

中图法分类号: TP391 文献标志码: A 文章编号: 1006-8961(2011)07-1199-07

论文索引信息: 蒋建国, 任靖, 郝世杰, 詹曙, 李鸿. 自适应主动轮廓模型下的骨关节 MRI 快速分割 [J]. 中国图象图形学报, 2011, 16(7): 1199-1205

# 自适应主动轮廓模型下的骨关节 MRI 快速分割

蒋建国<sup>1)</sup>, 任靖<sup>1)</sup>, 郝世杰<sup>1)</sup>, 詹曙<sup>1)</sup>, 李鸿<sup>2)</sup>

<sup>1)</sup>(合肥工业大学计算机学院, 合肥 230009) <sup>2)</sup>(安徽医科大学第一附属医院骨科, 合肥 230022)

**摘要:** 提出一种无须重新初始化的变分水平集自适应主动轮廓模型。该模型利用图像的局部特性自适应决定曲线的演化, 同时加入局部 C-V 能量项, 改进边界停止函数, 提高对灰度分布重叠、分布不均匀及弱边界处理的鲁棒性, 并加快了曲线演化的收敛速度。结合医学序列图像特点, 利用 Heaviside 函数对当前截面分割结果进行分段常量化后投射至相邻界面作为初始化曲线, 实现对序列图像的自动分割。最后, 以骨关节磁共振图像中正常结构和病灶组织的分割实验对算法进行了验证。

**关键词:** 主动轮廓模型; 水平集; 自适应; 局部 C-V; Heaviside 函数

## Fast joint MRI segmentation through an adaptive active contour

Jiang Jianguo<sup>1)</sup>, Ren Jing<sup>1)</sup>, Hao Shijie<sup>1)</sup>, Zhan Shu<sup>1)</sup>, Li Hong<sup>2)</sup>

<sup>1)</sup>(School of Computer & Information, Hefei University of Technology, Hefei 230009 China)

<sup>2)</sup>(Department of Orthopaedics, The First Affiliated Hospital of Anhui Medical University, Hefei 230022 China)

**Abstract:** An adaptive active contour model-variational level set without re-initialization is proposed in this paper. We use local characteristics of image to implement adaptive curve evolution. Simultaneously, We add local C-V energy term and improve the edge stop function. These can increase the iterative convergence speed and make it more robust to the intensity distribution overlapping, intensity inhomogeneity and weak boundary. Combining with the characteristics of serial medical images, transform the segmentation result of current slice to piecewise constant function using the Heaviside function. Cast it to the next slice as the initial curve to implement automatic segmentation of serial images. The proposed method has been applied to segment normal structure and diseased tissue in musculoskeletal MRI with promising results.

**Keywords:** active contour model; level set; adaptive; local C-V; Heaviside function

## 0 引言

在基于图像的计算机辅助诊断与 3 维可视化等应用中, 对医学图像的分割一般具有较强的针对性(如心室壁等正常结构或肿瘤等病灶), 同时要求有较高的分割精度。但医学图像中普遍存在组织内图像灰度分布不均匀、组织间灰度分布有重叠、边缘模

糊、背景复杂等因素, 因此, 如何实现目标组织或结构的精确、快速分割, 成为医学图像分析处理的难点。

近年来, 将主动轮廓模型应用到医学图像分割中的研究得到广泛关注。主动轮廓模型是基于曲线演化理论和水平集<sup>[1]</sup>的方法, 其基本思想是: 把演化曲线(主动轮廓)隐含地表示为一个更高一维函数(水平集函数)的零水平集, 根据分割要求建立合

收稿日期: 2010-03-30; 修回日期: 2010-05-20

基金项目: 安徽省 2010 高校省级自然科学研究重点项目(KJ2010A193); 教育部博士点基金项目(20060359004); 教育部留学归国人员科研启动基金项目(413117)。

第一作者简介: 蒋建国(1955—), 男, 教授, 博士生导师。主要研究方向为数字图像分析与处理、数字信号处理、分布式智能系统。E-mail: jjg@ah165.net。

适的偏微分方程,水平集在该偏微分方程(演化方程)的控制下进行演化,直到零水平集演化到图像的目标边界为止。该方法最大优点是在演化过程中水平集始终保持为一个连续函数,能够灵活地解决零水平集的拓扑结构改变问题。

