

基于 U-Net 改进模型的多模态脑肿瘤分割方法

黄莉^{1,2}, 何美玲^{1,2*}

(1. 武汉科技大学 计算机科学与技术学院, 湖北 武汉 430065;

2. 湖北省智能信息处理与实时工业系统重点实验室, 湖北 武汉 430065)

摘要: 诊断脑肿瘤时, 如果能从多种模态的核磁共振成像(MRI)图像中精准分割出脑肿瘤区域, 将有助于医生快速和准确的诊断。针对分割脑肿瘤时出现的边界分割不精准问题, 该文提出了一种基于 U-Net 改进模型的脑肿瘤分割方法。该方法将 U-Net 每级编码器的特征图保留, 来捕获分割目标的边界细节信息, 进而对保留的特征图采用自注意力模块计算通道级别注意力, 加强分割目标的边界空间信息提取, 最后使用尺度融合模块统一特征图的尺度和通道数, 来融合分割目标的边界信息, 作为解码器的输入, 从而提高分割性能。该方法在 BRATS2017 数据集上进行训练和测试, 在 Dice、SE、SP 三个评估指标的参考下, 通过消融实验证明了融合多尺度模块和自注意力机制的有效性, 并与 U-Net、ResUNet、SGNet、RelayNet 四种网络模型进行对比实验, 表明由于融合了分割目标边界的细节和空间信息, 该模型得到的分割区域更加接近真实脑肿瘤区域。

关键词: 脑肿瘤; U-Net; 卷积神经网络; 图像分割; 多尺度策略; 自注意力机制

中图分类号: TP391

文献标识码: A

文章编号: 1673-629X(2022)11-0058-06

doi: 10.3969/j.issn.1673-629X.2022.11.009

Multi-model Brain Tumor Segmentation Method Based on Improved U-Net Model

HUANG Li^{1,2}, HE Mei-ling^{1,2*}

(1. School of Computer Science and Technology, Wuhan University of Science and Technology,
Wuhan 430065, China;

2. Hubei Province Key Laboratory of Intelligent Information Processing and Real-time Industrial,
Wuhan 430065, China)

Abstract: When diagnosing brain tumors, if the brain tumor area can be accurately segmented from multiple modal MRI images, it will help doctors make a quick and accurate diagnosis. Aiming at the problem of inaccurate boundary segmentation when segmenting brain tumors, we propose a brain tumor segmentation method based on U-Net model. This method retains the feature map of each level of U-Net encoder to capture the boundary detail information of the segmentation target, uses the self-attention module to calculate the channel-level attention of the retained feature map, and strengthens the boundary space information extraction of the segmentation target. Finally, the scale fusion module is used to unify the scale and the number of channels of the feature map to fuse the boundary information of the segmentation target as the input of the decoder, thereby improving the segmentation performance. The proposed method is trained and tested on the BRATS2017 data set. Under the reference of the three evaluation indicators of Dice, SE and SP, the effectiveness of the fusion of multi-scale modules and the self-attention mechanism is proved through ablation experiments. Compared with the four network models of U-Net, ResUNet, SGNet and RelayNet, the segmentation area obtained by the model is closer to the real brain tumor area, due to the integration of the details and spatial information of the segmentation target boundary.

Key words: brain tumor; U-Net; convolutional neural network; image segmentation; multi-scale strategy; self-attention mechanism

0 引言

脑胶质瘤是最为多见的原发性脑肿瘤, 绝大多数

属恶性, 具有很高的致死率, 早发现与早治疗往往能够延长患者的平均寿命。在临床中, 核磁共振成像

收稿日期: 2021-12-03

修回日期: 2022-04-05

基金项目: 国家自然科学基金项目(51575407); 湖北省教育厅科研项目(B2019008)

作者简介: 黄莉(1982-), 女, 副教授, CCF 会员(E4267M), 研究方向为计算机视觉、语义 Web、智能信息处理; 通讯作者: 何美玲(1997-), 女, 硕士研究生, CCF 会员(D5874G), 研究方向为计算机视觉、智能信息处理。

