

DOI:10.3969/j.issn.1005-202X.2024.05.006

医学影像物理

基于有效感受野和注意力融合机制的脑肿瘤全自动分割

邹祥¹, 王瑜¹, 肖洪兵¹, 杨迪²

1. 北京工商大学计算机与人工智能学院, 北京 100048; 2. 中工国际工程股份有限公司, 北京 100048

【摘要】深度学习在医学图像分割领域取得了显著成果,但其在脑肿瘤分割任务中,仍面临感受野不足、冗余信息过多、信息丢失等问题;为此,本研究提出一种基于编-解码结构的脑肿瘤分割网络模型(EAU-Net)。EAU-Net采用有效感受野拓展模块和注意力融合模块改善脑肿瘤分割网络感受野不足与冗余信息过多带来的不利影响;同时,引入基于倒残差结构的瓶颈重采样模块,有效避免上下采样时造成的信息损失,并采用深度卷积降低网络的计算量。在BraTS2020数据集上的实验结果表明,EAU-Net获得最优的分割精度,验证了其在脑肿瘤分割任务中的可行性和有效性。

【关键词】脑肿瘤分割; EAU-Net; 有效感受野拓展模块; 注意力融合模块; 倒残差结构

【中图分类号】R318; TP181

【文献标志码】A

【文章编号】1005-202X(2024)05-0563-08

Fully-automatic brain tumor segmentation based on effective receptive field and attention fusion mechanism

ZOU Xiang¹, WANG Yu¹, XIAO Hongbing¹, YANG Di²

1. School of Computer and Artificial Intelligence, Beijing Technology and Business University, Beijing 100048, China; 2. China CAMC Engineering Co., Ltd., Beijing 100048, China

Abstract: Despite significant achievements of deep learning in medical image segmentation, there are challenges for brain tumor segmentation using deep learning, such as insufficient receptive field, excessive redundant information, and information loss. To address these issues, a novel brain tumor segmentation network model (EAU-Net) is proposed based on encoder-decoder structure. EAU-Net incorporates an effective receptive field expansion block and an attention fusion module to minimize the adverse effects caused by insufficient receptive field and excessive redundant information which often occurred in the current brain tumor segmentation network. Additionally, a bottleneck resampling module based on inverted residual structure is introduced to effectively avoid information loss during upsampling and downsampling, while deep convolutions are used to reduce computational complexity. Experimental results on the BraTS2020 dataset reveal that EAU-Net achieves the highest segmentation accuracy, demonstrating its feasibility and effectiveness for brain tumor segmentation.

Keywords: brain tumor segmentation; EAU-Net; effective receptive field expansion block; attention fusion module; inverted residual structure

前言

脑肿瘤是一种由大脑异常组织积累引起的神经性疾病^[1],经常出现在脑组织、脑神经和脑膜。据统计,脑肿瘤在所有癌症发病率中占比1.5%,但脑肿瘤造成的患者死亡率却高达3%^[2]。对于任何脑肿瘤的

治疗,其位置、大小和形状等信息均非常重要,因此磁共振成像(Magnetic Resonance Imaging, MRI)中脑肿瘤的精确分割对医生准确诊断至关重要,有助于医生更好地设计治疗方案^[3]。目前脑肿瘤分割主要依靠专业医生手动完成,需要大量的时间和专业知识,而且会受到临床经验、教育背景等很多不确定主观因素的影响^[4],因此每个专家分割肿瘤的亚区域时存在明显的差异^[5];而且胶质瘤形状、大小和位置都有不确定性^[6-7],专家有时也很难分辨。可见,对脑肿瘤精准分割是一项极具挑战性的任务。近年来,利用计算机全自动分割脑肿瘤不仅节省了时间和成本,而且提高了定量分析的客观性^[8],尤其随着人工智能技术的发展,深度学习在医学图像分割领域得

【投稿日期】2023-12-16

【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】邹祥,硕士研究生,研究方向:图像处理、机器学习, E-mail: 571529288@qq.com

【通信作者】王瑜,博士后,教授,博士生导师,研究方向:图像处理、模式识别, E-mail: wangyu@btbu.edu.cn

到广泛应用,并且由于其高精度和高效率的优势成为主流方法^[9]。

目前,研究者利用扩大感受野、融合注意力机制、获取多尺度特征等手段进行三维(Three-Dimensional, 3D)卷积神经网络(Convolutional Neural Networks, CNN)的相关研究。经过实验发现,CNN感受野中间像素的信息对输出的影响最大,整个感受野区域对输出的贡献呈高斯分布,从中心迅速衰减,感受野的有效区域只占感受野的一小部分,这一小部分称为有效感受野^[10]。

