

基于选择和变异机制的蛙跳 FCM 算法^{*}

赵小强^{1,2}, 刘悦婷¹

(1. 兰州理工大学 电气工程与信息工程学院, 兰州 730050; 2. 甘肃省工业过程先进控制重点实验室, 兰州 730050)

摘要: 为了改进模糊 C-均值(FCM)聚类算法对初始值和噪声数据敏感,且易陷入局部极小值的缺点,提出一种基于选择和变异机制的蛙跳 FCM 算法(SMSFLA-FCM)。该算法首先将线性递减的惯性权重引入蛙跳算法的更新策略中,按照一定的概率选择适应度值较优的青蛙代替较差青蛙,并对每只青蛙个体以不同的概率变异;再用改进后的蛙跳算法求得最优解作为 FCM 算法的初始聚类中心;然后利用 FCM 优化初始聚类中心;最后求得全局最优解,从而有效克服了 FCM 算法的缺点。人造数据和经典数据集的实验结果表明, SMSFLA-FCM 与 SF-LA-FCM 和 FCM 聚类算法相比,提高了算法的寻优能力,且迭代次数更少,聚类效果更好。

关键词: 模糊 C-均值聚类; 蛙跳算法; 选择和变异机制; 聚类分析; 数据挖掘

中图分类号: TP18 **文献标志码:** A **文章编号:** 1001-3695(2012)06-2068-04

doi:10.3969/j.issn.1001-3695.2012.06.016

Fuzzy clustering algorithm based on selection and mutation mechanism shuffled frog leaping algorithm

ZHAO Xiao-qiang^{1,2}, LIU Yue-ting¹

(1. College of Electrical & Information Engineering, Lanzhou University of Technology, Lanzhou 730050, China; 2. Key Laboratory of Gansu Advanced Control for Industrial Processes, Lanzhou 730050, China)

Abstract: Because of the problems such as the sensitivity to initial value and noise data with the fuzzy C-means(FCM) clustering algorithm and its ready occurrence of local minimum, this paper presented a fuzzy C-means clustering based on selection and mutation mechanism shuffled frog leaping algorithm. This algorithm introduced the linear decreasing inertia weight to correct the poor frog update strategy. Then it selected the frog with better fitness value to substitute the poor one, and made very frog to mutate with different probability. The optimal solution obtained with SMSFLA with strong global searching ability was taken as initial clustering centers of FCM algorithm to optimize initial clustering centers, so as to get the global optimum and overcome the shortcoming of the FCM algorithm. The results of experiment on the artificial and real data show that compared with the SFLA-FCM and FCM clustering algorithm, the new algorithm (SMSFLA-FCM) optimization ability would be stronger, the number of iterations less, and the clustering efficiency better.

Key words: fuzzy C-means clustering; shuffled frog leaping algorithm(SFLA); selection and mutation mechanism; cluster analysis; data mining

0 引言

聚类分析是数据挖掘技术的重要组成部分,它能从大量的、随机的数据中发现潜在的、有意义的数据信息。聚类是在事先不规定分组规则的情况下,将数据对象按照其自身特征划分成不同的群组,其重要特征是物以类聚,即要求同一群组中的对象之间具有较高的相似性,而不同群组的对象具有较大的差异性^[1]。这种类别的划分界限是分明的,但是在现实世界中却有许多实际问题并没有严格的属性,它们在性态和类属方面存在着模糊性,具有亦此亦彼的性质。因此,人们就提出要对待处理的对象进行软划分。Zadeh 提出的模糊集理论为软划分提供了有力的分析工具,并把用模糊方法处理聚类的问题称为模糊聚类分析。相对于传统的硬聚类算法,模糊聚类算法引入了模糊集理论,有着更好的数据表达能力与聚类性能。在

