

中图法分类号: TP391.4 文献标识码: A 文章编号: 1006-8961(XXXX)XX-0001-18

论文引用格式: Zhang Xingpeng, Liu Xiaopeng, Li Wei, Wang Qiuli. Multimodal brain tumor segmentation network fusing explicit boundary prior and decoupled attention[J/OL]. Journal of Image and Graphics, XXXX: 1-18. DOI: 10.11834/jig.260306. (张兴鹏, 刘晓鹏, 李伟, 王秋里. 融合显式边界先验与解耦注意力的多模态脑肿瘤分割网络[J/OL]. 中国图象图形学报, XXXX: 1-18. DOI: 10.11834/jig.260306.) [DOI: 10.11834/jig.260306]

融合显式边界先验与解耦注意力的多模态脑肿瘤分割网络

张兴鹏^{1,2}, 刘晓鹏¹, 李伟¹, 王秋里³

1. 西南石油大学 计算机与软件学院, 成都 610500; 2. 核医药与辐射安全防控四川省重点实验室, 川北医学院, 南充 637000; 3. 陆军军医大学第一附属医院 放射科, 重庆, 400038

摘要: 目的 精准的多模态磁共振脑肿瘤亚区分割对临床诊疗至关重要。但胶质瘤形态异质性强, 现有分割网络常面临边界建模困难、空间信息与深层语义特征融合不充分等问题, 易在低对比度区域出现定位偏差与拓扑断裂。为此, 本文提出一种融合显式边界先验的多模态脑肿瘤分割网络 (boundary prior enhanced network, BPE-Net)。
方法 设计辅助监督边界预测模块 (boundary predictor module, BPM), 聚合编码器多尺度层级特征提取具有类别感知能力的边界先验, 提供类别相关的空间信息; 构建边界特征增强模块 (edge feature enhancement module, EFM), 利用空间-通道解耦注意力机制以残差方式将边界先验融入解码特征, 在优化局部拓扑结构的同时保护核心语义表征。引入边界加权Dice损失 (boundary weighted Dice loss, BWD), 通过像素级权重矩阵强化对模糊边缘像素的约束, 缓解传统算法的体积评估偏见。
结果 在脑肿瘤分割挑战赛 (brain tumor segmentation, BraTS) 2019 和 BraTS 2020 数据集上与 7 种主流方法对比, 本方法平均 Dice 相似系数 (Dice similarity coefficient, Dice) 分别为 93.69% 和 92.51%, 平均 95% 豪斯多夫距离 (95% Hausdorff distance, HD95) 分别为 1.96mm 和 2.33mm, 较最优对比方法 Swin-Unet 平均 Dice 分别提高 7.43 和 8.60 个百分点, 平均 HD95 分别降低 1.23mm 和 1.43mm; 其中增强肿瘤 (enhancing tumor, ET) 区域的 Dice 提升最为明显, 分别提高 9.91 和 10.43 个百分点。
结论 显式边界引导策略有助于缓解低对比度区域的边界混淆, 为医学图像准确分割与复杂拓扑重建提供了一种有效的新方法。本文代码开源在链接: <https://www.scidb.cn/s/eeiMBv>。

关键词: 脑肿瘤分割; 多模态磁共振成像; 边界先验; 辅助监督学习; 解耦注意力

Multimodal brain tumor segmentation network fusing explicit boundary prior and decoupled attention

Zhang Xingpeng^{1,2}, Liu Xiaopeng¹, Li Wei¹, Wang Qiuli³

1. School of Computer Science and Software Engineering, Southwest Petroleum University, Chengdu, 610500, China; 2. Nuclear Medicine and Radiation Safety Key Laboratory of Sichuan Province, North Sichuan Medical College, Nanchong, 637000, China; 3. Department of Radiology, The First Affiliated Hospital of Army Medical University, Chongqing, 400038, China

Abstract: **Objective** Brain tumors, particularly gliomas, are among the most aggressive and heterogeneous malignancies in the central nervous system, with high morbidity and mortality. In clinical practice, precise and reliable segmentation of

收稿日期: 2026-05-27; 修回日期: 2026-08-19

基金项目: 国家自然科学基金专项项目 (项目编号: 62441610); 重庆市科卫联合面上项目 (项目编号: 2025MSXM016)

Supported by: National Natural Science Foundation of China (No. 62441610) and the Chongqing Science and Health Joint Medical Research Project (No. 2025MSXM016).

brain tumor sub-regions using multimodal magnetic resonance imaging (MRI) including native T1-weighted (T1), post-contrast T1-weighted (T1ce), T2-weighted (T2), and fluid-attenuated inversion recovery (FLAIR) is a fundamental prerequisite for initial diagnosis, surgical planning, targeted radiotherapy, and postoperative survival prediction. However, manual delineation by radiologists is exceptionally time-consuming, highly subjective, and prone to intra- and inter-observer variability. While deep learning-based automated segmentation methods have made substantial progress, existing architectures frequently encounter bottlenecks. Conventional convolutional neural networks (CNNs) are constrained by their localized receptive fields, limiting their ability to model long-range semantic dependencies. Conversely, vision Transformers (ViTs) excel in capturing global contexts but suffer from patch-partitioning mechanisms that inherently disrupt pixel-level continuity, leading to the loss of high-frequency geometric details. Moreover, owing to the strong morphological heterogeneity of gliomas, and to the difficulty of boundary modeling and the insufficient fusion of spatial information with deep semantic features in existing networks, segmentation is prone to localization deviations, semantic confusion, and topological fractures in low-contrast regions. **Method** To systematically address these critical bottlenecks, this study proposes boundary prior enhanced network (BPE-Net), which integrates explicit boundary priors and spatial-channel decoupled attention to couple explicit geometric perception with feature enhancement. The proposed BPE-Net is built upon an end-to-end 2D encoder-decoder architecture, comprehensively optimized to balance high-level semantic representation and low-level topological reconstruction. To explicitly capture high-frequency morphological details, we design an auxiliary-supervised boundary predictor module (BPM). Unlike traditional edge-detection operators that are vulnerable to medical imaging noise, the BPM adaptively aggregates multi-scale hierarchical features (from the first three down-sampling stages of the encoder). It projects these features into a unified resolution via bilinear interpolation and utilizes category-aware prediction heads to generate independent, three-channel spatial boundary probability maps for the whole tumor (WT), tumor core (TC), and the enhancing tumor (ET). The BPM is supervised using category-specific, two-pixel-wide contour labels generated from the corresponding ground-truth masks. Specifically, the contour of each binary mask is extracted and rendered with a width of two pixels, providing explicit spatial supervision for category-aware boundary learning. Subsequently, to effectively integrate this geometric prior into the deep semantic space without introducing early-stage structural noise, we strategically deploy the edge feature enhancement module (EFM) exclusively at the high-resolution decoding stages (up3 and up4). The EFM introduces a sophisticated spatial-channel decoupled attention mechanism. The spatial attention branch operates entirely on the boundary priors generated by the BPM to highlight high-frequency edge regions, while the channel attention branch dynamically recalibrates feature importance based on the decoder's intermediate representations using global average pooling and multi-layer perceptrons. The decoupled attention maps are then fused through element-wise multiplication and smoothly injected into the main network backbone via a residual connection parameterized by a learnable scaling factor. Furthermore, to rectify the inherent volumetric bias of standard regional losses (such as the traditional Dice loss), which disproportionately favor large target areas (WT) while neglecting small, complex regions (ET), we introduce a boundary weighted Dice loss (BWD). The BWD incorporates a pixel-level spatial weight matrix derived from ground-truth boundaries. By assigning the highest penalty coefficients to the most ambiguous and microscopic edge pixels (especially for the ET region), the BWD guides the network to focus more gradient updates on hard-to-classify transitional zones, thereby improving local discriminative capability. **Result** Extensive and rigorous evaluations were conducted on two internationally recognized public benchmark datasets: BraTS 2019 (brain tumor segmentation 2019) and BraTS 2020, comprising diverse multi-institutional, multi-scanner MRI scans. The quantitative evaluation metrics included the Dice similarity coefficient (Dice) for regional overlap and the 95% Hausdorff distance (HD95) for boundary spatial distance. The proposed BPE-Net was compared with seven mainstream segmentation networks under identical data splits and training settings. On BraTS 2019, BPE-Net achieved an average Dice of 93.69% and an average HD95 of 1.96mm, exceeding the best-performing comparative method Swin-Unet (86.26%, 3.19mm) by 7.43 percentage points in average Dice and reducing the average HD95 by 1.23mm, with Dice gains of 8.12 and 9.91 percentage points for TC and ET, respectively. On BraTS 2020, BPE-Net achieved an average Dice of 92.51% and an average HD95 of 2.33mm, exceeding Swin-Unet (83.91%, 3.76mm) by 8.60 percentage points in average Dice and reducing the average HD95 by 1.43mm; in the ET region, its Dice reached 88.55%, 10.43 percentage points higher than the best comparative result.

