

DOI: 10.19650/j.cnki.cjsi.J2210556

基于深度学习的铸件 CT 图像分割算法*

赵恩玄^{1,2}, 何云勇^{1,2}, 沈宽^{1,2}, 刘杰^{1,2}, 段黎明^{1,2}

(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)

摘要:针对现有方法分割弱边缘铸件 CT 图像难度大、精度低、鲁棒性差的问题,提出一种融合残差模块与混合注意力机制的 U 型网络分割算法(AttRes-U-Nets)。该算法以 U-Net 网络为基础,首先构建深度残差网络 ResNets 作为算法的编码网络,解决传统 U-Net 网络特征提取能力不足的问题;然后,引入改进后的混合注意力机制,突出分割目标区域与通道的特征响应,提高网络灵敏度;最后,将 Focal loss 与 Dice loss 结合为一种新损失函数 FD loss 缓解样本不平衡带来的负面影响。使用 120 阀体数据集对算法性能进行验证,实验结果表明,本文算法对铸件分割的像素准确率(PA)和交互比(IoU)分别达到 98.72% 和 97.40%,优于传统 U-Net 算法与其他主流语义分割算法,为弱边缘分割提供了新思路。

关键词: CT 图像分割;深度学习;U-Net;残差网络;CBAM

中图分类号: TH164 TP391.7 文献标识码: A 国家标准学科分类代码: 460.40

Casting CT image segmentation algorithm based on deep learning

Zhao Enxuan^{1,2}, He Yunyong^{1,2}, Shen Kuan^{1,2}, Liu Jie^{1,2}, Duan Liming^{1,2}

(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)

Abstract: The existing methods for segmenting CT images of castings with weak edges have problems of difficulty, low precision and poor robustness. To address these issues, this article proposes a U-shaped network segmentation algorithm that fuses residual module and mixed attention mechanism. Firstly, the algorithm is based on U-Net. The deep residual networks (ResNets) is established as the backbone of the network to solve the inadequate feature extraction capability of the original U-Net. Then, the improved hybrid attention mechanism is introduced, and it characterize the target region and the channel to improve the network sensitivity. Finally, a new loss function (FD loss) combining Focal loss and Dice loss is used to mitigate the negative effects of sample imbalance. The performance of the algorithm is evaluated by using the 120 valve body dataset. The experimental results show that the pixel accuracy (PA) and intersection over union (IoU) of the proposed algorithm for casting segmentation reach 98.72% and 97.40%, which are better than the those of the original U-Net and other mainstream semantic segmentation algorithms. This work provides a new idea for the weak edge segmentation problem.

Keywords: CT image segmentation; deep learning; U-Net; residual networks; CBAM

0 引言

铸件的尺寸测量^[1]是评估铸件是否符合标准的重要环节,传统的测量仪器如三坐标测量机、激光传感器等^[2-3],主要用于铸件的外部尺寸测量,难以满足实际测

量评估的需求。计算机断层扫描技术(computed tomography, CT)可通过 X 射线扫描铸件,获得铸件内部断层图像,并结合图像测量技术获取铸件内部尺寸信息,具有无接触、无损失、成像直观^[4]等优势,在工业测量领域发挥着不可替代的作用。CT 的高精度测量依赖于图像的精准分割定位,由于 CT 固有的射线散射、容积效应以及形位误差等,CT 图像不可避免的存在噪声^[5],尤其

是射线散射引起的图像对比度降低和边缘弱化,工业 CT 图像的分割有着更高的精度要求,在处理工业 CT 图像时,需要对原分割算法加以改进。

传统图像分割方法主要有阈值分割法^[6]、边缘检测分割法^[7]、区域分割法^[8]、聚类分割法^[9]以及基于主动轮廓模型的分割法^[10]等,但传统方法分割精度低、算法耗时长、对噪声敏感,如何实现高效精准分割是研究 CT 图像分割的关键所在。

随着将深度学习引入到图像处理领域,因其强大的特征学习能力,图像分割问题也取得了突破性的进展^[11]。2014 年,Long 等^[12]提出的全卷积网络(fully convolutional networks, FCN)奠定了深度学习在语义分割领域的基础,因其普适性和有效性,广泛应用于工业领域。Xie 等^[13]使用 SegNet 模型^[14]实现光伏组件红外图像有效区域分割任务,SegNet 相较于 FCN 添加了解码器结构,分割效果也优于 FCN。为改善卷积神经网络上下文信息提取能力,PSPnet^[15]、DeepLab^[16]和 Non-Local^[17]等一系列网络被提出,Wang 等^[18]提出一种基于 Deeplabv3+ 网络的胃癌自动分割模型,能较好捕捉物体边缘信息,使得分割精度进一步提升。近年来,Transformer 模型应用于图像处理取得成功,它以能提取图像全局信息的特点占有独特优势,大量基于 Transformer 模型的分割网络被提出,Transformer 模型架构大都类似 U-Net^[19],但作为大模型,模型训练会耗费更多的硬件资源,需要庞大的数据量。

