

## 特约论文



黄俊 副教授, 硕士/博士生导师, 安徽工业大学计算机科学与技术学院副院长(主持工作)、大数据挖掘与智能计算科研团队负责人。中国科学院大学博士, 东京大学博士后(特任研究员)。入选安徽省高校优秀青年人才支持计划、安徽工业大学青年拔尖人才“青年学者”培养对象。兼任安徽省人工智能学会常务理事、安徽省计算机学会理事、安徽省计算机学会青工委副主任、CCF多媒体专委会执委、*Intelligent Data Analysis* 编委及《安徽工业大学学报(自然科学版)》青年编委。主要从事数据挖掘、机器学习相关领域研究, 作为项目负责人承担了国家自然科学基金、CCF-蚂蚁科研基金、安徽省高校协同创新项目、安徽省高校优秀青年人才支持计划重点项目等课题。近年来, 发表学术论文30余篇, 其中以第一或通信作者发表CCF A/B类国际期刊和会议论文9篇, 获中国科学院院长优秀奖、中国科学院百篇优秀博士学位论文奖、ACM中国新星奖(合肥分会)、安徽省科技进步奖三等奖2项。

## 融合多尺度感知与模糊边界建模的息肉分割网络

王孙宾, 石刘伟, 黄俊

(安徽工业大学 计算机科学与技术学院, 安徽 马鞍山 243032)

**摘要:** 内窥镜图像分割技术作为常规临床诊断手段, 其分割精度直接影响对病变区域的诊断和治疗决策。针对现有方法在图像质量不佳、病变区域边界模糊等复杂场景下的局限性, 提出一种融合多尺度特征感知与模糊边界建模的息肉分割网络。首先, 通过离散小波变换将图像分解为不同尺度和频率的子带, 分别提取图像全局结构和局部细节特征, 并结合自适应注意力机制动态调整各子带特征权重, 实现多尺度特征感知。其次, 采用变分多采样模块将特征映射至潜在空间进行概率分布建模, 通过多次重参数化采样生成多样化潜在空间表示, 有效平滑模糊区域并提高边界分割准确性。在CVC-300, CVC-ClinicDB, Kvasir-SEG, CVC-ColonDB, ETIS-LaribPolyDB等5个公开数据集和USTCAI非公开数据集上进行实验, 验证本文方法的性能。结果表明: 本文方法在mDice系数和mIoU指标上均优于现有方法, 特别是在ETIS-LaribPolyDB数据集上以57.54%的mDice系数超越现有最优方法7.16%, 在CVC-ClinicDB数据集上达到91.88%的mDice系数, 展现出优异的复杂场景分割性能和泛化能力。本文方法通过融合多尺度特征感知与模糊边界建模技术, 有效解决了内窥镜图像分割中的关键难题, 为临床诊断提供了更精准可靠的技术支持。

**关键词:** 息肉图像; 图像分割; 特征感知; 模糊边界; 边界建模; 注意力机制; 智慧医疗

**中图分类号:** TP 391 **文献标志码:** A **doi:** 10.12415/j.issn.1671-7872.25009



收稿日期: 2025-01-22

基金项目: 国家自然科学基金项目(61806005); 安徽高校协同创新项目(GXXT-2022-052); 安徽省高校优秀青年人才支持计划项目(gxyqZD2022032)

作者简介: 王孙宾(2000—), 男, 安徽池州人, 硕士生, 主要研究方向为计算机视觉。

通信作者: 黄俊(1985—), 男, 安徽马鞍山人, 博士, 副教授, 主要研究方向为计算机视觉。

引文格式: 王孙宾, 石刘伟, 黄俊. 融合多尺度感知与模糊边界建模的息肉分割网络[J]. 安徽工业大学学报(自然科学版), 2025, 42(5):498-509.

# Polyp Segmentation Network Based on Multi-scale Feature Perception and Fuzzy Boundary Modeling

WANG Sunbin, SHI Liuwei, HUANG Jun

(School of Computer Science & Technology, Anhui University of Technology, Maanshan 243032, China)

**Abstract:** Endoscopic image segmentation technology as a routine clinical diagnostic method, whose segmentation accuracy directly affects physicians' diagnosis and treatment decisions of lesion areas. In view of the limitations of existing methods in challenging scenarios such as poor image quality and blurred lesion area boundaries, a polyp segmentation network integrating multi-scale feature perception and fuzzy boundary modeling was proposed. Firstly, the image was decomposed into sub-bands of different scales and frequencies through discrete wavelet transform to extract global structural and local detailed features, while an adaptive attention mechanism was employed to dynamically adjust the weights of each sub-band feature, achieving multi-scale feature perception. Secondly, a variational multi-sampling module was utilized to map features into latent space for probability distribution modeling, where diversified latent space representations were generated through multiple reparameterized samplings, effectively smoothing blurred regions and improving boundary segmentation accuracy. Experiments were conducted on five public datasets (CVC-300, CVC-ClinicDB, Kvasir-SEG, CVC-ColonDB, ETIS-LaribPolyDB) and the non-public USTCAI dataset to validate the performance of the proposed method. The results demonstrate that the proposed method outperforms existing methods in both Dice coefficient and mIoU metrics. Particularly on the ETIS-LaribPolyDB dataset, mDice coefficient of 57.54% is achieved, surpassing the state-of-the-art method by 7.16%, while on the CVC-ClinicDB dataset, an outstanding mDice coefficient of 91.88% is attained, exhibiting excellent segmentation performance and generalization capability in complex scenarios. By combining multi-scale feature perception with fuzzy boundary modeling techniques, the proposed method effectively addresses key challenges in endoscopic image segmentation, providing more accurate and reliable technical support for clinical diagnosis.

**Keywords:** polyp images; image segmentation; feature perception; fuzzy boundary; boundary modeling; attention mechanism; smart medical

结肠直肠癌作为全球高发的恶性肿瘤<sup>[1-2]</sup>, 早期发现并切除息肉可显著降低其癌变风险。内窥镜图像分割技术是一种常规的临床诊断手段, 其利用计算机辅助诊断技术能够实现息肉的自动精准分割, 从而减少人工干预并辅助医生进行诊断治疗<sup>[3-4]</sup>。在国家大力推进人工智能与医疗健康深度融合的背景下, 内窥镜下息肉精准分割技术已成为智慧医疗发展的关键突破口<sup>[5]</sup>。尽管内窥镜技术能够获取消化道内病灶的直观图像, 但在实际临床应用中仍面临挑战: 一方面, 内窥镜图像质量易受操作者技术水平影响, 常出现运动模糊、镜面反射等干扰问题; 另一方面, 息肉与正常组织间的边界往往模糊不清, 特别对于平坦型和微小息肉, 其细微的特征差异给精准分割带来困难。这些因素严重制约了智慧医疗产品的临床应用效果。因此, 深入开展内窥镜图像分割技术研究, 对于推动消化道疾病早筛早诊的智能化转型、提升基层诊疗水平具有重要的战略意义。