几何主动轮廓模型(GAC 模型)是这其中典型的方法之一,其实质是通过在局部寻找图像边缘来实现图像的分割,是局部最优的方法。Li 等人<sup>[2]</sup>在 GAC 模型的基础上提出了无须重新初始化的水平集模型,增加了补偿能量项,用于补偿水平集函数与符号距离函数之间的偏差,省去了水平集的周期性重新初始化;同时可以采用较大的时间步长来求解偏微分方程,提高了演化收敛速度。但该方法仍然存在如曲线演化趋势(收缩或扩张)固定、对于初始化曲线跨越目标边界时无法正确完成分割、对弱边界不鲁棒等不足。不少学者针对这些不足提出了改进,例如,王斌等人<sup>[3]</sup>提出变分的接力水平集,通过形态学操作打破已寻找到的边界稳态,使零水平集继续向内演化来寻找新的边界,直至零水平集曲线所包围的面积减小为零,结束演化。该方法很好地解决了内部有空洞的目标分割问题,但由于其曲线演化趋势依然只能表现为单一的收缩或扩张,所以对初始化跨越目标边界的情况仍然无法解决,因此不利于序列图像的自动分割。何宁等人<sup>[4]</sup>提出了基于边缘和区域信息相结合的水平集分割方法,但该方法加入了物体形状的先验知识作为约束信息,这对于医学图像,尤其是病灶的分割是不利的,因为组织器官或病灶因人而异,较难给出合适的先验形状信息。温铁祥等人<sup>[5]</sup>提出在仅考虑局部梯度信息的 Li 方法中加入 M-S 模型的全局信息,由于全局灰度信息的加入,对于结构较复杂、灰度分布不均匀的目标有较好的分割效果,在分割速度上也有一定的改进。同时也正是因为全局灰度的影响,对于待分割目标与其他组织在灰度分布上有重叠的图像无法实现较好的分割。孙晓欢等人<sup>[6]</sup>对分级 C-V 模型进行了改进,将非线性平滑去噪作为预处理,省去了 M-S 能量函数中的长度平滑项,加快了曲线演化速度,对于多目标、弱边界有较好的分割效果。但由于全局信息的影响,对灰度分布有重叠的情况也不好解决,由于分级 C-V 模型中后续分割要求重新初始化,故不利于序列图像的自动分割。

针对以上方法的缺陷,提出一种局部自适应的主动轮廓模型,并应用于骨关节磁共振图像序列中

目标的快速分割。该方法实现了曲线的局部自适应演化,改进局部 C-V 项的加入,对灰度分布重叠、分布不均匀更鲁棒,加快了曲线的演化速度。利用相邻序列图像间的相关性,将上一幅图像的分割结果经过预处理赋予相邻图像作为初始化曲线,实现对序列图像的自动分割。

## 1 无须重新初始化的水平集方法<sup>[2]</sup>

无须重新初始化的水平集方法通过在能量泛函中加入补偿能量项,补偿了水平集函数在演化过程中与符号距离函数之间的偏差,使得水平集方法从传统重新初始化的复杂且耗时的操作中解脱出来。其能量泛函定义为

$$E_{Li}(\phi) = \mu E_{in}(\phi) + E_{out}(\phi) \quad (1)$$

式中, $E_{in}(\phi)$  定义为

$$E_{in}(\phi) = \int_{\Omega} \frac{1}{2} (|\nabla\phi| - 1)^2 dx dy \quad (2)$$

在对能量  $E_{in}(\phi)$  最小化的过程中, $|\nabla\phi|$  逐渐向 1 逼近,在演化曲线的一个邻域中,水平集演化方程存在唯一解,且水平集函数能在这个邻域中保持为一个有符号的距离函数。所以这里可以将符号距离函数简化为式(3)的分段常量函数。

$$\phi = \begin{cases} -d & (x, y) \in \Omega_{in} \\ 0 & (x, y) \in \partial\Omega \\ +d & (x, y) \in \Omega_{out} \end{cases} \quad (3)$$

式中: $\Omega$  为图像区域; $\Omega_{in}$ ,  $\Omega_{out}$  分别表示曲线内部和外部区域; $\partial\Omega$  表示边界曲线; $d$  为一小的正常数。

