

基于多特征融合的有监督视网膜血管提取

梁礼明¹⁾ 刘博文¹⁾ 杨海龙²⁾ 石 霏³⁾ 陈新建³⁾

¹⁾(江西理工大学电气工程与自动化学院 江西 赣州 341000)

²⁾(国家电网广元供电公司 四川 广元 628000)

³⁾(苏州大学电子信息学院 江苏 苏州 215006)

摘 要 视网膜血管提取在眼科疾病的诊断和治疗中具有重要的临床价值,但由于其拓扑结构复杂与病灶噪声等原因,现有的提取方法精度低、鲁棒性差。为此,该文提出了一种基于多特征融合的有监督学习的视网膜血管提取方法。首先提取视网膜血管的线性特征、纹理特征、矩特征、方差特征和灰度特征等作为样本特征;然后通过随机森林模型训练得到视网膜图像血管分类器,由随机森林算法初步提取血管;最后利用视网膜血管灰度分布信息和连通域信息进行血管图像后处理,进一步去除初步提取结果中的伪影和病灶等非血管成分,获得最终的视网膜血管分割图像。通过在 DRIVE 和 STARE 眼底图像数据库上的实验仿真可知,该文算法的敏感度分别为 0.8354、0.8452,准确率分别为 94.83%、95.34%,总体指标优于已有的视网膜血管图像分割方法。

关键词 视网膜血管提取;特征提取;有监督学习;随机森林;血管图像后处理

中图法分类号 TP18

DOI号 10.11897/SP.J.1016.2018.02566

Supervised Blood Vessel Extraction in Retinal Images Based on Multiple Feature Fusion

LIANG Li-Ming¹⁾ LIU Bo-Wen¹⁾ YANG Hai-Long²⁾ SHI Fei³⁾ CHEN Xin-Jian³⁾

¹⁾(School of Electrical Engineering and Automation, Jiangxi University of Science and Technology, Ganzhou, Jiangxi 341000)

²⁾(State Grid Guangyuan Power Supply Company, Guangyuan, Sichuan 628000)

³⁾(School of Electronics and Information Engineering, Soochow University, Suzhou, Jiangsu 215006)

Abstract Retinal blood vessel segmentation plays an important role in ophthalmic diagnosis and treatment. Many research achieved segmentation with single feature extraction in decades, including supervised and unsupervised methods. Despite the results of these works were acceptable and significant, retinal vessel would be rupture or too thin in width on final binary images. To solve the above problem, this paper presents a supervised method for blood vessel extraction based on multiple feature fusion in retinal images. The proposed method consists of four steps. First, green channel images are separated from raw retinal images for their clear blood vessel information. Optic disc and macular center are removed by bilateral filtering. The intensity of processed images is stretched to 0—255. Second, according to changes in vessel morphology such as shape, tortuosity, branching pattern, width and size, a 34-D feature vector is extracted from linear feature, texture feature, moment feature, variance feature and intensity feature. Most retinal vascular morphological features are taken into consideration by means of the multiple feature fusion vectors. These features describe retinal vessel from edge information, intensity difference,

收稿日期:2017-05-05;在线出版日期:2017-11-16。本课题得到国家“九七三”重点基础研究发展计划项目(2014CB748600)、国家自然科学基金(81371629,61401293,61401294,81401451,81401472,51365017)、江苏省自然科学基金(BK20140052)、江西省自然科学基金资助项目(20132BAB203020)、江西省教育厅科学技术研究重点项目(GJJ170491)资助。梁礼明,男,1967年生,硕士,教授,主要研究领域为机器学习与医学图像分析。E-mail: lianglm67@163.com。刘博文,男,1994年生,硕士,主要研究方向为机器学习与医学图像处理。杨海龙,男,1990年生,硕士,高级工程师,主要研究方向为过电压识别与数字图像分割。石 霏,女,1980年生,博士,讲师,主要研究方向为医学图像处理及分析。陈新建(通信作者),男,1979年生,博士,教授,主要研究领域为模式识别、机器学习和医学图像处理与分析。E-mail: xjchen@suda.edu.cn。

blood vessel size, connectivity and statistics. Third, feature vectors in every pixel are treated as training data and manual segmentation standard is treated as training label. A random forest classifier, known for its simplicity, anti-overfitting and information fusion capability, is trained with 34-D feature vector and its label. Taken different feature into consideration, 100 decision trees are established from random forest model. During each decision tree, the vessel pixel is set as positive point and the non-vessel pixel is set as negative point. Preliminary binary segmentation results are voted by multi-decision tree classifier. Finally, segmentation results are obtained from vessel image post-processing. Small or non-vessel pixels, like artifact and lesion noise, are removed via vessel image post-processing filter operators which are defined with the information of intensity distribution and connected domain. The proposed method is tested on two publicly available fundus databases DRIVE and STARE. Average sensitivity is 0.8354 and 0.8452 on the DRIVE and STARE database respectively. Meanwhile Average accuracy is 94.83% and 95.34% on the DRIVE and STARE database respectively. The proposed method achieved highest sensitivity compared with existing method. Moreover, the accuracy also approaches the best value. The experiment results showed that proposed method acquired good segmentation performances in small blood vessel and connectivity. The results compared in each healthy and unhealthy retinal image achieved similar sensitivity and accuracy, which denotes that the strong robustness and good stability of proposed method. In comparison with the existing methods, the proposed method achieves the following contribution: feature extraction in this paper contains vascular geometry, morphology, intensity and statistic information, which describes retinal vessel information as much as possible. Healthy and unhealthy retinal vessel segmentation were both performed and achieved high accuracy. The vessel image post-processing method is also available in other vessel segmentation post-processing.

Keywords retinal vessel segmentation; feature extraction; supervised learning; random forest; vessel image post-processing

1 引言

视网膜血管病变能够反映青光眼、糖尿病、高血压、动脉硬化、心血管疾病等全身性疾病^[1],通过对视网膜血管的数量、角度、分支、曲度等参数的分析,能够辅助医师诊断患者病情^[2].因此使用数字图像处理技术提取视网膜血管,在疾病的诊断和治疗上具有实际的临床价值.2D彩色眼底图像能够清晰地、直观地反映视网膜血管结构和病灶^[3],而且能够通过彩色眼底相机对人眼直接拍摄得到,具有非入侵和非创伤性,这一特点使2D彩色图像成为视网膜血管提取的主要数据来源.

随着视网膜血管提取算法研究的深入,其方法大致可分为有监督和无监督两大类.无监督算法主要是采用预制的准则去完成血管和背景的划分,不需要先验知识和金标准标签.因此相比有监督方法,无监督方法有计算时间少、计算复杂度低和模型简

洁的优点.视网膜血管无监督方法一般包括:常规匹配滤波、图像形态学处理、血管跟踪、阈值分割、区域生长等.Frangi等人^[4]利用Hessian矩阵特征值在血管和背景上的差异性去构建血管滤波响应函数,以模板滤波的方法实现了视网膜血管分割.Wang等人^[5]使用Gabor小波变换滤波器响应作为分类特征实现血管分割.Nguyen等人^[6]构造了一个多尺度线性特征检测器(MSLD)对视网膜血管图像滤波得到提取结果.Yin等人^[7]提出了一种基于最大后验概率的血管跟踪模型,用高斯函数对血管截面的灰度值拟合判断跟踪血管结构,该方法在血管交叉和分支处有良好性能.Lázár和Hajdu^[8]实现了基于灰度发生矩阵(GLCM)的局部自适应阈值血管分割,该方法在彩色图像和灰度图像中均有一定的鲁棒性.Orlando等人^[9]提出了一种基于像素方向响应相似度向量的混合区域生长方法,这种血管提取方法只需要相对少的计算和预处理.