Qualitative visualizations further corroborated these findings, demonstrating that BPE-Net produces refined and topologically coherent segmentation masks that align well with expert annotations, reducing the over-segmentation and topological fractures frequently observed in baseline models. Comprehensive ablation studies verified the individual and synergistic contributions of the proposed components. The integration of the EFM alone improved the baseline average Dice from 86.31% to 93.57%, while the further addition of the BPM pushed the performance to 93.69%. Ablation on feature injection levels confirmed that the up3 and up4 combined strategy provides the optimal equilibrium between preserving deep semantics and recovering shallow structural fidelity. **Conclusion** In summary, this study proposes an explicit boundary-guided network, BPE-Net, which helps mitigate the edge confusion issue in multimodal brain tumor segmentation. By innovating the auxiliary supervised extraction of category-aware boundary priors and executing precise feature injection via spatial-channel decoupled attention, the model achieves competitive and robust performance, particularly in delineating highly irregular and invasive tumor sub-regions. This proposed framework mitigates the volumetric bias inherent in conventional algorithms, providing an effective method for medical image segmentation and complex topology reconstruction. While the current architecture demonstrates superior accuracy, its computational complexity and reliance on complete four-modality MRI inputs represent certain limitations. Future research will focus on developing lightweight deployment schemes, exploring adaptive feature imputation techniques for missing-modality clinical scenarios, and validating the model's generalization capabilities across broader multi-center cohorts and other complex organ segmentation tasks. The source code of this paper is available at: <https://www.scidb.cn/s/eeiMBv>.

Key words: Brain tumor segmentation; multimodal magnetic resonance imaging; boundary prior; auxiliary supervised learning; decoupled attention

论文引用格式: Zhang Xingpeng, Liu Xiaopeng, Li Wei, Wang Qiuli. XXXX. Multimodal brain tumor segmentation network fusing explicit boundary prior and decoupled attention. Journal of Image and Graphics, XX(X):0001-00XX (张兴鹏, 刘晓鹏, 李伟, 王秋里. XXXX. 融合显式边界先验与解耦注意力的多模态脑肿瘤分割网络. 中国图象图形学报, XX(X):0001-00XX) [DOI:10.11834/jig.260306]

0 引言

精准的多模态磁共振成像(magnetic resonance imaging, MRI)脑肿瘤亚区分割是临床诊疗、手术规划及预后评估的核心基础。脑肿瘤作为大脑内组织的异常生长,具有较高的形态异质性和位置不确定性,其恶性程度与风险评估在很大程度上取决于其扩散与浸润能力(Louis等,2016;Menze等,2015)。开发高精度的自动分割方法已成为计算机辅助诊断领域的研究热点(Xing等,2025)。在实际场景中,通过组合液体衰减反转恢复(fluid-attenuated inversion recovery, FLAIR)、T1加权(T1-weighted, T1)、增强T1加权(contrast-enhanced T1-weighted, T1ce)和T2加权(T2-weighted, T2)等多种模态,可以有效捕获肿瘤

内部复杂的病理信息。如图1所示,不同模态的图像捕捉到不同的病理结构,具有显著的互补性。

在过去十年中,以U-Net(Ronneberger等,2015)为代表的卷积神经网络(convolutional neural network, CNN)凭借编码器-解码器架构和跳跃连接,在医学图像分割领域取得显著成功。为有效处理MRI的三维特性,3D U-Net(Çiçek等,2016)和V-Net(Milletari等,2016)将传统的二维卷积操作扩展至三维空间维度,并引入Dice损失以应对类别不平衡问题。此后,国内外学者提出一系列增强方案:UNet++(Zhou等,2020)通过引入嵌套的密集跳跃路径来弥合编码器与解码器之间的语义鸿沟;DeepLab(Chen等,2018)利用空洞卷积扩大感受野。

值得注意的是,针对传统CNN在处理低对比度模糊边缘时的固有限制,部分研究尝试从边缘增强的角度优化卷积网络架构。AEEM-Net(Zeng,2025)通过可变形卷积动态调整特征采样位置,并引入边界监督机制来提升边缘完整性,为边界感知型网络提供新的设计范式。尽管CNN在提取局部细节方面极具优势,但受限于卷积核的固定感受野,其在显式建模全局长距离语义依赖方面存在天然瓶颈。针对这一问题,LMD-UNet(夏景明等,2023)通过引入残差连接与多尺度卷积模块有效增强跨层级特征传




图1 脑肿瘤分割的多模态磁共振成像示例。(a)真实标签,绿色、黄色和红色分别代表瘤周水肿(peritumoral edema, ED)、增强肿瘤(enhancing tumor, ET)以及坏死与非增强肿瘤核心(necrotic and non-enhancing tumor core, NCR/NET)。(b)T1 加权图像;(c)增强 T1 加权图像(T1ce);(d)T2 加权图像;(e)液体衰减反转恢复图像(FLAIR)。实际中,完整肿瘤(whole tumor, WT)由这三类区域合并构成,肿瘤核心(tumor core, TC)由 ET 和 NCR/NET 构成,增强肿瘤(ET)仅对应黄色区域

Fig. 1 Multimodal MRI examples for brain tumor segmentation. (a) Ground truth, with green, yellow, and red indicating peritumoral edema (ED), enhancing tumor (ET), and necrotic/non-enhancing tumor core (NCR/NET), respectively. (b) T1-weighted image; (c) contrast-enhanced T1-weighted image (T1ce); (d) T2-weighted image; and (e) fluid-attenuated inversion recovery image (FLAIR). For evaluation, the whole tumor (WT) is the union of all three sub-regions, the tumor core (TC) comprises ET and NCR/NET, while the enhancing tumor (ET) corresponds solely to the yellow region

递能力,但其网络结构仍以卷积为主,难以捕捉全局上下文依赖。多层级并行神经网络(丁熠等,2023)利用并行特征提取与上采样模块实现脑肿瘤特征的高效融合,然而该方法对多模态输入中的互补信息挖掘不够深入,尤其在肿瘤边缘区域的特征对齐方面存在不足。

为突破局部性限制, Vision Transformer 及其核心的自注意力机制被引入医学图像处理领域。Swin-UNet(Cao 等,2023)利用移位窗口机制在精度与算力间取得平衡;Trans-MT(Liao 等,2026)则通过半监督框架进一步提升特征提取的鲁棒性。针对单一架构的局限性,融合 CNN 与 Transformer 的混合架构逐渐成为近年来的研究热点。例如,DA-TransUNet(Sun 等,2024)集成空间与通道双重注意力块以有效过滤背景噪声;CFATrans(Goceri 等,2026)则提出连续融合注意力以构建收缩金字塔模型。然而,这类混合方法大多采用粗粒度的图块划分机制处理图像,在本质上破坏了像素间的连续性,导致在刻画脑肿瘤极端不规则的边界时容易出现严重的局部细节丢失。DAFANet(宋建丽等,2024)利用语义信息流引导上采样特征恢复并设计轻量级双重注意力模块,虽然有效缓解空间信息丢失问题,但由于缺乏对边界区域的显式空间建模,在低对比度区域仍难以较好地恢复精细的肿瘤边缘,模型在肿瘤核心与水肿区域的过渡带上仍易产生分割断裂。在多模态特征融合方面,早期的通道拼接策略缺乏对模态间深层互补关系的动态建模。为此,CKD-

TransBTS(Lin 等,2023)和 NestedFormer(Xing 等,2022)引入交叉注意力机制以实现更精准的特征空间对齐。在预处理与通道重校准层面,AMIN-CNN(Depuru 等,2025)提出自适应不变归一化以消除模态偏移,S2Net(Gui 等,2025)利用加权融合解决特征空间错位问题。尽管这些策略在一定程度上缓解了全局强度偏差,但其仍忽略了局部过渡区域边界模糊的复杂本质,未能根本解决边缘像素分类困难的瓶颈。D3D-Net(张奕涵等,2024)通过双层编码器结构提取不同模态组合的特征,并利用扩张多纤维模块捕获多尺度信息,显著降低计算开销,但其融合策略仍然侧重于整体区域而非边缘像素的判别性特征。类似地,三重注意力与空间-通道双重注意力分割方法(毋小省等,2023)增强感兴趣区域的位置和边界判断能力,然而该方法的注意力机制作用于全局特征图,对高频边界的空间定位精度有限,导致在 ET 区域的边缘处仍存在过分割现象。

针对边界感知难题,AS-WEC(Xiao 等,2025)曾尝试融合弱边缘与上下文特征,但其高度依赖传统的 Otsu 门槛算子,在处理低对比度医学图像时十分脆弱。在损失函数设计上,传统的 Dice 损失往往偏向大体积病灶,对边界复杂的 ET 区域不够敏感。虽然已有部分研究尝试组合形状与边界信息,但缺乏针对极度模糊边缘像素的自适应梯度加权机制,如 EGV-Net(姜灏天等,2023)实现了高频边缘对低频特征分割的引导,然而其边缘引导信息严重依赖于传统的图像梯度算子,在噪声干扰下极易产生虚假

边缘响应,且缺乏多尺度类别感知能力,难以自适应胶质瘤高度复杂的形态异质性。

综上所述,如何在提取深层高阶语义的同时精准重建高频边界特征,仍是当前多模态脑肿瘤分割面临的核心挑战。

为此,本文提出一种融合显式边界先验与解耦注意力的多模态脑肿瘤分割网络。本研究的切入点与主要贡献在于:1)构建辅助监督边界预测模块BPM,从编码器多尺度特征中自适应提取类别感知的空间几何边界。BPM既可作为独立的多任务分支约束共享编码特征,也可在完整模型中为后续特征增强提供显式边界先验;2)设计EFM模块,策略性地在解码器的高分辨率层级(up3和up4)进行边界先验的空间-通道解耦注入,实现高层语义与底层结构的较好平衡;3)引入BWD损失,通过构造基于真实边界的像素级空间惩罚矩阵,显著强化模型对模糊边缘的区分与鉴别能力,从而建立起从边界感知到特征增强的完整闭环范式。

