

深度学习在主动脉影像自动分割中的研究进展

唐玉宁,潘天岳,董智慧,符伟国

(复旦大学附属中山医院血管外科,上海 200032)

摘要:在医学图像处理领域,准确的图像分割对于主动脉疾病的诊断和治疗规划至关重要。深度学习技术,尤其是卷积神经网络近年来在医学图像分割任务中取得了显著的进展。本文基于深度学习模型应用于主动脉病变图像自动化分割的研究进行综述,总结了目前这些技术对于提高分割精度和效率方面的贡献,探讨了现有方法所面临的挑战和未来研究更多的可能性以及方向。

关键词:深度学习;主动脉图像分割;卷积神经网络;主动脉疾病;计算机视觉

中图分类号:R543.1

文献标志码:A

Research progress of deep learning in automatic segmentation of aortic images

TANG Yuning, PAN Tianyue, DONG Zhihui, FU Weiguo

(Department of Vascular Surgery, Zhongshan Hospital of Fudan University, Shanghai 200032, China)

Abstract: In the field of medical image processing, accurate image segmentation is crucial for the diagnosis and treatment planning of aortic diseases. Deep learning techniques, especially convolutional neural networks, have made significant progress in medical image segmentation tasks in recent years. This article reviewed the research on the application of deep learning models to the automatic segmentation of aortic lesion images, summarized the contributions of these current techniques to improving the segmentation accuracy and efficiency, and discussed the challenges faced by existing methods and more possibilities and directions for future research.

Key words: Deep learning; Aortic image segmentation; Convolutional neural networks; Aortic disease; Computer vision

《中国心血管健康与疾病报告 2022》表明,目前心血管疾病已成为我国城乡居民首要死亡原因^[1]。主动脉是人体最大的动脉,负责将氧和血液输送到全身各个组织和器官,以维持正常生命体征。主动脉因血管壁的结构、遗传、疾病等多个因素会发生病变,导致主动脉夹层(aortic dissection, AD)和主动脉瘤(aortic aneurysm, AA)等^[2]。AD和AA的发展往往迅速且急迫,尽早接受干预和治疗是挽回患者生命的关键。使用计算机断层扫描血管成像(computed tomography angiography, CTA)和核磁共振血管成像(magnetic resonance angiography, MRA)技术可对主动脉病变进行定性、定位和定因诊断,广泛应用于整个治疗和随访过程中。然而,主

动脉影像受到容积效应影响,出现组织边缘清晰度低、管腔内容与邻近组织结构灰度值接近、主动脉解剖结构形态变化等问题,导致自动化主动脉影像分割技术发展较缓慢^[3]。而伴随着深度学习的出现和发展,自动化医学图像分割取得了突破性的进展。自2016年Ravi等^[4]首次提出在医学图像领域可使用深度学习进行预测分析后,多位学者接连发表相关论文及综述,指出深度学习对于医学图像检测、识别以及分割具有难以替代的作用^[5]。

本文简明介绍基于深度学习进行图像语义分割的概念和结构,并探讨目前应用于主动脉自动化分割的技术水平情况。在此之前,也有多位学者关注心血管医学图像自动分割领域将其整理编写为综

述^[6-7],说明深度学习未来可期。本文聚焦于 AD 和 AA 的语义分割技术,进行最新研究综述。

1 深度学习模型

早在 2006 年 Hinton 等^[8]便提出了深度学习的概念。与传统阈值分割算法^[9]和边缘检测算法^[10]相比,深度学习对于不同数据具有鲁棒性能自动调整输入图像信息^[11]。近些年来已经涌现出各种针对于图像处理的分割模型^[12]。

目前医学图像分割中最经典的深度学习模型是全卷积神经网络 (fully convolutional network, FCN)^[13]。随后出现了很多基于 FCN 的网络架构,如 U-Net^[14]、PSPNet^[15]、SegNet^[16]。而 U-Net 在医学图像分割领域表现尤为突出,此后 U-Net 及其变

体如 UNet++^[17]、UNet 3 +^[18] 以及处理 3D 图像的 V-Net^[19] 被广泛用于医学图像分割任务。

1.1 FCN 概念

FCN 是一种可用于图像识别、分类、医学图像分析的语义分割模型,2015 年 Shelhamer 等^[14]提出用于语义分割的 FCN。FCN 在医学图像 (MRI、CT、X 射线等) 分割中取得了巨大成功,这主要得益于结构调整带来的新突破:①将全连接层全部由卷积层代替;②利用全卷积结构的参数共享机制;③经连续卷积和上采样操作;④首个端对端像素级输出的训练预测模型;⑤利用上采样将特征图还原至输入图像原始分辨率。经过上述改动在恢复图像的空间信息的同时使用跳跃链接技术融合不同层次特征,可防止模型过拟合,提升其泛化能力进一步提高分割准确性。FCN 结构见图 1。




