

基于改进U²-Net网络的金属涂层剥落与腐蚀图像分割方法

倪云峰 齐蜻蜓 朱代先 秋强 刘树林

Image segmentation method for metal coating peeling and corrosion based on improved U²-Net network

NI Yunfeng, QI Qingting, ZHU Daixian, QIU Qiang, LIU Shulin

引用本文:

倪云峰, 齐蜻蜓, 朱代先, 等. 基于改进U²-Net网络的金属涂层剥落与腐蚀图像分割方法[J]. 应用光学, 2024, 45(4): 759–767. DOI: 10.5768/JAO202445.0402005
NI Yunfeng, QI Qingting, ZHU Daixian, et al. Image segmentation method for metal coating peeling and corrosion based on improved U²-Net network[J]. Journal of Applied Optics, 2024, 45(4): 759–767. DOI: 10.5768/JAO202445.0402005

在线阅读 View online: <https://doi.org/10.5768/JAO202445.0402005>

您可能感兴趣的其他文章

Articles you may be interested in

基于改进U-net的金属工件表面缺陷图像分割方法

Image segmentation method of surface defects for metal workpieces based on improved U-net
应用光学. 2023, 44(1): 86–92 <https://doi.org/10.5768/JAO202344.0102004>

基于改进Fast-SCNN的裂缝图像实时分割算法

Real-time segmentation algorithm of crack images based on improved Fast-SCNN
应用光学. 2023, 44(3): 539–547 <https://doi.org/10.5768/JAO202344.0302001>

基于改进BiSeNet的非结构化道路分割算法研究

Unstructured road segmentation algorithm based on improved BiSeNet
应用光学. 2023, 44(3): 556–564 <https://doi.org/10.5768/JAO202344.0302003>

基于改进DeepLabv3+的无人车夜间红外图像语义分割

Semantic segmentation of nocturnal infrared images of unmanned vehicles based on improved DeepLabv3+
应用光学. 2020, 41(1): 180–185 <https://doi.org/10.5768/JAO202041.0106002>

基于多尺度残差注意力网络的水下图像增强

Underwater image enhancement based on multiscale residual attention networks
应用光学. 2024, 45(1): 89–98 <https://doi.org/10.5768/JAO202445.0102003>

基于深度学习的铸件X射线图像分割研究

Casting X-ray image segmentation based on deep learning
应用光学. 2021, 42(6): 1025–1033 <https://doi.org/10.5768/JAO202142.0602003>



关注微信公众号, 获得更多资讯信息

文章编号: 1002-2082 (2024) 04-0759-09

基于改进 U²-Net 网络的金属涂层剥落 与腐蚀图像分割方法

倪云峰¹, 齐蜻蜓¹, 朱代先¹, 秋 强¹, 刘树林²

(1. 西安科技大学 通信与信息工程学院, 陕西 西安 710054; 2. 西安科技大学 电气与控制工程学院, 陕西 西安 710054)

摘 要: 针对金属涂层缺陷图像分割中存在特征提取能力弱和分割精度低的问题, 提出了一种改进的 U²-Net 分割模型。首先, 在 U 型残差块 (RSU) 中嵌入改进的增大感受野模块 (receptive field block light, RFB_L), 组成新的特征提取层, 增强对细节特征的学习能力, 解决了网络由于感受野受限造成分割精度低的问题; 其次, 在 U²-Net 分割模型的解码阶段引入有效的边缘增强注意力机制 (contour enhanced attention, CEA), 抑制网络中的冗余特征, 获取具有详细位置信息的特征注意力图, 增强了边界与背景信息的差异性, 从而达到更精确的分割效果。实验结果表明, 该模型在两个金属涂层剥落与腐蚀数据集上的平均交并比、准确率、查准率、召回率和 F_1 -measure 分别达到 80.36%、96.29%、87.43%、84.61% 和 86.00%, 相比于常用的 SegNet、U-Net 以及 U²-Net 分割网络的性能都有较大提升。

关键词: 缺陷分割; 语义分割模型; 感受野模块; 注意力机制

中图分类号: TN201; TP391

文献标志码: A

DOI: 10.5768/JAO202445.0402005

Image segmentation method for metal coating peeling and corrosion based on improved U²-Net network

