

# 引入局部全局信息的区域自适应 局域化快速活动轮廓模型

廖祥云 袁志勇 郑 奇 童倩倩 赖虔葑 张贵安

(武汉大学计算机学院 武汉 430072)

**摘 要** 针对 HIFU 超声图像中子宫肌瘤的分割难题, 该文提出了一种准确高效的引入局部全局信息的区域自适应局域化快速活动轮廓模型. 该模型引入了图像的局部全局信息形成局部全局力, 并依据演化曲线上各点周围的灰度分布均匀程度动态地决定图像的局部全局信息和形状约束信息的使用范围, 克服了 HIFU 子宫肌瘤超声图像分割中的初始化轮廓敏感性问题. 该模型通过利用该灰度分布信息自适应地改变局域区域的半径大小, 进而在活动轮廓曲线演化过程中动态地调整局域化区域范围, 提高了分割的准确性及曲线的演化效率. 最后在演化曲线上通过使用同一局部区域计算相邻像素的局域作用力, 进一步提高了分割效率, 最终实现了 HIFU 子宫肌瘤超声图像的准确高效分割. 实验结果表明: 该文方法克服了 HIFU 子宫肌瘤超声图像分割的难题, 相较于最近提出的 MSLCV 模型, 获得了更准确高效的分割结果, 且平均计算效率提高了 84.6%.

**关键词** HIFU 子宫肌瘤超声图像分割; 活动轮廓模型; 局部全局信息; 自适应局域化; MSLCV 模型; 水平集  
**中图法分类号** TP391 **DOI 号** 10.11897/SP.J.1016.2016.01464

## Adaptive Localized Region-Based Fast Active Contour Model by Introducing Global Information in Local Region

LIAO Xiang-Yun YUAN Zhi-Yong ZHENG Qi TONG Qian-Qian  
LAI Qian-Feng ZHANG Gui-An

(School of Computer, Wuhan University, Wuhan 430072)

**Abstract** To solve the problems in segmenting HIFU (High Intensity Focused Ultrasound) ultrasound image of uterine fibroids, we propose an adaptive localized region-based fast active contour model by introducing HIFU image's global information in local region, which is more accurate as well as more efficient. The proposed segmenting model incorporates HIFU ultrasound image's global information in local region to form a locally global force. Meanwhile the gray level distribution uniformity around each pixel point on the evolution curve is calculated to dynamically determine the various application condition of HIFU image's global information in local region and the shape constrained information of the uterine fibroids in HIFU images, which is assigned to overcome the sensitivity of the initialized contour by applying the locally global force when segmenting HIFU ultrasound image of uterine fibroids. By using the calculated gray level distribution uniformity around each pixel point on the evolution curve, the adaptive localized region-based fast

收稿日期: 2015-01-31; 在线出版日期: 2015-11-17. 本课题得到国家自然科学基金(61373107)、国家“九七三”重点基础研究发展规划项目基金(2011CB707904)、北航虚拟现实技术与系统国家重点实验室开放课题基金(BUAA-VR-13KF-15)资助. 廖祥云, 男, 1989 年生, 博士, 中国计算机学会(CCF)学生会会员, 主要研究方向为图像处理、计算机仿真与虚拟现实. E-mail: xiangyun-l@163.com. 袁志勇(通信作者), 男, 1963 年生, 博士, 教授, 博士生导师, 中国计算机学会(CCF)高级会员, 主要研究领域为计算机仿真与虚拟现实、图像处理与计算机视觉、机器学习与模式识别. E-mail: zhiyongyuan@whu.edu.cn. 郑 奇, 男, 1990 年生, 硕士, 主要研究方向为图像处理. 童倩倩, 女, 1989 年生, 硕士研究生, 主要研究方向为嵌入式系统与图形图像. 赖虔葑, 男, 1991 年生, 硕士, 主要研究方向为计算机图形学. 张贵安, 男, 1985 年生, 博士, 主要研究方向为嵌入式系统与图形图像.

active contour model adaptively changes the local radius of the localized region, and then dynamically adjusts the size of localized region during the evolution process of the active contour curve, achieving more accurate and more efficient segmentation results of HIFU ultrasound image of uterine fibroids. By applying the same localized region to calculate the local forces of adjacent pixel points on the evolution curve, our method further improves the segmentation efficiency, finally achieving accurate and efficient segmentation of HIFU ultrasound image of uterine fibroids. The experimental results show that compared with recently proposed MSLCV (Multi-scale and Shape Constrained Localized C-V) model, our method solves the problems in segmenting HIFU ultrasound image of uterine fibroids as well as improves the segmentation accuracy and increases the average segmentation efficient by 84.6%.

**Keywords** segmentation of HIFU uterine fibroids ultrasound images; active contour model; global information in local region; adaptive localized region; MSLCV model; level set

## 1 引言

高强度超声聚焦(High Intensity Focused Ultrasound, HIFU)技术是一种从体外将超声波聚焦于肿瘤靶区组织,利用超声波的组织穿透性和能量沉积性达到治疗目的的新型微创手术技术.由于其所具有的不开刀和安全性特征,目前已广泛应用于女性子宫肌瘤的治疗<sup>[1-3]</sup>.然而在超声引导的 HIFU 手术过程中需要医生手工对肿瘤区域进行定位和引导,该过程非常耗时,增加了患者的痛苦.而通过图像分割技术实现肿瘤靶区的准确高效分割,将极大地提高手术治疗效率,减轻患者痛苦.由于超声图像具有低信噪比、多噪声及灰度分布不均匀的特点,其分割一直是图像分割领域的难题,而 HIFU 超声图像由于治疗中水介质的干扰,具有严重的低信噪比、低对比度、弱边界及灰度分布非均匀的特点,普通的分割模型难以取得良好的分割效果,因此亟待提出一种准确高效的 HIFU 超声图像分割方法.

活动轮廓模型是近年来较热门的一种基于能量的分割模型,其通过最小化能量泛函驱使活动轮廓曲线朝着能量降低的方向演化以达到目标边界.由于活动轮廓模型具有良好的封闭性以及平滑性,该模型已被许多研究学者应用到医学图像分割领域中,并取得了较好的分割效果<sup>[4-6]</sup>.活动轮廓模型最先由 Kass 等人<sup>[7]</sup>提出,其后按照其所依赖分割信息的不同,主要可以分为两类:基于边缘的模型<sup>[7-9]</sup>和基于区域的模型<sup>[10-13]</sup>.基于边缘的活动轮廓模型利用图像的梯度信息形成一种基于图像的力以驱使轮

廓曲线向目标边界运动,对于有清晰边界的目标有较好的分割效果. Lorigo 等人<sup>[14]</sup>基于 GAC(Geodesic Active Coutours, GAC)<sup>[8]</sup>模型提出了 CURVES 算法,解决了三维影像中复杂曲线结构的自动分割问题,并在磁共振血管成像中的血管分割中取得了良好的分割效果.但由于在基于边缘的模型中,梯度信息是一种高度局域化的图像信息,导致该模型有两个主要缺点:对图像噪声敏感和对初始化轮廓敏感<sup>[15]</sup>.将该模型应用于超声图像的分割中,极易产生边界泄露的问题.基于区域的活动轮廓模型则是利用前景和背景区域的统计信息形成驱动力以驱使轮廓曲线向目标边界运动,适用于图像各区域灰度分布均匀的分割任务中.其中最著名的方法是由 Chan 和 Vese<sup>[11]</sup>提出的分段常数模型,即 C-V 模型,该类模型能有效地分割含噪声和弱边界的图像,但由于该类模型大都假定图像中各区域灰度是均匀分布的,并采用全局的统计信息,对于灰度分布不均匀的图像容易产生错误的分割结果.为克服基于区域的活动轮廓难以分割灰度分布非均匀目标的缺点,近年来研究者进行了基于区域的局域化研究,提出了许多新的利用局域信息的活动轮廓模型. Li 等人<sup>[16]</sup>提出通过引入一个核函数在变分水平集框架中来定义局域二元拟合能量,从而嵌入局域的灰度信息到基于区域的活动轮廓模型中.之后, Li 等人<sup>[13]</sup>又在其此基础上深入研究了核函数的选择依据和局域区域范围大小的选择及其作用. Lankton 等人<sup>[15]</sup>提出了一个局域化框架,将利用全局区域统计信息的能量泛函重新改写为利用局部区域统计信息的局域化形式,并分析了局域半径大小对分割的

