一种采用克隆选择的免疫差分进化算法*

胡超杰，章　兢
（湖南大学 电气与信息工程学院，长沙 410082）

摘　要：为了解决基本差分进化算法易出现早熟收敛的问题，提出了一种融合人工免疫系统和差分进化的混合算法。该算法在差分进化过程中引入了克隆选择操作和受体编辑机制，以增强算法的局部搜索能力和种群多样性。通过对五个标准函数的仿真实验表明，该算法不仅可有效避免早熟收敛，而且全局优化能力和收敛速度有显著提高。

关键词：差分进化；人工免疫系统；局部搜索能力；多样性；全局优化
中图分类号：TP18；TP301.6　　**文献标志码**：A　　**文章编号**：1001-3695(2013)06-1640-03
doi：10.3969/j.issn.1001-3695.2013.06.009

Immune differential evolution algorithm using clone selection

HU Chao-jie, ZHANG Jing
(*College of Electrical & Information Engineering*, *Hunan University*, *Changsha* 410082, *China*)

Abstract: To solve the problem of standard differerntial evolution algorithm getting into premature convergence easily, this paper proposed a novel hybrid optimization algorithm base on artificial immune system(AIS) and differential evolution(DE) algorithm. In this algorithm, it inserted clonal selection and receptor edit mechanism into the differential evolution process to enhance the local search ability and the population diversity of the algorithm. Experimental results on five functions show that this algorithm not only effectively avoids the premature convergence, but also significantly improves the global optimization ability and the convergence speed.

Key words: differential evolution; artificial immune system; local search ability; population diversity; global optimization

差分进化(differential evolution,DE)算法是由 Storn 等人[1]于 1995 年共同提出的一种采用实数矢量编码在连续空间中进行随机搜索的优化算法。由于 DE 算法具有原理简单、受控参数少、鲁棒性强等特点，目前在许多领域的复杂优化问题求解中得到了应用[2~5]。DE 算法是通过当前个体间的差分矢量进行变异、交叉和选择来实现寻优的，与其他常用的进化算法(如遗传算法)一样易陷入局部最优，存在过早收敛的现象。为了提高 DE 算法的搜索性能，国内外学者提出了改进的方法。文献[6]提出了一种新颖的加速 DE 算法，引入了逆向学习策略，并将其用于群体初始化和跳出局部最优解；文献[7]提出了基于中心变异和自适应交叉概率的差分进化算法，改进了个体的变异方式，即把当前代的群体中心作为基向量，依据参加变异的三个随机个体向量间的函数适应值的大小关系确定差向量的方向；文献[8]提出了一种双种群差分蜂群算法，将种群中的个体随机分为两组，分别采用差分进化和蜂群优化策略同时寻优，并通过让两个群体进行交互学习来提高算法的收敛速度；文献[9]提出了基于免疫原理的差分进化算法，该方法在保留差分进化优良特性的前提下，充分利用在学习过程中积累的经验来制作疫苗，以抑制变异和交叉的退化现象。

人工免疫系统(artificial immune system,AIS)是模拟生物免疫系统机理的人工智能系统。其克隆选择机制中存在着克隆、超变异、抗体与抗原特性结合，免疫记忆产生等过程，收敛速度快、多样性好。其受体编辑机制中允许细胞受体在特定的条件下发生结构改变，致使抗原受体不易陷入局部极值。

本文为了克服 DE 算法在求解全局优化问题时的缺陷，提出了一种基于克隆选择的免疫差分算法。

1　标准差分进化算法

DE 算法是一种基于种群的并行进化算法。在初始化阶段，种群个体以平均分布概率在搜索空间随机初始空间；在进化阶段，种群个体进行变异、交叉和选择三个迭代过程，直到满足停止条件。种群中每一个个体代表了目标函数 $f(X)$ 的一个候选解，通过计算其适应度函数来评价其质量，并对最优个体进行记录跟踪。

