

基于改进 U-net 的金属工件表面缺陷分割方法

王一, 龚肖杰*, 程佳

华北理工大学电气工程学院, 河北 唐山 063210

摘要 针对金属工件表面缺陷分割精度低的问题, 通过对工件表面图像缺陷特征研究, 提出以 U-net 为基础, 结合多尺度自适应形态特征提取模块及瓶颈注意力模块的工件表面缺陷分割模型。首先, 在网络中嵌入多特征注意力有效聚合模块, 提高信息的利用率, 提取更多相关特征, 从而高精度地提取缺陷目标。然后, 在网络中引入瓶颈注意力模块, 增加缺陷目标的权重, 优化特征的提取, 获取更多的特征信息, 从而获得更好的分割精度。改进后的网络平均精度达到 0.8749, 比原网络相比提高了 2.92%, 平均交并比达到 0.8625, 提高了 3.72%。与原始网络相比, 改进后的网络具有更好分割的精度, 可以获得更好的分割结果。

关键词 表面光学; 表面缺陷; 图像分割; U-net 网络; 多特征注意力有效聚合模块; 瓶颈注意力模块

中图分类号 TP391

文献标志码 A

DOI: 10.3788/LOP221756

Metal Workpiece Surface Defect Segmentation Method Based on Improved U-Net

Wang Yi, Gong Xiaojie*, Cheng Jia

College of Electrical Engineering, North China University of Science and Technology,
Tangshan 063210, Hebei, China

Abstract To solve the problem of low segmentation accuracy of metal workpiece surface defects, we propose a workpiece surface defect segmentation model based on a U-net network combined with a multi-scale adaptive-pattern feature extraction and bottleneck attention module. First, we embed a multi-feature attention aggregation module in the network to improve the utilization of information and extract more relevant features, so as to extract defect targets with high accuracy. Then, the bottleneck attention modules are introduced into the network to increase the weight of defect targets, optimize the extraction of features, and obtain more feature information, thus obtaining better segmentation accuracy. The improved network mean pixel accuracy reaches 0.8749, which is 2.92% higher than the original network. The mean intersection over union reaches 0.8625, an increase of 3.72%. Compared to the original network, the improved network has better segmentation accuracy and segmentation results.

Key words optics at surfaces; surface defect; image segmentation; U-net network; multi-scale adaptive-pattern feature extraction; bottleneck attention module

1 引言

金属工件在生产过程中容易受生产工艺、环境、人为因素的影响, 产生表面性缺陷, 工件表面的缺陷不仅会影响产品的美观及使用寿命, 还会导致重大安全事故, 因此对金属工件表面缺陷检测至关重要。

传统方法效率低, 漏检率高, 不适用于金属工件的缺陷检测。语义分割网络解决了传统方法对缺陷特征

提取的问题, 广泛应用在缺陷检测领域。Tabernik 等^[1]提出基于分割的深度学习结构, 使用双分支网络对缺陷图像进行检测与分割, 但是输出图像分辨率大大降低, 尺寸较小的缺陷信息容易丢失。Hu 等^[2]提出基于生成对抗网络的检测缺陷的方法, 该方法引入新的编码器, 可以在保持正常纹理的情况下重建图像。Liu 等^[3]提出了基于 U-net 和 Res_U-net 网络的图像分割方法, 该方法首先对图像进行预处理, 再利用 U-

收稿日期: 2022-06-02; 修回日期: 2022-07-05; 录用日期: 2022-07-26; 网络首发日期: 2022-08-06

基金项目: 河北省高等学校科学技术研究项目 (ZD2022114)、唐山市科技计划项目 (21130212C)

通信作者: *1692994031@qq.com

net 网络提取目标轮廓,然后利用 Res_U-net 网络进行轮廓优化,最后使用 OpenCV 获取分割结果,该方法与传统图像处理方法相比,轮廓检测和优化方法更准确。刘佳伟等^[4]提出基于改进 U-Net 网络的结肠息肉图像分割方法,改进的双 U 型结构有效地提高了图像的分割精度。张恒良等^[5]提出基于改进的 3D-Unet 网络脑肿瘤图像分割方法,该方法显著地提高了小目标的分割精度。Xiao 等^[6]提出具有多尺度特征提取能力的 3D-Res2Net 分层连接网络,该方法不仅解决了梯度爆炸和消失的问题,而且提高了肺结节检测和分割的精度及模型的训练速度。

