

## 基于多尺度细节增强的脑瘤图像分割研究

刘遵雄, 陈子涵, 蔡体健, 陈均, 罗词勇  
华东交通大学信息工程学院, 江西 南昌 330013

**【摘要】**针对脑瘤图像分割网络的跳跃连接引起的语义特征传递不平衡,以及多尺度特征关联不足,导致细节特征丢失,从而造成对细小目标肿瘤的分割精度不佳的问题,提出一种改进的Res-UNet框架的分割模型。该模型引入多尺度注意力融合模块,通过混合多尺度特征使模型更好地适应不同尺寸的肿瘤;该模型在跳跃连接中引入空间注意力模块,增强特征表达同时避免无用信息的干扰,保留特征图空间细节特征;最后通过辅助分类器模块,在解码器部分对不同尺度特征图进行特征预测。使用BraTS2020数据集进行实验和评估,使用Dice系数来评估模型分割效果。结果显示,改进的网络在全肿瘤区域、肿瘤核心区域和增强肿瘤区域的Dice系数分别为0.8877、0.8229、0.8027,相比于通道注意力模型增强肿瘤区域和肿瘤核心区域的系数分别提升2.6%和0.14%,证明改进模型在脑瘤核磁共振图像分割的有效性和精确性。

**【关键词】**脑肿瘤;图像分割;注意力机制;辅助分类器

**【中图分类号】**R318;TP391

**【文献标志码】**A

**【文章编号】**1005-202X(2024)07-0828-08

### Brain tumor image segmentation based on multi-scale detail enhancement

LIU Zunxiong, CHEN Zihan, CAI Tijian, CHEN Jun, LUO Ciyong

School of Information Engineering, East China Jiaotong University, Nanchang 330013, China

**Abstract:** Given that the imbalance of semantic feature transfer caused by the skip connection of the brain tumor image segmentation network and the insufficient correlation of multi-scale features lead to the loss of details, resulting in poor segmentation accuracy for small tumors, an improved segmentation model of the Res-UNet framework is proposed. The model introduces a multi-scale attention fusion module which makes the model better adaptable to tumors of different sizes by mixing multi-scale features, and adds a spatial attention module to the skip connection to enhance feature expression while avoiding the interference of useless information, preserving the spatial details of feature maps. Through the auxiliary classifier module, the decoder performs feature prediction on feature maps of different scales. The BraTS2020 dataset is used for experiments and evaluations, and the model segmentation performance is evaluated with Dice score. The results show that the improved network achieved average Dice scores of 0.887 7, 0.822 9, and 0.802 7 for whole tumor, tumor core, and enhancing tumor, respectively. Compared with the channel attention model, the improved model increases the scores of enhancing tumor and tumor core by 2.6% and 0.14%, respectively, which proves its effectiveness and accuracy for brain tumor MR image segmentation.

**Keywords:** brain tumor; image segmentation; attention mechanism; auxiliary classifier

### 前言

胶质母细胞瘤是颅内神经胶质细胞产生突变导致的原发性神经系统肿瘤,一般分为高级胶质瘤和

低级胶质瘤<sup>[1-2]</sup>。脑瘤只有尽早诊断和治疗,才能有效地控制肿瘤扩散,延长患者存活时间<sup>[3]</sup>。人工手动划分肿瘤区域依赖于诊察人员的专业经验,并且费时费力、易受到主观不确定性的影响,导致手动标注的脑瘤分割训练样本数量有限<sup>[4]</sup>。因此,自动、快速、精准的脑瘤分割为脑瘤患者后续治疗和诊断提供有力的技术支持<sup>[5]</sup>。核磁共振成像(MRI)可以根据肿瘤病变的复杂性和异质性,生成多模态MRI图像,可以提供更为准确的肿瘤信息,是目前广泛应用的脑瘤分析和诊察的数据依据<sup>[6-7]</sup>。然而不同图像模式下对比度和像素值不一致,且脑瘤位置、尺寸大小和形

**【收稿日期】**2024-01-29

**【基金项目】**国家自然科学基金(62166018);江西省重点研发计划(20203BBE53029);江西省自然科学基金(20232BAB202055)

**【作者简介】**刘遵雄,博士,教授,研究方向:深度学习、计算机视觉、图像处理、金融数据分析,E-mail: darrent.liuzx@gmail.com

状的不确定性,使得脑瘤自动分割成为一项富有挑战性的任务<sup>[8]</sup>。

随着深度学习技术的发展,医学图像分割技术成为研究热点。Ronneberger等<sup>[9]</sup>在MICCAI会议上提出U-Net网络模型,该模型的编码器和解码器结构可以对分割目标位置进行详细的刻画,可有效应对图像分割中目标位置和物体尺寸大小变化问题,比较适用于医学图像的分割。Res-Unet将编码路径的卷积层替换为残差网络模块,解决了普通卷积网络模型随深度增大不易训练的问题。有关研究人员在Res-Net结构基础上做出改进,提出适用于医学图像的模式。夏峰等<sup>[10]</sup>提出CSPU-Net脑瘤分割网络,在上下采样过程中分别加入两种跨阶段局部网络模块。Colman等<sup>[11]</sup>在网络结构中加入瓶颈形状的残差模块,通过编码器部分重复残差模块设计出104层的类U-Net网络模型。Zhou等<sup>[12]</sup>采用三维密集连接架构为主干,设计三维分层特征金字塔模块融合多尺度上下文同时提高感受野。然而,在Res-Unet的深层结构中,跳跃连接结构直接将编码器提取到的低级特征传递到解码器层融合,忽略编码器中多尺度特征的互补信息对当前尺度特征的指导作用,容易造成语义特征差距引起细节特征丢失,影响模型对细小目标肿瘤的分割精度。

