基于改进卷积神经网络的视网膜血管图像分割

吴晨玥,易本顺*,章云港,黄松,冯雨

武汉大学电子信息学院,湖北 武汉 430072

摘要 彩色眼底图像视网膜血管分割对于临床医学诊断有重要价值。提出了一种基于改进卷积神经网络的视网 膜血管分割方法。首先,将残差学习和密集连接网络(DenseNet)相结合,更充分地利用每一层的特征;通过增加短 连接的方式,缩短了低层特征图到高层特征图之间的路径,强化了特征的传播能力。其次,为了提取更多细小血管,在编码器-解码器结构的网络中加入了空洞卷积,在不增加参数的情况下增加感受野。实验结果表明,与现存其 他深度学习方法相比,所提出网络结构的参数数量更少,在 DRIVE 标准数据集上平均准确率达到 0.9556,灵敏度 达到 0.8036,特异性达到 0.9778,受试者工作特性(ROC)曲线下的面积(AUC)达到 0.9800,比现存其他深度学习方 法的分割效果更优。

关键词 图像处理;图像分割;视网膜血管;卷积神经网络;深度学习 中图分类号 TP391 **文献标识码** A

doi: 10.3788/AOS201838.1111004

Retinal Vessel Image Segmentation Based on Improved Convolutional Neural Network

Wu Chenyue, Yi Benshun*, Zhang Yungang, Huang Song, Feng Yu Electronic Information School, Wuhan University, Wuhan, Hubei 430072, China

Abstract The retinal vessel segmentation in color fundus images is of great value for the clinical diagnosis and a retinal vessel segmentation method based on an improved convolutional neural network is proposed. First, the residual learning is combined with the densely connected network (DenseNet) to fully exploit the feature maps of each layer. The path from the low-level feature maps to the high-level ones via the addition of shortcuts is shortened and the feature propagation ability is strengthened. Second, as for the extraction of more fine vessels, the dilated convolutions are adopted in the encoder-decoder network to expand the receptive field without the increase of parameters. The experimental results show that the proposed network structure has less parameters, compared with the other existing deep learning methods. The average accuracy on the DRIVE datasets is up to 0.9556, the sensitivity is up to 0.8036, the specificity is up to 0.9778, the area under curve of receiver operating characteristic reaches 0.9800, better than the segmentation effects of the other existing deep learning methods.

Key words image processing; image segmentation; retinal vessels; convolutional neural network; deep learning OCIS codes 100.3008; 100.5010; 110.2970

1 引 言

视网膜血管是人体唯一可以通过无创伤手段观察到的清晰血管,目前医学研究表明^[1],视网膜血管 异常与高血压、冠心病、糖尿病等心血管疾病严重程 度有很大关系,视网膜血管的病变可能发生在发病 之前,因此彩色眼底图像的视网膜血管检测对于预 测、诊断和治疗心血管疾病有重要的应用价值。然 而,视网膜上血管分布错综复杂且往往有病变干扰, 但是由于眼底照相机的照明与成像方式的局限 性^[2],彩色眼底图像中血管末梢与背景的对比度低, 且往往存在噪声、光照不均匀的问题,视网膜血管难 以完全分割,人工标注耗时耗力,且存有较大的主观 性。因此,视网膜血管自动分割技术一直是眼底图 像分析领域的热点和难点。

多年来,国内外专家学者提出了大量方法并取 得了一定的成果,这些方法可分为5类^[3]:基于血管 跟踪的方法、基于匹配滤波的方法、基于形态学处理 的方法、基于形变模型的方法和基于机器学习的方 法,其中基于机器学习的方法分割血管的精度最高。

