

DOI:10.3969/j.issn.1005-202X.2024.01.006

医学影像物理

## LRAE-Unet:轻量级MRI脑肿瘤全自动分割网络

林嘉豪,王瑜,肖洪兵,孙梅

北京工商大学人工智能学院,北京 100048

**【摘要】**提出一种轻量级脑肿瘤全自动分割网络,即轻量级残差注意力增强网络(LRAE-Unet)。首先采用轻量级残差模块解决网络层数增加时出现的梯度消失和网络退化问题;其次采用轻量级自注意力模块抑制输入图像中的不相关区域,同时突出特定局部区域的显著特征;最后通过增强视野平均池化模块减少特征图的空间,节省计算资源,控制网络过拟合现象。在BraTS 2019数据集的测试结果显示LRAE-Unet在完整肿瘤、肿瘤核心与增强肿瘤区域的Dice相似系数为91.24%、88.64%与88.32%,证明使用LRAE-Unet进行脑瘤分割具有可行性与有效性。

**【关键词】**脑肿瘤;LRAE-Unet;轻量级残差模块;轻量级自注意力模块;平均池化模块

**【中图分类号】**R318;TP317.4

**【文献标志码】**A

**【文章编号】**1005-202X(2024)01-0043-07

## LRAE-Unet: a lightweight network for fully automatic segmentation of brain tumor from MRI

LIN Jiahao, WANG Yu, XIAO Hongbing, SUN Mei

School of Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China

**Abstract:** A lightweight residual attention enhanced Unet (LRAE-Unet) is designed for the fully automatic brain tumor segmentation. LRAE-Unet uses lightweight residual module to solve the problems of gradient disappearance and network degradation when the network layers increases, lightweight self-attention module to suppress the irrelevant areas and highlight the significant features of specific local areas, and enhanced average pooling module with a larger field of perception to reduce the space of feature map, save computing resources and avoid over-fitting. The experiment on BraTS 2019 dataset shows that the proposed method has a Dice similarity coefficient of 91.24%, 88.64% and 88.32% in the segmentations of the whole tumor, tumor core and enhanced tumor, which proves its feasibility and effectiveness for brain tumor segmentation.

**Keywords:** brain tumor; LRAE-Unet; lightweight residual module; lightweight self-attention module; average pooling module

### 前言

近年来,全球平均每年有880万人死于癌症,约占全球每年死亡总人数的16.7%<sup>[1]</sup>。磁共振成像(Magnetic Resonance Imaging, MRI)技术由于其高对比度、无侵害性、无骨像伪影等优势成为脑肿瘤诊断的首选方式。由专家从脑肿瘤MRI图像切片中手动勾画肿瘤区域的分割方式虽然准确,但效率低下,主

观误判率较高,影响患者后续的治疗<sup>[2]</sup>。传统的脑肿瘤分割方法主要有基于阈值的方法以及基于边缘轮廓的方法等。为提升脑肿瘤分割精度,万俊等<sup>[3]</sup>提出基于内容的主动轮廓模型,该模型使用主动轮廓内部的强度和纹理信息区分肿瘤与非肿瘤组织。基于机器学习的脑瘤分割方法主要是通过提取影像特征,利用分类器对提取的特征进行分类,从而实现脑肿瘤的分割。Lee等<sup>[4]</sup>提出一种虚假-条件随机场模型,并将其作为一种正则判别分类器,依据MRI图像中的体素及其相邻体素的特征进行分类。

近年来,作为机器学习的重要研究方向之一,深度学习以其良好的表现性能在人工智能领域中得到快速发展,也使得脑肿瘤分割的研究实现较大的突破<sup>[5]</sup>。2006年,Hinton等<sup>[6]</sup>率先提出区别于浅层学习的深度学习方法,在此基础上,AlexNet<sup>[7]</sup>、VGG<sup>[8]</sup>、