此外,针对脑肿瘤MRI图像相邻切片之间的差异,有研究者在上下文残差网络(Context Residual Networks, ConResNet)^[11]的编-解码器结构中引入一种新的上下文残差解码器,提出上下文残差映射和上下文注意力映射,以增强模型的上下文信息获取能力。Zhou等^[12]利用扩张卷积,引入特征金字塔融合多尺度上下文信息。Kamnitsas等^[13]提出DeepMedic网络架构,将多尺度特征从两个通道输入,以兼顾局部信息与全局信息。Isensee等^[14]将MRI数据中心裁剪为 $128 \times 128 \times 128$ 的图像块,基于3D U-Net架构,在编-解码器上做细微修改,取得BraTS2018挑战赛第二名的成绩,说明利用3D CNN组成的U型跳跃连接结构具有强大的学习特征和表示能力。

然而,基于3D CNN的编-解码结构在脑肿瘤图像分割任务中仍然存在很多问题和挑战,网络结构过深容易出现过拟合,较浅的网络结构则有效感受

野不足,难以提取到全局语义信息。此外,脑肿瘤MRI数据存在严重的类别不平衡,在BraTS2020数据中表现尤为明显,脑肿瘤只占整个图像的很小一部分,其余大部分均是正常脑组织^[15],这些不利因素都会降低分割精度。针对上述问题,本研究提出一种基于U-Net编-解码结构的脑肿瘤分割网络模型EAU-Net,设计有效感受野拓展(Effective Receptive Field Expansion, ERF)模块和注意力融合(Attention Fusion, AF)模块,克服浅层网络有效感受野不足以及浅层特征冗余信息过多带来的不利影响。此外,在上下采样过程中加入一种基于倒残差结构的瓶颈重采样(Bottleneck Resampling, BR)模块,并在解码器阶段加入深度监督,实现BraTs2020数据的最高分割精度。

1 方法

本研究提出的EAU-Net结构如图1所示,该网络采用编-解码结构。在编码器阶段,利用设计的ERF模块拓展有效感受野,同时采用BR算子来进行特征图放大与通道调整,可以有效避免上下采样时造成的信息损失,并采用深度卷积降低网络的计算量。此外,在跳跃连接上加入AF模块,减少低级特征图的冗余信息。在解码器阶段,通过每层抽取特征图的方式进行深度监督,有利于浅层得到更充分的训练,解决深度神经网络训练梯度消失和收敛速度过慢等问题,并能充分利用高级语义信息和丰富的细节特征。




图1 EAU-Net框架

Figure 1 EAU-Net framework

1.1 预处理

由于图像模态、患者和获取设备不同,脑肿瘤

MRI图像的强度表示存在差异,同时由于光线、人为误差等影响,图像存在模糊、噪声等降质现象;因此,

图像预处理工作非常重要。

首先,由于原始数据中存在大量黑色背景,不包含任何有用信息,所以需要图像进行裁剪,以图像中心坐标进行中心裁剪,将原始大小为 $240 \times 240 \times 155$ 体素的图像,裁剪为 $128 \times 128 \times 128$ 的尺寸。然后,对图像进行归一化处理,加快CNN的训练,并防止过拟合,随后采用Z-score方法对图像进行标准化:

$$z = \frac{x - \mu}{\sigma} \quad (1)$$

其中, x 表示原始数值, z 表示转化后的Z-score, μ 为像素平均值, σ 为总体像素标准差。最后,采用平移、镜像、旋转等数据增强技术提高EAU-Net的学习能力和泛化能力。

1.2 EAU-Net全自动脑肿瘤分割模型

1.2.1 宽有效感受野编码器 编码器是语义分割、图像重建和图像分类的特征提取器。VGG16^[16]不仅在分类和检测领域取得巨大的成功,而且在医学图像分割方面也取得很好的表现。deeplabV3^[17]和deeplabV3+^[18]的实验结果表明非常深的编码器,如深度残差网络^[19]或Xception^[20]都具有较大有效感受野,可以进一步提高语义分割的效果,但是这种深层网络结构需要消耗大量的计算资源,而浅层网络则准确性较差,因此,设计ERF模块可以实现利用较少的网络层数和计算资源进行精确分割的目的。为此,本研究设计一种有效感受野模块,改善网络的有效感受野不足带来的不利影响。

