

DOI:10.3969/j.issn.1003-5060.2023.08.010

基于 U1-net 网络的放疗脑肿瘤靶区分割

张本健¹, 林辉¹, 郭栋², 王桂林¹, 胡敏²

(1. 合肥工业大学 电子科学与应用物理学院, 安徽 合肥 230601; 2. 合肥工业大学 计算机与信息学院, 安徽 合肥 230601)

摘要:文章基于全卷积神经网络(fully convolutional network, FCN)的 U-net 网络, 并通过对 U-net 网络的调整, 构建适用于脑肿瘤图像分割的 U1-net 网络。U1-net 网络由卷积层、最大池化层、反卷积层和激活函数 4 个部分组成。通过在公共数据集 BRATS 2015 上的实验验证了该网络的有效性。实验结果表明, 该网络能适应脑肿瘤轮廓取得较好的分割效果, 在脑肿瘤的完整肿瘤区、核心肿瘤区、增强肿瘤区的 Dice 相似系数(Dice similarity coefficient, DSC)分别为 0.95、0.85、0.83。

关键词:深度学习(DL); 全卷积神经网络(FCN); U1-net 网络; BRATS 2015 数据集; 脑肿瘤分割

中图分类号:R811.1; TP391 **文献标志码:**A **文章编号:**1003-5060(2023)08-1070-09

Target segmentation of brain tumor in radiotherapy based on U1-net network

ZHANG Benjian¹, LIN Hui¹, GUO Dong², WANG Guilin¹, HU Min²

(1. School of Electronic Science and Applied Physics, Hefei University of Technology, Hefei 230601, China; 2. School of Computer Science and Information Engineering, Hefei University of Technology, Hefei 230601, China)

Abstract: This paper is based on the U-net network of the fully convolutional network(FCN), and by adjusting the U-net network, a U1-net network suitable for brain tumor image segmentation is constructed. The U1-net network is composed of four parts: convolution layer, max pooling layer, deconvolution layer and activation function. Through the experimental verification on the public data set BRATS 2015, the validity of the model is verified. The experimental results show that the model can adapt to the contour of brain tumors and achieve a good segmentation effect. In addition, the Dice similarity coefficient(DSC) values of 0.95, 0.85 and 0.83 are obtained in the complete tumor region, core tumor region and enhanced tumor region of brain tumors, respectively.

Key words: deep learning(DL); fully convolutional network(FCN); U1-net network; BRATS 2015 data set; brain tumor segmentation

0 引言

脑神经多形性胶质母细胞瘤(glioblastoma multiforme, GBM)是最常见的一类脑肿瘤, 分为高级胶质瘤(high grade glioma, HGG)和低级胶质瘤(low graded glioma, LGG), 其中 LGG 又分为低级星型细胞瘤和少突神经胶质瘤。HGG 寿命通常不超过 2 a, 且一经发现需要立即治疗;

LGG 具有几年的预期生存期, 积极治疗通常可以延长患者的寿命。手术切除是脑肿瘤治疗最常见的手段, 此外, 放疗、化疗可用于减缓不能手术移除的肿瘤组织。放疗作为肿瘤治疗的一种手段, 主要通过电离辐射直接或间接作用肿瘤细胞, 在照射的区域内沉积一定的能量从而达到破坏“靶区”肿瘤细胞的作用。

磁共振成像(magnetic resonance imaging,

收稿日期:2020-05-25;修回日期:2020-06-12

基金项目:国家自然科学基金资助项目(61672202;U1613217)

作者简介:张本健(1992—),男,安徽六安人,合肥工业大学硕士生;

林辉(1973—),女,安徽阜阳人,博士,合肥工业大学副教授,硕士生导师,通信作者,E-mail:huilin@hfut.edu.cn;

胡敏(1967—),女,安徽淮北人,博士,合肥工业大学教授,博士生导师。

MRI)是一种断层功能影像成像方法,具有高软组织成像分辨率、无电离辐射损伤等优点,在肿瘤的诊断、治疗过程中发挥着重要作用。MRI 通过在图像采集期间改变激发脉冲强度和重复时间,以生成 4 种包含 T1 加权成像(T1-weighted, T1)、增强 T1 加权成像(T1 with post-contrast, T1c)、T2 加权成像(T2-weighted, T2)和液体衰减翻转恢复(fluid attenuated inversion recovery, FLAIR)的 4 个相关联模态图像。将这些不同模态 MRI 图像相结合,可提供肿瘤形状、大小、位置等内部结构信息。为改进放疗的实施精度,近年来出现了 MRI 图像引导的自适应放射治疗(MRI-guided adaptive radio therapy, MRIgART),即利用 MRI 多模态图像进行放疗过程中的图像引导。

