

DOI:10.3969/j.issn.1005-202X.2023.01.008

医学影像物理

结合上下文和注意力机制改进的视盘分割模型

王振华, 刘阳星, 赵晓雨, 张书台
上海海洋大学信息学院, 上海 201306

【摘要】青光眼为多发性眼底疾病,是致盲的主要原因之一。眼底图像来源广,质量参差不齐,且视盘区域具有多尺度性特征,融合上下文信息有利于准确分割多尺度视盘边界。以U-Net为基础,结合上下文信息和卷积注意力模块(CBAM),提出了一种改进的视盘分割模型,包括:(1)使用实例-批处理归一化(IBN)模块与注意力机制改进主干网络ResNet34,提升分割模型的泛化性和图像通道特征的提取能力;(2)提出一种多层次上下文信息提取(MCE)模块处理主干网络输出的特征,融合上下文信息增强分割模型对视盘边缘特征的提取能力;(3)使用Transformer机制替换U-Net中的跳跃连接和上采样,进一步提高视盘多尺度特征和图像通道特征的提取能力。将改进的分割模型与U-Net、U-Net++、DeeplabV3+、FCN和PSPNet分割模型进行视盘分割精度比较,结果表明提出的分割模型具有更好的分割效果,Dice、MIoU、MPA和FPS指标分别为98.18%、96.45%、98.11%和17.56 Img/s。该研究成果可为青光眼的早期诊断提供技术支持。

【关键词】视盘分割;青光眼;上下文信息;注意力机制;Transformer

【中图分类号】R318;TP391.41

【文献标志码】A

【文章编号】1005-202X(2023)01-0047-07

Optic disc segmentation model improved by contextual information and attention mechanism

WANG Zhenhua, LIU Yangxing, ZHAO Xiaoyu, ZHANG Shutai
School of Information, Shanghai Ocean University, Shanghai 201306, China

Abstract: Glaucoma which is one of the main causes of blindness is a multiple fundus disease. Considering that fundus images come from a wide range of sources and vary in quality, and that the optic disc region has multi-scale nature, contextual information is beneficial to accurately segmenting the multi-scale optic disc. Based on U-Net, an improved optic disc segmentation model is proposed by combining contextual information and convolutional block attention module (CBAM). The backbone network (ResNet34) is improved by attention mechanism and instance-batch normalization module for enhancing the generalization of segmentation model and the ability to extract image channel features. A multi-level context extraction (MCE) module is proposed for processing the features output from the backbone network and enhancing the ability of the segmentation model to extract the edge features the optic disc. The extraction of the multi-scale features of the optic disc and image channel features is further improved by replacing skip connections and up-sampling with Transformer mechanism. The optic disc segmentation performance of the proposed model is compared with different segmentation models, such as U-Net, U-Net++, DeeplabV3+, FCN and PSPNet. The results show that the proposed segmentation model has better optic disc segmentation results, and achieves Dice, MIoU, MPA and FPS of 98.18%, 96.45%, 98.11% and 17.56 Img/s respectively. The study can provide technical support for the early diagnosis of glaucoma.

Keywords: optic disc segmentation; glaucoma; contextual information; attention mechanism; Transformer

前言

【收稿日期】2022-07-10

【基金项目】国家自然科学基金(41501419);上海市科委地方能力建设项目(19050502100)

【作者简介】王振华,博士,副教授,研究方向:大数据的处理及应用,
E-mail: zh-wang@shou.edu.cn

【通信作者】张书台,博士,讲师,研究方向:图像处理,E-mail: stzhang@shou.edu.cn

青光眼作为一种常见的慢性眼部疾病,对视力损伤具有不可逆性^[1]。青光眼早期并不伴随明显的症状且视力无明显下降,很多患者察觉症状再就医时已处于晚期。因此,青光眼的早期筛查与诊断对疾病预防与患者视力保护具有重要意义^[2]。将人工智能技术应用于青光眼筛查能够缓解医生短缺与临床影像数据量大之间的矛盾,且能缓解医疗资源空间分布不均等问题,对于早诊断早治疗有较大的辅助作用。视盘即视网膜眼底图像中视神经乳头。视

