

PAF-Net: 用于骶髂关节高效分割的并行注意力网络^①



严武军, 王家辉, 邱瑜茹

(太原师范学院 计算机科学与技术学院, 晋中 030600)

通信作者: 严武军, E-mail: yanwujun@tynu.edu.cn

摘要: 骶髂关节病变是预警强直性脊柱炎的主要体征之一, 精确高效的骶髂关节自动分割对于协助医生临床诊断和治疗至关重要。针对骶髂关节灰度多变、背景复杂、且因骶髂间隙狭小而存在容积效应导致的特征提取受限, 分割精度难以提升的问题, 本研究利用层次级联补偿下采样信息丢失以及注意力并行保留跨维信息特征的思想, 提出首个用于骶髂关节分割诊断的U型网络。此外, 为了提高临床诊断的效率, 将U型网络中传统的卷积替换为高效部分卷积块。本实验在山西白求恩医院提供的骶髂关节CT数据集中, 验证了分割精度及效率平衡方面的有效性, 最终DICE达到91.52%, IoU达到84.41%。实验结果表明, 改进的U型分割网络能有效提高骶髂关节分割精度, 减轻医疗专业人员的负担。

关键词: 骶髂关节; 医学图像分割; 注意力机制; 特征融合

引用格式: 严武军,王家辉,邱瑜茹.PAF-Net: 用于骶髂关节高效分割的并行注意力网络.计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9730.html>

PAF-Net: Parallel Attention Network for Efficient Sacroiliac Joint Segmentation

YAN Wu-Jun, WANG Jia-Hui, QIU Yu-Ru

(School of Computer Science and Technology, Taiyuan Normal University, Jinzhong 030600, China)

Abstract: A lesion of the sacroiliac joint is one of the primary signs for the early warning of ankylosing spondylitis. Accurate and efficient automatic segmentation of the sacroiliac joint is crucial for assisting doctors in clinical diagnosis and treatment. The limitations in feature extraction in sacroiliac joint CT images, due to diverse gray levels, complex backgrounds, and volume effects resulting from the narrow sacroiliac joint gap, hinder the improvement of segmentation accuracy. To address these problems, this study proposes the first U-shaped network for sacroiliac joint segmentation diagnosis, utilizing the concept of hierarchical cascade compensation for downsampling information loss and parallel attention preservation of cross-dimensional information features. Moreover, to enhance the efficiency of clinical diagnosis, the traditional convolutions in the U-shaped network are replaced with efficient partial convolution blocks. The experiment, conducted on a sacroiliac joint CT dataset provided by Shanxi Bethune Hospital, validates the effectiveness of the proposed network in balancing segmentation accuracy and efficiency. The network achieves a DICE value of 91.52% and an IoU of 84.41%. The results indicate that the improved U-shaped segmentation network effectively enhances the accuracy of sacroiliac joint segmentation and reduces the workload of medical professionals.

Key words: sacroiliac joint; medical image segmentation; attention mechanism; feature fusion

① 收稿时间: 2024-06-05; 修改时间: 2024-06-28; 采用时间: 2024-07-18; csa 在线出版时间: 2024-11-15

1 引言

强直性脊柱炎是一种慢性炎症性疾病,其核心病理表现集中于脊柱和骶髂关节,导致患者经历疼痛、僵硬等症状,并逐步丧失关节功能,最终可能引发残疾^[1].早期且精准的诊断对于遏制病情发展、缓解患者痛苦具有决定性的意义.鉴于骶髂关节是强直性脊柱炎的主要攻击部位,其病变区域的精准识别在疾病的诊断中占据至关重要的地位^[2].然而,在临床实践中,强直性脊柱炎的识别具有挑战.以山西白求恩医院为例,作为山西省内规模最大、功能最全面、标准最高的现代化综合性医疗机构,拥有华北最大的门诊区,日均接待门诊患者量逾万人次.这也直接决定风湿免疫科临床医生每天需要审阅大量的盆骨影像(computed tomography, CT),并运用丰富的专业经验,准确屏蔽干扰区域,费时费力的高强度工作容易出现误差.骶髂关节作为强直性脊柱炎等骨科疾病的关键诊断部位,其自动分割与精准诊断在临床实践中具有迫切的需求.

