

DOI: 10.13382/j.jemi.B2003781

基于改进 U-Net 网络的眼底血管图像分割研究

何晓云 许江淳 陈文绪

(昆明理工大学 信息工程与自动化学院 昆明 650500)

摘要:针对眼底血管图像存在血管细小、视网膜病变而导致分割精度低的问题,提出了一种引入残差块、级联空洞卷积、嵌入注意力机制的 U-Net 视网膜血管图像分割模型。首先采用提高视网膜图像分辨率,以点噪声为中心、512 为边长裁剪来扩增数据集,然后在 U-Net 模型中引入残差块,增加像素特征的利用率和避免深层网络的退化;并将 U-Net 网络的底部替换为级联空洞卷积模块,扩大特征图的感受野,提取更丰富的像素特征;最后在解码器中嵌入注意力机制,加重目标特征的权重,减缓无用信息的干扰。基于 CHASE 数据集的实验结果表明,所提模型的准确率达到 98.2%,灵敏度达到了 81.72%,特异值达到了 98.90%,与其他多尺度神经网络方法相比体现了更好的分割效果,充分验证了提出改进的 U-Net 网络模型能有效提高血管分割精度、辅助确诊血管病变。

关键词: 血管图像分割; U-Net 网络; 残差块; 注意力机制; 空洞卷积

中图分类号: TP391; TN911.7 **文献标识码:** A **国家标准学科分类代码:** 510.40

Research on fundus blood vessel image segmentation based on improved U-Net network

He Xiaoyun Xu Jiangchun Chen Wenxu

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

Abstract: Aiming at the problem of low segmentation accuracy due to small blood vessels and retinopathy in fundus blood vessel images, a U-Net retinal blood vessel image segmentation model that introduces residual blocks, cascaded cavity convolution, and embedded attention mechanism is proposed. First, increase the resolution of the retinal image, crop the data set with point noise as the center and 512 as the side length, and then introduce residual blocks in the U-Net model to increase the utilization of pixel features and avoid the degradation of deep networks; And replace the bottom of the U-Net network with a cascaded hole convolution module to expand the receptive field of the feature map and extract richer pixel features; finally, the attention mechanism is embedded in the decoder to increase the weight of the target feature and slow down useless information Interference. The experimental results based on the CHASE data set show that the accuracy of the proposed model reaches 98.2%, the sensitivity reaches 81.72%, and the singular value reaches 98.90%. Compared with other multi-scale neural network methods, it embodies better segmentation results, and fully verifies that the improved U-Net network model can effectively improve the accuracy of blood vessel segmentation and assist in the diagnosis of vascular disease.

Keywords: blood vessel image segmentation; U-Net network; residual block; attention mechanism; hole convolution

0 引言

视网膜图像的血管分割一直是医学领域的研究热点,常常被作为诊断视网膜血管病变、糖尿病、青光眼的重要手段^[1]。视网膜图像的分割主要分为监督型和非监

督型^[2]。精确的分割视网膜血管可以对眼底血管进行定量和定性的分析处理,但眼底血管图像目前存在数据集少、血管大小尺寸不一和病变背景干扰的问题,加大了图像分割的难度^[3],也导致了视网膜图像的血管分割一直充满挑战。

