

张伟, 张彦伟. 基于多策略的动态分群 ABC 算法[J]. 智能计算机与应用, 2025, 15(1): 136-143. DOI: 10.20169/j.issn.2095-2163.250121

基于多策略的动态分群 ABC 算法

张伟, 张彦伟

(河南理工大学 电气工程与自动化学院, 河南 焦作 454003)

摘要: 针对人工蜂群算法开发能力差, 探索和开发之间存在不平衡的缺点, 本文提出了一种基于多策略的动态分群人工蜂群算法(Multi-Strategy Dynamic Clustering Artificial Bee Colony algorithm, MSDCABC)。首先, 采用适应度排序和随机分组策略进行种群划分, 使其可以同时搜索不同的区域; 其次, 在搜索过程中结合动态子群策略, 根据适应度大小对优秀子群中的个体进行更新, 不同普通子群间根据其搜索策略的成功率竞争产生后代, 动态调整各普通子群间的种群数量; 最后, 运用多策略选取机制对各个子群设计不同的搜索策略, 通过加强优秀子群的引导作用, 增加普通子群在探索和开发上的多样性, 实现算法在探索与开发之间的平衡。9个基准测试函数的仿真实验结果表明, 与其他改进算法对比, 本文所提改进算法具有较高的收敛精度和较强的搜索能力。

关键词: 人工蜂群算法; 多策略; 种群划分; 动态子群

中图分类号: TP273

文献标志码: A

文章编号: 2095-2163(2025)01-0136-08

Multi-strategy dynamic clustering ABC algorithm

ZHANG Wei, ZHANG Yanwei

(School of Electrical Engineering and Automation, Henan Polytechnic University, Jiaozuo 454003, Henan, China)

Abstract: Aiming at the disadvantages of poor development ability and imbalance between exploration and development of Artificial Bee Colony Algorithm, multi-strategy dynamic clustering artificial bee colony algorithm was proposed. Firstly, the population is divided into multiple subgroups by using fitness ranking and random grouping strategies, so that it can search different regions at the same time. Secondly, in the search process, the dynamic subgroup strategy is combined to update the individuals in the excellent subgroup according to the fitness level. Different ordinary subgroups compete to produce offspring according to the success rate of their search strategy, and the population number of each ordinary subgroup is dynamically adjusted. Finally, the multi-strategy selection mechanism is used to design different search strategies for each subgroup. By strengthening the guiding role of excellent subgroups, the diversity of common subgroups in exploration and development is increased, and the balance between exploration and development of the algorithm is achieved. The simulation results of 9 benchmark test functions show that compared with other improved algorithms, the proposed algorithm has higher convergence accuracy and stronger searching ability.

Key words: Artificial Bee Colony Algorithm; multi-strategy; population division; dynamic subgroup

0 引言

人工蜂群(Artificial Bee Colony, ABC)算法是由 Karaboga 于 2005 年提出的一种基于群体智能的随机优化方法, 其灵感来源于蜂群觅食的自组织行为, 已被证明是一种解决各类优化问题非常有效的方法^[1]。相比其他群体智能算法, ABC 算法具有简单

稳定、易于实现、控制参数少等优点^[2-3]。近年来, ABC 算法受到相关领域中众多研究人员的密切关注。

然而, ABC 算法在求解复杂优化问题时存在求解精度不高、收敛速度慢等问题^[4]。导致 ABC 性能受限的一个主要原因是其解搜索方程的探索能力强而开发能力不足, 探索和开发之间存在不平衡^[5]。

基金项目: 国家自然科学基金(61703145); 河南省科技攻关项目(222102210213)。

作者简介: 张彦伟(1997—), 男, 硕士研究生, 主要研究方向: 智能优化算法, 智能特征建模, 污水处理过程优化控制等。

通信作者: 张伟(1978—), 女, 博士, 教授, 主要研究方向: 智能特征建模, 神经网络结构优化, 污水处理过程优化控制等。Email: zwei1563@126.com。