杯是位于视盘区域中的光亮区域,视神经细胞逐步死亡会伴随着中心视杯区域扩大,表现出不断扩大的视杯盘比(Cup to Disc Ratio, CDR)。CDR值是青光眼诊断的重要评价指标,准确地获取CDR值对眼底图像中视杯、盘区域准确分割和青光眼诊断具有重要影响。其中,视盘分割是视杯分割的关键步骤^[3]。

用于视盘分割的方法包括水平集分割方法、主动轮廓模型、以及基于聚类的分割方法等。例如Liu等^[4]提出一种变分水平集,利用颜色强度和阈值水平集两种方法分割视盘区域。Osareh等^[5]提出采用颜色空间实现视盘定位的方法,该算法通过灰度形态学定位视盘区域,然后进行拟合。Blanco等^[6]先通过聚类算法对视盘区域进行定位,然后通过使用模糊原型霍夫变换处理边缘信息来分割视盘。Tan等^[7]采用基于超像素的分类方法进行视杯定位。近年来,深度学习技术迅猛发展并广泛应用于医学图像的分割和识别。全卷积神经网络(Fully Convolutional Networks, FCN)^[8],以及在FCN基础上改进的U-Net^[9],已成为医学影像分割的基石。Sevastopolsky^[10]将U-Net模型应用于青光眼视杯、盘的分割。He等^[11]和Yu等^[12]提出了融合残差结构的U-Net视杯视盘分割模型,引入预训练好的ResNet34模型作为U-Net编码器,提高模型特征提取的能力和分割精度。Fu等^[13]设计M-Net(Multi-label Deep Network)实现视盘和视杯的联合分割。Pan等^[14]提出了IBN-Net,能够在不增加计算量的情况下,提升分割模型域适应能力。Woo等^[15]设计一种轻量注意力模块,可以加入到残差网络中,提高模型特征提取能力。Gu等^[16]提出了CENet,设计了上下文提取器(Context Extraction, CE)来生成更多高级语义特征,在医学影像分割上取

得较好效果。Wang等^[17]从通道角度重新思考U-Net中跳跃连接,引入Transformer机制,提升了分割效果。上述方法实现了眼底图像中视盘区域的自动化分割,但眼底图像来源多样、质量差异大,U-Net模型融合上下文信息能力较差,对视盘边缘信息不敏感,青光眼视盘区域具有多尺度的特点,青光眼图像不同通道的特征差异大。面向多源、异质的眼底图像,如何提升分割模型的泛化性,增强模型对上下文信息的提取能力,提高青光眼视盘的分割精度仍是待解决的问题。

针对以上问题,本文提出了一种改进的视盘分割模型,具体包括:(1)使用卷积注意力模块(Convolutional Block Attention Module, CBAM)与实例-批处理归一化(Instance-batch Normalization, IBN)模块改进ResNet34,提高模型对通道特征的提取能力和模型的泛化性;(2)提出多层次上下文提取(Multi-level Context Extraction, MCE)模块,减少参数量同时多层次融合图像上下文信息,提升模型对视盘边缘信息处理的能力;(3)使用Transformer架构中多尺度通道交叉融合(Channel-wise Cross fusion Transformer, CCT)模块融合下采样阶段特征图替换跳跃连接,多尺度通道交叉注意力(Channel-wise Cross-attention, CCA)模块引导CCT输出特征图与上采样特征图融合替换简单插值上采样方式,增强模型对多尺度上下文特征和通道特征的提取能力。

