

# 用于约束优化的人工免疫响应进化策略

公茂果<sup>1)</sup> 焦李成<sup>1)</sup> 杜海峰<sup>1),2)</sup> 马文萍<sup>1)</sup>

<sup>1)</sup>(西安电子科技大学智能信息处理研究所 西安 710071)

<sup>2)</sup>(西安交通大学机械工程学院 西安 710049)

**摘 要** 基于克隆选择学说及生物免疫响应过程的相关机理,探讨一种新的人工免疫系统模型——人工免疫响应,提出用于解决约束优化问题的人工免疫响应进化策略;基于算法网络拓扑结构的分析表明,新算法比传统的进化策略( $\mu, \lambda$ )-ES 具有更大的收敛概率. 对 10 个标准测试问题的测试结果表明,与采用随机排序的进化策略和采用动态惩罚函数的进化策略相比,新算法在收敛速度和求解精度上均具有一定的优势.

**关键词** 克隆选择;人工免疫系统;人工免疫响应;约束优化;进化策略

**中图法分类号** TP18

## A Novel Evolutionary Strategy Based on Artificial Immune Response for Constrained Optimizations

GONG Mao-Guo<sup>1)</sup> JIAO Li-Cheng<sup>1)</sup> DU Hai-Feng<sup>1),2)</sup> MA Wen-Ping<sup>1)</sup>

<sup>1)</sup>(Institute of Intelligent Information Processing, Xidian University, Xi'an 710071)

<sup>2)</sup>(School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049)

**Abstract** Based on the clonal selection theory and mechanisms of biological immune response, a novel artificial immune systems model, Artificial Immune Response (AIR), is discussed. And based on Artificial Immune Response a novel evolutionary strategy for constrained optimizations is put forward. Analysis of its network framework shows that the new algorithm is convergent with a higher probability than ( $\mu, \lambda$ ) evolutionary strategy. The experiments on 10 benchmark problems show that when compared with the ( $\mu, \lambda$ ) evolutionary strategies adopting stochastic ranking method and dynamic penalty function method, the new evolutionary strategy is capable of improving the search performance significantly no matter in convergent speed or precision.

**Keywords** clonal selection; artificial immune systems; artificial immune response; constrained optimizations; evolutionary strategy

## 1 引 言

20 世纪 80 年代, Farmer 等人<sup>[1]</sup>率先基于免疫网络学说给出了免疫系统的动态模型,并探讨了免

疫系统与其它人工智能方法的联系,开始了人工免疫系统的研究. 直到 1996 年 12 月,在日本首次举行的基于免疫性系统的国际专题讨论会上,首次提出了“人工免疫系统”(Artificial Immune System, AIS)的概念. 随后,人工免疫系统进入了兴盛发展

收稿日期:2004-12-09;修改稿收到日期:2006-08-18. 本课题得到国家自然科学基金重点项目(60133010,60372045)以及西安电子科技大学研究生创新基金(创 05004)资助. 公茂果,男,1979 年生,博士研究生,助教,主要研究方向为自然计算、数据挖掘、工程优化、图像处理. E-mail: maoguo\_gong@hotmail.com. 焦李成,男,1959 年生,博士,教授,博士生导师,主要研究领域为自然计算、数据挖掘、智能信息处理. 杜海峰,男,1972 年生,博士,副教授,主要研究方向为自然计算、智能信号处理以及智能控制与诊断. 马文萍,女,1981 年生,博士研究生,助教,主要研究方向为自然计算、数据挖掘、工程优化、图像处理.

时期, Dasgupta<sup>[2]</sup> 和焦李成<sup>[3]</sup> 等认为人工免疫系统已经成为人工智能领域理论和应用的研究热点, 相关论文和研究成果正在逐年增加. 1997 年和 1998 年 IEEE 国际会议还组织了相关专题讨论, 并成立了“人工免疫系统及应用分会”. Dasgupta<sup>[4]</sup> 在系统分析了人工免疫系统和人工神经网络的异同后, 指出自然免疫系统是人工智能方法灵感的重要源泉<sup>[2]</sup>. Gasper 等<sup>[5]</sup> 认为多样性是自适应动态的基本特征, 而 AIS 是比 GA 能更好地维护这种多样性的优化方法. 由于免疫系统本身的复杂性, 有关算法机理的描述还不多见. de Castro, Kim 等基于抗体克隆选择机理相继提出了克隆选择算法<sup>[6-8]</sup>, 但是, 将人工免疫系统算法应用到求解约束优化问题的有关成果还少见报道.

约束优化即非线性规划, 是几乎所有工程、运筹学和数学领域中非常重要的技术. 将进化算法应用于约束优化的主要问题是如何处理约束条件. 近年提出的处理约束的方法可以粗略地分类为拒绝方法、修补方法和惩罚函数法<sup>[9]</sup>. 其中, 惩罚函数法是一种最常用的约束条件处理方法, 但是传统的惩罚函数法对惩罚因子具有很强的依赖性, 需要根据具体的问题平衡惩罚函数与目标函数. 文献<sup>[10]</sup>提出了一种被称作随机排序的约束问题处理方法, 为进化计算求解相关问题提供了新思路, 获得了良好的效果.

本文基于解释生物免疫响应过程的相关理论, 提出了用于解决约束优化问题的人工免疫响应约束进化策略 (Artificial Immune Response Constrained Evolutionary Strategy, AIRCES), 该算法采用文献<sup>[10]</sup>提出的随机排序约束处理方法, 利用克隆增殖操作和克隆选择操作实现局部空间搜索, 利用克隆死亡操作对全局空间进行搜索, 对 10 个标准测试问题的测试结果表明, 与采用随机排序的进化策略<sup>[10]</sup> 和文献<sup>[11]</sup>中的进化策略相比, AIRCES 在收敛速度和求解精度上具有一定的优势.

本文第 2 节探讨人工免疫响应的四元组模型并定义抗原-抗体亲和度; 第 3 节阐述 AIRCES 算法的设计和操作流程; 第 4 节对算法进行具体的分析, 包括收敛性分析和种群多样性分析; 然后结合仿真实验结果对算法性能进行评价; 最后是结论和展望.

## 2 人工免疫响应模型及抗体—抗原亲和度定义

免疫响应是指免疫细胞对抗原分子的识别、活

化、分化和产生免疫效应的全过程. 免疫响应一般是由抗原引发、由多种免疫细胞参加的一系列反应<sup>[12]</sup>. 当免疫系统遇到新的抗原类型时, 会产生初次应答. 在初次应答期间, 免疫系统学习识别以前未见到的外部模式, 抗体基因频繁地变异和编辑, 抗体反应在经过免疫后得到改善, 即亲和力成熟 (affinity maturation). 1958 年 Burnet 等提出了著名的克隆选择学说, 对免疫响应的三大特征 (自身免疫禁忌、精细的特异性识别和免疫记忆) 做了合理解释, 其中心思想为, 抗体是天然产物, 以受体的形式存在于细胞表面, 抗原可与之选择性地反应. 抗原与相应抗体受体的反应可导致细胞克隆性增殖, 并分化为效应细胞, 执行高效而持久的免疫功能. 近年来的研究初步阐明, 机体对多样性外来抗原的选择识别能力来源于机体在免疫系统发育分化过程中对淋巴细胞的选择和删除, 通过基因重排产生多种多样的 T 细胞和 B 细胞克隆. B 细胞在抗体生成中的负调节作用 (即免疫耐受), 可能是克隆消亡 (clonal deletion), 也可能是克隆无反应 (clonal anergy). 如果不严格地区分 B 细胞和抗体, 可以认为在免疫反应过程中, 抗体可能是增殖、无反应或者消亡.

