

深度卷积神经网络在放射治疗计划图像分割中的应用

邓金城¹, 彭应林², 刘常春¹, 陈子杰¹, 雷国胜¹, 吴江华¹, 张广顺², 邓小武²

1. 深圳市医诺智能科技发展有限公司, 广东 深圳 518057; 2. 中山大学肿瘤防治中心/华南肿瘤学国家重点实验室/肿瘤医学协同创新中心, 广东 广州 510060

【摘要】目的:结合全卷积神经网络(Fully Convolutional Network, FCN)和多孔卷积(Atrous Convolution, AC)的深度学习方法,实现放射治疗计划图像的组织器官自动勾画。**方法:**选取122套已经由放疗医师勾画好正常器官结构轮廓的胸部患者CT图像,以其中71套图像(8 532张轴向切层图像)作为训练集,31套图像(5 559张轴向切层图像)作为验证集,20套图像(3 589张轴向切层图像)作为测试集。选取5种公开的FCN网络模型,并结合FCN和AC算法形成3种改进的深度卷积神经网络,即带孔全卷积神经网络(Dilation Fully Convolutional Network, D-FCN)。分别以训练集图像对上述8种网络进行调优训练,使用验证集图像在训练过程中对8种神经网络进行器官自动识别勾画验证,以获取各网络的最佳分割模型,最后使用测试集图像对充分训练后获取的最佳分割模型进行勾画测试,比较自动勾画与医师勾画的相似度系数(Dice)评价各模型的图像分割能力。**结果:**使用训练图像集进行充分调优训练后,实验的各个神经网络均表现出较好的自动图像分割能力,其中改进的D-FCN 4s网络模型在测试实验中具有最佳的自动分割效果,其全局Dice为94.38%,左肺、右肺、心包、气管和食道等单个结构自动勾画的Dice分别为96.49%、96.75%、86.27%、61.51%和65.63%。**结论:**提出了一种改进型全卷积神经网络D-FCN,实验测试表明该网络模型可以有效地提高胸部放疗计划图像的自动分割精度,并可同时进行多目标的自动分割。

【关键词】深度学习;卷积神经网络;医学影像分割;相似度系数;放射治疗

【中图分类号】R811.1

【文献标志码】A

【文章编号】1005-202X(2018)06-0621-07

Application of deep convolution neural network in radiotherapy planning image segmentation

DENG Jincheng¹, PENG Yinglin², LIU Changchun¹, CHEN Zijie¹, LEI Guosheng¹, WU Jianghua¹, ZHANG Guangshun², DENG Xiaowu²

1. Shenzhen Yino Intelligence Technology Co, Ltd., Shenzhen 518057, China; 2. Collaborative Innovation Center for Cancer Medicine/State Key Laboratory of Oncology in South China/Sun Yat-Sen University Cancer Center, Guangzhou 510060, China

Abstract: Objective To combine fully convolutional network (FCN) and atrous convolution (AC) for realizing automation segmentation of tissues and organs in radiotherapy planning image. **Methods** A total of 122 sets of chest CT images were selected in this study, in which the normal organ structures were sketched by radiotherapy physician, including 71 sets of CT images (8 532 axial slice images) as training set, 31 sets of CT images (5 559 axial slice images) as validation set, and 20 sets of CT images (3 589 axial slice images) as test set. Five kinds of published FCN models were selected and combined with AC algorithm to form 3 kinds of improved deep convolutional neural networks, namely dilation fully convolutional network (D-FCN). Training set was used for fully fine-tuning the above 8 kinds of network, and validation set was applied to validate the automatic segmentation results for obtaining the optimal model of each network, and finally, test set was used to perform segmentation test for the optimal models. The Dice similarity coefficients of automatic segmentation and physician sketching were compared for evaluating the performances of these image segmentation models. **Results** After being fully fine-tuned with the use of training set, each neural network model showed good performances in automatic image segmentation. The improved D-FCN 4s model achieved the best automatic segmentation results in validation test, with a global Dice of 94.38%. The Dice of automatic segmentations of left lung, right lung, pericardium, trachea and esophagus was 96.49%, 96.75%, 86.27%, 61.51% and 65.63%, respectively. **Conclusion** An improved D-FCN is put forward in this study and the verification test shows that the improved D-FCN can effectively improve the accuracy of automatic segmentation for radiotherapy planning image of chest, and segment multiple organs synchronously.

