

基于2D/3D U-plus-net的心脏自动分割

宋宇宸¹, 彭昭¹, 吴昊天², 周解平³, 皮一飞⁴, 陈志¹, 裴曦¹

1. 中国科学技术大学放射医学物理中心, 安徽 合肥 230027; 2. 安徽慧软科技有限公司, 安徽 合肥 230000; 3. 中国科学技术大学附属第一医院放疗科, 安徽 合肥 230001; 4. 郑州大学第一附属医院放疗科, 河南 郑州 450052

【摘要】目的:利用2D/3D U-plus-net提高心脏自动分割的准确率。**方法:**收集郑州大学第一附属医院60例患者胸部扫描CT图像(数据A)及中国科学技术大学附属第一医院45例患者胸部扫描CT图像(数据B)。基于改进的AlexNet将CT图像分为两类:心脏CT图像和无心脏CT图像。在2D/3D U-net拓扑结构基础上,通过减小网络深度、在长连接中增加新节点、增加解码器中卷积次数的方法,得到改进后的2D/3D U-plus-net;将靠近腹部的CT图像(图像张数由预实验决定)输入3D U-plus-net,其余图像输入2D U-plus-net;采用5倍交叉验证法对模型进行训练及测试。最后通过Dice系数、HD95和平均表面距离(MSD)评估自动分割精度。**结果:**数据A自动分割的Dice系数为 0.941 ± 0.012 , MSD为 (3.918 ± 0.201) mm, HD95为 (5.863 ± 0.561) mm;数据B自动分割的Dice系数为 0.934 ± 0.014 , MSD为 (4.112 ± 0.320) mm, HD95为 (6.035 ± 0.659) mm。**结论:**基于2D/3D U-plus-net的分割方法提高了心脏自动分割准确率。

【关键词】心脏; AlexNet; 2D U-plus-net; 3D U-plus-net; 自动分割

【中图分类号】R318; R445

【文献标志码】A

【文章编号】1005-202X(2021)09-1172-07

Automatic heart segmentation based on 2D/3D U-plus-net

SONG Yuchen¹, PENG Zhao¹, WU Haotian², ZHOU Jieping³, PI Yifei⁴, CHEN Zhi¹, PEI Xi¹

1. Center of Radiological Medical Physics, University of Science and Technology of China, Hefei 230027, China; 2. Anhui Wisdom Technology Co., Ltd, Hefei 230000, China; 3. Department of Radiation Oncology, the First Affiliated Hospital of University of Science and Technology of China, Hefei 230001, China; 4. Department of Radiation Oncology, the First Affiliated Hospital of Zhengzhou University, Zhengzhou 450052, China

Abstract: Objective To improve the accuracy of automatic heart segmentation using 2D/3D U-plus-net. **Methods** The chest CT images of 60 patients from the First Affiliated Hospital of Zhengzhou University (Data A) and the chest CT images of 45 patients from the First Affiliated Hospital of University of Science and Technology of China (Data B) were collected. A modified AlexNet was used to divide all CT images into two types, namely heart CT images and no-heart CT images. Based on the topological structure of 2D/3D U-net, a modified 2D/3D U-plus-net was obtained by reducing network depth, increasing nodes in a long connection and increasing the convolution number of the decoder. The heart CT images near the abdomen (the number of CT images was determined by pre-experiment) were input into 3DU-plus-net, while the other heart CT images were input into 2D U-plus-net. The obtained model was trained and tested by 5-fold cross-validation method. Finally, the accuracy of automatic heart segmentation was evaluated by Dice coefficient, HD95 and mean surface distance. **Results** The Dice coefficient, mean surface distance and HD95 of automatic heart segmentation on Data A were 0.941 ± 0.012 , (3.918 ± 0.201) mm and (5.863 ± 0.561) mm, respectively, while those of automatic heart segmentation on Data B were 0.934 ± 0.014 , (4.112 ± 0.320) mm and (6.035 ± 0.659) mm, respectively. **Conclusion** The automatic segmentation method based on 2D/3D U-plus-net improves the accuracy of automatic heart segmentation.