**【收稿日期】**2023-09-05

**【基金项目】**北京市自然科学基金-北京市教育委员会科技计划重点项目(KZ202110011015)

**【作者简介】**林嘉豪,硕士研究生,研究方向:图像处理与模式识别,E-mail: Radiant\_master@163.com

**【通信作者】**王瑜,博士,教授,研究方向:图像处理与模式识别,E-mail: wangyu@btbu.edu.cn

GoogLeNet<sup>[9]</sup>、ResNet<sup>[10]</sup>等网络结构相继提出,不断增强MRI图像分割的能力。此后,基于端到端的分割网络逐渐发展,并得到较广泛的应用,这种网络的输入是影像块或整幅影像,能对输入影像中的体素进行分类,最后输出与输入图像尺寸相同的分割结果图,一般具有编码-解码的结构。Long等<sup>[11]</sup>基于传统的卷积神经网络(Convolutional Neural Network, CNN),提出全卷积神经网络(Fully Convolutional Network, FCN),实现像素级的分类,同时引入跳跃连接改善经上采样得到较粗糙的像素定位。U-Net在FCN的基础上融合更多特征信息,相较FCN, U-Net在脑肿瘤分割中有着更高的分割精度<sup>[12]</sup>。

由于U-Net存在参数量较大、网络深度不够,且连续的卷积和池化层会造成全局空间信息损失等问题,不仅会导致网络模型占用内存较大,而且还降低图像边界的分割精度,影响普适性与扩展性。针对U-Net在医学图像分割中信息丢失、模型参数量大、多模态图像的病灶分割精度较低等问题,本研究在传统的U-Net基础上,增加轻量级残差模块、轻量级自注意力模块以及增强视野平均池化模块,提出一种轻量级残差注意力增强网络(Lightweight Residual Attention Enhanced Unet, LRAE-Unet)模型,不仅可以减少计算量,而且在脑肿瘤分割上能得到较高的精度。

LRAE-Unet通过加入轻量级残差模块可以构造深层网络,使网络的卷积层数达到90层,弥补U-Net网络不够深,对特征的表达不够准确的缺陷,并降低网络参数,实现网络模型的轻量化;通过加入轻量级自注意力模块,充分利用脑肿瘤MRI图像的空间信息和上下文信息,进一步提高模型的分割精度;最后设计增强视野平均池化模块,减少特征图的空间和模型中的参数量,节省计算资源,控制网络过拟合现象,相较传统平均池化具有更大的感受野,能获取更多语义信息。

1 LRAE-Unet全自动脑肿瘤分割模型

为增强网络对全局特征的获取能力,本研究提出一种LRAE-Unet模型,用于全自动脑肿瘤分割。主要改进如下:(1)在U-Net网络特征提取部分增加轻量级残差块,构建具有90个卷积层的轻量级残差网络LR-Unet,使原有U-Net网络模型拥有更深的网络结构,增强特征表达的准确度,同时减少参数量,使网络轻量化,提高计算效率。(2)在上述LR-Unet的上采样层连接部分引入轻量级自注意力模块,构建具有轻量级残差注意力机制的LRA-Unet网络,使深层网络能充分挖掘全局信息,增强重要特征获取,抑

制不必要特征的干扰,更准确地提取病灶边界的细节信息,同时减少网络参数量,使网络轻量化,提高网络的分割效果。(3)设计增强视野池化模块,不仅能扩大感受野,捕获更多特征信息,而且能避免训练过程中出现过拟合现象,尽可能准确地划分病灶区域边界。LRA-Unet网络引入增强视野平均池化模块,替换传统的平均池化方法,构建具有增强视野的轻量级残差注意力网络LRAE-Unet,网络架构如图1所示,该网络不仅可以提取图像中更丰富的特征信息,同时可以降低内存消耗,提高分割效率和精确率,更高效准确地完成脑肿瘤分割任务。

