

中图分类号: TP391 文献标志码: A 文章编号: 1006-8961(2011)11-2017-07

论文索引信息: 詹天明, 韦志辉, 张建伟, 肖亮, 张军. 脑 MR 图像分割和偏移场矫正的耦合水平集模型 [J]. 中国图象图形学报, 2011, 16(11): 2017-2023

脑 MR 图像分割和偏移场矫正的耦合水平集模型

詹天明¹⁾, 韦志辉^{1),2)}, 张建伟³⁾, 肖亮¹⁾, 张军²⁾

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

³⁾(南京信息工程大学数理学院, 南京 210044)

摘要: 脑核磁共振(MR)图像因需要偏移场矫正, 传统分割方法很难获得准确的分割结果。针对这一问题, 首先构造一组基函数拟合偏移场以保证偏移场的光滑特性, 再将其融入到高斯概率密度函数中, 结合统计分类准则建立脑 MR 图像的分割和偏移场矫正的能量方程, 最后将该能量方程引入到三相水平集的变分框架中得到脑 MR 图像的分割和偏移场矫正的耦合模型。实验表明该方法在得到准确的分割结果同时还可以得到较好的恢复结果。

关键词: 偏移场; 三相; 水平集; 图像分割

Coupling level set model for brain MR image segmentation and bias field correction

Zhan Tianming¹⁾, Wei Zhihui^{1),2)}, Zhang Jianwei³⁾, Xiao Liang¹⁾, Zhang Jun²⁾

¹⁾(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094 China)

²⁾(School of Computer Science and Engineering, Nanjing University of Science and Technology Nanjing 210094 China)

³⁾(College of Math & Physics, Nanjing University of Information Science and Technology, Nanjing 210044 China)

Abstract: Due to the correction of the bias field, it is hard to obtain the accurate segmentation results of magnetic resonance(MR) images using traditional methods. In this paper, a set of basis functions is constructed firstly to fit the smoothness bias field; then the information of the bias field is introduced to the Gaussian density function, and according to the statistics classification rule, we define the energy function for the brain MR image segmentation and bias field correction. At last, this energy function is incorporated into a three-phase level set framework to propose our model. Compared with other approaches, our experiments demonstrate that our method not only can obtain accurate segmentation results but also can restore images better.

Keywords: bias field; three-phase; level set; image segmentation

收稿日期: 2010-10-25; 修回日期: 2011-01-19

基金项目: 国家自然科学基金项目(60802039, 61071146, 61003209); 高等学校博士点学科点专项基金项目(200802880018); 南京理工大学资助科研重大专项项目(2010ZDJH07); 南京理工大学自主科研专项计划资助项目(2010ZYT070); 江苏省高校自然科学基金研究项目(10KJB520012); 南京理工大学优秀博士培养计划项目; 江苏省研究生培养创新工程项目。

第一作者简介: 詹天明(1984—), 男。南京理工大学计算机科学与技术学院模式识别与智能系统专业博士研究生, 主要研究方向: 医学图像处理与分析。E-mail: zhantianming1984@yahoo.cn。

