

基于参数化互信息的脑 MR 图像分割与 偏移场矫正模型及快速算法

詹天明¹, 张 军², 韦志辉^{1,2}, 肖 亮¹, 孙玉宝¹

(1. 南京理工大学计算机科学与技术学院, 江苏南京 210094; 2. 南京理工大学理学院, 江苏南京 210094)

摘 要: 脑核磁共振(Magnetic Resonance 简称 MR)图像中存在灰度不均匀现象使得传统方法很难得到理想的分割与偏移场矫正结果. 针对这一问题, 本文首先提出 Legendre 基函数拟合偏移场下的参数化互信息度量, 建立脑 MR 图像的分割与偏移场矫正的变分模型. 最后, 给出了基于分裂 Bregman 迭代方法的快速分割与偏移场矫正算法. 实验结果表明本文方法可以得到较准确的分割和偏移场矫正结果, 而且具有较快的收敛速度.

关键词: 脑核磁共振图像; 分割; 偏移场矫正; 分裂 Bregman 迭代

中图分类号: TP391 **文献标识码:** A **文章编号:** 0372-2112 (2011) 12-2807-06

Brain Image Segmentation and Bias Field Correction Model Based on Parametric Mutual Information and Fast Algorithm

ZHAN Tian-ming¹, ZHANG Jun², WEI Zhi-hui^{1,2}, XIAO Liang¹, SUN Yu-bao¹

(1. School of Computer Science & Technology, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China;

2. School of Science, Nanjing University of Science and Technology, Nanjing, Jiangsu 210094, China)

Abstract: Due to the intensity inhomogeneous in brain MR image, it is difficult for the traditional methods to obtain accurate segmentation results. In this paper, by using the bias fitting field with Legendre basis, a new parameterize mutual information metric is firstly proposed, and a unified variational model is proposed for the optimizing of segmentation and bias correction. Finally, we present a fast algorithm based on split Bregman iteration methods. Comparative results demonstrate that our method can obtain more accurate segmentation and bias correction results with a faster convergence rate.

Key words: brain MR image; segmentation; bias correction; split Bregman iteration

1 引言

脑核磁共振成像(Magnetic Resonance Imaging)作为一种高信息量的医学成像手段, 因可以清楚区分软组织、无需注射造影剂、无电离辐射、对人体影响小等特点, 已经成为人们进行脑结构、病理和解剖研究以及手术前中期的辅助干预的主要手段. 在中高层医学影像分析中, 往往需要对脑 MR 图像进行精确地分割, 然而由于磁场分布不均匀、生理组织电磁特性变化、激发射频线圈场受到干扰等原因, 目前脑 MR 脑图像不可避免地受到一个沿着空间缓慢变化的乘性场(又称偏移场 Bias Field)的影响^[1], 使得脑 MR 图像的灰度分布并不均匀, 因此基于图像灰度均匀假设的传统分割模型^[2,3]无法获得准确的分割结果.

近年来, 为了克服灰度分布不均匀对图像分割结果的影响, 许多专家学者提出了很多矫正偏移场的方法. 其中, 联合偏移场矫正和图像分割的耦合方法是这几年的研究热点. 例如, Wells 等^[4]提出了基于 EM 算法的偏移场校正自适应方法, Leemput 等^[5]进一步提出了参数化的 EM 算法, 将偏移场建模为一组多项式的基的线性组合以保证偏移场的光滑性. Pham 等^[6]将偏移场融入到 FCM 模型中, 提出了分割与偏移场矫正同时优化的能量最小化方法. 与单一的偏移场矫正方法^[7]不同, 该类方法综合考虑偏移场矫正与图像分割两个子问题求解的相互影响与信息补充, 得到的偏移场矫正结果更好^[4]. 但是这几种方法在预处理时都需对图像进行对数变换, 将乘性的偏移场变为加性场, 这会导致待分割图像中组织间的对比度降低, 无法准确将各个组织分开,

并且以上这些方法都是基于像素点的一阶统计信息,没有考虑邻域结构信息,对噪声比较敏感.Li 等人^[8]基于局部结构信息提出了分割和偏移场矫正的变分模型可以有效得到光滑的偏移场和较准确的分割结果,但他们提出的梯度下降迭代算法,每步都需要进行大量的卷积运算,因而收敛速度慢且分割效率低.此外,该方法得到的偏移场的光滑性受卷积核的尺寸影响,因此如何设计卷积核的大小也是该方法无法解决的问题.

