



· 专题论著 ·



刘屹，教授，硕士研究生导师，辽宁省肿瘤医院医学影像科副主任。中华医学会放射学分会第十五、十六届腹部学组委员，中华医学会放射学分会第十五届影像大数据和人工智能委员会委员，中华医学会放射学分会第十三、十四、十五届分子影像学组委员，中国医师协会放射医师分会第五届互联网与大数据影像专业组委员，中国医师协会放射医师分会第四届急诊影像专业委员会委员，中国医师协会结直肠肿瘤专业委员会第一届诊疗技术专委会委员，中国抗癌协会第五届胃癌专业委员会影像诊断学组副组长，辽宁省医学会第三届分子影像学分会副主任委员，辽宁省医学影像学学会第八届理事会副理事长，辽宁省医学会第十三届放射学分会委员，辽宁省抗癌协会第二届肿瘤影像专业委员会委员。

基于MRI的柔性分割网络：面向脑胶质瘤精准分割与三维重建

王泽坤¹，于永成²，王利华¹，罗娅红¹，刘屹¹

1. 辽宁省肿瘤医院暨大连理工大学附属肿瘤医院，中国医科大学肿瘤医院医学影像科，辽宁 沈阳 110042；
2. 辽宁师范大学计算机科学与人工智能学院，辽宁 大连 116000

[摘要] 目的：应用多模态磁共振成像（magnetic resonance imaging, MRI）通过包容-排斥融合原理构建多模态包容-排斥融合网络（multimodal inclusion-exclusion fusion-net, MIEF-Net）提升脑肿瘤分割的准确度与鲁棒性。方法：收集2021年1月—2023年12月辽宁省肿瘤医院（大连理工大学附属肿瘤医院）的脑胶质瘤患者的MRI图像及BraTS2020（Brain Tumor Segmentation Challenge 2020）公开数据集患者的MRI图像，并对全肿瘤（whole tumor, WT）、增强肿瘤（enhance tumor, ET）和肿瘤核心（tumor core, TC）的图像进行分割。每个数据集中随机使用80%的数据进行训练，剩余20%用于测试。采用在ImageNet-1k上预训练的密集预测任务设计的分层视觉构架（pyramid vision transformer v2, PVTv2）模型作为所提出的MIEF-Net的骨干网络。评估所提出的MIEF-Net模型在脑肿瘤分割中的性能，采用了Dice系数、HD95、灵敏度、准确度、精确率、召回率和交并比（intersection over union, IOU）等指标；对于评估拟议的MIEF-Net在脑肿瘤分割中的有效性，进行了广泛的视觉对比实验。结果：本文选取院内150例脑胶质瘤患者及BraTS2020公开数据集427个模态MRI图像，构建了一种MIEF-Net，改进了RSF算法，提出了MIEF-Net模型。MIEF-Net在BraTS2020数据集上Dice为0.933，灵敏度为0.943，HD95为0.935，IoU为0.895，这些数据明显优于比较方法。同时MIEF-Net在视觉对比实验中提供了更精确且清晰的肿瘤边界。并提出了一种跨模式协同积分器（cross-modal collaborative integrator, CCI）方法来增强多模态特征的兼容性，并利用丰富的信息关联。对于临床数据集和BraTS2020数据集对比实验，其中临床数据集中，弥散加权成像（diffusion-weighted imaging, DWI）影像与其他模态配合时表现更优；而在BraTS2020数据集中，两种模态可能具有足够的融合效果。MIEF-Net采用级联多模态特征映射框架，能够更准确地识别和切分不同类型的脑组织和病灶区域，三维重建图

基金项目：无。

利益冲突：作者声明无利益冲突。

伦理批件：20210408X。

知情同意：豁免。

引用本文：王泽坤，于永成，王利华，等. 基于MRI的柔性分割网络：面向脑胶质瘤精准分割与三维重建 [J]. 肿瘤影像学, 2025, 34(6): 574-586.

Funding: no.

Conflicts of interest: authors declare no conflicts of interest.

Ethical approval: 20210408X.

Informed consent: exemption.

Cite this article: WANG Z K, YU Y C, WANG L H, et al. A flexible segmentation network for MRI: toward accurate tumor delineation and 3D reconstruction in brain glioma [J]. Oncoradiology, 2025, 34(6): 574-586.

像视图也更加清晰精准。融合实验提出的包容-排斥原则在引入多尺度区域可伸缩拟合 (multi-scale region-scalable fitting, MRSF)、模态融合增强器 (modal fusion enhancer, MFE) 和CCI时, 能够取得高效挖掘丰富的模式。这使MIEF-Net在脑肿瘤分割任务中展现出更高的准确度和稳健性, 能够更准确地识别和切分不同类型的脑组织和病灶区域。**结论:** 本研究提出的MIEF-Net在解决分割技术中全局-局部特征平衡不足问题方面, 显著优于传统单一模态方法。视觉对比实验进一步表明, 基于MIEF-Net所构建的三维重建图像能够提供更精确且清晰的肿瘤边界划分。

[关键词] 脑肿瘤; 磁共振成像; 多模态; 脑肿瘤分割; 医学影像分析

中图分类号: R739.41; R445.2 文献标志码: A

DOI: 10.19732/j.cnki.2096-6210.2025.06.003

A flexible segmentation network for MRI: toward accurate tumor delineation and 3D reconstruction in brain glioma WANG Zekun¹, YU Yongcheng², WANG Lihua¹, LUO Yahong¹, LIU Yi¹ (1. Department of Radiology, Cancer Hospital of Dalian University of Technology, Liaoning Cancer Hospital & Institute, Shenyang 110042, Liaoning Province, China; 2. Department of Computing Science and Artificial Intelligence, Liaoning Normal University, Dalian 116000, Liaoning Province, China)

Correspondence to: LIU Yi E-mail: liuyicmu@sina.cn

[Abstract] **Objective:** To improve the accuracy and robustness of brain-tumor segmentation by leveraging multimodal magnetic resonance imaging (MRI) and an inclusion-exclusion fusion principle within a novel multimodal inclusion-exclusion fusion network (MIEF-Net). **Methods:** MRI images of brain glioma patients from Liaoning Provincial Cancer Hospital (Dalian University of Technology Affiliated Cancer Hospital) between January 2021 and December 2023, along with MRI images from the BraTS2020 (Brain Tumor Segmentation Challenge 2020) public dataset were collected for whole-tumor (WT), enhancing-tumor (ET) and tumor-core (TC) segmentation. Each cohort was randomly split 80% and 20 % for training and testing. All models—including the proposed MIEF-Net and competing methods—were implemented in PyTorch and MindSpore using publicly released code. Pyramid vision transformer v2 (PVTv2) pretrained on ImageNet-1k served as the backbone. Dice, HD95, sensitivity, accuracy, precision, recall and intersection over union (IoU) were employed for evaluation; extensive comparative experiments were conducted. **Results:** This study selected 150 in-hospital patients with brain gliomas and 427 multi-modal MRI images from the BraTS2020 public dataset to construct a MIEF-Net model. It improved the RSF algorithm and proposed the MIEF-Net model. On the BraTS2020 dataset, MIEF-Net achieved a Dice score of 0.933, sensitivity of 0.943, HD95 of 0.935, and IoU of 0.895. These metrics significantly outperformed the comparison methods. Visual assessment revealed sharper and more accurate tumor boundaries. The inclusion-exclusion strategy effectively integrated multimodal data, exploring both shared and modality-specific features. A cross-modal collaborative integrator (CCI) further enhanced feature compatibility and informative correlation. On the clinical dataset, DWI combined with other modalities yielded the best performance, whereas on BraTS2020 provided sufficient inclusion-exclusion capacity. Cascaded multimodal feature mapping enabled comprehensive information exploitation, leading to higher accuracy and robustness in delineating diverse brain tissues and lesions, and to clearer 3D reconstructions. Ablation studies confirmed that multi-scale region-scalable fitting (MRSF), modal fusion enhancer (MFE) and CCI together efficiently mine rich patterns under the inclusion-exclusion principle. **Conclusion:** The proposed MIEF-Net markedly outperforms traditional single-modality approaches in alleviating the global-local feature imbalance inherent to segmentation. Visual comparison experiments further demonstrate that the 3D reconstructions generated by MIEF-Net deliver more accurate and distinctly delineated tumor boundaries.