Keywords: deep learning; convolution neural network; medical image segmentation; similarity coefficient; radiotherapy

【收稿日期】2018-03-19

【基金项目】国家重点研发计划(2017YFC0113200);广东省科技计划项目(2015B020214002);广州市科技计划项目(201508020105);深圳市高技术产业化扶持计划项目(S2016165100017)

【作者简介】邓金城, E-mail: djc@szyino.com; 彭应林, E-mail: pengyl@sysucc.org.cn (同等贡献)

【通信作者】邓小武, 研究员, 研究方向: 肿瘤放射治疗物理学, E-mail: dengxw@sysucc.org.cn

前言

随着肿瘤放射治疗技术的迅猛发展,放射治疗进入了以图像引导和自适应放疗为代表的精准放疗阶段^[1-2]。精准放疗需要精确确定和勾画放疗的靶区和危及器官,并以在线图像引导治疗照射和后续放射治疗计划的设计与修改,精准杀伤肿瘤细胞的同时更好地保护正常组织器官。在目前的临床放射治疗计划设计实践中,靶区与危及器官的勾画通常由有经验的医师和物理师手工操作,勾画的准确性和效率依赖于医师和物理师的临床经验,勾画者之间的差异性大并且耗时费力。随着计算机自动处理和人工智能技术的发展,基于各种计算机图像处理技术的自动和半自动勾画算法得到了快速发展并部分进入了临床应用,如基于图像灰度、颜色和纹理等特征的分割算法、水平集等非线性扩散算法、基于模板的自动分割算法以及基于人工提取特征的机器学习算法等。但是,这些半自动和自动分割算法仍然不够成熟,尤其在器官和组织之间的边界不明显时,自动分割的效果仍不理想。基于模板的算法依据模板库的构成需要大量的运行时间,图像特征的识别则由于依赖专业经验导致效果不一定理想,同时目前的大部分算法均是针对单个器官或组织的,无法同时对多个器官或组织进行自动分割而降低了工作效率。

近年来,基于深度学习的人工智能技术开始进入包括临床医疗的各种技术领域,其中,深度卷积神经网络(Deep Convolutional Neural Network, DCNN),或称卷积神经网络(CNN)^[3],广泛应用于计算机图像识别并越来越多地应用于医学图像的自动分割技术研究中,如Olaf等^[4]提出的U-net DCNN应用于生物医学图像识别,实现了对生物细胞图像的自动分割。DCNN应用于医学影像分割,通过多层卷积操作可以从低层到高层逐层抽象出图像特征,通过对标定数据集的迭代训练和学习,对自动抽取的特性进行正确分类,从而实现对多结构目标的同时分割^[5-7]。结合训练好的DCNN模型和GPU硬件加速,可以实现对放疗图像的组织器官快速分割,精确地自动勾画靶区及危及器官结构,促进精准放疗技术的进一步发展。

1 材料与方法

1.1 实验图像数据集与计算机工作平台

本研究采用的实验图像数据集采集自先期构建的临床放射治疗病例影像库。依据病种和结构等字段检索该影像库,以肺癌、左肺、右肺、心包、气管和

食道等为条件,检索得到肺癌临床放射治疗病例的影像资料,包括脱敏后的患者胸部CT扫描序列和对应的器官结构轮廓文件。利用医学影像处理技术,解析并提取图像中的各器官结构的轮廓勾画数据,生成CT图像序列上每个切层图像对应的器官勾画图谱。

实验数据集共包含122套病例的胸部CT图像,随机选取其中71套作为训练集,包含8 532张切层图像和器官勾画轮廓图谱,31套CT图像作为验证集,包含5 559张切层图像和器官勾画图谱,20套CT图像作为测试集,包含3 589张切层图像和器官勾画图谱。图1为其中的一个样例,其中图1a为患者CT切层图像,图1b为医师勾画的器官结构图谱。