2015 年,Ronneberger 等^[20]提出 U-Net 网络,梁波等^[21]使用 U-Net 网络对钢轨表面损伤进行分割检测,2022 年曹富强等^[22]通过级联两个 U 型网络实现轮毂 X 射线图像缺陷分割,并融合注意力机制减少漏检率。同年,Huang 等^[23]提出一种深度可分离的 U 型网络对热轧带钢表面进行缺陷分割,采用深度可分离卷积代替传统卷积层提高分割性能。U-Net 网络是 CT 图像分割的经典算法之一,至今仍在 CT 图像分割领域中占据主导地位,它支持小样本数据训练,提取多尺度图像特征,拥有良好的分割性能,能满足铸件 CT 图在少量数据情况下的分割要求,但是网络深度不够,影响分割精度等方面亟待提高。

综上所述,为实现 CT 图像的精准分割,解决 CT 图像分割弱边缘等问题,本文基于 U-Net 提出一种 AttRes-U-Nets 分割网络。首先,提出一种融合残差结构^[24]的主干特征网络 ResNets,在 ResNet50 基础上进行改进,引入额外两条恒等映射,减少网络退化,降低训练难度;然后,在编码器-解码器的跳跃连接处引入改进后的混合注意力机制,在空间和通道两个层面削弱背景噪声的影响,增强算法抗干扰能力;最后,使用 Focal loss 与 Dice loss 结合的新损失函数 FD loss,解决样本不均衡带来的误分类问题,进一步提高网络的细节分割能力。

1 构建 AttRes-U-Nets 网络

铸件 CT 图像的背景复杂度较低,弱边缘细节信息难以捕捉,图像的低级特征与高级语义都很重要^[25]。同类型铸件 CT 图像数量有限,需在有限的样本数据中获取足够的特征信息,这对算法构成了新的挑战。综合考虑铸件 CT 图像的特点和实际生产需求,本文选择 U-Net 网络作为算法框架完成铸件 CT 图像的高精度分割任务。

1.1 编码网络

经典 U-Net 网络使用 VGG 网络系列作为主干特征网络,本文使用的铸件内部结构复杂,不同位置的切片图像差异较大,需要捕捉的更多的细节信息,VGG 网络的学习能力难以满足要求,需要更深的网络学习更多的特征信息。本文主要针对小样本数据,网络过深又容易出现过拟合的现象。为解决网络特征提取能力不足的问题,符合小样本数据训练的要求,本文提出了一种融合残差结构的主干特征网络 ResNets。ResNets 网络结构如图 1 所示。

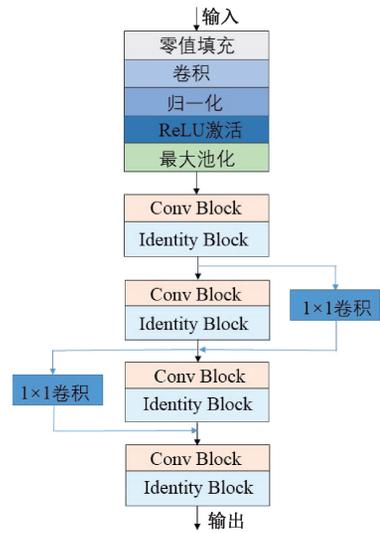


图 1 ResNets 结构图

Fig. 1 Diagram of ResNets architecture

ResNets 网络主要由残差结构堆叠而成,残差网络包含 Identity Block 和 Conv Block 两种残差结构。其中 Identity Block 包含 3 个网络层和一个跨越网络层的恒等映射,输入特征图经过 3 个网络层进行特征提取后,再与通过恒等映射的输入特征图相加:

$$\mathbf{x}_{i+1} = \mathbf{x}_i + F(\mathbf{x}_i, \{W_i\}) \quad (1)$$

式中: \mathbf{x}_i 表示第 i 层残差结构的输入, \mathbf{x}_{i+1} 表示第 $i+1$ 层残差结构的输入, $F(\mathbf{x}_i, \{W_i\})$ 表示特征提取部分。

Conv Block 结构与 Identity Block 相似,只另在恒等映射处使用一个 1×1 的卷积层进行变维处理,表达式为:

$$\mathbf{x}_{i+1} = h(\mathbf{x}_i) + F(\mathbf{x}_i, \{W_i\}) \quad (2)$$

$$h(\mathbf{x}_i) = W'_i \mathbf{x}_i \quad (3)$$

式中: W'_i 表示 1×1 的卷积部分,用于改变特征图的维度, $h(\mathbf{x}_i)$ 表示变维结果。

ResNets 在反向传播时,残差结构可以根据梯度情况自适应地调整网络的有效深度,防止网络过深带来的网络退化问题,同时在第三、四阶段额外添加了 1×1 的卷积的两条恒等映射,相当于将两个阶段当成一个特殊的残差结构,减小网络过拟合的概率,更进一步提高网络训练的推理速度,加快网络收敛。

