

DOI:10.13364/j.issn.1672-6510.20230005

基于改进 U-Net 的电子换向器表面缺陷分割方法

黄紫彤, 刘尧猛, 李 瑞
(天津科技大学人工智能学院, 天津 300457)

摘要: 电子换向器的表面缺陷形状各异、缺陷与背景差异较小,同时还存在表面杂质干扰缺陷分割结果等问题,导致电子换向器缺陷难以精细分割。本文提出一种基于多尺度融合和残差分离卷积的改进 U-Net 缺陷分割方法。将不同尺度的图像输入编码模块便于网络模型提取多尺度下缺陷特征信息,并构建残差分离卷积模块,在增大感受野的同时保留细节特征。将多尺度的输出图像放大到相同尺度并融合作为最终输出,实现特征信息语义和位置的信息互补,从而提高网络的分割精度。在公开的 KolektorSDD 数据集上的实验结果表明,该方法的相似性系数和精确率分别达到 97.3% 与 97.8%,缺陷分割效果相比于 SegNet、FCN-8S 等经典分割网络更加优秀,能够更加准确地识别细小缺陷。

关键词: 电子换向器; 缺陷检测; 多尺度融合; 残差分离卷积; U-Net

中图分类号: TP391 文献标志码: A 文章编号: 1672-6510(2023)04-0041-07

Surface Defect Segmentation of Electronic Commutator Based on Improved U-Net

HUANG Zitong, LIU Yaomeng, LI Rui

(College of Artificial Intelligence, Tianjin University of Science & Technology, Tianjin 300457, China)

Abstract: The surface defects of the electronic commutator are diverse in shape, with small differences between defects and backgrounds, and there are also such problems as surface impurities interfering with the detection results, which makes it difficult to finely segment commutator defects. To solve these problems, an improved U-Net defect segmentation method based on multi-scale fusion and residual separation convolution is proposed in this article. In the improved method, different scales of images are input into the coding module, which makes it convenient for the network model to extract defect feature information at multiple scales, and the residual separable convolution module is constructed to increase the receptive field while retaining detailed features. The output images of multiple scales are enlarged to the same scale and fused, thus realizing the complementary of feature information semantics and position, so as to improve the segmentation accuracy of the network. Experimental results on the published KolektorSDD dataset showed that the similarity coefficient and precision of the proposed method reached 97.3% and 97.8%, respectively, and the defect detection effect was better than that of classic segmentation networks such as SegNet and FCN-8S, and could identify small defects more accurately.

Key words: electronic commutator; defect detection; multiscale fusion; residual separable convolution; U-Net

电机是工业、交通、国防及日常生活中不可或缺的重要基本设备,其下游行业包含了几乎全部国民经济基础行业,在保障与促进社会经济发展中起到重要作用^[1]。作为电机的核心组成器件,电子换向器在生产过程中容易在表面产生破损、裂痕、断裂等缺陷,导致电机无法正常工作,甚至会造成严重的安全事

故,对电子换向器进行缺陷检测十分必要。

目前,电子换向器的缺陷检测以人工检测为主,存在成本高、精度低和耗时长等问题。仅采用人工检测,检测的效率与效果已经无法满足当前的生产要求,因此使用自动化的检测系统成为未来工业生产的必然趋势^[2]。机器视觉为缺陷检测提供了自动化

收稿日期: 2023-01-09; 修回日期: 2023-04-06

作者简介: 黄紫彤(1997—),男,湖北人,硕士研究生;通信作者: 刘尧猛,副教授, liuym@tust.edu.cn

方式,被视为替代人工检测的有效选择,能够加快检测速度、降低人工成本。该检测技术需要预先对缺陷特征进行提取,在单一缺陷和简单背景的情景下能够很好地解决问题。但是,电子换向器存在多种类型的表面缺陷,并且缺陷特征复杂多样,包括细微型、线型和块型等,传统机器视觉技术无法提取具有鲁棒性的特征,致使检测效果不佳。