注意力机制能够强化语义细节特征,提升医学图像的分割性能,广泛用于机器视觉的图像分类、分割、目标检测等领域<sup>[13-15]</sup>。Attention-Unet是在U-Net构架中引入注意力机制,提高特征提取能力而构建的分割网络<sup>[16]</sup>。Chen等<sup>[17]</sup>通过将低级特征、隐式形状信息和高级上下文结合在一起,提出VoxResNet的自动上下文版本脑瘤分割网络。Lee等<sup>[18]</sup>提出一种基于补丁的U-Net架构,该模型能保留更多局部信

息,提高肿瘤分割精度。罗恺锴等<sup>[19]</sup>在脑瘤MRI图像分割研究中,提出注意力机制和多视角融合U-Net算法,用多尺度特征融合模块代替传统的卷积层,进行多尺度特征图的提取与融合。Noori等<sup>[20]</sup>设计一种基于二维U-Net的低参数网络,采用通道注意力机制自适应地给每个通道赋予不同权值来防止模型的冗余。但是解码器简单的使用上采样和卷积层逐层恢复特征图,忽略解码器部分各层的多尺度特征图对分割预测的辅助作用,在深层传递中可能会丢失纹理和轮廓的低级特征。

针对当前网络模型语义细节特征差距和多尺度特征联系不足的问题,提出一种改进的多尺度细节增强网络,本文主要有以下几点改进:引入多尺度注意力融合模块在多尺度方面增强编码器低级语义特征间关联性,更好地适应不同尺寸的肿瘤;瓶颈残差模块减少信息的冗余,更大程度感知细节特征;设计空间注意力模块,提高显著目标的同时避免无用信息的干扰,保留特征图的长距离依赖关系和空间细节特征;解码器部分添加辅助分类器模块,对不同尺度特征图进行密集预测,提高解码器特征判别性。

## 1 方法

### 1.1 网络结构

本文提出一种改进的Attention-Unet网络,网络结构如图1所示。编码路径在多尺度瓶颈残差层提取低级语义特征,解码器路径恢复分辨率实现图像语义分割,使用跳跃连接在编码器和解码器之间保留特征语义信息,设计多尺度注意力混合(MAFM)模块,保留不同尺度的细节特征,通过拼接块将提取的低级语义特征和高级语义特征进行整合。

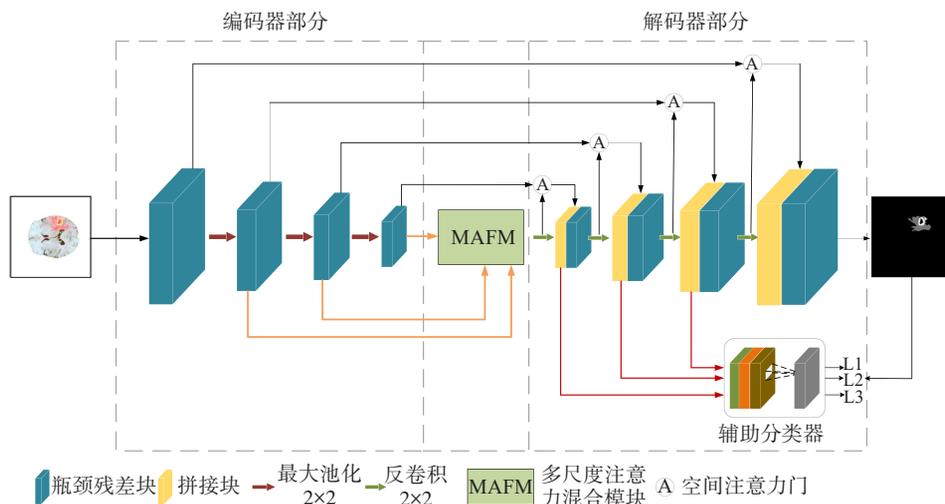


图1 基于多尺度细节增强的改进模型结构

Figure 1 Structure of the improved model based on multi-scale detail enhancement

编码器路径有4层网络结构,每一层都包含瓶颈残差块,瓶颈残差块结构见图2,采用一种形似瓶颈形状设计,其层叠顺序为1×1卷积层、3×3卷积层,然后是1×1卷积层。瓶颈残差模块一方面增加网络深度,使提取低级语义特征更加充分,残差结构能保留细节特征的同时减少信息冗余;另一方面瓶颈设计减少网络的参数数量以及特征通道数,训练参数数量减少能够提高模块训练效率。每个卷积操作后面都