1 改进的视盘分割模型

视盘分割是将彩色眼底图像中的像素点分成视盘和背景。图1所示为本文改进的视盘分割模型架构图。




图1 改进的视盘分割模型

Figure 1 Improved optic disc segmentation model

1.1 使用CBAM与IBN模块改进ResNet34网络

本文利用CBAM与IBN模块改进U-Net的主干网络ResNet34。CBAM将通道和空间注意力相结合并嵌入到残差网络结构中,可提升分割模型对空间和通道上特征信息的提取能力;IBN模块是实例归一化(Instance Normalization, IN)和批处理归一化(Batch Normalization, BN)的组合,通过使用IBN模

块替换ResNet34网络中的BN层,可增强分割模型的泛化性。

1.1.1 CBAM CBAM包含通道注意力(Channel Attention, CA)模块与空间注意力(Spatial Attention Module, SA)模块。图2所示为基于CBAM的图像处理流程图,输入的特征图先后经过通道注意力模块、空间注意力模块和残差块,输出处理后的特征图。




图2 基于CBAM的图像处理流程

Figure 2 Image processing flow based on CBAM

1.1.2 IBN 模块 图3所示为BN层与IBN模块对比图。本文利用IBN模块替换原残差块中的BN层。IBN模块由IN和BN组合得到,其中,IN可不受通道维度和批处理大小影响,对图像像素的高或宽维度做归一化,提升分割模型的泛化性。

1.2 多层次上下文信息提取模块提升模型的上下文信息融合能力

深层特征具有丰富的语义信息,但其分辨率不

高;浅层特征具有较高的分辨率,但语义信息匮乏。在不降低分辨率的前提下,空洞卷积能够扩大模型感受野,通过组合不同空洞率的空洞卷积可捕获多尺度上下文信息,但其会带来参数量的增加。

本文提出一种上下文信息处理模块即MCE模块,用于处理改进的ResNet34网络输出的特征图。如图4所示,该MCE模块对特征图的整体处理流程分为3个阶段:(1)将编码器后3层输出特征图作为MCE模块的输入,分别进行卷积后再上采样融合至原图1/8分辨率大小,该阶段可保证输出分辨率较高且语义信息丰富的特征图;(2)通过组合使用不同步长的深度可分离卷积实现捕获多尺度上下文信息的同时降低参数量。该模块使用4个不同步长(1、2、4、8)的深度分离卷积,分别对上采样后的特征图并行提取特征;(3)将拼接后的特征图输入至残留的多核池化(RMP)模块,RMP结构采用4个不同大小的接收场对多尺度特征进行编码,接收场大小分别为2×2、3×3、5×5和6×6。4个分支输出包含多种尺寸的特征图。为了进一步减少模型计算量和权重维数,在每个池化分支后使用1×1卷积进行降维。




图3 BN层与IBN模块对比

Figure 3 Comparison between BN and IBN modules




图4 MCE 模块结构图

Figure 4 MCE module structure

1.3 使用 Transformer 机制增强模型的多尺度特征提取能力

使用 Transformer 机制替换 U-Net 中跳跃连接与简单插值的上采样方式,提升分割模型对多尺度特征提取的能力,增强青光眼图像的通道特征信息提取。图 5 为 Transformer 架构图,包括 CCT 和 CCA 两个模块。CCT 模块利用 Transformer 的长依赖建模优势融合编码器输出的多尺度特征,包括:(1)多尺度特征嵌入。给定跳跃连接层的输出,对特征图进行 Token 化再转换为 patch 序列,最后映射到特征图相应区域。(2)多通道交叉注意力。将 Token 输入到多头通道交叉注意力结构,进行通道特征提取。(3)多层感知机制(MLP)。利用多尺度特征对通道关系和依赖项进行编码,实现对每个下采样级别特征图的细化。CCA 模块改变简单插值的上采样过程,引导 CCT 输出特征图与上采样特征图进行融合后再向上输出,包括:(1)特征图输入。将第 i 级 CCT 输出特征图 O_i 和第 i 级解码器特征图映射 D_i 作为输入特征图。(2)空间压缩与 Mask 生成。利用全局平均池化(GAP)压缩 O_i 与 D_i ,通过产生特征向量来嵌入全局空间信息并生成注意力 Mask。(3)特征图拼接。将 Mask 的 O_i 与第 i 级解码器上采样特征图拼接并输出。使用 Transformer 机制从通道角度对眼底图像进行特征图融合,可加强分割模型对彩色眼底图像在通道信息上的特征提取能力,形成的连接,即下采样特征图,经 CCT 模块处理,再输出到 CCA 模块与上采样特征图拼接。




