

基于 ACO-PSO 自适应的划分聚类算法

周文娟 赵礼峰

(南京邮电大学 理学院 江苏 南京 210023)

摘要: 针对经典划分聚类算法聚类数 K 先验未知及初始聚类中心随机选取,导致陷入局部最优的问题,提出一种基于 ACO-PSO 自适应的划分聚类算法。首先根据聚类算法内相似度最大差异度最小和类间相似度最小差异度最大的基本原则,将个体轮廓系数作为最佳聚类数的检验函数,得到聚类算法的自适应 K 值;其次利用群智能搜索方法思想,有效结合了粒子群算法和蚁群算法的优点,先利用具有全局性和快速性的粒子群算法获得初始信息素分布,再利用具有正反馈性和并行性的蚁群算法得到精确解。最后在多个 UCI 数据集上的仿真结果表明,该算法不仅求解能力优于传统聚类算法及基于个体轮廓系数优化的初始聚类中心算法,而且聚类时间效率大大提高,应用于大数据收敛速度更加明显。

关键词: K-means; 自适应; 个体轮廓系数; ACO-PSO; 鲁棒性

中图分类号: TP181

文献标识码: A

文章编号: 1673-629X(2019)02-0090-06

doi: 10.3969/j.issn.1673-629X.2019.02.019

A Segmentation Clustering Algorithm Based on ACO-PSO Adaptability

ZHOU Wen-juan ZHAO Li-feng

(School of Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Aiming at the problem that the prior unknown clustering number K and the random selection of the initial clustering center for the classical partitioning algorithm lead to local optimum, we propose a partitioning clustering algorithm based on ACO-PSO adaptability. Firstly, according to the basic principle of the minimum difference and maximum similarity within the class and the maximum difference and minimum similarity between classes, the adaptive K value of the clustering algorithm is obtained by using the individual contour coefficient as the test function of the best clustering number. Secondly, in combination with advantages of particle swarm optimization algorithm and ant colony algorithm inspired by swarm intelligence search, the initial pheromone distribution is obtained by particle swarm optimization algorithm with wholeness and rapidity, and then the exact solution is got by ant colony algorithm with positive feedback and parallelism. Finally, the simulation on multiple UCI data sets shows that the proposed algorithm is not only superior to the traditional clustering and initial clustering center algorithm based on individual contour coefficient optimization, but also shortens clustering time greatly, which is more obvious in convergence speed when applied to big data.

Key words: K-Means; adaptability; individual contour coefficient; ACO-PSO; robustness

0 引言

在科技社会飞速发展的今天,人工智能应用已经遍及世界各处,受到了人们的重视。聚类作为常用的无监督学习方法,在识别数据对象的内在关系方面,起到了极其重要的作用。K-Means 算法作为一种基于划分的经典聚类算法,根据差异度类内小类间尽可能大的原则进行聚类,基本思想通俗易懂,且聚类效果明显。但是该算法存在以下经典两大局限:(1)属于无监督的分类方法,聚类个数需要提前给出,不确定的 K

值对算法的性能影响很大;(2)易受初始聚类中心的影响,即不同的初始聚类中心聚类结果不同,容易陷入局部最优。学者们就以上问题提出了很多改进算法。

针对聚类中的 K 值问题, Pelleg 等^[1]在传统 K-Means 算法的基础上,对得到的 K 个聚类中心,利用贝叶斯信息标准(BIC)重新聚类以确定最佳 K 值;韩凌波^[2]综合了类内与类间差异度,构建距离评价函数作为最佳 K 值检验函数。另外粒子群优化算法^[3]也是一种全局优化算法, Merwe 等^[4]将 PSO 和 K-Means 进

收稿日期: 2018-03-19

修回日期: 2018-07-31

网络出版时间: 2018-11-15

基金项目: 国家自然科学基金青年基金项目(61304169)

作者简介: 周文娟(1992-),女,硕士研究生,研究方向为信息统计与数据挖掘;赵礼峰,教授,硕士,研究方向为图论及其在通信中的应用。

网络出版地址: <http://kns.cnki.net/kcms/detail/61.1450.TP.20181115.1050.064.html>

行融合,得到一种新算法,该算法充分利用 K-Means 较强的局部搜索能力和 PSO 的全局搜索能力,使得聚类结果更加精准;之后白树仁等^[5]以粒子群算法收敛条件为改进的切入点,探索在给定不同 K 值情况下适应度函数的变化特征,提出能够自动调整 K 值的改进算法。