收稿日期: 2023-09-18

针对 ABC 算法存在的缺陷与不足, 学者们提出了多种改进方案, 大多数集中在设计新的解搜索方程^[6]。受粒子群优化算法 (Particle Swarm Optimization, PSO) 的启发, Zhu 等^[7]提出了一种最优引导 ABC 算法, 利用全局最佳解作为食物源的学习对象, 对其他食物源进行引导, 以提高算法的开发能力, 但在迭代后期存在种群多样性不足的缺点。在此基础上, Xiang 等^[8]提出了一种粒子群启发的多精英 ABC 算法 (PS-MEABC), 采用全局最佳解, 从建立的精英档案中随机选择的精英个体作为学习对象, 对每个食物源的参数进行修改, 提高了种群的多样性; Zhou 等^[9]提出了一种基于邻域搜索的算法 (Neighborhood Search Artificial Bee Colony algorithm, NSABC), 选择环型邻域拓扑中的最优个体作为学习对象。这些改进的 ABC 变体主要是利用全局最佳解或一些精英解来提高开发能力。然而, 在加强开发的同时, 全局最佳解或精英解可能因为削弱探索或种群多样性而导致过早收敛。Peng 等^[10]提出了一种最优的邻域引导搜索策略来平衡探索和开发, 学习对象是从当前食物源的随机动态邻域中选择的最佳学习对象, 使算法在保持探索能力的同时增强了开发能力。但是面对不同的优化问题时, 固定的邻域大小及搜索策略缺乏适用性, 会导致收敛速度下降和陷入局部最优。

为了避免以上问题, 一些算法引入了多策略技术, 其有效性在大量的优化算法中得到了证明^[11-12]。多策略技术可以根据不同的优化问题的性质, 选择不同的搜索策略, 实现有效的多策略协同搜索^[13]。Kiran 等^[14]设计了 5 种不同的搜索策略, 使用计数器记录每个搜索策略中成功更新的解的数量, 根据计数器值计算各搜索策略的选择概率。但是这种方法并没有区分雇佣蜂和跟随蜂, 迭代过程中缺乏有效的跳出局部最优的手段。Song 等^[15]提出了两种不同的搜索策略, 分别用于探索和开发, 并且在迭代中根据历史经验自适应地选择搜索策略; Xing 等^[16]进一步选择和设计了多种具有不同探索和开发搜索能力的策略, 并提出了一个进化比率来反映搜索策略适应性的指标。但是这些多策略算法都是在整体种群的基础上进行更新, 在初始时随机选择搜索策略, 对种群中不同个体的特性缺乏针对性的策略。

本文提出了一种基于多策略的动态分群人工蜂群算法 (MSDCABC)。对 ABC 算法的主要改进在于:

(1) 提出一种适应度排序和随机分组策略, 将整个种群划分成多个互不相交的子种群, 根据其不同表现确定为优秀子群和普通子群, 其中个体数量最多的普通子群又被随机分为多组, 使多个子群可以同时搜索不同的区域, 增加了种群的多样性;

(2) 与目前大多数分群算法中固定种群中个体数量不同, 本文提出一种动态子群策略, 在搜索过程中子群进行动态重组与交流, 对优秀子群中的较差个体进行更新, 同时根据搜索策略的成功率, 对普通子群间进行个体重组, 加强了算法的开发能力, 能够有效避免算法陷入局部最优;

(3) 提出一种多策略选取机制, 利用不同搜索策略的不同特征, 实现了算法在探索与开发之间的平衡。最后通过实验进一步验证所提算法的性能。

1 基本人工蜂群算法

基本 ABC 算法通过模拟蜜蜂觅食过程中的智能机制处理函数优化问题, 将蜂群划分为雇佣蜂、旁观蜂、侦查蜂。在算法的初始阶段, 由下式随机生成食物源的初始位置:

$$x_{i,j} = x_{i,j}^{\min} + \phi_{i,j}(x_{i,j}^{\max} - x_{i,j}^{\min}) \quad (1)$$

其中, $i = 1, \dots, SN, j = 1, \dots, D$, 每个个体表示为 $x_i = (x_{i,1}, x_{i,2}, \dots, x_{i,D})$, $x_{i,j}^{\min}$ 、 $x_{i,j}^{\max}$ 分别表示个体在第 j 维上的下界和上界; $\phi_{i,j}$ 是在 $[0, 1]$ 之间生成的均匀随机数; SN 为食物源的数量。

食物源质量即对应优化问题的适应度值, 其越大表示该食物源质量越优, 由下式计算食物源的质量。

$$fit_i = \begin{cases} \frac{1}{1 + f_i}, & f_i \geq 0 \\ \frac{1}{1 + |f_i|}, & f_i < 0 \end{cases} \quad (2)$$

