

• 深度学习驱动的医学图像解析 •

基于大核卷积和联合注意力的子宫内膜癌病灶区域分割



彭如恕, 曾庆昊, 何滨, 刘俊杰, 肖章

南华大学 机械工程学院 (湖南衡阳 421200)

【摘要】 子宫内膜癌(EC)是常见的妇科恶性肿瘤之一,其发病率在全球范围内呈上升趋势。对计算机断层扫描(CT)图像中的病灶区域进行精确分割是辅助临床诊断的重要环节。本文设计了一种基于深度学习的新型分割模型:空间选择与组合权重网络(SCWU-Net),该模型包含新设计的空间选择模块(SSM)和组合权重模块(CWM)。空间选择模块通过深度卷积块来改善模型捕获上下文信息的能力,而在跳跃连接中采用基于联合注意力的组合权重模块进一步提高模型性能。本文通过集成两种模块的优势到U型多尺度模型中,实现了对EC病灶区域的精确分割。在公开数据集上的实验结果证明,本文提出的SCWU-Net结构的戴斯相似系数(DSC)达到82.98%,交并比(IoU)达到了78.63%,精准度(precision)达到了92.36%,召回率(recall)达到了84.10%,其综合性能显著优于其他先进模型。综上,本研究提高了EC病灶区域CT图像的分割精度,对EC辅助诊断具有一定的临床意义。

【关键词】 深度学习; 子宫内膜癌; 计算机断层扫描; 图像分割

Endometrial cancer lesion region segmentation based on large kernel convolution and combined attention

PENG Rushu, ZENG Qinghao, HE Bin, LIU Junjie, XIAO Zhang

School of Mechanical Engineering, University of South China, Hengyang, Hunan 421200, P. R. China

Corresponding author: XIAO Zhang, Email:2013000885@usc.edu.cn

【Abstract】 Endometrial cancer (EC) is one of the most common gynecological malignancies, with an increasing incidence rate worldwide. Accurate segmentation of lesion areas in computed tomography (CT) images is a critical step in assisting clinical diagnosis. In this study, we propose a novel deep learning-based segmentation model, termed spatial choice and weight union network (SCWU-Net), which incorporates two newly designed modules: the spatial selection module (SSM) and the combination weight module (CWM). The SSM enhances the model's ability to capture contextual information through deep convolutional blocks, while the CWM, based on joint attention mechanisms, is employed within the skip connections to further boost segmentation performance. By integrating the strengths of both modules into a U-shaped multi-scale architecture, the model achieves precise segmentation of EC lesion regions. Experimental results on a public dataset demonstrate that SCWU-Net achieves a Dice similarity coefficient (DSC) of 82.98%, an intersection over union (IoU) of 78.63%, a precision of 92.36%, and a recall of 84.10%. Its overall performance is significantly outperforming other state-of-the-art models. This study enhances the accuracy of lesion segmentation in EC CT images and holds potential clinical value for the auxiliary diagnosis of endometrial cancer.

【Key words】 Deep learning; Endometrial cancer; Computed tomography; Image segmentation

0 引言

子宫内膜是一种可高度再生的组织^[1],其增殖与分化高度依赖激素调控。这种特性使子宫内膜

在生理期易出现多种病理改变,其中子宫内膜癌(endometrial cancer, EC)是最严重的恶性病变^[2-3]。流行病学数据显示,EC约占妇科恶性肿瘤的20%~30%^[4]。更为严峻的是,EC发病率持续上

DOI: 10.7507/1001-5515.202502023

基金项目: 国家自然科学基金(82402372); 湖南省教育厅优秀青年项目(23B0416)

通信作者: 肖章, Email: 2013000885@usc.edu.cn



升,且呈现年轻化的趋势,严重威胁女性健康^[5-6]。开展早期诊断将有效提高 EC 患者的治疗效果,并改善其预后^[7-8]。临床试验证明,I 期患者在接受及时干预后,其 5 年存活率超过 90%,而晚期病例的 5 年存活率不足 20%^[9]。为达到尽早干预治疗的目的,患者病灶区域的精确定位与分割对于实现早期诊断和提高治疗效果具有重要意义^[10]。

