

医学图像分割的研究进展

黄仟甲¹, 张恒^{2,3,4,5}, 李奇轩¹, 曹德政^{2,3,4,5}, 焦竹青¹, 倪昕晔^{2,3,4,5}

1. 常州大学计算机与人工智能学院, 江苏 常州 213164; 2. 南京医科大学附属常州第二人民医院放疗科, 江苏 常州 213003; 3. 江苏省医学物理工程研究中心, 江苏 常州 213003; 4. 南京医科大学医学物理研究中心, 江苏 常州 213003; 5. 常州市医学物理重点实验室, 江苏 常州 213003

【摘要】医学图像是医生对患者进行病情诊断和治疗规划的有力工具。现今对于医学图像的分割不再局限于手工分割方法,通过传统方法与深度学习方法来实现医学图像分割已经取得更好、更准确的结果。本文基于近年来一些较为出众的医学图像创新分割方法进行综述,通过阐述深度学习如SAM、SegNet、Mask R-CNN和U-NET以及传统方法如活动轮廓模型、阈值分割模型创新等,对比各种图像分割方法的异同点,对医学图像分割方法做出总结与展望。以此来帮助学者们更好地了解目前的研究进展与未来的发展趋势。

【关键词】医学图像分割;深度学习;阈值分割;神经网络;任意分割模型;综述

【中图分类号】R318;TP391

【文献标志码】A

【文章编号】1005-202X(2024)08-0939-07

Review on medical image segmentation methods

HUANG Qianjia¹, ZHANG Heng^{2,3,4,5}, LI Qixuan¹, CAO Dezheng^{2,3,4,5}, JIAO Zhuqing¹, NI Xinye^{2,3,4,5}

1. School of Computer Science and Artificial Intelligence, Changzhou University, Changzhou 213164, China; 2. Department of Radiotherapy, Changzhou Second People's Hospital, Nanjing Medical University, Changzhou 213003, China; 3. Jiangsu Province Engineering Research Center of Medical Physics, Changzhou 213003, China; 4. Medical Physics Research Center, Nanjing Medical University, Changzhou 213003, China; 5. Key Laboratory of Medical Physics in Changzhou, Changzhou 213003, China

Abstract: Medical image is a powerful tool to assist doctors in the diagnosis and treatment planning. Nowadays, the segmentation of medical images is no longer limited to manual segmentation methods. Traditional methods and deep learning methods have been used to achieve more accurate results in medical image segmentation. Herein some innovative medical image segmentation methods in recent years are reviewed. By elaborating on the innovations of deep learning methods (SAM, SegNet, Mask R-CNN, and U-NET) and traditional methods (active contour model and threshold segmentation model), the differences and similarities between them are compared. The summary of medical image segmentation methods and the prospect is expected to help researchers better grasp and familiarize themselves with research status and development trend.

Keywords: medical image segmentation; deep learning; threshold segmentation; neural network; segment anything model; review

前言

医学图像分割是一种利用计算机技术与计算机

视觉相结合的处理方法或者是由医生根据自身经验对图像目标区域进行分割的操作,通过该操作可以将图像的目标病变组织与无关组织进行分离,勾画出目标区域。总而言之,医学图像分割是一种将医学图像中感兴趣区域与背景区域进行准确分离的过程,这些感兴趣区域可以是病患体内的不同组织结构(如各类器官、肌肉等)、非正常异变(如肿瘤、斑块等)与解剖结构等。通过该分割过程可以实现对病人的治疗方案作进一步的定量、定性分析以及治疗规划。

传统的图像分割是由经验丰富的诊断医生手动勾画出来的,然而人为勾画目标区域具有局限性,特

【收稿日期】2024-03-15

【基金项目】国家自然科学基金(62371243);江苏省医学重点学科建设单位[肿瘤治疗学(放射治疗)](JSDW202237);江苏省重点研发计划社会发展项目(BE2022720);江苏省卫健委面上项目(M2020006);江苏省自然科学基金(BK20231190);常州市社会发展项目(CE20235063)

【作者简介】黄仟甲,硕士研究生,主要研究方向:医学图像分割,E-mail: 424541674@qq.com

【通信作者】倪昕晔,博士,研究员,博士生导师,主要研究方向:医学物理,E-mail: nxy@njmu.edu.cn

别是在面对复杂医学图像时,人为勾画往往会忽略重要的细节和边界信息,同时对于模糊的边界图像,更是无法勾画提取出精准的目标区域。不同病症所对应的不同图像都存在极其明显的个体差异。同类型的病症图像之间也会存在诸如质量差异、时空分辨率差异以及不同设备所采用的标准不同的差异。以甲状腺结节为例,不同病人的结节之间可能会因为其大小、形状、位置以及呼吸运动等原因产生巨大的差异,因此使用计算机进行辅助诊断是一个很好的诊疗方式。对于此类问题,基于计算机视觉的医学图像分割方法的技术创新与多样化是必不可少的。近现代以来研究者们提出许多优秀的图像分割模型与架构,大致可分为传统方法与深度学习方法两大类。传统方法主要是基于对图像像素分割、阈值设置等,而深度学习方法则更多的是以神经网络为知识基础,以此实现高质量的图像分割。

