

基于平均熵的自适应人工蜂群算法

徐双双 黄文明 雷茜茜

(桂林电子科技大学计算机科学与工程学院 桂林 541000)

摘 要 针对基本人工蜂群算法容易陷入局部最优和早熟等问题,提出一种改进的人工蜂群算法(ASABC)。利用平均熵机制初始化种群,增加种群的多样性,避免算法陷入早熟;同时,采用自适应调节邻域搜索步长的策略来提高算法的局部搜索能力,提升算法的计算精度;为了平衡算法的全局搜索能力和局部搜索能力,引入自适应比例选择策略来代替人工蜂群算法的适应度比例选择方法。对 8 个标准测试函数的仿真实验结果表明,与 3 种常见的智能优化方法相比,改进的算法具有显著的局部搜索能力和较快的收敛速度。

关键词 人工蜂群算法,平均熵,搜索步长,自适应比例选择

中图法分类号 TP301.6 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2015.8.052

Self-adaptive Artificial Bee Colony Algorithm Based on Mean Entropy Strategy

XU Shuang-shuang HUANG Wen-ming LEI Qian-qian

(School of Computer Science and Engineering, Guilin University of Electronic Technology, Guilin 541000, China)

Abstract In order to overcome the shortcomings that artificial bee colony (ABC) traps into local optima and premature easily, an improved artificial bee colony algorithm named ASABC algorithm was proposed. The new algorithm adopts mean entropy tactic to initialize population, which can increase the diversity of population and avoid the stagnation and premature. At the same time, the new algorithm adopts the strategy which can adjust the neighbour selection step size adaptively to improve the local search ability and calculation precision. To balance the global search ability and the local search ability, the self-adaptive proportion selection strategy is used to replace the fitness proportion selection method of the ABC algorithm. The results of the simulation experiment on a suite of eight benchmark functions show that the new algorithm has remarkable local search ability and a faster convergence rate compared with three common intelligent optimization algorithms.

Keywords Artificial bee colony, Mean entropy, Search step, Self-adaptive proportion selection

人工蜂群算法^[1]是由 Karaboga 于 2005 年提出的一种基于蜂群采蜜行为的群体智能优化算法,具有控制参数少、计算简单、全局寻优能力强等优点^[2],近年来已被越来越多的学者所关注,成为进化计算领域的研究热点之一。它已在图像处理^[3]、函数优化^[4-6]、神经网络^[7]、聚类分析^[8]、最小生成树^[9]等领域取得了较好的效果。然而,作为一种新的随机优化算法,由于受到个体选择策略和进化方式的影响,人工蜂群算法在接近全局最优解时,依旧可能存在由于搜索速度变慢、个体多样性减少、收敛速度降低而陷入局部最优进而导致早熟收敛。针对这些问题,众多学者提出了许多不同的改进方案。例如, Akay 等^[5]针对人工蜂群算法中蜜源位置更新的不足,在新个体变异方程中引入一个扰动概率参数 MR(modify rate)和一个自适应尺度因子 ASF(adaptive scaling factor),提出了一种改进蜂群算法用于解决实值参数优化问题。 Banharnsakun 等^[10]为提高算法收敛精度以及加快算法收敛速度,提出利用当前全局最优解代替随机选取的邻域个体,利用当

前全局最优解的适应度调整邻域搜索步长。罗钧等^[11]提出采用“分段搜索”策略对个体进行贪婪更新,从而避免了算法早熟收敛,提高了算法收敛速度。向万里等^[12]为保持种群多样性,防止人工蜂群算法进化不会快速向适应度值高的蜜源处集中,在蜂群算法跟随蜂选择蜜源阶段引进了轮盘赌的反向选择机制。另外有很多学者利用基本人工蜂群算法或改进蜂群算法来改善一些经典模型或算法,如喻金平等^[13]将提出的改进的人工蜂群算法与 K 均值聚类算法结合,提出了一种混合蜂群算法来改善 K 均值聚类算法的聚类质量和综合性。针对高斯过程训练大样本时训练时间复杂度过高,超参数的选取容易影响回归模型的预测精度,张乐等^[14]采用人工蜂群算法搜寻改进高斯过程回归的最优超参数,利用得到的超参数构建最优的改进高斯回归模型来降低训练过程的时间复杂度和提高模型预测精度。郭莹等^[15]根据 SAT 问题的特点设计了多种觅食策略,并利用各子句和变量之间约束关系的启发式信息对各阶段的候选解进行离散操作,提出了一种

到稿日期:2014-08-22 返修日期:2015-05-23 本文受广西自然科学基金资助项目(2013GXNSFAA019350),广西可信重点实验室基金资助项目(kx201106)资助。

徐双双(1989—),男,硕士,主要研究方向为机器学习、数据挖掘, E-mail: jhyxss@126.com; 黄文明(1963—),男,教授,主要研究方向为网格计算、图形图像处理、软件工程; 雷茜茜(1990—),女,硕士,主要研究方向为图像处理、人工智能。

离散人工蜂群算法(ABCSAT)来解决 SAT 问题,取得了较好的效果。秦全德等^[16]综合性地介绍了人工蜂群算法的生物背景和基本原理,归纳出当前人工蜂群算法的改进研究主要集中在算法的参数调整、混合算法和设计新的学习策略 3 个方面,阐述了人工蜂群算法的应用现状,并提出了人工蜂群算法有待进一步研究的问题。