图5 Transformer 结构图

Figure 5 Transformer structure

集,其中训练集 805 张,验证集和测试集各 100 张。

4 个公开数据集分别是 DRISHTI-GS1, i Challenge-PM, RIGA 和 RIM-ONE。DRISHTI-GS1 数据集,包括 101 张彩色视网膜眼底图像,由 4 位专家标注^[18]; i Challenge-PM 挑战赛数据集包含 1 200 张彩色眼底图像,训练集、验证集、测试集各 400 张。数据先由中山大学中山眼科中心的 7 位专家标注,再由另外 1 位专家合并为单一标注^[19]; RIGA 数据集中选取了 Bin Rushed 眼科中心的 195 张眼底图像,由 6 个专家进行标注^[20]; RIM-ONE 数据集选取了 RIM-ONE-R1 数据集中的 169 张彩色眼底图像,由 5 个专家进行了标注,选取了 RIM-ONE-R3 数据集中的 159 张彩色眼底图像,其由 2 个专家进行了标注^[21]。

模型训练的参数设置如下:将输入图像送入模型前统一尺寸为 224×224 ,使用 Adam 优化器,初始学习率为 0.000 1, Batchsize 训练阶段为 2,测试阶段为 1,训练 100 epoch 损失函数达到收敛。对于训练的模型,以计算出的损失值最小的权重文件作为后面预测时的权重参数,在划分出来的测试集上进行独立测试,评估视盘分割的精度。

2 实验

2.1 数据集与参数

本文设计了消融实验与对比实验,实验数据选取了 4 个公开数据集共 1 005 张彩色眼底图像。将数据集按照 8:1:1 的比例划分为训练集、验证集、测试

2.2 实验环境

视盘分割模型的训练与测试均在 Windows10 操作系统下的 Visual Studio Code 平台上完成, 使用 PyTorch 1.7 深度学习框架。计算机的配置为 16 G 内存的 Intel(R) Core(TM) i7-9700 CPU 处理器, 6 GB 显存的 NVIDIA GeForce RTX 2060 显卡。

2.3 评价指标

采用 4 个评价指标, 对改进的视盘分割模型与其它分割模型进行性能比较, 包括 Dice 系数、平均交并比 (MIoU)、平均像素精度 (MPA) 和每秒传输帧数 (FPS)^[22-23]。

$$\text{Dice} = \frac{2TP}{FP + 2TP + FN} \quad (1)$$

$$\text{MIoU} = \frac{\sum \text{IoU}_i}{\text{Num}} \quad (2)$$

$$\text{MPA} = \frac{\sum \text{PA}_i}{\text{Num}} \quad (3)$$

$$\text{FPS} = \frac{1}{t} \quad (4)$$

其中:

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

$$\text{PA} = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

其中, TP 表示分类正确的视盘像素数, TN 表示分类正确的背景像素数, FP 表示背景像素被分为视盘像素的数量, FN 表示视盘像素被分为背景像素的数量, Num 表示分类类别数。

Dice 系数是一种集合相似度度量指标, 用于计算两个样本的相似度, Dice 系数的范围为 0~1, 分割结果最好时值为 1, 最差时为 0; 交并比 (IoU) 表示预测结果和真实结果的重合度; PA 是指像素精度, 表示标记正确的像素占总像素的比例; MIoU 表示所有类别的预测结果与真实结果的平均重合度; MPA 表示所有类别的平均像素精度; FPS 表示每秒可处理的图片数, t 表示处理图片所需的时间。

