

基于多尺度 MRF 的膝关节 MRI 图像快速分割

林芬华¹⁾ 吴从中¹⁾ 詹曙¹⁾ 蒋建国¹⁾ 李鸿²⁾

¹⁾(合肥工业大学计算机与信息学院,合肥 230009) ²⁾(安徽医科大学第一附属医院骨科,合肥 230022)

摘要 膝关节 MRI 图像中骨骼的精确分割是进一步分割与定量分析膝部软组织的前提。目前膝关节骨骼分割的方法比较耗时或需要一定的人机交互。为解决这一问题,将多尺度 MRF 方法引入到膝关节 MRI 分割中,以实现快速无监督的分割。首先建立高斯混合的灰度统计模型,运用 MDL 准则自动确定类别的数目。建立多尺度 MRF 的先验模型时,利用尺度间的因果性给出非迭代的计算方法,由细尺度往粗尺度传递统计信息,再由粗尺度往细尺度计算每个像素的最大后验概率,从而实现快速准确的分割。实验结果表明,与单尺度 MRF 相比,多尺度 MRF 分割膝关节 MRI 所需时间大大减少,且精度与专家手动分割标准相当。算法通过建立多尺度马尔可夫随机场模型,完成了低信噪比膝关节 MRI 图像快速准确分割,可作为进一步自动分割软骨与半月板等软组织的基础。

关键词 膝关节 MRI 图像分割 多尺度 MRF 模型 混合高斯模型 MDL 准则

中图法分类号: TP391 文献标识码: A 文章编号: 1006-8961(2009)09-1739-06

Fast Segmentation of Knee Structure Based on Multi-scale MRF in MRI Image

LIN Fen-hua¹⁾, WU Cong-zhong¹⁾, ZHAN Shu¹⁾, JIANG Jian-guo¹⁾, LI Hong²⁾

¹⁾ (School of Computer & Information, Hefei University of Technology, Hefei 230009)

²⁾ (Department of Orthopaedics, The First Affiliated Hospital of Anhui Medical University, Hefei 230022)

Abstract Bone segmentation in knee MRI can be regarded as the groundwork of segmenting and analyzing soft tissue in knees. Usually this task is time-consuming and needs human intervention. To solve this problem automatically and rapidly, a multi-scale MRF is introduced into knee MRI segmentation in this paper. Gaussian mixture model is firstly built as the statistical model for the intensity image, with an estimation of index number using MDL. In the phase of building multi-scale MRF model, non-iterated computing based on causality between scales is implemented, where statistical information is transferred from fine scales to coarse scales and MAP of every pixel is computed from coarse scales to fine scales. As a result, fast and unsupervised bone segmentation on knee MRI can be achieved. The experiments show that the temporal cost of segmenting knee bones based on multi-scale MRF is extremely low and the segmentation error can be comparable to manual segmentation by medical experts. In conclusion, the work presented here accomplishes fast and accurate segmentation on knee MRI of low SNR through building a multi-scale MRF model. Future work can be extended to further cartilage and meniscus segmentation.

Keywords knee MRI, image segmentation, multi-scale MRF model, Gaussian mixture model, MDL criteria

基金项目:教育部博士点基金项目(20060359004);教育部留学回国人员科研启动基金项目(413117)

收稿日期:2009-01-01;改回日期:2009-04-27

第一作者简介:林芬华(1986~),女。合肥工业大学计算机与信息学院信号与信息处理专业硕士研究生。主要研究方向为医学图像处理与分析。E-mail:jerryph@163.com

1 引言

膝关节是人体最大最复杂的关节,其软组织损伤常困扰相关社会群体和中老年人群。通过医学图像,定量获取与分析膝部软组织的医学信息,具有重要意义。与 CT 和 X 平片相比,膝部 MRI 图像可以很好地反映软骨、半月板、韧带等软组织的影像。在目前膝部 MRI 图像分析工作中,多为手动分割上述软组织^[1],这将消耗大量时间且不具有客观可重复性。本文提出以先分割膝关节 MRI 图像中的骨骼为基础,继而利用先验解剖上的位置约束进一步分割软骨与半月板等组织的思路。因而,快速准确地分割膝关节 MRI 图像中的骨骼是后续的软组织分割,乃至计算机辅助诊断膝部疾病的基础,也是本文所要解决的主要问题。

