

利用 SIFT 特征和群体统计信息进行 CT 前列腺图像分割

冯前进 秦安 陈武凡

(南方医科大学生物医学工程学院, 广州 510515)

摘要 提出了一种采用活动形状模型的图像自动分割方法,用于对放疗中 CT 前列腺图像的自动分割。活动形状模型的关键问题包括形状模型与表面模型的构建,本文利用尺度不变局部特征在前列腺图像边界上的特异性,建立了精确的前列腺表面模型。为了更好地描述特定病人前列腺形状变化,本文提出了在线学习训练机制,在当前病人样本数较少的情况下,采用群体统计信息建立形状模型,随当前病人样本数的增加,逐步增加当前病人样本统计信息在对构建形状模型的权重。本文对 24 个病人的共 264 套图像进行了实验,结果显示平均 Dice 相似性系数为 90.5%,平均表面距离为 1.90mm,表明本文方法有很高精确,264 套图像中只有一套图像的 Dice 相似性系数小于 70%,表明本方法有很好的鲁棒性。

关键词 活动形状模型 形状模型 表面模型 前列腺 CT 图像 尺度不变特征变换

中图法分类号: TP751.1 **文献标志码:** A **文章编号:** 1006-8961(2010)06-873-06

SIFT and Population Statistics Based Segmentation of CT Prostate Image

FENG Qianjin, QIN An, CHEN Wufan

(School of BME, Southern Medical University, Guangzhou 510515)

Abstract This paper presents a new active shape models (ASMs) based method to segment the prostate from CT images for the radiotherapy. The key point of ASMs is the construction of both shape model and appearance model. We utilize the scale invariant feature transform (SIFT) local descriptor, which is more distinctive than general intensity and gradient features on the edges of the prostate boundary in the CT images, to characterize the image features and build the appearance model. To accurately capture prostate shape variation, an online training mechanism is proposed to build the shape model. When the samples of current patient are limited, the population statistics is used to build the shape model. As the increase of the samples of current patient, the patient-specific statistics plays an important role for constructing the shape model gradually. We test our method on a data set including 264 images of 24 patients, the average Dice similarity coefficient (DSC) is 90.5% and the mean average surface distance (ASD) is 1.90mm. The results show that the proposed method is robust and accurate.

Keywords active shape model, shape model, appearance model, prostate CT images, SIFT

0 引言

前列腺 CT 图像的分割是 CT 引导前列腺癌放射治疗的必需过程。在临床前列腺癌适应性放疗

中,病人需预先进行一次 CT 检查,其图像中前列腺被手工精确分割以制定放疗计划,此图像称为计划图像。在后续每次放疗前,通过新采集的 CT 图像对放疗计划进行调整。在临床应用中,这些图像也需要手工分割,对于有经验的临床医师,手工分割前

基金项目:国家自然科学基金青年基金(30900380);广东省自然科学基金(9151051501000026);广东省产学研项目(cgzhzd0717)

收稿日期:2009-10-10;**改回日期:**2010-03-18

第一作者简介:冯前进(1974—),男,副教授。2003年于第一军医大学获生物医学工程专业博士学位。主要从事医学图像分析与可视化方面研究,已发表相关论文40余篇。E-mail: qianjinfeng08@gmail.com

列腺也是困难且耗时的的工作,精确分割一套前列腺数据常需 1 个小时以上。在一个患者整个放疗过程中,通常有 20 ~ 30 套 CT 数据需要分割,工作量极大。因此前列腺 CT 图像自动分割方法的研究有迫切的临床需要。

前列腺 CT 图像自动分割的主要难点在于前列腺图像与其周边组织间对比度较低且其自身形状差异较大。基于变形模型^[1]的分割方法可方便整合形状模型与表面模型,为当前主流前列腺分割方法。基于变形模型的前列腺自动分割方法的研究主要集中在:


1) 如何构建优化图像特征,以引导形状模型匹配到图像中的待分割目标。在医学图像处理领域,图像灰度信息^[1]、分位数直方图^[2]、图像灰度概率分布^[3]都已被作为图像特征用来引导形状变形过程。同时,在计算机视觉领域,近年来出现了多种图像特征提取方法,如尺度不变特征变换(SIFT)^[4]、方向滤波^[5]等,在这些特征中,SIFT 在刻画图像局部特性时具有最好的性能^[6]。Shi^[7]等人将 SIFT 特征应用于肺部 CT 图像的分割,取得了很好的效果,说明对于医学图像而言,SIFT 特征也具有很好的应用前景。本文将采用 SIFT 特征来引导前列腺的分割。

2) 如何构建紧密的统计形状模型,以精确地描述前列腺的形状变化。活动形状模型(ASMs)^[1]、中间形状表示模型(m-reps)^[8]为常用的构建形状模型的方法。本文中,类似于 ASMs,将采用点分布模型(PDMs)构建形状模型。


前列腺的形状变化包括同一病人前列腺随时间不同的形状变化(病人内变化)与不同病人前列腺

的形状变化(病人间变化)。在前列腺癌放疗过程中,计划图像通常被精确人工分割以制订放疗计划,有这一精确分割结果,同时如果能够求得当前放疗病人前列腺形状变化,其后续治疗过程中的前列腺分割将非常容易。换言之,对于放疗前列腺自动分割方法而言,获得待治疗病人前列腺形状变化至关重要。而传统的方法采用群体样本构建训练集,其训练得到的形状模型必定包括了病人内与病人间前列腺形状变化。而病人间的变化远大于同一病人不同图像的变化,如图 1 所示(每行为同一病人的前列腺形状,从图中可看出同一病人的前列腺形状非常相似,不同病人的前列腺形状差异较大。图 1(b)所示的量化结果表明对于测试的 24 个病人的数据,病人间的前列腺形状变化大于病人内的变化。)因此,在传统基于 ASMs 与 m-rep 的分割方法中,其主要成分分析(PCA)或主测地线分析(PGA)的结果必将被病人间的变化所主导,不利于描述病人内的前列腺形状变化。为了克服病人间前列腺形状变化对分割精度的影响,文献[2-3]用同一病人的数据组成训练集训练形状模型,虽得到了很好的分割精度,但在临床中,对于同一个病人,不可能有那么多已分割好的数据用来构建训练数据集,因此这类方法并不能适用在放疗临床。

本文旨在提出一种前列腺 CT 图像的自动分割方法,利用当前病人计划图像与已分割的图像数据,结合训练集中其他病人的数据,建立能精确描述当前病人前列腺形状变化的形状统计模型。同时引入 SIFT 特征,利用 SIFT 在前列腺边界上的特异性,建立更有效的表面模型,对当前病人在放疗过程中的后续 CT 图像进行精确的分割。



(a) 3 位病人 4 次放疗前的前列腺形状



(b) 24 位病人的定量计算结果

图 1 前列腺病人内与病人间形状变化比较图

Fig. 1 Demonstration of the comparison between intra-patient and inter-patient variation

1 方 法

本文方法包括两个部分:在线学习训练机制与基于变形模型的分割。在这两部分中,图像与形状将被变换到统一的基准空间中。文中采用当前放疗病人的计划图像空间作为训练和分割的基准空间。所有的图像和形状在处理之前都需要变换到该基准空间中,对于图像,利用通用软件包 FLIRT 将所有图像经仿射变换映射到基准空间,对于形状,采用最小二乘方法将所有形状经仿射变换映射到基准空间。

1.1 在线学习机制

在我们的训练集中有多个其他病人的数据,称其为群体数据,对当前待分割病人图像,至少有一个分割好的计划图像,随着其后续图像被分割,可得到多个当前病人的分割好的数据用于训练形状模型。(如:在时间点 t ,有 $t - 1$ 个已分割图像与一个计划图像可用于训练。)这部分数据称为特定病人的数据 (Patient-specific data)。为了去除病人间的前列腺形状变化对形状模型的影响,如文献[2-3]一样,可采用当前病人的数据训练形状模型,但在放疗初期,如第 1 次放疗时 ($t = 1$),只有一个计划图像可用,样本的个数太少,不能满足统计训练的要求,这也是我们说文献[2-3]方法不能应用于临床的原