传统的图像分割方法,如阈值分割、基于区域的分割等,在处理骶髂关节图像时,往往受到噪声干扰,难以获得满意的分割效果.随着深度学习技术的快速发展,卷积神经网络在图像分割领域展现出了强大的潜力^[3].Long等人^[4]提出了首个端对端的针对像素级预测的全卷积神经网络(fully convolutional network, FCN),解决了语义级别的图像分割问题.但FCN对细节信息不敏感,分割不够精细.针对此问题,Ronnerberger等人^[5]提出了一种基于FCN的U-Net图像分割模型,采用编码器-解码器结构及跳跃连接的设计模式,将浅层特征和深层特征进行融合,实现更精细的分割.目前,基于U-Net及其改进版本的医学图像分割技术已广泛应用于脑部、心肺病变区以及各类肿瘤的分割任务中,展现出了显著的性能优势,但在骨骼领域的分割应用相对较少.2018年,Minnema等人^[6]采用卷积神经网络对颅骨进行了分割.2019年,Klein等人^[7]采用基于改进的U-Net网络对全身骨骼进行分割.2020年,Noguchi等人^[8]采用卷积神经网络进行了全身骨骼的分割.2022年,刘金辉等人^[9]基于改进U-Net的网络对下肢骨骼CT图像进行分割.2023年,Qin等人^[10]采用改进U-Net分割网络对盆骨骨髓进行分割.基于深度学习的分割方法在分割准确性方面优于其他传统分割方法,但该类方法的最终分割结果与数据集质量、样本数据对比

度、样本前景背景均衡情况有着很大的依赖关系^[11].

骶髂关节由形状不规则的骶骨和髂骨耳状面组成,具有显著的个体差异.尤其是骨间隙狭窄容易造成部分容积效应,组织对比度低,加之盆骨区域内骨骼、血管和软组织等多种结构的灰度相似性,使得区分不同组织边界变得复杂.传统的U型分割网络在特征图下采样过程中,由于池化操作不可避免地丢失细节信息,且在实际临床应用中受到硬件性能的限制.强直性脊柱炎的及时诊断对避免严重后果至关重要,因此开发能够高效、精确分割骶髂关节的方法在临床应用中具有重要价值.

考虑到以上问题,本研究设计了一个用于执行骶髂关节分割任务的并行注意力特征融合网络(parallel attention feature fusion network, PAF-Net),该网络基于在分割问题中表现优异的U-Net架构,并针对其局限性进行了针对性的改进.总的来说,本文贡献主要有以下几点.

一是针对骶髂关节骨间隙狭窄造成部分容积效应,设计了层次级联特征融合模块(hierarchical cascade feature fusion module, HCFF),多尺度特征融合策略能够更精确地捕捉到骶髂关节的微小骨间隙和边缘信息,且能够有效解决传统分割网络下采样过程信息丢失的问题.

二是重视通道和空间相互作用,设计了通道空间并行注意力模块(channel-spatial parallel attention module, CSPA),对特征图进行精细特征提取与拼接,补偿传统注意力机制难以捕捉的跨维信息,有效地识别和强调与骶髂关节关键特征.

三是为了兼顾精度与效率,保证在临床中的实时应用.本文将编码器和解码器处的传统卷积替换为部分卷积(partial convolution, PConv),有效减少计算冗余和内存访问量,从而在保持高性能的同时实现高效的计算.

最后,鉴于医学图像数据集的稀缺性,除了传统的数据增强^[12]之外,本方法在网络上采样层添加了添加部分Dropout,以提高网络泛化能力.

