

文章编号:1671-6833(2018)06-0036-07

基于单纯形的改进精英人工蜂群算法

金 叶¹, 孙越泓^{1,2}, 王加翠¹, 王 丹¹

(1. 南京师范大学 数学科学学院, 江苏 南京 210023; 2. 南京师范大学 江苏省大规模复杂系统数值模拟重点实验室, 江苏 南京 210023)

摘 要: 针对人工蜂群算法收敛速度慢, 求解精度不高, 易陷入局部最优等问题, 基于受粒子群启发的多精英人工蜂群优化算法, 引入了蜂群中的精英个体和全局最优个体来增强开发全局最优解的能力. 文章中, 在雇佣蜂阶段借助精英个体引导蜜源搜索, 并利用蜂群中蜜源的质量排序重新构造蜜源的选择概率公式; 在跟随蜂阶段, 选择种群最优蜜源引领蜂群, 加强算法对全局最好解的局部开采能力, 同时将随机选择邻居蜜源变为最优定向选择. 最后利用单纯形算法对精英解集进行再次更新, 进一步平衡蜂群的全局搜索和局部寻优能力. 数值实验表明改进的新算法的寻优精度和收敛速度均有明显提高.

关键词: 人工蜂群算法; 定向更新策略; 精英解集; 选择概率; 单纯形

中图分类号: TP391; TN911. 7 **文献标志码:** A **doi:** 10. 13705/j. issn. 1671-6833. 2018. 06. 008

0 引言

人工蜂群 (artificial bee colony, ABC)^[1] 算法是模拟蜜蜂采蜜机制提出的群体智能随机搜索优化算法, 该算法结构简单, 设置参数少, 不需要求解函数的梯度, 易与其他算法结合, 在函数优化^[2]、工程优化^[3]等方面得到了广泛应用.

近年来, 已有不少专家学者对 ABC 算法进行了改进. 文献[4]在雇佣蜂阶段提出了一种带有新的搜索算子的改进的人工蜂群算法 (improved artificial colony algorithm, IABC); 文献[5]在跟随蜂阶段提出了一种新的选择策略 (improved artificial colony algorithm, iABC); 文献[6]提出了受粒子群启发的多精英人工蜂群算法 (particle swarm inspired muliti-elitist artificial bee colony, PS-MEABC). 人工蜂群算法具有较好的全局搜索能力, 但是文献[4-5]指出, ABC 算法和其他群智能算法一样, 在求解无约束优化问题时存在易早熟、局部搜索能力弱、寻优得到解的精度低等问题. 笔者在受粒子群启发的多精英人工蜂群算法^[6]的基础上, 提出一种新的基于单纯形的改进精英人工蜂群 (improved mu-

liti-elitist artificial bee colony algorithm based on nelder-mead simplex method, NM-PS-MEABC) 算法: 利用定向更新策略, 改进了蜂群随机选取邻居的方式, 建立新的跟随蜂选择概率公式, 并利用单纯形方法局部搜索能力强的特点提高算法的局部寻优能力. 8 个基准函数上的数值实验表明, 求解无约束优化问题时, 本文新算法与 ABC 和 PS-MEABC 算法相比, 求解精度和收敛速度都有较大改进.

1 基本人工蜂群算法

ABC 算法^[1]是通过模拟蜜蜂采蜜过程中的智能机制处理函数优化问题. 人工蜂群算法描述如下: 首先引入蜜源, 它代表解空间中各种可能的解, 函数优化过程中通过适应度值来衡量蜜源; 再引入 3 种蜂, 即雇佣蜂、跟随蜂和侦查蜂. 雇佣蜂在蜂房附近搜索蜜源, 侧重对蜜源的探测; 跟随蜂接收其他蜜蜂分享的蜜源信息, 主要负责开采蜜源; 侦查蜂在食物源枯竭时, 随机在蜂巢附近寻找新的蜜源. 求解无约束优化问题(1)时,

$$\min_{x \in X} f(x).$$

(1)

收稿日期:2018-04-25; 修订日期:2018-07-21
基金项目:国家自然科学基金资助项目(11371197); 教育部人文社会科学青年基金项目(12YJCZH179); 江苏省教育厅高校自然科学研究重大项目(16KJA110001); 江苏省大规模复杂系统数值模拟重点实验室开放基金项目(201601)
通信作者:孙越泓(1972—), 女, 江苏盐城人, 南京师范大学副教授, 博士, 主要从事智能优化研究, E-mail:05234@njnu.edu.cn.

