

# 基于 Unet 的多注意力脑肿瘤图像分割算法

吴 量,付殿臣,程 超

(长春工业大学 计算机科学与工程学院,吉林 长春 130012)

**摘 要:**针对多类型脑肿瘤医学图像分割中上下文信息联系匮乏及人工分割效率、准确率低等问题,提出了一种基于 Unet 的脑肿瘤自动分割算法。首先,在 Unet 模型的基础上引入残差结构(ResBlock),用于加深网络;其次,重新构建 Unet 的解码网络,增加一条并行的膨胀卷积(dilated convolution)特征提取模块;最后,网络结合改进后的通道和空间多注意力机制,使得网络在提取特征时更加专注某些特征层和空间区域,抑制了某些无效的非病灶区域的冗余特征,进而提高病灶分割的精度。该文使用医学分割 Dice 评价指标,充分测试算法对多序列脑肿瘤核磁共振(MRI)医学图像的分割性能。实验结果表明,改进后的算法在 Complete Dice、Core Dice 和 Enhancing Dice 上分别可达 0.909、0.820 和 0.766。与 Unet 及其改进的分割算法比较,该算法在参数量与 Unet 相当的情况下获得了更好的分割结果。

**关键词:**深度学习;脑肿瘤图像分割;Unet 网络;注意力机制;残差块

中图分类号:TP301

文献标识码:A

文章编号:1673-629X(2021)12-0085-07

doi:10.3969/j.issn.1673-629X.2021.12.015

## Multi-attention Brain Tumor Image Segmentation Algorithm Based on Unet

WU Liang, FU Dian-chen, CHENG Chao

(School of Computer Science and Engineering, Changchun University of Technology, Changchun 130012, China)

**Abstract:** In view of the lack of context information connection and the low efficiency and accuracy of artificial segmentation in medical image segmentation of multi-type brain tumors, a automatic segmentation algorithm based on Unet is proposed. Firstly, on the basis of the Unet model, the ResBlock structure is added to deepen the network. Secondly, the decoding network of Unet is reconstructed and a parallel dilation convolution feature extraction module is added. Finally, the network combines the improved channel and spatial multi attention mechanism, which makes the network focus more on some feature layers and spatial regions when extracting features, and suppresses the redundant features of some invalid non lesion regions, so as to improve the accuracy of lesion segmentation. In order to fully test the algorithm's segmentation performance of multiple sequence brain tumor MRI (magnetic resonance imaging) medical images, the indexes of medical segmentation Dice evaluation are used. The experiment shows that the improved algorithm is entitled to 0.909, 0.820 and 0.766 on Complete Dice, Core Dice and Enhancing Dice respectively. Compared with Unet and its improved segmentation algorithm, it will get a better segmentation result under the condition that the number of parameter quantity is the same as Unet.

**Key words:** deep learning; brain tumor image segmentation; Unet; attention mechanism; Resblock

## 0 引 言

医学图像分割是医学图像分析领域的一个重要内容,通常所说的分割指的是语义分割<sup>[1]</sup>,即通过对图像的每一个像素标记上语义信息,来实现像素级别的预测,属于计算机视觉的范畴。与自然图像分割相比,医学图像分割任务由于边界模糊、数据集小、语义简单等特点,实现的难度会更大。为了提高医学图像分割的效率和准确性,人们开展了越来越多的尝试,其中一个

很重要的方向就是脑肿瘤 MRI 图像的分割<sup>[2]</sup>。近年来,脑肿瘤在社会上已经成为一种常见的疾病,对人们的生命造成了巨大的威胁。脑肿瘤个体间形状、纹理差异较大,很难提升分割的精度。目前,脑肿瘤医学诊断主要依赖于医生个人知识的积累和实战经验的判断,这种依赖存在较大的潜在问题,比如耗时长,或在高强度的重复工作条件下医生过度疲劳而由此引发的漏诊和误诊。因此,构建一种精确、快速的脑肿瘤分割

收稿日期:2020-12-18

修回日期:2021-04-20

基金项目:吉林省发展改革委产品技术与开发项目(2019C040-3)