为了克服上述不足,本文首先将偏移场建模为一组多项式基函数的线性组合,并将其融入高斯概率密度函数中,提出参数化互信息的脑 MR 图像分割与偏移场矫正的变分模型,达到同时分割与偏移场矫正的联合优化目的.其次,本文给出了基于分裂 Bregman 迭代求解联合优化变分模型的快速算法.通过对比实验,可以表明本文方法不但具有更高的分割精度而且具有较快的收敛速度.

2 脑图像灰度与标记矩阵的互信息

2.1 互信息

互信息(Mutual Information)是信息论里一种非常有用的信息度量,它描述的是两个事件集合之间的相关性.两个随机事件 X 和 Y 的互信息定义为:

$$\begin{aligned} \text{MI}(X, Y) &= H(X) + H(Y) - H(X, Y) \\ &= H(X) - H(X|Y) \end{aligned} \quad (1)$$

其中, H 是熵(Entropy). 一个连续的随机变量 z 在支集 S 上的熵定义为:

$$H(z) = - \int_S p_z(z) \log(p_z(z)) dz \quad (2)$$

随机事件 X 和 Y 的相关性越强,两者的互信息 $\text{MI}(X, Y)$ 就越大. 由于这个特性,互信息被广泛的应用于信号分离、图像配准、特征提取等领域.

2.2 脑图像分割中的互信息

近年来, Kim 等^[9,10]将互信息应用在图像分割中,取得很好的分割效果. 设定在图像域 Ω 中脑图像为 I (见图 1(a)), 在预处理后只剩下白质(WM)、灰质(GM)、脑脊液(CSF)和背景(Background)四个子区域,脑图像分割的目的就是将这四个子区域区分开.




图1 脑图像与标记图像

构造一个从图像域 Ω 映射到 $\{B, C, G, W\}$ 的标记矩阵 $L: \Omega \rightarrow \{B, C, G, W\}$:

$$L(x) = \begin{cases} W & \text{if } x \in R_1 \\ G & \text{if } x \in R_2 \\ C & \text{if } x \in R_3 \\ B & \text{if } x \in R_4 \end{cases}$$

其中, R_1, R_2, R_3, R_4 是被两条曲线 C_1, C_2 分开的四个区域, $\{B, C, G, W\}$ 分别为 R_1, R_2, R_3, R_4 的标记.

设 x 是在 Ω 上服从均匀分布的随机变量,则 $L(x)$ 也为一个随机变量,其在四个子区域的概率分别为 $\frac{|R_i|}{|\Omega|}$, $i=1,2,3,4$, 其中 $|\cdot|$ 表示区域的面积. 在 x 处的图像灰度值 $I(x)$ 与对应的标记矩阵的值 $L(x)$ 的互信息可定义为:

$$\begin{aligned} \text{MI}(I(x); L(x)) &= H(I(x)) - H(I(x)|L(x)) \\ &= H(I(x)) - \Pr(L(x) = W)H(I(x)|L(x) = W) \\ &\quad - \Pr(L(x) = G)H(I(x)|L(x) = G) \\ &\quad - \Pr(L(x) = C)H(I(x)|L(x) = C) \\ &\quad - \Pr(L(x) = B)H(I(x)|L(x) = B) \end{aligned} \quad (3)$$

当 $I(x)$ 与 $L(x)$ 的互信息最大时,通过标记矩阵对应的符号即可得到脑图像的分割结果,此时曲线 C_1, C_2 停在脑图像各个组织的边界处,具体的分析见文献[10]. 基于上述理论,构造如下的能量函数:

$$E(C_1, C_2) = -\text{MI}(I(x); L(x)) + \alpha |C_1| + \alpha |C_2| \quad (4)$$

其中, $|C_i|$, $i=1,2$ 是曲线 C_i 的周长,保证曲线在演化时周长最短,起到抑制噪声的作用, α 是非负参数.

