

# 基于先验形状的混杂活动轮廓模型及其在图像分割中的应用

曹冬梅 徐 军

(南京信息工程大学信息与控制学院 南京 210044)

**摘要** 提出了一种新颖的基于先验形状学习的混杂活动轮廓(SHAC)模型,该模型采用变分水平集方法,融合自适应区域信息与边界信息,运用主成分分析的方法从给定的含有目标物体轮廓的训练集学习得到最佳形状信息,并将其作为先验形状。将自适应区域特征和轮廓特征作为局部信息,先验形状作为全局信息,在迭代过程中结合全局和局部信息实现对演化曲线的形变进行指导和约束,达到分割目标物体的目的。通过定量和定性分析低对比度的乳腺核磁共振图像中的乳腺轮廓的分割,以及具有复杂背景的自然图像中感兴趣区域的分割结果,验证了 SHAC 模型比传统活动轮廓模型具有更高的准确率,表明了该模型不仅提高了图像分割中对弱边界的识别度,减弱了非目标轮廓的干扰,而且具有良好的抗噪能力。

**关键词** 活动轮廓,先验形状学习,水平集方法,图像分割

**中图分类号** TP391.4 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2014.11.059

## Shape Prior Based Hybrid Active Contour Model and its Applications in Image Segmentation

CAO Dong-mei XU Jun

(School of Information and Control, Nanjing University of Information Science and Technology, Nanjing 210044, China)

**Abstract** In this paper, a new Shape-prior based Hybrid Active Contour (SHAC) model was presented for segmentation. By using level set method, this model combines boundary and adaptive region information together and learns an optimal prior shape from the training set. It takes the boundary and adaptive region feature as local information while prior shape as global information. The model combines global and local information in the process of iteration to guide the evolution of deformative curve and achieve the goal of segmenting target objects. Experiments show that compared with GAC, C-V, and RSF models, SHAC model displays its advantages not only in the segmentation of image strong noise and weak boundary, but also in the image with low contrast resolution, complicated background and contributes improved accuracy.

**Keywords** Active contour, Shape prior, Level set method, Image segmentation

## 1 引言

活动轮廓模型<sup>[1]</sup>是一种有效的图像分割方法,目前在目标跟踪<sup>[2]</sup>和医学图像分析<sup>[11,15,17,18]</sup>中得到了广泛的应用。与经典的图像分割方法如边界检测、阈值法、区域增长法等相比,活动轮廓模型有很多的优势:1)形式多样。活动轮廓模型按照轮廓线的表示方式可分为参数活动轮廓模型、传统水平集活动轮廓模型以及非传统水平集活动轮廓模型。而其中每一类模型又可细分为若干种经典的活动轮廓模型。例如,传统水平集活动轮廓模型又包括几何活动轮廓模型<sup>[3]</sup>、测地活动轮廓模型(GAC)<sup>[4]</sup>以及 Chan-Vese 模型<sup>[5]</sup>等。2)结构灵活。活动轮廓模型的结构使其能够融合多种信息,如图像的区域、颜色、纹理以及目标的形状特征等<sup>[6]</sup>。相比于经典的图像分割算法,其可以达到更鲁棒的分割效果。3)性能优越。由于活动轮廓模型具备使其轮廓线平滑的约束条件,对于分割之后的应用研究如形状分析、识别具有重要作用,因此该模

型通常具备优越的性能。

活动轮廓模型主要分为两大类:基于区域和基于边界的活动轮廓模型。基于边界的模型<sup>[4]</sup>根据边界梯度信息驱动活动边界向目标边界移动,虽然充分利用了边界附近的局部信息,但对于噪声和初始轮廓很敏感且过度依赖边界检测方程,容易陷入局部最小值。基于区域的模型<sup>[6-8]</sup>根据不同区域的灰度统计信息用一个区域描述子来引导边界移动从而分割不同的区域。该类方法充分考虑了全局信息,其初始曲线位置虽可以任意放置,但经典的基于区域的模型依赖于每个被分割区域内的灰度分布均匀性,如 Mumford-Shah 模型<sup>[9]</sup>就假设每个区域的灰度都是一个均匀的常数。然而,现实生活中,不同形式的图片通常灰度是不均匀的,特别对于医学图像,其背景的复杂、不同组织结构间的重叠以及成像时造成的不可避免的噪声等,使图像存在灰度不均的问题。为了处理灰度不均的问题,Mumford 和 Shah 在文献<sup>[9]</sup>中提出了基于区域的模型即找到一个与原始图像灰度分布最逼近的分段光滑函

到稿日期:2013-06-25 返修日期:2013-08-16 本文受国家自然科学基金(61273259,61005027,61272223)资助。

曹冬梅(1989-),女,硕士生,主要研究方向为图像分割,E-mail:caodongmei1989@gmail.com;徐 军(1972-),男,博士,教授,主要研究方向为图像分析、计算机视觉、机器学习。