上述的分割网络需要大量的数据集,当缺陷数量较少时,难以达到较好的分割效果,为解决这一难题,小样本学习应运而生。小样本分割利用少量样本图像指导测试图像的分割过程,获得较好的分割效果。许国良等^[7]提出基于协同注意力的分割网络实现小样本手机屏幕缺陷的分割。该方法引入交叉注意力与协同注意力增强特征信息的提取效果,并采用改进的联合损失函数训练网络,获得了较好的缺陷分割结果。赵凤等^[8]提出一种基于注意力的多尺度 U 型分割模型,实现了眼底血管的精确分割。Zhang 等^[9]提出相似度引导网络解决分割问题,该方法采用掩模平均池化

策略获取代表性特征,并利用余弦相似度建立引导特征与查询特征间的关系,指导查询集的分割。董阳等^[10]提出基于 U-net 的小样本分割方法,该方法通过调整网络结构、融合图像特征,并采用交叉熵损失函数,获得了较好的分割效果。王俊杰等^[11]提出深度金字塔注意力网络实现小样本遥感图像分割,该方法采用迁移学习提取目标,利用注意力机制及特征融合方法增强模型对特征学习能力,提高了网络对遥感图像的分割精度。

针对金属工件表面缺陷,本文提出改进 U-net 网络实现缺陷目标的精确分割。网络采用编码器-解码器结构,在网络的编码侧引入 MAFE 模块,提取不同形状缺陷的尺度特征信息,在解码器过程嵌入瓶颈注意力模块,捕获语义信息,关注详细特征,以使语义分割网络获得更好的分割效果。

2 U-net 网络

U-net 网络是端到端的语义分割网络^[12],该网络的所需数据量少、分割精度高、速度快,被广泛应用在场景、医学语义分割等目标检测任务中。U-net 网络结构如图 1 所示。

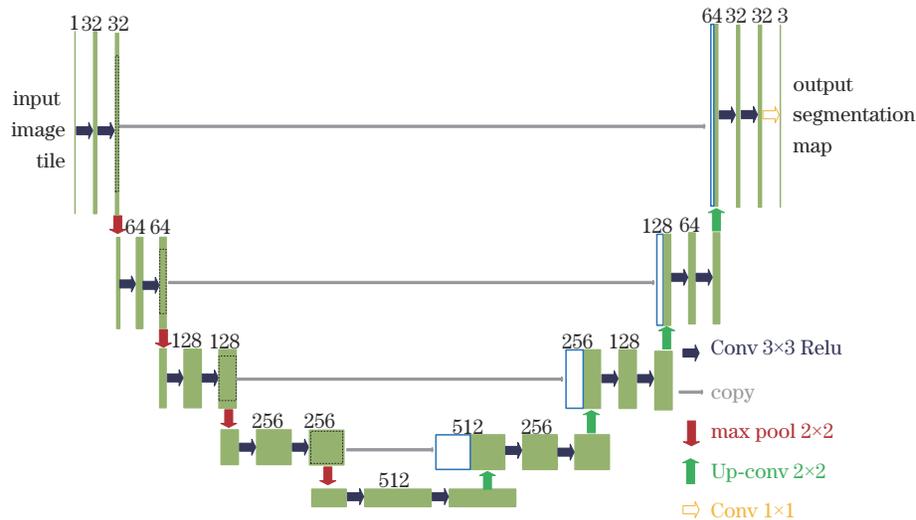


图 1 U-net 网络结构

Fig. 1 U-net network structure

U-net 网络可称为编码器-解码器结构,包括提取图像特征信息的下采样以及使分割图像恢复原图像大小的上采样两部分。编码过程包含 4 次下采样,分别为 3×3 的卷积、 2×2 的最大池化层及激活函数,每次完成下采样,网络的特征通道就会加倍。编码结束后,是包含 4 次上采样及特征图拼接的解码过程,即包括将图像扩大的转置卷积、将特征通道减半通过反卷积、相应层间特征提取部分的拼接、经过映射类别的 1×1 卷积。通过提取特征、恢复分辨率、融合不同特

征层的特征相互结合,网络具有较好的分割效果。

3 改进的 U-net 网络

改进的 U-net 模型结构如图 2 所示。编码过程和原网络经过类似的过程,即重复卷积、池化操作采集图像特征信息。但是在输入图像经过卷积模块后进行 MAFE 操作,为上采样特征图的融合做准备,在网络编码部分的卷积模块之后引入 MAFE 模块,在更大范围内获取更多的高级语义信息,同时避免了因感受野