$E_{out}(\phi)$  定义为

$$E_{out}(\phi) = \lambda L(\phi) + \beta A(\phi) = \lambda \int_{\Omega} g(\nabla I) \delta_{\epsilon}(\phi) |\nabla\phi| dx dy + \beta \int_{\Omega} g(\nabla I) H(\phi) dx dy \quad (4)$$

式中, $\lambda, \beta$  为大于 0 的常数,用于均衡长度和面积两项的影响。对能量  $E_{out}(\phi)$  最小化过程中,零水平集向加权长度  $L(\phi)$  最小化方向演化<sup>[7]</sup>,使得轮廓在演化过程中逐渐保持光滑;加权面积项  $A(\phi)$  的演化方向与  $\beta$  的符号有关,当  $\beta > 0$  时,向最小化方向演化,表现在曲线演化上就是向内收缩;当  $\beta < 0$  时,向最大化方向演化,表现在曲线演化上就是向外扩张,直到目标边缘处停止。

最小化泛函  $E_{Li}(\phi)$ , 得到驱动水平集演化的偏微分方程为

$$\frac{\partial \phi}{\partial t} = \mu \left[ \Delta \phi - \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right] + \lambda \delta_\varepsilon(\phi) \operatorname{div} \left[ g(\nabla I) \frac{\nabla \phi}{|\nabla \phi|} \right] + \beta \delta_\varepsilon(\phi) g(\nabla I) \quad (5)$$

式中,  $\delta_\varepsilon(\phi)$  为正则化的 Dirac 函数, 定义为

$$\delta_\varepsilon(\phi) = \begin{cases} \frac{1}{2\varepsilon} \left[ 1 + \cos\left(\frac{\pi\phi}{\varepsilon}\right) \right] & |\phi| \leq \varepsilon \\ 0 & |\phi| > \varepsilon \end{cases} \quad (6)$$

将该模型用于图像分割有以下几点不足:

1) 曲线的演化趋势是单一固定的。这就是说当初始化曲线跨越目标边界时, 将导致分割失败, 所以考虑到待分割目标的复杂背景问题, 初始化曲线一般要求位于待分割目标的内部。而在医学序列图像中, 相邻片中目标截面形状和位置的改变相对平缓, 如果将前一片的分割结果赋予相邻片, 则该曲线已位于目标周围, 这样的初始化曲线对于自动分割非常有利。但 Li 的方法由于无法实现曲线演化趋势的局部自适应, 因而无法实现序列自动分割。

2) 对弱边界及灰度分布不均匀目标分割不具有鲁棒性。停止函数  $g(\cdot)$  定义为

$$g(t) = (1 + t^2)^{-1}$$

式中,  $t$  为经高斯滤波后求得的图像梯度, 高斯滤波是一种被广泛采用的各向同性的扩散滤波方法, 它可以很好的平滑噪声, 但同时也破坏了图像中的重要边缘, 尤其是弱边缘信息; 而对于灰度分布不均匀的目标, 如肿瘤病灶等, 目标内部存在明显的误边界噪声, 容易造成错分割。

3) 虽然 Li 的方法避免了水平集的阶段性地重新初始化, 但其迭代速度依然是需要提高的, 尤其是用于分割大量的医学序列图像时, 实现序列图像的快速准确分割在医学辅助诊断方面是非常有用和必要的。

## 2 局部自适应主动轮廓模型

### 2.1 各向异性扩散滤波

相对于基于各向同性扩散高斯滤波的不足, 基于偏微分方程的各向异性扩散去噪方法可以实现去噪并同时保护边缘的目的, 这对于医学图像的预处理是有利的。

采用 Catté 等人<sup>[8]</sup>提出的改进 P-M 方程, 即 CLMC 模型进行滤波

$$\begin{cases} \frac{\partial I(x, y, t)}{\partial t} = \operatorname{div} [g(\nabla I_\sigma) \nabla I] \\ I_\sigma(x, y, t) = G_\sigma * I(x, y, t) \\ I(x, y, 0) = I_0(x, y) \end{cases} \quad (7)$$

