中图法分类号:TP751　　文献标识码:A　　文章编号:1006-8961(XXXX)XX-0001-16

论文引用格式:Zou Shuizhong, Wen Chuanqing, Wang Jian, Qiu Hao. Prostate MRI Segmentation via TransUNet with Policy Gradient-Driven Dynamic Attention[J/OL]. Journal of Image and Graphics, XXXX:1-16. DOI: 10.11834/jig.260018.(邹水中, 文传清, 王剑, 邱豪. 策略梯度驱动的动态注意力TransUNet前列腺MRI分割[J/OL]. 中国图象图形学报, XXXX:1-16. DOI: 10.11834/jig.260018.)[DOI:10.11834/jig.260018]

策略梯度驱动的动态注意力TransUNet前列腺MRI分割

邹水中[1],文传清[1],王剑[1],邱豪[2]

1. 桂林电子科技大学电子工程与自动化学院,桂林,541000; 2. 哈尔滨工业大学机器人技术与系统全国重点实验室,哈尔滨,150001

摘　要:目的　前列腺MRI分割是精准放疗与疾病诊断的前提。现有TransUNet类模型虽结合了CNN(Convolutional Neural Networks)与Transformer的优势,但其静态注意力机制导致计算资源冗余,且在处理多中心异质数据及模糊边界时表现不佳。针对此问题,本文提出一种基于强化学习策略梯度优化的RL-TransUNet模型。**方法**　该模型在TransUNet编码器中嵌入REINFORCE(REward Increment by Negative-gradient, Combined with Objective Function through REinforcement)策略梯度算法,将注意力头权重分配建模为动态决策过程。相较于静态注意力机制,本方法实现了任务驱动的自适应权重分配。通过构建"交叉熵+Dice+边界IoU"的复合奖励函数,智能体能够根据图像难易程度自适应地抑制冗余注意力头,聚焦于前列腺尖部等困难区域。此外,本文设计了包含空间/强度归一化的定制化预处理流程以适应多源数据。**结果**　在两个具有代表性的公开数据集上进行了全面验证:在多中心、高异质性的PROMISE12数据集上,模型Dice(Dice Similarity Coefficient)系数达0.940,HD95(95th percentile Hausdorff Distance)降至3.00 mm;在规模更大、质量更高的Prostate158数据集(158例3T MRI)上,Dice系数进一步提升至0.950,且推理效率与基线模型持平。**结论**　RL-TransUNet不仅有效解决了注意力冗余问题,更在小样本异质数据和大规模标准数据上均展现出卓越的分割精度与泛化能力,为临床辅助诊断提供了鲁棒的解决方案。

关键词:医学图像分割;前列腺分割;强化学习;策略梯度;注意力优化;多中心异质性

Prostate MRI Segmentation via TransUNet with Policy Gradient-Driven Dynamic Attention

Zou Shuizhong[1], Wen Chuanqing[1], Wang Jian[1], Qiu Hao[2]

1. Guilin University of Electronic Technology, Guilin 541000, China; 2. State Key Laboratory of Robot Technology and Systems, Harbin Institute of Technology (HIT), Harbin 150001, China

Abstract: Objective Prostate cancer (PCa) remains one of the most critical challenges within the global public health system, currently ranking first in incidence among male malignancies with a continuously rising mortality trajectory. In contemporary clinical practice, radiotherapy constitutes a frontline, curative intervention for patients with localized and locally advanced prostate cancer. The therapeutic efficacy of this treatment, alongside the critical mitigation of severe toxic side effects such as radiation proctitis and bladder injury, is profoundly dependent on the precise and accurate delineation of the Clinical Target Volume (CTV) and adjacent Organs at Risk (OARs). Due to its superior soft-tissue contrast and excep-

收稿日期:2026-01-08;修回日期:2026-05-12

基金项目:国家自然科学基金项目(项目编号:62363007);广西自然科学基金项目(项目编号:2025GXNSFAA069462)

Supported by: National Natural Science Foundation of China(62363007); Guangxi Natural Science Foundation Project(2025GXNSFAA069462)

© 中国图象图形学报版权所有

tional multi-planar imaging capabilities, T2-weighted Magnetic Resonance Imaging (MRI) has universally emerged as the gold standard modality for determining these delicate anatomical boundaries. However, achieving automated, high-precision prostate MRI segmentation is fraught with formidable clinical andtechnical difficulties. Anatomically, the prostate features highly complex structures; its apex is notoriously difficult to distinguish from the urethral sphincter, and its base shares severe gray-level similarities with the bladder neck, resulting in profoundly blurred and ambiguous boundaries. Furthermore, clinical data acquisitions inherently span multiple medical centers, involving distinct scanner vendors and magnetic field strengths (e. g. , 1. 5T versus 3T). This multi-source nature introduces significant domain shifts and spatial heterogeneity in image resolution, signal-to-noise ratio, and texture features. Historically, early traditional segmentation algorithms, such as multi-atlas registration and active contour models, severely struggled with these variations, typically achieving a Dice Similarity Coefficient (DSC) of only around 0. 78 and demonstrating extreme vulnerability to volume variations and rectal gas artifacts. While Convolutional Neural Networks (CNNs) established early deep learning benchmarks, their restricted local receptive fields struggle to model long-range global semantic dependencies, often leading to anatomically implausible fragmentations. Recently, hybrid architectures like TransUNet have integrated CNNs with Transformers to capture these essential global contexts. Nevertheless, standard Transformers exhibit severe computational redundancy in medical imaging. Empirical studies reveal that approximately 30% of standard static attention heads persistently focus on background noise rather than clinically challenging regions, thereby wasting computational resources and diluting effective feature representations, severely limiting their performance when processing multi-center heterogeneous data. **Methods** To systematically overcome the core bottlenecks of Transformer attention redundancy and the inherent lack of dynamic adaptability in static networks, this study proposes a novel reinforcement learning (RL) optimized framework, termed RL-TransUNet. The proposed architecture innovatively embeds the classic REINFORCE (REward Increment by Negative-gradient, Combined with Objective Function through REinforcement) policy gradient algorithm directly into the 12-layer Transformer encoder of the TransUNet framework. Unlike conventional paradigms that utilize static, equally weighted attention heads, our methodology formulates the allocation of multi-head attention weights as a dynamic, task-driven sequence decision-making process. By employing a lightweight, two-layer fully connected policy network, the RL agent evaluates the embedded image features and outputs a probability distribution for 12 attention head weights via Softmax normalization. The agent can adaptively prune redundant attention channels, enabling precise feature focusing. To strictly align the RL optimization with clinical segmentation imperatives, we design a sophisticated composite reward function that integrates a Hybrid Dice Coefficient Reward (weighted at 0. 6 to enforce regional overlap) and a Boundary Intersection over Union (IoU) Reward (weighted at 0. 4 to specifically enhance anatomical contour precision). The optimization process utilizes a moving average baseline to reduce variance, enabling the agent to calculate policy gradients and update the network without requiring a separate, parameter-heavy value network. Furthermore, the total loss function intelligently balances a segmentation loss (Cross-Entropy and Dice loss) with the policy gradient loss. Recognizing the severe performance degradation caused by domain shifts, this research also constructs a rigorous, four-stage customized preprocessing pipeline tailored for multi-center data. This pipeline meticulously executes spatial normalization via bicubic interpolation to standardize voxel dimensions to 1. 0mm×1. 0mm×3. 0mm, eliminating physical scale heterogeneity. Subsequently, intensity normalization employs a robust 99. 5% percentile truncation combined with Z-score standardization to smooth signal fluctuations. A strict double-criterion purification stage filters out degraded samples with a signal-to-noise ratio (SNR) below 20 or an annotation missing rate exceeding 5%. Finally, task-oriented data augmentations—including random rotations, scaling, and Gaussian noise perturbations—are exclusively applied to the training set to prevent overfitting under small-sample constraints. **Results** Comprehensive and systematic validations were conducted on two highly representative public datasets to rigorously evaluate the proposed model′s robustness and generalization upper bounds. On the multi-center, highly heterogeneous PROMISE12 dataset, the RL-TransUNet demonstrated exceptional anti-interference capabilities, achieving an outstanding DSC of 0. 940 and dramatically reducing the 95th percentile Hausdorff Distance (HD95) to an unprecedented 3. 00 mm. The model reached a sensitivity of 0. 937 and an Average Surface Distance (ASD) of 0. 85 mm, significantly outperforming traditional CNNs like U-Net (DSC 0. 817, HD95 8. 09 mm) and Attention U-Net (DSC 0. 828, HD95 14. 24 mm), as well as the baseline TransUNet (DSC 0. 882, HD95 8. 04 mm). Even when compared to the recent state-

© 中国图象图形学报版权所有

of-the-art GLCSA-UNet, which relies on complex global-local attention stacking (DSC 0.877, HD95 3.02 mm), our RL-TransUNet achieved superior accuracy with a lightweight policy. To further evaluate the model's performance on large-scale standardized data, experiments were extended to the Prostate158 dataset, comprising 158 high-quality 3T MRI scans. Here, the RL-TransUNet further pushed the performance envelope, realizing a DSC of 0.950, an HD95 of 5.52 mm, and an extraordinary sensitivity of 0.971, outperforming GLCSA-UNet (DSC 0.884, HD95 5.08 mm). Extensive ablation studies corroborated the contributions of each proposed module: implementing the customized preprocessing alone reduced the HD95 error by 42.29% on PROMISE12, while the standalone application of RL-driven attention optimization boosted the DSC by 3.40%. The synergistic combination of both strategies yielded a massive 62.69% reduction in HD95 compared to the baseline TransUNet. Qualitative visualizations and quantitative attention distribution analyses explicitly confirmed the efficacy of the REINFORCE algorithm. The RL agent significantly amplified the normalized weights of informative attention heads (e.g., heads 3, 7, and 11) while actively suppressing noise-oriented channels (e.g., heads 2, 5, and 9), seamlessly overcoming severe rectal coil artifacts and complex anatomical adhesions that heavily disrupted competing models. **Conclusion** In conclusion, the proposed RL-TransUNet effectively resolves the core clinical challenges of multi-center data heterogeneity, Transformer attention resource redundancy, and inadequate boundary segmentation accuracy in prostate MRI processing. By synergistically integrating a customized preprocessing pipeline with a dynamic, policy gradient-driven attention pruning mechanism, the model successfully aligns reinforcement learning objectives with critical clinical demands, providing accurate regional overlap and precise boundary adherence. Despite its outstanding performance, the current framework primarily relies on 2D feature processing, which may not fully exploit complete 3D spatial correlations, and its reliance on fully supervised pixel-level annotations remains a limitation for data-scarce scenarios. Future optimizations will focus on upgrading to 3D architectures (3D CNN and 3D Transformer modules) to enhance spatial context modeling, developing adaptive artifact correction modules for extreme clinical conditions, and exploring semi-supervised or weakly supervised learning paradigms to reduce annotation costs. Ultimately, the RL-TransUNet architecture provides an accurate, highly efficient, and morphologically robust computational framework for computer-aided diagnosis, precise treatment planning, and automated radiotherapy target delineation in clinical oncology.