有监督学习是指利用专家标记好的视网膜血管

标签作为训练数据,并用特定的训练模型得到一个分类器.在有监督学习中,首先需要选择一组区分度最大的特征向量,再依据所选择的向量选择合适的训练模型得到分类器.近年来有监督的机器学习算法在视网膜血管提取方面有众多成果,从最初的朴素贝叶斯分类器和 KNN 分类器发展到支持向量机(SVM)和人工神经网络(ANN),血管分割准确率逐步提高.随着深度学习在计算机视觉的成功应用,神经卷积网络(CNN)将视网膜血管分割算法的性能大大提高.其中 Mapayi 等人^[10]使用多尺度小波变换获取视网膜每个像素点的表征,训练了一个基于条件概率的贝叶斯血管分类器;Marín 等人^[11]采用灰度特征和矩不变特征来描述血管图像中的像素,并作为神经网络的输入特征训练得到血管分类器;Lupascu 等人^[12]以多尺度高斯匹配滤波、多尺度小波变换以及 Hessian 矩阵特征值等构建血管响应函数获取视网膜像素点的表征,再以此为 AdaBoost 集成分类器的训练集;Cheng 等人^[13]以笔划宽度变换(Stroke width transform, SWT)^[14]和 weber 局部描述符^[15]表征像素点,训练了一个随机森林血管分类器. Zhu 等人^[16]将极限学习(ELM)理论应用在眼底彩照血管分割上,提取了 39 维的特征向量经 ELM 分类器得到分割结果. Sekou 等人^[17]使用稀疏表示与字典学习提取血管特征,最后用随机森林分类器实现了血管分割. Liskowski 等人^[18]提出了一种深度神经网络血管分割模型,该方法的 AUC 可以达到 0.99. Fu 等人^[19]提出了一种全连接的 CNN 血管分类模型,这类深度学习模型可以考虑大跨度像素之间的联系. Luo 等人^[20]将 CNN 与条件随机场(CRF)串联,提出了 CNN-CRF 网络模型用以分割血管. Maninis 等人^[21]基于 CNN 提出了视网膜图像深度理解网络(DRIU),该网络可以同时分割视盘和血管像素.

尽管上述视网膜血管提取算法取得了可接受的结果,但视网膜血管提取仍然面临不少挑战.匹配滤波方法的许多参数需要人工设定,算法性能在不同数据库上差异很大,基于形态学的提取方法对噪声过于敏感且轮廓初始化步骤复杂.集成学习方法的特征提取往往只包含一类特征,最终导致血管分割结果不连续或者微小血管提取效果不理想.神经卷积网络方法性能较好,但其对硬件系统的要求较高,而且视网膜血管数据集有限,网络参数易过拟合.

针对以上方法存在的不足,本文提出了一种多特征融合的有监督学习视网膜血管提取方法.首先,增强原始图像信噪比,去除血管分割视盘和黄斑的

影响.其次,结合灰度差异、形态学、统计学以及血管纹理知识,在每个像素点上,选择最能体现血管与非血管像素之间差异的特征(线性特征、纹理特征、矩特征、方差特征、灰度特征).将每个点的特征依次排列组成该点特征向量,获取具有尺寸不变性、旋转不变性的像素特征向量,使之能够最大限度地区分视网膜血管像素与背景像素.然后,把每个像素的特征向量作为训练数据,每个像素的标签作为训练标签,通过随机森林模型训练得到多决策树的集成学习分类器,在测试集上得到血管提取初步结果.最后,根据血管与病灶的形态学差异,定义不同的形态学滤波算子^[22],移除病灶和伪影,得到最终的血管分割结果.其流程框图如图 1 所示.




图 1 本文算法流程图

本文的主要贡献如下:本文从尺寸、边界、分支模式、统计学和灰度值多个角度描述血管特性,得到了连续性好、对血管敏感的视网膜血管分割结果.随机森林分类器能很好地融合五类特征,使本文算法

在健康和病变图像中都有良好的鲁棒性。依据血管灰度和形态学定义的后处理算子有良好的推广性,适用于各类血管提取算法的后处理步骤。

2 理论基础

随机森林算法^[23] (Random Forest, RF) 是由 Breiman 于 2001 年在 Bagging^[24] 的基础上提出的,它是由一组二叉决策树 $\{h(\mathbf{X}, \boldsymbol{\theta}_k), k=1, 2, \dots, K\}$ 构成的集成分类器。其中 $\{\boldsymbol{\theta}_k\}$ 是通过 bootstrap 重采样技术获得的具有独立同分布的随机向量, K 表示森林规模。在给定的样本集 $(\mathbf{X}, \mathbf{Y})$ 的条件下,随机森林分类结果通过决策树的投票决定,定义如下:

$$y^* = \arg \max_{y \in Y} \sum_{k=1}^K I(h(x|k)=y) \quad (1)$$

其中 $I(\cdot)$ 为示性函数,取值是 $[0, 1]$ 。式(1)表示随机森林算法将把投票数最多的类别作为样本数据的输出类别。

每棵决策树分类器的训练集都是从原始数据集 $(\mathbf{X}, \mathbf{Y})$ 中以 bootstrap 采样方法随机采样得来的,其子特征集 f 是从总特征集 F 随机抽取得到且满足 $f \leq \sqrt{F}$ 。训练决策树时,根节点按照信息增益率进行分裂。其余量函数 (Margin Function) 定义如下:

$$mg(\mathbf{X}, \mathbf{Y}) = av_k I(h_k(x)=y) - \max_{j \neq y} av_k(h_k(x)=j) \quad (2)$$

其中, $av_k(\cdot)$ 表示取平均,余量函数 m_g 刻画了在正确分类 $\mathbf{Y}$ 下 $\mathbf{X}$ 的得票数超过其它类别的最大的票数的程度。余量函数 m_g 越大,表示该决策树的置信度越高。随机森林的泛化误差定义如下:

$$PE = P_{\mathbf{X}, \mathbf{Y}}(mg(\mathbf{X}, \mathbf{Y}) < 0) \quad (3)$$

其中, $\mathbf{X}, \mathbf{Y}$ 表示概率 P 覆盖 $\mathbf{X}, \mathbf{Y}$ 空间。

在随机森林中,当决策树 $h(\mathbf{X}, \boldsymbol{\theta}_k)$ 的数量足够大时,它遵循强大数定律。

定理 1. 随着决策树的增加,对于所有的序列 $\boldsymbol{\theta}_k$, PE 几乎处处收敛于:

$$P_{\mathbf{X}, \mathbf{Y}}\{P_{\boldsymbol{\theta}}(h_k(x, \boldsymbol{\theta})=y) - \max_{j \neq y} P_{\boldsymbol{\theta}}(h_k(x, \boldsymbol{\theta})=j) < 0\} \quad (4)$$

随机森林算法具有良好的抗过拟合性质, Breiman^[23] 在其论文中已证明。

模型的泛化误差 PE 有一个上边界,即

$$PE \leq \frac{\bar{\rho}(1-s^2)}{s^2} \quad (5)$$

其中, $\bar{\rho}$ 是决策树之间的平均相关度, s 是决策树的分类强度。 $\bar{\rho}$ 由边际函数的方差和决策树的平均差得到

$$\bar{\rho} = var(mr) / (E_{\boldsymbol{\theta}} sd(\boldsymbol{\theta}))^2 \quad (6)$$

其中, s 是边际函数在整个样本空间的期望,其定义如下:

$$s = E_{\mathbf{X}, \mathbf{Y}}(mr < 0) \\ = E_{\mathbf{X}, \mathbf{Y}}(P_{\boldsymbol{\theta}}(h_k(x, \boldsymbol{\theta})=y) - \max_{j \neq y} P_{\boldsymbol{\theta}}(h_k(x, \boldsymbol{\theta})=j) < 0) \quad (7)$$

在选取多特征向量作为有监督学习的训练样本时,若要得到泛化性能好的集成分类器,需要个体学习器尽可能独立。随机森林因每棵树的样本集采用 bootstrap 采样,这样得到互有交叠的采样子集,既涵盖了大部分样本点,又使生成树之间的差异性大大增加。选择随机森林学习分类器用于视网膜血管特征的训练分类,不但能融合所提取的多类特征,而且能很好地避免因大量特征数据导致的过拟合,得到泛化性能良好的视网膜血管分类器。

3 随机森林的血管分类

在视网膜血管提取中,假设有 N 个训练样本 $\{(\mathbf{X}_1, y_1), (\mathbf{X}_2, y_2), \dots, (\mathbf{X}_N, y_N)\}$ 。其中 $\mathbf{X}_i$ 是第 i 个输入样本,每个样本是 d 维的特征向量 $(x_{i1}, x_{i2}, \dots, x_{id})$, y_i 是对应于样本 $\mathbf{X}_i$ 的标签, $y_i \in \{1, 2\}$ 。然而为了得到视网膜血管分类器,首先需要从视网膜图像中提取能够描述血管与背景差异的特征向量,并作为随机森林的输入特征,才能最终训练得到血管分类器。因此本文血管提取算法重点在于对视网膜血管特征的提取。依据血管不同特征的不同特点,可以从血管的尺寸、形状、边界、分支模式和统计学等角度区分血管像素与非血管像素。为了增强眼底图像中血管每类特征的强度,需要使用不同的预处理方法对各种特征增强,如高斯滤波、顶帽变换等。待相应特征得到增强之后,再用对应的特征提取方法得到特征向量各个维度的特征值,最后得到该点的视网膜血管特征向量。