1 方法

1.1 整体框架

本研究提出的BPE-Net采用端到端的编码器-解码器架构,通过建立从显式边界感知到精准特征增强的闭环机制,有效解决脑肿瘤边缘分割难题。如图2所示,网络首先接收由FLAIR、T1、T1ce和T2构成的四模态MRI图像,并利用编码器通过连续的下采样操作提取层次化的多尺度特征,为后续特征重建提供丰富的上下文支撑。随后,在显式引导生

成的关键阶段,BPM模块聚合编码器的多尺度特征进行自适应融合;在训练阶段,该模块在真实边界标签的监督下学习类别感知的几何先验;而在推理阶段,BPM模块则自动生成精确表达不同病灶亚区边缘概率分布的三通道边界图,为后续的空间重建提供空间锚点。在特征解码阶段,为在保留强语义信息的同时精确矫正细微的边缘拓扑,EFM模块被策略性地部署在解码器的高分辨率上采样层级(即up3和up4)。

在此过程中,EFM接收中间解码特征与BPM生成的边界先验,通过空间-通道解耦注意力机制进行渐进式的特征修复。这种阶段性的注入策略不仅指导高频细节的精细化重建,还有效避免早期解码阶段因语义不确定性而引入的几何噪声。

最终,经过深度增强的特征图通过 1×1 卷积层映射为病灶类别的概率分布。通过在整个端到端流程中使BPM模块充当“先验生成器”并由EFM模块担任“引导执行器”,网络在训练和推理阶段采用一致的前向计算路径,从而实现边界信息对分割特征的联合约束与增强。

1.2 边界预测模块

精确的边界定位是实现精细化医学图像分割的重要前提。为此,本文设计BPM模块,如图3所示,旨在直接从编码器特征中自适应地学习多尺度的边界表示。该模块从编码器的不同层级提取多尺度特征集合 $X = \{X_1, X_2, X_3\}$ 。其中, $X_1 \in \mathbf{R}^{B \times 64 \times H \times W}$, $X_2 \in \mathbf{R}^{B \times 128 \times \frac{H}{2} \times \frac{W}{2}}$, $X_3 \in \mathbf{R}^{B \times 256 \times \frac{H}{4} \times \frac{W}{4}}$,且 B 为批次大小, H 和 W 分别为输入切片的高度和宽度。




图2 BPE-Net总体架构图。(a) BPM:辅助监督边界预测模块;(b) EFM:边界特征增强模块

Fig. 2 Overall architecture of BPE-Net. (a) BPM: Auxiliary supervised boundary predictor module; (b) EFM: Edge feature enhancement module




图3 辅助监督边界预测模块结构图

Fig. 3 Architecture of the auxiliary supervised boundary predictor module

为消除空间分辨率的异质性以捕获丰富的空间细节,这些特征通过双线性插值操作统一对齐到主干目标分辨率,并在通道维度上进行层叠。融合后的特征 $F_{cat} \in \mathbf{R}^{B \times 448 \times H \times W}$ 经过包含分组归一化的连续卷积层进行处理,表达式为

$$F_{cat} = \text{Concat}(X_1, \mathcal{U}(X_2), \mathcal{U}(X_3)) \quad (1)$$

式中, $\text{Concat}(\cdot)$ 表示沿通道维度的拼接操作, X_1, X_2, X_3 为编码器前三个下采样阶段输出的多尺度特征图; $\mathcal{U}(\cdot)$ 表示双线性上采样算子,用于将特征图的空间分辨率统一对齐至 $H \times W$ 。随后,对拼接特征进行融合以提取边缘上下文表征,表达式为

$$F_{fuse} = \Phi_{fuse}(F_{cat}) \quad (2)$$

式中, $\Phi_{fuse}(\cdot)$ 为复合特征映射算子,代表由两层连续的卷积层(每层卷积后级联分组数为32的 Group-Norm 和 ReLU 激活函数)构成的非线性变换序列,其作用是将特征通道数平滑降维至固定瓶颈层维度; $F_{fuse} \in \mathbf{R}^{B \times 64 \times H \times W}$ 为融合后的边缘上下文表征。

考虑到 WT、TC 及 ET 三个亚区的边界形态存在显著的病理学差异, BPM 采用一种类别感知的辅助监督预测方式,并结合可学习的类别先验权重,为每个语义类别生成原始边界预测图,即

$$E_c = \omega_c \cdot \mathcal{P}_c(F_{fuse}) \quad (3)$$

式中, $c \in \{1, 2, 3\}$ 分别对应 WT、TC 和 ET。 ω_c 为可学习的类别先验权重系数,初始值分别设为 $\omega_1 = 1.0, \omega_2 = 1.5, \omega_3 = 2.0$; $\mathcal{P}_c(\cdot)$ 为第 c 类的辅助监督预测头,由 3×3 卷积、GroupNorm、ReLU 激活以及末端 1×1 卷积复合而成; E_c 为第 c 个语义类别的原始边界

预测图。将各类别输出沿通道轴拼接,得到多类边缘概率图 $E_{raw} = \text{Concat}(E_1, E_2, E_3) \in \mathbf{R}^{B \times 3 \times H \times W}$ 。

最后,为缓解边界像素极度稀疏导致的梯度不稳定性,引入全局截断映射算子 $\mathcal{T}(\cdot)$ 输出最终的边界先验图,即

$$E_{pred} = \mathcal{T}(\alpha \cdot E_{raw} + \beta) \quad (4)$$

式中, α 和 β 分别为全局可学习的自适应缩放因子与偏置项; $\mathcal{T}(\cdot)$ 表示数值截断函数,其将所有输入的 logit 值严格限制在 $[-8.0, 8.0]$ 区间内,有效防止了端到端训练过程中的梯度异常; $E_{pred} \in \mathbf{R}^{B \times 3 \times H \times W}$ 为最终的边界先验图。

1.3 边界特征增强模块

尽管 BPM 能够生成精确的边界先验,但如何将这种几何信息有效整合到解码器的语义特征中而不干扰原始核心语义,仍是拓扑重建的挑战所在。针对这一问题,本文提出 EFM 模块,如图4所示,其核心在于实现空间与通道注意力的解耦组合,从而在不破坏深层语义表示的前提下增强特征的判别力。

给定中间解码特征 $F_{dec} \in \mathbf{R}^{B \times C \times H' \times W'}$, 以及经过分辨率对齐后的边界先验图 $E'_{pred} \in \mathbf{R}^{B \times 3 \times H' \times W'}$, EFM 内部的注意力解耦生成机制包括空间注意力分支和通道注意力分支。其中, C 为解码特征的通道数, H' 和 W' 分别为解码阶段特征图的高度和宽度。

空间注意力分支完全由边界先验驱动。利用空间映射函数 $\Psi_s(\cdot)$ 捕获高频几何轮廓的空间拓扑分布,生成单通道空间注意力矩阵,即




图4 边界特征增强模块结构图

Fig. 4 Architecture of the edge feature enhancement module

$$A_{\text{spatial}} = \sigma(\Psi_s(E'_{\text{pred}})) \quad (5)$$

式中, $\sigma(\cdot)$ 为 Sigmoid 激活函数; $\Psi_s(\cdot)$ 表示由 3×3 卷积、GroupNorm、ReLU 激活以及 1×1 卷积级联组成的复合空间变换器; $A_{\text{spatial}} \in \mathbb{R}^{B \times 1 \times H' \times W'}$ 为单通道空间注意力矩阵。

通道注意力分支由特征语义驱动, 动态重新加权各个特征通道对边缘几何的响应敏感度, 即

$$A_{\text{channel}} = \sigma(M(\text{GAP}(F_{\text{dec}}))) \quad (6)$$

式中, $\text{GAP}(\cdot)$ 代表全局平均池化(global average pooling)操作; $M(\cdot)$ 为多层感知机算子, 代表包含单隐藏层的两层 1×1 卷积算子; $A_{\text{channel}} \in \mathbb{R}^{B \times C \times 1 \times 1}$ 为通道注意力权重。

在获取解耦的注意力特征后, 联合注意力图通过逐元素乘法与 Dropout 机制计算得出, 即

$$A_{\text{joint}} = \mathcal{D}_p(A_{\text{spatial}} \otimes A_{\text{channel}}) \quad (7)$$

式中, $\otimes$ 表示逐元素乘法; $\mathcal{D}_p(\cdot)$ 表示失活率 $p = 0.1$ 的二维 Dropout 算子; $A_{\text{joint}} \in \mathbb{R}^{B \times C \times H' \times W'}$ 为联合注意力图。最终, 为了实现边缘特征的平滑注入并保持网络的稳健性, 通过基于可学习缩放因子的残差结构输出深度增强特征, 即

$$F_{\text{enh}} = F_{\text{dec}} + \sigma(\gamma) \cdot (F_{\text{dec}} \otimes A_{\text{joint}}) \quad (8)$$

式中, γ 为可学习的自适应标量参数(网络初始化时设为常数 -2.0 , 使得初始阶段 $\sigma(\gamma) \approx 0.12$ 处于受抑状态); $F_{\text{enh}} \in \mathbb{R}^{B \times C \times H' \times W'}$ 为输出的深度增强特征。这种柔性残差控制机制有效避免了边界强几何约束在训练初期对骨干网络核心语义表征的强行破坏。

