

文章编号 1004-924X(2013)12-3283-15

# 基于全局 LBF 水平集模型的 脑血管层次粗分割

王醒策<sup>1</sup>, 张美霞<sup>1</sup>, 武仲科<sup>1</sup>, 周明全<sup>1</sup>, 曹容菲<sup>1\*</sup>, 田 沅<sup>1</sup>, 刘新宇<sup>2</sup>

(1. 北京师范大学 信息科学与技术学院, 北京 100875;

2. 中国科学院 计算技术研究所 前瞻研究实验室, 北京 100190)

**摘要:**考虑对脑血管进行三维分割具有一定难度,提出了一种基于全局 LBF (Local Binary Fitting)水平集模型的脑血管层次化粗分割方法。首先,应用定向加权中值(DWM)滤波和各向异性扩散滤波去除脑图像噪声,同时保存血管边缘信息,在多尺度条件下局部梯度最大(LIGM)算法,应用灰度和梯度信息提取备选血管,基本实现脑灰质去除。然后,改进全局信息 LBF 水平集算法实现最大强度投影(MIP)图像分割,采用形态信息提取备选血管,剔除干扰组织。最后,融合两种方法实现脑血管粗提取。实验表明,层次化的分割方法可去除大部分不相关脑组织,包含直接双高斯统计模型中的所有分割血管信息。本研究基于时飞磁共振血管造影(TOF\_MRA)数据,相关研究结果可扩展到其它相似系统中。

**关键词:**脑血管三维重构;层次化分割;局部梯度最大算法;局部二值拟合模型;图像融合

**中图分类号:**TP391 **文献标识码:**A **doi:**10.3788/OPE.20132112.3283

## Level coarse brain vessel segmentation based on global LBF model

WANG Xing-ce<sup>1</sup>, ZHANG Mei-xia<sup>1</sup>, WU Zhong-ke<sup>1</sup>, ZHOU Ming-quan<sup>1</sup>,

CAO Rong-fei<sup>1\*</sup>, TIAN Yun<sup>1</sup>, LIU Xin-yu<sup>2</sup>

(1. *Department of Information Science and Technology, Beijing Normal University, Beijing 100875, China;*

2. *Advanced Computing Research Laboratory, Institute of Computing Technology,  
Chinese Academy of Sciences, Beijing 100190, China)*

*\* Corresponding author, E-mail: caorongfei521@163.com*

**Abstract:** To solve the problem that human brain vessels are difficult to be segmented, a level coarse brain vessel segmentation based on the global Local Binary Fitting(LBF) model was presented in the paper. First, the Directional Weight Median(DWM) filtering and the anisotropic diffusion model were used to reduce the noise and to enhance the vessel edges of brain images. Then, the Local Intensity Gradient Maximum(LIGM) algorithm was implemented based on a multi-scale space. The information of intensity and gradient was used to get the vessel candidate set and remove the influence of gray matter in the brain. At the same time, the improved global LBF level set model was used to segment the

收稿日期:2013-03-22;修订日期:2013-04-26.

基金项目:国家自然科学基金资助项目(No. 61271366, No. 61170170, No. 61003134, No. 61170203),首都科技条件平台资助项目(Z131110000613062);北京市自然科学基金重点项目(No. 4081002);中央高校基本科研业务费专项基金资助项目(No. 2012LYB49)

Maximum Intensity Projection(MIP) image. The vessel voxels were extracted with the conformation information. The results of these two steps were fused together to get the minimal covering set of the brain vessel. The experimental results show that all most the vessel voxels directly segmented by the double Gauss model can be reserved and most uncorrelated voxels can be removed. This research is based on the Time of Flight Magnetic Resonance Angiography(TOF MRA) and it is easy to expand to the similar system.

**Key words:** 3D reconstruction of brain vessel; level segmentation; Local Intensity Gradient Maximum (LIGM) algorithm; Local Binary Fitting(LBF) model; image fusion

## 1 引言

脑血管疾病一直是威胁人类健康的头号杀手,现在我国脑血管发病率依然处于上升阶段,并呈现年轻化趋势。医学影像技术以非入侵的方式实现脑血管检测,具有无创、高效的特点,现已为患者广泛接受,并普遍应用于临床。在脑血管疾病治疗中,构造一个精确的血管分割系统对于疾病的前期诊断和及时治疗意义重大。由于大脑成分复杂多样,包括灰质、白质、脑脊液、颅骨等多种组织,脑血管仅占颅腔体积的 5%,而且血管拓扑结构复杂,它们相互间有重叠或缠绕部分的灰度与周围组织的灰度有交集,对其进行图像分割非常困难。而脑血管的分割精度关乎病患生命,因此,对精度要求极高,这样仅依靠灰度对其进行直接分割难度极大。有研究利用血管形态信息及空间邻域信息构造高斯马尔科夫随机场模型(Gauss\_Markov Random Field Model, G-MRF Model),根据已知样本分布,通过分布函数的参数建模进行概率判断分类。但是血管在颅内所占比例太低,仅依靠统计方法进行分割,会使正例过小而反例过大,在参数估计的过程中势必出现参数漂移问题。基于此,本文提出一种层次化局部二值拟合(Local Binary Fitting, LBF)水平集粗分割方法,逐层递进地提取备选血管体素及与之灰度相近的脂肪体素,以提高后续精分割中的算法精度,并可以加快统计模型的计算速度。

本文提出的层次化的粗分割方法融合了灰度信息、形态信息和区域信息。首先,实现滤波预处理模块,得到降噪后的时飞磁共振血管造影(Time of Flight Magnetic Resonance Angiography, TOF MRA)序列图像。然后,应用局部梯度

极大和灰度极大搜索(Local Intensity Gradient Maximum, LIGM)算法对序列图像实现灰度空间和梯度空间的多尺度血管提取,纯化后对多尺度结果进行融合,获得备选血管体素的集合。同时,改进 LBF 水平集算法,在冠、矢、轴 3 个方向的最大强度投影(Maximum Intensity Projection, MIP)图上实现血管大致轮廓的提取。由于在 LBF 模型中引入了全局灰度信息拟合项,使得曲线演化过程具有更充分有效的约束信息,从而可以得到更精确的轮廓结果,增强了算法的稳定性;同时,结合能量惩罚项来保证水平集函数始终为符号距离函数,这就避免了重新初始化过程带来的时空损耗,使得算法运行效率大大提高。最后,对两种方法结果进行融合得到最终血管体素集,并基于此集合实现统计模型分割。经过粗分割步骤后,数据集合维数明显降低,而且,集合元素的邻域关系简单,正例集合和反例集合元素比例恰当。实验表明:提出的方法不仅使分割精度提高,同时也改善了系统效率。

降噪是 MRA 图像序列配准和组织分割前必要的预处理方法。在所有降噪方法中,最为常用的是高斯滤波方法。这种方法对某些种类的噪声具有很好的降噪效果,特别是对均质区域的噪声效果很好,不过它同时也降低了高频信号,会使图像序列非同质区域边界模糊。因此,这种方法经常用于规格化,以消除结构上的非一致性,例如:基于体素的形态测量<sup>[1]</sup>;另一种常用的方法是基于小波的方法,它是通过变换来提取特征,这种方法已很好地应用于 MRA 图像序列降噪<sup>[2]</sup>;主成分分析法<sup>[3]</sup>和离散余弦变换方法<sup>[4]</sup>也是通过类似方法实现降噪的;另外,还有一类降噪方法是边界保持滤波器,例如:各向异性扩散模型<sup>[5]</sup>,它利用梯度信息降噪后可以显著增强图像边界。最近有