3.1 视网膜图像预处理

由于眼底图像中包含血管、背景区域、掩模甚至是噪声,血管对比度较低,在血管特征提取前需要对原始图像预处理以提高血管特征的信噪比。通过对 STARE 和 DRIVE 眼底图像数据库的观察,发现眼底图像的绿色通道视网膜图像对比度高且噪声水平更低。为此,本文获取眼底图像的绿色通道视网膜图像作为预处理对象。首先以半径为 3 的圆形内核腐蚀掩模图像对眼底图像进行边缘拓展。其次,为保证血管图像边缘像素质量,采用双边滤波降噪,其中像素邻域直径为 25,颜色空间 $Sigma$ 为 50,坐标空间 $Sigma$ 为 12。最后将滤波后的图像灰度拉伸到 $0 \sim$

255,使得血管增强图像背景更加均匀,以保证血管与背景区域的特征区分度最大。

由双边滤波消除噪声,再通过对比度拉伸得到血管增强图像如图 2 所示。其中图 2(a)是来自

STARE 数据库的第 7 张原始图像;图 2(b)是其绿色通道图像;图 2(c)是其血管增强结果;图 2(d)是原图像矩形区域局部细节;图 2(e)是增强图像矩形区域局部细节。




图 2 视网膜血管预处理

从图 2 可以看出,双边滤波较好地保存了血管边缘信息。这对后续的视网膜特征提取,尤其是微小血管的特征提取十分有利;同时双边滤波较好地改善了黄斑与视盘中心背景处剧烈变化的灰度。在灰度拉伸后,背景区域与血管的对比度有了显著提高。

双边滤波与灰度拉伸处理提升了视网膜图像中血管与背景的对比度,增强了血管特征。然而,基于多特征的特征提取方法考虑了血管图像的多种特征,每类特征的侧重各有不同。因此,在提取每类特征之前先使用高斯函数模糊不感兴趣特征,降低不同特征间的耦合程度。在选用的数据库中,视网膜血管的宽度集中在 2~7 像素内,故采用尺寸分别为 3,5,7 的高斯算子对宽度分别小、中、大的血管特征加以屏蔽,使得提取的特征值尽可能包含同类特征。同时,一张图像经过三种尺度高斯滤波得到了三张图像,实验数据得以扩充。

3.2 特征提取

图像特征的选择会直接影响分类器的性能,本文基于视网膜眼底图像血管和背景的区别,引入线性特征、纹理特征、矩特征、方差特征、灰度特征以及采用多尺寸、形态学、高斯滤波等图像处理技术尽可能地度量视网膜血管和背景的差异。对图像的每个像素点提取了 34 个特征,这里表示为 $\{F_i\}$, $i=1$,

2, ..., 34。每个特征的获取原理具体如下:

3.2.1 多尺度线性特征

在视网膜图像中,血管区域大多为连续且径直的灰度值相近区域,这使得线性特征能很好区分血管区域与背景区域。多尺度线性特征的提取基于视网膜血管的连通性得到,该特征能保证血管提取的连续性。为提高线性特征的区分度,对预处理后的图像再进行图像增强。对预处理图像反转得到 I_{rev} ,对反转图像 I_{rev} 作冒顶变换得到去除了视盘和黄斑的图像 I_{top} 。

在增强后的图像中对每一个像素点,计算尺寸为 $W \times W$ 像素区域的平均灰度值 I_{avg}^w ,其计算公式为

$$I_{\text{avg}}^w = \frac{1}{W^2} \sum_{x=1}^W \sum_{y=1}^W I(x, y) \quad (8)$$

其中, $I(x, y)$ 为窗口中点 (x, y) 的像素值。

每一个像素点从水平方向开始,以 15° 为间隔,共有 12 条不同方向经过该点的直线。计算出这 12 条曲线的平均灰度值 I_i^L ($i=1, 2, \dots, 12$),灰度值最大的一条定义为“获胜直线”^[8],计算获胜直线的灰度值

$$I_{\text{max}}^L = \max\{I_i^L\} (i=1, 2, \dots, 12) \quad (9)$$

本文的线性特征在定义为

$$R_W^L = I_{\max}^L - I_{\text{avg}}^W \quad (10)$$

其中, $W = (L+1)/2$. 窗口宽度 W 一般选为血管宽度的两倍, 这样计算得到的获胜直线才能与血管的中心亮线相吻合, 检测得到的线性特征才有意义. 因此, 检测线长度 L 依据数据库中血管的宽度选取, 本文取 $L = \{3, 5, 7, 9, 11\}$, 得到 5 个尺度线性特征, 即 $F_1, F_2, \dots, F_5$. 多尺度线性特征既能够以灰度值差异提取血管特征, 又能保证提取结果的连通特性.

3.2.2 纹理特征

视网膜血管和背景可以看成具有不同纹理特性的两种结构, 不同结构的纹理特征不同, 引入 LBP (Local Binary Pattern) 纹理特征描述视网膜图像的局部边缘特征^[25].

为增强视网膜纹理信息且减少噪声, 在提取纹理特征前先用高斯滤波增强图像得到图像 I_{Gau} . 视网膜图像中每一个像素点 (x_c, y_c) 的 LBP 算子定义为

$$\text{LBP}(x_c, y_c) = \sum_{p=0}^{n-1} 2^p I(i_p - i_c) \quad (11)$$

其中, (x_c, y_c) 为中心像素坐标, n 为中心像素邻域像素总数, i_p 为第 p 个邻域像素的灰度值, i_c 为中心像素灰度值, $I(i_p - i_c)$ 为示值函数, 其定义为

$$I(i_p - i_c) = \begin{cases} 1, & (i_p - i_c) \geq 0 \\ 0, & \text{其他} \end{cases} \quad (12)$$

在正方形邻域内计算纹理特征, n 个点经过比较可产生 n 位二进制数, 将这 n 个数依次排列成一个二进制数, 取其所有排列中的最小值作为特征值.

采用三种尺寸的高斯模板对血管增强图像进行滤波, 然后采用像素大小为 3×3 和 5×5 的邻域窗口计算 LBP 特征, 这样每个像素点的特征提取共有 3×2 种组合, 总计 6 个特征 $F_6, F_7, \dots, F_{11}$, 且这些特征具有尺寸不变性和旋转不变性. 纹理特征主要描述血管与背景的边缘信息.

3.2.3 矩特征

视网膜血管结构相对于背景可看成突出的轮廓, 而 Haar 特征^[26]具有描述物体边缘和轮廓的作用, 因此本文选取 Haar 特征中垂直矩特征、水平矩特征和对角矩特征三种矩形框检测视网膜血管微小结构. 由于受试者个体不同以及其拍摄时的主观性, 获取的眼底图像角度都不尽相同. 不同的眼底图像视盘位置不同, 血管走势也不同, 这使得用一般方法提取的特征值的分类性能在不同图像上差异很大. 对于多角度、尺寸的血管信息, 本文采用 Haar 特征获取尺度不变与旋转不变特征.

三种 Haar 特征如图 3 所示, 选取窗口尺寸为



图 3 Haar 矩特征

W 的矩形区域作为基本算子. 矩特征的计算公式为

$$H = \sum_{\text{White}} I(x, y) - \sum_{\text{Black}} I(x, y) \quad (13)$$

即每个像素的矩特征为 Haar 算子中白色区域所有像素灰度值之和减去黑色区域所有像素灰度值之和.

在提取矩特征前首先采用三种尺寸的高斯模板对血管增强图像进行滤波. 由于血管像素与非血管像素在窗口中各占 50% 时, Haar 特征对纹理的区分最明显, 当选取滑动窗口尺寸为血管宽度两倍时, 矩特征值在血管边界处得到最大值, 故选取 $W = \{5, 7, 9\}$. 因此每个像素点的特征提取共有 3×3 种组合, 总计 9 个特征 $F_{12}, F_{13}, \dots, F_{20}$. 这样可取得具有尺寸不变性的垂直矩特征与水平矩特征以及具有尺寸不变性与旋转不变性的对角矩特征. 矩特征主要描述了微小血管信息与分支信息.