1.2 混合注意力机制

铸件 CT 图像不可避免的会存在噪声和边界伪影,这在很大程度上会影响铸件的分割精度,为了降低二者给铸件分割带来的负面影响,本文在算法中引入注意力机制,它通过重新分配特征层的权重,让网络更加注重感兴趣区域的特征信息,降低噪声与伪影的干扰。传统注意力机制分为空间注意力机制和通道注意力机制,前者为特征层的每一个位置分配权重,提升目标区域的特征表达;后者为每个通道赋予不同的权重系数,强化重要的特征通道。

为了突出铸件特征信息,抑制伪影和噪声,本文采用联合空间和通道的混合注意力机制(convolutional block attention module, CBAM)^[26],CBAM 包含了空间注意力模块(spatial attention module, SAM)和通道注意力模块(channel attention module, CAM),可以同时调整空间与通道两个层面的权重。

CAM 首先对单个输入特征层分别进行最大池化 MaxPool 与平均池化 AvgPool,将两个池化结果利用共享的全连接层进行卷积运算,再将两个运算结果相加,最后进行非线性处理得到一个通道权值:

$$M_c(\mathbf{F}) = \sigma((W_1(W_0(\mathbf{F}_{\text{avg}}^c))) + W_1(W_0(\mathbf{F}_{\text{max}}^c))), \quad M_c(\mathbf{F}) \in R^{c \times 1 \times 1} \quad (4)$$

式中: σ 表示 sigmoid 激活函数, $W_0 \in R^{C/r \times C}$ 、 $W_1 \in R^{C \times C/r}$ 为全连接层的权重, $\mathbf{F}_{\text{avg}}^c$ 、 $\mathbf{F}_{\text{max}}^c$ 分别表示平均池化与最大池化。

SAM 首先对输入特征层的每个点在通道上分别取最大值与平均值,得到两个大小为 $H \times W$ 的特征图,然后将两个特征图进行堆叠,使用一个卷积层将输出通道调整为 1,得到一个空间权值:

$$M_s(\mathbf{F}) = \sigma(f^{7 \times 7}([\mathbf{F}_{\text{avg}}^s; \mathbf{F}_{\text{max}}^s])), \quad M_s(\mathbf{F}) \in R^{H \times W} \quad (5)$$

式中: $f^{7 \times 7}$ 表示 7×7 大小的卷积层。

考虑到低维特征层具有更强的空间响应,高维特征层具有更强的通道响应,本文根据实际应用场景对

CBAM 进行改进,对 SAM 和 CAM 进行换位处理,改进后的 CBAM 结构如图 2 所示。

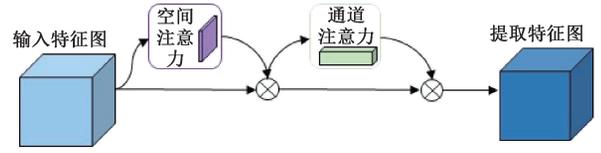


图2 CBAM 结构图

Fig. 2 Diagram of CBAM architecture

输入特征图首先经过 SAM 获得空间权值,将空间权值与输入特征图相乘得到空间特征图,再将空间特征图通过 CAM 获得通道权值,空间特征图再与通道权值相乘即为最后结果。

深层网络特征图的空间尺寸较小,通道数较大,对深层特征图进行空间层面的权重分配并不能强调信息特征,反而会增加网络的参数量,使网络变得更加臃肿,针对镶嵌在深层网络的注意力机制,只使用通道注意力模块 CAM。

1.3 混合损失函数

损失函数用来评价网络模型预测值和真实值的差异程度,训练神经网络以损失函数为基准,不断调整网络内部的权重参数,最终使损失函数的值达到最小。损失函数的性能会很大程度影响整个深度学习算法的性能,不同的损失函数适用于不同的应用场景,在图像分割神经网络中,常用的损失函数包括 Dice loss 和 Focal loss;其中, Dice loss 通过计算样本间相似度来获得损失,它重点关注前景像素是否分类正确,受背景影响很小,可以减少前景、背景样本不平衡的现象; Focal loss 能够有效解决分割过程中累计损失偏大导致的分类效果差的问题。

为了进一步改善网络性能,实现铸件边界的精准分割,本文采用 Dice loss 和 Focal loss 混合的新损失函数 FD loss,并引入参数 λ 作为二者的平衡系数。FD loss 结合二者的优点,可以同时解决样本失衡和误分类的问题。具体计算如下:

$$Loss_{FD} = Loss_{Dice} + \lambda Loss_{Focal} \quad (6)$$

$$Loss_{Dice} = V - \sum_v \frac{T_p(v)}{T_p(v) + \alpha M_p(v) + \beta F_p(v)} \quad (7)$$

$$Loss_{Focal} = -\lambda \sum_{v=0}^{V-1} \sum_{n=1}^N g_n(v) (1 - p_n(v))^2 \lg(p_n(v)) \quad (8)$$

式中: N 表示训练批次中的像素数量; v 为像素类别; V 为类别数量; $T_p(v)$ 、 $F_p(v)$ 、 $M_p(v)$ 分别为第 v 类的真阳性、假阳性和真阴性; $p_n(v)$ 表示 v 类第 n 个像素的预测率;

