

DOI:10.16136/j.joel.2022.12.0095

基于 3D U-Net 的轻量级脑肿瘤分割网络

魏 欣, 李 锵*, 关 欣

(天津大学 微电子学院, 天津 300072)

摘要:针对现有脑肿瘤核磁共振成像(magnetic resonance imaging, MRI)分割神经网络的参数量和计算量较大且对肿瘤区域小目标分割精度不高的问题,提出一种改进的轻量级脑肿瘤分割网络 MF-RES2Net(multiple fiber residual-like networks)。该网络以 3D U-Net 为基础架构,将多纤模块(multi-fiber, MF)和类残差模块(RES2)相结合代替传统卷积模块。MF 将特征图像的通道进行混合,增加了通道间信息的交流融合;RES2 将通道均分,单通道的卷积结果相加到相邻通道,在扩大图像感受野的同时保留了细节特征,同时降低网络参数量。此外,为改善数据不平衡问题,提出一种改进的加权损失函数,提高了网络对小目标的分割精度。将 MF-RES2Net 在 BRATS 2019 数据集进行验证,完整肿瘤、核心肿瘤和增强肿瘤分割的平均 *Dice* 系数分别为 89.98%、84.02%、77.62%,参数量和浮点数分别为 3.16 M 和 16.24 G,结果表明:该网络在降低参数量和计算量的同时进一步提升了分割性能,有效地降低了网络运行时的设备要求。

关键词:核磁共振成像(MRI); 脑肿瘤分割; 卷积神经网络(CNN); 轻量级; 加权损失函数

中图分类号: TP391.7 **文献标识码:** A **文章编号:** 1005-0086(2022)12-1338-07

Lightweight network in brain tumor segmentation based on 3D U-Net

WEI Xin, LI Qiang*, GUAN Xin

(School of Microelectronics, Tianjin University, Tianjin 300072, China)

Abstract: Considering that the current neural networks have some problems in brain tumor magnetic resonance imaging (MRI) segmentation, which are a large number of parameters and low accuracy of small target segmentation, an improved lightweight brain tumor segmentation network multiple fiber residual-like networks (MF-RES2Net) is proposed. The network is based on 3D U-Net and replaces the traditional convolution module with the multi-fiber (MF) unit and the RES2 unit. The MF unit mixes the channels of the feature image, which increases the communication between channels. The RES2 unit divides the channels equally, and the convolution result of one single channel is added to the adjacent channels, which expands the image receptive field and reduces the parameters while retaining feature details. In addition, a improved weighted-loss function is proposed to address the network segmentation accuracy of small targets for the data imbalance problem. MF-RES2Net is verified on the BRATS 2019 data set, and the average *Dice* coefficients of tumor segmentation in whole tumor, core tumor and enhanced tumor region have reached 89.98%, 84.02%, 77.62% respectively, and the network has 3.16 M parameters and 16.24 G FLOPs. The result shows MF-RES2Net achieves more accurate target segmentation with lower parameters and calculations, effectively reducing equipment requirements during network running.

Key words: magnetic resonance imaging (MRI); brain tumor segmentation; convolutional neural networks (CNN); lightweight; weighted-loss function

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

收稿日期: 2022-02-21 修订日期: 2022-03-23

基金项目: 国家自然科学基金(61471263, 61872267)、天津市自然科学基金(16JCZDJC31100)和天津大学自主创新基金(2021XZC-0024)资助项目

1 引言

脑肿瘤是发病率和致死率极高的肿瘤之一,据统计,近些年,脑肿瘤新发病例约占所有癌症新发病例的1.5%,死亡比例却高达3%^[1],患者的生命健康受到严重危害。通常,医生通过脑部多模态的核磁共振成像(magnetic resonance imaging, MRI)对患者进行检查和诊断。脑肿瘤MRI模态包括T1加权(t1-weighted, T1)、对比增强T1加权(contrast enhanced t1-weighted, T1C)、T2加权(t2-weighted, T2)和液体衰减反转恢复脉冲(fluid attenuated inversion recovery, FLAIR)。临床上,一般通过4种模态的图像进行综合诊断,从而对肿瘤区域进行分割^[2]。人工手动分割主要依靠医生的个人经验,而医生之间的专业水平存在差距,可能导致分割结果出入较大;且临床上图像数据量较大,专家数量较少,人工分割效率低下。因此,如何精准、高效地进行脑肿瘤分割成为研究重点。