作者简介:吴 量(1987-),男,博士,讲师,硕士,CCF 会员(E6409M),研究方向为机器视觉理论及应用;通信作者:程 超(1984-),男,博士后,副教授,博导,研究方向为动态系统故障诊断与预测维护。

方法对脑瘤的诊断和早期治疗具有很重要的意义。

## 1 相关工作

目前脑肿瘤分割算法有很多,主要分为传统图像分割方法和基于深度学习的分割方法。

### 1.1 传统图像分割方法

在传统的图像分割中,单独使用一种分割方法得到的分割精度较低,研究者经常将传统方法与其他的方法结合使用以提高分割的精度。

阈值法通过设定不同的阈值将分割目标与背景的像素区分,达到分割的目的,特点是计算速度快,但是适用性有限。赖小波等人结合传统机器学习方法随机森林和阈值法提出了一种多模态 MRI 图像和多特征融合的脑肿瘤分割方法<sup>[3]</sup>,首先进行图像校准和偏置场校正,融合提取的多模态特征构建 RF 模型进行粗分割,最后根据先验知识设定阈值进行分割。基于区域的方法优点是简单,能够正确分割具有相似属性的区域,缺点是容易造成过度分割。候冬奥等人结合区域生长法提出了一种全自动的脑肿瘤分割方法<sup>[4]</sup>,该方法利用人脑结构对称信息,通过区域生长法实现粗略分割,然后使用改进的测地线活动轮廓 (geodesic active contours, GAC) 模型对粗略分割区域进行精细分割。童云飞等人采用快速模糊 C 均值聚类 and 自动阈值法对肿瘤区域进行粗略轮廓提取<sup>[5]</sup>,而后使用混合水平集算法来提取病灶的边界。张腾达等人针对传统水平集 (Level Set) 方法对肿瘤 MRI 图像进行分割时弱边缘分割缺失的现象<sup>[6]</sup>,采用模糊聚类算法与 Level Set 结合的方式增强了传统方法对脑肿瘤分割的鲁棒性和准确性。

### 1.2 基于深度学习的图像分割方法

近年来,深度学习技术快速发展,人们结合深度学习,提出了很多优秀的脑肿瘤 MRI 图像分割方法。研究者首先应用卷积神经网络 (CNN) 对语义分割进行了探索,并将 CNN 应用于脑肿瘤 MRI 图像分割<sup>[7]</sup>,得到了良好的分割结果。但是,由于 CNN 本身的输出全连接层结构,模型在分割图像时耗费巨大的内存,计算效率很低。另外, CNN 只可以对输入图像进行像素的简单分类,且全连接层限制了输入图像必须固定尺寸大小,通常模型的预测图像较输入图像的分辨率会小一些,这大大影响了分割的效率和精度,因此得到的预测分割结果往往不尽如人意。

为解决这一问题,2015 年 Long 等人<sup>[8]</sup>提出了一种专门适用于图像分割任务的全卷积神经网络 (FCN) 模型。FCN 模型不仅避免了 CNN 全连接层在计算时重复冗余卷积造成的存储开销过大的问题,也解决了图像尺度的可变换问题,使得网络可以接受任

意大小的图像,模型的输出图像可以恢复到与原图大小的分辨率,实现了图像在真正意义上的语义分割。然而,医学图像数据对细节较为敏感,传统 FCN 的分割精度是远远不够的。邢波涛等人基于 FCN 模型<sup>[9]</sup>,将多模态 MRI 图像进行预处理和特征融合,通过结合条件随机场 (CRF) 来细化 FCN 的粗病灶分割结果。针对医学图像的分割任务, Ronneberger 等人<sup>[10]</sup>基于 FCN 提出更加适用于医学图像分割的 Unet 模型。与 FCN 模型相比, Unet 模型结构对称,其特有的 Skip Connection 结构充分结合底层空间特征和高层语义特征,对图像的细节特征提取更加敏感,针对医学图像的小目标分割更加精确。Dong 等人<sup>[11]</sup>将 Unet 模型应用于脑胶质瘤的分割,在 BraTS 2015<sup>[12]</sup>脑肿瘤 MRI 数据集上取得了优良的分割效果。