Key words: Medical Image Segmentation; Prostate Segmentation; Reinforcement Learning; Policy Gradient; Attention Optimization; Multi-center Heterogeneity

论文引用格式：Zou S Z, Wen C Q, Wang J and Qiu H. 2026. Prostate MRI Segmentation via TransU-Net with Policy Gradient-Driven Dynamic Attention Journal of Image and Graphics, 31(1): 320-334(邹水中，文传清，王剑，邱豪. 2026. 策略梯度驱动的动态注意力TransUNet前列腺MRI分割. 中国图象图形学报，[DOI:10.11834/jig.260].

0 引 言

前列腺癌(Prostate Cancer，PCa)是当前全球公共卫生体系面临的重大挑战之一。根据Siegel R L等人(2024)在《CA：A Cancer Journal for Clinicians》发布的最新统计数据，其发病率在男性恶性肿瘤中稳居首位，且死亡率呈现逐年上升趋势。在临床诊疗流程中，放射治疗(Radiotherapy)是局限性及局部晚期前列腺癌的一线根治性手段。放疗的疗效与毒副作用(如放射性直肠炎、膀胱损伤)之间存在着微妙的平衡，这种平衡高度依赖于对前列腺靶区(Clinical Target Volume，CTV)及危及器官(Organs at Risk，OARs)的精准勾画。T2加权磁共振成像(MRI)凭借其优越的软组织对比度和多平面成像能力，已成为前列腺边界界定的金标准影像模态。然而，实现精准的自动化前列腺MRI分割面临着极为严峻的挑战：一方面，前列腺解剖结构复杂，其尖部与尿道括约肌、基底部与膀胱颈的灰度特征极为相似，边界模糊不清；另一方面，临床数据采集往往跨越不同医疗中心，涉及不同厂商的扫描设备及磁场强度，导致图像在分辨率、信噪比及纹理特征上存在显著的分布异质性。

在前列腺MRI分割技术的发展历程中，早期的探索主要集中在基于先验知识的传统图像处理方法上。Litjens G等人(2014)在著名的PROMISE12挑战赛中，对包括多图谱配准、活动轮廓模型及水平集

© 中国图象图形学报版权所有

在内的多种传统算法进行了系统性评估。研究发现，尽管图谱匹配法通过引入解剖学先验在一定程度上约束了分割形状，但其Dice相似系数（DSC）平均仅能达到0.78左右，且极易受到前列腺体积变异及直肠气体伪影的干扰。为了量化这种边界误差，Huttenlocher D P等人（1993）定义的豪斯多夫距离（Hausdorff Distance，HD95）被广泛应用。在传统方法（如Graph-Cut）中，由于缺乏对图像深层语义的理解，低对比度区域的HD95往往超过6 mm，难以满足现代精准放疗对亚毫米级精度的需求。此外，传统方法通常依赖手工设计的特征，缺乏针对多源数据的自适应能力。正如Liu Q等人（2023）指出的，多中心数据的域偏移（Domain Shift）是限制模型临床泛化能力的核心瓶颈，通用预处理方法的缺失使得传统模型难以在未知域上保持鲁棒性。

深度学习技术的爆发式发展，特别是卷积神经网络（CNN）的引入，标志着医学图像分割进入了第二阶段。Ronneberger O等人（2015）提出的U-Net架构，以其精妙的对称编码器-解码器结构和跳跃连接设计，确立了该领域的基准地位。为了挖掘3D容积数据的空间相关性，V-Net（Milletari F等人，2016）将卷积扩展至三维空间，并引入Dice Loss以应对前景背景的极度不平衡问题——这一理论在Sudre C H等人（2017）的研究中被进一步阐述，成为解决小目标分割难题的基础。随着网络深度的增加，ResNet（He K M等人，2016）的残差学习思想被整合进分割网络，以提取更具判别力的特征。随后，为了解决CNN对解剖结构关注度不足的问题，Attention U-Net（Oktay O等人，2018）创新性地引入了注意力门控机制，通过抑制背景区域的特征响应来增强聚焦。近年来，Isensee F等人（2021）提出的nnU-Net框架，通过对数据指纹的自动分析，实现了网络拓扑及预处理的自适应配置，刷新了多项SOTA记录。然而，尽管CNN类方法表现优异，但其固有的局部感受野限制，使其在建模长距离全局语义依赖时存在先天不足，常导致分割结果出现不符合解剖学常识的孔洞。

为了突破局部感受野的限制，第三阶段的研究转向了Transformer架构。受ViT（Dosovitskiy A等人，2020）和Swin Transformer（Liu Z等人，2021）的启发，Chen J等人（2021）提出的TransUNet是这一领域的开山之作，它利用Transformer编码全局上下文，通过CNN恢复细节，首次证明了混合架构的优越性。随后，纯Transformer架构如Swin-Unet（Cao H等人，2022）、3D架构UNETR（Hatamizadeh A等人，2022）以及门控轴向注意力的Medical Transformer（Valanarasu J M等人，2021）相继提出。在多模态融合领域，TransBTS（Wang W H等人，2021）展示了Transformer的融合潜力。在此基础上，国内学者针对医学图像的复杂特征也进行了深入探索：刘威等人（2025）通过创新特征融合策略，实现了聚焦全局与中间层的细节增强分割；而彭晏飞和孙伟强（2026）则提出了双路径编码与自适应感受野驱动的分割框架，有效突破了局部感受野与全局特征融合的瓶颈。

尽管Transformer架构带来了性能飞跃，但其高昂的计算成本和潜在的冗余性逐渐成为新的痛点。近期相关研究与综述指出，标准Transformer在处理医学图像时存在显著的“计算冗余”——研究表明，约30%的注意力头长期聚焦于背景噪声，而并未有效关注前列腺尖部等困难区域。为了解决这一问题，近期出现了DA-TransUNet（Tran T T等人，2024）改进模型，试图通过堆叠多重注意力或多尺度门控来提升特征表达。然而，这种策略往往是一把双刃剑：在提升精度的同时，不可避免地增加了参数量和推理延迟，且其注意力分配策略在测试阶段通常是静态固定的。此外，随着大模型时代的到来，SAM（Segment Anything Model，Kirillov A等人，2023）展现了惊人的泛化能力，但Ma J等人（2024）的研究表明，SAM在处理医学图像特别是前列腺这种软组织边界模糊的任务时，未经微调的推理精度仍难以满足临床要求，且其庞大的资源消耗限制了临床部署。

针对上述“Transformer注意力冗余”及“静态网络缺乏动态适应性”的核心矛盾，强化学习（RL）提供了一种全新的解决思路。RL通过智能体与环境的交互，能够学习到最大化累积奖励的最优策略。目前，RL在分割领域的应用主要可归纳为三类：一是弱监督分割，利用RL减少对像素级全标注的依赖；二是超参数优化，利用RL动态搜索网络的最优学习率或增强策略；三是注意力机制的动态优化。值得注意的是，虽然基于REINFORCE（Williams R J，1992）的策略梯度算法为序列决策提供了坚实的理论基础，但现有的RL-Attention工作多局限于分类任务，鲜有研究将其无缝嵌入到像素级分割网络的端到端训练中。我们认为，理想的分割网络应当具备像人类医生一样的“动态注意力”——在处理简单

© 中国图象图形学报版权所有

切片时“放松”关注以节省资源，而在面对异质性数据时“主动”集中注意力。

综上，现有研究在前列腺MRI分割领域取得显著进展，但仍存在三大核心空白：一是预处理与模块优化脱节，缺乏针对PROMISE12（Litjens G等人，2014）多中心异质性的定制化预处理方案，而针对Prostate158（Adams L C等人，2022）等新兴大规模标准化数据的性能上限挖掘亦显不足，制约了模型的临床泛化潜力；二是Transformer注意力头静态化，多数方法采用均等权重或简单静态调整，未实现任务驱动的动态分配，冗余头浪费计算资源且稀释有效特征；三是RL与分割任务目标对齐不足，现有RL应用多聚焦弱监督或超参数优化，未与注意力机制深度融合，奖励函数未直接对齐临床关键指标。