其中: f_i 为食物源 i 的目标函数值。

在演化过程中, ABC 通过依次执行雇佣蜂阶段、旁观蜂阶段、侦查蜂阶段来使种群不断向最优解逼近。

雇佣蜂阶段。每个雇佣蜂在初始食物源附近进行搜索并产生新的食物源。 $v_{i,j}$ 是更新后的食物源:

$$v_{i,j} = x_{i,j} + \varphi_{i,j}(x_{k,j} - x_{i,j}) \quad (3)$$

其中, $x_{k,j}$ 是种群中随机选择的与 $x_{i,j}$ 不同的食物源, $\varphi_{i,j}$ 是 $[-1, 1]$ 的均匀随机数。

在新的食物源 v_i 和原有食物源 x_i 之间进行贪婪选择, 如果 v_i 比 x_i 好, 那么 x_i 将被 v_i 取代。

旁观蜂阶段。在接收到雇佣蜂的食物源信息后, 按贪婪法选择食物源进行开发, 由下式计算每个

食物源的选择概率:

$$p_i = \frac{fit_i}{\sum_{i=1}^{NP} fit_i} \quad (4)$$

其中, fit_i 是食物源 x_i 的适应值。

选择概率 p_i 随着 fit_i 的增加而增加,表明更好的食物源更有可能被旁观蜂选择。

侦察蜂阶段。食物源在限制次数 $limit$ 内持续更新失败,则相应的雇佣蜂转换成侦查蜂,在搜索区域内由式(1)随机产生一个新食物源取代该食物

源,对应的食物源限制次数置为0。

2 基于多策略的动态分群 ABC 算法

针对人工蜂群算法开发能力差,探索和开发之间存在不平衡的缺点,本文提出了一种基于多策略的动态分群人工蜂群算法(MSDCABC),整体框架如图1所示。通过算法的种群划分方法、动态子群策略、多策略选取等部分之间的协同,共同指导雇佣蜂、旁观蜂及侦查蜂的寻优过程,提升算法的综合性能。

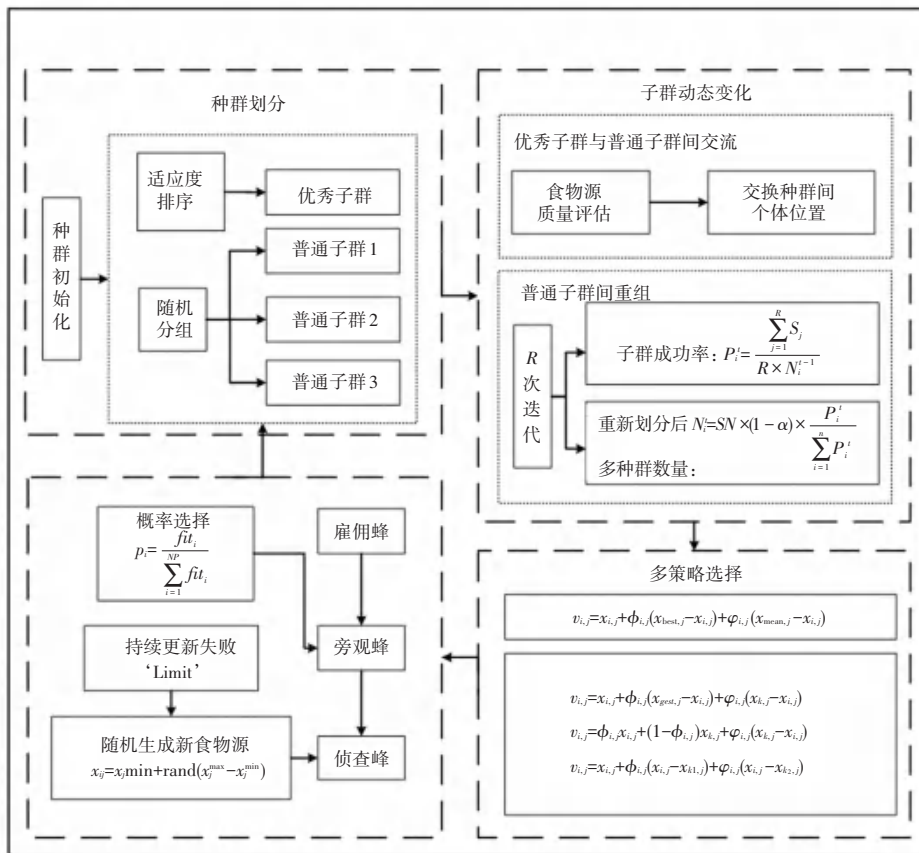


图1 MSDCABC 算法整体框架

Fig. 1 Overall framework of MSDCABC algorithm

2.1 种群划分

多策略集成 ABC 的相关研究中,通常对种群中的每个个体都一视同仁,但是从个体层次上看,个体之间存在优劣差异。根据适应度衡量,较好的个体可能离局部最优解或全局最优解更近,而较差的个体可能离局部最优解或全局最优解更远;较好的个体更适合进行开发,而对于较差的个体应更注重探索^[17]。因此,本文从个体层次出发,在设计多策略机制时,将种群分成4个具有不同特性的子群。