目前, 随着深度学习技术的快速发展, 图像分割

领域取得了显著进展<sup>[6-8]</sup>, 这些技术突破为医学图像分割, 尤其是具有重要临床意义的息肉分割提供了新的研究思路。其中, UNet<sup>[9]</sup> 凭借其独特的编码器-解码器架构跳跃连接机制, 在医学图像分割领域表现出卓越性能, 成为该领域的基准模型。基于此, Huang 等<sup>[10]</sup> 通过引入全尺度跳跃连接和深度监督机制, 进一步提升模型的分割精度。近年来, Transformer<sup>[11]</sup> 因其强大的特征建模能力在计算机视觉领域取得显著成效, 为医学图像分割技术的发展提供了新动力。Chen 等<sup>[12]</sup> 首次将 Transformer 结构整合至 UNet 框架; Lin 等<sup>[13]</sup> 基于轻量级 SwinTransformer<sup>[14]</sup> 提出了包含双分支 Transformer 模块的 DS-TransUNet; Cao 等<sup>[15]</sup> 则采用纯 Transformer 架构, 利用具有移位窗口的分层 SwinTransformer 实现了多尺度上下文特征提取。然而, 基于 Transformer 的模型通常需要大规模训练数据, 而现有息肉分割数据集规模有限, 容易导致模型过拟合。注意力机制因其在有限样本数据条件下优异的特征提取能力而受到广泛关注。Fan

等<sup>[16]</sup>采用反向注意力机制挖掘深层特征信息,Wei等<sup>[17]</sup>则利用浅层注意力模块抑制低级特征中的背景噪声。但现有研究方法在注意力建模方面仍难以实现有效的多尺度特征融合,且对模糊边界的建模能力有限。为此,提出一种融合多尺度特征感知与模糊边界建模的息肉分割网络 (multiscale feature perception and fuzzy boundary modeling based polyp segmentation network, MFNet),采用变分自编码器对编码器输出特征进行多次采样,实现精准的边界建模,同时引入小波变换增强注意力机制的多尺度特

征感知能力,以期为息肉图像分割提供更可靠的技术方案。

### 1 MFNet 的架构

本文提出的 MFNet 整体框架如图 1。该网络采用编码器-解码器基础框架,并集成变分多采样模块 (variational multi-sampling module, VMSM) 与小波注意模块 (wavelet attention module, WAM), 通过结合分割损失与 KL(Kullback-Leibler) 散度对网络参数进行联合优化。

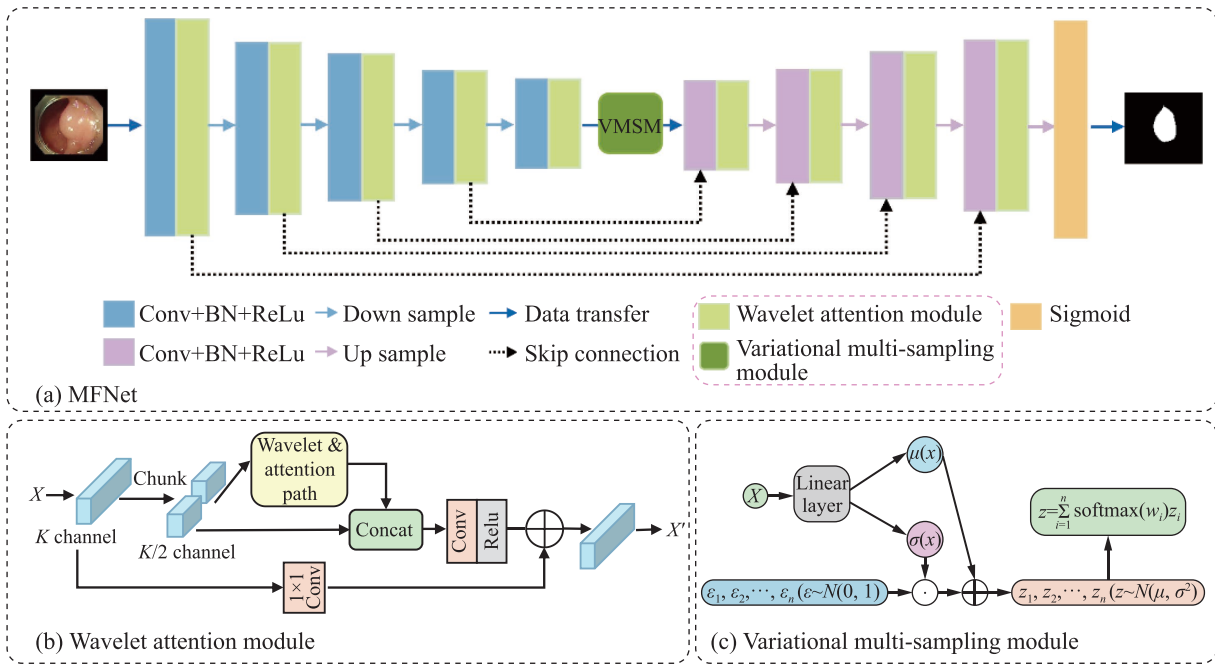


图1 MFNet 的整体框架

Fig. 1 Overall framework of MFNet

#### 1.1 小波注意模块

针对小目标病变在全局特征建模过程中易被低频特征 (图像主体信息) 遮蔽的关键问题,本文提出基于离散小波变换 (discrete wavelet transform, DWT) 与自适应注意力机制的小波注意模块 (如图 2), 其工作流程如图 3。该模块首先通过 DWT 将输入特征分解为多频率子带, 随后采用自适应注意力机制对不同频率特征进行动态权重分配, 重点增强包含小

目标病变特征的高频分量。特别地, 模块将输入特征  $X$  沿通道维度均分为两部分,  $X_q$  用于小波注意加权处理以捕获关键特征,  $X_p$  保留原始特征以确保信息完整性, 最后通过特征融合实现两者的优势互补。这种设计既有效解决了小目标特征被遮蔽的问题, 又保持了原始特征的完整性, 在提升小目标检测精度的同时避免了信息损失。

