

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2023)07-2182-13

论文引用格式: Ding Y, Zheng W, Geng J, Qiu L Y and Qin Z G. 2023. Multi-level parallel neural networks based multimodal human brain tumor image segmentation framework. Journal of Image and Graphics, 28(07):2182-2194(丁熠, 郑伟, 耿技, 邱泸谊, 秦志光. 2023. 基于多层次并行神经网络的多模态脑肿瘤图像分割框架. 中国图象图形学报, 28(07):2182-2194)[DOI:10.11834/jig.211197]

# 基于多层次并行神经网络的多模态 脑肿瘤图像分割框架

丁熠, 郑伟, 耿技\*, 邱泸谊, 秦志光

电子科技大学信息与软件工程学院, 成都 610054

**摘要:** 目的 在脑肿瘤临床诊疗过程中, 由于医疗资源稀缺与诊断效率偏低, 迫切需要高精度的医学图像分割工具进行辅助诊疗。目前, 使用卷积神经网络进行脑肿瘤图像分割已经成为主流, 但是其对于脑肿瘤信息的利用并不充分, 导致精度与效率并不完善, 而且重新设计一个全新且高效的深度神经网络模型是一项成本高昂的任务。为了更有效提取脑肿瘤图像中的特征信息, 提出了基于多层次并行神经网络的多模态脑肿瘤图像分割框架。方法 该框架基于现有的网络结构进行拓展, 以 ResNet(residual network)网络为基干, 通过设计多层次并行特征提取模块与多层次并行上采样模块, 对脑肿瘤的特征信息进行高效提取与自适应融合, 增强特征信息的提取与表达能力。另外, 受 U-Net 长连接结构的启发, 在网络中加入多层次金字塔长连接模块, 用于输入的不同尺寸特征之间的融合, 提升特征信息的传播效率。结果 实验在脑肿瘤数据集 BRATS2015(brain tumor segmentation 2015)和 BRATS2018(brain tumor segmentation 2018)上进行。在 BRATS2015 数据集中, 脑肿瘤整体区、核心区和增强区的平均 Dice 值分别为 84%、70% 和 60%, 并且分割时间为 5 s 以内, 在分割精度和时间方面都超过了当前主流的分割框架。在 BRATS2018 数据集中, 脑肿瘤整体区、核心区和增强区的平均 Dice 值分别为 87%、76% 和 71%, 对比基干方法分别提高 8%、7% 和 6%。结论 本文提出多层次并行的多模态脑肿瘤分割框架, 通过在脑肿瘤数据集上的实验验证了分割框架的性能, 与当前主流的脑肿瘤分割方法相比, 本文方法可以有效提高脑肿瘤分割的精度并缩短分割时间, 对计算机辅助诊疗有重要意义。

**关键词:** 多模态脑肿瘤图像; 多层次并行; 深度神经网络(DNN); 特征融合; 语义分割

## Multi-level parallel neural networks based multimodal human brain tumor image segmentation framework

Ding Yi, Zheng Wei, Geng Ji\*, Qiu Luyi, Qin Zhiguang

School of Information and Software Engineering, University of Electronic Science and Technology of China, Chengdu 610054, China

**Abstract: Objective** Clinical-oriented magnetic resonance imaging (MRI) has its priority to analyze human brain tumors in relevance to such fields of MRI brain images of Flair, T1, T1c, and T2 modalities. The glioma can be oriented as the

收稿日期: 2021-12-24; 修回日期: 2022-08-29; 预印本日期: 2022-09-05

\* 通信作者: 耿技 jigeng@uestc.edu.cn

**基金项目:** 国家自然科学基金项目(62076054, 62072074, 62027827, 61902054, 62002047); 国家重点研发计划前沿科技创新专项项目(2019QY1405); 四川省科技计划项目(2020YFSY0010, 2019YJ0636); 四川省杰出青年科技人才项目(2022JDJQ0039)

**Supported by:** National Natural Science Foundation of China (62076054, 62072074, 62027827, 61902054, 62002047); Frontier Science and Technology Innovation Projects of National Key R&D Program of China (2019QY1405); Sichuan Science-Technology Support Plan Program (2020YFSY0010, 2019YJ0636); Sichuan Science and Technology Innovation Platform and Talent Plan (2022JDJQ0039)

most common type of brain tumor for adults nowadays. Due to the features of its anatomical structure, such of lesions can be visually clarified in terms of MRI images analysis. The difference between medical treatment and scarcity of medical expertise are required of computers-assisted diagnosis and treatment. Recent deep learning technology for brain tumor segmentation has demonstrated its great potential for brain tumor image segmentation. In addition, to improve the segmentation accuracy of brain tumor images further, current literature reviews are focused on optimization of network feature extraction ability via an extraordinary network structure, and brain tumor images information are related to its multi-resolution information, spatial multi-view information, information post-processing, and symmetry information. Various of deep neural network (DNN) models have been developing in computer vision in recent years, such as Visual Geometry Group Network (VGGNet), GoogLeNet, ResNet, and DenseNet. The DNN model mentioned above can facilitate the development of deep learning-based brain tumor diagnosis methods. To extract feature information in brain tumor images more effectively, we develop a multi-level parallel neural networks based multimodal brain tumor image segmentation framework further.

**Method** To enhance the ability of feature information extraction and expression, this framework is facilitated derived from the existing network backbone, and the feature information of brain tumors can be extracted and fused adaptively via a multi-level parallel feature extraction module and parallel up-sampling module. Deeper features can be extracted in the depth of the network and iterate multiple backbone network branches for feature extraction in parallel. The layer-by-level connection of the neural network can not only broaden the width of the neural network but also mine the depth of the neural network. As a result, multi-level parallel feature extraction structure has its stronger and richer nonlinear representation capabilities than the single-level feature extraction structure, and more complex mapping transformations are fit into more complex image features as well. To preserve the richness of features, hierarchical parallel feature extraction structure has sufficient network width to extract various attribute information of images, such as different colors, shapes, spatial relationships, textures, and other related features. Furthermore, inspired by long connected structure of U-Net, a multi-level pyramid long connection module is melted into the network to fully achieve the integration of the input features of different sizes and improve the transmission efficiency of feature information. The richness of the feature is enhanced in terms of multi-level pyramid long connection module. Meanwhile, the input end of the multi-level pyramid long connection module can be used to fully analyze the information fusion between layers of different sizes. All of them can alleviate the loss and deformation of image information to a certain extent, which can improve the propagation efficiency of features of the same size at both ends of a long connection. It can affect the segmentation accuracy of multimodal brain tumor images ultimately.

**Result** To verify the overall performance of the algorithm, an evaluation is first carried out on the testing set of the public brain tumor dataset BraTS2015. The average Dice scores of the proposed algorithm in the entire tumor, tumor core, and enhanced tumor areas can be reached to 84%, 70%, and 60% of each. It can optimize segmentation duration to less than 5 s farther. Some other related comparative experiments are linked to such modules of feature extraction, up-sampling, and the pyramid long connection, and the effectiveness of each module is compared with the backbone method as well. An experiment is conducted on the BraTS2018 validation set. The proposed algorithm can achieve average Dice scores of 87%, 76%, and 71% of each. Compared to the backbone method, it illustrates higher average Dice scores of 8.0%, 7.0%, and 6.0%. **Conclusion** We extend the common network backbone and propose a multimodal brain tumor image segmentation framework based on a multi-level parallel neural network. We develop a multi-level parallel expansion at the same time. The hierarchical pyramid long connection module can be used to optimize original long connection model-derived multi-scale and receptive field-relevant unclear information, and the richness of features can be improved as well. Multi-level parallel neural network-based segmentation framework is demonstrated to optimize segmentation accuracy and efficiency.

