

## 基于超椭球模糊聚类的人脑磁共振图象分割<sup>\*</sup>

梁夷龙<sup>1</sup> 王松<sup>1</sup> 夏绍玮<sup>1</sup> 王子罡<sup>2</sup>

<sup>1</sup>(清华大学自动化系 北京 100084)

<sup>2</sup>(清华大学计算机科学与技术系 北京 100084)

E-mail: swxia@mail. tsinghua. edu. cn

**摘要** 通常使用的聚类分割方法认为样本的分布是超球形的,然而,这并不符合人脑磁共振 MR(magnetic resonance)图象的真正特点. 针对这一缺陷,提出了一种基于超椭球模糊聚类的人脑 MR 图象分割方法. 实验结果表明,这种分割方法能有效地将人脑 MR 图象分割为灰质和白质两种组织,并具有较高的效率和分割精度.

**关键词** MR(magnetic resonance)图象分割,自适应阈值,高斯滤波,超椭球模糊聚类.

**中图法分类号** TP391

人脑 MR(magnetic resonance)图象分割的目的在于,把图象划分出几个感兴趣的组织和区域,以进行三维重构和显示. 图象分割的方法有基于边缘、基于区域和基于像素分类等多种.<sup>[1]</sup>人脑 MR 图象分割的难点在于伪影、部分容量和噪声对图象的影响较大. 和普通图象分割相比较,多尺度特性是 MR 图象的优势所在,因此,基于像素分类的分割算法较之基于边缘和基于区域的分割算法在 MR 图象分割领域具有一定的优越性.

针对人脑 MR 图象的特点,本文提出了一种新的基于像素分类的超椭球模糊聚类分割方法. 首先,要找出大脑定位的轮廓线,在每层二维 MR 图象切片上,由图象四周沿径向向内搜索,使用分块自适应阈值法提取头部外轮廓. 然后由内向外沿径向搜索,利用自适应阈值法提取大脑的轮廓. 本文采用了轮廓像素的连通性作为自适应阈值寻优的标准. 上述算法实现了对大脑的定位,并克服了背景噪声的影响. 其次,要分割出大脑内部的不同组织,包括灰质和白质等. 由于这些组织是互相交叉在一起的,使用基于区域和边缘的算法实现起来比较困难,也难以获得较高的分割精度. 为了能够反映各像素的邻域和位置特性,我们对整个三维 MR 图象数据集合进行了三维高斯滤波,将滤波结果和像素点的灰度值合在一起,构成像素点的特征向量,然后采用超椭球模糊聚类对每一层二维 MR 图象切片进行分割,将大脑分割为白质和灰质两种组织.

### 1 头皮和大脑轮廓的提取

设待处理的人脑 MR 图象数据集为  $I = \{I_k(i, j) | 1 \leq I_k(i, j) \leq M, 1 \leq i, j \leq N, 1 \leq k \leq K\}$ . 其中元素  $I_k(i, j)$  表示第  $k$  层切片上坐标为  $(i, j)$  的像素的灰度. 每一层切片大小为  $N \times N$ , 共有  $K$  层, 灰度等级为  $M$ . 本文所处理的图象数据集是  $M=256, N=256, K=54$  的轴向人脑 MR 图象. 由于伪影的影响,使得图象中同一组织像素的灰度不仅在同一层中数值大小不同,分布不均匀,而且在不同层之间的分布也不均匀. 中间切片图象的灰度比较适中,灰质和白质的对比明显,而上部和下部的图象的灰度值偏高或偏低,灰质和白质的对比不明显. 这使得中间部分图象的分割相对容易. 针对这些特点,我们采用聚类的方法对图象进行了分割,聚类在二维 MR 图象切片上进行,然后将每次聚类的结果作为初始点分别向上部和下部逐层传递.

在人脑 MR 图象中,最令人感兴趣的区域是大脑部分. 为了对大脑部分的图象采用聚类的方法进行分割,需要对大脑进行精确的定位,将大脑从原始的人脑 MR 图象切片中提取出来. 这就需要进行预处理,提取出头部外缘和大脑的轮廓. 当然,头部外缘和大脑的轮廓线对于三维可视化也是必不可少的. 对于轮廓提取,通常是采用各种边缘检测算

\* 本研究得到国家自然科学基金和国家 863 高科技项目基金资助. 作者梁夷龙,1973 年生,博士生,主要研究领域为模式识别,图象处理,神经网络. 王松,1972 年生,博士生,主要研究领域为模式识别,图象处理. 夏绍玮,女,1932 年生,教授,博士生导师,主要研究领域为大系统理论与应用,智能决策系统. 王子罡,1972 年生,博士生,主要研究领域为计算机图形学, CAD.