1.4 损失函数

由于脑肿瘤多模态 MRI 图像中不同亚区(如 WT、TC 和 ET)存在显著的类别极度不平衡问题, 且肿瘤边缘结构通常复杂且模糊, 本研究采用了一种多任务联合监督的复合损失函数策略。网络的总损失函数由主分割损失、自监督边界预测损失以及边界加权 Dice 损失三部分构成

$$L_{\text{total}} = L_{\text{seg}} + \lambda_{\text{BPM}} L_{\text{BPM}} + \lambda_{\text{BWD}} L_{\text{BWD}} \quad (9)$$

式中, L_{total} 为总损失; L_{seg} 为主分割损失; L_{BPM} 为自监督边界预测损失; λ_{BPM} 和 λ_{BWD} 分别为边界预测与边界加权的动态平衡系数。这种动态权重策略旨在引导网络从初期的粗粒度全局语义感知平滑演进到后期的细粒度拓扑边界校正。

为在稳定全局语义优化的同时提升对极难分类样本的敏感度, 主分割损失采用二元交叉熵损失(binary cross-entropy loss, BCE Loss)、Dice 损失以及 Focal 损失按 $0.4:0.4:0.2$ 的加权组合, 其中 Focal 损失采用标准聚焦因子 $\gamma_{\text{focal}} = 2.0$, 通过指数级衰减占据多数的易分背景样本的梯度贡献, 强制模型将计算资源集中在低对比度的过渡区域。

辅助监督边界预测损失 L_{BPM} 专门用于约束 BPM 模块的边缘生成。考虑到脑肿瘤边缘极其不规则, 且单像素宽度的边界点占全图比例极低, 若直接进行严格惩罚极易引发严重的类别不平衡与梯度稀疏问题。因此, 本文基于拓扑轮廓提取算法从真实分割标签中显式生成多通道目标边界掩膜 $GT_{\text{edge}} \in \mathbb{R}^{B \times 3 \times H \times W}$, 并赋予其 2 个像素的物理线宽。

这种适当的“边界宽容度松弛”能够提供更密集的正样本分布,有效引导网络在训练中更稳定地收敛。为缓解训练初期因编码器提取的结构信息尚不成熟而引发的梯度振荡,约束权重 λ_{BPM} 在前3个epoch内由0线性预热至0.1,随后在整个训练周期内保持恒定。

边界加权复合Dice损失 L_{BWD} 是消除传统损失函数对大体积目标评估偏见、提升边缘细微结构分割精度的核心优化机制。针对每个语义类别,本文首先基于真实边界结构构造像素级空间惩罚权重,即

$$\mathbf{W}_{c,i} = 1.0 + \kappa_c \cdot \mathbf{GT}_{\text{edge}(c,i)} \quad (10)$$

式中, i 为切片中的像素级空间索引; $\mathbf{GT}_{\text{edge}(c,i)}$ 为基于真实分割标签生成的多通道目标边界掩膜 $\mathbf{GT}_{\text{edge}}$ 在类别 c 、像素 i 处的取值; κ_c 是针对不同解剖亚区设定的惩罚放大系数; $\mathbf{W}_{c,i}$ 为像素级空间惩罚权重。针对形态最为细小、错分代价极高的ET,本文赋予其最高的惩罚极值 $\kappa_3 = 2.0$,TC设为 $\kappa_2 = 1.5$,WT则设为基准惩罚系数 $\kappa_1 = 1.0$ 。

在此基础上,总边界加权损失通过对各类别加权相似性指标进行均值聚合得出

$$L_{\text{BWD}} = 1 - \frac{1}{3} \sum_{c=1}^3 \text{wDice}_c \quad (11)$$

式中, wDice_c 为类别 c 的边界加权局部重叠度量,其定义为

$$\text{wDice}_c = \frac{2 \sum_i \mathbf{W}_{c,i} p_{c,i} y_{c,i} + \epsilon}{\sum_i \mathbf{W}_{c,i} (p_{c,i} + y_{c,i}) + \epsilon} \quad (12)$$

式中, $y_{c,i} \in \{0, 1\}$ 与 $p_{c,i} \in (0, 1)$ 分别代表像素 i 在类别 c 上的真实二值标签与网络预测的概率值; $\epsilon = 10^{-5}$ 是确保数值计算稳定性的平滑项。为进一步分析空间权重对反向传播过程的影响,定义类别 c 的加权交叠项与加权体积项

$$A_c = 2 \sum_i \mathbf{W}_{c,i} p_{c,i} y_{c,i} + \epsilon \quad (13)$$

$$B_c = \sum_i \mathbf{W}_{c,i} (p_{c,i} + y_{c,i}) + \epsilon \quad (14)$$

式中, A_c 和 B_c 分别为 wDice_c 的分子项与分母项。根据商法则,边界加权损失关于像素 k 预测概率的梯度可表示为

$$\frac{\partial L_{\text{BWD}}}{\partial p_{c,k}} = \frac{\mathbf{W}_{c,k}}{3B_c^2} (A_c - 2y_{c,k} B_c) \quad (15)$$

式中, k 为任意指定像素的空间索引; $p_{c,k}$ 、 $y_{c,k}$ 分别为像素 k 处的预测概率、真实标签。当像素 k 位于真实

边界处时, $\mathbf{GT}_{\text{edge}(c,k)} = 1$,对应的空间权重为 $\mathbf{W}_{c,k} = 1 + \alpha_c$ 。该权重作为直接乘性因子提高了边界位置在概率梯度中的贡献,使网络在反向传播过程中更加关注模糊边界区域。然而,空间权重还同时参与全局统计量 A_c 和 B_c 的计算,Dice损失的商结构会通过分母 B_c^2 对同一类别内所有像素的梯度进行全局归一化。因此,边界像素的梯度并非在任意情况下均严格放大为普通像素的 $1 + \alpha_c$ 倍。只有当边界区域相对于整个目标区域较为稀疏,且加权前后 A_c 和 B_c 的变化较小时,边界梯度才可近似认为获得 $1 + \alpha_c$ 倍的线性增强;当边界像素占比较大或惩罚系数较高时,分母的同步增大会对局部梯度增益产生一定的非线性抑制。由此,BWD的作用本质上是在Dice全局归一化约束下,提高边界像素相对于普通像素的梯度优先级,而不是对其梯度进行无条件的绝对倍数放大。

对于前景像素与背景像素,上述梯度可分别表示为

$$\frac{\partial L_{\text{BWD}}}{\partial p_{c,k}} = -\frac{\mathbf{W}_{c,k} (2B_c - A_c)}{3B_c^2}, \quad y_{c,k} = 1 \quad (16)$$

$$\frac{\partial L_{\text{BWD}}}{\partial p_{c,k}} = \frac{\mathbf{W}_{c,k} A_c}{3B_c^2}, \quad y_{c,k} = 0 \quad (17)$$

当前景像素被漏分时,负梯度将推动其预测概率增大;当背景像素被误分时,正梯度将推动其预测概率减小。在相同空间权重下,定义前景与背景像素的梯度幅值之比

$$R_c = \frac{|\partial L_{\text{BWD}} / \partial p_{c,k}|_{y=1}}{|\partial L_{\text{BWD}} / \partial p_{c,k}|_{y=0}} \quad (18)$$

式中, R_c 为类别 c 在相同空间权重下前景像素与背景像素的梯度幅值之比。将式(12)代入可得其闭式表达

$$R_c = \frac{2B_c - A_c}{A_c} = \frac{2}{\text{wDice}_c} - 1 \quad (19)$$

当分割重叠度较低时,前景像素通常具有更大的修正梯度,说明Dice型目标对漏诊与误诊存在一定的不对称惩罚;随着预测结果逐渐接近真实标签,两类梯度趋于平衡。由于本文的边界掩膜由真实标签与其腐蚀结果之差获得,边界权重主要作用于目标内部的边缘像素,因而能够重点增强对边界漏分的修正,而目标外侧误分则同时受到Dice分母全局耦合的约束。该机制在维持区域重叠一致性的同时,提高了模型对细小、模糊边界的优化优先级,从

而有助于获得更加精确和连续的肿瘤轮廓。

2 实验

2.1 数据集与评估指标

本研究在公共数据集 BraTS 2019 与 BraTS 2020 上进行了全面评估,分别包含 335 和 369 个多模态 MRI 病例(包括 FLAIR, T1, T1ce, T2)(Bakas 等, 2017)。真实标签涵盖了三个嵌套的目标区域:WT、TC 及 ET。两个数据集均以患者为最小划分单位,先按 70%/30% 划分训练患者与临时患者,再将临时患者等分为验证集和测试集;两次划分均使用 random_state=42,保证同一患者的切片不会跨集合。训练随机种子为 2021。

为匹配 2D 网络架构,本研究首先从每例病例中选取轴向切片 48—107,并提取尺寸为 128×128 像素的轴向切片,同时利用 Z-score 标准化消除模态间的强度差异。为保证切片数据的有效性,本文剔除病灶区域过小的样本,仅保留同时满足以下条件的切片:肿瘤像素占比不低于 1%;WT 像素数不低于 80;若 TC 存在,其像素数须大于 35;若 ET 存在,其像素数须大于 20。BraTS 2019 共发现 335 例,328 例至少包含 1 张满足条件的切片;病例级随机划分包括 229 例训练、49 例验证和 50 例测试患者,患者集合无重叠。筛选统计见表 1 和表 2。筛选共移除 3627 张肿瘤阳性切片(23.25%)。筛选后 TC/WT 和 ET/WT 相对比例上升,说明类别不平衡有所缓解,但微小病灶切片的代表性相应降低。训练采样中 WT、TC 和 ET 的类别权重设置为 1、6 和 8,以进一步提高含 TC 和 ET 切片的采样概率。BraTS 2020 共发现 369 例患者,病例级随机划分后,训练集、验证集和测试集分别包含 253、54 和 55 例患者,三组患者无重叠。

