

基于上下文感知的轻量化医学图像分割方法

杨晋权 胡永祥*

湖南工业大学, 中国·湖南 株洲 412100

摘要: 针对临床实时分析、边缘设备部署以及资源受限平台中, 提出了一种轻量化医学图像分割模型 NeoMorphUNet。该模型在保持 U 型结构的基础上, 从特征提取、跳跃连接增强和跨层融合三个关键环节进行轻量化设计。具体而言, 通过构建 CHC Block 提升多尺度上下文信息和方向结构特征的提取能力; 引入 SAG Block 增强浅层特征的目标响应能力, 并设计 GAF Block 实现深浅层特征的高效融合, 从而在降低模型复杂度的同时保持较好的分割性能。在两个公开数据集上的实验结果表明, 该模型在显著减少参数量与计算量的情况下仍具备较强竞争力。

关键词: 医学图像分割; 注意力机制; 轻量化

A Context-Aware Lightweight Medical Image Segmentation Method

Yang Jinquan, Hu Yongxiang*

Hunan University of Science and Technology, China Hunan Zhuzhou 412100

Abstract: We propose NeoMorphUNet, a lightweight medical image segmentation model designed for real-time clinical analysis, edge device deployment, and resource-constrained platforms. While retaining the U-shaped architecture, this model incorporates lightweight design strategies across three key aspects: feature extraction, enhanced skip connections, and cross-layer fusion. Specifically, the CHC Block is constructed to enhance the extraction of multiscale contextual information and directional structural features; the SAG Block is introduced to improve the target response capability of shallow-layer features; and the GAF Block is designed to achieve efficient fusion of deep and shallow-layer features. This approach maintains strong segmentation performance while reducing model complexity. Experimental results on two public datasets demonstrate that the model remains highly competitive despite a significant reduction in the number of parameters and computational cost.

Keywords: Medical image segmentation; Attention mechanism; Lightweight

0 引言

医学图像分割是医学图像分析的基础任务, 在病灶定位、器官轮廓提取、手术规划及疗效评估中意义重大。随着深度学习发展, 分割方法已从传统图像处理转向以卷积神经网络为主的端到端学习^[1]。U-Net^[2] 凭借编码器-解码器结构与跳跃连接, 在多尺度特征提取方面表现优异, 衍生出 UNet++^[3]、Attention U-Net^[4]、CE-Net^[5] 等改进模型; DeepLabV3+^[6]、TransUNet^[7]、Swin-UNet^[8] 及 SegFormer^[9] 则从空洞卷积^[10]、Transformer^[11] 和轻量解码器设计等角度进一步提升性能。现有研究表明, 增强特征表达、优化多尺度融合与全局上下文建模是提升分割精度的关键。然而, 高精度模型往往复杂度高、参数量大, 限制了其在临床实时分析、边缘设备和资源受限平台中的应用^[12-13]。

现有轻量化方法多通过减少网络深度/宽度或使用深度可分离卷积来降低复杂度, 但常以牺牲特征表达为代价, 导致边界细节、结构完整性与复杂目标刻画能力下降。这一问题在 GLAS 腺体分割(形态多样、边界不规则、易粘

连)和 ISIC2018 皮肤病变分割(低对比度、边界不连续、背景复杂)中尤为突出。因此, 需在特征提取、关键区域增强及跨层信息融合等方面进行针对性优化。为此, 本文提出轻量化模型 NeoMorphUNet。该模型保留 U 型结构, 从特征提取、跳跃连接增强及跨层特征融合三方面进行轻量化设计: 构建 CHC Block 增强多尺度上下文与方向结构特征; 引入 SAG Block 增强浅层特征以突出关键区域; 设计 GAF Block 实现深浅层特征高效融合。在 GLAS 与 ISIC2018 数据集上, 通过定量分析、可视化和消融实验验证了模型在降低参数量和计算复杂度的同时保持良好分割性能。