数,这些模型又称为分段光滑模型,然而这种模型的计算复杂度非常高。该模型是基于区域活动轮廓模型先驱。基于 Mumford-Shah 模型,Chan 等提出了著名的 Chan-Vese(C-V)模型<sup>[5]</sup>。基于 Mumford-Shah 模型和 C-V 模型,Paragios 和 Deriche 在文献[12]中进一步运用高斯混合模型逼近全局区域的轮廓模型。但是此类主动轮廓曲线演化到物体的某些弱边缘部分或是边缘间隙处,且灰度值又相近时,仍会经常发生泄漏或者过分割。出现这个问题的原因是该模型并没有提供任何信息来把这些断开的边缘间隙连接起来。

为此,Li 在文献[10]中提出了一种基于区域的可伸缩区域拟合能量(RSF)模型,其通过两个拟合函数分别逼近局部边界内部和外部的灰度,不仅有效地解决了灰度不均的问题,而且能量函数中的水平集规范项保证了水平及演化过程中计算的准确性,避免了复杂的初始轮廓重置的问题。为了克服两种主动轮廓模型各自的缺点,我们在文献[11]中提出了运用分层的均值漂移算法和归一化分割方法与初始化轮廓相结合,再将颜色信息结合到 GAC 模型中,用颜色梯度代替灰度梯度作为边缘检测,处理彩色图像转灰度图像中导致的边缘磨损或削弱的情况。另一方面,现实中获得的图像总是不可避免地受到污染,如噪声、阴影或是目标物体被部分遮挡等,这增加了图像处理的难度,用标准的主动轮廓模型分割都难以获得满意的效果。

为解决上述问题,研究人员提出形状先验与主动轮廓模型相结合的分割方法<sup>[13-16]</sup>。其中,文献[13]提出的统计学形状先验模型使用最为广泛,其主要思想是用概率密度函数从形状样本训练集估计形状的概率分布,再将先验信息加入到基于边界的 GAC 模型中,为主动轮廓模型提供有效的初始轮廓。文献[14]将形状样本集表示成符号距离函数,用主成分分析算法(PCA)学习先验形状,再将形状信息融入基于区域的 C-V 模型中,结合全局区域信息使曲线收敛至目标真实轮廓。然而 C-V 模型的区域灰度是计算整个全局区域中前景和背景的平均灰度,若目标物体区域的灰度与全局计算的前景的平均灰度值相差较大,则区域项不能很好地借助灰度统计信息来驱动活动轮廓向目标物体靠近。

针对这些问题,本文融合自适应区域信息与边界信息,同时引入形状先验信息,提出一种新的基于先验形状的混杂活动轮廓(SHAC)模型。本文的主要贡献在于:1)学习形状先验为曲线演化提供全局轮廓信息,避免了主动轮廓模型因对初始位置敏感而无法准确地收敛至目标真实轮廓的问题;2)自适应区域信息作为局部区域信息,形状先验作为全局先验信息,结合全局和局部信息,定义了新的活动轮廓能量函数,该模型能够分割复杂背景和环境图像中的目标物体,复杂的背景和环境有噪声、边缘模糊或者目标物体被遮挡等。本文模型有效地解决了图像中感兴趣的目标物体像素灰度不均、目标物体边缘梯度不明显、感兴趣的目标物体被遮挡等问题,同时大大降低了计算的复杂度。

## 2 相关工作

### 2.1 C-V 模型

C-V 模型<sup>[3]</sup>基于区域一致性假设,根据图像的灰度特征将图像域划分为互不重叠的区域,从而达到分割的目的。令  $C$  为演化曲线,将整幅图像  $I$  分为两个区域,通过最小化能量

泛函  $E$  来寻找最优分割线  $C$ ,使其恰好在目标对象和背景的边界处, $E_{CV}$  的表达式如下:

$$E_{CV}(C, c_{in}, c_{out}) = \mu L(C) + \lambda_m \iint_{inside(C)} |I - c_{in}|^2 dx dy + \lambda_{out} \iint_{outside(C)} |I - c_{out}|^2 dx dy \quad (1)$$

式中, $c_{in}$  和  $c_{out}$  是每个区域的平均灰度值; $L(C) = \oint ds$ , 是闭合轮廓线  $C$  的长度; $\mu \geq 0, \lambda_m, \lambda_{out} > 0$ , 是各个能量项权重的系数。第一项是平滑项,后两项是实际图像与假定的分片常数图像之间的偏离。最终,分割轮廓线  $C$  的位置以及变量  $c_{in}$  和  $c_{out}$  可经最优化式(1)得到,即只有当  $C$  位于目标边界时,能量泛函  $E_{CV}$  才达到最小值。

### 2.2 RSF 模型

为解决 C-V 模型在处理灰度不均图像上遇到的问题,Li 在文献[10]中提出了基于自适应局部区域灰度拟合的活动轮廓模型,其利用一个高斯核函数来控制局部区域的大小,该拟合模型的能量函数定义为:

$$\epsilon_x^{Fit}(C, f_1(x), f_2(x)) = \sum_{i=1}^2 \lambda_i \int_{\Omega_i} K_\sigma(x-y) |I(y) - f_i(x)|^2 dy \quad (2)$$

