

基于双注意力编码-解码器架构的视网膜血管分割



李天培 陈黎

武汉科技大学计算机科学与技术学院 武汉 430065

武汉科技大学湖北省智能信息处理与实时工业系统重点实验室 武汉 430065

(2386586402@qq.com)

摘要 眼底视网膜血管的分割提取对于糖尿病、视网膜病、青光眼等眼科疾病的诊断具有重要的意义。针对视网膜血管图像中的血管难以提取、数据量较少等问题,文中提出了一种结合注意力模块和编码-解码器结构的视网膜血管分割方法。首先对编码-解码器卷积神经网络的每个卷积层添加空间和通道注意力模块,加强模型对图像特征的空间信息和通道信息(如血管的大小、形态和连通性等特点)的利用,从而改善视网膜血管的分割效果。其中,空间注意力模块关注于血管的拓扑结构特性,而通道注意力模块关注于血管像素点的正确分类。此外,在训练过程中采用 Dice 损失函数解决了视网膜血管图像正负样本不均衡的问题。在 3 个公开的眼底图像数据库 DRIVE, STARE 和 CHASE_DB1 上进行了实验,实验数据表明,所提算法的准确率、灵敏度、特异性和 AUC 值均优于已有的视网膜血管分割方法,其 AUC 值分别为 0.9889, 0.9812 和 0.9831。实验证明,所提算法能够有效提取健康视网膜图像和病变视网膜图像中的血管网络,能够较好地分割细小血管。

关键词: 视网膜血管分割;通道注意力;空间注意力;编码-解码器结构;特征可视化

中图分类号 TP391

Retinal Vessel Segmentation Based on Dual Attention and Encoder-decoder Structure

LI Tian-pei and CHEN Li

School of Computer Science and Technology, Wuhan University of Science and Technology, Wuhan 430065, China

Hubei Province Key Laboratory of Intelligent Information Processing and Real-time Industrial System, Wuhan University of Science and Technology, Wuhan 430065, China

Abstract The segmentation of the retinal vessels in fundus image is important for the diagnosis of ophthalmic diseases such as diabetes, retinopathy and glaucoma. Aiming at the difficulties of extracting blood vessels from retinal blood vessel images and the lack of data samples, a retinal vessel segmentation method combining attention module with encoder-decoder structure is proposed. To improve the segmentation effect of retinal blood vessels, a spatial and channel attention module is added to each convolutional layer of the encoder-decoder convolutional neural network to enhance the utilization of the spatial and channel information of the image features (such as the size, shape, and connectivity of the blood vessels), where the spatial attention focuses on the topological characteristics of blood vessels, and the channel attention focuses on the correct classification of blood vessel pixels. Moreover, the Dice loss function is used to solve the imbalance of positive and negative samples in retinal blood vessel images. The proposed method has been applied on three public fundus image databases DRIVE, STARE and CHASE_DB1. The experimental data show that the accuracy, sensitivity, specificity and AUC values are superior to the existing retinal vessel segmentation methods, with AUC values of 0.9889, 0.9812 and 0.9831, respectively. The experimental results show that the proposed method can effectively extract the vascular network in healthy retinal images and diseased retinal images, and can segment small blood vessels well.

Keywords Segmentation of retinal blood vessels, Channel attention, Spatial attention, Encoder decoder structure, Feature of proposed method visualization

到稿日期:2019-04-09 返修日期:2019-08-31 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61773297);智能信息处理与实时工业系统湖北省重点实验室开放基金资助项目(2016znss01A)

This work was supported by the National Natural Science Foundation of China(61773297) and Open Fund of Hubei Province Key Laboratory of Intelligent Information Processing and Real-Time Industrial System(2016znss01A).