1 模型整体架构




图1 NeoMorphUNet的整体架构

图 1 展示了 NeoMorphUNet 的整体架构。该网络采用轻量化的编码器—解码器结构，通过逐级下采样与上采样实现多尺度特征提取与空间细节恢复。在保持框架简洁的同时，模型强化了编码阶段的多尺度表征与解码阶段的跨层特征引导融合，从而在低计算开销下有效建模目标边界、纹理和上下文信息。编码阶段，输入图像经基础卷积层后进入由多个编码层构成的下采样路径。每个编码层以 CHC Block 为核心，通过多分支深度卷积提取不同感受野下的特征增强对尺度变化、方向结构和复杂边界的建模能力。随着网络加深，特征图分辨率降低，语义信息增强，获得更具判别性的高层表示。NeoMorphUNet 体现了“轻量化编码、多尺度增强、跨层引导、逐级解码”的设计思路。CHC Block 提升编码阶段的多尺度建模能力，SAG Block 强化跳跃连接中的特征选择性表达，GAF Block 优化深浅层特征融合效果。三者协同，使模型在低复杂度下更好地应对目标尺度变化大、边界模糊及背景干扰等挑战。

1.1 上下文感知异构卷积模块

在医学图像分割中，病灶等目标具有明显的尺度与方向变化，对特征图的多尺度表达能力要求较高。传统卷积使用单一尺度卷积核，难以同时捕获不同尺度和方向的上文信息，且大卷积核计算量大，不利于轻量化设计。




图2 CHC Block模块示意图

为此，本文提出上下文感知异构卷积模块（CHC Block）。该模块在轻量化基础上，引入非对称深度卷积与膨胀深度卷积的并行结构，联合建模局部方向特征与全局上下文信息，提升对复杂边界与多尺度目标的表征能力。模块由特征压缩单元、异构卷积分支与特征融合单元组成。

设输入特征图为 $X \in \mathbb{R}^{B \times C \times H \times W}$ ，首先经 1×1 卷积、批归一化与 ReLU 进行特征预处理：

$$X_0 = \text{ReLU}(\text{BN}(\text{Conv}_{1 \times 1}(X))) \quad (1)$$

随后进入两条并行分支：非对称深度卷积（ 3×1 与 1×3 串联），增强对水平 / 垂直方向边缘与细长结构的刻画能力：

$$X_1 = \text{DWConv}_{1 \times 3}(\text{DWConv}_{3 \times 1}(X_0)) \quad (2)$$

另一条分支采用膨胀深度卷积（膨胀率 2），扩大感受野以捕获更大范围的上下文结构：

$$X_2 = \text{DWConv}_{3 \times 3, d=2}(X_0) \quad (3)$$

最后，拼接两条分支输出，经 1×1 卷积、批归一化

与 ReLU 融合得到最终输出：

$$Y = \text{ReLU}(\text{BN}(\text{Conv}_{1 \times 1}(\text{Concat}(X_1, X_2)))) \quad (4)$$

通过上述设计，CHC Block 在保持轻量化的同时，协同建模局部方向细节与全局上下文信息，提升模型对边界模糊、结构粘连等复杂场景的特征表达能力。

1.2 层级语义引导注意力模块

为提升编码器浅层细节与深层语义的融合效果，增强模型对目标区域及边界的选择性表达能力，本文设计了层级语义引导注意力模块（SAG Block）。该模块利用浅层特征的高分辨率细节与深层特征的语义信息，分别构建通道引导与空间引导权重，对浅层特征进行自适应重标定，从而增强目标区域响应、抑制背景干扰。




图3 SAG Block模块示意图

如图所示，SAG Block 由两个并行引导分支与一个输出融合单元构成：通道引导分支基于浅层特征，空间引导分支基于深层特征。浅层分支通过全局平均池化提取通道统计信息并生成通道注意力；深层分支通过 1×1 卷积和上采样生成空间引导权重。两者依次作用于浅层特征，再经卷积、归一化与激活得到最终输出。

