

一种级联改进 U-Net 网络的脑肿瘤分割方法

褚晶辉, 黄凯隆, 吕卫*

天津大学电气自动化与信息工程学院, 天津 300072

摘要 提出了一种基于深度学习的 3D 脑肿瘤核磁共振图像(MRI)自动分割方法。为了降低分割难度,采用三级级联网络的策略分割脑肿瘤的三个子区域;为了进一步提高三维分割的精度,采用帧间卷积和帧内卷积,加入额外的多层特征融合机制和空洞卷积;为了进一步细化分割结果,将条件随机场构建的循环神经网络整合到网络结构中。在模型训练中结合了两种损失函数,进一步提高了准确率。该方法在 BraTS 2018 数据集上进行验证,对于脑肿瘤整体、肿瘤核以及增强肿瘤,其分割结果的 Dice 系数分别达到了 0.9093、0.8254 和 0.7855, Hausdorff 距离达到 3.8188、7.8487 和 4.3264, 优于大多数脑肿瘤图像分割方法。

关键词 图像处理; 脑肿瘤分割; 多层特征融合; 空洞卷积; 条件随机场

中图分类号 TP391.4

文献标志码 A

doi: 10.3788/LOP202158.0810020

A Method for Brain Tumor Segmentation Using Cascaded Modified U-Net

Chu Jinghui, Huang Kailong, Lü Wei*

School of Electrical and Information Engineering, Tianjin University, Tianjin 300072, China

Abstract We proposed a deep learning approach for automatic segmentation of three-dimensional gliomas magnetic resonance images(MRI). First, we used a three-stage cascaded strategy to sequentially segment the subregions of gliomas. Second, to further improve the segmentation accuracy, we used intraslice and interslice convolutions, introduced additional multi-levels feature fusing, and implemented dilated convolution. Third, to produce a fine-grained output, conditional random fields as recurrent neural network were adopted as a part of network structure. Finally, we combined two types of loss functions in the training procedure to further improve the segmentation accuracy. We applied our method on the BraTS 2018 dataset and achieved a Dice score of 0.9093, 0.8254, and 0.7855 and the Hausdorff distance of 3.8188, 7.8487, and 4.3264 for the whole tumor, tumor core, and enhanced tumor, respectively. The proposed methods achieved better performance than most brain tumor segmentation methods.

Key words image processing; gliomas segmentation; multi-levels feature fusing; dilated convolution; conditional random fields

OCIS codes 100.2000; 100.4996; 100.6890

1 引言

神经胶质瘤是人体中最常见的原发性脑肿瘤,具有较高的致死率,神经胶质瘤可分为高级别胶质瘤(HGG)和低级别胶质瘤(LGG),前者具有较强的侵略性。核磁共振图像(MRI)常被用来观测胶质

瘤。神经胶质瘤可以划分为水肿区域、肿瘤核区域、增强肿瘤区域、非增强肿瘤区域以及坏死区域。放射科医生需要根据不同模态的核磁共振图像来确定肿瘤的具体位置和区域范围,不同模态的图像侧重点不同,常见的模态有 4 种: T1 图像、T1 增强图像(T1ce)、T2 图像以及液体衰减反转恢复序列

收稿日期: 2020-08-24; 修回日期: 2020-09-12; 录用日期: 2020-09-20

* E-mail: luwei@tju.edu.cn

(FLAIR), 分别侧重于肿瘤核、增强肿瘤区域及坏死区域、水肿区域、肿瘤整体区域, 为分割肿瘤图像提供了互补信息。肿瘤区域的评判对于评估疾病和选择治疗方案至关重要, 而手动分割肿瘤非常费时且容易出错。因此有必要开发一种准确、高效且可重复的脑肿瘤分割系统。