Keywords: heart; AlexNet; 2D U-plus-net; 3D U-plus-net; automatic segmentation

【收稿日期】2021-03-02

【基金项目】安徽省自然科学基金(1908085MA27);安徽省重点研究与开发计划(1804a09020039)

【作者简介】宋宇宸, 硕士, 研究方向:人工智能在医学影像与放射治疗中的应用, E-mail: songycyc@mail.ustc.edu.cn

【通信作者】裴曦, 博士, 副教授, 研究方向:医学影像和放疗物理、辐射探测和辐射防护剂量学以及蒙特卡罗计算方法在核科学技术上的应用, E-mail: xpei@ustc.edu.cn

前言

近年来,胸部恶性肿瘤(乳腺癌等)发病率逐年增加,放疗已被广泛应用于胸部恶性肿瘤的治疗。其中,心脏作为最重要的胸部危及器官,其照射剂量必须受到严格限制。因此,心脏分割是胸部恶性肿瘤放疗的关键环节。然而,由于心脏周围解剖结构复杂,心脏分

割仍具有很大挑战。目前,临床使用的主要分割方法是医生手动分割,可获得精确的结果,但十分耗时。手动分割的局限性促使研究人员继续开发用于心脏分割的辅助分割方法。目前的器官辅助分割方法主要有基于统计模型的方法^[1-2]、基于图谱的方法^[3-5]以及基于深度学习的方法,包括基于U-net的方法^[6]、基于FCN的方法^[7-9]、基于CNN的方法^[10-12]及基于其他网络的方法^[13-14]等。其中,基于深度学习的方法因其准确率高、效率高而被广泛应用。U-net^[7]最初在MICCAI 2015被提出,并成为器官分割任务的主要基础网络,该网络改进了全卷积网络^[15],完善了扩展路径,将多通道卷积与特征金字塔网络的结构相结合,大大提高了器官分割的准确率;3D U-net在U-net基础上增加医学影像的三维信息,在小体积器官的分割任务中表现出色^[16]。深度学习为医学图像处理做出很大贡献,在图像分割任务中表现最优。但是这些方法对心脏的下边缘部分的分割精度不够高。目前已有不少研究者进行基于U-net的心脏自动分割^[17-18],但2D U-net和3D U-net在心脏的不同位置表现不同:在深度方向靠近腹部的CT图像上,3D U-net表现更优;在其余心脏CT图像上,2D U-net表现更优。因此,本研究提出将同一患者不同位置心脏CT图像输入不同网络进行训练的方法,利用改进后的AlexNet^[19](命名为modified-AlexNet)对胸部CT图像进行分类,准确挑选出含有心脏的CT图像;对2D U-net/3D U-net网络结构进行改进,改进后的网络命名为2D/3D U-plus-net,将心脏不同位置的图像分别用2D U-plus-net和3D U-plus-net分割。此方法可充分利用2D/3D U-net的优点并避免其缺点。

1 材料与方法

1.1 数据

收集郑州大学第一附属医院60例接受放疗的乳腺癌患者的胸部扫描CT图像,记为数据A;中国科学

技术大学附属第一医院的45例接受放疗的乳腺癌患者的胸部扫描CT图像,记为数据B。CT层厚为5 mm,分辨率为0.977 mm×0.977 mm,传输到Pinnacle规划系统(Philips Radiation Oncology Systems, Fitchburg, WI, USA)。

危及器官由临床经验丰富的放疗科医生进行手动分割。由于不同医院分割习惯不同,在满足危及器官分割标准的条件下,临床分割的器官轮廓有紧贴器官边缘和器官外扩两种,本研究中,数据A采用紧贴器官边缘的分割方法,数据B采用器官外扩的分割方法。为了避免因医生分割习惯不同而造成神经网络预测结果与医生分割结果的偏差,并证明本文方法在不同医院数据集上的通用性,本研究在两个不同医院的数据集上分别进行分割。

1.2 心脏分割方法

1.2.1 分割前工作 对数据A和数据B的CT图像进行预处理。去除所有患者CT图像的金属伪影;选取窗宽、窗位,提高图像对比度;以身体中心为裁剪中心,将图像裁剪至[256, 256];将含有心脏的CT图像标记为1(记为心脏CT),不含心脏的CT图像标记为0(记为无心脏CT),用于图像分类;利用RS文件提取每张心脏CT对应心脏掩膜,用于图像分割。

由于心脏在靠近腹部处体积较小,且与其他危及器官(如肝脏)距离近,2D网络难以分割,而3D网络可以利用层间三维信息确保轮廓连续性,因而3D网络表现更优;心脏在靠近头部处体积较大,且与其他危及器官距离远,2D网络足以区分,而3D网络会造成信息冗余,并占用更大内存,因而2D网络表现更优。因此,本研究提出一种将心脏不同位置CT图像输入不同神经网络进行分割的方法(图1)。