因。为解决这一问题,文献[9]假设,对于不同病人,病人内的前列腺形状变化是相似的,则可利用其他病人的病人内变化来约束当前病人的前列腺形状变化,在当前病人样本数很少时,这是好的选择,但我们认为,随着当前病人样本数的增加,当前病人的病人内变化应渐渐取代其他病人的信息而主导形状模型,这显然是合理的。出于这一想法,利用群体数据与当前病人数据构建训练数据集,在残留形状空间建立形状统计模型,通过加权 PCA 来调整群体信息与当前病人信息在形状统计模型中的权重。在线学习机制的流程图如图 2 所示,具体步骤如下:

- 1) 训练集中的和当前病人已分割图像的所有前列腺外表面经仿射变换映射到基准空间,用 s_{align} 表示。每一病人的平均形状用 s_{mean} 表示。通过在 s_{align} 中减去 s_{mean} 可以得到残留形状 s_{res} 。
- 2) 对残余形状 s_{res} 进行加权 PCA 变换。在 PCA 过程中对当前病人残余形状取权重 w_s ,对训练集中其他病人的残余形状取权重 w_p ,其中 $w_p = 1 - w_s$ 。通过调节 w_s 和 w_p 可以灵活控制特定病人信息和群体信息对统计形状模型的影响。
- 3) 经过加权 PCA 降维,得到一个残余形状空间。对此空间用当前病人的平均形状 s_{mean} 进行平移,就能得到当前病人合理的形状空间 D 。 D 即为

