

DOI: 10.13382/j.jemi.B2306742

# 改进 U\_Net 网络的钢结构表面锈蚀图像分割方法\*

陈法法<sup>1,2</sup> 董海飞<sup>1</sup> 何向阳<sup>2</sup> 陈保家<sup>1</sup>

(1. 三峡大学水电机械设计与维护湖北省重点实验室 宜昌 443002; 2. 国家大坝安全工程技术研究中心 武汉 430010)

**摘要:**为实现锈蚀图像分割网络模型轻量化,同时消除非单一特征背景和锈液等类似特征背景干扰,本文将 U\_Net 网络模型的编码部分替换为 MobilenetV3\_Large 网络,导入基于 ImageNet 数据集的 MobilenetV3\_Large 网络预训练权重,将 U\_Net 网络模型解码部分的普通卷积替换为深度可分离残差卷积,并在上采样的过程中添加注意力导向 AG 模块和 Dropout 机制。经实验验证表明,本文设计的改进 U\_Net 网络模型在非单一特征背景和锈液等类似特征背景干扰下,具有明显的锈蚀图像分割优势,相比于原 U\_Net 网络模型,模型大小减少了 81.18%,浮点计算量减少了 98.34%,检测效率提升了 3.27 倍,即从原来不足 6 fps,提升至 19 fps。网络模型实现轻量化的同时,网络模型的准确率达 95.54%,相比于原 U\_Net 网络模型提升了 5.04%。

**关键词:** 锈蚀区域分割; MobilenetV3; U\_Net; 注意力导向; 深度可分离残差卷积

**中图分类号:** TP391.41; TN911.73 **文献标识码:** A **国家标准学科分类代码:** 460.5

## Improved steel structure surface rust image segmentation method for U\_Net network

Chen Fafa<sup>1,2</sup> Dong Haifei<sup>1</sup> He Xiangyang<sup>2</sup> Chen Baojia<sup>1</sup>

(1. Hubei Key Laboratory of Hydropower Machinery Design &amp; Maintenance, China Three Gorges University, Yichang 443002, China; 2. National Dam Safety Research Center, Wuhan 430010, China)

**Abstract:** In order to lighten the rust image segmentation network model and eliminate the interference of non-single feature background and similar feature backgrounds such as rust liquid, this paper replaces the encoded part of the U-Net network model with the MobilenetV3\_large network, imports the pre-trained weights of the MobilenetV3\_large network based on the ImageNet dataset, and replaces the ordinary convolution of the decoded part of the U-Net network model with a deep separable residual convolution. And add the attention-oriented AG module and the Dropout mechanism in the process of upsampling. Experimental results demonstrate that the improved U-Net network model designed in this paper exhibits significant advantages in rust image segmentation under non-uniform feature background and similar feature background interference such as rust liquids. The model size is reduced by 81.18% compared to the original U-Net network model, resulting in a decrease of floating point calculations by 98.34%. Additionally, the detection efficiency has improved by 3.27 times, increasing from less than 6 frames/s to 19 frames/s. While the network model is lightweight, the accuracy of the network model is 95.54%, which is 5.04% higher than the original U\_Net network model.

**Keywords:** rust area segmentation; MobileNetV3; U\_Net; attention guided; depth separable residual convolution

## 0 引言

在我国大型结构工程项目的中安全问题中,钢结构的锈蚀问题十分严重<sup>[1]</sup>。如国内关于在役水工闸门锈蚀

情况的调研报告显示,因关键结构件锈蚀导致闸门不能安全运行的比例约占 90%<sup>[2]</sup>。为了延长钢结构的使用寿命,各业主单位通常是通过制定“锈蚀检测规范”和“锈蚀修复措施”来控制钢结构的表面锈蚀。通过调研各重点企业制定的“锈蚀检测规范”,锈蚀区域面积是其必备

收稿日期: 2023-07-17 Received Date: 2023-07-17

\* 基金项目: 国家自然科学基金(51975324)、国家大坝安全工程技术研究中心开放基金(CX2022B06)、湖北省教育厅科研项目(B2021036)资助

检测项目。传统对钢结构的锈蚀是通过人工目测来完成,然而,往往因检测场地局限、检测人员经验受限等原因导致锈蚀检测结果并不精确,尤其是对于不规则的锈蚀区域面积测算而言,传统的人工目测方法很难得到准确结果。

近年来,随着视觉图像技术和深度学习等信息技术的快速发展,基于深度学习的视觉图像技术在钢结构锈蚀区域检测任务中越来越受到重视。基于深度学习算法实现对锈蚀图像的区域检测与分割,可以快速获得钢结构表面锈蚀的分布状况、锈蚀面积等信息。如王达磊等<sup>[3]</sup>基于深度神经网络,对苏通大桥的锈蚀图像进行检测分割,结合分割结果定义锈蚀面积、锈蚀率等定量评价指标。陆廷杰等<sup>[4]</sup>通过构建卷积神经网络和颜色直方图,对水下钢结构图像分别实现了锈蚀识别和锈蚀区域分割,并基于锈蚀率实现锈蚀等级评估。