性能评估采用 Dice 相似系数与 95% 豪斯多夫距离作为核心评价指标。

表 1 BraTS 2019 筛选前后的类别切片分布

Table 1 Class-wise slice distribution before and after filtering on BraTS 2019

阶段	WT / TC / ET 切片数
筛选前	15603 / 11531 / 9861
筛选后	11976 / 10227 / 8838

表 2 BraTS 2019 病例级留出划分与切片筛选统计

Table 2 Patient-level holdout split and slice filtering statistics on BraTS 2019

集合	患者数	阳性切片(筛选前/后)
训练集	229	10827 / 8267
验证集	49	2334 / 1750
测试集	50	2442 / 1959
合计	328	15603 / 11976

2.2 实施细节

所有实验均在单个 NVIDIA RTX 4090 GPU 上完成,基于 PyTorch 框架并采用自动混合精度(automatic mixed precision, AMP)技术加速训练。网络优化选用 AdamW 优化器,初始学习率设为 2.0×10^{-4} ,权重衰减设为 1×10^{-4} 。学习率调度采用前 5 个 epoch 的线性预热与随后的余弦退火策略。模型总训练周期为 80 个 epoch,批量大小为 24,梯度累加步数设为 2,并采用最大范数为 1.0 的梯度裁剪以防止梯度爆炸。此外,为兼顾模型训练的稳定性与科学评估的客观性,本研究在边界信息的提取上采用了双轨制策略。在模型训练的数据预处理阶段,利用拓扑轮廓寻迹算法生成线宽 2 个像素的三通道真实边界图,作为监督先验以缓解梯度稀疏问题;而在模型评估阶段,为保证空间距离测量的绝对严谨性,算法回退至单像素层级。具体为首先利用 3×3 的全一结构元素对预测掩膜与真实掩膜进行数学形态学腐蚀,并将原始掩膜与腐蚀后的掩膜进行逻辑求差(即原图减去腐蚀图),从而精准剥离出严格的单像素物理边缘,最终完成点到点几何最短距离的量化计算。在损失函数的动态权重配置方面,针对自监督边界预测损失系数 λ_{BPM} ,本文引入了动态渐进策略:在训练的前 3 个 epoch 内, λ_{BPM} 从 0 线性增加至 0.1,随后保持恒定。该设计旨在缓解训练初期编码器特征表达能力较弱时,强边界约束可能导致的梯度振荡,从而实现从粗粒度语义提取到细粒度边界矫正的平滑过渡。此外,边界加权损失系数 λ_{BWD} 采用基于训练轮次的动态调整方案,在前 8 个 epoch 内由 0.22 线性预热至峰值 0.42,并保持至第 25 个 epoch;此后在随后 20 个 epoch 内平滑衰减至 0.28。

2.3 与其他方法的比较

为全面评估 BPE-Net 的有效性与先进性,本研究在 BraTS 2019 和 BraTS 2020 两个公开基准数据集

上,将本方法与现有的多种主流医学图像分割网络进行了对比分析。如表3所示,在BraTS 2019数据集上,本方法在WT、TC和ET区域均展现出显著的性能优势,平均Dice系数达到了93.69%,平均HD95降低至1.96mm。相比于对比模型中表现最佳的Swin-Unet(平均Dice为86.26%,HD95为3.19mm),本模型的平均Dice提升7.43个百分点,平均HD95

降低1.23mm(相对降低38.6%);分区域来看,WT、TC和ET的Dice分别提高4.25、8.12和9.91个百分点,HD95分别降低1.91mm、0.83mm和0.97mm。观察图5的全局可视化结果可以发现,在整体宏观轮廓上,本方法生成的分割掩膜相较于其他主流网络展现出更高的空间保真度,总体形态高度贴合真实标签。

表3 在BraTS 2019数据集上对分割性能的定量比较
Table 3 Quantitative comparison of segmentation performance on the BraTS 2019 dataset

Methods	WT		TC		ET		Average	
	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice(%)	HD95 (mm)	Dice (%)	HD95 (mm)
Swin-Unet(Cao等,2023)	90.79	3.83	87.04	2.79	80.95	2.95	86.26	3.19
DA-TransUnet(Sun等,2024)	90.53	4.37	85.71	4.00	80.71	4.79	85.65	4.39
S2Net(Gui等,2025)	86.87	6.40	84.50	4.83	77.85	6.35	83.07	5.86
AS-WEC(Xiao等,2025)	90.65	4.73	85.65	4.20	80.26	4.25	85.52	4.39
AMIN-CNN(Depuru等,2025)	90.04	4.39	84.00	4.70	79.34	5.06	84.46	4.72
CFATrans(Goceri等,2026)	89.56	4.85	82.95	4.19	78.81	3.37	83.77	4.13
Trans-MT(Liao等,2026)	89.94	4.62	83.41	3.96	78.83	3.80	84.06	4.13
本文	95.04	1.92	95.16	1.96	90.86	1.98	93.69	1.96

注:加粗字体表示各列最优结果。




图5 在BraTS 2019数据集上不同方法脑肿瘤分割结果的定性比较(从上至下为4个代表性病例)。(a) 输入图像;(b) Swin-Unet;(c) DA-TransUNet;(d) S2Net;(e) AS-WEC;(f) AMIN-CNN;(g) CFATrans;(h) Trans-MT;(i) 本文方法;(j) 真实标签
Fig. 5 Qualitative comparison of brain tumor segmentation results among different methods on the BraTS 2019 dataset (four representative cases from top to bottom). (a) Input image; (b) Swin-Unet; (c) DA-TransUNet; (d) S2Net; (e) AS-WEC; (f) AMIN-CNN; (g) CFATrans; (h) Trans-MT; (i) Ours; (j) Ground truth

为更深层次地剖析模型在复杂解剖结构与低对比度过渡带处的细粒度重建能力,本文在图6中策略性地挑选了Swin-Unet与AS-WEC两个最具代表性的网络进行微观拓扑对比。Swin-Unet作为经典纯Transformer架构的代表,虽然具备卓越的全局上下文建模能力,但其固有的图块划分(patch partitioning)机制天然破坏了局部像素的连续性,易导致高频几何细节的丢失;而AS-WEC作为近期主打边缘感知的混合网络,高度依赖传统的外部算子来提取初始边缘,在面对低对比度、高噪声的脑部MRI图像时表现出明显的脆弱性。通过与这两类典型机制进行局部放大对比,能够较直观地说明显式边界引导策略的作用。




图6 在BraTS 2019数据集上局部边界细节分割对比。(a) 输入图像;(b) Swin-Unet;(c) AS-WEC;(d) 本文方法;(e) 真实标签。其中第2、4行为完整的全局分割结果,第1、3行分别为第2、4行中绿色框标注区域的同步放大图

Fig. 6 Comparison of local boundary detail segmentation on the BraTS 2019 dataset. (a) Input image; (b) Swin-Unet; (c) AS-WEC; (d) Ours; (e) Ground truth. The 2nd and 4th rows show the complete global segmentation results, while the 1st and 3rd rows are the synchronized zoomed-in views of the regions marked by green boxes in the 2nd and 4th rows, respectively

图6展示了两个典型病例的微观拓扑结构与边缘重建细节。从局部放大对比中可以直观地观察到,当面对形态极不规则且呈浸润性生长的肿瘤边缘时,Swin-Unet丢失了大量底层的边缘几何特征,在细小区域产生严重的边缘模糊现象和过分割现象;AS-WEC尽管捕捉到大致边缘趋势,但传统算

子对抗噪声能力不足,引发虚假的边缘响应,不可避免地导致了局部过分割与拓扑结构错误。相比之下,得益于BPM提取的类别感知空间几何先验,配合EFM的空间-通道解耦注意力机制,本文提出的BPE-Net有效缓解了局部边缘混淆。从第一、三行的绿色放大图像中可清晰地看出,本方法显著减少了过分割与边缘拓扑伪影,边界连续性与真实标签更为接近。这定性证实显式边界引导机制在恢复微观病灶拓扑结构中的有效性。

在更具挑战性的BraTS 2020数据集上,见表4,本模型依然保持稳定的鲁棒性,其平均Dice系数和平均HD95分别为92.51%和2.33mm。值得注意的是,在形态最为复杂的ET区域,本方法的Dice为88.55%,较对比方法中该区域精度最高的Swin-Unet(78.12%)提高10.43个百分点,较DA-TransUnet(76.30%)和AS-WEC(76.27%)分别提高12.25和12.28个百分点。此外,本方法的平均Dice较最优对比方法Swin-Unet(83.91%)提高8.60个百分点,平均HD95由3.76mm降至2.33mm。