基于此，本文提出一种融合定制化预处理与RL优化的RL-TransUNet模型。针对前文所述的多中心数据异质性挑战，我们引入了具有高异质性的PROMISE12和大规模标准化的Prostate158双数据集进行互补验证。在方法论层面，利用经典的REINFORCE策略梯度算法构建轻量级策略网络，将注意力权重的分配建模为序列决策过程，实现任务驱动的动态“剪枝”。为了引导RL智能体关注临床核心指标，设计了包含Dice系数奖励和基于豪斯多夫距离（HD95）定义的边界奖励的复合奖励函数，直接优化分割的区域重叠度与轮廓精细度。实验结果表明，该方法在不显著增加参数量的前提下，有效提升了模型在复杂边界下的分割精度与鲁棒性。这一“数据提质-动态注意力-任务对齐”的协同优化范式，为前列腺癌的临床精准辅助诊疗提供了一种极具潜力的智能化解决方案。

1 方法设计

本文提出一种融合强化学习与Transformer注意力优化的前列腺MRI分割模型—RL-TransUNet。该模型以TransUNet为基础框架，通过策略梯度（REINFORCE）算法动态优化多头注意力权重，实现任务驱动的特征聚焦分配，其整体架构如图1所示，核心模块包含以下四部分：

1）多中心MRI数据的定制化预处理，经定制化预处理后的多中心前列腺MRI图像，作为图中初始输入图像，送入后续的特征处理链路。

2）融合CNN与Transformer的混合特征编码。如图1（b），输入的MRI图像先进入CNN编码层提取初始特征，经Linear Projection处理后传入Transformer encoder层进行序列特征建模；过程中配合下采样、上采样操作及特征拼接策略，搭建起CNN与Transformer结合的混合编码链路，实现多尺度特征的传递与融合。

3）基于RL的注意力权重优化机制，如图1（a）所示，嵌入序列经层归一化后送入“MSA+RL”模块，该模块将多头自注意力（MSA）与强化学习（RL）结合，借助策略梯度算法动态优化注意力权重；之后通过残差连接与层归一化，接入多层感知机（MLP）完成特征转换，最终输出优化后的特征表示Z。

4）结合Dice与边界IoU的复合奖励函数设计，由图中1（c）强化学习链路可知，分割结果与金标准对比后，以Dice系数、边界IoU为核心构建复合奖励函数完成奖励计算，再通过REINFORCE算法实现注意力权重的策略更新，以此提升分割任务的精准性。

1.1 定制化预处理流程

针对PROMISE12数据集多中心采集导致的空间尺度不一致、信号强度波动等异质性问题，以及Prostate158数据训练的标准化需求，本文设计了如图2所示的“标准化-净化-增强”四阶段定制化预处理流程。该流程各阶段的核心作用及具体实施如下：应注意力剪枝优化模块的性能得以充分发挥。

首先，空间归一化采用双三次插值法将所有MRI图像精准重采样至统一的体素尺寸（1.0 mm × 1.0 mm × 3.0 mm），并结合刚性配准将前列腺解剖位置对齐至标准模板。这一步骤彻底消除了多中心设备在空间分辨率及患者体位上的物理异质性，确保了模型输入空间尺度的高度一致性；

其次，强度归一化引入了“百分位截断结合Z-score标准化”的组合策略。通过截断99.5%以上的极端异常像素来剔除高频噪声，并抹平因不同厂商设备及磁场强度（如1.5T与3T）差异导致的信号波动，从而实现多源图像灰度分布的严格对齐；

第三，样本筛选与清洗（净化）确立了严格的双重质控标准。通过计算图像信噪比（剔除SNR<20的样本）以排除严重的运动伪影，同时对比参考标注（剔除缺失率>5%的样本）以过滤边界残缺的劣质数据。这种数据清洗机制守住了数据质量下限，最大

© 中国图象图形学报版权所有

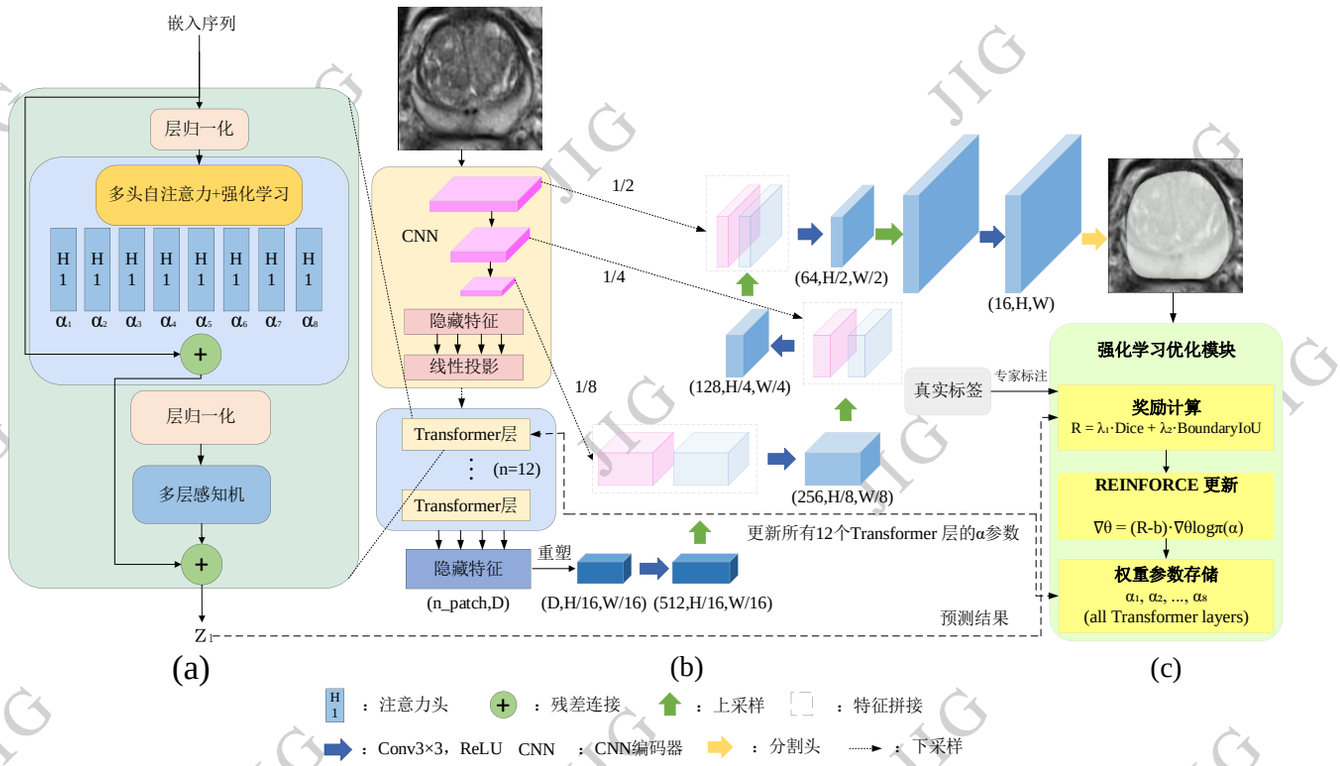


图1　RL-TransUNet模型结构

Fig. 1　Architecture of the proposed RL-TransUNet model

程度保障了训练集的可靠性与纯净度；

最后，任务导向数据增强针对训练集专属实施，综合利用随机翻转、旋转（±15°）、尺度缩放（0.8-1.2倍）及高斯噪声扰动等多元化策略。在物理形态与噪声维度上充分扩增了样本的多样性，有效缓解了在小样本（特别是PROMISE12数据集）条件下训练引发的模型过拟合风险。

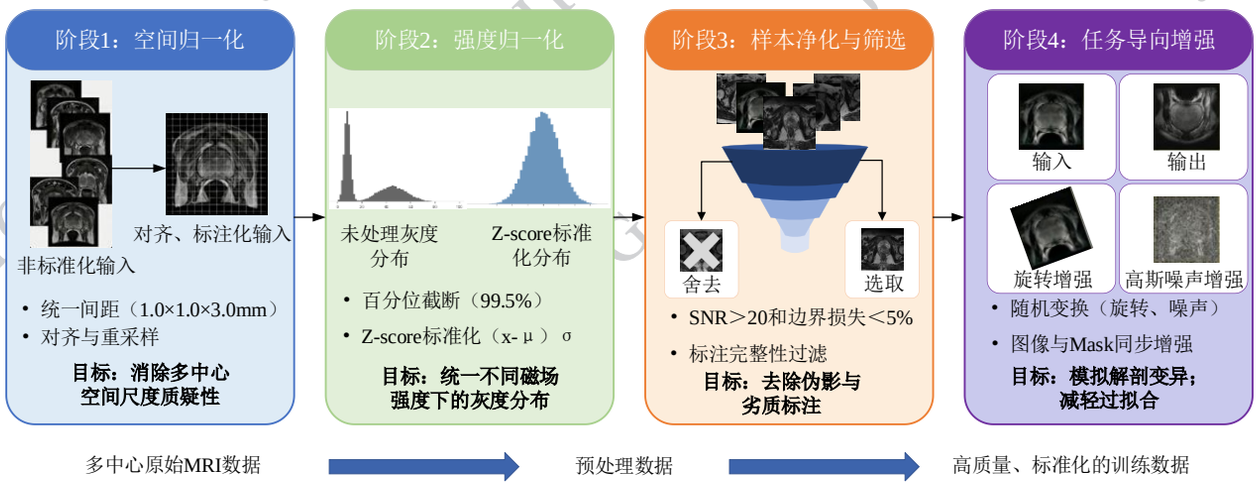


图2　定制化预处理四阶段流程图

Fig. 2　Four-stage customized preprocessing pipeline

1.1.1　空间归一化

采用线性插值法（双三次插值）将数据集所有T2加权MRI图像重采样至统一体素尺寸（1.0mm×1.0mm×3.0mm），该尺寸依据数据集多中心体素范围（0.4-1.0mm）选取，平衡分辨率与计算效率；同时以数据集内标准解剖模板为基准，通过刚性配准统