1.1 种群初始化

首先按照式(1)产生 SN 个个体的初始蜜源,得到初始种群:

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

式中: $i \in \{1, \dots, SN\}$, $j \in \{1, \dots, D\}$, D 代表决策变量维数; x_j^{\min} 、 x_j^{\max} 分别代表个体在第 j 维上搜索空间的下界和上界。

产生初始种群后,通过式(2)计算蜜源的质量:

$$fit_i = \begin{cases} \frac{1}{1+f_i}, & f_i \geq 0; \\ 1 + |f_i|, & f_i < 0, \end{cases} \quad (3)$$

式中: f_i 为蜜源 x_i 的目标函数值 $f(x_i)$; fit_i 为蜜源的适应度值,适应度值越大,表示该蜜源质量越优。

1.2 雇佣蜂阶段

雇佣蜂根据式(3)对每个蜜源进行一次邻域搜索,产生新蜜源:

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}), \quad (4)$$

式中: $k \in \{1, \dots, SN\}$, $j \in \{1, \dots, D\}$, 这两个数都是随机选取的,但 $k \neq i$; ϕ_{ij} 是 $[-1, 1]$ 上的随机数。在每次邻域搜索过程中随机更新一维(j)上的数值,然后评估 v_i 的质量,利用贪婪选择策略更新蜜源。

1.3 跟随蜂阶段

跟随蜂阶段,雇佣蜂先将蜜源信息共享给观察蜂,然后跟随蜂依据蜜源质量,选择蜜源进行开采,每个蜜源的选择概率计算方式如下:

$$P_i = \frac{fit_i}{\sum_{i=1}^{SN} fit_i}, \quad (5)$$

式中: P_i 表示蜜源 i 的选择概率。当蜜源被选中之后,跟随蜂将按照式(4)对所选中的蜜源进行邻域搜索,并根据贪婪选择策略更新蜜源。

1.4 侦查蜂阶段

控制参数 $limit$ 用来记录某个解未被更新的次数。假定某个解经过 $limit$ 次循环之后都未得到改善,即表明这个解陷入了局部最优,应该被放弃,与这个解相对应的雇佣蜂也转变为侦查蜂,将按式(2)重新随机产生新蜜源。

2 基于单纯形的改进精英蜂群算法

受精英人工蜂群算法^[6]和 Nelder-Mead 单纯形方法^[7]的启发,笔者提出了 NM-PS-MEABC 算法。该算法的基本思想是在蜂群中建立精英解集,

在雇佣蜂阶段借助精英个体引导蜜源搜索,并利用蜂群中蜜源的质量排序重新构造蜜源的选择概率公式。在跟随蜂阶段,选择种群最优蜜源引领蜂群,加强算法对全局最好解的局部开采能力,同时将随机选择邻居蜜源变为定向选择。最后,利用单纯形算法对精英解集进行再次更新,使得算法的局部寻优能力更强,从而达到提高求解精度的目的。而多精英人工蜂群算法和新算法的3个改进之处:多定向更新策略、基于蜜源目标函数值排序的选择概率公式和基于精英解集的单纯形局部搜索机制。

2.1 多精英蜂群算法

为了提高人工蜂群算法的求解精度,Xiang等^[6]受粒子群算法^[8]和文献^[9]的启发,将蜂群中多个蜜源丰富的个体作为精英,构建了精英解集。雇佣蜂阶段通过轮盘赌从精英解集中随机选择一个精英,利用式(6)改进蜜源的更新:

$$v_{id} = x_{id} + \phi_{id}(x_{id} - x_{kd}) + \sigma_{id}(x_{id} - Elitist_{md}), \quad (6)$$

式中: $i \in \{1, \dots, SN\}$; $d \in \{1, \dots, D\}$; $k \in \{1, \dots, SN\}$; ϕ_{id} 、 σ_{id} 是 $[-1, 1]$ 上的随机数; $Elitist_{md}$ 表示利用轮盘赌方法从精英种群中选出的第 m 个精英的第 d 维。同时,在跟随蜂阶段结合蜂群的最优蜜源信息,通过式(7)加强对优质蜜源的开采:

$$v_{ij} = x_{ij} + \phi_{ij}(x_{ij} - x_{kj}) + \theta_{ij}(x_{ij} - gbest_j), \quad (7)$$