因 Unet 在医学图像分割任务中表现出的优良性能,近几年来提出的医学图像分割模型<sup>[13-17]</sup>大多基于 U 型对称结构和应用 Unet 的特征融合方式,研究者分别在模型深度和特征融合方式等方面对 Unet 进行了改进。Ibtehaz 等人<sup>[14]</sup>通过结合深度残差网络 (ResNet) 和 Unet 模型,加深了模型的深度,并将算法应用于医学图像分割,在 5 个医学数据集上较 Unet 提升了分割的精度。最近, Cao 等人<sup>[15]</sup>充分利用密集连接网络<sup>[16]</sup> (DenseNet) 特征融合特性,将密集连接 (Dense Connection) 与 Unet 模型结合应用电磁图像的分割任务,并通过实验验证了 DenseUnet 分割性能的提升。医学图像多为 3D 数据, 2D 卷积不能充分利用 3D 数据的空间结构信息,而 3D 卷积具有较高的计算成本和 GPU 内存消耗。为了解决这些问题, Li 等人<sup>[17]</sup>提出了一种新的混合密集连接的 Unet, 并取得了优良的分割指标。针对 Unet 不同大小的数据集自适应层数问题, Zhou 等人<sup>[13]</sup>提出了 Unet++ 模型, 模型可以根据不同的数据集自适应调整网络的提取层数和减少训练参数量。随着深度学习理论的完善,人们对不同领域的任务也进行了交叉研究。有研究者尝试把与人类视觉机制相符合的注意力机制应用于图像处理领域。Li 等人<sup>[18]</sup>对注意力门输出层的通道结合方式进行了改进,并用 DenseNet 结合基础的 Unet 模型。该文基于 Unet 重新设计网络提取模型并结合改进后的多注意力机制,提出了一种基于 Unet 的多注意力脑肿瘤 MRI 图像自动分割算法。

该文的主要创新点总结如下:

(1) 提出了一种快速、准确、端到端的脑肿瘤 MRI 图像自动分割方法。

(2) 在主干特征提取网络部分,重新设计 Unet 网络的结构,模型与 ResBlock 结合并且增加并行 Dilated Convolution 特征提取模块,提升了网络特征提取的

性能。

(3) 针对小型病灶分割精度低的问题,引入空间注意力和层注意力多注意力机制,使得特征提取网络更加注意某些特征层和空间区域的关键特征,抑制了冗余区域的无效特征。

(4) 在 BraTS 数据集上对比了其他分割网络,验

证了该文的模型,得到了较好的分割效果。

## 2 算法设计

文中算法对四种模态图像数据进行并行处理,最后得到多类肿瘤的分割预测结果,整体的算法流程结构示意图如图 1 所示。

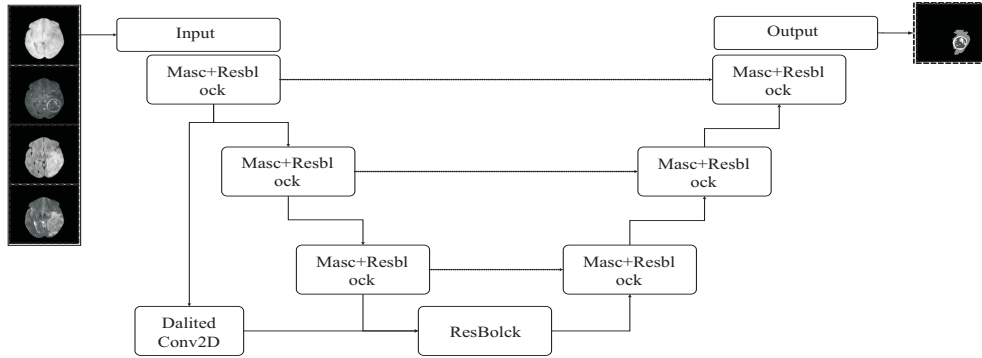


图 1 算法流程示意图

### 2.1 主干特征提取网络的设计

模型基于经典的 U 型网络,去掉了 Unet 的池化层并整体采用 ResBlock<sup>[19]</sup> 对网络进行加深处理,使得网络能够充分融合浅层和深层语义信息。为保证引入 ResBlock 后不增加大量的参数,模型去除了两层网络,将各层的通道数调整为原来的 1/2。另外,模型增加了一条并行的特征提取模块,提取的特征与最后一