嵌入有批量归一化(BN)和ReLU函数激活运算。解码器路径由4层瓶颈残差块组成。每个解码器层使用跳跃连接和注意门与相应的编码器层连接。上采样使用2×2的反卷积,上采样将特征图通道数减半,特征图尺度增加一倍。最终输出特征图被上采样到240×240大小,并通过分类层和Softmax激活函数得到最终预测输出,Softmax激活函数将特征映射转换成像素级别预测,最终与真实值进行比较计算损失。

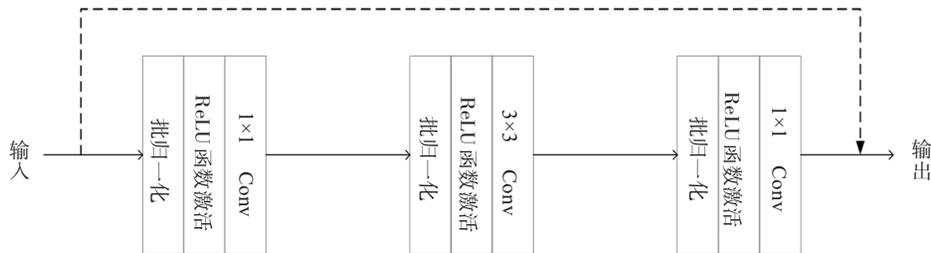


图2 瓶颈残差块结构

Figure 2 Bottleneck residual block structure

### 1.2 空间注意力模块

空间注意力模块学习相关特征区域的空间注意力系数来抑制不相关区域低级特征的提取,突出相关显著特征。注意力模块如图3所示,在将编码器特征图与注意力系数进行像素级相乘,得到经注意力聚焦的特征图。注意力门可以抑制图像中不相关区域特征的激活,注意力模块的输入分别是对应层的编码器输出和下方解码器层输出的门信号,输入的

特征图包含对应层中上下文信息以及空间信息。通过步长分别为1和2的卷积将两种输入调整一致大小后进行像素相加,经过激活函数、卷积、线性插值等处理后与原输入信号像素相乘,得到输出注意力信号。在跳跃连接中添加空间注意力模块,提取编码器特征图的全局特征,缩短不同层间语义特征差距,保留特征图空间细节特征,增强特征表达能力,能更准确定位肿瘤区域。

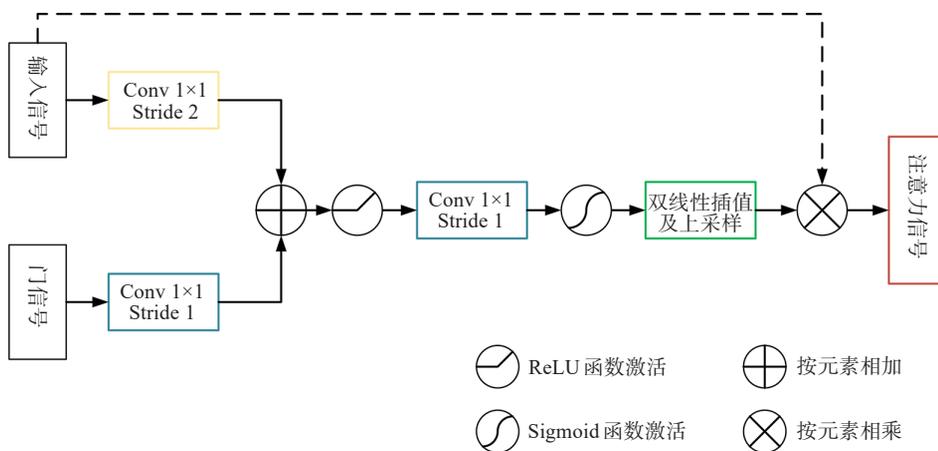


图3 空间注意力门结构

Figure 3 Spatial attention gate structure

### 1.3 多尺度注意力混合模块

不同层的感受野有大小差异,能够感知不同尺度的特征细节更好地获得全局特征信息。使用一种

多尺度注意力融合模块,也称为MAFM模块,通过对多尺度特征下采样后进行拼接,运用注意力模块来提取和融合不同尺度特征图的特征信息。如图4所

示,不同层大小不一的特征图通过注意力模块进行特征提取并细化,然后拼接细化。通过捕获不同尺度的图像特征,混合多尺度的信息从而感知更广泛的上下文细节信息,增强多尺度全局特征,更好地适应不同尺寸的肿瘤。多尺度注意力混合模块计算过程用式(1)表示:

$$F'_i = F_i \odot (\sigma(C_i([A(F_i), M(F_i)]))) \quad (1)$$

$$i \in \{ \text{low, mid, high} \}$$

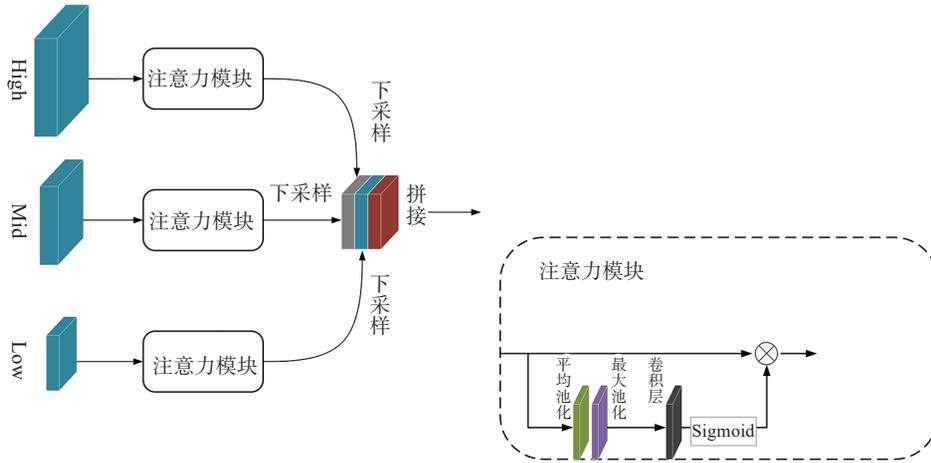


图4 多尺度注意力融合模块

Figure 4 Multi-scale attention fusion module

### 1.4 辅助分类器

每层解码器层的输出传递到辅助分类器中,各层通过辅助分类器与真值计算损失来实现深度监督操作。深度监督也称为中继监督,做法是在中间层使用辅助分类器作为网络分支来对网络进行监督,添加额外的损失函数,将更多的损失整合到学习过程的目标函数中来更新权重。深度监督是使用辅助分类器作为网络分支来对网络进行监督,添加额外的损失函数,辅助分类器模块结构见图5。输入特征图分别进行数次上采样到240×240大小,最终通过卷积操作将特征映射的通道数量减少到4个通道,再使用激活函数将特征图转换为概率预测。因此,辅助分类器中输出的每个通道都成为特定类的概率映射,然后将这些输出与真值进行损失计算。引入深度监督机制能够避免多尺度特征信息丢失,保留解码器层多尺度预报结果,从解码器多层感知多尺度的特征信息以提高网络分割精度。此外,深度监督还可缓解梯度消失问题。在解码器模块后添加辅助分类器模块,通过多尺度密集预报方式挖掘不同层级细节上下文信息细节。

### 1.5 损失函数

模型的性能不仅取决于网络结构,还依赖于损失

其中,⊙是哈达玛积, $F_i$ 和 $F'_i$ 是第*i*层输入特征图和经过注意力模块后的特征图,*i*层由高到低分别代表对应high、mid、low层编码器路径。 $A$ 和 $M$ 表示平均池化和最大池化层操作, $\sigma$ 指的是Sigmoid激活函数, $C_i$ 表示卷积层,卷积层 $C_{\text{high}}$ 、 $C_{\text{mid}}$ 、 $C_{\text{low}}$ 分别使用3×3、5×5、7×7卷积核进行多尺度卷积操作。然后将注意力加权后的特征图下采样到相同尺度大小,最后输出各层特征图的拼接融合结果。

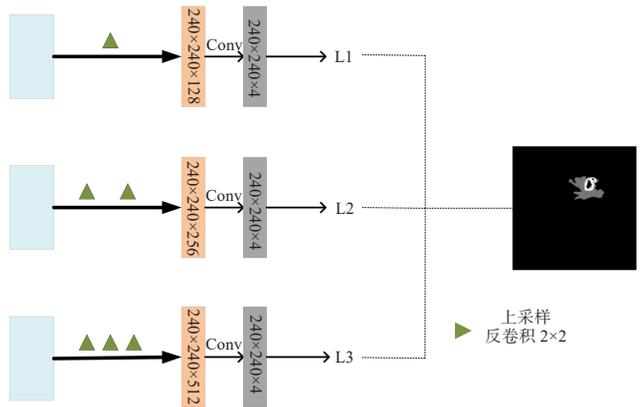


图5 辅助分类器模块结构

Figure 5 Auxiliary classifier structure

函数的选择。在图像分割任务中,常用的损失函数是交叉熵损失函数,交叉熵损失可以让网络准确分割区域,使模型倾向于学习标签数量较多的样本,提升分割精度<sup>[21]</sup>。但是在脑瘤分割任务中,绝大多数标签是背景标签,存在类别不平衡问题,会导致分割性能不佳<sup>[22]</sup>。广义骰子损失(GDL)是适合医学图像分割领域使用的损失函数,能够有效缩小真值和模型预测值之间的差距,且受类别不平衡问题的影响较小,能

使骰子系数(Dice系数)更快接近1,Dice系数越接近1表明预测分割与真值相似度越高。本文使用一种将GDL与交叉熵损失组合的损失计算方法,将两种损失相结合以解决类别不平衡的问题,加快收敛速度。组合损失函数计算见式(2),本文将λ设置为1.25。P是模型对n类的预测输出,G是n类的真值:

$$L = L_{GDL}(G, P) + \lambda L_{CE}(G, P) \tag{2}$$

$L_{GDL}$ 是GDL函数,公式为:

$$L_{GDL} = 1 - \frac{2 \sum Y_{true} \times Y_{pred}}{\sum Y_{true} + \sum Y_{pred}} \tag{3}$$