RAU-Net编码器的卷积模块如图2所示,由一个

$3 \times 3 \times 3$ 的卷积核、批归一化(Batch Normalization, BN)以及ReLU激活函数组成。传统的编码结构采用级联卷积层获得空间分辨率不断下降、视场不断增大的特征图,这种处理方式一方面会由于网络层数过多而导致计算量过大、难以训练,另一方面,实际网络的有效感受野^[21]增加并不明显,而有效感受野增加才能保证网络提取更多的上下文信息,这对脑肿瘤分割任务非常关键。因此,本研究设计的编码器结构中,在分辨率较高时加入ERF模块,在不大量增加网络层数的基础上,可以提取更宏观的语义特征,同时加入通道的压缩拓展进行激励,避免分割网络利用堆叠卷积层数提取图像高级语义信息时导致计算量过多的问题。ERF模块如图3所示,利用3个不同扩张率的空洞卷积拓展感受野。感受野计算如式(2)所示:

$$RF_{i+1} = [\sqrt[3]{RF_i} + (k - 1) \times S_i]^3 \quad (2)$$

其中, RF_{i+1} 表示当前层的感受野; RF_i 表示上一层的感受野; k 表示卷积核的大小,如 $3 \times 3 \times 3$ 的卷积核,则 $k = 3$; S_i 表示前面所有层的步长的乘积(不包含本层)。 S_i 的计算如式(3)所示:

$$S_i = \prod_{j=1}^i \text{stride}_j \quad (3)$$




图2 卷积模块

Figure 2 Convolutional module

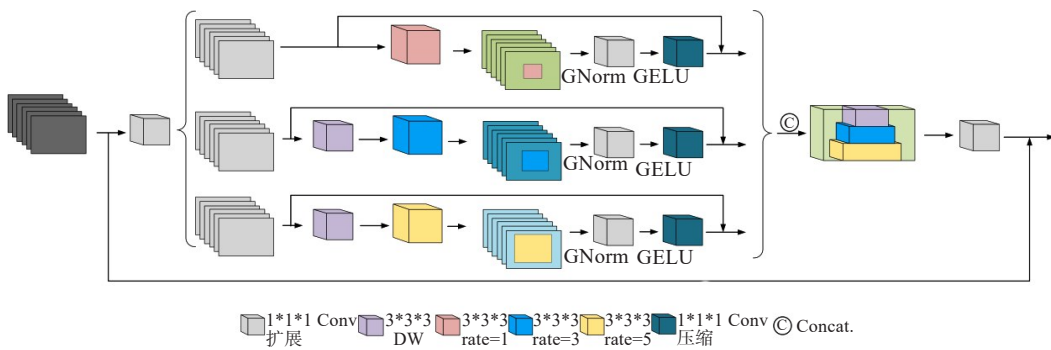


图3 有效感受野拓展模块

Figure 3 Effective receptive field expansion block

扩张卷积能快速扩大感受野,使网络在较浅层就能学习到MRI中的脑肿瘤特征,从而提高网络对脑肿瘤边缘的分割精度,有效避免网络过深带来的高复杂度和过拟合问题。

1.2.2 基于残差结构的深度监督解码器 有研究表明深度网络结构存在退化问题,即网络的精度不再随

着网络深度的增加而明显提升^[19]。由于本研究提出的具有编-解码器的EAU-Net结构属于深度网络模型,同样存在网络退化问题,因此在EAU-Net深层解码器阶段引入残差结构(图4)来缓解此问题。残差块表示如下:

$$\text{Output} = F(\text{Output}, w) + \text{Input} \quad (4)$$




图4 残差模块

Figure 4 Residual module

其中, w 表示卷积层的权重, $F(\cdot)$ 表示要学习的残差值。式(4)表示对输出特征图与原始特征图相似度进行判别。

此外, 具有编-解码器的 U-Net 可以分为很多层, 中间的跳跃连接将编码器与解码器相同大小的特征图进行连接, 使解码器卷积层可以更好地捕捉浅层特征图包含的上下文信息。然而普通解码器只对最后一层的特征图进行卷积, 然后输出, 无法有效提取解码器前几层特征图包含的丰富上下文信息, 这不仅影响分割结果的精度, 也不利于浅层网络的训练。为此, 在 EAU-Net 解码器阶段引入深度监督模块获取解码器中不同层的特征图, 充分提取多层特征图中包含的上下文信息和细节信息, 训练整个网络, 获得更准确的分割结果。本研究的深度监督机制将解码器每层的特征图进行输出, 并与标签值计算损失函数, 利用包含更多上下文信息的浅层特征图和较多细节信息的深层特征图同时对网络进行优化, 最后通过输出模块输出分割结果, 输出和深度监督模块结构如图 5 所示, 结果特征图利用 4 个通道, 步长为 1 的 $1 \times 1 \times 1$ 卷积层输出, 采用 Softmax 作为激活函数, 输出大小为 $4 \times 128 \times 128 \times 128$ 。