众多的模糊聚类算法中,基于目标函数的模糊 C-均值(fuzzy C-means, FCM)算法^[2]是应用最广泛的一种方法。FCM 算法计算简单且快速,具有比较直观的几何意义,而且已被应用于模式识别、图像处理以及计算机视觉等众多领域中。FCM 也有其不足,例如:a)聚类数目难以确定;b)只能识别团状的簇,不能识别不规则簇和带状簇;c)对初始值敏感、易陷入局部最优等。

文献[3]提出多中心思想并结合 DBSCAN 算法在一定程度上解决了问题 a)和 b)。近几年来,许多文献针对问题 c)提出了改进方法,如应用免疫算法的改进、应用遗传算法的改进、结合群智能的改进等。又如基于免疫遗传算法的模糊 C-均值聚类^[4]、一种基于微粒群的模糊聚类算法^[5]、粒子群优化的模糊 C-均值聚类航迹关联算法^[6]等,这些算法采用不同的方式对 FCM 算法进行改进,在一定程度上提高了 FCM 算法的性

收稿日期: 2011-11-14; **修回日期:** 2011-12-20 **基金项目:** 甘肃省支撑计划资助项目(090GKCA034); 甘肃省自然科学基金资助项目(0916RJZA017, 1112RJZA028)

作者简介: 赵小强(1969-),男,陕西岐山人,副教授,博士,主要研究方向为数据挖掘、故障诊断等;刘悦婷(1979-),女,硕士研究生,主要研究方向为数据挖掘算法(liuyueting996@qq.com)。

能。文献[7]用 SFLA 对 FCM 进行优化,并应用在交通状态判别中,取得了良好的效果。

1 FCM 算法

模糊 C-均值聚类算法是一种迭代优化算法,可以描述为最小化指数函数。设集合 $X = \{x_1, x_2, \dots, x_N\}$ 是特征空间 R^N 上的一个有限数据集,再把 X 划分为 C 类($2 \leq C \leq N$),设个数为 C 的聚类中心 $V = \{v_1, v_2, \dots, v_C\}$, $N \times C$ 维矩阵 $U = (u_{ij})$, $u_{ij} \in [0, 1]$ 表示每个样本的隶属度矩阵。其中, $i = 1, 2, \dots, N$; $j = 1, 2, \dots, C$ 。FCM 算法的目标函数为

$$J_{\text{FCM}}(U, V) = \sum_{i=1}^N \sum_{j=1}^C u_{ij} \|x_i - v_j\|^2 \quad (1)$$

在式(2)约束下取得极小值

$$\sum_{j=1}^C u_{ij} = 1 \quad u_{ij} \in [0, 1] \quad (2)$$

应用拉格朗日乘法,在式(2)约束条件下对式(1)求导,得

$$v_j = \frac{\sum_{i=1}^N u_{ij}^m x_i}{\sum_{i=1}^N u_{ij}^m} \quad (3)$$

$$u_{ij} = \frac{1}{\sum_{k=1}^C \left(\frac{\|x_i - v_j\|^2}{\|x_i - v_k\|^2} \right)^{\frac{2}{m-1}}} \quad (4)$$

其中: m 为模糊加权指数。恰当的 m 值具有抑制噪声、平滑隶属函数等功效,但是如何优选参数 m ,尚无好的理论指导。

FCM 算法的具体步骤如下:

输入: 聚类数目 C 和数据集。

输出: 聚类中心集合 v_j , 使 $J_{\text{FCM}}(U, V)$ 最小。

a) 根据聚类数目 C , 随机选取聚类中心 $V^0 = \{v_1, v_2, \dots, v_C\}$ 和终止误差 ε , 并设当前迭代次数为 $l = 0$ 。

b) 由式(3)求隶属度矩阵 U^l 。

c) 由式(4)求下一次迭代的聚类中心 V^{l+1} 。

d) 若 $\|U^{l+1} - U^l\| < \varepsilon$, 则迭代结束; 否则置 $l = l + 1$, 返回步骤 b) 执行。

2 蛙跳算法

蛙跳算法是由 Eusuff 等人^[8,9]在 2003 年提出的。在 SFLA 中, 先将青蛙群体分为不同的子群, 子群中每个青蛙都有自己的文化, 在子群中进行文化的传播, 即进行局部搜索, 局部搜索使得信息在局部个体间得到交换。当子群进化到一定阶段后, 执行混合策略使得局部间的信息得到交换, 继续前面的操作, 直到最终实现寻优的目的。

