

文章编号 1004-924X(2014)12-3435-08

## 结合概率密度函数和主动轮廓模型的磁共振图像分割

刘建磊<sup>1,2\*</sup>, 隋青美<sup>1</sup>, 朱文兴<sup>1</sup>

(1. 山东大学控制科学与工程学院, 山东 济南 250061; 2. 山东交通学院轨道交通学院, 山东 济南 250357)

**摘要:** 为了提高大脑磁共振图像的分割精度, 提出了一种新的图像分割算法。首先, 分析了常用于大脑磁共振图像分割的高斯混合模型和主动轮廓模型的优缺点, 联合高斯混合模型的概率密度函数和主动轮廓模型的能量函数构造了一个新的能量函数。然后, 利用遗传算法和最大期望算法获取概率密度函数的参数值。最后, 利用水平集方法和梯度下降法, 对获得的能量函数进行最小化, 从而得到最终的分割结果。与传统方法相比, 本文算法对脑组织中的白质和灰质的分割精度分别提高了 6.73% 和 14.07%。该算法利用像素点的区域信息和概率值驱动主动轮廓曲线的演化, 能有效区分具有相近灰度值的不同区域, 从而提高了大脑磁共振图像的分割精度。

**关键词:** 磁共振图像分割; 遗传算法; 概率密度函数; 主动轮廓模型

**中图分类号:** TP391; R445.2 **文献标识码:** A **doi:** 10.3788/OPE.20142212.3435

## MR image segmentation based on probability density function and active contour model

LIU Jian-lei<sup>1,2\*</sup>, SUI Qing-mei<sup>1</sup>, ZHU Wen-xing<sup>1</sup>

(1. School of Control Science and Engineering, Shandong University, Jinan 250061, China;

2. School of Rail Transit, Shandong Jiaotong University, Jinan, 250357, China)

\* Corresponding author, E-mail: jianleiliu2008@hotmail.com

**Abstract:** To improve the segmentation precision of brain Magnetic Resonance(MR) imaging, a novel brain tissue automated segmentation method was proposed. Firstly, the merits and demerits of Gaussian mixture model and active contour model used for MR image segmentation were analyzed, and a new energy function was constructed through combining the probability density function of the Gaussian mixture model with the energy function of the active contour model. Then, the genetic algorithm and expectation maximization algorithm were used to get the parameter values of the probability density function. Finally, segmentation results were achieved through minimizing the novel energy function by using the level set method and the gradient descent algorithm. The experiment results clearly indicate that the segmentation accuracies of white matter and gray matter in brain tissue by the proposed method are increased by 6.73% and 14.07%, respectively as compared with that of the traditional

收稿日期: 2014-08-19; 修订日期: 2014-09-11.

基金项目: 国家自然科学基金资助项目(No. 61174054)

methods. By using the area information and probability values of pixel points to drive the active contour curve, the proposed method automatically segments the brain MR image with high enough accuracy and improves the segmentation accuracy of brain MR images.

**Key words:** Magnetic Resonance (MR) image segmentation; genetic algorithm; probability density function; active contour model

## 1 引言

精确地分割出大脑磁共振图像中的灰质 (Gray Matter, GM) 和白质 (White Matter, WM), 将为相关疾病的发展提供宝贵的量化指标。手工分割不仅费时, 而且分割精度也很难保证<sup>[1]</sup>。因此, 磁共振图像的全自动分割技术成为国内外学者研究的热点和难点<sup>[2-3]</sup>。目前, 常用的大脑磁共振图像分割技术主要包括基于高斯混合模型的方法<sup>[4-7]</sup>和基于主动轮廓模型的方法<sup>[2, 8-9]</sup>。在基于高斯混合模型的方法中, 由 Jussia 等提出的 GA\_EM (Genetic Algorithms-Expectation Maximization) 算法<sup>[6]</sup>得到了广泛的认可。该方法利用遗传算法和最大期望算法, 求解高斯混合模型中各分量的参数值, 有效地降低了分割结果对各分量参数初始值的敏感度, 从而实现了大脑磁共振图像的全自动分割。但该方法仅根据像素点的灰度值对其逐一分类, 容易产生“颗粒”现象。在基于主动轮廓模型的方法中, 文献[8]提出的无边缘主动轮廓 (Chan\_vede, CV) 模型是利用像素点的区域信息分割图像的, 从而可以有效抑制噪声和“颗粒”现象, 但该方法很难有效分割灰度值相近的两类区域。

