

文章编号:1001-2486(2011)05-0036-05

## 基于种群分类的变尺度免疫克隆选择算法\*

郭忠全,王振国,颜力

(国防科技大学 航天与材料工程学院,湖南长沙 410073)

**摘要:**提出了一种基于种群分类的变尺度免疫克隆选择算法。该算法通过对目标函数进行非线性尺度变换,突出了全局最优解的优势地位;建立记忆子群实现了种群代际进化信息的交换;依据亲和度将抗体分为精英子群、普通子群、劣等子群,并对其分别执行自适应高斯变异、均匀变异和消亡更新等策略,增强了算法的局部和全局搜索能力。引入小生境技术提高了抗体分布的多样性,进而克服了算法的早熟。采用经典测试函数和星载天线结构优化问题对算法进行了测试,测试结果表明本算法寻优能力较经典克隆选择算法和标准遗传算法有较大改善,且计算复杂度并无显著增加。

**关键词:**人工免疫;克隆选择;种群分类;变尺度;星载天线优化

中图分类号:V423.4 文献标识码:A

## Mutative Scale Immune Clonal Selection Algorithm Based on Multi-population

GUO Zhong-quan, WANG Zhen-guo, YAN Li

(College of Aerospace and Material Engineering, National Univ. of Defense Technology, Changsha 410073, China)

**Abstract:** Mutative Scale Immune Clonal Selection Algorithm (MSICSA) based on Multi-population is proposed. In the algorithm, the dominant position of global optimal solution was highlighted by the nonlinear scale transformation of objective function. Memory sub-population was extracted to exchange information between populations. Antibody population was divided into elite, normal and inferior sub-population. To enhance local and global search capabilities of MSICSA, adaptive Gaussian and uniform mutation were applied to elite and normal sub-population respectively and the inferior antibody was extinguished and replaced by new ones. By introducing the niche technology to increase the diversity of population distribution, the algorithm can prevent premature. Test functions and a space antenna optimization were tested. The results show that the optimization capability of MSICSA is more advanced than CLONALG and SGA, and the computational complexity is reduced.

**Key words:** artificial immune; clone selection; multi-population; mutative scale; space antenna optimization

免疫系统是一个高效的生物信息处理系统,具有分布式、自组织、自适应、鲁棒性等特点<sup>[1]</sup>。人工免疫系统(AIS)是在生物免疫机制启发下产生的新兴智能系统,已在机器学习、计算机安全、智能计算等领域得到了广泛的应用。De Castro基于免疫克隆选择学说提出了克隆选择算法<sup>[2]</sup>(CLONALG)。该算法通过对抗体种群进行克隆扩增和高频变异实现了多模态函数的优化,并表现出较好的解决复杂工程优化问题的潜力<sup>[3-5]</sup>。但是,由于单一变异规则缺乏对个体特性差异的考虑<sup>[6-7]</sup>,种群代际之间也没有有效的信息交流,因而搜索的盲目性降低了算法的整体效率。此外,搜索过程中缺少对种群多样性的控制,使算

法存在陷入早熟而不能收敛到全局最优解的风险<sup>[8]</sup>。针对上述问题,本文提出一种新的免疫算法——变尺度免疫克隆选择算法(Mutative Scale Immune Clonal Selection Algorithm, MSICSA)。算法通过对目标函数进行非线性尺度变换,突出全局最优解的优势地位以便于问题求解;选取亲和度较高的抗体组成记忆子群直接进入下代种群,以实现种群代际的信息交流;依据亲和度将种群划分为多个子群,对精英子群执行高斯变异以增强算法的局部搜索能力,对普通子群执行均匀变异以扩展全局搜索能力,对劣等子群执行随机替代以维持种群的多样性;根据当前种群的进化状态自适应调整变异算子的步长以加速算法收敛速

