

陈梦雨, 郭嘉鹏, 徐国苏, 等. 基于多序列 MR 图像融合的脑肿瘤自动分割算法[J]. 智能计算机与应用, 2024, 14(8): 121-128. DOI:10.20169/j.issn.2095-2163.240820

# 基于多序列 MR 图像融合的脑肿瘤自动分割算法

陈梦雨, 郭嘉鹏, 徐国苏, 李敏, 朱珊, 朱红

(徐州医科大学 医学信息与工程学院, 江苏 徐州 221000)

**摘要:** 准确、高效的脑肿瘤分割, 对脑肿瘤的精准诊断具有重要意义。由于脑肿瘤 MR 图像存在对比度低、易出现噪声、偏移场和容积效应等问题, 现有脑肿瘤分割模型的分割精度较低。为了提高脑肿瘤分割精度, 提出了基于双通道全卷积神经网络和条件随机场的多序列 MR 图像融合的脑肿瘤分割算法。双通道全卷积神经网络可提取更丰富的图像特征, 条件随机场能克服训练过程的局部极小值和输入图片中噪声产生的不利影响。该算法在脑肿瘤分割挑战数据集 BRATS2018 中测试, 其 DSC、PPV、Sensitivity 系数均较传统分割方法有显著提高。

**关键词:** 多序列 MR 图像融合; 脑肿瘤分割; 双通道全卷积神经网络; 条件随机场

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2024)08-0121-08

## Automatic segmentation algorithm for brain tumors based on multi sequence MR image fusion

CHEN Mengyu, GUO Jiapeng, XU Guosu, LI Min, ZHU Shan, ZHU Hong

(School of Medical Information and Engineering, Xuzhou Medical University, Xuzhou 221000, Jiangsu, China)

**Abstract:** Accurate and efficient brain tumor segmentation is of great significance for the accurate diagnosis of brain tumors. Due to the low contrast, susceptibility to noise, offset field, and volume effects in brain tumor MR images, the segmentation accuracy of existing brain tumor segmentation models is relatively low. In order to improve the accuracy of brain tumor segmentation, a brain tumor segmentation algorithm based on dual channel fully convolutional neural network and conditional random field for multi sequence MR image fusion is proposed. Dual channel fully convolutional neural networks can extract richer image features, and conditional random fields can overcome the adverse effects of local minima during training and noise in input images. This algorithm was tested on the BRATS2018 brain tumor segmentation challenge dataset and showed significant improvements in DSC, PPV, and Sensitivity coefficients compared to traditional segmentation methods.

**Key words:** multi sequence MR image fusion; brain tumor segmentation; dual channel fully convolutional neural network; conditional random field

## 0 引言

脑肿瘤致死率、致残率极高, 严重威胁人类的健康, 而医生拟定的精准治疗方案以精确的脑肿瘤分割为前提<sup>[1]</sup>。因此, 精准的脑肿瘤分割是脑肿瘤诊疗的关键。目前, 脑肿瘤的分割主要依靠脑科学专家的主观经验, 但由于不同医师的技能、知识和临床经验不同, 脑肿瘤分割结果多样且耗时<sup>[2]</sup>。因此,

如何正确、有效、自动化地进行脑肿瘤分割, 是一个重要的研究目标。

脑磁共振(MR)图像在医学诊断中扮演着至关重要的角色, 尤其是在脑肿瘤的检测与分割方面<sup>[3]</sup>。然而, 这些图像常常受到噪声、偏移场和容积效应等问题的干扰, 导致以往的机器学习算法对脑肿瘤提取与分割的准确率较低。由于多序列 MR 图像是通过融合多种序列的 MR 图像, 对其不同种

**基金项目:** 江苏省高等学校大学生创新创业训练计划项目(202010313018Z)。

**作者简介:** 陈梦雨(1999-), 女, 学士, 主要研究方向: 智能医学图像处理; 郭嘉鹏(2001-), 男, 本科生, 主要研究方向: 智能医学图像处理; 徐国苏(2002-), 男, 本科生, 主要研究方向: 智能医学图像处理; 李敏(1999-), 女, 学士, 主要研究方向: 智能医学图像处理; 朱珊(1999-), 女, 学士, 主要研究方向: 智能医学图像处理。