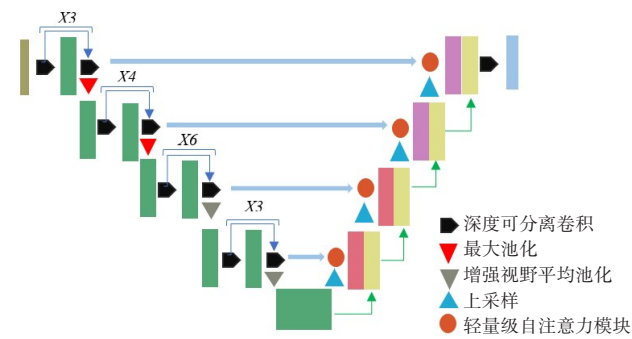


图1 LRAE-Unet网络结构图

Figure 1 LRAE-Unet structure

1.1 深度可分离卷积

深度可分离卷积<sup>[13-15]</sup>将标准卷积拆分为深度卷积和1×1逐点卷积,其过程如图2所示。其中,深度卷积使用单个滤波器映射到每个输入通道,逐点卷积通过1×1卷积的形式,将输入与深度卷积组合在一起。利用一次2D卷积运算,在一个步骤中既可以过滤输入,又可以将输入组合成新的输出。深度可分离卷积将卷积分解为两层,一层用于过滤,另一层用于组合;通过因式分解的方式降低模型计算量和模型大小。相对于标准2D卷积,深度卷积非常有效,然而它只过滤输入通道,并没有组合它们来融合特征信息,因此,通过加上逐点卷积计算深度卷积的输出。




图2 深度可分离卷积模块

Figure 2 Depth-separable convolution module

2D深度可分离卷积的计算量是深度卷积和 $1 \times 1$ 逐点卷积的计算量之和,即 $D_G^2 \times N \times M + D_K^2 \times M \times D_F^2$ ,其与2D标准卷积的计算量之比如式(1)所示:

$$\frac{D_G^2 \times N \times M + D_K^2 \times M \times D_F^2}{D_K^2 \times N \times M \times D_G^2} = \frac{D_F^2}{D_G^2 \times N} + \frac{1}{D_K^2} \quad (1)$$

其中, $D_F$ 表示输入特征图维度的大小, $M$ 表示输入通道的大小。输出的特征图为 $G = D_G^2 \times N$ ,其中 $D_G$ 表示输出特征图维度的大小, $N$ 表示输出通道的大小。卷积核为 $K = D_K^2$ , $D_K$ 表示卷积核的大小。从式(1)可以看出,相较2D标准卷积,2D深度可分离卷积极大减少卷积过程中产生的计算量。

### 1.2 轻量级残差模块

本研究将残差思想引入到经典的语义分割网络U-Net中,设计一个基于编码和解码的残差网络,一方面简化网络训练,避免因加深网络层数而造成梯度消失问题,另一方面在残差网络中使用融合连接<sup>[16]</sup>,容易得到更多的语义信息,同时低层次的细节特征能补偿较高层次的语义特征,达到优化分割的效果,既保留了U-Net网络的优秀能力,又加深了网络的深度。残差网络由多个残差单元构成,残差单元实现的一般形式如式(2)和式(3)所示:

$$y_z = h(x_z) + F(x_z, g_z) \quad (2)$$

$$x_{z+1} = \delta(y_z) \quad (3)$$

其中, $x_z, g_z$ 表示网络深度为 $z$ 时残差块的输入, $x_{z+1}$ 表示残差块的输出, $h(\cdot)$ 表示对当前输入信息的处理函数, $\delta$ 是一个激活函数, $F$ 是残差函数。

为降低3D MRI脑肿瘤分割模型计算成本<sup>[17]</sup>,实

现轻量级网络模型,本研究使用深度可分离卷积替换残差模块里的标准卷积,如图3所示,不仅降低网络参数,而且可以减少内存消耗,在不减少精确度的情况下实现网络轻量化。




图3 轻量级残差模块

Figure 3 Lightweight residual module

### 1.3 轻量级自注意力模块

本研究将注意力门<sup>[18-20]</sup>中的标准卷积替换为深度可分离卷积,如图4所示。该轻量级自注意力机制可以在不降低模型的灵敏度和预测精度的情况下,实现降低网络计算损耗,降低计算内存的作用。注意力机制可以在深层网络充分挖掘全局信息,增强重要特征获取,抑制不必要特征的干扰,更准确地提取病灶边界的细节信息。




