

doi: 10.12068/j.issn.1005-3026.2019.01.002

# 参数化水平集活动轮廓模型的快速图像分割算法

陈红<sup>1,2</sup>, 于晓升<sup>1</sup>, 吴成东<sup>1</sup>, 孙鹏<sup>2</sup>

(1. 东北大学 机器人科学与工程学院, 辽宁 沈阳 110819; 2. 鞍山师范学院 物理科学与技术学院, 辽宁 鞍山 114005)

**摘要:** 为了提高图像分割的速度,提出一种参数化水平集活动轮廓模型的快速图像分割算法.该算法中的水平集函数由参数向量确定,而非带符号距离函数,降低了水平集函数的维度.将参数化的水平集函数嵌入到经典的LGDF(local Gaussian distribution fitting)模型中进行图像分割,不需要重新初始化和额外的正则项,同时可选择较大迭代步长.实验结果表明:所提方法能够有效地分割超声、CT和核磁等医学图像,与带有正则项的分割算法LGDF和最近提出的快速分割算法MSLCV相比,在保证分割精度的同时,计算速度得到了明显提高.

**关键词:** 水平集;活动轮廓模型;图像分割;LGDF模型;MSLCV模型

中图分类号: TP 391.41

文献标志码: A

文章编号: 1005-3026(2019)01-0006-05

## Fast Image Segmentation Algorithm Based on Parametric Level Set Active Contour Model

CHEN Hong<sup>1,2</sup>, YU Xiao-sheng<sup>1</sup>, WU Cheng-dong<sup>1</sup>, SUN Peng<sup>2</sup>

(1. School of Robot Science and Engineering, Northeastern University, Shenyang 110819, China; 2. College of Physics Science and Technology, Anshan Normal University, Anshan 114005, China. Corresponding author: CHEN Hong, E-mail: chenhongbuty@126.com)

**Abstract:** In order to improve the segmentation speed, a fast image segmentation method based on parametric level set active contour model was proposed. The level set function was determined by the parameter vector, rather than the signed distance function, which reduces the dimension of the level set function. The parametric level set function was embedded into the classical LGDF (local Gaussian distribution fitting) segmentation algorithm, and it does not need to be re-initialized or additional regular terms, and it can choose larger step length. The experiment results show that the proposed method can effectively segment medical images such as ultrasound, CT and MR medical images. Compared with the LGDF model with regular terms and the recently proposed fast segmentation algorithm MSLCV, in the case of similar segmentation accuracy, the calculation speed of the proposed method is improved obviously.

**Key words:** level set; active contour model; image segmentation; LGDF model; MSLCV model

图像分割是分类、识别及目标跟踪等高级图像处理的基础步骤,是图像后期处理的重要保障.众多图像分割方法中,活动轮廓模型倍受关注,根据能量函数是否含有参数,分为参数活动轮廓模型和几何活动轮廓模型.参数活动轮廓模型将曲线以参数的形式显式地表达<sup>[1-2]</sup>.这类模型表示方式简单易懂,但在演化过程中难以适应曲线的拓扑变化.几何活动轮廓模型没有参数,典型代表是基于水平集方法的活动轮廓模型<sup>[3-7]</sup>.水平集

活动轮廓模型将演化曲线嵌入到高一阶的能量函数中,能量函数的零水平集就是演化曲线.演化曲线的这种隐式表达方式,使曲线能够自动处理演化过程中的拓扑变化,更适用于图像分割.大多基于水平集活动轮廓模型的分割方法,为了保证数值稳定而附加的正则项增加了计算开销,分割时间长,不能满足图像自动解译、图像引导微创手术等实时性应用的要求.一些改进的算法用来提高水平集活动轮廓模型的计算效率,如文献[8]中

收稿日期: 2017-10-27

基金项目: 国家自然科学基金资助项目(61503274, 61603080).

