

曹嘉璇, 王家琪, 邹北骥, 等. 基于多分组协调注意力卷积的缺血性脑卒中病灶分割方法 [J]. 智能计算机与应用, 2025, 15 (4): 9-16. DOI: 10.20169/j.issn.2095-2163.24110802

基于多分组协调注意力卷积的缺血性脑卒中病灶分割方法

曹嘉璇¹, 王家琪¹, 邹北骥², 郭纯³, 刘青萍¹

(1 湖南中医药大学 信息科学与工程学院, 长沙 410208; 2 中南大学 计算机学院, 长沙 410083;

3 湖南中医药大学第一附属医院, 长沙 410007)

摘要: 脑卒中是世界上仅次于心脏病的第二大死因。缺血性脑卒中病灶的自动分割可以提供受损组织的位置与面积信息, 对治疗方法的选择以及评估患者预后效果有着重要的意义。针对医生手动分割较为耗时, 以及对多尺度病灶分割效果较差的问题, 本文提出了一种基于多分组协调注意力卷积的缺血性脑卒中病灶分割方法。首先, 将改进的特征获取模块加入编码器头部, 以捕获更多轮廓特征; 其次, 引入一种轻量级协调注意力模块, 使得模型充分融合位置与上下文信息; 最后, 设计了一种多分组卷积模块, 在大幅降低计算成本的同时使网络融合不同尺度大小的特征映射。实验采用 ISLES2022 数据集评估所提方法, 结果显示, 本文方法的戴斯相似系数、召回率、精确率分别达到了 68.59%、78.90%、71.34%, 与其他先进的方法相比, 该模型的性能在所有指标上都达到了优秀的结果, 有望为临床诊断和治疗提供可靠辅助。

关键词: 缺血性脑卒中; 多分组卷积; 核磁共振; 计算机辅助诊断; 深度学习

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)04-0009-08

Ischemic stroke lesion segmentation method based on multi-group coordinated attention convolution

CAO Jiaxuan¹, WANG Jiaqi¹, ZOU Beiji², GUO Chun³, LIU Qingping¹

(1 School of Informatics, Hunan University of Chinese Medicine, Changsha 410208, China;

2 School of Computer Science and Engineering, Central South University, Changsha 410083, China;

3 The First Hospital of Hunan University of Chinese Medicine, Changsha 410007, China)

Abstract: Stroke is the second leading cause of death, just after heart disease. Automated segmentation of ischemic stroke lesions can provide crucial information on the location and size of damaged tissue, aiding in treatment selection and prognosis assessment. In response to the time-consuming manual segmentation by doctors and the poor performance of multi-scale lesion segmentation, this paper proposes a lesion segmentation method for ischemic stroke based on multi-group coordinated attention convolution. Firstly, an improved feature acquisition module is added to the encoder head to capture more contour features. Secondly, a lightweight coordinated attention module is introduced to enable the model to fully integrate positional and contextual information. Finally, a multi-group convolution module is designed to significantly reduce computational cost while allowing the network to fuse feature maps of different scales. The method is evaluated using the ISLES2022 dataset, and the results show that the Dice Similarity Coefficient, recall, and precision achieved by the proposed method are 68.59%, 78.90%, and 71.34%, respectively. Compared to other advanced methods, the performance of this model achieves excellent results across all metrics. It is expected to provide reliable assistance for clinical diagnosis and treatment.

Key words: ischemic stroke; multi-group convolution; MRI; Computer-Aided Diagnosis; deep learning

基金项目: 国家重大科技专项(2018AAA0102100); 2023年湖南省学位与研究生教学改革研究项目(2023JGYB151); 湖南中医药大学第一附属医院中医药传承创新专项重点项目(2024XYLH346); 2023年湖南中医药大学研究生科研创新项目(2023CX135); 2024年湖南中医药大学研究生科研创新项目(2024CX192)。

作者简介: 曹嘉璇(2000—), 男, 硕士研究生, 主要研究方向: 医学图像处理, 深度学习。

通信作者: 刘青萍(1982—), 女, 博士, 教授, 主要研究方向: 中医辅助临床决策支持系统, 数据挖掘与知识发现, 人工智能。Email: liuliu@hnucm.edu.cn。

