

基于超像素仿射传播聚类的视网膜血管分割

许言兵, 周阳, 李灿标, 郑楚君*, 张润谷, 王文斌

华南师范大学物理与电信工程学院, 广东 广州 510006

摘要 提出一种基于超像素仿射传播聚类的视网膜血管分割方法。首先对预处理后的图像提取 Hessian 最大本征值、Gabor 小波、B-COSFIRE 滤波特征, 构建 3 维眼底图像像素特征; 同时对眼底图像进行超像素分块, 并采用一致性准则对所分的超像素块进行筛选, 得到超像素候选块, 把超像素候选块当作样本点, 把候选块内的像素特征的统计平均值当作特征向量, 在特征空间中进行仿射传播聚类得出血管类和背景类两个聚类中心; 根据血管类和背景类两个聚类中心, 采用最近邻方法对眼底像素进行分类, 实现对视网膜血管的分割。实验表明: 在 DRIVE 和 STARE 眼底图像数据库上, 本文算法的平均准确率分别为 94.63% 和 94.30%; 相较于 K-means、模糊 C 均值 (FCM) 和其他聚类方法, 本方法对血管的识别度高, 所分割的视网膜血管有较好的连续性和完整性。

关键词 图像处理; 视网膜血管分割; 超像素; 仿射传播聚类; 一致性; 候选块

中图分类号 TN911.73

文献标志码 A

doi: 10.3788/AOS202040.0210002

Retinal Vessel Segmentation Based on Super-Pixel Affinity Propagation Clustering

Xu Yanbing, Zhou Yang, Li Canbiao, Zheng Chujun*,

Zhang Rungu, Wang Wenbin

*School of Physics and Telecommunication Engineering, South China Normal University,
Guangzhou, Guangdong 510006, China*

Abstract A retinal vessel segmentation method based on the affinity propagation clustering of superpixels was proposed herein. First, the maximum Hessian eigenvalue, the Gabor wavelet, and the B-COSFIRE filtering features were extracted from the preprocessed image to construct the three-dimensional fundus image. The fundus image was segmented into superpixel blocks, which were screened based on a pixel consistency criterion to select the best candidates; these candidates were considered as sample points and their statistical average pixel values were used as the feature vectors. Two clustering centers of the vessel and background classes were obtained by performing affinity propagation clustering on the feature space. Based on these clustering centers, the fundus pixels were classified via the nearest neighbor method for retinal vessel segmentation. The experimental results show that the accuracies are 94.63% and 94.30% for the DRIVE and STARE fundus image databases, respectively. Compared with K-means clustering, FCM (Fuzzy C-means), and other clustering methods, the proposed technique presents a high recognition degree for blood vessels and better continuity and integrity of the segmented retinal vessels.

Key words image processing; retinal vessel segmentation; super-pixel; affinity propagation clustering; consistency; candidate blocks

OCIS codes 100.2000; 100.3008; 100.5010

1 引 言

视网膜眼底血管宽度、角度、分支状态等特征^[1]对糖尿病、动脉硬化、高血压和青光眼等相关疾病的诊断和治疗具有重要的研究价值。视网膜血管分割

可看作是将眼底图像像素划分为血管像素和非血管像素的二分类问题。根据是否需要眼底图像像素点的类别标签信息, 可把视网膜血管分割方法分为有监督方法和无监督方法。有监督方法利用专家已标记好的类别标签来训练特定分类器, 一般包括特征

收稿日期: 2019-08-01; 修回日期: 2019-09-10; 录用日期: 2019-09-19

基金项目: 国家自然科学基金(10504008)

* E-mail: cjzheng@scnu.edu.cn

提取和分类两环节。李媛媛等^[2]提取 Hessian 矩阵、Gabor 小波、B-COSFIRE 滤波和相位一致性的四维(4D)融合特征,并基于支持向量机分类器对眼底图进行分割。梁礼明等^[3]通过构建眼底血管的线性、纹理、矩和灰度等多特征融合,采用随机森林对眼底像素进行分类,实现视网膜血管分割。吴奎等^[4]提出线算子与 Gabor 小波的 6 维特征组合并结合贝叶斯高斯混合模型的眼底分割方法。郑婷月等^[5]设计了无需进行特征提取的多尺度特征融合的全卷积神经网络的方法来检测视网膜血管。相较于有监督方法,无监督方法不需要类别标签进行划分,因其计算复杂度较低,没有复杂的分类器调参过程,节省了眼科医生对眼底图像进行手工标记的昂贵的时间开销。无监督视网膜血管分割方法主要可分为基于血管跟踪^[6]、基于形态学处理^[7]、基于匹配滤波^[8]以及聚类^[9-10]等方法。Kande 等^[9]对眼底图采用匹配滤波结合基于空间加权模糊 C 均值(FCM)聚类的分割方法。Yavuz 等^[10]采用增强滤波和无监督方法实现视网膜血管分割,通过实验证明采用 Gabor 滤波和 K-means 聚类能取得较好的分割性能。基于特征空间 K-means 和 FCM 的聚类视网膜血管分割方法会对噪声和初始聚类中心选取较为敏感,容易陷入局部最优及离群点容易影响聚类中心等问题。

仿射传播^[11](AP)聚类算法将所有样本数据点作为候选的聚类中心,构建各点间的相似度矩阵,通过竞争类似于选举的方式产生聚类中心进行聚类。相较于 K-means、FCM 等聚类算法,AP 算法的复杂性高,具有较强的可靠性和稳健性,能够防止 K-means、FCM 中噪声干扰和最重要的初始种子点选取的问题。周阳^[12]将 AP 聚类引入到视网膜血管分割领域,针对 AP 算法在视网膜血管分割中,数据量大导致存在相似度矩阵的复杂度较高、计算量大等问题,提出基于匹配滤波引导的局部特征空间 AP 聚类的视网膜血管分割方法。该方法能根据眼底图像匹配滤波响应值进行排序,然后分段选取样本点构成小样本集,在小样本集中实现 AP 聚类得到血管和背景聚类中心,根据血管和背景聚类中心采用最近邻方法对眼底图像像素进行分类,从而实现视网膜血管分割。然而在视网膜血管分割中,采取上述分段选取小样本集的 AP 算法采用像素特征空间聚类,没有考虑像素在空间域邻近的关联信息,容易受噪声的影响。

