

DOI:10.16136/j.joel.2022.11.0021

融合多层级特征的脑肿瘤图像分割方法

孙劲光, 陈倩*

(辽宁工程技术大学 电子与信息工程学院, 辽宁 葫芦岛 125105)

摘要:针对脑肿瘤图像分割中网络模型信息损耗、上下文信息联系不足及网络泛化能力较差导致分割精度较低的问题,提出了一种新型的脑肿瘤图像分割方法,该方法是通过深度门控卷积模块(depth gate convolution, DGC)和特征增强模块(feature enhancement module, FEM)组成的多层次连接(multi-level connection, MC)脑肿瘤分割模型。采用深度卷积模块降低特征信息在逐层传递的信息损耗;使用控制门单元(control gate unit, CGU)实现各个尺度的特征图的MC,其中组合池化来减少下采样过程中的信息丢失;通过FEM增强分割区域的特征权重。实验结果表明,预测分割脑肿瘤的整体肿瘤区(whole tumor, WT)、核心肿瘤区(tumor core, TC)和增强肿瘤区(en-hancement tumor, ET)的Dice系数分别达到了0.92、0.84和0.83,Hausdorff距离达到了0.77、1.50和0.92,脑肿瘤分割精度相较于当前较多方法分割精度和计算效率较高,具有良好的分割性能。

关键词:脑肿瘤分割;门控机制;多层次连接(MC);组合池化;U-Net**中图分类号:**TP391 **文献标识码:**A **文章编号:**1005-0086(2022)11-1215-10

Brain tumor image segmentation method based on multi-level features

SUN Jinguang, CHEN Qian*

(School of Electronic and Information Engineering, Liaoning Technical University, Huludao, Liaoning 125105, China)

Abstract: Aiming at the problems of low segmentation accuracy caused by the loss of network model information, insufficient context information and poor network generalization ability in brain tumor image segmentation, a new brain tumor image segmentation method is proposed. This method is a multi-level connected (MC) brain tumor segmentation model composed of depth gate convolution module (DGC) and feature enhancement module (FEM). The depth convolution module is used to reduce the information loss of feature information transmitted layer by layer. The control gate unit (CGU) is used to realize the MC of each scale feature map, in which the combination pooling is used to reduce the information loss in the down sampling process. The feature weight of the segmented region is enhanced by the FEM. The experimental results show that the Dice index of the whole tumor area (WT), tumor core area (TC) and enhanced tumor area (ET) predicted and segmented brain tumors reaches 0.92, 0.84 and 0.83 respectively, and the Hausdorff distance reaches 0.77, 1.50 and 0.92. Compared with many current methods, the segmentation accuracy and calculation efficiency of brain tumors are higher, and have good segmentation performance.

Key words: brain tumor segmentation; gating mechanism; multi-level connection (MC); combined pooling; U-Net

* E-mail: 2922467426@qq.com

收稿日期:2022-01-11 修订日期:2022-02-28

基金项目:国家重点研发计划项目(2018YFB1403303)资助项目

1 引言

脑肿瘤作为严重威胁人类健康的疾病之一,近几年发病率逐渐上升,给人们带来了恐慌。为防止肿瘤恶性发展,早期的医疗诊断以及相应的治疗方案至关重要。当前医学影像技术进步迅速,其中核磁共振成像(magnetic resonance imaging,MRI)通过产生高分辨率的脑部影像,对脑部肿瘤进行鉴别,在辅助医疗诊断与临床治疗^[1]的信息采集中发挥着重要作用。成像后医生会结合每个病例图像的Flair、T1、T1ce和T2 4个模态进行诊断^[2]。由于脑肿瘤的形状、位置、大小和边缘边界存在较多不确定因素,所以目前在脑肿瘤诊断中,肿瘤鉴别和分割工作主要是由临床专家手动进行标注^[3]分割,效率较低,另外不同的专家对脑肿瘤的认知具有差异性,分割精度难以得到保障。因此脑肿瘤的自动分割技术对当今医疗界疾病的诊断显得尤为重要。

传统的图像分割方法包括基于阈值^[4]、边缘^[5]和区域^[6]的图像分割技术,近年来兴起的基于深度学习的分割方式很大程度上提升了图像的分割精度。对于医学图像具有多种成像类型和多种分割方法,ZHANG等^[7]使用全连接网络(fully convolutional networks,FCN)对MRI图像脑肿瘤分割区域进行训练,得到了更精确的结果;U-Net是用于医学图像的经典分割算法,RONNEBERGER等^[8]通过含有跳跃连接的编码—解码的网络结构,有效地提升了分割精度;ZHOU等^[9]在U-Net基础上引入了多个解码器(decoder,DC),并在多个DC间增加了跳跃连接,分割精度有了进一步的提高;ZHOU等^[10]利用多任务网络将多子结构

分割问题集成到同一个网络,并通过学习的方式逐次实现多任务分支的训练。针对多模态MRI图像分割问题,DOLZ等^[11]在经典的编码—解码结构中引入了多个编码器(encoder,EC),并在多个EC间引入了超密集连接;LI等^[12]则使用了注意力机制来增强不同分支的多阶段融合,融合多模态信息提高了分割精度。

当前研究在分割脑肿瘤MRI图像时,肿瘤的边缘复杂度较高,位置不确定,在分割过程中仍有局部信息损失、冗余信息较多的情况,影响了分割精度。在上下文信息联系方面,对分割精度也有较大影响。本文提出了一种新型分割模型,通过多层次连接(multi-level connection, MC)的方式下,加强了上下文信息联系,深度门控卷积模块(depth gate convolution, DGC)降低了网络传递过程中特征信息的损耗与丢失,通过特征增强模块(feature enhancement module, FEM)增强分割特征权重,其中残差连接、注意力机制与组合池化,抑制信息损失和冗余信息的产生,加快模型的高效学习与收敛,提高模型的分割精度与性能。

