

多视图卷积轻量级脑肿瘤分割算法

单成响, 李强*, 关欣

天津大学微电子学院, 天津 300072

摘要 脑肿瘤分割对医学图像处理领域发展与人类健康都具有积极意义。针对三维卷积神经网络存在复杂度大且对硬件设备要求高等问题, 提出一种多视图卷积轻量级脑肿瘤分割算法。首先使用复用器模块有效融合各通道间的信息, 并为模型增加提取非线性特征的能力。其次使用伪三维卷积分别从轴向位、矢状位和冠状位进行卷积, 并加入组卷积以节约计算资源和降低设备显存使用。最后使用可训练参数权衡不同视图下提取的特征的重要性, 提高模型分割精度。此外, 实验使用分布式数据并行方法训练模型, 以提升图形处理器的利用率。在 2019 年脑肿瘤分割大赛公开数据集上的实验结果表明, 所提算法的平均 Dice 相似度系数仅低于第一名算法 2.52 个百分点, 然而参数量与浮点运算次数分别降低了 84.83% 和 96.67%, 且平均 Dice 相似度系数高于第二名算法 0.05%。通过对比实验分析, 验证了所提算法的精确与轻量, 为脑肿瘤分割模型的广泛应用提供了可能性。

关键词 多视图; 卷积神经网络; 脑肿瘤分割; 深度学习; 轻量级

中图分类号 TP391.7 文献标志码 A

DOI: 10.3788/LOP220774

Lightweight Brain Tumor Segmentation Algorithm Based on Multi-View Convolution

Shan Chengxiang, Li Qiang*, Guan Xin

School of Microelectronics, Tianjin University, Tianjin 300072, China

Abstract Brain tumor segmentation is significant in the development of medical image processing and human health. Owing to the high complexity and sophisticated requirements for the hardware equipment of 3D convolutional neural networks, this paper proposes a lightweight multi-view convolutional brain tumor segmentation algorithm. First, a multiplexer module is used to effectively fuse the information between each channel, and the extraction ability for nonlinear features is added to the model. Second, pseudo 3D convolution is used to perform convolution from axial, sagittal, and coronal positions, and group convolution is added to save computing resources and reduce device memory usage. Finally, trainable parameters are used to weigh the importance of features extracted from different views to improve the segmentation accuracy of the model. In addition, the distributed data parallel method is used to train the model to improve the graphics processing unit (GPU) usage. Experiments on the public dataset of the 2019 Brain Tumor Segmentation competition demonstrate that the average Dice similarity coefficient of the proposed algorithm is only 2.52 percentage points lower than that of the first-place algorithm, however, number of parameters and floating-point operations are reduced by 84.83% and 96.67% respectively, and the average Dice similarity coefficient is 0.05% higher than that of the runner-up algorithm. A comparative experimental analysis verifies the accuracy and lightness of the proposed algorithm, indicating the possibility for wide applicability of brain tumor segmentation models.

Key words multi-view; convolutional neural network; brain tumor segmentation; deep learning; lightweight

1 引言

脑肿瘤是脑中生长异常的细胞群^[1], 时刻威胁着

人们的生命。脑肿瘤可分为良性与恶性肿瘤, 良性肿瘤细胞分化良好且预后较好, 恶性肿瘤细胞分化不良, 通常难以治愈。数据显示, 脑肿瘤发病率约占全身肿

收稿日期: 2022-02-21; 修回日期: 2022-03-23; 录用日期: 2022-04-06; 网络首发日期: 2022-04-16

基金项目: 国家自然科学基金(62071323, 61471263, 61872267)、天津市自然科学基金(16JCZDJC31100)、天津市科技计划项目(20YDTPJC01110)、天津大学自主创新基金(2021XZC-0024)

通信作者: *liqiang@tju.edu.cn

瘤发病率的 1.4%，死亡率超过 2.4%^[2]，全球脑肿瘤死亡病例约占所有癌症死亡病例 2.5%^[3]。

原发性中枢神经系统淋巴瘤与胶质瘤是成年人中最常见的脑肿瘤类型，其中胶质瘤占恶性肿瘤 80% 以上^[4]。根据世界卫生组织制定的分级系统，胶质瘤可分为低级别胶质瘤(LGG)与高级别胶质瘤(HGG)。LGG 发展较慢，可通过手术进行治疗，HGG 通常难以治愈，生存时间较短。因此，快速有效分割胶质瘤对人类健康有着重要意义。

核磁共振成像技术(MRI)具有无侵入性、多参数成像等优点^[5]，目前已成为脑肿瘤诊断中使用的主要技术手段之一。脑肿瘤 MRI 数据包括 T2 (T2-weighted)、FLAIR (fluid attenuated inversion recovery)、T1 (T1-weighted) 和 T1c (contrast enhanced T1-weighted) 4 种模态图像，且不同模态图像强调不同信息。

Krizhevsky 等^[6]在 2012 年 ImageNet 图像分类大赛^[7]上凭借卷积神经网络(CNN)以远超第二名的好成绩夺冠后，CNN 迅速进入到大众的视野，并广泛应用于各类图像处理领域。