收稿日期: 2024-11-08

哈尔滨工业大学主办 ◆ 学术研究与应用

0 引言

脑卒中,俗称中风,是全球第二大死亡原因。世界中风组织(WSO)指出,每年有1 370万例新发中风,约550万人因此死亡^[1]。超过三分之二的中风幸存者经历了长期残疾,严重影响了日常活动^[2]。随着人口老龄化的日益加剧,中国已成为卒中终生风险最高和疾病负担最重的国家。脑卒中主要分为缺血性卒中、出血性卒中和蛛网膜下腔出血三大类,其中缺血性脑卒中的发病率最高,约占87%^[3]。对于缺血性脑卒中的诊断与治疗关键在于时间,如若不及时对缺血区域进行干预,每分钟死亡的细胞数将高达190万个^[4],缺血半暗带可以在数小时之内迅速演变为脑梗死,会对患者健康产生不可逆的影响。在临床治疗中,医生通常使用电子计算机断层扫描(Computed Tomography, CT)和核磁共振成像(Magnetic Resonance Imaging, MRI)来观测脑卒中病灶。脑卒中病灶分割是脑卒中病灶识别和判定的首要步骤。准确的识别和分割将提高医生对患者的正确诊断能力。目前,病变一般由专业放射科医生在磁共振图像上逐片手工分割,耗时长,且严重依赖主观感知^[5]。因此,在临床上迫切需要一种准确、快速的脑卒中病灶自动分割方法为医生提供第三方辅助意见。

随着深度学习的快速发展,医学图像分割方法取得了瞩目成就。基于卷积神经网络(CNN)的分割模型在脑卒中病灶分割任务中展现出显著效果。首先,由Ronneberger等学者^[6]提出的UNet模型是最早在医学图像分割中广泛应用的网络之一,由于其简单的结构和稳定的表现,使得UNet能够在少量标注数据上有效训练并实现精准的病灶分割。然而,在分辨复杂边界时,UNet容易出现细节信息丢失的问题。针对上述问题,Oktay等学者^[7]提出了Attention-UNet,在UNet的基础上引入注意力机制,使模型能够自动专注于重要的特征区域,减少了非病灶区域的干扰。然而,由于注意力机制增加了计算量,Attention-UNet的推理速度相对较慢,且模型结构更加复杂,训练时间有所增加。随后,Alom等学者^[8]提出的R2UNet模型通过引入递归机制,使模型能够在编码和解码过程中多次利用同一层的特征表示,从而提升特征表达的丰富度。这种设计在一定程度上增强了模型的特征学习能力,但递归结构导致计算复杂度增加,且对硬件资源的要求较高,因此在实际应用中存在一定局限性。为了降低计算开销,Valanarasu等学者^[9]提出了UNeXt模型,通过

有效地标记并投影卷积特征,减少了模型的复杂性和参数量,同时实现了更快的推理速度。该模型在保持一定分割精度的基础上降低了对硬件的依赖,适用于资源受限的环境。然而,UNeXt的性能在细粒度分割任务中有所下降,对于病变边缘等细节部位的准确定位仍有提升空间。

为了解决上述问题,本文提出了一种基于多分组协调注意力卷积的缺血性脑卒中病灶分割方法,称为MGCA-UNet。在编码器部分,首先采用了一种新的特征获取策略,使网络能够积极地从低级语义层中保留更多的特征。由该层提取的特征将会传递到模型中的多分组卷积模块。该模块使用多分组结构来增强不同通道的特征表示,从而获得不同尺度的特征信息。最后,通过引入协调注意力机制,用于提高模型的感知能力。总而言之,本文做出了以下贡献:

(1)在编码器头部加入特征获取策略,从而在输入图像中获取更充分的特征信息。与其他常见的设计相比,就在一定程度上补偿了池化过程中的特征损失。

(2)通过引入协调注意力机制,将空间注意力和通道注意力结合在一起,以分离式的方式进行特征处理,使得模型能够同时关注到特征的空间分布和通道分布。

(3)为了大幅度降低模型的参数量和计算量并更有效地提取不同层次的语义信息,本文构建了多分组卷积模块。该模块采用多分组结构,每个分组由不同数量和不同大小的卷积组成,从而扩展网络的接受域,减少卷积核的数量和计算量。

(4)研究采用ISLES2022(International Stroke Lesion Segmentation Challenge 2022)数据集进行实验,设计了一系列实验分析各个模块的表现,以及模块之间的影响。最后,为了验证模型的泛化能力,本文采用了3种不同类型的医学数据集进行测试。实验结果表明,与其他先进的方法相比,本文模型在多个测试指标上都达到了具有竞争力的结果,验证了MGCA-UNet的有效性和鲁棒性,有望为医学图像分割领域提供研究思路。

1 网络模型与结构

1.1 网络整体结构

本文提出的缺血性脑卒中病灶分割方法,保留了UNet原有的架构,模型的整体结构如图1所示。编码器部分用于逐步提取输入图像的特征,并将其

编码为更高层次的表示形式,解码器部分采用转置卷积将由编码器得到的低分辨率特征图还原为与输入图像相同分辨率的特征图,并结合跳跃连接将低级别的特征与高级别的语义信息相融合,以产生更准确的分割边界^[10]。最后,通过逐点卷积改变特征的通道数,得到最终的分割结果。MGCA-UNet 包含特征获取模块,协调注意力模块和多分组卷积模块。其中,特征获取模块位于模型编码器头部,用于保留输入图像中的主要特征。协调注意力模块被引入在跳跃连接处,使得网络在特征融合时更加关注病灶区域。多分组卷积模块位于整个网络架构中的卷积操作中,从而降低模型复杂度并增强特征提取的灵活性和表达能力。




图 1 模型整体结构示意图

Fig. 1 Schematic diagram of the overall model structure

1.2 特征获取策略

传统卷积通常由相同大小的卷积简单堆叠组成,如图 2(a) 所示,这种结构受到感受野大小和归纳偏置的限制,使得其在高效捕捉空间和通道间依赖性方面表现较差,通常需要更深的网络结构来实现所需的表示能力^[11]。另外,在捕捉复杂特征时,传统卷积在深度网络或计算资源有限的应用中效率较低。而深度可分离卷积保留了深度网络的表示能力,并且能够在不引入过多计算开销的情况下有效捕捉空间和通道关系。受到深度可分离卷积的启发,本文重新设计了一种新的特征获取模块 (Feature Acquisition module, FA),如图 2(b) 所示,其获取特征的过程可以分为 3 步。

(1)通道卷积。 3×3 大小的卷积用于改变通道

数并提取特征信息。

(2)深度卷积。通过 7×7 大小的卷积来快速获取低级特征的全局信息。

(3)逐点卷积。通过 1×1 大小的卷积对不同通道特征进行加权组合生成新的特征图。




图 2 传统卷积模块与 FA 模块的对比图

Fig. 2 Comparison of the traditional convolution module and the FA module

1.3 协调注意力机制

受限于 MRI 图像病灶区域和背景区域之间的边界模糊,网络在进行分割的时候难以准确地分割出病灶的边界区域^[12]。现有的注意力机制在求取通道注意力的时候,通道的处理一般是采用全局最大池化和平均池化,导致空间信息的严重损失^[13]。为此,本文在网络跳跃连接处加入协调注意力模块 (Coordinated Attention Module, CA),该模块通过坐标分离的方式,分别在水平和垂直方向上捕捉全局信息,保留了细粒度的位置信息,同时能够捕获长距离依赖关系^[14]。算法 1 描述了具体计算流程,其中 $GlobalAvgPool(\cdot)$ 表示沿指定轴进行全局平均池化; $BroadcastTo(\cdot)$ 表示将张量的形状扩展到指定大小,以适应后续的元素逐位相乘操作。

