

文章编号: 2095-2163(2022)07-0151-06

中图分类号: TP391

文献标志码: A

基于改进 U-Net 的视网膜血管分割

王师玮, 陈俊, 易才健

(福州大学 物理与信息工程学院, 福州 350108)

摘要: 针对传统算法在眼底视网膜血管分割过程中存在特征提取困难、细节区域分割不精确的问题, 本文在 U-Net 网络的基础上进行改进, 提出了一种能更好进行血管分割的算法 CSD-U-Net。首先, 在编码和解码阶段使用了卷积注意力模块, 通过引入注意力机制对血管的细微结构进行通道和空间增强; 其次, 采用了 SoftPool 的池化方法, 保证在下采样阶段保留更多原始信息, 增加感受野; 最后, 选择密集上采样卷积作为本算法的上采样方法, 产生像素级预测且捕获更多细节信息。在公开数据集 DRIVE、CHASE_DB1 上验证该算法, 结果表明, 该算法较现有的先进算法在分割效果上有一定的提升。

关键词: 视网膜血管分割; U-Net; 卷积注意力模块

Retinal vessel segmentation method based on improved U-Net

WANG Shiwei, CHEN Jun, YI Caijian

(College of Physics and Information Engineering, Fuzhou University, Fuzhou 350108, China)

[Abstract] In view of the difficulties in feature extraction and inaccurate segmentation of detail regions in the traditional algorithm for fundus retinal vessel segmentation, a new algorithm CSD-U-Net is proposed, which is improved on the basic U-Net. This new algorithm can segment blood vessels better. First, convolution attention module is used in the encoding and decoding stage to enhance the subtle structure of the blood vessel by introducing the channel and spatial attention mechanism. Secondly, the SoftPool method is adopted to ensure that more original information is preserved and the receptive field is increased in the down-sampling stage. Then, the dense upsampling convolution is selected as the up-sampling method to generate a pixel-level prediction and capture more detailed information. The proposed algorithm is verified on the open data set DRIVE, CHASE_DB1. The experimental results show that the proposed algorithm is superior to the existing advanced algorithms in segmentation effect.

[Key words] retinal vessel segmentation; U-Net; convolutional block attention module

0 引言

据统计报告, 中国是世界上盲人最多的国家之一, 约有 1 200 万盲人, 占全世界盲人的 18%^[1]。失明的主要原因之一就是眼底视网膜血管病变, 在众多致盲疾病的案例中, 有许多病例是可以通过视网膜检查来进行防治的。以糖尿病视网膜病变为例, 中国有近 1 亿糖尿病患者, 在已知病史的糖尿病患者中视网膜病变的患病率 65.2%, 糖尿病患者眼底 3~5 年发病率为 38.1%, 5~15 年发病率为 39.58%, 15 年以上发病率为 50%^[2]。如果患者能够在确诊为糖尿病后及时做眼底检查, 记录自己的眼底视网膜影像并按期复查, 就能在病变一出现苗头时及时治疗, 这将大大降低后期出现视力损伤、致盲的概率。因此, 建立眼科影像档案来进行视网膜病变的早期筛查工作就变得十分重要。

眼底视网膜血管是全身血管系统中唯一可以直

接无创观测到的部分, 其自身变化, 例如: 血管长度、宽度、弯曲度、分叉模式等结构特性的变化, 均可作为诊断与血管相关疾病的依据^[3]。许多眼部疾病的病变情况可以在视网膜血管上观察到, 例如: 青光眼、糖尿病视网膜病变、老年性黄斑病变等^[4]。通过对视网膜血管的结构特性进行专业分析, 就可以观察到这些眼底疾病病变的具体临床表现, 这为后续的诊断和治疗有着重要意义。视网膜血管分割是获取这些结构特性的重要步骤, 良好的分割结果将使后续的检测分析更准确。由于眼底存在许多微小的毛细血管, 视网膜血管结构又相对复杂、不规律, 采用人工分割视网膜血管图像的方式将会十分繁琐, 因此研究出一种高效、精确的视网膜血管自动分割算法是非常有必要的。

目前, 国内外的众多学者提出了许多优秀的视网膜血管自动分割算法, 根据是否需要标签分为两大类: 无监督算法和有监督算法。

作者简介: 王师玮(1998-), 女, 硕士研究生, 主要研究方向: 计算机视觉; 陈俊(1978-), 男, 硕士, 副教授, 主要研究方向: 物联网通信; 易才健(1998-), 男, 硕士研究生, 主要研究方向: 医学图像处理。

