第 27 卷第 10 期
2010 年 10 月

控 制 理 论 与 应 用
Control Theory & Applications

Vol. 27 No. 10
Oct. 2010

文章编号: 1000−8152(2010)10−1322−09

竞争合作型协同进化免疫算法及其在旅行商问题中的应用

刘朝华[1], 章 兢[1], 张英杰[2], 吴建辉[2]

(1. 湖南大学 电气与信息工程学院, 湖南 长沙 410082; 2. 湖南大学 计算机与通信学院, 湖南 长沙 410082)

摘要: 为提高人工免疫算法的收敛性能, 提出了一种竞争合作型协同进化免疫优势克隆选择算法(CCCICA). 把生态学中的协同进化思想引入到人工免疫算法中, 考虑了环境和子群间相互竞争的关系, 子种群内部通过局部最优免疫优势, 克隆扩增, 自适应动态高频混合变异等相关算子的操作加快了种群亲和度成熟速度. 把信息熵理论引入到算法中完善了种群的多样性. 所有子种群共享同一高层优良库, 并将其作为抗体子种群领导集合, 对高层优良种群进行免疫杂交操作, 通过迁移操作把优良个体返回到各子种群, 实现了整个种群信息交流与协作. 针对旅行商问题(traveling salesman problem, TSP)多个实例结果表明: 与其它智能算法相比较该算法具有较好的性能.

关键词: 人工免疫; 克隆选择; 局部最优免疫优势; 竞争合作; 协同进化; 旅行商问题(TSP)

中图分类号: TP18　　**文献标识码**: A

Competitive-cooperative coevolutionary immune-dominant clone selection algorithm for solving the traveling salesman problem

LIU Zhao-hua[1], ZHANG-jing[1], ZHANG Ying-jie[2], WU Jian-hui[2]

(1. College of Electrical and Information Engineering, Hunan University, Changsha Hunan 410082, China;
2. School of Computer and Communication, Hunan University, Changsha Hunan 410082, China)

Abstract: To improve the convergence performance of artificial immune algorithm, we propose a competitive-cooperative coevolutionary immune-dominant clone selection algorithm(CCCICA). Enlightened by the knowledge of ecological environment and population competition, we incorporate the cooperative evolution in ecology into the artificial immune system. The affinity maturation of antibody is enhanced by the local optimization of the immune-dominance, the clone expansion and the adaptive dynamic hyper-hybrid mutation and other factors in the species. The population diversity is evaluated and adjusted by the locus information entropy. All subpopulations share one memory which is also used as a leader set consisting of the dominant representatives of each evolved subpopulation. The high level memory is optimized by using the immune genetic crossover operator. Several best individuals are migrated to subpopulations from the top excellent population based on the predefined condition. Through those operations, information is shared among populations for co-evolution. The results demonstrate good performance of the CCCICA in solving the traveling salesman problem(TSP) when compared with other modern intelligent algorithms.

Key words: artificial immune system(AIS); clonal selection; local optimization immunodominance; competitive-cooperative; coevolution; traveling salesman problem(TSP)

1 引言(Introduction)

人工免疫系统(artificial immune system, AIS)是模拟生物免疫系统的机理而构造的高性能、自组织、鲁棒性好的人工智能系统. 克隆选择算法作为人工免疫算法的核心算法之一, 受免疫克隆选择学说的启发, De Castro等人提出了一种较为简洁的克隆选择算法(clonal selection algorithm, CSA), 并成功地用于解决模式识别, 数值优化和TSP问题[1], 建立了克隆选择机理用于搜索算法的框架. 至今人工免疫系统已应用到诸多领域[2], 如机器学习[3]、组合优化[4]、数据挖掘[5]、预测控制与系统辨识[6]等问题. 由于人工免疫算法采用基于个体自身亲和度的进化模式而没有考虑个体间及生态环境的影响. 正因如此, 它在应用中表现出了未成熟收敛, 并且收敛的速度较慢等缺陷, 纯粹基于个体亲和度来控制个体的进化, 很难达到理想的效果.

协同进化是借鉴生态学模型发展起来的一类新的进化算法, 最早的研究始于Potter和DeJong的工作[7], 引入多个子群, 意指多个种群通过适应度的关联, 最初被应用于遗传算法求解多目标优化问题, 并

收稿日期: 2009−05−30; 收修改稿日期: 2009−11−22.
基金项目: 国家自然科学基金重点资助项目(60634020); 湖南省科技计划重点资助项目(2010GK2022).

取得较好的效果. 根据算法采用的生物模型不同, 协同进化算法分为以下几类: 基于种间竞争机制的协同进化算法, 基于“捕食–猎物”机制的协同进化算法和基于共生机制的协同进化算法[8]. 同时协同进化算法中最常见的计算模型分为竞争型协同进化和合作型协同进化, 及竞争合作型协同进化[9]. 借鉴协同进化的思想和依据种群密度的概念而建立的竞争协同进化模型, 来描述个体与环境及群体间的协同行为, 基于该模型改进的克隆选择算法在一定程度上能够脱离基于个体适应度控制进化的生物进化框架, 然而纯竞争协同模型随进化过程趋于平衡点容易出现协同的弱化和退化现象[8].