脑肿瘤分割具有挑战性, 这是因为肿瘤不会以特定的形状和尺寸出现在固定的位置, 且边界也较为模糊^[1]。近年来, 卷积神经网络在图像分割领域具有突出的表现^[2]。Shelhamer 等^[3]提出了全卷积网络 (FCN) 用于语义分割, FCN 将 CNN (Convolutional Neural Network) 末尾的全连接层替换为卷积层, 通过实现与输入图像尺寸相同的输出, 产生了较为准确的分割结果。Ronneberger 等^[4]在 FCN 的基础上进行修改和拓展, 提出了 U-Net 结构, U-Net 采用对称的编码-解码结构和跳层连接, 融合上下文特征和细节特征, 提高了分割准确度。Milletari 等^[5]提出了 V-Net 网络结构, 使用 3D 卷积分割 3D 图像, 并加入残差结构, 缓解了梯度消失的问题。Chen 等^[6]提出 DeepLab 用于语义分割, 加入空洞卷积^[7]增大卷积核感受野; 提出空洞空间金字塔卷积, 对目标和图像背景进行多尺度捕捉; 加入条件随机场^[8]弥补由于降采样导致的误差。Chen 等^[9-10]对 DeepLab 结构加以改进, 将 ASPP (Atrous Spatial Pyramid Pooling) 修改为并行模式, 拓展为编码-解码结构。Wang 等^[11]提出了级联各向异性结构用于脑肿瘤分割, 使用级联框架和各向异性卷积, 极大地减少了参数量。Myronenko 等^[12]沿用了编码-解码结构分割脑肿瘤图像, 在解码路径上添加变分自动编码器分支, 对解码器施加额外的约束。

本文提出了一种级联 U-Net 网络用于多模态 3D 核磁共振图像的脑肿瘤分割, 实现了对脑肿瘤图像中肿瘤整体 (WT)、肿瘤核 (TC) 和增强肿瘤 (ET) 三个子区域的多类分割。首先, 针对多类分割任务难度较大, 且分割结果中假阳点多的问题, 使用三级级联网络策略分割脑肿瘤图像的三个子区域, 将前一级网络的分割结果作为当前网络的输入, 将多类分割任务化简为多个二类分割任务。其次, 为了进一步提高分割精度和网络性能, 在每一级网络中改进 U-Net 网络结构: 1) 针对 3D 卷积核参数量大、占用 GPU 内存多, 2D 卷积无法提取空间特征的问题, 使用帧内卷积和帧间卷积代替 3D 卷积核来分别提取帧内特征和帧间特征; 2) 为了进一步融合上

下文特征和细节特征, 在网络的解码路径加入多层特征融合机制, 用于整合解码器中不同层的多深度特征; 3) 针对为了扩大卷积核感受野而频繁降采样带来的损失细节特征的问题, 加入空洞卷积, 并减少降采样层数量。最后, 为了进一步细化分割结果, 提升分割精度, 本文使用条件随机场构建的循环神经网络作为网络结构的一部分, 与卷积神经网络一起作为一个整体参与训练。此外, 为了弥补 Dice 损失函数的缺陷, 本研究采用了 Dice 损失函数和交叉熵损失函数相结合的方式训练。

2 基本原理

2.1 三级级联策略

级联策略已经被证明是分割多类图像的有效方法^[13-14], 由于脑胶质瘤的子区域是分层次的, 即肿瘤整体区域包含肿瘤核区域, 肿瘤核区域包含增强肿瘤区域, 本文针对这种子区域分布的结构提出三级级联策略, 依次对脑胶质瘤的三个子区域进行二类分割。三级级联网络将多类分割任务简化为三个二类分割子任务, 如图 1 所示, 第一级网络 (WT-Net) 将核磁共振图像分割为健康的组织区域和肿瘤整体区域, 然后根据肿瘤整体区域设定边界框并进行裁剪, 作为下一级网络的输入; 第二级网络 (TC-Net) 将 WT 区域分割为水肿区域和肿瘤核区域, 根据 TC 区域设定边界框进行裁剪, 并将裁减部分作为最后一级网络的输入; 最后一级网络 (ET-Net) 将增强肿瘤区域从 TC 区域分割出来, 剩下的区域为非增强肿瘤区域和坏死区域。此外, 每一级分割任务都包含轴向、矢向和冠向三个方向的分割, 在每一级网络中对三个方向分别进行训练, 再使用 Softmax 进行融合。级联策略能够使每一级网络模型更加容易训练, 并且将后一级网络分割区域限定在前一级