根据 Wolpert 和 Macready 的“*No Free Lunch(NFL)*”定理^[17],对于特定问题,不同的搜索算法也许会得到不同的结果,但对于所有问题,这些不同的算法之间是没有性能差异的。也就是说,如果一个算法在某些问题上得到较好的解,那么必然在另外的问题上得到较差的解。因此,从解决实际问题的角度出发,充分发挥不同类型机制的优化算法的优势,并融合这些不同算法是当前进化领域解决问题的一大发展趋势。

为提高 ABC 算法获得最优解的概率,本文提出一种改进的 ABC 算法。首先,为增大初始种群多样性,使种群均匀分布在搜索空间,本文采用平均熵的策略来初始化种群,以提高算法收敛于全局最优解的鲁棒性;其次,针对目标函数自适应地调节邻域搜索的步长,从而提高 ABC 算法的局部搜索能力;最后,将自适应选择策略引入到人工蜂群算法中来代替适应度比例选择法,根据当前蜜源的性状动态地调节选择压力,使算法的全局搜索和局部搜索能力达到平衡。

1 基本人工蜂群算法

人工蜂群算法主要模拟蜂群的智能采蜜行为,把蜜蜂分为引领蜂、跟随蜂和侦查蜂 3 种,3 种蜜蜂根据各自分工的不同进行不同的采蜜活动,并实现蜜源信息的共享和交流,从而使算法朝最优方向进化。

考虑最小值优化问题

$$\min(f(X)), \text{ s. t. } X \in D \subset \mathbb{R}^n \quad (1)$$

其中, $X_i = (x_{i1}, x_{i2}, \dots, x_{in})$ 是式(1)的任意可行解,在蜂群算法中相当于一个蜜源位置, $f(X_i)$ 是 X_i 的适应度函数。假设初始种群含有 SN 个解(引领蜂或跟随蜂数量),每个解 X_i 是一个 D 维向量。

(1)引领蜂

引领蜂对种群中的每个个体依次执行更新操作,引领蜂首先寻找食物源,并根据式(2)对蜜源位置进行更新

$$x'_{ij} = x_{ij} + \varphi_{ij} (x_{ij} - x_{kj}) \quad (2)$$

式中, $k \in \{1, 2, \dots, SN\}$, $j \in \{1, 2, \dots, D\}$, x_{ij} 表示个体 X_i 的第 j 维分量位置; x_{kj} 为个体 X_k 的第 j 维分量位置; k, j 都是随机选择的,且 $k \neq i$; φ_{ij} 是 $[-1, 1]$ 间的随机数,它控制 x_{kj} 邻域的生成范围,随着问题最优解的逐步靠近,搜索的邻域范围也越来越小。 x'_{ij} 表示第 i 个引领蜂在 x_{kj} 基础上产生新蜜源 $X'_i = (x'_{i1}, x'_{i2}, \dots, x'_{in}) \in D$ 的第 j 个分量位置。算法根据式(3)更新个体 X_i ,并按式(4)记录个体的更新次数 $count_i$ 。

$$X_i = \begin{cases} X_i, & f(X_i) \leq f(X'_i) \\ X'_i, & f(X_i) > f(X'_i) \end{cases} \quad (3)$$

$$count_i = \begin{cases} count + 1, & f(X_i) \leq f(X'_i) \\ 0, & f(X_i) > f(X'_i) \end{cases} \quad (4)$$

(2)跟随蜂

当所有引领蜂都搜索完后,引领蜂回到舞蹈区将适应度

值信息通过摇摆舞方式传达给跟随蜂。然后跟随蜂在优秀个体附近作局部搜索,每次都采用轮盘赌策略选择蜜源,在选择新的蜜源时需要计算当前 SN 个引领蜂所在的蜜源 X_i ($1 \leq i \leq SN$) 各自的选择概率值 P_i ,即

$$P_i = f_i / \sum_{i=1}^{SN} f_i \quad (5)$$

$$fit_i = \begin{cases} \frac{1}{1+f_i}, & f_i \geq 0 \\ 1+|f_i|, & f_i < 0 \end{cases} \quad (6)$$

其中, fit_i 是第 i 个解的适应度, SN 是解的个数, f_i 是被优化问题的目标函数。

(3)侦查蜂

为了避免算法陷入局部极值,侦查蜂根据式(7)更新早熟个体 X_i 中的每一维分量。

$$x_{ij} = u_j + R \times (u_j - v_j) \quad (7)$$

式中, R 为 $[0, 1]$ 间的随机数, u_j 和 v_j 是第 j 维解空间的上、下边界。

2 基于平均熵的自适应人工蜂群算法

2.1 基于平均熵的种群初始化

文献^[18]采用熵最大的方法产生两个初始化种群,种群的初始化都遵守种群熵最大原则。依据文中对熵的定义,每当产生一个新的初始个体后,如果此新个体与已有的所有初始个体之间的熵值大于设定的阈值,则将此新个体纳入初始化种群。但是如果已有个体的种群熵值较大,即使新个体与已有个体重合时也会使种群熵大于设定的阈值,这时基于最大熵的种群初始化策略本质上仍为随机初始化,对增加种群多样性的影响非常小。针对这一问题,本文提出了基于平均熵的种群初始化策略。设初始化后的种群中包含 NP 个个体,每个个体具有 D 维编码。根据信息熵的定义^[19,20],各维编码熵 $H_j = (j=1, 2, \dots, D)$ 的总和等于种群的熵 H ,即