作者简介: 陈红(1978-),女,辽宁辽中人,东北大学博士研究生,鞍山师范学院副教授;吴成东(1960-),男,辽宁大连人,东北大学教授,博士生导师.

的快速算法,文献[9]中的分裂 Bregman 算法,文献[10]中的多尺度方法,这些方法改善了计算速度,但没有从本质上解决带符号距离函数的正则化问题。

为解决上述问题,本文提出一种基于参数水平集活动轮廓模型快速图像分割算法。算法中的水平集函数由判别参数确定,而非带符号距离函数。将参数化的水平集函数嵌入到无参数的几何活动轮廓模型 LGDF 中分割图像。参数化水平集无需附加正则项,保持带符号距离函数,既将拓扑变化自然融入到曲线的演化中,又降低了算法的维度,同时可选择较大步长,减少迭代次数。

## 1 背景介绍

### 1.1 传统水平集函数及正则化

带符号距离函数常被选作水平集函数,如下:

$$u(x, y, t) = \begin{cases} d[(x, y), C], & (x, y) \text{ 在轮廓线外部;} \\ -d[(x, y), C], & (x, y) \text{ 在轮廓线内部.} \end{cases} \quad (1)$$

式中:  $C$  为零水平集,即演化曲线;  $d$  为平面上某区域的点  $(x, y)$  到曲线  $C$  的欧几里得距离。由于水平集的梯度与法线共线但方向相反,故将在某区域内点的值按内负外正进行定义。

式(1)定义的带符号距离函数的梯度模恒等于 1,保证  $u(x, y, t)$  的变化处处均匀,数值计算稳定。因此,分割模型选其作为水平集函数。

根据曲线演化理论,水平集函数演化方程为

$$\frac{\partial u}{\partial t} = \beta |\nabla u|. \quad (2)$$

式中:  $\beta$  为法向速率,作为曲面函数  $u$  中各水平集的演化速率,但实际上  $\beta$  仅为零水平集的演化速率;  $t$  为演化时间。因此,在经过多次迭代后,水平集函数会偏离带符号距离函数的特性,破坏迭代的稳定性。当  $u$  的梯度模远大于 1 时,水平集函数会出现尖峰或深谷,导致能量函数陷入局部最小值;当  $u$  的梯度模远小于 1 时,水平集函数过于平坦,失去意义。为此,学者们采用重新初始化或者在模型中加入正则项的方法,使水平集函数在演化过程中保持为带符号距离函数。这些方法解决了水平集演化过程的稳定性问题,但增加了计算开销和计算时间。

### 1.2 LGDF 模型

局部高斯分布拟合 (local Gaussian distribution fitting, LGDF) 模型,是经典的基于水平集活动轮廓模型的分割算法之一<sup>[6]</sup>。LGDF 模

型的能量泛函如下:

$$E^{\text{LGDF}}(\varphi, u_1, u_2, \sigma_1, \sigma_2) = \nu \int_{\Omega} \frac{1}{2} (|\nabla \varphi| - 1)^2 dx + \mu \int_{\Omega} \delta_{\varepsilon}(\varphi) |\nabla \varphi| dx + \lambda_1 \int \left[ \int K(x - y) (\log \sigma_1(x) + \frac{(I(y) - u_1(x))^2}{2\sigma_1^2(x)}) \cdot H_{\varepsilon}(\varphi(y)) dy \right] dx + \lambda_2 \int \left[ \int K(x - y) (\log \sigma_2(x) + \frac{(I(y) - u_2(x))^2}{2\sigma_2^2(x)}) (1 - H_{\varepsilon}(\varphi(y))) dy \right] dx. \quad (3)$$

式(3)由 4 项构成,第 1,2 项是水平集正则项,保证水平集函数在演化中保持为带符号距离函数并平滑;第 3 项和第 4 项为局部二值拟合项,控制活动轮廓演化。可见,能量泛函中一部分开销是用来规范水平集函数的。