国内外使用 CNN 对脑肿瘤进行分割的方法大致可以分为基于二维 CNN 和三维 CNN 两种。尽管已有基于 U-Net^[8]、FCN^[9]、GoogLeNet^[10]等相关模型的二维 CNN 脑肿瘤分割算法，并且这些算法取得了不错的分割效果，然而脑肿瘤 MRI 是三维图像，使用二维 CNN 方法进行分割容易忽略三维数据间的联系，且在最终分割结果中会出现锯齿、断层等问题。由此可知，在硬件资源条件允许的情况下，三维 CNN 是脑肿瘤分割任务中的首选方法。Jiang 等^[11]利用级联三维 CNN 方法，首先获取第一个三维 CNN 模型的粗略输出结果，其次将此结果结合原始脑肿瘤 MRI 数据作为第二个三维 CNN 的输入，得到细化分割结果，取得了 2019 年脑肿瘤分割大赛 (BraTS) 第一名的好成绩。Zhao 等^[12]通

过三维 CNN 融合半监督学习、架构设计等方法对脑肿瘤 MRI 进行端到端分割，取得了 2019 年 BraTS 第二名。McKinley 等^[13]将局部注意力机制与 CNN 相结合，提高对特征的选择能力，有助于提升算法的分割准确率。AMPNet^[14]使用多尺度模块，用于解决原始输入数据在训练过程中信息丢失的问题。González 等^[15]提出一种多尺度输入模块，对脑肿瘤 MRI 的 4 个模态数据进行处理后再送入模型进行训练，有效提高分割精度。Xu 等^[16]将注意力机制引入三维 CNN 中，帮助网络专注图像中与任务相关的区域，提升模型的灵活性。Bhalerao 等^[17]将残差连接与 3D U-Net^[18]结合，并使用随机失活缓解过拟合现象。尽管上述三维 CNN 脑肿瘤分割方法均取得了不错的效果，然而存在显存占用多、参数量与计算量大等缺点，致使模型训练过程中对设备需求与计算资源要求均较高，阻碍了相关研究的发展。

针对上述问题，本文提出一种基于伪三维卷积的多视图轻量级脑肿瘤分割算法，该算法不仅能够取得较好的分割结果，与此同时，具有减少参数量、节省计算资源和降低显存占用等优势，为提升三维 CNN 图像分割模型的高效性提供了参考。

2 算法框架及原理

2.1 算法整体框架

所提算法以多视图卷积(MVC)单元为基础结构，算法整体框架如图 1 所示。算法沿用 3D U-Net^[19]解码与编码两条路径。编码路径中的第一层级使用尺寸为 $3 \times 3 \times 3$ 、步长为 2 的卷积核进行下采样，降低显存占用。在下采样中，初始输入数据尺寸大，使用较大尺寸卷积核时会增加网络引入的参数量，降低计算性能，使用较小尺寸卷积核时感受野较小，有用特征提取受限。为了减少算法参数量并融合多视图特征，其他层级通

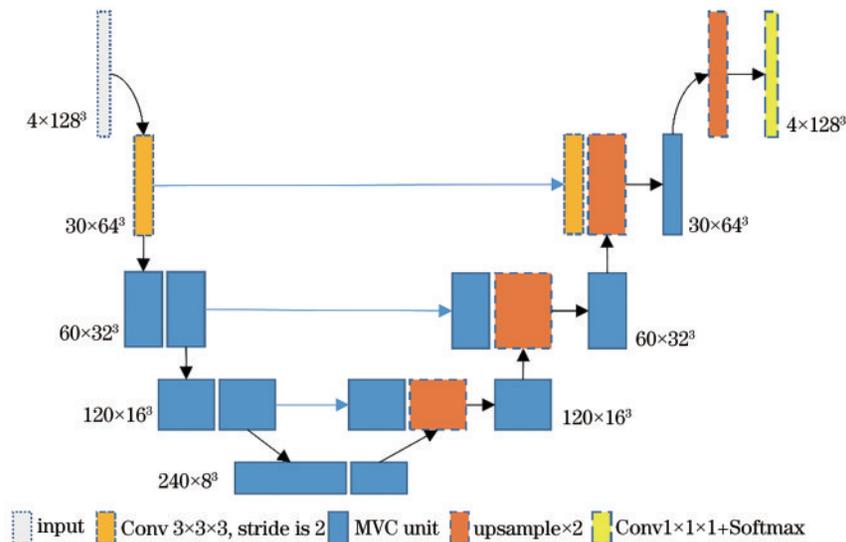


图 1 所提算法的整体框架

Fig. 1 Overall diagram of the proposed algorithm

过一个步长为 2 的 MVC 单元与一个步长为 1 的 MVC 单元组成的编码卷积块进行下采样,提取脑肿瘤 MRI 数据中的深层次特征。解码路径中使用三线性插值操作以节约计算资源,并结合一个 MVC 单元组成解码卷积块,逐步恢复特征尺寸为原始输入尺寸,同时拼接来自同级编码卷积块的输出,以融合不同路径中的特征信息。解码路径中的第一层级首先通过三线性插值得到与原始输入数据相同尺寸的输出,其次使用一个尺寸为 $1 \times 1 \times 1$ 、步长为 1 的卷积核进行卷积,融合各通道间的特征信息,最后通过一个 Softmax 层得到分别对应于背景区域、坏死与非强化肿瘤区域、水肿区域、增强肿瘤区域 4 个部分的概率值,实现端到端