为确定 m 的值,使得最终分割结果最优,在数据A和数据B上分别进行预实验:搭建2D U-net模型^[7],并将其网络层改写为3D层,形成与其拓扑结构

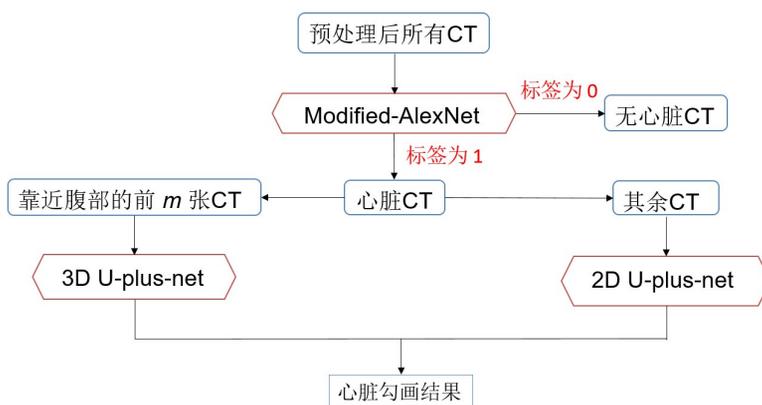


图1 基于2D/3D U-plus-net的心脏自动分割方法

Fig.1 Flowchart of automatic heart segmentation based on 2D/3D U-plus-net

相同的3D U-net模型,基于这两个模型做心脏分割对照实验。在数据A中随机选取48例作为训练集,其余12例作为测试集;在数据B中随机选取36例作为训练集,其余9例作为测试集。将两个训练集患者的心脏CT图像分别输入2D U-net和3D U-net进行训练,并用测试集患者作测试。将2D U-net和3D U-net在所有心脏CT图像上的分割Dice系数作成折线图,两条折线的交点即为 m 值。

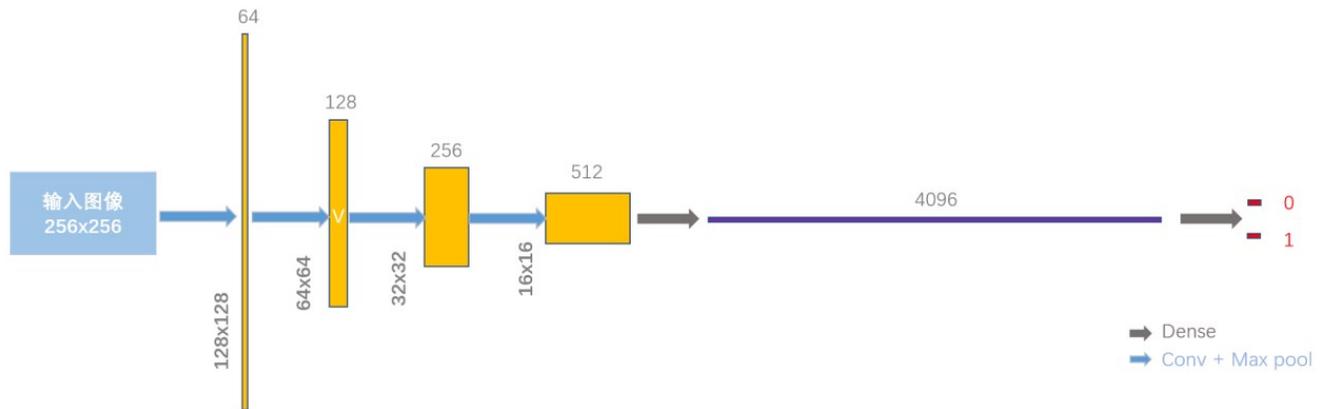


图2 改进后的 AlexNet 网络结构

Fig.2 Modified-AlexNet architecture

将训练集患者CT图像及标签经预处理后随机打乱,输入 modified-AlexNet 进行训练,并用验证集验证。将测试集患者CT图像及标签经预处理后输入训练好的 modified-AlexNet,输出标签。标签为1表示心脏CT图像,标签为0表示无心脏CT图像。

1.2.3 心脏自动分割 对U-net的拓扑结构进行改进,主要包括以下3点。(1)减小网络深度。编码器和解码器是U-net网络的核心,其作用分别是特征提取与图像重建。编码器和解码器中模块个数决定网络深度,深度越大,特征提取越精细,但同时也会造成信息冗余。因此,针对不同的图像处理任务,需选择不同的网络深度。本研究发现当编码器中特征提取模块和解码器中图像重建模块的个数为3个时,网络模型训练效果最好。(2)传统U-net网络特征提取模块和图像重建模块的网络层数相同,而本研究在每个图像重建模块中添加一个Convolution层,使其相比对应的特征提取模块多做一次卷积,从而提高网络的局部感知能力。(3)传统U-net网络中,第一层编码器和解码器由一个长连接相连,本研究在此长连接中增加两个神经节点,综合长连接和短连接,充分利用不同深度的图像特征。