© 中国图象图形学报版权所有

一前列腺解剖位置，消除个体体位差异。此步骤可解决多中心数据空间异质性，确保模型输入空间尺度一致。

1.1.2　强度归一化

采用“百分位截断+Z-score标准化”组合策略：先对图像像素强度进行99.5%百分位截断，剔除极端噪声像素；再计算剩余像素的均值μ与标准差σ，按公式(1)进行标准化，消除设备场强(1.5T/3T)差异导致的信号强度波动，统一图像灰度分布。

$$I_{\text{norm}} = \frac{I - \mu}{\sigma} \tag{1}$$

式中，I为原始像素值，I_{norm}为归一化像素值。

1.1.3　样本的筛选和清洗

在多中心、大规模的临床数据采集中，MRI图像常因患者不自主运动、直肠气体干扰等物理因素产生严重的运动伪影；同时，部分样本的专家手工标注在解剖结构复杂的边界区域可能存在客观上的残缺或主观偏差。为了防止这些低质量的“脏数据”对网络参数更新以及强化学习策略梯度的收敛造成严重误导，本阶段从图像的物理成像质量与标签的语义完整性两个维度出发，制定了严格的双重且量化的筛选标准：

1)信号质量筛选：计算图像信噪比(SNR，前列腺区域均值与背景噪声标准差的比值)，剔除SNR<20的运动伪影样本；

2)标注完整性筛选：与数据集官方参考标注对比，剔除前列腺边界标注缺失率>5%的样本。

1.1.4　任务导向数据增强

仅在训练集实施数据增强，策略包括：随机水平翻转(概率0.5)、随机旋转(±15°)、随机缩放(0.8-1.2倍)及高斯噪声扰动。所有操作同步作用于图像与掩膜，以缓解小样本过拟合问题。

1.2　混合特征编码与跳连解码模块设计

图3为混合特征编码与跳连解码模块的结构示意图，清晰呈现了“输入-编码-特征融合-解码”的全链路工作机制：

1)混合特征编码，模块接收经定制化预处理后的前列腺MRI图像，先通过混合特征编码器完成特征提取——经CNN编码层初步提取局部特征后，通过Linear Projection转换为序列特征，再传入由12个Transformer块组成的编码器随后通过3组跳跃连接将编码器输出的多尺度特征$\{F_i\}$传递至解码器对应层级；

2)解码器与跳连融器，解码器采用经典U-Net结构，经上采样、特征拼接与卷积融合逐步恢复特征图分辨率，最终输出像素级分割结果，实现了CNN局部特征与Transformer全局语义的协同融合，为精细化分割提供了多尺度特征支撑。

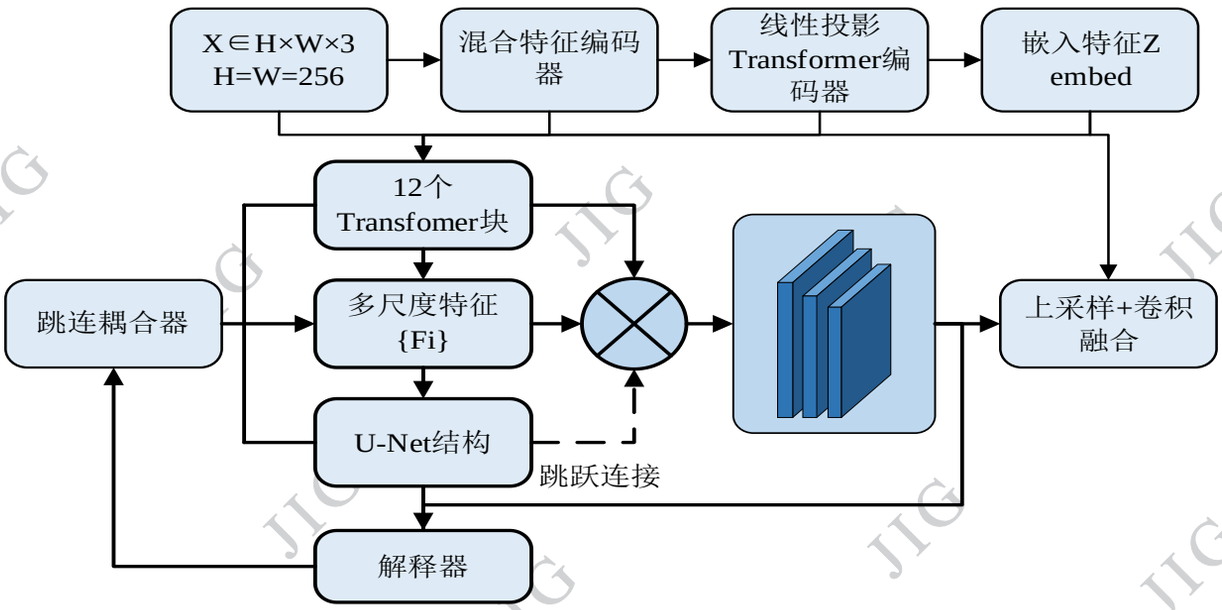


图3　混合特征编码与跳连解码模块的结构示意图

Fig. 3　Schematic Diagram of Hybrid Feature Encoding and Skip Connection Decoding Module

© 中国图象图形学报版权所有

1.2.1 混合特征编码器

给定输入前列腺图像$X\in^{H\times W\times 3}$，H=W=256分别表示图像的高度和宽度，网络首先通过混合编码器提取特征表示：

$$Z_{embed}=E(X)\in R^{N\times D} \tag{2}$$

式中，$\boldsymbol{Z}_{embed}$为Transformer输入的初始特征序列矩阵，N=256为图像块数量，D=768为隐藏层维度。

编码器由L=12个Transformer块组成，每个Transformer块包含多头自注意力机制（Multi-Head Self-Attention，MHSA）和前馈神经网络（Feed-Forward Network，FFN）。第l个Transformer块的计算过程可表示为：

$$Z_1'=LayerNorm(Z_{l-1}) \tag{3}$$

$$A_l,W_l^{head}=MHSA(Z_1') \tag{4}$$

$$Z_l''=Z_{l-1}+Dropout(A_l) \tag{5}$$

$$Z_1=Z_l''+FFN(LayerNorm(Z_l'')) \tag{6}$$

式中，$\boldsymbol{Z}_l'$为经过层归一化处理后的中间特征矩阵，$\boldsymbol{Z}_{l-1}$为第l-1层输出的特征矩阵，$\boldsymbol{A}_l$为多头自注意力机制计算得到的注意力输出矩阵，$W_l^{head}\in\mathrm{R}^{\mathrm{H}}$为第$l$层的注意力头权重，$\boldsymbol{Z}_l''$为经过残差连接与Dropout处理后的融合特征矩阵，$\boldsymbol{Z}_l$为第l层Transformer块最终生成的输出特征矩阵。

1.2.2 解码器与跳连融器

解码器采用经典的U-Net结构，通过跳跃连接（Skip Connections）融合编码器不同尺度的特征信息。设来自编码器的跳跃连接特征为$\{F_i\}$，S=3，则解码器的输出为：

$$Y=Decoder(Z_l,\{F_i\}_{i=1}^{S}) \tag{7}$$

该设计保证高层语义信息与低层空间细节的协同恢复，实现精细化分割。

1.3 强化学习的注意力权重优化机制

前列腺MRI分割面临边界模糊、组织异质性等挑战，标准多头自注意力机制对注意力头平等加权，难以适配复杂特征分布。强化学习的动态优化优势为注意力权重自适应分配提供有效途径，本文构建“参数化建模-策略化优化”双阶段框架：引入可学习参数实现差异化加权，基于REINFORCE算法设计策略梯度优化流程，控参开销并提升模型稳定性。

1.3.1 注意力权重参数化

在标准的自注意力机制中，每个注意力头的输出被平等对待。本文引入可学习的注意力头权重参数$\alpha_i\in\mathrm{R}^{\mathrm{H}}$，通过softmax归一化：

$$\tilde{\alpha}=\frac{\exp(\alpha_i)}{\sum_{j=1}^{H}\exp(\alpha_j)} \tag{8}$$

式中，α_i为第i个注意力头的归一化权重标量，α_j为策略网络输出的原始权重分值。

加权后的多头注意力输出为：

$$HeadOutput=\sum_{i=1}^{H}\tilde{\alpha}h_i \tag{9}$$

式中，h_i为第i个注意力头的输出。

1.3.2 策略梯度优化

策略梯度优化的核心是将注意力头权重动态分配建模为强化学习策略优化问题，基于REINFORCE算法实现“特征输入-权重生成-奖励反馈-梯度更新”闭环优化：定制化预处理后的前列腺MRI图像经混合特征编码器获取嵌入特征，输入2层全连接（含ReLU激活）的轻量化策略网络生成12个注意力头原始权重α，经Softmax归一化形成动作概率分布$\pi(\alpha)$，完整流程如图4所示。

将注意力头权重的学习建模为策略优化问题。策略$\pi(\alpha)$定义为当前注意力头权重的概率分布：

$$\pi(\alpha)=\prod_{l=1}^{L}\prod_{i=1}^{H}p(\alpha_{l,i}) \tag{10}$$

式中：

$$p(\alpha_{l,j})=\frac{\exp(\alpha_{l,j})}{\sum_{j-1}^{H}\exp(\alpha_{l,j})} \tag{11}$$

式中，$\boldsymbol{\alpha}$表示网络中所有层注意力头权重的集合或矩阵，$\alpha_{i,j}$策略网络输出的关于特定注意力头的原始逻辑分值（Logits）标量。