收稿日期: 2018-04-18; 修回日期: 2018-06-04; 录用日期: 2018-06-13

^{*} E-mail: yibs@whu.edu.cn

通过其他方法进行特征提取,用机器学习方法进行 特征训练和分割为目前最常用的方法。文献[4]提 出基于组合移位滤波响应的特征提取方法,并将提 取的特征输入 AdaBoost 分类器以对视网膜血管进 行检测。文献[5]提出一种具有自适应连接值的脉 冲耦合神经网络与高斯匹配滤波器相结合的视网膜 血管分割方法实现眼底图像中血管区域的自动生 长。文献[6]提出基于全连接条件随机场的方法进 行血管分割,条件随机场的参数则用结构化输出支 持向量机进行学习。

近年来,随着深度学习的发展,卷积神经网络 (CNN)作为深度学习的重要分支,通过局部感受野 和权值共享减少了所需要训练的参数,使卷积神经 网络能快速处理高维图像,并具有平移不变性,其强 大的自动学习特征能力也使其能捕捉目标的高层语 义信息,因此在图像识别、语义分割、目标检测等领 域有极大的优势,其应用也更加广泛[7-8]。在彩色眼 底图像视网膜血管分割方面,有别于传统的先手动 提取特征、再选择合适的分类器来分割眼底图像中 血管的方法,CNN 将特征提取和分类器设计融于一 个深层模型中,通过大量样本的训练来自动学习各 种场景下的血管特征,具有更好的泛化能力和稳健 性。文献「9]提出一种 CNN 方法,将血管分割视为 一个是否为血管的二分类任务,用 CNN 进行逐像 素分类,并结合结构化预测方法,同时对多个像素点 进行分类,其结果优于许多传统算法,对细小血管的 检测也有很好的效果,但其网络拥有千万级的参数 量。文献「10]提出一种多级卷积神经网络,拥有多 级输入,同时将源图像和经过最大池化处理的图像 输入该网络,并在网络中加入 dropout 层与 spatialdropout 层,这种网络具有应用于其他类型图像分 类的潜力,但多级输入意味着多个平行网络支路,从 而增加了网络的计算量。

针对眼底图像中细小血管难以提取的问题,本 文提出一种改进的基于编码器-解码器结构的全卷 积神经网络,其网络主要有两个特点:首先,将残差 学习^[11]和 DenseNet^[12]结构相结合的残差密集连接 结构引入网络,通过残差学习使网络更容易优化,更 充分地利用每一层的特征图信息,缩短了低层特征 图到高层特征图之间的路径,强化了特征的传播能 力,从而增强网络的性能;其次,将空洞卷积与编解 码器结构相结合,编解码结构网络具有强大的提取 感兴趣区域的能力,但在编码阶段丢失的细节信息 无法在解码阶段很好地复原,空洞卷积以不增加网 络参数数量的形式增大了网络的感受野,从而能获 取更多的细节结构信息,本文将两者相结合,在准确 地提取血管特征的同时,能保留更多的细小血管。

2 网络结构

2.1 残差密集连接模块

残差学习的基本思想是,假设网络的输入为 x, 要拟合的函数映射(即输出)为 H(x),残差学习认 为学习拟合一个残差映射 F(x)=H(x)-x 比直 接学习拟合一个近似恒等映射 H(x)更加容易,在 网络较深的情况下避免了梯度消失现象的发生。

DenseNet 的密集连接模块(DB)将前层结果与本层结果合并作为下一层的输入,设网络第 *l* 层的输出为 *x*_l,则一个密集连接模块第 *l* 层的输出可表示为

 $x_{l} = H_{l}([x_{0}, x_{1}, \dots, x_{l-1}]),$ (1) 式中 $H_{l}(\cdot)$ 表示第 l 层的非线性映射, $[x_{0}, x_{1}, \dots, x_{l-1}]$ 表示将 $0 \sim (l-1)$ 层输出的特征图合并。这种 密集连接结构缩短了前后层的距离,因此强化了特 征的传播,由于将各层输出的特征图合并,提高了每 层输出的特征图的利用率,鼓励了特征图的复用,因 此可以减少输出特征图数量,固定设置输出特征图 数量为 k,称为增长率^[12],这使得整体网络变窄,大 幅度减少了网络的参数数量,从而增加了小数据集 的抗过拟合性。