NI Yunfeng¹, QI Qingting¹, ZHU Daixian¹, QIU Qiang¹, LIU Shulin²

(1. College of Communication and Information Engineering, Xi'an University of Science and Technology, Xi'an 710054, China; 2. College of Electrical and Control Engineering, Xi'an University of Science and Technology, Xi'an 710054, China)

Abstract: An improved U²-Net segmentation model was proposed to address the issues of weak feature extraction ability and low segmentation accuracy in metal coating defect image segmentation. Firstly, an improved receptive field block light (RFB_L) module was embedded in the U-shaped residual block (RSU) to form a new feature extraction layer, which enhanced the ability to learn detailed features and solved the problem of low segmentation accuracy caused by limited receptive field in the network. Secondly, in the decoding stage of the U²-Net segmentation model, an effective contour enhanced attention (CEA) mechanism was introduced to suppress redundant features in the network, obtain feature attention maps with detailed position information, enhance the difference between boundary and background information, and achieve the more accurate segmentation results. The experimental results show that the average intersection and union ratio, accuracy, precision, recall, and F_1 -measure of the model on two metal coating peeling and corrosion datasets are 80.36%, 96.29%, 87.43%, 84.61%, and 86.00%, respectively. Compared with commonly used SegNet, U-Net, and U²-Net segmentation networks, the performance of the model is significantly improved.

Key words: defect segmentation; semantic segmentation model; receptive field module; attention mechanism

收稿日期: 2023-06-21; 修回日期: 2023-12-01

基金项目: 陕西省重点研发计划 (2021GY-338)

作者简介: 倪云峰 (1968—), 男, 博士, 教授, 主要从事控制理论与控制工程、模式识别研究。E-mail: 635129613@qq.com

通信作者: 朱代先 (1970—), 男, 博士研究生, 副教授, 主要从事智能机器人、嵌入式系统研究。E-mail: zhudaixian@xust.edu.cn

引言

涂层材料已经在各个领域得到广泛的应用,然而金属表面的涂层会随着时间的推移而降解,比如金属涂层的粉化、起泡、剥落或腐蚀,直接影响对金属材料的保护功能,造成不必要的经济损失^[1]。因此,及时检测涂层剥落与腐蚀的程度,将有助于抑制金属腐蚀情况的进一步恶化。目前检测金属涂层腐蚀与剥落主要采用人工检查方法,其存在主观性强、成本高、效率低等问题。

计算机技术已经得到广泛的应用,利用计算机视觉对金属涂层外观剥落和腐蚀特征的信息进行处理成为当前的研究热点。例如,VOEOBEL R 等人^[2]研究了基于智能图像分析的涂装钢材表面锈蚀缺陷分割,该方法首先将输入图像转换为 HSV 颜色空间,并确定涂层的颜色,其次采用一种参数化 Retinex 方法^[3]对图像进行预处理,最后采用自适应分割,检测图像上的铁锈污渍,但是由于铁锈周边存在一些污渍以及光照原因,自适应分割方法存在过度分割的情况。FORKAN A R M 等人^[4]提出了基于 CNN(convolutional neural network)的通信塔腐蚀检测方法,尽管 CNN 方法比传统方法获得了更好的精度,但使用滑动窗口来检测腐蚀区域并不能对缺陷进行像素级分割。HUANG Z 等人^[5]使用 DeepLab 进行特征图提取,将特征图输入递归交叉注意模块进行语义分割,但是这种方法需要大量的训练数据才能取得良好的效果,如果数据集较小,则容易出现过拟合的情况。曹富强^[6]等人针对图像分割存在精度较低的问题,提出一种改进 DeepLabv3+ 的缺陷分割算法,将原有的 Xception 模块^[7]用 EfficientNet^[8] 中的 MBConv 来代替,且将空洞空间金字塔池化(ASPP)^[9] 层中空洞卷积的扩张率重新设计,提高了分割精度,但是该网络采用的 ASPP 模块,使用的扩张率分别为 6、12 和 18,3 个扩张率存在大于 1 的公约数,从而导致出现 gridding^[10] 效应,因此图像的特征提取效果可能不佳。CHA Y J 等人^[11]提出了一种基于 Faster R-CNN 的缺陷检测方法,并且开发了数据库,可以快速检测分割钢腐蚀和钢分层等缺陷,但是在这种方法中,可以通过一个或多个边框来检测缺陷区域,不能精确地对缺陷区域进行像素级分割。王一^[12]等人针对金属工件表面缺陷尺寸小、难以分割的问题,提出了一种改进的 U-Net 语义分割网络,在原网络的基础上融入 CBAM(convolutional

