

DOI:10.19651/j.cnki.emt.2108625

# 基于多模型级联的轻量级缺陷检测算法

周宣 沈希忠

(上海应用技术大学电气与电子工程学院 上海 201418)

**摘要:** 基于深度学习技术的缺陷检测算法往往因为网络参数较多而需要大量的图像样本去训练模型,但是在工业生产过程中缺陷产品数量极少,采集大量缺陷数据图像费时又费力。针对这一难题,本文提出了一种基于多模型级联的轻量级缺陷检测算法,采用监督学习的训练方式,通过少量缺陷样本就可以获得较好的检测效果。首先,使用CBAM注意力残差模块代替常规卷积层进行特征提取,以聚焦缺陷特征,强化网络对缺陷的表征能力;其次,设计了SE-FPN模块,促进各级特征之间有效融合,提高网络对缺陷的分割效果,尤其是对小缺陷的分割效果;最后,在训练阶段,采用监督学习方式对本文所提的多模型算法网络进行训练。实验结果表明,本文所提算法在KolektorSDD数据集上的检测准确率高达99.28%,每张图像的平均检测时间仅需10.5 ms,不但充分满足了工业检测行业高精度、实时性的要求,同时,还能实现对缺陷区域精准定位。因此,本文的研究内容非常适合应用在工业产品表面质量在线检测领域。

**关键词:** 缺陷检测;多模型级联;监督学习;注意力;特征融合

中图分类号: TP391 文献标识码: A 国家标准学科分类代码: 520.2040

## Lightweight defect detection algorithm based on multi model cascade

Zhou Xuan Shen Xizhong

(College of Electrical and Electronic Engineering, Shanghai University of Applied Technology, Shanghai 201418, China)

**Abstract:** Defect detection algorithms based on deep learning technology often need a large number of image samples to train the model because of many network parameters. However, in the process of industrial production, the number of defective products is very small, and collecting a large number of defect data images is time-consuming and laborious. To solve this problem, this paper proposes a lightweight defect detection algorithm based on multi model cascade. It adopts the training method of supervised learning, and can obtain better detection results through a small number of defect samples. Firstly, CBAM attention residual module is used to extract features instead of conventional convolution layer to focus on defect features and strengthen the characterization ability of network to defects. Secondly, the SE-FPN module is designed to promote the effective integration of features at all levels and improve the segmentation effect of network on defects, especially for small defects. Finally, in the training stage, the supervised learning method is used to train the multi model algorithm network proposed in this paper. The experimental results show that the detection accuracy of the proposed algorithm on KolektorSDD data set is as high as 99.28%, and the average detection time of each image is only 10.5 ms. It not only fully meets the requirements of high precision and real-time in the industrial detection industry, but also realizes the accurate positioning of defect areas. Therefore, the research content of this paper is very suitable for application in the field of on-line detection of surface quality of industrial products.

**Keywords:** defect detection; multi model cascade; supervised learning; attention; feature fusion

## 0 引言

文献[1]提出,表面缺陷检测是机器视觉领域中非常重要的研究内容,是利用机器视觉设备获取图像来判断采集图像中是否存在缺陷的技术。在工业生产过程中,由

于各种外界因素,产品表面不可避免的会产生各种缺陷,比如文献[2]中列出污点、划痕、裂纹、缺角等这几种产品缺陷类型,这些缺陷在形状上往往具有多样性且缺陷发生的位置具有随机性,这就对工业产品在线缺陷检测带来了一定的困难。如果采用人眼去检查产品表面是否存在缺陷的方

法往往效率极低且不能长时间持续工作,而采用传统图像处理的方法漏检率又很高,难以达到工业应用要求,所以研究一种准确率高且实时效果好的缺陷检测算法对在线缺陷检测领域产业升级有重大意义。

