中图法分类号:TP391.7　　**文献标识码**:A　　**文章编号**:1006-8961(XXXX)XX-0001-14

论文引用格式:Huang Guanhui, Liu Xiang, Shi Yunyu, Ji Yu, Wang Shuohong. XXXX. EMPD: An edge-guided multi-perception decoder for medical image segmentation. Journal of Image and Graphics, XX(XX):0001-0014(黄冠珲, 刘翔, 石蕴玉, 纪雨, 王硕鸿. XXXX. EMPD: 面向医学图像分割的边缘引导多重感知解码器. 中国图象图形学报, XX(XX):0001-0014)[DOI:10.11834/jig.250251]

EMPD: 面向医学图像分割的边缘引导多重感知解码器

黄冠珲[1],刘翔[1*],石蕴玉[1],纪雨[1],王硕鸿[2]

1. 上海工程技术大学电子电气工程学院,上海　201620; 2. 哈佛大学分子与细胞生物学系,美国　MA　02138

摘　要:**目的**　医学图像分割在医学影像辅助诊断中具有重要的应用价值,然而传统的神经网络设计很难满足实际需求。为了解决图像边界分割不准确,特征融合有效性不足的问题,提出一种EMPD新型解码器,通过构建有效的边缘信息引导结合多重感知的解码器,实现医学图像的准确分割。**方法**　在保持Pyramid Vision Transformer全局建模能力的同时,引入边缘信息感知模块有效提升模型对空间结构的感知能力。该模块在边缘区域表现出更高的响应性,能够更精确地捕捉结构细节,从而缓解因多次下采样所导致的边缘信息模糊问题;通过设计双重尺度级联门控模块及三维注意力融合模块,能够使得网络以更加全面的视角充分利用编码器的信息,不仅能进行信息筛选还能将编码器与解码器信息有效融合,进而实现了医学图像的准确分割。**结果**　方法在涵盖三类医学图像分割任务的七个公开数据集上进行了系统性评估,在DICE指标方面表现出稳定的性能提升。具体而言,在ClinicDB数据集上,DICE分数相较于现有主流方法提升了1.58%;在五个Polyp数据集及ISIC2017皮肤病变数据集上,平均提升幅度达0.77%。此外,在Synapse多器官分割任务中,本方法在DICE和mIoU指标上分别较同一编码器的PVT-Cascade提升了2.16%和3.81%,进一步验证了其在复杂解剖结构建模方面的有效性与泛化能力。**结论**　实验结果证明本文提出的解码器与主流的方法相比具有更优异的性能,为医学图像分割研究提供了新的工具的同时,能够实现有效的医疗辅助诊断。

关键词:边缘感知;双重尺度级联门控;三维注意力;特征融合;医学图像分割

EMPD: An edge-guided multi-perception decoder for medical image segmentation

Huang Guanhui[1], Liu Xiang[1*], Shi Yunyu[1], Ji Yu[1], Wang Shuohong[2]

1. School of Electronic and Electrical Engineering, Shanghai University of Engineering and Technology, Shanghai 201620, China; 2. Harvard University Department of Molecular and Cellular Biology, MA 02138, USA

Abstract: **Objective** Medical image segmentation refers to the process of accurately separating the regions of interest in medical images from the background, in order to extract key information such as organs and lesion areas, and provide support for subsequent diagnosis, analysis, evaluation, and treatment. At present, benefiting from the widespread application of deep learning, especially convolutional neural networks and Transformer frameworks, it has evolved from traditional manual methods to automated and universal intelligent segmentation stages. Many AI assisted diagnosis and treatment sys-

收稿日期:2025-05-31;**修回日期**:2025-11-09

*通信作者:刘翔 xliu@sues.edu.cn

基金项目:中国上海自然科学基金(19ZR1421500)

Supported by:Shanghai Natural Science Foundation of China(19ZR1421500)

tems are being used in practice. Compared with using simple pixel computing, existing network structures can already recognize various biological information well by extracting and classifying image features, and automated segmentation has made significant progress. However, there are still some challenging issues, such as how to solve the difficulty of edge acquisition, how to fully utilize the obtained features, and how to determine which features among multiple features play a more important role in segmentation judgment. With the deepening of the network layer, the loss of high-frequency detail information leads to blurred and diffused image edges. The reasonable utilization and accurate fusion of multi-level and multi-scale feature information directly affects the accuracy of image segmentation. To address these issues, we introduce the following three modules and propose a novel edge guided multi information perception decoder: edge information perception module, dual scale cascade gating, and three dimensional attention fusion module. **Method** Inspired by U-shaped networks, using EMPD as an decoder after some high-performance encoders can effectively improve the model's segmentation accuracy. The input image first enters a Three-dimensional attention fusion module, which utilizes the encoder input features to interactively fuse positional and channel features. By rearranging the attention mechanism at the pixel location, features from the position, channel, and pixel dimensions are interactively combined to generate a Three-dimensional attention map. This attention map is then applied to the input to extract features at multiple scales for feature enrichment. These features are then interacted with encoder information from the previous layer through two-scale cascade gating. In this section, we simultaneously extract and interact information from different scales and layers to highlight primary information and suppress secondary information. An edge-aware module processes the original image and performs corresponding downsampling and edge extraction operations at different scales. During the progressive upsampling process, multiple operators extract edge information from different perspectives. This combination of multiple edge information, coupled with the introduction of learnable variables, makes it more informative, more learnable, and less expensive than other operators. The final learned result is input into the next layer of Three-dimensional attention fusion module, and finally the multilayer predicted image is combined with the MUTATION loss to obtain the final segmentation result. **Result** This paper conducted experimental evaluations on seven datasets representing three medical image segmentation tasks: the ClincDB, ColonDB, CVC-300, Kvasir, and EITS datasets for single-class polyp segmentation; the ISIC2017 dataset for single-class skin lesion segmentation; and the Synapse dataset for multi-organ segmentation. The proposed method achieved a 1.58% improvement in segmentation performance on the ClinicDB dataset compared to state-of-the-art methods. On the five Polyp and ISIC2017 datasets, the DICE score improved by an average of 0.77% compared to the best-performing network. On the Synapse dataset, DICE and mIoU improved by 2.16% and 3.81%, respectively, compared to PVT Cascade. In the segmentation of small organs such as the left and right kidneys, the DICE score improved by 2.92% and 2.50%, respectively. In the larger stomach region, the proposed method achieved a 3.28% improvement compared to PVT Cascade. Ablation experiments conducted on this architecture demonstrate that, on multiple datasets, the DICE coefficient is improved by more than 3 percentage points compared to a simple encoder cascade architecture. Introducing edge information and combining it with an effective fusion strategy significantly improves the problem of poor edge fitting and enhances overall segmentation accuracy, proving the effectiveness of our proposed module. However, more edge information is not always better. The number and distribution of edge-aware modules need to be controlled. When the image depth is too large, a small number of learnable parameters may be insufficient to compensate for the conflict between semantic and edge information, potentially leading to a decrease in accuracy. **Conclusion** EMPD, combined with high-performance encoder, achieved optimal performance on five datasets and approached the current best results on the remaining two datasets. Its performance surpassed mainstream image segmentation methods and had good generalization properties, providing new tools and model frameworks for medical image segmentation research, helping to achieve effective medical-assisted diagnosis.

