

文章编号: 2095-2163(2022)09-0208-07

中图分类号: TP183;TP391.41

文献标志码: A

一种基于 CA-Net 的脑肿瘤磁共振图像分割算法

柯盼盼, 陈 胜, 李珂然

(上海理工大学 光电信息与计算机工程学院, 上海 200093)

摘要: 磁共振影像是脑肿瘤疾病中常用的诊断工具, 临床上的量化分析需要对影像结果进行分割得到肿瘤区域, 但手动分割十分耗时且高度依赖于医生的临床经验。为此, 本文提出一种基于深度学习的脑磁共振图像分割算法, 解决了原网络无法有效提取关键特征的问题。该算法使用改进的有限对比度自适应直方图均衡(Contrast Limited Adaptive Histogram Equalization, CHALE)算法, 对脑肿瘤磁共振影像进行图像增强后, 将结果输入 CA-Net 网络对数据集初步分割, 并将全注意力算法和 U-net 骨架结构结合(包括空间、通道和尺度注意力模块), 实现对不同尺度的空间和通道的特征转换连接。模型应用混合损失函数提高分割精度。初步分割的结果可通过后处理进一步提高精度, 得到最终的肿瘤区域。初步分割结果中, *Dice* 指标可以达到 88.40(± 0.24)%, 结合图像处理提高至 89.21(± 0.36)%, 分割精度相较于其它算法有明显提高。

关键词: 图像分割; 深度学习; CA-Net; 注意力模块; 混合损失函数; 后处理

A method of brain tumor segmentation based on CA-Net

KE Panpan, CHEN Sheng, LI Keran

(School of Optical-Electrical and Computer Engineering, University of Shanghai for Science and Technology, Shanghai 200093, China)

[Abstract] Magnetic resonance imaging is a common diagnostic tool in brain tumor diseases. Clinical quantitative analysis needs to segment the image results to obtain the tumor area, but manual segmentation is very time-consuming and highly dependent on the clinical experience of the doctor. Therefore, this paper proposes a brain magnetic resonance image segmentation algorithm based on deep learning. Firstly, the algorithm enhances the magnetic resonance image of brain tumor using improved contrast limited adaptive histogram equalization (CHALE). The obtained results are input into CA-Net network to preliminarily segment the dataset. The network combines the full attention algorithm with the U-net skeleton structure, including spatial, channel and scale attention module to realize the feature conversion and connection of different scales of the space and channels. The model uses mixed loss function to improve the segmentation accuracy. The preliminary segmentation results can further improve the accuracy through post-processing to obtain the final tumor region. In the preliminary segmentation results, the *Dice* index can reach 88.40(± 0.24)%, which can be improved to 89.21(± 0.36)% combined with image processing. The segmentation accuracy is significantly improved compared with other algorithms.

[Key words] images segmentation; deep learning; CA-Net; attention module; mixed loss function; post-processing

0 引言

脑肿瘤是大脑中异常的细胞组织, 发病率和死亡率极高。脑肿瘤的治疗取决于患者的年龄、肿瘤的类型及其位置。磁共振图像是脑肿瘤诊断中已获广泛应用的辅助工具, 通过 MR 检测可以提供肿瘤大小、形状、定位等宝贵信息。脑肿瘤的精确分割对准确评估起着不小的作用, 对治疗规划也显得尤为重要^[1]。但是, 传统的手动分割是一个复杂的项目。将每个像素细分为肿瘤内部和外部, 是一项极其艰巨和具有挑战性的任务。而对 MR 图像进行自

动分割, 可以避免许多复杂的工作, 并进一步节省划分校正时间和人工劳动成本, 对脑肿瘤早期诊断和治疗具有重要意义。

传统的图像分割方法主要有模型法、阈值算法和区域法, 通常与特征工程相结合, 实现对脑组织和肿瘤区域进行分割。李永焯等人^[2]提出了一种改进的分水岭图像分割算法。该算法先对原始梯度图像进行形态学重建, 再设定阈值标记肿瘤部分, 以分水岭标记背景部分, 最后根据标记绘制出分水岭变换的分割线, 准确区分了背景和肿瘤部分, 有效避免了误分割。针对颅脑 MR 图像的模糊特点和实际应