式中,  $I_0(x, y)$  为原图像,  $\operatorname{div}$  为散度算子,  $\nabla$  为梯度算子。  $G_\sigma$  表示方差为  $\sigma$  的 Gaussian 函数。该模型在计算图像梯度之前, 先对图像做卷积, 这样可以有效地消除噪声, 尤其是在噪声比较强的情况下, 有助于更加准确地区分图像边界和噪声。这里的传导系数定义为

$$g(\nabla I_\sigma) = \frac{1}{1 + |\nabla I_\sigma| / K} \quad (8)$$

在图像平坦区域, 梯度较小,  $|\nabla I_\sigma| < K$ , 系数较大, 扩散增强, 图像被平滑; 在边缘区域, 梯度足够大以致  $|\nabla I_\sigma| > K$ , 系数较小, 扩散减弱, 即边缘锐化<sup>[9]</sup>, 从而实现了各向异性的扩散能力。这里的阈值  $K$  越大, 细节边缘越少, 梯度模值大的部分作为边缘保留, 梯度模值相对小的部分则被平滑滤除。

用该模型对脊椎 MRI 图像进行滤波, 参数设置为  $\sigma = 1.5$ ,  $K = 100$ ,  $\Delta t = 5$ , 迭代次数  $n = 2$ , 结果如图 1 所示。可以看出, 与高斯滤波相比, CLMC 可以更好的滤除噪声, 并保留重要边缘。



图 1 脊椎 MRI 滤波结果

Fig. 1 Filter results of spine MRI

### 2.2 局部演化趋势的自适应

在 Li 的方法中, 加权面积项系数  $\beta$  是常数, 限制了模型演化趋势的自适应性。文献[7]中提出了一种可变系数, 定义为  $c \cdot \operatorname{sgn}(\Delta G_\sigma \times I) |\nabla G_\sigma \times I|$ 。文献[7]中采用高斯滤波, 由图像梯度决定系数的大小。但考虑到高斯滤波的缺陷, 又由于梯度较大的区域一般被视为边界处理, 曲线在演化到该处时速度会收敛到 0, 因而对该系数的大小影响不大。本文重新定义该系数, 如式(9)所示, 此处  $\beta$  为变量。

$$\beta = c \cdot \operatorname{sgn}(\Delta I_c) \quad (9)$$

式中,  $I_c$  为各向异性扩散预处理后的图像,  $\Delta$  为 Laplace 算子,  $c > 0$  为常数, 用于均衡该项影响。

这里利用 2 阶导数在图像边界处的性质<sup>[9]</sup>, 即图像位于目标边界两侧的 2 阶导数符号是相反的。由此可以分析, 主动轮廓位于目标内的部分,  $\Delta I_c < 0$ , 故  $\beta < 0$ , 驱动主动轮廓向外扩张演化; 反之, 主动轮廓位

于目标外的部分,  $\Delta I_c > 0$ , 故  $\beta > 0$ , 驱动主动轮廓向内收缩演化。这样, 曲线上各点的演化趋势完全由其局部特性决定, 因而对初始化曲线跨越待分割目标边界的情况更加鲁棒, 有利于实现序列图像承前启后的自动分割。

### 2.3 局部 C-V 影响项

与基于边缘的分割方法不同, C-V 模型<sup>[10]</sup>是完全基于像素灰度的分割方法, 在全局寻找合适的边缘轮廓, 使得轮廓内、外的灰度值相差最大, 是全局最优的分割方法。能量泛函(这里为了方便讨论, 仅考虑灰度项, 忽略长度项)

$$E_{cv}(\phi) = \lambda_1 \int_{\Omega} (I - c_1)^2 H_{\varepsilon}(\phi) dx dy + \lambda_2 \int_{\Omega} (I - c_2)^2 (1 - H_{\varepsilon}(\phi)) dx dy \quad (10)$$

式中,  $c_1, c_2$  分别为区域  $\Omega$  内部、外部的灰度平均值, 最小化  $E_{cv}(\phi)$ , 得到驱动水平集演化的偏微分方程为

$$\frac{\partial \phi}{\partial t} = \delta_{\varepsilon}(\phi) [-\lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2] \quad (11)$$

C-V 模型可以很好地解决目标与背景灰度存在一定差异的图像分割问题, 但是对于灰度相差不大或存在灰度分布重叠的情况, 很难将目标分割开来, 尤其是应用于分割医学图像时, 如图 2 中的肿瘤 MRI, 由于肿瘤与周边皮下脂肪组织的灰度非常相近, C-V 模型无法将其区分开来。