在各种医学成像技术中,计算机断层扫描(computed tomography, CT)因其成像速度快,具有非侵入性以及对肿瘤扩散的高敏感性,在疾病检测和诊断中发挥着重要作用^[11-13]。然而,EC 的 CT 图像分割面临两个关键挑战:一方面,图像中包含大量与病灶分割无关的背景信息;另一方面,EC 作为软组织肿瘤,其病灶区域在 CT 图像中呈现出边界模糊、对比度低的特性^[14],这使得要对其实现精确分割面临巨大困难^[15]。为解决这些问题,本研究拟采用深度学习(deep learning, DL)技术实现对 EC 病灶区域的自动分割^[16-18],旨在为放射科医生提供更准确的诊断辅助^[19-20]。

在 EC 早期诊断研究中,深度学习技术已得到广泛应用。多项研究均证实了这一趋势:Chen 等^[21]采用基于卷积神经网络(convolutional neural network, CNN)的深度学习方法,利用磁共振成像(magnetic resonance imaging, MRI)加权成像评估 EC 的肌层浸润深度,其诊断性能已优于放射科医生。Kurata 等^[22]通过改进的“U”型网络(u-shaped networks, U-Net)架构处理多序列图像,不仅提升了分割精度,还证实了数据规模对模型性能的正向作用。Mao 等^[23]进一步利用三维(three dimensional, 3D)U-Net 处理盆腔 MRI 数据,证明现有算法具备与专业医师相当的肿瘤分割可靠性。在 CT 成像应用方面,Li 等^[24]证实机器学习方法能有效区分病变与正常子宫内膜组织,而且其诊断准确性优于人工判读。此外,Kim 等^[25]的研究方法针对股骨等高密度结构的 CT 图像分割效果优异,但对 EC 这类软组织肿瘤的区分效果则明显受限。针对这一局限,Li 等^[26]提出的焦点 U-Net 变换器(focal U-Net transformer, FocalUNETR)模型,在该问题上取得显著进展,但该模型也存在计算复杂度高、对小病灶适应性不足等应用瓶颈。

本文针对 CT 图像 EC 病灶分割的两大核心难题:病灶边界模糊和盆腔多器官干扰,提出了一种基于改进 U-Net 模型的解决方案。该模型拟通过构建三个关键模块提升对病灶区域的识别能力:首先,设计组合权重模块(combined weights

module, CWM)融合通道与空间注意力,改善软组织边界的区分度;其次,引入空间选择模块(spatial selection module, SSM)构建全局感知能力,帮助模型更好地识别病灶区域并抑制邻近器官的干扰;最后,增设并行支路结构,利用残差连接保留浅层空间细节,使其与深层语义特征形成互补,以期在保持对小病灶定位精度的同时,提升模型对复杂解剖结构的适应能力。

1 方法

1.1 模型框架

传统分割模型在应对 EC 病灶区域的自动分割挑战时存在两个关键局限:其一,在提取多尺度特征的过程中,随着网络层数的加深,浅层特征中的局部边缘信息逐渐丢失;其二,缺乏长距离上下文感知能力,难以有效抑制无关背景的干扰。

为克服上述问题,本文提出一种结合 SSM 与 CWM 的 U-Net (U-Net with SSM and CWM, SCWU-Net)模型,用于 EC 病灶区域分割,其整体框架如图 1 所示。该模型继承 U-Net 的编码器—解码器结构,其中编码器由标准 3×3 卷积层和最大池化层组成,通过四级下采样扩大通道维度并压缩空间尺寸,提取深层语义特征;在每级跳跃连接起点设置 CWM,对每个传递到解码器的特征进行同步处理,实现语义对齐的同时增强局部信息获取;在深层特征阶段,增设并行支路和 SSM,前者通过特征拼接保留高分辨率空间细节,后者则建模长距离空间依赖关系;最后,解码器阶段通过卷积层和上采样层操作,融合 CWM 与跳跃连接传递的多尺度特征,逐步恢复图像分辨率并输出分割结果。

