

结合全局概率密度差异与局部灰度拟合的超声图像分割

刘博¹ 黄剑华¹ 唐降龙¹ 刘家锋¹ 张英涛¹

摘要 由于超声图像具有高噪声、低对比度、边缘模糊不清等特点, 超声图像的分割成为图像处理领域中一个难度较高、亟待解决的问题. 本文提出了一种结合全局概率密度差异与局部灰度拟合的主动轮廓模型对超声图像进行分割的方法. 该方法分别在原始超声图像与预处理图像上利用了图像的全局和局部信息. 在原始图像上, 利用各区域的灰度分布, 并结合超声图像的背景知识对图像的全局信息建模. 为了考虑图像的局部信息, 首先对图像进行预处理, 在预处理图像上, 利用局部灰度拟合模型对图像中的局部信息进行建模. 通过分别在不同图像上对全局和局部信息建模的方式, 本方法将利用 Speckle 噪声与去除 Speckle 噪声的分割思想结合在一起. 本文提出的方法分别在模拟和临床超声图像上进行了实验. 实验结果证明, 该方法对图像中的噪声具有较好的适应性, 并对初始条件不敏感, 可以准确地对超声图像进行分割.

关键词 图像分割, 主动轮廓, 水平集, 超声图像

DOI 10.3724/SP.J.1004.2010.00951

Combining Global Probability Density Difference and Local Gray Level Fitting for Ultrasound Image Segmentation

LIU Bo¹ HUANG Jian-Hua¹ TANG Xiang-Long¹ LIU Jia-Feng¹ ZHANG Ying-Tao¹

Abstract Because of low signal-noise ratio (SNR), low contrast and blurry boundaries, the segmentation of ultrasound image becomes a difficult problem in the digital image processing field. In this paper, a novel active contour model combining global probability density difference and local gray level fitting is proposed for the segmentation of ultrasound image. In the proposed model, global information and local information are extracted in original ultrasound image and pre-processed image, respectively. In the original ultrasound image, by combining the background knowledge the distributions of gray levels of different regions are utilized for modeling the global information. For considering the local information, the ultrasound image is pre-processed, and in the pre-processed image, the local gray level fitting model is utilized for modeling the local information. By modeling the global and the local information in different images, the proposed method combines both approaches that utilize and remove speckle noise. With both simulated and clinical ultrasound images, the experimental results demonstrate that the proposed method is adaptive to the noise and robust to the initial conditions, and that it can segment ultrasound image accurately.

Key words Image segmentation, active contour, level set, ultrasound imaging

超声图像分割是计算机辅助诊断 (Computer aided diagnosis, CAD) 系统中的一个重要组成部分, 其作用是对超声图像进行分割, 标定图像中的病灶部位, 为对病灶部位的特征提取、诊断和分类提供必要条件^[1]. 由于超声图像具有高噪声、低对比度、边缘模糊不清等特点, 超声图像的分割成为图像处理领域中一个难度较高、亟待解决的问题. 目前的研究中, 所采用的方法大致可以分为以下几类: 马尔可夫随机场 (Markov random field, MRF) 方法^[2], 分水岭 (Watershed) 方法^[3], 区域增长 (Region growing) 方法^[4-5], 神经网络 (Neural network) 方法^[6],

主动轮廓 (Active contour) 方法^[5, 7-9] 等. 但是当前的超声图像分割方法仍然存在一些问题:

1) 超声图像中存在大量的 Speckle 噪声. 在目前的研究中, 对于 Speckle 噪声的处理仍存在一定争议^[1]. 一方面, Speckle 噪声会降低超声图像的质量, 使分割的难度加大. 基于此, 目前一些研究中提出先对超声图像进行降噪处理, 然后对降噪后的图像进行分割的处理方式, 减小 Speckle 噪声对分割方法的影响^[3, 5]. 但是, 在目前的研究中, 去除噪声和保留图像细节仍是一个两难的问题. 另一方面, 由于 Speckle 噪声能在一定程度上反映图像中不同人体组织区域的特征, 故在一些分割方法中, Speckle 噪声也作为一种有用的信息被利用, 如马尔可夫随机场方法^[2]、神经网络方法^[6]、主动轮廓方法^[9] 等.

2) 基于模型的分割方法 (如马尔可夫随机场方法、主动轮廓方法) 可以将图像信息与相邻像素之间的关系方便地融入代表模型的能量泛函中, 通过寻找能量泛函的最小 (大) 值点完成对图像的分割.

收稿日期 2009-01-14 录用日期 2009-05-11
Manuscript received January 14, 2009; accepted May 11, 2009
国家自然科学基金 (60873142), 黑龙江省青年自然科学基金 (QC08C20) 资助

Supported by National Natural Science Foundation of China (60873142) and Natural Science Foundation of Heilongjiang Province for Young Scientist (QC08C20)

1. 哈尔滨工业大学计算机学院 哈尔滨 150001
1. Department of Computer, Harbin Institute of Technology, Harbin 150001

由于考虑了各像素之间的关系, 基于模型的分割方法对噪声具有较高的健壮性, 较之其他方法更适合于超声图像的分割. 但是, 基于模型的分割方法经常受模型初值的影响: 不合适的初值会使模型收敛到不合适的局部最小值点, 影响分割的效果; 或者增加模型的迭代次数, 延长算法的运行时间^[2].

为了解决上述问题, 本文采用一种新颖的基于水平集 (Level set) 的主动轮廓模型对超声图像进行分割. 水平集方法首先由 Osher 等^[10] 提出, Malladi 等^[11] 将其首先应用于图像分割. 不同于 Kass 提出的主动轮廓模型^[12], 基于水平集的主动轮廓模型将图像中不同区域之间的边界作为零水平集嵌入定义在图像区域上的高一维的水平集函数中, 并利用对水平集函数的演化代替传统的主动轮廓模型中对图像上不同区域间的边界曲线的演化, 最终得到的零水平集隐含地表示图像上的边界位置.