本文提出一种基于超像素 AP 聚类的视网膜血

管分割的 ASLICAP(Adaptive Simple Linear Iterative Clustering Affinity Propagation)方法。超像素的引入降低了 AP 聚类相似度矩阵的复杂度,降低了 AP 聚类算法收敛的计算时间。超像素能充分利用局部像素间邻近灰度和空间的关联性。超像素的特征由超像素块内所包含像素的特征统计平均得到,具有较好的特征表征稳定性和可靠性。AP 聚类的视网膜血管分割方法具有较强的稳健性和抗噪性,能解决基于 K-means 和 FCM 分割方法对初始聚类中心选取敏感,离群点对聚类中心影响较大的问题。

2 基于超像素仿射传播聚类的视网膜血管分割

首先对彩色眼底图的绿色通道进行预处理操作得到血管增强图,对血管增强图进行特征提取,包括每个像素的 Hessian 最大本征值、Gabor 小波和 B-COSFIRE 滤波的三维像素特征,并进行特征归一化;同时对预处理的血管增强图进行超像素分割得到超像素块,依据超像素块内像素点特征值的一致性进行筛选,得到候选超像素块,并将其作为样本点,用候选超像素块所包含像素点的每维均值特征表示该超像素样本点的特征,在特征空间上进行 AP 聚类,产生血管类和背景类两个聚类中心;最后对图像所有像素点与两聚类中心在特征空间上采用基于曼哈顿距离的最近邻分类器进行分类,将眼底图像像素分为血管类和背景类,根据像素空间的邻域信息对少量与两个聚类中心距离近似相等的边界模糊点,采用 K 近邻进行再分类,通过后处理得到最终分割图。ASLICAP 具体流程如图 1 所示。

2.1 预处理

绿色通道眼底图具有对比度较高、噪声少、血管脉络清晰的特点^[1],本文选取绿色通道进行后续处理和视网膜血管分割。首先采用直径为 3 个像素的圆盘结构元素对绿色通道进行先腐蚀再膨胀的形态学开运算,去除血管中心反射现象,然后利用 CLAHE (Contrast Limited Adaptive Histogram Equalization)对图像进行增强处理。预处理结果如图 2 所示。

2.2 眼底图像像素特征提取

2.2.1 Hessian 最大本征值

本文采用标准差为 σ 的高斯核函数对预处理后的图像进行平滑滤波,滤波后的图像表示为 I ,图像 I 的 Hessian^[8]矩阵定义为

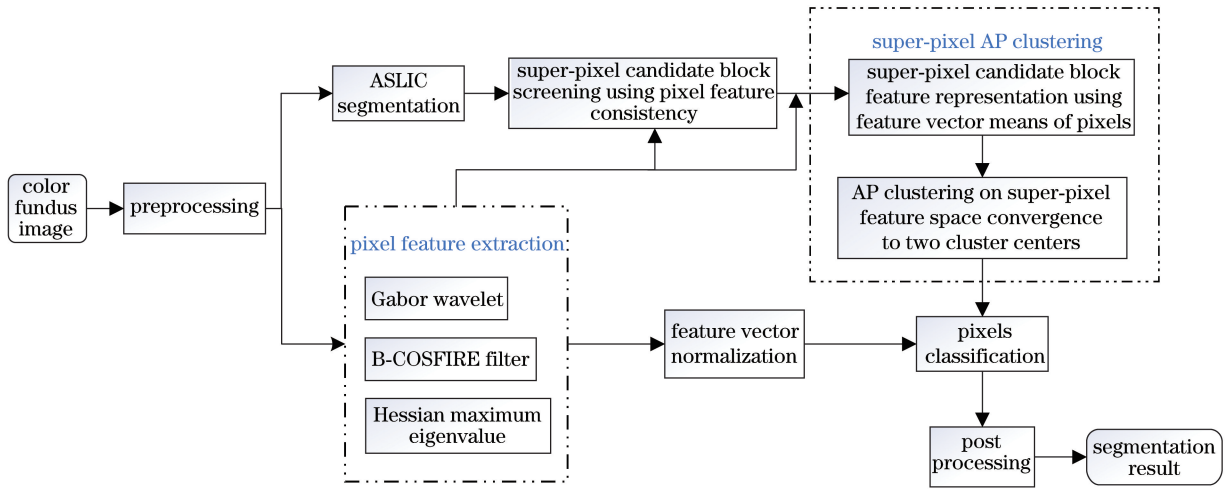


图 1 ASLICAP 方法流程框架图

Fig. 1 Framework diagram for ASLICAP method




图 2 图像预处理。(a)彩色眼底图;(b)绿色通道眼底图;(c) CLAHE 眼底增强图

Fig. 2 Image pre-processing. (a) Color fundus image; (b) green channel fundus image; (c) CLAHE fundus enhanced image

$$\mathbf{H} = \begin{bmatrix} \frac{\partial^2 I}{\partial x^2} & \frac{\partial^2 I}{\partial x \partial y} \\ \frac{\partial^2 I}{\partial y \partial x} & \frac{\partial^2 I}{\partial y^2} \end{bmatrix} = \begin{bmatrix} I_{xx} & I_{xy} \\ I_{yx} & I_{yy} \end{bmatrix}, \quad (1)$$

式中： \mathbf{H} 为 Hessian 矩阵，是一个二阶偏导数构建的实对称矩阵； I_{xx} 、 I_{xy} 、 I_{yx} 、 I_{yy} 为图像 I 关于像素位置坐标 (x, y) 的二阶偏导数。

Hessian 矩阵能较好地描述视网膜血管的线结构，依据 Hessian 矩阵的两个本征值的特性：在平滑背景处两个本征值较小，在血管处两个本征值一大一小，在分叉点和交叉点两个本征值都较大，可知 Hessian 矩阵在眼底图中无论是血管点还是血管分叉点，都至少存在一个较大的本征值 η 。本文实验设置 $\sigma = [1, 3, 5, 7, 9]$ ，将高斯滤波后图像 Hessian 矩阵本征值的最大值作为眼底图像像素的特征。

2.2.2 Gabor 小波变换

多尺度 Gabor 小波变换^[4]具有较好的方向性和尺度选择性，可以检测不同方向和不同尺寸的血

管。Gabor 小波定义为

$$\psi(x) = \exp(j\omega_0 x) \exp\left(-\frac{1}{2} |\mathbf{A}x|^2\right), \quad (2)$$

