

DOI:10.3969/j.issn.1005-202X.2025.10.014

医学影像物理

## 基于掩码建模的磁共振血管造影的三维血管分割

李得瑄<sup>1</sup>, 王成龙<sup>1</sup>, 张琪<sup>1</sup>, 张雪凤<sup>2</sup>, 杨光<sup>1</sup>

1. 华东师范大学医学磁共振与分子影像技术研究院/上海市磁共振重点实验室, 上海 200062; 2. 中国人民解放军海军军医大学第一附属医院, 上海 200433

**【摘要】**磁共振血管成像(MRA)是一种用于观察血管的无创成像技术。通过对MRA图像进行定量分析,可以显示血管的路径、状态和血流动态,对诊断血管病变、狭窄、阻塞等血管相关疾病具有重要意义。血管分割是血管定量分析的基础,相比其他器官的分割,血管形态复杂,难以标记,准确的三维血管标记相对稀缺,给磁共振血管造影的血管分割带来了很大的挑战。本文提出在训练血管分割模型时,采用选择性地遮挡血管的策略来增强算法捕获血管拓扑结构的能力,提升血管分割结果的连续性;同时,提出Refine网络,对分割网络的二值化分割结果进行调整,从而进一步提升分割精度。在MIDAS公开数据集的42例3D MRA数据上进行训练和测试。基于3D U-Net的基线模型,血管遮挡策略下测试集分割结果的 $\beta_0$  Error、 $\beta_1$  Error分别为 $1.2742 \pm 0.2103$ 和 $0.3393 \pm 0.0818$ ,比基线结果分别降低0.1136和0.0280。采用血管遮挡策略及Refine网络的模型,平均分割Dice达到 $0.7105 \pm 0.0125$ ,比基线结果提升0.0028。由此可见,本文方法可以在提升血管连通性的同时提升分割精度。

**【关键词】**深度学习;血管分割;磁共振血管成像;拓扑连通性

**【中图分类号】**R318;TP391.41

**【文献标志码】**A

**【文章编号】**1005-202X(2025)10-1361-08

### Three-dimensional vessel segmentation in magnetic resonance angiography using mask modeling

LI Dexuan<sup>1</sup>, WANG Chenglong<sup>1</sup>, ZHANG Qi<sup>1</sup>, ZHANG Xuefeng<sup>2</sup>, YANG Guang<sup>1</sup>

1. Shanghai Key Laboratory of Magnetic Resonance/Institute of Magnetic Resonance and Molecular Imaging in Medicine, East China Normal University, Shanghai 200062, China; 2. The First Hospital Affiliated to Naval Medical University, Shanghai 200433, China

**Abstract:** Magnetic resonance angiography (MRA) is a non-invasive imaging technique used to observe blood vessels. Quantitative analysis of MRA images enables visualization of vascular pathways, condition, and blood flow dynamics, which is essential for diagnosing vascular diseases such as vascular lesions, stenosis, and occlusions. Vessel segmentation serves as the fundamental basis for quantitative vascular analysis. However, the complex morphology of vessels, difficulties in labeling, and scarcity of accurate 3D vascular annotations pose significant challenges for MRA-based vessel segmentation. A strategy of selectively occluding vessels during model training is proposed to enhance the algorithm's capacity to capture the topological structure of blood vessels, thereby improving the continuity of vessel segmentation results. Additionally, a Refine network is incorporated to refine the binary segmentation results of the segmentation network, thereby further improving segmentation accuracy. Model training and testing are carried out using 42 cases of 3D MRA data from the public MIDAS dataset. For the test set, the 3D U-Net baseline model with vessel occlusion strategy shows a  $\beta_0$  Error of  $1.2742 \pm 0.2103$  and a  $\beta_1$  Error of  $0.3393 \pm 0.0818$ , respectively, which are 0.1136 and 0.0280 lower than the baseline. The model integrating vessel occlusion strategy and Refine network achieves an average Dice score of  $0.7105 \pm 0.0125$ , which is 0.0028 higher than the baseline. These results demonstrate that the proposed method effectively improves both vascular connectivity and segmentation accuracy.

**Keywords:** deep learning; vessel segmentation; magnetic resonance angiography; topological connectivity

**【收稿日期】**2025-05-15

**【基金项目】**上海市自然科学基金(20ZR1456300)

**【作者简介】**李得瑄, 硕士研究生, 研究方向: 医学图像处理、人工智能,  
E-mail: 51214700071@stu.ecnu.edu.cn

**【通信作者】**杨光, 博士, 副研究员, 研究方向: 医学图像处理、人工智能,  
E-mail: gyang@phy.ecnu.edu.cn

### 前言

根据世界卫生组织(WHO)的数据,心血管疾病仍是全球死亡的主要原因,每年约导致1 790万人死亡,这突显了对血管疾病早期诊断的需求<sup>[1-2]</sup>。磁共振血管成像(Magnetic Resonance Angiography, MRA)作为一

种非侵入性诊断工具,提供血管结构和血流信息,能有效检测血管狭窄、闭塞、瘤变等异常情况。然而,血管形态复杂且相互遮挡,传统的MRA分析依赖医生手工分割,增加了工作量并提高了漏诊风险。