影响. Wang 等人<sup>[17]</sup>提出了结合全局信息和局域信息的基于区域的灰度拟合能量模型,将利用局域信息的 LBF 模型和利用全局信息的 C-V 模型混合在一起作用于曲线的演化,且二者间的权重需要根据图像的非均匀程度人为选择. Tian 等人<sup>[18]</sup>提出使用混合的高斯分布模型描述脑血管和背景的分布,采用血管向量场建模血管形状信息并提出了轮廓自动初始化方法,将血管形状信息嵌入到活动轮廓模型中,从三维时间飞跃磁共振血管成像数据中准确地提取了 3D 大脑树. 解立志等人<sup>[19]</sup>结合区域增长方法提出了局部自适应 C-V 模型,将其应用于脑血管的分割并取得了较为精确的分割结果. 王斌等人<sup>[20]</sup>将图像的区域信息融入基于边缘的水平集方法中,并与形状先验信息相结合,能够较好地完成被遮盖目标的分割. 这些模型都引入了局域信息,对灰度非均匀的图像有较好的分割能力,但对于分割具有严重的低信噪比、低对比度、弱边界及灰度分布非均匀特征的 HIFU 子宫肌瘤超声图像依然有所欠缺,易出现边界泄露或过度收缩的错误分割结果. 为解决 HIFU 超声图像的分割问题, Liao 等人<sup>[21]</sup>提出了一种引入多尺度算法和形状约束信息的局域化区域活动轮廓模型(Multi-scale and Shape constrained Localized C-V, MSLCV),该模型采用多尺度算法提高分割效率,通过引入形状约束信息提高分割的准确性,取得了较准确高效的分割结果,但由于该模型是基于局域化区域活动轮廓模型的,计算量仍较大,依然难以满足手术过程中快速分割需求;并且该模型对初始化要求较高,而形状约束的引入导致其具有较高的初始化敏感性.

针对 MSLCV 模型的不足,本文在其基础上提出一种新的更准确高效的 HIFU 子宫肌瘤超声图像分割模型. 首先,我们引入局部全局信息,通过判断演化曲线上各点周围的灰度分布均匀程度决定局部全局信息和形状约束信息的使用范围,以克服初始化轮廓敏感性;其次,利用该灰度分布信息自适应地改变局域区域半径大小,进而在活动轮廓曲线演化过程中动态地调整局域化区域范围以提高分割准确性和曲线演化效率;最后,通过优化局域区域作用力的计算更好地提升了分割效率,实现了更高效的分割.

本文第 2 节为方法描述,首先介绍 MSLCV 模型及其实现方法,然后提出本文方法,即引入局部全局信息的区域自适应局域化快速活动轮廓模型;第 3 节为实验,将本文方法与其他模型进行了对比分析;第 4 节为总结.

## 2 方 法

### 2.1 MSLCV 模型介绍

#### 2.1.1 区域局域化

为克服基于区域的全局活动轮廓模型(如 C-V 模型)难以较好分割非均匀灰度图像的问题, Lankton 等人<sup>[15]</sup>提出了 LCV(Localized C-V, LCV)模型,即基于区域活动轮廓模型,将全局能量式重新改写成局域化的形式,从而利用局域信息更加准确有效地分割非均匀灰度图像. 其基本思想是以曲线上的每一个点为单位独自计算其局域能量,为了优化这些局域能量,每个点都单独考虑,并且朝着由其局域区域所计算的能量最小化方向移动,而每个点的局域区域被演化曲线划分为局域内部和局域外部. 然后通过对每一个局域区域拟合模型进行能量优化. 为了定义曲线上每个点的局域区域,定义一个特征函数如下:

$$B(x, y) = \begin{cases} 1, & \|x - y\| < r \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中:  $x, y \in \Omega$ , 作为独立的空间变量各自代表一个点,  $r$  为局域半径. 当点  $y$  在以点  $x$  为中心, 半径大小为  $r$  的圆内时, 该函数值为 1, 否则为 0.

根据特征函数  $B(x, y)$  可求出曲线上点  $x$  的局域区域内部和外部的均值强度  $c_{x_1}, c_{x_2}$ <sup>[15]</sup> 如下:

$$c_{x_1} = \frac{\int_{\Omega_y} B(x, y) \cdot H(\phi(y)) \cdot I(y) dy}{\int_{\Omega_y} B(x, y) \cdot H(\phi(y)) dy} \quad (2)$$

$$c_{x_2} = \frac{\int_{\Omega_y} B(x, y) \cdot (1 - H(\phi(y))) \cdot I(y) dy}{\int_{\Omega_y} B(x, y) \cdot (1 - H(\phi(y))) dy} \quad (3)$$

其中:  $\phi(y)$  是水平集函数;  $H(\phi)$  是 Heaviside 函数. 将该局域化框架应用到 C-V 模型中, 获得总能量函数及轮廓曲线上点  $x$  的水平集演化方程:

$$E^{\text{LCV}}(\phi) = \int_{\Omega_x} \delta(\phi(x)) \int_{\Omega_y} B(x, y) \cdot F_{\text{region}}(I(y), \phi(y)) dy dx + \mu \int_{\Omega_x} \delta(\phi(x)) \|\nabla \phi(x)\| dx \quad (4)$$

$$\frac{\partial \phi}{\partial t}(x) = \delta(\phi(x)) \left[ \int_{\Omega_y} B(x, y) \delta(\phi(y)) \cdot ((I(y) - c_{x_1})^2 - (I(y) - c_{x_2})^2) dy + \mu \text{div} \left( \frac{\nabla \phi(x)}{\|\nabla \phi(x)\|} \right) \right] \quad (5)$$

其中

$$F_{\text{region}} = H(\phi(y))(I(y) - c_{x_1})^2 + (1 - H(\phi(y)))(I(y) - c_{x_2})^2 \quad (6)$$

其中:  $F_{\text{region}}$  表示基于区域的驱动力;  $\delta(\varphi)$  是 Dirac 函数; 参数  $\mu$  表示弧长项的权值, 决定着曲线的平滑性.  $x$  为图像全局区域的一个像素点,  $y$  是以  $x$  为中心半径为  $r$  的局域区域内的一个像素点. 在该局域化方程中, 当曲线上每个点使其所对应的局域内部和外部是局域均值  $c_{x_1}, c_{x_2}$  的最优估计时, 获得能量最小化.

LCV 模型可较好地处理非均匀灰度图像, 由于局域化的特点, LCV 模型具有初始化轮廓敏感性较强的缺陷, 无法准确地分割低对比度、弱边界的 HIFU 超声图像. 因为需要对演化曲线上每一个点计算局域区域, 导致其计算量大且曲线演化速度缓慢. 同时, 若局域区域半径选取不当, 容易陷入局部最小值而产生错误分割结果.

### 2.1.2 形状约束

Liao 等人<sup>[21]</sup> 在 LCV 基础上, 提出了一种引入多尺度算法和形状约束信息的局域化区域活动轮廓模型 MSLCV, 通过在局域化的基于区域活动轮廓模型 LCV 中引入新的形状约束, 使得 MSLCV 模型可以处理低对比度、弱边界的 HIFU 超声图像, 即使图像中部分信息丢失, 也可以将目标准确分割. MSLCV 模型利用初始化轮廓形成一个简单有效的形状约束, 以减少分割过程中出现边界泄露或过度收缩问题, 并将该形状约束嵌入到基于区域活动轮廓模型的水平集框架中. 其基本思想是在以曲线上的每一个点为单位独自地计算其局域能量时, 加入形状约束能量, 该形状约束能量通过该点与初始轮廓最近距离的函数计算获得, 总能量函数为

$$E^{\text{MSLCV}}(\phi) = \int_{\Omega_x} \delta(\phi(x)) \int_{\Omega_y} B(x, y) \cdot F_{\text{region}}(I(y), \phi(y)) dy dx + \mu \int_{\Omega_x} \delta(\phi(x)) \|\nabla \phi(x)\| dx + \beta \int_{\Omega_x} \delta(\phi(x)) \cdot F_{\text{shape}} dx \quad (7)$$

其中

$$F_{\text{shape}} = \text{sign}(\phi_0(x)) \|p_x - p_{\min}\|^2 \quad (8)$$

$$\text{sign}(\phi_0(x)) = \begin{cases} 1, & \phi_0(x) > 0 \\ -1, & \phi_0(x) < 0 \\ 0, & \phi_0(x) = 0 \end{cases} \quad (9)$$

其中:  $p_x$  是当前轮廓上点  $x$  在图像中的位置;  $p_{\min}$  是

初始轮廓  $C_0$  上到点  $x$  的最近的点的位置.  $\phi_0(x)$  是初始轮廓  $C_0$  的水平集函数, 参数  $\beta$  为非负常量, 决定着形状约束力的大小,  $\text{sign}(\phi_0(x))$  函数为形状约束力的方向判断函数, 其始终指向初始轮廓. 在 MSLCV 模型中, 除了第 1 项数据拟合项和第 2 项弧长项外, 引入了第 3 项形状约束项, 用来形成演化曲线在演化过程中朝向初始轮廓方向的作用力.

