

基于解剖结构感知的宫颈癌危及器官结肠 CT 分割

张宇鑫¹, 谢耀钦², 孙德宇³, 高玉华⁴, 崔明⁵, 秦文健*

¹ (中国科学院大学深圳先进技术研究院, 深圳 518055)

² (中国科学院大学深圳先进技术研究院, 深圳 518055)

³ (辽宁省肿瘤医院, 沈阳 110042)

⁴ (辽宁省肿瘤医院, 沈阳 110042)

⁵ (辽宁省肿瘤医院, 沈阳 110042)

* (中国科学院大学深圳先进技术研究院, 深圳 518055)

摘要: 宫颈癌是全球女性癌症死亡的主要原因之一, 放疗是治疗宫颈癌的一种常见方式, 精确分割危及器官对于准确估算放疗剂量、最大程度地保护正常组织免受辐射损伤至关重要。管状结构(如结肠)的自动分割仍面临挑战, 肠道的褶皱和运动伪影等因素会影响分割效果, 同时, 宫颈癌内放疗数据中的放射源也会降低 CT 的影像质量, 进一步影响分割效果。本文提出了一种结合中心线和距离图信息的宫颈癌管状危及器官分割方法, 通过增强网络对解剖结构的理解, 改善管状器官的拓扑结构识别, 并定位其在人体内的空间关系, 从而提高分割精度并优化放疗剂量分布。通过对宫颈癌内放疗数据集的实验评估, 使用 Dice 相似度系数 (DSC)、交并比 (IoU)、召回率 (Recall) 和 95% 豪斯多夫距离 (HD95) 等指标进行性能分析。实验结果显示, 本文方法在多数指标均优于基线网络 ResUNet, 具体表现为: DSC 为 71.58%, IoU 为 52.12%, Recall 为 79.03%, 分别较 ResUNet 提高了 11.29%、7.84%、12.7%, HD95 为 10.06, 较 ResUNet 下降 1.76。实验表明, 本文方法能有效提高结肠在宫颈癌内放疗 CT 影像中的分割精度, 减少复杂器官和影像质量对分割结果的影响。

关键词 宫颈癌; 危及器官; 管状器官分割; CT 图像; U-Net

中图分类号: TP 183 文献标志码: A doi: 10.12146/j.issn.2095-3135.20241129003

Anatomical structure-aware CT segmentation of organ-at-risk colorectum for cervical cancer

来稿日期: 2024-11-29 修回日期: 2025-01-16

基金项目: 国家自然科学基金区域创新发展联合基金, 面向宫颈癌近距离放疗实时精准导航系统关键技术研究 (U20A20373)

作者简介: 张宇鑫, 硕士研究生, 研究方向为医学图像处理; 谢耀钦, 研究员, 研究方向为医学图像处理; 孙德宇, 主任医师, 研究方向为放射治疗; 高玉华, 主任医师, 研究方向为宫颈癌根治性放疗; 崔明, 博士, 研究方向为放射治疗; 秦文健 (通讯作者), 研究员, 研究方向为医学成像, Email: wj.qin@siat.ac.cn

ZHANG Yuxin¹, XIE Yaoqin², SUN Deyu³, GAO Yuhua⁴, CUI Ming⁵, QIN Wenjian*

¹(Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen, 518055, China)

²(Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen, 518055, China)

³(Liaoning Cancer Hospital, Shenyang, 110042, China)

⁴(Liaoning Cancer Hospital, Shenyang, 110042, China)

⁵(Liaoning Cancer Hospital, Shenyang, 110042, China)

* (Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Shenzhen, 518055, China)

Corresponding Author: QIN Wenjian, Shenzhen Institute of Advanced Technology, Chinese Academy of Sciences, Email: wj.qin@siat.ac.cn

Abstract Cervical cancer is one of the leading causes of cancer-related death among women globally, and radiotherapy is a common treatment method for cervical cancer. Accurate segmentation of organs-at-risk is crucial for accurately estimating radiotherapy doses and maximizing protection of normal tissues from radiation damage. However, automatic segmentation of tubular structures, such as the colon and rectum, remains challenging. Factors such as intestinal folds and motion artifacts can affect the segmentation performance, and at the same time, the radiation sources in cervical cancer brachytherapy data can degrade the quality of CT images, further impacting the segmentation results. This paper proposes a method for the segmentation of tubular organ-at-risk in cervical cancer based on centerline and distance map information. By enhancing the network's understanding of anatomical structures, the method improves the identification of the topological structure of tubular organs and their spatial relationships within the human body, thus improving segmentation accuracy and optimizing radiotherapy dose distribution. Through experimental evaluation on a cervical cancer brachytherapy dataset, performance analysis was conducted using metrics such as Dice Similarity Coefficient (DSC), Intersection over Union (IoU), Recall, and 95% Hausdorff Distance (HD95). The experimental results show that the proposed method outperforms the baseline network ResUNet in most metrics, specifically with a DSC of 71.58%, an IoU of 52.12%, a Recall of 79.03%, which improve by 11.29%, 7.84% and 12.7%, respectively, compared to ResUNet. The HD95 is 10.06, which is a decrease of 1.76 compared to ResUNet. The results indicate that the proposed method effectively improves the segmentation accuracy of the colon and rectum in cervical cancer brachytherapy CT images, reducing the impact of complex organs and image quality on the segmentation results.