对于 d 维问题, 随机生成 F 只青蛙(解)组成初始群体, 第 i 只青蛙可以表示为 $X_i = (x_{i1}, x_{i2}, \dots, x_{id})$, 将种群内青蛙个体按适应度降序排列。然后将整个群体分为 s 个子群, 每个子群包含 n 只青蛙, 满足 $F = s \times n$ 。第 1 只青蛙被分入第 1 个子群, 第 2 只青蛙被分入第 2 个子群……第 s 只青蛙被分入第 s 个子群, 第 $s+1$ 只青蛙被分入第 1 个子群。依此类推, 直到所有青蛙分配完毕^[10,11]。

在每一个子群中, 适应度值最好的解和最差的解分别记为 $X_b = (x_{b1}, x_{b2}, \dots, x_{bd})$ 、 $X_w = (x_{w1}, x_{w2}, \dots, x_{wd})$, 而群体中适应度值最好的解记为 $X_g = (x_{g1}, x_{g2}, \dots, x_{gd})$ 。在每次迭代中, 只对子群中的 X_w 进行更新操作, 其更新策略为

$$D_i = \text{rand}() \cdot (X_b - X_w) \quad (5)$$

$$X_w = X_w(\text{当前位置}) + D_i \quad (-D_{\max} \leq D_i \leq D_{\max}) \quad (6)$$

其中: $\text{rand}()$ 是 $0 \sim 1$ 的随机数, $D_{\max}$ 是允许青蛙移动的最大距离。

经过更新后, 如果得到的解 X_w 优于原来的解 X_w (当前位置), 则取代原来种群中的解; 否则用 X_g 取代 X_b , 重复执行更新策略式(5)(6); 如果仍然没有改进, 则随机产生一个新解取代原来的 X_w 。重复这种更新操作, 直到设定的迭代次数即完成一轮各子群的局部搜索, 然后将所有子群的青蛙重新混合排序, 并划分子群, 进行下一轮的局部搜索。如此反复直到满足终止条件。

3 基于选择和变异机制的蛙跳 FCM 算法 (SMSF-LA-FCM)

3.1 改进的更新策略

为了充分体现 SFLA 群体智能行为的信息共享机制, 提高局部搜索效率, 借鉴 PSO 算法中粒子更新策略, 对 SFLA 中最差青蛙的移动步长更新策略进行了改进。借鉴文献[12], 通过在 SFLA 中引入惯性权重 ω 来协调该算法的全局和局部搜索能力。具体实现是将式(5)的移动步长计算公式变为式(7), 同时式(6)的位置更新保持不变。

$$D_i = \omega D_i' + \text{rand}() \cdot (X_b - X_w) \quad (7)$$

其中: D_i' 为前一个最差青蛙的移动步长, ω 为惯性权重。

3.2 线性调整 ω

惯性权重 ω 表示青蛙运动趋势, 在局部最优解附近, ω 应取得较大, 有利于跳出局部最优解, 避免早熟; 在全局最优解附近, ω 应取得较小, 有利于在全局最优解附近更精细地搜索, 更迅速地找到最优解。因此, 在青蛙刚进入搜索时, ω 应取得较大, 随着搜索的进行, 算法向最优解靠近, 此时 ω 应取得较小。据此 ω 按式(8)进行线性递减调整, $\omega_i(t)$ 表示第 t 次第 i 只青蛙的惯性权重, $\omega_{\min}$ 、 $\omega_{\max}$ 分别表示惯性权重最小和最大值, 则有

$$\omega_i(t) = (\omega_{\max} - \omega_{\min}) \left[\frac{it \cdot tit - t}{it \cdot tit} \right] + \omega_{\min} \quad (8)$$