Key words: edge perception; dual scale cascaded gating; three-dimensional attention; feature fusion; medical image segmentation

0 引 言

医学图像分割作为计算机辅助诊断系统中的核心任务之一，在现代医疗中扮演着至关重要的角色。随着医学成像技术的飞速发展，临床中产生了大量复杂的图像数据（Cai等，2020），这些图像为疾病检测、术前规划和治疗评估提供了丰富的信息。然而，这些图像通常具有组织结构复杂、边界模糊、对比度低等特点（Wang等，2022），极大地增加了医生人工判读的难度与主观性（Salahuddin等，2022）。传统的手工分割准确率基本可以保证，但对操作者的专业性技能要求较高，往往需要多年的专业培养，通常情况下，一份CT包含上百张图像切片，依靠人工查找对医疗人力资源消耗大（Li等，2025）。在许多医疗场景下，分割结果直接影响到疾病的诊断准确性与治疗策略的制定（Rahman等，2023）。随着计算机和自动分割技术的发展，衍生出诸多医学图像分割模型，缓解了上述情况的发生，然而依然存在如下的问题。首先，医学图像中的组织边缘不明显，存在过渡模糊的情况（Lee等，2020），在获取图像特征的过程中，随着网络的深度，感受野的增大，高频信息会随网络进一步地压缩，从而导致边界定位误差加大（Marmanis等，2018），在上采样的过程中无法还原出原始的精细边界。其次，传统的跳跃连接在编码器浅层特征与解码器深层特征融合时，存在局部感知弱和语义融合不充分的情况（Wang等，2022），并且，网络的多尺度特征提取多基于上采样信息而忽视了编码器多尺度纹理信息，不能对编码器信息充分利用。此外，受限于医学图像的固有限制，难以获取充足且高效的标注数据，数据量的不足也加剧了模型准确分割的困难程度（Hesamian等，2019）。

综上所述，医学图像分割仍存在以下难点：1）医学图像固有的边缘特性及下采样的层层压缩使得边界信息难以捕捉；2）不同分割场景下，病灶及器官尺度变化大，结构信息复杂，不同尺寸目标的感知能力弱，有效的图像特征获取困难；3）不同层次获取的特征语义融合程度低，特征信息难以充分利用，导致分割精度不足。

本文的主要贡献如下：1）提出了一种针对2D医学图像处理的基于边缘信息引导的有效多重感知解码器，将边缘卷积信息表示与上采样信息相结合，减少了边界弥漫情况的产生，提升了分割精度；2）本文提出一种双重尺度级联门控机制，通过引入多尺度分支增强目标感知能力，并将不同层级的编码器特征经上采样级联融合，结合门控机制实现动态加权，有效提升了模型对细粒度结构与多尺度目标的识别能力；3）设计了一种三维注意力融合模块，结合通道交互与空间交互分支提取全局语义依赖与空间位置信息，并引入像素级注意力机制进行细粒度重加权，提升了关键区域的响应能力与整体融合表达的判别性。

1 相关工作

1.1 编码器-解码器框架

早期的解码器通常采用简单的卷积层和下采样层的堆叠结构（Badrinarayanan等，2017），这类设计能有效拓展感受野并提取深层特征，然而，重复的堆叠在获取更加广阔感受野的同时也会导致了深层网络训练困难的情况（Simonyan等，2014），残差神经网络（residual network，ResNet）（He等，2016）引入了残差连接，通过学习输入与输出之间的残差，梯度能够更顺畅地反向传播，使得更深层的网络结构成为可能。（Huang等，2017）通过密集连接实现了高效的特征复用与梯度传导，为构建深层高效解码器提供了理论支撑。为了弥补卷积特征中局部依赖强的问题，部分现代解码器设计开始引入注意力机制如：squeeze and excitation（Hu等，2018）、convolutional block attention module（Woo等，2018）、efficient channel attention（Wang等，2020），通过动态加权的方式实现对通道或空间位置的自适应调整，从而提高网络的表示能力与信息捕捉能力，与此同时，受到自然语言处理中的Transformer架构的启发，视觉方面，Vision Transformer（Dosovitskiy等，2021）与Swin Transformer（Liu等，2021）逐步引入图像分割领域，通过自注意力机制（Self-Attention）进行全局上下文建模，弥补了卷积神经网络（convolutional neural network，CNN）模型在捕捉图像全局结构关系上的不足（Vaswani等，2017），尤其在长程依赖建模和复杂场景的理解上展现出了巨大的优势，为了解决纯卷积网络和纯Transformer网络各自的局限，越来越多的研究开始提出混合模型，通过结合CNN和Transformer的优势，充分利用卷积网络的局部特征提取

能力和Transformer的全局建模能力(Zhang等，2021)。这类混合网络在编码器中通常先通过卷积层提取局部特征，再通过Transformer进行全局信息的捕捉。视觉Transformer-U形网络(vision Transformer-based unet，ViT-UNet)(Zhou等，2024)将传统的U-Net结构与Vision Transformer融合，在网络的编码器部分使用Transformer提取全局特征，而解码器部分使用卷积层进行局部信息恢复。(Jha等，2024)使用基于金字塔视觉Transformer的改进基线模型(improved baselines with pyramid vision Transformer，PVTv2)(Wang等，2022)作为编码器，通过层次化解码结构结合残差与全局注意力机制，有效提升医学图像分割中的全局上下文建模与边界的定位能力。引入Transformer的UNet网络架构(Transformers make strong encoders for medical image segmentation，TransUnet)(Chen等，2021)在有限的医学图像数据上通过预训练-微调策略，以克服小数据集性能有限的问题，虽然这些方法能提升模型的训练效率和泛化能力，但高效提取跨层级网络的多尺度特征仍是模型适应性和分割准确性的关键(Zhang等，2025)。在本文中，旨在提出一种新的医学图像多重感知解码器来进一步细化注意力权重并增强融合特征信息。

1.2 边缘信息

边缘信息可以帮助模型精确地捕捉到这些边界，避免因下采样和特征丢失导致的边缘模糊。早期的边缘信息获取通过边缘检测算子进行分割(Boykov等，2001)，传统的Sobel算子通过一阶微分运算能够快速定位医学影像中的结构边缘，Canny算法(Canny，1986)通过高斯滤波等操作进一步增强了算子的稳定性。U-Net(Ronneberger等，2015)通过其编码器-解码器结构中的跳跃连接有效地保留了边缘信息，从而提高了边界的准确性。双重注意力U-net与特征注入网络(dual attentive u-net with feature infusion，DAU-FI Net)，(Alshawi等，2023)结合U-net，将边缘检测算子注入网络，拓展了特征空间，(Sun等，2022)通过噪声抑制与结构增强的预处理方式提升了图像质量，为后续的临床分析提供了更可靠的输入基础。近年来，研究者在图像分割模型中引入了边缘感知机制，这种机制通过专门设计的边缘引导网络、边缘增强模块等进一步加强边缘区域的特征表达。(Yang等，2025)根据特征内容本身为每个像素动态生成卷积核以增强细小纹理，边缘引导与层级聚合网络(edge-guided and hierarchical aggregation network，EHANet)(Tang等，2025)对层间不同尺度的特征进行传统卷积并使用Softmax函数预测边界图以增强网络分割效果，边缘引导卷积如中心差分卷积(Yu等，2020)，不同于传统卷积，通过计算中心差分等方法增强对局部细节特征的捕捉，帮助网络聚焦于图像中的重要边缘区域，提升了图像的分割精度。多层边缘注意力网络的医学网络(multilayer edge attention network for medical image segmentation，MEA-Net)(Liu等，2022)通过多层边缘注意力机制强化编码阶段的边界特征提取。模型无关边界优化分割方法(Model-Agnostic Boundary Refinement for Segmentation，SegFix)(Yuan等，2020)是一种模型无关的后处理方法，通过学习边界像素的方向信息并进行偏移校正，有效提升了分割结果边界的连贯性与精度。息肉多尺度边缘引导分割网络(multi-scale edge-guided attention network for weak boundary polyp segmentation，MEGANet)(Bui等，2024)设计了一种边缘注意力模块，使用拉普拉斯算子与下采样特征相结合，解决了图像的弱边界问题。这些方法虽在一定程度上提升了边界表达能力，但大多存在边缘响应算子固定或学习能力弱、忽视多层次语义的问题。本文设计了一种基于差分卷积的边缘信息感知模型，通过多方向的差分卷积联合提取边缘响应特征，同时作用于编码器的多个阶段，实现端到端训练下的边界增强与目标精细刻画，有效提升了弱边界区域的分割精度与模型的结构感知能力。

2 方 法

在本节中，首先对EMPD解码器进行整体介绍，然后进一步阐述各模块间的细节机制。

2.1 整体框架

以Transformer为框架的模型在获取全局特征时无法有效地关注边界信息，模型针对图像进行准确分割的过程中会存在分割中断或图像弥漫的情况，无法对图像特征信息充分融合。为了解决这个问题，本文提出了一种新的使用边缘信息引导图像分割的医学图像多重感知解码器。

图1展示了EMPD结合PVTv2编码器的体系框

架，如图所示，位于图像左侧的编码器包含四个视觉金字塔模块从输入的医学图像中捕获不同尺度的特征组，对于编码器输入，使用三维注意力融合模块丰富编码器特征，实现特征加权，上采样信息与下一层编码器信息的融合在实现级联特征融合的同时，分别送入三个双重尺度门控机制，融合全局与局部信息，选择性增强特征，抑制无效信息。在此之后对应尺度的显式边缘特征与输出图像特征进行拼接，获取多重图像特征及卷积所丢失的边缘信息，再次经过三维注意力融合模块进行有效的信息融合，将每一层的输出汇总，结合每张分割图以得到最终的分割结果。