LGDF 模型利用均值和方差同时描述局部灰度分布,有效地解决了灰度不均和低对比度图像的分割问题,但同时也增加了计算开销。

## 2 参数化水平集活动轮廓模型

### 2.1 参数化水平集函数

本文采用文献[11]中描述形状的方法,利用参数向量  $\mathbf{W}$  确定水平集函数,而非带符号距离函数。依据析取范式数学理论构建参数化水平集如下:

$$\varphi(x; \mathbf{W}) = 1 - \prod_{i=1}^N \left( 1 - \prod_{j=1}^M \left( 1 - \frac{1}{1 + e^{\sum_{k=0}^n \omega_{ijk} x_k}} \right) \right). \quad (4)$$

式中:水平集函数  $\varphi(x; \mathbf{W})$  由  $N$  个多面体组成,每个多面体由  $M$  个半空间组成;  $n$  为目标轮廓线的维度。参数向量  $\mathbf{W} = [\omega_{ijk}]$  定义目标轮廓,参数  $\omega_{ijk}$  的更新过程就是轮廓线演化过程。

本文将半空间的示性函数改用逻辑 S 型函数的多项式表示:  $1 - \gamma_{ij}(x)$ 。逻辑 S 型函数定义如下:

$$\gamma_{ij}(x) = \frac{1}{1 + e^{\sum_{k=0}^n \omega_{ijk} x_k}}. \quad (5)$$

利用参数  $\omega_{ijk}$  确定的 S 型函数的多项式表示半空间,由半空间构成多面体,由多面体组合成水平集函数。在由参数  $\omega_{ijk}$  构造水平集函数的这一过程中,逻辑 S 型函数的意义在于保证了水平集函数  $\varphi$  的取值范围为  $[0, 1]$ 。

$\varphi(x; \mathbf{W})$  的取值为  $[0, 1]$ ,  $\varphi(x; \mathbf{W}) = 0.5$  的水平集作为前景和背景的分界线,前景区域水平集函数  $\varphi(x; \mathbf{W}) > 0.5$ , 背景区域水平集函数

$\varphi(x; \mathbf{W}) < 0.5$ . 演化过程无需式(3)中的正则项规范水平集函数.

## 2.2 本文参数的确定

参数向量  $\mathbf{W} = [\omega_{ijk}]$  的选取采用交互式的方法实现. 用户根据图像在感兴趣区域定义  $N$  个种子点, 即多面体. 利用这些多面体初始化水平集函数  $\varphi$ , 每个多面体由  $M = p \times q$  个半空间构成. 多面体近似为固定半径的球, 定义为

$$\omega_{ijk} = \begin{cases} \cos\theta_p \sin\varphi_q, & k=0; \\ \sin\theta_p \sin\varphi_q, & k=1; \\ \cos\varphi_q, & k=2; \\ -(r + C_{i_x} \cos\theta_p \sin\varphi_q + \\ C_{i_y} \sin\theta_p \sin\varphi_q + C_{i_z} \cos\varphi_q), & k=3. \end{cases} \quad (6)$$

式中:  $r$  为小圆半径;  $C_{i_x}$ ,  $C_{i_y}$  和  $C_{i_z}$  为小球的中心坐标;  $\theta_p = \frac{\pi}{4}p$ ,  $\varphi_q = \frac{\pi}{4}q$ , 在形状描述中依据形状描述理论及实验效果通常选取 32 个半空间, 故  $p = 1, \dots, 8$ ,  $q = 1, \dots, 4$ . 利用不同  $\theta_p$  和  $\varphi_q$  的组合得到参数  $\omega_{ijk}$ .

