

基于状态转移和模糊思考的迁徙优化算法

钟大鉴 冯 翔 虞慧群

(华东理工大学信息科学与工程学院 上海 200237)

摘 要 基于现有的动物迁徙算法(AMO),提出基于状态转移和模糊思考的迁徙优化算法(SMO)来解决全局优化问题。SMO 算法中引入了状态模型和模糊对立模型。首先,状态模型中使用两种状态(分散状态和集中状态)来描述种群分布。在分散状态下,群体随机分布于解空间中,因此,使用概率决策的方式探索解空间,这个过程属于空间探索;随着个体之间的相互学习,个体之间的差异已经很小,群体进入集中状态,此时使用基于步长的搜索策略来调节个体位置,这个过程属于局部勘探。因此,将二者结合可以平衡空间探索和局部勘探功能。其次,算法使用了模糊对立模型,充分利用个体的模糊对立位置,增加了群体的多样性,提高了算法的收敛精度。然后,从理论上证明了该算法的收敛性,并且使用 12 个基准测试函数来验证算法的性能。最后,将该算法与其他优化算法进行比较,实验结果验证了该算法在优化问题上的有效性。

关键词 状态模型,模糊对立模型,迁徙,优化算法

中图分类号 TP301.6 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2019.01.017

Migration Optimization Algorithm Based on State Transition and Fuzzy Thinking

ZHONG Da-jian FENG Xiang YU Hui-qun

(Department of Computer Science and Engineering, East China University of Science and Technology, Shanghai 200237, China)

Abstract Inspired by the existing animal migration optimization algorithm (AMO), a novel migration optimization algorithm based on state transition and fuzzy thinking (SMO) was proposed for solving global optimization problems. In the proposed algorithm, the state model and fuzzy opposite model are constructed. Firstly, the state model describes the distribution of the whole group with two states; the dispersed state and the centralized state. In the dispersed state, the whole group is distributed in the solution space randomly and a probabilistic decision-making method is used to search the solution space. It's the process of exploration. As the individuals learning from each other, the differences between individuals become smaller and smaller, and the state of the group changes into the centralized state. Meanwhile, a step based searching strategy is used to find the optimal value. It's the process of exploitation. Therefore, the balance between exploration and exploitation can be obtained by using different searching strategies according to the state of the group. Secondly, the algorithm uses a fuzzy opposite model. It can make full use of the fuzzy opposite position of individuals and increase the diversity of species. Moreover, it can improve the convergence precision of the algorithm. Then, the convergence of the algorithm is proved theoretically, and twelve benchmark functions are used to verify the performance of the proposed algorithm. Finally, the algorithm is compared with three other optimization algorithms. Experimental results attest to the effectiveness of SMO.

Keywords State model, Fuzzy opposite model, Migration, Optimization algorithm

1 引言

在动物行为生态学中,为了适应环境,迁徙成为一种普遍的现象。动物的迁徙过程是一项持久的群体运动,通常具有季节性,其目的是寻找适宜的生存环境,利于自身的生存和发展。动物在迁徙过程中通常会遵循 3 个原则:1)与邻居个体

保持方向一致;2)与邻居个体的距离不能太远;3)防止与周围邻居个体发生碰撞^[1]。

虽然目前关于动物迁徙的算法不多,但是仍然有很多其他优秀的自然演化算法值得借鉴,这些算法受到自然界中不同行为和规则的启发。例如,1993 年,Forrest 受自然界“物竞天择,适者生存”演化方式的启发,提出了遗传基因算法

到稿日期:2018-05-06 返修日期:2018-07-06 本文受国家自然科学基金(61472139,61462073),上海市经信委信息化发展专项资金(201602008)资助。

钟大鉴(1993-),男,硕士,主要研究方向为人工智能;冯翔(1977-),女,博士,教授,博士生导师,CCF 会员,主要研究方向为分布并行计算、人工智能、网络通信,E-mail:xfeng@ecust.edu.cn(通信作者);虞慧群(1967-),男,博士,教授,博士生导师,CCF 会员,主要研究方向为软件工程、可信计算和云计算。