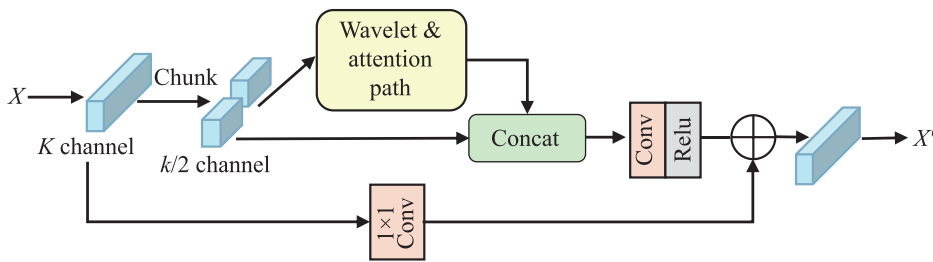



图2 小波注意模块

Fig. 2 Wavelet attention module



DWT—离散小波变换; CA—空间注意力机制; Conv body—一系列卷积层和激活函数; IWT—小波逆变换; SA—通道注意力机制。

图3 小波注意过程

Fig. 3 Wavelet attention path

### 1.1.1 离散小波变换过程

离散小波变换作为一种信号分解方法,通过预设的滤波器组将输入特征 $X_q \in \mathbf{R}^{B \times C \times H \times W}$  ( $\mathbf{R}$ 为实数集,  $B$ 为批次,  $C$ 为通道,  $H$ 为高度,  $W$ 为宽度)分离为补充的低频与高频子带。该变换采用固定间隔采样机制进行下采样,通过保持偶数行与奇数行采样点间隔恒定来捕捉频率特征:低频分量主要集中于偶数采样点(偶数行),而高频分量则集中于奇数采样点(奇数行)。由于小波变换的频域分解会导致能量在不同子带间分散,为维持能量守恒,需对各子带进行归一化处理。文中采用除以2的尺度调整方法,既将数值范围调整至适合后续计算,又确保了能量一致性。滤波器组的设计公式如下:

$$X_{01} = \frac{1}{2} X_q[:, :, 0 :: 2, :] \quad (1)$$

$$X_{02} = \frac{1}{2} X_q[:, :, 1 :: 2, :]$$

式中:  $[:, :, 0 :: 2, :]$ ,  $[:, :, 1 :: 2, :]$ 表示对特征图高度维度进行的切分操作,第一个从标识0开始以步长2选取元素,生成奇数行的特征图以捕获高频信息;第二个从标识1开始以步长2选取元素,生成偶数行的特征图以捕获低频信息。

接着,对特征图 $X_{01}$ 和 $X_{02}$ 的列方向也即宽度维度进行下采样:

$$\begin{aligned} X_1 &= X_{01}[:, :, :, 0 :: 2] \\ X_2 &= X_{02}[:, :, :, 0 :: 2] \\ X_3 &= X_{01}[:, :, :, 1 :: 2] \\ X_4 &= X_{02}[:, :, :, 1 :: 2] \end{aligned} \quad (2)$$

式中:  $[:, :, :, 0 :: 2]$ 和 $[:, :, :, 1 :: 2]$ 表示对特征图宽度维度进行的切分操作,第一个从标识0开始以步长2选取元素,第二个从标识1开始以步长2选取元素。

对于特征图 $X_{01}$ 和 $X_{02}$ ,经过行列双重采样操作生成4个结构互补的子块:  $X_1$ 包含 $X_q$ 的奇数行奇数列元素;同理,  $X_2$ 包含偶数行奇数列元素;  $X_3$ 包含奇数行偶数列元素;  $X_4$ 包含偶数行偶数列元素。基于小波分解理论,这4个子块通过自适应加权融合,最

终形成4个不同的频率子带,其数学表达式如下:

$$\begin{aligned} X_{DD} &= X_1 + X_2 + X_3 + X_4 \\ X_{GD} &= X_2 - X_4 + X_1 - X_3 \\ X_{DG} &= X_3 - X_4 + X_1 - X_2 \\ X_{GG} &= X_4 - X_3 + X_1 - X_2 \end{aligned} \quad (3)$$

式中:  $X_{DD} \in \mathbf{R}^{B \times C \times \frac{H}{2} \times \frac{W}{2}}$ 表示低频子带需要保留所有方向的信息,通过将4个子块直接相加的方式保留全局结构;  $X_{GD} \in \mathbf{R}^{B \times C \times \frac{H}{2} \times \frac{W}{2}}$ 表示水平高频子带,需要捕获图像水平边缘的信息,  $X_2 - X_4$ 和 $X_1 - X_3$ 强调水平细节;  $X_{DG} \in \mathbf{R}^{B \times C \times \frac{H}{2} \times \frac{W}{2}}$ 表示垂直高频子带,需要捕获图像垂直边缘的信息,  $X_3 - X_4$ 和 $X_1 - X_2$ 强调垂直细节;  $X_{GG} \in \mathbf{R}^{B \times C \times \frac{H}{2} \times \frac{W}{2}}$ 表示对角高频子带,需要捕获图像对角方向的信息,  $X_4 - X_3 + X_1 - X_2$ 的组合捕捉对角线方向的变化。

最后,将4个子带在通道维度拼接得到复合特征图 $F \in \mathbf{R}^{B \times 4C \times \frac{H}{2} \times \frac{W}{2}}$ 。

### 1.1.2 空间注意力

在得到包含4个频率子带的特征图 $F$ 后,对 $F$ 进行空间注意力计算,具体流程如图4。该机制重点针对富含边界信息的高频子带进行动态加权,对于不同尺寸的病变区域,该机制能够依据实际情况将注意力精准聚焦于相应的空间区域,从而有效提升对病变区域的识别能力。同时,针对复杂背景干扰,该机制还可降低无关区域的权重,减少其对分割结果的不良影响。首先,通过沿通道维度对特征图 $F$ 分别进行全局平均池化和全局最大池化,得到具有全局空间上下文信息的空间特征图 $F_\xi \in \mathbf{R}^{B \times 1 \times \frac{H}{2} \times \frac{W}{2}}$ 和 $F_\zeta \in \mathbf{R}^{B \times 1 \times \frac{H}{2} \times \frac{W}{2}}$ 。

$$F_\xi = \text{AvgPool}(F), \quad F_\zeta = \text{MaxPool}(F) \quad (4)$$

经过卷积和激活函数生成空间注意力图 $M_S \in \mathbf{R}^{B \times 1 \times \frac{H}{2} \times \frac{W}{2}}$ ,然后与输入特征图加权输出增强后的特征图 $F_S \in \mathbf{R}^{B \times 1 \times \frac{H}{2} \times \frac{W}{2}}$ 。

$$\begin{aligned} M_S &= \sigma(\text{Conv}_{3 \times 3}(\text{Concat}(F_\xi, F_\zeta))) \\ F_S &= M_S F \end{aligned} \quad (5)$$




图4 空间注意力

Fig. 4 Spatial attention

### 1.1.3 通道注意力

特征图中高频部分还富含细节信息,为此设计如图5所示的通道注意力机制动态调整高频部分权

重,增强网络对病变特征的捕捉能力,同时抑制无关噪声信息。




图5 通道注意力

Fig. 5 Channel attention

对于特征图 $F$ ,首先在空间维度上对每个通道进行全局池化,其计算公式如下:

$$F_{\zeta} = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F_{i,j} \quad (6)$$

其中 $F_{\zeta} \in \mathbf{R}^{B \times 4C \times 1 \times 1}$ 。接着通过全连接网络对池化的全局特征进行降维处理以减少计算量,再将其重新映射至原始维度,得到通道注意力特征图 $M_T \in \mathbf{R}^{B \times 4C \times 1 \times 1}$ 。最后将该特征图与输入特征进行加权整合输出,得到通道注意特征图 $F_T \in \mathbf{R}^{B \times 4C \times 1 \times 1}$ 。

$$\begin{aligned} M_T &= \sigma(W_1 \cdot \text{ReLu}(W_2 F_{\zeta})) \\ F_T &= M_T F \end{aligned} \quad (7)$$