Keywords cervical cancer; organ-at-risk; tubular organ segmentation; CT image; U-Net

Funding:

1 引言

结直肠的自动分割在宫颈癌的诊断与治疗中具有重要意义,尤其在宫颈癌放疗中,精确分割结直肠有助于医生优化放疗计划,准确投放放疗剂量至肿瘤区域,同时保护正常组织,减少对结直肠的辐射损伤及副作用^[1]。

近年来,自动化图像分割方法已成为放射学领域的重要研究方向。传统的医学图像分割方法,如基于阈值^[2]、边界检测^[3]和区域生长^[4]等技术,在面对拥有复杂解剖结构的器官时存在很大局限性。而卷积神经网络(CNN)^[5]凭借其特征提取能力成为医学图像分割的主流技术,其中 U-Net^[6]结构的提出极大地推动了生物医学图像的自动化分割任务,其改进版本如 U-Net++^[7]、Dense-U-Net^[8]和 Attention-U-Net^[9]等在全类医学图像分割任务中也取得了显著进展。此外,针对不同肿瘤类型,也涌现出许多深度学习分割方法,例如,Chongzhe Yan 等人^[10]基于 T2WI 和 ADC 提出一种多重分割模型,用于前列腺和肿瘤分割;Wenxia Wu 等人^[11]提出了一种并行生存预测和半监督肿瘤分割的多任务学习方法,来分割脑部肿瘤并提高生存预测的准确性。

在宫颈癌的诊断与治疗中,计算机断层扫描(CT)因其高分辨率、非侵入性以及快速扫描等优势,成为宫颈癌筛查和诊断的主要手段之一。但 CT 图像中肠道这些软组织器官区域对比度相对较低,深度学习方法虽能自动提取图像特征,但仍需进一步优化网络架构和特征融合策略以提高分割精度。而结直肠作为一种管状器官,其独特的解剖结构和复杂的形态变化给分割任务带来更多挑战,结直肠的拓扑结构、局部扩张、位置变化以及相邻器官的干扰,都可能影响分割精度。

针对复杂的拓扑结构,通常使用中心线来学习,以保证分割时的连续性,如 kumar 等人^[12]提出的血管分割、中心线跟踪和半径估计相结合的新方法,以及 Fengjun 等人^[13]、Jianqing Gao 等人^[14]、C. Kromm 等人^[15]针对不同管状结构的中心线提取及分割方法等。然而,当前中心线方法的应用主要集中在血管、骨架、道路等具有平滑边缘且无复杂褶皱或形态变化的管状结构分析上,在器官分割领域的应用较为有限,尤其是对于具有复杂形态和不规则边界的器官。器官的形态受个体差异影响较大,使传统的基于中心线的分割方法面临更多挑战。因此,如何将中心线方法引入到器官分割中,尤其是针对复杂器官形态的分割,仍然是一个亟待解决的问题。

结肠和直肠作为腹部器官,经常会出现位置不固定,形态过于复杂等问题,仅使用中心线提取无法完全捕捉其形态信息。因此需要与一些额外的信息例如结直肠的位置信息结

合使用来达到更好的效果。现有研究中经常使用距离来描述图像中不同区域之间的相对位置关系，从而提高器官定位的准确性，例如 Francesco 等人^[16]提出的基于距离约束的损失函数、Davood 等人^[17]的 Hausdorff 距离 (HD) 估计方法以及 Sanguk 等人^[18]的形状感知注意力模块等。然而这些研究基本都是将同一个组织的真实标签和预测结果做距离测算，并没有考虑不同组织之间的距离关系。本文提出用人体内位置相对固定的骨架作为相对位置参考，通过计算骨头与肠道之间的距离图，不仅可以得到分割目标的边界信息，还能够将分割重点放在一定的位置范围中。

受上述信息的启发，本文提出一种基于 ResUNet 的宫颈癌危及器官结直肠分割网络 ASA-Net (Anatomical Structure-Aware Network)，该网络进行了如下改进：(1)通过提取结直肠中心线获得结直肠拓扑解剖结构，保证分割过程中的拓扑结构准确性；(2)通过手工标注的骨架信息，计算与结直肠之间的距离图，定位结直肠位置解剖信息，从而提高分割准确性；(3)在网络编码器底层增加空间注意力模块，将不同编码器提取的特征进行融合，使分割网络充分学习提取到的结直肠解剖结构。

2 材料与方法

2.1 中心线提取

中心线是指二维或三维物体的中心骨架，是人体内重要的解剖信息。血管、肠道和骨骼等结构都有相应的中心线，能够反映它们的整体形状和拓扑结构。在结直肠CT图像分割中，提取中心线可以有效提高分割的连续性。尤其对于结直肠这种形态复杂的器官而言，确保中心线不间断即能保证结直肠分割的准确连通。