因为图像中各个像素点是相互独立的,因此式(3)中的 $H(I(x))$ 是一常数,所以只需考虑四个条件熵,以 R_1 为例,其条件熵的表达形式如下:

$$H(I(x)|L(x) = W) = - \frac{1}{R_1} \int_{R_1} \log p_{R_1}(I(x)) dx \quad (5)$$

其他三个条件熵与上式类似. 将式(5)带入式(3)中,忽略常数项 $H(I(x))$, 式(4)可改写为:

$$\begin{aligned} E(C_1, C_2) &= - \frac{1}{|\Omega|} \int_{R_1} \log p_{R_1}(I(x)) dx \\ &\quad - \frac{1}{|\Omega|} \int_{R_2} \log p_{R_2}(I(x)) dx \\ &\quad - \frac{1}{|\Omega|} \int_{R_3} \log p_{R_3}(I(x)) dx \\ &\quad - \frac{1}{|\Omega|} \int_{R_4} \log p_{R_4}(I(x)) dx \\ &\quad + \alpha |C_1| + \alpha |C_2| \end{aligned} \quad (6)$$

3 本文模型

3.1 参数化偏移场及概率密度函

偏移场是造成脑 MR 图像中图像灰度不均匀的主要原因,其表现为脑 MR 图像上为同一类别的像素灰度沿空间呈缓慢的变化.因此,可以对 MR 图像建立如下模型^[4]:

$$\mathbf{I} = \mathbf{J} \cdot \mathbf{B} + \mathbf{N} \quad (7)$$

其中, \mathbf{I} 为观察得到的图像, \mathbf{J} 为灰度分布均匀的图像, \mathbf{B} 为偏移场, \mathbf{N} 是噪声. 为了保证偏移场光滑的特性,借鉴文献[11]的思想,本文利用 Legendre 多项式来构造一组光滑的基函数,并用这组基函数的线性组合来拟合偏移场:

$$\mathbf{B} = \mathbf{w}^T \mathbf{G} \quad (8)$$

其中, $\mathbf{w} = (\omega_1, \omega_2, \dots, \omega_n)^T$ 是参数, $\mathbf{G} = (g_1, g_2, \dots, g_n)^T$ 是基函数. 这样可将求解偏移场的问题转化为求这组基的参数问题,且由这组基拟合得到的偏移场可以很好的保持其光滑的特性,无需再进行平滑操作.

设子区域 \mathbf{R}_i 的均值为 c_i , 因真实图像 \mathbf{J} 的灰度分布是均匀的, 因此其灰度值可以近似等于其所属类别中的均值: $\mathbf{J}(x) \approx c_i, x \in \mathbf{R}_i$, 结合式(7)和式(8)得:

$$\mathbf{I}(x) = (\mathbf{w}^T \mathbf{G})(x) \cdot c_i + n(x) \quad (9)$$

根据文献[12], 受到偏移场干扰后的脑 MR 图像的各个组织服从均值为 $\mathbf{B}(x) c_i$, 方差为 σ_i 的高斯分布. 因此当前像素点 x 属于区域 \mathbf{R}_i 的概率为:

$$\begin{aligned} p_{\mathbf{R}_i}(\mathbf{I}(x)) &= \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(\mathbf{I}(x) - \mathbf{B}(x) \cdot c_i)^2}{2\sigma_i^2}\right) \\ &= \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(\mathbf{I}(x) - (\mathbf{w}^T \mathbf{G})(x) \cdot c_i)^2}{2\sigma_i^2}\right) \end{aligned} \quad (10)$$

从上式可以看出, 互信息中的概率密度函数可由参数 $\mathbf{w}, c_i, \sigma_i$ 表达出, 且因加入了偏移场信息, 该概率密度函数可以准确的表达出每个组织的灰度分布. 因此利用该概率密度函数对脑 MR 图像分类的结果可以有效避免偏移场的干扰.

3.2 目标函数

借鉴多相位水平集思想, 本文利用两个二值符号表 $\mathbf{u}_1, \mathbf{u}_2$ 隐式表达曲线 C_1, C_2 . 四个区域的标记分别为: $\mathbf{R}_1: \{\mathbf{u}_1 = 1, \mathbf{u}_2 = 1\}, \mathbf{R}_2: \{\mathbf{u}_1 = 1, \mathbf{u}_2 = 0\}, \mathbf{R}_3: \{\mathbf{u}_1 = 0, \mathbf{u}_2 = 1\}, \mathbf{R}_4: \{\mathbf{u}_1 = 0, \mathbf{u}_2 = 0\}$. 将式(6)系数归一化, 得本文的目标函数为:

$$\begin{aligned} E(\mathbf{u}_1, \mathbf{u}_2) &= -\lambda \int_{\Omega} \log p_{\mathbf{R}_1}(\mathbf{I}(x)) \cdot \mathbf{u}_1(x) \cdot \mathbf{u}_2(x) dx \\ &\quad - \lambda \int_{\Omega} \log p_{\mathbf{R}_2}(\mathbf{I}(x)) \cdot \mathbf{u}_1(x) \cdot (1 - \mathbf{u}_2(x)) dx \end{aligned}$$

