

· 论 著 ·

基于nnU-Net的肾脏区域分割方法及其术中应用

王文韬¹ 张海康^{1,2} 黄清明^{1,3} 黄亦成^{1,4} 徐天宇^{1,5} 胡敏捷¹ 沈兵^{1,2,4}

摘 要 目的 探索基于nnU-Net的深度学习方法在肾脏手术中的应用,特别是术中图像分割的可行性。随着肾脏肿瘤手术的复杂性增加,精准的术中图像分割成为手术导航的关键。研究目标是通过nnU-Net框架,提高术中肾脏区域的自动识别和定位精度,从而为智能辅助手术系统提供技术支持。**方法** 基于术中获取的左目内镜图像,采用nnU-Net框架构建了二维语义分割模型。训练数据通过逐帧截取术中图像,并结合手工掩码标注生成。标注区域包括肾脏实质、肿瘤及表面粘连脂肪,作为一个统一的感兴趣区域(region of interest, ROI)进行识别。在数据验证方面,使用了独立的测试集,包括未参与训练和验证的5例肾脏手术病例,最终通过与人工标注的掩码进行对比分析,以评估模型在术中图像分割中的表现。**结果** 模型在独立测试集中表现良好,平均Dice相似系数(Dice similarity coefficient, DSC)为0.933 5,交并比(intersection over union, IoU)为0.878 4,精确率(precision)为0.951 7,召回率(recall)为0.921 1, *F1* 分数(*F1 score*)为0.933 5。nnU-Net能够有效地分割肾脏区域,并在不同情况下保持较高的分割精度。推理速度方面,模型的平均单帧分割时间约为0.38 s,显示出较强的处理能力,适用于术中快速图像更新与定位识别需求。**结论** nnU-Net模型在复杂术中图像环境中依然保持较高的准确性与鲁棒性,验证了nnU-Net在实时图像分割任务中的应用潜力。nnU-Net可以为智能辅助手术系统提供可靠的技术支撑,具有较好的临床应用前景。

关键词 深度学习;图像分割;肾脏区域;术中图像;nnU-Net

DOI: 10.3969/j.issn.1002-3208.2026.03.001.

中图分类号 R318.04 **文献标志码** A **文章编号** 1002-3208(2026)03-0221-08

本文著录格式 王文韬,张海康,黄清明,等. 基于nnU-Net的肾脏区域分割方法及其术中应用[J]. 北京生物医学工程, 2026, 45(3): 221-228, 246. WANG Wentao, ZHANG Haikang, HUANG Qingming, et al. Kidney region segmentation method based on nnU-Net and its intraoperative application [J]. Beijing Biomedical Engineering, 2026, 45(3): 221-228, 246.

Kidney region segmentation method based on nnU-Net and its intraoperative application

WANG Wentao¹, ZHANG Haikang^{1,2}, HUANG Qingming^{1,3}, HUANG Yicheng^{1,4}, XU Tianyu^{1,5},
HU Minjie¹, SHEN Bing^{1,2,4}

1 School of Health Science and Engineering, University of Shanghai for Science and Technology, Shanghai 200093;

2 Shanghai Engineering Research Center of Interventional Medical Device, University of Shanghai for Science and Technology, Shanghai 200093;

3 School of Medical Imaging, Shanghai University of Medicine & Health Sciences, Shanghai 201318;

4 Department of Urology, Shanghai Tenth People's Hospital, Tongji University, Shanghai 200072;

5 Shanghai Hospital Development Center, Shanghai 200041

Corresponding author: SHEN Bing (E-mail: uodrshenbing@shsmu.edu.cn)

