

一种改进的三维双路径脑肿瘤图像分割网络

张恒良, 李镛*, 关欣

天津大学微电子学院, 天津 300072

摘要 近几年,深度学习在生物医学图像处理中的应用得到了广泛关注。从深度学习的基本理论和医学领域应用出发,提出了一种改进的三维双路径脑肿瘤图像分割网络,用于提高核磁共振成像序列中对脑肿瘤各个区域的检测精度。所提算法以 3D-UNet 为基础架构,首先,使用改进的双路径网络单元构成类似于 UNet 的编码-解码器结构,该网络单元在保留原有特征的同时,还可以在脑肿瘤的纹理、形状和边缘等方面产生新特征,来提高网络分割精度;其次,在双路径网络模块中加入多纤结构,在保证分割精度的同时减少了参数量;最后,在每个网络模块中的组卷积之后加入通道随机混合模块来解决组卷积导致的精度下降问题,并使用加权 Tversky 损失函数替代 Dice 损失函数,提高了小目标的分割精度。所提模型的平均 Dice_ET、Dice_WT 和 Dice_TC 均优于 3D-ESPNet、DeepMedic、DMFNet 等算法。该研究结果具有一定的现实意义和应用前景。

关键词 图像处理; 神经网络; 双路径网络; 脑肿瘤图像分割; 加权损失函数

中图分类号 TP391.41

文献标志码 A

doi: 10.3788/AOS202141.0310002

An Improved Three-Dimensional Dual-Path Brain Tumor Image Segmentation Network

Zhang Hengliang, Li Qiang*, Guan Xin

School of Microelectronics, Tianjin University, Tianjin 300072, China

Abstract In recent years, the application of deep learning in biomedical image processing has received widespread attention. Based on the basic theories of deep learning and medical applications, this paper proposes an improved three-dimensional dual-path brain tumor image segmentation network to improve the detection accuracy of brain tumors in nuclear magnetic resonance imaging sequences. The proposed algorithm is based on 3D-UNet. First, the improved dual-path network unit is used to form the encoder-decoder structure similar to UNet. While retaining the original features, the network unit can also generate new features in texture, shape, and edge of the brain tumor to improve the accuracy of network segmentation. Second, the multi-fiber structure is added to the dual-path network module, which reduces the amount of parameters while ensuring the accuracy of the segmentation. Finally, after the group convolution in each network module, the channel random mixing module is added to solve the problem of accuracy reduction caused by group convolution, and the weighted Tversky loss function is used to replace the Dice loss function to improve the segmentation accuracy of small targets. The average Dice_ET, Dice_WT, and Dice_TC of the proposed model are better than 3D-ESPNet, DeepMedic, DMFNet, and other algorithms. The research results have certain practical significance and application prospects.

Key words image processing; neural networks; dual-path network; brain tumor image segmentation; weighted-loss function

OCIS codes 100.3008; 200.4260; 100.4996

收稿日期: 2020-08-10; 修回日期: 2020-09-08; 录用日期: 2020-09-15

基金项目: 国家自然科学基金(61471263)、天津市自然科学基金(16JCZDJC31100)

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

1 引言

脑肿瘤是颅内肿瘤的简称,脑肿瘤由无法控制的脑部细胞组成,任何脑肿瘤都会占据颅内的空间并导致各种致命的健康问题。脑胶质瘤是最常见的原发性颅脑恶性肿瘤,脑胶质瘤形状不规则、体积不定,可能出现在大脑中的任何位置。万幸的是,和其他肿瘤一样,早期诊断可以改善脑肿瘤的治疗过程、增加患者的生存机会,因此对脑肿瘤的准确分割具有重要意义^[1]。现在有很多技术手段可以对脑肿瘤进行成像,其中最常用的是核磁共振成像(MRI),脑肿瘤图像在 MRI 序列中对比度明显,可以给医疗工作者提供丰富的脑肿瘤信息^[2]。