\* 收稿日期:2011-03-25

基金项目:国家自然科学基金资助项目(50975280,61004094);教育部新世纪优秀人才支持计划资助项目(NCET-08-0149)

作者简介:郭忠全(1981—),男,博士生。

度;选择算子中引入基于小生境的多样性控制策略以有效避免算法的早熟。

## 1 变尺度免疫克隆选择算法

### 1.1 算法描述

不失一般性,考虑连续对象的极大值问题  $\max f(X)$ , 其中  $X = (x_1, x_2, \dots, x_n)$ ,  $x_i \in (x_l, x_u)$ ,  $i = 1, 2, \dots, n$ 。若求极小值,将目标函数改为  $\min -f(X)$  即可。

(1) 抗体初始化。抗体对应优化问题的候选解集,可采用多种编码形式,记为  $A = e(X)$ 。本算法采用实数编码形式,避免了对抗体进行编码和解码等步骤。按照均匀分布,在解空间上进行随机采样,形成规模为  $N$  的初始种群  $P(0)$ 。

(2) 非线性尺度变换。亲和度主要用于对抗体质量的评估,体现了抗体对抗原的识别程度,其本质是目标函数值域的映射  $F = g(f)$ 。CLONALG 算法<sup>[2]</sup>直接利用目标函数作为亲和度函数,对于不同的优化问题亲和度将在数值上面临巨大的尺度差异,且不能保证数值符号的一致性,为后续基于亲和度的种群扩增、变异和选择等算子设计和组织带来了困难。研究表明目标函数的性态对优化问题求解有着显著影响<sup>[6]</sup>,本文通过式(1)所示的非线性尺度变换以期改善优化问题的性态,从而利于问题的求解。

$$F = \alpha \cdot \frac{e^{\beta \cdot \frac{f - \tilde{f}_{\min}}{\tilde{f}_{\max} - \tilde{f}_{\min}} - 1}}{e^{\beta} - 1} \quad (1)$$

上述变换在没有改变最优值在可行域中位置的情况下,通过非线性映射突出了全局最优解和一般解的差异。同时,通过线性归一化处理使目标函数值域映射到  $[0, \alpha]$  区间。通常情况下,  $\alpha$  取 100,  $\beta$  大于 3。由于优化问题极值的不可预知性,计算中分别使用当前种群中的最小\大值 ( $\tilde{f}_{\min}$  \  $\tilde{f}_{\max}$ ) 替代。

(3) 免疫记忆。免疫系统初次应答时将高亲和度抗体分化成生命期较长的 B 记忆细胞。这些细胞在二次应答时能够预先被免疫系统选择出来,迅速活化、增殖、分化为效应细胞,产生高亲和力抗体。算法在上代种群中按照比例  $r_m$  提取了高亲和度抗体,形成记忆子群  $P_m$ ,直接进入下代抗体种群。 $P_m$  保留了上代种群的优秀个体,实现了种群之间的信息交换,提高了算法的收敛性和寻优效率。通常情况下,  $r_m$  取 0.05 ~ 0.1。

(4) 种群分类。模拟免疫系统抗体之间分布式协作的特性,按照  $r_c : r_g : r_b$  (其中,  $r_c + r_g + r_b =$

1) 的比例,将抗体种群分为精英子群  $P_{elite}$ 、普通子群  $P_{general}$  和劣等子群  $P_{bad}$  等。其中,精英子群被大量克隆,在当前最优值附近完成精细的局部搜索。普通子群则以当前位置为基点,在整个解空间范围内进行粗粒度的全局搜索。劣等子群则模拟生物体抗体自然消亡的机理,被淘汰更新为子群  $P_{new}$ 。

(5) 克隆扩增。依据亲和度大小对抗体进行克隆扩增,每个抗体的克隆规模  $q_i$  由式(2)确定:

$$q_i = \text{round} \left( r_c \cdot N \cdot \frac{F_i}{\sum_{i=1}^N F_i} \right), \quad i = 1, 2, \dots, N \quad (2)$$