随着人工智能的快速发展,深度学习尤其是卷积神经网络(convolutional neural networks, CNN)已广泛应用于图像分割领域^[3]。CNN通过多个卷积层、池化层和全连接层将图像与特征参数进行卷积,提取图像的特征,训练出具有较强鲁棒性和学习能力的网络模型。在医学图像分割领域,网络模型往往因为训练集图像尺寸较大、数量较小,导致精度提升有限。U-Net^[4]的提出极大地改善了此问题,它在CNN的基础上增加了多个上下文连接的通道和上采样模块,实现了低层特征和高层特征的融合,也更利于大尺寸图像的分割。

基于3D U-Net的网络模型通常参数量、计算量较大,需要更大的GPU显存、更长的训练时间。

如何将网络轻量化,从而减少硬件资源对研究的限制,提高网络的适用性成为当前的研究方向之一。NUECHTERLEIN等^[5]提出的3D-ESPNNet将ESPNNet^[6]扩展到3D脑肿瘤分割领域,网络中的高效空间金字塔模块有助于减小模型计算量和参数量,提高了网络在终端设备上的适用性。GAO等^[7]提出的Res2Net在原有的残差模块中加入小的残差块,形成类残差模块(RES2),不增加计算量的同时提升了网络的多尺度表征能力,在目标检测、语义分割领域有出色的表现。CHEN等^[8]提出的DMFNet将多纤结构(multi-fiber, MF)^[9]运用到网络模型中,并使用了与3D-ESPNNet相似的网络模块,用多个扩张率不同的卷积核分别对图像进行组卷积^[10],再将卷积结果拼接起来,有效地减少了计算量。但由于该网络模型使用了组卷积和过多的扩张卷积,在增加图像感受野的同时也丢失了许多局部细节。

针对当前轻量级网络对肿瘤细节分割精度不足的问题,本文提出一种改进的轻量级神经网络模型MF-RES2Net(multiple fiber residual-like networks),将MF与RES2相结合组成MF-RES2模块,在扩大感受野、保持网络整体性的同时降低网络的参数量和计算量;同时使用改进的损失函数,在Tversky函数^[11]的基础上加入类别权重,用以提高网络训练时对小目标的专注度。

2 网络模型

2.1 MF-RES2Net

MF-RES2Net以3D U-Net为基础网络,用MF-RES2单元代替传统卷积模块,网络总体结构如图1所示。网络分为下采样和上采样两部分,其中下采样部分共4层,每层都由一个步长为2、核尺寸




图1 MF-RES2Net整体结构

Fig. 1 Structure of MF-RES2Net

为 $3 \times 3 \times 3$ 的卷积、两个步长为 1 的 MF-RES2 单元组成,该操作用以降低特征图尺寸并提取深层信息。使用步长为 2 的卷积来降低图像特征层尺寸,相比于池化操作的精准度更高。上采样部分同样为 4 层,每层由一个三线性插值和一个步长为 1 的 MF-RES2 单元组成,用以增加特征层尺寸并压缩其深度。在每次上采样后,都会将得到的特征图像与对应下采样的特征图像相拼接,将深浅层的特征信息相融合,深层信息用以提供精准分割的定位依据,浅层信息用以提供分类识别依据。网络最后的 softmax 层将输出图像转化为与输入图像尺寸相同的分割结果。