通讯作者: 陈俊 Email: 13960901718@126.com

收稿日期: 2022-01-11

视网膜血管分割算法中的无监督算法主要有：基于形态学处理的方法、基于匹配滤波的方法、基于形变模型的方法等。无监督算法在分割过程中不需要利用专家手工标注的金标准图，主要是根据血管的原始信息来设计算法，此类算法易受数据的个体特征影响而无法广泛应用，且分割精度较难提高。

有监督算法在分割过程中需要依靠专家手工标注的金标准图来训练模型并进行迭代学习，得到最好的模型结果，此类算法在血管分割上通常能够得到比无监督算法更好的效果。近年来，随着基于有监督的深度学习技术的快速发展及其在计算机视觉任务中的良好表现，越来越多的学者将深度学习技术应用于目标分割领域。2014年 Long^[5]等人提出全卷积网络(Fully Convolutional Networks, FCN)，开创性地将网络中的全连接层改成卷积层，从而使整个网络结构中只有卷积层，并将其运用到分割任务中；Ronneberger^[6]等人提出了具有对称性结构的U-Net网络，其中包括了编码-解码过程，使用了跳跃连接方式在上采样阶段将浅层特征进行融合。U-Net特别的网络结构使得其在医学图像分割领域上表现出良好的性能，现有的很多模型也是在传统U-Net的基础上改进的。Zhang Zhengxin^[7]等和Zeng Yuanyi^[8]等分别受到残差连接和密集连接的启发，将U-Net的子模块分别替换为具有残差连接和密集连接的形式，由此设计了Res-UNet和Dense-UNet；Alom^[9]提出了R2U-Net，将残差连接与循环卷积的方法相结合，替换U-net的子模块；Lian^[10]等人在U-Net中引入注意力机制，在特征拼接之前，使用了一个注意力模块，该模块生成一个门控信号，用来控制不同空间位置处特征的重要性；Zongwei Zhou^[11]等人提出的U-Net++网络，可以抓取不同层次的特征并以特征叠加的方式进行融合；CAO Hu^[12]提出了首个基于纯Transformer的U形医学图像分割网络Swin-UNet，也取得了不错的效果。

为了减少在视网膜血管分割过程中的细节丢失问题，提升分割精度，本文设计了一种改进U-Net网络模型结构。经验证，本文算法较现有的先进模型在分割效果上有一定的提升，可为临床医学诊断提供辅助信息。

1 本文方法

针对传统算法在眼底视网膜血管分割过程中的特征提取困难、细节区域分割不精确的问题，本文在

U-Net网络的基础上进行改进，提出了一种能更好进行血管分割的算法CSD-UNet，其整体网络结构如图1所示。该网络在原U-Net的卷积过程中引入卷积注意力模块(Convolutional Block Attention Module, CBAM)，构成一个新的卷积模块CD-Conv，以此来对血管的细微结构进行通道和空间增强；使用SoftPool的池化方法、密集上采样卷积(Dense Upsampling Convolution, DUC)方法，解决结构信息丢失、损耗的问题。CSD-UNet算法能够在不丢失信息的情况下，进一步增加感受野并提高对细微特征的提取能力，进而提高分割准确率。

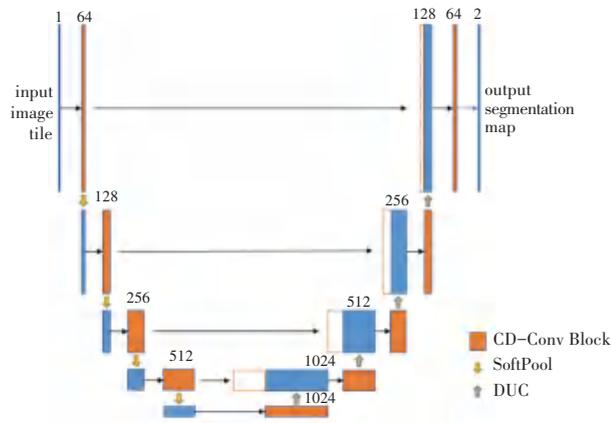


图1 CSD-UNet整体网络结构

Fig. 1 Overall network structure of CSD-UNet

1.1 CD-Conv 模块

CD-Conv 模块是由CBAM模块和双层卷积构成的，其结构如图2所示。在本文的血管分割任务中，考虑引入通道注意力来增强通道间的关联性，解决神经网络中不同通道对特征选择有不同依赖性的问题；考虑引入空间注意力来捕获不同尺度的空间位置信息，突出血管区域特征抑制背景噪声。CBAM模块正是这两者很好的结合，并且其是一个轻量级的通用模块，可以无缝集成于本文的分割网络之中，其结构如图3所示。