针对 K-Means 聚类的初始聚类中心易陷入局部优化问题,近年来,基于元启发式优化的改进算法得到广泛关注。元启发式算法的主要优点具有易实现、理论简单、随机搜索能力强等特点,可以应用于众多类别的组合优化中^[6]。

国内外众多学者将启发式群优化算法与聚类分析结合应用到相关不同的领域。潘晓英等^[7]提出基于适应步长的萤火虫划分聚类算法,在给定聚类数的情况下,该算法的随机性和全局搜索能力协助找到初始聚类中心;朱春等^[8]在标准布谷鸟算法的基础上将发现概率 P 由固定值转变成随迭代次数逐步减小的变量,这样不仅可以提高搜索种群的质量,而且保证了算法的收敛;梁冰等^[9]利用人工蜂群算法架构简单、全局收敛速度快的优势,提出一种改进的将人工蜂群算法与模糊聚类算法相结合的聚类算法,通过人工蜂群算法的启发性得到最优解,以此解决在模糊聚类算法求解过程中确定初始聚类中心的问题。

1 理论基础

1.1 蚁群算法

1.1.1 基本原理

蚁群算法(ant colony optimization, ACO)的基本思想是蚂蚁在觅食过程中会分泌一种特殊的物质—信息素,而蚁群之间的交流正是通过该物质进行信息传递以及分工协作。在一定范围内能够觉察到该信息素并指导它的行为,当某些蚁群在一些路径上留下足迹,也给其他蚂蚁提供了选择该路径的信号,使得蚂蚁越来越多,于是越发增加了信息素强度,形成一套正反馈学习系统慢慢接近最优路径。

1.1.2 模型

蚁群算法通常在组合优化问题中应用广泛。所谓组合优化是某种离散对象按某个确定的约束条件进行安排,当已知合乎这种约束条件的特定安排存在时,寻求这种特定安排在某个优化准则下的最大或最小的解问题。

假如 m 只蚂蚁有可供选择的 n 个城市,每只蚂蚁进行每一步选择都是建立在前面蚂蚁选择该路径的基础上,然后提供给下一个还没有访问该路径的蚂蚁,时刻位于城市 i 的蚂蚁 k 选择城市 j 为目标的概率是:

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{l \in U} [\tau_{il}(t)]^\alpha [\eta_{il}(t)]^\beta} & j \in U \\ 0 & \text{else} \end{cases} \quad (1)$$

信息素更新方程为:

$$\tau_{ij}(t+1) = \rho \tau_{ij}(t) + \sum_{k=1}^m \Delta \tau_{ij}^k(t) \quad (2)$$

说明:

m —蚂蚁个数;

n —节点(顶点)个数;

η_{ij} —边弧(i, j)的能见度,或称局部启发因子,一般取 $1/d_{ij}$, d_{ij} 表示路径(i, j)之间的长度;

(由城市 i 转移到城市 j 的能见度亦称启发信息)

$\tau_{ij}(t)$ —边弧(i, j)的信息素轨迹强度;

$\Delta \tau_{ij}^k$ —蚂蚁 k 在边弧(i, j)留下的信息素单位长度数量;

p_{ij}^k —蚂蚁 k 由城市 i 到城市 j 的概率;

α —信息启发式因子,代表轨迹的相对重要程度($\alpha \geq 0$);

β —期望启发式因子,代表能见度的相对重要程度($\beta \geq 0$);

ρ —信息素轨迹的持久性($0 \leq \rho \leq 1$), $1 - \rho$ 可理解为轨迹衰减度;

Q —体现蚂蚁所留轨迹数量的一个常数;

U —可行节点集合;

N_i^k —为第 k 只蚂蚁在第 i 节点出发下一步的可行节点集;

$\text{tabu}(k)$ —一个列表,用于记录第 k 只蚂蚁到目前为止已经访问的城市。

按照 $\Delta \tau_{ij}^k$ 的取法不同,通常有以下三种蚂蚁算法模型:

蚂蚁密度模型: $\Delta \tau_{ij}^k = Q$

蚂蚁数量模型: $\Delta \tau_{ij}^k = Q/d_{ij}$

蚂蚁圈模型: $\Delta \tau_{ij}^k = Q/L^k$

其中, U 为可行节点集合,具体应用中经常用 N_i^k 表示, N_i^k 为第 k 只蚂蚁在第 i 个节点出发下一步的可行节点集; L^k 为第 k 只蚂蚁在本次循环中所走的路径的长度。

总体而言,三种模型各有所长,从局部考虑的是采用蚂蚁密度模型和蚂蚁数量模型,而全局考虑较好的一般利用蚂蚁圈模型。

1.2 粒子群算法

1.2.1 思想原理

粒子群算法(particle swarm optimization, PSO)利用群体间的信息共享和个体自身经验的总结不断修正个体的行为策略。在空间中,鸟被视作一个可以忽略

大小的微粒,寻找最优解的过程就相当于鸟儿找到食物坐标的过程。每只鸟会分享当前时刻各自距离食物的最短路径,之后鸟群都会向着这个最短距离飞去,所以就会出现一聚一散,不断地变换方向,使整个群空间通过不断演化,从杂乱无章到一致协调,从而获得最优解。

1.2.2 模型

假设在 D 维空间中,有 m 个粒子,粒子 i 位置: $X_i = (X_{i1}, X_{i2}, \dots, X_{iD})$, 粒子 i 的飞行速度为: $V_i = (V_{i1}, V_{i2}, \dots, V_{iD})$, $i \in [1, m]$, $d \in [1, D]$, 粒子 i 经历过的历史最好位置: $P_i = (P_{i1}, P_{i2}, \dots, P_{iD})$, 群体内(或领域内)所有粒子经历过的最好位置: $pg = (pg_1, pg_2, \dots, pg_D)$ (以上变量均为实数空间取值)。

基本 PSO 公式:

$$\begin{aligned} V_{id}^{k+1} &= V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (pg_d^k - X_{id}^k) \\ X_{id}^{k+1} &= X_{id}^k + V_{id}^{k+1} \end{aligned} \quad (3)$$

其中, c_1, c_2 为学习因子或加速系数,一般为正常数,通常取 2; r_1, r_2 的取值范围是 $[0, 1]$, 是该区间内均匀分布的伪随机数; V_{\max} 为粒子速度能达到的最大值。

粒子 i 第 d 维的速度更新公式为:

$$V_{id}^{k+1} = \omega V_{id}^k + c_1 r_1 (P_{id}^k - X_{id}^k) + c_2 r_2 (pg_d^k - X_{id}^k) \quad (4)$$

粒子 i 第 d 维的位置更新公式为:

$$X_{id}^{k+1} = X_{id}^k + V_{id}^{k+1} \quad (5)$$

说明:

V_{id}^k —第 k 次迭代粒子 i 飞行速度矢量的第维分量;

X_{id}^k —第 k 次迭代粒子 i 位置矢量的第维分量;

c_1, c_2 —学习因子,调节学习的最大步长;

r_1, r_2 —两个随机函数,取值范围是 $[0, 1]$,以增加搜索随机性;

ω —惯性权重,调节对解空间的搜索能力。

2 自适应 K 值的个体轮廓系数算法

2.1 聚类数 K 值

聚类数 K 的最佳范围为 $[K_{\min}, K_{\max}]$, 即首先需要确定 K_{\min}, K_{\max} 的取值,一般而言 K_{\min} 取 2, 因为当 $K_{\min} = 1$ 为均匀分布, K_{\max} 根据经验法则取 \sqrt{n} , 符合大多数自然分布的样本,文中采用此规则来确定聚类数 K 的取值范围。

2.2 个体轮廓系数

轮廓系数是由 Kaufman 等提出的概念,其定义表达式如下:

$$S = \frac{1}{n} \sum_{i=1}^n s_i \quad (6)$$

不难看出,轮廓系数是所有个体轮廓系数的求和取平均,因此个体轮廓系数具体定义如下:

$$s_i = \frac{b(i) - a(i)}{\max[a(i), b(i)]} \quad (7)$$

$$a(i) = \frac{1}{n_c - 1} \sum_{j \in C_c, i \neq j} d(i, j) \quad (8)$$

$$b(i) = \min_{p \neq c} \left[\frac{1}{n_{pj} - 1} \sum_{j \in C_p, i \neq j} d(i, j) \right]$$