目前,随着卷积神经网络(CNN)的快速发展,很多研究人员将深度学习应用于医学图像领域^[3]。童云飞等^[4]和任璐等^[5]采用模糊 C 均值算法对脑肿瘤进行分割,但该算法属于半自动算法且容易陷入局部最优,导致分割精度不高。Ronneberger 等^[6]提出的 UNet 网络结构使用二维(2D)卷积对医学图像进行分割处理,其中的编码器和解码器可以将网络中的低级特征和高级特征连接起来,但 2D 卷积只能提取单张切片的信息,会导致脑肿瘤立体信息的丢失。褚晶辉等^[7]对 2D 图像处理后拼接起来形成三维(3D)图像,但拼接图像可能会出现锯齿、断层等问题。Çiçek 等^[8]在 UNet 基础上扩展为 3D-UNet,可以充分提取整体信息,提高了算法的精度。何承恩等^[9]在 3D-UNet 基础上使用混合膨胀卷积代替常规卷积,但最终分割精度不高。邢波涛等^[10]使用全卷积神经网络对融合了三种模态的脑肿瘤图像进行粗分割,然后使用条件随机场进行细分割,但融合后的图像丢失了较多特征信息,最终分割精度不高。Chen 等^[11]在 3D-UNet 基础上提出了 MFNet 与 DMFNet 脑肿瘤分割算法,使用多纤结构减少了参数量并保证了精度,同时使用了类似 3D-ESP^[12]的网络结构,该结构使用多个膨胀率不同的卷积核对输入图像分别卷积,然后将上一步生成的卷积结果按照一定规则拼接起来得到最终结果,由于使用了过多的膨胀卷积,该结构在增加感受野的同时丢失了许多图像特征。

为此,本文提出一种改进的三维双路径脑肿瘤图像分割网络,该网络以 3D-UNet 为基础架构,使用改进的双路径网络单元作为基本模块,该模块可以增加脑肿瘤的抽象特征,有效提高网络的分割精度。在改进的双路径网络单元中引入多纤结构,该

结构不仅参数量较少而且保证了脑肿瘤分割精度,并在此基础上将原本的常规卷积变为分组卷积,在分组卷积之后加入通道随机混合模块^[13],以降低分组卷积导致的精度下降影响。在损失函数方面,本文在 Tversky 损失函数^[14]的基础上引入类别权重得到加权损失函数(WTL),降低了在小目标分类时误分类的梯度变化影响,提高了对于小目标的分割精度。

2 脑肿瘤分割网络框架

2017 年,Chen 等^[15]提出了双路径网络(DPN),该网络融合了残差网络^[16]和密集连接网络^[17]的优点。为了提高脑肿瘤分割精度,本文以双路径网络的核心模块作为脑肿瘤分割基础网络模块,并在该模块中引入多纤结构和通道随机混合模块,使用 WTL 作为损失函数,使训练中的梯度变化更加稳定。最终形成拥有多纤结构的双路径脑肿瘤图像分割网络(DPN-MS)。

2.1 DPN-MS 网络结构

残差网络提高了特征的再利用率,但不擅长挖掘新的特征。密集连接网络善于挖掘新的特征,但同时也带来了较多的冗余特征。双路径网络综合了残差网络和密集连接网络的优点。

DPN-MS 网络以 3D-UNet 作为主干特征提取网络,在网络中加入双路径结构、多纤结构和通道随机混合模块形成双路径脑肿瘤图像分割网络,DPN-MS 网络结构如图 1 所示。方框里的数字是特征图像的大小(深度×宽度×高度×通道),连接线上的数字是卷积核的大小(通道深度×宽度×高度)。首先对输入图像进行步长为 2 的卷积操作,该卷积将输入图像的尺寸变小,相比于池化操作其精度更高。然后在编码网络中,使用下采样层和三个连续的 DPN-MSUint 对输入图像进行处理。最后在解码网络中,特征图由上采样层和 DPN-MSUint 进行处理,然后将解码网络与编码器网络中的对应层使用拼接操作将低级特征和高级特征连接起来。低级特征可以提供类别识别依据,高级特征可以提供精确分割的定位依据,这种连接结构适用于医学图像处理。

2.2 DPN-MSUint

本文对双路径网络的基本模块进行改进,在该模块中加入多纤结构,并且在分组卷积之后增加通道随机混合模块,用来提高分割精度,最终形成双路径模块 DPN-MSUint。图 2 为 DPN-MSUint 的示意图。