改进后的网络命名为U-plus-net,其结构如图3所示(输入图像以适用于2D U-plus-net的CT图像为例)。基于此拓扑结构分别添加2D与3D网络层,即

1.2.2 胸部CT图像分类 对AlexNet进行改进,改进后网络结构(modified-AlexNet)如图2所示。网络包括4个卷积模块和1个Dense模块;每个卷积模块包括2个Convolution层和1个Max-pooling层,激活函数采用Relu;Dense模块包括1个Flatten层、3个Dense层和2个Dropout层;激活函数采用Sigmoid,损失函数采用Binary_crossentropy,优化器采用RM-Sprop。

构成2D U-plus-net和3D U-plus-net。编码器包含3个重复的特征提取模块,每个特征提取模块由2个Convolution层和1个Max-pooling层组成;解码器包含3个重复的图像重建模块,每个图像重建模块由3个Convolution层和1个Up-sampling层组成;在最后一个图像重建模块中添加1个Convolution层;采用Concatenate层连接特征图大小相同的特征提取模块与图像重建模块。激活函数采用Relu和Sigmoid,损失函数采用Dice系数计算方法,优化器采用Adam。网络在Keras框架上搭建,以TensorFlow为后端。

应用本研究的胸部CT图像分类方法挑选出心脏CT图像,按UID降序进行排序。将排序后的前 m 张心脏CT图像及对应掩膜输入3D U-plus-net,其余心脏CT图像及对应掩膜输入2D U-plus-net。采用5倍交叉验证法对网络进行训练及测试。将数据A和数据B各均分为5组,每次取其中1组作为测试集,1组作为验证集,其余4组作为训练集,进行5次训练;取5次测试结果的平均值作为最终结果。

1.3 评估方法

本研究采用Dice系数,平均表面距离(Mean Surface Distance, MSD)和HD95(Hausdorff距离)来评估自动分割结果^[20]。

Dice系数计算公式为:

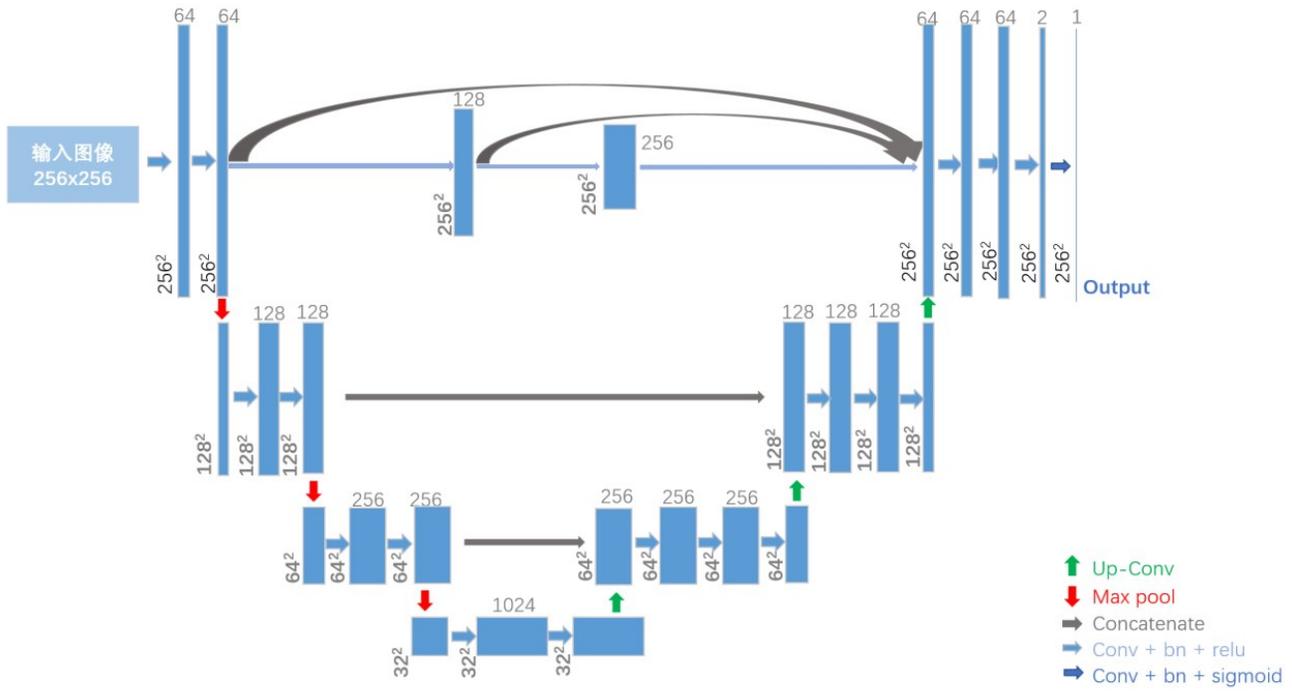


图3 U-plus-net网络结构(输入图像以适用于2D U-plus-net的CT图像为例)