层下采样层进行特征叠加。考虑到大幅度的下采样会导致有效特征的丢失,在特征融合前,并行模块采用了膨胀系数为 2 的 Dilated Convolution<sup>[20]</sup> 对第一层提取到的特征进行了二次特征提取,通过增大特征提取卷积的感受野,使得特征下采样过程更加平滑。并行的特征提取网络结构如图 2 所示。

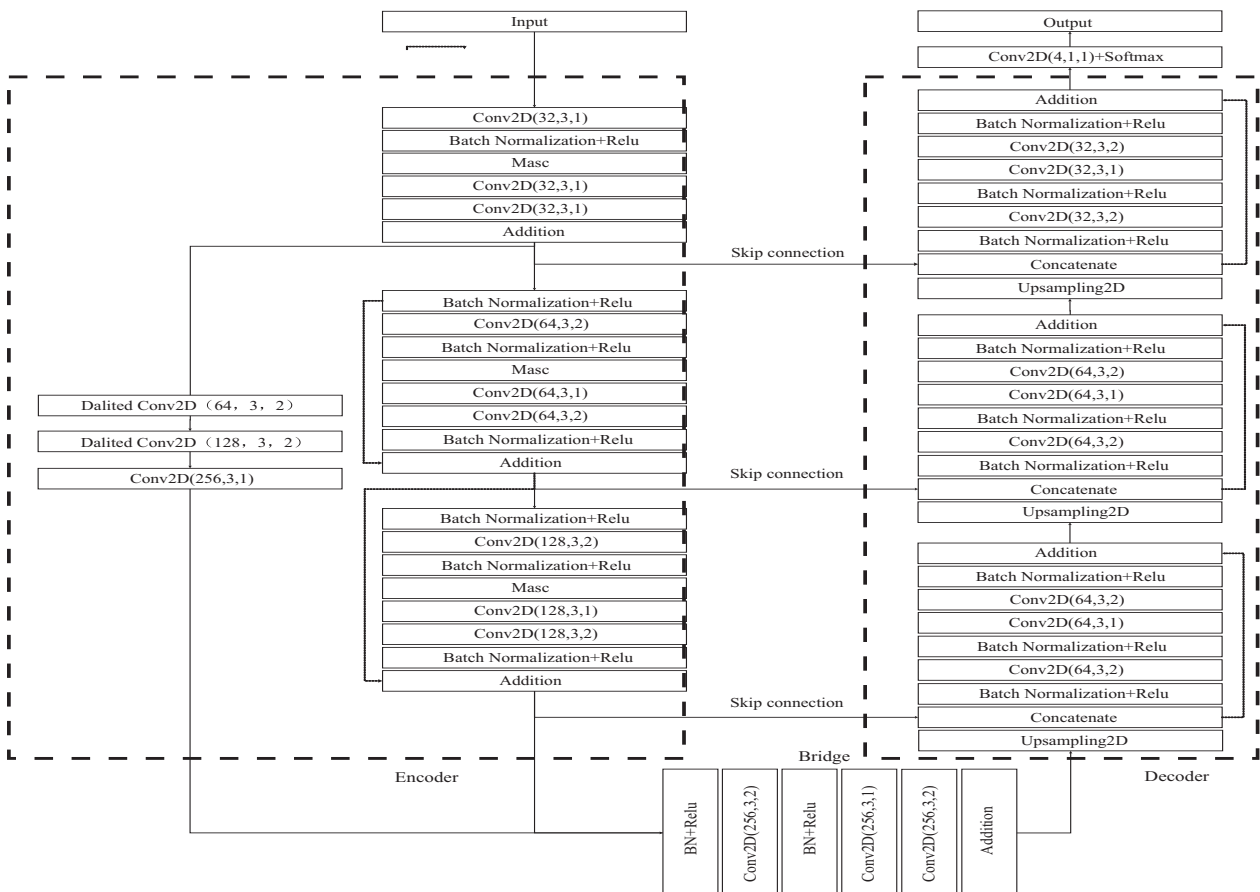


图 2 网络模型结构

## 2.2 多注意力机制 Masc 模块

该文提出的 Masc 注意力机制模块,延续了传统注意力机制对输入图像进行通道级别的注意力特征图像级联空间注意力模块的设计思想。在此基础上对模型的输入特征单独应用空间注意力模块进行空间注意特征提取,对两次注意力机制获取的空间注意力特征做了特征融合,使模型更加注重提取图像的二维空间信息。