借鉴生态学的种群密度[10]思想和协同进化思想, 提出了一种竞争合作型协同进化免疫优势克隆选择算法(CCCICA), 通过混合策略选取各子种群的优势代表组成优良种群, 充当抗体子种群领导集合, 对优势代表种群进行免疫杂交操作, 模拟自然界同物种不同种群间的协作与交流, 以提高全局寻优的能力, 把优良模式通过迁移操作各子种群中. 在子种群内部进化时, 提出了一种改进的克隆选择算法–局部最优免疫优势克隆选择算法(immunodominance clone selection algorithm, ICA), 抗体群通过局部最优免疫优势, 克隆操作等操作算子, 及基于信息熵的种群多样性调整机制. 针对TSP多个实验结果表明: 该算法在收敛速度与最优解等方面均取得了较好的效果.

2 多种群竞争合作协同进化模型 (Framework of competitive-cooperation coevolution)

借鉴协同进化思想和生态学的种群密度[10]思想, 提出了一种竞争–合作型协同进化免疫算法, 设计了竞争–合作协同进化免疫算法模型. 该模型维持群体的多样性, 把群体分割成若干子群体, 每个子种群独立地进行免疫操作, 底层子种群间采用基于生态种群密度的种群竞争协同模型, 高层优势代表种群采用免疫杂交操作, 通过迁移操作把全局最抗体引入到各子种群中. 促进了各种群合作协同进化.

定义 1 (CCCICA模型)　CCCICA由一个优势代表种群S^*和若干个抗体子种群

$$S=(S_1,S_2,\cdots,S_n)$$

组成, 其中S_i代表第i个子种群, 按照图1中的方式组织而成, 其下层是n个规模为N_i的抗体子种群, N_i采用基于生态种群密度的种群竞争调节机制(见2.1节).

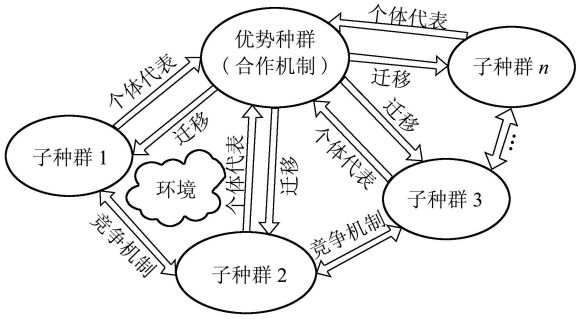

图 1　竞争–合作型协同进化模型

Fig. 1　Framework of competitive-cooperation coevolution

2.1 基于生态种群密度的种群竞争协同模型 (Co-evolution model based on ecological population)

生态学理论认为在一定生态环境中的种群, 其种群进化受到自身适应度, 环境及其他种群间的竞争协同的影响, 其中环境和种群间的协同竞争因素可以通过种群密度来体现. 如果存在n个种群$S_i(i=1,2,\cdots,n)$, 则种群S_i的增长符合如下Lotka-Volterra[10]竞争方程:

$$\frac{\mathrm{d}N_i}{\mathrm{d}t}=r_iN_i\{\frac{K_i-N_i-(\sum\limits_{j=1}^{n}a_{ij}N_j)}{K_i}\}. \tag{1}$$

式(1)中: N_i表示种群i的大小, K_i表示在不发生竞争的情况下, 种群i的环境负荷量, r_i表示种群i的个体的最大瞬时增长率, a_{ij}是竞争系数, 表示种群j的每个个体对种群i的抑制作用, $\frac{\mathrm{d}N_i}{\mathrm{d}t}$表示种群$i$的密度变化量. 把生态种群密度的种群竞争协同模型引入到人工免疫算法中可以得到新的进化算法, 考虑了环境和种群间相互竞争的关系, 提高了群体的多样性, 增强了算法的全局收敛性. 种群间通过竞争不断调整自身的规模, 具体方法如下:

1) 如果种群$\frac{\mathrm{d}N_i}{\mathrm{d}t}>0$, 通过随机产生$\frac{\mathrm{d}N_i}{\mathrm{d}t}$个染色体加入种群$N_i$来增大该种群的规模, 有利于提高该子群的多样性.

2) 如果种群$\frac{\mathrm{d}N_i}{\mathrm{d}t}<0$, 对种群$N_i$进行亲和度排序, 删除适应度较低且相对于种内密度较大的$\frac{\mathrm{d}N_i}{\mathrm{d}t}$个染色体, 从而减少该种群的规模, 一定程度上提高了该种群的总体适应度. 在下一轮的进化中, 可能显示出较强的竞争力.

3) 依照式(1)调整各个子种群的规模:

$$N_i(t+1)=N_i(t)+\frac{\mathrm{d}N_i}{\mathrm{d}t}.$$

这种处理方式既体现了抗体子群进化过程中的种间协同竞争, 也体现出抗体子群内部抗体之间的相互竞争过程.

定义 2 优势代表种群$S^* = (S_{11}, S_{12}, \cdots, S_{ij})$看成$i \times j$个优势抗体. S_{ij}代表第i个子种群的第j个代表. 优势个体代表的提取: 在每个子种群选择一个最好的个体(亲和度最高的个体)和随机选择一个次优个体. 优势代表种群充当多种群的记忆库功能, 充当了抗体种群间信息交流的功能.

