

本文引用:穆 珺,晏峻峰,彭清华. 基于小波变换和 U-Net 的眼底图像血管分割[J]. 湖南中医药大学学报,2022,42(12):2052-2058.

基于小波变换和 U-Net 的眼底图像血管分割

穆 珺,晏峻峰,彭清华

(湖南中医药大学,湖南 长沙 410208)

〔摘要〕 眼底血管在许多疾病的检测和诊断中含有丰富的信息,因此提高眼底血管分割精度对于多种疾病的诊断和临床研究具有重要意义。本文提出了一种基于小波变换和 U-Net 神经网络的眼底图像血管分割算法,该算法通过数据增广与预处理、小波系数图像获取、U-Net 神经网络训练与预测、阈值分割与后处理等步骤完成眼底血管的分割。采用分割准确率、特异度、灵敏度与 AUC 等指标,对本文算法进行了性能分析。实验结果显示,本文提出的眼底图像血管分割算法能得到满意的分割结果,在中医现代目诊中具有潜在的应用价值。

〔关键词〕 眼底血管分割;哈尔小波变换;U-Net;数据增广;图像预处理;阈值分割与后处理

〔中图分类号〕R276;TP391

〔文献标志码〕A

〔文章编号〕doi:10.3969/j.issn.1674-070X.2022.12.015

Blood vessel segmentation of retinal images based on wavelet transformation and U-Net

MU Jun, YAN Junfeng, PENG Qinghua

(Hunan University of Chinese Medicine, Changsha, Hunan 410208, China)

〔Abstract〕 The retinal blood vessel is informative to the detection and diagnosis of various retinal diseases. Therefore, improving the accuracy of blood vessel segmentation is highly important to diagnoses of certain diseases and clinical research. A blood vessel segmentation method of retinal images based on wavelet transformation and U-Net is proposed in this paper. The blood vessel is segmented by the major phases including data augmentation and image pre-processing, wavelet coefficient images obtaining, U-Net model training and predicting, threshold segmentation and post-processing. The performance of the proposed method has been analyzed in terms of accuracy, specificity, sensitivity, AUC, and other indicators. The experimental results demonstrate that the proposed retinal blood vessel segmentation method can achieve satisfying segmentation result, and have potential application in eye diagnoses.

〔Keywords〕 retinal blood vessel segmentation; Haar wavelet transformation; U-Net; data augmentation; image pre-processing; threshold segmentation and post-processing

中医现代目诊以传统目诊为基础,通过对眼科仪器设备检查结果的分析,联系相关临床经验从而做出诊断。而眼底图像分析包括眼底血管分析,属于中医现代目诊的一个重要研究内容^[1]。不仅如此,眼底血管在诸如高血压、糖尿病、青光眼等疾病的检测和诊断中含有丰富的信息^[2]。但对眼底图像血管进

行人工分割的方式,通常费时费力,并且需要具有专家知识^[3]。因此,眼底图像血管分割算法的研究一直受到医学图像处理领域的广泛关注^[4-6]。

SINGH 等^[2]使用基于 Gumbel 概率分布函数的滤波器和基于熵的阈值方法对眼底图像血管进行分析。LI 等^[3]通过 BP 算法训练深度神经网络来完成血

〔收稿日期〕2022-03-25

〔基金项目〕湖南省中医药科技计划重点项目(201901);湖南省教育厅科学研究项目(21C0224,21C0227);湖南省财政厅科研资助项目(2019103);湖南省中医学国内一流建设学科建设项目(湘教通[2018]469号)。