注意力模块的结构如图 3 所示,具体的算法流程接下来会详细描述。假设 Masc 模块的输入是任意一个中间特征  $F \in R^{H \times W \times C}$ ,  $F$  首先同时输入 Masc 模块的通道注意力模块和空间注意力模块,分别得到一维

通道注意图  $F_c \in R^{1 \times 1 \times C}$  和二维空间注意图  $F_{s2} \in R^{H \times W \times 1}$ ,在得到  $F_c$  之后,  $F_c$  会输入到级联的空间注意力模块得到  $F_{s1} \in R^{H \times W \times 1}$ ,最后采取特征相叠加的特征融合方式合并  $F_{s1}$  和  $F_{s2}$  得到最终的注意力图  $F_{sc} \in R^{H \times W \times 1}$ 。总体的注意力提取过程可以公式化如下:

$$F_c = M_c(F \in R^{H \times W \times C}) \quad (1)$$

$$F_{s1} = M_{s1}(F \in R^{H \times W \times C}) \quad (2)$$

$$F_{s2} = M_{s2}(F_{sc} \in R^{1 \times 1 \times C}) \quad (3)$$

$$F_{sc} = F_{s1} + F_{s2} \quad (4)$$

其中,  $M^*(*)$  表示特征图进入相应模块进行提取注意特征与原图进行矩阵元素相乘运算。 $F_{sc} \in R^{H \times W \times 1}$  是最终注意力模块的输出结果。




图 3 Masc 注意力机制模块

### 2.2.1 通道注意模块

该文首先使用全局平均池化操作提取输入特征图  $F^i$  的主要空间信息,得到  $F_{cavg}^i$ ,之后将其输入到一个  $1 \times 1 \times 1$  的卷积当中,对卷积参数进行压缩,最后经过一个 softmax 激活层与特征输入进行元素乘积运算得到  $F_c^i \in R^{1 \times 1 \times C/r}$ 。通道注意力可由公式(5)表示:

$$F_c^i = \sigma_1(\text{Conv}(\text{GlobalAvgPool}(F^i))) \otimes F^i = \sigma_1(w_1(\sigma_0(w_0 F_{cavg}^i + b_0)) + b_1) \otimes F^i \quad (5)$$

其中,  $\sigma_1$  表示 softmax 激活函数,  $\sigma_0$  表示 relu 激活函数,  $w_*$ ,  $b_*$  分别表示卷积层的权重和偏置,  $\otimes$  表示元素乘积运算。下面公式参数同式(5)。

### 2.2.2 空间注意模块

该文的注意力机制模块分为两部分,第一部分对通道注意力机制提取到的注意图  $F_c^i \in R^{1 \times 1 \times C/r}$  进行特征空间的处理,作为通道注意力模块的补充。为了计算空间注意力,模型首先将通道注意图  $F_c^i$  依次输入 2D 卷积层和激活层,并对卷积核的个数进行了参数扩展,然后从 softmax 层输出与  $F_c^i$  进行元素相乘得到  $F_{s1}^i$ 。第二部分是对输入特征图  $F \in R^{H \times W \times C}$  利用特征间的空间关系生成空间注意力图。与通道注意力相比,空间注意力更加注重图像的空间信息,这部分首先应用全局平均池化和最大池化对输入特征图  $F^i$  进行关

键特征提取,之后将得到的特征图聚合得到  $F_{pool}^i$ ,最后输入 2D 卷积层,产生二维空间图。简而言之,空间注意力计算如公式(6)和公式(7):

$$F_{s1}^i = \sigma_1(w_3(\sigma_0(w_2 F_c^i + b_2)) + b_3) \otimes F_c^i \quad (6)$$

$$F_{s2}^i = \sigma_1(\text{Conv}(\text{GlobalAvgPool}(F^i) + \text{GlobalMaxPool}(F^i))) \otimes F^i = \sigma_1(\text{Conv}(F_{pool}^i)) \otimes F^i = \sigma_1(w_5(\sigma_0((w_4 F_{pool}^i + b_4) + b_5))) \otimes F^i \quad (7)$$

