

控制与决策

Control and Decision

基于三端注意力机制的视网膜血管分割算法

曹飞道, 赵怀慈

引用本文:

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*, 2022, 37(10): 2505–2512.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0435>

您可能感兴趣的其他文章

Articles you may be interested in

[基于多尺度残差注意网络的轻量级行人属性识别算法](#)

Lightweight pedestrian attribute recognition algorithm based on multi-scale residual attention network

控制与决策. 2022, 37(10): 2487–2496 <https://doi.org/10.13195/j.kzyjc.2021.0411>

[基于紧凑混合网络的视网膜血管自动分割](#)

Automatic segmentation of retinal vessel via compact mixed network

控制与决策. 2022, 37(2): 353–360 <https://doi.org/10.13195/j.kzyjc.2020.0883>

[自适应感受野网络的行人重识别](#)

Adaptive receptive network for person re-identification

控制与决策. 2022, 37(1): 119–126 <https://doi.org/10.13195/j.kzyjc.2020.0505>

[融合注意力机制的域泛化行人再识别](#)

Domain generalization person re-identification based on attention mechanism

控制与决策. 2022, 37(7): 1721–1728 <https://doi.org/10.13195/j.kzyjc.2020.1844>

[基于偏差的图注意力神经网络推荐算法](#)

A bias-based graph attention neural network recommender algorithm

控制与决策. 2022, 37(7): 1705–1712 <https://doi.org/10.13195/j.kzyjc.2020.1626>

基于三端注意力机制的视网膜血管分割算法

曹飞道^{1,2,3,4}, 赵怀慈^{1,2,3†}

- (1. 中国科学院 光电信息处理重点实验室, 沈阳 110016;
2. 中国科学院 沈阳自动化研究所, 沈阳 110016;
3. 中国科学院 机器人与智能制造创新研究院, 沈阳 110169;
4. 中国科学院大学, 北京 100049)

摘要: 视网膜血管的结构和形态是计算机辅助系统诊断眼科疾病的重要依据. 针对细小血管分割精度低的问题, 提出一种融合残差密集模块与三端注意力模块的改进型 U-Net 算法. 首先, 将残差模块与密集模块相结合, 充分利用每层的特征, 提高网络提取细小血管特征的能力. 在解码阶段引入三端注意力模块, 利用空间注意力机制自适应地对特征进行空间校正, 抑制背景噪声, 突出目标区域. 同时, 通过多尺度特征融合的方式, 利用高级语义特征改善网络对细小血管的分割效果. 最后, 为获取血管的多尺度特征, 在编码-解码网络结构中加入空洞卷积, 在不增加参数的情况下增加感受野. 基于 DRIVE 和 STARE 数据集的实验结果表明, 所提出网络的灵敏度、特异性、准确率和 AUC (area under curve) 分别为 81.26% / 82.57%、98.20% / 98.37%、96.70% / 97.51% 和 98.12% / 98.41%, 优于现有先进算法.

关键词: 计算机辅助系统; 血管分割; U-Net; 残差密集模块; 空洞卷积; 三端注意力模块

中图分类号: TP391 文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0435

开放科学(资源服务)标识码(OSID):



引用格式: 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, 2022, 37(10): 2505-2512.

Improved U-Net based on three-terminal attention mechanism for retinal vessel segmentation

CAO Fei-dao^{1,2,3,4}, ZHAO Huai-ci^{1,2,3†}

- (1. Key Laboratory of Opto-Electronic Information Process, Chinese Academy of Sciences, Shenyang 110016, China;
2. Shenyang Institute of Automation, Chinese Academy of Sciences, Shenyang 110016, China;
3. Institutes for Robotics and Intelligent Manufacturing, Chinese Academy of Sciences, Shenyang 110169, China;
4. University of Chinese Academy of Sciences, Beijing 100049, China)

Abstract: The structure and morphology of retinal blood vessels are essential for computer-aided systems to diagnose ophthalmological diseases. To solve the problem of low precision of tiny blood vessel segmentation, we propose an improved U-Net algorithm combining a residual dense block and a three-terminal attention gate block. First of all, we combine the residual block with the dense block to make full use of the features of each layer and improve the ability to extract the characteristics of tiny blood vessels. In the decoding stage, we introduce a three-terminal attention gate block. And the spatial attention mechanism is used to adaptively correct the features, suppress background noise and highlight the target area. At the same time, we use high-level semantic features to improve the segmentation effect of tiny blood vessels through multi-scale feature fusion. Finally, to obtain the multi-scale features of blood vessels, we introduce deformable convolution into the network structure and increase the receptive field without increasing the parameters. The experimental results based on the DRIVE and STARE data sets show that the sensitivity, specificity, accuracy and AUC (area under curve) of the proposed network are 81.26% / 82.57%、98.20% / 98.37%、96.70% / 97.51% and 98.12% / 98.41%, which are better than existing advanced algorithms.

Keywords: computer-aided system; vessel segmentation; U-Net; residual dense block; deformable convolution; three-terminal attention gate block

收稿日期: 2021-03-16; 录用日期: 2021-07-19.