近年来,深度学习在血管检测和分割方面取得了广泛的应用<sup>[3-11]</sup>。血管分割的拓扑连续性可以保证血管结构的完整性,对于提高诊断精度和可靠性至关重要。许多研究开始关注拓扑连续性,推动了该领域的进展<sup>[4-7]</sup>。拓扑损失函数通过测量分割结果与真实标注之间的拓扑差异,指导模型关注血管的连通性而非像素级精度。例如,Hu等<sup>[8]</sup>提出的拓扑损失函数,以血管分割结果与真实标注之间的拓扑差异作为损失函数,然而拓扑损失函数计算复杂度比较高,优化过程很不稳定。Shit等<sup>[9]</sup>基于中心线的损失函数,该方法在损失函数中考虑了血管中心线的连续性,可以更好地保持血管的结构完整性,进而提升了血管分割结果的连续性。但是这种方法依赖于中心线计算的结果,使得其对细小血管和边界不够敏感。Yang等<sup>[10]</sup>通过独特的网络设计,挖掘图像中的方向信息,增强分割结果的连续性,但是其网络结构过于复杂,训练资源消耗过大。Xia等<sup>[11]</sup>通过提出了REAM (Reverse Edge Attention Module) 模块和FSM (Feature Selection Module),它通过增加对血管的边界部分的注意力权重,改善了血管边缘的分割效果,极大地提升了血管分割的整体精度,在脑血管分割和神经分割等多个数据集中有良好的表现,但这种方法没有考虑血管的拓扑连续性,难以保证细小血管的分割效果。

受到掩码自编码(Masked AutoEncoders, MAE)<sup>[12]</sup>和掩码图像建模(Masked Image Modeling, MIM)<sup>[13]</sup>等工作的启发,提出了掩码血管建模(Masked Vessel Modeling, MVM)方法,借此训练三维血管分割模型。该方法通过遮挡部分血管,促进网络学习血管结构的拓扑连续性,从而提升分割结果的精度。为了进一步优化分割效果,引入了精细化模型-Refine模型,Refine模型以基础分割模型的二值化的分割结果为输入,进一步优化血管分割的结果。由于网络使用了二值化的分割结果作为输入,减小了Refine模型的任务难度,使得模型训练更加简单高效。本文的主要工作就是基于MVM训练策略和Refine模型提升血管分割的精度和连续性,尝试用预训练的方法来解决血管分割结果不连续的问题。

## 1 实验数据与数据预处理

### 1.1 数据集介绍

MIDAS是一个公开的磁共振脑血管数据集<sup>[14]</sup>,

其中包括100名健康受试者的大脑图像,每个年龄段(18~29岁、30~39岁、40~49岁、50~59岁和60岁以上)扫描20名被试,每组按性别平均分配,并排除任何有糖尿病、高血压、头部外伤、精神疾病或其他可能影响大脑的症状或病史的受试者。根据标准化方案在3T设备上采集图像。所有被试都签署了同意书,允许在网络上公开其影像。本研究使用了此数据集中的42例MRA图像数据,这些数据由Siemens Allegra头部专用3T磁共振扫描仪以(0.5×0.5×0.8) mm<sup>3</sup>的空间分辨率采集,并使用了由Aylward和Bullitt从MRA图像中提取的颅内血管(中心线+半径)后利用开源工具ITK (Insight Toolkit)生成的血管标注<sup>[15]</sup>。图1展示了其中一例MRA数据的某一层图像和其对应的3D血管标注。




图1 MIDAS数据集图像展示

Figure 1 Examples from MIDAS dataset

a: MRA 图像的其中一层, b: 完整的3D标注

将42例带有3D血管标注的MRA图像随机划分23例用于训练,11例用于验证,8例用于测试。

### 1.2 数据预处理

在实验中,通过HD-BET工具<sup>[16]</sup>对原始MRA数据进行去头壳操作,去除颅骨对分割效果的影响。为了更好地显示血管结构,图像在经过Min-Max归一化之前,将所有图像统一设置窗宽为220,窗位设置为220,降低图像背景的灰度值,以获得更佳对比度的血管图像,每次训练之前都将图像随机裁剪为128×128×128大小的图像块输入网络,以降低显存占用。为了增加样本量,训练过程中每一个批次取两个来自同一个数据的图像块。通过对图像进行随机的对比度调整进行数据扩增,即对于图像中的每一个体素,进行如下变换:

$$x = \left( \frac{x - \min}{\max - \min} \right)^{\text{gamma}} \times (\max - \min) + \min \quad (1)$$

其中, $x$ 是当前体素的灰阶, $\max$ 是整个图像的最大灰

阶,  $\min$  是整个图像的最小灰阶,  $\gamma$  是对比度调整的参数, 设置为 0.7~1.3 之间的随机数。此外, 也通过对图像进行水平镜像翻转, 进一步增加训练数据的多样性。