式中:  $W_1, W_2$ 表示全连接层;  $\sigma$ 表示 Sigmoid 激活函数; ReLu 表示线性整流函数。

将得到的空间注意特征图 $F_S \in \mathbf{R}^{B \times 4C \times \frac{H}{2} \times \frac{W}{2}}$ 和通道注意特征图 $F_T \in \mathbf{R}^{B \times 4C \times \frac{H}{2} \times \frac{W}{2}}$ 在通道维度进行拼接操作,随后进行 $1 \times 1$ 卷积,生成合并的注意力特征图 $F_M \in \mathbf{R}^{B \times 4C \times \frac{H}{2} \times \frac{W}{2}}$ ;再将其与特征图 $F$ 相加得到最终的特征图 $\Phi \in \mathbf{R}^{B \times 4C \times \frac{H}{2} \times \frac{W}{2}}$ 。特征图 $\Phi$ 保留了原始特征图信息,可为后续逆小波变换(inverse wavelet transform, IWT)过程提供必要的频域成分,确保特征图能够准确重建至原始分辨率;同时可避免网络过度依赖注意力机制,使网络在特征处理和信息恢复方面更加稳健和全面,提升网络性能和适应性。

### 1.1.4 逆小波变换过程

将特征图 $\Phi$ 按通道顺序划分为 $X_{DD}, X_{DG}, X_{GD}, X_{GG}$ 4个频率子带,其数学表达式如下:

$$\begin{aligned} X_{DD} &= \Phi[:, 0 : C, :, :] \\ X_{GD} &= \Phi[:, C : 2C, :, :] \\ X_{DG} &= \Phi[:, 2C : 3C, :, :] \\ X_{GG} &= \Phi[:, 3C : 4C, :, :] \end{aligned} \quad (8)$$

在通道维度 $C$ 上进行特征切分操作,其中 $[:, 0 : C, :, :]$ 表示从标识0到 $C$ 选取元素,其他同理。然后进行重建,采用零填充插值方法,通过双线性插值将下采样后的特征图恢复至原始空间分辨率,其数学表达式为:

$$\begin{aligned} O[:, :, 0 : 2, 0 : 2] &= \frac{X_{DD} - X_{GD} - X_{DG} + X_{GG}}{r} \\ O[:, :, 1 : 2, 0 : 2] &= \frac{X_{DD} - X_{GD} + X_{DG} - X_{GG}}{r} \\ O[:, :, 0 : 2, 1 : 2] &= \frac{X_{DD} + X_{GD} - X_{DG} - X_{GG}}{r} \\ O[:, :, 1 : 2, 1 : 2] &= \frac{X_{DD} - X_{GD} - X_{DG} - X_{GG}}{r} \end{aligned} \quad (9)$$

在 $H$ 和 $W$ 维度上进行元素填充操作。其中 $O \in \mathbf{R}^{B \times C \times H \times W}$ 为恢复后的特征图;  $r$ 为缩放因子,恢复后的特征图各元素会放大4倍,故选取 $r$ 为4。

## 1.2 变分多采样模块

如图6所示,变分自编码(variational autoencoder, VAE)由编码器和解码器构成。通过学习输入数据的潜在变量表示生成新的数据,基于VAE设计的变分多采样模块(VMSM)将输入图像映射至潜在空间,使相似边界形状的病变区域在潜在空间中距离更近;同时通过多次重参数化采样加权输出,有效降低单次采样引入的随机误差,从而学习到不同形态的边界特征,缓解边界模糊问题。




图6 VAE模型结构

Fig. 6 Structure of VAE model

### 1.2.1 多次重采样流程

如图 7 所示, 变分多采样模块 (VMSM) 首先建立潜在空间概率模型: 输入图像  $X$  经编码器处理后, 输出潜在分布的参数 (均值  $\mu$  和标准差  $\sigma$ ), 共同定义潜在分布  $N(\mu, \sigma^2)$ 。该分布表示输入数据在潜在空间中的概率特性,  $\mu$  控制特征聚类中心;  $\sigma$  反映特征离散程度。训练过程中, 为使后验概率接近先验分布, 返回  $\mu$  和  $\sigma$  通过计算 KL 散度损失进行优化。




图7 变分多采样模块结构

Fig. 7 Structure of variational multi-sampling module

接着, 基于潜在分布  $N(\mu, \sigma^2)$  进行  $n$  次重参数化采样, 得到  $n$  个潜在表示  $z_1, z_2, \dots, z_n$ , 每次采样通过以下公式计算:

$$z_i = \mu + \varepsilon_i \sigma, \varepsilon_i \sim N(0, 1), i = 1, 2, \dots, n \quad (10)$$

式中:  $\varepsilon_i$  表示从标准正态分布中随机采样的噪声。对于同一输入  $X$ , 编码器输出的  $\mu$  和  $\sigma$  是固定不变的, 仅  $\varepsilon$  会随机变化, 故采用多次采样策略以减少随机性影响, 提升生成稳定性。采样次数的选择基于实验验证和任务需求, 本文通过对比实验发现: 当  $n = 3$  时, 网络在多数数据集上实现了分割精度和计算效率的最佳平衡; 进一步增加采样次数不仅无法提升性能, 反而会显著增加计算开销。

### 1.2.2 加权融合策略

为捕捉不同采样结果在特定场景下的重要程度, 对多次采样得到的结果进行加权融合处理, 其数学表达式如下:

$$b_i = \frac{\exp a_i}{\sum_{j=1}^n \exp a_j}, \quad \sum_{i=1}^n b_i = 1, z = \sum_{i=1}^n b_i z_i \quad (11)$$

式中  $b_i$  为可学习的权重参数。首先将每个潜在表示  $z_i$  输入轻量级全连接网络, 生成对应的权重得分  $a_i$ ; 然后通过 Softmax 函数对得分进行归一化, 得到最终权重  $b_i$ 。这种设计使网络能够根据任务需求动态调整采样结果的重要性, 如在面对噪声干扰或异常采样时, 加权融合机制能够有效抑制低质量采样结果的影响, 从而显著提升生成结果的可靠性和准确性。变分多采样模块 (VMSM) 的伪代码描述如下:

Algorithm 1: Variational multi-sampling module (VMSM)

Input: Mean  $\mu$ , standard deviation  $\sigma$ , number of samples  $n$

Output: Fused latent representation  $z$

1: // Step 1: Multiple reparameterized sampling

2:  $z = []$

3: for  $i = 1$  to  $n$  do

4:  $\varepsilon_i \sim N(0, 1)$  // Sample noise from standard normal distribution

5:  $z_i = \mu + \varepsilon_i \sigma$  // Reparameterized sampling

6:  $z$ . Append( $z_i$ )