本文提出的主动轮廓模型结合图像中的全局和局部信息建立能量泛函. 一方面, 通过考虑原始超声图像的各区域中灰度的概率密度分布与超声图像中各区域灰度分布的背景知识, 建立一种全新的关于超声图像中全局灰度信息的能量泛函. 此种能量泛函基于概率密度差异, 建立了超声图像中各区域内的灰度分布与超声图像的背景知识之间的联系. 另一方面, 利用基于二维一致性直方图的超声图像降噪方法^[13], 对超声图像进行预处理; 在预处理后的图像上, 利用区域灰度拟合模型^[14] 对局部灰度信息建模. 通过在原始图像和预处理图像上分别考虑图像的全局与局部信息, 本文提出的模型将利用 Speckle 噪声与去除 Speckle 噪声的思想有机地结合在一起, 更加适用于超声图像的分割.

1 结合概率密度差异与局部灰度拟合的主动轮廓模型

1.1 分割模型概述

设超声图像 I 是定义在区域 $\Omega \subset \mathbf{R}^2$ 上的正实函数. 将图像分为两类区域, 即前景区域和背景区域, 分别定义为 Ω_i 和 Ω_e , 其中 $\Omega_i \cup \Omega_e = \Omega$, $\Omega_i \cap \Omega_e = \emptyset$. 定义水平集函数 $\phi: (0, \infty) \times \Omega \rightarrow \mathbf{R}$, 将 Ω_i 和 Ω_e 分别表示为点集 $\{(x, y) | \phi(x, y) > 0, (x, y) \in \Omega\}$ 和 $\{(x, y) | \phi(x, y) < 0, (x, y) \in \Omega\}$, 区域边界隐含地表示为点集 $\{(x, y) | \phi(x, y) = 0, (x, y) \in \Omega\}$.

分割模型由如下的能量泛函表示:

$$E(\phi) = \alpha \cdot E_R(\phi) + \beta \cdot E_L(\phi) + \gamma \cdot E_C(\phi) + \rho \cdot E_P(\phi) \quad (1)$$

其中, E_R 用于描述原始超声图像中各区域内灰度的概率分布密度, 对图像的全局信息建模; E_L 用于

描述预处理图像中的局部灰度变化, 对图像的局部信息建模; E_C 用于控制边界曲线的长度, 防止过分割^[15]; E_P 用于控制水平集函数的演化过程^[16]; α , β , γ , ρ 分别是上述各项的权值, 为预先设置的正实数. 以下分别对模型中的各项进行详细说明.

1.2 基于概率密度差异的图像全局信息模型

本文采取利用 Speckle 噪声的方式, 针对图像的全局信息建立分割模型. 在原始图像中, 本文将各区域灰度的概率分布密度作为各区域的全局信息, 通过考虑关于 Speckle 噪声的先验知识, 建立各区域灰度的概率分布密度和先验知识之间的关系, 将分割问题转化为最小化概率密度差异问题, 从而建立基于全局信息的能量泛函.

定义在前景区域 Ω_i 和背景区域 Ω_e 中的灰度的概率分布密度分别为 p_i 和 p_e . 假设对于每个区域, 根据背景知识, 在区域内部灰度的概率分布密度具有一定的先验形式, 并可以通过某种概率密度估计方法 (如最大似然法、期望最大化 (Expectation maximization, EM) 方法等) 估计出来, 则可以定义前景和背景区域灰度的估计概率分布密度为 p_i^E 和 p_e^E . 由此, E_R 项可以表示为如下的泛函:

$$E_R(\phi) = A_i \cdot D(p_i, p_i^E) + A_e \cdot D(p_e, p_e^E) \quad (2)$$

其中, $D(p, p^E)$ 为概率密度 p 和 p^E 之间的差异, 由式 (3) 来度量:

$$D(p, p^E) = \sum_{g=0}^{255} p(g) (p(g) - p^E(g))^2 \quad (3)$$

A_i 和 A_e 分别为 Ω_i 和 Ω_e 区域的面积, 作为各区域内概率密度差异的权值, 其作用是防止在分割过程中过分考虑较小区域的概率密度差异而影响分割的整体效果: $A_i = \iint_{\Omega_i} dx dy$, $A_e = \iint_{\Omega_e} dx dy$. 此能量泛函的意义是: 寻找一个水平集函数 ϕ , 将图像分为 Ω_i 和 Ω_e 两部分, 使图像各区域中灰度的概率分布密度与通过先验知识估计得到的灰度概率分布密度之间的差异的加权总和最小. 这一能量泛函建立了各区域灰度的实际分布与背景知识之间的关系, 使各区域中的灰度分布更符合超声图像的背景知识, 从而可以更加合理地分割超声图像.

实际概率分布密度 p_i 和 p_e 分别由式 (4) 和 (5) 计算:

$$p_i(\phi, g) = \frac{\iint_{\Omega_i} \delta(I_{x,y} - g) dx dy}{A_i} \quad (4)$$

$$p_e(\phi, g) = \frac{\iint_{\Omega_e} \delta(I_{x,y} - g) dx dy}{A_e} \quad (5)$$

其中, $\delta(\cdot)$ 为 Delac 函数, g 为灰度等级, $I_{x,y}$ 为原

始图像中 (x, y) 点的灰度.

灰度的估计概率分布密度 p_i^E 和 p_e^E 可以由概率密度估计方法和超声图像中各区域内灰度分布的先验知识进行计算. 根据文献 [17], 在超声图像中, 由于 Speckle 噪声影响, 各区域在图像中的灰度分布可以表示为具有不同参数 σ^2 的 Rayleigh 分布: $p_{\text{Rayleigh}}(I, \sigma^2) = (I/\sigma^2) \cdot \exp(-I^2/2\sigma^2)$. 本文中, 利用此种概率密度分布形式描述各区域灰度的估计概率分布密度. 根据最大似然法, 每个区域上的似然函数可以定义为: $L_j = \prod_{(x,y) \in \Omega_j} p_{\text{Rayleigh}}(I_{x,y}, \sigma_j^2)$, $j \in \{i, e\}$, 通过计算可以得到使似然函数最大的参数 σ_j^2 :

$$\sigma_j^2 = \frac{\iint_{\Omega_j} I_{x,y}^2 dx dy}{2A_j}, j \in \{i, e\} \quad (6)$$

利用式 (6), 即可确定由 ϕ 定义的各区域中灰度的估计概率分布密度.

将 Heavyside 函数 $H(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases}$ 和 ϕ

引入式 (2) 和 (3), $E_R(\phi)$ 可以重新写成式 (7) 的形式 (见本页下方).

1.3 图像预处理与局部信息模型

如前所述, 本文采用先进行预处理、后分割的方式对图像的局部信息建立分割模型. 这里首先提出原始超声图像的预处理方法.

