

文章编号 1004-924X(2024)23-3525-11

融合条形注意力机制的电芯极片 计算机断层图像分割

刘泽芳^{1,2}, 龙超^{1,2}, 刘学栓³, 韩艳^{1,2}, 谭川东^{1,2}, 谭辉¹, 段黎明^{1*}

(1. 重庆大学光电技术及系统教育部重点实验室 ICT 研究中心, 重庆 400044;

2. 重庆大学光电工程学院, 重庆 400044;

3. 火箭军装备部装备项目管理中心, 北京 100085)

摘要:工业计算机断层扫描成像技术(Computed Tomography, CT)检测叠片电芯极片时,在CT图像中分割出极片是关键步骤。然而,由于叠片电芯的极片结构复杂、长宽比大,现有分割方法在速度与精度上难以满足大规模生产检测的需求。为解决这个问题,提出一种融合条形注意力机制的电芯极片CT图像分割网络。该网络主要由主干网络、条形空洞金字塔池化模块(Strip Atrous Spatial Pyramid Pooling, S-ASPP)和解码器模块组成。其中,主干网络设计为轻量型网络MobilenetV2,用于减少网络参数量并提高分割速度;S-ASPP模块中将全局池化设计为条形池化,用于减少条形特征信息的丢失,有效解决欠分割的问题;解码器模块的条形注意力机制用于关注图像中的边缘和细节信息,从而改善边缘模糊的问题。在电芯极片CT数据集上进行学习验证,实验结果表明,本文网络对电芯极片的平均像素分类准确率(mAcc)、平均交互比(mIoU)、参数量和分割速度分别达到了98.62%,89.97%,5.814M,56.94 frame/s。相比DANet, DeepLabV3+, U-Net, HRNet 和 Segnext 网络,本文网络的分割精度最高,分割速度优于DANet, DeepLabV3+, U-Net 和 HRNet 网络,略逊色 Segnext 网络。综合考虑评价指标 mIoU, mAcc, FPS, Parameters(M), 本文方法在保持较低计算成本的同时,显著提升了极片分割的精度和效率,优于目前主流的分割网络。

关键词: X 射线成像; 计算机断层成像; 深度学习; 图像分割; 叠片电芯

中图分类号: TP391.41 **文献标识码:** A **doi:** 10.37188/OPE.20243223.3525

Computed tomography image segmentation of cell pole piece via strip attention mechanism

LIU Zefang^{1,2}, LONG Chao^{1,2}, LIU Xueshuan³, HAN Yan^{1,2},

TAN Chuandong^{1,2}, TAN Hui¹, DUAN Liming^{1*}

(1. ICT Research Center, Key Laboratory of Optoelectronic Technology and Systems of Ministry of Education, Chongqing University, Chongqing 400044, China;

2. College of Optoelectronic Engineering, Chongqing University, Chongqing 400044, China;

3. Project Management Center, Equipment Department of Rocket Force, Beijing 100085, China)

* Corresponding author, E-mail: duanliming@cqu.edu.cn

Abstract: The segmentation of pole pieces in CT images is a crucial step in utilizing industrial computed

收稿日期: 2024-07-28; 修订日期: 2024-09-22.

基金项目: 国家重点研发计划资助项目(No. 2022YFF0706400); 重庆市英才计划资助项目(No. CQYC20210510579)

tomography (CT) to detect the pole pieces of laminated cells. However, the complex structure and high aspect ratio of laminated cells pose challenges for existing segmentation methods, which struggle to meet the speed and accuracy demands of large-scale production. To address this, this paper introduces a novel CT image segmentation network based on a strip attention mechanism. The proposed network comprises a lightweight backbone (MobilenetV2), a Strip Atrous Spatial Pyramid Pooling (S-ASPP) module, and a decoder module. MobilenetV2 reduces network parameters and enhances segmentation speed, while the S-ASPP module employs strip pooling to retain strip feature information, effectively mitigating under-segmentation issues. The strip attention mechanism in the decoder focuses on edge and detail information, improving edge sharpness and detail clarity. Experimental results demonstrate that the proposed network achieves an average pixel classification accuracy (mAcc) of 98.62%, an average intersection over union (mIoU) of 89.97%, a parameter count of 5.814M, and a segmentation speed of 56.94 frame/s. Compared to DANet, DeepLabV3+, U-Net, HRNet, and Segnext, the proposed method achieves the highest segmentation accuracy and outperforms DANet, DeepLabV3+, U-Net, and HRNet in speed, with slightly lower speed than Segnext. Considering mIoU, mAcc, FPS, and parameter count comprehensively, the proposed network significantly enhances segmentation precision and efficiency while maintaining low computational cost, outperforming mainstream segmentation networks.