近年来,基于深度学习技术的缺陷检测算法的研究越来越多,逐渐替代了传统的缺陷检测方法。比如:奥地利科技研究所<sup>[3]</sup>最早采集光度立体图像训练 CNN 网络来实现轨道表面空洞缺陷分类,在钢轨表面数据集上最终达到的错误识别率仅有 1.108%;Shang 等<sup>[4]</sup>提出了一种两阶段的铁轨缺陷识别算法,首先利用 Canny 和直线拟合算法在整个原始图像上对铁轨区域进行裁剪,然后将裁剪的图像放入 InceptionV3 网络中提取特征以进行轨道图像分类;Fusaomi 等<sup>[5]</sup>提出了一种 SSSNet (net with SVMs to classify sample images) 网络,该网络有两个分类分支,多类别分类采用这种二分支结构,可以充分利用缺陷样本与正常样本数目不均衡的特点,挖掘两者特征之间的差异;2019 年,Lin 等<sup>[6]</sup>提出了 LEDNet 架构,所提出的 LEDNet 结合 CAM 技术实现了芯片图像分类和缺陷区域定位,与传统方法相比,所提出的 LEDNet 显示出缺陷检测率的显著提高;Qiu 等<sup>[7]</sup>提出了三阶段缺陷区域的表面缺陷分割算法,他们提出的方法对缺陷区域进行了细化,取得了不错的检测效果,然而,其检测阶段仍采用滑动窗口采样的形式,检测效率有待提高;Božic<sup>[8]</sup>,Racki<sup>[9]</sup>和 Tabernik<sup>[10]</sup>等也提出了一种类似的网络模型,他们都是将产品表面图像的缺陷检测任务分多个阶段完成,这使得其最终的缺陷检测效果有所改善。

结合以上相关工作的研究,本文提出了一种基于多模型级联的缺陷检测算法,采用深度学习技术将缺陷检测任务拆成两步分别在多个模型中进行,在实验中取得了很好的缺陷检测效果。这样的设计大大减少了单模型中产品错分情况的发生,提高了缺陷检测的准确率,并且尽量减少了网络参数,提高了产品缺陷检测速度。本文主要做了如下工作:

- 1) 设计了多模型级联的轻量级缺陷检测算法,算法性能好,网络参数少,实用性强;
- 2) 提出 CBAM 注意力残差模块,增强了特征提取网络对缺陷特征的学习能力;
- 3) 提出 SE-FPN 模块,使图像的多级特征有效融合,提高了算法对多尺寸缺陷的检测能力;
- 4) 进行了模型融合,取消了全连接层,采用  $1 \times 1$  卷积层替换,并且在  $1 \times 1$  卷积层之前添加了全局平均池化(GAP)和全局最大池化(GMP)操作。

## 1 算法原理

### 1.1 模型框架

基于多模型级联的轻量级缺陷检测算法网络结构如图 1 所示,主要由分割模型和分类模型组成,它们共用

backbone 网络对输入图像进行特征提取,分割模型输出缺陷分割结果,对产品图像的缺陷区域进行精准定位,分类模型输出产品存在缺陷的概率,通过设定合适的阈值就可以准确将 Good 和 NG 产品区分开,实验表明,取阈值为 0.5 时分类效果最佳。

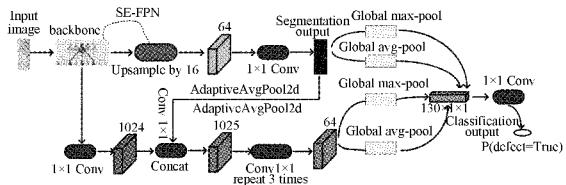


图 1 算法网络结构

分割模型采用编码器-解码器结构,编码阶段由 backbone 网络完成,如图 2 所示,产品图像进行预处理后送入 backbone 网络中,首先经过大小为  $5 \times 5$  的卷积层,然后将卷积结果依次送入 5 个 CBAM 残差模块中,前 4 个 CBAM 残差模块后面都连接着一个步长为 2,尺寸为  $5 \times 5$  的卷积层替代池化层进行下采样,增大感受野,提高各特征点之间的相关性;解码阶段由 SE-FPN 模块完成,由于每个特征通道都可以看成一个专门的特征检测器,因此,引入 SE 结构可以选择性强化重要特征的作用并且抑制非重要的特征,使浅层视觉特征和高级语义特征得以有效融合,从而进一步提升缺陷分割的准确率。

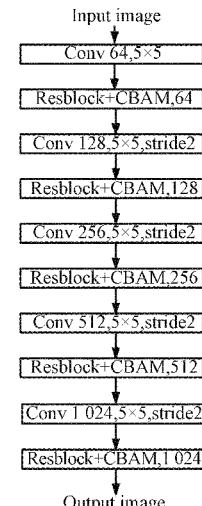


图 2 backbone 网络

而分类模型在 backbone 网络完成特征提取后与分割模型的输出进行通道数拼接,紧接着通过 3 个大小为  $5 \times 5$  的卷积层,进一步提取融合分割输出后的图像特征,然后同时对提取到的深层次特征和分割输出进行全局平均池化和全局最大池化并将结果拼接起来,最后送入  $1 \times 1$  卷积层得到产品存在缺陷的概率  $P$ ,设定合适阈值便可得到产品分类结果,实验中阈值取 0.5 时效果最佳。