2 脑肿瘤图像分割模型

2.1 整体网络结构

为了提高脑肿瘤医学图像的分割精度,本文基于U-Net模型进行了改进,提出了一种新型的脑肿瘤MRI图像分割方法。分割网络结构如图1所示。网络基于U-Net++进行了改进,改变了原有的EC和DC之间密集跳跃连接以及子DC之间的内部连接,通过控制门单元(control gate unit, CGU)将网络EC和DC的特征图进行尺度转换与融合连接,进而有助于捕获各个尺度下粗粒度和细粒度语义信息。

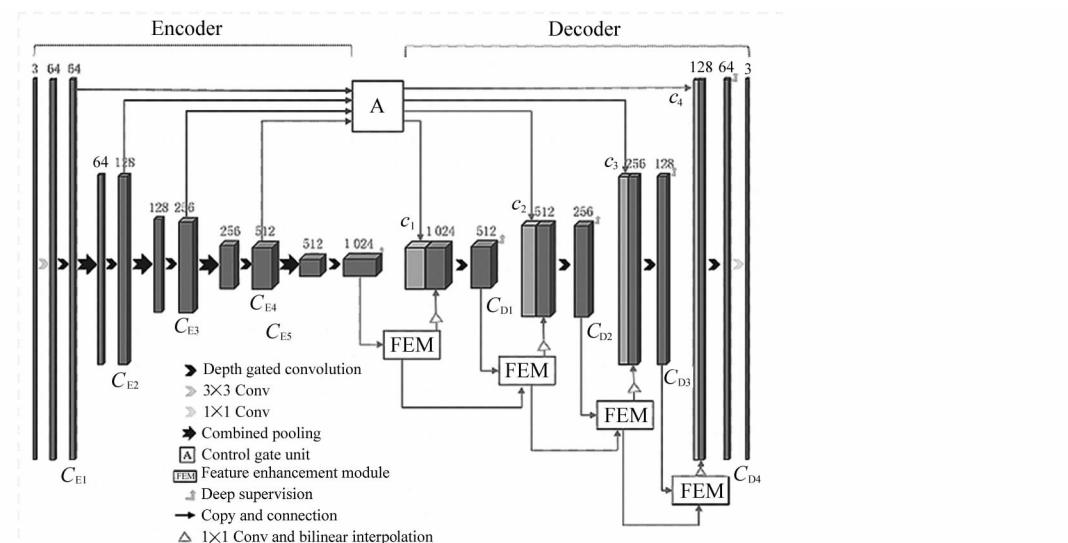


图1 整体网络结构示意图

Fig. 1 Schematic diagram of the overall network structure

网络主要由 EC、DC、MC 和 FEM 4 个部分组成。

网络模型 EC 部分主要包含了 DGC 和组合池化模块(combined pooling module, CPM)。通过 DGC 所包含的卷积层、全局池化层、全连接层和激活层实现特征的提取;CPM 为平均池化(average pooling, AP)和最大池化(max pooling, MP)的组合池化,用以实现对特征的降维操作。网络模型的 CGU 控制 DC 与 EC 的外部连接和 DC 的内部连接实现全尺度连接,即 DC 连接 EC 的同一行和上层每行的所有输出特征以及 DC 的下层每行的输出特征,结合来自 DC 的高级语义特征图和来自 EC 的相应尺度的低级语义特征图,实现了全面捕获各个尺度的语义特征信息。

网络模型 DC 部分包含 DGC、FEM 和上采样层,用以将得到的高级语义特征图恢复至原始图像的大小,其中 DGC 操作与 EC 部分相同。监督模块用于监督 DC 部分每一层的输出,在模型训练过程中,DC 部分某一层输出的特征图验证结果足够好时,通过监督模块实现对网络模型的修剪以及模型参数的大幅度缩减。

2.2 深度门控卷积

在 U-Net 特征提取过程中采用的是传统卷积操作,会导致特征信息在逐层传递过程中信息耗损,针对该问题,本文根据混合注意力机制、门控机制和残差连接的作用原理,提出了一种 DGC。该模块主要包括更新门和遗忘门两部分,对于输入该模块的图像(特征)首先通过 3×3 卷积操作进行特征粗提取(f_o),通过更新门和遗忘门并联,并接入残差连接,将初步卷积的输出与空间、通道域级进行特征融合,得到具有不同权重以及多尺度的特征信息。DGC 结构如图 2 所示。

在更新门设计中,采用了 3×3 卷积核不同扩张率(dilation_rate, d)的深度卷积,即 $d=1$ 和 $d=2$,得到多特征提取结果 f_{d1} 和 f_{d2} ,经过卷积压缩和全局池化操作,将所得特征与 f_{d1} 和 f_{d2} 进行残差连接,得到 F_{d1} 和 F_{d2} 。

将 F_{d1} 和 F_{d2} 通过通道连接的方式进行拼接,经过全连接操作与卷积压缩,使用 Sigmoid 函数激活,将该输出与 f_{di} ($i=1, 2$) 相乘,最后经过空间特征相加,得到尺寸为 $1 \times 1 \times C$ 的空间域级特征权重 W_{ug} 。