设浅层输入特征为 $X_s \in \mathbb{R}^{B \times C \times H \times W}$ ，深层输入特征为 $X_d \in \mathbb{R}^{B \times \frac{C}{2} \times \frac{H}{2} \times \frac{W}{2}}$ 。通道引导分支通过全局平均池化和 1×1 卷积生成通道权重，强化有效通道、抑制冗余：

$$W_c = \sigma(\text{BN}(\text{Conv}_{1 \times 1}(\text{GlobalAvgPool}(X_s)))) \quad (5)$$

空间引导分支利用深层特征的语义信息上采样生成空间权重，在高分辨率特征图上聚焦目标区域：

$$W_s = \sigma(\text{Upsample}(\text{BN}(\text{Conv}_{1 \times 1}(X_d)), (H, W))) \quad (6)$$

将两种权重依次作用于浅层特征，实现特征与空间维度的双重筛选：

$$X_{cs} = X_s \otimes W_c \otimes W_s \quad (7)$$

最后经卷积、归一化与 ReLU 增强特征稳定性与判别性：

$$Y = \text{ReLU}(\text{BN}(\text{Conv}_{1 \times 1}(X_{cs}))) \quad (8)$$

SAG Block 利用浅层特征与深层特征之间的互补关系，通过通道与空间双重引导增强特征选择性。该方法能有效缓解噪声与背景干扰，提升对小目标、模糊边界及不规则病灶的分割性能。

1.3 Ghost 卷积的高效特征融合模块

为充分融合浅层细节与深层语义，提升网络对边界、纹理及目标区域的表达能力，本文设计了基于 Ghost 卷积的高效特征融合模块（GAF Block）。该模块先对浅层与深层特征进行尺度对齐与通道映射，实现跨层融合，再利用逐点卷积与深度卷积对融合特征进行局部重构与上下文增强，获得紧凑且判别性的特征表示。




图4 GAF Block模块结构图

如图4所示，GAF Block由跨层特征对齐、特征融合和特征增强三部分组成。将低分辨率深层特征恢复至高分辨率，统一尺寸与通道分布：

$$X_{D\uparrow} = \text{BN}(\text{Conv}_{1\times 1}(\text{Upsample}(X_D, (H, W)))) \quad (9)$$

在不增加计算量、不引入冗余维度的前提下实现浅层细节与深层语义的初步融合，实现信息互补与特征增强：

$$X_F = X_S + X_{D\uparrow} \quad (10)$$

随后通过 1×1 卷积与 ReLU 提炼核心信息，降低计算开销：

$$X_C = \text{ReLU}(\text{BN}(\text{Conv}_{1\times 1}(X_F))) \quad (11)$$

使用轻量化深度卷积强化边缘、拐角、细小结构等局部细节信息：

$$X_A = \text{ReLU}(\text{BN}(\text{DWConv}_{3\times 3}(X_C))) \quad (12)$$

将全局压缩特征与局部增强特征进行互补性拼接，同时保留全局语义信息与局部细节信息：

$$Y = \text{Concat}(X_C, X_A) \quad (13)$$

GAF Block 的核心是在跨层融合基础上增强局部特征建模。实现了在较低计算复杂度下提高了跨层融合质量，适用于小目标、模糊边界及尺度变化明显的医学图像分割任务。

1.4 损失函数

在医学图像分割任务中，由于前景与背景像素分布通常存在显著不平衡，仅采用像素级分类损失容易导致模型对小目标区域的学习不足。为此，本文采用二值交叉熵损失（Binary Cross Entropy, BCE）与 Dice 损失相结合的复合损失函数，以同时兼顾像素级分类精度与区域重叠一致性，从而提升分割性能。

具体而言，整体损失函数定义为：

$$\mathcal{L}_{total} = \lambda \cdot \mathcal{L}_{BCE}(y, \hat{y}) + \mathcal{L}_{Dice}(y, \hat{y}) \quad (14)$$

其中， y 表示真实标签， $\hat{y}$ 表示模型预测结果， λ 为权重系数（本文设置为 0.5）。

二值交叉熵损失定义为：

$$\mathcal{L}_{BCE} = -\frac{1}{N} \sum_{i=1}^N [y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i)] \quad (15)$$