Key words: X-rays image; computed tomography; deep learning; image segmentation; laminated cell

1 引言

叠片电芯极片具有大长宽比特点,在封装过程中易受工艺影响,存在极片弯曲、对齐不良等问题,最终导致电池内部短路,引发电池自燃,因此,对封装后的电芯极片进行无损检测具有重要意义。工业计算机断层扫描成像技术(Computed Tomography, CT)能够无损且清晰地展示工件内部结构^[1],是检测电芯极片的有效手段。为了实现电芯极片的质量评估,需对CT图像中的极片进行精确分割。对分割后的图像后处理,就可以测量极片对齐度、极间距、极片弯曲度等相关参数,实现极片的质量评估。在此过程中,极片的分割精度决定了后续参数测量的准确程度,因此,实现CT图像中极片的快速准确分割是非常重要的。

传统的图像分割方法主要包括:阈值分割法^[2]、边缘检测法^[3]、聚类分析法^[4]、图论分割法^[5]和区域分割法^[6]等。这些方法主要利用图像的颜色、形状、纹理等低维度信息实现分割,在实际应用中存在精度低、耗时长且无法充分利用图像语义信息等问题。随着卷积神经网络(Convolutional Neural Network, CNN)的发展,

深度学习在图像分割中得到广泛的应用。刘等^[7]提出一种基于两阶段的细胞神经网络对铸件CT图像进行分割,第一阶段细胞神经网络得到一个粗略的分割结果,第二阶段细胞神经网络进一步细化第一阶段细胞神经网络的粗略分割结果,但该方法的分割精度仍有较大的提升空间。针对铸件分割精度问题,赵等^[8]提出一种融合残差模块与混合注意力机制的U-Net^[9]网络进行铸件分割,解决铸件CT图像分割难度大、边缘模糊的问题,该方法在分割精度和边界保持上得到显著提高,分割精度达到97.40%。然而,这些方法都是对铸件外轮廓进行分割,并不适用小目标分割。

针对小目标,Han等^[10]提出了一种基于CNN的缺陷分割方法,首先采用区域建议网络^[11](Region Proposal Network, RPN)获取潜在的缺陷区域,将它处理成相同尺寸的块,作为输入特征传入融合空洞卷积的分割网络中,分割精度达到63.5%。王等^[12]针对金属工件表面的小尺寸缺陷提出一种改进的U-Net语义分割网络,通过引入注意力机制和深度超参数化卷积来提高图像中缺陷目标的显著度,分割精度达到86.74%。Wu等^[13]改进了Mask R-CNN,该方法对低质量

工业 CT 图像的极小目标实现高精度分割,但一般的 Mask R-CNN 在特征提取和计算效率上仍不够理想。

上述方法虽然在多尺度特征融合中有所尝试,但仍未能完全解决图像细节和上下文信息的综合理解问题。因此,研究人员越来越多地关注多尺度特征融合的优化策略。这种方法通过结合来自不同尺度的特征图,不仅能提升模型对目标的分割精度,还能更全面地理解图像内容。随后,基于多尺度特征融合的分割网络如 PSPNet^[14],DeepLab^[15]和 HRNet^[16]等被提出。其中,DeepLab 在多尺度特征提取、边界处理和效率等方面均有显著的优势,并经过一系列优化衍生出 DeepLabV2^[17],DeepLabV3^[18],DeepLabV3+^[19],实现了更高的分割精度。

上述网络直接应用在具有大长宽比特点的叠片电芯极片分割中,存在欠分割、速度慢等问题。因此,本文基于 DeepLabV3+ 网络提出一种融合条形注意力机制的轻量型分割网络。为解决欠分割问题,结合电芯极片的长条形结构特点,通过设计新的 S-ASPP 模块和条形注意力机制提高网络对线性特征的提取能力,避免了相邻