图1 实验数据集的CT图像和提取的医师勾画轮廓样例
Fig.1 Computed tomography (CT) images in experimental data set and samples of physicians sketching

所有实验均在一台超微4028GR-TR型计算机服务器上完成,其中硬件系统包含两颗Intel E5-2650V4型号的CPU,128 GB的内存,3 TB的SSD硬盘,8块NVIDIA GeForce 1080Ti型号的GPU;软件系统包括Ubuntu Server 16.04操作系统,CUDA8.0和cuDNN6.0,以及最新的Caffe深度学习框架。

1.2 全卷积神经网络(FCN)的优选与改进

采用Shelhamer等^[8]提出的FCN结构,其基本原理为通过卷积化提取图像特征,对特征图像作池化(Pooling)处理进行特征压缩,进行上采样获得与原

图像大小相同的分割图像,再以跳跃结构进行优化输出调整。

实验采用5个公开发表的网络,包括基于VGG16^[9]算法的FCN和Chen等^[10-11]提出的DeepLab系列,以及3个经笔者改造的带孔全卷积神经网络(D-FCN)。以训练数据集进行调优训练,通过比较和综合分析各网络训练模型的自动分割结果与人工勾画结果,获得用于上述胸部影像分割的最优神经网络模型。

(1)实验数据集的预处理:由于实验所选的预训练模型是基于RGB三通道的自然图像训练的结果,而本实验处理的医学图像集为单通道的CT图像,因此需要在数据输入层中将单通道的医学图像构造成三通道的图像数据。本实验采取将原图像数据复制两份的方式,构成虚拟的三通道医学图像数据。

(2)公开发表的模型训练:选取5个以FCN-VGG16算法为基础的适用于图像分割的DCNN,包括FCN 32s、FCN 16s、FCN 8s、DeepLab-largeFOV、DeepLabv2-VGG16等,并将它们在其他自然图像数据集上已训练好的模型作为预训练模型(Pre-trained Model)。修改和优化预训练模型网络,包括更改数据输入层,使其适应医学影像实验数据集的数据格式;结合医学影像和自然图像的差异添加调窗层,本实验根据胸部CT各结构窗值的特性,对[-300,600]窗宽进行三等分,然后等分后的值域为窗宽及中值为窗值分别对每个通道进行调窗;根据实验希望分割的目标类别设置输出层的特征图数量;使用训练集图像对这些神经网络模型进行50万次反复迭代进行调优训练,以获取各网络的最优训练结果。此外,在训练过程中,需要根据训练的实际情况调节和优化训练超参数,包括学习策略、初始学习率、批大小、动量、权值衰减率等,以达到提高模型预测精度的目的。

(3)改造模型的训练:结合FCN的特性和多孔卷积思想,将FCN 32s网络的池化层pool3、pool4和pool5及后续卷积层的部分或全部改造成带孔卷积层,形成所谓的D-FCN,共生成3种经过我们改造的FCN模型,即D-FCN 4s、D-FCN 8s和D-FCN 16s。与上述方法类似地采用相同的实验数据集,并以FCN32s网络模型作为预训练模型对改造的D-FCN模型进行调优训练。

(4)最佳模型验证:训练过程中以每5 000次迭代为一个观察镜像得到一系列训练模型,并以验证集的31例患者的5 559张图像中人工勾画的结构轮廓区域作为预测目标,分别对上述8个深度学习神经

网络训练得到的训练模型进行分割一致性验证,将训练模型的自动分割结果与人工勾画结果进行相似度计算,获取分割结果的相似度系数(Dice),形成各网络不同迭代镜像下的训练模型Dice变化曲线图,通过分析Dice曲线图获取各网络的最佳分割模型。