通信作者:陈黎(52282375@qq.com)

1 引言

视网膜血管分析通常被用于各种疾病的诊断和治疗,许多眼科和心血管的病变可以直接反映在视网膜血管网络结构的变化上。例如,了解表征血管的特征(如血管宽度、血管弯曲程度)是防治糖尿病失明的关键^[1]。同时,血管网络(如视网膜、手掌静脉等)构成的生物特征识别系统被伪造的可能性更低,是一个相对更难欺骗的系统^[2]。然而,视网膜上血管分布错综复杂,且有病变干扰,加上眼底照相机的照明与成像方式存在局限性^[3],眼底图像中往往存在噪声、光照不均的问题,血管网络难以完全提取。采用人工的方式对视网膜血管进行标注耗时耗力,且受主观因素影响较大。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。

传统的机器学习方法大多依靠特征工程,对每个独立的像素点进行分类,包括基于直方图特征的阈值分割^[4]和图形切割方法^[5]。随着深度学习的快速发展,越来越多的人使用基于深度学习的方法来进行视网膜血管分割的研究。文献^[6]通过基于像素的特征向量将每个图像像素分类为血管或非血管来产生分割。文献^[7]使用卷积神经网络提取血管图像的深度特征,对不同尺度的特征图使用多个随机森林分类器进行分类,最后集成多个分类器的结果来得到最终的分割结果。文献^[8]使用稀疏训练的去噪自动编码器对血管网络进行无监督学习,通过随机森林对自编码器中输出的向量特征进行分类。文献^[9]开发了一种多尺度和多级卷积神经网络模型来进行分割,并通过全连接条件随机场来建模血管概率图和真实标签之间的内在联系。编码-解码器结构的出现使得神经网络能够端到端地处理整幅图片,通过一个“跳层连接”结构来融合不同尺度的上下文信息,从而获得更精确的分割结果。文献^[10]结合全卷积神经网络 U-Net 与残差网络,首先使用编码-解码器神经网络对视网膜血管进行初步提取;其次通过恒等映射将低层特征传递到更高层,加强每个卷积层对细小血管的注意力,用于应对血管形态和嘈杂背景的极端变化。

针对视网膜血管图像毛细血管分布广泛、视盘与边界区域形状亮度有较大差异等问题,本文提出了结合注意力机制(通道注意力和空间注意力)和编码-解码器结构的视网膜血管分割网络(Channel and Spatial Attention Neural Network, CSA-Net)。其中,通道注意力专注于对每个血管像素点的正确分类,而空间注意力更多地专注于不同血管像素点之间的相对位置。本文将这两个注意力模块与编码-解码器结构的每个卷积层结合,在准确分割每个血管点的同时保持了血管像素点之间的拓扑结构,保证了分割结果图中血管的连通性。

2 CSA-Net

2.1 编码-解码器结构

编码-解码器结构是语义分割领域最流行的框架之一,其能够端到端地分割整幅图片。许多分割方法都是基于编码-解码器结构的,如 U-Net^[11]和 SegNet^[12]。编码器主要由卷积层、激活层和池化层组成,解码器主要由卷积层、激活层和上采样层组成。卷积层对输入图像进行特征提取,激活层用于添加非线性因素,池化层在降低特征图分辨率的同时提取主要特征,上采样层对特征图进行反卷积操作以增大特征图的分辨率。编码器提取输入图像的有效特征并且逐渐减小输入数据的空间维度,解码器通过反卷积层等网络层逐渐恢复目标的细节和相应的空间维度,编码器到解码器之间通常存在直接的信息连接,用于融合中级和高级语义特征,以帮助解码器更好地恢复输出细节。本文所使用的编码器-解码器结构如图 1 所示。其中,每个卷积块由 2 个卷积层组成,每个卷积层使用 3×3 的卷积核,使用 Relu 激活函数对卷积之后的特征图添加非线性因素。在训练神经网络的过程中,前一层的参数变化导致每层的输入分布都不断变化,每一层网络训练需要的超参数也不断变化,因此难以充分构建一个具有饱满的非线性结构的模型。对此,本文在每个卷积层与激活函数之间添加批量归一化层(Batch Normalization, BN),即在每次随机梯度下降时对每个批处理的数据做归一化操作,使得输出特征图中每个通道数据的均值为 0,方差为 1。




