

DOI:10.3969/j.issn.1005-202X.2023.05.006

医学影像物理

MAUNet: 用于皮肤病变分割的轻量级模型

魏坤¹, 沈记全¹, 赵艳梅²

1. 河南理工大学计算机科学与技术学院, 河南 焦作 450000; 2. 河南省儿童医院重症监护室, 河南 郑州 460000

【摘要】针对当前深度学习分割算法参数数量多和计算复杂度高的问题,提出了一种融合多种注意力机制的轻量级模型 MAUNet 用于皮肤病变分割。该模型在 UNet 网络基础上融合深度可分离卷积和门控注意力机制模块,用于提取全局和局部特征信息;融入外部注意力机制模块来增强样本间的联系;利用空间和通道注意力模块分别提取通道和空间特征。以 ISIC2017 皮肤病公开数据集作为数据源,改进的 UNet 模型实现特征提取与分类。与基线模型 UNet 相比,平均交并比和 Dice 相似性系数分别提高了 2.18% 和 1.28%,同时参数数量和计算复杂度仅为基线模型的 2.1% 和 0.58%。实验结果表明该模型在参数数量平衡性、计算复杂度和分割检测性能上均达到了较好的水平。

【关键词】医学图像分割;注意力机制;皮肤病识别;轻量级;UNet

【中图分类号】R318;TP391.41

【文献标志码】A

【文章编号】1005-202X(2023)05-0555-07

MAUNet: a lightweight model for skin lesion segmentation

WEI Kun¹, SHEN Jiquan¹, ZHAO Yanmei²

1. College of Computer Science and Technology, Henan Polytechnic University, Jiaozuo 450000, China; 2. Intensive Care Unit, Henan Children's Hospital, Zhengzhou 460000, China

Abstract: The current depth learning segmentation algorithm has the problems of numerous parameters and high computational complexity. Therefore, a lightweight algorithm (MAUNet) which combines UNet and multiple attention mechanisms is proposed for skin lesion segmentation. The model integrates depth-wise separable convolution and gated attention mechanism modules on the basis of UNet to extract global and local feature information, adopts the external attention mechanism module to enhance the connection between samples, and uses the spatial and channel attention mechanism modules to extract channel and spatial features. The MAUNet model realizes feature extraction and classification on ISIC2017 skin disease public data set. Compared with the baseline model (UNet), the proposed model increases mIoU and DSC by 2.18% and 1.28% respectively, while reducing the number of parameters and computational complexity which were only 2.1% and 0.58% of the baseline model. The experimental results show that the model can balance the number of parameters, lower the computational complexity and perform well in segmentation and detection.

Keywords: medical image segmentation; attention mechanism; recognition of skin disease; lightweight; UNet

前言

医学图像分割算法模型可以辅助临床医生进行病症诊断,有效提高诊断准确率。皮肤癌是当前发病率较高的病症,所以皮肤病的早期筛查和诊断更为重要。随着计算机技术的飞速发展,尤其是人工智能领域中的医学图像分析技术在辅助诊疗中大规模

模应用和普及,出现了大量基于深度学习的医学图像诊断研究模型以及基于皮肤病研究的公开数据集,如 BCN20000、MSK、ISIC2017 等。

目前基于深度学习的皮肤病诊疗辅助技术得到了大幅度提升,而 UNet 模型是一种广泛应用于医学图像分割领域的 U 型深度卷积神经网络,它通过编码解码来实现图像的语义分割,已然成为了医学图像分割的一种标准框架模型^[1]。因其具备简单和可拓展的优势,提出了大量的改进模型,如 UNet++^[2]、Attention-Net^[3]、V-UNet^[4]、3D-UNet^[5]、Dense UNet^[6]等。谷歌提出的 Transformer 在自然语言处理领域取得非常好的效果后,很多研究者将其应用于计算机视觉,而将卷积神经网络

【收稿日期】2023-01-10

【基金项目】国家自然科学基金(61972134)

