

DOI:10.11784/tdxbz202401015

基于双路径特征融合的轻量级脑肿瘤分割网络

李 镛, 阮方号, 关 欣
(天津大学微电子学院, 天津 300072)

摘要: 脑肿瘤是世界上最致命的癌症之一, 从三维核磁共振图像(MRI)中快速、准确地分割正常脑组织和恶性肿瘤组织, 对临床诊断和手术治疗都至关重要。近年来, 基于卷积神经网络的分割架构, 特别是 3D U-Net 架构在脑肿瘤分割方面取得了巨大成功。然而, 现有的基于 3D U-Net 的网络存在下采样信息丢失的问题, 缺乏自动聚焦小尺度病灶的能力, 编码器和解码器之间的全局上下文信息交互不够充分, 并且参数量大、计算开销高。针对上述问题, 提出一种双路径特征融合的轻量级脑肿瘤分割网络。首先, 该网络通过增加一条分支路径, 将原始数据中的低级细节信息添加到编码器的各层中, 弥补下采样带来的特征信息损失。其次, 提出一种多层金字塔制导模块代替传统的跳跃连接, 增强解码器不同层次的全局上下文信息获取能力。最后, 在输出层引入多视图级联注意力模块, 利用肿瘤不同区域的包含关系, 使网络从各个视图自动聚焦小尺度肿瘤区域。在 BraTS2020 数据集上的实验结果表明, 采用 0.55×10^6 参数量和 41.21×10^9 浮点运算次数, 该网络在增强肿瘤、全肿瘤和肿瘤核心的 Dice 系数分别可达 78.64%、89.51% 和 83.77%。此外, 在 BraTS2018 数据集上进一步评估该网络的性能, 实验结果表明: 该网络在保持较小计算量的同时, 显著提高了对脑肿瘤各病灶区域的定位能力和分割性能, 在临床实践中具有重要意义。

关键词: 核磁共振图像; 脑肿瘤分割; 轻量级; 双路径; 多视图级联; 多层金字塔制导

中图分类号: TP391.41 **文献标志码:** A **文章编号:** 0493-2137(2024)11-1177-10

Lightweight Brain Tumor Segmentation Network Based on Dual-Path Feature Fusion

Li Qiang, Ruan Fanghao, Guan Xin
(School of Microelectronics, Tianjin University, Tianjin 300072, China)

Abstract: Brain tumors rank among the most lethal forms of cancer worldwide. The fast and accurate segmentation of normal brain tissue and malignant tumor tissue from 3D magnetic resonance imaging (MRI) scans is crucial for clinical diagnosis and surgical treatment. In recent years, convolutional neural network-based segmentation architectures, particularly those using 3D U-Net architectures, have shown exceptional success in this area. However, the existing 3D U-Net-based networks often face significant challenges, including loss of information during down-sampling. They also cannot automatically focus on small-scale foci, fail to incorporate sufficient global context information interaction between encoder and decoder, and possess a large parameter size that induces high computation costs. To overcome these limitations, we propose a lightweight brain tumor segmentation network that utilizes dual-path feature fusion. First, our network enriches each encoder layer with low-level details from the original data through an additional branch path. This design compensates for the loss of feature information typically caused by down-sampling. Second, we introduce a multilayer pyramid guidance module. This module serves as a sophisticated alternative to traditional skip connections, significantly enhancing the acquisition of global context information at different levels of the decoder. Lastly, our network features a multiview cascading attention module in the output layer. This module automatically focuses on small-scale tumor regions from each view, utilizing the inclusion relationship

收稿日期: 2024-01-21; 修回日期: 2024-04-16.

作者简介: 李 镛 (1974—), 男, 博士, 教授.

通信作者: 李 镛, liqiang@tju.edu.cn.

基金项目: 天津市自然科学基金资助项目 (22JCZDJC00220); 超声医学与工程国家重点实验室基金资助项目 (2022KFKT004).

Supported by the National Natural Science Foundation of Tianjin, China (No. 22JCZDJC00220), the Foundation of State Key Laboratory of Ultrasound in Medicine and Engineering (No. 2022KFKT004).

between different tumor regions. Our extensive testing on the BraTS2020 data set has yielded promising results, with Dice coefficients of 78.64%, 89.51%, and 83.77% for enhanced tumor region, whole tumor region, and tumor core, respectively. These achievements were accomplished using only 0.55×10^6 parameters and involving 41.21×10^9 floating point operations. Further validation of the BraTS2018 data set confirmed the network's superior performance in localizing and segmenting various focal regions of brain tumors while maintaining a small computational load, which is particularly significant in clinical practice.

Keywords: magnetic resonance imaging (MRI); brain tumor segmentation; lightweight; dual-path; multiview cascading; multilayer pyramid guidance (MPG)

脑肿瘤是发病率和致死率极高的癌症之一,根据国家癌症中心在 2022 年发布的数据显示^[1],2016 年中国脑肿瘤发病人数达 10.90 万人,死亡人数高达 5.85 万人.目前在医学上常用核磁共振成像(magnetic resonance imaging, MRI)进行脑部病变检查.对于脑部 MRI 来说,常见的模态图像有以下 4 种:流体衰减反演恢复图像 (FLAIR)、t1 加权图像(T1)、对比度增强 t1 加权图像(T1CE)和 t2 加权图像(T2)^[2].由于恶性脑肿瘤的攻击性强,生长速度快,病人的预期寿命不到两年.因此,精确分割肿瘤的位置和结构,对于脑肿瘤的诊断和治疗计划的制定都至关重要.但脑肿瘤通常具有形态不同、边界各异和大小不一等特点^[3],人工分割往往错误率高,耗时耗力.因此,研究一种自动、准确的脑肿瘤分割系统具有重要意义.

近年来,深度学习尤其是卷积神经网络(convolutional neural network, CNN)已被广泛应用于医学图像分类^[4-5]、检测^[6]、分割^[7]等图像处理任务^[8].Ronneberger 等^[9]提出编解码 U-Net 网络,与传统的全卷积网络(fully convolutional network, FCN)^[10]相比,编码器与解码器之间的特征映射拼接可以保持较完整的上下文信息,但不可避免地丢失了三维空间特征信息和背景信息.Çicek 等^[11]将 U-Net 网络由 2D 扩展为 3D,可以更好地利用空间特征信息,提升了分割精度,然而在编码器下采样阶段会造成部分特征信息损失.Chen 等^[12]将变压器(transformer)^[13]与 U-Net 相结合,通过变压器对 CNN 特征图标记化图像补丁进行编码,实现脑肿瘤的精确定位.但其模型的复杂度和计算量大大增加,对硬件资源的要求更高.为了降低计算开销,轻量级分割网络已成为研究热点.例如,Chen 等^[14]提出一种扩张多纤维网络(dilated multi-fiber network, DMF-Net),在 3D U-Net 基础上引入各种大小的扩张卷积,在显著降低模型计算成本的同时保持较高分割精度.然而,编解码器间信息交换不良的问题没有得到解决.Zhou 等^[15]提出一种有效的 3D 残差神经网络(efficient 3D residual neural network, ERV-Net),引入带有残差的解码器避

免退化,但是编码器各层的特征提取能力明显不足.Luo 等^[16]提出一种轻量级的分层解耦卷积网络(hierarchical decoupled convolutional network, HDC-Net),使用分层解耦卷积单元替代三维卷积,高效地探索多尺度多视图空间背景,进一步降低了计算开销.但是伪三维卷积对有用特征映射的聚焦不足,存在脑肿瘤小区域分割精度不足的缺点.