1)初始化　设种群个体数量为 NP，任意个体都可以看成是由 D 维向量值构成的，把它表示为 $X_i^g=(x_{i1}^g,x_{i2}^g,\cdots,x_{iD}^g)$ $(i=1,2,\cdots,NP)$，其中 x_{ij}^g 代表第 g 代第 i 个个体中的第 j 维向量值，个体 X_i^g 也就是目标函数 $f(X)$ 的一个候选解。

2)变异操作　在 DE 算法中，根据变异个体的生成方式不同，有多种不同的 DE 变异方式，常见的变异方式有 DE/rand/1/bin 和 DE/best/1/bin 两种。其变异公式如下：

$$v_{i,j}^g=x_{r1,j}^g+F\times(x_{r2,j}^g-x_{r3,j}^g) \tag{1}$$

$$v_{i,j}^g=x_{\mathrm{best},j}^g+F\times(x_{r1,j}^g-x_{r2,j}^g) \tag{2}$$

其中：$x_{\mathrm{best},j}^g$ 是第 g 代种群中最好个体的第 j 维向量；$r1$、$r2$、$r3$ 是异于 i 且互不相同的[1, NP]之间的整数；$F\in(0,1)$ 为缩放因子，F 用于控制差异向量的缩放程度。本文采用了 DE/best/1/

收稿日期：2012-10-09；**修回日期**：2012-11-14　　**基金项目**：国家自然科学基金资助项目(61174140)

作者简介：胡超杰(1988-)，男，河南信阳人，硕士研究生，主要研究方向为智能控制理论及应用、智能算法(huchaojie1988@gmail.com)；章兢(1957-)，男，教授，博导，主要研究方向为复杂系统工业控制、智能控制理论及应用、智能系统、节能减排管控一体化.

bin 差异方式。

3)交叉操作　按照一定的概率,将变异得到的中间个体 v_i 与父代个体 x_i 之间进行交叉操作,生成新的个体 u_i。

$$u_{i,j}^g = \begin{cases} v_{i,j}^g & \text{rand}(0,1) \leqslant CR \\ x_{i,j}^g & \text{其他} \end{cases} \tag{3}$$

其中:$CR \in [0,1]$ 为交叉概率;rand(0,1)为[0,1]之间均匀分布的随机数,这种交叉可以保证 u_i 中至少有一个分量由 v_i 提供。

4)选择操作　DE 采用贪婪选择策略,以保证适应度更优的个体进入下一代。将经过变异和交叉操作后生成的实验个体 u_i^g 与父代个体 x_i^g 进行竞争,只有当 u_i^g 的适应度较 x_i^g 更优时才能被选做子代;否则,直接将 x_i^g 作为子代。选择操作的方程为

$$x_i^{g+1} = \begin{cases} u_i^g & f(u_i^g) < f(x_i^g) \\ x_i^g & f(u_i^g) \geqslant f(x_i^g) \end{cases} \tag{4}$$

2　基于免疫克隆的免疫差分算法设计

DE 算法在选择操作中采用的是一种贪婪搜索策略,即经过变异和交叉操作后的个体与父代个体进行竞争,只有当其适应度优于父代才被选为子代,否则直接进入下一代。该机制可以增加算法的收敛速度,但也容易陷入局部最优点而使算法停滞,也就是早熟收敛。针对 DE 算法容易陷入局部最优的缺点,本文提出了基于克隆选择的免疫差分算法(ICDE)。在差分进化过程中对优秀个体进行克隆选择操作,以尽可能地保留优秀个体,从而提高算法收敛精度和种群多样性;同时对不活跃的个体进行受体编辑操作,在保证种群多样性的同时加快算法的收敛速度,使算法在合理的计算复杂度下提高总体寻优能力。

2.1　人工免疫算法

DE 算法产生早熟收敛的根本原因是随着迭代次数的增加和种群多样性的快速下降,形成了“聚集”现象。这表现在种群个体的适应度之间的差异越来越小,群体易集中收敛于一点,最后种群便无法在解空间内重新搜索。因此,算法陷入局部最优,出现了早熟收敛现象。由于差分进化算法是一种随机搜索策略,如果问题是多峰函数,则存在多个局部最优点,算法很容易陷入局部最优,难以找到全局最优点。为了提高算法求解多模态(多峰)全局优化问题能力,引入免疫系统中的克隆选择机制和受体编辑机制。