基金项目: 国家自然科学基金(81101116)。

作者简介: 柯盼盼(1997-), 男, 硕士研究生, 主要研究方向: 深度学习、医学影像; 陈 胜(1976-), 男, 博士, 副教授, 主要研究方向: 图像处理与分析、医学成像技术; 李珂然(1996-), 男, 硕士研究生, 主要研究方向: 医学影像。

通讯作者: 陈 胜 Email: chnshn@hotmail.com

收稿日期: 2022-03-03

用要求,柴黎等人^[3]运用阈值处理噪声干扰,对分水岭区域分割算法进行改进,从而抑制了过分割问题,并能快速、准确得到医学图像的分割结果,具有较强的抗噪声能力。宗晓萍等人^[4]利用灰度共生矩阵提取出的纹理特征,结合图像几何不变矩特征,对分割出的脑肿瘤图像进行特征提取。该方法可以同时从纹理和几何特征对图像特征进行描述,与分别采用灰度共生矩阵和不变矩方法进行特征提取相比较,不仅降低了算法计算量,同时也提升了算法的抗噪性。苗加庆^[5]提出一种字典学习降噪和分水岭算法相结合的脑 MR 医学图像分割算法。采用字典学习降低原始图像噪声,并利用形态学算法对降噪后的图像进行形态学处理,通过形态学知识提取图像边界,利用图像的几何特征,去除非目标区域,再采用分水岭变换进行图像分割。针对脑肿瘤 MR 图像的边界复杂度,传统方法往往不能精准分割其边缘区域,某些特殊的脑肿瘤 MR 影像分割效果一般,鲁棒性较差。

近年来,人工智能在医学影像领域得到快速发展,而图像分割是其中重要的组成部分。在卷积神经网络中,U-net 是最常用的图像分割模型之一,在肺部 CT 图像结节分割^[2]、超声心动图像心室分割^[6]、眼球分割^[7]、心脏 MRI 分割^[8]等医疗图像分割场景中得到了广泛应用。基于 U-net 网络骨架结构,U-net ++^[9]对编码器和解码器之间特征映射进行深层次连接,通过添加嵌套连接和 Dense 连接结构,减少其中的语义隔阂,从而更好地捕获高颗粒度的图像细节。另外,U-net++作为多分支网络,全局的 loss 由所有分支累加而成,引入了全尺寸跳跃连接,并充分利用了编码器和解码器中的多尺度信息。吴量等人^[10]将 U-net 与残差结构结合,并利用注意力模块提高网络提取关键特征层和空间区域,从而提高肿瘤的分割精度。Gu 等人^[11]通过新的空间、尺度、通道注意力模块,构建了综合注意力卷积神经网络 CA-Net,实现更准确和可解释的图像分割,并在皮肤病变分割和胎儿磁共振图像分割中取得较大提升。Lin 等人^[12]提出一种聚合注意力卷积网络 AANet,将 U-net 骨架结构与多尺度语义信息结合,利用增强的下采样和上采样层减少补偿信息丢失,进行脑胶质瘤分割。