Masc 模块最终的注意力图  $F_{masc}^i$  计算如公式(8):

$$F_{masc}^i = F_{s1}^i + F_{s2}^i = \sigma_1(w_3(\sigma_0(w_2 F_c^i + b_2)) + b_3) \otimes F_c^i + \sigma_1(w_5(\sigma_0((w_4 F_{pool}^i + b_4) + b_5))) \otimes F^i \quad (8)$$

该文的 Masc 模块分别对输入的图像进行通道注意力和双空间注意力的提取,更加注重图像 2 维空间的信息。

## 3 实验

### 3.1 数据集介绍及预处理

数据集采用的是公开数据集 BraTS 2019 脑胶质瘤 MRI 数据,其中包含 259 例高级别胶质瘤(HGG)和 76 例低级别胶质瘤(LGG)两类患者数据。HGG 患者



包括水肿 (edema), 坏死 (necrosis), 增生 (enhancing tumor) 肿瘤, 非增生 (non-enhancing tumor) 肿瘤部分, 而 LGG 患者增生 (enhancing tumor) 可能存在也可能不存在。BraTS 2019 数据集<sup>[12]</sup> 包括 4 类标签, 如图 4 (e) 所示, 分别是正常组织 (标签 0)、坏死和非增生肿瘤 (标签 1)、水肿 (标签 2)、增生肿瘤 (标签 4)。分割任务包括三个: (1) 完整肿瘤区域 (Complete tumor), 包括所有三个肿瘤内类, 标签是 1、2 和 4。(2) 核心肿瘤区域 (Core tumor), 不包括“edema”区域, 标签是 1 和 4。(3) 增强肿瘤区域 (Enhancing tumor), 只包括标签 4。实验将 BraTS 2019 的训练数据分成训练集、验证集和测试集, 比例分别是 0.6、0.2 和 0.2。原始数据集是由 T1、T2、T1C 和 FLAIR 四个序列构成的 3D 数据, 如图 4(a) ~ 图 4(d) 所示。每例数据由 155 张厚度为 1 mm×1 mm×1 mm, 大小为 240×240 的切片组成。在数据预处理方面, 该文取 3D 数据的 2D 切片, 只对数据做了主要部分的裁剪和空白切片的去除, 具体的做法是将 (155, 240, 240) 大小的切片处理成 (146, 192, 152) 大小, 除此之外未做任何的数据增强。另外, 该文没有对每种病灶对应相关模态单独处理, 四种模态都是单通道图片数据, 直接将数据合并成四通道数据送入网络, 这种数据处理方式能有效地结合每种模态的特性, 更利于模型的训练。




图 4 BraTS 脑肿瘤数据

### 3.2 训练环境及模型参数设置

该文的实验环境是 Nvidia Tesla V100 GPU, 所用框架为基于 Tensorflow 的 Keras 框架。模型参数设置: 网络优化器采用的是 Adam 优化器, 初始学习率 LR 设置为  $1e-3$ , Batch\_Size 设置为 4, Epoch 设置为 200。根据不同的实验模型, 参数略有调整。

该文的损失函数 (Loss Function) 采用 Sudre<sup>[21]</sup> 提到的 Weighted Cross-Entropy (WCE) 和 Generalized Dice Loss (GDL) 相结合的方式。

$$WCE = -\frac{1}{N} \sum_{n=1}^N w r_n \log(p_n) + (1 - r_n) \log(1 - p_n) \quad (9)$$

$$GDL = 1 - 2 \frac{\sum_{l=1}^2 w_l \sum_n r_{ln} p_{ln}}{\sum_{l=1}^2 w_l \sum_n r_{ln} + p_{ln}} \quad (10)$$