传统的深度学习算法由于计算量和内存占用庞大,难以部署到嵌入式平台中发挥实用价值<sup>[5-6]</sup>。然而,在实际的工程应用中,各企业业主普遍期望将锈蚀图像的处理算法和程序部署到可移动的嵌入式平台上,由此,企业业主只需少量的检测人员即可快速高效的完成钢结构的锈蚀检测任务。众多学者针对传统的深度学习算法进行轻量化的改进,使之适配嵌入式移动平台。如:刘宇等人针对 MobilenetV3\_Larg 网络模型,通过结构化剪枝来进一步压缩模型的参数量<sup>[7]</sup>。徐健等<sup>[8]</sup>针对 MobilenetV3 网络模型,将 5×5 卷积层替换为 3×3 卷积层,3×3 卷积层由 3×1+1×3 折叠取代。

上述针对 MobilenetV3 网络模型的轻量化改进主要是针对特定应用而实现的具体方法。由于实际工程中的锈蚀图像背景复杂,锈蚀特征渐变性强,锈蚀边界非常模糊难以界定,部分区域甚至还存在非单一特征背景和锈液等类似特征背景干扰。在进行锈蚀区域分割和锈蚀面积测算时,传统深度学习算法还可以通过改进进一步提高其分割精度,同时,由于传统深度学习算法结构复杂,直接将其部署到移动嵌入式设备上很难发挥其效用。为此,本文将 MobilenetV3\_Large 网络作为改进的 U\_Net 网络模型下采样部分,采用迁移学习的方法,将基于 ImageNet 数据集训练的 MobilenetV3\_Large 网络预训练权重导入改进的 U\_Net 网络中,并引入注意力导向 AG 模块<sup>[9-10]</sup>和 Dropout 机制<sup>[11]</sup>,对传统图像分割网络模型进行设计改进,以此实现对锈蚀区域的精确分割和锈蚀面积的快速测算。

## 1 改进 U\_Net 模型框架

### 1.1 模型分析

MobileNetV3 网络主要是通过神经网络架构搜索

(neural architecture search, NAS) 的方法来实现高效神经网络自动化设计,即首先使用资源受限的平台感知 NAS (platform-aware NAS) 来进行模块级搜索,再利用 NetAdapt 算法进行层级搜索,由此构建轻量化神经网络<sup>[12]</sup>。

MobileNetV3 基本网络单元如图 1 所示,其中“+”表示的短连接,仅在 Large 版本中步长为 1、输入和输出通道相等时出现,Dwise 表示深度卷积,NL 表示 ReLU6 和 h-swish 非线性激活函数,Pool 表示全局池化,FC 表示全连接计算。MobileNetV3 在具备 MobileNetV1 和 MobileNetV2 网络特点、实现轻量化自动设计的同时,引入一种全新设计非线性的激活函数 h-swish 和轻量级注意力模块,即挤压激励 (squeeze and excitation, SE) 模块<sup>[13]</sup>。其中非线性的激活函数 h-swish 能够在增加网络深度的同时,有效减少网络模型参数,其激活函数公式为:

$$h-swish = x \frac{\text{ReLU6}(x + 3)}{6} \quad (1)$$

其中, $x$  表示特征图中的特征量,ReLU6 表示上限为 6 的 ReLU 激活函数。




图 1 MobilenetV3 基本网络单元

Fig. 1 Basic network unit of MobilenetV3

挤压激励 (squeeze and excitation, SE) 模块的设计能够使网络模型更加关注图像目标区域,从而提升有效特征提取效率,其模块架构如图 2 所示,该注意力模块主要包含挤压和激励两个部分。在挤压 Fsq 部分,通过全局平均池化的方法对特征图的各个通道的特征值取平均值,得到维度为 1×1×C 的特征向量。激励 Fex 部分由两个全连接层和两个激活函数组成,同样输出一个维度为 1×1×C 的通道权重。最终将输入特征图进行 Fsc 操作,即将该特征图与激励 Fex 操作输出的通道权重进行相乘,得到经过挤压激励模块后的特征图。

此外,MobileNetV3 根据网络层数和部分网络参数的不同,进一步定义了适用高资源的 MobilenetV3\_Large 和适用于低资源的 MobilenetV3\_Small 两种网络模型。尽管 MobilenetV3\_Small 相比 MobilenetV3\_Large 能够减少模型的参数量和计算量,但同时也会造成网络模型精度的下降,因此本文将采用 MobilenetV3\_Large 作为 U\_Net 网络模型的特征提取网络<sup>[14-15]</sup>。




图 2 挤压激励模块

Fig. 2 Module of squeeze and excitation

### 1.2 改进的 U\_Net 网络

U\_Net 网络模型设计之初便是主要为了解决医学图像分割数据集少这一问题<sup>[16]</sup>,而对比钢结构表面锈蚀图像分割,后者在同样面临图像数据集少,轮廓边缘不规则性的同时,面临的类似特征干扰背景更加复杂。因此为更好适应锈蚀图像不规则、随机性、存在非单一特征背景和锈液等类似特征背景干扰等特点,本文将基于 U\_Net 网络模型进行网络结构轻量化的优化设计,提升锈蚀图像分割精度同时减小网络模型大小、浮点计算量,提高锈蚀图像分割效率。

结合 1.1 节模型分析,本文设计的网络架构如图 3 所示,其中方块模块右上角数字表示特征图通道数,左下角数字表示特征图尺寸,DSRCM 表示深度可分离残差卷积 (depth separable residual convolution), 本文将 MobilenetV3\_Large 网络作为 U\_Net 网络模型的编码区的骨干网络,实现锈蚀图像的特征提取,并采用迁移学习的方法,将基于 ImageNet 数据集训练的 MobilenetV3\_Large 网络预训练权重导入本文改进 U\_Net 网络中。对模型的解码区部分引入注意力导向 AG 模块和 Dropout 机制,并将上采样中的标准卷积替换为深度可分离卷积,以实现有效特征的高效提取,提升网络模型分割精度的同时,进一步实现网络模型轻量化。