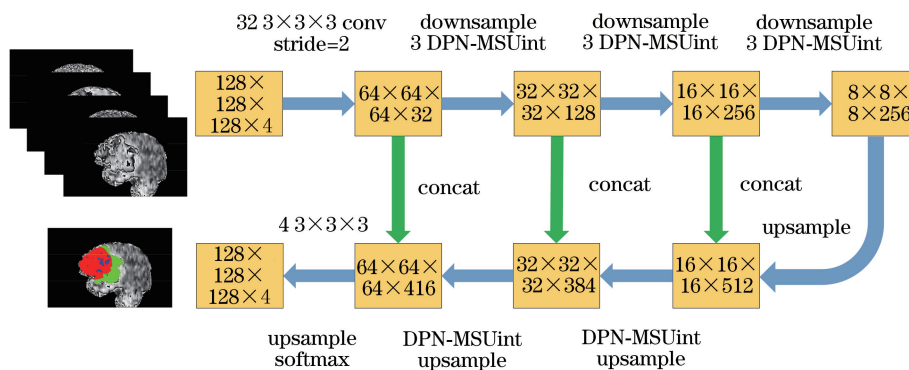


图 1 DPN-MS 网络结构

Fig. 1 Structure of DPN-MS

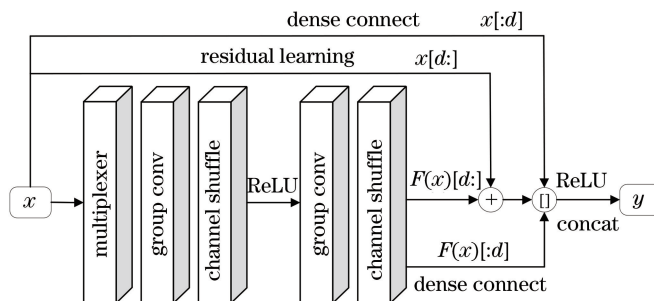


图 2 DPN-MSUint 模块结构

Fig. 2 Module structures of DPN-MSUint

从图 2 可以看出,该模块相比 MFUint 模块增加了密集连接,密集连接善于挖掘数据中新的特征,可以提高最终的分割精度,该模块可以表示为

$$y = G\{x[d:] + F(x)[d:], F(x)[:d], x[:d]\}, \quad (1)$$

式中: y 为双路连接的整体特征图; F 为卷积层; G 为 Relu 激活函数; d 为超参数,表示进行密集连接后增加的特征; $[:d]$ 表示从起始通道到 d 的通道数; $[d:]$ 表示从 d 到末尾通道的通道数; $x[d:] + F(x)[d:]$ 为残差连接部分。将残差连接部分、 $F(x)[:d]$ 以及 $x[:d]$ 三部分进行拼接,最终通过 Relu 激活函数输出。

图 3 为图 2 中的多纤结构,该结构将 1×1 卷积替换为两个 1×1 卷积,然后将中间通道变为输入通道的 $1/4$,该结构在保持分割精度的同时,减少了一半的参数量。

2.3 分组卷积

使用 3D-UNet 网络架构的脑肿瘤分割会产生较多的参数量,因此如何在使用较少参数量的同时保持脑肿瘤分割精度是个很重要的问题。分组卷积可以减少参数量,将输入特征图和输出特征图的通道进行分组,然后在每个组内进行卷积,这样会使卷




图 3 多纤结构

Fig. 3 Structure of multiplexer

积核的尺寸按分组数量减少,从而大幅减少参数量。但连续使用分组卷积会导致不同组之间的特征图互相没有联系,降低了特征提取能力。为了尽量消除分组卷积带来的影响,本文引入 ShuffleNet^[13] 中的通道随机混合模块,该模块将经过分组卷积后的通道均匀打乱并混合起来,增强了整体的特征提取能力。

图 4 为常规卷积、分组卷积和使用了通道随机混合模块的分组卷积等三种卷积在二维图像中的示意图。图 4(a)为常规卷积,图 4(b)为分组卷积,图 4(c)为使用了通道随机混合模块的分组卷积。图 4 中 H_1 、 W_1 、 C 分别表示输入图像的高度、宽度以及通道数, H_2 、 W_2 、 N 分别表示输出图像的高度、宽度以及通道数, k 为卷积核的尺寸, g 为分组数。图像经过分组卷积之后,该图像中的几个组之间联系较

