

基于深度学习的医学图像分割方法

游齐靖, 万 程

基金项目: 国家自然科学基金项目(编号:61603182); 中国博士后科学基金项目(编号:2019M661832); 江苏省博士后科研资助计划项目(编号:2019K226)

作者单位: 211106 江苏,南京航空航天大学电子信息工程学院
作者简介: 游齐靖(1995-),男,在读硕士研究生,研究方向:计算机视觉、医学图像处理。E-mail:526566416@qq.com
通讯作者: 万 程(1979-),女,博士,讲师,硕士研究生导师,研究方向:计算机视觉、智能眼科学。E-mail:wanch@nuaa.edu.cn



万 程,博士,硕士研究生导师,中国智能眼科学组、智能医学专委会委员,研究方向为计算机视觉和智能眼科学。教授数字图像处理、机器学习、深度学习与计算机视觉、数据结构等课程。担任《日本电子情报通信学会会刊》、《自动化学报》等期刊审稿人。主持国家自然科学基金、江苏省自然科学基金、中国博士后基金、留学归国人员科研基金等多项课题。发表 SCI/EI 论文 20 余篇,申请授权发明专利 11 项,获得 2019 年全国大学生智能技术应用大赛二等奖、2019 年度“创业新港”高层次人才、第二十一届中国国际高新技术成果优秀产品奖等。

〔摘要〕 近年来,日渐成熟的人工智能深度学习技术使得众多领域逐渐实现自动化智能化作业。在医疗领域,随着医疗数据电子化和互联网医疗的发展,基于卷积神经网络实现包含定位、分割和分类于一体的辅助诊断系统应用已成为新型医疗模式发展的必然趋势。医学影像分割技术是医疗图像自动分析中的难点和重点,目前仍面临许多亟待解决的问题。该文将从临床医学影像的特点、深度学习主流分割网络和医学图像分割网络在临床中的应用 3 个方面对医学图像分割领域的研究进展进行系统综述,并进一步分析卷积神经网络在医学影像分割任务中的发展现状、面临的挑战以及未来的发展方向。

〔关键词〕 深度学习; 医学影像; 卷积神经网络; 图像分割算法
〔中图分类号〕 TP 18 〔文献标识码〕 A 〔文章编号〕 1674-3806(2020)02-0115-04
doi:10.3969/j.issn.1674-3806.2020.02.02

Medical image segmentation methods based on deep learning YOU Qi-jing, WAN Cheng. College of Electronic and Information Engineering, Nanjing University of Aeronautics and Astronautics, Jiangsu 211106, China

〔Abstract〕 In recent years, the increasingly developed technology of deep learning of artificial intelligence makes many fields gradually realize automatic intelligent work. In the field of medicine, with the developments of medical data electronization and internet medicine, it has become an inevitable trend to develop a new medical mode to realize computer-aided diagnosis systems based on convolutional neural networks, which includes positioning, segmentation and classification. Medical image segmentation technology is the difficulty and key point in the automatic analysis of medical image. At present, there are still many problems to be solved. In this paper, the progress of medical image segmentation will be systematically reviewed from three aspects: the characteristics of clinical medical image, the introduction of deep learning mainstream segmentation networks and the application of current medical image segmentation networks in clinical application, and the current development situation, challenges and future development direction of convolution neural networks in medical image segmentation task will also be analyzed.

〔Key words〕 Deep learning; Medical image; Convolution neural networks; Image segmentation

随着数字图像成像技术的发展,各类新型医学影像拍摄设备日渐普及,医学图像也逐渐成为医生临床诊断的主要依据。传统诊断流程需要医生在观察分析病灶的同时给出诊断结果,一些发病率较高的常见病往往患者群体巨大,需要临床医生花费大量时间和精力重复地进行观察和诊断,且诊断结果