1.3 神经网络模型自动图像分割测试

以测试集20套3 589张切层图像的人工勾画轮廓区域为预测目标,使用上述优选出的最佳分割模型,对测试集的目标进行自动分割实验,测试各网络模型的有效性和自动分割的准确性,并将自动分割结果与人工勾画结果分别进行全局和单个器官结构的相似度计算,比较相似度系数,并结合自动分割处理的速度对各网络模型进行综合比较评价。

1.4 评价指标

本文使用Dice来评价神经网络模型进行自动分割的效果,即评价图像自动分割结果与医师人工勾画结果的相似性。Dice由以下公式计算:

$$\text{Dice}(P, G) = \frac{2 * |P \cap G|}{|P| + |G|} \quad (1)$$

其中, P 表示自动分割图像的像素集合, G 表示人工勾画图像的像素集合, $|P \cap G|$ 为两个像素集合的交集, $|P| + |G|$ 为两者的共集。Dice的值域为 $[0, 1]$,其数值越高表示自动分割结果越接近人工勾画结果。本文除了计算所有分割目标区域的全局Dice外,还分别计算单个分割目标区域的Dice,从而更全面地评价模型的自动分割效果。

2 结果

实验以71套共8 532张胸部放疗患者的CT切层图像和放疗医师手工勾画的器官图谱作为训练图像集,分别对8种深度神经网络,包括5种公开的网络和3种自行改造的网络,进行了自动图像分割的调优训练。以31套共5 559张CT图像和人工勾画的器官轮廓图谱,组成验证图像集对调优训练得到网络模型进行了一致性验证,并通过Dice分析确定各网络的最佳分割模型。最后以20套3 589张CT图像组成测试集对各网络的最佳分割模型进行有效性和准确性测试,综合评价了各网络模型对放疗定位图像的自动分割性能。

2.1 神经网络模型训练和优选结果

图2展示8种网络训练和验证过程的Dice变化曲线图。各网络模型在训练过程中随迭代次数增加,Dice值的收敛情况显示,与其他各个模型相比,本研究构建的改进型D-FCN 4s模型(图2h)的收敛速度最快,并且具有最好的稳定收敛率。

