

基于自适应采样与 Dense 机制的颅内动脉瘤血管多结构分割

张栩阳¹, 姚韵楚¹, 石悦², 佟鑫³, 梁昕语¹, 童薪宇¹, 刘爱华³, 陈端端^{1,4}

(1. 北京理工大学生命学院, 北京 100081; 2. 应脉医疗科技(上海)有限公司, 上海 200120; 3. 首都医科大学附属北京天坛医院神经介入中心, 北京 100070; 4. 北京理工大学医学技术学院, 北京 100081)

摘要: 颅内动脉瘤是一种具有较高致死和致残率的常见脑血管疾病。近年来, 临床对基于影像的智能化和精准化的疾病诊断策略提出了迫切需求, 其中血管及病灶的精准分割是其重要基础。本文提出了一种新型的颅内动脉瘤血管多结构分割框架, 利用血管先验灰度特征建立了自适应的数据采样方法, 并设计了一种基于 Dense 机制的深度网络模型实现血管分割。本文收集了 135 例颅内动脉瘤患者(年龄分布: 54.7 ± 12.7 岁, 75 名男性)的飞行时间磁共振血管影像进行模型的训练和测试。相比于原空间采样和图像压缩方法(平均 Dice 相似性系数: 0.829 和 0.780), 自适应采样方法可以明显提升血管分割的精度(平均 Dice 相似性系数: 0.858); 与经典的 3D UNet、SegNet 和 DeepLabV3+ 网络相比(平均 Dice 相似性系数: 0.854, 0.824 和 0.800), 基于 Dense 机制的网络能够利用更少的计算资源实现更优的分割效果, 对于不同位置和大小动脉瘤也表现出良好的分割鲁棒性。

关键词: 颅内动脉瘤; 磁共振血管造影; 血管分割; 深度学习; 自适应采样

中图分类号: TP183 **文献标志码:** A

Multi-structure Segmentation of Intracranial Vessels with Aneurysms Based on Adaptive Sampling and Dense Mechanism

ZHANG Xuyang¹, YAO Yunchu¹, SHI Yue², TONG Xin³, LIANG Xinyu¹, TONG Xinyu¹, LIU Aihua³, CHEN Duanduan^{1,4}

(1. School of Life Science, Beijing Institute of Technology, Beijing 100081, China; 2. Enlight Medical Technology (Shanghai) Co. Ltd., Shanghai 200120, China; 3. Department of Interventional Neuroradiology, Beijing Tiantan Hospital, Capital Medical University, Beijing 100070, China; 4. School of Medical Technology, Beijing Institute of Technology, Beijing 100081, China)

Abstract: Intracranial aneurysm is a common cerebral vascular disease with a relatively high lethiferous and disable rate. An image-based intelligent and accurate diagnosis method of the disease is urgently needed by the clinic in recent years, for which the accurate segmentation of the vessels and aneurysms is very essential. In this work, we present a novel segmentation framework for the multi-structure intracranial vessels with aneurysms. An adaptive image sampling method is designed using the prior gray-level vascular features, and a Dense mechanism-based network is proposed for the vessel segmentation. Time-of-flight magnetic resonance angiography images of 135 patients (age: 54.7 ± 12.7 , 75 males) with intracranial

aneurysms are collected for training and testing the framework. Compared with the sampling in the original space and image compression (mean DSC: 0.829 and 0.780), the adaptive sampling can obviously improve the accuracy of the vessel segmentation (mean DSC: 0.858). The Dense mechanism-based network can achieve better segmentation result while using less calculation space than the traditional models of 3D UNet, SegNet and DeepLabV3+ (mean DSC: 0.854, 0.824 and 0.800). It also shows good robustness for the segmentation of aneurysms with various locations and sizes.

