

基于改进模糊聚类算法鲁棒的图像分割

张 扬 王士同 韩 斌

(江南大学信息工程学院 无锡 214122)

摘 要 对噪声图像提出了一种改进的模糊聚类分割算法。因为模糊 C 均值聚类(FCM)算法具有对噪声数据敏感的缺点,该算法通过提升意义更趋明晰的模糊隶属度来改变模糊聚类中的目标函数,即通过在标准的 FCM 算法中使用到类的 Voronoi cell 的距离来取代到类的原型的欧氏距离,从而增强了聚类结果的鲁棒性。实验结果表明,改进的算法较之于 FCM 对于噪声图像的分割有更好的鲁棒性。

关键词 图像分割 模糊聚类 鲁棒性 Voronoi cell

中图法分类号:TP391 文献标识码:A 文章编号:1006-8961(2006)05-0911-07

Robust Image Segmentation Based on Improved Fuzzy Clustering Algorithm

ZHANG Yang, WANG Shi-tong, HAN Bin

(School of Information Technology, Southern Yangtze University, Wuxi 214122)

Abstract In this paper, an improved fuzzy-clustering-based segmentation algorithm for noise images is presented. Being sensitive to noise is one of the popular fuzzy C-means (FCM) algorithm's drawbacks. The new objective function used in fuzzy clustering is modified to obtain different membership functions by rewarding crisp membership degrees, that is, using distances to the Voronoi cell instead of using distances to the cluster prototypes. Thus the proposed algorithm enhances robustness to noise. Experimental segmentation results for noise images demonstrate the effectiveness and robustness capability of the proposed algorithm.

Keywords image segmentation, fuzzy clustering, robustness, Voronoi cell

1 引 言

许多使用模糊技术的图像分割算法已经被提出^[1-3]。目前一种流行的技术是使用模糊 C 均值聚类(FCM)算法或它的变体,该方法通过计算每个数据样本与聚类原型之间的隶属度对图像进行分割。

在 FCM 算法中,当从原始的输入数据中自动地构造模糊系统的时候,需要将原始数据集划分成模糊类。通常需要数据集被指定在本地的区域,也就是要求隶属函数有范围上的限制或迅速的衰落。如

果这个条件没有被满足,许多情况会同时出现并会用到多种不同的规则,从而很难得到最后的结果。第 2 个条件是原始的模糊集应当是简单的并且是单峰性的。

从表面看,模糊聚类算法非常适合得到这样的模糊类,因为它提供一个模糊隶属函数,这个隶属函数可以应用到很多模型中。不幸的是,模糊 C 均值(FCM)聚类算法家族^[4]及其派生的隶属函数都不满足上边提到的要求^[5]。

由于传统的 FCM 算法未能考虑其邻域信息,当分割的图像不含噪声或噪声很低时能很好地得到分

基金项目:国家自然科学基金项目(60704047,60773206);教育部跨世纪优秀人才培养计划项目(NCET-04-0496);教育部 05 年度科学研究重点基金项目(105087);国防应用基础研究基金项目(A1420061266)。

收稿日期:2006-11-20; **改回日期:**2007-01-27

第一作者简介:张 扬(1984 ~),男。江南大学信息学院计算机应用专业硕士研究生。主要研究领域为图像处理与分析、模式识别。

E-mail:zhangabb@yahoo.com.cn

割效果,然而图像在成像过程中不可避免地受到不同噪声的干扰。在图像的采集、获取、编码或传输过程中,所有的图像均不同程度地被可见或不可见的噪声“污染”。并且真实图像的数据很难满足单峰性的限制以及隶属函数的迅速衰落,从而采用标准的FCM算法并不能得到满意的分割结果。

为了克服FCM算法的这些缺点,许多学者进行了研究,例如Liew等人提出的ASFCM算法^[7]和Krishnapuram和Keller提出的PCM算法^[8],但是ASFCM算法的运算量过大,而PCM算法是一种特殊模型。