式中: $i \in \{1, \dots, SN\}$; $j \in \{1, \dots, D\}$; $k \in \{1, \dots, SN\}$; ϕ_{ij} 、 θ_{ij} 是 $[-1, 1]$ 上的随机数; $gbest_j$ 表示当代蜂群中的最优个体的第 j 维。

2.2 定向更新策略

Van den Bergh^[10]等指出,在粒子群算法中,粒子更新会出现整体在优化,但是某一维却恶化的情况。对于 ABC 算法同样存在这种现象,由式(4)、(6)和(7)可知,无论是雇佣蜂阶段还是跟随蜂阶段,在进行蜜源更新时,邻居食物源 x_{kj} , $k \in \{1, \dots, SN\}$ 均是随机从蜂群中选择的个体, k 的随机选取可能会导致蜜源第 j 维更新朝着远离最优蜜源的方向。

受文献^[10-11]的启发,笔者提出了多蜂群协作定向的更新策略,对于 D 维优化问题,在更新第 j 维时,将种群中所有个体的第 j 维和当前全局最优解 $gbest$ 的第 j 维求出距离 $Dist_j = (dist_{1j}, dist_{2j}, \dots, dist_{SNj})^T$,并从中找出最小的距离 $dist_{m'j}$,则蜜源在更新第 j 维时,邻居食物源暂时取为 x'_m 。接下来以 2 维为例,定向过程如图 1 所示。




图 1 2 维空间中蜜源搜索邻居的选取说明
Fig.1 Illustration of how to select the neighbour sources in 2-D solution space

图 1 中,种群个体数目 $SN = 5$,维数 $D = 2$, $gbest$ 为当前种群中的最优解. 对于第一维,种群中个体 x_2 距离 $gbest$ 最近;对于第二维,个体 x_4 距离 $gbest$ 最近,虽然它在第一维上是种群中距离 $gbest$ 最远的个体.

对于优化问题 $\min_{x \in X} f(x)$ 而言,整个蜂群在寻优过程中不断寻找质量高的蜜源,也即函数值不断下降的解. 然而函数的下降依赖于搜索过程中蜂群中个体不断趋向问题的解 x^* ($x^* \in X$). 最优定向策略应用于观察蜂阶段,通过 $Dist_j$ 的大小来衡量种群中不同个体在第 j 维和 $gbest$ 的距离.

同时,定向过程中为了避免种群搜索陷入局部,在确定了第 j 维离 $gbest$ 最近的食物源 x'_m 后,再结合种群中其他个体蜜源适应度信息,利用锦标赛^[12]角逐出优胜个体,对 x'_m 进行修正,最终确定为 x_m . 在新算法中用公式(4)更新蜜源的第 j 维时,邻居食物源 x_k 不是随机选取,而是选择 x_m . 这样定向选择每一维蜜源需要开采的区域,更好地利用了当前种群个体的有效信息. 同时,随着种群不断进化,最优蜜源 $gbest$ 在不断改进,从而加快更优质蜜源搜索的速度.

通过上述过程,在更新第 j 维时,借助当前最优解的同时,将整个种群中的所有个体进行比较. 一方面加强了个体间的信息交流,定向引导蜜源更新;另一方面随着迭代的进行,种群当前最优蜜源不断趋向问题的解 x^* ,也保证了种群 $Foods = \{x_1, x_2, \dots, x_{SN}\}$ 最终能够收敛到问题的最优解 x^* ,文献[13]中有详细的收敛证明.

2.3 基于蜜源目标函数值排序的选择概率公式

基本的人工蜂群算法在跟随蜂阶段,利用式(5)计算每只蜂的跟随概率. 在数值实验中发现,在迭代前期,整体蜜源的质量都不是很好,对应的

选择概率也就相对较低,从而被跟随的可能性较小;到了迭代后期,蜜源的整体质量都很高,即 f_{it} 比较相近,蜜源的选择概率大部分接近 $1/SN$. 产生这一现象的主要原因是对于目标函数值小于一定数量级的蜜源,已经很难通过蜜源适应度值的计算公式(3)和概率计算公式(4)将这些蜜源加以区分.