采用REINFORCE算法更新梯度算子参数：

$$\nabla_\theta J(\theta)=\mathbb{E}_{\pi_\theta(\alpha)}[(R-b)\nabla_\theta\log\pi_\theta(\alpha)] \tag{12}$$

式中，R为即时奖励，b为基线值，通过移动平均平滑更新基线值标量：

$$b_{t+1}=\beta b_t+(1-\beta)R_t \tag{13}$$

式中，β=0.9，b_t为基线值标量及第t次迭代的基线值标量，R_t为第t次迭代的即时奖励标量

该方法无需引入价值网络，稳定性高且参数开销极低（仅96个新参数）。

1.4 奖励函数设计

为协同优化分割结果的区域一致性与边界精度，本文设计复合奖励函数，其核心为混合Dice系数奖励与边界IoU奖励的加权求和，公式如下：

$$R=\lambda_1 Dice(Y,Y_{gt})+\lambda_2 BoundaryIou(Y,Y_{gt}) \tag{14}$$

© 中国图象图形学报版权所有

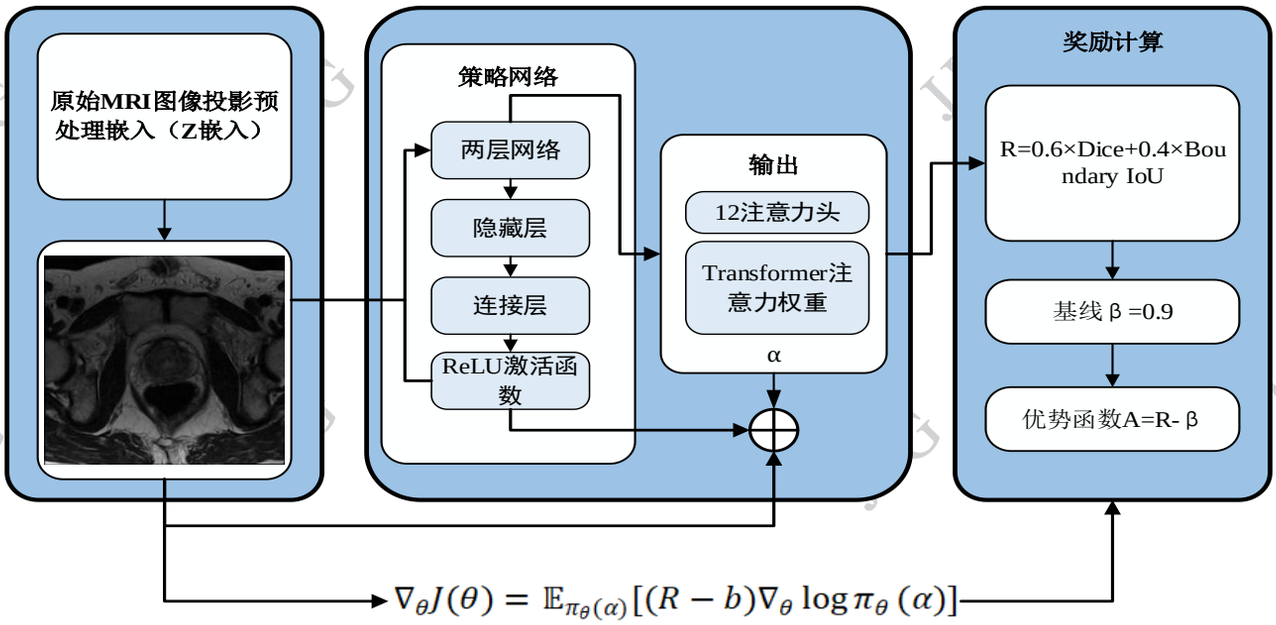


图4　策略梯度驱动的注意力权重动态优化机制示意图

Fig. 4　Diagram of Dynamic Optimization Mechanism for Attention Weights Driven by Policy Gradient

式中，λ_1=0.6对应混合Dice系数奖励的权重，用于强化预测区域与真值的重叠度优化；λ_2=0.4对应边界IoU奖励的权重，专注提升前列腺边界分割精度。

1.4.1　混合Dice系数奖励

Dice系数衡量预测区域与真值区域的重叠程度：

$$Dice(Y_{pred},Y_{gt}) = \frac{2\sum(Y_{pred}\quad Y_{gt}) + \varepsilon}{\sum Y_{pred} + \sum Y_{gt} + \varepsilon} \tag{15}$$

式中，ε=10^{-6}为平滑项，$\boldsymbol{Y}_{pred}$为网络模型输出的预测分割掩膜矩阵，$\boldsymbol{Y}_{gt}$为专家标注的真实分割掩膜矩阵。

1.4.2　边界IoU奖励

利用形态学梯度提取预测与真值边界：

$$E_{pred} = Conv2D(Y_{pred,}K_{3\times3}) - Y_{pred} \tag{16}$$

$$E_{gt} = Conv2D(Y_{gt},K_{3\times3}) - Y_{gt} \tag{17}$$

式中，$\boldsymbol{K}_{3\ \ 3}$为全1的3×3卷积核。

1.5　总损失函数与训练策略

为兼顾前列腺MRI分割的基础精度与强化学习驱动的注意力优化效果，本文设计由分割损失(L_{seg})与强化学习损失(L_{RL})构成的总损失函数，通过加权融合实现双目标协同优化，具体形式如下：

$$L_{seg} = L_{CE} + L_{Dice} \tag{18}$$

$$L_{total} = L_{seg} + \gamma L_{RL} \tag{19}$$

式中各项定义如下：

L_{seg}为分割基础损失，由交叉熵损失(L_{CE})与Dice损失(L_{Dice})线性叠加而成，L_{total}为网络训练的总损失，γ为平衡权重标量，聚焦像素级分类精度，公式为：L_{CE} = $-\frac{1}{H\times W}\sum_{i=1}^{H\times W}[Y_i\log(\hat{Y}_i) + (1-Y_i)\log(1-\hat{Y}_i)]$

(20)

式中，$\boldsymbol{H}$　$\boldsymbol{W}$为图像像素总数，Y_i为第i个像素的真值标签(1表示前列腺区域，0表示背景)，$\hat{Y}_i$为对应预测概率。

L_{Dice}用于缓解类别不平衡，强化区域重叠度，公式为：

$$L_{Dice} = 1 - \frac{2\sum_{i=1}^{H\times W}Y_i\hat{Y}_i + \varepsilon}{\sum_{i=1}^{H\times W}Y_i^2 + \sum_{i=1}^{H\times W}\hat{Y}_i^2 + \varepsilon} \tag{21}$$

L_{RL}为策略梯度损失，基于REINFORCE算法推导，公式为：

$$L_{RL} = -E_{\pi_\theta(\alpha)}[\log\pi_\theta(\alpha)\cdot(R-b)] \tag{22}$$

式中，$E_{\pi\theta(\alpha)}$为策略分布下的数学期望，$log_{\pi\theta(\alpha)}$为注意力头权重的概率对数，用于将注意力权重分配的优劣反馈为优化信号，γ=0.2为L_{RL}的平衡权重，经多组预实验确定，用于协调分割基础训练与RL注意力优化的比重，避免单一损失占比过高影响整体性能。

训练过程中，采用联合优化策略：同步计算L_{seg}与L_{RL}并反向传播，L_{seg}更新分割网络的特征提取与解码参数，L_{RL}调整策略网络的权重生成参数，同时对

© 中国图象图形学报版权所有

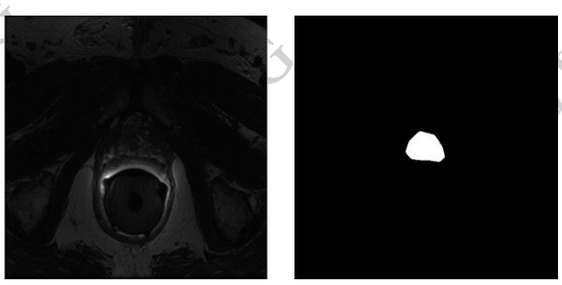
L_{RL}实施梯度裁剪(阈值设为1.0),确保训练稳定性。

2 实 验

2.1 数据集及预处理

2.1.1 PROMISE12数据集(异质性验证)

实验数据集采用国际医学图像计算和计算机辅助干预协会(Medical Image Computing and Computer Assisted Intervention Society,MICCAI)于2012年举办的前列腺MR图像分割挑战赛(Litjens 等,2014)上所提出的PROMISE12数据集,共包含100份前列腺MR数据。这些数据随机分为训练集(50份)、测试集(30份)和在线验证集(20份),以确保样本在各个集合中均匀分布,如图5所示。主要用于验证模型在多中心异质数据下的抗干扰能力。



(a) 前列腺MRI (b) 专家标注掩膜

((a)Prostate MRI;(b) Expert-Annotated Mask)

图5 前列腺MRI与专家标注掩膜

Fig. 5 Prostate MRI and Expert-Annotated Mask

2.1.2 Prostate158数据集(泛化性验证)

引入Prostate158数据集,包含158例由Siemens 3T扫描仪采集的高质量T2w图像。相比PROMISE12,该数据集样本量大、信噪比高、解剖结构清晰,用于评估模型在大规模标准化临床数据上的性能上限。

2.1.3 预处理执行

为消除数据异质性对模型训练的干扰,设计标准化预处理流程:首先,将所有图像通过双三次插值重采样至统一的体素尺寸(1.0 mm×1.0 mm×3.0 mm);其次,采用"百分位截断+Z-score标准化"进行强度归一化;最后,基于双重筛选标准净化数据:信号质量筛选中,选取前列腺区域均值与背景噪声标准差(背景区域选取远离前列腺的非组织区域)的比值作为信噪比(SNR),剔除SNR<20的低质量样本;标注完整性筛选中,与数据集官方参考标注对比,剔除前列腺边界标注缺失率>5%的样本,确保训练数据的可靠性。