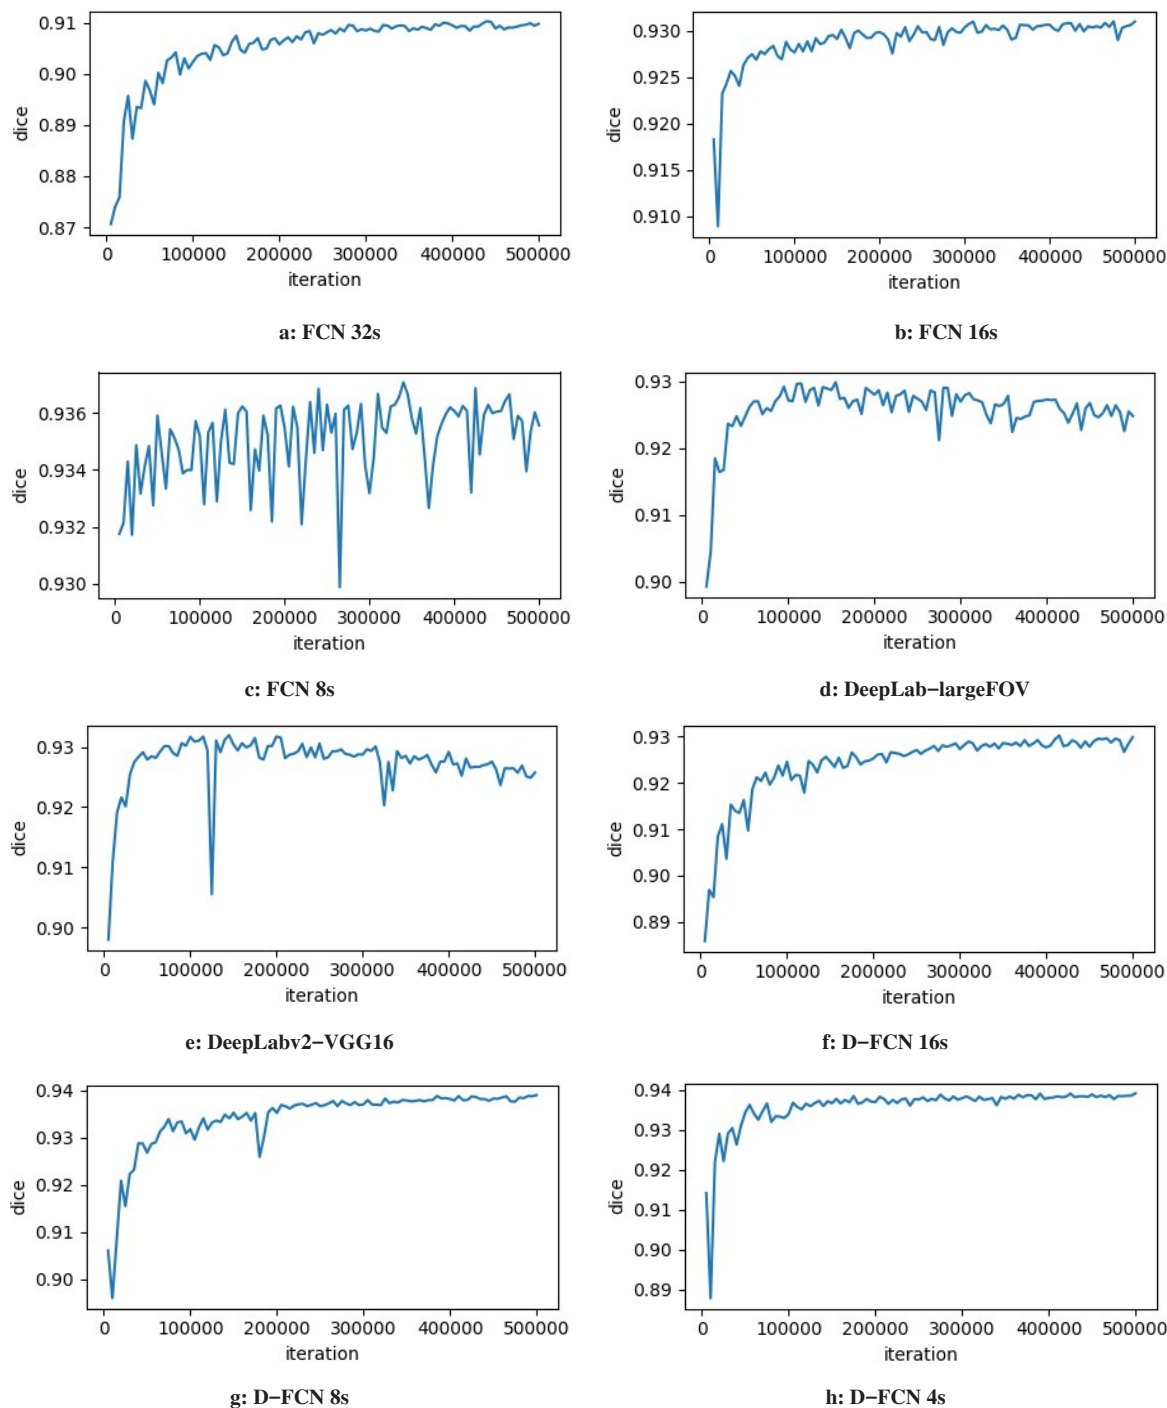


图2 8种网络模型对应的训练效果Dice曲线图

Fig.2 Dice-iteration curves of 8 kinds of network models

FCN: Fully convolutional network; AC: Atrous convolution; D-FCN: Dilation fully convolutional network

表1显示各网络模型的器官自动分割迭代运算统计结果,包括各模型的最佳Dice得分和达到最佳值的迭代次数。实验的所有网络模型均获得了较高的全局最优Dice,自动分割结果均接近专家勾画结果,其中本文提出的D-FCN 4s网络模型相对于其它网络模型具有最高的Dice(93.92%),表明其可以获得比其他模型更优越的自动分割效果。

