

广义模糊 Gibbs 随机场与 MR 图像分割算法研究

颜 刚 陈武凡 冯衍秋

(南方医科大学医学图像处理重点实验室, 广州 510515)

摘 要 为了对图像进行准确、可靠的分割, 提出了一种基于广义模糊集的软分割算法, 并将广义模糊集和 Gibbs 场结合起来, 提出了广义模糊 Gibbs 随机场模型, 同时建立了广义模糊 Gibbs 分割 (GFGS) 算法。该算法是首先把每一个分割类看作是广义模糊类, 并以最大后验概率 (MAP) 为判别准则来决定每一个像素值的归类以及它属于该类的隶属度; 然后用广义隶属度函数中负的部分来刻画数据中的异常值, 使得该算法能有效地处理异常值; 最后用该模糊类的质心来更新类的中心, 并以人脑的仿真图像和临床 MR 图像进行了实验。实验结果表明, 该算法能有效地滤除噪声和处理部分容积效应, 是一个分割能力强、稳健性好的算法。

关键词 广义模糊集 广义模糊 Gibbs 随机场 图像分割 部分容积效应

中图分类号: TP391.41 文献标识码: A 文章编号: 1006-8961(2005)09-1082-07

Generalized Fuzzy Gibbs Random Field and Research on Algorithm for MR Image Segmentation

YAN Gang, CHEN Wu-fan, FENG Yan-qiu

(Key Laboratory of Medical Image Processing, Southern Medical University, Guangzhou 510515)

Abstract A soft image segmentation algorithm based on the generalized fuzzy set is presented in this paper. We incorporate Gibbs random field into the generalized fuzzy set to compensate for the spatial information, and a generalized fuzzy Gibbs random field model is proposed, and the generalized fuzzy Gibbs segmentation algorithm (GFGS) is developed. Each class is considered as a generalized fuzzy class, and the segmented image is regarded as a generalized fuzzy set on the label set in the proposed algorithm. With the proposed algorithm, the outliers in the image data are described by the negative part in the generalized fuzzy membership function, and can be dealt with effectively. Maximum a posteriori (MAP) is used as the statistical segmentation criteria, in which the generalized fuzzy Gibbs random field is used to obtain priori knowledge. Every class center is updated by the centroid of the generalized fuzzy class. Experimental results on both MR real data and the stimulated brain data show that the proposed algorithm is robust, which can filter the noise and partial volume effect significantly.

Keywords generalized fuzzy set, generalized fuzzy Gibbs random field, image segmentation, partial volume effect

1 引 言

图像分割是当前模式识别与图像理解领域中的研究热点。准确地对医学图像 (如 CT、MR 图像) 中的不同组织进行分割, 对临床辅助诊断及量化分析

有重要意义, 然而由于噪声或部分容积效应等伪影的存在^[1], 使得准确地对图像进行分割非常困难。

目前有很多基于统计的分割算法, 如最大后验概率 (maximum a posterior, MAP)、最大似然 (maximum likelihood, ML)、期望最大法 (expectation maximization, EM) 及模拟退火算法 (simulated

基金项目: 国家“973”重点基础研究发展规划项目 (2003CB716101); 国家自然科学基金重点项目 (30130180); 国家科技攻关项目 (2004BA706B01)

收稿日期: 2004-09-27; **改回日期:** 2005-01-25

第一作者简介: 颜刚 (1972 ~), 男, 讲师。1999 年获中山大学应用数学硕士学位, 主要研究领域为图像处理与模糊随机场。E-mail: yangang@fimmu.com

annealing, SA)等都是非常流行的算法^[2]。其中,基于马尔可夫随机场的分割算法因其能很好地刻画图像的空间信息而广泛应用于图像的区域分割,但是它们都是硬分割算法^[1]。对于医学图像来说,由于部分容积效应及密度非均匀性等伪影的存在^[3],致使这些硬分割算法难于精确地对医学图像进行有效的分割,同时造成在图像边缘处、图像噪声处及其异常值处大量的错分现象。这些问题都是硬分割算法自身难以解决的矛盾。因此,近年来软分割算法越来越受到广泛的重视。