2.2 MF-RES2Net

MF-RES2 单元由 MF 单元和 RES2 单元拼接而




图2 MF-RES2 单元

Fig. 2 MF-RES2 unit

而通常使用 $1 \times 1 \times 1$ 大小卷积核不改变通道数的卷积操作的参数量为:

$$P = C_{in} \times C_{in} = C_{in}^2, \quad (2)$$

与之相比,MF 的参数量减少了一半。

RES2 如图 2(c)所示,输入特征图像经核为 $1 \times 1 \times 1$ 的卷积操作后被分为 s 部分(图中 $s=4$),每部分用 $X_i, i \in \{1, 2, \dots, s\}$ 表示,各 X_i 具有相同的尺寸,但通道数是输入特征的 $1/s$,除 X_1 外,其他子特征都有相对应的核为 $3 \times 3 \times 1$ 的卷积操作 K_i ,卷积的输出为 Y_i 。每个子特征都会和 K_{i-1} 的结果相加,然后输入到 K_i ,最终输出 Y_i 的表达式为:

$$Y_i = \begin{cases} X_i, i = 1 \\ K_i, i = 2 \\ K_i(X_i + Y_{i-1}), 2 < i \leq s \end{cases}. \quad (3)$$

因此,每个 $3 \times 3 \times 1$ 的卷积操作都可以接收所有来自左边的特征信息,如 Y_2 可以得到 $3 \times 3 \times 1$ 大

小的感受野,如图 2(b)所示,前者用于改善各通道间的信息交流,后者用于表征多尺度特征,增加每个网络层的感受野大小。

MF 如图 2(a)所示,由两个核为 $1 \times 1 \times 1$ 的卷积操作组成。核大小为 1 的卷积操作可以灵活改变通道数,实现降维或升维操作,从而融合不同通道间的信息,同时可在不损失分辨率的前提下大幅增加非线性特征,有利于构建更深的网络层数。输入的特征图像经过第一次卷积操作后,通道数由 C_{in} 变成 $C_{in}/4$,通道信息被整合,再经过第二次卷积操作将通道数还原成 C_{in} ,整合过的通道信息被重新分配到各个通道中,使得通道信息能够充分融合,促进了通道间的信息交流。MF 的参数量为:

$$P = C_{in} \times C_{in}/4 + C_{in}/4 \times C_{in} = C_{in}^2/2. \quad (1)$$

小的感受野, Y_3 可以接收 Y_2 卷积后的特征信息,从而得到 $5 \times 5 \times 1$ 大小的感受野,同理 Y_4 可以得到 $7 \times 7 \times 1$ 大小的感受野。这样一来,每个输出都能增大感受野,所以每个 RES2 单元都是一个获得不同数量和不同感受野大小的特征组合。最后将 4 个输出(Y_1, Y_2, Y_3, Y_4)进行拼接并依次经过核为 $1 \times 1 \times 1$ 和 $1 \times 3 \times 3$ 的卷积操作进行信息融合。相比于 CHEN 等^[8]直接使用不同扩张率的扩张卷积得到结果相加的操作,此方法同样增加了网络的感受野,同时仍保留了图像的细节特征,也降低了参数量和计算量。

2.3 加权损失函数

图像分割中常使用 Dice loss^[12]作为损失函数来评估两个样本之间的相似度,在正负样本严重不平衡的场景下有着较快的收敛速度和较好的性能。然而,在脑部 MRI 切片图像中,脑肿瘤往往仅占脑部体

积的一小部分,使用 Dice loss 时对小目标的分割十分不利,网络训练中损失函数容易到达局部最小值,从而影响分割精度。Generalized Dice loss^[13]将多个类别的 Dice loss 进行整合,将分割结果量化成一个指标 *GDL*,表达式如下:

$$GDL = 1 - \frac{1}{m} \times \frac{2 \sum_{l=1}^m \omega_l \sum_n r_{ln} p_{ln}}{\sum_{l=1}^m \omega_l \sum_n r_{ln} + p_{ln}}, \quad (4)$$