容易受到医生主观因素的影响。因此,一个能够实现图像定位、分割和分类等功能的自动化医学图像分析系统具有重大的临床意义。近几年来,深度学习方法在计算机视觉各个领域均取得了巨大的突破,深度学习主流算法卷积神经网络(convolutional neural networks, CNN)在医学图像分割等任务中的表现均超越了传统算法。作为各类神经网络算法的统称,深度学习概念由 Hinton 等^[1]在 2006 年首次提出。随后深度波尔兹曼机^[2](deep Boltzmann machine, DBM)、卷积深度信念网络(convolutional deep belief networks, CDBN)^[3]和 AlexNet^[4]等众多网络的提出逐步奠定了 CNN 在图像处理各个领域中的主导地位。目前,基于深度学习的分割算法在医学图像临床研究及辅助诊断中得到了广泛应用,此类算法通过准确分割病灶或目标器官辅助医生进行病情分析。本文将围绕临床医学影像的特点、深度学习主流分割网络和医学图像分割网络在临床中的应用 3 个方面对医学图像分割领域的研究进展进行综述。

1 医学图像特点

与自然图像相比,医学图像具有以下特点:(1)医学影像结构相对固定,语义内容少^[5]。在同一类型的医学影像中,因为人体同一器官的结构固定,即使病人患病程度不同,其图像中病灶区域整体表现依旧类似。例如在诊断脑胶质瘤的磁共振影像(magnetic resonance imaging, MRI)中,不同病例的颅骨、脑皮质等结构高度相似,胶质瘤出现在脑皮质中的不同区域,可作为诊断依据的仅有胶质瘤位置和大小等少量信息。(2)部分医学影像成像质量较低^[6]。虽然医学影像结构相对固定,但许多医学影像本身成像质量偏低,尤其对于具有多种模态的医学影像。在 CT、MRI、超声影像中,经常存在噪声严重、组织器官边界不明显、分辨率较低和灰度对比度不足等问题。此类医学影像在用于临床研究之前一般会进行图像预处理操作以减少上述干扰因素。(3)医学影像数据量较少^[7]。医学影像需要在临床研究中同步采集,每一个病例只能得到一组对应的影像数据,因此医学图像分割任务中的训练数据普遍较少,通常不会超过 1 000 例。同时,不同医院的仪器设备和拍摄方式差异较大,不同医院的临床数据集未经过预处理并不能通用。(4)医学影像大多数具有多种模态^[8]。医学影像和自然影像最大的不同点就是医学影像大多数都具有多种模态。以脑胶质瘤分割任务为例,在 BraTS 脑胶质瘤分割竞赛^[9]中,官方提供了 T1、T1c、T2 和 Flair 一共 4 个模态来进行胶

质瘤的分割任务。有别于处理自然图像的传统网络结构,多模态的存在需要我们在设计网络时充分考虑到各个模态影像特征的提取方法以及不同模态之间特征信息的融合方式。受上述特征的影响,医学图像分割任务难度远大于自然图像分割任务。

2 分割算法介绍

作为医学图像研究中的一个关键分支,医学影像语义分割任务一直在临床诊断中扮演重要的角色。根据分割算法的不同,医学图像分割任务可以分为两大类:基于传统算法的医学图像分割和基于深度学习方法的医学图像分割。

2.1 传统医学图像分割算法 主要通过研究人员手动设计特征实现分割任务,根据分割目标和背景区域的差异性可以从灰度信息、对比度信息和纹理信息等方面进行设计。传统医学图像分割算法包括基于阈值的分割算法、基于边界的分割算法、基于区域生长的分割算法、基于聚类的分割算法、基于图论的分割算法^[10~14]等。