通过最小化式(7)中的能量泛函, 求得相应的水平集演化方程如下:

$$\frac{\partial \phi}{\partial t}(x) = \delta(\phi(x)) \left[ \int_{\Omega_y} B(x, y) \delta(\phi(y)) \cdot ((I(y) - c_{x_1})^2 - (I(y) - c_{x_2})^2) dy + \mu \text{div} \left( \frac{\nabla \phi(x)}{\|\nabla \phi(x)\|} \right) + \beta \text{sign}(\phi_0(x)) \|p_x - p_{\min}\|^2 \right] \quad (10)$$

式(7)和式(10)中参数  $\beta$  的大小决定着形状约束在分割中所起到的作用力, 当其很大时, 初始轮廓几乎不会演化; 当其很小时, 则退化为无形约束. 可以根据所分割图像的质量选择参数  $\beta$  的大小. 由于形状约束的引入, MSLCV 模型有效解决了边界泄露或过度收缩的问题, 但同时也使其分割结果更依赖于初始化轮廓的好坏, 增加了其初始化敏感性.

### 2.1.3 多尺度分割

为了克服局域化的基于区域活动轮廓模型计算量大、分割时间长的缺陷, MSLCV 模型<sup>[21]</sup> 将多尺度思想引入到水平集曲线演化过程中, 有效地减少了计算时间, 提高了分割效率. MSLCV 模型使用一个二层的高斯金字塔, 其基本思想是在曲线演化过程中, 不直接利用原始大小的图像进行曲线演化, 而是首先对超声图像进行高斯金字塔分解, 然后在粗尺度图像上先进行粗分割, 将得到的粗分割结果作为细尺度图像上的初始轮廓进行细分割, 逐步进行轮廓优化, 最终实现图像分割.

## 2.2 本文方法

传统的 C-V<sup>[11]</sup> 模型由于利用图像的全局信息形成全局作用力, 对初始化轮廓敏感性较弱, 但对于全局灰度分布的均匀性要求较高. 而 MSLCV 模型<sup>[21]</sup> 由于使用了局域化信息和形状约束信息, 具有计算量较大及初始化敏感性较强的缺陷. 本文在 MSLCV 模型<sup>[21]</sup> 的研究工作基础上, 提出引入局部全局信息的区域自适应局域化快速活动轮廓模型, 通过引入局部全局信息形成了局部全局力, 用来克服 MSLCV 模型中初始化轮廓敏感性较强的问题, 通过判断演化曲线上各点周围的灰度分布均匀程度

决定局部全局信息和形状约束信息的使用范围,自适应调整局域化区域的范围以及采用局域计算优化实现了准确高效的分割,具体内容如下.

### 2.2.1 引入局部全局信息

在灰度非均匀图像的低对比度区域,即近似均匀分布的区域,基于局域区域信息的 MSLCV 模型驱动力微弱,以致在该区域曲线演化缓慢,初始化敏感性较强.为了克服此问题,本文方法在低对比度区域或近似均匀分布区域引入局部区域内的全局信息形成局部全局作用力,可有效地加速曲线朝目标边界的移动,同时依靠局部全局作用力减少初始化轮廓敏感性,通过判断曲线上各点周围的灰度分布均匀程度,决定局部全局信息和形状约束信息在模型中的使用范围.我们设计一个判断灰度分布均匀程度的特征函数  $t(x)$  如下:

$$t(x) = \begin{cases} 1, & |c_{x_1} - c_{x_2}| < \kappa_1 \\ 0, & \text{其他} \end{cases} \quad (11)$$

其中:  $c_{x_1}, c_{x_2}$  是上文中提到的曲线上点  $x$  的局域内部和外部的局域均值. 当其局域内部及外部均值之差的绝对值小于阈值  $\kappa_1$  时,则认为点  $x$  周围区域是低对比度和近似均匀分布的,此时应引入局部区域的全局信息形成局部全局作用力以加速曲线的演化. 在本文方法中,通过引入局部全局信息,我们提出以下总能量函数:

$$\begin{aligned} E(\phi) = & \int_{\Omega_x} \delta(\phi(x)) \int_{\Omega_y} B(x, y) \cdot \\ & F_{\text{region}}(I(y), \phi(y)) dy dx + \\ & \mu \int_{\Omega_x} \delta(\phi(x)) \|\nabla \phi(x)\| dx + \\ & (1 - t(x)) \beta \int_{\Omega_x} \delta(\phi(x)) \cdot \\ & F_{\text{shape}} dx + t(x) \int_{\Omega_z} \delta(\phi(z)) \cdot \\ & F_{\text{region-g}}(I(z), \phi(z)) dz \end{aligned} \quad (12)$$

其中

$$F_{\text{region-g}} = H(\phi(z))(I(z) - c_{z_1})^2 + (1 - (\phi(z)))(I(z) - c_{z_2})^2 \quad (13)$$

$F_{\text{region-g}}$  是通过引入局部区域  $\Omega_z$  内的全局信息形成局部全局作用力.  $\Omega_z$  是图像 I 中给定的局部区域,该区域完全覆盖待分割目标,如图 1 所示.  $\Omega_z$  的定义如下:

$$\Omega_z(x, y) = \begin{cases} x_{\min} - k < x < x_{\max} + k \\ y_{\min} - k < y < y_{\max} + k \end{cases} \quad (14)$$

其中:  $x_{\max}, y_{\max}$  分别是初始轮廓在图像  $x, y$  轴方向上的最大值,  $x_{\min}, y_{\min}$  分别是初始轮廓在图像  $x, y$

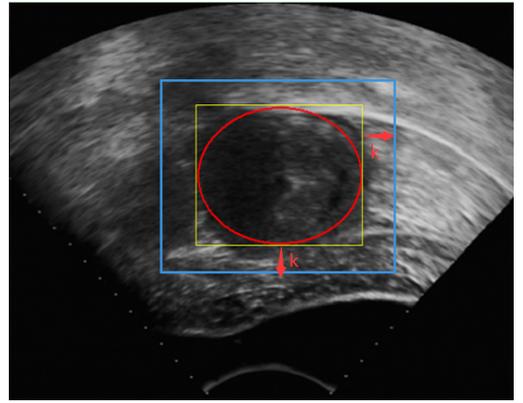


图 1 图像 I 中局部区域  $\Omega_z$ , 即外部矩形包含的区域,其中椭圆表示初始轮廓,内部矩形表示初始轮廓的外切矩形,外部矩形则是由外切矩形向外扩展形成

轴方向上的最小值,  $k$  是控制局部区域大小的参数,表示初始轮廓的外切矩形向外扩大的宽度范围,本文中  $k$  取值为 15.