1.2 空间选择模块

SSM 通过大核卷积级联、双路径池化操作和自适应门控机制实现空间关系的提取,其架构如图 2 所示。

CT 图像中的非目标区域往往具有高对比度,区分其所需的上下文信息较少;而病灶区域与子宫的正常组织结构相似,要精确区分则需要更丰富的上下文信息。为了实现对不同区域的自适应处理,模型需能根据上下文动态调整所需感受野。传统的卷积核感受野有限,难以捕捉长距离空间依赖关系;而直接使用过大的卷积核则会引入大量无关噪声,导致细节丢失并降低定位精度。基于此,本文设计了连续的两个大核深度卷积块: 5×5 卷积层和 7×7 卷积层,建立从局部到全局的渐进式




图1 SCWU-Net 模型架构概述

Fig.1 Overview of SCWU-Net architecture




图2 SSM 概述

Fig.2 The architecture of the SSM

上下文理解,显著扩大感受野,为后文的自适应特征选择奠定基础。同时,利用并行支路提供的浅层特征输入,该设计避免模块输入特征的细节信息丢失。随后, 1×1 卷积层分别处理两个大核卷积的输出,在保留关键信息的同时有效降低了计算的复杂度。

为了实现对多尺度上下文信息的自适应整合,在拼接两个大核卷积的输出以融合全部信息后,利用并行路径的最大池化和平均池化操作分别建模特征的不同空间属性:①最大池化突显显著响应区域;②平均池化保留全局上下文统计信息。接着,利用矩阵乘法建模两种池化特征的交互关系,

将交互结果逐元素相加，形成更加综合的特征表达。最后，通过门控加权生成动态权重，该权重与原特征图进行逐元素乘法，旨在抑制冗余背景区域并聚焦病灶区域特征，如式 (1) 所示：

$$Y = \varepsilon X(f_{\text{avg}} + f_{\text{max}}) \quad (1)$$

其中， Y 为输出特征， ε 表示 S 型生长曲线 (sigmoid) 函数， f_{avg} 和 f_{max} 分别为经过平均池化和最大池化操作后的特征， X 为模块的输入特征图。

1.3 组合权重模块

为应对 CT 图像中 EC 区域的边界模糊和低对比度特性，本文在跳跃连接中引入 CWM，与 SSM 协同增强模型性能。该模块通过三分支架构的联合注意力机制实现对病灶区域边缘的特征增强，其架构如图 3 所示。

图 3 中，通道分支首先利用全局平均池化压缩空间维度，生成通道描述符以表征各通道的全局信息；随后通过激励操作 (excitation operation) 生成通道权重。为降低模块复杂度以适配跳跃连接传递的低层级特征图，该激励操作包含两个全连接层。空间分支则基于特征图的方差来量化各位置的重要性。该设计灵感来源于视觉神经科学：有研究表明，信息含量高的神经元表现出与周围神经元不同的放电模式以抑制后者的活动，这种现象被称为空间抑制^[27-29]。基于此，本研究利用方差归一化操作生成空间权重，赋予病灶区域像素更高的激活权重，从而有效区分目标像素与背景像素，如式 (2)、式 (3) 所示：

$$\sigma^2 = \frac{1}{Z-1} \sum_{i=1}^{Z-1} (x_{H \times W} - \varphi) \quad (2)$$

$$W_{i,j} = \varepsilon \left(\frac{x_{i,j} - \varphi}{4(\sigma^2 + \omega)} + c \right) \quad (3)$$

其中 $Z = H \times W$ 为像素总数； σ^2 为方差； $x_{i,j}$ 为输入特征图在空间位置 (i, j) 处的特征值； $W_{i,j}$ 为生成的空间权重； ε 表示 sigmoid 函数； φ 为特征图在空间维度上的均值； ω 为极小常数，防止分母为零，默认为 10^{-4} ； c 为偏置量，避免极端权重 (0 或 1) 导致的梯度消失。

最终，通过矩阵乘法将通道权重和空间权重融合，将 CWM 应用到跳跃连接传递的特征图上，实现了对边缘细节的特征校准与增强。尤为重要的是，该模块的轻量化设计使其计算开销较小，特别适用于大型特征信息交互的环节。




