

## 引文格式:

张宇鑫, 谢耀钦, 孙德宇, 等. 基于解剖结构感知的宫颈癌危及器官结直肠 CT 分割 [J]. 集成技术, 2025, 14(2): 13-23.  
Zhang YX, Xie YQ, Sun DY, et al. Anatomical structure-aware CT segmentation of organ-at-risk colorectum for cervical cancer [J]. Journal of Integration Technology, 2025, 14(2): 13-23.

## 基于解剖结构感知的宫颈癌危及器官结直肠 CT 分割

张宇鑫<sup>1,2</sup> 谢耀钦<sup>1,2</sup> 孙德宇<sup>3</sup> 高玉华<sup>3</sup> 崔明<sup>3</sup> 秦文健<sup>1,2\*</sup>

<sup>1</sup>(中国科学院深圳先进技术研究院 深圳 518055)

<sup>2</sup>(中国科学院大学 北京 100049)

<sup>3</sup>(辽宁省肿瘤医院 沈阳 110042)

**摘要** 宫颈癌是全球女性癌症死亡的主要原因之一, 放射性治疗是治疗宫颈癌的常用方法。其中, 近距离放射治疗通过将放射源直接置入靠近肿瘤的区域, 能将高剂量的辐射集中在肿瘤部位, 比其他放疗方法的适用性高。精确分割危及器官对准确估算放疗剂量和最大度地保护正常组织免受辐射损伤至关重要。然而, 管状结构(如结直肠)的自动分割仍面临诸多挑战。例如: 肠道的褶皱、运动伪影等因素会影响分割效果; 近距离放射治疗中的放射源会降低 CT 影像的质量, 影响分割的准确性。本文提出了一种基于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学习, 该方法能更好地识别管状器官的拓扑结构和其在人体内的空间关系, 从而提高分割精度, 优化放疗剂量分布。该文利用 Dice 相似度系数 (DSC)、交并比 (IoU)、召回率 (Recall) 和 95% 豪斯多夫距离 (HD95) 等指标分析了宫颈癌内放射治疗 CT 数据集的性能。实验结果表明本文方法的多数指标优于基线网络 ResUNet。其中: DSC 为 71.58%, IoU 为 52.12%, Recall 为 79.03%, 分别较 ResUNet 提高了 11.29%、7.84% 和 12.70%; HD95 为 10.06, 较 ResUNet 下降了 1.76。由此表明本文方法能有效提高宫颈癌近距离放射治疗 CT 影像中结直肠的分割精度, 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 TP183; R319 文献标志码 A doi: 10.12146/j.issn.2095-3135.20241129003

CSTR: 32239.14.j.issn.2095-3135.20241129003

收稿日期: 2024-11-29 修回日期: 2025-01-16

基金项目: 国家自然科学基金项目 (U20A20373); 深港肿瘤智能计算综合实验室项目 (E3G111)

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, 研究方向为放疗治疗; 高玉华, 主任医师, 研究方向为宫颈癌根治性放疗; 崔明, 博士, 研究方向为放疗治疗; 秦文健 (通讯作者), 研究员, 研究方向为医学成像, E-mail: wj.qin@siat.ac.cn.

# Anatomical Structure-Aware CT Segmentation of Organ-at-Risk Colorectum for Cervical Cancer

ZHANG Yuxin<sup>1,2</sup> XIE Yaoqin<sup>1,2</sup> SUN Deyu<sup>3</sup> GAO Yuhua<sup>3</sup> CUI Ming<sup>3</sup> QIN Wenjian<sup>1,2\*</sup>

<sup>1</sup>( Shenzhen Institutes of Advanced Technology, Chinese Academy of Sciences, Shenzhen 518055, China )

<sup>2</sup>( University of Chinese Academy of Sciences, Beijing 100049, China )

<sup>3</sup>( Liaoning Cancer Hospital and Institute, Shenyang 110042, China )

\*Corresponding Author: 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. Among the various radiation therapies, brachytherapy, which involves placing the radiation source directly into an area close to the tumor, can deliver a high dose of radiation directly to the tumor, making it more applicable compared to other radiation methods. 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 the presence of the radiation source in brachytherapy can degrade CT image quality, 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 12.70%, 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** This work is supported by National Natural Science Foundation of China (U20A20373) and Shenzhen-Hong Kong Joint Lab on Intelligence Computational Analysis for Tumor Imaging (E3G111)