7: end for

8: // Step 2: Weighted fusion

9:  $b = \text{Softmax}(\text{FC}(z_i))$  // Learn weights via a fully connected layer

10:  $z = \sum_{i=1}^n b_i z_i$  // Weighted fusion

11: return  $z$

### 1.3 损失函数

MFNet 采用复合损失函数进行端到端优化, 包含分割损失与 KL 散度两部分。KL 散度用来约束潜在变量与标准正态分布的差异, 实现潜在空间的正则化; 分割损失用于衡量解码器输出与原始输入数据的差异, 确保解码器生成的输出能最大程度地逼近输入。分割损失由 Dice 损失和二元交叉熵 (binary cross-entropy loss, BCE) 损失组成。其中 Dice 损失主要用于评估预测的分割结果与真实分割结果的相似程度, 其计算公式如下:

$$L_{\text{Dice}} = 1 - \frac{2 \sum_{i=1}^m p_i g_i}{\sum_{i=1}^m p_i + \sum_{i=1}^m g_i + \tau} \quad (12)$$

式中:  $p_i$  为预测值, 通常为经 Sigmoid 处理后的概率;  $g_i$  为实际标签值;  $m$  为图像中的像素个数;  $\tau$  为一个很小的值, 避免分母为零。BCE 损失用于衡量像素预测值与真实标签的交叉熵损失, 其计算公式如下:

$$L_{\text{BCE}} = -\frac{1}{m} \sum_{i=1}^m [g_i \lg p_i + (1-g_i) \lg (1-p_i)] \quad (13)$$

损失函数 ( $L$ ) 由各损失加权组合而成, 其数学表达式如下:

$$L = w_{\text{Dice}} L_{\text{Dice}} + w_{\text{BCE}} L_{\text{BCE}} + \beta L_{\text{KL}} \quad (14)$$

式中:  $w_{\text{Dice}}$  和  $w_{\text{BCE}}$  为分割损失的权重, 两者之和为 1;  $\beta$  用于限制 KL 散度, 避免其在网络训练过程中起主导作用。

## 2 实验与结果分析

为验证 MFNet 的有效性, 设计 3 个维度的实验评估, 包括对比实验、消融实验以及超参数分析。

### 2.1 实验设置

实验共使用 6 个数据集, 包含 5 个公开数据集和 1 个非公开结肠镜检查数据集 USTCAI。公开数据集包括 Kvasir-SEG<sup>[18]</sup>、CVC-ClinicDB<sup>[19]</sup>、CVC-ColonDB<sup>[20]</sup>、ETIS-LaribPolypDB<sup>[21]</sup>、CVC-300<sup>[22]</sup>。为确保公平比较, 严格参照 PraNet<sup>[16]</sup> 的数据划分标准: 训练集构建基于 Kvasir-SEG 的 900 张图像及 CVC-ClinicDB 的 550 张图像, 初始合并共 1450 个样本; 随后从中划分出 442 张图像作为验证集, 剩下的 1008 张图像作为训练集。测试集包含 5 个独立子集: Kvasir-SEG 剩余的 100 张图像、CVC-ClinicDB 的 62 张图像、完整的 CVC-ColonDB 数据

集 (380 张图像)、完整的 ETIS-LaribPolypDB 数据集 (196 张图像) 及 CVC-300 的 60 张图像。非公开数据集 USTCAI 包含 21 名患者的 11 623 张训练图像, 按照患者 ID(0001~0021) 分类存储。每位患者的数据包含原始图像 (image)、JSON 标注 (json) 和二进制掩膜 (mask) 3 个子目录, 所有文件均采用统一的六位数字命名 (如 000001)。为确保数据分布一致性, 数据集按患者维度以 6:3:1 比例划分为训练集、验证集、测试集。

所有实验设置均保持一致: 输入图像统一调整为  $224 \times 224$  像素, 训练 200 轮 (若连续 50 轮未达到最优性能则提前终止), 采用 Adam 优化器 (初始学习率为  $1e-3$ , 批大小为 8), 硬件环境为 NVIDIA GeForce RTX 3090 的 GPU, 软件环境配置为 Python 3.8, PyTorch 1.12 框架。

### 2.2 对比实验与结果分析

采用平均 Dice 系数 (mean Dice, mDice) 和平均交并比 (mean intersection over union, mIoU) 作为评估指标。mDice 用于衡量预测区域与真实区域的重叠程度, 其值域为  $[0, 1]$ , 该值越大表示分割精度越高; mIoU 为计算预测区域与真实区域的交集占其并集的比例, 其值域为  $[0, 1]$ , 该值越大表示分割越精准。5 种主流方法 (U-Net<sup>[9]</sup>, Swin-UNet<sup>[15]</sup>, EGEUNet<sup>[23]</sup>, DUCKNet<sup>[24]</sup>, EMACD<sup>[25]</sup>) 及本文方法在全部 6 个测试集上的定量对比结果如表 1。

表 1 MFNet 与其他方法的对比实验结果

Tab. 1 Comparative experimental results of MFNet and other methods

%

%

数据集	指标	U-Net	Swin-UNet	EGENet	DUCKNet	EMACD	MFNet
USTCAI	mDice	72.02	82.13	86.10	72.65	92.05	<b>93.04</b>
	mIoU	62.31	75.15	76.75	67.05	83.38	<b>87.71</b>
Kvasir-SEG	mDice	63.58	71.86	80.73	<b>91.10</b>	86.52	90.13
	mIoU	55.54	62.41	67.18	<b>88.31</b>	78.86	88.30
ETIS-LaribPolypDB	mDice	28.14	30.46	55.95	51.24	50.44	<b>57.54</b>
	mIoU	23.74	23.64	40.80	40.66	42.53	<b>43.20</b>
CVC-ColonDB	mDice	28.19	45.53	70.83	71.25	71.20	<b>72.33</b>
	mIoU	23.23	36.44	54.84	58.14	<b>61.98</b>	61.80
CVC-ClinicDB	mDice	61.35	77.11	85.87	91.64	88.14	<b>91.88</b>
	mIoU	56.59	69.51	75.25	83.33	82.88	<b>86.61</b>
CVC-300	mDice	53.46	53.84	67.34	77.25	80.17	<b>80.71</b>
	mIoU	44.97	43.95	50.77	67.09	69.29	<b>71.86</b>

从表 1 可知, MFNet 在全部测试数据集上均展现出优越性能: 在包含丰富临床特征的 USTCAI 数据集上 mDice 达 93.04%, 验证了其强大的特征提取

能力; 在 Kvasir-SEG 数据集上以仅 0.97% 的差距次于采用数据增强的 DUCKNet, 但计算效率显著提升。针对 ETIS-LaribPolypDB 数据集 (主要包含早期息肉