(Magnetic Resonance Imaging, MRI) 技术是最常用的脑肿瘤诊断技术,可以准确描绘肿瘤区域。但是由于病人 MRI 图像数量巨大,医生手动标注脑肿瘤区域耗时且效率低下,因此基于深度学习的自动脑肿瘤分割方法在辅助医生诊断及确定治疗手段等方面具有重要意义。

医学图像分割^[1-4]作为图像分割的一类,是计算机视觉领域的一个重要研究方向。其主要研究内容是通过计算机把图像分成若干个特定的、具有独特性质的区域^[5-7]。传统的图像分割算法主要包括图像预处理、图像特征提取和目标区域分割三个步骤,其中图像特征提取是图像分割算法中最核心的部分,该部分所提取的特征的优劣直接影响到图像分割的性能。传统的图像分割算法在特征提取模块提取的特征对目标边界区域具有较大的冗余性和不精确性,从而会导致分割不精准,并且也不具有很好的泛化能力,因此研究者们提出了许多神经网络模型来解决上述问题。

一种方法是引入自注意力机制,通过在特征图提取阶段引入自注意力,网络能够更好地关注与图像类别相关的区域,捕获目标的边界空间信息。但是仅依靠自注意力机制,网络缺乏对于边界细节信息的学习。另一种是引入多尺度策略,由于图像经过多层卷积和池化操作,丢失了大量的细节信息,从而导致卷积网络及其改进模型所提取的特征往往表征能力不足。因此引入多尺度策略,用来最大程度地保留细节信息。但是仅依靠多尺度策略,网络缺乏对于目标边界空间信息的学习。

因此,该文提出了一种基于自注意力机制和多尺度策略的 U-Net 来解决上述问题。该方法将编码器模块每层卷积得到的特征图保留,对其计算通道注意力来获得自注意力图,然后将得到的自注意力图通过设计的尺度融合模块组成多尺度特征图,替代网络原本的特征图,提高神经网络模型的特征提取能力,从而提高分割性能。在 BRATS2017 数据集上的实验证明了该模型的有效性。

1 相关工作

1.1 自注意力机制

人类会选择性地使用数据中的重要部分来做出决策,类似地,人类在查看一张图像时,往往只会关注其中最重要的部分,而不是关注图像整体,此过程称之为注意力机制。自注意力机制是注意力机制的改进,其减少了对外部信息的依赖,更擅长捕捉数据或特征的内部相关性,现阶段被广泛应用于大量计算机视觉任务中^[8-11]。文献[12]提出了 DANET,将自注意力机制用于场景分割,在特征的空间维度和通道维度分别抓

取特征之间的全局依赖关系,增强特征的表达能力,然而它由两个并列的注意力模块组成,因此计算量较大。文献[13]针对自注意力占用 GPU 内存大和计算量大的问题提出了 CCNET,它只关注每个像素点所在的行与列的权重,循环两次后便能达到与自注意力机制一样的效果,进而能减少计算量,但因为只关注了所在行与列从而忽略了部分空间信息。除此之外,文献[14]提出的 ISSA 采用交错机制与自注意力机制结合的方式来获得任意两个位置的依赖关系,其主要思想是将密集相似矩阵分解为两个稀疏相似矩阵的乘积。文献[15-17]采用通道注意力机制,通过建模各个特征通道的重要程度,然后针对不同任务来增强或抑制不同的通道。在计算量与模型复杂度一样的情况下,使用通道级注意力的方法在所有注意力的方法中达到了最好效果,因而文献[18]采用通道级的注意力获得自注意力图来增强边界空间信息进而提升目标定位精度。

1.2 多尺度策略

目前大多数语义分割网络都采用的是编码器-解码器结构,传统的 U-Net^[19]将图像输入到编码器,获取编码器中最后一层的特征图后,输入到解码器中进行解码。虽然最后一层的特征图含有最丰富的语义信息,但其缺少相应的细节信息,导致网络学习不充分,进而出现过分割和欠分割的问题。为了解决这一问题,Relay-NET^[20]通过引入跳连接机制来保证关键位置信息的保存,进而提升分割性能,但对于目标边界信息仍会有丢失。为了解决目标边界信息会丢失的问题,文献[21-23]通过在传统网络中引入多尺度策略来增强目标边界信息的特征提取,进而提升任务精度。全监督方法^[24]证明通过引入较低级别的特征可以进一步加强细节特征与边界特征的获取。随着多尺度的进一步研究,多尺度特征融合策略引入了上下文相关的组合,以共同探索高级特征和低级特征的优势。文献[25]合并了多尺度特征进行语义分割,获得了更准确的结果。文献[26]将多尺度策略成功应用到类激活图中,在编码部分采用多尺度策略来获得精确的显著性图。