$c_{z_1}, c_{z_2}$  分别是  $\Omega_z$  区域内部和区域外部的均值强度,定义如下:

$$c_{z_1} = \frac{\int_{\Omega_z} H(\phi(z)) \cdot I(z) dz}{\int_{\Omega_z} H(\phi(z)) dz} \quad (15)$$

$$c_{z_2} = \frac{\int_{\Omega_z} (1 - H(\phi(z))) \cdot I(z) dz}{\int_{\Omega_z} (1 - H(\phi(z))) dz} \quad (16)$$

通过最小化式(12)中的能量函数,求得相应的水平集演化方程如下:

$$\begin{aligned} \frac{\partial \phi}{\partial t}(x) = & \delta(\phi(x)) \left[ \int_{\Omega_y} B(x, y) \delta(\phi(y)) \cdot \right. \\ & ((I(y) - c_{x_1})^2 - (I(y) - c_{x_2})^2) dy + \\ & \mu \operatorname{div} \left( \frac{\nabla \phi(x)}{\|\nabla \phi(x)\|} \right) + (1 - t(x)) \cdot \\ & \beta \operatorname{sign}(\phi_0(x)) \|\rho_x - \rho_{\min}\|^2 + t(x) \cdot \\ & \left. ((I(x) - c_{z_1})^2 - (I(x) - c_{z_2})^2) \right] \end{aligned} \quad (17)$$

其中  $x$  表示图像 I 的一个像素点. 由于局部全局信息的引入,可较好地改善 MSLCV 模型采用局域化信息和形状约束所导致的初始化轮廓敏感性较强的缺陷.

### 2.2.2 自适应改变局域区域范围

文献[15]讨论了局域半径的作用,指出了局域半径大小的选择直接影响局域区域分割结果的准确性和在该区域的曲线演化速度,然而文献[15]并没有给出局域半径大小的自动化选择的具体方法,只是在论文中提到局域半径的选择应依据目标物体的大小和邻近环境杂乱程度. 对于分割目标较小且周

围较杂乱的图像,采用较小的局域半径;而对于分割目标较大且周围较简单的图像,则采用较大的局域半径更为合适.而文献[21]仅仅根据目标物体的范围大小设计了半径大小的选择函数  $R(x)$ ,且  $R(x)$  只是依靠初始化轮廓自动地选择一个大小固定的局域半径值,其在曲线演化过程中局域半径无法自适应动态改变.为了实现更高效准确的分割,本文根据分割目标的范围大小和邻近环境杂乱的程度实现局域半径大小的自适应选择,在文献[21]根据目标物体的范围大小实现局域半径大小的初始化自动化选择基础上,通过判断曲线上各点周围的灰度分布均匀程度自适应地修正局域半径.

在文献[21]中,局域半径初始化大小的选择函数  $R(x)$  定义如下:

$$R(x) = 10 \times \arctan(0.28x - 6) + 24 \quad (18)$$

$$x = \lambda (\|x_{\max} - x_{\min}\| + \|y_{\max} - y_{\min}\|) \quad (19)$$

其中:  $x$  是初始轮廓在图像上  $x$  轴方向的最大最小值之差与  $y$  轴方向上最大最小值之差的和的一个比例值,  $\lambda$  是控制比例值大小的系数,一般取 0.25,  $x_{\max}, y_{\max}$  分别是初始轮廓在图像  $x, y$  轴方向上的最大值,  $x_{\min}, y_{\min}$  分别是初始轮廓在图像  $x, y$  轴方向上的最小值,最后求得的  $R(x)$  四舍五入取整即得到局域半径大小.

本文通过判断曲线上各点周围的灰度分布均匀程度动态地自适应调整局域半径大小,我们设计局域半径  $r$  的选择函数  $r(x)$ ,如式(20)所示.

$$r(x) = \begin{cases} r_0 + \omega_0, & |c_{x_1} - c_{x_2}| < \kappa_2 \\ r_0 + \omega_1, & \kappa_2 < |c_{x_1} - c_{x_2}| < \kappa_3 \\ r_0, & \kappa_3 < |c_{x_1} - c_{x_2}| < \kappa_4 \\ r_0 - \omega_1, & \kappa_4 < |c_{x_1} - c_{x_2}| < \kappa_5 \\ r_0 - \omega_0, & |c_{x_1} - c_{x_2}| > \kappa_5 \end{cases} \quad (20)$$

$\& \cdot r(x) \geq r_{\min}$

其中:  $r_0$  即是式(18)中得到的局域半径初始化大小,  $c_{x_1}, c_{x_2}$  是曲线上点  $x$  局域内部和外部的均值强度;  $\omega_0, \omega_1$  是局域半径大小变化的宽度系数,  $\omega_0 > \omega_1$ ;  $\kappa_2 < \kappa_3 < \kappa_4 < \kappa_5$ , 当其局域内外部均值的绝对值差小于阈值  $\kappa_2$  时,则认为点  $x$  周围区域非常近似均匀分布,此时局域半径增加较大;当其局域内外部均值的绝对值差小于阈值  $\kappa_3$  时,则认为点  $x$  周围区域相对近似均匀分布,此时局域半径增加少许;当其局域内外部均值的绝对值差大于阈值  $\kappa_4$  而小于阈值  $\kappa_5$  时,则认为点  $x$  周围区域分布比较不均匀,此时局域半径减小少许;当其局域内外部均值的绝对值差大于

阈值  $\kappa_5$  时,则认为点  $x$  周围区域分布极不均匀,此时局域半径应减少较大;  $r_{\min}$  表示局域半径的最小值.图 2 显示了局部半径由函数  $r(x)$  根据局域区域的灰度分布均匀程度动态地自适应改变的结果,其中轮廓曲线表示零水平集演化过程中的曲线变化,虚线圆圈表示了由局域半径所形成的局部区域大小,通过本文方法即可实现局域区域范围的自适应调整.

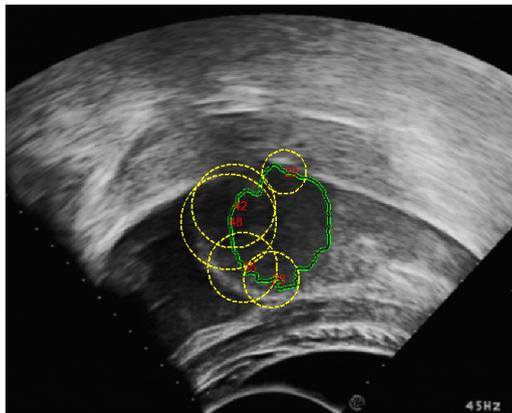


图 2 自适应改变局域区域大小.曲线演化过程中局域半径根据局域区域的灰度分布均匀程度动态地自适应改变.其中轮廓曲线表示零水平集演化过程中的曲线变化,虚线圆圈表示了由局域半径所形成的局部区域大小

### 2.2.3 局域计算优化

为减少 MSLCV 模型<sup>[21]</sup>计算量较大的问题,本文提出局域区域计算优化方法,即使用同一局域区域计算相邻像素局域作用力的方法,在保障分割准确性的基础上更好地提升分割效率. MSLCV 模型是以曲线上的每一个点为单位独自地计算其局域能量,形成局域作用力促使曲线上各个点朝着目标边界移动.因为需要对于曲线上每个像素点计算其局域能量,造成计算量明显较大,分割效率较低.为此,本文考虑相邻像素点使用中间像素点的局域区域作为这些相邻像素点共同的局域区域以计算其局域作用力.如图 3 所示,由于像素点相邻,故其局域区域

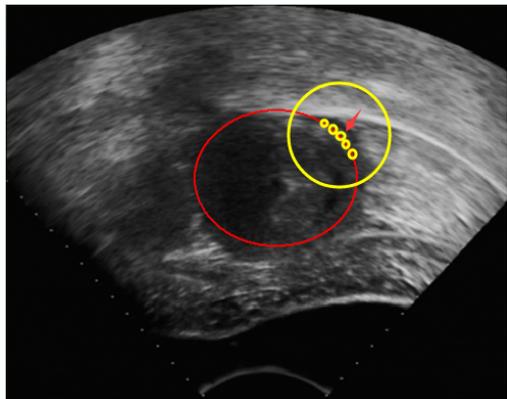


图 3 局域计算优化(椭圆表示初始轮廓,轮廓边缘处的圆表示 5 个相邻像素点共同的局域区域)

差异极小,其对分割准确性影响较小,并且对于曲线演化的每一次迭代计算却可以节省较多时间,可较大地提高分割效率.

点使用中间像素点的局域区域作为共同的局域区域计算局域作用力,所得结果即为 5 个相邻像素点共同的局域作用力.

在实验中,我们对演化曲线上每 5 个相邻像素

本文方法的整体流程如图 4 所示.