目前关于膝关节 MRI 图像中骨骼分割的相关工作,主要有 Lorigo^[2]等提出的基于纹理的 GAC 模型,然而由于 MRI 图像较低的信噪比和局部体效应引起的边界模糊,分割结果容易出现边界泄露;Kapur^[3]也提出逐层分割膝部组织的思路,并使用自适应的区域生长结合 Snake 对股骨和胫骨进行分割,但在框架中需要大量的手动分割和标记;Fripp^[4]将 3 维主动形状模型(ASM)用于膝关节分割,但是 3 维统计形状模型的建立和基于模型的分割需要大量的手动标记和人机交互,并且模型建立中的点对应问题与分割中的初始分割位置确定都对最终结果有较大的影响。

基于统计的马尔可夫随机场(Markov random field, MRF)模型对图像的区域特征及边缘特征等信息描述均较为恰当,是图像分割中一个极为活跃的方向。目前主要用于分割缺乏足够先验信息的图像,如脑组织的微小变化,遥感图像的物信息,监控系统的随机性等^[5]。相比只考虑灰度信息的传统分割方法, MRF 方法考虑了图像像素间的空间相关性,在分割低信噪比的医学图像时,在一定程度上提高了分割的准确性。 MRF 方法将图像的分割问题转化为确定像素分类标号的最优化问题。传统的单尺度 MRF 方法通过迭代的算法将图像单尺度平面网格上的局部空间相关信息逐步传递到整个图像,以求得分割标号的最大后验概率估计(maximum a posteriori, MAP)。单尺度 MRF 存在邻域大小固定、参数估计困难以及计算量庞大等问题;基于

MAP 估计的单尺度 MRF 将区域边缘的各向异性与区域内部的一致性合并起来以后作为图像分割的正则条件,容易使图像的边缘模糊,损失掉细节信息^[6]。

鉴于以上缺点, Bouman^[7]等人在图像分割中引入多尺度的思想,提出了尺度间具有因果特性的多尺度 MRF 先验模型。多尺度 MRF 先验模型是由一系列从粗尺度到细尺度的标号随机场组成,并假设每个随机场仅仅依赖于前一个较粗糙尺度的随机场。因此,这一系列随机场构成了一个马尔可夫链。多尺度 MRF 的特点在于:(1)在粗尺度中侧重区域的一致性,在细尺度侧重边缘的各向异性,从而兼得抗噪性和边缘定位精确性;(2)以序贯最大后验概率(sequential MAP, SMAP)为估计器,推导出非迭代的算法,大大减少了计算量,并在分割过程中完成模型参数的估计,具有快速、误分类少等优点^[8]。因此选择多尺度 MRF 来实现快速分割膝部 MRI 中的骨骼。

2 分类标号数的确定

膝关节图像的灰度直方图分布是一种缓慢变化的高斯分布,因此采用高斯混合模型对观测图像 Y 的灰度场进行建模。设灰度场由 K 个高斯分布组成,对应 K 类组织,分布函数的均值为 μ_k 、方差为 R_k ,使用期望值最大化(EM)方法来估计模型参数 $\theta_k = (\mu_k, R_k)$ 。同时注意到,分类的数目 K 对分割结果有着决定性的影响,若 K 过大,会产生过拟合的现象,造成对图像的过分割;否则会造成对图像的欠分割^[9]。Rissanen^[10]提出的最小描述长度准则(MDL),旨在寻找观测数据的描述准确度与所选模型复杂度之间的最佳平衡点,并已广泛应用于医学图像建模与分割之中。在随机场问题中, MDL 方法可以将标号数问题表述为模型以较高的概率分配给观测数据的信息编码问题,用最小的比特数来编码参数 θ 和数据 y ,以求得模型分布函数的最佳数目。本文在不同分类数目下用 EM 方法对高斯混合模型进行参数估计,计算其描述长度,最后由最小的描述长度来决定分类数目,实现了自动无监督的分布参数的估计和分类数目的确定。具体步骤如下:

第 1 步 设置较大的初始类别数 K , 初始化参数 $(\mu_k^{(0)}, R_k^{(0)})$ 和类别权重 λ_k 。

第 2 步 由式(1)计算条件期望值 $Q^{(0)}$ 。

$$\log p(Y | K, \theta) = \sum_{i=1}^N \log \left(\sum_{k=1}^K \frac{1}{\sqrt{2\pi R_k}} \exp \left\{ -\frac{(y_i - \mu_k)^2}{2R_k} \right\} \lambda_k \right) \quad (1)$$

$$Q^{(i)} = E[\log p(y | K, \theta) | Y = y, \theta_i] \quad (2)$$

第 3 步 由贝叶斯公式(式(3))计算每个像素点的后验概率,以重新计算权重 λ_k 和 K 个类别的均值、方差。

$$p(k | y_i, \theta_k) = \frac{p(y_i | k, \theta_k) \lambda_k}{\sum_{l=1}^K p(y_i | l, \theta_l) \lambda_l} \quad (3)$$

第 4 步 设 p 为迭代次数,执行第 2 步计算新的期望值 $Q^{(p)}$ 。若 $Q^{(p)} - Q^{(p-1)} > 0.03 \log N$, N 为总像素数目,转第 3 步,否则,结束 EM 算法。

第 5 步 将求得的最优参数 $\theta_k = (\mu_k, R_k)$ 代入式(4)求解 MDL 值。

$$MDL(K, \theta) = -\log p(Y | K, \theta) + \frac{1}{2}(3K - 1) \log N \quad (4)$$

第 6 步 根据式(5)合并距离最小的两类,重复第 2 步~第 5 步,直到 $K=1$ 。

$$d(l, m) = \frac{N \bar{\lambda}_l}{2} \log \left(\frac{|R_{(l,m)}|}{|R_l|} \right) + \frac{N \bar{\lambda}_m}{2} \log \left(\frac{|R_{(l,m)}|}{|R_m|} \right) \quad (5)$$

第 7 步 记录下 $MDL(K, \theta)$ 值最小时所对应的 K 值,完成分类标号数的确定。

3 多尺度 MRF

3.1 模型结构

在多尺度 MRF 中,待分割图像由观测场 Y 和标号场 X 组成。 X 中任一像素的取值 $x \in \{1, 2, \dots, K\}$, 代表了 Y 中对应像素所属类的标号。观测图像 Y 位于 2 维网格系统 S 中,标号场 X 由多层随机场组成,记为 $X^{(0)}, X^{(1)}, \dots, X^{(L)}$, 每一层随机场只依赖于相邻的上层随机场,而与其他更粗糙层的随机场无关,自上而下形成马尔可夫链。其中 $X^{(L)}$ 是最上层随机场,对应于最粗糙的尺度,只有一个节点; $X^{(0)}$ 是最下层随机场,对应于最精细的尺度,大小和观测图像 Y 相同。 $X^{(n+1)}$ 中的一个像素(父节点)对应于 $X^{(n)}$ 中的 4 个像素(子节点),即每层的

像素数是上一层的 4 倍,形成了图 1 所示的四叉树结构。




图 1 四叉树结构
Fig. 1 Quadtree structure

传统的四叉树结构同一尺度中相邻的像素不一定有同一个父节点,且相邻像素在同一尺度中又没有交互,常常导致分割结果具有块状现象和边界不连续的现象。针对此问题,在选取各像素的邻域节点时,除了考虑粗一尺度上的父节点外,同时也考虑父节点的邻域节点的影响,从粗尺度到细尺度构成金字塔结构,从而间接地实现同一尺度中相邻节点的交互作用,提高了分割的精度。设某一尺度上有一像素 $s = (i, j)$, 则该像素的邻域节点为

$$\begin{aligned} s_1 &= (\lfloor i/2 \rfloor, \lfloor j/2 \rfloor) \\ s_2 &= (\lfloor i/2 \rfloor + \text{odd}(i), \lfloor j/2 \rfloor) \\ s_3 &= (\lfloor i/2 \rfloor, \lfloor j/2 \rfloor + \text{odd}(j)) \\ s_4 &= (\lfloor i/2 \rfloor + \text{odd}(i), \lfloor j/2 \rfloor + \text{odd}(j)) \end{aligned}$$