【Abstract】 Objective Explore the application of deep learning methods based on nnU-Net in kidney

surgery, particularly the feasibility of intraoperative image segmentation. As the complexity of kidney tumor surgery increases, precise intraoperative image segmentation becomes crucial for surgical navigation. The research goal is to improve the automatic recognition and localization accuracy of the renal region during surgery using the nnU-Net framework, thereby providing technical support for intelligent assisted surgery systems. **Methods** Based on the left-eye endoscopic images obtained during surgery, a 2D semantic segmentation model was constructed using the nnU-Net framework. The training data were generated by extracting individual frames from the intraoperative images and combining them with manually annotated masks. The annotated regions include renal parenchyma, tumors, and surface-adhered fat, which were identified as a unified region of Interest (ROI). For data validation, an independent test set was used, consisting of five kidney surgery cases that did not participate in the training and validation. The model's performance in intraoperative image segmentation was evaluated by comparing it with manually annotated masks. **Results** The model performed well on the independent test set, with an average Dice similarity coefficient (DSC) of 0.9335, intersection over union (IoU) of 0.8784, precision of 0.9517, recall of 0.9211, and *F1* score of 0.9335. These results indicate that nnU-Net can effectively segment the renal region and maintain high segmentation accuracy under various conditions. In terms of inference speed, the average single-frame segmentation time of the model is approximately 0.38 seconds, demonstrating strong processing capability, making it suitable for rapid intraoperative image updates and localization tasks. **Conclusions** The nnU-Net model maintains high accuracy and robustness even in complex intraoperative image environments, validating its potential for real-time image segmentation tasks. nnU-Net can provide reliable technical support for intelligent assisted surgery systems, showing promising clinical application prospects.

【Keywords】 deep learning; image segmentation; kidney region; intraoperative image; nnU-Net

0 引言

肾脏肿瘤切除术是泌尿外科常见的重要手术方式,随着腹腔镜与机器人辅助手术的广泛开展,术中对肾脏区域的快速识别与精准定位需求不断提升^[1]。针对肾脏区域的快速识别与精准定位,传统依赖术者经验与术中视觉判断的方式,存在识别效率低、易受人为因素影响等问题,制约了手术精细化发展的进程^[2-3]。因此,如何提高肾脏区域定位的准确性和效率,成为当前医学影像领域亟待解决的挑战。

随着深度学习技术在医学图像处理中的迅猛发展,尤其是在自动分割领域,术中视觉增强已成

为技术突破的关键^[4-5]。其中,nnU-Net作为具备自适应配置能力的深度学习分割框架,在多项公开医学影像挑战中展现出优异性能与广泛适应性^[6]。已有研究将nnU-Net应用于术前CT或MRI图像的处理,取得了显著成果^[7-8],但术中内镜图像因结构动态变化、光照复杂等因素,尚缺乏成熟的分割方案^[9-10]。

针对上述问题,nnU-Net的自适应性和高效的分割能力使其成为术中图像分割的理想选择。通过自动化分割术中图像中的关键结构,nnU-Net能够为术前与术中图像的配准提供准确的解剖信息,从而增强手术导航系统的精度与实时性,提升手术的安全性与效果。然而,尽管nnU-Net在静态图像中的分割表现优秀,如何在动态变化的术中图像环境中实现高效的实时图像分割,仍然是当前研究中的一大难点。

本研究基于真实肾脏肿瘤手术中获取的左目内镜图像,构建nnU-Net二维语义分割模型,探索其在术中肾脏区域自动识别中的可行性。研究旨在通过利用nnU-Net的自适应性解决术中图像分割的

作者单位:1 上海理工大学健康科学与工程学院(上海 200093)

2 上海理工大学上海介入医疗器械工程技术研究中心
(上海 200093)

3 上海健康医学院医学影像学院(上海 201318)

4 同济大学附属第十人民医院泌尿外科(上海 200072)

5 上海申康医院发展中心(上海 200041)