2.1.1　克隆选择

克隆操作步骤如下:

a)生成一组候选解集 $X = \{x_{1d}, x_{2d}, \cdots, x_{nd}\}$,根据亲和度测量,从种群 X 选择亲和度最高的前 n 个个体(X_n)。

b)对种群 X_n 中的个体进行克隆,克隆规模与亲和度成正比,克隆倍数 Nc 如式(5)所示。

$$Nc = \sum_{i=1}^{n} \text{round}\left(\frac{\beta \times n}{i} + b\right) \tag{5}$$

其中:round 函数表示取整;n 为种群规模;$\beta \in (0,1)$。为了保证每个抗体都有一定的克隆数量,故加上了常量 $b \geqslant 1$ 的整数,生成一个临时种群 C。

c)对群体 C 中的每个个体实施高频变异,生成一个变异后的抗体群(C^*)。受自然生物进化思想启发[10,11],算法在进化初期变异尺度较大以保持种群的多样性,而在进化后期变异尺度逐渐缩小以提高局部微调能力。其变异算子如下:

$$x_{id}^{\text{new}} = x_{id} + \alpha \times \eta \times x_{id} \times \text{rand}(0,1) - \alpha \times \eta \times x_{id} \times \text{rand}(0,1) \tag{6}$$

$$\alpha = \begin{cases} 1 & \text{rand}(0,1) \leqslant p_m \\ 0 & \text{else} \end{cases} \tag{7}$$

其中:rand(0,1)为[0,1]之间的随机数,$P_m = 0.5$。

$$\eta(t) = 1 - r^{\left[1 - \frac{g}{g_{\max}}\right]^b} \tag{8}$$

其中:g 是群体当前进化代数;$g_{\max}$ 为总进化代数;b 为正常数,一般取值为 2;$r \in (0,1)$。从式(8)可看出,在进化初期,当 r 取较小的值时,$\eta(t) \approx 1$,此时的变异空间大;而在进化后期,g 接近 $g_{\max}$ 时,$\eta(t) \approx 0$,算法在小范围空间内进行局部搜索。

d)免疫选择操作,从克隆变异后的个体中选择亲和度最优的个体进入下一代,通过局部择优实现了种群的压缩,同时保证了抗体群中的最优解不会变差。

2.1.2　受体编辑

受体编辑机制[12]是指 T 细胞和 B 细胞受体在特定的条件下结构发生改变,从而发生亲和度的变化。受体编辑进一步丰富了抗原受体的多样性。在基于克隆选择的免疫差分算法系统中,每隔一定的代数就要鉴别出不活跃的细胞受体,对其中的 25% ~30% 进行受体编辑。对于不活跃的细胞受体,利用非线性 Logistic 序列随机又有规律的位置漂移。具体如式(9)所示。

$$X'_{id} = X_{id} + \frac{X_{id}^{\max} - X_{id}^{\min}}{m} + U_{r+1} \tag{9}$$

其中:$X_{id}^{\max}$、$X_{id}^{\min}$ 为位置的上界、下界;m 为正常数,视具体问题而定;U_{r+1} 为混沌序列 Logistic。U_{r+1} 为混沌序列 Logistic[10] 映射为

$$U_{r+1} = \mu \times U_r \times (1 - U_r) \quad r = 0,1,2,\cdots \quad 0 < U_0 < 1 \tag{10}$$

其中:μ 为系统的状态控制参量,文献[8]已证明,当 $\mu = 4$,初始值 U_0(0.25,0.5,0.75,1)时,式(10)表示的系统完全处于混沌状态;U_{r+1} 在(0,1)范围内遍历。