2.2 深度学习图像分割算法 其早期主要通过滑动图像块的方式实现^[15]:在目标像素周围截取固定大小的图像块送入 CNN,得到的分类结果即为当前像素点所属类别。图像块滑动方法存在大量的重复计算操作且运行效率低下,同时分割精度直接受图像块大小限制,具有一定局限性。在 Long 等^[16]提出全卷积网络(fully convolutional networks, FCN)后,此类全新的网络结构逐渐替代图像块滑动方法成为图像分割领域的主流框架。FCN 可以概括为一个编码器-解码器结构,该结构首先使用编码器提取原始图像高维特征,然后再通过解码器将高度抽象的特征映射到结果图像中的每一个像素点。FCN 使用卷积层替换经典分类 CNN 中的全连接层,利用转置卷积执行上采样从而实现任意尺寸输入图像的分割。以 FCN 为基础,各类分割网络的差异主要表现在解码器的构造方式上。Badrinarayanan 等^[17]提出的 SegNet 探索了不同解码器结构对分割网络性能的影响。为了保留原始图像的细节信息,FCN 采用跳跃连接方式结合图像的底层和高层信息,Chen 等^[18]提出的 Deep-Lab V3+ 网络则使用多个大小不同的膨胀卷积核提取图像中不同尺度的特征信息。相比之下,编码器通常为 ImageNet 分类数据集上表现优越的经典分类网络,如 VGG^[19]、ResNet^[20]、DenseNet^[21]等。

2.3 U-Net 网络 在医学影像分割领域,最为常见的分割网络是 Ronneberger 等^[22]提出的 U-Net 网络。U-Net 网络同样基于编码器-解码器思想构建,网络

结构可以简化为下采样、上采样和跳跃连接三大模块,其中下采样和上采样为完全对称结构,跳跃连接方式直接融合上下采样结构中的高层和底层信息,用于提升分割结果细节精度的同时使 U-Net 具有更好的可解释性。基于 U-Net 框架诞生了一系列在不同医学影像上表现优越的语义分割衍生网络,Zhou 等^[23]提出的 U-Net++ 网络使用密集连接方式替代 U-Net 中特征直接串联的跳跃连接模式。为了匹配不同难度的分割任务,U-Net++ 并没有限制网络下采样层数,而是根据最后的分割评价指标对网络进行修剪,该方案可以在保证模型分割性能的前提下使用最少的网络参数以节省计算资源。部分医学影像以三维格式存储,如 MRI、CT 等。为了对此类图像进行分割,Çiçek 等^[24]提出 3D U-Net 网络,将 U-Net 网络扩展为三维形式。3D U-Net 网络通过稀疏抽样的形式对部分二维切片进行标注,成功得到完整的三维分割结果。

3 分割算法的应用

3.1 分割算法在眼科疾病诊断中的应用 Google 旗下的 DeepMind 公司通过结合两个 CNN 模型实现了常规临床实践中的视网膜疾病诊断和转诊流程^[25]。该系统使用 14 884 个样本进行训练,可以准确诊断约 50 种常见眼科疾病,转诊判断准确率首次超过人类专家。研究人员使用分割网络和分类网络级联的方式使诊断系统更具有可解释性,首先使用分割网络对患者的视网膜光学相干断层扫描(optical coherence tomography, OCT)图像进行分割,提取不同类型的眼组织(视乳头、血管等)以及眼底病变区域(出血、渗出等)。然后应用分类网络对分割结果进行分析,最终输出眼疾病诊断结果并为临床医生提供转诊建议。考虑到 OCT 图像包含三维空间信息,该系统分割部分以 3D U-Net 网络作为基础框架,并使用迁移学习方法使用不同 OCT 数据集对分割模型进行微调。该系统中的迁移学习步骤可以保证模型对于不同设备拍摄的 OCT 图像均具有较高的分割精度。

3.2 分割算法在前列腺疾病诊断中的应用 Milletari 等^[26]提出了一个针对前列腺 MRI 影像的分割网络,名为 V-Net。V-Net 结合不同模态的 MRI 影像实现了端到端的前列腺分割流程,该网络在输出分割结果的同时计算前列腺容积用于后续临床分析。为了得到更好的分割精度,V-Net 基于 3D U-Net 做了以下改进:(1)在 3D U-Net 网络原来的层间三维卷积中引入了残差学习模块,通过残差连接方式提升下采样网络特征提取能力;(2)使用随机线性变换和直

方图匹配方式对训练数据集进行扩充,避免训练过程中网络出现过拟合现象;(3)基于 Dice Coefficient 提出 Dice Loss 作为一种全新的损失函数训练分割网络。Dice 系数^[27]是衡量两个集合相似度的一个统计学指标,通常用来评估模型分割性能。实验表明,V-Net 分割网络在前列腺 MRI 影像分割任务中具有优越的临床表现。