基于模糊集的软分割算法已经广泛应用于图像分割中^[1,3-5]。众所周知,模糊 C-均值 (fuzzy C-mean, FCM)是一个应用广泛又十分有效的算法,也是最早的软分割算法,以后所提出的各种软分割算法大多都是在此基础上发展和建立起来的。它突破了常规的分割算法中经典的二值逻辑,开始将模糊集引入到算法中。所谓的软分割就是同一个像素不同程度地归属两个以上的分割区域^[6],即在每一步迭代过程中没有严格地将像素归到某一类,而是将它以不同程度归到每一个类,在算法停止后,再以一定规则消除模糊,也就是通过将模糊集转化为经典集合来实现原图像的分割。这样由于每一个硬分类在模糊集意义下都是模糊类,因此就可以有效提高图像分割的精确性。

在 FCM 算法中,设定目标函数为

$$\begin{cases} J = \sum_{i=1}^c \sum_{j=1}^n \mu_{j,i}^b \|y_j - m_i\| \\ \text{s. t.} \quad \sum_{i=1}^c \mu_{j,i} = 1, j = 1, 2, \dots, n \end{cases} \quad (1)$$

其中, c 为类数, n 为像素数, b 为控制参数, $\mu_{j,i}$ 为第 j 个像素对于第 i 类的隶属度, y_j 为第 j 个像素的灰度值, m_i 为第 i 个类中心 (下面类中心均指该类的灰度值), 进而就可以得到以下目标函数最小时的必要条件:

$$m_i = \frac{\sum_{j=1}^n \mu_{j,i}^b \cdot y_j}{\sum_{j=1}^n \mu_{j,i}^b}, i = 1, 2, \dots, c \quad (2)$$

$$\mu_{j,i} = \frac{\left(\frac{1}{\|y_j - m_i\|} \right)^{1/(b-1)}}{\sum_{k=1}^c \left(\frac{1}{\|y_j - m_k\|} \right)^{1/(b-1)}}, i = 1, 2, \dots, c; j = 1, 2, \dots, n \quad (3)$$

虽然 FCM 算法被广泛地应用于图像分割,但是

可以看出它也存在以下诸多不足:

(1) 图像各像素间的数据是相互独立的,也就是它独立于空间位置。通常情况下,由于图像可看作是分段光滑的,因此,非相关性假设是不合理的,而且在图像有噪声时会严重影响分割质量;

(2) 隶属度函数的确定仅仅依赖于像素点到类中心 (也就是类均值) 的距离,即 $\mu = f(m)$, μ 为隶属度, m 为类中心,而没有考虑类的方差;

(3) 无法处理异常值。当某个像素的灰度值为异常值时,从式 (2) 看到,在计算类中心时,既增加了计算代价,同时也影响了类中心的计算,最终将产生不正确的分割结果。

针对以上情况,可采取以下对策:

(1) 用 Gibbs 随机场来刻画空间信息,因为 Gibbs 随机场能有效地描述图像的空间信息。将 Gibbs 随机场和模糊集集合起来,并以此来弥补 FCM 算法空间信息的缺失;

(2) 在隶属度的计算上,不仅需考虑此像素值与类中心的距离,而且要考虑此类的方差 σ , 即 $\mu = f(m, \sigma)$;

(3) 作者认为有以下两种情况的异常值:一是当有噪声存在时,如果考虑一个像素的灰度值与它的邻域的灰度有较大差异,且它们又属于同一类时,那么该像素的灰度值与本类中心就会差异很大。此时,它的标记在更大程度上应该由其邻域的属性来决定;二是图像本身就存在异常值,不但类与类之间的过渡数据,亦此亦彼,且远离每个类的中心。对于图像中的异常值,可以在计算中除去此点,以降低计算量和增加计算精度,而且稳健性也提高。以广义模糊集 (下面给出它的具体定义) 来代替模糊集,由广义模糊集来描述图像的模糊性则更为合理。

Caillolz 在文献 [7, 8] 和 Salzenstein 在文献 [9] 中是将模糊集和统计方法相结合用模糊随机场来进行图像分割,但是其仅仅解决了二值图像的分割。文献 [7~9] 在两个确定类的基础上增加了模糊类来进行分割,如果是多值分割,那么就在每两个确定类之间增加模糊类,由于其需要用多个狄拉克测度和勒贝格测度来描述,因此这无疑大大增加了算法的复杂性,而且算法难于实现。本文的算法不但将经典模糊集推广为广义模糊集,而且视每一个分割类都是广义模糊类,由于其从算法上容易实现,从而更好地解决了医学图像中的多值分割问题。