其中, $\text{odd}(i) = \begin{cases} 1 & i \text{ 为奇数} \\ -1 & i \text{ 为偶数} \end{cases}$ 。

然而,由金字塔结构很难推导出简单的从细尺度到粗尺度求解“似然”概率的递归式,因此需构造如图 2 所示的混合金字塔结构,对于尺度 n 上的像素,在小于 n 的尺度上通过四叉树结构计算像素的“似然”概率,在大于 n 的尺度上利用金字塔结构计算像素的“先验”概率。




图 2 混合金字塔结构

Fig. 2 Hybrid pyramidal structure

3.2 估计算法

根据贝叶斯估计器,图像分割可表示为一个优化问题: $\hat{x} = \arg \min_x E[C(X, x) | Y = y]$, 代价函数 C 表示真实配置为 X 而实际分割结果为 x 时的代价。定义不同的代价函数能得到不同的估计器。最常用的是 MAP 估计器,它分配给每一个不正确的分类相同的代价,考虑了样本间的相异性,但没有考虑相异的程度。第 2 种是 MPM 估计器,它根据不正确分类的像素数目分配相应的代价,尽管相对 MAP 估计更合理,但没有考虑到在多尺度模型中不同尺度上一个像素的错误分类所造成的代价是不同的。第 3 种是 SMAP 估计器,它随着尺度的增加分配较大的误分类代价,估计精度更高。SMAP 估计的代价函数为

$$C_{\text{SMAP}}(X, x) = \frac{1}{2} + \sum_{n=0}^L 2^{n-1} C_n(X, x)$$

$$C_n(X, x) = 1 - \prod_{i=n}^L \delta(X^{(i)} - x^{(i)}) \quad (6)$$

最小化代价函数可得

$$\hat{x} = \arg \min_x E[C_{\text{SMAP}}(X, x) | Y = y]$$

$$= \arg \max_x \sum_{n=0}^L 2^n p(X^{(i)} = x^{(i)} | i \geq n | Y = y) \quad (7)$$

由标号场 X 的马尔可夫性,利用贝叶斯准则,并假设 $X^{(L)}$ 是均匀分布的,可推导得到如下的 SMAP 递归式:

$$\hat{x}^{(L)} = \arg \max_{x^{(L)}} \log p(y | x^{(L)})$$

$$\hat{x}^{(n)} = \arg \max_{x^{(n)}} \left\{ \log p(y | x^{(n)}) + \log p(x^{(n)} | \hat{x}^{(n+1)}) \right\} \quad (8)$$

3.3 算法实现

(1)由细尺度向粗尺度(四叉树模型)传递统计信息。

初始化:用式(1)计算最精细尺度节点 $s \in S^{(0)}$ 的对数似然值 $l_s^{(0)}(k)$ 。

递归:对于节点 $s \in S^{(n)}, n = 1, 2, \dots, L$ 。

$$l_s^{(n+1)}(k) = \sum_{r \in d^{(-1)}(s)} \log \left\{ \theta_{n,0} \exp \{ l_r^{(n)}(k) \} + \frac{1 - \theta_{n,0}}{K} \sum_{m=1}^K \exp \{ l_r^{(n)}(m) \} \right\} \quad (9)$$

式中, $\theta_{n,0}$ 为四叉树模型中从尺度 n 到尺度 $n+1$ 节点标记相同的概率,参数 $\hat{\theta}_{n,0}$ 初始值设为 1; $d^{(-1)}(s)$ 表示节点 s 在细一尺度上的 4 个子节点; K 为总类别数。