2.2 实验设置

实现细节:所有实验均在PyTorch框架下进行,使用一台配备NVIDIA RTX 5060TI GPU的工作站。模型采用AdamW优化器,初始学习率设置为1e-4,并应用余弦退火调度策略。批量大小设为8,训练轮次为200。

评估指标:为全面评估模型性能,采用以下四个临床核心指标:

1)Dice相似系数(Dice):衡量预测区域与真值的重叠程度,是医学分割的核心评估指标,取值范围[0,1],越接近1表示分割效果越好;

2)95%豪斯多夫距离(HD95):反映分割边界与真值边界的最大距离分布,仅考虑95%分位数以排除极端异常值,单位为mm,数值越小表示边界精度越高;

3)灵敏度(Sensitivity):衡量模型对前列腺区域的识别能力,即真值中的前列腺区域被成功分割的比例,避免漏分割导致放疗靶区遗漏;

4)平均表面距离(ASD):计算分割表面与真值表面的平均欧氏距离,直观反映轮廓贴合度,数值越小表示分割轮廓越接近解剖真实形态。所有结果均采用5折交叉验证,报告均值与标准差,并通过配对t检验验证结果的统计显著性。

2.3 对比实验

为公正评估RL-TransUNet的综合性能,本文选取当前前列腺MRI分割领域的主流模型作为对比基准。

2.3.1 异质数据上的抗干扰能力(PROMISE12)

表1展示了各模型在PROMISE12数据集上的定量性能对比。评估涵盖了U-Net(2015)、Attention U-Net(2018)、ResU-Net(2018)等经典CNN模型,以及TransUNet(2021)和最新的GLCSA-UNet(2024)等Transformer或混合架构模型。从结果可见,RL-TransUNet在所有指标上均实现最优表现:Dice系数达0.940,较基线TransUNet(0.882)提升5.8%,且经配对t检验验证具有统计显著性。即便与2024年提出的GLCSA-UNet(Dice 0.877,HD95 3.02 mm)相比,本文方法在保持轻量级的同时,Dice提升了6.3%,HD95进一步降低至3.00 mm。这表明,面对

© 中国图象图形学报版权所有

多中心数据的异质性，单纯堆叠复杂的注意力模块往往不如基于RL的动态策略有效——后者能通过抑制冗余特征，在不增加参数负担的前提下，精准捕捉前列腺的模糊边界。Sensitivity达0.937，亦高于所有对比模型，确保了放疗靶区无遗漏。

2.3.2　大规模数据上的泛化潜力（Prostate158）

表2进一步展示了各模型在Prostate158数据集上的泛化性能。得益于该数据集更大的样本量和更高的信噪比，RL-TransUNet的性能潜力得到充分释放，Dice系数高达0.950。对比分析显示：

1）性能上限突破：虽然TransUNet（2021）在大数据量下表现稳定（Dice 0.880），但RL-TransUNet将Dice进一步推高了7.0%，证明了“动态注意力剪枝”在大规模数据训练中能有效减少过拟合，挖掘深层语义，且该增益在不同验证集上均保持一致，显著改善了目标边界的连续性。

2）优于最新方法：最新的GLCSA-UNet（2024）虽引入了全局-局部注意力机制，在Prostate158上取得了0.884的Dice和5.08 mm的HD95，但本文方法在Dice指标上具有优势。

表1　在PROMISE12数据集上的定量结果对比

Table 1　Quantitative comparison of results on the PROMISE12 dataset

模型	Dice	HD95	Sensitivity	ASD
U-Net	0.817	8.09	0.919	3.20
Attention U-Net	0.828	14.24	0.903	0.91
TransUNet	0.882	8.04	0.922	1.52
ResU-Net	0.862	20.78	0.873	0.64
GLCSA-UNet	0.877	3.02	0.859	1.17
RL-TransUNet(Ours)	0.940	3.00	0.937	0.85

表2　在Prostate158数据集上的定量结果对比

Table 2　Quantitative comparison of results on the Prostate158 dataset

模型	Dice	HD95	Sensitivity	ASD
U-Net	0.869	4.61	0.889	11.86
Attention U-Net	0.881	7.07	0.957	2.73
TransUNet	0.880	15.69	0.922	1.52
ResU-Net	0.892	8.27	0.858	0.24
GLCSA-UNet	0.884	5.08	0.757	1.51
RL-TransUNet(Ours)	0.950	5.52	0.971	2.06

2.4　消融实验

为严格验证本文所提各个模块的有效性及其协同作用，设计了详尽的消融实验。所有实验均在相同的训练-测试数据集划分、随机种子和超参数设置下进行，以确保结果的公平可比。实验结果如表3所示，其中包含了不同配置下的Dice系数与HD95指标。

表3　双数据集上消融实验分析

Table 3　Ablation Analysis on Both Datasets

	PROMISE12		Prostate158	
实验配置	Dice	HD95	Dice	HD95
A:TransUNet	0.882	8.04	0.880	15.69
B:A+定制化预处理	0.895(+1.47%)	4.64(−42.29%)	0.893(+1.48%)	8.69 (−44.61%)
C: A+RL 注意力优化	0.912(+3.40%)	6.23(−22.51%)	0.905(+2.84%)	6.35(−59.53%)
D:B+C	0.940(+6.58%)	3.00(−62.69%)	0.950(+7.95%)	5.52(−64.82%)

配置A：原始TransUNet模型，作为实验的基线参照。该配置完全沿用TransUNet的原始架构，采用均等注意力头权重分配策略，直接使用未经过定制化处理的原始数据进行训练，其性能指标反映了基线模型在双数据集上的基础表现。

配置B：在基线模型基础上仅加入定制化预处理流程。结果显示性能实现了显著提升，在PROMISE12和Prostate158数据集上，Dice系数分别提升了1.47%（至0.895）和1.48%（至0.893），而反映边界误差的HD95指标则大幅下降了42.29%（至

© 中国图象图形学报版权所有

4.64 mm)和44.61%(至8.69 mm)。这一提升的核心原因在于:“标准化-净化-增强”流程有效消除了多中心设备引起的体素尺度差异与信号强度波动,并筛除了严重伪影样本。这为网络提供了空间与灰度分布高度一致的高质量输入特征,大幅降低了模型在跨域数据上的学习难度与边界定位误差。

配置C:在未使用定制化预处理的原始数据上,仅加入基于强化学习(RL)的动态注意力优化机制。实验表明,即便面对存在异质性干扰的原始数据,该机制依然带来了卓越的增益:双数据集上的Dice系数分别显著提升了3.40%(至0.912)和2.84%(至0.905),HD95分别降低了22.51%(至6.23 mm)和59.53%(至6.35 mm)。其内在提升逻辑在于:RL策略梯度算法打破了传统Transformer中静态均等的权重分配局限,使得智能体能够根据具体图像特征自适应地“剪枝”那些过度关注背景噪声的冗余注意力头。有限的计算资源被精准聚焦于前列腺尖部、基底部等难分割区域,极大增强了模型对模糊边界的特征捕捉与抗干扰能力。

配置D:(全模型):同时结合定制化预处理与RL注意力优化后,模型各项指标达到最佳。相较于基线模型,在PROMISE12和Prostate158数据集上,Dice系数实现了最大幅度的跨越,分别提升了6.58%(达0.940)和7.95%(达0.950),HD95指标更是分别大幅收缩了62.69%(降至3.00 mm)和64.82%(降至5.52 mm)。如此巨大的性能飞跃充分证明了本文“数据质量提升-注意力资源调度”协同设计思路的必要性:高质量的标准化输入扫清了数据分布偏差的底层障碍,使得RL智能体无需再将宝贵的注意力资源消耗在辨别伪影与噪声上,从而能够更加极致地专注于真实解剖边缘的精细刻画,最终实现了全局分割精度与局部轮廓贴合度的全面突破。

2.5 定性分析

为直观验证模型在实际临床病例中的泛化表现,进一步支撑定量结果的可靠性,本文分别选取了PROMISE12(异质性样本)和Prostate158(标准化样本)的典型病例进行可视化对比分析。图6和图7展示了不同模型在两个数据集上的分割结果,以医学专家手工标注(Ground Truth)为金标准,从解剖学合理性、边界连续性及难点区域捕捉能力三个维度展开评估。为确保对比的全面性与客观性,每个病例均选取具有代表性的中间切片进行展示。

图6展示了PROMISE12数据集中含直肠线圈伪影、信噪比低且前列腺体积较小的困难样本。从图中可见,传统CNN模型受伪影干扰严重,出现了明显的漏分割或轮廓断裂,例如U-Net在伪影重叠区域将大片背景误判为前列腺,而ResU-Net的分割结果则呈碎片化,难以形成完整闭合的解剖轮廓,无法有效区分前列腺与周围相似的软组织;Attention U-Net虽通过门控机制有所改善,但对高强度伪影区域的抑制能力依然有限,其预测掩膜边缘仍存在不规则外溢。相比之下,RL-TransUNet得益于RL智能体对冗余特征的动态“剪枝”,有效抑制了背景噪声和线圈伪影的干扰,其生成的掩膜轮廓完整、平滑,紧密贴合前列腺的真实边界,即使在信噪比极低的区域也未出现断裂或异常凸起,展现了极强的抗干扰鲁棒性。