过大导致细节遗漏的问题,提高网络分割的精度。在解码器部分每次特征图拼接之后嵌入瓶颈注意力模块 (BAM),获取更多的细节、纹理特征,提高对目标物体特征的提取能力。在解码过程,将反卷积之后的特征图与经过 MAFE 模块具有相同大小的特征图进行融

合,然后依次经过 BAM 模块、卷积模块。重复 4 次反卷积、融合、BAM、卷积过程后经过映射类别的 1×1 卷积,输出分割结果。在网络中嵌入 MAFE 模块与 BAM 模块,使网络获得更多的特征信息,从而使得网络精确地分割缺陷。

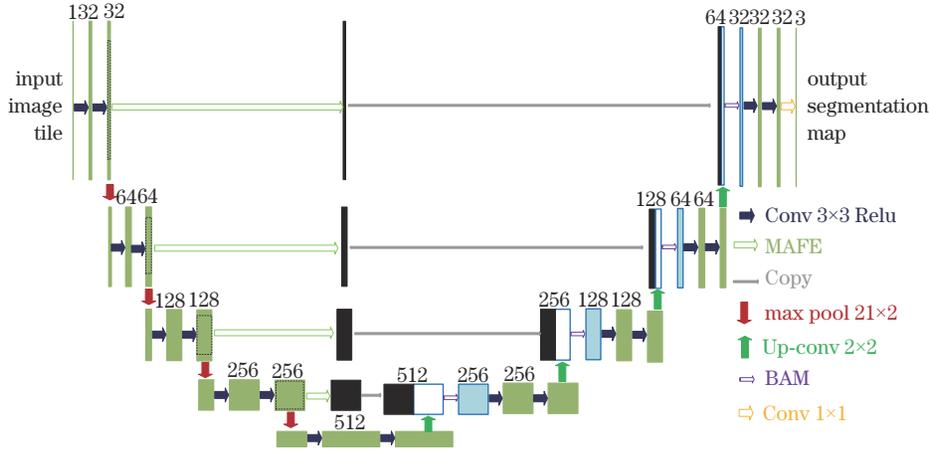


图 2 改进 U-net 网络结构

Fig. 2 Improved U-net network structure

3.1 多尺度自适应形态特征提取模块

MAFE 模块的提出是为了解决在分割任务中空洞空间金字塔池化 ASPP^[13]信息利用率较低导致局部特征丢失、不能很好适应不规则的缺陷特征的问题^[14]。MAFE 模块将 ASPP 中标准正方形的卷积核用可形变卷积核 (Def-Conv) 代替,并采用先级联后并行相加结构。可形变卷积^[15]可以捕获缺陷目标的形状特征,使卷积核自由形变。MAFE 结构如图 3 所示。

网络中引入 MAFE 模块能增大感受野,提高信息的利用率。MAFE 模块先后采用一个对输入特征降维的 1×1 卷积与 3 个加入 ReLU 函数的 3×3 可行变卷积核,增强网络非线性的处理能力,最后融合每层输出,增强模块对图像特征的学习能力。

卷积层叠加时,特征图的感受野也在扩大。单个像素对应的感受野计算公式为

$$F_{n-1} = s_n(r_{n-1} - 1) + k + (k - 1)(r - 1), \quad (1)$$

式中: F_{n-1} 为 $n - 1$ 层每个像素的感受野; r 为空洞率; s_n 为步长; k 为卷积核大小。

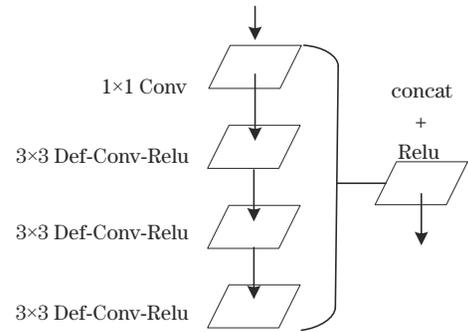


图 3 MAFE 结构

Fig. 3 MAFE structure

3.2 瓶颈注意力模块

瓶颈注意力模块^[16]能增强图像分割任务中的主要特征,抑制次要信息,整合位置与空间的特征信息,实现高效的特征提取,提高图像分割效果。结构如图 4 所示,输入特征图 F ,先经过混合注意力模块处理,得到特征图 $M(F)$,再将具有相同尺寸的特征图 F 与