目前，中心线提取方法主要分为基于像素处理的方法和基于深度学习的方法。其中，像素处理方法中的骨架化操作是一种常见且高效的技术。该操作通过对管状结构进行重复腐蚀，同时保留其主要形态特征，逐步提取出目标结构的中心骨架。在实际应用中，我们可以借助开源图像处理库 (scikit-image)^[19]中提供的函数快速实现这一操作。

在提取出中心线后，为了进一步提高其连贯性，通常会使用膨胀操作修复由于噪声或分割误差导致的断裂区域。膨胀操作通过将中心骨架向四周扩展一定的像素距离，连接断开的部分，确保生成的中心线具有连续性和完整性。在形态学操作中，膨胀算子通过选择3*3的结构元素，对断裂的骨架区域进行局部扩展和连接，具体操作如图1所示。

2.2 距离图生成

距离图的生成是医学图像分割中常用的技术，广泛用于对预测结果与手工标注结果的对比分析。通过计算两者边界之间的HD，可以有效评估分割的精确度。为了优化分

割效果，通常将HD作为损失函数的组成部分，通过最小化HD来提高分割性能。然而，现有的大多数研究主要集中在优化分割边界的距离，而较少关注如何利用目标区域与参考结构之间的距离信息来进行器官定位和精准分割。

本文提出了一种基于骨骼的距离图生成方法，旨在通过引入解剖学参考距离信息来辅助结肠的分割与定位。具体来说，参考结构的选择对于分割效果至关重要，我们通过对数据集的分析，选定了股骨颈作为解剖学参考结构。股骨颈具有稳定且易于标注的解剖位置，并且其与腹部器官之间的距离关系，能够在一定程度上反映目标器官的解剖学分布特征。首先，我们利用医学影像标注工具3D Slicer进行阈值分割，初步提取股骨区域；然后，在骨骼分割的基础上，手动勾画股骨颈区域，生成股骨颈的精确标注。

在获得股骨颈标注后，我们使用SciPy库^[20]中的函数计算每个肠道像素(x, y)到股骨颈标注中最近像素点的欧几里得距离，如公式(1)所示。这一过程生成的距离图，不仅为目标器官的分割提供了解剖参考，还在一定程度上将分割任务聚焦于解剖学上合理的区域，从而提升分割的精确性和连贯性。

$$d = \sqrt{(x - x_t)^2 + (y - y_t)^2} \quad (1)$$

其中，(x, y)是肠道像素点，(x_t, y_t)是股骨颈标注中最近的像素点。具体距离图计算结构如下图1所示。

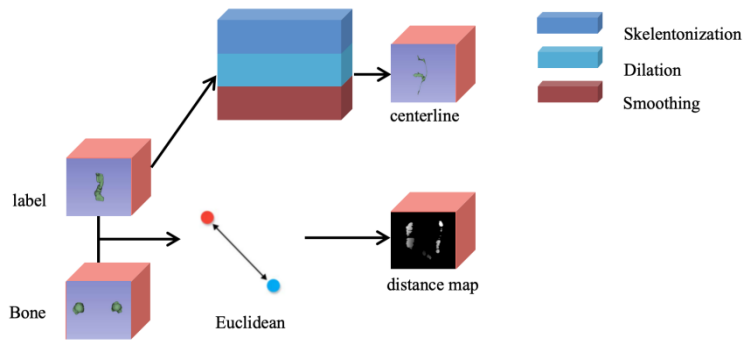


图1 中心线提取以及距离图生成

Fig.1 Centerline extraction and Distance map generation

2.3 整体网络结构

由于分割目标体积较小且局部细节特征难以提取，本文选用了ResUNet^[21]作为基线网络。ResUNet继承了3D-UNet^[22]经典的编码器-解码器架构，并在3D-UNet的基础上增

加了残差连接,帮助网络提取更多局部细节特征,对于体积占比较小,结构复杂的器官,分割效果会有明显提升。这一改进使得网络能够更好地捕捉三维图像中的细微结构和局部特征,同时通过增加空间维度的卷积运算,有效减轻了梯度消失问题,提升了网络的训练稳定性,最终增强了分割的性能和鲁棒性。

为进一步优化分割任务的性能,本文提出了一种基于ResUNet的改进网络 ASA-Net,该网络采用双编码器与三解码器的设计架构,如下图3所示。ASA-Net包含三个不同的学习任务,其中seg_net是肠道的分割任务,cl_net是肠道中心线学习任务,而dm_net是肠道距离图生成任务。seg_net和cl_net共享同一个编码器1提取特征图Feature Map1,而dm_net单独使用一个编码器2提取特征图Feature Map2。seg_net提取的Feature Map1与dm_net提取的Feature Map2通过注意力模块计算进行拼接,融合了来自seg_net和dm_net的多层次信息,确保分割任务能够捕捉到更加细腻边界特征和全局一致性,注意力计算模块如下图2所示。

在解码器阶段,三种任务分别学习,在seg_net进行分割任务的同时,cl_net的解码器2单独接收Feature Map1,用于学习目标器官的中心线拓扑结构,从而提升分割的连贯性和拓扑约束能力。dm_net的解码器3则单独处理Feature Map2,生成表示目标器官与参考骨骼之间空间关系的距离图,进一步优化目标区域的定位能力。