DenseNet 结构能充分利用所有输出特征图的 信息,而在密集连接层中加入残差学习可以进一步 强化特征传播,提升网络性能^[13]。因此,将残差学 习与 DenseNet 结构相结合,设计了残差密集连接 模块(RDB),其结构如图1所示。其中,BN-ReLU-Conv 三部分组成一层, BN 表示批量归一化(BN), ReLU 表示修正线性单元(ReLU), Conv 表示卷积 层,对每一层都进行密集连接,每层输出的特征图数 量均为 k,然后将每一层输出的特征图合并输入 Compression 层。Compression 层是核大小为 1×1 的卷积层,其目的是对特征图数量进行压缩,解决密 集连接层层数增加导致输出的特征图数量增多、网 络变宽的问题。假设 Compression 层输入的特征图 数量为m,设置压缩率记为 $\theta(0 < \theta < 1)$,则压缩后 的特征图数量为 $\theta \cdot m$,本文取 $\theta = 0.5$ 。Compression 层可以避免网络过宽,提高模型的紧凑性,并提高计 算效率。最后,通过一个短连接将前层输出(即本 RDB 的输入)与 Compression 层的输出相加,使得 网络更容易优化,并进一步提升网络的性能。



Fig. 1 Schematic of RDB

2.2 空洞卷积

CNN应用于图像语义分割的一个问题是使用 池化层、增加步长减小特征图尺寸会导致图像细节 结构丢失,从而导致分割结果不够精细^[14]。为应对 这个问题,部分研究者们提出了基于编码器-解码器 结构的全卷积神经网络^[14]并不断改进,如U-Net^[15]、 SegNet^[16],通过编码器结构逐步减小特征图从而学 习图像抽象特征,通过解码器结构将图像恢复到原 始大小,但解码器不能很好地恢复丢失的图像细节 结构,因此部分研究者^[17]提出去掉池化层,并使用 空洞卷积以不增加参数数量的方式增大感受野,从 而保留更多的图像细节结构。但网络越深,特征图 数量越多,保持特征图尺寸与原图一致则会带来更 大的计算量。因此,本文在基于编、解码器的全卷积 神经网络的结构上将一般卷积替换为空洞卷积,从 而提取出更多的细小血管。

空洞卷积可以看成带孔的卷积,其基本原理是 在普通卷积核的每个像素之间插入孔(即像素值为 0的像素),以不增加网络参数数量的形式增大了感 受野,如图 2 所示,从左到右分别为普通的 3×3 卷 积核,即扩张率(记为 r)分别为 r=1 的空洞卷积 核,r=2 的空洞卷积核(实际大小为 5×5),r=3 的 空洞卷积核(实际大小为 7×7)。



Fig. 2 Schematic of dilated convolutions under different dilation rates. (a) r=1; (b) r=2; (c) r=3

2.3 视网膜血管分割网络模型

针对视网膜图像特征的复杂性(如光照、病变 等因素干扰),设计了基于编码器-解码器结构的网 络模型,引入 RDB改善深层网络优化困难的问题, 进一步提升网络性能,并使得每一层所得的血管 特征得以反复利用,同时大幅减少网络参数数量, 使得视网膜血管图像的训练不容易过拟合;将普 通卷积替换成空洞卷积增大了网络的感受野,从 而使网络保留图像细节结构,提取出更多细小 血管。