**通讯作者:** 朱红(1970-), 女, 博士, 教授, 主要研究方向: 智能医学图像处理。Email: zhuhong@xzhmu.edu.cn

收稿日期: 2024-01-23

序列的 MR 图像进行融合,则可使脑肿瘤 MR 图像的特征更全面更丰富<sup>[4]</sup>,从而可以提高脑肿瘤的分割精度,有助于医师更好的进行判断。

传统的图像分割方法包括基于区域的图像分割方法<sup>[5]</sup>、基于阈值的图像分割方法<sup>[6]</sup>、基于边缘检测的图像分割方法<sup>[7]</sup>、基于深度学习的图像分割方法<sup>[8]</sup>等等。其中,基于深度学习的图像分割方法包括卷积神经网络、循环神经网络等。这些方法虽然可以通过训练数据,自动更新相关参数以提升分割精度,但在处理医学图像时,尤其是涉及脑肿瘤的 MR 图像,经常面临诸多挑战,这些图像往往显示出较低的对比度,使得不同软组织之间的界限,或者软组织与病灶之间的分界线变得模糊不清。脑肿瘤因其大小、外观各异,可能出现在大脑的任何位置,其组织与周围的白质、灰质及其他脑组织之间存在相似的灰质特征,这使得区分变得复杂。同时,微细血管和神经系统的复杂结构和形态分布,以及组织间特征的可变性较大,也增加了脑肿瘤识别的难度。此外,传统的卷积神经网络在处理 MR 脑肿瘤图像时,受限于卷积核的尺寸尤其是 MR(磁共振)脑肿瘤图像,往往难以捕获全局信息。同时,CNN 中的卷积和池化操作在降低图像分辨率的同时,也可能导致网络浅层的一些重要信息丢失。这些信息对于精确分割脑肿瘤等细微结构至关重要,进而影响到脑肿瘤分割的准确性。

针对上述问题,本文设计了一种基于双通道全卷积神经网络(Two-channel Full Convolution Neural Network, TFCNN)和条件随机场(Conditional Random Field, CRF)的多序列 MR 图像融合的脑肿瘤分割算法,用来完成多序列 MR 图像融合的脑部肿瘤的全自动分割任务。由于训练过程的局部极小值和输入图片中的噪声会导致分割结果较差,为了优化结果,本文将条件随机场嵌入双通道全卷积神经网络来进行优化和平滑化。

## 1 脑肿瘤自动分割算法

本文提出的脑肿瘤自动分割算法包括多序列 MR 图像预处理阶段、训练阶段、归类阶段、分割等阶段。通常的脑肿瘤 MRI 序列有 4 种成像序列:液体抑制的反转恢复(FLAIR)序列、T1 增强序列图像(T1C)、T2 权重序列图像、T1 权重序列图像<sup>[9]</sup>。预处理的方式主要有图像配准<sup>[10]</sup>、图像融合<sup>[11]</sup>以及图像对比增强等。

训练阶段是将预处理后的多序列 MR 图像分为

两部分,一部分用于训练局部通道,另一部分则用于训练全局通道。通过双通道全卷积神经网络(TFCNN)模型,分别对这两种通道的数据进行独立训练,以充分捕捉脑肿瘤图像的局部和全局特征,利用 Softmax<sup>[12]</sup>对训练过程提取到的特征信息进行分类,再将专家标记的 MR 脑肿瘤图像的标签和训练好的数据放入 CRF 模型中。

归类阶段利用高斯滤波器进行滤波,对 CRF 的输入数据分配权重进行相乘并相加求和,得到相应数值,利用 Gibbs 能量函数求取势能量,即像素归为某个标签的概率。最终将测试数据集应用到已经训练完成的模型中,以便对包含多个序列的脑肿瘤磁共振成像(MR)图像执行精确的分割操作。

## 2 基于 TFCNN 和 CRF 的脑肿瘤图像分割方法

将预处理后的多序列 MR 图像数据作为输入数据,利用 TFCNN 模型分别训练局部通道数据和全局通道数据,最后利用 softmax 对训练过程提取到的特征信息进行分类,输入图片中的噪声和训练时产生的局部极小值有可能导致预测结果较差。为了优化结果,也为了获得更好地分割效果,特在 TFCNN 模型后利用全连接条件随机场(CRF)进行平滑化和优化。

### 2.1 全卷积神经网络 FCN

2015 年,UC Berkeley 的 Jonathan Long 等<sup>[13]</sup>提出了 Fully Convolutional Networks (FCN)用于图像的分割,其解决的一个核心问题便是进行图像像素级别的分类。

FCN 的网络架构如图 1 所示,主要包含全卷积和反卷积两部分。全卷积部分借鉴了一部分经典的卷积神经网络的网络架构,经典的卷积神经网络结构最后一般是全连接层,而 FCN 把全连接层部分的结构改成继续卷积的结构,通常是  $1 * 1$  的卷积。增加卷积部分主要是为了使提取特征更加容易,从而形成热点图。反卷积部分把尺寸较小的热点图利用双线性插值法上采样,即可获得原来大小的分割图像。

### 2.2 TFCNN 网络模型架构

通过改变卷积网络的卷积核尺寸,即可获得不一样的图像信息。如果增加卷积核的大小,即可得到图像更多的信息,用这种方式获得的信息被称之为全局信息<sup>[14]</sup>。由于传统的卷积神经网络的卷积核大小有一定限制,其只能获取到图像的局部信息。为了既可以获得图像的全局信息,又可以获得图像

的局部信息,本文在全卷积神经网络的基础上做出了改进,提出一种双通道全卷积神经网络(TFCNN)<sup>[15]</sup>,网络架构图如图 2 所示。将全局信息与局部信息连结在一起,即可获得更加丰富的图像