ASA-Net中的中心线学习任务与距离图生成任务在整个网络的训练过程中起到了辅助作用。这两个辅助任务通过引导编码器和解码器不断优化特征提取的准确性,帮助分割网络学习到更精确的解剖结构信息。具体而言,中心线学习任务通过关注目标器官的内在拓扑结构,确保了分割结果在空间上的连通性和形态一致性。距离图学习任务则利用目标器官与骨骼之间的空间相对位置关系,为分割提供了额外的定位约束,减少了误分割现象的发生。

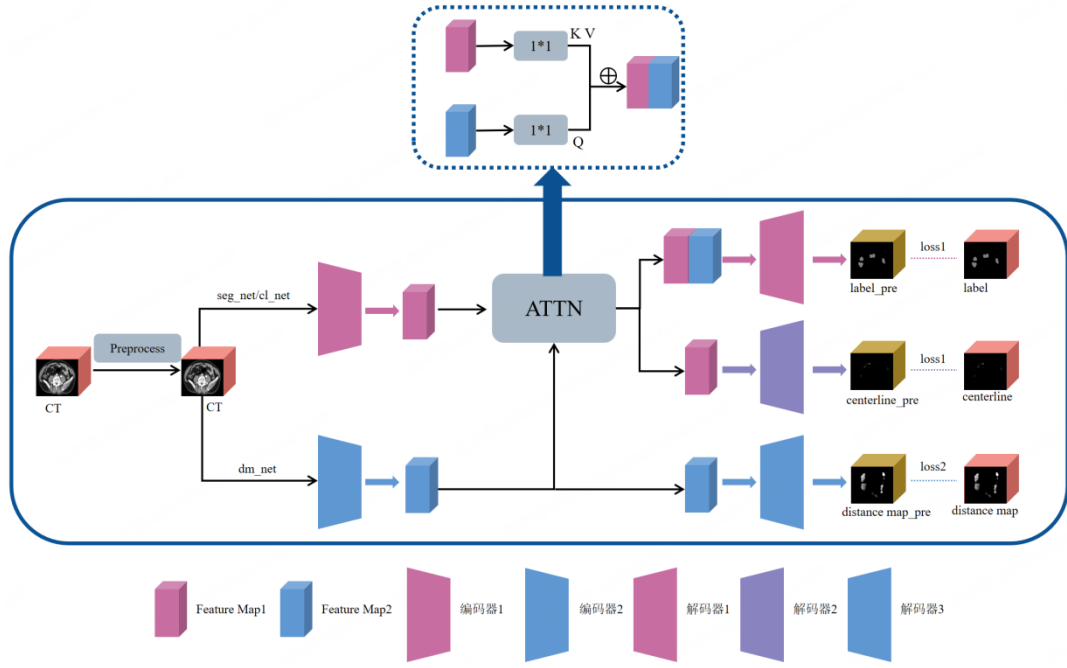


图2 全局网络结构

Fig.2 Overall network structure

2.4 损失函数

针对本文提出的三个任务,我们分别采用不同的损失函数来优化模型的参数。其中, seg_net 和 cl_net 的目标是分割图像区域,所以采用 Dice 损失函数^[23],该损失函数通过最大化真实标签与预测结果的重叠区域来衡量两者的相似性,从而提升分割精度。

Dice 损失函数的计算公式如公式 (2) 所示:

$$Loss_{Dice} = 1 - \frac{2 \sum_{i=1}^N p_i g_i}{\sum_{i=1}^N p_i^2 + \sum_{i=1}^N g_i^2} \quad (2)$$

其中, p_i 表示预测的概率值, g_i 表示真实标签的值(取值为 0 或 1), N 为总像素数。

dm_net 涉及距离回归,即每个像素的值代表距离目标结构的距离,我们采用 MSE 损失函数(Mean Squared Error)^[24],MSE 损失通过计算预测结果与真实标签之间的差值平方的平均值来评估预测的精确性,目标是 minimized 预测值与真实值之间的误差,优化每个像素的预测值,在回归任务中非常有效。其计算公式如公式 (3) 所示:

$$Loss_{MSE} = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (3)$$

其中， N 表示样本数量， y_i 为第 i 个样本的真实值， \hat{y}_i 为第 i 个样本的预测值。

上述设计通过合理选择不同任务的损失函数，充分考虑了分割任务的精度需求、中心线学习的拓扑约束以及距离图学习的回归特性，从而实现了对模型参数的有效优化，提升了整体分割性能。

3 实验结果

3.1 评估指标

本实验采用的评估指标包括 DSC、IoU、Recall 和 HD95，这些指标用于全面评估模型的分割性能，涵盖了重叠精度、边界一致性和检测能力等多个方面。DSC 是衡量预测结果与真实标签之间重叠程度的重要指标，其值范围在 0 至 1 之间，值越接近 1，表示预测结果与真实标签的相似度越高。DSC 的计算公式 (4) 如下：

$$DSC = \frac{2 \cdot |A \cap B|}{|A| + |B|} \quad (4)$$

其中， A 为模型预测的结果， B 为真实标签， $|A \cap B|$ 表示预测结果与真实标签的交集， $|A|$ 和 $|B|$ 分别表示预测结果和真实标签的像素数量。