本文中,提出一种更具鲁棒性的改进的FCM图像分割算法。考虑对隶属函数的隶属度值采用一个补偿性的规则,来提升意义更趋明晰的模糊隶属度。如果选择一个最大的补偿,得到的模糊隶属函数使用到类的Voronoi cell的距离取代欧氏距离,通过使用Voronoi cell距离替代欧氏距离,可以得到不同的隶属函数,这种隶属函数和最初的C均值的隶属函数很接近。我们采用的最大补偿法以及Voronoi距离都不是平方的,这个改变对噪声和离群数据有更少的敏感度,很好地增强了算法的鲁棒性。

2 基于标准的模糊聚类算法的图像分割

图像分割的任务可以描述为把一幅图像分割成一些无重复的区域,每个区域有不同的性质。根据这个定义,一幅图像A可以被划分为c个相似区域 $A_k(k=1,2,\dots,c)$ 。

$$A = \bigcup_{k=1}^c A_k \quad (1)$$

其中,每个区域通过它的属性 $v_k(x,y)$ 来指定, $v_k(x,y)$ 可以是灰度或密度等特征值。若存在随机噪声 $n_k(x,y)$,则 $A_k(x,y)((x,y) \in A_k)$ 可表示为

$$A_k(x,y) = v_k(x,y) + n_k(x,y) \quad (2)$$

每个区域可包含一个单独连在一起的部分或一组不相连的有相同属性值的部分。

令 $X = \{x_j, j \in \{1, \dots, n\}\}$ 表示整幅图像的特征向量集,可以用区域I上的图像的强度值或像素灰度值来表示。各个类原型表示为 $p_i, i \in \{1, \dots, c\}$ 。 $p_i \in P, P$ 是模糊类原型的集合,c是分类的数目。矩阵 $U = \{u_{i,j}\}$ 是X的一个模糊c分割, $u_{i,j}$ 表示隶属度值, $u_{i,j} \in [0,1]$,它表示像素点 x_j 到第i个类原型 p_i

的隶属度。将一个数据对象 x_j 到原型 p_i 之间的距离表示成 $d_{i,j}$,采用欧氏距离的标准,d表示为

$$d_{i,j}^2 = \|x_j - p_i\|^2 \quad (3)$$

根据以上定义,可以将传统的FCM算法借助 P, U 和 X 表示为

$$J_{FCM}(P, U, X) = \sum_{j=1}^n \sum_{i=1}^c u_{i,j}^m d_{i,j}^2 \quad (4)$$

这里, $m \in (1, \infty)$ 是预先选定的并且影响最终结果的模糊分类索引,它是一个控制算法柔性的参数,如果m过大,则聚类效果会很差,接近于完全模糊;而如果m过小则算法会接近HCM聚类算法。目标函数是在下列条件的限制下被迭代执行并不断减小其值的。

$$\sum_{i=1}^c u_{i,j} = 1 \quad 1 \leq j \leq n \quad (5)$$

$$\sum_{j=1}^n u_{i,j} > 0 \quad 1 \leq i \leq c \quad (6)$$

在每次迭代过程中, $u_{i,j}$ 和 p_i 的最小化是分别进行的。最小化必须的条件在执行过程中服从于更新方程式。模糊隶属函数独立于所选的距离函数和原型,表示为

$$u_{i,j} = \frac{1}{\sum_{k=1}^c \left(\frac{d^2(x_j, p_i)}{d^2(x_j, p_k)} \right)^{\frac{1}{m-1}}} \quad (7)$$

在标准的FCM算法中,聚类中心是和数据同维度的向量,聚类中心的更新方程式为

$$p_i = \frac{\sum_{j=1}^n u_{i,j}^m x_j}{\sum_{j=1}^n u_{i,j}^m} \quad (8)$$

3 具有更强鲁棒性的FCM图像分割算法

3.1 在模糊聚类中提升意义更趋明晰的模糊隶属度
隶属函数式(7)的一些性质在一些应用领域是不受欢迎的。当应用到图像分割时,希望得到更趋明晰的模糊隶属度,希望避免高隶属度成员的峰值区域,而对范围广的更明晰的模糊隶属度感兴趣,那样容易让我们对数据进行归类。并且我们希望模糊隶属度在 $[0,1]$ 之间变化的区域越狭窄越好,这样才能保证有更加准确的分割。