图 1 CSA-Net 的网络结构

Fig. 1 Structure of CSA-Net

2.2 注意力模块

注意力在人类感知中起着重要作用,人类利用一系列局部观察,并选择性地专注于显著部分,以便更好地捕捉视觉结构^[13]。近年来,许多研究人员^[14-15]通过添加注意力机制来改善卷积神经网络在大规模分类任务中的性能。受这些工作的启发,本文在视网膜血管分割任务中对每个卷积层添加通道与空间注意力模块,分别在空间维度和通道维度中捕获远程

上下文信息注意机制。该模块的结构如图 2 所示。




图 2 注意力模块

Fig. 2 Attention module

2.2.1 通道注意力

深度特征的每个通道特征图可被视为对特定类别的响应,并且不同的语义响应彼此关联。因此,本文通过构建一个通道注意模块来显式地建模通道之间的相互依赖关系。给定特征图 $F \in R^{C \times H \times W}$,其中 C 表示输入特征图的通道数, H 和 W 分别表示特征图的高度和宽度。首先,通过全局平均池化层将输入特征图的全局通道信息压缩成一个通道描述符 $F_c \in R^{C \times 1 \times 1}$ 。然后,通过一个多层感知机模型来生成通道注意力权重图 $M_c \in R^{C \times 1 \times 1}$ 。为了减小训练和测试过程中的参数开销,将隐藏层的大小设置为 $R^{C/r \times 1 \times 1}$,其中 r 是缩减比率。最后,将生成的特征图进行特征映射,使其大小变为 $C \times H \times W$,并将原始输入特征图逐元素相乘,从而得到通道注意力加权图 $F_{Cout} \in R^{C \times W \times H}$ 。

$$F_c = \frac{1}{H \times W} \sum_{i=1}^H \sum_{j=1}^W F(i, j) \quad (1)$$

$$M_c = \sigma(W_2 \delta(W_1 F_c)) \quad (2)$$

$$F_{out} = F \cdot F_{scale}(M_c) \quad (3)$$

其中, δ 表示 ReLU 激活函数, σ 表示 Sigmoid 激活函数, $W_1 \in R^{C/r \times C}$ 和 $W_2 \in R^{C \times C/r}$ 分别表示 MLP 中第一层和第二层的权重, F_{scale} 表示将 M_c 中每个通道的权重映射成一张大小为 $H \times W$ 的特征图。

通道注意力模块的网络结构如图 3 所示。




图 3 通道注意力模块

Fig. 3 Channel attention module

2.2.2 空间注意力

许多研究^[16-17]表明,传统 FCN 产生的局部特征表示可能导致目标和背景的错误分类。对于视网膜血管图片而言,不同区域的血管之间颜色、形状、纹理等存在较大的不同,而血管之间却存在着拓扑结构的相似性。为了建模丰富的局部特征间的上下文关系,本文提出空间注意力模型,将更广泛的上下文信息编码为局部特征,增强了其表达能力。具体操作为:对于输入特征图 $F \in R^{C \times H \times W}$,将其每个通道中相同位置的元素进行全局池化,从而得到一个空间描述符 $F_s \in R^{1 \times W \times H}$,以捕获水平和垂直方向上的目标图像的边缘信息;然后使用 7×7 的卷积核对该空间描述符进行卷积操作,生成一张二维的空间注意力权重图 $M_s \in R^{1 \times H \times W}$;最后将该权重图与原输入特征图的每个通道进行逐元素相乘,得到空间注意力加权图 $F_{Sout} \in R^{C \times W \times H}$ 。

$$F_s = \frac{1}{C} \sum_{i=1}^C F(i) \quad (4)$$

$$M_s = f^{7 \times 7}(F_s) \quad (5)$$

$$F_{Sout} = F \cdot F_{scale}(\sigma(M_s)) \quad (6)$$

其中, σ 表示 Sigmoid 激活函数; $f^{7 \times 7}$ 表示卷积操作,卷积核大小为 7×7 。

空间注意力模块的网络结构如图 4 所示。




图 4 空间注意力模块

Fig. 4 Spatial attention module

本文发现在视网膜血管分割任务中,通道注意力模块与空间注意力模块的并行排列提供了比顺序排列更好的分割性能。因此,本文将这两个模块以并行的方式排列,通过对特征图进行加权的方式来添加通道和空间注意力。

