

新型复杂进化全局优化算法的研究

郝海青^{1,2}, 马 航³, 庄 健⁴

(1. 华南理工大学机械与汽车工程学院, 广东广州 510006; 2. 广州大学土木工程学院, 广东广州 510006;
3. 南通大学附属第二医院呼吸内科, 江苏南通 226001; 4. 西安交通大学机械学院, 陕西西安 710049)

摘 要: 文章在复杂系统思想激励下设计了一种新型的基于复杂系统改进的进化算法, 该算法改进了进化算法的交叉、选择、变异和进化策略, 体现了进化过程中能量分布、空间搜索、信息利用的复杂性, 并保持了进化算法的简单结构框架; 进而通过计算实例分析了新型复杂系统进化算法两个主要参数对算法性能影响; 最后, 新算法测试了 CEC' 2012 大规模全局优化竞赛中的函数集合, 并与其他优秀算法的测试结果进行了对比, 结果表明本文所提出的基于复杂系统改进的进化算法综合性能强于所有的对比算法。

关键词: 复杂系统; 进化算法; 大规模; 全局优化

中图分类号: TP391.41

文献标识码: A

文章编号: 0372-2112 (2013)04-0704-06

电子学报 URL: <http://www.ejournal.org.cn>

DOI: 10.3969/j.issn.0372-2112.2013.04.013

The Study of a New Complex System Evolutionary Algorithm for Global Optimal Problems

HAO Hai-qing^{1,2}, MA Hang³, ZHUANG Jian⁴

(1. School of Mechanical and Automotive Engineering, South China University of Technology, Guangzhou, Guangdong 510006, China;

2. School of Civil Engineering, Guangzhou University, Guangzhou, Guangdong 510006, China;

3. The Respiratory Department of the Second Affiliated Hospital of Nantong University, Nantong, Jiangsu 226001, China;

4. School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an, Shaanxi 710049, China)

Abstract: Inspired by some complex system concepts, a new evolutionary algorithm is designed in paper. In the new algorithm, crossover, selecting operator, mutating operator and evolutionary strategy are improved by some characteristic properties of complex system. These improvements represent the complexity of energy distribution, space searching and information use during the evolution. And the simple procedure structure of evolutionary algorithm is reserved. Then, the influences of two parameters are discussed in paper. Finally, all functions of CEC' 2012 competition on large scale problems are tested by the new evolutionary algorithm. And testing results of the new evolutionary algorithm are compared with those of other excellent algorithms. The results show that comprehensive capabilities of the new evolutionary algorithm, presented in the paper, are better than all comparing algorithms.

Key words: complex system; evolution algorithm; large scale; global optimization

1 引言

进化算法与群智能优化算法均属于一类模拟生命系统的随机优化算法, 主要包括遗传算法^[1,2]、粒子群算法^[3]等。目前, 进化算法仅仅是对生物进化或生命活动的简单模拟, 而生命系统具有非均匀性、非线性性、自适应性和网络性等特性, 是一类巨型的复杂系统。自然界中生物种群数目庞大、种群的分布多样, 并且进化过程不仅仅是同一物种内部相互作用, 还包括了不同物种

之间的关系(共生、寄生)以及物种与环境之间的互动, Martin A 等人系统地给出生物在进化过程中合作的五种法则^[4], 所以模拟其活动的进化算法也应该属于复杂系统的范畴。基于上述理念, 本文所研究的新型基于复杂系统改进的进化算法(Evolutionary Algorithm Improved by Complex System Concepts, EACSC)将以复杂系统的理念来重新考虑进化算法的结构和参数之间的平衡关系, 从而提高进化算法的优化性能。