为了解决这一问题,笔者受文献[14]的启发,在构造选择概率公式时,不采用蜜源的适应度值,而是直接利用蜜源目标函数值从大到小排序后的序标,借助式(8)重新定义:

$$P_i = a + b \cdot \frac{e^{\frac{j-1}{NS-1}} - 1}{e^c - 1}. \tag{8}$$

式中: $a = 0.1$; $b = 0.9$; c 为常数; j 为第 i 个蜜源在整个蜂群中按照目标函数值从大到小排序得到的序标. 第 i 个蜜源越好,它的序标 j 将越大,通过式(8)计算得到的选择概率 P_i 也就越接近 1.

2.4 精英解集 Nelder-Mead 单纯形局部搜索机制

单纯形法 (nelder-mead simplex method, NM-SM)^[7] 是一种局部搜索算法,具有较强的局部搜索能力. 近年来,单纯形法被用于一些全局优化算法中来增强局部搜索能力. 单纯形法和人工鱼群算法^[15]、头脑风暴算法^[16]等优化算法都做结合. 单纯形算法的基本思想是:对于 D 维优化问题,利用 $D + 1$ 个点作为顶点构成凸包,即单纯形. 在已有单纯形的基础上通过反射、扩张和收缩去寻找一个目标函数值更小的点. 如果得到这样的点就可以用该点作为顶点构造新的单纯形,否则将已有单纯形缩小. 具体算法流程见文献[17].

在单纯形算法每次迭代过程中,反射系数、扩张系数、收缩系数分别为 α, γ, β , 定义如下:

$$\begin{cases} \text{反射点: } x^\alpha = \bar{x} + \alpha(\bar{x} - x^h); \\ \text{扩张点: } x^\gamma = \bar{x} + \gamma(x^\alpha - x^h); \\ \text{收缩点: } x^\beta = \bar{x} + \beta(x^h - \bar{x}), \end{cases}$$

$$\text{式中, } x^h = \arg \max_{1 \leq i \leq D+1} f(x^i); \bar{x} = \frac{1}{D} \sum_{i=1, i \neq h}^{D+1} x^i.$$

单纯形算法的大致过程如下:

步骤 1 初始化. 计算 $D + 1$ 个点的适应度值,找出最优点 x^g 、次优点 x^p 、中心位置 \bar{x} 、最差点 x^h .

步骤 2 对最差的点进行反射,得到反射点 x^α .

步骤 3 若 $f(x^\alpha) < f(x^g)$,则执行扩张操作得到扩张点 x^γ ,若 $f(x^\gamma) < f(x^g)$,则 $x^h = x^\gamma$;否则 $x^h = x^\alpha$.

步骤 4 若 $f(x^\alpha) < f(x^h)$,则执行收缩操作得到收缩点 x^β ,若 $f(x^\beta) < f(x^h)$,则 $x^h = x^\beta$.

步骤5 若 $f(x^h) > f(x^\alpha) > f(x^p)$, 执行收缩操作得到收缩点 x^w ; 若 $f(x^w) < f(x^h)$, 则 $x^h = x^w$. 否则, $x^h = x^\alpha$.

人工蜂群算法虽然全局搜索能力不错,但是存在着局部搜索能力差、在接近最优解时搜索效率下降、求解复杂问题时容易陷入局部最优而停滞不前的缺点^[18],而单纯形法具有很强的局部搜索能力,它和人工蜂群算法的全局搜索能力互补,如果将两者结合必然相得益彰.

因此,为了进一步加强算法对蜜源的开采能力,将更新后的精英解集在侦查蜂阶段之后结合当前全局最优蜜源,利用 $D + 1$ 个蜜源构成初始单纯形,初始单纯形的构造具体如下.

(1) 若 $SN > D$, 则对更新后的精英解集按照函数值从小到大排序,利用前 D 个精英蜜源和全局最优蜜源构成初始单纯形.

(2) 若 $SN < D$, 则利用式(9)重新产生 $(D - SN)$ 个体,和精英解集、全局最优蜜源一起构成初始单纯形:

$$v_i = elites_i + \varphi(x_i - x_k), \quad (9)$$

式中: $i \in \{1, \dots, D - SN\}$; $k \in \{1, \dots, SN\}$; φ 是 $[-1, 1]$ 上的随机数. 然后利用 Nelder-Mead 单纯形法进行局部搜索,加快算法的收敛. 单纯形方法的迭代次数和食物源数目保持一致,取为 SN .