## 2 实验方法

本文实验选择 3D U-Net 作为基线分割模型<sup>[17]</sup>。训练过程中主要使用了 MVM 策略, 引导网络学习如何将人为遮断的血管连接起来。在使用 MVM 训练分割模型的基础上, 笔者又预训练了一个专门用于提升血管连通性的 Refine 模型, 进一步提升血管分割结果的精度。具体的流程如图 2 所示。

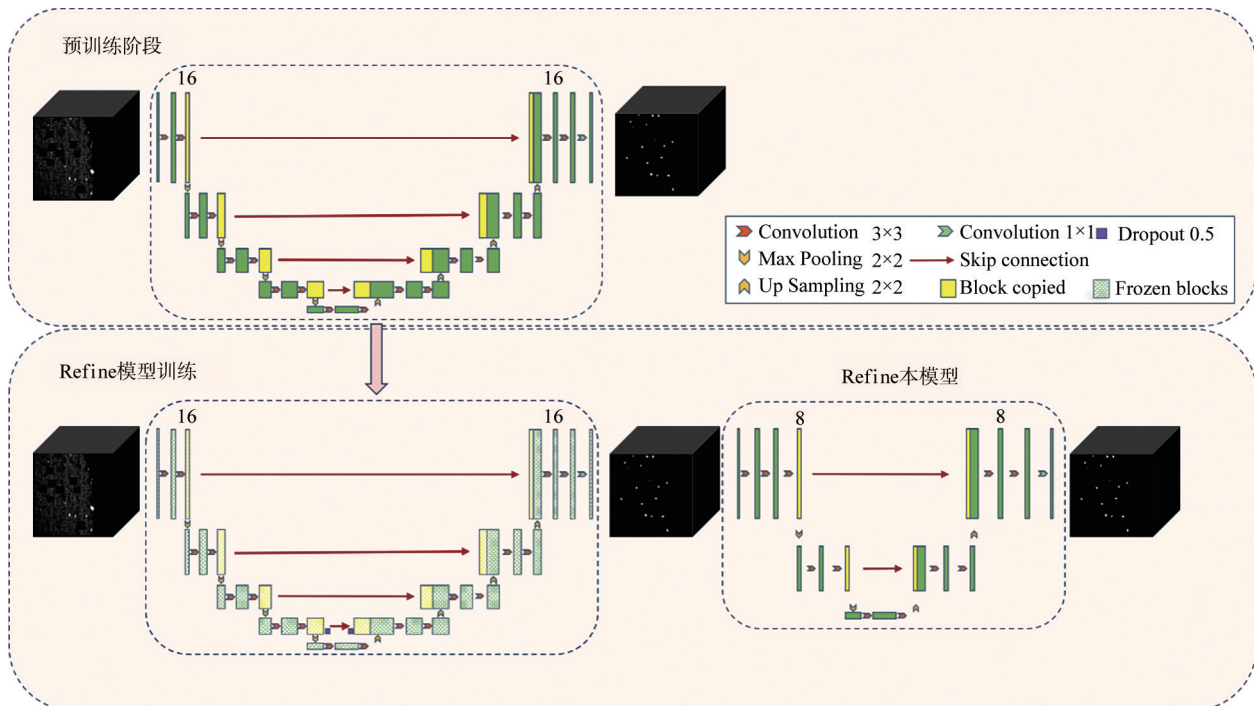


图2 Refine模型的分割流程

Figure 2 Segmentation process of the Refine model

第一步, 预训练分割模型; 第二步, 训练 Refine 模型, Refine 模型训练时会在预训练 U-Net 模型的瓶颈层前后加入 Dropout 层

### 2.1 掩码图像建模

掩码建模策略最初来源于人工智能算法的自然语言处理 (Natural Language Processing, NLP) 领域, 被称为掩码语言建模 (Masked Language Modeling, MLM), 最早在 2019 年由 Devlin 等<sup>[18]</sup>用于 BERT 模型, 是一种用于处理自然语言理解任务的预训练方法。其上游任务是预测输入语句中被随机掩盖的单词, 通过这种上游任务的设置赋予模型一定的文本纠错能力, 从而提升下游任务中对自然语言的理解能力。MLM 的简单高效使其在 NLP 领域成为了一种新的训练范式。Bao 等<sup>[19]</sup>提出 BEiT, 首次将掩码建模的思想引入了计算机视觉领域, 使得更多研究者注意到了掩码建模在视觉领域的价值。He 等<sup>[12]</sup>提出 MAE, 使用更加简单高效的方式进行了掩码图像建模预训练, 在图像被遮盖 70% 以上的区域时, 仍然

能够重建出原始图像, 并在各种下游视觉任务中取得了优异表现, 进一步证明了 MIM 这种训练范式的潜力。

由于血管影像的特殊性, 笔者在掩码图像建模的基础上提出掩码血管建模, 所遮挡的图块中心均位于血管中心线上, 通过对遮挡包含血管图块的重建, 训练网络将断掉的血管连接起来。遮挡图块前, 首先基于原始图像的标注计算血管的中心线, 遮挡图块的大小在一定范围内随机选择, 例如选择遮挡图块大小为  $(5 \times 5 \times 5)$  到  $(10 \times 10 \times 10)$  范围内, 为了保证遮挡图块之间相互不会重叠, 为遮挡图块的边界之间选择了一定的间隙, 默认为大于 2 个体素。实际计算中会先根据遮挡图块大小和间隙挑选出位于血管中心线上的所有候选的图块, 然后随机遮挡一定比例的图块。