2.2 编码器主干

在医学图像任务中，编码器作为特征提取的基石，单一框架难以兼顾局部细节感知与全局语义的建模，尤其在器官间结构复杂，不同组织分布分散的医学图像中表现受限。本文采用PVT v2作为编码器，通过金字塔结构逐步提取多尺度特征，兼具局部空间建模能力与长距离依赖建模能力。PVT v2包含四个阶段，每一阶段均会产生不同尺度的特征图，本文充分利用这种金字塔式的多尺度特征，按照不同层级将不同尺度的特征作为EMPD的输入信息。

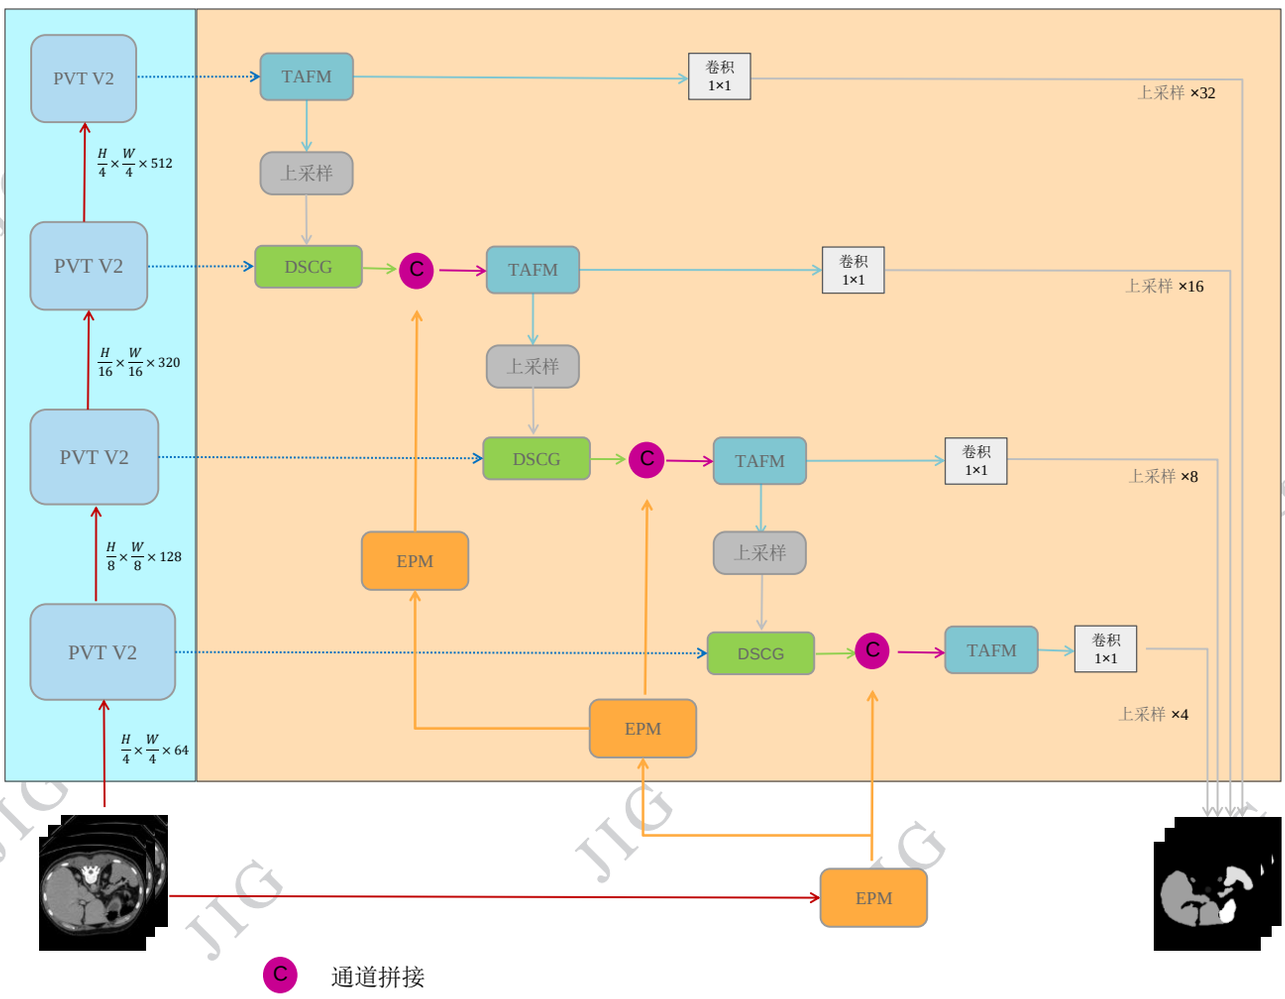

图1 整体框架图

Fig. 1 Overall framework diagram

2.3 边缘信息感知模型(EPM)

差分卷积在EPMs中是通过多种差分卷积结合普通卷积来实现，以往的工作(Su等，2021)验证了相较于普通卷积特征提取和泛化能力均有提升，近来一些工作(Chen等，2024)将其运用到单张图像去雾方向。Prewitt算子采用两个固定的卷积核分别模拟水平和垂直两方向的梯度，进而提取边缘。Sober算子在其工作的基础上，对中间行赋予了更高的权

重,有效的减少了来自上下行的噪声影响,起到了竖向平滑的效果,Canny算子在此基础上加入高斯降噪等步骤使得效果进一步提升,但仍然存在自定义阈值影响大,弱边缘易丢失的情况,除了上述算子还有多种差分算子,以中心差分(CDC)为例,通过使卷积核加权为0,当区域变化不大时,计算结果会趋近于0,从而起到对边缘更加敏感的效果。不同的计算方式产生了多种的差分卷积。本文引入边缘感知模块以融合多种差分卷积信息,在丰富边缘信息的同时加入普通卷积引入了可学习参数,在训练中自动优化,减少了自定义参数的影响。由于编码器各层之间存在尺度变换不一致的问题,传统的固定下采样策略难以实现有效对齐与信息融合。为此,本文设计了分步卷积的分步变形模块,通过保持每次下采样步长为2,实现不同尺度特征的对齐与融合,有效整合多层卷积信息,提升特征表达能力。

$$\mathrm{EMP}(x)=F_3\left\langle\sum_{i=1}^{5}F_3(x)\times ki_3\right\rangle_n \tag{1}$$

式中EMP(·)代表EMP模块的输出,$F_3\langle\cdot\rangle_n$代表n次步长为2,卷积核大小为3的下采样卷积,ki_3在i从1到5的过程中分别代表了五种卷积的卷积参数。$F_3(\cdot)$为融合后的单个卷积核大小为3卷积操作。