3.3 分割算法在糖尿病、高血压诊断中的应用 眼底图像中视网膜血管的自动分割对糖尿病、高血压等疾病的诊断具有重要意义。Jin 等^[28]提出的 DUNet 网络在 U-Net 基础上引入了可变形卷积思想,利用视网膜血管的局部特征实现了端到端的分割任务。DUNet 可以根据分割血管的粗细和形状自适应地调整卷积核大小,基于多尺度卷积得到血管的精准分割结果。在主流血管分割数据集中,DUNet 模型分割性能均优于已有的视网膜血管分割网络。对于 DRIVE、STARE、CHASE_DB1 和 HRF 眼底图像血管分割数据集,DUNet 分别取得了 0.9566、0.9641、0.9610、0.9651 的全局准确率和 0.9802、0.9832、0.9804、0.9831 的曲线下面积(area under curve, AUC)。

3.4 分割算法在神经胶质瘤诊断中的应用 MRI 是临床实践中诊断神经胶质瘤的一种极为有效的影像资料,根据多模态 MRI 自动分割肿瘤区域对于肿瘤患者的诊断、监测和治疗具有重要意义。NVIDIA 实验室的 Myronenko 等^[29]提出了一个新型胶质瘤分割网络,该网络在传统编码器-解码器结构的基础上额外添加了一个解码器实现对输入图像编码器特征提取结果的重构。因为共享编码器网络,此方式可以看作对编码器进行了正则化约束。作为 2018 年 BraTS 脑胶质瘤分割竞赛中的冠军方案,该分割模型在增强核(enhancing tumor core, ET)、整个肿瘤(whole tumor, WT)和肿瘤核(tumor core, TC)三个分割任务中分别取得了 0.77、0.88、0.82 的平均 Dice 值和 3.77、5.90、4.81 的平均 Hausdorff 距离,其中 Hausdorff 为欧式空间中两个点集间的距离度量。

4 展望

医学影像中的分割任务通常以病灶区域和整体器官作为目标进行分割,同时利用分割结果辅助临床医生进行后续的诊断与治疗。从使用视网膜眼底图像分割眼底血管,到使用肺部 CT 影像分割肺结节,再到使用脑部 MRI 影像分割脑胶质瘤等其他分割任务,医学影像自动化分割算法日渐成熟并在临床诊断中扮演着越来越重要的角色。但是当前的深度学习分割网络仍然存在着以下不足之处:(1)对

于几乎所有的医学影像分割任务,训练数据中的分割标签均需专业医生手动制作得到。一般情况下,分割标签大小和原始图像相同,其中使用不同像素值指示分割任务中的各类目标。训练 CNN 需要大规模的样本数据,而制作大量的分割标签往往需要耗费巨大的人力与财力资源。因此,分割标签的自动生成算法将会是未来分割任务的主要研究方向之一。(2)当前医学图像分割网络几乎都是以 U-Net 框架为基础演变得来,清一色的编码器-解码器结构一定程度上限制了分割网络的发展方向。对其他分割网络框架的探索将会是未来分割任务另外一个重要的研究方向。