传统的分割方法有阈值法、聚类法、边缘检测分割方

法^[4-5], 大部分都依赖手工设置特征, 如方向梯度直方图 (histogram of oriented gradient, HOG)^[6], 主要通过提取图片的灰度直方图, 然后人工设置阈值去对图片像素进行分类。这些传统的方法结构简单、速度快, 但随着眼底血管病变的出现, 特征提取的过程更加困难, 浅层的网络结构已经不能够达到高精度的分割目标。近年来, 基于深度学习的语义分割方法逐渐成为研究热点, 文献[7]在 2014 年提出了全卷积神经网络 (fully convolutional networks, FCN), 这是首次提出的端到端的算法模型, 它将反卷积层进行上采样, 跳跃连接改进上采样的粗糙度, 并在自然的数据集中取得了很好的分类效果。此后, 提出了很多 FCN 改进模型, 文献[8]提出了一种 U-Net 网络, 通过编码器与解码器的拼接减少信息损失, 算法结构简单、参数少, 首次在医学细胞图像分割中效果显著。文献[9]提出了一种 U-Net 网络和残差模块相结合, 并用残差块替换原来卷积核的细胞分割模型, 在二分类的语义分割数据集中, 所提模型的 Dice 系数达到了 87.75%。文献[10]提出密集注意力机制的视网膜血管图像分割方法, 引入注意力机制能有效抑制不相关背景干扰, 提高了视网膜血管的分割精度。文献[11]提出一种从图像到血管图模态数据转换的方法, 利用神经网络对分割任务进行重构。文献[12]提出基于 U-Net 网络的递归神经网络 (recurrent residual U-NET, RRCNN) 对视网膜血管分割的方法。文献[13]提出一种级联空洞卷积模块与 U-Net 网络的结合应用于视网膜的图像分割中, 分割效果明显优于其他算法模型。文献[14]提出一种膨胀多尺度卷积神经网络分割视网膜血管模型, 通过扩张卷积扩大感受野, 提高分割精度。总之, 随着深度学习的应用, 它在图像分割方面能克服一些传统方法的困难, 但随着网络加深、数据集增大, 容易出现细节特征丢失的问题, 导致细小血管分割精度降低, 因为细小血管能辅助确诊血管是否病变。

因此, 本文针对视网膜图像血管细小, 病变背景干扰而分割效果差的问题。提出一种引入残差块、级联空洞卷积块、嵌入注意力机制的 U-Net 眼底血管图像分割模型。1) 为了扩增数据集, 采用提高视网膜图像分辨率、随机添加点噪声, 并以点噪声为中心、512 为边长裁剪并进行翻转操作扩增数据集; 2) 为了减少浅层特征的丢失和提高像素特征的重复利用率, 及出现深层网络退化、梯度消失的问题, 在 U-Net 网络中引入残差块; 3) 为了提取丰富的图像特征, 并在不增加网络参数的基础上, 扩大特征图的感受野, 将 U-Net 网络的底部卷积核替换为级联空洞卷积模块; 4) 在解码器的卷积操作中嵌入注意力机制, 对需要关注的目标特征进行加权, 减缓无用信息的干扰。最终, 通过 CHASE 数据集的实验结果表明, 本文提出的模型与其他方法相比, 准确率能达到 98.2%, 验证了本文

方法的有效性。

1 相关工作

1.1 网络结构

U-Net 网络作为图像语义分割常用的一种模型, 具有网络结构简单、参数少、可塑性强的特点^[15]。由编码器、解码器组成的端到端对称模型, 可以对小数据集进行高精度的分割, 但随着网络加深, U-Net 网络的在采样过程中会造成一些细节特征的丢失, 此外, 还会出现网络退化的问题。本文提出的模型以 U-Net 为基本框架, 引入残差块、级联空洞卷积块和嵌入注意力机制作为改进。所提模型由编码器的 4 个残差块、解码器的 4 个残差块及 U-Net 底部的级联空洞卷积模块构成, 其中编码器和解码器中的每个残差块由 2 个串联的 3×3 的卷积层和增加一个恒等映射 (1×1 的卷积层) 通过跳跃连接组成, 引入残差块可以加强图像浅层特征和深层特征的结合, 提高特征的重复利用率, 并利用级联空洞卷积替换 U-Net 底部标准的卷积核, 在不增加参数的情况下扩大血管图像特征映射的感受野, 增强上下文之间的语义信息。在解码器的反卷积层嵌入了注意力机制, 使得模型对关键的语义特征加大权重系数, 突出目标的特征信息, 减弱背景信息的干扰, 从而提高模型的分割精度。最后通过 1×1 的卷积层对目标进行语义分割。本文算法的网络结构如图 1 所示。