图像, 多为小型未凸起的息肉), 以 57.54% 的 mDice 领先次优方法 (EGENet)1.59%, 充分验证了 MFNet 处理小目标息肉的优越能力; 在具有复杂边界的 CVC-ColonDB, CVC-ClinicDB 与 CVC-300 数据集 (息肉图像情况复杂, 息肉大小各异且边界模糊) 上分别取得了 72.33%, 91.88% 和 80.71% 的 mDice, 其中 CVC-ColonDB 数据集上 MFNet 的 MIoU 比 EMACD 仅低 0.18%, 充分证明其对多尺度息肉和模糊边界

的鲁棒分割能力。

为直观验证 MFNet 的优越性, 展示 6 个数据集的典型样本可视化对比结果, 如图 8。由图 8 看出: MFNet 在所有数据集上的分割结果与真实标签更为接近; 在处理不同数据集时, 仅 MFNet 呈现出稳定的性能表现, 其他方法在部分数据集上或多或少地会分割出额外目标。

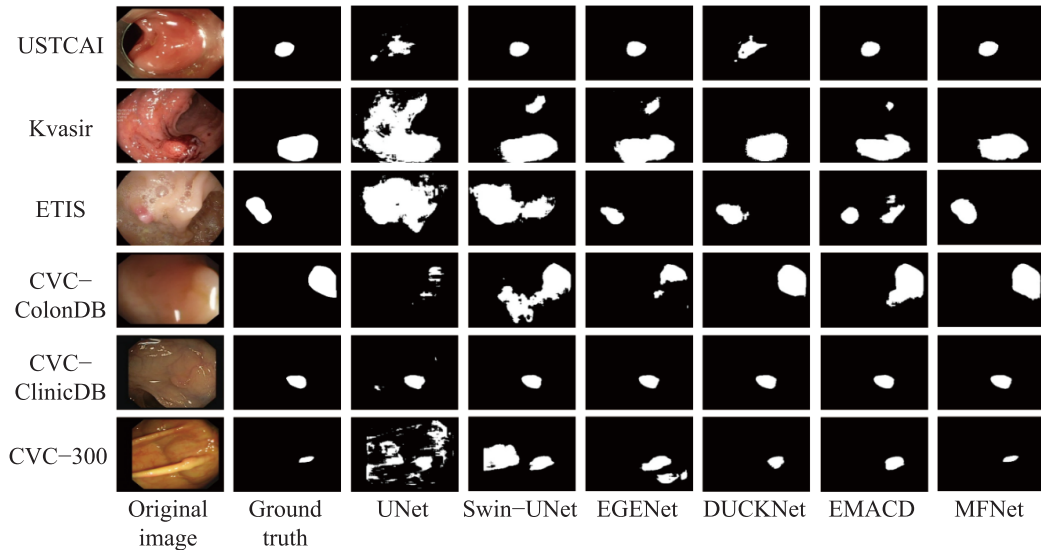


图 8 可视化结果

Fig. 8 Visualization results

图 8 中第二行第一列的图像取自 Kvasir 数据集, 其样例分割结果局部对比如图 9。由图 9 可看出其息肉边界受到体液干扰, DUCKNet 分割出的边界并不平滑, 表明该方法在处理此类边界时存在一定的局限性; 其他方法的表现更差, 甚至将正常组织误判为分割目标。

充分表明 MFNet 借助 VMSM 模块有效地捕捉到息肉边界的特征。对于图 8 中第五行第一列取自 CVC-ClinicDB 数据集的图像和第六行第一列取自 CVC-300 数据集的图像 (CVC-300 数据集图像样例分割结果局部对比如图 10), 二者息肉目标均较小。在此情形下, MFNet 在 WAM 模块的助力下, 成功对小目标息肉进行了有效分割。



图 9 Kvasir 数据集样例分割结果局部对比

Fig. 9 Local comparison of segmentation results on a sample from the Kvasir dataset

对于图 8 中第三行第一列源自 ETIS-Larib-PolyDB 数据集的图像, 同样受到体液干扰且息肉目标较小, 然而 MFNet 依然能够对其进行良好的分割, 展现出强大的适应性。对于图 8 中第一行第一列取自 USTCAI 数据集的图像及第一行第四列取自 CVC-ColonDB 数据集的图像, 前者因镜头反光, 后者因镜头运动致使息肉目标受到干扰。即便在如此复杂的情况下, MFNet 依旧能够准确地分割出目标,




图 10 CVC-300 数据集样例分割结果局部对比

Fig. 10 Local comparison of segmentation results on a sample from the CVC-300 dataset

### 2.3 消融实验与结果分析

为验证 MFNet 核心模块的贡献, 通过依次移除整体结构的各组件进行消融实验, 结果如表 2。其中 W/O VMSM 表示移除变分多采样模块 (VMSM), W/O WAM 表示移除小波注意模块 (WAM), W/O CA 表示移除小波注意模块中的通道注意力, W/O SA 表示移除小波注意模块中的空间注意力。

表2 消融实验结果

Tab. 2 Results of the ablation study

%

%

方法	USTCAI		Kvasir-SEG		ETIS-LaribPolyDB		CVC-ColonDB		CVC-ClinicDB		CVC-300	
	mDice	mIoU	mDice	mIoU	mDice	mIoU	mDice	mIoU	mDice	mIoU	mDice	mIoU
W/O MSM	91.51	85.39	86.96	79.90	50.38	42.48	68.25	59.88	89.18	83.58	77.41	68.02
W/O WAM	90.31	84.86	85.10	77.38	46.81	40.75	63.62	54.21	91.03	85.83	73.40	64.36
W/O SA	92.56	87.01	86.92	79.01	56.28	42.49	71.31	60.13	91.51	86.20	79.83	70.37
W/O CA	92.12	87.30	86.10	79.38	56.81	42.75	71.62	60.21	91.03	85.83	79.40	70.25
MFNet	<b>93.04</b>	<b>87.71</b>	<b>87.13</b>	<b>80.30</b>	<b>57.54</b>	<b>43.20</b>	<b>72.33</b>	<b>61.80</b>	<b>91.88</b>	<b>86.61</b>	<b>80.71</b>	<b>71.86</b>

分析表2可知:移除VMSM后导致全局性能显著下降(mDice系数下降了3.17%,mIoU下降了2.04%),其中边界模糊的CVC系列数据集降幅最大,ColonDB, ClinicDB和CVC-300的mDice系数分别下降了4.08%,2.70%和3.30%,验证了变分多采样模块对模糊边界建模的关键作用。同样地,移除WAM引发更剧烈的性能衰减(mDice系数下降了5.40%,mIoU下降了4.02%),尤其在ETIS-LaribPolyDB小目标数据集出现了7.16%的mDice滑坡,证明小波注意力模块的多尺度特征提取能力。此外,WAM中内部组件的通道注意力(CA)与空间注意力(SA)的缺失在USTCAI数据集上分别导致mDice下降了0.92%和0.48%,其中SA对复杂边界数据集(如ColonDB)影响更显著,mDice下降了1.02%。实验数据充分证实了VMSM的边界优化能力与WAM的多尺度感知能力具有协同增强效应,二者共同保障了方法在复杂场景下的鲁棒性。

