

自适应免疫克隆选择文化算法

郭一楠,王 辉,程 健

(中国矿业大学信息与电气工程学院,江苏徐州 221116)

摘 要: 免疫克隆选择算法中,单纯采用克隆选择机制的全局收敛能力较差,而采用 $(\mu + \lambda)$ 选择机制则容易陷入早熟收敛.为兼顾算法的搜索和探索能力,提出一类自适应免疫克隆选择文化算法.该算法采用文化算法的双层进化机制,提取并利用进化过程中的隐含知识,有机结合克隆选择和 $(\mu + \lambda)$ 选择两种机制,从而给出一种基于知识的自适应调整选择机制的混合选择策略.针对标准测试函数的仿真结果表明,该算法具有更稳定的全局收敛性能及较快的收敛速度.

关键词: 自适应; 克隆选择; $(\mu + \lambda)$ 选择; 文化算法; 免疫算法

中图分类号: TP301 **文献标识码:** A **文章编号:** 0372-2112 (2010) 04-0966-07

Adaptive Immune Clonal Selection Cultural Algorithm

GUO Yi-nan, WANG Hui, CHENG Jian

(School of Information and Electrical Engineering, China University of Mining and Technology, Xuzhou, Jiangsu 221116, China)

Abstract: In immune clonal selection algorithms, global convergence ability is worse if clonal selection is only adopted. However, immune algorithm with $(\mu + \lambda)$ selection is easy to fall into premature convergence. In order to ensure the exploitation and exploration, an adaptive immune clonal selection cultural algorithm is proposed. Dual structure of cultural algorithm is adopted in the algorithm. And a hybrid selection strategy integrating $(\mu + \lambda)$ selection and clonal selection is put forward. The proportion of population influenced by each selection method is adaptively adjusted according to implicit knowledge extracted from the evolution process. Aiming at benchmark functions, simulation results indicate that the algorithms can effectively improve the speed of convergence and have better computation stability.

Key words: adaptive; clonal selection; $(\mu + \lambda)$ selection; cultural algorithms; immune algorithm

1 引言

免疫克隆选择算法模拟生物学中的抗体克隆选择机理,通过克隆操作、免疫基因操作以及选择操作等新型算子,实现高效的搜索.它不要求问题具有可微、连续特性,是免疫算法中的一个新兴发展方向.

免疫克隆选择算法的选择操作通常采用克隆选择和 $(\mu + \lambda)$ 选择^[1,2].克隆选择^[3,4]是从父代抗体和其克隆衍生的子代子种群中,选择优势抗体进入下一代,因此其本质是一种局部择优选择机制.虽然该选择方式增强了算法的局部搜索能力,但是减弱了抗体间的竞争,影响了算法的全局收敛速度.而 $(\mu + \lambda)$ 选择^[5,6]采用生物的“优胜劣汰”进化准则,从父代和子代种群中选择优势抗体构成下一代种群.虽然该选择方式突出了抗体间的竞争,但是容易在算法进化初期保留过多的优势抗体,从而引起算法的早熟收敛.显然,两种选择策略各有优势和不足,目前的免疫克隆算法通常单纯采用其中一

种方式.为兼顾全局探索和局部搜索能力,本文提出一种结合克隆选择和 $(\mu + \lambda)$ 选择的混合选择机制,旨在提高算法的收敛速度和进化性能.

算法中,如何控制和协调两种选择机制的作用时机和作用比例是其核心问题.为有效解决该问题,本文引入文化算法的双层进化机制^[7,8].在种群空间实现上述基于混合选择策略的克隆选择免疫算法,信度空间用于提取进化过程中的隐含知识;并依据各类知识来自适应调节两类选择机制在种群中的作用比例,实现两种选择机制的有机结合.基于此,提出一种自适应免疫克隆选择文化算法(Adaptive Immune Clonal Selection Cultural Algorithm,简称 AICSCA).

AICSCA算法中的两个核心问题:混合选择策略和隐含知识的提取与利用,将在第二部分加以深入阐述;针对函数优化问题,算法性能通过第三部分的仿真实验加以具体分析;最后对全文加以总结.

2 自适应克隆选择免疫文化算法描述

自适应克隆选择免疫文化算法采用文化算法的双层进化机制,上层信度空间实现对进化过程隐含信息的提取,并以知识形式对种群空间的进化状况加以描述;底层种群空间实现克隆选择免疫算法,并根据信度空间知识,自适应调节混合选择策略中克隆选择机制和 $(\mu + \lambda)$ 选择机制的作用比例。

该算法的具体实现步骤如下.这里,抗原是指待优化的目标函数,抗体是候选解集,抗体的亲和度是其在目标空间中的适应度映射。

Step 1 初始化种群空间和信度空间.初始种群 $X(0) = \{x_1(0), x_2(0), \dots, x_m(0)\}$ 在整个搜索空间内随机产生,其中, m 为种群规模.信度空间的初始知识记录搜索空间中各变量的取值范围。