本文算法的网络结构如图 3 所示,可分为编码 器部分和解码器部分。编码器部分将具有 16 个 3×3大小的卷积核的卷积层作为第一层,随后有 4个RDB结构(层数分别为4,8,6,4),每一层输出 的特征图均为 12, 即增长率 k = 12, 其中 RDB 1 中 在 compression 层后局部特征融合之前添加了一个 核大小为2×2、步长为2的最大池化层,将特征图 的长宽缩小到原来的 1/2,4 个 RDB 的卷积层都为 空洞卷积。由于空洞卷积核的不连续性,用多个具 有相同扩张率的空洞卷积进行叠加会导致空间信息 不连续,因此 RDB 1 采用 r=2 的空洞卷积,其余三 个 RDB 的每一个卷积层都采用不同的扩张率, RDB 2的扩张率分别为 2,2,4,8,8,4,2,2; RDB 3 的扩张率分别为 2,4,8,8,4,2; RDB_4 的扩张率分 别为 2,4,4,2。此外,为进一步提高计算效率,本文 在 RDB 2、RDB 3、RDB 4 中设置了 Bottleneck 层, 即在每一个 BN-ReLU-Conv 层前加入 1×1 的卷积 层对每层输入的特征图数量进行压缩,将输入到每 一个 BN-ReLU-Conv 层的特征图数量固定为 48。 解码器部分由 Upsampling 层和卷积层组成,其中 Upsampling 层是核大小为 3×3、步长为 2 的反卷 积层,输出的特征图大小与上层相同,其对特征图 上采样将特征图恢复为原尺寸。由于上采样会造 成一部分图像细节丢失,因此通过一条全局短连 接将上采样层的输出与编码器中相同大小的特征 图合并,然后通过 3×3×32 的卷积层和 1×1×2 的卷积层。最后,解码器的结果通过 SoftMax 分类 器输出。



3 实验结果分析

进行实验仿真的计算机硬件配置为 Intel Core

i7-6850K 与 Nvidia GeForce GTX1080Ti,使用以 TensorFlow 作为后端的 Keras 开源库训练和测试 网络模型。

3.1 数据集与预处理

本文在 DRIVE^[18]公共数据集上进行实验, DRIVE 数据集是从荷兰的糖尿病视网膜病变筛查 项目中获得。其图像是从 25~90 岁之间的 400 名 糖尿病受试者拍摄的眼底图像中随机抽取的 40 张 图像,其中 20 张作为训练集,20 张作为测试集。每 幅图像均被裁剪为 584×565 大小,并对应有专家手 动分割的结果和掩模图像。

由于眼底图像中存在光照不均、血管与背景对 比度低等因素影响,为了更好地分割出视网膜血管, 本文对 DRIVE 数据集中的每一幅图像进行如下处 理:首先将其转化为灰度图像,然后采用对比度受限 制的自适应直方图均衡化(CLAHE)算法改善视网 膜图像光照不均匀的问题并增强图像的对比度^[19], 接着采用尺寸为 64×64、步长为 16 的滑动窗口将 图像分为局部重叠的图像块。

3.2 训练

由于 DRIVE 数据集本身较小,为防止网络过 拟合,本文对训练数据集进行数据增强。将经过预 处理的训练图像分别旋转 0°、90°、180°、270°之后, 分别对其进行水平和垂直翻转,扩充至原来训练集 的 12 倍。在输入网络之前,随机对训练集中的图像 进行 Gamma 矫正(γ 范围为[0.5,2.0])、高斯模糊处 理(核大小为 3×3)以及添加 σ =0.01 的高斯白噪声。

网络参数的权重初始化采用 He 正态分布方法^[20],采用交叉熵函数作为损失函数,其计算公式为

$$L = -\sum_{i} \mathbf{y}_{i} \ln(\hat{\mathbf{y}}_{i}), \qquad (2)$$

式中 *i* 表示分类个数,y 表示实际值,ŷ 表示模型预测值。本文采用 Adam 算法^[21]对损失函数进行优化,初始学习率为0.001。训练时,在 4 个 RDB 块中加入 dropout 层,参数设置为0.2;采用 L2 范数进行 正则化,权重衰减值设置为0.001,训练的 batch size 取 32,epoch 设置为100。