基于以上分析, 本文提出了一种新的磁共振图像分割算法。该算法将高斯混合模型中的概率密度函数与主动轮廓模型中的能量函数相结合, 构建了一个新的能量函数, 通过分层最小化, 该能量函数可以实现大脑磁共振图像的自动、精确分割。

## 2 传统的大脑磁共振图像分割算法

### 2.1 基于高斯混合模型的分割算法

大脑磁共振图像由 GM、WM 和脑脊液 (CSF) 三类子区域组成, 假设每个区域中像素点的灰度值符合高斯分布 (独立同分布), 则其数据模型<sup>[6]</sup>可由高斯混合模型<sup>[10-11]</sup>表示为:

$$\begin{cases} f(x | \Theta) = \sum_{k=1}^3 \lambda_k f_k(x | \theta_k) \\ f_k(x | \theta_k) = \frac{1}{(2\pi)^{1/2} |\Sigma_k|} \exp\left\{-\frac{(x - \mu_k)^T (x - \mu_k)}{2 \sum_k}\right\}, \end{cases} \quad (1)$$

其中:  $\Theta = \{\lambda_k, \theta_k : k=1, \dots, 3\}$ ;  $f_k(x | \theta_k)$  是概率密度函数;  $\lambda_k \in [0, 1]$  为先验概率 ( $\lambda_1 + \lambda_2 + \lambda_3 = 1$ );  $x$  表示像素点的灰度值;  $\theta_k = \{\mu_k, \Sigma_k\}$ 。式(1)的对数似然函数如式(2)所示。文献[6]提出首先利用遗传算法和 EM 算法最优化式(2)所示的表达式, 求取参数矢量  $\Theta$  的最大似然估计值。然后, 根据图像中每个像素点的灰度值, 利用贝叶斯聚类器, 判断其类别, 以完成整幅图像的分割。

$$\hat{\Theta} = \underset{\Theta}{\operatorname{argmax}} l(\Theta) = \underset{\Theta}{\operatorname{argmax}} \sum_{i=1}^N \log f(x_i | \Theta), \quad (2)$$

其中:  $x_i$  是像素点的灰度值;  $N$  是图像中像素点的个数。

### 2.2 基于无边缘主动轮廓模型的分割算法

基于图像中每个同质区域内像素点的灰度值是常数这一假设, 文献[8]定义了如下的能量函数:

$$F(C, c_1, c_2) = \int_{\operatorname{inside}(C)} |u_0(x, y) - c_1|^2 dx dy + \int_{\operatorname{outside}(C)} |u_0(x, y) - c_2|^2 dx dy, \quad (3)$$

其中:  $u_0(x, y)$  是被分割的图像;  $C$  为闭合的主动轮廓曲线;  $\operatorname{inside}(C)$  和  $\operatorname{outside}(C)$  分别代表  $C$  的内部和外部区域;  $c_1, c_2$  分别是内外部区域像素点的平均灰度值。只有当主动轮廓曲线  $C$  位于两个同质区域的边界时, 式(3)才能达到最小值。因此, 通过最小化式(3)所示的能量函数就可以实现图像的分割。

## 3 改进的 MR 图像分割算法

### 3.1 能量函数的构建

假设利用闭合的活动轮廓曲线  $C$  将定义域


为  $\Omega$  的图像  $u_0(x, y)$  划分为内部区域  $\text{inside}(C)$  和外部区域  $\text{outside}(C)$ , 内外区域像素点的平均灰度值分别为  $c_1$  和  $c_2$ , 白质和灰质的概率密度