本文主要阐述近年来各类图像分割方法的研究进展以及对于存在的问题找到最适合的解决方法。本文首先介绍图像分割的基本原理以及临床的重要性,并就传统手工勾画医学图像的方法提出个人观点。然后分别对图像分割传统方法与深度学习方法的现状进行综述,并且将研究重心置于深度学习方法在图像分割应用之中,发现其中的优劣势。最后,根据论文中所提及的模型与技术做出总结,并对未来医学图像分割研究趋势做出展望,为日后该研究领域的学者提供相应的建议与参考。

1 传统方法在医学图像分割中的应用

传统医学图像分割方法是以相应的数学论基础(线性代数、微积分、高数等),特征提取与描述[局部特征描述子(如SIFT^[1]、SURF)、颜色直方图、Gabor滤波器等],形态学理论等知识作为模型的建立基础。其中使用最为广泛的是活动轮廓方法与基于数学原理的阈值分割方法。

1.1 活动轮廓方法

活动轮廓模型,也被称为蛇模型^[2]。该模型首先是通过定义一个能量函数,结合图像外部信息和曲线内部属性,来指导曲线位置的迭代调整,以使曲线逐渐接近于图像中感兴趣区域的边界;然后通过最小化能量函数,实现对目标区域轮廓的精确提取与分割。然而,有些医学图像会存在像素强度分布不均匀的问题,影响分割的质量。

针对此类问题,Liu等^[3]提出一种基于局部图像统计的活动轮廓模型。通过引入局部特征函数,再结合概率分数边缘等信息,形成能够精确捕捉感兴趣区域边界的能量函数并以此积极感应图像像素之

间分布差异,在训练中Dice系数达到97.7%。对于肾脏区域,该模型并未进行有效的实验。Pandey等^[4]对于肾脏区域的分割提出一种基于活动轮廓和深度学习的自动化分割技术。该技术通过在3D U-Net网络中融入活动轮廓模型,以此集中模型的注意力来解决肾脏区域分割时边界模糊的问题,并在验证数据集集中取得高达97.6%的Dice系数。然而该方法缺乏对于图像重要信息的保护。Shabbir Tamboli等^[5]提出一个优化的主动轮廓模型。在该模型中通过使用改进的蜜蜂优化算法来微调主动轮廓模型的权重因子和最大迭代次数,并且可以分别对图像的感兴趣区域和背景区域进行压缩提取关键信息,实现较高的压缩比,同时保持图像的重要信息^[6]。Pang等^[7]提出一种用于超声和3T/5T磁共振图像分割的自适应加权曲率活动轮廓模型。该模型采用热核卷积操作来近似分割曲线的周长,减少计算复杂性。同时,高阶总变分项中的加权参数可以根据输入图像自动评估,同时利用交替方向乘子法将原始问题转化为易于解决的子问题以强调局部结构并提高分割精度^[8]。然而该方法过度依赖于人工标签。Fallahdizchah等^[9]提出的基于形态驱动阈值的顺序活动轮廓方法,可以实现无需标签或者训练便可以适应超声图像中腹水的不同形状、大小和位置。在该方法中提出一种新的贝叶斯活动轮廓算法,通过该算法获得的Dice系数为82.5%。分割时首先使用形态驱动阈值法自动定位腹水的初始轮廓,然后将识别的初始轮廓输入到新的顺序活动轮廓算法中,以便准确地从背景中分割出腹水。

1.2 阈值分割方法

基于数学原理的阈值模型是根据目标图像的灰度与颜色特征,运用相应的数学算法(高斯算法、sobel滤波算法等)进行区域边缘像素值的计算以实现分割。对于目前正在使用的各类医学图像(X光图像、热成像图像与CT图像等)而言,在基于阈值分割方法之上进行各类优化创新对于目标图像的分割具有重大意义。

针对于热成像医学图像的分割,Houssein等^[10]提出一种基于改进黑猩猩优化算法(IChOA)的多级阈值分割方法^[11]。该方法在技术创新上利用反向学习和Lévy飞行策略,并且结合Otsu和Kapur两种不同的目标函数使得分割结果更加全面与准确。对于2D与3D图像的分割,Hosny等^[12]提出基于混合冠状病毒优化算法(COVIDOA)和哈里斯鹰优化算法(HHOA)的多级阈值分割技术,提高医学图像分割的效率。但是该算法并未考虑到图像的空间信息和上下文信息,因此可能导致分割结果出现噪声和不连续性。Houssein