1.2 残差块

本文的残差卷积模块想法起源于 He 等^[16]在 2016 年提出的 Resnet (residual network) 模型, 是在卷积神经网络的基础上进行了跳跃连接的改进, 由许多个残差块 (residual block) 堆叠而成的, 能够解决网络加深而导致退化的问题。Resnet 的残差块主要有如下两种映射 (mapping): 与 CNN 相比, 增加了一种恒等映射 (identity mapping), 进行了跳跃连接的改进, 缩短了卷积层之间的距离, 能够提取细节特征; 另一种是原有的残差映射 (residual mapping), 输出为式(1)。

$$y = F(x) + x \quad (1)$$

式中: x 为输入的神经元, $F(x)$ 为残差映射的神经元; y 则是残差映射和恒等映射叠加的输出。

增加一个恒等映射的目的是为了使残差值 $F(x)$ 逐渐变为 0, 只剩下恒等映射, 使输入参数 x 与输出参数值 y 一致, 则网络模型达到了最优的状态。相比普通 CNN 网络, 残差结构具有更好的自适应能力, 解决了网络模型随着深度增加而导致梯度消失和爆炸的问题。

本文利用两个 3×3 的卷积层完成残差映射, 在恒等映射中增加了 1×1 的卷积层, 通过它进行遥感图像的特

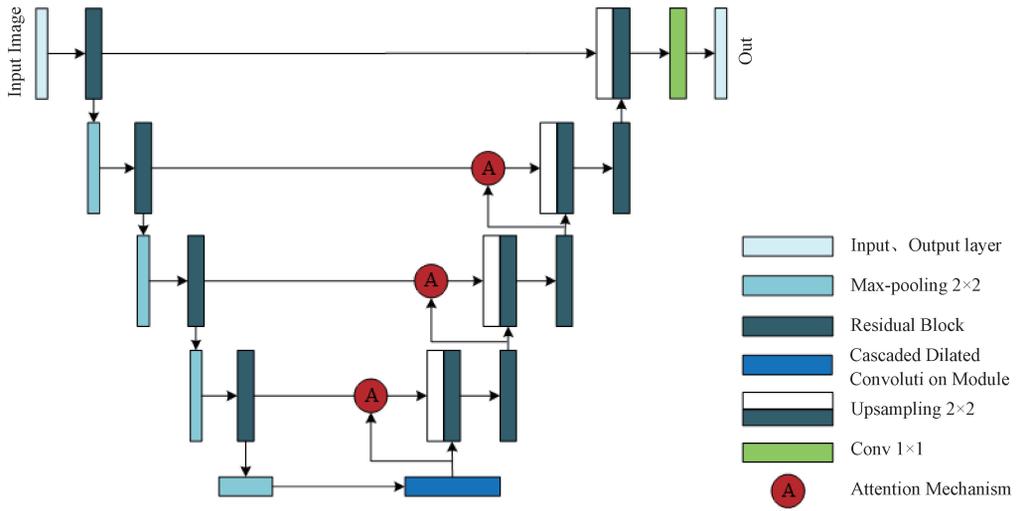


图 1 本文算法网络结构

Fig. 1 Network structure diagram of the algorithm in this paper

征维度匹配,因为只是增加了 1×1 的卷积层,并不会增加很大的计算量,还能提取图片更细节的特征,最终由 Add 进行特征融合操作,提取有效的语义信息。构建残差块模型,其本质就是用残差块替换 U-Net 的标准卷积块,并且采用批量归一化层 BN 和 Relu 激活函数进行训练。本文算法的残差块模型如图 2 所示。

式中: f_k 为卷积核大小; f_n 为空洞卷积核大小; r_j 为扩张率; $(\text{strid}S_i e)$ 为第 i 层步幅大小; l_{m-1} 、 l_m 分别为为第 $m-1$ 层、 m 层感受野的大小。