基金项目: 国家自然科学基金项目(62041302).

†通讯作者. E-mail: hczhao@sia.cn.

0 引言

随着技术的发展,计算机辅助系统的应用越来越广泛.在视网膜相关疾病诊断过程中,计算机辅助系统利用影像资料,首先定位与识别目标区域,然后利用领域专家知识进行决策,最后得出诊断结果.视网膜血管异常与糖尿病、高血压和青光眼等疾病有关联.视网膜血管的宽度、曲折度和增生为计算机辅助诊断视网膜疾病提供了重要依据^[1].定期对视网膜血管进行检查,可有效地对相关疾病进行评估,及时进行治疗.目前,视网膜血管的提取依然以眼科专家人工标注为主.由于眼睛结构复杂且血管细小,人工标注视网膜血管对医学专家来说是一项极具挑战性和繁琐的任务.由于细小血管不突出和光线不均等问题,人工标注耗时耗力且存在主观性,不利于大规模的研究与临床应用^[2].因此,研究自动提取视网膜血管的算法具有重要的研究与临床应用价值.

视网膜血管分割是将血管像素与背景像素进行二分类的问题.目前,国内外的研究方法主要分为两类:无监督学习分割方法^[3]和有监督学习分割方法^[4-5].无监督学习分割方法无需专家标注信息,只利用视网膜血管的分布和形态等固有属性进行特征编码,然后通过某种规则实现自动分割,比如基于模板匹配的方法、基于形态学的方法^[6-7]和基于活动轮廓的方法等. Yang等^[3]利用Frangi滤波器获取多尺度特征,再通过聚类与后处理操作进行分割.许言兵等^[8]利用Hessian最大本征值、Gabor小波和B-COSFIRE滤波器提取三维像素特征,然后利用超像素块进行筛选以实现分割的目的. Ali等^[9]使用Gabor小波滤波器对绿色通道图像进行像素特征提取,然后采用K-means聚类方法作为分类器进行分割.无监督学习分割方法使用预处理之后的眼底图像,通过滤波器提取特征,再利用分类器实现血管区域与背景区域的分类.由于无监督学习分割方法提取的特征粗糙,从而导致最终分割精度较低.

有监督学习分割方法使用专家标注信息引导算法不断提高分割能力,具有较强的稳定性与可靠性^[10-11].有监督学习分割方法中的卷积神经网络方法能自动提取特征,得到了广泛关注. Yan等^[12]在不增加模型复杂度的情况下,提出了像素损失与血管段级损失相结合的损失函数,有效地提取了血管特征. Wang等^[13]将样本分为易分样本和难分样本,然后分别训练并通过最终的融合网络预测完整的分割结果. Park等^[14]将两个U-Net^[15]网络串联起来作为网络结构,通过多尺度核提取多尺度不变特征,实现了两个U-Net网络之间的信息传递,并引入GAN提高

网络的稳定性. Alfonso Francia等^[16]采用与文献[14]一样的网络结构,但在两个U-Net网络每层之间通过跳跃连接实现特征的传递. Jin等^[17]将可变形卷积与注意力机制相结合,提高了算法的准确率和抗噪能力.虽然基于卷积神经网络的算法提高了视网膜血管分割效果,但是,其对细小血管特征提取不足,从而限制了分割的精度.细小血管尺度小且样本所占比例低,导致提取特征过程中易丢失信息,且收敛过程较慢.

针对细小血管分割精度低的问题,本文提出一种改进的U-Net视网膜血管分割算法,设计融合了残差密集连接模块(residual dense block, ResDB)与三端注意力模块(three-terminal attention gate block, TAG)的ResDBTAGU-Net网络.本文在编码-解码结构中,利用残差密集连接模块代替原来的卷积模块,实现对特征的充分利用,同时加强细小血管的误差传播.在密集连接模块中使用空洞卷积,既能减少参数,又能增加网络的感受野.在解码阶段引入三端注意力模块,利用高级语义信息提高局部区域的特异性,保留更多的细微结构特征,实现更精确地分割结果.

1 本文方法

1.1 残差密集连接模块

残差学习^[18]来自于卷积神经网络,其基本思想是:第 $l-1$ 层的输入特征 a^{l-1} 可以表示为第 l 层网络的拟合函数 $H_l(a^{l-1})$ 和残差映射 $F_l(a^{l-1})$,即 $H_l(a^{l-1}) = a^{l-1} + F_l(a^{l-1})$.此时损失函数 L 对第 l 层权重 w^l 的偏导^[18]为

$$\frac{\partial L}{\partial w^l} = \left(1 + \frac{\partial F_l(a^{l-1})}{\partial w^l}\right) \delta_j^l. \quad (1)$$