Step 2 克隆增殖操作.由父代种群 $X(t)$,通过克隆操作生成子代种群 $X^C(t)$ 。

Step 3 变异操作.由克隆后子代种群 $X^C(t)$,经过变异生成子代种群 $X^M(t)$ 。

Step 4 评价操作.合并父代种群 $X(t)$ 和克隆变异后子代种群 $X^M(t)$,对生成的合并种群 $\bar{X}(t)$ 评价抗体亲和度。

Step 5 选择操作.在合并种群 $\bar{X}(t)$ 中,依据信度空间知识,采用混合选择策略选出优势抗体,组成下一代种群 $X(t+1)$ 。

Step 6 知识更新.每代按照一定接受比例,从种群 $X(t+1)$ 中选取优势抗体作为样本;并依据样本集提取优势信息,更新信度空间的知识。

Step 7 判断是否满足终止条件,若满足则停止,否则 $t = t + 1$,转 Step2.本文采用最优抗体亲和度与种群抗体亲和度平均值的差值作为终止判断条件,当该差值小于某阈值时算法终止。

由上述算法描述可知,AICSCA算法的核心在于:信度空间知识的提取及更新、混合选择策略和种群空间的进化操作.下面分别对这三个部分加以详细阐述。

3 信度空间的知识更新与利用

随着文化算法的发展,研究人员先后提出五类信度空间的知识描述方式^[9],包括标准知识、状况知识、拓扑知识、领域知识和历史知识.这五类知识记录的信息不同,对算法具有不同的引导作用,适用于不同场合.AICSCA算法需要根据种群的进化状况,来自适应调整选择机制,故而信度空间采用拓扑知识。

拓扑知识记录了进化过程中优势抗体的适应度分布状况.它采用二叉树结构,依据各代优势抗体的适应

度,提取优良进化方向,并依此对搜索空间进行动态划分.假设第 t 代拓扑知识表示为

$$\bar{K}(t) = \langle K^1(t), \dots, K^q(t), \dots \rangle, q = 1, 2, \dots, |\bar{K}(t)| \quad (1)$$

其中, $|\bar{K}(t)|$ 为划分后的子空间数目. $K^q(t) = \langle L^q(t), U^q(t), \bar{x}^q(t) \rangle$ 分别代表划分后子空间 $R^q(t)$ 的下限、上限和该区域中的最优抗体.显然满足: $R^q(t) \subset R^1(0)$,即 $L^q(t) \geq L^1(0)$, $U^q(t) \leq U^1(0)$ 。

拓扑知识的更新反映为子空间划分的变化.初始阶段,搜索空间未做划分,即 $\bar{K}(0) = \langle K^1(0) \rangle$ 为整个搜索空间,且 $\bar{x}^1(0) = x_i(0)$, $i = \arg \max_{i=1,2,\dots,m} f(x_i(0))$;二叉树根节点 $R^1(0) \subset R^n$.当进化过程的优势抗体优于拓扑知识所记录的最优抗体时,对优势抗体所在子空间进行细化,记为

$$R_{\text{split}}(t) = R_j^q, j = \arg \max_{j=1,2,\dots,n} \Delta I_j \quad (2)$$

$$\exists q, f(x(t)) > f(\bar{x}^q(t-1)), \text{且 } x(t) \in R^q(t-1)$$

式中, n 是变量维数; ΔI_j 为信息增益,记录各变量维上的亲和度梯度。

$$\Delta I_j = \frac{f(x(t)) - f(\bar{x}^q(t-1))}{x_j(t) - \bar{x}_j^q(t-1)} \quad (3)$$

显然,知识细化只可能发生在二叉树的叶子节点,并且选取具有最大信息增益的变量维作为细化方向.相应变量维的二叉树分割点取值为:

$$x_j^{\text{split}}(t) = 0.5(x_j(t) - \bar{x}_j^q(t-1)) \quad (4)$$

4 基于知识的混合选择策略

克隆选择免疫算法的克隆和变异操作,将父代种群在抗体附近进行局部扩张,从而提高算法的局部搜索能力;通过选择操作,将扩张后的种群进行压缩,获得优秀的候选解集;通过对种群的反复扩张与压缩,实现问题的求解.其中,实现压缩的选择操作对算法收敛性和收敛速度具有显著影响,常采用克隆选择机制和 $(\mu + \lambda)$ 选择机制。