以遮挡图块的比例、遮挡图块的大小范围作为超参,利用网格搜索方法在训练集与验证集数据选择最优超参,网格搜索的范围为遮挡比例25%、50%、75%,遮挡范围的取值有 $5 \times 5 \times 5 \sim 10 \times 10 \times 10$ 、 $10 \times 10 \times 10 \sim 15 \times 15 \times 15$ 、 $15 \times 15 \times 15 \sim 20 \times 20 \times 20$ ,组合起来共有9种

参数组合,从其中选择验证集结果最好的参数组合作为最优超参,效果最好的参数设置为遮挡比例为25%,遮挡大小的范围为 $10 \times 10 \times 10 \sim 15 \times 15 \times 15$ ,遮挡效果如图3所示。




图3 血管遮挡效果展示

Figure 3 Illustration of vessel occlusion

## 2.2 Refine 模块的设计

在采用MVM训练策略后获得的分割结果中仍然存在部分离散的噪点,额外预训练了一个小型的Refine模型,对分割网络的结果进行精化,进一步提升分割结果的精度和连续性。直接将分割模型的二值化输出作为预训练Refine模型的输入,为了增加Refine网络数据的多样性,通过对分割模型额外加入一个Dropout层,随机地将一部分特征图的权重置零,对分割结果进行一定的扰动,从而输出多样性的预分割结果。Refine模型训练的过程中,使用的数据和数据拆分和MVM预训练时相同,其余训练参数除训练批次设为8外,均与MVM预训练时保持一致。

## 2.3 对比实验与消融实验

为了客观评价本文所提出方法的性能,在相同的数据集上训练并测试一系列代表性的State-of-the-art(SOTA)模型。这些模型包括3D U-Net、VNet、Uception、UNETR、UNet++以及Graph Cut Loss(在UNet基础上实现)。所有模型使用的数据和数据集拆分均相同,训练参数也保持一致,除Graph Cut Loss外,其他所有模型都使用了原始文章所采用的损失函数。学习率设置、优化器设置均与MVM预训练和Refine模型训练时保持一致。批次大小设置均为2。

为了验证MVM方法和Refine模型的有效性,设计了一系列消融实验。首先,以3D U-Net模型为基准,比较了加入MVM预训练和不加入预训练的3D U-Net模型的分割性能。之后,在MVM训练的基础上加上了Refine模型,来展示Refine模型的效果。

## 2.4 模型评价

使用Dice评价模型的分割结果,受试者工作特征(Receiver Operating Characteristic, ROC)曲线下面积(Area Under Curve, AUC)也作为分割效果的辅助评价指标使用。为了评价血管分割结果的连续性,使用了cIDice和Betti Error。

cIDice是由Shit等<sup>[9]</sup>在2020年提出的一种评价血管连续性的指标。最近,一个由大型的国际专家联盟提出的、旨在帮助生物学图像分析研究这选择适当的性能评价指标的框架Metrics Reloaded<sup>[20]</sup>中,也推荐cIDice作为血管分割算法的评价指标之一。其计算方法如下:

$$T_{\text{prec}}(S_p, V_L) = \frac{|S_p \cap V_L|}{|S_p|}, T_{\text{sens}}(S_L, V_p) = \frac{|S_L \cap V_p|}{|S_L|} \quad (2)$$

其中, $V_L$ 是输入图像的标签, $V_p$ 是分割结果, $S_L$ 是标签的骨架, $S_p$ 是分割结果的骨架,cIDice定义为

Tprec( $S_p, V_L$ )和Tsens( $S_L, V_p$ )的调和平均数:

$$cIDice(V_p, V_L) = 2 \times \frac{Tprec(S_p, V_L) \times Tsens(S_L, V_p)}{Tprec(S_p, V_L) + Tsens(S_L, V_p)} \quad (3)$$

Hu等<sup>[8]</sup>于2017年的一篇工作中首先将贝蒂误差(Betti Errors)作为衡量管状结构物体分割结果拓扑连续性的评价指标。贝蒂误差为贝蒂数(Betti Numbers)的绝对误差。在代数拓扑学中,贝蒂数 $\beta_0, \beta_1, \beta_2$ 是拓扑空间中的一组不变量,直观来说, $\beta_0$ 代表了拓扑空间中连通分量的个数, $\beta_1$ 代表了二维平面内“孔洞”的个数, $\beta_2$ 代表了三维空间内“空腔”的个数,更高维的贝蒂数不在本实验的讨论范围之内。在实际计算贝蒂误差时,笔者使用将原始大小为 $448 \times 448 \times 128$ 的图像裁剪成大小为 $112 \times 112 \times 64$ 的图像块,对每一块图像计算其标签和分割结果的贝蒂误差,最后取所有图像块的平均贝蒂误差作为最后结果来评价分割结果的连通性。