2 本文方法

人体盆骨CT图像常呈现灰度多变、背景繁杂的特性,且伴随多种骨骼软组织干扰,致使其与其他组织区分度有限^[13].因此,传统的神经网络在进行精确分割

时面临挑战。本文提出的 PAF-Net 是以医学分割领域中表现优异的 U-Net 作为基础网络，针对盆骨骨骼数

据集特点与 U-Net 自身缺点出发进行改进。PAF-Net 的整体模型如图 1 所示。




图 1 PAF-Net 模型整体结构

PAF-Net 模型分割的整体流程：对于输入的 CT 图像，首先编码器的下采样层逐步提取盆骨图像的语义特征，并通过 HCFF 模块融合上下文特征，保留细节信息；其次 CSPA 模块，将下采样输出的特征图，经过 3 个分支提取不同维度特征，拼接多维度特征后输出；最后解码器拼接跳跃连接的不同维度信息，经过多次上采样恢复图像分辨率，输出最终分割结果。

2.1 多层次融合的下采样模块

传统的 U 型分割网络（如 U-Net）在特征图下采样过程中，通常会使用池化操作（如最大池化或平均池化）来减小特征图的尺寸。但这种操作对于图像中的小结构或不规则边缘等细节信息具有破坏性，这些细节信息会在池化过程中被平滑掉或丢失。骶髂关节骨缝狭窄，且骨边缘信息因人而异，最容易被忽视掉。为了解决此问题，本研究在下采样层设计了一条专门用于保留细节信息的通路（detail preservation pathway, DPP）。图 2 中，DPP 通路采用步幅为 2 的 3×3 卷积层，通过捕捉局部区域信息并考虑上下文关系，实现特征图尺寸的减少。相较于更侧重选择或平均化局部信息的池化操作，能够有效保留纹理细节。

之后，将原始下采样通路与细节保留通路（DPP）的输出进行拼接，融合多尺度信息，输入到下一层。这一操作即保留了图像的细节信息，又结合了高层次的语义信息，能有效提高网络对于骶髂间隙和边缘的敏

感度，提升分割精度。

图 1 中，初始的骶髂 CT 图像 X ，其尺寸为 $3 \times 256 \times 256$ 被输入到分割网络中。 X 首先进入第 1 层传统下采样通路，经过两层卷积操作，分别为 3×3 的标准卷积层与改进的部分卷积层。随后，进行池化操作，尺寸大小变为 $X_1^{64 \times 256 \times 256}$ 。接着，将经池化处理的图像与原始输入图像 $X^{3 \times 256 \times 256}$ 进行拼接得到 $X_2^{67 \times 256 \times 256}$ ，形成的特征张量并传递至下一网络层级。




图 2 层次级联特征融合模块结构 (HCFF)

在后续的下采样层级中，处理流程相似但略有不同。在第 2 层中，特征张量 X_2 经过第 2 层下采样，其尺寸减小至 $X_3^{128 \times 128 \times 128}$ 。同时第 1 层下采样输出的特征图 X_1 经过 DPP 变为 $X_1^{64 \times 128 \times 128}$ 。将 X_3 与 X_1 拼接在一起得到 $X_4^{192 \times 128 \times 128}$ ，随后被送入网络的第 3 层级。后续层级依此类推，采用相同的处理机制。

2.2 改进的多重注意力机制 CSPA

为了提高各种计算机视觉任务的性能，人们已经研究了各种注意力机制。挤压和激励网络（squeeze-and-excitation network, SENet）是第 1 个显式建模卷积

神经网络中特征通道之间相互依赖性的网络^[14]. 然而, 它在抑制不重要的像素方面效率较低, 而且忽略位置信息. 卷积块注意力模块 (convolutional block attention module, CBAM), 同时考虑了空间维度和通道维度, 按顺序放置通道和空间注意力^[15]. 但是, 它忽略了通道的空间相互作用^[16,17], 丢失跨维信息. 针对以上问题, 为了提取更多特征信息, 并捕捉跨维交互, 本文设计了空间通道并行注意力模块 (CSPA), 从而有效地识别和强调与髌骨关节关键特征. 图 3 给出了该注意力模块的网络结构图, 其中包含并行三通路: 通道关注子模块、空