针对上述轻量级网络的问题,本文提出一种基于双路径特征融合的轻量级脑肿瘤分割网络(network based on dual-path feature fusion, DPFF-Net),进一步提高分割精度和保持较低的计算成本.首先,该网络主体采用两条下采样路径相融合的架构,其中从原始数据延伸的路径能够很好地弥补编码器下采样路径中丢失的细节特征信息,增强网络的特征提取能力.其次,设计轻量级的动态解耦特征提取(dynamic decoupling feature extraction, DDF)模块,将两条路径得到的特征进行多尺度提取和融合.然后,提出多层金字塔制导(multilayer pyramid guidance, MPG)模块来代替传统的跳跃连接,为解码器提供编码器中不同层次的全局上下文信息,提高编解码器之间的语义信息交互水平.最后,引入多视图级联注意力(multiview cascading attention, MVCA)模块,自动聚焦小目标区域,提高小尺度病灶的分割精度.

1 网络模型

1.1 整体网络框架

图 1 显示本文所提网络 DPFF-Net 的完整框架,包括 3 个重要部分,其中卷积块上面的数字表示相应特征图的大小(通道 \times 深度 \times 宽度 \times 高度).

(1) 由并行特征提取网络(parallel feature extraction network, PFE-Net)组成的基准网络.在编码阶段,第 1、2、3 层都使用周期性下移操作(period down-shuffling, PDS)^[17]对原始数据进行下采样,这是一种只对图像进行切割和拼接的下采样操作,因此能够保持图像的完整信息.在 PDS 操作得到的原始数据特征和卷积下采样得到的特征拼接后,使用

DDF 模块将拼接后的特征图进行多尺度、多视图提取和融合。在解码阶段,采用步长为 2 的 $3 \times 3 \times 3$ 反卷积进行 3 次上采样,将图像的分辨率逐层恢复到原始图像的尺寸。

(2) 多层金字塔制导(MPG)模块. 利用 MPG 模块将编码器不同层级的语义信息进行组合后,与解码器阶段对应层次的特征信息进行融合,为解码器不同

层次挖掘和融合丰富的全局或局部上下文信息,实现图像特征信息的充分利用。

(3) 多视图级联注意力(MVCA)模块. 在经过网络粗分割的基础上,利用 MVCA 模块提高对小区域的关注和定位,实现对小目标区域的精细分割,然后输出对应的三维分割结果。

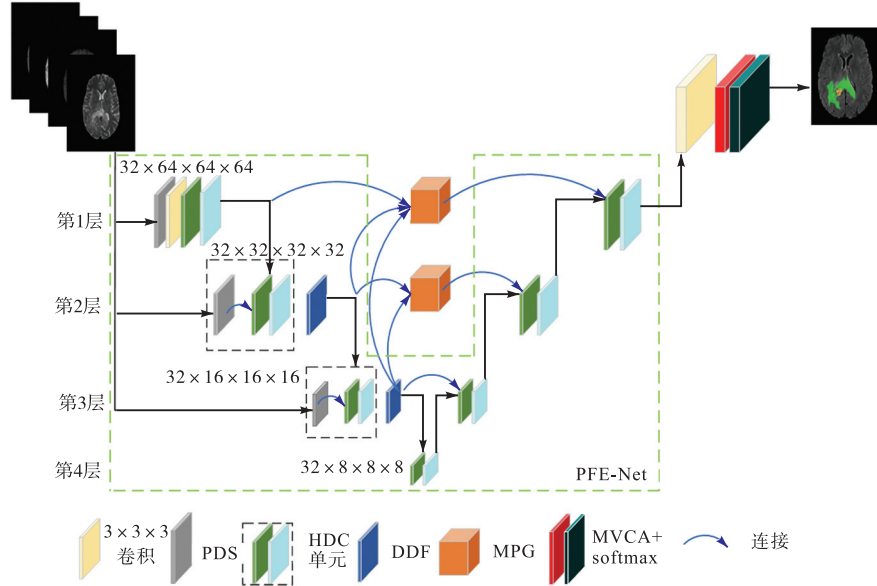


图 1 DPFF-Net 网络框架

Fig.1 DPFF-Net network framework

1.2 并行特征提取网络

本文设计的基准网络——并行特征提取网络(PFE-Net),以分层解耦卷积(hierarchical decoupled convolution, HDC)为基本单元,该单元使用两种伪三维卷积分解代替传统的三维卷积,并且分层进行特征提取,增强模型的空间信息感知能力,仅用低维核来提升精度,在精确分割脑肿瘤的同时显著减少了计算开销,实现了轻量级的要求。

然而,HDC 单元在降低计算量的同时,使用伪三维卷积将会丢失部分细节信息,导致特征提取不足,影响小病灶分割精度.为了解决这一问题,本文提出一种多级 PDS 模块作为分支路径的双路径特征采样架构,用来补充原始数据信息,如图 1 所示.使用不同大小的 PDS 模块为不同层次、不同尺寸的编码器特征提供相对应的原始数据特征,能够有效加强深层特征和浅层特征的联系,提高细节信息的利用率和模型的拟合能力。

为了使原始数据的浅层特征和经过 HDC 单元下采样后的深层特征能够更好地匹配和融合,本文提出一种动态解耦特征提取(DDF)模块,如图 2 所示,其中 $3 \times 3 \times 1$ 、 $1 \times 3 \times 3$ 表示三维卷积核大小, d 表示空

洞卷积扩张率, $d = 1, 2, 3, 4$. 该模块首先将输入通道数为 n 的特征图切分为 4 组,对每组特征图使用扩张率不同的伪三维卷积($3 \times 3 \times 1$ 卷积),在扩大感受野的同时减少参数量,然后将提取到的特征图进行融合.同时,对融合过的特征图再使用第 2 次伪三维卷积($1 \times 3 \times 3$ 卷积),用于提取互补视图上的空间上下文特征.接着利用残差连接与原分组特征进行融合,以此来增强对空间信息和细节信息的捕获,弥补伪三维卷积的缺点.最后在整个 DDF 模块的外部再次采用残差连接,可以将原始图像特征信息从下层传递到上层,补充下采样过程中丢失的信息。