图 1 FCN 架构图

Figure 1 FCN architecture diagram

1.2 U-Net 及其变形

2015 年由 Ronneberger 等^[15]提出编码器和解码器结构的 U-Net 常被视为医学图像分析领域的一个里程碑。通过连续卷积和下采样 (最大池化法) 来获得高级抽象的特征,再使用反卷积和上采样将

特征图还原到原始图像分辨率及大小。然后每个像素都被分类为目标区域或背景的一部分,最后输出分割结果。因左右对称被命名为“U-Net”。“U”型对称结构能够有效地提取和连接多尺度特征图。见图 2。

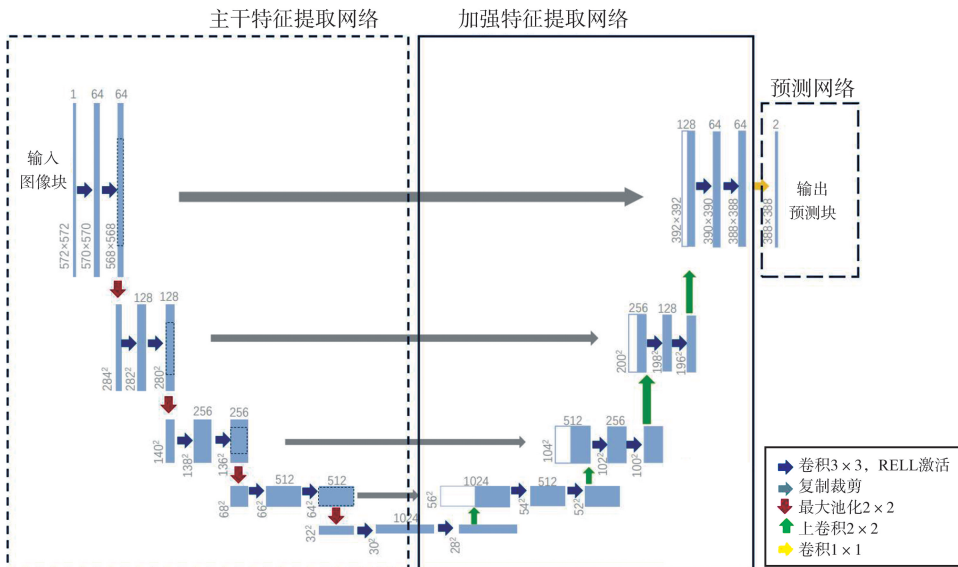


图 2 U-Net 架构图

Figure 2 U-Net architecture diagram

U-Net 在 FCN 的基础上通过跳跃连接有效融合低分辨率和高分辨率图像特征,现已成为医学图像分割的基准网络^[20]。紧接着多位学者基于U-Net 中跳跃链接机制而改进的 U-Net++ 和 U-Net 3+和 R2 U-Net 等均获得优异的分割效果^[17-18,21]。Ibtehaz 等^[22]修改了 U-Net 架构,提出了 MultiRes 块来从多个尺度中提取语义信息,利用 Res 路径来缓解两个对称编码器和解码器层之间的语义差距。由于大多数医疗数据以 3D 数据的形式存在, Milletari 等^[19]提出了一种基于 U-Net 使用 3D 卷积的三维神经网络架构 V-Net 并采用 Dice 系数的新型损失层进行训练优化模型,可使处理三维医学图像数据的效率直接提升三倍。

1.3 Transformer 模型用于语义分割

2017 年 Vaswani 等^[23]首次提出 Transformer,是第一个面向 sequence to sequence 任务的完全依赖自注意力 (self-attention) 来计算输入和输出的模型。这区别于序列对齐的递归神经网络或 CNN 的转换模型,为图像处理提供了新的思路。

2020 年 Dosovitskiy 等^[24]首次将纯 Transformer 结构独立应用于图像序列并命名为 Vision Transformer (ViT), ViT 与 CNN 相比在处理中小型图