使用排序法和随机分组策略将种群划分为优秀种群 X_1 、普通种群 X_2 、普通种群 X_3 、普通种群 X_4 。

首先,将种群个体按照适应度值进行排序,取序列前25%的个体组成优秀种群 X_1 ;其次,按照随机分组策略把剩下的个体随机分成3个子群,此过程如图2所示。

2.2 多策略选取

针对每个子群的不同特性,本文为不同子群的个体设计具备不同搜索能力的搜索策略。

在优秀种群 X_1 中,针对其个体注重开发的特性,设计解搜索方程如下式所示,目的是使搜索范围集中在优秀个体周围。

$$v_{i,j} = x_{i,j} + \phi_{i,j}(x_{best,j} - x_{i,j}) + \varphi_{i,j}(x_{mean,j} - x_{i,j}) \quad (5)$$

其中, $x_{best,j}$ 表示种群到目前为止得到的最佳食物源的第 j 个维数; $x_{mean,j}$ 是优秀子群中所有解对应的第 j 维的平均值; $\phi_{i,j}$ 是在 $[0,1]$ 之间生成的均匀随机数; $\varphi_{i,j}$ 是在 $[-1,1]$ 之间生成的均匀随机数。




图 2 MSDCABC 种群划分

Fig. 2 Population division of MSDCABC algorithm

为了防止陷入局部最优,在搜索中加入了优秀子群的平均值作为扰动个体,提供一定的多样性。在整个搜索过程中,相比普通子群,优秀子群中的个体处于引导搜索的地位,不参与后代的竞争。

在普通子群中,设计了兼顾探索与开发的搜索策略,各个子群间表现出不同的侧重。子群 X_2, X_3, X_4 分别采用下式的方法进行最优解的搜索:

$$v_{i,j} = x_{i,j} + \phi_{i,j}(x_{gest,j} - x_{i,j}) + \varphi_{i,j}(x_{k_1,j} - x_{i,j}) \quad (6)$$

$$v_{i,j} = \phi_{i,j}x_{i,j} + (1 - \phi_{i,j})x_{k,j} + \varphi_{i,j}(x_{k,j} - x_{i,j}) \quad (7)$$

$$v_{i,j} = x_{i,j} + \phi_{i,j}(x_{i,j} - x_{k_1,j}) + \varphi_{i,j}(x_{i,j} - x_{k_2,j}) \quad (8)$$

在整个搜索过程中,3 个子群中解搜索策略共存,竞争产生后代。

种群 X_2 中,为了更好的局部搜索能力,其个体向本身子群的局部最优解 $x_{gest,j}$ 学习,同时为了保证收敛速度及增加子群间信息交流,在搜索中增加了优秀子群中的随机个体 $x_{k_1,j}$ 。种群 X_3 中,个体与一个全局随机个体 $x_{k,j}$ 进行维度上的垂直交叉搜索,主要作用于两个不同的个体之间,在相同维度上进行交叉互换,使算法不容易落入局部最优^[18]。为了使种群 X_4 具有更好的全局搜索能力,其个体向其他两个子群的随机个体进行学习,增加了种群的多样性。

2.3 动态子群策略

为了更好发挥各个子群搜索策略的性能,采用动态子群策略使普通子群竞争产生后代。每个子群的个体数量在搜索过程中不是固定的,而是动态的

进行变化。每间隔 R 代,将普通子群按其搜索策略的成功率重新划分种群数量。成功率高的子群拥有更多的后代,自适应的分配 3 个子群中的个体数量。这种策略使得每个子群的信息能够互相交流,进而提升跳出局部最优解的能力,相比传统固定种群数量有更大灵活性。子群的重组过程如图 3 所示。




图 3 普通子群间重组

Fig. 3 Recombination among ordinary subgroups

每次迭代后,基于贪婪选择,保留适应度更好的食物源。经过 R 代后计算其成功率,普通子群 X_i 中搜索策略的成功率 P_i 及其重新分配的种群数量 N_i' 如下式所示:

$$P_i' = \frac{\sum_{j=1}^R S_j}{R \times N_i^{t-1}} \quad (9)$$

$$N_i' = 75\% \times SN \times \frac{P_i'}{\sum_{i=1}^n P_i'} \quad (10)$$

其中, S 为每次迭代时普通子群 X_i 中生成的新食物源优于原有食物源的个数, SN 为总的种群数量。

在算法搜索期间优秀子群中的种群数量保持不变,为增强其与普通子群间的信息交流,加强对普通子群的引导作用,在每次迭代后,比较 4 个种群中食物源的质量,如果普通子群中较好的个体质量比优秀子群中较差的个体更好,则两个个体互换子群,其优秀子群与普通子群交流过程如图 4 所示。




