

# 带偏场校正和邻域约束的快速 MR 脑组织分割新方法

李 伟,陈武凡

(南方医科大学生物医学工程学院医学信息研究所,广东广州 510515)

**摘 要:** 由于部分容积效应(PVE)、图像的偏场(INU)和噪声的存在,脑组织磁共振(MR)图像自动准确的分割是一项具有挑战性的任务.本文提出了一个准确度高并快速鲁棒的二维(2D)和三维(3D)分割算法来将脑部 MR 图像分割为白质(WM)、灰质(GM)和脑脊液(CSF)三种主要的解剖组织类型.该算法在标准模糊 C-均值算法(FCM)的基础上提出了一个新的目标函数,包含偏场校正和邻域约束.在该算法中,采用参数模型表示 INU,并且一个类似马尔可夫随机场(MRF)的邻域约束来表示脑组织空间分布一致性信息.本文给出了该算法的模拟和真实脑 MR 图像的分割结果,同时与其它算法进行了比较.比较结果显示该算法具有较高的准确度和较快的收敛速度.

**关键词:** 图像分割; 偏场校正; 邻域约束; 模糊聚类; 脑组织

**中图分类号:** TP391 **文献标识码:** A **文章编号:** 0372-2112 (2010) 08-1784-07

## A New and Fast Segmentation Algorithm for MR Brain Images with Bias Field Correction and Neighborhood Constrains

LI Wei, CHEN Wu-fan

(Institute of Medical Information and Technology, School of Biomedical Engineering, Southern Medical University, Guangzhou, Guangdong 510515, China)

**Abstract:** Accurate and automatic brain tissue segmentation of magnetic resonance (MR) images is a challenging problem because of partial volume (PV) effects, intensity non-uniformity (INU, also known as bias field) and noise. We present an efficient and accurate, fully automatic two-dimensional (2D) and three-dimensional (3D) algorithm for segmenting brain MR images into anatomical major tissue classes such as white matter (WM), gray matter (GM) and cerebrospinal fluid (CSF). Our algorithm is formulated by proposing an objective function based on standard FCM algorithm with bias field correction and neighborhood constrain. In our algorithm, a parameterized model is adopted to express the INU and a neighbor constrain similar to Markov random field (MRF) is proposed to express spatial consistency of brain tissue. Experimental results with both synthetic and real data are included, as well as comparisons of the performance of our algorithm with that of other published methods. The validation of the algorithm shows good accuracy and fast convergence.

**Key words:** image segmentation; bias field correction; neighborhood constrains; fuzzy-clustering; brain tissues

### 1 引言

在脑部医学图像的分析中,脑组织的形态学分割是一个必要的前提和步骤.脑内组织的二维(2D)和三维(3D)分割结果可用来完成组织形态显示、位置和体积的量化估计、形态学比较、病态组织检测(如肿瘤的分割、多发性硬化症的分割)、术后评价等,在脑部疾病的分析诊断中具有重要作用.脑部分割方法可粗略分为硬分割方法和软分割方法两类.由于部分容积效应(PVE)、图像的偏场(INU)和噪声的存在,脑组织磁共振(MR)图像的硬分割方法,即在分割过程中,将图像像素唯一地划分为某一种组织类型( $\{0,1\}$ ),是困难和不准确的.

因此,为了克服硬分割方法的缺点,软分割方法就被提出了.软分割方法就是先将每一像素以大小不同的隶属度划分给几种组织类型,然后根据某一优化准则,再将每一像素唯一地划分为某一种组织类别,获得最终的分割结果.像素隶属度(在 $[0,1]$ 区间取值)的值反映了图像像素可能受到了噪声、PVE 和 INU 影响的大小,同时将分割目标函数解的空间细化,分割结果得到进一步优化和改进.本文的分割算法就是基于软分割方法的.

脑组织分割就是要将脑内组织划分为灰质(GM)、白质(WM)和脑脊液(CSF)三种主要组织类型.快速、精确和稳健的脑组织 MR 图像分割是基于形态学比较的脑部疾病分析的前提,分割结果的准确度对后续分析

和诊断的结果具有决定性影响,如阿尔茨海默病(Alzheimer's disease)和精神分裂症<sup>[1,2]</sup>.脑部 MR 图像的人工分割非常费时,受主观因素影响大,其分割结果不具有良好的重复性.因此,需要脑组织的自动分割方法来完成 MR 图像的自动分割.但脑组织形态结构为复杂的回旋结构,加之噪声、PVE 和 INU 的存在,其组织像素的分割具有较强的模糊性和不确定性.目前,自动高效的脑组织分割方法的设计仍是一大挑战.脑组织的自动分割方法有基于分类的方法(如统计分类、聚类),基于区域的分割方法(如区域生长、分水岭和分离与融合),动态模型的方法(如 Snake, level set),混合方法(如基于图谱引导的方法、神经网络、图论优化)等<sup>[3,4]</sup>.其中,模糊聚类<sup>[5]</sup>的方法适合解决灰度图像中存在的模糊和不确定性的问题,且算法速度快,非常适合脑组织的快速分割.虽然已存在一些模糊聚类的方法应用于 MR 脑部图像的分割<sup>[6-8]</sup>,但由于这些算法需要对 MR 数据取对数(不符合高斯噪声观察模型的假设前提)、或采用非参数的偏场模型,或未利用脑组织空间分布连续的先验约束模型,算法存在计算量大,参数估计复杂,需要解大型线性或非线性方程组,分割结果对噪声敏感,算法对初始化敏感的缺点,或不适应有偏场的 MR 图像分割.