[Key words] Brain tumor; Magnetic resonance imaging; Multimodal; Brain tumor segmentation; Medical image analysis

脑肿瘤是威胁人类健康的重大疾病。全球诊断为脑肿瘤的患者数量每年都在增加^[1-2], 尤其是胶质瘤, 严重影响患者的生存期。其中, 即使世界卫生组织 (World Health Organization, WHO) I、II级的胶质瘤生长缓慢, 但它们仍然具有向恶性转化的潜力; 而WHO III、IV级胶质瘤, 尤其是胶质母细胞瘤, 具有高度侵袭性, 生长迅速, 患者预后差, 中位生存期短, 对患者生命构成极大的威胁^[3-4]。而颅脑作为人体最精

密的器官, 由于其高度复杂的解剖结构和功能性分区, 对于肿瘤诊断和治疗的准确度有极高的要求^[1]。

MRI作为脑胶质瘤检出、诊断及疗效评估最重要的影像学检查方法, 它提供了多模态的高分辨率的图像信息, 来阐述脑肿瘤的病理学特征, 以提高医疗决策的准确度。既往MRI图像主要通过影像科医师的视觉判读来逐层、逐区域手动或半自动标记目标区域分割来获取图像分割信息,

这种方式耗时且具有主观性^[5]。应用机器学习技术, 如支持向量机 (support vector machine, SVM)^[6]、随机森林 (random forest)^[7]和地 k-means 聚类^[8-9]分割医学图像, 此类技术有效地提高了分割数据量, 但在处理复杂的影像信息时准确度表现欠佳。

近些年, 多模态医学影像数据量激增, 特别是当患者脑肿瘤内异质性强时, 依赖人工及机器半自动图像分割的传统方法极易出错^[10]。面对此类挑战, 人工智能 (artificial intelligence, AI) 及深度学习 (deep learning, DL) 优势凸显^[11], DL从海量数据中不断学习, 在分析医学影像信息方面比依靠机器学习的方法更行之有效^[12-13]。

现有的脑肿瘤分割方法在处理胶质瘤, 尤其是胶质母细胞瘤这类呈浸润生长的肿瘤, 存在对于肿瘤复杂形态及模糊不清的肿瘤边界判定上的局限性。基于卷积神经网络 (convolutional neural network, CNN) 的U-Net擅长提取局部特征, 但不能有效地整合不同长度的信息, 导致对肿瘤边界和内部结构的捕捉能力不足^[14]。Transformer 虽能全局建模, 却存在计算成本高、对高分辨率图像处理效率低的问题。现有U-Net及Transformer架构虽通过改进融合提升性能, 但仍存在一些问题, 一是全局-局部特征平衡不足, 导致肿瘤分割精度欠佳; 二是长距离依赖建模局限于单一方向, 忽略多方向特征关联; 三是这种融合多依赖简单连接, 缺乏有效的交互^[15]。

本研究针对的单一模态图像之间存在肿瘤边界显示不一致所导致的排斥关系, 以及多模态中存在全局-局部平衡融合欠佳的情况。提出了通过包容-排斥融合原理来提升脑肿瘤分割的准确度与鲁棒性。

1 资料和方法

1.1 临床资料

回顾并收集2021年1月—2023年12月辽宁省肿瘤医院患者的资料, 包括T1加权成像 (T1-weighted imaging, T1WI)、T1加权成像增强

(T1-weighted imaging+contrast enhancement, T1WI+CE)、T2加权成像 (T2-weighted imaging, T2WI) 和弥散加权成像 (diffusion-weighted imaging, DWI) 扫描序列。纳入标准:

① 根据2021年WHO中枢神经系统肿瘤分类, 组织病理学诊断为脑胶质瘤的患者; ② 术前MRI检查包括T1WI、T2WI、T1WI+CE、磁共振水抑制成像 (fluid attenuated inversion recovery, FLAIR), DWI。排除标准: ① 缺少T1WI+CE扫描序列; ② 存在MRI伪影; ③ 无病理学检查证实。本研究经辽宁省肿瘤医院伦理委员会审查 (编号为20210408X), 豁免知情同意。

1.2 外部数据集

另一部分研究资料来源于BraTS2020公开数据集, 包括T1WI、T1WI+CE、T2WI和FLAIR共4种模态图像。每个模态的图像尺寸为240 mm × 240 mm × 155 mm, 并且还提供了包含全肿瘤 (whole tumor, WT)、增强肿瘤 (enhance tumor, ET) 和肿瘤核心 (tumor core, TC) 的T1WI分割。该数据集旨在有效地识别脑肿瘤的3个子区域。在实验中, 数据集中的图像在体素的轴向平面被切片为二维图像, 并对输入图像进行归一化和边缘裁剪。每个二维切片被裁剪为224 mm × 224 mm的图像, 以去除一些不必要的信息。在两个数据集中, 每例患者每种模态都有120~150张图像切片, 提供了足够广泛的数据集以支持实验的完整性和可靠性。本文使用两个数据集来评估所提出的多模态包容-排斥融合网络 (multimodal inclusion-exclusion fusion-net, MIEF-Net)。此外, 每个数据集中随机使用80%的数据进行训练, 剩余20%用于测试。

1.3 研究方法

本研究采用在ImageNet-1k上预训练的密集预测任务设计的分层视觉构架 (pyramid vision transformer v2, PVTv2) 模型作为所提出的MIEF-Net的骨干网络。该模型使用NVIDIA RTX 3060 GPU进行训练, 初始学习率设为0.01, 并采用随机梯度下降 (stochastic gradient descent, SGD) 优化器。在整个训练过程中应用多项式学

习率衰减策略。批量大小设置为12，模型训练超过100个周期。对于分割方法，使用BraTS2020数据集中的T1WI、T1WI+CE、T2WI和FLAIR共4种模态，以及临床数据集中的T1WI、T2WI、FLAIR和DWI。代码实现使用PyTorch和MindSpore完成，对于所有对比方法，这些模型均使用公开的源代码进行训练。

为了有效地评估所提出的MIEF-Net模型在脑肿瘤分割中的性能，采用了Dice系数、HD95、灵敏度、准确度、精确率、召回率和交并比（intersection over union, IoU）指标。本研究将包含-排除原则与多模态脑瘤分析相结合，旨在提取关于肿瘤特征更全面且具有区分性的信息。探究哪种模态在临床应用中表现更优。

1.4 对比实验选取

为全面评估拟议的MIEF-Net在脑肿瘤分割中的有效性，进行了广泛的对比实验，涵盖多种先进架构，包括U-Net、Attention U-Net、U-Net++、Gate CNN、DeepLabV3+和Cascade R-CNN^[1, 16]。

2 结果

本文收集213例临床诊断为的脑胶质瘤患者，最终所有符合纳入标准的脑胶质瘤患者150例；而在BraTS2020公开数据集，纳入427例多模态的MRI图像。实验设计流程见图1。