等^[13]提出的基于对立蛇优化算法(SO-OBL)的多级阈值图像分割方法利用蛇的独特交配行为和对立学习(OBL)策略,可以在分割过程中利用原始解和对立解来实现上下文信息的搜索效率,从而很好地解决了分割结果噪声影响等问题。因此,该方法在最大程度上实现了图像各类信息包括上下文信息的联系与利用,提高图像分割的质量。Katherine等^[14]根据CT医学图像的特性,将Hounsfield单位值(HU)和Otsu阈值法相结合提出一种基于HU值和Otsu阈值法的CT扫描图像分割方法,该方法可以实现对心脏的三维分割重建。此分割模型通过利用HU值作为输入,Otsu阈值法可以自动准确地确定最佳阈值,实现图像的分割。但是该模型缺乏考虑目标组织的特征与范围。图像的每一类信息对图像的分割都存在切实的意义。Guo等^[15]对于图像分割中缺乏应用的信息问题,提出一种基于改进鲸鱼群算法的多阈值图像分割方法。该方法利用改进的鲸鱼群算法结合非局部均值二维直方图,利用非局部均值滤波和灰度图像生成分割效果图,以此来提高分割图像的质量与效果。

基于数学原理的传统阈值分割模型及其各类变体在实际的应用中是一类非常简单且易实现的分割方法,只需要少量的参数与运算资源,而且该类模型适用于多种类型的医学图像,具有优异的通用性。在未来图像分割方法的研究中,可以考虑将深度学习交叉注意力机制与传统医学图像分割方法相结合,通过动态学习分配不同序列元素之间的权重,从而使模型能够专注于与当前任务相关的重要信息,实现更高精度的分割。

2 基于深度学习方法在医学图像分割中的应用

随着人工智能技术的不断发展,深度学习技术也在不断进步。基于深度学习的医学图像分割方法是通过利用神经网络实现对医学图像的精确分割。该类深度学习分割方法实现分割的大致机理是通过卷积神经网络(CNN)或者其各类变体对医学图像中的特征与结构进行学习及提取,并根据各类特征及像素值之间的关系勾画出目标区域实现分割^[16]。目前在深度学习领域中常见的一些分割框架可以归类为以下几种:任意分割模型(SAM)框架、SegNet框架、Mask R-CNN框架,以及基于U-Net及其变体的框架。

2.1 SAM框架

SAM是一个用于实现图像分割的大模型,该模型可以零样本学习以及实现在各类医学图像上的分割^[17]。SAM的强大优势是通过交互式分割引入可提

示分类的新任务类型,允许其在新的图像及分割任务中实现零转移。

Roy等^[18]对SAM进行介绍与相应的实验验证。在实验中研究者们使用SAM对腹部CT器官分割任务进行初步评估,展示模型在没有特定类别样本情况下的分割能力;同时该模型融合视觉提示工程来提高分割的精度,体现出该模型所具有的半自动分割性能。但是其在多数据集上训练的效果不佳。Wu等^[19]在原始的SAM模型上提出医用SAM适配器(Med-SA)分割架构,很好地解决这一问题。该架构是在SAM中植入了空间深度转置模块与Hyper-Prompting适配器,以此实现SAM从2D向3D图像进行适应。该模型在17个训练数据集上都取得很好的效果,并且仅仅只对2%的参数进行更新就超过了多个最新技术水平的方法,然而该模型要求较高的部署成本与存储成本。Zhang等^[20]基于SAM提出了一种名为SAMed的医学图像分割模型。其创新在于采用低秩调整策略对SAM图像编码器进行微调,降低参数大幅调整的可能性,减少运行和部署的成本,并结合提示编码器和掩码解码器在标记的医学图像数据集上进行训练;通过优化策略,SAMed在多器官分割数据集Synapse上的Dice系数达到82.9%。Chen等^[21]针对于血管等区域的分割提出一种名为SAM-OCTA的分割模型。该类模型为了细化分割区域,采用基础模型细调和低秩适应技术,并对多分割任务使用相应的提示点生成策略来处理光学相干断层血管造影图像分割问题。SAM-OCTA在训练数据集OCTA-500上获得98.03%的准确率,超过大多数分割模型。然而,SAM-OCTA对低质量、低分辨率的图像分割还存在着明显的不足。针对这一问题,Wang等^[22]通过在模型框架中使用并行框对原始低分辨率图像进行处理,使用传统分割网络预测粗糙掩码来生成精细边界框,再通过合并策略减少计算资源,对低分辨率图像特征信息实现精细化。

