论 文

一种基于动力学统计形状模型的超声图像分割方法

倪波^{①②}, 何发智^{①*}, 袁志勇^①^① 武汉大学计算机学院, 武汉 430033^② 湖北理工学院计算机学院, 黄石 435003

* 通信作者. E-mail: fzhe@whu.edu.cn

收稿日期: 2014-12-23; 接受日期: 2015-01-22; 网络出版日期: 2015-07-09

国家自然科学基金 (批准号: 61472289) 和国家重点基础研究发展计划 (973 计划) (批准号: 2011CB707904) 资助项目

摘要 从 2D 超声图像中分割出病灶区域的轮廓是计算机辅助治疗中制定术前计划的重要步骤. 然而, 有效的超声图像分割方法依旧是一个挑战性难题, 主要原因有两个: (1) 超声图像自身固有的低信噪比和灰度分布不均匀造成的病灶区域局部边缘模糊; (2) 成像过程中病人呼吸或外部挤压容易造成体内软组织的形变而引起病灶区域的几何轮廓的复杂性. 这些因素导致许多分割方法不容易收敛到真实的病灶区域. 为解决以上问题, 本文提出了一种基于动力学统计形状模型的分割方法. 首先, 该方法定义一种时间序列模型用作病灶区域形状的参数化表示模型, 并用随机差分方程 (stochastic difference equation, SDE) 作为轮廓的动力学生成模型; 然后利用 Fokker-Planck 方程 (FPE) 的性质和对样本集进行统计建模推导出动力学生成模型的系数项和形状先验概率, 我们称此统计形状模型 (statistical shape model, SSM) 为 SF-SSM; 此外, 根据超声图像中病灶区域内外灰度变化的统计信息并结合半径时间序列模型构建了一种径向轮廓特征模型 (radial profile feature model, RPFM), 该模型为先验形状提供置信区域和似然概率; 最后, 分割的优化过程被转化为求最大后验概率的过程. 为了验证本文方法的性能, 采用真实的临床超声图像作为训练和测试集合, 并与其他 3 种典型的分割方法在同一测试集合中进行比较. 实验结果显示, 在不同质量的超声图像中, 本文方法提供了更准确的分割结果. 此外, 该方法友好的初始化方式提高了交互式分割的效率, 从而提高了计算机辅助治疗的效率和效果.

关键词 动力学模型 Fokker-Planck 方程 统计形状模型 超声图像分割 计算机辅助治疗

1 引言

一个准确且高效的超声图像分割方法对于提高计算机辅助治疗的效率具有重要意义. 目前面临的挑战主要有两个: 相较于计算机断层扫描 (computed tomography, CT) 和核磁共振成像 (magnetic resonance imaging, MRI), 超声图像普遍具有低信噪比和图像灰度分布不均匀的特点而造成目标边缘轮廓模糊不清; 另一个潜在挑战是病人在手术过程中呼吸或身体的移动会使软组织受挤压造成形变, 导致超声图像上目标区域的形状变化较大. 一些传统的分割方法都不能在以上情况下得到理想的结果.

引用格式: 倪波, 何发智, 袁志勇. 一种基于动力学统计形状模型的超声图像分割方法. 中国科学: 信息科学, 2015, 45: 1449–1465, doi: 10.1360/N112014-00158

在过去的十几年里, 研究者提出了许多医学图像分割方法^[1,2], 其中基于活动轮廓模型的分割方法^[3~17]取得了较好的效果. 活动轮廓模型主要分为参数活动轮廓模型和几何活动轮廓模型. 例如 Snake 算法^[3]的主要思想是通过交互标记控制点构成轮廓线, 并通过使该轮廓线自身的外力(弹性形变)与内力(图像局部灰度特征)相匹配达到平衡, 使某种能量函数极小化, 从而完成目标区域的分割. 然而, 该模型也存在一些缺点: (1) 对控制点的初始位置敏感, 即控制点必须靠近真实边界附近; (2) 对深度凹陷的区域不敏感导致能量函数收敛到局部极值点, 甚至发散; (3) 无法处理曲线的拓扑变化, 使得无法对复杂拓扑结构的目标进行分割等. 而且超声图像中灰度分布不均匀的特点造成噪声图像的內力不足以使得轮廓收敛到全局最优值. Xu 等^[4]在此基础上提出了梯度向量场 (gradient vector field, GVF) 的概念来代替经典的內力场, GVF 可以看作对图像梯度场的逼近, 从而不仅使模型捕捉的范围得到提高, 而且能使活动轮廓进入凹陷区域. 但该方法在初始化时已经决定了目标轮廓的参数化模型, 所以不适用于曲线拓扑发生变化的区域. McInerney 等^[5]提出了一种拓扑自适应的 Snake 模型 (topology adaptive snake, T-Snake), 该方法借助三角网格和网格点的特征函数来确定边界三角形, 它可改善 Snake 模型演化, 从而保证其具有能够处理复杂形状轮廓的能力. 但该方法只是改变了轮廓外力场的形变能力, 由于超声图像自身的缺点造成內力场的不足, 同样会造成分割结果有弱边界或漏出边界等问题.

Caselles 等^[6]将水平集方法用于图像分割, 该方法将平面闭合曲线隐式地表达为三维连续函数曲面的一个具有相同函数值的同值曲线. 这样曲线的演化就转化为高维函数曲面的运动, 而每一时刻曲线的位置由高维函数的零水平集表征. 该方法的主要优势是对演化中的曲线曲面进行数值计算而不必对曲线曲面参数化, 因此活动轮廓可以方便地追踪到拓扑结构复杂的区域. 但活动轮廓的演化过程依然要依据目标边缘附近的灰度信息, 而且每次迭代都需要重新初始化轮廓的参数方程. Li 等^[7]提出了 DRLSE (distance regularized level set evolution) 方法, 该方法通过在图像的梯度场中引入距离规则项使得迭代过程中活动轮廓的初始化更加快速. 近年来, 有学者提出对目标的边缘或区域的局部信息进行建模, 从而为活动轮廓在演化过程中提供目标区域更加准确的先验信息. 如文献 [8~11] 通过对目标区域的纹理信息进行聚类分析, 从而避免活动轮廓收敛到灰度分布不均匀区域. Yuan^[12]提出了基于局部散度相似比率的活动轮廓模型, 从而提高活动轮廓对超声图像中噪声的鲁棒性. Zhou 等^[13]对图像序列中目标区域形状进行无监督学习, 以上下文之间形状的相似性作为先验知识对曲线演化的过程进行约束.