通信作者:沈兵。E-mail:urodrshenbing@shsmu.edu.cn

挑战,为智能辅助手术系统提供更加精确、实时的图像分析支持,并推动深度学习技术在临床手术中的应用。

1 材料与方法

1.1 数据来源与图像预处理

回顾性分析2023年9月—2024年5月在同济大学附属第十人民医院进行肾部分切除术(partial nephrectomy, PN)或根治性切除术(radical nephrectomy, RN)的75例经病理证实的肾脏肿瘤患者的术中资料。手术过程中采用高清双目内镜采集术野视频影像,本研究选取左目图像作为分析对象。所有影像数据均已完成脱敏处理,不含任何可识别个人身份的信息,研究过程符合医学伦理要求及相关隐私保护规定。术中视频由经验丰富的泌尿外科医师回顾筛选,选取肾脏完全暴露、图像清晰、光照均匀且无遮挡的关键帧图像作为研究样本,并统一保存为PNG格式,最终构建用于模型训练与测试的术中图像数据集。

1.2 掩码图标注与数据集构建

为实现肾脏区域的有效分割,本研究采用医学图像处理软件ITK-SNAP对术中图像进行手工掩码标注^[11]。由具备医学图像基础的专业人员对每张图像逐一标注感兴趣区域,标注范围包括肾脏实质主体、表面肿瘤及粘连脂肪等组织,整体作为统一的目标区域进行识别。背景部分不予标注,掩码图为二值形式,与原始图像保持一一对应,尺寸一致,均以PNG格式保存,构成标准的监督学习样本集。数据集划分严格按病例维度进行,确保同一病例的图像不会同时出现在训练集与测试集中,同时设置独立测试集用于模型性能评估。

1.3 模型训练与配置

本研究基于nnU-Net框架构建了用于术中肾脏图像分割的二维卷积神经网络模型,采用PlainConvUNet作为基础结构。图1为nnU-Net的自动化方法配置,概述了nnU-Net框架的数据处理流程,涵盖了训练数据的预处理、模型训练过程以及最终的预测步骤。其中“数据指纹”指的是在数据处理过程中提取的关键特征,这些特征用于表示数据的独特信息,有助于模型识别和处理不同类型的输入图像。“处理流程指纹”则指在数据处理、模型

训练和推理各阶段中生成的特征变化轨迹,体现了数据在各个阶段的转换和优化过程。模型输入为大小448×576的图像切块,图像数据为三通道术中内镜帧图像,监督信号为对应的二值掩码图。网络结构由7层下采样路径和对应的对称上采样路径构成,每个编码阶段包含2个3×3卷积模块,下采样采用步长为2×2的最大池化操作,特征通道数逐步增加,最大通道数为512。

图像预处理阶段采用Z-score标准化方法,对每个通道独立进行归一化,并使用感兴趣区域掩码辅助计算均值和标准差以提升归一化的稳定性。在训练阶段,模型采用组合损失函数以增强分割性能,启用了基于全batch计算的Soft Dice损失,用于缓解前景与背景类别比例不平衡的问题,并结合多类别交叉熵(cross entropy loss, CEL)共同优化网络参数。两者按线性加权方式组合构成总损失,权重均设为1,兼顾像素级预测精度与区域重叠程度的优化目标。总损失函数定义如下:

$$L = L_{CE} + L_{Dice} \quad (1)$$

$$L_{CE} = -\frac{1}{N} \sum_{i=1}^N \sum_{c=1}^C g_{i,c} \log(p_{i,c}) \quad (2)$$

$$L_{Dice} = 1 - \frac{2 \sum_{i=1}^N \sum_{c=1}^C p_{i,c} g_{i,c} + \varepsilon}{\sum_{i=1}^N \sum_{c=1}^C p_{i,c} + \sum_{i=1}^N \sum_{c=1}^C g_{i,c} + \varepsilon} \quad (3)$$

式中: L 为总损失函数,由多类别交叉熵损失 L_{CE} 与Soft Dice损失 L_{Dice} 线性加权组成; N 为参与计算的像素总数; C 为分割任务中的类别数量; $p_{i,c}$ 为模型对第 i 个像素属于第 c 类的预测概率(经softmax归一化后); $g_{i,c} \in \{0, 1\}$ 为该像素的one-hot编码标签,表示其真实所属类别; ε 为平滑项,避免分母为0,在本研究中取 10^{-5} 。