2 相关工作

复杂系统目前还没有一个公认的、清晰的定义,通常复杂系统可以用多个基本特性来反映,其具有非均匀性、非线性性、自适应性、网络性等特性^[5].人们已经采用许多与复杂系统相关的理念对进化和群智能优化算法做了相关的改进.在遗传算法中,Rechenberg 的“1/5成功法则”是变异概率适应参数控制法的一个早期例子^[6],该方法体现进化过程的信息反馈机制;在我们先前研究中也尝试在遗传算法中引入复杂系统概念,提高了遗传算法的寻优性能^[7].而在粒子群算法中,用复杂系统特性改进算法性能的例子则更多,主要体现在多种群方法和种群内部的网络关系.多种群粒子群算法用来改善算法执行过程中的种群分布,Kennedy 采用聚类算法实现粒子的多种群^[8].动态多子群粒子群优化器^[9]则采用一种动态与随机相邻关系拓扑结构,该算法在多模态问题上执行效果要优于其它的粒子群算法,但是其局部搜索能力不能令人满意.

3 复杂系统进化算法

本文所研究的 EACSC 包括了选择操作,交叉算子,变异算子,更新操作等 4 个主要操作,为了便于后续的描述,首先定义算法中一些集合符号的意义.

D 是待优化问题的维数; NP 为种群规模, \mathbf{X} 表示种群,其包含了 NP 个向量 \mathbf{x} ,每个向量表示种群中的一个个体,也是待优化问题的完整参数(\mathbf{x}^* 为最优解集); x 是构成 \mathbf{x} 向量的变量,也代表待优化问题每维的参数值, i 是种群中个体的下标, $i = \{1, 2, \dots, NP\}$, j 是向量下标 $j = \{1, 2, \dots, D\}$, $f(\cdot)$ 为适应度函数; FEs (Function Estimate Times) 为算法计算测试函数的次数, $rand(\cdot)$ 为 0-1 范围之内的均匀分布的随机数.

EACSC 属于群体进化算法的一种,其中,进化父代种群 \mathbf{X}_{ef} 构成了进化种群空间,并保存进化的结果;进化子代种群 \mathbf{X}_{es} 是进化过程中的临时种群,保存进化过程中的局部结果;记忆种群 \mathbf{X}_s 在进化中为了保证种群内模式的多样性而开辟的记忆空间,其规模建议为种群规模 NP 的 10 ~ 20 倍,用来保存近期几代的进化父代种群;交配雄性种群 \mathbf{X}_{mm} 从进化父代种群 \mathbf{X}_{ef} 通过一定规则选择出来,并作为进化子代种群产生的父体;交配雌性种群 \mathbf{X}_{mf} 从进化父代种群和记忆种群所构成的联合种群中通过一定规则选择出来,并作为进化子代种群产生的母体.

3.1 选择算子

在复杂系统研究中,人们发现诸如生物链中的能量传递、都市人口、网站规模、英文字符出现频率、国民生产总值等都符合所谓的幂次法则,该法被认为是复

杂系统自组织能力的表现,是系统能量合理分配的一种体现.在生物进化中,总是少数的高适应度个体雄性占有更多的资源,与幂次法则现象基本一致,所以在交配雄性种群的选择规则中引入幂次法则.借鉴于网络规模分布模型^[10],在 t 代时进化父代种群中个体 $\mathbf{X}_{ef,i}$ 被选为交配雄性种群 \mathbf{X}_{mm} 中个体的概率为:

$$P(T_{sf}(\mathbf{X}_{ef,i}^t) = \mathbf{X}_{mm,i}^t) = \frac{10^{c \cdot \text{rank}(f(\mathbf{X}_{ef,i}^t))}}{\sum_{i=1}^{NP} 10^{c \cdot \text{rank}(f(\mathbf{X}_{ef,i}^t))}}$$

$$\text{rank}(f(\mathbf{X}_{ef,\max}^t)) = 0,$$

$$\text{rank}(f(\mathbf{X}_{ef,\min}^t)) = NP - 1$$
(1)

式中: $T_{sf}(\cdot)$ 为交配父代选择规则, $c = -2.45$, $\text{rank}(\cdot)$ 为排序函数(在 NP 规模种群中适应度值最大的排序函数值为 0,最小的排序函数值为 $NP - 1$).