图4 轻量级自注意力机制

Figure 4 Lightweight self-attention mechanism

### 1.4 增强视野平均池化模块

池化层通常放置在卷积层的后面,主要作用是逐渐减少特征图的空间尺寸,减少模型中参数量,节省计算资源,控制网络过拟合现象。目前主要包括最大池化和平均池化的两种池化方式。平均池化如图5所示,取每个视野块的平均值,提取特征图中所有特征的信息进入下一层。

因为在网络前面的层,图像存在噪声和很多无用的背景信息,只包含少量有用信息,所以在本文网络模型的前两层采用最大池化,以此避免较多冗余信息的介入。由于网络深层包含比较丰富的语义信息,如果继续使用最大池化会丢失很多重要信息,因此在网络模型的后两层采用增强视野平均池化模块。本研究提出的增强视野平均池化模块除了标准






图5 标准平均池化模块  
Figure 5 Standard average pooling module

平均池化模块的功能外,还具有更大的感受野(图6)。因为在网络的后几层的特征区域都包含丰富的语义信息,增大感受野不仅不会丢失一些重要的语义信息,而且具有二次采集重要语义信息的功能,从而提高模型的分割精度。




图6 增强视野平均池化模块  
Figure 6 Enhanced average pooling module with a larger field of perception

1.5 客观评测标准

本研究使用 Dice 相似系数 (Dice Similarity Coefficient, DSC)、灵敏度 (Sensitivity) 和阳性预测值 (Positive Predictive Value, PPV)<sup>[21]</sup>来验证本文方法的可行性和有效性<sup>[22]</sup>。其中,DSC是用来衡量预测结

果和专家标注真实标签之间的相似性,其结果为0~1;灵敏度表示分割正确的肿瘤区域占肿瘤真实区域的比例;PPV用来衡量模型分割正确的脑肿瘤区域占模型分割的脑肿瘤区域的比例<sup>[23]</sup>。DSC、灵敏度和PPV越大越好。3种评测指标具体如式(4)、(5)和(6)所示:

$$DSC = \frac{2TP}{FP + 2TP + FN}$$

(4)

$$PPV = \frac{TP}{TP + FP}$$

(5)

$$Sensitivity = \frac{TP}{TP + FN}$$

(6)

假设脑肿瘤组织为正样本,则正常脑组织为负样本。TP即判定为正样本并且事实上为正样本,代表像素的真阳性;若事实上为负样本则为FP,代表像素的假阳性。TN是判定为负样本并且事实上为负样本,代表像素的真阴性;若事实上为正样本,则为FN,代表像素的假阴性。

2 实验结果与分析

2.1 数据集

本研究使用的数据集来自于国际医学图像计算和计算机辅助干预协会 (Medical Image Computing and Computer Assisted Intervention Society, MICCAI) 举办的脑肿瘤分割挑战赛 (Brain Tumor Segmentation, BraTS) 的公开数据集<sup>[24]</sup>。数据集 BraTS 2019,患者数据尺寸为240×240×155,共有480个样本,选取其中355个作为训练样本,其余为测试样本<sup>[25]</sup>。

数据集 BraTS 2019 每个病例均包含4种模态的MRI序列,分别为FLAIR (Fluid Attenuation Inversion Recovery)、T<sub>1</sub> (Spin-Lattice Relaxation)、T<sub>2</sub> (Spin-Spin Relaxation)、T<sub>1</sub>CE (T1-Contrasted)<sup>[26]</sup>以及专家标注好的标签图像,如图7所示。




图7 4种模态的MRI序列以及医生标注结果实例  
Figure 7 Four different MRI sequences and the ground truth annotated by doctors

2.2 实验结果分析

为验证本文方法对模型分割精确度的有效性,对仅使用轻量级残差模块组成的网络(LR-Unet)、轻量级残差模块+增强视野平均池化模块组成的网络(LRE-Unet)、轻量级残差模块+轻量级自注意力模块组成的网络(LRA-Unet),以及轻量级残差模块+轻量级自注意力模块+增强视野平均池化模块组成的网络(LRAE-Unet)进行对比实验。