综上所述,本文提出了一种基于 CA-Net 的脑肿瘤磁共振图像分割方法,并通过图像处理技术提高分割精度,具体流程如图 1 所示。

由图 1 可知,该方法先对图像进行 HSV 空间转换,对亮度参量进行自适应调整;利用 CLAHE 算法

实现图像增强;增强后的图像进一步输入 CA-Net 网络中进行训练,通过训练得到的模型完成脑肿瘤分割;利用二值图像后处理提升分割图像精度,得到最终的分割结果。

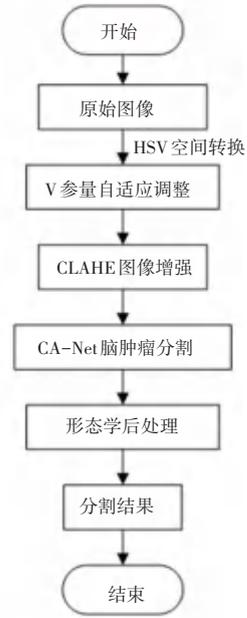


图 1 分割算法流程

Fig. 1 Flow chart of the segmentation algorithm

1 网络模型与算法设计

1.1 预处理

针对脑部 MR 图像可能存在对比度低、肿瘤边界信息模糊、灰阶信息不均匀等问题,使用图像增强处理可以抑制图像噪声,使肿瘤区域更显著。限制对比度直方图均衡化(CLAHE)算法^[13],通过计算图像的直方图并重新分布,由此提高整体的亮度。但是,这种算法可能会丢失部分灰阶信息,且对较暗的图像处理效果一般。因此,本文提出一种改进的 CLAHE 预处理方法。该方法先将图像转换到 HSV 空间,提取图像的亮度通道变量,并以此自适应调整图像的整体亮度。HSV 空间中的 V 通道和 S 通道计算公式如下:

$$V = \frac{\max(R, G, B)}{255} \quad (1)$$

$$C_{\max} = \frac{\max(R, G, B)}{255}, C_{\min} = \frac{\min(R, G, B)}{255} \quad (2)$$

$$S = \begin{cases} 0 & C_{\max} = 0 \\ \frac{C_{\max} - C_{\min}}{C_{\max}} & C_{\max} \neq 0 \end{cases} \quad (3)$$

自适应亮度转换公式如下:

$$imb = \begin{cases} img(2 - img) & V < T \\ img & V \geq T \end{cases} \quad (4)$$

其中, imb 为调整后的图像亮度, img 表示调整前原图像的实际亮度, T 为亮度阈值。

1.2 CA-Net

综合注意力卷积神经网络 (Comprehensive Attention Convolutional Neural Networks, CA-Net) 结构如图 2 所示。该网络基于 U-Net 骨架结构^[14], 分