由此可见在医学分割方法中引入目标区域的先验知识可以提高分割方法对复杂轮廓和边缘模糊的鲁棒性, 其中以活动形状模型 (active shape model, ASM) 为框架的方法^[14,15]取得了不错的效果. 该方法主要包括两个部分: (1) 根据训练样本集建立目标区域的统计形状模型 (statistical shape model, SSM); (2) 根据测试样本对目标区域的图像信息进行建模用以对先验模型进行匹配, 从而使先验形状模型能够收敛到目标区域. 在 SSM 部分, 点分布模型 (point distribution model, PDM)^[16]受到了广泛的使用. 主要方法是手动在目标区域边缘连续标记, 使用标记点坐标组成的一个向量来表示其几何形状, 即: $\mathbf{p}_i = \{x_i, y_i\}, i = 0, \dots, N-1$, 然后用 PCA^[17]对训练集合 $\mathbf{P} = \{\mathbf{p}_1, \dots, \mathbf{p}_{N-1}\}$ 进行降维. 该模型给出了点的平均位置和训练集中轮廓变化的主要模态的描述. 该方法的优点是通过对样本集的形状进行统计分析形成对分割的全局形变约束, 从而克服超声图像灰度分布不均造成的分割结果偏离正确的目标区域, 但主要缺点为在样本的训练阶段需要将每个样本对应的标记点进行对齐配准, 这个过程不准确且耗时. 再者, PCA 主要用于目标形状的特征变化呈现高斯分布的情况, 而大多数实际情况目标形状的变化是呈非线性和非高斯分布的, 这样一来 PCA 降维很容易失掉一些重要的信息, 从而不能完全反应形状产生变化的真实情况. 为了解决以上问题, Berks 等^[18]将 PDM 只应用于肿瘤

图 1 基于 SF-SSM 分割方法的流程图

Figure 1 The flow chart of SF-SSM based segmentation method

边缘特征少的区域, 从目标边缘起始点 (x_0, y_0) 开始, 使用相隔一段弧长距离的点作为标记点, 然而该方法无论是在起始点还是在标记点的设置都是任意的, 也存在潜在的对齐操作. Cremers 等^[19] 采用了隐式的形状表达模型而不是参数统计先验模型, 表面上看从模型的表达上省去了标记点的对齐, 但是在训练过程中还是作了标记点的对齐. 与此同时, Yan 等^[20] 利用超声图像序列中相邻图像的统计形状模型对局部的分割区域进行约束. 文献 [21,22] 通过引入流型学习方法构建形状的先验知识, 从而避免训练阶段失去形状变化的细节信息, 但是该方法受限于流型空间的三角网格化, 只有被投影到目标区域周围的 3 个顶点所确定的三角网格能被使用, 因此只能使用特定目标区域中的几个相似形状近似表示目标区域. 文献 [23] 利用核磁共振成像质量较超声图像清晰的优势, 通过对超声图像序列相对应的核磁共振成像的目标区域构建形状统计模型, 从而约束对应的超声图像序列中目标形变区域的分割. 文献 [24,25] 使用稀疏表达的方法构建图像目标区域纹理信息模型, 从而为活动轮廓的演化提供先验知识. Wang 等^[26] 提出了基于多尺度空间和异向扩散去噪模型的活动轮廓模型方法, 该方法将超声图像投影到一个多尺度空间, 并结合异向扩散去噪模型实现由粗至精的分割, 该方法结合去噪模型能够在边缘模糊区域达到更好的效果.

近年来, 有些学者将动力学的概念引入到图像分割的领域. Garnier 等^[27] 将牛顿第二定律引入到形状边界的追踪. Shepherd 等^[28] 引入高斯过程构建分割目标的先验知识. Carneiro 等^[29] 结合动力学模型和深度学习对超声图像中左心室的边缘进行检测. 受此启发, 本文提出了一种新的基于动力学统计形状模型的超声图像分割方法. 图 1 显示了本文方法的流程图. 该方法首先对训练集中目标区域的形状进行参数化建模, 并使用一个随机差分方程 (stochastic difference equation, SDE) 作为形状模型的动力学生成模型, 并结合 Fokker-Planck 方程 (FPE) 的性质对该生成模型的系数和目标区域边缘波动的先验概率进行统计分析, 从而构建目标区域的统计形状模型, 称该模型为 SF-SSM. 除此之外, 我们还根据超声图像上目标区域由内向外的灰度明暗变化这一特征, 设计了一种径向轮廓特征模型 (radial profile feature model, RPFM) 作为分割目标区域的观测模型. 该模型向 SF-SSM 生成的初始化先验形状提供分割区域的图像信息和似然概率. 最后, 将分割过程转化为求最大后验概率的过程, 并通过迭代计算得到分割区域的轮廓. 实验分析表明, 该方法在目标区域灰度分布不均匀且形变较大的区域依然能取得很好的分割效果, 并且有相对友好的交互方式, 从而提高了计算机辅助治疗的效果.

图 2 半径时间序列模型示意图

Figure 2 Radius time series model. (a) A prototype of radial time series model; (b) a discrete radius time series

和效率.

2 一种基于动力学的统计形状模型

2.1 半径时间序列模型

文献 [30,31] 中提出通过 N 个连续的半径长度来对分割目标的形状进行建模. 本文对该模型进行改进, 增加了目标边缘标记点的坐标, 并称该模型为半径时间序列模型. 图 2(a) 是一个半径时间序列模型的示意图, 其中红色实线表示目标区域的边缘轮廓, 蓝色实线表示连续的半径, “Central point” 表示目标区域的中心点, “Marks” 表示半径与轮廓边缘相交的标记点, 半径之间的夹角由 t 表示. 将该模型参数化表达式定义为式 (1), 其中 $\mathbf{R} = \{r_0, \dots, r_{N-1}\}$ 表示 N 个连续半径的长度, 即中心点 $\mathbf{x}_c = \{x_c, y_c\}$ 到 N 个连续标记点 $\mathbf{M} = \{\mathbf{m}_0, \dots, \mathbf{m}_{N-1}\}$ 的欧氏距离 (Euclidean distance), $\mathbf{m}_i = \{m_{ix}, m_{iy}\}$ 表示半径与轮廓边缘相交的标记点的像素点坐标, t 表示两个半径之间的夹角. 如图 2(b) 所示, 该模型通过一个离散的时间序列对轮廓形状的变化进行建模, 只不过在这里状态变量是半径的长度, 时间变量由角度替代. 从式 (1) 中可以看出只要给出变量 t , 该模型可以在极坐标中表示多种“星形”闭合形状而无需做标记点的对齐操作. 实际上, 超声图像中大部分组织的形状都属于这种类型.