2.2 抗体子种群局部最优免疫优势克隆选择算法(Local optimization immunodominance clonal selection)

抗体子种群$S_i(i = 1, 2, \cdots, n)$上的免疫算法的伪码描述如下:

开始

1) for对每个子种群S_i, do{

2) 利用Lotka-Volterra竞争方程, 计算抗体群S_i $(i = 1, 2, \cdots, n)$的增长值$\dfrac{\mathrm{d}N_i}{\mathrm{d}t}$;

① 如果种群$\dfrac{\mathrm{d}N_i}{\mathrm{d}t}$ >0, 通过随机产生$\dfrac{\mathrm{d}N_i}{\mathrm{d}t}$个染色体加入种群$N_i$来增大该种群的规模;

② 如果种群$\dfrac{\mathrm{d}N_i}{\mathrm{d}t}$ <0, 按照计算出来的适应度大小排序, 删除适应度最小的$\dfrac{\mathrm{d}N_i}{\mathrm{d}t}$个染色体, 从而减少该种群的规模(为了防止种群规模等于0, 种群规模$N_i(t) > 0$):

$$N_i(t+1) = N_i(t) + \frac{\mathrm{d}N_i}{\mathrm{d}t};$$

3) 计算抗体群亲和度并对亲和度进行排序, 选择前K个高亲和度抗体进行局部最优免疫优势操作, 按算法2, $S_i'(t) = LOIO(S_i(t))$;

4) 抗体亲和度进行排序, 按照亲和度大小克隆扩增, $S''_i(t) = T_{\mathrm{c}}^{\mathrm{C}}(S_i'(t))$;

5) 执行免疫基因操作: $Z_i(t) = T_{\mathrm{g}}^{\mathrm{C}}(S''_i(t))$;

6) 计算亲和度进行免疫选择得到新的抗体群

$$S_i(t+1) = T_{\mathrm{s}}^{\mathrm{C}}(Z(t)) = \max\{\mathrm{affinity}(Z_i(t)\};$$

7) 抗体优势代表S_{ij}的提取: $S^*(t) = S^*(t) \cup S_{ij}\}$;

8) $t = t + 1$;

结束.

2.3 基本问题描述及定义(Description and definition)

TSP问题是著名的NP难问题, 简单描述为: 已知N个城市$v = \{v_1, v_2, v_3, \cdots, v_N\}$, 以及任意两城市之间的距离$d = (v_i, v_j)$, 求一条经过$v$中所有城市一次且仅一次的闭合路径, 使得总行程

$$d = \sum_{i=1}^{N-1} d(v_{\pi_{(i)}}, v_{\pi_{(i+1)}}) + d(v_{\pi_{(N)}}, v_{\pi_{(1)}})$$

最小.

定义 3 亲和度定义, 抗体与抗原的亲和度反应抗体与抗原的匹配程度, 一般取路径距离的倒数, 为了更好区分抗体间的优劣, 重新定义亲和度函数如式(2):

$$\mathrm{affinity}(A_i) = \frac{S_0}{\mathrm{dist}(A_i)}. \tag{2}$$

式(2)中dist(A_i)为第i个抗体遍历整个城市的距离, S_0为已知的最短路径长度.

定义 4 克隆扩增算子B_i, 在现有抗体群中选择亲和度最大的k个抗体进行克隆, 避免进化的初期某些细胞因超强的繁殖能力而陷入局部极值, 同时防止进化后期因细胞优劣差距减少而使算法进化缓慢, 故按照以下公式计算克隆扩增算子B_i, 如公式(3):

$$B_i = \mathrm{round}(\alpha \cdot \frac{\mathrm{affinity}(A_i)}{i \cdot \sum\limits_{i=1}^{N} \mathrm{affinity}(A_i)} + b), \tag{3}$$

a为⩾1的比例系数, round(·)取整, b为>1的常量; 为了保证每个抗体都有一定克隆数量, 故加上了常量b.

定义 5 免疫基因操作$T_{\mathrm{g}}^{\mathrm{C}}$主要包括变异, 即: $Z(t) = T_{\mathrm{g}}^{\mathrm{C}}(Y(t))$. 变异操作可以有多种选择, 针对TSP问题, Inver_over操作算子[1]是在抗体周围的编码空间进行局部搜索, 已经证明该操作算子优于传统的交叉算子, 如: PMX, OX, CX等. 3-Opt变异算子有较强的局部搜索能力.

1) 动态变异概率(mutation probability). 通过动态地调整两种变异算子的变异概率以尽可能提高算法的收敛速度. 动态变异概率如下:

$$p = p \times (1 - t \times 0.02/T), \tag{4}$$

式中: p为变异概率, t为当前进化代数, T为总的进化代数.

2) 高频变异算子(hyper mutation).

算法 1 克隆变异操作算法:

for $Y(t)$中的每一个抗体$Y_i(t)$ do{

if (Rand(·)⩽ p) //p为变异概率.

3-Opt ($Y_i(t)$);

else Inver_over ($Y_i(t)$);}.

定义 6 免疫选择$T_{\mathrm{s}}^{\mathrm{C}}$, $P_i(t) = T_{\mathrm{s}}^{\mathrm{C}}(P(t)) = \max\{\mathrm{affinity}(Z_i(t)\}$, 然后$P_i(t) \cup A_i(t) -> A_i(t+1)$, 通过最优选择实现了种群的压缩, 同时保证了抗体群中的最优解不会变差.