研究者利用线性最小均方差和差分方程对各向异性扩散滤波<sup>[6]</sup>,可以很好地去除莱斯噪声。

所有的管状物造型方法中,基于形变模型的分割技术近几年受到广泛关注。形变模型可以综合各种对图像数据的解释和人的先验知识,能把对目标的几何形状限制和图像特征无缝地集成在一起。形变模型可分为两类:参数形变模型<sup>[7-9]</sup>和几何形变模型<sup>[10-12]</sup>。参数形变模型是以 Kass 等人<sup>[13]</sup>提出的 Snake 模型为标志;几何形变模型是借助水平集理论将曲线嵌入在高维曲面中。曲线作为超平面的零水平集,能够通过自动分裂和合并的方式自然地解决拓扑结构的变化问题,非常适合对复杂血管结构(如脑血管)的自动分割。一些学者将区域的统计信息加入几何形变模型中,提出了基于区域的测地线形变模型<sup>[10-11,14]</sup>,而上述方法是基于全局统计量,对局部细节把握不精确。之后, Li Chunming 等人将 CV 模型中的全局二值拟合能量项改为局部二值拟合能量项,并通过核函数方差控制区域尺寸,提出 LBF 模型<sup>[15-17]</sup>。统计学脑血管分割也是一类重要的方法,1999 年 Wilson 和 Noble<sup>[18]</sup>首次提出采用统计模型实现 TOF MRA 脑血管的分割。Hassouna 等人<sup>[19]</sup>在从 TOF-MRA 数据中提取 3D 脑血管的自动统计分割方法中提出了新的统计分割模型。郝聚涛<sup>[20]</sup>采用局部观测模型代替全局观测模型,使得每一段血管能够在不同的参数估计模型下进行分割,并用 ICM 算法提高了分割速度。在前期研究中,文献[21]通过构造双高斯有限混合模型拟合数据,较好地实现了脑血管中大动脉瘤和小动脉瘤的分割。文献[22]实现了精确分割灰度分布不均匀图像的 level set 算法,且具有很好的鲁棒性。以上研究为本文奠定了基础。

## 2 基于全局 LBF 水平集模型的脑血管层次粗分割方法

假设脑图像序列可被定义为一有限集合  $R = \{V(i, j, k) | 1 \leq i \leq I, 1 \leq j \leq J, 1 \leq k \leq Z\}$ , 其中:图像序列的体素个数为  $I \times J \times Z$ , 图像序列灰度水平集合定义为  $Q = \{0, 1, \dots, q\}$ , 体素灰度集合定义为  $I = \{I(i, j, k) | 1 \leq i \leq I, 1 \leq j \leq J, 1 \leq k \leq Z, I(i, j, k)$

$\in Q\}$ 。脑血管的粗分割即为集合  $R$  中的每一个元素设置二值化标签  $L = \{Background, Vessel Candidate\}$ , 即构造映射  $m: R \rightarrow L$ 。再根据映射提取备选血管体素, 削减与血管无关的体素数据。

### 2.1 图像预处理

预处理主要包括以下 3 个步骤:首先对图像降噪,降低噪声对结果的影响;其次对图像进行锐化,以突出边缘等感兴趣区域,方便后续处理;最后对切片图像配准,实现三维脑血管分割。脑医学图像的噪声主要有随机脉冲噪声和随机分布的其他噪声。因此,需要采用层次性的降噪方式。在低阶降噪处理中,主要采用模板方式,其中,定向加权中值(Directional Weight Median, DWM)滤波可以很好地去除随机脉冲噪声,而应用高斯模板可以去除其它噪声;在高阶降噪过程中,融合了多尺度思想,应用各向异性扩散方式,在去除噪声的同时又较好地保持了血管边缘。三维脑图像序列的各向异性扩散中,假设原始图像序列为  $I_0(x, y, z)$ , 定义在  $\Omega \subset R \times R \times R$  上,以时间  $t$  作为方差的高斯核  $G(x, y, z, t)$ , 将其与原始图像序列做卷积就可以由高分辨率图像得到一个低分辨率图像  $I(x, y, z, t)$ 。这种多尺度滤波用公式可表示为:  $I(x, y, z, t) = I_0(x, y, z) * G(x, y, z, t)$ 。多尺度描述从理论上可视为各向同性的热传导或热扩散方程,但各向同性扩散在滤除噪声的同时也会使图像边界变得模糊,于是有人提出各向异性扩散模型。通过求解初始条件  $I(x, y, z, t=0) = I_0$ , 得到式(1)所示的线性偏微分方程,进而得到图像平滑结果<sup>[5]</sup>。

$$\frac{\partial I(x, y, z, t)}{\partial t} = \operatorname{div}[c(\|\nabla I(x, y, z, t)\|)\nabla I(x, y, z, t)] = c(\|\nabla I(x, y, z, t)\|)\nabla I(x, y, z, t) + \nabla C(x, y, z, t) \cdot \nabla I(x, y, z, t), \quad (1)$$

其中:  $\operatorname{div}$  为散度算子;  $\nabla$  为梯度算子;  $\|\cdot\|$  表示取模运算;  $\|\nabla I(x, y, z, t)\|$  是梯度模值, 可视为边界检测器;  $c(\|\nabla I(x, y, z, t)\|)$  为扩散系数, 是关于图像梯度模值的非负递减函数;  $t$  为引入的时间算子, 它表示扩散过程与其持续的时间有关。本文采用分数型各向异性扩散方程:

$$c(\|\nabla I(x, y, z, t)\|) = \frac{1}{1 + (\|\nabla I(x, y, z, t)\|/k)^2}, \quad (2)$$

因为在对噪声图像的各向异性扩散平滑过程中,随着迭代次数和平滑程度的增加,图像梯度相对初始状态会不断下降,此时,若  $k$  仍然不变的话,被滤除的信息就越来越多,图像将会因为过多边缘细节信息的丢失而使其视觉效果失真。算法对图像序列的全局梯度直方图求积分,并按比例对其赋予不同  $k$  值,实现  $k$  值的自适应求取。

## 2.2 灰度空间提取备选血管集合

为了从 MRA 人脑医学图像序列中提取血管信息,必须获取正确、低冗余的备选血管体素全集。在灰度空间内寻找备选血管,主要利用图像序列的灰度信息和三维梯度信息。为了实现冗余查找,放宽了约束条件,这使得备选血管体素集在一定程度上大于真实血管树所含的体素数,这就需要构造血管体素覆盖集,具体步骤如下:

Step 1: 在多尺度条件下执行局部梯度最大值和灰度最大值的搜索—LIGM 算法<sup>[23]</sup>;

Step 2: 在轴、冠、矢三方向提取血管备选集合(Vessel Candidate—VC),并进行纯化;