式中, r_{ln} 表示类别 l 在第 n 个像素点的标准值, p_{ln} 表示对应的预测概率, ω_l 表示每个类别的权重,表达式为:

$$\omega_l = \frac{1}{N \left(\sum_{n=1}^N r_{ln} \right)^2}. \quad (5)$$

同样, Tversky loss^[11]的提出改善了数据不平衡的问题,在精度和召回率之间取得了较好的平衡,表达式为:

$$T = \frac{\sum_{i=1}^N p_{0i} g_{0i}}{\sum_{i=1}^N p_{0i} g_{0i} + \alpha \sum_{i=1}^N p_{0i} g_{1i} + \beta \sum_{i=1}^N p_{1i} g_{0i}}, \quad (6)$$

式中, g_{0i} 表示类别 l 在第 i 个像素点的标准值, p_{0i} 表示对应的预测概率, $p_{0i} g_{1i}$ 表示假阴性, $p_{1i} g_{0i}$ 表示假阳性, α 和 β 用来调节假阳性与假阴性之间的平衡。为了优化 Tversky loss 在进行多分类时的效果,本文提出加入权重参数 ω_l :

$$\omega_l = \frac{1}{N \left(\sum_{i=1}^N g_{0i} \right)^2 + eps}, \quad (7)$$

式中, $eps = 1 \times 10^{-4}$ 以保证分母不为零, $\sum_{i=1}^N g_{0i}$ 表示图像中各像素点标准值的和,若 $\sum_{i=1}^N g_{0i}$ 越小, ω_l 就越大,该类别损失值占整体的比重就越大。通过增加对小目标分类错误的惩罚来平衡不同分割目标的训练强度,从而提高对小目标分类的精度。改进后的加权损失函数的表达式为:

$$T_w = \frac{\sum_{l=1}^k \omega_l \sum_{i=1}^N p_{0i} g_{0i}}{\sum_{l=1}^N \omega_l \left(\sum_{i=1}^N p_{0i} g_{0i} + \alpha \sum_{i=1}^N p_{0i} g_{1i} + \beta \sum_{i=1}^N p_{1i} g_{0i} \right)}. \quad (8)$$

3 实验结果与分析

3.1 实验环境与参数设置

本文的实验环境为 CPU Intel i9-9900X,

GPU Nvidia RTX2080Ti (11 GB) × 4, Ubuntu 16.04 操作系统, Pytorch 框架。

实验数据来自网络公开数据集 BRATS 2019, 包含训练集和测试集两个部分。训练集包含 335 个 MRI 脑肿瘤图像, 其中高级别肿瘤图像 259 个, 低级别肿瘤图像 76 个, 测试集为 125 个脑肿瘤图像。所有图像分为 T1、T2、T1C、FLAIR 4 种模态, 大小为 $240 \times 240 \times 155$ 。本文实验是在 335 个训练集上进行网络训练, 然后将测试集的分割结果上传 BRATS 2019 网站进行结果评估。

由于训练集图像数量较少, 需要增加数据量, 本文实验将 $240 \times 240 \times 155$ 大小的原始图像随机裁剪成 $128 \times 128 \times 128$ 的大小, 然后沿任意轴进行镜像旋转翻转, 并在 $[-10^\circ, 10^\circ]$ 的区间内进行随机旋转, 这样便扩充了数据集, 提升了网络的泛化能力。实验选择 Adam 优化器, 学习率初始值为 1×10^{-3} , 正则化系数为 L2 范数, 初始值为 1×10^{-5} 。

3.2 评价标准

专业医师将数据集图像的脑肿瘤区域分为背景 (background, 标签为 0)、坏死核心和非增强肿瘤 (necrotic and non-enhancing tumor, 标签为 1)、水肿区域 (peritumoral edema, 标签为 2)、增强肿瘤 (enhanced tumor, ET, 标签为 4) 4 类。但在测试时, 分为了 3 类: 坏死和非增强肿瘤 (标签 1) 称为核心肿瘤 (tumor core, TC), 核心肿瘤以及水肿区域 (标签 1 和 2) 并称为完整肿瘤 (whole tumor, WT), 增强肿瘤 (ET)。本文以网络模型的精准度和复杂度为指标进行评估。