图 2 C-V 模型对骨肿瘤分割结果

Fig. 2 Segmentation result of bone tumour using C-V model

但相比 Li 的方法, C-V 模型有分割速度上的优势, 收敛速度快, 且综合了全局灰度信息, 可以弥补几何主动轮廓模型在分割速度及对灰度分布不均弱边界处理方面的不足。所以这里考虑将 GAC 方法中的局部思想引入 C-V 模型, 将 C-V 模型演化偏微分方程改写为

$$\frac{\partial \phi}{\partial t} = \delta_a(\phi) [-\lambda_1 (I - c_1)^2 + \lambda_2 (I - c_2)^2] \quad (12)$$

式中

$$\delta_a(\phi) = \begin{cases} \frac{\varepsilon}{\pi \varepsilon^2 + \phi^2} & |\phi| \leq a \\ 0 & |\phi| > a \end{cases} \quad (13)$$

此处将 C-V 的作用范围限制在  $[-a, a]$  之间, 即全局灰度信息在零水平集内、外  $a$  距离内对水平集的演化起作用, 相当于仅在待分割目标周围小范围内作用。该项的作用在于:

1) 对于不同组织灰度分布存在重叠的情况, 该项的加入既利用了全局信息, 又避免了将背景中有相似灰度分布的其他组织误分为目标。

2) 对于待分割目标存在灰度分布不均匀或弱边界的情况(如正常的组织结构或病灶), 基于梯度的分割容易出现误分割或边界泄漏, 而从全局的角度进行灰度约束可以较好的解决该问题, 避免陷入局部最优。

### 2.4 局部自适应主动轮廓模型

综上所述, 给出本文用于图像分割的局部自适应主动轮廓模型, 能量泛函为

$$E(\phi) = \mu E_m(\phi) + \lambda L(\phi) + \beta A(\phi) + \alpha E_{cv}(\phi) = \mu \int_{\Omega} \frac{1}{2} (|\nabla \phi| - 1)^2 dx dy + \lambda \int_{\Omega} g(\nabla I_c) \delta_{\varepsilon}(\phi) |\nabla \phi| dx dy + \beta \int_{\Omega} g(\nabla I_c) H(\phi) dx dy + \alpha (\lambda_1 \int_{\Omega} (I_c - c_1)^2 H_{\varepsilon}(\phi) dx dy + \lambda_2 \int_{\Omega} (I_c - c_2)^2 (1 - H_{\varepsilon}(\phi)) dx dy) \quad (14)$$

补偿能量项用于保持距离符号函数, 加权长度项保证曲线在向边界演化的过程中逐渐光滑, 加权面积项自适应曲线演化趋势, 局部 C-V 项用于加快曲线收敛, 对于灰度分布存在重叠、分布不均匀及弱边界更鲁棒, 一般取  $\lambda_1 = \lambda_2 = 1$ 。

故最小化能量  $E(\phi)$ , 得到水平集演化的驱动偏微分方程为

$$\frac{\partial \phi}{\partial t} = \mu \left[ \Delta \phi - \operatorname{div} \left( \frac{\nabla \phi}{|\nabla \phi|} \right) \right] + \lambda \delta_{\varepsilon}(\phi) \operatorname{div} \left[ g(\nabla I_c) \frac{\nabla \phi}{|\nabla \phi|} \right] + \beta \delta_{\varepsilon}(\phi) g(\nabla I_c) + \alpha \delta_a(\phi) [- (I_c - c_1)^2 + (I_c - c_2)^2] \quad (15)$$

式中:  $I_c$  为各向异性扩散预处理后的图像,  $\operatorname{div}$  为散度算子,  $\Delta$  为拉普拉斯算子,  $\nabla$  为梯度算子;  $\mu, \lambda, \alpha$  为正常数,  $\beta$  为曲线演化自适应项系数;  $H_{\varepsilon}(\phi)$ 、 $\delta_{\varepsilon}(\phi)$  分别为正则化的 Heaviside 函数和 Delta 函数, 定义为

$$\begin{cases} H_\varepsilon(\phi) = \frac{1}{2} \left[ 1 + \frac{2}{\pi} \arctan\left(\frac{\phi}{\varepsilon}\right) \right] \\ \delta_\varepsilon(\phi) = \begin{cases} \frac{\varepsilon}{\pi} \frac{1}{\varepsilon^2 + \phi^2} & |\phi| \leq \varepsilon \\ 0 & |\phi| > \varepsilon \end{cases} \end{cases} \quad (16)$$

