

一种求解高维约束优化问题的人工蜂群算法^{*}

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: 针对求解高维约束优化中算法的收敛速度和解的精度不高的缺点, 提出一种改进的人工蜂群约束优化算法。该算法在初始化种群和侦察蜂探寻新蜜源时采用了正交实验设计方法, 并在采蜜蜂搜索时使用了改进的高斯分布估计, 跟随蜂按照采蜜蜂的适应值大小选择一个采蜜蜂, 在其蜜源领域内采用差异算法搜索新的蜜源; 在处理约束条件时采用自适应优劣解比较方法。最后通过 13 个标准的 Benchmark 测试函数进行仿真实验, 结果表明该算法在处理高维约束优化问题时具有较好的收敛性和稳定性。

关键词: 人工蜂群; 正交实验设计; 高斯分布估计; 约束优化

中图分类号: TP301.6 **文献标志码:** A **文章编号:** 1001-3695(2012)03-0937-04

doi:10.3969/j.issn.1001-3695.2012.03.038

New high-dimensional constrained optimization algorithm based on artificial bee colony

TUO Shou-heng

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

Abstract: About convergence rate and solution precision are not high in high-dimensional constrained optimization problem (COP), this paper proposed an improved ABC optimization algorithm. Firstly, it used the orthogonal experimental design algorithm to generate initial population and discover a new food source for the scout. Secondly, employed bees used Gaussian distribution estimate algorithm (GDEA) to search, according to fitness value, onlooker bees selected one employed bees and search new nectar source in a self-adaptive differential search algorithm. Thirdly, processed constrained condition by self-adaptive fit and unfit quality solution comparison. At last tested this algorithm on 13 standard benchmark functions, and the experimental result show algorithm has some advantages in convergence velocity, solution precision, and stabilization.

Key words: artificial bee colony (ABC); orthogonal experimental design; Gaussian estimation of distribution algorithm; constrained optimization

许多的科学计算和工程优化问题都是高维复杂多模态约束优化问题(如工程设计、结构优化、大规模集成电路设计、投资决策和资源分配处理等)。在实践应用中,怎样在复杂度可接受的情况下获得这些问题的最优解是工程和学术界研究的热点。目前,约束优化问题的求解算法有确定性算法和随机算法。确定性求解算法有可行方向法和广义梯度下降法^[1]。由于确定性求解算法要求优化问题必须为连续和可微的,往往难以应用在实践中。而随机算法通过启发式搜索策略进行智能优化处理,基本能够适用于各种优化问题。目前随机搜索算法在约束优化问题中已取得了非凡的成绩,主要算法有遗传算法(GA)、差分进化算法(DE)和粒子群优化算法(PSO)等。针对约束优化问题,目前常见的约束处理技术有惩罚函数法^[2,3]、多目标优化法^[4,5]等。Joines 等人^[6]首先提出了采用惩罚函数法求解非线性约束优化问题;文献[7,8]提出采用 PSO 算法求解非线性约束优化问题;张慧斌等人^[9]提出一种求解高维约束优化问题的 γ -PSO 算法;彭虎等人^[10]提出了一种基于改进约束自适应方法的动态邻域粒子群算法(IPS0);刘若辰等

人^[11]把约束优化问题中的约束条件当做一个目标函数,从而把约束优化问题转换为有两个目标函数的多目标优化问题进行求解。上述算法在对约束优化问题的处理上基本都取得了不错效果,但对高维约束优化问题,文献[6~8]容易陷入局部搜索,文献[9~11]虽然在收敛性、通用性和稳定性方面有很好的效果,但对约束条件的处理算法非常复杂,增大了算法开销。

1 约束优化问题的数学模型

$$\begin{aligned} \min f(x) \quad & x = (x_1, x_2, \dots, x_D) \in R^D \\ \text{Subject to: } & g_i(x) \leq 0 \quad \text{for } (i = 1, \dots, q) \\ & h_i(x) = 0 \quad \text{for } (i = q + 1, \dots, m) \quad m \geq 0 \end{aligned}$$

其中, $x \in F \subseteq S, S \subseteq R^D$, 定义 F 为可行域, S 为一个 D 维的搜索空间: $L = (l_1, l_2, \dots, l_D), H = (h_1, h_2, \dots, h_D), x \in [L, H]$ 。