在人工免疫系统中完全套用生物学定义, 照搬生物学过程, 是不可能也不必要的. 本文给出一种新的人工免疫系统数学模型——人工免疫响应的四元组模型以及针对约束优化问题对抗体-抗原亲和度的定义.

### 2.1 人工免疫响应 (AIR)

人工免疫响应可以被描述为一个四元组  $Q = (G, I, R, A)$ , 其中  $G$  为引发免疫响应的外界刺激, 即抗原;  $I$  为所有可能抗体的集合;  $R$  为抗体间相互作用的规则集合;  $A$  为支配抗体反应、指导抗体进化的算法.

#### 2.1.1 抗原 $G$

在免疫学中, 抗原是一类能够诱导机体免疫应答并能与相应抗体或 T 细胞受体发生特异反应的物质. 在人工免疫系统中, 抗原一般指问题及其约束. 特别地, 针对约束优化问题

$$(P) \begin{cases} \text{Minimize} & f(\mathbf{x}) = f(x_1, x_2, \dots, x_n) \\ \text{Subject to} & g_i(\mathbf{x}) < 0, i = 1, 2, \dots, p \\ & h_j(\mathbf{x}) = 0, j = p + 1, p + 2, \dots, q \end{cases} \quad (1)$$

其中  $\mathbf{x} = (x_1, x_2, \dots, x_n)$ , 抗原是目标函数  $f(\mathbf{x})$  的函数, 记为  $G(\mathbf{x}) = g(f(\mathbf{x}))$ , 与免疫学中抗原的作用类似, 它是人工免疫系统算法的始动因子.

### 2.1.2 抗体空间 $I$

集合  $I = \{b_1, b_2, b_3, \dots, b_n\}$  被称作抗体空间, 是人工免疫响应中所有可能出现的抗体的集合, 其中  $n$  可以为无穷大的整数. 针对不同的抗原  $G$ , 抗体  $b$  的表现形式不同, 例如可以是二进制码串、实数序列、抽象的符号序列、特征序列等等. 抗体是人工免疫响应的基础, 其表现形式对抗体间相互作用的规则集合  $R$  的设计起着决定作用.

以字符串  $b = b_1 b_2 \dots b_l$  为例, 依生物学术语, 抗体  $b$  中,  $b_i$  被视为遗传基因, 其可能取值与编码方式有关. 在实践中, 常用的抗体编码方式有二进制和十进制. 例如, 一个抗体结构为八位二进制数, 则位串“0-1-1-1-0-1-0-0”即代表该抗体. 抗体群  $B = \{b_1, b_2, b_3, \dots, b_m\}$  为抗体  $b$  的  $m$  元组, 是抗体空间  $I$  的一个子集, 正整数  $m$  称为抗体群规模.

### 2.1.3 规则集合 $R$

抗体间相互作用的规则集合  $R = \{r_1, r_2, r_3, \dots, r_l\}$  描述了抗体空间  $I$  中所有抗体之间可能存在的作用形式. 一个规则  $r_i \in R$  可以从生物免疫系统中抗原与抗体间、抗体与抗体间的相互作用中启发得到. 对抗体群  $B = \{b_1, b_2, b_3, \dots, b_n\}$ , 一个规则  $r_i \in R$  可以简略地表示为

$$b_1 + b_2 + \dots + b_n \xrightarrow{r_i} b'_1 + b'_2 + \dots + b'_m \quad (2)$$

其中  $n, m$  为正整数,  $m$  的大小由规则  $r_i$  决定, 在这里“+”并不是传统意义上的操作算子, 只是为了对式(2)中各抗体之间进行分隔.

式(2)表示式子左边的  $n$  个抗体经过规则  $r_i$  的作用, 演变成式子右边的  $m$  个抗体. 为了细致地模拟生物免疫响应的过程, 应该尽量详尽地设计足够的规则, 从而实现对免疫响应过程的模拟. 针对约束优化问题, 本文设计的具体规则将在下文给出.

### 2.1.4 驱动算法 A

动态驱动算法 A 为模拟免疫系统中抗体进化过程以及支配免疫系统中抗体相互作用的算法, 包括规则集合  $R$  作用在抗体空间  $I$  中某一抗体群  $B$  上的具体方式以及人工免疫响应终止条件的判断等. 在人工免疫系统中, 终止条件一般设置为最大迭代次数或求解精度或者二者的结合. 算法 A 可以是任何迭代算法, 但是一般需要根据具体的问题进行设计. 针对约束优化问题, 本文设计的算法将在下文具体给出.

## 2.2 抗体-抗原亲和度 ( $A_g$ - $A_b$ Affinity)

抗体-抗原亲和度反映抗体与抗原之间的结合

力. 在人工免疫系统中, 一般指候选解对问题的适应性度量. 针对约束优化问题, 参考文献[10]中提出的约束问题处理方法, 本文定义抗体-抗原亲和度如下: 引入一个随机数  $P_f$ , 在问题的可行解空间内, 以概率 1 将目标函数值作为抗体-抗原亲和度, 在非可行解空间内以概率  $P_f$  将目标函数的归一化值作为抗体-抗原亲和度, 以概率  $1 - P_f$  将惩罚函数的归一化值作为抗体-抗原亲和度. 通过这种概率型的亲和度计算方式, 达到平衡目标函数和惩罚函数的目的. 这样, 两个抗体中某个抗体具有较高亲和度值(胜出)的概率为

$$P_w = P_{fw} P_f + P_{\phi w} (1 - P_f) \quad (3)$$

其中,  $P_{fw}$  为该抗体因目标函数值而胜出的概率,  $P_{\phi w}$  为该抗体因惩罚函数值而胜出的概率. 特别地, 当两个抗体都处在可行解区域时, 某个抗体胜出的概率  $P_w = P_{fw}$ .

## 3 规则与算法设计

在上述人工免疫响应模型的基础上, 针对约束优化问题设计合适高效的规则集  $R$  和驱动算法 A 将是本节的重点.

### 3.1 规则集 $R$ 的设计

受生物免疫响应过程的启发, 本文的规则集  $R$  主要包含以下克隆死亡操作  $r_1$ 、克隆增殖操作  $r_2$ 、基因变异操作  $r_3$  和克隆选择操作  $r_4$ .