不同扩张率的空洞卷积示意图如图 3 所示,空洞卷积的步长 $stride$ 都设置为 1,当扩张率为 1 时,空洞卷积相当于标准的卷积核,感受野大小为 3×3;当扩张率为 2 时,表示两个卷积核权值间补一个空洞,感受野大小为 7×7;当扩张率为 3 时,表示两个卷积核权值间补两个空洞,感受野大小为 15×15。本文级联空洞卷积模块分别由扩张系数为 1、2、4、8 的 3×3 的卷积核级联构成,首先对 $r=1$ 时对图像提取特征图,然后把该特征图作为 $r=2$ 时的输入,依此类推,最终通过级联方式得到 5 个部分组合的特征图。最后通过 1×1 卷积核的目的是减少学习参数,防止过拟合。级联的空洞卷积模块如图 4 所示。

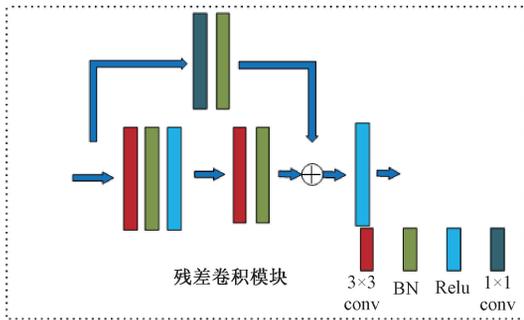


图 2 本文算法残差块模型

Fig. 2 The residual block model of the algorithm in this paper

1.3 级联空洞卷积模块

在 U-Net 网络的底部将普通的卷积层替换为级联空洞卷积模块,其目的是在不增加网络训练参数、不损失敏感图像的细节语义特征的基础上,扩大特征图的感受野。空洞卷积自被 Chen 等^[17]提出以来,广泛地应用于提取图像的多尺度特征,其本质是通过在卷积核像素间补零,达到增大扩张率 r 与扩大特征图的感受野的目的,连接方式一般有级联和并行两种模式,都具有较强的语义分割效果。空洞卷积核与感受野之间的计算公式如下:

$$f_n = f_k + (f_k - 1) * (r_j - 1) \quad (2)$$

$$l_m = l_{m-1} + (f_n - 1) * \prod_{i=1}^{m-1} S_i \quad (3)$$

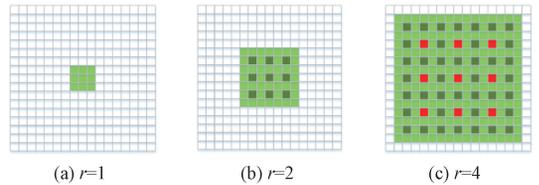


图 3 不同扩张率的空洞卷积示意图

Fig. 3 Schematic diagram of hole convolution with different expansion rates

1.4 高低维度特征融合注意力机制

注意力机制在图像语义分割中的运用主要是为了剔除冗余信息,放大关键像素特征的作用,近年来在图像分割中取得了不错的分类效果^[18-20]。本文提出一种权重注意力机制,如图 5 所示。注意力机制模块的输入有高层次(Hight-level)和低层次(low-level)的像素特征,分别包

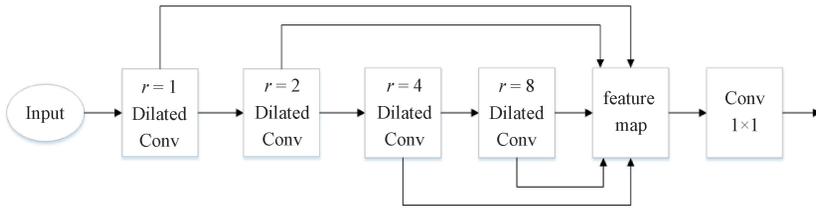


图 4 级联的空洞卷积模块示意图

Fig. 4 Schematic diagram of cascaded hole convolution module

含丰富的类别信息和位置信息。为了得到更加准确的特征图, 首先将高层次的像素特征与 U-net 神经网络的权重 W_1 相乘, 将低层次的像素特征与权重 W_2 相乘, 然后将两边得到的特征进行叠加, 并与 low-level 特征进行 concat 连接(一种 skip connection 连接), 最终得到包含丰富的类别信息和位置信息的像素特征图。其中 W_1 与 W_2 为 U-net 网络中不相等的可学习参数, 相当于一个权重系数。