从式(1)可以看出,残差学习使得误差信息 δ_j^l 能够直接反向传播,而不受网络激活值与权重等影响.所以本文提出基于残差的残差密集连接模块来代替卷积模块,加强对细小血管特征的提取.残差密集连接模块,一方面利用残差学习加强误差信息的反向传播,加快权重学习过程;另一方面,通过DenseNet^[19]的密集连接模块(DB)提高对特征的利用率.密集连接模块将本层输出与前面所有的输出进行合并作为下一层的输入^[19],即

$$a^l = H_l([a^0, a^1, \dots, a^{l-1}]), \quad (2)$$

其中 $[a^0, a^1, \dots, a^{l-1}]$ 表示合并 $0 \sim l-1$ 层的特征图.残差密集连接模块如图1所示.其中:conv-BN-ReLu(CBR)组成一层特征提取网络,conv表示卷积层,BN表示批量归一化(BN)^[20],ReLu表示修正线性单元(ReLU).由于残差学习与密集连接要求特征通

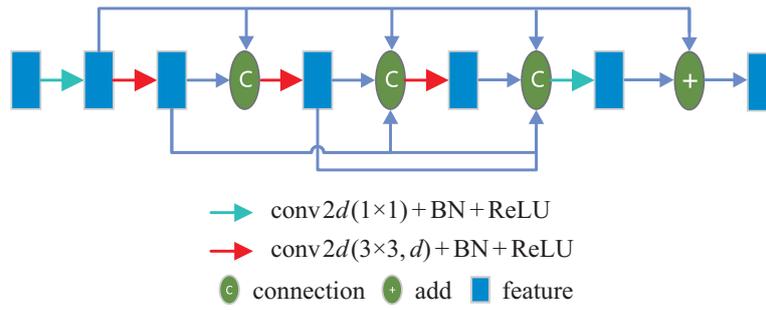


图1 ResDB示意图

道数相同,输入特征首先经过一层卷积核为1×1的CBR层,统一特征通道数为 m .此操作在鼓励特征复用的同时,可以防止网络变宽,减少网络参数数量,提高网络的抗过拟合性.然后,通过3层卷积核为3×3、膨胀率为 d 的conv-BN-ReLu-dropout(CBRD)层,实现多尺度信息的提取与融合.密集连接模块将所有输出的特征进行拼接,并利用卷积核大小为1×1的CBR层压缩特征通道数,解决特征通道数过多、网络变宽的问题^[20].最后,通过跳跃连接将密集连接模块的输入与输出进行相加,加强误差传播,加强对细小血管特征的学习.

1.2 空洞卷积

在提取特征阶段,需要获取充足的特征,才能实现视网膜血管的精确分割.不同区域的视网膜血管其尺度也不同.为了获取多尺度特征,卷积神经网络往往通过增加卷积核大小的方式增大感受野.增加

卷积核大小的方式,在增大感受野的同时会增加参数的数量,导致学习过程漫长和误差收敛缓慢等问题.为了避免产生这类问题,本文使用空洞卷积来代替传统的卷积层.

空洞卷积通过在普通卷积核中插入零值元素的方式增大感受野.在空洞卷积中,膨胀率 d 定义了普通卷积核中插入零值元素的数量.假设空洞卷积的卷积核大小为 k ,膨胀率为 d ,则空洞卷积所对应卷积核的实际大小 s 为

$$s = k + (k - 1)(d - 1). \quad (3)$$

可以看出,空洞卷积在没有增加参数的情况下增大了卷积核的有效尺寸,即增大了感受野.图2为卷积核大小为3×3,膨胀率 d 分别为1(实际大小为3×3)、2(实际大小为5×5)和3(实际大小为7×7)的空洞卷积示意图.

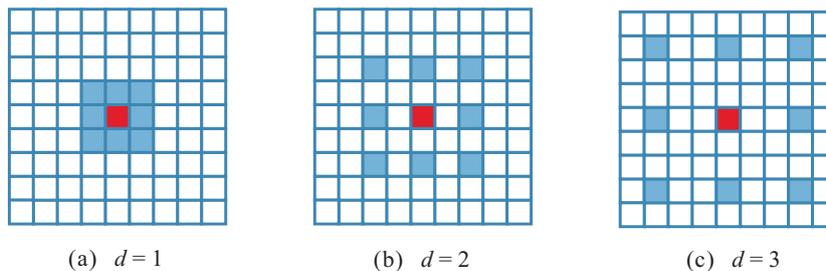


图2 不同膨胀率的空洞卷积示意图

1.3 三端注意力模块

由于视网膜血管的形态、尺寸和分布等复杂多样,保留和传递细节信息,对于算法对抗背景噪声的干扰和提高分割结果的准确率非常重要.在U-Net中,通过跳跃连接的方式,将编码器特征传递到解码器,实现了特征融合,补充了解码器特征的细节信息.这种在同尺度编码器-解码器之间通过剪切和复制传递特征的方式过于简单,无法有效地对视网膜血管复杂的形态与分布进行预测.为了解决这个问题,本文提出了三端注意力模块(three-terminal attention

gate block, TGA),充分利用多尺度特征加强提取和传递与任务相关的信息.该模块定义为

$$x'_l = H(\alpha_l x_l, \text{up}(x'_{l+1})). \quad (4)$$

其中: x_l 为第 l 层解码器的输出特征,即注意力模块的输入特征; $\alpha_l \in [0, 1]$ 为输入特征所对应的注意力系数, α_l 能识别出血管等有用特征和背景噪声等干扰特征,修正所对应特征的响应,保留血管的细节特征,提高分割任务的性能;up为上采样操作,使得特征尺寸一致, x'_{l+1} 为第 $l+1$ 层注意力模块的输入特征, x'_{l+1} 作为高级语义特征,更加关注轮廓、位置等高