### 1.2 CBAM 残差模块

本文所提算法主要是在工业缺陷样本难采集的情况下

而提出的,一般的卷积网络往往会因为缺陷样本过少而不能很好地学习到缺陷的具体特征参数。因此,为了提升网络对图像的特征提取能力,本文提出了把CBAM残差结构作为backbone网络的基本模块。CBAM残差结构如图3所示,就是在残差模块中从通道和空间两个维度上分别引入注意力,重点学习网络所关注的特征。这样的结构可以使网络自适应学习图像的有效特征,并且随着网络的加深还能避免训练过程中出现梯度消失的情况。

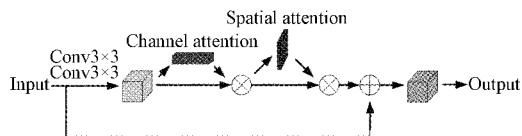


图3 CBAM残差结构

CBAM主要由通道注意力和空间注意力两部分级联组成,这两部分注意力可以看成是两个独立的模块,其具体网络结构如图4所示。

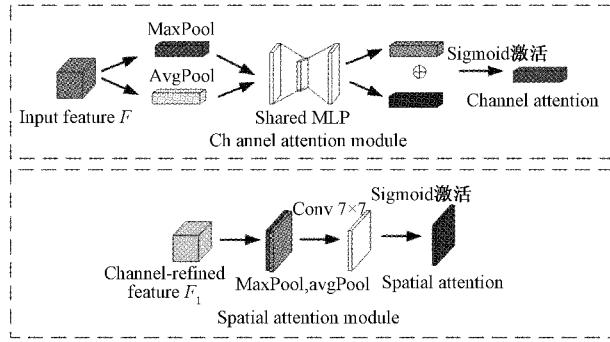


图4 CBAM注意力形成过程

其中通道注意力的Shared MLP部分采用的是两个大小为 $1 \times 1$ 的卷积层,取代全连接层求取通道注意力权重参数,同时为了较少参数,提高网络的泛化能力,本文对通道数进行了先降后升的操作,实验中缩放系数 $r$ 取16,获取通道注意力的具体过程是:假设输入是一个 $H \times W \times C$ 的特征 $F$ ,先分别对其进行空间维度上的全局平均池化和最大池化得到两个 $1 \times 1 \times C$ 的通道描述;接着,再将它们分别送入卷积核大小为 $1 \times 1$ 的卷积层中,第1层神经元个数为 $C/r$ ,激活函数为ReLU,第2层神经元个数为 $C$ ;然后,再将得到的两个特征相加后经过一个Sigmoid激活函数得到每个通道所对应的权重参数,将其称为通道注意力;最后,通道注意力和原来的特征 $F$ 相乘即可得到缩放后的新特征 $F_1$ 。空间注意力形成过程如图5所示,输入上述得到的新特征 $F_1$ ,先对其进行通道维度上的平均池化和最大池化操作,再将池化结果的通道拼接在一起,然后,送入一个 $7 \times 7$ 的卷积层,经Sigmoid函数激活之后便可得到空间上各个位置所对应的权重参数,将其称为空间注意力。空间注意力和特征 $F_1$ 相乘之后即可得到残差模块引入CBAM注意力的特征提取结果。