1.3 多层金字塔制导模块

本文提出一种多层金字塔制导(MPG)模块用来代替传统的跳跃连接,第 1 层 MPG 模块如图 3 所示.在 MPG 模块中,将每层的特征映射和高层的特征相结合重构跳跃连接,可以将编码器阶段深层和浅层的全局语义信息逐步引入到解码器的不同阶段,实现多阶段语义信息互通,解决传统跳跃连接上下文信息提供能力不足的问题,提高了模型对脑肿瘤边界、类别等的分割能力。

具体而言,首先通过不同膨胀率的 $3 \times 3 \times 3$ 空洞

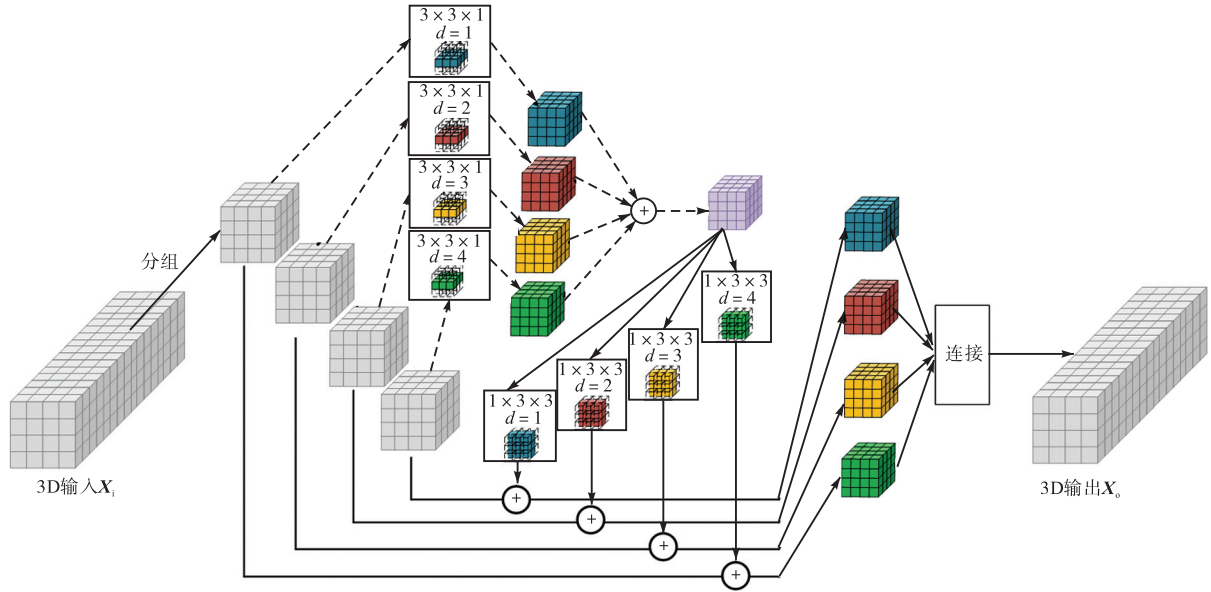


图 2 动态解耦特征提取 (DDF) 模块结构

Fig.2 Structure of the dynamic decoupling feature extraction (DDF) module

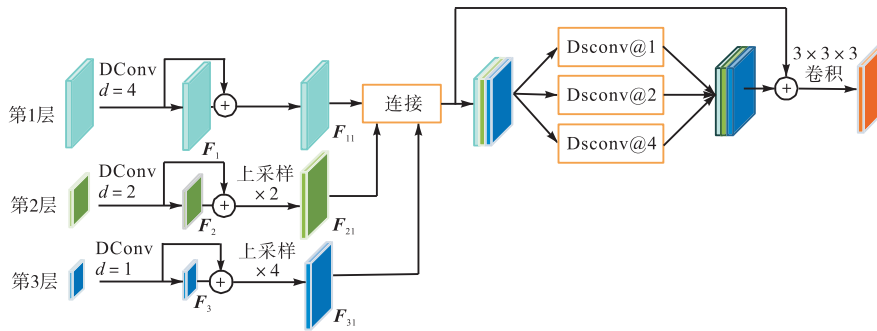


图 3 多层金字塔制导 (MPG) 模块结构

Fig.3 Structure of the multilayer pyramid guidance (MPG) module

卷积将所有层的特征映射到与第 1 层相同的通道空间,再采用残差连接将原始特征图融合到空洞卷积提取后的特征图中.接下来,将生成的特征映射 F_2 和 F_3 上采样到与 F_1 相同尺寸,得到特征映射 F_{21} 、 F_{31} ,将特征图 F_{11} 、 F_{21} 和 F_{31} 进行通道拼接.然后,为了从不同层次的特征映射中提取到全局上下文信息,本文使用膨胀率分别为 1、2 和 4 的 3 个并行的可分离卷积 (Dsconv@1, Dsconv@2, Dsconv@4),并再次使用残差连接.值得注意的是,随着层次的不同,采用平行路径的数量和膨胀率也不同.最后,使用 $3 \times 3 \times 3$ 卷积输出最终的特征图.综上所述,各层次的 MPG 模块可以总结为

$$\begin{cases} F_{ik} = \text{DConv}_{d=2^{3-i}}(X_i) + X_i & i \in [k, 3], k=1, 2 \\ G_k = C_k^3(F_i \& 2^{i-k}) \\ M_k = \text{Conv}\{C_k^3(\text{Dsconv}@2^{i-k}(F_{ik})) + G_k\} \end{cases} \quad (1)$$

式中: k 为网络第 i 层 MPG 模块的层数; i 为网络第 i

层输出特征的层数,当 $k=1$ 时, $i=1, 2, 3$ (即网络第 1 层 MPG 模块的输入为网络第 1、2、3 层的输出特征);当 $k=2$ 时, $i=2, 3$ (即网络第 2 层 MPG 模块的输入为网络第 2、3 层的输出特征); M_k 为第 k 层 MPG 模块的输出; F_i 为网络第 i 层的输出特征经过空洞卷积和残差连接的输出; $\&2^{i-k}$ 为速率 2^{i-k} 的上采样操作; C_k^3 为网络第 k 层到第 3 层特征的连接操作; $\text{DConv}_{d=2^{3-i}}$ 为空洞率 2^{3-i} 的空洞卷积; $\text{Dsconv}@2^{i-k}$ 为空洞率 2^{i-k} 的深度可分离卷积.为降低模型参数量,实现轻量级分割,本文只使用 2 个 MPG 模块.

