

文章编号:1007-2780(2016)07-0686-09

一种血管约束的局部活动轮廓模型

梁 思^{1,2,3}, 王 雷¹, 杨晓冬^{1*}

- (1. 中国科学院 苏州生物医学工程技术研究所, 江苏 苏州 21215163;
2. 中国科学院 长春光学精密机械与物理研究所, 吉林 长春 130033;
3. 中国科学院大学, 北京 100049)

摘要:活动轮廓作为一种重要的图像分割工具,近几年来在理论和应用方面都有很大的发展。然而,现有轮廓模型在处理灰度均匀性较差的图像时,通常存在较高的分割误差,并且对初始轮廓曲线位置敏感。为此,本文提出一种基于血管特征约束的活动轮廓模型,该模型首先使用局部相位(Local Phase)的血管增强算法对图像进行增强处理以生成一种不同于图像灰度的血管特征信息,然后将血管信息和图像灰度以线性加权的形式引入到局部二值拟合(Local Binary Fitting, LBF)能量泛函中,指导图像血管分割。基于视网膜血管图像数据(Digital Retinal Images for Vessel Extraction, DRIV)的实验显示:该模型能成功地从灰度分布不均匀和弱边界轮廓的视网膜图像中提取血管,分割灵敏度和准确性分别达到 74.43% 和 93.67%,同时对初始轮廓曲线位置的敏感性大为降低。由上述可知,该模型具有高分割准确性和低初始位置敏感性。

关 键 词:活动轮廓;局部相位;灰度不均;局部二值拟合

中图分类号:TP391 **文献标识码:**A **doi:**10.3788/YJYXS20163107.0686

A novel vessel-constrained active contour with application to vessel segmentation

LIANG Si^{1,2,3}, WANG Lei¹, YANG Xiao-dong^{1,*}

- (1. *Suzhou Institute of Biomedical Engineering and Technology, Chinese Academy of Sciences, Suzhou 215163, China;*
2. *Changchun Institute of Optics, Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China;*
3. *University of Chinese Academy of Sciences, Beijing 100049, China)*

Abstract: Active Contour Models are the essential instruments for image segmentation and have great development in both theory and application. However, these existing models cannot work well in the presence of intensity heterogeneity, and are in general sensitive to initial curve places. Therefore, a novel active contour is proposed so as to extract correctly vessels, which takes into account image intensity and vessel features simultaneously. The new model is obtained by local phase vesselness-enhanced algorithm, and is based on local binary fitting. Experimental results, which based on publicly

收稿日期:2015-09-08; **修订日期:**2015-11-25.

基金项目:中科院科研装备项目(No. YZ201253, No. YZ201445)

Supported by Chinese Academy of Sciences Project of Research Equipment (No. YZ201253, No. YZ201445)

* 通信联系人, E-mail: xiaodong_yang@sibet.ac.cn

available Digital Retinal Images for Vessel Extraction (DRIVE), show that our model can successfully extract the desired vessels in the presence of intensity inhomogeneity with 74.43% pixel sensitivity and 93.67% segmentation accuracy, and the model is insensitive to initial curve placement. This demonstrates our model is competent for image segmentation with high accuracy and robustness.

Key words: active contour; local phase; intensity inhomogeneity; local binary fitting

1 引 言

图像分割是一种依据成像对象纹理特性的不同,把图像分割成若干区域,从而将所需的对象提取出来的过程;其能为临床诊断和手术治疗提供可靠的依据而得到广泛深入地研究。在众多图像分割算法中,活动轮廓模型(Active Contour Models, ACM)^[1-4]是较为典型的。该类算法通过最小化预先定义的能量泛函,达到从图像信息中动态地描绘出物体轮廓的目的,并具有“亚像素”的分割精度^[5-7]。常用活动轮廓模型依据图像分割中使用图像信息的不同可以粗略分为基于边缘(edge-based)^[8-11]和基于区域(region-based)的活动轮廓模型^[12-14]。

基于边缘的活动轮廓模型^[15-16]主要利用图像梯度信息构建能量泛函,提取所需目标物体的边界轮廓。这类模型较适用于边缘信息明确且灰度分布均匀的图像,并能够获得较高的准确性。但当图像灰度均匀性较差,或含有较高的图像噪声时,这类模型的分割性能由于梯度局部性的约束而明显降低^[17]。同时,梯度的局部性要求初始轮廓曲线不能距离所需分割对象的边缘太远,否则就无法得到准确的目标曲线。这些不足限制了基于边缘的活动轮廓模型的应用范围,并推动了基于区域的活动轮廓模型的发展^[18-19]。