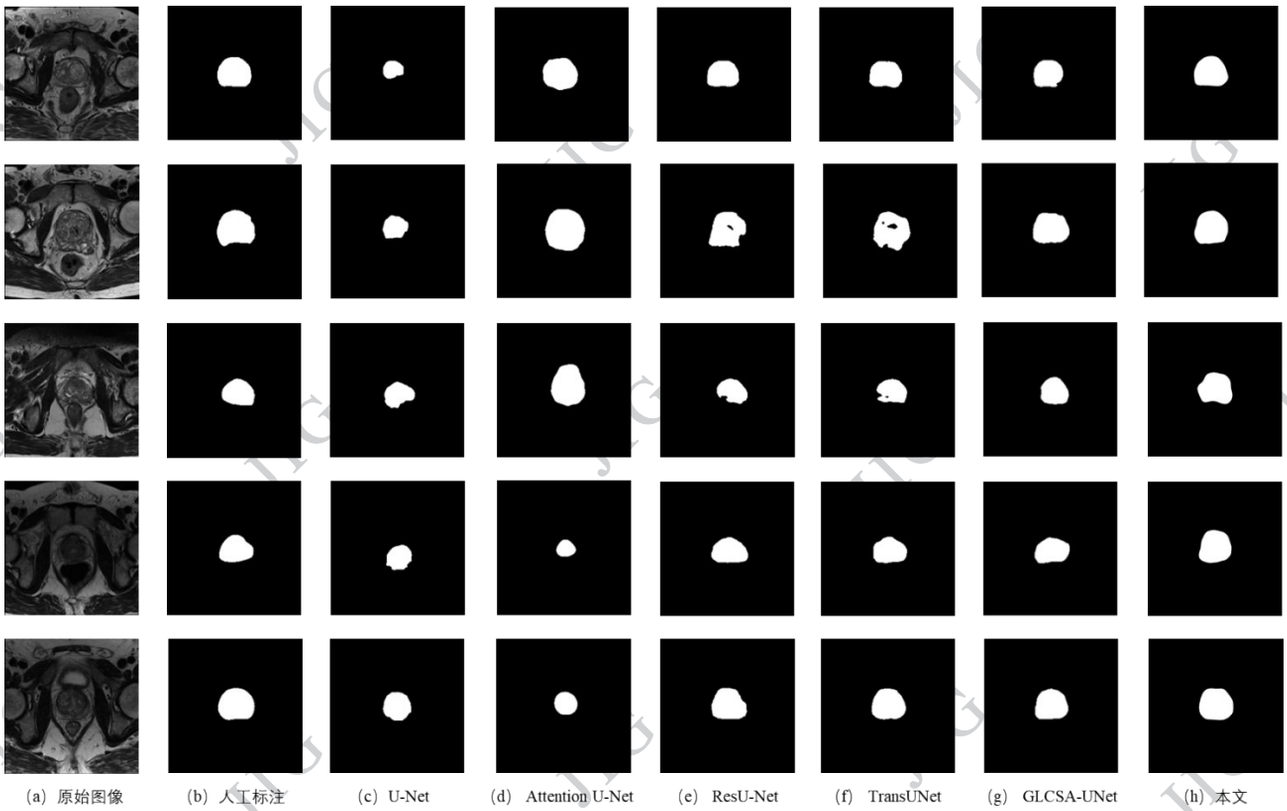
图7展示了Prostate158数据集中解剖结构复杂、边界粘连严重的高清样本(如前列腺尖部与尿道括约肌交界处、基底部与膀胱颈的灰度过渡区)。在这些高分辨率图像中,基线模型TransUNet因静态均等的注意力分配,容易在边界模糊处产生过分割现象,常将膀胱壁或部分精囊腺组织误判为前列腺,导致分割掩膜明显超出金标准范围;GLCSA-UNet虽通过堆叠注意力模块减少了部分误判,但在复杂粘连区域仍存在毛刺状边界。相比之下,RL-TransUNet凭借策略梯度优化的动态注意力机制,能够敏锐捕捉细微的边界纹理变化,准确分辨前列腺实质与周围正常组织的灰度过渡。特别是在极具挑战性的前列腺尖部(Apex)和基底部(Base),其预测轮廓与专家金标准高度吻合,实现了像素级的精准分类,展现出卓越的解剖结构还原能力。综合两组可视化结果,RL-TransUNet在低信噪比异质数据与高分辨率标准数据上均展现出优于对比模型的抗干扰能力与边界还原精度,充分验证了动态注意力策略在不同数据分布下的普适性与鲁棒性。

2.6 注意力机制可视化分析

为定量评估强化学习模块对注意力头的优化效果,统计了测试集上所有样本经过Softmax归一化后的平均注意力头权重,并绘制了RL-TransUNet与基线TransUNet的对比柱状图,如图8所示。

在原始TransUNet中,12个注意力头的权重分布相对均匀,这与“均等权重”策略相符,但导致了前

© 中国图象图形学报版权所有



((a)Original image;(b)Ground truth;(c)U-Net;(d)Attention U-Net;(e)ResU-Net;(f)TransUNet;(g)GLCSA-UNet;(h)ours)

图6 PROMISE12分割结果可视化

Fig. 6 Visualization of segmentation results on the PROMISE12 dataset

述的注意力头冗余问题。相比之下，经过RL优化后，RL-TransUNet的注意力头权重呈现出显著的差异化分布。具体而言，第3、7和11号注意力头的权重显著高于其他头，表明它们被模型判断为对前列腺分割任务更为重要；而第2、5和9号头的权重则被显著抑制。这一结果直观地证实了REINFORCE算法成功实现了任务驱动的注意力资源调度，抑制了冗余头，并将计算资源集中到了更具信息量的特征通道上，从而解释了模型性能提升的内在原因。

3 结 论

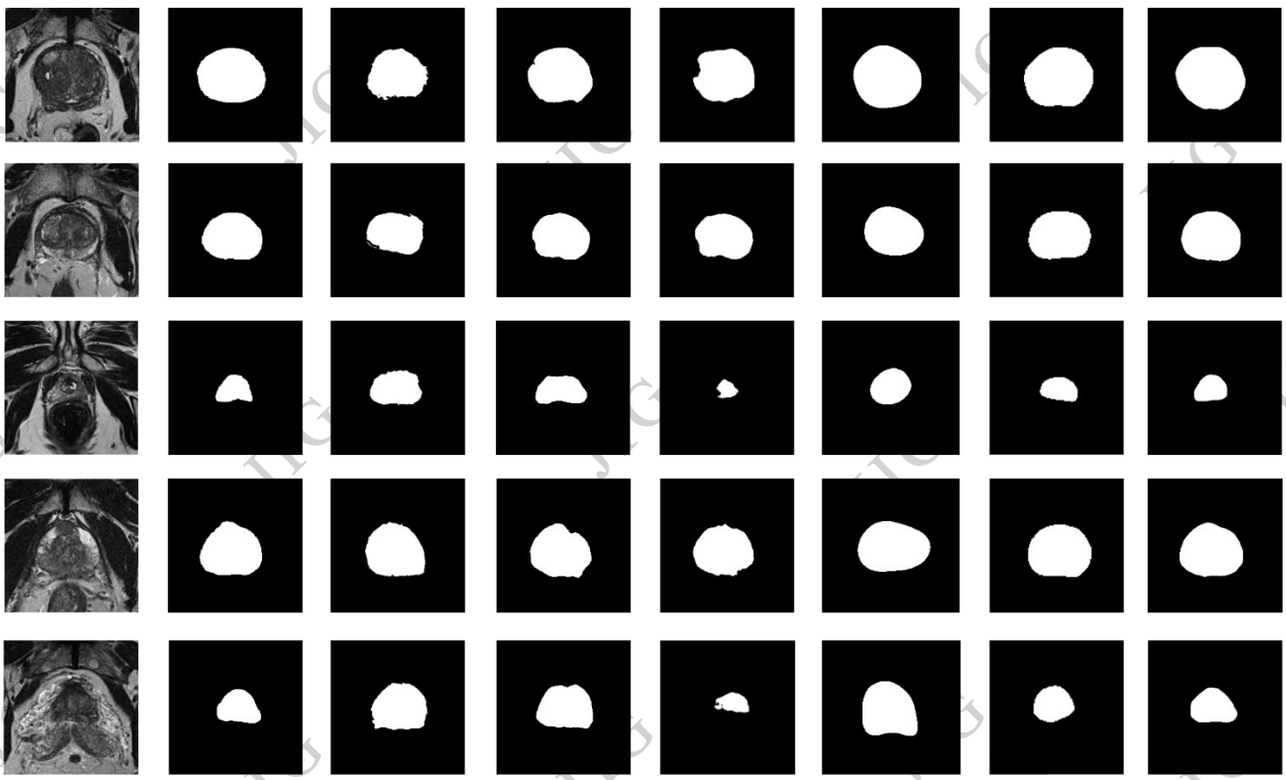
本文针对前列腺MRI分割中面临的多中心数据异质性干扰、Transformer注意力头冗余浪费、边界区域分割精度不足等关键挑战，提出了融合定制化预处理与强化学习注意力优化的RL-TransUNet模型，构建了“数据质量提升—注意力资源调度—任务目标对齐”的协同优化框架，为临床相关分割任务提供了高效解决方案。

该模型的核心优点体现在：其一，精准靶向临床分割痛点，通过多模块协同设计，同时改善数据层面的异质性问题与模型层面的资源分配问题，实现分割准确性与边界精细度的双重提升；其二，具备优异的实用性与经济性，在优化性能的同时未引入额外计算负担，契合临床场景对算法效率的需求；其三，适用范围具有针对性，对边界模糊、数据来源复杂的医学图像分割任务展现出强适配性，应用价值突出。