1.4 多视图级联注意力模块

脑肿瘤分割算法的最终目标是实现脑肿瘤图像中 3 个子区域 (全肿瘤 (whole tumor, WT)、肿瘤核心 (tumor core, TC) 和增强肿瘤 (enhanced tumor, ET)) 的多类分割.

如图 4 的真值标签所示,从层次结构上来看,绿

色区域为肿瘤周围水肿(peritumoral edema, ED),黄色区域为 ET,红色区域为坏死及非增强肿瘤(necrotic and non-enhancing tumor, NCR & NET). WT 则由水肿和 TC 组成,TC 由坏死、非增强性肿瘤和 ET 组成,因此 WT、TC、ET 呈相互包含的关系. 由此可以根据子区域层次关系,利用模型级联(model cascading, MC)^[18]策略将多类分割问题转化为多任务问题.




图4 真值标签

Fig.4 Ground truth

然而,使用该策略的缺点是需要将3个任务集成

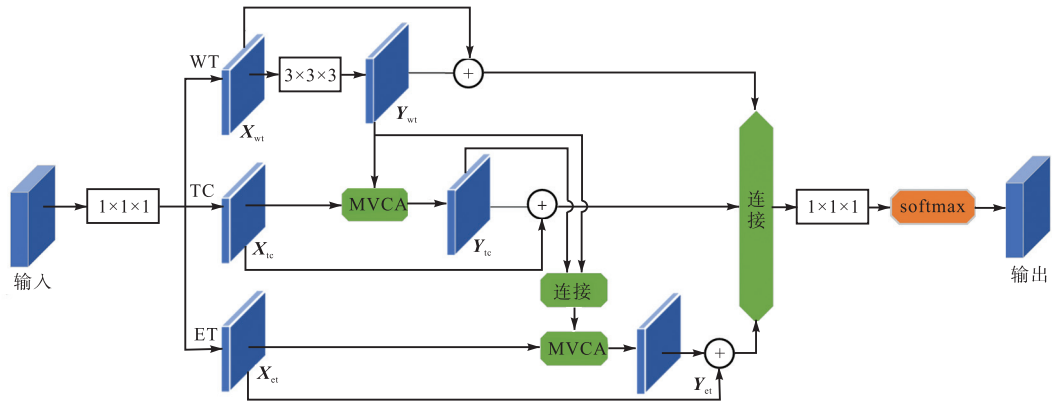


图5 多视图级联注意力网络(MVCAN)结构

Fig.5 Structure of the multiview cascading attention network (MVCAN)

如图5所示,MVCAN注意力网络具体实现过程如下.首先,将输入 X 按通道切片划分为3个任务分支输入, X_{wt} 使用 $3 \times 3 \times 3$ 卷积来提取特征并生成该分支的输出 Y_{wt} .其中 Y_{wt} 包含TC和ET区域的信息,将 X_{tc} 和 Y_{wt} 特征图添加到MVCA注意力模块中,能够利用 Y_{wt} 注意图来指导TC区域的分割,生成该分支的输出 Y_{tc} .然后,将 Y_{wt} 、 Y_{tc} 的特征映射拼接起来,指导ET区域分割,生成该分支的输出 Y_{et} .最后,将每个分支的输出 Y_{wt} 、 Y_{tc} 、 Y_{et} 与原始输入 X_{wt} 、 X_{tc} 、 X_{et} 进行残差连接后拼接起来,通过 $1 \times 1 \times 1$ 卷积和softmax后,得到MVCAN注意力网络的输出特

到一个网络中,3个几乎相同的网络训练方式大大增加了模型冗余,并且多个网络之间缺乏相关性.为了解决单个模型中的上述问题,本文提出一种轻量级的多视图级联注意力网络(multiview cascading attention network, MVCAN),如图5所示.首先通过本文提出的轻量化网络(PFE-Net + MPG模块)对输入图像进行粗分割,然后在粗分割的基础上进行通道分离产生3个两类分割任务,即WT、TC和ET分割任务,在不同任务分支之间引入MVCA模块,从多视图的角度捕获层次区域间潜在的相关性,为子区域的精细分割提供隐式指导.MVCAN结构用公式可表示为

$$Y_{wt} = \text{Conv}_{3 \times 3 \times 3}(X_{wt}) \quad (2)$$

$$Y_{tc} = X_{tc} \otimes (\text{MVCA}(Y_{wt})) \oplus X_{tc} \quad (3)$$

$$Y_{et} = X_{et} \otimes (\text{MVCA}(C(Y_{wt}; Y_{tc}))) \oplus X_{et} \quad (4)$$

$$Y_{out} = F_s [C(Y_{wt} + X_{wt}; Y_{tc} + X_{tc}; Y_{et} + X_{et})] \quad (5)$$

式中: X_{wt} 、 X_{tc} 、 X_{et} 为每一个任务分支的输入特征图; Y_{wt} 、 Y_{tc} 、 Y_{et} 为每一个任务分支的输出特征图; Y_{out} 为MVCAN的输出结果; F_s 为softmax操作; C 为连接操作;MVCA(\cdot)为经过MVCA注意力模块生成的注意图; \otimes 表示将两个特征图做乘积运算; \oplus 表示将两个特征图做加法运算.

征映射 Y_{out} .其中MVCA模块用公式表示为

$$F_a = F_R (F_B (F_1)) \oplus F_R (F_B (F_2)) \oplus F_R (F_B (F_3)) \quad (6)$$

$$M_{out} = F_{\text{sigmoid}}(F_a) \otimes X \oplus X \quad (7)$$

式中: X 为注意力模块的输入; M_{out} 为MVCA注意力模块的输出; F_1 、 F_2 、 F_3 分别为来自WT或TC区域的特征经过 $1 \times 3 \times 3$ 、 $3 \times 1 \times 3$ 、 $3 \times 3 \times 1$ 空洞卷积得到的输出; F_B 为批归一化; F_R 为ReLU激活函数; F_{sigmoid} 为sigmoid层; \otimes 表示两个特征图做乘积运算; \oplus 表示两个特征图做加法运算.

MVCA 模块的详细结构如图 6 所示. 来自 WT 或者 TC 区域的特征映射 Y_{wt} 、 Y_{tc} 经过伪三维空洞卷积提取大区域的多视图信息, 再由 sigmoid 层生成注意力映射. 将来自 TC 或者 ET 区域的特征输入与相对应的注意力映射相乘, 然后通过残差结构与自身相加, 从而实现对待分割小区域病变的精确定位. 实验中发现, 仅 TC 分支无法给 ET 区域提供足够的位置信息, 因此在本研究中将 Y_{wt} 、 Y_{tc} 连接起来, 扩充足够的定位信息, 指导 ET 任务分割.