$$H = \frac{1}{D} \sum_{j=1}^D H_j \quad (8)$$

$$H_j = \frac{1}{m+1} \sum_{i=1}^m (-S_{ik} \log S_{ik}) \quad (9)$$

在式(9)中, k 是新初始化个体, m 是已有的初始化个体数, S_{ik} 是第 i 个个体的第 j 维编码与第 k 个个体的第 j 维编码的相似程度,即

$$S_{ik} = 1 - \frac{|x_j(i) - x_j(k)|}{u_j - v_j} \quad (10)$$

式中, u_j 和 v_j 分别为第 j 维变量的上、下边界。

随机初始化 m ($0 < m < SN/2$) 个个体作为初始化种群,接着初始化一个新个体,按式(8)~式(10)计算种群的平均熵,如果种群的平均熵值小于设定的阈值,则将新个体抛弃;否则将其加入到已有的种群中,直到种群的大小规模为 SN 。通过平均熵策略初始化后种群中个体将尽可能均匀地分布在搜索空间,算法搜索到全局最优解的相对稳定性也会得到一定程度的提升。

2.2 局部搜索策略的增强

针对人工蜂群算法中式(2)所示的较差的局部搜索能力,利用自适应步长调整策略来调整步长的大小,增强适应度值信息对可行解的指导作用。新蜜源的位置更新公式为:

$$x'_{ij} = \lambda_k x_{ij} + (1 - \lambda_k) H_{ij} (x_{ij} - x_{kj}) \quad (11)$$

其中,

$$H_{ij} = 1 - \frac{1}{a \cdot e^{(f_i/f_k)^b}} \quad (12)$$

式中, $f < 0$ 时为极小值问题, $f > 0$ 时为极大值问题。

$$H_{ij} = 1 + \frac{1}{a \cdot e^{(f_i/f_k)^b}} - \frac{1}{a} \quad (13)$$

式中, $f < 0$ 时为极大值问题, $f > 0$ 时为极小值问题。

在式(11)中, $\lambda_k \in [-1, 1]$ 为均匀分布的随机数, $k=1, 2, \dots, D$ 。式(12)和式(13)中, f_i 和 f_k 分别是第 i 个和第 k 个引领蜂对应的目标函数。 a 和 b 为人工设置的参数。

当 $H_{ij} = 1 - \frac{1}{a \cdot e^{(f_i/f_k)^b}}$ 时, H_{ij} 随 f_i/f_k 值的增大在 $[1 - \frac{1}{a}, 1)$ 范围内递增。当 $H_{ij} = 1 + \frac{1}{a \cdot e^{(f_i/f_k)^b}} - \frac{1}{a}$ 时, H_{ij} 随 f_i/f_k 值的增大在 $[1, 1 - \frac{1}{a})$ 范围内递减。参数 a 控制 H_{ij} 的取值范围。

当目标函数 $f > 0$ 时来求解极小值问题, 此时 $H_{ij} = 1 - \frac{1}{a \cdot e^{(f_i/f_k)^b}}$, 如果 $f_i > f_k$, 则表明第 i 个引领蜂的适应度值比较差, 距离含蜜量丰富的蜜源地方较远, 即离最优值较远, 此时应扩大搜索步长, 加大位置调节尺度, 扩大邻域搜索范围; 如果 $f_i = f_k$, 则在非最优解的情况下, 搜索步长为 $[-1, 1]$ 内的某一随机数, 可以适当调节步长, 这样有利于引领蜂寻找新位置, 提高算法寻找优质蜜源的性能; 如果 $f_i < f_k$, 则第 i 个引领蜂的适应度值比较好, 距离含蜜量丰富的地方较近, 即离最优值较近, 此时应减小搜索步长, 缩小邻域搜索范围, 这样可以提高最优值附近的局部搜索能力。

2.3 自适应比例选择策略

设第 t 代蜜源为 $X(t) = (x_{t1}, x_{t2}, \dots, x_{tn})$, n 为蜜源的总数, $f(x_k)$ 为蜜源 x_k 的适应度值, 跟随蜂按照自适应比例选择策略选择蜜源的概率为

$$P(x_k) = \frac{f^{\lambda}(x_k)}{\sum_{j=1}^N f^{\lambda}(x_{kj})} \quad (14)$$