## 1 引 言

结直肠的自动分割在宫颈癌的诊断和治疗中

意义重大，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

的辐射损伤和副作用<sup>[1]</sup>。

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<sup>[2]</sup>、边界检测<sup>[3]</sup>和区域生长<sup>[4]</sup>等技术的方法, 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)<sup>[5]</sup>的特征提取能力较强, 成为医学图像分割的主流技术, 其中 U-Net<sup>[6]</sup>结构的提出极大地推动了生物医学图像自动化分割任务的发展, 其改进版本 (如 UNet++<sup>[7]</sup>、Dense-UNet<sup>[8]</sup> 和 Attention U-Net<sup>[9]</sup> 等) 在各类医学图像分割领域中也取得了显著进展。此外, 针对不同肿瘤类型, 研究者提出了许多深度学习分割方法。例如: Yan 等<sup>[10]</sup>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; Wu 等<sup>[11]</sup>提出一种并行生存预测和半监督肿瘤分割的多任务学习方法, 用于分割脑部肿瘤, 并提高生存预测的准确性。

在宫颈癌的诊断和治疗中, 计算机断层扫描 (computed tomography, CT) 具有分辨率高、非侵入性和快速扫描等优点, 成为宫颈癌筛查和诊断的主要手段之一。但在 CT 图像中, 肠道等软组织器官区域的对比度相对较低, 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。例如: 结直肠的拓扑结构、局部扩张、位置变化和相邻器官的干扰都可能影响分割精度。

研究者通常利用中心线学习复杂的拓扑结构, 以保证分割时的连续性。例如: Kumar 等<sup>[12]</sup>提出基于血管分割、中心线跟踪和半径估计的方法; Zhao 等<sup>[13]</sup>、Gao 等<sup>[14]</sup>、Kromm 等<sup>[15]</sup>针对不同管状结构提出中心线提取和分割方法。然而, 当前的中心线方法主要用于分析血管、骨架和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, 在器官分割领域的应用有限, 尤其是具

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, 导致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器官分割, 尤其是针对复杂器官形态的分割, 仍是一个亟待解决的问题。

结肠和直肠是腹部器官, 具有位置不固定和形态过于复杂等特点, 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 (如结直肠的位置信息) 结合使用, 以达到更好的效果。现有研究通常使用距离描述图像中不同区域间的相对位置关系, 以提高器官定位的准确性, 如 Caliva 等<sup>[16]</sup>提出的基于距离约束的损失函数、Karimi 等<sup>[17]</sup>的豪斯多夫距离 (Hausdorff distance, HD) 估计方法和 Park 等<sup>[18]</sup>的形状感知注意力模块等。然而这些研究大多仅测算同一组织的真实标签与预测结果的距离, 未考虑不同组织间的距离。本文将人体内位置相对固定的骨架作为参考, 通过生成骨头与肠道间的距离图, 不仅可以得到分割目标的边界信息, 还能将分割重点放在一定的位置范围。

受上述信息启发, 本文提出一种基于 ResUNet 的宫颈癌危及器官结直肠分割网络 (anatomical structure-aware network, ASA-Net), 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, 保证分割过程中拓扑结构的准确性; (2) 通过手工标注的骨架信息, 生成与结直肠间的距离图, 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, 融合不同编码器提取的特征, 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，提取中心线可有效提高分割的连续性，尤其是结直肠等形态复杂的器官，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，并通过保留其主要形态特征，逐步提取目标结构的中心骨架。实际应用中可借助开源图像处理库 (Scikit-image)<sup>[19]</sup> 中提供的函数快速实现这一操作。

在提取中心线后，为进一步提高中心线的连贯性，通常会使用膨胀操作修复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，确保生成中心线的完整性。在形态学操作中，膨胀算子通过选择  $3 \times 3$  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，广泛用于对比分析预测结果与手工标注结果。通过计算预测结果与手工标注结果的豪斯多夫距离 (HD)，可有效评估分割的精确度。为优化分割效果，通常将 HD 作为损失函数的组成部分，通过最小化 HD 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上，而对如何利用目标区域与参考结构之间的距离信息进行器官定位和精准分割的关注较少。