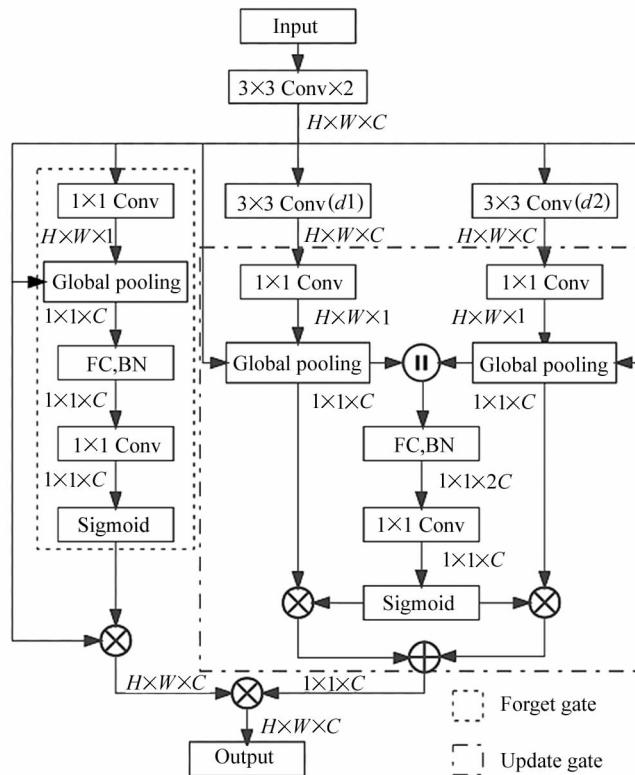


图 2 深度门控卷积结构图

Fig. 2 Structure diagram of depth gate convolution

计算式表示如下：

$$W_{ug} = (\sigma \Psi_o f_c(F_{d1}, F_{d2}) \otimes F_{d1}) \oplus (\sigma \Psi_o f_c(F_{d1}, F_{d2}) \otimes F_{d2}), \quad (1)$$

$$F_{di} = f_{di} + g_p \Psi_o f_{di}, \quad (2)$$

式中, σ 表示 Sigmoid 激活函数, Ψ_o 表示 1×1 卷积操作, f_c 表示全连接操作, \otimes 表示对应元素逐个相乘, \oplus 表示叠加操作, g_p 表示全局池化操作。

对遗忘门的设计, 将 f_o 通过卷积压缩和全局池化操作, 并将其结果与 f_o 进行残差连接, 然后依次经过全连接操作、卷积压缩和 Sigmoid 函数激活, 最后将输出特征与 f_o 相乘, 得到尺寸为 $1 \times 1 \times C$ 的通道域级特征权重 W_{fg} 。计算式表示如下:

$$W_{fg} = \sigma \Psi_o f_c(g_p \Psi_o f_o + f_o). \quad (3)$$

最后将初次卷积输出与遗忘门、更新门进行特征融合, 得到尺寸大小为 $H \times W \times C$ 的具有不同权重的输出特征。

2.3 CGU 与组合池化

为控制不同层次特征图的转化融合, 采用了 CGU 实现不同尺寸的特征图之间的 MC, 通过尺度特征管理模块 (feature structured module, FSM) 调节特征图的分辨率, 完成不同尺度特征信息的融合。在 CGU 中采用了 CPM, 即 AP 和 MP 的双池化。使用 AP 提取整体特征信息, 减少维度的同时, 更有利信息传递到下一个模块进行特征提取; 使用 MP 进行特征选择, 分类辨识度更高的特征, 对网络的计算学习提供了非线性。CGU 结构和 FSM 结构如图 3 和图 4 所示。

图中 C_i 为用于 MC 的编码部分特征图, 即连接第 i 层 DC 的特征图。CGU 的输出特征 C_i 可以用如下式表达:

$$C_i = F[P_a(C_{Ek}) \oplus P_m(C_{Ek}), s_{i-1}]_{k=1}^{N-i}, \quad (4)$$

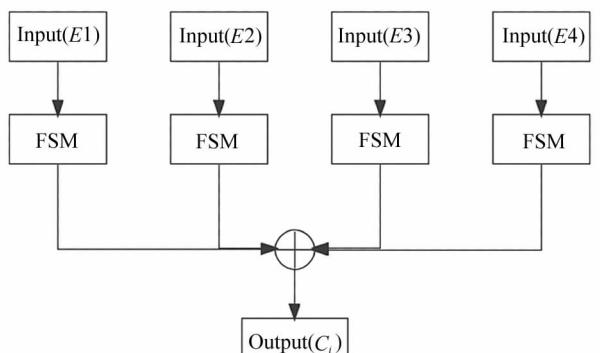


图 3 CGU 结构图

Fig. 3 Structure diagram of CGU

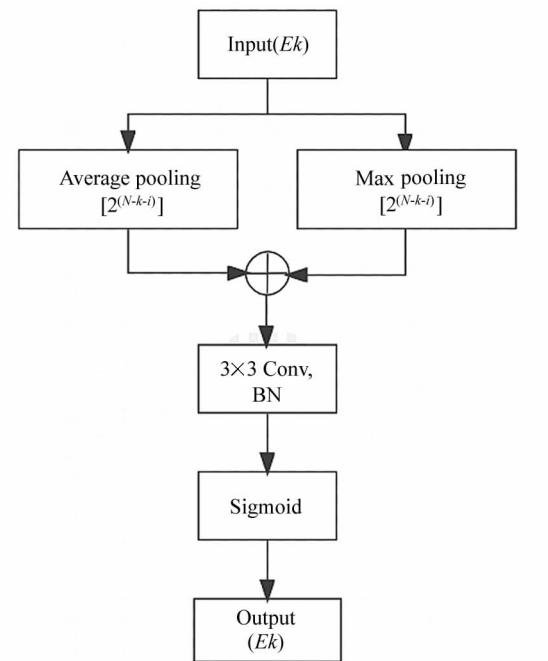


图 4 FSM 结构图

Fig. 4 Structure diagram of FSM

式中, $[,]$ 表示特征聚合操作, 包含卷积层、批标准化层 (batch normalization, BN) 和 Sigmoid 激活函数, P_a 和 P_m 分别表示 AP 和 MP。为了统一特征图的分辨率, 池化步幅 $s_i = 2^{i-k} s_o$ ($k \leq i$), s_o 为步幅初始值。

前期特征提取得到的不同尺度的特征图分别进入 AP 和 MP 层进行特征压缩, 然后将输出结果进行通道叠加, 通过步长为 1 的 3×3 卷积操作以及 Sigmoid 函数, 完成对不同尺寸的特征图的转化, 最后融合转化后的相同尺寸的特征图。

2.4 FEM

此前, SRIVASTAVA 等^[13] 和 HE 等^[14] 对深层神经网络使用跳层连接, 简化了学习过程, 增强了梯度传播和网络的泛化能力, 一定程度上减少了特征信息的丢失。为了进一步增强特征信息的完整性, 采用 FEM 通过高级特征图的语义信息加强低级特征图分割区域的特征权重, 在低级特征图中捕获更多细节信息。FEM 结构如图 5 所示。