结合图7的对比示例可以观察到,在病灶形态极度不规则的情况下,传统方法往往难以维持拓扑结构的连续性,而BPE-Net凭借其空间-通道解耦注意力机制,成功缓解了边缘混淆问题,实现了对细微浸润区域的精准定位与重建。定量实验与定性可视化的双重结果一致证明,通过引入辅助监督边界预测与显式特征增强机制,BPE-Net有效克服了传统CNN和Transformer架构在低对比度过渡区域的辨识瓶颈,在复杂脑肿瘤分割任务中具有较好的表现。本文从模型参数规模、理论计算量和实际推理效率三个方面评估不同方法的部署可行性,结果如表5所示。在参数规模上,BPE-Net仅包含17.629M个参数,在全部对比方法中位列第二低,仅高于S2Net;与Swin-Unet和DA-TransUnet相比,参数量分别减少57.40%和83.65%,表明BPM与EFM的引入并未带来明显的参数膨胀。与此同时,BPE-Net在BraTS2019上取得93.69%的平均Dice,较精度最高的对比方法Swin-Unet提升7.43个百分点,说明新增的边界建模模块以较小的参数代价换取了显著的分割性能增益。在理论计算量方面,BPE-Net为35.282 GFLOPs,略高于多数对比方法,这主要源于BPM对编码器多尺度特征的对齐聚合与EFM在高分辨率解码阶段的空间-通道解耦增强。需要指出

表4 BraTS 2020数据集上对分割性能的定量比较
Table 4 Quantitative comparison of segmentation performance on the BraTS 2020 dataset

Methods	WT		TC		ET		Average	
	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)
Swin-Unet(Cao等,2023)	90.18	4.04	83.42	3.71	78.12	3.54	83.91	3.76
DA-TransUnet(Sun等,2024)	90.19	4.08	80.71	7.64	76.30	6.93	82.40	6.22
S2Net(Gui等,2025)	87.18	7.25	80.94	6.30	74.12	6.69	80.75	6.75
AS-WEC(Xiao等,2025)	90.44	4.25	81.81	6.90	76.27	6.01	82.84	5.72
AMIN-CNN(Depuru等,2025)	90.29	4.12	81.10	7.16	75.63	7.23	82.34	6.17
CFATrans(Goceri等,2026)	89.37	4.79	79.71	6.26	76.24	5.37	81.78	5.47
Trans-MT(Liao等,2026)	89.41	4.42	80.75	4.92	76.65	4.67	82.27	4.67
本文	94.08	2.37	94.91	2.08	88.55	2.55	92.51	2.33

注:加粗字体表示各列最优结果。

的是,浮点运算次数(floating point operations, FLOPs)仅刻画理论运算次数,并不能反映算子并行度、显存访问与硬件调度效率,因而无法直接代表模型在实际部署中的运行速度。因此,本文以更贴近

临床部署需求的推理帧率(frames per second, FPS)与单张切片推理时延(ms/slice)作为衡量效率的主要指标。




图7 在BraTS 2020数据集上不同方法脑肿瘤分割结果的定性比较(从上至下为4个代表性病例)。(a) 输入图像;(b) Swin-Unet;(c) DA-TransUNet;(d) S2Net;(e) AS-WEC;(f) AMIN-CNN;(g) CFATrans;(h) Trans-MT;(i) 本文方法;(j) 真实标签
Fig. 7 Qualitative comparison of brain tumor segmentation results among different methods on the BraTS 2020 dataset (four representative cases from top to bottom). (a) Input image; (b) Swin-Unet; (c) DA-TransUNet; (d) S2Net; (e) AS-WEC; (f) AMIN-CNN; (g) CFATrans; (h) Trans-MT; (i) Ours; (j) Ground truth

在统一测试环境下,BPE-Net达到 383.59 ± 0.18 FPS,单张切片推理时间仅为 2.607 ± 0.001 ms,实际推理效率在全部方法中位列第二。与Swin-Unet相比,其推理吞吐率提升约2.73倍、单

slice时延降低64.03%;与DA-TransUNet相比,吞吐率提升约3.33倍、时延降低70.02%。可见,尽管理论FLOPs略高,BPM与EFM增加的计算量并未转化为实际推理瓶颈,模型仍能保持毫秒级的高吞吐

推理。

表5 在BraTS 2019数据集上各方法计算复杂度与推理效率比较

Table 5 Comparison of computational complexity and inference efficiency of different methods on the BraTS 2019 dataset

Methods	Params (M)	FLOPs (G)	FPS	Inference time (ms/slice)	Average Dice (%)
Swin-UNet(Cao 等, 2023)	41.386	5.689	140.54 ± 20.69	7.248 ± 1.130	86.26
DA-TransUNet(Sun 等, 2024)	107.850	16.603	115.04 ± 2.12	8.695 ± 0.162	85.65
S2Net(Gui 等, 2025)	9.506	16.259	170.78 ± 17.83	5.909 ± 0.645	83.07
AS-WEC(Xiao 等, 2025)	34.753	32.870	16.31 ± 0.83	61.436 ± 3.263	85.52
AMIN-CNN(Depuru 等, 2025)	20.010	2.444	146.44 ± 2.51	6.830 ± 0.117	84.46
CFATrans(Goceri 等, 2026)	71.343	169.901	115.78 ± 0.40	8.637 ± 0.030	83.77
Trans-MT(Liao 等, 2026)	17.996	2.472	535.74 8.81	1.867 0.031	84.06
本文	17.629	35.282	383.59 ± 0.18	2.607 ± 0.001	93.69

注:加粗字体表示各列最优结果。

尽管 Trans-MT 以 535.74 ± 8.81 FPS 取得最高帧率,但其 BraTS 2019 平均 Dice 仅为 84.06%,较 BPE-Net 低 9.63 个百分点;BPE-Net 的单 slice 时延虽较其增加约 39.64%,但仍稳定保持在 3ms 以内,同时以更低的参数量获得明显更高的分割精度。综合参数规模、推理速度与分割精度来看,BPE-Net 在三者之间取得了更均衡的折中:其优势在于以较低的参数量和毫秒级的实际推理速度,实现当前最优的分割精度,从而具备面向临床辅助分析场景进一步部署优化的潜力。

2.4 消融实验

2.4.1 核心模块消融

本文首先验证 BPM 和 EFM 对整体网络性能的核心价值。如表 6 所示,仅包含主干网络的 Baseline 模型在处理复杂的肿瘤边界时表现受限,其平均 Dice 为 86.31%,HD95 为 4.58mm。

在 Baseline 上仅引入 BPM,并使用边界损失对其输出进行独立监督,而不将预测边界输入 EFM。该模型取得了 86.41% 的平均 Dice 和 4.65mm 的平均 HD95,较 Baseline 分别提升 0.1 个百分点和增加 0.07mm。这表明 BPM 不依赖 EFM 也能够作为辅助任务独立优化,其边界监督梯度可通过共享编码器促进网络学习对几何突变更敏感的特征。当单独引入 EFM 后,模型平均 Dice 达到 93.57%,平均 HD95 降至 2.07mm,说明空间一通道解耦增强有助于改善边界区域的特征判别能力。在此基础上,同时启

用 BPM 与 EFM 后,完整模型获得 93.69% 的平均 Dice 和 1.96mm 的平均 HD95。这表明 BPM 能够独立提供辅助边界监督并约束边界表征,但缺少显式注入时对最终分割的传递有限。而 EFM 进一步建立了预测边界与解码特征之间的直接交互路径。二者联合使用能够将边界表征学习转化为显式特征校正,在区域重叠精度与边界距离指标之间取得更优平衡。

2.4.2 动态策略对比

为考察边界加权 Dice 损失权重 λ_{BWD} 的取值与调度方式对分割性能的影响,本文在保持患者划分及其他训练参数一致的前提下,对 λ_{BWD} 进行敏感性分析,结果见表 7。一方面,固定动态调度形式、仅改变峰值权重,在 $\{0.20, 0.30, 0.42, 0.50\}$ 范围内进行网格搜索。随峰值增大,平均 Dice 呈现先升后降的单峰趋势(分别为 93.70%、93.76%、93.97%、93.82%),平均 HD95 在峰值 0.42 处最低(1.85mm):峰值过小时边界约束不足,过大时边界项过度主导而抑制区域重叠一致性;峰值 0.42 在平均 Dice 与平均 HD95 上同时取得最优,故最终选定 λ_{BWD} 峰值为 0.42。另一方面,在相同峰值 0.42 下比较动态调度与固定权重两种策略:动态调度的平均 Dice 为 93.97%、平均 HD95 为 1.85mm,固定权重为 93.90%、1.89mm。动态策略在综合平均 Dice (+0.07 个百分点)与平均 HD95 (-0.04mm)上均略优,表明前期预热与后期衰减有助于缓解训练初期

表 6 核心模块消融实验
Table 6 Ablation study of the core modules

Configurations	WT		TC		ET		Average	
	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)
Baseline	90.93	4.31	86.56	4.40	81.44	5.02	86.31	4.58
Baseline+BPM	90.94	4.28	86.68	4.60	81.60	5.06	86.41	4.65
Baseline+EFM	94.41	2.17	95.57	2.03	90.73	2.00	93.57	2.07
Baseline+EFM+BPM	95.04	1.92	95.16	1.96	90.86	1.98	93.69	1.96

注:加粗字体表示各列最优结果。

边界结构不成熟引起的优化波动,并在后期抑制过拟合。就单项指标而言,固定权重仅在 WT 的 Dice (94.97% 对 94.95%) 和 ET 的 HD95 (1.82mm 对 1.85mm)上略优,而动态调度在 WT/TC 的 HD95、TC/