分割。

如图 2 所示, MVC 单元由复用器模块^[19]和伪三维卷积模块组成,并且通过残差连接^[20]来缓解梯度消失问题。如图 2(a)和图 2(b)所示,当输入与输出特征通道数量相同时,将输入与输出相加实现残差连接;当输入与输出通道数量不同时,首先使用尺寸为 $1 \times 1 \times 1$ 的卷积核输入进行卷积,其次与输出特征进行相加实现残差连接。为了减少模型中参数量并节约计算资源,伪三维卷积模块中引入了分组卷积。针对三个不同视图角度伪三维卷积的输出, MVC 单元使用三个可训练的参数为各个视图输出赋予权重,提高有效特征的占比并抑制不利于提升分割精度的特征。

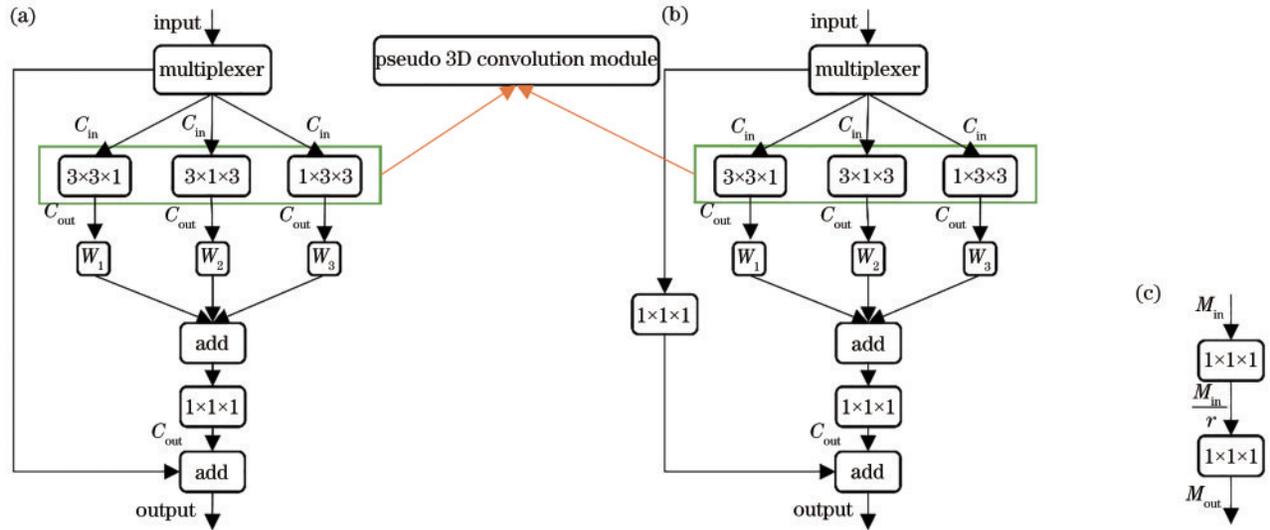


图 2 MVC 单元示意图。(a)输入与输出特征数量相同时的 MVC 单元;(b)输入与输出特征数量不相同时的 MVC 单元;(c)复用器模块

Fig. 2 Schematic of MVC unit. (a) MVC unit when feature numbers of the input equals to the output; (b) MVC unit when feature numbers of the input does not equal to the output; (c) multiplexer module

2.2 算法原理

为了提升不同通道间信息的流动性并增加模型提取非线性特征的能力,使用复用器模块作为 MVC 单元的组成部分。如图 2(c)所示,复用器模块由两个级联的尺寸为 $1 \times 1 \times 1$ 、步长为 1 的卷积核组成,其中 r 为通道压缩因子,可根据需要进行设定, M_{in} 、 M_{out} 分别表示复用器模块的输入与输出特征数量。复用器模块的参数量为

$$p_1 = M_{in} \times \frac{M_{in}}{r} + \frac{M_{in}}{r} \times M_{out} = \frac{M_{in}(M_{in} + M_{out})}{r} \quad (1)$$

传统三维卷积参数量大,且随着网络的加深容易出现过拟合现象。Wang 等^[21]将传统 $3 \times 3 \times 3$ 尺寸的卷积核拆分为 $3 \times 3 \times 1$ 尺寸的切片内卷积核和 $1 \times 1 \times 3$ 尺寸的切片间卷积核,有效降低了参数量。然而仅从两个维度进行卷积并且感受野不同,提取的特征代表性不强。为了克服此缺陷,Wang 等分别使用三个不同视图角度的切片内卷积核与切片间卷积核组成基础卷积单元训练模型,得到三个基于不同视图的模

型,最终对三个模型的结果进行融合,实现精确分割,然而此方式较为繁琐。因此,所提算法在单个模型中使用伪三维切片内卷积,即尺寸分别为 $3 \times 3 \times 1$ 、 $3 \times 1 \times 3$ 和 $1 \times 3 \times 3$ 的卷积核,从三个不同视图角度进行卷积并通过可训练权重参数对结果进行融合,实现高效分割。