像时更加优秀,且所需计算资源更少。由于 Transformer 的注意力机制能够很好的弥补 CNN 下采样时丢失图像信息的不足,2021 年 Zheng 等^[25]提出了 SETR,在 ViT 的基础上加入上采样、下采样,分为三种处理方式,三种分割结构的平均交并比 (mean Intersection over Union, mIoU) 为 48.06%、50.09%、50.28%。随后 Chen 等^[26]首次结合 Transformer 和 U-Net 两者的优点将其结合应用于医学图像处理领域命名为 TransUNet。在充分提取上下文输入序列的同时结合高分辨率特征图进行预测分割。2024 年 Tang 等^[27]提出了名为 HTC-Net 的医学图像分割方法,其利用深度卷积网络学习局部信息并结合 Transformer 能够捕捉全局语义信息的优势。在 ISIC-2017 数据集和 Kvasir-SEG 数据集评估了 HTC-Net。mIoU 值分别为 84.02% 和 85.94%。所提出的结构展现了良好的性能,也为未来医学图像分割走上集成深度模型的道路提供思路。

1.4 常用评估指标

Dice 相似系数 (dice similarity coefficient, DSC) 和 mIoU 均是一个用于评估图像分割模型性能指标。语义分割分类情况见表 1。

表 1 语义分割分类情况
Table 1 Semantic segmentation classification situation

情况	真实值	预测	中文名称
TP (True Positive)	Positive	Positive	真阳性
FN (False Negative)	Positive	Negative	假阴性
FP (False Positive)	Negative	Positive	假阳性
TN (True Negative)	Negative	Negative	真阴性

DSC 主要衡量分割结果与真实标注 (ground truth) 之间的相似度。

见公式(1)。

$$s = \frac{2|X \cap Y|}{|X| + |Y|} \quad (1)$$

分子为预测图和标签图逐元素点乘结果之和,分母是预测图元素之和与标签图逐元素之和。该指标范围从 0 到 1,1 表示完美的分割结果,0 表示完全不匹配^[28]。这种度量方式对于平衡分割结果中的假阳性 FP 和假阴性 FN 特别有用,因此在医学图像处理中,Dice 系数是一个非常重要的评价指标。

mIoU 为语义分割的标准度量。其计算两个集合的交并比,在语义分割的问题中,这两个集合为真实值 (ground truth) 和预测值 (predicted segmentation)。

见公式(2)。

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{P_{ii}}{\sum_{j=0}^k P_{ij} + \sum_{j=0}^k P_{ji} - P_{ii}} \quad (2)$$

等价于公式(3)。

$$mIoU = \frac{1}{k+1} \sum_{i=0}^k \frac{TP}{FN + TP + FP} \quad (3)$$

式中,分母中 $\sum_{j=0}^k P_{ij}$ 表示 i 的所有预测结果,即

$FN+TP, \sum_{j=0}^k P_{ji}$ 表示所有预测为 i 的值。mIoU 能够表示模型在预测不同类别的对象时具有的准确度和泛化能力,提供一个整体的性能指标。

1.5 主动脉影像分割领域常用数据集

通常高质量的数据集往往能够决定模型最终的训练效果和泛化能力。选择数据集时往往会将高分辨率、高清晰度的影像数据以及准确、详细的标注作为标准之一。因此本文汇总在主动脉影像分割领域

常用高质量数据集如下:

①ImageTBAD2021^[29]:此数据集可用于B型主动脉夹层的自动分割。数据集由100张3D CTA图像组成,数据来自广东省人民医院。

②The Aorta Segmentation Challenge (ASOCA)数据集^[30]:在MICCAI上发布,用于评估主动脉分割算法的性能,包含腹主动脉瘤相关数据。

③Aneurysm Segmentation Challenge (MICCAI)数据集^[31]:该数据集用于动脉瘤分割挑战,包含主动脉瘤的影像数据,提供详细的分割标注,用于训练和评估分割算法。

④AMOS^[32]:该数据集由深圳市大数据研究院发布,提供了大量的CT扫描和MRI扫描,包括了15个腹部多器官的体素级标注。总之,优质且丰富的数据集能够提升模型泛化能力以及鲁棒性。

2 在AD中的应用

主动脉解剖结构包括内膜、中膜、外膜三个部分。当主动脉内膜发生破裂,血液会从破口处涌入主动脉中膜而导致内膜逐渐剥离、扩展,在动脉内形成真、假两腔,引起主动脉中膜分离,并沿主动脉长轴方向撕裂,从而造成主动脉内膜和中膜与外膜之间形成假腔,为AD^[2]。AD患者需要终身影像监测,但是实际临床环境中,随时对AD影像进行手动分割会由于耗时、专业技能要求高等原因难以实现。因此如何使用深度学习对AD影像进行自动化分割并自动评估成像特征便成为国内外学者的研究目标。主要着力于对主动脉真腔(true lumen, TL)和假腔(false lumen, FL)的有效辨别。