(GA)^[2];1995年,Eberhart等人从鸟群移动中得到启发,提出粒子群(PSO)^[3];2000年,Bonabeau受蚂蚁在移动过程中会留下信息的启发,提出蚁群算法(ACO)^[4];2005年,Karaboga提出蜂群算法(ABC)^[5-6];2008年,Simon根据物种在各个栖息地的迁徙规律,提出了基于生物地理学的优化算法(BBO)^[7];2011年,Zhang模拟生物的免疫系统,提出了人工免疫系统(AIS)^[8];2013年,Li根据动物迁徙规律提出了动物迁徙算法(AMO)^[1];同年,Feng根据蚊子的目标追踪能力,提出了蚊子追踪算法(MHSA)^[9];2014年,Zhang受植物根系生长的启发,提出了根生算法(RGA)^[10];2015年,Qiu等人将遗传算法应用于实际问题^[11],并得到了很好的实验效果;2015年,Chen等人基于PSO算法提出了社会群学习粒子群算法(SL-PSO)来解决大规模问题^[12];2016年,Cheng等人提出了基于基准向量的多目标优化算法^[13]。空间探索和局部勘探是优化算法的两大重要模块^[14],通过构建算法模型使算法在初期具有良好的收敛速度,在末期具有良好的收敛精度,是本文的核心内容。

本文的主要贡献如下:

- 1)将群体划分为核心个体与普通个体。核心个体占据有利位置,可以向邻居个体学习;普通个体处于劣势,因此,除了向邻居个体学习外,还需要向核心个体学习。
- 2)引入状态模型,在不同状态下使用不同的搜索策略,有利于群体更快、更好地收敛到最终解。
- 3)引入模糊思考模型,增加了模糊思考的过程,利用个体的模糊对立位置,丰富群体多样性,有利于挖掘解空间中的更优解。
- 4)使用12个基准测试函数验证算法的性能,并将SMO算法与其他3种优化算法进行对比。

2 物理模型

2.1 社会群模型

文献[15]提到了双层优化问题中严密的领导跟随结构,利用不同等级个体之间的相互合作,达到最高收益。如文献[16]中提到狼群中有领导狼的存在,更有利于群体之间的责任分工和相互学习。因此,将整个群体分为核心个体和普通个体。

- 1)核心个体:这类个体在群体中处于领导地位,可以按自己的意志行动,是群体发展的主要方向。
- 2)普通个体:这类个体一方面可以按照自身的决策进行活动,另一方面也会受核心个体的影响,二者结合后形成最终的决策。

2.2 状态模型

本文从文献[17]中得到启发,将群体当前所处的状态分为集中状态和分散状态。

定义1(平行坐标) 在 N 条竖直且等距的平行线下,高维空间中的点可以表示为一条拐点在 N 条平行坐标轴上的折线,各个坐标轴上的位置是对应维度上的值。

定义2(群体状态) 令个体 X_i 各个维度上的坐标分别为 $X_{i1}, X_{i2}, X_{i3}, \dots, X_{iD}$,若 $\forall i, j \in [1, NP], i \neq j, k \in [1, D]$,都有 $|X_{ik} - X_{jk}| \leq m$,则群体处于集中状态;否则群体处于分

散状态。其中, D 为个体的维度; m 为状态因子,用来判断个体之间的紧密程度; NP 为群体规模。

2.3 模糊思考模型

受文献[18]的启发,本文设计了模糊思考模型,以充分挖掘解空间。

定义3(模糊对立数) 假设 x 为区间 $[a, b]$ 之间的实数,即 $x \in [a, b]$, z 为 $[a, b]$ 的中值,即 $z = (a + b) / 2$,则 x 的模糊对立数 \bar{x} 为:

$$\bar{x} = \begin{cases} z + rand * (\bar{x} - z), & \text{if } x \leq z \\ \bar{x} + rand * (z - \bar{x}), & \text{if } x > z \end{cases} \quad (1)$$