2 人工蜂群算法

人工蜂群(ABC)算法是 Karaboga 提出的一种模仿蜜蜂觅食的仿生智能优化算法^[12,13],与遗传、免疫克隆、粒子群等算

收稿日期: 2011-08-09; 修回日期: 2011-09-17 基金项目: 国家“863”高技术研究发展计划资助项目(2008AA01A303); 国家自然科学基金资助项目(81160183); 陕西省教育厅科研基金资助项目(2010JK459); 宁夏自然科学基金资助项目(NZ11105); 宁夏卫生厅科研项目(2011033); 陕西理工学院“汉水文化”省级重点学科资助课题(SLGH1226)

作者简介: 拓守恒(1978-), 男, 宁夏中卫人, 讲师, 硕士, CCF 会员, 主要研究方向为智能优化算法、人工智能、陕西水资源优化等(tuo.sh@163.com)。

法相比,ABC 在每代进化中都进行全局和局部搜索,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 算法将蜂群分为三组:采蜜蜂群、跟随蜂群和侦察蜂群。采蜜蜂与一个正在采蜜的蜜源对应,记录蜜源的相关信息,通过摇摆舞与其他蜜蜂分享信息;跟随蜂在跳舞区等待分享采蜜蜂带来的蜜源信息;侦察蜂探索新的蜜源。

3 关键技术

3.1 正交表实验设计算法

在群体智能优化算法中,由于种群分布的好坏直接影响算法收敛性和求解精度,本文采用正交实验设计算法产生种群。采用正交设计算法能均匀地将种群分布在解空间中,提高种群中个体的多样性,使算法能在全局范围内以较快的速度收敛。正交实验设计(orthogonal experimental design, OED)是由日本著名的统计学家田口玄一提出的研究多因素多水平的一种设计方法。它使用一种规范化的正交表进行实验设计,可以用很少的实验次数取得有代表性的点进行实验,这些有代表性的点具备“均匀分散,齐整可比”的特点。正交实验设计是分式析因设计(fractional factorial designs)的主要方法,是一种高效率、快速、经济的设计方法。将正交实验选择的水平组合列成表格,称为正交表,记为 $L_n(j^i)$ 。其中: L 代表正交表; n 是正交表的行数(实验次数); j 是正交表中的数码(因素的位级数); i 是正交表的例数(实验因素的个数); $N=j^i$ 是全部实验次数(完全因素位级组合数)。

$L=(l_1, l_2, \dots, l_D), H=(h_1, h_2, \dots, h_D), Q=[L, H]$ 为 D 维可行解空间。将可行解 $X=\{(x_1, x_2, \dots, x_D) \mid l_i \leq x_i \leq h_i\}$ 的各个变量当做正交设计的每个因素,假设每个因素有 q 个水平,即把 $[L, H]$ 的每个域量化为 q 个水平,用 β_{ij} 表示第 i 个因素的第 j 个水平。

$$\beta_{ij} = \begin{cases} \min(l_i) & j=1 \\ \min(l_i) + (j-1) \left(\frac{h_i - l_i}{q-1} \right) & 2 \leq j \leq q-1 \\ \max(h_i) & j=q \end{cases} \quad (1)$$

创建具有 D 个因素,每个因素具有 q 个水平的正交表 $L=(b_{ij})_{N \times D}$ 。其中, N 表示水平组合数, D 表示维数。文献[14, 15]对正交表设计算法进行了详细的描述。例如, $L=(1, 1, 0, 1, 6), H=(1, 1, 2, 3, 8)$,构造正交表 $L_9(3^5)$:

$$\beta = \begin{bmatrix} 1 & 1 & 0 & 1 & 6 \\ 1 & 1 & 0 & 2 & 7 \\ 1 & 1 & 0 & 3 & 8 \\ 1 & 1 & 1 & 1 & 7 \\ 1 & 1 & 1 & 2 & 8 \\ 1 & 1 & 1 & 3 & 6 \\ 1 & 1 & 2 & 1 & 8 \\ 1 & 1 & 2 & 2 & 6 \\ 1 & 1 & 3 & 3 & 7 \end{bmatrix}$$