3.2.4 方差特征

图像的局部方差 (Local Variance, LV) 能够描述物体边缘轮廓结构, 局部方差能够从统计学角度较好地地区分血管区域与背景区域. 在特征提取前同样使用高斯滤波器对预处理图像增强滤波, 用 $\text{var}(I(x, y))$ 表示视网膜增强图像 I_{Gau} 的局部方差, 对于像素尺寸为 $W \times W$ 的矩形区域, 局部方差计算特征为

$$\text{var}(I(x, y)) = \frac{1}{W^2} \sum_{p=1}^{W^2} (\eta_p^W - \bar{I}(x, y)^W) \quad (14)$$

其中, η_p^W 表示尺寸长度为 W 区域内的第 p 个像素值, $\bar{I}_{x,y}^W$ 表示尺寸长度为 W 区域内的平均像素值, 计算公式如下:

$$\bar{I}(x, y)^W = \frac{1}{W^2} \sum_{p=1}^{W^2} \eta_p^W \quad (15)$$

本文在提取方差特征时同样采用三种尺寸的高斯模板对血管增强图像进行滤波, 依据血管尺寸分别计算窗口尺寸大小为 $W = \{3, 5, 7\}$ 的像素局部方差, 使每个像素点获得具有尺寸不变性的 9 个特征 $F_{21}, F_{22}, \dots, F_{29}$. 方差特征主要描述了图像中的异常点信息.

3.2.5 灰度特征

由血管增强图像可知, 血管与背景灰度值分布范围只有小部分存在重叠, 二者的灰度值有较大的区分度. 这里对血管增强图像进行反转和 top-hat

变换,获得特征 F_{30} ;然后采用三种尺寸高斯模板对 top-hat 变换后的图像滤波及全阈值分割,若为血管则灰度值不变,反之灰度值变为 0,以此获得灰度特征 F_{31}, F_{32} ;采用尺寸因子 $\sigma = \{6/6\}$ 高斯模板对反转图像滤波及 top-hat 变换,得到特征 F_{33} ;对特征 F_{33} 采用尺寸因子 $\sigma = \{9/6\}$ 高斯模板滤波得到特征 F_{34} . 特征 $F_{31}, F_{32}, F_{33}, F_{34}$ 主要是为了描述视网膜的大尺寸血管,同时抑制噪声特征的产生,提高后期基于随机森林算法训练的血管分类器的抗噪性.

最后,为便于后续的计算,对提取的视网膜血管特征 $F_1, F_2, \dots, F_{34}$ 进行归一化处理组成特征向量,其数值转化到区间 $[0, 1]$.

3.3 随机森林算法步骤

步骤 1. 选取训练集. 视网膜眼底图像一般是由数十张健康和病变的视网膜图像组成的. 如果单纯随机地选取单幅图像的所有像素点作为训练集,由于数据库图像有限,选取的结果随机性过大,样本很难符合真实环境下的数据分布,训练结果不具有代表性. 因此本文以像素点为最小随机选取单位,随机选取数据库图像中的像素点. 以专家分割结果作为标准,一幅视网膜图像中血管像素与非血管像素的比例约为 1:4. 为了让选取的血管像素点与非血管像素点更加符合真实比例,本文选取样本像素点时也按照 1:4 的比例在正负样本中随机选取共 20 万个像素点作为样本集.

步骤 2. 采样随机树. 对样本集采用 bootstrap 采样得到样本子集 θ_k , 作为训练每棵分类决策树 $h(X, \theta_k)$ 的训练集. 综合考虑时间开销与算法过拟合,随机森林规模 $K=100$.

步骤 3. 生成决策树. 每棵随机树按照信息增益原则进行样本属性划分. 决策树尽最大程度生长,若样本数少于 50 或者树深已达到 20 后,待分裂节点样本还未纯净,那么停止生长. 生成完成后决策树不剪枝.

步骤 4. 集成分类器. 生成的 100 棵决策树以相对多数投票准则结合,获得票数最多的类作为最终输出,由此得到有监督下的随机森林分类器.

3.4 血管图像后处理

采用上述特征提取方法得到的样本集,能够使训练出的随机森林血管分类器最大限度地提取视网膜血管信息,获得高敏感度. 但由于病灶和伪影的灰度特征以及 Haar 矩特征与血管特征相似,随机森林算法的提取结果往往还包含病灶和伪影. 在处理有病变的视网膜图像时,病灶和伪影也将被划分为

血管,这将引起特异性偏高. 为进一步提高本文算法的鲁棒性,引入血管图像后处理,从灰度和形态学特征考虑,在保证血管提取敏感度的同时,滤去随机森林提取结果中的非血管像素,降低特异性,提高血管分割精度. 具体实现原理如下.

首先从灰度差异考虑,通过观察血管增强后的视网膜图像灰度值分布,视盘区域是一个灰度值高于其它像素的连续区域. 在灰度直方图中,高亮灰度值区域(视盘)与视网膜图像主要信息区域(血管和背景)分布在以 190 为分割阈值的两侧. 因此,选择 190 为灰度阈值,将灰度值大于 190 的分割结果滤去,排除由视盘中心灰度值过高所导致的血管图像误分割,进一步提高分割准确率.

然后从形态学考虑血管、病灶和伪影的先验知识^[27],血管像素区域往往狭长、弯曲、像素跨度大,而病灶伪影像素区域往往长度与宽度相近、饱满、像素跨度小. 因此以连通域的面积(Area)和连通域的长(Length)、连通域的宽(Width)为基础评价指标. 但单从这三项指标不足以有效区分血管与病灶伪影,故通过数学运算定义 $Length/Width$ 和 $Length \times Width$ 两个新的几何形态学算子. 几何形态学算子的阈值由该算子的统计直方图确定,即选取该血管像素的统计波峰与病灶伪影像素的统计波峰之间的波谷作为滤波阈值. 其几何算子定义如下:

- (1) $0.4 < Length/Width < 2.5$;
- (2) $Length \times Width < 3.5 \times Area$;
- (3) $Area < 30$.

随机森林算法通过生成随机树的方法对血管图像特征进行分类,能解决大样本训练下的过拟合现象,使得血管分类结果相比于金标准不至于过细,保证分类结果敏感度. 然而该算法也将导致病灶等非血管区域被误识别为血管区域,这会严重影响提取算法的特异性. 因此,为提高算法的特异性,在得到 RF 的分类结果之后再进行血管图像后处理是十分必要的. 后处理效果在图 4 中予以展示.

4 实验结果与分析

本文实验仿真平台为 vs2013+opencv2.4.10, 计算机配置为 Intel(R) Core(TM)i7-7700 CPU@3.60GHz,8.00GB 内存,64-bit Operating System. 血管提取算法将在 STARE 和 DRIVE 数据库上进行验证,并做定性分析和定量分析. 程序采用 C++ 编程实现,用 RF(Random Forest)表示随机森林血

管提取结果,TP(This Paper)表示使用 3.4 节血管后处理方法去除 RF 中非血管像素(过亮区域、伪影、病灶)所得的最后血管图像. 本文算法分别在 STARE 和 DRIVE 视网膜数据集上测试.

STARE(Structured Analysis of the Retina)于 1975 年由 Michael Goldbaum 建立,各有 10 幅有病变和健康的眼底图像,图像像素尺寸 605×700 ,每幅图像都对应两位专家的手动分割结果(金标准). 本文取 labels-ah1 作为血管提取算法性能验证的金标准,其次训练随机森林模型时每幅视网膜图像随机抽取 3000 个血管样本和 7000 个非血管(背景)样本共 200 000 样本作为训练样本.

DRIVE (Digital Retinal Images for Vessel Extraction)于 2004 年由 Niemeijer 团队建立,分别包含了训练集和测试集,其眼底图像数各 20 幅,图像像素尺寸 565×584 ,每幅图像都对应两位专家的手动分割结果(金标准)1st_manual 和 2nd_manual. 本文取 1st_manual 作为血管提取算法性能验证的金标准,在测试集中对每幅视网膜图像随机抽取 3000 个血管样本和 7000 个非血管(背景)样本,测试样本从 20 幅训练图片中选出,共选择 200 000 样本作为随机森林血管分类器的训练集.

4.1 视网膜血管提取结果

STARE 和 DRIVE 数据库中都存在健康视网膜图像与病变视网膜图像. 在视网膜血管提取中,病

变视网膜图像分割一直是此问题的难点与重点,其分割结果也是评价算法优劣的一项重要指标. 本文对 STARE 和 DRIVE 两个数据库中的所有图像都进行了分割,这里以 STARE 数据库的 im0081(健康视网膜)和 im0239(病变视网膜)的分割结果作为结果展示. 每张图像的各项指标详情将以表格形式在后文列出.