图2 CD-Conv 模块结构

Fig. 2 The structure of CD-Conv module

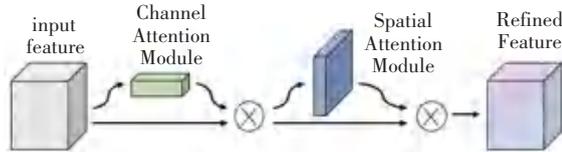


图3 CBAM 模块结构

Fig. 3 The structure of CBAM module

给定一个中间特征映射 $F \in R^{C \times H \times W}$ ，CBAM 模块顺序地沿着通道和空间两个独立的维度进行推

导, 分别得到注意力图 $M_c \in R^{C \times 1 \times 1}$ 、 $M_s \in R^{1 \times H \times W}$, 其中 \otimes 表示按位相乘, F' 是最终的细化输出。完整过程可归纳为式(1) ~ 式(2):

$$F' = M_c(F) \otimes F \quad (1)$$

$$F'' = M_s(F') \otimes F' \quad (2)$$

其中, M_c 是由通道注意力模块获得的, M_s 是由空间注意力模块获得的, 可定义为式(3) ~ 式(4):

$$M_c(F) = \sigma(MLP(AvgPool(F)) + MLP(MaxPool(F))) = \sigma(W_1(W_0(F_{avg}^c)) + W_1(W_0(F_{max}^c))) \quad (3)$$

$$M_s(F) = \sigma(f^{7 \times 7}([AvgPool(F); MaxPool(F)])) = \sigma(f^{7 \times 7}([F_{avg}^s; F_{max}^s])) \quad (4)$$

其中, F_{avg}^c 、 F_{max}^c 和 F_{avg}^s 、 F_{max}^s 是通过平均池化、最大池化操作生成的两个不同的空间上下文描述符。

将两个描述符 F_{avg}^c 、 F_{max}^c 送入一个共享的由多层感知机(MLP)组成的网络中, 生成 1D 通道注意力图 M_c , 其中 MLP 的权重为 $W_0 \in R^{C/r \times C}$ 和 $W_1 \in R^{C \times C/r}$, r 是衰减率, σ 为 sigmoid 函数。将两个描述符 F_{avg}^s 、 F_{max}^s 拼接在一起, 得到一个更高效的特征描述符, 再通过一个卷积层生成 2D 空间注意力图 M_s , $f^{7 \times 7}$ 表示一个卷积核为 7×7 的卷积操作。

CBAM 的通道注意力模块、空间注意力模块的结构如图 4 和图 5 所示。

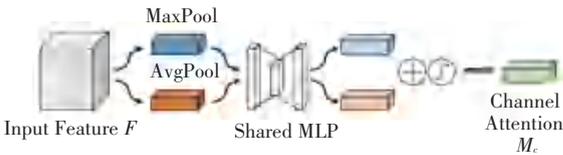


图 4 通道注意力模块结构

Fig. 4 The structure of channel attention module

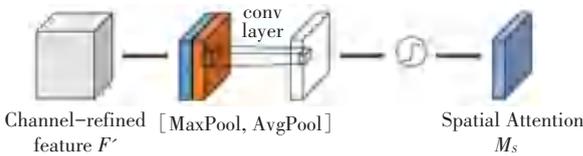


图 5 空间注意力模块结构

Fig. 5 The structure of spatial attention module

1.2 SoftPool

选择 SoftPool 作为本文算法中的池化方法, 在保持池化层功能的同时, 尽可能地减少池化过程中的信息损失, 增加感受野, 提升血管分割的精度。SoftPool 主要是基于 SoftMax 方法加权池化, 定义大小为 $C \times H \times W$ 的特征图 a 的局部区域 R , 根据特征值非线性地计算区域 R 的权重 w_i , 再通过加权区域 R 内的特征值得到输出 \tilde{a} , 其数学公式为式(5) ~ 式(6)。

$$w_i = \frac{e^{a_i}}{\sum_{j \in R} e^{a_j}} \quad (5)$$

$$\tilde{a} = \sum_{i \in R} w_i * a_i \quad (6)$$

SoftPool 能较好地参考特征区域内的激活值分布, 进而服从一定的概率分布, 能够很好地保留视网膜血管的细微特征表达。

1.3 密集上采样卷积

视网膜中存在的许多细微血管结构往往会在训练过程中丢失, 造成视网膜血管分割精度降低。因此, 选择密集上采样卷积作为本算法的上采样方法, 产生密集的像素级预测映射, 且在上采样过程中捕获更多细节信息。其结构如图 6 所示。