ET 的 Dice 以及总体平均 Dice 和平均 HD95 上均更优。综合来看, λ_{BWD} 采用峰值 0.42 的动态调度在区域重叠与边界距离之间取得了更均衡的整体表现。

表 7 损失权重敏感性分析
Table 7 Sensitivity analysis of loss weights

BPM 辅助权重	BWD 配置	WT		TC		ET		Average	
		Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)
前 3 epoch 由 0→0.10	动态,峰值 0.42	94.95	1.87	95.82	1.85	91.12	1.85	93.97	1.85
前 3 epoch 由 0→0.10	固定 0.42	94.97	1.93	95.73	1.93	91.00	1.82	93.90	1.89
前 3 epoch 由 0→0.10	动态,峰值 0.20	93.91	2.07	95.98	1.71	91.22	1.96	93.70	1.91
前 3 epoch 由 0→0.10	动态,峰值 0.30	94.73	2.04	95.64	2.26	90.91	1.94	93.76	2.08
前 3 epoch 由 0→0.10	动态,峰值 0.50	94.94	2.03	95.88	1.81	90.64	2.17	93.82	2.00

注:加粗字体表示各列最优结果。

2.4.3 EFM 模块特征注入层级消融

在解码器中,不同层级的特征图蕴含着截然不同的信息:浅层特征空间分辨率高但包含大量冗余的语义噪声;深层特征语义高度抽象,但高频空间细

节严重丢失。如表 8 所示,为探寻边界先验注入的最佳“平衡点”,本文针对 EFM 模块在不同解码层级的注入策略进行详尽的消融实验。

表 8 EFM 特征注入层级消融实验
Table 8 Ablation study of EFM feature injection levels

Injection Level	WT		TC		ET		Average	
	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)
up4	91.72	4.07	90.42	3.11	87.96	4.29	90.03	3.82
up2 + up3 + up4	93.26	2.23	94.79	2.33	91.07	2.12	93.04	2.22
up2	90.72	4.22	86.71	4.18	81.47	5.04	86.30	4.48
up3 + up4 (本文)	94.18	2.17	95.28	2.03	90.73	2.00	93.40	2.06

注:加粗字体表示各列最优结果。

实验数据清晰地揭示了特征层级对拓扑重建的剧烈影响。当仅在最深层(up4,分辨率最低)进行特征注入时,模型的平均Dice仅为90.03%,在对边缘最为敏感的ET区域Dice值仅有87.96%。这是因为在极低的分辨率下,细微的边界几何信息已被严重压缩和平滑,此时注入高频边界先验往往会引发特征表达的冲突。相反,若仅在最浅层(up2,分辨率最高)进行单点注入,模型的平均Dice骤降至全组最低的86.30%,HD95更是恶化至4.48mm。产生这种现象的根本原因在于,最浅层特征尚未经过充分的深层语义过滤,此时过早地引入强边界约束,会导致网络将大量背景噪声与正常组织的微小纹理误认为肿瘤边缘,进而引发极其严重的过分割现象。

此外,本文还测试了全层级级联注入策略(up2 + up3 + up4)。尽管其性能(平均Dice 93.04%)较单

一浅层注入有大幅提升,但仍劣于本文提出的组合。引入up2层不仅未能带来增益,反而因为冗余的底层噪声稀释了高层语义的纯度。综合上述分析,本文最终确立了“up3 + up4”的联合注入策略。在本组注入层级消融中,该策略在保留深层强语义表征与恢复浅层细微结构之间取得了较好折中,平均Dice为93.40%、平均HD95为2.06mm,优于仅在单一级(up2、up4)注入以及全层级级联(up2+up3+up4)的方案。

2.4.4 BPM模块特征融合层级消融

BPM模块的核心任务是生成可靠的类别感知边界先验,而高质量边界先验的提取高度依赖于输入特征的感受野尺度。如表9所示,本文对提取边界先验的编码器特征融合尺度进行系统的消融对比。

表9 BPM特征融合层级消融实验
Table 9 Ablation study of BPM feature fusion levels

Feature Levels	WT		TC		ET		Average	
	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)
x1	94.65	2.21	95.92	2.00	90.60	2.15	93.73	2.12
x1 + x2	95.06	2.04	95.26	2.25	90.95	2.02	93.76	2.11
x2 + x3	95.19	2.04	95.03	2.21	90.86	2.15	93.69	2.13
x1 + x2 + x3 (本文)	95.17	1.91	95.49	1.98	90.93	1.93	93.86	1.94

注:加粗字体表示各列最优结果。

观察数据可知,当仅利用单一的高分辨率特征(x1)时,模型获得了93.73%的平均Dice。这说明最浅层特征由于未经过多层卷积降采样,确实保留了最原始的绝对位置信息与锐利的物理边缘;然而,感受野极其狭窄,x1缺乏足够的宏观上下文来区分“肿瘤真实边界”与“大脑正常沟回的灰度突变”,导致模型在形态最复杂的ET区域(90.60%)存在一定的识别瓶颈。另一方面,当摒弃浅层特征,仅融合较深层特征(x2 + x3)时,由于感受野的扩大,模型对大体积目标的感知增强,因此在WT区域取得了95.19%的优异表现;但由于深层特征固有的空间下采样信息流失,其在刻画精细的ET和TC边缘时表现出了明显的乏力,平均HD95退化至2.13mm。

为兼顾宏观定位与微观细节,本文的BPM模块最终采用了跨越三个尺度的特征聚合方案(x1 + x2 + x3)。如表9所示,在本组特征融合消融中,该组合

取得最优平均Dice(93.86%)与最低平均HD95(1.94mm),优于单尺度(x1)及双尺度(x1+x2、x2+x3)方案。这表明BPM内部多尺度聚合机制的必要性:通过将x1提供的高频物理边缘响应与x2、x3提供的低频宏观语义支撑互补融合,BPM能够过滤非肿瘤区域的伪影边缘,生成兼具宏观轮廓与高保真细节的几何先验。

2.5 患者级五折交叉验证与稳定性分析

为评估BPE-Net对患者划分变化的敏感性及其在同一数据集内的稳定性,本文在BraTS 2019数据集上开展了患者级五折交叉验证,结果见表10。

本文在外层五折划分中严格采用病例级互斥策略,335例中,328例满足预设二维切片纳入条件,7例因无有效切片被排除。五个外层测试折分别包含66、66、66、65和65例患者;每折从非测试患者中划分33例作为内部验证集,其余229或230例用于训

练,三者患者集合无重叠。划分种子为 2021,外层 测试折不参与模型选择,测试阈值为 0.5。

表10 BPE-Net在BraTS 2019上的患者级五折交叉验证结果
Table 10 Patient-level five-fold cross-validation results of BPE-Net on BraTS 2019

Fold	WT		TC		ET		Average	
	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)	Dice (%)	HD95 (mm)
1	93.27	2.567	94.56	2.184	91.85	1.507	93.23	2.086
2	94.20	2.209	94.87	2.006	91.81	1.468	93.63	1.894
3	94.94	1.869	94.26	2.404	90.58	1.709	93.26	1.994
4	95.03	2.425	93.58	2.216	89.93	1.735	92.85	2.125
5	94.86	2.219	92.44	2.638	88.43	2.273	91.91	2.377
Mean±SD	94.46±0.74	2.258±0.264	93.94±0.97	2.290±0.241	90.52±1.43	1.738±0.321	92.97±0.66	2.095±0.181

注:加粗字体表示各列最优结果,SD为标准差(standard deviation)。

五折评估的平均 Dice 系数达到 92.97%±0.66%,平均 HD95 为 2.095±0.181mm。分区域统计显示,WT、TC 和 ET 的 Dice 分别为 94.46%±0.74%、93.94%±0.97% 和 90.52%±1.43%。其中,ET 的标准差高于 WT 和 TC,表明面积较小且形态复杂的增强肿瘤区域对患者划分变化更为敏感。总体而言,五折交叉验证结果表明,BPE-Net 在 BraTS 2019 不同患者划分下的平均性能保持稳定、波动较小,说明方法在同一数据集内具有较好的稳健性。需要说明的是,本实验采用的是数据集内部的患者级划分,主要用于考察模型对患者分组变化的敏感性;而对于不同中心、不同磁场强度(如 1.5T 与 3T)以及不同扫描协议下的表现,仍有待在包含明确机构与设备信息的独立外部队列上进一步评估。因此,在具备跨中心、跨设备标注信息的数据上开展外部验证,并结合跨数据集迁移系统考察模型的泛化能力,是本文后续工作的重点方向之一。

3 结 论

针对多模态 MRI 脑肿瘤分割中面临的病灶形态异质性强、边界极度模糊以及过渡区域特征混淆等核心挑战,本文提出了一种融合显式边界先验与解耦注意力的多模态脑肿瘤分割网络(BPE-Net)。该架构通过 BPM 模块从编码器多尺度特征中自适应提取类别感知的空间几何先验,并借助 EFM 模块的空间-通道解耦注意力机制,在解码器的高分辨率层级(up3 和 up4)以残差方式将几何先验注入解码特