FCM算法通过迭代计算使目标函数式(4)最小化,以此来得到对数据集的模糊划分,因此希望在运

算时逐步减小目标函数的值。选择一组参数 $a_j \in \mathbf{R}_{\geq 0}, 1 \leq j \leq n$, 并且为方便起见令 $m=2$, 考虑下面已被改进的目标函数:

$$J = \sum_{j=1}^n \sum_{i=1}^c u_{i,j}^2 d_{i,j}^2 + \sum_{j=1}^n a_j \sum_{i=1}^c u_{i,j} (1 - u_{i,j}) \quad (9)$$

注意, 第1部分同标准 FCM 算法的目标函数相同。

对于第2部分, 先考虑下面定义的函数及提出的引理1。

$$f(u_{i,j}) = \sum_{i=1}^c u_{i,j} (1 - u_{i,j}) \quad (10)$$

$$0 \leq u_{i,j} \leq 1, \sum_{i=1}^c u_{i,j} = 1$$

引理1 当 $u_{i,j} (i=1, 2, \dots, c)$ 均为 $\frac{1}{c}$ 时, 函数 $f(u_{i,j})$ 取得最大值 $1 - \frac{1}{c}$; 当 $u_{i,j}$ 中有一个为1, 其他 $u_{k,j} (k \neq i)$ 为0时, $f(u_{i,j})$ 取最小值0, 即 $0 \leq f(u_{i,j}) \leq 1 - \frac{1}{c}$ 。

证明 从一个单独的数据对象 x_j 来考虑函数式(10)。

(1) 因为 $0 \leq u_{i,j} \leq 1$, 所以 $\sum_{i=1}^c u_{i,j} (1 - u_{i,j})$ 中每一项 $u_{i,j} (1 - u_{i,j})$ 均大于等于0, 那么 $f(u_{i,j}) \geq 0$ 。并且 $f(u_{i,j}) = 0$ 当且仅当 $\sum_{i=1}^c u_{i,j} (1 - u_{i,j})$ 中的每一项均为0, 即 $u_{i,j} (1 - u_{i,j}) = 0 (0 \leq i \leq c)$ 。此时必有 $u_{i,j} = 0$ 或 $u_{i,j} = 1$ 。由于有 $\sum_{i=1}^c u_{i,j} = 1$ 的限制, 则这种情况下只能有某一个 $u_{i,j} = 1$, 其他 $u_{k,j} = 0 (k \neq i)$ 。

(2) 应用拉格朗日乘数法求

$f(u_{i,j}) = \sum_{i=1}^c u_{i,j} (1 - u_{i,j})$ 在约束条件 $\sum_{i=1}^c u_{i,j} = 1$ 和 $0 \leq u_{i,j} \leq 1$ 下的极值。构造拉格朗日函数如下:

$$G = \sum_{i=1}^c u_{i,j} (1 - u_{i,j}) - \lambda (\sum_{i=1}^c u_{i,j} - 1) \quad (11)$$

令 $\frac{\partial G}{\partial u_{1,j}}, \frac{\partial G}{\partial u_{2,j}}, \dots, \frac{\partial G}{\partial u_{c,j}}$ 均为0, 得

$$u_{1,j} = u_{2,j} = \dots = u_{c,j} = \frac{1}{c}, \lambda = 1 - \frac{2}{c}$$

而对于 $\forall 1 \leq i \leq c, 1 \leq k \leq c, \frac{\partial^2 G}{\partial u_{i,j} \partial u_{k,j}} = -2$ 故当

$u_{1,j} = u_{2,j} = \dots = u_{c,j} = \frac{1}{c}$ 时, $f(u_{i,j})$ 在开区域 $(0, 1)^c$