【作者简介】魏坤,硕士,研究方向:图像处理和网络安全,E-mail: weikunzz@qq.com

【通信作者】沈记全,博士,教授,研究方向:云计算和网格计算,E-mail: sjq@pu.edu.cn

(Convolutional Neural Network, CNN)与Transformer相结合的方法得到了更多的重视,Transfuse^[7]、Swin-UNet^[8]、TransBTS^[9]等改进算法相继被提出,进一步增强了视觉特征提取能力。

一般认为,增加网络层数可以更好地提取高级特征,所以以往的研究习惯在UNet网络的基础上引入更复杂的模块或者更深的网络层以换取性能的提升。然而由于移动医疗设备配置有限,许多具有大量参数的模型并不适合临床环境部署应用;其次医学图像分割属于特定的任务^[10],并且数据集中的样本之间的差异很小但是样本内的差异却很大,所以医学图像分割算法需要充分考虑多阶段和多尺度信息。

受上述研究工作的启发,平衡模型的精度以及检测速率,本研究设计了新的轻量级图像分割模型MAUNet,主要提出3个模块来优化解决上述问题。首先引入扩张门控注意力机制,它通过获取全局和局部信息使模型更多地关注目标区域,同时深度可分离卷积进一步减少参数个数并降低了计算复杂度;其次引入一种高效的外部注意力机制,它可以增强样本之间的信息关联,获取整体数据集的特征;最后针对多阶段,多尺度信息的获取引入空间和通道注意力机制模块,该模块由空间注意力子模块和通道注意力子模块组成,并采用混合损失函数提升网络的分割精度。

1 相关工作

全卷积网络(Fully Convolutional Networks, FCN)是深度学习用于语义分割领域的开山之作,是第一个端到端的图像语义分割算法,并充分利用卷积提取特征信息^[11]。UNet是建立在FCN上并适用于医学图像语义分割的端到端神经网络,在医学领域图像分割上取得了非常好的效果,已经成为了医学领域图像分割的一种基础框架。

基于UNet改进的UNet++用叠加的方式连通所有层的skip-connection,构建了多尺度的网络模型获取不同层次特征信息,补偿了采样造成的信息损失。Attention-UNet利用注意力门机制来抑制输入图像中的不相关区域,使其更加关注目标。为了进一步减少信息的丢失,提高性能,Res-UNet和Dense-UNet分别用ResNet中的Res-block和DenseNet中的Dense-block替换了纯卷积^[12]。Alom等^[13]提出了基于UNet的递归残差神经网络,利用残差网络和RCNN(Region-CNN)在UNet上的优点,提供了更好的分割检测效果。曹飞道等^[14]为了改善网络对细小毛细血管的分割性能,设计了一种基于残差空洞卷积网络

并融合三端注意力机制的神经网络模型,通过利用空间注意力机制自适应地对特征进行空间调整。

但是上述网络模型在提高性能的同时忽略了参数规模和计算复杂度的问题,使得其难以应用于真实的医疗环境中。Valanarasu等^[15]在MLP与UNet结合的基础上提出了UNeXt,在保证分割性能的前提下,显著减少了参数的数量。对于实际应用来说,轻量级模型是必然的。因此,本研究在前人研究的基础上,提出了一种用于医学图像分割的轻量级模型,并引入了多种注意模块在提升算法分割性能的同时减少模型参数和计算复杂度。

2 本文方法

2.1 改进的门控注意力模块

医学图像分割属于密集的预测任务,同时获取全局和局部信息对于提高图像分割性能至关重要。全局信息有助于模型了解病灶的整体结构及其与背景的关系,使其更准确地定位病灶区域。此外,局部信息有助于获取病灶区域的边缘细节,使预测结果更加完整。