0 引言

脑核磁共振成像(MRI)由于具有非介入性,非损伤性,以及受目标物体运动的影响较小等特性,在临床医学上起着越来越重要的作用。目前,它已成为专家研究脑组织结构、组织量化测定、病灶确定,以及脑组织疾病预测的主要手段^[1]。在这些应用中都需要对脑 MR 图像进行精确地分割。然而,在实际应用中,由于受射频频场不均匀性、MR 设备本身,人脑不同组织之间的差异性和脑组织的容积效应等影响,图像的灰度沿某一方向缓慢变化,其分布不再均匀。若只依靠传统基于灰度分布均匀假设的方法来分割图像是得不到准确结果的。为了取得准确的分割结果,需要对脑 MR 图像进行偏移场矫正。近二十年来,国内外学者提出了很多偏移场矫正的方法,文献[2]将这些方法总的分为基于变换域和基于空间域这两种方法。目前,将 MR 图像偏移场矫正和图像分割融入到一个能量框架中,利用交替迭代算法同时实现偏移场矫正和分割的方法是国内外广大学者的研究重点^[3-6]。例如,Wells 等人^[3]将偏移场信息引入到统计分类框架中提出了脑 MR 图像的分割和偏移场矫正的耦合模型,可以自动地分割脑 MR 图像。但为了保证偏移场光滑的特性,该方法在每一步迭代后都需要额外的对求出的偏移场进行平滑操作。Leemput 等人^[4]对 Wells 方法进行改进,利用一组基函数拟合偏移场,将求偏移场的问题划归为求解基函数的系数问题,保证了偏移场光滑的特性。但该方法与 Wells 方法一样需对图像进行对数变换,对数变换后图像各个类别的灰度对比度差异变小,导致分割结果很不准确,进而也会影响偏移场矫正的效果。除此之外,上述两种方法未考虑像素点的空间位置信息,分割结果会受到噪声的干扰。为克服噪声对分割结果的影响,Ahemd 等人在 FCM 方法中引入空间约束项,提出了改进 FCM 方法^[5]。但该方法仍然需要对图像作对数变换,且与 Wells 方法类似,在每一步迭代后都要额外的对求出的偏移场进行平滑操作。

近年来,为克服噪声对脑 MR 图像分割精度的影响,基于区域的水平集方法受到了许多学者的广泛关注^[7-9],其中比较经典的是 Chan 和 Vese 提出的多相位水平集分割框架(PC model)^[9],该方法通过最小化曲线的长度项控制零水平集的光滑程度。与在 FCM 方法中增加空间约束项相比,该方法可以更好地避免噪声对分割结果的干扰,且光滑的水平集更能体现出图

像边界区域是光滑的特性。但该方法是在建立在图像灰度均匀的假设之上,所以也无法正确地分割脑 MR 图像。Li 等人将偏移场信息引入多相位水平集分割框架中,提出了灰度不均匀图像的分割和偏移场矫正的变分水平集方法^[6]。该方法无须对图像进行对数变换且分割结果可以很好地克服噪声的干扰。但是该方法的偏移场光滑程度是由卷积核的大小控制的,因此无法确保得到的偏移场是真正光滑的。此外,该方法只利用近邻法作为分类决策,分割准确性不高。

针对上述问题,首先构造一组基函数拟合偏移场以保证偏移场的光滑特性,再将其融入到高斯概率密度函数中,结合统计分类准则建立脑 MR 图像的分割和偏移场矫正的能量方程,最后根据脑 MR 图像的特性构造三相位水平集的变分框架,将上述能量方程引入到该变分框架下得到脑 MR 图像的分割和偏移场矫正的耦合模型。该模型不但能保证偏移场的光滑特性,还可避免噪声对分割结果的影响,而且因利用含有均值和方差信息的高斯概率作为分类决策,可以得到更准确的分割结果。实验表明本文方法分割精度较其他方相比有了进一步的提高,而且利用计算出的光滑偏移场得到的恢复图像的灰度分布更加均匀。

1 本文模型及算法

1.1 偏移场的拟合

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^[2]。含偏移场的 MR 图像可建模为

$$I = b \cdot J + n \quad (1)$$

式中, I 为观测图像, J 为真实图像, b 为偏移场, n 是噪声。由于偏移场比较光滑,可用一组基来构造偏移场^[10],而且这组基必须是光滑函数。使用 Legendre 多项式构造基函数:

$$g(x) = \sum_{i=0}^l \sum_{j=0}^{l-i} p_{ij} P_i(x) P_j(y) \quad (2)$$

式中 p_{ij} 为参数,图像的位置信息需要转换到 $[-1, 1]$ 之间, l 为多项式的次数,次数较小时精度不够,次数增高时计算复杂度成倍增加。一般情况下取 $l = 4$,此时需要 $(l+1)(l+2)/2 = 15$ 个参数。使用 Legendre 多项式的原因是该多项式为正交多项式,利于参数的计算。