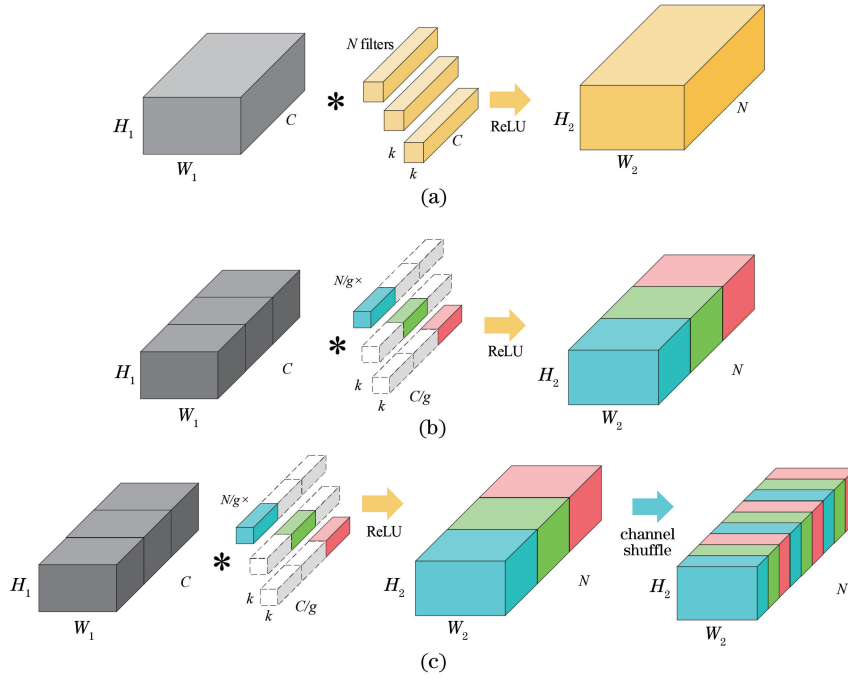


图 4 三种卷积的对比示意图。(a)常规卷积;(b)分组卷积;(c)使用了通道随机混合模块的分组卷积
Fig. 4 Comparison diagram of three convolutions. (a) Conventional convolution; (b) group convolution;
(c) group convolution with channel random mixing module

少,不利于特征的整体提取,由图 4(c)可以看出,经过通道随机混合模块之后,各个组之间的联系加强。

2.4 加权损失函数

在脑肿瘤分割中某些脑肿瘤仅占据脑部很小的一部分,属于小目标分割,在训练过程中容易陷入局部极小值,影响网络的分割精度。为了解决这个问题,本文提出一种基于 Tversky 损失改进的加权损失函数,Tversky 损失函数定义为

$$L_T = 1 - \frac{P_{TP,i}}{P_{TP,i} + \alpha P_{FP,i} + \beta P_{FN,i}}, \quad (2)$$

式中: $P_{TP,i}(l)$ 、 $P_{FP,i}(l)$ 和 $P_{FN,i}(l)$ 分别是类别 l 在第 i 个像素点处的真阳性、假阳性和假阴性的预测概率,假阳性和假阴性之间的权衡由 α 和 β 两个参

数控制。以上三种预测概率的具体定义分别为

$$P_{TP,i}(l) = \sum_i p_{li} q_{li}, \quad (3)$$

$$P_{FN,i}(l) = \sum_i (1 - p_{li}) q_{li}, \quad (4)$$

$$P_{FP,i}(l) = \sum_i p_{li} (1 - q_{li}), \quad (5)$$

式中: p_{li} 为类别 l 在第 i 个像素点处的预测概率值; q_{li} 为类别 l 在第 i 个像素点处的标签。在进行多分类时,该损失函数效果不理想,因此本文使用权重参数 ω_l 对多个类别的损失函数进行调整。 ω_l 定义为

$$\omega_l = \frac{1}{\left(\sum_{i=1}^n q_{li}\right)^2 + \epsilon}. \quad (6)$$

为了保证分母不为零, $\epsilon = 1 \times 10^{-5}$,本文改进后的加权损失函数定义为

$$L_{WT} = 1 - \frac{\sum_{l=1}^k \omega_l \sum_i p_{li} q_{li}}{\sum_{l=1}^k \omega_l \left[\sum_i p_{li} q_{li} + \alpha \sum_i p_{li} (1 - q_{li}) + \beta \sum_i (1 - p_{li}) q_{li} \right]}. \quad (7)$$