级语义信息,对血管的定位与识别有很大帮助,同时 x'_{l+1} 对背景噪声等干扰的响应也比 x_l 弱,利用 x'_{l+1} 包含的高级语义信息,可协助 $\alpha_l x_l$ 自适应地保留血管的特征和抑制背景噪声等干扰特征,提高网络的整体性能; H 为特征融合操作. 三端注意力模块示意图如图3所示. 其中: w_x 是 x_l 的权重, w_g 是解码器输出特

征 g_l 的权重. 首先获取 w_x 和 w_g ; 其次,利用加法实现多尺度特征融合;然后,通过 ReLU、sigmoid 和重采样 (resampler) 得到 α_l 并获取经过空间校正之后的特征 $\alpha_l x'_l$; 最后,通过一层卷积核为 1×1 的 CBR 层将 $\alpha_l x'_l$ 与经过上采样的 x'_{l+1} 在通道方向进行特征融合和压缩通道数,获得最终的 x'_l .

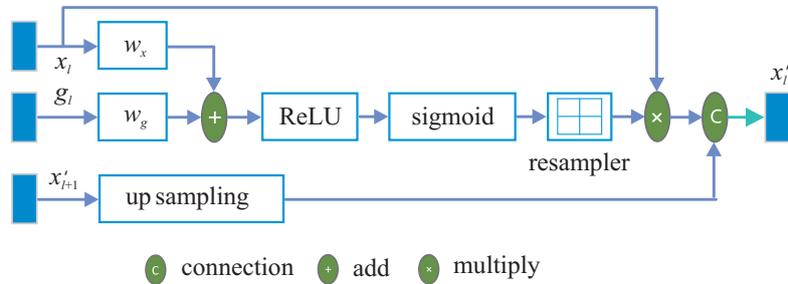


图3 三端注意力模块示意图

1.4 本文网络模型

本文提出的 ResDBTAGU-Net 网络结构如图4所示. 输入的视网膜图像在编码器中,首先经过一层卷积核为 1×1 的 CBR 层,获取通道数为 32 的粗特征;然后,经过一层 ResDB 和三层 ResDB 与下采样,其中卷积核大小为 3×3 ,对应输出特征的通道数为 [32, 64, 96, 128]. 解码器结构与编码器对称. ResDB 中密集连接的增长率 $m = 32$,膨胀率^[21]为 [1, 2, 3]. 将膨胀率^[21]设置为 [1, 2, 3] 起到两方面的作用:一方

面,连续的膨胀率可以克服空洞卷积的网络效应,避免信息的丢失;另一方面,较小的膨胀率将空洞卷积的感受野控制在一定范围内,避免感受野过大造成计算无关的远距离信息. 解码器最后一层由卷积核大小为 1×1 的卷积与 sigmoid 激活函数组成,以获取最后的输出结果. 在每层编码器与解码器之间, TGA 实现对编码器特征的自适应滤波并传递到解码器,实现特征融合与细节信息的保留,有效地降低背景噪声的干扰和提高血管分割精度.

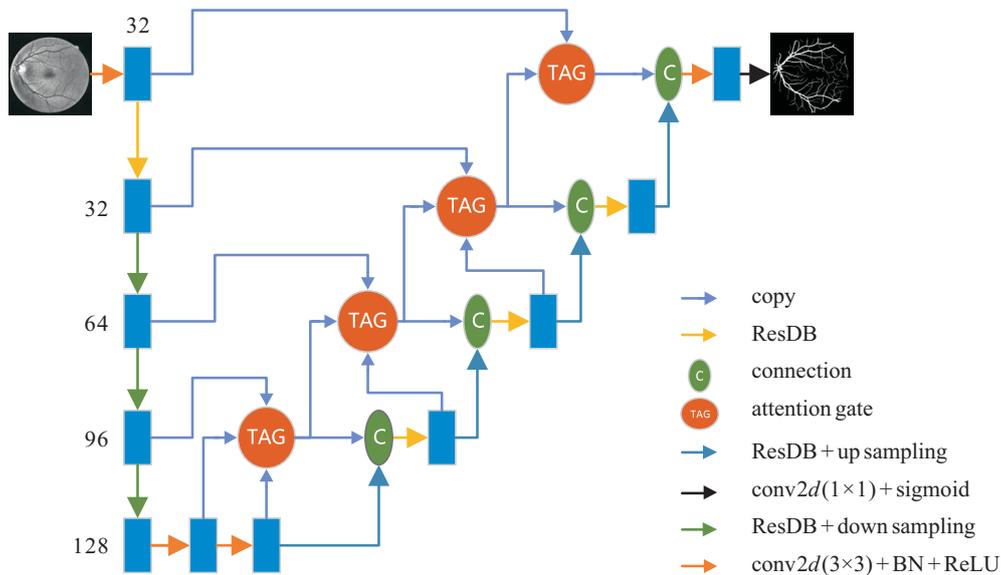


图4 整体网络结构示意图

2 实验结果与分析

2.1 数据集

本文在 DRIVE^[22] 和 STARE^[23] 公共数据集上进行实验. DRIVE 和 STARE 数据集是衡量视网膜血管分割方法性能最常用的数据库. DRIVE 数据集来自