预处理分为两步. 首先使用基于二维一致性直方图和方向均值滤波的图像降噪方法^[13] 去除超声图像中的噪声. 该方法的主要步骤是: 1) 计算各像素的一致性 (Homogeneity) 值, 建立二维一致性直方图; 2) 在二维一致性直方图上通过最大模糊熵方法将所有像素分为两类, 即一致性的点和非一致性的点; 3) 对非一致性的点通过方向均值滤波器进行处理.

对超声图像进行降噪后, 采用模糊化方法增强降噪后图像的对比度. 设原始图像 I 降噪后得到的图像为 I^D , 定义 I^D 为一个模糊集, 其模糊关系为 S 函数^[18] (式 (8)), 其中参数 a, b, c 通过最大模糊熵方法决定. 在本文中, 模糊熵由式 (9) 定义^[19]. 通过寻找使式 (9) 最大的参数 a, b, c , 即可确定模糊关系. 将图像导入模糊域, 完成图像的预处理. 预处理

后的图像定义为 I^P (M, N 分别为图像的长度和宽度).

$$\mu(I^D, a, b, c) = \begin{cases} 0, & 0 \leq I \leq a \\ \frac{(I^D - a)^2}{(b - a)(c - a)}, & a < I \leq b \\ 1 - \frac{(I^D - c)^2}{(c - b)(c - a)}, & b < I \leq c \\ 1, & I > c \end{cases} \quad (8)$$

$$H(\mu) = \frac{1}{M \times N} \sum_{i=1}^M \sum_{j=1}^N S_n(\mu(I_{x,y}^D)) \quad (9)$$

式中, $S_n(\mu(I_{x,y}^D)) = -\mu(I_{x,y}^D) \log_2 \mu(I_{x,y}^D) - (1 - \mu(I_{x,y}^D)) \log_2(1 - \mu(I_{x,y}^D))$.

图像预处理的效果如图 1 所示. 由图 1 中可以看出, 预处理可以大大降低 Speckle 噪声, 提高对比度, 有利于对图像中的局部信息建立模型.



(a) 原始超声图像 (b) 降噪后图像 (c) 预处理图像
(a) Original (b) De-noised (c) Pre-processed

图 1 超声图像的预处理

Fig. 1 Pre-processing of an ultrasound image

Li 等^[14] 提出了一种可放缩区域拟合 (Region-scalable fitting, RSF) 模型对医学图像进行分割, 本文利用其对预处理图像中的局部灰度信息建模. 根据 Li 等提出的模型, E_L 项可以写成式 (10) 的形式 (见本页下方). 式 (10) 中, $K_\sigma(\cdot)$ 为高斯核, $d_{x',y'}$ 是点 (x, y) 与点 (x', y') 之间的距离, $f^i = \frac{K_\sigma * (H(\phi) I^P)}{K_\sigma * H(\phi)}$, $f^e = \frac{K_\sigma * ((1 - H(\phi)) I^P)}{K_\sigma * (1 - H(\phi))}$. 文献 [14] 中提出, 参数 σ 可以控制 RSF 模型考虑图像中每点周围信息的临域范围 (σ 值越大, 则对每点考虑的邻域范围越大). 由于在本文中, E_L 项着重于处理临床超声图像中的局部灰度信息, 根据文献 [14] 的研究, 采用较小的 σ 值.

$$E_R(\phi) = \sum_{j \in \{i, e\}} \iint_{\Omega} (p_j(I_{x,y}) - p_j^E(I_{x,y}))^2 M_j(\phi_{x,y}) dx dy, \quad M_j(\phi_{x,y}) = \begin{cases} H(\phi_{x,y}), & j = i \\ 1 - H(\phi_{x,y}), & j = e \end{cases} \quad (7)$$

$$E_L(\phi) = \iint_{\Omega} \left(\sum_{j \in \{i, e\}} \iint_{\Omega} K_\sigma(d_{x',y'}) (I_{x',y'}^P - f_{x,y}^j)^2 M(\phi_{x',y'}) dx' dy' \right) dx dy \quad (10)$$

1.4 过分割与水平集演化的控制

为了防止过分割, 在模型中引入前景与背景区域间边界曲线的长度项 $E_C^{[15]}$:

$$E_C(\phi) = \iint_{\Omega} |\nabla H(\phi_{x,y})| dx dy \quad (11)$$

通过控制边界曲线的长度, 可以防止分割过程中产生过多细小区域, 抑制过分割现象.

为了在最小化能量泛函的过程中控制水平集函数的演化, 防止水平集函数变得过平或过陡, 影响分割过程, Li 等^[16] 提出了一种无重新初始化 (Non re-initialization) 的演化控制方法. 本文采用此种方法, 引入控制项 E_P , 控制水平集函数的演化:

$$E_P(\phi) = \iint_{\Omega} \frac{1}{2} (|\nabla \phi_{x,y}| - 1)^2 dx dy \quad (12)$$

1.5 能量泛函的最小化

将式 (7), (10)~(12) 代入式 (1), 利用梯度下降法, 可以得到水平集函数的演化方程 (13) (见本页下方).

式 (13) 中, \mathbf{n} 为图像边界 $\partial\Omega$ 的外法向量, $\frac{\delta(\phi)}{|\nabla\phi|} \cdot \frac{\partial\phi}{\partial\mathbf{n}} = 0$ 为方程 (13) 的边界条件^[15]; p_i 和 p_e 由式 (4) 和 (5) 确定, p_i^E 和 p_e^E 由式 (6) 确定, e_i 和 e_e 由式 (14) 确定:

$$e_j = \iint_{\Omega} K_{\sigma}(d_{x',y'}) (I_{x',y'}^P - f_{x',y'}^j)^2 dx' dy', \quad j \in \{i, e\} \quad (14)$$

$\phi^0(x, y)$ 是 ϕ 的初始条件, 由式 (15) 确定:

$$\phi_{x,y}^0 = \begin{cases} -c_0, & (x,y) \in \Omega_0 - \partial\Omega_0 \\ 0, & (x,y) \in \partial\Omega_0 \\ c_0, & (x,y) \in \Omega - \Omega_0 \end{cases} \quad (15)$$

其中, c_0 为常数, 在实验中设为 4.0; $\partial\Omega_0$ 是初始边界, 在实验中, 采用了式 (16) 和 (17) 两种条件.