偏移场 b 可表示为这组基的线性组合,即

$$b = W^T G \quad (3)$$

式中, $\mathbf{W} = (\omega_1, \omega_2, \dots, \omega_n)^T$ 是参数, $\mathbf{G} = (g_1, g_2, \dots, g_n)^T$ 是基函数。

1.2 融入偏移场信息的能量方程

设 $\Omega \in \mathbb{R}^2$ 是图像空间, $I: \Omega \rightarrow \mathbb{R}$ 是观测图像, 为了将图像 I 准确地分割为 N 个互不相交的子区域 $\Omega_i, i = 1, \dots, N$, 利用最大化后验概率方法作为图像分割的准则。 x 在 Ω_i 中的后验概率 $p(x \in \Omega_i | I(x))$ 可表示为

$$p(x \in \Omega_i | I(x)) = \frac{p(I(x) | x \in \Omega_i)p(x \in \Omega_i)}{p(I(x))} \quad (4)$$

$i = 1, 2, \dots, N$

式中, $p(I(x) | x \in \Omega_i)$ 是 $x \in \Omega_i$ 条件概率, $p(x \in \Omega_i)$ 是 $x \in \Omega_i$ 的先验概率, $p(I(x))$ 是灰度值 $I(x)$ 的先验概率。假设各个区域中的像素点是独立分布的, 忽略 $p(I(x))$, 所以要得到正确的分割结果即要求下式最大化:

$$\prod_{i=1}^N \prod_{x \in \Omega_i} p(I(x) | x \in \Omega_i)p(x \in \Omega_i) \quad (5)$$

设 x 属于各个区域的先验概率是相等的, 即 $p(x \in \Omega_i) = \frac{1}{N}, i = 1, \dots, N$, 并对上式进行对数变换, 最大化式(5)转化为极小化:

$$\sum_{i=1}^N \int_{\Omega_i} -\log(p(I(x) | x \in \Omega_i)) dx \quad (6)$$

由上式可以看出, 为实现图像分割的目的, 合理地得到 $x \in \Omega_i$ 的条件概率 $p(I(x) | x \in \Omega_i)$ 非常重要。由于图像 I 受到偏移场的干扰, 利用传统的高斯概率密度函数得到的条件概率并不准确, 所以合理地估计条件概率是分割是否准确的重要因素。

因为真实图像 J 的灰度分布是均匀的, 所以在每个子区域中每个像素点灰度值可以近似为一个常数: $J(x) \approx \mu_i, x \in \Omega_i$, 结合式(1)(2)得

$$I(x) = (\mathbf{W}^T \mathbf{G})(x) \cdot \mu_i + n(x) \quad (7)$$

假设区域 Ω_i 中的噪声 $n(x)$ 服从均值为 0, 方差为 σ_i 的高斯分布, 可得到当前像素点 x 属于区域 Ω_i 的条件概率:

$$p(I(x) | x \in \Omega_i) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(I(x) - (\mathbf{W}^T \mathbf{G})(x) \cdot \mu_i)^2}{2\sigma_i^2}\right) \quad (8)$$

与传统的高斯概率密度函数不同, 上式中的参数 μ_i 是真实图像 J 在区域 Ω_i 中的均值, 且该式中融入了光滑的偏移场信息, 所以利用该式求出

的条件概率克服了偏移场对图像灰度分布的影响, 比传统高斯概率密度函数求出的条件概率更准确。将该条件概率带入到式(6)中, 即得图像分割和偏移场矫正耦合的能量方程。与 Li 等人在文献[9]中仅利用 K 近邻作为能量方程相比, 能量方程在分割时不但需要待分割点与所属类别的均值最近还需保证所属类别的方差最小, 所得的分割结果会更准确。该能量方程的极小化可通过水平集的演化方程求得。