本研究共纳入75例经病理证实的肾脏肿瘤患者术中影像数据,其中70例用于nnU-Net模型的训练与验证,5例作为独立测试病例。为保证模型性能评估的客观性,数据划分严格按病例维度执行,确保同一病例的图像不会同时出现在不同数据集中。在训练过程中监控了损失函数和模型的Pseudo Dice系数(Pseudo Dice coefficient, PDC),学习曲线如图2所示。

从图2可以看出,模型在训练过程中逐步收敛,并且Pseudo Dice系数不断提高,表明模型的分割性





图1 nnU-Net 自动化方法配置

Figure 1 Configuration of the nnU-Net automated framework



蓝色曲线表示训练损失,红色曲线表示验证损失,绿色虚线表示Pseudo Dice系数,绿色实线表示Pseudo Dice系数的移动平均

图2 学习曲线

Figure 2 Learning curves

能有所提升。

在模型训练阶段,nnU-Net框架采用五折交叉验证(five-fold cross-validation)方式自动划分训练与验证数据,每次迭代中约80%的病例用于训练,20%的病例用于验证。该策略可有效缓解单次划分可能造成的偏差,提高模型在有限样本条件下的稳定性与泛化能力。

1.4 测试方法与性能评估

为客观评估模型在术中图像中的分割性能,本研究设置独立测试集,选取5例未参与训练与验证的肾脏手术病例,共计100张肾脏暴露清晰的关键帧图像。所有测试图像均由人工标注掩码构成标准测试集,使用训练完成的模型逐帧进行分割预测,并与对应人工标注结果进行对比分析。为了确

保评估的科学性与全面性,本研究选择了多个常用的医学图像分割性能评估指标,包括Dice相似系数(Dice similarity coefficient, DSC)、交并比(intersection over union, IoU)、精确率(precision)、召回率(recall)及F1分数(F1-score)。Dice相似系数和IoU主要衡量预测区域与真实区域的重叠度,能够有效评估肾脏区域的分割精度,特别适用于处理复杂边界和不规则形状的器官。精确率和召回率则分别从预测结果的准确性和完整性角度进行评价,精确率反映了模型预测为肾脏区域的像素中实际为肾脏的比例,召回率则衡量了实际肾脏区域中被正确预测的比例,这两者的平衡对于保证分割结果的全面性至关重要。F1分数作为精确率与召回率的调和平均,综合考虑了二者之间的权衡,能够在两者不平衡的情况下提供更为客观的评估。通过这些指标的结合使用,能够全面、系统地评价模型在术中图像分割中的性能,并确保评估方法的科学性与可靠性。此外,通过与传统分割方法U-Net在相同评价指标下的对比,验证了本研究方法的科学性,并在分割效果上展示了其优越性。各项指标定义如下:

$$DSC = \frac{2 \times TP}{2 \times TP + FP + FN} \quad (5)$$

$$IoU = \frac{TP}{TP + FP + FN} \quad (6)$$

$$精确率 = \frac{TP}{TP + FP} \quad (7)$$

$$召回率 = \frac{TP}{TP + FN} \quad (8)$$

$$F1分数 = \frac{2 \times 精确率 \times 召回率}{精确率 + 召回率} \quad (9)$$

式中:TP(true positive)为模型正确预测为感兴趣区域的像素数;FP(false positive)为模型误判为感兴趣区域的像素数;FN(false negative)为模型漏判为背景的像素数。

除分割精度外,本研究还评估了模型的推理速度,以验证其在术中应用中的可行性。推理实验使用单帧分割时间作为评价指标,评估了模型在术中图像处理中的响应速度和实时性。

2 结果

2.1 测试样本分割效果

为直观展示所构建模型在术中图像中的分割

效果,本研究选取5个肾脏解剖结构差异较大的病例作为图像独立测试集。针对每例病例的关键帧图像,分别展示原始术中图像、人工标注掩码及模型预测结果,用于对比分析分割准确性与边界拟合情况,如图3所示。