图 1 三级级联框架

Fig. 1 Three stages cascaded architecture

网络分割的区域内,能够有效减少出现在限定区域之外的假阳点。

2.2 帧内卷积和帧间卷积

3D 卷积可以直接从 3D 特征图中提取空间特征,但代价是会大量占用 GPU 内存;2D 卷积可以减轻 GPU 负担,但代价是只能提取到切片的内部特征,无法提取到空间特征。因此,本文结合使用帧内卷积和帧间卷积对保全 3D 空间特征和减少 GPU 内存消耗进行权衡。将原始 3D 图像切分成尺寸为 $144 \times 144 \times 19$ 的切块,而后帧内卷积和帧间卷积可以将每个 3D 的切块作为一组 2D 的切片序列,即为 19 张大小为 144×144 的 2D 切片。卷积核尺寸为 $3 \times 3 \times 1$ 的帧内卷积用于提取每张切片内部的特征,卷积核尺寸为 $1 \times 1 \times 3$ 的帧间卷积用于提取同一组序列中切片之间的特征。将帧内卷积与帧间卷积结合使用便可以提取切块的空间特征,由此不仅可以减少卷积核的参数,而且能够提取到特征图的空间特征信息。由于切片平面尺寸的数据量与切片数量之间不平衡,本文采用的帧内卷积数量远远多于帧间卷积,并在连接编码路径和解码路径特征图的跳层结构中加入帧间卷积,以充分提取切片之间的信息。

2.3 多层特征融合机制

传统的 U-Net^[4] 网络可以根据其结构划分为很多层,编码路径和解码路径在同一层具有尺寸相同的特征图,跳层结构可将编码路径与解码路径同一层特征图连接,使得后继卷积层可以利用编码路径上的含有上下文信息的特征图与解码路径上的含有细节信息的特征图来得到更加准确的分割结果。然而传统 U-Net 的输出只取决于解码路径的最后一层卷积,丢失了解码器中前几层包含上下文信息的特征图。因此,本文在解码器上拓展出了多层特征融合机制,用于连接解码路径中不同层的特征图,以充分利用传统 U-Net 网络在解码路径中丢失的特征信息。如图 2 所示,本文提取了解码器中每一层的特征图,其中较低层的特征图包含了更多的上下文信息,较高层的特征图包含了更多细节信息;在多层特征融合机制中,将提取的每层特征图通过反卷积层恢复为原来的尺寸,再通过通道数维度的连接方式进行拼接,由此得到能够进一步整合上下文特征与细节特征的输出。与传统的 U-Net 相比,输出可以参考更多的上下文特征,能够得到较好的分割结果。

2.4 空洞卷积

卷积核的感受野大小受限于其尺寸,一般为了

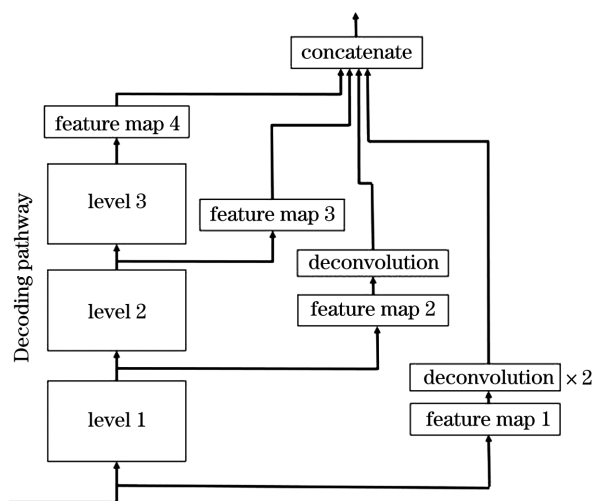


图 2 多层特征融合

Fig. 2 Multi-levels feature maps fusing

减少参数数量,需将卷积核限制在一个较小的尺寸内,然后通过降采样操作或者加入空洞卷积来增大感受野。然而重复的降采样操作会损失特征图的分辨率,丢失了很多细节特征信息,无法通过上采样操作恢复。所以本文在帧内卷积中加入空洞卷积并减少降采样层的数量,使网络能够在提取帧内特征时拥有较大的感受野。对于二维图像的空洞卷积来说, w 为空洞卷积核, i 为特征图上的每个像素点,输入特征图 x 与输出特征图 y 的关系为

$$y[i] = \sum_k x[i + r \cdot k] w[k], \quad (1)$$

式中: r 为扩张率,代表空洞卷积的采样间隔; k 为空洞卷积过程中除中心像素点之外的其他像素点。如图 3 所示,在空洞卷积中,卷积核尺寸是固定的 (3×3),当扩张率增大时,卷积核的采样间隔增大,感受野也相应增大。本文将空洞卷积应用在 U-Net 网络靠近底部的卷积层中,通过调整扩张率来得到合适的感受野,进而可以减少降采样层的数量,避免因过多降采样操作带来的不可逆的细节特征丢失。




