标为相对小目标; ② 像素面积小于  $32^2$  的目标为绝对小目标。本文采用第 1 种定义,并使用小目标的  $\text{IoU}^{\text{Small}}$  (长宽小于原图像长宽 1/10 的目标的 IoU,下文简称为  $\text{IoU}^{\text{S}}$ ) 单独对小目标检测效果进行分析验证。

## 2.5 消融实验

为验证改进 DeepLabv3+ 网络对铝塑泡罩缺陷区域的分割精度,对原始 DeepLabv3+、特征提取网络改为 MobileNetV2 轻量级网络的改进 DeepLabv3+、特征提取模块和 ASPP 模块加入 ECA 的改进 DeepLabv3+、解码器中加入边界细化模块的改进 DeepLabv3+ 进行消融实验。实验结果见表 2 所列。

1) 方法 1。将传统 DeepLabv3+ 网络的特征提取网络 Xception 更改为 MobileNetV2 轻量级网络。

2) 方法 2。在方法 1 的基础上,在特征提取模块和 ASPP 模块加入 ECA。

3) 方法 3。在方法 2 的基础上,在 DeepLabv3+解码器中加入边界细化模块。

表 2 消融实验结果

方法	MIoU/ %	训练时间/ h	预测时间/ ms	参数量/ MiB
DeepLabv3+	83.92	4.80	144.46	54.71
方法 1	87.24	2.94	92.73	5.81
方法 2	88.64	2.81	95.78	5.81
方法 3	89.48	2.86	97.69	7.04

由表 2 实验结果可知:方法 1 模型的训练时间、单图预测时间和参数量显著减少,表示 DeepLabv3+模型的特征提取网络使用 MobileNetV2 网络相较于 Xception 网络能够显著提高模型训练及预测速度,同时降低模型复杂度;相较于方法 1,方法 2 和方法 3 模型的训练时间、单图预测时间与参数量相近,但平均交并比有提升,且方法 3 提升效果最明显。消融实验结果表明,本文方法可以有效提升对铝塑泡罩包装表面缺陷区域的分割精度。

## 2.6 不同方法性能分析

为验证本文改进 DeepLabv3+方法对铝塑泡罩表面缺陷区域的分割性能,使用传统 DeepLabv3+、PSPNet<sup>[19]</sup>、HRNet<sup>[20]</sup>方法与本文方法进行对比,结果见表 3 所列。

表 3 不同语义分割方法比较

方法	MIoU/ %	训练时间/ h	预测时间/ ms	参数量/ MiB
DeepLabv3+	83.92	4.80	144.46	54.71
PSPNet	74.98	1.89	112.09	46.72
HRNet	84.69	2.88	190.40	29.54
本文方法	89.48	2.86	97.69	7.04

从表 3 可以看出,本文方法的平均交并比为 89.48%,比传统 DeepLabv3+、PSPNet、HRNet 方法分别提高了 5.56%、14.50%、4.79%,表明本文方法有效提高了对铝塑泡罩表面缺陷区域的分割精度。神经网络模型的参数量及复杂度随着模型层数的增多而增多,训练难度也随之增大。由表 3 可知:相较于传统 DeepLabv3+、HRNet,本文方法的模型参数量显著减少,同时模型训练速度及单图预测速度加快;相较于 PSPNet,本文方法的模型参数量也有明显减少,但是模型训练速度降低,原因是 PSPNet 模型结构简单,提高了模型训练速度。总而言之,本文方法模型的特征

提取网络使用 MobileNetV2 网络,使模型参数量大大减少,加快了模型计算速度。

为进一步全面评估本文方法,将其他对比方法与本文方法在药片、药板和背景上的分割效果做对比实验,结果见表 4 所列。

表 4 各类别目标的分割效果

方法	IoU/%		
	药片	药板	背景
DeepLabv3+	67.31	85.69	98.76
PSPNet	63.24	63.33	98.36
HRNet	71.56	83.61	98.91
本文方法	78.11	91.15	99.19

由表 4 各方法在药片、药板和背景上的交并比可知,背景的平均交并比最高,药板略低,药片最低。这是由于整张图片中背景、药板、药片所占比例依次减少。总而言之,本文方法在药片、药板和背景上的交并比都比其他方法高,表明本文方法在各类别上的分割精度都有提升效果。

为验证本文方法对小目标缺陷的分割性能,使用验证集中只含药片缺损小目标缺陷的铝塑泡罩包装图片在 4 种方法模型上做对比实验,结果见表 5 所列。

表 5 小目标缺陷的分割效果

方法	IoU <sub>s</sub> /%
DeepLabv3+	50.56
PSPNet	9.18
HRNet	19.19
本文方法	70.62

由表 5 可知,DeepLabv3+、PSPNet 和 HRNet 方法对小目标缺陷的分割精度都很低,而本文方法比传统 DeepLabv3+ 的交并比提高了 22.06%,达到 70.62%,表明本文方法对提升小目标缺陷的分割精度具有良好的效果。