2.3 Dice 损失函数

在视网膜血管的分割任务中,将视网膜血管区域视为正样本,非血管区域视为负样本。在 DRIVE, STARE 和 CHASH_DB1 数据集中,正负样本的比例接近 1:9,正负样本严重失衡,如果使用常用的均方差或者交叉熵损失函数,神经网络会更加关注样本多的类别,导致网络在训练过程中陷入损失函数的局部最小值,从而使得预测强烈偏向背景的网络模型。因此,为了解决正负样本不平衡造成的问题,本文使用 Dice loss^[18] 损失函数来对网络进行参数更新,更新公式如下:

$$Dice = 1 - \frac{2 \sum_i p_i g_i + \lambda}{\sum_i p_i^2 + \sum_i g_i^2 + \lambda} \quad (7)$$

其中, N 表示像素点总数; $p_i \in [0, 1]$ 表示每个样本的预测值; $g_i \in \{0, 1\}$ 表示每个样本的标签值; $\lambda = 0.0001$ 为拉普拉斯平滑因子,用于避免过度拟合。该损失函数相对于每个像素点产生的梯度计算如下:

$$\frac{\partial Dice}{\partial p_i} = -2 \left[\frac{g_i (\sum_i p_i^2 + \sum_i g_i^2 + \lambda) - 2 p_i (\sum_i p_i g_i + \lambda)}{(\sum_i p_i^2 + \sum_i g_i^2 + \lambda)^2} \right] \quad (8)$$

3 数据集与图像预处理

本文实验的数据集为视网膜血管分割任务常用的 3 个眼底图像数据集 (DRIVE^[19], STARE^[20] 和 CHASE_DB1^[21])。

3.1 数据集介绍

DRIVE 数据集由 40 幅彩色视网膜图像组成,每张原始图像的分辨率为 565×584 ,其中 20 个样本用于训练,剩余的 20 个样本用于测试。

STARE 数据集包含 20 幅彩色图像,每张原始图片的分辨率为 700×605 ,其中一半图像包含病变区域,另一半图像为健康血管。由于样本数量较少,且该数据集并没有区分测试集与训练集,本文使用交叉验证 ($K=4$) 方法对该数据集进行训练和测试,即每次选取 15 张图片用于训练,其余 5 张用于测试,一共抽取 4 次,每次实验的训练样本和测试样本之间没有重叠,且每次的测试样本之间也没有重叠,最后将每次的测试结果进行汇总。

CHASH_DB1 数据集包含 28 幅彩色视网膜图像,每张原始图像的分辨率为 999×960 。该数据集中的图像是从 14 名学童的左眼和右眼中收集的。将其随机分为两类,20 个样本用于训练,其余 8 个样本用于测试。

3个数据集中均包括第一专家和第二专家标准,本文实验中以第一专家的标注结果为金标准图像。

3.2 数据扩增与数据增强

当只有少数训练样本可用时,数据扩增对于训练网络所需的不变性和鲁棒性至关重要。本文实验中,为了满足网络输入对图片尺寸的需要和数据扩增,在训练过程中对每个数据集进行以下操作:以32像素为间隔,将每张图片裁剪为若干个 512×512 的图像块,并对每个图像块以25%的概率进行随机上下左右翻转。为了减少网络的过拟合现象,增强网络的泛化能力,以更好地适应不同的应用场景,对数据集进行数据增强。对每个图像块进行25%概率的随机亮度增强、色度增强、对比度增强和锐度增强,数据增强效果如图5所示。测试时,在每张图片周围填充若干个值为0的像素,使其长和宽为16的倍数,不进行任何数据增强。




图5 数据增强

Fig. 5 Data enhancement

4 实验与结果分析

本文实验所使用的电脑CPU为Intel Core i7-8700K,内存为16GB,GPU为Nvidia GeForce GTX 1080Ti,使用PyTorch开源库训练和测试网络模型。

4.1 网络参数及训练

本文采用随机梯度下降算法(Stochastic Gradient Descent,SGD)对网络权重进行优化,网络参数的初始化采用




图6 特征可视化

Fig. 6 Feature visualization

实验2 研究不同顺序的注意力模块对分割性能的影响。该实验比较了3种通道和空间注意力模块使用顺序下的结果:通道注意力-空间注意力(CS-Net),空间注意力-通道注