本文提出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辅助结直肠的分割和定位。具体来说，参考结构的选择对分割效果至关重要，本文根据宫颈癌近距离放射治疗 CT 数据集的分析结果，将股骨颈作为解剖学参考结构。股骨颈的解剖位置稳定且易于标注，与腹部器官的距离能在一定程度上反映目标器官的解剖学分布特征。本文先利用医学影像标注工具 3D Slicer 分割阈值，初步提取股骨区域，再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，本文使用 SciPy 库<sup>[20]</sup> 中的函数计算每个肠道像素点  $(x, y)$  到股骨颈标注中最近像素点  $(x_i, y_i)$  的欧几里得距离，表示如下：

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

其中， $(x_i, y_i)$  为股骨颈标注中距离  $(x, y)$  最近的像素点。具体的距离图生成结构如图 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。

## 2.3 整体网络结构

由于分割目标的体积较小且局部细节特征难

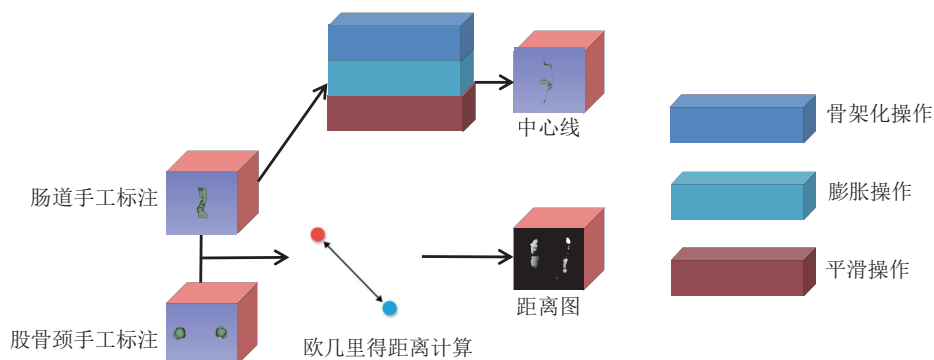


图 1 中心线提取和距离图生成

Fig. 1 Centerline extraction and distance map generation

以提取, 因此本文将 ResUNet<sup>[21]</sup> 作为基线网络。ResUNet 继承了 3D U-Net<sup>[22]</sup> 经典的编码器-解码器架构, 并在 3D U-Net 的基础上增加了残差连接, 可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, 分割效果提升明显。这一改进不仅使网络能更好地捕捉三维图像中的细微结构和局部特征, 还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, 如图 2 所示。ASA-Net 包含 3 个学习任务。其中: seg\_net 为肠道分割任务; cl\_net 为肠道中心线学习任务; dm\_net 为肠道距离图生成任务。seg\_net 和 cl\_net 共享编码器 1 提取特征图 feature map1, 而 dm\_net 单独使用编码器 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, 确保分割任务能捕捉更细腻的边界特征和全局一致性, 注意力模块如图 2 所示, 其中 feature map1 与一个二维参数矩阵相乘后作为注意力计算中的键向量  $K$  和值向量  $V$ , feature map2 与一个二维参数矩阵相乘后作为注意力计算中的查询向量  $Q$ 。

在解码器阶段, 3 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 的中心线学习和距离图生成任务在整个网络的训练过程中起辅助作用, 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, 确保分割结果在空间上的连通性和形态