2.4 抗体局部最优免疫优势算法(Immunodominance)

定义 7 局部最优免疫优势算子, 免疫学认为[11], 一个抗原分子上可以有多个表位, 但在诱导宿主免疫应答时只有一种或一个表位起主要作用, 使宿主产生以该特异性为主的免疫应答, 该现象称为免疫优势. 用于TSP问题的抗体局部最优免疫优势算子为设有n个节点(城市号)

$$e_1 = (v_1, v_2, \cdots, v_i, v_{i+1}, \cdots, v_n) \subset a_p,$$

$a_p \in Ab$, 设有待插入节点$v_j \in e_2 \subset a_p$, e_1, e_2是抗体a_p的两个子集(也称作用域), 满足$e_1 \cap e_2 = \varnothing$. $v_i, v_{i+1} \in e_1, v_j \in e_2$, $ID = \{(\Delta d_i, v_i, v_j, v_{i+1})\}$为抗体局部最优免疫优势算子. $\Delta d_i, v_i, v_j, v_{i+1}$如满足式(5):

$$\Delta d_i = \min(d(v_i, v_j) + d(v_j, v_{i+1}) - d(v_i, v_{i+1})). \tag{5}$$

算法 2 局部最优免疫优势算子(LOIO):

开始

{while($e_2 \neq \Phi$) do{

求抗体免疫优势$ID = \{(d_i, v_i, v_j, v_{i+1})\}$, 其中$d_i = \min(d(v_i, v_j) + d(v_j, v_{i+1})d(v_i, v_{i+1}))$;

$v_i, v_{i+1} \in e_1, vj \in e_2$;

将v_j插入v_i之后, $e_1 = e_1 \cup v_j$

从e_2中移出$v_{j,}e_2 = e_2 - v_j$

}}

结束

显然, 针对TSP问题的抗体局部最优免疫优势算子, 是针对特定抗体的一个动态调整局部最优过程, 它包括基本免疫优势的形成及抗体免疫优势的获得.

2.5 基于信息熵的种群多样性控制(Diversity control)

定义 8 均信息熵定义: 假设抗体群由N个抗体组成, 每个抗体有L位基因, 采用的编码符号集大小为

$$|K|,\ K = \{k_1, k_2, \cdots, k_{|S|}\},$$

则对应于基因座j的信息熵定义为

$$H_j(N) = -\sum_{k=1}^{|K|} p_{kj} \log_2(p_{kj}),$$

$H_j(N)$为第j个基因座的总体信息测度, P_{kj}为第k个符号在基因座j上的概率

$$P_{kj} = \frac{n_{kj}}{N};$$

n_{Kj}为在基因座上出现第k个符号总个数. 定义群体的平均信息熵为

$$H = \frac{1}{L}\sum_{j=1}^{L} H_j(N).$$

种群的平均信息熵越大, 种群的分布性越好. 随着进化代数t的增加及亲和度的提高, 种群的多样度将降低, 当种群趋同时, 多样度为零.

1) 多样性判断多样性阈值定义:

$$\varphi(t) = A \cdot \log_2(|K|) \cdot \mathrm{e}^{-\frac{Bt}{T}}, \tag{6}$$

式中: A调节系数($A \in (0, 1)$), B为加速因子($B > 0$), t当前代数, T为总代数.

2) 多样性调整策略在子种群中N_{b}(N_{b} >1)个路径长度相同抗体(一般为最优的抗体, 或次优个体)里选择$N_{\mathrm{b}} - 1$个抗体, 对每一个选择个体进行低多样性基因位的变换操作直到多样性超过预定阈值.

2.6 种群间协同合作算法(Cooperative)

优良库种群由普通种群中亲和度较优的个体代表组成, 是一个优良子库, 供各种群的进化进程共享. 协同合作主要有: 优良抗体免疫杂交及个体迁移操作.

1) 优良抗体种群免疫杂交: 模拟自然界同物种间不同种群间的杂交, 完成信息在种群间交流. 借鉴遗传算法的杂交策略, 考虑抗体间的差异度. 选择抗体时避免“近亲繁殖”. 免疫杂交如下:

If ($|\mathrm{affinity}(A(i)) - \mathrm{affinity}(B(i))| < \varepsilon$), Then crossover(). ε为很小的正常数免疫阈值. 免疫杂交操作采取最优保存, 杂交后生成的抗体将代替原始抗体. 为了确保优秀模式在子群间传递, 算法采用最优杂交策略, 选取优势代表库中的待杂交抗体S与来自不同子群最优解抗体进行免疫杂交操作.

2) 优势抗体迁移: 普通子种群内部进化过程中, 每隔数代直接从优良种群库中引进若干优良种子个体(一般取1∼2个抗体)代替本种群中的较劣个体. 操作如下:

If ((gen%migration_interval)==0), Then

Migrate(sig, Num_migrant); 其中sig为迁移信号(见式(7))当sig = 1时表示迁移:

$$\mathrm{sig} = \begin{cases} 1, & \dfrac{F^i_{\mathrm{best}}(k) - F^i_{\mathrm{best}}(k-1)}{F^i_{\mathrm{best}}(k-1) - F^i_{\mathrm{best}}(k-2) + \varepsilon} < 1, \\ 0, & \text{其他}, \end{cases} \tag{7}$$

$F^i_{\mathrm{best}}(k)$表示第i个种群第K代亲和度最优的抗体, ε为平滑系数. 该式表明: 若种群i在进化的过程中进化减慢现象, 需要从优良种群库中迁移优良抗体来提高该子种群的性能.