Cao等^[33]开发了基于3D U-Net的三种不同架构深度学习算法,用于在接受胸部血管内修复

术的TBAD患者的对比增强CT扫描中自动分割整个主动脉、TL和FL的3D体积。其中CNN3的分割效果最佳,整个主动脉的DSC为0.93,TL为0.93,FL为0.91。此研究采用了分步式的分割方式,从结果也可以直观感受到恰当的分割策略搭配合适的算法模型对于提升分割精度而言是十分重要的。Cheng等^[34]利用单个基于U-Net模型在垂直于血管中心线的横截面上单独分割TL。最终与基线网络和U-Net网络的变形进行比较后实现了0.91的DSC。Chen等^[26]使用Transforme模型将ViT应用于医学图像分割中命名为TransUNet,利用Transforme优点表现TransUNet对于全局特征的捕捉能力,利用U-Net表现TransUNet的高效图像分割能力。Cheng等^[34]和Chen等^[26]两团队均探讨了有关于U-Net及其变种的不同应用,前者是针对于TL的精细分割,后者则结合Transforme和U-Net的优势来提高全局特征捕捉能力和分割效率,均体现了通过优化模型架构和策略来提升医学图像分割效果的重要性。在此基础上,Hahn等^[35]使用TransUNet架构基于2D图像数据利用主动脉中心线进行分割。在另一项研究中,Jung等^[36]同样基于ViT内层机制利用transformer和U-Net级联网络进一步开发,使用全景上下文感知的3D转换器来捕捉AD整体位置信息,再利用U-Net模型对于局部细节进行纹理细化,最后形成全景缩小定位-放大细化分割的方案(ZOZI-seg)。以上模型为提高AD图像分割精度均在尝试结合不同架构的优势。而后三者^[26,35-36]同时使用Transformer关注全局特征的感知,通过U-Net进行局部细节的捕捉。虽然在分割策略和部位各有侧重,但是其最终分割精度均取得不错的提升。见表2。

表2 深度学习应用于主动脉实例
Table 2 Application of deep learning to aortic examples

文献作者	图像类型	分割部位	网络架构	数据集	分割结局
Cao等 ^[33]	CT	主动脉、TL、FL	3D U-Net (CNN1\CNN2\CNN3)	276例	整体DSC:0.93 TL:0.93 FL:0.91
Chen等 ^[26]	CT	主动脉	基于Transforme和UNet的TransUNet	70例	整体DSC:0.87
Hahn等 ^[35]	CT	主动脉	基于TransUNet并依据中心线精细切割	45例	验证集DSC:0.87 测试集DSC:0.90
Cheng等 ^[34]	CT	TL	基线网络和U-Net的变形	63例	整体DSC:0.91
Jung等 ^[36]	CT	TL、FL和FH	基于3D转换器和U-Net的组合	253例	各部位DSC TL:0.917 FL:0.882 FH:0.630

深度学习模型在分割 AD 时表现出了优秀的性能,全程自动化尽可能避免了因人为手动标注带来的误差,用时远远小于人工标注且分割准确性高,这无疑为未来真正应用于医学领域打下基础。同时,深度学习的鲁棒性依赖于专家预先标注的数据集质量。因此在 AD 自动分割模型搭建以及训练测试过程中如何提高数据集质量仍是关键一环。并且考虑到主动脉病变形态的多样性,如不常见的夹层变异(双管 AD)时,自动分割技术在此情况下的分割效率以及准确率存在一定不足,无法深入进行准确的识别分割。所以,在主动脉自动分割技术真正应用于临床上还有一段距离,需要继续进行研究,日后真正意义上为医生助力。

3 在 AA 中的应用

AA 主要包括胸主动脉瘤(thoracic aortic aneurysm, TAA)和腹主动脉瘤(abdominal aortic aneurysm, AAA)。由于 AAA 发病率一般高于 TAA,因此本节主要聚焦于 AAA 图像分割。当腹主动脉最大直径超过 3 cm 或扩张超过其直径的 50% 将被判定为 AAA^[37]。AAA 位于肾动脉和髂动脉之间,发病率和死亡率较高。在过去几年中,AAA 的外科治疗已从手术转向微创腔内修复术(endovascular aortic repair, EVAR),减少了动脉瘤囊的加压,降低了壁破裂的风险^[38]。CTA 是用于评估、管理和监测 AAA 的主要成像技术。CTA 扫描后的主动脉腔分割结果是测量主动脉长度和直径的关键。