Key words: intracranial aneurysm; magnetic resonance angiography; vessel segmentation; deep learning; adaptive sampling

引 言

颅内动脉瘤是一种相对常见的颅内血管疾病,通常瘤体形态较小,状态相对稳定,但仍然存在一定的破裂风险。颅内动脉瘤的破裂会导致血液进入蛛网膜下腔区域,引起蛛网膜下腔出血^[1-2],造成高达25%~50%的致死率,近一半的幸存者还会发生永久性残疾^[3]。飞行时间(Time-of-flight, TOF)磁共振血管造影(Magnetic resonance angiography, MRA)是临床最常用的颅内动脉瘤诊断影像模态之一^[4]。在传统诊断流程中,医生通常基于TOF-MRA从瘤体大小和发生位置等多元形态特征对颅内动脉瘤进行风险评估^[5],从而决定是否开展介入干预^[6]。医生在进行形态学分析时,通常经验化地对血管和动脉瘤结构进行视觉估测,缺乏支持三维精准分析的标准体系。另外,人工进行血管三维重建和分析所需要的时间成本极高,从诊断效率而言,这种流程无法适用于临床。因此,随着病患数量的逐年增加,临床对于颅内动脉瘤疾病的快速诊断和精准规划的需求越来越明显。这种诊疗模式的优化对于减轻临床工作压力、高效分配医疗资源以及推进精准诊疗建设都十分关键,而血管三维重建是实现这种优化的重要基础。近年来,针对颅内动脉瘤疾病的医学工程研究也对快速精确的血管重建提出了需求。通过在血管和病灶上测量三维参数,临床可开展疾病规律的统计学分析^[7]或建立关于疾病风险评估的机器学习模型^[8-10]。此外,血管三维重建也为各类新型数字诊疗技术研究提供关键支持,例如虚拟支架技术^[11-12]可在术前模拟支架的选择并验证其部署效果,提升手术的安全性和有效性;结合血液动力学分析技术,可计算颅内动脉瘤患者的三维血流功能特征,为疾病分析提供新的特征维度^[13-15]。

很多团队针对颅内动脉开展了一系列的分割算法研究,这些方法可大致分为两类:基于规则的传统分割方法和基于深度学习的智能分割方法。在传统方法中,以Level-set为基础的分割策略较为常见,例如有研究团队构建了一种局部化的混合Level-set方法^[16],并在TOF-MRA脑血管分割任务中进行了测试。也有研究对结合血管增强技术的3种不同的Level-set方法进行了测试,分析它们在脑血管分割中的应用性能^[17]。其他研究者基于Hessian矩阵^[18]、Otsu^[19]、优化聚类算法^[18,20]以及主动轮廓模型^[21]等,设计了TOF-MRA颅内动脉的分割模型,也都取得了不错的效果。然而,对于具有复杂特征的大规模血管影像而言,传统分割方法在泛化性上仍然具有一定的劣势。近年来,有许多团队结合深度学习技术设计了颅内血管分割方法,主要是以U-Net模型为基础^[22-23],结合图像滤波^[24]或数据增强^[25]等方案进行模型设计,或者在模型结构上引入注意力机制^[26]来实现泛化性较强的分割。然而,由于计算资源的制约,这些方法都是基于2D的图像块进行模型的训练和测试,缺乏对三维血管特征的理解。有研究者建立了一种基于3D U-Net的多尺度学习模型^[27],在输入3D图像块的同时,压缩原始影像作为输入以补充全局特征,在适应有限的计算资源的同时取得了不错的分割效果。以上研究均未面向颅内动脉瘤疾病开展分割算法的设计和测试。此外,许多新型的数字诊断与疾病分析技术需应用于特定的血管结构。例如,虚拟支架技术需将支架部署于含动脉瘤的血管区域,并模拟其与血管壁之间的力

学交互^[11-12];血液动力学分析需以局部血管区段(例如基底动脉段、左或右侧大脑动脉等)作为求解域,提升血流参数计算的准确性^[13-14];对于血管和病灶形态学特征的计算而言,特定血管区域的预识别能够有效提升测量算法的执行效率和计算精度。上述技术均能够服务于颅内动脉瘤疾病的临床诊疗流程,为其提供自动化和智能化的辅助,而血管多结构的自主识别是实现上述技术的关键基础。因此,颅内动脉不同区域的识别与重建对于临床研究和辅助诊疗技术研发都具有重要意义,但现有算法研究尚未对颅内动脉多结构分割的问题做出探索。因此,本文提出了一种面向颅内动脉瘤血管的三维分割框架,采用自适应的数据采样机制和基于Dense机制的深度卷积模型,从TOF-MRA影像中自动实现基底动脉和左、右大脑动脉3个颅内血管区域的多类别分割。