**Key words:** multimodal brain tumor image; multi-level parallelism; deep neural network (DNN); feature fusion; semantic segmentation

## 0 引言

在临床诊疗过程中,核磁共振成像(nuclear magnetic resonance imaging, MRI)是临床医生分析脑部肿瘤时的首选,如常见的T1、T1c、T2、Flair模态的MRI脑部影像。T1指T1加权成像,此模态可更好地呈现脑部解剖结构;T1c指增强T1加权成像,此模态使用造影剂对图像进行对比度增强,增加了血管组织的强度;T2指T2加权成像,此模态对含水组织具有更高的敏感度,因此可以更好地呈现病变组织;Flair指流体衰减反转恢复图像,可以抑制脑脊液,使该组织与其他组织更易区分。多模态脑肿瘤数据不论在人工临床诊疗还是在计算机辅助诊疗中,都是不可或缺的数据。

脑部肿瘤诊断鉴别的任务主要是关注脑部的神经胶质瘤,神经胶质瘤在成人脑部肿瘤中最为常见,由于它的解剖结构的特殊性,可以通过MRI影像进行直观检查与分析(Shang等,2012;Martínez-Murcia等,2014)。而不同个体在临床诊疗上的差异以及医生医疗等资源的稀缺,使得通过计算机进行辅助诊疗已经成为必不可少的步骤(El-Dahshan等,2014)。

多模态MRI数据给临床诊断人员带来了诸多便利,但是基于多模态MRI数据对脑部神经胶质瘤进行自动化分割的任务极具挑战性(Goetz等,2016),主要原因有两点:1)脑部的神经胶质瘤可以出现在脑部的任何位置,而且形状、外观、大小以及类型各不相同,增加了脑肿瘤区域精确定位的难度;2)脑部的神经胶质瘤会侵及周围正常的脑组织,而不是非简单的视觉上的移位,这样会造成肿瘤区域的边界模糊,难以判别。

随着深度学习的不断发展,研究者不断拓展深度学习技术在脑肿瘤分割领域的应用,在BRATS 2015挑战赛(Menze等,2015)提出了基于深度学习模型的脑肿瘤分割方法(Zikic等,2014;Havaei等,2017;Pereira等,2015),采用不同的深度学习模型,包括卷积神经网络(convolutional neural network, CNN)、卷积受限玻尔兹曼机和叠加去噪自编码等。这些早期的深度学习方法尽管结构简单,但取得了令人瞩目的效果,表明深度学习在脑肿瘤图像分割中的巨大潜力。另外,为了进一步提升脑肿瘤图像

的分割精度,提出了很多改进方法,一部分改进聚焦于通过设计特殊的网络结构来提升网络特征提取能力(Dvořák和Menze,2015;Shaikh等,2017;Islam和Ren,2017;Ding等,2019a,b;Pereira等,2019),另一部分则是考虑如何充分利用脑肿瘤图像的多方面信息,包括多分辨率信息(Islam和Ren,2017)、空间多视角信息(Salehi等,2017;Zhao等,2018)、信息后处理(Zhao等,2018;Kamnitsas等,2017)和对称信息(Chen等,2020)等。

基于深度神经网络模型的方法在脑肿瘤分割任务中取得了良好效果,但是其性能改进的空间依旧很大,对于脑肿瘤图像特征信息利用并不充分,而且设计一个全新而且高效的深度神经网络模型是一项成本高昂的任务。本文通过对现有的基于网络进行多层级扩展,构建了基于多层级并行神经网络的多模态脑肿瘤分割框架,以提取更多维度的网络空间特征,并考虑将网络中的不同维度特征信息进行融合,以充分利用网络中的多维度特征信息,捕捉多模态脑肿瘤图像中的多种语义细节信息,提升脑肿瘤多模态脑肿瘤图像分割的分割精度与分割效率。该方法在BRATS 2015数据集(Menze等,2015)与BRATS 2018数据集(Bakas等,2018)上测试,结果表明其分割效果良好,分割效率高。

本文的主要贡献包括4个方面:1)提出一种基于多层级并行神经网络的分割框架用于多模态脑肿瘤图像分割;2)提出多层级并行特征提取模块与多层级并行分割模块,在深度神经网络的下采样与上采样阶段,对多维度网络特征信息之间的关联性展开研究,实现不同维度特征之间的自适应融合,融合了多个基于网络的不同层级的网络特征,通过合理设计降低了模型参数量,并增强了特征的表达能力,进一步提升了模型的性能;3)提出多层级金字塔长连接模块,提升了特征的局部感受野与整体感受野,增强了特征的丰富度与长连接两端同尺寸特征的传播效率,最终提升了脑肿瘤图像的分割精度;4)通过多种实验证明了本文方法的有效性与高效性,对计算机辅助诊疗有重要意义。

## 1 相关工作

### 1.1 卷积神经网络

随着深度学习神经网络的快速发展,深度学习

神经网络技术已经成为一种强大的监督学习工具, Krizhevsky 等人(2012)在 ImageNet 挑战赛中证明了 CNN 的性能, 从此, 在图像分类和其他应用领域中得到广泛接受与采纳(Ding 等, 2018, 2019a, b, c, 2021; 余凯等, 2013; 孟子尧等, 2021)。更深层次的卷积神经网络结构以及各种网络结构的变形, 都是由 CNN 基础模型发展演变而来, 如 VGG (Visual Geometry Group) (Simonyan 和 Zisserman, 2015)、U-Net (Ronneberger 等, 2015)、ResNet (residual network) (He 等, 2016) 等网络结构。U-Net 采用编码器解码器的结构, 先进行图像特征的下采样, 再将特征进行上采样逐步还原, 通过长连接操作将下采样阶段的特征连接到上采样过程中, 增加特征的多样性, 解决在下采样过程中边缘信息丢失问题, 在生物医学图像分割上取得了不错的效果。ResNet 采用残差单元, 以短连接的方式增加恒等映射分支, 解决了随着网络层数的不断增加, 导致梯度不断减小甚至消失、网络训练缓慢甚至效果变差的问题。

其他的一些网络如密集堆叠的 U-Nets (Guo 等, 2018)、融合跨阶段的 U-Nets (夏峰等, 2022) 以及引入注意力机制和多视角融合的 U-Net (罗恺锴等, 2021), 则在 U-Net 的基础上结合 ResNet 等网络模型的改进, 进一步提升了 U-Net 网络的性能。与此同时, SegNet (deep convolutional encoder-decoder architecture for image segmentation) (Badrinarayanan 等, 2017)、DeepLab (Chen 等, 2018a) 等深层次网络结构在语义分割任务中表现优异, SE-Net (Hu 等, 2018) 以及 EfficientNet (rethinking model scaling for convolutional neural network) (Tan 和 Le, 2019) 等高性能的神经网络模型, 不仅考虑网络模型的扩展, 还考虑如何更加高效地提取数据对应的高层次特征。这些深层次的高性能模型在多种数据集上的表现优异, 充分证实了深度卷积神经网络在图像处理领域中的重要性。

## 1.2 基于卷积神经网络的脑肿瘤分割

在基于深度学习的脑肿瘤图像分割方法中, 基于 CNN 的方法取得了较好的分割效果, 特别是采用 3D-CNN 和 2D-CNN 模型构建肿瘤图像分割的方法。虽然 3D-CNN 具有充分利用 MRI 数据三维信息的潜力, 但也大量增加了网络规模和计算成本, Roth 等人 (2014) 指出了在医学成像数据上使用 3D-CNN 时存

在的问题和明显的局限性, 因此, 2D-CNN 广泛应用于脑肿瘤的分割方法中。

Pereira 等人 (2015) 采用通过使用尺寸较小的卷积核, 减少了网络参数量, 并设计了较深层次的 CNN 对脑肿瘤进行分割处理。Havaei 等人 (2015) 将早期训练的 CNN 获得的像素级概率分割结果作为后续 CNN 的额外输入, 构建了级联的网络模型结构, 取得了脑肿瘤分割精度的提升。Dvořák 等人 (2015) 将多类别脑肿瘤分割任务分别建模为 3 个子任务 CNN, 进行不同类别肿瘤区域的局部结构预测, 最终将不同类别肿瘤区域的局部预测结果整合, 完成脑肿瘤图像的分割任务; Shaikh 等人 (2017) 提出利用 100 层网络结构从多模态 MRI 图像中分割脑肿瘤, 该结构基于密集连接全卷积神经网络, 取得了不错的脑肿瘤分割效果。Islam 和 Ren (2017) 从对应于同一像素的多层提取特征, 并每次在少量图像中采样适量的像素使用随机梯度下降进行批量更新, 以此用于脑肿瘤图像分割。Chen 等人 (2018b) 提出一种端到端的可训练网络, 将不同肿瘤区域合并以将网络预测限制在肿瘤区域内, 从而主要减轻非肿瘤区域的影响。Salehi 等人 (2017) 提出一种用于特征重组和空间自适应校准块, 适用于全卷积网络的语义分割, 提升了脑肿瘤图像语义分割的效果。