使用Dice系数、cIDice、AUC和Betti Error等评价指标对所有模型的性能进行评价,以全面反映分割的精度、连贯性和可靠性。

### 2.5 实验硬件与软件环境

本实验的硬件配置为:操作系统Ubuntu 18.04,显卡为GeForce RTX 2080 Ti。使用PyTorch 1.7.1作为深度学习框架,Python版本为3.8.13。预训练过程选择的优化器为Adam,设初始化学学习率0.001, $\beta_1=0.9, \beta_2=0.999$ ,权重衰减设为0.0005,训练1000代,批次大小为2。训练过程使用了早停策略,当训练集的Dice值超过200代没有提升时停止训练。在训练Refine模型时,在预训练模型的瓶颈层(bottle neck)层前后加入丢弃概率为0.5的Dropout层,以此产生

差异较大的预训练输入,增加Refine模型的训练样本,增强Refine模型的泛化性能。

## 3 实验结果

### 3.1 结果统计

为了展示遮挡训练的效果和已有的一些经典的血管分割模型进行对比。3D U-Net<sup>[17]</sup>将二维U-Net扩展到三维结构,通过编码器-解码器和跳跃连接有效捕获空间上下文信息,被广泛应用于医学图像分割。VNet<sup>[21]</sup>则采用全三维卷积结构,并结合残差学习与Dice损失,在处理类别不平衡问题时表现良好。Uception<sup>[22]</sup>在U-Net框架中引入多尺度特征提取机制,以提升对复杂血管结构的分割能力。UNETR<sup>[23]</sup>将Transformer引入医学图像分割,利用其捕捉长距离依赖的优势,并结合U-Net结构实现逐层特征融合,在三维血管分割中展现出优异性能。除此之外,Graph Cut Loss<sup>[24]</sup>通过建模像素间的关系来优化分割损失,能够提升结果的边界一致性和血管连通性。

如表1所示,在加入遮挡训练后,在没有影响血管的整体分割精度的情况下,3D U-Net模型的 $\beta_0$  Error、 $\beta_1$  Error分别由 $1.3878 \pm 0.2534$ 和 $0.3673 \pm 0.0872$ 下降到了 $1.2742 \pm 0.2103$ 和 $0.3393 \pm 0.0818$ ,这证明了血管分割在二维和三维空间上产生的空洞数变少,血管的连续性有一定的提升。在遮挡预训练的基础上增加Refine模型后,血管的平均分割Dice由原来的 $0.7069 \pm 0.0148$ 提升到了 $0.7105 \pm 0.0125$ 。cIDice也略有提升,由 $0.8113 \pm 0.0151$ 提升到了 $0.8158 \pm 0.0125$ 。但 $\beta_0$  Error、 $\beta_1$  Error有所增加,猜测是Refine模型的输出结果有一些离散的点或者血管连接紧密的地方,影响了计算的结果。

表1 不同血管分割模型的性能

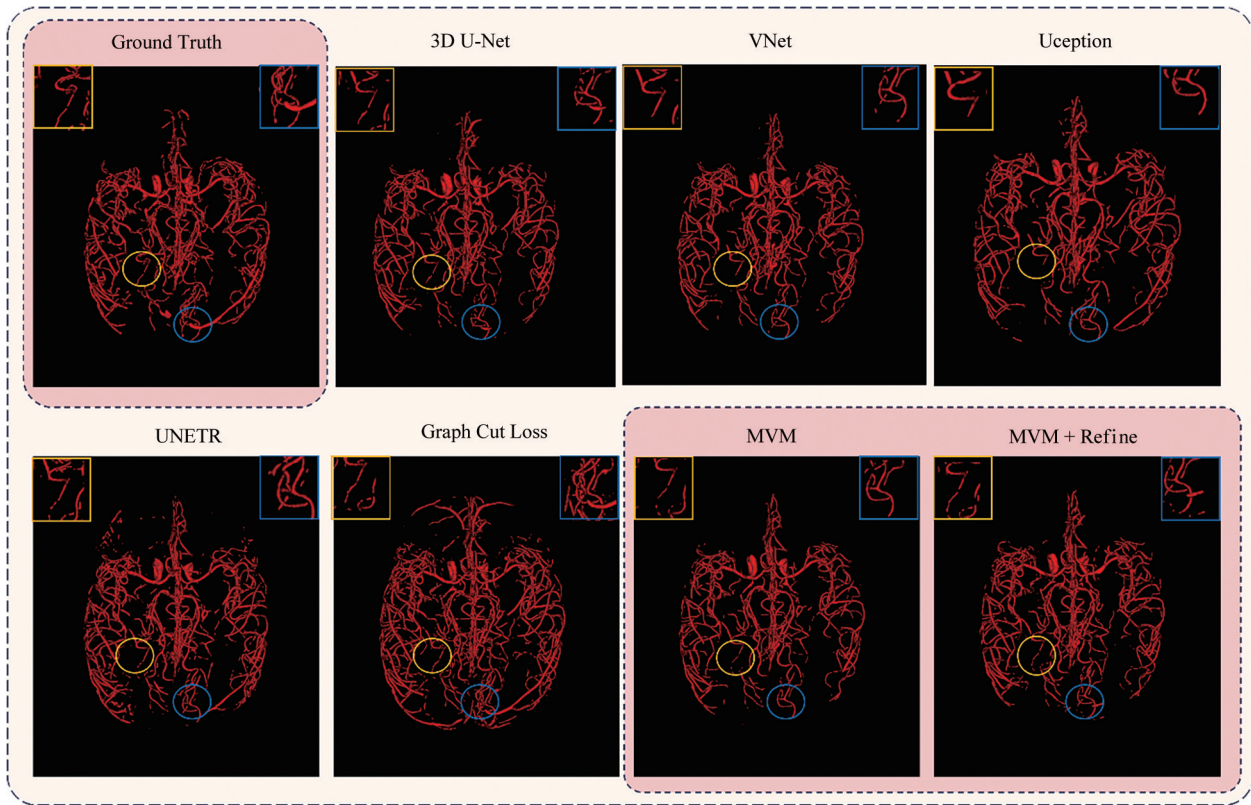
Table 1 Performance of different vessel segmentation models