〔第一作者〕穆 珺,女,硕士,讲师,研究方向:图像处理、医学数据挖掘,E-mail:junmu@hnuem.edu.cn。

管分割。HU等^[7]提出了一个多尺度卷积神经网络来获取眼底图像血管分割的概率图,并使用条件随机场获取最终分割结果。DASGUPTA等^[8]提出了一个全卷积神经网络架构来进行眼底图像血管分割。BARKANA等^[9]提出了一个眼底图像血管分割模型,使用多种统计特征,并融合多种分类器来提升和评估分割性能。RONNEBERGER等^[10]提出了一个名为U-Net的端到端神经网络架构,并通过U-Net神经网络进行医学图像分割。此后的研究者提出了许多基于U-Net神经网络进行眼底图像血管分割的算法,并显示出优秀的性能^[6]。JIN等^[11]提出了一个可变形的U-Net神经网络架构来分割眼底血管。ORUJOV等^[12]提出了一种模糊边缘检测的算法来分割眼底图像血管。CHENG等^[13]提出了一个密集连接U-Net神经网络架构来分割眼底血管。FENG等^[14]提出了一个跨连接神经网络来分割眼底血管。YU等^[15]使用零相位分量分析和全局对比度规范化进行预处理,然后训练卷积神经网络获取眼底血管分割结果。尽管研究者们付出了大量的努力,也取得了不少进展,但眼底图像血管分割仍然具有值得进一步改进的空间^[4-6]。

1 方法

本文所提出的眼底图像血管分割算法的总体流程包括:数据增广与预处理、小波系数图像获取、U-Net神经网络训练与预测、阈值分割与后处理。

1.1 数据增广与图像预处理

1.1.1 数据来源 本文所提出的眼底图像血管分割算法是在DRIVE数据集上进行训练和测试。DRIVE数据集是广泛使用于眼底图像血管分割的公开数据集,其中包含40张眼底图像,每张图像的尺寸为565像素宽、584像素高。该数据集的40张图像中,20张被划分为训练图像,20张被划分为测试图像。每一张眼底图像都提供了对应的专家手动分割图像。本文采用U-Net神经网络,将训练图像和对应的分割图像作为训练数据进行训练;将算法对测试图像的分割结果与测试图像的专家分割结果进行对比,以度量算法分割性能。

1.1.2 数据增广 在诸如眼底图像血管分割等医学图像处理问题中,要获取大量的专家手动分割信息以构成训练数据通常是非常困难的。而训练数据数量的缺乏,很可能造成训练中的模型过拟合问题,从

而降低以神经网络等算法为代表的有监督的分割算法的准确性和泛化能力。为解决该问题,本文采用数据增广操作,将原始数据集中的40张图像增广为160张图像。数据增广操作对于每一张图像,计算得到其水平镜像图像、竖直镜像图像、水平与竖直镜像图像。单张原始图像的数据增广结果如图1所示。




图1 数据增广

1.1.3 图像预处理 在输入U-Net神经网络进行训练和测试之前,本文将对原始图像进行一系列预处理操作。预处理操作包括图像灰度化、图像数据标准化、图像对比度受限自适应直方图均衡化^[16]、伽玛变换。图像灰度化是将彩色图像转换为灰度图,其计算公式如下:

$$\text{GrayScale}=0.299\times R+0.587\times G+0.114\times B \quad (1)$$

其中,R、G、B分别为每个像素点的红、绿、蓝3个颜色通道的亮度值,通过加权求和,得到GrayScale,即该像素点的灰度值。

图像数据标准化操作的作用是将数据转化为具有均值0和标准差1的新数据,以避免具有较大取值范围的变量对计算结果产生剧烈影响,标准化的公式如下:

$$x'=\frac{x-\bar{x}}{S_x} \quad (2)$$

其中, x 是每个像素点的灰度值, \bar{x} 是所有像素点的平均灰度值, S_x 是所有像素点灰度值的标准差, x' 是标准化之后的灰度值。

图像对比度受限自适应直方图均衡化算法的作用是利用局部图像块的直方图对图像的灰度值进行映射,以提高图像对比度,实现图像的增强。伽玛变换的作用也是对图像进行增强,其公式如下:

$$\text{gamma}(x)=255 \cdot (x/255)^{\gamma} \quad (3)$$

其中, x 是每个像素点的灰度值, $\text{gamma}(x)$ 是变换后的灰度值, 参数 γ 取值为 0.833。

原始图像经过预处理后的结果如图 2 所示。




图 2 图像预处理

1.2 小波系数图像获取

1.2.1 哈尔小波变换 小波变换是信号处理与图像处理中一个强有力的数学工具。小波变换能同时描述图像的空间域和频率域的信息。哈尔小波是一种应用极为广泛的小波变换^[7]。哈尔小波的计算公式如下:

$$\psi_j^i(x) = \sqrt{2^j} \psi(2^j x - i) \quad (4)$$

其中, $j=0,1,\dots$; $i=0,1,\dots,2^j-1$

并且

$$\psi(x) = \begin{cases} 1 & \text{当 } 0 \leq x < 1/2 \\ -1 & \text{当 } 1/2 \leq x < 1 \\ 0 & \text{其他} \end{cases} \quad (5)$$

通过哈尔小波变换,可以得到图像的两种小波系数,分别为近似系数与细节系数。近似系数可以视为原始图像在低分辨率下的近似;而细节系数可以描述原始图像在各个局部的细微变化。

对二维灰度图像进行一阶哈尔小波变换,可以视为在行和列两个方向分别进行一维哈尔小波变换,从而可以得到以下小波系数矩阵:图像的近似系数矩阵、反映图像水平方向变化细节的水平细节系数矩阵、反映图像垂直方向变化细节的垂直细节系数矩阵、反映图像对角方向变化细节的对角细节系数矩阵。

1.2.2 小波系数矩阵上采样 对灰度图像进行一阶哈尔小波变换,可以得到水平细节系数矩阵、垂直细节系数矩阵、对角细节系数矩阵,这 3 个细节系数矩阵可以综合反映出图像各个局部在不同方向上的细微的变化情况。

因此,将这 3 个细节系数矩阵作为富含信息的

输入,和预处理得到的灰度图像共同组成神经网络训练和测试的输入。

由于小波变换得到的细节系数矩阵尺寸为原始图像的一半,因此,采用双线性插值算法对小波系数矩阵进行上采样,得到尺寸和原始图像一致的小波系数图像。

小波变换的输入图像和上采样得到的 3 个小波系数图像如图 3 所示。




图 3 小波变换的输入图像和上采样得到的 3 个小波系数图像

1.3 U-Net 神经网络训练与预测

1.3.1 U-Net 神经网络架构 U-Net 是 RONNEBERGER 等^[10]于 2015 年提出的端到端的卷积神经网络。U-Net 网络由收缩路径与扩张路径两个对称的部分构成。U-Net 神经网络对输入的图像块进行处理,最终得到同样尺寸的特征图作为分割预测结果输出。

在收缩路径中,原始输入图像块经过两次 3×3 卷积与 ReLU 操作,再进行 2×2 最大池化,如此操作重复 4 次;得到的特征图像块再经过两次 3×3 卷积与 ReLU 操作,此后进入扩张路径;在扩张路径中,将收缩路径最末端得到的特征图像块进行上采样,并与收缩路径中处于同层的特征图像块进行拼接,拼接后进行两次 3×3 卷积与 ReLU 操作,将得到的像块进行上采样,如此重复 4 次。在扩张路径的最末端,通过 2 个 1×1 卷积将输出特征图映射为每个像素点分别属于血管和背景的预测值。

本文在大体借鉴文献^[10]中的 U-Net 神经网络架

构基础上,对网络架构进行了一些调整和改善。

首先,本文将收缩路径中的池化操作设置为重复2次,相应的扩张路径中的上采样操作也设置为重复2次,以适应于本文所处理的眼底图像及眼底图像块尺寸有限的特点。其次,本文在每个 3×3 卷积与ReLU操作之后,加入了批标准化与丢弃操作,以加速神经网络收敛。