算法 1 CA 模块伪代码

输入 特征图 x , 大小为 $F_m \times H \times W$

输出 特征图 y , 大小为 $F_m \times H \times W$

1. 获取输入特征图大小:

$$batch_size, channels, height, width = x.shape$$

2. 沿高度和宽度方向进行全局平均池化:

$$avg_pool_h = GlobalAvgPool(x, axis = 2);$$
$$avg_pool_w = GlobalAvgPool(x, axis = 3)$$

3. 通道数缩减并应用 *ReLU* 激活函数:

$Conv_h = Relu(Conv1 \times 1(avg_pool_h, channels // reduction_ratio))$;

$Conv_w = Relu(Conv1 \times 1(avg_pool_w, channels // reduction_ratio))$

4. 恢复通道数到原始大小并生成坐标注意力权重:

$coord_attention_h = Sigmoid(Conv1 \times 1(conv_h, channels))$;

$coord_attention_w = Sigmoid(Conv1 \times 1(conv_w, channels))$

5. 调整注意力权重的尺寸:

$coord_attention_h = BroadcastTo(coord_attention_h, [batch_size, channels, height, width])$;

$coord_attention_w = BroadcastTo(coord_attention_w, [batch_size, channels, height, width])$

6. 应用注意力权重到输入特征图:

$y = x \times coord_attention_h \times coord_attention_w$

7. 返回加权后的特征图 y :

return y

1.4 多分组卷积模块

深层网络结构已经应用在许多语义分割网络中,卷积层的累积,在一定程度上可以增大感受野,但使用相同结构的卷积层,无法获取输入特征图的多尺度特征信息^[15]。在缺血性脑卒中病灶分割任务中,病灶的大小、形状等是不同的,而相同卷积的重复堆叠会导致分割精度不高^[16]。为了解决这个问题,本文提出了多分组卷积模块 (Multi-Group Convolution Module, MGC),每个分组采用不同的卷积结构以保证多尺度特征的充分表示。MGC 模块如图 3 所示,该模块采用 2 个特征分组用来获取不同尺度的特征信息。首先,都会经过一个 1×1 卷积和 3×3 卷积, 1×1 卷积用于获取当前尺度的特征信息。为了提取多尺度特征,第二分组的输出特征将与第一分组的结果相结合并通过一个 3×3 卷积接收语义信息。在融合 2 组特征中,采用了全局池化收集全局空间信息,并通过赋予权值,获取特征图中的关键信息。融合特征图的过程可由描述为:

$$g' = \sum_{i=1}^N F_i(X_i), g' \in R^{H \times W \times C} \quad (1)$$

其中, H 、 W 和 C 表示输出特征图的比例。全局平均池化对空间信息进行求和,增强输入特征图空间变化的鲁棒性。随后将 $H \times W \times C$ 的张量转化为 $1 \times 1 \times C$ 的张量 Y_c ,建立特征与通道之间的关系,并通过自我

学习获取图像的全局特征信息和各个通道的重要性^[17]。具体公式如下:

$$Y_c = \frac{1}{H \times W} \sum_{m=1}^H \sum_{n=1}^W g', Y \in R^C \quad (2)$$

最后将像素级别的特征映射到类别概率分布,以实现缺血性脑卒中病变的分割。其中, $\delta_i(\cdot)$ 代表使用 *BatchNorm* 和 *ReLU* 激活。2 个 1×1 卷积将经过全局平均池化得到的空间信息 Y 进行量化,其运算过程具体如下:

$$S = \frac{\exp(\delta_i(Y))}{\sum_{j=1}^N \exp(\delta_j(Y))} \quad (3)$$




图 3 MGC 模块图

Fig. 3 MGC module diagram

2 实验与结果分析

2.1 实验细节

本文中的所有方法使用 PyTorch 1.10.0 框架实现,在单个 NVIDIA Tesla P40 GPU (24 GB)、6 核 CPU 上完成。训练中采用常见的分割损失函数 *Dice loss* 和自适应矩估计 (Adaptive moment estimation, Adam) 优化算法,初始学习率为 $10e-4$,批量大小 (*batchsize*) 设为 8,迭代 (*epoch*) 为 300。为了扩增数据集图像的数量,训练期间以 0.25 的概率对每个数据集中的训练集随机应用水平翻转、旋转和切出等图像转换技术进行数据增强,以扩展样本的多样性并增强模型的泛化。