1.3 三相位水平集框架

利用曲线演化理论和水平集方法求解式(6)的极小化问题。目前, 基于区域的水平集方法的脑 MR 图像分割方法都是利用两条曲线构造 4 个相位来分别表示图中的白质、灰质、脑脊液和背景 4 个部分。但脑 MR 图像背景较大, 且大部分灰度值等于零导致该部分的方差较小, 往往会导致曲线演化时会发生错误。为解决这一问题, 提出 3 相位的水平集框架(见图 1), 首先将背景部分去除, 构造符号矩阵(ROI)表示脑 MR 图像的待分割区域即目标区域: $O(x) = \begin{cases} 1 & x \in \text{object} \\ 0 & x \in \text{background} \end{cases}$, 再用两条曲线 φ_1, φ_2 构造 3 个区域 $\{\varphi_1 > 0, \varphi_2 > 0, O = 1\}, \{\varphi_1 > 0, \varphi_2 < 0, O = 1\}, \{\varphi_1 < 0, O = 1\}$ 来分别表示白质(WM)、灰质(GM)和脑脊液(CSF)这 3 类脑组织。




图 1 三相位水平集图示

Fig. 1 Picture of three phase level set

引入 Heaviside 函数 H , 将式(6)引入到上述 3 个水平集框架可得:

$$E(\Phi, U, K, W) = \int -\log(p(I(x) | x \in \Omega_1)) \cdot O(x) \cdot M_1(\Phi(x)) dx + \int -\log(p(I(x) | x \in \Omega_2)) \cdot O(x) \cdot M_2(\Phi(x)) dx + \int -\log(p(I(x) | x \in \Omega_3)) \cdot O(x) \cdot M_3(\Phi(x)) dx + \int -\log(p(I(x) | x \in \text{background})) \cdot (1 - O(x)) dx \quad (9)$$

式中,

$$\Phi = \{\varphi_1, \varphi_2\}, U = \{\mu_1, \mu_2, \mu_3\}, K = \{\sigma_1, \sigma_2, \sigma_3\},$$

$$M_1(\Phi(x)) = H(\varphi_1(x)) \cdot H(\varphi_2(x)),$$

$$M_2(\Phi(x)) = H(\varphi_1(x)) \cdot (1 - H(\varphi_2(x))),$$

$$M_3(\Phi(x)) = 1 - H(\varphi_1(x)).$$

为了克服噪声对图像分割结果的影响以及水平集重新初始化带来的计算量增大的问题,加入零水平集的长度项和惩罚项^[11]:

$$\ell(\Phi) = \int |\nabla H(\varphi_1(x))| dx + \int |\nabla H(\varphi_2(x))| dx \quad (10)$$

$$P(\Phi) = \int \frac{1}{2} (|\nabla \varphi_1(x)| - 1)^2 dx + \int \frac{1}{2} (|\nabla \varphi_2(x)| - 1)^2 dx \quad (11)$$

由式(9)–(11),得 3 相位水平集的总能量方程:

$$F(\Phi, U, K, W) = \lambda E(\Phi, U, K, W) + \gamma \ell(\Phi) + \nu P(\Phi) \quad (12)$$

式中 $\lambda, \gamma, \nu > 0$ 是权重参数。

$$\text{利用光滑函数 } H_\varepsilon(x) = \frac{1}{2} \left[1 + \frac{2}{\pi} \arctan\left(\frac{x}{\varepsilon}\right) \right]$$

近似等式(9)–(11)中的 Heaviside 函数,得水平集耦合模型:

$$F_\varepsilon(\Phi, U, K, W) = \lambda E_\varepsilon(\Phi, U, K, W) + \gamma \ell_\varepsilon(\Phi) + \nu P(\Phi) \quad (13)$$