近年来,随着深度学习技术的飞速发展,以卷积神经网络(convolutional neural network, CNN)为代表的计算机视觉算法在缺陷分类、缺陷定位和缺陷分割方面表现出色^[3]。缺陷分类的目的是判断缺陷类型,He 等^[4]提出一种用于钢材表面缺陷的分类方法,借助半生成对抗网络随机生成图像的优势,将卷积自编码器提取和堆叠后的特征进行分类,能够有效减少训练过程对多样本的依赖,并且分类识别的精度较高。缺陷定位对缺陷的位置更加感兴趣,黄凤荣等^[5]将聚类理论引入 Faster R-CNN 网络框架,提出多级感兴趣区域池化的零件表面缺陷定位算法,通过引入多级感兴趣区域,减少了池化过程中带来的偏差,实现高效并准确框选零件表面缺陷的目的。缺陷分割是通过对图像进行像素级别的标记,以实现更细粒度的理解和分析。Huang 等^[6]在 2018 年提出一种基于全卷积网络(fully convolutional network, FCN)的缺陷分割方法,该方法可以从复杂彩色图像中准确提取精细的裂缝路径和形态信息,实现缺陷语义分割。与机器视觉检测方法相比,深度学习可以提取更复杂、更多样的特征,故可以较好地满足各类型检测任务的需求。

深度学习模型通常需要经过大量数据的训练后才能发挥最佳效果。在现实环境中,缺陷样本不容易获取,而且缺陷样本还需经过标注后才可用于训练。针对缺陷样本不足的问题,常见的解决方式有数据扩增、迁移学习及网络结构设计^[7-9]。数据扩增包括数据增强和数据合成,前者通过采用镜像、旋转、平移等方式操作原始图像,后者借助无监督学习算法直接生成缺陷图像,两种方法均直接增加了缺陷样本数量。He 等^[7]利用无监督的生成对抗网络训练生成大量未标记的缺陷图像,并与残差网络整合,这种混合训练方式相比于仅使用有监督网络效果更好。迁移学习是将在其他训练集上预训练后的网络权重迁移至目标数据集继续训练,从而降低训练效果对样本数量的依赖。O'Leary 等^[8]将使用 SEM 图像数据预训练后的 CNN 模型冻结,解冻全连接层后输入 EDX

数据继续训练,实验结果表明迁移学习不仅能够加快训练速度,还能提高模型准确度。通过设计合理的网络结构同样可以减少训练效果对样本数量的需求,U-Net 网络结构^[9]是一个典型的多层对称式编码-解码结构,在不同层级的编码和解码过程中,样本图像的高维特征和低维特征不断融合交叉,使得数据能够被充分学习。连续多层编码容易丢失特征细节信息,导致 U-Net 网络对于细微缺陷分割效果不佳。同时,U-Net 网络仅使用了一层特征图作为输出,未能充分使用多尺度特征。

在 U-Net 网络的基础上,本文提出一种基于多尺度融合和残差分离卷积的改进 U-Net 缺陷分割算法。在模型的编码器端,将样本图像不断平均池化后的多尺度特征作为不同层级的额外输入,对上一层的输出结果形成补充,从而提高模型对多尺度缺陷特征的感知能力,使缺陷分割更加准确。同时,使用残差分离卷积模块代替常规卷积模块,以便在不增加计算量的情况下获得更大范围的感受野,使模型不遗漏面积较小的缺陷,增强模型对较小缺陷区域分割的准确程度。在模型的解码器端,将多尺度的输出图像放大到相同尺度并融合作为最终输出,实现特征信息语义和位置的信息互补,从而提高网络的分割精度。我们在 KolektorSDD 和 Crack500 数据集上进行了实验,并与其他语义分割网络进行比较。

1 相关工作

图像语义分割是计算机视觉领域中的一个经典任务,其目的是确定图像中每个点所属的类别。在图像语义分割中,既要对物体进行分类,又要确定其在图像中的具体位置,并准确地分割出不同物体之间的边界。电子换向器的表面缺陷分割是语义分割在工业检测方向的具体应用。

在机器学习兴起之前,图像语义分割大多是根据图像像素本身具有的低级特征执行分割任务,主要根据图像的纹理、颜色、空间结构等特征,通过设置阈值等方式将图像划分为不同的区域。黄林江^[10]提出了一种基于局部阈值的稳定区域分割方法,能够分割出完整的电子换向器柱面缺陷。

相较于传统方法,机器学习为语义分割提供了容易泛化的解决方案,这类算法可以利用学习到的高级特征进行分割,从而能够更好地应对复杂场景的分割任务。郝雪桐^[11]基于马尔可夫随机场模型将电子换