实验配置如下:在 Windows 10 系统下,GPU 为 1 块 NVIDIA GeForce RTX 3060 Ti, 编码框架 PyTorch 1.12.0, CUDA11.0, 编译环境为 PyCharm。训练时 Batchsize 设置为 12,学习率为 0.000 1,迭代 epoch 为 200 次,终止次数为所设置的迭代次数 20,采用 Adam 优化器。实验结果如表 1 所示。WT、TC、ET 分别表示完整肿瘤、肿瘤核心与增强肿瘤区域。

表 1 对比实验结果(%)  
Table 1 Comparative experimental results (%)

模型	DSC			阳性检测率			敏感度		
	WT	TC	ET	WT	TC	ET	WT	TC	ET
U-Net	88.89	82.92	86.91	85.74	81.67	91.38	90.73	87.40	83.78
LR-Unet	91.01	88.09	87.28	89.73	85.98	87.21	92.85	92.06	88.85
LRE-Unet	91.13	88.19	87.80	89.57	86.20	88.04	93.11	92.57	88.47
LRA-Unet	90.54	87.19	86.19	88.41	84.71	84.54	93.27	92.09	89.88
LRAE-Unet	91.24	88.64	88.32	91.20	87.42	88.66	91.64	91.62	88.73

从表 1 可以看出,LR-Unet 模型在 WT、TC 和 ET 上的 DSC 分别为 91.01%、88.09% 和 87.28%, 优于 U-Net 模型,说明轻量级残差模块可使网络模型提高特征表示的准确性。与 WT 中的 LR-Unet 相比,LRA-Unet 的敏感度有所提高,说明轻量级自注意力模块使深度网络能充分利用全局信息,增强对重要特征的获取,抑制不必要特征的干扰。LRAE-Unet 模型在 WT、TC 和 ET 中的 DSC 分别为 91.24%、88.64% 和 88.32%,表明改进后的平均池化模块能更好地提取图像特征,LRAE-Unet 较 LRA-Unet 提高了大部分指标。

为验证 LRAE-Unet 的有效性和可行性,选用目

前流行的 U-Net<sup>[8]</sup>、HybridResUnet<sup>[27]</sup>、DeepResUnet<sup>[28]</sup> 网络模型进行对比实验。表 2 列出不同模型的参数量,实验结果如表 3 所示。

表 2 各模型参数量大小  
Table 2 Number of parameters in each model

模型	参数量
U-Net	39 400 067
HybridResUnet	31 565 635
DeepResUnet	32 613 835
LRAE-Unet	7 256 303

表 3 BraTS 2019 数据集各种算法的实验对比结果(%)  
Table 3 Comparison among various algorithms on BraTS 2019 dataset (%)

模型	DSC			阳性检测率			敏感度		
	WT	TC	ET	WT	TC	ET	WT	TC	ET
U-Net	88.89	82.92	86.91	85.74	81.67	91.38	90.73	87.40	83.78
HybridResUnet	90.37	86.57	86.26	92.69	87.72	90.98	88.83	88.11	83.58
DeepResUnet	90.93	87.35	85.68	93.00	89.79	90.42	89.48	87.17	83.45
LRAE-Unet	91.24	88.64	88.32	91.20	87.42	88.66	91.64	91.62	88.73

从表 2 可以看出,U-Net 网络模型参数量最大,LRAE-Unet 模型的参数量最小,不到其 1/5,因此具有

更轻量化的特征,能降低内存损耗,提高运行效率。  
从表 3 可以看出,LRAE-Unet 模型在 WT、TC 和

ET中的DSC分别为91.24%、88.64%和88.32%,与其他模型相比性能最佳,说明LRAE-Unet是一种有效的脑肿瘤分割模型。LRAE-Unet模型WT的DSC比U-Net模型高2.35%,比HybridResUnet模型高0.87%,比DeepResUnet模型高0.31%;阳性检测率比U-Net网络高5.46%;敏感度比U-Net模型高0.91%,比HybridResUnet模型高2.81%,比DeepResUnet模型高2.16%。