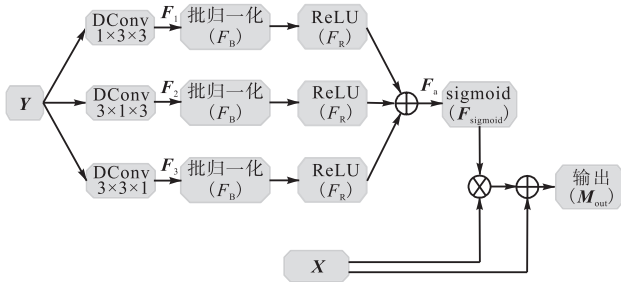


图 6 多视图级联注意力 (MVCA) 模块结构

Fig.6 Structure of the multiview cascading attention (MVCA) module

2 实验与结果

2.1 实验环境与数据集

本文实验使用 PyTorch 深度学习框架, 服务器为 Ubuntu 16.04、CPU Inter® Core i9-9900x (3.5 GHz)、GPU Nvidia GTX2080Ti (11 GB) × 4. 实验参数设置如下: 批处理量为 8, 最大迭代次数为 900. 使用 Adam 优化器对网络进行优化, 初始学习率为 $l_0 = 1 \times 10^{-3}$. 本文采用 L2 范数作为归一化系数, 初始值为 1×10^{-5} . 在网络训练过程中, 对训练集采用随机裁剪、随机旋转、随机强度偏移的数据增强方法来增加训练数据量, 增强算法的鲁棒性和泛化能力.

为了验证网络的通用性和泛化性, 本文使用两个数据集进行实验, 分别为 BraTS2018 数据集 (包括 285 名患者的训练集样本和 66 名未标记患者的验证集样本) 和 BraTS2020 数据集 (包括 369 名患者的训练集样本和 125 名未标记患者的验证集样本). 训练集的每个样本包括 4 个 MRI 模态图像 (FLAIR、T1、T1CE、T2) 和一个真值标签. 所有 MRI 图像的尺寸为 $240 \text{ mm} \times 240 \text{ mm} \times 155 \text{ mm}$, 体素间距为 $1 \text{ mm} \times 1 \text{ mm} \times 1 \text{ mm}$. 真值标签如图 4 所示, 包括肿瘤周围水肿 (ED), 标签值为 2; 增强肿瘤 (ET), 标签值为 4; 坏死及非增强肿瘤 (NCR & NET), 标签值为 1. 全肿瘤 (WT) 由标签 1、2 和 4 组成, 肿瘤核心 (TC) 由标签

1 和 4 组成, ET 由标签 4 组成. 由于验证集不包括真值标签图, 因此预测分割结果需要上传到在线平台 (<https://ipp.cbica.upenn.edu>) 进行验证.

2.2 评估指标

本文通过计算网络复杂度和分割精度作为综合指标, 来评价脑肿瘤分割算法的性能. 分割精度采用 Dice 系数和豪斯多夫距离 (HD) 来衡量. Dice 系数表示预测肿瘤和真实肿瘤之间的相似度. Dice 系数越高, 表示算法对脑肿瘤的分割效果越好, 用公式可表示为

$$\text{Dice} = 2 \times \frac{|P \cap T|}{|P| + |T|} \quad (8)$$

豪斯多夫距离 (HD) 表示两组点之间的最大不匹配程度, 用来衡量预测的分割结果与真值标签之间的距离, 用公式表示为

$$\text{HD} = d(P, T) = \max \left\{ \sup_{p \in P} \inf_{t \in T}, \sup_{t \in T} \inf_{p \in P} d(t, p) \right\} \quad (9)$$

式中: P 、 T 分别表示预测脑肿瘤区域和真实标记脑肿瘤区域的体素集; p 、 t 分别表示两个体素集中的体素.

通过网络参数量 M 和浮点运算次数 F 对计算复杂度进行定量分析, 用公式分别表示为

$$M = k_d \times k_h \times k_w \times C_{in} \times C_{out} \quad (10)$$

$$F = 2 \times (k_d \times k_h \times k_w \times C_{in}) \times C_{out} \times d \times h \times w \quad (11)$$

式中: k_d 、 k_h 、 k_w 分别表示卷积核的深度、高度和宽度; C_{in} 、 C_{out} 表示输入和输出的通道数量; d 、 h 、 w 分别表示图像的深度、高度和宽度.

2.3 实验结果与分析

2.3.1 在 BraTS2020 数据集上的消融实验

本文所有消融实验均在 BraTS2020 数据集上进行, 实验结果如表 1 所示. 实验采用本文提出的并行特征提取网络 PFE-Net 作为基准网络, 同时在 PFE-Net 中加入不同的改进策略来观察分割效果.

本文采用的基准网络 PFE-Net 是在 HDC-Net 的基础, 通过增加一条多级 PDS 模块的分支路径所构成. PFE-Net 相较于 HDC-Net 的模型参数量和计算量略有增加, 但是 ET、TC 区域 Dice 系数分别提升 1.50% 和 0.43%. 这表明 PFE-Net 通过增强对细节特征的充分提取和利用, 显著提高了分割精度. 此外, 在 PFE-Net 上加入 MVCA 注意力模块, 参数量和计算量基本上没有变化, 但是 ET、WT、TC 区域的 Dice 系数分别提升 0.16%、0.26% 和 0.47%, 这表明 MVCA 模块能够在对较小肿瘤区域分割时提供更准确的定位. 其次, 在 PFE-Net 上加入 MPG 模块, 分割精度得

到进一步提升,ET、TC 区域的 Dice 系数分别提升 0.51% 和 1.73%, 这表明 MPG 模块可以增加解码器获取全局上下文信息的能力,提升整体分割效果. 最后,在基准网络 PFE-Net 上同时加入 MVCA 和 MPG 模块,即为本文所提的网络 DPFF-Net, Dice 系数和

豪斯多夫距离总体上达到了最佳性能.

图 7 显示消融实验三视图分割结果的可视化图像,图中的每一行代表不同的病例,DPFF-Net 的分割结果比单一网络更接近真值标签,具有更好的分割效果,进一步验证了本文改进方法的有效性.

