

# 控制与决策

Control and Decision

## 基于改进U-Net网络的齿轮点蚀测量

王四军, 秦毅, 奚德君

引用本文:

王四军, 秦毅, 奚德君. 基于改进U-Net网络的齿轮点蚀测量[J]. *控制与决策*, 2022, 37(12): 3233–3239.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0763>

---

## 您可能感兴趣的其他文章

### Articles you may be interested in

#### 基于三端注意力机制的视网膜血管分割算法

Improved U-Net based on three-terminal attention mechanism for retinal vessel segmentation

*控制与决策*. 2022, 37(10): 2505–2512 <https://doi.org/10.13195/j.kzyjc.2021.0435>

#### 自适应感受野网络的行人重识别

Adaptive receptive network for person re-identification

*控制与决策*. 2022, 37(1): 119–126 <https://doi.org/10.13195/j.kzyjc.2020.0505>

#### 基于可变形卷积的孪生网络目标跟踪算法

Target tracking based on deformable convolution siamese network

*控制与决策*. 2022, 37(8): 2049–2055 <https://doi.org/10.13195/j.kzyjc.2021.0088>

#### 基于双分支特征融合的场景文本检测方法

A scene text detection based on dual-path feature fusion

*控制与决策*. 2021, 36(9): 2179–2186 <https://doi.org/10.13195/j.kzyjc.2020.0002>

#### 复杂背景下全景视频运动小目标检测算法

Panoramic video motion small target detection algorithm in complex background

*控制与决策*. 2021, 36(1): 249–256 <https://doi.org/10.13195/j.kzyjc.2019.0686>

# 基于改进U-Net网络的齿轮点蚀测量

王四军, 秦毅<sup>†</sup>, 奚德君

(重庆大学机械与运载工程学院, 重庆 400044)

**摘要:** 针对U-Net存在的小目标分割精度低、计算复杂度高、收敛慢的问题,构建基于空洞卷积和重构采样单元的U-Net网络(DSU-Net)。在DSU-Net中,为增大图像特征提取的感受野并融合多尺度信息,设计具有不同膨胀率空洞卷积层;针对池化过程丢失大量语义信息的缺点,构建将池化与卷积相结合的采样单元,并运用深度可分离卷积进行特征提取,从而增强神经网络的特征提取能力并降低计算成本。两个公开医学图像数据集的实验结果表明,在IoU、Dice Coeff和F1 Score三个评价指标上,DSU-Net较U-Net、ResU-Net、R2U-Net和U-Net++有着更好的分割性能。最后,将DSU-Net应用于齿轮点蚀的视觉测量,结果表明所提出方法能够更加精确地计算出齿轮点蚀面积率,从而解决了齿轮接触疲劳试验中高效准确检测齿轮失效的难题。

**关键词:** 图像分割; 空洞卷积; 深度可分离卷积; 重构采样单元; 齿轮点蚀; 视觉测量

中图分类号: TP391 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0763

引用格式: 王四军,秦毅,奚德君. 基于改进U-Net网络的齿轮点蚀测量[J]. 控制与决策, 2022, 37(12): 3233-3239.

## Gear pitting measurement based on improved U-Net network

WANG Si-jun, QIN Yi<sup>†</sup>, XI De-jun

(College of Mechanical and Vehicle Engineering, Chongqing University, Chongqing 400044, China)

**Abstract:** Aiming at the problems of low segmentation accuracy of small targets, high computational complexity, and slow convergence in the U-Net, an U-Net network based on dilated convolution and reconstructed sampling units (DSU-Net) is constructed. In the DSU-Net, in order to increase the receptive field of image feature extraction and fuse multi-scale information, dilated convolutional layers with different dilation rates are designed; in view of the shortcoming of losing a large amount of semantic information during the pooling process, sampling units which combine pooling and convolution are constructed, and depthwise separable convolution is used for feature extraction, thereby enhancing the feature extraction capability of the neural network and reducing the computational cost. The experimental results of two public medical image datasets show that DSU-Net has better segmentation performance than the U-Net, the ResU-Net, the R2U-Net and the U-Net++ on the three metrics of IoU, Dice Coeff and F1 Score. Finally, the DSU-Net is applied to the visual measurement of gear pitting. The results show that the proposed method can calculate the gear pitting area ratio more accurately, so as to solve the problem of efficiently and accurately detecting gear failure in the gear contact fatigue test.