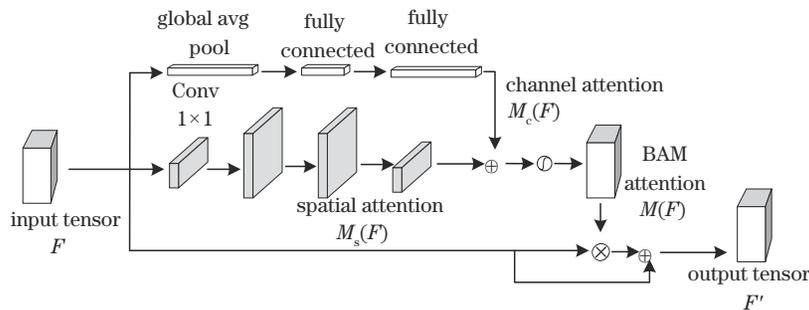


图 4 瓶颈注意力模块

Fig. 4 Bottleneck attention module

$M(F)$ 逐点相乘, 最后和 $M(F)$ 相加得到显著特征图 F' , 对重要的缺陷特征信息给予更多的注意力, 提高网络的分割精度。表达式为

$$F' = F + F \odot M(F), \quad (2)$$

$$M(F) = \sigma[M_c(F) + M_s(F)], \quad (3)$$

式中: F 为输入特征图; \odot 为逐点相乘; $M(F)$ 为经过 BAM 的注意力特征图; σ 为 sigmoid 函数; $M_c(F)$ 与 $M_s(F)$ 分别为不同通道经过处理的特征、不同空间位置经过处理的特征。

通道注意力模块能提取丰富的全局特征, 使得网络分割效果更好。输入特征图先经过全局平均池化处理, 得到通道矢量, 随后利用多层感知器 (MLP) 学习每个通道的估计, 最后通过批量正则化 (BN) 来调整其大小, 得到通道注意力特征图, 公式为

$$M_c(F) = \varphi_{bn} \left\{ \text{MLP} \left[\text{Avgpool}(F) \right] \right\}, \quad (4)$$

式中: φ_{bn} 为批量正则化; MLP 为含有隐含层的多层感知器; Avgpool 为全局平均池化; F 为输入特征图; $M_c(F)$ 为经过通道注意力后的特征图。

空间注意力模块采用空洞卷积扩大了感受野, 利用不同大小的卷积对通道的特征映射进行整合与压缩、捕捉上下文信息、降低特征图维度, 并且为了调整输出特征图的大小加入 BN, 最后输出空间注意力特征图, 公式为

$$M_s(F) = \varphi_{bn} \left\{ f_3^{1 \times 1} \left\{ f_2^{3 \times 3} \left\{ f_1^{3 \times 3} \left[f_0^{1 \times 1}(F) \right] \right\} \right\} \right\}, \quad (5)$$

式中: f_x^y 表示卷积操作, 下标表示步数, 上标表示卷积核大小; $M_s(F)$ 为经过通道注意力得到的特征图。

3.3 LovaszSoftmax 损失函数

在语义分割任务中往往采用交叉熵损失函数, 但当正负样本不平衡时, 存在模型性能不好的问题。采用 LovaszSoftmax 损失函数比交叉熵函数效果要好, 因而网络分割精度更好。LovaszSoftmax 损失函数是由重叠度 (IOU) 公式演变而来, 由指数损失和交叉熵函数组合而成。公式表示为

$$L_{\text{loss}}(f) = \frac{1}{C} \sum_{c \in C} \overline{\Delta J_c} [m(C)], \quad (6)$$



图 6 裁剪及填充示意图。(a) 缺陷图像; (b) 处理后图像

Fig. 6 Schematic diagram of cutting and filling. (a) Defect image; (b) image after processing

式中: $L_{\text{loss}}(f)$ 为所有类别损失; C 为类别个数; ΔJ_c 为模型训练时产生的损失值; $m(C)$ 为像素误差数。

4 实验与结果分析

以凸轮轴为实验对象, 通过搭建的图像采集视觉平台采集图像, 运用改进的算法实现凸轮轴表面缺陷的精确分割。

4.1 实验设置与数据集

图像采集系统如图 5 所示, 选用堡盟 VCXG-25.1 工业相机和 computar M1614-MP2 工业镜头, 以及两个条形 LED 光源。将光源放置在待检凸轮轴两侧, 并形成约 45° 的照明角度, 减少工件表面的强反光, 从而增加缺陷与背景的对比如。