本文通讯联系人:梁夷龙,北京 100084,清华大学自动化系

本文 1998-02-28 收到原稿,1998-04-20 收到修改稿

子对整幅图象进行卷积处理,从而检测出边缘.再使用轮廓跟踪等方法来提取出封闭的轮廓线.<sup>[2]</sup>但是,由于伪影象、部分容量以及噪声等的影响,MR 图象的灰度分布很不均匀,使用边缘检测算子会产生太多的碎片,难以分辨出所需要的边缘.阈值法是一种简单易行的轮廓边缘提取算法.但是为了克服伪影象的影响,对整幅图象不能采用同样的阈值,而是要在不同的区域采用不同的阈值,为此,我们采用分块自适应阈值算法.

首先是对头部外轮廓线的提取.图 1 是位于中部的第 31 层人脑 MR 图象的切片,其余的 MR 图象切片的物质分布与此相类似.在图中沿径向从头部外缘向外搜索便是图象的背景.因此,可以从其外侧的背景开始向内搜索,确定最先遇到的非背景象素为头的外轮廓边缘.为此,需要确定一个介于背景灰度和头皮灰度之间的一个阈值.同时,由于伪影象的影响,同一组织的灰度在不同位置上会有一些差别.因此,可以先把整幅图象划分为几个子图象,在每个子图象中自适应地确定各自的阈值,从而提高分割的精度.为提高运算速度和减少存储开支,头部外轮廓的提取分别在每一层二维 MR 图象切片中进行.






图 1 第 31 层人脑 MR 图象切片

图 2 人脑 MR 分块图象

图 3 第 31 层切片的头部外轮廓

在第  $k$  层切片  $I_k = \{I_k(i, j) | 1 \leq i, j \leq N\}$  头皮轮廓线提取算法中,首先以中心点为圆心,以角度  $2\pi/n$  将  $I_k$  均匀地  $n$  等分为扇形子图象,依次记作  $SI_{k1}, SI_{k2}, \dots, SI_{kn}$  (如图 2 所示).对每一个子图象  $SI_{ki}$ ,作如下处理.

- (1) 初始化阈值为可能的最低阈值  $M_0$ ;
- (2) 从  $SI_{ki}$  中每一个图象边缘象素  $p, 1 \leq p \leq P$  (所有横坐标或者纵坐标为 1 或  $N$  的象素) 沿径向向圆心搜索.记达到阈值  $M_0$  的第 1 个象素点的坐标为  $SI_{ki}(p)$ ;
- (3) 评价由象素  $SI_{ki}(p), 1 \leq p \leq P$  构成的曲线段的连通性.若符合要求,则当前阈值确定为该子图象的阈值,二值化该子图象,记为  $SI'_{ki}$ ,结束.否则,转下步;
- (4) 阈值递增一个单位,分别从象素  $SI_{ki}(p), 1 \leq p \leq P$  开始继续沿径向向圆心搜索.记达到当前阈值的第 1 个象素的坐标,并以其更新  $SI_{ki}(p)$ ;转(3).

本文采用的曲线段的连通性定义为 8 连通.将得到的各分块子图象的二值化结果合并为整幅的二值化图象,然后利用轮廓跟踪方法即得到头部的外轮廓线(如图 3 所示).由于背景中的噪声点和实际轮廓线的距离较远,若将噪声点归为轮廓线上的点,其连通性的评价必然不符合要求,因此,通过自适应阈值寻优的方法,可以有效地消除背景噪声的影响.

对大脑轮廓线的提取,其算法基本和提取头皮轮廓的算法相似.不同之处只是其搜索方向相反,即搜索方向为从中心点沿径向向外,同时,阈值改为递减变化,得到的大脑轮廓线如图 4 所示.用得到的大脑轮廓线与原 MR 图象相对照,就可以提取出大脑部分的图象(如图 5 所示).下一步对大脑进行分割时,就不再需要考虑介于头皮和大脑之间的其他部分,如眼窝、鼻腔、耳朵等.