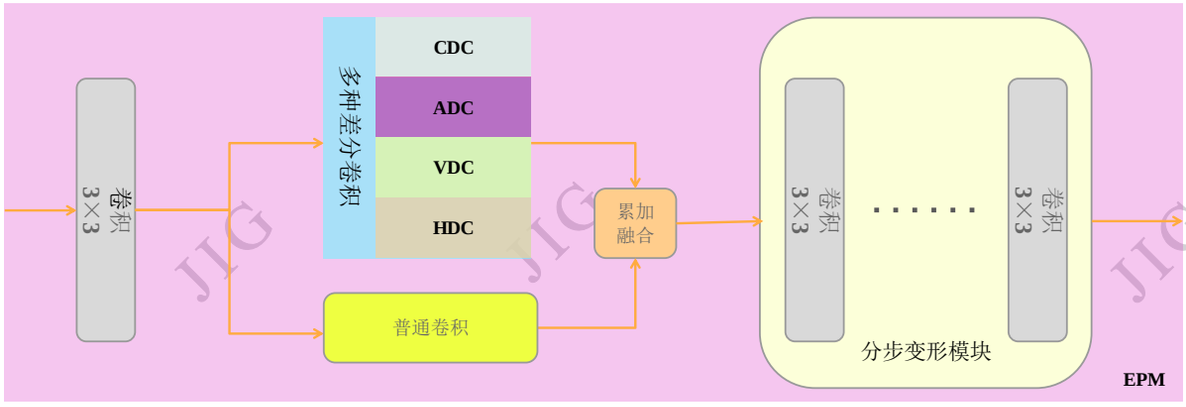

图2 边缘信息感知模块结构图

Fig. 2 Structural diagram of edge information perception module

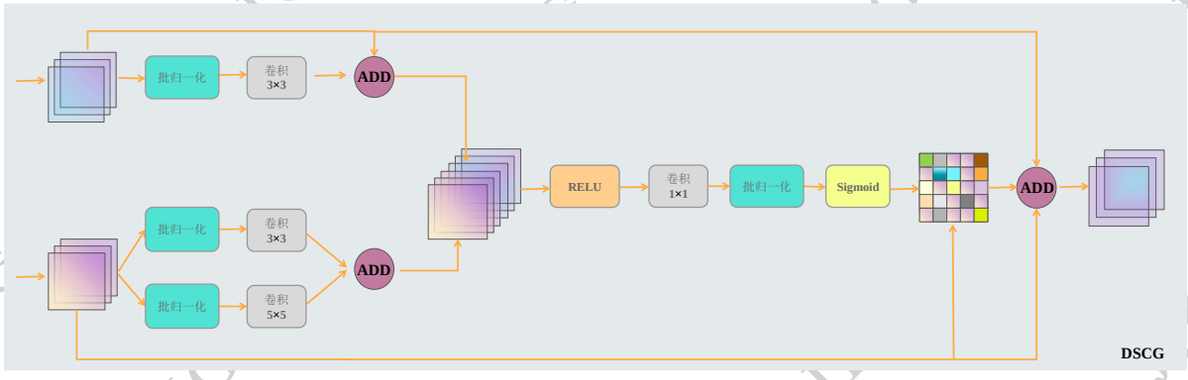

图3 双重尺度级联门控模块结构图

Fig. 3 Structural diagram of dual scale cascaded gate control module

2.4 双重尺度级联门控(DSCG)

编码器在不同尺度下生成四个特征组,信息融合以获取更加丰富的语义信息可以帮助图像分割精度提升,这也是以Unet为代表的U型网络被广泛作为图像分割基石的原因之一。但是简单的上采样相加会引入冗余的特征信息并导致语义信息不匹配的情况。为了解决这个问题,设计了DSCG来处理不同尺度信息融合的情况。图2显示了模型的具体细节。来自不同尺度编码器的特征作为输入分别进入两个支路,每个支路先经过卷积和归一化操作以统一维度与尺度。其次,在模块内部的双分支结构中,显式地提取了具有不同感受野的上下文信息,将两条路径提取的特征在通道维度进行拼接,最终生成门控权重图。该权重图用于动态调整初始输入特征

的通道响应，实现对有效信息的强调与无关信息的抑制，进而实现具有多尺度感受野、融合上下文语义并具备选择性的门控机制。级联门控 DSCG(·)由以下公式得出：

$$F_U = F_3\left(BN\left(F_1(U)\right)\right) + U \tag{2}$$

$$F_I = F_3\left(BN\left(F_1(I)\right)\right) + F_5\left(BN\left(F_1(I)\right)\right) + I \tag{3}$$

$$Att = \sigma\left(BN\left(F_1\left(RE([F_U, F_I])\right)\right)\right) \tag{4}$$

$$\mathrm{DSCG}(U, I) = I \times Att + U \tag{5}$$

式中[·]代表在通道维度进行拼接，$F_x(\cdot)$代表采样 x 大小的卷积核进行卷积，$BN(\cdot)$和 $RE(\cdot)$分别代表批量规范化，*RELU* 激活层，*Att* 代表注意力图，σ为 *sigmoid* 函数。

2.5 三维注意力融合模块(TAFM)

仅具备丰富的特征信息并不足以充分发挥其判别能力。针对医学图像中结构复杂、边界模糊等挑战，仍需进一步挖掘特征之间的深层联系与协同作用，以实现更精准的区域识别与边界定位。为此，本文设计了一种三维注意力融合模块(TAFM)，从通道、空间位置与像素粒度三个维度动态建模特征依赖关系，增强模型的表达能力与细粒度感知能力。TAFM 由通道信息增强模块(CIB)、位置信息建模模块(SIB)、像素混合注意力模块及多尺度信息提取模块(MIM)组成，以捕捉不同维度的判别性特征。设计与空间与通道双重注意力的 Transformer Unet 分割网络(integrating spatial and channel dual attention with transformer u-net for medical image segmentation，DA-TransUnet)(Sun 等，2024)类似，如图 4 所示，本文采用并行结构对输入进行信息提取，再将其进行对应位置的像素值拼接，通过卷积扩大感受野提取融合特征生成信息注意力图，最后通过多尺度融合方法进一步整合各分支特征从而实现全局与局部信息的有效融合，提升特征表达的精细程度与模型在复杂场景下的稳定表达。

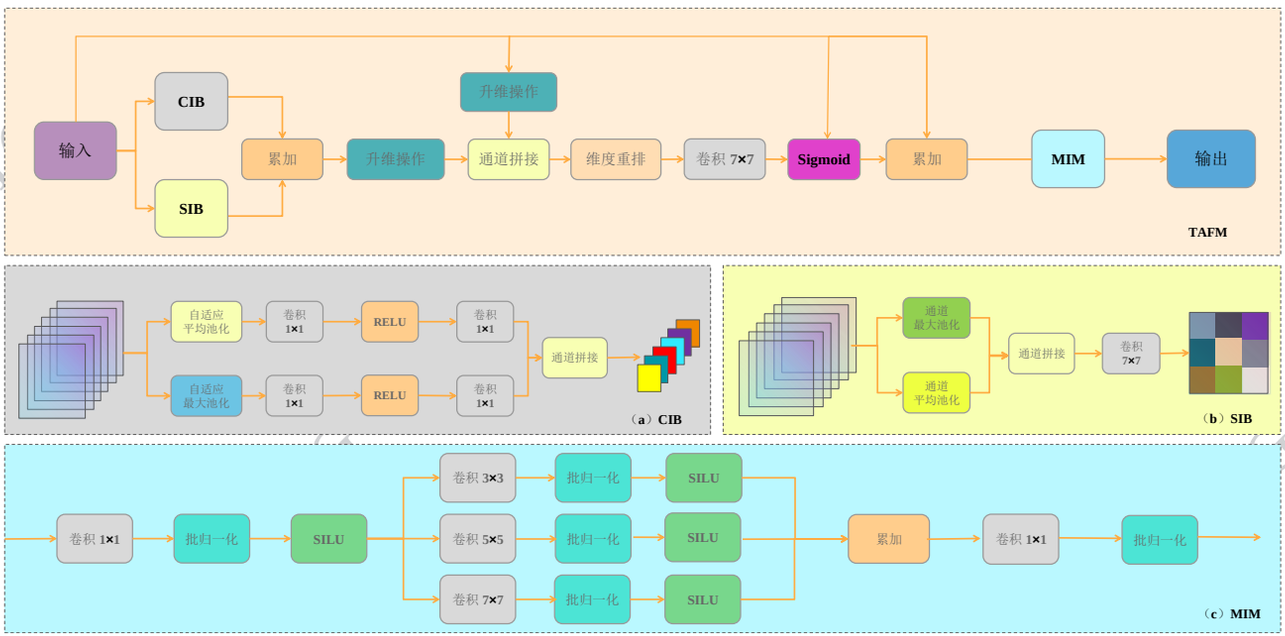

((a) channel information module diagram; (b) position information module diagram; (c) multi-scale inverted bottleneck module diagram)

图 4 三维注意力融合模块框架图，通道信息模块图，位置信息模块图以及多尺度倒置瓶颈模块图

Fig. 4 Three dimensional attention fusion module framework diagram, channel information module diagram, position information module diagram, and multi-scale inverted bottleneck module diagram

$$Att_{\inf}(X) = \sigma\left(F_7\left(\Phi_{rear}\left[r_{\uparrow 2}(\mathrm{CIB} + \mathrm{SIB}), r_{\uparrow 2}(X)\right]\right)\right) \tag{6}$$

$$\mathrm{TAFM}(X) = \mathrm{MIM}\left(X + Att_{\inf}(X) \times X\right) \tag{7}$$