其中, $rand$ 是属于 $[0, 1]$ 之间的随机数。

定义4(模糊对立个体) 假设个体 X_i 的坐标为 $X_i = (x_{i1}, x_{i2}, \dots, x_{iD})$,且 $x_{ij} \in [a_k, b_k]$,则 X_i 的模糊对立模糊个体为 $\bar{X}_i = (\bar{x}_{i1}, \bar{x}_{i2}, \dots, \bar{x}_{iD})$ 。其中, D 为个体的维度; \bar{x}_{ij} 是对应的 x_{ij} 的模糊对立数,且 $i \in [1, NP], j \in [1, D]$ 。

3 算法模型

3.1 群体初始化

令群体总数为 NP ,维度为 D ,定义域为 $[a, b]$,使用随机化算法,在定义域内为每个个体的每个维度随机赋值,然后将个体按适应度值从小到大进行排序,最后根据核心个体选择公式 $N_{core} = \lfloor NP * core \rfloor$,选择前 N_{core} 个个体作为核心个体,其余个体视作普通个体。

3.2 群体搜索

每次搜索解空间之前,先要利用定义2判断当前种群的状态,当群体处于分散状态时,使用分散状态下的搜索策略进行空间探索;当群体处于集中状态时,使用集中状态下的搜索策略进行局部探测。群体搜索的整个过程包括3个部分:信息学习、信息筛选和位置决策。

3.2.1 分散状态

信息学习:个体在移动过程中会受到领导者和附近个体的影响,个体信息的拥有量将会影响个体等级,从而采取不同的信息学习过程。核心个体将收集与之形成关联的邻近个体和任意一个普通个体的信息,从而综合考虑下一步的移动方向。核心个体的速度更新方式如式(2)所示:

$$V_{t+1,i}^{core} = \omega \times V_{t,i} + \alpha \times (X_{t,r} - X_{t,i}) + \beta \times (X_{t,n} - X_{t,i}) \quad (2)$$

普通个体将收集与之形成关联的邻近个体和任意一个核心个体的信息,再做出移动决策。普通个体的速度更新方式如式(3)所示:

$$V_{t+1,i}^{ordinary} = \omega \times V_{t,i} + \beta \times (X_{t,l} - X_{t,i}) + \alpha \times (X_{t,c} - X_{t,i}) \quad (3)$$

用式(4)描述个体的位置更新方式:

$$X_{t+1,i} = X_{t,i} + V_{t+1,i} \quad (4)$$

在上述3个公式中, $V_{t+1,i}$ 和 $X_{t+1,i}$ 分别表示个体 i 在 $t+1$ 时刻的速度和位置, $V_{t,i}$ 和 $X_{t,i}$ 分别表示个体 i 在 t 时刻的速度和位置; $X_{t,r}$ 和 $X_{t,l}$ 分别表示 t 时刻,根据适应度值排序后,个体 i 左边和右边的个体; $X_{t,n}$ 和 $X_{t,c}$ 分别表示任意一个普通个体和核心个体的位置; ω 为学习权重; α 和 β 是服从 $[0, 1]$ 的均匀分布函数,且当 $\alpha > \beta$ 时,可以在算法前期加快算法的收敛速度。

信息筛选:个体在发现学习对象之后,需要对信息进行处理。个体自身具有一定的判断能力,将会从已学习信息中选择有利的信息。本文在这一过程进行阈值的随机选择,即设定阈值 γ ,在任意维度上,若 $rand \leq \gamma$,则选择该维度上信息学习后的位置,否则放弃该维度上的信息学习。为了保证信息学习的能力,可以适当调大 γ 的值, γ 越大,越有可能在维度上进行更新。信息筛选过程如式(5)所示:

$$X_{t+1,i}(d) = \begin{cases} X_{t+1,i}(d), & \text{if } rand \leq \gamma \\ X_{t,i}(d), & \text{if } rand > \gamma \end{cases} \quad (5)$$

其中, $rand$ 是属于 $[0,1]$ 之间的随机数, $\gamma \in (0,1)$, $X_{t+1,i}(d)$ 和 $X_{t,i}(d)$ 分别是个体 X_i 第 $t+1$ 次和第 t 次迭代后在维度 d 上的值。