假设输入特征 (Input) 为 x_i , 经过 FEM 可用如下式表达说明:

$$y_i = \Psi_1 \delta x_i \oplus \gamma_i, \quad (5)$$

式中, i 为像素空间大小, x_i 表示对输入特征图的直接映射, γ_i 表示输入特征经过增强后的残差映射, Ψ 表示卷积操作, δ 表示 ReLu 激活函数^[15], y_i 表示通

过 FEM 的输出特征图(Output)。 γ_i 的计算式为:

$$\gamma_i = \beta_i \otimes t_i = \beta_i \otimes \Psi_1^2 \delta x_i, \quad (6)$$

式中, β_i 表示网络学习到的特征参数, 取值范围为 $[0, 1]$, 用以突出目标分割区域和抑制无关信息, t_i 和 s_i 为输入特征图 x_i 经过两层卷积后的特征图, 即 $t_i = s_i = \Psi_1^2 x_i + b$ 。

$$\beta_i = \sigma(\Psi_2^T \delta(\Psi_2^T s_i \oplus \alpha_i) + b_1), \quad (7)$$

$$\alpha_i = \Psi_2^T \delta g_i(s_i) + b_2, \quad (8)$$

式中, α_i 为中间输出特征, g_i 表示全局最大池化操作, b, b_1 和 b_2 表示偏移项, T 表示转置操作。通过残差跳层连接与加性注意力操作增强网络梯度传播, 集中目标分割区域, 抑制非目标区域信息, 提升了网络的学习能力和分割精度。

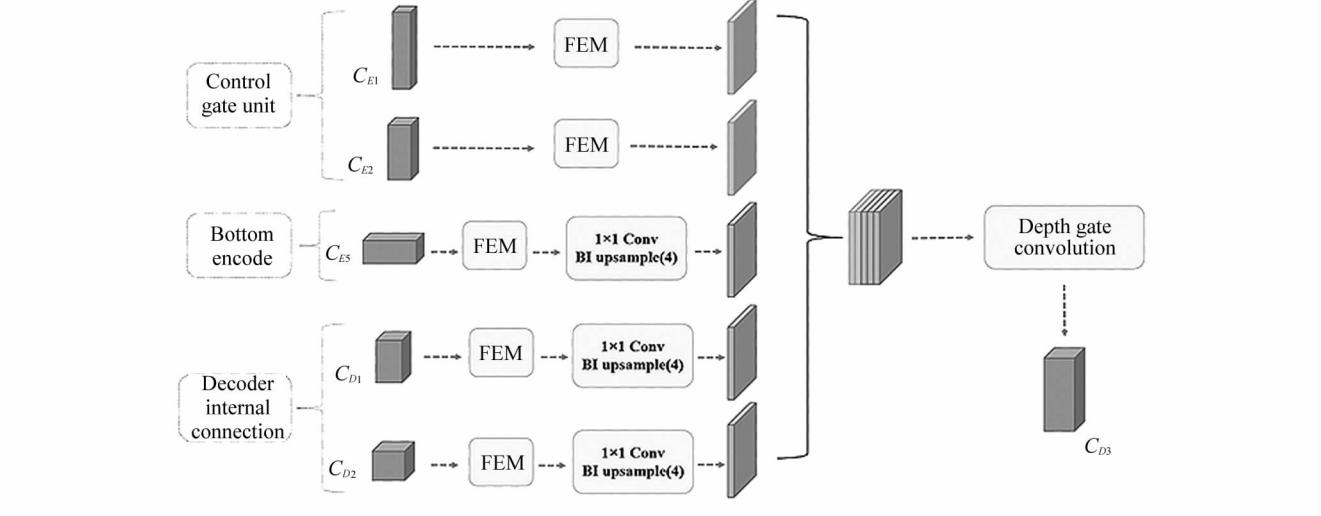


图 6 特征图 C_{D3} 的构造示意图

Fig. 6 Schematic diagram of the structure of the feature map C_{D3}

进一步提高。图 6 说明了多层次跳跃连接方式下 C_{D3} 的构造过程。

假设 EC 的层数为 N 层, 第 i 层 DC 的输出特征为 C_{Di} , EC 通过 CGU 用于连接 DC 的输出特征为 C_i , 第 N 层 EC 的输出特征与 DC 之间的内部连接结果为 \bar{C}_i , 则第 i 层 DC 的输出特征 C_{Di} 可表示为:

$$C_{Di} = f_{fsm}[F(C_i, \bar{C}_i)], \quad (9)$$

式中, f_{fsm} 表示 DGC 的计算, F 表示通道维度的拼接融合, 第 N 层 EC 的输出特征与 DC 之间的内部连接 C_i 由如下式表达:

$$\bar{C}_i = f_{fem}\left[B_{r_{i+1}}[\Psi_o(C_{EN})], B_{r_j}[\Psi_o(C_{Ek})]\right]^{i-1}, \quad (10)$$

式中, f_{fem} 表示 FEM 的计算, Ψ_o 表示上采样中的 1×1 卷积层, B_r 为双线性插值(bilinear interpolation, BI)计算, 用于缩放特征图的分辨率, 其中 $r_i =$

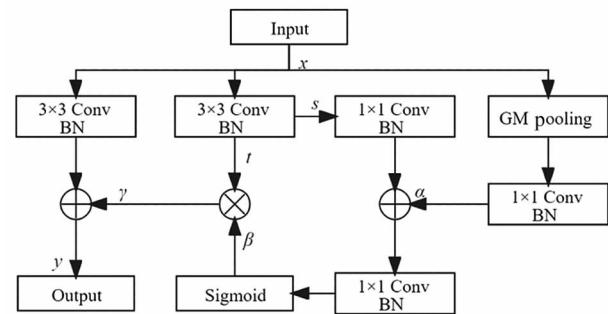
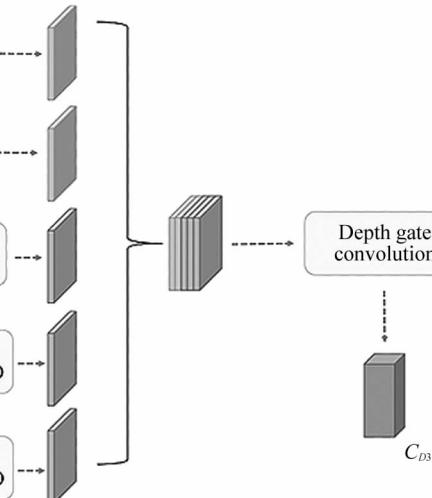


