

# 基于核聚类算法和模糊 Markov 随机场模型的 脑部 MR 图像的分割

廖 亮 林土胜

(华南理工大学电子与信息学院, 广州 510641)

**摘 要** 为了更有效地对被噪声污染的脑部 MR 图像进行分割, 提出了一种基于模糊核聚类和模糊 Markov 随机场的脑部 MR 图像分割算法。该算法在使用高斯径向基函数的核聚类目标函数中, 引入了基于 Markov 随机场的补偿项, 作为分割算法的空间约束。这种空间补偿项用 Gibbs 分布描述, 实际上是一种归一化的核函数, 其和用来度量灰度特征的核函数的形式是相似的, 并且这种空间约束利用了分割结果的模糊信息。这种基于核函数和 Markov 随机场模型的算法克服了传统聚类以及核聚类算法的缺陷, 不仅提出了更加合理的空间约束, 而且改善了原有的分割模型, 因此可以得到更加分段光滑的聚类结果。通过对合成图像、模拟 MR 图像以及临床 MR 图像进行的分割实验以及和标准分割结果的比较表明, 该算法优于相关算法, 可以有效地分割被污染的 MR 图像。

**关键词** MR 图像分割 核聚类算法 模糊 Markov 场 空间约束

中图法分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2009)09-1732-07

## A Kernelized Fuzzy C-means Clustering Using Fuzzy Markov Random Field Model for Brain MR Image Segmentation

LIAO Liang, LIN Tu-sheng

(School of Electronic and Information Engineering, South China University of Technology, Guangzhou 510641)

**Abstract** In order to more effectively segment noise-corrupted brain MRI images, a kernelized clustering algorithm using fuzzy Markov random field (MRF) model is proposed. The proposed algorithm is implemented by incorporating the MRF based spatial constraints as a regularization term to the objective function of the kernelized fuzzy C-means clustering (FCM). The spatial connectivity modeled by the Gibbs distribution is actually formulated as a normalized Gaussian radius basis function (GRBF), and very similar to the kernel function used to measure the intensity feature of image data. Due to the introduction of fuzzy information in the spatial constraints, the MRF and GRBF based clustering algorithm improves the segmentation model and usually outperforms the conventional intensity based FCM method and the corresponding kernelized clustering method. The modified algorithm can incline the solution to a piecewise smoother segmentation result. Experiments on synthetic data, simulated and real clinical MR images and the result comparisons with ground truth show the proposed algorithm is superior to its rivals and is effective to segment MR data corrupted by noise.

**Keywords** MR image segmentation, kernelized clustering, fuzzy Markov random field, spatial constraints

基金项目: 国家自然科学基金项目(60472006); 广东省自然科学基金团队项目(04205783)

收稿日期: 2007-04-24; 改回日期: 2007-12-05

第一作者简介: 廖 亮(1975 ~ ), 男。现为华南理工大学在读博士研究生。研究方向为图像处理、模式识别等。E-mail: liaoliangis@

## 1 引言

在脑部疾病的诊断中,能否精确度量脑白质(white matter, WM),灰质(gray matter, GM),脊髓液(cerebrospinal fluid, CSF)的数量和分布对临床的定量分析是至关重要的。由于磁共振(magnetic resonance, MR)图像相对其他诊断影像具有较大的优势,因此大量针对于 MR 图像的分割方法被提出。

在图像分割算法中,使用硬分割聚类的算法,难以使数据呈现某种程度的交叠,从而难以描述图像数据本身的不精确性。而 FCM (fuzzy C-means clustering) 是一种有效的模糊聚类算法,FCM 算法可通过迭代方式来优化目标函数,并可获得数据的聚类中心和隶属度矩阵,最终通过隶属度矩阵把像素的模糊聚类转化为硬分割。

为了提高传统的 FCM 算法的有效性,可以在聚类的过程中,考虑像素的空间约束。在图像分割中,像素和聚类中心的差别常常受到其邻域的影响,而不仅仅和像素的灰度值有关。通常,由于特征相似的像素在空间上是彼此靠近的,从而在图像上会形成类似的区域,应该被划分为一类。因此可以在聚类过程中加入空间约束来补偿被噪声和低频有偏场所污染的灰度特征<sup>[1-6]</sup>。例如 Ahmed 等人提出的聚类算法,就是在传统的目标公式中增加了一个像素邻域的附加项,从而补偿了图像灰度的不均匀性。新算法不但考虑了像素和聚类中心的差值受邻域点的影响,并讨论了图像中乘性有偏场的估算问题<sup>[3]</sup>。而 Liew 等人则提出用新的像素间的差别指标来度量各个点空间上的联系,并用 B 样条插值来表示有偏场,该改进的算法可以得到光滑的分割图像<sup>[3]</sup>。

