

利用深度反卷积神经网络自动勾画放疗危及器官

门阔,戴建荣

国家癌症中心/中国医学科学院北京协和医学院肿瘤医院,北京 100021

【摘要】目的:勾画危及器官是放射治疗中非常重要的常规工作。然而,目前的人工勾画非常耗时,而且依赖于医生的知识和经验。为此,本研究提出一种深度反卷积神经网络,用于自动和精确地勾画危及器官。**方法:**深度反卷积神经网络是一个用于自动分割的端到端框架。实验使用了230例头颈部患者的数据,在其中随机选择了184例作为训练集,用于调制自动分割模型的参数,其余46例用作测试集评估方法的性能。用于分割的危及器官包括脑干、脊髓、左腮腺、右腮腺、左颞叶、右颞叶、甲状腺、喉、气管9个危及器官。自动分割精度的量化指标使用戴斯相似性系数和豪斯多夫距离。**结果:**所有危及器官自动分割的戴斯相似性系数值均在0.70以上(平均值为0.81),豪斯多夫距离值在5.0 mm内(平均值为4.3 mm),表明本研究提出的自动分割方法能准确地分割危及器官。**结论:**利用深度反卷积神经网络建立了一种自动分割危及器官的方法,可以得到较准确的结果,为放射治疗流程自动化提供了技术支持。

【关键词】深度学习;自动分割;放射治疗;危及器官勾画;深度反卷积神经网络

【中图分类号】R815.6

【文献标志码】A

【文章编号】1005-202X(2018)03-0256-04

Automatic segmentation of organs at risk in radiotherapy using deep deconvolutional neural network

MEN Kuo, DAI Jianrong

National Cancer Center/Cancer Hospital, Chinese Academy of Medical Sciences and Peking Union Medical College, Beijing 100021, China

Abstract: Objective The segmentation of organs-at-risk (OAR) is essential to radiotherapy. However, the current manual segmentation is time-consuming and dependent on the physicians' knowledge and experience. Herein deep deconvolutional neural network (DDNN) is proposed for the automatic and accurate segmentation of OAR. **Methods** DDNN is an end-to-end framework for automatic segmentation. The data of 230 head and neck patients were selected in this study. Among all the selected patients, 184 cases were randomly chosen as training set used for adjusting the parameters of automatic segmentation model, and the other 46 cases were regarded as test set used for evaluating the performance of the proposed method. The OAR to be segmented included brainstem, spinal cord, left parotid, right parotid, left temporal lobe, right temporal lobe, thyroid gland, larynx and trachea. Dice similarity coefficient and Hausdorff distance were used to measure the accuracy of segmentation. **Results** All the Dice similarity coefficient values of OAR were higher than 0.70, with a mean value of 0.81 and the Hausdorff distance values were within 5.0 mm, with a mean value of 4.2 mm, which demonstrated that the proposed method could segment OAR accurately. **Conclusion** The DDNN-based automatic method for OAR segmentation achieves an accurate segmentation result, providing technical supports for the automation of radiotherapy.

Keywords: deep learning; automatic segmentation; radiotherapy; organs-at-risk segmentation; deep deconvolutional neural network

前言

【收稿日期】2018-01-25

【基金项目】国家自然科学基金(11605291, 11475261);国家重大研发计划(2016YFC0904600)

【作者简介】门阔,博士,助理研究员,研究方向:图像引导放射治疗, E-mail: menkuo126@126.com

【通信作者】戴建荣,博士,二级研究员,研究方向:放疗系统的优化、术中放疗技术和图像引导放疗等, E-mail: dai_jianrong@cicams.ac.cn

现代放射治疗技术,如调强放射治疗、容积调强放射治疗和螺旋断层放射治疗等,能够为肿瘤靶区实施高度适形的剂量分布,从而降低危及器官的辐射剂量,以减少辐射诱导的毒性^[1-2]。制定精准的放射治疗计划,需要在计划CT上准确勾画危及器官,才能充分实现先进放疗技术所带来的益处。然而有很多报道指出^[3-6],不同医生之间勾画的危及器官存在很大的差异,这些差异会导致剂量评估不准确,误导治疗计划的制定,影响放射治疗的疗效。而且,由