1 颅内动脉瘤MRA数据收集与标注

基于首都医科大学附属北京天坛医院的影像平台,本研究收集了2018—2020年共166例颅内动脉瘤患者的TOF-MRA影像(包含男性患者75例),患者年龄分布为 54.7 ± 12.7 岁。在该数据集中,影像水平分辨率范围为 $0.391 \sim 0.557$ mm,垂直扫描层厚范围为 $0.449 \sim 0.900$ mm,其中83.7%的数据在 (z, y, x) 方向上的体素数量为 $(256, 512, 512)$ 。部分患者的影像存在两方面问题:就成像空间的规范性而言,扫描范围可能覆盖了主动脉等大量无关区域,或者并未覆盖完整的颅内血管结构;就成像质量而言,血管远端细小分支造影不充分,或影像噪声严重十分严重。本文首先针对上述问题对数据进行清洗,最终筛选出135例影像数据形成最终数据集。为了更加客观地进行算法比较,本研究采用5-fold交叉验证机制训练和测试不同模型,在每组实验中训练数据与测试数据的比例为4:1,并用5组测试结果的平均值作为模型性能的衡量标准。

本文基于颅内血管的先验解剖结构,将整个血管树划分为3个部分:(1)根据前交通动脉,将大脑前、大脑中以及颈内动脉分为左、右对称的两个区域,分别记为L和R;(2)将基底动脉和两侧对称的大脑后动脉归为同一区域,并根据后交通动脉将该区域与L和R分离,记为M。对于在血管解剖结构中不存在后交通动脉,导致大脑后动脉与基底动脉未连通的患者,本文同样将大脑后动脉和基底动脉归于同一类中,从而避免在不同患者的血管结构划分上产生歧义。本文全部入组数据均由1位专家医生完成标注,并通过了多位其他专家的验证,建立了最终的标注数据集。

2 本文方法

2.1 基于血管灰度先验特征的感兴趣区域自适应计算

在MRA影像中,颅内动脉具有如下两种明显的形态学特征:颅内血管由近端到远端呈现出由粗渐细的树状结构,结构曲率变化明显且十分复杂;血管远端的树状结构几乎分布于整个颅腔内,占据了较大的成像空间,但单根血管非常细小,占据了极少量的体素。为了能够基于三维影像特征实现更加精准的三维血管结构分析,有两种方案可以采取:(1)基于插值运算压缩全图进行分割,但由于颅内血管过于细小,图像压缩必定会造成大量不可弥补的细节丢失;(2)对图像进行区块采样,通过增加采样率来模拟全图视觉,但可能对于血管复杂的连接特征学习不充分,影响到血管分割的完整性。本文以图像裁剪策略为基础,首先建立了一种自适应的感兴趣区域(Volume of interest, VOI)计算方法来预设采样空间,旨在强化训练过程中数据裁剪的有效性。

图1描述了VOI自适应计算的全过程。首先,已知TOF-MRA影像中血管结构的先验灰度范围在50~700之间,本文提取介于该范围的全部体素作为前景,实现图像的二值化,但由于部分骨性结构也在该灰度范围内,特别是分布于外周的不对称颅骨可能会影响到VOI的定位,可以通过形态学开运算去除颅骨区域,随后取出最大连通域,剩余前景结构则主要由颅内血管组成。考虑到血管树远端的血

管结构在 X 和 Y 方向上分布更广,也更能够反映血管全局结构的实际位置,本文提取了 Z 轴上半部分影像中的前景结构,获取其在水平面内的最小边界框,并设定边界框的几何中心为 (x_0, y_0) 。进一步地,本文对边界框进行优化,预设在每个影像的 X - Y 平面内均提取边长为 S 的方形空间作为 VOI,并通过如下方式计算其在每个原始影像中对应地实际采样区域,即

$$\begin{cases} d_{\min} = d_0 - \frac{S}{2r_s} \\ d_{\max} = d_0 + \frac{S}{2r_s} \end{cases} \quad (1)$$

式中: d 表示 x 或 y ; \min/\max 描述在该维度上 VOI 空间的下/上边界; r_s 表示每例图像在 X/Y 轴方向的原始分辨率。本文保留了全部数据的原始分辨率,避免因插值造成细节特征丢失,并设置 $S = 170$ mm。由于血管树分布于整个 Z 轴空间,并未在 Z 轴方向限定采样区间,最终提取的 VOI 区域进行灰度范围的约束,即将灰度值低于 50 或高于 900 的背景和噪声区域置零。