Fig.3 U-plus-net architecture (The input image takes CT images that apply to 2D U-plus-net as an example)

$$Dice = \frac{2|X \cap Y|}{|X| + |Y|} \quad (1)$$

其中, X 和 Y 分别为轮廓的真值与预测值。

有向平均Hausdorff测度定义为轮廓 X 中的所有点到轮廓 Y 的距离的平均值:

$$\vec{d}_{H,avg}(X, Y) = \frac{1}{|X|} \sum_{x \in |X|} \min_{y \in |Y|} d(x, y) \quad (2)$$

MSD定义为两次有向平均Hausdorff测度的平均值:

$$MSD = \frac{\vec{d}_{H,avg}(X, Y) + \vec{d}_{H,avg}(Y, X)}{2} \quad (3)$$

95%有向百分比Hausdorff测度定义为轮廓 X 中的所有点到轮廓 Y 的距离按升序排列后95%位置处的值:

$$\vec{d}_{H,95}(X, Y) = K_{95}(\min_{y \in |Y|} d(x, y)), \forall x \in X \quad (4)$$

95%Hausdorff距离(HD95)定义为两个95%有向百分比Hausdorff测度的平均值:

$$HD95 = \frac{\vec{d}_{H,95}(X, Y) + \vec{d}_{H,95}(Y, X)}{2} \quad (5)$$

分别计算数据A和数据B中测试集患者心脏自动分割的Dice系数、HD95和MSD。

2 结果与分析

2.1 预实验结果

将2D U-net与3D U-net在测试集患者心脏CT图像上自动分割的Dice系数作成折线图。结果发现在两

个医院的数据集上均呈现如下规律:心脏CT图像编号沿人体轴向从下至上,在靠近腹部的第7或8张CT图像位置上,两条折线相交;对于前8张CT图像,3D U-net表现远优于2D U-net;对于其余CT图像,2D U-net表现略优于3D U-net。因此,本研究中 m 取8,即将靠近腹部的8张心脏CT图像输入3D U-plus-net进行自动分割,其余心脏CT图像输入2D U-plus-net进行自动分割。

为了直观显示2D和3D网络在心脏不同位置分割性能的差异性,在数据A和数据B中各选取一名测试集患者Dice系数折线图展示见图4;为了说明此规律在所有患者上的普遍适用性,本研究将所有测试集患者的平均Dice系数展示见表1、表2。

由图4以及表1、表2可见,基于2D U-net在心脏靠近头颈部的CT图像上分割的平均Dice系数很高,但在靠近腹部的8张CT图像上表现呈断崖式下跌,大大拉低心脏整体分割的平均Dice系数;基于3D U-net的心脏分割Dice系数沿人体轴向从下到上稳步提高。Dice系数的变化幅度体现出两种网络各自的优缺点:3D网络可将连续两张CT图像的分割结果偏差控制在一定范围内,但整体性能不高;2D网络在心脏特征明显的CT图像上表现良好,但难以在特征不明显的CT图像上进行分割。