4.1 克隆选择

克隆选择是从父代抗体及其克隆衍生的子代种群中,选择优势抗体进入下一代.设 $x^M(t) \in X_i^M(t)$ 是由抗体 $x_i(t)$ 克隆衍生得到的子种群中最优抗体,其被选入 $X(t+1)$ 的概率为:

$$p(x_i(t+1) = x^M(t)) = \begin{cases} 1, & f(x_i(t)) < f(x^M(t)) \\ \exp\left(-\frac{f(x_i(t)) - f(x^M(t))}{\sigma}\right), & [f(x_i(t)) \geq f(x^M(t))] \wedge [f(x_i(t)) < f(x_j(t)), \\ & \exists x_j(t) \in X(t)] \\ 0, & [f(x_i(t)) \geq f(x^M(t))] \wedge [f(x_i(t)) > f(x_j(t)), \\ & \forall x_j(t) \in X(t)] \end{cases} \quad (5)$$

式中, σ 为种群的多样性系数.

$$\sigma = \frac{1}{m} \sum_{i=1}^m \left(x_i(t) - \frac{1}{m} \sum_{i=1}^m x_i(t) \right)^2 \quad (6)$$

显然, 克隆衍生的子代优势抗体进入下一代的可能性取决于其解性能及其父代种群的分布性能. 由式(5)可知, 优于其父代的子代最优抗体以概率 1 被选入下一代种群. 当子代最优抗体劣于其父代抗体时, 则根据父代种群的多样性和父代抗体在种群中的位置来确定子代抗体进入下一代的概率. 此时若父代抗体是种群的最优抗体, 为保留优势抗体, 则以概率 1 选择父代抗体进入下一代; 否则根据父代种群的多样性确定子代最优抗体进入下一代种群的概率, 种群多样性越好, 说明种群正在对搜索空间进行广度探索, 为保证种群的多样性, 避免陷入局部最优解, 选择亲和度较低子代最优抗体进入下一代种群的概率就越大; 反之, 种群多样性较差时, 说明种群进入进化后期, 为加速收敛, 则选取亲和度较高的父代抗体进入下一代的概率较大, 子代最优抗体被选择的概率较小.

综上所述, 克隆选择仅局限于父代抗体及其自身克隆衍生子代抗体构成的子种群中进行, 没有考虑抗体之间的竞争关系, 因此单纯采用该选择机制可以保证种群的多样性, 但是算法的全局收敛能力较差.

4.2 $(\mu + \lambda)$ 选择

$(\mu + \lambda)$ 选择是依据合并种群 $\bar{X}(t) = X(t) \cup X^M(t)$ 中抗体的亲和度, 选取亲和度较高的前 m 个抗体进入下一代, 即

$$p(\bar{x}_j(t) \in X(t+1)) = \begin{cases} 1, & j \leq m \\ 0, & \text{else} \end{cases} \quad (7)$$

$$\exists j, f(\bar{x}_j(t)) \geq f(\bar{x}_{j+1}(t))$$

为了保证算法收敛, 采用最优保留 + $(\mu + \lambda)$ 选择策略, 即用当前最优抗体替换种群中的最差抗体. 由于 $(\mu + \lambda)$ 选择使压缩后种群倾向于当前局限较优抗体, 所以单纯采用该选择机制, 容易使算法陷入早熟收敛.

4.3 混合选择策略

混合选择策略依据拓扑知识各子空间中的进化状况, 确定位于该子空间中的抗体子种群选择机制. 由两种选择机制的特性可知, 克隆选择机制适用于抗体多样性较好的子空间, 从而保持对该区域的探索能力; 而对于抗体较聚集的优势子空间, 应采用 $(\mu + \lambda)$ 选择机制, 确保优势抗体进入下一代, 提高算法的全局收敛能力; 同时, 为避免陷入早熟收敛, 对于抗体较聚集的非优势子空间, 采用 $(\mu + \lambda)$ 选择 + 随机替代机制.

可见, 子空间进化状况需要反映该区域内抗体的分布状况及其相对进化程度. 因此, 给出进化程度、抗体覆盖度和抗体分散度三种测度加以描述. 以子空间 $R^q(t)$ 为例加以说明.

定义 1 进化程度描述子空间中抗体相对于整个种群的进化状况, 记为

$$ED^q(t) = \frac{\bar{f}^q(t)}{f(t)} \quad (8)$$

式中, $\bar{f}^q(t)$ 为分布于子空间中抗体的平均亲和度. 设 m_q 是子空间 $R^q(t)$ 中的抗体总数, 则有

$$\bar{f}^q(t) = \frac{1}{m_q} \sum_{k=1}^{m_q} f(\bar{x}_k(t)), \bar{x}_k(t) \in R^q(t), \bar{x}_k(t) \in \bar{X}(t) \quad (9)$$

$\bar{f}(t)$ 为合并种群 $\bar{X}(t)$ 的平均亲和度, 表示为

$$\bar{f}(t) = \frac{1}{\bar{m}} \sum_{k=1}^{\bar{m}} f(\bar{x}_k(t)), \bar{x}_k(t) \in \bar{X}(t) \quad (10)$$

其中, $\bar{m} = \sum_q m_q$ 为合并种群 $\bar{X}(t)$ 规模. 显然, $ED^q(t)$ 越大, 表明该子空间中抗体的亲和度越好, 出现优势抗体的相对可能性更高.