$c_1, c_2$  定义为

$$\begin{cases} c_1 = \frac{\int_{\Omega} I_c(x, y) H_\varepsilon(\phi(x, y)) dx dy}{\int_{\Omega} H_\varepsilon(\phi(x, y)) dx dy} \\ c_2 = \frac{\int_{\Omega} I_c(x, y) (1 - H_\varepsilon(\phi(x, y))) dx dy}{\int_{\Omega} (1 - H_\varepsilon(\phi(x, y))) dx dy} \end{cases} \quad (17)$$

$g(\cdot)$  为边界停止函数定义为

$$g = (1 + |\nabla I_c / s|^2)^{-1} \quad (18)$$

式中,  $s$  为大于或等于 1 的正常数, 对因分布不均匀产生的突变弱边界,  $|\nabla I_c / s|^2$  接近于 0,  $g$  逼近 1, 曲线继续演化; 而对经预处理后增强的目标边界, 梯度值越大,  $|\nabla I_c / s|^2$  值增大,  $g$  减小, 曲线演化受阻。故对于存在明显灰度不均匀的待分割目标, 将  $s$  值设置为大于 1 的常数, 否则设置为 1。这样设置, 水平集在演化过程中可以跳过目标内部因灰度分布不均匀而造成的突变弱边界, 避免误分割; 对初始化曲线周围非目标边界的其他弱边界, 也有抗干扰作用。

### 3 医学序列图像的分割

在医学序列图像中, 目标组织或病灶在相邻片中的形状和位置变化平缓, 所以利用本文的方法可以实现承前启后的序列图像自动分割。利用前一片图像的分割结果, 将其投射到当前片图像, 作为初始化曲线。

进行投射之前, 首先要利用  $H(\phi)$  函数将初始化水平集函数重新定义成分段常量的函数。 $H(\phi)$  在演化过程中会保持为与 0 或 1 相近的值, 对  $H(\phi)$  就近取整到 0 或 1, 可得到新的初始化水平集函数为

$$\phi = \begin{cases} -d & H(\phi(x, y)) = 0 \\ 0 & (x, y) \in \partial\Omega \\ +d & H(\phi(x, y)) = 1 \end{cases} \quad (19)$$

由于在迭代过程中, 补偿项能量项只可以保证在零水平集附近将一个分段常量函数逐渐演变为一个有符号的距离函数, 而在远离零水平集的部分, 会出现尖锐或平滑的情况, 已经不再符合符号距离函数的要求, 如果直接将这样的水平集函数作为后续迭代的初始化, 将会严重影响迭代的收敛速度和偏微分方程

解的稳定性。故本文提出利用当前的  $H(\phi)$  将水平集函数重新定义成分段常量函数。这样既能保证水平集在迭代过程中演化为符号距离函数, 又可以加快收敛速度。有利于序列图像的快速分割。

### 4 实验结果与分析

对背景复杂, 存在灰度分布重叠、目标灰度分布不均匀且存在弱边界的膝关节股骨和 大腿骨肿瘤 MRI 进行实验。先对单幅图像进行分割, 验证目标曲线能够根据当前图像局部特征完成自适应演化, 对复杂的分布有较好的鲁棒性; 然后对整套膝关节股骨和 大腿骨肿瘤的序列图像实现自动分割。

分割前, 进行各向异性扩散预处理, 参数设置为  $\sigma = 1.5, K = 100, \Delta t = 5$ , 迭代次数  $n = 2$ 。

与 Li 的方法作对比, 使用相同的初始化曲线和参数设置。  $d = 3, \varepsilon = 1, \Delta t = 5$ , 补偿能量项  $\mu = 0.2 / \Delta t$ , 长度项  $\lambda = 8$ , 面积项参数取值范围一般为  $[1, 5]$ , 本文方法中取  $c = 2$ , Li 的方法中, 若曲线向内演化面积项系数  $c = 2$ , 向外演化则  $c = -2$ 。由于 C-V 模型的迭代时间步长较小, 一般设为 0.1, 本文中衡量各项的作用将局部 C-V 项系数设置为  $\alpha = 0.05$ 。算法平台为 MATLAB 2007, Core2 CPU, 1 GB 内存。