因此,本研究引入了改进的门控注意力机制算法。如图1所示,该模块由两个块组成:深度可分离卷积单元和门控注意力机制(GAE)网络^[16]。沿信道维度将特征图分割为4部分,通过不同扩张率的深度可分离卷积,得到全局特征信息。然后,在通道维度上进行拼接操作,恢复特征图的大小,与全局和局部信息交互进行卷积操作。接下来,通过深度可分离卷积生成与输入特征形状相同的注意力图,以抑制传输的不重要特征信息,使模型更加关注重要信息。最后,通过残差连接操作获得输出。以上过程可以用式(1)~式(5)表示:

$$x_1, x_2, x_3, x_4 = \text{Chunk}_4(X) \quad (1)$$

$$x'_1, x'_2, x'_3, x'_4 = W_1(x_1), W_2(x_2), W_5(x_3), W_7(x_4) \quad (2)$$

$$X' = W(\text{Concat}(x'_1, x'_2, x'_3, x'_4)) \quad (3)$$

$$\text{Att} = \sigma(\text{DW}(X')) \quad (4)$$

$$\text{Out} = \text{DW}(\text{DW}(X') \odot \text{Att}) + W(X') \quad (5)$$

其中,Chunk₄表示输入特征映射沿通道维度 W_i 分为4个维度的卷积, i 表示空洞卷积的空洞率,Concat表示连接运算, W 表示普通卷积运算, σ 为sigmoid函数,DW表示深度可分离卷积。

2.2 改进的外部注意力机制模块

外部注意力机制算法(External Attention, EA)^[17]使用了两个共享参数的Conv1D来表征整个数据集的特征信息。此外,基于MobileNetV2中的倒残差卷积启发,设计了一种改进的外部注意力机制模块(EAI),如图2所示。




图1 改进的门控注意力机制

Figure 1 Improved gated attention mechanism

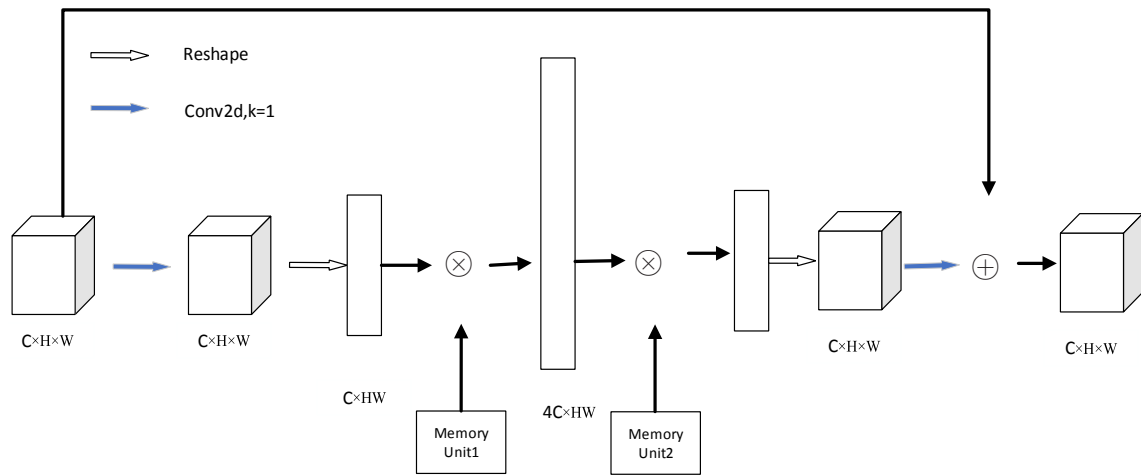


图2 改进的外部注意力机制

Figure 2 Improved external attention mechanism

给定一个输入 $X \in \mathbb{R}^{C \times H \times W}$, 经过 1×1 卷积和重塑运算后, 大小变为 $X \in \mathbb{R}^{C \times HW}$ 。然后将特征映射展开4倍, 得到 $Att \in \mathbb{R}^{4C \times HW}$, 然后恢复原来的维数再进行重塑操作, 恢复到原来的特征图大小。最后, 通过 1×1 卷积得到输出的特征图, 并加入残差信息。两个存储单元之间的通道数升高4倍维度, 这样内存单元更好地将输入映射到更高维度空间, 使得内存单元对数据集的整体特征信息描述更加全面。

