

文章编号: 2095-2163(2023)12-0080-07

中图分类号: TP391

文献标志码: A

基于多重注意力机制的多模态脑肿瘤图像分割

陈子昂¹, 刘娜¹, 袁野², 李清都², 万里红³

(1 上海理工大学 健康科学与工程学院, 上海 200093; 2 上海理工大学 机器智能研究院, 上海 200093;

3 中原动力智能机器人有限公司, 郑州 450018)

摘要: 本文提出了一种新型的多模态脑肿瘤图像分割方法,该方法将3种注意力机制与传统U-Net模型相结合,从三维多模态MRI医学图像中分割脑肿瘤。所提出的模型分为编码器、解码器、特征融合和瓶颈层4部分,各采用不同的注意力机制,增强了多模态信息提取能力。在特征融合部分,提出了一种新的注意力模块—注意力门控传播模块(AGPM),该模块将通道注意力和注意力门结合起来,沿通道维度和空间维度依次推断注意力映射;瓶颈层部分,在卷积层之间应用了一个多头自注意力层(MHSA)来增强感受野。此外,在模型的瓶颈层部分加入了一种新的注意力模块—多头特征增强模块(MHFEM),来补充多尺度信息。通过在BraTS2020数据集上的实验结果,表明了所提模型的有效性。

关键词: 医学图像; 深度学习; 语义分割; 注意力机制

Multimodal image segmentation of brain tumors based on multiple attentional mechanisms

CHEN Ziang¹, LIU Na¹, YUAN Ye², LI Qingdu², WAN Lihong³

(1 School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China;

2 Institute of Machine Intelligence, University of Shanghai for Science and Technology, Shanghai 200093, China;

3 Origin Dynamics Intelligent Robot Co.,Ltd., Zhengzhou 450018, China)

Abstract: In this paper, a novel multimodal brain tumor image segmentation method is proposed, which combines three attentional mechanisms with a traditional U-Net model to segment brain tumors from 3D multimodal MRI medical images. The proposed model is divided into four parts: encoder, decoder, feature fusion and bottleneck layer, each of which employs a different attentional mechanism to enhance the multimodal information extraction capability. In the feature fusion part, a new attention module—attention gated propagation module (AGPM) is proposed, which combines channel attention and attention gates to infer the attention mapping sequentially along the channel dimension and spatial dimension; in the bottleneck layer part, a multi-head self-attention layer (MHSA) is applied between the convolutional layers to enhance the sensory field. In addition, a new attention module—Multi-Headed Feature Enhancement Module (MHFEM)—is added to the bottleneck layer part of the model to supplement the multi-scale information. The effectiveness of the proposed model is demonstrated by experimental results on the BraTS2020 dataset.

Key words: medical image; deep learning; semantic segmentation; attention mechanism

0 引言

脑肿瘤根据其来源可分为原发性肿瘤和继发性肿瘤,胶质瘤是最常见的原发性脑肿瘤,由大脑和脊髓中的胶质细胞癌变引起^[1],可进一步分为低级别胶质瘤(LGG)和高级别胶质瘤(HGG)。HGG是一种恶性脑肿瘤,侵袭性高,预后较差,治疗后复发性较高。胶质瘤的治疗主要以切除为主,因此准确的

脑肿瘤分割对于疾病的诊断和治疗计划至关重要^[2]。然而,由于胶质瘤的位置、外观和形状的多样性,胶质瘤的自动分割仍然具有挑战性,被认为是医学领域最困难的分割问题之一。

多模态磁共振成像(Multi-modal Magnetic Resonance Imaging, MRI)能提供高对比度和空间分辨率的脑图像,是一种常用的脑结构分析方法^[3],已广泛应用于临床,如大脑、心脏、椎间盘分割

基金项目: 国家自然科学基金(61773083);上海市浦江人才计划(2019PJD035);上海市人工智能创新发展专项;上海市引进海外高层次人才工作专项;上海高校特聘教授(东方学者)计划。