向器缺陷分割问题转化为能量函数最小化的优化问题, 并结合聚类方法提取特定的缺陷区域实现分割。基于深度学习的卷积神经网络还可以通过端到端的训练方式学习到更具鲁棒性的特征表示, 从而提高分割的准确性。Božič 等^[12]通过混合监督方法对电子换向器图像缺陷进行分割, 以图像级标签为基础, 逐步

添加像素级标签, 从而提升模型效果。

2 电子换向器表面缺陷分割方法

基于多尺度和残差分离卷积改进的 U-Net 网络模型结构如图 1 所示。

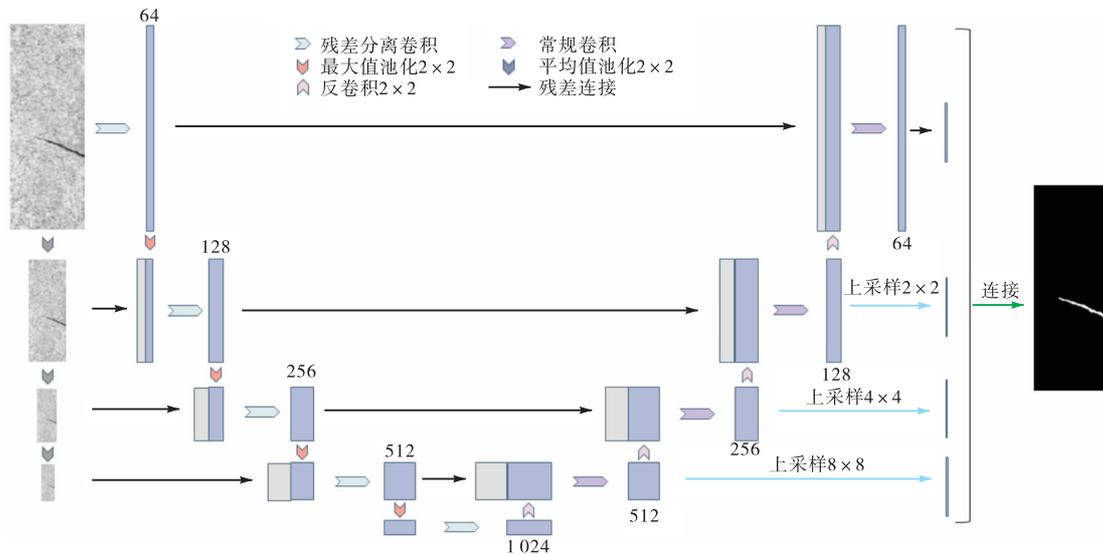


图 1 改进的 U-Net 网络模型结构

Fig. 1 Structure of improved U-Net network

为了进一步提升电子换向器的缺陷分割效果, 本文对 U-Net 增加了以下 3 个方面的设计:

(1) 在编码模块中添加多尺度的特征输入, 使网络能够提取更泛化的缺陷特征, 相较标准 U-Net 结构而言, 增强了模型的特征提取能力。

(2) 在编码模块使用残差分离卷积扩大网络的感受野范围, 避免在下采样中损失大量边缘细节特征信息, 同时能够减少网络的参数量。

(3) 在解码模块中将多层次不同尺度的输出进行融合, 分别放大到同一尺度并叠加作为最终输出, 这使得定位缺陷位置更加准确, 增强了对缺陷分割的准确度。

2.1 多尺度图像特征输入

电子换向器的缺陷形状大小不一, 缺陷面积存在明显差异。在多次卷积后, 微小的缺陷信息容易丢失, 可以通过引入不同尺度的输入图像, 利用空间冗余信息弥补卷积操作带来的损失。使用 3 次连续平均池化将原始图像大小减半, 操作后的图像尺度依次递减, 然后将对应尺度的图像分别注入编码端的不同卷积模块, 与前一层输出叠加作为本层输入。经过 5 个不同层级的残差分离卷积模块处理, 获得多尺度的