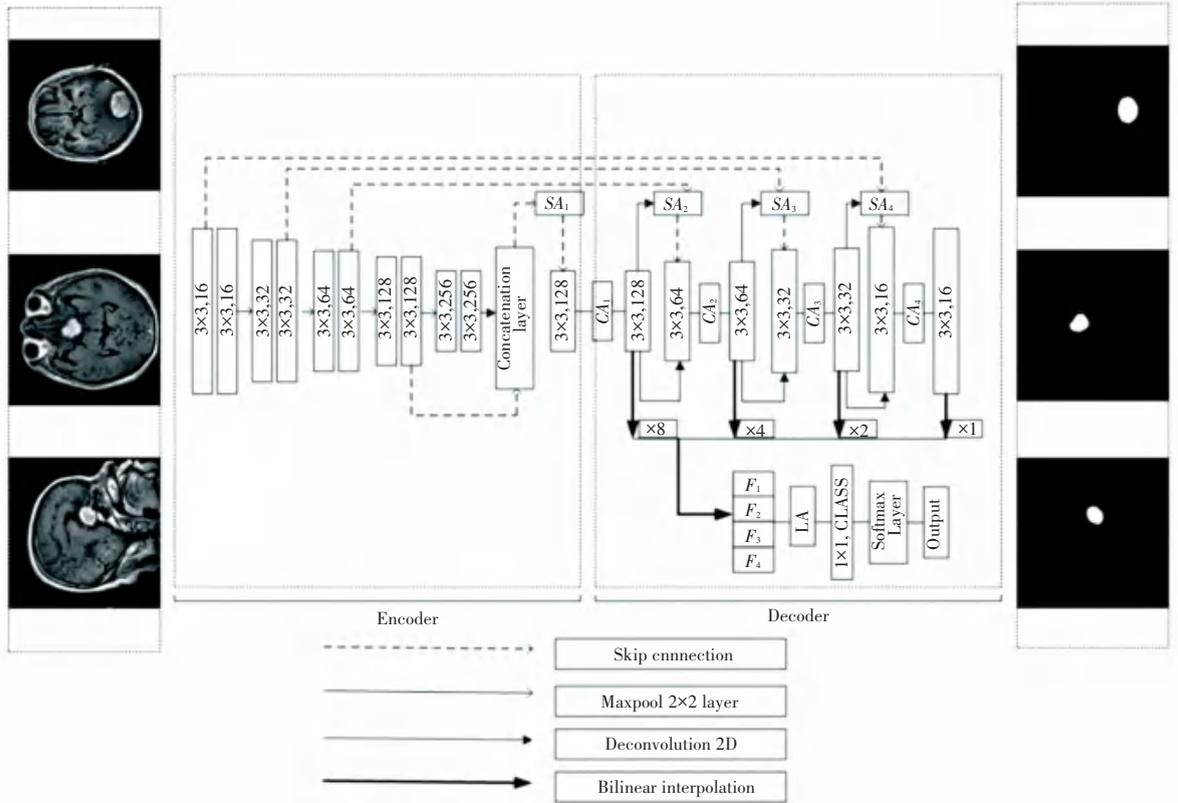


图 2 CA-Net 网络结构

Fig. 2 CA-Net network structure

编码器是一个特征提取器,可以连续获得多个尺度的高维特征;解码器利用这些编码特征来恢复分割目标。为了更好地利用前后的高低维特征,利用注意力模块进行连接,可以有效增强像素之间的关系。在网络结构中,使用 4 个空间注意力模块 (SA), 由最低分别率级别的非局部块^[15]和其它分别率水平的双通路^[16]相结合,形成一种多尺度空间注意力机制。 SA_{1-4} 与编码器的不同分辨率层相联结,分别对应不同分辨率级别的特征图。为更好地学习其网络层的上下文关系,内部使用卷积块来捕获像素之间的交互。如图 3(a)所示, SA_1 输入特征图形状为 $C \times H \times W$, 这里的 C 为通道数, H 和 W 分别表示高度和宽度。注意力块使用 3 个并行的 1×1 卷积层进行特征压缩,

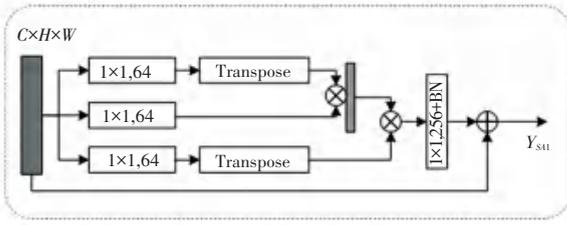
别包括编码器和解码器两部分,组成一个端到端可训练模型。通过添加复合注意力模块,实现对空间、通道和尺度的综合特征信息提取。其中, SA_{1-4} 为空间注意力模块, CA_{1-4} 为通道注意力模块以及一个尺度注意力模块 LA 。注意力模块可以有效学习当前特征地图中显著空间区域,使网络更好聚焦于分割目标,同时抑制不相关背景部分,提升预测准确性。

并依次将 3 个特征映射,重新构造为二维矩阵。图 3 (b) 为单路空间注意力 SA_{2-4} 。其中, X_h 为高级特征,来自解码器上采样, X_l 为低级特征,来自编码器、为关键特征。2 种特征经过压缩通道进行加权,通过 $ReLU$ 激活函数层和卷积层输出单通道,最后利用注意力系数进行校准,得到更新的 X_l 。SA 模块中利用多个注意门控结构,使网络关注特征图最相关的信息,同时抑制不相关的部分。