目前已经提出了几种传统的机器学习方法来分割包括动脉瘤的不同表面和体积,包括壁与管腔、血栓识别分割、管腔体积测量等。其中图切割理论^[38]是一种基于强度梯度的分割^[39]和可变邻域搜索^[40]的方法。由于血管壁与血栓表面图像数据接近导致分割困难,所以许多研究集中于血栓与血管的识别分割方向。López-Linares 等^[41]使用经过训练的 CNN 对术后 CT 图像进行了血栓分割。Zohios 等^[42]应用水平集方法检测血栓和外壁边界。这种方法在处理复杂边界和形状时表现优异,有助于更加准确评估动脉瘤的状况。Drapikowski 和 Domagala^[43]提出了一种基于轮廓的分割方法来提取主动脉结构形态。

通过以上对比不难看出主动脉壁分割传统模型具有两个特点:①需要用户进行干预(半自动方法),效率相对较低;②需要对于输入数据进行预处理。但标注者之间操作存在差异性,并且不同患者

的动脉瘤解剖结构也有所不同。所以将深度学习引入主动脉瘤图像分割是有必要的,例如 López-Linares 等^[41]利用 CNN 能够自动学习提取图像特征这一能力来保障最终分割的准确性和效率。Hwang 等^[44]使用基于区域的 CNN 进行了血栓分割。Brutti 等^[45]提出了一种全自动的深度学习模型,利用多视图集成法将 U-Net 用于识别并分割血栓,再利用管腔中心线自动提取并计算动脉瘤和管腔直径。2023 年 Abdolmanafi 等^[46]提出了一种基于 ResNet-18 架构的膨胀卷积编码器-解码器结构的全自动模型,在设定计算成本、步幅和参数数量等参数与标准卷积一致时,该模型可完整进行腹主动脉分割,包括动脉壁、管腔、血栓和钙化,对于不同型号 CT 拍摄图像均可适配。这种全自动模型基于 ResNet-18 架构,在腹主动脉分割任务中展现出了很好的潜力和性能。其创新性的设计、适应性、通用性以及高密度的输出特征为医学影像分析领域带来了新的启示。2024 年 Kim 等^[47]比较了 UNETR、SwinUNETR 和 nnU-Net 在 AAA 自动分割工作中的优势和不足。其中 UNETR 基于 Transformer 的自注意力机制,虽全局信息捕捉能力强,但训练时间长且 DSC 表现未优于其他模型;SwinUNETR 采用 Swin Transformer 编码器,在捕捉多尺度特征方面具有优势但训练复杂度高,需要更多计算资源;而 3D U-Net 的 DSC 在三者中是最佳。因此,在选择模型时,需要权衡性能和训练复杂度之间的关系,最终选择性价比高的模型进行分割。

由上可知,在 AAA 相关医学图像分析中深度学习技术越来越凸显其优势。目前深度学习模型依据 CT 影像可自动分割出 AAA 形态学结构,从而辅助医生准确进行病灶的三维重建工作。也可以预测瘤体的增长速度和破裂风险,为临床决策提供有力支持。从长期来看,它还能实现对患者的自动化跟踪与管理,及时监测瘤体变化。

自动分割模型不仅在 AAA 和 AD 方面发挥出优异的作用,在主动脉其他方向同样展露锋芒。例如:在主动脉瓣狭窄自动分割中,Rouhollahi 等^[48]为能够准确分割升主动脉和病理性瓣膜形状构建了一种基于 U-Net 架构的模型;在主动脉缩窄及主动脉弓分割中,Ramirez 等^[49]使用基于 3D U-Net、DenseNet121 和 VoxelMorph 相结合,联合训练后分割准确率为 0.99(0.01)。

尽管深度学习在主动脉诊疗分析中表现优异,但模型最终的分割效果也需要依赖于高质量数据和跨学科合作。所以针对不同的影像技术也需要选择

恰当的模型进行自动分割任务。如:Imran 等^[50]提出的 CIS-UNet 模型,结合了 CNN 和 Swin Transformer,在 CT 影像上的训练及测试中取得了优异的效果,DSC 为 0.713,优于目前最先进的 SwinUNetR 分割模型。这表明通过结合不同的深度学习技术可以进一步提高分割的准确性。Jung 等^[36]利用 Transformer 和 U-Net 的原理,设计了一种专门用于 CT 影像的 AD 分割模型。这种创新性的结合提高了分割的精度和稳定性,为临床应用提供了更可靠的工具。Manokaran 等^[51]使用 U-Net++模型对三维主动脉体积进行分割,在 MRA 影像中获得了高 DSC,显示了 U-Net++在处理三维医学图像分割中的强大能力。