内取得极大值, 此时 $f(u_{i,j}) = 1 - \frac{1}{c}$ 。

对于 $[0, 1]^c$ 的边界点 $(u_{1,j}, u_{2,j}, \dots, u_{c,j})$, 设 $u_{1,j}, u_{2,j}, \dots, u_{c,j}$ 中有 $p (1 \leq p \leq c)$ 个 $u_{i,j}$ 为0, $q (0 \leq q \leq 1)$ 个 $u_{i,j}$ 为1。若 $p + q = c$, 则 $\sum_{i=1}^c u_{i,j} (1 - u_{i,j}) = 0 \leq 1 - \frac{1}{c}$ 。

若 $p + q < c$, 将 $u_{i,j} = 0, 1$ 代入 $f(u_{i,j})$ 中, 则 $f(u_{i,j})$ 转化为 $c - p - q$ 维的形如式(10)的函数。于是由前面的分析, 上式右端函数的极值为 $1 - \frac{1}{c - p - q}$, 而 $1 - \frac{1}{c - p - q} < 1 - \frac{1}{c}$, 所以 $f(u_{i,j})$ 在 $u_{1,j} = u_{2,j} = \dots = u_{c,j} = \frac{1}{c}$ 时取最大值 $1 - \frac{1}{c}$ 。

上面所证明的函数 $f(u_{i,j})$ 的性质表明, 函数 $f(u_{i,j})$ 的值变小时, $u_{c,j}, u_{2,j}, \dots, u_{c,j}$ 的值趋向于集中, 即某个 $u_{i,j}$ 接近于1, 其他大部分的 $u_{k,j}$ 接近于0, 这正是—个明晰的隶属度。

在进行模糊分类时, 希望出现某个 $u_{i,j}$ 趋向于1, 其他的 $u_{k,j} (k \neq i)$ 趋向于0的情况。如果一个数据对象 x_j 被明确地分配到一个原型 p_i , 那样得到 $u_{i,j} = 1, u_{k,j} = 0 (k \neq i)$ 。对于所有这样的情况, 第2部分估计为0。当隶属度变得越来越模糊时, 第2部分便增加。既然试图减小式(9)的值, 那么这种改变可以使我们得到更加明晰的隶属度。

在式(9)的第2部分中没有对 p_i 进行任何的改动, 聚类中心的更新步骤和相应的模糊聚类算法 (FCM, GK, FCRM, ...) 保持相同, 所以这种改变的结果不会对最后的分割结果产生较大影响。

下面从一个单独的数据对象 x_j 来考虑目标函数式(9), 用拉格朗日乘子 λ 来满足约束条件

$$\sum_{i=1}^c u_{i,j} = 1, \text{可以得到}$$

$$F = \sum_{i=1}^c u_{i,j}^2 d_{i,j}^2 + a_j \sum_{i=1}^c u_{i,j} (1 - u_{i,j}) + \lambda (\sum_{i=1}^c u_{i,j} - 1) \quad (12)$$

让斜率等于零得

$$\frac{\partial F}{\partial \lambda} = \sum_{i=1}^c u_{i,j} - 1 = 0 \quad (13)$$

$$\frac{\partial F}{\partial \mu_{k,j}} = 2\mu_{k,j} d_{k,j}^2 + a_j - 2a_j \mu_{k,j} + \lambda = 0 \quad (14)$$

由 $\partial F / \partial u_{k,j} = 0$, 得到

$$\mu_{k,j} = \frac{-a_j - \lambda}{2(d_{k,j}^2 - a_j)} \quad (15)$$

将式(15)代入式(13),得

$$\sum_{i=1}^c \frac{-a_j - \lambda}{2(d_{i,j}^2 - a_j)} = 1 \Leftrightarrow \lambda = -a_j - \frac{1}{\sum_{i=1}^c \frac{1}{2(d_{i,j}^2 - a_j)}} \quad (16)$$