图8和图9是不同网络和病例的脑肿瘤分割可视化对比结果。图8中从上到下为选取病例不同视角的分割结果。黑色为背景区域,红色为非增强肿瘤(Non-Enhancing Tumor, NET),绿色为水肿区域(Peritumoral Edema, ED),黄色为增强肿瘤(Enhancing Tumor, ET)。WT包含NET、ED、ET,TC包含NET、ET<sup>[29]</sup>。

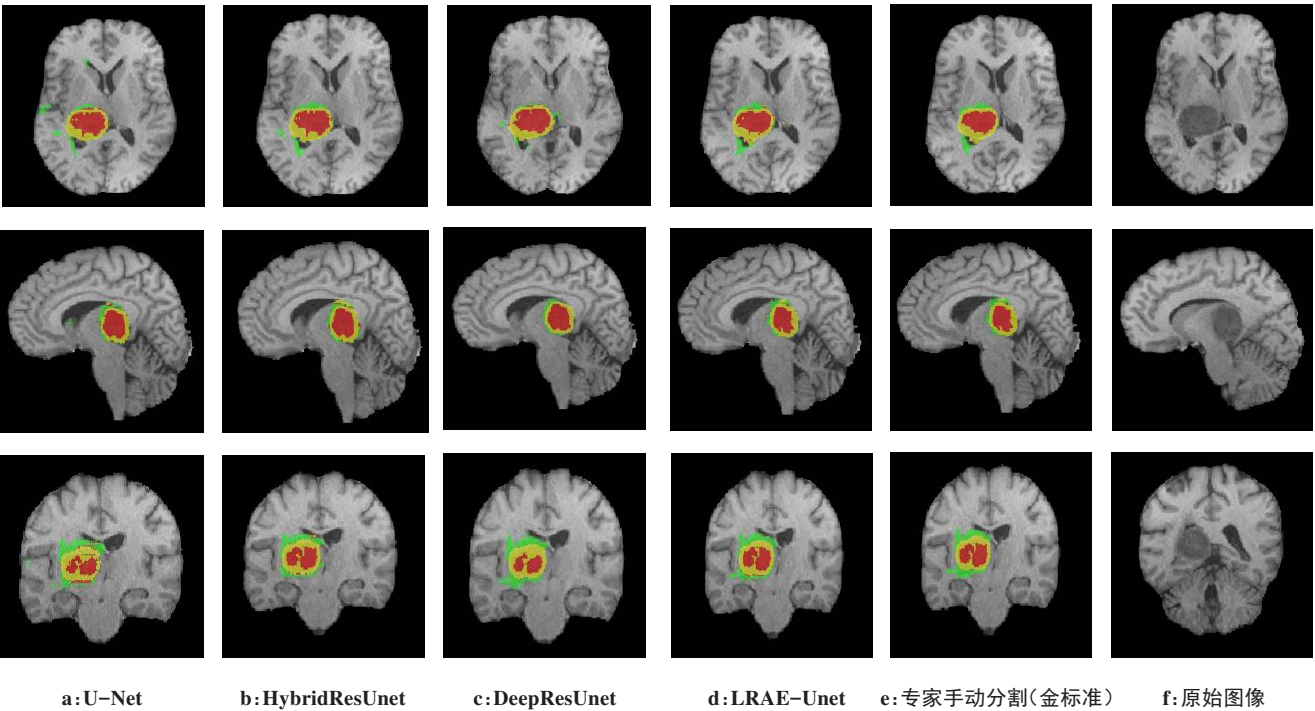


图8 2D分割可视化结果的视觉对照

Figure 8 Comparison of 2D segmentation visualization results

从上到下为选取病例不同视角的分割结果。黑色为背景区域,红色为NET,绿色为ED,黄色为ET

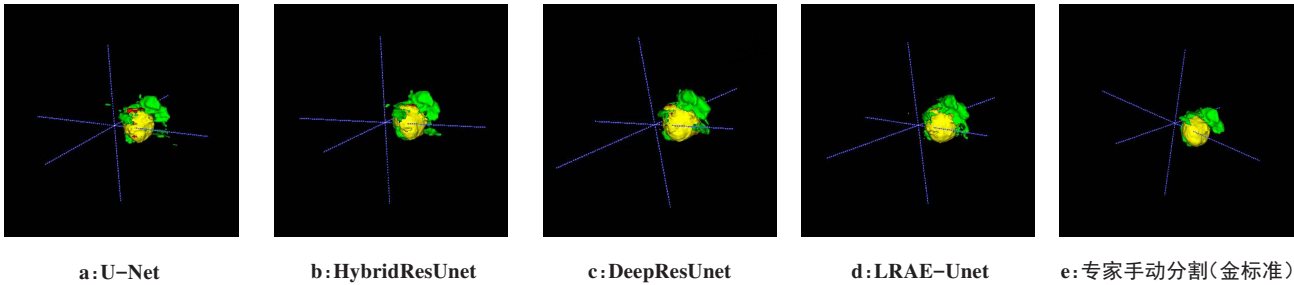


图9 3D分割可视化结果对比实例

Figure 9 Comparison of 3D segmentation visualization results