作者简介: 陈子昂(1998-),男,硕士研究生,主要研究方向:计算机视觉。

通讯作者: 刘娜(1985-),女,博士,讲师,主要研究方向:计算机视觉。Email:liuna@usst.edu.cn

收稿日期: 2022-12-16

等^[4]。通过改变磁共振信号,可以获得 4 种模态的磁共振图像,分别为 T1-加权(T1)、T1-带对比增强(T1ce)、T2-加权(T2)和 T2 流体衰减反演恢复(Flair)。其中,T2 和 Flair 像能突出瘤周水肿,T1 和 T1ce 像能显示坏死和非增强的肿瘤核心,T1ce 能进一步显示增强的肿瘤区域^[3]。因此,多模态 MR 图像在脑肿瘤分割中的应用越来越受到重视。

近年来,随着卷积神经网络(Convolutional Neural Networks, CNN)的提出,基于深度学习的方法成为三维 MRI 脑肿瘤分割的常用方法。文献[5]将分割问题转化为像素级的分类问题,首次将 CNN 引入图像分割中,提出了一种全卷积网络(Fully Convolutional Network, FCN)的编码器-解码器神经网络架构。在编码阶段,使用 CNN 提取特征,并将 CNN 的最后一个全连接层替换为卷积层,从而减小图像的尺寸,增加特征的数量;在解码阶段,通过插值或反褶积对图像进行恢复,并对 ground truth 的每个像素对应的预测结果进行分类,实现像素级分类。尽管 FCN 在自然图像分割方面具有很强的性能,但仍存在许多缺点,容易丢失自然图像的局部信息。文献[6]提出了一种称为 U-Net 的神经网络架构来弥补这一缺陷,其给编码器和解码器设置相同的层数,形成 U 型架构,并以此得名。U-Net 在每个编码器层的输出和相应解码器层的输入之间引入了跳跃式连接。跳跃连接的优点使其保留了精确的局部信息,可以被解码器用来实现清晰的分割轮廓。文献[7]使用基于 U-Net 的深度卷积网络进行脑肿瘤图像分割,有效地获得了出色的分割结果。

注意力机制本质上类似于人类对外部事物的观察机制。一般来说,人们在观察外部事物时,首先比较注意并倾向于观察事物的一些重要的局部信息,然后将不同区域的信息结合起来,形成对所观察事物的整体印象。注意力机制在各种 AI 任务中非常流行,经常用于各种网络模型的组件中,使用注意力机制的网络模块通常称为注意力模型。注意力机制的体系结构大致可分为空间域、通道域和混合域三大类。文献[8]提出了一种名为 Spatial Transformer 的网络模块,通过生成并计算所有通道特征图的权重,来聚焦图像的不同区域。文献[9]提出了一种称为 SE block 的网络模块,用于为所有通道生成权重参数,这些权重参数可以描述对不同通道的重视程度。文献[10]提出了一种混合域注意力模块(Convolutional Block Attention Module, CBAM),集成了通道注意力和空间注意力。文献[11]首次将自

注意力(Self-Attention)机制引入计算机视觉,本质上是一种特殊的空间注意力。文献[12]首次在计算机视觉中引入了多头自我注意力(MHSA),将瓶颈层的卷积层换成了 MHSA 块,模型的精度得到了明显的提高。文献[13]提出了一种专门用于语义分割的空间注意力机制模块。与传统的空间注意力机制相比,权值层结合了上采样和下采样的特征,在给予注意力权值的同时进行特征融合。一些研究尝试使用注意力模型优化多模态融合。文献[14]尝试在 U-Net 的跳跃连接部分添加 CBAM 模块,优化鼻咽癌(NPC)MRI 的多模态融合。文献[15]提出了一种注意相互增强(AME)模块,在特征提取阶段融合每种模态的特征,以挖掘不同图像模态之间的关系,用于宫颈发育不良的诊断。

综上所述,本文认为三维 MRI 脑肿瘤分割还存在以下不足:

(1) 仅将脑肿瘤 MRI 的 4 个多模态序列转换为四通道输入,未充分利用 3D MRI 的多模态信息。

(2) 感受野缺失一直是 CNN Based Network 中存在的问题,导致分割结果缺乏详细信息。

(3) 在脑肿瘤分割中,整个图像只有极小部分包含肿瘤。在 BraTS^[3]数据集的训练集中,大约超过 95%的体素属于 background,不足 5%的体素属于 ED、NCR、NET 和 ET。数据集存在类不平衡问题。

为此,提出了一种全新的基于多重注意力机制的多模态脑肿瘤图像分割方法。为了克服这些挑战,本文考虑以下设计:

(1) 提出注意门控传播模块(AGPM),同时获取信道注意和空间注意信息,优化多模态融合;

(2) 在瓶颈层增加三维多头自注意力(MHSA)块,补充分割细节,扩展网络接受域;

(3) 将多头特征增强模块(Multi-Head Feature Enhancement Module, MHFEM)置于瓶颈层后,有利于远程信息建模,并将低层特征作为门控特征的多尺度信息进行组合,实现对噪声的滤波;

(4) 将广义骰子损失(GDL)^[16]与二元交叉熵(BCE)相结合,用以处理类不平衡问题。

1 方法

1.1 整体网络结构

如图 1 所示,本文中所提模型采用了基于 U-Net 的三维全卷积编码器-解码器架构,其体系结构可分为编码器、解码器、特征融合、瓶颈层等 4 个部分。模型输入是 $128 * 128 * 128$ 的立方体,其中所

有体素将被预测属于某个类。编码器部分使用5个基于CNN的模块提取脑肿瘤MRI图像的特征。这些基于CNN的模块由三维卷积层、BatchNorm层和LeakyReLU层组成,由两个小模型块组成一个整体。在第一个小模型块的最后,设置三维卷积层的步长为2,用来代替池化层进行降维。解码器部分采用5个基于三维卷积层和转置卷积层的模型块来实现特征恢复和上采样。这些模型块与编码器中的大致相

同,但其步长设置为1。在瓶颈部分,本文在两个三维卷积层之间添加一个三维MHSA模型块,然后提供多头特征增强模块(MHFEM)来获取远程建模信息。此外,利用跳跃连接实现上采样与下采样同层特征映射之间的特征融合。这是语义分割中常见的体系结构,其可以补充特征,改善图像细节。在特征融合过程中增加了通道注意力模块和空间注意力模块。

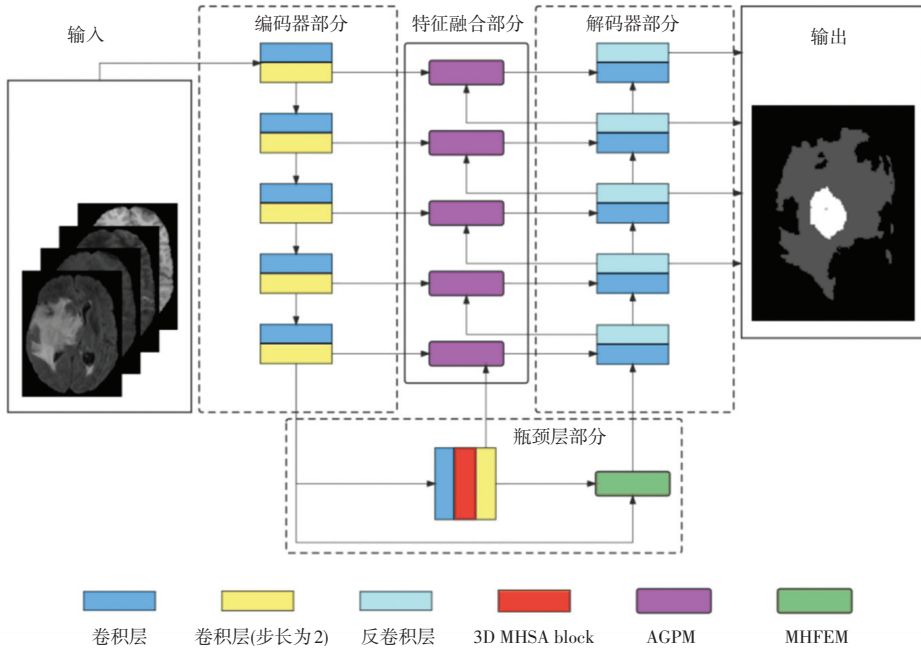


图1 整体网络结构

Fig. 1 The architecture of the proposed network

1.2 3D MHSA 模块

多头自注意力(MHSA)模块作为Transformer模块中一种重要的结构,在计算机视觉领域得到了广泛的应用。许多研究表明,MHSA模块可以显著提高CNN的性能。例如,在文献[12]中,将ResNet瓶颈层的第二个卷积层替换为MHSA模块,扩大感受域。实验表明,该替换方法可以大大提高模型在目标检测、实例分割等任务中的性能。鉴于其优异的性能,本文将MHSA引入到脑肿瘤MRI分割任务中。此外,为了匹配MRI图像的三维度,本文在原MHSA块的基础上设计了一种新的3D MHSA块,并在U-Net瓶颈层的两个卷积层之间添加了新设计的MHSA块。