2.5 NM-PS-MEIABC 算法步骤

步骤1 参数设置. 设置蜂群规模 NP , 雇佣蜂数 $SN = NP/2$, 跟随蜂数 $SN = NP/2$. 迭代步数计数器 $t = 0$, 最大函数计算次数, 蜜源停留最大限制次数 $limit$, 初始化蜜源停留次数 $trial = 0$.

步骤2 初始化种群. 按式(2)随机产生 SN 个蜜源. 利用式(3)对蜜源质量进行评价. 并记录下此时的全局最优蜜源 $gbest$, 并利用初始种群初始化精英解集.

步骤3 精英个体引导雇佣蜂搜索. 利用轮盘赌方法, 随机从精英解集中选取一个精英个体 $Elitist_m$, 利用式(6)对蜜源进行搜索. 对超出搜索范围的解直接利用精英 $Elitist_m$ 代替, 接着利用贪婪选择决定是否更新蜜源, 更新 $gbest$ 和蜜源停留次数 $trial$.

步骤4 选择概率计算. 将所有蜜源按照目标函数值从大到小排列. 蜜源 x_i 质量越高, 序标 j 越大. 利用式(8)计算跟随蜂选择蜜源 x_i 的概率 P_i .

步骤5 全局最优蜜源引导跟随蜂搜索. 被吸

引的跟随蜂利用式(7), 结合雇佣蜂的邻域信息和全局最优蜜源信息, 对优质蜜源进行局部开采. 式(7)中蜜源 x_i 的邻居 x_k 不再是随机选取的, 而是对即将更新的第 j 维, 利用定向更新策略, 从第 j 维中, 选取距离当前最优解第 j 维最近的个体 x'_m 后, 再利用锦标赛修正. 对更新后超出搜索范围的解直接利用蜜源搜索空间的边界替换, 接着利用贪婪选择决定是否更新蜜源, 更新 $gbest$ 和蜜源停留次数 $trial$.

步骤6 侦查蜂更新. 若蜜源的停留次数 $trial > limit$ 成立, 则该蜜源转为侦查蜂, 用式(2)重新随机产生新的蜜源将其更新.

步骤7 精英解集的更新. 如果种群中全局最优蜜源优于轮盘赌选出的最差精英个体, 则将其替换从而更新精英解集, 保持精英蜜源个数为 SN .

步骤8 基于精英解集的单纯形局部搜索机制. 用更新后的精英解集和全局最优蜜源构造初始单纯形, 接下来采用 Nelder-Mead 单纯形进行局部再开采, 最后利用输出的单纯形更新对应的精英个体. 若单纯形最优解优于蜂群最差个体, 则替换蜂群最差个体, 将利用单纯形进行局部搜索得到的最优蜜源信息传递给蜂群.

步骤9 记录全局最优. 单纯形开采后的最优蜜源和 $gbest$ 进行比较, 记录较优的蜜源作为当前全局最优蜜源.

步骤10 停止准则. 判断是否达到最大函数计算次数 FES , 若满足则输出全局最优解, 否则转步骤3.

3 数值仿真实验结果

3.1 测试函数

为了验证 NM-PS-MEIABC 算法的有效性, 笔者进行了数值实验, 将其与 ABC 算法^[1] 和 PS-MEABC^[6] 算法, NMABC^[18] 作比较. 实验设备为: 台式电脑 HP LV2011, CPU 为 Intel Core2 Duo CPU E7500 2.93 GHz, 2 012 MB 内存, 实验仿真软件 Matlab2012b. 所有用于比较的算法的种群大小 $SP = 100$, 食物源数目 $SN = 50$, 最大限制次数 $limit = 100$, 决策变量维数为 30 维, 函数计算次数 (maximum function evaluations, MFE) 为 300 000 次. 参照基于精英蜂群搜索策略的人工蜂群算法^[19], 笔者选取 8 个基本测试函数, 如表 1 所示.