用得到的所有二维切片的头部外轮廓线进行三维重构即可得到人头部的外观(如图 6 所示);同样,用所有二维切片的大脑轮廓线进行三维重构,即得到大脑的外形.经过上述预处理方法提取出了人脑 MR 图象中的大脑部分,记作  $B = \{B_k | 1 \leq k \leq K\}$ ,以进行下一步的特征提取和聚类分析.

## 2 大脑内部的特征提取

大脑的内部是相对复杂的.主要的组成部分有灰质和白质等.各部分相互交叉,伪影象严重.采用阈值法,往往只考虑象素的灰度值这一个特征,而没有把象素点的位置和邻域特性考虑进去,难以获得理想的结果.为了实现对大

脑图象的自动分割,通常采用聚类的方法,将大脑中所有的象素点聚成指定的几类.本文所要实现的是将大脑分割为白质和灰质两种组织,因此,聚类的类别数为 2,或者按灰度先聚成 3~4 类,最终再合并为两类.这里主要考虑的是特征提取和聚类方法的设计.





图 4 第 31 层切片的大脑轮廓

图 5 第 31 层切片的大脑部分

图 6 头部外轮廓的三维重构结果

文献[3]中对原始的 MR 图象进行多尺度分析和主成分分析来提取特征.然而它未曾先将大脑提取出来,而是对整幅 MR 图象包括背景一起进行处理.这样,将大脑内外的物质混合处理,进行分割时难以获取高精度的结果.本文只对上面提取出的大脑部分  $B = \{B_k | 1 \leq k \leq K\}$  进行处理,从而可以获取更为精确的分割结果.同时,文献[3]中提取出的特征因维数较高,先使用了主成分分析,对特征进行了降维处理.但是,由第 4 节中的实验可以看到,对于人脑 MR 图象,选择较高的特征维数分割效果并不好,且使运算量加大.经过综合考虑,对于  $B_k$  中的象素点,本文所选择的特征是:(1)象素点的灰度值.(2)用  $3 \times 3 \times 3$  的高斯滤波器对象素点的灰度值进行三维滤波所得到的滤波值.(3)用  $5 \times 5 \times 5$  的高斯滤波器对象素点的灰度值进行三维滤波所得到的滤波值.

这里,考虑到象素的位置和邻域特性以及图象的整体性,对图象进行了三维高斯滤波.  $B_k(i, j) \in B_k$  为要进行滤波的象素.以该象素为中心,  $n \times n \times n$  ( $n=3$  或  $5$ ) 范围内所有象素的集合为  $R_n(i, j, k) = \{(x, y, z) | i - (n-1)/2 \leq x \leq i + (n-1)/2; j - (n-1)/2 \leq y \leq j + (n-1)/2; k - (n-1)/2 \leq z \leq k + (n-1)/2\}$ . 高斯滤波即对  $R_n(i, j, k)$  中的所有象素点的灰度,按高斯滤波器因子进行加权平均.其中  $(x, y, z)$  处加权因子的计算公式如下.

$$G'_n(x, y, z) = \exp\left(-\frac{2((x-i)^2 + (y-j)^2 + (z-k)^2)}{(n-1)^2}\right), \quad (1)$$

$$G_n(x, y, z) = G'_n(x, y, z) / \sum_{(m, n, l) \in R_n(i, j, k)} G'_n(m, n, l). \quad (2)$$

设  $F_k = \{f_k(i_l, j_l) | 1 \leq l \leq L\}$  是  $B_k$  中象素点的特征集合,其中  $L$  为象素点的个数,  $f_k(i_l, j_l) = (f_k^1(i_l, j_l) \ f_k^2(i_l, j_l) \ f_k^3(i_l, j_l))'$  为列向量,则

$$f_k^1(i_l, j_l) = I_k(i_l, j_l), \quad (3)$$

$$f_k^2(i_l, j_l) = \sum_{x=i_l-1}^{i_l+1} \sum_{y=j_l-1}^{j_l+1} \sum_{z=k-1}^{k+1} G_3(x, y, z) \times I_z(x, y), \quad (4)$$

$$f_k^3(i_l, j_l) = \sum_{x=i_l-2}^{i_l+2} \sum_{y=j_l-2}^{j_l+2} \sum_{z=k-2}^{k+2} G_5(x, y, z) \times I_z(x, y). \quad (5)$$

由图 5 可知,大脑图象象素点的灰度值和其背景图象象素点的灰度值(为 0)有较大的差别,如果直接对图象进行高斯滤波,那么,位于大脑图象边缘上的象素点由于在滤波时有背景象素点参与计算,其滤波值偏低,用这样的滤波结果进行聚类时,容易将其认为是独立的一类,而影响分割的效果.因此,对这一部分象素点进行滤波时,需要进行以下的特殊处理.