2.2 自动分割测试结果和分析

表2是利用测试集图像对8种网络模型进行目标结构自动分割的测试结果,表中列出了不同模型对每个测试例的6个目标器官进行一次性自动分割的全局Dice、单个器官结构的最优Dice,以及各模型的自动分割运算时间。

各模型对测试集图像的自动分割结果与对验证集图像的分割结果比较,无论全局的Dice还是单个结构的Dice,均显示D-FCN4s具有优于或相当于其

表1 各网络模型的器官自动分割迭代运算结果
Tab.1 Automatic segmentation results of each network model

Network model	Global Dice/%	Numbers
FCN 32s	90.96	485 000
FCN 16s	93.10	475 000
FCN 8s	93.69	425 000
DeepLab-largeFOV	92.97	115 000
DeepLabv2-VGG16	93.19	145 000
D-FCN 16s	92.98	500 000
D-FCN 8s	93.91	500 000
D-FCN 4s	93.92	500 000

他网络模型的分割效果。自动分割运算耗时方面,D-FCN4s相对于其他网络模型的预测分割速度较慢,是因为其保留了更多的图像细节以获得更精细的分割效果,从Pool3层开始,不再进行下采样操作,导致后续各层特征图像的分辨率较大,从而使运算量大幅增加,预测速度变慢。但在放疗实践中,D-FCN4s平均耗时不到2 min的预测自动勾画速度属于可接受范围。

图3为部分测试例的自动分割勾画与放疗医师手工勾画结果的比较,图中各行不同测试例的比较,每行左侧为医师勾画,右侧为D-FCN4s模型自动勾画,两者勾画的轮廓显示了较好的一致性,尤其对

表2 各网络最佳分割模型的测试结果
Tab.2 Test results of the optimal segmentation model of each network

Network model	Dice/%						Average time/s
	Global	Lung (L)	Lung (R)	Heart	Trachea	Esophageal	
FCN 32s	91.32	93.08	93.73	86.21	37.41	50.68	20
FCN 16s	93.28	95.10	95.54	86.70	50.84	61.41	21
FCN 8s	93.81	95.72	96.19	86.49	57.98	62.78	20
DeepLab-largeFOV	93.33	95.36	95.63	85.74	48.85	63.53	18
DeepLabv2-VGG16	93.51	95.73	95.86	85.01	49.11	64.99	25
D-FCN 16s	93.39	95.23	95.63	86.90	53.34	62.40	21
D-FCN 8s	94.29	96.21	96.46	87.28	60.51	65.36	35
D-FCN 4s	94.38	96.49	96.75	86.27	61.51	65.63	117

部分不易肉眼分辨的闭合食管或气管轮廓,经训练后的D-FCN4s表现了较好的预测分割能力。

3 讨论

临床放射治疗计划设计过程中,放疗医师不仅需要精准地确定和勾画需要治疗的肿瘤靶区,还需要一一勾画可能受到辐射的正常组织和器官(危及器官)。危及器官轮廓勾画的准确与否,决定了放射治疗计划剂量优化的质量,从而直接影响放射治疗的成败或并发症的发生率^[12-14]。然而,人工勾画的精度高度依赖于放疗医师的临床经验并且效率低下^[15-16],因此,基于图像分割的自动器官勾画方法一直是很多学者的研究方向,并且发展了众多不同的图像自动分割和勾画算法模型。但是目前放射治疗临床常用的自动分区和勾画软件,多为基于区域特征如灰度分布的区域分割方法,以及基于经验图谱和形变模型的模板自动勾画方法。前者对于灰度分