荷兰的糖尿病视网膜病变筛选项目. 其包括 40 幅数字视网膜 RGB 图像,每幅图像的分辨率为 565×584 ,其中 7 幅图像存在早期糖尿病视网膜病变现象. DRIVE 数据集已分为训练集和测试集,每组包括 20 幅图像. STARE 数据集来自由 Michael Goldbaum 发

起的项目,它包括20幅分辨率为 605×700 的视网膜RGB图像。DRIVE和STARE数据集的每幅图像对应两位专家的标注结果。由于STARE数据集未划分训练集和测试集,本文将前10幅作为训练集,后10幅作为测试集。训练过程中以第一观察者的手动分割结果作为标准。测试组中以第一观察者的手动分割结果作为标准,对模型进行评估,并将模型的预测结果与第二观察者的手动分割结果进行对比。

2.2 数据预处理

为了提高分割效果,需要对所获取的视网膜图像进行预处理。视网膜图像的绿色通道对比度高,血管与背景的差异大,噪声小,利于分割血管,因此,本文提取绿色通道作为输入,并经过图像归一化和对比度受限的自适应直方图均衡化算法提高图像的对比度。由于原数据数量较少,为了得到稳定可靠的训练结果,对训练组数据进行数据增强与扩充。首先,将原数据旋转 0° 、 90° 、 180° 和 270° ;然后,进行水平、垂直和镜像翻转扩充至原来的12倍;接着,采用大小为 128×128 、步长为16的滑动窗口将训练图像与第一观察者手动分割结果分割为局部重叠的图像块,如图5所示。

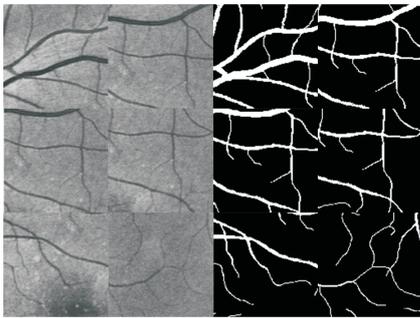


图5 局部图像块

2.3 实验设置

实验环境配置为Intel Xeon E5 CPU @2.5 GHz,显卡为NVIDIA GTX 1080Ti,显卡内存为11 G,内存为32 G。本文模型在Pytorch框架上进行实验,批处理(batch size)设置为20,训练epoch为200。采用Focal loss作为损失函数,并利用Adam算法进行优化,初始学习率为0.001。

2.4 评估指标

为了定量分析模型的性能与分割结果,本文采用准确率(ACC)、灵敏度(SE)和特异性(SP)作为客观评价指标,计算公式为

$$ACC = \frac{T_P + T_N}{T_P + F_P + T_N + F_N}, \quad (5)$$

$$SE = \frac{T_P}{T_P + F_N}, \quad (6)$$

$$SP = \frac{T_N}{T_N + F_P}. \quad (7)$$

其中: T_P 为真阳性,代表正确分割的血管像素个数; T_N 为真阴性,代表正确分割的背景像素个数; F_P 为假阳性,代表错误分割的血管像素个数; F_N 为假阴性,代表错误分割的背景像素个数。以假阳性率(即 $1 - \text{特异性}$)为横坐标、真阳性率(即灵敏度)为纵坐标的受试者工作特性(ROC)曲线可以反映设定不同阈值时的灵敏度和特异性变化的情况。曲线下的面积(AUC)越接近1,说明算法性能越好,即分割效果越好。

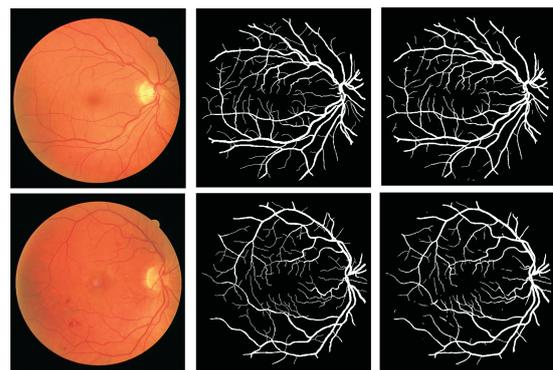
2.5 实验结果

表1列出了ResDBTGAU-Net在DRIVE和STARE数据上的预测结果与两位观察者手动分割结果的对比。可以看出,本文算法在ACC、SE和SP方面均优于相应的第二观察者专家标注的分割结果,可以基本实现视网膜血管分割任务。