从图3可见,模型预测的肾脏区域与人工标注结果在轮廓形态和空间范围上高度一致,能准确勾勒肾脏边界并在复杂术野中保持良好识别效果。

结果表明,术中肾实质的分割是一项极具挑战性的任务。首先,患者之间存在显著的外观差异。其次,由于手术操作及解剖结构的差异,患者在手术过程中内部外观变化较大。第三,受边缘模糊、肾周脂肪粘连及术中出血等因素影响,肾实质与周围组织之间的边界对比度显著降低,使得边界区域的精确判定具有一定难度。在此情况下,模型在部分复杂场景下的边界识别仍可能出现局部偏差,表现为边界处的少量过分割或欠分割现象,如图4中预测新增区域与遗漏区域所示。

2.2 模型性能定量评估

为进一步验证模型分割结果的准确性,本研究采用DSC、IoU、精确率、召回率和F1分数等指标对模型性能进行定量评估。


表1总结了模型在5个样本测试集上的平均性能指标。结果显示,各项指标均保持在较高水平,其中DSC和IoU反映了预测区域与真实标注的高重叠度,精确率与召回率的平衡说明模型在检出率与误检率间表现稳定,整体性能具有较好的可靠性。

除分割精度外,本研究还评估了模型的推理速度,以验证其在术中应用中的可行性。推理实验在具有高性能GPU的工作站上完成,对100张分辨率为1 980×1 020的术中图像进行批量推理的总耗时约为37.7 s,平均单帧分割时间约为0.38 s(约2.6帧/s)。该结果表明模型具备较快的响应速度和关键帧级近实时处理能力,可满足术中快速图像更新与定位识别的需求,为进一步实现实时分割与导航增强提供了技术基础^[12]。

2.3 与传统分割方法的对比分析

为验证所构建nnU-Net模型在本研究数据集上的性能优势,本研究在相同的术中肾脏图像数据集上与经典U-Net模型进行了对比实验^[13]。


U-Net模型在训练过程中采用



左:原始图像;中:原图+人工标注;右:原图+模型预测。黄色曲线为分割边界

图 3 5 个病例在不同帧图像中的分割结果

Figure 3 Representative segmentation results of five cases across different image frames



从左到右依次为原始图像、人工标注、模型预测结果及人工标注与模型预测结果的差异图(绿色为预测新增区域,红色为预测遗漏区域)

图 4 用于肾脏分割的 3 张测试图像

Figure 4 Three test images for kidney segmentation

表1 模型在测试集上的平均性能评估指标

Table 1 Average performance evaluation metrics of the model on the test set

指标名称	平均值±标准误差
DSC	0.933 5±0.004 5
IoU	0.878 4±0.007 5
精确率	0.951 7±0.005 4
召回率	0.921 1±0.007 1
F1分数	0.933 5±0.004 5

BCEWithLogitsLoss(Binary Cross Entropy with Logits Loss, BCEWithLogitsLoss)与Dice Loss的加权组合作为优化目标,训练集与验证集按8:2比例划分。为保证实验的可比性,两种模型均在本研究自建的术中图像数据集上使用相同的训练策略与评价指标进行评估(表2)。

表2 nnU-Net与传统分割方法U-Net对比的性能评估指标
(平均值±标准误差)

Table 2 Performance evaluation metrics comparing nnu-net with traditional segmentation method U-Net(mean ± standard error)

指标名称	nnU-Net	U-Net
DSC	0.933 5±0.004 5	0.663 1±0.025 1
IoU	0.878 4±0.007 5	0.540 7±0.024 4
精确率	0.951 7±0.005 4	0.844 3±0.018 9
召回率	0.921 1±0.007 1	0.621 9±0.027 8
F1分数	0.933 5±0.004 5	0.683 1±0.023 7

实验结果显示,在相同数据集与评估条件下,nnU-Net在Dice相似系数和IoU指标上分别提升了约40.78%和62.46%,召回率提升了约48.11%。表明针对肾脏左目内镜图像数据,nnU-Net模型的特征提取与目标识别能力更强,能够实现更高精度的术中肾脏区域分割。