征,从而形成边界预测、辅助约束与特征增强相协同的分割框架。

在 BraTS 2019 与 BraTS 2020 基准数据集上的系统评估,以及患者级五折交叉验证结果表明,BPE-Net 的平均 Dice 分别达到 93.69% 和 92.51%,平均 HD95 分别为 1.96mm 和 2.33mm,且在不同患者划分下保持稳定。在此基础上,本文认为该方法仍有进一步拓展的空间:一方面,当前评估主要基于公开基准数据集的内部划分,后续将在具有明确机构与扫描设备信息的独立临床队列上开展跨中心、跨设备(如 1.5T 与 3T)的外部泛化验证,并辅以跨数据集迁移评估;另一方面,本文将进一步探索模型轻量化、缺失模态自适应以及三维上下文建模等方向,以提升方法在真实临床场景中的适用性与鲁棒性。

参考文献(References)

Bakas S, Akbari H, Sotiras A, Bilello M, Rozycki M, Kirby J S, et al. 2017. Advancing The Cancer Genome Atlas glioma MRI collections with expert segmentation labels and radiomic features. Scientific Data, 4: 170117 [DOI: 10.1038/sdata.2017.117]
Cao H, Wang Y Y, Chen J, Jiang D S, Zhang X P, Tian Q, et al. 2023. Swin-Unet: Unet-like pure transformer for medical image segmentation // European Conference on Computer Vision (ECCV 2022) Workshops. Cham: Springer: 205-218 [DOI: 10.1007/978-3-031-25066-8_9]
Chen L C, Papandreou G, Kokkinos I, Murphy K, and Yuille A L. 2018. DeepLab: Semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected CRFs. IEEE Transactions on Pattern Analysis and Machine Intelligence, 40

- (4): 834-848 [DOI: 10.1109/TPAMI.2017.2699184]
- Çiçek Ö, Abdulkadir A, Lienkamp S S, Brox T, and Ronneberger O. 2016. 3D U-Net: Learning dense volumetric segmentation from sparse annotation // International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2016). Cham: Springer International Publishing: 424-432 [DOI: 10.1007/978-3-319-46723-8_49]
- Depuru S, and Kumar M S. 2025. AMIN-CNN: Enhancing Brain Tumor Segmentation through Modality-Aware Normalization and Deep Learning. *Journal of Electronics, Electromedical Engineering, and Medical Informatics*, 7 (3): 835-849 [DOI: 10.35882/jeeemi.v7i3.934]
- Ding Y, Zheng W, Geng J, Qiu L Y, and Qin Z G. 2023. Multi-level parallel neural networks based multimodal human brain tumor image segmentation framework. *Journal of Image and Graphics*, 28 (7): 2182-2194 (丁熠, 郑伟, 耿技, 邱沛谊, 秦志光. 2023. 基于多层级并行神经网络的多模态脑肿瘤图像分割框架. *中国图象图形学报*, 28(7): 2182-2194) [DOI: 10.11834/jig.211197]
- Göçeri E, and Winter Y D. 2026. CFATrans: Brain tumor segmentation from MRIs using Consecutive Fusion-Attention transformer with convolutional networks and a composite loss function. *Biomedical Signal Processing and Control*, 112: 108370 [DOI: 10.1016/j.bspc.2025.108370]
- Gui C Z, An X W, Liu S, and Ming D. 2025. S2Net: Self-adaptive weighted fusion and self-adaptive aligned network for multi-modal MRI segmentation. *Medical Physics*, 52(6): 4175-4187 [DOI: 10.1002/mp.17742]
- Jiang H T, Wang Q Z, Huang Y L, Zhang Y Q, and Hu K. 2023. Medical Image Segmentation Based on Multi-scale Edge Guidance. *Computer Science*, 50(11A): 220900059-7 (姜灏天, 王琦智, 黄扬林, 章雅琴, 胡凯. 2023. 基于边缘引导的多尺度医学影像分割方法. *计算机科学*, 50(11A): 220900059-7) [DOI: 10.11896/jsjx.220900059]
- Liao Y H, Zheng Y, Jiao Y J, Tang N, Wang Y H, Hu Y, et al. 2026. Trans-MT: a 3D semi-supervised glioma segmentation model integrating transformer architecture and asymmetric data augmentation. *Displays*, 93: 103365 [DOI: 10.1016/j.displa.2026.103365]
- Lin J W, Lin J T, Lu C, Chen H, Lin H, Zhao B C, et al. 2023. CKD-TransBTS: Clinical Knowledge-Driven Hybrid Transformer with Modality-Correlated Cross-Attention for Brain Tumor Segmentation. *IEEE Transactions on Medical Imaging*, 42(8): 2451-2461 [DOI: 10.1109/TMI.2023.3250474]
- Louis D N, Perry A, Reifemberger G, von Deimling A, Figarella-Branger D, Cavenee W K, et al. 2016. The 2016 World Health Organization classification of tumors of the central nervous system: a summary. *Acta Neuropathologica*, 131(6): 803-820 [DOI: 10.1007/s00401-016-1545-1]
- Menze B H, Jakab A, Bauer S, Kalpathy-Cramer J, Farahani K, Kirby J, et al. 2015. The multimodal brain tumor image segmentation benchmark (BRATS). *IEEE Transactions on Medical Imaging*, 34 (10): 1993-2024 [DOI: 10.1109/TMI.2014.2377694]
- Milletari F, Navab N, and Ahmadi S A. 2016. V-Net: Fully convolutional neural networks for volumetric medical image segmentation // International Conference on 3D Vision (3DV 2016). Stanford: IEEE: 565-571 [DOI: 10.1109/3DV.2016.79]
- Ronneberger O, Fischer P, and Brox T. 2015. U-Net: Convolutional networks for biomedical image segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2015). Cham: Springer International Publishing: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]
- Song J L, Lü X Q, and Gu Y. 2024. Brain tumor image segmentation based on Semantic Flow Guided Sampling and Attention Mechanism. *Optics and Precision Engineering*, 32(4): 565-577 (宋建丽, 吕晓琪, 谷宇. 2024. 语义流引导采样结合注意力机制的脑肿瘤图像分割. *光学精密工程*, 32(4): 565-577) [DOI: 10.3718/OPE.20243204.0565]
- Sun G Q, Pan Y Z, Kong W K, Xu Z C, Ma J H, Racharak T, et al. 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]
- Wu X S, Yang Q H, Tang C S, and Sun J D. 2023. Multimodal Brain Tumor MR Image Segmentation Network Fused with Attention Mechanism. *Journal of Computer-Aided Design & Computer Graphics*, 35(9): 1429-1438 (毋小省, 杨奇鸿, 唐朝生, 孙君顶. 2023. 融合注意力机制的多模态脑肿瘤 MR 图像分割. *计算机辅助设计与图形学学报*, 35(9): 1429-1438) [DOI: 10.3724/SP.J.1089.2023.19694]
- Xia J M, Tan L, and Liang Y. 2023. Application of LMD-UNET Network in Multi-Modal MRI Images Segmentation of Brain Tumors. *Chinese Journal of Biomedical Engineering*, 42(4): 431-441 (夏景明, 谈玲, 梁颖. 2023. LMD-UNet 网络在脑肿瘤多模态 MRI 图像分割中的应用. *中国生物医学工程学报*, 42(4): 431-441) [DOI: 10.3969/j.issn.0258-8021.2023.04.006]
- Xiao L Y, Zhou B X, and Fan C D. 2025. Automatic brain MRI tumors segmentation based on deep fusion of weak edge and context features. *Artificial Intelligence Review*, 58(5): 154 [DOI: 10.1007/s10462-025-11151-8]
- Xing J and Zhang J. 2025. Segmentation of Brain Tumors Using a Multi-Modal Segment Anything Model (MSAM) with Missing Modality Adaptation. *Bioengineering*, 12(8): 871 [DOI: 10.3390/bioengineering12080871]
- Xing Z H, Yu L Q, Wan L, Han T, and Zhu L. 2022. NestedFormer: Nested Modality-Aware Transformer for Brain Tumor Segmentation // International Conference on Medical Image Computing and Computer-Assisted Intervention (MICCAI 2022). Singapore: Springer: 140-150 [DOI: 10.1007/978-3-031-16443-9_14]
- Zeng Y. 2025. AEEM-Net: adaptive edge enhancement network for

robust medical image segmentation // Fourth International Conference on Electronics Technology and Artificial Intelligence (ETAI 2025). SPIE, 13692: 136928D [DOI: 10.1117/12.3068593]

Zhang Y H, Bai Z Y, You Y L, and Li Z K. 2024. Adaptive modal fusion dual encoder MRI brain tumor segmentation network. Journal of Image and Graphics, 29(3): 768-781 (张奕涵, 柏正尧, 尤逸琳, 李泽锴. 2024. 自适应模态融合双编码器MRI脑肿瘤分割网络. 中国图象图形学报, 29(3): 768-781) [DOI: 10.11834/jig.230275]

Zhou Z, Siddiquee M M R, Tajbakhsh N, and Liang J. 2020. UNet++: Redesigning skip connections to exploit multiscale features in image segmentation. IEEE Transactions on Medical Imaging, 39(6): 1856-1867 [DOI: 10.1109/TMI.2019.2959609]

作者简介

张兴鹏,男,讲师,主要研究方向为计算机视觉、医学影像计算、自然语言处理、深度学习等。E-mail:xpzhang@swpu.edu.cn

刘晓鹏,男,硕士研究生,主要研究方向为医学影像计算等。E-mail:jdlxp1314@163.com

李伟,男,硕士研究生,主要研究方向为医学影像计算、深度学习等。E-mail:lix1912025@163.com

王秋里,通信作者,男,副研究员,主要研究方向为医学影像计算、深度学习等。E-mail:wangqiuli@tmmu.edu.cn