图 3 为使用的伪三维卷积核从不同角度进行卷积的示意图, MVC 单元从三个不同视角进行卷积并通过可训练权重参数进行相加,有效降低参数量。如图 2(a)与图 2(b)所示,其中 C_{in} 、 C_{out} 分别表示伪三维卷积块的输入与输出特征数量,且 $C_{in} = M_{out}$ 。三个伪三维卷积块卷积的参数量为

$$p_2 = \frac{k^2 C_{in} C_{out}}{g} + \frac{k^2 C_{in} C_{out}}{g} + \frac{k^2 C_{in} C_{out}}{g} = \frac{3k^2 C_{in} C_{out}}{g} \quad (2)$$

式中: k^2 和 g 分别表示伪三维卷积核参数量和分组卷积的分组数量,分组数量为 10。在所提算法中,当 MVC 单元的输入通道数量,即复用器模块的输入通道

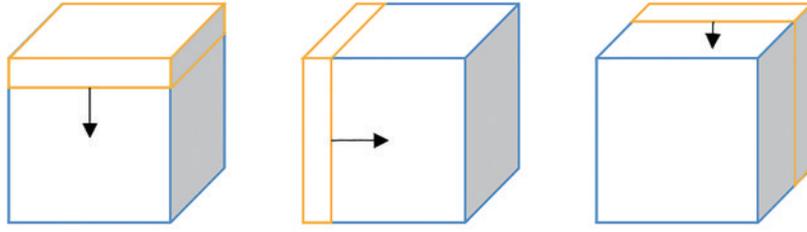


图 3 不同视图的伪三维卷积核卷积示意图。(a)轴向位;(b)矢状位;(c)冠状位

Fig. 3 Schematic of pseudo three-dimensional convolution kernel convolution from different views. (a) Axial; (b) sagittal; (c) coronal

数量 M_{in} 小于 MVC 单元的输出通道数量 C_{out} 时,复用器模块的输出 M_{out} 等于 M_{in} ,反之等于 C_{out} ,且通道压缩因子 $r=4$ 。由此可得,输入小于输出通道与输入大于输出通道两种情况下 MVC 单元所需参数量分别为

$$p_3 = p_1 + p_2 + C_{out}^2 = \frac{M_{in}(M_{in} + M_{out})}{r} + \frac{3k^2 C_{in} C_{out}}{g} + C_{out}^2 = \frac{M_{in}(M_{in} + M_{in})}{r} + \frac{3k^2 M_{in} C_{out}}{g} + C_{out}^2 = \frac{2gM_{in}^2 + 3rk^2 M_{in} C_{out} + grC_{out}^2}{gr}, \quad (3)$$

$$p_4 = p_1 + p_2 + C_{out}^2 = \frac{M_{in}(M_{in} + M_{out})}{r} + \frac{3k^2 C_{in} C_{out}}{g} + C_{out}^2 = \frac{M_{in}(M_{in} + C_{out})}{r} + \frac{3k^2 C_{out}^2}{g} + C_{out}^2 = \frac{gM_{in}^2 + gM_{in} C_{out} + (3k^2 + g)rC_{out}^2}{gr}. \quad (4)$$

而传统卷积单元参数量为

$$p_5 = k^3 M_{in} C_{out}, \quad (5)$$

式中: k^3 为传统卷积核参数量。由式(3)~(5)可知,当 MVC 单元的输入通道小于输出通道和输入通道大于输出通道时,其与传统卷积单元参数量之比分别为

$$\frac{p_3}{p_5} = \frac{M_{in}}{2k^3 C_{out}} + \frac{3}{10k} + \frac{C_{out}}{k^3 M_{in}}, \quad (6)$$

$$\frac{p_4}{p_5} = \frac{M_{in}}{4k^3 C_{out}} + \frac{1}{4k^3} + \frac{3C_{out}}{10kM_{in}} + \frac{C_{out}}{k^3 M_{in}}. \quad (7)$$

由此可得,当 $k \geq 3$ 时,两种情况下, MVC 单元的参数量与传统卷积单元参数量之比分别约等于 $3/10k$ 和 $3C_{out}/10kM_{in}$ 。本文中, k 的值为 3,则当输入通道数量小于输出通道数量时($M_{in} < C_{out}$), MVC 单元参数量仅为传统卷积单元参数量的 $1/10$;当输入通道数量大于输出通道数量时($M_{in} > C_{out}$), MVC 单元参数量与传统卷积单元参数量之比为 $C_{out}/10M_{in}$,小于 $1/10$,此时减少参数量效果更突出,并且随着卷积核大小 k 的增加, MVC 单元相比传统卷积单元减少参数量的效果更明显。

3 实验与结果分析

3.1 数据集与预处理

所有实验均在 2019 年 BraTS 提供的数据集上进行,其中训练集与验证集分别包含 335 例与 125 例脑肿瘤患者的 MRI 数据。每例数据中含有 T2、FLAIR、T1 和 T1c 四个模态的数据。此外,训练集中包含专家手动分割的真值标签数据。对所有原始数据均进行 $1 \text{ mm} \times 1 \text{ mm} \times 1 \text{ mm}$ 分辨率插值、颅骨剥离等预处理操作。