2.2 心脏自动分割结果

图5为基于2D/3D U-plus-net在数据A和数据B中的4张心脏分割结果。其中,绿色轮廓为预测结果,红色轮廓为医生分割结果。从图中可见,无论是

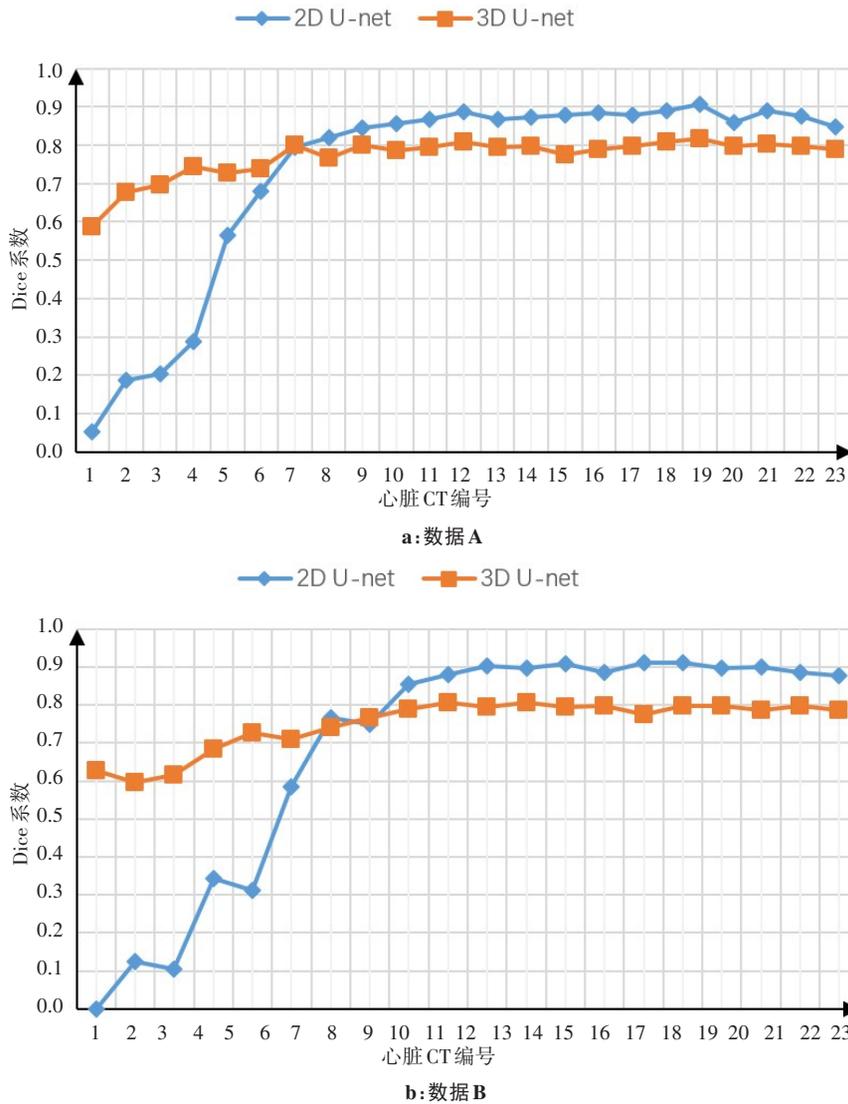


图4 基于2D U-net/3D U-net对测试集中一名患者进行心脏自动分割的Dice系数
Fig.4 Dice coefficient of 2D U-net/3D U-net based automatic heart segmentation for a patient from the testing set

表1 基于2D U-net/3D U-net在数据A中进行心脏自动分割的Dice系数

Tab.1 Dice coefficient of 2D U-net/3D U-net based automatic heart segmentation on Data A

网络	靠近腹部的8张CT图像	其余CT图像	心脏整体
2D U-net	0.611±0.118	0.944±0.013	0.808±0.075
3D U-net	0.863±0.023	0.891±0.016	0.880±0.018

表2 基于2D U-net/3D U-net在数据B中进行心脏自动分割的Dice系数

Tab.2 Dice coefficient of 2D U-net/3D U-net based automatic heart segmentation on Data B

网络	靠近腹部的8张CT图像	其余CT图像	心脏整体
2D U-net	0.589±0.098	0.928±0.014	0.795±0.062
3D U-net	0.854±0.024	0.877±0.016	0.869±0.020

采用紧贴器官还是器官外扩的分割方法,2D/3D U-plus-net 预测结果与医生分割结果都非常接近,即该网络模型在不同数据集中鲁棒性较好。

基于原始U-net的训练模型大小约200 M,而本研究所使用的2D U-plus-net模型大小约33 M,3D U-plus-net模型大小约45 M,大大降低神经网络训练所占的内存空间。其原因主要是2D/3D U-plus-net减小了网络深度。

基于2D/3D U-plus-net对数据A和数据B中的测

试集患者进行心脏自动分割的Dice系数、MSD及HD95见表3。基于不同网络模型的心脏自动分割平均Dice系数如表4所示。其中,2D/3D U-net列的数据为取预实验中基于3D U-net在靠近腹部的8张心脏CT图像上的分割Dice系数与基于2D U-net在其余心脏CT图像上分割的Dice系数作加权平均得到。从2D/3D U-net列与2D U-net列及3D U-net列对比可见,将2D U-net与3D U-net相结合的方法与单独使用2D U-net或3D U-net相比,在心脏整体上分割