图1 基于血管先验灰度特征的VOI自适应计算

Fig.1 Adaptive VOI calculation based on the prior vascular gray-level feature

2.2 网络设计

本文借鉴 DenseNet 网络^[28]的设计理念,构建了1种以 Dense 模块为核心的分割网络模型,网络的基本架构如图2所示。在网络的降采样结构中,共建立了3个具有不同深度的 Dense 模块,每一个模块的逐层信道增量均为 12,但深度不同。3个 Dense 模块分别包含 4、8 和 16 层卷积层(Conv),每层 Conv 均采用 $3 \times 3 \times 3$ 的卷积核输出 12 个特征信道,并基于 Batchnorm 和 LReLU 层进行归一化和特征激活。为了更加适应有限的显存空间,在每一个 Dense 模块前均设置了单层 Conv 进行图像的下采样(卷积核为 $4 \times 4 \times 4$,卷积步长为 2),每个下采样层同时接受上一个 Dense 模块处理前、后的浅层和深层特征;在网络的升采样结构中包含 3 个升采样模块,每个模块由单个具有 $3 \times 3 \times 3$ 卷积核的反卷积层构成,同时接受上一层的输出和来自同层级 Dense 模块的浅层与深层特征。最终,网络通过单层 Conv 实现信道收缩和输出,由于在该分割任务中需要实现背景和 3 种血管结构的识别,输出层的输出信道设置为 4。以 Dense 模块为核心的网络模型具有较高的计算效率,能够用较少的计算参数进行高效的特征和梯度传递,因此也易于用更少的计算空间实现高精度的分割任务。

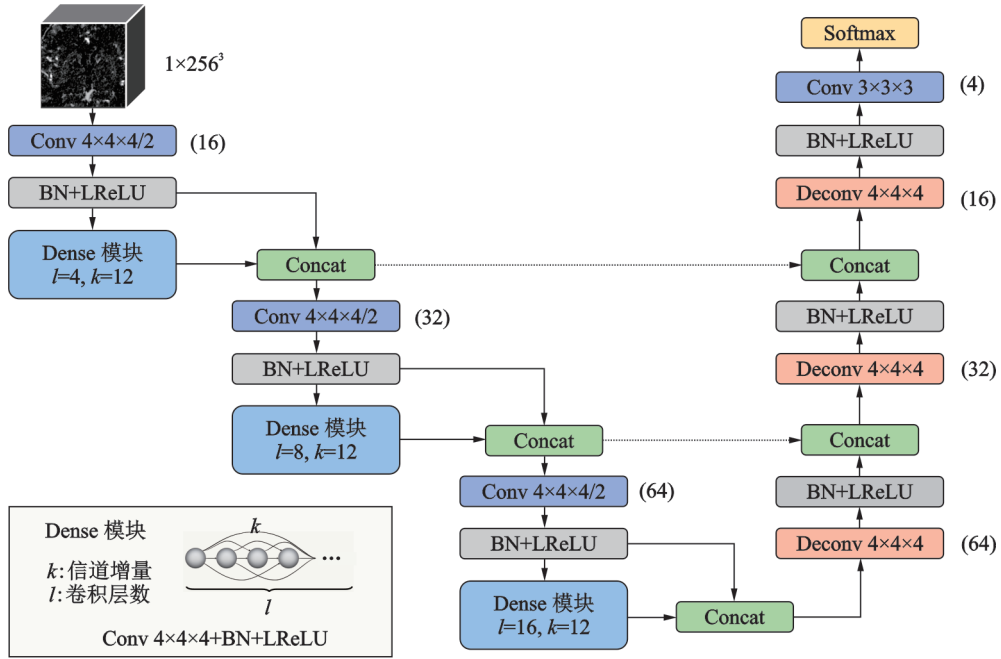


图2 基于Dense模块的网络结构

Fig.2 The proposed network based on Dense block

2.3 训练设置及评价指标

针对多类别结构的分割任务,在本研究中直接采用多类别Dice损失函数进行模型的优化,损失函数为

$$L_{\text{Dice}} = -\frac{2}{C} \sum_{c=1}^C \frac{\|Y_c \cdot \hat{Y}_c\|_1}{\|Y_c\|_2^2 + \|\hat{Y}_c\|_2^2} \quad (2)$$