## 2.3 能量泛函的建立

将参数化水平集函数  $\varphi(x; \mathbf{W})$  引入到经典活动轮廓模型 LGDF 中, 本文定义的参数水平集函数取值为从 0 到 1 之间的数值, 而非传统的符号距离函数, 因此在数据拟合项中引入  $\varphi(x; \mathbf{W})$  近似 LGDF 中的  $H_\varepsilon(\varphi(y))$ , 引入  $1 - \varphi(x; \mathbf{W})$  近似 LGDF 中的  $1 - H_\varepsilon(\varphi(y))$ , 将演化曲线内外两部分的积分项统一定义于全局图像, 同时控制两部分积分项在水平集演化过程中的主导作用. 参数化水平集能量泛函定义如下:

$$\begin{aligned} \mathcal{E}(\mathbf{W}) = & \lambda_1 \int \left[ \int K(x-y) (\log\sigma_1(x) + \frac{(I(y) - u_1(x))^2}{2\sigma_1^2(x)}) \cdot \right. \\ & \left. \varphi(x; \mathbf{W}) dy \right] dx + \lambda_2 \int \left[ \int K(x-y) (\log\sigma_2(x) + \right. \\ & \left. \frac{(I(y) - u_2(x))^2}{2\sigma_2^2(x)}) (1 - \varphi(x; \mathbf{W})) dy \right] dx. \quad (7) \end{aligned}$$

式中:  $\lambda_1$  和  $\lambda_2$  是非负常数;  $K(x-y)$  为高斯窗;  $I(y)$  为  $y$  点像素值;  $u_1(x)$  和  $u_2(x)$  表示轮廓线内、外部的局部均值;  $\sigma_1(x)$  和  $\sigma_2(x)$  表示轮廓线内、外部的局部方差. 各量分别定义如下:

$$u_1(x) = \frac{\int K(y-x) I(y) H(\varphi - 0.5) dy}{\int K(y-x) H(\varphi - 0.5) dy}, \quad (8)$$

$$u_2(x) = \frac{\int K(y-x) I(y) (1 - H(\varphi - 0.5)) dy}{\int K(y-x) (1 - H(\varphi - 0.5)) dy}, \quad (9)$$

$$\sigma_1^2(x) =$$

$$\frac{\int K(x-y) (I(y) - u_1(x))^2 H(\varphi - 0.5) dy}{\int K(x-y) H(\varphi - 0.5) dy}, \quad (10)$$

$$\sigma_2^2(x) =$$

$$\frac{\int K(x-y) (I(y) - u_2(x))^2 (1 - H(\varphi - 0.5)) dy}{\int K(x-y) (1 - H(\varphi - 0.5)) dy}. \quad (11)$$

本文参数化水平集函数  $\varphi$  在演化过程无需重新初始化和附加的正则化项. 与式(3)相比, 精简了能量泛函, 降低了计算开销.

## 2.4 能量最小化

能量最小化过程即图像分割过程, 利用梯度下降流法实现:

$$\frac{\partial \mathcal{E}}{\partial \omega_{ijk}} = (\lambda_1 e_1 - \lambda_2 e_2) \frac{\partial \varphi}{\partial \omega_{ijk}}. \quad (12)$$

式中:

$$e_1(x) = \int K(x-y) (\log\sigma_1(x) + \frac{(I(y) - u_1(x))^2}{2\sigma_1^2(x)}) dy; \quad (13)$$

$$e_2(x) = \int K(x-y) (\log\sigma_2(x) + \frac{(I(y) - u_2(x))^2}{2\sigma_2^2(x)}) dy; \quad (14)$$

$$\frac{\partial \varphi}{\partial \omega_{ijk}} = x_k \cdot [1 - A_{ij}(x; \mathbf{W})] \cdot$$

$$\prod_{l=1}^M A_{il}(x; \mathbf{W}) \cdot \prod_{r \neq i, r=1}^N B_r(x; \mathbf{W}). \quad (15)$$