**Keywords:** image segmentation; dilated convolution; depthwise separable convolution; reconstructed sampling units; gear pitting; visual measurement

## 0 引言

齿轮箱是机械设备中常用的运动和动力传递装置,被广泛应用于工业、农业、国防、航空航天等诸多领域。在齿轮箱发生的故障中,由齿轮引起故障的概率高达60%,可以说齿轮是齿轮箱中最易损坏的机械零部件,其中齿轮疲劳点蚀是齿轮最常见的失效形式之一。齿轮在长期运转工作后,其啮合面会受到接

触疲劳破坏,产生金属材料脱落,形成早期点蚀。如果不及时发现并处理,齿面点状小坑会进一步扩大,甚至导致断齿,造成严重的经济损失和设备故障<sup>[1]</sup>。齿轮点蚀面积率这一指标通常被用于衡量齿轮寿命和齿轮健康状态,尤其是在齿轮接触疲劳测试中,是评价齿轮是否失效的重要依据。目前没有有效的方法或测试仪器来定量测量齿轮点蚀面积率,只能依靠具

收稿日期: 2021-04-30; 录用日期: 2021-07-30.

基金项目: 国家重点研发计划项目(2018YFB2001300); 重庆市研究生科研创新项目(CYB21010).

责任编辑: 赵春晖.

<sup>†</sup>通讯作者. E-mail: qy\_808@cqu.edu.cn.

有相关资质的专家进行人工观察和检测,该方法存在主观臆断性,效率低、成本高,无法满足现代工业生产的要求.因此,研究齿轮点蚀测量方法具有十分重要的意义.本文将探索一种基于计算机视觉的测量方法,可以自动准确地测量出齿轮点蚀面积率.

在信息时代背景下,计算机视觉技术作为当前一种前沿技术,经过不断创新和完善,逐渐被广泛应用于工业缺陷检测领域.齿轮点蚀面积率测量的关键,在于如何准确分割有效齿面区域和点蚀区域.传统图像分割方法在具有复杂背景或非结构化形状的缺陷检测任务中往往无法实现高鲁棒性,常见的有阈值分割算法、边缘分割算法及区域生长算法等<sup>[2-4]</sup>.由于齿轮点蚀图像具有其自身特点,不同等级的点蚀图像灰度、纹理、形状和面积大小信息差异较大,故传统图像分割方法应用在点蚀面积率测量中具有一定局限性.随着深度学习理论和计算机技术的高速发展,具有特征表示学习能力的深度卷积神经网络(DCNNs)在图像分割领域中得到了广泛应用.例如,文献[5]利用卷积神经网络的深层结构检测不同条件下(例如强光点、阴影和非常薄的裂缝)的混凝土裂缝.文献[6]开发了一个新的大规模数据集,并提出基于卷积神经网络的道路损伤检测和分类模型.文献[7]提出了一种基于卷积神经网络的层级化智能故障诊断算法,以适应旋转机械设备复杂的工作环境及工况.文献[8]提出了一种轻量级的多尺度多路径集成卷积神经网络模型,以较少的参数和计算量取得了更好的性能.

U-Net<sup>[9]</sup>是一种基于卷积神经网络的图像分割模型,自2015年被提出以来,便被广泛应用于医学成像研究,并取得了一定的效果.为了适应不同对象及成像模式,许多U-Net改进网络被逐渐提出,例如将U-Net与残差网络相结合的ResU-Net,以及基于递归