$$\begin{aligned} &- \lambda \int_{\Omega} \log p_{\mathbf{R}_3}(\mathbf{I}(x)) \cdot (1 - \mathbf{u}_1(x)) \cdot \mathbf{u}_2(x) dx \\ &- \lambda \int_{\Omega} \log p_{\mathbf{R}_4}(\mathbf{I}(x)) \cdot (1 - \mathbf{u}_1(x)) \cdot (1 - \mathbf{u}_2(x)) dx \\ &+ \int |\nabla \mathbf{u}_1(x)| dx + \alpha \int |\nabla \mathbf{u}_2(x)| dx \end{aligned} \quad (11)$$

其中, $\lambda = \frac{|\Omega|}{\alpha}, \mathbf{c} = \{c_1, c_2, c_3, c_4\}, \boldsymbol{\sigma} = \{\sigma_1, \sigma_2, \sigma_3, \sigma_4\}$, $p_{\mathbf{R}_i}(\mathbf{I}(x))$ 的参数化表达形式见式(10). 该模型利用参数化的概率密度估计的方法将偏移场信息融入到基于互信息的分割框架内, 在能量极小化时分别求出参数 $\mathbf{w}, \mathbf{c}, \boldsymbol{\sigma}$ 以及 $\mathbf{u}_1, \mathbf{u}_2$, 实现了同时分割与偏移场矫正的目的. 本文模型不但可以保证准确的分割结果, 而且因利用基函数拟合偏移场保证了其光滑的特性. 能量极小化可表示为:

$$\min_{\mathbf{u}_1 \in \{0,1\}, \mathbf{u}_2 \in \{0,1\}, \mathbf{w}, \mathbf{c}, \boldsymbol{\sigma}} E(\mathbf{u}_1, \mathbf{u}_2, \mathbf{w}, \mathbf{c}, \boldsymbol{\sigma}) \quad (12)$$

4 本文快速算法

因为 $\mathbf{u}_1(x) \in \{0,1\}, \mathbf{u}_2(x) \in \{0,1\}$ 的解的集合是非凸的, 因此式(11)是一个非凸的能量极小化问题, 借鉴文献[13, 14]的思想, 将其转化为关于 $\mathbf{u}_1(x) \in [0, 1], \mathbf{u}_2(x) \in [0, 1]$ 凸集上的能量极小化问题:

$$\min_{\mathbf{u}_1 \in [0,1], \mathbf{u}_2 \in [0,1], \mathbf{w}, \mathbf{c}, \boldsymbol{\sigma}} E(\mathbf{u}_1, \mathbf{u}_2, \mathbf{w}, \mathbf{c}, \boldsymbol{\sigma}) \quad (13)$$

待求的区域 \mathbf{R}_i 可通过在区间 $[0, 1]$ 内的阈值 α 求出, 以 \mathbf{R}_2 为例: $\mathbf{R}_2 = \{\mathbf{u}_1 > \alpha, \mathbf{u}_2 < \alpha\}$, 其他区域与此类似, 而 $\mathbf{u}_i(x) \in [0, 1], i = 1, 2$ 的限制条件可由投影法简单求出. 原问题的最优解可通过如下几个简单方法求得:

首先利用交替迭代方法求出 $\mathbf{c}, \boldsymbol{\sigma}$ 和 \mathbf{w} , 表达式如下:

$$c_i = \frac{\int \mathbf{I}(x) \cdot \mathbf{M}_i(x) dx}{\int \mathbf{M}_i(x) dx} \quad (14)$$

$$\sigma_i = \frac{\int (\mathbf{I}(x) - (\mathbf{w}^T \mathbf{G})(x) c_i)^2 \cdot \mathbf{M}_i(x) dx}{\int \mathbf{M}_i(x) dx} \quad (15)$$

$$\mathbf{w} = \mathbf{A}^{-1} \mathbf{V} \quad (16)$$

其中, $i = 1, \dots, 4, \mathbf{M}_1(x) = \mathbf{u}_1(x) \cdot \mathbf{u}_2(x), \mathbf{M}_2(x) = \mathbf{u}_1(x) \cdot (1 - \mathbf{u}_2(x)), \mathbf{M}_3(x) = (1 - \mathbf{u}_1(x)) \cdot \mathbf{u}_2(x), \mathbf{M}_4(x) = (1 - \mathbf{u}_1(x)) \cdot (1 - \mathbf{u}_2(x))$.