3.3 性能评价指标

为了定量分析检验网络性能和分割结果,本文 采用准确率、灵敏度和特异性这三个通用指标来客 观评价视网膜血管的分割效果。这三个指标的计算 公式为

$$R_{\text{Accuracy}} = \frac{T_{\text{P}} + T_{\text{N}}}{T_{\text{P}} + F_{\text{P}} + T_{\text{N}} + F_{\text{N}}}, \qquad (3)$$

$$R_{\text{Sensitivity}} = \frac{T_{\text{P}}}{T_{\text{P}} + F_{\text{N}}},\tag{4}$$

$$R_{\text{Specificity}} = \frac{T_{\text{N}}}{T_{\text{N}} + F_{\text{P}}},\tag{5}$$

式中 $T_{\rm P}$ 为真阳性,指分割正确的血管像素个数, $T_{\rm N}$ 为真阴性,指分割正确的背景像素个数, $F_{\rm P}$ 为 假阳性,指分割错误的血管像素个数, $F_{\rm N}$ 为假阴 性,指分割错误的背景像素个数。

受试者工作特性(ROC)曲线也是衡量视网膜血 管分割标准的重要曲线,其以假阳性率(即1-特异性) 为横坐标,以真阳性率(即灵敏度)为纵坐标,反映了 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)为 ROC 曲线下方的面积,AUC 越接 近1,说明算法性能越好,分割效果越好。本文采用 AUC 作为其中一个评价指标,采用 Python 开源库 中的 scikit-learn 库绘制 ROC 曲线并计算 AUC。

3.4 实验结果

本文在 DRIVE 数据集的测试集上进行实验。 图 4 展示了本文方法主观效果,并与同采用深度学 习方法具有较高准确率的文献[9]方法进行比较,从 上往下分别为两组健康视网膜图像及其分割结果图 像和一组有病变区域的图像及其分割结果图像, 图 4(a)为源图像,图 4(b)为专家手工分割的金标准 图像,图 4(c)为由文献[9]方法分割的结果,图 4(d) 为本文算法结果。从总体上看,与文献[9]的结果相 比,本文算法结果的噪点更少;从细节上来看(红框 内),本文算法所得结果的细小血管保留更加完整, 血管更具有连续性;在有视网膜病变的图像中,可以 看出,文献[9]算法更容易受病变区域影响。

图 5 为本文方法与文献[9]方法的分割结果 ROC 曲线,本文算法的 ROC 曲线比文献[9]算法更 接近左上角,说明在相同假阳性率的情况下,相比文 献[9]方法,本文方法正确分割的血管数更多,算法 性能更好。

表1为本文方法与其他眼底图像分割方法在 DRIVE数据集上分割性能的对比,由于图像中非血 管部分所占比重极大,本文方法只取图像中眼底区 域计算性能指标,对比算法的结果来自于原文献。 由表1可知,本文方法在分割准确率和灵敏度上均 优于其他算法,在AUC上优于已有的深度学习算 法,在特异性上略低于已有算法,但只比最高的文 献[10]算法低了 0.0058,在灵敏度上比文献[10]算 法高了 0.057,说明本文算法性能优异,能分割出更 多细小血管。



图 4 本文算法与文献[9]算法的分割效果。(a)源图像;(b)金标准图像;(c)文献[9]结果;(d)本文算法结果 Fig. 4 Segmentation results by proposed method and method in Ref. [9]. (a) Original images; (b) ground truth; (c) results in Ref. [9]; (d) results by proposed method





(a) ROC curves; (b) curves in red box of Fig. (a) $% \left({{\left({{{\bf{n}}} \right)}_{{{\bf{n}}}}} \right)$

TT 1 1 1	D 1	1		C			1.00	1 • 1	DDT	1711	1
Lable L	Refinal	vessel	segmentation	performance	comparison	among	different	algorithms	on DRL	VF.	datasets
r ubic r	rectinai	100001	Segmentation	periormanee	comparison	among	unicient	angommin	on Ditt	· L	aatabetb