本文中取 $\alpha + \beta = 1.0$ 。由实验可知,当 $\alpha = \beta = 0.5$ 时,网络的分割精度最高。

3 实验结果与分析

3.1 实验环境与数据集

本文的实验环境如下:CPU Intel © Core i9-9900X 3.5 GHz,GPU Nvidia RTX2080Ti(11GB)×4,

Ubuntu 16.04 操作系统,Pytorch 深度学习框架。

实验采用脑肿瘤数据库 BRATS 2018^[18],BRATS 2018 的训练集有 285 个病例,测试集有 66 个病例,每个病例都有四种模态(T1、T1ce、T2、FLARE),每种模态的图像大小均为 $240 \times 240 \times 155 \times 1$,真实标签由 1~4 位经验丰富的医师手动标定。该数据集拥有一个在线评估服务器,可以用来

验证算法的有效性。本文设计的脑肿瘤图像分割实验均在 BRATS-18 数据集上进行训练,在该数据集的在线服务器上进行测试。

3.2 评价标准

从有效性和复杂度两方面对算法进行评估。算法的有效性可以使用分割精度和豪斯多夫距离(D_{HD})两个指标进行衡量,分割精度主要取决于相似系数(D_{sc})。相似系数表达式为

$$D_{sc} = 2 \times \frac{|P \wedge T|}{|P| + |T|}, \quad (8)$$

式中: P 为预测的结果; T 为医师标记的标签。由于相似系数对于边缘的刻画不够敏感,而 D_{HD} 对于分割出的边界比较敏感,因此使用 D_{HD} 作为另一指标对实验结果做出补充。 D_{HD} 的表达式为

$$D_{HD} = d_H(X, Y) = \max\{\sup_{x \in X, y \in Y} d(x, y), \sup_{y \in Y, x \in X} d(x, y)\}. \quad (9)$$

算法的复杂度可以使用参数量和计算量(O_{FP})进行量化,参数量可以对应算法的空间复杂度,计算量可以对应算法的时间复杂度,参数量和计算量的表达式为

$$P = (k_d \times k_h \times k_w \times C_{in} + 1) \times C_{out}, \quad (10)$$

$$O_{FP} = [(k_d \times k_h \times k_w \times C_{in}) + (k_d \times k_h \times k_w \times C_{in} - 1) + 1] \times C_{out} \times d \times h \times w, \quad (11)$$

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} 分别表示输入和输出的通道数量; $d, h,$

表 1 不同参数在脑肿瘤图像分割中的性能对比

Table 1 Comparison of different parameters in brain tumor image segmentation

Penalties	$D_{sc} / \%$			D_{HD}		
	ET	WT	TC	ET	WT	TC
$\alpha=0.5, \beta=0.5$	80.56	90.23	86.28	2.91	3.97	5.65
$\alpha=0.4, \beta=0.6$	79.23	89.89	85.02	2.50	5.11	6.05
$\alpha=0.3, \beta=0.7$	80.16	89.92	84.59	2.43	3.92	6.21
$\alpha=0.2, \beta=0.8$	80.30	90.02	84.06	2.58	4.15	6.38
$\alpha=0.1, \beta=0.9$	79.09	89.48	82.16	2.63	4.14	7.86

为了验证本文算法的性能和分割结果,分别将本文算法与 3D-UNet^[8]、3D-ESPNet^[12]、DeepMedic^[19]、MFNet^[11]、DMFNet^[11] 和 NVDLMED^[20] 等深度学习算法对脑肿瘤图像的分割结果进行对比,对比结果如表 2 所示。由表 2 可知,本文提出的 DPN-MS 网络在 ET、WT、TC 上的 D_{sc} 分别达到了 80.56%、90.23%、86.28%。与该数据集上分割精度最高的网络模型 NVDLMED 相比,本文算法在 ET 区和 WT 区与其相差 1.17% 和

w 分别表示图像的深度、高度和宽度。

医师将脑肿瘤区域分为四类,分别是:背景(标记为 0)、坏死核心和非增强肿瘤(标记为 1)、水肿区域(标记为 2)和增生性肿瘤(标记为 4)。对于增强肿瘤区 ET(标签 1)、整体肿瘤区 WT(标签 1、2 和 4)以及核心肿瘤区 TC(标签 1、4),该数据集在线评估服务器的 D_{sc} 分数可以分为 Dice_ET、Dice_WT 和 Dice_TC。