布差异不大的区域分割效果不佳,后者则对模板质量敏感,勾画效果也还难以满足临床要求。阴晓娟等^[17]测试基于模板的自动分区勾画软件在自动勾画头颈部放疗危及器官轮廓的几何精度报道中,采用单模板和多模板勾画的平均Dice值分别为0.68±0.20和0.74±0.16($P=0.01$)。彭应林等^[18]对与上述报道相同的自动勾画软件的临床前测试报道中发现,当待勾画图像与模板图像差别较大时,器官轮廓自动勾画的Dice得分仅为0.46~0.89。近年兴起的基于神经网络的深度学习方法,能够自动学习特征并可以在多个层次进行特征识别,在医学图像自动识别和分割的应用中取得了很好的成绩。詹曙等^[19]利用反卷积神经网络方法对前列腺磁共振图像进行自动分割,Dice百分数大于89.75%。李健等^[20]利用多尺度卷积神经网络方法对脑肿瘤磁共振图像进行自动分割的Dice百分数为83.11%。本文利用深度学习的预训练和调优方法,对适用于自然图像分割的FCN和




图3 D-FCN 4s模型对5个测试例的器官轮廓自动勾画结果

Fig.3 Automatic organ segmentations of D-FCN 4s model in 5 test cases

The left images were manually contoured by physicians, and the right images were automatically contoured by D-FCN 4s model.

DeepLab等公开的DCNN模型进行预训练和优选评价,在优选了FCN网络模型基础上结合多孔卷积方法对其进行改进。在对模型进行了充分的调优训练后,以另一组同类图像数据集进行的自动分割测试,结果显示经改进的网络模型获得了相比于其他公开模型更优的器官自动分割效果。研究提出的D-FCN 4s模型对测试图像数据集的各个器官结构自动分割结果,在大部分器官的表现与人工勾画结果非常接近。测试实验显示,对于单个器官结构,该模型在肺和心包的自动分割准确性最高,平均Dice分别达到96%和86%,对气管和食道的自动勾画与人工勾画的相似度相对较低,Dice百分值分别为61.51%和65.63%。由于医师勾画处于闭合状态的食管等器官时也常常有较大分歧,使用这些医生勾画的数据集训练神经网络模型有可能降低了模型的自动识别能力,

同时,医师勾画的个体差异也会在一定程度上降低了自动勾画测试的一致性。这也提示我们,在使用机器学习类人工智能自动勾画工具时,一方面需要对用于深度学习模型的数据进行标注和优选外,使用自动勾画的结果仍需要由医师进行确认和修改。另外,本实验研究结果中,模型对一些体积较小的器官结构的识别分割能力相对较差,表明进行分割训练优化时,调试的参数和迭代深度可能需要进一步加强,寻找更合适的网络参数和迭代终点以提高训练模型的自动识别能力和分割精度。这些工作应该是我们后续研究需要解决的问题。

综上所述,本文将基于自然图像分割的DCNN引入医学影像分割,并建立了一种有效提高图像目标预测分割能力的改进型D-FCN,结合GPU硬件加速,进一步优化网络参数设置与训练水平可望实现胸部放疗计划图像的危及器官快速分割,为实现将来的放疗计划自动设计建立基础。

【参考文献】

- [1] 吴宜灿, 贾婧, 曹瑞芬, 等. 质子调强放射治疗计划系统 KylinRay-IMPT[J]. 中国医学物理学杂志, 2017, 34(6): 541-545.
WU Y C, JIA J, CAO R F, et al. Proton modulated radiation therapy planning system KylinRay-IMPT[J]. Chinese Journal of Medical Physics, 2017, 34(6): 541-545.
- [2] 林奈尔, 赵晋华, 邢岩. PET/CT在肺癌精准放疗中的应用进展[J]. 国际医学放射学杂志, 2017, 40(2): 161-164.
LIN N E, ZHAO J H, XING Y. Progress of PET/CT in lung cancer precision radiotherapy[J]. International Journal of Medical Radiology, 2017, 40(2): 161-164.
- [3] LECUN Y, BOSER B, DENKER J S, et al. Backpropagation applied to handwritten zip code recognition[J]. Neural Comput, 1989, 1(4): 541-551.
- [4] OLAF R, PHILIPP F, THOMAS B. U-Net: convolution networks for biomedical image segmentation[G]. Medical Image Computing and Computer-Assisted Intervention (MICCAI), 2015: 234-241.
- [5] CHARBONNIER J P, RIKXOORT E M, SETIO A A, et al. Improving airway segmentation in computed tomography using leak detection with convolutional networks[J]. Med Image Anal, 2017, 36: 52.
- [6] FU H, XU Y, WONG D W, et al. Retinal vessel segmentation via deep learning network and fully-connected conditional random fields[C]. IEEE International Symposium on Biomedical Imaging, 2016: 698-701.
- [7] ZILLY J, BUHMANN J M, MAHAPATRA D. Glaucoma detection using entropy sampling and ensemble learning for automatic optic cup and disc segmentation[J]. Comput Med Imaging Graph, 2016, 55: 28-41.
- [8] SHELHAMER E, LONG J, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal Machine Intell, 2017, 39(4): 640-651.
- [9] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[J]. Comput Sci, 2014.
- [10] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. Semantic image segmentation with deep convolutional nets and fully connected CRFs[J]. Comput Sci, 2014(4): 357-361.

