

一种基于人工蜂群的高维非线性优化算法

拓守恒

(陕西理工学院 数学与计算机科学学院, 陕西 汉中 723000)

摘 要: 针对传统优化算法在求解高维非线性优化问题时, 存在收敛速率慢和求解精度不高等问题, 提出一种改进的人工蜂群优化算法。正交试验设计算法被用于初始化蜂群和侦察蜂探索新蜜源。采蜜蜂利用高斯分布估计优化算法在蜜源附近搜索, 跟随蜂采用自适应差分算法进行搜索。最后, 通过 4 个标准的高维 Benchmark 函数测试表明, 本文算法在收敛速度、求解精度和稳定性方面有一定优势。

关键词: 人工蜂群优化算法; 高维非线性优化问题; 高斯分布估计算法; 正交试验设计算法

中图分类号: TP18

文献标识码: A

文章编号: 1000-7180(2012)07-0042-05

A New High-Dimensional Nonlinear Optimization Algorithm Based on Artificial Bee Colony

TUO Shou-heng

(School of Mathematics and Computer Science, Shaanxi University of Technology, Hanzhong 723000, China)

Abstract: About convergence rate and solution precision are not high in high-dimensional Nonlinear Optimization Problem (NOP), an improved Artificial Bee Colony (ABC) optimization algorithm is proposed in this paper. Firstly, the orthogonal experimental design algorithm was used to generate initial population and discover a new food source for the scout; Secondly, employed bees uses Gaussian Distribution Estimate Algorithm (GDEA) to search, according to fitness value, onlooker bees select one employed bees and search new nectar source in an self-adaptive differential search algorithm. At last this algorithm is tested on 4 standard benchmark functions, and the experimental results show this algorithm has some advantages in convergence velocity, solution precision, and stabilization.

Key words: artificial bee colony; high-dimensional nonlinear optimization problem; Gaussian estimation of distribution algorithm; orthogonal experimental design

1 引言

高维非线性问题的最优化求解在科学计算、工程设计与规划和资源优化配置等领域应用非常广泛, 而生物群体智能优化算法以对其优化问题的数学模型复杂度要求较低、优化过程与初始值无关, 搜索速度快等优势, 成为学术界的研究热点, 典型算法有遗传算法 GA、微粒子群算法 PSO、模拟退火算法

SA 和差分进化算法 DE 等。对于高维优化问题, 文献[1]提出了一种基于多进化模式协作的高维函数差分进化算法, 作者在文献[2]中利用膜计算求解了高维非线性优化问题, 在文献[3]中提出一种求解高维多模优化问题的正交小生境自适应差分演化算法, 都取得了很好的效果, 本文针对高维非线性优化问题, 提出一种基于高斯分布估计的人工蜂群算法。

收稿日期: 2011-12-11; 修回日期: 2012-01-12

基金项目: 国家自然科学基金项目(81160183); 国家“八六三”计划项目(2008AA01A303); 陕西理工学院“汉水文化”省级重点学科课题(SLGH1226)

2 关键技术

2.1 人工蜂群优化算法

人工蜂群算法(artificial bee colony algorithm; ABC)是 D. Karaboga 提出的一种模仿蜜蜂觅食的仿生智能优化算法^[4],是集群智能思想的一个具体应用,它的主要特点是不需要了解问题的特殊信息,只需要对问题进行优劣的比较,通过各人工蜂个体的局部寻优行为,最终在群体中使全局最优值突现出来,有着较快的收敛速度.传统生物智能优化算法(遗传算法、免疫克隆、粒子群等算法)相比,ABC 算法采用实数编码,易于实现,控制参数少,在解决高维复杂问题方面有很好的应用前景.

ABC 算法将蜂群分为 3 组:采蜜蜂群(employed bees),跟随蜂群(onlooker bees)和侦察蜂(scout bees).

(1) 采蜜蜂与一个正在采蜜的蜜源(food source)对应,记录蜜源的相关信息,通过摇摆舞与其他蜜蜂分享这些信息.

(2) 跟随蜂在跳舞区等待分享采蜜蜂带来的蜜源信息.