间关注子模块和跳跃连接子通路. 跳跃连接子通路如图 3 中间红线所示, 借鉴了 U-Net 网络架构中的中间跳跃连接部分, 旨在将原始特征图与其余两种经过注意力模块强化提取的特征图进行拼接, 从而实现多尺度特征的融合. 这种结构设计增强了网络对细节和上下文信息的整合能力, 优化了特征表示. 最终, 空间通道并行注意力模块 (CSPA) 模块的输出, 由式 (1) 表示. 其中介绍在第 2.2.1 节和第 2.2.2 节详细给出.

$$X_{\text{out}} = \text{Cat}[X, Y_{\text{CA}}, Y_{\text{SA}}] \quad (1)$$




图 3 通道空间并行注意力结构

2.2.1 基于双层 MLP 的通道关注子模块

在通道关注子模块中图 3 上半部分所示, 输入的特征张量 $X \in R^{C \times H \times W}$ 首先进行 Permute 操作, 通过 3D 置换操作得到 $X \in R^{W \times H \times C}$, 将不同维度上的信息重新排列组合, 以便更好地捕捉跨维关系. 然后, 经过 3D 置换的特征图输入到多层感知器 (multilayer perceptron, MLP) 中放大跨维度通道的空间相关性^[18]. 多层感知器由两边的线性变换层 Linear, 和中间的一个激活函数层 ReLU 组成. 第 1 层 Linear 将输入通道数压缩, 以减少参数数量和计算复杂度. 接着通过 ReLU 函数引入非线性变换, 并且设置了 `inplace=True`, 以进行原位操作节省内存. 第 2 层 Linear, 将压缩后的通道数放大回原始的输入通道数, 以便与原图相乘, 最终输出带权通道注意力图 Y_{CA} . 可以用式 (2)–式 (4) 表示:

$$X_{\text{per}} = \text{Per}(X) \quad (2)$$

$$X_{\text{att}} = \text{Lin}_2[\text{ReLU}(\text{Lin}_1(X_{\text{per}}))] \quad (3)$$

$$Y_{\text{CA}} = X_{\text{att}} \times X \quad (4)$$

其中, $\text{Per}(\cdot)$ 表示 3D 置换. Permute 函数可以改变张量的存储顺序, 但不会改变张量中的数据内容, Lin_2 和 Lin_1 表示多层感知机, R 为激活函数.

2.2.2 基于全局池化的空间关注子模块

在空间关注子模块图 3 下半部分中, 对于输入特征张量经过了一个包含 3×3 卷积、批量归一化和 ReLU 激活函数的卷积层, 得到了一组经过特征增强的特征图 X_{Conv} , 接着对 X_{Conv} 做通道上的全局平均池化和全局最大池化后进行通道维度加性拼接, 得到了一个融合了全局信息的特征图 x_{pool} . 最后, 利用一个 1×1 卷积层和 Sigmoid 激活函数, 对 x_{pool} 进行处理得到一个通道数为 1 的权重图 X_{att} . 最后, X_{att} 与高级特征图 X_{Conv} 相乘, 得到了最终的带权空间注意力图. 可以用式 (5)–式 (8) 表示:

$$E_{\text{mp}} = \text{MP}(X_{\text{Conv}}) \quad (5)$$

$$E_{ap} = AP(X_{Conv}) \quad (6)$$

$$X_{att} = S \left\{ Conv \left[Add(E_{mp}, E_{ap}) \right] \right\} \quad (7)$$

$$Y_{SA} = X_{att} \times X \quad (8)$$

其中, $MP(\cdot)$ 和 $AP(\cdot)$ 分别是最大池化操作和平均池化操作. 值得注意的是, 这里的 $Add(\cdot)$ 表示加性连接, 是两个图层对应元素相加. 这样可以保持通道数不变, 避免了高维度的特征图导致的计算和存储压力. $Conv(\cdot)$ 表示 1×1 卷积层和 Sigmoid 激活函数, 将输入值映射到 0–1 之间.