block attention module)^[13] 模块并在编码阶段采用 DO-Conv(depthwise over-parameterized convolutional) 代替传统卷积,增强特征的学习,使其能够更高效地对缺陷特征进行提取,但是 U-Net 网络分割对于复杂的背景存在一定的识别误差,导致分割结果不够精确。


基于以上分析,在表面锈蚀区域分割过程中可能会出现一些问题,比如在不均匀光照和存在铁锈污渍的情况下进行铁锈分割,会导致过度分割,所以传统的图像分割方法不能很好地满足金属涂层剥落与腐蚀图像分割需求。在典型的金属构件腐蚀图像分割方面,深度学习取得了较好效果,但对于腐蚀程度较轻的特征,存在分割精度较低的问题。针对以上图像分割问题,本文提出了一种融入改进的 RFB_1 模块和 CEA^[14] 的 U²-Net^[15] 语义分割模型。首先,利用改进的 RFB_1 模块增强对细节特征的学习能力,解决了网络由于感受野受限造成分割精度低的问题;其次,通过在 U²-Net 分割模型的解码阶段引入的 CEA 抑制网络中的冗余特征,获取具有详细位置信息的特征注意力图,增强了边界与背景信息的差异性,提高了缺陷图像的分割精度。

1 网络结构

1.1 语义分割网络 U²-Net

U²-Net 网络结构如图 1 所示。它是一种基于编-解码结构的显著目标检测网络,主要架构是 U-Net^[16],每个阶段都由 RSU(road side unit) 组成。U²-Net 作为经典的深度学习模型,具备训练样本少、分割精度高等优势。因此,本文选取 U²-Net 网络来设计金属涂层剥落与腐蚀缺陷分割方法。

该模型的整体设计框架为一个两级嵌套的 U 型网络结构,每个级别都遵循一个类似于 U-Net 模型的编码器-解码器结构。U²-Net 模型的最外层是 11 个独立的大 U 形结构,由编码器、解码器和映射融合模块组成,每个块都充满了小的 RSUs 块。解码阶段与编码阶段相似,采用解码器部分对高分辨率特征图进行逐步上采样和合并操作。逐步上采样可以逐渐恢复特征图的分辨率,而合并操作可以将编码器和解码器的特征图进行融合,以获得更多的上下文信息和细节特征。



1.2 改进的语义分割网络

1.2.1 感受野增强的 RSU 块

传统的 RSU 结构如图 2 所示。主要由输入卷积层、编解码结构和残差结构 3 部分组成, 它的结构由 $RSU-L(C_{in}, M, C_{out})$ 来表示, 其中 C_{in} 表示特征图输入的通道数, C_{out} 表示特征图输出通道数, RSU 内部层的通道数用 M 表示, 编码器中包含的

层数用 L 表示。

RSU 块结构和 U-Net 网络结构类似,即首先通过 3×3 卷积层对输入特征图进行下采样,将特征层进行压缩,其次用 3×3 的卷积核进行上采样,最后将相同尺度的特征层进行融合,得到有效特征层,但是在连续下采样过程中由于图形分辨率的降低会导致信息丢失。




图2 U型残差块的结构图

Fig. 2 Structure diagram of U-shaped residual block

“感受野”一词最初是在研究人类视觉系统时所提出。卷积运算通过一种叫做“滑动窗口”的方式进行操作，窗口的大小表示卷积运算的采样范围，类似于视觉系统。采样范围越大，网络接受域越大，所能获得的信息越全面，从而有助于提升分割、识别等任务的准确率。