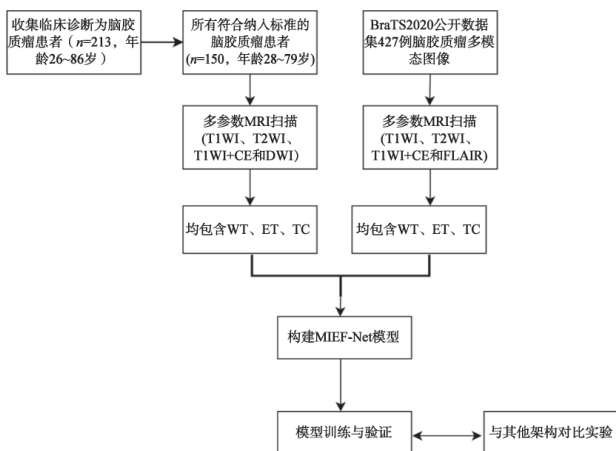


图1 研究设计流程图

Fig.1 Flow chart of research design

本文提出了一种MIEF-Net，主要包括2个基于Transformer的特定学习网络和1个跨模态信息混合网络，如图2所示。首先，对输入图像进行了更清晰的定位和分析。然后对MRI多模态图像进行基于变压器的2个特定网络处理，学习多层次特征表示。然后，通过模态融合增强器（modal fusion enhancer, MFE）融合这些表征，并通过共享学习网络进行分层处理。同时，所提出的网络使用将原始多层特征表示与相应的解码器相结合的跳跃式连接。此外，还提出了跨模态协同积分器（cross-modal collaborative integrator, CCI）模块，可以选择性地将特定编码器的特征集成到共享解码器中，从而提供更丰富的信息，提高特征表示能力。

2.1 特定学习网络

为了提高分割性能，本文采用Transformer作为网络骨干，利用不同模态和之间的相关性捕获更丰富的特征表示。脑胶质瘤的单一模态之间存在排斥关系，这将导致肿瘤边缘判别差异性显著，图像分割结果不理想。为了解决这一问题，本文提出的包容-排斥融合原理，如图2所示，本文首先将脑肿瘤的T1WI、T2WI、T1WI+CE和DWI图像输入到增强边缘模块（enhanced edge module, EEM）模块中。

在EEM模块中，本文改进了区域可缩放拟合（region-scalable fitting, RSF）算法，并将其与多模态包容-排斥原理相结合。首先，本文选择合适的核函数替换原算法的高斯函数：

$$K_q(\mu) = \frac{1}{1+\mu^q} q \in (0, 1], \mu \geq 0 \quad (1)$$

经过EEM模块后，图像进入编码器。如图2所示，基于Transformer的每个模态特定编码器的输入分辨率定义为 $W \times H$ 。首先，将输入图像分割成多个 $\frac{W}{P} \times \frac{H}{P}$ 非重叠补丁，其中 P 为补丁大小。编码表示是通过将不重叠的patch特征投影到 c 维空间中获得的。然后，将包含位置信息的嵌入补丁特征馈送到基于Transformer的编码器中^[17]。该编码器包括1个空间缩减注意（self-attention, SA）层，可以更好地捕捉贴

片特征之间的空间关系。随后, 输出被重塑为 $\frac{W}{P} \times \frac{H}{P} \times C$ 。基于Transformer的PVTv2模块, 本文以渐进收缩策略逐级压缩空间分辨率, 所提出的方法可以在不同阶段灵活调整补丁大小, 并利用重叠的补丁嵌入层生成多尺度特征。因此, 本文采用渐进式收缩策略获得了两组多尺度特征:

$$F^1 = \{f_i, i=1, 2, 3, 4\} \quad (2)$$

$$F^2 = \{f_i, i=1, 2, 3, 4\} \quad (3)$$

此外, 为了构建解码路径, 本文采用跳过连

接的方法将编码器特征与解码器特征结合起来。如图2所示, 本文使用了一个简单的级联块 (Cas. Block) 结合分层特征:

$$D_i = \text{Conv}_{3 \times 3} (\text{Concat} (T_{\text{conv}} (D_{i-1}), f_{4-i})) \quad (4)$$

其中 D_i 表示解码器第 i 层的输出, f_{4-i} 表示编码器中对应的特征映射。 $T_{\text{conv}}(\cdot)$ 表示产生上采样映射的转置卷积操作, 使用 $\text{Conv}_{3 \times 3}(\cdot)$ 表示执行两次 3×3 卷积, 随后进行批处理归一化和 ReLU 激活。