于通常需要由医生手动勾画所有的危及器官,这项工作非常耗力费时。

因此,一种完全自动的危及器官勾画方法不仅可以减轻医生的工作量,而且可能提高勾画的准确性、一致性和可重复性。目前临床应用的主要是基于Atlas的自动分割方法^[7-12],但这种方法需要对不同体型的患者分别建立模型,缺乏普适性,另外,由于需要进行形变配准,这种方法也非常耗时。深度学习方法是快速、准确分割的一个有效工具,它已经成功地应用于计算机视觉方面的任务,如图像分类^[13-14]、目标检测^[15]和语义分割^[15-17]等。作为深度学习最流行的算法之一,深度卷积神经网络^[14]由多个卷积层和池化层组成,可以提取多层次的视觉特征,用于自动预测。

本课题组之前利用深度反卷积神经网络(Deep Deconvolutional Neural Network, DDNN)^[18]自动勾画了鼻咽癌的靶区,并得到了较为准确的结果。而放射治疗危及器官的数量更多,本研究基于之前提出的DDNN算法,研究其在自动分割危及器官方面的效果。

1 材料和方法

1.1 实验数据

实验使用的CT图像来自2011年1月~2017年1月期间接受放射治疗的230名头颈部肿瘤患者。所有患者均采用仰卧位,使用头颈肩热塑性面罩固定。图像采集使用西门子Somatom Definition AS 40 CT模拟定位机(Siemens Healthcare, Forchheim, Germany)或飞利浦Brilliance Big Bore CT模拟定位机(Philips Healthcare, Best, the Netherlands)。图像重建分辨率为512×512,层厚为3.0 mm。医生使用Pinnacle计划系统(Philips Radiation Oncology Systems, Fitchburg, WI, USA)勾画肿瘤靶区和危及器官。

1.2 自动分割方法

本研究使用DDNN自动分割危及器官,该方法流程如图1所示,首先使用训练集得到一个分割模型,然后使用该模型对测试集进行自动分割,验证该方法的准确性。方法的细节见本课题组之前发表的论文^[18]。

1.3 自动分割实验

从230组数据中随机选出184组作为训练集,用来调整DDNN模型的参数,其余46组数据作为测试集来评估模型的性能。分割的危及器官包括脑干、脊髓、左腮腺、右腮腺、左颞叶、右颞叶、甲状腺、喉、气管等。我们使用Caffe^[19]深度学习框架来实现模型的培训、评估、错误分析和可视化。在实验中,我们

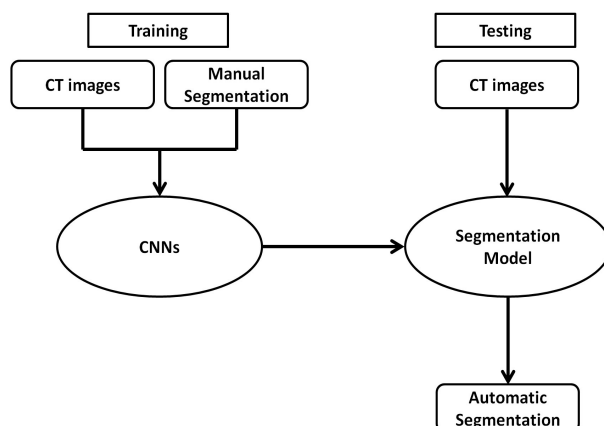


图1 自动分割方法的流程

Fig.1 Flowchart of deep deconvolutional neural network (DDNN)-based automatic segmentation method

采用一些数据增强技术,如随机裁剪、翻转等操作。利用随机梯度下降法对函数的损失进行优化。我们将初始学习速率设为0.000 1,学习速率衰减因子为0.000 5,衰减步长为2 000,最大迭代次数设为5万次。实验使用了NVIDIA TITAN XP GPU。

1.4 评估方法

使用戴斯相似性系数(Dice Similarity Coefficient, DSC)和豪斯多夫距离(Hausdorff Distance, HD)来量化分析自动分割的精度。