Step 3: 多尺度空间的结果融合。

### 2.2.1 局部梯度极大值和灰度极大值搜索(LIGM)

设定  $N_n(V(i, j, k))$  是  $V(i, j, k)$  的  $n$  邻域,  $S = \{n_1, n_2, \dots, n_1, \dots, n_L\}$  是邻域大小,  $\text{Max}(V(i, j, k), N_n(V(i, j, k)))$  是  $V(i, j, k)$  在邻域  $N_n(V(i, j, k))$  下的梯度或者灰度局部极大值。

LIGM 步骤如下: 选择体素  $V(i, j, k)$ , 在其邻域系统  $N_n(V(i, j, k))$  下计算灰度和梯度的极大值, 设定阈值范围。若此体素  $V(i, j, k)$  标示为 VC, 当且仅当满足公式(3):

$$|I(i, j, k) - \text{Max}(V(i, j, k), N_n(V(i, j, k)))| < TG_{n_1} \text{ or } I(i, j, k) > TI_{n_1}. \quad (3)$$

其中:  $TG_{n_1} \in \mathbb{Q}$ ,  $TI_{n_1} \in \mathbb{Q}$ ,  $n_1 \in N_n(V(i, j, k))$ 。  $TG_{n_1}$  表示在邻域尺度下  $n_1$  梯度阈值,  $TI_{n_1}$  是在邻域尺度下的  $n_1$  灰度阈值。对图像序列中的所有体素均执行此操作, 设定此邻域尺度下图像的所有体素的标号集合。血管体素是脑图像序列中灰度最大的部分, 所以高亮体素应为血管体素。因此, 在  $n_1$  邻域尺度和特定搜索方向(轴、冠、矢)下, 若某一体素  $V(i, j, k)$  的灰度  $I(i, j, k)$  超过预设灰度阈值, 或者其与某邻域内体素灰度极值的差异性不大, 则该体素就极可能是血管体素。

### 2.2.2 纯化 VC 集合

面向 MRA 图像序列, 当某体素仅在 3D 体数据中的某一个特定图片上具有高强度信号值时, 它有可能不是真实的目标血管体素, 而是噪声点; 当它在两张或两张以上的图片上(即 3D 图像)都具有高强度信号值时, 则该体素就极有可能是血管体素。

假设:  $RVC^A$  为 3D 图像轴向搜索 VC 集,  $RVC^S$  为 3D 图像矢向搜索 VC 集,  $RVC^C$  为 3D 图像冠向搜索 VC 集。则纯化后的全部血管体素集合  $TPVC$  定义如下:

$$TPVC = \{RVC^A \& (RVC^C | RVC^S)\} | \{RVC^S \& (RVC^A | RVC^C)\}. \quad (4)$$

这样可以去掉冗余信息, 得到的冗余最少, 同时又获得最低误判率的 VC 集合, 即血管体素的最小覆盖集。

### 2.2.3 多尺度融合

在实际应用中, 邻域大小  $n_1$  可以从  $S$  集中任意选择的多个不同的值, 这就是所谓的多尺度分割。将多尺度下的  $TPVC$  融合后得到灰度空间的最终结果  $VC_I$ , 通过集合或运算完成多尺度融合, 如式(5)所示。融合后的结果可将具有高灰度的粗大血管分割出来, 同时将灰度较低的血管并入集合。

$$VC_I = TPVC_{\eta_{11}} | TPVC_{\eta_{12}}. \quad (5)$$

## 2.3 形态空间内备选血管集合提取算法

### 2.3.1 LBF 模型

LBF 模型<sup>[16]</sup>利用图像局部区域像素的灰度信息, 将全局二值拟合能量项改为局部二值拟合能量项, 通过调节核函数的方差  $\sigma$  控制中心像素的邻域, 可以在小邻域内精确求解细小目标, 加快大目标在大邻域的演化速度。LBF 对于灰度不均匀的图像分割效果显著, 而对于弱边界图像却无法进行分割。因此, 在图像降噪过程中, 本文通过各向异性扩散方式实现降噪和边缘增强。假设  $\forall X \in \Omega$ , 以像素点  $x$  为中心的局部二值拟合能量泛函的定义及其水平集的表达形式如下:

$$\epsilon_x^{\text{LBF}}(\phi, f_1(x), f_2(x)) = \lambda_1 \int K_\sigma(x-y) |I(y) - f_1(x)|^2 H(\phi(y)) dy + \lambda_2 \int K_\sigma(x-y) |I(y) - f_2(x)|^2 (1 - H(\phi(y))) dy, \quad (6)$$

其中:  $x$  是积分的中心点,  $f_1(x)$  和  $f_2(x)$  表示  $x$

点邻域内灰度分布的拟合项。 $K_\sigma$  是具有局部特性的核函数, $K_\sigma(x-y)$  随着  $|x-y|$  的减小而减小,直至最终趋于零。 $\lambda_1>0, \lambda_2>0$  是权重系数, $\phi$  是水平集函数, $H(\phi)$  是标准的 Heaviside 函数, $\delta(\phi)$  是 Dirac 函数。水平集方法可等价于如下的定义在  $\Omega$  上的积分。轮廓提取就是要使该能量泛函最小化。即为公式(7)所示:

$$\begin{aligned} \epsilon^{\text{LBF}}(C, f_1, f_2) &= \int_{\Omega} \epsilon_x^{\text{LBF}}(C, f_1(x), f_2(x)) dx = \\ &\lambda_1 \int \left[ \int K_\sigma(x-y) |I(y) - f_1(x)|^2 H(\phi(y)) dy \right] dx + \\ &\lambda_2 \int \left[ \int K_\sigma(x-y) |I(y) - f_2(x)|^2 (1 - H(\phi(y))) dy \right] dx. \end{aligned} \quad (7)$$

### 2.3.2 融合全局信息的脑血管 LBF 模型

医学脑图像中同时存在弱边界、噪声污染和灰度不均等现象,因此需要对 LBF 模型进行改进。即在考虑局部区域信息的前提下,结合全局信息进行优化。以 CV 模型的全局能量作为优化的指导项,在优化过程中,为了避免由于局部能量

$$\begin{aligned} E^{\text{CV-LBF}}(\phi, c_1, c_2, f_1, f_2) &= \lambda_1 \int_{\Omega} |I(x, y) - c_1|^2 H(\phi) dx dy + \lambda_2 \int_{\Omega} |I(x, y) - c_2|^2 (1 - H(\phi)) dx dy + \\ &\lambda_3 \int \left[ \int K_\sigma(x-y) |I(x, y) - f_1(x)|^2 H(\phi(y)) dy \right] dx + \lambda_4 \int \left[ \int K_\sigma(x-y) |I(x, y) - f_2(x)|^2 (1 - H(\phi(y))) dy \right] dx, \end{aligned} \quad (9)$$

其中:

$$\begin{aligned} c_1 &= \frac{\int_{\Omega} I(x, y) H(\phi(x, y)) dx dy}{\int_{\Omega} H(\phi(x, y)) dx dy}, \quad (10) \\ c_2 &= \frac{\int_{\Omega} I(x, y) (1 - H(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H(\phi(x, y))) dx dy}, \quad (11) \end{aligned}$$

$$f_1(x) = \frac{K_\sigma(x) * [H_\epsilon(\phi(x))I(x)]}{K_\sigma(x) * H_\epsilon(\phi(x))}, \quad (12)$$

$$f_2(x) = \frac{K_\sigma(x) * [(1 - H_\epsilon(\phi(x)))I(x)]}{K_\sigma(x) * [1 - H_\epsilon(\phi(x))]} \quad (13)$$

