

具有双重认知能力的人工蜂群算法及性能分析

谢 娟¹ 邱剑锋² 闵 杰¹ 汪继文²

(安徽建筑大学数理系 合肥 230022)¹ (安徽大学计算机科学与技术学院 合肥 230601)²

摘 要 针对人工蜂群算法在解决单峰问题时收敛速度过慢而在优化多峰问题时易陷入局部最优值的问题,依据群体动力学原理,引入“自我认知能力”和“社会认知能力”对蜂群觅食时的蜜源搜索策略进行改进,提出了具有双重认知策略的人工蜂群算法。用经典的标准测试函数进行了实验并与其他改进算法进行了比较,结果表明,改进的搜索策略提高了算法的优化能力,优于其他改进的人工蜂群算法。

关键词 人工蜂群算法,群体动力学,认知能力,优化

中图分类号 TP301.6 文献标识码 A DOI 10.11896/j.issn.1002-137X.2014.11.052

Improved Artificial Bee Colony Algorithm with Dual Cognitive Abilities and Performance Analysis

XIE Juan¹ QIU Jian-feng² MIN Jie¹ WANG Ji-wen²

(Department of Mathematics & Physics, Anhui Jianzhu University, Hefei 230022, China)¹

(School of Computer Science and Technology, Anhui University, Hefei 230601, China)²

Abstract Aiming at the problem that artificial bee colony algorithm has slower convergence rate in resolving unimodal problems and is easily trapped into local optimum in optimizing multimodal problems, according to the theory of group dynamics, an improved artificial bee colony algorithm with dual cognitive abilities which improves the search strategies of bees foraging behavior was presented by introducing the self-cognition and social cognition abilities. The experimental results show that the improved search strategies enhance the optimization performance of artificial bee colony algorithm and are superior to others by testing in a set of standard test functions.

Keywords Artificial bee colony algorithm, Group dynamics, Cognitive ability, Optimization

1 引言

人工蜂群算法(Artificial Bee Colony algorithm, ABC)是由土耳其学者 Dervis Karaboga 于 2005 年首次提出的一种基于群智能的优化算法^[1]。ABC 算法是对自然界蜜蜂觅食行为的模拟,整个蜂群由采蜜蜂、侦察蜂和观察蜂组成,由于劳动分工的不同,它们各自进行不同的活动,彼此之间通过摇摆舞实现信息共享和信息交互,从而确定问题的最优解。ABC 算法概念上易于理解,实现简单且具有较少的控制参数,越来越引起众多学者的关注并广泛地应用于图像聚类^[2]、组合优化^[3]、神经网络参数优化^[4]等多个领域。与其他的群智能算法类似,局部“开采”与全局“探测”能力的平衡是影响算法优化能力的重要因素。过度的局部开采将使算法过早地停滞而陷入局部最优;反之,将使算法收敛速度降低。ABC 算法中的“局部开采”由采蜜蜂和观察蜂负责,而侦察蜂负责新蜜源的发现,即“全局探测”。ABC 算法中所采用的搜索策略更倾向于“全局探测”而相对弱化了“局部开采”^[5],因此在优化单峰函数时收敛速度过慢,而在多峰函数优化时易陷入局部最优。近年来,不少学者提出了改进的 ABC 算法。Guopu Zhu

等受粒子群优化算法(Particle Swarm Optimization, PSO)的启发,在当前种群中引入最优值,用以改进其搜索策略,提出了 GABC 算法^[5];差分进化算法(Differential Evolution, DE)中的“最佳个体”对提高 DE 算法的收敛速度有明显的效果,据此 Weifeng Gao 等提出了改进的 ABC 算法 ABC/best。这些算法的改进提高了其局部开采的能力,但是这里的“最优个体”在多峰问题中往往可能是局部最优点,因此存在算法过早地陷入局部最优的风险^[6]。银建霞等在差分变异算子中引入混沌序列,以提高观察蜂的局部搜索能力^[7]。毕晓君等提出了基于反向学习的变异策略,以达到避免陷入局部最优的效果^[8]。此外,还包括基于混沌优化的双种群人工蜂群算法(BCABC)^[9]、基于自适应选择策略的蜂群算法(SABC)^[10]等杂交的改进 ABC 算法。