4 总结与展望

越来越多的科研人员开始利用人工智能的力量来研究主动脉疾病。尤其在深度学习技术发展的推动下,主动脉自动分割技术逐渐向好。当前的研究重点不再局限于传统分类、分割算法,还包括了多任务学习、生成对抗网络、3D 分割模型等新型分割方式。然而,主动脉成像仍然很大程度上是一个有待深耕的领域。本文探讨了基于深度学习的技术在主动脉图像分割领域的最新进展和应用,重点关注 AD 和 AAA 这两类重要的疾病。通过回顾和分析现有的研究文献,明确了深度学习,尤其是 FCN 如 U-Net,以及近年来发展的 Transformer 架构对于提高图像分割准确性和效率所起到的关键作用。这些先进的算法能够从丰富的训练数据中自动学习复杂的图像特征,从而实现了对主动脉疾病影像的高精度分割。

未来主动脉自动分割技术将向着更加个性化、更加高效率、跨模态以及更加全面的方面发展。总体而言,使用深度学习分割医学图像是一条可行的道路。随着技术的不断进步和多领域合作的加强,基于深度学习的主动脉图像分割在未来的医疗健康领域将展现更加广阔的应用前景。

参考文献:

[1] 《中国心血管健康与疾病报告》编写组.《中国心血管健康与疾病报告 2022》要点解读[J]. 中国心血管杂志, 2023, 28(4): 297-312.
Committee of the Report on Cardiovascular Health and Diseases in China. Interpretation of report on cardiovascular health and diseases in China 2022[J]. Chinese Journal

of Cardiovascular Medicine, 2023, 28(4): 297-312.

[2] 高新海,徐仲卿,张晓明,等.主动脉夹层患者临床特征及导致死亡相关危险因素分析[J]. 实用临床医药杂志, 2015, 19(13): 130-131.
GAO Xinhai, XU Zhongqing, ZHANG Xiaoming, et al. Analysis of clinical characteristics and related risk factors of death in patients with aortic dissection[J]. Journal of Clinical Medicine in Practice, 2015, 19(13): 130-131.

[3] de Bruijne M, van Ginneken B, Viergever MA, et al. Interactive segmentation of abdominal aortic aneurysms in CTA images[J]. Med Image Anal, 2004, 8(2): 127-138.

[4] Ravì D, Wong C, Deligianni F, et al. Deep learning for health informatics [J]. IEEE J Biomed Health Inform, 2017, 21(1): 4-21.

[5] Shen DG, Wu GR, Suk HI. Deep learning in medical image analysis[J]. Annu Rev Biomed Eng, 2017, 19: 221-248. doi:10.1146/annurev-bioeng-071516-044442.

[6] Slomka PJ, Dey D, Sitek A, et al. Cardiac imaging: working towards fully-automated machine analysis & interpretation [J]. Expert Rev Med Devices, 2017, 14(3): 197-212.

[7] Litjens G, Kooi T, Bejnordi BE, et al. A survey on deep learning in medical image analysis[J]. Med Image Anal, 2017, 42: 60-88. doi:10.1016/j.media.2017.07.005.

[8] Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.

[9] Wang R, Zhou YQ, Zhao CY, et al. A hybrid flower pollination algorithm based modified randomized location for multi-threshold medical image segmentation [J]. Biomed Mater Eng, 2015, 26(Suppl 1): S1345-S1351.

[10] Patil DD, Deore SG. Medical image segmentation: a review[J]. International Journal of Computer Science and Mobile Computing, 2013, 2(1): 22-27.

[11] Huang BS, Tian JR, Zhang HY, et al. Deep semantic segmentation feature-based radiomics for the classification tasks in medical image analysis[J]. IEEE J Biomed Health Inform, 2021, 25(7): 2655-2664.

[12] Sevastopolsky A. Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network[J]. Pattern Recognit Image Anal, 2017, 27(3): 618-624.

[13] Yu Z, Jiang XD, Zhou F, et al. Melanoma recognition in dermoscopy images via aggregated deep convolutional features[J]. IEEE Trans Biomed Eng, 2019, 66(4): 1006-1016.

[14] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[C]//IEEE Transactions on Pattern Analysis and Machine Intelligence. IEEE, 2017: 640-651. doi:10.1109/TPAMI.2016.2572683.