3 算法分析(Analysis)

抗体子种群免疫优势的时间复杂度$T(n) = \mathrm{O}(N_{\mathrm{C}} \cdot m \cdot n^2 \log(n))$($m$为抗体个数, n为基因长度, N_{C}为循环次数), 免疫选择、变异等其他操作的最坏时间复杂度为$\mathrm{O}(N_{\mathrm{C}} \cdot m \cdot n^2)$($m$为抗体个数). 高层优势抗体代表免疫杂交时间复杂度为$\mathrm{O}(m_0 \cdot n^2)$($m_0$为优势抗体个数). 文中算法的时间复杂度最坏为

$$T(n) = \mathrm{O}(N_{\mathrm{C}} \cdot m \cdot n^2) + \mathrm{O}(N_{\mathrm{C}} \cdot m \cdot n^2 \log(n)) + \mathrm{O}(N_{\mathrm{C}} \cdot m \cdot n^2) + \mathrm{O}(m \cdot n^2).$$

4 实验仿真(Experiments)

实验仿真环境: Windows XP系统, AMD处理器, 1.90 GHZ 448 MB内存, 仿真软件MATLAB 7.0. 选用国际上通用的TSPLIB测试库中的多个实例进行测试.

实验参数设置: 结合大量的实验及参考文献[10,11]综合得出, 主要考虑算法的执行时间及求解问题的精度. 抗体子种群分为6个, 初始变异概率为0.75, 环境负荷量$K = 75$, 每个子种群抗体初始规模为35, 克隆算子比例系数$\alpha = 100$, 克隆算子常数$b = 10$等参数设置较合理.

4.1 3种不同形式ICA算法性能比较(Comparison of three algorithm)

为了验证竞争合作型协同进化免疫算法CCCICA的有效性, 采用3种不同形式ICA(文中提出的局部最优免疫优势克隆选择算法)算法来求解下列TSP实例, 实例1对a280(城市规模280个, TSPLIB提供的已知最优值$S_0 = 2586.8$)进行30次测试, 3种算法分别为: 1) 无生态种群竞争的纯多种群免疫优势克隆选择算法(multi-population local optimization immunodominance clonal selection algorithm, MICA). 2) 引入环境与生态种群竞争的多种群免疫优势克隆选择算法(competitive coevolutionary immunodominance clonal selection algorithm, CCICA), 但高层不做优良个体交叉及优良个体迁移操作. 3) 竞争合作型协同进化免疫优势克隆选择算法(CCCICA).

1) 若采用MICA算法, 子种群分为6个, 每个子种群抗体规模35, 子种群抗体变异概率为0.75, 迭代次数为城市数的3.5倍, 30次测试得到的最大值为2628.5140, 最小值为2606.8601, 均值为2609.1480, 偏离最优路径的平均比率为0.86%.

2) 若采用CCICA算法, 子种群分为6个, 每个子种群抗体初始规模35, 子种群变异概率0.75, 环境负荷量$K = 75$, 种群间的竞争抑制指数为

$$a_{ij} = \frac{\alpha \cdot \mathrm{aff}(S_j) + (1-\alpha) \cdot F_{\max}(S_j)}{\alpha \cdot \mathrm{aff}(S_i) + (1-\alpha) \cdot F_{\max}(S_i)},$$

$\alpha < 1$的正常数, $\mathrm{aff}(S_j)$为第j个子种群的平均亲和度, $F_{\max}(S_j)$为第j个子种群亲和度最大的个体值), 30次测试得到的最大值为 2626.2182, 最小值为2597.4407, 均值为2608.0100, 偏离最优路径的平均比率为0.82%.

3) 若采用CCCICA算法, 子种群分为6个, 每个子种群抗体初始规模35, 子种群变异概率0.75, a_{ij}及环境负荷量K与CCICA设置一样, 30次测试得到的最大值为2629.0110, 最小值为2586.7696, 均值为2603.1524, 偏离最优路径的平均比率为0.632%.

其3种算法比较的收敛曲线见图2. 从上述结果及图2可以看出CCCICA在求解精度与收敛速度均优于MICA算法及CCICA算法.

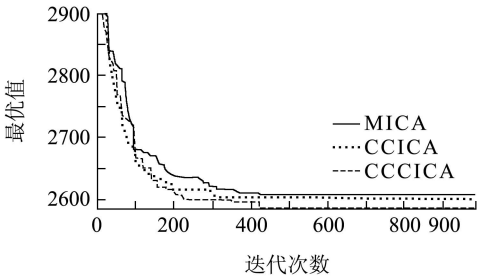

图 2 不同算法的收敛(a280)

Fig. 2 The convergent features of the different algorithms(a280)

表1、表2中的best, worst, avg, std, T, error分别代表一次迭代找到的最优值、最差值、均值、标准方差、平均求解时间及偏离最优路径的平均比率

$$\mathrm{error} = \sum_{i=1}^{30} (S_{T_i} - S_0)/30S_0 \times 100\%.$$

式中: S_{Ti}为第i次测试得到的值, S_0为TSPLIB提供的已知最优路径值. 从图1及表1可以看出CCICA在求解问题时所得到的最大值、最小值、均值、标准均方差及偏离最优路径的平均比率优于MICA算法, CCCICA所得到的最大值、最小值、均值、标准均方差及偏离最优路径的平均比率均优于CCICA算法与MICA算法, 说明了基于生态种群密度的协同进化算法的有效性, 以及优良个体交叉和优良个体迁移操作作用是明显的. 同时还可以看出CCCICA的求解时间复杂度并没有增大, 大部分实例CCCICA的求解时间复杂度比MICA, CCICA少, 这是因为CCCICA求解精度高, 收敛速度快, 能尽快找到最优解或者满意解, 所以节约了大量的时间.