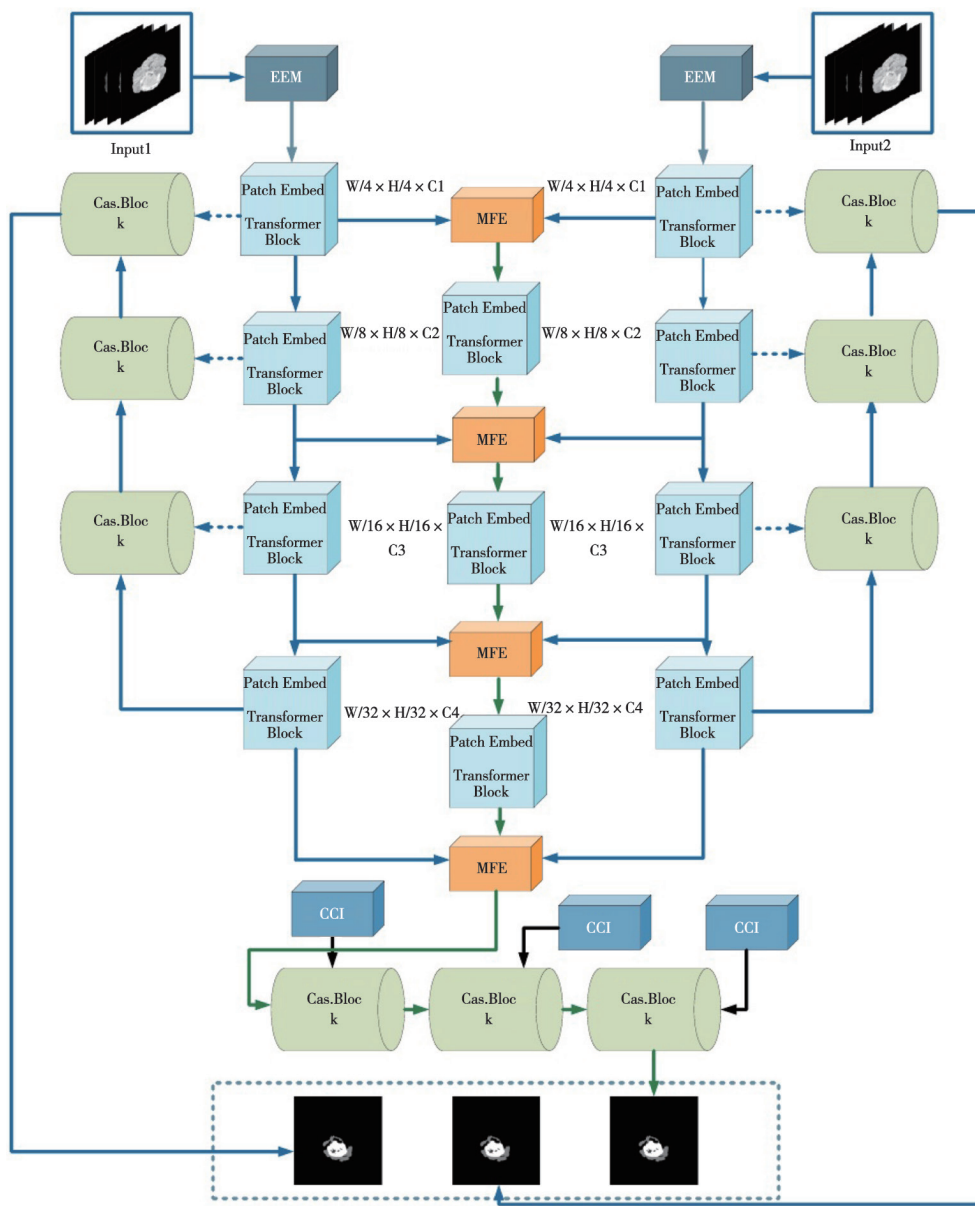


图2 MIEF-Net架构概述

Fig.2 Overview of the MIEF-Net Architecture

2.2 模态信息共享网络

在本文中，可以将来自特定的基于Transformer的学习网络的跨模态特征合并到共享学习流中，以提取共享表示，如图2所示。此外，编码器层的所有输出将使用跳过连接放入共享解码器中。

2.2.1 模态融合增强

基于2.1介绍的多模态包容-排斥原理，本文建立了用于多层特征融合的MFE，如图3。




图3 模态融合增强器 (MFE) 结构概述

Fig.3 Overview of the modal fusion enhancer (MFE) structure

首先，将两个模态特定编码器学习到的特征记为 f_i^1 和 f_i^2 ($i \in 1, 2, 3, 4$)，并采用 3×3 卷积层。然后将该卷积层的输出通过激活函数传递，以获得一组权重系数 w_i 。这些权重系数 w_i 用于控制不同模态特征对跨模态特征增强的贡献程度：

$$w_i = \alpha (A_{\text{conv}} (\text{Concat} (f_i^1, f_i^2))) \quad (5)$$

其中 α 表示激活函数， A_{conv} 代表是包含 3×3 卷积层、批处理归一化和ReLU激活的一系列操作。Concat表示连接操作。为了考虑互补性，本文引入了模态之间的不同特征：

$$D(i, j) = \text{abs} (F_i - F_j) \quad (6)$$

其中 F_i 和 F_j 为不同模态的低维特征表示。结合不同的特征、权重系数和低阶特征表示，得到基于多模态包容-排斥融合策略的增强特征表示：

$$f_i^{1''} = w_i \times F_i + w_{(i, j)} \times D(i, j) \quad (7)$$

其中 $f_i^{1''}$ 和 $f_i^{2''}$ 表示两种增强的特征表示， $w_{(i, j)}$ 表示不同特征对跨模态特征增强的贡献权重。通过在排除原理中加入不同的特征，可以捕获模态之间的局部差异和对比信息，进一步增强特征表

示的丰富性和鲁棒性。

此外，共享编码器以保留前一层的上下文信息可以通过MFE层来实现。具体来说，操作后的连接特征将与前一层MFE输出相结合。

$$f_i^{MFE} = A_{\text{conv}} (\text{Concat} (f_i^{1''}, f_i^M)) \quad (8)$$

其中， f_i^{MFE} 为MFE映射的输出特征， f_i^M 为MFE输出的第一层特征。所提出的MFE以分层方式将多模态信息无缝注入Transformer骨架，实现模态互补与语义增强的协同演化。

2.2.2 跨模式合作积分器

在跨模态共享学习网络的解码器中，编码器的特征通过跳过连接传递到共享解码器路径中。目的是从互补信息中捕获的多模态数据中自适应地提取共享解码器中的特征。然而，简单的聚合操作可能导致不同模态之间的特征不一致。为此，本文提出了一种跨模式协同积分器 (cross-modal collaborative integrator, CCI) 来增强多模态特征的兼容性，并利用丰富的上信息关联。

如图4所示，本文首先对 f_i^1 和 f_i^2 进行特征调制，使 f_i^M 集中在所需的特征部分。将集中的特征通过 f_i^M 连接到Sigmoid函数中，得到增强特征 E_i^1 和 E_i^2 ：

$$\begin{aligned} E_i^1 &= \varphi (f_i^1 \times f_i^M) \\ E_i^2 &= \varphi (f_i^2 \times f_i^M) \end{aligned} \quad (9)$$

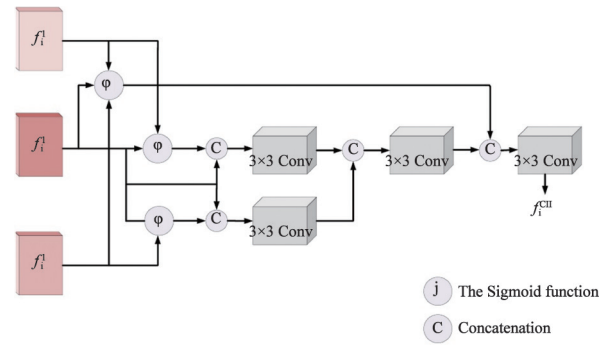


图4 跨模态协同积分器 (CCI) 概述结构

Fig.4 Overview of cross-modal synergistic integrator (CCI)

其中 φ 代表非线性Sigmoid函数。为了保留共享编码器的原始信息，本文连接 f_i^M 增强特征：

$$\begin{aligned} E_i^{1''} &= A_{\text{conv}} (\text{Concat} (E_i^1, f_i^M)) \\ E_i^{2''} &= A_{\text{conv}} (\text{Concat} (E_i^2, f_i^M)) \end{aligned} \quad (10)$$

然后，将 E_i^1 和 E_i^2 连接起来，通过 A_{conv} 进行处理，得到增强的特征表示：

$$E_i^{eh} = A_{\text{conv}}(\text{Concat}(E_i^{1n}, E_i^{2n})) \quad (11)$$

$$E_i^{mu} = \varphi(\alpha \times f_i^1 + \beta \times f_i^2 + \gamma f_i^M) \quad (12)$$

为了进一步增强共享编码器的特征, 本文采用多模态包容-排斥原理得到增强特征的 E_i^{mu} 。通过这一策略, 本文可以保证模型充分利用各种模态的信息, 得到协同特征 f_i^{CCI} :

$$f_i^{CCI} = A_{\text{conv}}(\text{Concat}(E_i^{eh}, E_i^{mu})) \quad (13)$$

2.3 对比实验结果

2.3.1 临床数据集和BraTS2020数据集对比结果

图5和图6展示了所提MIEF-Net与多个先进

网络(包括U-Net、Attention U-Net、U-Net++、Gate CNN、DeepLabV3+和Cascade R-CNN)在临床数据集和BraTS2020数据集上的视觉分割比较。

图6和图7的展示可以观察到, MIEF-Net在WT、TC和ET细分中, 所有主要评估指标(Dice、HD95、灵敏度和IoU)始终优于基线和近期方法。MIEF-Net在BraTS2020数据集上实现了Dice为0.933, 灵敏度为0.943, HD95为0.935, IoU为0.895, 这些数据明显优于比较方法。