2.3 双注意力机制模块

卷积块注意力机制模块 (Convolutional Block Attention Module, CBAM) 序列化在通道和空间两个维度产生注意力特征信息, 然后两种特征信息与之前原输入特征图相乘进行自适应性的特征修正输出最终特征图^[18]。通道注意力和空间注意力在抑制无关信息方面都发挥着至关重要的作用, 极大地提高了计算机视觉任务的水准。并且多阶段多尺度信息的融合已被证明是提高性能的关键。因此将 CBAM

引入模型中, 如图3所示。CBAM 主要包含两个步骤: 首先将通道轴上不同阶段的特征串联起来, 生成通道注意力; 其次在空间维度上对通道领域再次提取特征进行 GMP 和 GAP 的压缩, 生成二维的特征图, 然后根据分配的特征权重实现特征信息增强, 因此提升了浅层中的关注度, 以更好地整合信息。通道注意力可以用式(6)~式(10)表示:

$$t'_i = \text{GAP}(t_i) \quad (6)$$

$$T = \text{Concat}(t'_1, t'_2, \dots, t'_{s-1}) \quad (7)$$

$$T' = \text{Conv1D}(T) \quad (8)$$

$$\text{Att}_i = \sigma(\text{FC}_i(T')) \quad (9)$$

$$\text{Out}_i = t_i + t_i \odot \text{Att}_i \quad (10)$$

其中, GAP 表示全局平均池化, t_i 表示从编码器获得的不同阶段的特征图, Concat 表示通道维度上的级联运算, s 表示级的总数, Conv1D 表示 1D 卷积运算, T 表示链接的特征, T' 表示卷积特征, Out_i 双注意力机制输出结果。

在空间注意力模块中,笔者在通道维度上采用全局平均池化和全局最大池化的操作并将它们连接起来,得到具有两个通道的特征图,而高度和宽度保持不变。然后,利用一个共享的扩张卷积操作,使用一个sigmoid函数生成每个阶段的空间注意力地图。最后,将生成的空间注意力地图按元素乘上原始属

性,并加入残差信息,得到每个阶段的特征图。

最后CBAM模块将多阶段、多尺度的局部信息和全局信息相融合以提供信息量更大的通道注意力特征图;同时,将空间轴上的多阶段、多尺度信息进行融合,生成每个阶段的注意力地图。




图3 CBAM结构
Figure 3 CBAM architecture

2.4 损失函数

基于UNet的医学图像分割模型一般采用BCE损失函数训练,具体如式(10)所示:

$$L_B = -\sum_{i=1}^N (T_i \log(P_i) + (1 - T_i) \log(1 - P_i)) \quad (10)$$

其中, P_i 为预测数值, T_i 是标签数值, N 是样本个数综合, L_B 是BCE损失值,即先通过预测结果与标签值之间的损失然后应用反向传播方式更新网络模型。医学图像样本具有特殊性,数据样本的类不平衡将导致训练不稳定。Dice损失函数通过校验预测值和标签之间的相似度,很好地解决了类不平衡问题,如式(11)所示:

$$L_{Dice} = 1 - \frac{2|X \cap Y|}{|X| + |Y|} \quad (11)$$

其中 $|X \cap Y|$ 表示 X 和 Y 之间交集元素的个数, $|X|$ 和 $|Y|$ 分别表示 X 、 Y 中元素的个数。结合两类损失函数的优点,按照权重相加的形式获取复合损失函数,提高网络在医学图像领域的预测能力,具体如式(12)所示:

$$L = \lambda_1 \times BCE + \lambda_2 \times Dice \quad (12)$$

其中, λ_1 、 λ_2 表示2个损失函数的权重,本研究中,权重默认均为1。

3 网络结构设计

如图4所示,本文所提模型MAUNet中,使用了6

阶段的U型架构,各个阶段的通道数分别为{8, 16, 24, 32, 48, 64},在UNet网络5阶段基础上增加了1个阶段。阶段1~3中卷积运算从2个减少到1个。阶段4~6中,把改进的门控注意力机制模块和改进的外部注意力模块串联排列起来,前者获取数据集的整体特征和样本之间的关系,后者获取样本中的全局和局部特征信息,两者相辅相成,充分利用了不同注意力机制的优点。此外,CBAM双注意模块可以融合多阶段、多尺度特征阶段(1~5阶段),生成空间维度和通道维度的注意力地图,然后将CBAM注意模块获得的特征与解码器部分的特征进行添加,以减少编码器和解码器之间的特征语义差异,同时减少采样过程造成的信息损失。

4 实验结果与分析

4.1 实验数据和环境

本研究使用ISIC2017皮肤病公开数据集进行实验仿真,以评估和测试本文模型的性能。ISIC2017含有2150张带有分割标识的图片,按照8:2的比例随机划分训练集和测试集。

实验环境为Ubuntu操作系统,32G内存,GeForce RTX3080 GPU的计算平台。首先将所有图片都归一化并调整成256×256的大小,然后采用水平翻转、垂直翻转和随机旋转数据增强算法。使用

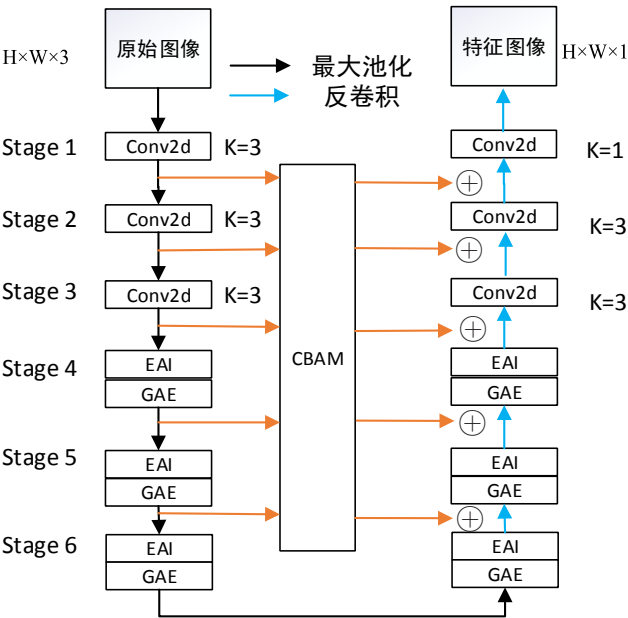


图4 MAUNet 结构
Figure 4 MAUNet architecture

BceDice 复合损失函数,初始化学学习率为 0.001,AdamW 作为优化器。使用余弦退火学习速率调度器,最大迭代次数为 50,最小学习率为 0.000 01,训练轮次为 300,批处理大小为 8。

4.2 评估指标

二分类模型一般按照混淆矩阵计算,其中 TP、

FP、FN、TN 代表真阳性、假阳性、假阴性、真阴性。该模型引入平均交并比(mIoU)、准确性(ACC)、特异性(Spe)、Dice 相似性系数(DSC)评估模型分割效果。此外利用 Params 来表示参数量,单位为 Million(M),浮点运算符(GFLOPs)表示计算复杂度,各指标公式如式(13)~(16)所示:

$$mIoU = \frac{TP}{TP + FP + FN} \tag{13}$$

$$DSC = \frac{2TP}{2TP + FP + FN} \tag{14}$$

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \tag{15}$$

$$Spe = \frac{TN}{TN + FP} \tag{16}$$

4.3 实验结果对比

为了证明本文模型的有效性,基于 ISIC2017 数据集与近年来其他 UNet 改进模型性能进行测试对比。实验结果如表 1 所示,本文模型参数量和计算量显著优于其他模型,并且在 ACC 和 Spe 评价指标上取得了最好的成绩。另外与基准模型 UNet 相比可以看出,本文模型不仅性能得到大幅度提升而且计算复杂度也大幅度改善。与 TransFuse 相比虽然 mIoU 和 DSC 分别降低了 0.05% 和 0.13%,但是大幅度减少了参数量和计算复杂度,并且与 UNeXt-S 相比,性能得到了提升的同时进一步减少了参数量和计算复杂度。

表 1 与其他网络模型性能对比实验结果
Table 1 Performance comparison with other algorithms

模型	Params/M	GFLOPs/G	mIoU/%	DSC/%	ACC/%	Spe/%
UNet	7.77	13.78	76.98	86.99	95.65	97.44
TransFuse	26.27	11.54	79.21	88.40	96.10	97.98
TNetV2	128	15.50	77.35	87.23	95.83	98.03
UNeXt-S	30	0.10	78.26	87.80	95.98	97.70
本文模型	0.16	0.08	79.16	88.27	96.21	98.51

图 5 给出了各模型对具体病灶图像的检测识别结果。可以看出,本文模型可以全部准确识别这些图像,而其他模型都存在识别差异的现象。可见本文模型可对临床皮肤病灶进行较好的识别,模型精度较高、泛化能力较好。

4.4 消融实验对比分析

4.4.1 消融实验 在 ISIC2017 数据集上对每个提出的模块进行对比实验,证明 3 种改进的注意力机制模块可以在不同程度上提升算法的性能。实验结果如表 2 所示,本研究以 6 阶段的 UNet 网络为基准模型。对比第一组(UNet 基准模型)和第二组(UNet+DGA)实验发

现,GAE 模块取代了 UNet 中 4~6 阶段的卷积运算,深度可分离卷积可以使模块参数量明显降低,因此 DGA 在提高性能的同时减少了参数量和计算复杂度,同时获取全局和局部特征信息也提升模型的精度。对比第三组(UNet+EA)和第四组(UNet+EAI)实验发现,加入倒残差卷积后,网络的性能指标都得到了明显的提升,说明残差卷积不丢失局部细节,可以获得更充足的细节特征。最后 CBAM 模块的引入(UNet+CBAM)同时获取通道和空间的特征信息,虽然增加了参数数量但是提升了模型的精度。

4.4.2 通道数量的差异与基线模型对比消融实验

UNet 是一个 5 阶段的 U 型架构模型,并且各个阶段的通道数为 {32, 64, 128, 256, 512}, 每个阶段含有两个卷积层。本文模型将 5 阶段架构改成 6 阶段,每个阶段是一个卷积层。表 3 显示了不同配置下训练结果。UNet 主要是使用编码器和解码器之间的串联,而 6 阶段模型是逐元素加法计算。