函数分别为  $f(u_0(x, y) | \Phi_1)$  和  $f(u_0(x, y) | \Phi_2)$ , 其中,  $\Phi_1 = \{\mu_1, \sigma_1\}$ ,  $\Phi_2 = \{\mu_2, \sigma_2\}$ 。根据以上假设, 本文构建了式(4)所示的新能量函数:

$$F_1(C) + F_2(C) = \int_{\text{inside}(C)} (|u_0(x, y) - c_1|^2 / (f(u_0(x, y) | \Phi_1) + \alpha)) dx dy + \int_{\text{outside}(C)} (|u_0(x, y) - c_2|^2 / (f(u_0(x, y) | \Phi_2) + \alpha)) dx dy \quad (4)$$

其中:  $\alpha$  是一个很小的正数, 以防止除数等于零。

本文以图 1 为例说明该能量函数的原理和有效性。图 1(a) 中的圆形区域设为目标, 其他区域设为背景。当主动轮廓曲线(白色的曲线)与目标边界重合时(如图 1(a) 所示),  $c_1$  与曲线内部所有像素点的灰度值近似相等,  $c_2$  与曲线外部所有像素点的灰度值近似相等, 则  $|u_0(x, y) - c_1|^2 = |u_0(x, y) - c_2|^2 \approx 0$ , 又因为  $(f(u_0(x, y) | \Phi_1) + \alpha) > 0$  和  $(f(u_0(x, y) | \Phi_2) + \alpha) > 0$ , 所以  $F_1(C) + F_2(C) \approx 0$ , 此时式(4)的值达到最小, 通过最小化式(4)所示的能量函数, 可以实现图像的分割。



(a) 仿真图像 (b) 磁共振图像  
(a) Simulation image (b) MR image

图 1 主动轮廓曲线位置图

Fig. 1 Positions of active contour curve

当主动轮廓曲线演化至由白质到灰质的渐变区域的边界时(如图 1(b) 所示),  $|u_0(x, y) - c_1|^2$  和  $|u_0(x, y) - c_2|^2$  的值都近似等于零, 并且随着迭代的进行, 其变化幅度较小。因此, 若使用式(3)所示的能量函数驱动主动轮廓曲线, 主动轮廓曲线会在渐变区域的边界处停止演化, 从而使得分割结果不精确。

式(4)中的概率密度函数  $f(u_0(x, y) | \Phi_1)$  和  $f(u_0(x, y) | \Phi_2)$  对渐变区域内像素点的灰度值比较敏感。当主动轮廓曲线演化至由白质到灰质的渐变区域的边界时, 设  $u_0(x, y)$  是位于主动轮廓曲线外部的渐变区域内的白质像素点(如图 2(b) 中的 A 点所示), 则  $f(u_0(x, y) | \Phi_2)$  的值远小于  $f(u_0(x, y) | \Phi_1)$ , 即  $|u_0(x, y) - c_2|^2 / (f(u_0(x, y) | \Phi_2) + \alpha)$  的值远大于  $|u_0(x, y) - c_1|^2 / (f(u_0(x, y) | \Phi_1) + \alpha)$  的值。因此, 随着迭代的进行, 主动轮廓曲线会继续向渐变区域演化(扩张), 直到包含所有的白质像素点。由以上分析可知, 通过最小化式(4)所示的能量函数驱动主动轮廓曲线的演化, 可使其停止在渐变区域的中间位置, 从而提高了分割精度。

在式(4)中引入正则化项, 则构成了完整的能量函数, 如式(5)所示:

$$F(c_1, c_2, C, f(u_0(x, y) | \Phi_k)) = \omega \text{Length}(C) + \omega_1 \int_{\text{inside}(C)} (|u_0(x, y) - c_1|^2 / (f(u_0(x, y) | \Phi_1) + \alpha)) dx dy + \omega_2 \int_{\text{outside}(C)} (|u_0(x, y) - c_2|^2 / (f(u_0(x, y) | \Phi_2) + \alpha)) dx dy \quad (5)$$

其中:  $\text{Length}(C)$  是闭合主动轮廓曲线  $C$  的长度,  $\omega \geq 0$ ,  $\omega_1 > 0$ ,  $\omega_2 > 0$  是各个能量项的权重系数。