图 4 不同子群间交流

Fig. 4 Communication between different subgroups

3 仿真实验及分析

3.1 实验设置

为了验证本文提出的 MSDCABC 算法的有效性,本文采用 9 个标准测试函数做寻优测试实验,9 个标准函数见表 1。 $f_1 \sim f_5$ 为单峰函数,其中 f_5 是不连续的阶跃函数, $f_6 \sim f_9$ 是多峰函数;将 MSDCABC 算法与基本 PSO^[19]、基本 ABC^[1]、最优邻域引导的 ABC^[10] 及 NSABC^[20] 进行对比实验,每个算法独立运行 30 次,采用所获得目标函数值的均值作为算法

的评价标准,反映算法求解的质量。为了比较的公平性,实验中其他对比算法所用参数与其对应原文相同,问题的维度为 $D = 30$ 时,最大迭代次数为 1 000;问题的维度为 $D = 100$ 时,最大迭代次数为 2 000;种群规模 $SN = 100$,控制参数 $limit = SN \times D$ 。当 R 较大时,在整个搜索过程中子群重组交流次数较少,不利于增加种群的多样性及跳出局部最优解的能力,当 R 较小时,子群重组交流次数过多,会导致算法的收敛速度缓慢,本文中取 $R = 50$ 。

表 1 测试函数
Table 1 Test function

函数理论	最优值	取值范围	函数表达式
f_1 -Sphere	0	$[-100, 100]$	$f(x) = \sum_{i=1}^n x_i^2$
f_2 -Schwefel2. 22	0	$[-10, 10]$	$f(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $
f_3 -Schwefel1. 2	0	$[-100, 100]$	$f(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$
f_4 -Rosenbrock	0	$[-30, 30]$	$f(x) = \sum_{i=1}^{n-1} 100(x_{i+1} - x_i^2)^2 + m(x_i - 1)^2$
f_5 -Step	0	$[-100, 100]$	$f(x) = \sum_{i=1}^n ([x_i + 0.5])^2$
f_6 -Schwefel2. 26	-12 569	$[-500, 500]$	$f(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$
f_7 -Rastrigin	0	$[-5.12, 5.12]$	$f(x) = \sum_{i=1}^n [x_i^2 - 10\cos(2\pi x_i) + 10]$
f_8 -Ackley	0	$[-32, 32]$	$f(x) = -20\exp\left(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^n x_i^2}\right) - \exp\left(\frac{1}{n}\sum_{i=1}^n \cos(2\pi x_i)\right) + 20 + e$
f_9 -Griewank	0	$[-600, 600]$	$f(x) = 1/4000 \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(x_i/\sqrt{i}) + 1$

3.2 实验结果与分析

为直观看出各算法的收敛精度和速度,在维度 $D = 30$ 且其他参数不变的情况下,给出各算法在 9 个基准测试函数的收敛曲线,如图 5 所示。从图 5 中可以看出,在除了函数 f_2 以外的其他函数中,MSDCABC 算法求解精度均优于其他 4 种算法,且在函数 f_2 中 MSDCABC 算法收敛速度更快,稳定性更高;在函数 $f_4 \sim f_9$,MSDCABC 算法在迭代前期均

能快速收敛到最优解,尤其在函数 f_5 、 f_7 和 f_9 中收敛到了理论最优值。虽然在少数测试函数中 MSDCABC 算法的收敛速度较其它算法优势并不明显,但却是最稳的,尽管在函数 f_4 和 f_6 中收敛速度出现波动,但没有陷入局部最优值。从单峰函数和多峰函数的收敛曲线图对比中,可以看出 MSDCABC 算法在多峰测试函数中较其它算法具有更大的优势,能够快速收敛且达到最优值。