2.2　算法流程

本文提出的基于克隆选择的免疫差分算法实现步骤如下:

a)设置种群规模 NP、最大迭代次数 $g_{\max}$、差分变异矢量收缩因子 F、交叉概率 CR、求解精度 ε,令 $g = 1$,按式(11)随机初始化每一个个体。

$$x_{ij} = \text{rand}(0,1) \times (x_j^u - x_j^l) + x_j^l \tag{11}$$

其中:$i = 1,2,\cdots,NP$;$j = 1,2,\cdots,D$;x_j^u 为第 j 维变量的上限,x_j^l 为下限。

b)计算个体适应度 Fitness,求出最优适应值 Bestfitness 并记录下当前代最优个体 X_{best}^g。

c)如果最优适应度 Bestfitness 达到理论最优值或迭代次数 g 等于最大迭代次数 $g_{\max}$,输出结果;否则,执行步骤 d)。

d)将所有个体按适应度排序,对于前 1/4 的优秀个体进行克隆选择操作。如果所有个体中最优个体适应度值优于当前代全局最优个体适应度,则用该个体取代全局最优个体 X_{best}^g,同时每隔 10 代对适应度较差的后 1/4 的个体进行受体编辑操作。

e)在种群中随机选择两个不同的个体,按式(2)进行变异操作,生成变异个体 v_i^g。

f)按式(3)进行交叉操作,生成实验个体 u_i^g。

g)按式(4)进行选择操作,生成 $g+1$ 代个体 x_i^{g+1}。

h)$g = g + 1$,返回步骤 b)。

3　仿真实验及结果分析

3.1　实验设置

为了验证本文所提出改进算法的有效性，采用了五种典型的 Benchmark 函数进行测试，均为最小化问题。测试函数具体形式如表 1 所示。其中：f_1 为 Sphere 单峰二次函数，主要用来测试算法寻优精度；f_2 为 Rosenbrock 函数，是一个非凸、病态函数；f_3 为 Griewank 函数，多峰，存在大量局部极小点；f_4 为 Ackley 函数，是一个具有深度局部最小点的多峰函数；f_5 为 Rsatrigin 函数，多峰，在 $S=\{x_i\in(-5.12,5.12),i=1,2,\cdots,n\}$ 范围内大约存在 $10n$ 个局部极小点，一般算法较难得到全局最优解。在本文 $f_3\sim f_5$ 主要用来检验算法全局搜索的性能和避免早熟的能力。

表 1　五种标准测试函数

函数	方程	取值范围	最优解
Sphere	$f_1(x)=\sum_{i=1}^{n}x_i^2$	$[-100,100]$	0
Rosenbrock	$f_2(x)=\sum_{i=1}^{n}(100(x_{i+1}-x_i^2)^2+(x_i-1))$	$[-30,30]$	0
Griewank	$f_3(x)=\frac{1}{4000}\sum_{i=1}^{n}x_i^2-\prod_{i=1}^{n}\cos(\frac{x_i}{\sqrt{i}})+1$	$[-600,600]$	0
Ackley	$f_4=-20\exp(-0.2\sqrt{\frac{1}{n}\sum_{i=1}^{n}x_i^2})-\exp(\frac{1}{n}\sum_{i=1}^{n}\cos(2\pi x_i)+20+e)$	$[-32,32]$	0
Rsatrigin	$f_5(x)=\sum_{i=1}^{n}[x_i^2-10\cos(2\pi x_i)+10]$	$[-5.12,5.12]$	0

在实验中，函数维数为 30，种群规模 NP 均设为 100。为了使 ICDE 算法的测试结果更具对比性，将其与 DE 以及 ODE[6]、BDABC[8] 算法进行比较。DE 和 ICDE 的参数设置为 $F=0.5$，$CR=0.8$；ODE 和 BDABC 的参数设置参见文献[6,8]。对于每个测试函数的最高迭代次数均设置为 2 000。为了减小随机影响，针对每个测试函数各算法均独立运行 30 次求其平均值。实验结果如表 2、图 1 ~5 所示。