DSC的计算如公式(1)所示:

$$DSC(A, B) = \frac{2|A \cap B|}{|A| + |B|} \quad (1)$$

其中, A 代表参考的分割区域, B 代表自动分割区域, $|A \cap B|$ 代表 A 和 B 的交集。DSC的数值范围是0~1,数值越高分割效果越好,0代表两者没有交集,1代表两者完全重合。

A 和 B 的豪斯多夫距离 $H(A, B)$ 的计算如公式(2)所示:

$$H(A, B) = \max(h(A, B), h(B, A)) \quad (2)$$

其中, $h(A, B)$ 表示集合 A 中的点与集合 B 的距离的最大值,其表达式为:

$$h(A, B) = \max_{a \in A} (\min_{b \in B} \|a - b\|) \quad (3)$$

豪斯多夫距离 $H(A, B)$ 越小,表示 A 和 B 的交集越大,自动分割越精确。

2 结果

2.1 精度

Zijdenbos等^[20]提出 $DSC > 0.7$ 则表示两种重复度高,分割效果较好。表1列出了所有测试集危及器官自动分割精度的量化评价指标(DSC和HD)值,自动

分割的DSC值均在0.70以上(平均值为0.81),HD值在5.0 mm内(平均值为4.3 mm),平均值表明本文提出的方法可以很好地分割危及器官。对于脑干和气管,自动分割的准确度最高,DSC达到0.88,这是因为这两个危及器官的低对比分辨率高,在CT上能够清楚地被识别。而脊髓的DSC数值虽然低,但HD值仅为3.6 mm,也说明分割精度较高,其DSC数值低是因为脊髓的体积较小,导致DSC计算数值较低。

表1 自动勾画准确性的量化结果($\bar{x}\pm s$)
Tab.1 Quantitative results of the automatic segmentation($Mean\pm SD$)

OAR	DSC	HD/mm
Brainstem	0.88±0.01	3.6±1.3
Spinal cord	0.70±0.05	3.6±1.2
Left parotid	0.81±0.03	4.3±1.3
Right parotid	0.80±0.03	4.3±1.1
Left temporal lobe	0.82±0.03	4.8±1.7
Right temporal lobe	0.81±0.04	5.0±1.6
Thyroid gland	0.78±0.03	4.9±1.7
Larynx	0.83±0.04	4.5±1.1
Trachea	0.88±0.04	3.5±1.7

OAR: Organs-at-risk; DSC: Dice similarity coefficient; HD: Hausdorff distance

图2显示了自动分割的可视化结果图,在这些例子中,自动分割的轮廓与参考轮廓有较好的一致性。

2.2 效率

使用DDNN自动分割1个患者CT数据大概需要21 s,较人工勾画大大提高了效率。

3 结论及讨论

危及器官的勾画是放射治疗的一个重要步骤。然而,大量研究表明不同医生的勾画存在较大的差异,如果能够提高勾画的精度,则有望进一步改善放射治疗的效果。本研究提出了使用DDNN来自动分割危及器官,该网络是端到端的,可以提高效率,减轻医生的工作量。根据文献[12],DSC大于0.70则表示分割效果较好,本研究的结果均优于此基准,表明该模型具有良好的性能,并且有潜力提高勾画的准确性和一致性。同时,我们观察到自动分割的结果与参考值是有差别的,临床应用时需要医生认真的核查,并做必要的修正。

本研究的自动分割是在CT图像上完成的,但由于CT的软组织对比度差,会影响危及器官自动勾画的精度。而磁共振成像技术可以提高软组织的对比度,进一步将研究把CT与核磁(或其他类型的)成像方法相结合,以提高分割的准确性。另外,继续增加训练集的数据可以包括更多的患者特性,从而使模型更加稳定。




图2 自动分割结果
Fig.2 Results of automatic segmentation

Red lines: Reference segmentation; Blue line: Automatic segmentation; a: Temporal lobe and brainstem; b: Temporal lobe and brainstem; c: Parotid and spinal cord; d: Parotid and spinal cord; e: Larynx and spinal cord; f: Larynx and spinal cord; g: Trachea, thyroid gland, and spinal cord; h: Trachea, thyroid gland, and spinal cord