2 广义模糊集与广义模糊 Gibbs 随机场

2.1 广义模糊集

陈武凡等在文献[10]里首次提出广义模糊集的概念,其是对经典模糊集的补充与推广,现已经广泛地应用于图像处理的各个领域。其概念如下:

论域 U 上广义模糊集可表征为

$$A = \int_{x \in U} \mu_A(x)/x \text{ 或 } A = \{(\mu_A(x), x \in U)\} \quad (4)$$

其中, $\mu_A(x) \in [-1, 1]$ 称为 U 上 A 的广义隶属度函数;称 $\mu_A(x) \in [-1, 0]$ 为 U 上不完全属于 A 的广义隶属度函数;称 $\mu_A(x) \in (0, 1]$ 为 U 上完全属于 A 的广义隶属度函数; $\mu_A(x) = 0$ 为 U 上 A 的模糊分界点函数。

2.2 建立广义模糊类

经典的基于 Gibbs 随机场的图像分割需要以下两个随机场来描述。记 $S = \{1, 2, \dots, n\}$ 为图像的像素集, $X = (X_i)_{i \in S}$ 是隐 Gibbs 随机场, 它的一个现实代表一个分割结果; $Y = (Y_i)_{i \in S}$ 是可见随机场, 它的一个现实 $y = (y_i)_{i \in S}$ 就是人们所观察到的图像。每一个随机变量 X_i 取值于 $\Omega = \{1, 2, \dots, k\}$, 而 Ω 就是图像分割后类的集合。事实上, 图像分割就是一个逐点标记的过程, 标记函数为

$$l: y \rightarrow \Omega \quad y_i \mapsto j = l(y_i) \quad (5)$$

然而, 如果两个像素点的灰度 y_i 和 y_j 都被标记为第 p 类, 那么由于它们距第 p 类中心 m_p 的距离不同, 因此可以认为 y_i 和 y_j 被标记为 p 的程度应有所区别。由于可考虑用软分类来代替硬分类, 也就是将标记类 Ω 里的元素用模糊集来代替, 同时考虑到每一个类里都会有异常值存在, 因此这里每一个类可用广义模糊集来表示, 更符合实际情况, 即

$$\Omega = \{\tilde{1}, \tilde{2}, \dots, \tilde{k}\} \quad (6)$$

\tilde{j} 是广义模糊类, $j = 1, 2, \dots, k$ 。

如何建立每一个广义模糊类。假定图像中 k 个类的均值和方差为 $(m_1, \sigma_1^2; m_2, \sigma_2^2; \dots; m_k, \sigma_k^2)$, 这里总假定每个类的灰度均服从正态分布, 而将类的每一个元素都看作是正态随机变量的抽样。这样就可以考虑把像素值 y_i 归到哪一类, 如果把 y_i 归到第 j 类, 那么就on把像素 y_i 标记为 j , 即 $l(y_i) = j$ 。可通过假设检验(原假设为 $H_0: l(y_i) = j$, 对立假设为 $H_1: l(y_i) \neq j$)来确定 y_i 是否的确被标记为第 j 类或是确定被标记为第 j 类的可信度是多少。检验时,

取检验水平 $\alpha = 10\%$, 如果原假设成立, 则意味着像素 y_i 属于第 j 类, 或者说 y_i 与第 j 类中心灰度无显著性差异, 即像素点 y_i 的灰度值落在了 90% 置信区间 $[m_j - 1.64\sigma_j, m_j + 1.64\sigma_j]$ 内。为计算方便, 可取 90% 的置信区间为 $[m_j - 1.6\sigma_j, m_j + 1.6\sigma_j]$ 。对于置信区间外的值, 则认为它与类中心 m_j 有显著性差异, 可视它为异常值。此外, 对于随机变量 $\xi \sim N(m, \sigma^2)$, 由于有 $P(|\xi - m| < 3\sigma) \approx 0.9973$, 也就是几乎所有 ξ 的样本都落在 $[m - 3\sigma, m + 3\sigma]$ 里面, 因此, 如果某个灰度值与类中心的差值大于本类标准差的 3 倍时, 就可以认为它完全不属于本类, 则设定的广义模糊类为

$$\tilde{j} = \{\mu_j(y_i), i \in S\} = \{\mu_{j,i}, i \in S\}, j = 1, 2, \dots, k \quad (7)$$