(1) 以要进行滤波的象素点为中心,在  $n \times n \times n$  ( $n=3$  或  $5$ ) 的范围内,判断参与滤波计算的象素点中是否有背景象素点,若无,转(3);

(2) 对  $n \times n \times n$  范围内背景象素点的灰度值进行赋值,所赋灰度值为距该点最近的非背景象素点的灰度值;

(3) 对  $n \times n \times n$  范围内处理后的象素灰度值用高斯滤波器的因子进行加权求和,实现高斯滤波.

经过上述方法的处理,消除了边缘象素点对聚类的影响,得到大脑  $B_k$  的特征集合  $F_k, 1 \leq k \leq K$ .

### 3 用超椭球模糊聚类对大脑进行分割

人脑 MR 图象分割的目的是提取出感兴趣的组织和区域。大脑部分主要包括灰质、白质、CSF 和其他物质。因此，对大脑进行聚类的类别数较少。使用自组织特征映射(SOFM)神经网络分类器<sup>[3]</sup>可以实现对大脑的物质的自动分割，但是由于分类的类别数少，如果 SOFM 神经网络的维数太大，则分割的结果难以合并；如果 SOFM 神经网络的维数太少，则难以发挥 SOFM 自组织聚类的优点。而且由于 MR 图象本身所具有的特点，使用 SOFM 神经网络对其进行聚类时，如果在整个三维空间中对所有的大脑象素点一起进行处理，则伪影象的影响无法消除，如果在二维空间对每一层切片进行自组织聚类，则对每一层几乎都要训练和测试同样的时间，效率不高。同时，由于样本在特征空间中的分布往往不是超球形的，使用超椭球聚类更符合样本的分布特点，而使用 SOFM 神经网络则无法实现超椭球聚类。为了得到令人满意的结果，我们使用超椭球模糊聚类方法。由于人脑的中部切片图象易于分割，所以分割时是从第 31 层切片开始的。此后，将第 31 层切片的聚类结果——中心点作为对第 30 层和第 32 层切片进行聚类的初始中心点，然后逐层向上和向下传递。由于相邻两层切片的相对变化较小，其最终聚类得到的中心点相差不大，采用逐层传递的做法，使得后一层切片进行聚类时有一个较好的初始中心点，算法能够很快收敛，大大节省了聚类的时间，提高了算法的效率。

超椭球模糊聚类方法对以上每一层二维大脑图象的特征集合  $F_k$  进行聚类，得到样本集  $F_k$  与  $C$  个类别的隶属度关系  $u = (u_d)_{C \times L} \in R^{C \times L}$ ，其中  $L$  为总样本个数， $u_{cl}$  表示第  $l$  个样本聚类后属于第  $c$  类别的隶属度。  $0 \leq u_{cl} \leq 1; l = 1, 2, \dots, L; c = 1, 2, \dots, C$ 。  $\sum_{c=1}^C u_{cl} = 1; l = 1, 2, \dots, L$ 。  $C$  个类别以中心点集合  $m$  表示，  $m = (m_1, m_2, \dots, m_C) \in R^{d \times C}$ ，  $d$  为特征维数，  $m_c (1 \leq c \leq C)$  为第  $C$  个聚类类别的中心点。

超椭球模糊聚类算法如下。

Step 1. 设迭代步数为  $t=0$ ，初始化模糊类内离散度矩阵  $A^{(0)}$  和中心点集合  $m^{(0)}$ 。

Step 2. 根据当前的模糊类内离散度矩阵  $A^{(t)}$  和中心点集合  $m^{(t)}$ ，求取划分矩阵  $u^{(t)}$ 。

当第  $l$  个样本  $f_k(i_l, j_l)$  和任一中心点  $m_c^{(t)} (1 \leq c \leq C)$  都不重合时，

$$u_{cl}^{(t)} = 1 \left/ \sum_{n=1}^C \left( \frac{(f_k(i_l, j_l) - m_c^{(t)})^T (A^{(t)})^{-1} |A^{(t)}|^{\frac{1}{d}} (f_k(i_l, j_l) - m_c^{(t)})}{(f_k(i_l, j_l) - m_n^{(t)})^T (A^{(t)})^{-1} |A^{(t)}|^{\frac{1}{d}} (f_k(i_l, j_l) - m_n^{(t)})} \right)^{\frac{1}{\alpha-1}} \right. \quad (6a)$$