文献[1-2]对精准放射治疗关键物理与技术进行了研究,开发了具有完全自主知识产权的精准放疗计划系统 KylinRay“麒麟刀”,已通过国家药监局认证检验。该系统发展了高精度剂量计算、快速计划优化、患者智能摆位、多维精准建模、射束精准调控、实时剂量反演与验证等一系列放疗关键技术,提出了“精准计划、精准定位、精准照射、精准测评”耦合的四精放疗技术体系,可为肿瘤放射治疗的全过程提供高效解决方案。MRIgART 是 KylinRay“麒麟刀”目前正在研发的产品之一,属于其前端基于先进人工智能深度学习的靶区自动勾画方法的研究。

肿瘤放疗靶区勾画在本质上属于图像分割,肿瘤放疗优质计划建立的前提是对放疗靶区的准确勾画。目前临床上常用的方法是医师的手工勾画,工作量巨大且具有很强的为主观性,且脑肿瘤的形状多样性、位置不固定、结构复杂以及在不同患者身上具有非常大的差异,给人工分割脑肿瘤带来了许多实际困难,因此自动分割脑部肿瘤的研究具有重要的应用价值。

深度学习(deep learning, DL)是近年来兴起的一项人工智能技术,无论在科研还是其他领域都受到广泛的关注,并在医学肿瘤图像领域得到了应用。基于深度学习的医学图像分割方法不需要人工设计特征,而是由模型自己去学习数据中的深层信息,以加快诊断的速度与提升诊断的准确度,避免人为因素造成的误诊。肿瘤放疗优质计划建立的前提是对放射靶区的准确勾画,手工勾画工作量巨大且具有很强的为主观性。利用深度学习方法辅助肿瘤靶区的自动勾画是人工智

能技术在医学领域的渗透与应用。

深度学习中最典型的算法是卷积神经网络(convolutional neural network, CNN)^[3], CNN 是一种基于深度学习理论的多阶段全局可训练模型,可以从图像中学习深层的特征结构,获取高维的图像特征,对自然图像的识别与定位非常有效。目前,脑肿瘤分割方面的深度学习研究,主要集中在网络模型结构设计上^[4]。文献[5]建立了多通道的网络结构,每次通过获取肿瘤图片的局部特征对每个像素分类,经过反复训练后恢复 1 张完整的分割图;文献[3]基于 CNN 完成脑肿瘤的分割任务,在其设计的网络中使用较小的 3×3 的卷积核,该模型取得了较好的结果;文献[6]提出将深度 CNN 框架用于脑肿瘤的分割。通过训练 2 个 CNN 模型分别对恶性胶质瘤和良性胶质瘤进行分割,提高了神经网络的处理速度,在 CNN 模型中使用尺寸较小的卷积核,不仅提高了速度,更有利于图像特征的获取。因为脑肿瘤 MRI 图像是三维结构,所以一些文献也提出了 3D-CNN 应用于脑肿瘤分割任务,例如文献[7]提出了用三维图像作为 CNN 模型的输入来训练三维 CNN 模型。这种 3D-CNN 模型虽然保留了 MRI 图像的空间信息,但是很大程度上增加了计算量,且训练速度慢。

CNN 提取的抽象特征对图像进行分类,对图像中包含的对象进行分类,以及对图像中对象的粗略定位是非常有效的,然而由于采用了感受野,对图像特征的提取更多地是以“1 小块临域”为单位的,很难做到精细(像素级)的分割,不能准确地划定物体具体的轮廓。鉴于 CNN 在图像精细分割方面的局限性,文献[8]提出了将全卷积网络用于语义分割问题的研究。

原始的 U-net 网络正是基于全卷积神经网络(fully convolutional network, FCN)的架构,是文献[9]提出使用编码-解码的结构, U-net 网络与 FCN 都可应用于很小的数据集,网络最初提出时是用于细胞壁的分割,并且在肺结节检测和眼底视网膜上的血管提取等方面都有着出色的表现。U-net 的优点有:① 通过对每个像素点进行分割,获得了更高的分割准确率;② 支持少量数据训练模型;③ 可实现端到端,输入 1 张图像,输出 1 张图像。