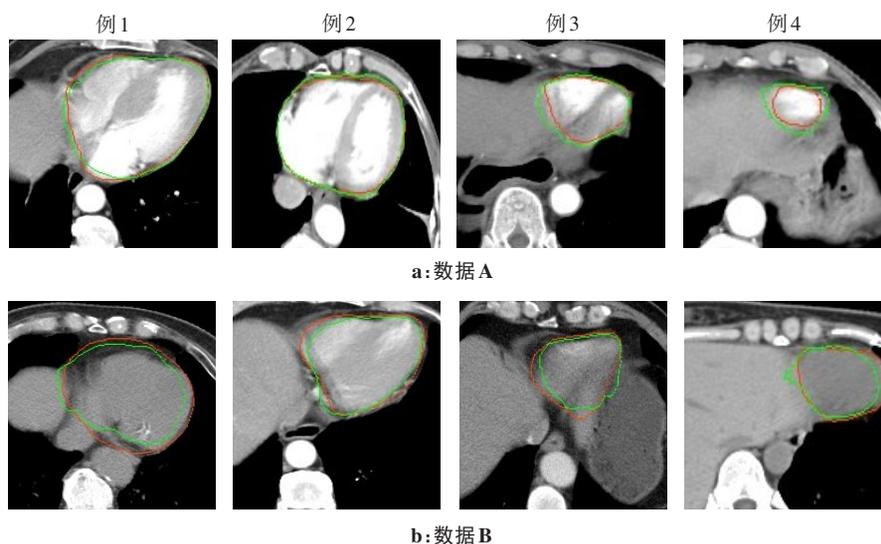


图5 基于2D/3D U-plus-net的心脏分割结果

Fig.5 Results of automatic heart segmentation based on 2D/3D U-plus-net

的Dice系数均有所提高。一方面,此方法充分利用2D和3D网络在不同位置图像上分割的优势;另一方面,将心脏CT图像分为两类,使得每个网络接受训练的图像形状大小更相近,特征更集中,有利于神经网络的学习。从2D/3D U-plus-net列与2D/3D U-net列对比可见,本研究所提出的2D/3D U-plus-net与原始2D/3D U-net网络相比,对网络结构的改进使得网络性能大幅提升,进一步提高心脏自动分割的准确率。

表3 基于2D/3D U-plus-net的心脏自动分割Dice系数、MSD和HD95

Tab.3 Dice coefficient, mean surface distance and HD95 of automatic heart segmentation based on 2D/3D U-plus-net

数据	Dice系数	MSD/mm	HD95/mm
A	0.941±0.012	3.918±0.201	5.863±0.561
B	0.934±0.014	4.112±0.320	6.035±0.659

表4 基于不同网络模型的心脏自动分割Dice系数
Tab.4 Dice coefficient of automatic heart segmentation based on different networks

数据	2D U-net	3D U-net	2D/3D U-net	2D/3D U-plus-net
A	0.808±0.075	0.880±0.018	0.912±0.017	0.941±0.012
B	0.795±0.062	0.869±0.020	0.900±0.018	0.934±0.014

3 讨论

近年来,用于图像分类识别的神经网络发展迅速,vgg16^[21]、Googlenet^[22]等网络在大数据量图像分类任务中表现出色,然而在小批量图像处理时产生

了过拟合现象;相反,结构简单的AlexNet能够很好地适应小批量患者的CT图像心脏识别。因此,本研究经过实验对比,最终选定对AlexNet进行改进,并基于modified-AlexNet将胸部CT图像分为心脏CT图像和无心脏CT图像。

由预实验结果可见,在郑州大学第一附属医院和中国科学技术大学附属第一医院两个不同数据集中,在CT层厚5mm的情况下,2D和3D网络的性能差异都在心脏CT图像靠近腹部的第8张左右的位置发生改变;对于其他医院的临床数据,由于CT扫描及重建技术不同,2D和3D网络性能差异发生改变的位置也可能不同,可根据预实验结果决定m的取值。

由表4中基于不同网络模型的心脏自动分割Dice系数的对比可见,本研究对网络结构的改进使得网络性能有不小的提升。其中,最重要的改进为在长连接中增加网络节点,同时利用网络深层和浅层特征,提高了图像特征利用率。同时,本研究提出的思想方法可以应用到其他的神经网络,即对网络结构作出其他改进时,也可将2D和3D网络相结合,将心脏不同位置CT图像输入不同网络,从而提高心脏分割准确率。

本研究所采用的方法在大面积与小面积器官分割上均表现良好,理论上适用于所有单连通的大体积器官。因此,下一步会将此方法集成到智能化靶区和器官自动分割系统DeepViewer中,并应用到肝脏、胃等器官的自动分割。

本研究基于modified-AlexNet将胸部CT图像准确分类为心脏CT图像和无心脏CT图像;基于2D U-plus-net分割靠近腹部的心脏CT图像,基于3D U-plus-net分