本文借鉴蜂群中的个体对其自身和整个蜂群的认知,提出一种新的具有双重认知能力的人工蜂群算法(ABC with dual cognitive abilities, DCA-ABC)。该算法中的蜜蜂可根据自身的采蜜经验和当前种群中的最佳蜜源,对其未来的搜索方向做出判断。几个典型的不同类型的测试函数用于验证 DCA-ABC 算法的优化性能。实验结果表明,该改进算法具

到稿日期:2013-06-25 返修日期:2013-08-16 本文受国家自然科学基金项目(71101002),安徽省自然科学基金项目(KJ2013A009),安徽高校省级自然科学基金项目(KJ2012B038),安徽省优秀青年人才基金项目(2011SQRL018),安徽大学青年科学研究基金(KJQN1015)资助。

谢娟(1980-),女,硕士,副教授,主要研究方向为群智能算法;邱剑锋(1979-),男,硕士,讲师,主要研究方向为自然计算、群智能算法, E-mail: qoujianf@sohu.com(通信作者)。

有较好的优化性能,可有效地平衡搜索过程中算法的“局部搜索”和“全局开采”能力,提高算法在解决不同优化问题时的鲁棒性。

2 基本的人工蜂群算法

ABC算法模拟蜜蜂觅食过程中所产生的智能行为。承担不同任务的蜜蜂彼此之间进行信息共享和信息交互,从而共同完成对问题的求解。整个ABC算法的框架如图1所示。

初始化

Repeat

采蜜蜂阶段:对蜜源的更新过程

观察蜂阶段:依据每个蜜源的适应度值选择一个蜜源,执行和采蜜蜂阶段相同的更新过程

侦察蜂阶段:淘汰含蜜量即将殆尽的蜜源,重新随机选择一个新的蜜源

Until 满足预先设定的条件

图1 ABC算法框架

2.1 初始化

ABC算法中每个蜜源代表优化问题的一个候选解,通常表示为:

$$x = (x_1, x_2, \dots, x_D) \quad (1)$$

D 代表优化问题的维数。基于种群的优化算法希望初始化的种群能够尽可能均匀地分布在整个搜索空间,以提高种群的收敛速度和最优解的质量。ABC算法中通常采用均匀分布的方式产生初始蜜源。

$$x_{ij} = x_j^{\min} + \text{rand}(0, 1)(x_j^{\max} - x_j^{\min}) \quad (2)$$

$i=1, \dots, SN; j=1, \dots, D$

SN 代表蜜源的数量, D 代表候选解的维数。初始化之后,整个ABC算法进入前述3个阶段的循环,直至满足某种条件,完成搜索任务。

2.2 采蜜蜂阶段

每个采蜜蜂对应一个蜜源,即蜜源的数量由采蜜蜂的数量决定。每个蜜源通常由式(1)表示为一个 D 维向量,作为对蜜蜂采蜜活动的抽象,每个采蜜蜂在其所在蜜源处产生一个扰动,以生成新的候选蜜源,候选蜜源采用下式产生:

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) \quad (3)$$

其中, x_i 表示搜索空间第 i 个候选解, x_k 为搜索空间内任意一个候选解且 $k \neq i \in [1, 2, \dots, SN]$, $\phi_{ij} \in [-1, 1]$ 为均匀分布的随机数。以差分向量 $x_i - x_k$ 作为对当前蜜源 x_i 的扰动,即算法的搜索步长。当算法接近全局最优值时,搜索步长会自适应地减小。

2.3 观察蜂阶段

采蜜蜂对各自所在的蜜源进行随机扰动,产生新的候选蜜源,根据贪婪算法确定是否需要原蜜源进行更新操作。为了便于对每个蜜源进行评估,在ABC算法中引入适应度值作为对每个蜜源优劣的度量。在蜜蜂采蜜过程中,蜂巢周围驻留了一批观察蜂,采蜜蜂通过摇摆舞的形式与观察蜂共享蜜源信息,通常较好的蜜源往往能招募到更多的观察蜂前往采蜜。这种信息共享和信息交互是蜂群智能行为的重要表现之一。在ABC算法中,对每个蜜源引入一个概率公式:

$$p_i = \frac{fitness_i}{\sum_{i=1}^{SN} fitness_i} \quad (4)$$

其中, $fitness_i$ 代表第 i 个蜜源的适应度值, p_i 对应第 i 个候选解在整个解集中所占百分比, p_i 越大,对应蜜源的质量越高,意味着该蜜源往往能招募到更多的观察蜂前往采蜜,以期发现更多的潜在最佳蜜源,此时观察蜂变为采蜜蜂。