其中, $\lambda_1, \lambda_2 > 0, f_1(x)$  和  $f_2(x)$  分别是逼近以  $x$  为中心的区域  $\Omega_1$  和  $\Omega_2$  的平均灰度, $I(y)$  是区域内任意一点  $y$  的灰度, $\Omega_1$  和  $\Omega_2$  的范围由  $K_\sigma$  控制, $K_\sigma(u) = (1/(2\pi)^{\frac{n}{2}} \sigma^n) e^{-|u|^2/2\sigma^2}$ , 参数  $\sigma$  的值越大,区域范围越大。

对于一个中心点  $x$ ,最小化拟合函数  $\epsilon_x^{Fit}$  可以得到边界的闭合曲线  $C$  以及曲线内部和外部最优的局部灰度近似值  $f_1$  和  $f_2$ ,而对整个图像区域,要得到最优的分割曲线  $C$ ,必须对图像内所有的点进行最小化  $\epsilon_x^{Fit}$ ,从而找到整个图像域内灰度最相近的区域,而不是整个图像的前景和背景的平均灰度,即  $\int \epsilon_x^{Fit}(C, f_1(x), f_2(x)) dx$ 。为了平滑边界  $C$ ,将边界的弧长  $|C|$  作为惩罚项加入到拟合函数中,最终的 RSF 模型的能量泛函定义为:

$$E_{RSF}(C, f_1(x), f_2(x)) = \int \epsilon_x^{Fit}(C, f_1(x), f_2(x)) dx + v|C| \quad (3)$$

为解决曲线演化过程中拓扑结构的变化问题,将式(3)用水平集函数表示:

$$E_{RSF}(\phi, f_1(x), f_2(x)) = \sum_{i=1}^2 \lambda_i \int \left( \int K_\sigma(x-y) |I(y) - f_i(x)|^2 M_i(\phi(y)) dy \right) dx + v \int |\nabla H(\phi(x))| dx \quad (4)$$

在函数  $\phi$  固定的条件下,相对  $f_1(x), f_2(x)$  最小化式(4),可得:

$$f_i(x) = \frac{K_\sigma(x) * [M_i(\phi(x)) I(x)]}{K_\sigma(x) * M_i(\phi(x))}, i=1,2 \quad (5)$$

在  $f_1(x), f_2(x)$  固定的条件下,相对  $\phi$  最小化式(4),可得:

$$\frac{\partial \phi}{\partial t} = -\delta(\phi) (\lambda_1 e_1 - \lambda_2 e_2) v \delta(\phi) \operatorname{div} \frac{\nabla \phi}{|\nabla \phi|} \quad (6)$$

其中, $e_i(x) = \int K_\sigma(y-x) |I(x) - f_i(y)|^2 dy, M_1(\phi(y)) = H(\phi), M_2(\phi(y)) = 1 - H(\phi), H$  是 Heaviside 函数, $H_\epsilon(z) = 0.5 [1 + (2/\pi) \arctan(z/\epsilon)], \delta(x) = H'(x)$ , 其中, $\delta_\epsilon(z) = (2/\pi) (\epsilon/\epsilon^2 + z^2)$ 。本文中  $\epsilon$  的值取为 1。

### 3 SHAC 模型

本文提出的 SHAC 模型的构建流程如图 1 所示。首先,根据形状几何相似性对样本训练集进行配准,将配准之后的形状表示成符号距离函数(SDF),应用 PCA 算法提取训练图像集的特征值、特征向量以及形状变化模式,结合平均符号距离函数和形状变化模式建立先验形状模版。然后,将先验形状模版融入结合了基于自适应区域的 RSF 模型的混杂活动轮廓模型中,使初始的主动轮廓在局部灰度信息及全局先验形状信息的约束下朝目标边界演化。

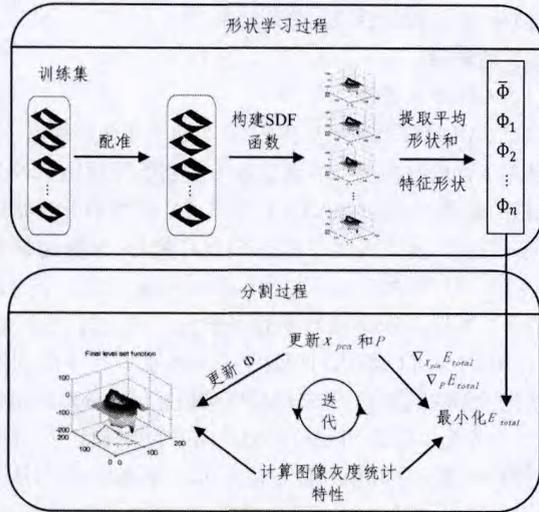


图 1 SHAC 模型构建流程

#### 3.1 先验形状学习

##### 3.1.1 形状配准

首先把  $N$  幅大小为  $m \times n$  的灰度图像二值化,其中每幅图像感兴趣的目标物体灰度值定义为 1,背景部分灰度值定义为 0。所有的目标形状都是相似的,用刚性配准方法可以对图像进行变换。当前瓶子形状和目标瓶子形状之间的刚性转换是一个映射  $T[p]$ ,  $p = [a \ b \ s \ \theta]$ ,其中  $a$  和  $b$  是  $x$  轴和  $y$  轴方向的平移参数, $\theta$  是旋转角度参数, $s$  是尺度参数,且转换之后在同一坐标系。设  $\tilde{I}(\tilde{x}, \tilde{y})$  分别是经过转换之后的对应的图像以及坐标轴,则  $\tilde{I}(\tilde{x}, \tilde{y})$  以及  $I(x, y)$  之间满足如下关系:

$$\tilde{I}(\tilde{x}, \tilde{y}) = T[p]I(x, y)$$

即:

$$\begin{bmatrix} \tilde{x} \\ \tilde{y} \\ 1 \end{bmatrix} = \begin{bmatrix} 1 & 0 & a \\ 0 & 1 & b \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} s & 0 & 0 \\ 0 & s & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} \cos\theta & -\sin\theta & 0 \\ \sin\theta & \cos\theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x \\ y \\ 1 \end{bmatrix} \quad (7)$$

则联合配准  $N$  幅图可用基于欧氏几何相似性变换 (EST) 的方法,此方法的形状配准函数  $E_{align}$  定义为:

$$E_{align} = \sum_{i=1}^n \sum_{j=1, j \neq i}^n \frac{\iint_{\Omega} (\tilde{I}^i - \tilde{I}^j)^2 dx dy}{\iint_{\Omega} (\tilde{I}^i + \tilde{I}^j)^2 dx dy} \quad (8)$$

对任意的  $i$ , 固定  $j$  最小化式(8),可得最优参数  $p^j$ , 即最优的  $s_i, \theta_i, a_i, b_i$ 。

图 2 示出 8 个瓶子的二值图像,图 3 是配准之后的结果。可以注意到图 2 和图 3 在边界上有微小的不同,是因为当参

数  $s$  改变的时候使用了膨胀或腐蚀的操作来维持演化曲线的闭合性。

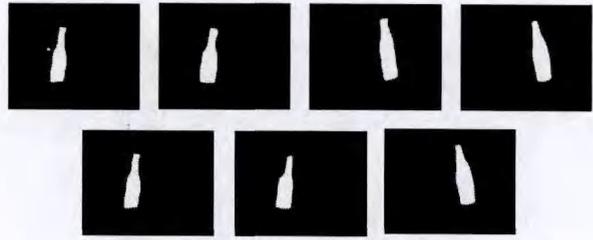


图 2 训练图像集: 8 个瓶子的二值图

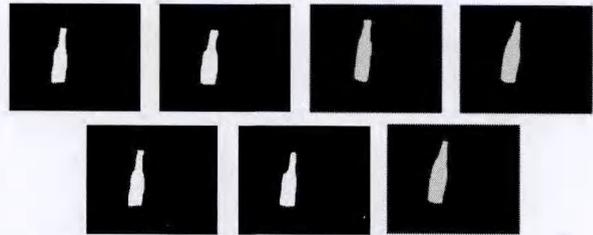


图 3 配准之后的瓶子的二值图

##### 3.1.2 运用 PCA 算法学习先验形状

将  $N$  幅配准之后的二值图像根据感兴趣目标物体的边界定义符号距离函数(SDF)表示为  $\{\varphi_i\}_{i=1, \dots, N}$ , 则平均水平集函数  $\bar{\varphi} = (1/N) \sum_{i=1}^N \varphi_i$ 。为了描述形状的变化,求每一个 SDF 函数与平均水平集函数  $\bar{\varphi}$  的偏移量  $\{\tilde{\varphi}_1, \tilde{\varphi}_2, \dots, \tilde{\varphi}_n\}$ , 其中,  $\tilde{\varphi}_i = \varphi_i - \bar{\varphi}, i = 1, 2, \dots, N$ , 这些偏移量函数可以捕捉  $N$  个形状与平均形状的变化。把所有的  $m \times n$  图像  $\tilde{\varphi}_i$  用列向量的形式定义为  $mn \times N$  维的形状变化矩阵  $M$ , 对相应的协方差矩阵  $C = (1/N)MM^T$  进行奇异值分解得:  $C = U\Sigma U^T$ , 其中  $\Sigma$  是由对应的奇异值构成的  $N \times N$  的对角矩阵,  $U$  是  $mn \times N$  矩阵, 矩阵的列是对应特征值的特征向量, 其代表的是形状的  $N$  个正交变化模式  $\{\omega_1, \omega_2, \dots, \omega_N\}$ , 特征值越大, 对应的形状变化模式越重要。假设降维后取前  $h$  个主要变化成分, 训练样本集中的任意一个形状可以用平均形状和前  $h$  个变化模式的加权和来近似表示:

$$\varphi_i = \bar{\varphi} + W_h X_{pca} = \bar{\varphi} + \sum_{i=1}^h \omega_i x_i \quad (9)$$