移动位置决策:在进行群体中信息学习及信息筛选过程后,个体将得到一个学习后的新位置 $X_{t+1,i}$,并将对比位置更新前后的适应度。若位置更新后适应度更优,则个体会移动到新的位置;否则,个体放弃这次信息学习后的位置,回退到原先的位置。这一过程的数学模型如式(6)所示:

$$X_{t+1,i} = \begin{cases} X_{t+1,i}, & \text{if } fitness(X_{t+1,i}) \leq fitness(X_{t,i}) \\ X_{t,i}, & \text{otherwise} \end{cases} \quad (6)$$

3.2.2 集中状态

处于集中状态时,个体的信息学习方式和移动位置决策与个体在分散状态下相同。但是,在信息筛选方式上,由于集中状态中的个体在每个维度上都比较接近,因此需要选择另一种策略筛选信息,以加速寻找最优值,如式(7)所示:

$$X_{t+1,i}(d) = \begin{cases} X_{t,i}(d), & \text{if } S_i \leq avg \\ X_{t+1,i}(d), & \text{if } S_i > avg \end{cases} \quad (7)$$

其中, S_i 和 avg 分别表示个体 X_i 与学习对象在对应维度上的差值和在所有维度上的平均差值。

3.3 概率淘汰

在文献[19]中,种群中表现不佳的个体会被淘汰,因此本文使用概率淘汰的方式来保证种群的良性发展。个体被淘汰的概率按照式(8)进行计算:

$$P(X_i) = \frac{fitness(X_i)}{\sum_{i=1}^{NP} fitness(X_i)} \quad (8)$$

其中, $fitness(X_i)$ 为个体 X_i 的适应度值,因此用 $(0,1)$ 之间的随机数 r 进行淘汰个体的选择,若 $\sum_{i=1}^{k-1} P(X_i) < r < \sum_{i=1}^k P(X_i)$,则个体 X_k 将被淘汰。

个体淘汰后,将有新个体加入群体,以保证群体总数不变。个体加入公式如式(9)所示:

$$X_i^{new} = \begin{cases} X_{r1,G} + rand * (X_{best,G} - X_{i,G}), & rand \geq 0.5 \\ low + rand * (up - low), & rand < 0.5 \end{cases} \quad (9)$$

其中, X_{best} 和 $X_{r1,G}$ 分别为群体中的最优个体和任意一个个体,且这两个个体不能为同一个个体; up 和 low 分别为问题解空间的上界和下界。

3.4 SMO 算法

SMO 算法的流程为:1)群体和相关参数初始化;2)判断群体状态;3)根据群体状态,使用对应的搜索策略;4)根据适应度值的变化情况决定个体是否更新位置;5)生成模糊对立

个体,并保留 NP 个最优个体;6)计算个体被淘汰的概率,进行个体淘汰并向种群中加入新个体。

3.5 收敛性分析

引理 1 对任意初始向量 v_0 和右端项 q ,由迭代公式 $v_{k+1} = Mv_k + q$ 产生的向量序列 $\{v_0, v_1, \dots, v_k\}$ 收敛的充分必要条件是谱半径 $\rho(M) < 1$ 。

定理 1 当算法中的参数满足 $w < 1, \alpha + \beta > 0, \alpha < 1, \beta < 1, 2w + 2 > \alpha + \beta$ 时,根据式(2)一式(4)进行速度和位置更新,SMO 算法可以收敛。

下面证明根据式(2)和式(4)进行速度和位置的更新满足定理 1 的要求。

将式(2)代入式(4)可得:

$$X_{t+1,i} = w \times V_{t,i} + \alpha \times X_{t,r} + \beta \times X_{t,n} + (1 - \alpha - \beta) \times X_{t,i} \quad (10)$$