	Method	Accuracy	Sensitivity	Specificity	AUC
	Method in Ref. [4]	0.9489	0.7657	0.9809	-
Traditional	Method in Ref. [5]	0.9539	0.7039	0.9783	-
method	Method in Ref. [6]	-	0.7897	0.9684	-
	Method in Ref. [22]	0.9457	0.7527	0.9744	-
D 1 .	Method in Ref. [9]	0.9535	0.7811	0.9807	0.9765
Deep learning	Method in Ref. [10]	0.9533	0.7464	0.9836	0.9752
method	Proposed method	0.9556	0.8036	0.9778	0.9800

文献[9]方法和本文深度学习算法的网络参数 数量分别为 48 M 和 4.4 k,文献[10]未给出具体的

网络参数,无法计算参数数量。可以看出,本文算法 网络具有更少的参数,计算效率大幅度提升。

3.5 网络结构的影响

对网络分别进行以下调整:1) 删去了 RDB 结构 中的短连接,即去掉残差学习,转为普通的密集连接 模块结构,该网络记为 Network_1;2) 不使用空洞卷 积,即扩张率 r=1,该网络记为 Network_2;3) 设置所 有空洞卷积的扩张率 r=2,该网络记为 Network_3; 4) 4 个 RDB 采用不同扩张率的空洞卷积,RDB_1、 RDB_2、RDB_3 和 RDB_4 的空洞卷积扩张率分别 为 2、4、8 和 2,该网络记为 Network_4。

表 2 对比了调整后的 4 个网络与本文所提网络 在 DRIVE 数据集上的性能差别。从表 2 可以看 出:1)将残差学习和密集连接相结合的 RDB 结构在 视网膜血管分割方面比一般密集连接结构具有更好 的性能;2)使用空洞卷积比未使用空洞卷积的网络 性能更好;3)所提网络结构采用的空洞卷积方案比 采用连续多个相同扩张率的空洞卷积效果更好。

表 2 不同网络结构在 DRIVE 数据集上的 视网膜血管分割性能对比

Table 2Retinal vessel segmentation performance comparisonamong different network structures on DRIVE datasets

Method	Accuracy	Sensitivity	Specificity	AUC
Network_1	0.9537	0.7897	0.9777	0.9780
Network_2	0.9537	0.7968	0.9766	0.9772
Network_3	0.9542	0.7986	0.9768	0.9784
Network_4	0.9548	0.7973	0.9778	0.9792
Proposed	0.9556	0.8036	0.9778	0.9800

4 结 论

针对彩色眼底图像视网膜血管手工分割难度 大、细小血管难以分割的问题,提出了一种改进的卷 积神经网络方法。首先,将残差密集连接结构引入 网络,密集连接结构强化了特征图的传播并大幅减 少了网络参数数量,而残差学习使网络更容易优化, 两者结合更进一步提升了网络的性能。其次,将空 洞卷积引入编、解码器结构网络中,在准确提取血管 图像的同时保留了更多的细小血管。与其他传统方 法和深度学习方法相比,本文算法准确率和灵敏度 更高;与现有准确度较高的深度学习算法相比,本文 算法在大幅减少网络参数、提高计算效率的同时,细 小血管的保留更加完整,分割性能更好。

参考文献

[1] Wong T Y, Klein R, Sharrett A R, *et al*. Retinal arteriolar diameter and risk for hypertension[J].

Annals of Internal Medicine, 2004, 140(4): 248-256.