#### 3.1.1 克隆死亡操作 $r_1$

克隆死亡操作  $r_1$  是对免疫学中免疫耐受现象的简单模拟. 免疫学中, B 细胞在抗体生成中的负调节作用可能是克隆消亡也可能是克隆无反应. 本文在此不加区分, 统一称为克隆死亡. 对抗体种群  $B = \{b_1, b_2, b_3, \dots, b_n\}$  的克隆死亡操作  $r_1$  定义为

$$b_1 + b_2 + \dots + b_n \xrightarrow{r_1} \alpha_1 b_1 + \alpha_2 b_2 + \dots + \alpha_n b_n \quad (4)$$

其中,  $\alpha_i b_i$  表示抗体  $b_i$  经过克隆死亡操作后在抗体群中存在  $\alpha_i$  个  $b_i$ , 系数  $\alpha_i$  是大于等于零的整数,  $\alpha_i = 0$  表示抗体  $b_i$  在人工免疫响应过程中呈现免疫耐受, 即克隆死亡. 造成抗体  $b_i$  克隆死亡的原因可能是因为抗体  $b_i$  具有较低的抗体-抗原亲和度值, 也有可能是因为抗体  $b_i$  与其它抗体具有相同的基因表现型, 而造成抗体群的整体多样性下降.  $\alpha_i > 1$  表示伴随免疫耐受现象所呈现的靶细胞正反馈免疫调节作用, 促使亲和度高的抗体(靶细胞)进行局部增殖, 即少数抗体因多样性下降或抗体-抗原亲和度较低而被删

除的同时,一些较优抗体占据了被删除抗体在抗体种群中的位置,从而表现为少数较优抗体复制代替较差抗体的现象,因而在克隆死亡过程中复制增殖的抗体只是整个抗体群中的少数. 为了保持算法的可持续性,一般有  $\alpha_1 + \alpha_2 + \dots + \alpha_n = n$ , 且局部增殖抗体等概率增殖.

### 3.1.2 克隆增殖操作 $r_2$

在免疫学中,克隆增殖是指通过无性繁殖(如细胞丝分裂)可连续传代并形成群体. 在人工免疫系统中,对抗体种群  $B = \{b_1, b_2, b_3, \dots, b_n\}$  的克隆增殖操作  $r_2$  定义为

$$b_1 + b_2 + \dots + b_n \xrightarrow{r_2} \{b_1^1 + b_1^2 + \dots + b_1^{q_1}\} + \{b_2^1 + b_2^2 + \dots + b_2^{q_2}\} + \dots + \{b_n^1 + b_n^2 + \dots + b_n^{q_n}\} \quad (5)$$

其中,  $b_i^j = b_i, i = 1, 2, \dots, n; j = 1, 2, \dots, q_i, q_i \in [1, n_c]$  为一自适应参数,也可以设定为一常数,  $n_c$  为设定的克隆比例上限,  $q_i = 1$  表示对抗体没有进行克隆增殖操作. 可见,上述克隆增殖过程与免疫学中的克隆增殖类似,是简单的无性繁殖过程. 与克隆死亡操作中的局部增殖不同,克隆增殖操作是对抗体群中的所有抗体进行复制. 同一个抗体  $b_i$  经过克隆增殖后形成的亚群体  $B_i(b_i^1, b_i^2, \dots, b_i^{q_i})$  中的所有抗体与抗体  $b_i$  具有完全相同的属性.

### 3.1.3 基因变异操作 $r_3$

基因变异操作  $r_3$  是对免疫系统学习识别外部模式、抗体基因变异和编辑过程的模拟. 对抗体种群  $B = \{b_1, b_2, b_3, \dots, b_n\}$  的基因变异操作  $r_3$  定义为

$$b_1 + b_2 + \dots + b_n \xrightarrow{r_3} b_1' + b_2' + \dots + b_n' \quad (6)$$

基因变异操作的基本内容是对抗体的某些基因位置上的基因值作变动. 就基于字符集  $\{0, 1\}$  的二值编码串而言,变异操作就是把某些基因位置上的基因值以概率取反,即  $1 \rightarrow 0$  或  $0 \rightarrow 1$ . 对实数编码串而言,可以采用均匀变异、高斯变异、柯西变异等随机变异策略. 针对约束优化问题,本文采用高斯变异,即

抗体  $b_i$  包含两个信息  $(x, \sigma)$ , 其中第一个向量  $x$  表示搜索空间中的一个点,而第二个向量  $\sigma$  表示标准差. 同理,后代  $b_i'$  也包含两个元素  $(x', \sigma')$ , 其中  $x'$  和  $\sigma'$  由下式产生:

$$\sigma' = \sigma e^{N(0, \Delta\sigma)} \quad (7)$$

$$x' = x + N(0, \Delta\sigma') \quad (8)$$

其中  $N(0, \Delta\sigma)$  是均值为 0, 标准差为  $\sigma$  的独立高斯随机数向量.

### 3.1.4 克隆选择操作 $r_4$

与进化算法中的选择操作不同,克隆选择操作  $r_4$  是从抗体各自克隆增殖后的子代中选择优秀的个体,从而形成新的种群,是一个无性选择过程.

对抗体群  $B(b_1^1, b_1^2, \dots, b_1^{q_1}, b_2^1, b_2^2, \dots, b_2^{q_2}, \dots, b_n^1, b_n^2, \dots, b_n^{q_n})$ , 克隆选择操作  $r_4$  定义如下

$$\{b_1^1 + b_1^2 + \dots + b_1^{q_1}\} + \{b_2^1 + b_2^2 + \dots + b_2^{q_2}\} + \dots + \{b_n^1 + b_n^2 + \dots + b_n^{q_n}\} \xrightarrow{r_4} b_1' + b_2' + \dots + b_n' \quad (9)$$

可见,克隆选择操作是克隆增殖操作的逆操作. 同一个抗体  $b_i$  经过克隆增殖后形成的亚群体在经过人工免疫系统的编辑后通过克隆选择操作实现局部的亲和度升高. 具体地,  $\forall i = 1, 2, \dots, n, \exists j \in \{1, 2, \dots, q_i\}$ , 使抗体  $b_i^j$  为亚群体  $B_i(b_i^1, b_i^2, \dots, b_i^{q_i})$  中亲和度最高的抗体,则在亚群体  $B_i(b_i^1, b_i^2, \dots, b_i^{q_i})$  中  $b_i^j$  的选择压力最大,即  $b_i' = b_i^j$  的概率最大,本文设置  $p(b_i' = b_i^j) = 1$ .

与生物进化系统有性别之分不同,免疫系统是一个无性系统,通过上述描述可以看出,规则集  $R = \{r_1, r_2, r_3, r_4\}$  中的 4 个规则均为无性操作过程,可以理解为人工免疫响应对免疫系统这一特点的简单刻画.

## 3.2 动态算法 A 的设计

针对约束优化问题,设定抗原  $G$  如式(1)所示,抗体-抗原亲和度定义按 2.2 节中所述,支配规则集  $R = \{r_1, r_2, r_3, r_4\}$  运作的动态算法设计如下.

**算法 1.** 人工免疫响应约束进化策略(AIRCES).

1. 设置算法初始参数:随机数  $P_f$ 、抗体群规模  $N$ 、克隆比例  $q$ 、克隆死亡比例  $d$  和基因变异概率  $P_m$ ; 随机产生初始抗体群  $B(0)$ ; 设定亲和度成熟条件; 令当前迭代次数  $k = 0$ ;
2. 若抗体群  $B(k)$  满足亲和度成熟条件,则输出  $B(k)$  中抗体-抗原亲和度最高的抗体,算法停止; 否则,转步 3;
3. 对抗体群  $B(k)$  执行克隆死亡操作  $r_1$ , 得到新的抗体群  $B^{(1)}(k)$ ;
4. 对抗体群  $B^{(1)}(k)$  执行克隆增殖操作  $r_2$ , 得到新的抗体群  $B^{(2)}(k)$ ;
5. 对抗体群  $B^{(2)}(k)$  执行基因变异操作  $r_3$ , 得到新的抗体群  $B^{(3)}(k)$ ;
6. 对抗体群  $B^{(3)}(k)$  执行克隆选择操作  $r_4$ , 得到新的抗体群  $B^{(4)}(k)$ ;
7. 令  $B(k+1) = B^{(4)}(k)$ ;  $k := k+1$ , 转步 2.