表1 DRIVE和STARE数据集的平均性能评估结果

数据集	模型	准确率	灵敏度	特异性	AUC
DRIVE	第二观察者	0.9475	0.7784	0.9724	-
	本文	0.9670	0.8126	0.9820	0.9812
STARE	第二观察者	0.9343	0.8959	0.9354	-
	本文	0.9751	0.8257	0.9837	0.9841

图6给出了部分分割结果。通过与专家手动分割结果对比可知,ResDBTGAU-Net可将背景与血管有效地区分开,所得结果正确率高。从细节上看,结果中细小血管的完整性和连续性较好。



(a) 原始图像 (b) 标准图像 (c) 分割结果

图6 分割结果

2.6 算法改进前后对比

为了进一步说明本文的ResDB和TGA能有效地提升U-Net对视网膜血管的分割性能,本文对原U-Net结构进行调整,并在DRIVE数据集上进行实验对比,结果如表2所示。其中:N1表示原U-Net的分割结果,N2表示利用ResDB代替原U-Net中卷积层的分

割结果, N3表示将TGA与原U-Net进行融合的分割结果, N4表示本文算法的分割结果。

表2 改进前后算法性能指标比较

模型	准确率	灵敏度	特异性	AUC
N1	0.9535	0.7759	0.9782	0.9772
N2	0.9623	0.7985	0.9809	0.9794
N3	0.9665	0.8109	0.9816	0.9803
N4	0.9670	0.8126	0.9820	0.9812

由表2可知:原U-Net对视网膜血管的分割效果已经很好,其ACC、SE、SP和AUC值分别为95.35%、77.59%、98.04%和97.72%,其中SE的值较低。N2利用ResDB代替原U-Net中卷积层,使得ACC、SE和AUC值得到了显著提升,表明ResDB提高了网络提取细小血管特征的能力,使网络的分割性能得到了改善。N3将原U-Net的直接跳跃连接替换为TAG,与N1相比,各项指标的值得到了大幅提升;与N2相比,ACC和SE值提升明显。从而表明TGA能够有效地抑制背景噪声和提高算法的稳定性,提高细小血管分割精度的能力比ResDB强。本文算法在ACC、SE、SP和AUC指标方面与N1相比都有显著提升,且均高于N1和N2的性能指标。从图7的损失函数曲线可以看出,本文算法在训练100次之后,损失函数逐渐趋

于平稳,即训练过程收敛。实验结果表明,ResDB具有很强的特征提取能力,能有效地改善提取细小血管特征的能力。TGA能使网络更加关注与血管相关的特征和抑制背景噪声的影响。本文算法有效地提升了U-Net的分割性能。

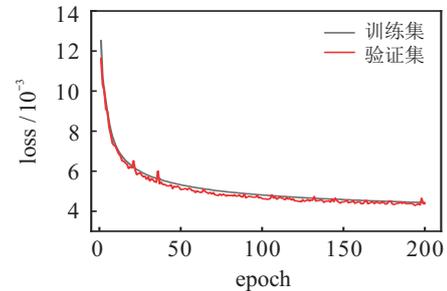


图7 训练过程的损失函数曲线

图8展示了不同算法对局部细小血管的分割效果,其中虚线框标识出了本文算法显著改进细小血管分割精度的区域。可以直观地看出:U-Net的分割结果中末端细小血管分割精度低,连续性差;本文算法对细小血管特征提取能力强且通过TAG自适应地保留细小特征,使得分割结果中细小血管的分割精度高和连续性好,具有一定的临床应用能力。以上结果说明,本文的算法设计,在算法层面上具有一定的合理性与有效性。

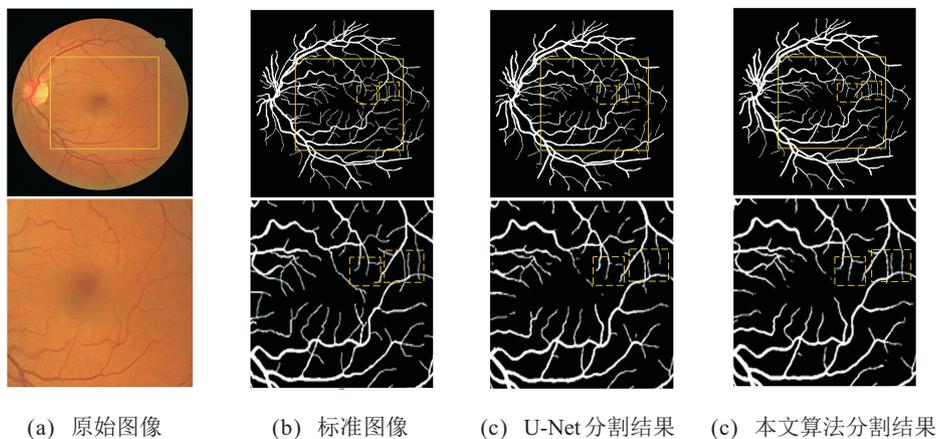


图8 分割结果

2.7 与其他算法进行对比

为了进一步表明本文算法的先进性,使用上述指标将本文算法在DRIVE和STARE数据集上与其他算法进行对比,结果如表3和表4所示。

基于DRIVE数据集的对比,本文算法的ACC、SE、SP和AUC值分别为96.70%、81.26%、98.20%和98.12%,均优于除了文献[25]的其他基于有监督和无监督的算法。文献[25]与本文算法的SE值共同取得最大值,表明文献[25]与本文算法能很好地识别背景像素。但是,从文献[25]的其他指标均低于本文