精准度采用 Dice 系数来判断。Dice 系数是一种集合相似度度量函数, 通常用于计算两个样本之间的相似度, 表达式为:

$$D = \frac{2 |A \cap B|}{|A| + |B|}, \quad (9)$$

式中, A 表示分割的真值图像, B 表示预测的分割图像。其值在 0—1 之间, 越接近 1 说明模型效果越好。Dice 还可以表示为:

$$D = \frac{2TP}{2TP + FN + FP}, \quad (10)$$

式中, TP 、 FN 、 FP 分别表示真阳性、假阴性、假阳性的像素个数。

复杂度采用参数量 (parameters) 和浮点数 (floating-point operations per second, FLOPs) 进行量化评估。其中参数量用于评估算法的空间复杂度, 表现在对计算机显存资源占用的大小; 浮点数用

于评估算法的时间复杂度,表现在算法执行时间的长短。

在三维 CNN 中,卷积层参数量的表达式为:

$$P = (C_{in} \times k_w \times k_h \times k_d + 1) \times C_{out}, \quad (11)$$

式中, $k_w \times k_h \times k_d$ 表示卷积核的大小, C_{in} 为输入通道的大小, +1 表示偏置, C_{out} 为卷积层输出通道的大小。全连接层参数量的表达式为:

$$P = (N_{in} + 1) \times N_{out}, \quad (12)$$

式中, N_{in} 表示输入特征向量的权重, +1 表示偏置, N_{out} 表示输出特征向量的权重。

卷积层 FLOPs 的表达式为:

$$F = [(C_{in} \times k_w \times k_h \times k_d) + (C_{in} \times k_w \times k_h \times k_d - 1) + 1] \times C_{out} \times w \times h \times d, \quad (13)$$

式中, $C_{in} \times k_w \times k_h \times k_d$ 表示一次卷积操作的乘法计算量, $C_{in} \times k_w \times k_h \times k_d - 1$ 表示加法计算量, +1 表示偏置, w, h, d 分别表示特征图的宽、高、深度, $C_{out} \times w \times h \times d$ 表示特征图中的所有元素。全连接层 FLOPs 的表达式为:

$$F = [N_{in} + (N_{in} - 1) + 1] \times N_{out}, \quad (14)$$

式中, $N_{in} + (N_{in} - 1) + 1$ 表示计算一个元素所需的计算量, 第一个 N_{in} 表示乘法计算量, $N_{in} - 1$ 表示加法计算量, +1 表示偏置。

3.3 实验结果与分析

3.3.1 不同损失函数对比

图 3 为部分病例的脑部 MRI 分割的真值图像, 阴影面积最大的部分为水肿区域, 其次为 *ET*, 面积最小的区域为 *TC*。由图 3 可看出肿瘤区域通常只占大脑体积的一小部分, 而 *TC* 和 *ET* 又只占 *WT* 体积的一小部分, 这会增加网络训练时的难度, 要求算法对小目标的识别更为精准。




图 3 部分病例脑肿瘤区域展示

Fig. 3 Regional display of brain tumors in some cases

为了验证改进的加权损失函数对分割结果的影响, 实验分别使用不同的损失函数对 MF-RES2Net 进行训练, 并将结果上传 BRATS 2019 验证集。采用 3 种不同损失函数得到的分割结果如表 1 所示。

通过 Dice loss, Generalized Dice loss 和本文改进的加权 Tversky loss 分割结果的对比, 可看出 3 者在 *WT* 指标的分割精度上相差不大, 但在 *ET* 和 *TC* 两个指标上, 加权的 Tversky loss 比其他两种损失函数高出一两百分点, 表明改进的损失函数在训练时会增加网络对小目标的关注, 从而提高小目标的分割精度。

表 1 不同损失函数的分割结果对比

Tab. 1 Comparison of different loss functions segmentation results

Loss functions	Dice/%		
	WT	TC	ET
Dice loss	89.93	82.49	76.42
GDL	89.83	82.71	76.62
T_w	89.98	84.02	77.62