图 4 是健康和病变视网膜图像的血管提取结果. 其中图 4(a)和(d)分别是健康视网膜和病变视网膜原图像,图 4(b)和(e)分别是利用 RF 算法对健康视网膜和病变视网膜提取的结果. 由图 4(b)可知,单纯的 RF 血管分类器在正常视网膜图像上有一个较好的血管提取结果,血管图像中仅含有少量的伪影等非血管成分,图 4(c)为血管后处理结果,后处理基本上消除了离散而细小的伪影与病灶区域. 从图 4(e)中可见,在处理病变的视网膜图像时,RF 的提取结果含有更多病灶和伪影等非血管成分,图 4(f)是后处理结果,可以看出本文定义的形态学算子消除了大部分的非血管成分,证明了本文所采用的血管后处理方法的有效性. 综上,通过对血管提取结果的分析对比可以看出,单纯的 RF 算法对健康视网膜血管提取效果较好,但在病变图像中不能很好得分分类血管和病灶,而血管图像后处理弥补了其对病变视网膜图像时特异性不足的缺点,增强鲁棒性,使得本文算法的适应性有了进一步提高.




图 4 本文算法血管提取结果

图 5 给出了文献[27]、文献[28]以及本文算法在 DRIVE 数据库上两幅视网膜图像的分割结果,第 1 行是健康视网膜图像,第 2 行是早期病变的视

网膜图像. 为方便分析对照,图 5 还附上了原图像与专家手动提取的参考标准图像,第 3 行是细小血管与血管重叠处的细节放大. 图 5(a)为视网膜原始图

像,图 5(b)是本文选取的专家手动分割标准参考图像,图 5(c)是文献[27]运用形状先验水平集算法得到的提取结果,图 5(d)是文献[28]运用多尺度线性特征算法得到的提取结果,图 5(e)是本文的提取结果.通过对比不同算法的分割结果发现,文献[28]算法在血管分支处与重合处提取效果不好,提取结果中有部分

分支血管断裂,视盘误分割.而文献[27]算法提取的血管宽度过细,许多细小血管没有体现,血管提取的完整度不高.在诊断中细小血管对视网膜图像有着重要意义,丢失细小血管信息不利于医生临床诊断.相比上面这两种做法,本文的提取算法相比文献[28]算法具有更好的连通性,相比文献[27]有更好的完整性.




图 5 不同算法分割结果比较

在健康视网膜图像上,本文算法与文献[28]算法均有不错的效果,虽然文献[27]的提取结果血管宽度最接近参考标准,但该算法丢失了许多细小血管信息,许多血管末端由于水平集算法的过拟合现象而未被提取.文献[28]所运用的多尺度线性特征检测方法其实是本文血管特征提取的一部分;另外从集成学习的角度考虑,文献[28]的分类器为提取单一特征的弱分类器,本文分类器融合了多种特征,属于强分类器,所以本文提取结果不仅包含了大血管信息,还对细小血管信息有足够的保留.

早期病变视网膜图像由于眼底结构发生变化,其感光特性与正常视网膜也有不同.对比图 5(a)第 1 行的正常图像与第 2 行的早期病变图像,二者不同的感光特性反应在眼底彩照中为病变图像眼底较为浑浊,在远离视盘区域有大片暗色区域,该处的血管像素对比度急剧下降,这对视网膜血管的提取是一个不小的挑战.图 5 第 2 行展示了各算法在早期病变视网膜图像中的血管提取结果,第 3 行选取了第 2 行图像中的血管交叉与细小血管区域进行放大并做细节对比.从细节对比中可知,文献[28]的提取

结果中血管管状结构不明显,在血管末端和分支处存在断裂;文献[27]的提取结果仅有主要的血管分支,许多细小血管未被提取.从对比算法的实验结果可以发现,从灰度值变化或者形态结构单方面考虑血管与非血管点特征,其最终的分割能力都十分有限.图(e)中展示了本文的提取结果,相比于上述算法,本文方法的提取结果有如下优势:在血管交叉处不易因其特殊的形态结构而造成分割断裂,分割结果完整、连通性好;末端的视网膜血管能很好地识别;在视网膜病变所致的暗色区域也能正常地分割血管,算法鲁棒性好.

为定量分析本文视网膜血管提取算法性能.本文统计了血管分割中 5 个常用的性能度量指标.其中敏感度又称真阳性率(*Sensitivity*),表示正确分类的血管像素占真实血管像素的百分率;假阳性率 *FPR*(False Positive Rate)表示将背景像素错分为血管的像素占真实背景像素的百分率;特异性(*Specificity*)表示正确分类的非血管像素占真实非血管像素的百分率;精确率(*Precision*)表示正确分类的血管像素占总正确分类像素的百分率;准确率(*Accuracy*)表示正确分类血管和非血管像素占整个

图像总像素的百分率. F -measure 表示敏感度与精确率($Precision$)之间的比率关系. 血管提取性能指标的具体计算公式如下:

$$Sensitivity = \frac{T_P}{T_P + F_N} \tag{16}$$

$$FPR = \frac{F_P}{F_P + T_N} \tag{17}$$

$$Specificity = \frac{T_N}{T_N + F_P} \tag{18}$$

$$Sensitivity = \frac{T_P + T_N}{T_P + T_N + F_P + F_N} \tag{20}$$

$$F\text{-measure} = 2 \times Precision \times \frac{Sensitivity}{Sensitivity + Precision} \tag{21}$$

其中,真阳性(T_P)为正确识别血管像素的数目;真阴性(T_N)为正确识别非血管像素的数目;假阳性(F_P)为错误识别非血管像素的数目;假阴性(F_N)为错误识别血管像素的数目. 在这 5 类指标中假阳性率(FPR)越小越好,其余指标均越大越好. 表 1 和表 2 给出了本文算法在 DRIVE 数据库和 STARE 数据库上的血管提取性能度量指标. 为便于区分,每一类指标的最优值用加粗字体表示.

表 1 DRIVE 数据库视网膜分割结果

Image	Sen		FPR		Spe		Pre		Acc	
	RF	TP	RF	TP	RF	TP	RF	TP	RF	TP
1	0.9508	0.9206	0.0838	0.0652	0.9162	0.9348	0.5266	0.5804	0.9193	0.9335
2	0.9015	0.8769	0.0454	0.0375	0.9546	0.9625	0.6939	0.7275	0.9492	0.9538
3	0.9000	0.8682	0.0847	0.0583	0.9153	0.9417	0.5403	0.6226	0.9137	0.9344
4	0.8346	0.8116	0.0293	0.0250	0.9707	0.9750	0.7426	0.7666	0.9582	0.9599
5	0.7986	0.7759	0.0256	0.0216	0.9744	0.9784	0.7629	0.7879	0.9579	0.9594
6	0.8781	0.8345	0.0681	0.0470	0.9319	0.9530	0.5816	0.6567	0.9267	0.9414
7	0.8249	0.7947	0.0410	0.0272	0.9590	0.9728	0.6694	0.7460	0.9468	0.9565
8	0.7291	0.6989	0.0259	0.0192	0.9741	0.9808	0.7258	0.7743	0.9530	0.9566
9	0.8661	0.8180	0.0445	0.0323	0.9555	0.9677	0.6317	0.6909	0.9482	0.9556
10	0.8513	0.8202	0.0418	0.0342	0.9582	0.9658	0.6464	0.6825	0.9494	0.9538
11	0.8810	0.8501	0.0832	0.0537	0.9168	0.9463	0.5102	0.6090	0.9136	0.9377
12	0.8483	0.8159	0.0395	0.0328	0.9605	0.9672	0.6698	0.7017	0.9508	0.9542
13	0.8557	0.8207	0.0464	0.0361	0.9536	0.9639	0.6666	0.7111	0.9440	0.9499
14	0.9019	0.8600	0.0600	0.0442	0.9400	0.9558	0.5696	0.6312	0.9370	0.9481
15	0.8853	0.8647	0.0583	0.0450	0.9417	0.9550	0.5392	0.5968	0.9376	0.9485
16	0.9278	0.8789	0.0735	0.0535	0.9265	0.9465	0.5560	0.6196	0.9266	0.9403
17	0.8604	0.8044	0.0555	0.0390	0.9445	0.9610	0.5802	0.6556	0.9374	0.9478
18	0.9274	0.8937	0.0828	0.0630	0.9172	0.9370	0.4900	0.5498	0.9180	0.9336
19	0.9064	0.8888	0.0537	0.0482	0.9463	0.9518	0.6041	0.6252	0.9430	0.9466
20	0.8438	0.8108	0.0409	0.0358	0.9591	0.9642	0.6207	0.6429	0.9506	0.9530
overall	0.8686	0.8354	0.0542	0.0409	0.9458	0.9591	0.6164	0.6689	0.9390	0.9482