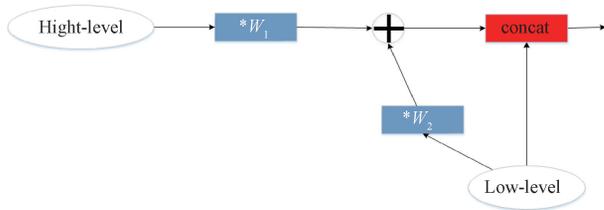


图 5 注意力机制模块

Fig. 5 Attention mechanism module

2 实验步骤

2.1 数据集预处理和实验参数设置

数据集选择公开的 CHASE 数据集, CHASE 数据集来自英国儿童心脏与健康研究中心, 包含 28 张图像, 由 14 张左眼视网膜图像和 14 张右眼视网膜图像组成, 每张图像的像素大小为 999×960 , 本文选择 20 张图片为训练集, 8 张图片为测试集。数据集里的每张图片分别由两位专家手动标注, 本文以第 1 位专家标注结果为金标准图像, 并将模型分割结果与第 2 位专家分割结果做对比。

由于数据集较少, 为了防止网络在训练的过程中出现过拟合的现象, 数据集采用了预处理操作。首先将图片像素分辨率提高 5 倍, 比如像素大小为 999×960 的提高到像素为 4995×4800 , 然后在变大的图片上随机添加点噪声, 并以点噪声为中心, 512 为边长将图片裁剪为 512×512 的大小, 最后采用图旋转方式将 CHASE 数据集扩增到 10 000 张。

2.2 实验相关参数设置

软件环境是基于 Win10 操作系统, python3.6 编程软件下运行的, 深度学习框架为 pytorch (GPU); 硬件环境

是两张 Nvidia GTX 1080Ti 显卡。选用 Adam 作为网络的优化方法; 初始学习率设为 0.001, 衰减系数为 0.001, 训练迭代周期 (epochs) 为 200; 批量数据大小 (batch size) 为 4。

2.3 评价指标

对于分类模型而言, 评价指标可以更好地判断模型的分类性能。本文选择准确度 (Acc , Acc)、灵敏度 (S_n , S_n)、特异性 (Sp , Sp) 和 AUC (area under curve) 值作为评价标准, 其中 AUC 是基于分割模型的一种评价指标, 指受试者工作特性 (ROU) 曲线下的面积, 值越大, 说明模型分类效果越好, 范围在 0.5~1。Acc 表示正确分割血管和背景的能力, S_n 表示将血管正确分割的能力, Sp 表示将背景正确分类的能力。

$$S^p = \frac{x_{TN}}{x_{TN} + x_{FP}} \quad (4)$$

$$S^n = \frac{x_{TP}}{x_{TP} + x_{FP}} \quad (5)$$

$$A^{cc} = \frac{x_{TP} + x_{TN}}{x_{TP} + x_{TN} + x_{FP} + x_{FN}} \quad (6)$$

式中: (TP , X_{TP}) 代表真阳性, 表示将血管正确分类的像素; (FN , X_{FN}) 代表假阴性, 表示将血管错误分类为背景的像素; (TN , X_{TN}) 代表真阴性, 表示将非血管正确分类为背景的像素; (FP , X_{FP}) 代表假阳性, 表示将背景错误分类为血管的像素。

3 实验结果分析

3.1 本文算法的结果

本文算法在 CHASE 数据集的分割结果如图 6 所示。图 6(a) 为 CHASE 数据集的眼底血管原图, 图 6(b) 为选择第一位专家标注的结果, 作为金标准图像, 图 6(c) 为本文算法的分割结果, 可以看出, 在细小的血管上, 本文算法能很好地将它与背景分割出来。

眼底血管病变的检测是视网膜血管分割最大的挑战之一, 它在医疗领域是一个不容忽视的问题。为了突出本文算法的优势, 对两张病变的图像进行分割, 并进行局部分割对比, 如图 7 所示。