神经网络的R2U-Net<sup>[10]</sup>等.U-Net网络由于具有结构简单、分割性能较好等优点,被逐渐尝试应用于各类工程检测领域.例如,文献[11]提出了一种基于U-Net网络的多任务学习的建筑地物语义分割方法;文献[12]提出了一种结合条件生成对抗网络的道路图像裂缝检测的U-Net分割方法;文献[13]利用U-Net强大的编码和解码功能实现地震断层图像的自动识别;文献[14]提出了一种基于多特征融合的U-Net高炉炉料矿石图像分割方法.上述方法尽管取得了较好的分割效果,但分割对象多为目标区域形状和面积差异性较小的图像,且模型计算复杂度较高,对于齿轮点蚀图像分割具有一定的局限性.因此,为开发适应齿轮点蚀测量的分割网络,解决传统齿轮点蚀测量效率低、成本高、精度低等系列问题,提出一种基于U-Net的齿轮点蚀分割网络DSU-Net.本文的主要贡献归纳如下:

1) 设计了多层具有不同膨胀率的空洞卷积层,在不损失空间分辨率的前提下增大图像特征提取的感受野,提高网络模型对于不同尺度上特征信息的融合能力.

2) 构建了将池化层与卷积层相结合的采样单元,并在下采样过程中运用深度可分离卷积进行特征提取,增强神经网络的特征提取能力以及降低计算成本,改善池化过程丢失大量语义信息的缺点.

3) 所提出方法在两个公开医学图像数据集的多个指标上达到最优或者可比较的结果,并能够很好地应用于齿轮点蚀面积率的计算,从而解决了齿轮接触疲劳试验中高效准确检测齿轮失效的难题.

## 1 DSU-Net 齿轮点蚀分割网络

本文提出的齿轮点蚀分割网络DSU-Net如图1所示.




图1 齿轮点蚀分割网络DSU-Net整体框架

齿轮点蚀分割网络 DSU-Net 整体框架与 U-Net 网络的编码器解码器结构类似, 模型深度为 4, 通道数依次为 64、128、256 和 512。首先, 在图像输入、紧接的两次下采样以及三次上采样之后都设计了空洞卷积层<sup>[15]</sup>, 形成对称结构, 增大了图像特征提取的感受野, 提升了远程信息的获取能力。空洞卷积的膨胀率随着通道数的增加而逐渐增大, 依次为 2、3、4, 在下采样和上采样过程中逐渐融合了不同尺度上的特征信息。然后, 构建了将池化层 (MaxPooling) 与卷积层相结合的 P-C 下采样单元, 以及 UpSampling 层与卷积层相结合的 S-C 上采样单元。同时, 在下采样单元中运用深度可分离卷积进行特征提取, 增强了网络模型的特征提取能力并降低了计算成本<sup>[16]</sup>。卷积层的加入弥补了 MaxPooling 层和 UpSampling 层不具有可训练性的缺点, 因而能够减少采样过程中特征信息的损失, 有效提高了对于微小点蚀的分割精度。

### 1.1 P-C 下采样单元

在 U-Net 模型结构中, 下采样过程采用的是最大池化操作, 在降低特征输出尺度的同时会丢失大量语义信息, 影响微小点蚀的分割精度。而 DSU-Net 针对齿轮点蚀图像具有不同形状和面积点蚀区域的特点, 构建了将最大池化与深度可分离卷积相结合的 P-C 下采样单元, 如图 2(a) 所示, 实现下采样过程的可学习性。特征图首先分别通过最大池化层和深度可分离卷积层。深度可分离卷积相比普通卷积减少了训练参数量, 节约计算成本, 防止过拟合。接着对池化和卷积运算后的两个特征图分别使用  $1 \times 1$  卷积运算, 实现信息的跨通道整合和交互, 并增加非线性特性。最后, 将输出的特征图沿通道拼接起来输送到下一卷积层, 实现信息融合, 提升网络的表达能力。该过程可以用公式表示如下:

$$F'_1 = [\sigma(f^{1 \times 1}(\text{MP}(F_1))); \sigma(f^{1 \times 1}(\text{DS}(F_1)))] \quad (1)$$

其中:  $F_1$  和  $F'_1$  分别代表输入特征和输出特征, MP 表示 MaxPooling 操作, DS 表示深度可分离卷积层,  $f^{1 \times 1}$  表示卷积核为  $1 \times 1$  的卷积操作,  $\sigma$  表示 ReLU 激活函数, “;” 表示通道拼接。