[15] Ronneberger O, Fischer P, Brox T. U-net: Convolution-

- al networks for biomedical image segmentation [C]// Medical image computing and computer-assisted intervention-MICCAI 2015: 18th international conference, Munich, Germany. Springer International Publishing, 2015: 234-241.
- [16] Yu QH, Xie LX, Wang Y, et al. Recurrent saliency transformation network; incorporating multi-stage visual cues for small organ segmentation [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA. IEEE, 2018: 8280-8289. doi:10.1109/CVPR.2018.00864.
- [17] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Trans Pattern Anal Mach Intell, 2017, 39(12): 2481-2495.
- [18] Huang HM, Lin LF, Tong RF, et al. UNet 3+: a full-scale connected UNet for medical image segmentation [C]//ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Barcelona, Spain. IEEE, 2020: 1055-1059. doi: 10.1109/ICASSP40776.2020.9053405.
- [19] Milletari F, Navab N, Ahmadi SA. V-net: fully convolutional neural networks for volumetric medical image segmentation[C]//2016 Fourth International Conference on 3D Vision (3DV). Stanford, CA, USA. IEEE, 2016: 565-571. doi:10.1109/3DV.2016.79.
- [20] Fu J, Liu J, Tian HJ, et al. Dual attention network for scene segmentation [C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Long Beach, CA, USA. IEEE, 2019: 3141-3149. doi: 10.1109/CVPR.2019.00326.
- [21] Alom MZ, Hasan M, Yakopcic C, et al. Recurrent residual convolutional neural network based on U-Net (R2U-Net) for medical image segmentation[EB/OL]. 2018; arXiv: 1802.06955. (2018-05-29) [2024-03-20]. <http://arxiv.org/abs/1802.06955>.
- [22] Ibtehaz N, Rahman MS. MultiResUNet: Rethinking the U-Net architecture for multimodal biomedical image segmentation[J]. Neural Netw, 2020, 121: 74-87. doi:10.1016/j.neunet.2019.08.025.
- [23] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. 2017; arXiv: 1706.03762. (2023-08-02) [2024-03-20]. <http://arxiv.org/abs/1706.03762>.
- [24] Dosovitskiy A, Beyer L, Kolesnikov A, et al. An image is worth 16x16 words: transformers for image recognition at scale [EB/OL]. 2020; arXiv: 2010.11929. (2021-06-03) [2024-03-20]. <http://arxiv.org/abs/2010.11929>.
- [25] Zheng SX, Lu JC, Zhao HS, et al. Rethinking semantic segmentation from a sequence-to-sequence perspective with transformers [C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Nashville, TN, USA. IEEE, 2021: 6877-6886. doi:10.1109/CVPR46437.2021.00681.
- [26] Chen JN, Lu YY, Yu QH, et al. TransUNet: transformers make strong encoders for medical image segmentation [EB/OL]. 2021; arXiv: 2102.04306. (2021-02-08) [2024-03-20]. <http://arxiv.org/abs/2102.04306>.
- [27] Tang H, Chen YB, Wang T, et al. HTC-Net: a hybrid CNN-transformer framework for medical image segmentation [J]. Biomed Signal Process Contr, 2024, 88: 105605. doi:10.1016/j.bspc.2023.105605.
- [28] 苏炎洲. 基于深度学习的结直肠息肉图像分割方法研究[D]. 成都: 电子科技大学, 2023.
- [29] Yao Z, Xie W, Zhang J, et al. Imagetbad: A 3D computed tomography angiography image dataset for automatic segmentation of type-b aortic dissection[J]. Front Physiol, 2021, 12: 732711. doi: 10.3389/fphys.2021.732711.
- [30] Gharleghi R, Adikari D, Ellenberger K, et al. Annotated computed tomography coronary angiogram images and associated data of normal and diseased arteries[J]. Sci Data, 2023, 10(1): 128.
- [31] Su Z, Jia Y, Liao W, et al. 3D attention U-Net with pretraining: a solution to CADA-aneurysm segmentation challenge[C]// Hennemuth A, Goubergrits L, Ivantsits M, et al. Cerebral aneurysm detection and analysis. AG, Switzerland; Springer, 2021: 58-67.
- [32] Ji Y, Bai H, Ge C, et al. AMOS: A large-scale abdominal multi-organ benchmark for versatile medical image segmentation[C]// 36th Conference on Neural Information Processing Systems (NeurIPS 2022). Advances in Neural Information Processing Systems 35. New Orleans, USA; Curran Associates, Inc., 2022: 36722-36732.
- [33] Cao L, Shi RQ, Ge YY, et al. Fully automatic segmentation of type B aortic dissection from CTA images enabled by deep learning [J]. Eur J Radiol, 2019, 121: 108713. doi:10.1016/j.ejrad.2019.108713.
- [34] Cheng JL, Tian SW, Yu L, et al. A deep learning algorithm using contrast-enhanced computed tomography (CT) images for segmentation and rapid automatic detection of aortic dissection [J]. Biomed Signal Process Contr, 2020, 62: 102145. doi: 10.1016/j.bspc.2020.102145.
- [35] Hahn LD, Mistelbauer G, Higashigaito K, et al. CT-based true- and false-lumen segmentation in type B aortic dissection using machine learning[J]. Radiol Cardiothorac Imaging, 2020, 2(3): e190179. doi:10.1148/ryct.2020190179.