表 1 测试函数
Tab.1 Test functions

S	函数名称	函数方程	取值范围	最优解	特征
f_1	Sphere	$f_1(X) = \sum_{i=1}^D x_i^2$	$[-100,100]^D$	$f_1(\vec{0}) = 0$	UM
f_2	Step	$f_2(X) = \sum_{i=1}^D (\lfloor x_i + 0.5 \rfloor)^2$	$[-100,100]^D$	$f_2(\vec{0}) = 0$	UM
f_3	Quartic Noise	$f_3(X) = \sum_{i=1}^D ix_i^4 + \text{rand}[0,1)$	$[-1.28,1.28]^D$	$f_3(\vec{0}) = 0$	UM
f_4	Ackley	$f_4(X) = -20\exp\left(0.2\sqrt{\frac{1}{D}\sum_{i=1}^D x_i^2}\right) - \exp\left(\frac{1}{D}\sum_{i=1}^D \cos(2\pi x_i)\right) + e$	$[-32,32]^D$	$f_4(\vec{0}) = 0$	MM
f_5	Griewank	$f_5(X) = 1 + \sum_{i=1}^D (x_i^2/4000) - \prod_{i=1}^D (\cos(x_i/\sqrt{i}))$	$[-600,600]^D$	$f_5(\vec{0}) = 0$	MM
f_6	Penalized1	$f_6(X) = \frac{\pi}{D}\{10\sin^2(\pi y_1) + \sum_{i=1}^{D-1} (y_i - 1)^2[1 + 10\sin^2(\pi y_{i+1})] + (y_D - 1)\} + \sum_{i=1}^D u(x_i, 10, 100, 4), y_i = 1 + \frac{1}{4}(x_i + 1),$ $\sum_{i=1}^D u(x_i, 10, 100, 4) = \begin{cases} k(x_i - a)^m, x_i > a \\ 0, -a \leq x_i \leq a \\ k(-x_i - a)^m, x_i < -a \end{cases}$	$[-50,50]^D$	$f_6(\vec{0}) = 0$	MM
f_7	Schaffer	$f_7(X) = 0.5 + \sin^2\sqrt{\sum_{i=1}^D x_i^2} - 0.5/[1 + 0.001(\sum_{i=1}^D x_i^2)]^2$	$[-100,100]^D$	$f_7(\vec{0}) = 0$	MM
f_8	Penalized2	$f_8(X) = \frac{\pi}{D}\{10\sin^2(3\pi x_i) + \sum_{i=1}^{D-1} (x_i - 1)^2[1 + 10\sin^2(\pi x_{i+1})] + (x_D - 1)\} + \sum_{i=1}^D u(x_i, 5, 100, 4)$	$[-50,50]^D$	$f_8(\vec{0}) = 0$	MM

新算法在构建好的精英解集上引入了Nelder-Mead单纯形局部搜索机制,以增强人工蜂群的局部寻优能力.单纯形中反射系数、扩张系数以及收缩系数的不同取值,在不同问题中对算法影响程度不同.通常反射系数 $\alpha=1$,扩张系数 $1<\gamma\leq 2$,收缩系数 $0<\beta<1^{[20]}$.接下来对反射系数和收缩系数设置不同取值,进行实验分析,测试中选取单峰函数 f_1 ,多峰函数 f_4 f_7 .在30维上进行30次模拟,最大函数计算次数为300 000.

表 2 算法 NM-PS-MEIABC 关于扩张系数 γ 的不同取值 ($\beta=0.5$) 和关于收缩系数 β 的不同取值 ($\gamma=1.2$)

Tab.2 The different values of the expansion coefficient and contraction coefficient

函数	标准	$\gamma=1.2$	$\gamma=1.5$	$\gamma=2$	$\gamma=2\sim1.2$	$\beta=0.2$	$\beta=0.5$	$\beta=0.8$
f_1	Mean	1.13E-59	1.54E-57	1.15E-55	1.28E-63	3.84E-18	1.13E-63	4.52E-65
	Std	3.86E-59	2.18E-57	1.63E-55	1.91E-63	5.44E-18	3.86E-63	9.41E-66
f_4	Mean	2.61E-15	4.15E-15	3.67E-14	1.58E-15	6.66E-01	1.73E-14	6.42E-15
	Std	3.20E-15	2.48E-15	2.96E-14	5.42E-15	1.15E+00	2.36E-14	1.36E-15
f_7	Mean	1.59E+00	2.87E+00	3.53E+00	8.29E-01	3.71E+01	1.59E+00	9.79E-01
	Std	2.15E+00	2.70E+00	1.39E+00	3.59E-01	4.90E+01	2.15E+00	3.45E-01

缩系数 $\beta = 0.2$ 时,算法在 3 个给定函数上的结果最差,可知局部寻优的单形收缩过小容易导致算法陷入局部最优.当 $\beta = 0.8$ 时,算法的效果最好,故在新算法 NM-PS-MEIABC 中取 $\beta = 0.8$.