基于区域的活动轮廓模型使用图像灰度间存在的统计分布关系构建能量泛函,获取所需的目标曲线。灰度统计关系的建立基于如下假设:根据成像对象的不同可将图像分为多个不同的区域块^[20-21],且描述不同对象的灰度值在各个区域上是均匀分布的。这使得一幅图像仅根据灰度的统计学数值便可粗略地分为不同的区域,从而避免由图像梯度信息的使用导致的对初始轮廓曲线位置敏感、抗噪能力弱等问题。然而,这类模型通常无法准确分割灰度分布均匀性较差的图像。

最近, Li^[22-23]等提出了一种局部二值拟合(Local Binary Fitting, LBF)的活动轮廓模型,以解决灰度分布不均匀性对图像分割造成的干扰。该模型首先分析 Chan and Vase 提出的全局区域活动轮廓模型(简称 CV 模型)仅依据全局图像信息分割图像特征存在的问题;然后引入高斯核函数对图像全局范围内的目标和背景信息的灰度统计信息进行改进,从而在全局信息中引入局部灰度信息以解决一定范围内灰度分布不均匀的问题。实验表明该模型具有较高的分割准确性,并且该模型涉及较少的分割参数,能大幅降低算法的使用难度。但是该模型对初始轮廓曲线的位置敏感,抗噪能力有待提升^[24],从而在一定程度上限制了它的广泛应用。

为此,本文提出一种新的基于血管特征约束的活动轮廓模型(vessel-constrained LBF, VLBF),该模型首先使用局部相位(Local Phase)的增强算法增强图像中的血管特征信息,然后将血管特征作为一种不同于图像灰度的特征信息引入到 LBF 模型中,以改善 LBF 模型的图像分割性能。基于公开发表的视网膜图像(Digital Retinal Images for Vessel Extraction, DRIVE)的分割实验表明该算法具有良好的分割性能。

2 方 法

VLBF 模型在保留 LBF 模型的图像分割优点的基础上,引入血管特征信息改善其存在的问题。为更好地介绍 VLBF 模型,下面详细介绍 LBF 模型,以清晰阐述该算法具有的分割特性和存在的不足,随后引出本文所提算法。

2.1 LBF 模型

LBF 模型是一种利用图像局部信息的活动轮廓模型,这使得其相较于基于图像全局信息的活动轮廓模型添加了局部细节,能够获得更高的分割准确性和抗噪能力。LBF 模型具体表示如下:

$$E^{\text{LBF}} = \lambda_1 \int \left[\int_{\text{inside}(C)} K_\sigma(x-y) |I(y) - f_1(x)|^2 H_1(\phi(x)) dy \right] dx + \lambda_2 \int \left[\int_{\text{outside}(C)} K_\sigma(x-y) |I(y) - f_2(x)|^2 H_2(\phi(x)) dy \right] dx + R(\phi(x)) \quad (1)$$

$$R(\phi(x)) = \vartheta \int |\nabla H(\phi(x))| dx + \mu \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx \quad (2)$$

其中: C 为所需的轮廓曲线, 其能将图像划分为 $\text{inside}(C)$ 和外部区域 $\text{outside}(C)$ 两部分, 曲线 C 实际求解中常用零阶 Lipschitz 函数 $\phi(x): \Omega \subset R$ 集替代。 $I: \Omega \subset R$ 为给定灰度图像, x 是图像区域 Ω 中的任意一个像素点。 $\lambda_1, \lambda_2 > 0$ 分别是图像灰度在内、外两部分的能量泛函的权重系数, y 表示点 x 为中心的邻域范围。 $K_\sigma(\cdot)$ 是带有标准差 $\sigma > 0$ 的高斯核函数, 通常可表示为 $K_\sigma(u) = \frac{1}{(2\pi)^{n/2} \sigma^n} e^{-|u|^2/2\sigma^2}$, 当 $|u|$ 增加时, $K_\sigma(u)$ 减小并逐渐趋向于零, 同时满足局部非负单调的性质。 $f_1(x)$ 和 $f_2(x)$ 是轮廓曲线内、外局部图像区域上像素灰度的平均拟合值, 通常由极小化能量泛函公式 E^{LBF} 得到。 $\nabla H(\cdot)$ 是 Heaviside 函数 $H(\cdot)$ 的梯度, 其中 $H(\phi) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{\phi}{\epsilon}\right) \right]$ 。 令 $H_1(\phi) = H(\phi)$, $H_2(\phi) = 1 - H(\phi)$ 分别代表 ϕ 的内部和外部。 $R(\cdot)$ 是一个正则项, 包括长度项 $\int |\nabla H(\phi(x))| dx$ 和距离保证项 $\int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx$, ϑ 和 μ 分别为二者的权重系数。