DS( $F$ ) 的计算过程可表示如下:

$$\text{PointwiseConv}(W_p, y)_{(i,j)} = \sum_c^C W_c \cdot y_{(i,j,c)} \quad (2)$$

$$\text{DepthwiseConv}(W_d, y)_{(i,j)} = \sum_{(k,l)}^{(K,L)} W_{(k,l)} \odot y_{(i+k,j+l)} \quad (3)$$

$$\text{DS}(F)_{(i,j)} =$$

$$\text{PointwiseConv}(W_p, \text{DepthwiseConv}(W_d, y)_{(i,j)})_{(i,j)} \quad (4)$$

其中:  $K(k)$ 、 $L(l)$  和  $C(c)$  分别表示特征图的高度、宽度和通道数;  $(i, j)$  表示像素点的索引;  $W_p$ 、 $W_c$ 、 $W_d$  和  $W_{(k,l)}$  分别表示学习到的权重;  $y$  表示像素值; 符号  $\cdot$  表示数乘,  $\odot$  表示逐元素相乘。

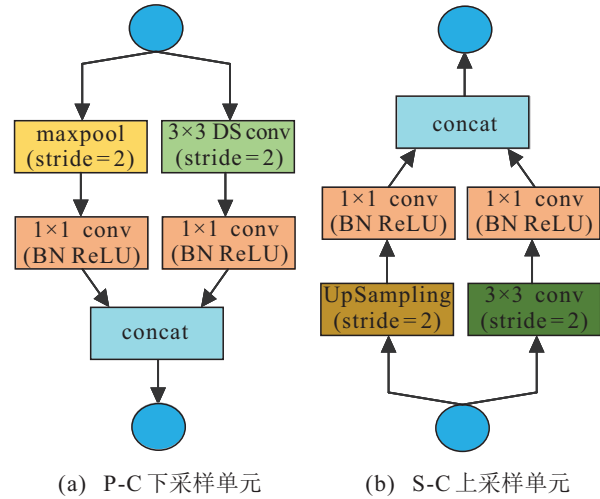


图 2 重构采样单元

### 1.2 S-C 上采样单元

与 P-C 下采样单元类似, 上采样过程也作了相应的修改, 如图 2(b) 所示。在 S-C 上采样单元中, 特征图首先分别通过 UpSampling 层和转置卷积层。UpSampling 可看作是池化的逆操作, 而转置卷积则是正常卷积的逆操作。同样分别进行  $1 \times 1$  卷积运算, 并将输出的两个特征图沿通道拼接起来作为下一卷积层的输入。该过程可以如下表示:

$$F'_2 = [\sigma(f^{1 \times 1}(\text{US}(F_2))); \sigma(f^{1 \times 1}(\text{UP}(F_2)))] \quad (5)$$

其中:  $F_2$  和  $F'_2$  分别代表输入特征和输出特征; US 表示 UpSampling 操作; UP 表示转置卷积层。

UP( $F$ ) 的计算过程可表示如下:

$$\text{UP}(F)_{(i,j)} = \sum_{(k,l,c)}^{(K,L,C)} W_{(k,l,c)} \cdot y_{(i+k,j+l,c)} \quad (6)$$

## 2 公开数据集对比实验

医学图像与齿轮点蚀图像均具有语义简单、结构固定、边界模糊等特点, 表现出一定程度上的相似性。由于 U-Net 在医学图像分割上有较好的表现, 本文首先使用 2 个公开医学图像数据集来验证 DSU-Net 的分割性能, 包括 Skin Lesion 数据集和 CVC ClinicDB 数据集。Skin Lesion 数据集<sup>[17]</sup> 是从 2018 年国际皮肤成像协会主办的一次图像分割挑战赛中获得的, 该数据集融合了上一届比赛所用的数据集和 HAM10000 数据集, 总共包含 2 594 个不同类型的皮

肤损伤图像,这些图像的分辨率不尽相同,但出于计算目的,它们都被调整到256×192. CVC ClinicDB数据集<sup>[17]</sup>是从29个结肠镜检查视频序列的帧中提取出来的,仅考虑带有息肉的图像,总共有612张,这些

图像最初的分辨率为384×288,最后同样被调整到256×192. 由于验证集可调整模型的超参数以及用于模型泛化能力的初步评估,将训练集、验证集和测试集之间的划分比例设为8:1:1,具体信息如表1所示.