式中： $\mathbf{A} = \text{diag}[\epsilon^{-1/2}, 1]$ ， \mathbf{A} 为一个的 2×2 对角矩阵， $\epsilon \geq 1$ ，定义过滤器的各向异性； ω_0 为复指数频率，定义基本频率向量。通过 Gabor 小波与图像的标量积的快速傅里叶变换(用“ \cdot ”符表示)，实现二维 Gabor 小波变换，即

$$T_\psi(b, \theta, \mu) = c_\psi^{-\frac{1}{2}} \mu^{-1} \int \exp(j\tau x) \hat{\psi}(\mu r_\theta \omega) \hat{f}(\tau) d^2 \tau, \quad (3)$$

式中： c_ψ 为归一化常数； μ 、 b 、 θ 分别为膨胀尺度、平移量、旋转角度； $r_\theta = (x \cos \theta - y \sin \theta, x \sin \theta + y \cos \theta)$ ， $\theta \in [0, 2\pi]$ ； f 为原图像。

本文设置 $w = [0, 2.7]$ ， $\mu = [2, 3]$ ， $\epsilon = 4$ ，以 10° 为步长构造 18 个不同方向的 Gabor 滤波器，采用不同方向和尺度下的最大响应模值作为特征输出。

2.2.3 B-COSFIRE 滤波

COSFIRE 滤波器^[13]是一种棒状选择组合移位

式滤波器,能够实现对血管管状结构的自动选择和检测。其原理如图 3 所示,图 3(a)白色圆柱形的中点为滤波中心,灰色虚线椭圆区域为 B-COSFIRE 的中间支持域,浅灰色圆形区域为以特定点为圆心,

对亮度变化响应的一组高斯差分(DoG)滤波值。在视网膜血管检测中,可通过图 3(b)对称 B-COSFIRE 滤波器来检测连续血管,通过图 3(c)非对称 B-COSFIRE 来检测血管末端。

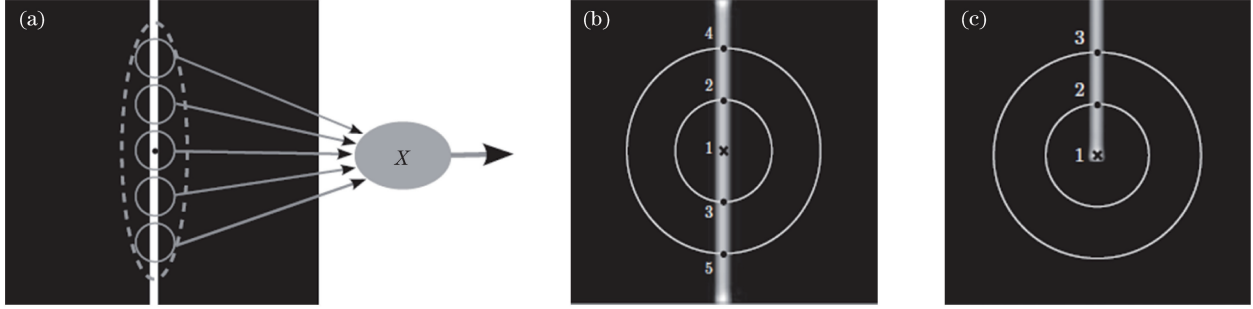


图 3 B-COSFIRE 滤波器配置。(a) B-COSFIRE 原理图;(b)对称 B-COSFIRE;(c)非对称 B-COSFIRE
Fig. 3 B-COSFIRE filter configuration. (a) B-COSFIRE schematic; (b) symmetric B-COSFIRE;
(c) asymmetric B-COSFIRE

B-COSFIRE 滤波响应由一组 DoG 滤波响应的乘积加权几何平均得到。其 DoG 滤波公式为

$$D_{\sigma}(x, y) = \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right) - \frac{1}{2\pi\sigma^2} \exp\left(-\frac{x^2 + y^2}{2\sigma^2}\right), \quad (4)$$

式中: σ 为高斯标准差。DoG 滤波器沿同心圆进行滤波响应,响应最大的位置表征强度变化最大的点,即关键点。用一组响应集合 V 记录关键点的信息,为提高各点位置的容错性,对 DoG 滤波响应进行模糊和移位操作,即对集合 V 中每个位置极坐标邻域进行最大加权阈值计算,再将该响应进行加权几何平均操作,得到 B-COSFIRE 滤波器响应公式。B-COSFIRE 滤波器响应公式为

$$r_V(x, y) = \left| \left\{ \prod_{i=1}^{|V|} [V_{\sigma_i, \rho_i, \varphi_i}(x, y)]^{\hat{\omega}_i} \right\}^{1/\sum_{i=1}^{|V|} \hat{\omega}_i} \right|, \quad (5)$$

$$\hat{\omega}_i = \exp[-\rho_i^2/(\hat{\sigma}^2)], \hat{\sigma} = 1/3 \max_{i \in \{1, \dots, |n|\}} \{\rho_i\}, \quad (6)$$

式中: $V_{\sigma_i, \rho_i, \varphi_i}(x, y)$ 为模糊移位后的 DoG 滤波响应; i 为图 3(b)和(c)的关键点; ρ_i 为该响应沿 φ_i 反方向的移动距离。

为了匹配眼底血管的多方向性,将滤波器旋转 12 个方向,将得到的最大响应值作为匹配血管输出的滤波结果。

对预处理的眼底图进行 Hessian 最大本征值、Gabor 小波和 B-COSFIRE 滤波的特征提取,其特征响应如图 4 所示。构造图像各像素点的三维特征向量 $U = (u_{\text{Hessian}}, u_{\text{Gabor}}, u_{\text{B-COSFIRE}})$,并将特征值进行归一化处理。

$$\hat{u}_{\gamma} = \frac{u_{\gamma} - \min(u_{\gamma})}{\max(u_{\gamma}) - \min(u_{\gamma})}, \quad (7)$$

式中: u_{γ} 为第 γ 个特征的特征值, $\gamma = 1, 2, 3$; $\hat{u}_{\gamma} \in$




图 4 各特征响应图。(a)Hessian 最大本征值;(b)Gabor 小波变换;(c)B-COSFIRE 滤波
Fig. 4 Response map for each feature. (a) Hessian maximum eigenvalue; (b) Gabor wavelet transform;
(c) B-COSFIRE filter