2.4 实验结果对比与分析

2.4.1 消融实验 本文提出的分割模型主要改进了 4 个模块: CBAM、IBN 模块、MCE 模块、Transformer 模块, 将各模块改进对视盘分割模型的影响进行了评估, 表 1 给出了不同模块改进模型的分割效率比较, 表 2 比较了 CENet 中上下文提取模块 (CE) 与本文提出的 MCE 模块的性能。

由消融实验结果表 1 可看出: 利用 CBAM 改进的 U-Net 模型, 明显提高了分割结果的 MIoU; 融合 CBAM 和 IBN 模块改进后的分割模型, 以及使用 CBAM、IBN、MCE 模块改进后的分割模型, 分割结果各性能指标均有提升; 而本文提出的分割模型即融合了所有模块的架构, 各项性能指标更高, 其 Dice、MIoU、MPA 和 FPS 分别提高 3.85%、10.14%、4.01% 和 8.93%。由表 2 得出 MCE 模块相较于 CE 模块, 性能更优, FPS 大幅上升, 提高了 1.78 倍, 参数量大幅下降, 下降了 59.3%。综上实验结果表明, 本文提出的分割模型提高了青光眼视盘的分割精度。

表 1 消融实验

Table 1 Ablation experiment

模型 1	CBAM	IBN	MCE	Transformer	Dice/%	MIoU/%	MPA/%	FPS/Img·s ⁻¹
U-Net	-	-	-	-	94.54	87.57	94.32	16.12
U-Net+CBAM	√	-	-	-	95.51	93.43	96.12	14.89
U-Net+CBAM+IBN	√	√	-	-	96.43	94.81	97.27	13.51
U-Net+CBAM+IBN+MCE	√	√	√	-	97.12	95.81	97.85	13.48
本文模型	√	√	√	√	98.18	96.45	98.11	17.56

√代表模型中包含的模块, -代表未包含

2.4.2 对比实验 将本文提出的视盘分割模型与 U-Net、U-Net++^[24]、DeeplabV3+^[25]、FCN 和 PSPNet^[26] 进行比较, 不同分割模型的青光眼视盘分割结果如图 6 所示, 不同分割模型的青光眼视盘分割结果性能比较如表 3 所示。由图 6 和表 3 可以看出, 本文提出的视盘分割模型降低了 FCN、U-Net 和 DeeplabV3+ 等分割模型的误分割与欠分割现象, 优化了 DeeplabV3+、

PSPNet 和 U-Net++ 等分割模型的边界不平滑问题。且本文提出的视盘分割模型分割精度更高, 其 Dice、MIoU、MPA 和 FPS 分别为 98.18%、96.45%、98.11% 和 17.56 Img/s。综上所述, 本文提出的视盘分割模型与现有的分割模型相比, 具有更高的视盘分割精度。

2.4.3 模型泛化性验证实验 模型泛化能力指模型对新鲜样本的适应能力^[27]。为验证本文提出模型的泛

表2 CE与MCE模块比较

Table 2 Performance comparison between CE and MCE modules

模块	Dice/%	MIoU/%	MPA/%	FPS/Img·s ⁻¹	模型参数大小/MB
CE	97.72	95.55	97.34	9.84	1 280
MCE	98.18	96.45	98.11	17.56	520

化性,在已经使用的4个数据集基础上增加CHASEDB1和ORIGA-650数据集^[28-29],利用训练好的模型对每个数据集进行测试,不同模型的泛化性如图7所示。由图7可以看出,在6个测试数据集上,本文提出的分割模型具有更高的Dice、MIoU和MPA分值,其具有更稳定和优异的分割性能。




图6 不同分割模型的视盘分割结果

Figure 6 Optic disc segmentation results of different segmentation methods

表3 不同分割模型性能对比

Table 3 Performance comparison among different methods

模型	Dice/%	MIoU/%	MPA/%	FPS/Img·s ⁻¹
U-Net	93.33	83.26	88.13	9.67
U-Net++	97.12	95.81	97.85	9.77
DeeplabV3+	93.44	92.20	95.11	13.61
FCN	81.22	74.21	94.32	6.72
PSPNet	96.71	93.49	96.03	14.21
本文模型	98.18	96.45	98.11	17.56