Dice 损失用于衡量预测区域与真实区域之间的重叠程度，其定义为：

$$\mathcal{L}_{Dice} = 1 - \frac{2 \sum_{i=1}^N y_i \hat{y}_i + \epsilon}{\sum_{i=1}^N y_i + \sum_{i=1}^N \hat{y}_i + \epsilon} \quad (16)$$

其中， ϵ 为平滑项，用于避免分母为零的情况。

该复合损失函数的设计具有以下优势：BCE 损失能够提供稳定的像素级监督信号，而 Dice 损失则直接优化分割区域的重叠度，有效缓解类别不平衡问题。两者的结合有助于提升模型在边界区域及小目标结构上的分割精度，从而获得更鲁棒的分割结果。

2 实验结果与分析

2.1 数据集

为评估模型所述方法在 GLAS 分割数据集，ISIC2018 数据集上进行了相关实验，具体的数据集信息如下：




图5 ISIC2018数据集和GLAS数据集的实例

(1) GLAS: GLAS (Gland Segmentation in Colon Histology Images) 数据集是腺体分割任务中较为经典且常用的公开数据集，由 MICCAI2015 Gland Segmentation Challenge 发布，主要用于推动结肠组织病理图像中腺体结构自动分割方法的研究。该数据集包含 165 张 H&E 染色的结肠组织病理图像，其中 85 张用于训练，80 张用于测试；

(2) ISIC2018: ISIC2018 数据集由 International Skin Imaging Collaboration (ISIC) 组织发布是皮肤病灶分割任务中应用最广泛的公开数据集之一。其中 Task 1 的目标是实现皮肤镜图像中病灶区域的自动分割。根据官方数据说明 ISIC2018 Task 1 共提供 2594 张训练图像和 100 张验证

图像和 1000 张测试图片。

2.2 实验环境与设置

所有实验基于 PyTorch 2.1、Python 3.10 和 CUDA 11.8，在 Intel Xeon Gold 6430 CPU 与 GeForce RTX 4090 GPU 上完成。采用 SGD 优化器，动量 0.9，初始学习率 0.01，权重衰减 0.0001，并采用带 1 个 epoch 预热的 Polynomial Decay 学习率调整策略（幂指数 0.9）。对于 GLaS 和 ISIC 任务，批次大小设为 8，训练最多 100 轮，输入图像统一调整为 224×224 ，并采用随机翻转、旋转等数据增强提升模型泛化能力。

2.3 评估指标

为全面评估 NeoMorphUNet 与各基线模型在医学图像分割中的性能，本文采用 IoU、Dice 相似系数（DSC）、准确率（ACC）、精确率（Precision）、召回率（Recall）等指标。

IoU 用于衡量预测分割区域与真实标注区域之间的重叠程度，数值越高表示预测结果与真实标签的一致性越好。Dice 系数为精确率与召回率的调和平均值，在目标区域占比较小的医学图像分割任务中，对类别不平衡问题具有较高敏感性。ACC 表示被正确分类像素占总像素数的比例，用于评估模型整体的预测准确程度。精确率反映模型抑制假阳性的能力。召回率表示实际阳性像素中被正确识别的比例，体现模型对病变区域的检测敏感性。

$$\text{Dice} = \frac{2TP}{2TP + FP + FN} \quad (17)$$

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (18)$$

$$\text{mIoU} = \frac{1}{C} \sum_{i=1}^C \frac{TP_i}{TP_i + FP_i + FN_i} \quad (19)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (20)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (21)$$

2.4 对比实验

表1 不同模型GLAS数据集上分割性能的比较分析

Method	Dice	Accuracy	mIoU	Recall	Precision
Afformer	0.7986	0.8312	0.7110	0.8322	0.8194
CENet	0.7932	0.8148	0.6875	0.8041	0.8206
DCSAUNet	0.8045	0.8236	0.7002	0.8051	0.8427
DeepLabV3plus	0.8535	0.8777	0.7818	0.8830	0.8638
Nested U-Net	0.8178	0.8510	0.7404	0.8499	0.8436
TransUNet	0.8594	0.8775	0.7818	0.8619	0.8921
U-Net	0.8163	0.8485	0.7366	0.8521	0.8344
NeoMorphUNet	0.8820	0.8966	0.8126	0.8750	0.9195