幂指数 λ 根据下式确定:

$$\lambda = \frac{k}{\frac{f_{\max} - f_{\min}}{f} - 1} \quad (15)$$

式(15)中, $f_{\max} = \max\{f(x_{t,i}); i=1, 2, \dots, n\}$, 代表第 t 代蜜源中收益度最好的个体, $\bar{f}$ 为第 t 代蜜源的平均适应度值, k 为系数。当 $\bar{f}/(f_{\max} - f_{\min}) \rightarrow 0$ 时, $\lambda \rightarrow 0$; 当 $\bar{f}/(f_{\max} - f_{\min}) \rightarrow 1$ 时, $\lambda \rightarrow +\infty$; 当 $\bar{f}/(f_{\max} - f_{\min}) = (k+1)^{-1}$ 时, $\lambda = 1$; 当 $\bar{f}/(f_{\max} - f_{\min}) < (k+1)^{-1}$ 时, $\lambda < 1$; 当 $\bar{f}/(f_{\max} - f_{\min}) > (k+1)^{-1}$ 时, $\lambda > 1$ 。因此, 本文采用的自适应比例选择策略就是根据 $\bar{f}/(f_{\max} - f_{\min})$ 比值的不同, 确定幂指数 λ 。

2.3.1 $\lambda \rightarrow 0$

如果幂指数 $\lambda \rightarrow 0$, 则任意蜜源被选择的概率为

$$P_i(x_k) = \lim_{\lambda \rightarrow 0} \frac{f^{\lambda}(x_k)}{\sum_{j=1}^n f^{\lambda}(x_{ij})} \quad (16)$$

如果 $f^{\lambda}(x_{ij}) > 0$, $\lim_{\lambda \rightarrow 0} f^{\lambda}(x_{ij}) = 1$, 则式(16)可以进一步改写为

$$P_i(x_k) = \frac{1}{n} \quad (17)$$

从式(16)到式(17)的变化知, 跟随蜂选择蜜源的压力随着幂指数 λ 的变小而相应减少, 收益度较差的蜜源被选中的机会也会增加, 增大了算法的搜索空间, 而当幂指数 λ 很小时, 跟随蜂将在蜜源中进行随机选择。

2.3.2 $\lambda \rightarrow +\infty$

如果幂指数 $\lambda \rightarrow +\infty$, 则任意蜜源被选择的概率为

$$P_s(x_k) = \lim_{\lambda \rightarrow +\infty} \frac{f^{\lambda}(x_k)}{\sum_{j=1}^n f^{\lambda}(x_{ij})} \quad (18)$$

假设 m 是第 t 代蜜源中最优秀个体的数目, 根据极限运算法则, 从式(18)可以得出以下结论:

$$P_s(x_k) = \begin{cases} 0, & f(x_k) < f_{\max} \\ 1/m, & f(x_k) = f_{\max} \end{cases} \quad (19)$$

从式(18)到式(19)的变化知, 跟随蜂选择蜜源的压力随着幂指数 λ 的变大而相应增大, 收益度较差的蜜源被选中的机会也会减少, 减小了算法的搜索空间, 而当幂指数 λ 很大时, 跟随蜂将在蜜源中只选择收益度最大的蜜源。

在引领蜂搜索蜜源时, 由于蜜源的初始化位置是随机的, 各个蜜源之间的性状是不一样的, 有些蜜源可能是最优蜜源或次优蜜源, 而有些蜜源的性状是比较差的, 这样蜜源的平均适应度值与最优蜜源个体间的差距较大, 本文采用的自适应比例选择策略可以有效地减少跟随蜂选择蜜源的压力, 因而改进算法具有较好的全局搜索能力来扩大算法的搜索空间, 即 $\lambda \rightarrow 0$ 时, 保障了较差蜜源具有被跟随蜂选择的机会, 避免了算法出现早熟收敛的现象。算法到了搜索的中期, 随着种群性状发生变化, 幂指数 λ 会自适应地改变, 跟随蜂相应地调节选择蜜源的压力, 这样能够平衡算法的全局搜索能力和局部搜索能力。而在算法搜索的后期, 种群的平均适应度值接近全局最优解, 自适应比例选择策略中的幂指数 $\lambda \rightarrow +\infty$, 跟随蜂选择蜜源的压力较大, 改进算法会相应地快速收敛于全局最优解。

2.4 改进的人工蜂群算法流程

基于平均熵的自适应人工蜂群算法的基本步骤如下:

步骤1 随机初始化 m 个个体作为初始种群 ($0 < m < SN/2$), 并设定 u_j, v_j, SN, a, b, k 和 $maxCycle$ 等值。

步骤2 按式(8)~式(10)计算种群的平均熵, 随机初始化一个新个体, 并利用平均熵和设定阈值之间的大小关系判定新个体能否加入到已有的初始化种群中。

步骤3 重复步骤2直至种群规模大小为 SN , 即生成 SN 个解, 构成初始蜜源位置。

步骤4 引领蜂按照式(11)搜索一个新蜜源, 并计算该位置的适应度, 如果新位置优于原来的位置, 则用新位置替换原位置。

步骤5 跟随蜂利用式(14)选择蜜源。

步骤6 跟随蜂利用式(11)进行蜜源更新, 并计算其适应度值。

步骤7 跟随蜂采用贪婪选择机制选择蜜源位置。

步骤8 侦查蜂按照式(7)产生新蜜源替换掉含蜜量最差的蜜源。

步骤9 记录下当前的最优蜜源位置及适应度值。

步骤10 判断是否满足终止条件, 如果满足则输出最优解; 否则返回步骤4。

算法的大致流程如图1所示。




图1 改进蜂群算法流程图

3 实验研究

3.1 实验设计

为验证本文改进算法(记为ASABC)的有效性,下面通过8个典型的 Benchmarks 函数进行测试,本文在 CPU 3.4 GHz、内存 4GB、系统为 Win7 的计算机上将 ASABC 算法与基本人工蜂群算法(记为 ABC)、差分进化(DE)算法以及粒子群优化(PSO)算法进行对比实验。4种算法对每个测试函数进行30次独立实验,对各个函数在不同维数下的平均值和方差进行比较。8个典型的 Benchmarks 函数如表1所列。