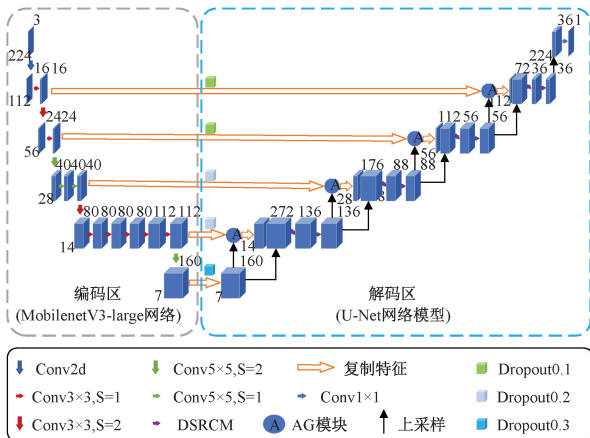


图 3 改进的 U\_Net 网络结构

Fig. 3 Improved U\_Net network architecture

## 2 网络结构及算法优化设计

### 2.1 迁移学习

迁移学习 (transfer learning) 类似于知识蒸馏,本质是将 A 场景学到的知识迁移到 B 场景中,从而有效利用现有 ImageNet\_VOC 等大数据集训练得出的网络模型参数。本文采用 U\_Net 网络模型的同时,采用迁移学习的方法,将基于 ImageNet 数据集训练得出的 MobilenetV3 网络预训练权重,导入至本文设计的改进 U\_Net 网络模型中,从而实现网络模型轻量化设计,并进一步提升钢结构表面锈蚀图像分割精度<sup>[17-18]</sup>。

### 2.2 注意力导向 AG 模块和 Dropout 机制

为进一步提升网络模型对锈蚀区域图像的特征提取,本文引入了注意力导向 AG 模块 (attention guide model),其网络架构如图 4 所示,其中 Fs 表示编码区下采样通过跳跃连接输出的特征图,Fx 表示解码区经插值上采样后输入的特征图,上述两类特征图输入至 AG 模块时,首先均通过 1x1 卷积和 GN 归一化操作,再进行特征图通道融合,融合后的特征图经过 ReLU 激活函数后,再通过 1x1 卷积、GN 归一化和 Sigmoid 激活函数操作后,得到一个 1x1xC 维度的特征向量,最后将得到的特征向量与 Fx 特征图进行相乘操作,得到经过 AG 模块处理后的特征图。




图 4 AG 模块示意图

Fig. 4 AG module diagram

与此同时,本文在解码区上采样部分引入多参数的 Dropout 损失机制,即在网络下采样的最低层引入 Dropout 参数为 0.3,其余 4 个上采样层中分别引入两个 Dropout 参数为 0.2、0.1,从而避免本文设计的网络模型出现过拟合的同时,提高网络模型的对于钢结构表面锈蚀图像的分割精度。

### 2.3 深度可分离残差卷积

为进一步减少网络模型的参数量和浮点计算量,同时保持图像分割精度,本文将解码区上采样部分的标准卷积替换为深度可分离残差卷积<sup>[19]</sup>。深度可分离残差卷积架构如图 5 所示,其卷积方式分为主干分支和辅助分支。在主干分支中,特征图 Fc 输入后,依次 1x1 卷积、GN 归一化函数、ReLU 激活函数和 5x5 卷积、GN 归一化函数、ReLU 激活函数。在辅助分支中,原特征图 Fc 输入



后经过一个  $5 \times 5$  卷积核大小的卷积操作。两个分支处理后的特征图经过特征图通道融合后得到最后的输出特征图。




图 5 深度可分离残差卷积

Fig. 5 Depth separable residual convolution

### 3 实验与结果分析

#### 3.1 数据集处理及评价指标

本文采用的钢结构表面锈蚀图像数据集来源于网上搜集及本课题组前期的研究工作,锈蚀图像数据集共有 500 张钢结构表面锈蚀图像。与此同时,由于现有的钢结构表面锈蚀图像数据集较少,为进一步提升网络模型的泛化性,一方面,本文按照  $6:2:2$  的比例来对应划分训练集、训练集和测试集,从而减少模型过拟合的可能性;另一方面,本文通过旋转、对比度增强等 8 种数据集扩充方法,对数据集划分后的训练集和验证集进行扩充,而对测试集不进行数据集扩充,以便于更好地评估网络模型的实际检测分割精度。对此,通过上述数据集扩充方法,本文采用的锈蚀图像数据集共 3 300 张,其中训练集 2 400 张,验证集张 800 图像,测试集共 100 张图像,且数据集扩充后图像对比效果如图 6 所示。



图 6 数据集扩充图像对比

Fig. 6 Dataset enrichment effect plot

本文采用准确率 (Accuracy)、精确率 (Precision)、交并比 (IoU),参数量 (Params),浮点计算量 (FLOPs) 来对各个锈蚀图像分割网络模型进行定量对比分析和评估<sup>[20]</sup>,其中准确率、精确率和交并比的计算公式分别如式(2)~(4)所示。

$$Accuracy = \frac{TP + TN}{TP + TN + FN + FP} \quad (2)$$

$$Precision = \frac{TP}{TP + FP} \quad (3)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (4)$$