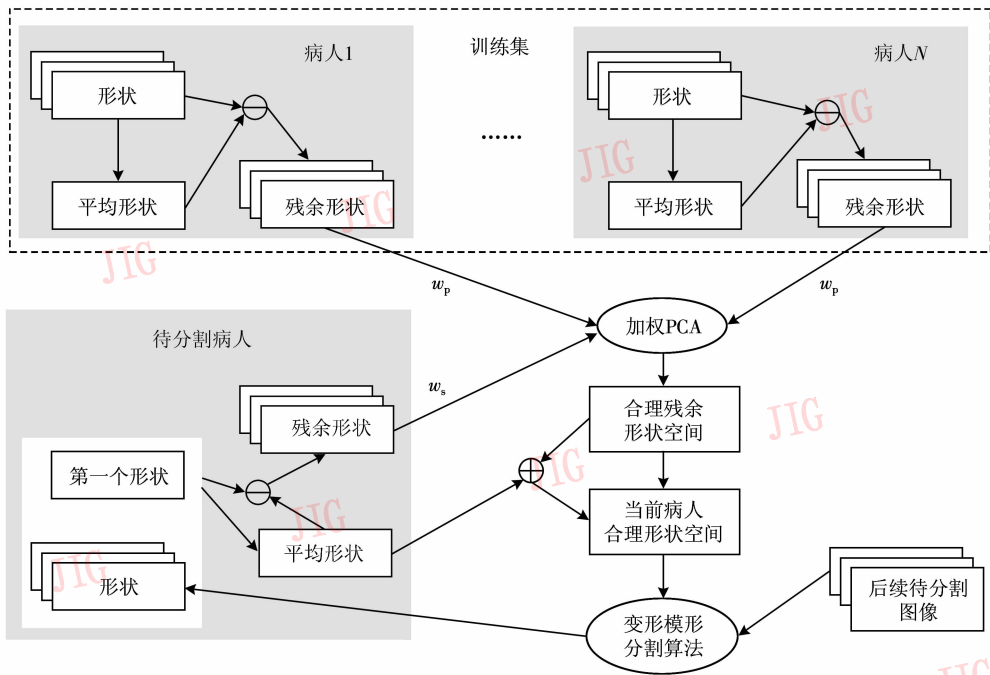


图 2 在线学习机制示意图

Fig. 2 Demonstration of main procedures of online training

分割当前病人的后续时间点图像的形状约束。

本文的训练过程是一个动态调节的过程。每当获得一个当前病人新的图像和分割结果之后,当前病人的平均形状 s_{mean} 和与残余形状 s_{res} 就随着新信息的加入动态更新。同时,逐步减小 w_p , 增加 w_s 。这样,随着当前病人的图像和分割结果的累积,当前病人形状信息将主导形状统计模型。本文采用 *sigmoid* 函数控制 w_s 的增加, w_s 随时间点变化曲线如图 3 所示。从图中可看出,当当前病人的已分割图像数量到达 9 ($t=9$) 时, w_s 接近 1, 此时当前病人的形状信息完全主导了形状模型。




图 3 w_s 随时间点的变化

Fig. 3 The curve of w_s along the time points

1.2 基于变形模型的分割

图像的分割是在计划图像空间中进行的,当获得病人的新时间点图像后,通过 FLIRT 工具包,利用盆骨图像(通过原图调节窗宽窗位得到),将图像经仿射变换映射到计划图像空间,得到的正规化图像 I_{norm} 。如前所述,这时形状模型 s_{mdl} ,即当前病人的平均形状 s_{mean} ,以及 I_{norm} 都在同一个图像空间,即当前病人的计划图像的空间。此时,形状模型 s_{mdl} 应位于图像 I_{norm} 中的前列腺附近,为了获

得更精确的初始化, s_{mdl} 可以在一个小范围内作细微的平移和旋转调整,并按文中提出的能量函数计算能量,当能量最小时,即能得到更为精确的初始化。

1.2.1 局部 SIFT 特征

SIFT 特征被认为是当前最有效的图像局部特征。提取 SIFT 特征包括下面 4 个主要步骤: 1) 尺度空间的峰值选择; 2) 关键点定位; 3) 方向分配; 4) 关键点描述矢量生成。前两个步骤用于关键点的选取,在本文中,由于前列腺形状表面的顶点已经存在,所以不涉及该问题。因此,只采用后两步来计算图像的 SIFT 特征,方法和文献[7]中的类似。每个点的主方向用局部邻域的梯度来决定,通过梯度直方图来计算该点的 SIFT 特征。

通过在前列腺 CT 图像上的实验可以展示 SIFT 特征在前列腺边界上有很好的特异性。图 4 显示 SIFT 特征可以探测到前列腺 CT 图像中的对应点。图 4(a) 为某时间点 CT 图像,红色交叉点的 SIFT 特征被用来和另外一个时间点图像(如图 4(b))中各点的 SIFT 特征比较,并计算欧氏距离。距离结果显示在图 4(c) 中,可以看到图 4(c) 中距离最近点(白色圈)正是两幅不同时间点前列腺图像的对应位置。

1.2.2 基于变形模型的分割算法

在变形模型的框架下,通过最小化以下能量函数,寻找最佳形状 s^*

$$s^* = \arg \min_s \{E_{\text{SIFT}}(s)\} \quad s \in \mathcal{D} \quad (1)$$

式中,能量项 $E_{\text{SIFT}}(s)$ 是 SIFT 的距离测度,通过最小化这个测度,实际要求模型表面每个点的 SIFT 特征和当前时间点的正规化图像 I_{norm} 上每个点的 SIFT 特征匹配。对表面上的每个点 p_i , 它的 SIFT 特征矢




图 4 SIFT 特征在前列腺边界上的特异性示意图

Fig. 4 Demonstration of SIFT features for correspondence detection in two different treatment images of the same patient

量包括 128 个分量。 $E_{\text{SIFT}}(s)$ 的定义如下:

$$E_{\text{SIFT}}(s) = \sum_{i=1}^N \sum_{l=1}^{128} \left(\frac{|v_i(l) - \bar{v}_i(l)|}{\sigma_i(l)} \right) \quad (2)$$