图 3 CWM 概述

Fig.3 The architecture of the CWM

2 数据集和评价指标

2.1 子宫内膜癌数据集

本文实验使用的数据库为：用于语义分割评估和高代谢区域检测 EC 的正电子发射断层扫描 (positron emission tomography, PET) 与 CT 图像数据集 (EC PET/CT image dataset for evaluation of semantic segmentation and detection of hypermetabolic regions, ECPC-IDS)。该数据集是由东北大学、德国吕贝克大学和中国医科大学合作创建的公开 EC 数据集^[30]，包含多格式共计 7 159 张图像，涵盖了 155 个病例。该数据集中图像的病灶区域均由两位经验丰富的放射科医生使用医学影像分析与可视化软件 3D Slicer 5.6.2 (Kitware Inc., 美国) 手动勾勒每层 EC 图像中的肿瘤区域。

2.2 评价指标

为全面评估模型性能，本文采用戴斯相似系数 (Dice similarity coefficient, DSC)^[31] 作为关键评估的指标，以衡量预测掩码和真实标签之间的相似程度。此外还增加三项指标，即交并比 (intersection over union, IoU)、精确度 (precision)、召回率 (recall)^[31-32]，用于评估定量分割性能。

3 实验与分析

3.1 实验设置

本文选用了隶属于语义分割任务的 1 166 张 CT 图像数据 (因部分图像损坏，予以剔除)。图像大小为 512×512 ，按照 8 : 2 的比例划分为训练集和测试集，采用随机旋转、翻转等数据增强方法将数据导入模型中进行训练，以此扩大样本量。训练过程中所有实验模型损失均已达到收敛状态。

为验证本文方法的有效性，使用 8 种医学图像分割模型作为方法对比，包含本领域最具代表性的 U-Net^[33]、分割网络 (segmentation network,

SegNet)^[34] 和第 3 代深度研究实验室 (deeplab version 3+, DeepLabv3+)^[35] 模型, 还包括拥有先进注意力机制的注意力 U-Net (attention U-Net, AttU-Net)^[36]、高效注意力 U-Net (efficient attention U-Net, EA-UNet)^[37] 和多分支分割网络 (multi-branch segmentation network, MBSNet)^[38], 以及包含先进变换器 (transformer) 结构的基于 transformer 与注意力机制的 U-Net (transformer-based attention U-Net, TransAttUnet)^[39] 和混合 CNN 和 transformer 的医学图像分割网络 (hybrid CNN-transformer framework for medical image, HTC-Net)^[40]。针对上述网络模型, 本研究以公平的性能比较为前提, 故对比实验将会使用相同的数据预处理方法和学习策略。

3.2 参数设置

本实验所有的实验模型均使用图形处理器 NVIDIA RTX 3080 (NVIDIA Inc., 美国)、Windows 10 专业版 (Microsoft Inc., 美国) 和计算统一设备架构 (compute unified device architecture, CUDA) 11.3.1 (NVIDIA Inc., 美国) 进行训练。实验采用的批大小 (batch size) 设置为 4, 训练轮次 (epoch) 设置为 200, 初始的学习率为 0.001, 权重衰减系数设置为 1×10^{-8} 。

3.3 消融实验

在 SSM 中, 不同的卷积核尺寸配置对分割精度的影响截然不同, 如表 1 所示, 最优结果用粗体表示。具体而言, 当卷积核配置为 $3 \times 3 \rightarrow 5 \times 5$ 时, precision 达 90.78%, 这表明该配置下模型在保留精细纹理特征方面能力较强, 但 DSC 和 recall 提升较少, 反映出其全局感知能力仍有局限。相比之下, 当卷积核配置为 $7 \times 7 \rightarrow 9 \times 9$ 时, 各评估指标呈明显下降趋势, precision 值甚至低于基础模型。这表明过大的卷积核会引入过多无关噪声导致模型损失大量关键的局部细节信息。综合以上实验结果, 本研究验证了在 SSM 中适度扩大感受野的必要性, 同时证明了本文所采用的卷积核配置方案在平衡感受范围与局部信息保留方面的有效性。