其中,TP (true positive) 为真阳性,即预测结果为正样本,实际也是正样本;FP (false positive) 为假阳性,即预测结果为正样本,实际却是负样本;TN (true negative) 为真阴性,即预测结果为负样本,实际也是负样本;FN (false negative) 为假阴性,即预测结果为负样本,实际却是正样本。

#### 3.2 模型训练

本文所涉及的网络模型训练均采用 Binary Focal Loss 损失函数、Adam 模型优化器,采用阶梯级学习率调整策略,即当训练损失函数值保持不变时,模型学习率进行减半,从而进一步探索模型权重参数的最优值。

图像尺寸大小为  $224 \times 224$  pixels,初始学习率 (learning rate) 设定为 0.001,网络模型训练轮数 (Epoch) 设置为 50,批处理大小 (batch size) 设置为 4。网络模型训练平台基于 RTX3060 Laptop GPU、4GB 运行显存、软件环境为 64 位 Windows 11 系统、采用 Pytorch1.13.0 深度学习框架。

#### 3.3 模型验证与分析

为验证本文设计的改进 U\_Net 网络模型的合理性和可靠性,首先对本文设计的网络模型与现有的网络模型进行对比验证,随后再针对本文设计的网络模型进行消融实验验证。

##### 1) 不同网络模型对比实验

为验证分析本文设计的改进 U\_Net 网络模型对锈蚀图像分割所具备的优势,选用 FCNs、U\_Net、DeepLabV3+、FAT\_Net 这 4 种图像分割模型作对比实验。此外,为了避免因模型参数初始化以及随机数据集而导致模型输出结果的波动,本文在相同环境和相同参数设置下分别进行 5 次训练测试,其输出的准确率评价指标波动如图 7 所示。

在图 7 中,折线的中间点代表各个网络模型 5 次测试集准确率结果的平均值,误差棒的上下端分别对应各个网络模型准确率指标的最大值和最小值。

由图 7 可以看出,在 5 次相同条件下的训练中,DeepLabv3+ 网络模型的准确率指标波动范围最大,其准确率波动最大值达到 3.6%,究其原因这是由于这类网络的架构较为复杂,不同的初始化参数对网络训练的结果影响较大。FCNs 网络模型准确率波动范围在 0.66%,FAT\_Net 网络模型准确率波动范围在 0.48%,而本文设计的改进 U\_Net 网络模型准确率波动范围在 0.45%,仅次于准确率波动范围为 0.41% 的 U\_Net 网络模型。而这是由于本文设计的改进 U\_Net 网络模型属于轻量化及结




图 7 不同网络模型准确率对比及指标波动情况

Fig. 7 Comparison of accuracy rates and index fluctuations of different network models

构较为简单的网络模型,从而不同的初始化参数对网络训练的结果影响相对较小,识别结果相对稳定。综上所述,本文设计的改进 U\_Net 网络模型在钢结构表面锈蚀图像分割任务中,其模型的准确率和稳定性均占有较大优势。

不同网络模型锈蚀图像分割效果图如图 8 所示,在图 8 中,第 a、b、f 列为非单一特征背景下的锈蚀图像分割结果对比,在第 a 列图像中,对比的图像分割模型均出现了漏分割现象,同时 FAT\_Net 模型出现了对类似特征背景的误分割。在第 b 列实验结果图像中,对比的图像分割模型均出现了对锈蚀区域误分割的现象。在第 f 列实验结果图像中,DeepLabV3+网络模型出现误分割的现象,本文设计的改进 U\_Net 网络模型较对比的图像分割网络模型而言,其锈蚀边缘更加准确、清晰连贯。

在图 8 中,第 c、d、e 列为单一特征背景下的锈蚀图像分割结果对比,在第 c 列图像中,FCNs 网络模型出现了明显的锈蚀区域误分割。在 d 列图像中,FCNs、U\_Net 和 FAT\_Net 网络模型出现了锈蚀区域图像的漏分割。在第 e 列图像中,由于锈液的干扰,对比的图像分割网络模型均出现了锈蚀区域图像的误分割。综合而言,本文设计的改进 U\_Net 网络模型很好的实现了对锈蚀区域图像的精确分割,锈蚀边缘清晰连贯。

为定量评价本文设计的改进 U\_Net 网络模型对锈蚀图像分割的优良性能,采用 3.1 节中定义的准确率、精确率和交并比指标,并采用 profile 函数计算的模型参数量、浮点计算量指标,以及取 100 张测试集得到的平均每张锈蚀图像分割所用时间指标,对各网络模型进行定量分析,结果如表 1 所示。