当第  $l$  个样本  $f_k(i_l, j_l)$  和某个中心点  $m_c^{(t)}$  重合时，

$$u_{cl}^{(t)} = 1 \quad (6b)$$

Step 3. 根据当前的划分矩阵  $u^{(t)}$  和模糊类内离散度矩阵  $A^{(t)}$ ，求取中心点集合  $m^{(t+1)}$  和模糊类内离散度矩阵  $A^{(t+1)}$ 。

$$m_c^{(t+1)} = \sum_{l=1}^L (u_{cl}^{(t)})^\alpha f_k(i_l, j_l) / \sum_{l=1}^L (u_{cl}^{(t)})^\alpha \quad (7)$$

$$A^{(t+1)} = \sum_{l=1}^L \sum_{c=1}^C u_{cl}^\alpha (f_k(i_l, j_l) - m_c^{(t+1)})(f_k(i_l, j_l) - m_c^{(t+1)})^T / \sum_{l=1}^L \sum_{c=1}^C u_{cl}^\alpha \quad (8)$$

Step 4. 若中心点集合  $m^{(t)}$  尚未收敛，  $t=t+1$ ，返回 Step 2；若收敛，算法结束。

在算法中，  $\alpha$  为模糊聚类指数，是大于 1 的常数。

上述算法是模糊 C-均值聚类<sup>[5]</sup>的推广，从中可以看出，其实质是在计算样本  $f_k(i_l, j_l)$  和中心点  $m_c$  的距离时引入了加权矩阵  $(A)^{-1} |A|^{\frac{1}{d}}$ ，此加权矩阵即为经过归一化处理的模糊类内离散度矩阵的逆。直观来说，即在离散度比较大的方向上加权比较小，而在离散度比较小的方向上加权比较大，从而可以实现超椭球模糊聚类。

由于最终是将大脑分割为白质和灰质，所以对隶属度矩阵  $u$  需要进一步的处理。在本文中，若样本  $f_k(i_l, j_l)$  对于第  $c$  个类别的隶属度最大，则将该样本划分为第  $c$  类。在具体进行分割时，取  $C=2, \alpha=1.5$ 。

### 4 实验分析和结果

因为人脑 MR 图象数据集  $I$  的分割结果不可能与真实人脑作对比，因此，在实验中使用图 7 所示的人脑 MR 图象切片和图 8 所示的专家手工分割结果作对比(来自 the Center for Morphometric Analysis (CMA), Internet Brain Segmentation Repository (IBSR) of the Massachusetts General Hospital)，来验证本文提出的特征提取和超椭球模糊 C-均值聚类方法的有效性。

由于图 7 是二维图象，因此，在这里提取特征时，对图象进行的是二维滤波。为了选取合适的特征维数，对图 7 中的大脑部分(和分割结果相比较而得)的图象分别使用  $3 \times 3, 5 \times 5, 7 \times 7, 9 \times 9, 11 \times 11$  和  $13 \times 13$  的高斯滤波器进行了

滤波,使用超椭圆模糊 C-均值聚类方法对大脑进行分割.对于分割得到的结果,和专家手工分割的结果相比较,统计分割正确的像素点占所有大脑像素点的百分比作为分割性能的评价(如图 9 所示).由此可见,采用  $3 \times 3$  效果最好,而且使用超椭圆模糊聚类,其正确分割的百分比可以达到 95%以上.这说明本文提出的方法可以对人脑 MR 图象进行有效的分割,取得令人满意的结果.同时,我们可以看到,当特征维数增加时,分割的效果反而下降.这是因为在所选取的特征中,像素点的灰度值是最重要的特征,用高斯滤波器进行滤波后得到的特征虽然考虑了邻域内的特点,但由于此特征是邻域内所有像素点灰度值的加权平均,所以会将像素点本身的灰度值这一最重要的特征削弱.因此,本文对人脑 MR 图象进行处理时,综合考虑了特征维数的有效性和计算复杂度,选取的是第 2 节中所描述的三维特征.