(3) 侦察蜂负责探索新的蜜源.

由于传统的 ABC 算法收敛速度较慢,在求解高维复杂问题时难以快速获得高精度解.本文将高斯分布估计优化算法引入到采蜜蜂的搜索中,加快搜索速度,提高解的精度.

2.2 正交试验设计算法

正交试验设计(Orthogonal experimental design: OED)^[5]是研究多因素多水平的又一种设计方法,它是根据正交性从全面试验中挑选出部分有代表性的点进行试验,这些有代表性的点具备了“均匀分散,齐整可比”的特点,正交试验设计是分式析因设计的主要方法.是一种高效率、快速、经济的实验设计方法.文献^[5]对正交表设计算法进行了详细的描述.

2.3 分布估计算法

分布估计算法(Estimation of Distribution Algorithms: EDA)^[6]是一种全新的进化模式,利用概率模型的学习和采样.EDA 通过一个概率模型描述候选解在空间的分布,采用统计学习的手段从宏观上建立一个描述解分布的概率模型,然后对概率模型进行随机采样产生新的种群,如此反复进行,实现种群的进化,直到终止条件.

根据概率模型的复杂程度以及不同的采样方法,分布式估计算法可以归纳为两个主要步骤:

(1) 构建描述解空间的概率模型.通过对种群的评估,选择优秀的个体集合,然后采样统计学习等手段构造一个描述当前解集的概率模型

(2) 由概率模型随机采样产生新的种群.

高斯分布估计算法是实数变量无关分布估计算法^[7-8],它采用高斯分布作为描述连续解空间的概率模型,具有很强的探索能力,求解精度高.

2.4 基于高斯分布估计的采蜜蜂搜索算法

高斯分布估计算法在对高维复杂优化问题时能够有效的降低时间复杂度,但容易陷入局部搜索.在人工蜂群算法中采蜜蜂主要是在蜜源附近进行搜索,为了有效的提高搜索速度,本文中采蜜蜂使用高斯分布估计算法进行局部搜索.

改进后的采蜜蜂高斯分布估计搜索算法的具体描述如下:

设某一采蜜蜂(蜜源) $e=(e_1, e_2, \dots, e_D)$,跟随采蜜蜂 e 采蜜的跟随蜂群为: $X_e=(x_1, x_2, \dots, x_{N_e})'$, 其中 $x_j=(x_{j1}, x_{j2}, \dots, x_{jD})$, $j=1, 2, \dots, ne$; ne 是选择跟随蜜源 e 的跟随蜂的数量, D 是搜索空间的维度.算法描述如下:

算法 1 基于高斯分布估计的采蜜蜂搜索算法

$t = 1$;

For $j = 1$ to D

$$\begin{cases} u_j^t = \frac{1}{ne+1} \left(\sum_{i=1}^{ne} x_{ij} + e_j \right) \\ \sigma_j^t = \sqrt{\frac{\sum_{i=1}^{ne} (x_{ij} - u_j^t)^2 + (e_j - u_j^t)^2}{ne+1}} \end{cases} \quad (1)$$

End for

While ($t < T$)

For $i = 1$ to nc (nc 是采蜜蜂群蜜蜂数量)

For $j = 1$ to D

$$r_n = \sqrt{-2 \ln r_1} \sin(2\pi r_2)$$

% r_1, r_2 为 $[0, 1]$ 之间的随机数

$$v_j = r_n \sigma_j^t + u_j^t$$

Next j

IF $fitness(v) > fitness(e)$ Then $e = v$

Next i

For $j = 1$ to D

$$\begin{cases} u_j^{t+1} = \alpha u_j^t + (1 - \alpha)(e_j + x_j^{\text{best}} - x_j^{\text{worst}}) \\ \sigma_j^{t+1} = \\ \beta_j^{t+1} + (1 - \beta) \sqrt{\frac{\sum_{i=1}^{ne} (x_{ij} - u_j^t)^2 + (e_j - u_j^t)^2}{ne + 1}} \end{cases}$$