上述模型中含有 Φ, U, K, W 4 个参数,可通过交替迭代的形式极小化该问题得到图像的分割结果。该分割结果是由水平集 Φ 隐式表达。

1.4 本文算法

总能量方程式(14)对 Φ 的极小化问题可转化为求解如下的梯度下降流方程:

$$\frac{\partial \varphi_1}{\partial t} = \delta_\varepsilon(\varphi_1) \cdot \{\lambda \cdot ROI \cdot (-\log(p_1) \cdot H_\varepsilon(\varphi_2)) - \log(p_2)(1 - H_\varepsilon(\varphi_2)) + \log(p_3)\} + (\gamma \cdot \text{div}(\nabla \varphi_1 / |\nabla \varphi_1|)) + \nu(\nabla^2 \varphi_1 - \text{div}(\nabla \varphi_1 / |\nabla \varphi_1|)) \quad (14)$$

$$\frac{\partial \varphi_2}{\partial t} = \delta_\varepsilon(\varphi_2) \cdot \{\lambda \cdot ROI \cdot [-\log(p_1)H_\varepsilon(\varphi_1) + \log(p_2)H_\varepsilon(\varphi_1)] + \gamma \cdot \text{div}(\nabla \varphi_1 / |\nabla \varphi_1|)\} + \nu(\nabla^2 \varphi_1 - \text{div}(\nabla \varphi_1 / |\nabla \varphi_1|)) \quad (15)$$

式中,

$$p_i(x) = \frac{1}{\sqrt{2\pi}\sigma_i} \exp\left(-\frac{(I(x) - (W^T G)(x)\mu_i)^2}{2\sigma_i^2}\right)$$

$$i = 1, \dots, 4, \delta_\varepsilon(x) = \frac{1}{\pi} \frac{\varepsilon}{\varepsilon^2 + x^2}.$$

固定 Φ 和 W ,利用梯度下降法可求各个类别的均值和方差:

$$\mu_i = \frac{\int I(x)b(x)M_i(\Phi(x))O(x)dx}{\int b^2(x)M_i(\Phi(x))O(x)dx} \quad i = 1, \dots, 3 \quad (16)$$

$$\mu_4 = \frac{\int I(x)b(x)(1 - O(x))dx}{\int b^2(x)M_i(\Phi(x)) \cdot (1 - O(x))dx} \quad (17)$$

$$\sigma_i^2 = \frac{\int (I(x) - b(x)\mu_i)^2 \cdot M_i(\Phi(x)) \cdot O(x)dx}{\int M_i(\Phi(x)) \cdot O(x)dx} \quad i = 1, \dots, 3 \quad (18)$$

$$\sigma_4^2 = \frac{\int (I(x) - b(x)\mu_4)^2 \cdot (1 - O(x))dx}{\int (1 - O(x))dx} \quad (19)$$

式中, $b(x) = (W^T G)(x)$ 。

同样,固定 Φ, U 和 K ,可求得基函数的系数:

$$W = A^{-1}V \quad (20)$$

式中,

$$A = \sum_{i=1}^3 \int \frac{G(x)G^T(x)\mu_i^2(x)}{2\sigma_i^2} M_i(\Phi(x)) \cdot O(x) dx + \int \frac{G(x)G^T(x)\mu_4^2(x)}{2\sigma_4^2} (1 - O(x)) dx$$

$$V = \sum_{i=1}^3 \int \frac{I(x)G(x)\mu_i(x)}{2\sigma_i^2} M_i(\Phi(x)) \cdot O(x) dx + \int \frac{I(x)G(x)\mu_4(x)}{2\sigma_4^2} (1 - O(x)) dx$$