2.3 部分卷积

相对于传统的 U-Net 架构, 本网络在设计上融合了注意力模块和跨级拼接, 提高分割精度的同时, 也不可避免地增加了网络的复杂度. 为了平衡计算负担, 将 U-Net 编码层和解码层的第 2 层卷积替换为部分卷积块, 旨在保持性能同时实现高效计算, 确保网络稳定性和实用性. 部分卷积如图 4(b) 所示, 是一种特殊的卷积操作, 与传统的卷积图 4(a) 有所不同, 它仅对输入特征图的部分通道进行空间特征提取, 同时保持其余通道不变^[19]. 这种方法的显著降低了浮点运算次数和内存访问量, 从而提高了计算效率.




图 4 卷积示意图

另一方面, CT 图像扫描时, 患者部位可能因组织阻挡或结构影响出现信息不全或伪影. 而部分卷积可以输入图像的掩码 (mask) 选择性地更新特征图像素, 避免对遮挡部分错误更新. 因此, 引入部分卷积能够有效地处理图像中存在的遮挡情况, 不仅减少参数量, 还能提升分割效果.

3 实验结果及分析

3.1 实验环境及参数设置

PAF-Net 模型在 Python 3.8.10 的 PyTorch 中实现, 并在配备 Intel Xeon Gold 5218 和 NVIDIA RTX 3090 的高性能平台上训练. 实验中, 本文采用 Adam 优化算法, 初始学习率设为 0.0002, 进行 100 个 epoch 的训练, 以最小化损失函数. 根据最终测试集性能指标, 选取最

优化的模型权重进行模型部署.

3.2 数据集

这项研究得到了山西白求恩医院的批准. 专业医生提供了 40 个包含骶髂关节的 3D 盆骨样本, 以建立文本注释骶髂关节 CT 骨盆数据集. 两位经验丰富的临床专业医师对分割的基本事实进行了标记. 图 5(a) 为盆骨轴位 CT 图, 可清晰显示骶髂关节的骨质结构和关节间隙, 图 5(b) 为标签图.




图 5 盆骨三方位 CT 图

3.3 数据集预处理

对于 3D 样本, 本文从 Z 轴提取的 5951 张盆骨切片中, 剔除全黑标签的切片后, 得到 2431 张完好标签的切片用于训练. 实验按 7:3 分割训练集 (1702 张) 和测试集 (729 张), 图片分辨率大小为 256×256, 并对其进行传统数据增强, 归一化操作.

3.4 评价指标与损失函数

度量用于评估图像实况和预测结果之间的相似性, 以显示网络的性能. 在这项工作中, 本文选择了 4 种指标来评估性能, 包括交并比 (intersection over union, IoU)、Dice 相似系数 (Dice similarity coefficient, $DICE$)、精度 (precision, PRE)、HD 距离 (Hausdorff, HD) 以及参数量 (Params). 这些指标描述如下:

$$IoU = \frac{|A \cap B|}{|A \cup B|} \times 100\% \quad (9)$$

$$DICE = \frac{2|A \cap B|}{|A| + |B|} \times 100\% \quad (10)$$

$$PRE = \frac{TP}{TP + FP} \times 100\% \quad (11)$$

$$HD = \max \{dis(P, G), dis(G, P)\} \quad (12)$$

$DICE$ 系数用于衡量算法在分割盆骨骶髂区域时的性能, 特别是与金标准之间的重叠程度. 除了 $DICE$ 系数, IoU (交并比) 和 PRE (精确率) 也是重要的评估指标, 分别反映了正确分割的像素比例和误分割情况. 这 3 个指标的值都在 0–1 之间, 且越高越好. HD 距离

则用于度量两个形状或点集间的差异。 HD 距离的值越低，表示两个形状或点集之间的差异越小，即分割结果越好。另外，在模型设计和优化的过程中，参数量是一个重要的考虑因素。通过合理控制模型的参数量，可以在保证模型性能的同时降低计算资源需求和过拟合风险。