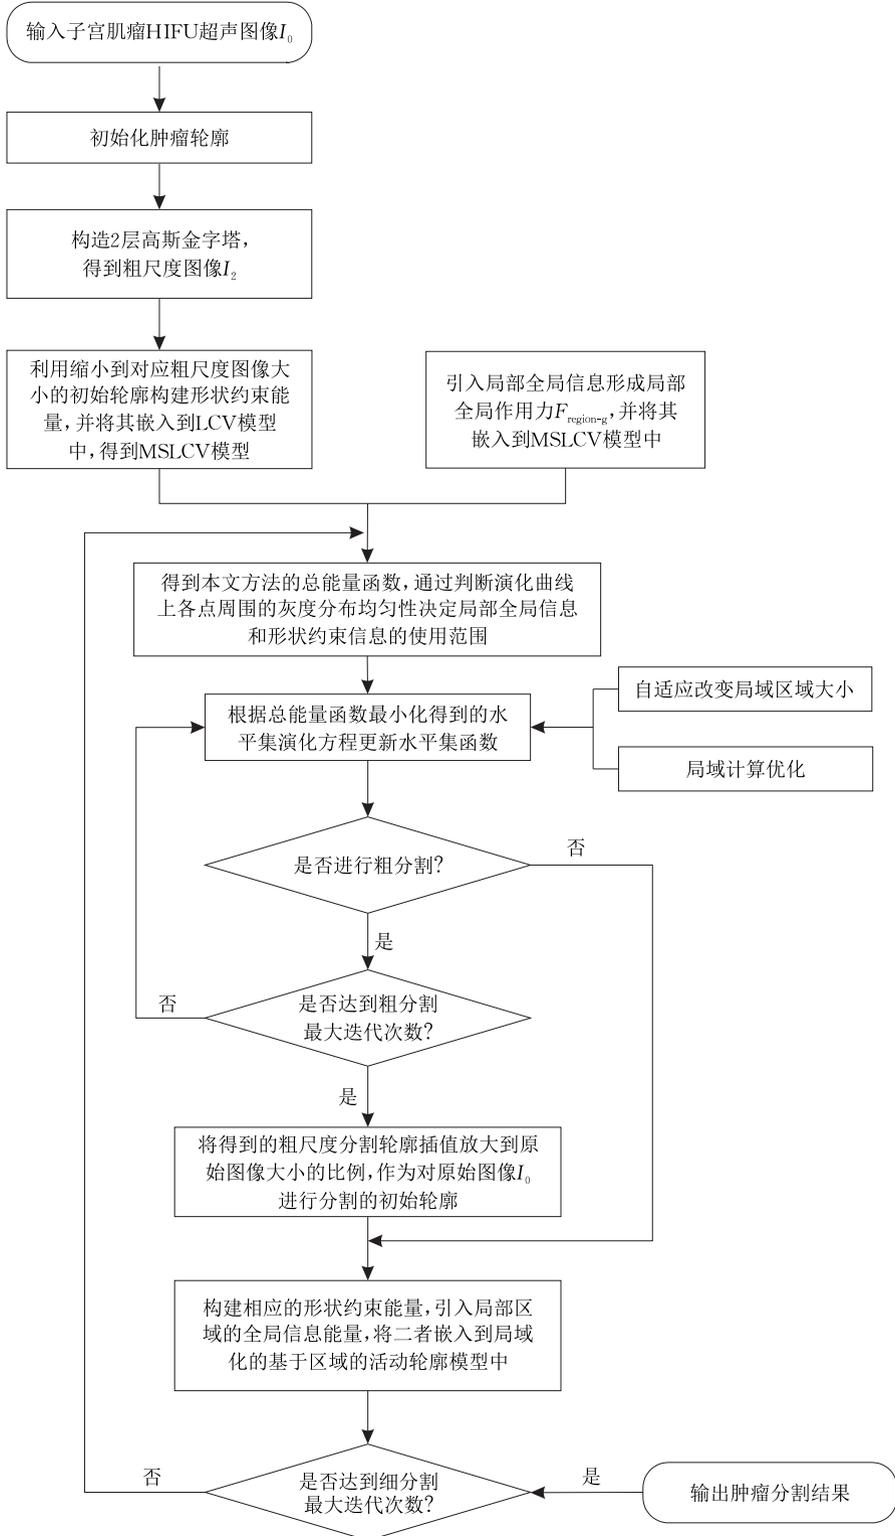


图 4 本文方法的整体流程图

## 3 实验

### 3.1 算法对比

我们将本文方法应用于 HIFU 子宫肌瘤超声图像分割中,并将其实验结果与 6 种活动轮廓模型进行了对比分析.实验中所用 HIFU 子宫肌瘤超声图像数据来自重庆医科大学第二附属医院 HIFU 治疗中心,并采用专家手工分割结果作为基准.为便于统计分析,我们调整每幅图像的分辨率为  $524 \times 413$ .我们将本文方法与 GAC(Geodesic Active Contours)模型<sup>[8]</sup>、C-V 模型<sup>[11]</sup>、RSF(Region-Scalable Fitting)模型<sup>[13]</sup>、LGF(Local Gaussian Fitting)模型<sup>[23]</sup>、LCV 模型<sup>[15]</sup>和 MSLCV 模型<sup>[21]</sup>在 HIFU 子宫肌瘤超声图像上的分割表现进行了对比.本文针对待分割图像的特征以及参数的实际数学物理意义,并结合实验测试效果选取最佳的参数作为本文模型的最终参数.

在实验中,GAC 模型控制曲线收缩或扩张的参数设置为  $-1$ ;C-V 模型弧长项权值设置为  $0.2$ ;RSF 模型弧长项权值设置为  $0.1$ ,水平集正则项参数设置为  $1$ ;LGF 模型弧长项权值设置为  $0.001$ ,水平集正则项参数设置为  $1$ ;LCV 模型弧长项权值设置为  $0.2$ ,局域半径为  $30$ ;MSLCV 模型弧长项权值为  $0.2$ ,控制形状约束大小的系数  $\beta$  取  $0.6$ ;本文方法弧长项权值及  $\beta$  的取值与 MSLCV 模型一致,控制局部全局区域大小的参数  $k$  取  $15$ .

A~J 这 10 张测试图像依据模糊程度被分为好、中、差 3 个层次,其中图像 A 与 B 属于好的层次,有较清晰的目标轮廓;C~F 属于中等层次,某些区域较为模糊,弱边界;而 G~J 属较差层次,该类图像整体具有非常严重的模糊性和低对比度,边界很难区分.由于超声图像自身的特点以及为了便于对比分析,本文在实验时大多使用了较好的初始轮廓.因为子宫肌瘤大都具有近似椭球体的形状,所以我们用一个椭圆形初始化待分割图像.图 5 显示了