Models	Dice	cIDice	$\beta_0$ Error	$\beta_1$ Error
3D U-Net	0.7077±0.0150	0.8137±0.0144	1.3878±0.2534	0.3673±0.0872
VNet	0.7097±0.0127	0.8106±0.0131	1.2003±0.2106	0.3469±0.0722
Uception	0.6944±0.0157	0.7951±0.0188	1.5026±0.3695	0.3737±0.0914
UNETR	0.6724±0.0145	0.7706±0.0167	5.9337±0.8837	0.4056±0.0673
Graph Cut Loss	0.6919±0.0154	0.7763±0.0118	4.5255±0.5141	0.5829±0.2182
MVM	0.7069±0.0148	0.8113±0.0151	1.2742±0.2103	0.3393±0.0818
MVM + Refine	0.7105±0.0125	0.8158±0.0125	1.6301±0.3797	0.3712±0.0920

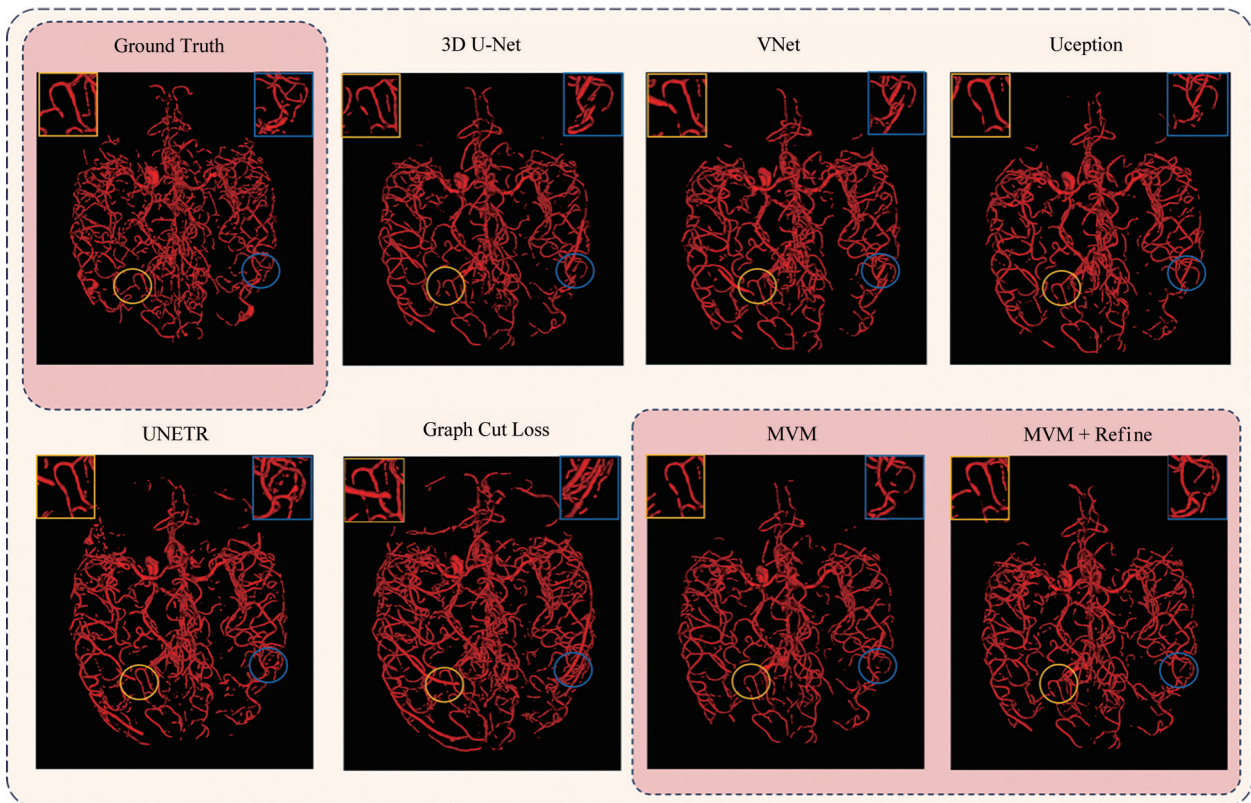
### 3.2 分割结果展示

如图4所示,UNet和VNet基本上可以分割出整

体的血管形状,但是一些细小的血管无法连续,尤其是比较长的细小血管,无法捕捉其图像特征。



典型案例 1



典型案例 2

图 4 分割结果图示

Figure 4 Visualization of segmentation results

Uception 和 UNETR 都是基于 Transformer 的 UNet 架构网络, 得益于 Transformer 架构的全局注意力机制,

对细长血管的分割能力有一定提升, 其他的对比模型包括本文模型对长血管的效果略有不足(典型案例

例1),但是误分割的噪点比较多,反而影响了最终的整体效果。Graph Cut loss是一种拓扑损失函数,在它的作用下模型对于细小血管的分割能力有所提升,但可以看出他并没有捕捉到血管形态,将头壳的一部分边缘也作为血管分割了出来。遮挡训练的结果在U-Net的基础上对于细小血管的连续性有一定的提升,一部分原本断裂的细小血管被连接上了,但是也有一部分断裂比较多的血管未被模型识别为血管结构而被舍弃。因此,笔者加入了Refine模型,在Refine模型的分割结果中,可以看到部分前级网络未能分割出来的血管被Refine模型分割出来了(典型案例2),说明Refine网络进一步提升了血管的分割精度和连续性。