2.4 侦察蜂阶段

当一个蜜源经过若干次开采之后,其对应的候选解的质量仍然得不到更新,该蜜源将被抛弃,进而由侦察蜂在整个搜索空间随机生成新的未被开采的蜜源。在ABC算法中,开采次数的上限由参数 $limit$ 决定,即当 $trials > limit$ 时,对应的蜜源被根据式(2)产生的新的蜜源所代替。重复上述几个阶段,直到算法收敛至最优值或满足迭代次数为止。

GABC^[5], ABC/best, ABC/rand^[6,11]等改进ABC算法所采用的策略是在ABC算法中引入“全局最优值”,即依据社会认知模型来更新搜索公式,这个“全局最优值”在一定程度上加速了算法的收敛,但在优化多峰问题时,也存在过早陷入局部最优的风险。

3 双重认知能力的人工蜂群算法(DCA-ABC)

在基本ABC算法中,每个蜜源利用其与蜂群内其他蜜源的差分作为更新策略,产生新的候选蜜源,这种策略存在一些不足,如前所述。同时,该策略对蜂群内其他信息没有进行充分的共享,如当前种群中每个采蜜蜂自身搜索过程中出现的最优值等。

本文提出的基于双重认知能力的人工蜂群算法的主要策略如下:

1. 每个采蜜蜂通过对自身历史最优值的学习(自我认知能力)和整个蜂群中的最优蜜源的学习(社会认知能力)来提高整个蜂群的整体优化能力。

2. 为了缓解算法“早熟”进而停滞的问题,引入互斥因子来避免蜜蜂个体在同一位置“黏着”现象,增加了在搜索空间寻找新的候选解的机会,同时提高了种群的多样性。具体方法描述如下:

1) 种群初始化之后,计算每个蜜源所对应的适应度值,根据适应度值大小排序,确定每个蜜源自身的最优值(初始情况下 $lbest_i = fitness_i$)和整个蜂群的最优值 $gbest$,即:

$$gbest = \min(lbest_i)_{i=1}^{SN}$$

2) 每个采蜜蜂需要记住各自蜜源的位置及其所对应的适应度值 $lbest_i = (fitness, id)$,其中 id 表示第 i 个蜜源的位置,通常为一个 D 维向量。如果新产生的蜜源的适应度值小于 $lbest_i$. $fitness$ (最小化问题),则更新 $lbest_i$. $fitness$ 。也就是说 $lbest_i$ 反映了个体在自身发展过程中的自我学习能力。类似, $gbest$ 记录了整个蜂群的最优值,采蜜蜂可以通过学习全局中的最优蜜源来逼近最优值。

3) 根据库尔特·勒温提出的群体动力学(group dynamics)原理,即“个体的行为是由个性特征和场(指环境的影响)相互作用的结果”,结合自我认知能力和社会认知能力,我们给出基于双重认知能力的搜索策略:

$$v_i = x_i + r_b(lbest_i - x_i) + r_g(gbest - x_i) \quad (5)$$

其中, r_b 和 r_g 是在 $[0, 1]$ 上服从均匀分布的随机数;式中的第二项为采蜜蜂对自身经验的学习,代表了自我认知能力,第三项反映了采蜜蜂对周围环境即社会认知能力。由式(5)替代

式(3)得到的改进 ABC 算法通过综合自我认知和社会认知获得了较好的优化性能。

4)在优化问题中,尤其在接到多峰优化问题时,“早熟”是一个较为普遍的问题。在 ABC 算法中,若所有的个体都选择搜索空间中同一位置,例如多峰问题中局部最优,则算法陷入停滞状态。在 PSO 算法中引入互斥因子来克服早熟问题,取得了较好的实验结果^[12]。在 ABC 算法中,引入互斥因子 rp 改变搜索方向,旨在减少在优化多峰问题时出现的算法停滞、“早熟”现象。由于 rp 因子的引入,搜索方程(5)改为:

$$x_i = x_i + rp * \{r_n(lbest_i - x_i) + r_g(gbest - x_i)\} \quad (6)$$

其中, $rp = \begin{cases} 1, & \text{if } (r \leq RP) \\ -1, & \text{if } (r > RP) \end{cases}$, r 为在 $[0, 1]$ 均匀分布的随机数, RP 为预先定义的互斥率,控制采蜜蜂搜索的方向,以避免早熟问题的出现。