## 2.4 超参数影响实验与结果分析


MFNet网络涉及采样次数 $n$ 和损失函数权重关键超参数,文中采用控制变量法进行实验分析。

### 2.4.1 采样次数对MFNet性能的影响

VMSM中设计了多重采样,为探究采样次数 $n$ 对MFNet网络性能的影响,固定损失函数权重 $w_{Dice}$ 和 $w_{BCE}$ 为0.5, $\beta=0.001$ ,在6个数据集上进行实验,结果如图10,11。

由图10,11可见:当VMSM模块的重采样次数设定为3时,MFNet网络在6个数据集上均达到性能最优;而当重采样次数超过3时,mDice与mIoU开始下滑。这一现象说明多重采样有助于网络更精准地刻画潜在空间的分布特征,同时有效抑制单次采样引入的噪声干扰;然而当采样次数过多时,潜在空间的表征会逐渐趋于均值化,致使特征过度平滑,网络性能降低。由图11还可见,单次采样与六次采样的性能相近,mDice分别为77.23%和77.47%,说明过度增加重采样次数,不仅大幅提升计算资源需

求,还会显著增加网络复杂度,导致网络在训练过程中难以达到最优状态,影响整体性能。

图11 USTCAI数据集上不同 $n$ 的结果Fig. 11 Results of different  $n$  on the USTCAI dataset

### 2.4.2 损失函数权重对MFNet性能的影响

为探究损失函数权重对MFNet网络性能的影响,设定采样次数为3,在Kvasir-SEG数据集上通过改变权重进行两组实验:固定 $\beta$ (取值0.001),分析 $w_{Dice}$ 和 $w_{BCE}$ 变换对网络性能的影响;固定 $w_{Dice}$ 和 $w_{BCE}$ (均为0.5),分析 $\beta$ 对网络性能的影响,结果分别如图12~14。实验过程中,对于 $w_{Dice}$ 和 $w_{BCE}$ 取值在0~1之间,选取组合( $w_{Dice}=0, w_{BCE}=1$ ), ( $w_{Dice}=0.3, w_{BCE}=0.7$ ), ( $w_{Dice}=0.5, w_{BCE}=0.5$ ), ( $w_{Dice}=0.7, w_{BCE}=0.3$ ), ( $w_{Dice}=1, w_{BCE}=0$ ),当其中一权重确定时,另一

权重为  $1 - w_{Dice}$  或  $1 - w_{BCE}$ ; 设置  $\beta$  小于  $w_{Dice}$  和  $w_{BCE}$  的取值, 在  $\{0, 0.001, 0.01, 0.1\}$  中选取。




图12 5个数据集上不同  $n$  的平均结果

Fig. 12 Average results of different  $n$  on five datasets




图13  $w_{Dice}$  和  $w_{BCE}$  权重对网络性能的影响

Fig. 13 Influence of the weights of  $w_{Dice}$  and  $w_{BCE}$  on network performance

由图 12, 13 可知: 当  $w_{Dice} = 0.5, w_{BCE} = 0.5$  时, 网络性能达到最佳 ( $mDice=90.13\%$ ); 当  $w_{Dice}$  增至  $0.7 (w_{Dice} = 0.7, w_{BCE} = 0.3)$ , 网络性能略有下降 ( $mDice=89.80\%$ )。这是因为 Dice 损失更关注区域重叠, 在某些情况下过度依赖 Dice 损失可能导致网络对边界细节的敏感性降低。当完全依赖 Dice 损失时, 即  $w_{Dice} = 1, w_{BCE} = 0$ , 网络性能显著下降 ( $mDice=87.20\%$ ), 说明单独使用 Dice 损失无法充分优化网络的分类

能力。当  $w_{BCE}$  增至  $0.7 (w_{Dice} = 0.3, w_{BCE} = 0.7)$ , 网络性能接近最佳 ( $mDice=89.30\%$ ), 表明 BCE 损失在优化像素级分类任务中起到重要作用; 当完全依赖 BCE 损失时, 即  $w_{Dice} = 0, w_{BCE} = 1$ , 网络性能低于最佳 ( $mDice=88.50\%$ ), 说明单独使用 BCE 损失可能无法有效处理类别不平衡问题。上述实验结果表明, 将 Dice 损失和 BCE 损失相结合能够显著提升网络性能, 尤其在分割任务中, 最佳权重分配为  $w_{Dice} = 0.5, w_{BCE} = 0.5$  时, 网络能够平衡区域重叠和像素级分类的目标。




图14 超参数  $\beta$  对网络性能的影响

Fig. 14 Influence of the hyper-parameter  $\beta$  on network performance

由图 14 可知: 在固定权重参数  $w_{Dice}=0.5, w_{BCE}=0.5$  的条件下, 当超参数  $\beta=0$  时, 变分多采样模块不发挥作用, 导致网络无法理解边界呈现形式; 而当  $\beta$  值过度增大时, 网络会过度关注分布对齐, 从而削弱了分割任务的学习效果。由此可见, 网络性能依赖各参数间的协同作用: 分割损失需要均衡分配, 同时 KL 散度也需适度约束。

### 3 结论

为提升息肉图像在病变区域受干扰且边界模糊情况下的分割性能, 提出了一种融合多尺度特征感知与模糊边界建模的分割网络。该网络首先通过多次变分采样进行边界概率建模以增强边界定位能力, 其次利用小波变换分解低频与高频特征并结合注意力机制实现多尺度特征融合。在公开数据集上的对比实验表明, 该网络在分割精度和鲁棒性上均优于现有方法, 尤其对复杂边界的处理能力通过可视化结果也得到验证。本研究可为息肉图像分割提供更可靠的技术方案, 然而针对医学图像数据样本不平衡的普遍问题, 推广至其他医疗场景时需重点提升网络在有限数据条件下捕捉关键特征的能力。为满足临床实际应用需求, 还可进一步优化网络结构以提升推理效率, 包括设计更轻量化架构和部署方案, 从而兼顾计算效率和精度的双重要求。