算法可以看出,文献[25]仅引入空洞卷积来扩大感受野,未能准确地识别细小血管。基于STARE数据集的对比,本文算法的ACC、SP和AUC值分别为97.51%、82.57%和98.41%,均高于其他基于有监督和无监督的算法。在SE值方面,本文算法低于文献[17]和文献[26]。但是,本文算法的ACC、SP和AUC值高于文献[17]和文献[26],说明文献[17]和文献[26]识别背景像素的准确率高,同时将血管像素误判为背景像素的风险也大。以上实验结果表明,本文算法能更准确地识别和分割细小血管。

表 3 DRIVE数据集上与其他方法的性能指标对比

类型	模型	年份	准确率	灵敏度	特异性	AUC
无监督	文献[10]	2018	0.9540	0.7680	0.9700	0.9700
	文献[7]	2019	0.9380	0.5690	0.9930	—
	文献[8]	2019	0.9460	0.7880	0.9730	—
	文献[3]	2020	0.9522	0.7681	0.9747	—
有监督	文献[12]	2018	0.9542	0.7653	0.9818	0.9752
	文献[17]	2019	0.9556	0.7963	0.9800	0.9802
	文献[24]	2019	0.9541	0.7648	0.9817	—
	文献[25]	2019	0.9538	0.7631	0.9820	0.9750
	文献[26]	2020	0.9519	0.7761	0.9792	—
	本文	2021	0.9670	0.8126	0.9820	0.9812

表 4 STARE数据集上与其他方法的性能指标对比

类型	模型	年份	准确率	灵敏度	特异性	AUC
无监督	文献[10]	2018	0.9570	0.7810	0.9770	0.9680
	文献[7]	2019	0.9460	0.6380	0.9820	—
	文献[8]	2019	0.9430	0.7930	0.9580	—
	文献[3]	2020	0.9513	0.6713	0.9731	—
有监督	文献[12]	2018	0.9542	0.7653	0.9818	0.9752
	文献[17]	2019	0.9640	0.7595	0.9878	0.9832
	文献[24]	2019	0.9541	0.7648	0.9817	—
	文献[25]	2019	0.9538	0.7631	0.9820	0.9750
	文献[26]	2020	0.9704	0.8120	0.9895	—
	本文	2021	0.9751	0.8257	0.9837	0.9841

综上所述,本文提出的ResDBTAGU-Net网络对细小血管的分割精度高,具有一定的稳定性和抵抗背景噪声干扰的能力,能够有效地完成视网膜血管分割任务。

3 结 论

针对视网膜血管中细小血管难以分割的问题,本文提出了一种改进U-Net的分割算法。首先,细小血管的误差在反向传播过程中误差较小,对权重更新过程中的贡献低,是导致细小血管难分割的原因。ResDB利用残差学习改善了细小血管的误差反向传播过程,同时,利用密集连接提升了网络提取细小血管特征的能力。ResDB代替传统的卷积模块提升了网络分割细小血管的性能。在残差密集连接中,利用空洞卷积,在不增加参数数量的情况下,增加了感受野。在解码过程中,引入三端注意力模块,利用高级语义特征引导注意力模块自适应地保留血管细节和抑制背景噪声,提升了网络的分割性能。实验结果表明,本文算法优于其他算法,能显著提升U-Net的分割性能。本文算法改善了U-Net对细小血管的分割性能,提高了网络的分割精度。在后续工作中,将继续开发此算法,并将其应用到其他医学影像分割任务中。

参考文献(References)

- [1] Fraz M M, Remagnino P, Hoppe A, et al. Blood vessel segmentation methodologies in retinal images — A survey[J]. Computer Methods and Programs in Biomedicine, 2012, 108(1): 407-433.
- [2] Shao F, Yang Y, Jiang Q P, et al. Automated quality assessment of fundus images via analysis of illumination, naturalness and structure[J]. IEEE Access, 2018, 6: 806-817.
- [3] Yang J Z, Huang M X, Fu J, et al. Frangi based multi-scale level sets for retinal vascular segmentation[J]. Computer Methods and Programs in Biomedicine, 2020, 197: 105752.
- [4] 罗凌, 薛定宇, 冯兴隆. 基于紧凑混合网络的视网膜血管自动分割[J]. 控制与决策, 2022, 37(2): 353-360. (Luo L, Xue D Y, Feng X L. Automatic segmentation of retinal vessel via compact mixed network[J]. Control and Decision, 2022, 37(2): 353-360.)
- [5] Li X, Jiang Y C, Li M L, et al. Lightweight attention convolutional neural network for retinal vessel image segmentation[J]. IEEE Transactions on Industrial Informatics, 2021, 17(3): 1958-1967.
- [6] Dash J, Bhoi N. Retinal blood vessel extraction using