3 讨论

本研究基于深度学习分割框架nnU-Net,构建了一种面向术中内镜图像的二维肾脏区域自动分割方法,并在真实肾脏肿瘤手术图像数据集上完成系统训练与验证。该方法在复杂术中场景下表现出较高分割精度和推理速度,具备结构自适应与实

时应用潜力,可与术中导航系统集成,实现器官识别与动态可视化,为智能辅助手术提供技术支撑。

已有研究针对机器人辅助手术场景提出了语义分割模型,其在器械与单一解剖结构(前列腺、膀胱)上表现良好(整体DSC=0.85;膀胱DSC=0.74)^[14],但这些任务往往结构边界清晰、组织相对规则。在肾脏相关研究中,Kilian等^[15]采用U-Net对肾脏实质区进行语义分割,其模型在真实术中图像中的平均DSC为0.891 1, IoU为0.810 1,该网络主要作为视觉增强系统中的前处理模块,用于辅助关键点跟踪,在边界精度和目标轮廓细节保持方面仍存在一定局限。

相比之下,本文基于nnU-Net的模型在无需区域限制与结构定制的前提下即实现DSC=0.933 5、IoU=0.878 4的更优性能,且面向完整肾脏区域进行端到端分割,进一步体现了其在复杂术中图像场景下的泛化能力与实用价值。通过与传统方法U-Net的对比,进一步验证了本研究方法的科学性与分割效果上的优越性。nnU-Net相比U-Net在多个指标上均显示了显著的提升,特别是在DSC和IoU上,提升超过40个百分点,召回率提升近50个百分点,表明nnU-Net在复杂术中图像场景中的应用潜力。

结合对多个典型病例的可视化分析可以看出,模型在大多数样本中能够准确识别肾脏区域的边界轮廓,与人工标注结果高度一致,反映出其对肾脏结构的有效学习与表征能力。尤其在肾脏暴露充分、组织边界清晰的图像中,模型分割结果更加贴近真实解剖结构,验证了其对术中图像语义信息的良好感知能力。相比传统方法依赖手工特征、需针对特定器官或成像设备调参的方式,nnU-Net展现出更高层次的自动化与泛化性^[16],具备进一步集成至智能辅助手术系统的潜力。

尽管如此,本研究仍存在一定局限性。首先,由于术中图像易受遮挡、器械干扰及光照变化等因素影响,模型在部分图像中出现了边界轮廓偏移或局部区域漏检等问题,影响了局部区域的分割精度^[17-18],这种局部误差反映了术中图像质量的不稳定性,以及模型在复杂环境下的局部适应能力的不足,未来可以通过增强图像的鲁棒性来解决这一问题。其次,目前训练数据主要来源于单一中心,图像样本数量相对有限,可能限制了模型在多机构、

多设备下的泛化能力^[19],因此在未来的研究中,应进一步拓展数据集,采集来自不同医疗中心和不同成像设备的图像,以提高模型的跨机构、跨设备应用能力。此外,现阶段模型未引入专门的注意力机制、边界增强模块及图像增强策略等方法^[20-22],对于组织边界模糊、肿瘤侵犯或脂肪粘连区域的细致识别仍有提升空间,未来研究将考虑引入这些技术,以增强模型在复杂图像和模糊边界区域的分割能力。模型的进一步优化可能还需要通过引入更多的领域知识或多模态数据来提升分割精度,尤其是在肿瘤侵犯和粘连组织的区域。未来研究将重点提升模型在多中心数据下的泛化能力与复杂边界区域的识别精度,同时推进模型结构的轻量化设计^[23-24],以在确保精度的前提下提升实时推理速度与资源利用效率,探索其在术中实时应用中的可行性。