4 实验及结果分析

为了便于和其他优化算法及 ABC 的改进算法进行比较,以验证 DCA-ABC-rp 算法的有效性,实验选择了 5 个国际通用的标准函数作为测试对象,并与文献^[13]给出的 GA(Genetic Algorithm)、PSO、CPSO(Cooperative Particle Swarm Optimization)、ABC、CABC(Cooperative Artificial Bee Colony)、HABC(Hybrid Artificial Bee Colony)的优化结果和文献^[6]给出的 ABC/best/1、ABC/best/2 等群智能优化算法进行比较。这 5 个基本测试函数如表 1 所列。

表 1 基本测试函数

函数名	表达式	搜索范围
Sphere	$f(x) = \sum_{i=1}^D x_i^2$	$[-100, 100]$
Rosenbrock	$f(x) = \sum_{i=1}^{D-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$[-50, 50]$
Ackley	$-20 \exp(-0.2 \sqrt{\frac{1}{D} \sum_{i=1}^D x_i^2}) - \exp(\frac{1}{D} \sum_{i=1}^D \cos 2\pi x_i) + 20 + e$	$[-32, 32]$
Griewank	$f(x) = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos(\frac{x_i}{\sqrt{i}}) + 1$	$[-600, 600]$
Rastrigin	$f(x) = \sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$

4.1 测试函数及参数设置

Sphere 函数为单峰函数,搜索空间限定在 $[-100, 100]$, 该函数在 $[0, 0, \dots, 0]$ 处取得全局极小值 0。Rosenbrock 函数为单峰函数,搜索范围为 $[-50, 50]$, 该函数在 $[1, 1, \dots, 1]$ 处取得全局极小值 0。Ackley、Griewank 和 Rastrigin 函数均为多峰函数,分别在 $[0, 0, \dots, 0]$ 、 $[100, 100, \dots, 100]$ 和 $[0, 0, \dots, 0]$ 处取得全局极小值 0。我们的实验分为两组:1)将 DCA-ABC-rp 与文献^[13]中给出的 HABC、ABC、CABC、PSO、CP-SO 和 GA 等优化算法的优化结果作比较,种群大小均为 100,每个测试函数在 $D=30$ 的情况下独立运行 30 次,记录下优化结果的平均值和标准偏差。详细的参数设置见文献^[13],实验结果如表 2 所列。2)文献^[6]提出了改进的 ABC 算法如 ABC/best/1、ABC/best/2,为了便于比较,取相同的参数设置即种群大小为 100, $Foodnumber=50$, $limit=0.5 * Foodnumber * D$,实验独立运行 30 次,记录运行的平均最优值和标准偏差。实验结果如表 3 所列。

表 2 DCA-ABC-rp v. s HABC、ABC、CABC、PSO、CPSO 和 GA 的均值 mean 和标准偏差(std)

	Sphere	Rosenbrock	Ackley	Griewank	Rastrigin
DCA-ABC-rp	3.2841e-115 (1.2365e-115)	1.2035e-003 (2.1315e-003)	2.2346e-017 (1.1846e-017)	0 (0)	0 (0)
HABC	0 (0)	2.8123e+001 (5.4347e-001)	8.8818e-016 (2.0059e-031)	0 (0)	0 (0)
ABC	4.5432e-012 (2.8022e-012)	4.2762e-001 (3.1812e-001)	5.9675e-006 (3.1375e-006)	1.0603e-007 (4.6102e-007)	1.3560e-001 (3.2734e-001)
CABC	3.1217e-013 (3.3430e-013)	6.2047e+000 (1.4323e+001)	2.6176e-005 (1.1918e-005)	4.1380e-004 (1.8419e-003)	2.8432e-007 (6.2806e-007)
PSO	1.0349e-005 (7.0148e-006)	3.4052e+001 (2.1111e+001)	2.1160e+000 (4.7084e-001)	3.1380e-002 (1.4547e-002)	5.9976e+001 (1.6514e+001)
CPSO	7.7769e-009 (7.7165e-009)	3.1661e+000 (2.6112e+000)	8.1068e-004 (3.8408e-004)	4.8202e-002 (3.0448e-002)	9.8190e-006 (9.8810e-006)
GA	1.3899e+000 (5.1561e-001)	1.4398e+003 (7.8130e+002)	1.9190e+001 (8.4643e-001)	5.0599e+000 (1.6339e+000)	1.3799e+002 (3.2469e+001)