表 1 在 BraTS2020 数据集上的消融实验

Tab.1 Ablation experiments on the BraTS2020 validation set

网络	参数量/ 10^6	浮点运算次数/ 10^9	Dice 系数/%			HD/mm		
			ET	WT	TC	ET	WT	TC
HDC-Net	0.29	25.62	76.42	89.02	80.86	35.82	9.61	13.02
PFE-Net (HDC-Net + PDS)	0.38	26.57	77.92	89.45	80.71	27.24	5.73	13.59
PFE-Net + MVCA	0.38	26.74	78.08	89.71	81.18	29.33	4.93	17.78
PFE-Net + MPG	0.55	41.03	78.43	89.50	82.44	29.23	8.17	9.61
DPFF-Net (PFE-Net + MVCA + MPG)	0.55	41.21	78.64	89.51	83.77	26.33	7.43	8.36

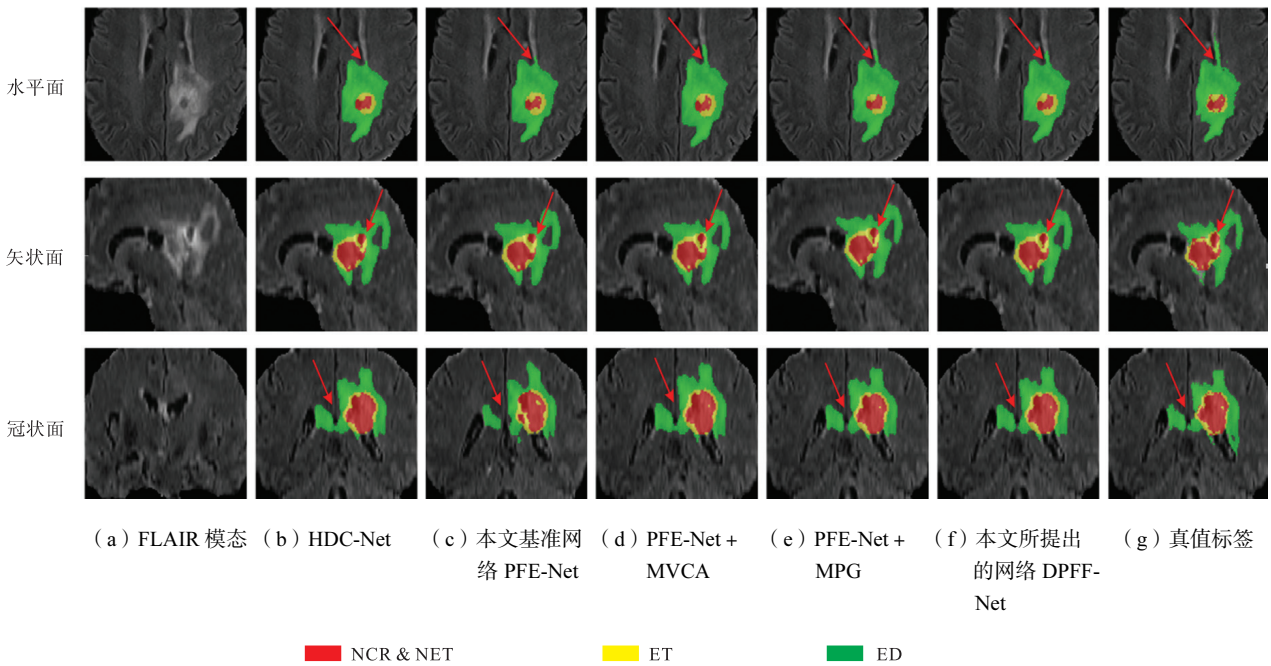


图 7 消融实验分割结果的可视化图像

Fig.7 Visualization of the segmentation results from the ablation experiments

2.3.2 非轻量级脑肿瘤网络对比实验

为了验证本文所提网络的有效性,本文比较了 DPFF-Net 与其他非轻量级模型在 BraTS2020 数据集上的分割性能,实验结果如表 2 所示. 对于多区域脑肿瘤分割,由于 3D U-Net 及其变体具有较强的竞争力,因此本文选取 Akbar 等^[19]提出的基于单层 3D U-Net 的脑肿瘤分割网络、ME-Net^[20]、CASPIANET++^[21]等先进 U-Net 网络进行比较. 此外,基于 Transformer 的网络能打破 CNN 远程建模的局限性,在脑肿瘤分割上取得了领先的分割精度,因此本文选取 SwinBTS^[22]、TransBTS^[23]等先进 Transformer 网络进行对比.

表 2 结果^[11-12,19-27]表明,与先进 TransBTS 模型相比,DPFF-Net 的参数量减少 32.25×10^6 ,浮点计算

次数减少 291.88×10^9 ,而在 ET、WT、TC 区域的 Dice 系数分别提升 0.14%、0.51%、2.41%. 与其他非轻量级网络相比,所提出的 DPFF-Net 不仅具有低复杂度、低计算量的优势,而且分割精度得到大幅提升. 因此,DPFF-Net 在非轻量级网络中具有较强的竞争力.

2.3.3 轻量级脑肿瘤网络对比实验

为了验证本文所提网络的综合性能,本文依据低复杂度、高分割精度的原则,选取 DMF-Net 等高性能的轻量化网络与 DPFF-Net 进行对比. 实验结果见表 3 和图 8,表 3 中的数据为使用 BraTS2020 数据集对模型再训练所得.

从表 3 可以看出,DPFF-Net 只使用了 3D ESP-Net^[26]1/6 左右的参数量和 1/2 左右的浮点运算次数,

而 ET、WT 和 TC 的 Dice 系数有了大幅提高,分别提升 9.64%、2.41% 和 5.17%。与 DMF-Net 相比, DPFF-Net 的参数数量减少 85.80%, 而 Dice 系数平均

提升 1.31%。以上分析表明, 本文所提出的轻量化改进方法是可行的。

表 2 非轻量级脑肿瘤网络对比实验

Tab.2 Comparison experiment of non-lightweight brain tumor network

网络	参数量/ 10^6	浮点运算次数/ 10^9	Dice 系数/%			HD/mm		
			ET	WT	TC	ET	WT	TC
3D U-Net ^[11]	16.21	1 669.53	68.76	84.11	79.06	50.98	13.37	13.61
V-Net ^[24]	—	—	68.79	86.11	77.90	43.52	14.49	16.15
ME-Net ^[20]	—	—	70.00	88.00	74.00	38.60	6.95	30.18
Residual U-Net ^[25]	—	—	71.63	83.46	76.47	37.42	12.43	13.11
Attention U-Net ^[26]	—	—	71.83	85.57	75.96	32.94	11.91	19.43
Akbar 等 ^[19]	—	—	72.91	88.57	80.19	31.97	10.26	13.58
CASPIANET++ ^[21]	—	—	77.37	89.26	81.56	27.13	7.22	9.45
Vu 等 ^[27]	—	—	77.17	90.55	82.67	27.04	4.99	8.63
SwinBTS ^[22]	—	—	77.36	89.06	80.30	26.84	8.56	15.78
TransUNet ^[12]	105.00	1 205.76	78.42	89.46	78.37	12.85	5.97	12.84
TransBTS ^[23]	32.80	333.09	78.50	89.00	81.36	16.67	6.47	10.47
DPFF-Net(本文网络)	0.55	41.21	78.64	89.51	83.77	26.33	7.43	8.36