图 3 空洞卷积

Fig. 3 Dilated convolution

2.5 条件随机场构建循环神经网络

条件随机场 (CRFs) 常被用作与 CNN 分离的

后处理,用于细化分割结果。然而,单独的 CRFs 不与 CNN 一起参与训练,因而不能充分利用 CRFs 的优点。本文受文献[15-16]的启发,使用条件随机场构建循环神经网络(CRF-RNN),并将其整合到改进的 U-Net 网络当中,利用反向传播方法进行训练、优化参数。在 CRF-RNN 结构中,将 CRFs 的均场近似作为迭代器,一次均场迭代可以作为 CNN 网络中的一组层,能够参与训练。均场应用了高斯空间滤波器和双边滤波器,通过消息传递、赋予权重、兼容性变换、添加一元势函数和正则化操作,使得 CRFs 可以在训练阶段通过反向传播算法优化参数。如图 4 所示,使用多次均场迭代构建循环神经网络。给定原始输入图像 I 和一元势函数信号 U , CRF-RNN 的过程可以表示为

$$H_1(t) = \begin{cases} \text{Softmax}(U), & t = 0 \\ H_2(t-1), & 0 < t \leq T \end{cases}, \quad (2)$$

$$H_2(t) = f_{\omega, \mu}(I, U, H_1(t)), \quad (3)$$

$$Y = \begin{cases} 0, & t < T \\ H_2(t), & t = T \end{cases}, \quad (4)$$

式中: $\text{Softmax}(\cdot)$ 为激活函数; T 为均场迭代器的迭代次数; $f_{\omega, \mu}$ 是一次均场迭代的变换关系; ω, μ

为均场推断中赋予权重和兼容性变换时需要训练的参数。图 4 中 G_1 和 G_2 是门函数,可以控制 H_1 和 Y 的输出。

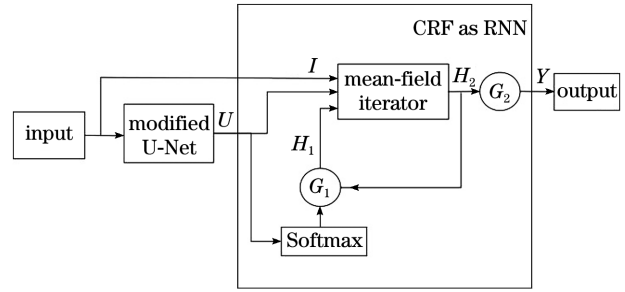


图 4 条件随机场作循环神经网络

Fig. 4 Condition random fields as recurrent neural network

本文提出的网络模型如图 5 所示,使用帧内卷积和帧间卷积相结合的方式,每个卷积层后都有一个批归一化层(BN)^[17] 和一个参数线性整流单元(PReLU)^[18],解码路径上加入多层特征融合机制,网络底部加入空洞卷积,在网络末尾额外添加了 CRF-RNN 的结构。考虑到后两级网络输入的切块分辨率较小,本研究减少了 TC-Net 和 ET-Net 网络中降采样层和反卷积层的数量。