表 1 展示了不同模型在 GLAS 数据集上的定量分割结果。NeoMorphUNet 在 Dice（0.8820）、Accuracy（0.8966）、mIoU（0.8126）、Recall（0.8750）和 Precision（0.9195）五项指标上均取得最优结果，综合性能优于其他模型。虽然 Recall 略低于 DeepLabV3plus（0.8830），但整体表现稳定，表明该方法在保持较高检出能力的同时有效减少了误分割。传统卷积网络（如 U-Net、Nested U-Net、CENet）在 GLAS 上表现稳定，但在 Dice 和 mIoU 等关键指标上仍有局限，说明仅靠局部卷积难以应对腺体形态差异大、边界模糊及相邻腺体易粘连等问题。

在所有方法中，NeoMorphUNet 取得了最佳综合结果。相较于 U-Net，其 Dice、Accuracy、mIoU 和 Precision 分别提升 0.0657、0.0481、0.0760 和 0.0851；该模型在区域重叠度、边界一致性和预测精确性方面均具明显优势，验证了其在腺体分割任务中的有效性、鲁棒性及对复杂形态与粘连结构的适应能力。

表2 不同模型ISIC2018数据集上对比实验结果

Method	Dice	Accuracy	mIoU	Recall	Precision
Afformer	0.8692	0.9314	0.8422	0.8632	0.8822
CENet	0.8790	0.9317	0.8402	0.8867	0.8525
DCSAUNet	0.8711	0.9301	0.8393	0.8610	0.8792
DeepLabV3plus	0.8791	0.9364	0.8523	0.8750	0.8878
Nested U-Net	0.8750	0.9317	0.8410	0.8782	0.8629
TransUNet	0.8728	0.9287	0.8344	0.8757	0.8533
U-Net	0.8668	0.9264	0.8289	0.8773	0.8411
NeoMorphUNet	0.8867	0.9371	0.8525	0.8883	0.8734

与基线 U-Net 相比，NeoMorphUNet 的 Dice、Accuracy 和 mIoU 分别提高了 0.0199、0.0107 和 0.0226，Recall 提高了 0.0011，Precision 提高了 0.0323，说明所提出模型在分割精度、区域重叠度及误分割抑制方面具有一定优势。尤其是在 Precision 指标上的提升较为明显，表明 NeoMorphUNet 在减少背景区域误检方面表现更好。

NeoMorphUNet 在 ISIC2018 数据集上的整体性能并未超过 DeepLabV3plus 和 TransUNet 等表现最优的方法。这说明虽然所提出模型在轻量化结构设计下取得了较稳定的分割结果，但在皮肤病变图像中更加复杂的颜色分布、纹理变化和边界不规则场景下，其全局语义建模能力和特征表达能力仍有进一步提升空间。

总体来看，NeoMorphUNet 在 ISIC2018 数据集上取得了较好的分割性能，相比基线模型表现出一定改进，验证了 CHC Block、SAG Block 和 GAF Block 在轻量化分割网络中的有效性。该结果表明，所提出模型在保证较低复

杂度的同时，能够较好地适应皮肤病变分割任务。




图6 GLAS数据集上不同模型可视化分割结果

图6展示了不同模型在GLAS数据集上的可视化分割结果。整体来看，NeoMorphUNet的分割结果与真实标签最为接近，在边界恢复、结构完整性和腺体分离能力方面表现优异。

对于图中前两组细长且边界复杂的腺体样本，传统模型容易出现边界断裂、局部缺失或腺体误连接，而NeoMorphUNet能完整恢复主体区域并保持边界连续性，展现出对复杂形态腺体的更强表征能力。对于图中后两组腺体密集、纹理复杂的样本，部分对比模型存在明显粘连、空洞填充不准或小腺体遗漏，而NeoMorphUNet在区域划分和边界定位上更加准确，能有效区分相邻腺体并减少背景误分割。总体而言，NeoMorphUNet在复杂边界恢复、细长结构保持和密集目标分离方面具有明显优势，验证了其多尺度特征融合与上下文信息提取能力，与定量结果一致，进一步证明了其在腺体分割任务中的有效性。