本文所采用的U-Net神经网络架构如图4所示。

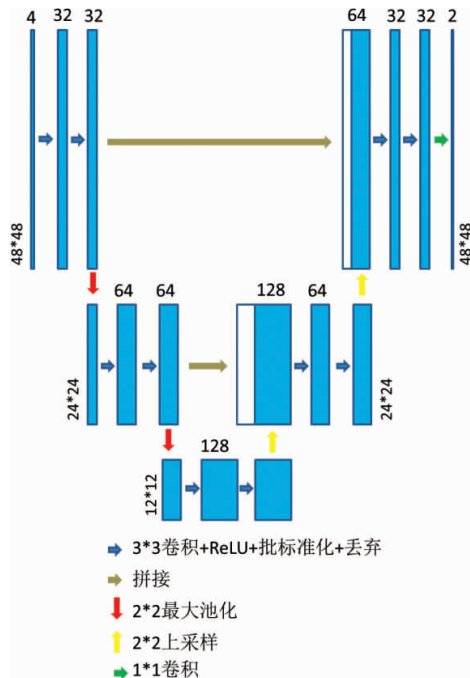


图4 U-Net神经网络架构

1.3.2 U-Net神经网络训练 (1)训练图像块采样 尽管已经通过数据增广将训练图像的数量从20增加到80,但是训练图像的数量仍然非常有限。为避免U-Net神经网络训练中出现过拟合,本文采用随机采样的方式,在每张原始训练图像中,随机采样9500个尺寸为 48×48 的图像块,从而构造总数量为76000的图像块作为训练数据。

(2)损失函数 本文对于U-Net神经网络的最终输出层采用softmax函数作为激活函数。softmax函数的公式如下:

$$p(z_i) = \frac{e^{z_i}}{\sum_{c=1}^2 e^{z_c}} = \frac{e^{z_i}}{e^{z_1} + e^{z_2}} \quad (6)$$

其中, $z_i(i \in \{1,2\})$ 表示U-Net神经网络的输出,即图像块中每个像素点分别属于血管和背景的预测值,并且预测值被排列成2条向量。 $p(z_i)$ 就是将预测值归一化后得到的每个像素点分别属于血管和背景的概率值,分别用 $p(z_1)$ 和 $p(z_2)$ 表示,若 $z_1 > z_2$,则

$p(z_1) > p(z_2)$,反之亦然;每个像素点将被算法预测为 $p(z_i)$ 取最大值所对应的类别。

对于每个像素 x ,损失函数可以衡量算法对像素预测值与真实值之间的差异,本文采用交叉熵损失函数。交叉熵损失函数的公式如下:

$$\text{Loss}(y(x), p(x)) = y_1(x) \log p_1(x) + y_2(x) \log p_2(x) \quad (7)$$

其中, $y(x)$ 与 $p(x)$ 分别是像素 x 的真实类别标签和预测值。 $y_1(x)$ 是表示像素 x 是否属于背景点的类别标签,而 $y_2(x)$ 是表示像素 x 是否属于血管点的类别标签。 $p_1(x)$ 是算法预测像素 x 属于背景点的概率值,而 $p_2(x)$ 是算法预测像素 x 属于血管点的概率值,考虑所有采样的像素点 $x(x \in \Omega)$,总体的损失函数如下所示:

$$J = \frac{1}{m} \sum_{(x \in \Omega)} \text{Loss}(y(x), p(x)) \quad (8)$$

其中, m 是所有属于训练样本集的像素总数,而 $\text{Loss}(y(x), p(x))$ 是单个像素 $x(x \in \Omega)$ 的损失函数。

1.3.3 U-Net神经网络预测 在完成训练后,本文使用训练得到的U-Net神经网络对于测试图像的所有像素点属于血管的概率进行预测。预测值越接近1表示像素点属于血管的概率越大,预测值越接近0表示像素点属于背景的概率越大。

由于训练中采用了尺寸为 48×48 的图像块,在测试中,也需要将测试图像划分为 48×48 的图像块。对每一张原始测试图像,本文使用步幅为2像素的间隔进行图像块采样。对于原始测试图像中的同一个像素点,将多次出现在不同采样块的不同位置;每个采样图像块中分别得到的同一个像素点的预测值,再将同一个像素点的多个预测值求平均作为该像素点的最终预测值,以此减轻采样位置的差异对于预测结果的影响。