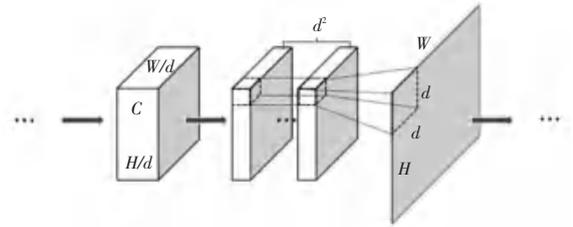


图 6 密集上采样卷积模块结构

Fig. 6 The structure of DUC module

给定输入图片 $H \times W$, 整个网络在预测前的输出特征映射大小为 $h \times w \times c$, 其中: $h = H/d$, $w = W/d$, d 为下采样因子。DUC 方法通过通道维度来弥补长宽尺寸上的损失, 将 $h \times w \times c$ 转为 $h \times w \times (d^2 \times L)$, L 是分割类别的数目, 最后再 reshape 回 $H \times W \times L$ 尺寸。其 DUC 的核心思想就是将整个标签映射划分为与特征映射等尺寸的子部分, 这些子部分被叠加 d^2 次后又会直接得到整个标签映射。

2 实验结果与分析

2.1 实验环境及预处理

CSD-UNet 模型的开发集成环境为 PyCharm, 基于开源的 Pytorch 框架, 运行平台为 Windows 系统, GPU 为 NVIDIA GeForce RTX 2070, 内存为 16 GB。使用 DRIVE 数据集和 CHASE_DB1 数据集来验证本文的算法。

DRIVE 数据集共有 40 张 565×584 彩色眼底图像, 其中 33 张为正常眼底图像, 7 张存在轻度早期糖尿病视网膜病变, 本文从中选择训练集和测试集各 20 张; CHASE_DB1 数据集包括从 14 名学童的双眼中拍摄的 28 张视网膜图像, 每幅图像的大小为 999×960 , 本文从中选择 20 张用于训练, 8 张用于测试。

为了提高模型分割血管的精度, 要先对图像进

行预处理之后再输入网络模型进行训练。预处理方法主要包括以下步骤:

- (1) 提取视网膜图像的 G 通道,并转为灰度图;
 - (2) 归一化处理后再采用自适应直方图均衡化方法 (CLAHE),增强血管与背景对比度的同时不放大噪声;
 - (3) 使用伽马算法对图像进行对比度的均匀增强;
 - (4) 采用随机裁剪的方式进行数据扩充。
- 测试集不进行数据预处理。

2.2 实验结果与分析

在 DRIVE、CHASE_DB1 数据集上对本文算法进行测试,视网膜血管分割结果如图 7、8 所示,第一列是原始图像,第二列是本文算法的分割结果,第三列是本文算法的分割二值图像,第四列是手工标记的分割结果图。可以看出,本文的 CSD-UNet 模型可以较好地克服血管分割的难点,得到良好的分割结果。

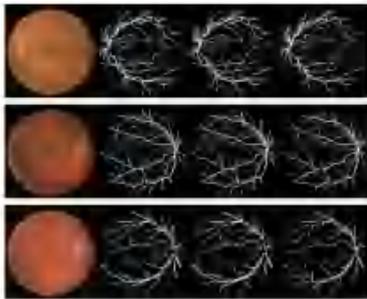


图 7 DRIVE 数据集上的分割结果

Fig. 7 Segmentation results on DRIVE dataset

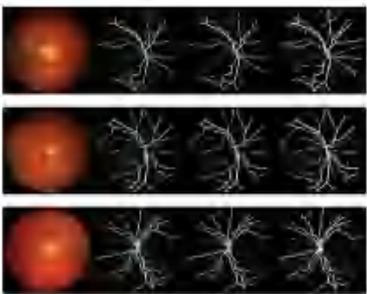


图 8 CHASE_DB1 数据集上的分割结果

Fig. 8 Segmentation results on CHASE_DB1 dataset

将本文算法与近年用于视网膜血管分割的几种先进算法进行对比,采用了准确率 (Accuracy, ACC), 敏感度 (Sensitivity, SE), 特异性 (Specificity, SP), $F1$ ($F1$ -score) 以及 AUC (Area Under Curve) 5 种常用的衡量算法性能的指标来进行分析,其定义分别如式(7)~式(10):