我们提出了一种基于像素灰度值的改进 FCM 自适应快速自动分割算法,来完成对含有偏场的脑部 MR 图像进行优质分割.在该算法中,给出了一种新的分割目标函数,采用参数模型来近似偏场和类似马尔可夫随机场先验的邻域约束来模拟脑组织分布的空间一致性.该算法不需要对 MR 数据取对数或滤波等预处理,在目标函数递归优化的过程中,利用偏场参数模型和邻域约束来同时完成像素的分割和图像偏场的估计.由于算法利用分割结果估计偏场,使得偏场的估计更加合理和准确.同时参数模型减少了需要估计参数的数目,提高了算法分割结果的准确度和分割的速度.模拟和临床脑部 MR 图像的分割实验结果表明,我们的算法对初始值不敏感,对噪声有较强的抑制,有效地克服了偏场的影响,分割结果准确度高,速度快.我们的算法在三维 MR 图像的自动分割实验中取得了满意的分割速度和准确度.

## 2 算法

### 2.1 新算法的目标函数

标准的 FCM 算法是根据图像中  $N$  个像素的灰度值、聚类中心  $\mathbf{V}$  和像素对每个聚类中心的隶属度函数  $U$ ,对目标函数进行迭代优化.目标函数为:

$$J_{\text{FCM}}(U, \mathbf{V}) = \sum_{j \in \Omega} \sum_{k=1}^C u_{jk}^q \|y_j - v_k\|^2 \quad (1)$$

其中: $\Omega$  是图像像素的位置空间集,其势  $|\Omega| = N$ ;  $C$  为聚类的类数且  $C \geq 2$ ;  $q$  为模糊加权指数且  $q > 1$ ;  $\mathbf{U} = \{u_{jk}\}$  为模糊隶属度函数矩阵,其中  $u_{jk}$  为像素  $j$  属于第  $k$  类的隶属度,且  $\sum_{k=1}^C u_{jk} = 1 \forall j \in \{1 \cdots N\}, k \in \{1 \cdots C\}$ ;  $\mathbf{V} = \{v_k\}_{k=1}^C = \{v_1, v_2, \cdots, v_C\}$  为  $C$  个聚类中心的集合;  $y_j$  为像素  $j$  的灰度值;  $\|\cdot\|$  为范数,通常是欧氏范数.当图像像素灰度值在靠近某一类的聚类中心,其该类的隶属度被赋予高的值,在其灰度值在远离某一类的聚类中心,其该类的隶属度被赋予低的值.通过优化调整各类的聚类中心,FCM 目标函数(1)被最小化<sup>[9]</sup>,获得模糊分割的结果(每个像素的隶属度函数  $U$  值).模糊分割的结果可通过最大隶属度准则转化为最终的硬分割结果,即图像像素根据其最大隶属度值被唯一地划分为相应的某一类,获得最终的分割结果.

在脑部 MR 图像的基于像素灰度值的分割中,MR 图像的偏场效应,即在 MR 图像采集过程中,因射频场的不均匀性引起的图像灰度不均匀,严重影响 MR 图像分割结果的准确性<sup>[10-12]</sup>.因此,必须对 MR 图像进行偏场估计和校正.由于偏场是低频缓慢变化的场,我们将偏场效应看作是对聚类中心的一种低频场调制的结果.即在图像空间中,每类的聚类中心随着每个像素位置处的偏场幅值的大小而变化.根据偏场的特性和减少偏场估计计算复杂度的要求,我们采用参数模型来表示偏场,从而将偏场的估计,变成对模型参数的估计,提高了算法的速度和稳定性.在我们的算法中,我们采用多项式函数模型或三次 B 样条函数模型来近似模拟偏场  $B$ .