特征<sup>[16]</sup>。TFCNN 网络架构图中具有两种信息获取的通路,包含获取局部信息的通路和提取全局信息的通路。

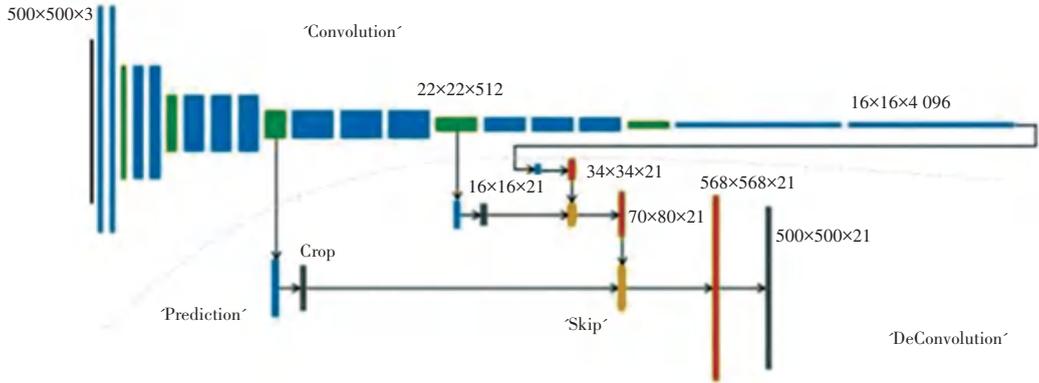


图 1 FCN 网络结构

Fig. 1 FCN network structure

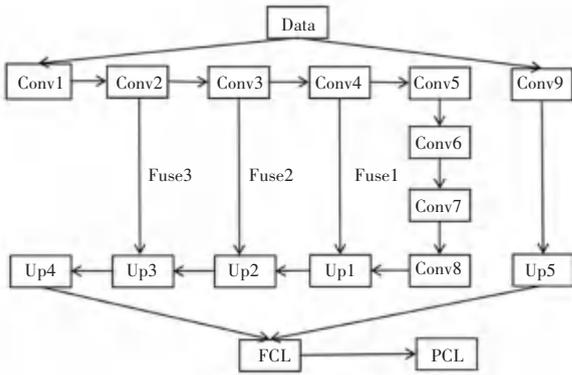


图 2 TFCNN 网络架构

Fig. 2 TFCNN network architecture

由 TFCNN 网络架构图可见,Data 分为两个信息获取通路,即获取局部信息的通路和提取全局信息的通路。Conv1 到 Conv8 为获取局部信息的通道,每一个 Conv 中都具备池化层、卷积层、激活函数层。与此同时,本文方法在每一个卷积层后都加入了批量正则化(Batch Normalization, BN)层,从而使网络训练时间简短,网络训练加快,模型的训练结果更好。其中图像的边缘、位置等信息都可通过卷积层获得;池化层通过对提取的特征进行降维操作,来保存卷积层中获得的特征信息。本文所采用的网络架构通过不同池化层得到不同特征信息,从而使特征信息的多级融合(Fuse)实现<sup>[17]</sup>。第一次上采样是在 Conv8 卷积层的输出之后,上采样的主要功能是增大特征矩阵,其主要通过反卷积的方法。第一次采样(Up1)所得的特征向量矩阵与 Conv4 中第四次池化所得的特征向量矩阵进行第一次融合;第二次对 Up2 所得的特征向量矩阵与 Conv3 中第 3 次池

化所得的特征向量矩阵进行融合;再对 Up3 所得的特征向量矩阵与 Conv2 中第三次池化所得的特征向量矩阵进行融合,此局部信息通道一共进行三轮融合,将最后得出的特征矩阵进行第四次采样,从而输出与原图相同尺寸的图像。在获取局部信息的通路中,通常会使用较小的卷积核(即 3 \* 3),这对应于较小的感受野从而专注于图像的局部特征。

全局通道一般使用 9 \* 9 像素的卷积核,因此全局信息提取通道对应相较于局部信息提取通道更大的感受野,更大的感受野即可使其获取更加丰富的图像特征信息,也可称为全局信息。获取全局信息的通路 Data 直接进入 Conv9,与局部信息提取通道相同,Conv 中也具备卷积层、池化层、激活函数层。而与局部信息提取通道不同的是,在全局通道中 Conv9 卷积后直接进行上采样(Up5),即可获得与原图尺寸一致的图像。

全局信息提取通道与局部信息提取通道都可获得与原图尺寸大小一致的图像,这样可以使得从局部通道和全局通道中提取到的特征信息全都传递到全连接层(FCL)。在分类层(PCL)中,为了对其进行多分类,使用非线性函数 Softmax,得到输出属于各个类别的概率。本模型共输出 5 种结果,分别是通过模型输入图像各个像素属于这 5 种的概率,最终选取概率最大所对应的种类作为该图像像素点的种类。该模型可分割出背景(健康组织)、坏死、水肿、增强肿瘤与非增强肿瘤这 5 种结果。

### 2.3 嵌入条件随机场的 TFCNN 模型

本文使用 Kamnitsa 等<sup>[18]</sup>提出的全连接条件随

机场(CRF)嵌入双通道全卷积神经网络模型中,用来消除训练过程中的局部最小导致的假性输出,以及使噪声消减。为处理与分析3D图像,一般采用两个高斯核,CRF模型可以建立在任意大小的三维像素邻域集。