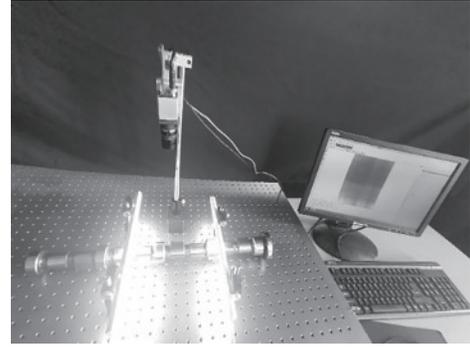


图 5 图像采集视觉平台

Fig. 5 Image acquisition visual platform

实验方法在 Intel(R) Core(TM) i5-1035G1 中央处理器、MX350 显卡硬件及 Anaconda4.10.1 版本的环境管理器、Python3.8 编程软件、深度学习框架 Pytorch 软件上实现。训练 epoch 设为 100, 学习率设置为 0.0001, 选用 Adam 训练网络。

通过图像视觉平台采集凸轮轴污渍、划痕及凹坑三种缺陷图像, 并分别用 bl、sc、sca 字母代表, 采集图像通过裁剪、翻转进行扩增, 得到 2287 张缺陷图像, 其中: 1782 张图像使用 labelme 软件进行标记用于模型训练; 505 张图像, 用于验证。数据增强后, 为保证图像不失真, 采用 letterbox 方式进行填充, 裁剪及填充如图 6 所示。

4.2 评价指标

选用平均交并比(mIOU)与均像素精度(mPA)作为评价语义分割任务的指标,mIOU是各类缺陷目标交并比的均值,mIOU值越大,目标分割精度越高,mPA是像素精度(PA)的提升,mPA是所有类别PA的均值。mIOU、mPA公式为

$$P_{mIOU} = \frac{1}{k+1} \frac{\sum_{i=1}^k p_{ii}}{\sum_{j=0}^k p_{ij} + \sum_{j=0}^k p_{ji} - p_{ii}}, \quad (7)$$

$$P_{mPA} = \frac{1}{k+1} \frac{\sum_{i=0}^k p_{ii}}{\sum_{j=0}^k p_{ij}}, \quad (8)$$

式中:k为缺陷类别数; p_{ij} 表示真实值为*i*、预测值为*j*的数量; p_{ii} 为真正的数量; p_{ij} 、 p_{ji} 分别为假正和假负。

4.3 实验结果与分析

在相同硬件和数据集条件下,分别将原U-net网络、在原网络中加入MAFE模块的U-net-MAFE网络、在原网络中加入BAM模块的U-net-BAM网络、在原网络中同时加入MAFE模块与BAM模块的U-net-MAFE-BAM网络进行训练。4个模型的损失值变化曲线图如图7所示,横纵坐标分别表示权值更新次数、损失值。各个模型在训练开始阶段,损失值下降较快,在迭代20后损失值下降缓慢,当epoch值为80时,损失值保持相对平稳,改进后模型整体收敛性较好,训练效果较理想。

各模型的实验数据对比如表1所示,从表中可以看出,U-net-MAFE网络、U-net-BAM网络与U-net-MAFE-BAM网络的mPA与mIOU均高于原始U-net网络的mPA,改进后的U-net-MAFE-BAM网络mPA与mIOU最高分别达到0.8749和0.8625。改进后的YOLOv5-G-SP-SE网络能够提取到更多关键信息,具

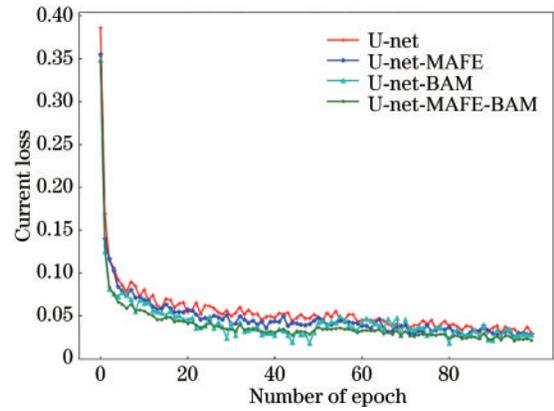


图7 损失值变化曲线图

Fig. 7 Change curves of loss value

有更好的分割精度,能更精确地分割出凸轮轴表面的缺陷,并且改进措施不会大量增加实验的测试时间,具有较好的计算效率。

表1 实验网络数据对比

Table 1 Data comparison in the experimental network

Number	Approach	mPA	mIOU	Test time /s
1	U-net	0.8457	0.8253	0.156
2	U-net-MAFE	0.8537	0.8365	0.158
3	U-net-BAM	0.8583	0.8436	0.161
4	U-net-MAFE-BAM	0.8749	0.8625	0.165