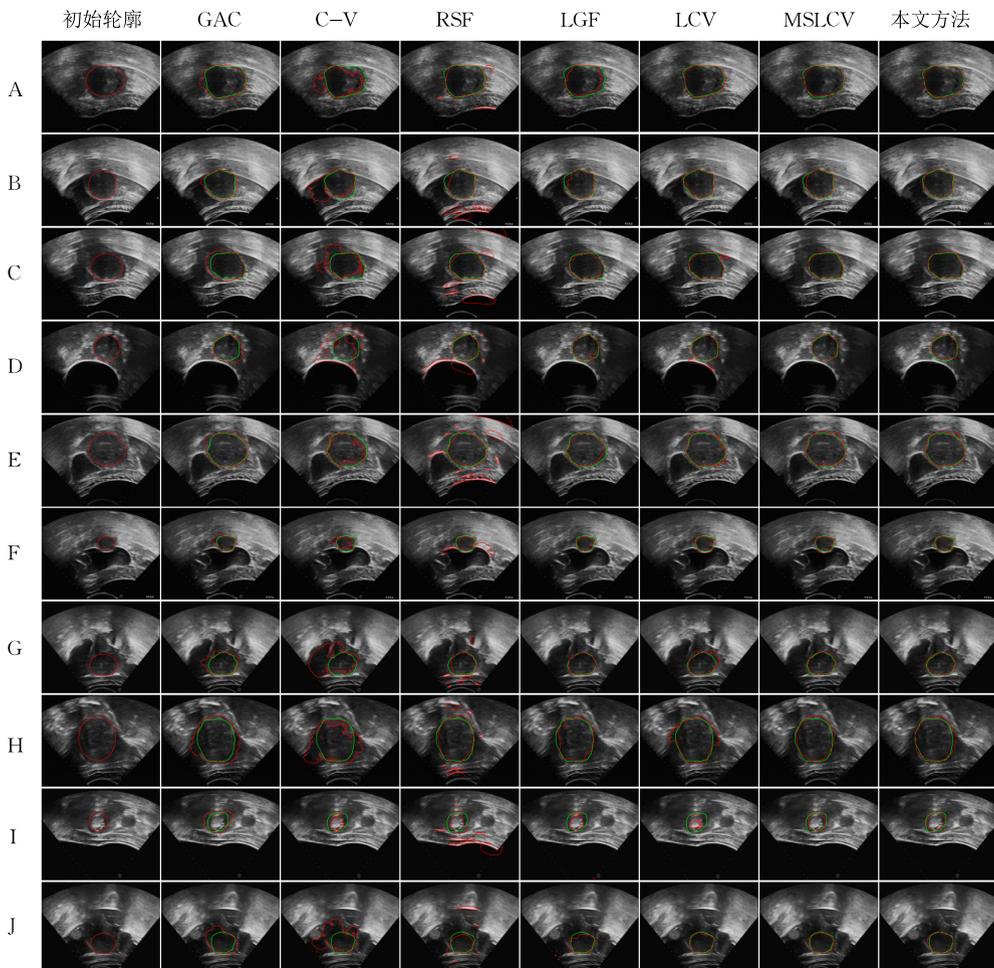


图 5 本文方法同其他 6 种方法的 HIFU 子宫肌瘤分割结果(第 1 列为带有初始轮廓的测试图像;第 2 列到第 8 列依次显示了使用 7 种活动轮廓模型的分割结果,依次是 GAC<sup>[8]</sup>、C-V<sup>[11]</sup>、RSF<sup>[13]</sup>、LGF<sup>[23]</sup>、LCV<sup>[15]</sup>、MSLCV<sup>[21]</sup>和本文方法.每行图像第 2 列到第 8 列图中相同曲线轮廓表示专家手工分割结果,另一轮廓曲线则是分别采用对应方法分割后的轮廓)

本文方法同其他 6 个活动轮廓方法在 10 张典型的 HIFU 子宫肌瘤超声图像上的分割效果的比较,为便于比较和曲线充分演化,实验中的曲线总迭代次数统一设为 400,其中多尺度分割中粗分割阶段迭代次数为 350,细分割阶段迭代次数为 50.

为了更加准确地估计各分割结果同专家手工分割的定量比较,我们采用基于面积的  $DSC$  (Dice Similarity Coefficient)<sup>[22]</sup> 和基于边缘的  $MSSD$  (Mean Sum of Square Distance)<sup>[22]</sup> 两个标准进行比较分析,其定义分别如下:

$$DSC(S_S, S_R) = \frac{2 \cdot Area(S_S \cap S_R)}{Area(S_S) + Area(S_R)} \quad (21)$$

其中  $S_S$  和  $S_R$  各自代表获得的分割结果和基准.  $DSC$  值越接近于 1,表明分割效果越好.

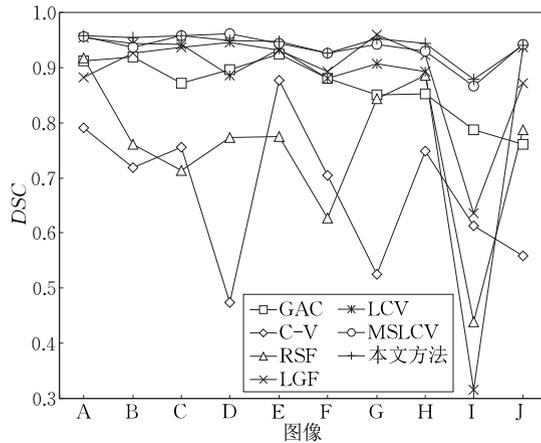
$$MSSD = \frac{1}{N} \sum_{n=1}^N D_2^2(A, B(x_n)) \quad (22)$$

其中

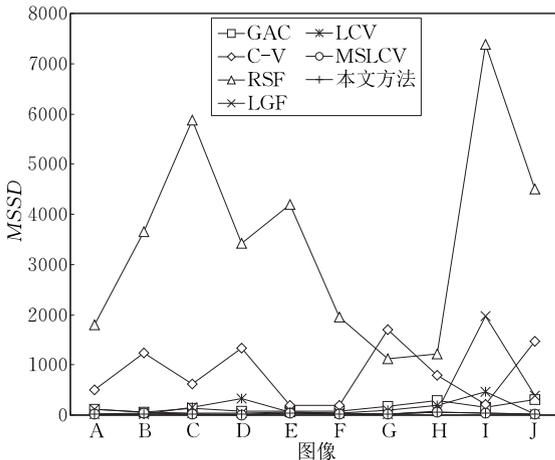
$$D_2(A, B(x)) = \min_{y \in A} (\|y - x\|) \quad (23)$$

$A$  和  $B$  分别为基准轮廓和分割轮廓,  $N$  是分割轮廓上的像素点数.  $MSSD$  值越接近于 0,分割结果越好.图 5 中分割结果的  $DSC$  和  $MSSD$  值如表 1 所示,在每行中最好的数值结果采用加粗显示,从表中可以明显地看出本文方法在分割精度上明显优于其他活动轮廓模型.

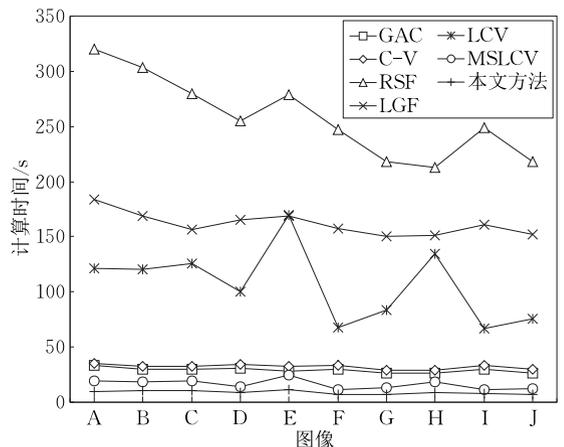
同时,我们在表 2 中给出了这几种方法对图 5 中子宫肌瘤超声图像分割的计算时间的比较,从表 2 中可以看出本文方法的分割效率最高,且相比较 MSLCV 模型,本文方法的平均分割效率提升了 84.6%.图 6 为本文方法与  $GAC^{[8]}$ 、 $C-V^{[11]}$ 、 $RSF^{[13]}$ 、 $LGF^{[23]}$ 、 $LCV^{[15]}$  及  $MSLCV^{[21]}$  的  $DSC$ 、 $MSSD$  和计算时间的对比,从图 6 中可知,本文方法在分割准确性及计算效率上都明显优于其他分割方法.