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

$$SE = \frac{TP}{TP + FN} \quad (8)$$

$$SP = \frac{TN}{TN + FP} \quad (9)$$

$$F1 = \frac{2TP}{2TP + FN + FP} \quad (10)$$

其中, TP (真阳性) 表示将正例预测为正例的数量; FP (假阳性) 表示将负例预测为正例的数量; FN (假阴性) 表示将负例预测为负例的数量; TN (真阴性) 表示将正例预测为负例的数量。

AUC 为 ROC 曲线下方的面积, ROC (Receiver Operating Characteristic, ROC) 曲线以 tpr (真阳性率)、 fpr (假阳性率) 为纵、横坐标,计算为式(11)~式(12):

$$tpr = \frac{TV}{N_v} \quad (11)$$

$$fpr = \frac{FV}{N_{nv}} \quad (12)$$

其中, N_v 表示金标准图中正例数量; N_{nv} 表示金标准图中负例数量; TV 表示预测结果中正例数量; FV 表示预测结果中负例数量。

在 DRIVE、CHASE_DB1 测试集上的实验结果见表 1、表 2。实验结果表明, CSD-UNet 方法在视网膜血管分割任务上的性能较其他方法有一定的提升。在 DRIVE、CHASE_DB1 数据集上的 PR 曲线和 ROC 曲线如图 9、图 10 所示。

表 1 DRIVE 数据集上各种算法的实验结果

Tab. 1 Experimental results of various algorithms on DRIVE dataset

方法	$F1$	SE	SP	ACC	AUC
U-Net ^[6]	0.814 2	0.753 7	0.982 0	0.953 1	0.975 5
R2U-Net ^[9]	0.817 1	0.779 2	0.981 6	0.955 6	0.978 4
Residual U-Net ^[9]	0.814 9	0.772 6	0.982 0	0.955 3	0.977 9
Recurrent U-Net ^[9]	0.815 5	0.775 1	0.981 6	0.955 6	0.978 2
CSD-UNet	0.824 1	0.795 2	0.980 4	0.956 8	0.979 3

表 2 CHASE_DB1 数据集上各种算法的实验结果

Tab. 2 Experimental results of various algorithms on CHASE_DB1 dataset

方法	$F1$	SE	SP	ACC	AUC
U-Net ^[6]	0.778 3	0.828 8	0.970 1	0.957 8	0.977 2
R2U-Net ^[9]	0.792 8	0.775 6	0.982 0	0.963 4	0.981 5
Residual U-Net ^[9]	0.780 0	0.772 6	0.982 0	0.955 3	0.977 9
Recurrent U-Net ^[9]	0.781 0	0.745 9	0.983 6	0.962 2	0.980 3
LadderNet ^[13]	0.803 1	0.797 8	0.981 8	0.965 6	0.983 9
IterNet ^[14]	0.807 3	0.797 0	0.982 3	0.965 5	0.985 1
CSD-UNet	0.832 3	0.764 0	0.991 1	0.965 9	0.987 8