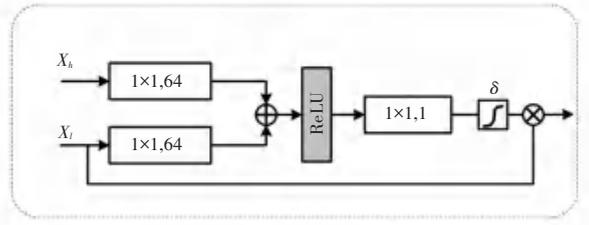
在 CA-Net 网络中包含 4 个通道注意力模块 (CA_{1-4}), 用以实现网络中低层特征和高层特征的通道连接,并对更相关的通道进行加权,赋予更高的系数。相较于 SE 模块^[17], 引入全局最大池化后的特征作为通道注意的更显著特征,保留更多全局信

息。由于编码器和解码器的特征通道不同,在分割任务中具有不同的重要性。为了更好提取特征通道

中有用的语义信息,添加通道注意力模块来自动突出相关的特征通道。



(a) 空间注意力块



(b) 单通道注意力块

图 3 空间注意力模块

Fig. 3 Spatial attention module

模型的主要网络是 U-Net,其主要的特点就是获取不同尺度的特征图,而为了联结这些不同分辨率的特征,得到最后的分割结果,需要在解码器部分进行多尺度连接。针对具有不同尺度特征图对象具有不同的相关性,需要赋予其不同权重系数。运用尺度注意力模块对网络将解码器中的不同尺度的特征图进行加权。其中包含编码器中的低维特征,以及经过空间通道注意力提取的重要语义信息。该模块作为网络的输出端,整合并校准不同尺度的图像信息。

1.3 混合损失函数

FocalLoss 函数^[18]是二元交叉熵损失函数的一种变体,利用较低简单样本的权重来解决标准交叉熵和类别不平衡的问题,从而实现较复杂的样本的学习。此处用到的数学公式可写为:

$$p_t = \begin{cases} p & y = 1 \\ 1 - p & \text{otherwise} \end{cases} \quad (5)$$

$$FocalLoss(p_t) = - (1 - p_t)^\gamma \log(p_t) \quad (6)$$

其中, $p \in [0, 1]$, 是模型对于类别 $y = 1$ 时得到的预测概率。当样本被误分且 p_t 很小时,对 *loss* 影响不大。随着 $p_t \rightarrow 1$, 调制因子趋近于零,容易分类的简单样本则被减少权重。

DiceLoss^[19]源自 dice 系数,是一种度量 2 个样本相似度的函数。针对二元分类问题,推导得到的数学公式为:

$$DiceLoss = \frac{2|X \cap Y|}{|X| + |Y|} \quad (7)$$

其中, X, Y 分别表示预测值和真实标签,分子为两者的交集,通过系数 2 控制取值范围在 0 到 1 之间; $|X|$ 和 $|Y|$ 分别为 X, Y 的个数。

为进一步提高网络模型的学习能力和优化训练过程,减少由于肿瘤区域较小、与背景不平衡导致的差异,本文结合 *FocalLoss* 和 *DiceLoss* 两种损失函

数,使用改进的混合 *loss* 进行训练,具体公式如下:

$$MixedLoss = -\lambda (1 - p_t)^\gamma \log(p_t) + (1 - \lambda) \frac{2|X \cap Y|}{|X| + |Y|} \quad (8)$$

其中, $\lambda \in [0, 1]$, 确定 2 个 *loss* 分量的相对权重, γ 控制背景类的抑制和较难样本类别的增强。

1.4 形态学后处理

本文使用形态学后处理方法,进一步提升脑肿瘤的分割精度,即二值图像闭运算和开运算,并进行相关对照实验。形态学处理主要根据图像中锚点位置的像素点,通过像素值的差异,对周边像素区域进行膨胀和腐蚀操作。开运算和闭运算均为膨胀和腐蚀复合操作,可排除较小像素块,将区域连接,形成连通域。将卷积神经网络模型输出作为预分割结果,并分别进行形态学后处理操作。