无关信息对分割结果的干扰;为提高网络的分割速度,设计了轻量型网络进行特征提取,在保持网络特征提取能力的同时减少参数量,提高分割速度。

2 构建网络

本文提出的融合条形注意力机制的极片分割网络结构如图 1 所示。所提出的网络结构与 DeepLabV3+ 相似,由主干网络、S-ASPP 和解码器模块组成。图 1 中,首先将预处理后尺寸为 $H \times W$ 的叠片电芯极片 CT 图像作为输入传入主干网络,通过主干网络的卷积层对图像进行特征提取。卷积层中,使用深度可分离卷积对网络参数量进行压缩,加快网络的分割速度。接着,将通过卷积提取的特征图输入到 S-ASPP 模块中,经过并行的卷积操作,捕获多尺度的上下文信息,使得网络在处理不同大小的目标时具有更强的稳定性。然后,将含有多尺度上下文信息的特征图传入针对叠片电芯极片设计的条形注意力机制,为每个通道赋予不同的权重系数。最后,在解码器模块将得到的特征图与含有丰富空间信息的低维特征图进行拼接和上采样得到预测




图 1 融合条形注意力机制的极片分割网络的整体结构

Fig. 1 Overall structure of cell pole piece segmentation network via strip attention mechanism

图像。上采样过程中逐渐恢复特征图的空间分辨率,从而生成与输入图像尺寸相同的高分辨率分割图,每个像素点在分割图中被赋予一个类别标签。

2.1 主干网络

主干网络的作用是对输入的叠片电芯CT图像进行特征提取,为后续的S-ASPP模块和解码器模块提供有效的输入信息。DeepLabV3+的主干网络为Xception,但该结构参数量庞大,需要消耗大量的显存,为了降低计算成本、提高模型的推理速度,本文将主干网络设计为轻量型的MobilenetV2结构,如图2所示。

MobilenetV2网络引入倒残差结构和线性瓶颈结构。倒残差结构与传统残差结构的不同点在于,先将低维特征作为输入扩展到高维,再使用轻量型深度卷积进行特征提取,然后通过线性卷积投影映射回低维特征,进而减少网络参数量。线性瓶颈结构是指进行 1×1 卷积降维时不再使用非线性激活函数ReLU6,而采用线性激活函数,以保留更多的特征信息。




图2 主干网络结构

Fig. 2 Structure of backbone

2.2 S-ASPP模块

S-ASPP模块的主要作用是解决由于感受野大小限制导致网络在电芯极片边界等复杂区域欠分割的问题,其结构如图3所示。该模块包含5个并行分支:1个 1×1 的卷积分支,3个 3×3 空洞率不同的卷积分支和1个条形池化分支。其中, 1×1 的标准卷积用来整合和压缩特征通道,增强局部特征的表达能力;3个空洞率不同的 3×3 卷积分支用来进行不同尺度上的特征提取;条形池化分支用来获取电芯极片的长条形特征。




图3 S-ASPP模块示意图

Fig. 3 Schematic of S-ASPP module

为更好地提取电芯极片的长条形特征,本文将池化过程设计为一种条形池化结构。传统的池化操作($N \times N$ 的池化核)由于池化核固定的原因,在进行电芯极片特征提取时,不可避免会将目标之间或目标与背景的特征信息融合在一起,影响分割结果。除此之外,网络在全局中的长距离信息捕获能力也会受到限制。因此,考虑到电芯极片的特性,模块中使用条形池化,通过调节池化核的尺寸和形状,减少特征信息的丢失。通过多次参数调节,本文的 N 选取20。条形池化的结构示意图如图4所示。

图4中,经过主干网络特征提取后输出尺寸为 $\frac{H}{8} \times \frac{W}{8} \times 32$ 特征图,将图中某一像素所在的行和列经过水平和竖直条纹池化后变为 $\frac{H}{8} \times 1$ 和 $1 \times \frac{W}{8}$ 的特征图。随后,经过卷积对两个输出特征层分别沿着左右和上下进行扩充,扩充后两个特征图尺寸相同,将得到的特征图对应位置进




图 4 条形池化示意图

Fig. 4 Schematic of strip pooling

行逐像素求和得到 $\frac{H}{8} \times \frac{W}{8} \times 32$ 的特征图。最后,通过 1×1 的卷积操作与 sigmoid 函数激活处理后的特征图与原输入图对应像素相乘得到输出结果。经过上述操作,输出特征中的每个像素与输入特征像素所在的行列建立关系,避免在相距较近但无用信息之间建立连接,影响后续的分割结果。