参考文献

- Hinton GE, Osindero S, Teh YW. A fast learning algorithm for deep belief nets[J]. *Neural Comput*, 2006, 18(7): 1527-1554.
- Salakhutdinov R, Hinton G. Deep boltzmann machines[C]. *Artificial intelligence and statistics*, 2009: 448-455.
- Lee H, Grosse R, Ranganath R, et al. Convolutional deep belief networks for scalable unsupervised learning of hierarchical representations[C]. *Proceedings of the 26th annual international conference on machine learning*, 2009: 609-616.
- Krizhevsky A, Sutskever I, Hinton G. ImageNet Classification with Deep Convolutional Neural Networks[J]. *Adv Neural Inf Process Syst*, 2012, 25(2): 1097-1105.
- Wernick MN, Yang Y, Brankov JG, et al. Machine learning in medical imaging[J]. *IEEE Signal Processing Magazine*, 2010, 27(4): 25-38.
- Carneiro G, Nascimento J, Bradley AP. Unregistered multiview mammogram analysis with pre-trained deep learning models[C]. *International Conference on Medical Image Computing and Computer-Assisted Intervention*, 2015: 652-660.
- Greenspan H, Van Ginneken B, Summers RM. Guest editorial deep learning in medical imaging: Overview and future promise of an exciting new technique[J]. *IEEE Transactions on Medical Imaging*, 2016, 35(5): 1153-1159.
- Lee J-G, Jun S, Cho Y-W, et al. Deep learning in medical imaging: general overview[J]. *Korean J Radiol*, 2017, 18(4): 570-584.
- Menze BH, Jakab A, Bauer S, et al. The multimodal brain tumor image segmentation benchmark (BRATS)[J]. *IEEE Trans Med Imaging*, 2015, 34(10): 1993-2024.
- Boykov Y Y, Jolly M-P. Interactive graph cuts for optimal boundary & region segmentation of objects in ND images[C]. *Proceedings eighth IEEE international conference on computer vision. ICCV 2001*, 2001: 105-112.
- Rudra AK, Chowdhury AS, Elnakib A, et al. Kidney segmentation using graph cuts and pixel connectivity[J]. *Pattern Recognition Letters*, 2013, 34(13): 1470-1475.
- Shi J, Malik J. Normalized cuts and image segmentation[J]. *Departmental Papers (CIS)*, 2000, 22(8): 888-905.
- Gong M, Liang Y, Shi J, et al. Fuzzy C-means clustering with local information and kernel metric for image segmentation[J]. *IEEE Trans Image Process*, 2013, 22(2): 573-584.
- Haralick RM, Shapiro LG. Image segmentation techniques[J]. *Computer Vision, Graphics, and Image Processing*, 1985, 29(1): 100-132.
- Ciresan D, Giusti A, Gambardella LM, et al. Deep neural networks segment neuronal membranes in electron microscopy images[C]. *Advances in neural information processing systems*, 2012: 2843-2851.
- 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.
- Badrinarayanan V, Kendall A, Cipolla R. SegNet: A deep convolutional encoder-decoder architecture for image segmentation[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(12): 2481-2495.
- Chen L-C, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation[C]. *Proceedings of the European conference on computer vision (ECCV)*, 2018: 801-818.
- Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[J]. *Computer Science*, 2014.
- He K, Zhang X, Ren S, et al. Deep Residual Learning for Image Recognition[C]. *IEEE Conference on Computer Vision & Pattern Recognition*, 2016: 770-778.
- Huang G, Liu Z, Maaten L V D, et al. Densely Connected Convolutional Networks[C]. *CVPR*, 2017: 4700-4708.
- 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*, 2015: 234-241.
- Zhou Z, Siddiquee M M R, Tajbakhsh N, et al. Unet++: A nested u-net architecture for medical image segmentation[M]. *Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: Springer*, 2018: 3-11.
- Çiçek Ö, Abdulkadir A, Lienkamp SS, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation[C]. *International conference on medical image computing and computer-assisted intervention*, 2016: 424-432.
- De Fauw J, Ledsam JR, Romera-Paredes B, et al. Clinically applicable deep learning for diagnosis and referral in retinal disease[J]. *Nat Med*, 2018, 24(9): 1342-1350.
- Milletari F, Navab N, Ahmadi SA. V-net: Fully convolutional neural networks for volumetric medical image segmentation[C]. *2016 Fourth International Conference on 3D Vision(3DV)*, 2016: 565-571.
- Dice LR. Measures of the amount of ecologic association between species[J]. *Ecology*, 1945, 26(3): 297-302.
- Jin Q, Meng Z, Pham TD, et al. DUNet: A deformable network for retinal vessel segmentation[J]. *Knowledge-Based Systems*, 2019, 178: 149-162.
- Myronenko A. 3D MRI brain tumor segmentation using autoencoder regularization[C]. *International MICCAI Brainlesion Workshop*, 2018: 311-320.