图7 ISIC2018数据集上不同模型可视化分割结果

图7展示了不同模型在ISIC2018数据集上的可视化分割结果。整体来看，各模型对轮廓清晰、面积较小的病变均能基本定位，但在边界贴合度、形状保持与小目标识别稳定性上存在差异，其中NeoMorphUNet的分割结果整体较为稳定。

对于形状规则、边界清晰的病变，大多数模型能较好恢复轮廓，但部分方法存在轻微形状偏差或过度平滑，而NeoMorphUNet在形态保持方面表现更好。

对于较小的病变目标，部分方法容易出现目标偏移、区域缩小或边界不完整，而NeoMorphUNet能较稳定地识别病变区域，具备一定的小目标分割能力。

总体而言，NeoMorphUNet在ISIC2018上的可视化

结果较为稳定，能较好保持病变整体轮廓，但在复杂边界刻画和细节恢复方面仍有提升空间。该结果与定量分析一致，说明模型在轻量化前提下能较好完成皮肤病变分割任务。

2.5 轻量化实验




图8 不同模型在GLAS上的params和Dice性能比较

图8展示了不同模型在GLAS数据集上的参数量与Dice值的关系。NeoMorphUNet位于左上区域，在仅2.56M参数的条件下取得0.8820的Dice值，说明其在低复杂度下仍具较强分割能力，整体优势明显。与其他模型相比，NeoMorphUNet的参数量显著低于U-Net、DeepLabV3+、Nested U-Net和TransUNet等方法，却取得了最高Dice，体现了模型效率与精度之间的更优平衡，进一步验证了其网络结构设计的有效性的同时，仍能有效提升特征表达与边界恢复能力。




图9 不同模型在GLAS上的params和mIoU性能比较

图9展示了不同模型在GLAS数据集上的参数量与mIoU的关系。NeoMorphUNet位于左上区域，在仅2.56M参数的条件下取得0.8820的mIoU值，表明其在低复杂度下仍具较强分割能力，整体性能优势明显。总体来看，NeoMorphUNet兼具较低参数量与较高分割精度，具有良好的性能说明所提出的轻量化结构在降低计算开销的同时，仍能有效提升腺体分割中的特征表达与边界恢复能力。

表3 GLAS数据集消融实验研究

CHC	SAG	GAF	Params	FLOPs	Dice	Acc	mIoU	Recall	Pre
×	×	×	17.263	30.771	88.20	89.66	81.26	87.50	91.95
√	×	×	2.749	5.134	83.88	86.86	76.72	88.58	83.89
√	√	×	3.186	5.174	83.36	86.06	75.51	86.37	84.82
√	√	√	2.562	3.512	81.63	84.85	73.66	85.21	83.44

2.6 消融实验

表 3 展示了 NeoMorphUNet 在 GLAS 数据集上的轻量化模块替换实验结果。逐步引入 CHC、SAG 和 GAF 模块，比较不同结构在参数量、计算量与分割性能上的变化。

基础模型的 Dice 和 mIoU 分别为 88.20% 和 81.26%，性能最优，但参数量和 FLOPs 较高，达 17.263M 和 30.771G。引入 CHC 模块后，参数量降至 2.749M，FLOPs 降至 5.134G，但 Dice 和 mIoU 分别降至 83.88% 和 76.72%，说明效率提升的同时部分特征表达能力下降。进一步加入 SAG 模块后，参数量与 FLOPs 分别为 3.186M 和 5.174G，Dice 与 mIoU 为 83.36% 和 75.51%，表明 SAG 在特征融合中发挥作用，但尚不足以完全弥补精度损失。继续引入 GAF 模块后，参数量和 FLOPs 降至最低（2.562M 和 3.512G），Dice 与 mIoU 为 81.63% 和 73.66%，三个模块组合显著提升了计算效率，但同时也带来一定性能下降。