- [2] Wang X H, Xue Q S. Optical design of portable nonmydriatic fundus camera with large field of view[J]. Acta Optica Sinica, 2017, 37(9): 0922001.
 王晓恒,薛庆生.大视场手持式免散瞳眼底照相机光 学设计[J].光学学报, 2017, 37(9): 0922001.
- [3] Zhu C Z, Zou B J, Xiang Y, et al. A survey of retinal vessel segmentation in fundus images[J]. Journal of Computer-Aided Design & Computer Graphics, 2015, 27(11): 2046-2057.
 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.
- [4] Huang W B, Wang K, Yan Y. Automatic detection method of blood vessel for color retina fundus images[J]. Optics and Precision Engineering, 2017, 25(5): 1378-1386.
 黃文博,王珂,燕杨.彩色视网膜眼底图像血管自动 检测方法[J].光学 精密工程, 2017, 25(5): 1378-1386.
- [5] Xu G Z, Zhang L, Zou Y B, et al. Retinal blood segmentation with adaptive PCNN and matched filter[J]. Optics and Precision Engineering, 2017, 25(3): 756-764.
 徐光柱,张柳,邹耀斌,等. 自适应脉冲耦合神经网络与匹配滤波器相结合的视网膜血管分割[J].光学精密工程, 2017, 25(3): 756-764.
- [6] Orlando J I, Prokofyeva E, Blaschko M B. A discriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images[J]. IEEE Transactions on Biomedical Engineering, 2017, 64(1): 16-27.
- [7] Gao L, Wang J F, Fan Y, et al. Robust visual tracking based on convolutional neural networks and conformal predictor [J]. Acta Optica Sinica, 2017, 37(8): 0815003.
 高琳, 王俊峰, 范勇, 等. 基于卷积神经网络与一致 性预测器的稳健视觉跟踪 [J]. 光学学报, 2017, 37(8): 0815003.
- [8] Li S M, Lei G Q, Fan R. Depth map superresolution reconstruction based on convolutional neural networks[J]. Acta Optica Sinica, 2017, 37(12): 1210002.

李素梅, 雷国庆, 范如. 基于卷积神经网络的深度图 超分辨率重建[J]. 光学学报, 2017, 37(12): 1210002.

- [9] Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks[J]. IEEE Transactions on Medical Imaging, 2016, 35 (11): 2369-2380.
- [10] Ngo L, Han J H. Multi-level deep neural network for efficient segmentation of blood vessels in fundus

images[J]. Electronics Letters, 2017, 53(16): 1096-1098.

- [11] He K, Zhang X, Ren S, et al. Deep residual learning for image recognition[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2016: 770-778.
- [12] Huang G, Liu Z, Maaten L, et al. Densely connected convolutional networks[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2017: 2261-2269.
- [13] Zhang Y, Tian Y, Kong Y, et al. Residual dense network for image super-resolution[C] // IEEE Conference on Computer Vision and Pattern Recognition, 2018.
- [14] Shelhamer E, Long J, Darrell T. Fully convolutional networks for semantic segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(4): 640-651.
- [15] 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.
- [16] Badrinarayanan V, Kendall A, Cipolla R. SegNet: a deep convolutional encoder-decoder architecture for image segmentation[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2017, 39(12): 2481-2495.
- [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] Staal J, Abramoff M D, Niemeijer M, et al. Ridgebased vessel segmentation in color images of the retina[J]. IEEE Transactions on Medical Imaging, 2004, 23(4): 501-509.
- [19] Chen M M, Xiong X L, Zhang Y, et al. A new method for retinal fundus image enhancement[J]. Journal of Chongqing Medical University, 2014, 39(8): 1087-1090.
 陈萌梦,熊兴良,张琰,等.1种视网膜眼底图像增强的新方法[J].重庆医科大学学报, 2014, 39(8): 1087-1090.
- [20] He K, Zhang X, Ren S, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification[C] // IEEE International Conference on Computer Vision (ICCV), 2015: 1026-1034.
- [21] Kingma D P, Ba J. Adam: a method for stochastic optimization [C] // The 3rd International Conference on Learning Representations, 2015: 1-15.
- [22] Wang X H, Zhao Y Q, Liao M, et al. Automatic segmentation for retinal vessel based on multi-scale 2D Gabor wavelet[J]. Acta Automatica Sinica, 2015, 41(5): 970-980.
 王晓红,赵于前,廖苗,等.基于多尺度 2D Gabor 小 波的视网膜血管自动分割[J]. 自动化学报, 2015, 41(5): 970-980.