上述算法每一代进化可以理解为抗体群  $B(k)$  所处状态的 4 步转移过程,可以形象地用图 1 所示的网络诠释.




图1 人工免疫响应约束进化策略的网络拓扑结构

## 4 算法分析

### 4.1 收敛性分析

基于以前的工作基础<sup>[13]</sup>,从图1所示的特定网络结构中可以看出,人工免疫响应约束进化策略的网络拓扑结构是一个权值为确定值、网络节点变化的前向网络.对于任意的抗体编码空间和上文所述的抗体作用规则集合  $R = \{r_1, r_2, r_3, r_4\}$ ,有  $B(k+1) = g[B(k)]$

$$= g \left[ \bigcup_{i=1}^n \varphi^{-1} \left( \max \left( \bigcup_{j=1}^{\alpha_i \times q_i} \varphi(b_i(k) + \Delta b_{ij}(k)) \right) \right) \right] \quad (10)$$

其中  $\varphi(\cdot)$  表示抗体-抗原亲和度计算方法,  $\alpha_i$  和  $q_i$  的含义与上文相同,  $\Delta b_{ij}(k)$  为基因变异操作的变异尺度.特别地,当  $\alpha_i = 0$  时所对应的运算  $\bigcup_{j=1}^0 \varphi(b_i(k) + \Delta b_{ij}(k))$  表示空操作.对于该网络,需要调节的参数实际上有3个,  $\alpha_i$ ,  $q_i$  和  $\Delta b_{ij}(k)$ .其中,  $\alpha_i$  和  $q_i$  控制了网络的结构.  $\Delta b_{ij}(k)$  直接影响到算法的效率和性能.基于李雅普洛夫稳定性定理<sup>[14]</sup>,本节通过分析算法的网络拓扑结构,推导出算法的收敛条件.

设定偏差  $e = |y^d - y^*| = y^* - y^d$ , 其中  $y^d$  是问题的理想解,  $y^*$  是网络输出的最优解,则  $y^*(k) = \varphi(b^*(k))$ ,  $b^*(k)$  为  $k$  次迭代后的最优抗体.

取离散李雅普洛夫函数为

$$V(k) = \frac{e^2(k)}{2} = \frac{(y^d - y^*(k))^2}{2} \quad (11)$$

于是有

$$\begin{aligned} \Delta V(k) &= V(k+1) - V(k) \\ &= \frac{1}{2} (e^2(k+1) - e^2(k)) \\ &= (e(k+1) - e(k)) \times \end{aligned}$$

$$\begin{aligned} & \left( e(k) + \frac{1}{2} (e(k+1) - e(k)) \right) \\ &= \Delta e(k) (e(k) + \frac{1}{2} \Delta e(k)) \end{aligned} \quad (12)$$

其中  $\Delta e(k) = e(k+1) - e(k)$ . 显然  $\Delta V(k) < 0$  的必要条件是  $\Delta e(k) \times e(k) < 0$ , 考虑到  $e \geq 0$ , 因此,在相平面内,人工免疫响应约束进化策略所形成的相轨迹最后只有落入第四象限,才能保证算法收敛.用一阶泰勒级数逼近得

$$\begin{aligned} e(k+1) - e(k) &= \left[ \frac{\partial e(k)}{\partial b^*} \right]^T \times [b^*(k+1) - b^*(k)] + \\ & o[b^*(k+1) - b^*(k)] \end{aligned} \quad (13)$$

又因

$$\begin{aligned} y^*(k+1) &= y^*(k) + \left[ \frac{\partial y^*(k)}{\partial b^*} \right]^T \times \\ & [b^*(k+1) - b^*(k)] + o[b^*(k+1) - b^*(k)] \end{aligned} \quad (14)$$

所以  $\frac{\partial e(k)}{\partial b^*} = \frac{\partial y^*(k)}{\partial b^*}$ , 且

$$\begin{aligned} y^*(k+1) - y^*(k) &= \Delta e(k) = \left[ \frac{\partial y^*(k)}{\partial b^*} \right]^T \times \\ & [b^*(k+1) - b^*(k)] + o[b^*(k+1) - b^*(k)] \end{aligned} \quad (15)$$

令  $b^*(k+1) - b^*(k) = \Delta b^*(k)$ , 则

$$\begin{aligned} \Delta V(k) &\approx \left[ \frac{\partial e(k)}{\partial b^*} \right]^T \times \\ & \Delta b^*(k) \left\{ e(k) + \left[ \frac{\partial e(k)}{\partial b^*} \right]^T \times \Delta b^*(k) \right\} \end{aligned} \quad (16)$$

若  $\Delta b^*(k) = \eta \nabla \varphi = \eta \frac{\partial y^*(k)}{\partial b^*}$ ,  $\eta$  为搜索步长, 则

$$\Delta V(k) \approx - \left\| \frac{\partial y^*(k)}{\partial b^*} \right\|^2 \left( \eta e(k) - \eta^2 \left\| \frac{\partial y^*(k)}{\partial b^*} \right\|^2 \right) \quad (17)$$

要使  $\Delta V(k) < 0$ , 当且仅当

$$\eta e(k) - \eta^2 \left\| \frac{\partial y^*(k)}{\partial b^*} \right\|^2 > 0 \quad (18)$$

即

$$0 < \eta < \frac{e(k)}{\left\| \frac{\partial y^*(k)}{\partial b^*} \right\|^2} \quad (19)$$

因此,如果抗体沿着抗体-抗原亲和度函数的梯度方向进化且步长由式(19)确定,则算法是收敛的,且算法所刻画动态过程是渐近稳定的.但是,由于以进化算法为代表的仿生算法的生物机理决定了算法应该更加重视对基因的操作,另一方面,目标函数(适应度函数或者抗体-抗原亲和度函数)的梯度甚至目标函数本身在很多情况下都难有确切的表达式.因此,在实际过程中,上述收敛条件在仿生算法中一般难以严格满足.