2.2 数据集

为了评估 MGCA-UNet 在缺血性脑卒中病灶分割任务中的有效性以及该模型在其他医学图像中表现出的泛化能力,本文分别在 4 个公开的医学数据集上进行了实验。

(1) ISLES2022。是 2022 年缺血性脑卒中梗死分割挑战赛中提供的公开数据集^[18],该数据集包含 250 例患有缺血性脑卒中患者的多模态 MRI 图像。本文选取其中的 DWI 模态的图像进行实验。

(2) Kvasir-SEG 结肠息肉数据集^[19]。包括 1 000 张胃肠息肉图像及其对应的分割掩码,这些图像都由资深胃肠病专家亲自标注和核实。

(3) Montgomery 数据集^[20]。由蒙哥马利大学提供,包含了多种类型的肺部图像,该数据集包含 138 张结核病患者的胸部 X 光图像。

(4) ISIC-2018^[21]。来自国际皮肤癌图像学协会官方网站 2018 年发布的皮肤病数据集。该数据集包含 2 594 张皮肤癌图像,涵盖了不同类型的病变、各种年龄和肤色的病患以及不同成像条件下的图像。

所有数据集都按 7:2:1 随机划分为训练集、测试集和验证集。考虑到 ISLES2022 数据集存在大面积背景区域^[22],本文将该数据集重采样到 256×256 ,其它 3 个医学数据集设置为 512×512 。

2.3 评价指标

本研究采用戴斯相似系数 (Dice Similarity Coefficient, *DSC*)、召回率 (*Recall*) 和精确度 (*Precision*) 来衡量所提方法的分割性能。以上指标越高,分割效果越好。评价指标直接由混淆矩阵计算得到,推得的公式具体如下:

$$DSC = \frac{2TP}{2TP + FP + FN} \quad (4)$$

$$Recall = \frac{TP}{TP + FN} \quad (5)$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

其中, *TP* 和 *FP* 分别表示真阳性变量和假阳性变量,分别代表模型正确分割的缺血性脑卒中病灶像素数和错误将背景像素划分为缺血性脑卒中病灶的像素; *TN* 表示真正的负变量,代表正确分割的背景像素; *FN* 代表假阴性变量,代表缺血性脑卒中病灶像素被错误标记为背景的像素。

另外,为了客观体现模型的计算效率,本文通过计算将单张大小为 256×256 的 RGB 缺血性脑卒中图像输入模型中所需运行的浮点运算次数 *FLOPS* (Floating Point Operations Per Second),以衡量本文算法的时间复杂度;通过统计模型训练中所需的参数量 *Params*,用来衡量本文算法的空间复杂度^[23]。以上指标越低,模型的分割效率越高。

2.4 实验结果与分析

2.4.1 消融实验

为了深入评估 MGCA-UNet 模型的有效性以及各个模块的重要性,本文在 ISLES2022 数据集上进行了消融实验。结果见表 1,最优指标加粗表示。由表 1 可知,相比于 UNet,在仅加入 FA 模块后,模型分割精度有较大的提升,计算量和参数量均有小幅度的减少,验证了 FA 模块中 7×7 大小的深度卷积能够在不增加计算负担的同时提升模型对低级特征的全局感知能力;在仅加入 CA 注意力机制后, *DSC* 指标提升了 3.9%,说明 CA 模块能够通过结合空间位置信息、长距离依赖关系和动态的通道权重调整,实现了在边界模糊的分割任务中更精准地识别病灶区域;在仅加入 MGC 模块后,分割精度指标均有提升,在计算性能方面有显著的优化,验证了 MGC 模块的设计能够通过分组操作、 1×1 卷积降维和全局池化等方法,在保持多尺度特征的表达能力的同时显著降低参数量和计算复杂度。综合分割精度和模型计算性能来看,相比于 FA 和 CA 模块, MGC 模块具有更显著的影响。在同时加入 FA 和 MGC 模块后,模型的分割精度和计算性能仍有小幅度的提高,说明这 2 个模块在结构上互补,在分割任务中产生了正向协同效果^[24]。最后,在同时添加 FA、CA 和 MGC 模块后,即 MGCA-UNet, *DSC*、*Recall*、*Precision* 指标达到最高,相比于 UNet,分别提升 13.1%、17.5%、14.6%;在 *Param* 和 *FLOPS* 指标中表现也十分优异,这证明了本文所提出模型的合理性和高效性,实现了在分割任务中精度与效率的双重优化。