$g_n(v)$ 表示 v 类第 n 个像素的专家标注值; λ 为平衡 Dice loss 和 Focal loss 的系数; α, β 分别为假阳性和假阴性的平衡系数。

1.4 AttRes-U-Nets 网络结构

本文提出一种基于 U-Net 的 AttRes-U-Nets 分割网络, 结构如图 3 所示。

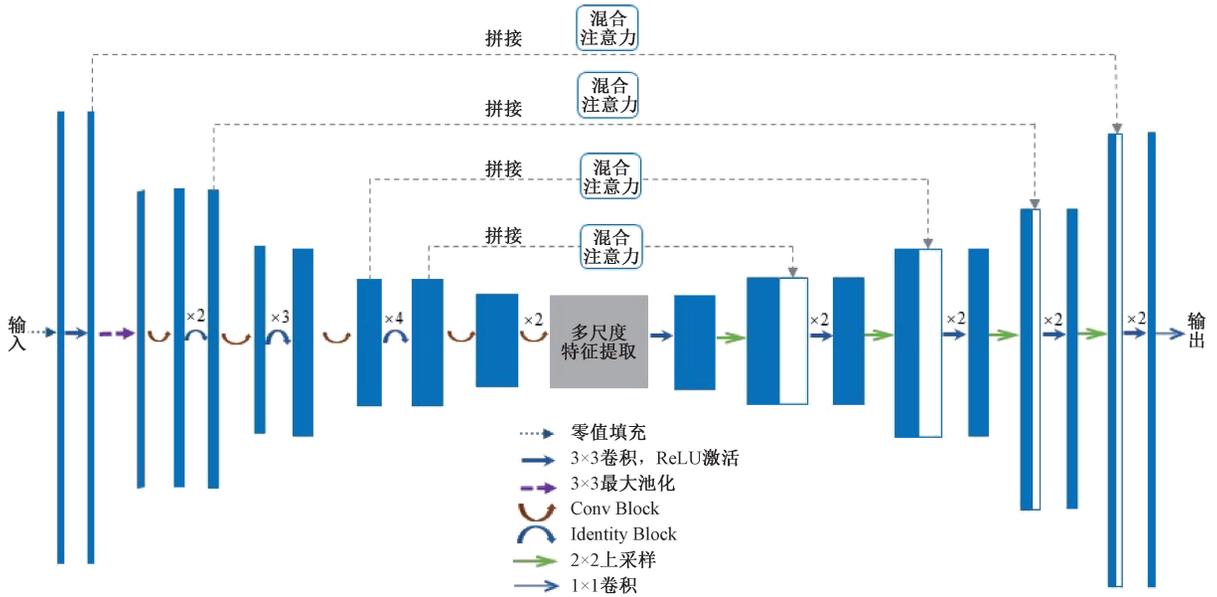


图 3 AttRes-U-Nets 结构图

Fig. 3 Diagram of AttRes-U-Nets architecture

从图 3 可知, AttRes-U-Nets 整体保留经典 U-Net 网络的跳连结构, 具有较好的迁移特性。它主要由 3 部分组成, 分别是编码网络、解码网络以及带有注意力机制的跳连结构。编码网络使用深度残差网络 ResNets, 较深的网络层数保证了足够的学习能力, 残差结构也能有效解决梯度弥散或梯度爆炸的问题。译码网络与传统 U-Net 保持一致, 由 4 个上采样模块构成, 每个上采样模块包含 2 个 3x3 的卷积层和 1 个 2x2 上采样层, 卷积层用于融合特征, 上采样层用于恢复特征图尺寸。编码网络与译码网络之间通过跳跃层进行连接, 目的是拼接同维度特征, 实现低级语义信息的复用。采用注意力机制的跳跃连接结构, 在低维特征的跳跃连接层引入改进后的 CBAM, 在高维特征的跳跃连接处引入 CAM, 通过增加工件特征信息的训练权重来降低内部缺陷以及边界伪影的干扰。

2 实验及结果分析

2.1 实验平台

本文使用的实验平台相关配置如表 1 所示。实验在 Windows10 操作系统上完成, 系统内存为 16 G, 采用 TensorFlow 框架实现改进图像语义分割算法, 使用 CUDA 对算法进行加速。

表 1 实验配置

Table 1 Configuration of experiment

实验设备	配置
CPU	Intel i5-10400F
GPU	NVIDIA GTX1080
CUDA	10.1
CUDNN	7.6.5
Python	3.7
TensorFlow	2.2

2.2 数据集与参数设置

本文使用实际扫描的 120 阀体 CT 图像作为数据集, 其具备内部结构复杂、存在弱边缘和伪影以及不同部位切片图像差距大等特点, 满足本文算法实验要求。数据集共有不同部位切片图像 120 张, 采用旋转、颠倒以及加入随机噪声等操作对其进行数据集扩充, 扩充后的图像共有 570 张, 划分 470 张图像为训练集, 100 张图像为测试集。数据扩充过程如图 4 所示。