交叉熵损失见式(4):

$$L_{CE} = -\frac{1}{N} \sum_n \sum_c Y_{true}^n \times \log(Y_{pred}^n) \tag{4}$$

其中, $Y_{true}$ 是真值标签, $Y_{pred}$ 是网络模型的最终预测值。

辅助分类器对每层解码器进行预测,将各个中间层的加权损失传递到最终的损失计算中,可以提高模型分割精度。最终损失函数计算如式(5)所示:

$$L_{All} = \alpha L_{output} + \beta L_1 + \varepsilon L_2 + \gamma L_3 \tag{5}$$

其中, $L_{output}$ 是最终输出预测的组合损失, $L_1$ 、 $L_2$ 和 $L_3$ 是辅助分类器各层计算的组合损失。 $\alpha$ 、 $\beta$ 、 $\varepsilon$ 和 $\gamma$ 分别对应各损失权重,由于最后的输出层是模型的预测结果,因此赋予 $L_{output}$ 更大的权重。经实验,权重值大小设置为: $\alpha=0.5$ , $\beta=\varepsilon=\gamma=0.125$ 。

## 2 实验

### 2.1 数据集

多模态脑瘤分割(BraTS)是公认的一项国际医学图像分割挑战<sup>[23]</sup>,实验数据使用BraTS2020数据集,是国际医学图像计算和计算机辅助干预协会(MICCAI)提供的公共数据集。脑瘤数据包含低级别胶质瘤和高级别胶质瘤两种类别,将数据集的369例患者的训练数据作为训练集和验证集,125例患者的验证数据作为测试集。每例患者图像数据包含有4种MRI图像,分别为T<sub>1</sub>、T<sub>1</sub>ce、T<sub>2</sub>、Flair的MRI图像。患者的MRI图像数据的大小是244×244×155,且图像都对齐到同一公共空间,并进行头骨剥离操作。训练集包含由专家手动注释标签的肿瘤分割掩码,注释的标签有4种,分别是增强肿瘤(ET)、水肿(ED)、坏死(NET)以及背景。分割任务目标是对全肿瘤(WT)、肿瘤核心(TC)、ET子区域进行准确分割,WT区域包括ET、ED和NET标签,TC区域包括ET和NET标签,ET区域包括ET标签。

### 2.2 数据预处理和数据增强

对BraTS2020数据集进行图像处理,首先将各个样本的三维MRI图像进行切片操作,一个样本有155

个切片。MRI图像切片在训练之前,使用数据标准化对其进行预处理。使用式(6)进行标准化:

$$v = \begin{cases} 254, & v > \text{mean} + 3 \times \text{SD} \\ \frac{(v - \text{mean}) + 127}{3 \times \text{SD}/128}, & \text{otherwise} \\ 0, & v < \text{mean} - 3 \times \text{SD} \end{cases} \tag{6}$$

其中,mean表示平均值,SD表示标准差。将每一个切片保存为单个PNG图像,预处理后数据的输入大小为244×244×4,244×244是每个图像的大小,4表示序列模态数量,一个通道代表一个MRI模态序列。应用的图像增强方法是随机对图像进行左右或者上下翻转,翻转的概率为50%,这样能有效防止模型过拟合和增加图像数量,提高模型泛化能力。

### 2.3 评价指标

为了评价模型的性能和分割效果,本文对ET、WT和TC区域使用Dice系数和豪斯多夫距离度量(HD95)系数进行评价。Dice系数是反映两个集合相似度的指标<sup>[24]</sup>,值越大说明肿瘤分割的精度越高,且Dice ∈ (0, 1),其计算公式见式(7),式中A和B分别表示预测值和真值:

$$\text{Dice} = \frac{2(|A \cap B|)}{|A| + |B|} \tag{7}$$

HD95是两个子集之间的距离,能体现两个点集之间的相似度,表示预测分割与标签真值两个点集之间最短距离的最大值<sup>[25]</sup>。本文使用HD95作为评估指标,主要是为了减小离群点对结果的影响,由式(8)计算:

$$H(A, B) = \max[h(A, B), h(B, A)] \tag{8}$$

其中, $h(A, B) = \max_{a \in A} \min_{b \in B} \|a - b\|$ , $h(B, A) = \max_{b \in B} \min_{a \in A} \|b - a\|$ 。

### 2.4 参数设置

在模型进行训练过程中,本文提出的模型批量大小设置为10,Epoch大小是50,一个Epoch的训练迭代次数是3100次,使用学习率为0.0001的Adam优化器。在本文模型每一层使用批量标准化来提高模型的稳定性,采用L2正则化来进行正则化,在每个卷积操作后添加正则化项防止过拟合,L2正则化参数是0.000001。本文架构在Keras中实现,且带有tensorflow后端。实验中使用的是具有16GB内存的Tesla P100图形卡执行,CUDA 11.4架构平台。

## 3 结果

本文使用包含125例患者的验证数据集对提出的模型架构进行评估,且使用训练数据相同的方式进行数据预处理。后将二维的预测分割结果掩码组合为三维的nii图像,最后将结果上传到IPP