原始测试图像和U-Net神经网络预测得到的概率图像如图5所示。



(a) 原始测试图像 (b) 预测概率图像

图5 原始测试图像与U-Net的预测结果

1.4 阈值分割与后处理


1.4.1 阈值分割 通过 U-Net 神经网络预测,可以得到测试图像所有像素点属于血管的概率预测值,该预测值取值为 0 到 1 之间,预测值越接近 1 表示像素点属于血管的概率越大。

本文采用阈值分割方法将每个像素点属于血管的概率预测值转化为像素值是否属于血管的分类标签。具体计算公式如下:

$$\text{seg}(x) = \begin{cases} 0, & \text{PredictionMap}(x) \leq T \\ 1, & \text{PredictionMap}(x) > T \end{cases} \quad (9)$$

其中, $\text{PredictionMap}(x)$ 表示每个像素点 x 属于血管的概率预测值, T 是分割的阈值,本文中设置 $T=0.5$ 。而 $\text{seg}(x)$ 表示阈值分割的结果, $\text{seg}(x)=1$ 表示像素 x 为血管点;而 $\text{seg}(x)=0$ 表示像素 x 为背景点。

阈值分割的结果如图 6(a)所示。



(a) 阈值分割结果 (b) 后处理结果
图 6 阈值分割与后处理结果

1.4.2 后处理 在眼底图像中,许多局部区域的对比度很低,细小的血管非常不清晰,因此,即使借助于 U-Net 神经网络,许多血管尤其是细小血管的分割也是极其困难的。表现在阈值分割结果上,就是分割出的血管有很多断裂的情况。为解决这一问题,本文在阈值分割的基础上,引入闭运算作为后处理,从而将血管分割结果中出现的断裂处进行融合。

后处理的结果如图 6(b)所示。直接对比阈值分割结果与后处理结果,两者差异不明显;但在“2.4”的实验分析中,通过对一些测试图像的阈值分割结果与后处理结果进行局部放大,可明显观察到后处理结果相对于阈值分割结果有所改进。

2 结果

2.1 实验设置

本文所有实验均运行于笔记本计算机,该计算机

配置了型号为英特尔酷睿 i7-9750H、主频为 2.60 GHz 的 CPU,并配置了 16 GB RAM 和 6GB 型号为 NVIDIA GeForce GTX 1660Ti 的 GPU。该计算机所使用的操作系统为 64 位 Win10。本文算法实现所使用的编程语言为 python,用到的第三方库主要包括 TensorFlow、Keras、sklearn、numpy、opencv、pywt 等。本文实验所用到的眼底图像数据集为 DRIVE 数据集,该数据集的介绍在“1.1.1”。

2.2 评价指标

本文用来对算法性能进行评价与度量的主要指标包括:准确率(Acc)、特指度(Spe)、灵敏度(Sen)、精度(Pre)、F1 值与 ROC 曲线的 AUC 指标。上述评价指标的定义如下:

$$\text{Acc} = (\text{TP} + \text{TN}) / (\text{TP} + \text{TN} + \text{FP} + \text{FN}) \quad (10)$$

$$\text{Spe} = \text{TN} / (\text{FP} + \text{TN}) \quad (11)$$

$$\text{Sen} = \text{TP} / (\text{TP} + \text{FN}) \quad (12)$$

$$\text{Pre} = \text{TP} / (\text{TP} + \text{FP}) \quad (13)$$

$$\text{F1} = 2\text{TP} / (2\text{TP} + \text{FP} + \text{FN}) \quad (14)$$

其中,TP 表示被模型正确预测的正样本数;FP 表示被模型错误预测为正样本的负样本数;FN 表示被模型错误预测为负样本的正样本数;TN 表示被模型正确预测的负样本数。在本文实验中,正样本是指对应血管的像素点;负样本是指对应背景的像素点。