式中: C 和 c 分别表示任务中所需要分割的类别数和类别编号; Y_c 和 \hat{Y}_c 分别表示对应类别的标注结果和预测概率。对于算法的数值评价,采用了两项评价指标,分别为Dice相似性系数(Dice similarity coefficient, DSC)和95% Hausdorff距离(95% Hausdorff distance, HD_{95}),其中DSC用于评价分割结果和标注结果的全局重合性,但并不能充分反映细小血管的分割效果,而 HD_{95} 对于小血管分割不良或噪声所造成的边界差异则更加敏感。两种评价指标的计算公式为

$$\text{DSC} = \frac{2|R \cap G|}{|R| + |G|} \quad (3)$$

$$\text{HD}_{95} = \frac{P_{95}[D(R, G)] + P_{95}[D(G, R)]}{2} \quad (4)$$

式中: R 和 G 分别表示分割结果和标注结果; $D(R, G)$ 描述了从 R 中的每一个边界体素到 G 中边界体素的最近距离的集合; $P_{95}[D]$ 计算了该集合中的95%百分位的距离值。

在模型训练的过程中,本文设置的超参数如下:单次迭代采用的批数据量为2,共执行约30 000次迭代;基于随机梯度下降算法优化模型参数,初始学习率为0.01,并在每10 000次迭代后衰减为原学习率的 10^{-1} ;模型权重的衰减系数为 10^{-4} 。所有模型均部署于Linux服务器(显卡配置:Geforce RTX3090 \times 2)上开展训练和测试。本文设定训练过程中3D图像裁剪的目标大小为 256^3 ,单个VOI中图像块采样频率为40;在推理的过程中,算法首先计算测试数据的VOI,随后在VOI中紧邻图像

边缘取出数个大小为 256^3 的图像块,并确保任意2个图像块间重叠最小,所有图像块可共同覆盖整个VOI。由于图像块之间重叠的体素会被重复分割,本文采用这些体素在不同图像块中预测结果的均值作为最终的分割结果。

3 实验验证

3.1 自适应VOI计算模块作用分析

本文首先分析自适应VOI计算模块对分割效果的影响,并与2种传统的数据采样方案进行比较。(1)原空间裁剪。直接在原始影像空间中多次随机提取三维图像块进行模型训练。本文设定图像块的采样频率为40,所提取的图像块大小同样为 256^3 ,与自适应采样方法中提取的图像块大小一致。(2)图像压缩。基于插值运算对原图进行压缩后训练模型。由于这种方案会造成训练样本量的锐减,在训练的过程中设计了数据增强策略。首先,在 $[-60^\circ, 60^\circ]$ 的范围内随机选取转角,并使压缩后的图像在X-Y平面内旋转对应的角度;另外,鉴于颅内血管解剖结构的对称性,压缩后的影像可随机进行左右对侧翻转,但在翻转后需对换标注中的L和R,避免造成左、右侧动脉的位置歧义。在该实验中,图像压缩的目标大小同样为 256^3 ,基于数据增强的图像采样率为40。上述3种采样方案均以本文构建的基于Dense机制的网络为载体进行测试(2.2节),并在训练的过程中使用了同样的超参数(2.3节)。为了公平比较数据采样方案的作用,在计算评价指标之前,本文首先通过插值运算将图像压缩策略下的分割结果复原为原始分辨率。最终所有指标的计算均在原始空间分辨率下进行。

表1展示了基于不同数据采集方案训练的模型在测试集上的分割效果,可以发现就DSC而言,本文提出的方法具有明显优势。该结果说明预先设定图像裁剪的VOI区域可能强化了训练数据的有效性,从而在训练过程中提供更加丰富的血管特征,能够在一定程度上减少血管断裂和假阳性分割,提高模型的鲁棒性。图3展示了2个案例在3种不同采样方法下分割结果的可视化,可以发现图像压缩策略会明显造成血管特征失真,导致血管轮廓非常粗糙,难以用于进一步的测量和分析;在原始空间进行图像采样时,模型难以充分理解血管的空间连续性,容易分割出断裂的血管片段,并且受到细小骨性结构的影响,造成假阳性分割。

表1 基于不同数据采集及训练方案的分割结果

Table 1 Segmentation results based on different image collection and training strategies