(a) DSC



(b) MSSD



(c) 计算时间

图 6 本文方法与  $GAC^{[8]}$ 、 $C-V^{[11]}$ 、 $RSF^{[13]}$ 、 $LGF^{[23]}$ 、 $LCV^{[15]}$  及  $MSLCV^{[21]}$  的  $DSC$ 、 $MSSD$  以及计算时间的对比(横坐标为 A~J 这 10 张测试图像,各子图纵坐标分别为  $DSC$ 、 $MSSD$  以及计算时间,本文方法在分割准确性及计算时间上都明显优于其他分割方法)

表 1 DSC 和 MSSD 标准下的图 5 中各分割方法的表现(加粗文本表示对于一张具体的图片所得到的最好表现)

Method	A		B		C		D		E		F		G		H		I		J		平均值	
	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD	DSC	MSSD
GAC	0.912	111.08	0.919	48.71	0.871	135.61	0.896	83.83	0.925	77.50	0.881	69.59	0.851	165.24	0.853	287.40	0.787	155.58	0.760	302.89	0.865	143.74
C-V	0.791	505.22	0.718	1243.59	0.756	613.14	0.475	1332.22	0.877	186.35	0.704	192.55	0.526	1704.19	0.749	793.00	0.613	221.83	0.558	1462.99	0.676	825.51
RSF	0.918	1789.09	0.760	3657.52	0.714	5875.36	0.773	3411.81	0.775	4188.33	0.628	1953.21	0.843	1115.22	0.886	1211.66	0.439	7385.04	0.787	4505.49	0.752	3509.27
LGF	0.882	115.49	0.927	56.79	0.937	33.60	0.946	40.90	0.931	48.70	0.893	30.90	<b>0.959</b>	<b>11.13</b>	0.923	84.46	0.636	1977.27	0.872	377.68	0.890	277.69
LCV	0.955	<b>18.11</b>	0.943	23.30	0.942	159.92	0.886	336.86	0.933	56.09	0.881	36.46	0.906	93.91	0.892	191.70	0.315	471.75	0.937	14.96	0.859	140.31
MSLCV	0.956	20.01	0.937	32.54	<b>0.958</b>	<b>13.06</b>	<b>0.961</b>	<b>9.43</b>	0.944	43.81	<b>0.927</b>	14.39	0.942	16.62	0.930	53.75	0.866	46.98	<b>0.942</b>	<b>12.33</b>	0.936	26.29
本文方法	<b>0.957</b>	19.69	<b>0.955</b>	<b>13.06</b>	<b>0.958</b>	14.55	0.949	16.66	<b>0.947</b>	<b>35.99</b>	<b>0.927</b>	<b>13.41</b>	0.952	11.15	<b>0.943</b>	<b>49.68</b>	<b>0.878</b>	<b>38.06</b>	0.940	15.42	<b>0.941</b>	<b>22.77</b>

表 2 对图 5 中的分割各活动轮廓模型分割方法的计算时间比较

(单位:s)

image	Method						
	GAC	C-V	RSF	LGF	LCV	MSLCV	本文方法
A	33.15	35.43	320.00	183.78	121.00	19.09	<b>9.78</b>
B	29.99	32.96	303.51	169.11	120.90	18.52	<b>10.66</b>
C	29.61	32.17	280.02	156.48	125.73	19.15	<b>10.30</b>
D	30.61	34.46	254.99	165.12	99.95	14.39	<b>8.55</b>
E	28.49	32.14	278.83	168.50	170.11	24.52	<b>11.36</b>
F	29.73	33.04	246.96	157.10	67.85	11.53	<b>7.37</b>
G	26.75	28.96	218.13	150.72	83.81	13.49	<b>6.85</b>
H	26.20	29.23	212.57	151.65	134.11	18.61	<b>9.03</b>
I	30.26	33.55	248.50	160.97	66.56	11.79	<b>7.71</b>
J	26.80	29.78	218.07	152.02	75.40	12.30	<b>6.86</b>
平均值	29.16	32.17	258.16	161.54	106.54	16.34	<b>8.85</b>

### 3.2 初始化敏感性

相比于 MSLCV 模型,本文方法所引入的局部全局信息有效地减少了对初始轮廓产生的初始化敏感性,以下通过对 A,B 图像采用不同的初始化轮廓进行分割更好地验证其作用,实验结果如图 7 和表 3 所示。

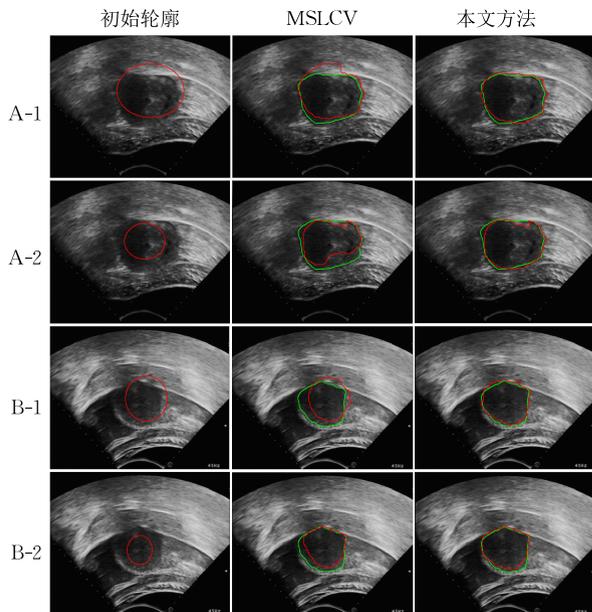


图 7 本文方法与 MSLCV 模型在不同初始轮廓下对 HIFU 子宫肌瘤超声图像的分割结果

表 3 采用不同初始轮廓后本文方法相比于 MSLCV 模型的分割结果对比

Image	MSLCV		本文方法	
	DSC	MSSD	DSC	MSSD
A-1	0.873	207.89	<b>0.938</b>	<b>33.86</b>
A-2	0.849	96.69	<b>0.945</b>	<b>36.38</b>
B-1	0.754	290.13	<b>0.931</b>	<b>30.05</b>
B-2	0.863	117.22	<b>0.933</b>	<b>33.70</b>

从图 7 和表 3 可以看出不同的初始轮廓对 MSLCV 模型分割结果准确性影响较大,即 MSLCV 对初始轮廓较敏感,初始轮廓不佳时,在图像灰度较均匀区域的局域力则较小,由于形状约束力的存在会导致曲线较难演化,本文方法通过引入局部全局信息形成了局部全局力,克服了 MSLCV 模型中初始化轮廓敏感性较强问题,从表 3 可以看出,即使在不佳的初始轮廓下,本文方法所得的分割结果依然较 MSLCV 模型的分割结果更准确。

### 3.3 效率对比

为了验证本文方法对分割效率的提升作用,我们在 HIFU 子宫肌瘤超声图像 A 和 B 上,使用相同的初始轮廓,分别采用模型 1(未使用多尺度算法和局域计算优化)、模型 2(只使用局域计算优化,未使用多尺度算法)、模型 3(只使用多尺度算法,未使用局域计算优化)和本文方法(同时使用多尺度算法和

局域优化)对图像 A 和 B 进行分割,实验结果如表 4 和图 8 所示.从表 4 和图 8 可以看出本文方法同其

他 3 个模型得到的分割结果准确性相近,但本文方法的时间耗时明显降低,较大地提高了分割效率.

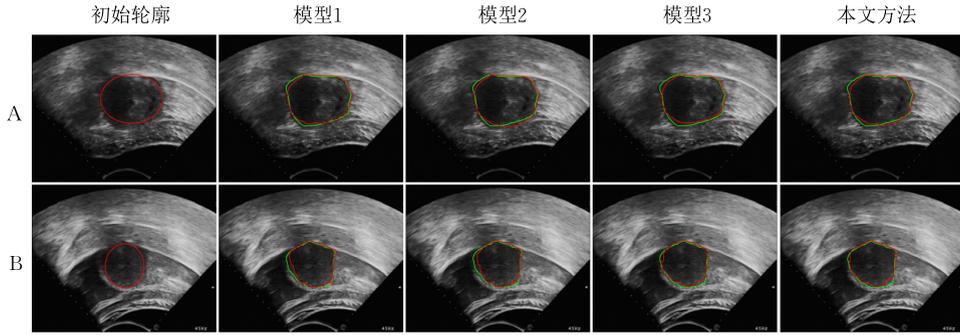


图 8 本文方法和模型 1、模型 2、模型 3 对子宫肌瘤超声图像 A、B 的分割结果对比

表 4 模型 1、模型 2、模型 3 以及本文方法的分割准确性和分割时间比较

Method	A			B		
	DSC	MSSD	时间/s	DSC	MSSD	时间/s
模型 1	0.959	17.15	158.29	0.952	22.29	118.25
模型 2	0.954	22.90	53.82	0.946	26.77	44.58
模型 3	0.946	28.57	26.39	0.954	18.22	22.38
本文方法	0.953	20.91	9.60	0.952	21.38	8.52

## 4 总 结

本文针对子宫肌瘤 HIFU 超声图像中的分割难题,提出了一种更加准确高效的引入局部全局信息的区域自适应局域化快速活动轮廓模型.该模型通过引入局部全局信息形成局部全局力来克服初始轮廓敏感性问题,并依据演化曲线上各点周围的灰度分布均匀程度动态地决定局部全局信息和形状约束信息的使用范围,同时利用该灰度分布信息自适应改变局域区域半径大小进而调整局域化区域大小,最后通过使用同一局域区域计算相邻像素的局域作用力实现快速高效分割.实验结果表明,本文方法对 HIFU 子宫肌瘤超声影像中肿瘤分割有准确的分割效果,克服了 MSLCV 的初始化敏感性较强的缺陷,在保证准确性的基础上进一步提高了分割效率,获得了更加准确高效的分割效果.