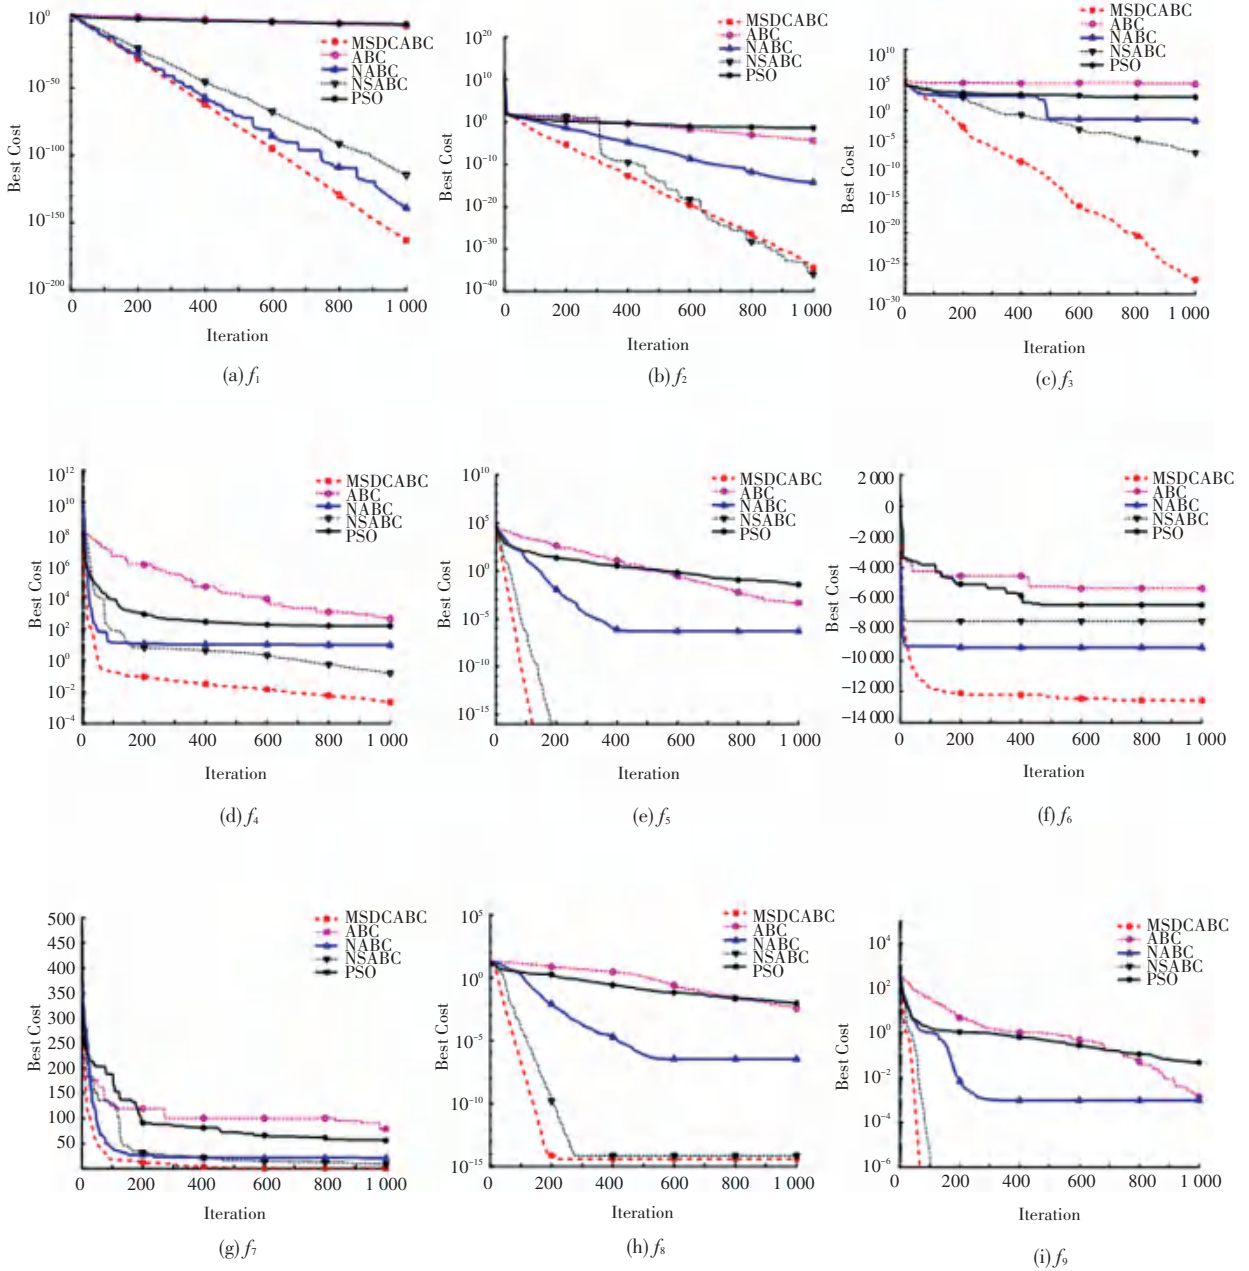


图 5 各测试函数迭代曲线
 Fig 5 Iteration curve of each test function

$D = 30$ 和 $D = 100$ 时,MSDCABC 算法和其他算法求解 9 个测试函数得到的均值见表 2 和表 3,其中最好的数据结果以加粗字体表示。

从表 2 中数据可以看出,在 $D = 30$ 时,MSDCABC 算法在 9 个测试函数中取得了 8 个第一和 1 个第二的成绩,另外在 3 个测试函数 f_5 , f_7 和 f_9 的结果均达到理论最优值 0,说明 MSDCABC 算法具有很强的收敛精度。对比其他算法,所提算法无论在单峰函数还是多峰函数上都具有明显优势。当维数逐渐增大时,搜索空间也会变得更为复杂,对算法的寻优能力考验更大。从表 3 中数据可以看出,

当维数增加到 $D = 100$ 时,所提算法在 9 个测试函数上的收敛精度都优于其他对比算法,且优势更加明显,函数 f_9 更是在 $D = 100$ 时仍收敛到理论最优值 0。对比表 2 和表 3,所提算法相对于其他算法的优势随着维数的增加而增加。综合表 2 和表 3 来看,无论是在 $D = 30$ 还是在 $D = 100$ 的情况下,所提算法较其他对比算法均具有明显的优势,这说明 MSDCABC 算法的种群划分方法、多策略选取机制及动态子群策略能够有效的提高算法的寻优能力和收敛精度。

表2 各算法实验结果对比 ($D=30$)Table 2 Comparison of experimental results of different algorithms ($D=30$)

函数	ABC	NABC	NSABC	MSDCABC	PSO
f_1	1.652 39e-04	3.956 80e-152	3.746 81e-114	3.307 65e-165	8.443 93e-04
f_2	8.110 38e-05	9.301 08e-13	4.565 39e-32	5.343 63e-32	4.349 43e-02
f_3	3.807 97e+02	3.150 23e-03	7.874 50e-09	2.730 70e-15	3.526 73e+01
f_4	3.078 05e+02	2.095 54e+01	6.383 01e-01	5.462 80e-04	2.788 22e+02