由于 MR 图像噪声的存在,在分割出来的类中产生粗粒和碎片,这是不符合组织分布先验知识的,亦是不准确的.由于脑部组织的空间分布是连续的,因此,我们将这种连续的先验信息,以一种类似 Gibbs 场先验的方式结合进分割目标函数,利用像素邻域的信息来约束分割的结果,达到抑制噪声对分割结果的不利影响.在模糊聚类算法中,每一像素根据其灰度值都被赋予一个模糊隶属度矢量,来表达其属于不同的类的程度.当邻域像素与中心像素的模糊隶属度矢量差的模小时,它们属于同类的概率将大,相反当邻域像素与中心像素的模糊隶属度矢量差的模大时,它们属于同类的概率将小.因此,在以下式(2)中加入第二项来用邻域的分类结果约束当前中心像素的分类结果.由于该项的作用使得当前中心像素的模糊隶属度矢量的取值尽量靠近邻域像素的模糊隶属度矢量值,从而达到符合组织分布连续先验的优化分割结果,即抑制了噪声的不利影响.利用像素隶属度函数的矢量值,结合其邻域的素隶属度函数矢量场的信息来软约束隶属度函

数的取值,这与马尔可夫随机场(MRF)模型灰度值标量值的硬约束又有不同,隶属度函数的矢量场软约束进一步提高了优化的连续性和分割算法的稳定性.我们的算法不需要像利用马尔可夫随机场(MRF)统计分类方法中那样的复杂的参数估计(各类的均值、方差和各类的权值比例),或由于参数的选择不合适,导致图像细节的丢失<sup>[13,14]</sup>.

为了同时进行偏场校正和抑制噪声对分割结果的影响,我们提出了以下新的聚类目标函数:

$$J = \sum_{j \in \Omega} \sum_{k=1}^C u_{jk}^q \left\| y_j - \sum_l c_l \phi_l(y_j) v_k \right\|^2 + \lambda_1 \sum_{j \in \Omega} \sum_{k=1}^C \sum_{i \in N_j} \frac{(u_{jk} - u_{ik})^2}{|N_j|} \quad (2)$$

其中:  $\sum_l c_l \phi_l(y_j)$  为参数模型表达的 MR 图像的偏场  $B$ ,  $l$  为参数模型的基函数的个数,  $\phi_l(y_j)$  为象素  $j$  处的基函数的值,  $c_l$  为待估计的模型参数,即基函数的系数;  $N_j$  为象素  $j$  的邻域;  $|N_j|$  为象素  $j$  邻域的势,即象素  $j$  邻域象素的数目;  $\lambda_1$  为邻域约束的权重系数,在我们的递归优化算法中是不变的.

比较目标函数(1)和目标函数(2),不同之处在于,除了增加了偏场  $B$  外,还增加了象素模糊隶属度矢量邻域约束项,即目标函数(2)中的第二项.在目标函数(2)中,采用一个连续的参数模型偏场与聚类中心相乘的方式来建模由于 MR 图像偏场而导致组织象素灰度值的变化.目标函数(2)中的第二项对象素模糊隶属度矢量函数增加了邻域的空间位置约束,这样使得模糊隶属度矢量函数的取值趋向于空间连续变化,而不是突变,从而有效的克服了 MR 图像噪声对聚类分割结果的不利影响.  $\lambda_1$  值越大,这种空间位置约束就越强.

## 2.2 参数的估计

式(2)目标函数  $J$  的最小化类似于标准的 FCM 算法,采用了最小化必要条件之间交替递归优化的策略(iterative alternating optimization)<sup>[9]</sup>.对目标函数(2)的最小化通过在 3 个最小化必要条件之间交替递归优化.在实际应用中,当前后两次递归获得的模糊隶属度矢量函数变化小于某个很小的阈值时,就认为算法收敛.就我们的多次分割实验的经验,本文的递归优化算法也总是收敛的.对目标函数  $J$  分别对  $u_{jk}$ 、 $v_k$  和  $c_l$  取偏导数,并置各自偏导数等于零,从而推导出使得目标函数  $J$  取得局部极值的必要但非充分条件.

### 2.2.1 隶属度函数估计

式(2)的约束优化用拉格朗日乘子

$$L = \sum_{j \in \Omega} \sum_{k=1}^C u_{jk}^q \left\| y_j - \sum_l c_l \phi_l(y_j) v_k \right\|^2 + \lambda_1 \sum_{j \in \Omega} \sum_{k=1}^C \sum_{i \in N_j} \frac{(u_{jk} - u_{ik})^2}{|N_j|} + \lambda_2 \left( 1 - \sum_{k=1}^C u_{jk} \right) \quad (3)$$

来解决.对  $L$  取  $u_{jk}$  偏导数,并置偏导数等于零,即

$$\left[ \frac{\partial L}{\partial u_{jk}} = qu_{jk}^{q-1} D_{jk} + \lambda_1 \sum_{i \in N_j} \frac{2(u_{jk} - u_{ik})}{|N_j|} - \lambda_2 \right]_{u_{jk} = u_{jk}^*} = 0 \quad (4)$$

其中:  $D_{jk} = y_j - \sum_l c_l \phi_l(y_j) v_k$ .