(2)由粗尺度向细尺度(金字塔模型)逐层计算每一个节点的最大后验概率,进而估计各节点所属的类别。

初始化:将最粗糙尺度节点 $s \in S^{(L)}$ 的最大对数似然值对应的标号 k 作为节点 s 的分割结果。

递归:对于节点 $s \in S^{(n)}, n = L-1, \dots, 1, 0$ 。

$$\hat{x}_s^{(n)} = \arg \max_{1 \leq k \leq K} \left\{ l_s^{(n)}(k) + \log p_{x_s^{(n)} | x_{\partial_s^{(n+1)}}}(k | \hat{x}_{\partial_s^{(n+1)}}^{(n+1)}) \right\} \quad (10)$$

$$p_{x_s^{(n)} | x_{\partial_s^{(n+1)}}}(k | \hat{x}_{\partial_s^{(n+1)}}^{(n+1)}) = \frac{\theta_{n,1}}{9} (3\delta_{m,i} + 2\delta_{m,j} + 2\delta_{m,k} + 2\delta_{m,l}) + \frac{1 - \theta_{n,1}}{K} \quad (11)$$

式(11)^[11]描述了尺度间邻域的空间相关性。 $\theta_{n,1}$ 为金字塔模型中从尺度 $n+1$ 到尺度 n 节点标记相同的概率,参数 $\hat{\theta}_{L-1,1}$ 的初始值设为 0.5。

由粗尺度向细尺度的递归过程中对每一尺度 n 利用 EM 算法进行参数 $\theta_{n,0}$ 和 $\theta_{n,1}$ 的估计:

E 步:用式(9)和式(11)计算对数似然函数的期望值 $Q(\theta_{n,1}, \theta_{n,1}^p)$ 。

M 步:用线性搜索法求解 $\theta_{n,1}^{p+1} \in \arg \max_{\theta_{n,1} \in \Omega} \{ Q(\theta_{n,1}, \theta_{n,1}^p) \}$, 当 $|\theta_{n,1}^{p+1} - \theta_{n,1}^p| > \varepsilon$ 时,用 $\theta_{n,1}^{p+1}$ 更新 $\theta_{n,1}^p$, 进行下一次迭代,否则停止 EM 算法,更新参数 $\theta_{n,0}$, 设置下一尺度的初始参数 $\hat{\theta}_{n-1,1} = \hat{\theta}_{n,1} (1 - 10^{-3})$ 。

4 实验与分析

算法分别在冠状面和矢状面膝关节 MRI 中加以验证。图 3(a)是尺寸为 512×512 的膝关节冠状面灰度图像,像素物理尺寸为 0.293×0.293 mm。算法自动对图像建立高斯混合模型并确定类别数,规定 x 为类别标号, μ 为均值, R 为方差,具体见表 1。实验中亦用相同分类数的单尺度 MRF 实现相同分割任务。由于 ICM 迭代优化算法容易陷入局部极值,实验采用 Gibbs 采样的迭代算法进行传统的单尺度 MRF 分割,算法记为 S_MRF,而本文使用的基于 SMAP 估计的多尺度 MRF 算法记为

M_MRF。图 3 (b)、图 3 (c) 分别是 S_MRF, M_MRF 的分割结果;图 3 (d) 是骨科专家对 MRI 图像手动分割的结果;图 3 (e)、图 3 (f) 是在分割结果的基础上通过连通区域的判断将前景与背景完全分离的效果。图 4 (a) 是膝关节矢状面图像,次序与图 3 一致。




图 3 冠状面骨骼分割结果

Fig. 3 An illustration of bone segmentation in coronal image

表 1 冠状面中分类参数,算法耗时及分割误差

Tab. 1 Parameters, temporal cost and segmentation error in coronal image

| | x | μ | R | $t(s)$ | η | RMS |
|-------|-----|--------|--------|---------|--------|------------------|
| M_MRF | 0 | 6.38 | 18.48 | | | 4.098 8 |
| | 1 | 54.76 | 586.66 | 1.046 | 94.94% | (pixel) 1.201 |
| | 2 | 160.78 | 674.57 | | | (mm) |
| S_MRF | 0 | 8.73 | 4.93 | 327.547 | | 6.670 8 |
| | 1 | 46.60 | 39.43 | 迭代 | 98.69% | (pixel) 1.955 |
| | 2 | 154.54 | 206.33 | 274 次 | | (mm) |