为了进一步提升脑肿瘤分割的精度, Kamnitsas 等人 (2017) 将马尔可夫随机场, 尤其是条件随机场 (Krähenbühl 和 Koltun, 2011) 与深度学习技术相结合, 用于脑肿瘤图像分割研究, 可以作为 CNN 的后处理步骤, 从而达到更好的分割性能。Zhao 等人 (2018) 结合了条件随机场和多视角方向处理的方法, 并提出了一套专有的后处理方法来进行脑肿瘤图像的分割。Chen 等人 (2020) 设计了一种 CNN 方法, 通过考虑脑部图像的对称性, 计算轴状视角中左右脑部的余弦相似度, 并通过注意力机制增强肿瘤区域在网络中的表现。Ding 等人 (2019a) 将神经网络进行横向堆叠, 并通过桥接连接相邻的网络中同等尺度的特征向量, 进行脑肿瘤图像的逐网络分割。Ding 等人 (2020) 提出一种多路径自适应融合网络, 将残差网络中的跳层连接思想应用于密集连接块中, 从而有效保留和融合更多的低级特征, 提升脑肿瘤图像分割精度。

## 2 多层次并行神经网络的脑肿瘤分割框架

基于现有的常用深度神经网络模型,本文提出基于多层次并行神经网络的多模态脑肿瘤分割

框架,整体架构如图1所示。基于多维度特征信息融合的分割框架的网络结构主要采用基于ResNet的特征提取结构和基于U-Net上采样阶段的结构,包含多层次并行特征提取模块、多层次并行分割模块和多层次金字塔长连接模块。图中 $L$ 表示网络中卷积后的特征层, $U$ 表示网络反卷积后的特征层。

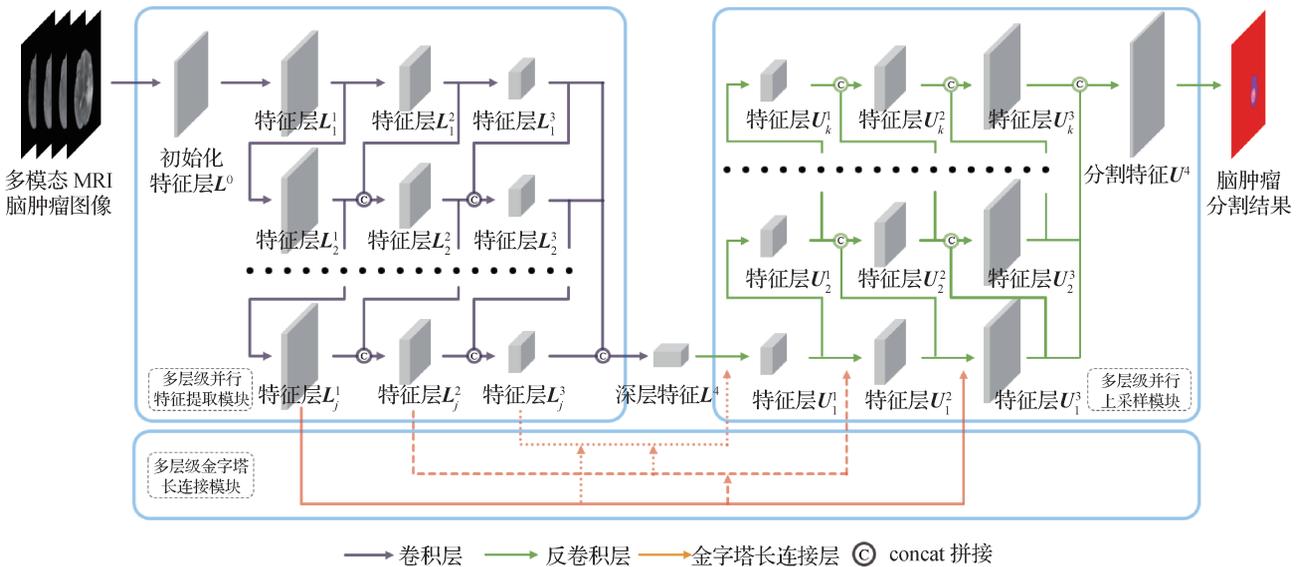


图1 基于多层次并行神经网络的多模态脑肿瘤图像分割框架

Fig. 1 Illustration of multimodal brain tumor image segmentation framework based on multi-level parallel neural network

### 2.1 多层次并行特征提取模块

本文基于ResNet-50的模型特点和结构,并针对多模态脑肿瘤图像分割任务,对ResNet模型进行了一些优化调整,详细结构如表1所示,使其更加适配语义分割任务。首先,收集同一脑肿瘤的多模态

MRI图像,将每个模态的脑肿瘤图像特征图作为特征向量的一个通道,合并输入到多层次并行的特征提取结构中,由网络初始化模块得到初始化特征层。然后,一方面在网络深度上不断提取更深层特征,另一方面并行迭代多个特征提取的基于网络分支,每

表1 基于ResNet-50的网络特征提取结构

Table 1 Network feature extraction structure based on ResNet-50

网络层名称	输出尺寸/像素	卷积参数
输入图像	240 × 240	-
初始化	120 × 120	[3×3, 32, 步长 2],[5×5, 最大池化, 步长 2],[1×1, 32, 步长 1]
瓶颈残差连接块 1	120 × 120	[[1×1, 64, 步长 1],[3×3, 64, 步长 1],[1×1, 64, 步长 1]]×3
下采样层 1	60 × 60	[1×1, 64, 步长 1],[3×3, 64, 步长 2]
瓶颈残差连接块 2	60 × 60	[[1×1, 64, 步长 1],[3×3, 64, 步长 1],[1×1, 128, 步长 1]]×3
下采样层 2	30 × 30	[1×1, 128, 步长 1],[3×3, 128, 步长 2]
瓶颈残差连接块 3	30 × 30	[[1×1, 64, 步长 1],[3×3, 64, 步长 1],[1×1, 256, 步长 1]]×3
下采样层 3	15 × 15	[1×1, 256, 步长 1],[3×3, 256, 步长 2]
瓶颈残差连接块 4	15 × 15	[[1×1, 64, 步长 1],[3×3, 64, 步长 1],[1×1,256,步长 1]]×3

注:“-”代表忽略该项参数。

个基于网络分支同时进行由浅入深的特征提取,进一步将多个基于网络分支进行相同网络深度上的逐层级连接,在扩展神经网络宽度的同时,扩展神经网络的深度,使多层级并行的特征提取结构相比于单层级特征提取结构有更强更加丰富的非线性表达能力,可以学习更加复杂的映射变换,从而可以拟合更加复杂的图像特征。同时,多层级并行的特征提取结构拥有足够的网络宽度,用于提取图像的多方面属性信息,如不同颜色、形状、空间关系和纹理等特征,以此保证特征的丰富度。

在多层级并行特征提取结构中,共包含 $j$ 层并行的基于网络,每个层级包含3个由浅入深的特征层,如第 $i$ 层级基于网络包含了特征层 $L_i^1, L_i^2, L_i^3$ ,不同层级的基于网络对应特征层的尺寸是完全相同的,在原始的单层基于网络 $L$ 中,网络中的每一层特征的计算方法为

$$L^l = \begin{cases} F^l(L^{l-1}) & l = 1 \\ F^l(g(L^{l-1})) & 2 \leq l \leq 4, l \in N \end{cases} \quad (1)$$

式中, $L^l$ 表示第 $l$ 层特征, $F^l()$ 表示第 $l-1$ 层特征到第 $l$ 层特征的迭代瓶颈残差连接层转换函数, $g()$ 表示卷积下采样层函数。