为了以下表达方便,我们在这令  $q = 2$ . 解式(4)得

$$u_{jk} \text{ 的估计为 } u_{jk}^* = \frac{\frac{\lambda_2}{2} + T_1}{D_{jk} + \lambda_1} \quad (5)$$

$$\text{其中: } T_1 = \frac{\lambda_1}{|N_j|} \sum_{i \in N_j} u_{ik}, \lambda_2 = \frac{1 - \sum_{k=1}^C \frac{T_1}{D_{jk} + \lambda_1}}{\sum_{k=1}^C \frac{1}{D_{jk} + \lambda_1}}.$$

### 2.2.2 聚类中心的估计

在式(3)中我们选取欧氏范数.对  $L$  取  $v_k$  的偏导数,并置偏导数等于零,即

$$\left[ \frac{\partial L}{\partial v_k} = \sum_{j \in \Omega} u_{jk}^2 (y_j - \sum_l c_l \phi_l(y_j) v_k) (\sum_l c_l \phi_l(y_j)) \right]_{v_k = v_k^*} = 0 \quad (6)$$

解式(6)得  $v_k$  的估计为

$$v_k^* = \frac{\sum_{j \in \Omega} u_{jk}^2 (\sum_l c_l \phi_l(y_j)) y_j}{\sum_{j \in \Omega} u_{jk}^2 (\sum_l c_l \phi_l(y_j))^2} \quad (7)$$

### 2.2.3 偏场 $B$ 的估计

同样地,对  $L$  取  $c_l$  的偏导数,并置偏导数等于零,即

$$\left[ \frac{\partial L}{\partial c_l} = \sum_{j \in \Omega} \sum_{k=1}^C u_{jk}^2 (y_j - \sum_l c_l \phi_l(y_j) v_k) (\phi_l(y_j)) \right]_{c_l = c_l^*} = 0, \forall k \quad (8)$$

解方程组(8)得  $c_l$  的估计.为了表达明确,我们采用矩阵地表达形式,即

$$\begin{bmatrix} c_1^* \\ c_2^* \\ \vdots \end{bmatrix} = (A^T M A)^{-1} A^T W Y \quad (9)$$

$$\text{其中: } A = \begin{bmatrix} \phi_1(y_1) & \phi_2(y_1) & \phi_3(y_1) & \cdots \\ \phi_1(y_2) & \phi_2(y_2) & \phi_3(y_2) & \cdots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix}$$

$$M = \text{diag}(\sum_{k=1}^C u_{jk}^2 v_k^2), W = \text{diag}(\sum_{k=1}^C u_{jk}^2 v_k), Y = \begin{bmatrix} y_1 \\ y_2 \\ \vdots \end{bmatrix}.$$

在方程组(8)中,方程个数大于估计参数  $c_l$  的个数,所以方程组(8)是过定的.因此方程组(8)的解是在最小平方意义下的最优解.由于我们采用了低频缓变的连续参数模型来近似 MR 图像中的真实偏场  $B$ ,且在算法递归的每一步获得了 MR 图像的相应分割结果,因此我们

利用像素分割结果的抽样来快速估计偏场  $B$  的参数  $c_l$ , 这样估计偏场准确又快速, 进一步提高了算法的速度.

### 2.3 算法的初始化

我们的算法只需要简单的初始化就可进行 2D 和 3D 的 MR 图像的分割. 初始化步骤如下: (1) 正则化图像像素灰度值到  $[0, 1]$  区间. (2) 根据具体的问题人工选择分割的聚类数  $C$ , 在我们的脑部 MR 图像的分割实验中,  $C = 3$ ; (3) 选择邻域形式, 邻域形式可以根据需要选择各种形式. 在我们以下的试验中对于 2D 的情况选择 4 邻域或 8 邻域, 而 3D 的情况选择 6 邻域或 26 邻域; (4) 设置初始聚类中心  $V^0 = \{v_k^0\}_{k=1}^C$ , 这个聚类中心可以随机选取. 在我们的实验中聚类中心设置为  $V^0 = \{v_1^0, v_2^0, \dots, v_C^0\} = \left\{\frac{1}{1+C}, \frac{2}{1+C}, \dots, \frac{C}{1+C}\right\}$ . (5) 选择偏场模型基函数形式和阶数, 可以选择多项式和样条基函数. 试验中, 我们选择 3 或 4 次多项式基函数. 偏场参数初始值可以根据其它方法 (如用低阶多项式拟合低频滤波后的 MR 图像) 估计得到参数来设置, 也可以简单设置偏场为零, 即设置偏场初始参数  $\{c_1^0, c_2^0, \dots, c_l^0\} = \{1, 0, \dots, 0\}$ . (6) 初始化隶属度函数矩阵  $U^0 = \{u_{jk}^0\} \forall j, k$ , 计算每个像素的灰度值与初始各聚类中心的欧氏距离  $d_{jk} = (y_j - v_k^0)^2 \forall j, k$ , 然后归一化该距离得到初始隶属度函数矩阵.