### 3.3 评价指标

在 MRI 脑肿瘤分割任务中, 最重要的评价指标是 Dice 相似系数。Dice 相关系数有效地衡量了算法分割结果与真实标注标签的重叠程度, 具体计算如公式 (11):

$$Dice = \frac{2TP}{FP + 2TP + FN} \quad (11)$$

其中, TP、FP、FN 分别为真阳性、假阳性、假阴性。Dice 相关系数越大表示脑肿瘤的分割结果越好。

### 3.4 实验结果

如表 1 所示, 文中模型 MascParallelUnet 在参数量并未增加的条件下, 分割性能较原始 Unet 模型分割 Complete Dice 提升了 1.56%, Core Dice 提升了 4.06%, Enhancing Dice 提升了 9.58%。

表 1 对比实验 Dice 指标对比

Model	Complete Dice	Core Dice	Enhancing Dice
Unet	0.895	0.788	0.699
ResUnet	0.896	0.824	0.739
Unet++	0.903	0.811	0.740
DenseUnet	0.907	0.821	0.766
MascParallelUnet (ours)	0.909	0.820	0.766

表 2 注意力模块 Dice 指标对比

Model	Complete Dice	Core Dice	Enhancing Dice
CBAMUnet	0.888	0.781	0.737
AGUnet	0.897	0.783	0.723
MascUnet (ours)	0.897	0.804	0.760
ParallelUnet (ours)	0.904	0.817	0.758
MascParallelUnet (ours)	0.909	0.820	0.766

分割效果如图 5 所示, 可以看到文中模型得到的分割结果对于脑肿瘤病灶的细节处理得更好。与现有的模型对比, 文中模型比 DenseUnet 模型的分割精度略低, 但是 DenseUnet 的参数量较该文网络参数量多了 2 倍左右。

该文分别测试了结合 Masc 模块和不结合 Masc 模块对模型分割精度的影响, 并与其他注意力模块进行了对比。如表 2 所示, 可以发现 Masc 注意力结构加入 Unet, Complete Dice 没明显提升, 而 Core Dice 和 Enhancing Dice 有显著提升, 分割效果如图 6 所示。该文在对比实验中加入 CBAMUnet 和 AGUnet, 实验结

果表明两种注意力模块的 Complete Dice 和 Core Dice 都比传统 Unet 略低,在 Enhancing Dice 上有所提高。该文提出的新的注意力模块结构较 Unet 的 Core Dice 提升了 2.03%,在 Enhancing Dice 上提升了 8.73%,可以发现该文提出的 Masc 模块对小目标病灶的分割更加精确,证明了该文改进的注意力模块的有效性。另

外,不加入 Masc 模块的并行特征提取网络 ParallelUnet 较 Unet 模型在 Core Dice 和 Enhancing Dice 上也有显著的提升,说明该文提出的并行特征提取网络对总体脑肿瘤分割精度的提升起到了主导作用。




图 5 对比实验分割效果图




图 6 注意力模块性能分割效果图

#### 4 结束语

为了提升脑肿瘤多类型病灶分割的分割精度,该文提出了一种基于 Unet 网络的快速、准确的脑肿瘤自动分割模型。首先,重新设计了模型编码网络结构,引入并行 Dilated Convolution 提取模块,融合浅层空间特征与高层语义特征,使特征提取更加充分。其次,模型结合多注意力机制并对空间注意力模块进行了特征融合加强,使模型更加注意图像的二维空间信息。最后,对比其他基于 Unet 改进的方法,该文模型的分割精度得到了一定程度的提升。此外,模型是基于 2D 数据集进行分割的,并没有充分利用数据集 3D 的空间信息。因此,下一步研究重点是把 2D 模型拓展到 3D 模型。

#### 参考文献:

[1] 胡 涛,李卫华,秦先祥. 图像语义分割方法综述[J]. 测控

技术,2019,38(7):8-12.