在各种空间信息的提取方法中,Markov 随机场(MRF)理论可以很好地描述邻域各点之间相互影响的关系,而对势团能量的估算实际上决定了标记场的先验概率。所以 Gibbs 随机场模型可以弥补传统的聚类算法中对空间约束描述的不足,从而可克服以灰度为特征的 FCM 算法的固有缺陷。例如陈武凡等人就基于广义模糊集的 Markov 模型中的 Gibbs 分布,建立了新的分割算法,该算法首先把每个分类定义为广义模糊类,然后结合 Markov 模型,使用最大后验概率来决定每个像素的归类和其隶属度。这种利用 Markov 模型的聚类算法可以有效地

滤除噪声和处理部分容积效应<sup>[7]</sup>。

另一种有效的方法是利用 Mercer 核函数进行聚类,即在聚类过程中,把原始空间中的数据距离转化为在高维核空间中进行度量,以增加聚类数据的线性可分性,这种方法被称为核聚类算法<sup>[5-9]</sup>。

使用核函数和空间约束的聚类算法可以有效地提高图像分割的准确度,例如 Zhang 和 Chen 提出的聚类算法就是使用高斯径向基函数(Gaussian radial basis function, GRBF)来核化特征空间中的距离,同时在目标函数中增加了一个邻域的空间约束项(使用数据隶属度或数据与聚类中心间的核函数距离)的加权和,并利用聚类的迭代公式来完成图像分段光滑的分割<sup>[5-6]</sup>。

在描述像素相互关系的模型中,Markov 随机场模型中用来描述标记场分布的 Gibbs 函数和 GRBF 核函数非常相似<sup>[10-11]</sup>。实际上 Gibbs 分布和归一化的 GRBF 函数具有相同的形式。所以本文提出一种使用 Gibbs 分布描述的空间约束项的算法,用来弥补核聚类算法的不足,并使用该算法对合成图像、MR Phantom 和临床 MR 图像进行了实验,实验结果表明,该算法可以得到准确的分段光滑的分割结果。

## 2 使用空间约束的核聚类算法

满足 Mercer 条件的核函数即可以得到聚类数据的高维核空间中的距离,而不需要知道由原始特征空间到核空间的显式映射关系。在聚类算法中,用核函数距离代替 Euclid 距离,以便把一个原始特征空间中的线性不可分问题转化为在高维空间中的线性可分问题<sup>[7-9]</sup>。而使用空间约束则可以提高分割算法对噪声和有偏场的不敏感性,以便得到分段光滑的分割结果。Zhang 等人提出的 KSFCM 算法<sup>[5-6]</sup>就是这种使用空间约束的核聚类算法。该算法对图像的分割可以通过对目标函数  $J$  的最小化获得,即

$$U = \arg \min_U J = \arg \min_U \left[ \sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m (1 - K(x_k, v_i)) + \frac{\alpha}{\tilde{N}} \sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m \sum_{r \in N_k} (1 - \mu_{i,r})^m \right] \quad (1)$$

需要说明的是,若记像素  $r$  对应的序号为  $k$  (即像素  $r_k$  为第  $k$  个像素),则上式中  $\mu_{i,r} = \mu_{i,r_k}$ ,本文在无歧义的情况下,遵循这个默认的约定。另外式(1)中  $U = [\mu_{i,k}]_{c \times N}$  为隶属度矩阵,  $K(\cdot, \cdot)$  为核函