如图2所示,输入MHSA模块的特征图维度设置为 $H * W * D * C_d$ 。其中, H 、 W 、 D 分别为特征图的高、宽、深, C_d 为通道数除以MHSA模块的多头数 d 。文中使用绝对位置编码^[17]来学习空间注意力。

RW 、 RH 、 RD 分别表示维度为 $H * 1 * D * d$ 、 $1 * W * D * d$ 、 $H * W * 1 * d$ 的可学习权重矩阵。在单个头中,输出可用式(1)表示:

$$Z = \text{softmax}(q^{kT} + qr^T)v \quad (1)$$

1.3 注意门控传播模块

注意力门(Attention-Gate)^[13]是一种专门用于医学图像的空间注意力模型。其通过计算一个门控向量来确定每个像素的焦点区域,摒弃了以单一标量值表示每个像素向量的注意力级别的传统方法。该模型通过抑制与任务无关的区域特征,采用补充上层特征的方式,更有效地捕捉注意力依赖性。这种策略在处理数据集较小的医学图像任务时尤为有益。然而,需要注意的是,该注意力模型在通道特征方面并未经过优化。在三维MRI图像中,通道信息用来表示MRI图像的模态特征,因此,对通道特征的优化显得尤为重要。为此,本文提出了一种新的注意模型——注意门控传播模块(AGPM)来解决这一问题。

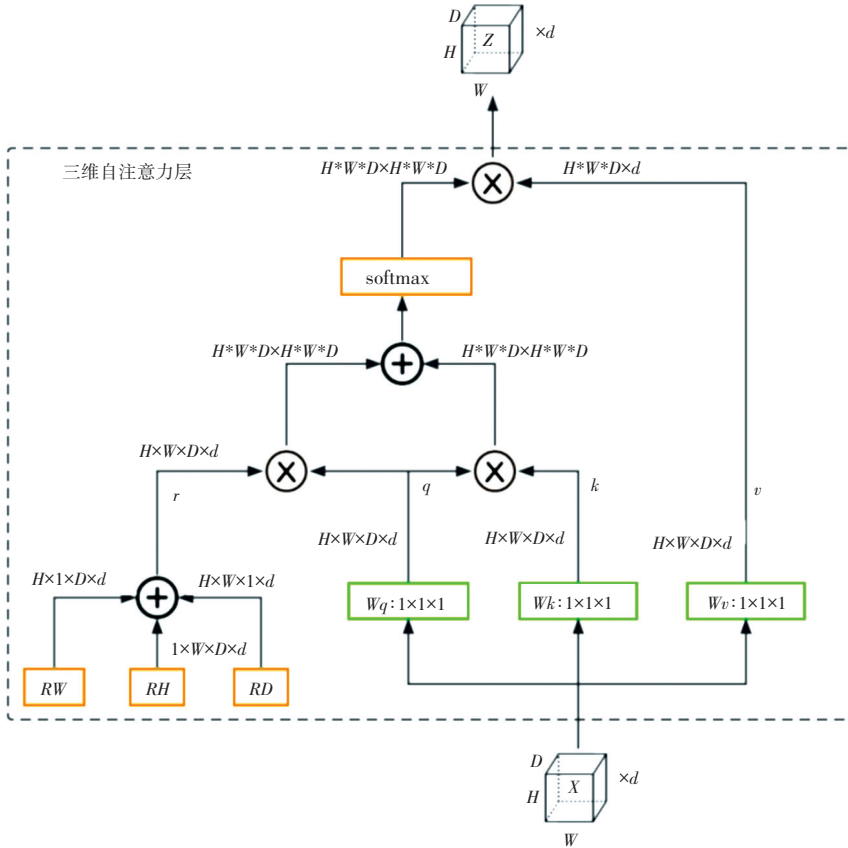


图 2 3D MHSA 模块

Fig. 2 3D Multi-Head Self-Attention (MHSA) block

MRI 数据集通常具有多模态序列, 而 BraTS 数据集中有 T1、T2、FLAIR 和 T1CE 4 种模式。在本文所提出的工作中, 将多模态图像叠加成一个四通道输入。因此, 如果要直接优化 MRI 的多模态融合, 优化网络中的通道是最好、最直接的方法。