#### 实验 1 曲线演化趋势自适应性

对膝关节 MRI 图像进行实验, 初始化曲线设置为跨越待分割目标边界的闭合曲线, 方程为

$$\phi_0 = \sqrt{(x - 135)^2 + (y - 200)^2} - 80$$

由于目标没有明显的灰度不均匀, 故本文方法中边界停止函数中参数  $s = 1$ 。 Li 的方法分别向内、向外进行演化实验, 均迭代 100 次。

从图 3 的分割结果中可以看出: 当初始化曲线




图 3 膝关节 MRI 分割结果

Fig. 3 Segmentation results of knee MRI

跨越目标边界时, Li 的方法由于无法实现演化趋势的自适应, 因此不能完成分割; 而本文方法可以较好地解决该问题, 在分割效果上显然优于 Li 的方法; 本文方法在迭代 20 次时已经很好地找到了目标边界, 迭代 40 次时完成分割, 继续迭代也可以保持分割的稳定性。

实验 2 对灰度分布重叠、分布不均匀及目标弱边界的鲁棒性

图 4 为大腿骨肿瘤 MRI 的分割, 分别与 Li 的方法及 C-V 模型作对比, 初始化曲线位于目标区域内部

$$\phi_0 = \sqrt{(x - 130)^2 + (y - 155)^2} - 45$$

由于目标存在明显的灰度不均匀, 故本文方法中边界停止函数的参数  $s = 200$ 。




图 4 骨肿瘤 MRI 分割结果

Fig. 4 Segmentation results of bone tumour MRI

为了更好地说明, 这里采用递进式的实验。

图 4(b) 为 Li 方法的分割结果, 由于肿瘤内部存在灰度不均匀现象, 误将肿瘤内部的灰度不均匀

部分当成边界处理, 造成错分割, 迭代 500 次也没有完成分割。图(c)一(e)为本文方法, 其中图(c)不使用局部 C-V 项, 即  $\alpha = 0$ , 图(d)(e)中  $\alpha = 0.05$ 。由分割结果可以看出, 使用本文给出的边界停止函数可以很好地避免目标内部的错分割, 但对于目标正确的弱边界仍然不具有很好的鲁棒性, 如图(c)所示, 进行多次迭代就会出现边界泄漏情况。而局部 C-V 项的加入(如图(d)(e)所示), 对目标灰度不均匀及弱边界都有较好的鲁棒性, 演化曲线在目标周围迭代速度快, 多次迭代稳定性好。

与 2.3 节中图 2 的 C-V 模型分割结果相比, 显然本文方法可以解决灰度分布存在重叠的问题, 避免了将灰度分布相近的皮下脂肪误分为肿瘤目标。

### 实验 3 医学序列图像的自动分割

对大腿骨肿瘤和膝关节 MRI 序列进行自动分割, 经实验分析, 将肿瘤序列局部 C-V 项作用范围的  $a$  设为 0.05, 膝关节序列  $a$  设为 1。分割结果如图 5, 6 所示(仅给出部分序列), 其中第 1 行为初始化, 第 2 行为分割结果。

从实验结果可以看出, 本文的方法对于分割目标在序列图像中的形状和位置的变化具有较好的鲁棒性, 曲线演化趋势的自适应以及局部 C-V 能量项的约束, 使得前一幅的分割结果可以得到充分的利用, 在保证分割准确度的同时提高了分割速度, 实现了序列图像的快速自动分割。

为了更好地比较, 对图 5 中所示的骨肿瘤 MRI 序列(共 18 幅列出 5 幅), 分别用 Li 的方法与本文方法进行实验。由于 Li 的方法无法实现曲线演化趋势的自适应, 固对每幅图像均进行手动设置初始化曲线, 首幅图的初始化曲线两者相同。平均每幅