数,该核函数用高斯径向基函数 (GRBF) 定义如下:

$$K(x_k, v_i) = \exp(-\|x_k - v_i\|^2 / \sigma^2) \quad (2)$$

式中,  $x_k, v_i$  分别为输入的数据和聚类中心, 可以为向量或标量, 为了表述上的方便, 本文将两者取为标量, 即  $x_k$  为第  $k$  个像素的灰度值,  $v_i$  为第  $i$  个类的聚类中心的灰度值,  $\sigma$  为用来控制核函数峰值的参数。  $N_k$  为第  $k$  个目标像素的邻域点集,  $\tilde{N}$  为集合  $N_k$  中像素的个数。  $0 \leq m < \infty$  用来控制隶属度对聚类的影响。系数  $\alpha \in (0, 1)$  用来平衡空间约束项在目标函数中的比重。使用 Lagrange 乘数法得到的对  $J$  取极值的两个必要条件为

$$\mu_{i,k} = \frac{\left( (1 - K(x_k, v_i)) + \frac{\alpha}{\tilde{N}} \sum_{r \in N_k} (1 - \mu_{i,r})^m \right)^{\frac{1}{1-m}}}{\sum_{j=1}^c \left( (1 - K(x_k, v_j)) + \frac{\alpha}{\tilde{N}} \sum_{r \in N_k} (1 - \mu_{j,r})^m \right)^{\frac{1}{1-m}}} \quad (3)$$

$$v_i = \frac{\sum_{k=1}^n \mu_{i,k}^m K(x_k, v_i) x_k}{\sum_{k=1}^n \mu_{i,k}^m K(x_k, v_i)} \quad (4)$$

用式(3)和式(4)对算法进行循环迭代,直到隶属度矩阵收敛。收敛后把像素标记为具有最大隶属度的类标记,以实现图像的一个硬划分。

KSFCM 算法使用的核函数和空间补偿项弥补了传统的基于灰度的聚类算法的不足。对于受噪声污染严重的图像,式(1)中的系数  $\alpha$  应取较大的值,以加强空间约束在目标函数中的影响。式(2)中的参数  $\sigma$ ,取值过大或过小都将导致产生不理想的分割结果。

### 3 使用 Markov 场的核聚类算法

大家知道,图像的分割问题可以归结为像素的标记问题。而在 Markov 随机场模型中,标记取值的先验概率只和该点邻域的标记有关。该模型中的二阶邻域系统描述的是 8 邻域标记值对当前点标记的影响<sup>[10,12]</sup>。使用 Markov 场不仅简化了图像空间约束模型,并且可以使用模糊信息来定义非齐次 Markov 场,以更准确地描述图像不同区域的性质<sup>[10]</sup>。

根据 Hamersley-Clifford 定理,Markov 标记场取值的先验概率可以用 Gibbs 分布表示,即设  $y$  为 Markov 标记场随机变量 ( $y = 1, \dots, c$ ),其先验概率可以表示为

$$P_s(y) = Z^{-1} \exp(-U_s(y) / \beta^2) \quad (5)$$

$$Z = \sum_{i=1}^c \exp(-U_s(i) / \beta^2) \quad (6)$$

$Z$  为归一化常数,  $c$  为分类数。参数  $\beta$  用于控制 Markov 场中各点间的相互影响。  $U_s(y)$  为在像素  $s$  处的势能,其定义如下:

$$U_s(y) = \sum_{(s,t) \in C} V_{s,c}(y | y_t) \quad (7)$$

其中,  $y$  为像素  $s$  的标记值,  $y_t$  为邻域像素  $t$  的标记值 ( $y, y_t = 1, \dots, c$ ),  $C$  为势团 (clique),  $V_{s,c}(y | y_t)$  的取法可以有多种模型。如前所述,Markov 场可以利用数据的模糊信息来得到非齐次势团能量分布。本文只考虑二阶 Markov 邻域中的两点势团,像素对  $(s, t)$  为该邻域中相邻的两点,即  $V_{s,c}(y | y_t)$  为邻域点  $t$  被标记为  $y_t$  时,点  $s$  被标记为  $y$  时的势团能量。

本文在多级逻辑模型 (multi-level logistic, MLL) 基础上定义的两点势团能量如下:

(1) 硬分割

$$V_{s,c}(y | y_t) = 1 - \delta(y_t - y) = \begin{cases} 0 & (y_t = y) \\ 1 & (y_t \neq y) \end{cases} \quad (8)$$

(2) 模糊分割

$$V_{s,c}(y | y_t) = \sum_{y_t=1}^c \mu_{y_t,t} (1 - \delta(y_t - y)) = 1 - \mu_{y,t} \quad (9)$$