Acc、Spe、Sen、Pre、F1 值,是从不同角度衡量分类模型的性能,上述指标的取值范围都在 0 到 1 之间,取值越接近 1,说明模型性能越好。ROC 曲线是接受者操作特征曲线,ROC 曲线下方的面积,简称为 AUC 指标,可以综合地评价模型的平均性能。AUC 指标的取值范围也在 0 到 1 之间,取值越接近 1,说明模型性能越好。

2.3 使用小波系数对分割结果的影响

为分析本文所使用的小波系数图像对于分割算法性能的影响,本文在其他实验设置完全相同的情况下,对比分析了不加入小波系数和加入小波系数时,血管分割结果的性能差异,如表 1 所示。实验结果显示,从 Acc、Spe、Pre、F1 值、AUC 指标等 5 个方面比较,加入小波系数的结果均优于不加入小波系数的结果;唯一在 Sen 指标上,加入小波系数的结果略


差于不加入小波系数的结果。综合而言,本文所使用的小波系数对分割结果具有一定的提升作用。

表1 不加入小波系数和加入小波系数的性能比较

组别	Acc	Spe	Sen	Pre	AUC	F1
不加入小波系数	0.955 6	0.981 0	0.781 1	0.857 3	0.978 9	0.817 5
加入小波系数	0.956 3	0.982 1	0.779 2	0.863 9	0.980 4	0.819 4

2.4 后处理结果的局部放大分析

分析对比阈值分割结果与后处理结果,从图像全局观察来看,两者不明显。为此,本文将一些测试图像的阈值分割结果与后处理结果进行了局部放大和对比分析。阈值分割结果与后处理结果的局部放大图像如图7所示。其中,列(a)为阈值分割结果局部放大图,列(b)为后处理结果局部放大图。通过对于细小血管所处局部图像进行放大,可以明显观察到,引入闭运算作为后处理所得到的分割结果中,原先断裂的细小血管实现了融合。



(a) 阈值分割局部放大图 (b) 后处理局部放大图

图7 阈值分割与后处理局部放大图

2.5 本文算法与现有算法比较

根据现有眼底图像血管分割算法所普遍采用的评价指标,从 Acc、Spe、Sen、ROC 曲线的 AUC 指标 4 个方面对本文算法和现有算法进行性能比较,如表 2 所示。本文算法分割结果的 ROC 曲线如图 8 所示。实验结果显示,本文算法均超过或者不弱于现有的眼底图像分割算法。

表2 本文算法与现有算法性能比较

方法	Acc	Spe	Sen	AUC
文献[2]方法	0.9522	0.970 8	0.759 4	0.928 7
文献[3]方法	0.952 7	0.981 6	0.756 9	0.973 8
文献[8]方法	0.953 3	0.980 1	0.769 1	0.974 4
文献[9]方法	0.950 2	0.984 0	0.722 4	0.953 2
文献[7]方法	0.953 3	0.979 3	0.777 2	0.975 9
文献[11]方法	0.956 6	0.980 0	0.796 3	0.980 2
文献[12]方法	0.939 0	0.957 0	—	—
文献[13]方法	0.955 9	0.983 4	0.767 2	0.979 3
文献[14]方法	0.9528	0.980 9	0.762 5	0.967 8
文献[15]方法	0.952 4	0.980 3	0.764 3	0.972 3
本文方法	0.956 3	0.982 1	0.779 2	0.980 4




图8 本文算法分割结果的 ROC 曲线


需要说明的是,本文算法为有监督的分割方法,需要将数据集中的原始图像划分为训练图像和测试图像。本文采用 DRIVE 数据集的发布者所给出的划分,将 DRIVE 数据集中的 40 张原始图像划分为 20 张训练图像和 20 张测试图像。此外,文献[3]、文献[8]、文献[9]、文献[7]、文献[11]、文献[13]、文献[14]、文献[15]的算法也都是有监督的分割方法,上述论文中均是采用相同的划分方法,将 DRIVE 数据集中的 40 张原始图像划分为 20 张训练图像和 20 张测试图像。