表 2 STARE 数据库视网膜分割结果

Image	Sen		FPR		Spe		Pre		Acc	
	RF	TP	RF	TP	RF	TP	RF	TP	RF	TP
1	0.8123	0.7931	0.0808	0.0621	0.9192	0.9379	0.4659	0.5255	0.9107	0.9263
2	0.7625	0.7207	0.0786	0.0641	0.9214	0.9359	0.4089	0.4450	0.9108	0.9215
3	0.8456	0.8180	0.0622	0.0356	0.9378	0.9644	0.4640	0.5939	0.9323	0.9556
4	0.8210	0.7793	0.0461	0.0294	0.9539	0.9706	0.5877	0.6798	0.9440	0.9564
5	0.8991	0.8853	0.0725	0.0552	0.9275	0.9448	0.5518	0.6145	0.9249	0.9395
6	0.9250	0.9159	0.0572	0.0391	0.9428	0.9609	0.5476	0.6366	0.9416	0.9577
7	0.9144	0.9058	0.0389	0.0334	0.9611	0.9666	0.6720	0.7025	0.9574	0.9617
8	0.9232	0.9141	0.0442	0.0363	0.9558	0.9637	0.6278	0.6701	0.9534	0.9600
9	0.9105	0.9002	0.0367	0.0320	0.9633	0.9680	0.6792	0.7058	0.9591	0.9625
10	0.9100	0.8896	0.0684	0.0437	0.9316	0.9563	0.5379	0.6403	0.9299	0.9509
11	0.8883	0.8697	0.0340	0.0301	0.9660	0.9699	0.6667	0.6891	0.9604	0.9627
12	0.9567	0.9528	0.0476	0.0416	0.9524	0.9584	0.6273	0.6575	0.9527	0.9580
13	0.9229	0.9155	0.0682	0.0539	0.9318	0.9461	0.5695	0.6240	0.9310	0.9434
14	0.9114	0.8973	0.0519	0.0398	0.9481	0.9602	0.6361	0.6921	0.9447	0.9545
15	0.8621	0.8340	0.0419	0.0309	0.9581	0.9691	0.6604	0.7182	0.9498	0.9574
16	0.8005	0.7763	0.0619	0.0464	0.9381	0.9536	0.5951	0.6553	0.9240	0.9355
17	0.9008	0.8872	0.0320	0.0268	0.9688	0.9732	0.7348	0.7648	0.9620	0.9655
18	0.7734	0.7448	0.0166	0.0112	0.9834	0.9888	0.7133	0.7797	0.9728	0.9765
19	0.8338	0.7974	0.0287	0.0192	0.9713	0.9808	0.5670	0.6510	0.9654	0.9729
20	0.7614	0.7063	0.0569	0.0322	0.9431	0.9678	0.4890	0.6103	0.9310	0.9503
overall	0.8667	0.8452	0.0513	0.0382	0.9488	0.9619	0.5901	0.6528	0.9429	0.9534

在这两个数据库中都选取了 20 幅图像作为测试集,每一张图像的数据指标包括敏感度、假阳性率、特异性、精确率以及准确率.除了本文算法(This Paper,TP)的各项指标,为了方便验证血管提取结果后处理算法性能,每一项指标都给出了 RF 算法的数据结果. RF 算法的敏感度高于本文算法,但其余三项指标和准确率都是本文算法有更好的指标.这是因为在移除病灶和伪影的后处理过程中,虽然移除了病灶和伪影像素,大大减少了 F_p ,但也不可避免地极少血管像素作为背景,减少了 T_N . 血管图像后处理以平均牺牲敏感度 0.03 为代价,改善了其余 4 项指标均,其中假阳性率平均减少 0.014,使特异性平均增加 0.013,精确率平均增加 0.052,准确率平均提高 0.007. 表 1 和表 2 说明视网膜血管图像后处理算法有显著的效果. 在两个数据库中,无论是健康视网膜图像还是病变视网膜图像,本文算法均能将准确率保持在 95%左右. 这表明本文算法对病变视网膜图像较好的提取能力,同时具有较强的抗病灶和抗噪声的能力.

4.2 多特征与单一特征 RF 算法性能比较

为了验证结合多类视网膜特征方法对算法性能的提升,在 DRIVE 数据库中分别使用 5 类单一特征(多尺度线性特征、LBP 局部特征、Haar 矩特征、方差特征、灰度特征)用于随机森林训练前 20 幅视网膜图像,最后得到 5 个单特征视网膜血管分类器. 统计每个分类器的敏感度与准确率,并与本文提出的 34 维多特征向量的算法对比,对比结果见表 3.

表 3 单一特征与多特征 DRIVE 数据库性能比较		
Feature	Sen	Acc
Multi-scale linear	0.7283	0.9403
LBP Feature	0.6825	0.8352
Haar Feature	0.6543	0.9247
Variance Feature	0.5782	0.7483
Intensity Feature	0.7366	0.9356
34-D Feature vector	0.8354	0.9482

从表 3 中可以看出,单一特征分类器的敏感度和准确率都不如多特征融合分类器. 多种单一特征经过融合其分类性能有了整体的提升,各类指标均高于仅用单一特征的分类指标. 表 3 通过定量分析表明本文选取的特征从各个方面体现了视网膜血管特征,也验证了本文选取的五类特征融合的方法是可行有效的.

4.3 不同视网膜血管分割算法性能比较

在视网膜血管分割算法中,有监督算法的性能

要普遍优于无监督算法,为验证本文选取的分类器的性能,选取了 SVM 和 AdaBoost 两种应用最广泛的有监督学习分类器作为对照算法,在 DRIVE 数据库中选取前 20 幅图像为训练图像,后 20 幅为测试图像,以每类算法的训练时间、分割时间、灵敏度和准确率作为性能指标. 对比实验结果如表 4 所示.

表 4 各类有监督分类器在 DRIVE 数据库中性能比较				
Method	Training time/s	Segmentation time/s	Sen	Acc
SVM	5739.6	1342.3	0.6324	0.9421
AdaBoost	749.9	14.2	0.7958	0.9371
Random forest	2497.1	12.6	0.8354	0.9482

从时间开销比较三类分类器,由于训练样本的维度高,在训练样本较大时,SVM 的计算复杂度急剧增加,其训练和分割时间远超过另二类方法,这不利于实时医疗辅助诊断. 而且由于不同的视网膜眼底图像适用于不同的核函数,SVM 算法的核函数需根据视网膜图像选择,算法适应性低. AdaBoost 算法有着最短的训练时间,但其分割的准确率是三种方法中最低的. 随机森林分类器有着中等的训练时间、最少的分割耗时和分割准确率最高. 综合比较这三类方法,随机森林分类器是最适用于多特征高维特征向量的有监督血管分类器.

对本文算法与其他文献算法的性能比较分别展示在表 5 和表 6 上. 在 DRIVE 和 STARE 数据库中均选取了有监督和无监督算法加以比较,选取敏感度、特异性和准确率作为性能比较的指标. 比较了近五年各类视网膜血管分割算法在 DRIVE 和 STARE 数据库的性能,对比得出本文算法在保证高准确率的同时,有着良好的敏感度. 这意味着分割结果能尽可能地保留血管信息,分割得到的血管连续完整.

表 5 DRIVE 数据库视网膜血管分割结果					
No.	Type	Method	Sen	Spe	Acc
1	Unsupervised methods	2nd human observer	0.7796	0.9717	0.9470
2		Nguyen et al. [6]	0.7527	—	0.9457
3		Yin et al. [7]	0.8644	—	0.9464
4		Gao [28]	0.7240	0.9742	0.9533
5		Wang et al. [29]	—	—	0.9461
6		Zhao et al. [30]	0.7354	0.9789	0.9477
7	Supervised methods	Zhao et al. [31]	0.7420	0.9820	0.9540
8		Liang et al. [27]	0.7535	0.9724	0.9536
9		Zhu et al. [32]	0.7447	0.9838	0.9606
10		Fraz et al. [33]	0.7406	0.9807	0.9480
11		Liskowski et al. [18]	0.8460	0.9673	0.9507
12		Dasgupta et al. [34]	0.7691	0.9801	0.9533
13		TP	0.8354	0.9591	0.9482


表 6 STARE 数据库视网膜血管分割结果

No.	Type	Method	Sen	Spe	Acc
1	Unsupervised methods	2nd human observer	0.8951	0.9384	0.9348
2		Nguyen et al. [6]	0.7686	—	0.9451
3		Yin et al. [7]	0.8254	—	0.9532
4		Gao [28]	0.7051	0.9710	0.9524
5		Wang et al. [29]	—	—	0.9512
6		You et al. [35]	0.7260	0.9756	0.9497
7		Zhao et al. [31]	0.7800	0.9780	0.9560
8	Supervised methods	Azzopardi et al. [36]	0.7716	0.9701	0.9497
9		Liang et al. [27]	0.7909	0.9630	0.9503
10		Wang et al. [37]	0.8173	0.9733	0.9767
11		Liskowski et al. [34]	0.9289	0.9710	0.9667
12		TP	0.8452	0.9619	0.9534


在 DRIVE 数据集上对比 12 类算法,本文的准确率为 0.9482,相比排名第一由 Zhu 等人^[32]所提出的随机森林方法的准确率 0.9606 低了 0.012,与其它算法的差距小于 0.01. 敏感度方面,本文算法有排名第二的敏感度 0.8354,仅次于 Liskowski 所使用的深度学习网络模型,在分割结果中表现为能提取细小血管,在血管分支重叠处连通性好、完整度高. 本文算法的总体性能优于贝叶斯后验概率模型、区域生长、血管跟踪与单一特征分类等算法. 本文算法的敏感度依然优于大部分深度学习算法.