表 2 列出了训练 Att Res-U-Nets 网络模型过程中的超参数设置。采用 Adam 优化器, 批量大小设置为 2, 初始学习率设置为 0.0002, 最大训练轮次设置为 100, 采用指数衰减的方式动态调整学习率, 加快网络收敛速度。为防止模型在训练过程中出现过拟合, 使用早停法来决

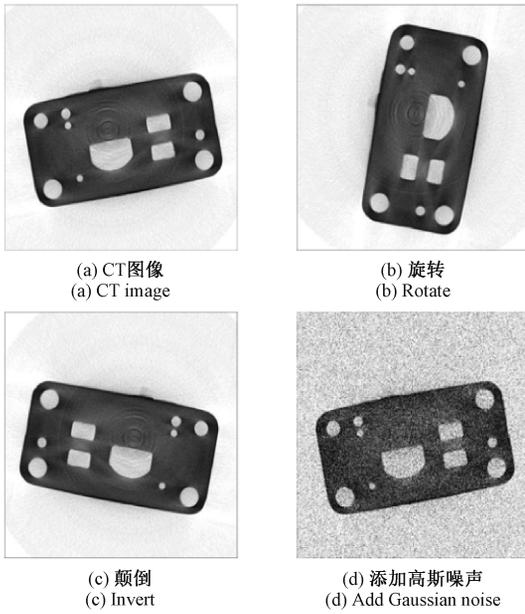


图4 数据扩充过程

Fig. 4 Dataset augmentation process

定训练是否提前终止,早停止值设置为10,即当训练中的损失值10个轮次不下降则认为模型基本收敛,将自动停止训练。实验设定训练上限为100个训练轮次,最终训练77个训练伦次后自动停止,训练集的 acc 收敛于99.89%, loss 收敛于0.005,测试集的 acc 收敛于99.64%、loss 收敛于0.006。

表2 超参数设置

Table 2 Hyperparametric setting

超参数	设定值
训练轮次	100
早停止	10
批量大小	2
学习率	0.000 2
衰减率	0.000 1

2.3 评价指标

为了对本文算法的分割性能进行评估,采用像素准确率 (pixel accuracy, PA) 和交互比 (intersection over union, IoU) 作为评价标准,其中 PA 表示预测正确的像素数占全部像素数的比重, IoU 表示预测正确的目标像素数占真实目标像素数与伪目标像素数之和的比重,二者越接近1,说明算法性能越好。计算如下:

$$PA = (TP + TN) / (TP + TN + FP + FN) \quad (9)$$

$$IoU = TP / (TP + FP + FN) \quad (10)$$

式中: TP、TN、FP、FN 分别表示真正例、真反例、假正例、假反例像素数。

2.4 算法对比实验

为验证本文算法的优势,用 HRnet、DeepLabv3+、DNLnet 和 SegNext 主流算法与本文算法进行对比,不同算法的分割结果如图5所示。

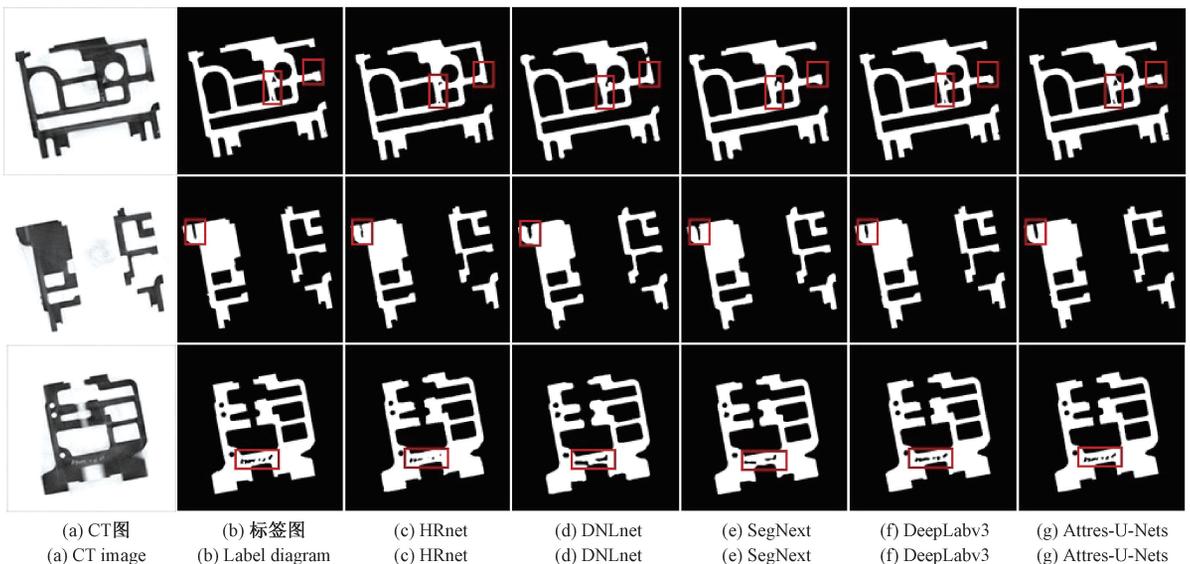


图5 不同算法的分割结果

Fig. 5 Segmentation results for different algorithms

从图 5 中可以看出,HRnet 与 DNLnet 的整体分割效果不佳,一些样本中的弱边缘无法识别,其中 HRnet 对缺陷分割不明显,过分割现象严重,DNLnet 欠分割现象严重;DeepLabv3+ 与 SegNext 能够分割弱边缘,但分割得较为粗糙,其中 SegNext 没有将小空洞缺陷分割开;本文算法无论是缺陷还是弱边缘都处理得出色,边缘分割清晰,小空洞缺陷也能分割出来,整体分割效果最接近 Ground Truth。

不同算法的实验数据如表 3 所示。从参数量、分割速度、PA 和 IoU 这 4 个方面进行了对比。

表 3 不同算法的实验数据

Table 3 Experimental data for different algorithms

方法	参数量/M	分割速度/FPS	PA/%	IoU/%
HRnet	9.64	6.8	96.48	93.97
DNLnet	47.60	6.6	96.64	94.24
SegNext	4.22	7.6	96.75	94.61
DeepLabv3+	42.21	6.2	96.86	95.01
本文算法	43.16	6.5	98.72	97.40

从表 3 中可以看出,本文算法参数量为 43.16 M,推理速度为 6.5 fps,像素准确率 PA 为 98.72%,交互比 IoU 为 97.4%。在分割性能方面,相对于 HRnet、DNLnet、SegNext 和 DeepLabv3+ 网络,PA 值分别提高了 2.18%、3.16%、2.24% 和 3.43%,IoU 值分别提高了 1.97%、2.79%、1.97% 和 2.79%。在算法复杂度方面,本文算法优于 DNLnet。与 HRnet、SegNext 和 DeepLabv3+ 相比,本文算法复杂度虽高于这 3 种模型,但在分割精度方面都优于这 3 种对比算法。在实际应用中,本文网络参数量和推理速度满足实际工业应用需求。

2.5 泛化性实验

为了验证本文算法对于多类样本依然有高分割精度,具有普适性,泛化能力强的优点,将经过数据扩充后的 600 张航空发动机叶片图像、600 张喷嘴图像与 570 张 120 阀体图像混合进行训练,总共 1 770 张,将 3 类数据样本分别以 3:1:1 的比例随机划分训练集、验证集和测试集。在该测试集中,类别平均像素准确率 MPA 与平均交互比 MIoU 分别达到了 98.23% 和 96.74%。

泛化性能实验分割结果如图 6 所示,从图中可以看出,本文算法对叶片、叶片空洞、喷嘴和 120 阀体这 4 类目标均有较好的分割效果,边界分割清晰,细节分割精准,与 Ground Truth 有很高的相似度,验证了本文算法具有良好的泛化性能。

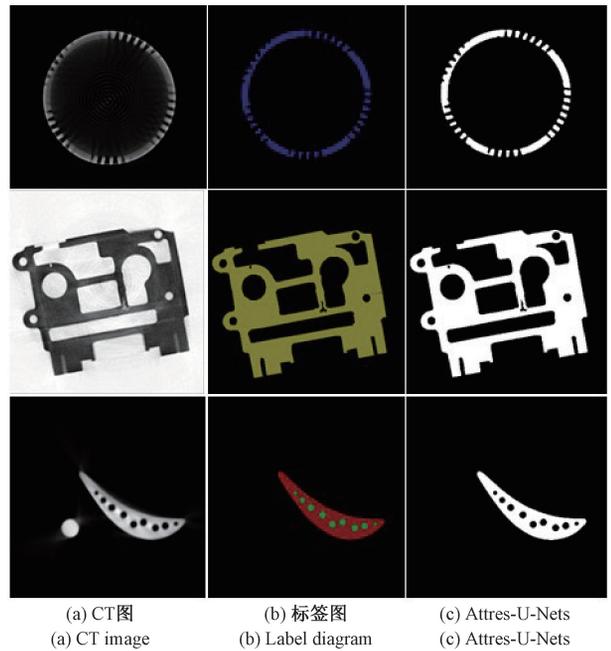


图 6 泛化实验分割结果

Fig. 6 Segmentation results of generalization experiment

2.6 消融实验

为了验证本文算法引入 CBAM、ResNets 和 FD loss 的必要性,进行了消融实验,消融实验结果如图 7 所示。从图 7 中可以看出,传统 U-Net 网络由于特征提取能力不足,虽分割出铸件整体,却无法识别铸件内部缺陷;加入 CBAM 后,网络的抗干扰能力有所提升,能够将内部缺陷识别出来,但细节学习能力不足,铸件边缘分割比较粗糙;在此基础上采用 ResNets,网络的学习能力得到增强,分割边缘变得更加平滑,但会忽略边缘弱化严重的区域,缺陷的细节变得不够明显;最后再引入混合损失函数 FD loss,网络分割性能得到进一步提升,弱边界跟缺陷都能准确分割,并且边缘细节也能很好保持。