其中: $t = it_j \times tit_k$, it_j 为当前子群内的迭代次数; it 为子群内迭代总次数; tit_k 为当前混合迭代次数; tit 为混合迭代总次数; $j \in [1, it]$ 的整数, $k \in [1, tit]$ 的整数。

3.3 选择机制

用适应度值来衡量解的优劣, 受遗传算法中轮盘赌策略启发, 按青蛙个体的适应度值来确定其选择概率, 计算公式为

$$P_i = 1 - \frac{f(x_i)}{\sum_{i=1}^F f(x_i)} \quad (9)$$

其中: P_i 为第 i 只青蛙的选择概率; $f(x_i)$ 为第 i 只青蛙的适应度值; $\sum_{i=1}^F f(x_i)$ 为 F 只青蛙适应度值的总和。

从式(9)可知, 青蛙个体的适应度值越小, 选择概率越大; 反之, 选择概率越小。为了发挥优秀青蛙的作用, 让群体向最优解的方向靠近。在 SFLA 中引入了选择机制, 通过式(9)计算每只青蛙的选择概率, 再按选择概率将青蛙进行降序排列, 让选择概率位于前 $\frac{1}{4}$ 的青蛙代替后 $\frac{1}{4}$ 的青蛙, 使算法向最优解的方向进行。

3.4 变异机制

SFLA 实质是用函数的适应度值来衡量青蛙的优劣。最差青蛙根据自己的移动经验及其他青蛙的移动经验,动态调整自己的移动步长,向群体中最好青蛙位置移动,从而使所优化问题得到最优解。若搜索到的位置对应的解只是优化问题的一个局部最优解,则算法出现早熟现象。因此将遗传算法中的变异思想引入 SFLA 中,对青蛙的惯性权重 ω 和青蛙群体的最优解 X_g 进行变异。在算法出现早熟时,让变异操作后的青蛙在解空间的其他区域进行搜索,找到更优的全局解,避免算法陷入局部最优解,变异方程为

$$\omega' = \omega + \xi_1 N(0,1) \omega \quad (10)$$

$$X'_g = X_g + \xi_2 N(0,1) X_g \quad (11)$$

其中: ω' 为变异后的惯性权重值; X'_g 为变异后群体的最优解; ξ_1, ξ_2 为变异参数; $N(0,1)$ 是均值为 0 且方差为 1 的随机变量。新算法将所有青蛙按适应度值从大到小排列,对群体的前 $\frac{1}{2}$ 青蛙使用较大的变异概率 $P_{\max}$,对群体的后 $\frac{1}{2}$ 青蛙使用较小的变异概率 $P_{\min}$ 。

3.5 适应度函数

适应度函数是度量个体对聚类问题的适应程度,对于聚类的模型而言,其最优聚类结果对应目标函数值最小,即聚类效果越好,目标函数值越低,而聚类结果对应的个体适应度值越大。

设样本空间 $X = \{x_1, x_2, \dots, x_N\}$, 其中 x_i 为 d 维向量。SFLA 中一个青蛙代表一个聚类中心集合 $C = \{c_1, c_2, \dots, c_C\}$, 其中 c_j 是与 x_i 同维的向量,对于混合蛙跳算法中每个解(聚类中心)的评价,定义个体适应度函数为

$$f(x_i) = \frac{1}{J+1} = \frac{1}{\sum_{i=1}^N \sum_{j=1}^C u_{ij} \|x_i - v_j\| + 1} \quad (12)$$