由于四个模态数据的分布区间不同,在模型训练过程中会出现拟合困难问题。因此,在数据送入模型进行训练前先对数据进行归一化处理。首先提取四个模态中的非背景区域作为感兴趣区域,其次分别获取四个模态数据中感兴趣区域的均值与标准差,最后对每个数据通过减去均值并除以标准差的方式进行归一化,具体公式为

$$y = \frac{x - \mu}{\sigma}, \quad (8)$$

式中: x 、 y 、 μ 、 σ 分别表示输入数据、输出数据、均值与标准差。为了节约设备资源并增加模型的鲁棒性,引入了数据裁剪、随机翻转、强度转换等的数据增强方法。

3.2 实验

实验中使用基于 Python 的开源深度学习框架 PyTorch,并通过三个并行的 Nvidia GTX2080Ti 图形处理器(GPU)加速模型训练,每个 GPU 的实际显存不足 11 GB。经过实验,所提模型训练过程中的参数设定如表 1 所示。由于脑肿瘤 MRI 数据中背景区域、坏死与非强化肿瘤区域、水肿区域、增强肿瘤区域 4 个部分的比例严重不均衡,使用广义 Dice 相似度损失函数(GDL)^[22]来解决类别不均衡引起的分割准确率降低问题。GDL 具体公式为

$$L_{GDL} = 1 - 2 \frac{\sum_k w_k \sum_n p_{kn} t_{kn}}{\sum_k w_k \sum_n (p_{kn} + t_{kn})}, \quad (9)$$

式中: k 与 n 分别表示数据中的类别数量与体素点数量; p_{kn} 和 t_{kn} 分别表示第 n 个体素点预测为第 k 类别的概率和第 n 个体素点对应的标签值,当前体素点属于第 k

表 1 模型训练时的参数设定
Table 1 Parameter setting during model training

Parameter	Content
Weight decay coefficient	0.00001
Weight initialization	He initialization ^[23]
Initial learning rate	0.001
Optimizer	Adam
Training times	600
Batch size	12

类别时,标签值为 1,否则为 0; $w_k = 1/(\sum_n t_{kn})^2$ 表示第 k 类别对损失函数的贡献。在计算损失函数过程中,出现体素越多的类别对应的 w_k 越小的现象,以降低体素数量多的类别对损失函数的贡献,反之增加体素数量少的类别对损失函数的贡献,以此达到抑制类别不平衡的目的。

使用多 GPU 训练模型时,传统数据并行训练方法需要将每个 GPU 上的运算结果汇总至总 GPU 上并进行相关计算,导致多 GPU 显存使用不均,同时影响每批次训练数据个数,降低模型训练效率。分布式数据并行训练方法在每个 GPU 上分别开辟一个进程进行管理,通过多个进程实现数据交换,数据交换量小,效率更高。所提算法在三个 GPU 上使用传统数据并行训练方法时,批尺寸最高为 9,除了主 GPU 外,其余两个 GPU 仍有过多显存未被使用;使用分布式数据并行训练方法时,批尺寸能够达到 12,且每个 GPU 显存使用均匀。在相同实验环境下,分别使用传统数据并行训练方法与分布式数据并行训练方法训练模型

600 次,耗时分别为 500 min 与 450 min。由此可见,分布式数据并行方法效率更高。

脑肿瘤分割结果的评估指标包括 Dice 相似度系数(Dice)和豪斯多夫距离(HD95),用于评价模型的分割准确率。此外,引入参数量(parameters)、浮点运算数(FLOPs)和模型训练过程中一个数据所需的设备内存空间对模型复杂度进行衡量。

3.3 结果与分析

通过所提算法训练好的模型,对验证集中 125 例脑肿瘤 MRI 数据进行分割,并将分割结果上传至 BraTS 提供的在线评估平台,获取模型的分割结果,如表 2 所示。所提算法在肿瘤增强区(ET)、肿瘤整体区(WT)和肿瘤核心区(TC)的 Dice 得分分别为 78.32%、89.63% 和 82.1%,参数量与浮点运算数分别为 0.71×10^6 和 6.64×10^9 。与 2019 年 BraTS 比赛第一名^[11]相比,所提算法对三个肿瘤区域的平均 Dice 得分仅降低 2.52 个百分点,然而参数量与浮点运算数分别降低了 84.83% 和 96.67%。所提算法对三区域的平均 Dice 得分高于 2019 年 BraTS 第二名^[9]与其他相关前沿算法,且在效果较难提升的肿瘤增强区域的表现更为突出。如表 2 所示,本文使用 Chen 等^[24]提出的轻量级脑肿瘤分割算法源码训练获取模型,同时参照 Çiçek 等^[18]使用的尺寸为 $3 \times 3 \times 3$ 的卷积核构成基础对比模型 3D U-Net,取得其在 2019 年 BraTS 验证集上的结果,所提算法在计算量与参数量均远低于该算法的前提下,取得了更精确的分割结果。由此可见,所提算法能够在保持较高分割精度的同时降低模型的复杂度。

表 2 不同算法在 2019 年 BraTS 验证集上的分割效果对比
Table 2 Segmentation effect comparison of various algorithms on BraTS validation set in 2019