假设样本 i 被聚到 C 类, $a(i)$ 表示样本 i 和同属于 C 类的其他所有样本之间的平均距离, $b(i)$ 表示样本 i 和非 C 类的各个类中所有样本的平均距离的最小值, s_i 表示类内样本与类间样本的差异性的最小值,从而体现样本聚类结果的优越性,其取值范围在 $[-1, 1]$, 取值越大,表示该样本的类内平均距离远与类间平均距离越明显,则说明对该样本的聚类达到了最优效果。

2.3 变化率函数

适应度函数是用来评价当前步骤聚类结果的好坏,针对个体轮廓系数,知道随着群集数量的增加,该值不断减少,通过绘制结果曲线,则可能会发现在达到某个 K 值时,平方距离的总和会突然下降很快,然后再慢慢减小。在这里,可以找到最佳聚类数。因此文中定义一种新的适应度函数—基于个体轮廓系数的变化率函数。

适应度函数值的大小表示聚类效果的好坏,越大越好,用式 9 表示算法的适应度。显然,不同的 K 值得到的适应度值不同,而在数据集合适的 K 值之前或之后,适应度值的大小有着明显的差异,一般是之前的幅度非常大,之后增大的程度很微小。因此,需要一个能反应单次变化程度在总变化过程中最突出的变量,从而引入变化率概念,表达式定义如下:

$$p_k = \frac{S_k - S_{k-1}}{S_k - S_1} > \varepsilon \quad (9)$$

其中,用 p_k 表示 K 时的变化率, ε 表示一个很小的数。根据 K 值的特点可知,随着其值不断增加, p_k 逐渐减小,最后无限接近零,可以根据 p_k 的变化来知道哪一步迭代为最佳迭代过程。

2.4 算法

根据个体轮廓系数设计了 K 值优化算法,即在传统 K-Means 算法的基础上,通过个体轮廓系数优化 K 值,运算过程描述如下:

Input: n 个数据对象的数据集;

Output: 个体轮廓系数最小时的 K 值。

(1) 根据检验法则确定 K 的取值范围: $1 < K \leq \sqrt{n}$, 以及事先拟定的迭代次数 N ;

(2) 利用 K-Means 算法计算出不同聚类数 K 下的聚类结果, 在每个 K 值上重复运行数次 K-Means(避免局部最优解);

(3) 根据个体轮廓系数分别计算不同聚类数 K 下的 S , 计算当前 K 的平均轮廓系数;

(4) 利用变化率函数搜索在变化率最大值下的相应 K 值;

(5) 输出最佳聚类数 K 。

3 蚁群和粒子群融合算法

3.1 依据

蚁群算法和粒子群算法作为人工智能领域的两大主要算法, 两种算法的有效融合已经广泛应用于许多领域, 如离散优化问题、旅行商问题、最大流最短回路问题等。粒子群算法也是起源于对简单社会的模拟, 最初是模拟鸟群觅食的过程, 但后来发现其是一种很好的优化工具。二者的优缺点对比如表 1 所示。

表 1 算法对比

算法	优点	缺点
蚁群算法	正反馈性能力	初始信息素缺乏 求解速度慢
	分布式计算	
	通用型随机化方法	
	启发式搜索	
粒子群算法	全局搜索且同时进行	后期局部搜索速度慢 不能充分利用信息
	快速收敛, 高效调整参数	
	能够扩展, 易于结合其他算法	

通过对比可以看出, 蚁群算法多应用于离散变量问题处理, 但是搜索时间很长, 很容易陷入局部最优解。粒子群算法更加擅长解决连续问题, 并且它具有收敛速度快、算法简单等优点。因此, 针对优化初始聚类中心点, 文中试图通过融合两大算法各自优势, 找到一种更加科学合理的改进策略, 并且融合两大算法策略已经被充分肯定。

如陈睿等^[10]针对双边匹配问题, 以求得利益最大化以及同时满足多方需求为主要目标, 提出一种改进的粒子群蚁群优化算法。柴大宝等^[11]考虑到蚁群算法的控制参数往往需要经验来取得, 提出将粒子群算法应用于蚁群算法中, 从而解决著名的旅行商问题。且融合算法验证得到新算法对于参数的调整工程量大大降低, 避免了许多盲目查询的实验。潘鸿雁^[12]将蚁群算法和粒子群算法融合到 Ad Hoc 网络组传播路由的研究中, 用以解决单一算法存在的局限性, 主要策略是用蚁群算法发现大量的路径并选出较优备选路径集后, 通过粒子群算法的全局搜索能力^[13]进一步搜索, 然后依据其约束条件和调整算子交叉进行及时调整, 解决算法在求解 QoS 组播路由问题中的最优路径。