表 3 DCA-ABC-rp v. s ABC/best/1、ABC/best/2(mean±std)

Function	D	G	ABC/best/2 mean±std	ABC/best/1 mean±std	DCA-ABC-rp mean±std	排名
Sphere	30	1000	4.37E-22 2.14E-22	1.57E-27 1.14E-27	9.7030e-017±5.4244e-017	3
	60	2000	1.57E-20±4.90E-21	2.42E-25±1.09E-25	9.1020e-016±3.0709e-016	3
Rosenbrock	3	1000	1.95E-03±1.52E-03	9.06E-06±1.41E-05	0±0	1
	4	2000	1.86E-03±1.03E-03	1.29E-07±3.83E-07	1.7264e-009±3.5192e-009	1
Ackley	30	1000	1.89E-11±4.75E-12	1.26E-13±3.48E-14	7.0621e-014±3.9992e-014	2
	60	2000	1.08E-10±4.97E-12	3.40E-13±6.35E-14	1.1851e-012±3.4236e-011	2
Griewank	30	1000	4.47E-08±1.05E-07	4.23E-11±2.16E-11	1.0007e-011±8.7001e-012	1
	60	2000	2.18E-10±4.33E-10	0±0	1.6483e-012±1.6602e-012	2
Rastrigin	30	1000	0±0	0±0	1.2473e-014±1.6923e-013	3
	60	2000	0±0	0±0	1.0407e-012±2.8905e-012	3