LBF 模型通过引入高斯核函数 $K_\sigma(\cdot)$ 实现了图像全局信息与局部信息间的转换, 从而避免了远离所需目标的图像信息的干扰, 提升目标物体附近的局部图像信息在曲线求解中的有效性; 使得 $f_1(x)$ 和 $f_2(x)$ 的求解仅仅需要 x 附近的图像信息即可确定。 图像局部信息的使用不仅在区分所需目标和图像背景中起着关键性作用, 而且能够有效提升模型的分割准确性和抗干扰能力。 然而, LBF 模型对初始轮廓曲线位置的敏感性不足, 处理灰度不均匀图像的能力也有待提升。 存在这些不足的原因可能是 LBF 模型在分割求解过程中忽略了像素灰度外的其他重要图像信息。 为了改善 LBF 模型的这些问题, 有必要引入更多的图像信息到 LBF 模型中, 提升其分割性能。

2.2 VLBF 模型

为了改善 LBF 模型的分割性能, 一种不同于图像灰度的血管特征信息被引入到该模型中, 从而形成一种新的基于血管特征约束的 VLBF 模型。 该模型首先使用局部相位 (Local Phase) 的血管增强算法对图像进行增强处理以生成一种不同于图像灰度的血管特征信息, 然后将血管信息和图像灰度以线性加权的形式引入到局部二值拟合能量泛函中, 指导图像血管分割。 下面分别对局部相位的血管增强算法和 VLBF 能量泛函进行详细介绍。

2.2.1 局部相位的血管增强

局部相位是从基于单元信号的正交滤波器中衍生而来的重要特征, 可以被看作一个空间域的复杂滤波器, 其中实部和虚部分别对应线滤波器、边缘滤波器。 实部与虚部之间的角度 θ 可以作为一个重要的指标, 用来表征图像中线和边缘的局部特征, 这个指标已被广泛应用于边缘检测、对称性分析和血管特征增强^[25]的过程中。

局部相位的求解过程中, 正交滤波器通常使用相位差为 $\pi/2$ 的一个偶数滤波器和一个奇数滤波器, 在尺度 m 和方向 j 上分别表示为 E_m^j 和 O_m^j 。 对于图像 I 的每一个像素点, 根据以下公式可以得到滤波器的响应, 记为 q_m^j :

$$q_m^j = e_m^j(x) + o_m^j(x) \cdot i \quad (3)$$

$$e_m^j(x) = I(x) * E_m^j \quad (4)$$

$$o_m^j(x) = I(x) * O_m^j \quad (5)$$

其中: $*$ 表示卷积运算, $i = \sqrt{-1}$ 表示虚数单元。 为了获得一个方向不变的相位图, 需要用绝对值替代虚部的 O_m^j , 使 $\overline{q_m^j} = e_m^j + |o_m^j| \cdot i$, 将尺度 m 上的 J 个方向的响应进行累加, 得到 $q_m = \sum_{j=1}^J \overline{q_m^j}$ 。 结合各个尺度上的响应, 可以得到一个方向不变的全局响应 P , 其公式如下:

$$P = \frac{\sum_{m=1}^M q_m |q_m|^\beta}{\sum_{m=1}^M |q_m|^\beta}, \quad (6)$$

其中: M 是尺度的个数, 权重系数满足 $\beta \geq 1$ 。为了使相位图更规则, 需要增加一个小的正数 β 对响应 P 做归一化处理以得到最终的血管特征图像, 具体公式如下:

$$LP = \frac{P \cdot |P|}{P^2 + \beta^2}. \quad (7)$$

将上述计算局部相位的血管增强算法应用于视网膜图像, 可以得到如图 1 所示的结果。在图 1 中, 图 A 表示待增强处理的原视网膜图像, 图 B 是图 A 绿色分量对应的灰度图像(相比红色分量、蓝色分量而言, 图像的绿色分量中轮廓信息更明显, 下文同样适用原始图像的绿色分量的灰度图像), 图 C 和 D 分别为图 B 经局部血管增强处理后局部相位对应的实部和虚部图。从图 C 中可以清晰地看出, 图像中血管所在的区域得到明显地增强, 血管与背景间的差异也得到进一步地突显; 并且图中每个像素点对应的滤波响应值越大, 其可能为血管的概率就越大。为此, 本文将