其中,  $r_c$  为种群克隆规模,通常取 1 ~ 3;  $N$  为当前种群的规模;  $F_i$  为抗体的亲和度;  $\text{round}(\ast)$  为就近取整操作。本算法仅对精英子群和普通子群进行克隆扩增操作。

(6) 自适应超变异。对克隆扩增后的精英抗体子群  $P_{elite}$ ,算法在解空间内按照式(3)描述的高斯分布进行变异。对于普通抗体子群  $P_{general}$ ,按照式(4)描述的均匀分布进行变异。式(5)描述的是抗体超变异的步长自适应调节机制。

$$X' = X + \gamma \cdot L \cdot N(0, 1) \quad (3)$$

$$X' = X + L \cdot U(-1, 1) \quad (4)$$

$$\gamma = \rho e^{(-\eta T)}, L = \frac{X_u - X_l}{2} \quad (5)$$

其中,  $X_u, X_l$  分别是  $X$  的上下限,  $T$  为当前最优值迟滞代数,  $\rho, \eta$  为调节系数。上式表明随着迟滞代数  $T$  增加,算法将缩小寻优范围进行精细搜索。最优值若更新,抗体变异尺度将还原以扩大搜索范围。

(7) 共享度计算。经过多轮进化后,抗体种群可能因多样性减少而聚集到局部最优解周围出现早熟现象。借鉴小生境技术对抗体浓度进行控制,对聚集区抗体通过共享函数进行惩罚,同时激励浓度较低群体的繁衍。两个抗体之间的欧氏距离为  $d_{ij} = \|X_i - X_j\|$ , 抗体共享度计算如式(6)所示:

$$Sh(d_{ij}) = \begin{cases} 1 - \left[ \frac{d_{ij}}{\sigma_{share}} \right]^{\theta}, & d_{ij} < \sigma_{share} \\ 0, & \text{otherwise} \end{cases}$$

$$S_i = \sum_{j=1}^n Sh(d_{ij}), \quad i = 1, 2, \dots, n \quad (6)$$

其中,  $\theta$  为共享函数形状控制参数,通常取 1;  $\sigma_{share}$  为小生境的共享半径。

(8) 免疫选择。合并精英子群  $P_{elite}$  和普通子群  $P_{general}$ ,按照调整后的亲和度  $F'_i = F_i / S_i$ ,采用轮盘赌的形式选择  $(1 - r_m - r_b)N$  个抗体,形成进

化子群  $P_s$ 。进而将进化子群  $P_s$ 、记忆子群  $P_m$ 、更新子群  $P_{new}$  合并生成下一代种群  $P(k+1)$ 。

(9) 终止准则, 采用最大迭代次数  $T_{max}$  和最优值最大停滞代数  $St_{max}$  的组合条件进行控制。

### 1.2 算法步骤

变尺度免疫克隆选择算法 (MSICSA) 的主要流程如图 1 所示, 算法步骤描述如下:

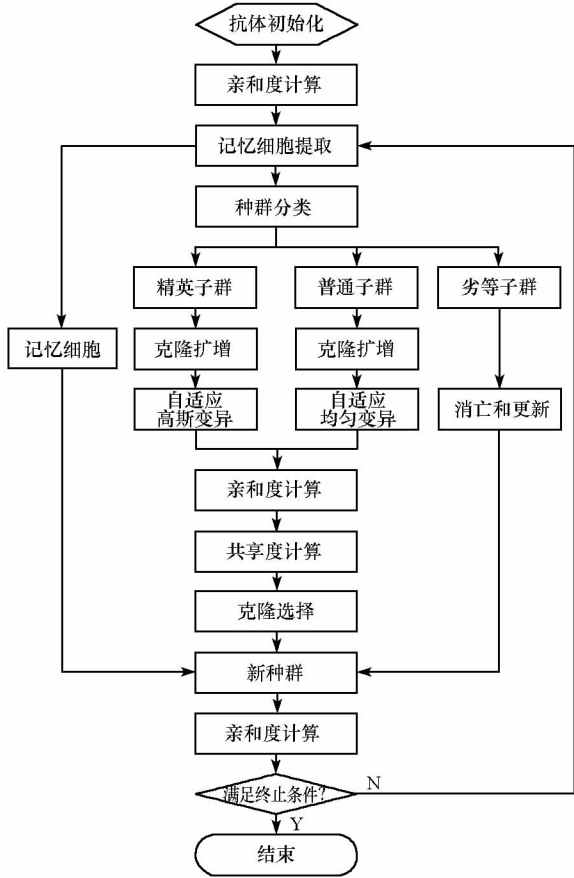


图 1 MSICSA 的算法流程图

Fig. 1 Computational procedure for the MSICSA

Step 1 设定算法参数, 抗体初始化得到规模为  $N$  的初始种群  $P(0)$ 。

Step 2 按照式(1)进行亲和力计算, 并对种群排序。

Step 3 假设当前为第  $k$  代。首先依比例  $r_m$  在种群中抽取优秀抗体, 形成记忆子群  $P_m(k)$ 。

Step 4 依比例  $r_e:r_g:r_b$  将种群  $P(k)$  分解为精英子群  $P_{elite}(k)$ 、普通子群  $P_{general}(k)$  和劣等子群  $P_{bad}(k)$ 。

Step 5 按照式(2)分别对  $P_{elite}(k)$ 、 $P_{general}(k)$  进行克隆扩增操作, 得到种群  $P_{elite}^c(k)$ 、 $P_{general}^c(k)$ 。

Step 6 按照式(3)~(5)对种群  $P_{elite}^c(k)$ 、 $P_{general}^c(k)$  进行自适应变异操作。变异后得到种群  $P_{elite}^m(k)$ 、 $P_{general}^m(k)$ 。

Step 7 合并  $P_{elite}^m(k)$ 、 $P_{general}^m(k)$  生成原始进

化子群  $P_{os}(k)$ , 并计算其亲和度  $F$  及共享度  $S$ 。

Step 8 对原始进化子群  $P_{os}(k)$  进行免疫选择, 生成进化子群  $P_s(k)$ 。

Step 9 劣等子群  $P_{bad}(k)$  更新为等规模的更新子群  $P_{new}(k)$ 。

Step 10 合并记忆子群  $P_m(k)$ 、进化子群  $P_s(k)$  和更新子群  $P_{new}(k)$ , 生成下一代种群  $P(k+1)$ 。

Step 11 对种群  $P(k+1)$  进行亲和力计算。

Step 12 判断是否满足终止条件。不满足, 则跳转到 Step 3; 若满足, 则算法结束。

### 2 算法性能分析

(1) 收敛性。MSICSA 算法每步迭代对应种群的  $P(k)$  的变化仅由  $P(k-1)$  决定, 而与之前的种群状态无关。因而, 在克隆扩增、自适应变异及克隆选择作用下产生的种群序列  $\{P(k), k \geq 0\}$  构成了有限齐次马尔可夫链。可以证明当算法迭代足够多次后, 种群中包含全局最佳个体的概率接近于 1, 即 MSICSA 依概率 1 收敛。严格的证明过程参考了文献[2], 在此不再展开叙述。

(2) 计算复杂性。由算法描述可知, MSICSA 从第  $k$  代进化到第  $k+1$  代所需计算目标函数的次数为

$$M = N + \sum_{i=1}^{r_e+r_g} q_i \approx N + r_c N \left( \sum_{i=1}^{r_e+r_g} F_i / \sum_{i=1}^N F_i \right) \quad (7)$$