从图8可以看出LRAE-Unet的分割结果相比于其他3个网络没有较多的碎块。与U-Net相比,对WT没有出现过多的缺损;与HybridResUnet相比,ET的分割没有出现过多的碎块。从整体的视觉效果上

来看,LRAE-Unet的分割结果与金标准的重叠度更高。

从图9可以明显观察到神经胶质瘤的异质性,并且可以观察到LRAE-Unet的分割结果相较其他3个

网络,与金标准的重叠度更高、碎块少、更准确和完整。与DeepResUnet相比,ET区域分割缺损少;与U-Net和HybridResUnet相比,WT区域碎块更少。从整体的视觉效果上来看,LRAE-Unet的分割结果相比其他3种网络更接近金标准。

### 3 结 语

针对经典U-Net存在参数量较大、网络深度不够、全局信息提取不充分以及分割边界不够清晰而导致分割误差等问题,本研究提出一种结合轻量级残差块、轻量级自注意力机制和增强视野池化模块的全自动脑肿瘤分割网络LRAE-Unet,该网络不仅可以充分利用编码器与解码器不同层次的语义特征,而且在降低网络参数的情况下,也能得到更高的精度,且分割性能不亚于其它经典的3D图像分割网络,能在配置较低的计算机上运行。LRAE-Unet将助力临床应用中脑肿瘤结构精准的分割任务,为脑肿瘤病情诊断和治疗方案制定提供科学依据。