局部相位增强后实部对应的图像称为血管图像。至于图 D, 其更侧重于凸显血管边缘所在的区域, 这对血管的提取有非常重要的指导作用。




图 1 局部血管图像增强结果

Fig. 1 Results of the local phase-based vesselness enhancement

2.2.2 整合局部相位的能量泛函

为了充分利用局部相位增强后的血管特征信息, 本文将血管特征与像素灰度作为图像中两个相互独立的随机变量, 并以线性加权的形式将二者对应的图像信息整合用于分割图像目标的能量泛函。该能量泛函可表示如下:

$$E^{\text{VLBF}} = \alpha E_I + (1 - \alpha) E_V + R(\phi(x)) \quad , \quad (8)$$

$$E_I = \lambda_1 \int \left[\int_{\text{inside}(C)} K_\sigma(x-y) |I(y) - f_1(x)|^2 H_1(\phi(x)) dy \right] dx + \lambda_2 \int \left[\int_{\text{outside}(C)} K_\sigma(x-y) |I(y) - f_2(x)|^2 H_2(\phi(x)) dy \right] dx \quad , \quad (9)$$

$$E_V = \lambda_3 \int \left[\int_{\text{inside}(C)} K_\sigma(x-y) |V(y) - f_3(x)|^2 H_1(\phi(x)) dy \right] dx + \lambda_4 \int \left[\int_{\text{outside}(C)} K_\sigma(x-y) |V(y) - f_4(x)|^2 H_2(\phi(x)) dy \right] dx \quad , \quad (10)$$

$$R(\phi(x)) = \oint |\nabla H(\phi(x))| dx + \mu \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx$$

其中, $V(y)$ 为血管图像中位于像素点 y 处的图像血管响应, λ_3 、 λ_4 分别为 $V(y)$ 在内、外两部分的能量泛函的权重系数。 E_I 和 E_V 分别对应灰度和血管信息的能量泛函。 α 是一个位于 $0 \sim 1$ 之间的权重系数, 用来表示 E_I 和 E_V 所占用的比重。其他参数代表的含义可参考前文。

最小化上述能量泛函的过程通常以变分水平集的方式进行求解, 同时结合欧拉-拉格朗日方程可得到能量泛函中的各个参数满足如下公式:

$$\int K_\sigma(x-y) |I(y) - f_i(x)|^2 \times$$

$$H_i(\phi(x)) dy = 0, i = 1, 2 \quad , \quad (11)$$

$$\int K_\sigma(x-y) |I(y) - f_j(x)|^2 \times$$

$$H_{j-2}(\phi(x)) dy = 0, j = 3, 4 \quad . \quad (12)$$

经求解公式可得到 $f_n, n = 1, 2, 3, 4$ 的计算公式:

$$f_1(x) = \frac{K_\sigma(x) * [H_1(\phi(x))I(x)]}{K_\sigma(x) * H_1(\phi(x))} \quad , \quad (13)$$

$$f_2(x) = \frac{K_\sigma(x) * [H_2(\phi(x))I(x)]}{K_\sigma(x) * H_2(\phi(x))} \quad , \quad (14)$$

$$f_3(x) = \frac{K_\sigma(x) * [H_1(\phi(x))V(x)]}{K_\sigma(x) * H_1(\phi(x))} \quad , \quad (15)$$

$$f_4(x) = \frac{K_\sigma(x) * [H_2(\phi(x))V(x)]}{K_\sigma(x) * H_2(\phi(x))}. \quad (16)$$

使用梯度下降法对上述能量泛函 E^{VLBF} 极小化后,最终得到所需轮廓曲线随时间演化的偏微分方程:

$$\begin{aligned} \frac{\partial \phi}{\partial t} = & -\alpha \delta_\epsilon(\phi) (\lambda_1 e_1 - \lambda_2 e_2) - \\ & (1 - \alpha) \delta_\epsilon(\phi) (\lambda_3 e_3 - \lambda_4 e_4) + \\ & \delta_\epsilon(\phi) \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) + \mu \left(\nabla^2 \phi - \operatorname{div} \left(\frac{\nabla \phi}{|\nabla \phi|} \right) \right), \end{aligned} \quad (17)$$

其中:

$$e_i = \int K_\sigma(x-y) |I(y) - f_i(x)|^2 dy, \quad (i=1,2), \quad (18)$$

$$e_j = \int K_\sigma(x-y) |V(y) - f_j(x)|^2 dy, \quad (j=3,4), \quad (19)$$

$\delta_\epsilon(x)$ 是 Dirac 函数,

$$\delta_\epsilon(x) = H'(x) = \frac{\epsilon}{\pi(\epsilon^2 + x^2)}. \quad (20)$$