- morphological operators and Kirsch's template[M]. Singapore: Springer, 2019: 603-611.
- [7] 汪维华, 张景中, 吴文渊. 改进的形态学与Otsu相结合的视网膜血管分割[J]. 计算机应用研究, 2019, 36(7): 2228-2231.
(Wang W H, Zhang J Z, Wu W Y. New approach to segment retinal vessel using morphology and Otsu[J]. Application Research of Computers, 2019, 36(7): 2228-2231.)
- [8] 许言兵, 周阳, 李灿标, 等. 基于超像素仿射传播聚类的视网膜血管分割[J]. 光学学报, 2020, 40(2): 60-70.
(Xu Y B, Zhou Y, Li C B, et al. Retinal vessel segmentation based on super-pixel affinity propagation clustering[J]. Acta Optica Sinica, 2020, 40(2): 60-70.)
- [9] Ali A, Wan Zaki W M D, Hussain A. Blood vessel segmentation from color retinal images using K -means clustering and 2D Gabor wavelet[M]. Cham: Springer International Publishing, 2017: 221-227.
- [10] Na T, Xie J Y, Zhao Y T, et al. Retinal vascular segmentation using superpixel-based line operator and its application to vascular topology estimation[J]. Medical Physics, 2018, 45(7): 3132-3146.
- [11] Guo F, Li W Q, Kuang Z H, et al. MES-Net: A new network for retinal image segmentation[J]. Multimedia Tools and Applications, 2021, 80(10): 14767-14788.
- [12] Yan Z Q, Yang X, Cheng K T. Joint segment-level and pixel-wise losses for deep learning based retinal vessel segmentation[J]. IEEE Transactions on Bio-Medical Engineering, 2018, 65(9): 1912-1923.
- [13] Wang D Y, Haytham A, Pottenburgh J, et al. Hard attention net for automatic retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2020, 24(12): 3384-3396.
- [14] Park K B, Choi S H, Lee J Y. M-GAN: Retinal blood vessel segmentation by balancing losses through stacked deep fully convolutional networks[J]. IEEE Access, 2020, 8: 146308-146322.
- [15] Ronneberger O, Fischer P, Brox T. U-net: Convolutional networks for biomedical image segmentation[M]. Cham: Springer International Publishing, 2015: 234-241.
- [16] Alfonso Francia G, Pedraza C, Aceves M, et al. Chaining an U-net with a residual U-net for retinal blood vessels segmentation[J]. IEEE Access, 2020, 8: 38493-38500.
- [17] Jin Q G, Meng Z P, Pham T D, et al. DUNet: A deformable network for retinal vessel segmentation[J]. Knowledge-Based Systems, 2019, 178: 149-162.
- [18] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition[C]. IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas, 2016: 770-778.
- [19] Huang G, Liu Z, van der Maaten L, et al. Densely connected convolutional networks[C]. IEEE Conference on Computer Vision and Pattern Recognition. Honolulu, 2017: 2261-2269.
- [20] Ioffe S, Szegedy C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[C]. The 32nd International Conference on International Conference on Machine Learning. Lille: JMLR, 2015: 448-456.
- [21] Fu Q L, Li S Q, Wang X. MSCNN-AM: A multi-scale convolutional neural network with attention mechanisms for retinal vessel segmentation[J]. IEEE Access, 2020, 8: 163926-163936.
- [22] Staal J, Abramoff M D, Niemeijer M, et al. Ridge-based vessel segmentation in color images of the retina[J]. IEEE Transactions on Medical Imaging, 2004, 23(4): 501-509.
- [23] Hoover A D, Kouznetsova V, Goldbaum M. Locating blood vessels in retinal images by piecewise threshold probing of a matched filter response[J]. IEEE Transactions on Medical Imaging, 2000, 19(3): 203-210.
- [24] Wang X H, Jiang X D, Ren J F. Blood vessel segmentation from fundus image by a cascade classification framework[J]. Pattern Recognition, 2019, 88: 331-341.
- [25] Yan Z Q, Yang X, Cheng K T. A three-stage deep learning model for accurate retinal vessel segmentation[J]. IEEE Journal of Biomedical and Health Informatics, 2019, 23(4): 1427-1436.
- [26] Zou B J, Dai Y L, He Q, et al. Multi-label classification scheme based on local regression for retinal vessel segmentation[J]. IEEE/ACM Transactions on Computational Biology and Bioinformatics, 2021, 18(6): 2586-2597.

作者简介

曹飞道(1991—), 男, 博士生, 从事医学图像优化与分割的研究, E-mail: caofeidao@sia.cn;

赵怀慈(1974—), 男, 研究员, 博士生导师, 从事图像处理、虚拟环境仿真和三维重建等研究, E-mail: hczhao@sia.cn.

(责任编辑: 李君玲)