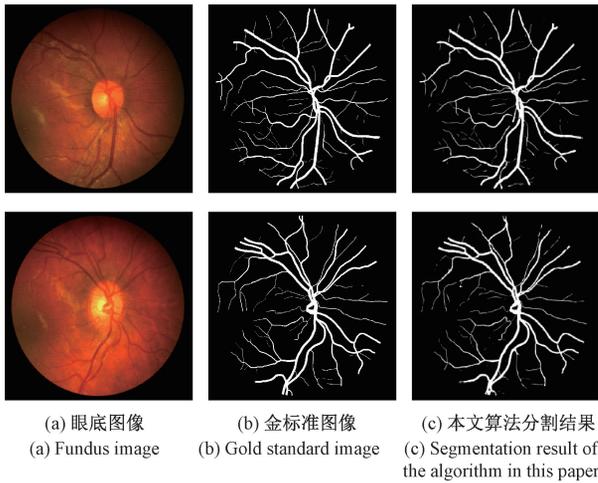


图 6 CHASE 数据集的分割结果

Fig. 6 Segmentation results of the CHASE dataset

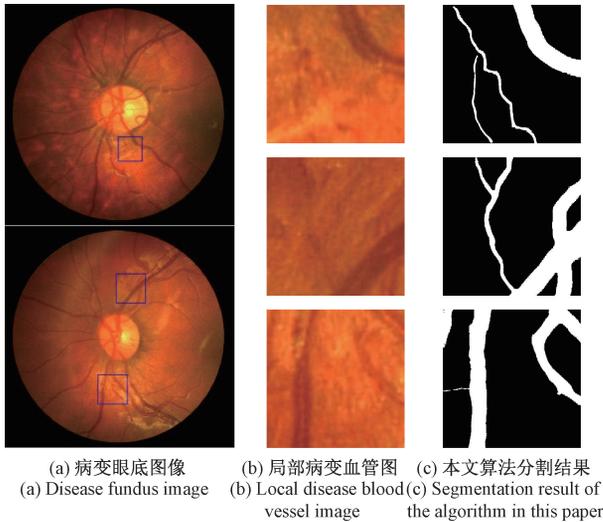


图 7 病变眼底血管的分割结果

Fig. 7 Segmentation result of diseased fundus blood vessels

图 7 可以明显看出,本文算法提出来的残差块替换卷积核,引入注意力机制和级联空洞卷积,能够减小病变区域度分割血管的干扰,在病变区域中细小的血管都能取得较好的分割效果。

3.2 与原始 U-Net 网络对比

为了验证本文提出改进点对 U-Net 网络的改进程度,分别将每个改进点对应的模型与原始网络 U-Net 进行性能评估实验,如表 1 所示。模型 1 为原始的 U-Net 网络;模型 2 将 U-Net 模型中的卷积核替换为残差块;模型 3 将 U-Net 网络的底部替换为级联空洞卷积模块;模型 4 在 U-Net 网络的基础上添加注意力机制。为了定性和定量分析这 4 种模型,在 CHASE 数据集中,将准确率 Acc 和灵敏度 Se 、特异性 Sp 和 AUC 值作为评价指标。

表 1 不同模型在 CHASE 数据集的性能评价
Table 1 Performance evaluation of different models in the CHASE data set (%)

算法	S_n	S_p	Acc	AUC
Model 1	78.40	98.23	96.43	98.12
Model 2	78.98	98.44	97.11	98.49
Model 3	78.81	98.12	96.88	98.24
Model 4	80.91	98.50	97.27	98.52
本文	81.72	98.90	98.20	98.84

从表 1 可以明显看出,每个改进点与 U-Net 网络结合都比原始网络分割效果好。其中 Model 1 效果最差,因为没做任何预处理,基于 U-Net 网络的分割准确率只能达到 96.43%。Model 2~4 和本文所提模型,都采用了先提高分辨率,添加以点噪声为中心进行裁剪的预处理,分割效果有明显的提升。在算法中引入注意力机制、级联空洞卷积模块、残差块后,本文所提模型效果最好,准确率能达到 98.20%。本文模型相比于传统的 U-Net 网络,分别提高了 3.32%、0.67%、1.77%、0.72%。