在此基础上引入零水平轮廓(曲线或曲面)的长度规则项,如式(14)所示:

$$L(\phi) = \int_{\Omega} \delta(\phi(x)) |\nabla \phi(x)| dx, \quad (14)$$

造成的整体性差和全局不收敛现象,在曲线演化过程中进行约束分割,并通过加入弧长约束项和水平集函数来规则化能量项,从而降低重新初始化操作次数,加快了整体迭代速度。

首先,考虑在 LBF 模型的基础上加入 CV 模型的全局信息<sup>[17]</sup>,如公式(8)所示:

$$\begin{aligned} E^{\text{CV-LBF}} &= E^{\text{CV}}(C, c_1, c_2) + \epsilon^{\text{LBF}}(C, f_1, f_2) = \lambda_1 \int_{in(C)} |I(x, y) - c_1|^2 dx dy + \lambda_2 \int_{out(C)} |I(x, y) - c_2|^2 dx dy \\ &+ [\lambda_3 \int_{in(C)} K_\sigma(x-y) |I(x, y) - f_1(x)|^2 dy + \\ &\lambda_4 \int_{out(C)} K_\sigma(x-y) |I(x, y) - f_2(x)|^2 dy] dx, \end{aligned} \quad (8)$$

其中: $I(x, y)$  是待分割图像; $C$  是演化曲线; $out(C)$  和  $in(C)$  分别表示当前演化曲线的外部 and 内部区域; $\lambda_1, \lambda_2, \lambda_3, \lambda_4$  是权重系数,它们的值均大于零; $c_1, c_2$  分别定义为图像在区域  $out(C)$  和  $in(C)$  中的平均灰度值。

$E^{\text{CV-LBF}}$  能量泛函的水平集表达式如下:

再根据水平集函数相对于符号距离函数的偏差,施加变分水平集框架下积分形式的距离偏差惩罚项,如式(15)所示:

$$P(\phi) = \int_{\Omega} \frac{1}{2} (|\nabla \phi(x) - 1|)^2 dx, \quad (15)$$

则整个能量泛函表示为公式(16)

$$E_{\text{new}}(\phi, c_1, c_2, f_1, f_2) = E^{\text{CV-LBF}} + \mu L(\phi) + \tau P(\phi). \quad (16)$$

其中: $\mu, \tau$  为非负常数。

利用规则化的  $H_\epsilon(x)$  来近似标准的 Heaviside 函数:

$$H_\epsilon(x) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctan\left(\frac{x}{\epsilon}\right) \right], \quad (17)$$

相应的  $H_\epsilon(x)$  的导数即是平滑的 Dirac 函数,即  $\delta_\epsilon(x) = H'_\epsilon(x) = \frac{1}{\pi} \frac{\epsilon}{\epsilon^2 + x^2}$ ,  $H_\epsilon(\phi) > 0, 1 - H_\epsilon(\phi) > 0$ 。此时能量泛函表示为:

$$E_\epsilon(\phi, c_1, c_2, f_1, f_2) = E_\epsilon^{\text{CV-LBF}} + \mu L_\epsilon(\phi) + \tau P(\phi). \quad (18)$$

对于具体图像,  $f_1, f_2$  已定, 根据以上公式, 以最小化关于  $\phi$  的能量泛函  $E_c(\phi, c_1, c_2, f_1, f_2)$  为原则, 加入人工变量时间步长  $t$ , 可以导出水平集函数的梯度下降流为公式(19):

$$\frac{\partial \phi}{\partial t} = -\delta_c(\phi) [(\lambda_1 (I(x, y) - c_1)^2 - \lambda_2 (I(x, y) - c_2)^2) + (\lambda_3 e_1 - \lambda_4 e_2) - \mu \operatorname{div}(\frac{\nabla \phi}{|\nabla \phi|})] + \tau(\nabla^2 \phi - \operatorname{div}(\frac{\nabla \phi}{|\nabla \phi|})), \quad (19)$$

其中:  $e_i(x) = \int_{\Omega} K_{\sigma}(y-x) |I(x) - f_i(y)|^2 dy$ , ( $i = 1, 2$ );  $\nabla^2 \phi$  等价于求水平集函数的 Laplacian 算子  $\frac{d^2 \phi}{dy^2} + \frac{d^2 \phi}{dx^2}$ ;  $\operatorname{div}(\frac{\nabla \phi}{|\nabla \phi|})$  为单位梯度向量的散度, 其等价于求水平集函数的曲率;  $\lambda_1, \lambda_2, \lambda_3, \lambda_4$  分别为新算法中各分量的权重系数。

### 2.3.3 形态空间融合算法

数据预处理的目的是为了减少混合模型的成分。脑医学图像序列的混合模型成分比较复杂, 对于给定的一系列脑图像序列很难判定其确切的组织成分的数目。若能去除颅骨及大部分脑组织, 只保留血管成分和周围少量的脑组织, 则可提高分割的精度。

选择对脑 MRI 图像在轴(Z)、矢(X)、冠(Y) 3 个方向进行投影, 得到最大强度投影图, 应用改进的 LBF 算法求取轴、矢、冠 MIP 投影图中的脑血管轮廓线, 并据此将二维 MIP 图进行 0 和 1 二值化, 即轮廓线的内点位置用 1 标记, 表示 VC 点, 外点视为无关的背景, 用 0 标记。以轴向(即 Z 轴方向)为例:

$$I^{x,y} = \begin{cases} 1 & \phi \geq 0 \\ 0 & \phi < 0 \end{cases}, \quad (20)$$

$I^{x,y}$  为轴向 MIP 图中通过全局 LBF 模型获得的区域值, 即轴向投影后的 VC 掩码图中  $(x, y)$  处的掩码值, 其为布尔型变量。将轴向所得的内点结果作为掩码图, 将其分别与原始图像中的每一幅逐一相乘, 得到的一组三维图像。处理过程如式(21)所示:

$$I_k(i, j, k) = \begin{cases} I(i, j, k), & \text{if } I^{x,y} = 1 \\ 0, & \text{otherwise} \end{cases}, \quad (21)$$

其中:  $I_k(i, j, k)$  为原始数据轴向第  $k$  张图像中位于  $(x, y)$  处的像素灰度值,  $I_k(i, j, k) \in Q$ 。

最后将 3 个方向所得的三维图像数据结果相

融合, 如公式(22)所示:

$$I_{VCL}(i, j, k) = \begin{cases} I(i, j, k) & \text{if } (I^{x,y} \& I^{x,z}) | (I^{x,z} \& I^{y,z}) \\ & (I^{x,y} \& I^{y,z}) = 1 \\ 0 & \text{otherwise} \end{cases} \quad (22)$$

其中:  $I_{VCL}(i, j, k)$  表示形变模型中 VC 集合中的  $(i, j, k)$  点的灰度值,  $I^{x,z}$  与  $I^{y,z}$  分别表示冠向、矢向 MIP 图的布尔掩码值。