几种模型分割效果对比图如图8所示,其中图8(b)是由标注软件标、计算机自动分割的标签图像。可以看出,用U-net分割的图像,缺陷目标边缘分割得不准确,被分割部位的边缘不光滑,比较粗糙,U-

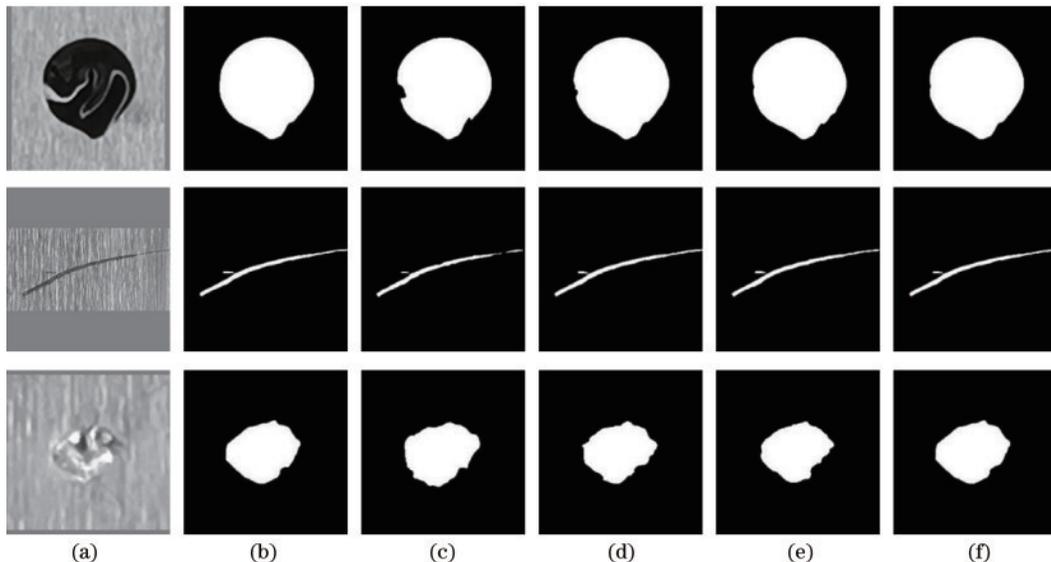


图8 分割效果对比图。(a)原图;(b)标签;(c)U-net分割效果;(d)U-net-MAFE分割效果;(e)U-net-BAM分割效果;(f)U-net-MAFE-BAM分割效果

Fig. 8 Comparison of the segmentation effects. (a) Original images; (b) label; (c) U-net segmentation effect; (d) U-net-MAFE segmentation effect; (e) U-net-BAM segmentation effect; (f) U-net-MAFE-BAM segmentation effect

net-MAFE 网络与 U-net-BAM 网络分割效果有所改善,改进后的 U-net-MAFE-BAM 网络分割的图像,分割的边缘最为光滑,分割的准确性有较大提升。

5 结 论

为解决金属工件表面缺陷分割精度低、容易误检的问题,本文提出了改进的 U-net 网络分割工件表面图像缺陷。在网络中引入多尺度自适应形态特征提取模块及瓶颈注意力模块,增强了模型的特征提取能力,保留更多有用的特征信息,降低误检的概率,提高缺陷分割的精度。实验结果表明,改进后的 U-net-MAFE-BAM 网络在分割任务中比原网络具有更高的精度,能更准确地分割出金属工件表面的缺陷,分割效果较好。