由此,该文将自注意力机制和多尺度策略相结合,提出了一种新的 U-Net,借助自注意力机制获取目标边界空间信息,在编码器部分采用多尺度策略使输入到解码器的特征图包含边界细节信息,从而提高图像分割的性能。

2 文中方法

提出的 U-Net-AMS (U-Net with Attention and Multiple Scale) 模型是基于 U-Net^[19]的改进模型。主要改进是使用自注意力机制处理每层编码器得到的特

征图,然后将特征图通过多尺度融合模块进行融合作为解码器输入,增强编码器对分割目标边界信息的特征表达能力,提高分割准确度。

U-Net-AMS 模型整体呈 U 型结构,如图 1 所示。主要分为三步:多尺度特征图的获取、特征图信息加强、特征图的融合。多尺度特征图的获取是通过保留编码器的所有特征图实现的,来最大程度地捕获分割

目标的边界细节信息;特征图信息加强是采用自注意力模块 SAM(Self Attention Module)实现的,SAM 模块采用通道注意力机制计算特征图的自注意力图,使用 sigmoid 激活函数来加强分割目标边界的空间信息。特征图融合模块是通过尺度融合模块 SDS(Scaling and Downsampling)实现的,对特征图的尺度和通道进行归一化,基于通道进行融合。

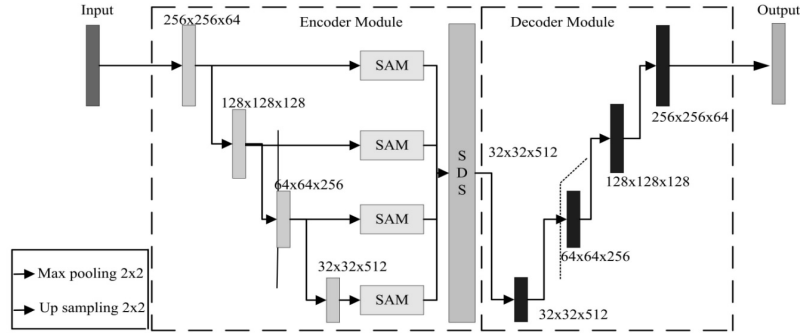


图 1 U-Net-AMS 网络结构

从上述过程可知,U-Net-AMS 使用自注意力机制和特征图融合获取了包含丰富细节和语义信息的特征图,最终将融合特征图作为解码器的输入来提升目标分割精度。

2.1 SAM 模块

自注意力模块 SAM 使用通道注意力机制来对编码器的输出特征图进行处理,加强其边界空间信息的特征,其网络结构如图 2 所示。该文利用通道间的相互关系,采用全局平均池化的方法整合每个通道的特征映射来生成相应的权重信息。对于编码器第 n 层特征图的每一个输出通道,先用全局平均池化,得到 0 到 1 之间的标量作为通道权重,随后将通道的每个元素与权重分别相乘,得到处理后的注意力图 $M_{att}^n \in R^{H_n \times W_n}$ 。给定编码器第 n 层特征图 $F^n \in R^{H_n \times W_n \times C_n}$,采用公式(1)计算 F_n 的聚合通道的权重:

$$s_{chan}^n = \frac{1}{H_n \times W_n} \sum_{i=1}^{H_n} \sum_{j=1}^{W_n} u_n(i, j) \quad (1)$$

其中, i 表示纵向的位置, j 表示横向的位置, $H_n \times W_n$ 表示 F_n 中每个通道特征图的所有像素数量, u_n 表示第 n 张特征图的像素集合。




图 2 SAM 模块结构

获得聚合通道的权重后,将所有元素分别与权重相乘,生成自注意力图 $M_{att}^n \subseteq R^{H_n \times W_n}$ 。为了获得位置信