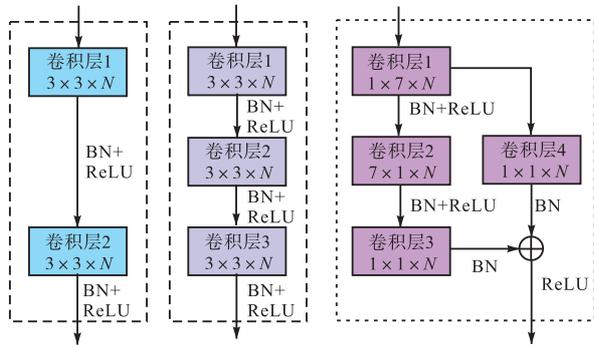
语义特征, 并通过最大值池化作为本层输出。

2.2 残差分离卷积

缺陷区域所占的像素范围可能很小, 非常容易随着卷积层和下采样层的操作逐渐减少甚至消失, 导致分割精度不高。本文基于残差思想^[13], 通过短残差连接将底层边缘特征充分利用, 可以降低卷积过程中引入的边缘噪声干扰, 进而获取更高精度的高层语义信息。为了获得更好的语义分割效果, 神经网络的层数在不断增加, 过度追求网络深度容易导致梯度消失, 使分割效果不升反降。感受野的大小和卷积核尺寸成正比, 采用更大的卷积核能够更加全面地发掘缺陷特征, 提高分割效果, 但是计算量会大幅增加^[14]。基于空间可分离卷积^[15]的思想, 本文将 1 层感受野大小为 7×7 的卷积核进行空间分离, 调整成大小分别为 1×7 和 7×1 的 2 层卷积核, 与标准 U-Net 的 2 层 3×3 卷积核相比, 感受野范围更大; 与感受野大小相同的 3 层 3×3 传统卷积相比, 计算量更小, 如图 2 所示。

图 2 中, N 为卷积核通道数。标准 U-Net 卷积模块的总参数量为 $9N^2 + 2N$, 传统卷积模块的总参数量为 $13.5N^2 + 3N$, 残差分离卷积模块的总参数量为

$8N^2 + 4N$; 残差分离卷积模块的总参数量最小,能够在计算量更小的情况下获得更大的感受野,使特征提取更加准确。



(a) U-Net 卷积模块 (b) 传统卷积模块 (c) 残差分离卷积模块

图2 U-Net 卷积、传统卷积和残差分离卷积模块结构

Fig. 2 Structures of U-Net convolution, traditional convolution and residual separable convolution

2.3 多尺度特征融合输出

在标准 U-Net 网络中,通常仅使用最后一个卷积层的特征,此方式未充分利用较高层语义信息。本文基于特征金字塔思想^[16],将解码端每次反卷积操作后的特征图尺寸调整至与最终输出图像相同,从而可以将多幅不同层级的特征图进行叠加。对解码端不同层级输出的特征图像使用不同倍率的上采样操作,操作后获得的图像尺度相同。将不同特征图同一位置的像素值累加,作为最终该位置的像素值,进而实现多尺度特征在输出图像的融合。此举能够有效地将缺陷位置信息和边缘信息联系起来,在完整检出缺陷范围的同时,保留精细的缺陷边缘特征。

2.4 损失函数

在分类问题中通常使用交叉熵损失函数量化标签图像和输出图像之间的差别,语义分割网络的目的是实现像素级别分类,衡量模型表现的指标是标签图像和输出图像对应位置像素值的差值。不同损失函数关注的属性并不一致,导致训练出的模型分割效果存在很大差异,交叉熵损失函数在缺陷像素和背景像素数量不平衡的场景下表现不佳。当背景像素的成分占据主导地位时,网络模型会严重偏向背景,导致分割效果较差。

为了解决样本数据集中缺陷像素数量占比较小导致分割效果较差的难题,使模型能够更准确地识别小面积缺陷,本文使用 L_C (Combo loss) 损失函数^[17]作为模型训练的损失函数。该损失函数定义为

$$L_C = \alpha L_{WCE} - (1 - \alpha) L_{Dice} \quad (1)$$

式中: L_{WCE} 为加权交叉熵损失函数; L_{Dice} 为 Dice 损

失函数; α 为用于控制 Dice 损失函数对 L_C 损失函数贡献的因子, α 越大贡献越大,在文中 α 设置为 0.5 时训练效果最佳。

加权交叉熵损失函数和 Dice 损失函数分别为

$$L_{WCE} = -\frac{1}{N} \sum_{i=1}^N \beta (t_i \ln p_i + (1 - \beta) [(1 - t_i) \ln (1 - p_i)]) \quad (2)$$

$$L_{Dice} = \frac{2 \sum_{i=1}^N p_i t_i + S}{\sum_{i=1}^N p_i + \sum_{i=1}^N t_i + S} \quad (3)$$