从所求曲线的演化方程中可以发现,VLBF 模型同时使用灰度图像和血管图像位于轮廓曲线 ϕ 附近的局部信息进行图像分割,因而能够更好地从背景信息中辨别和分割所需的对象。

3 实验结果与分析

3.1 实验数据

实验环境为: Matlab 2010b, 处理器: Intel (R) Core™ i3-2120 CPU, 主频: 3.30 GHz。实验数据: 从公开发表的视网膜血管图像数据中随机抽取的四张图像, 截取其中包含细小血管的局部区域。将截取后的局部区域图像进行分割处理, 并将分割结果与数据集中的手动分割结果进行对比, 客观地评估了 VLBF 模型的分割性能。

3.2 实验参数设置

局部相位血管增强算法中, 参数设置借鉴已发表的与视网膜图像性质有关的文章^[26]中的参数, 根据实际图像特点, 滤波器的尺度 scale 设置为 2。VLBF 模型的参数设置如下: 图像大小 $(283 \times 182 \sim 320 \times 150)$ 像素, $\sigma = 2.0 \sim 3.0$, $\lambda_1^I = \lambda_3^V = 1.05$, $\lambda_2^I = \lambda_4^V = 0.95$, $\vartheta = (0.0001 \sim 0.000125) \times 255 \times 255$, $\mu = 1$, $\Delta t = 0.1$ 。实验中, 随机选取的含有细小血管区域的图像大小

为 $(83 \times 182 \sim 320 \times 150)$ 像素。由于不同图像存在差异, 需要 σ 和 ϑ 的值以达到最佳的分割效果。

3.3 结果

根据上述实验参数, VLBF 模型对 4 张局部视网膜图像进行了分割, 结果如图 2 所示。其中, 第一列红色轮廓曲线部分是分割出的结果, 第二列是将第一列中的红色轮廓曲线映射到相应的数据集手动分割图像后的结果。图 2(A) 的实验参数 $\sigma = 3.0, \vartheta = 0.0001 \times 255 \times 255$ 。图 2B 的实验参数 $\sigma = 2.0, \vartheta = 0.000125 \times 255 \times 255$, 图 2C 的实验参数 $\sigma = 2.0, \vartheta = 0.000125 \times 255 \times 255$, 图 2D 的实验参数 $\sigma = 2.0, \vartheta = 0.000125 \times 255 \times 255$ 。




图 2 随机选取的 4 幅图像经 VLBF 模型后的分割结果

Fig. 2 Segmentation performances of the VLBF model in contrast to the manual segmentations based on four randomly chosen retinal images.

从图 2(A)、(C)、(E)、(G) 可以看出, 大多数的小血管已被准确地分割出来, 这些轮廓曲线可以成功的覆盖在其对应的模板上 (如图 2(B)、(D)、(F)、(H)), 但由于图像中某些血管轮廓不明显, 且不容易由视觉识别出来, 这些区域并未能被完全分割, 在第二列图像可以明显看出这些未被分割出来的细小血管和一些分离的细小区域, 这可能是由图像噪声和局部灰度差异引起的, 因它们仅占图像的小部分, 并未影响整体的分割性

能。由上述分析可知,VLBF 模型可以得到较准确的分割结果。

为了进行定量的评估,对分割结果在灵敏度(Se)^[27]和准确性(Acc)^[27]方面进行了分析,具体定义如下:

$$Se = \frac{tp}{tp + fn} \quad , \quad (21)$$

$$Acc = \frac{tp + tn}{tp + fp + tn + fn} \quad , \quad (22)$$

其中: tp 、 tn 、 fp 、 fn 分别表示正确识别的目标像素点个数、正确识别的背景像素点个数、错误识别的目标像素点个数和错误识别的背景像素点个数。Se 反映了分割算法的有效性,Acc 反应了模型的分割性能。另外,CV 模型、LBF 模型、LG-DF 模型也被用于分割实验中,以对比研究它们与本文算法间的性能差异。其中,CV 模型和 LGDF 模型分别表示如下:

$$E^{CV} = \lambda_1 \int_{\text{inside}(C)} |I(x) - c_1|^2 H(\phi(x)) dx + \lambda_2 \int_{\text{outside}(C)} |I(x) - c_2|^2 (1 - H(\phi(x))) dx + \vartheta \int |\nabla H(\phi(x))| dx \quad , \quad (23)$$

$$E^{LGDF} = - \iint \omega(x - y) \log_{P_{1,x}}(I(y)) H_1(\phi(x)) dy dx - \iint \omega(x - y) \log_{P_{2,x}}(I(y)) H_2(\phi(x)) dy dx + R(\phi(x)) \quad , \quad (24)$$
$$R(\phi(x)) = \vartheta \int |\nabla H(\phi(x))| dx + \mu \int \frac{1}{2} (|\nabla \phi(x)| - 1)^2 dx \quad .$$

CV 模型和 LGDF 模型中的参数可参照文献[13]、[26]中的介绍,在此不进行赘述。四种模型的分割结果如图 3 所示,并对各模型在 Se 和 Acc 方面做了定量分析,结果如表 1 所示。




图 3 CV、LBF、LGDF 和 VLBF 四种模型的图像分割结果

Fig. 3 Segmentation results by different models with red color. (A) ~ (D) correspond to the CV, LBF, LGDF and VLBF models, respectively.