息更加明确的特征图,使网络对分割目标边界的空间信息的提取更加准确,对自注意力图进行额外处理。通过公式(2)将得到的自注意力图 M_{att}^n 通过 sigmoid 激活函数获得重要性图 $M_{imp}^n \subseteq R^{H_n \times W_n}$ 。sigmoid 函数的作用是使差别大的区域中的每个像素的强度接近于 1,对于差别较小的区域中的每个像素的强度接近于 0,这样可以提高特征图中边缘区域的提取精度。

$$M_{imp}^n = \text{sigmoid}(M_{att}^n) \quad (2)$$

最后采用公式(3)将重要性图 M_{imp}^n 与第 n 层解码器的输出特征图 F_n 进行空间尺度上的相乘获得处理后的特征图 $F_n^A \in R^{H_n \times W_n \times C_n}$ 。

$$F_n^A = M_{imp}^n \otimes F_n \quad (3)$$

其中, \otimes 表示逐元素相乘,经过上述过程,特征图边缘区域的差别更加明显,可以更好地提取空间信息特征,从而提高边缘区域的分割效果。

2.2 SDS 模块

为了解决编码器得到的特征图在尺度和通道都不一致而无法直接融合的问题,提出了尺度融合模块 SDS,其网络结构如图 3 所示。编码器的特征图经过 SAM 模块处理得到多个不同尺度的特征图 ($F_1^A, F_2^A, \dots, F_N^A$)。为了使网络最大程度地学习到分割目标的边界信息,将这些特征图使用 SDS 模块来统一其尺度和通道数,随后进行融合。




图 3 SDS 模块结构

所提出的尺度融合模块主要包含以下三个步骤:第一,将多尺度特征图 ($F_1^A, F_2^A, \dots, F_N^A$) 通过 1×1 的卷积核来归一化其通道数,用来均衡不同尺度的信息。第二,对归一化后的特征图通过下采样来统一其大小,以便进行基于通道的特征图融合。第三,将处理后的特征图基于通道拼接进行融合,用来替换传统的仅含有丰富语义信息的底层特征图,最大程度保留分割目标的边界信息。

文中方法是通过将编码器的所有特征图保留,采用自注意力模块处理,来加强对边界信息的提取能力,进而使用 SDS 模块归一化特征图的尺度与通道数,最后将处理后的特征图基于通道进行融合,最大程度保留分割目标的边界信息。设计的整个流程可以看作是特征融合的操作,其目的是使输入到解码器中的特征图包含丰富的分割目标边界信息。

3 实验与分析

实验在一个高性能服务器集群上运行,管理平台为 kubernetes 工作站,核心服务器配置为 linux,操作系统为 centos,工作站配备 Intel(R) Xeon(R) CPU E5-2660 v4 处理器,主频 2.00 GHz,内存 32G。实验使用 Pytorch 深度学习框架,使用的 IDE 为 JetBrains 公司的 Pycharm,编程语言为 Python。Pytorch 是由 Facebook 公司开发的一个开源的 Python 深度学习库,通过使用 Pytorch 搭建平台,用户可以调用相关的第三方开源函数工具包。

3.1 数据集介绍

该文采用 BRATS2017 脑肿瘤分割数据集^[27],该数据集提供了带注释的低等级神经胶质瘤 (Low Grade Gliomas, LGG) 和高等级神经胶质瘤 (High Grade Glioblastomas, HGG)。BRATS2017 由 210 个 HGG 和 75 个 LGG 病例组成,图像尺寸为 256×256 。BRATS2017 数据集采用的 MRI 图像来自 19 家研究机构,并通过不同的磁场强度和 MRI 扫描仪获得,由四位专家进行手动标注。

3.1.1 预处理

为了改善图像的质量,避免对网络性能造成影响,使用中值滤波 (median filter) 去噪算法进行预处理。通过把图像中的某一点用它邻域中各点值的中值进行替换,让该点周围的像素值尽可能地接近真实值,从而去除多余的噪声点,最大程度地减少噪声对图像的干扰。图 4 中显示了预处理前后的脑肿瘤图像。