将式(16)代入式(15),得

$$u_{i,j} = \frac{1}{\sum_{k=1}^c \frac{d_{i,j}^2 - a_j}{d_{k,j}^2 - a_j}} \quad (17)$$

在上式中可以很明显的看到,当选择的 a_j 大于 $d_{i,j}^2$ 的时候, $d_{i,j}^2 - a_j$ 会变成负的。同样隶属度 $u_{i,j}$ 也可能出现负值的情况。因此,我们不得不明确地限制 $u_{i,j} \geq 0$ 。根据库恩-塔克(Kuhn-Tucker)条件,如果只有一个原型到 x_j 的距离小于 a_j ,可以通过单独令 $u_{i,j} = 1$ 来达到最小。但是,很可能会出现多个 $d_{i,j}^2 - a_i$ 为负值的情况,那就会很难处理,所以最好有一种通用的解决方法。

为了避免出现负的模糊隶属度,可以启发式地提升 a_i ,以使得 $d_{i,j}^2 - a_i$ 始终为正。可以给出的最大的提升为

$$\text{mind}_{*j}^2 = \min\{d_{i,j}^2 | i \in \{1, \dots, c\}\} - \eta \quad (\eta > 0)$$

从而

$$u_{i,j} = \frac{1}{\sum_{k=1}^c \frac{d_{i,j}^2 - \text{mind}_{*j}^2}{d_{k,j}^2 - \text{mind}_{*j}^2}} \quad (18)$$

如果没有使用 $\eta > 0$,那么对于某些 i 会经常出现 $d_{i,j}^2 = \text{mind}_{*j}^2$ 的情况,在这种情况下得到了一个十分明晰的分割,即 $u_{i,j} = 1$,算法在此时简化为 c 均值算法。对 η 的选择影响了划分的模糊程度,避免出现 $d_{i,j}^2 - \text{mind}_{*j}^2 = 0$ 这种情况,取一个合适的 η 值就变得非常有意义。一般情况下可以取 $\eta \in [0.01, 0.1]$ 。

改进的函数提升了隶属度的明晰含义,而且除了隶属函数形式的不同,该算法同传统的 FCM 算法最后生成的聚类中心是非常相似的。并且改变的版本对噪声和例外值又少了些敏感性。

3.2 使用 Voronoi 距离产生的隶属函数

FCM 算法中,确定隶属函数的过程中起核心作用的是聚类中心和数据对象之间的欧氏距离,该距离定义了一个成员隶属于一个类的程度。比如说,如果 x_j 到 p_1 的距离是到 p_2 的距离的一半,那么隶属度 $u_{1,j}$ 是 $u_{2,j}$ 的两倍。如果按前面的提升隶属度

的明晰意义来考虑这种方法,情况就会变得不同,隶属度不依赖于距离的比率,距离仅仅作作为求隶属度的一个阈值。按照这种思想,如果一个数据点到类 p_1 的距离小于到类 p_2 的距离,不管有多小,始终有 $u_{1,j} = 1$ 。

重新考虑式(18)并且假设 p_i 非常靠近 x_j 。不管 x_j 离 p_i 很远还是离 p_i 很近,离其他的 $p_k (k \neq i)$ 总是更远,那么距离比的分子位置始终是常数 η 。在所有的数据点都靠近 p_i 的区域的内部,到 i 类的距离被认为是常量 η 。模糊隶属度 $u_{i,j}$ 也因此主要由 $d_E^2(x_j, p_k)$ 决定。因此,由式(18)得到的成员隶属度不再是由一个距离的比率来决定,最大的补偿值 mind_{*j}^2 则成了一个阈值。