四种模型的同一张视网膜图像的分割结果如图 3 所示,(A)、(B)、(C)、(D) 分别表示 CV、LBF、LGDF 和 VLBF 的分割结果。CV 模型的

分割结果,由于受灰度不均匀的影响^[28],并未能清晰的分割出主要的轮廓,且干扰区域较多、分割结果粗糙。图 3(B)、(C)中的分割结果有较大改善,能够清晰的分割出血管的主要轮廓,但是因灰度不均匀和图像噪声等问题的存在,并未分割出血管的细小分支。VLBF 模型提取出了更多的血管区域,由图(D)中绿色矩形指定的区域可以看出,该算法在分割细小血管方面有更优良的性能。

表 1 不同模型的灵敏度(Se)和准确率(Acc)

Tab. 1 Means and standard deviations of sensitivity (Se) and accuracy (Acc) by different models

Model	Se	Acc
CV	0.723 0±0.005 5	0.618 9±0.004 7
LBF	0.708 8±0.011 0	0.930 9±0.000 1
LGDF	0.741 8±0.007 0	0.935 8±0.000 4
VLBF	0.779 3±0.001 9	0.943 3±0.000 1

四种模型的定量分析如表 1 所示,CV 模型的准确率最低,LBF、LGDF 和 VLBF 三种模型的准确率比较接近,4 种模型的灵敏度方面差异不大,其中 VLBF 的准确率和灵敏度都是最高的。

由图 3 和表 1 的定量分析可知,我们的模型具有更佳的分割性能。

4 讨 论

由上述实验可知,VLBF 模型的性能优于其他 3 种模型。影响模型结果的参数 σ 和 ϑ 等参数在已有文章^[26-27]中进行了详细分析,但是模型中的原始图像 I 和局部增强产生的血管图像 V 的权重 α 及模型初始位点的选取仍然影响着具体的分割结果,有必要对这两个参数进行具体分析。

4.1 初始曲线位置对分割结果的影响

选取图 2(G)的原始图像进一步分析初始区域的选取对图像分割结果的影响。实验参数 $\sigma = 2.0$, $\vartheta = 0.000\ 125 \times 255 \times 255$, 图像 I 与图像 V 的权重系数 $\alpha = 0.7$ 。分别选取中心点(300, 58)、(52, 141)、(200, 125)、(50, 33), 半径 10 像素的区域(图中白色圆圈覆盖的区域)作为初始区域,使用 VLBF 算法生成的分割结果如图 4 中的(A)、(B)、(C)、(D)。图 4 中的 4 幅图像初始区域不同,但都能够得到较准确的分割结果且差异较小。上述差异主要集中在图像边缘,可能是边缘处血管轮廓形态对分割结果造成的影响,但是这些边缘区域通常只包含少量的血管信息,在临床应用中的影响相对较小。通过图 4 的分析可知,VLBF 模型可以使用在灰度不均匀的情况下,且对初始位置的敏感性相对较低。




图 4 VLBF 不同初始曲线位置下的图像分割结果

Fig. 4 VLBF segmentation results of our model based on the image, the same with Fig. 2 (G), with different initializations highlighted by white circles

同样,分别适用中心点(300, 58)、(52, 141)、(200, 125)、(50, 33), 半径 10 像素的区域(图中白

色圆圈覆盖的区域)作为初始区域,使用 LBF 算法生成的分割结果如图 5 中的(A)、(B)、(C)、(D)。图 5 中,选择不同的初始区域,结果有一定的差异,尤其是图 5(D)中的结果与其他图差异叫显著。由此可知 VLBF 与 LBF 模型相比,初始位置敏感性降低,具有更稳定的分割效果。两种算法的分割准确率如表 2 所示。




图 4 LBF 算法不同初始曲线位置下的图像分割结果

Fig. 4 LBF segmentation results of our model based on the image, the same with Fig. 2 (G), with different initializations highlighted by white circles