2 实验结果与分析

2.1 实验数据与参数设置

本文训练使用的数据集来自 Kaggle 数据集,其中磁共振图像共 3 064 张,图像包含不同的切面和多种尺寸,标记的掩膜标签与肿瘤位置相对应。使用 Pytorch 框架实现 CA-Net 网络模型;实验环境使用的处理器为 Intel(R) Core(TM) i7-8700 CPU,主频 3.20 GHz、显卡为 NVIDIA Titan 1080 GPU;编程使用 Python 3.7,以及 Anaconda 集成开发环境,其中运用 Opencv、Numpy 等库。

实际训练采用五折交叉验证,在所有测试集上保留性能最佳的模型。模型训练选用 Adam 优化器,学习率为 0.001,利用余弦退火策略动态调整,对此可表示为:

$$\eta_t = \eta_{\min} + \frac{1}{2}(\eta_{\max} - \eta_{\min}) \frac{\cos \frac{\pi}{2} \frac{cur}{T}}{e} + \cos \frac{\pi}{2} \frac{cur}{T} \frac{\ddot{\theta}}{e T_i \theta} \quad (9)$$

其中, η_{\max}^i 和 η_{\min}^i 分别表示学习率最大值和最小值, T_{cur} 和 T_i 分别为已运行的 *epoch* 数以及目前的第 i 个 *epoch*。

单次传递的样本数大小 (*Batch Size*) 将影响模型的优化程度和速度, 直接影响到 GPU 内存的使用情况。随着 *batch size* 增大, 处理相同数据量的速度越快, 达到相同精度所需要的 *epoch* 数量会越来越多。但 *batch size* 过大容易导致网络收敛到一些不好的局部最优点; 同样, 太小的 *batch size* 也存在训练速度很慢、训练不容易收敛等问题。在本数据集中, 选择 *batch size* 为 16。另外, 所有模型训练均选择损失函数 *loss* 值最低的状态作为最佳模型, 此时保存的模型权重将用于后续的对比如实验。

2.2 评价指标

针对二元图像分割, 通常使用 *Dice* 相似系数对结果进行评估, 可用如下公式计算得出:

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

其中, *TP* (True Positive) 表示真阳性, 即预测为阳性且实际为正例; *FP* (False Positive) 为假阳性, 即实际为负例、而预测为阳性; *FN* (False Negative) 为假阴性, 即实际是正例、而预测为阴性。

2.3 实验结果对比

2.3.1 预处理

本实验使用改进的 CLAHE 算法进行图像增强操作, 对照组分别为原始图像和传统 CLAHE 算法。实际预处理中, 亮度阈值取为 0.67 时表现较好, 脑 MR 原图像经过自适应调整全局亮度后, 暗部细节得到增强, 更能突显肿瘤区域的实际位置以及其边界信息。分别在基于相同网络参数下进行模型训练。不同预处理方法对比结果见表 1。

表 1 不同预处理方法对比结果

Tab. 1 Comparison of training results of different pre-processing methods

预处理方法	<i>Dice</i> 系数
原始图	86.18 (± 1.44) %
CLAHE	86.43 (± 1.36) %
改进的 CLAHE	87.26 (± 0.76) %

由表 1 的实验结果可见, 使用原始图像, 即不进行任何预处理, 模型平均 *Dice* 系数为 86.18 (± 1.44)%; 经过传统的 CLAHE 算法进行预处理, 模型最终分割结果的 *Dice* 系数为 86.43 (± 1.36)%; 而原数据集经过改进的 CLAHE 预处理算法, 实现的最终分割效果最好, 平均 *Dice* 系数为 87.26 (± 0.76)%。结果表

明, 使用自适应亮度调整的 CLAHE 算法进行图像增强, 对图像的暗部细节以及肿瘤区域的边界显著性有明显提高。整体效果如图 4 所示。图 4 中 (a) 为原图像, (b) 为直接利用 CLAHE 算法处理图像, (c) 为采用基于空间域转换的亮度自适应调整 CLAHE 算法结果。