式中[·]代表进行维度拼接，$r_{\uparrow 2}$代表在第 2 维度新增一个维度，Φ_{rearr}代表分组重排操作，$F_7(\cdot)$代表 7×7 卷积，$Att_{\inf}$代表信息注意力图，MIM(·)为下文多尺度瓶颈倒置模块。

2.5.1 通道信息模块(CIB)

通道信息以结构化方式对各通道特征进行全局建模,从而感知不同通道间的依赖关系,并对关键通道进行响应增强,以提升特征表示的选择性与判别能力。CIB的计算公式定义如下:

$$f(X)=F_1\left(RE(F_1(X))\right) \tag{8}$$

$$\mathrm{CIB}(X)=f\left(AAP(X)\right)+f\left(AMP(X)\right) \tag{9}$$

式中$F_1(\cdot)$代表通道映射卷积,两个$F_1(\cdot)$卷积参考瓶颈模块思想,先将通道变成原始的1/16后升维恢复,以减少计算量,$AAP(\cdot)$和$AMP(\cdot)$代表在空间特征图中自适应最大池化和在空间特征图中自适应平均池化。

2.5.2 位置信息模块(SIB)

位置信息模块通过生成响应增强图,对特征图各位置之间的空间依赖关系进行建模,从而显式编码空间位置信息,强化目标区域的表达能力,并提升模型对结构分布的整体感知。SIB的计算公式定义如下:

$$\mathrm{SIB}(X)=F_7\left[CM(X),CA(X)\right] \tag{10}$$

式中$[\cdot]$代表在通道维度进行拼接,$F_7(\cdot)$代表7×7卷积,$CM(X)$是对每个空间位置上的全部通道取平均值,$CA(X)$是对每个空间位置上的全部通道取最大值。

2.5.3 多尺度瓶颈倒置模块(MIM)

MIM采用残差连接以保持三维特征结构的连续性,同时提升模型在梯度传播时的稳定性。类似于移动神经网络架构(inverted residuals and linear bottlenecks, MobileNetV2)(Sandler等, 2018),采用倒置瓶颈结构先升维再降维,在增强信息流动能力的同时,使用多尺度卷积提升特征表达的多样性,增强模型的表达能力。MIM的计算公式定义如下:

$$f_i(X)=SL\left(BN\left(F_{2i+1}(X)\right)\right) \tag{11}$$

$$\mathrm{MIM}(X)=BN\left(F_1\left(\sum_{i=1}^{3}f_i\left(f_0(X)\right)\right)\right)+X \tag{12}$$

式中$F_x(\cdot)$代表采样x大小的卷积核进行卷积,$SL(\cdot)$代表SILU激活层。

2.6 损失

传统损失如Cross Entropy Loss(Krizhevsky等, 2017),Dice Loss(Milletari等, 2016)在多尺度分割中难以协调各输出分支的优化,容易导致训练冲突与泛化不足,MUTATION损失(Rahman等, 2023)组合多个阶段输出生成丰富且互补的监督信号,通过组合预测的方式将模型各阶段输出的预测图进行子集组合,四阶段输出除空集外共有15种组合方式,对每一种组合结果单独计算损失,并将所有组合损失进行聚合,构建隐式集成机制,从而实现稳定协同训练与性能提升。

$$I_s=\sum_{i\in s}p_i \quad \text{where } i\in\{1,2,3,4\} \tag{13}$$

$$L_{total}=\sum_{s\in G}\left(\omega_{\mathrm{ce}}\times L_{\mathrm{CE}}(I_s,y)+\omega_{\mathrm{DI}}\times L_{\mathrm{DI}}(I_s,y)\right) \tag{14}$$

式中G为除空集以外的全部子集序列,p_i为第i层预测图,I_s为s对应子集预测图之和,$L_{\mathrm{CE}}(\cdot)$为交叉熵损失函数,$L_{\mathrm{DI}}(\cdot)$为Dice损失函数,ω_{ce}和ω_{DI}分别为交叉熵与Dice的权重系数。

3 实验结果与分析

在这一部分,首先介绍实验所用的数据集,通过与先进的代表性算法效果进行比较以证明本模型的优越性,最后通过消融实验的形式验证模块的有效性及实验框架的不同方面。

3.1 数据集及评价指标

3.1.1 Polyp数据集

ClinicDB数据集包含从31个结肠镜视频中提取的612张图片,其中550张作为训练集。Kvasir数据集为Kvasir-SEG的息肉数据集中得到的1000张息肉图像,其中900张作为网络的训练集。遵循CASCADE中的数据集格式,将两个数据集中的训练集图像组合作为模型训练集,同时将剩余的62张ClinicDB图像与100张Kvasir图像作为各自数据集的测试集。模型同时应用于CVC-300,ColonDB以及ETIS数据集,分别包含60,380以及196张图像。

3.1.2 Synapse数据集

Synapse数据集包含30例增强腹部CT扫描,每例由512×512像素的切片组成。按照6:4的比例随机划分,遵循TransUnet数据集格式,其中18例用于训练,12例用于验证。选取左肾、右肾、主动脉、脾脏、胆囊、肝脏、胃和胰腺共八个器官,用于多器官分割任务。

3.1.3 ISIC2017数据集

ISIC2017数据集由国际皮肤影像挑战赛提供,

遵循TransFused所设置的数据格式，其中共计2000张图像作为训练集，150张图像构成验证集，600张图片构成测试集。

3.2 评估指标

在Polyp及ISIC2017数据集中采用*DICE*得分作为评估标准，在Synapse数据集中添加mIoU指标进行共同评估，*DICE*得分*DICE*(P, G)，mIoU分数*mIoU*(P, G)计算方式如以下方程所示：

$$Dice(P,G) = \frac{2|P \cap G|}{|P| + |G|} \tag{15}$$

$$mIoU(P,G) = \frac{1}{C}\sum_{i=1}^{C}\frac{|P_i \cap G_i|}{|P_i \cup G_i|} \tag{16}$$

式中P，G分别为预测分割区域和真实标签区域，C为类别数，从1开始代表除背景类外的类别，P_i和G_i分别代表预测与真实的第i类别像素集合。

3.3 实验设置

本实验基于Pytorch框架实现，模型在单个具有24GB显存的NVIDIA-GeForce-RTX-4090显卡上进行训练。PVTv2网络在ImageNet数据集进行预训练并作为本模型的编码器部分，训练采用AdamW优化器，学习率与权重衰减为1e-4，在Synapse数据集训练300个Epoch，批次大小为6，其余数据集训练200个Epoch，批次大小为12。本文在Synapse数据集上采用90°倍数旋转加随机反转后再进行[-20°，20°]随机小角度旋转，其余数据集未进行数据增强。Polyp数据集输入转化为352×352图像大小，使用[0.75，1，1.25]三个尺度进行训练。