3.3 参数设置

由于该数据集数据量较少,为了增加训练数据,本文对大小为 $240 \times 240 \times 155$ 的脑肿瘤 MRI 序列进行随机裁剪处理,裁剪后的大小为 $128 \times 128 \times 128$,然后通过沿任意轴向的镜像翻转操作,将裁剪后的图像在 $-10^\circ \sim 10^\circ$ 之间随机旋转。网络使用 Adam 优化器,学习率的初始值为 0.001,使用 L2 范数作为正则化系数,初始值设定为 1×10^{-5} ,为了充分使用实验设备的显存资源,本文将批处理量设定为 8,共训练 500 轮。在训练过程中,学习率随训练轮数的增加而降低,确保训练趋于稳定。

3.4 结果与分析

为了验证本文提出的加权损失函数中参数 α 和 β 对算法性能和分割结果的影响,本文设置了 5 组不同的取值。表 1 对比了不同取值下的算法在数据集上的分割精度,可以看出,当 $\alpha = \beta = 0.5$ 时,损失函数在测试集中的 ET、WT、TC 三个指标上取得了领先的结果。在 D_{HD} 的 ET 区没有显著差异,在 WT 和 TC 两个区域上差距较大。

0.45%,在 TC 区比该算法高 0.26%。但该网络的参数量和计算量达到了 40.06 M 和 1495.5 G,是本文网络的 6.57 倍和 59.31 倍。实验结果表明,本文所提模型在算法复杂度较低的情况下,可以有效提高脑肿瘤图像分割的精度。

图 5 为 DMFNet 和本文算法在测试集上的 Dice 箱型图,箱型图可以很好地说明算法的稳定性。图 5 中最上方和最下方的线段表示数据的最大值和最小值,其中矩形上方和下方的线段分别表示

第三四分位数和第一四分位数,矩形中间的线段表示中位数。从图 5 和表 2 的 Dice 结果中可以看出,本文算法与 DMFNet 相比,在 ET 和 TC 区域的稳

定性都较高,在 WT 区的稳定性不如 DMFNet。但从算法的精度与复杂度来看,本文算法的整体性能优于其他算法。

表 2 不同算法在脑肿瘤图像分割中的性能对比

Table 2 Comparison of different algorithms in brain tumor image segmentation

Model	P / M	O_{FP} / G	$D_{sc} / \%$			D_{HD}		
			ET	WT	TC	ET	WT	TC
3D-UNet ^[8]	16.21	1669.53	75.96	88.53	71.77	6.04	17.10	11.62
3D-ESPNet ^[12]	3.63	76.51	73.70	88.30	81.40	—	—	—
DeepMedic ^[19]	9.45	203.96	78.75	90.47	81.35	3.81	4.32	7.56
MFNet ^[11]	3.19	20.61	79.91	90.43	84.61	2.68	4.68	6.31
DMFNet ^[11]	3.88	27.04	80.12	90.62	84.54	3.06	4.66	6.44
NVDLMED ^[20]	40.06	1495.50	81.73	90.68	86.02	3.82	4.52	6.85
DPN-MS	6.09	25.21	80.56	90.23	86.28	2.91	3.97	5.65




图 5 测试集的 Dice 箱型图。(a) DMFNet;(b) DPN-MS

Fig. 5 Dice box diagram on test set. (a) DMFNet; (b) DPN-MS

图 6 为本文算法在部分病例上的可视化分割结果图,分别为大脑的水平面、矢状面和冠状面的胶质瘤图像。通过图 7 中的 Flair 和 T1 模态可以看出脑肿瘤各个区域的边界,其中 GT 代表真实标签。

与真实标签的对比可以看出,本文算法在该病例的 WT 和 ET 区的预测结果与真实标签几乎没有差别,当矢状面和冠状面上的 TC 区形状不规则时,本文模型预测结果也和真实标签相差不多。