### 2.4 递归优化算法

我们提出的采用参数模型偏场校正和邻域约束的新算法的步骤如下:

(1) 初始化算法: 根据 2.3 节初始化算法参数.

(2) 设置最大迭代次数  $iter\_max$  和一个小的标量值  $\epsilon > 0$ .

(3) 令迭代次数  $iter = 0$ .

(4) 更新隶属度函数矩阵  $U$ : 用式(5)计算新的隶属度函数矩阵  $U = \{u_{jk}\}$ .

(5) 更新聚类中心  $V$ : 用式(7)计算新的聚类中心  $V = \{v_k\}_{k=1}^C$ .

(6) 更新偏场模型参数: 用式(9)计算新的偏场模型参数  $\{c_l\}$ .

(7) 如果  $\frac{U_{new} - U_{old}}{U_{old}} \leq \epsilon$  或  $iter > iter\_max$ , 终止迭代; 否则,  $iter = iter + 1$ , 重复(4) ~ (6).

## 3 算法分割实验和验证

### 3.1 实验数据和量化比较测度

为了验证本文算法的有效性, 我们将本文的算法用于两组 3D 脑部 MR 图像数据集的分割实验中. 数据集(a): 为来自于 BrainWeb 的 3D 脑部 MR 仿真图像, 共

8 套. 它们是分别含有 1% ~ 9% 噪声和 20% ~ 40% 偏场的 T1 权重 MR 图像, 3D 数据大小为  $181 \times 217 \times 181$  像素, 像素大小为  $1 \times 1 \times 1$  mm, 具体参见表 1; 数据集(b): 为真实的临床 3D 脑部 MR 图像, 共 7 套. 该组数据为对比剂增强 T1 权重 MR 图像. 3D 数据大小为  $256 \times 256 \times 124$  像素, 像素大小为  $0.9375 \times 0.9375 \times 1.0$  mm, 图像数据含有严重的偏场, 偏场幅度达到 100%.

由于是对脑组织分割, 我们首先要对获得的 MR 脑部图像数据进行去除非脑组织的预处理, 即去除颅骨、皮肤和眼球等组织. 利用文献[15]的 3D 自动算法快速提取脑组织, 提取的脑组织的结果如图 1 所示. 图 1 显示了其中一个 3D 临床 MR 脑部数据去除非脑组织前后的横断面、矢状面和冠状面, 从左向右, 依次为原图像、提取出的脑组织图像和提取脑组织图像的掩模.




图1 脑组织的3D提取

将本文算法与标准 FCM 算法(FCM)<sup>[5]</sup>及高斯马尔可夫-期望最大化(EM)分割算法(GMRF)<sup>[13]</sup>的分割结果进行比较. 为了量化分析和比较分割结果, 我们采用 Dice 测度来评价分割算法的结果与标准分割结果 (金标准) 的像素空间覆盖率<sup>[16]</sup>, Dice 测度在区间  $[0, 1]$  取值, 值越大则一致程度越好, 即分割结果越准确. Dice 测度的定义为:  $Dice(S_1, S_2) = \frac{2 * |S_1 \cap S_2|}{|S_1| + |S_2|}$ , 其中  $S_1$ ,  $S_2$  为集合. 在下面的试验中,  $S_1$  表示算法的分割结果标记集合,  $S_2$  表示标准分割结果的标记集合,  $S_1 \cap S_2$  表示两个集合的交集,  $|\cdot|$  表示集合的势. 同时为了评价

分割结果的差异性,我们采用了假阴性和假阳性测度.假阴性测度表示属于某类组织的像素而被算法遗漏的像素数,假阳性测度表示不属于某类组织的像素而被算法错误地分割为该组织的像素数.

算法在 Windows XP 平台下由 Matlab7.0 编程实现.处理器为 Intel Pentium(R) D 2.80GHz 双核 CPU,内存为 1.0GB.

### 3.2 实验参数的选择

本文算法需要设置的参数为邻域约束项权重  $\lambda_1$ 、邻域的形式和大小  $N_j$ (对每个象素  $j$  邻域是一样的)和偏场模型的基函数形式、阶数和相应基函数的个数  $l$ .在实验中, $\lambda_1$  参数选择正比于待分割图像的信噪比,一般取 0.02;分割图像为 2D 时, $N_j$  选取 4-邻域或 8-邻域,基函数选取 3 阶或 4 阶多项式模型,其个数  $l$  分别为 10 或 15.分割图像为 3D 时, $N_j$  选取 6-邻域,基函数选取 3 阶多项式模型其个数  $l$  为 20.

### 3.3 实验结果 3.3.1 2D 合成图像

图 2(a)为合成的测试图像,该测试图像用两种灰度值 80 和 140 代表两种组织,噪声为加性高斯噪声,其均值为零,标准方差为 20.同时其含有图 2(c)所示的偏场,幅度为 30%.该实验主要用于评估算法对偏场估计结果的准确度.将本文的分割算法应用于图 2(a),获得了图 2(b)的正确分割结果和图 2(d)算法估计的偏场结果.从图中可以看出偏场的估计结果是基本准确的.