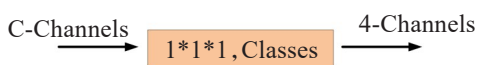


图5 输出/深度监督模块

Figure 5 Output/deep supervision module

1.2.3 AF 跳跃连接 AF 模块的目的是从不同源图像中突出最重要的特征, 以显示与目标区域有很大相关性的区域。由于不同的 MRI 模态可以表示肿瘤的不同属性, 同一种 MRI 模态的不同位置包含不同的肿瘤信息, 因此, 本研究提出把 AF 模块加入到跳跃连接中, 其能更好地融合模态之间的互补信息。该模块结构如图 6 所示, 分为空间注意力分支和通道注意力分支, 特征图输入后, 模块的通道注意力部分是在特征图通道上学习权重值, 而空间注意力部分是在特征图的长宽高维度上学习权重值, 然后这些权重分别和输入特征图进行加权, 而后将其进行拼接卷积运算后, 与原始输入特征图相加, 输出最终的特征图, 其尺寸与输入特征图尺寸保持一致。

1.2.4 重采样模块 BR 模块如图 7 所示, 将倒置瓶颈块应用到采样块, 其基于卷积核的 ConvNeXt 缩放策略进行改进, 在该模块中采用深度卷积, 并在最后一个压缩层加入相应的通道压缩或增加的设计。此外, 为使网络梯度更加流畅, 添加一个带有 $1 \times 1 \times 1$ 卷积的残差连接, 或者步幅为 2 的转置卷积, 这种设计可以使 EAU-Net 充分利用反向瓶颈灵活调整维度, 并通过维度的缩放提升网络模型特征的特异性, 同时减少计算量, 利用较低分辨率特征图保留丰富的语义信息, 更适应脑肿瘤分割任务。

1.3 损失函数

深度学习模型的架构会影响效率和性能, 损失函数的设置也具有关键性作用^[22]。由于在多数情况下, 脑肿瘤仅约占大脑 2%, 而在肿瘤区域中, 一般 24% 属于肿瘤核心区 (Tumor Core, TC), 15% 属于增强肿瘤区域 (Enhancing Tumor, ET), 因此, 在脑肿瘤分割任务中, 数据集存在严重的类别不平衡现象。为此, 选择一个合适的损失函数来降低数据中类别不平衡的影响, 对于模型的性能评估是非常重要的。本研究采用焦点损失函数和 Soft Dice 损失函数相结合的融合损失函数来解决类别不平衡问题中损失函数的收敛性问题。多类焦点损失函数表示如下:

$$L_{\text{focal}}(x, y) = -\frac{1}{N} \sum_{n=1}^N \sum_{c=1}^C (1 - x_{nc})^y y_{nc} \log x_{nc} \quad (5)$$

其中, x 表示预测输出, y 表示真实值, C 表示类别, N 为类别总数。

多类 Soft Dice 损失函数使用如下公式表示:

$$L_{\text{dice}}(x, y) = 1 - \frac{1}{N} \sum_{c=1}^C \frac{2x \sum m, n x_{cmn} y_{cmn} + \epsilon}{\sum m, n x_{cmn}^2 + \sum m, n y_{cmn}^2 + \epsilon} \quad (6)$$

其中, m 表示体素, ϵ 表示为了避免分子分母出现 0 值。

Soft Dice 损失函数重点关注预测值和真实值之间最大重叠这一简单类别, 而且该函数在数据极度不平衡情况下容易出现收敛问题, 因此, 加入焦点损失函数可以使模型更关注较难识别的类别。本研究构建的融合损失函数如式(7)所示:

$$L_{\text{fusion}} = L_{\text{focal}} + L_{\text{dice}} \quad (7)$$

2 实验设置

2.1 数据设置

本实验采用的数据集来自于公开数据集

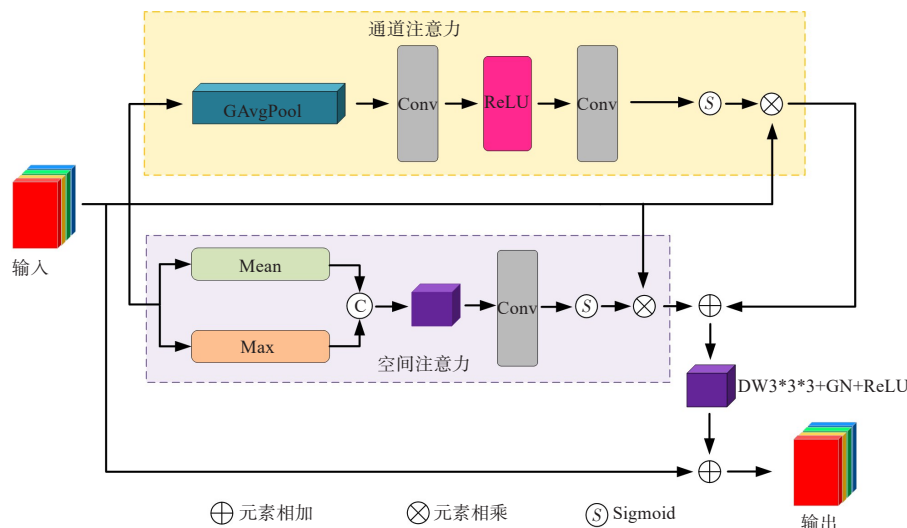


图6 注意力融合模块
Figure 6 Attention fusion module

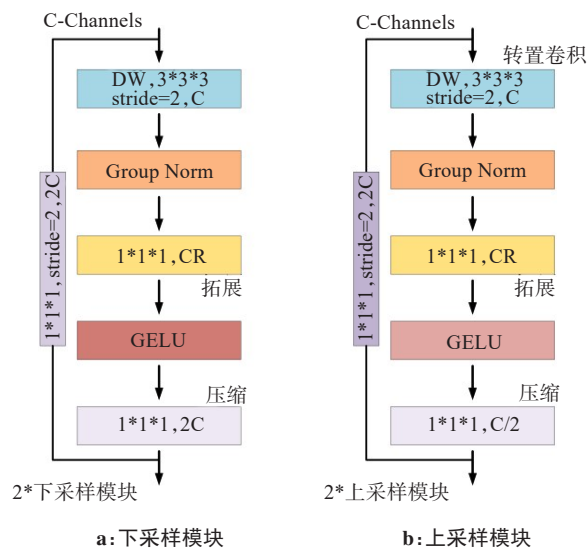


图7 下/上采样模块
Figure 7 Down/upsampling module

BraTS2020。BraTS是多模态脑肿瘤分割重要的公开数据集,被广泛应用于脑肿瘤分割课题研究和MICCAI脑肿瘤分割挑战赛,其主要分割TC、ET、整

个肿瘤区域(Whole Tumor, WT)。BraTS2020数据中每位患者的脑肿瘤MRI具有4种模态(T1、T1ce、T2、Flair)及专家标注好的标签数据,且均经过去颅骨、配准、重采样等预处理。实验时设置369例训练集、125例验证集、100例测试集,数据大小为240×240×155体素。专家标注的脑肿瘤标签数据分为TC(标签1)、ET(标签4)、水肿区域(标签2),具体示例见图8。

2.2 评价指标

为验证提出模型的性能,采用脑肿瘤分割模型通用的评价指标Dice系数、灵敏度和Hausdoff距离进行实验结果对比分析。

Dice系数用来衡量预测值Y与真实值X之间的重叠区域,其值的分布范围在0~1之间,Dice系数越大表明分割结果越好,具体公式如下:

$$\text{Dice Score}(X, Y) = 2 \frac{|X \cap Y|}{|X| + |Y|}$$

(8)

灵敏度表示真阳性体素与预测阳性体素比值,有助于确定脑肿瘤区域是否被过度分割或分割不足,具体公式如下:




图8 模型训练采用的脑肿瘤MRI数据示例
Figure 8 Example of brain tumor MRI data used for model training
标签数据中绿色代表水肿区域,蓝色代表ET,红色代表TC

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

(9)

Hausdoff距离用来计算分割区域表面与真值表面之间的最大距离,用来度量分割结果边界的优劣程度,具体公式如下:

$$H(X,Y) = \max\left\{\max_{x \in X} \min_{y \in Y} d(x,y), \max_{y \in Y} \min_{x \in X} d(x,y)\right\}$$

(10)

其中, X 表示GT, Y 表示预测, $d(\cdot)$ 表示计算 x 与 y 之间欧式距离的函数。本研究采用Hausdoff95(豪斯多夫距离×95%)进行结果分析。