式(16)中的 \mathbf{A} 和 \mathbf{V} 的表达式为:

$$\mathbf{A} = \sum_{i=1}^4 \int \frac{\mathbf{G}(x) \mathbf{G}^T(x) c_i^2(x)}{2\sigma_i^2} \mathbf{M}_i(x) dx$$

$$\mathbf{V} = \sum_{i=1}^4 \int \frac{\mathbf{I}(x) \mathbf{G}(x) c_i(x)}{2\sigma_i^2} \mathbf{M}_i(x) dx$$

在求解 $\mathbf{u}_1, \mathbf{u}_2$ 时, 将式(13)转化为两个耦合的凸优化问题:

$$\begin{cases} \min_{\mathbf{u}_1 \in [0,1]} \{E_1(\mathbf{u}_1) = |\nabla \mathbf{u}_1| - \lambda \langle \mathbf{r}_1 - \mathbf{r}_2, \mathbf{u}_1 \rangle\} \\ \min_{\mathbf{u}_2 \in [0,1]} \{E_2(\mathbf{u}_2) = |\nabla \mathbf{u}_2| - \lambda \langle \mathbf{r}_3 - \mathbf{r}_4, \mathbf{u}_2 \rangle\} \end{cases} \quad (17)$$

其中

$$\begin{cases} r_1 = \log p_{R_1}(I(x)) \cdot u_2(x) + \log p_{R_2}(I(x)) \cdot (1 - u_2(x)) \\ r_2 = \log p_{R_3}(I(x)) \cdot u_2(x) + \log p_{R_4}(I(x)) \cdot (1 - u_2(x)) \\ r_3 = \log p_{R_1}(I(x)) \cdot u_1(x) + \log p_{R_3}(I(x)) \cdot (1 - u_1(x)) \\ r_4 = \log p_{R_2}(I(x)) \cdot u_1(x) + \log p_{R_4}(I(x)) \cdot (1 - u_1(x)) \end{cases} \quad (18)$$

利用梯度下降法求解式(17)时,一般利用 $\sqrt{|\nabla u_i|^2 + \varepsilon}$ 来近似 $|\nabla u_i|$ $i=1,2$, 以避免求导后分母为零的问题,因此求得的解并不是原问题的解,且为保证算法收敛梯度下降法的迭代步长 Δt 的取值都很小,影响了能量下降的速度.为了克服这两个缺陷,本文利用分裂 Bregman 方法^[13,14]快速求解 u_1, u_2 . 该方法求得的解不但是原问题的最优解且能量下降速度非常快.

首先引入新的向量 d_1, d_2 对式(18)进行解耦:

$$\begin{cases} \min_{u_1 \in [0,1], d_1} \{ E_1(u_1, d_1) \\ = |d_1|_1 - \lambda \langle r_1 - r_2, u_1 \rangle, \text{ subject to } d_1 = \nabla u_1 \} \\ \min_{u_2 \in [0,1], d_2} \{ E_2(u_2, d_2) \\ = |d_2|_1 - \lambda \langle r_3 - r_4, u_2 \rangle, \text{ subject to } d_2 = \nabla u_2 \} \end{cases} \quad (19)$$

通过引入新变量,将求 TV 范数 $|\nabla u_i|$ 的导数问题转化为求 L_1 范数 $|d_i|_1$ 的导数,而 L_1 范数的导数可通过现有的软阈值方法直接求出(见式(25)),从而有效避免了很难求出 $|\nabla u_i|$ 导数的问题.本文利用 Bregman 迭代将式(19)的有约束优化问题转化为无约束优化问题,且该迭代方法可保证式(19)的解是原问题(式(17))的精确解,详细证明参见文献[17].以极小化 E_1 为例,引入中间变量 b_1 其 Bregman 迭代形式如下:

$$\begin{cases} (u_1^{k+1}, d_1^{k+1}) = \\ \min_{u_1 \in [0,1], d_1} \{ |d_1|_1 - \lambda \langle r_1 - r_2, u_1 \rangle + \frac{\mu}{2} \|d_1 - \nabla u_1 - b_1\|_2^2 \} \\ b_1^{k+1} = b_1^k + \nabla u_1^{k+1} - d_1^{k+1} \end{cases} \quad (20)$$