1.5 算法流程

由于分割结果会受到初始化水平集的影响,采用一种有效的初始化方法,可以更快更准确地得到分割结果。首先由 OSTU 方法^[12]给出待分割区域 ROI,再采用简单的阈值法将图像分成两类:一类主要由灰质和脑脊液组成;一类主要由白质构成。假设此时的阈值为 T_1 。然后再分别用阈值 T_2 对第一类进一步分割,分别得到脑脊液、灰质和白质。这样采用 OSTU 方法和两个阈值初步将图像分成了 4 类:背景、脑脊液、灰质和白质。采用式(21)(22)定义初始水平集 $\varphi_{1,0}, \varphi_{2,0}$:

$$\varphi_{1,0}(x) = \begin{cases} c_0 & I(x) < T_1 \\ -c_0 & \text{其他} \end{cases} \quad (21)$$

$$\varphi_{2,0}(x) = \begin{cases} c_0 & \mathbf{I}(x) < T_2 \\ -c_0 & \text{其他} \end{cases} \quad (22)$$

所有实验中,时间步长取 0.1, $\lambda = 1\ 000$, $\gamma = 0.01 \times 255 \times 255$, $\nu = 1$,所有的导数采用中心差分格式。算法步骤如下:

- 1) 构造符号矩阵确定目标区域,初始化 Φ ;
- 2) 由式(16)–(19)计算各个类别的均值 μ_i 和方差 σ_i ;
- 3) 由式(20)计算基函数的参数 W ;
- 4) 利用式(14)(15)更新曲线 Φ ;
- 5) 若收敛则停止迭代,利用 $\mathbf{J} = \mathbf{I} ./ \mathbf{b}$ 得到偏移场校正图像,否则转步骤 2)。

2 实验结果与分析

本节所有实验是在 Pentium 4 处理器、512 MB 内存的联想 PC 机上用 Matlab R 2008 完成。

2.1 和 PC 模型以及四相位水平集方法比较

图 2 是用基于分段常数水平集方法、四相位水平集方法和本文方法对真实的 3T 脑 MR 图像的分割结果比较。图 2(a)是原始图像和初始曲线,该图像被偏移场干扰,导致各个类别中的灰度分布不再均匀,因此基于图像灰度分布均匀假设的分段常数的水平集方法是无法得到正确分割(图 2(b))。图 2(c)是四相位的水平集方法的分割结果,因该图像背景较大且背景灰度值几乎都等于 0,方差非常小,极易导致曲线在演化时发生错误,无法得到正确

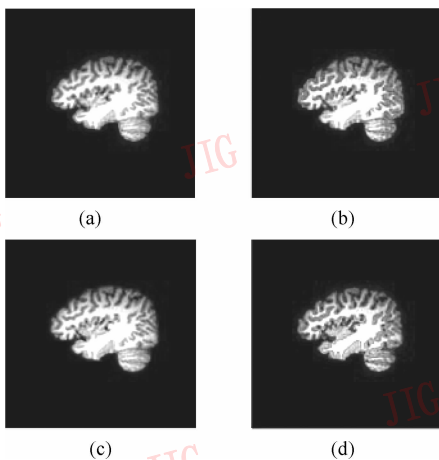


图 2 3T 脑 MR 图像的分割结果比较
Fig. 2 Comparison with segmentation results of 3T brain MR image

的分割结果。图 2(d)是本文方法得到的准确的分割结果,该结果表明本文提出的三相位水平集方法的有效性。表 1 中给出了本文方法和四相位水平集方法的时间效率,从表中可以看出,本文方法的时间效率要优于传统的四相位水平集方法。

表 1 算法时间比较

Tab. 1 Comparison of CPU time

	迭代次数				/s
	10	20	30	40	
四相位水平集方法	5.44	11.25	16.82	22.57	
本文方法	4.85	9.69	14.47	19.44	