为了实现全局最优解, 水平集函数<sup>[12]</sup>  $\phi$  被引入到式(5)中:

$$F(c_1, c_2, \phi, f(u_0(x, y) | \Phi_k)) = \omega \int_{\Omega} \delta(\phi(x, y)) |\nabla \phi(x, y)| dx dy + \omega_1 \int_{\Omega} (|u_0(x, y) - c_1|^2 / (f(u_0(x, y) | \Phi_1) + \alpha)) H(\phi(x, y)) dx dy + \omega_2 \int_{\Omega} (|u_0(x, y) - c_2|^2 / (f(u_0(x, y) | \Phi_2) + \alpha)) (1 - H(\phi(x, y))) dx dy \quad (6)$$

其中:  $H(z)$  和  $\delta(z)$  分别是正则化后 Heaviside 函数和 Dirac 函数, 文献[8]给出了它们的表达式。

### 3.2 能量函数的求解

首先, 利用遗传算法和最大期望算法获取概率密度函数的参数矢量值  $\Theta = \{\lambda_k, \theta_k : k=1, \dots, 3\}$ 。然后在此基础上分两步最小化式(6)所示的能量函数:

$$\begin{cases} \frac{\partial \phi}{\partial t} = \delta(\phi) \left[ \omega \cdot \operatorname{div} \left[ \frac{\nabla \phi}{|\nabla \phi|} \right] - \omega_1 (|u_0(x, y) - c_1|^2 / (f(u_0(x, y) | \Phi_1) + \alpha)) + \omega_2 (|u_0(x, y) - c_2|^2 / (f(u_0(x, y) | \Phi_2) + \alpha)) \right] = 0 \\ \phi(x, y, 0) = \phi_0(x, y) \\ \frac{\delta(\phi)}{|\nabla \phi|} \frac{\partial \phi}{\partial n} = 0 \end{cases}, \quad (8)$$

其中:  $\mathbf{n}$  和  $\partial \phi / \partial \mathbf{n}$  分别是边界的外部法线和水平集函数在边界处的法线导数。迭代运算式(7)和式(8), 直到水平集函数收敛。这时能量函数达到最小值, 抽出零水平集, 完成分割。

通过最小化式(6)所示的能量函数, 只能将图像分成两个区域。但大脑磁共振图像由灰质、白质和脑脊液 3 个区域组成。如果基于像素的灰度值把灰质、白质和脑脊液这类 3 种物质分成两类的话, 则脑脊液属于一类, 灰质和白质属于另一类(称为脑实质)。基于此, 本文提出了双层的大脑磁共振图像分割方法。首先通过最小化式(6)所示的能量函数实现脑脊液的分割; 然后, 再次最小化式(6)实现灰质和白质的分割。本文算法的具体步骤如下:

(1) 利用基于实编码的遗传算法<sup>[6]</sup>和最大期望算法获取每类组织(灰质、白质和脑脊液)的概率密度函数的参数值, 它们分别是:  $\Phi_{gm} = \{\lambda_{gm}, \mu_{gm}, \sigma_{gm}\}$ 、 $\Phi_{wm} = \{\lambda_{wm}, \mu_{wm}, \sigma_{wm}\}$  和  $\Phi_{csf} = \{\lambda_{csf}, \mu_{csf}, \sigma_{csf}\}$ 。

(2) 初始化主动轮廓曲线, 并设定  $\Phi_1 = \{\mu_{csf}, \sigma_{csf}\}$ ,  $\Phi_2 = \left\{ \frac{\lambda_{gm}\mu_{gm} + \lambda_{wm}\mu_{wm}}{\lambda_{gm} + \lambda_{wm}}, \frac{\lambda_{gm}\sigma_{gm} + \lambda_{wm}\sigma_{wm}}{\lambda_{gm} + \lambda_{wm}} \right\}$ 。

(3) 迭代运算式(7)和式(8), 直到水平集函数收敛, 抽出零水平集, 完成脑脊液的分割。

(4) 在背景区域内初始化主动轮廓曲线, 并设定  $\Phi_1 = \{\mu_{wm}, \sigma_{wm}\}$ ,  $\Phi_2 = \{\mu_{gm}, \sigma_{gm}\}$ 。