表 2　四种算法的测试结果

函数	DE 平均值（标准差）	ODE 平均值（标准差）	BDABC 平均值（标准差）	ICDE 平均值（标准差）
f_1	5.10e-17 (2.67e-17)	3.98e-46 (1.04e-45)	2.18e-66 (6.81e-66)	3.13e-171 (0)
f_2	14.08 (5.28e-1)	20.74 (1.20e+00)	1.80e+00 (1.23e+00)	3.13e-5 (7.96e-5)
f_3	7.40e-4 (2.21e-3)	0 (0)	1.92e-11 (4.87e-11)	0 (0)
f_4	2.06e-9 (5.49e-10)	4.85e-15 (1.42e-15)	3.08e-13 (1.27e-13)	6.63e-15 (1.63e-15)
f_5	169.49 (6.70e+00)	7.85e+1 (2.01e+1)	3.54e-12 (5.90e-12)	0 (0)

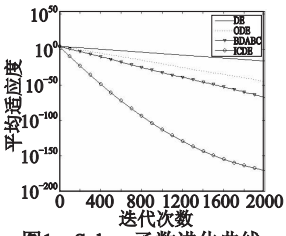

图1　Sphere函数进化曲线

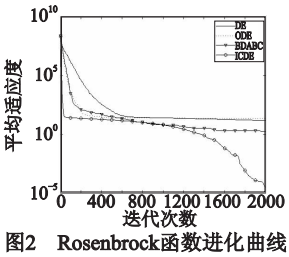

图2　Rosenbrock函数进化曲线

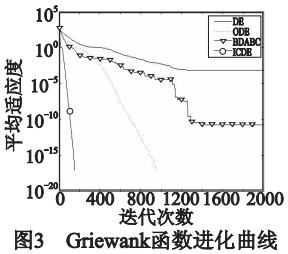

图3　Griewank函数进化曲线

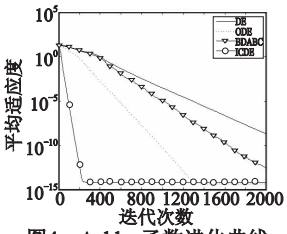

图4　Ackley函数进化曲线

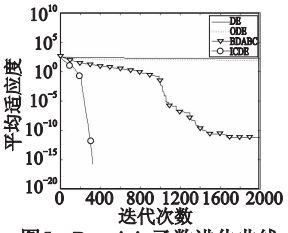

图5　Rastrigin函数进化曲线

3.2　实验结果分析

a）对于复杂的单模态函数 Sphere，由表 2 和图 1 可知，ICDE 算法的收敛速度明显快于 DE、ODE 和 BDABC 算法，几乎线性递减地收敛到最优解。另外，ICDE 收敛精度也明显高于其他三种算法，BDABC 次之，ODE 只比 DE 好。

b）对于 Rosenbrock 函数，由图 2 可看出，ICDE 算法进化到 100 代左右就开始收敛，ODE 和 BDABC 均在 300 代左右收敛，DE 到 500 代以后才开始收敛。由于采用了受体编辑策略，到 1 500代后 ICDE 可以继续优化到更高的精度，说明 ICDE 算法有更强的跳出局部最优能力。根据表 2 可看出，ICDE 算法最靠近理论最优值，BDABC 和 ODE 甚至比 DE 没有明显优势。

c）Griewank、Ackley、Rastrigin 三种多模态函数均是复杂的非线性全局优化问题，主要用来测试算法的全局搜索性能。从图 3 ~5 和表 2 可以看出，三种改进的 DE 算法的优化效果均比 DE 好。对于三种函数，ICDE 算法的收敛速度均高于 DE、ODE 和 BDABC 算法。对于 Griewank 函数，ICDE 和 ODE 算法均得到理论最优值，但 ICDE 几乎是线性收敛到最优值，收敛速度最快。BDABC 算法在收敛精度和收敛速度方面都很不理想，只比 DE 稍好。对于 Ackley 函数，ICDE 算法也能几乎线性收敛，且收敛速度最快，ODE 算法次之，BDABC 算法最差。收敛精度方面三种改进的算法均优于 DE，其中 ODE 算法最好，ICDE 算法稍差，BDABC 算法仅比 DE 好。对于 Rastrigin 函数，三种改进的 DE 算法中，ICDE 无论在收敛速度还是在收敛精度方面都有绝对的优势，并且达到了理论最优值，BDABC 次之，ODE 最差，甚至无法收敛，以至于与 DE 相差无几。