卷积块注意力模块 (CBAM)^[10] 是一个同时获得通道注意和空间注意的注意力块, CBAM 的通道注意力块不仅使用全局平均池层捕获平均值, 还使用了全局最大池层获得特征映射的最大值, 平均值和最大值都被输入到共享 MLP 中, 其空间注意力模块也使用了全局平均池层和全局最大池层, 通过 softmax 获取空间注意。本文认为, 在医学图像任务中, 注意门比 CBAM 中的空间注意力模块能更好地获取空间注意力信息, 通道注意可以优化医学图像的多模态融合。因此, 本文在网络特征融合部分结合了通道注意力和注意力门。

如图 3 所示, 在特征融合部分, 先将编码器同层的特征映射输入到信道注意力块中, 得到信道注意映射; 然后将特征图与通道注意图点积输入注意力门, 并结合上层特征得到空间注意图; 最后, 将其与空间注意图进行点积, 得到结果。




图 3 注意力门控传播模块

Fig. 3 Attention Gated Propagation Module

1.4 多头特征增强模块

在瓶颈层部分, 本文提出了多头特征增强模块 (MHFEM), 在输入解码器之前对特征进行增强。基于多头注意力, 利用特征图生成注意力权重, 有利于远程信息建模和集成多尺度信息。

如图 4 所示, 将待上采样的特征设为 X , 编码器中上层的特征映射设为门控特征 G 。先使用三线性插值上采样, 使 X 的维度与门控特性 G 的维度 $H_g * W_g * D_g * d$ 统一, 然后将特性 X 与门控特征 G 点积; 同时使用 3D 绝对位置编码, 生成空间位置特征 X ; 将两组特征点积并相加求和; 再通过 Softmax 层得到注意力权重, 并与门控特征 G 点乘得到结果。其表达如式 (2) 所示:

$$Z = \text{softmax}(xg^T + xr^T)g \quad (2)$$

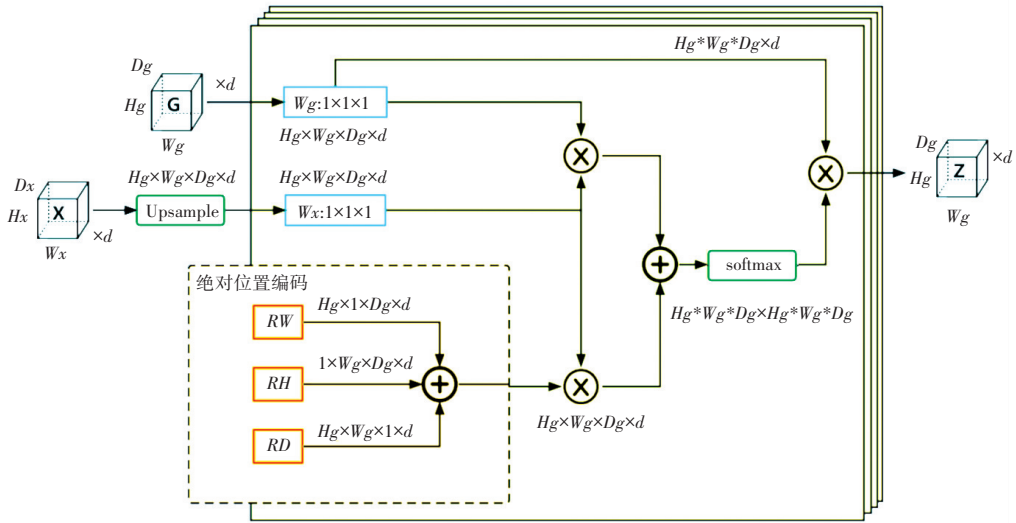


图4 多头特征增强模块

Fig. 4 Multi-Head Feature Enhancement Module

1.5 广义骰子损失

文献[16]中提出的广义骰子损失 (Generalized Dice Loss) 已被证明是一种强大的图像分析工具, 现在广泛用于分割 2D 和 3D 医学图像。当处理一些罕见图像数据集时, 候选标签之间可能会发生严重的类不平衡, 从而导致性能欠佳。由于只有很小一部分的完整图像代表了有特征的病理区域, 这种问题在医学图像中尤其严重。广义骰子损失可表示为式(3)形式:

$$GDL = 1 - \frac{2 \sum_{l=1}^L w_l \sum_{i=1}^N r_{li} p_{li}}{\sum_{l=1}^L w_l \sum_{i=1}^N r_{li} p_{li}} \quad (3)$$