[0,1]为经过归一化后的特征响应值,以便于像素点在特征空间的后续操作。

2.3 候选超像素块的获取

2.3.1 超像素分割

ASLIC(adaptive simple linear iterative clustering)由 Achanta 等^[14]在 2012 年提出,将相似纹理、颜色、亮度的相邻像素构成像素块,通过动态更新距离度量 D 自动分割图像,减少输入参数,提高图像分割的紧凑性,且分割的块数 K 可以人为设定。

通过对预处理绿通道像素点 h 的空间位置 x_h, y_h 和像素灰度值 g_h 构建距离度量 D ,即

$$\begin{aligned} d_c &= \sqrt{(g_h - g_o)^2} \\ d_s &= \sqrt{(x_h - x_o)^2 + (y_h - y_o)^2} \end{aligned} \quad (8)$$

$$D = \sqrt{\left(\frac{d_c}{m_c}\right)^2 + \left(\frac{d_s}{m_s}\right)^2} \quad (9)$$

式中: d_c 为像素点 h 和 o 值域空间的欧氏距离; d_s 为像素点 h 和 o 像素空间的欧氏距离; m_c 和 m_s 为前一次 K-means 迭代中在 $2Q \times 2Q$ 块区域观察到 d_c 和 d_s 的最大值,用来标准化 K-means 聚类的近邻度, $Q = \sqrt{N/K}$, N 为总像素数。

通过指定产生 K 个超像素块,在 $2Q \times 2Q$ 块区域内进行 K-means 迭代聚类,直到满足最大迭代次数或目标函数时,达到最优,进而完成对眼底图的 ASLIC 分割,得到超像素块。

2.3.2 筛选候选块

眼底图经过 ASLIC 分割后存在既含有血管又含有背景的像素点部分超像素块,对这些混合块进行后续操作最终会影响其分割性能,因此需要对超像素块进行筛选。

由于对图像像素进行特征提取会增强像素点的信息,本文把像素特征的每一维特征按线性量化表示为[0,255],共 256 个量化级,统计第 n 个超像素块内每个量化级出现的概率,将超像素块内像素特征分布的一致性表示为

$$P_\gamma(n) = \sum_{l=1}^{L-1} v^2(l) \quad (10)$$

式中: l 为量化级; L 为量化级别总数; $v(l)$ 为每个量化级概率; $n \in [1, K]$; $\gamma \in [1, 3]$ 为特征维度。

计算每块所有灰度级每维特征的一致性,通过对每块三维特征设置权值系数 $\lambda_{\text{Hessian}}, \lambda_{\text{Gabor}}, \lambda_{\text{B-COSFIRE}}$,计算每块三维特征的加权一致性 G_n ,即

$$G_n = \lambda_{\text{Hessian}} \times P_{(\text{Hessian})n} + \lambda_{\text{Gabor}} \times P_{(\text{Gabor})n} + \lambda_{\text{B-COSFIRE}} \times P_{(\text{B-COSFIRE})n} \quad (11)$$

对每块特征加权一致性进行升序操作,设置阈值系数为 α ,找到第 $\alpha \times K$ 处位置块的加权归一性值,并将该值作为阈值 G_{thr} ,对各像素块进行阈值比较筛选候选块:若该像素块的加权一致性值大于或等于阈值 G_{thr} ,则该像素块记作候选块;反之将该像素块舍弃。在特征响应图中,Hessian 最大本征值可以较好地检测到视网膜血管的交叉点、分叉点和细小血管;Gabor 小波的多尺度、多方向描述能力有利于描述不同方向和尺度的视网膜血管;B-COSFIRE 滤波响应能较好地表征血管的连通性和完整性。因多数混合块存在细小血管、交叉、分叉处区域,筛选时需要细小血管、交叉点、分叉点较好识别的特征响应设置较大的权重,本文在 DRIVE 和 STARE 两数据库中的权值系数 $\lambda_{\text{Hessian}}, \lambda_{\text{Gabor}}, \lambda_{\text{B-COSFIRE}}$ 设置为 0.5、0.25、0.25 较为合理。

根据加权一致性原则,采用升序的方案剔除混合块,因考虑到带有重要信息的细小血管像素块的加权一致性值不高,需将阈值系数 α 设置为较小值。在 DRIVE 和 STARE 数据库,测试集中分别有 4 张和 10 张病变眼底图,在眼底图病变区域的混合像素块的特征响应较大,导致加权一致性值较高,会影响候选块的筛选,因此将 α 分别设置为 0.15 和 0.35 时,分割效果较好。

2.3.3 候选块的特征表征

将筛选后的候选块记作样本点,找到样本点内所有像素点的每维特征向量均值,得出候选超像素块的特征向量 $\bar{u}_z = \frac{1}{B} \sum_{b=1}^B (u_{(\text{Hessian})_b}, u_{(\text{Gabor})_b}, u_{(\text{B-COSFIRE})_b})$,以表征眼底图中第 z 个超像素样本点,其中 B 为样本点 z 内的总像素数, b 为样本点 z 的像素点。

2.4 AP 聚类的视网膜血管分割

AP 聚类根据 q 个数据点之间的相似度构建 $q \times q$ 的相似度矩阵 S ,并进行聚类。元素 $S(i, j)$ 代表用欧氏距离表示数据点 x_i 和 x_j 的相似程度。AP 算法传递两种信息,分别为吸引力 $r(i, k)$ 和归属感 $a(i, k)$ 。 $r(i, k)$ 为从数据点 i 传向聚类中心 k 的信息值,表示 k 点成为 i 点聚类中心的支持程度; $a(i, k)$ 为从聚类中心 k 传向数据点 i 的信息值,表示 i 点选取 k 点作为聚类中心的倾向程度。AP 算法旨在寻找最优的类别代表点,使得所有数据点与其距离最近类别中心点的相似度之和达到最大^[11]。

经过 ASLIC 分割和筛选得到 Z 个超像素样本点 $R(z)$,其中 $z, i, j \in [1, Z]$ 。将带有三维均值特征向量 \bar{u}_z 的样本点作为数据点,在特征空间上构建

相似度矩阵 $S = -\|R(i) - R(j)\|^2$ 进行 AP 聚类。然后进行交替迭代更新

$$r(i, k) = s(i, k) - \max_{k' \neq k} \{a(i, k') + s(i, k')\}, \quad (12)$$

$$a(i, k) = \begin{cases} \min\{0, r(k, k) + \sum_{i' \neq i, k' \neq k} \max[0, r(i', k)]\}, & i \neq k \\ \sum_{i' \neq i, k' \neq k} \max\{0, r(i', k)\}, & i = k \end{cases}, \quad (13)$$