式中, $\bar{v}_i(l)$ 表示模型图像空间上第 i 个点的平均 SIFT 特征矢量中第 l 个分量。 $v_i(l)$ 表示 I_{norm} 上对应点的 SIFT 特征矢量的第 l 个分量, $\sigma_i(l)$ 是从训练集中计算得到第 i 个点的第 l 个分量的标准差。 N 是形状表面 s 上点的数目。

SIFT 特征的统计特性, 如 SIFT 矢量的平均值和每个分量的标准差, 都被用来构建能量函数。这样可以使 SIFT 特征匹配比使用单个图像的 SIFT 特征更为鲁棒和无偏差。和形状统计特征的计算类似, 平均 SIFT 特征 $\bar{v}_i(l)$ 由当前病人数据计算, 而 $\sigma_i(l)$ 通过病人数据和群体数据的加权计算。权重的调节是根据当前病人已经获得的数据量, 和形状模型中动态调节特定病人信息和群体信息的思想是一致的。

为了优化能量函数式(1), 提出了一种迭代优化策略, 交替地最小化该能量函数并根据统计形状约束 D 校正分割结果, 最终收敛于优化结果。对于第 t 步迭代步骤如下:

1) 对形状表面 s_t 上的每一个顶点, 在其附近进行局部搜索, 将其移至一个新的位置, 使该顶点处 SIFT 特征与表面模型的 SIFT 特征更加匹配。如此得到更新的形状模型 s_i , 此时 $E_{\text{SIFT}}(s_i)$ 较 $E_{\text{SIFT}}(s_t)$ 有更小的值;

2) 用群体和特定病人的统计形状特征来约束新的 s_i 。在形状统计空间 D 中寻找离 s_i 最近的形状 $s_{i,D}$;

3) 用 $s_{i+1} = s_i + \omega(s_{i,D} - s_i)$ 式加权平均 s_i 和 $s_{i,D}$ 得到本迭代步的最终结果 s_{i+1} 。权重参数 ω 用来调节形状约束的强度。本文采用的 ω 参数从 0.8 遵从指数函数逐渐降到 0。

2 实验结果与讨论

实验数据采用包括 24 位病人的数据集, 每位病人有 12 套不同时间点的 CT 数据。图像 XY 平面大小为 512×512 , 像素大小为 $0.98 \text{ mm} \times 0.98 \text{ mm}$, 层间距离为 3 mm。每套数据都提供了专家人工分割结果。对每个病人的数据, 将第 1 套图像作为计划图像, 其他 11 套数据作为测试图像, 共有 $11 \times 24 = 264$ 套测试图像。实验过程中, 采用剩余单病人策

略, 即如要分割测试某一病人的图像, 则将其他病人的数据作为群体数据, 当前病人的数据作为特定病人数据训练模型, 测试算法性能。本文用 SIFT 特征与传统的灰度轮廓特征^[1]进行了对比实验。


采用两种定量测度评估自动分割结果的精度: Dice 相似性系数(DSC)和平均表面距离(ASD)。如果 DSC 系数大于 0.7, 一般认为分割结果比较接近^[10]。

表 1 显示了 264 套图像的平均 DSC 和 ASD。从表中可以看到, 本文方法平均 DSC 为 90.5%, 平均 ASD 为 1.90 mm。图 5 为 DSC 在 90% 左右时算法分割结果和专家分割结果的对比(图 5(a)为第 1 个病人第 3 个时间点图像分割结果的两个横断面显示, 其 DSC 为 90.4%; 图 5(b)为第 3 个病人第 3 个时间点图像分割结果的两个横断面显示, 其 DSC 为 90.8%, 图中白色轮廓为本文方法自动分割结果, 黑色轮廓为专家手工分割结果。)从图中看出, 如果 DSC 达到 90%, 算法给出的前列腺边界和人工分割结果非常接近。图 6 显示了所有图像分割结果的