2.3 解码器模块

解码器模块的作用是在保持高级语义信息

的同时,恢复丰富的空间细节,从而得到高质量的语义分割结果。然而,CT 图像不可避免地存在噪声和伪影的问题^[20],这会影响网络的分割结果恢复性能。为更好地在解码过程中恢复图像线性细节的分割结果,本文设计了针对电芯极片的条形注意力 (Strip Attention Mechanism, SA) 机制。通过 SA 机制,生成的特征图不仅能强化图像中的重要区域,还可以捕获图像中的方向特征信息,从而提高网络在分割电芯极片时的性能,其结构如图 5 所示。




图 5 条形注意力机制示意图

Fig. 5 Schematic of strip attention mechanism

图 5 中,将输入特征图同时送入 3 个分支,前两个分支分别是最大池化分支和平均池化分

支,这两个分支根据池化核大小对特征图分别取最大值和平均值,得到最显著信息的特征图

和整体平均的特征图。然后,将得到的两个特征图在通道维度上拼接,拼接特征图与原特征图相乘生成最终的空间权重。第3个分支是条形池化分支,该分支对输入特征图沿着条形池化核长度方向进行池化,提取该方向上的局部特征信息,再经过卷积、扩张得到与输入特征图尺寸相同的特征图,与输入特征图逐点相加生成条形空间权重。最后,对包含不同空间权重的特征层进行拼接、卷积操作,再经过 Sigmoid

函数生成对每个空间位置和特定方向进行加权后的特征图。

3 实 验

3.1 实验设置

数据采集设备为 CD-130BX/ μ CT 微焦点工业 CT,实验参数如表 1 所示,CT 系统如图 6 所示。

表 1 微焦点工业 CT 检测仪参数设置

Tab. 1 Parameter setting of microfocus industrial CT detector

Parameter	Values
Radiation source type	Hamamatsu L10321 microfocus ray source
Detector type	IRUI NDT0505J flat panel detector
Detector pixel size/mm	0.1 $\times$ 0.1
Number of detector units/pixel	1 024 $\times$ 1 024
Tube voltage/kV	90
Tube current/ μ A	92




图 6 CT 扫描系统

Fig. 6 CT scanning system

实验的硬件环境如下:中央处理器为 AMD Ryzen 9 5900X 12-Core Processor,系统内存为 32 GB,图形处理器为 NVIDIA GeForce RTX 3070Ti GPU。软件环境如下:操作系统 Windows 10,编译语言为 Python 3.9,编程框架 torch 2.0.1+torchvision 0.15.2,程序加速库 CUDA 11.7+cuDNN 7.6.5。

本文所提出的网络采用自适应矩估计优化器(Adaptive Moment Estimation, Adam),Batch-size 设置为 2,epoch 设置为 300,初始学习率设置为 0.01,采用指数衰减的方式动态调整学习率,加快网络的收敛速度。

实验对象为刀片电池,如图 7 所示。利用工业 CT 进行扫描后,共得到 856 张切片图像,采用镜像、平移、旋转和添加噪音的方式增强数据集,最终得到 1 296 张图像。将数据样本按照的 8:1:1 比例划分为训练集、验证集和测试集。




图 7 实验对象

Fig. 7 Test object

3.2 评价指标

本实验使用各类别平均像素准确率(mAcc)和平均交并比(mIoU)评估网络的分割结果。

3.2.1 mAcc

mAcc 用来评估网络在不同类别之间的性能差异,并反映网络在像素分类方面的整体性能。

其计算公式如下:

$$mAcc = \frac{1}{k} \sum_{i=1}^k \left(\frac{p_{ij}}{\sum_{j=1}^k p_{ij} + \sum_{i=1}^k p_{ii}} \right), \quad (1)$$

式中: k 为类别总数; p_{ij} 为真实像素类为 i 但被预测为类别 j 的像素数量; p_{ii} 为真实像素类别为 i 且被预测为类别 i 像素的总数量。

3.2.2 mIoU

平均交并比(mean Intersection of Union, mIoU)是度量图片分割性能的标准。网络对每一类预测结果和真实值的交集与并集的比值求和再平均的结果,计算公式如下:

$$mIoU = \frac{1}{k} \sum_{i=1}^k \left(\frac{p_{ii}}{\sum_{j=1}^k p_{ij} + \sum_{j=1}^k p_{ji} - p_{ii}} \right), \quad (2)$$