表 1　其他实例3种ICA算法的比较(30次测试)

Table 1　Comparison of three algorithm(30 tests)

TSP实例测试(S_0)	算法	worst	best	avg	std	T/s	error/%
Eil51 (428.8718)	MICA	429.1179	428.8718	428.9403	0.11	69.8	0.016
	CCICA	428.9816	428.8718	428.9047	0.04	66.5	0.008
	CCCICA	**428. 8718**	**428.8718**	**428.8718**	**0**	**11.48**	**0**
Kroc100 (20750.8)	MICA	20852.2785	20750.7625	20771.0657	40.6	174.3	0.09
	CCICA	20852.2785	20750.7625	20760.9141	30.45	166.8	0.049
	CCCICA	**20750.7625**	**20750.7625**	**20750.7625**	**0**	**132.9**	**0**
Eil101 (642.3)	MICA	650.3956	640.2116	644.4464	3.31	182.3	0.39
	CCICA	649.0493	640.4219	644.2551	2.95	175.8	0.35
	CCCICA	**642.2416**	**640.2116**	**640.62**	**0.81**	**142.9**	**0**
Gr202 (489.099)	MICA	492.0689	488.7174	490.5203	1.78	1615.3	0.29
	CCICA	491.7781	487.8320	489.9422	2.12	1163.4	0.17
	CCCICA	**490.3508**	**487.2631**	**489.0657**	**1.73**	**703.39**	**0**
Pcb442 (5078.35)	MICA	5276.6	5118.0	5193.0	48.95	**11554.1**	2.26
	CCICA	5214.9945	5113.0214	5178.4137	37.77	15653.1	1.97
	CCCICA	**5198.268**	**5101.513**	**5111.2**	**29.02**	16653.1	**0.65**

表 2　其他实例4种免疫克隆选择算法的比较(30次测试)

Table 2　Comparison of four algorithms(30 tests)

TSP实例测试(S_0)	算法	worst	best	avg	std	T/s	error/%
Att48 (33524)	IDIA	34076	33524	33666	—	—	0.42
	ICA	33784	3353.7085	33614.85	99.69	22.3	0.27
	CCCIDIA	33588.34	33523.7085	33530.17	19.39	22.5	0.019
	CCCICA	**33523.7085**	**33523.7085**	**33523.7085**	**0**	**11.48**	**0**
Rd100 (7910.4)	IDIA	8182.0	7910.4	8021.4	—	—	1.4
	ICA	7944.3219	7910.3962	7931.0242	12.13	294.12	0.26
	CCCIDIA	7959.09	7910.3962	7922.32	14.43	166.8	0.15
	CCCICA	**7911.304**	**7910.396**	**7910.67**	**0.32**	**142.9**	**0.003**
Ch130 (6110.9)	IDIA	6318.3	6153.7	6218.8	—	—	1.77
	ICA	6231.7526	6112.8669	6170.1797	26.78	288.7	0.97
	CCCIDIA	6170.937	6125.071	6146.81	10.51	295.1	0.59
	CCCICA	**6143.75**	**6110.721**	**6122.704**	**7.98**	**275.0**	**0.194**
a280 (2586.8)	IDIA	2815.2	2621.6	2704.4	—	—	4.55
	ICA	2668.7999	2592.9980	2639.7102	17.51	1756.3	2.05
	CCCIDIA	2626.22	2589.015	2608.01	**8.49**	1849.6	0.82
	CCCICA	**2629.011**	**2586.769**	**2603.152**	9.8	**1601.4**	**0.63**
Pcb442 (5078.35)	IDIA	5468.83	5184.49	5278.40	—	—	3.94
	ICA	5276.6	5118.0	5193.0	48.9	32114.1	2.26
	CCCIDIA	5221.28	5122.23	5157.32	32.1	17653.1	1.55
	CCCICA	**5198.268**	**5101.513**	**5111.2**	**29.02**	**16653.1**	**0.65**

4.2 CCCICA与其他免疫克隆选择算法的性能比较(Comparisons between CCCICA and several immune algorithm)

实例2对ch150(城市规模150个)进行30次测试, 各算法的变异初始概率

$$P_{\mathrm{m}} = 0.75,$$

其中IDIA(文献[11]基于优势抗体的免疫算法), ICA(文中提出的局部最优免疫优势克隆选择算法)抗体种群规模为150, CCCIDIA(竞争合作型协同进化IDIA算法), CCCICA算法的抗体子种群数为6个, 每个子种群抗体初始规模35.

CCCICA 算法获得最大路径距离为 6601.7850, 最短路径距离为 6530.9025, 平均路径距离为 6570.4182, 偏离最优路径值的平均误差率为 0.58%, 得到的最短路径长度优于 TSPLIB 提供的最优路径长度 6532.3. ICA 算法得到最大值 6662.26, 最小值为 6563.16, 平均值为 6607.6, 偏离最优路径的平均比率为 1.15%. CCCIDIA 算法得到的最大值为 6659.9806, 最小值为 6558.16, 平均值为 6597.0687, 偏离最优路径值的平均误差率为0.99%, 同时CCCICA算法也优于文献[11]基于优势抗体的免疫 IDIA 算法获得最大路径长度为6805.6, 最优路径长度6568.4, 平均值6690.2, 偏离最优路径值的误差率为2.42%. 其收敛曲线如图3所示. 从图3可以看出CCCICA的收敛速度和求解精度均优于IDIA, ICA, CCCIDIA, 还可以看出ICA的收敛速度与求解精度高于IDIA. 这说明提出局部最优免疫算法优于IDIA, 但同时CCCIDIA的求解精度与收敛速度优于IDIA, 证实了基于一种竞争合作型的CCIDIA算法效果比较好.