但是,针对特定的规则集合  $R=\{r_1, r_2, r_3, r_4\}$ ,由式(4),(5)可以得出, AIRCES 算法对抗体群  $B(k)$  中的最优抗体  $b^*=b_{\text{best}}(k)$  在一步迭代过程中沿着  $\alpha_{\text{best}} \times q_{\text{best}}$  个不同的方向以式(8)所示的变异方式进化,即

$$\Delta b^*(k) = \eta \frac{\partial y^*(k)}{\partial b^*} = N(0, \Delta \sigma') \quad (20)$$

$$\text{因此 } \eta = \left\| \frac{N(0, \Delta \sigma')}{\frac{\partial y^*(k)}{\partial b^*}} \right\|, \text{ 代入式(19)得到}$$

$$0 < \left\| \frac{N(0, \Delta \sigma')}{\frac{\partial y^*(k)}{\partial b^*}} \right\| < \frac{e(k)}{\left\| \frac{\partial y^*(k)}{\partial b^*} \right\|^2} \quad (21)$$

因此有

$$0 < \|N(0, \Delta \sigma')\| < \frac{e(k)}{\left\| \frac{\partial y^*(k)}{\partial b^*} \right\|} \quad (22)$$

特别地,对于凸规划,在搜索方向满足收敛条件的情况下,有  $\left\| \frac{e(k)}{\frac{\partial y^*(k)}{\partial b^*}} \right\| > 1$ , 因此,只要保证式(8)中的  $0 < \|N(0, \Delta \sigma')\| < 1$ , 就能满足收敛条件对搜索步长的要求。

已有理论证明,保留当代最优个体的进化算法是以概率 1 收敛的<sup>[15-16]</sup>. 我们在以前的工作中基于 Markov 链理论已经证明了,相应的人工免疫系统算法同样具有以概率 1 收敛的特性<sup>[17-20]</sup>. 但是,这种意义上的收敛概率为 1 是在迭代次数趋向于无穷大时才成立的,而对于约束优化或者更具体的工程优化问题,在有限的迭代次数内找到全局最优才是算法有效性的客观评价. 因此,在有限的迭代次数内让算法以最大的概率收敛到全局最优,是评价算法性能的核心问题. 以上基于算法网络拓扑结构的算法收敛条件的分析表明,采用规则集  $R=\{r_1, r_2, r_3, r_4\}$  的人工免疫响应约束进化策略的最优抗体在一步迭代过程中将沿着  $N_1 = \alpha_{\text{best}} \times q_{\text{best}}$  个不同的方向搜索,而相应的进化策略  $(\mu, \lambda)$ -ES<sup>[11]</sup> 的最优抗体在一步迭代过程中将沿着  $N_2 = \lambda / \mu$  个不同的方向搜索. 因此,只要令克隆死亡比例  $d = 1 - \mu / \lambda$ , 则  $\alpha_{\text{best}} = \lambda / \mu$ , 于是  $\frac{N_1}{N_2} =$

$\frac{\alpha_{\text{best}} \times q_{\text{best}}}{\lambda / \mu} = q_{\text{best}}$ , 即 AIRCES 中最优个体在一步迭代过程中的搜索方向是  $(\mu, \lambda)$ -ES 的  $q_{\text{best}}$  倍. 特别的,针对本文所要解决的约束优化问题以及为之设计的高斯变异搜索算子,式(22)表明,通过控制高斯随机数的均值和方差,很容易满足收敛条件对搜索步长的要

求. 因此,在合理的取值范围内  $(\mu \geq 1, \lambda > \mu)$ ,  $(\mu, \lambda)$ -ES 无论如何修改  $\mu$  和  $\lambda$  的取值,规则集  $R=\{r_1, r_2, r_3, r_4\}$  均能保证 AIRCES 满足式(19)的概率是  $(\mu, \lambda)$ -ES 的  $q_{\text{best}}$  倍.

于是可以得到如下结论:采用规则集  $R=\{r_1, r_2, r_3, r_4\}$  的人工免疫响应约束进化策略 AIRCES 与进化策略  $(\mu, \lambda)$ -ES 相比,在有限的迭代次数内收敛到全局最优的概率更大.

#### 4.2 种群多样性保持

在上一节收敛性分析过程中可能存在这样的疑问:在有效个体数目相同且克隆死亡比例  $d = 1 - \mu / \lambda$  的情况下,虽然 AIRCES 中的优秀个体比  $(\mu, \lambda)$ -ES 中的优秀个体具有更强的搜索能力,但是这是以牺牲种群整体多样性为代价的. 我们认为在规则集  $R=\{r_1, r_2, r_3, r_4\}$  中,由克隆选择操作  $r_4$  和克隆死亡操作  $r_1$  分步完成的选择操作不同于传统进化策略基于  $(\mu, \lambda)$  的选择操作, AIRCES 算法通过局部择优操作  $r_4$  和全局择优操作  $r_1$  分步完成来保持种群多样性,这一点从图 1 所示网络的第四层节点到第五层节点的转移过程可以形象地看出. 但是,要从理论上证明 AIRCES 与  $(\mu, \lambda)$ -ES 在种群多样性保持上能力相当确实比较困难. 一些研究者采用个体在目标空间的分布标准差(或方差)来衡量进化算法的种群多样性<sup>[21-23]</sup>, 结合本文的算法我们设计以下实验,进一步说明基于人工免疫响应的约束进化策略 AIRCES 与文献[10]所述的约束进化策略(记为 RY)具有相近的保持种群多样性的能力.

设置算法 AIRCES 的运行参数如下:  $P_f = 0.45$ , 抗体群规模  $N = 100$ , 克隆比例  $q = 2$ , 变异概率  $P_m = 1$ , 克隆死亡比例  $d = 1 - \mu / \lambda$ ,  $\mu / \lambda$  的值参考文献[16]取为  $1/7$ . 设置算法 RY 的运行参数为文献[10]中所述的最优运行参数. 在上述参数设置下,两种算法每代函数值评价次数均为 200, 运算复杂度相当,分别用算法 AIRCES 和 RY 解决标准测试问题中的 G01 和 G04 并记录下迭代过程中种群中所有可行解对应目标函数值的标准差的进化过程,独立运行 30 次取均值,结果如图 2 所示.

图 2 中‘ $\nabla$ ’表示 AIRCES 算法迭代过程中种群中所有可行解对应目标函数值的标准差的进化轨迹,‘ $*$ ’表示 RY 算法迭代过程中种群中所有可行解对应目标函数值的标准差的进化轨迹. 从图中看出,对测试问题 G01,在进化过程中, AIRCES 算法比 RY 具有更好的种群多样性,对测试问题 G04, AIRCES 算法的种群多样性又稍差于 RY.





图2 AIRCES 与 RY 解决 G01 和 G04 时所呈现的种群多样性随进化代数的变化情况

## 5 仿真实验与结果分析

### 5.1 测试问题描述

本文选用以下 10 个标准约束优化测试问题对算法性能进行测试,所有函数均已在文献[10]中有所描述.

G01:

$$\text{Minimize } f(x) = 5 \sum_{i=1}^4 x_i - 5 \sum_{i=1}^4 x_i^2 - \sum_{i=5}^{13} x_i$$

Subject to

$$g_1(x) = 2x_1 + 2x_2 + x_{10} + x_{11} - 10 \leq 0;$$

$$g_2(x) = 2x_1 + 2x_3 + x_{10} + x_{12} - 10 \leq 0;$$

$$g_3(x) = 2x_1 + 2x_3 + x_{11} + x_{12} - 10 \leq 0;$$

$$g_4(x) = -8x_1 + x_{10} \leq 0;$$

$$g_5(x) = -8x_2 + x_{11} \leq 0;$$

$$g_6(x) = -8x_3 + x_{12} \leq 0;$$

$$g_7(x) = -2x_4 - x_5 + x_{10} \leq 0;$$

$$g_8(x) = -2x_6 - x_7 + x_{11} \leq 0;$$

$$g_9(x) = -2x_8 - x_9 + x_{12} \leq 0.$$

其中,  $0 \leq x_i \leq 1 (i=1, 2, \dots, 9)$ ;  $0 \leq x_i \leq 100 (i=10, 11, 12)$ ;  $0 \leq x_{13} \leq 1$ .