f_5	1.621 60e-04	1.384 51e-06	0.000 00e-00	0.000 00e-00	3.625 96e-03
f_6	-5.760 11e+03	-1.052 95e+04	-1.174 04e+04	-1.256 94e+04	-6.818 47e+03
f_7	9.990 94e+01	2.139 91e+00	1.293 44e+01	0.000 00e-00	3.521 49e+01
f_8	3.716 54e-03	3.589 39e-07	6.794 56e-14	3.996 80e-15	9.390 76e-01
f_9	1.024 21e-02	7.471 39e-03	0.000 00e-00	0.000 00e-00	1.374 60e-02

表3 各算法实验结果对比 ($D=100$)Table 3 Comparison of experimental results of different algorithms ($D=100$)

函数	ABC	NABC	NSABC	MSDCABC	PSO
f_1	6.156 86e-02	7.202 85e-72	1.006 32e-53	2.634 61e-84	4.145 36e-02
f_2	9.948 68e-03	4.245 68e-06	1.683 07e-12	3.831 17e-13	3.346 67e-01
f_3	3.112 22e+04	5.933 16e-01	1.426 31e-04	4.716 65e-09	2.141 33e-00
f_4	9.287 29e+04	2.554 08e+02	2.396 40e+00	7.694 74e-01	3.253 46e+04
f_5	4.640 78e-00	1.174 70e-02	1.201 09e-20	4.638 56e-29	4.267 78e+01
f_6	-1.000 16e+04	-1.271 48e+04	-2.912 11e+04	-3.437 47e+04	-1.138 37e-04
f_7	2.430 26e+02	1.224 50e+02	1.552 84e+02	4.021 03e+01	1.345 45e+02
f_8	8.840 37e-01	6.626 15e-04	5.319 10e-06	7.936 02e-09	2.284 58e-00
f_9	6.106 40e+01	8.329 16e-02	7.396 04e-06	0.000 00e-00	5.132 45e+01