其中: J 是式(1)中定义的目标函数, J 越小, $f(x_i)$ 就越高,聚类效果越好。

3.6 SMSFLA-FCM 描述

SMSFLA-FCM 主要思想是:先将线性递减的惯性权重引入蛙跳算法的更新策略中,按照一定的概率选择适应度值较优的青蛙代替较差青蛙,并对每只青蛙个体以不同的概率变异;再用改进后的蛙跳算法来求得最优解(聚类中心)作为 FCM 算法的初始聚类中心;然后利用 FCM 算法优化初始聚类中心;最后求得全局最优解。算法的具体步骤如下:

a) 参数初始化,给定聚类数目 C ,允许误差 $\varepsilon, l=1$,模糊指数 m ;青蛙种群总数 F ,子群数 s ,每个子群内青蛙数 n ,子群内迭代总次数 it ,混合迭代总次数 tit ,变异参数 ξ_1, ξ_2 ,变异概率 $P_{\min}, P_{\max}$ 。

b) 随机产生青蛙群体,初始化青蛙群 $v_1, \dots, v_C$,其中 v_j 为一个任意产生的聚类中心的集合 $X = \{x_1, x_2, \dots, x_N\}$ 。

c) 针对每只青蛙,根据式(4)计算隶属度矩阵 U 。

d) 根据式(12)计算每只青蛙的适应度值 $f(x_i)$,按照 $f(x_i)$ 以降序对青蛙群体进行排序和子群划分。

e) 通过式(8)动态调整 ω ,再按式(6)(7)对最差青蛙进行更新,直到设定的迭代总次数 it ,对更新后的子群进行混合,取代原来的群体。

f) 用式(9)计算每只青蛙的选择概率 P_i ,并按降序排列,用位于前 $\frac{1}{4}$ 的青蛙代替后 $\frac{1}{4}$ 的青蛙。

g) 根据式(10)(11),对群体前 $\frac{1}{2}$ 青蛙使用 $P_{\max}$,后 $\frac{1}{2}$ 青蛙使用 $P_{\min}$ 进行变异。

h) 若当前迭代次数达到预先设定的最大次数 tit ,则迭代停止,在最后一代找到最优解,输出取得 X_g 的青蛙,即聚类中心的集合;否则转到步骤 c), $l=l+1$ 。

i) 根据式(4)更新青蛙群体的隶属度矩阵。

j) 根据式(3)更新群体的聚类中心,计算相邻两代隶属度矩阵之差 E ,若 $E < \varepsilon$,停止;否则转到步骤 i)。

4 实验结果与分析

为验证 SMSFLA-FCM 算法的聚类性能,分别采用人造数据、经典数据集进行了两组测试实验,并与 SFLA-FCM 和 FCM 算法进行了比较。各算法中允许最小误差 $\varepsilon = 10^{-3}$,模糊指数 $m=2$ 。SMSFLA-FCM 算法采用文献[9]中建议的参数设置:青蛙种群总数 $F=150$,子群数 $s=5$,每个子群内青蛙数 $n=30$,子群内迭代总次数 $it=50$,混合迭代总次数 $tit=1000$ 。变异参数 $\xi_1 = \xi_2 = 0.5$,变异概率 $P_{\min} = 0.01, P_{\max} = 0.1$ 。

4.1 人造数据实验

图 1 构造了二维空间中两类非线性可分且样本空间分布差别较大的数据,一类为顶点在 $(2,0)$ 处的抛物线 $y = (x-2)^2, x \in (0,4), y \in (0,4)$ 上的呈对称分布的 100 个点;另一类为二维空间 (x,y) 中均匀分布的 100 个点,其中 x 的取值范围为 $(0.5,4)$, y 的取值范围为 $(1,6)$ 。将三种算法分别运行 20 次,聚类结果如表 1 所示。抛物点数据的 20 次平均适应度进化曲线如图 2 所示。

表 1 人造数据的聚类结果

算法	平均错分的个数		平均准确率/%	迭代次数	CPU 运行时间/s	方差
	抛物线点	随机点				
SMSFLA-FCM	6/100	2/100	96.00	11	36.35	1.97
SFLA-FCM	9/100	5/100	93.00	15	42.32	3.46
FCM	13/100	7/100	90.00	11	1.34	6.27