- [2] 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.
- [3] 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.
- [4] 侯东奥,鲁宇明,汪宇玲,等. MRI 的脑部肿瘤分割及其三维重建[J]. 应用科学学报,2018,36(5):808-818.
- [5] 童云飞,李 铮,关 欣. 改进的多模式脑肿瘤图像混合分割算法[J]. 信号处理,2018,34(3):340-346.
- [6] 张腾达,吕晓琪,任晓颖,等. 基于模糊水平集的脑肿瘤 MR 图像分割方法[J]. 现代电子技术,2016,39(18):91-95.
- [7] 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.
- [8] LONG J, SHELHAMER E, DARRELL T. Fully convolution-

- al networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39 (4): 640–651.
- [9] 邢波涛, 李 镝, 关 欣. 改进的全卷积神经网络的脑肿瘤图像分割[J]. 信号处理, 2018, 34(8): 911–922.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation [C]// Medical image computing and computer-assisted intervention – MICCAI 2015. Munich, Germany: [s. n.], 2015: 234–241.
- [11] DONG H, YANG G, LIU F, et al. Automatic brain tumor detection and segmentation using U-Net based fully convolutional networks [J]. Medical Image Understanding and Analysis, 2017, 723: 506–517.
- [12] MENZE B H, JAKAB A, BAUER S, et al. The multimodal brain tumor image segmentation benchmark (BRATS) [J]. IEEE Transactions on Medical Imaging, 2014, 34(10): 1993–2024.
- [13] ZHOU Z W, SIDDIQUEE M M R, TAJBAKHS N, et al. UNet++: a nested u-net architecture for medical image segmentation [C]// Deep learning in medical image analysis and multimodal learning for clinical decision support. Granada, Spain: Springer, 2018: 3–11.
- [14] IBTEHAZ N, RAHMAN M S. MultiResUNet: rethinking the U-Net architecture for multimodal biomedical image segmentation [J]. Neural Networks, 2019, 121: 74–87.
- [15] CAO Y, LIU S, PENG Y, et al. DenseUNet: densely connected UNet for electron microscopy image segmentation [J]. IET Image Processing, 2020, 14(12): 2682–2689.
- [16] HUANG G, LIU Z, DER MAATEN L V, et al. Densely connected convolutional networks [C]// The 30th IEEE conference on computer vision and pattern recognition. Hawaii, USA: IEEE, 2017: 2261–2269.
- [17] LI X M, CHEN H, QI X J, et al. H-DenseUNet: hybrid densely connected UNet for liver and tumor segmentation from CT volumes [J]. IEEE Transactions on Medical Imaging, 2018, 37(12): 2663–2674.
- [18] LI S, DONG M, DU G, et al. Attention Dense-U-Net for automatic breast mass segmentation in digital mammogram [J]. IEEE Access, 2019, 7: 59037–59047.
- [19] HE K, ZHANG X, REN S, et al. Deep residual learning for image recognition [C]// The 29th IEEE conference on computer vision and pattern recognition. Las Vegas, USA: IEEE, 2016: 770–778.
- [20] CHEN L, ZHU Y, PAPANDREOU G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]// Computer vision – ECCV 2018. Munich, Germany: Springer, 2018: 833–851.
- [21] 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. Québec City, QC, Canada: Springer, 2017: 240–248.
- 
- (上接第 54 页)
- 不平衡数据分类 [J]. 计算机技术与发展, 2015, 25(9): 17–21.
- [12] 石洪波, 陈雨文, 陈 鑫. SMOTE 过采样及其改进算法研究综述 [J]. 智能系统学报, 2019, 14(6): 1073–1083.
- [13] HA J, LEE J S. A new under-sampling method using genetic algorithm for imbalanced data classification [C]// Proceedings of the 10th international conference on ubiquitous information management and communication. NY, United States: Association for Computing Machinery, 2016: 1–6.
- [14] CHAWLA N V, BOWYER K W, HALL L O, et al. SMOTE: synthetic minority over-sampling technique [J]. Journal of Artificial Intelligence Research, 2002, 16(1): 321–357.
- [15] GHAZIKHANI A, MONSEFI R, YAZDI H S. Online neural network model for non-stationary and imbalanced data stream classification [J]. International Journal of Machine Learning and Cybernetics, 2014, 5(1): 51–62.
- [16] GUO H X, LI Y J, LI Y A, et al. BPSO-Adaboost-KNN ensemble learning algorithm for multi-class imbalanced data classification [J]. Engineering Applications of Artificial Intelligence, 2016, 49: 176–193.
- [17] 郑建华, 刘双印, 贺超波, 等. 基于混合采样策略的改进随机森林不平衡数据分类算法 [J]. 重庆理工大学学报: 自然科学版, 2019, 33(7): 113–123.