为便于计算, 将方程 (13) 离散化. 首先, 将 $\delta(\cdot)$ 近似为 $\delta_{\varepsilon}(z) = \frac{1}{\pi} \cdot \frac{\varepsilon}{\varepsilon^2 + z^2}$ ^[15], 其中, 参数 ε 的值设为 1.0.

利用中心差分对方程 (13) 进行离散化:

$$\begin{aligned} \frac{\phi_{i,j}^{n+1} - \phi_{i,j}^n}{\Delta t} &= \delta_{\varepsilon}(\phi) \left[-\alpha \cdot (p_i - p_i^E)^2 + \alpha \cdot (p_e - p_e^E)^2 - \beta \cdot e_i + \beta \cdot e_e + \gamma \cdot K_{i,j} \right] + \rho \cdot (L_{i,j} - K_{i,j}) \\ K_{i,j} &= D_{i,j}^{0x} \cdot \left(\frac{D_{i,j}^{0x} \phi}{\sqrt{(D_{i,j}^{0x} \phi)^2 + (D_{i,j}^{0y} \phi)^2}} \right) + D_{i,j}^{0y} \cdot \left(\frac{D_{i,j}^{0y} \phi}{\sqrt{(D_{i,j}^{0x} \phi)^2 + (D_{i,j}^{0y} \phi)^2}} \right) \\ L_{i,j} &= D_{i,j}^{0xx} \phi + D_{i,j}^{0yy} \phi \end{aligned} \quad (18)$$

其中, D^0 为中心差分算子.

由此, 完整的分割算法的步骤如下:

步骤 1. 对超声图像进行预处理.

步骤 2. 利用式 (15) 初始化水平集函数 ϕ .

步骤 3. 根据式 (4)~(6) 和式 (14) 分别计算 $p_i, p_e, p_i^E, p_e^E, e_i$ 和 e_e .

步骤 4. 通过式 (18) 使水平集函数由 ϕ^n 演化为 ϕ^{n+1} , 确定新的分割区域.

步骤 5. 判断水平集函数的演化是否收敛, 如果演化方程没有达到稳定状态 (Steady state), 且没有达到最大迭代次数, 则转到步骤 3, 进行下一次迭代.

$$\begin{cases} \frac{\partial\phi}{\partial t} = \delta(\phi) \left[-\alpha \cdot (p_i - p_i^E)^2 + \alpha \cdot (p_e - p_e^E)^2 - \beta \cdot e_i + \beta \cdot e_e + \gamma \cdot \operatorname{div} \left(\frac{\nabla\phi}{|\nabla\phi|} \right) \right] + \rho \cdot \left(\Delta\phi - \operatorname{div} \left(\frac{\nabla\phi}{|\nabla\phi|} \right) \right) \\ \phi(0, x, y) = \phi^0(x, y) \text{ in } \Omega \\ \frac{\delta(\phi)}{|\nabla\phi|} \cdot \frac{\partial\phi}{\partial\mathbf{n}} = 0 \text{ on } \partial\Omega \end{cases} \quad (13)$$

$$\partial\Omega_0 = \left\{ (x, y) \mid \left(\frac{M}{4} \leq x \leq 3\frac{M}{4}, y = \frac{N}{4} \right) \text{ 或 } \left(\frac{M}{4} \leq x \leq 3\frac{M}{4}, y = 3\frac{N}{4} \right) \text{ 或 } \left(x = \frac{M}{4}, \frac{N}{4} \leq y \leq 3\frac{N}{4} \right) \text{ 或 } \left(x = 3\frac{M}{4}, \frac{N}{4} \leq y \leq 3\frac{N}{4} \right) \right\} \quad (16)$$

$$\partial\Omega_0 = \left\{ (x, y) \mid \sqrt{\left(x - \frac{M}{2} \right)^2 + \left(y - \frac{N}{2} \right)^2} = \min \left(\frac{M}{4}, \frac{N}{4} \right) \right\} \quad (17)$$

2 实验结果

用本文方法对模拟和临床超声图像进行分割, 以下分别对两部分实验进行说明.

2.1 模拟图像分割

本文对 10 幅模拟图像 (图像大小为 256 像素 \times 256 像素) 进行了分割, 各图像的信噪比如表 1 所示.

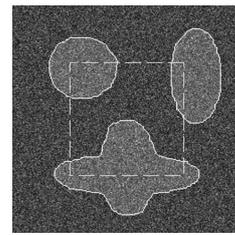
表 1 模拟图像分割结果 (RSE) (%)
Table 1 Segmentation results of simulated images (RSE) (%)

SNR (dB)	本文模型 (式 (16))	本文模型 (式 (17))	文献 [9] 的模型	RSF 模型
1.27	0.29	0.28	0.28	0.28
-0.92	0.30	0.30	0.30	0.30
-2.97	0.29	0.31	0.31	0.32
-5.71	0.39	0.37	0.72	0.44
-6.98	0.44	0.42	0.99	0.57
-7.92	0.54	0.57	1.47	0.64
-8.69	0.53	0.55	1.59	1.05
-9.98	0.62	0.62	2.31	2.05
-11.36	0.74	0.75	4.43	2.51
-12.01	0.79	0.77	4.83	4.39

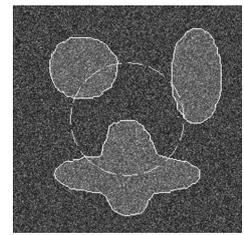
根据文献 [16], 为保证演化过程的稳定, ρ 的值应与迭代步长 Δt 成反比, 且 $\rho \cdot \Delta t$ 应小于 0.25, Δt 应小于 10.0. 在本文中, $\Delta t = 3.0$, $\rho = 0.2/3.0$. 在实验中, 通过选取不同的 α 值, 发现 α 的选取与图像的大小成正比, 可以写成 $\alpha = a \cdot A$, 其中 A 是图像的面积, a 为权值. 在实验中发现, $a > 0.25$ 时, 每次迭代的变化过大, 可能导致分割过程不稳定, 最终选定 $a = 0.1$. β 和 γ 的选择与其和 α 的比值有关. 当 β/α 过大或过小时, 模型将过分强调局部信息, 或对局部信息考虑不足, 导致分割结果不理想. 通过实验, 选定 $\beta = 0.02$. 当 γ/α 过小时, 模型对噪声不能很好地控制, 可能导致过分割现象发生; 当 γ/α 过大时, 模型不能充分考虑图像信息, 使边界收敛到不合理的位置. 由于对模拟图像分割的主要目的是验证本文提出的模型的有效性, 故采用较小的 γ 值, 以使本文提出的结合全局信息和局部信息的分割模型 (即 E_R 项和 E_L 项) 在分割过程中起主要作用, 从而有利于对其特性进行考察. 由此, 选定 $\gamma = 1.5$.