为评估 SSM 和 CWM 以及并行支路的有效性, 本文实验通过对比这些模块在独立或协同作用时对 ECPC-IDS 公开数据集的分割性能差异以展开验证。定量对比结果如表 2 所示, 最优结果用粗体表示, 次优结果用下划线表示。

消融实验中, 当 SSM 和 CWM 被单独引入时, 其余指标虽有所提升, 但 precision 出现小幅度的下降。这一现象表明, 缺乏并行支路提供的浅层纹理

表 1 不同卷积核设置的消融实验结果

Tab.1 Results of ablation experiments with different convolutional kernel settings

卷积核设置	DSC	IoU	precision	recall
$3 \times 3 \rightarrow 5 \times 5$	74.68%	72.11%	90.78%	74.68%
$5 \times 5 \rightarrow 7 \times 7$	82.98%	78.63%	92.36%	84.10%
$7 \times 7 \rightarrow 9 \times 9$	71.84%	69.37%	89.12%	71.84%

表 2 消融实验结果

Tab.2 Results of ablation experiments

模型	DSC	IoU	precision	recall
基础模型	71.38%	69.42%	91.74%	74.05%
基础模型 + SSM	74.17%	71.28%	91.01%	76.68%
基础模型 + CWM	72.07%	69.99%	90.88%	75.28%
基础模型 + 并行支路	<u>75.35%</u>	<u>73.11%</u>	<u>91.77%</u>	<u>78.23%</u>
SCWU-Net	82.98%	78.63%	92.36%	84.10%

特征和 CWM 强化的边缘细节时, 仅依赖 SSM 处理深层特征会因局部信息的损失而导致部分病灶区域漏检。同时, CWM 的空间抑制机制在缺少全局上下文支持的情况下, 易受到盆腔复杂解剖结构的干扰, 同样加剧了漏检风险。当 SSM 和 CWM 以及并行支路协同工作时, 各项指标均显著提升。这证实了 SSM 提供的全局信息感知能力可为 CWM 施加空间位置约束, 而 CWM 对病灶边缘的强化有效补充了模型缺失的局部细节特征。此外, 并行支路为 SSM 输送了浅层高分辨率特征进一步保障了网络的稳定性。上述结果充分验证了模块间的功能性互补, 共同驱动了模型分割性能的显著优化。

为直观展示模型的分割结果, 本文在测试集中筛选出四张典型 CT 图像作为示例 (示例 1 ~ 示例 4), 它们的病灶边缘中存在微小的形态学凸起且处于低对比度区域, 属于分割难度较高的样本。如图 4 所示, 每行展示一个示例的真实标签和不同配置的分割结果, 其中蓝色代表真实标签, 红色代表错检, 黄色代表漏检, 绿色代表正确分割。对比观察可见, 相较于模块单独工作的结果, 本文方法的分割结果错检、漏检区域明显减少, 与真实标签轮廓更加吻合。这一可视化证据进一步验证了本文方法的有效性。

3.4 对比实验

对比实验结果如表 3 所示, 最优结果用粗体表示, 次优结果用下划线表示。SCWU-Net 在 DSC (82.98%)、IoU (78.63%) 和 recall (84.10%) 三项核心指标上均优于所有对比模型, 其中 DSC 较次优模型有较大提升。值得关注的是, 尽管 TransAttUnet 的 precision 指标高达到 94.26%, 但 DSC




图 4 不同模块在消融实验中的效果对比

Fig.4 Comparison of different modules in the ablation study

(57.62%) 和 recall (59.34%) 却显著偏低, 呈现明显的性能失衡问题。该现象的根本原因在于模型结构设计, 同样是多层标准卷积层进行下采样, TransAttUnet 仅对最深层特征图应用 transformer 结构, 忽视了浅层特征图中丰富的细节纹理信息。此外, 相比对深层特征的复杂处理, 其他层特征仅通过简单的跳跃连接传递, 这种设计会导致特征间的语义差异和融合问题。实验数据表明, 本文方法通过协同优化多尺度特征提取, 能够全面地建模病灶区域的形态和纹理特征, 最终实现更加高效且性能均衡的自动分割效果。