图 5 FEM 结构图

Fig. 5 Structure diagram of FEM

2.5 MC

MC 融合了各个尺度的特征, 实现了分割精度的



2^{i-k} ($k \leq i$) 是上采样层通过 BI 法对特征图的放大倍数。

2.6 损失函数

本文损失函数采用的是多尺度结构相似性损失函数(multiscale-structural similarity index, MS-SSIM)、交叉熵损失函数和 IOU(intersection over union)损失函数的混合损失函数。

$$L = 1 - \sum_{i=1}^m \left(\prod_{k=1}^m C(x_i, y_i)^{\beta_k} S(x_i, y_i)^{\gamma_k} + \sum_{j=1}^n (p_{x_{ij}} (\log p_{y_{ij}}) + \ln \frac{p_{x_{ij}} p_{y_{ij}}}{p_{x_{ij}} + p_{y_{ij}}}) \right), \quad (11)$$

$$C(x_i, y_j) = \frac{2\mu_{x_i} \mu_{x_j} + c_1}{\mu_{x_i}^2 + \mu_{x_j}^2 + c_1}, \quad (12)$$

$$S(x_i, y_j) = \frac{2\vartheta_{x_i y_j} + c_2}{\vartheta_{x_i}^2 + \vartheta_{y_j}^2 + c_2}, \quad (13)$$

式中, m 表示尺度的总数量, C 表示对比度因子, S 表

示结构对比因子, β 和 γ 表示每个尺度两类对比因子的相对重要性, μ 和 ϑ 分别表示真实图和预测图的均值和方差, c 表示维持稳定的变量, p_x 和 p_y 分别表示真实概率分布和预测概率分布。混合损失函数用于分割像素、块和图像 3 个不同层次, 通过给予图像目标分割区域模糊边界更高的权重, 可使网络增加对模糊边界的关注度, 以及对平滑梯度和对类不平衡的优化处理, 获取不同尺度目标清晰的边界, 并加快了网络的收敛速度。

3 实验结果及分析

3.1 实验平台与数据

实验平台为 Ubuntu 18.04.2 版本, 内存 32 GB, 处理器 Intel® Core™ i7-8700 K (3.70 GHz), NVIDIA GTX 1080Ti 显卡。网络结构使用 PyTorch 框架实现, 模型训练时设置的批量大小为 18, 学习率为 0.001, 训练迭代次数为 100, 优化方法为批量随机梯度下降法。

实验数据来自 MICCAI 提供的脑肿瘤公共数据集 Brats2018 和 Brats2019^[16], 数据集包含了 19 个不同机构使用不同的核磁共振扫描仪获得的 335 例病人的脑部图像, 其中包括 259 例高级别胶质瘤 (HGG), 76 例低级别胶质瘤 (LGG), 每个病例有 Flair、T1、T1ce 和 T2 4 种模态, 分割部分为整体肿瘤区 (whole tumor, WT)、肿瘤核心区 (tumor core, TC) 和增强肿瘤区 (enhancement tumor, ET) 3 个部分, 如图 7 所示为脑肿瘤病例的 4 种模态数据图。

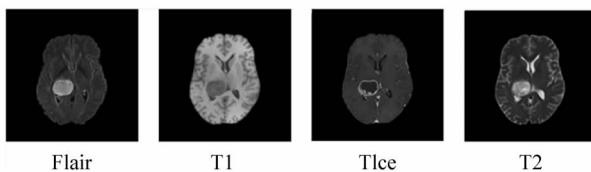


图 7 脑肿瘤实验数据图

Fig. 7 Experimental data of brain tumors

3.2 评价指标

为了评估本文提出方法的分割效果, 选取了 Dice 相似系数 (dice similarity coefficient, DSC)^[17]、IOU 重叠度、阳性预测值 (positive predictive value, PPV), 敏感度 (sensitivity) 和 Hausdorff 距离 (HD) 对实验结果进行综合评价, 计算式如下:

$$DSC = \frac{2TP}{FP + 2TP + FN}, \quad (14)$$

$$IOU = \frac{TP}{FP + TP + FN}, \quad (15)$$

$$PPV = \frac{TP}{FP + TP}, \quad (16)$$

$$Sensitivity = \frac{TP}{TP + FN}, \quad (17)$$

$$HD = \max\{d'_{XY}, d'_{YX}\} = \max\{\max_{x \in X} \min_{y \in Y} d'(x, y), \max_{y \in Y} \min_{x \in X} d'(x, y)\}, \quad (18)$$

式中, TP 和 TN 代表像素点为真阳性 (脑肿瘤) 和真阴性 (正常脑组织), FP 和 FN 代表像素点为假阳性 (错判为脑肿瘤, 实际为正常脑组织) 和假阴性 (错判为正常脑组织, 实际为脑肿瘤), X 表示真实脑肿瘤区域, Y 表示预测脑肿瘤区域, d' 表示真实值点与预测值点之间的距离。Dice 系数、IOU 重叠度、阳性预测值和敏感度用于衡量预测结果和真实结果间的相似度或重叠程度, 其指标越高, 说明模型分割效果越好, Hausdorff 距离用于计算真实的脑肿瘤分割边界和预测的脑肿瘤分割边界之间的距离, 该值越小说明预测结果与真实结果越接近, 模型分割效果越好。

3.3 模型训练

本文模型的具体训练步骤如下:

输入: 含有标签的各模态脑肿瘤图像。
输出: 预测分割出的脑肿瘤图像。

- 1) 采用 z-score 方式来对各模态脑肿瘤图像的数据标准化为零均值和单位标准差。
- 2) 对各模态脑肿瘤图像进行裁剪, 灰色部分为脑部区域, 裁剪黑色部分即背景区域。
- 3) 对各模态脑肿瘤图像进行切片, 丢弃不含病灶的切片, 组合病灶切片。
- 4) 将处理后的脑肿瘤训练图像输入本文模型, 取训练集的 15% 作为验证集, 其余 75% 作为训练集进行训练。
- 5) 根据输入和输出图像, 使用式(11)计算模型损失, 并更新模型参数。
- 6) 根据损失值可中途保存最优模型。

图 8 为本文模型在训练过程中训练集和验证集

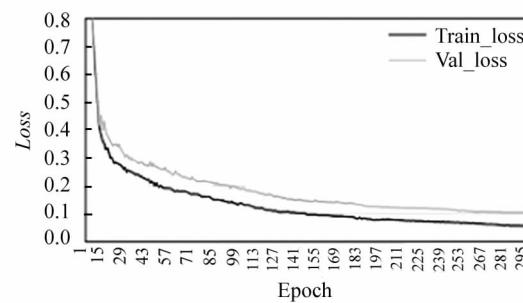


图 8 损失函数变化情况

Fig. 8 Change of loss function

的损失值随迭代次数的变化曲线图,由图可以看出,在训练过程中随着迭代次数的增加,训练集和验证集的损失值均逐渐降低,当迭代次数到 300 左右时,网络开始收敛,训练集的损失值到达 0.05 左右,验证集的损失值到达 0.10 左右,并均趋于稳定。

3.4 实验效果与分析

如图 9 所示为 7 个病例(L1—L7)的 4 种模态脑肿瘤图像实验数据图。

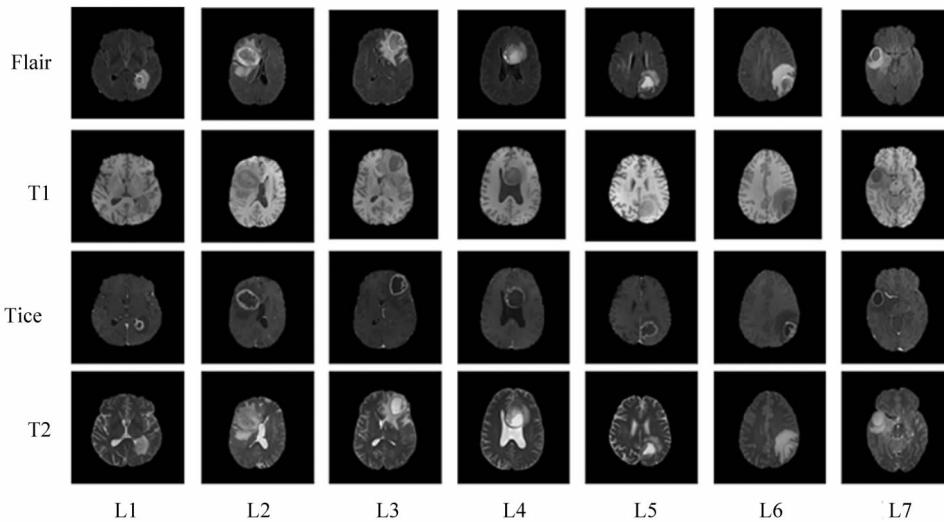


图 9 脑肿瘤实验数据图

Fig. 9 Experimental data of brain tumors

升,Hausdorff 距离较小,预测分割肿瘤图像与真实肿瘤标签相似度较高,分割边界差距较小,分割性能较好。

表 1 消融实验分割性能对比

Tab. 1 Comparison of ablation experiment segmentation performance

Method	DSC			HD		
	WT	TC	ET	WT	TC	ET
Original(Ori)	0.84	0.82	0.72	2.35	1.77	2.27
Ori+MC	0.86	0.83	0.78	1.94	1.71	1.49
...+MC+CPM	0.85	0.83	0.78	2.02	1.68	1.36
...+CPM+FEM	0.89	0.83	0.81	1.24	1.61	1.13
...+FEM+DGC	0.92	0.84	0.83	0.77	1.50	0.92

图 10 所示为原始网络加入不同组合模块后对 L2 的分割结果对比图,可以较为直观地看出:相比于原始网络,依次加入各个模块后,分割精度得到提升,分割区域信息的精确度越来越高,分割边界越来越细腻,信息损耗降低,得到了较优的分割结果。

3.4.1 消融实验

为了验证各模块的有效性,对原始网络加入不同组合模块进行训练,得到相应的分割效果,其性能评价指标如表 1 所示。通过采用 MC 方式,相比于原始网络,分割区域 Dice 相似系数得到提升,Hausdorff 距离降低;加入 CPM 后,对核心肿瘤区和增强肿瘤区的分割精度有一定的提高;加入 FEM 和采用 DGC 后,分割区域的 Dice 相似系数得到了较大的提

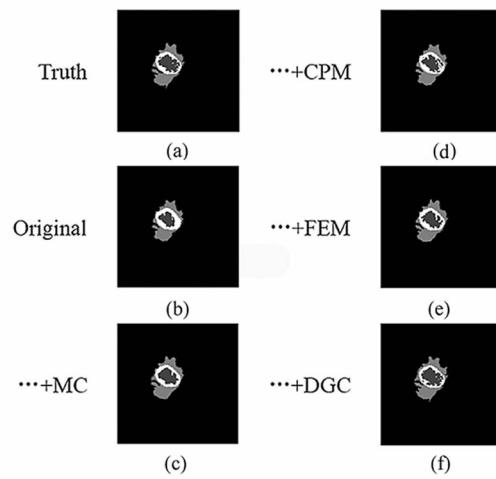


图 10 对 L2 的消融实验对比图:(a) 分割标签;

(b) 原始网络分割图;(c) 加入 MC;