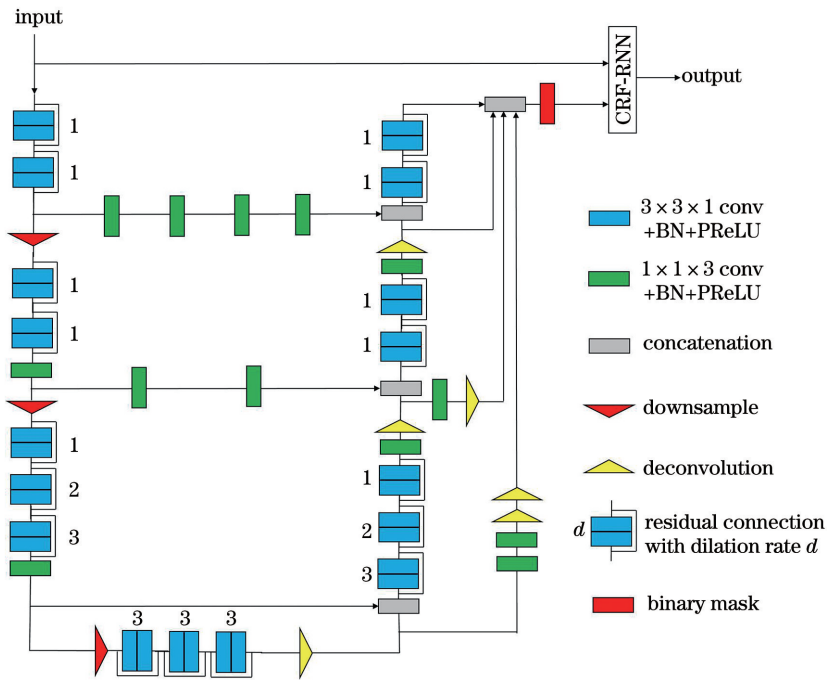


图 5 改进 U-Net 结构

Fig. 5 Modified U-Net structure

3 实验结果分析

3.1 三维脑肿瘤核磁共振图像数据集

本文使用 MICCAI Brain Tumor Segmentation

(BraTS) 2018^[19-20] (亦可参见网址 <https://www.cancerimagingarchive.net/>)数据集进行验证,其中包含训练集和验证集。训练集有 285 例脑胶质瘤患者的 3D 核磁共振图像,其中有 75 例患有 LGG 和

210 例患有 HGG, 每个病例的图像包含 4 种模态 (T1、T1c、T2 和 FLAIR), 且包含专家手动标注的标签。标签将脑胶质瘤划分为 3 种区域: 肿瘤整体区域、肿瘤核区域以及增强肿瘤区域, 3 种区域之间为分层次的包含关系。验证集包含 66 例脑胶质瘤患者的 3D 核磁共振图像, 肿瘤类型未知且没有标签。图 6 为数据集中同一组图像的 4 种模态的核

磁共振图像以及专家手动标注的标签图。每个核磁共振图像的尺寸为 240 pixel×240 pixel×155 pixel。本文将训练集的 285 例核磁共振图片裁剪成大小为 144 pixel×144 pixel×19 pixel 的切块作为训练集, 使用验证集的 66 例核磁共振图片作为测试集用于测试训练后的模型, 由于验证集缺少标签, 本文使用 BraTS 2018 比赛官网的评分作为实验结果。




图 6 不同模态的核磁共振图像及标签图

Fig. 6 Different modalities of MRI and label images

3.2 实验设置

本文实验使用内存为 11 GB 的 NVIDIA 1080 Ti 显卡在 TensorFlow^[21] 框架下基于 NiftyNet^[22] 进行, 使用 285 组 3D 核磁共振图像 (75 组 LGG 和 210 组 HGG) 训练模型, 每一组将 4 种模态的图像同时作为输入。本文按照 WT-Net、TC-Net 和 ET-Net 的顺序依次训练模型, 在级联网络的每一级当中分别对图像的轴向、矢向和冠向进行训练。由于 GPU 内存的限制, 本文在训练时将 WT-Net、TC-Net 和 ET-Net 的批量处理数据规模分别设为 1、2 和 4, 使用 Adam (adaptive moment estimation) 算法作为训练优化器, 初始学习率为 10^{-4} , 使用 L_2 正则化, 权重为 10^{-7} , 将 CRF-RNN 的迭代次数 T 设为 5。由于 GPU 内存的限制, 在训练阶段, 将原始的 3D 核磁共振图像裁剪成若干尺寸为 144 pixel×144 pixel×19 pixel 的切块作为 WT-Net 的输入, 在 WT-Net 训练阶段结束后, 根据 WT 的分割结果设定感兴趣区域的边界框作为 TC-Net 的输入, 而后再根据 TC 的分割结果设定边界作为最后一级网络 ET-Net 的输入。训练阶段结束后, 用验证集的 66 组无标签的 MR 图像进行测试, 通过 BraTS 2018 官方网站, 得到 WT、TC 和 ET 三个子区域分割结果的 Dice 系数^[23] 和 Hausdorff 距离^[24]。

3.3 实验结果分析

本文进行了一系列的对比实验, 以证明本文在 U-Net 网络中改进的方法有效。将含有帧内卷积和帧间卷积的级联 U-Net 网络作为基准 (Base), 分别加入空洞卷积 (DC)、多层特征融合机制 (MFF) 以及 CRF-RNN (CRF) 对比分割结果的 Dice 系数和