在实验中, 分别采用了式 (16) 和 (17) 作为初始条件, 对图像进行分割. 图 2(a) 和图 2(b) 是本文方法分别采用式 (16) 和式 (17) 作为初始条件, 对信噪比为 -12.01 dB 的模拟图像进行分割的结果 (图

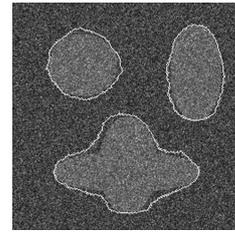
中虚线为 $\partial\Omega_0$ 的位置). 根据结果可以看出, 在不同的初始条件下产生的结果差异很小. 在不同条件下分割结果产生差异的原因是: 由于采用梯度下降法对模型进行优化, 可能使模型收敛于某个局部最小值. 但是, 由于本文的模型可以合理地为目标图像进行建模, 因此在不同初始条件下, 虽然结果可能存在一些差异, 仍可以对图像较为准确地分割. 图 2(c) 和图 2(d) 是文献 [9] 中提出的基于统计的分割模型和 RSF 模型^[14] 对相同图像进行分割的结果. 其中, 使用单一 RSF 模型进行分割时, 考虑存在较强的噪声, 根据 Li 等的研究^[14], 参数 σ 设为 5.0. 通过对比可以看出, 本文方法的分割结果更加准确. 文献 [9] 的模型不能收敛到正确的位置, 而 RSF 模型受噪声影响较大, 产生了过多细小的区域.



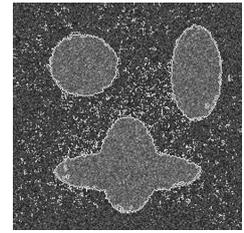
(a) 本文方法的结果 (式 (16))
(a) Result of the proposed method (using (16))



(b) 本文方法的结果 (式 (17))
(b) Result of the proposed method (using (17))



(c) 文献 [9] 模型的结果
(c) Result of the model in [9]



(d) RSF 模型的结果
(d) Result of RSF model

图 2 模拟图像的分割 (-12.01 dB)

Fig. 2 The segmentation of simulated image (-12.01 dB)

由于模拟图像中各区域的位置确定, 模拟图像的分割结果可以用误分率来衡量. 设像素总数为 N_T , 被错分的前景和背景像素分别为 N_I 和 N_E , 则误分率 (Ratio of segmentation error, RSE) 为: $RSE = (N_I + N_E)/N_T$. 分割结果如表 1 所示, 其中第 1 列和第 2 列分别为本文的模型在不同初始条件下的结果, 第 3 列和第 4 列分别为文献 [9] 的模型和 RSF 模型的结果. 由表 1 可以看出, 在信噪比较高的图像上, 文献 [9] 的模型与 RSF 模型和本文模型产生了相似的效果, 但是随着信噪比的降低, 文献 [9] 的模型和 RSF 模型的误分率上升, 这是由于文献 [9] 的模型和 RSF 模型对图像不能合理地建模, 因此当噪声增强时, 不能很好地处理. 而本文的模型

对所有模拟图像的误分率均在 1.0% 以下, 说明本文提出的模型对不同信噪比的模拟图像均有较好的分割效果, 同时, 本文提出的模型对噪声较强, 信噪比较低的图像具有健壮性, 可以有效地处理. 对比表 1 的第 1 列和第 2 列可以看出, 对各信噪比图像, 本文模型在不同初始条件下的结果相近, 这说明虽然可能收敛于不同的局部最小值, 但初始条件对本文方法的影响较小.

2.2 临床图像分割

为了验证本文的方法在医学超声图像上的分割效果, 本文对 50 幅乳腺癌超声图像进行了分割. 由于乳腺癌超声图像中的肿瘤形状大小复杂多变, 图像对比度低, 边缘模糊^[5], 乳腺癌超声图像成为医学超声图像中较难分割的一种. 本文采用的所有乳腺癌超声图像由哈尔滨医科大学附属第二医院超声科提供, 并由超声专家对肿瘤区域进行手工标注, 作为金标准 (Gold standard) 验证分割的效果. 由于各病例的差异, 临床超声图像的大小不同, 长度为 290~370 像素, 高度为 260~320 像素.

由于临床图像的信噪比较低, 同时, 临床图像分割要求分割出的区域尽可能与实际病灶区域相近, 因此应尽量避免过分割现象的产生. 由此, 在对临床图像的分割中选用较大的 γ 值, $\gamma = 5.0$. 其他参数的选定与模拟图像分割相同. 在临床图像的分割中, 采用式 (16) 作为初始条件. 图 3 是本文的方法对图 1 中的超声图像进行分割的结果. 通过对比分割结果 (图 3(b)) 和医生手工标出的肿瘤区域 (图 3(f)) 可以看出, 本文的方法可以准确地分割出图像中的肿瘤区域. 图 3(c)~3(e) 分别是 Chan 等提出的非边界主动轮廓 (Active contour without edges, ACWE) 模型^[15]、文献 [9] 的模型和 RSF 模型^[14]对同一图像的分割结果. 根据分割结果可以看出, ACWE 模型和 RSF 模型不能合理地表述超声图像中各区域的特征, 分割结果不理想. 文献 [9] 的模型考虑了超声图像中各区域的灰度分布, 产生了和本文的方法相似的结果. 但是, 相对本文的方法, 其结果与医生手工标定的区域差异仍相对较大.

图 4 和图 5 分别是对两幅对比度较低、边界模糊的乳腺癌超声图像进行分割的结果. 通过对比医生标定的肿瘤区域可以看出, 本文方法对于对比度较低、边界较模糊的超声图像仍然可以较为准确地分割 (图 4(b), 5(b)). ACWE 模型和 RSF 模型则不能产生理想的分割结果 (图 4(c), 5(c), 4(e), 5(e)). 文献 [9] 的模型对于对比度较低、边界模糊的超声图像同样不能准确地分割, 在分割结果中, 肿瘤区域与周围的一部分正常组织连在一起 (图 4(d), 5(d)).