式中: p_{ji} 为真实像素类为 j 但被预测为类别 i 的像素数量。

3.3 对比实验

在对比实验中,使用DeepLabV3+, DANet, Segnext, U-Net和HRNet网络与本文网络进行分割结果进行对比,分割结果如图8~图10所示。




图8 分割结果1

Fig. 8 Segmentation results 1




图9 分割结果2

Fig. 9 Segmentation results 2




图10 分割结果3

Fig. 10 Segmentation results 3

由图 8 可知,DeepLabV3+,DANet,Segnext,U-Net 和 HRNet 网络在分割叠片电芯极片时出现正负极片黏连的问题,如图 8(c)~8(g)中白色虚线框所示。这是由于叠片电芯极片密集排列并且 CT 图像的弱边缘性导致的,这些网络不能实现电芯极片的精准分割。由图 8(h)可知,本文网络可以有效解决极片边缘模糊导致分割黏连的问题,实现电芯正负极片的准确分割。

由图 9(a)可知,叠片电芯的 CT 图像中存在严重的伪影,DeepLabV3+,DANet,Segnext,U-Net 和 HRNet 网络都会将图像中的伪影信息识别为正极极片(条纹),进行错误的分割,如图 9(c)~9(g)白色虚线框中所示。本文网络可以

正确识别伪影信息,增强了网络的抗干扰能力,如图 9(h)所示。

由图 10 可知,DeepLabV3+,DANet,Segnext,U-Net 和 HRNet 网络在分割更密集排列的电芯极片时,3 种对比网络中都存在将正极片错误分割为负极片的问题,如图 10(c)~10(g)中白色虚线框所示。如图 10(h)所示,本文提出网络可以有效解决正负极片错误分割的问题,其分割结果图也最接近标签图,这表明本文网络能够有效解决极片欠分割的问题。

本文使用常用的语义分割指标 mAcc,mIoU、参数量、分割速度对不同分割方法的结果进行定量评价,结果如表 2 所示。

表 2 对比实验评价指标结果

Tab. 2 Results of contrast experiment evaluation index

Method	mIoU/%	mAcc/%	FPS	Parameters/M
DeepLabV3+	86.81	93.25	26.24	41.27
DANet	62.68	75.41	29.40	47.45
U-Net	86.19	91.20	31.17	28.99
HRNet	82.22	90.46	31.58	9.64
Segnext	64.08	79.14	69.41	4.22
Ours	89.97	95.92	56.94	7.81

由表 2 可知,在分割精度方面,相较于 DeepLabV3+,DANet,Segnext,U-Net 和 HRNet 网络,mIoU 分别提高了 3.16%,28.29%,3.78%,7.75%,25.89%,mAcc 提高了 2.67%,20.51%,4.72%,5.46%,16.78%,本文网络具有最好的分割精度。在网络复杂度方面,本文网络的参数量为 5.814M,推理速度为 56.94 frame/s,优于 DeepLabV3+,DANet,U-Net 和 HRNet 网络,略低于 Segnext 网络。然而,本文网络的平均交并比相较于 Segnext 提高了 25.89%,平均像素分类准确率提高了 16.78%。因此,综合分析网络的分割精度和分割速度,本文网络的性能最佳。

3.4 消融实验

为验证本文设计模块的有效性,设置了消融实验,分割结果如图 11 所示。DeepLabV3+ 网络对电芯极片执行分割任务时由于特征提取能力不足,存在欠分割问题,如图 11(c)虚线框所示。




图 11 消融实验结果对比

Fig. 11 Comparison of ablation results

轻量型主干网络 MobilenetV2 可以提高网络的特征学习能力,实现更精准的分割,结果如图 11(d)所示,虽然仍存在错误分割的问题,但结果优于标准的 DeepLabV3+。在此基础上,本文又设计 S-ASPP 模块,增强网络的线性特征提取能力,避免无用信息对分割结果的干扰,显著减少了伪影对分割结果的影响,如图 11(e)所示,图中白线框中的伪影错误分割问题得到解决。最后设计条形注意力机制,为不同信息通道赋予不同的空间权重,使网络能够更准确地处理关键信息,提高网络的抗干扰能力,进一步提升网络的分割性能,最终实现对叠片电芯极片的精准分割,结果如图 11(f)所示,不存在正负极片错误分割的情况,说明本文设计的各个模块都能进一步提升网络分割性能。