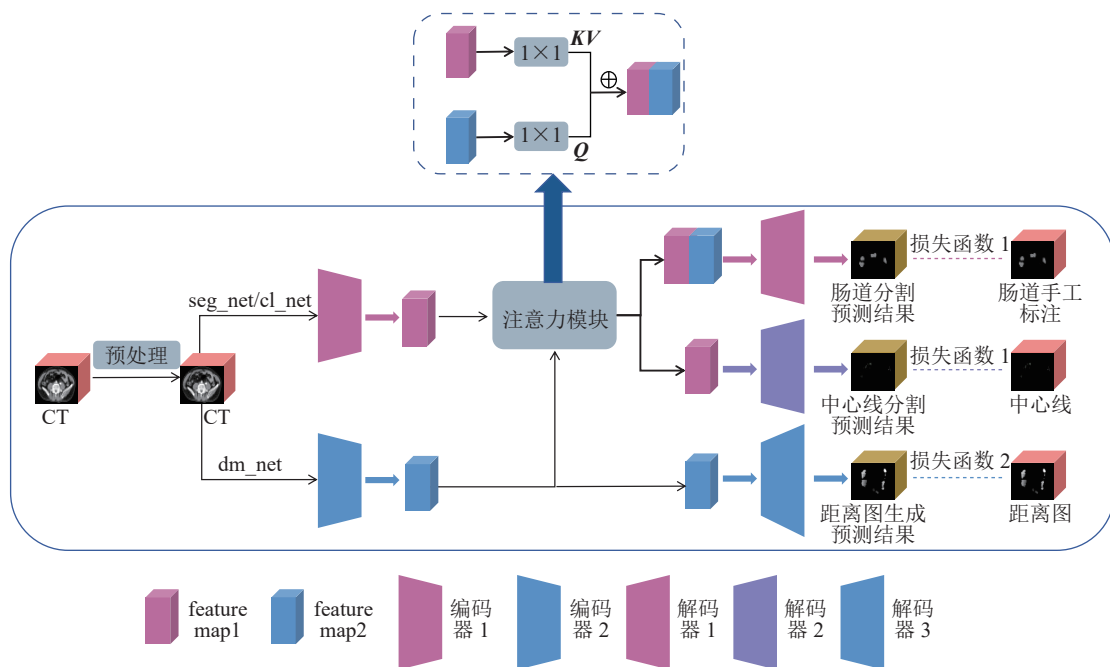


图 2 全局网络结构

Fig. 2 Overall network structure

一致性。距离图生成任务则利用目标器官与骨骼间的空间相对位置关系，为分割提供额外的定位约束，减少误分割现象。

## 2.4 损失函数

针对 ASA-Net 的 3 个学习任务，本文分别采用不同的损失函数优化 ASA-Net 的参数。其中，seg\_net 和 cl\_net 的目标是分割图像区域，因此采用 Dice 损失函数<sup>[23]</sup>。该损失函数通过最大化真实标签与预测结果的重叠区域衡量两者的相似性，从而提升分割精度。Dice 损失函数表示如下：

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

其中， $p_i$  为第  $i$  个像素点预测的概率； $g_i$  为真实标签在第  $i$  个像素点的值（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与目标结构的距离。本文利用均方误差 (mean squared error, MSE)<sup>[24]</sup> 评估预测的精确性。MSE 损失函数的目标是 minimized 预测值与真实值间的误差，优化每个像素的预测值，这在回归任务中非常有效，表示如下：

$$\text{Loss}_{\text{MSE}} = \frac{1}{M} \sum_{n=1}^M (y_n - \hat{y}_n)^2 \quad (3)$$

其中， $M$  为样本数量； $y_n$  为第  $n$  个样本的真实值； $\hat{y}_n$  为第  $n$  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和距离图生成的回归特性，有效优化了模型参数，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 Dice 相似度系

数 (DSC)、交并比 (IoU)、召回率 (Recall) 和 95% 豪斯多夫距离 (HD95)，用于全面评估模型的分割性能，涵盖重叠精度、边界一致性和检测能力等多方面。

DSC 是衡量预测结果与真实标签之间重叠程度的重要指标，其值在 0~1，越接近 1，预测结果与真实标签的相似度越高，表示如下：

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

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

IoU 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间的重叠程度，表示如下：

$$\text{IoU} = \frac{|A \cap B|}{|A \cup B|} \quad (5)$$

其中， $|A \cup B|$  为预测结果与真实标签的并集。IoU 的值为 0~1，值越大，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 是衡量模型对真实目标检测能力的重要指标，表示如下：

$$\text{Recall} = \frac{|A \cap B|}{|B|} \quad (6)$$

Recall 为模型正确预测的目标区域占真实目标区域的比例，其值越大，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间距离的指标。具体来说，HD 指两组点集间的最大距离，而 HD95 取其中的 95% 分位数，去除了极端误差点对结果的影响，使其更稳定和鲁棒，表示如下：

$$\text{HD95}(P, G) = \text{percentile}_{95} \left( \max \left( \max_{p \in P} \min_{g \in G} d(p, g), \max_{g \in G} \min_{p \in P} d(g, p) \right) \right) \quad (7)$$