消融实验数据如表 4 所示。从表 4 可知,相较于传统 U-Net 算法,PA 提升了 2.71%,IoU 提升了 3.39%,验证了本文算法引入 CBAM、ResNets 和 FD loss 的必要性。

表 4 消融实验数据

Table 4 Experimental data for ablation experiments

方法	PA/%	IoU/%
U-Net	96.01	94.01
U-Net+CBAM	97.83	96.04
U-Net+CBAM+ResNets	98.58	96.94
U-Net+CBAM+ResNets+FD loss	98.72	97.40

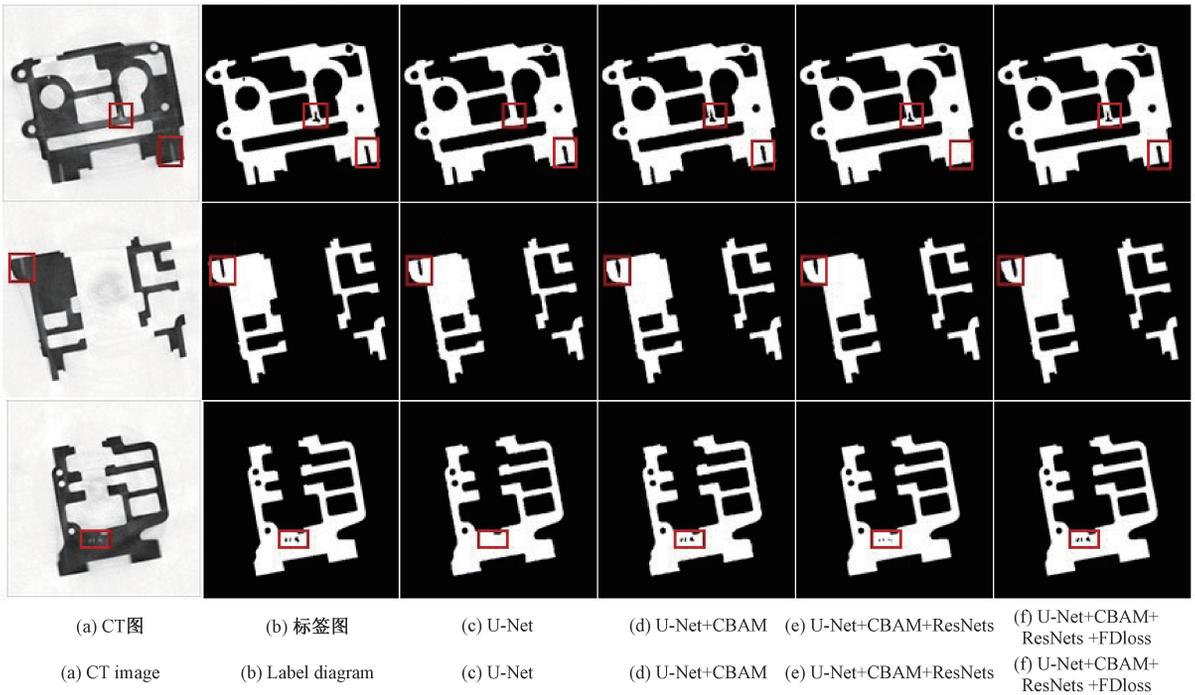


图7 消融实验结果

Fig. 7 Results of ablation experiments

3 结 论

为了实现铸件弱边缘 CT 图像的精准分割,本文提出一种改进的 U-Net 算法,在传统 U-Net 算法的基础上进行优化了编码网络与损失函数,引入了注意力机制。将本文算法与 HRnet、DNLnet、SegNext 和 DeepLabv3+算法进行对比,验证了本文算法能有效分割铸件弱边缘与铸件内部缺陷,具有高分割准确率,且模型复杂度满足工业应用需求;将不同类别的铸件进行混合训练实验,验证了本文算法可以对不同铸件实现精准分割,具有较好的泛化性能;最后,将每一步优化的实验结果与原算法进行对比分析,优化后的算法优于传统 U-Net 算法,验证了优化工作的必要性。实验证明,本文算法可以同时解决铸件弱边缘 CT 图像分割难度大、精度低、鲁棒性差的问题,但算法在结构上略显臃肿,因此后续研究工作可围绕算法的轻量级进行展开。

参考文献

- [1] 杨晗,谭川东,盛晋银,等. 基于工业 CT 的零件内外曲面形位误差分析[J]. 仪器仪表学报, 2021, 42(11): 230-238.
 YANG H, TAN CH D, SHENG J Y, et al. Analysis of shape and position error of internal and external surfaces of parts based on industrial CT[J]. Chinese Journal of

Scientific Instrument, 2021, 42(11): 230-238.