式中: N 为图像中像素的总数量; t 为具体像素的标签信息; p 及 $1 - p$ 分别为缺陷和背景两类像素的样本信息; β 为调节参数,用于控制假阳性 (FP)/假阴性 (FN) 的惩罚程度,当 β 设置为小于 0.5 的值时,对 FP 的惩罚要大于对 FN 的,反之亦然,在文中 β 设置为 0.6。为防止除零问题的出现,使用加法平滑/拉普拉斯平滑 (additive/Laplace smoothing),将分母和分子都加上单位常数 S ,在文中 S 设置为 1。

3 实验结果与分析

3.1 实验设置

3.1.1 数据集

本文采用的数据集为公开的电子换向器缺陷图像数据集 KolektorSDD 和道路缺陷图像数据集 Crack500。KolektorSDD 数据集中包括 52 张缺陷图像和 347 张无缺陷图像,合计 399 张图像。部分图像的分辨率大小与其他图像不同,需要统一调整为 512 像素 \times 1408 像素。为了达到更好的训练效果,本文采取了一些数据增强方法,例如对样本进行角度旋转、水平翻转等,最终获得含有 800 张图像的数据集。在该数据集中按照 4 : 1 的比例划分训练集和测试集。Crack500 数据集是自然拍摄的道路缺陷的彩色图像,道路环境更加复杂多样,并且道路缺陷更加显著,每张图像的大小为 3264 像素 \times 2448 像素,总共有 516 张图像。由于照片拍摄质量参差不齐,所以剔除了部分质量不佳的样本,并将原始图像尺寸压缩至 2560 像素 \times 1440 像素。剩余样本 476 张,其中 381 张为训练集,剩余 95 张为测试集。

3.1.2 实验设置及训练策略

实验环境是基于 Ubuntu 18.04 操作系统,使用的硬件环境为 AMD Ryzen 7 5800H 处理器、NVIDIA GeForce GTX 3060 12 GB 显卡、16 GB 内存,软件环境为 PyTorch 1.10 和 CUDA 11。训练过程中采

用 Adam 优化器, 学习率设置为 0.000 1, 批处理大小为 2。

3.1.3 评估指标

为了更好地衡量模型的分割性能, 采用相似性系数 (D)、精确率 (P)、召回率 (R) 作为模型的评估指标, 具体计算公式为

$$D = \frac{2N_{TP}}{2N_{TP} + N_{FN} + N_{FP}} \times 100\% \quad (4)$$

$$P = \frac{N_{TP}}{N_{TP} + N_{FP}} \times 100\% \quad (5)$$

$$R = \frac{N_{TP}}{N_{TP} + N_{FN}} \times 100\% \quad (6)$$

式中: N_{TP} 为真实缺陷被预测为缺陷的图像数量, N_{FP} 为真实背景被预测为缺陷的图像数量, N_{FN} 为真实缺陷被预测为背景的图像数量。

3.2 实验结果

3.2.1 KolektorSDD 数据集测试结果

为了验证上述电子换向器缺陷分割方法的有效性, 统计标准 U-Net 网络和本文方法在实验数据集中相似性系数、精确率和召回率 3 个方面指标的数据, 结果见表 1。由表 1 可知, 本文方法的精确率及相似性系数分别达到 97.8% 和 97.3%, 相较于 U-Net 网络分别提高了 2.1% 和 2.3%。

3.2.2 消融实验

为了进一步研究本文模型对缺陷分割效果的提升程度, 对多尺度输入、残差分离卷积、多尺度融合和三者融合的情况进行相关实验。在标准 U-Net 网

络基础上逐步添加多尺度输入、残差分离卷积、多尺度融合模块, 结果见表 1。由表 1 可知: 多尺度输入和多尺度融合能够在召回率下降程度较小的情况下提升精确率, 提高模型分割缺陷的准确度; 残差分离卷积能够有效保存图像细节信息, 全面提升模型整体性能。总之, 本文方法针对电子换向器图像提出的一系列措施均能提高缺陷分割性能。