IoU（交并比）是一种常见的分割评估指标，用于衡量预测结果与真实标签之间的重叠程度。其计算公式 (6) 如下。

$$IoU = \frac{|A \cap B|}{|A \cup B|} \quad (6)$$

其中， $|A \cap B|$ 表示预测结果与真实标签的交集， $|A \cup B|$ 表示两者的并集。IoU 的取值范围为 0 至 1，值越大表示预测结果与真实标签的重叠区域越多。与 DSC 相比，IoU 更关注整体区域的覆盖率，在评估整体分割质量时具有优势。

Recall（召回率）是衡量模型对真实目标检测能力的重要指标，其计算公式如下。

$$recall = \frac{|A \cap B|}{|B|} \quad (7)$$

其中, $|A \cap B|$ 表示预测结果与真实标签的交集, $|B|$ 为真实标签的像素数量。Recall 表示模型正确预测的目标区域占真实目标区域的比例, 值越高说明模型对真实目标的识别能力越强。

HD95 是一种衡量分割结果边界与真实标签边界之间距离的指标。具体来说, Hausdorff 距离 (HD) 定义为两组点集之间的最大距离, 而 HD95 取其中的 95% 分位数, 去除了极端误差点对结果的影响, 使其更加稳定和鲁棒。HD95 的计算公式 (5) 如下。

$$HD95(A, B) = percentile_{95} \left(\max \left(\max_{a \in A} \min_{b \in B} d(a, b), \max_{b \in B} \min_{a \in A} d(b, a) \right) \right) \quad (5)$$

其中, A 和 B 分别为预测边界点集和真实边界点集, $d(a, b)$ 为点 a 到点 b 的欧几里得距离。HD95 注重边界的一致性, 对于需要高边界精度的医学图像分割任务尤为重要。

3.2 数据集介绍

本实验的数据集来自辽宁省肿瘤医院, 该数据集包括 101 位病患的三维 CT 图像, 数据采集基于宫颈癌放疗进行, 每个 CT 图像包含结肠和直肠的手工标注, 每个 CT 图像由 159 到 330 个 512×512 像素的切片组成, 平面内分辨率为 $0.976\text{mm} \times 0.976\text{mm}$, 层间距为 2.5mm 到 3.0mm 。我们将 101 个图像数据进行划分, 以 8:2 的比例将病患数据划分为训练集和测试集, 并在训练集上进行五折交叉验证, 最后在测试集上进行测试。

本文的数据是宫颈癌内放射治疗数据, 在采集过程中, 插值针将放射源准确地放置在肿瘤位置, 以实现高剂量的局部治疗。插值针通常由金属材料制成, 金属在 CT 图像中会产生伪影, 这些伪影以光晕、条纹等形式出现, 可能会干扰图像的边界和纹理细节。同时插值针也会增加 CT 图像中的噪声, 从而导致边界模糊, 使得分割区域不够准确。

实验开始前, 我们对图像数据进行预处理。首先我们根据将输入网络的几种数据进行统一分辨率, 并根据真实标签的标注范围对数据进行适当剪裁以及降采样, 以减少数据大小和模型训练时的内存需求。之后对数据进行归一化、随即裁剪、左右翻转以及上下翻转来进行数据增强, 在保证模型输入一致性的同时, 增加数据的多样性, 提高模型

的泛化能力。

3.3 实验结果

本实验使用 pytorch 深度学习框架进行训练, 批次大小 batch_size 设置为 1, 使用 FusedAdam 优化器, 训练轮次设置为 200, 初始学习率为 0.0001, 该实验在数据集上的结果如表 1 所示, ASA-Net 的 DSC 为 71.58%, IoU 为 52.12%, Recall 为 79.03%, 相较于基线网络分别提升 11.29%, 7.84%, 12.7%, HD95 为 10.06, 较 ResUNet 下降 1.76。本文选取 3D-UNet、V-Net^[25]、SegNet^[26]、ResUNet 作为常见分割网络进行了对比实验, ASA-Net 相较于这些网络均有不同程度上的性能提升, 其中针对于 DSC 指标, 本文模型较 3D-UNet 提升 23.75%, 较 V-Net 提升 22.1%, 较 SegNet 提升 25.88%。本文还选取学习骨架线拓扑结构以提升鲁棒性的级联网络^[27]、基于 Swin Transformer 和 UNet 架构的语义分割模型 Swin-UNet^[28]以及 nnUNet^[29]作为对比, 本文网络相较于这三种网络的 DSC 分别提升 8.15%, 2.11%, 0.54%。我们对 Swin-UNet、nnUNet 这两种分割性能相对较好的模型进行分析, 在 DSC、IoU、Recall 等指标相差不大的情况下, 我们的 ASA-Net 拥有明显更小的 HD95, 说明我们的模型在目标物体边界存在一定复杂性的情况下, 能够更好地追踪目标的边缘轮廓信息。