(a) 原图 (b) CLAHE 算法结果 (c) 改进的 CLAHE 算法结果

图 4 预处理结果对比

Fig. 4 Comparison of pre-processing results

2.3.2 卷积神经网络模型

实验主要将 CA-Net 与 U-Net、U-Net++ 和 Attention U-Net 等图像分割常用模型进行比较。同时, 针对混合 *loss* 训练的效果, 进行消融实验。所有的网络模型结果使用 *Dice* 评价指标进行对比。实验结果见表 2。

表 2 不同模型训练的结果对比

Tab. 2 Comparison of training results of different models

训练模型	<i>Dice</i> 系数/%	分割耗时/ms
U-Net	81.73 (± 2.36) %	2.7
U-Net++	84.06 (± 1.04) %	3.1
Attention U-Net	86.17 (± 0.89) %	2.6
CA-Net	87.26 (± 0.76) %	2.1
CA-Net+ Mixed loss	88.40 (± 0.24) %	2.2

由表 2 中数据可见, 使用原始的 U-net 网络, 平均 *Dice* 系数为 81.73 (± 2.36)%; U-Net++ 模型 *Dice* 系数为 84.06 (± 1.04)%; Attention U-Net 网络分割结果的 *Dice* 系数为 86.17 (± 0.89)%; CA-Net 的分割结果为 87.26 (± 0.76)%。相较于其它网络模型, CA-Net 网络的 *Dice* 指标有一定的提升。模型还进一步结合 *MixedLoss* 进行训练, 平均 *Dice* 指标有近 1.2% 的提升。在图像分割耗时方面, CA-Net 网络的分割每张图片平均耗时为 2.1 ms, U-Net、U-Net++ 以及 Attention U-Net 网络耗时分别为 2.7 ms、3.1 ms 和 2.6 ms, CA-Net 表现优于其他网络模型。

2.3.3 形态学后处理

为进一步提升分割肿瘤区域的精度, 将形态学后处理应用于深度学习模型的预分割结果, 主要使用二值图像的开闭运算。

针对不同的形态学后处理结果,本文使用五折交叉验证,将全部数据集分割结果与原数据集的掩膜标签进行对照,对比最后的平均 *Dice* 系数。不同形态学后处理算法实验结果见表 3。

表 3 不同形态学后处理结果的 *Dice* 系数对比

Tab. 3 Comparison of *Dices* of different morphological post-processing results

<i>Fold</i>	原始分割结果	开运算结果	闭运算结果
1	88.41(±0.24)	88.75(±0.39)	88.13(±0.39)
2	88.18(±0.23)	88.76(±0.37)	89.22(±0.36)
3	88.01(±0.27)	88.38(±0.39)	88.50(±0.39)
4	88.89(±0.23)	89.77(±0.33)	90.03(±0.32)
5	88.53(±0.22)	88.99(±0.31)	90.20(±0.31)
平均	88.40(±0.24)	88.93(±0.36)	89.21(±0.36)

原始模型的平均 *Dice* 系数为 88.40(±0.24)%,开运算 *Dice* 结果为 88.93(±0.36)%,闭运算后处理表现最优,平均 *Dice* 系数为 89.21(±0.36)%。相较于 CA-Net 网络的分割结果,*Dice* 指标有所提升。

最终实现的分割效果如图 5 所示。图 5 中,(a)为原图像,(b)为选用 CA-Net 结合闭运算后处理的最终分割结果,(c)为原数据的掩膜标签。可以看出,本文基于 CA-Net 的脑肿瘤分割算法可以准确分割脑肿瘤区域,并且减少了由于图像噪声出现的误分割状况。