考虑一个由聚类中心生成的明晰的划分。这样的划分和 Voronoi 图非常相似。

Voronoi 图是对欧氏平面的一个分割。欧氏平面上存在一组点集 $p = \{p_1, p_2, p_3, \dots\}$,分割之后的 Voronoi 图将每一个点分配到最近的区域。一个 Voronoi cell(也称为 Voronoi 区域)包含所有被分配到这个区域的点,它可以表示为

$$V(p_i) = \{x : |p_i - x| \leq |p_j - x| \} (j \neq i)$$

由该数学定义可以看出 Voronoi 图的特点为 Voronoi 图是和每个点相对应的一个划分,划分的每个区域中所有的点(包括边界)到该区域中心点的距离都比到该平面中其他区域中心点的距离要近。

一个数据对象 x_j 到超平面的欧氏距离可以表示为 $|(x_j - h_k)^T n_k|^{[6]}$,这个距离把类 p_i 和 p_k 分开,其中, h_k 是超平面的一个点,可以令 $h_k = (p_k + p_i)/2$, n_k 是法向量, $n_k = \beta_k (p_i - p_k)$, $\beta_k = 1/(\|p_i - p_k\|) (k \neq i)$ 。如果不取绝对值,得到的是有向距离 $(x_j - h_k)^T n_k$,如果 x_j 和类中心在同一边则值为正,反之为负。所有的有向距离绝对值的最小值为到单元边界的距离。如果 x_j 在类 i 的 Voronoi cell 之中,则到该区域的距离为零。令 $\beta_k = 1$,得

$$d_v(x_j, p_i) = \left| \min_{1 \leq k \leq c} (x_j - h_k)^T n_k \right| \quad (19)$$

在图 1 中, x_j 靠近 p_1 与 p_4 之间的分割线,因此这个距离是到 p_1 的距离。

若对所有 k 都假设 $\beta_k = 1$,而不将法向量 n_k 衡量为最小整数长度,对式(19)进行如下简单的变形:




图 1 质心 p_1 的 Voronoi cell^[6]

Fig.1 Voronoi cell of centroid p_1

$$\begin{aligned}
 d_v(\mathbf{x}, \mathbf{p}_i) &= \left| \min_{1 \leq k \leq c} \left(\mathbf{x} - \frac{\mathbf{p}_k + \mathbf{p}_i}{2} \right)^T (\mathbf{p}_i - \mathbf{p}_k) \right| \\
 &= \frac{1}{2} \left| \min_{1 \leq k \leq c} \mathbf{x}^T \mathbf{x} - 2\mathbf{x}^T \mathbf{p}_k + \mathbf{p}_k^T \mathbf{p}_k + \right. \\
 &\quad \left. (\mathbf{x}^T \mathbf{x} - 2\mathbf{x}^T \mathbf{p}_i + \mathbf{p}_i^T \mathbf{p}_i) \right| \\
 &= \frac{1}{2} \left| \min_{1 \leq k \leq c} \|\mathbf{x} - \mathbf{p}_k\|^2 - \|\mathbf{x} - \mathbf{p}_i\|^2 \right| \\
 &= \frac{1}{2} (\|\mathbf{x} - \mathbf{p}_i\|^2 - \min_{1 \leq k \leq c} \|\mathbf{x} - \mathbf{p}_k\|^2)
 \end{aligned}$$

在上面等式中,用到了一个事实,即任何 $d_E(\mathbf{x}, \mathbf{p}_i)$ 都大于或等于 $\min_{1 \leq k \leq c} d_E(\mathbf{x}, \mathbf{p}_k)$, 所以 $\|\mathbf{x} - \mathbf{p}_i\|^2 - \min_{1 \leq k \leq c} \|\mathbf{x} - \mathbf{p}_k\|^2 \geq 0$ 。由此可以得到,给定一个由一组不同的点 $\mathbf{p}_i (1 \leq i \leq c)$ 和点 \mathbf{x} 引起的 Voronoi 图,对所有的 $k (1 \leq k \leq c)$, 令 $\beta_k = 1$, 则 \mathbf{x} 到 \mathbf{p}_i 的 Voronoi cell 的距离为

$$d_v(\mathbf{x}, \mathbf{p}_i) = \frac{1}{2} (d_E^2(\mathbf{x}, \mathbf{p}_i) - \min_{1 \leq k \leq c} d_E^2(\mathbf{x}, \mathbf{p}_k)) \quad (20)$$