LIU S 等^[17] 提出了感受野模块 (receptive field block, RFB), RFB 模块就是借鉴以上思想所设计,

结合膨胀卷积^[18]和 InceptionNet^[19]的并行卷积来扩大特征层的感受野。RFT 网络结构如图 3 所示。输入的特征层首先经过 1×1 的普通卷积, 其次分别是 3×3 和 5×5 的普通卷积, 再分别经过膨胀率为 1、3 和 5 的 3×3 膨胀卷积, 最后进行级联。

为了尽可能减少模型的参数,本文对 RFB 模块进行轻量化改进,在 RFB 模块的基础上,将 5×5 卷积用 $1 \times 3 + 3 \times 1 + 3 \times 3$ 的结构替代,使用不同尺




图3 RFB网络结构

Fig. 3 Structure diagram of RFB network

寸的卷积核获取多尺度特征,最终通过特征融合来提高网络的性能。将其命名为RFB_1模块,其结构如图4所示。为了提高模型的准确性,RFB_1模块运用了多种卷积核和空洞卷积操作。

如图5所示,将RFB_1模块嵌入RSU块中,对输入的特征层进行特征提取,增大特征层的感受




图4 RFB_1网络结构

Fig. 4 Structure diagram of RFB_1 network

野,使其包含更多信息,且使用RFB_1模块不会过多地增加计算量,将融入RFB_1模块的RSU块命名为RFB_1-RSU模块。主要步骤包括:将输入图像进行3×3卷积下采样,连续进行压缩,得到特征图;在3×3卷积下采样之后,嵌入一个RFB_1模块,再将改进之后模块与上采样卷积块连接;最后将得到的特征图进行融合,输出最终特征图。




图5 感受野增强的RSU块

Fig. 5 RSU block with enlarged receptive field

1.2.2 CEA 模块

由于现有图像分割方法在目标区域与背景之间边缘像素点划分不准确,导致分割结果中目标物体与背景之间边界模糊不清,分割效果不理想。本文采用CEA模块,CEA模块是一种针对计算机视觉领域中图像语义分割任务而提出的注意力机制,该机制主要是通过对图像边缘部分的特征增强,从而提高图像分割的准确性。

在融入RFB_1模块的U²-Net模型上,将CEA模块应用于解码过程中,使用CEA加强对目标区

域的关注,有效地解决图像分割中的边界模糊问题,同时通过边缘增强特征来提高图像分割的精度和鲁棒性。在解码器网络结构中,CEA模块的设计如图6所示,将经过上采样的特征图输入该模块,对其进行双向编码,以更充分地获取金属涂层剥落和腐蚀区域的位置信息,可以增强目标区域与背景的边界差异,以便增强腐蚀图像的分割效果。其详细过程如下:

1) 初始化。输入尺寸大小为 $h \times w$ 的特征图 X ,沿着水平和垂直两个方向进行平均池化操作,获

取输入特征的信息编码, 即:

$$g_h = \frac{1}{w} \sum_{0 \leq i \leq w} X(h, i) \quad (1)$$

$$g_w = \frac{1}{h} \sum_{0 \leq i \leq h} X(j, w) \quad (2)$$

2) 特征压缩。拼接水平和垂直两个方向的特征, 通过卷积层 G 传递, 得到水平和垂直两个方向空间信息的特征图。同时对融合的特征图应用非线性归一化操作, 提高模型收敛速度, 改善对目标区域的关注度, 即:

$$l = \lambda(G([g_h, g_w^T])) \quad (3)$$

式中: T 表示转置; $[]$ 表示拼接处理; G 表示卷积处理; λ 表示非线性激活函数。

3) 特征激励。融合之后, 特征被分为水平和垂直两个方向的特征向量, 使用 1×1 卷积得到激励后的方向特征 $\phi(l_h)$ 和 $\psi(l_w)$, 通过 Sigmoid 函数 γ 将