2.2 基于SegNet的分割框架

SegNet医学图像分割技术是一种基于像素级别的图像分割方法,该类分割方法的创新在于将编码器-解码器结构进行优化与升级,并且可以很好地应用语义分割任务。但是该类基础模型存在需要参数量过大与计算量过高等缺点。为此,Alqazzaz等^[23]提出一种基于SegNet的自动脑肿瘤分割模型。通过训练4个SegNet模型结合它们的特征图和原始图像像素值进行分割。该分割模型中用到的决策树分类器比单一模态MR图像分割具有更高的精度,并通过特征融合形成分割所需要的参考特征向量。但是其目前仅局限于单一数据集训练。对此,Peiris等^[24]提出

一种叫做 Duo-SegNet 的半监督医学图像分割模型。Duo-SegNet 中应用置信区域交换技术可为对抗学习产生置信度图^[25],通过该置信度图可以选择分割网络预测结果中更为可靠的区域,提高分割结果的准确性。不过,对抗学习一般在模型中的收敛是极其不稳定的。由此 Kuang 等^[26]提出一个用于医学图像分割的身体和边缘感知网络(BEA-SegNet),在 BEA-SegNet 中应用短期多尺度结合模块(STMSC)实现在不增加参数的情况下学习高层次的多尺度特征表示,并且还使用解码器与监督器进行分割与提高精度。该类创新打破了单一数据集的局限性,增加了应用的普遍性,在 ISIC2018 上的准确率达到 95.5%。然而,优秀的分割方法需要考虑全局与局部信息融合。因此 Gai 等^[27]提出一种用于医学图像分割的全局-局部表示学习网络 GL-Segnet。该网络中嵌入的特征编码器可以使用多尺度卷积(MSC)和多尺度池化(MSP)模块在浅层网络编码全局语义来表示信息,同时使用多尺度特征融合操作跨层丰富局部几

何细节信息实现高效分割,具有 91.5% 的准确率。Kibriya 等^[28]根据图像语义提出一个基于 SegNet 的语义分割模型,可以用来分割皮肤镜图像中的黑色素瘤皮损。该分割模型使用轻量级的网络架构,在其中使用了编码器-解码器结构,利用编码器的最大池化层的索引来进行上采样并作为解码器的输入,避免过度下采样和特征丢失。但是该方法很难应用于不同模态的图像,并且对图像的分辨率与质量要求较高。最后,基于存在的这些问题,Ahmed 等^[29]提出一种叫做 Twin-SegNet 的双流分割框架。该模型在原始模型基础上进行了多种创新,利用部分通道重标定(PCR)来计算通道注意力权重从而实现特征交换和梯度传播^[30]。并通过一个限定区域的均方误差来惩罚重建误差,从而促进两个流的协同优化。对不同的图像模态、分辨率、对比度和噪声水平而言,模型的泛化能力显著提升,同时保持较高的分割精度和边缘质量。基于 SegNet 分割技术的各类创新模型指标比较如表 1 所示。

表 1 基于 SegNet 的各分割模型性能比较
Table 1 Performance comparison of segmentation frameworks based on SegNet

框架来源	测试数据集	创新应用	灵敏度	特异度	准确率	Dice 系数
Alqazzaz 等 ^[23]	BraTS 2017	决策树分类器	0.767	0.954	0.933	0.783
Peiris 等 ^[24]	Nuclei	置信区域交换技术	-	-	-	0.881
Kuang 等 ^[26]	ISIC2018	STMSC	0.921	0.965	0.955	0.903
Gai 等 ^[27]	ISIC	MSC+MSP	0.942	-	-	0.915
Kibriya 等 ^[28]	ISIC	编码器-解码器结构	0.750	-	0.890	-
Ahmed 等 ^[29]	BUSI	部分通道重标定	0.809	-	0.895	-

2.3 基于 Mask R-CNN 的分割模型框架

Mask R-CNN 是一类用于实例分割的模型,针对主流分割模型只能实现单一目标分割任务的缺点,基于 Mask R-CNN 及其变体的分割框架有效地解决了此类问题。Shibata 等^[31]提出一种基于 Mask R-CNN 的医学图像分割方法。该方法使用 Mask R-CNN 进行胃癌检测和图像分割,同时使用五折交叉验证方法,将数据集随机分成 5 个子集,每次用 1 个子集作为测试集,其余 4 个子集作为训练集,重复 5 次,得到平均的评估指标。但是该模型受到分割目标单一的局限。为了实现多目标分割,Shu 等^[32]提出一个改进的 Mask R-CNN 模型。该模型在区域建议网络(RPN)中提出一种感兴趣区域生成方法,利用多尺度的语义特征,在原始的 mask 分支中生成一个用于背景分类的子网络^[33]。该模型能够准确地分割出各目