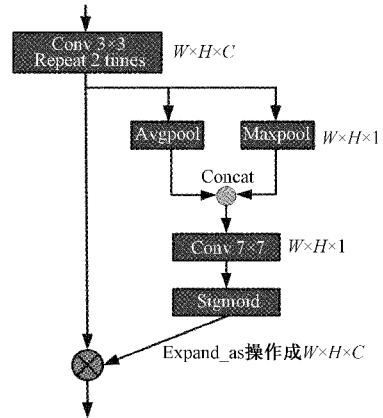


图5 空间注意力形成过程

### 1.3 SE-FPN模块

特征金字塔网络<sup>[11]</sup>(FPN)结构最早应用在目标检测领域,主要是为了促进多级特征融合,提高小目标的检测效果,同时考虑到每一个特征通道就好比一个专门的特征检测器,基于此,为了提高本文算法对多尺度缺陷的检测效果,本文在FPN的基础上进行改进,提出了图6所示的SE-FPN模块,其采用了和特征金字塔网络一样的top-down结构,但与FPN不同的是,本文通过跳跃连接实现通道数叠加之后将融合后的特征送入SENet模块中进行压缩和激励操作,选择性强化重要特征的作用并且抑制非重要的特征,使低级图像特征和高级语义特征有效融合。这样的结构设计使得在高分辨率的浅层特征映射上含有较多深层能够概况缺陷最本质特征的有用信息,可以大大提高网络对缺陷目标的分割效果,尤其可以提高对小缺陷目标的分割效果。

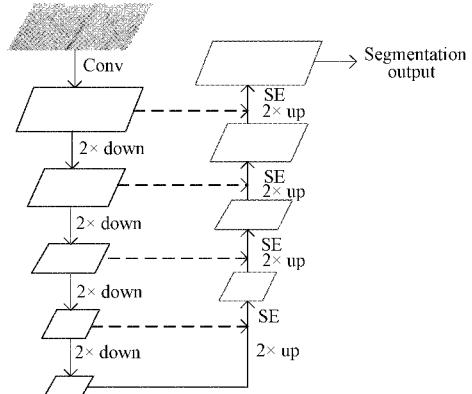


图6 SE-FPN结构

SENet模块能够在网络中自适应学习每个特征通道的重要程度,并通过赋予特征图的各通道不同的权值,调整特征通道的重要性。对于低质量产品表面图像,这种结构可以在网络中取得很大的优势,使模型聚焦于具有更多有效特征信息的通道,提升低质量产品表面缺陷分割的精度。SENet网络结构如图7所示,为得到输入特征图各通道的

权重,SENet 将对其进行压缩和激励两步操作,压缩操作就是对每个特征通道在空间维度上进行全局平均池化,激励操作就是将压缩结果送入两个卷积核为  $1 \times 1$  大小的卷积层中,结合 ReLU 非线性函数建立各通道之间的相关性,从而得到各个特征通道相应的激励系数,具体过程如图 8 所示。

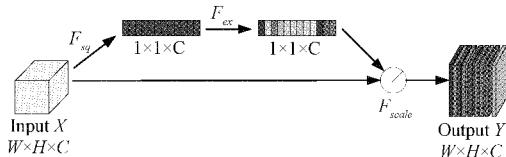


图 7 SENet 网络结构

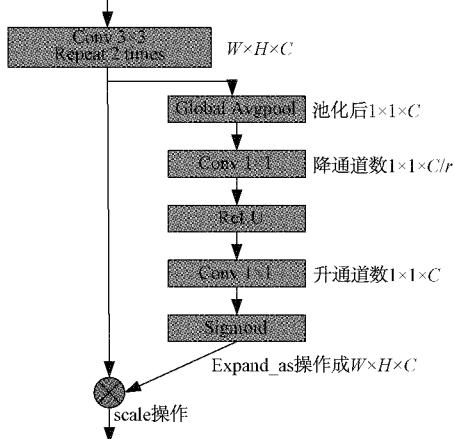


图 8 SE 流程图

## 2 网络训练

### 2.1 KolektorSDD 数据集

本文所采用 KolektorSDD 数据集是由 Kolektor Group 提供并注释的,这些图像来自于 50 个电子换向器中,每个换向器有 8 个面,每个面采集一张图像,总共 400 张图像样本,每个样本的尺寸为  $500 \times 1259$ ,其中缺陷样本只有 52 张,如图 9 所示,产品中缺陷的形状、长度、粗细以及位置都具有多样性。

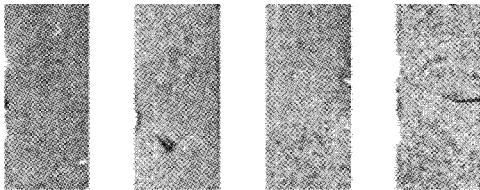


图 9 缺陷样本图像

### 2.2 图像预处理

由于缺陷样本数量较少,模型在训练过程中很难学习到能够表示缺陷最本质的特征,针对这一情况,为了增加样本图像数量,扩充训练集,本文在实验前尝试采用图像垂直翻转、水平翻转以及尺寸变换等方式对训练集图像数量扩