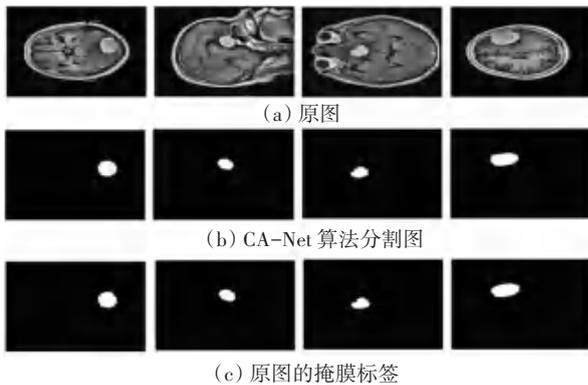


图 5 分割结果与原图和掩膜标签的对比

Fig. 5 Comparison of segmentation results with original images and masks

3 结束语

针对脑肿瘤 MR 图像分割问题,应用改进的自适应亮度 CLAHE 算法进行图像增强,并将 CA-Net 网络模型与混合损失函数结合,解决了原网络丢失部分关键信息的问题,使网络关注特征图的最相关信息的连接,同时抑制不相关的部分,取得比 U-Net、U-Net 以及 Attention U-Net 更高的分割精

度。经过二值图像闭运算后处理,有效减少了误分割的概率,提高最后的平均 *Dice* 系数。该分割算法能更准确且稳定用于 MR 图像的脑肿瘤区域分割,并对患者早期治疗和诊断有重要意义。

本文的方法仍有部分局限性,在一些方面可以进一步优化。如:针对多序列 MR 图像,可考虑进行多模型融合;由于该模型是基于二维数据进行分割,还未用到脑肿瘤 MR 图像的三维空间信息,可考虑进行三维模型扩展。

参考文献

- [1] 延鹏翔. 脑肿瘤的早期识别和诊治[J]. 人口与健康,2020(10): 90-94.
- [2] 李永焯,戴曙光. 改进分水岭算法在脑肿瘤 CT 图像分割中的应用[J]. 软件导刊,2018,17(06): 157-159.
- [3] 柴黎,王明泉. 颅脑 MRI 图像的分水岭分割方法研究[J]. 中国生物医学工程学报,2007,26(03):384-388.
- [4] 宗晓萍,田伟倩. 采用 K-means 的脑肿瘤磁共振图像分割与特征提取[J]. 计算机工程与应用,2020,56(03):187-193.
- [5] 苗加庆. 基于自适应字典学习降噪改进的脑 MRI 图像分水岭精确分割算法研究[J]. 激光杂志,2015,36(01):35-39.
- [6] 苗语,丰振航,杨华民,等. 基于改进的 U-Net 肺结节分割方法研究[J]. 计算机应用与软件,2021,38(12):213-219.
- [7] 盛克峰,李文星. 基于可变形卷积和语义嵌入式注意力机制的眼球超声图像分割方法[J]. 计算机系统应用,2022,31(02): 342-349.
- [8] 葛帅,严加勇,谢利剑,等. 改进型 U-Net 网络的左心室超声心动图像分割[J]. 软件导刊,2021,20(02): 206-209.
- [9] ZHOU Zongwei, SIDDIQUEE M M R, TAJBAKHSH N, et al. Unet++: Redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Transactions on Medical Imaging, 2019, 39(6): 1856-1867.
- [10] 吴量,付殿臣,程超. 基于 Unet 的多注意力脑肿瘤图像分割算法[J]. 计算机技术与发展,2021,31(12):85-91.
- [11] GU Ran, WANG Guotai, SONG Tao, et al. CA-Net: Comprehensive attention convolutional neural networks for explainable medical image segmentation[J]. IEEE Transactions on Medical Imaging, 2020, 40(2): 699-711.
- [12] LIN C W, HONG Yu, LIU Jinfu. Aggregation-and-Attention Network for brain tumor segmentation[J]. BMC Medical Imaging, 2021, 21(1): 1-12.
- [13] 王帆,吕继东,申根荣,等. 基于 CLAHE 和开闭运算的绿色苹果图像分割[J]. 计算机测量与控制,2017,25(02):141-145.
- [14] 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. Cham: Springer, 2015: 234-241.
- [15] WANG X, GIRSHICK R, GUPTA A, et al. Non-local neural networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City: IEEE, 2018: 7794-7803.
- [16] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: Learning where to look for the pancreas[J]. arXiv preprint arXiv:1804.03999, 2018.

(下转封三)