图 1 人造数据空间分布图




图 2 人造数据运行 20 次平均适应度进化曲线

从表 1 的仿真结果和图 2 可以看出, SMSFLA-FCM 算法的寻优效果明显好于其他两种算法。SFLA-FCM 和 FCM 在迭代过程中都不同程度地发生了早熟现象;而 SMSFLA-FCM 能动态调整惯性权重,提高了算法跳出局部收敛的能力,能够跳出局部最优,获得全局最优解。

4.2 经典数据集实验

4.2.1 IRIS 数据集实验

实验采用 IRIS 数据^[13]对算法进行测试,将三种算法分别运行 20 次。IRIS 数据集由 150 个样本组成,每个样本是四维向量,分别表示 IRIS 花萼的长度和宽度、花瓣的长度和宽度。整个样本集分为 setosa、versicolor 和 virginica 三个 IRIS 类,每类各有 50 个样本,其中 setosa 是线性的,versicolor 和 virginica

是非线性的。

图3所示为 IRIS 数据集前两维表示的分类结果,表2列出了两种算法对 IRIS 数据集的聚类结果,可见 SMSFLA-FCM 的聚类效果良好。图4是其他参数不变、动态惯性权重 ω 分别取 0.4、1、1.8 时对应的迭代曲线图。比较三条曲线可知,在局部最优解附近, $\omega = 1.8$ 时算法易跳出局部最优解,避免早熟;在全局最优解附近, $\omega = 0.4$ 时可使算法在全局最优解附近更精细地搜索,更迅速地找到最优解; $\omega = 1$ 时算法收敛速度较高,并且可以取得全局最优解。经过多次实验,可以确定 ω 满足线性递减的变化规律,既可以提高收敛速度,又可以提高解的精度。




图3 SMSFLA-FCM算法对IRIS数据集的聚类结果




图4 不同 ω 值迭代曲线图

从图3和表2的仿真结果可以看出, SMSFLA-FCM 聚类正确率较其他两种算法高,且运行时间较 SFLA-FCM 明显缩短。

4.2.2 高维数据、多样本高维数据集的实验

为验证本文算法对多样本、高维数据的聚类性能,利用三种算法分别对 multiple features^[13] 高维数据集和 breast cancer Wisconsin (diagnostic)^[13] 多样本高维数据集进行聚类,将三种算法分别运行 20 次。Multiple features 高维数据集的聚类结果如图5所示。从图5可看出, FCM 算法的收敛速度很快且易陷入局部最优, SFLA-FCM 算法在搜索初始阶段,适应度值变化较快,在中后期局限于局部空间的范围,易陷入局部最优解。本文算法引入了 SMSFLA,在进化早期,算法的 ω 较大,全局搜索能力很强,能获得较优初始解;在进化中期,采用动态调整 ω 可以平衡全局搜索和局部搜索能力,并按照一定的概率选择适应度值较优的青蛙代替较差青蛙,对较优青蛙以较小的概率变异,而对较差青蛙以较大的概率变异,使算法能跳出局部最优;在进化后期,算法的局部搜索能力较强,有利于得到更准确的全局最优解。从表2可知,本文算法的聚类效果优于 SFLA-FCM 和 FCM,显示出新算法的稳定性和鲁棒性。

Breast cancer Wisconsin (diagnostic) 多样本高维数据集的聚类结果如图6和表2所示。从聚类结果可知, FCM 算法快速下降后陷入了局部最优,而 SFLA-FCM 算法在初始阶段增加了全局的搜索能力,但是在中后期难逃局部最优的困扰。本文算法通过动态线性递减调整 ω 可以平衡全局搜索和局部搜索的能力,对各个阶段按照一定的概率选择适应度值较优的解代替较差解,同时对每个解以不同的概率变异,从而获取全局最优解。