式中: r_{li} 表示属于 L 类的第 i 个体素的真值, p_{li} 为相应的预测值, N 是体素的总数, L 是类的总数, w_l 用于为不同的标签集属性提供不变性。

2 实验

2.1 数据集

本文中所提出的方法在包含 FLAIR、T1、T1c、T2 四种 MRI 图像的 BraTS2020 数据集上得到了验证。BraTS2020 训练集包含 369 张不同患者的胶质母细胞瘤 (HGG) 和低级别胶质瘤 (LGG) 的 MRI 扫描图。训练集包含 293 个 HGG 扫描和 76 个 LGG 扫描, 并附有经委员会认证的神经放射专家的地面真相标签; 验证集包含 125 个案例。在分割任务中需要分割 3 个区域: 非增强性肿瘤、增强性肿瘤、瘤周水肿。在评价指标中, 整个肿瘤区域由水肿区、非增强区和增强区组成。肿瘤核心区由增强区和非增

强区组成^[18]。此外, BraTS 挑战一直专注于评估 MRI 扫描中脑肿瘤分割的最先进方法。BraTS 2020 利用多机构术前 MRI 扫描, 重点关注内在异质性脑肿瘤 (称为胶质瘤) 的外观、形状和组织学分割。最后, 该挑战旨在通过实验评估肿瘤分割的不确定性。

2.2 实验设置

本文方法在 PyTorch 中实现; 模型采用 NVIDIA GeForce RTX 2080 Ti GPU 和 Intel Xeon (R) CPU e5-2650 v3 @ 2.30 GHz x2032 gb RAM CPU 进行, 且仅使用 BraTS2020 数据集训练模型; 4 种模态数据 (Flair、T1ce、T2、T1) 重叠作为初始通道; 初始输入为 $4 * 128 * 128 * 128$ patch。本文方法在在线评估平台上进行评估, 可以与许多最先进的方法直接比较。

首先将每种网络结构的改进效果在 BraTS2020 训练集上的五折交叉验证实验进行了比较, 选择效果最好的网络结构上传到在线评价平台, 得到验证集结果。此外, 还将提出的方法与近年来常用的深度学习模型进行了比较, 并且在相同的数据集中重现这些训练模型。在 BraTS 数据集中, 训练的标签为水肿、非增强性肿瘤和增强性肿瘤。通常, BraTS 评估分割使用部分重叠的整个肿瘤、肿瘤核心、增强肿瘤区域。实验设置 sigmoid 作为分类器, 将二元交叉熵 (Binary Cross-Entropy, BCE) 与 GDL 相结合作为损失函数; 设置 batch size 为 5, 初始学习率为 $1e-2$ 。在训练阶段, 学习率是线性下降的。

2.3 实验结果

本文报告了近年来深度学习模型应用于脑肿瘤

分割的结果。项目组复制了这些模型,并在 BraTS2020 数据集上评估了这些方法,见表 1。由于表 1 中提到的模型参数并不明确,故而在重新生成这些模型时做了很多更改。表中模型代码采用开源项目,本项目组采用了相同的预处理和后处理方法,本研究集中在模型层面。为了评估现有的深度学习方法,比较了 5 个具有最先进性能的方法,本文提出的网络架构性能更佳。除了提高肿瘤骰子得分外,