Hausdorff 距离 (HD)。此外, 比较了两种损失函数的作用: Dice 损失函数^[5] 以及 Dice 和交叉熵相结合的损失函数 (Dice+CE)^[25]。Dice 系数的高低反映了两张图片的相似度大小, 在训练阶段可以通过降低 Dice 损失函数的值来提高分割结果与标签的相似度, 然而 Dice 损失函数依然存在缺陷: 如果标签和分割结果中目标区域都很小, 损失函数的梯度会变得很大, 导致训练过程不稳定, 所以需要添加交叉熵损失函数作为补充项来弥补单个 Dice 损失函数的不足。在对比实验中, 默认的损失函数为 Dice 损失函数, Dice 损失函数与交叉熵损失函数的公式为

$$L_{\text{Dice}} = 1 - \frac{2 \cdot \sum_i p_i \times g_i}{\sum_i p_i + \sum_i g_i}, \quad (5)$$

$$L_{\text{Cross-Entropy}} = - \sum_i g_i \cdot \log \frac{\exp p_i}{\sum_i \exp p_i}, \quad (6)$$

其中 p_i 和 g_i 分别为预测图与标签中目标的像素点, 将两种损失函数相加可以实现 Dice 损失函数和交叉熵损失函数的结合。

表 1 为上述对比实验中 WT、TC 和 ET 三个子区域分割的 Dice 系数和 Hausdorff 距离, 结果表明加入空洞卷积、多层特征融合机制和 CRF-RNN 对分割结果有积极作用, Dice 和交叉熵结合的损失函数比只用 Dice 损失函数的分割结果要好。图 7 为从 BraTS 2019 数据集中的训练集挑选样例的分割结果, 与专家手动分割的标签 [图 7(a)] 相比, Base [图 7(b)] 中的 WT 区域含有大块的假阳性区

表 1 用 BraTS 2018 数据集中验证集(66 例)对不同的方法比较 Dice 系数和 Hausdorff 距离

Table 1 Dice scores and Hausdorff distances on BraTS 2018 validation set (66 cases) with different methods

Model	DiceWT	DiceTC	DiceET	HDWT	HDTC	HDET
Base	0.89150	0.80173	0.77798	14.90034	8.63881	5.17406
Base+DC	0.90298	0.81979	0.77562	8.07772	8.34964	5.23973
Base+DC+MFF	0.90587	0.82019	0.78639	5.72804	8.42580	4.39199
Base+DC+MFF(Dice+CE)	0.90749	0.82053	0.77983	5.51981	8.67849	3.06801
Base+DC+MFF+CRF(Dice+CE)	0.90932	0.82536	0.78549	3.81877	7.84873	4.32642




图 7 分割结果图

Fig. 7 Results of segmentation

域,并且存在一小块 ET 区域的假阴点区域,Base+DC[图 7(c)]和 Base+DC+MFF[图 7(d)]的分割结果中 WT 的假阳点区域有所改善,改用 Dice 和交叉熵结合的损失函数[图 7(e)]后改善了 ET 的假阴点区域,最后添加 CRF-RNN[图 7(f)]之后的分割结果进一步得到改善,与标签的相似度最高。

本文方法与其他方法进行比较,比较 BraTS 2018 数据集中验证集(66 例)分割结果的 Dice 系数和 Hausdorff 距离。Myronenko^[12]在编码-解码结构中加入额外的 VAE 分支,McKinley 等^[26]在浅层

类 U-Net 网络结构中的密集连接块中加入空洞卷积,Wang 等^[27]在级联 FCN 网络中加入各向异性卷积和空洞卷积,并做了数据增强,Mehta 等^[28]使用了 3D U-Net 网络,Hua 等^[29]使用级联 V-Net 网络。表 2 为本文使用的方法与其他方法在肿瘤整体、肿瘤核、增强肿瘤三个子区域的比较,使用 BraTS 2018 数据集中的验证集(66 例)对 Dice 系数和 Hausdorff 距离进行比较。通过对比可以看出,在使用单个模型的前提下,本文使用的方法在肿瘤整体的 Dice 系数和 Hausdorff 距离指标上具有较强优势。

表 2 使用 BraTS 2018 数据集中验证集(66 例)对比本文方法和其他方法

Table 2 Performance comparison of segmentation methods on BraTS 2018 validation set (66 cases)