实验中分别采用基于区域与基于边缘的方法衡量分割精确度,以比较算法性能。 η 代表手动分割与算法分割结果区域间的重合程度,计算公式为 $\eta = (S_0 \cap S_i) / S_0$, 其中, S_0 表示手动分割的骨骼面积, S_i 表示多尺度或单尺度分割得到的骨骼面积; RMS 代表手动分割和算法分割结果中感兴趣骨骼边界对应点之间的误差, 实验中由专家对有软骨附着的股骨和胫骨的部分边缘进行采样, 分别计算手动分割与 S_MRF, M_MRF 分割结果中骨骼边缘间的均方根值, 从而比较边缘定位误差。

由表 1 中的区域重合率 η 可以看出, M_MRF 的分割误差稍逊于 S_MRF, 其原因由图 3 分割结果可

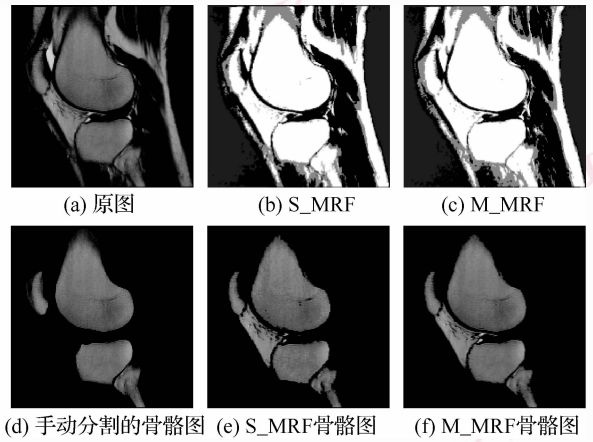


图 4 矢状面骨骼分割结果

Fig. 4 An illustration of bone segmentation in sagittal image

以看出,误差主要存在于胫骨底部的分割。而这部分的分割结果与膝关节病变的观察,进一步分析关系不大。由于本文更关注于骨骼与软骨接触部分的分割准确程度,从表 1 的边缘定位误差 RMS 可见, S_MRF, M_MRF 均较为精确,且 M_MRF 的定位精度高于 S_MRF。从分割时间上看,专家手动分割耗时约为 6 min, S_MRF 的分割时间 t 超过 5 min, 而 M_MRF 仅耗时 1 s 左右,在确保分割精度可以接受情况下分割时间有了 2 个数量级的飞跃。

由表 2 中的 η 可见, MRF 方法在膝关节矢状面的分割精度相比冠状面较差,这是由于在所选 MRI 成像中,骨骼与髌骨下脂肪垫具有相似的灰度分布,并且髌骨内的灰度变化范围较大,从而导致 S_MRF 与 M_MRF 分割出的区域与手动分割区域之间的重合度均较低。但从基于边缘的 RMS 来看, S_MRF 与 M_MRF 分割效果仍基本与冠状面中一致,并且 M_MRF 的精确度要好于 S_MRF。同样,专家手动分割时间约为 10 min, S_MRF 分割时间近 7 min, 而 M_MRF 分割时间仍为 1 s 左右,时间效率上有大幅提高。

由表 1 和表 2 显然可见,单尺度 MRF 与多尺度 MRF 的分割精度相当,但是多尺度 MRF 算法将单尺度平面网格上信息的迭代扩散转换为信息在不同尺度间的传递,推导出的非迭代递归算法大大减少了计算量,能有效地实现快速分割。由实验结果图还能观察到, S_MRF 分割结果在均匀区域中存在不少孤立的误分类,区域边界划分不够精确、平滑,而 M_MRF 算法能更好地保持区域的一致性和边缘的平滑。

表 2 矢状面分类参数,算法耗时及分割误差

Tab. 2 Parameters, temporal cost and segmentation error in sagittal image

| | x | μ | R | $t(s)$ | $\eta(\%)$ | RMS |
|-------|-----|--------|--------|-------------|------------|--------------------|
| M_MRF | 0 | 5.30 | 2.88 | | | 5.442 9 (pixel) |
| | 1 | 20.12 | 38.01 | 1.406 | 90.71 | |
| | 2 | 45.84 | 208.59 | | | 1.595 (mm) |
| | 3 | 108.47 | 410.94 | | | |
| S_MRF | 0 | 4.93 | 1.62 | 415.718 | | 8.532 2 (pixel) |
| | 1 | 23.67 | 28.22 | | | |
| | 2 | 54.25 | 40.99 | 迭代 282 次 | 87.91 | 2.450 (mm) |
| | 3 | 105.31 | 34.86 | | | |