本文方法在整个肿瘤骰子得分及肿瘤核心骰子得分上都有较好的表现。实验表明,本文方法在最先进的模型中仍然具有竞争力。

在图 5 中,展示了不同深度学习架构的分割结果,并选择了 5 个有代表性的样本进行验证。结果表明,与其他网络相比本文方法在细节特征的生成方面具有更好的性能。

表 1 实验结果对比

Table 1 The detailed BraTS2020 validation set result

| Model | WT | TC | ET | Mean |
|--------------------------|----------------|----------------|----------------|---------|
| 3DUNet ^[19] | 0.882 2 | 0.792 7 | 0.719 8 | 0.798 2 |
| MMTSN ^[20] | 0.882 3 | 0.801 2 | 0.763 7 | 0.815 7 |
| nnUNet ^[21] | 0.905 0 | 0.839 0 | 0.740 0 | 0.828 0 |
| TransBTS ^[22] | 0.890 0 | 0.813 6 | 0.785 0 | 0.829 5 |
| Ours | 0.908 3 | 0.846 8 | 0.749 8 | 0.834 9 |

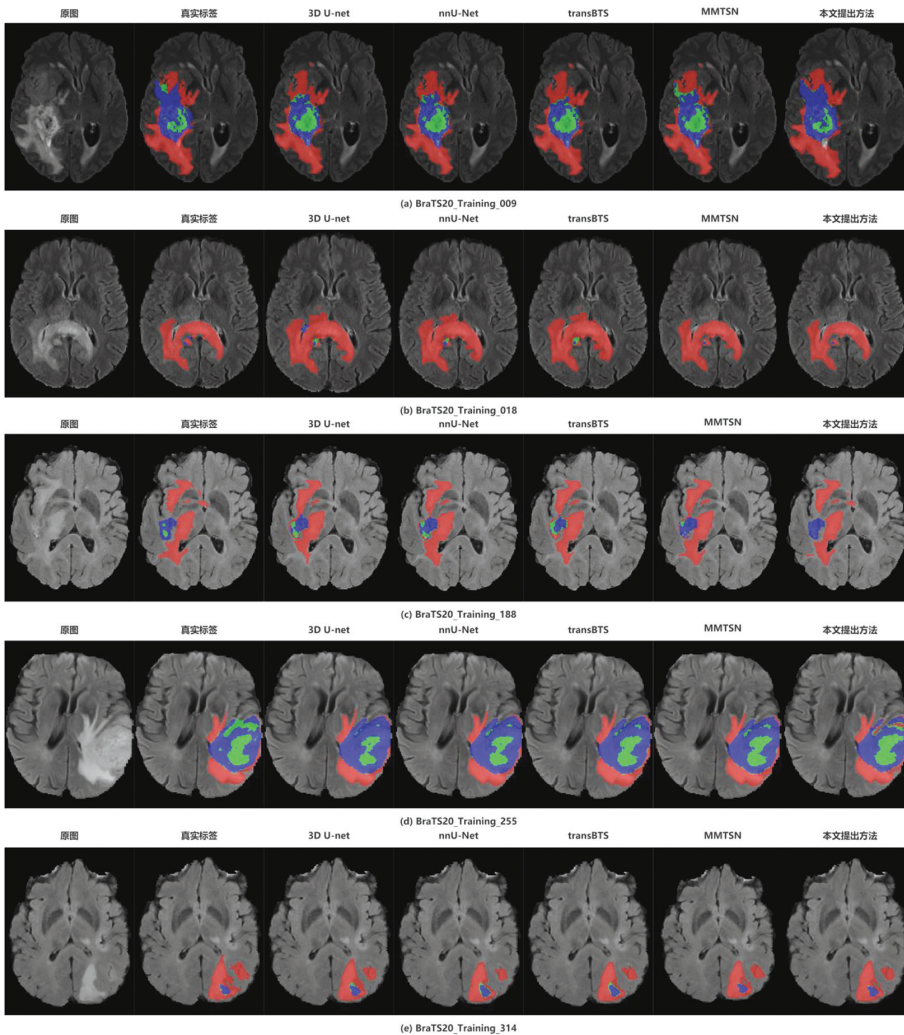


图 5 分割结果可视化

Fig. 5 Segmentation result visualization

3 结束语

本文将 U-Net 结构与 3 种注意力模块相结合,提出了一种新的多模态脑肿瘤分割模型。其中,包含了注意门控传播模块 (AGPM) 和多头特征增强模块 (MHFEM) 的设计与应用。本文通过 AGPM 优化 MRI 的多模态融合,在上采样期间使用 MHFEM 补充详细信息,并使用 MHSA 学习全局语义相关性。同时,提出了一种基于广义 DiceLoss (GDL) 和二元交叉熵 (BCE) 的混合损失函数来处理类不平衡问题,从而在评价平台上获得更好的评价指标。在未来的工作中,将重点简化注意力模块,开发高效、高精度的三维 MRI 脑肿瘤分割模型。