Xavier^[22],初始学习率为0.01,权重衰减设定为0.0005,使用policy策略进行训练过程中的学习率衰减,即当前学习率等于初始学习率乘以 $(1 - iter/max_iter)^{power}$ 。本文将衰减权重power设置为0.9,训练时batchsize设为4,epoch设为400。

4.2 评价指标

为了定量评估本文算法,采用准确率(ACC)、灵敏度(SE)、特异性(SP)和ROC曲线下方的面积(AUC)这4个通用指标来客观评价视网膜血管的分割效果。

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$SE = \frac{TP}{TP + FN} \quad (10)$$

$$SP = \frac{TN}{TN + FP} \quad (11)$$

其中,TP为真阳性,指正确分类的血管像素点个数;TN为真阴性,指正确分类的非血管像素点个数;FP为假阳性,指误分成血管像素点的个数;FN为假阴性,指误分成非血管像素点的个数。ROC曲线以假阳性率(FPR)为横坐标,以真阳性率(TPR)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。AUC越接近1,说明算法的分割效果越好。

4.3 实验设计与结果分析

实验1 研究注意力模块对语义分割网络的性能影响。本文实验使用的基线网络为U-Net,与加入注意力模块的网络(CSA-Net)进行对比实验。表1列出了实验结果,可以看出加入注意力模块后的网络在准确率、灵敏度、特异性以及AUC指标上均超过了U-Net。

表1 注意力模块的消融实验

Table 1 Ablation study for attention module				
网络模型	ACC	SE	SP	AUC
U-Net	0.9515	0.7515	0.9623	0.9618
CSA-Net	0.9692	0.8337	0.9824	0.9889

为了研究注意力模块在网络中的具体作用,本文分别将输入注意力模块的特征图、注意力模块生成的权重图以及最终输出的特征图进行可视化。图6给出了最后一个卷积块的特征可视化图。输入特征图(见图6(a))通过与注意力模块得到的注意力权重图(见图6(b))进行加权(见图6(c)),能够对输入特征图中非血管区域的杂质进行过滤,增加血管像素点处的权重,从而提高网络对血管区域的提取性能。

意力(SC-Net),以及将两个注意力模块并行排列(CSA-Net)。最后,使用Sigmoid激活函数对两个注意力模块的输出特征图进行标准化。表2列出了不同顺序的注意力

模块在 DRIVE 数据集上的评价指标。

表 2 不同顺序注意力模块的消融实验

Table 2 Ablation study for attention module of different order

网络模型	ACC	SE	SP	AUC
CS-Net	0.9658	0.8233	0.9813	0.9773
SC-Net	0.9633	0.8218	0.9819	0.9792
CSA-Net	0.9692	0.8337	0.9824	0.9889

实验 3 研究不同损失函数对分割性能的影响。本文在 CSA-Net 上分别使用 Dice 损失函数和交叉熵损失函数 (BCE) 进行对比实验。表 3 列出了实验的结果。使用交叉熵损失函数在准确率与特异性指标上略高于 Dice 损失函数,但是在灵敏度和 AUC 值上远低于 Dice 损失函数,其原因是血管图像中正负样本极不平衡,导致网络模型对样本数较多的分类过拟合。因此,本文使用 Dice loss 作为损失函数有助于提高对血管的分割性能。

表 3 Dice 损失函数的消融实验

Table 3 Ablation study for Dice loss function

网络模型	ACC	SE	SP	AUC
CSA-Net+BCE	0.9703	0.8010	0.9869	0.9795
CSA-Net+Dice	0.9692	0.8337	0.9824	0.9889

图 7 给出了本文算法的主观效果,从上往下分别为 DRIVE, STARE 和 CHASE_DB1 的视网膜图像。

由图 7 可以看出,本文算法相对于 U-Net 能够提取视网膜图像的大部分血管,且能够完整地提取出血管的主干部分。从细节上看(红框处),本文算法分割结果中细小血管保留得更加完整,血管更具有连通性,避免了 U-Net 网络分割结果中部分血管断裂的情况。