割其余心脏CT图像,最终提高心脏整体的自动分割准确率。

【参考文献】

- [1] CERROLAZA J J, VILLANUEVA A, CABEZA R. Hierarchical statistical shape models of multiobject anatomical structures: application to brain MRI[J]. IEEE Trans Med Imaging, 2012, 31(3): 713-724.
- [2] OKADA T, LINGURARU M G, HORI M, et al. Abdominal multi-organ segmentation from CT images using conditional shape-location and unsupervised intensity priors[J]. Med Image Anal, 2015, 26(1): 1-18.
- [3] 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.
- [4] KLEIN S, VAN DER HEIDE U A, LIPS I M, et al. Automatic segmentation of the prostate in 3D MR images by atlas matching using localized mutual information[J]. Med Phys, 2008, 35(4): 1407-1417.
- [5] 张富利, 崔德琪, 王秋生, 等. 基于深度学习和图谱库方法自动勾画肿瘤放疗中危及器官的比较[J]. 中国医学物理学杂志, 2019, 36(12): 1486-1490.
ZHANG F L, CUI D Q, WANG Q S, et al. Comparative study of deep learning- versus Atlas-based auto-segmentation of organs-at-risk in tumor radiotherapy[J]. Chinese Journal of Medical Physics, 2019, 36(12): 1486-1490.
- [6] RONNEBERGER O, FISCHER P, BROX T. U-net: convolutional networks for biomedical image segmentation[C]//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Switzerland: Lecture Notes in Computer Science, 2015: 234-241.
- [7] GUO X T, SCHWARTZ L H, ZHAO B. Automatic liver segmentation by integrating fully convolutional networks into active contour models[J]. Med Phys, 2019, 46(10): 4455-4469.
- [8] ZHOU X R, TAKAYAMA R, WANG S, et al. Deep learning of the sectional appearances of 3D CT images for anatomical structure segmentation based on an FCN voting method[J]. Med Phys, 2017, 44(10): 5221-5233.
- [9] MA Z Q, WU X, WANG X, et al. An iterative multi-path fully convolutional neural network for automatic cardiac segmentation in cine MR images[J]. Med Phys, 2019, 46(12): 5652-5665.
- [10] FENG X, QING K, TUSTISON N J, et al. Deep convolutional neural network for segmentation of thoracic organs-at-risk using cropped 3D images[J]. Med Phys, 2019, 46(5): 2169-2180.
- [11] HUO Y K, TERRY J G, WANG J, et al. Fully automatic liver attenuation estimation combining CNN segmentation and morphological operations[J]. Med Phys, 2019, 46(8): 3508-3519.
- [12] DANGI S, LINTE C A, YANIV Z. A distance map regularized CNN for cardiac cine MR image segmentation[J]. Med Phys, 2019, 46(12): 5637-5651.
- [13] MORRIS E D, GHANEM A I, DONG M, et al. Cardiac substructure segmentation with deep learning for improved cardiac sparing[J]. Med Phys, 2019, 47(2): 576-586.
- [14] 王沛沛, 李金凯, 李彩虹, 等. 基于人工智能技术的危及器官自动勾画在胸部肿瘤中的应用[J]. 中国医学物理学杂志, 2019, 36(11): 1346-1349.
WANG P P, LI J K, LI C H, et al. Application of automatic organs-at-risk segmentation based on artificial intelligence technology in thoracic tumors[J]. Chinese Journal of Medical Physics, 2019, 36(11): 1346-1349.
- [15] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[J]. IEEE Trans Pattern Anal Machine Intell, 2017, 39(4): 640-651.
- [16] ÇIÇEK Ö, ABDULKADIR A, LIENKAMP S S, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C] // Medical Image Computing and Computer-Assisted Intervention-MICCAI 2016. Switzerland: Lecture Notes in Computer Science, 2016: 424-432.
- [17] DONG X, LEI Y, WANG T, et al. Automatic multiorgan segmentation in thorax CT images using U-net-GAN[J]. Med Phys, 2019, 46(5): 2157-2168.
- [18] 周正东, 李剑波, 辛润超, 等. 基于带孔U-net神经网络的肺癌危及器官并行分割方法[J]. 东南大学学报(自然科学版), 2019, 49(2): 231-236.
ZHOU Z D, LI J B, XIN R C, et al. Parallel segmentation method for organs at risk in lung cancer based on dilated U-net neural network[J]. Journal of Southeast University (Natural Science Edition), 2019, 49(2): 231-236.
- [19] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. ImageNet classification with deep convolutional neural networks[C]//Neural Information Processing Systems 2012. Lake Tahoe, Nevada: Curran Associates Inc, 2012: 1097-1105.
- [20] WANG T, LEI Y, TIAN S, et al. Learning-based automatic segmentation of arteriovenous malformations on contrast CT images in brain stereotactic radiosurgery[J]. Med Phys, 2019, 46(7): 3133-3141.
- [21] SIMONYAN K, ZISSERMAN A. Very deep convolutional networks for large-scale image recognition[C]//International Conference on Learning Representations 2015. San Diego, 2015: 1-14.
- [22] SZEGEDY C, LIU W, JIA Y, et al. Going deeper with convolutions[C]//Computer Vision and Pattern Recognition 2015. Boston, 2015: 1-9.

(编辑:谭斯允)