表 1 264 个测试图像的平均 DSC 与平均 ASD

Tab. 1 Average DSC and average ASD of all 264 images

		均值 \pm 标准差	最小值	最大值	中值
DSC/%	灰度轮廓	87.2 \pm 0.7	40.7	96.5	90.0
	SIFT	90.5 \pm 4.0	55.1	96.9	91.2
ASD/mm	灰度轮廓	2.30 \pm 1.47	0.79	10.88	2.18
	SIFT	1.90 \pm 0.71	0.84	8.35	1.76



(a)



(b)

图 5 部分分割结果示意图

Fig. 5 Some segmentation results




图 6 264 套图像的 DSC

Fig. 6 DSCs of all 264 images

DSC, 可以看到在 264 套图像中只有一套的 DSC 小于 70%, 这证明了算法的鲁棒性。本文方法由于采用了计算量大的 SIFT 特征, 和采用灰度轮廓特征的传统方法相比, 计算时间较长, 为 210 s (采用灰度轮廓特征时为 68 s), 但分割精度有大幅提高, DSC 提高了 3.3%, ASD 降低了 0.7 mm。另外, 本文方法精度与文献[2-3]相当, 但正如引言中所述, 文献[2-3]中方法只采用当前病人的数据训练形状模型, 在当前病人样本不足时, 无法实现。本文方法通过结合群体数据的统计信息解决了这一问题, 非常适合于临床应用。

3 结论

本文提出了一种应用于临床放疗计划的分割 CT 前列腺图像的新方法, 它在变形模型的框架下, 同时利用了特定病人信息和群体信息来约束引导分割过程。特定病人的统计信息通过在线学习的机制, 随着不断增加的时序病人图像和分割结果进入统计模型中, 并逐渐主导变形模型的分割过程。当分割结果越来越多的时候, 特定病人的统计约束变得越来越重要。为了计算变形模型分割过程的对应点, 还引入了 SIFT 局部特征, 实验结果证明 SIFT 在寻找时序图像中对应点时, 相对其他特征更具区分

性和鲁棒性。实验结果表明本文算法是鲁棒和精确的, 非常适合临床应用。

参考文献 (References)

- [1] Cootes T F, Edwards G J, Taylor C J. Active appearance models [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2001, 23(6): 681-685.
- [2] Stough J V, Broadhurst R E, Pizer S M, et al. Regional appearance in deformable model segmentation [C] // Information Processing in Medical Imaging, Rolduc Abbey: Springer-Verlag, 2007: 532-543.
- [3] Freedman D, Radke R J, Zhang T, et al. Model-based segmentation of medical imagery by matching distributions [J]. IEEE Transactions on Medical Imaging, 2005, 24(3): 281-292.
- [4] Lowe D G. Distinctive image features from scale-invariant keypoints [J]. International Journal of Computer Vision, 2004, 60(2): 91-110.
- [5] Freeman W T, Adelson E H. The design and use of steerable filter [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1991, 13(9): 891-906.
- [6] Mikolajczyk K, Schmid C. A performance evaluation of local descriptors [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2005, 27(10): 1615-1630.
- [7] Shi Y H, Qi F H, Xue Z. Segmenting lung fields in serial chest radiographs using both population-based and patient-specific shape statistics [J]. IEEE Transactions on Medical Imaging, 2008, 27(4): 481-494.
- [8] Fletcher P T, Lu C, Pizer S M. Principal geodesic analysis for the study of nonlinear statistics of shape [J]. IEEE Transactions on Medical Imaging, 2004, 23(8): 995-1004.
- [9] Pizer S M, Broadhurst R E, Jeong Y, et al. Intra-patient anatomic statistical models for adaptive radiotherapy [C] // MICCAI Workshop From Statistical Atlases to Personalized Models: Understanding Complex Diseases in Populations and Individuals, Copenhagen: Springer-Verlag, 2006: 43-46.
- [10] Zou K H, Warfield S K, Baharatha A, et al. Statistical validation of image segmentation quality based on a spatial overlap index 1 scientific reports [J]. Academic Radiology, 2004, 11(2): 178-189.