5 结 论

针对现有膝关节 MRI 图像分割方法存在的耗时、需要人机互动等不足,将基于 MDL 准则的自动聚类 and 基于 SMAP 估计的多尺度马尔可夫随机场的分割相结合,在低信噪比的膝关节 MRI 中实现了快速无监督的骨骼分割。实验结果表明,该方法可以准确地分割膝关节的骨骼,算法耗时极低。进一步的工作将包括以下几点:(1)结合数学形态学,利用形状及位置约束消除矢状面分割中脂肪垫的误分割;(2)基于矢状面和冠状面的分割结果,使用形状约束的水平集方法分割膝关节软骨,进而定量分析,为临床诊断、手术计划、康复观察提取有医学价值的信息。

参考文献 (References)

1 Williams T, Holmes A, Waterton J, *et al.* Anatomically equivalent focal regions defined on the bone increases precision when measuring cartilage thickness from knee MRI [A]. In: Proceedings of the MICCAI Joint Disease Workshop [C], Copenhagen, Denmark, 2006:25-32.

2 Lorigo L M, Faugeras O, Grimson W, *et al.* Segmentation of bone in clinical knee MRI using texture-based geodesic active contours [A]. In: Proceedings of the Medical Image Computation and Computer Assisted Interventions [C], Boston, USA, 1998:1195-1204.

3 Kapur T, Beardsley P A, Gibson S F, *et al.* Model based segmentation of clinical knee MRI [A]. In: Proceedings of the IEEE International Workshop on Model-based 3D Image Analysis [C], Bombay, India, 1998:97-106.

4 Fripp J, Ourselin S, Warfield S K, *et al.* Automatic segmentation of the bones from MR images of the knee [A]. In: Proceedings of the 4th IEEE International Symposium on Biomedical Imaging: From Nano to Macro [C], Washington, USA, 2007:336-339.

5 Li Xu-chao, Zhu Shan-an. A survey of the Markov random field method for image segmentation [J]. Journal of Image and Graphics, 2007, **12**(5):789-798. [李旭超,朱善安. 图像分割中的马尔可夫随机场方法综述 [J]. 中国图象图形学报, 2007, **12**(5):789-798.]

6 Wang Peng-wei. Research on Image Segmentation Methods Based on Multiscale Theory [D]. Hefei: University of Science and Technology of China, 2007. [王鹏伟. 基于多尺度理论的图像分割方法研究 [D]. 合肥: 中国科学技术大学, 2007.]

7 Bouman C A, Shapiro M. A multiscale random field model for Bayesian image segmentation [J]. IEEE Transactions on Image Processing, 1994, **3**(2):162-177.

8 Wang Xi-li, Liu Fang, Jiao Li-cheng. A hierarchical Markov image model and its inference algorithm [J]. Journal of Software, 2003, **14**(9):1558-1563. [汪西莉,刘芳,焦李成. 一种分层马尔可夫图像模型及其推导算法 [J]. 软件学报, 2003, **14**(9):1558-1563.]

9 Li Xu-chao, Zhu Shan-an. Application of FGMM-MRF hierarchical model to image segmentation [J]. Journal of Computer-Aided Design & Computer Graphics, 2005, **17**(12):2660-2664. [李旭超,朱善安. FGMM-MRF 层次模型在图像分割中的应用 [J]. 计算机辅助设计与图形学学报, 2005, **17**(12):2660-2664.]

10 Rissanen J. A universal prior for integers and estimation by minimum description length [J]. Annals of Statistics, 1983, **11**(2):417-431.

11 Kam A H, Fitzgerald W J. General unsupervised multiscale segmentation of images [A]. In: Proceedings of the Thirty-third A silomar Conference on Signals, Systems, and Computers [C], Pacific Grove, CA, USA, 1999:63-67.