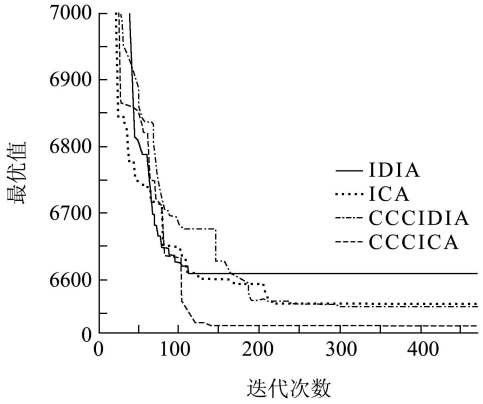

图 3 不同算法的收敛曲线(ch150)

Fig. 3 The convergent features of the different algorithms

表2中的IDIA为文献[11]基于优秀抗体的免疫算法, ICA为文中提出的单种群局部最优免疫优势克隆选择算法, CCCIDIA为竞争合作型协同进化IDIA算法. 从表2可以看出, CCCICA在求得的最大值、最小值、均值、标准方差及偏离最优路径的平均比率优于IDIA, ICA及CCCIDIA算法. 通过ICA算法与IDIA算法以及CCCICA算法与CCIDIA算法的比较证实了局部最优免疫优势算子的高效, 通过CCCIDIA算法与ICA和DIA算法以及CCCICA算法与ICA算法的比较, 进一步说明了竞争合作型协同进化算法的有效性.

4.3 CCCICA与其他智能算法的性能比较(Comparisons between CCCICA and other algorithms)

表3中KG(KNIES_TSP_Global), KL(KNIES_TSP_Local), KD(KNIES_DECOMPOSE)的结果引自文献[12]; SETSP(SOM efficiently applied to the TSP)的结果引自文献[13]. ISOM(泛化竞争和局部渗透机制的自组织网方法)数据结果来自文献[14].

表4中NGA为带贪婪算子的遗传算法其实验数据结果引自文献[11], FFM(填充函数变换方法)实验数据引自文献[15], ACS(改进的蚁群算法)优化结果引自文献[16]. 从表3、表4知, 文中CCCICA算法与其他智能算法性能的比较可以看出, CCCICA算法具有明显的优势. 随着城市规模的增大, CCCICA表现出优势越明显.

表 3 CCCIA与神经网络有关方法的比较(30次测试)

Table 3 Comparisons between CCCIA and neural network method(30 tests)

实例测试	error/%					
	KG	KL	KD	SETSP	ISOM	CCCICA
Eil51	2.86	2.86	3.53	2.22	3.8132	0
St70	2.33	1.51	3.67	1.60	2.1104	0
Eil76	5.48	4.98	6.49	4.23	4.6264	0.288
Rd100	2.62	2.09	4.89	2.60	3.4011	0.003
Lin105	1.29	1.98	2.18	1.30	0.2420	0.017
pcb442	10.45	11.07	8.00	10.16	8.1955	0.65
Pr1002	7.20	—	7.08	—	5.0090	2.31

表 4　CCCICA与NGA,ACS,FFM算法性能的比较(30次测试)

Table 4　Comparisons between CCCIA and NGA,ACS,FFM(30 tests)

Eil51(428.87)	NGA	460.7428	438.0805	445.7453	3.71
	ACS	437.80	428.87	429.48	0.14
	CCCICA	**487.87**	**428.87**	**487.87**	**0**
Eil76(544.37)	NGA	589.30	568.89	577.16	5.84
	ACS	565.16	545.97	553.77	1.73
	CCCICA	**550.4968**	**544.37**	**546.39**	**0.288**
KroA100(21285.44)	NGA	23340.8	22924.7	23076.2	8.41
	ACS	22499.74	21285.44	21456.98	0.81
	CCCICA	**21636.18**	**21285.44**	**21359.60**	**0.35**
D198(15808.65)	ACS	16936.53	15919.55	16143.66	2.12
	CCCICA	**15879.4109**	**15811.3409**	**15836.3510**	**0.18**
Att48(33524)	NGA	35594	34228	34584	3.16
	FFM	33523.71	33523.71	33523.71	0
	CCCICA	**33523.7085**	**33523.7085**	**33523.7085**	**0**
Rd100(7910.4)	NGA	8723.1	8291.2	8449.9	6.82
	FFM	7949.32	7910.4	7921.2	0.14
	CCCICA	**7911.3049**	**7910.3962**	**7910.6688**	**0.003**
Ch130(6110.9)	NGA	6724.9	6364.8	6570.1	7.51
	FFM	6194.54	6126.51	6152.8	0.69
	CCCICA	**6143.7507**	**6110.7219**	**6122.7045**	**0.19**
Ch150(6532.3)	NGA	7374.8	6955.9	7173.6	9.82
	FFM	**6560.94**	6533.81	**6537.3**	**0.076**
	CCCICA	6601.7850	**6530.90**	6570.4182	0.586
Ch144(30356)	FFM	30720.94	**30355.01**	30533.12	0.58
	CCCICA	**30643.4098**	30355.11	**30501.5037**	**0.48**

5　结论(Conclusions)

分析了人工免疫算法的特点, 提出了一种竞争合作型协同进化免疫优势克隆选择算法(CCCIA), 考虑了进化的环境和个体之间的复杂联系提高了人工免疫算法的收敛性能. 通过实验表明, 基于生态种群密度的协同进化算法的有效性, 优良库免疫杂交与迁移操作算子效果是明显的. 通过ICA算法与IDIA算法的比较证实了局部最优免疫优势算子的高效, 通过CCCIDIA算法与ICA和DIA算法的比较, 进一步说明了协同进化算法的有效性. CCCIA与神经网络有关方法的比较, 及与改进的遗传算法, 蚁群等智能算法性能的比较充分说明了CCCICA的高效性.