全局最优值在  $x^* = (1, 1, 1, 1, 1, 1, 1, 1, 1, 3, 3, 3, 1)$ ,  $f(x^*) = -15$ .

G02:

$$\text{Maximize } f(x) = \left| \frac{\sum_{i=1}^n \cos^4(x_i) - 2 \prod_{i=1}^n \cos^2(x_i)}{\sqrt{\sum_{i=1}^n i x_i^2}} \right|$$

$$\text{Subject to } g_1(x) = 0.75 - \prod_{i=1}^n x_i \leq 0;$$

$$g_2(x) = \sum_{i=1}^n x_i - 7.5n \leq 0.$$

$n=20$  且  $0 \leq x_i \leq 10 (i=1, 2, \dots, n)$

目前找到的最优值为  $f(x^*) = 0.803619$ , 其中  $g_1 = -10^{-8}$ .

G03:

$$\text{Maximize } f(x) = (\sqrt{n})^n \prod_{i=1}^n x_i$$

$$\text{Subject to } h(x) = \sum_{i=1}^n x_i^2 - 1 = 0.$$

$n=10$  且  $0 \leq x_i \leq 1 (i=1, 2, \dots, n)$ , 全局最大值在  $x_i^* = 1/\sqrt{n} (i=1, 2, \dots, n)$ ,  $f(x^*) = 1$ .

G04:

$$\text{Minimize } f(x) = 5.3578547x_3^2 + 0.8356891x_1x_5 + 37.293239x_1 - 40792.141$$

Subject to

$$g_1(x) = 85.334407 + 0.0056858x_2x_5 + 0.0006262x_1x_4 - 0.0022053x_3x_5 - 92 \leq 0;$$

$$g_2(x) = 85.334407 - 0.0056858x_2x_5 - 0.0006262x_1x_4 + 0.0022053x_3x_5 \leq 0;$$

$$g_3(x) = 80.51249 + 0.0071317x_2x_5 + 0.0029955x_1x_2 + 0.0021813x_3^2 - 110 \leq 0;$$

$$g_4(x) = -80.51249 - 0.0071317x_2x_5 - 0.0029955x_1x_2 - 0.0021813x_3^2 + 90 \leq 0;$$

$$g_5(x) = 9.300961 + 0.0047026x_3x_5 + 0.0012547x_1x_3 + 0.0019085x_3x_4 - 25 \leq 0;$$

$$g_6(x) = -9.300961 - 0.0047026x_3x_5 - 0.0012547x_1x_3 - 0.0019085x_3x_4 + 20 \leq 0;$$

其中,  $78 \leq x_1 \leq 102$ ;  $33 \leq x_2 \leq 45$ ;  $27 \leq x_i \leq 45 (i=3, 4, 5)$ .

最优值在  $x^* = (78, 33, 29.995256025682, 45, 36.775812905788)$ ,  $f(x^*) = -30665.539$ .

G05:

$$\text{Minimize } f(x) = (x_1 - 10)^3 + (x_2 - 20)^3$$

Subject to  $g_1(x) = -(x_1 - 5)^2 - (x_2 - 5)^2 + 100$   
 $\leq 0; g_2(x) = (x_1 - 6)^2 + (x_2 - 5)^2 -$   
 $82.81 \leq 0.$

其中,  $13 \leq x_1 \leq 100; 0 \leq x_2 \leq 100.$

最优值在  $x^* = (14.095, 0.84296), f(x^*) =$   
 $-6961.81388.$

G06:

Maximize  $f(x) = \frac{\sin^3(2\pi x_1) \sin(2\pi x_2)}{x_1^3(x_1 + x_2)}$

Subject to

$g_1(x) = x_1^2 - x_2 + 1 \leq 0;$   
 $g_2(x) = 1 - x_1 + (x_2 - 4)^2 \leq 0.$

其中,  $0 \leq x_1 \leq 10; 0 \leq x_2 \leq 10.$

最优值在  $x^* = (1.2279713, 4.2453733),$  最优  
值为  $f(x^*) = 0.095825.$

G07:

Minimize  $f(x) = (x_1 - 10)^2 + 5(x_2 - 12)^2 +$   
 $x_3^4 + 3(x_4 - 11)^2 + 10x_5^6 + 7x_6^2 + x_7^4 -$   
 $4x_6x_7 - 10x_6 - 8x_7$

Subject to

$g_1(x) = -127 + 2x_1^2 + 3x_2^4 + x_3 + 4x_4^2 + 5x_5 \leq 0;$   
 $g_2(x) = -282 + 7x_1 + 3x_2 + 10x_3^2 + x_4 - x_5 \leq 0;$   
 $g_3(x) = -196 + 23x_1 + x_2^2 + 6x_6^2 - 8x_7 \leq 0;$   
 $g_4(x) = 4x_1^2 + x_2^2 - 3x_1x_2 + 2x_3^2 + 5x_6 - 11x_7 \leq 0.$

其中,  $-10 \leq x_i \leq 10 (i=1, 2, \dots, 7),$

最优值在  $x^* = (2.330499, 1.951372, -0.4775414,$   
 $4.365726, -0.6244870, 1.038131, 1.594227),$  最优值为  
 $f(x^*) = 680.6300573.$

G08:

Minimize  $f(x) = x_1^2 + (x_2 - 1)^2$

Subject to  $h(x) = x_2 - x_1^2 = 0.$

其中,  $-1 \leq x_1 \leq 1, -1 \leq x_2 \leq 1,$

最优值在  $x^* = (\pm 1/\sqrt{2}, 1/2),$  最优值为  
 $f(x^*) = 0.75.$

G09:

Maximize  $f(x) = (100 - (x_1 - 5)^2 - (x_2 - 5)^2 -$   
 $(x_3 - 5)^2)/100$

Subject to  $g(x) = (x_1 - p)^2 + (x_2 - q)^2 +$   
 $(x_3 - r)^2 - 0.0625 \leq 0.$

其中,  $0 \leq x_i \leq 10 (i=1, 2, 3), p, q, r=1, 2, \dots, 9,$

最优值在  $x^* = (5, 5, 5),$  最优值为  $f(x^*) = 1.$

G10:

Minimize  $f(x) = e^{x_1x_2x_3x_4x_5}$

Subject to

$h_1(x) = x_1^2 + x_2^2 + x_3^2 + x_4^2 + x_5^2 - 10 = 0;$   
 $h_2(x) = x_2x_3 - 5x_4x_5 = 0;$   
 $h_3(x) = x_1^3 + x_2^3 + 1 = 0.$

其中,  $-2.3 \leq x_i \leq 2.3 (i=1, 2); -3.2 \leq x_i \leq 3.2$   
 $(i=3, 4, 5).$

最优值在  $x^* = (-1.717143, 1.595709,$   
 $1.827247, -0.7636413, -0.763645),$  最优值为  
 $f(x^*) = 0.0539498.$

5.2 测试结果及性能评价

表 1 所示的结果为本文提出的人工免疫响应约束进化策略(AIRCES)与文献[10]所述的基于随机排序的约束进化策略(记为 RY)以及文献[11]所述基于动态惩罚函数法的约束进化策略(记为 KM)在解决上述约束问题时的性能比较. 其中算法 AIRCES 的运行参数如下:  $P_f = 0.45,$  抗体群规模  $N = 100,$  克隆比例  $q = 2,$  克隆死亡比例  $d = 1 - \mu/\lambda = 0.857$  和个体变异概率  $P_m = 1.$  算法 RY 和 KM 的运行参数按文献[10]中的最优参数设置. 在上述情况下, 针对一个测试问题, KM 算法需要评价函数值  $70 \times 20000$  次, RY 算法和 AIRCES 算法只需要评价  $200 \times 1750$  次. 对每个测试问题独立运行 30 次, 表 1 中最优结果表示对每次运行得到的最优解的 30 次统计平均, 平均结果表示对每次运行得到的所有解平均值的 30 次统计平均, 最差结果表示对每次运行得到的最差解的 30 次统计平均.