再利用变分原理得:

$$\Delta u_1 = \frac{\lambda}{\mu} (r_1 - r_2) + \nabla \cdot (d_1^k - b_1^k), u_1(x) \in [0,1] \quad (21)$$

利用 Gaussian-Seidel 迭代法以及投影算法求得 u_1^{k+1} :

$$\alpha_{i,j} = (d_1)_{i-1,j}^{x,k} - (d_1)_{i,j}^{x,k} - (b_1)_{i-1,j}^{x,k} + (b_1)_{i,j}^{x,k} + (d_1)_{i-1,j}^{y,k} - (d_1)_{i,j}^{y,k} - (b_1)_{i-1,j}^{y,k} + (b_1)_{i,j}^{y,k} \quad (22)$$

$$\beta_{i,j} = \frac{1}{4} [(u_1)_{i-1,j}^{k,n} + (u_1)_{i+1,j}^{k,n} + (u_1)_{i,j-1}^{k,n} + (u_1)_{i,j+1}^{k,n} - \frac{\mu}{\lambda} (r_1 - r_2) + \alpha_{i,j}] \quad (23)$$

$$(u_1)_{i,j}^{k+1,n+1} = \max\{\min\{\beta_{i,j}, 1\}, 0\} \quad (24)$$

d_1^{k+1} 由软阈值方法求得:

$$d_1^{k+1} = \max\{\|b_1^k + \nabla u_1^{k+1}\| - \lambda, 0\} \frac{b_1^k + \nabla u_1^{k+1}}{\|b_1^k + \nabla u_1^{k+1}\|} \quad (25)$$

同理可利用该方法极小化 E_2 . 通过上述步骤可知本文算法通过引入新变量将 TV 范数求导问题转化为求 L_1 范数的导数,而 L_1 范数的导数可由软阈值方法直接给出,从而提高了计算效率,且本文利用 Bregman 迭代保证求得的解是原问题(式(17))的解,实现了精确快速最小化目标函数的目的.

下面给出本文算法的流程:

Step1 初始化 u_1, u_2, w ;

Step2 利用式(14), (15)求解参数 c_i, σ_i

Step3 利用式(22) ~ (24)更新 u_1, u_2 ;

Step4 利用式(16)更新 w

Step5 若不收敛转 Step2, 否则利用下式求出恢复

图像 J :

$$J = I/B \quad (26)$$

其中, B 由式(8)求出.

5 实验结果与分析

本文实验结果是在 Pentium 4 处理器, 2.8GHz, 512MB 内存的 PC 机上利用 MATLAB R2008 软件运行得到的. 不失一般性, 本文实验中的参数选取如下: $\lambda = 0.7, \mu = 1, \lambda$ 越小分割结果对噪声的抗干扰性越强. 为了方便与其他方法的分割结果比较, 本文实验中用 0、90、160、250 分别表示背景、脑脊液(CSF)、灰质(GM)、白质(WM)的灰度值.

图 2 是本文方法与梯度下降法的比较结果. 图 2(a) 是含 7% 噪声和 100% 灰度不均匀(INU)的脑 MR 图像. 图 2(b) 是对应的不含噪声和偏移场的脑 MR 图像. 图 2(c) 是用梯度下降法求解本文模型的结果, 由于图像受噪声的严重污染, 梯度下降法求解与原问题的解偏差较大, 因此无法保证准确的分割结果. 图 2(d) 是本文方法得到的分割结果, 由于本文方法得到的是原始问题的最优解, 因此分割结果比较准确. 图 2(e) 显示了

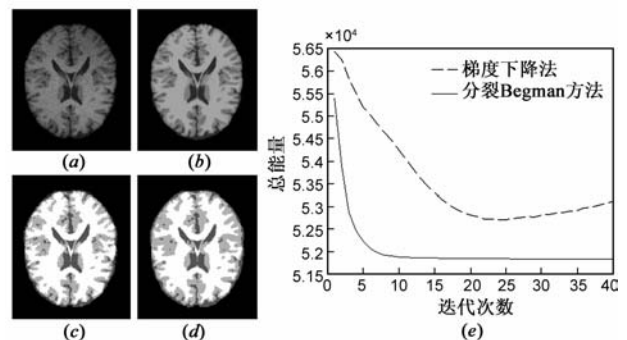


图2 与梯度下降方法的分割结果比较

两种方法在迭代过程中的能量衰减过程,从图中可以看出与梯度下降法相比,本文方法的收敛速度具有较大优势.在时间效率上,利用本文方法的分割耗时是 1.2s,而利用梯度下降法的分割耗时是 22.4s,这说明本文方法具有速度优势适合实时的应用.