充了 3 倍,并且对训练集中的标签图像进行了膨胀操作,而测试集不做任何变化。

实验结果表明,用扩充后的数据集训练本文所提模型比原数据集训练的缺陷检测准确率提高了 18.5%,并且缺陷分割效果也得到了改善,如图 10 所示,图 10(a)是缺陷产品表面图像,图 10(b)是数据集扩充之前的缺陷定位结果,图 10(c)是数据集扩充 3 倍之后的缺陷定位结果。

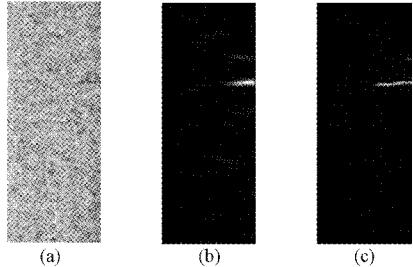


图 10 数据集扩充前后的算法效果对比

### 2.3 训练细节

在分割网络训练任务中,本文结合两种损失函数 Dice Loss<sup>[12]</sup> 和 Focal Loss<sup>[13]</sup> 训练分割网络,其计算公式为:

$$LDice = \sum_{c=0}^{C-1} \frac{TP_p(c)}{TP_p(c) + \alpha FN_p(c) + \beta FP_p(c)} \quad (1)$$

$$LFocal = \frac{1}{N} \sum_{c=0}^{C-1} \sum_{n=1}^N gn(c)(1 - pn(c))^2 \log(pn(c)) \quad (2)$$

$$Loss = C - (LDice + \lambda LFocal) \quad (3)$$

其中,  $TP_p(c)$ ,  $FN_p(c)$ ,  $FP_p(c)$  分别为类别的真阳性率,假阴性率,假阳性率;  $c$  表示某个特定的类别;  $C$  为总类别数(包括背景);  $N$  为总像素数量;  $pn(c)$  是像素  $n$  为  $c$  类的预测概率;  $\alpha$  和  $\beta$  分别为假阴性和假阳性的惩罚权重,均设置为 0.5;  $gn(c)$  是像素  $n$  为  $c$  类的真实情况;  $\lambda$  为 Dice Loss 和 Focal Loss 之间的权重,设置为 0.5。

在训练分类网络时使用了均方误差作为损失函数,其具体计算公式为:

$$LMSE(c) = \frac{1}{N} \sum_{n=1}^N (xi(c) - \hat{xi}(c))^2 \quad (4)$$

其中,  $xi(c)$  表示图像为  $c$  类的真实情况 ( $xi(c) = 0$  或  $xi(c) = 1$ );  $\hat{xi}(c)$  表示图像为  $c$  类的预测概率。

本文的实验部分是在 Pycharm 软件基于 Pytorch 深度学习框架结合 Python 编程语言搭建的,计算机配置如下:CPU 型号为 i5-11400;GPU 型号为 NVIDIA GeForce GTX 3060,显存 12 G;系统内存 32 G。优化算法采用 Adam 算法,其中学习率参数设置为 0.01, betas 参数设置为 (0.5, 0.999)。在训练过程中分割网络和分类网络分开训练,首先训练好分割部分的网络参数,将其保存在 PTH 文件中,每隔 10 个 epoch 保存一次,共迭代 100 次;分割网络训练结束后,挑选出分割效果最好的一组参数,将其作为预训练数据迁移到分类网络的训练中,分类网络共迭代 60 次。

## 2.4 评价指标

由于缺陷检测系统通常作用在生产线上,这就决定了所设计的缺陷检测算法必须同时具有检测准确率高、实时效果好等特点。为了表明本文所提算法能够很好地应用在工业生产线上,本文将采用准确率和每张图像的平均检测时间  $t_s$  作为该算法的客观评价指标,准确率  $Acc$  的具体计算公式为:

$$Acc = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

其中,  $TP$  代表被模型预测为正类的正样本数量;  $TN$  代表被模型预测为负类的负样本数量;  $FP$  代表被模型预测为正类的负样本数量;  $FN$  代表被模型预测为负类的正样本数量。

同时本文也将展示产品缺陷定位的实际效果图,将其作为该算法的一项主观评价指标。

## 3 实验结果及分析

### 3.1 消融实验

为了展示本文所提出的算法在少量缺陷数据集情况下对电子换向器表面图像的检测效果以及跳跃连接结构和注意力模块对算法检测效果的影响,设计了消融实验,评估对应算法的检测效果。具体实验内容及检测结果如表 1 所示,其中,“√”表示使用了对应方法。