图 8 给出了本文算法与金标准图像的对比结果,其中红色、绿色、蓝色和白色像素分别表示真阳性、假阳性、假阴性和真阴性的结果。本文算法对血管的主干部分和大部分毛细血管有较好的分割性能,但对于细小血管会产生过分割的情况(绿色像素区域)。

表 4 不同算法的分割性能

Table 4 Performance comparison of different algorithms

方法	DRIVE				STARE				CHASE_DB1			
	ACC	SE	SP	AUC	ACC	SE	SP	AUC	ACC	SE	SP	AUC
第二专家	0.9472	0.7760	0.9724	—	0.9349	0.8952	0.9384	—	0.9545	0.8105	0.9711	—
文献[22]中的算法	0.9442	0.7655	0.9704	0.9614	0.9497	0.7716	0.9701	0.9563	0.9387	0.7585	0.9587	0.9487
文献[23]中的算法	0.9494	0.7395	0.9782	0.9672	0.9560	0.7317	0.9842	0.9673	0.9467	0.7615	0.9575	0.9623
文献[24]中的算法	0.9540	0.7420	0.9820	0.8620	0.9560	0.7800	0.9780	0.8740	—	—	—	—
文献[25]中的算法	0.9533	0.7603	0.9776	0.9789	0.9609	0.7412	0.9701	0.9790	0.9581	0.7130	0.982	0.9806
本文算法	0.9692	0.8337	0.9824	0.9889	0.9682	0.8193	0.9852	0.9812	0.9687	0.8172	0.9867	0.9831

结束语 本文提出了基于注意力机制和全卷积神经网络的视网膜血管分割方法,使用带有跳层连接的编码-解码器结构,融合不同尺度的低层特征和高层语义信息;通过对每个卷积层添加通道注意力与空间注意力模块,使得神经网络充分学习血管分类与位置信息,提高了视网膜血管分割的准确性与血管之间的连通性;最后,使用数据扩增来增加样本数,并通过 Dice 损失函数来有效解决视网膜血管图像中正负样本不平衡的问题。实验结果表明,本文算法具有比其他算法更好的分割性能。但是,本文算法的分割结果图中出现了部分血管断裂的情况,未来将针对这一问题,通过结合卷积层与



(a)原始图片 (b)金标准图像 (c)U-Net 分割结果 (d)本文算法

图 7 本文算法的分割结果(电子版为彩色)

Fig. 7 Results of proposed algorithm




图 8 本文算法与金标准图像的对比(电子版为彩色)

Fig. 8 Comparison of proposed algorithm and grand-truth


表 4 列出了本文算法与具有较高分割性能的文献[23]中的算法、文献[24]中的算法,文献[25]中的算法和文献[26]中的算法在各项评价指标上的对比情况。由表 4 可以看出,本文算法在准确率、特异性、灵敏度和 AUC 等指标上均优于其他算法。本文算法在准确率和特异性上均优于第二专家的结果;但在 STARE 数据集上的灵敏度较差,主要原因是训练时样本较少,网络没有很好地捕获图像中血管分布的规律。

机游走算法,在端到端的训练过程中提高模型对断裂血管的连接性能。

参考文献

- [1] CHENG E, DU L, WU Y, et al. Discriminative vessel segmentation in retinal images by fusing context-aware hybrid features [J]. Machine Vision and Applications, 2014, 25(7): 1779-1792.
- [2] KANG W, WU Q. Contactless palm vein recognition using a mutual foreground-based local binary pattern [J]. IEEE Transactions on Information Forensics and Security, 2014, 9(11): 1974-1985.