在多层级并行特征提取结构中,网络中的每一层特征的输入有所变化(除第1层级外),前一层级每一特征层的输出都可以作为后一层级相应特征层的输入,具体计算为

$$L_i^l = \begin{cases} F^l(L^{l-1}) & i = 1, l = 1 \\ F^l(g(L_i^{l-1})) & i = 1, 2 \leq l \leq 3, l \in N \\ Q^i(L_{i-1}^l) & 2 \leq i \leq j, l = 1, i \in N \\ F^l(\text{concat}(g(L_i^{l-1}), L_{i-1}^l)) & 2 \leq i \leq j, 2 \leq l \leq 3, \\ & i \in N, l \in N \end{cases} \quad (2)$$

式中, $L_i^l$ 表示第 $i$ 层级基于网络的第 $l$ 层特征, $Q^i(\cdot)$

表示第 $i-1$ 层级基于网络到第 $i$ 层基于网络相同深度特征层的一系列卷积转换函数, $\text{concat}(\cdot)$ 表示特征在通道维度上的拼接。

通过多层级的方式,迭代地将前一个主干网络的输出特征作为输入特征的一部分输入到之后的主干网络中,可以逐层级地增强主干网络的特征表示,第 $i$ 层级基于网络的第 $l$ 层融合了所有第 $1 \sim i-1$ 层级基于网络的第 $1 \sim l$ 层特征以及第 $i$ 层级基于网络的第 $1 \sim l-1$ 层特征,并且最后的深层特征为

$$L^l = F^l(\text{concat}(g(L_1^{l-1}), g(L_2^{l-1}), \dots, g(L_j^{l-1}))), l = 4 \quad (3)$$

多层级并行的特征提取结构融合了多个基于网络的不同深度的网络特征,从而增强了特征的表达能力,进一步提升了基于网络模型的表现。同样,可以按照多层级并行的方式,对现有其他单层深度神经网络基于模型进行多层级扩展。

## 2.2 多层级并行上采样模块

在基于U-Net结构的基础上,为了后续将网络上采样过程进行多层级叠加,减少了中间部分叠加的卷积操作,并减少了上采样过程中的输出通道数,优化后的上采样结构网络层结构参数信息如表2所示。

多层级并行的上采样结构和多层级并行的特征提取结构原理类似,为了更好地利用深度特征进行分割,对基于U-Net的上采样结构进行多层级扩展,将之前提取到的深层特征,一方面按照单一级不断还原特征尺寸,另一方面并行迭代多个上采样分支,每个分支同时进行特征还原,进一步地,将多个分支产生的特征进行不同特征尺寸上的逐层级连接。同样,多层级并行的上采样结构相比于单层级

表2 基于U-Net的网络上采样结构

Table 2 Network up-sampling structure based on U-Net

网络层名称	输出尺寸/像素	卷积参数
深层特征	15 × 15	-
反卷积层 1	30 × 30	[反卷积,3×3,256,步长2], [卷积,3×3,256,步长1]
反卷积层 2	60 × 60	[反卷积,3×3,128,步长2], [卷积,3×3,128,步长1]
反卷积层 3	120 × 120	[反卷积,3×3,64,步长2], [卷积,3×3,64,步长1]
反卷积层 4	240 × 240	[反卷积,3×3,32,步长2], [卷积,3×3,32,步长1]
分割输出	240 × 240	[卷积,3×3,5,步长1], softmax

注:“-”代表忽略该项参数。

网络结构能够进行更复杂的映射变换,对深层次特征进行多维度信息的还原,还原出更多的图像多方位特征与细节信息,最终能够综合多模态MRI脑肿瘤图像的多维度特征进行分割,影响分割精度。

在多层级并行的上采样结构中,共包含 $k$ 层并行的上采样分支,每个层级包含3个特征层,如第 $i$ 层级上采样分支包含了特征层 $U_i^1, U_i^2, U_i^3$ ,不同层级的分割分支对应特征层的尺寸完全相同,在原始的单层上采样分支 $U$ 中,每一层特征计算为

$$U^l = \begin{cases} h(f(L^4)) & l = 1 \\ h(f(U^{l-1})) & 2 \leq l \leq 4, l \in N \end{cases} \quad (4)$$

式中, $U^l$ 表示第 $l$ 层特征, $f(\cdot)$ 表示反卷积层转换函数, $h(\cdot)$ 表示卷积层转换函数。在多层级并行上采样结构中,除了并行计算特征层之外,前一层级每一特征层的输出都可以作为后一层级相应特征层的输入,具体计算为

$$U_i^l = \begin{cases} h(f(L^4)) & i = 1, l = 1 \\ h(f(U_i^{l-1})) & i = 1, 2 \leq l \leq 3, l \in N \\ h(U_{i-1}^l) & 2 \leq i \leq k, l = 1, i \in N \\ h^l(\text{concat}(f(L_i^{l-1}), L_{i-1}^l)) & 2 \leq i \leq k, 2 \leq l \leq 3, \\ & i \in N, l \in N \end{cases} \quad (5)$$

式中, $U_i^l$ 表示第 $i$ 层级上采样分支的第 $l$ 层特征。与多层级并行的特征提取结构类似,迭代地将前一个上采样分支的输出特征作为输入特征的一部分输入到之后的上采样分支中,使第 $i$ 层级上采样分支的第 $l$ 层特征融合了所有第 $1 \sim i-1$ 层级上采样分支的第 $1 \sim l$ 层特征以及第 $i$ 层级上采样分支的第 $1 \sim l-1$ 层特征,能够为不同尺寸的特征在进行还原时提供更多维度的信息,并且最后的分割特征为

$$U^l = h(\text{concat}(h(f(L_1^{l-1})), h(f(L_1^{l-1})), \dots, h(f(L_k^{l-1}))))), l = 4 \quad (6)$$

利用尺寸与输入多模态脑肿瘤图像相同的分割特征,可以通过 $\text{softmax}()$ 函数预测出逐像素的类别概率,最终概率最大的类别即为该脑肿瘤图像像素的最终预测类别。

### 2.3 多层级金字塔长连接模块

结合池化与卷积融合的金字塔结构,本文对基于U-Net模型的多层级并行分割模块中的长连接部分进行改进,提出了多层级金字塔长连接结构,如图2所示,图中 $L$ 表示网络中卷积后的特征层, $U$ 表

示网络反卷积后的特征层。

本文取代了原有的多层级特征拼接到多层级并行分割模块中方式,将特征提取模块中的第 $i$ 特征层 $L_k^i$ 作为输入, $i \in (1, 2, 3)$ ,进行多尺度的并行卷积操作。式中包含尺度为 $3 \times 3$ 和 $5 \times 5$ 的卷积核,然后将该特征层 $L_k^i$ 与特征提取模块中尺寸大于该层特征的所有特征层 $L_k^{i-1}, L_k^{i-2}, \dots, L_k^1$ ,经过池化层进行特征尺寸适配,包含尺寸为 $7 \times 7$ 和 $5 \times 5$ 的最大池化层,输出与特征层 $L_k^i$ 相同尺寸的特征,再将这些相同尺寸的特征进行通道上的拼接,并通过 $1 \times 1$ 的卷积将这些拼接后的多尺度特征进行压缩融合,将融合结果与多层级并行分割模块中的同尺寸特征进行拼接,再经过计算得到特征层 $U_i^{4-i}$ 。

通过多层级金字塔长连接模块,提升了特征的局部感受野与整体感受野,增强了特征的丰富度,另外,多层级金字塔长连接模块的输入端充分考虑了不同尺寸特征之间的信息融合,在一定程度上防止了图像信息的丢失和变形,可以更好地提升长连接两端同尺寸特征的传播效率,最终影响多模态脑肿瘤图像的分割精度。

## 3 实验结果及分析

### 3.1 数据集及评价指标

BRATS 2015数据集提供的训练数据集包含220个HGG(human gamma globulin)病例数据和54个LGG(low-grade glioma)病例数据,测试集包含110个病例数据。其中,训练集和测试集中有极少数病例数据是人工合成的,合成数据的肿瘤类别数目少于真实数据。每个病例数据都有4种不同的MRI模态,分别是Flair、T1、T1c和T2,不同MRI模态对脑部不同区域的关注度不同,每个病例数据的每个模态数据的尺寸都为 $155 \times 240 \times 240$ 。