图 7 二维人脑 MR 图象切片




图 8 专家手工分割结果




图 9 正确分割率—特征维数关系曲线

本文处理的数据是 54 幅的一个完整的人脑 MR 图象,每层切片的大小为  $256 \times 256$ ,灰度等级为 256.这里给出了最先进行处理的第 31 层切片的结果.图 1 是原始图象,其数据集合为  $I_{31}$ ,使用分块自适应阈值法进行预处理,依次提取出头部外轮廓(图 3)和大脑轮廓(图 4),并将大脑部分(图 5)的数据集合  $B_{31}$ 提取出来.再对大脑部分进行三维高斯滤波,提取出第 31 层切片的特征集合  $F_{31}$ ,最后使用超椭圆模糊聚类将大脑部分分割为灰质(图 10)和白质(图 11)两种组织.再将第 31 层切片聚类结束时的中心点作为初始中心点,对第 30 层切片和第 29 层切片进行聚类,依此类推,对所有图象完成分割.图 12~24 给出了部分大脑图象的分割结果(灰质部分).




图 10 第 31 层切片分割结果—灰质




图 11 第 31 层切片分割结果—白质




图 12 第 9 层切片的分割结果




图 13 第 12 层切片的分割结果




图 14 第 15 层切片的分割结果




图 15 第 18 层切片的分割结果






图 16 第 21 层切片的分割结果

图 17 第 24 层切片的分割结果

图 18 第 27 层切片的分割结果






图 19 第 30 层切片的分割结果

图 20 第 33 层切片的分割结果

图 21 第 36 层切片的分割结果






图 22 第 39 层切片的分割结果

图 23 第 42 层切片的分割结果

图 24 第 45 层切片的分割结果

## 5 结 论

本文首先对图象进行了预处理,提取出头部外轮廓和大脑轮廓,对大脑进行了精确定位,从而消除了背景噪声和其他部分对大脑分割的影响.然后使用高斯滤波提取出大脑图象的有效特征,最后使用超椭圆模糊聚类把大脑分割为白质和灰质.在进行聚类时,因为上下两层图象切片的相似度较大,其最终聚类的中心点相差不大,可将聚类的中心点依次传递,使得后一层切片聚类时是从一个较好的初始中心点开始的,从而使收敛的速度大大加快,提高了分割的效率.人脑 MR 图象受伪影现象的影响很大,导致图象灰度分布不均匀,进而导致最上部和最下部图象的灰度偏高或偏低.采用本文的做法,对每一层切片进行聚类,使得每一层图象都较准确地分割为白质和灰质两部分,从而克服了伪影现象的影响,取得了相当好的分割效果.

## 参 考 文 献

- 1 Zijdenbos A P, Dawant B M. Brain segmentation and white matter lesion detection in MR images. *Critical Reviews in Biomedical Engineering*, 1994, 22(5~6): 401~465
- 2 Rosenfeld A, Kak A C. *Digital Picture Processing*. New York: Academic Press, 1976
- 3 Ahmed M N, Farag A A. Two-stage neural network for volume segmentation of medical images. In: *Proceedings of IEEE In-*

- ternational Conference '97 on Neural Networks. New York; IEEE Press, 1997. 1373~1378
- 4 Kohonen T. The self-organizing map. In: Proceedings of the IEEE. 1990,78(9),1464~1480
- 5 Gustafson D E, Kessel W D. Fuzzy clustering with a fuzzy covariance matrix. In: Proceedings of IEEE CDC. San Diego, CA: IEEE Press, 1979. 761~766

## Human Brain Magnetic Resonance Image Segmentation Based on Hyperellipsoidal Fuzzy Clustering Algorithm

LIANG Yi-long<sup>1</sup> WANG Song<sup>1</sup> XIA Shao-wei<sup>1</sup> WANG Zi-gang<sup>2</sup>

<sup>1</sup>(Department of Automation Tsinghua University Beijing 100084)

<sup>2</sup>(Department of Computer Science and Technology Tsinghua University Beijing 100084)

**Abstract** The commonly used cluster based segmentation method assumes that the sample distribution is hyper-spherical, but this kind of assumption is not consistent with the real characteristic of the human brain MR (magnetic resonance) image. In order to surmount this drawback, a new algorithm for segmenting MR image based on hyperellipsoidal fuzzy clustering is presented in this paper. Provided experimental results indicate that the proposed strategy is feasible for classifying the white matter and the gray matter of the brain, and has the merits of both high efficiency and remarkable accuracy.

**Key words** MR (magnetic resonance) image segmentation, adaptive threshold, Gaussian filtering, hyperellipsoidal fuzzy clustering.