本文基于 MATLAB 平台 MatConvNet^[9] 公共源深度学习工具箱,针对 CNN 模型在图像分割领域很难做到精细分割的缺点,并结合脑肿瘤

丰富的 MRI 图像信息,在全卷积神经网络的 U-net 网络的基础上,通过调整 U-net 网络,构建了适用于脑肿瘤图像的 U1-net 网络模型(以下简称为 U1-net 网络)。该网络克服了 CNN 模型忽略全局信息和丢失浅层网络信息的缺点,能够保留脑部 MRI 的全面信息,获得 MRI 的丰富特征,并且在公共数据集 BRATS 2015 上得到实验验证,表明了该网络的有效性,及其在勾画脑部肿瘤靶区精度上具有的良好效果。

1 材料与方法

1.1 BRATS 数据集

本实验的脑肿瘤图片数据来源于 BRATS




图 1 BRATS 2015 数据集

2015 数据集^[10],该数据集包含训练集和测试集。训练数据集由 220 个 HGG 病例和 54 个 LGG 病例组成。测试数据集由 110 个等级未知的病例组成。不同数据集的图像对齐到相同模板,插值成 $1\text{ mm} \times 1\text{ mm} \times 1\text{ mm}$ 体素分辨率的图像。由 T1、T1c、T2 和 FLAIR 的 4 个相关联模态图像形成了患者的 MRI 图像。BRATS 2015 数据集如图 1 所示。所有图像标注整合了 FLAIR、T1、T1c、T2 等信息。每个图像数据在像素级上被标记为 5 类,分别是正常组织、坏死、水肿、非增强肿瘤区域、增强肿瘤区域。此外,BRATS 数据集还提供了由临床专家手工分割的脑肿瘤勾画图作为自动勾画的真值标签(判别标准)(ground truth,GT)。

1.2 MatConvNet 工具箱

MatConvNet 为英国 VLFeat 小组开发的基于 MATLAB 平台的深度学习算法工具箱,简单易用、扩展性强。MatConvNet 主题框架清晰,模块之间耦合性较小,便于用户根据需要对模块进行方便调整。其部分核心函数(如卷积、子采样等)使用 C++ 编写,从而保证了运行速度。

MatConvNet 可提供构建深度学习模型需要的模块化的卷积层(convolution layer)、池化层(pooling layer)(子采样层)、反卷积层(deconvolution layer)(转置卷积层)、激活函数(activation function)等。

卷积层由若干卷积核组成,卷积运算的目的是提取输入的不同特征,并输出提取的特征,浅层的卷积层可能只能提取一些低级的特征,深层的网络能从低级特征中迭代提取更复杂的特征;池化层一般位于卷积层之后,由于卷积层提取到维度很大的特征,需要池化操作来特征降维、减小特征规模、减少参数量、减小过拟合,同时提高模型的鲁棒性,且池化分为最大池化和平均池化;反卷积层中的反卷积操作通常用于将低维特征映射成高维输入,反卷积其实就是卷积的逆过程,通过反卷积操作并不能还原出卷积之前的图片,只能

还原出卷积之前图片的尺寸;激活函数主要对卷积层的输出进行一个非线性映射,如果不用激励函数,CNN 中每一层输出都是上层输入的线性函数,激活函数是用来增加非线性因素,用来提高线性模型的表达能力。

1.3 U-net 网络

原始的 U-net 网络的 U 形结构如图 2 所示^[9],由卷积层、最大池化层(下采样)、反卷积层(上采样)和 ReLU 函数 4 个部分组成。整个 U-net 网络的运行过程具体如下:

1) 下采样阶段。原始输入图像大小为 572×572 ,经过 2 次由 64 个 3×3 的卷积核组成的卷积层后,得到特征图(feature map, FM)的大小变为 $568 \times 568 \times 64$,经过 2×2 的最大池运算后,FM 的大小变为 $284 \times 284 \times 64$;根据上述过程重复 4 次,即 $(3 \times 3$ 卷积 $+ 2 \times 2$ 池化) $\times 4$ 次,每个池化后的第 1 个 3×3 卷积运算, 3×3 卷积核数成倍增加;到达最底层时,即在第 4 次最大池化之后,FM 大小变为 $32 \times 32 \times 512$,然后执行 $3 \times 3 \times 1\ 024$ 的卷积操作 2 次,最终 FM 大小变化为 $28 \times 28 \times 1\ 024$ 。