图 5 骨肿瘤 MRI 序列图像分割

Fig. 5 Segmentation results of serial bone tumour MRIs




图 6 膝关节 MRI 序列图像分割

Fig. 6 Segmentation results of serial knee MRIs

图像的迭代次数、耗时及总耗时对比如表 1 所示。可见,本文的方法明显快于 Li 的方法。

表 1 迭代耗时对比

Tab. 1 Compare of iteration time

方法	单幅迭代次数	单幅耗时/s	总耗时/s
Li 方法	500	122	2 196
本文方法	首幅:80	首幅:25	331
	其他序列:50	其他序列:18	

## 5 结 论

给出一种用于目标快速分割的局部主动轮廓模型。该模型给出了曲线演化趋势的自适应算法,能较好的解决初始化曲线跨越目标边界的分割问题;同时加入局部 C-V 能量,改进停止函数,使模型对灰度分布存在重叠、目标灰度分布不均匀及对存在弱边界的情况有较好的鲁棒性。利用待分割目标的截面形状和位置在序列图像的相邻片间变化平缓这一自明先验知识,结合本文提出算法,实现序列目标的快速分割。本文算法中局部 C-V 项的作用范围是经过实验分析确定的,对于某一序列是实验固定值,如何实现作用范围的自适应将是下一步工作的研究内容。

## 参考文献 (References)

[ 1 ] Osher S, Sethian J A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton-Jacobi formulations [ J ]. Journal of Computational Physics, 1988, 79 ( 1 ): 12-49.

[ 2 ] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: a new variational formulation [ C ] // Conference on Computer Vision and Pattern Recognition. Los Angeles: IEEE Computer Society, 2005: 430-436.

[ 3 ] Wang Bin, Gao Xinbo. Automatic image segmentation using sequential level set method [ J ]. Journal of Software, 2009, 20 ( 5 ): 1185-1193. [ 王斌, 高新波. 基于水平集接力的图像自动分割方法 [ J ]. 软件学报, 2009, 20 ( 5 ): 1185-1193. ]

[ 4 ] He Ning, Zhang Peng. Variational level set image segmentation method based on boundary and region information [ J ]. Acta Electronica Sinica, 2009, 37 ( 10 ): 2215-2219. [ 何宁, 张朋. 基于边缘和区域信息相结合的变分水平集图像分割方法 [ J ]. 电子学报, 2009, 37 ( 10 ): 2215-2219. ]

[ 5 ] Wen Tiexiang, Yang Feng. A new image segmentation algorithm based on hybrid curve evolution model [ J ]. Journal of Circuits and Systems, 2007, 12 ( 4 ): 48-52. [ 温铁祥, 杨丰. 一种新的曲线演化混合模型图像分割算法 [ J ]. 电路与系统学报, 2007, 12 ( 4 ): 48-52. ]

[ 6 ] Sun Xiaohuan, Yang Feng, Zhao Qiyang. Improved hierarchical multiphase image segmentation model and its fast implementation [ J ]. Journal of Data Acquisition & Processing, 2010, 25 ( 1 ): 44-49. [ 孙晓欢, 杨丰, 赵祺阳. 改进的分级多相图像分割模型及其快速实现 [ J ]. 数据采集与处理, 2010, 25 ( 1 ): 44-49. ]

[ 7 ] He Chuanjiang, Li Meng, Zhan Yi. Adaptive distance preserving level set evolution for image segmentation [ J ]. Journal of Software, 2008, 19 ( 12 ): 3161-3169. [ 何传江, 李梦, 詹毅. 用于图像分割的自适应距离保持水平集演化 [ J ]. 软件学报, 2008, 19 ( 12 ): 3161-3169. ]

[ 8 ] Catté F, Lions P L, Morel J M, et al. Image selective smoothing and edge detection by nonlinear diffusion [ J ]. SIAM Journal on Numerical Analysis, 1992, 29 ( 1 ): 182-193.

[ 9 ] Wang Dakai, Hou Yuqing, Peng Jinye. Partial Differential Equation Methods in Image Processing [ M ]. Beijing: Science Press, 2008: 113-115. [ 王大凯, 侯榆青, 彭进业. 图像处理的偏微分方程方法 [ M ]. 北京: 科学出版社, 2008: 113-115. ]

[ 10 ] Chan T, Vese L. Active contours without edges [ J ]. IEEE Transactions on Image Processing, 2001, 10 ( 2 ): 266-277.