表 1 消融实验结果对比

算法	SE-FPN	CBAM	准确率/%	$t_s$ / ms
1			92.08	6.5
2	√		97.12	6.7
3		√	97.84	10.3
4	√	√	99.28	10.5

1) 算法 1 中 CBAM 残差模块和 SE-FPN 模块都不引入,从表 1 中可以发现,算法 1 的缺陷检测准确率高达 92.08%,单张图片平均检测时间为 6.5 ms,这说明本文提出的基于多模型级联的缺陷检测算法在缺陷样本过少的情况下也能取得不错的检测准确率,是一种可取的设计思路,但缺陷分割效果有待提升,如图 11(b)所示。

2) 算法 2 设计了 SE-FPN 模块,主要是为了使产品图像的不同层级特征有效融合,解决小缺陷检测效果差的问题。从表 1 和图 11 中不难发现,算法 2 的缺陷检测准确率和缺陷分割效果均有提升,平均检测准确率提高了 5.04%,通过图 11(b)、(c)两组图片对比可知,算法 2 对小缺陷的分割效果也得到了明显改善,这说明 SE-FPN 模块能够改善网络对缺陷的检测效果,尤其是对小缺陷的检测效果。

3) 算法 3 在网络特征提取过程设计了 CBAM 残差模

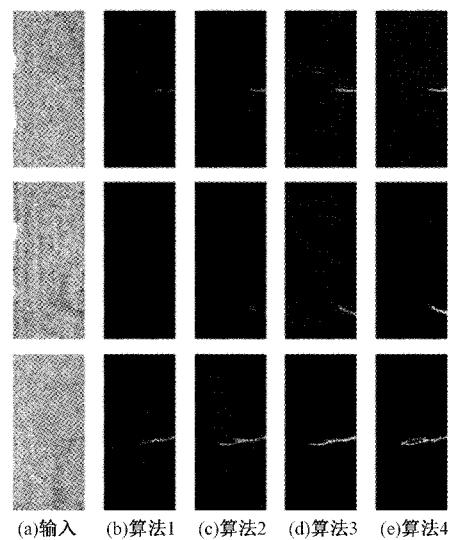


图 11 缺陷分割效果可视化对比

块,主要是为了解决网络对缺陷特征学习能力不足的问题。从表 1 和图 11 中可以看出,算法 3 的提升效果更为明显,平均检测准确率比算法 1 提高了 5.76%,缺陷分割效果从主观上来说也更加好,这说明 CBAM 残差模块确实能够提升网络对缺陷特征的学习能力。在实时性方面,单张图片的平均检测时间为 10.3 ms,比算法 1 增加了 3.8 ms,但这个检测速度依然满足工业生产的实时性要求。

4) 算法 4 为本文所提算法,组合使用 SE-FPN 模块和 CBAM 残差模块对缺陷样本进行训练,从表 1 可以看出,本文算法对缺陷的检测准确率在这几个实验中最高,达 99.28%,单张图片的平均检测时间也只有 10.5 ms,并且从图 11 中的各组图片对比不难发现,该算法的缺陷分割效果也更加细腻,充分满足了工业生产过程中对产品表面缺陷在线检测准确率和实时性方面的要求,同时还能提供缺陷产品表面缺陷区域具体位置的可视化结果。总之,本文所提算法模型解决了电子换向器表面缺陷检测任务中因为缺陷样本少而导致检测效果差的实际问题,验证了该算法在工业缺陷检测领域的可行性和有效性。

### 3.2 不同检测算法性能对比实验

为了进一步评估本文算法的有效性,与当前常见算法包括 SE-ResNet101<sup>[14]</sup>、SegNet<sup>[15]</sup>、U-Net<sup>[16]</sup>以及 DeepLabv3+<sup>[17]</sup>进行性能对比。如表 2 所示,本文所提算法的总体检测效果最好,在 KolektorSDD 数据集上的准确率高达 99.28%,且网络参数相对较少。尽管 U-Net 算法网络参数更少,但是其检测准确率和缺陷分割效果都不如本文所提算法,而 DeepLabv3+ 模型虽然对缺陷分类的准确率和本文算法差不多,但是其网络参数量巨大,由于本文使用的数据集缺陷样本过少,导致网络在训练过程中存在过拟合,缺陷分割效果较差。