2) 上采样阶段。此时,FM 的大小为 $28 \times 28 \times 1\ 024$ 。首先进行 2×2 反卷积操作,使 FM

的尺寸变为 $56 \times 56 \times 512$; 然后对最大池化层之前的图像进行复制和剪切, 再将反卷积得到的图像拼接在一起, 得到 1 张 $56 \times 56 \times 1024$ 的图像, 然后再进行 $3 \times 3 \times 512$ 的卷积操作; 重复上述过程 4 次, 即进行 $(2 \times 2$ 反卷积 $+ 3 \times 3$ 卷积) $\times 4$ 次, 每次拼接后的第 1 个 3×3 卷积操作后, $3 \times$

3 个卷积核的数目会翻倍; 当到达顶层时, 即经过第 4 次反卷积后, FM 的大小将变为 $392 \times 392 \times 64$, 进行复制剪裁后再拼接, 得到尺寸为 $392 \times 392 \times 128$ 。然后再进行 2 次 $3 \times 3 \times 64$ 的卷积操作得到 $388 \times 388 \times 64$ 大小的图像, 最后再进行 1 次 $1 \times 1 \times 2$ 的卷积操作。




图 2 U-net 网络结构图

1.4 面向 GBM 靶区勾画的 U1-net 网络

加载原始的预训练 U-net 网络, 并对 U-net 网络进行调整, 构建适用于脑肿瘤图像分割的

U1-net 网络。U1-net 网络由下采样阶段和上采样阶段组成, U1-net 网络的框架结构如图 3 所示。




图 3 U1-net 网络结构图

整个 U1-net 网络的运行过程如下:

1) 下采样阶段。该阶段由 5 个卷积块和 4 个池化层组成。这 5 个卷积块都包含 2 个卷积层, 卷积层中卷积核大小为 3×3 , 步长为 1。每个卷

积层后都使用 ReLU 激活函数增加非线性因素。除了最后 1 个卷积块, 在每个卷积块后使用相同的池化尺寸为 2×2 的最大池化操作。为了获取脑肿瘤像较高的分辨率, 将 U1-net 网络的输入图

像尺寸调整为 320×320 , 经过下采样阶段, 特征图大小转变为 20×20 。

2) 上采样阶段。该阶段由 4 个反卷积和 4 个卷积块组成, 每个卷积块开始于反卷积层, 其中卷积核大小 3×3 , 步长为 2, 使得特征图大小增加 1 倍, 数量减少 1 倍, 最后特征图的大小再由下采样阶段的 20×20 变为 320×320 。U1-net 网络在上采样阶段的卷积块中采用 2 个卷积层, 用于减少特征图的数量。上采样阶段中的特征图来源于上一级上采样的特征图和对应的下采样的特征图。相比于原始的 U-net 网络, U1-net 网络还使用了零填充来保证下采样和上采样阶段中的卷积层的输出维度。

1.5 输入图片数据的预处理

对于所有病例, 有 FLAIR、T1、T1c、T2 共 4 个 MRI 序列。由于 MRI 图像强度的偏场畸变效应, 引起图像中在同一区域的灰度值也会有差异, 即使是同一扫描仪, 也会在不同时间或者从不同患者身上采集到的切片通常具有不同的强度范围。

偏移场校正是校正由于磁场不均匀导致的图像对比度, 强度标准化是将所有图像的强度值映射到标准或参考标度的过程。

为了解决这种强度归一化的问题, 采用 N4ITK 处理方法。N4ITK 是一款医学图像处理软件包, 采用了多模态数据分割配准算法, 用于处理图像配准和分割的问题, N4ITK 方法主要是通过减去最高频率的灰度值, 再除以校正后的灰度

值来对图像进行归一化处理^[11]。U1-net 网络的输入图像尺寸为 320×320 , 因此将所有图像数据全部归一化到 320×320 。MRI 预处理前后对比图如图 4 所示。