图2 测试图像的分割与偏场估计结果

### 3.3.2 BrainWeb 仿真 MR 图像

图 3 显示了本文算法和标准 FCM 算法 (FCM) 及高斯马尔可夫分割算法 (GMRF) 的 2D 分割结果的比较.图 3(a) 来自于 BrainWeb 的含 9% 噪声和 40% 偏场的第 70 层仿真 T1 权重的 MR 脑图像.将本文算法的分割结果、FCM 和 GMRF 分割结果与标准分割结果比较,可以看出标准 FCM 算法的分割结果对噪声敏感,分割出的同种组织标记中有细碎的其他组织标记的颗粒,分割

结果差.而 GMRF 和本文的算法对噪声有良好的抑制能力,分割出的同种组织标记中没有细碎的其他组织标记的颗粒,但 GMRF 算法由于没有进行偏场校正,图像中偏场严重的区域存在分割错误,如图 3(d) 的左上角,部分白质被分割为灰质.比较本文算法和 GMRF 算法的分割结果,可以看出本文算法的分割结果算法保持了较多的图像细节,更接近于标准分割结果,同时由于具有偏场校正的能力,在图像偏场严重的区域,其分割结果也是正确的.




图3 MR仿真图像的2D分割结果比较

为了定量地比较三种分割算法的结果,利用 BrainWeb 提供的标准分割结果,我们计算出三种算法在不同迭代次数的分割结果 Dice 测度值,用来比较它们的迭代收敛性能和分割结果的准确性.图 4 显示了三种分割算法分割图 3(a) 的迭代收敛过程,纵坐标为每次迭代后的 Dice 测度值,横坐标为迭代次数.从图 4 中可以看出,本文的分割算法收敛递归次数与 FCM 算法相当,但少于 GMRF 算法(GMRF 算法由一个 C 均值算法初始化).同时,我们的算法分割结果的 Dice 测度值最大,因此分割结果较 FCM 和 GMRF 算法要好,分割结果也最准确.




图4 算法性能的比较

表 1 为我们的算法分割 8 套含有不同程度噪声和偏场的 3D 仿真 T1 权重的 MR 图像的结果.由于 3D 数据量太大,我们选取了所有包含大脑的断层作为分割的 3D 数据,数据大小为  $181 \times 217 \times 130$ .图 5 显示了其中一个 3D 仿真 MR 数据的横断面、矢状面和冠状面的分割结果,从左向右依次为原图像、分割结果和估计的偏场.表 1 显示本文的算法在噪声和偏场分别为 3% 和 20% 时,分割结果的 Dice 值最大,平均为 0.945;在噪声和偏场分别为 9% 和 40% 时,Dice 值最小,平均为 0.909.各类组织的假阴性和假阳性的像素数也随着噪声和偏场增大而相应变大.算法的平均时间为 269.9 秒,算法速度较快.

3.3.3 临床真实 MR 图像

图 6 显示了本文算法应用于第二组数据集的其中一套临床 T1 权重 MR 脑图像不同断层的 3D 分割结果,从左向右依次为原图像、分割结果和估计的偏场.由于该套图像含有严重的偏场,导致它的灰像素灰度直方

图有严重的重叠.我们利用本文算法估计的图像偏场,对原图进行偏场校正.校正后的图像灰度直方图和原图像的灰度直方图如图 7 所示.从图 7 中可以看到,校正后的图像的直方图分布接近混合高斯分布,且彼此

表 1 BrainWeb 仿真 MR 图像 3D 分割结果

数据序号	图像模式	噪声	偏场	组织类型	标准结果(像素)	算法结果(像素)	Dice	假阴性(像素)	假阳性(像素)	算法时间(秒)
1	T1	3%	20%	白质	674062	705110	0.946	21981	53029	265.43
				灰质	868418	844740	0.937	65755	42077	
				脑脊液	337297	329927	0.951	20096	12726	
2	T1	5%	20%	白质	674062	700808	0.940	27890	54636	263.57
				灰质	868418	846244	0.930	70951	48777	
				脑脊液	337297	332725	0.944	20889	16317	
3	T1	7%	20%	白质	674062	709801	0.931	29641	65380	268.63
				灰质	868418	834335	0.919	85946	51881	
				脑脊液	337297	335641	0.936	22244	20588	
4	T1	9%	20%	白质	674062	709300	0.920	37898	73136	270.13
				灰质	868418	829411	0.905	100486	61479	
				脑脊液	337297	341066	0.925	23587	27356	
5	T1	3%	40%	白质	674062	732219	0.930	20354	78511	269.35
				灰质	868418	818634	0.921	91648	41864	
				脑脊液	337297	328924	0.948	21514	13141	
6	T1	5%	40%	白质	674062	729033	0.928	23225	78196	272.41
				灰质	868418	818438	0.917	94987	45007	
				脑脊液	337297	332306	0.942	21783	16792	
7	T1	7%	40%	白质	674062	729327	0.921	28031	83296	276.28
				灰质	868418	812591	0.908	105627	49800	
				脑脊液	337297	337859	0.935	21775	22337	
8	T1	9%	40%	白质	674062	731015	0.910	35024	91977	273.69
				灰质	868418	802792	0.893	122504	56875	
				脑脊液	337297	345970	0.923	21871	30544	