式(2)和式(10)可以转换成矩阵方程:

$$y_{t+1} = A y_t + B x_t + C z_t \quad (11)$$

其中, $A = \begin{bmatrix} w & -(\alpha + \beta) \\ w & 1 - (\alpha + \beta) \end{bmatrix}$, $B = \begin{bmatrix} 0 & \alpha \\ 0 & \alpha \end{bmatrix}$, $C = \begin{bmatrix} 0 & \beta \\ 0 & \beta \end{bmatrix}$, $y_t =$

$$\begin{bmatrix} V_{t,i} \\ X_{t,i} \end{bmatrix}, x_t = \begin{bmatrix} V_{t,r} \\ X_{t,r} \end{bmatrix}, z_t = \begin{bmatrix} V_{t,n} \\ X_{t,n} \end{bmatrix}, y_{t+1} = \begin{bmatrix} V_{t+1,i} \\ X_{t+1,i} \end{bmatrix}.$$

在式(11)中,矩阵 B 的两个特征值分别为 0 和 α 。根据引理 1,当 $|\alpha| < 1$ 时, $\lim_{t \rightarrow \infty} B_t = 0$;同理,当 $|\beta| < 1$ 时, $\lim_{t \rightarrow \infty} C_t = 0$;矩阵 A 的特征值为: $\lambda_{1,2} = 1 + w - \alpha - \beta \pm \sqrt{(\alpha + \beta - w - 1)^2 - 4w}/2$,当 $|\lambda_{1,2}| < 1$ 时,即: $w < 1, \alpha + \beta > 0, 2w + 2 > \alpha + \beta$, $\lim_{t \rightarrow \infty} A_t = 0$ 。

综上所述,当 $w < 1, \alpha + \beta > 0, \alpha < 1, \beta < 1, 2w + 2 > \alpha + \beta$ 时,根据式(2)和式(4)可以使向量序列 $\{y_0, y_1, \dots, y_k\}$ 收敛;同理,根据式(3)和式(4)也可以使该向量序列收敛,定理 1 得证。

4 实验与结果分析

4.1 实验设置

本次实验的运行环境为联想深腾 6800 高性能计算集群,该集群拥有 8 个计算节点和 1 个控制节点,每个节点拥有 24GB 内存和 2 个四核处理器,每个节点都安装了 Red Hat Enterprise Linux 7 系统,实验计算平台为 Matlab R2009b。实验中各类参数设置为:群体规模为 50,迭代次数为 1000;GA 算法的交叉概率为 0.8,变异概率为 0.01;PSO 算法的权重区间为 $[0.2, 0.8]$,移动速度的最大值为个体最大取值范围的 0.1 倍,学习能力 c_1 为 3.47, c_2 为 1.5;AMO 算法的邻居拓扑长度为 5。

4.2 实验结果分析

首先,为了观察算法的收敛精度及其稳定性,本文将 4 种算法在 12 个基准测试函数上各运行 10 次,记录每种算法在每个函数上的平均值(Mean)和标准差(Std),12 个基准测试函数均取自社会蜘蛛算法(SSO)[20]。在 30 和 45 维度下各个函数的测试结果分别如表 1 和表 2 所列。实验结果表明,在 30 维度上,SMO 算法在 $f_3, f_5, f_7, f_8, f_{10}, f_{11}, f_{12}$ 这 7 个函

数上表现最优;在 45 维度上,SMO 算法在 $f_1, f_3, f_4, f_5, f_7, f_8, f_{10}, f_{11}, f_{12}$ 这 9 个函数上表现最优,说明 SMO 算法在处理较高维问题上更有优势;为了观察 SMO 算法的收敛性能,

将 4 种算法分别运行于 f_3, f_5, f_7, f_8 这 4 个基准测试函数上,实验结果如图 1 所示。实验表明,SMO 算法在初期具有更快的收敛速度,在末期具有更佳的收敛精度。

表 1 在 30 维度下 GA,PSO,AMO,SMO 在 12 个基准函数上的结果对比

Table 1 Comparison results of GA,PSO,AMO,and SMO on 12 benchmark functions in 30D