表1 基准函数

序号	函数表达式	搜索空间
1	$f_1(\vec{x}) = \sum_{i=1}^n x_i^2$	$[-100, 100]$
2	$f_2(\vec{x}) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	$[-30, 30]$
3	$f_3(\vec{x}) = \sum_{i=1}^n (x_i^2 - 10 \cos(2\pi x_i) + 10)$	$[-5, 12.5, 12]$
4	$f_4(\vec{x}) = 20 + e - \frac{1}{5} \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} - e - \frac{1}{n} \sum_{i=1}^n \cos(2\pi x_i)$	$[-32, 32]$
5	$f_5(\vec{x}) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	$[-600, 600]$
6	$f_6(\vec{x}) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$
7	$f_7(\vec{x}) = \sum_{i=1}^n (\lfloor x_i + 0.5 \rfloor)^2$	$[-100, 100]$
8	$f_8(\vec{x}) = \sum_{i=1}^n ix_i^4 + \text{random}[0, 1)$	$[-1, 28, 1, 28]$

3.2 实验参数分析

本文提出的 ASABC 算法中,设置 $SN=40, \maxCycle=3000$,当测试函数的维数为 3、4 或 30 时, $limit=0.6 \cdot SN \cdot D$ (D 为测试函数的维数);当测试函数的维数为 60 时, $limit=0.4 \cdot SN \cdot D$ 。参数 a, b, k 对算法的性能有重要影响;参数 a 控制搜索步长的取值范围,参数 b 控制 H_g 的形状,对跟随蜂在优质蜜源附近作局部搜索有重要影响;为了检验参数 k 对算法的影响,在实验中设置 5 个不同的 k 值,分别为: 0.001、0.01、0.1、0.5 和 1。

在实验中采用均匀设计法来组合上述 3 个不同参数的取值,并按照均匀设计表 $U_5(5^3)$ 设计均匀实验。其它参数依据上述取值,令函数 Schwefel's_P2.22 作为测试 3 个参数取不同值时对算法实验结果影响的函数,将 Schwefel's_P2.22 函数(30 维)独立运行 30 次得到的平均值和标准差作为实验结

果。结果如表 2 所列。

表2 不同参数取值对 ASABC 算法在函数 Schwefel's_P2.22 上的影响

水平	a	b	k	平均值	标准差
1	2	2	1	3.41E-126	6.25E-126
2	3	4	0.5	7.59E-131	8.04E-132
3	4	6	0.1	5.70E-129	6.87E-129
4	5	3	0.01	3.78E-128	4.96E-128
5	6	5	0.001	9.33E-125	2.49E-124

从表 2 显示的实验结果得知,当 $a=3, b=4, k=0.5$ 时, ASABC 算法在平均值和标准差两个测试指标上得到的结果较好。因此,后面的实验均采用 3 个参数的这组取值来进行实验。

差分进化算法需要设置的控制参数只有两个,分别为缩放因子 F 和杂交概率 CR ,实验中两个参数的具体取值分别为 0.6 和 0.45。

粒子群优化算法需要设置的控制参数为 4 个,其中速度限制常数的值设置为 2.5;单个粒子速度的 2 个惯性因子取值分别为 0.8 和 0.7;最大评估次数取值为 1500;粒子的最大速度设置为最大上下限区间的一半。

3.3 实验结果分析

3.3.1 与原始 ABC 算法的比较

本节实验中,基于平均熵的种群初始化的阈值设置为 0.085, ASABC 算法中的其它参数设置参照 3.1 节和 3.2 节。本实验将原始 ABC 算法和本文提出的 ASABC 算法进行了比较,表 3 列出了各个函数两种不同维数下的测试结果。

表3 不同函数在两种算法下的测试结果

函数	算法	维数	平均值	标准差
$f_1(x)$	ABC	30	6.65E-016	6.11E-017
		60	4.05E-010	1.96E-010
	ASABC	30	2.68E-175	2.20E-175
		60	5.42E-191	4.95E-175
$f_2(x)$	ABC	3	9.04E-003	1.20E-002
		4	1.04E-002	1.32E-002
	ASABC	3	5.36E-003	2.48E-002
		4	3.01E-003	5.07E-002
$f_3(x)$	ABC	30	1.35E-013	7.97E-014
		60	3.33E-007	1.79E-008
	ASABC	30	6.54E-015	9.25E-016
		60	4.89E-016	6.40E-017
$f_4(x)$	ABC	30	3.59E-015	4.95E-016
		60	6.57E-011	4.20E-011
	ASABC	30	5.90E-018	1.00E-019
		60	4.36E-013	2.84E-014
$f_5(x)$	ABC	30	2.64E-016	3.60E-017
		60	7.08E-016	7.59E-017
	ASABC	30	0	0
		60	0	0
$f_6(x)$	ABC	30	6.45E-016	6.96E-017
		60	4.44E-010	1.56E-010
	ASABC	30	7.59E-131	8.05E-131
		60	6.01E-132	5.32E-132
$f_7(x)$	ABC	30	0	0
		60	0	0
	ASABC	30	0	0
		60	0	0
$f_8(x)$	ABC	30	5.45E-002	1.15E-002
		60	2.06E-001	3.95E-002
	ASABC	30	6.98E-004	8.02E-004
		60	5.46E-003	8.47E-003