由表 1 可以看出,本文设计的改进 U\_Net 网络模型在准确率、精确率表现均优于对比图像分割模型,其中准确率为 95.54%、而对比的网络模型的准确率介于

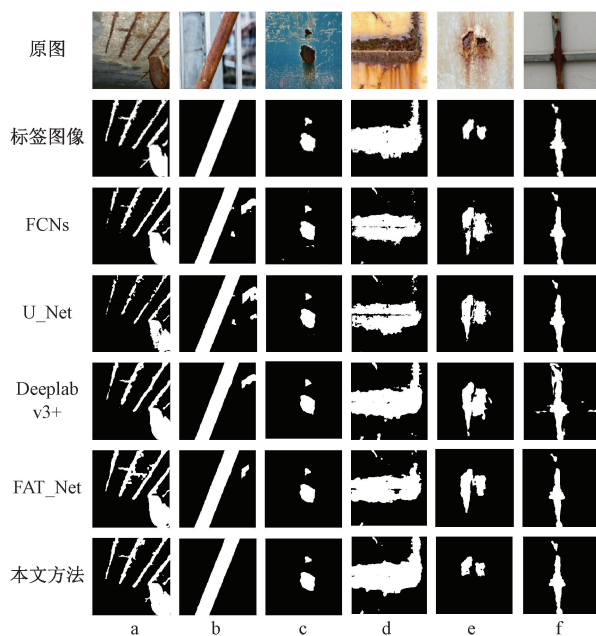


图 8 不同网络模型锈蚀分割效果图对比

Fig. 8 Comparison of rust segmentation renderings of different network models

表 1 不同网络模型锈蚀分割性能对比  
Table 1 Comparison of rust segmentation performance of different network models

不同网络	Accuracy/	Precision/	IoU/	Params/	FLOPs/	时间/
	%	%	%	M	G	ms
FCNs	93.28	83.26	72.66	18.64	19.52	103.56
UNet	90.50	81.92	68.00	17.27	30.77	169.91
Deeplabv3+	93.35	81.72	69.99	40.35	13.26	137.01
FAT_Net	93.36	83.71	<b>82.47</b>	29.62	42.80	186.00
本文方法	<b>95.54</b>	<b>84.59</b>	77.43	<b>3.25</b>	<b>0.51</b>	<b>52.03</b>

90.50%与 93.36%之间;精确率为 84.59%,而对比的网络模型的精确率介于 81.72%与 83.71%之间;交并比为 77.43%,虽低于 FAT\_Net 网络模型 84.47%的交并比,但在参数量、浮点计算量和锈蚀图像分割效率指标上,本文设计的改进 U\_Net 网络模型均占据最大优势。相比于原 U\_Net 网络模型,本文设计的改进 U\_Net 网络模型的准确率提高了 5.04%,交并比提高了 9.63%,浮点计算量减少了 43.36%,图像分割效率提升了 69.38%,模型大小减少了 81.18%,浮点计算量减少了 98.34%,检测效率提升了 3.27 倍。综上所述,本文设计的改进 U\_Net 网络模型不仅实现了网络模型轻量化,并且对于锈蚀图像分割精度有了一定的提升,锈蚀图像分割的结果也更加清晰连贯。

由于现有公开标注好的锈蚀图像数据集少,导致国内外现有有关锈蚀图像分割研究较少,同时数据集的大

小和质量对于网络模型评估指标将产生决定性影响。倪有豪等人通过深度卷积生成对抗网络(DCGAN)生成虚拟桥梁锈蚀图像数据集,其中 DeepLabv3+网络模型的图像分割精度为 93.5%<sup>[21]</sup>。与本文对比实验中 DeepLabv3+网络模型的图像精度相近,但本文改进 U\_Net 网络模型的准确率达到 95.54%,同时对模型进行了轻量化设计。因此结合上述实验对比分析,本文改进 U\_Net 网络模型对于锈蚀图像分割领域更具优势。

不同网络模型基于训练集的准确率和损失函数值变化曲线图如图 9 所示,其中训练轮数(epoch)为 50 轮,左侧坐标轴对应网络模型准确率数值变化范围,右侧坐标轴对应网络模型损失函数值的变化范围。

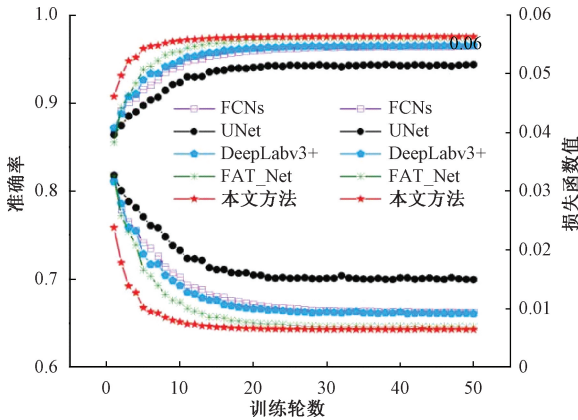


图 9 不同网络模型训练集准确率和损失函数值变化情况

Fig. 9 Changes of accuracy and loss function values of different network model training sets

从图 9 中可以看出,自 20 轮以后,本文设计的改进 U\_Net 网络模型和对比图像分割模型训练集准确率和损失函数值曲线均趋于平缓,即各个网络模型的训练达到饱和状态,锈蚀图像分割精度也达到最大值,并且训练集的准确率均高于验证集准确率。因此可以得出本文设计的改进 U\_Net 网络模型和对比的图像分割模型在本文创建的数据集基础上进行训练时,均未出现模型过拟合的现象。

2) 消融实验

该部分对比实验目的是进一步分析本文设计的网络模型中,所添加的注意力导向模块、深度可分离残差卷积模块及 Dropout 机制对网络模型准确率的提升效果,其检测分割效果图如图 10 所示,其中 MVL\_Unet 表示基于 MobilenetV3\_Large 网络改进的轻量化 U\_Net 网络模型;MVL\_Unet\_ag 表示在 MVL\_Unet 基础上,对网络模型的上采样部分添加注意力导向 AG 模块;MVL\_Unet\_res 表示在 MVL\_Unet 基础上,对网络模型的上采样部分,将 3×3 标准卷积方式替换为深度可分离残差卷积;MVL\_Unet\_ag\_res 表示在 MVL\_Unet 基础上,对网络模型上采样部分