Function	Name	GA(Mean±Std)	PSO(Mean±Std)	AMO(Mean±Std)	SMO(Mean±Std)
f_1	Shpere	2.29E-01±1.57E-01	2.62E-02±2.20E-02	1.46E-17±3.49E-17	6.75E-09±2.13E-08
f_2	SumSquares	3.02E-02±1.32E-02	2.20E-02±2.44E-02	5.25E-10±1.30E-09	5.55E-05±9.86E-05
f_3	Rosenbrock	1.76E+02±6.13E+01	4.48E+01±2.54E+01	9.13E+01±1.19E+02	2.11E+01±1.08E+01
f_4	Schwefel 2.22	9.75E-02±3.39E-02	2.10E+01±3.78E+01	8.55E-05±1.93E-04	5.25E-02±1.49E-01
f_5	Rastrigin	8.17E-01±5.37E-01	1.42E+02±3.33E+01	4.53E+01±6.98E+00	8.68E-04±2.19E-03
f_6	Schwefel	-1.24E+04±6.38E+01	-7.63E+03±1.43E+03	-5.09E+03±5.96E+02	-4.96E+03±5.04E+02
f_7	Ackley	1.09E-01±4.91E-02	2.90E+00±6.55E-01	4.24E+00±9.80E-01	7.33E-05±2.29E-04
f_8	Griewank	2.75E-01±8.83E-02	2.09E+01±2.06E-01	2.50E-02±2.90E-02	8.17E-05±2.21E-04
f_9	F4	1.07E+04±7.00E-02	1.02E+04±2.48E+02	1.13E+04±1.79E+02	1.38E+04±2.82E+02
f_{10}	Quartic	3.29E-02±2.07E-02	3.95E-01±3.01E-01	1.99E-01±9.29E-02	1.02E-04±1.51E-04
f_{11}	schwefel 1.2	1.22E+03±8.32E+02	8.79E+04±9.26E+04	6.15E+02±4.74E+02	1.40E+02±2.96E+02
f_{12}	step	1.64E+02±1.59E+02	3.66E+02±1.16E+02	0.00E+00±0.00E+00	0.00E+00±0.00E+00

表 2 在 45 维度下 GA,PSO,AMO,SMO 在 12 个基准函数上的结果对比

Table 2 Comparison results of GA,PSO,AMO,and SMO on 12 benchmark functions in 45D

Function	Name	GA(Mean±Std)	PSO(Mean±Std)	AMO(Mean±Std)	SMO(Mean±Std)
f_1	Shpere	6.41E-01±2.53E-01	5.64E-01±1.88E-01	4.34E-06±1.30E-05	6.54E-07±1.35E-04
f_2	SumSquares	9.86E-02±3.86E-02	2.04E+00±1.16E+00	1.63E-06±3.37E-06	3.02E-06±7.16E-04
f_3	Rosenbrock	2.36E+02±5.53E+01	1.25E+02±4.86E+01	1.26E+02±1.36E+02	33.08E+01±2.08E+01
f_4	Schwefel 2.22	2.18E-01±4.84E-02	3.50E+01±4.66E+01	1.77E-02±2.38E-02	2.98E-05±4.91E-05
f_5	Rastrigin	1.83E+00±1.10E+00	3.10E+02±7.76E+01	8.57E+01±9.69E+00	4.71E-05±8.90E-05
f_6	Schwefel	-1.85E+04±7.11E+01	-9.69E+03±7.83E+02	-6.94E+03±8.63E+02	-6.12E+03±1.94E+03
f_7	Ackley	1.87E-01±4.80E-02	7.17E+00±5.98E+00	7.38E+00±1.28E+00	1.17E-04±1.98E-04
f_8	Griewank	5.23E-01±2.22E-01	2.02E+01±2.10E-01	2.55E-01±4.14E-01	2.07E-06±5.59E-06
f_9	F4	1.60E+04±1.34E+00	1.66E+04±2.08E+02	1.71E+04±1.55E+02	2.59E+04±2.99E+02
f_{10}	Quartic	4.40E-02±2.09E-02	8.73E-01±3.09E-01	8.19E-01±3.24E-01	1.91E-04±3.14E-04
f_{11}	schwefel 1.2	2.21E+03±1.12E+03	1.08E+05±7.71E+04	3.12E+03±9.80E+02	2.01E+02±3.12E+02
f_{12}	step	5.63E+02±4.89E+02	1.20E+03±3.52E+02	0.00E+00±0.00E+00	0.00E+00±0.00E+00