图 3 是本文方法与 Wells、Leamput 及 Li 方法的比较结果.第一列第一行是一幅受偏移场严重干扰的脑 MR 图像,且含有少量噪声,第二行是对应不含偏移场和噪声的脑 MR 图像.第二列至第五列分别为 Wells、leamput、Li 及本文方法得到偏移场(第一行)、分割结果(第二行)及恢复图像(第三行).从第一行可以看出本文方法和 Leamput 方法都利用基函数对偏移场建模,因此能很好的保证其光滑的特点,而 Wells 方法和 Li 方法得到的偏移场受卷积模板大小的影响结果不是很平滑.从分割结果中可以看出 Wells 和 Leamput 的分割结果对噪声比较敏感,Li 方法得到的分割结果虽然能很好的克服噪声的干扰,但因为偏移场计算不正确,导致分割结果也不准确.因本文模型符合脑图像的特点且利用分裂 Bregman 方法得到其最优解,所以本文方法得到的分割结果比较准确.第三行是四种方法得到的恢复图像,表 1 列出了这些恢复图像的熵(见表 1),熵越小说明图像灰度分布越均匀,恢复的效果越好.因本文方法和 Leamput 方法得到的偏移场符合光滑的特点,因此这两种方法得到的恢复图像灰度分布较 Wells 和 Li 方法得到的结果更加均匀.而又由于本文方法的分割结果比 Leamput 方法更准确,因此偏移场矫正图像的效果也更好.

为了比较本文方法与其他方法所得的分割结果的精确度,本文选用 McGill 大学 Montreal 脑神经学研究所大脑成像中心的 BrainWeb 仿真脑 MR 数据库做定量分析.图 4 中第一列分别为仿真数据中的轴向面、冠状面的矢状面的某一帧图像,都含有 100% 的偏移场和 3% 的随机噪声.第二~五列分别为 Wells 方法、Leamput 方法、Li 方法以及本文方法得到的




图 3 合成脑MR图像的结果比较




图 4 仿真脑MR图像的分割结果比较

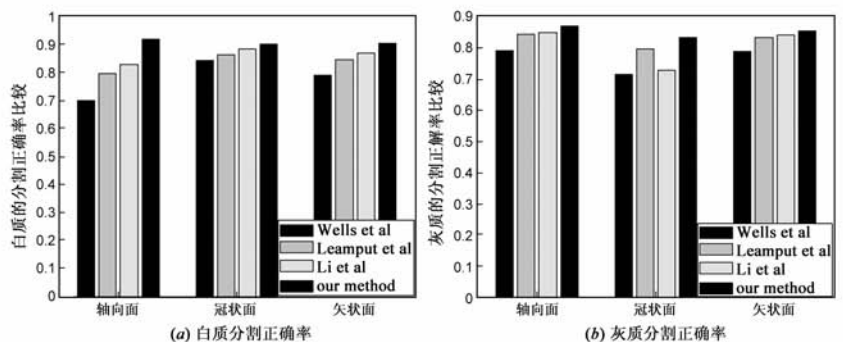


图 5 仿真脑MR图像分割正确率比较

分割结果.视觉上很难分别出各自方法所得结果的准确性.因此,本文采用式(27)求出这四种方法的分割正确率(见图 5).从图 5 中可以看出本文方法的分割正确率较其他方法都有明显的提高.

$$J(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|} \quad (27)$$

其中, S_1 是利用方法获得的分割结果, S_2 是真实的分割结果.

表 1 恢复图像熵的比较

	Wells 方法	Leamput 方法	Li 方法	本文方法
恢复图像的熵	6.2655	5.9604	6.2299	5.8474

6 总结

本文利用融入偏移场信息的高斯概率密度函数来参数化互信息中的概率密度函数, 提出脑 MR 图像的分割与偏移场矫正的变分模型, 该模型能实现同时分割与偏移场计算的目的. 由于利用参数化的基函数对偏移场建模, 因此本文方法可保证偏移场的光滑特点. 此外, 本文利用分裂 Bregman 迭代代替传统的梯度下降法求得该模型极小化问题的最优解, 保证了算法的收敛速度. 实验结果表明与现有的几种方法相比, 本文方法的分割精度和偏移场矫正结果都有一定的优势. 将来可以将本文方法推广到 3D 脑 MR 数据的处理中.