在线评估网站,该网站对上传的病变分割结果进行计算评估,得到Dice系数、HD95、灵敏性、特异性结果。Dice和HD95应用于评估ET、WT、TC3种分割区域的模型性能。图6对比了模型训练过程中提出模型与U-Net网络模型中Dice系数随Epoch增加的变化曲线,可以看出本文提出的模型提高图像分割的精度,检测出更细微的肿瘤细节,收敛速度更快。图7和图8分别为分割结果的Dice系数盒图和HD95系数盒图,模型预测分割结果如图9所示。

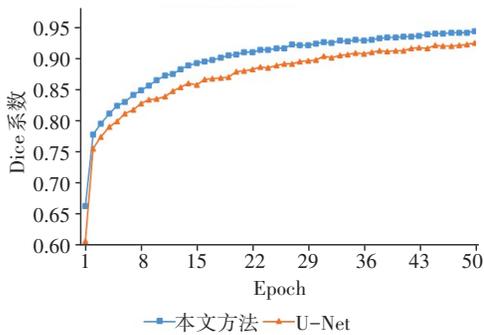


图6 训练过程中不同模型Dice系数变化对比图

Figure 6 Comparison of Dice score changes of different models during training

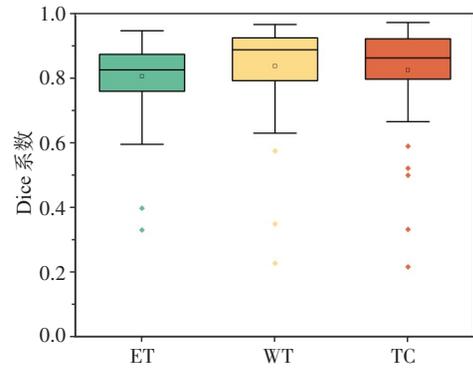


图7 Dice系数盒图

Figure 7 Box plots of Dice score

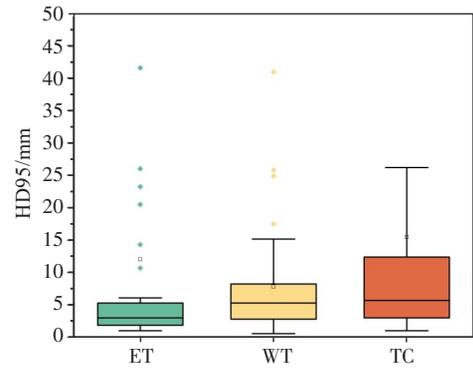


图8 HD95系数盒图

Figure 8 Box plots of HD95

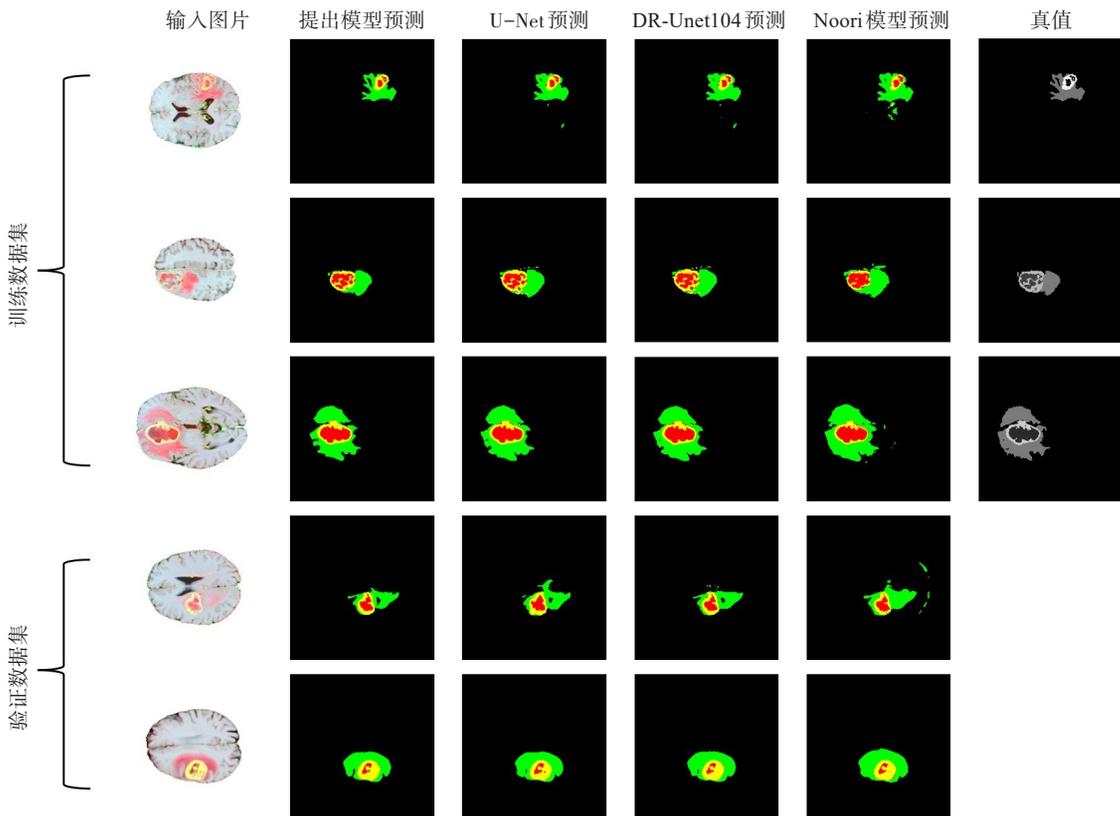


图9 提出的模型对训练数据集和验证数据集的视觉分割结果

Figure 9 Visual segmentation results of the proposed model on the BraTS 2020 training and validation datasets