在BRATS 2015脑肿瘤分割任务中,需要根据各肿瘤区域的划分分别评估其分割预测情况,共3种脑肿瘤区域。1)完整肿瘤区域,包含坏死、水肿、非增强肿瘤、增强肿瘤等4种肿瘤结构;2)核心肿瘤区域,包含坏死、非增强肿瘤、增强肿瘤等3种肿瘤结构;3)增强肿瘤区域,仅包含增强肿瘤1种肿瘤结构。

本文采用Dice系数作为的脑肿瘤图像的分割评价指标,计算方式为

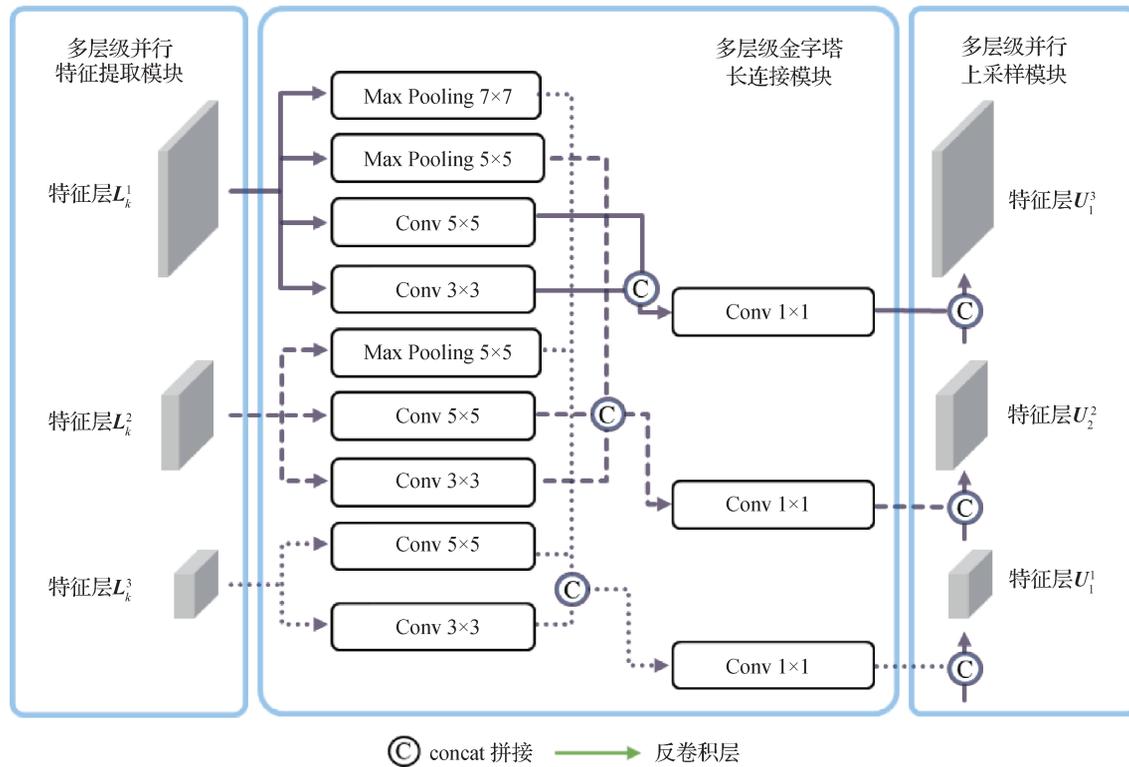


图2 多层次金字塔长连接模块图

Fig. 2 Illustration of multi-level pyramid long connection module

$$Dice(GT, AT) = \frac{2|GT \cap AT|}{|GT| + |AT|} \quad (7)$$

式中,  $GT$ 和 $AT$ 分别表示真值和方法的分割结果。

### 3.2 实验设置

所有深度神经网络的超参数设置如下:批处理大小设置为8,损失函数采用多类别交叉熵损失,采用Adam算法作为模型的优化器,网络模型的学习率初始值为0.0001,并在每个训练周期衰减为原来的一半,运行神经网络采用的实验服务器为NVIDIA RTX2080Ti。

### 3.3 多层次并行特征提取模块对比实验

根据本文对多层次并行特征提取模块的定义。首先,使用BRATS 2015脑肿瘤数据集,对不同层级数目的并行特征提取结构( $j = 1, 2, 3, 4, 5$ )以及原始的ResNet-50的特征提取结构进行实验,结果如表3所示。

综合表3中Dice各项分割指标能够发现,任意多层次并行特征提取结构( $j = 2, 3, 4, 5$ )的分割效果要比单层结构( $j = 1$ )要好。随着特征提取模块层级数目的增加,参数量成倍的增加,而取得的综合Dice值具有上升趋势(除了 $j = 4$ )。特别的,当层级数目为3或5时,取得的综合分割效果最佳。另外,对比于原始ResNet-50基础骨干结构,多层次并行的特征

表3 不同层级数目的并行特征提取模块在BRATS 2015数据集上的Dice表现

Table 3 Performance of Dice on different levels of parallel feature extraction modules on the BRATS 2015 dataset

层级数目	完整肿瘤	核心肿瘤	增强肿瘤	参数量/ $10^6$
$j = 1$	0.82	0.67	0.57	3.344 1
$j = 2$	0.83	0.68	0.58	7.001 2
$j = 3$	0.83	0.69	0.59	10.068 3
$j = 4$	0.83	0.69	0.58	13.135 4
$j = 5$	0.84	0.69	0.58	16.202 4
ResNet-50	0.83	0.68	0.55	30.356 0

提取结构取得了更好效果,而且网络参数量更低。这也证明了多层次并行特征提取模块中特征融合的有效性以及该网络设计结构的可行性与合理性。

### 3.4 多层次并行上采样模块对比实验

与多层次并行特征提取模块的验证过程类似,根据本文对多层次并行上采样模块的定义,使用BRATS 2015数据集对不同层级数的并行上采样结构( $k = 1, 2, 3, 4, 5$ )与原始的U-Net上采样结构分别进行实验,结构如表4所示。可以看出,任意多层次并行上采样结构( $k = 2, 3, 4, 5$ )的分割效果要比单层

结构( $k = 1$ )要好。另外,不同于多层次并行的特征提取结构,随着层级数目的进一步增加( $k > 2$ ),增强肿瘤区域的Dice值有着略微的上升趋势( $k = 3$ 时略微下降),完整肿瘤与核心肿瘤的变化趋势不明显。当层级数目为2时,多层次并行上采样结构的分割效果靠前,且参数开销不大。另外,相比较于原始U-Net的上采样结构,在同样级别的参数量开销情况下,本文的结构效果更好,由此也证明了多层次并行上采样结构的可行性。

表4 不同层级数目的并行上采样模块在BRATS 2015数据集上的Dice表现

Table 4 Performance of Dice on different levels of parallel up-sampling modules on the BRATS 2015 dataset

层级数目	完整肿瘤	核心肿瘤	增强肿瘤	参数量/ $10^6$
$k = 1$	0.82	0.67	0.57	3.344 1
$k = 2$	0.83	0.69	0.58	5.462 1
$k = 3$	0.83	0.69	0.57	6.808 3
$k = 4$	0.83	0.70	0.58	8.154 5
$k = 5$	0.83	0.69	0.59	9.500 7
U-Net	0.82	0.69	0.58	5.278 1

### 3.5 多层次金字塔长连接模块对比实验

本文使用多层次金字塔长连接模块替换基于U-Net网络中原有的长连接结构,并使用

BRATS 2015数据集进行实验验证,表5展示了是否使用多层次金字塔长连接结果的实验结果对比。对比表5第1、2行数据可以看出,相比于原有的长连接结构,使用多层次金字塔长连接模块后,完整、核心和增强肿瘤区域的Dice分割精度均有所提升。