- [3] WANG X H, XUE Q S. Optical design of portable non-mydiatic fundus camera with large field of view[J]. *Acta Optica Sinica*, 2017, 37(9):0922001.
- [4] RAMESH N, YOO J H, SETHI I K. Thresholding based on histogram approximation[J]. *IEE Proceedings—Vision, Image and Signal Processing*, 1995, 142(5):271-279.
- [5] BOYKOV Y Y, JOLLY M P. Interactive graph cuts for optimal boundary & region segmentation of objects in ND images[C]// *Proceedings Eighth IEEE International Conference on Computer vision (ICCV 2001)*. IEEE, 2001:105-112.
- [6] SOARES J V B, LEANDRO J J G, CESAR R M, et al. Retinal vessel segmentation using the 2-D Gabor wavelet and supervised classification[J]. *IEEE Transactions on Medical Imaging*, 2006, 25(9):1214-1222.
- [7] WANG S, YIN Y, CAO G, et al. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning[J]. *Neurocomputing*, 2015, 149:708-717.
- [8] MAJI D, SANTARA A, GHOSH S, et al. Deep neural network and random forest hybrid architecture for learning to detect retinal vessels in fundus images[C]// *2015 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2015:3029-3032.
- [9] FU H, XU Y, WONG D W K, et al. Retinal vessel segmentation via deep learning network and fully-connected conditional random fields[C]// *2016 IEEE 13th International Symposium on Biomedical Imaging (ISBI)*. IEEE, 2016:698-701.
- [10] XIAO X, LIAN S, LUO Z, et al. Weighted Res-UNet for High-Quality Retina Vessel Segmentation[C]// *2018 9th International Conference on Information Technology in Medicine and Education (ITME)*. IEEE, 2018:327-331.
- [11] 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*. Cham: Springer, 2015:234-241.
- [12] 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.
- [13] LAROCHELLE H, HINTON G E. Learning to combine foveal glimpses with a third-order Boltzmann machine[C]// *Advances in Neural Information Processing Systems*. 2010:1243-1251.
- [14] WANG F, JIANG M, QIAN C, et al. Residual attention network for image classification[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017:3156-3164.
- [15] HU J, SHEN L, SUN G. Squeeze-and-excitation networks[C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2018:7132-7141.
- [16] ZHAO H, SHI J, QI X, et al. Pyramid scene parsing network [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017:2881-2890.
- [17] PENG C, ZHANG X, YU G, et al. Large Kernel Matters—Improve Semantic Segmentation by Global Convolutional Network [C]// *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. 2017:4353-4361.
- [18] MILLETARI F, NAVAB N, AHMADI S A. V-net: Fully convolutional neural networks for volumetric medical image segmentation[C]// *2016 Fourth International Conference on 3D Vision (3DV)*. IEEE, 2016:565-571.
- [19] STAAL J, ABRÁMOFF 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.
- [20] HOOVER A, KOUZNETSOVA V, GOLDBAUM M. Locating blood vessels in retinal images by piece-wise threshold probing of a matched filter response[C]// *Proceedings of the AMIA Symposium*. American Medical Informatics Association, 1998:931.
- [21] FRAZ M M, REMAGNINO P, HOPPE A, et al. An ensemble classification-based approach applied to retinal blood vessel segmentation[J]. *IEEE Transactions on Biomedical Engineering*, 2012, 59(9):2538-2548.
- [22] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[C]// *Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics*. 2010:249-256.
- [23] AZZOPARDI G, STRISCIUGLIO N, VENTO M, et al. Trainable COSFIRE filters for vessel delineation with application to retinal images[J]. *Medical Image Analysis*, 2015, 19(1):46-57.
- [24] ROYCHOWDHURY S, KOOZEKANANI D D, PARHI K K. Iterative vessel segmentation of fundus images[J]. *IEEE Transactions on Biomedical Engineering*, 2015, 62(7):1738-1749.
- [25] ZHAO Y, RADA L, CHEN K, et al. Automated vessel segmentation using infinite perimeter active contour model with hybrid region information with application to retinal images[J]. *IEEE Transactions on Medical Imaging*, 2015, 34(9):1797-1807.
- [26] FU H, XU Y, LIN S, et al. Deepvessel: Retinal vessel segmentation via deep learning and conditional random field[C]// *International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cham: Springer, 2016:132-139.



LI Tian-pei, born in 1995, postgraduate. His main research interests include image processing and deep learning.



CHEN Li, born in 1977, Ph.D, professor, Ph.D supervisor. His main research interests include image processing, computer vision, intelligent media computing, and deep learning applications.