(5) 迭代运算式(7)和式(8), 直到水平集函数

Step 1. 固定水平集函数不变, 利用下式计算  $c_1$  和  $c_2$  的值:

$$\begin{cases} c_1(\phi) = \text{average}(u_0) \text{ in } \{\phi \geq 0\} \\ c_2(\phi) = \text{average}(u_0) \text{ in } \{\phi < 0\} \end{cases}, \quad (7)$$

Step 2. 固定  $c_1$  和  $c_2$  的值不变, 利用梯度下降法最小化式(6)所示的能量函数, 可得到水平集函数  $\phi$  的欧拉拉格朗日方程:

收敛, 抽出零水平集, 完成整个大脑图像的分割。

## 4 实验结果与分析

在本小节中, 通过三部分验证算法有效性数据: 模拟数据、由 Massachusetts General Hospital 的形态特征分析(Morphometrics Analysis)中心提供的 Internet Brain Segmentation Repository (IBSR) 真实大脑磁共振数据(含有 18 个成人的数据)和实际扫描的数据。通过模拟数据可以精确获取灰质、白质和脑脊液的位置; IBSR 数据含有专家手工分割的结果。在本实验中, 这两部分数据用来定量比较分割算法的性能; 实际扫描的数据由于没有标准的分割结果, 因此用来定性比较分割算法的性能。在本文提出的算法中, 为了使式(4)所示的两个数据项具有相同的权重, 同时加快主动轮廓曲线的演化速度, 设定  $\omega_1 = \omega_2 = 10$ 。为了简化算法, 将时间步长和空间步长均设为 1; 分别将  $\omega$  和  $\alpha$  的值经验性地设定为 300 和 0.01。

### 4.1 分割算法性能的定性比较

图 2 给出了 CV 模型, FGCMAC 算法<sup>[13]</sup>、ACSEE 算法<sup>[14]</sup>、GA\_EM 算法和本文算法的分割比较结果。第一列是原图像, 第二列是 CV 模型的分割结果, 第三列是 FGCMAC 算法的分割结果, 第四列是 ACSEE 算法的分割结果, 第五列是 GA\_EM 算法的分割结果, 最后一列是本文算法的分割结果。从分割结果可以看出, CV 模型没有有效地区分开脑脊液和灰质, 以及灰质和白

质,这是因为无论是在脑脊液与灰质的交界处,还是白质和灰质的交界处它们之间的灰度值差别都较小,故随着迭代的进行, CV 模型中的演化曲线会逐渐划过灰度值相似的边界,从而导致分割精度的降低。FGCMAC 算法通过同时演化 2 个主动轮廓实现大脑磁共振图像的分割,虽然其分割效果优于 CV 模型,但该算法没有从根本上克服 CV 模型所具有的缺点,在分割结果中,很多灰质被分割为了脑脊液。ACSEE 算法在主动轮廓模型中引入了一个突出边缘能量项,该能量项在增

强分割区域联通性的同时,降低了分割细小目标的能力,在分割结果中可以看出,很多细小的脑脊液区域被分割成了灰质。GA\_EM 算法通过逐一判断像素点的后验概率实现图像分割,没有考虑同质区域内像素点的联通性,使得灰度值改变较大的像素点会被错误划分,从而容易产生“颗粒”现象。由于本文算法是利用图像像素点的区域信息和概率值驱动主动轮廓曲线的演化的,因此保持了 CV 模型和 GA\_EM 算法的优点,与上述 4 种分割算法相比,具有最优的分割精度。






图 2 磁共振图像的分割比较结果

Fig. 2 Comparison of segmentation results of MR images



(a)原图像

(a)Original image



(b)脑脊液的分割结果

(b)Segmentation results of cerebrospinal fluid



(c) 灰质的分割结果

(c) Segmentation results of gray matter



(d) 白质的分割结果

(d) Segmentation results of white matter

图 3 脑脊液、灰质和白质的分割比较结果

Fig. 3 Comparison of segmentation results for cerebrospinal fluid, gray matter and white matter