图5 Multiple features数据集运行20次平均适应度进化曲线




图6 Breast cancer Wisconsin (diagnostic)数据集运行20次平均适应度进化曲线

表2 经典数据集的聚类结果

指标	数据集								
	IRIS 数据集			multiple features数据集			breast cancer Wisconsin (diagnostic)数据集		
	SMSFLA-FCM	SFLA-FCM	FCM	SMSFLA-FCM	SFLA-FCM	FCM	SMSFLA-FCM	SFLA-FCM	FCM
平均准确率/%	97.08	93.27	92.14	95.04	93.04	89.89	94.83	92.02	89.10
迭代次数	10	15	12	18	24	19	19	34	26
CPU 运行时间/s	37.45	44.28	1.84	48.23	64.78	8.28	58.43	87.89	14.18
方差	4.87	11.24	21.09	6.81	17.25	37.16	12.29	40.79	98.57

5 结束语

本文提出的 SMSFLA-FCM 算法先用线性递减的惯性权重修正最差青蛙的更新策略,按照一定的概率选择适应度值较优的青蛙代替较差青蛙,并对每只青蛙个体以不同的概率变异,再用 SMSFLA 求得最优解,将其作为 FCM 算法的初始聚类中心;然后利用 FCM 算法优化初始聚类中心;最后求得全局最优解。该算法既克服了 FCM 算法易陷入局部最优解的不足,又弥补了 FCM 算法对初始值敏感的缺陷。通过人工数据和经典数据集的实验表明, SMSFLA-FCM 算法通过线性递减调整惯性权重,可以很好地平衡局部搜索和全局搜索能力;同时,在优化的各个阶段,选择较优的解代替较差的解,并对较优青蛙以较小的概率变异,对较差青蛙以较大的概率变异,从而得到全局最优解,也使 FCM 算法对初始划分不再敏感,加快了收敛速度,聚类效果良好。

参考文献:

- [1] 毛国君. 数据挖掘原理与算法[M]. 2版. 北京:清华大学出版社, 2005:30-55.
- [2] 高新波. 模糊聚类分析及其应用[M]. 西安:西安电子科技大学出版社, 2004:37-60.
- [3] 周涓,熊忠阳,张玉芳,等. 基于最大最小距离法的多中心聚类算法[J]. 计算机应用, 2006, 26(6):1425-1427.
- [4] 孙洋,罗可. 基于免疫遗传算法的模糊 C-均值聚类[J]. 计算机工程与应用, 2009, 45(23):152-153, 169.
- [5] 陈治亚,方小斌,雷定猷. 一种基于微粒群的模糊聚类算法[J]. 计算机工程, 2007, 33(22):198-199.
- [6] 王敏,张冰. 粒子群优化的模糊 C-均值聚类航迹关联算法[J]. 探测与控制学报, 2010, 32(6):26-29.
- [7] 杨祖元,徐姣,罗兵,等. 基于 SFLA-FCM 聚类的城市交通状态判别研究[J]. 计算机应用研究, 2010, 27(5):1743-1745.
- [8] EUSUFF M M, LANSEY K E. Optimization of water distribution network design using the shuffled frog leaping algorithm[J]. Journal of Water Sources Planning and Management, 2003, 129(3):210-225.
- [9] AMIRI B, FATHIAN M, MAROOSI A. Application of shuffled frog-leaping algorithm on clustering[J]. The International Journal of Advanced Manufacturing Technology, 2009, 45(1-2):199-209.
- [10] ELBELTAGI E, HEGAZY T, GRIERSON D. Comparison among five evolutionary-based optimization algorithms[J]. Advanced Engineering Informatics, 2005, 19(1):43-53.
- [11] RAHIMI-VAHED A, MIRZAEI A H. A hybrid multi-objective shuffled frog-leaping algorithm for a mixed-model assembly line sequencing problem[J]. Computers & Industrial Engineering, 2007, 53(4):642-666.
- [12] 王俊伟,汪定伟. 粒子群算法中惯性权重的实验与分析[J]. 系统工程学报, 2005, 20(2):194-198.
- [13] <http://archive.ics.uci.edu/ml/datasets/> [EB/OL].