3.3.2 与其他网络对比

本文方法与其他经典网络模型在 BRATS 2019 验证集上的分割结果对比如表 2 所示。本文方法在 *WT*、*TC*、*ET* 的 *Dice* 指标分别达到了 89.98%、84.02%、77.62%, 参数量和 FLOPs 分别为 3.16 M 和 16.24 G。与经典 3D U-Net 相比, 本文方法在 *WT*、*TC*、*ET* 的 *Dice* 指标上分别高出 1.63%、3.28%、2.80%, 且参数量和 FLOPs 仅为其 1/5 和 1/76; 与当前脑肿瘤分割领域表现较好的 No New-Net 相比, 本文方法在 *WT* 和 *TC* 指标上仍存在差距, 分别相差 0.76% 和 0.88%, 但在 *ET* 指标上, 比其高出 2.22%, 且参数量和 FLOPs 为其 1/3 和 1/12; 与其他轻量级网络 (3D-ESPNet, DMFNet) 相比, 本文方法分割精准度均有提升, 在 *TC* 指标上尤为明显, 同时参数量和计算量比最轻量化的 DMFNet 分别减少 0.72 M 和 10.80 G。结果表明, 本文方法在网络模型复杂度较低的情况下, 仍能取得较好的图像分割精度。

本文方法与其他轻量级网络 (DMFNet, 3D-ESPNet) 在部分病例的 MRI 脑肿瘤图像分割结果图的对比如图 4 所示。从图 4(a) 中的 FLAIR 模态可看到脑肿瘤不同区域的大致轮廓, 图 4(b) 的 GT 为人工分割的真实标签。通过与 GT 的对比可观察到, 各类方法均能分割出脑肿瘤不同区域的位置和大体轮廓, 但对于各区域形状不规则的边缘位置, 3D-ESPNet 的分割效果最为模糊, 本文方法的分割效果与真实标签最为接近。这与表 2 中得到的结果保持一致, 表明本文算法对较为复杂的小目标边界处理得更好。

表 2 与其他方法的分割结果对比

Tab. 2 Comparison of segmentation results with other networks

Methods	Parameters/M	FLOPs/G	Dice/%		
			WT	TC	ET
MF-RES2Net (ours)	3.16	16.24	89.98	84.02	77.62
3D-ESPNet ^[5]	3.63	76.51	87.15	78.68	66.32
DMFNet ^[8]	3.88	27.04	89.34	82.87	77.19
3D U-Net ^[14]	15.80	1 240.27	88.35	80.74	74.82
3D U-Net++ ^[15]	27.47	2 019.31	89.53	82.91	74.80
No New-Net ^[16]	10.36	202.25	90.74	84.90	75.40




图 4 与其他轻量级网络的分割图对比

Fig. 4 Comparison of segmentation graphs with other lightweight networks

4 结 论

在实际应用中,轻量级脑肿瘤分割网络存在数据不平衡的问题,从而导致对小目标分割精度偏低。针对此类问题,本文提出了一种轻量级的多纤类残差网络模型 MF-RES2Net。MF 负责进行不同通道间信息的交流融合,RES2 代替了轻量级网络中常用的扩张卷积模块,在增加图像感受野的同时仍保留了细节信息,同时降低了参数量和计算量。此外,在本文网络中使用加权的 Tversky 损失函数,改善了数据不平衡的问题,提高了网络对小目标的分割精度。本文方法在 BRATS 2019 验证集上取得了较好的分割结果,WT、TC、ET 的平均 Dice 指数分别为 89.98%、84.02%、77.62%,参数量和 FLOPs 分别为 3.16 M 和 16.24 G,相较于其他方法有更高的分割精度和更小的参数量、计算量,能够降低训练网络所需的时间和设备要求。

参考文献:

[1] KOCARNIK J M,COMPTON K,DEAN F E,et al. Cancer

incidence,mortality, years of life lost, years lived with disability,and disability-adjusted life years for 29 cancer groups from 2010 to 2019:a systematic analysis for the global burden of disease study 2019[J]. JAMA Oncology, 2021,30:e216987.