为进一步比较上述 5 种算法的分割性能,图 3(b)~3(d)分别给出了脑脊液、灰质和白质的分割结果。在图 3(b)~3(d)中,从第一列到第五列分别是 CV 模型、FGCMAC 算法、ACSEE 算法、GA\_EM 算法和本文算法的分割结果,原图像如图 3(a)所示。从图 3 所示的分割结果可以看出, CV 模型、FGCMAC 算法、ACSEE 算法和 GA\_EM 算法 4 种分割方法对脑脊液和白质的分割都远远超出了其实际区域,分割精度较低;而本文算法的分割精度与上述 4 种算法相比有着显著改善。

在本文提出的分层分割算法中,第一次最小化式(6)所示能量函数的分割目标是脑脊液,背景是脑实质(包含灰质和白质),脑脊液的分割结果如图 3(b)中的最后一列所示。在脑实质区域再一次最小化该能量函数,则可以将脑实质区域分割为灰质(图 3(c)中的最后一列)和白质(图 3(d)中的最后一列)。

#### 4.2 分割算法性能的定量比较

本文使用 Dice 统计方法定量比较 CV 模型, FGCMAC 算法、ACSEE 算法、GA\_EM 算法和本文算法的分割性能。Dice 统计方法的定义如下:

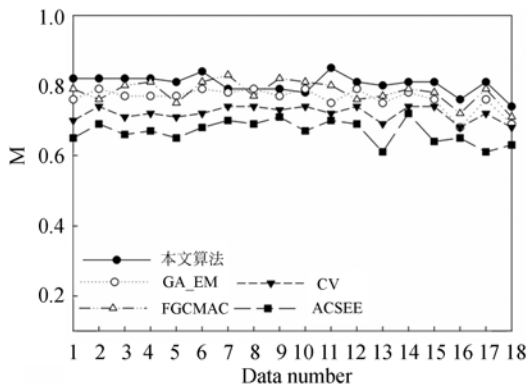
$$M^k = \frac{2V_{ae}^k}{(V_a^k + V_e^k)}$$

其中:  $V_{ae}^k$  表示对于第  $k$  类组织分割算法的结果和

专家手工分割的结果中重合像素的个数。  $V_a^k$  和  $V_e^k$  分别表示分割算法得到的第  $k$  类组织像素点的个数和专家手工分割得到的第  $k$  类组织像素点的个数。在本实验中,  $M$  表示分割精度,  $M$  的值越大,表示算法的分割精度越高。

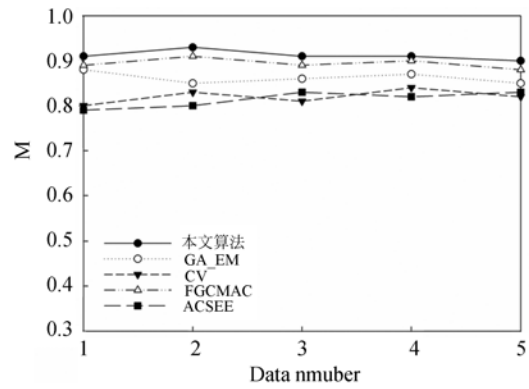
图 4 是 IBSR 数据的定量比较结果。图 4(a)是白质分割精度( $M$ )的比较结果;图 4(b)是灰质分割精度( $M$ )的比较结果;图 4(c)是 18 个大脑数据平均耗时的分割比较结果。图 4 中的横轴是数据库中的数据编号,数据库中一共含有 18 个大脑的数据。从统计结果可以看出,与 CV 模型, FGCMAC 算法、ACSEE 算法、GA\_EM 算法相比,本文算法对白质和灰质的分割精度平均提高了 7.01% 和 15.95%。从耗时的比较结果中可以看出,本文算法的平均耗时约为 CV 模型和 GA\_EM 算法耗时之和, FGCMAC 算法的耗时最低,约为本文算法的 1/7。