4 结束语

针对人工蜂群算法开发能力差,探索和开发之间存在不平衡的缺点,本文提出了基于多策略的动态分群人工蜂群算法(MSDCABC)。算法通过适应度排序和随机分组策略把种群分为多个子群,充分利用种群中个体的有用信息,能够同时搜索不同的区域,保持了种群的多样性;在算法迭代期间结合动态子群策略,实现了子群间的信息交流,加强了算法的开发能力,有效的避免陷入局部最优;同时针对不同种群设计了不同特性的搜索策略,有效解决了探索和开发之间存在不平衡的问题。仿真实验结果表明,与其他改进算法对比,本文提出的改进算法在收敛精度和收敛速度上都具有明显优势,且在整个迭代过程中没有发生陷入局部最优的情况。综上所述,MSDCABC算法是一种有效可靠的优化算法。在以后工作,拟开展将所提算法应用于出水氨氮软测量方法的研究中,进一步验证算法在实际优化问题中的适用性。

参考文献

- [1] KARABOGA D. An idea based on honey bee swarm for numerical optimization[R]. Kayseri: Erciyes University, 2005.
- [2] 宋晓宇,肖以简,赵明,等. 子种群规模可变的多种群人工蜂群算法[J]. 计算机应用研究, 2021, 38(6): 1704-1709.
- [3] 李田来,刘方爱,王新华. 基于分治策略的改进人工蜂群算法[J]. 控制与决策, 2015, 30(2): 316-321.
- [4] ZENG T, WANG W J, WANG H, et al. Artificial bee colony based on adaptive search strategy and random grouping mechanism [J]. Expert Systems with Applications, 2022, 192: 116332.
- [5] WANG H, WANG W J, ZHOU X Y, et al. Artificial bee colony based on adaptive search strategy and random grouping mechanism [J]. Complex & Intelligent Systems, 2021, 7: 1139-1152.
- [6] DJABALLAH C B, NOUIBAT W. A new multi-population artificial bee algorithm based on global and local optima for numerical optimization[J]. Cluster Computing, 2022, 25: 2037-2059.
- [7] ZHU G P, S KWONG S. Gbest-guided artificial bee colony algorithm for numerical function optimization [J]. Applied Mathematics and Computation, 2010, 217(7): 3166-3173.
- [8] XIANG Y, PENG Y, ZHONG Y. A particle swarm inspired multi-elitist artificial bee colony algorithm for real-parameter optimization [J]. Computational Optimization & Applications, 2014, 57: 493-516.

- [9] ZHOU X, WU Z, DENG C, et al. An artificial swarm algorithm for neighborhood search[J]. *Journal of Central South University (Science and Technology)*, 2015, 46(2): 534-547.
- [10] PENG H, DENG C S, WU Z J. Best neighbor-guided artificial bee colony algorithm for continuous optimization problems[J]. *Soft Computing*, 2019, 23: 8723-8740.
- [11] WANG H, WU Z J, RAHNAMAYAN S, et al. Multi-strategy ensemble artificial bee colony algorithm [J]. *Information Sciences*, 2014, 279: 587-603.
- [12] CAN Y, SHI H. An adaptive multi-strategy artificial bee colony algorithm for integrated process planning and scheduling[J]. *IEEE Access*, 2021, 9: 65622-65637.
- [13] CHEN X, WEI X, YANG G X, et al. Fireworks explosion based artificial bee colony for numerical optimization[J]. *Knowledge-Based Systems*, 2020, 188: 105002.
- [14] KIRAN M S, HAKLI H, GUNDUZ M, et al. Artificial bee colony algorithm with variable search strategy for continuous optimization[J]. *Information Sciences*, 2015, 300: 140-157.
- [15] SONG X Y, ZHAO M, YAN Q F, et al. A high-efficiency adaptive artificial bee colony algorithm using two strategies for continuous optimization [J]. *Swarm and Evolutionary Computation*, 2019, 50: 100549.
- [16] XING S Y, SONG X Y, ZHAO M. A multi-strategy fusion artificial bee colony algorithm with small population[J]. *Expert Systems with Applications*, 2020, 142: 112921.
- [17] YIN Y L, XIONG X F, GUO Z L. Rosenbrock artificial bee colony algorithm with directed information[J]. *Journal of Jiangxi University of Science and Technology*, 2015, 36(5): 98-104.
- [18] SU H, ZHAO D, YU F H, et al. Horizontal and vertical search artificial bee colony for image segmentation of COVID-19 X-ray images[J]. *Computers in Biology and Medicine*, 2022, 142: 105181.
- [19] KENNEDY J, EBERHART R. Particle swarm optimization [C]// *Proceedings of IEEE ICNN'95-International Conference on Neural Networks*. Piscataway, NJ:IEEE, 1995: 1942-1948.
- [20] WANG Hui, WANG Wenjun, XIAO Songyi, et al. Improving artificial bee colony algorithm using a new neighborhood selection mechanism[J]. *Information Sciences*, 2020, 527: 227-240.