3.2 融合策略

(1) PSO 拥有粒子本身位置和速度参考信息, 但是在进行精确求解过程中搜索能力差, 不能充分利用反馈信息。将 ACO 引入到 PSO 系统的每次迭代过程中, 以 ACO 每一代形成的解作为 PSO 的初始种群, 然后经过 PSO 的多次迭代, 通过其正反馈性进行不断调整, 从而找到更好的解, 提高求解速率, 得到快速收敛。

(2) ACO 是某种启发式算法和正反馈机制有机结

合的产物, 这种结合容易出现早熟现象, 加上求解速度慢以及初始信息匮乏等缺点, 将 PSO 引入到 ACO 中, 使得蚁群算法具有粒子群算法独特的优势, 从而可以根据全局和局部最优解及时进行有效调整。

3.3 算法过程

Input: n 个数据对象的数据集 $D = \{X_1, X_2, \dots, X_n\}$, 聚类数目 K , 粒子群体大小 N , 初始化种群 $P(0)$;

Output: 最优初始聚类中心。

(1) 在给定聚类数下, 随机选定初始聚类中心。首先按照 K-Means 算法随机或者人为给定初始聚类结果, 然后通过计算粒子适应度值进行不断调整并给定粒子的速度。重复操作反复进行 N 次, 共生成 N 个初始粒子群。

(2) 对于粒子每一维适应度值, 将其与它所经历的最好位置 p_{id} 的适应值进行比较, 如果更好, 按照式 4 和式 5 更新 p_{id} , 反之则进行下一步。

(3) 对每个粒子适应度值, 将其和群体所经历的最好位置 p_{gd} 的适应值进行比较, 如果更好, 按照式 3 更新 p_{gd} , 反之则进行下一步。

(4) 对于新一代粒子, 按照以下的蚁群算法优化, 得到新个体的 K-Means 优化。

(a) 对粒子的聚类中心编码, 此步中信息素即为上述适应度值, 按照式 1 和式 2 进行更新, 以确定对所有粒子的聚类划分;

(b) 按照聚类划分, 计算新的聚类中心, 更新粒子的适应度值, 取代原来的编码值。

(5) 如果满足结束条件(给定阈值或最大迭代次数), 则结束, 否则转步骤 2。

4 实验仿真

该实验是基于 MATLAB 平台验证文中算法在处理大规模数据时的稳定性和鲁棒性,验证数据集来源于 UCI 机器学习网站,分别为 Iris、Wine、Yeast 三个分类数据集。各个数据集的属性特征如表 2 所示。

表 2 数据集的属性特征

数据集	类别数	属性数量	样本数量
Iris	3	4	150
Wine	3	13	178
Yeast	10	8	1 484

为了验证改进算法的稳定性和鲁棒性,从以下两部分进行讨论求解。

4.1 聚类数 K 的确定

根据文中提出的聚类数 K 确定算法,求出三种数据集的个体轮廓系数图,通过画出其个体轮廓系数图得到合理可视化的聚类数目,如图 1 所示。

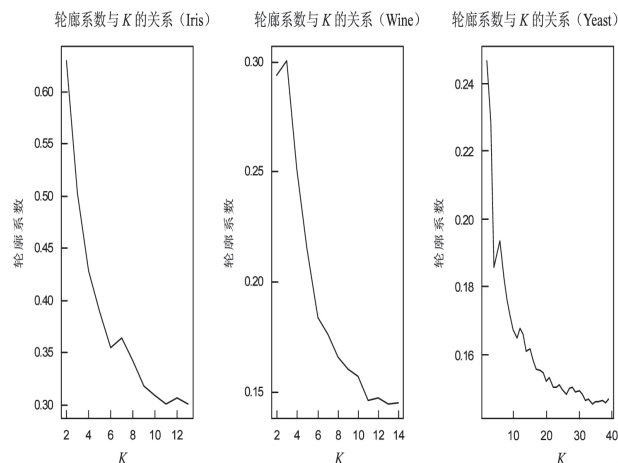


图 1 三个数据集关于 K 值的轮廓系数

由图 1 可知:

(1) 针对数据集 Iris,当 K 值等于 2 时,具有最大轮廓系数,而数据集实际分为了三个类,而 K 值取 4 之后,轮廓系数的变化趋势就不是特别明显。

(2) 针对数据集 Wine, K 值等于 3 时,具有最大轮廓系数,而数据集实际也是三类,当 K 值取 6 之后,轮廓系数的变化趋势就不是特别明显。

(3) 针对数据集 Yeast,当 K 值等于 3 时,具有最大轮廓系数,实际也是十类,而 K 值取 4 之后,轮廓系数的变化趋势就不是特别明显。

综上,随着 K 值的不断增大,个体轮廓系数逐渐减小,并不能作为适应度函数的评价标准,所以需要选择一个合适的适应度函数——变化率函数。各数据集的个体轮廓系数变化率趋势图如图 2 所示。

利用变化率函数来判断最佳的聚类个数 K ,通过计算得出数据集 Iris、Wine、Yeast 的最佳聚类数为 3,

4 4。




图 2 三个数据集的相邻轮廓系数间的变化率

4.2 初始聚类中心的优化

由上一步可知,三个数据集的最佳聚类数均已确定,那么接下来分别针对这三个数据集进行初始聚类中心的优化。

确定选取粒子群大小均为 $N = 30$,当三个数据集 Iris、Wine、Yeast 的最佳聚类数分别为 $K = 3, 4, 4$,依次采用传统 K-Means 算法,基于个体轮廓系数自适应地选取优秀样本来确定初始聚类中心的改进算法 (OIC-CABICC) 以及文中算法 (PSO-ACO),基于 MATLAB 对所提算法的有效性进行验证。

首先,通过粒子群算法选取的 30 个粒子种群进行加权求平均,得到问题的次优解,然后利用次优解的类内路径长度、类间形成的路径长度,作为蚁群算法信息素更新公式中的初始信息素,在蚁群算法中,蚂蚁的个数等于粒子个数,遍历城市个数等于聚类个数 K ,然后利用信息素更新公式得到最优解。新算法避免了优化过程中的搜索盲目性,并且加入了精确求解思想,从而显示新算法在求解能力和时间效率上的对比,如表 3 和表 4 所示。

表 3 新算法在求解能力上的优势比较

数据集	拟合效果			轮廓系数		
	K-Means	ICBAS	PSO-ACO	K-Means	ICBAS	PSO-ACO
Iris	70.20%	90.67%	98.89%	0.384 1	0.563 3	0.630 0
Wine	59.94%	70.22%	83.00%	0.560 4	0.571 1	0.300 5
Yeast	49.37%	66.32%	82.53%	0.531 9	0.551 6	0.258 7

表 4 新算法在求解效率上的优势比较

数据集	运行时间/min		
	K-Means	ICBAS	PSO-ACO
Iris	0.021	0.126	0.077
Wine	0.042	0.172	0.113
Yeast	0.532	10.979	4.257

从以上结果可以看出,新算法较其他两种算法在

求解效率和优化能力上有明显的优势。首先经过粒子群算法的优化,初始聚类中心得到了改善,不再是随机或者人为给定,避免了传统算法由于初期信息素缺乏而造成的盲目性,也有利于蚁群算法更精确的求解。

5 结束语

仿真实验表明,通过设定粒子群和以个体轮廓系数作为适应度函数评价准则,使得 K-Means 聚类的最佳聚类数目得以确定,个体轮廓系数结合粒子类内距离与类间距离,判断某个粒子被聚到某一类的合理性,数值越大,表明某粒子的类内平均距离与类间平均距离的差异性越大,即越合理;另外,通过设定粒子群,避免个体轮廓系数陷入局部最优,文中将粒子群个数取 30,30 个粒子群的平均个体轮廓的系数值作为最终值。

初始聚类中心优化的好坏程度,主要体现在最终聚类的时间性能和优化性能上,文中算法的优势较其他算法均有体现,具有可行性。并且该算法能够应用于所有类型的数据集。此次实验数据是建立在小型数据平台实现的,对于大数据平台 Hadoop 应用是下一步研究的重点。

参考文献:

- [1] PELLEG D, MOORE A. X-means: extending K-Means with efficient estimation of the number of clusters [C]//Proceeding of the 17th international conference on machine learning. San Francisco, CA, USA: Morgan Kaufmann Publishers Inc., 2000: 727-734.
- [2] 韩凌波. K-均值算法中聚类个数优化问题研究 [J]. 四川理工
- 工学院学报: 自然科学版, 2012, 25(2): 77-80.
- [3] 胡旺, Gary G. YEN, 张鑫. 基于 Pareto 熵的多目标粒子群优化算法 [J]. 软件学报, 2014, 25(5): 1025-1050.
- [4] VAN DER MERWE D W, ENGELBRECHT A P. Data clustering using particle swarm optimization [C]//Congress on evolutionary computation. Canberra, ACT, Australia: IEEE, 2003: 215-220.
- [5] 白树仁, 陈龙. 自适应 K 值的粒子群聚类算法 [J]. 计算机工程与应用, 2017, 53(16): 116-120.
- [6] JAFAR O A M, SIVAKUMAR R. A study on fuzzy and particle swarm optimization algorithms and their applications to clustering problems [C]//IEEE international conference on advanced communication control and computing technologies. Ramanathapuram, India: IEEE, 2012: 462-466.
- [7] 潘晓英, 陈雪静, 李昂儒, 等. 基于自适应步长的萤火虫划分聚类算法 [J]. 计算机应用研究, 2017, 34(12): 3576-3579.
- [8] 朱春, 李林国, 郭剑. 基于改进布谷鸟优化的模糊聚类图像分割 [J]. 计算机科学, 2017, 44(6): 278-282.
- [9] 梁冰, 徐华. 基于改进人工蜂群的核模糊聚类算法 [J]. 计算机应用, 2017, 37(9): 2600-2604.
- [10] 陈睿, 赵志刚, 张雁茹, 等. 基于改进粒子群蚁群算法的多目标双边匹配问题 [J]. 计算机工程与设计, 2017, 38(1): 220-225.
- [11] 柴宝杰, 刘大为. 基于粒子群优化的蚁群算法在 TSP 中的应用 [J]. 计算机仿真, 2009, 26(8): 89-91.
- [12] 潘鸿雁. 基于蚁群算法和粒子群算法的 Ad Hoc 网络组播路由的研究 [D]. 秦皇岛: 燕山大学, 2014.
- [13] SHI Y, EBERHART R C. A modified particle swarm optimizer [C]//Proceedings of the IEEE international conference on evolutionary computation. [s.l.]: IEEE, 1998: 69-73.
- [1] PATKAR S, GHAUDHURI P. Wetting of porous solids [J]. Visualization and Computer Graphics, 2013, 19(9): 765-774.
- [2] LIU Zhibin, LI Zhanli. Dynamic cloth animation in virtual environments [C]//Proceedings of the conference on information visualization. [s.l.]: IEEE, 2006: 761-765.
- [3] 吕梦雅, 许立瑶, 唐勇, 等. 随机可控风场中三维布料实时仿真 [J]. 小型微型计算机系统, 2015, 36(12): 2769-2772.
- [4] INAKEAGE M. A simple model of flames [C]//Proceedings of the CGI90. [s.l.]: [s.n.], 1990: 71-81.
- [5] 石敏, 毛天露, 夏时洪, 等. 布料动画方法研究进展及问题 [J]. 计算机学报, 2012, 35(12): 2446-2458.
- [6] 刘亦歆. 三维场景中柔性物体仿真的研究 [D]. 成都: 西南石油大学, 2014.
- [7] FOSTER N, METAXAS D. Modeling water for computer animation [J]. Communications of the ACM, 2000, 43(7): 60-67.
- [8] 黄聪. 基于振动力和风力作用的服装仿真研究 [D]. 成都: 西南交通大学, 2016.
- [9] 范小娜. 基于 Kinect 三维重构及织物模拟研究 [D]. 杭州: 浙江大学, 2014.
- [10] 李杰. 面向智能眼镜的交互控制系统研究及实现 [D]. 成都: 电子科技大学, 2015.
- [11] 吴艳繁. 基于视线追踪的人机交互系统 [D]. 长春: 吉林大学, 2014.
- [12] 周忠, 周颐, 肖江剑. 虚拟现实增强技术综述 [J]. 中国科学, 2015, 45(2): 157-180.

(上接第 89 页)