图 4 MRI 预处理前后对比图

1.6 U1-net 网络训练及参数设置

本文针对脑肿瘤图像分割构建的 U1-net 网络的输入是一整张图像, 以 FLAIR、T1、T1c 和 T2 4 个模态图像作为训练图像, 取同一层切片组成的 4 通道图像。最后的输出类别设置为 5, 对应脑肿瘤的 5 个类别。训练参数设置为: 初始学习率为 5×10^{-4} , 权值衰减为 0.005, 迭代 9 000 次以上。

U1-net 网络的准确度与迭代次数的关系如图 5 所示。




图 5 U1-net 网络的准确度随迭代次数的变化

由图 5 可知, 网络的准确度随着迭代次数的增加越来越趋于稳定, 逼近 100%。

U1-net 网络的损失函数值与迭代次数的关系如图 6 所示。

从图 6 可以看出, 损失函数值趋于 0, 表明预测结果与真实结果具有较高的一致性, U1-net 网络训练效果较好, 能完全适用于脑肿瘤图像分割任务。




图 6 U1-net 网络的损失函数值随迭代次数的变化

1.7 分割的评估标准

利用 Dice 相似系数 (Dice similarity coefficient, DSC)、阳性预测值 (positive predictive value, PPV)、灵敏度 S 对分割方法进行评估^[12], 每种指标都是根据 3 种肿瘤区域来计算的。这 3 种区域包括完整肿瘤区域、核心区域和增强区域。完整的肿瘤区由坏死区、水肿区、非强化区和强化区组成; 核心区域由坏死区、非强化区和增强区组成; 增强区域只包括增强核心。这 3 个指标的计算公式为:

$$D_{sc} = \frac{2t_p}{f_p + 2t_p + f_n} \quad (1)$$

$$P_{pv} = \frac{t_p}{t_p + f_p} \quad (2)$$

$$S = \frac{t_p}{t_p + f_n} \quad (3)$$

其中, t_p 、 f_p 、 f_n 分别是检测为真阳性、假阳性、假阴性的肿瘤点的数量。

2 实验结果讨论与分析

本文选取 3 个病人的经过 U1-net 网络后的分割预测图, 分割结果如图 7 所示。

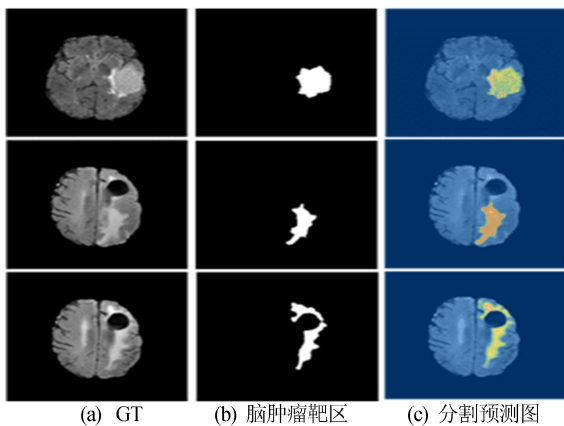


图 7 U1-net 网络的 GT 图与分割图的对比

图 7 中: 黄色区域代表水肿; 红色区域代表非增强肿瘤结构; 绿色区域代表囊性坏死部分。由

图 7 可知, U1-net 网络可以分割出完整脑肿瘤区域, 且与 GT 较为相似, 获得了较好的匹配率, 接近脑肿瘤的分割轮廓, 分割效果较好。

针对脑肿瘤图像构建的 U1-net 网络与文献 [6, 13-15] 方法, 基于 BRATS 2015/BRATS 2013 数据集分割结果的 DSC 值对比见表 1 所列。表 1 中, 前 3 种实验方法和本文的分割方法都是基于 BRATS 2015 进行的实验, 第 4 种方法基于 BRATS 2013 进行的实验, BRATS 2015 数据集和 BRATS 2013 数据集在肿瘤图像特点上几乎没有区别。

表 1 不同方法在 BRATS 2015/BRATS 2013 数据集的 DSC 值

方法	完整肿瘤区	核心肿瘤区	增强肿瘤区
文献[6]	0.87	0.75	0.75
文献[13]	0.88	0.87	0.81
文献[14]	0.89	0.79	0.80
文献[15]	0.83	0.73	0.69
U1-net	0.92±0.03	0.85±0.02	0.83±0.02