3.2 搜索空间解的优劣性比较算法

在求解约束优化问题时,除了优化算法的搜索能力以外,约束条件的处理也非常关键。在目前的生物群体优化算法中,对于非线性约束优化问题,主要的解决方式有:a)采用罚函数法将约束条件作为惩罚项添加到适应值函数中,将其转换为无

约束优化问题进行求解;b)将约束条件作为一个目标函数,将优化问题转换为多目标优化问题求解。罚函数法的优点是实现容易;缺点是惩罚因子不好确定,难以合理地给出各个约束条件的惩罚因子权重。而多目标法恰恰相反,虽然不需要确定惩罚因子,但增加了算法的设计与实现难度,需要多目标优化策略来解决,增加了算法的计算复杂度。由于 ABC 算法在蜂群寻找蜜源时以优胜劣汰的方式更新蜂群,本文以一种简单易行的方式处理约束条件,即在蜜蜂寻蜜过程中,通过比较蜜蜂新旧采蜜点的优劣性来决定下一步的采蜜位置。新旧采蜜点优劣性的判断准则如下:

a)当两个采蜜点都在可行域 F 中时,选择适应值好的采蜜点作为新的采蜜位置。

b)当一个采蜜点 x_1 在可行域,另一个采蜜点 x_2 不在可行域时,如果可行域的采蜜点 x_1 适应值更好,将其作为新的采蜜位置;如果采蜜点 x_2 的适应值更好,则根据不可行区域采蜜点的可接受概率 sp 进行选择:

$$x_{\text{new}} = \begin{cases} x_1 & r \geq sp(t) \\ x_2 & r < sp(t) \end{cases}$$

其中: $sp(t) = c + 0.5(T-t)/T$ 是当前可接受概率, $c(0 < c < 0.5)$ 是最小可接受概率(本文选取0.2), t 是进化代数, T 是最大进化次数, rand 是(0,1)之间的随机数。

这样做的原因是:在今后起始时,为了扩大搜索区域,保证种群的多样性,需要较大的可接受概率 $sp(t)$ 在不可行域附近进行搜索,但随着进化次数的增加 $sp(t)$ 逐步减小,有利于蜂群向可行域内的最优解收敛。

c)当两个采蜜点 x_1 和 x_2 都在不可行域时,选择违反约束条件程度小的采蜜点作为新的采蜜位置。违反约束条件程度等于个体 x 与所有约束条件的距离之和:

$$Gh(x) = \sum_{i=1}^q \max(g_i(x), 0) + \sum_{j=q+1}^m |h_j(x)| \quad (2)$$

3.3 采蜜蜂高斯分布估计搜索算法

分布估计算法(estimation of distribution algorithms, EDA)通过概率模型来分析变量的关系,并根据当前种群的分布状况来产生下一代种群。EDA的主要步骤有:

a)建立解空间的概率模型。模型对当前种群进行评估并构建优秀个体解集来描述群体的分布概率模型。

b)根据a)构建的概率模型产生下一代种群。

分布估计算法在高维复杂优化问题时能够有效地降低时间复杂度,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,为了有效地提高搜索速度,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 $X_e=(x_1, x_2, \dots, x_{ne})'$ 。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 的跟随蜂数量; D 是搜索空间的维度。算法描述如下:

$$\begin{aligned} & t=1; \\ & \text{for } j=1 \text{ to } D \\ & \quad \left\{ \begin{aligned} & u_j^t = \frac{1}{ne+1} \left(\sum_{i=1}^{ne} x_{ij} + e_j \right) \\ & \sigma_j^t = \sqrt{\frac{1}{ne+1} \left[\sum_{i=1}^{ne} (x_{ij} - u_j^t)^2 + (e_j - u_j^t)^2 \right]} \end{aligned} \right. \end{aligned}$$

```
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
vj = N(ujt, σjt)
next j
if fitness(v) > fitness(e) then e = v
next i
for j = 1 to D
{
ujt+1 = αujt + (1 - α)(ej + xjbest - xjworst)
σjt+1 = βσjt + (1 - β) √(1/(ne+1) [∑i=1ne (xij - ujt)2 + (ej - ujt)2])
}
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。

3.4 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。

a) 采蜜蜂 e_i 被选择概率为

$$P_i = \frac{\text{fitness}(e_i)}{\sum_{j=1}^N \text{fitness}(e_j)} \tag{3}$$

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

b) 应用选择概率选择后,采蜜蜂 e_i 的跟随蜂集合为 X_{ei} , 跟随蜂个数为 ne 。跟随蜂在第 t 代的算法进行搜索:

```
if ne >= 3 then
随机从集合 Xei 中选取两个不同于 xj 的跟随蜂 xr1、xr2
vjt = xjt + λj [ Fc1(eit - xjt) + Fc2(xr1t - xr2t) ]
else
vjt = xjt + λj Fc1(eit - xjt)
```

其中: F_{c1} 、 F_{c2} 是缩放因子; $\lambda_j = \begin{cases} 1, \text{rand}(0,1) \geq op \\ 0, \text{rand}(0,1) < op \end{cases}$, $op = e^{-\frac{(s-u)^2}{2\delta^2}}$, $s = 1 - t/T$, $u \in [0.8, 1.5]$, $\delta \in [0.7, 2]$ 。 op 表示跟随蜂 x 在第 t 代时的更新概率,更新概率随着进化代数的增加逐步递减。当 $u = 1.1$, $\delta = 0.8$ 时,更新曲线如图 1 所示。




图1 更新概率曲线

然后根据优劣性判断准则参数下一代 $x_j^{t+1} = \begin{cases} v_j^t, v_j^t > x_j^t \\ x_j^t, \text{others} \end{cases}$ 。

其中, $v_j^t > x_j^t$ 表示根据优劣性比较算法判断前者优于后者。

4 基于正交实验与高斯分布估计算法改进的人工蜂群算法模型

假设蜂群 NP 中蜜蜂总数为 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 , F 为可行域, $\bar{F}$ 为不可行域, $F \cup \bar{F} = S$ 。

a) 设置初始参数: 蜂群规模、学习因子、最大进化代数、函数最高评价次数等。

b) 采用正交实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。

c) 根据蜜蜂的适应值划分蜂群 NP 为采蜜蜂群 Nc 和跟随蜂群 Nb。按照跟随蜂选择概率式(3)记录每只跟随蜂选择的蜜源(采蜜蜂)位置。

d) 利用高斯分布估计算法(见 3.3 节)在采蜜蜂附近邻域进行搜索。

e) 跟随蜂蜂群采用跟随蜂自适应差异搜索算法来进行搜索。

f) 存储记忆处于可行域的最优蜜源的适应值和具体位置。

g) 侦察蜂探索新的蜜源。如果某一采蜜蜂 e_i 的搜索次数达到阈值 Limit 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两个个体 $X_1 = \{x_{11}, x_{22}, \dots, x_{2D}\}$, $X_2 = \{x_{21}, x_{22}, \dots, x_{2D}\}$, $X = L + \text{rand}(0, 1)(H - L)$, $L = (l_1, l_2, \dots, l_D)$, $H = (h_1, h_2, \dots, h_D)$ 。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 个新个体中选择一个最好个体作为新的蜜源 e_i^{t+1} 。

h) 通过拥挤裁剪算法^[16]对采蜜蜂群和跟随蜂群进行裁剪,并随机产生新个体补充到群体中,使得蜂群规模保持不变。

i) 如果满足结束条件,则停止搜索并输出可行域内的最优解及位置;否则转向 d) 继续搜索。

5 仿真分析

为了评估本文算法的性能,选取了 13 个有条件约束 Benchmark 函数,包括线性、非线性和二次函数(限于篇幅,函数具体表达式请参见文献[8]),实验测试结果分别与标准的蜂群算法(ABC)、差分进化算法(DE)和粒子群优化算法(PSO)进行比较;后面又与取得较好效果的改进算法——基于多目标优化的差分进化约束优化算法(MuMODECOA)^[11]和正交实验设计的约束优化进化算法(COEA/OED)^[4]作了比较和分析。

5.1 运行环境与参数设置

测试的硬件环境为华硕笔记本电脑(i3 450CPU, 1 GB 内存),在 MATLAB 2009a 软件平台上进行编程实现。设置蜂群 NP 规模为 $n = 100$, 采蜜蜂群 Nc 规模 $nc = 20$, 跟随蜂群 Nb 规模 $nb = 80$; 采蜜蜂高斯分布式估计算法中学习因子 $\alpha = 0.6$, $\beta = 0.5$; 跟随蜂自适应差异搜索算法中缩放因子 $F_{c1} = 0.6$, $F_{c2} = 0.4$, $u = 1.1$, $\delta = 0.8$; 侦察蜂利用正交表设计算法产生新个体时,水平组合数设置为 5, 阈值 $\text{Limit} = n \times D/2$, 设置最大进化代数 $T = 5000$, 函数最高评价次数为 300 000 次。

5.2 运行结果与分析

对本文的所有测试函数,让程序各自独立运行 30 次,记录最优解(opt)和最优适应值(best)、平均值(mean)、最差适应值(worst)和标准差(std),统计结果见表 1。通过 30 次的独立运行可以看出,除了函数 g02、g05、g07、g13 以外,本文算法都获得了可行域全局最优解,对所有函数都非常接近全局的最优。