2.2 偏移场以及恢复图像比较

为显示本文方法得到的偏移场以及恢复图像的有效性,将本文方法与 Wells 方法、Leemput 方法、Li 方法进行比较,如图 3 所示。图 3(a)是含偏移场的脑 MR 图像,图 3(b)–(e)是依次用 Wells 方法、Leemput 方法、Li 方法以及本文方法得到的偏移场。Wells 方法和 Li 方法都是利用卷积的方法来保证偏移场的光滑特性。但受到卷积模板大小的影响,这两种方法得到的偏移场不是特别光滑。而 Leemput 方法和本文方法都是利用光滑基函数拟合的方法,所以能很好的保证偏移场是平滑的特性。与

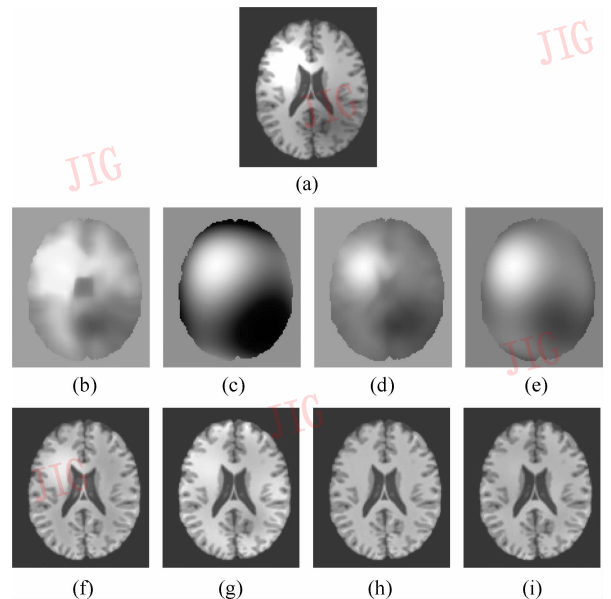


图 3 含 60% 偏移场的脑 MR 轴向图偏移场校正结果
Fig. 3 Bias correction results of brain MR image with 60% bias field

Leemput 方法得到的偏移场相比,本文方法得到的偏移场更符合偏移场缓慢变化的特性。此外,本文方法不需要对图像进行对数变换,分割结果更准确。第 2 行是对应的恢复图像,因本文方法得到的偏移场更准确,所以对应的恢复图像的灰度分布也更均匀。

2.3 分割精度比较

为了比较本文方法与其他方法得到的分割结

果的精确度,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 数据库中 30 幅轴向图做定量分析。为方便比较,用 80、160、240 分别代表分割结果中脑脊液、灰质、白质的灰度值。图 4(a) 分别是含 3% 随机噪声 60% 偏移场、3% 随机噪声 100% 偏移场以及 5% 随机噪声 100% 偏移场的脑 MR 图像。




图 4 BrainWeb 数据库中 3 类脑 MR 图像的分割结果

Fig. 4 Segmentation results of three categories brain MR images from BrainWeb

从图 4 中可以看出随着偏移场和噪声变大, Wells 方法和 Leemput 方法的分割结果会变差, Li 方法虽然能克服噪声的影响但因其只采用 K 近邻作为分割度量,在细长结构区域分割效果不是很好。本文方法在分割时还考虑了区域的方差信息,所以分割结果比 Li 方法得到的结果更好。为定量分析分割效果,采用 Jaccard similarity (JS) 指标来判断分割的精度^[13]:

$$J(S_1, S_2) = \frac{|S_1 \cap S_2|}{|S_1 \cup S_2|} \quad (23)$$

式中, S_1 是利用方法获得的分割结果, S_2 是真实的分割结果。该指标越高则意味着算法的性能越好。分割精度如表 2 所示,从表 2 中可以看出本文方法的分割精度优于其他方法的分割精度。

表 2 4 种方法的分割精度

Tab. 2 Segmentation accuracy of four methods

图像	组织	方法				/%
		Wells	Leemput	Li	本文	
3% 噪声	白质	84	85	90	94	
60% 偏移场	灰质	77	77	84	87	
3% 噪声	白质	82	83	86	92	
100% 偏移场	灰质	74	75	79	86	
5% 噪声	白质	77	79	82	90	
100% 偏移场	灰质	71	75	80	85	