### 2.4 求取最小覆盖集合

最终得到的最小覆盖集合如式(23)所示:

$$VC = VC_I | VC_L, \quad (23)$$

$VC_I$  为在灰度空间得到的备选血管集合,  $VC_L$  为应用形变模型得到的备选血管集合,  $VC$  为粗分割算法最终得到的脑血管最小覆盖集合。在新图像序列中去除强度较低部分, 得到只包含血管和周围脑组织两部分的预处理结果。融合后的结果可将具有高灰度的粗大血管分割出来, 同时也可将灰度较低的血管并入集合。将预处理后数据的所有像素作为基于高斯-马尔科夫随机场概率模型的输入数据, 进行统计分析, 以降低计算量, 提高分割精度。

## 3 算法模型及技术框架

基于以上层次化分割算法实现原型系统, 系统框架主要为数据输入模块、粗分割模块、精分割模块及绘制模块 4 个部分, 具体如图 1 所示。

### (1) 数据输入模块

对脑图像数据应用 DWM 滤波和高斯模板去除噪声, 实现脑图像的低阶降噪; 应用 Laplace 和 Robert 算子提取边缘, 应用边界特征法进行图像配准, 以消除医学图像采集过程中产生的噪声和干扰以及由于不同层图像间的位置偏移对算法准确度造成的影响。进一步采用各向异性扩散方法对脑图像序列进行滤波, 在降噪时保持甚至增强图像边缘信息来实现脑图像的高阶降噪。

### (2) 粗分割模块

经过预处理之后的脑图像序列, 在灰度空间和梯度空间都实现了多尺度搜索, 得到包含所有血管体素和最少冗余信息的脑血管体素备选集合, 通过纯化和多尺度融合后, 可以求取最小覆盖集。对预处理之后的脑图像模块, 在轴(Z)、矢(X)、冠(Y) 3 个方向做 MIP 投影, 融合全局信息

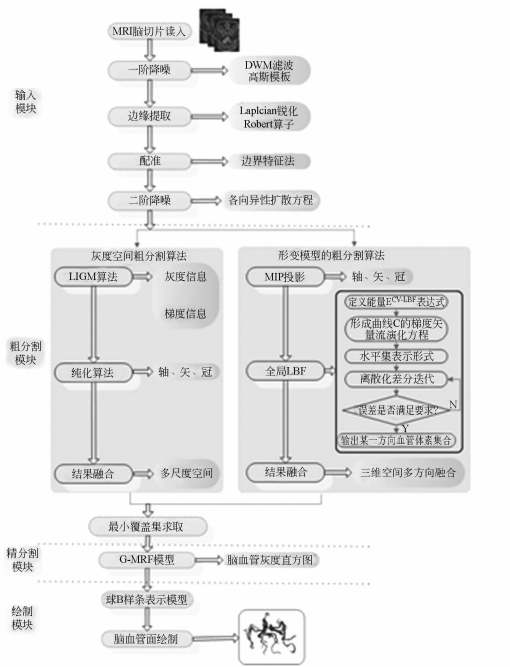


图 1 基于全局 LBF 模型脑血管层次粗分割方法流程图  
Fig. 1 Flowchart of coarse segmentation method for brain vessel based on global LBF model

构造 LBF 模型水平集分割模型,应用形变模型提取 MIP 图像中的脑血管部分,以消除脑血管中的背景和非脑血管组织的影响。之后,将其作为掩码回乘,通过融合算法,实现形态空间上脑血管体素备选集合求取。融合形态信息和灰度信息,最终确定脑血管备选集合。

(3)精分割模块

构造高斯-马尔科夫随机场模型,设计势函数的求取,采用 SEM 法估计模型参数,通过计算观测数据的条件概率,并据此给每个像素指定类别标号,实现脑血管的精细分割。


(4)绘制模块

对分割后得到的血管像素采用树结构表示血管模型的拓扑信息,采用球 B 样条曲线表示血管的几何信息,并通过面绘制得到脑血管三维模型结果。

4 实验结果及数据分析


本系统现在已经存储了 32 位病患的脑 CT 或脑 MRI 数据,相关系统已经在北京 304 医院脑神经外科和北京海军总医院的放射科初步上线测试应用,同时在天津医科大学的医学影像专业教

学中也得到了部分应用。根据本文提出模型,应用上述算法,实现脑血管的粗分割。对一组 DICOM 格式的临床人脑医学体数据进行了实验,其中包含 136 幅 TOF MRA 图像序列,图像间的最大间隔为 2.1 mm,最小间隔为 0.7 mm,重构直径为 200 mm。其它数据涉及到患者隐私,故此不再提供。实验中所用硬件系统为 Intel(R) Core(TM) 2 CPU, 2.00 GB 内存, NVIDIA Quadro FX 550 显卡。软件平台为 Windows XP, VC 6.0, Matlab 7.0 及 VTK 5.0。由于脑血管的分割精度与脑图像质量直接相关,而脑图像质量受采样设备影响较大,生物磁自旋成像技术又发展迅速,故现在还未出现公认的 MRA 脑血管金标准数据。而医生手工分割数据受主观影响,个体差异性太大,且在二级以上血管处无法进行精确判断。故为说明算法的有效性,实验中采用实际数据,并将本文算法和前期工作进行比较<sup>[20]</sup>。



(a) 第 110 张原始图片

(a) Original image of the 110th level



(b) 第 110 张图片各向异性扩散后结果

(b) Anisotropic diffusion result of Fig. 2(a)

图 2 各向异性扩散降噪

Fig. 2 Results of anisotropic diffusion denoising

图 2 是数据 1 第 110 张图片做完二阶降噪后的处理结果。经过一阶高斯及 DWM 滤波和二阶各向异性扩散滤波后,两图片差异不明显。其中的直线表示图片中第 248 行。图 3 是原始图片和经过各向异性扩散滤波之后的相应图片在同一直线位置(红线)上像素的灰度分布情况对比图,原始图片的灰度分布用蓝色曲线表示,各向异性扩散之后的灰度分布用红色曲线表示(彩图见期刊电子版),X 轴表示红色直线上当前像素与红色直线左端起点的距离,Y 轴表示当前像素的灰度值按灰度最大值映射(除以 928)到  $[0, 1]$  区间之后的值。可以看出,在蓝色曲线的大梯度处(曲线的上、下陡坡段,即图片的边界位置),红色曲线也相应地保留了蓝色曲线的大波峰和大波谷;在蓝色曲线上的灰度较平坦的区域,红色曲线表现出了明显的平滑处理。这说明各向异性扩散在很好地滤掉随机脉冲噪声的同时,很好地保留了边缘细节信息。






图 3 第 110 张切片做各向异性扩散前后的灰度对比  
Fig. 3 Comparison of gray scales for the 110th slice image before and after anisotropic diffusions



(a) 第 73 张原始切片



(b) 各向异性扩散后结果



(c) 灰度阈值(TI=400)分割结果

(a) Original image of the 73th slice

(b) Anisotropic diffusion result of Fig5(a)

(c) Segmentation result with grayscale threshold(TI=400)