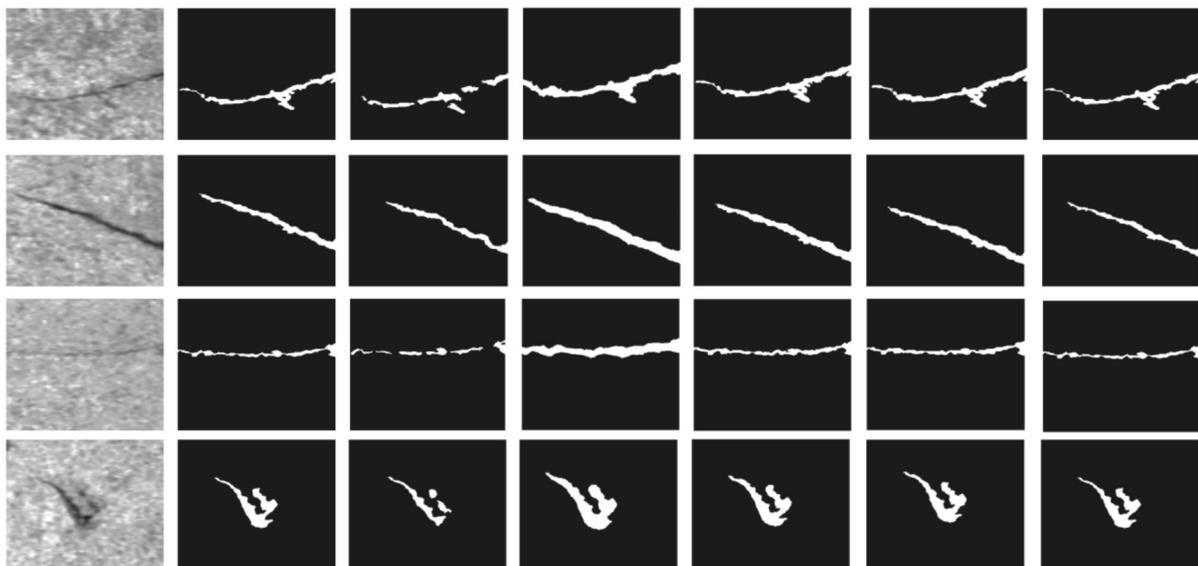
表 1 多种改进策略分割算法的比较

Tab. 1 Comparison of several improved strategy segmentation algorithms

方法	D/%	P/%	R/%
U-Net	95.0	95.7	94.6
U-Net + 多尺度输入	95.8	96.3	93.4
U-Net + 多尺度输入 + 残差分离卷积	96.4	96.8	95.3
U-Net + 多尺度输入 + 残差分离卷积 + 多尺度融合(本文方法)	97.3	97.8	94.8

3.2.3 不同网络训练结果对比

经典图像分割方法主要有 SegNet、FCN-8S、DeepLab V3 和 U-Net 等, 为了进一步体现本文方法的优势, 将本文方法与上述 4 种方法在实验数据集上进行对比, 不同方法的部分缺陷分割效果如图 3 所示。在经典图像分割方法中同样存在多尺度融合思想, 例如在 SegNet 中仅仅使用解码端最后一层的特征图像进行语义分割, 而在 FCN-8S 中基于跳跃连接结构将解码端末级 3 层特征融合后进行图像分割。在扩大感受野的方式上, DeepLab V3 使用了空洞卷积核代替传统卷积核。



(a) 测试图像 (b) 测试标签 (c) SegNet (d) FCN-8S (e) DeepLab V3 (f) U-Net (g) 本文方法

图 3 不同方法的部分缺陷分割效果图

Fig. 3 Partial effect images of defect segmentation with different methods

不同方法的缺陷分割指标结果见表 2。对比各项指标及可视化结果可以发现,分割效果较差的是 SegNet 和 FCN-8S,丢失了较多缺陷边缘特征信息;DeepLab V3 的缺陷分割效果稍好,而 U-Net 的缺陷分割效果更加接近标签图像,两者均能够区分出比较清晰的缺陷区域;本文方法的缺陷分割效果最佳,能分辨出极为精细的缺陷边缘。

表 2 不同方法的缺陷分割指标结果

Tab. 2 Defect segmentation results of different methods

方法	D/%	P/%	R/%
SegNet	81.5	82.4	85.3
FCN-8S	92.3	92.7	95.2
DeepLab V3	95.7	96.0	93.4
U-Net	95.0	95.7	94.6
本文方法	97.3	97.8	94.8

本文在标准 U-Net 网络模型的基础上,引入多种改进举措,有效地提升了对含有小范围缺陷区域图像的分割性能,在电子换向器数据集上表现效果相较于其他图像分割方法更加优秀。