总体来看，模型复杂度由 17.263M 和 30.771G 分别降至 2.562M 和 3.512G，NeoMorphUNet 实现了较好的精度—效率平衡。这表明 CHC、SAG 和 GAF 模块能够有效服务于模型轻量化设计，为资源受限场景下的医学图像分割提供了可行方案。

3 结语

针对医学图像分割中模型参数量大、计算复杂度高及难以兼顾性能与部署效率的问题，本文构建了 NeoMorphUNet 轻量化分割模型。其中，CHC Block 增强多尺度上下文与方向结构特征，SAG Block 提升跳跃连接中的特征选择与关键区域响应能力，GAF Block 实现深浅层特征的高效融合，改善解码阶段的边界恢复与细节重建。

在 GLAS 和 ISIC2018 数据集上的实验表明，NeoMorphUNet 模型表现了较好的分割性能并在复杂背景与低对比度条件下取得了稳定分割效果。可视化结果进一步验证了其在目标完整性、边界平滑性及细节保持方面的优势。消融实验表明，CHC、SAG 和 GAF 模块在降低模型复杂度的同时，提升了特征利用效率，对维持分割性能起到关键作用。综上所述，NeoMorphUNet 在低计算开销下实现了较好的分割性能，取得了效率与精度的有效平衡，

为资源受限场景下的医学图像分割提供了可行方案。

参考文献：

- [1] Conze P H, Andrade-Miranda G, Singh V K, et al. Current and emerging trends in medical image segmentation with deep learning[J]. IEEE Transactions on Radiation and Plasma Medical Sciences, 2023, 7(6): 545–569.
- [2] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation [C]//International Conference on Medical image computing and computer-assisted intervention. Cham: Springer international publishing, 2015: 234–241.
- [3] Zhou Z, Rahman Siddiquee M M, Tajbakhsh N, et al. Unet++: A nested u-net architecture for medical image segmentation[C]//International workshop on deep learning in medical image analysis. Cham: Springer International Publishing, 2018: 3–11.
- [4] Oktay O, Schlemper J, Le Folgoc L, et al. Attention U-Net: Learning Where to Look for the Pancreas[C]//Medical Imaging with Deep Learning.
- [5] Gu Z, Cheng J, Fu H, et al. Ce-net: Context encoder network for 2d medical image segmentation[J]. IEEE transactions on medical imaging, 2019, 38(10): 2281–2292.
- [6] Liu Y, Bai X, Wang J, et al. Image semantic segmentation approach based on DeepLabV3 plus network with an attention mechanism[J]. Engineering Applications of Artificial Intelligence, 2024, 127: 107260.
- [7] Chen J, Mei J, Li X, 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.
- [8] Cao H, Wang Y, Chen J, et al. Swin-unet: Unet-like pure transformer for medical image segmentation[C]//European conference on computer vision. Cham: Springer Nature Switzerland, 2022: 205–218.
- [9] Xie E, Wang W, Yu Z, et al. SegFormer: Simple and

efficient design for semantic segmentation with transformers[J]. Advances in neural information processing systems, 2021, 34: 12077-12090.

[10] 马利, 刘新宇, 李皓宇等. 应用空洞卷积的神经网络轻量化方法[J]. Journal of Computer Engineering & Applications, 2022, 58(5).

[11] Han K, Xiao A, Wu E, et al. Transformer in transformer[J]. Advances in neural information processing

systems, 2021, 34: 15908-15919.

[12] Garcia-Garcia A, Orts-Escolano S, Oprea S, et al. A Review on Deep Learning Techniques Applied to Semantic Segmentation[J]. 2017.DOI:10.48550/arXiv.1704.06857.

[13] Gao Y, Jiang Y, Peng Y, et al. Medical image segmentation: A comprehensive review of deep learning-based methods[J]. Tomography, 2025, 11(5): 52.

* 通讯作者: 胡永祥。