特征值映射为 $[0, 1]$ 之间的权重值, 即:

$$f_h = \gamma(\phi(l_h)) \quad (4)$$

$$f_w = \gamma(\psi(l_w)) \quad (5)$$

4) 计算加权特征图。通过矩阵相乘操作, 可以将水平方向的权重矩阵和垂直方向的权重矩阵综合起来, 从而得到空间中每一个位置的权重, 这个权重矩阵可以被应用于原始图像中, 以获得空间加权后的特征注意力, 即:

$$y(i, j) = x(i, j) \times f_h(i) \times f_w(j) \quad (6)$$

5) 计算增强边缘特征。将每个像素点在原始特征图 X 和加权特征注意力图 y 中的值相减, 得到一个偏移量, 表示该像素点在边缘特征上的重要程度。通过加权特征注意力图和边界偏移量的计算, 可以提取并突出边缘特征信息, 进而改善模型的性能, 即:

$$H = x(i, j) - y(i, j) \quad (7)$$




图6 边缘增强注意力模块

Fig. 6 Edge-enhanced attention module

1.2.3 损失函数

由于对金属涂层剥落与腐蚀图像进行分割, 每张缺陷图像中, 涂层剥落和腐蚀部分所占的像素比例很小, 导致出现正负样本不均衡的情况。这种不均衡的情况会使模型在训练时更倾向于学习背景信息, 而忽略目标的细节特征, 从而影响分割效果。为解决这个问题, 可以采用基于损失函数的方法来平衡正负样本的权重, 因此, 本文的损失函数采用 Focal-loss 函数 (L_F)^[20] 与 Tversky-loss 函数 (L_T)^[21] 的组合, 代替了原来标准二分类交叉熵函数, 即:

$$l = \sigma L_F + \omega L_T \quad (8)$$

式中: l 表示最终融合特征图的输出; σ 和 ω 分别表示 L_F 和 L_T 损失函数占总损失的比例。 L_F 与 L_T 的计算公式为

$$L_F = \begin{cases} -\sigma_F(1-q)^q \ln q \\ -(1-\sigma_F)q^q \ln(1-q) \end{cases} \quad (9)$$

$$L_T = \frac{N_q}{N_q + \sigma_T F_q + \omega_T F_N} \quad (10)$$

式中: σ_F 表示样本缺陷像素与整体像素的比值; q 表示当预测样本为 1 时的概率; σ_T 和 ω_T 分别表示调节系数。

1.2.4 改进后的 U²-Net 网络

该模型在 U²-Net 的基础上, 采用基于感受野增强的 RSU 块和基于 CEA 模块构建了新的分割模型, 命名为 CEA-U²-RFB_Net, 网络结构如图 7 所示。RFB_1 模块主要是为了在增大网络感受野的同时对 RFB 模块进行轻量化改进, 以提高特征的可辨别性和鲁棒性。CEA 可以消除上采样过程

中产生的混叠效应,使金属涂层剥落与腐蚀图像分割效果更好。




图 7 CEA-U²-RFB_INet 网络结构图

Fig. 7 Structure diagram of CEA-U²-RFB_INet network

CEA-U²-RFB_INet 分割模型整个过程和 U²-Net 模型一样,每个级别都遵循一个类似于 U-Net 模型的编码器-解码器结构。最外层是 11 个独立的大 U 形结构,由编码器、解码器和映射融合模块组成,每个块都充满了感受野增强的 RSU 块。接着在进行解码阶段引入 CEA,增强了腐蚀区域与背景区域的差异,从而有效提取腐蚀区域信息,提高了图像分割结果的准确性。

2 实验与结果分析

2.1 实验设置与数据集

2.1.1 实验设置

表 1 所示为本章算法所用的相关配置。实验平台是基于 Windows10 操作系统,处理器使用 Intel core i7-8700K/3.7 GHz,搭建了 NVIDIA-2080Ti 16 GB 显卡,编程语言是 Python,该模型训练所用的深度学习框架是基于 Pytorch1.10 实现。

表 1 实验相关配置

Table 1 Experiment-related configuration

名称	数值
学习率	0.001
正则化系数	0.9
epoch	100
CUDA版本	10.0
批处理大小	10
优化器	Adam

2.1.2 数据集

数据集来源于参加项目的甲方公司材料研究实验室,部分数据集来源于自动科学评估材料的腐蚀图像数据集^[22],选择其中部分图像作为本文研究分割网络的数据集。本文从以上数据集中选择了 1 190 张图像,为了避免模型的过拟合,在原始图像上通过旋转、平移、缩放、镜像等操作对数据集进行扩充处理,同时通过添加噪声、变换颜色等方式增加数据的多样性,最终得到了 4 038 张实验数据。本文将训练数据集和测试数据集的分配比例设置为 4 : 1,部分样本如图 8 所示。