标区域,在数据集 BCDR 上的准确率与 Dice 系数分别达到 99.5% 与 98.9%。一种改进的 Mask R-CNN 网络被芦苇等^[34]提出,通过复用低层特征信息,提高对小目标的检测能力和特征金字塔的融合能力,最终根据所需分割的器官或病变区域的特性,实现精确有效分割。但是其分割边界的光滑程度还有提升的空间。因此,Li 等^[35]提出一种基于 3D-Mask RCNN 的自动分割和检测模型。该分割模型在 RPN 组件中使用了 3D CNN 从 MRI 中提取特征,并且使用 RoI Pooling 方法改进后的 RoI Align 模型来对齐建议的区域和特征图。Yao 等^[36]提出一种基于转移学习的 DenseSE-Mask R-CNN 网络模型,将 PET 图像中的肿瘤相关信息迁移至 MR 图像中,以提供先验知识^[37]。该模型中植入 Dense block 和 SE block,该两类模块的植入可以提高网络对有效信息的敏感度,增加模型

对目标图像的深层特征提取与融合,对19个患者的PET/MRI图像数据训练的Dice系数达到99.7%。最后,Kiernan等^[38]针对颈动脉内膜图像分割提出了Mask R-CNN网络。该网络以MimickNet B-mode作为主要框架,将传统的延迟求和图像转换为近似的

动态组织对比度增强(DTCE)处理后图像;嵌入的奇异值分解滤波消除高阶奇异值来抑制随机噪声,减少图像中的斑点噪声。该模型具有极高的正确率与自动化水平。基于Mask R-CNN的各分割模型性能比较如表2所示。

表2 基于Mask R-CNN的各分割模型性能比较
Table 2 Performance comparison of segmentation frameworks based on Mask R-CNN

框架来源	测试数据集	创新应用	灵敏度	特异度	准确率	Dice系数
Shibata等 ^[31]	自收集数据	五折交叉验证方法	-	-	-	0.720
Shu等 ^[32]	BCDR	区域建议网络	0.990	1	0.995	0.989
卢苇等 ^[34]	自收集数据	复用低层特征信息	-	-	-	-
Li等 ^[35]	自收集数据	RoI Align模型	0.861	0.827	0.851	-
Yao等 ^[36]	PET/MRI Dataset	迁移学习	0.786	0.997	-	0.997
Kiernan等 ^[38]	自收集数据	奇异值分解滤波	-	-	-	-

2.4 基于U-NET的分割框架

U-NET于2015年被提出,它是一种U型对称结构的网络模型^[39]。该类模型融合了跳跃连接,将编码器-解码器之间进行层层对应,有助于保留图像更加丰富的全局上下文信息。Zhang等^[40]在U-Net模型的基础上,提出了DIU-Net医学图像分割模型,并且在该模型的U-Net架构中结合DenseNet和GoogLeNet。使用不同大小的卷积核和残差连接结构来增加网络的稳定性和宽度,提高分割的精度,在混合数据集DRIVE2+STARE3+CHASE_DB14中Dice系数为95.8%,准确率达到96.6%。但是DIU-Net学习到的特征之间的交互性较弱。对于提升特征的交互性问题,变换器(Transformer)具有明显的效果。Petit等^[41]将U型全卷积网络与Transformer的注意力机制相结合,提出U-Transformer网络。该网络应用了自注意力(MHSA)和交叉注意力(MHCA)模块^[42],可以分别提取全局结构特征与过滤非语义特征,提高复杂和低对比度解剖结构的分割精度。除此之外,Su等^[43]还提出多尺度分割模型U-Net(MSU-Net)。通过应用多尺度块(multi-scale block),使用不同感受野的卷积核来提取和恢复图像特征^[44],并在特征之间应用交互式跳跃连接提高分割精度。不过该类模型都需要耗费时间与空间资源。Wang等^[45]提出一种混合变换器U-Net模型。该模型应用局部-全局高斯加权自注意力机制(LGG-SA),可以在不同的粒度上捕捉图像的局部和全局依赖关系,同时通过一个可学习的高斯矩阵来增强近邻区域的权重,促进特征间交互。值得一提的是,该模型不依赖于大规模的

预训练数据集,这使得它更适合于小数据医学图像分割任务。最后,Chen等^[46]基于U-Net结合Transformer和多级注意力机制,提出TransAttUnet分割模型,该模型应用Transformer自注意力(TSA)和全局空间注意力(GSA)两种技术,捕捉编码器特征之间的长距离依赖关系和全局空间关系^[47]。将多尺度跳跃机制融合其中,生成更优的特征表示。该模型有效弥补了U-Net在建模长距离上下文信息方面的不足,提高分割的精度和质量。Cao等^[48]提出一种基于深度神经网络的改进模型RASNet。该模型中引入多尺度空间感知模块(MSPM),并利用其不同尺度的空洞卷积扩大感受野,捕获多尺度的信息,保留目标的原始形状。通过带注意力连接的解码模块(DMAC)抑制背景噪声的干扰,细化目标边缘的预测,提高分割的准确性。在SPECT中训练的准确率高达99.4%,Dice系数为96.3%。从表3可以看到Cao等^[48]提出的模型具有更好的分割效果。