本文主要考虑条件随机场( $I, X$ )的情况,其中 $I$ 表示输入图片数据, $X$ 表示标签。目标就是求 $X$ ,使得后验概率(见公式(1))最大,使用的Gibbs能量函数如下:

$$P(X|I) = \exp(-E(X|I)) \quad (1)$$

$$E(z) = \sum_i \varphi_u(z_i) + \sum_{i,j,i \neq j} \varphi_p(z_i, z_j) \quad (2)$$

其中,  $\varphi_u(z_i) = -\log P(z_i | I)$ , 标签融合函数  $\varphi_p(z_i, z_j) = \mu(z_i, z_j)k(z_i, z_j)$ ,  $\mu(z_i, z_j) = [z_i \neq z_j]$ , 其惩罚附近的被给予不同标签的相似体素。在全连接的情况下,其惩罚所有不同标签的体素。这里的核函数使用线性Gauss核函数:

$$k(f_i, f_j) = \sum_{m=1}^M \omega^{(m)} k^{(m)}(f_i, f_j) \quad (3)$$

本文采用两个高斯核<sup>[19]</sup>: Smoothness kernel 和 Appearance kernel。其中, Smoothness kernel 的函数式如公式(4)所示, Appearance kernel 的函数式如公式(5)所示。

$$k^{(1)}(f_i, f_j) = \exp\left(-\sum_{d=x,y,z} \frac{|p_{i,d} - p_{j,d}|^2}{2\sigma_{a,d}^2}\right) \quad (4)$$

Smoothness kernel 是用对角协方差矩阵定义的,其中  $p_{i,d}$  是体素的坐标。参数  $\sigma_{a,d}$  对应于每个坐标轴,表示周围鼓励相同标签的尺寸与程度。

从定义式中可见,如果不同标签的体素离得越远,后验概率就越大,离得越近,后验概率越小,这与实际相符,因为大部分区域靠的近的一般是同一类。

$$k^{(2)}(f_i, f_j) = \exp\left(-\sum_{d=x,y,z} \frac{|p_{i,d} - p_{j,d}|^2}{2\sigma_{\beta,d}^2} - \sum_{c=1}^C \frac{|I_{i,c} - I_{j,c}|^2}{2\sigma_{\gamma,c}^2}\right) \quad (5)$$

这样定义的原因是观察到一般附件的有相似颜色的体素很有可能是同一类,注意这里的  $I_i$  表示颜色特征,也就是输入图面的每个体素的特征向量。最后,代表两个因子的相对重要性。注意,这里所有的参数都是通过 configuration 实验(通过随机搜索)学习出来的。

CRF 配置:对于多分类问题来说,需要为 CRF 找到一组可以持续改进的全局参数,用于所有类的分割。因此,需要将每个类别预测的概率图合并成

一个“全肿瘤”图,用于 CRF 后处理。这个 CRF 除了会细化肿瘤和背景之间的界限,还可以消除孤立的假阳性。

### 3 实验结果与分析

#### 3.1 数据集

实验采用 BRATS 2018 数据集。BRATS 数据集是脑肿瘤分割比赛数据集, BRATS 2018 中的训练集(Training set)有 285 个病例,其中包含 210 例 HGG 病例, HGG 即高级别的胶质瘤(WHO3~4级), 75 例 LGG 病例, LGG 是低级别的胶质瘤(WHO1~2级), 每个病例有 4 个模态(T1、T2、FLAIR、T1C), 需要分割 3 个部分: Whole Tumor(WT), Enhance Tumor(ET), and Tumor Core(TC)。T1、T2、FLAIR、T1C 可以理解为核磁共振图像的 4 个不同纬度信息, 每个序列的图像 Shape 为(155, 240, 240)。最终结果会参考专家给出的手动分割结果。分割完毕后的数据集以 nii 格式存储。

#### 3.2 数据预处理

首先,对 MR 图像进行 n4ITK 偏差校正后,进行预处理操作,即对多序列 MR 图像进行配准融合、对比增强,多序列 MR 图像的配准、融合部分图像如图 3 所示。然后将 ROI 中的数据强度标准化为零均值、单位方差空间,如果强度不在该值范围内,训练效果会显著变差。

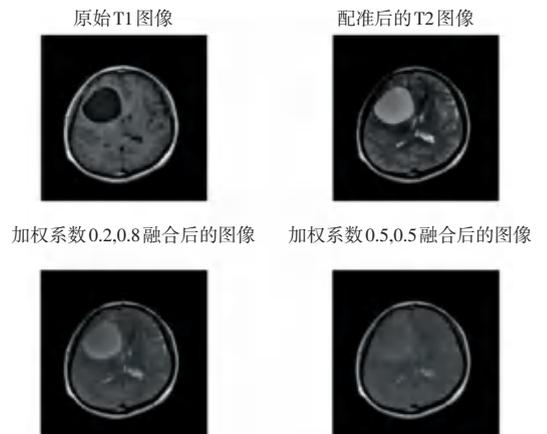


图3 多序列 MR 图像配准、融合的部分图像

Fig. 3 Partial images of multi sequence MR image registration and fusion

脑肿瘤 MR 图像的分割结果如图 4 所示。MR 图像的像素被分为 5 类,其中灰色部分表示为脑部健康脑组织,绿色部分表示为水肿,黄色部分表示为增强脑肿瘤,红色部分表示为坏死,还有一部分表示为非增强肿瘤(图中未具体标出)。数据集在完成预