为直观展示 SCWU-Net 与其他对比模型的分割性能差异, 本文选取具有代表性的分割结果进行定性对比分析。如图 5 所示, SegNet 因缺乏注意力引导, 难以有效识别病灶的结构特性, 导致分割结果存在明显缺失; DeepLabv3+ 善于捕捉目标的边缘细节, 但对边界模糊的病灶区域敏感度不足, 存在较多的漏检和错检; 基于注意力机制的 AttU-Net、EA-UNet 和 MBSNet 模型虽然病灶主体识别精度明显提升, 但其注意力模块对低对比度边界的响应能力仍显不足, 致使边界分割准确性受限; TransAttUnet 的网络架构与 EC 病灶特性适配不足, 分割区域过度保守, 与真实标签存在明显差异; HTC-Net 采用 transformer 结构替换标准卷积

表 3 不同模型在 ECPC-IDS 数据集上的分割性能对比

Tab.3 Comparison of segmentation performance of different models on ECPC-IDS dataset

模型	年份	DSC	IoU	precision	recall
U-Net	2015	71.38%	69.42%	91.74%	74.05%
SegNet	2017	70.84%	67.67%	85.40%	76.52%
DeepLabv3+	2018	75.00%	71.27%	87.30%	79.51%
AttU-Net	2021	<u>75.35%</u>	72.75%	91.07%	<u>78.34%</u>
EA-UNet	2023	75.23%	72.87%	91.77%	77.97%
TransAttUnet	2022	57.62%	57.27%	<u>94.26%</u>	59.34%
MBSNet	2023	75.11%	<u>73.59%</u>	97.37%	75.11%
HTC-Net	2024	73.39%	71.42%	92.15%	73.39%
SCWU-Net	2025	82.98%	78.63%	92.36%	84.10%

进行下采样, 虽然增强了模型上下文的感知能力, 但在复杂示例中 (如图 5 中示例 4) 的分割表现不佳, 反映其在小样本数据集中存在局限性。而本文 SCWU-Net 模型在病灶结构完整性和细节保留方面表现最优, 其分割轮廓与金标准的重合度最高。总之, 在定量指标和定性结果的双重验证下, 证实了本研究模型设计的有效性。

4 结论

本文针对 EC 早期诊断的 CT 图像分割需求, 提出了一种新型分割模型 SCWU-Net, 其核心创新在于将 SSM 和 CWM 集成到 U-Net 中, 显著提升了对 ECPC-IDS 数据集中 CT 图像的分割精度。具






图 5 不同模型在 ECPC-IDS 数据集上的分割效果对比

Fig.5 Comparison of segmentation results by different models on the ECPC-IDS dataset

体而言，通过并行分支获取浅层细节特征，引入SSM 通过并行大核深度卷积层构建渐进式的感受野扩大，并联合双路径池化特征拼接与自适应门控实现多尺度上下文感知，以精确定位病灶区域。同时，将 CWM 部署于跳跃连接处，通过通道注意力激励与基于方差归一化的空间抑制机制协同增强边缘响应，显著改善低对比度肿瘤边界模糊问题。在 ECPC-IDS 数据集上的实验表明，SCWU-Net 在四项评估指标 (DSC、IoU、precision 和 recall) 中分别达到了 82.98%、78.63%、92.36% 和 84.10%，其综合性能显著优于对比模型。可视化分析进一步证实，其分割结果轮廓与真实标签高度吻合且显著优于其他先进的分割模型。综上所述，本文不仅推进了 EC 病灶区域分割的技术性能，更为 CT 图像中弱边界组织的精准分割提供了可扩展的解决方案。

现阶段，基于单模态 CT 图像的病灶分割仍存在固有局限；未来，本领域研究或将拓展至多模态融合框架，基于 PET/CT 图像的代谢与解剖特征互补性，构建跨模态特征协同分割模型，以进一步提升 EC 病灶区域的分割精度。

重要声明

利益冲突声明：本文全体作者均声明不存在利益冲突。

作者贡献声明：彭如恕主要负责数据收集与处理、论文撰写与修改、成果验证；曾庆昊负责论文撰写、算法及实验设计与执行；何滨研究概念设计；刘俊杰负责实验方案设计与审核；肖章负责实验实施指导及论文审核、基金支持。