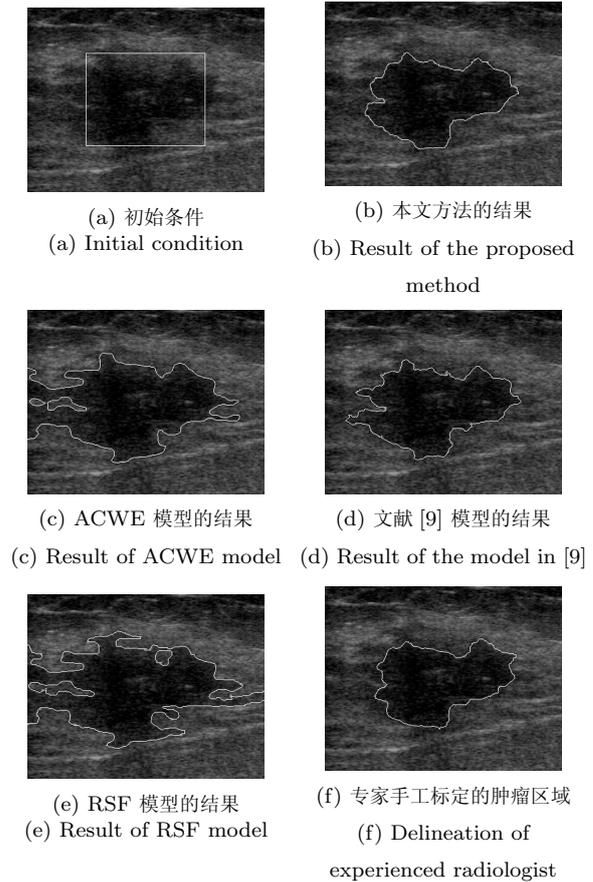


图 3 对图 1 中的乳腺癌超声图像的分割效果

Fig. 3 Results of the case in Fig. 1

图 6 是本文方法采用其他权值进行分割的例子. 图 6(a)~6(c) 分别是采用 $\gamma = 1.0$, $\gamma = 8.0$ 和 $\beta = 0.1$ 对图 3 的图像进行分割的结果. 采用过小的 γ 值 ($\gamma = 1.0$) 时, 分割产生了过多细小的区域和曲折的边界曲线, 即过分割. 而采用过大的 γ 值 ($\gamma = 8.0$), 模型过多考虑了对边界曲线的长度的控制, 使模型不能收敛到准确的肿瘤区域. 采用过大的 β 值 ($\beta = 0.1$) 时, 由于过多考虑了图像的局部信息, 模型同样不能准确地分割出肿瘤区域. 图 6(d) 是采用 $\beta = 0$ 对图 5 的图像进行分割的结果, 可以看出, 由于没有考虑局部信息, 分割出的肿瘤区域错误地包含了正常组织区域.

本文采用真阳性比 (True positive ratio, TP), 假阳性比 (False positive ratio, FP) 和总体相似性度 (Similarity, SI) 三个指标衡量分割结果与专家手工标定的肿瘤区域的差异, 以评价分割效果^[5]:

$$TP = \frac{|A_M \cap A_S|}{|A_M|}$$

$$FP = \frac{|A_M \cup A_S - A_M|}{|A_M|}$$

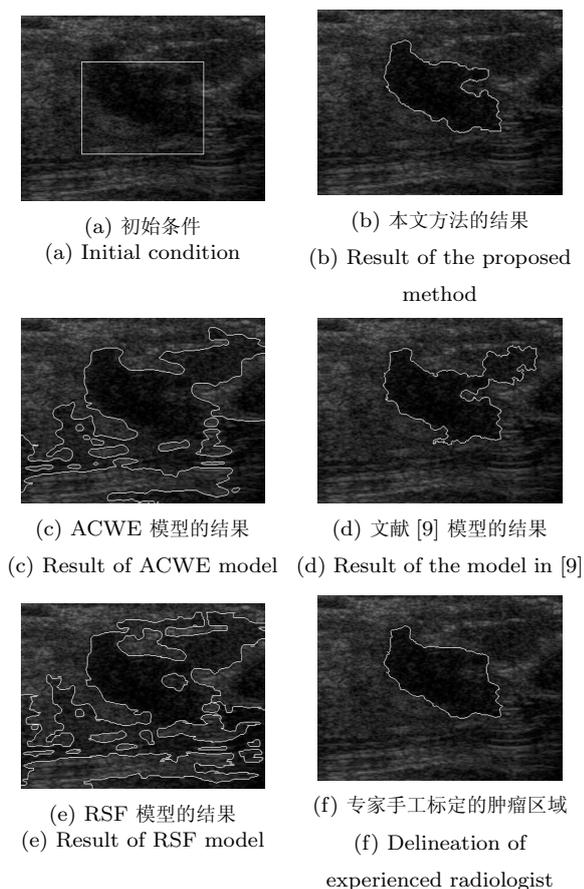


图 4 对比度低、边缘模糊的乳腺癌超声图像的分割效果
Fig. 4 Segmentation results of breast ultrasound image with low contrast and blurry boundaries

$$SI = \frac{|A_M \cap A_S|}{|A_M \cup A_S|}$$

其中, A_S 表示算法分割出的肿瘤区域, A_M 表示医生手工标定的肿瘤区域.