式中: $s(i, k)$ 为像素点 i, k 间负的欧氏距离; i' 为前一次迭代时 i 像素点; k' 为前一次迭代时 k 像素点。

在迭代更新过程中, 为防止数值振荡, 引入阻尼因子 $\lambda \in [0, 1]$ 缓解聚类更新的速度, λ 值越大, 算法收敛越快。更新公式为

$$r_{\text{new}}(i, k) = \lambda \times r_{\text{old}}(i, k) + (1 - \lambda) \times r(i, k), \quad (14)$$

$$a_{\text{new}}(i, k) = \lambda \times a_{\text{old}}(i, k) + (1 - \lambda) \times a(i, k), \quad (15)$$

式中: old 和 new 分别为前一次和本次更新^[12]。将吸引度和归属度矩阵之和最大的点视为聚类中心, 产生 v 个高质量的聚类中心, 同时将其余数据点分配到相应的聚类中, 在一定的迭代次数内聚类结果不变或到达最大迭代次数时聚类终止。

$$v = \operatorname{argmax}[a(i, k) + r(i, k)]. \quad (16)$$

上述 AP 聚类得到样本点两个聚类中心的类别标签, 需要对两个聚类中心进行血管类和背景类判别。由特征响应图 4 可知, 在滤波特征响应中, 血管类

的响应值较大而背景类的响应值较小。通过找到两个聚类中心的特征向量并计算特征向量模值的平方, 将较大的值归为血管类, 较小的值归为背景类, 最终得到 AP 聚类产生的血管类和背景类的聚类中心。

2.5 像素点分类

初始近邻分类: 统计眼底图中感兴趣区域各像素点, 和 AP 聚类得到样本点的两个聚类中心在特征空间上的曼哈顿距离值, 依据距离值的大小进行近邻分类。由于存在某些像素点到两聚类中心的距离近似相等的问题, 通过设置阈值 ξ 进行判别, 得到分类的精确像素点和边界的模糊像素点。其思路如图 5(a) 所示, 依据距离分类原则: 在双曲线外侧的星状点为距离近似相等的边界模糊点, 内部的三角点和圆点为精确的像素点。依据边界模糊点较多存在于低对比度的血管与背景的交接处、曼哈顿距离差值较小以及数量较少等因素, 在两个数据库中阈值设置 $\xi = 0.01$ 。

K 近邻(KNN)再分类: 对于初分类出现的边界模糊点, 采用 KNN 思想统计该模糊点 3×3 像素空间邻域内精确的血管类和背景类像素点的个数信息, 利用此信息来判定该模糊点的类别: 若该邻域内精确的血管类像素点多于精确的背景类像素点, 则该模糊点被判定为血管点; 反之则将该模糊点被判定为背景点。其思路如图 5(b) 所示, 在 3×3 邻域内, 中心点为需要判别的模糊点, 邻域的三角形和圆形点分别为已知精确的血管和背景点。以上分类方法能提高眼底图分割的精度和性能。

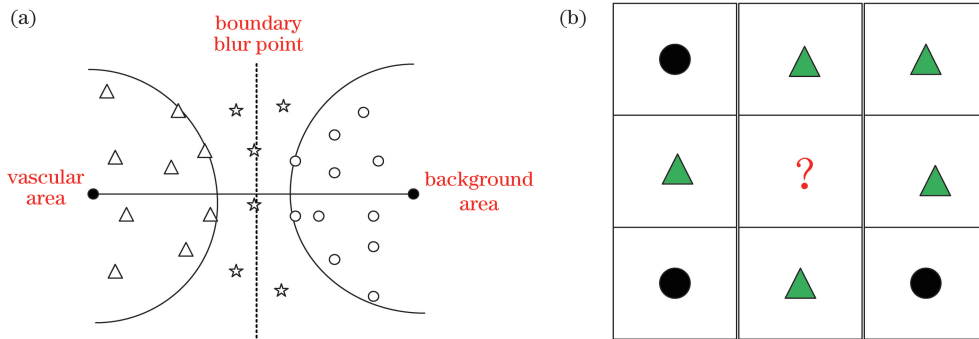


图 5 像素点分类思路图。(a) 初始近邻分类; (b) KNN 再分类

Fig. 5 Pixel point classification diagram. (a) Initial nearest neighbor classification; (b) KNN reclassification

2.6 形态学后处理

对眼底图进行分割后得到的二值图可能会出现噪声等问题, 为了提高分割准确度和图像可视性, 采用基于连通区域的面积阈值法去除血管中面积小于 6 pixel 的空隙以及面积小于 25 pixel, 被误分为血

管的孤立点块, 得到最终的视网膜血管分割图。

3 实验结果与分析

3.1 实验数据

本文采用国际上两个公开且大量使用的

DRIVE^[15] 和 STARE^[16] 眼底图像数据库。

DRIVE 数据库共有 40 张图片,其中 7 张为病变图,33 张为未病变图。训练集和测试集各 20 张。图像分辨率为 768 pixel×584 pixel。40 张图都有各自对应的掩模图、2 位专家手动标记的分割图。

STARE 数据库共有 20 张图片,其中 10 张为病变图,其余正常,图像分辨率为 605 pixel×700 pixel。20 张图没有各自的掩模图,但有 2 位专家手动标记的分割图。

3.2 评价指标

为了验证视网膜血管分割方法的性能,将血管分割结果和专家手动标记图进行比较。 N_{TP} (真阳性)表示正确分割的血管点, N_{TN} (真阴性)表示正确分割的背景点, N_{FP} (假阳性)表示分割错误的血管点, N_{FN} (假阴性)表示分割错误的背景点^[1]。 A_{cc} (准

确率)为分割正确的像素点占总像素点的比例; S_e (灵敏度)为分割正确的血管点占标准血管点总和的比例; S_p (特异性)为分割正确的背景点占标准背景点总和的比例。计算公式为

$$\begin{cases} A_{cc} = (N_{TP} + N_{TN}) / (N_{TP} + N_{FP} + N_{TN} + N_{FN}) \\ S_e = N_{TP} / (N_{TP} + N_{FN}) \\ S_p = N_{TN} / (N_{TN} + N_{FN}) \end{cases} \quad (17)$$