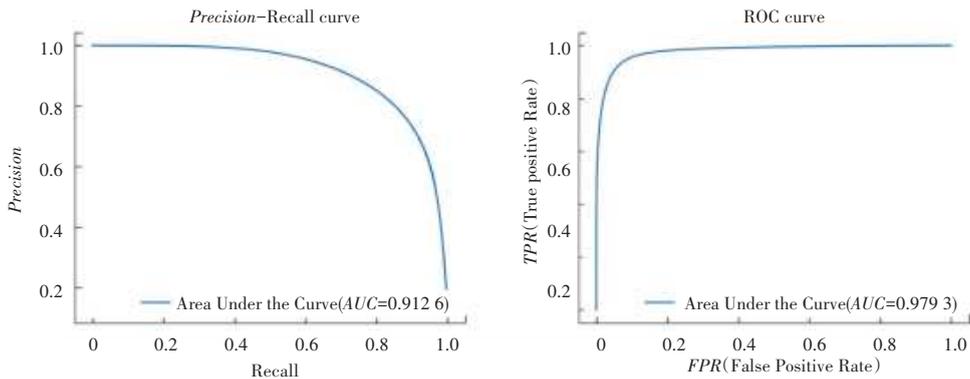


图 9 DRIVE 数据集上的 PR 曲线和 ROC 曲线

Fig. 9 PR curve and ROC curve on DRIVE dataset

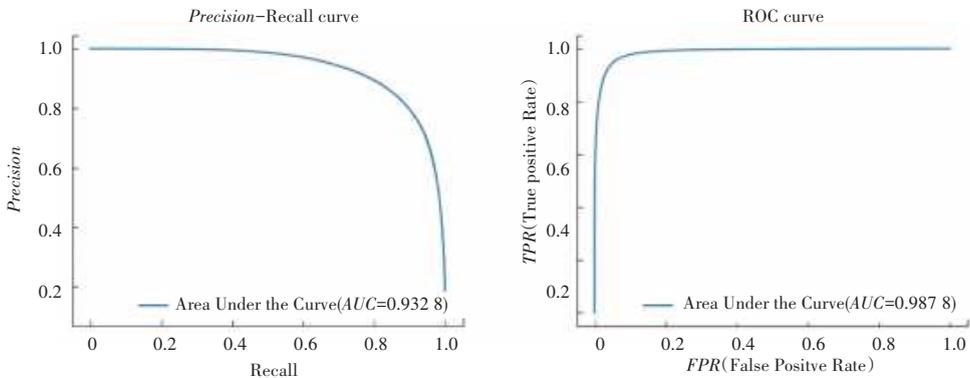


图 10 CHASE_DB1 数据集上的 PR 曲线和 ROC 曲线

Fig. 10 PR curve and ROC curve on CHASE_DB1 dataset

3 结束语

本文基于 U-Net 网络, 引入 CBAM、SoftPool、DUC 方法, 设计了一种能够更好地进行眼底视网膜血管分割的算法 CSD-UNet。该算法在公开数据集 DRIVE、CHASE_DB1 上进行验证, 得到结果 ACC 值为 0.956 8、0.965 9, AUC 值为 0.979 3、0.987 8, F1 值为 0.824 1、0.832 3, SE 值为 0.795 2、0.764 0, SP 值为 0.980 4、0.991 1。分割结果的客观评价指标与主观视觉验证了该算法在分割精度方面的有效性, 且较现有的先进算法有一定的提升。

参考文献

[1] 谢立信, 周庆军, 徐海峰, 等. 我国眼科学和视觉科学领域生物工程研究现状和应对策略[J]. 中国工程科学, 2017, 19(2): 100-105.

[2] 朱承璋, 邹北骥, 向遥, 等. 彩色眼底图像视网膜血管分割方法研究进展[J]. 计算机辅助设计与图形学学报, 2015, 27(11): 2046-2057.

[3] KIRBAS C, QUEK F. A review of vessel extraction techniques and algorithms[J]. ACM Computing Surveys (CSUR), 2004, 36(2): 81-121.

[4] ABRAMOVIĆ M D, GARVIN M K, SONKA M. Retinal imaging and image analysis[J]. IEEE reviews in biomedical engineering,

2010, 3: 169-208.

[5] LONG J, SHELHAMER E, DARRELL T. Fully convolutional networks for semantic segmentation[C]//Proceedings of the IEEE conference on computer vision and pattern recognition. 2015: 3431-3440.

[6] 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.

[7] ZHANG Z, LIU Q, WANG Y. Road extraction by deep residual u-net[J]. IEEE Geoscience and Remote Sensing Letters, 2018, 15(5): 749-753.

[8] ZENG Y, CHEN X, ZHANG Y, et al. Dense-U-Net: densely connected convolutional network for semantic segmentation with a small number of samples[C]//Tenth International Conference on Graphics and Image Processing (Icgip 2018). International Society for Optics and Photonics, 2019: 11069; 110692B.

[9] ALOM M Z, YAKOPCIC C, HASAN M, et al. Recurrent residual U-Net for medical image segmentation[J]. Journal of Medical Imaging, 2019, 6(1): 014006.

[10] LIAN S, LUO Z, ZHONG Z, et al. Attention guided U-Net for accurate iris segmentation[J]. Journal of Visual Communication and Image Representation, 2018, 56: 296-304.

[11] ZHOU Z, SIDDIQUEE M M R, TAJBAKHSH N, et al. Unet++: A nested u-net architecture for medical image segmentation[M]//Deep learning in medical image analysis and multimodal learning for clinical decision support. Springer, Cham, 2018: 3-11.

(下转第 159 页)