3.1.2 数据增强

为了使网络更好地学习目标的所有特征,并同时增强网络的鲁棒性,引入数据增强到网络的训练中。该文采用随机水平平移和随机旋转两种图像增强方法

处理训练集中的图像和图像掩码。训练集包含 665 张原始图像和图像掩码;测试集包含 332 张原始图像和图像掩码;所有图像大小统一为 256×256 ,并且都经过相同的数据预处理。




图 4 预处理前后对比

3.2 评价指标

在脑肿瘤的分割中,若模型分割的结果 (A) 与专家标注的图像区域 (B) 相同则该像素点为真阳性 (TP),反之为假阳性 (FP);对于图像背景区域,若分割结果的像素点与标注图像相同则该像素点为真阴性 (TN),反之为假阴性 (FN)。

为了定量分析网络模型的分割结果并且更好地与其他方法进行对比,该文采用 Dice、灵敏度 (SE) 和特异性 (SP) 这三个通用指标来客观评价模型对脑肿瘤的分割效果。以上指标计算公式如下:

$$\text{Dice} = \frac{2 | A \cap B |}{| A | + | B |} \quad (4)$$

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

$$\text{SP} = \frac{\text{TN}}{\text{TN} + \text{FP}} \quad (6)$$

3.3 参数设置及训练

优化方法采用随机梯度下降 (Stochastic Gradient Descent, SGD), 训练批次设定为 200, 测试批次设定为 50, 学习率初始化为 0.002, 编码器卷积层数 N 设置为 4, 采用 Dice 损失函数训练网络。

3.4 实验结果及分析

3.4.1 消融实验

为了证明多尺度策略和自注意力机制的有效性和必要性,进行了消融实验,结果如表 1 所示,表明提出的模型的分割能力和自注意力机制以及多尺度策略相关。

表 1 是否添加 SAM 模块和 SDS 模块的消融实验

| 指标 | U-Net | U-Net +SAM | U-Net +SDS | U-Net +SAM+SDS |
|------|---------|---------------|---------------|-------------------|
| Dice | 0.847 2 | 0.855 1 | 0.886 9 | 0.896 2 |
| SE | 0.831 9 | 0.849 2 | 0.861 7 | 0.887 3 |
| SP | 0.942 5 | 0.949 8 | 0.953 7 | 0.961 4 |

3.4.2 不同分割方法的分析

为了验证提出的 U-Net-AMS 模型的有效性,与 RelayNet^[20]、U-Net^[19]、ResUNet^[28] 和 SGNet^[29] 四种分

割网络进行对比实验。采用相同的网络训练参数,利用验证集对训练好的模型性能进行测试。采用 Dice

系数进行分割效果评估,列出了三种病变 Dice 值以及平均 Dice 值,实验结果如表 2 所示。

表 2 U-Net-AMS 与其他网络分割性能的对比 (Dice)

| 网络 | Lesion1 | Lesion2 | Lesion3 | Avg |
|----------|----------|----------|----------|----------|
| Ours | 0.849 32 | 0.934 28 | 0.679 04 | 0.934 26 |
| RelayNet | 0.659 91 | 0.719 44 | 0.413 84 | 0.846 47 |
| U-Net | 0.578 22 | 0.173 54 | 0.731 21 | 0.829 91 |
| ResUNet | 0.717 98 | 0.532 91 | 0.731 81 | 0.882 92 |
| SGNet | 0.773 72 | 0.671 74 | 0.773 32 | 0.876 42 |

其中,Lesion1 表示水肿区域,Lesion2 表示增强肿瘤区域,Lesion3 表示坏死肿瘤区域。所提方法在三种病变组织的 Dice 上均有提升,并且在平均 Dice 上取得了最高值。实验表明,文中模型通过引入自注意力机制和多尺度策略,能最大程度地保留分割目标的边界信息,有效提升网络对输入图像特征的提取能力,进而提高分割精准度。

图 5 选择 5 个不同的脑肿瘤图像分割结果进行展示,从左到右依次是原始图像、专家标注、U-Net-AMS、RelayNet、ResUNet、SGNet 和 U-Net 的分割结果图像。可以看出,对比第二列的专家标注,文中方法的分割结果与其更加接近。这表明通过引入自注意力机制和多尺度策略能够有效提升网络对目标的分割精度。