Algorithm	Parameters / 10^6	FLOPs / 10^9	Dice / %			HD95 / mm		
			ET	WT	TC	ET	WT	TC
Proposed algorithm	0.71	6.64	78.32	89.63	82.1	3.22	4.78	6.20
Algorithm in Ref. [11]	4.68	199.69	80.21	90.94	86.47	3.15	4.26	5.44
Algorithm in Ref. [12]			75.40	91.00	83.50	3.84	4.57	5.58
Algorithm in Ref. [13]			77.00	91.00	83.00	3.92	4.52	6.27
Algorithm in Ref. [14]	5.90	1534.99	75.57	90.29	79.32	4.77	4.49	8.19
Algorithm in Ref. [15]	33.55	293.76	72.31	88.82	78.33	4.91	8.12	7.56
Algorithm in Ref. [16]			75.90	89.30	80.70	4.19	6.94	7.66
Algorithm in Ref. [17]			66.68	85.27	70.91	7.27	8.08	9.57
Algorithm in Ref. [24]	3.88	27.04	77.60	90.00	81.50	2.99	4.64	6.22
Algorithm in Ref. [18]	13.08	233.36	77.60	88.40	79.60	4.48	9.11	8.68

表 3 为不同算法的实验环境与设置。文献[11]中的算法在模型训练过程中一个数据占用超过 12 GB 显存,对比同等块大小(patch size)为 $128 \times 128 \times 128$ 的所提算法,实际训练过程中仅需 2.5 GB,降低了约 79.17%。对比其他算法同样可以发现,所提算法有效降低了模型在训练过程中对显存的需求。因此,所提

算法不仅能够获得与前沿算法相当的效果,而且具有节约计算资源、训练过程中对设备要求低等优点,打破了相关领域对模型训练设备的高要求,推动轻量级卷积神经网络的发展。

图 4 为脑肿瘤四种模态图像、所提算法分割结果与专家手动分割结果标注在 FLAIR 模态图像上的对

表 3 不同算法的实验环境与设置

Table 3 Experimental environment and settings of various algorithms

Algorithm	Experiment device	Batch size	Patch size
Proposed algorithm	Three parallel Nvidia GTX2080Ti(11 GB) GPUs	12	128 × 128 × 128
Algorithm in Ref. [11]	One Nvidia Titan V GPU with 12 GB	1	128 × 128 × 128
Algorithm in Ref. [12]	Two Titan GPUs with 12 GB	1	128 × 128 × 128
Algorithm in Ref. [13]	One Nvidia Tesla V100 32 GB GPU	1	160 × 224 × 160
Algorithm in Ref. [15]	One Nvidia Titan Xp 12 GB GPU	1	128 × 128 × 128
Algorithm in Ref. [16]	Two GeForce GTX 1080 Ti(11 GB)	2	128 × 128 × 128
Algorithm in Ref. [24]	Four parallel Nvidia GTX2080Ti(11 GB) GPUs	12	128 × 128 × 128
Algorithm in Ref. [18]	Three parallel Nvidia GTX2080Ti(11 GB) GPUs	9	128 × 128 × 128

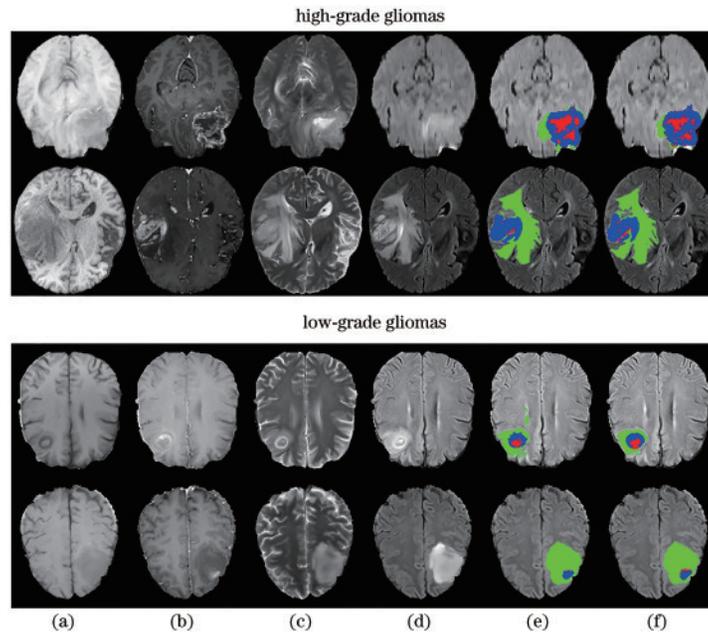


图 4 分割结果对比。(a) T1; (b) T1c; (c) T2; (d) FLAIR; (e)所提模型分割结果; (f)专家手动分割结果

Fig. 4 Comparison of segmentation results. (a) T1; (b) T1c; (c) T2; (d) FLAIR; (e) segmentation results of the proposed model; (f) expert manual segmentation results

比。其中,红色、绿色和蓝色分别代表坏死与非强化肿瘤区域、水肿区域和增强肿瘤区域。对所提算法在三个不同肿瘤区域上的分割效果与专家手动分割结果进行对比,可以看出,所提算法的准确度较高,尤其表现在水肿区域和增强肿瘤区域上。