其中,  $W_h = (\omega_1, \omega_2, \dots, \omega_h)$  是由前  $h$  个特征向量构成的矩阵, 向量  $X_{pca} = (x_1, x_2, \dots, x_h)$  中的每一个元素是每个特征向量所对应的权系数, 可表示为  $X_{pca} = W_h^T (\varphi_i - \bar{\varphi})$ , 若令  $\Phi = W_h X_{pca}$  表示特征性状, 则不同的  $X_{pca}$  会产生不同的特征形状, 从而产生不同的形状模板。假设训练样本集在降维后的空间中的概率密度函数满足  $N$  维高斯分布, 则  $\Phi(X_{pca})$  的概率为:

$$P(\Phi(X_{pca})) = \frac{1}{(2\pi)^{\frac{h}{2}} |\Lambda_h|^{\frac{1}{2}}} \exp\left(-\frac{1}{2} X_{pca}^T \Lambda_h^{-1} X_{pca}\right) \quad (10)$$

其中,  $\Lambda_h$  是包含前  $h$  个特征值的对角矩阵。设  $E = -\log P(\Phi(X_{pca}))$ , 用梯度下降法求解此方程, 搜索最优的  $X_{pca}$ , 从而得到最优先验模型:

$$\begin{aligned} [\Phi(X_{pca})]_{n+1} &= [\Phi(X_{pca})]_n - \epsilon \nabla E \\ &= [\Phi(X_{pca})]_n - \epsilon \Lambda_h^{-1} [\Phi(X_{pca})]_n \end{aligned} \quad (11)$$

当式(11)收敛时, 可得最优的  $\Phi$ , 从而得到最优的  $X_{pca}$ ; 根据式(9)可得最优先验形状  $\psi$ 。

图 4 是 6 个主要特征值下瓶子的形状变化模式, 其中图

右侧的色带表示对应空间内瓶子形状变化模式的权重分配系数。图5是经过PCA变换之后的第一主成分对应的瓶子的形状信息,其中黑色实线表示的是瓶子的平均形状。

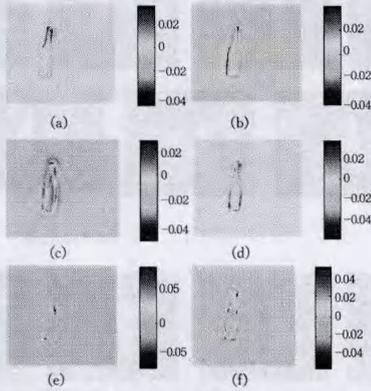


图4 6个主要特征值下瓶子的形状信息

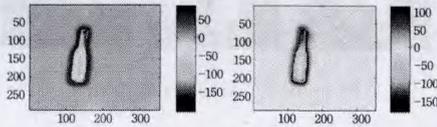


图5 瓶子的第一主成分±2√λ<sub>1</sub>

### 3.2 先验形状与混杂活动轮廓模型的融合

如引言中所述,由于基于区域的C-V模型和基于边界的GAC模型各自都有自身的不足,本文将先验形状模版作为约束,融入到基于自适应区域的RSF模型的混杂活动轮廓模型中,本文提出的模型的能量泛函定义是  $E_{total} = E_{RSF} + \lambda_s E_{shape}$ ,其中  $E_{shape}$  为:

$$E_{shape} = \iint_{\Omega} \{H(\phi) - H(\psi)\}^2 dx dy \quad (12)$$

$\psi$ 是由3.2节中训练出的最优形状,结合RSF模型的能量函数式(4),则最终的水平集能量泛函表示为:

$$\begin{aligned} E_{total}(\phi, \psi, f_1(x), f_2(x)) &= \sum_{i=1}^2 \lambda_i \int \left[ \int K_{\sigma}(x-y) |I(y) - f_i(x)|^2 M_i(\phi(y)) dy \right] dx + \\ & \quad v \int |\nabla H(\phi(x))| dx + \lambda_s \iint_{\Omega} \{H(\phi) - H(\psi)\}^2 dx dy \end{aligned} \quad (13)$$

运用变分法最小化该能量函数可以推导出基于水平集的曲线运动方程:

$$\frac{\partial \phi}{\partial t} = -\delta(\phi) (\lambda_1 e_1 - \lambda_2 e_2) + v \delta(\phi) \operatorname{div} \frac{\nabla \phi}{|\nabla \phi|} + 2\delta(\phi) \lambda_s (H(\phi) - H(\psi)) \quad (14)$$

当满足下面两个条件时,算法停止:

1. 演化曲线达到稳态,即式(14)收敛。

2. 演化曲线和形状模版之间满足

$$\iint_{\Omega} \{H(\phi) - H(\psi)\}^2 dx dy \leq \iint_{\Omega} \alpha \delta(\psi) dx dy$$

其中, $\alpha$ 是恒定值,在我们的实验中设为0.2。如果在演化过程中不满足条件2,说明形状项的影响权重不够,需要增大 $\lambda_s$ 或者减小 $\lambda_1$ 和 $\lambda_2$ 。

## 4 实验

### 4.1 实验设计

我们将运用本文提出的SHAC模型分析人工合成的被

遮挡的和带噪声的瓶子图、动态对比度增强的乳腺核磁共振图像以及具有复杂背景的汽车图像。实验主要分为以下几个步骤:

(1)根据形状几何相似性对样本训练集进行配准。

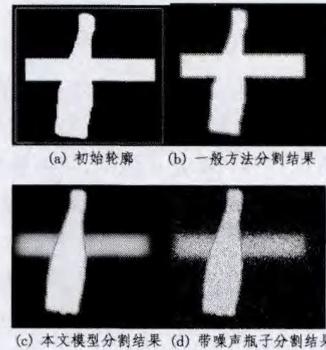
(2)根据配准之后的形状边界用符号距离函数求出平均水平集函数,然后运用PCA算法提取形状集的特征值、特征向量以及形状变化模式,结合平均符号距离函数和形状变化模式构建先验形状。

(3)对曲线运动方程(13)构建任意的初始状态,初始曲线在局部灰度信息以及全局先验形状信息的共同约束下朝目标边界演化,算法收敛后得到分割结果。

### 4.2 实验结果

#### 4.2.1 人工合成图像

选取MPEG7的数据集中的20个瓶子作为训练集。图6(a)是人工合成的被遮挡的测试瓶子的初始轮廓图。若分割有遮挡的瓶子的完整轮廓,GAC或者CV模型的分割结果如图6(b)所示。运用本文提出的SHAC模型,分割结果如图6(d)所示。其中,参数 $\lambda_1 = \lambda_2 = 1, v = 0.001 \times 255 \times 255, \lambda_s = 1/3, \sigma = 3.0$ ,Heaviside函数的时间步长 $\epsilon = 1$ ,迭代步长 $\Delta t = 0.4$ 。由图6(c)可以看出,即使目标物体瓶子有一部分被遮挡,在先验形状的驱动下,SHAC模型仍然可以分割出完整的瓶子。此外为了验证SHAC模型对噪声的鲁棒性,图6(d)是对图像6(a)加入了均值0且方差为0.05的高斯噪声,从分割结果可以看出,即使在有噪声的情况下,SHAC模型也仍然可以得到理想的分割结果,如图6(d)所示。



活动轮廓模型的分割结果如图中灰色曲线所示

图6 MPEG7的数据集中有遮挡的瓶子分割结果

#### 4.2.2 UCUI汽车数据集

从UCUI汽车数据集中选取60幅图像作为训练集,其余的30幅作为测试集,图7(c)是一幅背景复杂的汽车图,而且汽车的车头部分被树木遮挡,白色矩形框表示初始轮廓。图7(a)是基于PCA算法学习到的最优先验形状。图7(e)、(g)、(i)分别是运用GAC模型、C-V模型、RSF模型分割汽车的分割结果。在背景复杂的背景下,这3种模型均不能准确地分割目标物体。图7(k)是本文提出的SHAC模型的分割结果,从图中可以看出SHAC模型在复杂的背景下仍然能够分割出感兴趣的物体。这里我们选取的模型参数为: $\lambda_1 = 1, \lambda_2 = 2, \lambda_s = 1/2, \sigma = 3.0, v = 0.001 \times 255 \times 255$ 。

#### 4.2.3 乳腺动态对比度增强核磁共振图像

核磁共振具有对比度不高、灰度不均等特点,这种特点对分割算法具有较大的挑战。本文选取16个不同患者的同一

个乳腺 MRI 切面图作为训练集,10 幅作为测试集,图 7(d)是其中一幅测试的乳腺图像,图中白色矩形框表示初始轮廓,图 7(b)是基于 PCA 算法学习到的最优先验形状。图 7(f)、(h)、(j)分别是运用 GAC 模型、C-V 模型、RSF 模型的分割结果。可以看到,由于乳腺和身体连接部分组织灰度非常相似,这 3 种模型的分割结果都不是很理想。图 7(l) 是本文提出的 SHAC 模型的分割结果,从图中可以看到,该模型在低对比度、边界模糊、灰度不均的情况下仍然可以较好地分割出感兴趣区域轮廓。其中,参数设置为: $\lambda_1=1, \lambda_2=2, \lambda_3=1/3, \sigma=3.0, v=0.003 \times 255 \times 255$ ,迭代步长  $\Delta t=0.4$ 。

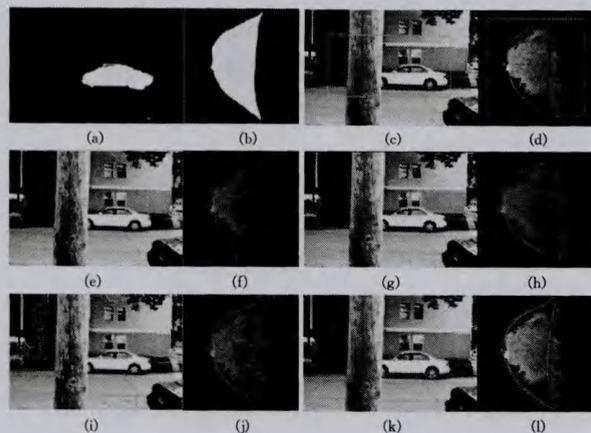


图 7 不同分割方法定量结果对比图

### 4.3 实验结果评估及分析

本文通过计算分割结果与参照图像的相似度来评价算法的优劣,相似度用戴斯系数(Dice coefficient)和峰值信噪比(PSNR)两种准则对 4 种模型的分割结果进行评估。其中戴斯系数  $DC=2(C_1 \cap C_2)/(C_1 + C_2)$  是一个从 0 到 1 的数,DC 越大表明分割结果越接近参照图像;峰值信噪比  $PSNR=10 \log((2^n - 1)^2 / MSE)$ ,比值越大说明分割结果越理想。表 1 是 4 种方法在 2 个数据集上获得的 Dice 和 PSNR 值,每组获得的最高值用黑体字标出。从表 1 中的结果可以看出:

(1) 基于先验形状的混杂活动轮廓模型得到的 Dice 和 PSNR 值明显高于其他方法,说明该模型在低对比度、噪声、遮挡、复杂背景干扰等情况下能较好地提取出感兴趣区域的轮廓,使目标分割更为准确。

(2) 对乳腺图的分割,其他 3 种方法的分割结果差异不太大。对背景复杂的汽车分割时,单独的 RSF 模型的 Dice 和 PSNR 值反而没有 CV 和 GAC 的值大,这是因为 RSF 模型是基于局部区域灰度的活动轮廓模型,由于背景复杂、不同的灰度区域较多,RSF 将这些区域都分割出来了。

表 1 不同分割方法的 Dice 和 PSNR 值

模型	Dice		PSNR	
	乳腺 MRI	汽车	乳腺 MRI	汽车
GAC	0.65	0.70	8.88	15.18
CV	0.74	0.67	9.44	14.81
RSF	0.72	0.17	8.80	3.02
SHAC	<b>0.99</b>	<b>0.98</b>	<b>9.66</b>	<b>19.21</b>

**结束语** 本文提出了一种新颖的基于先验形状学习的混杂活动轮廓模型(SHAC),该模型融合自适应区域信息与边界信息,同时引入先验信息来实现对感兴趣区域的分割。自

适应区域信息与边界信息作为局部信息,先验形状作为全局信息,约束水平集的演化范围,使水平集朝特定形状收敛。而且基于 RSF 函数的区域项克服了 C-V 模型中计算感兴趣区域的灰度是相对整个全局区域中前景和背景的平均灰度的缺点,自适应地向灰度最相似的地方靠近,增加了主动轮廓的收敛速度,同时较好地保持了曲线在演化过程中的光滑。把 SHAC 模型与 GAC、C-V 以及 RSF 模型应用于低对比度的乳腺磁共振图像中的乳腺轮廓的分割,以及具有复杂背景的自然图像中感兴趣区域的分割结果的定量和定性分析,其结果表明在低对比度、噪声、遮挡、复杂背景干扰等情况下,SHAC 模型都能较好地提取出感兴趣区域的轮廓,使目标分割更为准确。

### 参考文献

- [1] Kass M, Witkin A, Terzopoulos D. Snakes: Active contour models[J]. International journal of computer vision, 1988, 1(4): 321-331
- [2] Chuang C H, Chao Y L, Li Z P. Moving object segmentation and tracking using active contour and color classification models[C]// 2010 IEEE International Symposium on Multimedia (ISM). IEEE, 2010: 73-80
- [3] Paragios N, Mellina-Gottardo O, Ramesh V. Gradient vector flow fast geometric active contours[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2004, 26(3): 402-407
- [4] Caselles V, Kimmel R, Sapiro G. Geodesic active contours[J]. International journal of computer vision, 1997, 22(1): 61-79
- [5] Chan T F, Vese L A. Active contours without edges[J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277
- [6] Cremers D, Rousson M, Deriche R. A review of statistical approaches to level set segmentation: integrating color, texture, motion and shape[J]. International journal of computer vision, 2007, 72(2): 195-215
- [7] Zhang K, Zhang L, Song H, et al. Active contours with selective local or global segmentation: A new formulation and level set method[J]. Image and Vision Computing, 2010, 28(4): 668-676
- [8] Liu Z, Zhang L, Ren H, et al. A robust region-based active contour model with point classification for ultrasound breast tumor segmentation[C]// SPIE Medical Imaging, International Society for Optics and Photonics, 2013, 8670
- [9] Mumford D, Shah J. Optimal approximations by piecewise smooth functions and associated variational problems[J]. Communications on pure and applied mathematics, 1989, 42(5): 577-685
- [10] Li C, Kao C Y, Gore J C, et al. Minimization of region-scalable fitting energy for image segmentation[J]. IEEE Transactions on Image Processing, 2008, 17(10): 1940-1949
- [11] Xu J, Janowczyk A, Chandran S, et al. A high-throughput active contour scheme for segmentation of histopathological imagery [J]. Medical Image Analysis, 2011, 15(6): 851-862
- [12] Paragios N, Deriche R. Geodesic active regions: A new framework to deal with frame partition problems in computer vision [J]. Journal of Visual Communication and Image Representation, 2002, 13(1): 249-268

(下转第 316 页)

**结束语** 传统的高斯滤波对整幅图像采用固定大小的高斯掩模窗口,并未考虑局部高频边缘信息或平滑区域中可能存在的纹理细节信息,这必然会使滤波后的图像在实现图像去噪的同时,丢失丰富的纹理信息。本文通过分析局部亮度相似性,构建一种局部自适应的不规则高斯掩模窗口,剔除可能存在的噪声点或相似性较低的像素,在较好地实现了图像滤波的同时最大程度地保留了边缘及纹理细节信息,从而改善了图像的质量。如何将本文提出的算法应用于彩色图像的有效滤波,提高信噪比,将是我们下一步的研究内容。