4 结论

本文提出了一种基于 nnU-Net 的术中肾脏区域自动分割方法,该方法在复杂术场景中表现出较高分割精度和推理速度。相比传统方法(如 U-Net),nnU-Net 在 Dice 相似系数、IoU 和召回率等指标上均有显著提升,展现出更高的自动化程度和更强的泛化能力。该方法能够适应多样的术中图像特点,为智能辅助手术系统中的术中图像分割提供有效的解决方案。nnU-Net 的结构自适应能力和较高的推理速度使其具备了实时应用的潜力,未来有望在多中心数据和复杂边界区域的识别精度上进一步优化,推动其在临床中的广泛应用。

参考文献

- [1] Stefano P, Ahmed E, Enrico C, et al. New imaging technologies for robotic kidney cancer surgery[J]. Asian Journal of Urology, 2022, 9(3): 253-262.
- [2] Wang Y, Wilder S, Hijazi M, et al. Surgeon skill and perioperative outcomes in robot-assisted partial nephrectomy[J]. JAMA Network Open, 2024, 7(7): e2421696.
- [3] Soomro NA, Hashimoto DA, Porteous AJ, et al. Systematic review of learning curves in robot-assisted surgery[J]. BJS Open, 2020, 4(1): 27-44.
- [4] Gao YH, Jiang Y, Peng YA, et al. Medical image segmentation: a comprehensive review of deep learning-based methods[J]. Tomography (Ann Arbor, Mich.), 2025, 11(5): 52.
- [5] Yao WJ, Bai JJ, Liao W, et al. From CNN to transformer: a review of medical image segmentation models[J]. Journal of Imaging Informatics in Medicine, 2024, 37(4): 1529-1547.
- [6] Jeon KS, Joo I, Park J, et al. Fully-automated multi-organ segmentation tool applicable to both non-contrast and post-contrast abdominal CT: deep learning algorithm developed using dual-energy CT images[J]. Scientific Reports, 2024, 14(1): 4378.
- [7] Krishnan C, Schmidt E, Onuoha E, et al. nnUNet for automatic kidney and cyst segmentation in autosomal dominant polycystic kidney disease[J]. Current Medical Imaging, 2024, 20(1): 1-9.
- [8] Luo H, Li JZ, Huang HY, et al. AI-based segmentation of renal enhanced CT images for quantitative evaluation of chronic kidney disease[J]. Scientific Reports, 2024, 14(1): 16890.
- [9] Nie ZH, Xu MH, Wang ZY, et al. A review of application of deep learning in endoscopic image processing[J]. Journal of Imaging, 2024, 10(11): 275.
- [10] Zhang M, Ye Z, Yuan EY, et al. Imaging-based deep learning in kidney diseases: recent progress and future prospects[J]. Insights into Imaging, 2024, 15(1): 50.
- [11] Yushkevich PA, Gao Y, Guido G. ITK-SNAP: An interactive tool for semi-automatic segmentation of multi-modality biomedical images[J]. Annual International Conference of the IEEE Engineering in Medicine and Biology Society, 2016, 2016: 3342-3345.
- [12] Tanzi L, Piazzolla P, Porpiglia F, et al. Real-time deep learning semantic segmentation during intra-operative surgery for 3D augmented reality assistance[J]. International Journal of Computer Assisted Radiology and Surgery, 2021, 16(9): 1435-1445.
- [13] Ronneberger O, Fischer P, Brox T. U-Net: convolutional networks for biomedical image segmentation[M]// Navab N, Hornegger J, Wells W, et al, eds. Medical image computing and computer-assisted intervention-MICCAI 2015. Cham: Springer, 2015: 234-241.
- [14] Park GS, Park J, Choi RH, et al. Deep learning model for real-time semantic segmentation during intraoperative robotic prostatectomy[J]. European Urology Open Science, 2024, 62: 47-53.
- [15] Kilian C, Rasoul S, Salomé M, et al. Kidney tracking for live augmented reality in stereoscopic mini-invasive partial nephrectomy[J]. Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization, 2023, 11(4): 1251-1260.

(下转第 246 页)