定义 2 抗体覆盖度描述子空间中抗体在该区域内的分布跨度, 记为

$$CD^q(t) = \min_{j=1, \dots, n} \left[\frac{\max_{k=1, \dots, m_q} x_{kj}^q(t) - \min_{k=1, \dots, m_q} x_{kj}^q(t)}{u_j^q - l_j^q} \right] \quad (11)$$

式中, u_j^q, l_j^q 分别为子空间 $R^q(t)$ 第 j 维变量的上限和下限. 显然, $CD^q(t)$ 越大, 表明抗体所覆盖的子空间区域越大.

定义 3 抗体分散度描述子空间中抗体的相对聚集程度, 记为

$$SD^q(t) = \min_{j=1, \dots, n} \sigma_j^q(t) \quad (12)$$

式中, $\sigma_j^q(t)$ 为子空间中第 j 维上抗体的分散度.

$$\sigma_j^q(t) = \frac{1}{m_q} \sum_{k=1}^{m_q} \left(x_{kj}^q(t) - \frac{1}{m_q} \sum_{k=1}^{m_q} x_{kj}^q(t) \right)^2 \quad (13)$$

显然, $SD^q(t)$ 越小, 子空间中的抗体分布越集中.

根据子空间进化状况, 确定该区域中抗体的选择机制为:

Rule1 $CD^q(t) \geq \alpha$ 或 $SD^q(t) \geq \beta$, 表明该子空间中的抗体分布较分散, 因此采用克隆选择机制.

Rule2 $CD^q(t) < \alpha$ 且 $SD^q(t) < \beta$ 且 $ED^q(t) \geq \gamma$, 表明该优势子空间中的抗体分布较聚集, 因此采用最优保留 + $(\mu + \lambda)$ 选择机制.

Rule3 $CD^q(t) < \alpha$ 且 $SD^q(t) < \beta$ 且 $ED^q(t) < \gamma$, 表明该劣势子空间中的抗体分布较聚集, 因此采用 $(\mu + \lambda)$ + 随机替代机制, 即从拓扑知识记录的其他子空间中随机选取一个子空间, 并以该子空间中生成的新抗体替代劣势子空间的非优势抗体.

5 种群空间的克隆免疫操作

种群空间通过克隆复制抗体, 实现抗体增殖; 并经

过变异操作提高抗体的亲和度,促进抗体的成熟.

5.1 克隆操作

克隆就是对抗体进行复制.抗体的克隆规模与抗体的亲和度以及抗体和其他抗体之间的相似度有关.设抗体 $x_i(t)$ 的克隆规模为 $c_i(t)$,则有^[1]

$$c_i(t) = \left\lceil n_c \cdot \frac{f(x_i(t))}{\sum_{j=1}^m f(x_j(t))} \cdot \theta_i(t) \right\rceil \quad (14)$$

式中, $\lceil \cdot \rceil$ 表示向上取整, n_c 是与克隆规模有关的设定值. $f(x_i(t))$ 表示抗体 $x_i(t)$ 的亲和度值; $\theta_i(t)$ 描述抗体 $x_i(t)$ 与其他抗体之间的亲合力,反映抗体之间的相似度,记为

$$\theta_i(t) = \min_{j=1, \dots, m} \{d_{ij}\} = \min_{j=1, \dots, m} \{\exp\|x_i(t) - x_j(t)\|\}, i \neq j \quad (15)$$

式中, $\|\cdot\|$ 表示欧式距离.

通过克隆操作,抗体 $x_i(t)$ 扩展为规模为 $c_i(t)$ 的子抗体群,从而构成子代种群为

$$X^C(t) = \{x_{11}^C(t), \dots, x_{1c_1}^C(t), x_{21}^C(t), \dots, x_{2c_2}^C(t), \dots, x_{m1}^C(t), \dots, x_{mc_m}^C(t)\}$$

其中, $x_{11}^C(t) = x_{12}^C(t) = \dots = x_{1c_1}^C(t) = x_i(t)$, 其种群规模为 $\sum_{i=1}^m c_i(t)$.

5.2 变异操作

克隆后子代种群通过变异操作生成衍生子种群.本文采用高斯变异算子,对克隆后抗体 $x_i^C(t)$ 实施变异操作,记为^[10]

$$x_i^M(t) = x_i^C(t) + \sqrt{|f(x_i^C(t))|} \times N(0, 1) \quad (16)$$

其中, $N(0, 1)$ 是服从标准正态分布的 n 维随机数向量.

6 仿真结果与分析

为深入分析本文提出的自适应克隆选择免疫文化算法性能,针对函数优化问题,采用标准测试函数对知识影响下两类选择机制的影响比例演化情况,以及关键参数对算法性能的影响进行了深入分析,并将其与采用 $(\mu + \lambda)$ 选择机制的免疫克隆规划算法^[6] (Immune Clonal Programming, 简称 ICP) 以及采用克隆选择机制的免疫克隆选择算法^[1] (Immune Clonal Selection Algorithm, 简称 IC SA) 进行性能的比较.