其中, $\mu_j: y \rightarrow [-1, 1] \quad y_i \mapsto \mu_j(y_i)$,

$$\mu_j(y_i) = \begin{cases} 1 - \frac{|y_i - m_j|}{1.6\sigma_j} & |y_i - m_j| \leq 1.6\sigma_j \\ \frac{8}{7} - \frac{|y_i - m_j|}{1.4\sigma_j} & 1.6\sigma_j < |y_i - m_j| \leq 3\sigma_j \\ -1 & |y_i - m_j| > 3\sigma_j \end{cases} \quad (8)$$

由式(8)可以看出, 当某灰度值与某类中心的差值小于本类标准差的 1.6 倍时, 则隶属度规定为正值; 当大于本类标准差 1.6 倍时, 则隶属度规定为负值; 当超过本类标准差 3 倍时, 则隶属度规定为 -1。

当建立起 k 个广义模糊类后, 则每一个像素点都有一个广义模糊表达, 每个像素的灰度值不但有一个类的归属, 而且有其属于该类的隶属度。如果记 $l(y_i)$ 为灰度值 y_i 的标记, 称 $L = (l_i)_{i \in S}$ 为标记场, $\mu_{l(y_i)}$ 为灰度值 y_i 属于类 $l(y_i)$ 的广义隶属度, 那么

$$X = x = (x_1, x_2, \dots, x_n)$$

$$= \left(\frac{\mu_{l(y_1)}}{l(y_1)}, \frac{\mu_{l(y_2)}}{l(y_2)}, \dots, \frac{\mu_{l(y_n)}}{l(y_n)} \right), \quad (9)$$

x 是 X 的一个现实,

$$-1 \leq \mu_{l(y_i)} \leq 1, 1 \leq l(y_i) \leq k, i = 1, 2, \dots, n$$

即为一幅图像的广义模糊现实, 也可以看作是标记集 $\Omega = \{1, 2, \dots, k\}$ 上的广义模糊集。

2.3 广义模糊 Gibbs 随机场

在上述广义模糊集的定义下, 图像就有了广义模糊表达, 如果建立了适当的势函数, 那么也就建立了广义模糊 Gibbs 随机场。这里, 本文仅考虑具有二元势函数的 Gibbs 模型, 定义能量函数为

$$E(x) = \sum_{i \in S} \sum_{j \in N_i} \beta_i \cdot V(x_i, x_j) \quad (10)$$

其中, N_i 为第 i 个位置的邻域, $V(x_i, x_j)$ 为势函数。

如果 β_i 恒为一个常数,则称此广义模糊 Gibbs 随机场为齐次的;反之,若 β_i 是随空间位置而变化的,则随机场就是非齐次的。对于齐次的 Gibbs 随机场, β_i 越大,说明空间相关性越强; β_i 越小,说明空间相关性越弱。对于一幅图像,由于其空间相关性是随空间位置变化的,所以本文考虑用非齐次的 Gibbs 随机场更为合理。它的势函数定义为

$$V(x_i, x_j) = \begin{cases} |\mu_p(x_i) - \mu_p(x_j)| - 1, & l(x_j) = l(x_i) = p, 1 \leq p \leq k \\ \mu_p(x_j), & l(x_j) \neq l(x_i) = p \end{cases} \quad (11)$$

3 分割算法与实验

本文的算法是属于贝叶斯方法,它是以广义模糊 Gibbs 随机场 $X = (X_i)_{i \in S}$ 作为先验知识来得到后验概率 $P(x|y)$, 同时以 MAP 作为分割准则,并采用条件迭代模式(conditional iteration mode, ICM)作为优化方案来得到 MAP 的解。该所得到的 MAP 的解既包含了原图像的标记,又包含了该标记的广义隶属度,也就是得到了 k 个更新的广义模糊类,这样就可利用广义模糊类的隶属度函数正的部分的质心来更新本类的中心。

3.1 算法描述

该算法称为广义模糊 Gibbs 分割(generalized fuzzy gibbs segmentation, GFGS)算法,该算法描述如下:

(1) 用 k -均值法实现图像的初始分割 $L = (l(y_i))_{i \in S} = (l_i)_{i \in S}$ 和得到各类的均值和方差:

$$(m_1, \sigma_1^2; m_2, \sigma_2^2; \dots; m_k, \sigma_k^2)$$

(2) 如上所述,如果已建立起广义模糊类, $\tilde{j} = \{\mu_j(y_i), i \in S\}, j = 1, 2, \dots, k$; 那么每一个像素

点的广义模糊可表达为 $x_j = \frac{\mu_{l_i}}{l_i} = \frac{\mu_{l_i}(y_i)}{l(y_i)}, 1 \leq l_i \leq k, -1 \leq \mu_i \leq 1$;

(3) 计算先验能量 $E(x_i | x_{N_i}) = \sum_{j \in N_i} \beta_i \cdot V(x_i, x_j)$, 其中势函数如上定义,设定 $\beta_i = 1 - 0.5\mu_{l_i}(y_i)$, 这里,所取的平滑参数 β_i 是随空间位置而改变的量,也就是它是空间位置的函数,由此可以看出,对于某一像素点的灰度值 y_i ,如果将其标记为 m ,那么 β_i 是 $\mu_m(y_i)$ 的减函数,之所以这样设置,是因为 $\mu_m(y_i)$ 越小,说明它属于类 m 的程度就越小,也就是它应该更多地视其邻域的状况来决定其归属;而

当 $\mu_m(y_i)$ 较大时,则说明它与类 m 的差异较小,所以它的归属应该主要由其自身的灰度特性来决定,仅兼顾其邻域的情况;

(4) 计算似然能量 $E(y_i | x_i) = E(y_i | l_i) = \frac{(y_i - m_i)^2}{2\sigma_i^2} + \lg \sigma_i$;

(5) 得到后验能量 $E(x_i | y_i) = E(x_i | x_{N_i}) + E(y_i | x_i)$, 由 ICM 可得到

$$x_i = \frac{\mu_{l_i}}{l_i} = \arg \min_{\substack{1 \leq l_i \leq k \\ -1 \leq \mu_i \leq 1}} E(x_i | y_i);$$

(6) 由 x_i 来更新类的均值和方差,其中的均值可用广义模糊集的质心来计算

$$m_j = \frac{\sum_{i, \mu_j > 0} \mu_j(y_i) y_i}{\sum_{i, \mu_j > 0} \mu_j(y_i)} \quad (12)$$

$$\sigma_j^2 = \frac{\sum_{i \in S} (y_i - m_j)^2 I_A(y_i)}{\sum_{i \in S} I_A(y_i)} \quad (13)$$

其中, $A = \{y_i | l(y_i) = j, \mu_j(y_i) > 0\}, I_A(x) = \begin{cases} 1, & x \in A \\ 0, & x \notin A \end{cases}$;

(7) 重复步骤(2) ~ 步骤(6)。

3.2 实验

为验证本文算法的效果,采用脑部仿真图像和真实的脑部 MR 图像对本算法进行了测试实验。仿真数据用不同的噪声对本算法进行量化评估,同时采用 FCM 算法、基于经典 Gibbs 随机场的分割算法(classical Gibbs segmentation, CGS)和 ML 算法进行对比分割实验。实验首先将脑部图像分割为 4 个类,分别为背景(BG)、灰质(GM)、白质(WM)和脑脊液(CSF)。

图 1 给出了几种不同的算法对真实的临床 MR 图像进行分割的结果。其中图 1(a)为真实的临床 MR 图像的原图;图 1(b) ~ 图 1(d)分别为用 GFGS 算法、FCM、CGS 和 ML 算法进行分割的结果。从分割结果可以看出,对于 ML 算法和 FCM 算法的分割结果,分割区域有明显的异类残存,且分割区域不完整。这是由于它们没有考虑图像的空间信息所致。对于 CGS 算法而言,在图像的底端,不仅白质区域和灰质区域没有完全分割开来,同时也存在分割区域不完整,而且分割边界不连续,光滑性也不好的问题。这是由于此处的数据属于异常值所致,而本算法用广义模糊集来刻画此异常值,其分割结果得到

明显的改善,且区域完整,边界连续光滑。

图 2 给出了用几种不同的算法对脑部仿真图像进行分割的结果。由图 2 各图的对比可见,本文的 GFGS 算法仍然可以得到各个完整的无噪声残存的区域,而且边界连续光滑。