表1 公开医学图像数据集

数据集	原始分辨率	输入分辨率	图像总数目	训练集	验证集	测试集
Skin Lesion	多种	256×192	2 594	2 075	259	260
CVC ClinicDB	384×288	256×192	612	489	61	62

2.1 训练方法

在本次实验中,使用Dice Loss作为网络的损失函数. Dice系数<sup>[18]</sup> (Dice Coeff)是一种集合相似度度量函数,通常用于计算两个样本的相似度(值的范围为[0,1]),Dice Coeff定义如下:

$$\text{Dice Coeff} = \frac{2|X \cap Y|}{|X| + |Y|} \quad (7)$$

其中: X和Y分别表示不同模型方法的分割结果和真实标签,当这两结果完全重合时Dice Coeff = 1表示最完美分割结果,否则相反. Dice Loss和Dice Coeff的关系是:

$$\text{Dice Loss} = 1 - \text{Dice Coeff} \quad (8)$$

实验是在一台带有英特尔Xeon E5-2687处理器、32 GB运行内存和NVIDIA GTX 1080Ti显卡的台式计算机上进行的. 所有的算法均使用Python 3编程语言,并通过带有Tensorflow后端的Keras框架实现. 训练过程采用同步SGD优化,初始学习率设置为0.001,权值衰减设置为0.0005,冲量设置为0.9,每个训练批次包含4幅图像. 由于Skin Lesion数据集较大,其迭代次数设置为300,在CVC ClinicDB数据集上的迭代次数设置为400.

2.2 评价指标

除了使用Dice Coeff外,还引入了以下指标来评价分割模型的性能.

1) IoU. IoU<sup>[19]</sup>也被称为Jaccard系数,是分割模型性能的基本评价指标,表示分割结果与真实标签之间的重合度.

2) F1 Score. F1 Score<sup>[20]</sup>是用来衡量分割模型精确度的指标,可看作是模型准确率和召回率的一种加权平均.

2.3 在医学图像数据集上的实验


为了更好地验证DSU-Net的分割性能,首先在两个医学图像数据集上与U-Net及其他3种改进网络(ResU-Net、R2U-Net和U-Net++)进行了实验对比. 为了比较各种模型的计算复杂度,表2给出5种分割模

型的训练参数量. 由表2可知,DSU-Net具有最小的训练参数量,不到U-Net参数量的一半,因而可以大大降低计算复杂度.


表2 5种分割模型的训练参数量

DSU-Net	U-Net	ResU-Net	R2U-Net	U-Net++
14 475 205	31 059 141	67 370 245	70 542 661	36 193 797

在训练阶段,比较了5种分割模型的Dice损失函数,如图3所示. 在Skin Lesion和CVC ClinicDB两个数据集上,DSU-Net相比于其他4种模型收敛更快,且其训练损失更小.



(a) Skin Lesion



(b) CVC Clinic DB

图3 不同模型在训练阶段的Dice损失曲线

表3 不同模型在两个数据集上的测试结果 %

	Skin Lesion			CVC ClinicDB		
	IoU	Dice Coeff	F1 Score	IoU	Dice Coeff	F1 Score
DSU-Net	75.21	85.35	86.65	71.85	83.76	86.92
U-Net	74.17	84.20	85.71	69.83	81.87	84.72
ResU-Net	72.11	82.73	84.24	65.43	78.62	81.71
R2U-Net	74.06	84.23	85.79	69.94	82.86	85.79
U-Net++	69.42	81.48	83.57	63.54	76.51	81.95