添加注意力导向模块,同时将 3×3 标准卷积替换为深度可分离残差卷积。MVL\_Unet\_ag\_res\_dropt 是本文设计的改进 U\_Net 网络模型,其网络架构在 MVL\_Unet\_ag\_res 基础上,对网络模型特征提取最底层和跳跃连接部分添加 Dropout 机制,避免本文设计的改进 U\_Net 网络模型因结构复杂所造成测试集准确率下降或模型过拟合的现象。

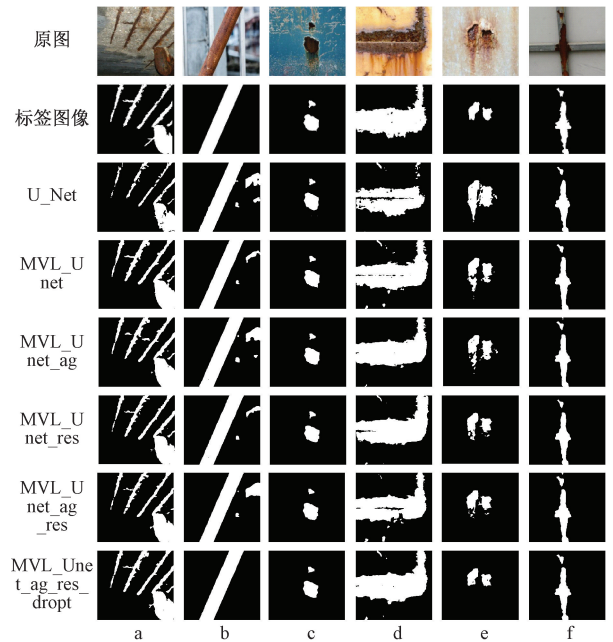


图 10 添加不同模块网络模型的效果图对比

Fig. 10 Add a comparison of renderings of different module network models

图 10 中,第 a、b、f 列为非单一特征背景下的锈蚀图像分割效果图对比,在第 a 列图像中,原 U\_Net 和仅添加部分模块的图像分割模型均出现了漏分割,并且 MVL\_Unet\_ag 网络模型出现了锈蚀区域误分割的现象。在第 b 列图像中,原 U\_Net 和仅添加部分模块的图像分割模型均出现了锈蚀区域误分割的现象。在第 f 列图像中,原 U\_Net 出现了误分割现象,并且本文设计的改进 U\_Net 网络模型较仅添加部分模块的图像分割网络模型而言,其锈蚀区域边缘更加准确、清晰连贯。

图 10 中,第 c、d、e 列为单一特征背景下的锈蚀图像分割结果对比,在第 c 列图像中,原 U\_Net 和仅添加部分模块的网络模型均出现了锈蚀区域误分割的现象。在 d 列图像中,本文设计的改进 U\_Net 网络模型较仅添加部分模块的图像分割网络模型而言,出现的误分割区域较少,其锈蚀区域边缘分割更加准确、清晰连贯。在第 e 列图像中,在锈液的干扰下,原 U\_Net 和仅添加部分模块的图像分割网络模型均出现了锈蚀区域图像的误分割,本文设计的改进 U\_Net 网络模型虽然出现了一定区域的漏



分割,但总体而言,本文设计的改进 U\_Net 网络模型的图像分割精度相对更高。综上所述,本文设计的改进 U\_Net 网络模型很好的实现了对锈蚀区域图像的精确分割,锈蚀边缘分割更加准确、清晰连贯。

为定量对比添加不同模块网络模型在测试集上的模型表现效果,结合 3.1 节 1) 中的评价指标来进行对比分析。实验结果由表 2 所示,其中 MVL\_Unet 网络模型相较于 U\_Net 网络模型,不论锈蚀图像分割精度指标,还是网络模型轻量化指标均占据较大优势,其中准确率上升了 4.7%,精确率上升了 2.5%,交并比上升了 9%,参数量减少了 78%,浮点计算量减少了 95.97%,锈蚀图像分割效率提升了 76.73%。MVL\_Unet\_ag 网络模型相较于 MVL\_Unet 网络模型,准确率提高了 0.05%,但精确率、交并比指标值分别下降了 0.24% 和 0.45%,并且不可避免的增加了模型参数量和浮点计算量,以及降低了网络

模型的检测分割效率。MVL\_Unet\_res 网络模型相较于 MVL\_Unet 网络模型,准确率和精确率有了较小提升,但交并比指标值却出现了下降,并且其深度可分离残差卷积的结构,使得其模型参数量减少了 17.37%,浮点计算量减少了 62.9%,但锈蚀图像分割效率降低了 14.2%。MVL\_Unet\_ag\_res 网络模型相较于 MVL\_Unet\_ag 和 MVL\_Unet\_res 网络模型,其模型准确率、精确率和交并比都有所提升。MVL\_Unet\_ag\_res\_dropout 为本文设计的改进 U\_Net 网络模型,相较于 MVL\_Unet\_ag\_res 网络模型,其模型的准确率、交并比和图像分割效率均被有所提升,相较于原 UNet 模型,其模型参数量减少了 81.18%,浮点计算量减少了 98.34%,检测效率提升了 3.27 倍,即从原来每秒检测不足 6 张锈蚀图像下,提升至每秒检测 19 张锈蚀图像。