表 2 LBF 和 VLBF 初始区域不同时的准确率

Tab. 2 Accuracy (Acc) by LBF and VLBF models with different initializations highlighted by white circles

	VLBF(Acc)	LBF(Acc)
(300,58)	0.949 1±0.000 1	0.945 4±0.000 1
(52,141)	0.943 4±0.000 1	0.943 0±0.000 1
(200,125)	0.943 4±0.000 1	0.943 2±0.000 1
(50,33)	0.943 4±0.000 1	0.940 1±0.000 1

由表 2 中 VLBF 和 LBF 的数据可知,LBF 模型易受初始区域的影响,准确率有所差异,而相同的图像和初始位置时,VLBF 模型受初始区域的影响较小,对不同的图像准确率数据可能略有差异。

4.2 参数 α 对分割结果的影响

VLBF 模型首先使用局部相位血管增强算法进行处理,将增强后的图像与图像的灰度信息作为特征信息,进行分割实验,模型中用 α 、 $1-\alpha$ 定义两种图像的权重。不同 α 的选择对实验结果有一定的影响。在 $\sigma = 2.0$, $\vartheta = 0.000\ 125 \times 255 \times 255$, 初始位点中心为(300, 58)的情况下,选取不同




图 5 VLBF 模型中,不同 α 值的图像结果
Fig. 5 Comparison of the segmentation results by the VLBF model with different values of α

的权重值: $\alpha=0.9、0.7、0.5、0.3$,得到如图 5(A)、(B)、(C)、(D)中的分割结果。图 5 中 4 幅图都能将主要血管轮廓准确的分割出来,但出现了部分非血管区域的干扰。图 5(B)分割结果较(A)有所改进,无用信息逐渐变小,细小血管轮廓更加准确。与图 5(B)比较,图 5(C)、(D)细小血管轮廓缩小、

部分信息丢失,分割结果降低。由四幅图像对比可知, α 在 0.9 到 0.3 递减的过程中,在 $\alpha=0.7$ 附近,分割结果比较精确且保留了尽可能多的血管轮廓信息,可以在 0.7 周围取值,得到更加准确的分割结果。

5 结 论

本文提出了一种基于血管约束的局部活动轮廓模型(VLBF 模型),将局部相位信息与图像灰度信息结合,作为图像分割过程中的特征信息,弥补了 LBF 模型使用灰度作为单一特征信息的缺陷,能够处理灰度分布不均匀和弱边界轮廓的血管图像。分割实验的灵敏度和准确性分别达到 74.43%和 93.67%,通过上述数据可说明,该模型不仅可以提高血管的分割精度,而且可以减弱对初始化的敏感性。

致谢:感谢中科院医工所董涛同学在项目期间给予的指导和帮助。

参 考 文 献:

[1] PARAGIOS N, DERICHE R. Geodesic active contours and level sets for the detection and tracking of moving objects [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(3): 266-280.

[2] MIKIC I, KRUCINSKI S, THOMAS J D. Segmentation and tracking in echocardiographic sequences: Active contours guided by optical flow estimates [J]. *IEEE transactions on medical imaging*, 1998, 17(2): 274-284.

[3] GUIDRY D L, FARAG A A. Active Contours: An overview with applications to motion artifact cancellation in MRI [C]. *Proceedings of the 20th Annual International Conference of the IEEE Engineering in Medicine and Biology Society*, Hong Kong, China: IEEE, 1998, 2: 644-647.

[4] MYLONA E A, SAVELONAS M A, MAROULIS D. Automated adjustment of region-based active contour parameters using local image geometry [J]. *IEEE Transactions on Cybernetics*, 2014, 44(12): 2757-2770.

[5] SETHIAN J A. A review of level set and fast marching methods for image processing [M]//BOURLIOUX A, GANDER M J, SABIDUSSI G. *Modern Methods in Scientific Computing and Applications*. Netherlands: Springer, 2002, 75: 365-396.

[6] ESTELLERS V, ZOSSO D, LAI R J, *et al.* Efficient algorithm for level set method preserving distance function [J]. *IEEE Transactions on Image Processing*, 2012, 21(12): 4722-4734.

[7] DONG B, CHIEN A, MAO Y, *et al.* Level set based surface capturing in 3D medical images [M]//METAXAS D, AXEL L, FICHTINGER G, *et al.* *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2008*. Berlin Heidelberg: Springer, 2008, 5241: 162-169.

[8] KASS M, WITKIN A, TERZOPOULOS D. Snakes: Active contour models [J]. *International Journal of Computer Vision*, 1988, 1(4): 321-331.