因此,通过使用最大的补偿,即使用一个 Voronoi cell 距离替代欧氏距离,隶属度同我们使用的标准的 FCM 的隶属度相同。

通过使用 Voronoi 距离替代欧氏距离,得到不同的隶属函数,这隶属函数和最初的 c 均值的隶属函数很接近。从这种意义上说可以认为是一种新的 c 均值模糊化方法。

更重要的是,FCM 中是使用平方过的欧氏距离来决定隶属度的。但是最大补偿以及 Voronoi 距离在算术上都不是平方的。因此,这个改变对噪声和离群数据有更少的敏感度。

3.3 新的图像分割算法

依据前述的改进的聚类方法,提出一个新的图像分割方法,它使用前面提到的提升意义更趋明晰

的隶属度函数,另外在算法中使用到类的 Voronoi cell 的距离来取代到类的原型的距离,这样增加了算法在图像分割时的鲁棒性,得到更加准确的图像效果。新的图像分割方法描述如下:

- (1) 读入一幅图像 X , 在 X 中选加均值为 0, 方差为 σ^2 的高斯噪声,使其变成图像 Y , Y 为要处理的数据集;
- (2) 设定聚类的数目 c , 令 $m = 2$; 选择终止门槛 $\varepsilon > 0$; 选择 $\eta > 0$; 设置最大循环次数 M ;
- (3) 用值在 0, 1 间的随机数初始化隶属矩阵 U , 使其满足式(5)和式(6)的约束条件;
- (4) 从 $i = 0$ 到 M , 进行如下循环操作:
 - ① 根据式(7)更新 \mathbf{p}_i ;
 - ② 根据式(20)更新距离值;
 - ③ 根据式(4)计算价值函数。如果它小于某个确定的阈值,或它相对上次价值函数值的改变量小于某个阈值 ε , 则算法停止;
 - ④ 通过式(18)更新成员隶属度;
- (5) 根据隶属度矩阵,对图像 Y 进行分割。

4 图像分割实验及分析

为了表明改进的算法在图像分割中的作用以及其特殊的抗噪性能,对人造数据和实际数据进行大量的实验,并与传统 FCM 算法的分割效果进行了比较。

实验 1 对加高斯噪声的图像进行分割实验。一个含有高斯噪声的图像实际上是在原图像每个像素点灰度值基础上包含了在一定范围内变化的、不确定的灰度值。实验中采用的原始图像如图 2(a) 所示,将整幅图像选加均值 $\mu = 0$, 方差 $\sigma = 0.05$ 的高斯随机噪声,所得结果如图 2(b) 所示。分割时取类别数为 2, 利用改进的算法进行分割时得到图 2(d) 所示的图像。由于利用标准 FCM 进行分割时仅考虑当前像素的值,对于增加过噪声的图像缺乏良好的聚类能力。经过和标准 FCM 算法对噪声图像分割结果(如图 2(c) 所示)的比较,显然本文的新算法对噪声图像的分割处理更加出色。从图 3 中也可以看出,新方法有更强的收敛速度以及更低的目标函数值。