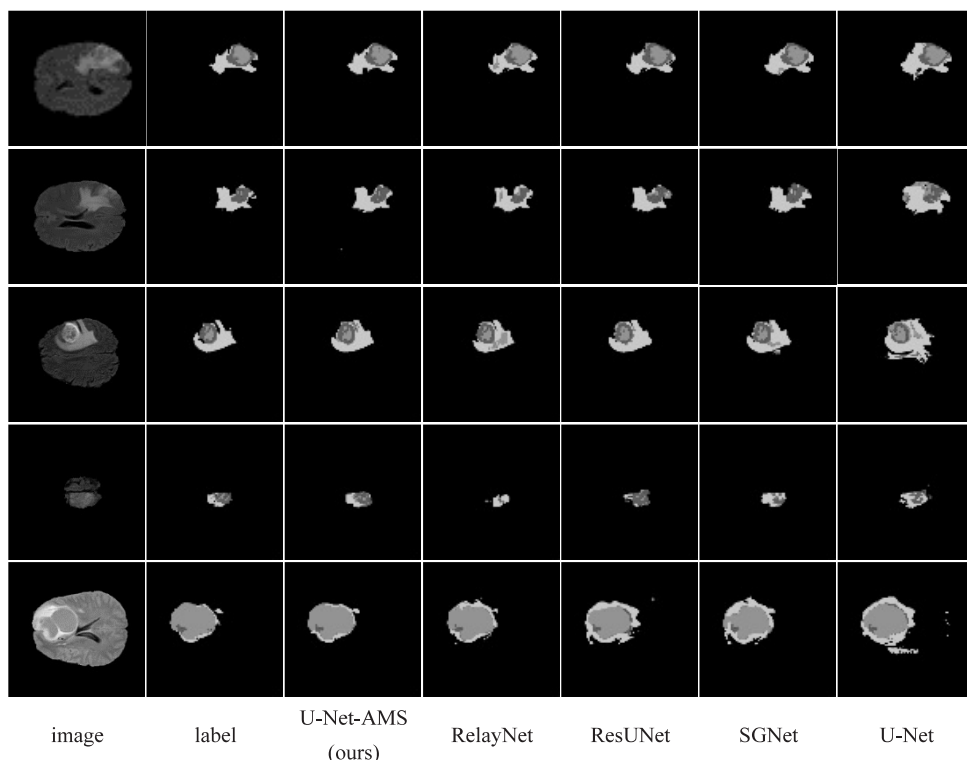


图 5 不同模型的脑肿瘤分割结果

型对计算资源的需求还有待研究。

4 结束语

针对医学影像分割特点和脑肿瘤分割不精准的问题,提出了一种融合自注意力机制和多尺度策略的方法,确保分割目标的边界信息最大程度地保留。在 BRATS2017 数据集上通过实验证实,该方法可以更大程度地提高神经网络模型对目标的分割精度。在今后的工作中,进一步提高网络分割性能,同时减少网络模

参考文献:

- [1] 苑金辉,乔 艳,费烨琳,等. 基于深度迁移学习的心脏 MRI 图像左心室分割[J]. 计算机技术与发展,2021,31(6):35-39.
- [2] 史健婷,崔闫靖,常 亮. 基于优化 U-Net 网络的乳腺肿瘤区域分割方法[J]. 计算机技术与发展,2021,31(8):156-161.