其中:

$$A_{ij}(x; \mathbf{W}) = 1 - \frac{1}{1 + e^{\sum_{k=0}^n x_k \omega_{ijk}}}; \quad (16)$$

$$B_i(x; \mathbf{W}) = 1 - \prod_{j=1}^M A_{ij}(x; \mathbf{W}). \quad (17)$$

在迭代过程中判别参数向量  $\mathbf{W}$  不断更新, 水平集函数随之演化, 当能量最小时, 判别参数最优,  $\varphi(x; \mathbf{W}) = 0.5$  水平集对应的是最终分割轮廓线. 判别参数更新公式如下:

$$\omega_{ijk} \leftarrow \tau \frac{\partial \mathcal{E}}{\partial \omega_{ijk}} - \omega_{ijk}. \quad (18)$$

式中,  $\tau$  为步长. 本文所提出的参数水平集方法不受 CFL 标准的限制, 可以选择较大步长加速收敛.

### 3 实验结果

为使本文算法的分割效果达到最优,对本文中算法中参数的选取进行了实验测试.为了验证算法的有效性和高效性,选用多幅医学图像进行测试,与 LGDF 和文献[10]中快速算法 MSLCV 进行了对比.实验在 PC 机上 MATLAB2013 环境下进行,配置为英特尔 CPU 3.20, 4 GB 内存, Windows7 操作系统.在实验中,针对分割图像的特征以及参数的实际数学物理意义,结合实验测试结果选取最佳的参数作为实验中各算法的最终参数. LGDF 模型弧长项系数设置为 0.05,水平集正则项参数设置为 1,步长 0.1. MSLCV 模型弧长项系数为 0.2,形状约束系数为 0.6,步长 0.1. 本文中算法中多面体个数  $N$  取 5,半空间个数  $M$  取 32,步长 0.3.

选择了乳腺结节超声图像进行参数选择的实验测试.图 1 所示为选用不同数量  $N$  的多面体来构造水平集对左侧乳腺结节的超声图像进行分割的结果图.通过对比  $N(1, 2, 3, 4, 5, 6)$  个多面体的分割结果,可以看出,在  $N=3$  时就可以分割出大部分信息;当  $N=5$  时,分割结果接近完美;当  $N=6$  时,效果没有明显提升.因此本文以下的测试中  $N$  取 5.

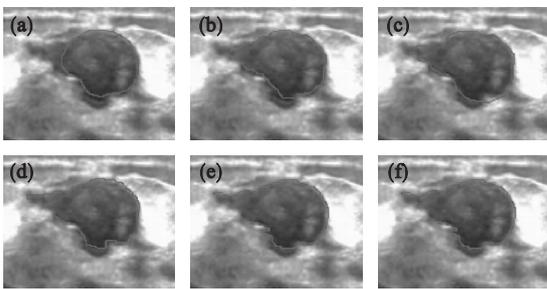


图 1 不同  $N$  值乳腺结节超声图像分割结果

Fig. 1 Segmentation of breast nodule ultrasound images with different  $N$  values

(a)— $N=1$ ; (b)— $N=2$ ; (c)— $N=3$ ;  
(d)— $N=4$ ; (e)— $N=5$ ; (f)— $N=6$ .

图 2 是三种算法对左心室超声图像的分割.由图 2 可见,本文算法的分割效果最好,对图像左下角的狭长处进行了精准的分割,MSLCV 算法略优于 LGDF.

图 3 所示为利用三种算法对左心室核磁图像进行分割.由图 3 可见,本文算法和 MSLCV 算法分割结果相近,优于 LGDF,在图像右下角的边界模糊处分割效果好.

图 4 是三种方法对脑瘤 CT 图像的分割.由图 4 可见,本文算法对肿瘤的分割效果好于 MSLCV 和

LGDF,对肿瘤左上角的低对比度处分割细致.

