

DOI: 10.7652/xjtuxb201302009

多尺度非参数化水平集的超声心动图分割

高燕华¹, 刘玉欢², 喻罡²

(1. 西安交通大学第三附属医院, 710068, 西安; 2. 中南大学地球科学与信息物理学院, 410083, 长沙)

摘要: 针对超声心动图噪声很大、提取目标区域边界不够平滑完整的问题, 将非参数技术与水平集相结合, 提出了多尺度非参数化的水平集图像分割方法。利用非局域均值滤波建立尺度空间, 保护图像特征, 在粗尺度预分割, 然后在细尺度优化分割。采用 Parzen 窗技术对超声心动图的亮度分布进行统计建模, 不需要先验假设, 引入到水平集框架中, 设计了非参数化水平集分割模型。分割实验证明: 预分割结果和真实边界的平均绝对距离为 2.162, 优化后为 0.710。该方法可以精确地自动提取感兴趣区域, 在图像分割鲁棒性和精确性方面优于常规分割方法。

关键词: 图像分割; 非局域均值滤波; 水平集; 非参数化

中图分类号: TN911.7 **文献标志码:** A **文章编号:** 0253-987X(2013)02-0053-05

Multiscale Non-Parametric Level Set Segmentation of Ultrasound Echocardiography

GAO Yanhua¹, LIU Yuhuan², YU Gang²

(1. Third Affiliated Hospital, Xi'an Jiaotong University, Xi'an 710068, China;

2. School of Geosciences and Info-Physics, Central South University, Changsha 410083, China)

Abstract: To solve difficulty that the boundary of segmented objective region is not enough smooth and complete due to ultrasound echocardiography with serious noise, a multiscale segmentation approach combined non-parametric technique with level set, is presented. The nonlocal means filtering (NLM) is performed to create scale space and preserve image features. Pre-segmentation is firstly carried out in a coarser scale image, then an optimized segmentation in a finer scale image, the intensity distribution of the ultrasound echo images is modeled by Parzen window technique without prior assumption. A non-parametric model on level set framework is designed to segment the ultrasound echocardiography. The segmentation experiments show that the mean absolute distance (MAD) between real boundary and pre-segmentation result gets to 2.162, but, and the optimized result only 0.710. The approach outperforms the conventional segmentation methods by accurately and automatically extracting the regions of interest.

Keywords: image segmentation; nonlocal means filtering; level set; non-parametric

超声心动图的自动分割对于心脏疾病的临床诊断具有重要意义。超声图像存在大量的斑点噪声, 这些噪声会严重影响分割。尽管过去提出了许多分割方法, 但是在分割精确度、自动化等方面存在许多

问题。

早期超声心动图像的边界检测应用一些统计方法, 精确性需要进一步改进^[1]。水平集方法可以稳定处理轮廓的拓扑变化, 在图像分割中得到广泛应

收稿日期: 2012-05-16。 作者简介: 高燕华(1977—), 女, 硕士, 主治医师; 喻罡(通信作者), 男, 博士, 副教授。 基金项目: 国家自然科学基金资助项目(81000635)。

网络出版时间: 2012-09-28

网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20120928.1135.001.html>

用^[2]。例如,Chan 提出了无边界的活动轮廓模型,使用内部和外部的平均亮度来分割图像^[3],但难以分割复杂的超声图像。Paragios 提出了基于梯度矢量流的分割模型^[4],但是需要大量的计算时间,在弱边界上容易失效。一些水平集模型引入先验形状来提取超声心动图的边界^[5],但是需要进行大量训练。形状模型不适合个体差异大的对象,如心室与心房的形状与超声探头的位置、扫描方向相关。

另一种分割思想是将统计学方法和水平集相结合^[6-7],包括参数化和非参数化方法。其中,参数化方法对超声图像的概率分布的形式进行假设。图像的斑点状信号常用 Rayleigh 分布来描述,广泛用于超声图像分割^[8]。另外,一些非 Rayleigh 统计模型也用于超声图像建模,如 K 分布和 Rician inverse Gaussian(RIG)分布等。为了改善超声图像分割,需要先抑制斑点噪声,常用的方法如小波、非线性扩散等。非局域均值滤波(NLM)可得到均匀组织且不容易引入伪影,对超声图像去噪表现出极好的性能^[9]。去噪会改变图像的统计学规律,若采用大模板的高斯滤波器后,概率密度会趋于高斯分布。采用非线性滤波器,则概率密度变得更为复杂。所以,参数化方法常假设去噪后图像符合高斯分布^[6]。