- [3] 龚 安,赵 莉,姚鑫杰. 基于改进的 U-Net 网络模型的气胸分割算法[J]. 计算机技术与发展,2021,31(10):173-178.
- [4] 赵晓梅,刘兆邦,张正平,等. 基于超像素和密度聚类算法的皮肤镜图像分割[J]. 计算机技术与发展,2020,30(6):167-171.
- [5] 高海军,曾祥银,潘大志,等. 基于 U-Net 改进模型的直肠癌肿瘤分割方法[J]. 计算机应用,2020,40(8):2392-2397.
- [6] KOLLIGS F T. Diagnostics and epidemiology of colorectal cancer[J]. Visceral Medicine,2016,32(3):158-164.
- [7] SIEGEL R L, MILLER K D, SAUER A G, et al. Colorectal cancer statistics,2020[J]. CA: A Cancer Journal for Clinicians,2020,70(3):145-164.
- [8] ANDERSON P, HE X, BUEHLER C, et al. Bottom-up and top-down attention for image captioning and visual question answering[C]//Computer vision and pattern recognition (CVPR). Salt Lake City:IEEE,2018:6077-6086.
- [9] ZHANG Y, LI K. Image super-resolution using very deep residual channel attention networks[C]//European conference on computer vision (ECCV). Munich:Springer,2018:294-310.
- [10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Advances in neural information processing systems. Long Beach:Curran Associates, Inc,2017:6000-6010.
- [11] 王文冠,沈建冰,贾云得. 视觉注意力检测综述[J]. 软件学报,2019,30(2):416-439.
- [12] FU J, LIU J, TIAN H, et al. Dual attention network for scene segmentation[C]//Computer vision and pattern recognition (CVPR). Long Beach:IEEE,2019:3141-3149.
- [13] HUANG Z, WANG X, HUANG L, et al. Ccnet: criss-cross attention for semantic segmentation[C]//International conference on computer vision. Seoul:IEEE,2019:603-612.
- [14] HUANG L, YUAN Y, GUO J, et al. Interlaced sparse self-attention for semantic segmentation[J]. arXiv:1907.12273, 2019.
- [15] XIAO T, XU Y, YANG K, et al. The application of two-level attention models in deep convolutional neural network for fine-grained image classification[C]//Computer vision and pattern recognition (CVPR). Boston:IEEE,2015:842-850.
- [16] HU J, SHEN L, ALBANIE S, et al. Squeeze-and-excitation networks[C]//Computer vision and pattern recognition (CVPR). Salt Lake City:IEEE,2018:7132-7141.
- [17] WANG F, JIANG M, CHEN Q, et al. Residual attention network for image classification[C]//Computer vision and pattern recognition (CVPR). Honolulu: IEEE, 2017: 6450 - 6458.
- [18] CHOE J, SHIM H. Attention-based dropout layer for weakly supervised object localization[C]//Computer vision and pattern recognition (CVPR). Long Beach:IEEE,2019:4256-4271.
- [19] 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. Munich:Springer,2015:234-241.
- [20] ABHIJIT G R, SAILESH C, SRI P K K, et al. ReLayNet: retinal layer and fluid segmentation of macular optical coherence tomography using fully convolutional networks[J]. Biomedical Optics Express,2017,8(8):3627-3642.
- [21] LI Y. Scale-aware trident networks for object detection[C]//International conference on computer vision. Seoul:IEEE,2019:6053-6062.
- [22] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Computer vision and pattern recognition (CVPR). Boston:IEEE,2015:3431-3440.
- [23] GHIASI G, LIN T Y, LE Q V. Nas-fpn: learning scalable feature pyramid architecture for object detection[C]//Computer vision and pattern recognition (CVPR). Long Beach:IEEE,2019.
- [24] CHEN L C, PAPANDREOU G, KOKKINOS I, et al. DeepLab: semantic image segmentation with deep convolutional nets, atrous convolution, and fully connected crfs[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017,40(4):834-848.
- [25] LIU J J. A simple pooling-based design for real-time salient object detection[C]//Computer vision and pattern recognition (CVPR). Long Beach:IEEE,2019:3912-3921.
- [26] MA X, JI Z, NIU S, et al. MS-CAM: multi-scale class activation maps for weakly-supervised segmentation of geographic atrophy lesions in SD-OCT images[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(12):3443-3455.
- [27] MENZE B H. The multimodal brain tumor image segmentation benchmark (BRATS)[J]. IEEE Transactions on Medical Imaging,2015,34(10):1993-2024.
- [28] DIAKOIANNIS F, WALDNER F, CACCETTA P, et al. Resunet-a: a deep learning framework for semantic segmentation of remotely sensed data[J]. ISPRS Journal of Photogrammetry and Remote Sensing,2020,162:94-114.
- [29] LIU X, CAO Jun, FU Tianyu, et al. Semi-supervised automatic segmentation of layer and fluid region in retinal optical coherence tomography images using adversarial learning[J]. IEEE Access,2019,7:3046-3061.