3.2 实验结果

由表 3 可以看出,当函数计算次数相同时,很明显 NM-PS-MEIABC 算法具有较好的寻优性能,比 ABC 算法、PS-MEABC、NMABC 算法有更高的求解精度.

表 3 本文算法与其他人工蜂群算法在 30 维上结果比较

Tab.3 The comparison results with ABC variants

函数	标准	NM-PS-MEIABC	PS-MEABC	NMABC	ABC
f_1	Mean(Std)	8.25E-65(3.17E-65)	1.67E-37(2.22E-37)	2.71E-31(4.50E-31)	3.66E-16(5.17E-16)
f_2	Mean(Std)	0.00E+00(0.00E+00)	0.00E+00(0.00E+00)	0.00E+00(0.00E+00)	0.00E+00(0.00E+00)
f_3	Mean(Std)	5.50E-03(1.50E-03)	1.11E-01(2.36E-02)	1.20E-02(1.29E-02)	7.60E-01(1.07E-02)
f_4	Mean(Std)	1.96E-14(6.96E-15)	4.43E-14(5.65E-15)	1.24EE-09(2.15E-09)	3.20E-14(4.52E-14)
f_5	Mean(Std)	5.51E-16(2.45E-16)	3.73E-15(1.09E-14)	2.98E-14(1.26E-14)	4.99E-13(7.06E-12)
f_6	Mean(Std)	1.57E-32(2.43E-48)	1.76E-32(2.71E-33)	4.32E-32(4.76E-32)	3.31E-16(4.68E-16)
f_7	Mean(Std)	6.32E-02(3.12E-02)	4.21E-01(5.68E-01)	4.25E-01(1.36E-01)	4.77E-01(2.51E-01)
f_8	Mean(Std)	1.35E-32(8.71E-34)	1.48E-32(1.55E-33)	1.35E-32(2.35E-32)	2.69E-16(3.81E-16)

图 2、图 3 分别给出了 ABC 算法、PS-MEABC 算法、NMABC 算法和 NM-PS-MEIABC 算法对于 30 维 f_1 (Sphere) 函数和 f_5 (Griewank) 函数,在独立运行 30 次时取平均最优值的收敛情况.从

图 2 ~ 图 3 可以看出,笔者算法在收敛速度和搜索精度上要优于其余 3 种算法.

4 结束语

笔者提出了一种基于单纯形的改进精英人工蜂群算法,算法利用单纯形算法加强对解的局部寻优,并提出了新的邻域搜索方法和跟随概率的计算公式.数值实验结果表明,新算法与 ABC、PS-MEABC、NMABC 算法相比,求解精度和收敛速度均有显著提高,寻优性能也更加稳定,未来可以进一步做 ABC 算法的应用以及综述.

参考文献:

[1] KARABOGA D. An idea based on honey bee swarm for numerical optimization,TR06[R]. Kayseri:Faculty of Engineering,Erciyes University,2005.

[2] AKAY B, KARABOGA D. A modified artificial bee colony algorithm for real parameter optimization[J]. Information sciences, 2012, 192: 120 - 142.

[3] 苏国韶,钱坤. 人工蜂群算法在重力坝断面优化设计中的应用[J]. 计算机工程与应用, 2011, 47(11): 223 - 225.

[4] QUAN H,SHI X. On the analysis of performance of the improved artificial-bee-colony algorithm[C]// Proceedings of the fourth international conference on natural computation. Jinan,China: IEEE, 2008: 654 - 658.

[5] KIRAN M S, BABALIK A. Improved artificial bee colony algorithm for continuous optimization problems[J]. Journal of computer and communications, 2014, 2(4): 108.