损失函数采用二值交叉熵损失函数，交叉熵损失函数是深度学习和机器学习中常用的一种损失函数。它的基本原理是衡量模型预测的概率分布与真实标签的概率分布之间的差异。交叉熵损失函数的定义和计算方式如(13)所示：

$$L_{BCE} = -y \log(y_i + \varepsilon) - (1 - y) \log(1 - y_i + \varepsilon) \quad (13)$$

其中， y 是真实的标签(0 或 1)， y_i 是模型预测该样本为正类的概率。并且为了防止计算过程中对数函数内的值为 0，对 y_i 进行平滑处理，添加一个很小的 ε 值。

3.5 对比实验

为了验证本文方法的优势，将其与 FCN32S^[20]、U-Net^[5]、CE-Net^[21]、UNet++^[22]、DenseUNet^[23]、Att-UNet 网络进行对比实验。采用 IoU 、 $DICE$ 系数、精确率、 HD 距离以及运行参数量 5 个评价指标对模型进行定量分析，如表 1 所示。

表 1 对比实验

算法	IoU (%)	$DICE$ (%)	PRE (%)	HD (mm)	Params (M)
FCN32S	68.21	79.10	85.41	3.131	134.3
U-Net	75.82	85.58	86.27	1.988	34.32
CE-Net	77.62	87.43	89.32	1.671	28.99
UNet++	84.15	91.31	91.61	1.154	47.18
DenseUNet	82.41	90.21	88.73	1.279	34.87
Att-UNet	83.81	92.11	92.41	1.096	32.87
Our-Net	84.41	91.52	92.84	1.072	36.58

表 1 中的实验结果表明，PAF-Net 在几乎所有的评估指标上都优于其他先进模型。在骶髂关节的分割中实现了 IoU (84.41%)、 PRE (92.84%) 和 HD (1.072 mm) 的最佳度量。一方面，这归功于在上采样部分引入了层次级联特征融合，聚集多尺度信息。另一方面，在上采样和下采样部分引入空间通道并行注意力模块(CSPA)，聚焦关键信息，对于背景复杂的骶髂关节分割，效果明显。另外，在分割效果提升的情况下，参数量也在控制范围内，甚至更低。这主要归功于引入的部分卷积，显著降低了浮点运算次数和内存访问量。

此外，本文通过使用小提琴图可视化了骶髂关节的 $DICE$ 系数，如图 6 所示。小提琴的形状反映了对应数据集下 $DICE$ 系数的概率密度分布，宽度表示了数

据在此位置的频率，而面积则代表了数据的整体分布范围，图中本文网络的频率、范围集中处均高于其他网络。小提琴内部的黑线区域标记了中位数，展示了 $DICE$ 系数的中心趋势，本文网络的中心明显高于前 5 个网络，与 Att-UNet 基本持平。




图 6 $DICE$ 小提琴图

3.6 定性结果

分割效果如图 7 所示，其中第 1 列为骶髂关节 CT 图像 input image，第 2 列为专家标注的金标准 ground truth，剩下依次为各种分割网络和本文算法的分割效果图。本文算法的分割结果相较于其他算法，轮廓更精细，与 ground truth 更接近。

3.7 消融实验

为了验证所提算法以及算法中各模块的有效性，本文进行各模块的消融实验。首先选择 U-Net 作为基准网络，然后将 HCFF、CSPA、PConv 依次引入网络中，以验证每个模块的实用性。如表 2 数据所示，层次级联特征融合、空间通道并行注意力模块和部分卷积模块的引入分别使骶髂关节分割的 $DICE$ 增加 2.24%、2.63% 和 1.94%。

尤其是 PConv 的引入，参数量直接下降 11.59M。此外，引入这 3 个模块后的其他指标也不同程度的超过基网指标，证明了所提出的模块的实用性。值得注意的是，与将这 3 个模块单独引入基网相比，PAF-Net 在分割中获得了最好的数据，这表明基网与 3 个模块相结合可以显著提高分割性能。尤其是引入部分卷积(PConv)后，达到参数量仅增加 2.58M 的情况下， $DICE$ 值提高了 5.94%， IoU 值提高了 8.59%。