### 3.1 消融实验

通过消融实验测试本文提出模型中各个模块性能,本文以经典U-Net网络为基础,依次添加注意力模块和辅助分类器模块来检验各个模块的效果,验证提出方法中模块的有效性和必要性。结果如表1所示,Attn表示添加多尺度注意力混合模块和空间注意力模块,deep supervised是辅助分类器模块。辅助分类器模块增强多尺度全局特征,一定程度提高WT区域的Dice系数得分。而多尺度注意力混合模块和空间注意力模块提高分割难度更大的ET区域和TC区域的关注,提高细节特征的提取能力,优化该区域的Dice系数。随着将注意力模型、深度监督模块添加到U-Net网络模型中,分割结果得到改进,在ET、WT、TC区域的Dice系数分别提高0.0867、0.0740、0.1294。本文提出的模型能实现对WT、TC、ET区域获得更满意的分割结果,表明提出模型的各个模块对分割结果有一定提高。

表1 模型结构使用不同模块的Dice系数结果

Table 1 Dice scores achieved by models using different modules

模块	ET	WT	TC
U-Net	0.7160	0.8137	0.6935
U-Net+deep	0.7540	0.8513	0.7326
U-Net+Attn	0.7819	0.8228	0.7929
U-Net+Attn+deep	0.8027	0.8877	0.8229

### 3.2 对比实验

在验证集上,本文将提出的网络结构与目前有关脑瘤医学图像语义分割模型进行比较。从表2可以看出,WT区域的分割精度要高于ET和TC区域,原因是病变肿瘤区域结构复杂,ET标签和NET标签难以识别。本文提出的模型在各种指标中达到较好的性能,DR-Unet104模型<sup>[13]</sup>引入瓶颈残差块,但本文提出模型的ET和TC区域的Dice系数要高于DR-Unet104模型,原因是本文模型的空间注意力机制可以对形状更细小、结构更复杂的肿瘤区域识别更加敏感,所提出的模型生成的预测分割图像与真值更接近。Noori等<sup>[20]</sup>使用的通道注意力模块,在特征图通道维度上提高模型性能。对比Noori等<sup>[20]</sup>方法的评估结果,本文WT区域的Dice系数较低,原因是通道注意力更注重通道维度中全局特征的挖掘,能更有效分割WT区域。

最后,深入研究融合损失函数的参数设置对模型分割精度的影响,并进行对比实验。对比结果如

表3所示,经过对比实验,证明权重值大小设置为: $\alpha=0.5$ 和 $\beta = \epsilon = \gamma = 0.125$ ,使得模型的整体效率达到最佳效果。

表2 不同模型的Dice系数评估结果  
Table 2 Dice scores achieved by different models

方法	ET	WT	TC
FCN <sup>[8]</sup>	0.6812	0.8338	0.7475
DR-Unet104 <sup>[11]</sup>	0.6756	0.8862	0.6721
Zhou等 <sup>[12]</sup>	0.7530	0.8652	0.7730
Noori等 <sup>[20]</sup>	0.7762	0.8880	0.8215
本文方法	0.8027	0.8877	0.8229

表3 使用不同的 $\alpha$ 、 $\beta$ 、 $\gamma$ 和 $\epsilon$ 实验的Dice系数结果  
Table 3 Dice scores obtained using different  $\alpha$ ,  $\beta$ ,  $\gamma$  and  $\epsilon$

$\beta = \epsilon = \gamma$	$\alpha$	ET	WT	TC
0	1.0	0.7819	0.8228	0.7929
0.125	0.5	0.8027	0.8877	0.8229
0.200	0.4	0.7716	0.8860	0.8375

## 4 结语

针对脑瘤MRI图像自动分割问题,基于多尺度细节增强提出了U-Net改进模型。模型引入空间注意力机制,突出显著目标特征,避免信息冗余;添加多尺度注意力融合模块,整合各层特征信息;使用深度监督模块,较大程度保留解码器层预测。实验结果表明,本文提出的方法能提高特征提取能力,能有效分割脑瘤MRI图像,具有鲁棒性和高效性。虽然本研究模型取得精准的分割效果,但是添加注意力模块和辅助分类器加深网络层数,一定程度增加了模型参数,在模型轻量化方面需要继续改进。后续将尝试探索网络结构轻量化,改进模型网络结构以及损失函数算法,减小模型参数量,同时保存分割性能。