非参数方法,如 Parzen 窗,利用手动或者预分割获取样本,估计总体概率密度,然后依据分割准则得到分割结果。文献[10]利用 Parzen 窗估计概率,结合马尔科夫模型分割肿瘤图像。文献[11]用 Parzen 窗估计各类别的概率密度,基于统计神经网络,实现超声图像的分类。这些方法可以得到绝大部分的目标区域,但边界不够平滑完整,需要进一步处理。

水平集捕获的图像边界完整且光滑,适用于各种边界形状。所以,将非参数方法和水平集相结合,可以很好地估计超声图像的概率密度,也能获取优化的分割边界。本文利用 NLM 滤波建立尺度空间,以保护超声图像的特征,尽可能降低斑点噪声,然后采用非参数方法估计去噪后图像的概率密度,再与水平集方法相结合,分割心动图。

1 方 法

本文方法建立在尺度空间的基础上,对图像先进行预分割,然后优化分割,以降低对斑点噪声的敏感性,流程如图 1 所示。

1.1 非局域均值滤波

NLM 滤波认为图像中有许多相似的图像块,




图 1 本文方法的流程图

对这些块进行加权平均,可以有效降低噪声并保护信号。为了获取更多的图像块,尽可能搜索图像中的更大区域,所以称为非局域滤波^[9]。在像素 x 处,NLM 滤波结果如下

$$I(x) = \sum_{y \in N_L} w(x, y) I(y), \quad \sum_{y \in N_L} w(x, y) = 1 \quad (1)$$

式中: x 是要滤波的像素; y 是搜索范围 N_L 内的一个像素; $I(x)$ 和 $I(y)$ 是 x 和 y 的亮度值。设 N_x 和 N_y 是以 x 和 y 为中心的图像块,权值定义为

$$w(x, y) = \frac{1}{Z} \exp\left(-\frac{d(N_x, N_y)}{\delta^2}\right) \quad (2)$$

式中:距离加权的 N_x 和 N_y 相似性量度 $d(N_x, N_y) = G_p \|I(N_x) - I(N_y)\|^2$, G_p 是 x 和 y 之间的距离; δ 是与噪声水平有关的衰退系数; Z 是所有权值之和,用于权值的归一化。式(2)表明:离滤波像素 x 较近的,且 N_y 和 N_x 相似的 y 具有较大的权值。搜索范围内所有相似的 $I(y)$ 加权平均后, x 的像素值趋于真实的像素值。

1.2 非参数化的预分割模型


在尺度空间上,对粗尺度图像进行预分割。首先运用 Mory 提出的误差函数,对单个像素的分割错误进行建模^[12]。图像灰度级范围为 A ,则像素 x 对区域 i 的分割错误定义如下

$$e(i, x) = \int_{a \in A} (p_i(a) - K(I(x) - a))^2 da \quad (3)$$

式中: $p_i(a)$ 是灰度值为 a 的像素属于区域 i 的概率; K 定义为 $\int K(x) dx = 1$, $K(x) > 0$; $I(x)$ 为像素 x 处的亮度值; K 表示在 x 处估计的局部概率密度。这个误差函数描述了 x 误分为区域 i 的惩罚项,见图 2。

设图 2 中有两个区域, x 局部概率密度靠近 $p_1(a)$,所以可以认为 x 属于区域 1。如果 x 误分到区域 2,那么式(3)的计算值会变大,成为误分割的惩罚项。

假设图像中只有两个区域,那么总的分割误差可以表示为图像中所有像素分割误差之和,能量函数表示如下



(a)图像的两个区域 (b)图像亮度与概率密度的关系

图2 单像素图像的分割误差示意图

$$E = \int_{x \in \Sigma} \int_{a \in A} (p_1(a) - K(I(x) - a))^2 da dx + \int_{x \in \Sigma^c} \int_{a \in A} (p_2(a) - K(I(x) - a))^2 da dx \quad (4)$$