3.8 应用测试

医学图像最终分割后应保证图像不失真，保留原图清晰度。本文网络输出的分割预测掩膜为 256×256 ，与相同尺寸 CT 图像相乘，清晰度下降。于是考虑将分割预测掩膜扩充至 512×512 ，与原图相乘，得到最终分

割图像。经专业医生评价后,符合要求。在传统家用电脑上进行分割测试,随机选取一位患者,共 205 张 CT

图像,分割批处理设置为 8,全部分割完毕,用时 90 s 左右。效果如图 8 所示。




图 7 不同模型分割效果

表 2 消融实验

算法	<i>IoU (%)</i>	<i>DICE (%)</i>	<i>PRE (%)</i>	<i>HD (mm)</i>	Params (M)
基网(A)	75.82	85.58	86.27	1.988	34.32
HCFF+A	78.61	87.82	88.13	1.732	38.37
CSPA+A	78.81	88.21	86.73	1.749	44.48
PConv+A	78.21	87.52	88.12	1.839	22.73
HCFF+CSPA+A	80.91	89.3	90.41	1.369	48.31
Our-Net	84.41	91.52	92.84	1.072	36.58




图 8 测试效果图

4 结论与展望

准确识别和保护骶髂关节对于早期发现病变并减轻患者痛苦至关重要。自动化骶髂关节分割技术能辅

助放射科医生标记病变区域,减轻工作负担。本文提出首个专用于骶髂关节分割的 PAF-Net 模型,集成了层次级联特征融合模块 (HCFF) 和空间通道并行注意力模块 (CSPA),并引入部分卷积以平衡效率。在骨盆 CT 数据集上,PAF-Net 展现出色性能, *DICE* 系数达 91.52%, *IoU* 达 84.41%,精确率为 92.84% 以及 *HD* 距离 1.072, 优于其他先进模型。实验证明其可行性和有效性,可聚焦目标区域并恢复细节。消融实验验证了各部件的贡献。然而,作为二维模型,PAF-Net 缺乏学习片间信息的能力,可能影响分割准确性。未来研究将探索将所提模块与三维模型结合,以进一步提升性能。并且对于临床分割来说,时间还有待进一步提升。

参考文献

- 曹立坤,王云,马壮飞,等.深度学习重建算法在超重者低剂量骶髂关节CT中的价值.影像诊断与介入放射学,2024,33(1): 37–43.
- 曹伟.CT与MRI平扫诊断强直性脊柱炎骶髂关节病变的效果.影像研究与医学应用,2020,4(23): 121–123.
- 吴绯红,赵煌旋,杨帆,等.医学影像+人工智能的发展、现状与未来.临床放射学杂志,2022,41(4): 764–767.
- Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation. Proceedings of the 2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Boston: IEEE, 2015. 3431–3440.
- Ronneberger O, Fischer P, Brox T. U-Net: Convolutional networks for biomedical image segmentation. Proceedings of