4 种方法在铝塑泡罩包装部分验证集上的可视化结果如图 7 所示。

图 7 中:绿色代表药板缺陷;红色代表药片缺陷;黑色代表背景。

从图 7 可以看出,样本 1 红框内为药片缺损小目标缺陷,在使用 DeepLabv3+、PSPNet、HRNet 方法进行缺陷检测时,均出现不同程度的漏检情况,其中 PSPNet 的漏检情况最为严重。但本文方法对小目标缺陷具备良好的分割效果,能够将药片缺损缺陷区域完整准确识别与分割。样本 2 和样

本 3 红色框内细长的药板横纹和药板压粉缺陷区域边缘由于受到复杂纹理背景干扰,在使用 DeepLabv3+、PSPNet、HRNet 方法进行缺陷检测时,缺陷边缘部分像素容易出现漏检和误检,从而导致细长缺陷分割时出现断裂的情况。但本文方法在背景有复杂纹理干扰的情况下仍能准确分割出细长缺陷,在其余方法对细长缺陷分割时出现断裂的情

况下仍能保持完整性,并且缺陷边缘细节处理更加清晰,轮廓更加明显。

综上可知,本文方法在小目标缺陷及复杂纹理背景的条件下准确分割了缺陷区域,比其他 3 种方法的分割效果都要好,证明了加入注意力机制和边界细化模块的必要性。




图 7 4 种方法的可视化结果

### 3 结 论

本文研究了一种基于改进 DeepLabv3+ 的语义分割缺陷检测方法,对铝塑泡罩药板表面缺陷区域进行提取,为提高模型对复杂表面纹理条件下具有小目标缺陷的铝塑泡罩药板的检测精度和效率,提出以下 3 种改进措施。

1) 针对部分铝塑泡罩泡罩表面缺陷尺度小的特点,在特征提取模块和 ASPP 模块中串联 ECA,加快全局特征融合,使像素特征间的语义关联性增加,降低细节信息损失,从而提高模型对小目标缺陷的分割效果,提高分割精度。

2) 采用轻量级 MobileNetV2 网络替代的 Xception 网络作为主干特征提取网络,并根据迁移学习方法在模型训练时使用基于 VOC 数据集训练之后的 MobileNetV2 预训练权重,在减少模型参数量提高模型计算速度的同时提升模型分割效果。

3) 将边界细化模块加入 DeepLabv3+ 网络的解码器中,提升模型在铝塑表面复杂纹理背景下对缺陷区域边缘的分割精度。

实验结果表明,本文提出的方法能够对铝塑泡罩包装表面缺陷区域进行有效提取,实现在提升对缺陷区域分割精度的同时提高模型训练和检测效率。

### [参 考 文 献]

[1] 张辉,易俊飞,王耀南,等. 医药质量检测关键技术及其应  
用综述[J]. 仪器仪表学报,2020,41(3):1-17.

[2] 赵朗月,吴一全. 基于机器视觉的表面缺陷检测方法研究进  
展[J]. 仪器仪表学报,2022,43(1):198-219.

[3] KIM S, JO Y, CHO J, et al. Spatially variant convolutional  
autoencoder based on patch division for pill defect detection  
[J]. IEEE Access, 2020, 8: 216781-216792.

[4] 谷紫颖,唐启慧,李振华. 基于机器视觉的泡罩药板穿泡缺  
陷检测方法[J]. 包装与食品机械,2019,37(4):58-63.

[5] 方文星,王野. 一种铝塑泡罩药品包装缺陷检测方法[J]. 包  
装工程,2019,40(1):133-139.

[6] 程旭,宋晨,史金钢,等. 基于深度学习的通用目标检测研究  
综述[J]. 电子学报,2021,49(7):1428-1438.

[7] LONG J, SHELHAMER E, DARRELL T, et al. Fully con-  
volutional networks for semantic segmentation[C]//IEEE  
Conference on Computer Vision and Pattern Recogniton.  
[S. l.]: IEEE, 2015: 3431-3440.

[8] 哈纳提·吐尔森哈力,林杭. 融合自注意力机制与深度学  
习的混凝土表面裂隙智能识别[J]. 铁道科学与工程学报,  
2021,18(4):844-852.

[9] 王卓,王玉静,王庆岩,等. 基于协同深度学习的二阶段绝  
缘子故障检测方法[J]. 电工技术学报, 2021, 36(17):  
3594-3604.

[10] HE K M, ZHANG X Y, REN S Q, et al. Spatial pyramid  
pooling in deep convolutional networks for visual recogni-  
tion [J]. IEEE Transactions on Pattern Analysis & Ma-  
chine Intelligence, 2015, 37(9): 1904-1916.

[11] 黄峥,颜上取,邹孝,等. 基于超声图像语义分割的 HIFU  
治疗目标区域提取方法[J]. 计算机辅助设计与图形学学  
报,2022,34(5):693-700.

[12] 曹斯言,刘君强,宋高腾,等. 基于自注意力语义分割的航  
空发动机孔探图像检测[J]. 北京航空航天大学学报,  
2023,49(6):1504-1515.

[13] 赵立新,侯发东,吕正超,等. 基于迁移学习的棉花叶部病  
虫害图像识别[J]. 农业工程学报,2020,36(7):184-191.