Model	Dice WT	Dice TC	Dice ET	HD WT	HD TC	HD ET
Ours	0.90932	0.82536	0.78549	3.81877	7.84873	4.32642
Myronenko ^[12] (single model)	0.9042	0.8596	0.8145	4.4834	8.2777	3.8048
Mehta et al ^[28] (ensembles)	0.9092	0.8530	0.8137	4.4519	7.1535	2.7092
Mehta et al ^[28]	0.909	0.825	0.788	4.923	8.316	3.520
Wang et al ^[27]	0.908	0.869	0.807	5.86	6.09	3.01
Hua et al ^[29]	0.9048	0.8364	0.7768	5.1759	6.2780	3.5123
McKinley et al ^[26]	0.903	0.847	0.796	4.17	4.93	3.55

4 结 论

本文提出一种级联改进型 U-Net 网络结构,使用 4 种模态的 3D 脑肿瘤核磁共振图像,将患者的脑肿瘤图像划分为三个子区域。首先,使用三级级联的策略将多类分割任务简化为三个二类分割任务,依次对 WT、TC 以及 ET 三个子区域进行分割,将前一级网络的输出作为后一级网络的输入,降低了分割难度和网络复杂度,并且有效减少了假阳点。其次,在每一级网络中使用改进的 U-Net 网络:1)将 3D 卷积核替换为帧内卷积核与帧间卷积核,分别提取切片内部和切片之间的特征,在提取空间特征的同时节省了 GPU 内存;2)在解码路径上加入额外的多层特征融合机制,将解码器中每层特征图进行连接,融合上下文特征和细节特征作为输出,提高了分割准确度;3)使用空洞卷积扩大卷积核感受野,同时减少降采样层的数量,减少了细节特征的损失。此外,加入条件随机场构建的循环神经网络,结合改进的 U-Net 网络一起训练,进一步细化了分割结果。最后,将 Dice 损失函数替换为 Dice 与交叉熵结合的损失函数,克服了单个 Dice 损失函数的不足。基于本文方法对 BraTS 2018 数据集的 66 组验证集进行测试,获得肿瘤整体、肿瘤核、增强肿瘤的平均 Dice 系数为 0.90932、0.82536、0.78549, Hausdorff 距离为 3.81877、7.84873、4.32642。结果表明,本文方法优于脑肿瘤图像分割的大多数方法,可以得到精度较高的分割结果。

参 考 文 献

- [1] Ren L, Li Q, Guan X, et al. Three-dimensional segmentation of brain tumors in magnetic resonance imaging based on improved continuous max-flow[J]. *Laser & Optoelectronics Progress*, 2018, 55(11): 111011.
任璐, 李镛, 关欣, 等. 改进的连续型最大流算法脑肿瘤核磁共振成像三维分割[J]. *激光与光电子学进展*, 2018, 55(11): 111011.
- [2] Zhang X F, Liu J, Shi Z S, et al. Review of deep learning-based semantic segmentation[J]. *Laser & Optoelectronics Progress*, 2019, 56(15): 150003.
张祥甫, 刘健, 石章松, 等. 基于深度学习的语义分割问题研究综述[J]. *激光与光电子学进展*, 2019, 56(15): 150003.
- [3] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation [C] // *IEEE Transactions on Pattern Analysis and Machine Intelligence*, New York: IEEE Press, 2015: 640-651.
- [4] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M] // Navab N, Hornegger J, Wells W, et al. *Medical Image Computing and Computer-Assisted Intervention Cham: Springer*, 2015, 9351: 234-241.
- [5] Milletari F, Navab N, Ahmadi S A. V-net: fully convolutional neural networks for volumetric medical image segmentation [C] // *2016 Fourth International Conference on 3D Vision (3DV)*, October 25-28, 2016, Stanford, CA, USA. New York: IEEE Press, 2016: 565-571.
- [6] Chen L C, Papandreou G, Kokkinos I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2018, 40(4): 834-848.
- [7] Yu F, Koltun V. Multi-scale context aggregation by dilated convolutions [EB/OL]. (2016-04-30) [2020-08-17]. <https://arxiv.org/abs/1511.07122>.
- [8] 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.
- [9] Chen L C, Papandreou G, Schroff F, et al. Rethinking atrous convolution for semantic image segmentation [EB/OL]. (2017-06-17) [2020-08-17]. <https://arxiv.org/abs/1706.05587v1>.
- [10] Chen L C, Zhu Y K, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C] // Ferrari V, Hebert M, Sminchisescu C, et al. *Computer Vision-ECCV 2018*. Cham: Springer, 2018, 11211: 833-851.
- [11] Wang G T, Li W Q, Ourselin S, et al. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks [EB/OL]. 2017 [2020-08-17]. <https://arxiv.org/pdf/1709.00382.pdf>.
- [12] Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization [C] // Crimi A, Bakas S, Kuijf H, et al. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer, 2018, 11384: 311-320.
- [13] Malmi E, Parambath S, Peyrat J M, et al. CaBS: a cascaded brain tumor segmentation approach [C] // *Proceedings MICCAI Brain, Tumor Segmentation (BRATS)*. [S.l.: s.n.], 2015: 42-47.
- [14] Chu J H, Li X C, Zhang J Q, et al. Fine-grained segmentation method for three-dimensional brain