采用的标准测试函数及其最优解分布如表 1 所示.

表 1 标准测试函数

测试函数 ($n = 2$)	变量范围	最优解 x^*	最优值 $f(x^*)$
$\max f_1(x, y) = 1 + x \sin(4\pi x) - y \sin(4\pi y + \pi) + \frac{\sin(6\sqrt{x^2 + y^2})}{6\sqrt{x^2 + y^2 + 10^{-15}}}$	$x, y \in [-1, 1]$	$(+0.64, +0.64) (-0.64, -0.64)$ $(+0.64, -0.64) (-0.64, +0.64)$	2.118
$\min f_2(x, y) = 20 + x^2 - 10\cos(2\pi x) + y^2 - 10\cos(2\pi y)$	$x, y \in [-5.12, 5.12]$	$(0, 0)$	0
$\min f_3(x, y) = 0.5 + \frac{\sin^2 \sqrt{x^2 + y^2} - 0.5}{[1 + 0.001 \times (x^2 + y^2)^2]^2}$	$x, y \in [-10, 10]$	$(0, 0)$	0
$\max f_4(x_i) = - \sum_{i=1}^{m-1} [(x_i^2 - x_{i+1})^2 + (1 - x_i)^2]$	$x_i \in [-10, 10]$	$(1, 1)$	0
$\max f_5(x_i) = - [\sum_{i=1}^m x_i + \prod_{i=1}^m x_i]$	$x_i \in [-10, 10]$	$(0, 0)$	0
$\min f_6(x_i) = \sum_{i=1}^m x_i^2$	$x_i \in [-100, 100]$	$(0, 0)$	0

仿真分析中算法主要参数取值如表 2 所示.

表 2 主要参数取值

种群规模	样本库规模	克隆规模	运行次数	解精度
30	30	10	30	10^{-3}
接受比例	进化终止代数	α	β	γ
0.2	200	0.3	0.01	1

6.1 知识影响下两类选择机制的影响比例

拓扑知识是从不断更新的样本库中提取获得的进化过程隐含信息.在其引导作用下,两类选择机制共同作用于种群,并在进化过程的不同阶段呈现出对种群的不同影响程度.不失一般性,以标准测试函数 f_1 的寻优过程(收敛代数 = 9) 为例,记录两类选择机制的影响比例演化曲线如图 1 所示.




图 1 两类选择机制影响比例演化曲线

可见,在进化初期,种群中的多数抗体采用克隆选择机制,以保证种群的多样性,避免了算法陷入早熟收

敛;随着进化深入, $(\mu + \lambda)$ 选择机制的影响比例逐渐增加, 从而提高算法的收敛速度, 保证算法的全局收敛性.

在进化过程中, 拓扑知识所记录的优势子空间逐渐缩小明确. 以上述标准测试函数 f_1 的寻优过程为例, 记录进化过程中拓扑知识结构及受其影响的子空间选择机制的演化过程如图 2 所示. 图中, “ \circ ” 代表抗体, I 代表该区域采用克隆选择机制, II 代表该区域采用 $(\mu + \lambda)$ 选择机制, III 代表该区域采用 $(\mu + \lambda)$ 选择 + 随机替代机制. 图 2(d) 和 (f) 分别放大显示图 2(c) 和 (e) 中的方框区域.