Next j
 $t = t + 1$
End While

其中 $\alpha \in (0, 1)$, $\beta \in (0, 1)$ 为学习因子, x_j^{best} 和 x_j^{worst} 分别表示跟随蜂群中最优个体、最差个体所对应的 x_j 值。

2.5 面向蜜源的跟随蜂自适应差异搜索算法

跟随蜂按照采蜜蜂的适应值的大小选择一个采蜜蜂,并在其蜜源领域内采用差异算法搜索新的蜜源。

(1) 为了避免蜂群过早陷入局部搜索,本文使用一种对初始采蜜点不是非常敏感的、鲁棒性和稳定性较好的 Boltzmann 选择机制。

跟随蜂选择食物源的选择概率为 P_i :

$$P_i = \frac{\exp\left[\frac{\text{fitness}(e_i)}{T}\right]}{\sum_{j=1}^N \exp\left[\frac{\text{fitness}(e_j)}{T}\right]} \quad (2)$$

$\text{fitness}(e_i) = \frac{1}{f(e_i)}$ 是采蜜蜂 e_i 的适应度。

(2) 跟随蜂按照选择概率 P_i 选择采蜜蜂 e_i (蜜源)后,采蜜蜂 e_i 的跟随蜂集合为 X_a , 跟随蜂个数为 ne 。

设跟随蜂 x_j 跟随采蜜蜂 e_i , 则 x_j 在第 t 代按照下列算法进行搜索:

算法 2 跟随蜂差分搜索算法

IF $ne \geq 3$ Then

Get x_{r1} and x_{r2} from X_a ($r_1 \neq r_2 \neq j$)

%% 随机从集合 X_a 中选取 2 个不同于 x_j 的跟随蜂 x_{r1}, x_{r2}

$v_j' = x_j^t + \lambda_j [F_{c1}(e_i^t - x_j^t) + F_{c2}(x_{r1}^t - x_{r2}^t)]$

ELSE

$v_j' = x_j^t + \lambda_j F_{c1}(e_i^t - x_j^t)$

EndIF

$x_j^{t+1} = \begin{cases} v_j', & v_j' > x_j^t \\ x_j^t, & \text{others} \end{cases}$

式中, F_{c1} 、 F_{c2} 是缩放因子, $\lambda_j = \begin{cases} 1, \text{rand}(0, 1) \geq op \\ 0, \text{rand}(0, 1) < op \end{cases}$, $op = e^{-\frac{(u-0.5)^2}{2s^2}}$, $s = 1 - t/T$, $u \in [0.8, 1.5]$, $\delta \in [0.7,$

2]. op 表示跟随蜂 x 在第 t 代时的被更新的概率, 更新概率随着进化代数的增加逐步递减。

3 基于正交试验设计与高斯分布估计算法改进的人工蜂群算法模型

算法 3 基于高斯分布估计的人工蜂群搜索算法

假设蜂群 NP 蜜蜂总数为 n , 采蜜蜂群 Nc 中蜜蜂数量为 nc , 跟随蜂群 Nb 规模为 nb , 搜索空间 $S \subseteq R^D$ 的维度为 D 。

(1) 设置初始参数: 蜂群规模、学习因子 α 、 β , 缩放因子 F_{c1} 、 F_{c2} 、最大进化代数, 函数最高评价次数等。

(2) 采用正交试验设计算法在搜索空间 S 中初始化蜂群 NP . 计算蜂群中蜜蜂的适应值。

(3) 根据蜜蜂的适应值划分蜂群 NP 为采蜜蜂群 Nc 和跟随蜂蜂群 Nb . 根据公式(2)计算每只跟随蜂选择的蜜源位置, 划分跟随蜂集合。

(4) 采蜜蜂根据高斯分布估计算法(算法 1)在采蜜蜂附近邻域进行搜索。

(5) 跟随蜂蜂群利用跟随蜂搜索算法(算法 2)进行自适应差分搜索。

(6) 记录的最优蜜源的适应值和具体位置。

(7) 侦察蜂采用下列算法探索新的蜜源:

如果某一采蜜蜂 e_i 的搜索次数达到阈值 Limit 并且仍然没有发现更好的蜜源, 则在搜索空间中按照下面表达式随机产生 2 个个体:

$$X_i = L + \text{rand}(0, 1)(H - L), i = 1, 2$$

其中 $L = (l_1, l_2, \dots, l_D)$, $H = (h_1, h_2, \dots, h_D)$

然后在 X_1 和 X_2 形成的空间 $[\min(X_1, X_2), \max(X_1, X_2)]$ 中用正交表实验设计算法产生 pN (水平组合数) 个新个体, 根据优劣性比较算法从 pN 中选择一个最好个体作为新的蜜源 e_i^{t+1} 。

(8) 通过拥挤裁剪算法对采蜜蜂群和跟随蜂群进行裁剪, 裁剪后随机产生新个体补充到群体中, 使得蜂群规模保持不变。

(9) 如果满足结束条件, 则停止进行搜索并输出可行域内的最优解及位置。否则转向(4)继续搜索。

4 仿真分析

为了评估本文算法的性能, 选取了 4 个复杂高维的多峰值 benchmark 函数 (f_1 : Rastrigin; f_2 : Ackley; f_3 : Griewangk; f_4 : Rosenbrock) 进行测

试,在 4 个函数中 $f_1 \sim f_3$ 属于多峰值函数,存在多个极值点,函数 f_4 被称作变态函数,变量之间具有很强的关联性,最优解是 $(1, 1, \dots, 1)$, 最优函数值为 0, 但该函数在优化时,非常容易收敛于点 $(0, 0, \dots, 0)$. 4 个函数具体表达式如下:

(1) Rastrigin

$$\min f_1(x) = \sum_{i=1}^D [x_i^2 - 10\cos(2\pi x_i) + 10]$$

$$x \in [-5.12, 5.12]_D$$

(2) Ackley

$$\min f_2(x) = 20 + e - 20\exp\left[-0.2\sqrt{\frac{1}{D}\sum_{i=1}^D x_i^2}\right] - \exp\left(\frac{1}{D}\sum_{i=1}^D \cos 2\pi x_i\right), x \in [-30, 30]_D$$

(3) Griewangk

$$\min f_3 = \frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \left(\cos\left(\frac{x_i}{\sqrt{i}}\right)\right) + 1$$

$$-600 \leq x_i \leq 600$$

(4) Rosenbrock

$$\min f_4 = \sum_{i=1}^{D-1} [100(x_i^2 - x_{i+1})^2 + (x_i - 1)^2]$$

$$-5 \leq x_i \leq 10$$

实验测试结果和算法 ABC 进行了比较和分析。

4.1 运行环境与参数设置

在测试中,使用微机硬件环境为华硕笔记本电脑, I3 450CPU, 1GB 内存, 在 MATLAB 2009(a) 软件平台上进行编程实现。

设置种群空间中种群规模 $N=100$, 差分进化算法中缩放因子 $\lambda=0.4$, $F=0.6$; 高斯分布估计算法中学习因子 $\alpha=0.5$, $\beta=0.5$; 在 100 和 200 维时, 设置函数 $f_1 \sim f_3$ 的最大进化代数 $T=1\,000$, 最高评价次数为 300 000 次, 设置函数 f_4 的最大进化代数为 3 000, 最高评价次数为 1 000 000 次, 在 500 维时, 设置最大进化代数为 $T=5\,000$, 函数最高评价次数为 1 500 000 次。

4.2 运行结果与分析

在所有测试函数中, 让程序各自独立运行 20 次, 记录最优值 (Best), 平均值 (Mean), 最差值 (Worst) 和标准差 (Std. Dev), 统计结果如表 1。

由表 1 可以看出, 本文算法对每个函数在进行的 20 独立测试中, 除了 f_4 函数在 500 维时平均最优解的精度不够高外, 其它函数都获得了高精度全局最优解。本文算法和 ABC 的实验结果如表 2 所示。