- tumors using cascaded convolutional network [J]. *Laser & Optoelectronics Progress*, 2019, 56(10): 101001.
- 褚晶辉, 李晓川, 张佳祺, 等. 一种基于级联卷积网络的三维脑肿瘤精细分割 [J]. *激光与光电子学进展*, 2019, 56(10): 101001.
- [15] Lafferty J, McCallum A, Pereira F, et al. Conditional random fields: probabilistic models for segmenting and labeling sequence data [C] // *Proceedings of 18th International Conference on International Conference on Machine Learning*, June 28-July 1, 2001, Williamstown, MA, USA. [S. l.]: International Machine Learning Society, 2001: 282-289.
- [16] Zheng S, Jayasumana S, Romera-Paredes B, et al. Conditional random fields as recurrent neural networks [C] // *2015 IEEE International Conference on Computer Vision (ICCV)*, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1529-1537.
- [17] Ioffe S, Szegedy C. Batch normalization: accelerating deep network training by reducing internal covariate shift [EB/OL]. (2015-03-02) [2020-08-17]. <https://arxiv.org/abs/1502.03167>.
- [18] He K M, Zhang X Y, Ren S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C] // *2015 IEEE International Conference on Computer Vision (ICCV)*, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1026-1034.
- [19] Menze B H, Jakab A, Bauer S, et al. The multimodal brain tumor image segmentation benchmark (BRATS) [J]. *IEEE Transactions on Medical Imaging*, 2015, 34(10): 1993-2024.
- [20] Bakas S, Akbari H, Sotiras A, et al. Advancing the cancer genome atlas glioma MRI collections with expert segmentation labels and radiomic features [J]. *Scientific Data*, 2017, 4: 170117.
- [21] Abadi M, Barham P, Chen J M, et al. TensorFlow: a system for large-scale machine learning [EB/OL]. (2016-05-27) [2020-08-17]. <https://arxiv.org/abs/1605.08695>.
- [22] Gibson E, Li W Q, Sudre C, et al. NiftyNet: a deep-learning platform for medical imaging [J]. *Computer Methods and Programs in Biomedicine*, 2018, 158: 113-122.
- [23] Thada V, Jaglan D V. Comparison of jaccard, dice, cosine similarity coefficient to find best fitness value for web retrieved documents using genetic algorithm [J]. *International Journal of Innovations in Engineering and Technology*, 2013, 2(4): 202-205.
- [24] Huttenlocher D P, Klanderman G A, Rucklidge W J. Comparing images using the Hausdorff distance [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1993, 15(9): 850-863.
- [25] Isensee F, Kickingereder P, Wick W, et al. No new-net [EB/OL]. (2019-01-31) [2020-08-17]. <https://arxiv.org/abs/1809.10483?context=cs.CV>.
- [26] McKinley R, Meier R, Wiest R. Ensembles of densely-connected CNNs with label-uncertainty for brain tumor segmentation [C] // Crimi A, Bakas S, Kuijf H, et al. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer, 2018, 11384: 456-465.
- [27] Wang G T, Li W Q, Ourselin S, et al. Automatic brain tumor segmentation based on cascaded convolutional neural networks with uncertainty estimation [J]. *Frontiers in Computational Neuroscience*, 2019, 13: 56.
- [28] Mehta R, Arbel T. 3D U-net for brain tumour segmentation [C] // Crimi A, Bakas S, Kuijf H, et al. *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer, 2018, 11384: 254-266.
- [29] Hua R, Huo Q, Gao Y Z, et al. Multimodal brain tumor segmentation using cascaded V-nets [M] // *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Cham: Springer, 2019: 49-60.