表1 不同方法实验结果对比

Table1 Comparison results of different methods

方法	DSC%	IoU%	Recall%	HD95
3D-UNet	47.83	31.43	57.33	28.46
V-Net	49.48	32.87	58.10	34.02
SegNet	45.70	30.02	55.79	12.87
ResUNet	60.29	44.28	66.33	11.82
Cascaded UNet	63.43	46.39	58.97	14.56
Swin-UNet	69.47	53.22	73.63	22.94
nnUNet	71.04	56.42	74.53	25.65
ASA-Net	71.58	52.12	79.03	10.06

我们还将对 ASA-Net 中的模块进行了消融实验，如下表 2 所示，表中的 cl_net 代表中心线分割任务，dm_net 代表距离图生成任务，可以发现无论是中心线分割任务、距离图生成任务的增加，都对提升实验效果起到了积极作用，显著优化了分割结果。

表2 消融实验结果，其中cl_net代表中心线分割任务，dm_net代表距离图生成任务

Table1 Ablation results, cl_net represents the centerline segmentation task, and dm_net represents the distance map generation task

cl_net	dm_net	DSC%	IoU%	Recall%	HD95
X	X	60.29	44.28	66.33	11.82
✓	X	63.63	47.57	67.22	8.60
X	✓	62.02	46.32	66.80	10.34
✓	✓	71.58	52.12	79.03	10.06

为了更直观地观察几种网络的效果对比，我们将几种网络预测的图像进行保存，并选择多例具有代表性的病例切片进行可视化。如下图 3，图 4 所示，每行均为一个病例，共选取了十个病例，每列为不同网络的分割结果。可以看出，我们的网络能够在复杂结构的分割上依然保持拓扑结构准确性，尤其是在弯曲、管状、体积占比小的部分，效果更加明显。3D-UNet、SegNet 以及 V-Net 会在不同程度上出现拓扑结构不连续、解剖结构不准确等情况，说明在图像噪声大、软组织边界模糊的情况下，无法很好的学习到正确的解剖结构。而我们的网络相比于 ResUNet、Cascaded UNet、Swin-UNet、nnUNet，在边缘细微区域的分割上会更加有优势。