处理后,即可作为 TFCNN 的模型输入,构成训练数据集。

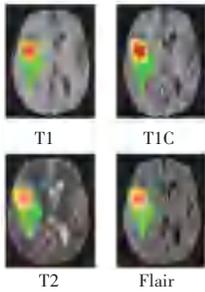


图 4 脑肿瘤 MR 图像的分割结果

Fig. 4 MR image segmentation results of brain tumor

### 3.3 模型参数设置与训练过程

#### 3.3.1 参数设置

表 1 列出了本章使用的方法中所需要的参数。将 barts2018 数据集划分为训练集和测试集,对于每个病例图像,无规则地选取 4 个切片,再从这 4 个切片中无规则地选择一些点,使其作为训练样本,其余病例图像的切片作为测试数据。由于每个类别的像素点数之间存在较大的差异,因此需要确保在每个类别的像素点中选择数量相同的训练样本。

表 1 参数配置

Table 1 Parameter Configuration

步骤	参数	参数值
预处理	图像块	33×33×4
	$\omega \times \omega \times k$	
	归一化后的向量大小	4356
	每个类别的训练样本数量	240×240×15
训练 TFCNN 模型	局部通道	1
	卷积层	8 个(33×33)
	激活函数 ReLU	8
	池化层	8 个(3×3)
	上采样	3
	卷积核	8 个(3×3)
	全局通道	1
	卷积层	2 个(33×33)
	激活函数 ReLU	2
	池化层	2 个(3×3)
	上采样	1
	卷积核	2 个(9×9)
	输出层分类器	5

#### 3.3.2 训练过程

权重衰减系数对于网络的过拟合程度具有一定影响,本文比较了不同的权重衰减系数下该网络的训练精度和准确率。从表 2 的数据可以看出,当网络中权重衰减系数太小时,对权重的衰减效果并不明显,则导致降低网络训练的准确率;而当网络中权重衰减系数太大时,网络就会导致一定的过拟合,训练的准确率有所降低。因此,本文最终选择权重衰减系数值为 0.005。

将 BRATS 2018 数据集作为模型输入来训练基于 TFCNN 和 CRF 的脑肿瘤自动分割模型,得到的 Class0~Class4 训练结果如图 5~图 9 所示。其中,Class0 表示健康组织部分,Class1 表示坏死核心部

分,Class2 表示水肿部分,Class3 表示非强化部分和 Class4 表示强化核心部分。

表 2 不同权重衰减系数下网络训练准确率

Table 2 Training accuracy of the network under different weight attenuation coefficients

权重衰减系数	训练准确率
0.000 1	0.734 8
0.000 2	0.767 2
0.000 4	0.834 9
0.000 5	0.857 9
0.000 6	0.842 6
0.001 0	0.851 3
0.002 0	0.803 8