表 2 将 13 个 Benchmark 函数 30 次独立运行获得的最优结果 best 与 PSO 和 DE 算法进行了比较。通过与最优解的误差比较可以看出本文算法对所有 13 个测试函数的最优解都优于 PSO 和 DE 算法。表 3 将 13 个 Benchmark 函数 30 次独立运行的最优平均值 mean 与 COEA/OED 和 MuMODECOA 算法进行了比较。由结果可看出,本文算法除了在函数 g10(误差为 2.284)和 g13(误差为 0.122 796)的平均最优解精度稍差外,其余函数基本都优于或等同于算法 COEA/OED 与 MuMODECOA 的优化效果,整体来说本文算法表现出良好的性能优势。

表 1 本文算法对 13 个 Benchmark 函数测试统计结果

pro	opt	best	mean	worst	std
g01	-15.0	-15.0	-15	-15.0	0.0
g02	0.803619	0.8036	0.80033	0.757797	0.0042
g03	1.000	1.000	1.000	1.000	0.000
g04	-30665.54	-30665.54	-30665.54	-30665.539	0.000
g05	5126.498	5126.484	5126.484	5126.518	53e-4
g06	-6961.814	-6961.814	-6961.814	-6961.814	0.000
g07	24.306	24.307	24.3134	25.317	1.6e-3
g08	0.095825	0.095825	0.095825	0.095825	0.000
g09	680.630	680.63	680.63	680.6471	7.4e-4
g10	7049.25	7049.25	7051.534	7343.323	118.70
g11	0.75	0.75	0.75	0.750	0.000
g12	1.000	1.000	1	1.000	0.000
g13	0.053950	0.05397	0.1767458	0.05425	1.15e-4

表 2 PSO、DE 和本文算法对 13 个测试函数 30 次独立运行的平均最优结果比较

pro	best			opt - best		
	本文算法	PSO	DE	本文算法	PSO	DE
g01	-15	15	-15	0	30	0
g02	0.8036	0.669158	0.472	1.87e-05	0.134461	0.331619
g03	1	0.99393	1	0	0.00607	0
g04	-30665.54	-30665.54	-30665.54	0	0	0
g05	5126.484	5126.484	5126.484	0.014	0.014	0.014
g06	-6961.814	-6161.814	-6954.434	0	800	7.38
g07	24.307	24.370153	24.306	0.001	0.064153	0
g08	0.095825	0.095825	0.095825	0	0	0
g09	680.63	680.63	680.63	0	0	0
g10	7049.25	7049.381	7049.248	0	0.131	0.002
g11	0.75	0.749	0.752	0	0.001	0.002
g12	1	1	1	0	0	0
g13	0.05397	0.085655	0.385	2.5e-05	0.031705	0.33105

表 3 COEA/OED、MuMODECOA 和本文算法对 13 个测试函数 30 次独立运行的平均值、最优解的比较

pro	mean			mean - opt		
	COEA/OED	MuMO-DECOA	本文算法	COEA/OED	MuMODECOA	本文算法
g01	-15	-15	-15	0	0	0
g02	0.8029	0.791021	0.80033	0.000719	0.012598	0.003289
g03	1	1	1	0	0	0
g04	-30665.54	-30665.54	-30665.54	0	0	0
g05	5126.4967	5126.498	5126.484	0.0013	0	0.014
g06	-6961.814	-6961.814	-6961.814	0	0	0
g07	24.306	24.306	24.3134	0	0	0.0074
g08	0.095825	0.095825	0.095825	0	0	0
g09	680.6	680.63	680.63	0.03	0	0
g10	7049.253	7070.424	7051.534	0.003	21.174	2.284
g11	0.9499	0.75	0.75	0.1999	0	0
g12	1	1	1	0	0	0
g13	0.37277	0.0539498	0.1767458	0.31882	2e-07	0.122796

化算法;为了提高搜索算法的全局性并保持种群的多样性,采用正交实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,跟随蜂采用一种改进的差异搜索算法,针对约束优化问题,采用自适应优劣解比较算法进行处理。通过 13 个标准的 Benchmark 测试函数仿真实验表明,本文算法适用于约束优化问题的处理。

参考文献:

[1] 陈翠玲,李明,李略. 一个求解非线性不等式约束优化问题的带有共轭梯度参数的广义梯度投影算法[J]. 应用数学,2011(2):399-406.

[2] HAMIDA S B, SCHOPENHAUER M. ASCHEA: new results using adaptive segregational constraint handling[C]//Proc of Congress on Evolutionary Computation. Piscataway:IEEE Press,2002:884-889.

[3] FARMANI R, WRIGHT J A. Self-adaptive fitness formulation for constrained optimization[J]. IEEE Trans on Evolutionary Computation, 2003,7(5):445-455.

[4] YU J X, YAO Xin, CHOI C, et al. Materialized view selection as constrained evolutionary optimization[J]. IEEE Trans on Systems, Man and Cybernetics, Part C: Application and Reviews, 2003, 33(4):458-467.

[5] 周育人,李元香,王勇,等. Pareto 强度值进化算法求解约束优化问题[J]. 软件学报,2003,14(7):1243-1249.

[6] JOINES J A, HOUCK C R. On the use of nonstationary penalty functions to solve nonlinear constrained optimization problems with gas[C]//Proc of the 1st IEEE Conference on Evolutionary Computation. [S. l.]:IEEE Press,1994:579-585.

[7] HU Xiao-hui, EBERHART R C. Solving constrained nonlinear optimization problems with particle swarm optimization[C]//Proc of the 6th World Multi Conference on Systemics, Cybernetics and Informatics. 2002:203-206.

[8] ZAVALA A E M, AGUIRRE A H, DIHARCE E R V. Constrained optimization via particle evolutionary swarm optimization algorithm[C]//Proc of Conference on Genetic and Evolutionary Computation. New York:ACM Press,2005:209-216.

[9] 张慧斌,王鸿斌,邸东泉. 一种求解高维约束优化问题的 γ -PSO 算法[J]. 计算机工程与应用,2011.

[10] 彭虎,田俊峰,邓长寿. 求解约束优化问题的动态邻域粒子群算法[J]. 计算机应用研究,2011,28(7):2476-2478.

[11] 刘若辰,焦李成,雷七峰,等. 一种新的差分进化约束优化算法[J]. 西安电子科技大学学报:自然科学版,2011,38(1):47-53.

[12] KARABOGA D. An idea based on honey bee swarm for numerical optimization, Technical Report-TR06[R]. [S. l.]:Erciyes University, 2005.

[13] BASTURK B, KARABOGA D. An artificial bee colony (ABC) algorithm for numeric function optimization[C]//Proc of IEEE Swarm Intelligence Symposium. 2006.

[14] 江中央,蔡自兴,王勇. 一种新的基于正交实验设计的约束优化进化算法[J]. 计算机学报, 2010,33(5):855-864.

[15] 江中央,蔡自兴,王勇. 求解全局优化问题的混合自适应正交遗传算法[J]. 软件学报, 2010,21(6):1296-1307.

[16] 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,2011,31(4):1094-1098.

[17] LEUNG Y W, WANG Yu-ping. An orthogonal genetic algorithm with quantization for global numerical optimization[J]. IEEE Trans on Evolutionary Computation,2001,5(1):41-53.

6 结束语

为了求解高维约束优化问题,本文提出改进的人工蜂群优