图 4 为应用形变模型所构造备选血管的实验结果,白色高亮区域表示备选血管体素。图 4(a)表示第 73 张切片的原始图像;图 4(b)表示经过二阶去噪后的结果;图 4(c)表示局部灰度搜索结果;图 4(d)表示小邻域内低尺度下的梯度搜索结果;图 4(e)表示大邻域内高尺度梯度搜索的结果;图 4(f)表示不同尺度下的融合结果。通过分析可以看出,血管为脑图像中最明亮的区域,通过灰度可以得到大部分血管信息,而通过梯度搜索可以获得血管边缘灰度较低的血管体素。不同尺度下融合结果的血管体素点明显比单纯灰度的体素点增多。该算法不仅保留了边缘信息,较大尺寸的血管以及灰度较高的像素,还可以检测出细小血管分支上像素点集,使之最大限度地包含真实血管体素集,并且尽可能少的包含冗余信息,得到 VC 集的最小覆盖。在实验中,灰度阈值统一设为  $TI_{\eta_1}=400$ ,小尺度  $\eta_1=3 \times 3 \times 3-1$  的邻域系统下,梯度局部极值的允许波动范围阈值  $TG_{\eta_1}=0.6$ ,大尺度  $\eta_2=5 \times 5 \times 5-1$  的邻域系统下,梯度局部极值的允许波动范围阈值  $TG_{\eta_2}=1$ 。同时经过实验测试可以发现,备选血管集合中,灰度搜索算法贡献的体素个数明显多于梯度搜索贡献的体素个数。这是因为灰度搜索主要是提取高亮血管体素,而梯度搜索主要是提取血管边缘体素。同时经过测试发现,该算法对梯度阈值  $TG$  的敏感程度高于对灰度阈值  $TI$  的,经过分析可知,这主要由于梯度是差量计算,取值范围较小,因此小幅波动会带来更多点的变化。

图 5~图 7(彩图见期刊电子版)是利用数据 1 的形变模型构造出的备选血管结果。其中:图 5



(d) 小邻域内梯度搜索 LIGM3 (TG = 0.6, Nnl = 26)

(d) Gradient search LIGM3 in small neighborhood (TG = 0.6, Nnl = 26)

(e) 大邻域内梯度搜索 (TG = 1, Nnl = 124)

(e) Gradient search in large neighborhood (TG = 1, Nnl = 124)

(f) 多尺度下的信息融合结果

(f) Information fusion results of multi-scale

图 4 第 73 张图片灰度空间的备选血管集合确定


Fig. 4 Determination of vessel candidate set of gray space for the 73th image in gray space

(a), 图 6(a), 图(7)为初始轮廓线的设置; 图 5(b), 5(c), 6(b), 6(c), 7(b), 7(c)为迭代的中间结果; 图 5(d), 图 6(d), 图 7(d)为最终的迭代结果。而通过对图 5(b), 5(c), 5(d)的分析可以发现, 单纯 LBF 模型的演化速度较慢, 对于细小血管很难分割。也就是对于脑血管这种结构复杂、灰度不均匀的物体, 单纯 LBF 模型难以处理。分析其原因单纯的 LBF 模型是由图像局部统计信息驱动轮廓线进行演化得到的, 只有在所设置的初始轮廓线合适, 且物体灰度变化相对平缓的情况下, 才能够准确检测出物体边界。由图 6(b)~6(d)可知, CV 模型不能够精确地检测出血管轮廓。在多次迭代之后, 迭代曲线集中在脑皮质轮廓上, 在血管周围的迭代点并不能收敛, 出现过分割现象。由此可见, 此种模型难以处理脑血管这种轮廓复杂且灰度分布不均匀的图像。原因是它仅考虑了图像的全局统计信息, 而忽略了物体的几何信息或局部统计信息。而本文模型融合了全局信息和局部信息, 对于复杂的结构具有更好的收敛能力。另外, 由于增加了距离偏差惩罚项使得更新公式对于灰度变化不均匀的弱边界的真实边缘位置也能够准确定位, 且所形成的区域均为封闭区域, 更容易提取血管像素点。


为了进一步验证算法的有效性, 针对血管形态构造了改进的全局 LBF 试验。其中: 图 8(a)~

8(c)为对数据 1 在轴、冠、矢三方向的 MIP 图上应用文中改进的 LBF 算法所获得的血管区域, 为 DICOM 格式图像; 图 8(d)和图 8(e)是经典的水平集测试数据, 为 BMP 图像, 标识其为血管 1 和血管 2 图像。通过试验可以发现, 文中改进的 LBF 算法对于灰度不均匀, 形态复杂的图像有效。应用于血管分割时, 可以很好地解决脑血管医学图像中的弱边界问题。


图 8 中 5 幅图像的改进 LBF 系数如表 1 所示。总体看来, 基本系数变化不大, 也就是说, 对于脑血管这类图像应用改进的 LBF 方法时, 并不需要大量的变换参数即可得到较好的分割效果。全局信息仅对搜索具有指导使用, 因此, 图 8(a)~8(d)中的全局系数  $\lambda_1$  和  $\lambda_2$  都较小。这是因为使用少量的全局信息引导或启动轮廓线的演化可以避免陷入局部极小值。对于图 8(e)的血管 2 来说, 由于边缘灰度交错程度较低, 故可适当加大  $\lambda_1$  和  $\lambda_2$ 。这样, 可以减少对局部区域信息和边缘信息的依靠, 在一定程度上提高优化速度。 $\lambda_3$  和  $\lambda_4$  是区域信息的加权系数。当物体边缘较模糊时, 可适当增大它们的值。 $\Delta t$  用来控制演化效率。当  $\Delta t$  较小时, 演化效率较低, 但较精确; 反之, 演化精度降低。由表 1 可以看到, 对于 DICOM 格式的图像, 算法参数基本相似; 而对于 BMP 格式的图像, 算法参数也大致相同。这说明




(a)轴向MIP图及初始轮廓  
(a)Axial MIP and it's initial contour




(b)单纯的LBF模型迭代80次  
(b)Results of LBF model with 80 iterations




(c)单纯的LBF模型迭代120次  
(c)Results of LBF model with 120 iterations




(d)单纯的LBF模型迭代180次  
(d)Results of LBF model with 180 iterations  
图5 基于单纯的LBF模型的备选集合确定  
Fig.5 Determination of vessel candidate set based on LBF model




(a)轴向MIP图及初始轮廓  
(a)Axial MIP and it's initial contour




(b)单纯的CV模型迭代2次  
(b)Results of CV model with 2 iterations




(c)单纯的CV模型迭代4次  
(c)Results of CV model with 4 iterations




(d)单纯的CV模型迭代20次  
(d)Results of CV model with 20 iterati  
图6 基于CV模型的备选集合确定  
Fig.6 Determination of vessel candidate set based on CV model




(a)轴向MIP图及初始轮廓  
(a)Axial MIP and it's initial contour



(b)改进模型迭代1次后的结果  
(b)Results of improved model with 1 iteration



(c)改进模型迭代2次后的结果  
(c)Result of improved method with 2 iterations



(d)改进模型迭代3次后的结果  
(d)Results of improved method with 3 iterations  
图7 基于改进模型的备选集合确定  
Fig.7 Determination of vessel candidate set based on improved method