$$\mathbf{Q} = \{\mathbf{R}, \mathbf{M}, t, \mathbf{x}_c\} = \{\{r_0, \dots, r_{N-1}\}, \{\mathbf{m}_0, \dots, \mathbf{m}_{N-1}\}, t, \{x_c, y_c\}\}. \quad (1)$$

2.2 SF-SSM

由 2.1 小节可知, 超声图像中病灶区域的形状可用一个半径时间序列模型来表示. 本文将轮廓形状的变化看作是一个半径序列 $r(t) = \{r_0, \dots, r_{N-1}\}$ 随角度 t 变化的非线性动力学系统. 由文献 [32] 可知, 一维随机变量的非线性动力学系统通常由一个一维随机变量的 SDE 来表示, 如式 (2) 所示. 将式 (2) 作为目标轮廓形状的生成模型.

$$r(t) = r(t - \Delta t) + A(r(t), \mathbf{a}) \cdot dt + B(r(t), \mathbf{b}) \cdot W_t \cdot dt, \quad (2)$$

其中, $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 分别代表式 (2) 中的确定项和随机项, $\mathbf{a}$ 和 $\mathbf{b}$ 分别是 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 中的系数, W_t 是一个独立的均值为零的随机噪声项. 由上式可知, $r(t)$ 的状态取决于半径 $r(t - \Delta t)$ 的

状态, 以及 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 的函数形式和对应的系数. 根据非线性动力学的性质可知, 式 (2) 中的状态变量 $r(t)$ 的演化满足 Markov 特性, 即

$$\Pr(r(t)) = f(\Pr(r(t - \Delta t))), \quad (3)$$

其中, $\Pr(\cdot)$ 表示状态变量 $r(t)$ 的概率, f 表示一个概率转移方程.

根据文献 [33] 可知, 式 (3) 可由 FPE 方程推导出来. FPE 最早是由 Fokker 和 Planck 两位学者提出用于表示微观粒子随机运动位移或速率的概率方程. 近年来, 该方程被广泛用在金融市场股票波动预测和天气变化的预报. 对于一维空间的变量 x , FPE 的方程形式如下:

$$\frac{\partial}{\partial t} f(x, t) = -\frac{\partial}{\partial x} [D^{(1)}(x, t)f(x, t)] + \frac{\partial^2}{\partial x^2} [D^{(2)}(x, t)f(x, t)], \quad (4)$$

其中, $f(x, t)$ 为状态变量 x 在 t 时刻的概率密度函数, $D^{(1)}(x, t)$ 和 $D^{(2)}(x, t)$ 分别被称为漂移项和扩散项. 将式 (3) 代入到式 (4) 可知随机变量 $r(t)$ 的概率推导公式为

$$\frac{\partial}{\partial t} \Pr(r(t)|r(t - \Delta t)) = \left[-\frac{\partial}{\partial r} D^{(1)}(r(t)) + \frac{\partial^2}{\partial r^2} D^{(2)}(r(t)) \right] \Pr(r(t)|r(t - \Delta t)), \quad (5)$$

$D^{(1)}(x, t)$ 和 $D^{(2)}(x, t)$ 的形式由时间变量 t 在平稳条件下状态变量 r 在状态空间中的值所决定. 可用样本空间的离散数据逼近 $D^{(1)}(x, t)$ 和 $D^{(2)}(x, t)$ 的形式, 具体如式 (6) 所示:

$$D^{(n)}(r(t)) = \lim_{\Delta t \rightarrow 0} \frac{1}{\Delta t} ([r(t + \Delta t) - r(t)]^n | r(t) = r), n = 1, 2. \quad (6)$$

根据文献 [34] 中有关 FPE 的性质可知, 式 (2) 中的 $A(x(t))$ 和 $B(x(t))$ 与 FPE 中的 $D^{(1)}(x, t)$ 和 $D^{(2)}(x, t)$ 之间的关系通过式 (7) 和 (8) 可以得到.

$$A(r, t) = \frac{D^{(1)}(r)}{\Delta t}, \quad (7)$$

$$B(r, t) = \frac{D^{(2)}(r)}{\sqrt{\Delta t}}. \quad (8)$$

目前的关键任务是根据样本集提供的数据对方程 (6) 中 $D^{(1)}(x)$ 和 $D^{(2)}(x)$ 的形式进行拟合, 进而根据式 (7) 和 (8) 推导出 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 的函数形式和相关系数. Friedrich 等 [35] 提出了通过离散数据构建方程形式和系数的方法. 受此启发, 我们设计一个半径转移直方图对样本集中的观测数据进行训练, 并估计半径转移的概率, 具体步骤如算法 1 所示.

图 3(a) 显示了算法 1 构建的一个半径转移直方图实例, 它显示了观测数据 r 在整个状态空间中进行转移的分布频率, 图 3(b) 是对其中一个 bin 中的观测数据进行概率估计的示例. 我们发现每个 bin 中的观测数据符合正态分布, 并通过核密度估计计算对应的均值 μ_n 和标准差 σ_n . 由此可以得到半径的转移概率密度函数 $\Pr(r(t)|r(t - \Delta t) \in r_n \pm \frac{\Delta r}{2})$, 如式 (9) 所示. 与此同时, 将式 (6) 转化为式 (10) 的离散定义形式, 并根据每个 bin 中观测的离散的 μ_n 和 σ_n 值进行拟合, 从而得到 $D^{(1)}(x, t)$ 和 $D^{(2)}(x, t)$ 的函数形式. 最后, 根据式 (7) 和 (8), 以及计算得到的 $D^{(1)}(x, t)$ 和 $D^{(2)}(x, t)$, 推导出式 (2) 中的 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 的函数形式.

$$\Pr\left(r(t + \Delta t)|r(t) \in r_n \pm \frac{\Delta r}{2}\right) = \mathcal{N}(\mu_n, \sigma_n), \quad (9)$$

算法 1 Training radius transition histogram**Preprocess:**

- 1: Transforming training set $\{\mathbf{R}^1, \dots, \mathbf{R}^M\}$ into state space $\Omega = \{r_{\min}, \dots, r_{\max}\}$.
- 2: Setting radius increment Δr and dividing the state space Ω into N bins by $N = \lceil \frac{r_{\max} - r_{\min}}{\Delta r} \rceil$.
- 3: Computing center values $r_n \in \{r_1, \dots, r_N\}$ for every bin.
- 4: Setting up N sets $\mathbf{x}_i, i \in \{1, \dots, N\}$, which correspond to N bins.