由于  $F_i$  为降序排列, 因此

$$(r_e + r_g) \leq \sum_{i=1}^{r_e+r_g} F_i / \sum_{i=1}^N F_i \leq 1 \quad (8)$$

$$(1 + r_e - r_b r_c) N \leq M \leq (1 + r_c) N \quad (9)$$

由于  $r_b$  通常是一个小量, MSICSA 计算复杂性主要与种群规模  $N$  和克隆扩增比率  $r_c$  成正比。因此, 要降低算法的计算复杂性, 必须将  $N$  和  $r_c$  控制在合理范围内。

### 3 算例分析

选取了 4 个典型优化测试函数和某星载天线结构优化问题为例, 对 MSICSA、CLONALG 和标准遗传算法 (SGA) 进行性能测试。通过对测试结果进行对比分析, 验证 MSICSA 算法的有效性。

#### 3.1 经典函数测试

测试函数均变换为求最大值问题, 其数学描述和函数特点如表 1 所示。

为保证结果的可比性, 各算法设置如下:

MSICSA、CLONALG、SGA 的初始种群均为  $N = 100$ ,最大迭代步数设为  $T = 1000$ ,最大停滞步数  $St = 50$ ,目标值的容许误差  $\varepsilon = 1 \times 10^{-5}$ 。MSICSA、CLONALG 的克隆规模均为  $r_c = 1$ 。MSICSA 亲和度变换参数取  $(\alpha, \beta) = (100, 5)$ ;各比例参数分别为  $r_m = 0.05, r_e = 0.3, r_e = 0.6, r_e = 0.1$ ;  $\sigma_{share} = 0.01 (X_u - X_l)$ 。SGA 的交叉概率为 0.8,变异概率为 0.05。各算法分别针对 4 个测试问题进行 100 次独立试验,得到统计结果如表

2 所示。

从表 2 中的数据可看出,MSICSA 算法有效地克服了算法早熟的问题,具有较好的全局寻优能力。MSICSA 算法对与函数  $F_1、F_2、F_3$  均能 100% 找到最优解,较之 CLONALG 和 SGA 算法能够跳出局部最优解,具有更强的全局搜索能力和稳定性。对于高维多峰函数  $F_4$ ,MSICSA 算法能够以 75% 的概率获得全局最优解,其最优值的均值和标准差也显著优于 CLONALG 和 SGA 算法。

表 1 优化测试函数

Tab. 1 Optimization test functions

编号	数学描述	取值范围	函数特点
$F_1$	$F_1(X) = 0.5 - \frac{\sin^2(\sqrt{x_1^2 + x_2^2}) - 0.5}{[1 + 0.001(x_1^2 + x_2^2)]^2}$	$-10 \leq x_1, x_2 \leq 10$	$F_1$ 又名 Schaffer 函数,在 $(0,0)$ 处取得全局最大值 1,最大峰值周围有一个圈脊,很容易停滞在此局部极大区域。
$F_2$	$F_2(X) = \left(\frac{3}{0.05 + x_1^2 + x_2^2}\right)^2 + (x_1^2 + x_2^2)^2$	$-5.12 \leq x_1, x_2 \leq 5.12$	$F_2$ 是典型的大海捞针 (Needle-in-a-haystack) 问题,在 $(0,0)$ 处取得全局最大值 3600。在边界上有 4 个局部极值点。
$F_3$	$F_3(X) = e^{-( x_1  +  x_2 )^{50}} (\cos  x_1  + \cos  x_2 )$	$-50 \leq x_1, x_2 \leq 50$	$F_3$ 是一个典型的多峰函数,在 $(0,0)$ 点处取得唯一最大值 2。此外,函数有多个局部极大值。
$F_4$	$F_4(X) = \prod_{i=1}^{10} \cos(x_i/\sqrt{i}) - \frac{1}{4000} \sum_{i=1}^{10} (x_i^2) - 1$	$-50 \leq x_i \leq 50$ $i = 1, \dots, 10$	$F_4$ 是典型的复杂高维多峰优化问题,在 $(0,0)$ 点处取得唯一最大值 0。全局最大值附近集中了难以计数的局部极值。