3 结束语

青光眼作为一种常见的慢性眼部疾病,其早期筛查与诊断对疾病预防与患者视力保护具有重要意义。将人工智能技术应用于青光眼筛查对其早诊断早治疗有较大的辅助作用。对于多源、异质的眼底图像,传统模型对视盘边缘特征提取能力差,青光眼视盘区域存在多尺度性特征且不同通道图像特征差

异大,本文基于U-Net模型提出了一种结合上下文信息和注意力机制的视盘分割模型:在ResNet34主干网络加入IBN与CBAM模块,解决模型泛化性差与通道特征提取的问题;提出MCE模块处理主干网络输出的后3层特征图,该模块在减少参数数量的同时融合了多层次图像上下文信息,增强了模型对视盘边缘特征提取能力;跳跃连接与上采样过程使用Transformer机制,提升模型对多尺度上下文特征提取能力同时增强对通道特征提取能力,最终实现提高视盘分割精度的效果。

通过消融实验以及对比实验,表明本文提出的视盘分割模型具有更高的分割精度和推理速度,其Dice、MIoU、MPA和FPS分别为98.18%、96.45%、98.11%和17.56 Img/s。模型泛化性实验证明本文提出的模型在3个评价指标上表现优异且稳定。以上实验结果表明本文算法综合指标相比其他算法具有一定优势,提升了视盘分割的效果,有助于进一步提高青光眼计算机辅助诊断效率。