表 2 不同网络模型锈蚀分割性能对比

Table 2 Comparison of rust segmentation performance of different network models

不同网络	Accuracy/%	Precision/%	IoU/%	Params/M	FLOPs/G	时间/ms
U_Net	90.50	81.92	68.00	17.27	30.77	169.91
MVL_Unet	95.20	84.42	77.00	3.80	1.24	<b>39.53</b>
MVL_Unet_ag	95.25	84.18	76.55	3.91	1.28	46.07
MVL_Unet_res	95.27	85.14	76.93	<b>3.14</b>	<b>0.46</b>	46.07
MVL_Unet_ag_res	95.51	85.25	77.01	3.25	0.51	52.45
MVL_Unet_ag_res_dropout	<b>95.54</b>	<b>84.59</b>	<b>77.43</b>	3.25	0.51	52.03

综上所述,本文设计的改进 U\_Net 网络模型在进行轻量化设计时,通过引入预训练权重、注意力导向 AG 模块、深度可分离残差卷积和 Dropout 机制,在非单一特征背景和锈液等类似特征背景干扰下,具有明显的锈蚀图像分割优势,实现了本文设计的改进 U\_Net 网络模型对于钢结构表面锈蚀图像分割精度的提升。

## 4 结论

本文在钢结构表面锈蚀图像分割研究中,为提高图像分割精度的同时,大幅度缩减模型的参数量、浮点计算量,本文将 U\_Net 模型的编码部分替换为 MobilenetV3\_Large 网络,导入基于 ImageNet 数据集的 MobilenetV3\_Large 网络预训练权重,将 U\_Net 模型的解码部分的普通卷积替换为深度可分离残差卷积,在上采样的过程中添加注意力导向 AG 模块和 Dropout 机制。

本文设计的网络模型经不同网络模型对比实验和消融实验验证后表明,本文设计的改进 U\_Net 网络模型在非单一特征背景和锈液等类似特征背景干扰下,具有明显的锈蚀图像分割优势,并且相比于原 U\_Net 网络模型,其模型大小减少了 81.18%,浮点计算量减少了 98.34%,检测效率提升了 3.27 倍,即从原来每秒检测不足 6 张锈

蚀图像下,提升至每秒检测 19 张锈蚀图像。网络模型较为轻量化的同时,网络模型的准确率达到 95.54%,相比于原 U\_Net 网络模型提升了 5.04%。综上所述,本文设计的网络模型在满足了轻量化的同时,提升了网络模型的准确率,可尝试应用于嵌入式设备中,从而为钢结构表面锈蚀图像检测和评估提供更好的解决方案。

## 参考文献

- [1] 贾晨,邵永松,郭兰慧,等. 建筑结构用钢的大气腐蚀模型研究综述[J]. 哈尔滨工业大学学报, 2020, 52(8):1-9.  
JIA CH, SHAO Y S, GUO L H, et al. A review of atmospheric corrosion models of building structural steel[J]. Journal of Harbin Institute of Technology, 2020, 52(8): 1-9.
- [2] 朱振寰. 基于可靠度的在役水工钢闸门锈蚀后工作性能评估研究[D]. 南昌:南昌大学,2020.  
ZHU ZH H. Research on the evaluation of working behavior of in-service hydraulic steel gate after corrosion based on reliability [D]. Nanchang: Nanchang University, 2020.
- [3] 王达磊,彭博,潘玥,等. 基于深度神经网络的锈蚀图像分割与定量分析[J]. 华南理工大学学报(自然科学