图 8 金属涂层剥落与腐蚀图像

Fig. 8 Images of metal coating peeling and corrosion

2.2 实验结果与分析

2.2.1 不同网络的对比

为了证明提出的网络结构在金属涂层剥落与腐蚀图像分割领域的有效性,通过交并比 (IoU)、准确率 (Accuracy)、查准率 (Precision)、召回率 (Recall) 和 F_1 -measure 来综合评估。选择常用的 SegNet^[23]、U-Net、DeepLab 以及 U²-Net,在同样的数据集上进行对比实验。其实验结果分别如表 2 和表 3 所示。

表 2 各个网络在金属涂层剥落数据集上的实验结果

Table 2 Experimental results of different networks on metal coating peeling dataset

网络	交并比	准确率	查准率	召回率	F_1
SegNet ^[23]	70.78	94.71	73.09	66.50	69.64
U-Net ^[16]	69.11	92.06	78.83	75.32	77.04
DeepLab ^[5]	74.32	93.87	81.45	78.79	80.10
U²-Net ^[15]	77.97	95.73	85.09	81.76	83.39
本文方法	81.77	97.07	88.34	85.91	87.11

从表 2 可知, 对金属涂层剥落数据集, DeepLab 和 U²-Net 两个网络的性能基本呈递增状态, 远高于 U-Net 和 SegNet 的性能。相比于 U²-Net, 提出的 CEA-U²-RFB_INet 网络的 5 个指标分别提高了 3.80%、1.34%、3.25%、4.15% 和 3.72%, CEA-U²-RFB_INet 的交并比、准确率、查准率、召回率以及 F_1 -measure 都比 SegNet、U-Net 和 U²-Net 高出了很多。

表 3 各个网络在金属涂层腐蚀数据集上的实验结果

Table 3 Experimental results of different networks on metal coating corrosion dataset %

网络	交并比	准确率	查准率	召回率	F_1
SegNet ^[23]	67.13	91.32	71.26	63.54	67.19
U-Net ^[16]	63.53	90.49	76.97	73.35	75.12
DeepLab ^[5]	69.16	91.98	79.31	75.17	77.18
U ² -Net ^[15]	74.21	93.73	83.43	78.96	81.13
本文方法	78.94	95.51	86.52	83.31	84.88

从表 3 可以看出, 对金属涂层腐蚀数据集, 与 U²-Net 相比, 提出的 CEA-U²-RFB_INet 的交并比、准确率、查准率、召回率和 F_1 -measure 的 5 个指标分别提高 4.73%、1.78%、3.09%、4.35% 和 3.75%, SegNet、U-Net 和 U²-Net 网络的性能是逐渐增加的, 且 CEA-U²-RFB_INet 的交并比、准确率、查准率、召回率和 F_1 -measure 比 SegNet、U-Net、DeepLab 和 U²-Net 都有了明显增长。

所以通过表 2 和表 3 可知, 本文提出的 CEA-U²-RFB_INet 分割模型在交并比、准确率、查准率、召回率和 F_1 -measure 这 5 个指标上优于其他模型, 其评价指标的值都相比于其他模型较高, 从而表明本文的方法在金属涂层剥落与腐蚀图像分割方面具有较高的准确性, 使得分割金属涂层剥落与腐蚀的结果更加精确。

为了更明确地证明本文方法的有效性, 选择了一部分金属涂层剥落与腐蚀分割图像进行对比, 如图 9 所示。




图 9 分割结果对比图

Fig. 9 Comparison images of segmentation results

通过观察图 9 中各种网络在金属涂层腐蚀与剥落数据集上的分割效果, 可以发现 SegNet 和 U-Net 等网络在分割时会出现过度分割的情况, 将涂层腐蚀区域误分割为背景区域, 进而影响计算金属涂层腐蚀区域大小的精确度。虽然 U²-Net 处理结果有所提高, 但提出的 CEA-U²-RFB_INet 网络分割结果更加接近专家标注图, 分割结果比较精