从表3的实验结果可知,ASABC算法在优化单峰函数 $f_1(x)$ 、 $f_2(x)$ 、 $f_6(x)$ 、 $f_7(x)$ 和 $f_8(x)$ 时得到的解的精度和稳定性都明显优于基本ABC算法。对于单峰函数 $f_7(x)$ 来说,基本ABC算法和ASABC算法都能得到理论最优解,从 $f_7(x)$ 函数的空间形状来看,函数 $f_7(x)$ 的最优解集中在一个区域,而不是一个点。ASABC算法在优化多峰函数 $f_3(x)$ 、 $f_4(x)$ 和 $f_5(x)$ 时得到的解的精度和稳定性较基本ABC算法也有一定程度的提升。而对于多峰函数 $f_5(x)$,在两种维数下,ASABC算法都达到了理论全局最优解。通过对8个benchmark函数进行多次测试,都能得到相近的结果,表明算法稳定性较高,具有较好的鲁棒性。

3.3.2 与DE和PSO算法的比较

本节将ASABC算法与另外两种常见的智能进化优化算法(DE算法和PSO算法)进行对比。各算法的参数设置参照3.2节,测试函数 $f_2(x)$ 的维数在本节实验中取值为3,其他测试函数的维数设置为30。表4给出了3种不同进化算法的实验结果。

表4 3种算法的实验测试结果

函数	算法	平均值	标准差
$f_1(x)$	DE	5.47E-022	7.14E-023
	PSO	4.91E-019	6.88E-020
	ASABC	2.68E-175	2.20E-175
$f_2(x)$	DE	9.67E-003	8.54E-003
	PSO	7.74E-003	6.49E-003
	ASABC	5.36E-003	2.48E-002
$f_3(x)$	DE	2.98E-014	1.18E-014
	PSO	6.90E-013	8.98E-014
	ASABC	6.54E-015	9.25E-016
$f_4(x)$	DE	4.78E-015	6.11E-016
	PSO	8.52E-017	3.05E-017
	ASABC	5.90E-018	1.00E-019
$f_5(x)$	DE	6.47E-017	5.33E-017
	PSO	9.08E-015	3.32E-016
	ASABC	0	0
$f_6(x)$	DE	4.45E-020	3.15E-021
	PSO	9.87E-019	1.58E-019
	ASABC	7.59E-131	8.05E-131
$f_7(x)$	DE	0	0
	PSO	0	0
	ASABC	0	0
$f_8(x)$	DE	4.78E-002	2.28E-002
	PSO	6.40E-002	4.37E-002
	ASABC	6.98E-004	8.02E-004

从表4显示的实验结果可知,在8个标准测试函数中,ASABC算法相比于DE算法和PSO算法在平均值和标准差上都有一定程度的提升,其中在函数 $f_1(x)$ 、 $f_5(x)$ 和 $f_6(x)$ 上提升的效果较明显。通过这两小节实验的对比可知,改进的蜂群算法ASABC在改善早熟现象、局部搜索能力不足以及难以平衡算法全局搜索能力和局部搜索能力方面都取得了一定的成效。

结束语 为了增强基本ABC算法获得最优解的概率,本文提出了基于平均熵的自适应人工蜂群算法。改进算法通过3个方面来提高获得优质蜜源的概率,首先,本文基于平均熵的策略来初始化种群,使初始种群能够均匀分布在搜索空间,这样能增大种群的多样性,避免了算法出现早熟现象;其次,针对不同的目标函数,采用自适应的机制来调节邻域搜索空间的步长,加强算法的局部搜索能力,同时提高了算法的开采能力,并加快了算法的收敛速度;最后,将自适应比例选择策略引入到人工蜂群算法中,根据当前蜜源的状况动态地调节

选择压力,平衡算法的全局搜索能力和局部搜索能力。对8个标准测试函数的仿真实验结果表明,本算法在计算精度和收敛速度两方面都有显著的提升,而且算法也具有较好的全局搜索能力和局部搜索能力,算法整体性能得到了较大的改善。另外,将算法进一步拓展到实际的连续优化问题或者多目标优化等其他优化问题中将是下一步的研究方向。