图5 仿真MR图像3D分割




图6 临床真实MR图像3D分割

间的距离较远,重叠较少.本文算法估计的图 6(b)的偏场的 3D 显示如图 8 所示, $X-Y$  坐标平面为 2D 图像平面, $Z$  坐标为偏场的值.从图 6(b)矢状面偏场幅值为  $0.3 \sim 0.8$ ,偏场是很大的.6(b)偏场校正前后的 MR 图像的比较如图 9 所示.因此,本文的算法可以在大偏场存在的情况下(偏场幅度远大于 30% 临床要求,这更符合临床上一些图像的实际情况),对 3D 脑部 MR 图像进




图7 偏场校正前后的直方图





图8 本文算法估计的图6(b)的偏场3D显



(a) 未校正的图6(b) (b) 校正后的图6(b)  
图9 偏场校正前后的图6(b)

#### 4 讨论和结论

本文通过构造一种新的模糊聚类分割目标函数,提出了一种采用参数偏场校正模型和邻域约束模型的 FCM 快速 MRI 脑组织分割新方法.实验结果表明,新算法的图像分割性能优于标准 FCM 方法和采用高斯马尔可夫随机场模型和期望最大化算法(EM)的 GMRF 方法.新算法同时具有 FCM 方法速度快和 MRF 随机场模型准确度和一致性较高的特点.算法基本满足对三维 MR 图像快速分割和优质分割的要求.同时本文的算法可以对偏场幅度很大的 MR 图像的快速和优质分割.

本文的算法只采用了像素灰度值的一维特征空间和欧氏距离作为改进的 FCM 算法中像素灰度值到聚类中心的距离测度,但可以很容易的扩展到多维特征空间(如 T1、T2 和 PD 权重 MR 图像)和它的合适的距离测度(如 Gustafson-Kessel 距离测度).

表 1 显示本文算法在强噪声和大偏场(如 9% 噪声和 40% 偏场)下,分割结果的 Dice 的测度值有所降低,但仍达到 0.909.这是由于噪声和偏场的增大导致同种组织像素灰度值变化较大,像素的组织隶属性更加模糊和不确定.虽然我们的算法具有空间约束,但这种像素邻域内的空间约束是一种局部约束,在图像噪声和偏场过大时,其作用有限.因此,在后续算法改进中,将概率图谱等约束加入目标函数模型中,以期获得性能更稳健的算法.

行正确的分割和偏场估计.该算法不同于已有文献[12]的偏场逐层分割和偏场校正的方法,也不同于文献[17]的分层常数的偏场校正方法.我们方法的偏场模型表达的偏场形式更加丰富,假设条件仅是偏场在图像 3D 空间连续缓慢变化,而不是层内缓慢变化,层间为分层常数的特殊情况.

#### 作者简介:



李 伟 男,1975 年 5 月出生于江西省南昌市.现为南方医科大学医学图像信息研究所讲师、博士.主要研究方向为医学图像分析.

E-mail: shibazis@163.com



陈武凡 男,1949 年 10 月出生于湖南汨罗.现为南方医科大学教授、博士生导师,973 首席科学家,中国生物医学工程学会常务理事,中国图像图形学会副理事长.主要研究方向为模式识别,医学图像处理,医学图像重建等.

E-mail: chenwf@fimmu.com

#### 参考文献:

- [1] Guttman C, Benson R, Warfield S K, et al. White matter abnormalities in mobility-impaired older persons[J]. Neurology, 2000, 54(6): 1277 - 1283.
- [2] Smith S, Zhang Y, Jenkinson M, et al. Accurate, robust, and automated longitudinal and cross-sectional brain change analysis [J]. NeuroImage, 2002, 17(1): 479 - 489.
- [3] Meritxell Bach Cuadra, Leila Cammoun, Torsten Butz, et al. Comparison and validation of tissue modelization and statistical classification methods in T1-weighted MR brain images[J]. IEEE Transactions on Medical Imaging, 2005, 24(12): 1548 - 1565.