确。因此, CEA-U²-RFB_INet 网络可以更准确地分割金属涂层腐蚀区域, 提高了分割涂层腐蚀与剥落的准确性。

2.2.2 消融实验

为了验证各个改进模块对金属涂层腐蚀图像分割结果的影响, 本文设计了消融实验来评估算法的各个模块的有效性, 具体实验结果如表 4 所示。

表4 消融实验结果对比

Table 4 Comparison of ablation experiment results

网络	RFB-RSU	RFB_I-RSU	CEA	交并比/%	准确率/%	查准率/%	召回率/%	F_1 /%	测试时间/s
原算法	×	×	×	74.21	93.73	83.43	78.96	81.13	26.91
算法1	√	×	×	75.83	93.97	84.07	79.73	81.84	27.44
算法2	×	√	×	76.02	94.13	84.94	80.21	82.51	27.16
算法3	×	×	√	76.91	93.92	84.51	81.09	82.76	27.53
本文方法	×	√	√	78.94	95.51	86.52	83.31	84.88	28.11

算法1为利用RFB-RSU替换原RSU进行特征提取,RFB模块可以扩大特征层的感受野,获取更多的特征信息,提高了有效特征的提取能力。由表4可知,算法1的改进使得准确率提升了0.24%,测试时间仅增加了0.53 s。算法2为将RFB-RSU做轻量化处理,以便减少测试时间,首先将RFB模块的 5×5 卷积用 $1\times 3+3\times 1+3\times 3$ 的结构替代,称为RFB_I模块,将RFB_I模块嵌入RSU块中,对输入的特征层进行特征提取,增大特征层的感受野。由表4可知,算法2在测试时间缩短0.28 s的同时,准确率比原算法提高了0.40%。在解码过程中,加入CEA模块以加强对目标区域的关注,有效地解决图像分割中的边界模糊问题,同时通过边缘增强特征来提高图像分割的精度和鲁棒性。由表4可知,算法3的改进使得准确率提高了0.19%。本文算法将所提的RFB-I-RSU模块和CEA模块加入到原网络中,增强RSU结构的有效特征提取能力,利用CEA模块增强边界信息与背景信息的差异性,使得网络的分割能力得到提升。如表4所示,相较于U²-Net,本文算法准确率提高了1.78%,召回率提高了4.35%,查准率提高了3.09%, F_1 -measure提高了3.75%。

3 结论

本文在U²-Net分割网络基础上,加入改进后的RFB_I模块和CEA模块,最终构建了CEA-U²-RFB_I-Net分割模型。首先对原始的RFB模块进行改进,得到轻量型RFB_I模块;其次在U²-Net分割网络的基础上,融入轻量型的RFB_I模块,增强对细节特征的学习能力,解决了网络由于感受野受限造成分割精度低的问题;最后在网络中引入有效的CEA模块抑制网络中的冗余特征,增强边界信息与背景信息的差异性,解决了网络由于目标与背景之间边缘像素点划分不准确,导致分割结果不佳的问题。通过实验结果可以得出,改进的

网络CEA-U²-RFB_I-Net比常用的SegNet、U-Net、DeepLab以及U²-Net分割网络性能都有所提高。表明该方法可以准确地识别和分割金属涂层的缺陷,为后续的缺陷检测和维护提供更加精确的数据支持。

参考文献:

- [1] HARSIMRAN S, SANTOSH K, RAKESH K. Overview of corrosion and its control: a critical review[J]. Progress in Engineering Science, 2021, 3(1): 13-24.
- [2] VOEOBEL R, IVASENKO I, BEREHULYAK O, et al. Segmentation of rust defects on painted steel surfaces by intelligent image analysis[J]. Automation in Construction, 2021, 123(30): 103515.
- [3] 杨吉花, 杨华, 贾维丁, 等. 基于多尺度Retinex的激光雷达图像自适应增强方法[J]. 激光杂志, 2023, 44(5): 192-197.
YANG Jihua, YANG Hua, JIA Weiding, et al. Adaptive enhancement method for LiDAR images based on multiscale retinex[J]. Laser Journal, 2023, 44(5): 192-197.
- [4] FORKAN A R M, KANG Y B, JAYARAMAN P P, et al. CorrDetector: a framework for structural corrosion detection from drone images using ensemble deep learning[J]. Expert Systems with Applications, 2022, 193: 116461.
- [5] HUANG Z, WANG X, HUANG L, et al. Cenet: criss-cross attention for semantic segmentation[C]// Proceedings of the IEEE/CVF international conference on computer vision. New York: IEEE, 2019: 603-612.
- [6] 曹富强, 王明泉, 张俊生, 等. 基于深度学习的铸件X射线图像分割研究[J]. 应用光学, 2021, 42(6): 1025-1033.
CAO Fuqiang, WANG Mingquan, ZHANG Junsheng, et al. Casting X-ray image segmentation based on deep learning[J]. Journal of Applied Optics, 2021, 42(6): 1025-1033.