(下转第 1327 页)

- Optimal thermal operation of liquid-cooled electronic chips [J]. *International Journal of Heat and Mass Transfer*, 2012, 55(7/8):1957-1969.
- [12] DOWLING K M, SURIA A J, WON Y, et al. Inductive coupled plasma etching of high aspect ratio silicon carbide microchannels for localized cooling [C]//*International Electronic Packaging Technical Conference and Exhibition*. [S. l.]: American Society of Mechanical Engineers, 2015, 56901:V003T07A006.
- [13] DRUMMOND K P, BACK D, SINANIS M D, et al. A hierarchical manifold microchannel heat sink array for high-heat-flux two-phase cooling of electronics [J]. *International Journal of Heat and Mass Transfer*, 2018, 117:319-330.
- [14] DRUMMOND K P, BACK D, SINANIS M D, et al. Characterization of hierarchical manifold microchannel heat sink arrays under simultaneous background and hotspot heating conditions [J]. *International Journal of Heat and Mass Transfer*, 2018, 126:1289-1301.
- [15] GAMBIN V, POUST B, FERIZOVIC D, et al. Impingement cooled embedded diamond multiphysics co-design [C]//2016 15th IEEE Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems (ITherm). [S. l.]: IEEE, 2016:1518-1529.
- [16] SONG Y, FU R, CHEN C, et al. Case-embedded cooling for high heat flux microwave multi-chip array [J]. *Applied Thermal Engineering*, 2022, 214:118852.
- [17] HAN Y, LAU B L, TANG G, et al. Thermal management of hotspots using diamond heat spreader on Si microcooler for GaN devices [J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2015, 5(12):1740-1746.
- [18] COLLIN L M, COLONNA J P, COUDRAIN P, et al. Add-on microchannels for hotspot thermal management of microelectronic chips in compact applications [J]. *IEEE Transactions on Components, Packaging and Manufacturing Technology*, 2018, 9(3):434-445.
- [19] COLLIN L M, COLONNA J P, COUDRAIN P, et al. Hot spot aware microchannel cooling add-on for microelectronic chips in mobile devices [C]//2017 16th IEEE Intersociety Conference on Thermal and Thermomechanical Phenomena in Electronic Systems (ITherm). [S. l.]: IEEE, 2017:460-464.
- [20] ZHOU F, JOSHI S N, LIU Y, et al. Near-junction cooling for next-generation power electronics [J]. *International Communications in Heat and Mass Transfer*, 2019, 108:104300.
- [21] YE Y, LIU R, DU X, et al. Investigation on multidimensional test vehicle for embedded microfluidic cooling performance evaluation [J]. *Applied Thermal Engineering*, 2021, 195:117149.
- [22] DITRI J, PEARSON R R, CADOTTE R, et al. GaN unleashed: the benefits of microfluidic cooling [J]. *IEEE Transactions on Semiconductor Manufacturing*, 2016, 29(4):376-383.
- [23] KANG T, YE Y, JIA Y, et al. Enhanced thermal management of gan power amplifier electronics with micro-pin fin heat sinks [J]. *Electronics*, 2020, 9(11):1778.
- [24] ZHANG N, JIAO B, YE Y, et al. Embedded cooling method with configurability and replaceability for multi-chip electronic devices [J]. *Energy Conversion and Management*, 2022, 253:115124.
- [25] SCHLOTTIG G, DE FAZIO M, ESCHER W, et al. Lid-integral cold-plate topology: integration, performance, and reliability [J]. *Journal of Electronic Packaging*, 2016, 138(1):010906.

(责任编辑 胡亚敏)

## (上接第 1320 页)

- [14] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [M]//FERRARI V, HEBERT M, SMINCHISESCU C, et al. *Computer vision-ECCV 2018 lecture notes in computer science*. Cham: Springer, 2018:833-851.
- [15] SANDLER M, HOWARD A, ZHU M L, et al. MobileNetV2: inverted residuals and linear bottlenecks [C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Salt Lake City: IEEE, 2018:4510-4520.
- [16] CHOLLET F. Xception: deep learning with depthwise separable convolutions [C]//*Proceedings of the 2017 IEEE Conference on Computer Vision and Pattern Recognition*. Washington, D. C.: IEEE Computer Society, 2017:1800-1807.
- [17] XIANG X Z, ZHANG Y Q, SADDIK A E. Pavement crack detection network based on pyramid structure and attention mechanism [J]. *IET Image Processing*, 2020, 14(8):1580-1586.
- [18] 刘颖, 刘红燕, 范九伦, 等. 基于深度学习的小目标检测研究与应用综述 [J]. *电子学报*, 2020, 48(3):590-601.
- [19] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]//*IEEE Conference on Computer Vision and Pattern Recognition*. [S. l.]: IEEE, 2017:2881-2890.
- [20] SUN K, XIAO B, LIU D, et al. Deep high-resolution representation learning for human pose estimation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition. [S. l.]: IEEE, 2019:5686-5696.

(责任编辑 胡亚敏)