2.4 3D 分割结果显示

图 5 显示的是本文方法得到的 3D 图像的分割

结果。3D 图像大小为 $181 \times 217 \times 181$ 。这说明本文方法可以应用于高维图像的分割中去。




图 5 3 维分割结果

Fig. 5 Segmentation results of 3D image

3 结 论

首先构造一组基函数拟合偏移场,再将其融入统计分类方法中得到脑 MR 图像分割和去偏移场模型,最后在 3 相位水平集框架下实现同时图像分割和偏移场计算。该方法不但能保证偏移场的光滑特性,还可避免噪声对分割结果的影响。实验表明本文方法分割精度较其他方相比法有了进一步的提高,而且利用计算出的光滑偏移场得到的恢复图像的灰度分布更加均匀。

参考文献 (References)

- [1] Wang Y, Adali T, Kung S Y, et al. Quantification and segmentation of brain tissues from MR images: a probabilistic neural network approach [J]. IEEE Transactions on Image Processing, 1998, 7(8) : 1165-1181.
- [2] Belaroussi B, Milles J, Carne S, et al. Intensity non-uniformity correction in MRI: Existing methods and their validation [J]. Medical Image Analysis, 2006, 10(2) : 234-246.
- [3] Wells III, Grimson W, Kikinis R, et al. Adaptive segmentation of MRI data [J]. IEEE Transactions on Medical Imaging, 2002, 15(4) : 429-442.
- [4] Van Leemput K, Maes F, Vandermeulen D, et al. Automated model-based bias field correction of MR images of the brain [J]. IEEE Transactions on Medical Imaging, 2002, 18(10) : 885-896.
- [5] Mohamed Ahmed, Sameh Yamany, Nevin Mohamed, et al. A modified fuzzy C-Means algorithm for bias estimation and segmentation of MRI data [J]. IEEE Transactions on Medical Imaging, 2002, 21(3) : 193-199.
- [6] Li C, Huang R, Ding Z, et al. A variational level set approach to segmentation and bias correction of medical images with intensity inhomogeneity [C] // Proceedings of Medical Image Computing and Computer Aided Intervention (MICCAI, 2008). New York City, USA: Springer Press, 2008 : 1083-1091.
- [7] Wang L, Li C, Sun Q, et al. Brain MR image segmentation using local and global intensity fitting active contours/surfaces [C] // Proceedings of Medical Image Computing and Computer Aided Intervention (MICCAI, 2008). New York City, USA: Springer Press, 2008 : 384-392.
- [8] Li Jun, Yang Xin. A fast level set approach to image segmentation based on Mumford-Shah model [J]. Chinese Journal of Computers, 2002, 25 (11) : 1175-1183. [李俊, 杨新. 基于 Mumford-Shah 模型的快速水平集图像分割方法 [J]. 计算机学报, 2002, 25(11) : 1175-1183.]
- [9] 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.
- [10] Li C, Gatenby C, Wang L, et al. A robust parametric method for bias field estimation and segmentation of MR images [C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR, 2009). Miami, Florida, USA: IEEE Press, 2009 : 218-223.
- [11] Li C, Xu C, Gui C, et al. Level set evolution without re-initialization: a new variational formulation [C] // Proceedings of IEEE Conference on Computer Vision and Pattern Recognition (CVPR, 2005). San Diego, CA, USA: Springer Press, 2005 : 430-436.
- [12] Ostu N. A threshold selection filter from grey level histogram [J]. Automatica, 1975, 11 : 285-296
- [13] Vovk U, Pernus F, Likar B. A review of methods for correction of intensity inhomogeneity in MRI [J]. IEEE Transactions on Medical Imaging, 2007, 26(3) : 405-421.