图4 不同模型在两个数据集上的分割图像结果

为了验证DSU-Net模型的分割性能,在两个数据集上进行了验证,通过重复实验求平均后得到的测试结果如表3所示,典型分割结果如图4所示。

由表3测试数据可以看出,DSU-Net的性能指标达到最优。在Skin Lesion数据集上,IoU为0.7521、Dice Coeff为0.8535、F1 Score为0.8665;而在CVC ClinicDB数据集上,IoU为0.7185、Dice Coeff为0.8376、F1 Score为0.8692。通过比较图4中的分割图像结果可知,DSU-Net的分割结果更接近真实标签,表明DSU-Net较其他4种模型具有更强的特征表达能力,对于小目标具有较好的分割性能。

### 2.4 消融实验

为了验证所设计的空洞卷积层和重构采样单元分别在DSU-Net中的作用及效果,在Skin Lesion数据集上进行了消融实验。DU-Net表示在DSU-Net上保留空洞卷积层并用原U-Net采样单元替代重构采样单元后的网络模型。SU-Net表示在DSU-Net上保留重构采样单元并去掉空洞卷积层后的网络模型。Net表示同时去掉上述两项改进后的网络模型。消融实验测试结果如表4所示。

表4 在Skin Lesion数据集上的消融实验结果 %

	IoU	Dice Coeff	F1 Score
DSU-Net	75.21	85.35	86.65
DU-Net	74.42	84.59	85.97
SU-Net	72.35	83.24	84.76
Net	71.84	82.85	84.31

由表4可以看出,空洞卷积层和重构采样单元的构建分别对网络模型的分割性能有一定的提升,其中空洞卷积层所起作用更大。DSU-Net结合了两者的优点,因此具有最好的分割能力。

## 3 在齿轮点蚀测量中的应用

### 3.1 齿轮点蚀图像获取

本文获取齿轮点蚀图像数据集(Gear Pitting)的实验装置如图5所示。

首先用透明有机玻璃板代替试验齿轮箱盖板,然




图5 齿轮点蚀图像采集装置

后将带有柔性可调节支架的图像采集装置固定到齿轮接触疲劳试验台上,以灵活调节相机的拍摄角度,最后通过控制台、CCD工业相机(型号MER-131-210U3C)、LED光源和笔记本电脑等设备获得了810张齿轮点蚀图像,并在Pycharm中使用Labelme图像标注工具制作了相对应的标签。另外,所有图片的分辨率都被调整为256×256。齿轮点蚀数据集的具体信息如表5所示。

表5 齿轮点蚀图像数据集

数据集	原始分辨率	输入分辨率	图像总数目	训练集	验证集	测试集
Gear Pitting	256×256	256×256	810	648	81	81

### 3.2 点蚀面积率相对误差

除了IoU、Dice Coeff和F1 Score这3个指标以外,还提出了点蚀面积率相对误差Re来评价网络的分割精度。首先统计有效工作齿面的像素数 $A_p$ 和点蚀区域的像素数 $A_t$ ,然后通过如下公式计算齿轮点蚀面积率:

$$AR = \frac{A_t}{A_p} \times 100\% \quad (9)$$

根据式(9)可以计算出齿轮的实际点蚀面积率 $AR_a$ 和检测到的点蚀面积率 $AR_p$ ,进而可以计算出相对误差

$$Re = \left| \frac{AR_p - AR_a}{AR_a} \right| \times 100\% \quad (10)$$

可通过统计多张测试图像的相对误差Re,计算出平均相对误差 $\overline{Re}$ ,以比较不同模型在齿轮点蚀图像上的分割性能优劣。

3.3 在齿轮点蚀图像数据集上的实验

利用获取的齿轮点蚀图片数据集,采用DSU-Net测量齿轮点蚀面积率.首先需要将齿轮点蚀图像进行有效齿面和点蚀区域的分割.图6所示是5种分割模型在分别进行有效齿面分割和点蚀分割的Dice训练损失曲线.可以看出,在Dice训练损失上,DSU-Net相比于其他4个分割模型收敛更快,且其训练损失更小.