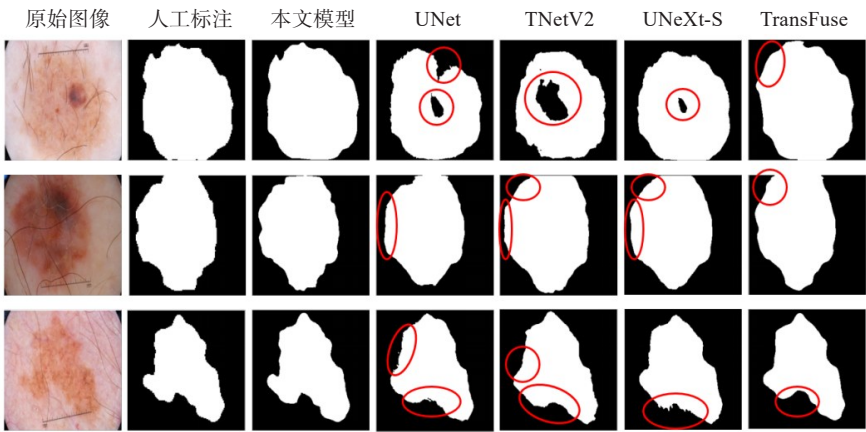


图5 皮肤病图像分割结果对比图

Figure 5 Comparison of skin disease image segmentation results

表 2 不同模块的消融实验结果

Table 2 Ablation study of modules

模型	Params/M	GFLOPs/G	mIoU/%	DSC/%	ACC/%	Spe/%
UNet	0.11	0.07	78.26	87.89	94.02	96.09
UNet+DGA	0.08	0.06	79.15	88.47	94.33	96.28
UNet+EA	0.15	0.08	79.30	88.43	94.29	96.63
UNet+EAI	0.18	0.09	79.83	88.75	94.62	96.79
UNet+CBAM	0.12	0.07	78.94	88.21	94.36	96.61

表 3 通道数量差异消融实验

Table 3 Ablation study of channels

通道数	Params/M	GFLOPs/G	mIoU/%	DSC/%	ACC/%	Spe/%
{32, 64, 128, 256, 512}	7.77	13.76	77.98	87.55	95.05	97.69
{16, 32, 64, 128, 160, 256}	1.32	0.48	78.49	88.15	95.17	97.07
{8, 16, 32, 64, 128, 160}	0.53	0.15	78.40	87.89	95.24	97.75
{8, 16, 32, 48, 64, 96}	0.19	0.11	78.36	87.80	95.16	97.08
{8, 16, 24, 32, 48, 64}	0.11	0.08	78.14	87.77	95.09	97.32

5 结 语

针对当前医学图像分割算法带来的网络复杂、计算量大、难以快速大规模应用等在辅助诊疗存在的局限性问题,提出了一种轻量级的图像分割网络 MAUNet。本研究取得的主要结论成果如下所示。轻量级 MAUNet 网络引入了 3 个注意力机制模块:(1)将深度可分离卷积引入 GAE 获取全局和局部特征信息并显著降低网络参数数量和计算损耗;(2)将倒残差卷积思想引入 EA 模块,获取数据集整体样本特

征,建立样本之间的关系;(3)引入 CBAM 模块,融合多阶段多尺度特征信息,在空间和通道处获得相应的注意力图,提高模型的分割精度。实验结果表明本文模型在精度和参数数量上都有很大的优势,其特性在处理临床数据集时更实用和高效。虽然本研究取得了一定的进展,但是目前还未适用于其他数据集。因此,在保持模型的预测精度和训练速度的基础上使模型适用于其他疾病,是下一步的研究重点。