表 2 SGA、CLONALG、MSICSA 的寻优能力比较

Tab. 2 Optimization performance of SGA、CLONALG、MSICSA

函数	SGA			CLONALG			MSICSA		
	平均值	标准差	寻优次数	平均值	标准差	寻优次数	平均值	标准差	寻优次数
$F_1$	0.8882	0.1079	23	0.9560	0.0845	70	1.0000	0.0000	100
$F_2$	3524.789	164.5767	80	3560.189	125.8164	93	3600.000	0.0000	100
$F_3$	1.9182	0.1310	72	2.0000	0.000	100	2.0000	0.0000	100
$F_4$	-0.2726	0.0859	0	-0.1226	0.0358	0	-0.0125	0.0043	75

表 3 SGA、CLONALG、MSICSA 的算法复杂性比较

Tab. 3 Algorithm complexity of SGA、CLONALG、MSICSA

函数	SGA (计算次数)			CLONALG (计算次数)			MSICSA (计算次数)		
	最小值	平均值	标准差	最小值	平均值	标准差	最小值	平均值	标准差
$F_1$	10058	21512	5271	17455	25421	4821	28621	37454	5436
$F_2$	6210	9700	1759	5278	9452	2651	12485	16432	2643
$F_3$	7685	12647	3049	19864	32652	7881	24221	28654	2599
$F_4$	45368	78194	7881	65854	110682	27771	71287	89621	11321

表 3 数据显示,MSICSA 计算复杂性高于 CLONALG 和 SGA,但是随着优化问题维数的增加,这种差别在逐渐缩小。对于高维函数  $F_4$ ,MSICSA 计算复杂度均值与 SGA 不相上下,低于 CLONALG 方法。可以预见,兼具良好寻优能力的 MSICSA 算法,在处理高维复杂工程优化问题

时具有潜在的应用优势。

### 3.2 星载天线优化

结构轻量化是星载天线设计的普遍要求。某星载天线反射面结构如图 2 所示,主要由反射面和背架组成。其中背架为正八边形加“井”字加强筋结构。以最小化天线结构质量  $W$  为目标,建

立如下优化模型:



图2 星载天线实体模型

Fig.2 Solid model of space antenna

$$\max -W(T_0, R, H_1, T_1, H_2, T_2) \quad (10)$$

$$\begin{aligned} \text{s. t. } & \sigma_p - \sigma_1 \leq 0 \\ & \sigma_f - \sigma_2 \leq 0 \\ & \bar{\omega} - \omega_1 \leq 0 \\ & RMS \leq \delta \\ & T_{\max}, T_{\min} \subset [T_l, T_u] \end{aligned} \quad (11)$$

其中,设计变量  $T_0$  为反射面板厚度,  $R$  是正八边形加强筋外接圆半径,  $H_1$ 、 $T_1$  分别为八边形加强筋高度和厚度,  $H_2$ 、 $T_2$  分别为“井”字加强筋高度和厚度。约束条件包括,反射面结构最大应力  $\sigma_p$  小于相应材料许用应力  $\sigma_1$ ;加强筋结构最大应力  $\sigma_f$  小于相应材料许用应力  $\sigma_2$ ;反射面结构基频  $\omega_1$  大于设计指标  $\bar{\omega}$ ;面板在轨热变形  $RMS$  小于设计值;反射面天线的最高/低温度,  $T_{\max}$ 、 $T_{\min}$  在设计允许范围内。