3.2.4 Crack500 数据集上的实验结果及分析

为了验证本文所提出的缺陷分割算法的泛化性与鲁棒性,在 Crack500 数据集上对本文算法模型进行检验。在保持实验环境和模型参数设置不变的情况下,借助迁移学习将 KolektorSDD 数据集上训练好的参数模型作为初始化模型,在 Crack500 数据集上继续训练,对预训练模型参数进行微调。计算并统计本文算法以及其他经典分割网络在 Crack500 数据集上的相似性系数、精确率和召回率,实验结果见表 3。

表 3 Crack500数据集上不同网络的评价指标

Tab. 3 Evaluation metrics for different networks on Crack500 dataset

方法	D/%	P/%	R/%
SegNet	62.0	65.9	58.5
FCN-8S	64.4	70.4	59.3
DeepLab V3	67.3	71.1	64.9
U-Net	68.6	71.5	65.9
本文方法	70.0	75.4	64.1

由表 3 可以看出,本文提出的缺陷分割算法在 Crack500 数据集上仍然取得了较好的效果,相似性系数及精确率均优于 SegNet、FCN-8S、DeepLab V3 和 U-Net 分割算法,召回率略低于 DeepLab V3 和 U-Net。虽然 DeepLab V3 模型在召回率上的表现优于本文方法,但其网络参数量更加庞大,对数据依赖性更强,对数据集的要求更高。本文方法引入残差分离

卷积,在扩大了感受野的同时减少了计算量,网络参数相对较少。实验结果显示,本文方法并不局限于分割电子换向器的细小缺陷,在不同的数据集上同样表现优异,具有较好的泛化性与鲁棒性。

4 结 语

针对电子换向器缺陷形状各异、缺陷与背景差异较小导致电子换向器缺陷难以精细分割的问题,本文基于改进 U-Net 提出一种电子换向器缺陷分割方法。在编码器端输入多尺度图像,便于网络模型提取多尺度缺陷特征信息。构建残差分离卷积模块,在增大感受野的同时保留细节特征。在解码器端融合多尺度的输出图像,实现缺陷特征语义和位置的信息互补,从而提高网络对图像分类的准确度。在 KolektorSDD 数据集上的分割实验结果表明,相较于基础 U-Net 网络模型,本文方法在相似性系数和精确率评价指标上分别提高了 2.3% 和 2.1%,对缺陷的分割效果与 SegNet、FCN-8S 等经典图像分割方法相比更加优秀,在 Crack500 数据集上仍然取得了较好的效果,具有较好的泛化性与鲁棒性。在后续的工作中,将进一步精简分割模型,减少网络参数量,从而提升该方法的实时性。

参考文献:

- [1] 张凤阁,杜光辉,王天煜,等. 高速电机发展与设计综述[J]. 电工技术学报,2016,31(7):1-18.
- [2] HUANG Z, FU H L, CHEN W, et al. Damage detection and quantitative analysis of shield tunnel structure[J]. Automation in construction, 2018, 94: 303-316.
- [3] 陶显,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.
- [4] HE D, XU K, ZHOU P, et al. Surface defect classification of steels with a new semi-supervised learning method[J]. Optics and lasers in engineering, 2019, 117: 40-48.
- [5] 黄凤荣,李杨,郭兰申,等. 基于 Faster R-CNN 的零件表面缺陷检测算法[J]. 计算机辅助设计与图形学学报,2020,32(6):883-893.
- [6] HUANG H W, LI Q T, ZHANG D M. Deep learning based image recognition for crack and leakage defects of metro shield tunnel[J]. Tunnelling and underground space technology, 2018, 77: 166-176.
- [7] HE Y, SONG K C, DONG H W, et al. Semi-supervised defect classification of steel surface based on multi-