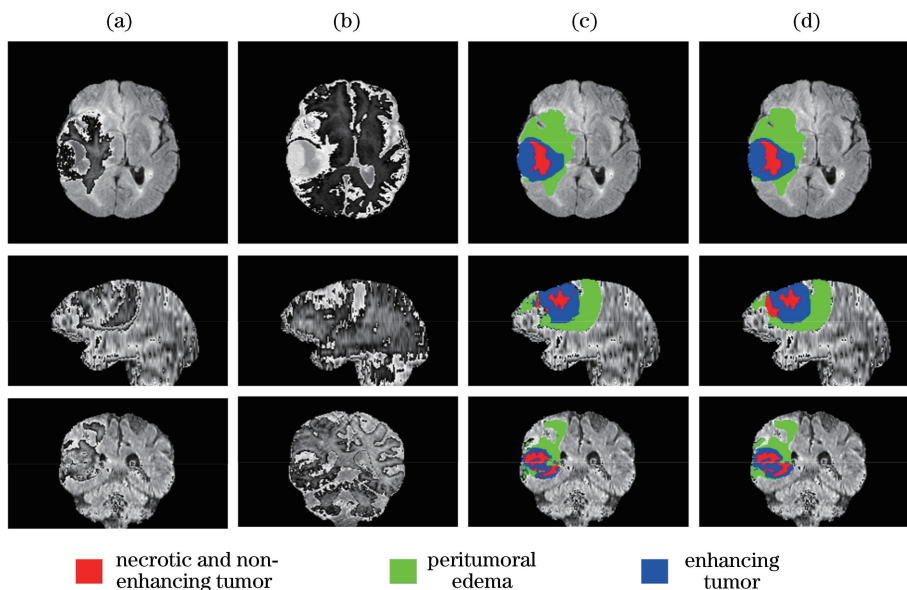


图 6 分割结果图。(a) Flair;(b) T1;(c)真实标签;(d) DPN-MS

Fig. 6 Graph of segmentation results. (a) Flair; (b) T1; (c) GT; (d) DPN-MS

图 7 为 Flair、GT、3D-ESPNet、DMFNet 以及本文算法在部分病例上的分割效果对比图,在图 7 第一行的对比中可以看出,本文算法在整体形态上与真实标

签最接近,其他算法在 TC 区与真实标签的差别较大。在图 7 第二行的对比中可以看出,对小目标进行分割时,本文算法得到的最终分割图与真实标签最为接近。

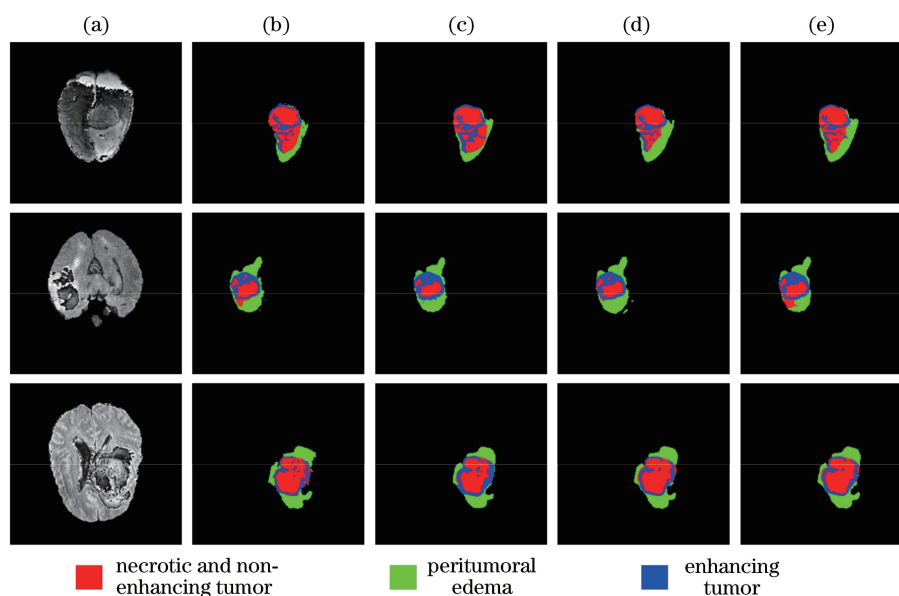


图 7 分割结果对比图。(a) Flair;(b)真实标签;(c) 3D-ESPNet;(d) DMFNet;(e) DPN-MS

Fig. 7 Comparison of segmentation results. (a) Flair; (b) GT; (c) 3D-ESPNet; (d) DMFNet; (e) DPN-MS