- the 18th International Conference on Medical Image Computing and Computer-assisted Intervention-MICCAI 2015. Munich: Springer, 2015. 234–241.
- 6 Minnema J, van Eijnatten M, Kouw W, et al. CT image segmentation of bone for medical additive manufacturing using a convolutional neural network. Computers in Biology and Medicine, 2018, 103: 130–139. [doi: [10.1016/j.combiomed.2018.10.012](https://doi.org/10.1016/j.combiomed.2018.10.012)]
- 7 Klein A, Warszawski J, Hillengäß J, et al. Automatic bone segmentation in whole-body CT images. International Journal of Computer Assisted Radiology and Surgery, 2019, 14(1): 21–29. [doi: [10.1007/s11548-018-1883-7](https://doi.org/10.1007/s11548-018-1883-7)]
- 8 Noguchi S, Nishio M, Yakami M, et al. Bone segmentation on whole-body CT using convolutional neural network with novel data augmentation techniques. Computers in Biology and Medicine, 2020, 121: 103767. [doi: [10.1016/j.combiomed.2020.103767](https://doi.org/10.1016/j.combiomed.2020.103767)]
- 9 刘金辉, 童晶, 倪佳佳, 等. 基于改进 U-Net 的下肢骨骼 CT 图像分割. 计算机系统应用, 2022, 31(10): 134–141. [doi: [10.15888/j.cnki.csa.008746](https://doi.org/10.15888/j.cnki.csa.008746)]
- 10 Qin CB, Zheng B, Li WY, et al. MAD-Net: Multi-attention dense network for functional bone marrow segmentation. Computers in Biology and Medicine, 2023, 154: 106428. [doi: [10.1016/j.combiomed.2022.106428](https://doi.org/10.1016/j.combiomed.2022.106428)]
- 11 赵其杰, 周安稳, 朱俊豪. 基于 PE-Vnet 网络的三维骨骼图像分割方法. 仪器仪表学报, 2020, 41(7): 243–251.
- 12 杜少帅. 基于数据增强和双重编码的医学图像多尺度分割研究 [硕士学位论文]. 上海: 东华大学, 2023.
- 13 李府天. 基于骶髂关节 CT 影像的强直性脊柱炎自动分级研究 [硕士学位论文]. 汕头: 汕头大学, 2022.
- 14 Xiong LL, Yi C, Xiong QL, et al. SEA-NET: Medical image segmentation network based on spiral squeeze-and-excitation and attention modules. BMC Medical Imaging, 2024, 24(1): 17. [doi: [10.1186/s12880-024-01194-8](https://doi.org/10.1186/s12880-024-01194-8)]
- 15 Woo S, Park J, Lee JH, et al. CBAM: Convolutional block attention module. Proceedings of the 15th European Conference on Computer Vision. Munich: Springer-Verlag, 2018. 3–19.
- 16 He ZX, Li XX, Chen YL, et al. Attention-based dual-path feature fusion network for automatic skin lesion segmentation. BioData Mining, 2023, 16(1): 28. [doi: [10.1186/s13040-023-00345-x](https://doi.org/10.1186/s13040-023-00345-x)]
- 17 Cui JG, Wang LJ, Jiang SC. A multi-scale cross-fusion medical image segmentation network based on dual-attention mechanism Transformer. Applied Sciences, 2023, 13(19): 10881. [doi: [10.3390/app131910881](https://doi.org/10.3390/app131910881)]
- 18 Zhang KN, Yang XT, Cui YF, et al. Automatic segmentation of rectal tumors from MRI using multiscale densely connected convolutional neural network based on attention mechanism. Physics in Medicine & Biology, 2023, 68(16): 165001.
- 19 Chen JR, Kao SH, He H, et al. Run, don't walk: Chasing higher FLOPS for faster neural networks. Proceedings of the 2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Vancouver: IEEE, 2023. 12021–12031.
- 20 Sun CJ, Guo SX, Zhang HM, et al. Automatic segmentation of liver tumors from multiphase contrast-enhanced CT images based on FCNs. Artificial Intelligence in Medicine, 2017, 83: 58–66. [doi: [10.1016/j.artmed.2017.03.008](https://doi.org/10.1016/j.artmed.2017.03.008)]
- 21 Gu ZW, Cheng J, Fu HZ, et al. CE-Net: Context encoder network for 2D medical image segmentation. IEEE Transactions on Medical Imaging, 2019, 38(10): 2281–2292. [doi: [10.1109/TMI.2019.2903562](https://doi.org/10.1109/TMI.2019.2903562)]
- 22 Zhou ZW, Rahman Siddiquee MM, Tajbakhsh N, et al. UNet++: A nested U-Net architecture for medical image segmentation. Proceedings of the 4th International Workshop, DLMIA 2018, and the 8th International Workshop on Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support. MICCAI 2018. Granada: Springer, 2018. 3–11.
- 23 Zhou YP, Chang HY, Lu XL, et al. DenseUNet: Improved image classification method using standard convolution and dense transposed convolution. Knowledge-based Systems, 2022, 254: 109658. [doi: [10.1016/j.knosys.2022.109658](https://doi.org/10.1016/j.knosys.2022.109658)]

(校对责编: 孙君艳)