本文的基准网络以 HDC-Net 为基础, 但由于 HDC-Net 网络设计过于简化, 导致其在肿瘤 3 个区域的分割指标上表现欠佳。与 HDC-Net 相比, DPFF-Net 在 ET、WT 和 TC 上 Dice 系数分别提升 2.22%、0.49% 和 2.91%, HD 分别缩短 9.49 mm、2.18 mm 和 4.66 mm。

略有增加, 但在肿瘤亚区边界和子区域大小的分割上, 特别是对边界小病灶的精确分割上, 表现更为优异。下面通过可视化分析验证其性能, 本文选取具有竞争力的轻量级网络 DMF-Net 和 HDC-Net 进行分割结果的可视化分析。图 8 分别展示了 BraTS2020 训练集的 3 个随机病例。如图 8(b) 所示, HDC-Net 能够分割出肿瘤的大致形状, 但对于单独的小病变区

DPFF-Net 尽管在网络参数量和浮点运算次数上

表 3 轻量级脑肿瘤分割网络对比实验

Tab.3 Comparison experiment of the lightweight brain tumor segmentation network

网络	参数量/ 10^6	浮点运算次数/ 10^9	Dice 系数/%			HD/mm		
			ET	WT	TC	ET	WT	TC
3D ESP-Net ^[28]	3.36	76.51	69.00	87.10	78.60	31.29	7.10	14.61
DMF-Net ^[14]	3.88	27.04	76.41	90.08	81.50	35.17	7.17	12.17
HDC-Net ^[16]	0.29	25.62	76.42	89.02	80.86	35.82	9.61	13.02
DPFF-Net(本文网络)	0.55	41.21	78.64	89.51	83.77	26.33	7.43	8.36

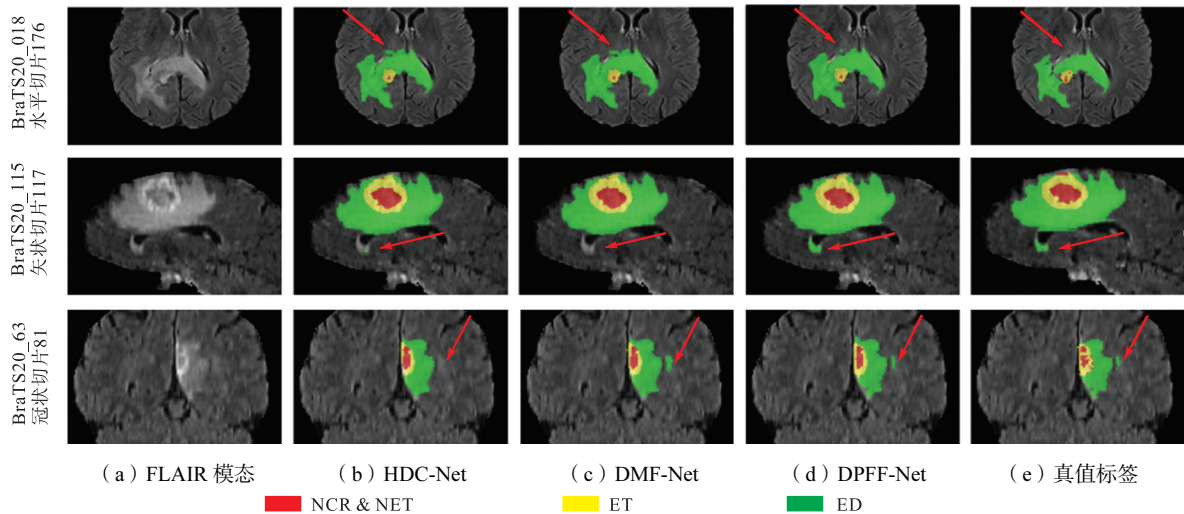


图 8 不同网络分割结果的可视化图像

Fig.8 Visualizations of different network segmentation results

域,其分割效果并不理想. DMF-Net 的分割结果如图 8(c) 所示,其在零星病变区域和边界分割上存在过度分割的现象,与真值标签存在较大差距. DPFF-Net 的分割结果如图 8(d) 所示,其分割出的肿瘤区域与真值标签更为接近,尤其是全肿瘤区域和边界病变方面,充分验证了 DPFF-Net 的优异性能.

2.3.4 在 BraTS2018 数据集上的对比实验

为了评估 DPFF-Net 的广义性能和泛化能力,本文还比较了 DPFF-Net 与其他轻量级模型在 BraTS

2018 数据集上的分割性能.

在 BraTS2018 数据集上得到的结果如表 4 所示. DPFF-Net 在 ET、WT、TC 区域的 Dice 系数分别为 80.93%、90.74%、85.11%,与 3D ESP-Net 和 DMF-Net 相比具有更少的参数和更高的分割精度,与 Akbar 等^[19]提出的网络相比,在 ET、WT、TC 区域的 Dice 系数分别提升 3.22%、1.15%、5.34%,HD 分别减少 1.25 mm、4.09 mm、3.71 mm. 因此,DPFF-Net 在轻量级和非轻量级网络中展现出更强的竞争力.

表 4 在 BraTS2018 数据集上的对比实验

Tab.4 Comparative experiments on the BraTS2018 data set

网络	参数量/ 10^6	浮点运算次数/ 10^9	Dice 系数/%			HD/mm		
			ET	WT	TC	ET	WT	TC
3D U-Net ^[11]	16.21	1 669.53	75.96	88.53	71.77	6.04	17.10	11.62
3D ESP-Net ^[28]	3.36	76.51	73.70	88.30	81.40	5.30	5.46	7.85
DMF-Net ^[14]	3.88	27.04	80.12	90.62	84.54	3.06	4.66	6.44
HDC-Net ^[16]	0.29	25.62	80.90	89.70	84.70	2.43	4.62	6.12
Akbar 等 ^[19]	—	—	77.71	89.59	79.77	3.90	9.13	8.67
Zhang 等 ^[29]	—	—	78.20	89.60	82.40	3.57	5.73	9.27
DPFF-Net(本文网络)	0.55	41.21	80.93	90.74	85.11	2.65	5.02	4.96

3 结 语

本文提出一种双路径特征融合的轻量级脑肿瘤分割网络 DPFF-Net,在保持低复杂度的同时,有效提高了脑肿瘤不同区域的分割精度.通过双路径结构,最大限度地充分融合原始特征信息,补充下采样过程中丢失的细节信息.采用 MPG 模块代替传统的跳跃连接,填补传统跳跃连接由于接受域不匹配而产生的语义缺口,动态挖掘和融合多尺度上下文信息.同时,在粗分割的基础上使用 MVCA 模块,利用肿瘤区域相互关联的性质进行精细分割,提高肿瘤小区域的分割精度.