其中， $P$  和  $G$  分别为预测边界点集和真实边界点集； $d(p, g)$  为点  $p$  到点  $g$  的欧几里得距离； $d(g, p)$

为点  $g$  到点  $p$  的欧几里得距离。HD95 注重边界的一致性, 对需要高边界精度的医学图像分割任务尤其重要。

### 3.2 数据集介绍

本实验的数据集来自辽宁省肿瘤医院, 包括 101 位患者的三维 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 159~330 个  $512 \times 512$  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  $2.5 \sim 3.0 \text{ mm}$ 。本文按 8:2 的比例将 101 个图像数据分为训练集和测试集, 并在训练集上进行五折交叉验证, 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在肿瘤处, 以实现高剂量的局部治疗。插值针通常由金属材料制成, 而金属会在 CT 图像中产生伪影, 并以光晕、条纹等形式出现, 可能会干扰图像的边界和纹理细节。此外, 插值针还会增加 CT 图像的噪声, 从而导致边界模糊, 使得分割区域不准确。

实验开始前对图像数据进行预处理。首先, 将输入网络的几种数据统一分辨率; 其次, 根据真实标签的标注范围对数据进行适当剪裁和降采样, 以减少数据大小和模型训练时的内存需求; 最后, 对数据进行归一化、随机裁剪、左右翻转和上下翻转, 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 深度学习框架进行模型训练, 批次大小 `batch_size` 设为 1, 使用 FusedAdam 优化器, 训练轮次设为 200, 初始学习率设为 0.0001, 在数据集上的实验结果如表 1 所示。ASA-Net 的 DSC 为 71.58%、IoU 为 52.12%、Recall 为 79.03%, 与 ResUNet 相比, 分别提升 11.29%、7.84%、12.70%; HD95 为 10.06, 与 ResUNet 相比, 下降 1.76。本文对比分析了 3D U-Net、VNet<sup>[25]</sup>、SegNet<sup>[26]</sup> 和 ResUNet 等常见分割网络, ASA-Net 的各项性能均提升。其中, 依次与 3D U-Net、VNet 和 SegNet 相比, 本文模型的 DSC 分别提升了 23.75%、22.10% 和 25.88%。本文还依次与 cascaded U-Net<sup>[27]</sup>、基于 Swin Transformer 和 Unet 架构的语义分割模型 Swin-Unet<sup>[28]</sup> 和 nnU-Net<sup>[29]</sup> 进行了对比实验, 本文网络的 DSC 依次提升了 8.15%、2.11% 和 0.54%。本文与分割性能较好的 Swin-Unet 和 nnU-Net 模型进行了对比分析, 在 DSC、IoU、Recall 等指标相差不大的情况下, 本文网络的 HD95 更小, 表明本文模型在目标物体边界存在一定复杂性的情况下, 能更好地追踪目标的边缘轮廓信息。

本文还对 ASA-Net 中的模块进行了消融实

表 1 不同方法结果对比

Table 1 Comparison results of different methods

方法	DSC/%	IoU/%	Recall/%	HD95
3D U-Net	47.83	31.43	57.33	28.46
VNet	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 U-Net	63.43	46.39	58.97	14.56
Swin-Unet	69.47	53.22	73.63	22.94
nnU-Net	71.04	56.42	74.53	25.65
ASA-Net	71.58	52.12	79.03	10.06

验, 如表 2 所示。其中: `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, 无论增加中心线分割任务, 还是增加距离图生成任务, 都可显著优化分割结果。

为更直观地对比几种网络的效果, 本文保存了几种网络预测的图像, 并可视化了多例具有代表性的病例切片。如图 3 所示, 每行均为一个病例, 共选取了 10 个病例, 每列为不同网络的