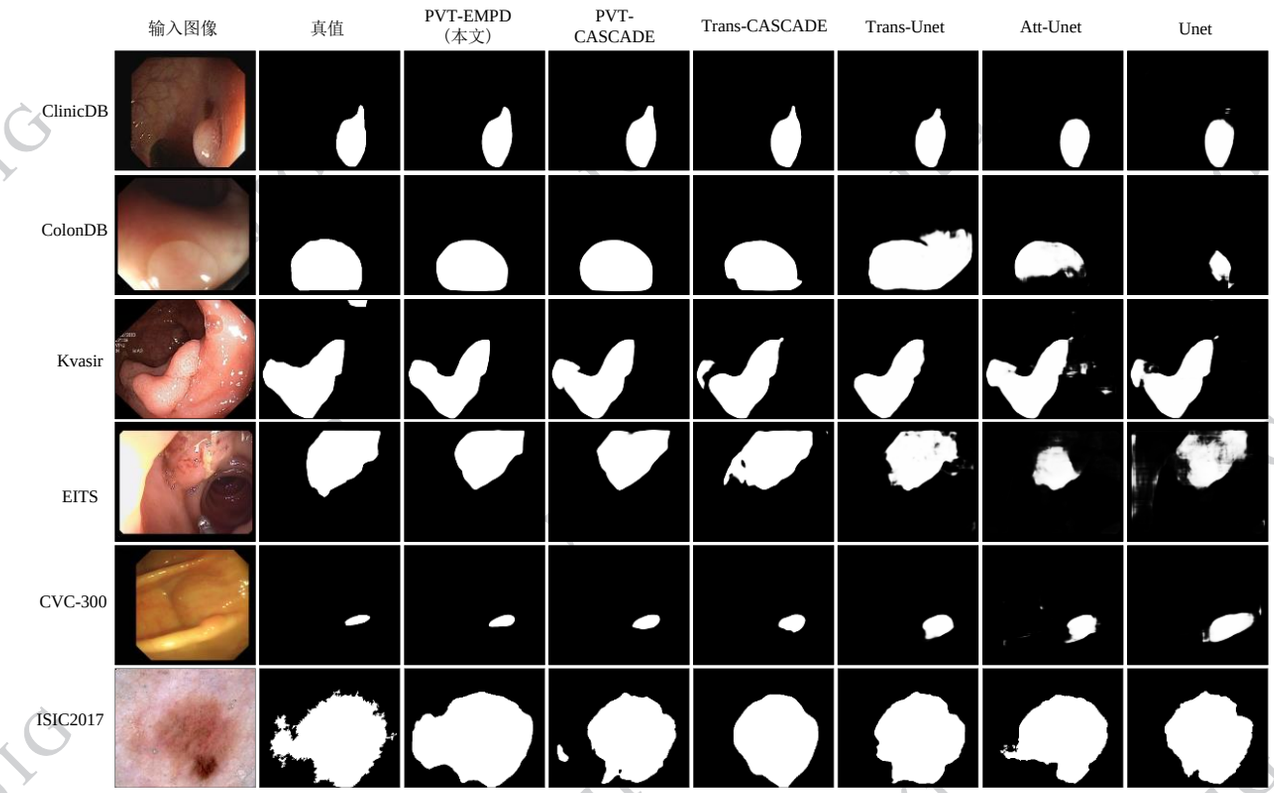

图5 可视化分割结果在Polyp与ISIC2017数据集主流的方法进行定性比较

Fig. 5 Qualitative comparison of visualization segmentation results between mainstream methods in the Polyp and ISIC2017 datasets

3.4 数据集实验结果分析

本文在多个医学图像分割数据集上对所提出的EMPD解码器进行了全面性能评估，涵盖消化道息肉与皮肤图像的二分类任务（Polyp和ISIC2017）以及多器官分割的多分类任务（Synapse）。

这三个方向代表了临床应用中常见的两类任务场景：结构边界不清晰的小目标检测与多类复杂器官分割。

表1展示了与当前基于CNN、Transformer以及二者融合结构的主流图像分割网络在Polyp和ISIC2017数据集上的对比结果。可以看出，EMPD解码器在四个数据集上取得了最高的DICE分数，在另外两个数据集上仅次于最优表现。以ClinicDB为例，相较于同样采用PVT编码器的PVT-Cascade，

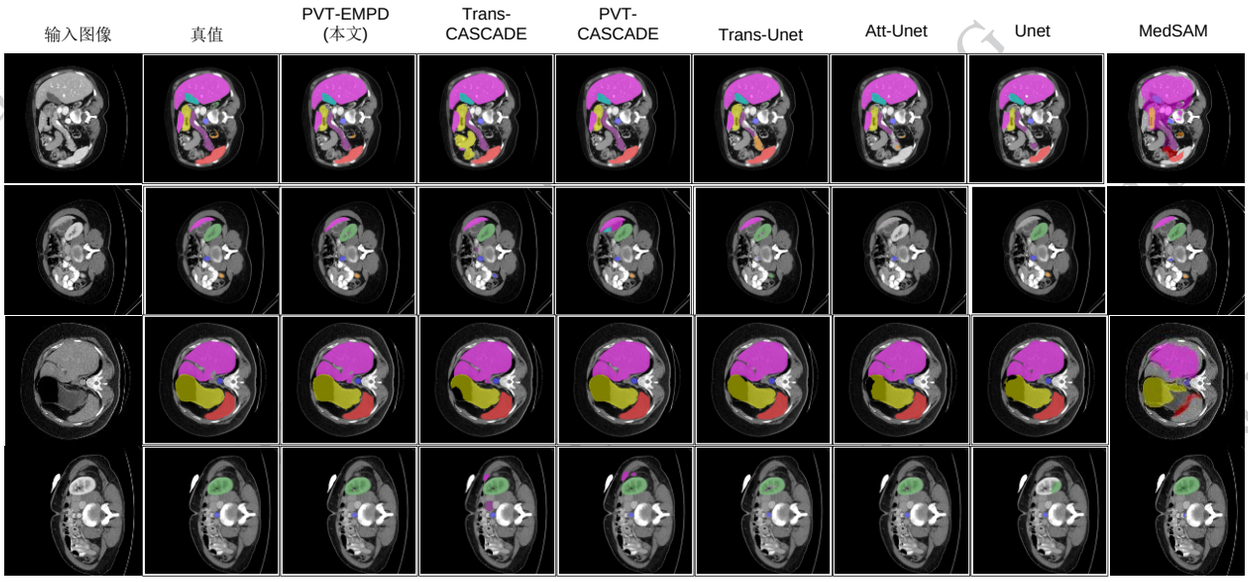

图6　可视化分割结果在Synapse数据集与主流方法进行定性比较

Fig. 6　Qualitative comparison of visualized segmentation results between the Synapse dataset and mainstream methods

表1　息肉分割数据集及ISIC2017皮肤病变分割数据集结果

Table 1　Results of polyp segmentation dataset and ISIC2017 skin lesion segmentation dataset

/%

方法	ClinicDB	ClonoDB	Kvasir	EITS	CVC-300	ISIC2017	均值
Unet	71.37	53.31	81.03	40.86	71.38	82.60	66.76
AttnUnet	72.53	54.48	81.46	40.49	74.24	82.19	67.56
TransUnet	86.88	64.90	84.99	54.86	83.62	82.66	76.32
TransCascade	91.66	78.02	90.64	72.13	87.59	**84.28**	84.05
PVT-Cascade	92.87	81.24	91.96	**76.79**	89.25	82.63	85.79
PVT-EMPD	**94.45**	**81.98**	**92.83**	75.96	**89.94**	84.19	**86.56**

注：加粗、下划线字体分别表示各列最优、次优结果。

表2　Synapse多器官分割数据集整体及各器官结果

Table 2　Multi organ segmentation dataset overall and individual organ results

/%

方法	DICE	mIoU	主动脉	胆囊	左肾	右肾	肝脏	胰腺	脾脏	胃
MedSAM	59.41	52.16	71.80	32.96	71.24	68.57	44.00	**73.36**	44.00	69.34
Unet	77.72	68.29	86.84	62.94	81.50	75.27	94.13	59.11	86.58	75.39
AttnUnet	78.27	68.98	88.20	61.67	81.76	78.38	93.07	62.69	86.44	73.97
TransUnet	76.17	65.59	87.69	63.69	75.84	72.37	92.73	54.01	85.84	77.21
PVTCascade	81.98	71.28	84.15	69.43	85.07	82.13	94.89	68.68	90.23	81.24
TransCascade	82.74	73.83	87.73	69.04	86.70	82.71	95.08	69.52	91.15	79.99
PVT-EMPD	**84.14**	**75.09**	**88.18**	**70.17**	**87.99**	**84.63**	**95.59**	70.84	**91.22**	**84.52**

注：加粗、下划线字体分别表示各列最优、次优结果。

DICE分数提升了1.58%，在六个数据集上平均提升0.77%。这表明EMPD解码器具有良好的泛化性能，能够适应不同器官下的二分类分割任务并稳定提升分割精度。

在多类别的Synapse数据集上，进一步评估了模型在复杂器官分割任务中的表现。表2给出了各方法的详细对比结果。医学分割大模型如MedSAM（Ma等，2024）在输入时需要额外信息指定输入位置，相较于其他模型可以在确定的小范围内进行分割避免误分类的情况，因此在不规则且经常间断性出现的胰腺分割存在优势，与PVT-Cascade相比，本文提出的模型在DICE和mIoU上分别提升了2.16%和3.81%。就具体器官来说，在小器官如左肾与右肾的分割上DICE分数分别提升2.92%和2.50%，在胃部较大器官区域提升3.28%。这主要得益于解码器中引入的多尺度特征整合与边缘感知机制，增强了对小目标与模糊边界结构的识别能力，提升了整体分割精度。