参考文献

- [1] Karaboga D. An idea based on honey bee swarm for numerical optimization[R]. Kayseri: Erciyes University, 2005
- [2] Karaboga D, Basturk B. On the performance of artificial bee colony (ABC) algorithm[J]. Applied Soft Computing, 2008, 8(1): 687-697
- [3] Horng M H. Multilevel thresholding selection based on the artificial bee colony algorithm for image segmentation[J]. Expert Systems with Application, 2011, 38(11): 13785-13791
- [4] Gao Wei-feng, Liu San-yang. A modified artificial bee colony algorithm[J]. Computers & Operations Research, 2012, 37(3): 687-697
- [5] Akay B, Karaboga D. A modified artificial bee colony algorithm for real-parameter optimization[J]. Information Sciences, 2012, 192(1): 120-142
- [6] 胡珂, 李迅波, 王振林. 改进的人工蜂群算法性能[J]. 计算机应用, 2011, 31(4): 1107-1110
Hu Ke, Li Xun-bo, Wang Zhen-lin. Performance of an improved artificial bee colony algorithm[J]. Journal of Computer Applications, 2011, 31(4): 1107-1110
- [7] Irani R, Nasimi R. Application of artificial bee colony-based neural network in bottom hole pressure prediction in underbalanced drilling[J]. Journal of Petroleum Science and Engineering, 2011, 78(1): 6-12
- [8] Karaboga D, Oztruk C. A novel clustering approach: artificial bee colony (ABC) algorithm[J]. Applied Soft Computing, 2011, 11(1): 652-657
- [9] Singh A. An artificial bee colony algorithm for the leaf-constrained minimum spanning tree problem[J]. Applied Soft Computing, 2009, 9(2): 625-631
- [10] Banharnsakun A, Achalakul T, Sirinaovakul B. The best-so-far selection in artificial bee colony algorithm[J]. Applied Soft Computing, 2011, 11(2): 2888-2901
- [11] 罗钧, 肖向海, 付丽, 等. 基于分段搜索策略的改进蜂群算法[J]. 控制与决策, 2012, 27(9): 1402-1405
Luo Jun, Xiao Xiang-hai, Fu Li, et al. Modified artificial bee colony algorithm based on segmental-search strategy[J]. Control and Decision, 2012, 27(9): 1402-1405
- [12] 向万里, 马寿峰. 基于轮盘赌反向选择机制的蜂群优化算法[J]. 计算机应用研究, 2013, 30(1): 86-89
Xiang Wan-li, Ma Shou-feng. Artificial bee colony based on reverse selection of roulette[J]. Application Research of Computers, 2013, 30(1): 86-89
- [13] 喻金平, 郑杰, 梅宏标. 基于改进人工蜂群算法的K均值聚类算法[J]. 计算机应用, 2014, 34(4): 1065-1069
Yu Jin-ping, Zheng Jie, Mei Hong-biao. K-means clustering algorithm based on improved artificial bee colony algorithm[J]. Journal of Computer Applications, 2014, 34(4): 1065-1069
- [14] 张乐, 刘忠, 张建强, 等. 基于人工蜂群算法优化的改进高斯过程模型[J]. 国防科技大学学报, 2014, 36(1): 154-160
Zhang Le, Liu Zhong, Zhang Jian-qiang, et al. Optimized improved Gaussian process model based on artificial bee colony algorithm[J]. Journal of National University of Defense Technology, 2014, 36(1): 154-160

- [15] 郭莹,张长胜,张斌.一种求解 SAT 问题的人工蜂群算法[J]. 东北大学学报(自然科学版),2014,35(1):29-32
Guo Ying, Zhang Chang-sheng, Zhang Bin. An Artificial Bee Colony Algorithm for Solving SAT Problem[J]. Journal of Northeastern University(Natural Science), 2014,35(1):29-32
- [16] 秦全德,程适,李丽,等.人工蜂群算法研究综述[J]. 智能系统学报,2014,9(2):127-135
Qin Quan-de, Cheng Shi, Li Li, et al. Artificial bee colony algorithm: a survey[J]. CAAI Transactions on Intelligent Systems, 2014,9(2):127-135
- [17] Wolpert D H, Macready W G. No free lunch theorems for optimization[J]. IEEE Transactions on Evolutionary Computation, 1997,1(1):67-82
- [18] 杨小芹,黎明,周琳霞.基于熵的双群体遗传算法研究[J]. 模式识别与人工智能,2005,18(3):286-289
Yang Xiao-qin, Li Ming, Zhou Lin-xia. Entropy Based Genetic Algorithm with Dual Subpopulations[J]. Pattern Recognition and Artificial Intelligence, 2005,18(3):286-289
- [19] Chun J S, Kim M K, Jung H K. Shape Optimization of Electromagnetic Devices Using Immune Algorithm[J]. IEEE Trans on Magnetics, 1997,33(2):1876-1879
- [20] Bessaou M, Siarry P. A Genetic Algorithm with Real-Value Coding to Optimize Multimodal Continuous Functions[J]. Structure Multidiscipline Optimization, 2001,23(1):63-74

(上接第 235 页)