实验 2 对真实图像的分割实验。原始图像比较模糊(如图 4(a) 所示)。分割时取类别数为 3, 可以看到新算法分割的效果还是要明显好于标准

FCM 算法。

实验 3 改进的方法也可以应用到医学图像的分割中。图 5 是对一幅医学图像进行分割的实验结

果,分割时取类别数为 3,由实验结果可以看出,对于医学图像中类似于噪声的模糊部分,新算法具有更好的分割效果。




图 2 噪声图像分割实验结果

Fig. 2 Segmentation experiment on a noisy image

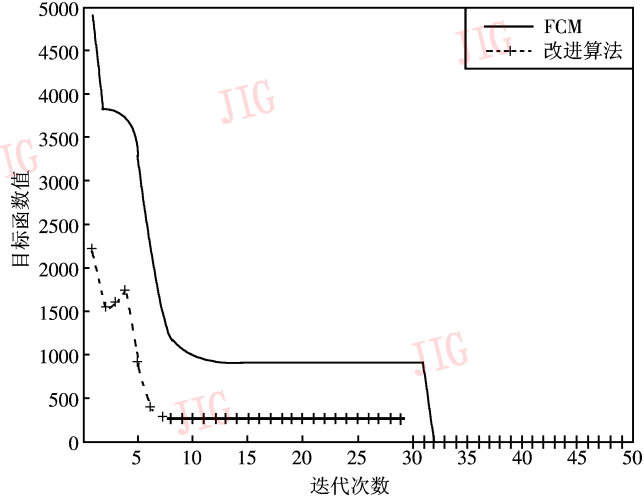


图 3 收敛速度的比较

Fig. 3 Comparison of convergence speeds




图 4 真实图像的分割结果对比

Fig. 4 Comparison of segmentation results on a real image




图 5 医学图像分割结果

Fig. 5 Segmentation result of a medical image

表1中所使用的正确分割率定义为

$$\text{正确分割率} = \frac{\text{正确分割的像素数}}{\text{总像素数}} \times 100\% \quad (21)$$

其中,正确分割的像素为被合理地分配到所属图像类别中的像素点。由式(21)可知,正确率越大表明分割的效果越好。从表1可以看出,对于加噪声图像以及比较模糊的真实图像,改进的算法有明显的优势。

表1 新算法和标准FCM算法正确分割率的比较

Tab.1 Comparison of segmentation correctness percentages between proposed algorithm and standard FCM algorithm

实验图像	正确分割率(%)	
	标准FCM	新算法
图2(a)	85.03	97.24
图4(a)	93.37	96.33
图5(a)	92.50	94.21
平均正确分割率	90.27	95.93

5 结 论

对噪声图像的分割提出了一种基于改进的FCM算法的新算法,新算法更接近于原始的C均值算法,但又保持了FCM的模糊划分的优势且比FCM更具鲁棒性。在这个新方法中,提出了一种改进的隶属度函数,通过选择一个“最大的补偿”得到意义

更趋明晰的隶属度。另外可以通过使用一个数据对象到Voronoi cell的距离来取代标准的欧氏距离,这样可以得到更强的鲁棒性。实验结果表明,改进的算法在对噪声图像的处理中明显好于FCM算法,对噪声具有较强的鲁棒性。

参考文献 (References)

- Wang F. Fuzzy classification of remote sensing images [J]. IEEE Transactions on Geoscience and Remote Sensing, 1990, 28(2): 194~201.
- Cheng H D, Chen Y H, Jiang X H. Thresholding using two dimensional histogram and fuzzy entropy principle [J]. IEEE Transactions on Image Processing, 2000, 9(4): 732~735.
- Zhao M S, Fu A, Yan H. A technique of three-level thresholding based on probabilistic partition and fuzzy three-partition [J]. IEEE Transactions on Fuzzy Systems, 2001, 9(3): 469~479.
- Bezdek J C. A convergence theorem for the fuzzy ISODATA clustering algorithms [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1980, 2(1): 1~8.
- Runkler T A, Bezdek J C. Alternating cluster estimation: a new tool for clustering and function approximation [J]. IEEE Transactions on Fuzzy Systems, 1999, 7(4): 377~393.
- Hoppner F, Klawonn F. Improved fuzzy partitions for fuzzy regression models [J]. International Journal of Approximate Reasoning, 2003, 32(2): 85~102.
- Liew A W C, Yan H, Law N F. Image segmentation based on adaptive cluster prototype estimation [J]. IEEE Transactions on Fuzzy Systems, 2005, 13(4): 444~453.
- Krishnapuram R, Keler J M. A possibilistic approach to clustering [J]. IEEE Transactions on Fuzzy Systems, 1993, 1(2): 98~110.