参考文献

- 1 Hong I S. Endometrial stem/progenitor cells: properties, origins, and functions. *Genes Dis*, 2022, 10(3): 931-947.
- 2 曹瑾瑾, 李佳, 李奇灵, 等. 子宫内膜癌筛查策略. *中国实用妇科与产科杂志*, 2023, 39(11): 1062-1065.
- 3 Ge L, Liu G, Hu K, *et al*. A new risk index combining d-dimer, fibrinogen, HE4, and CA199 differentiates suspecting endometrial cancer from patients with abnormal vaginal bleeding or discharge. *Technol Cancer Res Treat*, 2020, 19: 1533033819901117.
- 4 Huang G Q, Xi Y Y, Zhang C J, *et al*. Serum human epididymis protein 4 combined with carbohydrate antigen 125 for endometrial carcinoma diagnosis: a meta-analysis and systematic review. *Genet Test Mol Biomarkers*, 2019, 23(8): 580-588.
- 5 Wang J, Wang Y, Li Y, *et al*. Trend and characteristics of endometrial cancer in guangzhou from 2000 to 2020. *Eur J Obstet Gynecol Reprod Biol*, 2025, 305: 381-386.
- 6 李芳, 张果, 王建六. 子宫内膜癌筛查研究进展. *中国妇产科临床杂志*, 2025, 26(2): 152-155.
- 7 Baker-Rand H, Kitson S J. Recent advances in endometrial cancer prevention, early diagnosis and treatment. *Cancers*, 2024, 16(5): 1028.
- 8 王尧鑫, 吴昆华. 子宫内膜癌的影像组学研究进展. *中国医学影像学杂志*, 2022, 30(6): 630-634.
- 9 Shen Y, Yang W, Liu J, *et al*. Minimally invasive approaches for the early detection of endometrial cancer. *Molecular Cancer*, 2023, 22(1): 53.
- 10 王晓君, 刘军秀. 人工智能在妇科恶性肿瘤中的进展. *中山大学学报*, 2025, 46(1): 21-29.
- 11 冯龙锋, 陈英, 周滔辉, 等. CT图像肺及肺病变区域分割方法综述. *中国图象图形学报*, 2022, 27(3): 722-749.
- 12 田苗苗, 支力佳, 张少敏, 等. 医学CT影像超分辨率深度学习方法综述. *计算机工程与应用*, 2024, 60(3): 44-60.
- 13 Guo L, Yu Y, Yang F, *et al*. Accuracy of baseline low-dose computed tomography lung cancer screening: a systematic review and meta-analysis. *Chinese Medical Journal*, 2023, 136(9): 1047-1056.
- 14 金涛, 王震, 李昭蒂. 基于多尺度注意力U-Net的医学肝脏计算