## 【参考文献】

- [1] McFaline-Figueroa JR, Lee EQ. Brain tumors[J]. Am J Med, 2018, 131(8): 874-882.
- [2] Pereira S, Pinto A, Alves V, et al. Brain tumor segmentation using convolutional neural networks in MRI images[J]. IEEE Trans Med Imaging, 2016, 35(5): 1240-1251.
- [3] Kickingereder P, Isensee F, Tursunova I, et al. Automated quantitative tumour response assessment of MRI in neuro-oncology with artificial neural networks: a multicentre, retrospective study[J]. Lancet Oncol, 2019, 20(5): 728-740.
- [4] Latif U, Shahid AR, Raza B, et al. An end-to-end brain tumor

- segmentation system using multi-inception-UNET[J]. *Int J Imaging Syst Technol*, 2021, 31(4): 1803-1816.
- [5] Zeineldin RA, Karar ME, Coburger J, et al. DeepSeg: deep neural network framework for automatic brain tumor segmentation using magnetic resonance FLAIR images[J]. *Int J Comput Assist Radiol Surg*, 2020, 15(6): 909-920.
- [6] 赖小波, 许茂盛, 徐小媚. 多模态MR图像和多特征融合的胶质母细胞瘤自动分割[J]. *计算机辅助设计与图形学学报*, 2019, 31(3): 421-430.
- Lai XB, Xu MS, Xu XM. Automatic segmentation for glioblastoma multiforme using multimodal MR images and multiple features[J]. *Journal of Computer-Aided Design & Computer Graphics*, 2019, 31(3): 421-430.
- [7] Weizman L, Eldar YC, Ben Bashat D. Reference-based MRI[J]. *Med Phys*, 2016, 43(10): 5357.
- [8] Li HC, Li A, Wang MH. A novel end-to-end brain tumor segmentation method using improved fully convolutional networks[J]. *Comput Biol Med*, 2019, 108: 150-160.
- [9] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[C]//*Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015*. Cham: Springer International Publishing, 2015: 234-241.
- [10] 夏峰, 邵海见, 邓星. 融合跨阶段深度学习的脑肿瘤MRI图像分割[J]. *中国图象图形学报*, 2022, 27(3): 873-884.
- Xia F, Shao HJ, Deng X. Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation[J]. *Journal of Image and Graphics*, 2022, 27(3): 873-884.
- [11] Colman J, Zhang L, Duan WT, et al. DR-Unet104 for multimodal MRI brain tumor segmentation [C]//*Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer International Publishing, 2021: 410-419.
- [12] Zhou ZX, He ZS, Shi MF, et al. 3D dense connectivity network with atrous convolutional feature pyramid for brain tumor segmentation in magnetic resonance imaging of human heads[J]. *Comput Biol Med*, 2020, 121: 103766.
- [13] 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.
- [14] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[C]//*Proceedings of the 31st International Conference on Neural Information Processing Systems*. Red Hook, NY, USA: Curran Associates Inc., 2017: 6000-6010.
- [15] Xu JH, Teng WP, Wang XJ, et al. A deep supervised U-attention net for pixel-wise brain tumor segmentation [C]//*Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer International Publishing, 2021: 278-289.
- [16] Khanh TL, Dao DP, Ho NH, et al. Enhancing U-net with spatial-channel attention gate for abnormal tissue segmentation in medical imaging[J]. *Appl Sci*, 2020, 10(17): 5729.
- [17] Chen H, Dou Q, Yu LQ, et al. VoxResNet: deep voxelwise residual networks for brain segmentation from 3D MR images [J]. *Neuroimage*, 2018, 170: 446-455.
- [18] Lee B, Yamanakkanavar N, Choi JY. Automatic segmentation of brain MRI using a novel patch-wise U-net deep architecture[J]. *PLoS One*, 2020, 15(8): e0236493.
- [19] 罗恺锴, 王婷, 叶芳芳. 引入注意力机制和多视角融合的脑肿瘤MR图像U-Net分割模型[J]. *中国图象图形学报*, 2021, 26(9): 2208-2218.
- Luo KK, Wang T, Ye FF. U-net segmentation model of brain tumor MR image based on attention mechanism and multi-view fusion [J]. *Journal of Image and Graphics*, 2021, 26(9): 2208-2218.
- [20] Noori M, Bahri A, Mohammadi K. Attention-guided version of 2D UNet for automatic brain tumor segmentation [C]//*2019 9th International Conference on Computer and Knowledge Engineering (ICCKE)*. Piscataway, NJ, USA: IEEE, 2019: 269-275.
- [21] Ho Y, Wookey S. The real-world-weight cross-entropy loss function: modeling the costs of mislabeling[J]. *IEEE Access*, 2020, 8: 4806-4813.
- [22] Zhou XY, Li XY, Hu K, et al. ERV-net: an efficient 3D residual neural network for brain tumor segmentation [J]. *Expert Syst Appl*, 2021, 170: 114566.
- [23] Bakas S, Reyes M, Jakab A, et al. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge[EB/OL]. (2019-04-23). <https://arxiv.org/abs/1811.02629>.
- [24] Sudre CH, Li WQ, Vercauteren T, et al. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations[J]. *Deep Learn Med Image Anal Multimodal Learn Clin Decis Support*, 2017, 2017: 240-248.
- [25] van Kreveld M, Miltzow T, Ophelders T, et al. Between shapes, using the Hausdorff distance [J]. *Computational Geometry*, 2022, 100: 101817.

(编辑:陈丽霞)