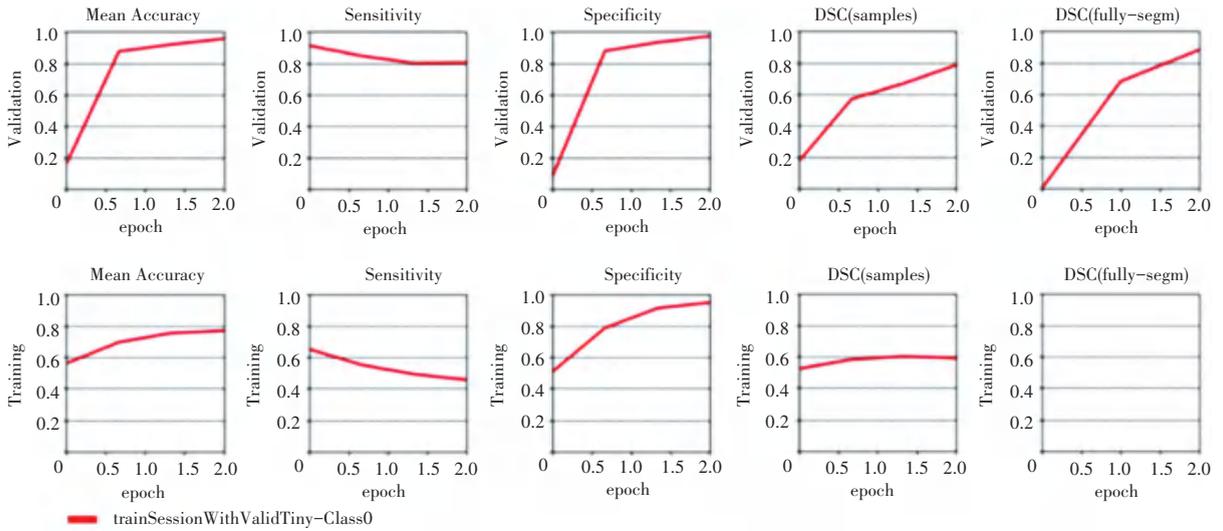


图5 Class0 的模型训练结果

Fig. 5 Model training results of Class0

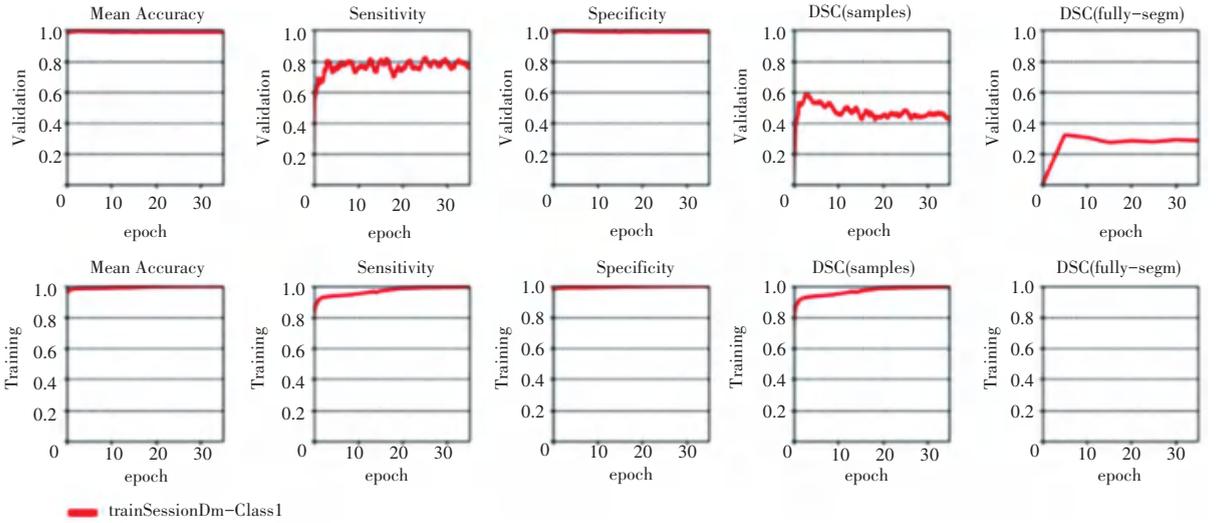


图6 Class1 的模型训练结果

Fig. 6 Model training results of Class1

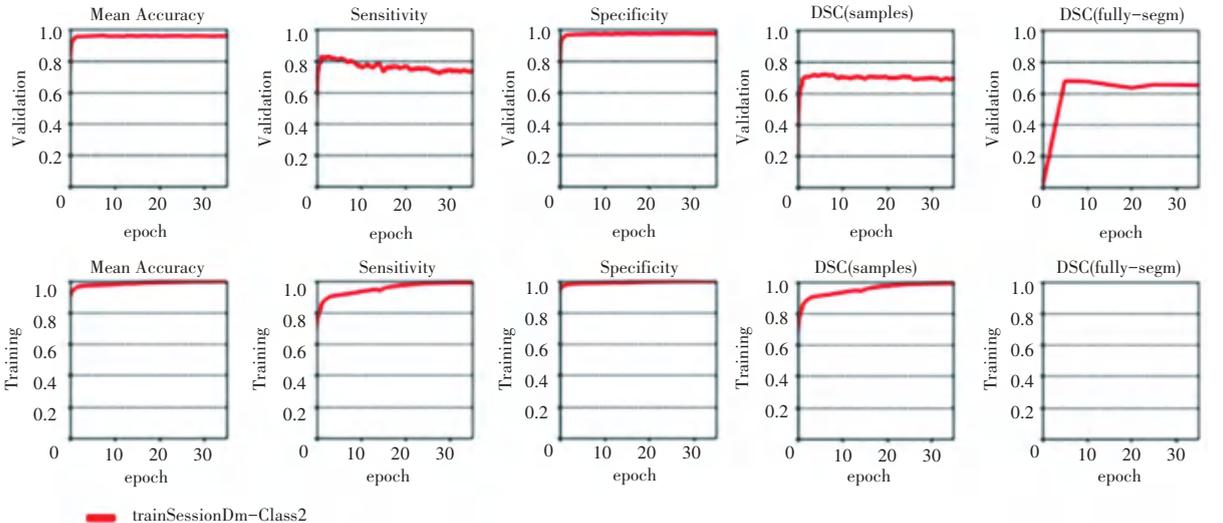


图7 Class2 的模型训练结果

Fig. 7 Model training results of Class2

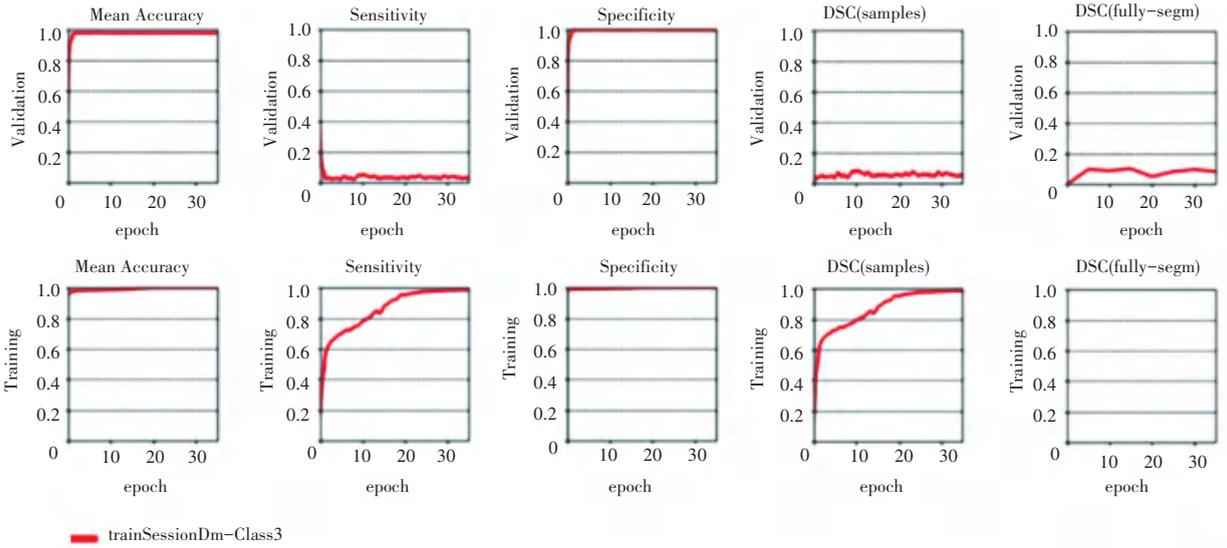


图 8 Class3 的模型训练结果

Fig. 8 Model training results of Class3

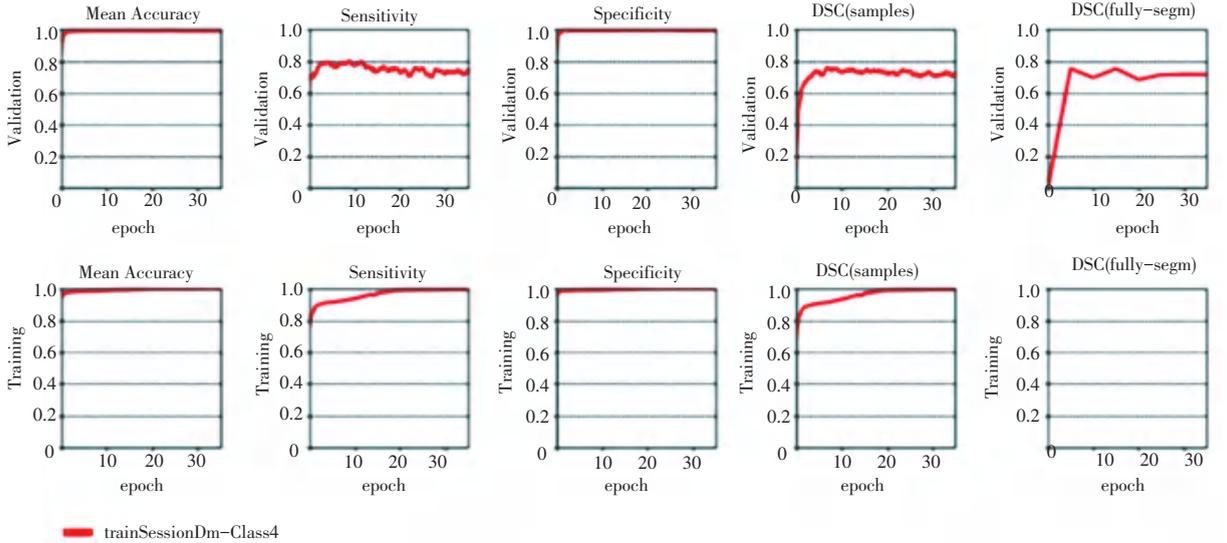


图 9 Class4 的模型训练结果

Fig. 9 Model training results of Class4

3.3.3 实验结果分析

模型经过训练后即可对模型进行测试, 经过对模型的多次测试, 并且与普通 FCN 脑肿瘤分割的相关分数对比, 其结果数据见表 3。

表 3 测试结果

Table 3 Test results

	DSC	PPV	Sensitivity
FCN	0.809	0.833	0.857
U-NET	0.830	0.821	0.862
TFCNN	0.915	0.911	0.891
TFCNN+CRF	0.934	0.922	0.901

表 3 显示了 BRATS2018 在本文模型和其他脑肿瘤分割模型的对比实验结果。结果表明, 本文使

用的基于 TFCNN 和 CRF 的脑肿瘤分割方法的 PPV 指标为 0.922, DSC 指标为 0.934, Sensitivity 指标为 0.901。对比之下, 不使用条件随机场的 TFCNN 模型的 DSC 指标为 0.915, PPV 指标为 0.911, Sensitivity 指标为 0.891。PPV、DSC 以及 Sensitivity 这 3 个指标值越高, 意味着分割结果的准确性越高。