(d) 加入 CPM;(e) 加入 FEM;(f) 加入改进卷积

Fig. 10 Comparison of ablation experiments on L2:

(a) Segmentation label; (b) Map of original network

segmentation; (c) Adding multi-level connections;

(d) Adding combined pooling module;

(e) Adding feature enhancement module;

(f) Adding improved convolution

3.4.2 对比实验

为了验证本文方法的分割性能,分别与 FCN、ResNet^[9]、U-Net 和 U-Net++ 4 种网络模型进行了对比实验。根据图 11 所示,FCN 可以定位肿瘤的位置,大致实现了对 WT、TC 和 ET 3 个部分的分割,但忽略了多尺度的特征融合,导致需要的分割区域出现分割不完整或分割错误的现象,分割效果较差。ResNet 对 WT 和 CT 的分割有所提升,但肿瘤边界处理较为粗糙;ET 分割准确率较低,出现过度分割现象,分割精度较低。U-Net 分割结果相对于前两种方法有了很大的提升,U-Net++ 是基于 U-Net 进行的改进,分割效果进一步提升,但在分割 WT 时,对肿瘤边界处理仍有欠缺,部分区域出现分割不完整或过度分割现象,对细小或断点区域分割错误率较高,分割效果仍然需要提升。相比之下,本文方法的分割结果与真实分割标签更为相近,对肿瘤边界的分割更为精确,大幅度提升了细小或断点区域的分割精度,具有良好的分割性能。

表 2 为 5 种模型的分割性能评估结果。由表 2

可知,本文方法采用了 MC 与 DGC,下采样联合了 MP 和 AP 的特征信息,上采样对分割特征图进一步增强,网络上下文信息联系密切,大幅度抑制冗余信息的产生,减少特征信息的损耗,在 Dice 相似系数、IOU 重叠度、阳性预测值和敏感度的评分较高,对 WT 的分割 Dice 相似系数表现超过了 0.92,对 TC 与 ET 的分割 Dice 系数同样取得了 0.84 和 0.83 的高评分,Hausdorff 距离数值较低,对 WT、TC 与 ET 的预测脑肿瘤分割的 Hausdorff 距离降至 0.77、1.50 和 0.92,真实脑肿瘤边界与预测脑肿瘤边界距离较小,预测分割结果与真实分割标签相似度较高,对脑肿瘤 3 类分割区域的分割精度均较高,在分割性能和敏感度上均优于其他 4 种方法。

表 3 为本文方法与其他作者方法的性能比较结果,本文方法对脑肿瘤 3 个分割区域的 Dice 相似系数达到 0.92、0.84 和 0.83,Hausdorff 距离达到了 0.77、1.50 和 0.92。通过对 3 个脑肿瘤分割区域的性能评价,本文方法的分割效果较好,总体分割性能优于其他方法。

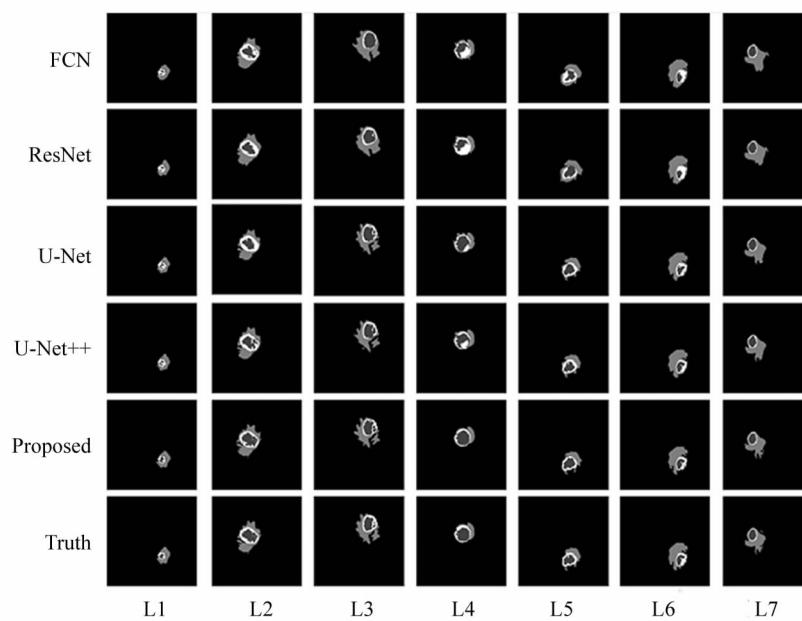


图 11 使用不同方法的脑肿瘤预测分割对比图

Fig. 11 Comparison of brain tumor prediction and segmentation using different methods

表 2 5 种模型脑肿瘤分割性能评价指标

Tab. 2 Evaluation indexes of brain tumor segmentation performance of five models

Model	DSC			IOU			PPV			Sensitivity			HD		
	WT	TC	ET	WT	TC	ET	WT	TC	ET	WT	TC	ET	WT	TC	ET
FCN	0.81	0.80	0.70	0.67	0.68	0.56	0.79	0.82	0.70	0.85	0.88	0.75	2.98	1.85	3.20
ResNet	0.84	0.81	0.76	0.72	0.67	0.63	0.84	0.85	0.76	0.86	0.88	0.80	2.76	1.79	2.90
U-Net	0.84	0.82	0.77	0.72	0.70	0.64	0.85	0.85	0.79	0.86	0.89	0.79	2.35	1.77	2.27
U-Net++	0.86	0.82	0.79	0.75	0.70	0.66	0.86	0.86	0.82	0.87	0.90	0.80	1.62	1.75	1.86
Proposed	0.92	0.84	0.83	0.84	0.76	0.72	0.91	0.87	0.91	0.90	0.91	0.81	0.77	1.50	0.92

表3 本文方法与其他方法性能比较

Tab.3 The performance comparison of this method with other methods

Method	DSC			HD		
	WT	TC	ET	WT	TC	ET
HAVAEI ^[18]	0.81	0.78	0.70	3.06	2.05	3.14
ISENSEE ^[19]	0.85	0.80	0.78	2.64	1.79	2.70
MOU ^[20]	0.88	0.84	0.80	2.52	1.51	2.66
Proposed	0.92	0.84	0.83	0.77	1.50	0.92