另外,对多层次并行特征提取结构以及多层次并行上采样结构进行实验验证,通过衡量精度、模型参数量大小以及模型效率,选择3层级并行特征提取和2层级并行上采样结构作为基于多层次并行神经网络的分割框架的最终网络模型,表5同样展示了3层级特征提取和2层级上采样模型的分割效果,可以看到,对比于单层级的特征提取与上采样模型,3层级特征提取和2层级上采样模型在完整和核心肿瘤区域的分割效果提升最为明显。同样,在此结构基础上使用多层次金字塔长连接模块也提升了肿瘤的分割精度,且主要体现在增强肿瘤区域。值得注意的是,本文方法达到了最佳的分割精度,在完整、核心和增强肿瘤区域的Dice精度分别为0.84,0.70,0.60。由此证明了多层次金字塔长连接模块的性能,特别是对核心与增强肿瘤区域,因为这些区域中包含的肿瘤类别较小且形状最为复杂多变,对于这一部分的肿瘤细节信息来说,也最容易在特征提取过程中丢失。

表5 有无多层次金字塔长连接模块在BRATS 2015数据集上的Dice表现

Table 5 Performance of Dice with or without the multi-level pyramid long connection module on the BRATS 2015 dataset

多层次并行网络模型	多层次金字塔长连接	完整肿瘤	核心肿瘤	增强肿瘤	参数量/ $10^6$
$j = 1, k = 1$	无	0.82	0.67	0.57	3.344 1
$j = 1, k = 1$	有	0.83	0.69	0.58	6.499 3
$j = 3, k = 2$	无	0.84	0.70	0.58	12.186 4
$j = 3, k = 2$	有	0.84	0.70	0.60	15.341 6

### 3.6 同其他方法的对比

为了进一步验证基于多层次并行神经网络的分割性能,与当前主流的脑肿瘤分割方法进行精度与效率对比,结果如表6所示。在BRATS 2015数据集中,早期只有53个测试病例,后来增加到110个,而更多的测试病例数会使分割任务更具挑战性。Pereira等人(2015)和Havaei等人(2017)在53个测试病例上进行实验;Kamnitsas等人(2017)、

Zhao等人(2018)、Chen等人(2020)、Ding等人(2019a, 2020)和本文方法在110个测试病例进行实验评估。从实验结果可以发现,即使面临更具挑战性的任务,本文提出的方法比Havaei等人(2017)和Pereira等人(2015)的方法获得了更好的分割性能。

此外,与在110例病例中评估的其他几种方法相比,Kamnitsas等人(2017)和Zhao等人(2018)的方

法在增强肿瘤区域的分割精度较好,但是对于单病例的分割时间较长,效率低下,造成这种差异的原因可能是 Zhao 等人(2018)使用了 N4ITK(improved N3 bias correction)方法(Tustison 等, 2010)进行数据预处理,同时 Zhao 等人(2018)和 Kamnitsas 等人(2017)采用的 3D CRF(3D conditional random field)方法(Krähenbühl 和 Koltun, 2011)对分割结果进行后处理。N4ITK 预处理方法可以增强原始图像质量,而 3D CRF 方法可以对分割结果进行修正。但是,无论

是 N4ITK 预处理方法或 3D CRF 后处理方法,都会大幅增加脑肿瘤分割任务的计算负担,同时也是一项极其耗时的工作。相比之下,在本文的多层级并行神经网络中,没有使用任何后处理方法,仅用不到 5 s 的时间即可完成对单个病例的分割,与分割精度较高的方法相比,本文的分割精度略低,但分割效率大幅提升。在与其他 3 种速度较快(小于 15 s)的分割方法对比中,本文方法的分割速度最快,并且对各个肿瘤区域的分割精度达到了最高。

表 6 在 BRATS 2015 数据集上与其他方法对比  
Table 6 Compare with other methods on the BRATS 2015 dataset

病例总数/个	方法	Dice			单病例分割时间
		完整肿瘤	核心肿瘤	增强肿瘤	
53	Pereira 等人(2015)	0.78	0.65	0.75	< 20 s
	Havaei 等人(2017)	0.79	0.58	0.69	25 s ~ 3 min
	Kamnitsas 等人(2017)	0.85	0.67	0.63	< 30 s
	Zhao 等人(2018)	0.84	0.73	0.62	2 ~ 4 min
110	Chen 等人(2020)	0.82	0.66	0.58	< 11 s
	Ding 等人(2019a)	0.84	0.67	0.59	< 10 s
	Ding 等人(2020)	0.84	0.67	0.60	< 12 s
	本文	0.84	0.70	0.60	< 5 s

### 3.7 其他数据集的验证

为了验证本文方法的泛化性,在 BRATS 2018 数据集上进行实验验证,该数据集的数据构成与 BRATS 2015 一致, BRATS 2018 提供的训练数据集包含 210 个 HGG 病例数据和 75 个 LGG 病例数据,验证数据集包含 66 个病例数据。实验结果如图 3 所示,基于方法为单层级特征提取和单层级上采样结构。图 4 展示了数据集所有病例的详细分割情况,可以看出,使用多层次并行神经网络后,数据集中所有病例数据的整体分割精度都达到了较高水准,特别是在完整肿瘤区域。

此外,在 BRATS 2018 数据集上使用多层次并行神经网络与当前主流分割网络的性能进行对比。实验结果如表 7 所示。Tuan 等人(2018)、Rezaei 等人(2017, 2018)、Zhou(2020)等人、Benson 等人(2018)和本文方法在 66 个测试病例进行实验评估。从实验结果可以看出,在不同数据集上,本文提出的方法比其他网络具有更好的性能,证明了本文方法具有良好的泛化性。

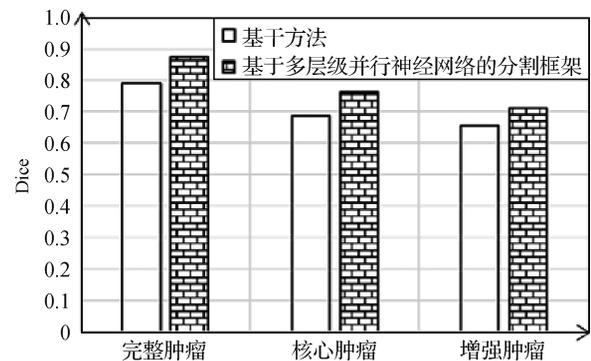


图 3 BRATS 2018 数据集上的验证结果

Fig. 3 Verification results on the BRATS 2018 dataset

## 4 结论

本文基于常用的网络骨干对网络结构进行扩展,提出基于多层次并行神经网络的多模态脑肿瘤图像分割框架。该框架不需要复杂的网络设计,可以快速对现有网络进行扩展,以充分提取并利用网络中的多维度特征信息,提升网络性能并用于多模

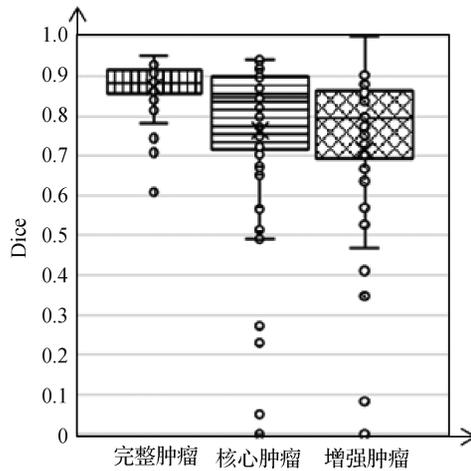


图4 BRATS 2018数据集上的详细分割结果

Fig. 4 Detailed segmentation results on the BRATS 2018 dataset

表7 在BRATS 2018数据集上与其他方法的Dice对比  
Table 7 Comparison of Dice with other methods on the BRATS 2018 dataset

方法	完整肿瘤	核心肿瘤	增强肿瘤
Tuan 等人(2018)	0.81	0.69	0.68
Rezaei 等人(2017)	0.84	0.79	0.63
Rezaei 等人(2018)	0.81	0.64	0.61
Zhou 等人(2020)	0.84	0.75	0.72
Benson 等人(2018)	0.82	0.72	0.66
基干	0.79	0.69	0.65
本文	0.87	0.76	0.71