TP 指标越高, 则分割结果覆盖手工标定区域的程度越高; FP 指标越低, 则覆盖的错误区域越少; SI 指标越高则分割结果与手工标定的区域越接近. 表 2 中列出了本文的模型和文献 [9] 的模型对相同的临床超声图像分割的结果. 由结果可以看出, 本文的模型和文献 [9] 的模型在 TP 指标上取得了相似的结果, 结果均大于 90%. 这说明本文的模型和文献 [9] 的模型分割出的肿瘤区域都可以覆盖绝大部分的真实肿瘤区域. 文献 [9] 的模型得到的 TP 指标略高 (相差 0.22%), 这是由于在某些临床超声图像中, 各区域间的边界十分模糊, 难以准确界定. 在这种情况下, 为保证包含完整的肿瘤区域, 医生在手工标定时将肿瘤与周围正常组织间较为模糊的区域包含在肿瘤区域之中. 由于本文的方法可以有效地在模糊区域中找到边界位置, 某些模糊区域没有包含在

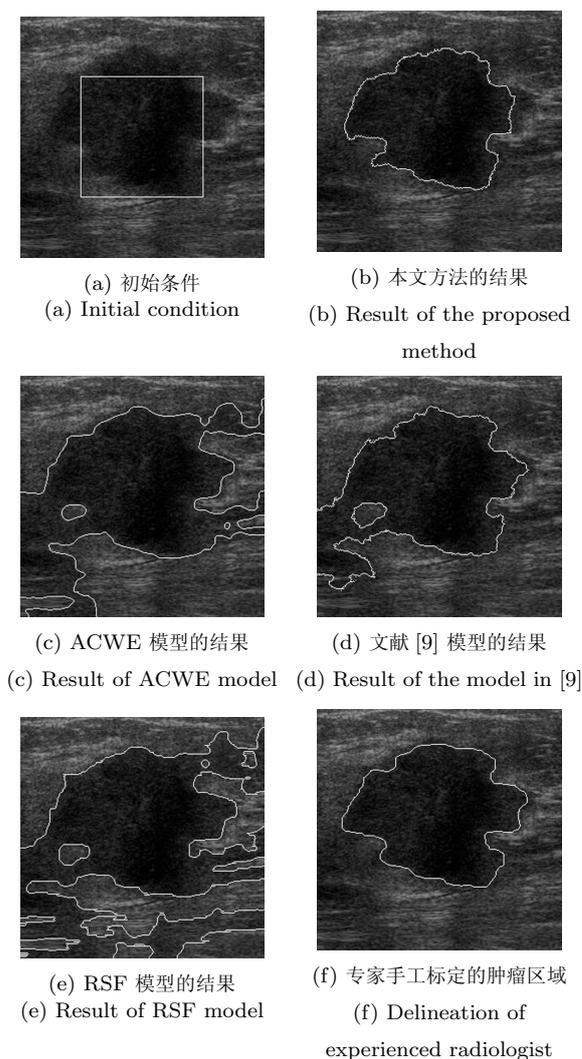


图 5 对比度低、边缘模糊的乳腺癌超声图像的分割效果
Fig. 5 Segmentation results of another breast ultrasound image with low contrast and blurry boundaries

本文的方法所产生的肿瘤区域中, 这导致 TP 略有下降. 而文献 [9] 的模型将一些肿瘤与正常组织间较为模糊的区域错误地包含在肿瘤区域中, 故其 TP 指标略高. 在 FP 指标上, 本文的模型得到了较好的结果, 这说明本文的方法分割出的肿瘤区域覆盖的错误区域小于文献 [9] 的模型, 分割的准确性更高. 在作为分割总体效果衡量标准的 SI 指标上, 通过对比可以看出, 相对文献 [9] 的模型, 本文的模型取得了较好的总体分割效果.

表 3 列出了算法的平均迭代次数和运行时间. 在本文中, 采用以下方法判断水平集函数的演化是否收敛: 每隔 m 次迭代, 记录当前的分割结果, 并与上次记录的分割结果比较, 可得在两次分割结果中属于不同区域的点点占图像中所有点的比例为 p_{diff} . 如果连续 D 次比较, p_{diff} 均小于某阈值 T_{diff} , 则判定演化过程收敛. 在临床图像分割实验中, 考虑算法

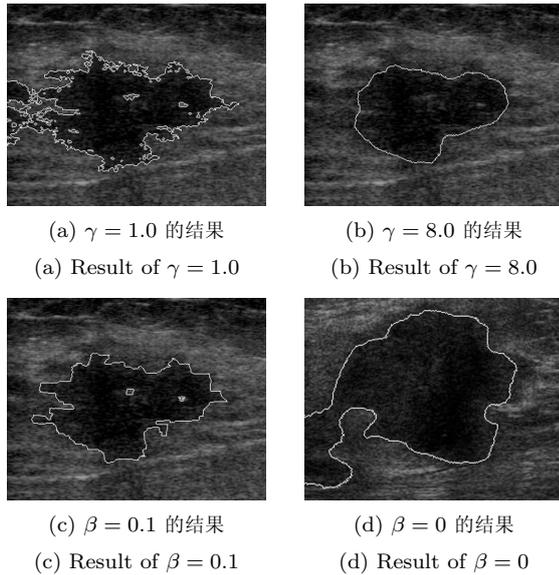


图6 采用其他权值的分割结果

Fig. 6 Segmentation results of other weights

表2 临床图像分割结果 (%)

Table 2 Segmentation results of clinical ultrasound image (%)

	TP	FP	SI
本文的模型	90.57	8.54	83.44
文献 [9] 的模型	90.79	13.12	80.26

表3 算法迭代次数和运行时间

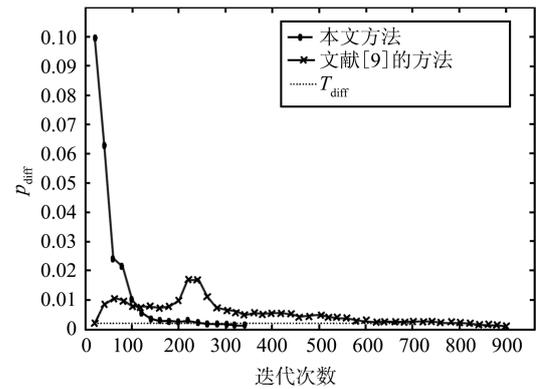
Table 3 Average numbers of iterations and CPU times

	平均迭代次数	平均运行时间 (s)
本文的模型 (平均)	360	73.7
文献 [9] 的模型	970	159.2

的精度与效率, 设 $m = 20$, $D = 5$, $T_{\text{diff}} = 0.002$. 相对于文献 [9] 的方法, 本文方法的运行速度较快, 其原因有二: 1) 本文提出的模型可以更合理地描述超声图像的特征, 提高了演化过程的效率; 2) 本文通过无重新初始化的演化方法采用更大的步长使收敛加快. 图 7 是两种方法对图 3 的图像进行分割过程中, p_{diff} 值的变化曲线 (迭代次数分别为 340 次和 900 次). 可以看出, 本文方法的 p_{diff} 值下降速度较快, 更快地达到收敛条件.