4 结 论

本文针对应用于医学脑肿瘤图像分割的方法计算效率和分割精度较低、冗余信息较多、特征信息损耗以及上下文联系不足等问题,提出了一种新型的脑肿瘤MRI图像分割方法。提出的方法基于U-Net使用MC和组合池化的方式,全面捕获各个尺度的特征信息,通过DGC和FEM降低特征信息损耗,抑制冗余信息产生,解决梯度消散的问题,获得更好的分割结果。通过实验结果对比,本文提出的脑肿瘤分割方法,取得了整体WT、TC和ET Dice指数为0.92、0.84和0.83的良好分割效果,在多个评价指标和分割预测效果图中均较优,模型计算效率较高,具有更高的分割精度和性能。然而本文方法也存在一定的局限性,在实际应用中,脑肿瘤MRI图像多为三维数据,且含样本标注的脑肿瘤MRI图像数据集较少,人工标注工作量较大,针对当前存在的问题可以对本文方法进一步改进,推动省时、省力和高效的脑肿瘤MRI图像分割的发展。

参考文献:

- [1] MAYER G S,VRSCAY E R. Self-similarity of fourier domain MRI data[J]. Nonlinear Analysis: Theory, Methods & Applications,2009,71(12):e855-e864.
- [2] ZHU 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.
- [3] YU W J,CHEN Z D,LUO X,et al. DELTA: a deep dual-stream network for multi-label image classification[J]. Pattern Recognition,2019,91:322-331.
- [4] SAHOO P K,SOLTANI S,WONG A K. A survey of thresholding techniques[J]. Computer Vision,Graphics, and Image Processing,1988,41(2):233-260.
- [5] ZIOU D,TABBONE S. Edge detection techniques-an overview[J]. International Journal of Pattern Recognition and Image Analysis,1998,8:537-559.
- [6] MANGIN J F,FROUIN V,BLOCH I,et al. From 3D magnetic resonance images to structural representations of the cortex topography using topology preserving deformations[J]. Journal of Mathematical imaging and Vision,1995,5(4):297-318.
- [7] ZHANG C J,FANG M C,NIE H H. Brain tumor segmentation using fully convolutional networks from magnetic resonance imaging [J]. Journal of Medical Imaging and Health Informatics,2018,8(8):1546-1553.
- [8] RONNEBERGER O,FISHER P,BROX T. U-Net: convolutional networks for biomedical image segmentation[C]// International Conference on Medical Image Computing and Computer Assisted Intervention (MICCAI), October 5-9, 2015, Munich, Germany. Cham: Springer, 2015: 234-241.
- [9] ZHOU Z,SIDDIQUEE M M R,TAJBAKHSH N,et al. A nested U-Net architecture for medical image segmentation [EB/OL].(2018-07-18)[2022-01-11]. <http://arxiv.org/abs/1807.10165>.
- [10] ZHOU C H,DING C X,LU Z T,et al. One-pass multi-task convolutional neural networks for efficient brain tumor segmentation[C]//21st International Conference on Medical Image Computing and Computer-Assisted Intervention, September 16-20, 2018, Granada, Spain. Cham: Springer,2018:637-645.
- [11] DOLZ J,GOPINATH K,YUAN J,et al. HyperDense-Net:a hyper-densely connected CNN for multi-modal image segmentation [J]. IEEE Transactions on Medical Imaging,2019,38(5):1116-1126.
- [12] LI C,SUN H,LIU Z Y,et al. Learning cross-modal deep representations for multi-modal MR image segmentation [C]//22nd International Conference on Medical Image Computing and Computer-Assisted Intervention, October 13-17, 2019, Shenzhen, China. Cham: Springer: 2019: 57-65.
- [13] SRIVASTAVA R K,GREFF K,SCHMIDHUBER J. Training very deep networks[C]//Advances in Neural Information Processing Systems, December 7-12, 2015, Montreal, Canada. New York: America Institute of Physics, 2015: 2377-2385.
- [14] HE K,ZHANG X,REN S,et al. Deep residual learning for image recognition [C]//IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las

Vegas, NV, USA. New York: IEEE, 2016: 770-778.

- [15] PETERSEN P, VOIGTLAENDER F. Optimal approximation of piecewise smooth functions using deep ReLU neural networks[J]. *Neural Networks*, 2018, 108(8): 296-330.
- [16] MENZE B, JAKAB A, BAUER S, et al. The multimodal brain tumor image segmentation benchmark (BRATS) [J]. *IEEE Transactions on Medical Imaging*, 2015, 30(10): 1993-2024.
- [17] JHA S, SON L H, KUMAR R, et al. Neutrosophic image segmentation with Dice coefficients [J]. *Measurement*, 2019, 134(11): 762-772.
- [18] HAVAEI M, DAVY A, W F D, et al. Brain tumor segmentation with deep neural networks[J]. *Medical Image Analysis*, 2017, 35: 18-31.
- [19] ISENSEE F, KICKINGERDER P, WICK W, et al. Brain tumor segmentation and radiomics survival prediction: Contribution to the BRATS 2017 challenge[C]//Brainles: International MICCAI Brainlesion Workshop, September 14, 2017, Quebec City, QC, Canada. Cham: Springer, 2017: 287-297.
- [20] MOU H W, GUO Y, QUAN X H, et al. Brain tumor image segmentation of magnetic resonance imaging based on improved u-net[J]. *Laser and Optoelectronics Progress*, 2021, 58(4): 0410022.
牟海维, 郭颖, 全星慧, 等. 基于改进 U-Net 的磁共振成像脑肿瘤图像分割[J]. 激光与光电子学进展, 2021, 58(4): 0410022.

作者简介:

陈倩 (1997—), 女, 硕士研究生, 主要从事计算机图像处理中图像识别、图像分割和目标检测方面的研究。