参 考 文 献

- [1] 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.
- [2] Hu G H, Huang J F, Wang Q H, et al. Unsupervised fabric defect detection based on a deep convolutional generative adversarial network[J]. *Textile Research Journal*, 2019, 90(3/4): 247-270.
- [3] Liu X B, Zhang Y W. Ore Image Segmentation method of conveyor belt based on U-net and Res_UNet models [J]. *Journal of Northeastern University (Natural Science)*, 2019, 40(11): 1623-1629.
- [4] 刘佳伟, 刘巧红, 李晓欧, 等. 一种改进的双 U 型网络的结肠息肉分割方法[J]. *光学学报*, 2021, 41(18): 1810001.
Liu J W, Liu Q H, Li X O, et al. Improved colonic polyp segmentation method based on double U-shaped network[J]. *Acta Optica Sinica*, 2021, 41(18): 1810001.
- [5] 张恒良, 李镛, 关欣. 一种改进的三维双路径脑肿瘤图像分割网络[J]. *光学学报*, 2021, 41(3): 0310002.
Zhang H L, Li Q, Guan X. An improved three-dimensional dual-path brain tumor image segmentation network[J]. *Acta Optica Sinica*, 2021, 41(3): 0310002.
- [6] Xiao Z T, Liu B W, Geng L, et al. Segmentation of lung nodules using improved 3D-UNet neural network[J]. *Symmetry*, 2020, 12(11): 1787.
- [7] 许国良, 毛骄. 基于协同注意力的小样本的手机屏幕缺陷分割[J]. *电子与信息学报*, 2022, 44(4): 1476-1483.
Xu G L, Mao J. Few-shot segmentation on mobile phone screen defect based on co-attention[J]. *Journal of Electronics & Information Technology*, 2022, 44(4): 1476-1483.
- [8] 赵凤, 钟蓓蓓, 刘汉强. 基于注意力机制的多尺度残差 U-Net 眼底血管分割[J]. *激光与光电子学进展*, 2022, 59(18): 1810002.
Zhao F, Zhong B B, Liu H Q. Multi-scale residual U-Net fundus blood vessel segmentation based on attention mechanism[J]. *Laser & Optoelectronics Progress*, 2022, 59(18): 1810002.
- [9] Zhang X L, Wei Y C, Yang Y, et al. SG-one: similarity guidance network for one-shot semantic segmentation[J]. *IEEE Transactions on Cybernetics*, 2020, 50(9): 3855-3865.
- [10] 董阳, 潘海为, 崔倩娜, 等. 面向多模态磁共振脑瘤图像的小样本分割方法[J]. *计算机应用*, 2021, 41(4): 1049-1054.
Dong Y, Pan H W, Cui Q N, et al. Few-shot segmentation method for multi-modal magnetic resonance images of brain tumor[J]. *Journal of Computer Applications*, 2021, 41(4): 1049-1054.
- [11] 王俊杰, 张军航. 基于多尺度特征融合的小样本遥感图像分割[J]. *华中科技大学学报(自然科学版)*, 2022, 50(3): 62-67.
Wang J J, Zhang J H. Small sample remote sensing image segmentation based on multiscale feature fusion[J]. *Journal of Huazhong University of Science and Technology (Natural Science Edition)*, 2022, 50(3): 62-67.
- [12] Khan R A, Luo Y G, Wu F X. RMS-UNet: residual multi-scale UNet for liver and lesion segmentation[J]. *Artificial Intelligence in Medicine*, 2022, 124: 102231.
- [13] Yin S C, Deng H M, Xu Z L, et al. SD-UNet: a novel segmentation framework for CT images of lung infections [J]. *Electronics*, 2022, 11(1): 130.
- [14] 杨志秀, 韩建宁, 于本知, 等. 一种改进的 DeepLab V³⁺ 的医学图像分割方法[J]. *国外电子测量技术*, 2021, 40(9): 18-23.
Yang Z X, Han J N, Yu B Z, et al. Improved medical image segmentation method based on DeepLab V³⁺ [J]. *Foreign Electronic Measurement Technology*, 2021, 40(9): 18-23.
- [15] Dai J F, Qi H Z, Xiong Y W, et al. Deformable convolutional networks[C]//2017 IEEE International Conference on Computer Vision, October 22-29, 2017, Venice, Italy. New York: IEEE Press, 2017: 764-773.
- [16] 赵琰, 赵凌君, 匡纲要. 基于注意力机制特征融合网络的 SAR 图像飞机目标快速检测[J]. *电子学报*, 2021, 49(9): 1665-1674.
Zhao Y, Zhao L J, Kuang G Y. Attention feature fusion network for rapid aircraft detection in SAR images[J]. *Acta Electronica Sinica*, 2021, 49(9): 1665-1674.