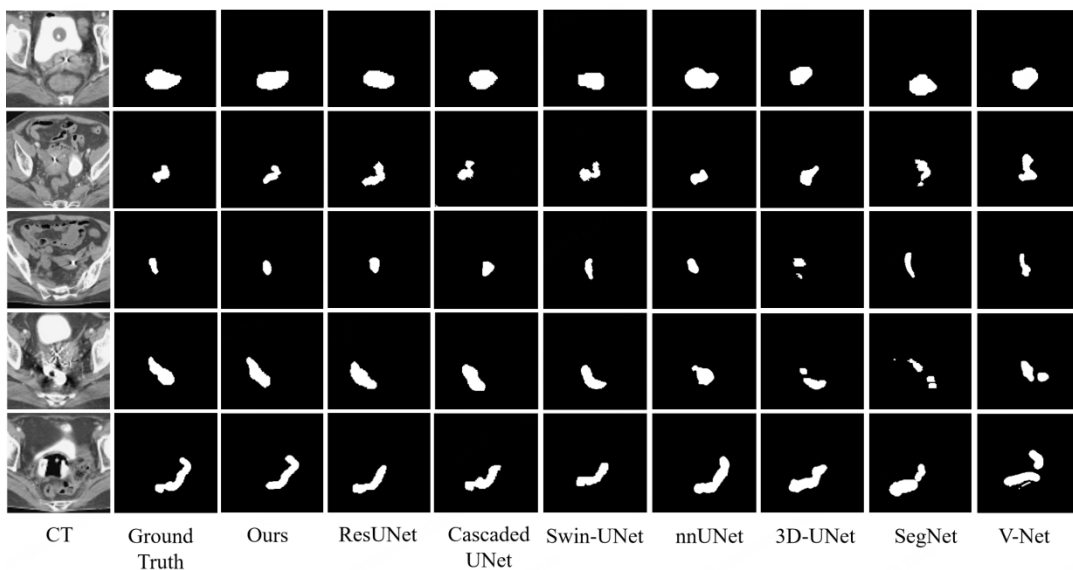


图3 不同网络预测结果对比

Fig.3 Comparison of Prediction Results from Different Networks

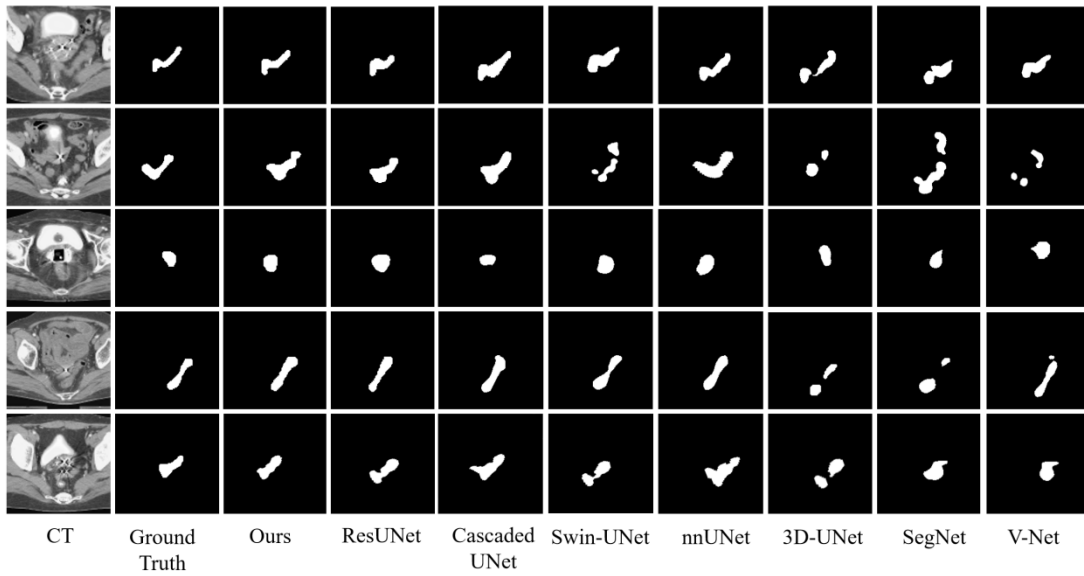


图4 不同网络预测结果对比

Fig.4 Comparison of Prediction Results from Different Networks

4 讨论

随着宫颈癌放疗技术的不断发展,如何在保证治疗效果的同时最大限度地保护周围正常组织,尤其是结肠等危及器官,已成为临床实践中的重要挑战。本研究提出了一种基于解剖结构感知的结肠 CT 图像分割方法,创新性地结合了中心线拓扑结构和骨架距离图信息,构建了多分支分割网络 ASA-Net。该方法在结肠和直肠的分割任务中展现出优异的性能,显著提升了分割的准确性和鲁棒性,为宫颈癌放疗中结肠这一危及器官的精准保护带来了新的希望。

从实验结果来看,ASA-Net 在多个评估指标上优于包括 ResUNet 在内的多种基线网络,尤其在低对比度的 CT 图像中仍能保持较高分割精度,这表明该方法能有效克服因肠道褶皱、运动伪影以及放疗数据中放射源导致的图像质量下降等问题对分割造成的影响。这一优势主要得益于网络设计中对解剖结构特征的充分利用:通过引入中心线拓扑结构信息,网络能够更好地理解结肠的解剖学特征;而骨架距离图信息的加入则增强了网络对边界区域的识别能力。在消融实验中,本文评估了中心线分割任务和距离图生成任务对最终分割效果的影响。实验结果表明,单独引入中心线分割任务可使 Dice

系数提升 3.34%，而距离图生成任务的加入则带来了 1.73% 的性能提升。当两个任务同时存在时，产生了 11.29% 的协同增益，这充分验证了这两个关键模块在网络中的重要性。此外，通过可视化分析发现，ASA-Net 在结肠弯曲部位和边界模糊区域的分割效果明显优于传统方法，这进一步证实了多任务学习策略的有效性。

然而，本文研究也存在一定的局限性。由于宫颈癌内放疗数据的特殊性，目前仅在辽宁省肿瘤医院的数据集上进行了实验，数据集的规模和多样性有限，可能无法充分展现算法的泛化能力。此外，网络结构虽然取得了较好效果，但分割性能和模型效率仍有优化空间。未来研究将针对这些问题，在更多公开数据集上验证算法的有效性，同时探索更优的网络结构，推动该技术在临床实践中的广泛应用。

5 结论

总的来说，本研究提出的 ASA-Net 为结肠 CT 图像分割提供了一种新的解决方案，其创新性地 将解剖结构信息引入肠道分割中，为解决临床实际问题提供了新的思路。随着后续研究的深入和技术的不断完善，相信该方法将在精准医疗领域发挥更大的作用，为提升宫颈癌放疗的安全性和有效性做出重要贡献。

参考文献

- [1]. Cohen P A, Jhingran A, Oaknin A, et al. Cervical cancer[J]. The Lancet, 2019, 393(10167): 169-182.
- [2]. Bhargavi K, Jyothi S. A survey on threshold based segmentation technique in image processing[J]. International Journal of Innovative Research and Development, 2014, 3(12): 234-239.
- [3]. Rong W, Li Z, Zhang W, et al. An improved CANNY edge detection algorithm[C]//2014 IEEE international conference on mechatronics and automation. IEEE, 2014: 577-582.
- [4]. Shrivastava N, Bharti J. Automatic seeded region growing image segmentation for medical image segmentation: a brief review[J]. International Journal of Image and Graphics, 2020, 20(03): 2050018.