- [11] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs[J]. IEEE Trans Pattern Anal Machine Intell, 2018, 40(4): 834-848.
- [12] PENG Y L, CHEN L, DENG X W, et al. Interobserver variations in the delineation of target volumes and organs at risk and their impact on dose distribution in intensity-modulated radiationtherapy for nasopharyngeal carcinoma[J]. Oral Oncol, 2018, 82(1): 1-7.
- [13] NELMS B E, TOMÉ W A, ROBINSON G, et al. Variations in the contouring of organs at risk: test case from a patient with oropharyngeal cancer[J]. Int J Radiat Oncol Biol Phys, 2012, 82(1): 368-378.
- [14] LOBEFALO F, BIGNARDI M, REGGIORI G, et al. Dosimetric impact of inter-observer variability for 3D conformal radiotherapy and volumetric modulated arc therapy: the rectal tumor target definition case[J]. Radiat Oncol, 2013, 8(1): 176-185.
- [15] FENG M, DEMIROZ C, VINEBERG K A, et al. Normal tissue anatomy for oropharyngeal cancer: contouring variability and its impact on optimization[J]. Int J Radiat Oncol Biol Phys, 2012, 84(2): e245-e249.
- [16] RAUDASCHL P F, ZAFFINO P, SHARP G C, et al. Evaluation of segmentation methods on head and neck CT: auto-segmentation challenge 2015[J]. Med Phys, 2017, 44(5): 2020-2036.
- [17] 阴晓娟, 胡彩容, 张秀春, 等. 基于图谱库的ABAS自动勾画软件在头颈部肿瘤中的可行性研究[J]. 中华放射肿瘤学杂志, 2016, 25(11): 1233-1237.
- YIN X J, HU C R, ZHANG X C, et al. The feasibility study of atlas-based auto-segmentation (ABAS) software in head-and-neck cancer[J]. Chinese Journal of Radiation Oncology, 2016, 25(11): 1233-1237.
- [18] 彭应林, 游雁, 韩非, 等. ABAS软件勾画OAR临床前测试重要性研究[J]. 中华放射肿瘤学杂志, 2016, 25(6): 609-614.
- PENG Y L, YOU Y, HAN F, et al. Commissioning of an atlas-based auto-segmentation software for application in organ contouring of radiotherapy planning[J]. Chinese Journal of Radiation Oncology, 2016, 25(6): 609-614.
- [19] 詹曙, 梁植程, 谢栋栋. 前列腺磁共振图像分割的反卷积神经网络方法[J]. 中国图象图形学报, 2017, 22(4): 516-522.
- ZHAN S, LIANG Z C, XIE D D. Deconvolutional neural network for prostate MRI segmentation[J]. Journal of Image and Graphics, 2017, 22(4): 516-522.
- [20] 李健, 罗蔓, 罗晓, 等. 基于多尺度卷积神经网络的磁共振成像脑肿瘤分割研究[J]. 中国医学装备, 2016, 13(2): 25-28.
- LI J, LUO M, LUO X, et al. Research on the application of brain tumor segmentation of MRI based on multi-scale convolutional neural networks[J]. China Medical Equipment, 2016, 13(2): 25-28.

(编辑:黄开颜)