类似地,利用测试集对5种分割模型进行了验证,得到有效齿面和点蚀分割的评价指标如表6所示,典型分割结果如图7所示.由测试数据可以看出,DSU-Net在有效齿面分割和点蚀分割上均表现出最佳的分割能力,前者IoU为0.9348、Dice Coeff为0.9683、F1 Score为0.9827;而后者IoU为0.7969、Dice Coeff为0.8927、F1 Score为0.9254.通过比较图7分割图像结果可知,DSU-Net的分割结果更接近真实标签,表明DSU-Net较其他4种模型充分地利用了图像的特征,表现出最好的分割性能.

得到齿轮点蚀测试图像的有效齿面和点蚀区域的分割结果后,可根据公式计算出每张图像的点蚀面积率,然后与实际的点蚀面积率进行比较,得到点蚀分割相对误差率Re.为了更好地评估不同模型在齿

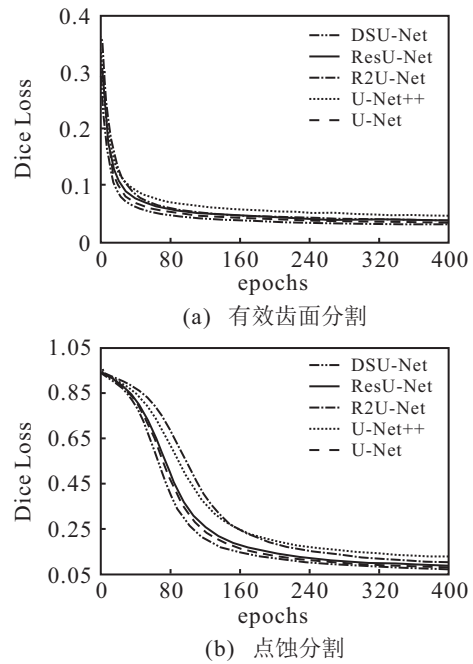


图6 不同模型在训练阶段的Dice损失曲线

轮点蚀图像上的分割性能,取50张测试图像的点蚀分割相对误差率Re的平均值作为评价依据,如表7所示.可以看出,本文所提出的DSU-Net模型性能最优,平均相对误差率仅为5.07%,表明能够准确地计算出齿轮点蚀面积率,为齿轮接触疲劳试验中齿轮失效的检测提供了有效依据.

表6 不同模型在齿轮点蚀数据集上的测试结果

	有效齿面分割			点蚀分割		
	IoU	Dice Coeff	F1 Score	IoU	Dice Coeff	F1 Score
DSU-Net	<b>93.48</b>	<b>96.83</b>	<b>98.27</b>	<b>79.69</b>	<b>89.27</b>	<b>92.54</b>
U-Net	92.29	95.71	97.22	78.36	88.00	91.60
ResU-Net	91.57	95.57	96.89	78.25	88.02	91.47
R2U-Net	91.02	95.64	97.25	77.78	87.46	91.33
U-Net++	91.11	95.35	96.74	76.56	86.68	91.15




图7 不同模型在齿轮点蚀数据集上的分割图像结果

表7 不同模型在齿轮点蚀图像上的 $\overline{Re}$ 值 %

DSU-Net	U-Net	ResU-Net	R2U-Net	U-Net++
5.07	5.86	6.14	6.42	6.65

## 4 结论

针对齿轮点蚀分割问题,本文提出了基于空洞卷积和重构采样单元U-Net网络的分割模型.首先,设计了多个空洞卷积层,增大了图像特征提取的感受野.空洞卷积的膨胀率随着通道数的增加而逐渐增大,使网络模型融合了不同尺度上的特征信息.其次,针对池化过程不具有可训练性并丢失大量语义信息的缺点,构建了将池化与卷积相结合的采样单元,并运用深度可分离卷积进行特征提取,有效提高了对于齿轮微小点蚀的分割精度.最后,通过实验分析验证了本文所提出方法的有效性.DSU-Net不仅在医学图像数据集上有较好的表现,还实现了对齿轮点蚀图像中有效齿面和点蚀区域的精确分割,为高效准确计算齿轮点蚀面积率提供了保障,从而解决了齿轮接触疲劳试验中检测齿轮失效的难题.