- [5]. Kattenborn T, Leitloff J, Schiefer F, et al. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing[J]. ISPRS journal of photogrammetry and remote sensing, 2021, 173: 24-49.
- [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: 18th international conference, Munich, Germany, October 5-9, 2015, proceedings, part III 18. Springer International Publishing, 2015: 234-241.
- [7]. Zhou Z, Rahman Siddiquee M M, Tajbakhsh N, et al. Unet++: A nested u-net architecture for medical image segmentation[C]//Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support: 4th International Workshop, DLMIA 2018, and 8th International Workshop, ML-CDS 2018, Held in Conjunction with MICCAI 2018, Granada, Spain, September 20, 2018, Proceedings 4. Springer International Publishing, 2018: 3-11.
- [8]. Cai S, Tian Y, Lui H, et al. Dense-UNet: a novel multiphoton in vivo cellular image segmentation model based on a convolutional neural network[J]. Quantitative imaging in medicine and surgery, 2020, 10(6): 1275.
- [9]. Islam M, Vibashan V S, Jose V J M, et al. Brain tumor segmentation and survival prediction using 3D attention UNet[C]//Brainlesion: Glioma, Multiple Sclerosis, Stroke and Traumatic Brain Injuries: 5th International Workshop, BrainLes 2019, Held in Conjunction with MICCAI 2019, Shenzhen, China, October 17, 2019, Revised Selected Papers, Part I 5. Springer International Publishing, 2020: 262-272.
- [10]. Yan C, Liu F, Peng Y, et al. 3D convolutional network with edge detection for prostate gland and tumor segmentation on T2WI and ADC[J]. Biomedical Signal Processing and Control, 2024, 90: 105883.
- [11]. Wu W, Yan J, Zhao Y, et al. Multi-task learning for concurrent survival prediction and semi-supervised segmentation of gliomas in brain MRI[J]. Displays, 2023, 78: 102402.
- [12]. Kumar R P, Albregtsen F, Reimers M, et al. Blood vessel segmentation and centerline tracking using local structure analysis[C]//6th European Conference

- of the International Federation for Medical and Biological Engineering: MBEC 2014, 7–11 September 2014, Dubrovnik, Croatia. Springer International Publishing, 2015: 122–125.
- [13]. Zhao F, Sun F, Hou Y, et al. A monocentric centerline extraction method for ring-like blood vessels[J]. *Medical & Biological Engineering & Computing*, 2018, 56: 695–707.
- [14]. Gao J, Chen G, Lin W. An effective retinal blood vessel segmentation by using automatic random walks based on centerline extraction[J]. *BioMed research international*, 2020, 2020(1): 7352129.
- [15]. Kromm C, Rohr K. Inception capsule network for retinal blood vessel segmentation and centerline extraction[C]//2020 IEEE 17th international symposium on biomedical imaging (ISBI). IEEE, 2020: 1223–1226.
- [16]. Caliva F, Iriondo C, Martinez A M, et al. Distance map loss penalty term for semantic segmentation[J]. *arXiv preprint arXiv:1908.03679*, 2019.
- [17]. Karimi D, Salcudean S E. Reducing the hausdorff distance in medical image segmentation with convolutional neural networks[J]. *IEEE Transactions on medical imaging*, 2019, 39(2): 499–513.
- [18]. Park S, Chung M. Cardiac segmentation on CT Images through shape-aware contour attentions[J]. *Computers in Biology and Medicine*, 2022, 147: 105782.
- [19]. Van der Walt S, Schönberger J L, Nunez-Iglesias J, et al. scikit-image: image processing in Python[J]. *PeerJ*, 2014, 2: e453.
- [20]. Bressert E. SciPy and NumPy: an overview for developers[J]. 2012.
- [21]. Diakogiannis F I, Waldner F, Caccetta P, et al. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 162: 94–114. Diakogiannis F I, Waldner F, Caccetta P, et al. ResUNet-a: A deep learning framework for semantic segmentation of remotely sensed data[J]. *ISPRS Journal of Photogrammetry and Remote Sensing*, 2020, 162: 94–114.
- [22]. 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: 19th International Conference, Athens, Greece, October 17-21, 2016, Proceedings, Part II 19. Springer International Publishing, 2016: 424-432.
- [23]. Zhao R, Qian B, Zhang X, et al. Rethinking dice loss for medical image segmentation[C]//2020 IEEE International Conference on Data Mining (ICDM). IEEE, 2020: 851-860.
- [24]. Han X Y, Pappas V, Donoho D L. Neural collapse under mse loss: Proximity to and dynamics on the central path[J]. arXiv preprint arXiv:2106.02073, 2021.
- [25]. Abdollahi A, Pradhan B, Alamri A. VNet: An end-to-end fully convolutional neural network for road extraction from high-resolution remote sensing data[J]. Ieee Access, 2020, 8: 179424-179436.
- [26]. Badrinarayanan V, Kendall A, Cipolla R. Segnet: A deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE transactions on pattern analysis and machine intelligence, 2017, 39(12): 2481-2495.
- [27]. Rougé P, Passat N, Merveille O. Cascaded multitask u-net using topological loss for vessel segmentation and centerline extraction[J]. arXiv preprint arXiv:2307.11603, 2023.
- [28]. Cao H, Wang Y, Chen J, et al. Swin-unet: Unet-like pure transformer for medical image segmentation[C]//European conference on computer vision. Cham: Springer Nature Switzerland, 2022: 205-218.
- [29]. Isensee F, Jaeger P F, Kohl S A A, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation[J]. Nature methods, 2021, 18(2): 203-211.