为进一步定量分析各模块的有效性,使用指

标 mAcc,mIoU 和分割速度进行评价,结果如表 3 所示。

相较于 DeepLabV3+,设计轻量型主干网络 MobilenetV2 后,网络的 FPS 显著提高,达到 84.56 frame/s,比 DeepLabV3+高 58.32 frame/s。在此基础上加入 S-ASPP 模块,网络的 mIoU 和 mAcc 分别提高了 0.24% 和 0.55%。加入 SA 模块后,网络的 mIoU 和 mAcc 分别提高了 1.43% 和 1.04%,虽然增加部分参数,分割速度有所下降,但本文网络的分割速度仍然优于 DeepLabV3+,此时的 FPS 比 DeepLabV3+高 30.70 frame/s。结合图 11(f)可知,本文网络的分割速度、分割精度和抗干扰能力都优于 DeepLabV3+网络,mIoU 提升了 3.16%,mAcc 提升了 2.67%,验证了本文设计轻量型主干网络 MobilenetV2,S-ASPP 模块和 SA 模块的作用。

表 3 消融实验的评价指标结果
Tab. 3 Results of ablation experiment evaluation index

Method	mIoU/%	mAcc/%	FPS
DeepLabV3+	86.81	93.25	26.24
+ MobilenetV2	88.30	94.33	84.56
+ MobilenetV2+S-ASPP	88.54	94.88	74.93
+ MobilenetV2+S-ASPP+SA	89.97	95.92	56.94

4 结 论

针对目前分割方法在分割叠片电芯极片时存在欠分割、速度慢和边缘模的问题,本文提出一种融合条形注意力机制的轻量型分割网络。该网络中,MobilenetV2 主干网络实现网络的轻量化,S-ASPP 模块和条形注意力机制来提高网络对线性特征提取能力。实验结果表明,本文提出的分割网络相比于当前主流分割网络取得了更高的分割精度。分割速度优于 DANet,DeepLabV3+,U-Net 和 HRNet 网络,虽然略逊于 Segnext,但分割精度更高。综合考

虑评价指标 mIoU,mAcc,FPS 和 Parameters (M),本文网络是最优的。消融实验结果表明,每个模块的设计对网络的精度都有提升。在分割速度上,本文网络比 DeepLabV3+高 30.70 frame/s;在分割精度上,mIoU 和 mAcc 比 DeepLabV3+分别高 3.16% 和 2.73%。在未来工作中,一方面通过构建多样化的数据集,涵盖不同类型和结构的电池极片,来提高模型的泛化能力;另一方面,对分割后的 CT 图进行后处理,通过计算极片的长度、极片间距离以及极片的弯曲度等参数来实现对电芯极片的质量评估。

参考文献:

[1] 余浩松,邹永宁,张智斌,等. 利用 CAD 模型的不

完全扫描 CT 图像重建[J]. 光学学报, 2021, 41 (6): 107-117.