4.2 实验结果

为了更直观地表示 DCA-ABC 算法的优化能力,我们选取

了几个代表性的标准测试函数,分别采用 ABC、ABC/best/1 和 ABC/best/2 算法进行优化,基本的参数设置如下:种群大

小为 80,最大迭代次数为 1000, $limit=Foodnumber * D$,收敛性能分析如图 2—图 5 所示。

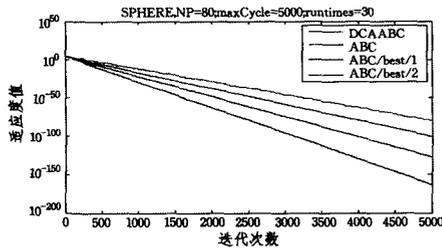


图 2 Sphere 函数

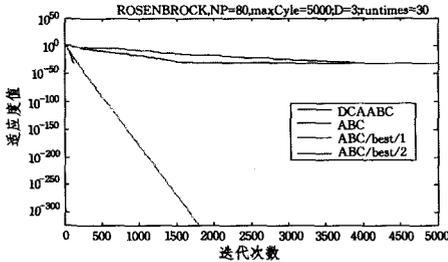


图 3 Rosenbrock 函数

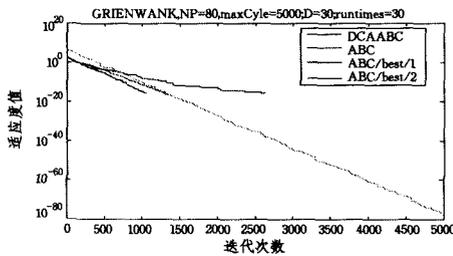


图 4 Griewank 函数

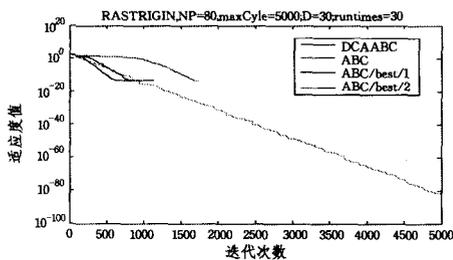


图 5 Rastrigin 函数

4.3 结果分析

为了避免多个采蜜蜂集中在某个蜜源附近(该蜜源可能是多峰问题中的某个局部最优值),使搜索过程停滞不前,算法陷入“早熟”,采用了基于互斥因子的 DCA-ABC 算法,其通过引入互斥因子 rp 改变采蜜蜂的搜索方向,减少在同一蜜源处的“黏着”现象,扩大种群的多样性,在一定程度上避免上述情况的发生。从表 2 的实验结果也可看出, DCA-ABC 在处理多峰问题(Ackley, Griewank, Rastrigin)时优于其他的优化算法,而在优化单峰问题时, DCA-ABC 继续保持了较好的优化能力。表 3 中,除了 Sphere 和 Rastrigin 函数外,其余类型的测试结果表明, DCA-ABC 算法优于或接近于其他改进的 ABC 算法,较快地收敛到近似最优解。需要注意的是,在表 1 中的基本测试函数,其最优值均为 0,故算法的迭代终止条件

设为“超过最大迭代次数”或“函数值为 0”。图 3—图 5 中 DCA-ABC 算法均在不超过最大迭代次数的情况下结束,即达到函数的最优值,明显优于或接近于其他几种算法。图 1 中的 Sphere 函数虽然在最大迭代次数内没有达到最优值,但收敛速度和性能上仍优于 ABC 算法。

结束语 人工蜂群算法和其他群智能算法类似,也存在着诸如早熟、优化多峰问题时易陷入局部最优等问题。本文借鉴库尔特·勒温提出的群体动力学原理,引入“自我认知能力”和“社会认知能力”的搜索策略。实验结果表明,改进后的 ABC 算法在算法的优化性能和鲁棒性方面有了较为明显的改善。今后应进一步加强对算法适用性的研究,拓宽其应用范围。

参考文献

- [1] Karaboga, Dervis. An idea based on honey bee swarm for numerical optimization[R]. Techn. Rep. TR06. Erciyes Univ. Press, Erciyes, 2005
- [2] Manda K, Satapathy S C, Rao K R. Artificial Bee Colony Based Image Clustering[C]//Proceedings of the International Conference on Information Systems Design and Intelligent Applications 2012. Visakhapatnam, India, Springer Berlin Heidelberg, January 2012; 29-37
- [3] 周清雷,陈明昭,张兵. 多目标人工蜂群算法在服务组合优化中的应用[J]. 计算机应用研究, 2012, 29(10): 3625-3628
- [4] Ozturk C, Karaboga D. Hybrid artificial bee colony algorithm for neural network training[C]// 2011 IEEE Congress on Evolutionary Computation (CEC). IEEE, 2011: 84-88
- [5] Zhu Guo-pu, Kwong S. Gbest-guided artificial bee colony algorithm for numerical function optimization[J]. Applied Mathematics and Computation, 2010, 217(7): 3166-3173
- [6] Gao Wei-feng, Liu San-yan. A global best artificial bee colony algorithm for global optimization[J]. Journal of Computational and Applied Mathematics, 2012, 236(11): 2741-2753
- [7] 银建霞,孟红云. 具有混沌差分进化搜索的人工蜂群算法[J]. 计算机工程与应用, 2011, 47(29): 27-30
- [8] 毕晓君,王艳娇. 加速收敛的人工蜂群算法[J]. 系统工程与电子技术, 2011, 33(12): 2755-2761
- [9] 王珊,顾幸生. 基于混沌优化的双种群人工蜂群算法[J]. 上海电机学院学报, 2012, 15(1): 11-17
- [10] 杨琳,孔峰,贺师超. 基于自适应选择策略的人工蜂群算法[J]. 广西工学院学报, 2012, 23(3): 39-44
- [11] Gao Wei-feng, Liu San-yan, Huang Ling-ling. A global best artificial bee colony algorithm for global optimization[J]. Journal of Computational and Applied Mathematics, 2012, 236(11): 2741-2753
- [12] Hsieh S T, Sun T Y, Lin C L, et al. Effective learning rate adjustment of blind source separation based on an improved particle swarm optimizer[J]. IEEE Transactions on Evolutionary Computation, 2008, 12(2): 242-251
- [13] Yan X, Zhu Y, Zou W, et al. A new approach for data clustering using hybrid artificial bee colony algorithm[J]. Neurocomputing, 2012, 97: 241-250