(1)基于 Voronoi 图的不确定拓扑关系和不确定反向最近邻查询方法。

(2)障碍空间中基于 Voronoi 图的最近邻查询方法及几种变体结构。

参考文献

- [1] Shekhar S, Chawla S. 空间网络数据库[M]. 北京:机械工业出版社,2004
Shekhar S, Chawla S. Space Network Database[M]. Beijing: Machinery Industry Press, 2004
- [2] 马希荣,王嵘.一种基于最近邻决策的点集分类方法的确定与实现[J]. 计算机科学,2007,34(12):182-183
Ma Xi-rong, Wang Rong. A New Method to Class a Point Set Based on Nearest-Neighbour Decision Boundaries[J]. Computer Science, 2007,34(12):182-183
- [3] 郭薇,郭菁,胡志勇.空间数据库索引技术[M]. 上海:上海交通大学出版社,2006:1-7
Guo Wei, Guo Jing, Hu Zhi-yong. The technology of spatial database indexing[M]. Shanghai: Shanghai Jiaotong University Press, 2006:1-7
- [4] 张丽平,李松,郝忠孝.球面上的最近邻查询方法研究[J]. 计算机工程与应用,2011,47(5):126-129
Zhang Li-ping, Li Song, Hao Zhong-xiao. Research of methods for nearest neighbor query on spherical surface[J]. Computer Engineering and Applications, 2011,47(5):126-129
- [5] 朱庆生,唐汇,冯骥.一种基于自然最近邻的离群检测算法[J]. 计算机科学,2014,41(3):276-278,305
Zhu Qing-sheng, Tang Hui, Feng Ji. Outlier Detection Algorithm Based on Natural Nearest Neighbor[J]. Computer Science, 2014,41(3):276-278,305
- [6] 李松,张丽平,朱德龙,等.动态受限区域内的单纯型连续近邻链查询方法[J]. 计算机科学,2014,41(6):136-141
Li Song, Zhang Li-ping, Zhu De-long, et al. Simple Continues Near Neighbor Chain Query in Dynamic Constrained Regions[J]. Computer Science, 2014,41(6):136-141
- [7] Korn F, Muthukrishnan S. Influence sets based on reverse nearest neighbor queries[C]//Proceedings of 2000 ACM SIGMOD International Conference on Management of Data. Dallas, Texas, USA, 2000:201-212
- [8] Yang C, Lin K. An index structure for efficient reverse nearest neighbor queries[C]//Proceedings of 17th International Conference on Data Engineering. Heidelberg, Germany, 2001:485-492
- [9] Xia C, Hsu W, Lee M L. ERkNN: Efficient Reverse k-Nearest Neighbors Retrieval with Local kNN-Distance Estimation[C]//Proceedings of CIKM 2005. Bremen, Germany. 2005:533-540
- [10] 郝忠孝,刘永山.空间对象的反向最近邻查询[J]. 计算机科学, 2005,32(11):115-118
Hao Zhong-xiao, Liu Yong-shan. Reverse Nearest Neighbor Search in Spatial Database[J]. Computer Science, 2005,32(11):115-118
- [11] Wu W, Yang F, Chan C, et al. FINCH: Evaluating Reverse k-Nearest-Neighbor Queries on Location Data[J]. VLDB Endowment, 2008,1(1):1056-1067
- [12] 李松,郝忠孝.基于 Voronoi 图的反向最近邻查询方法研究[J]. 哈尔滨工程大学学报,2008,29(3):261-265
Li Song, Hao Zhong-xiao. Reverse nearest neighbor queries using Voronoi diagrams[J]. Journal of Harbin Engineering University, 2008,29(3):261-265
- [13] Emrich T, Kriegel H, Mamoulis N, et al. Reverse-Nearest Neighbor Queries on Uncertain Moving Object Trajectories[M]//Database Systems for Advanced Applications. Springer, 2014:92-107
- [14] Sun H L, Jiang C, Liu J L, et al. Continuous Reverse Nearest Neighbor Queries on Moving Objects in Road Networks[C]//The Ninth International Conference on Web-Age Information Management(WAIM 08). 2008:238-245
- [15] 齐峰,金顺福,刘国华,等.道路网络环境下的近似反 k 最近邻查询算法[J]. 小型微型计算机系统,2010,8(8):1599-1603
Qi Feng, Jin Shun-fu, Liu Guo-hua, et al. Approximation Reverse k-nearest Neighbor Queries in Road Network[J]. Journal of Chinese Computer Systems, 2010,8(8):1599-1603
- [16] 朱彩云,刘国华,宋金玲,等.空间网络数据库中反 k 最近邻查询算法[J]. 小型微型计算机系统,2009,9(9):1781-1786
Zhu Cai-yun, Liu Guo-hua, Song Jin-ling, et al. Algorithm for Reverse k-Nearest Neighbor Queries in Spatial Network Databases[J]. Journal of Chinese Computer Systems, 2009,9(9):1781-1786
- [17] Cheema M A, Zhang W, Lin X, et al. Continuous reverse k nearest neighbors queries in Euclidean space and in spatial networks[J]. The VLDB Journal—The International Journal on Very Large Data Bases, 2012,21(1):69-95
- [18] Okabe A, Boots B, Sugihara K, et al. Spatial Tessellations, Concepts and Applications of Voronoi Diagrams(2nd ed)[M]. John Wiley and Sons Ltd, 2000
- [19] Kolahdouzan M R, Shahabi C. Voronoi-Based K Nearest Neighbor Search for Spatial Network Databases[C]//Proceedings of the 30th International Conference on very Large Data Bases (VLDB). 2004:840-851
- [20] Data set [EB/OL]. <http://www.cs.fsu.edu/lifeifei/SpatialDataset.htm>, 2013
- [21] Yin M L, Papadias D, Mamoulis N. Reverse nearest neighbors in large graphs[C]//The 21st International Conference on Data Engineering. Tokyo, Japan, 2005:301-304