图 3 给出了有噪声的仿真图像的分割结果。图 3(a)为原图,它是加了 9% 噪声的图 2(a)脑部仿真

图像。图 3(b) ~ 图 3(d) 分别为用 GFGS 算法、FCM、CGS 和 ML 算法进行分割的结果。由图 3 可以看出,FCM 算法和 ML 算法对噪声图像几乎无能为力。CGS 算法由于考虑了图像的空间信息,所以分割结果相对于 FCM 和 ML 算法有了明显改善,但是,在异常值及边缘处仍然存在大量的孤立点以及不平滑的边界。




图 1 临床 MR 图像几种不同算法的分割结果对比

Fig. 1 Comparison of segmentation results on a real MR image




图 2 脑部仿真图像几种不同算法的分割结果对比

Fig. 2 Comparison of segmentation results on an MR phantom





图 3 添加了 9% 噪声的脑部仿真图像几种不同算法的分割结果对比

Fig. 3 Comparison of segmentation results on an MR phantom corrupted with 9% Gaussian noise


图 4 是图 2(a)和图 3(a)用不同算法分割得到的白质输出图。其中,图 4(a) ~ 图 4(d) 分别是用 GFGS、FCM、CGS 和 ML 算法对图 2(a)进行分割得

到的白质输出图;图 4(e) ~ 图 4(h) 分别是用 GFGS、FCM、CGS 和 ML 算法对图 3(a)进行分割得到的白质输出图。由各图对比可见,GFGS 算法较



GFGS 算法 FCM 算法 CGS 算法 ML 算法

(a) 图2 原图白质输出结果



GFGS 算法 FCM 算法 CGS 算法 ML 算法

(b) 图3 原图白质输出结果

图4 不同算法下的白质输出结果

Fig. 4 White matter of original image in Figure 2 using different algorithms

其他算法能更清晰地得到完整的白质,特别是在处理噪声图像时,GFGS 算法得到的白质较之无噪声时几乎没有差别。

表 1 给出了几种不同算法在不同噪声情况下,图 2(a)的错分率(misclassification rate, MCR)^[8] MCR。错分率定义为分类错误的像素数 N_1 除以图像总的像素数 N ,即

$$MCR = \frac{N_1}{N} \times 100\%$$

由此可以看出,对于噪声强度比较小的情况,几种算法错分率在相差不大;而当噪声强度增加时,几种算法的错分率则有明显区别。对于本文的算法,错分率随噪声强度的增加而略有增加,而对于其他算法,则错分率增加幅度较大。

表 1 不同噪声下几种算法的错分率

Tab. 1 Misclassification rate with different noise level

噪声含量(%)	错分率(%)			
	GFGS 算法	FCM 算法	CGS 算法	ML 算法
5	5.7	5.5	5.8	6.8
7	5.8	7.1	5.9	8.9
9	6.0	9.7	6.2	11.8

为了考察这几个算法的分割能力和稳健性,本文采用重叠率(overlap metric)作为测度来进行算法鲁棒性的评估。重叠率是计算两个分割结果中同一组织的重叠程度。具体的说,如果考察 GFGS 算法在不同噪声下的分割结果中的白质与无噪声分割结果中的白质重叠率,记 A 为无噪声图像分割结果的白质像素的集合, B 为噪声情况下图像分割结果的白质像素的集合,那么两个分割结果的白质重叠率为

$$\frac{\text{card}(A \cap B)}{\text{card}(A \cup B)}$$

其中, $\text{card}(A)$ 是集合 A 元素的个数。如果重叠率高,则说明算法抗击噪声的能力强。表 2、表 3 和表 4 分别给出了 GFGS、FCM、CGS 和 ML 算法对图 2(a)进行分割的结果与其在不同噪声强度下的分割结果的白质、灰质和脑脊液的重叠率。对于 FCM、CGS 和 ML 算法,其白质、灰质和脑脊液的重叠率均是随噪声强度的增加而迅速减小,对于 GFGS 算法,则减小得慢。而对于相同噪声情况下,GFGS 算法的重叠率也是最高的,这反映出本算法良好的稳健性。

表 2 几种算法在不同噪声下白质重叠率
Tab. 2 Overlap metric of white matter with different noise level