图 8 不同血管图片使用全局 LBF 效果图

Fig. 8 Segmentation results of different vessel images by using global LBF

参数设定主要受图像格式的影响。同时也说明本文算法对于不同格式的图像进行分割均会取得较好的结果。

表 1 本文算法分割不同图像所对应的参数

Tab. 1 Parameters corresponding to different segmented images by using proposed method

	$\varepsilon$	$\sigma$	$t$	$\mu$	$\lambda_1$	$\lambda_2$	$\lambda_3$	$\lambda_4$	$\lambda_5$	$\Delta t$
轴向 MIP	1.0	3.0	1.0	0.000 01	0.05	0.05	0.95	0.95	0.05	0.1
冠向 MIP	1.0	2.0	1.0	0.000 001	0.05	0.05	0.95	0.95	0.05	0.08
矢向 MIP	1.0	2.0	1.0	0.000 001	0.05	0.05	0.95	0.95	0.05	0.034
血管 1	1.0	5.0	1.0	0.001 5	0.05	0.05	0.95	0.95	0.05	0.024 2
血管 2	1.0	4.0	1.0	0.001 5	0.16	0.16	0.84	0.84	0.16	0.013

对图 8(a)~8(e)分别采用单纯 LBF 算法,

CV 模型和本文改进算法进行处理,计算各自的迭代次数和 CPU 时间,如表 2 所示。由表 2 可以看到,对于 MIP 投影图,CV 模型的代价较低,但是效果相对较差。而对于血管 1 和血管 2 图像,CV 模型较其余 2 种方法需要更多的计算时间。单纯的 LBF 算法由于只利用局部信息,因此,如果要获得全局最优集合需要更长的迭代时间。本文模型融合了全局信息和局部信息,是边缘信息和区域信息的有机结合,因此,其迭代收敛次数比其它算法有所减少。虽然在某些图像(冠向 MIP,矢向 MIP)中迭代次数略高,但是对血管 1 和血管 2 的经典测试数据(灰度不均匀,边界不明显)来说,其比单纯的 CV 及单纯的 LBF 有更好的效率。

表 2 对于不同图片 3 种模型的迭代次数及 CPU 时间

Tab. 2 CPU consuming time and iteration numbers corresponding to different images by using CV、LBF and our method


	单纯 LBF 迭代次数	单纯 LBF CPU 时间/s	CV 模型迭代次数	CV 模型的 CPU 时间/s	本文模型迭代次数	本文模型的 CPU 时间/s
轴向 MIP	180	228.453 1	20	160.468 8	3	5.046 9
冠向 MIP	7	0.781 3	2	1.515 6	5	2.875 0
矢向 MIP	8	0.906 3	3	0.671 9	7	3.921 9
血管 1	200	4.312 5	500	38.625 0	96	14.093 8
血管 2	120	2.390 6	900	49.718 8	63	7.765 6

在本模型的数值离散化迭代求解过程中,LBF 局部能量拟合项的计算复杂性主要在于  $f_1$ ,  $f_2$  和水平集演化中的  $\lambda_1 e_1 - \lambda_2 e_2$  的计算。 $f_2$  可

转化为  $f_2(x) = \frac{K_\sigma * I - K_\sigma [H_\varepsilon(\phi) I]}{K_\sigma * 1 - K_\sigma * H_\varepsilon(\phi)}$ 。由此可以看出, $K_\sigma * I$  只于原始图像有关,与迭代过程无


关;而  $K_s * 1$  是高斯核函数与常量的卷积,所以,这两步都可以在迭代之前计算出来,不用在迭代过程中重复计算。因此,每次迭代时,只需要计算  $f_2$  的分子和分母中的第二项:  $K_s[H_e(\phi)I]$  和  $K_s * H_e(\phi)$ 。而这 2 个卷积都与  $f_1$  的计算结果相同,这样,可在一定程度上降低程序的计算量。

图 9 是粗分割的最终结果。图 9(a)为由数据 1 直接体绘制结果;图 9(b)为数据 1 在灰度空间获得的备选血管集合  $VC_i$  的直接体绘制结果。可以看到,经过 LIGM 算法处理后,可获得大部分的脑血管体素,脑血管形态已经非常明显。但由于该过程只是在灰度空间进行的,而血管灰度分布不均匀会使在细小血管处出现不连续现象。图 9(c)是形变模型中最终获得的备选血管集合  $VC_L$ ,图中脑血管的基本形态也比较明显。这是因为考虑到了空间血管的形态信息,所以,在图 9(c)中可以保持良好的血管联通性,但是在单体素的毛细血管顶端会产生体素丢失现象。两种方法融合之后产生的脑血管最小覆盖集合如图 9(d)所示。由图 9(d)可以看到,融合结果既可以保证血管联通,又可保证毛细血管等的细节信息不丢失。虽然在整体 VC 集合中存在着大量的无关噪声点集,但是血管集合均在此覆盖中。



(a)直接体绘制结果

(a) Direct volume rendering results of raw data



(b)灰度空间备选血管点集体绘制结果

(b) Volume rendering result of vessel candidate points set in grayscale space



(c)形变模型备选血管体绘制

(c) Volume rendering results of vessel candidate for deformation models



(d)脑血管最小覆盖集合

(d) Minimum covering set of brain vessel

图 9 脑图像数据中脑血管集合分析

Fig. 9 Brain vessel set analysis of brain TOF MRA images

通过实验分析可以看出,各向异性扩散在保留边界信息的同时过滤掉了大量噪声点,使得同质区域内图像更加平滑;异质区域边界增强的更明显。在灰度空间内,算法融合了图像序列中的灰度信息和梯度信息,可以分割出图像序列中仅具有 1 个,2 个体素的血管值。在形变模型中,改进的全局 LBF 模型由于融合了全局信息和局部信息,可以在较少的迭代次数内获得比单纯的 LBF 模型更好的分割结果。在分割精度和效率上有所提高。融合后得到的最小覆盖集合去掉了冗余信息,精简了数据的信息量,为后续精细分割做了有效的铺垫。可以避免将医学图像数据整体导入内存进行基于高层参数统计的精分割时会出现的内存泄露、长时间迭代不收敛等问题。但由于算法中参系数较多,目前还没有完全给出能量函数中全局信息和局部信息的关系,这需要在后续研究中进一步分析。

## 5 结 论

本文将基于图像全局信息的能量加入到图像局部信息的 LBF 模型能量项,使得改进的模型能够有效分割灰度不均匀的图像。同时,引入内部能量约束项来约束水平集函数使其始终保持为符号距离函数,从而去除了水平集函数的重新初始化过程,提高了水平集函数演化的稳定性。实验表明,改进模型不但能够对边界模糊或边界缺损的灰度不均匀目标图像进行分割,具有很强的抗噪能力,而且还使曲线演化具有双向性,使得演化速度和准确率都大大提高。整个数据预处理过程有效地减少了体数据中组织的成分,去除了颅骨及大部分脑组织,只保留了血管和周围极少的脑组织。将整个结果作为后续精细分割的输入数据,为下一步的类自适应的基于高斯-马尔科夫随