2.3 实验环境

提出的EAU-Net模型使用Python编程语言构建,利用Pytorch框架进行后端实现。在预处理阶段,将原始4种模态大小为4×240×240×155的数据进行裁剪,将裁剪后大小为4×128×128×128的数据进行

Z-score 归一化处理、数据增强等操作,然后输入模型。在实验中使用ADAM优化器,学习率设置为0.000 1,使用组归一化(Group Normalization, GN)和ReLU激活函数。模型批量大小设为4,最大训练epochs为500,训练过程中选用损失函数的指数移动平均值(Itrain MA)学习权重,当其在50个epochs内不再减小或学习率小于1×10⁻⁶时,停止训练。

3 实验结果与分析

3.1 EAU-Net消融实验

在BraTS2020数据集上进行EAU-Net的消融实验,验证网络模型中ERF、AF、BR等不同结构改进的有效性,本消融实验不改变网络的其他结构,只对网络当中的ERF、AF、BR进行拆解替换实验,以验证所提出模块的有效性,具体实验结果如表1所示。

表1 消融实验结果
Table 1 Ablation experiment results

模型	模块					Dice系数/%			Hausdoff95/mm		
	ERF	AF	BR	SA	C-TC	TC	WT	ET	TC	WT	ET
1	×	√	√	×	×	86.73	88.92	85.35	8.25	6.89	7.39
2	√	×	√	√	×	87.03	88.99	85.86	6.32	6.87	7.78
3	√	√	×	×	√	87.75	90.67	86.01	8.09	5.15	6.23
4	√	√	√	×	×	88.91	91.89	86.78	7.38	4.83	6.62

由于ERF具有拓展有效感受野的优势,可以让网络在较浅层的网络特征图中学习到更宏观的脑肿瘤信息,有利于网络快速捕捉到脑肿瘤的特征,从而提升模型的整体性能,尤其是对于WT具有更好的分割效果,因此增加ERF后,分割结果中WT具有最明显的提升,对比模型1的WT分割结果,模型4的Dice系数提升2.97%,Hausdoff95距离提升2.06 mm,充分说明该模块对于网络学习中宏观语义信息捕获的有效性。

注意力机制一直是脑肿瘤分割模型的一个重要研究方向,其中自注意力(SA)机制是一个优秀的代表方法,其在不大量增加计算支出的情况下取得了优异的性能,因此本研究的注意力机制的消融实验采用SA模块,并与AF模块进行对比。结果表明,SA模块借鉴深度可分离卷积,获得基于空间注意力和通道注意力的轻量化注意力机制,但其不能很好地获取全局信息。AF模块采用融合注意力,获得基于空间注意力和通道注意力的全局信息,并且利用深度卷积将该模块的计算消耗降至较低水平。此外,

通过实验结果可以看到,相较于SA模块,本研究所提出的注意力机制关于脑肿瘤WT、ET、TC的Dice系数和Hausdoff95距离都有较为明显的提升,说明本研究提出的AF机制能更好地加强特征图中的有效信息,并减少冗余特征干扰,进而取得更好的结果。

在具有编-解码结构的网络当中,常采用的重采样策略包括卷积和线性插值。卷积可以通过改变步长来实现对特征图尺寸的压缩,转置卷积可以实现对特征图尺寸的拓展。线性插值可以根据前一层的网络特征图的序列进行数值的估计,实现上采样。常用的重采样策略是在下采样阶段使用跨步卷积对图像进行压缩,在上采样阶段采用插值或者转置卷积,从网络轻量化的角度理解,线性插值可以减少参数量和计算量,但是其相较于卷积会降低分割精度。所以针对该结构的消融实验,使用当前脑肿瘤分割先进网络模型常用的卷积-转置卷积(Convolution-Transpose Convolution, C-TC)重采样策略与本研究所采用的BR重采样策略进行对比实验。通过实验结果可以看出,BR重采样策略相较于C-TC方法,在

脑肿瘤3个子区域分割结果的数据指标都有所提升,进一步说明BR能在上下采样过程中通过其特有的瓶颈结构很好地保持特征图的信息,提升网络的分割性能。

3.2 其他模型的对比结果

表2 本研究所提方法与最新方法的对比结果
Table 2 Comparison of the proposed method and the latest methods