反射面天线结构设计参数为,天线口径  $D = 1.5\text{m}$ ,焦径比  $F/D = 0.5$ 。反射面板是铝蜂窝芯加 kevlar 纤维蒙皮形成的夹心薄壳结构,背架为的铝合金结构。面板等效弹性模量为  $3.4\text{e}9$ ,泊松比为  $0.3$ ,密度为  $128\text{kg}/\text{m}^3$ ,热膨胀系数为  $2.3\text{e}-5$ 。背架弹性模量为  $6.67\text{e}10$ ,泊松比为  $0.3$ ,密度为  $2640\text{kg}/\text{m}^3$  热膨胀系数为  $2.47\text{e}-5$ 。

采用正交试验设计在设计空间进行采样和学科分析,针对采样结果建立各状态变量的代理近似模型,并在此基础上分别采用 SGA、CLONALG、MSICSA 进行优化。优化结果如表 4 所示,SGA、CLONALG、MSICSA 的优化结果分别比初始设计减少  $9.43\%$ 、 $11.61\%$  和  $16.55\%$ 。同时,MSICSA 的系统分析次数和 SGA 相近,较 CLONALG 有较大改善。

表4 星载天线的优化结果

Tab.4 Optimization results of space antenna

	初始设计	SGA	CLONALG	MSICSA
$T_0$ (mm)	5	4.26	4.53	4.02
$R$ (mm)	600	685.95	652.23	668.52
$H_1$ (mm)	20	18.63	15.26	18.96
$T_1$ (mm)	5	4.62	5.06	4.25
$H_2$ (mm)	25	20.16	26.25	23.56
$T_2$ (mm)	10	8.16	7.65	6.54
$W$ (kg)	6.89	6.24	6.09	5.75
迭代次数	/	2654	4657	2875

## 4 结论

本文基于免疫克隆选择学说,提出了一种基于种群分类的变尺度免疫克隆算法 (MSICSA)。MSICSA 算法通过目标函数到亲和度函数的非线性尺度变换,突出了全局最优解和普通解的差别,有利于优化问题的求解。通过对原始种群的分解,针对抗体的特点进行有区别的克隆和变异操作,实现了多个子群体的分工协作。通过自适应的步长调整加速了局部搜索效率,采用小生境技术克服了算法早熟并增强了全局搜索能力。几个典型函数优化和星载天线轻量化设计的试验表明,MSICSA 算法的寻优能力显著地优于 CLONALG 和 SGA。此外,对于高维优化问题求解,MSICSA 的计算复杂度并没有显著地增加。因此,MSICSA 算法对解决复杂的工程优化问题有很好的推广价值。

## 参考文献:

- [1] 莫宏伟. 人工免疫系统原理与应用[M]. 哈尔滨: 哈尔滨工业大学出版社, 2002.
- [2] 焦李成, 杜海峰, 刘芳, 公茂果. 免疫优化计算、学习与识别[M]. 北京: 科学出版社, 2006.
- [3] De Castro L N, Von Zuben F J. Learning and Optimization Using the Clonal Selection Principle [J]. IEEE Transactions on Evolutionary Computation, 2002, 6(3):239-251.
- [4] Kelsey J, Timmis J. Immune Inspired Somatic Contiguous Hypemutation for Function Optimization [C]//Proceedings of the Genetic and Evolutionary Computation Conference. Heidelberg: Springer Verlag, 2003, 2723:207-218.
- [5] Cutello V, Narzisi G, Nicosia G, et al. Clonal Selection Algorithms: A Comparative Case Study Using Effective Mutation Potentials [C]//Published in the Proceedings of ICARIS, 4th International Conference on Artificial Immune Systems, Banff, Canada, 2005.
- [6] 杜海峰, 焦李成, 刘若辰. 免疫优势克隆算法[J]. 电子与信息学报, 2004, 26(12).
- [7] 胡江强, 郭晨, 李铁山. 启发式自适应免疫克隆算法[J]. 哈尔滨工程大学学报, 2007, 28(1).
- [8] 钱海, 马建辉, 王煦法. 一种新的基于克隆选择原理的人工免疫算法[J]. 中国科技大学学报, 2008, 38(12).