综合表 2、图 1 ~5 可以看出，基于所测试的 5 种 Benchmark 函数实验表明，在相同的参数设置下，对比 DE、ODE 和 BDABC 算法，本文提出的 ICDE 算法不仅优化速度更快，而且收敛精度更高、鲁棒性更好。

4　结束语

本文针对 DE 算法的不足，结合克隆选择算法，提出了一种基于克隆选择的免疫差分算法（ICDE）。通过引入克隆选择策略和受体编辑，提高了种群的多样性及解的质量。通过对复杂的全局优化问题的仿真实验表明，该算法在保证种群多样性的同时，避免了早熟收敛，全局搜索和跳出局部最优的能力强于 DE、ODE 和 BDABC 算法。

（下转第 1651 页）

对比车辆容量缩小至四分之一后分别使用不可拆分和可拆分两种算法得到的最优解,可发现使用本文拆分算法明显优于 Solomon 不可拆分算法,证明在容量有限的情况下,可拆分算法可以更好地利用车辆的剩余空间,达到减小运输成本的目的。

另外,对比车辆容量缩小后使用本文拆分算法求得的最优解和在原始容量时通过不可拆分算法求得的已知最优解,可发现在计算 R202、R203、R211、RC202、RC203 和 RC205 数据集时,使用本文拆分算法得到最优解甚至优于四倍车辆容量时的已知最优解,而对其他 R_2 和 RC_2 系列数据集,本文拆分算法的最优解亦非常接近四倍车辆容量时的已知最优解。这是因为 R_2 和 RC_2 系列数据集的 RDC 开放时间窗较宽,车辆可以访问更多的集货点后再返回 RDC,此时需求可拆分的优势可以得到充分发挥。

对比本文拆分算法在 R_1、C_1、RC_1、R_2、C_2、RC_2 各子集上的表现,发现在 R_2 和 RC_2 子集上的表现最佳,原因如前述;而在 C_1 和 C_2 子集上表现稍差,分析原因为 C 系列的数据具有区域聚集性,本文算法并未对其做特殊处理,应有更有效的算法针对具有区域聚集性特点的数据。

4　结束语

本文针对汽车零部件供货物流的循环取货路径规划问题,提出了具有时间窗的、供应商需求可拆分配送的方案,并依此思路建立数学模型,设计了改进的启发式算法求解。通过采用 Solomon VRPTW 问题的标准测试数据验证了本文拆分算法的有效性。并且通过求解缩小车辆容量的 Solomon 数据,验证了在容量有限的情况下,本文拆分算法相较不可拆分算法,可以更好地利用车辆剩余空间,减小运输成本。特别是在时间窗较宽的情况下,本文拆分算法优越性显著。另外,本文为计算方便假设了货物为均一规格、车辆容量以货物件数为单位。在实际情况中,这一假设并不合理,此时可以考虑以货物和车辆的体积或质量为单位进行计算。同时,本文仅考虑了单一 RDC、单一车型的情况,并且假设了供应商可以同时服务多辆货车,即当有多辆货车同时到达同一供应商处时不会出现拥挤和等待。在后续研究中,可以加入多个 RDC、多种车型及供应商服务能力有限、车辆排队等候的情况,进一步考察此时需求可拆分算法的表现。

参考文献:

[1] 张坤,江海容. 汽车零部件循环取货车辆路径优化研究[J]. 物流科技,2009,32(2):69-72.