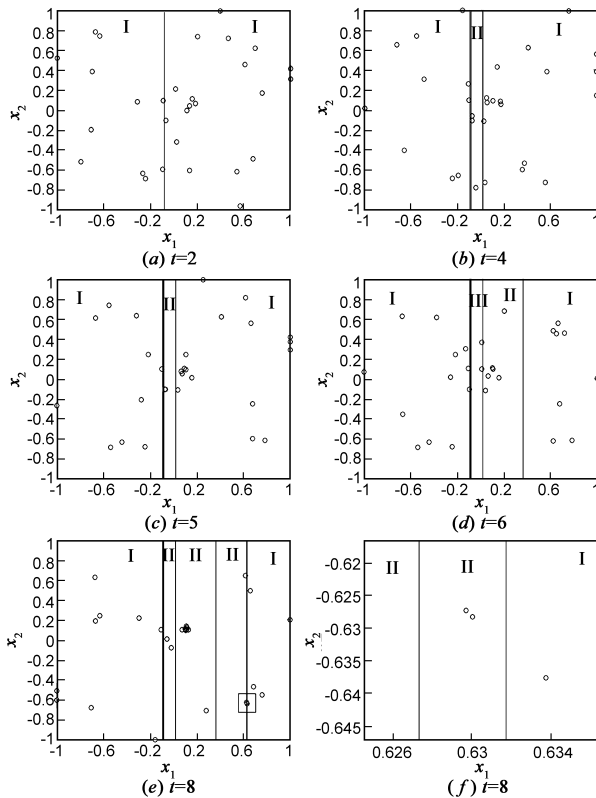


图2 子空间选择机制的演化过程

可见, 在进化初期, 抗体分布较分散, 多数抗体采用克隆选择机制, 如图 2(a) 所示; 随着进化深入, 拓扑知识记录的优势子空间划分愈加精细, $(\mu + \lambda)$ 选择机制在优势区域作用的比例逐渐增加, $(\mu + \lambda)$ 选择 + 随机替代机制在劣势区域作用的比例也逐渐增加, 如图 2(b) ~ (d) 所示; 进化后期, 种群趋于成熟, $(\mu + \lambda)$ 选择机制作用于大多数子空间, 有效促进种群的全局收敛, 如图 2(e) 所示.

6.2 混合选择策略中测度阈值对性能的影响

混合选择策略中, 拓扑知识各子空间的进化状况通过进化程度、抗体覆盖度和抗体分散度三种测度加以描述. 后两者描述了子空间中抗体的分布状况, 其测度阈值 (α 、 β) 的选取会对该子空间中抗体子种群所采用的选择机制产生影响; 进化程度阈值 (γ) 用于判定当前区域的优势程度, 决定补入新抗体的时机, 会对算法跳出局部极值点的能力产生影响.

为深入分析上述三种测度阈值对算法性能的影响, 针对表 1 中的标准测试函数, 分别选取 3 组 α 、 β 和 γ , 统计其 30 次运行结果如表 3 ~ 5 所示. 表中, $M1$ 表示平均最优目标值, $M2$ 表示最优值均方差, $M3$ 表示获得最优解的运行次数, $M4$ 表示平均收敛代数.

由表 3 可见, $\alpha = 0.3$ 时, 算法在达到相同或更高收敛速度的同时, 其求解精度较高, 解的稳定性较好. 分析表明: α 取值越小, 满足 Rule1 的子空间数目越多, 即克隆选择机制在种群中的作用比例越大, 使 $(\mu + \lambda)$ 选择机制不会过早的作用于抗体, 从而保证了算法的探索能力, 避免算法陷入局部较优区域. 综上所述, 本文选取 $\alpha = 0.3$.

表 4 的仿真结果表明, $\beta = 0.01$ 时, 算法具有较好的求解精度和较快的收敛速度. 虽然 AICSCA 算法在针对 f_5 的测试中, $\beta = 0.01$ 时的收敛速度略差于 $\beta = 0.07$ 时的测试结果, 但是前者的算法求解精度高于后者. 分析表明: β 取值较大时, 满足 Rule1 的子空间数目减少,

表 3 不同 α 取值算法性能比较 ($\beta = 0.01$ 、 $\gamma = 1$)

函数	f_1	f_2	f_3	f_4	f_5	f_6	
$\alpha = 0.3$	$M1$	2.1181	4.48×10^{-4}	4.14×10^{-4}	-5.01×10^{-4}	-6.02×10^{-4}	6.48×10^{-4}
	$M2$	4.28×10^{-4}	2.7×10^{-4}	2.8×10^{-4}	2.92×10^{-4}	2.39×10^{-4}	2.95×10^{-4}
	$M3$	30	30	27	26	30	30
	$M4$	10	50	72	76	98	127
$\alpha = 0.5$	$M1$	2.1180	6.97×10^{-4}	5.24×10^{-4}	-7.67×10^{-4}	-8.01×10^{-4}	9.907×10^{-4}
	$M2$	5.28×10^{-4}	1.65×10^{-3}	2.88×10^{-4}	3.1×10^{-4}	4.3×10^{-4}	1.31×10^{-3}
	$M3$	30	30	26	21	29	30
	$M4$	11	57	96	109	102	126
$\alpha = 0.8$	$M1$	2.1179	2.98×10^{-2}	4.17×10^{-4}	-7.66×10^{-4}	-1.31×10^{-3}	1.6×10^{-3}
	$M2$	5.73×10^{-4}	1.36×10^{-2}	2.82×10^{-4}	3.02×10^{-4}	3.24×10^{-3}	2.5×10^{-3}
	$M3$	30	30	26	20	29	30
	$M4$	10	55	87	97	99	125

即克隆选择机制在种群中的作用比例减小. 于是, $(\mu + \lambda)$ 选择机制会较早的作用于抗体, 算法易于陷入局部极值点, 所得解的精度较差. 因此, 本文算法选取 $\beta = 0.01$.