2.6 分割结果

本文算法所得到的眼底图像血管分割结果如图 9 所示,其中列(a)为原始眼底图像,列(b)为本文算法得到的最终分割结果。

3 结论

针对中医现代目诊的一个重要研究内容,即眼底血管分析,本文提出了一种基于小波变换和 U-Net 的眼底图像血管分割算法。该算法主要通过数



(a)原始图像 (b)分割结果

图9 眼底图像血管分割结果

据扩增与预处理、小波系数图像获取、U-Net神经网络训练与预测、阈值分割与后处理等步骤完成眼底血管的分割。本文从不同角度对本文算法进行了性能分析,实验结果显示,本文所使用的小波系数对分割结果具有一定的提升作用,并且本文算法超过或者不弱于现有的眼底图像分割算法。

综上所述,本文提出的眼底图像血管分割算法能得到满意的分割结果,在中医现代目诊中具有潜在的应用价值。

参考文献

- [1] 李翔,邓颖,蒋鹏飞,等.基于眼底图像视网膜血管分割、分类方法的中医目诊研究[J].湖南中医药大学学报,2021,41(3):406-411.
- [2] SINGH N P, SRIVASTAVA R. Retinal blood vessels segmen-

tion by using Gumbel probability distribution function based matched filter[J]. Computer Methods and Programs in Biomedicine, 2016, 129: 40-50.

- [3] LI Q L, FENG B W, XIE L P, et al. A cross-modality learning approach for vessel segmentation in retinal images[J]. IEEE Transactions on Medical Imaging, 2016, 35(1): 109-118.
- [4] MOCCIA S, et al. Blood vessel segmentation algorithms—Review of methods, datasets and evaluation metrics[J]. Computer Methods and Programs in Biomedicine, 2018, 158: 71-91.
- [5] IMRAN A, LI J Q, PEI Y, et al. Comparative analysis of vessel segmentation techniques in retinal images[J]. IEEE Access, 2019, 7: 114862-114887.
- [6] LIU L L. A survey on U-shaped networks in medical image segmentations[J]. Neurocomputing, 2020, 409: 244-258.
- [7] HU K. Retinal vessel segmentation of color fundus images using multiscale convolutional neural network with an improved cross-entropy loss function[J]. Neurocomputing, 2018, 309: 179-191.
- [8] DASGUPTA A, SINGH S. A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation[C]//2017 IEEE 14th International Symposium on Biomedical Imaging. Melbourne, VIC, Australia. IEEE: 248-251.
- [9] BARKANA B D. Performance analysis of descriptive statistical features in retinal vessel segmentation via fuzzy logic, ANN, SVM, and classifier fusion[J]. Knowledge-Based Systems, 2017, 118: 165-176.
- [10] RONNEBERGER O, FISCHER P, BROX T. U-net: Convolutional networks for biomedical image segmentation[M]//Lecture Notes in Computer Science. Cham: Springer International Publishing, 2015: 234-241.
- [11] JIN Q G. DUNet: A deformable network for retinal vessel segmentation[J]. Knowledge-Based Systems, 2019, 178: 149-162.
- [12] ORUJOV F. Fuzzy based image edge detection algorithm for blood vessel detection in retinal images[J]. Applied Soft Computing, 2020, 94: 106452.
- [13] CHENG Y L, MA M N, ZHANG L J, et al. Retinal blood vessel segmentation based on Densely Connected U-Net[J]. Mathematical Biosciences and Engineering, 2020, 17(4): 3088-3108.
- [14] FENG S T. CcNet: A cross-connected convolutional network for segmenting retinal vessels using multi-scale features[J]. Neurocomputing, 2020, 392: 268-276.
- [15] YU L F. A framework for hierarchical division of retinal vascular networks[J]. Neurocomputing, 2020, 392: 221-232.
- [16] REZA A M. Realization of the contrast limited adaptive histogram equalization (CLAHE) for real-time image enhancement[J]. Journal of VLSI Signal Processing Systems for Signal, Image and Video Technology, 2004, 38(1): 35-44.
- [17] 孙延奎.小波分析及其应用[M].北京:机械工业出版社,2005:1-16.

(本文编辑 匡静之)