态脑肿瘤图像分割。在该分割框架中,分别对深度神经网络中的特征提取阶段以及上采样阶段进行多层次并行扩展,并通过实验验证了多层次并行扩展在各个阶段的可行性。另外,本文设计了多层次金字塔长连接模块,弥补了原有长连接模型缺失的多尺度多感受野信息,提升了特征的丰富度。通过在多模态脑肿瘤数据集上的实验,证明了本文提出的基于多层次并行神经网络分割框架具有良好的分割精度与效率。但是,本文在使用多层次并行的网络模型提升网络的整体性能的同时,随着基干网络层数的增多,网络模型开销也会成倍增加,加大了计算量开销,对运行设备的性能提出了更高要求。在后续研究中,将探索通过特征复用策略和网络蒸馏策略进一步优化神经网络模型参数,希望通过高效的卷积层面的操作并减少网络参数量,提高特征提取

效率,使模型达到更好效果。

## 参考文献 (References)

- Badrinarayanan V, Kendall A and Cipolla R. 2017. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 39(12): 2481-2495 [DOI: 10.1109/TPAMI.2016.2644615]
- Bakas S, Reyes M, Jakab A, Bauer B and Pawar K. Identifying the best machine learning algorithms for brain tumor segmentation, progression assessment, and overall survival prediction in the BRATS challenge [EB/OL]. [2021-12-24]. <https://arxiv.org/pdf/1811.02629.pdf>
- Benson E, Pound M P, French A P, Jackson A S and Pridmore T P. 2018. Deep hourglass for brain tumor segmentation//Proceedings of the 4th International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Granada, Spain: Springer: 419-428 [DOI: 10.1007/978-3-030-11726-9\_37]
- Chen H, Qin Z G, Ding Y, Tian L and Qin Z. 2020. Brain tumor segmentation with deep convolutional symmetric neural network. *Neurocomputing*, 392: 305-313 [DOI: 10.1016/j.neucom.2019.01.111]
- Chen L C, Zhu Y K, Papandreou G, Schroff F and Adam H. 2018a. Encoder-decoder with Atrous separable convolution for semantic image segmentation//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer: 833-851 [DOI: 10.1007/978-3-030-01234-2\_49]
- Chen X, Liew J H, Xiong W, Chui C K and Ong S H. 2018b. Focus, segment and erase: an efficient network for multi-label brain tumor segmentation//Proceedings of the 15th European Conference on Computer Vision. Munich, Germany: Springer: 674-689 [DOI: 10.1007/978-3-030-01261-8\_40]
- Ding Y, Chen F J, Zhao Y, Wu Z X, Zhang C and Wu D Y. 2019a. A stacked multi-connection simple reducing net for brain tumor segmentation. *IEEE Access*, 7: 104011-104024 [DOI: 10.1109/ACCESS.2019.2926448]
- Ding Y, Dong R F, Lan T, Li X R, Shen G Y, Chen H and Qin Z G. 2018. Multi-modal brain tumor image segmentation based on SDAE. *International Journal of Imaging Systems and Technology*, 28(1): 38-47 [DOI: 10.1002/ima.22254]
- Ding Y, Gong L P, Zhang M F, Li C and Qin Z G. 2020. A multi-path adaptive fusion network for multimodal brain tumor segmentation. *Neurocomputing*, 412: 19-30 [DOI: 10.1016/j.neucom.2020.06.078]
- Ding Y, Li C, Yang Q Q, Qin Z and Qin Z G. 2019b. How to improve the deep residual network to segment multi-modal brain tumor images. *IEEE Access*, 7: 152821-152831 [DOI: 10.1109/ACCESS.2019.2948120]
- Ding Y, Luo C J, Li C, Lan T and Qin Z G. 2019c. High-order correla-

- tion detecting in features for diagnosis of Alzheimer's disease and mild cognitive impairment. *Biomedical Signal Processing and Control*, 53: #101564 [DOI: 10.1016/j.bspc.2019.101564]
- Ding Y, Wu G Z, Chen D J, Zhang N, Gong L P, Cao M S and Qin Z G. 2021. DeepEDN: a deep-learning-based image encryption and decryption network for internet of medical things. *IEEE Internet of Things Journal*, 8 (3): 1504-1518 [DOI: 10.1109/JIOT.2020.3012452]
- Dvořák P and Menze B. 2015. Local structure prediction with convolutional neural networks for multimodal brain tumor segmentation// *Proceedings of International Workshop on Medical Computer Vision: Algorithms for Big Data*. Munich, Germany: Springer: 59-71 [DOI: 10.1007/978-3-319-42016-5\_6]
- El-Dahshan E S A, Mohsen H M, Revett K and Salem A B M. 2014. Computer-aided diagnosis of human brain tumor through MRI: a survey and a new algorithm. *Expert Systems with Applications*, 41(11): 5526-5545 [DOI: 10.1016/j.eswa.2014.01.021]
- Goetz M, Weber C, Binczyk F, Polanska J, Tarnawski R, Bobek-Billewicz B, Koethe U, Kleesiek J, Stieltjes B and Maier-Hein K H. 2016. DALSA: domain adaptation for supervised learning from sparsely annotated MR images. *IEEE Transactions on Medical Imaging*, 35(1): 184-196 [DOI: 10.1109/TMI.2015.2463078]
- Guo J, Deng J K, Xue N N and Zafeiriou S. 2018. Stacked dense U-nets with dual transformers for robust face alignment// *Proceedings of British Machine Vision Conference 2018*. Newcastle, UK: BMVC: 1-13
- Havaei M, Davy A, Warde-Farley D, Biard A, Courville A, Bengio Y, Pal C, Jodoin P M and Larochelle H. 2017. Brain tumor segmentation with deep neural networks. *Medical Image Analysis*, 35: 18-31 [DOI: 10.1016/j.media.2016.05.004]
- Havaei M, Dutil F, Pal C, Larochelle H and Jodoin P M. 2015. A convolutional neural network approach to brain tumor segmentation// *Proceedings of the 1st International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Munich, Germany: Springer: 195-208 [DOI: 10.1007/978-3-319-30858-6\_17]
- He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition// *Proceedings of 2016 IEEE Conference on Computer Vision and Pattern Recognition*. Las Vegas, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]
- Hu J, Shen L and Sun G. 2018. Squeeze-and-excitation networks// *Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition*. Salt Lake City, USA: IEEE: 7132-7141 [DOI: 10.1109/CVPR.2018.00745]
- Islam M and Ren H L. 2017. Fully convolutional network with hypercolumn features for brain tumor segmentation// *Proceedings of the 3rd International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Quebec City, Canada: Springer: 298-308 [DOI: 10.1007/978-3-319-75238-9\_26]
- Kamnitsas K, Ledig C, Newcombe V F J, Simpson J P, Kane A D, Menon D K, Rueckert D and Glocker B. 2017. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation. *Medical Image Analysis*, 36: 61-78 [DOI: 10.1016/j.media.2016.10.004]
- Krähenbühl P and Koltun V. 2011. Efficient inference in fully connected CRFs with Gaussian edge potentials// *Proceedings of the 24th International Conference on Neural Information Processing Systems*. Granada, Spain: Curran Associates Inc.: 109-117
- Krizhevsky A, Sutskever I and Hinton G E. 2012. ImageNet classification with deep convolutional neural networks// *Proceedings of the 25th International Conference on Neural Information Processing Systems*. Lake Tahoe, USA: Curran Associates Inc.: 1097-1105
- Luo K K, Wang T and Ye F F. 2021. U-Net segmentation model of brain tumor MR image based on attention mechanism and multi-view fusion. *Journal of Image and Graphics*, 26(9): 2208-2218 (罗恺楷, 王婷, 叶芳芳. 2021. 引入注意力机制和多视角融合的脑肿瘤MR图像U-Net分割模型. *中国图象图形学报*, 26(9): 2208-2218) [DOI: 10.11834/jig.200584]
- Martínez-Murcia F J, Górriz J M, Ramírez J, Alvarez Illán I, Salas-González D and Segovia F. 2014. Projecting MRI brain images for the detection of Alzheimer's disease// *Proceedings of the 2nd KES International Conference on Innovation in Medicine and Healthcares*. San Sebastian, Spain: IOS Press: 225-233 [DOI: 10.3233/978-1-61499-474-9-225]
- Meng Z Y, Gu X, Liang Y C, Xu D and Wu C G. 2021. Deep neural architecture search: a survey. *Journal of Computer Research and Development*, 58(1): 22-33 (孟子尧, 谷雪, 梁艳春, 许东, 吴春国. 2021. 计算机研究与发展, 58(1): 22-33) [DOI: 10.7544/issn1000-1239.2021.20190851]
- Menze B H, Jakab A, Bauer S, Kalpathy-Cramer J, Farahani K, Kirby J, Burren Y, Porz N, Slotboom J, Wiest R, Lanczi L, Gerstner E, Weber M A, Arbel T, Avants B B, Ayache N, Buendia P, Collins D L, Cordier N, Corso J J, Criminisi A, Das T, Delingette H, Demiralp Ç, Durst C R, Dojat M, Doyle S, Festa J, Forbes F, Geremia E, Glocker B, Golland P, Guo X T, Hamamci A, Iftekharuddin K M, Jena R, John N M, Konukoglu E, Lashkari D, Mariz J A, Meier R, Pereira S, Precup D, Price S J, Raviv T R, Reza S M S, Ryan M, Sarikaya D, Schwartz L, Shin H C, Shotton J, Silva C A, Sousa N, Subbanna N K, Szekely G, Taylor T J, Thomas O M, Tustison N J, Unal G, Vasseur F, Wintermark M, Ye D H, Zhao L, Zhao B S, Zikic D, Prastawa M, Reyes M and Van Leemput K. 2015. The multimodal brain tumor image segmentation benchmark (BRATS). *IEEE Transactions on Medical Imaging*, 34(10): 1993-2024 [DOI: 10.1109/TMI.2014.2377694]
- Pereira S, Pinto A, Alves V and Silva C A. 2015. Deep convolutional neural networks for the segmentation of gliomas in multi-sequence MRI// *Proceedings of the 1st International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries*. Munich, Germany: Springer: 131-143 [DOI: 10.1007/978-3-319-30858-6\_12]