## 4 讨论

本文使用的遮挡血管训练策略借鉴了掩码图像建模(MIM)策略,通过随机遮挡图像中的部分血管来训练模型预测遮挡区域的二值分割结果。不同于MIM,本文MVM方法仅对血管区域进行遮挡,以此引导模型重点学习如何连接断开的血管,通过遮挡部分血管,强制模型不再仅仅依赖局部特征,而是学习并理解整个血管的结构,从而提升血管拓扑结构的连续性。遮挡训练还类似于Cutout<sup>[25]</sup>数据增强方法,通过随机遮挡输入图像中的部分内容来提升模型的表现。这样不仅继承了传统数据增强的优势,还赋予模型对部分遮挡图像的更好适应能力,特别是在数据有限的情况下。该策略增强了模型对整体图像特征的学习,使模型捕捉到更细微且关键的图像信息,提升了分割的稳定性。作为一种数据扩增方式,该方法增加了训练样本量和多样性,从而提升了模型的泛化能力,在训练样本有限的情况下作用尤为显著。

以往的工作都是通过特殊的损失函数或者网络设计,使得模型能够在血管分割任务中学习到更为丰富的血管结构特征,提升了血管分割的连续性。本文方法没有特殊的损失函数和网络设计,通过MVM预训练,模型能够在血管分割任务中学习到更为丰富的血管结构特征,提升了血管分割的连续性。之后再使用Refine模型对分割结果进行二次优化,通过进一步学习血管的局部细节,提升模型在边缘区域的分割精度。实验结果显示,Refine模型在保持整体血管连贯性的同时,能够有效提升分割的精细度。相比基础的3D U-Net模型,加入MVM预训练和Refine模块后,模型在各项评估指标上均有一定提升,验证了本文方法在血管分割任务中的有效性和潜力。此外,Refine模型的重点学习血管之间的连通

性信息,其输入输出均为二值化图像,二值化图像之间的映射大幅度降低了模型的复杂性,同时加快了推理过程。实验结果表明,Refine模型有助于保留关键细节和纹理特征,改善了图像边缘的清晰度,进一步提升了结果的可靠性与实用性。

## 5 总结

本文探讨MRA图像中的三维血管分割技术,聚焦提升分割结果的连续性。针对普通的分割网络对于三维血管进行分割的结果连续性较差的问题,采取了两种措施:(1)为使分割网络更好地捕捉到血管连续性的特点,采用遮挡部分血管的方法进行模型训练,可以有效地提升血管分割精度,特别是提升了分割血管的连通性;遮挡训练的优势在于,无需额外的模型设计或使用特殊的损失函数,使用遮挡策略对图像进行数据增强的同时,迫使网络连接断掉的血管,提升分割结果的连通性。此外,对图像遮挡也起到了一定的正则化效果,减少了模型的过拟合。(2)提出了使用Refine网络,对普通分割模型的输出进行进一步改进,增强血管分割的连续性。Refine网络针对二值化分割结果进一步优化,优势在于其任务相当于二值图像之间的映射,需要的训练资源比较少。此外,通过在分割模型中插入Dropout层来获得具有随机扰动的二值分割结果作为Refine模型的输入,理论上来说可以有足够的训练数据来训练Refine模型。本研究也有一些限制:一方面,Refine模型需预训练,未与分割模型同步训练。未来可探索专门的Refine架构与分割模型联合训练。另外,本研究仅在单一公开数据集上进行测试,未来需要在真实的临床数据上验证其有效性。