本文创新点主要包括三方面：一是设计定制化预处理流程，通过空间归一化、强度归一化、样本筛选与任务导向增强的递进式操作，系统性解决多中心数据的异质性问题；二是提出基于REINFORCE策略梯度的注意力动态优化机制，突破传统静态权重分配的局限，实现任务驱动的注意力资源精准调度，有效抑制冗余头干扰；三是构建与分割核心目标对齐的优化逻辑，将强化学习优化与临床关键分割需求紧密结合，提升模型对核心区域的特征捕捉能力。

本文所提出的模型仍存在一定不足：其一，当前

© 中国图象图形学报版权所有



((a)Original image;(b)Ground truth;(c)U-Net;(d)Attention U-Net;(e)ResU-Net;(f)TransUNet;(g)GLCSA-UNet;(h)ours)

图7 Prostate158分割结果可视化

Fig. 7 Visualization of segmentation results on the Prostate158 dataset

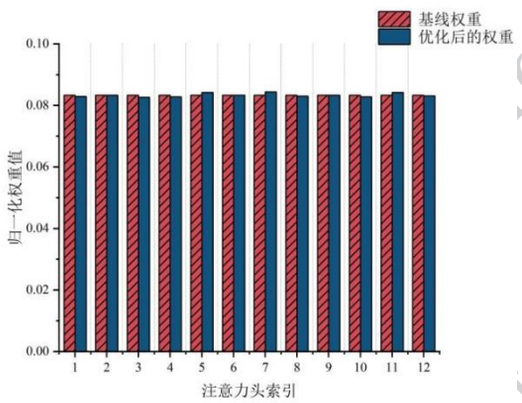


图8 注意力头权重分布对比

Fig. 8 Attention Head Weight Distribution Comparison

架构以2D特征处理为主,未能充分挖掘3D体数据中完整的空间关联信息,对前列腺立体结构的建模存在局限;其二,对极端成像条件(如严重运动伪影、罕见解剖变异)的鲁棒性有待提升,面对超出常规分布的临床数据时,性能可能出现波动;其三,依赖全量像素级标注数据进行训练,而医学影像标注成本高、周期长,限制了模型在数据稀缺场景下的推广;其四,可解释性仅停留在注意力可视化层面,缺乏面向临床医生的直观决策依据,难以充分支撑临床信任。

针对上述不足,后续可从以下方向推进优化:其一,开展3D结构升级,融合3D CNN与3D Transformer模块,充分利用体数据的空间上下文信息,强化对前列腺立体形态的建模能力;其二,增强极端场景适配性,引入自适应伪影校正模块与解剖变异鲁棒性训练策略,扩大模型对复杂临床数据的适配范围;其三,拓展半监督与弱监督学习范式,结合伪标签生成、少量标注引导等方法,减少对全量精准标注的依赖,降低临床应用门槛;其四,提升临床可解释性,结合医学解剖先验知识,构建结构化解释框架,将模型决策过程与临床解剖逻辑对应,增强临床医生对分割结果的信任度。

参考文献(References)

Adams L C, Makowski M R, Engel G, Rattunde M, Busch F, Asbach

© 中国图象图形学报版权所有

P, et al. 2022. Prostate158-An expert-annotated 3T MRI dataset and algorithm for prostate cancer detection. Computers in Biology and Medicine, 148: 105817 [DOI: 10.1016/j.compbiomed.2022.105817].

Cao H, Wang Y, Chen J, Jiang D, Zhang X, Tian Q, et al. 2022. Swin-Unet: Unet-like pure transformer for medical image segmentation// Proceedings of the European Conference on Computer Vision. Cham: Springer: 205-218 [DOI: 10.1007/978-3-031-25066-8_9].

Chen J, Lu Y, Yu Q, Luo X, Adeli E, Wang Y, et al. 2021. TransUNet: Transformers make strong encoders for medical image segmentation[EB/OL]. [2024-11-20]. https://arxiv. org/abs/2102.04306 [DOI: 10.48550/arXiv. 2102.04306].

Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, et al. 2020. An image is worth 16x16 words: Transformers for image recognition at scale[EB/OL]. [2024-11-20]. https://arxiv. org/abs/2010.11929 [DOI: 10.48550/arXiv. 2010.11929].

Hatamizadeh A, Tang Y, Nath V, Yang D, Myronenko A, Landman B, et al. 2022. UNETR: Transformers for 3D medical image segmentation//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa: IEEE: 574-584 [DOI: 10.48550/arXiv.2103.10504].

He K M, Zhang X Y, Ren S Q and Sun J. 2016. Deep residual learning for image recognition//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90].

Huttenlocher D P, Klanderman G A and Rucklidge W J. 1993. Comparing images using the Hausdorff distance. IEEE Transactions on Pattern Analysis and Machine Intelligence, 15(9): 850-863 [DOI: 10.1109/34.232073].

Isensee F, Jaeger P F, Kohl S A A, Petersen J and Maier-Hein K H. 2021. nnU-Net: A self-configuring method for deep learning-based biomedical image segmentation. Nature Methods, 18(2): 203-211 [DOI: 10.1038/s41592-020-01008-z].

Kirillov A, Mintun E, Ravi N, Mao H, Rolland C, Gustafson L, et al. 2023. Segment anything//Proceedings of the IEEE/CVF International Conference on Computer Vision. Piscataway: IEEE: 4015-4026 [DOI: 10.1109/ICCV51070.2023.00371].

Litjens G, Toth R, van de Ven W, Hoeks C, Kerkstra S, van Ginneken B, et al. 2014. Evaluation of prostate segmentation algorithms for MRI: The PROMISE12 challenge. Medical Image Analysis, 18(2): 359-373 [DOI: 10.1016/j.media.2013.12.002].

Liu Q, Dou Q and Heng P A. 2020. Shape-aware meta-learning for generalizing prostate MRI segmentation to unseen domains//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer: 475-485 [DOI: 10.1007/978-3-030-59713-9_46].

Liu W, Zhong M, Liu G W, Wang H N and Ning Q. 2025. Detail-enhanced medical image segmentation focusing on global and intermediate features. Journal of Image and Graphics, 30(10): 3392-3410 (刘威, 钟淼, 刘光伟, 王浩男, 宁倩. 2025. 聚焦全局与中间层的细节增强医学图像分割. 中国图象图形学报, 30(10): 3392-3410) [DOI: 10.11834/jig.240463].

Liu Z, Lin Y T, Cao Y, Hu H, Wei Y, Zhang Z, et al. 2021. Swin transformer: Hierarchical vision transformer using shifted windows// Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal: IEEE: 10012-10022 [DOI: 10.1109/ICCV48922.2021.00986].

Ma J, He Y, Li F, Han L, You C and Wang B. 2024. Segment anything in medical images. Nature Communications, 15(1): 654 [DOI: 10.1038/s41467-024-44824-z].

Milletari F, Navab N and Ahmadi S A. 2016. V-Net: Fully convolutional neural networks for volumetric medical image segmentation// Proceedings of the 2016 Fourth International Conference on 3D Vision. Stanford: IEEE: 565-571 [DOI: 10.1109/3DV.2016.79].

Oktay O, Schlemper J, Folgoc L L, Lee M, Heinrich M P, Misawa K, et al. 2018. Attention U-Net: Learning where to look for the pancreas[EB/OL]. [2024-11-20]. https://arxiv.org/abs/1804.03999.

Peng Y F and Sun W Q. 2026. Medical image segmentation via dual-path encoding and adaptive receptive fields. Journal of Image and Graphics, 31(1): 320-334 (彭晏飞, 孙伟强. 2026. 双路径编码与自适应感受野驱动的医学图像分割. 中国图象图形学报, 31(1): 320-334) [DOI: 10.11834/jig.250128].

Ronneberger O, Fischer P and Brox T. 2015. U-Net: Convolutional networks for biomedical image segmentation//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Munich: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28].

Siegel R L, Giaquinto A N and Jemal A. 2024. Cancer statistics, 2024. CA: A Cancer Journal for Clinicians, 74(1): 12-49 [DOI: 10.3322/caac.21820].

Sudre C H, Li W, Vercauteren T, Ourselin S and Jorge Cardoso M. 2017. Generalised dice overlap as a deep learning loss function for highly unbalanced segmentations//Proceedings of the 1st International Workshop on Deep Learning in Medical Image Analysis. Québec City: Springer: 240-248 [DOI: 10.1007/978-3-319-67558-9_28].

Tran T T and Le N Q K. 2024. DA-TransUNet: Integrating spatial and channel dual attention with transformer U-net for medical image segmentation. Frontiers in Bioengineering and Biotechnology, 12: 1398237 [DOI: 10.3389/fbioe.2024.1398237].

Valanarasu J M, Oza P, Hacihaliloglu I and Patel V M. 2021. Medical transformer: Gated axial-attention for medical image segmentation// Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer: 36-46 [DOI: 10.1007/978-3-030-87193-2_4].

© 中国图象图形学报版权所有

Wang W H, Chen C, Ding M, Yu H, Zha S and Li J. 2021. TransBTS: Multimodal brain tumor segmentation using transformer//Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Strasbourg: Springer: 109-119 [DOI: 10.1007/978-3-030-87193-2_11].

Williams R J. 1992. Simple statistical gradient-following algorithms for connectionist reinforcement learning. Machine Learning, 8(3): 229-256 [DOI: 10.1007/BF00992696].

作者简介

邹水中,男,副教授,主要研究方向为医疗外科手术机器人、医学图像处理,E-mail:zoushuizhong@guet.edu.cn。

文传清,男,硕士研究生,主要研究方向为医学图像处理,E-mail:951981212@qq.com。

王剑,男,讲师,主要研究方向为光电检测,E-mail:328467126@qq.com。

邱豪,男,博士研究生,主要研究方向医疗外科手术机器人,E-mail:20b908024@stu.hit.edu.cn。

© 中国图象图形学报版权所有