表2 不同算法性能对比

算法	参数量( $10^6$ )	准确率/%
SE-ResNet101	47.28	86.49
SegNet	29.44	89.27
U-Net	7.78	92.84
DeepLabv3+	59.34	98.56
本文算法	15.36	99.28

## 4 结论

本文针对缺陷产品样本不足所提出的基于多模型级联的轻量级缺陷检测算法,在保证产品检测准确率、缺陷分割效果以及实时性的同时,还避免了在工业生产过程中采集大量缺陷样本耗时耗力的局面。为了检验算法以及算法部分模块设计的有效性,本文在小样本的KolektorSDD数据集上进行了大量实验,还通过实验与目前常见的几种算法性能进行了对比,进一步印证了本文算法的有效性。唯一不足的是,该算法只在电子换向器这一种产品上进行了验证,为了证明该算法在工业产品表面缺陷检测的普适性,我们将在后续工作中在其他多种产品上进行表面缺陷检测实验,尝试在工业实际应用中发挥价值。

## 参考文献

- [1] 陶昱,侯伟,徐德.基于深度学习的表面缺陷检测方法综述[J].自动化学报,2021,47(5):1017-1034.
- [2] 杨珂,方诚,段黎明.基于深度学习模型融合的铸件缺陷自动检测[J].仪器仪表学报,2021,42(11):150-159.
- [3] SOUKUP D, HUBER-MORK R. Convolutional neural networks for steel surface defect detection from photometric stereo images [C]. Proceedings of International Symposium on Visual Computing, 2014: 668-677.
- [4] SHANG L, YANG Q, WANG J, et al. Detection of rail surface defects based on CNN image recognition and classification[C]. Proceedings of the 20th International Conference on Advanced Communication Technology (ICACT), IEEE, 2018: 45-51.
- [5] FUSAOMI N, KENTA T, KENTO N, et al. Fusion method of convolutional neural network and support vector machine for high accuracy anomaly detection [C]. Proceedings of IEEE International Conference on Mechatronics and Automation (ICMA), IEEE, 2019: 970-975.
- [6] LIN H, LI B, WANG X, et al. Automated defect inspection of LED chip using deep convolutional neural network [J]. Journal of Intelligent Manufacturing, 2019, 30(6): 2525-2534.
- [7] QIU L, WU X, YU Z. A high-efficiency fully convolutional networks for pixel-wise surface defect detection[J]. IEEE Access, 2019, 7:15884-15893.
- [8] BOŽIĆ J, TABERNIK D, SKOCAJ D. End-to-end training of a two-stage neural network for defect detection[C]. 2020 25th International Conference on Pattern Recognition(ICPR), 2021:5619-5626.
- [9] RACKI D, TOMAZEVIC D, SKOCAJD. A compact convolutional neural network for textured surface anomaly detection [C]. IEEE Winter Conference on Applications of Computer Vision, 2018: 1331-1339.
- [10] TABERNIK D, ŠELA S, SKVARČ J, et al. Segmentation-based deep-learning approach for surface-defect detection [J]. Journal of Intelligent Manufacturing, 2020, 31(3): 759-776.
- [11] LIN T, DOLLAR P, GIRSHICK R, et al. Feature pyramid networks for object detection[C]. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition(CVPR), 2017: 2117-2125.
- [12] MILLETARI F, NAVAB N, AHMADIS A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation [C]. 2016 Fourth International Conference on 3D Vision (3DV), 2016: 565-571.
- [13] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2020, 42(2): 318-327.
- [14] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]. IEEE Computer Society Press, 2018: 7132-7141.
- [15] BADRINARAYANAN V, KENDALL A, CIPOLLA R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.
- [16] RONNEBERGER O, FISCHER P, BROX T. U-Net: Convolutional networks for biomedical image segmentation [C]. Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention, 2015: 234-241.
- [17] CHEN L C, ZHU Y K, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. Proceedings of the European Conference on Computer Vision, 2018: 833-851.

## 作者简介

周宣,硕士研究生,主要研究方向为计算机视觉与图像处理。

E-mail:3530026055@qq.com

沈希忠(通信作者),工学博士,博士后,教授,硕士研究生导师,主要研究方向为信号处理与人工智能技术。

E-mail:xzshen@yeah.net