参考文献

- [1] 方玲玲,王欣. MRI 脑肿瘤图像的超像素/体素分割及发展现状[J]. 中国图象图形学报, 2022, 27(10): 2897-2915.
- [2] 方新林,方艳红,王迪. 基于多模态特征融合的脑瘤图像分割方法[J]. 中国医学物理学杂志, 2022, 39(6): 682-689.
- [3] 张志强,石磊,程晓东. 脑肿瘤分割算法研究[J]. 中国生物医学工程学报, 2022, 41(3): 290-300.
- [4] ZHANG W, LI R, DENG H, et al. Deep convolutional neural networks for multi-modality isointense infant brain image segmentation[J]. NeuroImage, 2015, 108: 214-224.
- [5] LONG J, SELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2015: 3431-3440.
- [6] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[C]//Proceedings of Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015; 18th International Conference, Munich, Germany: Springer International Publishing, 2015: 234-241.
- [7] DONG H, YANG G, LIU F, et al. Automatic brain tumor detection and segmentation using U-Net based fully convolutional networks [C]//Medical Image Understanding and Analysis: 21st Annual Conference, MIUA 2017. Edinburgh, UK: Springer International Publishing, 2017: 506-517.
- [8] JADERBERG M, SIMONYAN K, ZISSERMAN A, et al. Spatial transformer networks [C]//Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 2. 2015: 2017-2025.
- [9] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7132-7141.
- [10] WOO S, PARK J, LEE J Y, et al. Cbam: Convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). 2018: 3-19.
- [11] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. 2018: 7794-7803.
- [12] SRINIVAS A, LIN T Y, PARMAR N, et al. Bottleneck transformers for visual recognition [C]// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 2021: 16519-16529.
- [13] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: Learning where to look for the pancreas[J]. arXiv preprint arXiv:1804.03999, 2018.
- [14] CHEN H, QI Y, YIN Y, et al. MMFNet: A multi-modality MRI fusion network for segmentation of nasopharyngeal carcinoma[J]. Neurocomputing, 2020, 394: 27-40.
- [15] CHEN T, MA X, YING X, et al. Multi-modal fusion learning for cervical dysplasia diagnosis [C]//Proceedings of 2019 IEEE 16th International Symposium on Biomedical Imaging (ISBI 2019). IEEE, 2019: 1505-1509.
- [16] SUDRE C H, LI W, VERCAUTEREN T, et al. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Third International Workshop, DLMIA 2017, and 7th International Workshop, ML-CDS 2017, Held in Conjunction with MICCAI 2017, Québec City, QC, Canada: Springer International Publishing, 2017: 240-248.
- [17] BELLO I, ZOPH B, VASWANI A, et al. Attention augmented convolutional networks [C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2019: 3286-3295.
- [18] ZHANG J, ZENG J, QIN P, et al. Brain tumor segmentation of multi-modality MR images via triple intersecting U-Nets [J]. Neurocomputing, 2021, 421: 195-209.
- [19] LIU C, DING W, LI L, et al. Brain tumor segmentation network using attention-based fusion and spatial relationship constraint [C]//International MICCAI Brainlesion Workshop. Cham: Springer International Publishing, 2020: 219-229.
- [20] CIRILLO M D, ABRAMIAN D, EKLUND A. Vox2Vox: 3D-GAN for brain tumour segmentation [C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop, BrainLes 2020, Held in Conjunction with MICCAI 2020. Lima, Peru: Springer International Publishing, 2021: 274-284.
- [21] MILLETARI F, NAVAB N, AHMADI S A. V-net: Fully convolutional neural networks for volumetric medical image segmentation [C]//Proceedings of 2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016: 565-571.
- [22] WANG W, CHEN C, DING M, et al. Transbts: Multimodal brain tumor segmentation using transformer [C]//Medical Image Computing and Computer Assisted Intervention - MICCAI 2021; 24th International Conference. Strasbourg, France: Springer International Publishing, 2021: 109-119.