图 5 是 5 组模拟数据的定量比较结果。图 5(a)是白质分割精度( $M$ )的比较结果;图 5(b)是灰质分割精度( $M$ )的比较结果。图 5 中的横轴是模拟数据的编号。从实验结果可以看出,对于模拟数据本文算法的分割精度也优于其他 4 种分割方法,白质和灰质的分割精度平均提高了 6.45% 和 12.2%。由图 4 和图 5 所示的定量比较结果可知,与传统方法相比,本文算法对白质和灰质的




(a) 白质分割结果

(a) Segmentation results of white matter




(a) 白质分割结果

(a) Segmentation results of white matter



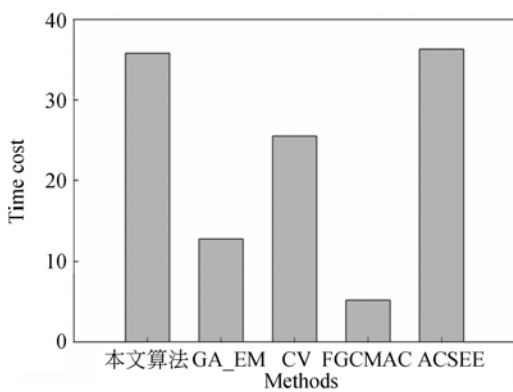
(b) 灰质分割结果

(b) Segmentation results of gray matter



(b) 灰质分割结果

(b) Segmentation results of white matter



(c) 耗时比较结果

(c) Comparison results of time cost

图 4 IBSR 数据分割结果的比较

Fig. 4 Comparison of IBSR data segmentation results

图 5 模拟数据分割结果比较

Fig. 5 Comparison of simulation data segmentation results

分割精度分别提高了 6.73% 和 14.07%。

从定性和定量的比较实验中可以看出, 与其他算法相比, 本文算法虽然具有较高的时间复杂度, 但分割精度最高, 而临床应用中对于大脑的分割并不苛求实时完成。因此, 本文算法具有较强的实际应用价值。本文算法是基于大脑磁共振图像数据符合高斯分布这一假设提出的, 对于不符合这一假设的大脑磁共振图像的分割效果并不理想。

### 5 结 论

为了精确地分割大脑磁共振图像, 本文在详细分析高斯混合模型和主动轮廓模型优缺点的基

基础上,提出了一种新的分割算法。新算法同时利用了两种模型的优点,有效克服了两种模型单独使用时的缺点。本文算法通过分层最小化一个新建的能量函数来实现磁共振图像的精确分割。实验结果表明,与传统的分割算法相比,本文算法对白质和灰质的分割精度分别提高了 6.73%和 14.07%。

T1 加权的大脑磁共振图像主要用来观察大脑的解剖组织结构。在 T1 加权成像中,人体各组织的 T1 值越小,其 MR 信号强度越大。脑脊液、灰质和白质 3 种组织相比较,脑脊液的 T1 值最大、灰质的次之,白质的最小,并且灰质与白质

T1 值的差别要小于灰质与脑脊液的 T1 值的差别。这些特征反应在 T1 加权图像中,则是脑脊液的灰度值最小,灰质次之,白质最大。另外,本文假设这 3 种组织的数据符合高斯分布,其数据模型可由高斯混合模型表示。本文算法是基于 T1 加权图像的上述特征设计的,而在临床中用来显示病变组织的 T2 加权图像,具有与 T1 加权图像不同的灰度值特征,其灰度值的大小与人体各组织的 T2 值有关,T2 值越大,灰度值越高。因此,本文提出的算法不适合于 T2 加权大脑磁共振图像,提出有效的 T2 加权大脑磁共振图像的分割算法将是下一步工作。