式(4)是预分割的目标函数。如果每个像素都被分割到了正确区域,那么总的分割误差最小。依据变分方法,对式(4)最小化,则曲线演化的速度函数为

$$F = 2 \int_{a \in A} (p_2(a) - p_1(a)) K(I(x) - a) da + \int_{a \in A} (p_1(a)^2 - p_2(a)^2) da \quad (5)$$

式中

$$p_1(a) = \frac{1}{|\Sigma|} \int_{\Sigma} K(I(x) - a) dx$$

$$p_2(a) = \frac{1}{|\Sigma^c|} \int_{\Sigma^c} K(I(x) - a) dx$$

显然, $p_1(a)$ 和 $p_2(a)$ 是目标和背景区域概率密度的 Parzen 窗估计。为了加快收敛速度,引入测地线活动轮廓作为边界力^[13],与式(5)合并,得

$$F' = wF + (1 - w) \{ g(|\nabla I|) (c_1 + c_2 k) - (\nabla g(|\nabla I|) \cdot \mathbf{N}) \} \quad (6)$$

式中:大括号内是测地线速度函数; c_1 、 c_2 是测地线模型中的参数; k 是演化曲线的曲率; $\mathbf{N}$ 是曲线的单位向量; g 是一个单调下降函数。式(6)是非参数化的速度函数,实现预分割。

1.3 非参数化的局部优化分割模型

预分割后,演化曲线收敛到真实边界附近。一般来说,真实边界内侧和外侧(在边界附近的)像素差异最大,可以简单地认为两侧像素亮度的平均值相差最大。同时,曲线长度应尽可能短,以保证边界的光滑性。因此,能量函数定义如下

$$E = -(\mu_1 - \mu_2)^2 + \lambda \oint ds \quad (7)$$

其中

$$\mu_1 = \int_{L_1} I(x) p_1(I(x)) dx$$

$$\mu_2 = \int_{L_2} I(x) p_2(I(x)) dx$$

$$p_1(a) = \frac{1}{|L_1|} \int_{L_1} K(I(x) - a) dx$$

$$p_2(a) = \frac{1}{|L_2|} \int_{L_2} K(I(x) - a) dx$$

式中: L_1 和 L_2 是演化曲线内、外两侧附近(局部)区域,初始状态由预分割得到; μ_1 和 μ_2 是像素亮度的加权平均值; $\oint ds$ 是曲线长度; λ 是权值。当曲线演化到真实边界时, μ_1 和 μ_2 相差最大,当边界光滑时, $\oint ds$ 最小,因此式(7)取得最小值。依据变分方法,得到速度函数为

$$F = (\mu_1 - \mu_2) \left(\frac{I(x) - \mu_1}{|L_1|} + \frac{I(x) - \mu_2}{|L_2|} \right) + \lambda k \quad (8)$$

2 实验

实验数据集由 100 个超声心动图样本(检查对象)组成,从西安交通大学第三附属医院 B 超室一个月获取的 1 000 多个样本中随机抽取。每张图像为 759 像素 $\times$ 562 像素。实验采用平均绝对距离 (L_{MAD}) 定量评估真实边界 A 与分割边界 B (演化曲线停止位置) 的相似性。令 A 和 B 由一些点集组成, $A = \{a_1, a_2, \dots, a_n\}$, $B = \{b_1, b_2, \dots, b_m\}$, 则 L_{MAD} 定义如下

$$L_{MAD}(R, S) = \frac{1}{2} \left\{ \frac{1}{n} \sum_{i=1}^n d(r_i, S) + \frac{1}{m} \sum_{i=1}^m d(s_i, R) \right\} \quad (9)$$

式中: $d(a_i, B) = \min_{j \in [1, m]} \|b_j - a_i\|$ 。显然, L_{MAD} 越小,分割越精确。NLM 滤波的 N_x 和 N_y 大小为 5, 搜索范围 N_L 为 15, 实验证明适合大多数超声图像。根据噪声水平 δ 设为 $[0.2, 3]$, 式(6)中 $w = 0.6$, $c_1 = 1$, $c_2 = 0.2$, 式(8)中 λ 设为 0.4, 图像分割过程见图 3~图 6。