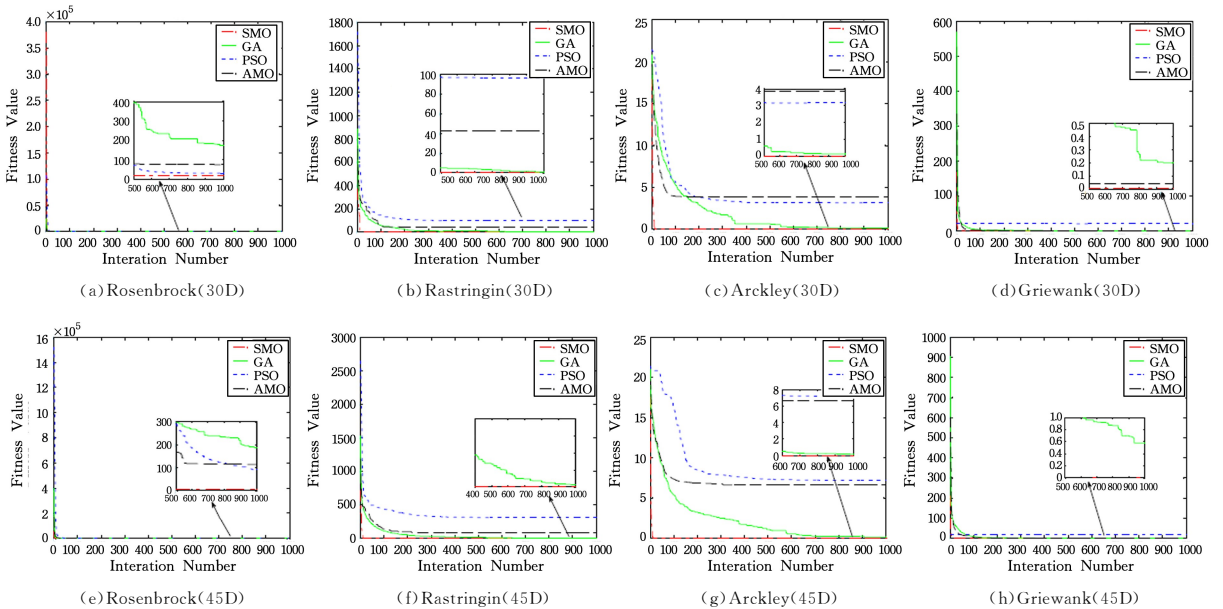


图 1 SMO,GA,PSO,AMO 算法的演化曲线

Fig.1 Evolution curves of SMO,GA,PSO and AMO

为了更加直观地观察不同算法在各个函数上的性能,本文使用 Friedman 测试来比较算法性能。从图 2 中可以看出,SMO 算法在 $f_3, f_5, f_7, f_8, f_{10}, f_{11}, f_{12}$ 上均优于其他算法;在

f_1, f_2 和 f_4 这三个函数上,SMO 算法的 Friedman 排名在第一和第二之间波动;在 f_6 和 f_9 上,SMO 算法的表现不如其他算法,但由表 1 和表 2 可知,SMO 算法仍可以找到一个可

以接受的解。




图2 4种算法在12个基准测试函数上的Friedman排名
Fig.2 Friedman ranks of four algorithms on 12 functions

结束语 本文提出了基于状态转移和模糊对立的迁徙优化算法,主要介绍了状态模型、模糊对立模型和一种新的搜索策略。其中,状态模型利用平行坐标计算群体之间的紧密程度,判断群体当前所处的状态,从而执行不同的搜索策略;模糊对立模型通过计算个体的模糊对立位置,增加群体多样性,挖掘空间中的更优解;搜索策略可以根据种群所处的状态特点,使算法更快、更好地收敛。最后,实验测试了4种优化算法在12个基准测试函数上的性能,结果表明,SMO算法在这4种优化算法中综合排名最高。

算法所表现出来的良好性能,可能得益于以下两点:1)合理地将群体分类为核心个体与普通个体,避免决策只集中于一个最优个体;2)利用状态模型,在不同状态下使用不同的搜索策略,可以平衡空间探索和局部勘探功能。