- [36] Jung JH, Oh HM, Jeong GJ, et al. ZOZI-Seg: a transformer and UNet cascade network with Zoom-Out and Zoom-In scheme for aortic dissection segmentation in enhanced CT images[J]. *Comput Biol Med*, 2024, 175: 108494. doi:10.1016/j.compbiomed.2024.108494.
- [37] Kumar Y, Hooda K, Li S, et al. Abdominal aortic aneurysm: pictorial review of common appearances and complications[J]. *Ann Transl Med*, 2017, 5(12): 256.
- [38] Duquette AA, Jodoin PM, Bouchot O, et al. 3D segmentation of abdominal aorta from CT-scan and MR images[J]. *Comput Med Imaging Graph*, 2012, 36(4): 294-303.
- [39] Siriapisith T, Kusakunniran W, Haddawy P. Outer wall segmentation of abdominal aortic aneurysm by variable neighborhood search through intensity and gradient spaces[J]. *J Digit Imaging*, 2018, 31(4): 490-504.
- [40] Siriapisith T, Kusakunniran W, Haddawy P. 3D segmentation of exterior wall surface of abdominal aortic aneurysm from CT images using variable neighborhood search [J]. *Comput Biol Med*, 2019, 107: 73-85. doi:10.1016/j.compbiomed.2019.01.027.
- [41] López-Linares K, Aranjuelo N, Kabongo L, et al. Fully automatic detection and segmentation of abdominal aortic thrombus in post-operative CTA images using Deep Convolutional Neural Networks[J]. *Med Image Anal*, 2018, 46: 202-214. doi:10.1016/j.media.2018.03.010.
- [42] Zohios C, Kossioris G, Papaharilaou Y. Geometrical methods for level set based abdominal aortic aneurysm thrombus and outer wall 2D image segmentation[J]. *Comput Methods Programs Biomed*, 2012, 107(2): 202-217.
- [43] Drapikowski P, Domagała Z. Semi-automatic segmentation of ct/MRI images based on active contour method for 3D reconstruction of abdominal aortic aneurysms[J]. *Image Process Commun*, 2014, 19(1): 13-19.
- [44] Hwang B, Kim J, Lee S, et al. Automatic detection and segmentation of thrombi in abdominal aortic aneurysms using a mask region-based convolutional neural network with optimized loss functions [J]. *Sensors*, 2022, 22(10): 3643.
- [45] Brutti F, Fantazzini A, Finotello A, et al. Deep learning to automatically segment and analyze abdominal aortic aneurysm from computed tomography angiography [J]. *Cardiovasc Eng Technol*, 2022, 13(4): 535-547.
- [46] Abdolmanafi A, Forneris A, Moore RD, et al. Deep-learning method for fully automatic segmentation of the abdominal aortic aneurysm from computed tomography imaging[J]. *Front Cardiovasc Med*, 2022, 9: 1040053. doi:10.3389/fcvm.2022.1040053.
- [47] Kim T, On S, Gwon JG, et al. Computed tomography-based automated measurement of abdominal aortic aneurysm using semantic segmentation with active learning [J]. *Sci Rep*, 2024, 14(1): 8924.
- [48] Rouhollahi A, Willi JN, Haltmeier S, et al. CardioVision: a fully automated deep learning package for medical image segmentation and reconstruction generating digital twins for patients with aortic stenosis[J]. *Comput Med Imaging Graph*, 2023, 109: 102289. doi:10.1016/j.compmedimag.2023.102289.
- [49] Ramirez P, Uus A, van Poppel MPM, et al. Multi-task learning for joint weakly-supervised segmentation and aortic arch anomaly classification in fetal cardiac MRI [J]. *Melba*, 2023, 2(PIPPi 2022): 406-446. doi:10.59275/j.melba.2023-b7bc.
- [50] Imran M, Krebs JR, Gopu VRR, et al. CIS-UNet: multi-class segmentation of the aorta in computed tomography angiography via context-aware shifted window self-attention[EB/OL]. 2024; arXiv: 2401.13049. (2024-01-23) [2024-03-20]. <http://arxiv.org/abs/2401.13049>.
- [51] Manokaran J, Garcia Flores J, Ukwatta E. Fully automated aortic segmentation of 3D phase-contrast magnetic resonance angiography images using deep learning techniques[C]//*Medical Imaging 2023: Biomedical Applications in Molecular, Structural, and Functional Imaging*. February 19-24, 2023. San Diego, USA. SPIE, 2023. doi:10.1117/12.2653344.

(编辑:房红娟)