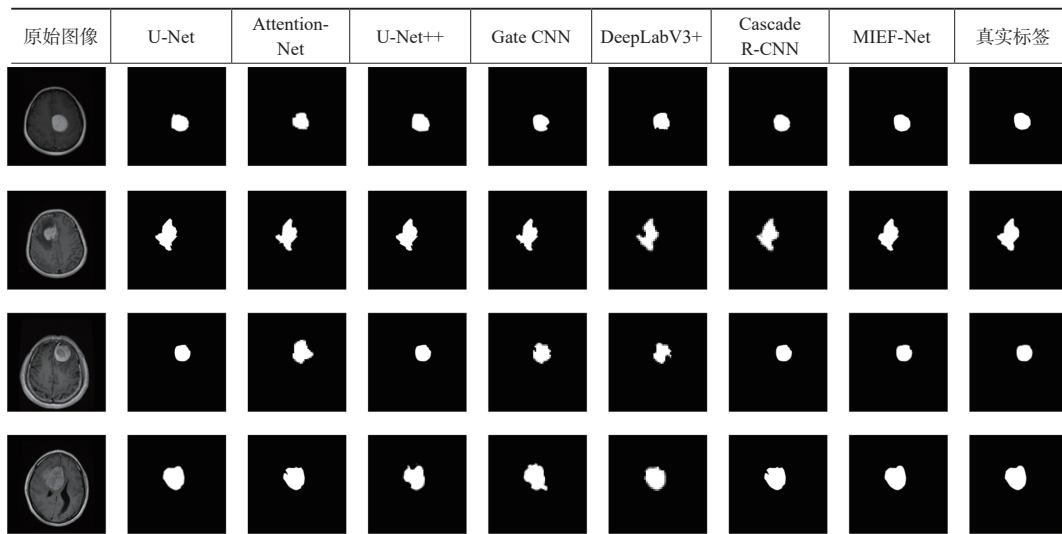


图5 临床数据集中不同网络的分割结果

Fig.5 Segmentation results of different networks on the clinical dataset

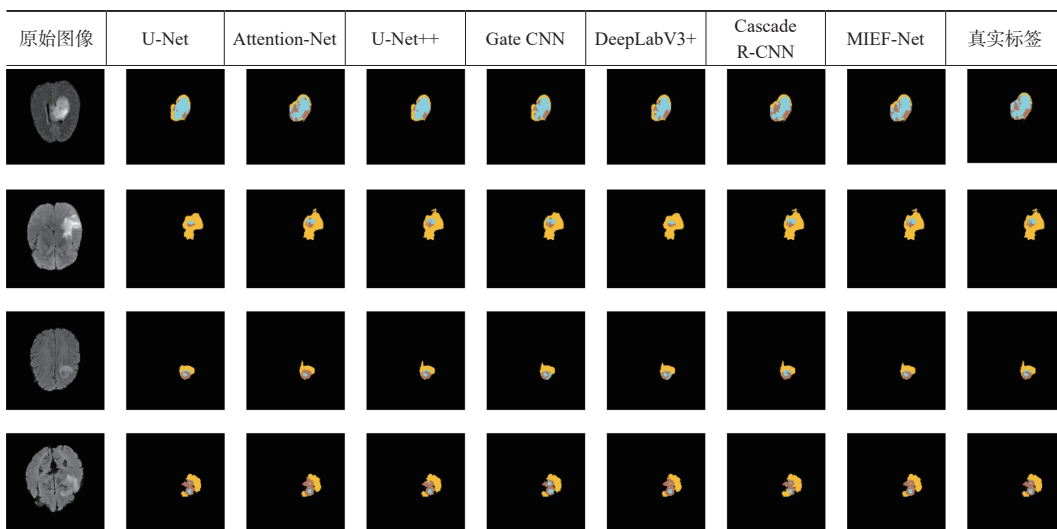


图6 BraTS2020数据集中不同网络的分割结果

Fig.6 Segmentation results of different networks on the BraTS2020 dataset

注: 棕色、蓝色和黄色区域分别代表TC、ET和WT。




图7 MIEF-Net与其他新方法在临床数据集上的比较结果

Fig.7 Comparison results between MIEF-Net and other state-of-the-art methods on the clinical dataset

2.3.2 视觉对比实验

与传统的单模态分割方法不同，MIEF-Net采用级联多模态特征映射框架，同时将4种不同的成像模态输入网络，以利用不同模态间互补和相关的信息。图8和图9所示的视觉比较表明，相较于其他对应工具，MIEF-Net提供了更精确且清晰的肿瘤边界。

2.4 包容-排斥、融合实验结果

2.4.1 临床数据集和BraTS2020数据集包容-排斥结果

在临床数据集和BraTS2020数据集上进行了一系列消融实验。图10展示了医院临床数据集中2种模态、3种模态以及BraTS2020数据集中T1WI、T2WI、T1WI+CE和DWI的所有模态的包容排斥融合实验，以及T1WI、T2WI、T1WI+CE和FLAIR的结合实验。

2.4.2 各模式及BraTS2020数据集融合实验结果

表1和表2展示了临床数据集中各模式及BraTS2020中包容-排斥融合的效果。结果表明，提出的包容-排斥原则在引入多尺度区域可伸缩拟合 (multi-scale region-scalable fitting, MRSF)、MFE和CCI时，能够高效挖掘丰富的模式。此外，表3显示，在BraTS2020数据集中，FLAIR模态表现出强烈的包容性，且与其他模态结合时表现良好。相比之下，表1显示，在临床数据集中，DWI影像与其他模态配合时表现更优。此外，在临床数据集中，3种模态的组合通常能获得令人满意的分割结果，而在BraTS2020数据集中，选择2种模态具有足够融合效果 (例如T1WI+CE和T2WI)。

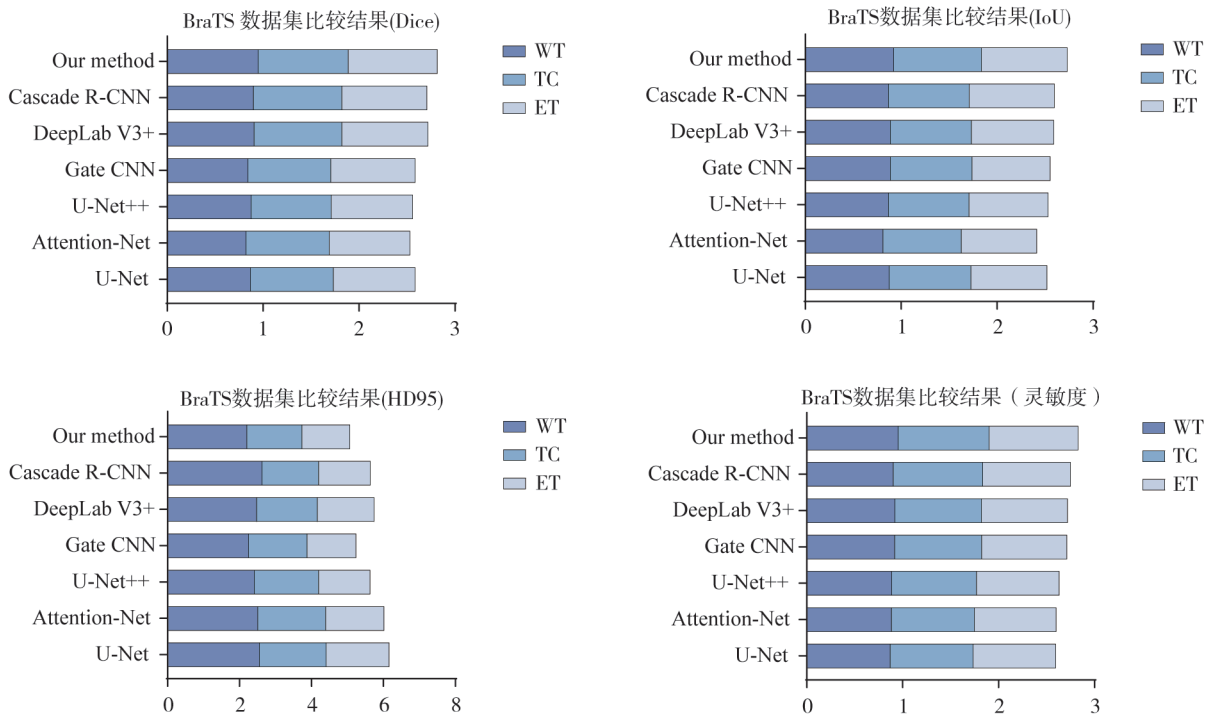


图8 MIEF-Net和其他模型在BraTS数据集的比较结果

Fig.8 Comparison results of MIEF-Net and other novel methods on the BraTS dataset