噪声含量 (%)	白质重叠率 (%)			
	GFCS 算法	FCM 算法	CGS 算法	ML 算法
1	98.35	97.54	97.16	88.27
3	95.46	93.61	91.74	73.36
5	91.80	89.15	90.81	69.38
7	89.30	83.37	88.70	65.21
9	86.71	75.86	85.41	61.05

表 3 几种算法在不同噪声下灰质重叠率
Tab. 3 Overlap metric of gray matter with different noise level

噪声含量 (%)	灰质重叠率 (%)			
	GFCS 算法	FCM 算法	CGS 算法	ML 算法
1	97.74	96.88	96.37	87.24
3	93.98	91.62	87.54	77.32
5	89.31	86.13	87.45	72.03
7	86.46	79.34	85.24	65.00
9	83.60	69.80	80.80	58.10

表 4 几种算法在不同噪声下脑脊液重叠率
Tab. 4 Overlap metric of cerebrospinal fluid with different noise level

噪声含量 (%)	脑脊液重叠率 (%)			
	GFCS 算法	FCM 算法	CGS 算法	ML 算法
1	92.77	93.34	91.04	91.08
3	88.08	87.79	80.32	85.63
5	83.71	83.79	81.02	80.56
7	82.08	79.01	71.07	73.38
9	78.73	65.30	72.55	64.51

4 结论与讨论

由于广义模糊集已经成功地运用到图像处理的一些领域,为此本文首先建立了基于广义模糊集的 Gibbs 模型,然后以此为基础,建立了一种无监督的软分割算法,即广义模糊 Gibbs 分割算法。它是对经典 FCM 算法和基于 Gibbs 随机场的算法的补充

和扩展。该算法既能有效地抑止噪声,又能有效地解决部分容积效应。最后以仿真图像和真实临床 MR 图像为实验数据,对本算法与 FCM 算法、CGS 算法和 ML 算法进行了对比实验。实验表明,本文所提出的算法更稳健,分割质量优于其他算法。但是,本文的算法未能处理带有密度非均匀性伪影(intensity nonuniformity artifact, INU)^[8]的 MR 图像。对有 INU 伪影的 MR 图像进行有效的校正是得到正确分割结果的前提条件^[8]。正确地校正 INU 伪影是一个非常困难的问题,笔者将在下一步的工作中会继续研究这个问题。

参考文献 (References)

- Pham D L, Prince J L. Adaptive fuzzy segmentation of magnetic resonance images [J]. IEEE Transactions on Medical Imaging, 1999, 18(9): 737 ~ 752.
- Zhang Yong-yue, Michael B, Stephen S. Segmentation of brain images through a hidden Markov random field model and the expectation-maximization algorithm [J]. IEEE Transactions on Medical Imaging, 2001, 20(1): 45 ~ 57.
- Liew Alan Wee-Chang, Yan Hong. An adaptive spatial fuzzy clustering algorithm for 3-D MR image segmentation [J]. IEEE Transactions on Medical Imaging, 2003, 22(9): 1063 ~ 1075.
- Zhu Chao-zhe, Jiang Tian-zi. MultiContext fuzzy clustering for separation of brain tissues in magnetic resonance images [J]. NeuroImage, 2003, 18(3): 685 ~ 696.
- Ahmed M N, Yamany S M. 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.
- Prewer D, Kitchen L J. Soft image segmentation by weighted linked pyramid [J]. Pattern Recognition Letters, 2001, 22(2): 123 ~ 132.
- Caillol H, Pieczynski W, Hillion A. Estimation of fuzzy Gaussian mixture and unsupervised statistical image segmentation [J]. IEEE Transactions on Image Processing, 1997, 6(3): 425 ~ 440.
- Caillol H, Hillion A. Fuzzy random fields and unsupervised image segmentation [J]. IEEE Transactions on Geoscience and Remote Sensing, 1993, 31(4): 801 ~ 810.
- Salzenstein F, Pieczynski W. Parameter estimation in hidden fuzzy Markov random fields and images segmentation [J]. Graphical Models and Image Processing, 1997, 59(4): 205 ~ 220.
- CHEN Wu-fan, LU Xian-qing, CHEN Jian-jun, et al. A new algorithm of edge detection for color image: generalized fuzzy operator [J]. Science in China, 1995, 38(10): 1272 ~ 1280.