为了进一步探究 MVC 单元组成的合理性,通过削减 MVC 单元的组成部分进行相关实验。如图 2 所

示,将去除复用器模块、左边伪三维卷积模块、中间伪三维卷积模块、右边伪三维卷积模块与可训练权重参数的模型分别记为模型 1、模型 2、模型 3、模型 4 与模型 5。分别获取 5 个模型在验证集上的结果,具体对比如表 4 所示。与模型 1 进行对比发现,所提算法中复用器模块的引入提升了对脑肿瘤三个子区域的分割准确率;与模型 2、模型 3 和模型 4 进行对比发现,所提算法

表 4 不同 MVC 单元的分割效果对比

Table 4 Comparison of segmentation result of different MVC units

Parameter	Area	Proposed algorithm	Model 1	Model 2	Model 3	Model 4	Model 5
Dice / %	WT	89.63	89.10	89.47	89.54	90.08	89.71
	TC	82.10	80.00	80.78	81.97	80.18	81.29
	ET	78.32	76.19	76.50	77.02	76.30	77.05
HD95 / mm	WT	4.78	7.61	7.70	5.30	4.52	5.09
	TC	6.20	9.00	15.89	5.76	6.39	6.68
	ET	3.22	32.41	35.40	2.95	3.40	2.84

Note: bold font is the optimal value for each line.

中每一个视图的伪三维卷积块对提升模型分割精度均起到了积极的作用;与模型 5 进行对比发现,所提算法中权重参数的引入对肿瘤核心区和肿瘤增强区的分割准确率提升较为明显。图 5 为所提模型中 9 个 MVC 单元中的可训练权重参数随训练次数变化而变化的示

意图,可以发现每个单元中的权重参数最终都处于一个收敛的状态,体现了不同视图伪三维卷积块的作用。因此,所提出的 MVC 单元的设计较为合理,各个部分均对模型分割准确度的提升做出了贡献。

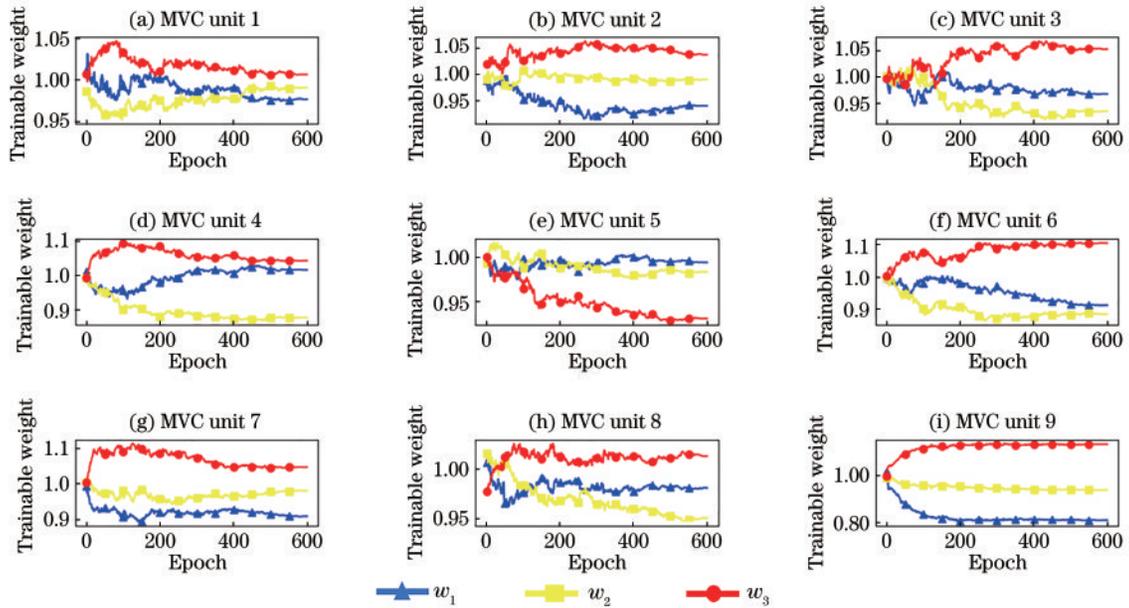


图 5 权重参数随训练次数变化而变化的示意图

Fig. 5 Schematic of weight parameters changing with training times

4 结 论

基于三维卷积神经网络的脑肿瘤分割算法精度较高,但较为复杂且在训练过程中对设备要求较高。对此,提出一种基于伪三维卷积并结合组卷积、复用器的脑肿瘤分割算法,使用分布式数据并行方法训练模型,实现精确分割的同时降低模型复杂度与提高设备空间的利用率。所提算法在肿瘤增强区、肿瘤整体区与肿瘤核心区的 Dice 得分分别为 78.32%、89.63% 和 82.1%,参数量与浮点运算次数分别为 0.71×10^6 和 6.64×10^9 ,与当前最优算法相比,三个肿瘤区域的平均 Dice 得分仅相差 2.52 个百分点,然而模型的参数量与浮点运算数分别降低了 84.83% 和 96.67%,并且模型训练时占用设备内存降低了 79.17%。所提算法具有分割准确率高、复杂度低、节约设备空间等优点。由此可见,对于三维卷积神经网络脑肿瘤分割算法复杂度高的问题,通过改变基础卷积方式、引入高效卷积模块等方法能够得到一定缓解。所提算法在脑肿瘤分割问题上效果较好,但并未对其普遍适用性进行相关验证。此外,模型训练过程中保存的参数类型默认是单精度浮点数,每个参数需要 4 个字节的存储空间进行存储,对设备要求较高,并且降低了模型的训练速度。对此,能否使用单精度与半精度结合的混合精度方式训练模型,以降低模型训练过程中对设备内存空间的占用并提升训练速度,这将在今后的工作中进行探求。