## 参考文献:

- [1] SIEGEL R L, MILLER K D, WAGLE N S, et al. Cancer statistics, 2023[J]. CA: A Cancer Journal for Clinicians, 2023, 73(1):17-48.
- [2] GRANADOS-ROMERO J J, VALDERRAMA-TREVIÑO A I, CONTRERAS-FLORES E H, et al. Colorectal cancer: a review[J]. International Journal of Research in Medical Sciences, 2017, 5(11):4667.
- [3] SALPEA N, TZOUVELI P, KOLLIAS D. Medical image segmentation: a review of modern architectures[M]// Computer Vision-ECCV 2022 Workshops. Cham: Springer Nature Switzerland, 2023:691-708.
- [4] RAMESH K K D, KUMAR G K, SWAPNA K, et al. A review of medical image segmentation algorithms[J]. EAI Endorsed Transactions on Pervasive Health and Technology, 2022, 7(27):e6.
- [5] NIE Z, XU M, WANG Z, et al. A review of application of deep learning in endoscopic image processing[J]. Journal of Imaging, 2024, 10(11):275.
- [6] 武治, 孙照旋, 周芳. 基于改进萤火虫算法的多阈值微生物图像分割[J]. 安徽工业大学学报(自然科学版), 2020, 37(1):46-52,59.  
WU Z, SUN Z X, ZHOU F. Multi-threshold microbial image segmentation based on improved firefly algorithm[J]. Journal of Anhui University of Technology (Natural Science), 2020, 37(1):46-52,59.
- [7] 胡小为, 刘宏申, 徐国雄, 等. 一种结合 GVF 和 CV 模型的水平集图像分割方法[J]. 安徽工业大学学报(自然科学版), 2016, 33(3):289-294.  
HU X W, LIU H S, XU G X, et al. A level set image segmentation method combined with GVF and CV model[J]. Journal of Anhui University of Technology (Natural Science), 2016, 33(3):289-294.
- [8] 郑近德, 姚殷柔, 潘海洋, 等. 多尺度熵方法在机械故障诊断中的应用研究进展[J]. 安徽工业大学学报(自然科学版), 2024, 41(1):46-57,97.  
ZHENG J D, YAO Y R, PAN H Y, et al. Research progress on the application of multi-scale entropy method in the mechanical fault diagnosis[J]. Journal of Anhui University of Technology (Natural Science), 2024, 41(1):46-57,97.
- [9] RONNEBERGER O, FISCHER P, BROX T. U-Net: convolutional networks for biomedical image segmentation[M]// Medical Image Computing and Computer-Assisted Intervention-MICCAI 2015. Cham: Springer International Publishing, 2015:234-241.
- [10] HUANG H M, LIN L F, TONG R F, et al. UNet 3+: a full-scale connected UNet for medical image segmentation[C]// ICASSP 2020-2020 IEEE International Conference on Acoustics, Speech and Signal Processing. Barcelona, Spain. IEEE, 2020:1055-1059.
- [11] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]// Advances in Neural Information Processing Systems 30 (NIPS 2017). New York: Curran Associates, Inc, 2017.
- [12] CHEN J N, MEI J R, LI X H, et al. TransUNet: rethinking the U-Net architecture design for medical image segmentation through the lens of transformers[J]. Medical Image Analysis, 2024, 97:103280.
- [13] LIU Z, LIN Y T, CAO Y, et al. Swin transformer: hierarchical vision transformer using shifted windows[C]// 2021 IEEE/CVF International Conference on Computer Vision. Montreal, QC, Canada. IEEE, 2021:10012-10022.
- [14] LIN A L, CHEN B Z, XU J Y, et al. DS-TransUNet: dual swin transformer U-Net for medical image segmentation[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71:1-15.
- [15] CAO H, WANG Y Y, CHEN J, et al. Swin-unet: unet-like pure transformer for medical image segmentation[M]// Computer Vision-ECCV 2022 Workshops. Cham: Springer Nature Switzerland, 2023:205-218.
- [16] FAN D P, JI G P, ZHOU T, et al. PraNet: parallel reverse attention network for polyp segmentation[M]// Medical Image Computing and Computer Assisted Intervention-MICCAI 2020. Cham: Springer International Publishing, 2020:263-273.
- [17] WEI J, HU Y W, ZHANG R M, et al. Shallow attention network for polyp segmentation[M]// Medical Image Computing and Computer Assisted Intervention-MICCAI 2021. Cham: Springer International Publishing, 2021: 699-708.
- [18] JHA D, SMEDSRUD P H, RIEGLER M A, et al. Kvasir-SEG: a segmented polyp dataset[C]// MultiMedia Modeling. Cham: Springer International Publishing, 2020:451-462.
- [19] BERNAL J, SÁNCHEZ F J, FERNÁNDEZ-ESPARRACH G, et al. WM-DOVA maps for accurate polyp highlighting in colonoscopy: validation vs. saliency maps from physicians[J]. Computerized Medical Imaging and Graphics, 2015, 43:99-111.
- [20] BERNAL J, SÁNCHEZ J, VILARIÑO F. Towards automatic polyp detection with a polyp appearance model[J]. Pattern Recognition, 2012, 45(9):3166-3182.
- [21] SILVA J, HISTACE A, ROMAIN O, et al. Toward embedded detection of polyps in WCE images for early diagnosis of colorectal cancer[J]. International Journal of Computer Assisted Radiology and Surgery, 2014, 9(2): 283-293.
- [22] VÁZQUEZ D, BERNAL J, SÁNCHEZ F J, et al. A

- benchmark for endoluminal scene segmentation of colonoscopy images[J]. *Journal of Healthcare Engineering*, 2017, 2017(1):4037190.
- [23] RUAN J C, XIE M Y, GAO J S, et al. EGE-UNet: an efficient group enhanced UNet for skin lesion segmentation[M]//*Medical Image Computing and Computer Assisted Intervention—MICCAI 2023*. Cham: Springer Nature Switzerland, 2023:481–490.
- [24] DUMITRU R G, PETELEAZA D, CRACIUN C. Using DUCK-net for polyp image segmentation[J]. *Scientific Reports*, 2023, 13(1):9803.
- [25] RAHMAN M M, MUNIR M, MARCULESCU R. EMCAD: efficient multi-scale convolutional attention decoding for medical image segmentation[C]//2024 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, WA, USA: IEEE, 2024:11769–11779.
- 责任编辑: 何莉
- 
- (上接第 497 页)
- [22] WEI Y S, CAO X Q, WANG G, et al. Study on carbon fixation ratio and properties of foamed concrete[J]. *Materials*, 2023, 16(9):3441.
- [23] GAO L. Experimental study of the effect of chemical additives on mechanical properties of foamed concrete[J]. *Functional Materials*, 2019, 26(4):802–806.
- [24] 陈梦义, 李北星. 超高性能混凝土用于配制泡沫混凝土的技术研究 [J]. *新型建筑材料*, 2023, 50(6):100–102,141.
- CHEN M Y, LI B X. Research on the preparation technology of ultra-high performance concrete for foamed concrete[J]. *New Building Materials*, 2023, 50(6):100–102,141.
- [25] 邓琪丰, 刘卫东, 韩云婷. 发泡剂对淤泥固化性能的影响研究 [J]. *新型建筑材料*, 2022, 49(7):138–143.
- DENG Q F, LIU W D, HAN Y T. Study on the effect of foaming agent on the solidification performance of silt[J]. *New Building Materials*, 2022, 49(7):138–143.
- [26] 朴春爱, 权宗刚, 唐玉娇. 发泡混凝土微结构的研究进展 [J]. *硅酸盐通报*, 2020, 39(9):2699–2705.
- PIAO C A, QUAN Z G, TANG Y J. Research progress on microstructure of foamed concrete[J]. *Bulletin of the Chinese Ceramic Society*, 2020, 39(9):2699–2705.
- 责任编辑: 何莉