预处理策略	DSC			HD ₉₅ / mm		
	M	L	R	M	L	R
原空间裁剪	0.831 (0.126)	0.831 (0.102)	0.825 (0.103)	7.157 (10.12)	5.885 (4.066)	9.902 (9.890)
图像压缩	0.781 (0.082)	0.781 (0.041)	0.777 (0.040)	4.563 (4.185)	5.960 (4.593)	5.655 (4.760)
本文方法	0.861 (0.099)	0.862 (0.083)	0.852 (0.069)	5.032 (6.049)	6.941 (7.288)	8.886 (10.98)

HD₉₅所描述的是边界误差,但就该指标而言,本文构建的模型并未表现出明显的优势,而是图像压缩方法表现出更好的效果。这主要是因为边界误差对于离散的分割结果和噪声十分敏感,图像压缩虽然导致细节丢失,但完整的结构信息有利于模型区分血管和骨性区域,减少了假阳性分割和血管断裂的发生。另外,在不同结构分割结果的比较中可以发现,L和R的分割结果中表现出更多的离散噪声,这可能是由于大脑上动脉和中动脉远端的小血管十分复杂,而且造影不均匀,更易产生不连续的血管分割,引发更大的边界误差。

3.2 多网络模型横向比较

为了验证基于Dense机制的网络模型所具有的优势,引入了其他在医学或自然图像领域广泛应用




图3 基于不同数据采集方案的分割结果可视化

Fig.3 Visualization of segmentation results based on different image sampling strategies

的模型进行横向比较,包括3D U-Net^[29],SegNet^[30]和DeepLabV3+^[31]三种网络模型。本文在确保每种网络的全局结构不变的条件下,对上述3种网络的信道数量进行适当调整,使GPU能够在训练过程中容纳下尺寸为 256^3 的输入图像,并和Dense机制网络占用相同大小的计算空间。所有训练均采用本研究提出的基于VOI的自适应图像裁剪方法进行数据采样,并使用与2.3节中描述一致的超参数。不同模型的参数规模及其在2种指标上的测试结果均展示于表2中。结果可以证明,以Dense模块为核心的网络不仅可以提升参数利用效率,还能够进一步提高血管分割的精度。

表2 基于不同网络模型的分割结果

Table 2 Segmentation results based on different network architectures

网络模型	参数规模/ 10^6	DSC			HD ₉₅ /mm		
		M	L	R	M	L	R
3D U-Net	3.63	0.860 (0.104)	0.857 (0.091)	0.845 (0.100)	6.080 (9.580)	6.352 (6.944)	7.450 (7.832)
SegNet	6.59	0.827 (0.092)	0.820 (0.075)	0.824 (0.069)	4.774 (3.745)	6.347 (4.457)	7.832 (7.364)
DeepLabV3+	303.41	0.806 (0.116)	0.800 (0.073)	0.793 (0.068)	5.565 (8.749)	5.806 (5.702)	6.942 (6.943)
本文方法	2.84	0.861 (0.099)	0.862 (0.083)	0.852 (0.069)	5.032 (6.049)	6.941 (7.288)	8.886 (10.98)

3.3 颅内动脉瘤分割定性分析

颅内动脉瘤血管结构的自动分割可以支持精确诊断、病灶测量以及手术规划等临床流程。其中,对于动脉瘤病灶区域的精准分割在很大程度上反映了算法的实际应用价值。本文针对分布于不同血管结构、具有不同大小的颅内动脉瘤分割结果进行定性分析,进一步验证模型的有效性。图4展示了3个分别生长于左大脑动脉、基底动脉和右大脑动脉上的动脉瘤,以及对应的人工标注和自动分割结果。可以发现,虽然颅内动脉瘤在形态和空间分布上均具有一定的随机性,本文所建立的分割框架对于瘤体的分割仍表现出良好的泛化性。




图4 具有不同位置及形态特性的颅内动脉瘤分割效果定性分析

Fig.4 Qualitative segmentation analysis of the intracranial aneurysms with different location and morphology features

4 结束语

本文提出了一种面向 TOF-MRA 中颅内动脉瘤血管的多结构自动分割框架。该框架基于血管灰度先验特征,从原始影像中自适应计算血管区域的 VOI,通过限定数据采样空间来强化图像采样的有效性。本文还构建了一种以 Dense 模块为核心的网络模型,实现了基底动脉和左、右大脑动脉 3 种血管结构区域的高精度分割。实验结果表明,基于造影血管先验特征的自适应采样可以有效提升分割精度;与传统网络模型相比,基于 Dense 机制的分割网络在计算效率和精度上均具有明显优势。本文提出的分割框架不仅能够自动区分血管解剖区域,对于具有不同大小和生长位置的瘤体也表现出良好的分割泛化性,因此具有良好的临床及科研应用价值。

参考文献:

- [1] JOHNSTON S C, SELVIN S, GRESS D R. The burden, trends, and demographics of mortality from subarachnoid hemorrhage[J]. *Neurology*, 1998, 50(5): 1413-1418.