3 结论

本文提出了一种结合概率密度差异与局部灰度拟合的主动轮廓模型对医学超声图像进行分割. 本方

图7 p_{diff} 值变化曲线Fig. 7 The curve of p_{diff}

法具有以下几个特点: 1) 本方法基于概率密度差异, 建立了超声图像中灰度分布信息与背景知识的联系, 从而更加合理地利用了图像的全局信息; 2) 本方法通过对超声图像进行预处理, 降低了图像中的 Speckle 噪声, 增强了区域间的对比度, 为有效地利用图像的局部信息提供了必要条件; 3) 分别在原始超声图像与经过预处理的图像上考虑全局和局部信息, 使本方法可以更加充分地考虑超声图像的特性. 实验结果表明, 本文的方法可以准确地对超声图像进行分割. 在未来的工作中, 笔者拟将此方法应用于更多种类的超声图像, 以进行更深一步的研究, 为医学图像处理技术的发展作出更进一步的贡献.

References

- Noble J A, Boukerroui D. Ultrasound image segmentation: a survey. *IEEE Transactions on Medical Imaging*, 2006, **25**(8): 987–1010
- Boukerroui D, Baskurt A, Noble J A, Basset O. Segmentation of ultrasound images — multiresolution 2D and 3D algorithm based on global and local statistics. *Pattern Recognition Letters*, 2003, **24**(4-5): 779–790
- Cheng J, Chen C, Chou Y, Chen C S K, Tiu C, Chen K. Cell-based two-region competition algorithm with a MAP framework for boundary delineation of a series of 2D ultrasound images. *Ultrasound in Medicine Biology*, 2007, **33**(10): 1640–1650
- Yeh C, Chen Y, Fan W, Liao Y. A disk expansion segmentation method for ultrasonic breast lesions. *Pattern Recognition*, 2009, **42**(5): 596–606
- Madabhushi A, Metaxas D N. Combining low-, high-level and empirical domain knowledge for automated segmentation of ultrasonic breast lesions. *IEEE Transactions on Medical Imaging*, 2003, **22**(2): 155–169
- Wu H M, Lu H H. Iterative sliced inverse regression for segmentation of ultrasound and MR images. *Pattern Recognition*, 2007, **40**(12): 3492–3502
- Chang R F, Wu W J, Moon W K, Chen W M, Lee W, Chen D R. Segmentation of breast tumor in three-dimensional

ultrasound images using three-dimensional discrete active contour model. *Ultrasound in Medicine and Biology*, 2003, **29**(11): 1571–1581

- 8 Unal G, Bucher S, Carlier S, Slabaugh G, Fang T, Tanaka K. Shape-driven segmentation of the arterial wall in intravascular ultrasound images. *IEEE Transactions on Information Technology in Biomedicine*, 2008, **12**(3): 335–347
- 9 Sarti A, Corsi C, Mazzini E, Lamberti C. Maximum likelihood segmentation of ultrasound images with Rayleigh distribution. *IEEE Transactions on Ultrasonics, Ferroelectrics and Frequency Control*, 2005, **52**(6): 947–960
- 10 Osher S, Sethian J A. Fronts propagating with curvature dependent speed: algorithms based on Hamilton Jacobi formulation. *Journal of Computational Physics*, 1988, **79**(1): 12–49
- 11 Malladi R, Sethian J A, Vemuri B. Shape modeling with front propagation: a level set approach. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 1995, **17**(2): 158–175
- 12 Kass M, Witkin A, Terzopoulos D. Snakes: active contour models. *International Journal of Computer Vision*, 1988, **1**(4): 321–331
- 13 Guo Y H, Cheng H D, Tian J W, Zhang Y T. A novel approach to speckle reduction in ultrasound imaging. *Ultrasound in Medicine and Biology*, 2009, **35**(4): 628–640
- 14 Li C M, Kao C Y, Gore J C, Ding Z H. Minimization of region-scalable fitting energy for image segmentation. *IEEE Transactions on Image Processing*, 2008, **17**(10): 1940–1949
- 15 Chan T F, Vese L A. Active contours without edges. *IEEE Transactions on Image Processing*, 2001, **10**(2): 266–277
- 16 Li C M, Xu C Y, Gui C F, Fox M D. Level set evolution without reinitialization: a new variational formulation. In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. San Diego, USA: IEEE, 2005. 430–436
- 17 Aysal T C, Barner K E. Rayleigh-maximum-likelihood filtering for speckle reduction of ultrasound images. *IEEE Transactions on Medical Imaging*, 2007, **26**(5): 712–727
- 18 Cheng H D, Li J G. Fuzzy homogeneity and scale space approach to color image segmentation. *Pattern Recognition*, 2003, **36**(7): 1545–1562
- 19 Pal S K, Dutta-Majumder D K. *Fuzzy Mathematical Approach to Pattern Recognition*. New York: Halsted Press, 1986



刘博 哈尔滨工业大学计算机学院博士研究生. 主要研究方向为医学图像处理, 模式识别和人工智能. 本文通信作者. E-mail: scor_gen@163.com

(LIU Bo Ph. D. candidate in the Department of Computer, Harbin Institute of Technology. His research interest covers medical imaging, pattern recognition, and artificial intelligence. Corresponding author of this paper.)



黄剑华 哈尔滨工业大学计算机学院教授. 主要研究方向为图像处理与模式识别. E-mail: jhhuang@hit.edu.cn

(HUANG Jian-Hua Professor in the Department of Computer, Harbin Institute of Technology. His research interest covers image processing and pattern recognition.)



唐降龙 哈尔滨工业大学计算机学院教授. 主要研究方向为人工智能与信息处理. E-mail: txl60@hit.edu.cn

(TANG Xiang-Long Professor in the Department of Computer, Harbin Institute of Technology. His research interest covers artificial intelligence and information processing.)



刘家锋 哈尔滨工业大学计算机学院副教授. 主要研究方向为图像处理与模式识别. E-mail: jefferyliu@hit.edu.cn

(LIU Jia-Feng Associated professor in the Department of Computer, Harbin Institute of Technology. His research interest covers image processing and pattern recognition.)



张英涛 哈尔滨工业大学计算机学院讲师. 主要研究方向为模式识别与医学图像处理. E-mail: yingtao@hit.edu.cn

(ZHANG Ying-Tao Lecturer in the Department of Computer, Harbin Institute of Technology. Her research interest covers pattern recognition and medical imaging.)