从表 1 可以看出, U1-net 网络分割效果较好, 在完整肿瘤区、核心肿瘤区、增强肿瘤区的 DSC 值分别为 0.92、0.85、0.83。与文献 [14] 方法构建的网络模型相比, 完整肿瘤区和增强肿瘤区的 DSC 值高于其提出的网络模型, 说明 U1-net 网络对完整肿瘤区和增强肿瘤区有良好的特性, 但是在核心肿瘤区的 DSC 值略低于其建立的网络模型, 可能是由于在 1 幅图像中, 正常组织区域所占的比例较大, 而肿瘤内部其他子区域还要进一步分为 4 个类别, 因此肿瘤每个子区占的比例就更小, 导致类别学习不平衡。

从表 1 还可以看出, 文献 [15] 方法构建的网络模型在完整肿瘤区、核心肿瘤区、增强肿瘤区的 DSC 数值相比于本文提出的 U1-net 网络明显低很多, 这是由于其建立的网络是一种基于 CNN 的分割模型, 而 CNN 模型存在易忽略全局信息和丢失浅层网络信息的缺点, 从而导致其建立的

网络获得了较低的 DSC 值。本文提出的 U1-net 网络是基于全卷积神经网络的网络模型,克服了 CNN 模型存在的缺点,在脑肿瘤图像上分割效果较好,相比于 CNN 模型,也做到了精细的像素级分割。

相关文献方法的分割结果如图 8 所

示^[6,13-14]。图 8 中,每幅图从左到右依次是原始脑肿瘤靶区、分割标准 GT、分割结果。对比图 7 的效果图可知,虽然都区分出了脑肿瘤区域和正常组织,但是本文提出的分割方法在脑肿瘤边界处的分割结果相对更光滑,而且在脑肿瘤内各个子区域的分割效果也相对较好。




图 8 相关文献方法的分割结果

U1-net 网络和文献[16]提出的方法基于 BRATS 2015 数据集分割结果的 DSC 定量比较结果见表 2 所列。

表 2 不同方法在 BRATS 2015 数据集的 DSC 值

方法	完整肿瘤区	核心肿瘤区	增强肿瘤区
文献[16]	0.90±0.04	0.80±0.02	0.81±0.02
U1-net	0.92±0.03	0.85±0.02	0.83±0.02

文献[16]针对脑肿瘤构建的基于图像块分类的分割模型(6-CNN 网络),其思路是将肿瘤靶区的图像分割问题转化为肿瘤与非肿瘤图像块的分类问题来解决。图像块是从整张图像中依次提取

的局部区域,并将其中心像素值作为整个图像块的像素值,同样中心像素的标签也作为整个图像块的标签。

在训练阶段,提取大量的图像块训练 CNN;在测试阶段,从测试图像中提取的图像块被训练的 CNN 分类。每个图像块将通过 CNN 获得 1 个标签,图像块及其对应的标签将组成 1 个新的带有标签的大脑 MRI,以此标签将被用来分割相应的区域,即所有图像块分类结果整合构成测试图像的分割结果,然而 6-CNN 网络存在易丢失数据空间结构、训练过程繁琐、分割效率低下等弊端,且不能做到像素级精细分割。由表 2 可知,U1-net 网络整体分割效果优于 6-CNN 网络,特

别在核心肿瘤区的精度有明显提高,约提高了 5%,U1-net 网络对比 6-CNN 网络更能做到精细分割。

文献[17]除了在基于 BRATS 2015 数据集做过关于脑肿瘤分割方法的研究,还在基于 BRATS 2013 数据集提出了分层脑肿瘤的分割方

法。本文构建的 U1-net 网络与文献[17]提出的分层脑肿瘤分割方法的 3 个指标对比结果见表 3 所列。

从表 3 可以看出,U1-net 网络在完整肿瘤区、核心肿瘤区的 DSC、PPV、灵敏度数值都有不同程度的提高,在增强肿瘤区的灵敏度数值相等。

表 3 U1-net 网络与文献[17]方法在各个指标上的比较

方法	DSC			PPV			灵敏度		
	完整区	核心区	增强区	完整区	核心区	增强区	完整区	核心区	增强区
文献[17]	0.85	0.76	0.74	0.80	0.78	0.74	0.92	0.79	0.78
U1-net	0.92±0.03	0.85±0.02	0.83±0.02	0.93±0.01	0.80±0.02	0.80±0.03	0.93±0.01	0.80±0.02	0.78±0.04