### 参 考 文 献

[1] Jafar I F, AlNa'mneh R A, Darabkh K A. Efficient improvements on the BDND filtering algorithm for the removal of high-density impulse noise [J]. *IEEE Transactions on Image Processing*, 2013, 22(3): 1223-1232

[2] Rajwade A, Rangarajan A, Banerjee A. Image denoising using the higher order singular value decomposition [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(4): 849-862

[3] Yu Wei, Franchetti F, Hoe J C, et al. Fast bilateral filtering by adapting block size [C]// *Proceedings of IEEE International Conference on Image Processing*. Hong Kong, China, 2010: 3281-3284

[4] 许光宇, 檀结庆, 钟金琴. 自适应的有效非局部图像滤波 [J]. *中国图象图形学报*, 2012, 17(4): 471-479

[5] Kang B, Choi O, Kim J D, et al. Noise reduction in magnetic resonance images using adaptive non-local means filtering [J]. *Electronics Letters*, 2013, 49(5): 324-326

[6] 张闯, 迟健男, 张朝晖, 等. 基于边缘检测与双边滤波的彩色图像去噪 [J]. *电子学报*, 2010, 33(8): 1771-1783

[7] Overton K I, Weymouth T E. A noise reducing reprocessing algorithm [C]// *Proceedings of IEEE Computer Science Conference*

on Pattern Recognition and Image Processing. Chicago, USA, 1979: 498-507

[8] 肖秀春, 彭群生, 卢晓敏, 等. 基于次序统计量像素灰度相似度的图像双边滤波 [J]. *计算机辅助设计与图形学学报*, 2011, 23(7): 1232-1237

[9] Zheng You-Yi, Fu Hong-bo, Au OK C, et al. Bilateral normal filtering for mesh denoising [J]. *IEEE Transactions on Visualization and Computer Graphics*, 2011, 17(10): 1521-1530

[10] Zhang Ke, Lu Jian-Bo, Lafruit G. Cross-based local stereo matching using orthogonal integral images [J]. *IEEE Transactions on Circuits and Systems for Video Technology*, 2009, 19(7): 1073-1079

[11] Guerreiro R F C, Aguiar P M Q. Learning simple texture discrimination filters [C]// *Proceedings of IEEE International Conference on Image Processing*. Hong Kong, China, 2010: 261-264

[12] Buades A, Coll B, Morel J M. Nonlocal image and movie denoising [J]. *International Journal of Computer Vision*, 2008, 76(2): 123-139

[13] Markus A M, Anjia B, Martin W, et al. Wavelet denoising of multiframe optical coherence tomography data [J]. *Biomedical Optics Express*, 2012, 3(3): 572-589

[14] de Decker A, Lee J A, Verleysen M. A principle approach to image denoising with similarity kernels involving patches [J]. *Neurocomputing*, 2010, 73(7): 1199-1209

[15] He Kai-Ming, Sun Jian, Tang Xiao-Ou. Guided Image Filtering [J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2013, 35(6): 1397-1409

[16] Dabov K, Foi A, Katkovnik V et al. Image denoising by sparse 3D transform-domain collaborative filtering [J]. *IEEE Transactions on Image Processing*, 2007, 16(8): 2080-2095

[17] Xydeas C S, Petrovic V. Objective image fusion performance measure [J]. *Electronics Letters*, 2000, 36(4): 308-309

(上接第 305 页)

[13] Leventon M E, Grimson W E L, Faugeras O. Statistical shape influence in geodesic active contours [C]// *IEEE Conference on Computer Vision and Pattern Recognition*, 2000. IEEE, 2000, 1: 316-323

[14] Tsai A, Yezzi A J, Wells W, et al. A shape-based approach to the segmentation of medical imagery using level sets [J]. *IEEE Transactions on Medical Imaging*, 2003, 22(2): 137-154

[15] Ali S, Madabhushi A. An Integrated Region-, Boundary-, Shape-Based Active Contour for Multiple Object Overlap Resolution in Histological Imagery [J]. *IEEE Transactions on Medical Imaging*, 2012, 31(7): 1448-1460

[16] Liu W, Shang Y, Yang X, et al. A shape prior constraint for implicit active contours [J]. *Pattern Recognition Letters*, 2011, 32

(15): 1937-1947

[17] Agner S C, Xu J, Madabhushi A. Spectral embedding based active contour (SEAC) for lesion segmentation on breast dynamic contrast enhanced magnetic resonance imaging [J]. *Medical Physics*, 2013, 40(3): 032305

[18] Fatakawala H, Basavanahally A, Xu J, et al. Expectation-maximization driven geodesic active contour with overlap resolution (emagacor): Application to lymphocyte segmentation on breast cancer histopathology [C]// *Proceedings of the 2009 Ninth IEEE International Conference on Bioinformatics and Bioengineering*. 2009: 69-76

[19] 杨利萍, 邹琪. 基于先验形状信息的水平集图像分割 [J]. *计算机科学*, 2012, 39(8): 288-291