- Pereira S, Pinto A, Amorim J, Ribeiro A, Alves V and Silva C A. 2019. Adaptive feature recombination and recalibration for semantic segmentation with fully convolutional networks. *IEEE Transactions on Medical Imaging*, 38(12): 2914-2925 [DOI: 10.1109/TMI.2019.2918096]
- Rezaei M, Harmuth K, Gierke W, Kellermeier T, Fischer M, Yang H J and Meinel C. 2017. A conditional adversarial network for semantic segmentation of brain tumor//Proceedings of the 3rd International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Quebec City, Canada: Springer: 241-252 [DOI: 10.1007/978-3-319-75238-9\_21]
- Rezaei M, Yang H J and Meinel C. 2018. Voxel-GAN: adversarial framework for learning imbalanced brain tumor segmentation//Proceedings of the 4th International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Granada, Spain: Springer: 321-333 [DOI: 10.1007/978-3-030-11726-9\_29]
- Ronneberger O, Fischer P and Brox T. 2015. U-net: convolutional networks for biomedical image segmentation//Proceedings of the 18th International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich, Germany: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4\_28]
- Roth H R, Lu L, Seff A, Cherry K M, Hoffman J, Wang S J, Liu J M, Turkbey E and Summers R M. 2014. A new 2.5D representation for lymph node detection using random sets of deep convolutional neural network observations//Proceedings of the 17th International Conference on Medical Image Computing and Computer-Assisted Intervention. Boston, USA: Springer: 520-527 [DOI: 10.1007/978-3-319-10404-1\_65]
- Salehi S S M, Erdogmus D and Gholipour A. 2017. Auto-context convolutional neural network (auto-net) for brain extraction in magnetic resonance imaging. *IEEE Transactions on Medical Imaging*, 36(11): 2319-2330 [DOI: 10.1109/TMI.2017.2721362]
- Shaikh M, Anand G, Acharya G, Amrutkar A, Alex V and Krishnamurthi G. 2017. Brain tumor segmentation using dense fully convolutional neural network//Proceedings of the 3rd International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Quebec City, Canada: Springer: 309-319 [DOI: 10.1007/978-3-319-75238-9\_27]
- Shang H B, Zhao W G and Zhang W F. 2012. Preoperative assessment using multimodal functional magnetic resonance imaging techniques in patients with brain gliomas. *Turkish Neurosurgery*, 22(5): 558-565 [DOI: 10.5137/1019-5149.JTN.5332-11.1]
- Simonyan K and Zisserman A. 2015. Very deep convolutional networks for large-scale image recognition//Proceedings of the 3rd International Conference on Learning Representations. San Diego, USA: ICLR: 28-29 [DOI: 10.48550/arXiv.1409.1556]
- Tan M X and Le Q V. 2019. EfficientNet: rethinking model scaling for convolutional neural networks//Proceedings of the 36th International Conference on Machine Learning. Long Beach, USA: ICML: 6105-6114
- Tuan T A, Tuan T A and Bao P T. 2018. Brain tumor segmentation using bit-plane and UNET [C]//Proceedings of the 4th International Workshop on Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries. Granada, Spain: Springer: 466-475 [DOI: 10.1007/978-3-030-11726-9\_41]
- Tustison N J, Avants B B, Cook P A, Zheng Y J, Egan A, Yushkevich P A and Gee J C. 2010. N4ITK: improved N3 bias correction. *IEEE Transactions on Medical Imaging*, 29(6): 1310-1320 [DOI: 10.1109/TMI.2010.2046908]
- Xia F, Shao H J and Deng X. 2022. Cross-stage deep-learning-based MRI fused images of human brain tumor segmentation. *Journal of Image and Graphics*, 27(3): 873-884 (夏峰, 邵海见, 邓星. 2022. 融合跨阶段深度学习的脑肿瘤MRI图像分割. *中国图象图形学报*, 27(3): 873-884) [DOI: 10.11834/jig.210330]
- Yu K, Jia L, Chen Y Q and Xu W. 2013. Deep learning: yesterday, today, and tomorrow. *Journal of Computer Research and Development*, 50(9): 1799-1804 (余凯, 贾磊, 陈雨强, 徐伟. 2013. 深度学习的昨天、今天和明天. *计算机研究与发展*, 50(9): 1799-1804)
- Zhao X M, Wu Y H, Song G D, Li Z Y, Zhang Y Z and Fan Y. 2018. A deep learning model integrating FCNNs and CRFs for brain tumor segmentation. *Medical Image Analysis*, 43: 98-111 [DOI: 10.1016/j.media.2017.10.002]
- Zhou Z X, He Z S and Jia Y Y. 2020. AFPNet: a 3D fully convolutional neural network with Atrous-convolution feature pyramid for brain tumor segmentation via MRI images. *Neurocomputing*, 402: 235-244 [DOI: 10.1016/j.neucom.2020.03.097]
- Zikic D, Ioannou Y, Brown M and Criminisi A. 2014. Segmentation of brain tumor tissues with convolutional neural networks//Proceedings of 2014 MICCAI Workshop on Multimodal Brain Tumor Segmentation Challenge. Boston, USA: MICCAI: 36-39

## 作者简介

丁熠,男,教授,主要研究方向为深度学习、医学图像处理、计算机辅助诊疗和软件工程。E-mail: yi.ding@uestc.edu.cn

耿技,通信作者,男,教授,主要研究方向为深度学习、计算机开放系统与网络安全、信息系统安全。

E-mail: jgeng@uestc.edu.cn

郑伟,男,硕士研究生,主要研究方向为深度学习、医学图像处理。E-mail: 1303710705@qq.com

邱泸谊,女,硕士研究生,主要研究方向为深度学习、医学图像处理。E-mail: 15181165812@163.com

秦志光,男,教授,主要研究方向为深度学习、计算机开放系统与网络安全、信息系统安全、智能交通、电子商务。

E-mail: qinzg@uestc.edu.cn