表 1 本文算法的试验结果

Fun	D	N	Best	Mean	Worst	Std. Dev
f_1	100	100	0.0	0.0	0.0	0.0
	200	100	0.0	0.0	0.0	0.0
	500	100	9.495E-7	5.628E-5	3.0056E-3	0.0015
f_2	100	100	0.0	0.0	0.0	0.0
	200	100	0.0	7.392E-15	1.4915E-7	7.457E-8
	500	100	1.1695E-5	1.521E-4	6.553E-4	6.387E-4
f_3	100	100	0.0	0.0	0.0	0.0
	200	100	2.3315E-15	1.0025E-13	7.465E-12	1.158E-13
	500	100	1.06635E-6	1.5E-6	4.537E-4	2.156E-5
f_4	100	100	0.0176	0.1530	0.4898	0.1856
	200	100	0.73996	2.7647	6.1097	3.2913
	500	100	1.5257	79.0003	116.2634	53.7365

表 2 本文算法和 ABC 的试验结果比较

Fun	D	N	本文算法 Mean	ABC Mean
f_1	100	100	0.0	1.0E-5
	200	100	0.0	1.45
f_2	100	100	0.0	1.2E-7
	200	100	7.392E-15	3.123E-4
f_3	100	100	0.0	1.0E-8
	200	100	1.0025E-13	0.005984
f_4	100	100	0.1530	10.7569
	200	100	2.7647	115.218

从表 2 中可以看出, 对所有函数本文算法在同等条件下都明显优于 ABC。图 1~图 3 分别描述了函数 Griewangk, Rosenbrock 和 Rastrigin 在 200 维时, 本文算法与 ABC 的进化曲线。可以看出, 本文算法不论是收敛速度还是求解精度都优于 ABC 算法,




图 1 函数 Griewangk 在 200 维的进化曲线




图2 函数 Rosebrock 在 200 维的进化曲线




图3 函数 Rastrigin 在 200 维的进化曲线

并且本文算法曲线始终处于下降过程中,没有出现水平曲线,说明算法不会出现早熟现象,始终能够保持种群的多样性与活跃性。

5 结束语

本文提出改进的人工蜂群优化算法. 为了提高算法的搜索全局性并保持种群的多样性,采用正交试验设计算法初始化种群和产生新蜜源. 为了提高

解的精度,采蜜蜂采用高斯分布估计算法进行搜索,为了加速收敛速度,跟随蜂采用了一种改进的差异搜索算法. 仿真实验表明本文算法适用于高维非线性优化问题的处理。

参考文献

- [1] 贺毅朝, 王熙照. 差分演化的收敛性分析与算法改进[J]. 软件学报, 2010, 21(5): 875—885.
- [2] 拓守恒, 邓方安, 周涛. 一种利用膜计算求解高维函数的全局优化算法[J]. 计算机工程与应用, 2011(19): 27—30.
- [3] 拓守恒, 汪文勇. 求解高维多模优化问题的正交小生境自适应差分演化算法[J]. 计算机应用, 2011(4): 1094—1098.
- [4] Basturk B, Karaboga D. An artificial bee colony (ABC) algorithm for numeric function [C]// optimization, IEEE Swarm Intelligence Symposium Indianapolis, Indiana, USA. 2006.
- [5] Leung YW, Wang YP. An orthogonal genetic algorithm with quantization for global numerical optimization [J]. IEEE Trans. On Evolutionary Computation, 2001, 5(1): 41-53.
- [6] Larra Naga P, Lozano J A. Estimation of distribution algorithms—A new tool for evolutionary computation [M]. Boston: Kluwer Academic Publishers, 2002.
- [7] Larra Naga P, Etxeberria R, Lozano J A, et al. Optimization in continuous domains by learning and simulation of Gaussian networks[C]// Proc of the 2000 Genetic and Evolutionary Computation Conf Workshop Program. Las Vegas, 2000: 201-204.
- [8] Sebag M, Ducoulombier A. Extending population-based incremental learning to continuous search spaces [C]// Proc of the 5th Conf on Parallel Problem Solving from Nature—PPSN V. Amsterdam: Springer-Verlag, 1998: 418-427.

作者简介:

拓守恒 男, (1978-), 硕士, 讲师, CCF 会员. 研究方向为智能优化算法、人工智能、陕南水资源优化。