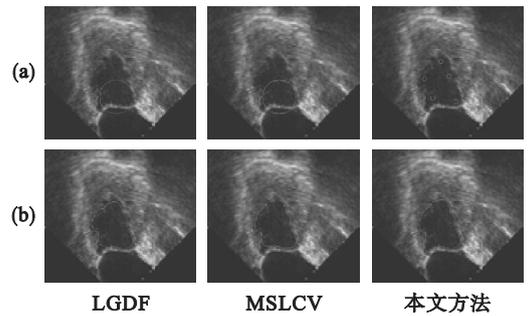


图 2 左心室超声图像分割

Fig. 2 Segmentation of left ventricle ultrasound images

(a)—初始轮廓; (b)—分割结果.

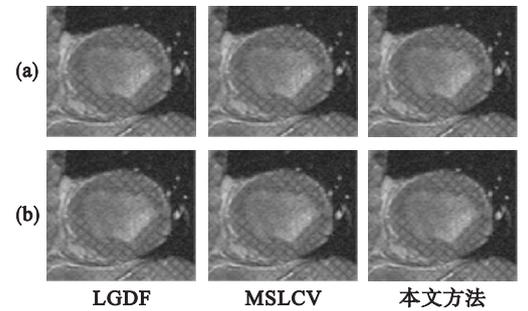


图 3 左心室磁共振图像分割

Fig. 3 Segmentation of left ventricle MR images

(a)—初始轮廓; (b)—分割结果.

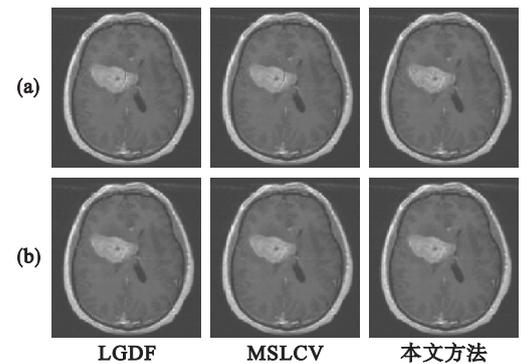


图 4 脑瘤 CT 图像分割

Fig. 4 Segmentation of brain tumor CT images

(a)—初始轮廓; (b)—分割结果.

图 5 所示为边界不规则的乳腺癌实性包块分割,包块有多发狭长的蟹足状边界.

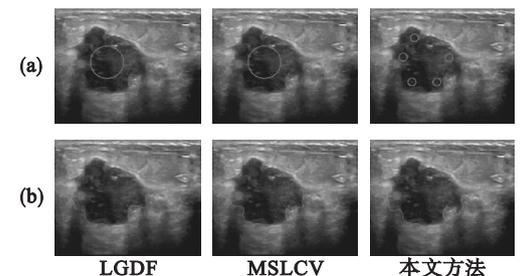


图 5 乳腺癌实性包块超声图像分割

Fig. 5 Segmentation of solid masses of breast cancer ultrasound images

(a)—初始轮廓; (b)—分割结果.

由图 5 可见, LGDF 和 MSLCV 分割效果相近, 对大部分蟹足状组织分割失败. 本文算法明显优于 LGDF 和 MSLCV, 成功分割出多发的狭长的蟹足状边界.

为了定量地评估算法的分割精度, 用 Dice 相似系数(DSC)与均方差和(MSSD)两个指标进行统计, 见表 1. DSC 值越接近 1 分割效果越好, MSSD 值越接近 0 分割效果越好<sup>[12]</sup>.

表 1 分割精度比较

Table 1 Comparison of segmentation accuracy

图 像	LGDF 算法		MSLCV 算法		本文算法	
	DSC	MSSD	DSC	MSSD	DSC	MSSD
图 2	0.915	67.59	0.917	52.87	0.962	10.89
图 3	0.892	112.24	0.938	35.42	0.942	33.61
图 4	0.928	43.57	0.931	38.65	0.951	15.72
图 5	0.878	143.87	0.886	107.54	0.958	16.09
均值	0.903	91.82	0.918	66.35	0.953	19.08

由表 1 可见, 本文算法的分割精度较好. 这是由于本文算法所采用的参数化水平集和初始轮廓选取准确地表达了轮廓曲线及目标区域的细节.