总之,本研究建立了一种自动分割危及器官的方法,并得到了较高的分割精度,为放射治疗流程自

动化和规范化提供了技术支持。

【参考文献】

- [1] TRAN A, ZHANG J, WOODS K, et al. Treatment planning comparison of IMPT, VMAT and 4 π radiotherapy for prostate cases [J]. *Radiat Oncol*, 2017, 12(1): 10.
- [2] MURTAZA G, TOFTEGAARD J, KHAN E U, et al. Volumetric modulated arc therapy with dynamic collimator rotation for improved multileaf collimator tracking of the prostate [J]. *Radiother Oncol*, 2016, 122(1): 109-115.
- [3] LI X A, TAI A, ARTHUR D W, et al. Variability of target and normal structure delineation for breast cancer radiotherapy: an RTOG multi-institutional and multiobserver study[J]. *Int J Radiat Oncol Biol Phys*, 2009, 73(3): 944-951.
- [4] HARDCASTLE N, TOMÉ W A, CANNON D M, et al. A multi-institution evaluation of deformable image registration algorithms for automatic organ delineation in adaptive head and neck radiotherapy [J]. *Radiat Oncol*, 2012, 7(1): 90.
- [5] 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.
- [6] FENG M U, DEMIROZ C, VINEBERG K A, et al. Intra-observer variability of organs at risk for head and neck cancer: geometric and dosimetric consequences[J]. *Int J Radiat Oncol Biol Phys*, 2010, 78(3): S444-S445.
- [7] ALJABAR P, HECKEMANN R A, HAMMERS A, et al. Multi-atlas based segmentation of brain images: atlas selection and its effect on accuracy[J]. *Neuroimage*, 2009, 46(3): 726-738.
- [8] HAN X, HOOGEMAN M S, LEVENDAG P C, et al. Atlas-based auto-segmentation of head and neck CT images [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer-Verlag, 2008: 434-441.
- [9] BUCKNER R L, HEAD D, PARKER J, et al. A unified approach for morphometric and functional data analysis in young, old, and demented adults using automated atlas-based head size normalization: reliability and validation against manual measurement of total intracranial volume[J]. *Neuroimage*, 2004, 23(2): 724-738.
- [10] ANDREASEN N C, RAJARETHINAM R, CIZADLO T, et al. Automatic atlas-based volume estimation of human brain regions from MR images[J]. *J Comput Assist Tomogr*, 1996, 20(1): 98-106.
- [11] COUPÉ P, MANJÓN J V, FONO V, et al. Patch-based segmentation using expert priors: application to hippocampus and ventricle segmentation[J]. *Neuroimage*, 2011, 54(2): 940-954.
- [12] ARTAECHAVARRIA X, MUNOZBARRUTIA A, ORTIZDESOLORZANO C. Combination strategies in multi-atlas image segmentation: application to brain MR data[J]. *IEEE Trans Med Imaging*, 2009, 28(8): 1266-1277.
- [13] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks [C]//International Conference on Neural Information Processing Systems. Curran Associates Inc, 2012, 25: 1097-1105.
- [14] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]//Computer Vision & Pattern Recognition, 2014.
- [15] GIRSHICK R, DONAHUE J, DARRELL T, et al. Rich feature hierarchies for accurate object detection and semantic segmentation [C]. *Proceedings of the IEEE conference on Computer Vision And Pattern Recognition*, 2014: 580-587.
- [16] 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 Mach Intell*, 2018, 40(4): 834-848.
- [17] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]. *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2015: 3431-3440.
- [18] MEN K, CHEN X Y, ZHANG Y, et al. Deep deconvolutional neural network for target segmentation of nasopharyngeal cancer in planning CT images[J]. *Front Oncol*, 2017, 7: 315.
- [19] JIA Y, SHELHAMER E, DONAHUE J, et al. Caffe: convolutional architecture for fast feature embedding[C]. *Proceedings of the 22nd ACM international conference on Multimedia*. ACM, 2014: 675-678.
- [20] ZIJDENBOS A P, DAWANT B M, MARGOLIN R A, et al. Morphometric analysis of white matter lesions in MR images: method and validation[J]. *IEEE Trans Med Imaging*, 1994, 13(4): 716-724.

(编辑:薛泽玲)