4 结 论

针对现有脑肿瘤分割算法精度不高的问题,本文提出一种改进的三维双路径脑肿瘤图像分割网络,目的是提高 MRI 序列中对脑肿瘤各个区域的检测精度。该算法一方面使用改进的双路径网络单元作为网络中的基本模块,该单元通过引入多纤维结构和通道随机混合模块,在参数量较少的情况下保证了分割精度。另一方面在 Tversky 损失函数的基础上加以改进,形成了加权损失函数,该损失函数提高了小目标的分割精度。在 Brats-18 数据集上的实验结果表明,本文算法的平均 Dice_ET、Dice_WT 和 Dice_TC 分别达到了 80.56%、90.23% 和 86.28%。从最终的分割精度和算法的整体复杂度来看,本文算法优于 3D-ESPNet、DeepMedic、DMFNet 等算法。

参 考 文 献

- [1] 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.
- [2] Abd-Ellah M K, Awad A I, Khalaf A A M, et al. A review on brain tumor diagnosis from MRI images: practical implications, key achievements, and lessons learned[J]. Magnetic Resonance Imaging, 2019, 61: 300-318.
- [3] Li Q, Bai K X, Zhao L, et al. Progresss and challenges of MRI brain tumor image segmentation [J]. Journal of Image and Graphics, 2020, 25(3): 419-431.
李镛, 白柯鑫, 赵柳, 等. MRI 脑肿瘤图像分割研究进展及挑战 [J]. 中国图象图形学报, 2020, 25(3): 419-431.
- [4] Tong Y F, Li Q, Guan X. An improved multi-modal brain tumor segmentation hybrid algorithm [J]. Journal of Signal Processing, 2018, 34(3): 340-346.
童云飞, 李镛, 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.
- [5] 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磁共振成像三维分割 [J]. 激光与光电子学进展, 2018, 55(11): 111011.
- [6] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation [C] // Medical Image Computing and Computer-Assisted Intervention - MICCAI 2015, 2015: 234-241.
- [7] 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.
- [8] Çiçek 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*, 2016: 424-432.
- [9] He C E, Xu H J, Wang Z, et al. Automatic segmentation algorithm for multimodal magnetic resonance-based brain tumor images[J]. *Acta Optica Sinica*, 2020, 40(6): 0610001.
- 何承恩, 徐慧君, 王忠, 等. 多模态磁共振脑肿瘤图像自动分割算法研究[J]. *光学学报*, 2020, 40(6): 0610001.
- [10] Xing B T, Li Q, Guan X. A brain tumor image segmentation method based on improved fully convolutional neural network [J]. *Journal of Signal Processing*, 2018, 34(8): 911-922.
- 邢波涛, 李镛, 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.
- [11] Chen C, Liu X P, Ding M, et al. 3D dilated multi-fiber network for real-time brain tumor segmentation in MRI[C]//*Medical Image Computing and Computer Assisted Intervention - MICCAI 2019*, 2019: 184-192.
- [12] 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*, 2019: 245-253.
- [13] Zhang X Y, Zhou X Y, Lin M X, et al. ShuffleNet: an extremely efficient convolutional neural network for mobile devices [C] // *2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*, June 18-23, 2018, Salt Lake City, UT, USA. New York: IEEE Press, 2018: 6848-6856.
- [14] Salehi S S M, Erdogmus D, Gholipour A. Tversky loss function for image segmentation using 3D fully convolutional deep networks [C] // *Machine Learning in Medical Imaging*, 2017: 379-387.
- [15] Chen Y, Li J, Xiao H, et al. Dual path networks [C] // *Advances in Neural Information Processing Systems*, 2017: 4467-4475.
- [16] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C] // *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [17] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks [C] // *2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, July 21-26, 2017, Honolulu, HI, USA. New York: IEEE Press, 2017: 2261-2269.
- [18] 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.
- [19] Kao P Y, Ngo T, Zhang A, et al. Brain tumor segmentation and tractographic feature extraction from structural MR images for overall survival prediction [C] // *Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*, 2019: 128-141.
- [20] Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization [M]. Cham: Springer International Publishing, 2019: 311-320.