3.5 EMPD不同组成部分的有效性

本文在三类医学图像分割任务的七个公开数据集上设计并开展了多组消融实验，旨在系统评估所提出模型各个关键模块对整体性能的影响与泛化能力。首先以采用ImageNet预训练的PVTv2编码器为基础模型，结合级联解码结构构建初始模型框架作为对比基线。在此基础上，逐步引入本文提出的三大核心模块：三维注意力融合模块、边缘增强模块以及双重尺度注意力模块，并分别评估其独立和联合使用时对分割性能的贡献。实验结果如表3所示，三维注意力融合模块显著提升了模型对关键语义区域的响应能力。该模块通过在通道、空间及像素层面上建模多维注意力，有效引导网络聚焦于器官边界及关键结构区域，从而提升了分割精度。进一步地，加入边缘增强模块后，模型对器官边界的识别能力得到了进一步加强。该模块融合低级特征中的边缘线索，有助于缓解高层特征中的语义模糊问题，从而在提高边界清晰度的同时，保持了全局结构的一致性。双重尺度注意力模块通过在不同尺度上对输入特征进行细粒度建模与筛选，使得网络能够在保留丰富上下文信息的同时，抑制冗余或干扰区域的信息流入，为后续的特征融合与判别提供了更加稳健的表达支持。最终，当三大模块协同工作时，模型在评价指标上均取得了最优表现，验证了各模块之间的互补性与协同增强效果，充分说明了本文方法在提升医学图像分割性能方面的有效性与实用性。

表3　以PVT-V2为骨架的组件消融实验

Table 3　Component ablation experiments using PVT-V2 as the skeleton

/%

组件			Synapse	ClinicDB	ClonoDB	Kvasir	EITS	CVC-300	ISIC2017
TAFM	EPM	DSCG	DICE						
			81.10	92.19	78.34	91.09	72.21	88.77	82.66
✔			81.94	92.86	78.37	91.78	72.55	89.15	82.92
✔		✔	82.16	93.60	79.24	91.90	72.92	89.85	83.15
✔	✔		83.22	93.63	81.09	90.98	74.74	89.77	83.62
✔	✔	✔	**84.14**	**94.45**	**81.98**	**92.83**	**75.96**	**89.94**	**84.19**

注：加粗字体表示各列最优结果，“　”为未使用，“✔”为使用

3.6 EPM块位置影响

边缘信息感知模块已经证明其在解码器上的有效性，在图像的中上层，融合边缘信息带来了明显的收益，但在最深层，由于特征图的高度抽象，主要承载语义信息，此时，少量的参数增不足以弥补过多边缘特征引入导致的信息冲突，可能会出现准确率略有下降的情况。尽管如此，其性能仍然优于仅在浅层单一阶段引入边缘信息的场景。

4 总　结

为提升医学图像分割精度，本文提出一种基于边缘信息引导的多重感知解码器，该解码器能有效地将边缘信息与多尺度多阶段的图像信息相结合，

表4　不同位置结合EPM模块的实验结果

Table 4　Experimental results combining EPM modules at different locations

/%

位置	参数量	DICE
[1]	27.19M	82.87
[1,2]	27.99M	**84.14**
[1,2,3]	33.68M	83.26

注：加粗字体为各列最优结果。

利用双重门控机制在筛选信息的同时结合三维注意力机制，使得图像能够更加精确的学习到边缘信息以突出重点减少边界弥漫，提升图像分割的准确程度，这对医学图像分割来说十分重要。实验结果相对于其他主流的方法在五个数据集的DICE分数上取得最好的效果并在其他两个数据集上与最好结果近似，显示了EMPD所具有的优异性能和泛化能力。

在以后的工作中将探索EMPD模型在多模态医学图像分割任务中的表现，以进一步验证其在不同成像手段下的适应性和鲁棒性。此外，还将使用本方法与医学大模型进行结合，引入语义先验信息以辅助分割模型对复杂结构的理解，从而提升模型的可解释性和诊断价值。

参考文献(References)

Alshawi R, Hoque M T, Ferdaus M M, Abdelguerfi M, Niles K, Prathak K, Tom J, Klein J, Mousa M and Lopez J J. 2023. Dual Attention U-Net with Feature Infusion: Pushing the Boundaries of Multiclass Defect Segmentation[EB/OL]. [2025-09-14]. https://arxiv.org/pdf/2312.14053.pdf

Badrinarayanan V, Kendall A and Cipolla R. 2017. SegNet: A Deep Convolutional Encoder-Decoder Architecture for Image Segmentation. IEEE Transactions on Pattern Analysis and Machine Intelligence, 39(12): 2481—2495. [DOI: 10.1109/TPAMI.2016.2644615]

Boykov Y and Jolly M P. 2001. Interactive Graph Cuts for Optimal Boundary & Region Segmentation of Objects in N-D Images//Proceedings of the Eighth IEEE International Conference on Computer Vision. Vancouver, Canada: IEEE: 105—112. [DOI: 10.1109/ICCV.2001.937505]

Bui N T, Hoang D H, Nguyen Q T, Tran M T and Le N. 2024. MEGANet: Multi-Scale Edge-Guided Attention Network for Weak Boundary Polyp Segmentation//Proceedings of the 2024 IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, HI, USA: IEEE: 4219-4228 [DOI: 10.1109/WACV57701.2024.00422]

Cai L, Gao J and Zhao D. 2020. A Review of the Application of Deep Learning in Medical Image Classification and Segmentation. Annals of Translational Medicine, 8(11): 713 [DOI: 10.21037/atm.2020.02.44]

Canny J. 1986. A Computational Approach to Edge Detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, PAMI-8(6): 679-698 [DOI: 10.1109/TPAMI.1986.4767851]

Chen J, Lu Y, Yu Q, Luo X, Adeli E, Wang Y, Lu L, Yuille A L and Zhou Y. 2021. TransUNet: Transformers Make Strong Encoders for Medical Image Segmentation//Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham, Switzerland: Springer: 492-502 [DOI: 10.1007/978-3-030-87193-2_49]

Chen Z X, He Z W and Lu Z M. 2024. DEA-Net: Single Image Dehazing Based on Detail-Enhanced Convolution and Content-Guided Attention. IEEE Transactions on Image Processing, 33(1): 917-930 [DOI: 10.1109/TIP.2023.3339823]

Dosovitskiy A, Beyer L, Kolesnikov A, Weissenborn D, Zhai X, Unterthiner T, Dehghani M, Minderer M, Heigold G, Gelly S, Uszkoreit J and Houlsby N. 2020. An Image Is Worth 16×16 Words: Transformers for Image Recognition at Scale [EB/OL]. [2025-09-14]. https://arxiv.org/pdf/2010.11929.pdf

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, USA: IEEE: 770-778 [DOI: 10.1109/CVPR.2016.90]

Hesamian M H, Jia W, He X and Kennedy P. 2019. Deep Learning Techniques for Medical Image Segmentation: Achievements and Challenges. Journal of Digital Imaging, 32(4): 582-596 [DOI: 10.1007/s10278-019-00227-x]

Huang G, Liu Z, Van Der Maaten L and Weinberger K Q. 2017. Densely Connected Convolutional Networks//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, USA: IEEE: 4700-4708 [DOI: 10.1109/CVPR.2017.243]

Hu J, Shen L and Sun G. 2018. Squeeze-and-Excitation Networks//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 7132-7141 [DOI: 10.1109/CVPR.2018.00745]

Jha D, Tomar N K, Biswas K, Durak G, Medetalibeyoglu A, Antalek M, Velichko Y, Ladner D, Borhani A and Bagci U. 2024. CT Liver Segmentation via PVT-based Encoding and Refined Decoding//Proceedings of the 21st IEEE International Symposium on Biomedical Imaging. Athens, Greece: IEEE: 1-5 [DOI: 10.1109/ISBI56570.2024.10635659]

Krizhevsky A, Sutskever I and Hinton G E. 2017. ImageNet Classifica-

tion with Deep Convolutional Neural Networks. Communications of the ACM, 60(6): 84-90 [DOI: 10.1145/3065386]

Lee H J, Kim J U, Lee S, Kim H G and Ro Y M. 2020. Structure Boundary Preserving Segmentation for Medical Image with Ambiguous Boundary//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 4817-4826 [DOI: 10.1109/CVPR42600.2020.00487]

Liu H L, Feng Y, Xu H, Liang S F, Liang H Z, Li S K, Zhu J J, Yang S and Li F F. 2022. MEA-Net: Multilayer Edge Attention Network for Medical Image Segmentation. Scientific Reports, 12: 7868 [DOI: 10.1038/s41598-022-11721-y]