Iterations:

- 5: **for** $\mathbf{R}^j, j = 1 : M$ **do**
- 6: **for** bins, $i = 1 : N$ **do**
- 7: find $r^j(t) \in [r_n - \Delta r/2, r_n + \Delta r/2], t \in [0 : \Delta t : 2\pi]$
- 8: **if** $t + \Delta t < 2\pi$ **then**
- 9: put $r^j(t + \Delta t)$ into set $\mathbf{x}_i$
- 10: **else**
- 11: put $r^j(t + \Delta t)$ into set $\mathbf{x}_1$
- 12: **end if**
- 13: **end for**
- 14: **end for**

图 3 SF-SSM 中半径转移直方图的示意图

Figure 3 Radius transition histogram in SF-SSM. (a) The radius transition histogram trained by Algorithm 1; (b) the estimation of the transition probability of radius r_i in one of bins

$$\begin{cases} D^{(1)}(r_n(t)) = (\mu_n - r_n)\Delta t, \\ D^{(2)}(r_n(t)) = \sigma_n \sqrt{\Delta t}, r_n \in \{r_{\min}, \dots, r_{\max}\}. \end{cases} \quad (10)$$

根据 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 的形式, 我们可以使用式 (2) 迭代求出整个闭合轮廓半径的长度并计算对应标记点的坐标值, 然后通过 B-spline 插值得到轮廓的先验形状. 除此之外, 根据式 (9) 计算半径序列 $\mathbf{R} = \{r_0, \dots, r_{N-1}\}$ 的联合概率, 从而推导出整个分割目标的先验形状的概率, 如式 (11) 所示.

$$\Pr(\mathbf{Q}) = \prod_{i=0}^{N-1} \Pr(r(t + \Delta t) | r(t) = r_i). \quad (11)$$

图 4 构建径向特征轮廓模型的示意图

Figure 4 Constructing radial feature profile model. (a) Along the radial direction, the pixels were sampled from inside and outside of the marks; (b) the sample of Rayleigh distribution between the r_i and the $|g|$

3 基于 SF-SSM 的分割方法

3.1 径向特征轮廓模型

本小节的主要任务是构建待分割的超声图像中目标区域的观测模型, 该模型为 SF-SSM 生成的先验形状提供匹配并为式 (11) 提供似然概率. 文献 [36] 是根据边缘标记点上垂直方向的采样点灰度共生矩阵值为先验形状模型提供病灶区域的边缘置信信息, 但超声图像中的斑点噪声和模糊边缘容易造成灰度共生矩阵的不稳定, 从而影响先验模型的收敛效果. Yang 等 [37] 在 ASM 分割方法的框架下对观测模型进行了改进, 提出了法向特征轮廓 (normal vector feature profile, NVFP). 该方法将 SIFT 特征进行改进, 并应用于标记点垂直方向的轮廓进行建模, 从而增强边缘信息对活动轮廓的吸引. 超声图像中最显著的特征就是病灶区域边缘内外灰度的明暗变化, 文献 [38,39] 揭示超声图像中目标区域由内向外的灰度分布呈 Rayleigh 分布这一显著特征. 我们结合半径时间序列模型提出径向特征轮廓模型 (radial profile feature model, RPFM). 如图 4 所示, 该模型沿半径 r_i 方向, 对标记点 m_i 内外进行像素采样, 并对采样像素灰度的梯度幅值进行统计, 从而建立半径与轮廓边缘相交的似然概率, 具体步骤如下:

步骤 1 交互式定义超声图像中病灶区域的中心点 x_c ;

步骤 2 针对半径 r_i 上的标记点 m_i , 在轮廓边缘内外沿着半径方向以等距离 δ 各采样 η 个像素点, $\{m_i^k | 1 \leq k \leq 2\eta\}$;

步骤 3 计算 m_i^k 的径向灰度的梯度幅值作为 r_i 的径向特征轮廓, $g_i = [|g_i^1|, \dots, |g_i^{2\eta}|]$;

步骤 4 针对每个样本的 g_i , 根据最大似然概率算法计算 Rayleigh 分布模型的参数并以此作为半径 r_i 与目标区域边缘相交的似然概率,

$$\Pr(g_i|r_i) = \frac{r_i}{\sigma^2} \exp\left(-\frac{(r_i-a)^2}{2\sigma^2}\right). \quad (12)$$

由式 (12) 可知半径时间序列模型中半径 R 与目标区域边缘相交的的似然概率可由式 (13) 计算得出:

$$\Pr(G|Q) = \prod_{i=0}^{N-1} \Pr(g_i|r_i). \quad (13)$$

算法 2 SF-SSM based segmentation method

1: Training SF-SSM from the training set according to Subsection 2.2.

2: Setting radius offset δ .

3: Input a test ultrasound image.

Initialization:4: Defining the central point $\mathbf{x}_c$ in the lesion area, and generating initialize prior shape $\mathbf{Q}_{\text{SF-SSM}} = \{\{r_0, \dots, r_{N-1}\}, \{\mathbf{m}_0, \dots, \mathbf{m}_{N-1}\}, t, \mathbf{x}_c\}$ with (2).**Optimization:**5: **for** $i = 0 : \Delta t : 2\pi$ **do**6: Finding $k = \operatorname{argmax}_{k \in \{-\eta, \dots, \eta\}} Pr(r_i^k) \times Pr(\mathbf{g}_i^k | r_i^k)$ according to Subsection 3.1 and (15).7: $r_i \leftarrow r_i + k\delta$ 8: $\mathbf{m}_i \leftarrow \mathbf{m}_i^k$ 9: **end for****Output:**Interpolating $\mathbf{m}_i$ and generating a closed segmentation region.