2.4.3 不同模块融合研究结果

为体现各模块的重要性, 本文采用了对照变量进行分析, 具体记录为实验1 (PVTv2)、实验3 (PVTv2+MFE)、实验5 (PVTv2+MRSF+MFE) 和实验7 (PVTv2+MFE+CCI) 等, 如表3所示。分割结果显示MRSF显著影响脑肿瘤分割。通过引入

MRSF, MIEF-Net能够更好地处理多模态数据, 充分利用不同模态之间的相关性和互补信息。MFE模块可以提取每种模态的重要特征, 以有效增强多模态数据表示。这种对不同模态的全面信息利用使MIEF-Net在脑肿瘤分割任务中展现出更高的准确度和稳健性, 能够更准确地识别和切分不同类型的脑组织和病灶区域。




图9 部分三维重建示例

Fig.9 Examples of partial 3D reconstruction

红色代表肿瘤, 黄色部分代表肿瘤边界。

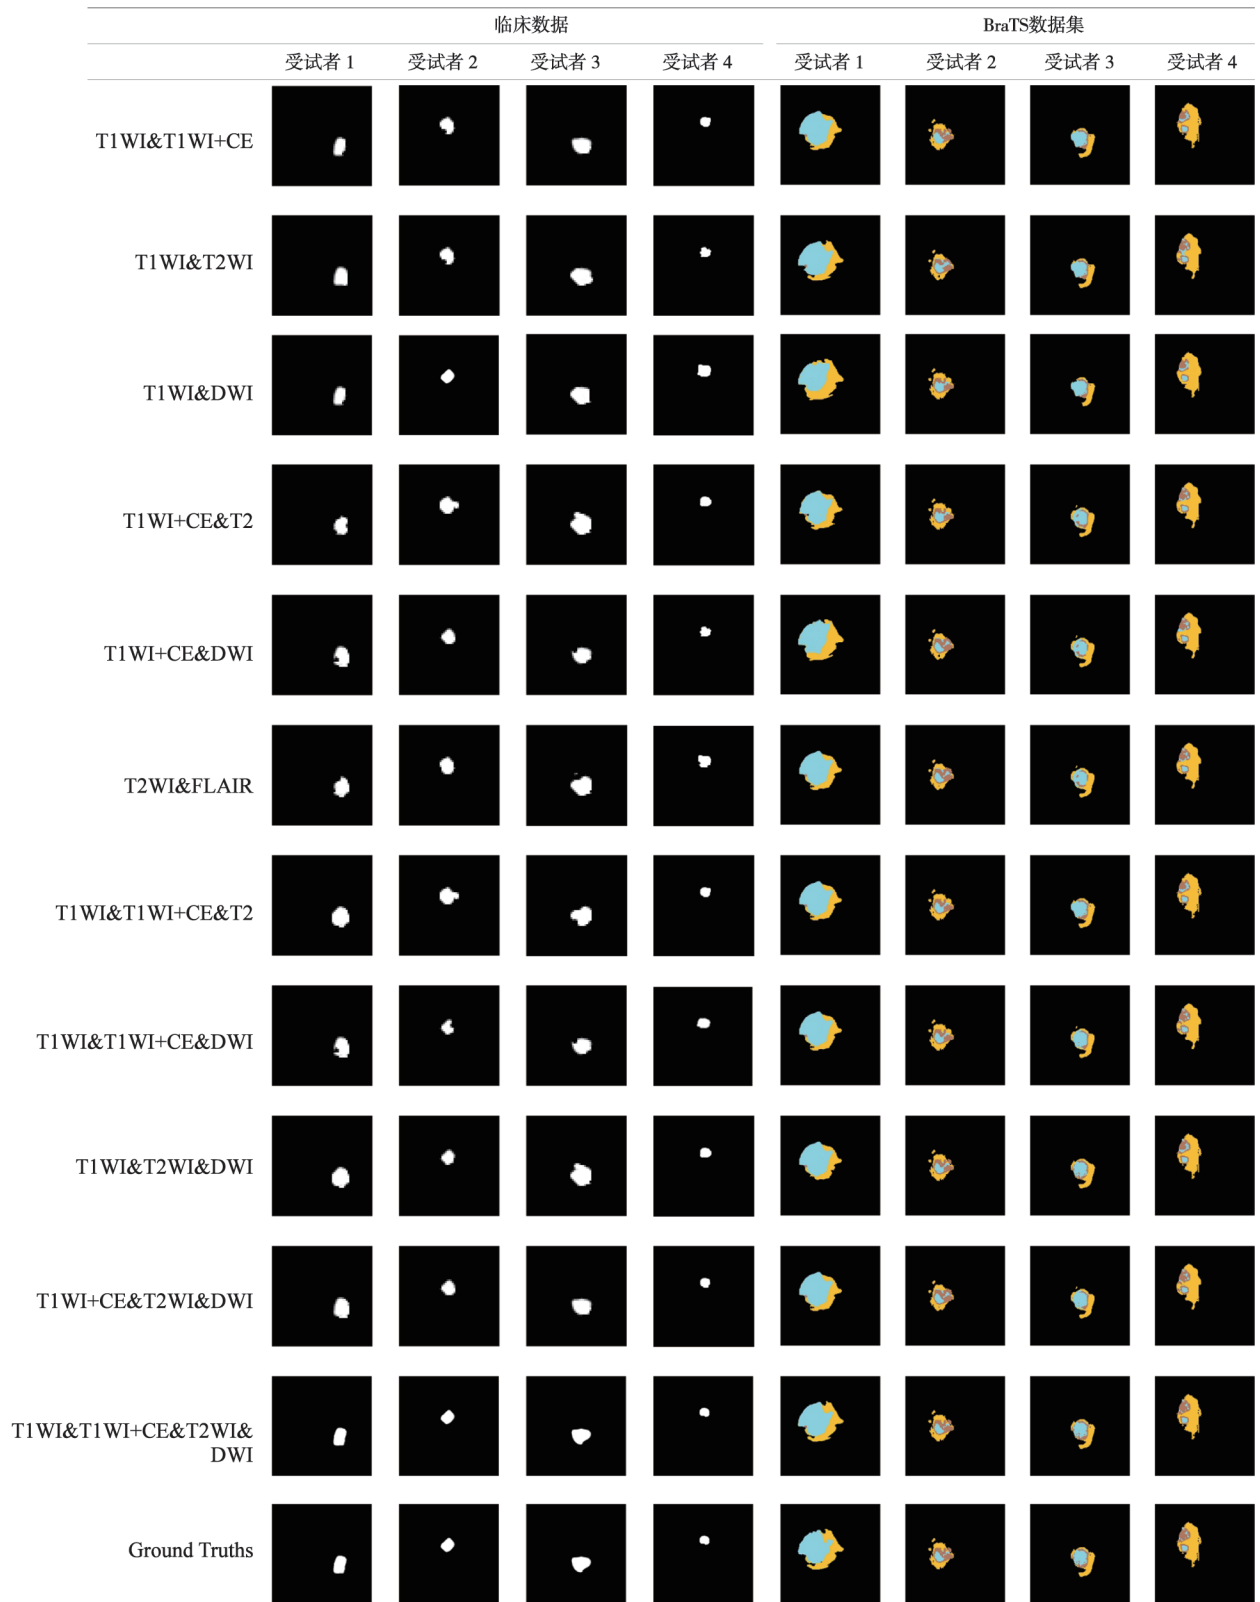


图10 临床和BraTS2020数据集中不同疗法对包容-排斥融合的影响

Fig.10 Impact of different therapies on inclusive-exclusive fusion in the clinical and BraTS2020 datasets