### 【参考文献】

- [1] Patel AP, Fisher JL, Nichols E, et al. Global, regional, and national burden of brain and other CNS cancer, 1990-2016: a systematic analysis for the Global Burden of Disease Study 2016[J]. *Lancet Neurol*, 2019, 18(4): 376-393.
- [2] 计亚荣,王瑜,付常洋,等.基于典型相关分析与双模态数据融合的抑郁症辅助诊断[J].*中国医学物理学杂志*, 2021, 38(10): 1316-1320.
- [3] Ji YR, Wang Y, Fu CY, et al. Aided diagnosis of major depressive disorder based on canonical correlation analysis and bimodal data fusion[J]. *Chinese Journal of Medical Physics*, 2021, 38(10): 1316-1320.
- [4] 万俊,聂生东,王远军.基于MRI的脑肿瘤分割技术研究进展[J].*中国医学物理学杂志*, 2013, 30(4): 4266-4271.
- [5] Wan J, Nie SD, Wang YJ. Research progress of brain tumor segmentation technology based on MRI[J]. *Chinese Journal of Medical Physics*, 2013, 30(4): 4266-4271.
- [6] Lee CH, Wang S, Murtha A, et al. Segmenting brain tumors using pseudo-conditional random fields[C]//*Medical Image Computing and Computer-Assisted Intervention-MICCAI 2008: 11th International Conference*, 2008: 359-366.
- [7] Colman J, Zhang L, Duan W, et al. DR-Unet104 for multimodal MRI brain tumor segmentation [C]//*Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 6th International Workshop*, 2021: 410-419.
- [8] Hinton GE, Salakhutdinov RR. Reducing the dimensionality of data with neural networks[J]. *Science*, 2006, 313(5786): 504-507.
- [9] Krizhevsky A, Sutskever I, Hinton GE. ImageNet classification with deep convolutional neural networks[J]. *Commun ACM*, 2017, 60(6): 84-90.
- [10] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]//*Proceedings of International Conference on Learning Representations*, 2015: 39-53.
- [11] Szegedy C, Liu W, Jia Y, et al. Going deeper with convolutions[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 1-9.
- [12] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//*Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, 2016: 770-778.
- [13] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [14] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[C]//*Proceedings of Medical Image Computing and Computer-Assisted Intervention*, 2015: 234-241.
- [15] Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recogn*, 2018, 77: 354-377.
- [16] Zhang R, Zhu F, Liu J, et al. Depth-wise separable convolutions and multi-level pooling for an efficient spatial CNN-based steganalysis[J]. *IEEE Trans Inf Foren Sec*, 2019, 15: 1138-1150.
- [17] Lu G, Zhang W, Wang Z. Optimizing depthwise separable convolution operations on GPUs[J]. *IEEE Trans Parallel Distr Syst*, 2021, 33(1): 70-87.
- [18] Zhang J, Du J, Liu H, et al. LU-Net: an improved U-Net for ventricular segmentation[J]. *IEEE Access*, 2019, 7: 92539-92546.
- [19] Chollet F. Xception: deep learning with depthwise separable convolutions[C]//*2017 IEEE Conference on Computer Vision and Pattern Recognition*, 2017.
- [20] Kamal KC, Yin Z, Wu M, et al. Depthwise separable convolution architectures for plant disease classification[J]. *Comput Electron Agr*, 2019, 165: 104948.
- [21] Bai L, Zhao Y, Huang X. A CNN accelerator on FPGA using depthwise separable convolution[J]. *IEEE Trans Circuits Syst*, 2018, 65(10): 1415-1419.
- [22] Oktay O, Schlemper J, Folgoc LL, et al. Attention U-Net: Learning where to look for the pancreas [C]//*Proceedings of International Conference on Medical Imaging with Deep Learning*, 2018: 83-93.
- [23] 江宗康,吕晓钢,张建新,等. MRI脑肿瘤图像分割的深度学习综述[J].*中国图象图形学报*, 2020, 25(2): 215-228.
- [24] Jiang ZK, Lü XG, Zhang JX, et al. Review of deep learning methods for MRI brain tumor image segmentation[J]. *Journal of Image and Graphics*, 2020, 25(2): 215-228.
- [25] Roy AG, Navab N, Wachinger C. Recalibrating fully convolutional networks with spatial and channel 'squeeze & excitation' blocks[J]. *IEEE Access*, 2018, 38(2): 540-549.
- [26] Park S, Kwak N. Analysis on the dropout effect in convolutional neural networks[C]//*Computer Vision-ACCV 2016: 13th Asian Conference on Computer Vision*. Taipei, Taiwan, 2017: 189-204.
- [27] Wu Z, Shen C, van Den Hengel A. Wider or deeper: revisiting the resNet model for visual recognition[J]. *Pattern Recogn*, 2019, 90: 119-133.
- [28] Bakas S, Akbari H, Sotiras A, et al. Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features[J]. *Sci Data*, 2017, 4: 170117.
- [29] Jones TL, Byrnes TJ, Yang G, et al. Brain tumor classification using the diffusion tensor image segmentation (D-SEG) technique[J]. *Neuro-oncology*, 2015, 17(3): 466-476.
- [30] Atek S, Mehidi I, Jabri D, et al. SwinT-UNet: hybrid architecture for medical image segmentation based on Swin Transformer block and dual-scale information [C]//*2022 7th International Conference on Image and Signal Processing and their Applications*, 2022: 1-6.
- [31] Zhang Z, Liu Q, Wang Y. Road extraction by deep residual U-Net[J]. *Geosci Remote Sensing Lett*, 2018, 15(5): 749-753.

(编辑:谭斯允)