图 3a 和图 5a 是数据集集中的两幅心动图像。图 3b 是粗尺度图像, 3c 是演化曲线的初始位置。图 4a 是预分割结果, 由预分割模型(式(6))得到。预分割结果作为优化分割的初始位置, 图 4b 是优化结果(式(8)), 可见优化结果更加平滑, 更加接近专家的手动结果(见图 4c)。图 5 和图 6 是另一个样本分割结果。分割时间和图像大小、初始曲线位置有关, 一般约在 3~5 s 左右。

由 3 个有经验的医生手动分割超声心动图像, 采用他们的平均结果作为真实边界。图 4b 的 L_{MAD} 约为 0.859, 图 5b 的 L_{MAD} 约为 0.642。100 个样本




图 3 样本 1 粗尺度图像分割的初始状态




图 4 样本 1 超声心动图的预分割和优化分割结果




图 5 样本 2 粗尺度图像分割的初始状态



图 6 样本 2 超声心动图的预分割和优化分割结果

分割结果的 L_{MAD} 如表 1 所示,包括平均 L_{MAD} 、最大 L_{MAD} 和最小 L_{MAD} 。

为了证明本文方法的有效性,采用 4 种已有的

表 1 100 个样本分割结果的 L_{MAD}

方法	平均 L_{MAD}	最小 L_{MAD}	最大 L_{MAD}
预分割	2. 162	1. 225	4. 486
优化分割	0. 710	0. 326	1. 103

水平集方法进行对比,分别是 Ning 模型^[10]、Alessandro 模型^[8]、测地线模型^[13]、Malladi 模型^[14]。Ning 模型采用高斯分布估计超声心动图像,在尺度空间上进行分割;Alessandro 模型利用 Rayleigh 分析超声图像,直接在原始图像中分割;测地线模型和 Malladi 模型利用边界信息分割,分割结果见图 7。

图 7b 中 Ning 模型使用高斯滤波,模糊了边




图 7 本文方法和 4 种传统方法的分割结果的对比

界,演化曲线在右侧出现溢出,预分割不精确,所以优化分割也难以得到满意结果。Alessandro 模型在原始图像上分割,没有采用有效的降噪策略,超声图像存在大量噪声,所以错误标记了一些区域,曲线出现局部收敛,见图 7c。实验发现:如噪声较低,且心室内部比较均匀,Alessandro 能取得较好的结果。测地线和 Malladi 模型都没有使用区域信息,超声图像噪声较大,边界估计不够准确,所以均出现溢出,且在大多数情况下,这两种方法结果接近。因为 4 种现有方法在一些超声心动图上分割失败,这里只对基本分割成功的样本计算 L_{MAD} ,结果见表 2。

表 2 4 种传统分割方法和本文方法的 L_{MAD}

方法	平均 L_{MAD}	最小 L_{MAD}	最大 L_{MAD}
Ning 模型	1.281	0.412	1.904
Alessandro 模型	1.453	0.633	2.146
测地线模型	2.152	1.529	2.868
Malladi 模型	1.816	1.472	2.537
本文方法	0.710	0.326	1.103

3 结 论

本文提出了一种非参数化的统计水平集方法,用于超声心动图分割。这种方法不需要对图像的先验概率密度进行假设,因此可以应用任何一种滤波方法来降低噪声。采用 NLM 滤波建立尺度空间,可以保护心动图上的必要细节,降低噪声,提高分割

鲁棒性。结果证明:本文方法可以比较好地处理超声图像中的噪声,完成心动图的分割,与 4 个水平集模型的结果相比,具有更高的鲁棒性和精确性。

参考文献:

[1] XIAO G, BRADY M, NOBLE J A, et al. Segmentation of ultrasound B-mode images with intensity in homogeneity correction [J]. IEEE Transactions on Medical Imaging, 2002, 21(1): 48-57.

[2] LIU Jiamin, JAYARAM K U. Oriented active shape models [J]. IEEE Transactions on Medical Imaging, 2009, 28(4): 571-584.

[3] CHAN T F. Active contours without edges [J]. IEEE Transactions on Image Processing, 2001, 10(2): 266-277.

[4] 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.

[5] PARAGIOS N. A level set approach for shape-driven segmentation and tracking of the left ventricle [J]. IEEE Transactions on Image Processing, 2003, 22(6): 773-776.

[6] LIN N, YU W, DUNCAN J S. Combinative multi-scale level set framework for echocardiographic image segmentation [J]. Medical Image Analysis, 2003, 7(4): 529-537.

(下转第 96 页)