为了对比本文算法与其他算法的效果,采用与其他文献方法对比,如表 2 所示。可以看出本文算法的灵敏度、特异值、准确率和 AUC 等评价指标分别为 81.72%、98.90%、98.20%、98.84%,除了特异值略低于文献[14],其他指标均高于其他文献,验证了本文算法的优势。

表 2 不同算法在 CHASE 数据集的性能评价
Table 2 Performance evaluation of different algorithms in the CHASE data set (%)

算法	年份	S_n	S_p	Acc	AUC
文献[2]	2012	72.24	97.11	94.69	97.19
文献[11]	2016	75.07	97.93	95.81	97.93
文献[12]	2018	77.56	98.20	96.34	98.15
文献[14]	2019	78.39	98.94	97.21	98.66
本文	2020	81.72	98.90	98.20	98.84

4 结论与展望

本文针对视网膜图像存在血管细小难以提取、而血管的分割精度低的问题,提出了一种引入残差块、级联空洞卷积、嵌入注意力机制的改进 U-Net 模型。首先为了扩增数据集,采用放大视网膜图像分辨率、随机添加点噪声,并以点噪声为中心、512 为边长裁剪并进行翻转操作。然后为了减少浅层特征的丢失和出现深层网络退化、梯度消失的问题,在 U-Net 网络中引入残差块;其次为了扩大特征图的感受野,将 U-Net 网络的底部卷积核

替换为级联空洞卷积模块;最后在解码器的卷积操作中嵌入注意力机制,减缓无用信息的干扰。通过 CHASE 数据集的实验结果表明,本文提出的改进 U-Net 网络的眼底血管图像分割模型,准确率能达到 98.2%,验证了本文方法的有效性。下一步将针对其它不同视网膜血管病变的图像进行分割研究。