参考文献

- [1] Sled J, Zijdenbos A, Evans A. A nonparametric method for automatic correction of intensity non-uniformity in MRI data[J]. IEEE Trans Med Imaging, 1998, 17(1): 87 - 97.
- [2] Vese L, Chan T. A multiphase level set framework for image segmentation using the Mumford and Shah Model[J]. Computer Vision, 2002, 50(3): 271 - 293.
- [3] 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): 643 - 645.
FENG Yan-qiu, CHEN Wu-fan, LIANG Bin, LIN Ya-zhong. A new algorithm for image segmentation based on Gibbs random field and fuzzy C-means clustering[J]. Acta Electronica Sinica, 2004, 32(4): 643 - 645. (in Chinese)
- [4] Wells III W, Grimson W, Kikinis R, Jolesz F. Adaptive segmentation of MRI data[J]. IEEE Trans Med Imaging, 1996, 15(4): 429 - 442.
- [5] Van Leemput, Maes F, Vandermeulen D, Suetens P. Automated model-based bias field correction of MR images of the brain [J]. IEEE Trans Med Imaging 1999, 18(10): 885 - 896.
- [6] Pham D, Prince J. An adaptative fuzzy C-means algorithm for image segmentation in the presence of intensity inhomogeneities [J]. Pattern Recognition Letter, 1999, 20(1): 57 - 68.
- [7] Likar B, Viergever M A, Pernus F. Retrospective correction of MR intensity inhomogeneity by information minimization[J].

IEEE Transactions on Medical Imaging, 2002, 20(12): 1398 - 1410.

- [8] C Li, R Huang, Z Ding, C Gatenby, D Metaxas, J Gore. A variational level set approach to segmentation and bias correction of medical images with intensity inhomogeneity[A]. Proceedings of Medical Image Computing and Computer Aided Intervention (MICCAI), Part II [C]. New York, USA: Springer, 2008. 1083 - 1091.
- [9] Kim J, Fisher III, et al. A nonparametric statistical method for image segmentation using information theory and curve evolution[J]. IEEE Transactions on Image Processing, 2005, 14(10): 1486 - 1502.
- [10] Kim J, et al. Nonparametric shape priors for active contour-based image segmentation[J]. Signal Processing, 2007, 87(12): 3021 - 3044.
- [11] Li C, Gatenby C, Wang L, Gore J C. A robust parametric method for bias field estimation and segmentation of MR images[A]. IEEE Conference on Computer Vision and Pattern Recognition, (CVPR) [C]. Miami, USA: Springer, 2009. 218 - 223.
- [12] Zhang K, Zhang L, Zhang S. A variational multiphase level set approach to simultaneous segmentation and bias correction [A]. The Int Conf on Image Processing, (ICIP) [C]. Hong Kong, China: IEEE, 2010. 1 - 4.
- [13] Goldstein T, Osher S. The split Bregman method for L1 regularized problems [J]. SIAM Journal on Imaging Sciences, 2009, 2(2): 323 - 343.
- [14] 王利. 脑核磁共振图像分割技术研究[D]. 南京: 南京理工大学计算机科学与技术学院, 2010.

作者简介

詹天明 男, 1984 年 10 月生于江苏省高邮市, 现为南京理工大学博士研究生, 主要研究方向为医学图像处理与分析.

E-mail: zhantianming1984@yahoo.cn

张 军 男, 1977 年 2 月出生, 博士, 现为南京理工大学理学院讲师, 目前研究方向图像处理中的反问题、图像建模与算法.

E-mail: phil_zj@mail.njust.edu.cn

韦志辉 男, 1963 年 11 月出生, 教授, 博士生导师. 主要研究方向为图像处理, 图像建模, 多尺度变换理论, 数字水印, 编码与压缩.

E-mail: gswei@mail.njust.edu.cn

肖 亮 男, 1976 年 2 月出生, 副教授, 硕士生导师, 主要研究方向为变分偏微分方程在图像处理中的应用, 三维医学图像处理等.

E-mail: txiaoliang@163.com

孙玉宝 男, 1983 年 9 月出生, 南京理工大学博士后, 主要研究领域为图像的稀疏表示, 超分辨, 分布式仿真, 网络虚拟环境设计与开发. E-mail: syb8692833@126.com