3.2 本文方法的框架

算法 2 给出本文方法的框架. 首先在训练阶段, 需要对训练集 $\{\mathbf{Q}_j | 1 \leq j \leq M\}$ 中每个样本构建目标轮廓的半径时间序列模型. 通常情况下, 手动选择目标区域内部距离轮廓边缘最远的点作为轮廓的中心点 $\mathbf{x}_c^j$, 并依次计算 $\mathbf{x}_c^j$ 与 $\mathbf{m}_i^j$ 之间的欧氏距离作为半径 r_i^j . 为了消除不同图像尺度的影响, 将训练集中的半径转化到均值—方差域, 即每一半径 r_i^j 表示成半径的长度减去该训练集中半径的均值 $\bar{r}_i = \frac{1}{M} \sum_{j=1}^M r_i^j$. 为了消除手动定义 $\mathbf{x}_c$ 的误差, 定义 $\Delta x_c = \frac{1}{M} \sum_{j=1}^M (\bar{\mathbf{m}}_x^j - \mathbf{x}_{cx}^j)$ 和 $\Delta y_c = \frac{1}{M} \sum_{j=1}^M (\bar{\mathbf{m}}_y^j - \mathbf{x}_{cy}^j)$ 作为中心点误差的偏移量, 式 (14) 作为对中心点误差进行补偿的公式,

$$\begin{cases} x'_c = x_c + \Delta x_c, \\ y'_c = y_c + \Delta y_c, \end{cases} \quad (14)$$

然后, 由 2.2 小节中的方法构建 SF-SSM. 在初始化阶段, SF-SSM 生成目标区域的先验形状和该形状的先验概率. 与此同时, 由 3.1 小节中的方法计算分割图像中目标区域的观测模型 RPFM 和对应的似然概率. 最后先验形状与观测模型根据设置的参数不断进行匹配完成目标区域的分割. 根据 Bayes 理论将该过程转化成求最大后验概率 (maximum a posteriori probability, MAP) 的过程, 如式 (15) 所示:

$$\{r_0, \dots, r_i, \dots, r_{N-1}\} = \operatorname{argmax}_{r_i} \prod_{i=0}^{N-1} \Pr(r_i) \times \Pr(\mathbf{g}_i | r_i). \quad (15)$$

4 实验结果与分析

本节中的所有实验是在 MATLAB2013a 环境下进行的, 计算机硬件配置为 Intel(R)Core(TM)i3-3220 3.30 GHz, 内存 8 GB. 采集来自 11 个不同患者 150 张临床子宫肌瘤的超声图像作为数据集用于验证本文方法, 其中 100 张用于训练, 50 张用于测试. 子宫肌瘤是一种常见的妇科良性肿瘤, 作

为一种软组织其形状容易受到外部压力或阻力的变化, 因此具有一定的代表性. 近年来高强度超声聚焦 (high-intensity focused ultrasound, HIFU) 作为一种典型的计算机辅助治疗手段被广泛用于此病的治疗, 并取得了良好的疗效. HIFU 治疗的一个重要步骤就是分割超声图像, 从而为高强度超声聚焦病灶区域提供导航. 实验中的每张图像的像素尺寸为 524×413 , 像素的分辨率为 $0.3 \text{ mm} \times 0.3 \text{ mm}$. 将有经验的临床医生手动分割的结果作为 ground truth. 首先使用 TP (the true position) 和 FP (the false position) 来度量计算得到的分割区域和手动分割区域之间的重叠误差, 其定义如下:

$$\text{TP} = \frac{|\Omega_m \cap \Omega_a|}{|\Omega_m|}, \quad (16)$$

$$\text{FP} = \frac{|\Omega_m \cup \Omega_a - \Omega_m|}{|\Omega_m|}, \quad (17)$$

其中, Ω_m 和 Ω_a 分别表示手动分割轮廓和计算分割轮廓上的像素集合, TP 的值越高表示越多的目标区域被覆盖, FP 值越低表示计算分割的轮廓越匹配目标的轮廓. 此外, 我们还使用 AMED (average minimum Euclidean distance) 和 HD (Hausdorff distance) 这两个指标分布对计算分割轮廓和手动分割轮廓之间的距离差异进行度量, 其定义为

$$\text{AMED}(A, B) = \frac{1}{2m} \sum_{i=1}^m \text{MED}(a_i, B) + \frac{1}{2n} \sum_{j=1}^n \text{MED}(b_j, A), \quad (18)$$

$$\text{HD}(A, B) = \max\left\{\max_{i \in \{1, \dots, m\}} \text{MED}(a_i, B), \max_{j \in \{1, \dots, n\}} \text{MED}(b_j, A)\right\}, \quad (19)$$

其中, $A = \{a_1, \dots, a_m\}$ 和 $B = \{b_1, \dots, b_n\}$ 分别表示两个轮廓上有序的点集, MED (minimum Euclidean distance) 定义为

$$\text{MED}(a_i, B) = \min_{j \in \{1, \dots, n\}} \text{dis}(a_i, b_j), \quad a_i \in A. \quad (20)$$

4.1 构建 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$

本小节的目的是根据训练集和算法 1, 结合式 (6)~(8) 对 $A(r(t), \mathbf{a})$ 和 $B(r(t), \mathbf{b})$ 进行拟合, 从而选择相应的函数形式和参数. 图 5 是 $\{\mu_i - \sigma_i\}$ 和 $\{\sigma_i\}$ 的离散分布情况的一个实例. 在拟合过程中对一些孤立的点进行排除, 并使用 Levenberg Marquardt 算法取最小的 χ^2 值对这些离散数据进行拟合, 式 (21) 为本文实验的拟合结果.

$$\begin{cases} A(r(t), \mathbf{a}) = a_0 r \exp\left[\frac{(r - a_1)^2}{a_2}\right] - a_3, \\ B(r(t), \mathbf{b}) = b_0(r - b_1)^3 + b_2. \end{cases} \quad (21)$$

4.2 比较 SF-SSM 和 PDM

本小节通过分别比较 SF-SSM 和 PDM 生成先验形状与目标轮廓之间的 TP 和 AMED 值来判断哪个先验形状模型更接近目标区域. 实验过程中, SF-SSM 中半径时间序列的标记点数量与 PDM 中标记点数量相同. 从图 6 中可以看出在样本较少的情况下, PDM 生成的先验形状的 TP 值和 AMED 值比 SF-SSM 生成的高, 但从图 6(a) 可以看出随着训练样本数的增加, PDM 生成的先验形状的 TP 明显趋缓, 说明 PDM 生成的先验形状趋于稳定, 而 SF-SSM 生成的先验形状的 TP 值呈现上升趋势, 说明 SF-SSM 的先验形状与病灶区域有更多的重叠区域. 图 6(b) 显示在样本数较少的情况下, 基于

图 5 $A(r(t))$ 和 $B(r(t))$ 离散分布及拟合方程示例图

Figure 5 The samples of discrete distribution of $A(r(t))$ and $B(r(t))$ and those fitting functions. (a) The fitting function of $A(r(t))$; (b) the fitting function of $B(r(t))$