由表 5 可见, $\gamma = 1$ 时算法的求解精度最好, 且算法得到最优解的次数也最多. 分析表明: 若 γ 取值太小,

容易将非优势区域误判为优势区域, 从而采用 $(\mu + \lambda)$ 选择机制, 保留过多的局部较优解; 若 γ 取值太大, 则优势区域的判定过于严格, 会导致在优势区域中采用 $(\mu + \lambda) +$ 随机替代机制, 从而破坏已有的优势抗体子种群. 显然, 上述两种情况都会导致算法的求解精度及收敛速度降低. 因此, 本文算法选取 $\gamma = 1$.

表 4 不同 β 取值算法性能比较 ($\alpha = 0.3, \gamma = 1$)

函数	f_1	f_2	f_3	f_4	f_5	f_6	
$\beta = 0.01$	M1	2.1181	4.48×10^{-4}	4.14×10^{-4}	-5.01×10^{-4}	-6.02×10^{-4}	6.48×10^{-4}
	M2	4.28×10^{-4}	2.7×10^{-4}	2.8×10^{-4}	2.92×10^{-4}	2.39×10^{-4}	2.95×10^{-4}
	M3	30	30	27	26	30	30
	M4	10	50	72	76	98	127
$\beta = 0.03$	M1	2.1180	5.04×10^{-4}	4.54×10^{-4}	-7.19×10^{-4}	-7.79×10^{-4}	1.38×10^{-3}
	M2	5.07×10^{-4}	3.01×10^{-4}	2.97×10^{-4}	3.27×10^{-4}	3.33×10^{-4}	2.27×10^{-3}
	M3	30	30	25	26	30	30
	M4	11	67	73	86	102	138
$\beta = 0.07$	M1	2.1180	5.33×10^{-4}	5.26×10^{-4}	-7.38×10^{-4}	-1.11×10^{-3}	2.23×10^{-3}
	M2	4.76×10^{-4}	2.98×10^{-4}	3.24×10^{-4}	3.08×10^{-4}	1.06×10^{-3}	2.94×10^{-3}
	M3	30	30	26	24	30	30
	M4	11	65	74	88	95	132

表 5 不同 γ 取值算法性能比较 ($\alpha = 0.3, \beta = 0.01$)

函数	f_1	f_2	f_3	f_4	f_5	f_6	
$\gamma = 0.8$	M1	2.1181	5.2×10^{-4}	4.86×10^{-4}	-7.66×10^{-4}	-1.99×10^{-3}	8.09×10^{-4}
	M2	5.01×10^{-4}	2.85×10^{-4}	3.02×10^{-4}	5.98×10^{-4}	4.6×10^{-3}	2.3×10^{-4}
	M3	30	30	23	25	30	27
	M4	11	53	92	95	100	150
$\gamma = 1$	M1	2.1181	4.48×10^{-4}	4.14×10^{-4}	-5.01×10^{-4}	-6.02×10^{-4}	6.48×10^{-4}
	M2	4.28×10^{-4}	2.7×10^{-4}	2.8×10^{-4}	2.92×10^{-4}	2.39×10^{-4}	2.95×10^{-4}
	M3	30	30	27	26	30	30
	M4	10	50	72	76	98	127
$\gamma = 1.2$	M1	2.1180	4.9×10^{-4}	4.9×10^{-4}	-6.48×10^{-4}	-7.02×10^{-4}	2.16×10^{-3}
	M2	5.45×10^{-4}	4.32×10^{-4}	2.81×10^{-4}	3.1×10^{-4}	3.25×10^{-4}	3.08×10^{-3}
	M3	30	29	25	23	20	30
	M4	10	61	99	88	92	133

6.3 与其它算法性能对比分析

针对表 1 中的 6 个测试函数, 分别采用 AICSCA、ICP 和 ICSA, 参照表 2 所示算法参数进行仿真实验, 运行结果的统计分析如表 6 所示.

可见, 自适应克隆选择免疫文化算法在整体上具有较高的求解精度、较好的解稳定性和收敛能力; 而采用克隆选择机制的 ICSA 算法容易陷入局部较优解, 解

稳定性较差; 采用 $\mu + \lambda$ 选择机制的 ICP 算法收敛速度较慢. 其中, 根据表 6 中的统计运行结果可知, 对于测试函数 f_4 , AICSCA 算法的收敛能力较其他两种算法差, 但解精度和稳定性较好. 这是因为, 对于 f_4 这种“平坦”函数, 克隆选择机制在进化过程中占主导作用的时间较长, 且进化后期 $(\mu + \lambda)$ 选择作用的子空间过多, 导致收敛速度降低, 可以通过提高 γ 来改善算法的收敛性能.