分割模型	Dice 系数/%			敏感度/%			Hausdoff95/mm		
	TC	WT	ET	TC	WT	ET	TC	WT	ET
3D U-Net	79.06	84.11	68.76	N/A	N/A	N/A	13.60	13.36	50.98
3D V-Net	75.26	84.63	62.15	N/A	N/A	N/A	12.18	20.41	47.70
Li U-Net	82.00	90.00	78.00	N/A	N/A	N/A	6.64	5.14	7.71
RF-Net	85.21	91.11	78.00	89.32	95.85	86.02	8.26	5.11	12.29
nnU-Net	86.99	91.08	83.79	90.29	95.31	88.15	9.92	5.87	9.33
TransBTS	81.73	90.09	78.73	88.02	95.15	86.21	9.77	5.96	10.95
EAU-Net	88.91	91.89	86.78	91.18	96.33	85.28	7.38	4.83	6.62

3D U-Net 利用 3D CNN 替换传统 U-Net 中的 2D CNN,将 3D 脑肿瘤 MRI 作为输入,进行模型训练与分割,虽然其相较于传统 2D 方法有了较大提升,但网络需要更多的计算资源,而且精度也不够理想。V-Net 利用补丁技术降低传统 3D CNN 需消耗大量内存的问题,但同时也牺牲了一部分的分割精度。使用级联 3D 密集连接的 Li U-Net 在脑肿瘤 WT 的分割精度有了明显的进步,但 ET 分割效果不够好。RF-Net 加入了区域感知模块,其在脑肿瘤 WT 分割精度上得到进一步的提升,但 ET 分割精度没有明显改善。nnU-Net 使用传统的 3D U-Net 和 2D U-Net 进行级联,并结合有效的前后处理策略,取得较明显的分割精度提升。TransBTS 利用 Transformer 进行分割,凭借 Transformer 感受野的优势在脑肿瘤 WT 上有较好的表现。

本研究提出的 EAU-Net 采用 ERF 和融合注意力模块提取特征,更容易提取到图像的重要语义信息,并采用深度监督,使得浅层网络能得到更好的训练。通过对比表 2 数据可以看出,与 nnU-Net 相比,EAU-Net 在 TC 和 WT 上取得了明显的优势,并结合实验得出的分割结果(图 9)可以明显看出,TC 分割有非常明显的提升,这得益于 EAU-Net 的 AF,能让网络更加聚焦特征图的脑肿瘤信息。在表 2 以及图 9 上对比 TransBTS 与 EAU-Net 的 WT 分割结果,可以发现 EAU-Net 取得更精细的结果,主要原因在于,EAU-Net 中的 ERF 提供了可以媲美 Transformer 的有效感受野。可视化对比图 9 的结果显示,相较于 RF-Net,

为验证本研究所提出算法的优越性,将 EAU-Net 与当前最先进的脑肿瘤语义分割模型进行比较,包括 3D U-Net^[23]、3D V-Net^[24]、Li U-Net^[25]、RF-Net^[26]、nnU-Net^[27]、TransBTS^[28]等,实验结果如表 2 所示。

EAU-Net 在脑肿瘤 TC 和 ET 边缘分割上有明显优势。总体来说,本研究所提出的 EAU-Net 模型,在 BraTS2020 数据集上得到的 WT、ET、TC 的 Dice 系数、敏感度以及豪斯多夫距离分割结果均最接近 GT,边缘也更清晰。

4 结 论

本研究尝试解决 3D MRI 脑图像肿瘤分割时常遇到的边缘分割不清晰,网络结构过深容易出现过拟合,较浅的网络结构则有效感受野不足,难以提取到全局语义信息的问题,提出一种新型脑肿瘤分割网络 EAU-Net。在编码器部分成功嵌入 ERF,通过扩展有效感受野,提升网络对肿瘤边缘分割的能力;在跳跃连接上加入 AF,增强有用局部信息,并保留局部特征响应,利用跳跃连接将其从编码器侧的适当级别传递到解码器侧的激活,改进学习过程;并在解码器阶段嵌入残差块与深度监督,旨在改进整体训练过程,并克服梯度消失问题。在 BraTS2020 数据集上的实验结果表明大的有效感受野与 AF 相结合可以最大化相邻脑胶质瘤区域之间的强度相异性响应,自适应地挖掘脑胶质瘤相关特征,抑制无关特征,改善现有脑胶质瘤分割方法效果不佳的现状。提出的 EAU-Net 具有良好的分割性能,在 ET、WT、TC 上的 Dice 系数分别达到 88.91%、91.89% 和 86.78%,优于现有模型。未来工作将尝试不同的增强技术或迁移学习思想,进一步提高所提方法的性能。