式(9)可以解释为隶属度在硬分割情况下势团能量的加权和。本文只考察二阶邻域内的 8 个两点势团,即两个水平势团,两个垂直势团和 4 个对角线势团。由此可以发现,由于模糊条件下的两点势团能量  $V_{s,c}(y | y_t)$  和式(1)补偿项中  $1 - \mu$  的表示是一致的,故使用基于模糊集的 Gibbs 势团能量可以有效地对图像的空间约束进行描述。若使用上面的模糊势团定义,并且约去空间项的指数,则不失有效性,式(1)可以改变为

$$J = \sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m (1 - K(x_k, v_i)) + \frac{\alpha}{\tilde{N}} \sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m \sum_{r \in N_k} V_{s_k,c}(i | y_r) \quad (10)$$

其中  $s_k$  表示与序号  $k$  对应的像素。值得注意的是,式(5)和式(2)相似,式(2)是指数函数,式(5)是归一化的指数函数,基于这种描述上的一致性,并使用式(9)中的多级逻辑模型中两点势团能量的模糊定义由式(5)、式(7)即可得到以下基于模糊 Gibbs 分布描述的像素分布的先验概率:

$$P_s(y) = Z^{-1} \exp\left(-\frac{\sum_{r \in N_k} (1 - \mu_{y,r})}{\beta^2}\right) \quad (11)$$

$$v_l = \frac{\sum_{k=1}^N \mu_{i,k}^m K(x_k, v_l) x_k}{\sum_{k=1}^N \mu_{i,k}^m K(x_k, v_l)} \quad (15)$$

即  $P_s(y)$  与归一化的核函数具有相似的形式。由于这种相似性对核聚类算法是有效的,因此本文提出了一种用  $P_s(y)$  来描述空间约束的核聚类算法,其目标函数如下:

$$\begin{aligned} J &= \sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m (1 - K(x_k, v_i)) + \\ &\sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m (1 - P_{s_k}(i)) \\ &= \sum_{i=1}^c \sum_{k=1}^N \mu_{i,k}^m (2 - K(x_k, v_i) - P_{s_k}(i)) \end{aligned} \quad (12)$$

式(12)中的核函数可在整体上对图像的灰度特征进行度量,而 Gibbs 分布则在图像局部上对标记值的相似性进行度量。通常由于灰度的取值范围要远大于标记值的取值范围,所以核函数可以看作是一种像素高解析度上的度量,而其标记的 Gibbs 分布则是一种较低解析度上的度量,这种度量有效地描述了图像的空间约束,而且核函数和使用模糊 Gibbs 模型定义的像素的先验概率都是使用指数函数来定义,后者在形式上是前者的归一化描述。和式(1)类似,上面的目标函数也有两个参数需要确定,即式(2)中的  $\sigma$  和式(11)中的  $\beta$ 。由于式(2)和式(11)表达形式上具有相似性,因此两式可能存在某种联系。由于在理论上描述最优参数之间的关系,目前还有困难,本文暂且通过实验进行确定,实验表明,对于图像良好的分割而言,通常存在  $\sigma \geq \beta$ ,若设

$$\sigma^2 = \lambda^2 \beta^2 \quad (13)$$

则对于分段光滑的图像来说, $\lambda$  的值较稳定,且变化幅度不大。通常对低信噪比的图像应取较大的  $\lambda$  值,或较小的  $\beta$  值,以增强邻域像素间的相互作用,进而克服噪声的影响。目前还没有  $\sigma$  和  $\beta$  取值的精确模型,两参数的取值主要靠经验确定,实验表明,对于 8 bits 格式灰度图像, $\sigma$  取数 150 附近是合适的<sup>[6]</sup>,并且通常  $\beta < 2$ ,本文通过实验在这个范围确定两参数的合理取值。

采用与传统的 FCM 算法类似的方法,利用 Lagrange 乘数法,即可以得到以下隶属度和聚类中心的迭代公式:

$$\mu_{i,k} = \frac{(2 - K(x_k, v_i) - P_{s_k}(i))^{-1/(m-1)}}{\sum_{j=1}^c (2 - K(x_k, v_j) - P_{s_k}(j))^{-1/(m-1)}} \quad (14)$$

本文算法步骤可以归纳如下:

- (1) 选择初始的聚类中心集合  $\{v_i \mid i = 1, \dots, c\}$ , 并设定一个足够小的正数  $\varepsilon$ 。
- (2) 使用式(14)更新隶属度矩阵。
- (3) 使用式(15)更新聚类中心。
- (4) 反复迭代第(2),(3)步,直到达到预先设定的最大迭代步数,或者目标函数满足下面的收敛条件:

$$|J^{\text{new}} - J^{\text{old}}| \leq \varepsilon \quad (16)$$

## 4 实验结果及其分析

为了验证本文算法的分割效果,使用 FCM, KSFCM 算法和本文算法对合成图像、MR Phantom 和临床 MR 图像进行了分割实验,并对实验结果进行了分析。实验时,目标函数  $J$  中的隶属度指数取  $m = 2$ ,并取目标点的  $3 \times 3$  邻域。对于 8 bits 灰度图像,采用文献[6]中的建议,即在  $\sigma = 150$  附近确定最优的分割参数。另外,对于 16 bits 灰度的脑部临床 MR 图像, $\sigma$  的取值应该比前者大得多。注意到,8 bits 灰度的最大值为 255,16 bits 灰度的最大值为 65 535,实验表明,合适的  $\sigma$  取值的数量级应该和最大灰度的数量级相匹配。本文在进行 16 bits 灰度图像的分割中,通常在  $\sigma = 15\ 000$  附近搜索最优的参数。

在进行 KSFCM 算法分割实验时,本文在文献[5]建议的基础上,通过扩大空间约束项系数  $\alpha$  的取值范围,即  $\alpha \in (0, 2)$ ,并通过实验得到了最优的分割结果。使用本文算法进行分割实验时,设 Gibbs 分布的参数  $0.01 \leq \beta \leq 2$ ,在大多数情况下取值在  $\beta = 1.2$  附近是合适的。由于核函数参数  $\alpha$  和 Gibbs 分布参数  $\beta$  的取值具有相对的稳定性,若设式(13)中的  $\lambda$  为常数(例如对于 8 bits 灰度的 MR 图像,可设  $\lambda = 125$ ),则本文算法实际上只有一个调整参数。即便放松这个限制,也将和 KSFCM 算法一样有两个可调参数。实验表明,即使在只有一个可调参数的情况下,本文算法往往也能得到更优的分割结果。

图 1 和图 2 给出了使用 FCM,KSFCM 算法和本文算法经过 100 次迭代后(通常足够达到收敛)对

合成图像进行分割的结果。

图 1 的实验数据为被高斯噪声污染的 4 色 8 bits 灰度图像,其中噪声的均值为 0,方差为最大灰度值的 1%。图像大小为  $64 \times 64$  pixels,4 个灰度值被噪声污染前分别为 32,96,160,224。图 2 的实验的数据也为 8 bits 灰度图像,被噪声污染前的灰度

值、高斯噪声的均值和方差以及图像的大小和图 1(a)相同。此外,图 2(a)合成数据在水平方向上还受一个低频变化的乘性正弦场的影响。正弦的振幅为 1.1,周期为图像水平宽度的 2 倍,正弦在图像水平方向左端点的初始相位为  $\frac{\pi}{2}$ 。

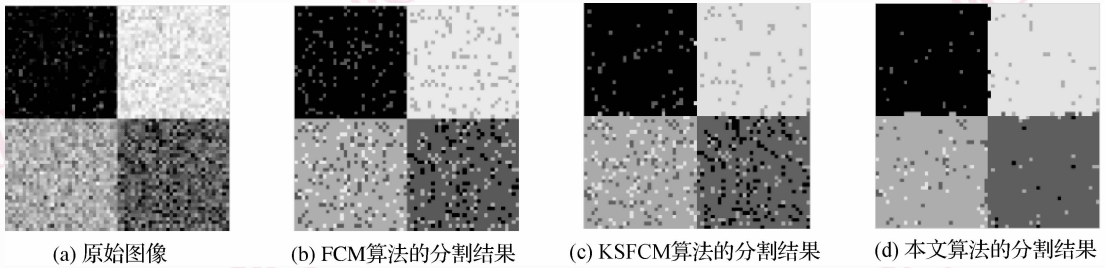


图 1 被高斯噪声污染的合成图像的不同算法分割结果比较

Fig. 1 Comparison of the segmentation results on a synthetic image corrupted by Gaussian noise




图 2 被高斯噪声和水平正弦有偏场污染的合成图像的不同算法分割结果比较

Fig. 2 Comparison of the segmentation results on a synthetic image corrupted by Gaussian noise and horizontal sinusoidal intensity inhomogeneity.