(下转第 1797 页)



- variation models for variable lighting face recognition [J]. IEEE Transactions on PAMI, 2006, 28(9): 1519 – 1524.
- [5] Georgiades A, Belhumeur P, Kriegman D. From few to many: Illumination cone models for face recognition under variable lighting and pose [J]. IEEE Transactions on PAMI, 2001, 23(6): 643 – 660.
- [6] Wang H, Li S Z, Wang Y. Generalized Quotient Image [A]. Proceedings of IEEE Conference on CVPR [C]. Washington, DC, 2004. 498 – 505.
- [7] Shim H J, Luo J, Chen T H. A Subspace Model-Based Approach to Face Relighting Under Unknown Lighting and Poses [J]. IEEE Transactions on Image Processing, 2008, 17(8): 1331 – 1341.
- [8] Xie X, Lam K M. Face recognition under varying illumination based on a 2D face shape model [J]. Pattern Recognition, 2005, 38(2): 221 – 230.
- [9] Coleman T F, Li Y. A Reflective Newton Method for Minimizing a Quadratic Function Subject to Bounds on some of the Variables [J]. SIAM Journal on Optimization, 1996, 6(4): 1040 – 1058.
- [10] Sim T, Baker S, Bsat M. The CMU pose, illumination, and expression database [J]. IEEE Transactions on PAMI, 2003, 25(12): 1615 – 1618.

## 作者简介:



谢晓华 男, 1981 年 10 月出生于广东. 2007 年 7 月毕业于中山大学, 获信息计算科学专业硕士学位. 现为中山大学数学与计算科学学院博士研究生, 研究方向为图像处理与模式识别.

E-mail: sysuxiexh@gmail.com



赖剑煌(通讯作者) 男, 1964 年生, 中山大学信息科学与技术学院教授、博士生导师, 副院长. 现任广东省图象图形学会理事长, 中国图象图形学会常务理事. 1989 年获中山大学应用数学硕士学位, 1999 年获中山大学基础数学博士学位. 主要研究方向为数字图像处理、模式识别、小波分析及其应用.

E-mail: stsljh@mail.sysu.edu.cn

(上接第 1790 页)

- [4] Liew A W C, Yan H. Current methods in the automatic tissue segmentation of 3D magnetic resonance brain images[J]. Current Medical Imaging Reviews, 2006, 2(1): 91 – 103.
- [5] Bezdek, J. Pattern recognition with fuzzy objective function algorithms[M]. New York: Plenum Press, 1981.
- [6] Dzung L Pham, Jerry L Prince. Adaptive fuzzy segmentation of magnetic resonance images[J]. IEEE Transactions on Medical Imaging, 1999, 18(9): 737 – 752.
- [7] Mohamed N Ahmed, Sameh M Yamany, Nevin Mohamed, 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.
- [8] 冯衍秋, 陈武凡, 梁斌, 林亚忠. 基于 Gibbs 随机场与模糊 C 均值聚类的图像分割新算法[J]. 电子学报, 2004, 32(4): 645 – 647.
- Feng Yan-qi, Chen Wu-fan, Liang Bin, et al. A new algorithm for Image segmentation based on Gibbs random field and fuzzy C-Means clustering [J]. Acta Electronica Sinica, 2004, 32(4): 645 – 647. (in Chinese)
- [9] Bezdek J. A convergence theorem for the fuzzy ISODATA clustering algorithms[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1980, 2(1): 1 – 8.
- [10] Styner M, Brechbuhler C, Szckely G. Parametric estimate of intensity inhomogeneities applied to MRI[J]. IEEE Transactions on Medical Imaging, 2000, 19(3): 153 – 165.
- [11] Sled J G, Zijdenbos A P, Evans A C. A nonparametric method for automatic correction of intensity nonuniformity in MRI data[J]. IEEE Transactions on Medical Imaging, 1998, 17(1): 87 – 97.
- [12] Wells W M I, Grimson W E L, Kikinis R. Adaptive segmentation of MRI data[J]. IEEE Transactions on Medical Imaging, 1996, 15(4): 429 – 442.
- [13] Zhang Yong-yue, Michael Brady, Stephen Smith. Segmentation of brain MR images through a hidden Markov random field model and the expectation-maximization algorithm[J]. IEEE Transactions on Medical Imaging, 2001, 20(1): 45 – 57.
- [14] Sanjay-Gopal S, Thomas J Hebert. Bayesian pixel classification using spatially variant finite mixtures and the generalized EM algorithm[J]. IEEE Transactions on Image Processing, 1998, 7(7): 1014 – 1028.
- [15] SM Smith. Fast robust automated brain extraction [J]. Hum Brain Mapping, 2002, 17(3): 143 – 155.
- [16] Shattuck D W, Sandor-Leahy S R, Schaper K A, et al. Magnetic resonance image tissue classification using a partial volume model[J]. NeuroImage, 2001, 13(5): 856 – 876.
- [17] Leemput K V, Maes F, Vandermeulen D, et al. Automated model-based bias field correction of MR images of the brain [J]. IEEE Transactions on Medical Imaging, 1999, 18(10): 885 – 896.