3 总结与展望

基于深度学习与传统的医学图像分割模型可以有效且准确地辅助医生对患者制定针对性的治疗方案。对于各类医学图像的目标区域勾画而言,实现自动、快速、准确的图像分割具有重大意义。手动勾画感兴趣区域不仅费时费力,而且这类方法只能捕捉到医生感兴趣的特定区域或特征,忽略了其他可能潜在的重要信息;并且勾画的结果通常缺乏标准化和量化的特征,难以进行可靠的比较和分析。这些情况可能导致对患者病情的全面评估不足,从而

表 3 基于 U-NET 的各分割模型性能比较

Table 3 Performance comparison of segmentation frameworks based on U-NET

框架来源	测试数据集	创新应用	灵敏度	特异度	准确率	Dice 系数
Zhang 等 ^[40]	DRIVE2+STARE3+CHASE_DB14	结合 DenseNet 和 GoogLeNet	0.797	0.986	0.966	0.958
Petit 等 ^[41]	TCIA	MHSA+MHCA	-	-	-	0.785
Su 等 ^[43]	CXR	multi-scale block	-	-	0.887	0.929
Wang 等 ^[45]	ACDC	局部-全局高斯加权自注意力机制	-	-	-	0.904
Chen 等 ^[46]	ISIC-2018	Transformer 自注意力	-	-	0.963	0.907
Cao 等 ^[48]	SPECT	多尺度空间感知模块 (MSPM)	0.959	0.997	0.994	0.963

影响最终的诊断和治疗效果。因此采用计算机模型方法不仅提高了图像分割效率,还有效解决了这些问题。本文针对目前各类医学图像分割方法及其创新变体进行全面综述,特别关注基于深度学习的方法,并详细分析这些方法在各类数据集上的分割性能。观察到目前基于深度学习的医学图像分割方法成功克服了传统方法在分割效果和速度方面的不足,实现了显著的性能提升。

根据目前较主流的基于 U-Net 框架模型在医学图像分割上的创新与临床应用所展示出的显著优势,未来在 U-Net 创新上可以通过引入领域自适应和迁移学习等技术,借鉴其他领域或任务的知识,将其迁移应用到医学图像分割任务中,以应对数据稀缺或特定领域的挑战,实现分割性能的提升。对医学领域的需求,基于深度学习的自动化医学图像分割存在着一系列的机遇与挑战,是一个具有巨大创新潜力的研究领域。但是,考虑到深度学习模型在硬件和计算资源等方面的不足,目前尚未在临床应用中得到充分体现。随着科技的不断进步和研究人员的不懈努力,我们完全有理由相信未来将出现更多符合临床需求、具备实际临床价值的方法。这些方法有望为各类疾病诊断和治疗提供更准确、可靠的支持,从而在医疗领域发挥重要作用。

【参考文献】

[1] Wang L, Chang CH, Liu ZQ, et al. A medical image fusion method based on SIFT and deep convolutional neural network in the SIST domain[J]. J Healthc Eng, 2021, 2021: 9958017.

[2] 王相海, 方玲玲. 活动轮廓模型的图像分割方法综述[J]. 模式识别与人工智能, 2013, 26(8): 751-760.

Wang XH, Fang LL. Survey of image segmentation based on active contour model[J]. Pattern Recognition and Artificial Intelligence, 2013, 26(8): 751-760.

[3] Liu HX, Fang JX, Zhang ZJ, et al. Localised edge-region-based active contour for medical image segmentation[J]. IET Image Process, 2021, 15(7): 1567-1582.

[4] Pandey M, Gupta A. Tumorous kidney segmentation in abdominal CT images using active contour and 3D-UNet[J]. Ir J Med Sci, 2023, 192(3): 1401-1409.

[5] Shabbir Tamboli S, Butta R, Sharad Jadhav T, et al. Optimized active contour segmentation model for medical image compression [J]. Biomed Signal Process Control, 2023, 80, Part 1: 104244.

[6] 李伟强, 徐建城, 殷剑锋. 蜜蜂群优化算法用于训练前馈神经网络 [J]. 计算机工程与应用, 2009, 45(24): 43-45.

Li WQ, Xu JC, Yin JF. Bee colony optimization algorithm for training feed-forward neural net-works [J]. Computer Engineering and Applications, 2009, 45(24): 43-45.