图 6 不同训练样本数量下, 基于 SF-SSM 的先验形状与基于 PDM 的先验形状的 TP 和 AMED 值比较

Figure 6 The comparison of TP and AMED values of the prior shapes based on SF-SSM and PDM respectively with the different numbers of training samples

SF-SSM 的先验形状的 AMED 值比基于 PDM 的值要小, 这就说明在样本少的情况下基于 PDM 的先验形状覆盖了一些错误的区域, 并且随着样本数量的增加, 它们之间 AMED 值在不断扩大. 因此, SF-SSM 的先验形状比 PDM 的先验形状更靠近目标区域的边缘, 从而缩小了先验形状在优化时捕获真实轮廓的范围, 提高了分割方法的精度. 从图 7 可知, 随着目标轮廓的变化, SF-SSM 生成的先验形状也会动态地改变, 而基于 PDM 的先验形状则不能捕捉到此变化, 说明本文提出的基于动力学的方法能更好地构建分割区域的先验形状.

4.3 不同方法分割结果比较

为了分析本文方法的分割性能, 选择 Wang 等 [26] 的 Multiscale GAC with SRAD 方法与文献 [8] 中的 Bias-LevelSet 方法作为基于活动轮廓模型分割方法的代表, 选择文献 [37] 中的 ASM with NVFP 方法与本文的方法作为基于先验形状模型分割方法的代表, 对同一测试样本的分割效果进行对比. 首先, 请有经验的临床医生将测试样本按照形状轮廓的形变和边缘模糊的程度分为 Good, Medium, Poor 3 个等级, 其中每个等级包含的测试样本数量如表 1 所示. 然后, 将不同临床医生对同一样本分割结果

图 7 先验形状与目标轮廓进行比较

Figure 7 Comparing the prior shapes and the target contours (the dotted lines represent the target contours and the solid lines represent the prior shapes). The top row: the prior shapes given by SF-SSM; the bottom row: the prior shapes given by PDM

表 1 不同等级的测试样本数量

Table 1 The number of test samples on different levels

Level	Good	Medium	Poor
The number of test samples	16	21	13

的均值作为测试样本的 ground truth, 分割方法分别对这 3 个不同等级的图片进行分割. 为了保证各方法分割的结果是在相同的参数环境下得到的, 本文方法的参数 t 和 η 分别被设置为 20 和 50, ASM with NVFP 中每一训练样本的标记点的个数被设置为 36, Multiscale GAC SRAD, ASM with NVFP 和 Bias-LevelSet 的迭代次数均设置为 100. 图 8 给出了 4 种分割方法在不同等级图像中分割结果的测量值, 可以看出每种分割方法得到 TP 均值都很高 ($\geq 90\%$). 但仅仅看 TP 的均值并不能完全说明分割方法的性能, 从 FP 的均值可以看出 Multiscale GAC with SRAD 和 Bias-LevelSet 的值要高于 ASM with NVFP 和本文的方法, 说明 Multiscale GAC with SRAD 和 Bias-LevelSet 的分割结果覆盖到错误的区域比 ASM with NVFP 和本文的方法多, 这一点在 Medium 和 Poor 组的结果中表现的尤为明显. 这说明在超声图像分割中, 先验知识能够起到很好的辅助作用, 使得分割方法在图像灰度分布不均匀和目标形状严重变形的情况下更加鲁棒. 由于本文方法使用 SF-SSM 初始化先验形状, 因此在目标区域有较大变形的情况下比 ASM with NVFP 取得的结果更理想, 这一点可以从 Poor 组的各个测量结果中看出. 同样在 AMED 和 HD 中, 也能得到相同的结论. 除了分割的精度, 还用这 4 种测量指标的标准差表示分割结果的稳定性. 由于基于 SF-SSM 的初始化过程只需估计目标区域的中心位置和对中心位置的误差进行补偿, 并且生成的先验模型能适应目标区域的形变, 所以其标准差更小. Multiscale GAC with SRAD 和 Bias-LevelSet 的初始化过程都是在目标区域内手动设置一个轮廓, 轮廓的形状以及大小是随机的, ASM with NVFP 的初始化过程是手动将先验模型放置在目标区域的周围, 这些初始化的过程都带有人为的误差从而造成分割结果的稳定性较本文方法差, 因此标准差也相对较大. 图 9 显示了不同方法分割后的一个实例图, 从左至右分别表示 Good, Medium, Poor 3 组等级的一个实例, 绿色实线表示手动分割的平均轮廓, 红色实线表示分割后的轮廓线.

图 8 4 种方法在不同等级的超声图像中分割结果的 TP, FP, AMED 和 HD 比较

Figure 8 The TP (a), FP (b), AMED (c) and HD (d) comparison of the four methods segmentation results with the different quality US images

表 2 不同算法的运行时间比较

Table 2 The comparison of run time

Algorithms	Our method	ASM with NVFP	Multiscale GAC with SRAD	Bias-LevelSet
Runtime (s)	23.12	37.07	47.72	33.17

4.4 算法复杂度分析

从 3.2 小节可知, 本文算法的计算复杂度主要由初始化过程和迭代过程来决定. 由式 (2) 和 (21) 可知, 初始化的计算复杂度为 $O(n^2)$, 迭代过程的计算复杂度主要由算法 2 的第 5, 6 两行语句实现, 因此算法 2 总的计算复杂度为 $O(n^2)$. 表 2 给出了这几种算法的平均运行时间, 在设置相同的迭代次数时, ASM with NVFP 分割过程要进行标记点的对齐操作以及 SIFT 特征的匹配计算, Bias-LevelSet 需要对分割区域的灰度进行聚类分析, Multiscale GAC SRAD 需要对同一图像构建不同多个尺度空间的图像, 并对每一尺度下的图像进行去噪处理, 所以这 3 种方法平均运行时间比本文提出的方法较长.