图7 模型泛化性验证结果

Figure 7 Model generalization verification results

【参考文献】

- [1] Mary VS, Rajsingh EB, Naik GR. Retinal fundus image analysis for diagnosis of glaucoma: a comprehensive survey[J]. IEEE Access, 2016, 4: 4327-4354.
- [2] Almazroa A, Burman R, Raahemifar K, et al. Optic disc and optic cup segmentation methodologies for glaucoma image detection: a survey [J]. J Ophthalmol, 2015: 1-28. Doi: 10.1155/2015/180972.
- [3] Hagiwara Y, Koh JE, Tan JH, et al. Computer-aided diagnosis of glaucoma using fundus images: a review [J]. Comput Methods Programs Biomed, 2018, 165: 1-12.
- [4] Liu J, Wong DW, Lim JH, et al. Optic cup and disk extraction from retinal fundus images for determination of cup-to-disc ratio[C]//2008 3rd IEEE Conference on Industrial Electronics and Applications. IEEE, 2008: 1828-1832.
- [5] Osareh A, Mirmehdi M, Thomas B, et al. Comparison of colour spaces for optic disc localisation in retinal images[C]// 2002 International Conference on Pattern Recognition. IEEE, 2002: 743-746.
- [6] Blanco M, Penedo MG, Barreira N, et al. Localization and extraction of the optic disc using the fuzzy circular hough transform [C]// International Conference on Artificial Intelligence and Soft Computing. Springer, Berlin, Heidelberg, 2006: 712-721.
- [7] Tan NM, Xu Y, Liu J, et al. Multi-scale superpixel classification for optic cup localization [C]//2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI). IEEE, 2014: 137-140.
- [8] Long J, Shelhamer E, Darrell T. Fully convolutional networks for semantic segmentation[C]//Proceedings of The IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2015: 3431-3440.
- [9] 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. Springer, Cham, 2015: 234-241.
- [10] Sevastopolsky A. Optic disc and cup segmentation methods for glaucoma detection with modification of U-Net convolutional neural network[J]. Pattern Recognition and Image Analysis, 2017, 27(3): 618-624.
- [11] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2016: 770-778.
- [12] Yu S, Xiao D, Frost S, et al. Robust optic disc and cup segmentation with deep learning for glaucoma detection[J]. Comput Med Imaging Graph, 2019, 74: 61-71.
- [13] Fu HZ, Cheng J, Xu YW, et al. Joint optic disc and cup segmentation based on multi-label deep network and polar transformation[J]. IEEE Trans Med Imaging, 2018, 37(7): 1597-1605.
- [14] Pan X, Luo P, Shi J, et al. Two at once: enhancing learning and generalization capacities via IBN-Net [C]//Proceedings of the European Conference on Computer Vision (ECCV). Springer, 2018: 464-479.
- [15] Woo S, Park J, Lee JY, et al. CBAM: convolutional block attention module[C]//Proceedings of the European Conference on Computer Vision (ECCV). Springer, 2018: 3-19.
- [16] Gu Z, Cheng J, Fu H, et al. CE-Net: context encoder network for 2D medical image segmentation[J]. IEEE Trans Med Imaging, 2019, 38 (10): 2281-2292.
- [17] Wang H, Cao P, Wang J, et al. UCTransNet: rethinking the skip connections in U-Net from a channel-wise perspective with transformer [J]. arXiv preprint arXiv: 2109.04335, 2021.
- [18] Sivaswamy J, Krishnadas SR, Joshi GD, et al. Drishti-GS: retinal image dataset for optic nerve head (ONH) segmentation [C]//2014 IEEE 11th International Symposium on Biomedical Imaging (ISBI). IEEE, 2014: 53-56.
- [19] Fu HZ, Li F, Orlando J, et al. PALM: PAtHoLogic myopia challenge[J/OL]. IEEE Dataport, (2019-07-08)[2022-05-03]. <https://dx.doi.org/10.21227/55pk-8z03>.
- [20] Almazroa A, Alodhayb S, Osman E, et al. Agreement among ophthalmologists in marking the optic disc and optic cup in fundus images[J]. Int Ophthalmol, 2017, 37(3): 701-717.
- [21] Fumero F, Alayon S, Sanchez JL, et al. RIM-ONE: an open retinal image database for optic nerve evaluation [C]//2011 24th International Symposium on Computer-based Medical Systems (CBMS). IEEE, 2011: 1-6.
- [22] Milletari F, Navab N, Ahmadi SA. V-Net: fully convolutional neural networks for volumetric medical image segmentation [C]//2016 Fourth International Conference on 3D Vision (3DV). IEEE, 2016: 565-571.
- [23] 田莹, 王亮, 丁琪. 基于深度学习的图像语义分割方法综述[J]. 软件学报, 2019, 30(2): 440-468.
- [24] Tian X, Wang L, Ding Q. Review of image semantic segmentation based on deep learning[J]. Journal of Software, 2019, 30(2): 440-468.
- [25] Zhou Z, Siddiquee MM, Tajbakhsh N, et al. UNet++: redesigning skip connections to exploit multiscale features in image segmentation[J]. IEEE Trans Med Imaging, 2019, 39(6): 1856-1867.
- [26] Chen LC, Zhu Y, Papandreou G, et al. Encoder-decoder with atrous separable convolution for semantic image segmentation [C]// Proceedings of the European Conference on Computer Vision (ECCV). Springer, 2018: 801-818.
- [27] Zhao H, Shi J, Qi X, et al. Pyramid scene parsing network [C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. IEEE, 2017: 2881-2890.
- [28] Fu J, Liu P, Zhang Q. Rethinking generalization of neural models: A named entity recognition case study [C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(5): 7732-7739.
- [29] Zhang J, Dashtbozorg B, Bekkers E, et al. Robust retinal vessel segmentation via locally adaptive derivative frames in orientation scores[J]. IEEE trans Med Imaging, 2016, 35(12): 2631-2644.
- [30] Cheng J, Zhang Z, Tao D, et al. Similarity regularized sparse group lasso for cup to disc ratio computation[J]. Biomed Opt Express, 2017, 8(8): 3763-3777.

(编辑:薛泽玲)