- [2] KEEDY A. An overview of intracranial aneurysms[J]. *McGill Journal of Medicine*, 2006, 9(2): 141-146.
- [3] XU Z, RUI Y N, HAGAN J P, et al. Intracranial aneurysms: Pathology, genetics, and molecular mechanisms[J]. *NeuroMolecular Medicine*, 2019, 21(4): 325-343.
- [4] MAUPU C, LEBAS H, BOULAFTALI Y. Imaging modalities for intracranial aneurysm: More than meets the eye[J]. *Frontiers in Cardiovascular Medicine*, 2022, 9: 793072.
- [5] THOMPSON B G, BROWN R D, AMIN-HANJANI S, et al. Guidelines for the management of patients with unruptured intracranial aneurysms: A guideline for healthcare professionals from the American heart association/American stroke association [J]. *Stroke*, 2015, 46: 2368-2400.
- [6] DONNELLY P, MCMILLEN J, RAMAN V, et al. Intracranial aneurysms: The era of endovascular intervention in Australia [J]. *Journal of Clinical Neuroscience*, 2022, 97: 127-135.
- [7] KLEINLOOG R, DE MUL N, VERWEIJ B H, et al. Risk factors for intracranial aneurysm rupture: A systematic review[J]. *Neurosurgery*, 2018, 82(4): 431-440.
- [8] WALTHER G, MARTIN C, HAASE A, et al. Machine learning for rupture risk prediction of intracranial aneurysms: Challenging the PHASES score in geographically constrained areas[J]. *Symmetry*, 2022, 14(5): 943.
- [9] HEO J, PARK S J, KANG S H, et al. Prediction of intracranial aneurysm risk using machine learning[J]. *Science Report*, 2020, 10(1): 6921.
- [10] LIU Q, JIANG P, JIANG Y, et al. Prediction of aneurysm stability using a machine learning model based on PyRadiomics-derived morphological features[J]. *Stroke*, 2019, 50(9): 2314-2321.
- [11] ZHAO L, CHEN D, CHEN Z, et al. Rapid virtual stenting for intracranial aneurysms[C]//*Proceedings of SPIE*. Sandiego, CA, USA: SPIE, 2016: 9786.
- [12] BERG P, SAALFELD S, JANIGA G, et al. Virtual stenting of intracranial aneurysms: A pilot study for the prediction of treatment success based on hemodynamic simulations[J]. *The International Journal of Artificial Organs*, 2018, 41(11): 698-705.
- [13] ZHANG Y, MU S, CHEN J, et al. Hemodynamic analysis of intracranial aneurysms with daughter blebs[J]. *European Neurology*, 2011, 66(6): 359-367.
- [14] HAN P, JIN D, WEI W, et al. The prognostic effects of hemodynamic parameters on rupture of intracranial aneurysm: A systematic review and meta-analysis[J]. *International Journal of Surgery*, 2021, 86: 15-23.
- [15] CHO K C, YANG H, KIM J J, et al. Prediction of rupture risk in cerebral aneurysms by comparing clinical cases with fluid - structure interaction analyses[J]. *Scientific Reports*, 2020, 10(1): 18237.
- [16] HONG Q, LI Q, WANG B, et al. 3D vasculature segmentation using localized hybrid level-set method[J]. *BioMedical Engineering OnLine*, 2014, 13: 169.
- [17] NEUMANN J O, CAMPOS B, YOUNES B, et al. Evaluation of three automatic brain vessel segmentation methods for stereotactical trajectory planning[J]. *Computer Methods and Programs in Biomedicine*, 2019, 182: 105037.
- [18] 曹容菲,王醒策,武仲科,等.基于Hessian矩阵特征值聚类的脑血管分割方法[J].*系统仿真学报*, 2014, 26(9): 2104-2109, 2115.
CAO Rongfei, WANG Xingce, WU Zhongke, et al. Cerebrovascular segmentation method based on hessian matrix and clustering[J]. *Journal of System Simulation*, 2014, 26(9): 2104-2109, 2115.
- [19] 张汴卡,相艳,易三莉,等.MRA脑血管图像局部Otsu分割研究[J].*计算机科学与探索*, 2013, 7(11): 1026-1032.
ZHANG Bianka, XIANG Yan, YI Sanli, et al. Local Otsu segmentation of MRA cerebrovascular image[J]. *Journal of Frontiers of Computer Science and Technology*, 2013, 7(11): 1026-1032.
- [20] 王喆,赵世凤,田云,等.基于自适应聚类中心的脑血管分割方法[J].*郑州大学学报(工学版)*, 2019, 40(1): 18-23, 31.
WANG Zhe, ZHAO Shifeng, TIAN Yun, et al. Cerebral vessel segmentation based on adaptive clustering centers[J]. *Journal of Zhengzhou University(Engineering Science)*, 2019, 40(1): 18-23, 31.
- [21] 杜光伟,曹会志,罗述谦.一种脑MRA图像自动分割算法及其在图像导引神经外科中的应用[J].*中国生物医学工程学报*, 2005, 4: 438-442.
DU Guangwei, CAO Huizhi, LUO Shuqian. Automatic segmentation and visualization of brain MRA images for image-guided neurosurgery[J]. *Chinese Journal of Biomedical Engineering*, 2005, 4: 438-442.