[6] XIANG Y, PENG Y, ZHONG Y, et al. A particle swarm inspired multi-elitist artificial bee colony algo-




图 2 Sphere 函数收敛情况

Fig.2 The convergence of Sphere function




图 3 Griewank 函数收敛情况

Fig.3 The convergence of Griewank function

- rithm for real-parameter optimization [J]. Computational optimization and applications, 2014, 57(2): 493–516.
- [7] KAMIYAMA D, TAMURA K, YASUDA K. Down-hill simplex method based differential evolution[C]//Proceedings of annual conference in society of instrument and control engineers, SAC 2010. Tokyo; SAC, 2010: 1641–1646.
- [8] EBERHART R C, KENNEDY J. A new optimizer using particle swarm theory[C]//Proceedings of the Sixth International Symposium on Micro Machine and Human Science, MHS 1995. Nagoya; IEEE, 1995: 39–43.
- [9] KENNEDY J, EBERHART R C. Particle swarm optimization[C]//Proceedings of ICNN 1995 International Conference on Neural Networks. Porth; IEEE, 1995: 1942–1948.
- [10] VAN DEN BERGH F, ENGELBRECHT A P. A cooperative approach to particle swarm optimization[J]. IEEE transactions on evolutionary computation, 2004, 8(3): 225–239.
- [11] MA L, HU K, ZHU Y, et al. Discrete and continuous optimization based on hierarchical artificial bee colony optimizer[J]. Journal of applied mathematics, 2014(1): 1–20.
- [12] LIANG J J, QIN A K, SUGANTHAN P N. Comprehensive learning particle swarm optimizer for global optimization of multimodal functions[J]. IEEE transactions on evolutionary computation, 2006, 10(3): 281–295.
- [13] 江铭炎, 袁东风. 人工蜂群算法及其应用[M]. 北京: 科学出版社, 2015.
- [14] LYNN N, SUGANTHAN P N. Heterogeneous comprehensive learning particle swarm optimization with enhanced exploration and exploitation[J]. Swarm and evolutionary computation, 2015, 24: 11–24.
- [15] 张红霞, 罗毅, 师瑞峰. 基于单纯形法的改进型人工鱼群算法[J]. 计算机应用, 2011, 31(5): 1321–1327.
- [16] CAO Y Y, CHEN W, CHENG S, et al. A simple brain storm optimization algorithm via visualizing confidence intervals[C]//Proceedings of 11th International conference on Simulated Evolution and Learning. Shenzhen, China; SEAL, 2007: 27–28.
- [17] NELDER J A, MEAD R. A simplex method for function minimization[J]. Computer journal, 1965, 7(4): 308–313.
- [18] 罗琨, 杨磊, 查本波, 等. 基于单纯形法的人工蜂群算法改进研究[J]. 广西师范学院学报(自然科学版), 2014, 31(3): 90–98.
- [19] 马卫, 孙正兴. 基于精英蜂群搜索策略的人工蜂群算法[J]. 计算机应用, 2014, 34(8): 2299–2305.
- [20] RANAN K P, KUMAR V, GARG Y, et al. Efficient design of discrete fractional-order differentiators using nelder-mead simplex algorithm[J]. Circuits systems & signal processing, 2016, 35(6): 2155–2188.

An Improved Multi-elitist Artificial Bee Colony Algorithm Based on Nelder-Mead Simplex Method

JIN Ye¹, SUN Yuehong^{1,2}, WANG Jiacyi¹, WANG Dan¹

(1. School of Mathematical Sciences, Nanjing Normal University, Nanjing 210023, China; 2. Jiangsu Provincial Key Laboratory for Numerical Simulation of Large Scale Complex Systems, Nanjing Normal University, Nanjing 210023, China)

Abstract: There were some problems in the Artificial Bee Colony (ABC) algorithm, such as the slow convergence speed, low solution precision and easy to fall in local optimum. Inspired by particle swarm optimization algorithm, multi-elitist artificial bee colony algorithm for real-parameter optimization the with use of global best solution and an elitist randomly selected from the elitist set were adopted to enhance the exploitation of the global best solution. In this paper, we the elitist to guide the nectar search during the employed bee process was introduced. And the selection probability formula of food source was reconstructed by using the quality of food source. In the onlooker bee stage, the best food source was selected to guide the swarm to enhance the exploitation of the global best solution, and the neighbor food source was selected to be the optimally directional choice. As the same time, a simplex method was used on elitist solution set to balance the exploration and exploitation ability of the algorithm. The numerical experiment results showed that the proposed algorithm had higher searching precision and faster convergence speed.

Key words: Artificial Bee Colony algorithm; directional update strategy; elitist solution set; selecting probability; simplex method