从图 1 和图 2 的分割结果可以看出,由于基于灰度的 FCM 算法没有考虑像素间的空间联系,因此往往难以得到精确的分割结果,而使用核函数和空间约束的 KSFCM 算法则可以得到较好的分割结果。本文算法也是一种使用空间约束的核聚类算法,并提出了空间约束、核函数以及图像模糊信息间的联系,因此可以得到更精确的分段光滑的分割结果(见表 1)。

表 1 合成图像分割的正确率

Tab. 1 Segmentation accuracy on synthetic images

算法	正确率 (%)	
	图 1	图 2
FCM	83.7	81.4
KSFCM	86.6	86.5
本文算法	95.6	93.6

另外,还使用 MNI BrainWeb 的 MR brain Phantom 数据进行了分割实验,该数据是一组模拟的 MR 脑部图像。使用该数据不仅可以方便地进行各种受控制的分割实验,并且由于该数据提供了脑组织在空间和灰度上分布的各种信息,因此使用这种模拟 MR 图像可以精确地定量分析分割效果的优劣<sup>[12]</sup>。

本文使用 MR brain Phantom 数据提供的标准分割结果,对使用不同算法得到的分割结果进行了比较。实验数据为 T1 加权脑部图像的轴面数据,其是大小为  $217 \times 181$  pixels,并受到 9% 的高斯噪声和 40% 有偏场影响的 8 bits 灰度图像。

图 3(a)为实验使用的 MRI Phantom 轴面数据的第 101 帧图像。分割的目的是把图像划分为白质,灰质和脊髓液 3 个部分。在进行分割前,已经去除了该图像的颅外部分。图中白质、灰质和脊髓液的分割结果以不同的灰度显示。




图 3 被高斯噪声和灰度有偏场污染的 T1 加权脑部 MR Phantom 的不同算法分割结果比较

Fig. 3 Segmentation results on a T1 weighted brain phantom corrupted by Gaussian noise and intensity inhomogeneity

从图中所示的分割结果来看,本文算法得到的分割结果较之 FCM 和 KSFCM 算法的分割结果更加光滑。为了进一步定量分析所得到的分割结果,对分割图像和标准分割结果进行了比较。表 2 的数据也显示本文算法的分割效果最佳。

表 2 图 3 的分割结果的定量评价指标

Tab. 2 Quantitative indices of the segmentation in Fig 3

算法	重叠度 (%)			正确率 (%)
	白质	灰质	脊髓液	
FCM	81.7	70.3	76.8	86.8
KSFCM	84.2	74.6	80.8	88.9
本文算法	87.2	78.1	79.8	90.6

在对临床脑部 MR 图像进行分割实验时,采用了美国麻省总医院形态分析中心的在线脑部图像分




图 4 被高斯噪声人工污染的临床 T1 加权脑组织图像的不同算法分割结果比较

Fig. 4 A real T1 weighted brain tissue image artificially corrupted by Gaussian noise and the segmentation results using different algorithms

表 3 图 4 分割结果的定量评价指标

Tab. 3 Quantitative indices of the segmentation in Fig 4

算法	重叠度 (%)		正确率 (%)
	白质	灰质	
FCM	46.3	56.4	68.3
KSFCM	61.4	70.5	79.9
本文算法	62.6	75.8	82.8

析数据度 (MGH CMA IBSR) 脑部 MR 数据,该数据也具有一个由专家半手工分割的标准结果,使用该标准分割结果,可以方便地进行各种算法分割效果的定量评价。实验图像由成像磁场强度为 1.5 Tesla 的设备获得,平面解析度为  $0.9375 \text{ mm}^2$ 。

图 4(a) 为除去了颅外部分的脑部冠面数据,并加入了均值为 0,方差为最大灰度 1% 的高斯噪声的 16 bits 灰度图像。图中的分割结果以不同的灰度显示。和专家的分割结果相比较而得到的定量评价结果见表 3。从图 4 可以看出,基于灰度的 FCM 算法的分割结果依然存在大量的离散点,而 KSFCM 算法的分割结果中这样的离散点则大量减少,但分割结果依然比较分散。而本文算法的分割结果,离散点和分散区域则大大减少。

在对分割结果和标准结果进行比较时,使用了分割正确率  $S_1$ ,和分割覆盖率  $S_2$  两个数值指标来衡量分割结果的优劣<sup>[3,7]</sup>。两个指标定义如下:

$$S_1 = \frac{N_1}{N} \quad (17)$$

其中,  $N_1$  为分割正确的像素数,  $N$  为总像素数。

$$S_2 = \frac{A_j \cap A_j^{\text{std}}}{A_j \cup A_j^{\text{std}}} \quad j \in \{1, \dots, c\} \quad (18)$$