3.3 实验结果及分析

3.3.1 实验结果

用 ASLICAP 方法分别在 DRIVE 和 STARE 数据库的测试集中对眼底图进行实验,将两数据库第 1 位专家的分割金标准进行性能测试和分析。在 DRIVE 和 STARE 数据库中,本方法均将块数分别设置为 2500 和 4750。实验数据见表 1。

表 1 ASLICAP 分割性能指标

Table 1 ASLICAP segmentation performance indicators

Difference	DRIVE database (K=2500)			STARE database (K=4750)		
	A_{cc}	S_e	S_p	A_{cc}	S_e	S_p
Average	0.9463	0.7879	0.9725	0.9430	0.7930	0.9581
Worst	0.9358	0.7352	0.9722	0.9203	0.6577	0.9413
Best	0.9593	0.8929	0.9711	0.9506	0.9174	0.9551

由表 1 可知,在 DRIVE 和 STARE 数据库中,平均分割的 A_{cc} 为 94.63% 和 94.30%,平均 S_e 为 78.79% 和 79.30%,其分割结果较好。图 6 为 ASLICAP 方法在两数据库中的分割图,图 6 中第 1 列和第 3 列为 ASLICAP 方法在两数据库中性能最差的分割图,且两图均为病变图。在非病变区域具有较好的分割性能,在部分病变区域能够保持血管的大体主干,但存在将背景错误分割成血管以及在血管末端和分支处出现断裂的现象。图 6 中第 2 列和第 4 列为在两数据库中性能最好的分割图,特别是在 DRIVE 数据库中,其 A_{cc} 和 S_e 性能最优,

两张图中大部分血管均被较好地分割,在血管的交叉处和细小血管处具有较好的完整性和连通性,说明 ASLICAP 算法对于未病变眼底血管具有较好的分割效果。

3.2.2 对比分析

为验证 ASLICAP 方法分割的有效性,将本方法同机器学习中最常见的 K-means 和 FCM 算法进行对比分析,在预处理以及特征提取 (Hessian 最大本征值、Gabor 滤波、B-COSIFRE) 参数设置完全一致的情况下,对三种算法进行定量和定性分析。定量分析结果见表 2。

表 2 ALISCAP 方法与 K-means、FCM 算法性能指标对比

Table 2 Comparison of performance parameters of ALISCAP method, K-means, and FCM algorithm

Algorithm	DRIVE database			STARE database		
	A_{cc}	S_e	S_p	A_{cc}	S_e	S_p
K-means	0.9467	0.7515	0.9785	0.9331	0.8184	0.9447
FCM	0.9457	0.6973	0.9852	0.9424	0.7619	0.9609
ASLICAP	0.9463	0.7879	0.9725	0.9430	0.7930	0.9581

由表 2 可知,在 DRIVE 数据库中,ASLICAP 方法的 A_{cc} 比 FCM 提高了 0.0006,比 K-means 算法

降低了 0.0004;但在 S_e 方面与 K-means 和 FCM 相比,分别提高了 0.0364 和 0.0906。在 STARE 数据

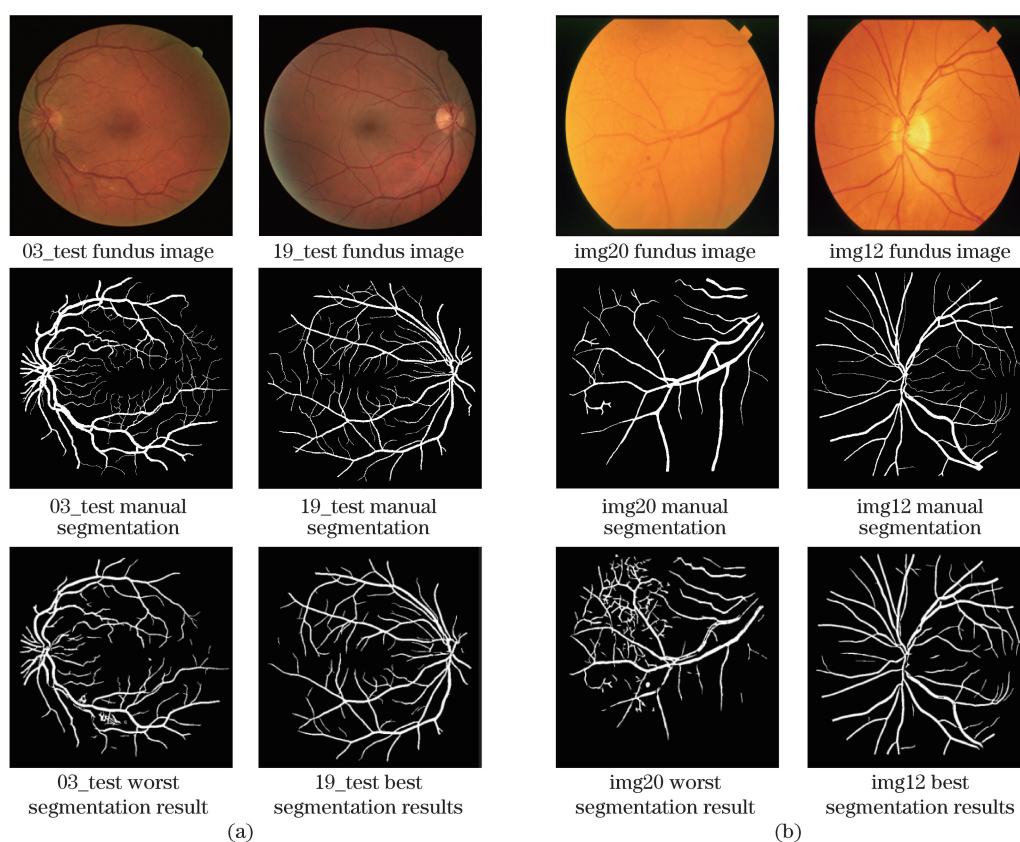


图 6 ASLICAP 方法在两数据库中的分割图。(a) DRIVE 数据库;(b) STARE 数据库

Fig. 6 Segmentation diagrams of ASLICAP method in two databases. (a) DRIVE database; (b) STARE database