在这几种方法中, 本文采用的基于双通道全卷积神经网络和条件随机场方法的相关评价指标明显高于其它方法, 这也验证了本文方法在 MR 脑肿瘤分割应用中的优势。

4 结束语

针对脑肿瘤 MR 图像分割, 本文通过训练卷积

神经网络,可以得到一个训练好的模型,该模型能够精确地对脑肿瘤 MR 图像进行分割,从而帮助医生诊断与治疗脑肿瘤。使用卷积神经网络对脑肿瘤进行分割是一种全自动分割方式,这种方式摆脱了人为干预,且效率较高。

本文提出基于双通道全卷积神经网络(TFCNN)和条件随机场(CRF)的脑肿瘤分割方法。利用TFCNN既能具备网络浅层信息,同时又能兼具全局信息的双通道全卷积神经网络模型完成多序列MR图像融合的脑部肿瘤的全自动分割任务。将条件随机场(CRF)嵌入TFCNN来进行优化和平滑化以消除训练过程中的局部极小值和图像噪声导致的分割结果较差问题。该方法在脑肿瘤分割挑战数据集BRATS2018中测试,其DSC指标为0.934,PPV指标为0.922,Sensitivity指标为0.901,取得了较好的脑肿瘤分割结果。

在后续的工作中,将增加BRATS 2017/BRATS 2019数据集,更深层次的对该网络模型进行测试和训练,以进一步提高脑肿瘤分割效果;同时在TFCNN和CRF的基础上增加更多不一样的信息提取通道,研究不同数量的通道是否会对分割效果产生影响。

## 参考文献

- [1] ZHANG Y, MATUSZEWSKI B J, SHARK L K. A novel medical image segmentation method using dynamic programming [C]//Proceedings of International Conference on Medical Information Visualization Biomedical Visualization. IEEE, 2007: 69-74.
- [2] 梁芳烜,杨锋,卢丽云,等. 基于卷积神经网络的脑肿瘤分割方法综述[J]. 计算机工程与应用,2021,57(7):34-43.
- [3] 龙佼松. 多模态MR图像的深度特征提取及分割方法研究[D]. 武汉:华中科技大学,2023.
- [4] 曹剑云. 基于多尺度信息的2D-3D级联网络在多序列MRI图像中的胶质瘤分割问题研究[D]. 广州:南方医科大学,2023.
- [5] 葛婷,詹天明,李勤丰,等. 基于核磁共振图像的脑肿瘤分割方法研究[J]. 南京理工大学学报,2021,45(2):179-188.
- [6] El-HAG N A, SEDIK A, BANBY G E, et al. Utilization of image interpolation and fusion in brain tumor segmentation [J]. International Journal for Numerical Methods in Biomedical Engineering, 2021, 37(8): e3449.
- [7] 杨洁洁,杨顶. 基于深度学习的语义分割综述[J]. 长江信息通信,2022,35(2):69-72.
- [8] ZHAO Yue, REN Xiaoqiang, HOU Kun, et al. Recurrent multi-fiber network for 3D MRI brain tumor segmentation [J]. Symmetry, 2021, 13(2):320.
- [9] CONTE G M, WESTON A D, VOGELSANG D C, et al. Generative adversarial networks to synthesize missing T1 and FLAIR MRI sequences for use in a multisequence brain tumor segmentation model[J]. Radiology, 2021, 299(2): 313-323.
- [10] 周勤,王远军. 基于深度学习的医学图像配准研究进展[J]. 上海理工大学学报,2021,43(5): 421-428.
- [11] 黄滢萍,李伟生. 医学图像融合方法综述[J]. 中国图象图形学报,2023,28(1):118-143.
- [12] 葛婷,牟宁,李黎. 基于softmax回归与图割法的脑肿瘤分割算法[J]. 电子学报,2017,45(3):644-649.
- [13] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2015, 39(4): 640-651.
- [14] 朱婷,王瑜,肖洪兵,等. 基于多通路CNN的多模态MRI神经胶质瘤分割[J]. 计算机应用与软件, 2018,35(4):220-226.
- [15] 张琳琳. 基于卷积神经网络的人脸表情识别研究[D]. 长春:长春工业大学,2019.
- [16] 王西虎. 基于多序列MR图像融合的脑肿瘤自动分割方法研究[D]. 镇江:江苏大学,2019.
- [17] 邢波涛,李镔,关欣. 改进的全卷积神经网络的脑肿瘤图像分割[J]. 信号处理,2018,34(8):911-922.
- [18] KAMNITSAS K, LEDIG C, NEWCOMBEV F J, et al. Efficient multi-scale 3D CNN with fully connected CRF for accurate brain lesion segmentation[J]. Medical Image Analysis, 2017, 36: 61-78.
- [19] 曾子恒. 基于高斯核函数热点图与融合信息距离的三维目标检测算法研究[D]. 南昌:南昌大学,2023.