4.5 本文方法的局限性分析

从上面的讨论可知, 算法 1 是一种有监督的统计学习方法, 因此 SF-SSM 的性能取决于训练样本的规模大小. 但受客观条件影响, 获取大数据量的训练样本往往是困难的, 所以当有些测试图像中目标区域的形状与训练样本中的形状差别很大时, SF-SSM 生成的先验形状往往不是很理想, 从而造成分割效果不理想. 图 10 显示了当目标区域的形状变化很大时, SF-SSM 生成的先验形状和基于 SF-SSM 的分割结果与目标形状之间的比较, 其中绿色实线表示目标轮廓, 先验形状的轮廓和分割结果的轮廓

图 9 4 种方法分割结果对比

Figure 9 The comparison of the segmentation results with the four methods

图 10 目标区域形状变化大的情况下本文方法分割结果的示例

Figure 10 The segmentation result given by the our method in the case of a large deformable target region. (a) The SF-SSM based prior shape; (b) the segmentation result of our method

分别用红色实线表示. 由于采用半径时间序列模型对目标区域具有封闭形状的组织器官有很好的建模能力, 如前列腺、肝脏、心脏以及胎儿头颅轮廓等. 这些组织器官的形状不会因个体的不同而造成组织的形状产生差异. 如果当分割区域的形状不符合以上前提时, 本文的方法就不适用. 例如胸腔肋骨架, 它整个的形状是非封闭的, 因此无法用本文的半径时间序列模型进行建模; 患者的癌细胞形状也是随着病情的发展或因患者发病位置的不同而各异, 因此也不能采用本文的方法对其先验形状进行统计分析. 除此之外, 从 3.1 小节可知, 构建 RPFM 是基于一般情况下超声图像中目标区域内的灰度分布符合 Rayleigh 分布这个前提的, 但受超声发射器的频率和扫描角度影响, 少量样本的成像质量不

图 11 当目标区域附近的灰度分布不符合 Rayleigh 分布时, 本文方法的分割结果示例

Figure 11 The result of our segmentation method, when the gray distribution around the target region dose not conform to rayleigh distribution. (a) Defining roughly the target region; (b) the gray distribution within the region; (c) the segmentation result of our method

能满足以上前提, 这样会影响本文方法的分割效果. 图 11 显示了目标区域的灰度分布呈现一个类似的高斯分布的情况下, 本文方法的分割结果不理想的示例, 其中黄色椭圆定义了一个目标区域的大致范围, 绿色轮廓表示 ground truth, 红色轮廓表示分割的结果.

5 结论与展望

综上所述, 在超声图像中目标边缘模糊以及目标区域灰度分布不均匀的情况下, 基于统计形状模型的分割方法要比单纯的基于图像信息的活动轮廓模型分割方法效果更加鲁棒, 本文在构建统计形状模型时融入了动力学的非线性特性, 该模型比线性的统计形状模型更能反映目标区域形状的形变特征, 因此能得到更好的分割结果. 除此之外, 本文中的半径时间序列模型是在极坐标下表示目标区域的形状, 因此无需在训练和初始化阶段对标记点进行对齐操作, 从而提高了方法效率, 而这一点对提高计算机辅助治疗的效率是非常有价值的. 在未来, 希望引入 CUDA 并行计算进一步提高方法的计算效率, 并将动力学模型用于 3D 的超声图像分割和软组织形变仿真实验.

致谢 感谢重庆医科大学第二附属医院郑元义教授等提供 HIFU 的子宫肌瘤超声图像, 对病灶区域进行标注, 并提供在 HIFU 治疗方面的知识.

参考文献

- 1 Noble J A, Boukerroui D. Ultrasound image segmentation: a survey. *IEEE Trans Med Imag*, 2006, 25: 987–1010
- 2 Saini K, Dewal M L, Rohit M. Ultrasound imaging and image segmentation in the area of ultrasound: a review. *Int J Adv Sci Technol*, 2010, 11: 41–60
- 3 Kass M, Witkin A, Terzopoulos D. Snakes: active contour models. *Int J Comput Vision*, 1988, 1: 321–331
- 4 Xu C, Prince J L. Snakes, shapes, and gradient vector flow. *IEEE Trans Image Process*, 1998, 7: 359–369
- 5 McInerney T, Terzopoulos D. T-snakes: topology adaptive snakes. *Med Image Anal*, 2000, 4: 73–91
- 6 Caselles V, Kimmel R, Sapiro G. Geodesic active contours. *Int J Comput Vision*, 1997, 22: 61–79
- 7 Li C, Xu C, Gui C, et al. Distance regularized level set evolution and its application to image segmentation. *IEEE Trans Image Process*, 2010, 19: 3243–3254
- 8 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 Trans Image Process*, 2011, 20: 2007–2016
- 9 Xie X, Wang C, Zhang A, et al. A robust level set method based on local statistical information for noisy image segmentation. *Optik Int J Light Electron Opt*, 2014, 125: 2199–2204