表 1 MGCA-UNet 架构的详细消融结果(均值±标准差)

Table1 Detailed ablation results of the MGCA-UNet architecture (Mean ± Standard Deviation)					
Methods	DSC ↑	Recall ↑	Precision ↑	Params/ M ↓	FLOPS/ G ↓
UNet ^[6]	0.554(±0.341 0)	0.614(±0.356)	0.567(±0.364 0)	34.52	65.52
UNet+FA	0.643(±0.258 0)	0.732(±0.272)	0.642(±0.305 0)	34.51	64.10
UNet+CA	0.593(±0.376 0)	0.685(±0.386)	0.573(±0.406 0)	34.53	65.54
UNet+MGC	0.629(±0.313 3)	0.658(±0.304)	0.680(±0.337 0)	2.62	8.34
UNet+FA+MGC	0.675(±0.247 0)	0.743(±0.262)	0.674(±0.268 8)	2.59	6.91
MGCA-UNet(ours)	0.685(±0.246 0)	0.789(±0.282)	0.713(±0.274 0)	2.61	6.93

2.4.2 对比实验

为了验证本文模型的病灶分割性能,仿真实验使用 ISLES2022 数据集分别在 UNet、注意力 UNet 仿真(Attention-UNet)、循环残差卷积网络(R2UNet)、基于多层感知器的卷积网络(UNeXt)和本文模型上进行训练,所有训练参数均保持一致,结果见表 2,最优指标加粗表示。由表 2 可知,本文模型在 ISLE2022 数据集上的 DSC、Recall 和 Precision 分别为 0.685、0.789 和 0.713,均优于其它模型,验证了所提模型的可行性。而

在 Params 和 FLOPS 指标中,UNeXt 模型表现都更出色,这是因为该模型在潜在空间中使用了一种标记化的多层感知器(Multi-Layer Perceptrons,MLP),减少了参数量和计算复杂度,但本文方法的分割精度在可接受范围内得到了改善,且相比其他模型,本文方法在时间和空间复杂度都有明显的降低。综上所述,本文模型的综合性能更优,但仍有改进的空间,以在保持分割精度的同时满足实际应用中快速分割的需求。

表 2 不同网络在 ISLES2022 数据集上的实验结果(均值±标准差)

Table 2 Experimental results of different networks on the ISLES2022 dataset (Mean ± Standard Deviation)					
Methods	DSC ↑	Recall ↑	Precision ↑	Params/ M ↓	FLOPS/ G ↓
UNet ^[6]	0.554(±0.341)	0.614(±0.356)	0.567(±0.364)	34.52	65.52
Attention-UNet ^[7]	0.551(±0.348)	0.612(±0.366)	0.542(±0.371)	34.88	66.63
R2UNet ^[8]	0.528(±0.332)	0.658(±0.333)	0.507(±0.331)	39.09	152.92
UNeXt ^[9]	0.663(±0.258)	0.695(±0.297)	0.675(±0.267)	1.47	0.58
MGCA-UNet(ours)	0.685(±0.246)	0.789(±0.282)	0.713(±0.274)	2.61	6.93

为了更加直观地体现 MGCA-UNet 模型在缺血性卒中病灶分割任务中的显著改进,本文将所有模型的分割结果进行了可视化,如图 4 所示。从定性结果来看,表现仅次于本文方法的 UNeXt 网络在一定程度上提升了分割精度。但在处理缺血性卒中图像时存在特征表征的局限性,UNeXt 网络设计可能无法充分捕捉这些复杂的特征信息,导致误分割。而 MGCA-UNet 通过不同的网络结构来充分地捕获特征的尺度和分布信息,因此 MGCA-UNet 在正确分割、过分割和欠分割的综合性能,以及对病灶的准确定位方面表现最佳^[25]。