Liu Z, Lin Y, Cao Y, Hu H, Wei Y, Zhang Z, Lin S and Guo B. 2021. Swin Transformer: Hierarchical Vision Transformer Using Shifted Windows//Proceedings of the IEEE/CVF International Conference on Computer Vision. Montreal, Canada: IEEE: 10012-10022 [DOI: 10.1109/ICCV48922.2021.00986]

Li Y C, Chen D L, Guo D H and Sun Y. 2025. Integrating spatiotemporal features and temporal constraints for dual-modal breast tumor diagnosis. Journal of Image and Graphics, 30(1): 268-281 (李一宸, 陈大力, 郭丁豪, 孙羽. 2025. 融合时空特征与时间约束的双模态乳腺肿瘤诊断. 中国图象图形学报, 30(1): 268-281) [DOI: 10.11834/jig.240217]

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]

Marmanis D, Schindler K, Wegner J D, Galliani S, Datcu M and Stilla U. 2018. Classification with an edge: Improving semantic image segmentation with boundary detection. ISPRS Journal of Photogrammetry and Remote Sensing, 135: 158-172 [DOI: 10.1016/j.isprsjprs.2017.11.009]

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, USA: IEEE: 565-571 [DOI: 10.1109/3DV.2016.79]

Rahman M M and Marculescu R. 2023. Medical Image Segmentation via Cascaded Attention Decoding//Proceedings of the IEEE/CVF Winter Conference on Applications of Computer Vision. Waikoloa, HI, USA: IEEE: 6222-6231 [DOI: 10.1109/WACV56629.2023.00982]

Rahman M M and Marculescu R. 2023. Multi-scale hierarchical vision transformer with cascaded attention decoding for medical image segmentation//Proceedings of Machine Learning Research, MIDL 2023 - Full paper track. 227: 1526-1544

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, Germany: Springer: 234-241 [DOI: 10.1007/978-3-319-24574-4_28]

Salahuddin Z, Woodruff H C, Chatterjee A and Lambin P. 2022. Transparency of deep neural networks for medical image analysis: A review of interpretability methods. Computers in Biology and Medicine, 140: 105111 [DOI: 10.1016/j.compbiomed.2021.105111]

Sandler M, Howard A, Zhu M, Zhmoginov A and Chen L C. 2018. MobileNetV2: Inverted Residuals and Linear Bottlenecks// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Salt Lake City, USA: IEEE: 4510-4520 [DOI: 10.1109/CVPR.2018.00474]

Simonyan K and Zisserman A. 2014. Very Deep Convolutional Networks for Large-Scale Image Recognition[EB/OL]. [2025-09-14]. https://arxiv.org/abs/1409.1556

Sun G D, Shi Y Y and Liu X. 2022. Feature extraction algorithm based on carotid artery ultrasound vessels. Laser & Optoelectronics Progress, 59(10): 1017002-1) - 1017002-7)孙国栋, 石蕴玉, 刘翔. 2022. 基于颈动脉超声血管的特征提取算法. 激光与光电子学进展, 59(10): 1017002-1) (- 1017002-7 [DOI: 10.3788/LOP202259.1017002]

Sun G, Pan Y, Kong W, Xu Z, Ma J, Racharak T, Nguyen L M and Xin J. 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]

Su Z, Liu W, Yu Z, Hu D, Liao Q, Tian Q, Pietikäinen M and Liu L. 2021. Pixel Difference Networks for Efficient Edge Detection. IEEE Transactions on Pattern Analysis and Machine Intelligence, 43(11): 3764-3779 [DOI: 10.1109/TPAMI.2020.2991239]

Tang Y, Zhao D, Pertsau D, Gourinovitch A and Kupriyanava D. 2025. Edge-guided and hierarchical aggregation network for robust medical image segmentation. Biomedical Signal Processing and Control, 101: 107202 [DOI: 10.1016/j.bspc.2025.107202]

Vaswani A, Shazeer N, Parmar N, Uszkoreit J, Jones L, Gomez A N, Kaiser Ł, and Polosukhin I. 2017. Attention is all you need// Advances in Neural Information Processing Systems. 6000-6010

Wang H N, Cao P, Wang J Q and Zaiane O R. 2022. UCTransNet: Rethinking the Skip Connections in U-Net from a Channel-Wise Perspective with Transformer// Proceedings of the AAAI Conference on Artificial Intelligence. Virtual Event: AAAI Press: 2441-2449 [DOI: 10.1609/aaai.v36i2.20044]

Wang Q L, Wu B G, Zhu P F, Li P H, Zuo W M, and Hu Q H. 2020. ECA-Net: Efficient channel attention for deep convolutional neural networks//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. 11531-11539 [DOI: 10.1109/CVPR42600.2020.01155]

Wang R S, Lei T, Cui R X, Zhang B T, Meng H Y and Nandi A K. 2022. Medical image segmentation using deep learning: A survey. IET Image Processing, 15(11): 3244-3267 [DOI: 10.1049/ipr2.12419]

Wang W, Xie E, Li X, Fan D P, Song K, Liang D, Lu T, Luo P and

Shao L. 2022. PVT v2: Improved baselines with Pyramid Vision Transformer. Computational Visual Media, 8(3): 415-424 [DOI: 10.1007/s41095-022-0274-8]

Woo S, Park J, Lee J Y and Kweon I S. 2018. CBAM: Convolutional Block Attention Module// Proceedings of the European Conference on Computer Vision. Munich, Germany: Springer: 3-19 [DOI: 10.1007/978-3-030-01234-2_1]

Yang K X, Liu L, Fu X D, Liu L J and Peng W. 2025. Scale feature representation learning network for retinal vessels image segmentation. Journal of Image and Graphics, 30(3): 0855-0869 (杨可欣, 刘骊, 付晓东, 刘利军, 彭玮. 2025. 视网膜血管图像分割的尺度特征表示学习网络. 中国图象图形学报, 30(3): 0855-0869) [DOI: 10.11834/jig.240120]

Yuan Y H, Xie J Y, Chen X L and Wang J D. 2020. SegFix: Model-Agnostic Boundary Refinement for Segmentation// Proceedings of the European Conference on Computer Vision. Glasgow, UK: Springer: 489-506 [DOI: 10.1007/978-3-030-58539-6_29]

Yu Z, Zhao C, Wang Z, Qin Y, Su Z, Li X, Yang G, Zhao G, Liu Z and Lei Z. 2020. Searching Central Difference Convolutional Networks for Face Anti-Spoofing// Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. Seattle, USA: IEEE: 5295-5305 [DOI: 10.1109/CVPR42600.2020.00534]

Zhang D P, Li Z, Xie Y G, Wang D Y, Tang S L, Bu Y Z and Wang M T. 2025. Boundary cue deep fusion polyp image segmentation network. Journal of Image and Graphics, 30(5): 1479-1496 (章东平, 李铮, 谢亚光, 王都洋, 汤斯亮, 卜玉真, 王梦婷. 2025. 边界线索深度融合息肉图像分割网络. 中国图象图形学报, 30(5): 1479-1496) [DOI: 10.11834/jig.240383]

Zhang Y, Liu H and Hu Q. 2021. TransFuse: Fusing Transformers and CNNs for Medical Image Segmentation// Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Strasbourg, France: Springer: 14-24 [DOI: 10.1007/978-3-030-87237-3_2]

Zhou N, Xu M M, Shen B Q, Hou K, Liu S W and Sheng H. 2024. ViT-UNet: A Vision Transformer Based UNet Model for Coastal Wetland Classification Based on High Spatial Resolution Imagery. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 17: 19575-19587 [DOI: 10.1109/JSTARS.2024.3487250]

作者简介

黄冠珲, 男, 硕士研究生, 主要研究方向为医学影像分析, 计算机视觉。Email: beihuan1meng@gmail.com

刘翔, 通讯作者, 男, 教授, 硕士生导师, 主要研究方向为医学影像分析, 计算机视觉与人工生命。Email: xliu@sues.edu.cn

石蕴玉, 女, 博士研究生, 主要研究方向为医学影像分析。Email: yunyushi@sues.edu.cn

纪雨, 男, 讲师, 主要研究方向为垂直领域大模型及其优化。Email: yuji0201@outlook.com

王硕鸿, 女, 博士研究生, 副研究员, 主要研究方向为计算机视觉、医学生物学图像处理和机器学习。wangsh@fas.harvard.edu