库中,ASLICAP 与 K-means 和 FCM 相比, A_{cc} 分别提升了 0.0099 和 0.0006,在 S_e 方面略低于 K-means 0.0254,但高于 FCM 0.0311。由此可知,相较于传统的 FCM 和 K-means 聚类,ASLICAP 方法能够较为精确地分割正确的血管,但是在 SATRE 数据库中灵敏度 S_e 略低于 K-means,可能是由于 DRIVE 数据库相较于 STARE 数据库中含有较多病变图,而 ASLICAP 算法对病变区域的眼底血管分割性能一般。

图 7 为同等条件下三种聚类方法的分割图,将 ASLICAP、K-means、FCM 三种分割方法通过在两数据库中各抽选一张眼底图像进行定性对比分析。由第一行 DRIVE 数据库的 20_test 图和第二行 STARE 数据库的 img17 图可知,三种算法能够对主干血管进行较好地分割,但是 FCM 算法丢失了部分细小血管,K-means 算法虽然对细小血管有所保留,但是对于分割血管的连通性有所欠缺。ASLICAP 方法在整体的分割效果上要优于 FCM 和 K-means 算法。

第三行选取了第一行图像中的血管分叉和细小血管局部区域进行放大并进行细节对比。由图可知,FCM 算法将许多重要的细小血管和血管分叉处

错误地分割成了背景,影响了分割的准确性;K-means 算法在血管末端和分叉处存在断裂,从而影响了分割的灵敏度;ASLICAP 分割方法对眼底血管具有较好地识别性能,能够较大程度地保留细小血管,对血管断裂、分叉和交叉处血管的遗失等问题具有较大的改善。FCM 和 K-means 算法在视网膜血管分割中,因其自身存在聚类中心的随机选取,易导致出现局部最优和易受到离群点的干扰等问题,而 ASLICAP 血管分割方法则具有较强的抗干扰性和稳定性。

为了进一步证明本方法在眼底图分割中的有效性,在 DRIVE 和 STARE 数据库中均选用分割算法的准确率 A_{cc} 、灵敏度 S_e 、特异性 S_p 作为性能指标。将 ASLICAP 方法与其他非监督的视网膜血管分割方法进行定量对比分析,结果见表 3。

由表 3 可知,在 DRIVE 数据库上对比 8 类非监督方法,ASLICAP 方法分割所得 A_{cc} 为 0.946,比排名第 1 的文献[21]提出的多尺度线检测的算法仅仅低了 0.001;但 S_e 为 0.788,在所有算法中是最高的,说明本方法能够准确分割和识别出更多细小的血管。在 STARE 数据库中,由于有 10 张病变图,ASLICAP 算法的 A_{cc} 处于第 4 位置,比排名第 1

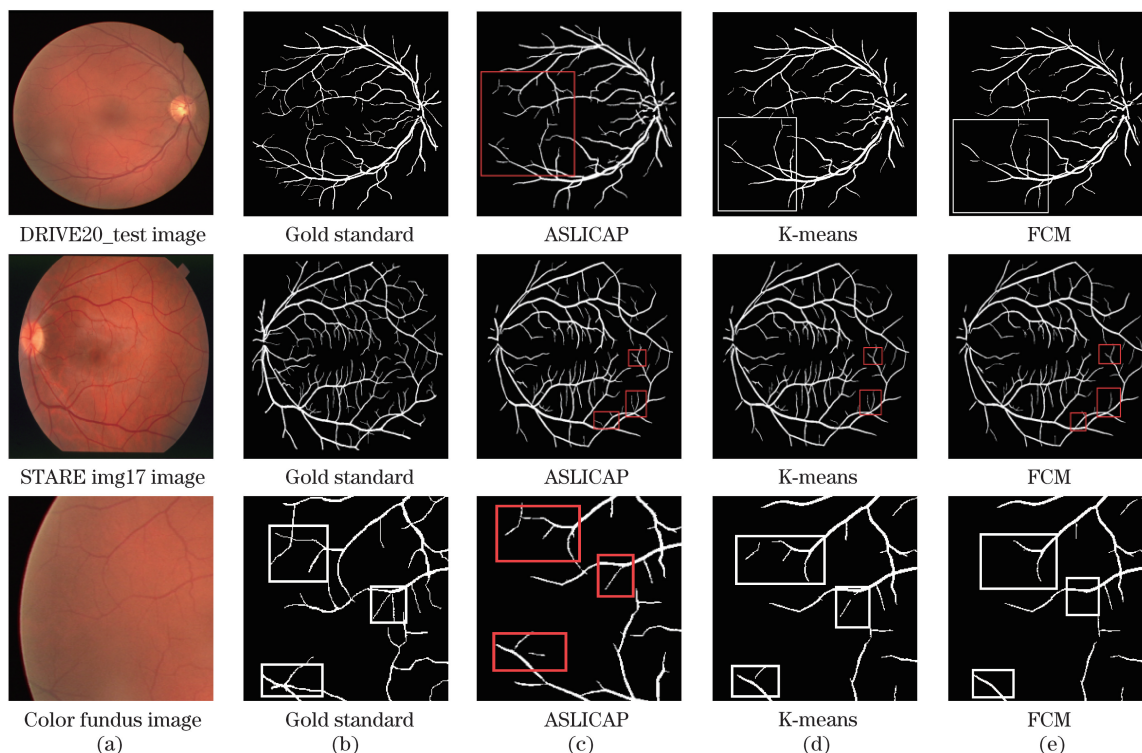


图 7 同等条件下三种聚类方法分割图。(a)原图;(b)金标准图;(c) ASLICAP; (d) K-means; (e) FCM
 Fig. 7 Segmentation diagrams of three clustering methods under the same conditions. (a) Original picture;
 (b) gold standard; (c) ASLICAP; (d) K-means; (e) FCM

表 3 不同算法分割结果比较

Table 3 Comparison of segmentation results of different algorithms

Num	Method	DRIVE database			STARE database		
		A_{cc}	S_e	S_p	A_{cc}	S_e	S_p
1	Ref. [7]	0.938	0.781	0.966	0.887	0.767	0.939
2	Ref. [13]	0.944	0.740	0.978	0.950	0.772	0.970
3	Ref.[17]	0.934	0.725	0.966	0.941	0.751	0.957
4	Ref. [18]	0.937	0.703	0.971	0.932	0.758	0.950
5	Ref. [19]	0.933	0.739	0.955	0.920	0.825	0.944
6	Ref. [20]	0.938	0.569	0.993	0.946	0.638	0.982
7	Ref. [21]	0.947	0.780	0.972	0.945	0.769	0.938
8	Ref. [22]	0.940	0.725	0.979	0.933	0.854	0.984
9	Proposed method	0.946	0.788	0.973	0.943	0.793	0.958