2.4.3 泛化实验

为了验证本文模型的泛化能力,本文选取 3 种公开医学图像数据集(Kvasir-SEG、Montgomery、

ISIC-2018)进行测试,模型分割效果如图 5 所示。实验结果表明,MGCA-UNet 在上述 3 种医学数据集上 DSC 指标分别达到了 0.821 5、0.965 1、0.885 7,均优于其他对比方法。这 3 种任务的目标区域特征存在显著差异,例如,结肠息肉形态复杂,胸部 X 光片边界模糊,而皮肤病变在颜色和纹理上变化多样。本文模型在这些不同的挑战下均取得优异的分割效果,表明模型具备良好的多任务适应性。同时,模型在不同任务中保持一致高性能,也表明其在特征提取和特征融合上具备通用能力,而不仅局限于特定类型的医学图像^[26]。这种跨任务的一致性进一步验证了 MGCA-UNet 架构的稳健性,提升了其在多样化临床应用场景中的潜在实用价值^[27]。




图 4 不同方法的缺血性脑卒中病灶分割结果对比
Fig. 4 Comparison of ischemic stroke lesion segmentation results from different methods

3 结束语

本文基于 UNet 网络提出了一种新颖的缺血性脑卒中病灶分割方法,通过采用多分组卷积结构、全局上下文捕获以及位置信息嵌入的注意力机制,有效增强了模型的多尺度特征提取和关键区域关注能力,显著提高了分割精度。同时,本文方法控制了参数量和计算开销,实现了精度与效率的平衡,展现出良好的实用价值。尽管 MGCA-UNet 在分割精度和计算效率上均有提升,但模型在处理极小病灶区域




图 5 不同类型医学数据集上的病灶分割结果对比
Fig. 5 Comparison of lesion segmentation results on different types of medical datasets

和具有复杂背景的图像时,分割精度仍有一定局限性。未来工作中可以探索自适应多尺度模块和多模态数据融合,以增强模型在小病灶和复杂背景方面的处理能力。

参考文献

[1] 张晓飞,宋其江. 基于 RF-RFECV 和 Stacking 集成学习的脑卒中预测研究[J]. 智能计算机与应用, 2024, 14(5): 252-256.
[2] ATIGOSSOU O L G, OUÉDRAOGO F, HONADO A S, et al. Association between post-stroke psychological disorders, activity limitations and health-related quality of life in chronic stroke

survivors in Benin [J]. Disability and Rehabilitation, 2023, 45 (13): 2087-2094.

[3] TAN S M L, ONG S H, YEO T T, et al. Ischemic and hemorrhagic strokes in young adults: Comparison of functional outcomes and return to work after stroke [J]. Clinical Neurology and Neurosurgery, 2023, 233: 107964.

[4] 余唯一,陈涛,张军平,等. 基于深度学习的 MRI 脑卒中病灶分割方法综述[J]. 智能科学与技术学报, 2023,5(3):293-312.

[5] 黄梨,卢龙. 基于长距离依赖编码与深度残差 U-Net 的缺血性卒中病灶分割[J]. 计算机应用, 2021,41(6):1820-1827.

[6] RONNEBERGER O, FISCHER P, BROX T. U - Net: Convolutional networks for biomedical image segmentation [C]// Proceedings of the 2015 International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2015:234-241.

[7] OKTAY O, SCHLEMPER J, FOLGOC L L, et al. Attention u-net: Learning where to look for the pancreas [J]. arXiv preprint arXiv,1804.03999, 2018.

[8] ALOM M Z, HASAN M, YAKOPCIC C, et al. Recurrent residual convolutional neural network based on UNet (R2UNet) for medical image segmentation [J]. arXiv preprint arXiv,1802.06955, 2018.