表 6 不同算法性能比较

函数	ICP 算法				ICSA 算法				AICSCA 算法			
	M1	M2	M3	M4	M1	M2	M3	M4	M1	M2	M3	M4
f_1	2.1179	4.34×10^{-4}	30	12	2.107	0.018	22	49	2.1181	4.28×10^{-4}	30	10
f_2	5.48×10^{-4}	2.97×10^{-4}	30	64	5.83×10^{-4}	2.18×10^{-4}	5	90	4.48×10^{-4}	2.7×10^{-4}	30	50
f_3	4.52×10^{-4}	2.87×10^{-4}	26	83	0.077	0.072	5	11	4.14×10^{-4}	2.8×10^{-4}	27	72
f_4	-5.32×10^{-4}	3.49×10^{-4}	30	49	-7.21×10^{-4}	2.91×10^{-4}	30	20	-5.01×10^{-4}	2.92×10^{-4}	26	76
f_5	-8.57×10^{-4}	9.41×10^{-3}	7	87	-9.75×10^{-4}	0	1	54	-6.02×10^{-4}	2.39×10^{-4}	30	98
f_6	8.45×10^{-4}	1.02×10^{-4}	28	165	5.03×10^{-4}	2.83×10^{-4}	25	82	6.48×10^{-4}	2.95×10^{-4}	30	127

纵上所述,本文采用的混合选择策略,根据进化过程隐含知识有效结合两种选择机制,在进化初期通过克隆选择机制保证较好的种群多样性;在进化后期通过 $(\mu + \lambda)$ 选择机制提高求解精度.因此,自适应克隆选择免疫文化算法在整体上能兼顾求解精度及其稳定性与收敛速度两方面性能.

7 结语

克隆选择免疫算法中,单纯采用克隆选择机制的全局收敛能力较差;而单纯使用 $(\mu + \lambda)$ 选择机制又容易早熟收敛.针对该问题,本文借鉴文化算法的双层进化结构,提出一种自适应混合选择策略.根据信度空间中描述进化状况的拓扑知识,在划分后的搜索子空间中自适应确定选择机制,从而将两种选择方式有机结合,共同作用于种群.基于标准测试函数的仿真实验结果表明,本文算法在整体上具有较好的全局寻优能力和解稳定性,且收敛速度较快.面向多模或高维函数优化问题的进化过程隐含知识的提取与利用,还有待于进一步深入研究.


参考文献:

- [1] 焦李成,杜海峰,刘芳,等.免疫优化计算、学习与识别[M].北京:科学出版社,2006.
Jiao Licheng, Du Haifeng, Liu Fang, et al. Immune optimization computation, learning and recognition [M]. Beijing: Science Press. 2006. (in Chinese)
- [2] 焦李成,杜海峰.人工免疫系统进展与展望[J].电子学报.2003,31(10):1540-1548.
Jiao Licheng, Du Haifeng. Development and Prospect of the artificial immune system [J]. Acta Electronica Sinica. 2003, 31 (10): 1540 - 1548. (in Chinese)
- [3] L N de Castro, F J V Zuben. Learning and optimization using the clonal selection principle [J]. IEEE Transactions on Evolutionary Computation. 2002, 6(3): 239 - 251.
- [4] Liu Ruochen, Chen Li, Wang Shuang. Immune clonal strategies based on three mutation methods [A]. Proceedings of the 2th International Conference on Natural Computation [C]. Berlin, Heidelberg: Springer-Verlag. 2006. 114 - 121.
- [5] L Hong, Z C Mu. A novel clonal chaos adjustment algorithm [A]. Proceedings of the 26th Chinese Control Conference [C]. 2007. 710 - 714.
- [6] Y He, C B Jian. Clonal selection algorithm with adaptive mutation and roulette wheel selection [A]. The 20th IEEE Interna-

tional Conference on Micro Electro Mechanical Systems [C]. Piscataway, NJ, USA: IEEE. 2007. 93 - 96.

- [7] R L Bacteria, C A Coello. Cultured differential evolution for constrained optimization [J]. Computer Methods in Applied Mechanics and Engineering. 2006, 195: 4303 - 4322.
- [8] 郭一楠,巩敦卫.双层进化交互式遗传算法的知识提取与利用[J].控制与决策.2007,22(12):1329-1335.
Guo Yi-nan, Gong Dunwei. Extraction and utilization about knowledge in hierarchical interactive genetic algorithms [J]. Control and Decision. 2007, 22(12): 1329 - 1335. (in Chinese)
- [9] Bin Peng. Knowledge and population swarms in cultural algorithms for dynamic environments [D]. USA: Wayne State University. 2005.
- [10] 王凌.智能优化算法及其应用[M].北京:清华大学出版社,2001.
Wang Ling. Intelligent Optimization algorithm with Applications [M]. Beijing: Tsinghua University Press. 2001. (in Chinese)

作者简介:



郭一楠 女,1975 年生于山西太原.博士,中国矿业大学信息与电气工程学院副教授.主要从事智能优化算法、机器学习、多 agent 技术的研究工作. E-mail: nanfly@126.com



王 辉 女,1982 年生于山东兖州.中国矿业大学信息与电气工程学院硕士生.研究方向为智能优化算法.



程 健 男,1974 年生于四川平昌.博士,中国矿业大学信息与电气工程学院副教授.主要从事核机器学习、智能计算等的研究工作.