表 2 消融实验结果

Table 2 Ablation study results

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

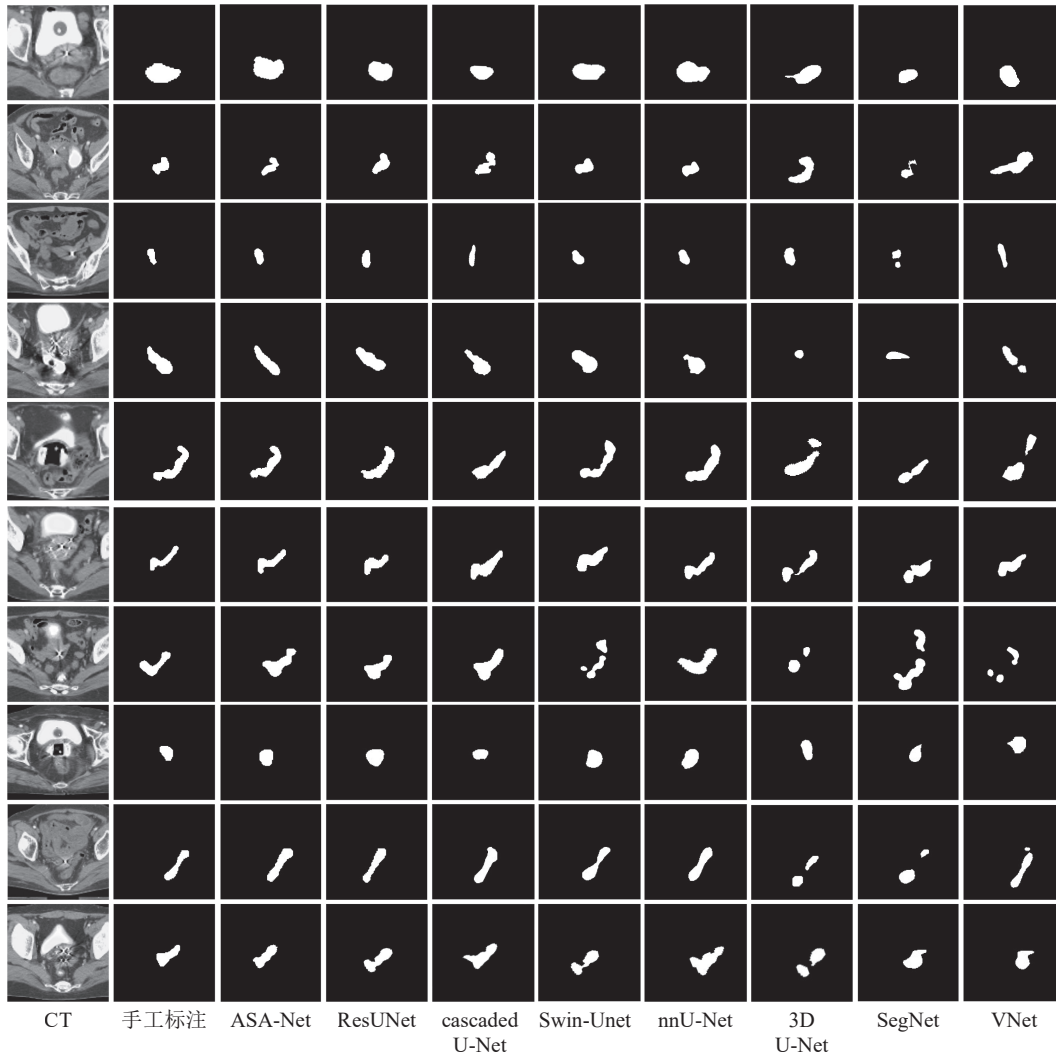


图 3 不同网络预测结果对比

Fig. 3 Comparison of prediction results from different networks



割结果。可以看出, 在复杂结构的分割上, 本文网络能保持拓扑结构的准确性, 尤其是在弯曲、管状、体积占比小的部分, 效果更明显。3D-UNet、SegNet 和 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, 表明在图像噪声大、软组织边界模糊的情况下, 这些网络无法很好地学习正确的解剖结构。而与 ResUNet、Cascaded UNet、Swin-Unet 和 nnUNet 相比, 本文网络在边缘细微区域的分割上更有优势。