[9] VALANARASU J M J, PATEL V M. Unext: Mlp-based rapid medical image segmentation network [C]//Preceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention. Cham: Springer, 2022: 23-33.

[10] 徐旺旺,许良凤,李博凯,等. TransAS - UNet: 融合 Swin Transformer 和 UNet 的乳腺癌区域分割[J]. 中国图象图形学报,2024,29(3):741-754.

[11] 梁正友,蔡俊民,孙宇,等. 结合残差动态图卷积与特征强化的点云分类[J]. 广西师范大学学报(自然科学版), 2023,41(5): 37-48.

[12] 孙兴,蔡肖红,李明,等. 视觉大模型 SAM 在医学图像分割中的应用综述[J]. 计算机工程与应用, 2024,60(17):1-16.

[13] 陈子昂,刘娜,袁野,等. 基于多重注意力机制的多模态脑肿瘤图像分割[J]. 智能计算机与应用,2023,13(12):80-86.

[14] 刘昕斐,张荣芬,刘宇红,等. 基于 YOLOv5s 的导盲系统障碍物检测算法[J]. 智能计算机与应用, 2023, 13(11):220-226.

[15] ULKU I, AKAGÜNDÜZ E. A survey on deeplearning - based architectures for semantic segmentation on 2d images [J]. Applied Artificial Intelligence, 2022, 36(1): 2032924.

[16] 张岩,李凤莲,张雪英,等. 基于卷积融合和残差-注意力的脑卒中病灶分割[J]. 重庆理工大学学报(自然科学), 2023,37(5):185-193.

[17] 赵一铭,王佩瑾,刁文辉,等. 基于通道注意力机制的小样本 SAR 飞机图像分类方法[J]. 南京大学学报(自然科学), 2024, 60(3):464-476.

[18] PETZSCHE M R H, ROSA D L E, HANNING U, et al. ISLES 2022: A multi-center magnetic resonance imaging stroke lesion segmentation dataset [J]. Scientific Data, 2022, 9(1): 762.

[19] JHA D, SMEDSRUD P H, RIEGLER M A, et al. Kvasir-seg: A segmented polyp dataset [C]//Proceedings of the 26th International Conference on MultiMedia Modeling. Cham: Springer, 2020: 451-462.

[20] CANDEMIR S, JAEGER S, PALANIAPPAN K, et al. Lung segmentation in chest radiographs using anatomical atlases withnonrigid registration [J]. IEEE Transactions on Medical Imaging, 2013, 33(2): 577-590.

[21] CODELLA N C F, GUTMAN D, CELEBI M E, et al. Skin lesion analysis toward melanoma detection: A challenge at the 2017 International Symposium on Biomedical Imaging (ISBI), Hosted by the International Skin Imaging Collaboration (ISIC) [C]//Proceedings of the IEEE 15th International Symposium on Biomedical Imaging. Piscataway, NJ: IEEE, 2018: 168-172.

[22] 金毅东,王孟飞,陈晶晶,等. 基于深度可分离卷积的缺血性脑卒中多模态磁共振图像梗死分割模型研究[J]. 生物医学工程学杂志,2024,41(3):535-543.

[23] KOTHALA L P, JONNALA P, GUNTUR S R. Localization of mixed intracranial hemorrhages by using a ghost convolution-based YOLO network [J]. Biomedical Signal Processing and Control, 2023, 80: 104378.

[24] 毛秀华,张强,阮航,等. 多任务协同的多模态遥感目标分割算法[J]. 电子与信息学报,2024,46(8):3363-3371.

[25] 王一诺,张俊然,刘彦,等. 基于注意力增强 U-Net 的脑卒中病灶分割[J]. 计算机工程与设计, 2022, 43(8):2268-2274.

[26] 杨晶东,李皓秋,姜泉,等. 基于协同训练的半监督学习 3D 医学图像分割模型[J]. 智能计算机与应用, 2024,14(8):174-183.

[27] ZHAO Zihao, LIU Yuxiao, WU Han, et al. Clip in medical imaging: A comprehensive survey [J]. arXiv preprint arXiv, 2312.07353, 2023.