- [2] 李兵,闫潇,陈磊,等. 一种基于激光传感器快速检测透平叶片的方法[J]. 光子学报, 2017, 46(11): 211-221.
 LI B, YAN X, CHEN L, et al. Rapid method to measure turbine blade based on laser sensors[J]. Acta Photonica Sinica, 2017, 46(11): 211-221.
- [3] 陈洪芳,高毅,王帼媛,等. 基于区间层次分析法的三坐标测量机精度分配方法[J]. 仪器仪表学报, 2023, 44(4): 163-171.
 CHEN H F, GAO Y, WANG J H, et al. Accuracy allocation method of coordinate measuring machine based on interval analytic hierarchy process [J]. Chinese Journal of Scientific Instrument, 2023, 44(4): 163-171.
- [4] 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.
- [5] 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):

- 281-291.
- LONG CH, JIN H, LI L, et al. CT image denoising with non-local means algorithm base on feature fusion [J]. *Acta Optica Sinica*, 2022, 42(11): 281-291.
- [6] 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.
- [7] 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: 6664970.
- [8] 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]. *Neuro-Computing*, 2021, 452: 606-622.
- [9] LIU H, ZHAO F. Multiobjective fuzzy clustering with multiple spatial information for noisy color image segmentation [J]. *Applied Intelligence*, 2021, 51(8): 5280-5298.
- [10] LIASKOS M, SAVELONAS M A, ASVESTAS P A. 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.
- [11] 黄鹏, 郑淇, 梁超. 图像分割方法综述 [J]. *武汉大学学报(理学版)*, 2020, 66(6): 519-531.
- HUANG P, ZHENG Q, LIANG CH. Overview of image segmentation methods [J]. *Journal of Wuhan University (Natural Science Edition)*, 2020, 66(6): 519-531.
- [12] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [13] XIE Y, SHEN Y, ZHANG K J, et al. Efficient region segmentation of pv module in infrared imagery using segnet [C]. *IOP Conference Series: Earth and Environmental Science*, 2021, 793: 012018.
- [14] 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.
- [15] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2017: 2881-2890.
- [16] 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.
- [17] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks [C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2018: 7794-7803.
- [18] WANG J, LIU X. Medical image recognition and segmentation of pathological slices of gastric cancer based on DeepLabv3+ neural network [J]. *Computer Methods and Programs in Biomedicine*, 2021, 207: 106210.
- [19] XIAO H, LI L, LIU Q, et al. Transformers in medical image segmentation: A review [J]. *Biomedical Signal Processing and Control*, 2023, 84: 104791.
- [20] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2015: 234-241.
- [21] 梁波, 卢军, 曹阳. 基于改进 U-Net 卷积神经网络的钢轨表面损伤检测方法 [J]. *激光与光电子学进展*, 2021, 58(2): 334-340.
- LIANG B, LU J, CAO Y. Rail surface damage detection method based on improved U-Net convolutional neural network [J]. *Laser Optoelectronics Progress*, 2021, 58(2): 334-340.
- [22] 曹富强, 王明泉, 张俊生, 等. 基于 AW-Net 的轮毂射线图像分割算法 [J]. *光电子激光*, 2022, 33(1): 45-52.
- CAO F Q, WANG M Q, ZHANG J SH, et al. A segmentation algorithm of wheel hub ray image based on AW-Net [J]. *Journal of Optoelectronics and Laser*, 2022, 33(1): 45-52.
- [23] HUANG Z, WU J J, XIE F. Automatic surface defect segmentation for hot-rolled steel strip using depth-wise

separable U-shape network[J]. *Materials Letters*, 2021, 301: 130271.

- [24] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]. *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, 2016: 770-778.
- [25] 李原, 李艳君, 刘进超, 等. 基于改进 Res-UNet 网络的钢铁表面缺陷图像分割研究[J]. *电子与信息学报*, 2022, 44(5): 1513-1520.
LI Y, LI Y J, LIU J CH, et al. Research on image Res-UNet network[J]. *Journal of Electronics & Information Technology*, 2022, 44(5): 1513-1520.
- [26] WOO S, PARK J, LEE J Y, et al. CBAM: Convolutional block attention module [J]. Springer, Cham, 2018: 3-19.

作者简介



赵恩玄, 2021 年于中南民族大学获得学士学位, 现为重庆大学硕士研究生, 主要研究方向为深度学习, CT 图像处理。

E-mail: 2310194215@qq.com

Zhao Enxuan received her B. Sc. degree

from South-Central University for Nationalities in 2021. She is currently a master student at Chongqing University. Her main research interests include deep learning, and CT image processing.



段黎明(通信作者), 1985 年于成都科技大学获得学士学位, 1988 年于重庆大学获得硕士学位, 1998 年于重庆大学获得博士学位。现任重庆大学教授, 博士生导师。主要研究方向为工业计算机层析成像技术及系统、精密机械及仪器等。

E-mail: duanliming163@163.com

Duan Liming (Corresponding author) received his B. Sc. degree from Chengdu University of Science and Technology in 1985, and received his M. Sc. and Ph. D. degrees both from Chongqing University in 1988 and 1998, respectively. He is currently a professor and a Ph. D. advisor at Chongqing University. His main research direction include industrial computer tomography technology and system, precision machinery and instruments.