【参考文献】

- [1] Olaf R, Philipp F, Thomas B, et al. U-Net: convolutional networks for biomedical image segmentation [C]//International Conference on Medical Image Computing and Computer-Assisted Intervention. Springer, 2015: 234-241.
- [2] 何易龙, 文晓涛, 王锦涛, 等. 基于3D U-Net++L3卷积神经网络的断层识别[J]. 地球物理学进展, 2022, 37(2): 607-616.
- He YL, Wen XT, Wang JT, et al. Fault recognition based on 3D U-Net++L3 convolutional neural network[J]. Progress in Geophysics, 2022, 37(2): 607-616.
- [3] Oktay O, Schlemper J, Folgoc LL, et al. Attention U-Net: learning where to look for the pancreas[J]. arXiv, arXiv: 1804.03999, 2018.
- [4] Milletari F, Navab N. V-Net: fully convolutional neural networks for volumetric medical image segmentation [C]//Fourth International Conference on 3D Vision (3DV). IEEE, 2016: 565-571.
- [5] 侯腾璇, 赵涓涓, 强彦, 等. CRF 3D-UNet肺结节分割网络[J]. 计算机工程与设计, 2020, 41(6): 1663-1669.
- Hou TX, Zhao JJ, Qiang Y, et al. Pulmonary nodules segmentation based on CRF 3D-UNet structure[J]. Computer Engineering and Design, 2020, 41(6): 1663-1669.
- [6] 王莹, 朱家明, 徐婷宜, 等. 融合深度残差结构的Dense-UNet脑肿瘤分割[J]. 无线电工程, 2022, 52(9): 1566-1573.
- Wang Y, Zhu JM, Xu TY, et al. Dense-UNet fused with deep residual structure for brain tumor segmentation[J]. Radio Engineering, 2022, 52(9): 1566-1573.
- [7] 王媛媛, 董芳, 尚丽娜, 等. 基于改进TransUNet网络的血管内超声图像边界提取方法研究[J]. 中国生物医学工程学报, 2023, 42(1): 41-50.
- Wang YY, Dong F, Shan LN, et al. Research on the IVUS border detection method based on improved TransUNet[J]. Chinese Journal of Biomedical Engineering, 2023, 42(1): 41-50.
- [8] 张文康. 基于Swin-UNet的云分割算法的研究[J]. 仪器仪表用户, 2022, 29(4): 5-9.
- Zhang WK. Research on cloud segmentation based on Swin-UNet[J]. Instrumentation Customer, 2022, 29(4): 5-9.
- [9] Wang WX, Chen C. TransBTS: multimodal brain tumor segmentation using transformer [C]//Medical Image Computing and Computer-Assisted Intervention. Springer, 2021: 109-119.
- [10] Liu AB, Yang YQ, Sun QY, et al. A deep fully convolution neural network for semantic segmentation based on adaptive feature fusion [C]//5th International Conference on Information Science and Control Engineering. IEEE, 2018: 16-20.
- [11] Xiao X, Lian S, Luo ZM, et al. Weighted Res-UNet for high-quality retina vessel segmentation [C]//9th International Conference on Information Technology in Medicine and Education (ITME). IEEE, 2018: 327-331.
- [12] He KM, Zhang XY, Ren SQ. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). IEEE, 2016: 770-778.
- [13] Alom MZ, Yakopcic C, Taha TM, et al. Nuclei segmentation with recurrent residual convolutional neural networks based U-Net (R2U-Net) [C]// 2018 IEEE National Aerospace and Electronics Conference. IEEE, 2018: 228-233.
- [14] 曹飞道, 赵怀慈. 基于三端注意力机制的视网膜血管分割算法[J]. 控制与决策, 2021, 37(10): 2505-2512.
- Cao FD, Zhao HC. Improved U-Net based on three-terminal attention mechanism for retinal vessel segmentation[J]. Control and Decision, 2021, 37(10): 2505-2512.
- [15] Valanarasu JM, Patel VM. UNeXt: MLP-based rapid medical image segmentation network[J]. arXiv, arXiv: 2203.04967, 2022.
- [16] 郑诚, 梅亮, 赵伊研, 等. 基于双向注意力机制和门控图卷积网络的文本分类方法[J]. 计算机科学, 2023, 50(1): 221-228.
- Zheng C, Mei L, Zhao YY, et al. Text classification method based on bidirectional attention and gated graph convolutional networks[J]. Computer Science, 2023, 50(1): 221-228.
- [17] Ei Asnaoui K, Chawki Y. Using X-ray images and deep learning for automated detection of coronavirus disease[J]. J Biomol Struct Dyn, 2021, 39(10): 3615-3626.
- [18] 吴福彬, 卢浩然, 王统, 等. 基于CBAM YOLOv4-Mish的乳腺X线摄片肿块检测方法[J]. 中南民族大学学报(自然科学版), 2023, 42(2): 245-252.
- Wu FB, Lu HR, Wang T, et al. Mammography mass detection method based on CBAM YOLOv4-Mish [J]. Journal of South-Central University for Nationalities (Natural Science Edition), 2023, 42(2): 245-252.

(编辑:薛泽玲)