## 【参考文献】

- [1] Benjamin EJ, Blaha MJ, Chiuve SE, et al. Heart disease and stroke statistics-2017 update: a report from the American Heart Association [J]. *Circulation*, 2017, 135(10): e146-e603.
- [2] Wilder B, Pinedo A, Abusin S, et al. A global perspective on socioeconomic determinants of cardiovascular health [J]. *Can J Cardiol*, 2025, 41(1): 45-59.
- [3] Chen C, Zhou KN, Wang ZL, et al. All answers are in the images: a review of deep learning for cerebrovascular segmentation [J]. *Comput Med Imaging Graph*, 2023, 107: 102229.
- [4] Araújo RJ, Cardoso JS, Oliveira HP. A deep learning design for improving topology coherence in blood vessel segmentation [C]// *Medical Image Computing and Computer Assisted Intervention - MICCAI 2019*. Cham: Springer International Publishing, 2019: 93-101.
- [5] Banerjee S, Toumpanakis D, Dhara AK, et al. Topology-aware learning for volumetric cerebrovascular segmentation [C]// *2022 IEEE 19th International Symposium on Biomedical Imaging (ISBI)*. Piscataway, NJ, USA: IEEE, 2022: 1-4.
- [6] Yao LL, Shi F, Wang S, et al. TaG-Net: topology-aware graph network for centerline-based vessel labeling [J]. *IEEE Trans Med Imaging*, 2023, 42(11): 3155-3166.

- [7] Zhang X, Sun KC, Wu DJ, et al. An anatomy- and topology-preserving framework for coronary artery segmentation[J]. *IEEE Trans Med Imaging*, 2024, 43(2): 723-733.
- [8] Hu XL, Li FX, Samaras D, et al. Topology-preserving deep image segmentation[C]//*Proceedings of the 33rd International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2019: 5657-5668.
- [9] Shit S, Paetzold JC, Sekuboyina A, et al. cDice - a novel topology-preserving loss function for tubular structure segmentation[C]//2021 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2021: 16555-16564.
- [10] Yang ZY, Farsiu S. Directional connectivity-based segmentation of medical images[C]//2023 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2023: 11525-11535.
- [11] Xia LK, Zhang H, Wu YF, et al. 3D vessel-like structure segmentation in medical images by an edge-reinforced network[J]. *Med Image Anal*, 2022, 82: 102581.
- [12] He KM, Chen XL, Xie SN, et al. Masked autoencoders are scalable vision learners[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 15979-15988.
- [13] Hondru V, Croitoru FA, Minaee S, et al. Masked image modeling: a survey[J]. *Int J Comput Vis*. (2025-07-14). <https://doi.org/10.1007/s11263-025-02524-1>.
- [14] Bullitt E, Zeng DL, Gerig G, et al. Vessel tortuosity and brain tumor malignancy: a blinded study[J]. *Acad Radiol*, 2005, 12(10): 1232-1240.
- [15] Aylward SR, Bullitt E. Initialization, noise, singularities, and scale in height ridge traversal for tubular object centerline extraction[J]. *IEEE Trans Med Imaging*, 2002, 21(2): 61-75.
- [16] Isensee F, Schell M, Pflueger I, et al. Automated brain extraction of multisequence MRI using artificial neural networks[J]. *Hum Brain Mapp*, 2019, 40(17): 4952-4964.
- [17] Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]//*Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016*. Cham: Springer International Publishing, 2016: 424-432.
- [18] Devlin J, Chang MW, Lee K, et al. BERT: pre-training of deep bidirectional transformers for language understanding [C]//*Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*. Stroudsburg, PA, USA: ACL, 2019: 4171-4186.
- [19] Bao HB, Dong L, Piao SH, et al. BEiT: BERT pre-training of image transformers [EB/OL]. (2022-09-03). <https://arxiv.org/abs/2106.08254v2>.
- [20] Maier-Hein L, Reinke A, Godau P, et al. Metrics reloaded: recommendations for image analysis validation[J]. *Nat Methods*, 2024, 21(2): 195-212.
- [21] 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). Piscataway, NJ, USA: IEEE, 2016: 565-571.
- [22] Sanches P, Meyer C, Vigon V, et al. Cerebrovascular network segmentation of MRA images with deep learning[C]//2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019). Piscataway, NJ, USA: IEEE, 2019: 768-771.
- [23] Hatamizadeh A, Tang YC, Nath V, et al. UNETR: transformers for 3D medical image segmentation[C]//2022 IEEE/CVF Winter Conference on Applications of Computer Vision (WACV). Piscataway, NJ, USA: IEEE, 2022: 1748-1758.
- [24] Zheng Z, Oda M, Mori K. Graph Cuts loss to boost model accuracy and generalizability for medical image segmentation[C]//2021 IEEE/CVF International Conference on Computer Vision Workshops (ICCVW). Piscataway, NJ, USA: IEEE, 2021: 3297-3306.
- [25] DeVries T, Taylor GW. Improved regularization of convolutional neural networks with cutout[EB/OL]. (2017-11-29). <https://arxiv.org/abs/1708.04552>.

(编辑:薛泽玲)