[2] 徐秋华. Milkrun—循环取货方式在上海通用汽车的实践和应用[J]. 汽车与配件,2003(3):21-24.

[3] 王旭,陈栋,王振锋. 汽车零部件 Milk-run 车辆调度优化模型和算法[J]. 计算机应用,2011,31(4):1125-1128,1132.

[4] 汪金莲,蒋祖华. 汽车制造厂零部件入厂物流的循环取货路径规划[J]. 上海交通大学学报,2009,43(11):1703-1709.

[5] JIN Ming-zhou, LIU Kai, BOWDEN R O. A two-stage algorithm with valid inequalities for the split delivery vehicle routing problem[J]. International Journal of Production Economics, 2007, 105(1): 228-242.

[6] 孟凡超,陆志强,孙小明. 需求可拆分车辆路径问题的禁忌搜索算法[J]. 计算机辅助工程,2010,19(1):78-83.

[7] 刘旺盛,黄娟. 需求可拆分的车辆路径问题的分段求解[J]. 集美大学学报,2011,16(1):38-44.

[8] 李三彬,柴玉梅,王黎明. 需求可拆分的开放式车辆路径问题研究[J]. 计算机工程,2011,37(6):168-171.

[9] SOLOMON M M. Algorithms for the vehicle routing and scheduling problems with time window constraints[J]. Operations Research, 1987, 35(2): 254-265.

[10] 邢文训,谢金星. 现代优化计算方法[M]. 2 版. 北京:清华大学出版社,2005.

[11] HO S C, HAUGLAND D. A tabu search heuristic for the vehicle routing problem with time windows and split deliveries[J]. Computers & Operations Research, 2004, 31: 1947-1964.

(上接第 1642 页)

参考文献:

[1] STORN R, PRICE K. Differential evolution: a simple an efficient heuristic for global optimization over continuous spaces[J]. Journal Global Optimization, 1997, 11(4): 341-359.

[2] QIN A K, HUANG V L, SUGANTHAN P N. Differential evolution algorithm with strategy adaptation for global numerical optimization [J]. IEEE Trans on Evolutionary Computation, 2009, 13(2): 398-417.

[3] DAS S, SUGANTHAN P N. Differential evolution: a survey of the state-of-the-art[J]. IEEE Trans on Evolutionary Computation, 2011, 15(1): 4-31.

[4] 杨卫东,姚峰,张明. 基于自适应交叉概率因子的差分进化算法及其应用[J]. 信息与控制,2010,32(2):187-193.

[5] GONG Wen-yin, CAI Zhi-hua, LING C X, *et al*. Enhanced differential evolution with adaptive strategies for numerical optimization [J]. IEEE Trans on System, Man, and Cybernetics, Part B: Cybernetics, 2011, 41(2): 397-413.

[6] RAHNAMAYAN S, TIZHOOSH H R, SALAMA M M A. Opposition based differential evolution [J]. IEEE Trans on Evolutionary Computation, 2008, 12(1): 64-79.

[7] 池元成,方杰,蔡国飙. 中心变异差分进化算法[J]. 系统工程与电子技术,2010,32(5):1105-1108.

[8] 暴励,曾建潮. 一种双种群差分蜂群算法[J]. 控制理论与应用,2011,28(2):266-272.

[9] 吴燕玲,卢建刚,孙优贤. 基于免疫原理的差分进化[J]. 控制与决策,2007,22(11):1309-1312.

[10] 任子武,伞冶. 实数遗传算法的改进及性能研究[J]. 电子学报,2007,35(2):269-274.

[11] 刘朝华,章兢,李小花,等. 免疫协同微粒群进化算法的永磁同步电机多参数辨识模型方法[J]. 自动化学报,2012,38(10):1698-1708.

[12] GE Hong-wei, SUN Liang, LIANG Yan-chun, *et al*. An effective PSO and AIS-based hybrid intelligent algorithm for Job-Shop scheduling [J]. IEEE Trans on Systems, Man, and Cybernetics, Part A: System and Humans, 2008, 38(2): 358-368.