式中,  $A_j$  为分割结果第  $j$  个区域的像素集合,  $A_j^{\text{std}}$  为标准分割第  $j$  个区域的像素集合。  $S_1$  从图像的整体上描述了分割结果的质量, 而指标  $S_2$  则反映了局部区域的分割精度。两式中的数值越大 ( $S_1, S_2 \leq 1$ ), 则说明分割的效果越好。

表 2 ~ 表 3 分别列出了合成图像、MR Phantom 和临床 MR 数据的分割结果的定量衡量指标。表中列出的数据显示了本文算法的分割效果最佳。

## 5 结 论

在核聚类算法的基础上, 利用 Markov 随机场模型, 提出将 Gibbs 分布描述的图像空间约束用来分割脑部 MR 图像。改进了原有聚类算法的目标函数, 并给出了新目标函数下的数据隶属度和聚类中心的迭代公式。

由于本文算法使用的核函数和 Gibbs 分布具有相似的形式, 从而更自然地提供了一个使用空间约束的核聚类算法。该算法可以补偿图像噪声和低频有偏场对聚类结果的影响。

作为算法中两个关键参数, 即 GRBF 核中的  $\sigma$  和 Gibbs 分布中的  $\beta$ , 本文通过实验确定。关于两参数的估计和定量分析将还需要进行后续的工作。

对合成图像、MR Phantom 和临床脑部 MR 数据的实验结果表明, 本文算法的分割效果最佳, 可见本文算法有利于进行脑部 MR 图像分段光滑的分割。

另外需要指出的是, 本文算法虽然可以在一定程度上克服有偏场, 但并未额外考虑有偏场估计的问题。有偏场的估计是一个复杂的问题, 基于核聚类和空间约束的有偏场的纠正是以后将要研究的问题。

## 参考文献 (References)

- Liew A W C, Leung S H, Lau W H. Fuzzy image clustering incorporating spatial continuity [J]. IEE Proceedings-Vision Image and Signal Processing, 2000, **147**(2): 185-192.
- Liew A W C, Yan H. An adaptive spatial fuzzy clustering algorithm for 3-D MR image segmentation [J]. IEEE Transactions on Medical Imaging, 2003, **22**(9): 1063-1075.
- Ahmed M N, Yamany S M, Mohamed N, et al. A modified fuzzy C-means algorithm for bias field estimation and segmentation of MRI data [J]. IEEE Transactions on Medical Imaging, 2002, **21**(3): 193-199.
- Pham D L. Fuzzy clustering with spatial constraints [A]. In: Proceedings of IEEE International Conference in Image Processing [C], New York, USA, 2002: 65-68.
- Zhang D Q, Chen S C. A novel kernelized fuzzy C-means algorithm with application in medical image segmentation [J]. Artificial Intelligence in Medicine, 2004, **32**(1): 37-50.
- Chen S C, Zhang D Q. Robust image segmentation using FCM with spatial constraints based on new kernel-induced distance measure [J]. IEEE Transactions on Systems, Man and Cybernetics, 2004, **34**(4): 1907-1916.
- Müller K R, Mika S, Rätsch G, et al. An introduction to kernel-based learning algorithms [J]. IEEE Transactions on Neural Networks, 2001, **12**(2): 181-201.
- Kim D W, Lee K Y A, Lee D, et al. A kernel-based subtractive clustering method [J]. Pattern Recognition Letters, 2005, **26**(7): 879-891.
- Girolami M. Mercer kernel-based clustering in feature space [J]. IEEE Transactions on Neural Networks, 2002, **13**(3): 780-784.
- Yan Gang, Chen Wu-fan, Feng Yan-qiu. Generalized fuzzy Gibbs random field and research on algorithm for MR image segmentation [J]. Journal of Image and Graphics, 2005, **10**(9): 1082-1088. [颜刚, 陈武凡, 冯衍秋. 广义模糊 Gibbs 随机场与 MR 图像分割算法研究 [J]. 中国图象图形学报, 2005, **10**(9): 1082-1088.]
- Salzenstein F, Pieczynski W. Parameter estimation in hidden fuzzy markov random fields and image segmentation [J]. Graphical Models and Image Processing, 1997, **59**(4): 205-220.
- Collins D L, Zijdenbos A P, Kollokian V, et al. Design and construction of a realistic digital brain phantom [J]. IEEE Transactions on Medical Imaging, 1998, **17**(3): 463-468.