针对TSP多个标准实例进行了的测试, 结果表明: 该算法具有较好的收敛性, 较高的求解精度和很强的全局搜索能力. 但随着问题规模的增大, 算法的计算复杂度也会相应的增大, 既提高算法的精度又降低算法的复杂度是接下来的研究方向.

参考文献(References):

[1] DE CASTRO L N, ZUBEN F J V. Learning and optimization using the clonal selection principle[J]. *IEEE Transactions on Evolutionary Computation*, 2002, 6(1): 239 – 251.

[2] DASGUPTA D. Advances in artificial immune systems[J]. *IEEE Computational Intelligence Magazine*, 2006, 1(4): 40 – 49.

[3] AMANDA M, WHITBROOK, UWE AICKELIN, et al. Idiotypic immune networks in mobile–robot control[J]. *IEEE Transactions on Systems, Man, and Cybernetics-Part B: Cybernetics*, 2007, 37(6): 1581 – 1597.

[4] IDOCANOVA, FABIOFRESCHI, MICHELETARTAGLIA. Multi – objective optimization of parallel cable layout[J]. *IEEE Transactions on Magnetic*, 2007, 43(10): 3914 – 3920.

[5] FREITAS A A, TIMMIS J. Revisiting the foundations of artificial immune systems for data mining[J]. *IEEE Transactions on Evolutionary Computation*, 2007, 11(4): 521 – 530.

[6] 龚固丰, 章兢, 何昭晖, 等. 混合编码免疫算法在船舶载重计量的应用[J]. 控制理论与应用, 2009, 26(3): 349 – 352.
(GONG Gufeng, ZHANG Jing, HE Zhaohui, et al. Application of combinatorial-coded artificial immune system(AIS) to ship cargo

weighing[J]. *Control Theory & Applications*, 2009, 26(3): 349 – 352.)

[7] POTTER MA, DE JONG KA. A cooperative coevolutionary approach to function optimization[C] //*Proceedings of the 3rd Parallel Problem Solving from Nature*. Berlin: Springer-Verlag, 1994: 249 – 257.

[8] 尚玉昌, 蔡晓明. 普通生态学[M]. 北京: 北京大学出版社, 1996. (SHANG Yuchang, CAI Xiaoming. *Common Ecology*[M]. Beijing: Beijing University Press, 1996.)

[9] CHI-KEONG GOH, KAY CHEN TAN. A competitive-cooperative coevolutionary paradigm for dynamic multi objective optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2009, 13(1): 103 – 127.

[10] 曹先彬, 罗文坚, 王煦法. 基于生物种群竞争模型的协同进化[J]. 软件学报, 2001, 12(4): 556 – 562.
(CAO Xianbin, LUO Wenjian, WANG Xufa. A co-evolution pattern based on ecological population competition model[J]. *Journal of Software*, 2001, 12(4): 556 – 56.)

[11] 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, 2007.
(JIAO Licheng, DU Haifeng, LIU Fang, et al. *Immune Optimized Computer, Learning and Recognition*[M]. Beijing: Science press, 2007.)

[12] ARAS N, ALTINEL I K, OOMMEN BJA. Kohonen-like decomposition method for the euclidean traveling salesman problem-KNIES_DECOMPOSE[J]. *IEEE Transactions on Neural Networks*, 2003, 14(1): 869 – 890.

[13] VIEIRA F C, NETO A D D. An efficient approach to the traveling salesman problem using self-organizing maps[J]. *International Journal of Neural Systems*, 2003, 13(2): 59 – 66.

[14] 张军英, 周斌. 基于泛化竞争和局部渗透机制的自组织网TSP问题求解方法[J]. 计算机学报, 2008, 31(2): 220 – 227.
(ZHANG Junying, ZHOU Bin. Self-organizing map with general ized and localized parallel competitions for the TSP[J]. *Chinese Journal of Computers*, 2008, 31(2): 220 – 227.)

[15] 朱文兴, 傅清祥. 一个基于填充函数变换的对称TSP问题的局部搜索算法[J]. 计算机学报, 2002, 25(7): 701 – 707.
(ZHU Wenxing, FU Qingxiang. A filled function method for the travel ing salesman problem[J]. *Chinese Journal of Computers*, 2002, 25(7): 701 – 707.)

[16] ALICE R MALISIA, HAMID R. Tizhoosh applying opposition-based ideas to the ant colony system[C] //*Proceedings of IEEE Swarm Intelligence Symposium(SIS2007)*. Hawaii, USA: IEEE, 2007: 182 – 189.

作者简介:

刘朝华 (1983—), 男, 博士研究生, 主要从事计算机控制技术、智能控制控制理论与应用、智能系统的研究, E-mail: 163liuzhaohua@163.com;

章 兢 (1957—), 男, 教授, 博士生导师, 主要从事智能控制、复杂系统工业控制、节能减排管控一体化、智能系统的研究, E-mail: zhangj@hnu.cn;

张英杰 (1970—), 男, 博士, 副教授, 主要从事复杂工业系统计算机控制、智能计算、节能减排管控一体化研究, E-mail: zyj18502@hnu.cn;

吴建辉 (1970—), 男, 博士研究生, 主要从事智能计算、数字系统的研究, E-mail: wujianhui123@163.net.