[9] CASELLES V, CATTÉ F, COLL T, *et al.* A geometric model for active contours in image processing [J]. *Numerische Mathematik*, 1993, 66(1): 1-31.

[10] LI C M, XU C Y, GUI C F, *et al.* Level set evolution without re-initialization: A new variational formulation [C]. *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Diego, CA, USA:IEEE, 2005, 1: 430-436.

- [11] LI C M, LIU J D, FOX M D. Segmentation of edge preserving gradient vector flow: An approach toward automatically initializing and splitting of snakes [C]. *Proceedings of the 2005 IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, San Diego, CA, USA: IEEE, 2005, 1: 162-167.
- [12] VESE L A, CHAN T F. A multiphase level set framework for image segmentation using the Mumford and Shah model [J]. *International Journal of Computer Vision*, 2002, 50(3): 271-293.
- [13] CHAN T F, VESE L A. Active contours without edges [J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277.
- [14] ROUSSON M, PARAGIOS N, DERICHE R. Implicit active shape models for 3D segmentation in MR imaging [M]//BARILLOT C, HAYNOR D R, HELLIER P. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2004*. Berlin Heidelberg: Springer, 2004, 3216: 209-216.
- [15] CASELLES V, KIMMEL R, SAPIRO G. Geodesic active contours [J]. *International Journal of Computer Vision*, 1997, 22(1): 61-79.
- [16] LI C M, KAO C Y, GORE J C, *et al.* Implicit active contours driven by local binary fitting energy [C]. *Proceedings of the 2007 IEEE Conference on Computer Vision and Pattern Recognition*, Minneapolis, MN: IEEE, 2007: 1-7.
- [17] WU H, APPIA V, YEZZI A. Numerical conditioning problems and solutions for nonparametric i. i. d. statistical active contours [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(6): 1298-1311.
- [18] AN J, ROUSSON M, XU C Y. Γ -convergence approximation to piecewise smooth medical image segmentation [M]//AYACHE N, OURSELIN S, MAEDER A. *Medical Image Computing and Computer-Assisted Intervention-MICCAI 2007*. Berlin Heidelberg: Springer, 2007, 4792: 495-502.
- [19] LANKTON S, NAIN D, YEZZI A, *et al.* Hybrid geodesic region-based curve evolutions for image segmentation [C]. *Proceedings of the Medical Imaging 2007: Physics of Medical Imaging*, San Diego, CA: SPIE, 2007, 6510: 65104U.
- [20] YEZZI A, TSAI A, WILLSKY A. Medical image segmentation via coupled curve evolution equations with global constraints [C]. *Proceedings of the IEEE Workshop on Mathematical Methods in Biomedical Image Analysis*, Hilton Head Island, SC: IEEE, 2000: 12-19.
- [21] KIM J, FISHER J W, CETIN M, *et al.* Incorporating complex statistical information in active contour-based image segmentation [C]. *Proceedings of the 2003 International Conference on Image Processing*, Barcelona, Spain: IEEE, 2003, 2: II-655-8.
- [22] LI C M, KAO C Y, GORE J C, *et al.* Minimization of region-scalable fitting energy for image segmentation [J]. *IEEE Transactions on Image Processing*, 2008, 17(10): 1940-1949.
- [23] LANKTON S, TANNENBAUM A. Localizing region-based active contours [J]. *IEEE Transactions on Image Processing*, 2008, 17(11): 2029-2039.
- [24] 张艳超, 赵建. 改进 C-V 分割算法在多光谱成像仪中的应用[J]. *中国光学*, 2015, 8(1): 68-73.
ZHANG Y C, ZHAO J. Application of improved C-V segmentation in multi-spectral imager [J]. *Chinese Optics*, 2015, 8(1): 68-73. (in Chinese)
- [25] LÄTHÉN G, JONASSON J, BORGA M. Blood vessel segmentation using multi-scale quadrature filtering [J]. *Pattern Recognition Letters*, 2010, 31(8): 762-767.
- [26] WANG L, HE L, MISHRA A, *et al.* Active contours driven by local Gaussian distribution fitting energy [J]. *Signal Processing*, 2009, 89(12): 2435-2447.
- [27] WANG L, LI C M, SUN Q S, *et al.* Active contours driven by local and global intensity fitting energy with application to brain MR image segmentation [J]. *Computerized Medical Imaging and Graphics*, 2009, 33(7): 520-531.
- [28] 杨名宇, 李刚. 利用区域信息的航拍图像分割[J]. *中国光学*, 2014, 7(5): 779-785.
YANG M Y, LI G. Aerial image segmentation with region information [J]. *Chinese Optics*, 2014, 7(5): 779-785. (in Chinese)