- [7] CHOLLET F. Xception: deep learning with depthwise separable convolutions[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. New York: IEEE, 2017: 1251-1258.
- [8] TAN M, LE Q. Efficientnet: rethinking model scaling for convolutional neural networks[C]// International Conference on Machine Learning. [S. l.]: PMLR, 2019: 6105-6114.
- [9] WU Y, SHEN X, BU F, et al. Ultrasound image segmentation method for thyroid nodules using ASPP fusion features[J]. IEEE Access, 2020, 8(8): 172457-172466.
- [10] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Deeplab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 40(4): 834-848.
- [11] CHA Y J, CHOI W, SUH G, et al. Autonomous structural visual inspection using region - based deep learning for detecting multiple damage types[J]. *Computer - Aided Civil and Infrastructure Engineering*, 2018, 33(9): 731-747.
- [12] 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.
WANG Yi, GONG Xiaojie, SU Hao. Image segmentation method for surface defects of metal workpieces based on improved U-net[J]. *Journal of Applied Optics*, 2023, 44(1): 86-92.
- [13] WOO S, PARK J, LEE J Y, et al. Cbam: convolutional block attention module[J]. Proceedings of the European Conference on Computer Vision, 2018, 11211: 3-19.
- [14] 李翠云, 白静, 郑凉. 融合边缘增强注意力机制和 U-Net 网络的医学图像分割[J]. *图学学报*, 2022, 43(2): 273-278.
LI Cuiyun, BAI Jing, ZHENG Liang. Medical image segmentation based on the fusion of edge enhancement attention mechanism and U-Net network[J]. *Journal of Graphics*, 2022, 43(2): 273-278.
- [15] QIN X, ZHANG Z, HUANG C, et al. U²-Net: going deeper with nested U-structure for salient object detection[J]. *Pattern Recognition*, 2020, 106(53): 107404.
- [16] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]// Medical Image Computing and Computer-Assisted Intervention—MICCAI 2015: 18th International Conference, Munich, Germany, October 5-9, 2015, Proceedings, Part III 18. Berlin: Springer International Publishing, 2015: 234-241.
- [17] LIU S, HUANG D. Receptive field block net for accurate and fast object detection[C]// Proceedings of the European Conference on Computer Vision. [S.l.]: arxiv, 2018: 385-400.
- [18] YU F, KOLTUN V. Multi-scale context aggregation by dilated convolutions[EB/OL]. [2023-05-15]. <https://arxiv.org/pdf/1511.07122.pdf%5D>.
- [19] SZEGEDY C, VANHOUCKE V, IOFFE S, et al. Rethinking the inception architecture for computer vision[C]// Proceedings of the IEEE conference on Computer Vision and Pattern Recognition. New York: IEEE, 2016: 2818-2826.
- [20] LIN T Y, GOYAL P, GIRSHICK R, et al. Focal loss for dense object detection[C]// Proceedings of the IEEE International Conference on Computer Vision. Venice: IEEE, 2017: 2980-2988.
- [21] SALEHI S M, ERDOGMUS D, GHOLIPOUR A. Tversky loss function for image segmentation using 3D fully convolutional deep networks[C]// International Workshop on Machine Learning in Medical Imaging. Cham: Springer, 2017: 379-387.
- [22] YIN B, JOSSELYN N, CONSIDINE T, et al. Corrosion image data set for automating scientific assessment of materials [EB/OL]. (2021-09-20)[2023-05-15]. https://arl.wpi.edu/corrosion_dataset/#.
- [23] 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.