- training and generative adversarial network[J]. *Optics and lasers in engineering*, 2019, 122: 294–302.
- [8] O'LEARY J, SAWLANI K, MESBAH A. Deep learning for classification of the chemical composition of particle defects on semiconductor wafers[J]. *IEEE Transactions on semiconductor manufacturing*, 2020, 33(1): 72–85.
- [9] 郝华颖, 赵昆, 苏攀, 等. 一种基于改进 ResU-Net 的角膜神经分割算法[J]. *计算机工程*, 2021, 47(1): 217–223.
- [10] 黄林江. 面向产品在线质检的图像拼接与柱面缺陷检测方法研究[D]. 武汉: 华中科技大学, 2017.
- [11] 郝雪桐. 基于机器视觉的换向器柱面缺陷在线检测方法研究[D]. 武汉: 华中科技大学, 2019.
- [12] BOŽIČ J, TABERNIK D, SKOČAJ D. Mixed supervision for surface-defect detection: from weakly to fully supervised learning[J]. *Computers in industry*, 2021, 129: 103459.
- [13] ARSALAN M, KIM D S, LEE M B, et al. FRED-Net: fully residual encoder-decoder network for accurate iris segmentation[J]. *Expert systems with applications*, 2019, 122: 217–241.
- [14] WU Z F, SHEN C H, VAN DEN HENGEL A. Wider or deeper: revisiting the resnet model for visual recognition[J]. *Pattern recognition*, 2019, 90: 119–133.
- [15] GHOLAMI A, KWON K, WU B C, et al. SqueezeNext: hardware-aware neural network design[EB/OL]. (2018–08–27) [2023–01–03]. <https://arxiv.org/pdf/1803.10615v2.pdf>.
- [16] LIN T Y, DOLLÁR P, GIRSHICK R, et al. Feature pyramid networks for object detection[EB/OL]. (2017–04–19) [2023–01–03]. <https://arxiv.org/pdf/1612.03144v2.pdf>.
- [17] TAGHANAKI S A, ZHENG Y F, ZHOU S K, et al. Combo loss: handling input and output imbalance in multi-organ segmentation[J]. *Computerized medical imaging and graphics*, 2019, 75: 24–33.

责任编辑: 周建军

(上接第 15 页)

- hydrolysis/ultrasound[J]. *Fibers and polymers*, 2015, 16(3): 529–536.
- [15] LI J, SONG Z, LI D, et al. Cotton cellulose nanofiber-reinforced high density polyethylene composites prepared with two different pretreatment methods[J]. *Industrial crops and products*, 2014, 59: 318–328.
- [16] RHIM J W, PARK H M, HA C S. Bio-nanocomposites for food packaging applications[J]. *Progress in polymer science*, 2013, 38(10/11): 1629–1652.
- [17] THEIVASANTHI T, CHRISTMA F L A, TOYIN A J, et al. Synthesis and characterization of cotton fiber-based nanocellulose[J]. *International journal of biological macromolecules*, 2018, 109: 832–836.
- [18] DE CARVALHO BENINI K C C, VOORWALD H J C, CIOFFI M O H, et al. Preparation of nanocellulose from *Imperata brasiliensis* grass using Taguchi method[J]. *Carbohydrate polymers scientific & technological aspects of industrially important polysaccharides*, 2018, 192: 337–346.
- [19] REDDY K O, MAHESWARI C U, REDDY D J P, et al. Properties of lignocellulose ficus religiosa leaf fiber[J]. *CSIR Research space*, 2010, 2(1): 29–35.
- [20] PING L, HSIEH Y L. Preparation and properties of cellulose nanocrystals: rods, spheres, and network[J]. *Carbohydrate polymers*, 2010, 82(2): 329–336.
- [21] DAI Z, XU X, GU Y, et al. Experimental and theoretical study on terahertz spectra for regenerated cellulose[J]. *Spectroscopy and spectral analysis*, 2017, 37(3): 697–703.
- [22] 周佳豪, 熊熊, 刘成国, 等. 纳米纤维素添加量及干燥温度对海藻酸钠可食用膜性能的影响[J]. *食品研究与开发*, 2020, 41(20): 45–50.
- [23] LAWRIE G, KEEN I, DREW B, et al. Interactions between alginate and chitosan biopolymers characterized using FTIR and XPS[J]. *Biomacromolecules*, 2007, 8(8): 2533–2541.
- [24] PRATEEPCHANACHAI S, THAKHIEW W, DEVAHASTIN S, et al. Mechanical properties improvement of chitosan films via the use of plasticizer, charge modifying agent and film solution homogenization[J]. *Carbohydrate polymers*, 2017, 174: 253–261.
- [25] HABIBI Y, LUCIA L A, ROJAS O J. Cellulose nanocrystals: chemistry, self-assembly, and applications[J]. *Chemical reviews*, 2010, 110(6): 3479–3500.
- [26] KHAN A, KHAN R A, SALMIERI S, et al. Mechanical and barrier properties of nanocrystalline cellulose reinforced chitosan based nanocomposite films[J]. *Carbohydrate polymers*, 2012, 90(4): 1601–1608.

责任编辑: 郎婧