对比 STARE 数据集中的 12 类算法,本文的准确率为 0.9534,在 12 类算法中排第 3. 准确率高于本文的算法分别是 Zhao 等人^[31]提出的混合区域信息活动轮廓模型和 Wang 等人^[37]提出的集成学习模型, Wang 等人采用神经卷积网络提取特征图,准确率已经高达 0.9767,相比于径向投影^[38]、可训练 B-COSFIRE 算法^[30]本文准确率明显提高. 本文算法的敏感度为所有比较算法中第二高的,敏感度为 0.8354,比其它算法平均高了 0.1. 本文算法对血管像素有着极好的敏感度,虽然其余 3 项指标没有达到最好,但与最优指标相差都不大. 本文算法以略微牺牲准确率为代价,极大地提升了算法敏感度,得到了能提取细小血管、分割结果完整度高、有临床应用价值的分割结果. 比较表明本文的视网膜血管提取算法具有较好的血管分割性能.

图 6 展示了本文方法、文献[28]和文献[27]的 F -measure 血管性能评价指标. 在 DRIVE 数据库上,文献[28]、文献[27]和本文的 RF 与 TP 的 F -measure 平均计算结果分别是 0.7114、0.7377、0.7162、0.7389;而对于 STARE 数据库,文献[28]、文献[27]和本文的 RF 与 TP 的 F -measure 平均计算结果分别是 0.7339、0.7251、0.6991、0.7341. 相对于文献[28]单一线性特征的视网膜血管提取算



(a) DRIVE 数据库中 F -measure



(b) STARE 数据库中 F -measure

图 6 F -measure 性能评价指标

法,本文算法的敏感度提升了 0.14,这表明多特征的血管分类算法对血管像素敏感,能最大程度地保留血管像素信息. 综合两个数据库的实验结果,本文的视网膜血管提取算法的 F -measure 平均指标均高于多尺度线性特征算法与水平集算法.

进一步比较不同算法在单幅图像中的性能,结合图 6 各算法的指标曲线可以看出,本文算法的 F -measure 曲线最为平稳. 在 DRIVE 数据库中计算 20 幅测试图像中线性特征算法、水平集算法和本文算法 F -measure 的方差分别为 0.0175、0.0242、0.004,本文算法方差最小;在 STARE 数据库中计算 20 幅测试图像 F -measure 的方差分别为 0.0093、0.0129、0.0008,由于 STARE 库中有较多病变图像,大部分算法在该数据库中表现差异很大,在两个数据库中,本文算法的 F -measure 方差均为最小. 该实验结果表明无论在健康眼底图像还是病变眼底图像中,本文方法均有良好性能,验证了算法的

鲁棒性。

从图 6 中可知,本文算法 F -measure 曲线(TP)均高于随机森林算法曲线(RF),表明血管图像后处理方法对随机森林血管分类器的分割结果有明显提高。通过比较不同算法的各类性能指标可知,本文算法整体性能优于现有算法。

5 总结与展望

在分析视网膜血管结构的基础上,本文首先引入线性特征、纹理特征、矩特征、方差特征和灰度特征描述视网膜血管和背景像素的差异性;其次在提取视网膜血管特征过程中结合多尺度、高斯滤波、形态学等数字图像处理手段,得到具有尺寸不变性和旋转不变性的血管特征,使之最大限度地度量血管像素与非血管像素的差异;然后在随机森林血管分类器训练时,训练集来源于对每幅视网膜图像的随机抽样;最后针对随机森林(RF)血管分割结果,进一步采用了血管后处理方法,利用视网膜血管灰度值分布统计信息和连通域面积、长宽比信息去除了 RF 提取结果中的非血管成分(过亮区域、伪影、病灶),以此获得最后的血管分割结果(TP)。通过在 DRIVE 和 STARE 数据库上的实验仿真和分析,本文的血管分割方法在 DRIVE 数据库上准确率为 94.82%;在 STARE 数据库上准确率分别为 95.34%, F -measure 指标良好且平稳,验证了算法的鲁棒性。本文的视网膜血管提取算法在同类算法中有着最高的敏感度,连通性较好,能最大限度地提取视网膜图像中的血管信息,具有较好的临床应用价值。

本文的主要创新点如下:(1)本文算法所提取的视网膜血管特征涵盖几何、形态学、灰度值和统计学,在特征提取前对每类特征都进行了预处理增强,从多个方面描述血管信息,提出了一种对血管像素敏感、提取结果连通性好的有监督算法;(2)本文算法在健康和病变的视网膜图形均有良好的分割性能,有强健的鲁棒性;(3)本文的血管分割算法和血管后处理算法可推广性良好,最新的视网膜血管特征提取可作为部分特征更新本文算法,血管后处理算法也可应用在其它血管分割算法中。

本文的算法依然可以进一步改进。针对分割结果过宽的问题,在特征提取中可以考虑加入灰度梯度相关特征强化对血管边缘的提取效果。本文算法在训练阶段代码效率不高,导致生成的分类树单棵分类能力不足,分类树棵树不足,可根据分类结果对

输入的特征设置相应的权值,加大分类结果理想的特征的输入权值,减小分类结果不理想的特征的输入权值。后处理方法虽然实用,但缺乏完整的理论依据,在特征提取时可结合病灶与伪影像素的特点,设计易于区分血管与病灶伪影的特征用于训练模型。

参 考 文 献

- [1] Kirbas C, Quek F. A review of vessel extraction techniques and algorithms. *ACM Computing Surveys*, 2004, 36(2): 81-121
- [2] Vermeer K A, van der Schoot J, et al. Automated segmentation by pixel classification of retinal layers in ophthalmic OCT images. *Biomedical Optics Express*, 2011, 2(6): 1743-1756
- [3] Winder R J, Morrow P J, McRitchie I N, et al. Algorithms for digital image processing in diabetic retinopathy. *Computerized Medical Imaging and Graphics*, 2009, 33(8): 608-622
- [4] Frangi A F, Niessen W J, Vincken K L, et al. Multiscale vessel enhancement filtering//*Proceedings of the International Conference on Medical Image Computing and Computer-Assisted Intervention*. Cambridge, USA, 1998: 130-137
- [5] Wang Xiao-Hong, Zhao Yu-Qian, Liao Miao, et al. Automatic segmentation for retinal vessel based on multi-scale 2D Gabor wavelet. *Acta Automatica Sinica*, 2015, 41(5): 970-980(in Chinese)
- [6] 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. *自动化学报*, 2015, 41(5): 970-980
- [7] Nguyen U T V, Bhuiyan A, Park L A F, et al. An effective retinal blood vessel segmentation method using multi-scale line detection. *Pattern Recognition*, 2013, 46(3): 703-715
- [7] Yin Y, Adel M, Bourennane S. Automatic segmentation and measurement of vasculature in retinal fundus images using probabilistic formulation. *Computational & Mathematical Methods in Medicine*, 2013, 2013(1): 260410
- [8] Lázár I, Hajdu A. Segmentation of retinal vessels by means of directional response vector similarity and region growing. *Computers in Biology and Medicine*, 2015, 66(C): 209-221
- [9] Orlando J, Prokofyeva E, Blaschko M B. A discriminatively trained fully connected conditional random field model for blood vessel segmentation in fundus images. *IEEE Transactions on Biomedical Engineering*, 2017, 64(1): 16-27
- [10] Mapayi T, Viriri S, Tapamo J R. Adaptive thresholding technique for retinal vessel segmentation based on GLCM-energy information. *Computational and Mathematical Methods in Medicine*, 2015, 2015: 597475
- [11] Marín D, Aquino A, Gegúndez-Arias M E, et al. A new supervised method for blood vessel segmentation in retinal images by using gray-level and moment invariants-based features. *IEEE Transactions on Medical Imaging*, 2011, 30(1): 146-158