3 结 论

U-net 网络作为深度学习分割网络,也应用于其他生物学图像处理领域,且已在具有差异性的其他医学图像分割任务中取得了优异的分割表现,而本文在结合 MRI 多模态丰富信息和基于全卷积神经网络的 U-Net 网络的基础上,通过调整并针对脑肿瘤图像分割构建了 U1-net 网络,其本质上属于 U-Net 网络模型的一种,因此在脑肿瘤医学图像分割任务中获得了良好的表现,能适应脑肿瘤因以任何形状存在于任意位置带来的差异性,从而能自动、准确地分割脑肿瘤靶区。

因此,该方法可以帮助医生在人工分割脑肿瘤时由于人为因素(如疲劳度、不同医师的个体化差异等)影响而导致的正确率下降。U1-net 网络靶区分割效率也较高,一般处理一套人体脑部 MRI 切片(一般 155 张)平均只需要 10~30 s,在医学成像应用中常常需要处理大量的数据而造成时间瓶颈,因此本文提出的 U1-net 网络具有重要的实用价值。

U1-net 网络仅以 MRI 图像数据集进行模型训练与肿瘤靶区的分割,不需要参考病人的 CT 图像,这正是目前国际上普遍认可的 MRI 图像引导放疗概念的优势。本文工作所解决的问题是放疗肿瘤靶区的勾画,作为放疗计划制定的预工作,U1-net 网络在完整肿瘤区的指标值较高,完整肿瘤区也正是肿瘤放射靶区,完整肿瘤区的分割精度越高,肿瘤放射靶区的放射效果越好。U1-net 网络为放疗的自动化实施提供了基础,也为靶区自动勾画领域的研究提供了更多方向和借鉴思路。

[参 考 文 献]

- [1] WU Y C, HU L Q, LONG P C, et al. Development and validation of an adaptive accurate radiotherapy system Kylin-Ray[J]. Journal of Medical and Biological Engineering, 2019, 39(4): 498-507.
- [2] 吴宜灿,曹瑞芬,胡丽琴,等. 动态调强精准放射治疗计划系统 KylinRay-IMRT 的研发及验证[J]. 中国医学器械杂志 2018, 42(1): 7-10.
- [3] PEREIRA S, PINTO A, ALVES V, et al. Brain tumor segmentation using convolutional neural networks in MRI images[J]. IEEE Transactions on Medical Imaging, 2016, 35(5): 1240-1251.
- [4] BENGIO Y, COURVILLE A, VINCENT P. Representation learning: a review and new perspectives[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2013, 35(8): 1798-1828.
- [5] HAVAEI M, DAVY A, WARDE-FARLEY D, et al. Brain tumor segmentation with deep neural networks[J]. Medical Image Analysis, 2015, 35(2017): 18-31.
- [6] PEREIRA S, PINTO A, ALVES V, et al. Deep convolutional neural networks for the segmentation of Gliomas in multi-sequence MRI[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2015. [S. l. : s. n.], 2015: 131-143.
- [7] ÖZGÜN C, ABDULKADIR A, LIENKAMP S S, et al. 3D U-net: learning dense volumetric segmentation from sparse annotation [C]//The 19th International Conference on Medical Image Computing and Computer Assisted Intervention-MICCA 2016. [S. l. : s. n.], 2016: 424-432.
- [8] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//IEEE Conference on Computer Vision and Pattern Recognition. [S. l.], IEEE, 2017: 3431-3440.
- [9] 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. [S. l.]: Springer, 2015: 234-241.
- [10] MENZE B H, JAKAB A, BAUER S, et al. The multimodal brain tumor image segmentation benchmark (BRATS) [J]. IEEE Transactions on Medical Imaging, 2015, 34(10):1993-2024.
- [11] TUSTISON N J, AVANTS B B, COOK P A, et al. N4ITK: improved N3 bias correction[J]. IEEE Transactions on Medical Imaging, 2010, 29(6): 1310-1320.
- [12] DICE L R. Measures of the amount of ecologic association between species[J]. Ecology, 1945, 26(3): 297-302.
- [13] DONG H, YANG G, LIU F, et al. Automatic brain tumor detection and segmentation using U-net based fully convolutional networks[C]//Medical Image Understanding and Analysis. [S. l. : s. n.], 2017: 506-551.
- [14] YI D, ZHOU M, CHEN Z, et al. 3-D convolutional neural networks for glioblastoma segmentation[EB/OL]. [2019-10-29]. <https://arxiv.org/abs/1611.04534>.
- [15] ZIKIC I, LOANNOU Y, CRIMINISI A, et al. Segmentation of brain tumor tissues with convolutional networks [C]//MICCAI Workshop on Multimodal Brain Tumor Segmentation Challenge. [S. l. : s. n.], 2014: 36-39.
- [16] 张本健, 林辉, 郭栋, 等. 基于卷积神经网络的放疗脑肿瘤靶区分割方法研究[C]//2019 放射肿瘤物理学年会. [出版地不详: 出版者不详], 2019: 224-225.
- [17] PEREIRA S, OLIVEIRA A, ALVES V, et al. On hierarchical brain tumor segmentation in MRI using fully convolutional neural networks: a preliminary study[C]//2017 IEEE 5th Portuguese Meeting on Bioengineering. [S. l.]: IEEE, 2017: 1-4.