- 机断层扫描图片分割算法. 哈尔滨工程大学学报, 2025, 46(3): 529-539.
- 15 扈拯宁, 黄强, 谢尧, 等. 基于卷积神经网络的卵巢囊腺瘤CT图像病灶分割. 计算机应用与软件, 2025, 42(1): 189-196.
- 16 石军, 王天同, 朱子琦, 等. 基于深度学习的医学图像分割方法综述. 中国图象图形学报, 2025, 30(6): 2161-2186.
- 17 Rai H M. Cancer detection and segmentation using machine learning and deep learning techniques: a review. *Multimedia Tools and Applications*, 2024, 83(9): 27001-27035.
- 18 张玮智, 于谦, 苏金善, 等. 从U-Net到Transformer: 深度模型在医学图像分割中的应用综述. 计算机应用, 2024, 44(1): 204-222.
- 19 Wang Y, Chen Z, Liu C, *et al.* Radiomics-based fertility-sparing treatment in endometrial carcinoma: a review. *Insights into Imaging*, 2023, 14(1): 127.
- 20 Reeder K, Lee H. Impact of artificial intelligence on US medical students' choice of radiology. *Clinical Imaging*, 2022, 81: 67-71.
- 21 Chen X, Wang Y, Shen M, *et al.* Deep learning for the determination of myometrial invasion depth and automatic lesion identification in endometrial cancer MR imaging: a preliminary study in a single institution. *European Radiology*, 2020, 30(9): 4985-4994.
- 22 Kurata Y, Nishio M, Moribata Y, *et al.* Automatic segmentation of uterine endometrial cancer on multi-sequence MRI using a convolutional neural network. *Scientific Reports*, 2021, 11(1): 14440.
- 23 Mao W, Chen C, Gao H, *et al.* A deep learning-based automatic staging method for early endometrial cancer on MRI images. *Frontiers in Physiology*, 2022, 13: 974245.
- 24 Li D, Hu R, Li H, *et al.* Performance of automatic machine learning versus radiologists in the evaluation of endometrium on computed tomography. *Abdominal Radiology*, 2021, 46(11): 5316-5324.
- 25 Kim N, Chang J S, Kim Y B, *et al.* Atlas-based auto-segmentation for postoperative radiotherapy planning in endometrial and cervical cancers. *Radiation Oncology*, 2020, 15(1): 106.
- 26 Li C, Qiang Y, Sultan R I, *et al.* FocalUNETR: a focal transformer for boundary-aware prostate segmentation using CT images//International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer Nature Switzerland, 2023: 592-602.
- 27 Guo M H, Xu T X, Liu J J, *et al.* Attention mechanisms in computer vision: a survey. *Computational Visual Media*, 2022, 8(3): 331-368.
- 28 Yang L, Zhang R Y, Li L, *et al.* Simam: a simple, parameter-free attention module for convolutional neural networks//International Conference on Machine Learning, Vienna: PMLR, 2021: 11863-11874.
- 29 Yao M, Zhao G, Zhang H, *et al.* Attention spiking neural networks. *IEEE Trans Pattern Anal Mach Intell*, 2023, 45(8): 9393-9410.
- 30 Tang D, Li C, Du T, *et al.* ECPC-IDS: a benchmark endometrial cancer PET/CT image dataset for evaluation of semantic segmentation and detection of hypermetabolic regions. *Computers in Biology and Medicine*, 2024, 171: 108217.
- 31 潘丹, 骆根强, 曾安. 基于Transformer和卷积神经网络双并行分支编码器神经网络的冠状动脉分割. 生物医学工程学杂志, 2024, 41(6): 1195-1203,1212.
- 32 武星, 陶晨杰, 李智, 等. 基于通道权重和数据效用特征的医学图像分割数据增强方法. 生物医学工程学杂志, 2024, 41(2): 220-227,236.
- 33 Ranneberger O, Fischer P, Brox T. U-net: convolutional networks for biomedical image segmentation//Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015: 18th International Conference, Munich: Springer International Publishing, 2015: 234-241.
- 34 Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation. *IEEE Trans Pattern Anal Mach Intell*, 2017, 39(12): 2481-2495.
- 35 Chen L C, Zhu Y, Papandreou G, *et al.* Encoder-decoder with atrous separable convolution for semantic image segmentation//Proceedings of the European conference on computer vision (ECCV), Munich: EACV, 2018: 801-818.
- 36 Wang S, Li L, Zhuang X. AttU-Net: attention U-Net for brain tumor segmentation//International MICCAI brainlesion workshop. Cham: Springer International Publishing, 2021: 302-311.
- 37 Xiao Z, Du M, Liu J, *et al.* EA-UNet based segmentation method for OCT image of uterine cavity. *Photonics*, 2023, 10(1): 73.
- 38 Jin S, Yu S, Peng J, *et al.* A novel medical image segmentation approach by using multi-branch segmentation network based on local and global information synchronous learning. *Scientific Reports*, 2023, 13(1): 6762.
- 39 Chen B, Liu Y, Zhang Z, *et al.* Transattunet: multi-level attention-guided U-net with transformer for medical image segmentation. *IEEE Transactions on Emerging Topics in Computational Intelligence*, 2023, 8(1): 55-68.
- 40 Tang H, Chen Y, Wang T, *et al.* HTC-Net: a hybrid cnn-transformer framework for medical image segmentation. *Biomedical Signal Processing and Control*, 2024, 88: 105605.

收稿日期: 2025-02-12 修回日期: 2025-07-16

本文编辑: 陈咏竹