参考文献

- [1] NGUYEN U T V, BHUIYAN A, PARK L A F, et al. An effective retinal blood vessel segmentation method using multi-scale line detection [J]. Pattern Recognition, 2013, 46(3) : 703-715.
- [2] ZHANG S, SHE L, WANG Y F, et al. Retinal image segmentation based on multifractal detrending fluctuation analysis [J]. Journal of Northeastern University (Natural Science Edition), 2019, 40(2) : 158-163.
张石,余黎煌,王雅凡,等.基于多重分形去趋势波动分析的视网膜图像分割 [J]. 东北大学学报 (自然科学版), 2019, 40(2) : 158-163.
- [3] REMAGNINO P, BASIT A, HOPPA, et al. An approach to localize the retinal blood vessels using bit planes and centerline detection [J]. Computer Methods and Programs in Biomedicine: An International Journal Devoted to the Development, Implementation and Exchange of Computing Methodology and Software Systems in Biomedical Research and Medical Practice, 2012, 108(2) : 600-616.
- [4] 潘峰,孙红霞.基于蝗虫算法的图像多阈值分割方法 [J]. 电子测量与仪器学报, 2019, 33(1) : 149-155.
PAN F, SUN H X. Multi-threshold image segmentation method based on locust algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(1) : 149-155.
- [5] LIANG X Y, LUO CH, QUAN J, et al. Research progress of image semantic segmentation technology based on deep learning [J]. Computer Engineering and Applications, 2020, 56(2) : 18-28.
梁新宇,罗晨,权冀川,等.基于深度学习的图像语义分割技术研究进展 [J]. 计算机工程与应用, 2020, 56(2) : 18-28.
- [6] DALAL N, TRIGGS B. Histograms of oriented gradients for human detection [C]. IEEE Computer Society Conference on Computer Vision and Pattern Recognition, San Diego, USA, 2005 : 886-893.
- [7] LONG J, SHELHAMER E, DARREL T. Fully Convolutional Networks for Semantic Segmentation [J]. IEEE Transactions on Pattern Analysis & Machine Intelligence, 2014, 39(4) : 640-651.
- [8] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation [C]. Proceedings of International Conference on Medical Image Computing and Computer-Assisted Intervention, IEEE, 2015 : 234-241.
- [9] 张文秀,朱振才,张永合,等.基于残差块和注意力机制的细胞图像分割方法 [J]. 光学学报, 2020, 40(17) : 1710001.
ZHANG W X, ZHU ZH C, ZHANG Y H, et al. Cell image segmentation method based on residual block and attention mechanism [J]. Acta Optica Sinica, 2020, 40(17) : 1710001.
- [10] 梅旭璋,江红,孙军.基于密集注意力网络的视网膜血管图像分割 [J]. 计算机工程, 2020, 46(3) : 267-272, 279.
MEI X ZH, JIANG H, SUN J. Retinal vessel image segmentation based on dense attention network [J]. Computer Engineering, 2020, 46(3) : 267-272, 279.
- [11] LI Q, FENG B, XIE L, LIANG P, et al. A cross-modality learning approach for vessel segmentation in retinal images [C]. IEEE Transactions on Medical Imaging, 2016 : 109-118.
- [12] ALOM M Z, YAKOPCIC C, TAHA T M, et al. Nuclei segmentation with recurrent residual convolutional neural networks based U-Net (R2U-Net) [C]. NAECON 2018-IEEE National Aerospace and Electronics Conference, 2018 : 228-233.
- [13] 李大湘,张振.基于改进 U-Net 视网膜血管图像分割算法 [J]. 光学学报, 2020, 40(10) : 1010001.
LI D X, ZHANG ZH. Based on improved U-Net retinal blood vessel image segmentation algorithm [J]. Acta Optica Sinica, 2020, 40(10) : 1010001.
- [14] JIANG Y, TAN N, PENG T, et al. Retinal vessels segmentation based on dilated multi-scale convolutional neural network [C]. IEEE Access, 2019 : 76342-76352.
- [15] 罗仁泽,李阳阳.一种基于 RUnet 卷积神经网络的地震资料随机噪声压制方法 [J]. 石油物探, 2020, 59(1) : 51-59.
LUO R Z, LI Y Y. A random noise suppression method for seismic data based on RUnet convolutional neural network [J]. Geological Prospecting for Petroleum, 2020, 59(1) : 51-59.
- [16] HE K M, ZHANG X Y, REN H Q, et al. Deep residual learning for image recognition [C]. Proceedings of 2016 IEEE Conference on Computer Vision and Pattern

Recognition, Las Vegas, USA, 2016: 770-778.

- [17] 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, 2018, 40 (4): 834-848.
- [18] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [C]. Advances in Neural Information Processing Systems, 2017: 1251-1258.
- [19] JO Y J, CHO H, LEES Y, et al. Quantitative phase imaging and artificial intelligence: A review [J]. IEEE Journal of Selected Topics in Quantum Electronics, 2018, 25(1): 1-14.
- [20] 侯向丹, 赵一浩, 刘洪普, 等. 融合残差注意力机制的 UNet 视盘分割 [J]. 中国图象图形学报, 2020, 25(9): 1915-1929.
- HOU X D, ZHAO Y H, LIU H P, et al. UNet optic disc segmentation fused with residual attention mechanism [J]. Journal of Image and Graphics, 2020, 25(9): 1915-1929.

作者简介



何晓云, 2018 年于玉溪师范学院获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为深度学习、图像处理。

E-mail: 2327961045@qq.com

He Xiaoyun received her B. Sc. degree from Yuxi Normal University in 2018. She is currently a M. Sc. candidate at Kunming University of Science and Technology. Her main research interests include deep learning and image processing.



许江淳 (通信作者), 1989 年于昆明理工大学获得硕士学位, 现为昆明理工大学副教授、硕士生导师, 主要研究方向为嵌入式应用与研究。

E-mail: jx19631018@163.com

Xu Jiangchun (Corresponding author) received his M. Sc. degree from Kunming University of Science and Technology in 1989. He is currently an associate professor and M. Sc. supervisor at Kunming University of Science and Technology. His main research interests include embedded applications and research.