红色标注的数据代表模态间的包容，蓝色标注的数据代表模态间的排斥。实验结果表明，所提出的包容排斥策略能够有效整合多模态数据，有利于探索共享信息和模态特征。

表1 基于临床数据集的包容-排斥原则消融实验

Tab.1 Ablation study of the inclusive-exclusive principle on the clinical dataset

方法	准确度	精确率	召回率	IoU
T1WI及T1WI+CE	0.822	0.813	0.812	0.829
T1WI及T2WI	0.877	0.871	0.867	0.881
T1WI及DWI	0.831	0.839	0.835	0.847
T1WI+CE及T2WI	0.894	0.876	0.877	0.873
T1WI+CE及DWI	0.892	0.881	0.855	0.887
T2WI及DWI	0.851	0.864	0.867	0.884
T1WI、T1WI+CE及T2WI	0.834	0.843	0.831	0.833
T1WI、T1WI+CE及DWI	0.891	0.895	0.893	0.891
T1WI、T2WI及DWI	0.899	0.892	0.883	0.871
T1WI+CE、T2WI+DWI	0.901	0.906	0.908	0.903
T1WI、T1WI+CE、T2WI及DWI	0.911	0.916	0.927	0.908

表2 基于BraTS2020数据集的包容-排斥原则消融实验

Tab.2 Ablation study of the inclusive-exclusive principle on the BraTS2020 dataset

方法	准确度				精确率				召回率				IoU			
	WT	TC	ET	平均值	WT	TC	ET	平均值	WT	TC	ET	平均值	WT	TC	ET	平均值
T1WI及T1WI+CE	0.841	0.813	0.813	0.830	0.837	0.832	0.835	0.835	0.825	0.832	0.811	0.823	0.827	0.801	0.873	0.834
T1WI及T2WI	0.847	0.846	0.846	0.860	0.841	0.853	0.831	0.842	0.846	0.859	0.831	0.845	0.846	0.852	0.861	0.853
T1WI及FLAIR	0.851	0.857	0.857	0.854	0.838	0.832	0.829	0.833	0.806	0.812	0.897	0.838	0.865	0.878	0.901	0.881
T1WI+CE及T2WI	0.939	0.902	0.902	0.925	0.933	0.944	0.901	0.926	0.917	0.925	0.919	0.921	0.901	0.906	0.826	0.891
T1WI+CE及FLAIR	0.943	0.905	0.905	0.933	0.953	0.945	0.916	0.938	0.931	0.929	0.932	0.931	0.923	0.912	0.857	0.897
T2WI及FLAIR	0.925	0.924	0.924	0.927	0.946	0.948	0.931	0.942	0.927	0.929	0.915	0.924	0.918	0.906	0.891	0.905
T1WI、T1WI+CE及T2WI	0.853	0.865	0.865	0.862	0.841	0.861	0.853	0.852	0.831	0.825	0.821	0.826	0.867	0.875	0.896	0.879
T1WI、T1WI+CE及FLAIR	0.939	0.946	0.946	0.945	0.943	0.948	0.938	0.943	0.934	0.929	0.935	0.933	0.921	0.911	0.918	0.917
T1WI、T2WI及FLAIR	0.941	0.943	0.943	0.944	0.943	0.947	0.918	0.936	0.928	0.927	0.949	0.935	0.918	0.905	0.917	0.913
T1WI+CE、T2WI+FLAIR	0.944	0.906	0.906	0.934	0.951	0.955	0.927	0.944	0.926	0.932	0.921	0.926	0.923	0.918	0.868	0.903
T1WI、T1WI+CE、T2WI及FLAIR	0.949	0.953	0.953	0.955	0.956	0.957	0.942	0.952	0.941	0.939	0.929	0.936	0.926	0.919	0.939	0.928

表3 不同模块消融研究结果

Tab.3 Ablation study results of different modules

方法	准确度	精确率	召回率	IoU
实验1 (PVTv2)	0.868	0.859	0.857	0.873
实验2 (PVTv2+MRSF)	0.872	0.875	0.876	0.881
实验3 (PVTv2+MFE)	0.891	0.882	0.897	0.879
实验4 (PVTv2+CCI)	0.893	0.879	0.901	0.882
实验5 (PVTv2+MRSF+MFE)	0.905	0.921	0.906	0.886
实验6 (PVTv2+MRSF+CCI)	0.912	0.919	0.911	0.889
实验7 (PVTv2+MFE+CCI)	0.921	0.931	0.917	0.892
实验8 (PVTv2+MRSF+MFE+CCI)	0.935	0.944	0.925	0.899

3 讨论

本文为了充分分析医学图像、提高分割性能,利用PVTv2模型^[18],结合了针对ImageNet-1k^[19]训练数据集设计的Transformer构建了层次化的特征图,并通过多尺度图像处理在捕获多样化信息方面表现出色。

针对脑胶质瘤生长方式呈弥漫浸润的特点,综合利用多模态图像的信息,巧妙地利用不同模态之间的相关性和互补信息,提出了一种多模态MIEF-Net^[20]。该方法允许模态在处理多尺度数据时,通过降压策略在保持效率的同时提高性能。此外,为了构建解码路径,实现特定于模态的属性保存,本研究使用了一个简单的级联块(Cas)^[17]来达到学习跨模态数据的更多特征,从而提高分割任务的性能。通过引入MRSF, MIEF-Net能够更好地处理多模态数据,充分利用不同模态之间的相关性和互补信息,显著影响脑肿瘤分割,能够更准确地识别和切分不同类型的脑组织和病灶区域。利用多模态包容-排斥原理所提出CCI可以有效地结合不同模态的细节特征和共享表征的语义特征,同时抑制与任务无关的模态特定信息来提高脑肿瘤分割的准确度。全方位地分析MRI多序列信息,提高分割性能,可以更全面地了解脑肿瘤的形态、位置和特征。本研究构建了层次化的特征图,并通过多尺度图像处理在捕获多样化信息方面表现出色,优于Unet和其他Transformer扩展^[1]。且根据具体需求轻松应用任意数量的多模态,扩大其适用范围。

图6和图7展示所提MIEF-Net与多个先进网络在临床数据集^[21]和BraTS2020数据集上的视觉分割比较始终优于其他先进网络。具体来说, MIEF-Net在BraTS2020数据集上Dice为0.933,灵敏度为0.943, HD95为0.935, IoU为0.895,这些数据明显优于比较方法。这些改善在ET和TC亚区域尤为明显,这些区域由于形状不规则、对比度低且体积小,常常具有挑战性。虽然传统架构如U-Net及其变体在WT区域表现尚可,但由于上下文建模有限和模态交互不足,它们在ET和TC