## 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 ASA-Net。该网络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, 为宫颈癌放疗中结直肠等危及器官的精准保护带来了希望。

实验结果表明, 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, 表明该方法能有效减少肠道褶皱、运动伪影和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 ASA-Net 设计时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, ASA-Net 能更好地学习结肠的解剖学特征; 而骨架距离图信息的加入则增强了 ASA-Net 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 DSC 提升 3.34%, 而距离图生成任务的加入则可使 DSC 提升 1.73%。

当两个任务同时存在时, 可使 DSC 提升 11.29%, 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, 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局限。由于宫颈癌内放疗数据的特殊性, ASA-Net 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, ASA-Net 虽然取得了较好的效果, 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本文研究的有效性, 同时探索更优的网络结构, 推动 ASA-Net 在临床实践中的广泛应用。

## 5 结 论

综上所述, 本研究提出的 ASA-Net 为结直肠 CT 图像分割提供了一种新的解决方案, 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作用, 为提升宫颈癌放疗的安全性和有效性作出重要贡献。

## 参 考 文 献

- [1] Cohen PA, 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 ZJ, Zhang W, et al. An improved Canny edge detection algorithm [C] // *Proceedings of the 2014 IEEE International Conference on Mechatronics and Automation*, 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(3): 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] // *Proceedings of the Medical Image Computing and Computer-assisted Intervention*, 2015: 234-241.
- [7] Zhou ZW, Rahman Siddiquee MMR, Tajbakhsh N, et al. UNet++: a nested U-Net architecture for medical image segmentation [C] // *Proceedings of the Deep Learning in Medical Image Analysis and Multimodal Learning for Clinical Decision Support*, 2018: 3-11.
- [8] Cai SJ, Tian YX, 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): 1275-1285.
- [9] Oktay O. Attention U-Net: learning where to look for the pancreas [Z/OL]. arXiv Preprint, arXiv: 1804.03999, 2018.
- [10] Yan CZ, Liu F, Peng YS, 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 RP, Albrechtsen F, Reimers M, et al. Blood vessel segmentation and centerline tracking using local structure analysis [C] // *Proceedings of the 6th European Conference of the International Federation for Medical and Biological Engineering*, 2015: 122-125.
- [13] Zhao FJ, Sun FF, Hou YQ, et al. A monocentric centerline extraction method for ring-like blood vessels [J]. *Medical & Biological Engineering & Computing*, 2018, 56: 695-707.
- [14] Gao JQ, Chen GN, Lin WR. 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] // *Proceedings of the 2020 IEEE 17th International Symposium on Biomedical Imaging*, 2020: 1223-1226.
- [16] Caliva F, Iriondo C, Martinez AM, et al. Distance map loss penalty term for semantic segmentation [Z/OL]. arXiv Preprint, arXiv: 1908.03679, 2019.
- [17] Karimi D, Salcudean SE. 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*, 2021, 147: 105782.
- [19] van der Walt S, Schönberger JL, 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 [M]. California: O'Reilly Media, 2012.
- [21] Diakogiannis FI, 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 SS, et al. 3D U-Net: learning dense volumetric segmentation from sparse annotation [C] // *Proceeding of the Medical Image Computing and Computer-Assisted Intervention—MICCAI 2016*, 2016: 424-432.
- [23] Zhao RJ, Qian BY, Zhang XL, et al. Rethinking

- Dice loss for medical image segmentation [C] // Proceedings of the 2020 IEEE International Conference on Data Mining, 2020: 851-860.
- [24] Han XY, Papyan V, Donoho DL. Neural collapse under MSE loss: proximity to and dynamics on the central path [Z/OL]. 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 multi-task U-Net using topological loss for vessel segmentation and centerline extraction [Z/OL]. arXiv Preprint, arXiv: 2307.11603, 2023.
- [28] Cao H, Wang YY, Chen J, et al. Swin-Unet: Unet-like pure Transformer for medical image segmentation [C] // Proceedings of the European Conference on Computer Vision, 2022: 205-218.
- [29] Isensee F, Jaeger PF, Kohl SAA, et al. nnU-Net: a self-configuring method for deep learning-based biomedical image segmentation [J]. Nature methods, 2021, 18(2): 203-211.