本文工作还处于初步研究阶段,目前算法虽然已经取得了不错的效果,但是还存在不足之处,未来将针对SMO算法的物理模型和算法模型进行改进,以进一步提高算法性能。

参考文献

- [1] LI X,ZHANG J,YIN M. Animal migration optimization: an optimization algorithm inspired by animal migration behavior[J]. Neural Computing and Applications,2014,24(7):1867-1877.
- [2] FORREST S. Genetic Algorithms: Principles of Natural Selection Applied to Computation[J]. Science,1993,261(5123):872-878.
- [3] KENNEDY J,EBERHART R. Particle swarm optimization [C]// IEEE International Conference on Neural Networks, 1995. Proceedings. IEEE Xplore,1995:1942-1948.
- [4] BONABEAU E,DORIGO M,THERAULAZ G. Inspiration for Optimization from Social Insect Behavior[J]. Nature,2000,406(6791):39-42.
- [5] KARABOGA D,BASTURK B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm [J]. Journal of Global Optimization,2007,39(3):459-471.
- [6] KARABOGA D,BASTURK B. On the performance of artificial bee colony (ABC) algorithm[J]. Appl Soft Comput,2008,8(1):687-697.
- [7] SIMON D. Biogeography-Based Optimization[J]. IEEE Transactions on Evolutionary Computation,2009,12(6):702-713.
- [8] ZHANG Z,QIAN S. Artificial immune system in dynamic environments solving time-varying non-linear constrained multi-objective problems[J]. Soft Computing,2011,15(7):1333-1349.
- [9] FENG X,LAU F C M,YU H. A novel bio-inspired approach based on the behavior of mosquitoes [J]. Information Sciences An International Journal,2013,233(2):87-108.
- [10] ZHANG H,ZHU Y,CHEN H. Root growth model: a novel approach to numerical function optimization and simulation of plant root system[J]. Soft Computing,2014,18(3):521-537.
- [11] QIU M,MING Z,LI J,et al. Phase-Change Memory Optimization for Green Cloud with Genetic Algorithm[J]. IEEE Transactions on Computers,2015,64(12):3528-3540.
- [12] CHENG R,JIN Y,OLHOFER M,et al. A Reference Vector Guided Evolutionary Algorithm for Many-Objective Optimization [J]. IEEE Transactions on Evolutionary Computation, 2016,20(5):773-791.
- [13] CHENG R,JIN Y. A social learning particle swarm optimization algorithm for scalable optimization [J]. Information Sciences, 2015,291(6):43-60.
- [14] TAN K C,CHIAM S C,MAMUN A A,et al. Balancing exploration and exploitation with adaptive variation for evolutionary multi-objective optimization [J]. European Journal of Operational Research,2009,197(2):701-713.
- [15] SINHA A,MALO P,DEB K,et al. Solving Bilevel Multicriterion Optimization Problems With Lower Level Decision Uncertainty [J]. IEEE Transactions on Evolutionary Computation, 2016,20(2):199-217.
- [16] LIU C Y,YAN X H,WU H. The Wolf Colony Algorithm and Its Application [J]. Chinese Journal of Electronics,2011,20(2):212-216.
- [17] FENG X,WANG Y,YU H,et al. A Novel Intelligence Algorithm Based on the Social Group Optimization Behaviors [J]. IEEE Transactions on Systems Man & Cybernetics Systems, 2017,48(1):65-76.
- [18] WANG B. A novel artificial bee colony algorithm based on modified search strategy and generalized opposition-based learning [J]. Journal of Intelligent & Fuzzy Systems,2015,28(3):1023-1037.
- [19] TRUJILLO L,MUÑOZ L,GALVÓN-LÓPEZ E,et al. neat, Genetic Programming: Controlling bloat naturally [J]. Information Sciences,2016,10(333):21-43.
- [20] CUEVAS E,CORTÉS M A D,NAVARRO D A O. A Swarm Global Optimization Algorithm Inspired in the Behavior of the Social-Spider [J]. Expert Systems with Applications,2013,40(16):6374-6384.