的文献[13]中可训练的 B-COSFIRE 算法低了 0.007;在 S_e 方面本算法处于第 3 位置,要低于相较于排名第 1 的文献[22]中 Gabor 结合线算子检测算法和第 2 的文献[19]中形态学顶帽变换和区域生长算法,但两者的 A_{cc} 分别为 0.933 和 0.920,可知两者算法是以牺牲 A_{cc} 为代价来提高 S_e 。

综上所述,相较于 FCM 和 K-means 等其他聚类算法,ASLICAP 方法对血管的识别度高,具有较

强的稳健性和稳定性,对未病变的眼底图具有较好的分割效果,在保证高准确率的同时,具有较高的灵敏度,能够准确地识别血管和有效地分割视网膜血管。

4 结 论

提出一种基于超像素 AP 聚类的视网膜血管分割方法,超像素的引入降低了 AP 聚类相似度矩阵

的复杂度,降低了 AP 聚类算法收敛的计算时间。在 DRIVE 和 STARE 眼底图像数据库中进行仿真实验,在同等条件下,与 K-means、FCM、其他聚类算法的定性的对比可知,本文分割方法具有较高的分割准确率,对细小血管、交叉及分叉和血管连通性具有大大的改善,也对未病变的血管具有很好的分割效果,能较好地解决基于 K-means 和 FCM 分割方法对初始聚类中心选取敏感,离群点对聚类中心影响较大的问题。本文方法在有病变眼底图的分割性能还有待提升,这将是进一步研究要解决的问题。

参 考 文 献

- [1] 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.
- [2] Li Y Y, Cai Y H, Gao X R. Retinal vessel segmentation algorithm based on hybrid phase feature[J]. *Journal of Computer Applications*, 2018, 38(7): 2083-2088.
李媛媛, 蔡轶珩, 高旭蓉. 基于融合相位特征的视网膜血管分割算法[J]. *计算机应用*, 2018, 38(7): 2083-2088.
- [3] Liang L M, Liu B W, Yang H L, et al. Supervised blood vessel extraction in retinal images based on multiple feature fusion[J]. *Chinese Journal of Computers*, 2018, 41(11): 2566-2580.
梁礼明, 刘博文, 杨海龙, 等. 基于多特征融合的有监督视网膜血管提取[J]. *计算机学报*, 2018, 41(11): 2566-2580.
- [4] Wu K, Cai D M, Jia P, et al. Retinal vessel segmentation based on 2D Gabor wavelet and combined line operators[J]. *Science Technology and Engineering*, 2016, 16(12): 106-112.
吴奎, 蔡冬梅, 贾鹏, 等. 基于 2D Gabor 小波与组合线检测算子的视网膜血管分割[J]. *科学技术与工程*, 2016, 16(12): 106-112.
- [5] Zheng T Y, Tang C, Lei Z K. Multi-scale retinal vessel segmentation based on fully convolutional neural network[J]. *Acta Optica Sinica*, 2019, 39(2): 0211002.
郑婷月, 唐晨, 雷振坤. 基于全卷积神经网络的多尺度视网膜血管分割[J]. *光学学报*, 2019, 39(2): 0211002.
- [6] Vlachos M, Dermatas E. Multi-scale retinal vessel segmentation using line tracking[J]. *Computerized Medical Imaging and Graphics*, 2010, 34(3): 213-227.
- [7] Meng L, Liu J, Cao H, et al. Retinal vessel segmentation based on Frangi filter and Otsu algorithm[J]. *Laser & Optoelectronics Progress*, 2019, 56(18): 181004.
孟琳, 刘静, 曹慧, 等. 基于 Frangi 滤波器和 Otsu 视网膜血管分割[J]. *激光与光电子学进展*, 2019, 56(18): 181004.
- [8] Chen L, Chen X Y. Retinal vessel segmentation based on feature combination and multimodel learning[J]. *Computer Engineering and Applications*, 2019, 55(17): 214-220.
陈莉, 陈晓云. 特征组合和多模块学习的视网膜血管分割[J]. *计算机工程与应用*, 2019, 55(17): 214-220.
- [9] Kande G B, Subbaiah P V, Savithri T S. Unsupervised fuzzy based vessel segmentation in pathological digital fundus images[J]. *Journal of Medical Systems*, 2010, 34(5): 849-858.
- [10] Yavuz Z, Köse C. Blood vessel extraction in color retinal fundus images with enhancement filtering and unsupervised classification[J]. *Journal of Healthcare Engineering*, 2017, 2017: 4897258.
- [11] Frey B J, Dueck D. Clustering by passing messages between data points[J]. *Science*, 2007, 315(5814): 972-976.
- [12] Zhou Y. Retinal vascular segmentation based on local feature space guided by matching filter of affinity propagation clustering[D]. Guangzhou: South China Normal University, 2019.
周阳. 基于匹配滤波引导局部特征空间仿射传播聚类的视网膜血管分割[D]. 广州: 华南师范大学, 2019.
- [13] 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.
- [14] Achanta R, Shaji A, Smith K, et al. SLIC superpixels compared to state-of-the-art superpixel methods[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2012, 34(11): 2274-2282.
- [15] 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.
- [16] 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.
- [17] Bankhead P, Scholfield C N, McGeown J G, et al. Fast retinal vessel detection and measurement using

- wavelets and edge location refinement[J]. PLoS One, 2012, 7(3): e32435.
- [18] Yin Y, Adel M, Bourennane S. Automatic segmentation and measurement of vasculature in retinal fundus images using probabilistic formulation[J]. Computational and Mathematical Methods in Medicine, 2013, 2013: 260410.
- [19] Fraz M M, Basit A, Barman S A. Application of morphological bit planes in retinal blood vessel extraction[J]. Journal of Digital Imaging, 2013, 26(2): 274-286.
- [20] 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.
- 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.
- [21] Nguyen U T V, Bhuiyan A, Park L A F, et al. An effective retinal blood vessel segmentation method using multi-scale line detection[J]. Pattern Recognition, 2013, 46(3): 703-715.
- [22] Yin B J, Li H T, Sheng B, et al. Vessel extraction from non-fluorescein fundus images using orientation-aware detector[J]. Medical Image Analysis, 2015, 26(1): 232-242.