- [12] Lupascu C A, Tegolo D, Trucco E. FABC: Retinal vessel segmentation using AdaBoost. *IEEE Transactions on Information Technology in Biomedicine*, 2010, 14(5): 1267-1274
- [13] Cheng E, Du L, Wu Y, et al. Discriminative vessel segmentation in retinal images by fusing context-aware hybrid features. *Machine Vision and Applications*, 2014, 25(7): 1779-1792
- [14] Epshtein B, Ofek E, Wexler Y. Detecting text in natural scenes with stroke width transform//*Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. Providence, USA, 2011: 2963-2970
- [15] Chen J, Shan S, He C, et al. WLD: A robust local image descriptor. *IEEE Transactions on Pattern Analysis & Machine Intelligence*, 2010, 32(9): 1705-1720
- [16] Zhu C, Zou B, Zhao R, et al. Retinal vessel segmentation in color fundus images using extreme learning machine. *Computerized Medical Imaging & Graphics*, 2017, 55: 68-77
- [17] Sekou T B, Hidane M, Olivier J, et al. Segmentation of retinal blood vessels using dictionary learning techniques//*Proceedings of the Fetal, Infant and Ophthalmic Medical Image Analysis*. Quebec, Canada, 2017: 83-91
- [18] Liskowski P, Krawiec K. Segmenting retinal blood vessels with deep neural networks. *IEEE Transactions on Medical Imaging*, 2016, 35(11): 2369-2380
- [19] Fu H, Xu Y, Wong D W K, et al. Retinal vessel segmentation via deep learning network and fully-connected conditional random fields//*Proceedings of the IEEE International Symposium on Biomedical Imaging*. Prague, Czech Republic, 2016: 698-701
- [20] Luo Y, Yang L, Wang L, et al. Efficient CNN-CRF network for retinal image segmentation//*Proceedings of the International Conference on Cognitive Systems and Signal Processing*. Beijing, China, 2016, 710: 157-165
- [21] Maninis K K, Ponttuset J, Arbeláez P, et al. Deep retinal image understanding//*Proceedings of the Medical Image Computing and Computer-Assisted Intervention*. Athens, Greece, 2016: 140-148
- [22] Liang Li-Ming, Huang Chao-Lin, Zhu Sha, et al. Retinal blood vessel segmentation based on Hessian matrix and level set. *Science Technology and Engineering*, 2016, 16(10): 44-49(in Chinese)
(梁礼明, 黄朝林, 朱莎等. 基于 Hessian 矩阵和水平集的视网膜血管分割. *科学技术与工程*, 2016, 16(10): 44-49)
- [23] Breiman L. Random forests. *Machine Learning*, 2001, 45(1): 5-32
- [24] Breiman L. Bagging predictors. *Machine Learning*, 1996, 24(2): 123-140
- [25] Morales S, Engan K, Naranjo V, et al. Retinal disease screening through local binary patterns. *IEEE Journal of Biomedical & Health Informatics*, 2017, 21(1): 184-192
- [26] Rokade P M, Manza R R. Automatic detection of hard exudates in retinal images using Haar wavelet transform. *International Journal of Application or Innovation in Engineering & Management*, 2015, 4(5): 402-410
- [27] Liang Li-Ming, Huang Chao-Lin, et al. Retinal vessel segmentation using level set combined with shape priori. *Chinese Journal of Computers*, 2018, 41(7): 1678-1692(in Chinese)
(梁礼明, 黄朝林, 石霏等. 融合形状先验的水平集眼底图像血管分割. *计算机学报*, 2018, 41(7): 1678-1692)
- [28] Gao Xiang-Jun. Retinal vessel segmentation based on multi-Scale line detection. *Science Technology and Engineering*, 2013, 13(23): 6820-6824(in Chinese)
(高向军. 基于多尺度线性检测的视网膜血管分割. *科学技术与工程*, 2013, 13(23): 6820-6824)
- [29] Wang Yang-Fan, et al. Retinal vessel segmentation using multiwavelet kernels and multiscale hierarchical decomposition. *Pattern Recognition*, 2013, 46(8): 2117-2133
- [30] Zhao Y Q, Wang X H, Wang X F, et al. Retinal vessels segmentation based on level set and region growing. *Pattern Recognition*, 2014, 47(7): 2437-2446
- [31] 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. *IEEE Transactions on Medical Imaging*, 2015, 34(9): 1797-1807
- [32] Zhu Cheng-Zhang, Cui Jin-Kai, Zou Bei-Ji, et al. Retinal vessel segmentation based on multiple feature fusion and random forest. *Journal of Computer-Aided Design & Computer Graphics*, 2017, 29(4): 585-592(in Chinese)
(朱承章, 崔锦恺, 邹北骥等. 基于多特征融合和随机森林的视网膜血管分割. *计算机辅助设计与图形学学报*, 2017, 29(4): 585-592)
- [33] Fraz M M, et al. An ensemble classification-based approach applied to retinal blood vessel segmentation. *IEEE Transactions on Bio-Medical Engineering*, 2012, 59(9): 2538-2548
- [34] Dasgupta A, Singh S. A fully convolutional neural network based structured prediction approach towards the retinal vessel segmentation//*Proceedings of the IEEE International Symposium on Biomedical Imaging*. Melbourne, Australia, 2017: 248-251
- [35] You X, Peng Q, Yuan Y, et al. Segmentation of retinal blood vessels using the radial projection and semi-supervised approach. *Pattern Recognition*, 2011, 44(10-11): 2314-2324
- [36] Azzopardi G, et al. Trainable COSFIRE filters for vessel delineation with application to retinal images. *Medical Image Analysis*, 2015, 19(1): 46-57
- [37] Wang Shuang-Ling, et al. Hierarchical retinal blood vessel segmentation based on feature and ensemble learning. *Neurocomputing*, 2015, 149(PB): 708-717
- [38] Guo Z, Lin P, Ji G, et al. Retinal vessel segmentation using a finite element based binary level set method. *Inverse Problems and Imaging*, 2014, 8(2): 459-473



LIANG Li-Ming, born in 1967, M. S. , professor. His research interests include medical image analysis and computer vision.

LIU Bo-Wen, born in 1994, M. S. candidate. His research interests include machine learning and medical image processing.

Background

Ophthalmological diseases can cause vision loss, Diabetes, glaucoma, multiple sclerosis, cardiovascular and other systemic diseases of the retina will lead to retinal lesion. By analyzing the quantity, angle, branch and curvature of the retinal blood vessel, it can help the diagnosis. Traditional manual segmentation is subjective and not repeatable. It will cost plenty of time to extract lesion and vessel from abnormal images. That is the challenge of retinal image analysis. Thus automated retinal vessel segmentation is much needed for real-time medical assistant diagnosis. Retinal vessel segmentation methods have greatly developed in decade. However, they all have following disadvantages: (1) Fractured micro vessel in the result. (2) Segmentation error of crossing vessels. (3) Excessively huge size of the vessel in the result. (4) Less robustness to the pathological retina.

In recent years, there are many method proposed for retinal blood vessel segmentation including unsupervised methods and supervised methods. Most of these methods acquired segmentation results from single feature, which will lead to too small vessel width or broken segmentation result.

This paper presents a supervised method for blood vessel extraction based on multiple feature fusion in digital retinal

YANG Hai-Long, born in 1990, M. S. , senior engineer. His research interests include overvoltage recognition and image processing.

SHI Fei, born in 1980, Ph. D. , lecturer. Her research interests include pattern recognition, medical image processing and analysis.

CHEN Xin-Jian, born in 1979, Ph. D. , professor. His research interests include pattern recognition, machine learning and medical image processing and analysis.

images. Taken different feature into consideration, our method can describe the retinal from shape, texture, micro vessel et al. The proposed method obtains not only good performance in accuracy but also in sensitivity. Besides automated blood vessel segmentation in fundus images, some other works in fundus have been completed, such as automated detection of retinal capillary hemangioma and Jiangsu Provincial Natural Science Foundation of China (Grant No. BK20140052) automated detection of hard exudates in retinal image. These works can be as the significant feature of ophthalmological diseases and assist ophthalmologists to analysis and diagnose.

This work was supported in part by the National Basic Research Program (973 Program) of China under Grant No. 2014CB748600, the National Natural Science Foundation of China under Grant Nos. 81371629, 61401293, 61401294, 81401451, 81401472 and 51365017, the Jiangsu Provincial Natural Science Foundation of China under Grant No. BK20140052, the Jiangxi Provincial Natural Science Foundation of China under Grant No. 20132BAB203020, and the Key Project of Science and Technology Research of Jiangxi Provincial Education Department under Grant No. GJJ170491.