参 考 文 献

- [1] Zubair M, Rana I A, Islam Y, et al. Variable structure based control for the chemotherapy of brain tumor[J]. IEEE Access, 2021, 9: 107333-107346.
- [2] 孔媛媛, 李军华, 王艳, 等. 基于 Hough 变换和 GVF Snake 模型的脑肿瘤分割方法[J]. 计算机应用研究, 2018, 35(11): 3469-3471, 3475.
Kong Y Y, Li J H, Wang Y, et al. Brain tumor segmentation method based on Hough transform and GVF Snake model[J]. Application Research of Computers, 2018, 35(11): 3469-3471, 3475.
- [3] Bray F, Ferlay J, Soerjomataram I, et al. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries[J]. CA: a Cancer Journal for Clinicians, 2018, 68(6): 394-424.
- [4] 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.
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.
- [5] Bauer S, Wiest R, Nolte L P, et al. A survey of MRI-based medical image analysis for brain tumor studies[J]. Physics in Medicine and Biology, 2013, 58(13): R97-R129.
- [6] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks[J]. Communications of the ACM, 2017, 60(6): 84-90.

- [7] Deng J, Dong W, Socher R, et al. ImageNet: a large-scale hierarchical image database[C]//2009 IEEE Conference on Computer Vision and Pattern Recognition, Miami, June 20-25, 2019, FL, USA. New York: IEEE Press, 2019: 248-255.
- [8] Ronneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation[M]//Navab N, Hornegger J, Wells W M, et al. Medical image computing and computer-assisted intervention-MICCAI 2015. Lecture notes in computer science. Cham: Springer, 2015, 9351: 234-241.
- [9] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [10] Szegedy C, Liu W, Jia Y Q, et al. Going deeper with convolutions[C]//2015 IEEE Conference on Computer Vision and Pattern Recognition, June 7-12, 2015, Boston, MA. New York: IEEE Press, 2015.
- [11] Jiang Z Y, Ding C X, Liu M F, et al. Two-stage cascaded U-net: 1st place solution to BraTS challenge 2019 segmentation task[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 231-241.
- [12] Zhao Y X, Zhang Y M, Liu C L. Bag of tricks for 3D MRI brain tumor segmentation[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 210-220.
- [13] McKinley R, Rebsamen M, Meier R, et al. Triplanar ensemble of 3D-to-2D CNNs with label-uncertainty for brain tumor segmentation[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 379-387.
- [14] Chen M L, Wu Y Z, Wu J H. Aggregating multi-scale prediction based on 3D U-Net in brain tumor segmentation[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 141-152.
- [15] González S R, Sekou T B, Hidane M, et al. 3D automatic brain tumor segmentation using a multiscale input U-net network[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 113-123.
- [16] Xu X W, Zhao W Y, Zhao J. Brain tumor segmentation using attention-based network in 3D MRI images[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 3-13.
- [17] Bhalerao M, Thakur S. Brain tumor segmentation based on 3D residual U-net[M]//Crimi A, Bakas S. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2020, 11992: 218-225.
- [18] Çiçek Ö, Abdulkadir A, Lienkamp S S, et al. 3D U-net: learning dense volumetric segmentation from sparse annotation[M]//Ourselin S, Joskowicz L, Sabuncu M R, et al. Medical image computing and computer-assisted intervention-MICCAI 2016. Lecture notes in computer science. Cham: Springer, 2016, 9901: 424-432.
- [19] Chen Y P, Kalantidis Y, Li J S, et al. Multi-fiber networks for video recognition[M]//Ferrari V, Hebert M, Sminchisescu C, et al. Computer vision-ECCV 2018. Lecture notes in computer science. Cham: Springer, 2018, 11205: 364-380.
- [20] 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, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 770-778.
- [21] Wang G T, Li W Q, Ourselin S, et al. Automatic brain tumor segmentation using cascaded anisotropic convolutional neural networks[M]//Crimi A, Bakas S, Kuijf H, et al. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture notes in computer science. Cham: Springer, 2018, 10670: 178-190.
- [22] Sudre C H, Li W Q, Vercauteren T, et al. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations[M]//Cardoso M J, Arbel T, Carneiro G, et al. Deep learning in medical image analysis and multimodal learning for clinical decision support. Lecture notes in computer science. Cham: Springer, 2017, 10553: 240-248.
- [23] 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, December 7-13, 2015, Santiago, Chile. New York: IEEE Press, 2015: 1026-1034.
- [24] Chen C, Liu X P, Ding M, et al. 3D dilated multi-fiber network for real-time brain tumor segmentation in MRI [M]//Shen D G, Liu T M, Peters T M, et al. Medical image computing and computer assisted intervention-MICCAI 2019. Lecture notes in computer science. Cham: Springer, 2019, 11766: 184-192.