[7] Pang ZF, Geng MX, Zhang L, et al. Adaptive weighted curvature-based active contour for ultrasonic and 3T/5T MR image segmentation[J]. Signal Process, 2023, 205: 108881.

[8] 夏书育. 目标函数耦合的交替方向乘子法的研究[D]. 南京: 南京财经大学, 2020.

Xia SY. Research on alternating direction multiplier method of coupling of objective function[D]. Nanjing: Nanjing University of Finance & Economics, 2020.

[9] Fallahdizchah A, Laroia S, Wang C. Sequential active contour based on morphological-driven thresholding for ultrasound image segmentation of ascites[J]. IEEE J Biomed Health Inform, 2023, 27(9): 4305-4316.

[10] Houssein EH, Emam MM, Ali AA. An efficient multilevel thresholding segmentation method for thermography breast cancer imaging based on improved chimp optimization algorithm[J]. Expert Syst Appl, 2021, 185: 115651.

[11] Khishe M, Mosavi MR. Chimp optimization algorithm[J]. Expert Syst Appl, 2020, 149: 113338.

[12] Hosny KM, Khalid AM, Hamza HM, et al. Multilevel segmentation of 2D and volumetric medical images using hybrid coronavirus optimization algorithm[J]. Comput Biol Med, 2022, 150: 106003.

[13] Houssein EH, Abdalkarim N, Hussain K, et al. Accurate multilevel thresholding image segmentation via oppositional snake optimization algorithm: real cases with liver disease[J]. Comput Biol Med, 2024, 169: 107922.

[14] Katherine, Rulaningtyas R, Ain K. CT scan image segmentation based on hounsfield unit values using Otsu thresholding method[C]//Journal of Physics: Conference Series. Bristol, United Kingdom: IOP Publishing, 2021: 012080.

[15] Guo HL, Li MY, Liu HB, et al. Multi-threshold image segmentation based on an improved Salp swarm algorithm: case study of breast cancer pathology images[J]. Comput Biol Med, 2024, 168: 107769.

[16] Karpathy A. Convolutional neural networks for visual recognition[J]. Notes accompany the Stanford CS class CS231, 2017.

[17] Mazurowski MA, Dong HY, Gu HX, et al. Segment anything model for medical image analysis: an experimental study[J]. Med Image Anal, 2023, 89: 102918.

[18] Roy S, Wald T, Koehler G, et al. SAM.MD: zero-shot medical image segmentation capabilities of the segment anything model[EB/OL]. (2023-04-10). <https://arxiv.org/abs/2304.05396>.

[19] Wu JD, Ji W, Liu YP, et al. Medical SAM adapter: adapting segment anything model for medical image segmentation[EB/OL]. (2023-12-29). <https://arxiv.org/abs/2304.12620>.

[20] Zhang KD, Liu D. Customized segment anything model for medical image segmentation [EB/OL]. (2021-10-17). <https://arxiv.org/abs/2304.13785>.