图9 结果可视化对比图

Figure 9 Result visualization comparison

【参考文献】

- [1] Agravat RR, Raval MS. Brain tumor segmentation: towards a better life[J]. CSI Commun, 2016, 40(9): 31-35.
- [2] Fitzmaurice C, Allen C, Barber RM, et al. Global, regional, and national cancer incidence, mortality, years of life lost, years lived with disability, and disability-adjusted life-years for 32 cancer groups, 1990 to 2015: a systematic analysis for the global burden of disease study[J]. JAMA Oncol, 2017, 3(4): 524-548.
- [3] Isensee F, Kickingereder P, Wick W, et al. Brain tumor segmentation and radiomics survival prediction: contribution to the BRATS 2017 challenge[C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Cham: Springer International Publishing, 2018: 287-297.
- [4] Nyúl LG, Udupa JK, Zhang X. New variants of a method of MRI scale standardization[J]. IEEE Trans Med Imaging, 2000, 19(2): 143-150.
- [5] Zhou CH, Ding CX, Wang XC, et al. One-pass multi-task networks with cross-task guided attention for brain tumor segmentation[J]. IEEE Transactions on Image Processing, 2020, 29: 4516-4529.
- [6] 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.
- [7] Havaei M, Davy A, Warde-Farley D, et al. Brain tumor segmentation with deep neural networks[J]. Med Image Anal, 2017, 35: 18-31.
- [8] Stefano A, Gioè M, Russo G, et al. Performance of radiomics features in the quantification of idiopathic pulmonary fibrosis from HRCT[J]. Diagnostics (Basel), 2020, 10(5): 306.
- [9] Zhang WB, Yang G, Huang H, et al. ME-net: multi-encoder net framework for brain tumor segmentation[J]. Int J Imaging Syst Technol, 2021, 31(4): 1834-1848.
- [10] Luo WJ, Li YJ, Urtasun R, et al. Understanding the effective receptive field in deep convolutional neural networks[C]//30th Conference on Neural Information Processing Systems (NIPS 2016). San Francisco, CA, USA: Curran Associates Inc., 2016: 1-9.
- [11] Zhang JP, Xie YT, Wang Y, et al. Inter-slice context residual learning for 3D medical image segmentation[J]. IEEE Trans Med Imaging, 2021, 40(2): 661-672.
- [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] Kamnitsas K, Ledig C, Newcombe VF, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation[J]. Med Image Anal, 2017, 36: 61-78.
- [14] Isensee F, Kickingereder P, Wick W, et al. No new-net[C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Cham: Springer International Publishing, 2019: 234-244.
- [15] Wang P, Chung AC. Relax and focus on brain tumor segmentation[J]. Med Image Anal, 2022, 75: 102259.
- [16] Simonyan K, Zisserman A. Very deep convolutional networks for large-scale image recognition[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2014: 24-27.
- [17] Chen LC, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 21-26.
- [18] Chen LC, Zhu YK, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 833-851.
- [19] He KM, Zhang XY, Ren SQ, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [20] Chollet F. Xception: deep learning with depthwise separable convolutions[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2017: 1800-1807.
- [21] Ding XH, Zhang XY, Han JG, et al. Scaling up your kernels to 31×31 : revisiting large kernel design in CNNs[C]//2022 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2022: 11953-11965.
- [22] Sudre CH, Li WQ, 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. Cham: Springer International Publishing, 2017: 240-248.
- [23] Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-net: learning volumetric segmentation from sparse annotation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016. Cham: Springer International Publishing, 2016: 424-432.
- [24] Ballestar LM, Vilaplana V. Brain tumor segmentation using 3D-CNNs with uncertainty estimation[C]//Proceeding of IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Piscataway, NJ, USA: IEEE, 2020: 13-19.
- [25] Ghaffari M, Sowmya A, Oliver R. Automated brain tumour segmentation using cascaded 3D densely-connected U-net[C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Cham: Springer International Publishing, 2021: 481-491.
- [26] Ding YH, Yu X, Yang Y. RFNet: region-aware fusion network for incomplete multi-modal brain tumor segmentation[C]//2021 IEEE/CVF International Conference on Computer Vision (ICCV). Piscataway, NJ, USA: IEEE, 2021: 3955-3964.
- [27] Isensee F, Jäger PF, Full PM, et al. nnU-Net for brain tumor segmentation[C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Cham: Springer International Publishing, 2021: 118-132.
- [28] Wang WX, Chen C, Ding M, et al. TransBTS: multimodal brain tumor segmentation using transformer[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 109-119.

(编辑:谭斯允)