表 1 AIRCES、RY 和 KM 三种算法的测试结果

问题	Optimal	统计项	统计结果		
			AIRCES	RY	KM
G01	-15.000	最优结果	-15.000	-15.000	-14.7864
		平均结果	-15.000	-15.000	-14.7082
		最差结果	-15.000	-15.000	-14.6154
G02	-0.803619	最优结果	-0.803575	-0.803515	-0.79953
		平均结果	-0.779465	-0.781975	-0.79671
		最差结果	-0.716312	-0.726688	-0.79119
G03	-1.000	最优结果	-1.000	-1.000	-0.9997
		平均结果	-1.000	-1.000	-0.9989
		最差结果	-0.999	-1.000	-0.9978
G04	-30665.539	最优结果	-30665.539	-30665.539	-30664.5
		平均结果	-30665.539	-30665.539	-30655.3
		最差结果	-30665.539	-30665.539	-30645.9



(续 表)

问题	Optimal	统计项	统计结果		
			AIRCES	RY	KM
G05	-6961.814	最优结果	-6961.814	-6961.814	-6952.1
		平均结果	-6695.987	-6875.940	-6342.6
		最差结果	-6030.333	-6350.262	-5473.9
G06	-0.095825	最优结果	-0.095825	-0.095825	-0.095825
		平均结果	-0.095825	-0.095825	-0.0891568
		最差结果	-0.095825	-0.095825	-0.0291438
G07	680.630	最优结果	680.630	680.630	680.91
		平均结果	680.652	680.656	681.16
		最差结果	680.801	680.763	683.18
G08	0.750	最优结果	0.750	0.750	0.75
		平均结果	0.750	0.750	0.75
		最差结果	0.750	0.750	0.75
G09	-1.000000	最优结果	-1.000000	-1.000000	-0.999999857
		平均结果	-1.000000	-1.000000	-0.999134613
		最差结果	-1.000000	-1.000000	-0.991950498
G10	0.053950	最优结果	0.053950	0.053957	0.054
		平均结果	0.054716	0.057006	0.064
		最差结果	0.440825	0.216915	0.557

表 2 AIRCES 和 RY 算法获得表 1 所示最优结果所需进化代数 30 次运行的中值

	中值									
	G01	G02	G03	G04	G05	G06	G07	G08	G09	G10
AIRCES	621	1316	1094	348	16	124	592	66	62	340
RY	741	1086	1146	441	590	381	557	57	82	349

从表 1 中可以看出, AIRCES 与 RY 算法求得的最优结果明显优于 KM 算法求得的最优结果, 而对测试问题 G02 和 G10, AIRCES 算法又能找到比 RY 算法更优的结果, 对其它 8 个测试问题, AIRCES 与 RY 算法能找到同等精度的结果. 从表 1 中可以看出, 对测试问题 G01, G06 和 G10, AIRCES 和 RY 算法求得平均结果明显优于 KM 算法, 而对于测试问题 G10, AIRCES 算法又明显优于 RY 算法, 但是对于测试问题 G02, AIRCES 和 RY 算法又劣于 KM 算法, 对测试问题 G05, AIRCES 和 KM 算法又劣于 RY 算法. 从表 1 中可以看出, 对测试问题 G01, G03, G04, G05, G06, G07, G09 和 G10, KM 算法得到的最差结果明显较差. 从表 2 中可以看出, 对测试问题 G01, G03, G04, G05, G06, G09 和 G10, AIRCES 算法获得表 1 所示的最优结果所需进化代数要少于 RY 算法, 特别是对测试问题 G05 和 G06, AIRECS 算法的全局收敛速度远远快于 RY 算法. 但是对测试问题 G02, G07 和 G08, AIRECS 算法的收敛速度又略低于 RY 算法.

评价一个算法的好坏, 求解精度和收敛速度是两个最重要的指标, 综合考虑以上的结果, 可以得出以下结论:

(1) 考虑求解精度时, 对测试问题 G02 和 G10, AIRCES 算法要优于 RY 算法, 而对其它 8 个测试

问题, AIRCES 与 RY 算法具有同样的求解精度; 对 10 个测试问题, AIRCES 算法均优于 KM 算法.

(2) 考虑收敛速度时, 对测试问题 G01, G03, G04, G05, G06, G09 和 G10, 算法 AIRCES 优于 RY, 对测试问题 G02, G07 和 G08, 算法 AIRCES 略差于 RY; 而得到上述测试结果 AIRCES 和 RY 算法只需要 KM 算法约四分之一的计算量.

### 6 结论与展望

本文基于解释生物免疫响应过程的相关理论, 提出了一种新的人工免疫系统模型——人工免疫响应的四元组模型, 提出了用于解决约束优化问题的人工免疫响应进化策略, 该算法采用文献[10]提出的随机排序约束处理方法, 利用克隆增殖操作和克隆选择操作实现局部空间的搜索, 利用克隆死亡操作对全局空间进行搜索; 基于算法的网络拓扑结构, 分析出与传统进化策略( $\mu, \lambda$ )-ES 相比, AIRCES 算法具有更大的收敛概率. 对 10 个标准测试问题的测试结果表明, 与采用随机排序的进化策略和采用动态惩罚函数法的进化策略相比, AIRCES 算法在求解精度上具有一定的优势; 在收敛速度上, 虽然对测试问题 G02, G07 和 G08, 新算法稍显逊色, 但是对其它 7 个测试问题, 新算法具有明显优势.