机场模型的脑血管分割做了有力的铺垫,对于最终分割和绘制结果的有效性、精确性起到了不可忽视的良好作用。

## 6 致 谢

本文的实验的数据来源于中国人民解放军海军总医院脑血管病例数据。对比实验中的单纯 LBF 模型源码来源于李春明博士公布的开源软件包,血管 1 和血管 2 的图片数据来源于李春明博士公开的水平集测试图片,脑血管双高斯统计学分割源码来源于徐丰博士提供的软件包。对于他们前期的工作表示衷心的感谢。另外,感谢 Newcastle 大学的 Jesse J. Jin 教授给予算法上的讨论帮助。

## 参考文献:

- [1] RUBINSTEIN R, BRUCKSTEIN A M, ELAD M. Dictionaries for sparse representation modeling [J]. *Proceedings of the IEEE*, 2010, 98(6): 1045-1057.
- [2] ANDREA C, PAOLO B, PIERO C, *et al.*. Local MRI analysis approach in the diagnosis of early and prodromal Alzheimer's disease [J]. *NeuroImage*, 2011, 58(2): 469-480.
- [3] ZHANG L, LUKAC R, WU X, *et al.*. PCA-based spatially adaptive denoising of CFA images for single-sensor digital cameras [J]. *IEEE Transactions on Image Processing*, 2009, 18(4): 797-812.
- [4] MANJÓN J V, COUPÉ P, BUADES A, *et al.*. New methods for MRI denoising based on sparseness and self-similarity [J]. *Medical image analysis*, 2012, 16(1): 18-27.
- [5] KRISIAN K, AJA-FERNÁNDEZ S. Noise-driven anisotropic diffusion filtering of MRI [J]. *IEEE Transactions on Image Processing*, 2009, 18(10): 2265-2274.
- [6] 金炜, 俞建定, 符冉迪, 等. 双树轮廓波变换域的磁共振图像降噪 [J]. *光学精密工程*, 2010, 18(3): 756-763.
- [7] JIN W, YU J D, FU R D, *et al.*. Magnetic resonance image denoising in dual-tree contourlet transform domain [J]. *Opt. Precision Eng.*, 2010, 18(3): 756-763. (in chineses)
- [8] BOISSONNAT J D, CHAINE R, FREY P, *et al.*. From arteriographies to computational flow in saccular aneurysms: the INRIA experience [J]. *Medical image analysis*, 2005, 9(2): 133-143.
- [9] FRIDMAN Y, PIZER S M, AYLWARD S, *et al.*. Extracting branching tubular object geometry via cores [J]. *Medical Image Analysis*, 2004, 8(3): 176-196.
- [10] VOLKAU I, ZHENG W L, BAIMOURATOV R, *et al.*. Geometric modeling of the human normal cerebral arterial system [J]. *IEEE Transactions on Medical Imaging*, 2005, 24(4): 529-539.
- [11] PARAGIOS N, DERICHE R. Geodesic active regions and level set methods for motion estimation and tracking [J]. *Computer Vision and Image Understanding*, 2005, 97(3): 259-282.
- [12] CHAN T F, VESE L A. Active contours without edges [J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277.
- [13] BOGUNOVIC H, POZO J M, VILLA-URIOL M C, *et al.*. Automated segmentation of cerebral vasculature with aneurysms in 3DRA and TOF-MRA using geodesic active regions: An evaluation study [J]. *Medical Physics*, 2011, 38(1): 210.

- Snakes; active contour models [J]. *International Journal of Computer Vision*, 1988, 1(4): 321-331.
- [14] 王卫星, 苏培垠. 基于颜色, 梯度矢量流活动轮廓及支持向量机实现白细胞的提取和分类[J]. *光学精密工程*, 2012, 20(12): 2781-2790.  
WANG W X, SU P Y. Blood cell image segmentation on color and GVF Snake for Leukocyte classification on SVM [J]. *Opt. Precision Eng.*, 2012, 20(12): 2781-2790. (in Chinese)
- [15] LI C M, XU C Y, GUI C F, *et al.*. Level set evolution without re-initialization; a new variational formulation [C]. *IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, (CVPR 2005), 2005, 1: 430-436.
- [16] 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.
- [17] WANG L, LI C, SUN Q, *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.
- [18] WILSON D L, NOBLE J A. An adaptive segmentation algorithm for Time-of-Flight MRA data [J]. 1999, 18(10): 938-945.
- [19] HASSOUNA M S, FARAG A A, HUSHEK S, *et al.*. Cerebrovascular segmentation from TOF using stochastic models [J]. *Medical Image Analysis*, 2006, 10(1): 2-18.
- [20] HAO J T, ZHAO J J, LI M L. Spatial continuity incorporated multi-attribute fuzzy clustering algorithm for blood vessels segmentation [J]. *Science China Information Sciences*, 2010, 53(4): 752-759.
- [21] 徐丰, 王醒策, 周明全, 等. SEM 混合模型脑血管分割算法[J]. *计算机辅助设计与图形学学报*, 2010, 22(11): 1905-1911.  
XU F, WANG X C, ZHOU M Q, *et al.*. Segmentation algorithm of brain vessel image based on SEM statistical mixture model [J]. *Journal of Computer-Aided Design & Computer Graphics*, 2010, 22(11): 1905-1911. (in Chinese)
- [22] TIAN Y, DUAN F Q, ZHOU M Q, *et al.*. Active contour model combining region and edge information [J]. *Machine Vision and Applications*, 2013, 24(1): 47-61.
- [23] LUO S H, JIN J J, LI J. A knowledge-based approach for segmenting cerebral vasculature in neuroimages [C]. 2011 *Third International Conference on Measuring Technology and Mechatronics Automation (ICMTMA)*, 2011, 1: 74-77.

#### 作者简介:



王醒策(1977—),女,北京人,工学博士,副教授,1999年、2002年、2005年于哈尔滨工程大学分别获得学士、硕士及博士学位,主要从事图像处理,医学可视化及智能优化算法等方向的研究。E-mail: wangxingce@bnu.edu.cn




张美霞(1986—),女,湖北黄冈人,工学硕士,2012年于北京师范大学获得工学硕士学位,主要从事医学影像降噪和分割研究。E-mail: zhangmeixia0502@163.com



武仲科(1965—),男,辽宁海城人,教授,博士生导师,1988年于北京大学获得学士学位,1991年、1995年于北京航空航天大学分别获得硕士、博士学位,1997年于中国科学院软件所博士后出站,主要从事三维几何造型和虚拟现实技术方面的研究。E-mail: zwu@bnu.edu.cn



周明全(1954—),男,陕西西安人,教授,博士生导师,1988年于西北大学获得硕士学位,现为教育部虚拟现实应用工程研究中心主任,主要从事虚拟现实与三维可视化相关技术的研究。E-mail: mqzhou@bnu.edu.cn



**曹容菲**(1988-),女,山西长治人,硕士研究生,2011年于西北大学获得学士学位,主要从事脑图像统计分割研究。  
E-mail: caorongfei521@163.com



**田 云**(1980-),男,河南人,工学博士,副教授,2007年于西北工业大学获得博士学位,主要从事医学图像处理、模式识别方面的研究。E-mail: tianyun@bnu.edu.cn



**刘新宇**(1972-),男,北京人,工学博士,副研究员,2002年于哈尔滨工业大学获得博士学位,2004年于中国科学院计算所博士后出站,主要从事芯片设计及智能信息处理方向的研究。E-mail: liuxinyu@ict.ac.cn

(版权所有 未经许可 不得转载)