## 参考文献(References)

- [1] Xi D J, Qin Y, Luo J, et al. Multipath fusion mask R-CNN with double attention and its application into gear pitting detection[J]. IEEE Transactions on Instrumentation and Measurement, 2021, 70: 1-11.
- [2] Zhang W H, Wang X, You W, et al. RESLS: Region and edge synergetic level set framework for image segmentation[J]. IEEE Transactions on Image Processing, 2020, 29: 57-71.
- [3] Wang L, Xu L Y, Yu J, et al. Context-aware edge similarity segmentation algorithm of time series[J]. Cluster Computing, 2016, 19(3): 1421-1436.
- [4] Drever L, Roa W, McEwan A, et al. Iterative threshold segmentation for PET target volume delineation[J]. Medical Physics, 2007, 34(4): 1253-1265.
- [5] Cha Y J, Choi W, Büyükoztürk O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(5): 361-378.
- [6] Maeda H, Sekimoto Y, Seto T, et al. Road damage detection and classification using deep neural networks with smartphone images[J]. Computer-Aided Civil and Infrastructure Engineering, 2018, 33(12): 1127-1141.
- [7] Qu J L, Yu L, Yuan T, et al. A hierarchical intelligent fault diagnosis algorithm based on convolutional neural network[J]. Control and Decision, 2019, 34(12): 2619-2626.
- [8] Wang X S, Bao A C, Lv E H, et al. Multiscale multipath ensemble convolutional neural network[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2021, 51(9): 5918-5928.
- [9] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[C]. Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. 2015: 234-241.
- [10] Alom M Z, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[J/OL]. 2018, arXiv: 1802.06955.
- [11] Liu S W, Cui Z Y, Li D Y. Multi-task learning for building object semantic segmentation of remote sensing image based on Unet network[J]. Remote Sensing for Land & Resources, 2020, 32(4): 74-83.
- [12] Zhang H C, Peng B, Xu W Q. Road crack detection based on UNet++ and conditional generative adversarial nets[J]. Journal of Computer Applications, 2020, 40(S2): 158-161.
- [13] Xi Y J, Li K W, Xu Y H, et al. A SPD-UNet model for seismic fault image identification[J]. Computer Engineering, 2021, 47(12): 249-255.
- [14] Ye F Q, Jiang C H, Zhou H, et al. Blast furnace charge ore image segmentation based on Unet of multi-layer feature fusion[C]. Proceedings of 2020 China Automation Conference (CAC2020). Shanghai, 2020: 1-6.
- [15] Wang S H, Hu S Y, Cheah E, et al. U-Net using stacked dilated convolutions for medical image segmentation[J/OL]. 2020, arXiv: Image and VideoProcessing.
- [16] Kaiser L, Gomez A N, Chollet F. Depthwise separable convolutions for neural machine translation[J/OL]. 2017, arXiv: 1706.03059.
- [17] Ibtehaz N, Rahman M S. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation[J]. Neural Networks, 2020, 121: 74-87.
- [18] Luo L, Xue D Y, Feng X L. Automatic segmentation of retinal vessel via compact mixed network[J]. Control and Decision, 2022, 37(2): 353-360.
- [19] Garcia G A, Orts E S, Oprea S, et al. A review on deep learning techniques applied to semantic segmentation[J/OL]. 2017, arXiv: 1704.06857.
- [20] Zhuang J. LadderNet: Multi-path networks based on U-Net for medical image segmentation[J/OL]. 2018, arXiv: 1810.07810.

## 作者简介

王四军(1998—),男,硕士生,从事机器视觉、模式识别的研究, E-mail: wsjwyt@cqu.edu.cn;

秦毅(1982—),男,教授,博士生导师,从事智能故障诊断与预测、大数据处理与人工智能等研究, E-mail: qy\_808@cqu.edu.cn;

奚德君(1992—),女,博士生,从事机器视觉、模式识别的研究, E-mail: xidejun10427@cqu.edu.cn.

(责任编辑:孙艺红)