- 版), 2018, 46(12): 121-127, 146.
- WANG D L, PENG B, PAN Y, et al. Segmentation and quantitative analysis of corrosion Images based on deep neural networks[J]. Journal of South China University of Technology (Natural Science Edition), 2018, 46(12): 121-127, 146.
- [4] 陆廷杰, 刘东海, 齐志龙. 基于深度学习的水下钢结构锈蚀识别与评价[J]. 天津大学学报(自然科学与工程技术版), 2023, 56(7): 713-722.
- LU T J, LIU D H, QI ZH L. Identification and evaluation of underwater steel structure corrosion based on deep learning [J]. Journal of Tianjin University (Natural Science and Engineering Technology Edition), 2023, 56(7): 713-722.
- [5] 郭浩然, 郭继昌, 汪显东. 面向水下场景的轻量级图像语义分割网络[J]. 浙江大学学报(工学版), 2023, 57(7): 1278-1286, 1296.
- GUO H R, GUO J CH, WANG Y D. Lightweight image semantic segmentation network for underwater scenes[J]. Journal of Zhejiang University (Engineering Science), 2023, 57(7): 1278-1286, 1296.
- [6] 任凤雷, 杨璐, 周海波, 等. 基于改进 BiSeNet 的实时图像语义分割[J]. 光学精密工程, 2023, 31(8): 1217-1227.
- REN F L, YANG L, ZHOU H B, et al. Real-time image semantic segmentation based on improved BiSeNet[J]. Optics and Precision Engineering, 2023, 31(8): 1217-1227.
- [7] 刘宇, 雷雪梅. 融合 MobileNetV3 特征的结构化剪枝方法[J]. 上海交通大学学报, 2023, 57(9): 1203-1213.
- LIU Y, LEI X M. Structured pruning method based on MobileNetV3 features[J]. Journal of Shanghai Jiao Tong University, 2023, 57(9): 1203-1213.
- [8] 徐健, 胡道杰, 刘秀平, 等. 基于改进型 RFB-MobileNetV3 的棉杂图像检测[J]. 纺织学报, 2023, 44(1): 179-187.
- XU J, HU D J, LIU X P, et al. Cotton miscellaneous image detection based on improved RFB-MobileNetV3[J]. Journal of Textile Research, 2023, 44(1): 179-187.
- [9] ZHANG S, FU H, YAN Y, et al. Attention guided network for retinal image segmentation [C]. Medical Image Computing and Computer Assisted Intervention-MICCAI 2019: 22nd International Conference, Shenzhen, China, October 13-17, 2019, Proceedings, Part I 22. Springer International Publishing, 2019: 797-805.
- [10] 李承昊, 茹乐, 何林远, 等. 一种可变锚框候选区域网络的目标检测方法[J]. 北京航空航天大学学报, 2020, 46(8): 1610-1617.
- LI CH H, RU L, HE L Y, et al. An object detection method for candidate area networks with variable anchor frame [J]. Journal of Beijing University of Aeronautics and Astronautics, 2020, 46(8): 1610-1617.
- [11] 吴晓建, 危一华, 王爱春, 等. 基于融合 Dropout 与注意力机制的 LSTM-GRU 车辆轨迹预测[J]. 湖南大学学报(自然科学版), 2023, 50(4): 65-75.
- WU X J, WEI Y H, WANG AI CH, et al. LSTM-GRU vehicle trajectory prediction based on fusion of Dropout and attention mechanism [J]. Journal of Hunan University (Natural Science Edition), 2023, 50(4): 65-75.
- [12] 刘艳菊, 王秋霖, 赵开峰, 等. 基于卷积神经网络的热轧钢条表面实时缺陷检测[J]. 仪器仪表学报, 2021, 42(12): 211-219.
- LIU Y J, WANG Q J, ZHAO K F, et al. Real-time defect detection on the surface of hot-rolled steel strips based on convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2021, 42(12): 211-219.
- [13] 王凌云, 李婷宜, 李阳, 等. 基于 FEF-DeepLabV3+ 的电力金具锈蚀分割方法[J]. 电子测量与仪器学报, 2023, 37(3): 166-176.
- WANG L Y, LI T Y, LI Y, et al. Corrosion segmentation method for power fittings based on FEF-DeepLabV3+[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(3): 166-176.
- [14] 刘雪, 沈长盈, 吕学泽, 等. 基于改进 MobileNetV3-Large 的鸡蛋新鲜度识别模型[J]. 农业工程学报, 2022, 38(17): 196-204.
- LIU X, SHEN CH Y, LYU X Z, et al. Egg freshness recognition model based on improved MobileNetV3-Large[J]. Transactions of the CSAE, 2022, 38(17): 196-204.
- [15] MOON C I, LEE O. Skin microstructure segmentation and aging classification using CNN-based models [J]. IEEE Access, 2021, 10: 4948-4956.
- [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. Springer International Publishing, 2015: 234-241.
- [17] ALHANOUF A, BELGACEM B Y, HAIKEL A. MobileUNetV3—A combined UNet and MobileNetV3 architecture for spinal cord gray matter segmentation [J]. Electronics, 2022, 11(15): 2388.
- [18] SUN K, CHEN Y, CHAO Y, et al. A retinal vessel



segmentation method based improved U-Net model[J]. Biomedical Signal Processing and Control, 2023, 82: 104574.

- [19] 陈法法,成孟腾,杨蕴鹏,等.融合双注意力机制和 U\_Net 网络的锈蚀图像分割[J].西安交通大学学报,2021,55(12):119-128.

CHEN F F, CHENG M T, YANG Y P, et al. Rust image segmentation based on dual attention mechanism and U\_Net network [J]. Journal of Xi'an Jiaotong University, 2021, 55(12): 119-128.

- [20] 王慧赢,王春平,付强,等.面向嵌入式平台的轻量级光学遥感图像舰船检测[J].光学学报,2023,43(12):121-134.

WANG H Y, WANG CH P, FU Q, et al. Lightweight optical remote sensing image ship detection for embedded platform [J]. Acta Optica Sinica, 2023, 43 ( 12 ): 121-134.

- [21] 倪有豪,陆欢,季超,等.基于语义分割的桥梁锈蚀病害识别对比分析[J].东南大学学报(自然科学版),2023,53(2):201-209.

NI Y H, LU H, JI CH, et al. Comparative analysis of bridge rust disease identification based on semantic segmentation[J]. Journal of Southeast University (Natural Science Edition), 2023, 53(2): 201-209.

## 作者简介



陈法法,2008年于太原理工大学获得硕士学位,2013年于重庆大学获得博士学位,现任三峡大学机械与动力学院教授、硕士生导师,主要研究方向为水工金属结构病害检测与修复等。

E-mail: chenfafa2005@126.com

**Chen Fafa** received his M. Sc. degree from Taiyuan University of Technology in 2008 and received Ph. D. degree from Chongqing University in 2013. He is now an associate professor and supervisor for Master's student in China Three Gorges University. His main research interests include the detection and repair of hydraulic metal structural diseases.



董海飞(通信作者),2021年于塔里木大学获得学士学位,现为三峡大学硕士生,主要研究方向为水工金属结构病害检测与修复。

E-mail: jia6653007@163.com

**Dong Haifei** (Corresponding author) received his B. Sc. degree from Tarim University in 2021. He is now a M. Sc. candidate in China Three Gorges University. His main research interests include the detection and repair of hydraulic metal structural diseases.