- 10 Yang H, Ahuja N. Automatic segmentation of granular objects in images: combining local density clustering and gradient-barrier watershed. *Pattern Recogn*, 2014, 47: 2266–2279
- 11 Wang L, Pan C. Robust level set image segmentation via a local correntropy-based K-means clustering. *Pattern Recogn*, 2014, 47: 1917–1925
- 12 Yuan J. Active contour driven by local divergence energies for ultrasound image segmentation. *IET Image Process*, 2013, 7: 252–259
- 13 Zhou X, Huang X, Duncan J S, et al. Active contours with group similarity. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Portland, 2013. 2969–2976
- 14 Cootes T F, Taylor C J, Cooper D H, et al. Active shape models-their training and application. *Comput Vision Image Und*, 1995, 61: 38–59
- 15 Shen D, Zhan Y, Davatzikos C. Segmentation of prostate boundaries from ultrasound images using statistical shape model. *IEEE Trans Med Imag*, 2003, 22: 539–551
- 16 Cootes T F, Taylor C J. *Active Shape Models-‘Smart Snakes’*. London: Springer, 1992. 266–275
- 17 Wold S, Esbensen K, Geladi P. Principal component analysis. *Chemometr Intell Lab Syst*, 1987, 2: 37–52
- 18 Berks M, Caulkin S, Rahim R, et al. Statistical appearance models of mammographic masses. In: *Digital Mammography*. Berlin: Springer, 2008, 5116: 401–408
- 19 Cremers D, Schmidt F R, Barthel F. Shape priors in variational image segmentation: convexity, lipschitz continuity and globally optimal solutions. In: *Proceedings of IEEE Conference on Computer Vision and Pattern Recognition*, Anchorage, 2008. 1–6
- 20 Yan P, Xu S, Turkbey B, et al. Adaptively learning local shape statistics for prostate segmentation in ultrasound. *IEEE Trans Biomed Eng*, 2011, 58: 633–641
- 21 Tenenbaum J B, De Silva V, Langford J C. A global geometric framework for nonlinear dimensionality reduction. *Science*, 2000, 290: 2319–2323
- 22 Etyngier P, Segonne F, Keriven R. Shape priors using manifold learning techniques. In: *Proceedings of IEEE International Conference on Computer Vision*, Rio de Janeiro, 2007. 1–8
- 23 Ni B, He F Z, Yuan Z Y, et al. Fibroid segmentation in ultrasonic image for constructing statistical deformation model from MRI. *J Comput-Aid Des Comput Graph*, 2013, 25: 817–822 [倪波, 何发智, 袁志勇, 等. 构建 MRI 统计形变模型的子宫肌瘤超声图像分割方法. *计算机辅助设计与图形学学报*, 2013, 25, 817–822]
- 24 Gao Y, Bouix S, Shenton M, et al. Sparse texture active contour. *IEEE Trans Image Process*, 2013, 22: 3866–3878
- 25 Rosas-Romero R, Tagare H D. Segmentation of endocardium in ultrasound images based on sparse representation over learned redundant dictionaries. *Eng Appl Artif Intell*, 2014, 29: 201–210
- 26 Wang W M, Zhu L, Qin J, et al. Multiscale geodesic active contours for ultrasound image segmentation using speckle reducing anisotropic diffusion. *Opt Laser Eng*, 2014, 54: 105–116
- 27 Garnier C, Bellanger J J, Wu K, et al. Prostate segmentation in HIFU therapy. *IEEE Trans Med Imag*, 2011, 30: 792–803
- 28 Shepherd T, Prince S J D, Alexander D C. Interactive lesion segmentation with shape priors from offline and online learning. *IEEE Trans Med Imag*, 2012, 31: 1698–1712
- 29 Carneiro G, Nascimento J C. Combining multiple dynamic models and deep learning architectures for tracking the left ventricle endocardium in ultrasound data. *IEEE Trans Pattern Anal Mach Intell*, 2013, 35: 2592–2607
- 30 Kartikeyan B, Sarkar A. Shape description by time series. *IEEE Trans Pattern Anal Mach Intell*, 1989, 11: 977–984
- 31 Yuan X, Zhong F, Zhang Y, et al. Automatic segmentation of head-and-shoulder images by combining edge feature and shape prior. In: *Proceedings of International Conference on Computer-Aided Design and Computer Graphics (CAD/Graphics)*, Hangzhou, 2011. 163–170
- 32 Gardiner C W. *Handbook of Stochastic Methods*. Berlin: Springer, 1985. 117–174
- 33 Elgin J N. The Fokker-Planck equation: methods of solution and applications. *J Mod Opt*, 1984, 31: 1206–1207
- 34 Frank T D, Beek P J, Friedrich R. Fokker-Planck perspective on stochastic delay systems: exact solutions and data analysis of biological systems. *Phys Rev E*, 2003, 68: 1–10
- 35 Friedrich R, Siegert S, Peinke J, et al. Extracting model equations from experimental data. *Phys Lett A*, 2000, 271: 217–222
- 36 Van Ginneken B, Frangi A F, Staal J J, et al. Active shape model segmentation with optimal features. *IEEE Trans*

- Med Imag, 2002, 21: 924–933
- 37 Yang M, Yuan Y, Li X, et al. Medical image segmentation using descriptive image features. In: Proceedings of the British Machine Vision Conference, Dundee, 2011. 1–11
- 38 Sarti A, Corsi C, Mazzini E, et al. Maximum likelihood segmentation of ultrasound images with Rayleigh distribution. IEEE Trans Ultrason Ferr Freq Control, 2005, 52: 947–960
- 39 Boukerroui D. A local Rayleigh model with spatial scale selection for ultrasound image segmentation. In: Proceedings of the British Machine Vision Conference, Surrey, 2012. 1–12

A novel ultrasound image segmentation based on a dynamical statistical shape model

NI Bo^{1,2}, HE FaZhi^{1*} & YUAN ZhiYong¹

1 *Computer School of Wuhan University, Wuhan 430033, China;*

2 *Computer School of Hubei Polytechnic University, Huangshi 435003, China*

*E-mail: fzhe@whu.edu.cn

Abstract Segmenting the lesion region from 2D ultrasound (US) images is an importance step in defining the intra-operative planning of computer-assisted therapy. However, it still remains a challenge owing to two reasons: (1) The signal-to-noise ratio (SNR) of the US images is originally low, and the inhomogeneous distribution of intensity causes local fuzzy boundaries. (2) The deformation of soft tissue causes makes the geometry contour of the segmentation area complex. Because of these factors, the classical segmentation methods do not yield the desired results in US images. To solve these problems, a novel segmentation method based on a dynamics statistical shape model is proposed. In this study, first, a radial time series model was defined for use as a parametric shape model of the lesion region, and a stochastic difference equation (SDE) was used as the contour dynamics generating model; then, the coefficients of the dynamics generating model and the shape prior probability were deduced by utilizing the property of Fokker-Planck equation (FPE) and training the samples. This statistical shape model (SSM) was referred to as the SF-SSM. Furthermore, a radial profile feature model (RPFM) was developed based on the statistical features of the intensity distribution from the inside to outside of the lesion region and based on the radial time series model. The RPFM provided a likelihood probability for the prior shape. Finally, through the segmentation optimization process, the maximum posteriori process was determined. In order to verify the performance of our method, we used real clinical ultrasound images as the training and test sets. We compared the proposed model with three well-known segmentation methods for the same test set. The experimental results showed that the proposed method provided more accurate results than the other methods for different quality US images. Furthermore, the friendly initialization of the proposed method improves the efficiency of interactive segmentation, thus benefitting computer-assisted therapy.

Keywords dynamical model, Fokker-Planck equation, statistical shape model, ultrasound image segmentation, computer-assisted therapy

NI Bo was born in 1980. He received the M.E. degree in Computer Science from Wuhan University of Technology, Wuhan in 2006. He has been a teacher with the Hubei Polytechnic University. Currently, he is currently pursuing his Ph.D. Degree in Computer Science from Wuhan University. His main research interests are image processing, pattern recognition, and computer vision.

HE FaZhi was born in 1968. He received his B.S., M.S., and Ph.D. degrees from Wuhan University of Technology. He pursued post-doctoral research in Zhejiang University, and was a visiting researcher at the Korea Institute of Science and Technology and a visiting faculty member at the University of North Carolina at Chapel Hill. Currently, he is a professor at the School of Computer Science and Technology, Wuhan University. His research interests are computer-aided design, computer graphics, and collaborative computation.