#### 参考文献:

- [1] TIAN G, XIA Y, ZHANG Y, *et al.*. Hybrid genetic and variational expectation-maximization algorithm for Gaussian-mixture-model-based brain MR image segmentation [J]. *IEEE Transactions on Information Technology in Biomedicine*, 2011, 15(3): 373-380.
- [2] SHYU K K, PHAM V T, TRAN T T, *et al.*. Unsupervised active contour driven by density distance and local fitting energy with applications to medical image segmentation [J]. *Machine Vision and Applications*, 2012, 23(6): 1159-1175.
- [3] 汪源源,原宗良,唐三. 利用自适应纹理分布的活动形状分割前列腺磁共振图像[J]. *光学精密工程*, 2013, 21(9): 2371-2380.
- WANG Y Y, YUAN Z L, TANG S. Segmentation of prostate magnetic resonance image with active shape of adaptive texture distribution [J]. *Opt. Precision Eng.*, 2013, 21(9): 2371-2380. (in Chinese)
- [4] ZHOU Y, BAI J. Atlas-based fuzzy connectedness segmentation and intensity nonuniformity correction applied to brain MRI [J]. *IEEE Transactions on Biomedical Engineering*, 2007, 54(1): 122-129.
- [5] BAZIN P L, PHAM D L. Topology preserving tissue classification of magnetic resonance brain images [J]. *IEEE Trans. Med. Imag.*, 2007, 26(4): 487-496.
- [6] TOHKA J, KRESTYANNILOV E, DINOVI, I D, *et al.*. Genetic algorithms for finite mixture model based voxel classification in neuroimaging [J]. *IEEE Transactions on Medical Imaging*, 2007, 26(5): 696-711.
- [7] 王醒策,文蕾,武仲科,等. 面向时飞磁共振血管造影术的脑血管统计分割混合模型[J]. *光学精密工程*, 2014, 22(2): 497-507.
- WANG X C, WEN L, WU ZH K, *et al.*. Finitermixtuer model of stochastic cerebrovascular segmentation based on TOF MRA [J]. *Opt. Precision Eng.*, 2014, 22(2): 497-507. (in Chinese)
- [8] CHAN T, VESE L A. Active contours without edges [J]. *IEEE Transactions on Image Processing*, 2001, 10(2): 266-277.
- [9] HUANG A, ABUGHARBIEH R, TAM R, *et al.*. A hybrid geometric-statistical deformable model for automated 3-D segmentation in brain MRI [J]. *IEEE Transactions on Biomedical Engineering*, 2009, 56(7): 1838-1847.
- [10] CHOI H S, HAYNOR D R, KIM Y. Partial volume tissue classification of multichannel magnetic resonance images-A mixel model [J]. *IEEE Transactions on Medical Image*, 1991, 10(3): 395-407.
- [11] 吴迪,曹洁,王进花. 基于自适应高斯混合模型与静态听觉特征融合的说话人识别[J]. *光学精密工程*, 2013, 21(6): 1598-1604.
- WU D, CAO J, WANG J H. Speaker recognition based on adapted Gaussian mixture model and static and dynamic auditory feature fusion [J]. *Opt. Preci-*

- sion Eng.*, 2013,21(6):1598-1604. (in Chinese)
- [12] 姜慧研,冯锐杰. 基于改进的变分水平集和区域生长的图像分割方法的研究[J]. 电子学报,2012,40(8):1659-1664.
- JIANG H Y, FENG R J. Image segmentation method research based on improved variational level set and region growth [J]. *Acta Electronica Sinica.*, 2012,40(8):1659-1664. (in Chinese)
- [13] MORENO J C, SURYA P V B, PEROENCA H, *et al.*. Fast and globally convex multiphase active contours for brain MRI segmentation[J]. *Computer Vision and Image Understanding*, 2014, (125):237-250.
- [14] KIM W, KIM C. Active contours driven by the salient edge energy model [J]. *IEEE Transactions on Image Processing*, 2013, 22(4):1667-1673.

#### 作者简介:



刘建磊(1981—),男,山东济宁人,博士,2012年于西安电子科技大学获得博士学位,主要研究方向为医学图像处理、模式识别和智能交通。E-mail: jianleiliu2008@hotmail.com



隋青美(1963—),女,山东东营人,博士,教授,博士生导师,1983年、1986年于山东工业大学分别获得学士、硕士学位,2001年于天津大学获得博士学位,主要从事检测理论与应用,光纤传感技术等方面的研究。E-mail: qm-sui@sdu.edu.cn

(本栏目编辑:李自乐)  
(版权所有 未经许可 不得转载)