**致 谢** 对于重庆医科大学郑元义教授的指导并手工分割 HIFU 子宫肌瘤超声图像,在此表示感谢!

## 参 考 文 献

- [1] Kennedy J E. High-intensity focused ultrasound in the treatment of solid tumours. *Nature Reviews Cancer*, 2005, 5(4): 321-327
- [2] Orsi F, Arnone P, Chen W, Zhang L. High intensity focused ultrasound ablation: A new therapeutic option for solid tumors. *Journal of Cancer Research and Therapeutics*, 2010, 6(4): 414-420
- [3] Lee S H, Lee J M, Kim K W, et al. Dual-energy computed tomography to assess tumor response to hepatic radiofrequency ablation: Potential diagnostic value of virtual noncontrast images and iodine maps. *Investigative Radiology*, 2011, 46(2): 77-84
- [4] Cheng H D, Shan J, Ju W, et al. Automated breast cancer detection and classification using ultrasound images: A survey. *Pattern Recognition*, 2010, 43(1): 299-317
- [5] Ghose S, Oliver A, Marti R, et al. A survey of prostate segmentation methodologies in ultrasound, magnetic resonance and computed tomography images. *Computer Methods and Programs in Biomedicine*, 2012, 108(1): 262-287
- [6] Li C, Huang R, Ding Z, et al. A level set method for image segmentation in the presence of intensity inhomogeneities with application to MRI. *IEEE Transactions on Image Processing*, 2011, 20(7): 2007-2016
- [7] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models. *International Journal of Computer Vision*, 1988, 1(4): 321-331
- [8] Caselles V, Kimmel R, Sapiro G. Geodesic active contours. *International Journal of Computer Vision*, 1997, 22(1): 61-79
- [9] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: A new variational formulation//Proceedings of the IEEE Conference on Computer Vision and Pattern. San Diego, USA, 2005: 430-436
- [10] Ronfard R. Region-based strategies for active contour models. *International Journal of Computer Vision*, 1994, 13(2): 229-251
- [11] Chan T F, Vese L A. Active contours without edges. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277
- [12] Vese L A, Chan T F. A multiphase level set framework for image segmentation using the Mumford and Shah model. *International Journal of Computer Vision*, 2002, 50(3): 271-293

- [13] Li C, Kao C Y, Gore J C, et al. Minimization of region-scalable fitting energy for image segmentation. *IEEE Transactions on Image Processing*, 2008, 17(10): 1940-1949
- [14] Lorigo L M, Faugeras O D, Grimson W E L, et al. Curves: Curve evolution for vessel segmentation. *Medical Image Analysis*, 2001, 5(3): 195-206
- [15] Lankton S, Tannenbaum A. Localizing region-based active contours. *IEEE Transactions on Image Processing*, 2008, 17(11): 2029-2039
- [16] Li C, Kao C Y, Gore J C, et al. Implicit active contours driven by local binary fitting energy//*Proceedings of the IEEE Conference on Computer Vision and Pattern*. Minneapolis, USA, 2007: 1-7
- [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. *Computerized Medical Imaging and Graphics*, 2009, 33(7): 520-531
- [18] Tian Yun, Duan Fuqing, Lu Ke, et al. A flexible 3D cerebrovascular extraction from TOF-MRA images. *Neurocomputing*, 2013, 121: 392-400
- [19] Xie Li-Zhi, Zhou Ming-Quan, Tian Yun, et al. Cerebrovascular segmentation based on region growing and local adaptive C-V model. *Journal of Software*, 2013, 24(8): 1927-1936 (in Chinese)  
(解立志, 周明全, 田云等. 基于区域增长与局部自适应 C-V 模型的脑血管分割. *软件学报*, 2013, 24(8): 1927-1936)
- [20] Wang Bin, Li Jie, Gao Xin-Bo. An edge- and region-based level set method with shape priors for image segmentation. *Chinese Journal of Computers*, 2012, 35(5): 1067-1072 (in Chinese)  
(王斌, 李洁, 高新波. 一种基于边缘与区域信息的先验水平集图像分割方法. *计算机学报*, 2012, 35(5): 1067-1072)
- [21] Liao X, Yuan Z, Zheng Q, et al. Multi-scale and shape constrained localized region-based active contour segmentation of uterine fibroid ultrasound images in HIFU therapy. *PLoS One*, 2014, 9(7): e103334
- [22] Diertenbeck T, Alessandrini M, Friboulet D, et al. CREASEG: A free software for the evaluation of image segmentation algorithms based on level-set//*Proceedings of the IEEE International Conference on Image Processing*. Hong Kong, China, 2010: 665-668
- [23] Wang L, He L, Mishra A, et al. Active contours driven by local gaussian distribution fitting energy. *Signal Processing*, 2009, 89(12): 2435-2447



**LIAO Xiang-Yun**, born in 1989, Ph.D. His research interests include image processing, computer simulation and virtual reality.

**YUAN Zhi-Yong**, born in 1963, Ph.D., professor, Ph.D. supervisor. His research interests include computer simulation and virtual reality, image processing and computer vision, machine learning and pattern recognition.

**ZHENG Qi**, born in 1990, M. S. His research interest is image processing.

**TONG Qian-Qian**, born in 1989, M. S. candidate. Her research interests include embedded system, graphics and image processing.

**LAI Qian-Feng**, born in 1991, M. S. His research interest is computer graphics.

**ZHANG Gui-An**, born in 1985, Ph. D. His research interests include embedded system, graphics and image processing.

## Background

HIFU treatment is a new type of non-invasive operation and has been gradually put into actual treatment of uterine fibroid. The segmentation of uterine fibroids in HIFU ultrasound images is a critical stage in HIFU therapy, but now the precise segmentation of ultrasound images has always been a problem and there are no appropriate and special segmentation methods for it in HIFU treatment.

Many state-of-the-art methods can obtain good segmentation when the ultrasound images are clear and homogeneous. However, the HIFU ultrasound images have severe intensity inhomogeneity and blurry boundaries and common methods are easy to lead to boundary leakage or excessive contraction.

In recent years, though many region-based localized active contour models had been proposed to segment uneven targets in clutter images, but for HIFU ultrasound images with seriously low signal to noise ratio, low contrast level, and weak edges, they were unable to obtain satisfying results.

In this work, to obtain more accurate and efficient segmentation results, we propose an adaptive localized region-based fast active contour model, which is more accurate and efficient and overcomes the initialization sensitivity by introducing the global information in local region to form locally global force. We propose an adaptive localized region-based fast active contour model, which is more accurate and

efficient and overcomes the initialization sensitivity by introducing the global information in local region to form locally global force. Our method solves the problems in segmenting HIFU ultrasound image of uterine fibroids, overcomes the initialization sensitivity of MSLCV, improves the efficiency on the premise of accuracy and gains more accurate and efficient segmentation results. The segmentation results can further be adopted to reconstruct the 3D models of tissues and organs in our projects.

The method proposed in this work can help obtain the segmentation results of HIFU ultrasound images of uterine fibroids faster and more accurate, which greatly impacts overall process of the operation, relieving patients' pain in

HIFU therapy.

We have published a paper about segmentation of HIFU uterine fibroids ultrasound images on PLOS ONE in July 2014, which was named "Multi-Scale and Shape Constrained Localized Region-Based Active Contour Segmentation of Uterine Fibroid Ultrasound Images in HIFU Therapy" and is the basis of the method proposed in this work.

This work was supported by a grant from the National Natural Science Foundation of China (Grant No. 61373107), a grant from the National Basic Research Program of China (Grant No. 2011CB707904) and the open funding project of State Key Laboratory of Virtual Technology and Systems, Beihang University (Grant No. BUAA-VR-13KF-15).