对各算法的计算效率进行了比较, 见表 2.

表 2 分割效率比较

Table 2 Comparison of segmentation efficiency

图 像	LGDF 算法		MSLCV 算法		本文算法	
	迭代 次数	计算 时间/s	迭代 次数	计算 时间/s	迭代 次数	计算 时间/s
图 2	500	25.41	60	18.36	40	10.29
图 3	800	47.57	120	28.13	60	18.04
图 4	250	17.92	50	10.03	20	8.76
图 5	600	56.41	100	29.53	50	17.32
均值	537	36.83	83	21.51	43	13.60

由表 2 可见, 本文算法迭代次数最少, 耗时最少. 计算速度比 LGDF 提高了近 63%, 比 MSLCV 提高了近 36%. 这是由于本文算法采用的参数化水平集函数不是带符号距离函数, 无需其他两种算法中的正则项, 也没有产生高一阶的运算, 降低了计算开销, 提高了计算速度. 本文算法的迭代步长不受 CFL 限制, 采用较大步长减少了迭代次数. 初始化的形式更加具有针对性, 加速了曲线向真实轮廓演化.

## 4 结 论

本文为解决传统水平集活动轮廓模型在分割图像时计算量大、计算速度慢的问题, 提出了参数化水平集活动轮廓模型分割算法. 该算法利用参数向量确定水平集函数, 无需高一阶的带符号距离函数, 在不附加正则项的情况下可以有效分割核磁、超声等医学图像. 与 LGDF 和 MSLCV 算法相比, 本文算法分割精度有所提高, 计算速度比 LGDF 提高了近 63%, 比 MSLCV 提高了近 36%.

## 参考文献:

- [1] Kass M, Witkin A, Terzopoulos D. Snakes: active contour model[J]. *International Journal of Computer Vision*, 1988, 1(4):321-331.
- [2] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. *International Journal of Computer Vision*, 1997, 22(1):61-79.
- [3] Chan T, Vese L. Active contours without edges[J]. *IEEE Transactions on Image Processing*, 2001, 10(2):266-277.
- [4] Li C, Kao C, Gore J, et al. Implicit active contours driven by local binary fitting energy[C]//IEEE Conference on Computer Vision and Pattern Recognition. Minneapolis, 2007:1-7.
- [5] Li C, Kao C, Gore J, et al. Minimization of region-scalable fitting energy for image segmentation[J]. *IEEE Transactions on Image Processing*, 2008, 17(10):1940-1949.
- [6] 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.
- [7] 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[J]. *IEEE Transactions on Image Processing*, 2011, 20(7):2007-2016.
- [8] Sethian J. A fast marching level set method for monotonically advancing fronts[C]//Proceedings of the National Academy of Sciences. Washington D C, 1996:1591-1595.
- [9] Osher S, Burger M, Goldfarb D, et al. An iterative regularization method for total variation-based image restoration[J]. *Multi-scale Modeling and Simulation*, 2005, 4(2):460-489.
- [10] Liao X, Yuan Z, Zheng Q, et al. Multi-scale and shape constrained localized region-based active contour segmentation of uterine fibroid ultrasound image in HIFU therapy[J]. *PLoS One*, 2014, 9(7):303-334.
- [11] Ramesh N, Mesadi F, Cetin M, et al. Disjunctive normal shape models[C]//Proceedings of the IEEE International Symposium on Biomedical Imaging. New York, 2015:1535-1539.
- [12] Dietenbeck T, Alessandrini M, Friboulet D, et al. CREASEG: a free software for the evaluation of image segmentation algorithms based on level-set[C]//Proceedings of the IEEE International Conference on Image Processing. Hong Kong, 2010:665-668.