中捕捉详细结构的性能往往较差。

研究^[22]显示, MIEF-Net在分割多个脑肿瘤亚区域且减少病变组织遗漏方面表现卓越。虽然所有比较的方法在多类分割任务中均能区分病灶区域与正常脑结构,但前期研究^[22]表明单模态与多模态方法在性能上的差异有统计学意义。值得注意的是,单模态方法如U-Net和Attention U-Net常常无法捕捉细粒度肿瘤细节,尤其是在解剖复杂或低对比度患者中^[4]。这一限制源于它们在利用模态间互补性和空间相关性方面的能力有限,而这些对准确的细分至关重要。相比之下, MIEF-Net通过精心设计的架构(包括MRSF、MFE和CCI)模块,可以有效地整合多模态上下文线索。该架构促进了异构模态特性的融合,增强了网络的表征能力。因此, MIEF-Net在边缘保护和假阳性检测减少方面实现了更优异的分割性能,尤其是在病变较小或不明显的区域。总体而言, MIEF-Net的提升性能凸显了其临床部署的稳健性和实用性。其减少细微和广泛肿瘤区域的分割错误的的能力,凸显了其支持神经肿瘤学工作流程中更准确诊断、治疗计划制订和疾病进展监测的潜力。视觉对比实验也进一步验证MIEF-Net可提供更精准且清晰的肿瘤边界。

从临床角度看,该方法在支持放射影像决策方面具有相当的潜力。通过提高切段精度和减少假阳性,尤其是在细微或早期肿瘤区域, MIEF-Net有望促进更可靠的诊断、治疗计划和预后评估。此外,其在临床和基准数据集中的鲁棒性表明了强烈的泛化性,进一步强化了其在现实医疗场景中的适用性。

本研究有一定的局限性。测试数据样本较少,缺乏多中心验证。本研究主要针对于肿瘤的精准确分割,未能进一步对瘤内异质性做出更深入的分割;其次,未能对其他器官部位医学成像数据和任务的通用性进行验证。暂时未能在临床实践中广泛推广并应用。

这项研究主要针对脑胶质瘤MRI图像多模态下的精准分割及三维重建。为了解决单一成像序列常存在显示范围差异性的现象;对比其他传统分割技术在全局-局部特征平衡不足这些问题,

我们提出了MIEF-Net。在公共数据集中的实验表明, MIEF-Net在解决上述问题方面优于传统的单一模态的分割, 其设计是新颖且有效的。同时视觉对比实验中, MIEF-Net依据所构建的三维重建图像提供了更精确且清晰的肿瘤边界。

第一作者:

王泽坤 (ORCID: 0000-0002-6985-160X), 硕士研究生, 主治医师。

通信作者:

刘屹 (ORCID: 0000-0002-3442-8713), 主任医师, 教授, E-mail: liuyicmu@sina.cn。

作者贡献声明:

王泽坤: 起草和撰写稿件, 获取、分析和解释本研究的数据; 于永成: 获取、分析和解释本研究的数据, 对稿件重要内容进行了修改。王利华: 收集、获取数据并参与撰写; 罗娅红: 对稿件进行审阅指导; 刘屹: 设计本研究的方案, 对稿件重要内容进行了修改。

[参 考 文 献]

- [1] CHEN W N, CAI C Q, TAN X H, et al. MAUNet: a mixed attention U-Net with spatial multi-dimensional convolution and contextual feature calibration for 3D brain tumor segmentation in multimodal MRI [J] . Front Neurosci, 2025, 19: 1682603.
- [2] ZARENIA E, FAR A A, REZAEI K. Automated multi-class MRI brain tumor classification and segmentation using deformable attention and saliency mapping [J] . Sci Rep, 2025, 15(1): 8114.
- [3] REHMAN M U, RYU J, NIZAMI I F, et al. RAAGR2-Net: a brain tumor segmentation network using parallel processing of multiple spatial frames [J] . Comput Biol Med, 2023, 152: 106426.
- [4] ZHOU T X, ZHU S. Uncertainty quantification and attention-aware fusion guided multi-modal MR brain tumor segmentation [J] . Comput Biol Med, 2023, 163: 107142.
- [5] LIN C W, LIN Y. A cross-dimensional synergistic network for brain tumor segmentation [J] . Eng Appl Artif Intell, 2025, 160: 111829.
- [6] QIN Z F, LI Q Q. An uncertain support vector machine with imprecise observations [J] . Fuzzy Optim Decis Mak, 2023, 22(4): 611-629.
- [7] MAHAPATRA D. Analyzing training information from random forests for improved image segmentation [J] . IEEE Trans Image Process, 2014, 23(4): 1504-1512.
- [8] SINAGA K P, YANG M S. Unsupervised K-means clustering algorithm [J] . IEEE Access, 2020, 8: 80716-80727.
- [9] SHARMA P, NAYAK D R, BALABANTARAY B K, et al. A survey on cancer detection *via* convolutional neural networks: current challenges and future directions [J] . Neural Netw, 2024, 169: 637-659.
- [10] GENCER K, GENCER G. Hybrid deep learning approach for brain tumor classification using EfficientNetB0 and novel quantum genetic algorithm [J] . PeerJ Comput Sci, 2025, 11: e2556.
- [11] ISHAQ A, ULLAH F U M, HAMANDAWANA P, et al. Improved efficientNet architecture for multi-grade brain tumor detection [J] . Electronics, 2025, 14(4): 710.
- [12] HE S, FENG Y F, GRANT P E, et al. Segmentation ability map: Interpret deep features for medical image segmentation [J] . Med Image Anal, 2023, 84: 102726.
- [13] COX J, LIU P, STOLTE S E, et al. BrainSegFounder: towards 3D foundation models for neuroimage segmentation [J] . ArXiv, 2024: arXiv: 2406.10395v3.
- [14] ZUNAIR H, BEN HAMZA A. Sharp U-Net: depthwise convolutional network for biomedical image segmentation [J] . Comput Biol Med, 2021, 136: 104699.
- [15] ZHU Z Q, WANG Z D, QI G Q, et al. Visually stabilized mamba U-shaped network with strong inductive bias for 3-D brain tumor segmentation [J] . IEEE Trans Instrum Meas, 2025, 74: 2518511.
- [16] QIAN L D, WEN C Y, LI Y, et al. Multi-scale context UNet-like network with redesigned skip connections for medical image segmentation [J] . Comput Methods Programs Biomed, 2024, 243: 107885.
- [17] YANG H Y, ZHOU T, ZHOU Y, et al. Flexible fusion network for multi-modal brain tumor segmentation [J] . IEEE J Biomed Health Inform, 2023, 27(7): 3349-3359.
- [18] WANG W H, XIE E Z, LI X, et al. PVT v2: Improved baselines with pyramid vision transformer [J] . Comput Vis Medium, 2022, 8(3): 415-424.
- [19] DENG J, DONG W, SOCHER R, et al. ImageNet: a large-scale hierarchical image database [C] //2009 IEEE Conference on Computer Vision and Pattern Recognition. June 20-25, 2009, Miami, FL, USA. IEEE, 2009: 248-255.
- [20] DING K Y, XIAO L F, WENG G R. Active contours driven by region-scalable fitting and optimized Laplacian of Gaussian energy for image segmentation [J] . Signal Process, 2017, 134(C): 224-233.
- [21] LIN C W, CHEN Z S. MM-UNet: a novel cross-attention mechanism between modules and scales for brain tumor segmentation [J] . Eng Appl Artif Intell, 2024, 133: 108591.
- [22] ZHAO Q Z, WU R Y, CHEN M T, et al. MIEF-Net: multimodal image-enhanced fusion network for intelligent fall risk prediction [J] . Neural Netw, 2025, 195: 108260.

(收稿日期: 2025-10-31 修回日期: 2025-12-07)