- [22] LIVNE M, RIEGER J, AYDIN O U, et al. A U-Net deep learning framework for high performance vessel segmentation in patients with cerebrovascular disease[J]. *Frontiers in Neuroscience*, 2019, 13: 97.
- [23] CHENG M, XIAO N, YUAN H, et al. Automatic intracranial aneurysm segmentation based on spatial information fusion feature from 3D-RA using U-Net[C]//*Proceedings of IEEE International Conference on Mechatronics and Automation (ICMA)*. [S.l.]: IEEE, 2021: 236-241.
- [24] 秦志光,陈浩,丁熠,等.基于多模态卷积神经网络的脑血管提取方法研究[J].*电子科技大学学报*, 2016, 45(4): 573-581.
QIN Zhiguang, CHEN Hao, DING Yi, et al. Research on brain vessel extraction via multi-modal convolutional neural networks[J]. *Journal of University of Electronic Science and Technology of China*, 2016, 45(4): 573-581.
- [25] KOSSEN T, SUBRAMANIAM P, MADAI V I, et al. Anonymization of labeled TOF-MRA images for brain vessel segmentation using generative adversarial networks[EB/OL]. (2020-11-16) [2022-05-01]. <https://doi.org/10.48550/arXiv.2009.04227>.
- [26] NI J, WU J, WANG H, et al. Global channel attention networks for intracranial vessel segmentation[J]. *Computers in Biology and Medicine*, 2020, 118: 103639.
- [27] HILBERT A, MADAI V I, AKAY E M, et al. BRAVE-NET: Fully automated arterial brain vessel segmentation in patients with cerebrovascular disease[J]. *Frontiers in Artificial Intelligence*, 2020, 3: 552258.
- [28] HUANG G, LIU Z, VAN D M L, et al. Densely connected convolutional networks[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*. [S.l.]: IEEE, 2017: 2261-2269.
- [29] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: Learning dense volumetric segmentation from sparse annotation[EB/OL]. (2016-06-21)[2022-05-01]. <https://arxiv.org/abs/1606.06650>.
- [30] 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.
- [31] CHEN L C, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//*Proceedings of European Conference on Computer Vision*. [S.l.]: Springer, 2018: 801-818.

作者简介:



张栩阳(1997-),男,博士研究生,研究方向:图像处理、人工智能, E-mail: 3120215706@bit.edu.cn.



姚韵楚(1998-),女,硕士研究生,研究方向:医学图像处理。



石悦(1986-),男,博士研究生,研究方向:生物力学与仿真。



佟鑫(1994-),男,博士研究生,研究方向:神经介入、医学图像处理。



梁昕语(1999-),女,硕士研究生,研究方向:医学图像处理。



童薪宇(1997-),女,硕士研究生,研究方向:医学图像处理。



刘爱华(1974-),男,主任医师,研究方向:神经介入。



陈端端(1982-),通信作者,女,博士,教授,研究方向:生物力学与仿真、人工智能, E-mail: duanduan@bit.edu.cn.

(编辑:刘彦东)