“没有免费的午餐理论”<sup>[24]</sup>指出,任何一种算法想在所有问题上占尽优势是不可能的,一种新算法只能在特定问题和特定评价标准上而被肯定,因此,与新算法的进一步推广同等重要的另一个任务就是算法适用对象的分析与界定。

**致 谢** 感谢 Mr. Runarsson 和 Professor Yao Xin 无偿提供参考文献[10]的源程序,为我们进行算法性能的比较和工作的开展提供了帮助!

## 参 考 文 献

- [1] Farmer J D, Packard N H, Perelson A S. The immune system, adaptation, and machine learning. *Physica D*, 1986, 22: 187-204
- [2] Dasgupta D., Forrest S.. Artificial immune systems in industrial applications//Proceedings of the 2nd International Conference on Intelligent Processing and Manufacturing of Materials, Hawaii, USA, 1999: 257-267
- [3] Jiao Li-cheng, Du Hai-feng. Artificial immune system: Progress and prospect. *Acta Electronica Sinica*, 2003, 31(10): 1540-1548  
(焦李成, 杜海峰. 人工免疫系统进展与展望. 电子学报, 2003, 31(10): 1540-1548)
- [4] Dasgupta D.. Artificial neural networks and artificial immune systems: Similarities and differences//Proceedings of the 1997 IEEE International Conference on Computational Cybernetics and Simulation, Orlando, Florida, USA, 1997: 873-8781
- [5] Gasper A., Collard P.. From GAs to artificial immune systems: Improving adaptation in time dependent optimization//Proceedings of the Congress on Evolutionary Computation (CEC'99), Washington DC, USA, 1999: 1859-1866
- [6] de Castro L. N., Von Zuben F. J.. The clonal selection algorithm with engineering applications//Proceedings of the Genetic and Evolutionary Computation Conference. Morgan Kaufmann, Las Vegas, 2000: 36-37
- [7] Kim J., Bentley P. J.. Towards an artificial immune system for network intrusion detection: An investigation of clonal selection with a negative selection operator//Proceedings of the Congress on Evolutionary Computation (CEC'01), Seoul, Korea, 2001: 1244-1252
- [8] Du Hai-feng, Jiao Li-cheng, Wang Sun-An. Clonal operator and antibody clone algorithms//Proceedings of the 1st International Conference on Machine Learning and Cybernetics, Beijing, China, 2002: 506-510
- [9] Gen Mitsuo, Cheng Run-Wei. Genetic Algorithm and Engineering optimization. New York: John Wiley & Sons Inc, 1999
- [10] Runarsson T. P., Yao Xin. Stochastic ranking for constrained evolutionary optimization. *IEEE Transactions on Evolutionary Computation*, 2000, 4(3): 284-294
- [11] Koziel S., Michalewicz Z.. Evolutionary algorithms, homophous mapping, and constrained parameter optimization. *Evolutionary Computation*, 1999, 7(1): 19-44
- [12] Dong Zhi-Wei, Wang Yan. Antibody Engineering. Beijing: Beijing Medical University and Peking Union Medical College Press, 1997(in Chinese)  
(董志伟, 王琰. 抗体工程. 北京: 北京医科大学、中国协和医科大学联合出版社, 1997)
- [13] Du Hai-Feng, Jiao Li-Cheng, Gong Mao-Guo, Liu Ruo-Chen. Immune clonal selection network and learning algorithm. *Pattern Recognition and Artificial Intelligence*, 2005, 18(2): 198-204(in Chinese)  
(杜海峰, 焦李成, 公茂果, 刘若辰. 一种免疫克隆选择网络及其学习算法. 模式识别与人工智能, 2005, 18(2): 198-204)
- [14] Liu Bao. Modern Control Theory. Beijing: China Machine Press, 1998(in Chinese)  
(刘豹主编. 现代控制理论. 北京: 机械工业出版社, 1998)
- [15] Rudolph G.. Convergence analysis of canonical genetic algorithms. *IEEE Transactions on Neural Networks*, 1994, 5(1): 96-101
- [16] Bäck T.. Evolutionary Algorithms in Theory and Practice. New York: Oxford University Press, 1996
- [17] Du Hai-Feng, Gong Mao-Guo, Jiao Li-Cheng, Liu Ruo-Chen. A novel artificial immune system algorithm for high-dimensional function numerical optimization. *Progress in Natural Science*, 2005, 15(5): 463-471
- [18] Du Hai-Feng, Gong Mao-Guo, Liu Ruo-Chen, Jiao Li-Cheng. Adaptive chaos clonal evolutionary programming algorithm. *Science in China: Series F—Information Sciences*, 2005, 48(5): 579-595
- [19] Gong Mao-Guo, Jiao Li-Cheng, Du Hai-Feng, Wang Ling. An artificial immune system algorithm for CDMA multiuser detection over multi-path channels//Proceedings of the Genetic and Evolutionary Computation Conference (GECCO 2005), Washington D. C., 2005: 2105-2111
- [20] Gong Mao-Guo, Du Hai-Feng, Jiao Li-Cheng. Optimal approximation of linear systems by artificial immune response. *Science in China: Series F—Information Sciences*. Science in China Press, co-published with Springer-Verlag GmbH, 2006, 49(1): 63-79
- [21] Qi Xiao-Feng, Palmieri F.. Theoretical analysis of evolutionary algorithms with an infinite population size of continuous space, part II: Analysis of the diversification role of crossover. *IEEE Transactions on Neural Networks*, 1994, 5(1): 120-129
- [22] Zhang Xiao-Hui, Dai Guan-Zhong, Xu Nai-Ping. Study on diversity of population in genetic algorithms. *Control Theory and Applications*, 1998, 15(1): 404-407(in Chinese)

(张晓缙, 戴冠中, 徐乃平. 遗传算法种群多样性的分析研究. 控制理论与应用, 1998, 15(1): 404-407)

[23] Wang Cheng-Dong, Zhang You-Yun. Adaptive pseudo-parallel genetic algorithm based on real coding. Journal of Xi'an Jiaotong University, 2003, 37(7): 707-710(in Chinese)

(王成栋, 张优云. 基于实数编码的自适应伪并行遗传算法. 西安交通大学学报, 2003, 37(7): 707-710)

[24] Wolpert D. H., Macready W. G.. No free lunch theorems for search. Santa Fe, NM: Santa Fe Institute. Technical Report: SFI-TR-05-010, 1995



**GONG Mao-Guo**, born in 1979, Ph. D. candidate. His research interests include natural computation, data mining, engineering optimization, and image processing.

**JIAO Li-Cheng**, born in 1959, Ph.D., professor, Ph.D. supervisor. His research interests include natural computa-

tion, data mining, and intelligent information processing.

**DU Hai-Feng**, born in 1972, Ph. D., associate professor. His research interests include natural computation, intelligent signal processing, and intelligent control and diagnosis.

**MA Wen-Ping**, born in 1981, Ph. D. candidate. Her research interests include natural computation, data mining, engineering optimization, and image processing.

Background

Constrained optimizations, i. e. nonlinear programming, is a very important technology in engineering, operational research and mathematics. The human immune system (HIS) is a highly evolved, parallel and distributed adaptive system. The information processing abilities of HIS provide important aspects in the field of computation. This emerging field is referring to as the Artificial Immune Systems (AIS). Nowadays, there is no report about artificial immune system algorithms solving constrained optimization problems effectively.

This work is supported by the National Natural Science Foundation of China with the title “Evolutionary Algorithms Theories and Applications” (No. 60133010), “Immune Clonal

Evolutionary Algorithms and Applications” (No. 60372045) and the Graduate Innovation Fund of Xidian University with the title “Artificial Immune Systems Model Design and Applications” (No. 05004). The authors have made a lot of researches on many fields of natural computation, such as artificial immune systems, evolutionary algorithms, neural computation and so on, and have applied these methods to the field of SAR image processing and many other fields. The study in this paper belongs to the part of artificial immune systems and focuses on proposing a new method for constrained optimizations, so as to provide new tools for practical applications.