(责任编辑 李 凯)

(上接第 1051 页)

体力和压缩比正相关;结合几何性能和力学性能对优化对象进行优化,利用多目标遗传算法分别在单初始参数和多初始参数条件下对目标函数进行优化,得到 F_a 和 $1/v$ 的非劣解集;并得出在多初始参数优化下,目标函数的取值比单初始参数优化下范围更大;从定量角度将非劣解集中的优化型涡旋盘和未优化涡旋盘所受的轴向气体力和压缩比进行对比。结果表明,优化型涡旋盘在压缩比提升 16.14% 的同时,轴向气体力降低了 5.62%,证明通过算法优化可以有效改善变截面涡旋盘的几何性能和力学性能。

因此,进行圆渐开线变截面涡旋压缩机设计时,可以根据相关性能的要求选取满足设计要求的型线参数,以得到兼顾几何性能和力学性能的圆渐开线变截面涡旋盘。

[参 考 文 献]

- [1] LIU Y G, TANG Y H, CHANG Y C, et al. Optimum design of scroll profiles created from involute of circle with variable radii by using finite element analysis[J]. Mechanism and Machine Theory, 2012, 55(9): 1-17.
- [2] BRYCE R S, ECKHARD A G. Variable wall thickness scroll geometry modeling with use of a control volume approach[J]. International Journal of Refrigeration, 2013, 36(7): 1809-1820.
- [3] MURRAY C. Variable wall thickness boosts scroll compressor's performance [J]. Design News, 1997, 53(5): 116-117.
- [4] 彭斌, 孙迎. 变截面涡旋压缩机数学模型及试验研究[J]. 机械工程学报, 2015, 51(14): 185-191.
- [5] 王君, 查海滨, 张晓慧, 等. 一种渐变啮合间隙的变壁厚涡旋齿型线研究[J]. 工程热物理学报, 2013, 34(8): 1453-1456.
- [6] 王立存, 陈进, 张贤明, 等. 基于泛函的制冷涡旋压缩机变壁厚涡旋型线理论及形状优化[J]. 中国机械工程, 2010, 21(16): 1898-1901.
- [7] 刘涛, 赵睿琦, 孙永吉. 基于自适应 NSGA II 算法的变截面涡旋盘优化[J]. 华中科技大学学报(自然科学版), 2021, 49(3): 63-68.
- [8] 侯才生, 刘涛. 基于 Frenet 标架的变截面涡旋压缩机型线的研究[J]. 华中科技大学学报(自然科学版), 2019, 47(2): 76-80.
- [9] 张朋成, 彭斌, 张宇波. 基于圆渐开线建立变截面涡旋齿的方法与理论[J]. 吉林大学学报(工学版), 2022, 52(4): 789-798.
- [10] 张朋成, 彭斌, 张宇波. 圆渐开线变截面涡旋压缩机几何性能综合分析[J]. 机械工程学报, 2020, 56(23): 118-128.
- [11] 刘涛, 侯富勇, 李传恒. 三段基圆渐开线涡旋型线的多目标遗传算法优化[J]. 流体机械, 2015, 43(8): 32-35.
- [12] 彭斌, 蒋龙. 变壁厚涡旋膨胀机型线参数的优化分析[J]. 合肥工业大学学报(自然科学版), 2021, 44(1): 7-13.
- [13] 刘涛, 郭再新, 刘振全. 法向等距线法生成涡旋压缩机型线的研究[J]. 机械工程学报, 2004, 40(6): 55-58.

(责任编辑 胡亚敏)