YU H S, ZOU Y N, ZHANG ZH B, *et al.* Image

- reconstruction of incomplete CT scanning using a CAD model[J]. *Acta Optica Sinica*, 2021, 41(6): 107-117. (in Chinese)
- [2] 章斌, 卢洪义, 刘舜, 等. 发动机部件 CT 图像特征提取与区域生长算法[J]. *兵工学报*, 2023, 44(4): 1171-1180.
ZHANG B, LU H Y, LIU SH, *et al.* Feature extraction and region growing algorithm for processing CT scans of engine parts[J]. *Acta Armamentarii*, 2023, 44(4): 1171-1180. (in Chinese)
- [3] YU X K, WANG Z W, WANG Y H, *et al.* Edge detection of agricultural products based on morphologically improved canny algorithm[J]. *Mathematical Problems in Engineering*, 2021, 2021 (1): 6664970.
- [4] ZOU L, SONG L T, WEISE T, *et al.* A survey on regional level set image segmentation models based on the energy functional similarity measure[J]. *Neurocomputing*, 2021, 452: 606-622.
- [5] LIU H Q, ZHAO F. Multiobjective fuzzy clustering with multiple spatial information for Noisy color image segmentation [J]. *Applied Intelligence*, 2021, 51(8): 5280-5298.
- [6] LIASKOS M, SAVELONAS M A, ASVESTAS P A, *et al.* Vertebrae, IVD and spinal canal boundary extraction on MRI, utilizing CT-trained active shape models[J]. *International Journal of Computer Assisted Radiology and Surgery*, 2021, 16(12): 2201-2214.
- [7] 刘长江, 曾理. 基于两组细胞神经网络的工业 CT 图像分割[J]. *计算机工程与应用*, 2008, 44(7): 206-208.
LIU CH J, ZENG L. Industrial Computerized Tomography image segmentation based on two Cellular Neural Networks[J]. *Computer Engineering and Applications*, 2008, 44(7): 206-208. (in Chinese)
- [8] 赵思玄, 何云勇, 沈宽, 等. 基于深度学习的铸件 CT 图像分割算法[J]. *仪器仪表学报*, 2023, 44(11): 176-184.
ZHAO E X, HE Y Y, SHEN K, *et al.* Casting CT image segmentation algorithm based on deep learning [J]. *Chinese Journal of Scientific Instrument*, 2023, 44(11): 176-184. (in Chinese)
- [9] BEECHE C, SINGH J P, LEADER J K, *et al.* Super U-Net: a modularized generalizable architecture[J]. *Pattern Recognition*, 2022, 128: 108669.
- [10] HAN H, GAO C Q, ZHAO Y, *et al.* Polycrystalline silicon wafer defect segmentation based on deep convolutional neural networks [J]. *Pattern Recognition Letters*, 2020, 130: 234-241.
- [11] DEVIN B, KAVIDA A C, MURUGAN R. Feature extraction and object detection using fast-convolutional neural network for remote sensing satellite image[J]. *Journal of the Indian Society of Remote Sensing*, 2022, 50(6): 961-973.
- [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 Y, GONG X J, SU H. Image segmentation method of surface defects for metal workpieces based on improved U-net[J]. *Journal of Applied Optics*, 2023, 44(1): 86-92. (in Chinese)
- [13] GOU J, WU X Y, LIU L. Detection and segmentation of defects in industrial CT images based on mask R-CNN[J]. *Journal of Computers*, 2020, 31(6): 141-154.
- [14] YUAN W, WANG J, XU W B. Shift pooling PSPNet: rethinking PSPNet for building extraction in remote sensing images from entire local feature pooling [J]. *Remote Sensing*, 2022, 14 (19): 4889.
- [15] NIU Z J, LIU W, ZHAO J Y, *et al.* DeepLab-based spatial feature extraction for hyperspectral image classification [J]. *IEEE Geoscience and Remote Sensing Letters*, 2019, 16(2): 251-255.
- [16] YU C Q, XIAO B, GAO C X, *et al.* LiteHRNet: a lightweight high-resolution network [C]. 2021 *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)*. June 20-25, 2021. Nashville, TN, USA. IEEE, 2021: 10435-10445.
- [17] 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*, 2018, 40(4): 834-848.
- [18] NING Q Q, ZHU J K, CHEN C. Very fast semantic image segmentation using hierarchical dilation and feature refining [J]. *Cognitive Computation*, 2018, 10(1): 62-72.
- [19] BAI Y, LI J, SHI L J, *et al.* DME-DeepLabV³⁺: a lightweight model for diabetic macular edema extraction based on DeepLabV³⁺ architecture [J].

Frontiers in Medicine, 2023, 10: 1150295.

- [20] 龙超, 金恒, 黎玲, 等. 基于特征融合的非局部均值 CT 图像降噪[J]. 光学学报, 2022, 42(11): 1134024.

LONG CH, JIN H, LI L, *et al.* CT image denoising with non-local means based on feature fusion [J]. *Acta Optica Sinica*, 2022, 42 (11) : 1134024. (in Chinese)

作者简介:



刘泽芳(1999—),女,山西吕梁人,硕士研究生,2022年于中北大学获得学士学位,主要从事CT图像处理方面的研究。E-mail: 202208021011@cqu.edu.cn

通讯作者:



段黎明(1964—),男,四川南充人,教授,博士生导师,1985年于成都科技大学获得学士学位,1988年、1998年于重庆大学分别获得硕士和博士学位,主要从事CT图像处理、工业计算机层析成像技术及系统等方面的研究。E-mail: duanliming@cqu.edu.cn