- [21] Chen XR, Wang CL, Ning HJ, et al. SAM-OCTA: prompting segment-anything for OCTA image segmentation[EB/OL]. (2024-03-20). <https://arxiv.org/abs/2310.07183>.
- [22] Wang HH, Ye HZ, Xia Y, et al. Leveraging SAM for single-source domain generalization in medical image segmentation[EB/OL]. (2024-01-04). <https://arxiv.org/abs/2401.02076>.
- [23] Alqazzaz S, Sun XF, Yang X, et al. Automated brain tumor segmentation on multi-modal MR image using SegNet[J]. Comput Vis Media, 2019, 5(2): 209-219.
- [24] Peiris H, Chen ZL, Egan G, et al. Duo-SegNet: adversarial dual-views for semi-supervised medical image segmentation[C]//Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 428-438.
- [25] Huang L, Joseph AD, Nelson B, et al. Adversarial machine learning [C]//Proceedings of the 4th ACM Workshop on Security and Artificial Intelligence. New York, NY, USA: ACM, 2011: 43-58.
- [26] Kuang HL, Liang YX, Liu N, et al. BEA-SegNet: body and edge aware network for medical image segmentation[C]//2021 IEEE International Conference on Bioinformatics and Biomedicine (BIBM). Piscataway, NJ, USA: IEEE, 2021: 939-944.
- [27] Gai D, Zhang JQ, Xiao YS, et al. GL-segnet: global-local representation learning net for medical image segmentation [J]. Front Neurosci, 2023, 17: 1153356.
- [28] Kibriya H, Abdullah I, Kousar F. Melanoma lesion segmentation and classification using SegNet[C]//2023 4th International Conference on Advancements in Computational Sciences (ICACS). Piscataway, NJ, USA: IEEE, 2023: 1-6.
- [29] Ahmed S, Hasan MK. Twin-SegNet: dynamically coupled complementary segmentation networks for generalized medical image segmentation[J]. Comput Vis Image Underst, 2024, 240: 103910.
- [30] Woo S, Park J, Lee JY, et al. CBAM: convolutional block attention module [C]//Computer Vision-ECCV 2018. Cham: Springer International Publishing, 2018: 3-19.
- [31] Shibata T, Teramoto A, Yamada H, et al. Automated detection and segmentation of early gastric cancer from endoscopic images using mask R-CNN[J]. Appl Sci, 2020, 10(11): 3842.
- [32] Shu JH, Nian FD, Yu MH, et al. An improved mask R-CNN model for multiorgan segmentation[J]. Math Probl Eng, 2020, 2020: 8351725.
- [33] 熊金波, 毕仁万, 陈前昕, 等. 边缘协作的轻量级安全区域建议网络[J]. 通信学报, 2020, 41(10): 188-201.
Xiong JB, Bi RW, Chen QX, et al. Towards edge-collaborative, lightweight and secure region proposal network [J]. Journal on Communications, 2020, 41(10): 188-201.
- [34] 卢苇, 刘丹, 邵敏, 等. 改进Mask R-CNN网络在医学图像识别与分割中的应用[J]. 计算机工程与应用, 2021, 57(24): 234-241.
Lu W, Liu D, Shao M, et al. Application of improved Mask R-CNN network in medical image recognition and segmentation[J]. Computer Engineering and Applications, 2021, 57(24): 234-241.
- [35] Li ST, Zhang L, Guo P, et al. Prostate cancer of magnetic resonance imaging automatic segmentation and detection of based on 3D-mask RCNN[J]. J Radiat Res Appl Sci, 2023, 16(3): 100636.
- [36] Yao Y, Chen Y, Gou SP, et al. Auto-segmentation of pancreatic tumor in multi-modal image using transferred DSMask R-CNN network[J]. Biomed Signal Process Control, 2023, 83: 104583.
- [37] Pan SJ, Yang Q. A survey on transfer learning[J]. IEEE Trans Knowl Data Eng, 2010, 22(10): 1345-1359.
- [38] Kiernan MJ, Al Mukaddim R, Mitchell CC, et al. Lumen segmentation using a mask R-CNN in carotid arteries with stenotic atherosclerotic plaque[J]. Ultrasonics, 2024, 137: 107193.
- [39] 周涛, 董雅丽, 霍兵强, 等. U-net网络医学图像分割应用综述[J]. 中国图象图形学报, 2021, 26(9): 2058-2077.
Zhou T, Dong YL, Huo BQ, et al. U-net and its applications in medical image segmentation: a review[J]. Journal of Image and Graphics, 2021, 26(9): 2058-2077.
- [40] Zhang ZA, Wu CD, Coleman S, et al. DENSE-INception U-net for medical image segmentation[J]. Comput Methods Programs Biomed, 2020, 192: 105395.
- [41] Petit O, Thome N, Rambour C, et al. U-net transformer: self and cross attention for medical image segmentation[C]//Machine Learning in Medical Imaging. Cham: Springer International Publishing, 2021: 267-276.
- [42] 张宸嘉, 朱磊, 俞璐. 卷积神经网络中的注意力机制综述[J]. 计算机工程与应用, 2021, 57(20): 64-72.
Zhang CJ, Zhu L, Yu L. Review of attention mechanism in convolutional neural networks [J]. Computer Engineering and Applications, 2021, 57(20): 64-72.
- [43] Su R, Zhang DY, Liu JH, et al. MSU-net: multi-scale U-net for 2D medical image segmentation[J]. Front Genet, 2021, 12: 639930.
- [44] Li YH, Chen YT, Wang NY, et al. Scale-aware trident networks for object detection[C]//2019 IEEE/CVF International Conference on Computer Vision (ICCV). IEEE, 2019: 6053-6062.
- [45] Wang HY, Xie SA, Lin LF, et al. Mixed transformer U-net for medical image segmentation [C]//ICASSP 2022-2022 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP). Piscataway, NJ, USA: IEEE, 2022: 2390-2394.
- [46] Chen BZ, Liu YS, Zhang Z, et al. TransAttUnet: multi-level attention-guided U-net with transformer for medical image segmentation[J]. IEEE Trans Emerg Top Comput Intell, 2024, 8(1): 55-68.
- [47] Wang XL, Girshick R, Gupta A, et al. Non-local neural networks[C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ, USA: IEEE, 2018: 7794-7803.
- [48] Cao GY, Sun ZQ, Wang CL, et al. RASNet: renal automatic segmentation using an improved U-net with multi-scale perception and attention unit[J]. Pattern Recognit, 2024, 150: 110336.

(编辑: 薛泽玲)