在 BraTS2020 数据集上的实验结果表明,DPFF-Net 在 ET、WT 和 TC 区域上的平均 Dice 系数分别达到 78.64%、89.51% 和 83.77%,参数量仅为 0.55×10^6 ,浮点运算次数仅为 41.21×10^9 .同时,通过与当前先进的轻量级网络进行对比,验证了 DPFF-Net 在分割精度和运算资源消耗方面具有显著的优势,可以为临床医生进行脑肿瘤分割提供有力的参考.

参考文献:

- [1] Zheng R S, Zhang S W, Zeng H M, et al. Cancer incidence and mortality in China, 2016[J]. Journal of the National Cancer Center, 2022, 2(1): 1-9.
- [2] 李 镝, 苏雅梦, 关 欣. 变分自编码的分层解耦卷积脑肿瘤分割网络[J]. 天津大学学报(自然科学与工

程技术版), 2023, 56(7): 767-775.

Li Qiang, Su Yameng, Guan Xin. A variational autoencoding-hierarchical decoupled convolutional brain tumor segmentation network[J]. Journal of Tianjin University(Science and Technology), 2023, 56(7): 767-775 (in Chinese).

- [3] Kamnitsas K, Ledig C, Newcombe V F J, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation[J]. Medical Image Analysis, 2017, 36: 61-78.
- [4] Mehnatkesh H, Jalali S M J, Khosravi A, et al. An intelligent driven deep residual learning framework for brain tumor classification using MRI images[J]. Expert Systems with Applications, 2022, 213: 119087.
- [5] 刘开华, 田 岚, 李 镝, 等. 基于八度卷积神经网络的多标签胸部 X 光图像分类算法[J]. 天津大学学报(自然科学与工程技术版), 2023, 56(4): 381-390. Liu Kaihua, Tian Lan, Li Qiang, et al. Multi-label chest X-ray image classification method based on the octave convolutional neural network[J]. Journal of Tianjin University(Science and Technology), 2023, 56(4): 381-390 (in Chinese).
- [6] Wu Y N, Du R, Feng J, et al. Deep CNN for COPD identification by multi-view snapshot integration of 3D airway tree and lung field[J]. Biomed Signal Process Control, 2023, 79: 104162.
- [7] Işın A, Direkoğlu C, Şah M. Review of MRI-based brain tumor image segmentation using deep learning

- methods[J]. *Procedia Computer Science*, 2016, 102: 317-324.
- [8] Mazumdar I, Mukherjee J. Fully automatic MRI brain tumor segmentation using efficient spatial attention convolutional networks with composite loss[J]. *Neurocomputing*, 2022, 500: 243-254.
- [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*. Munich, Germany, 2015: 234-241.
- [10] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Boston, USA, 2015: 3431-3440.
- [11] Çicek Ö, Abdulkadir A, Lienkamp S S, et al. 3D U-Net: Learning dense volumetric segmentation from sparse annotation[C]// *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2016*. Athens, Greece, 2016: 424-432.
- [12] Chen J N, Lu Y Y, Yu Q H, et al. TransUNet: Transformers make strong encoders for medical image segmentation[EB/OL]. <https://doi.org/10.48550/arXiv.2102.04306>, 2021-02-08.
- [13] Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need[EB/OL]. <https://doi.org/10.48550/arXiv.1706.03762>, 2017-06-12.
- [14] Chen C, Liu X P, Ding M, et al. 3D dilated multifiber network for real-time brain tumor segmentation in MRI[C]// *Medical Image Computing and Computer-Assisted Intervention—MICCAI 2019*. Shenzhen, China, 2019: 184-192.
- [15] Zhou X Y, Li X Y, Hu K, et al. ERV-Net: An efficient 3D residual neural network for brain tumor segmentation[J]. *Expert Systems with Applications*, 2021, 170: 114566.
- [16] Luo Z R, Jia Z D, Yuan Z M, et al. HDC-Net: Hierarchical decoupled convolution network for brain tumor segmentation[J]. *IEEE Journal of Biomedical and Health Informatics*, 2020, 25(3): 737-745.
- [17] Zeng G D, Zheng G Y. Holistic decomposition convolution for effective semantic segmentation of medical volume images[J]. *Medical Image Analysis*, 2019, 57: 149-164.
- [18] Lessmann N, van Ginneken B, Zreik M, et al. Automatic calcium scoring in low-dose chest CT using deep neural networks with dilated convolutions[J]. *IEEE Transactions on Medical Imaging*, 2017, 37(2): 615-625.
- [19] Akbar A S, Faticah C, Suciati N. Single level UNet3D with multipath residual attention block for brain tumor segmentation[J]. *Journal of King Saud University—Computer and Information Sciences*, 2022, 34: 3247-3258.
- [20] Zhang W B, Yang G, Huang H, et al. ME-Net: Multi-encoder net framework for brain tumor segmentation[J]. *International Journal of Imaging Systems and Technology*, 2021, 31: 1834-1848.
- [21] Liew A, Lee C C, Lan B L, et al. CASPIANET++: A multidimensional channel-spatial asymmetric attention network with noisy student curriculum learning paradigm for brain tumor segmentation[J]. *Computers in Biology and Medicine*, 2021, 136: 104690.
- [22] Jiang Y, Zhang Y, Lin X, et al. SwinBTS: A method for 3D multimodal brain tumor segmentation using swin-transformer[J]. *Brain Science*, 2022, 12: 797.
- [23] 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*. Strasbourg, France, 2021: 109-119.
- [24] Milletari F, Navab N, Ahmadi S A. V-Net: Fully convolutional neural networks for volumetric medical image segmentation[EB/OL]. <https://doi.org/10.48550/arXiv.1606.04797>, 2016-06-05.
- [25] Zhang Z X, Liu Q J, Wang Y H. Road extraction by deep residual U-Net[J]. *IEEE Geoscience and Remote Sensing Letters*, 2018, 15(5): 749-753.
- [26] Oktay O, Schlemper J, Folgoc L L, et al. Attention U-Net: Learning where to look for the pancreas[EB/OL]. <https://doi.org/10.48550/arXiv.1804.03999>, 2018-04-11.
- [27] Vu M H, Nyholm T, Löfstedt T. Multi-decoder networks with multi-denoising inputs for tumor segmentation[C]// *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Lima, Peru, 2020: 412-423.
- [28] Nuechterlein N, Mehta S. 3D-ESPNet with pyramidal refinement for volumetric brain tumor image segmentation[C]// *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Granada, Spain, 2019: 245-253.
- [29] Zhang D W, Huang G H, Zhang Q, et al. Exploring task structure for brain tumor segmentation from multi-modality MR images[J]. *IEEE Transactions on Image Processing*, 2020, 29: 9032-9043.

(责任编辑:孙立华)