[2] 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.

李镭,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.

[3] ISIN A,DIREKOGLU C,SAH M. Review of MRI-based brain tumor image segmentation using deep learning methods[J]. Procedia Computer Science, 2016, 102: 317-324.

[4] RONNEBERGER O,FISCHER P,BROX T. U-net:convolutional networks for biomedical image segmentation[C]// International Conference on Medical Image Computing and Computer-Assisted Intervention, October 5-9, 2015, Munich, Germany. Berlin: Springer, 2015:234-241.

[5] NUECHTERLEIN N,MEHTA S. 3D-ESPNet with pyramidal refinement for volumetric brain tumor image segmentation [M]//Crimi A,Bakas S,Kuijff H,et al. Brainlesion: glioma,multiple sclerosis,stroke and traumatic brain injuries.

- Lecture Notes in Computer Science. Berlin: Springer, 2018;245-253.
- [6] MEHTA S, RASTEGARI M, CASPI A, et al. ESPNet: efficient spatial pyramid of dilated convolutions for semantic segmentation[C]//European Conference on Computer Vision, September 8-14, 2018, Munich, Germany. Berlin: Springer, 2018;552-568.
- [7] GAO S, CHENG M M, ZHAO K, et al. Res2net: a new multi-scale backbone architecture[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2019, 43 (2): 652-662.
- [8] CHEN C, LIU X, DING M, et al. 3D dilated multi-fiber network for real-time brain tumor segmentation in MRI[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, October 13-17, 2019, Shenzhen, China. Berlin: Springer, 2019;184-192.
- [9] HA Q, WATANABE K, KARASAWA T, et al. MFNet: towards real-time semantic segmentation for autonomous vehicles with multi-spectral scenes[C]//IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS), September 24-28, 2017, Vancouver, Canada. New York: IEEE, 2017;5108-5115.
- [10] IOANNOU Y, ROBERTSON D, CIPOLLA R, et al. Deep roots: improving CNN efficiency with hierarchical filter groups[C]//IEEE Conference on Computer Vision and Pattern Recognition, July 21-26, 2017, Honolulu, Hawaii. New York: IEEE, 2017;1231-1240.
- [11] SALEHI S, ERDOGMUS D, GHOLIPOUR A. Tversky loss function for image segmentation using 3D fully convolutional deep networks[M]//Wang Q, Shi Y H, Suk H I. Machine learning in medical imaging. Lecture Notes in Computer Science. Berlin: Springer, 2017;379-387.
- [12] MILLETARI F, NAVAB N, AHMADI S A. V-Net: fully convolutional neural networks for volumetric medical image segmentation[C]//Fourth International Conference on 3D Vision, October 25-28, 2016, California, USA. New York: IEEE, 2016;565-571.
- [13] SUDRE C H, LI W, 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. Berlin: Springer, 2017;240-248.
- [14] CICEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]//International Conference on Medical Image Computing and Computer-Assisted Intervention, October 17-21, 2016, Athens, Greece. Berlin, Springer, 2016;424-432.
- [15] ZHOU Z, SIDDIQUEE M, TAJBAKHSH N, et al. UNet++: a nested U-Net architecture for medical image segmentation[M]//Stoyanov D, Taylor Z, Carneiro G, et al. Deep learning in medical image analysis and multimodal learning for clinical decision support. Lecture Notes in Computer Science. Berlin: Springer, 2018;3-11.
- [16] ISENSEE F, KICKINGEREDER P, WICK W, et al. No New-Net[M]//Crimi A, Bakas S, Kuijff H, et al. Brainlesion: glioma, multiple sclerosis, stroke and traumatic brain injuries. Lecture Notes in Computer Science. Berlin: Springer, 2018;234-244.

作者简介:

李 镛 (1974—),男,博士,教授,博士生导师,主要从事医学图像处理、数字系统与微系统设计方面的研究。