由于数值模拟的进化计算中种群规模有限(本文中种群规模为 $N < 20$),为了充分利用种群内部模式,交配雌性种群 \mathbf{X}_{mf} 的在进化父代种群和记忆种群的合集中选取,采用随机选择策略.

3.2 交叉算子

在生物进化过程中,环境对其进化有着显著的影响.在自然界中的不同种类生物如果生活在条件相同的环境中,在同样选择压的作用下,有可能产生功能相同或十分相似的形态结构,以适应环境,该现象被称为趋同进化.并且生物能够通过自身学习的特性来改造自身周围的环境等方法到达加速或改变自身的进化,生物修复环境的过程被称为生态位构建^[11],比如:白蚁独特巢穴结构实现了通风调温功能,保证了白蚁生存最佳条件.因此在算法中,设计一种环境学习变量,进化群体中的每个个体能拥有自身的环境变量,该环境变量通过迭代学习的方式既保持过去的已有的经验,又通过由选择压力所获取对父代和母代之间的遗传编码差分来获得新的经验,最后再将由环境学习变量反作用于该个体自身的遗传编码.环境变量可以描述为:

$$e_{ij}^{t+1} = \begin{cases} r_1 e_{ij}^t + r_2 (x_{mm,ij}^t - x_{mf,ij}^t), & \text{if } (rand() \leq 0.618) \\ r_1 e_{ij}^t + r_2 (x_{mf,ij}^t - x_{mm,ij}^t), & \text{others} \end{cases}$$
(2)

式中 r_1 为记忆系数, r_2 是学习系数.在本文中 r_1 在 0.2 ~ 0.8 之间的均匀分布,并且所有 e_{ij} 的学习系数一致. r_2 建议值为 1.0.

式(2)中,进化方向包括交配雄性个体和交配雌性个体两个方向,由于交配雄性个体是通过幂次法则选择获得的,其代表了当前最优,从而环境学习变量向局部最优方向收敛;而交配雌性个体是由随机选择而产生,因此环境学习变量向随机方向移动,保证环境变量的多样性.环境学习变量向两个方向移动的概率按黄

金分割比例分配。

EACSC 算法的交叉算子中考虑引入一项表示将来的信息,对进化方向进行预测.当进化子代种群 X_{es} 中个体的代价函数大于相应的进化父代种群 X_{ef} 中个体时,其编码空间的进化方向预测变量描述为:

$$d_{ij}^t = x_{es,ij}^t - x_{ef,ij}^t, \quad \text{if}(f(\bar{X}_{es,i}^t) > f(\bar{X}_{ef,i}^t)) \quad (3)$$

式(3)实质是进化算法在上次成功进化的方向,是对进化方向的预测,能够加速算法的收敛速度.综上所述,EACSC 的交叉算子如下式所示:

$$T_c(x_{es,ij}^t | x_{mm,ij}^t, x_{mf,ij}^t) = x_{es,ij}^{t-1} + \frac{1}{2}(r_3 e_{ij}^t + r_4 d_{ij}^t) \quad (4)$$

式中: $T_c(\cdot)$ 为交叉算子, r_3, r_4 为权重系数. r_3, r_4 建议在 $[1.4, 0.0]$ 之间的均匀分布.

3.3 变异算子

算法中采用了两种变异操作来模拟生物的变异,他们分别是直接变异操作和交换变异操作,并采用概率驱动切换.算法的参数采用泛化到 $[0, 1]$ 空间的实数,其为 20 位十进制编码的小数,其参数可以表述为:

$$x_{ij} = \sum_{k=1}^{20} c_k 10^{-k}, \quad c_k \in \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\} \quad (5)$$

直接变异操作就是在 20 个系数 c_k 中任意选择一位 c_m ,并在集合 $\{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}$ 随机选择一个数 b_m 代替 c_m ,从而产生新的参数,如式(6);交互变异是 20 个系数 c_k 中任意选择两位 c_m, c_n ,并交换这两个系数的位置而产生新的参数,如式(7).

$$T_{m_1}(x_{ef,(i,j)}) = \dots + b_m 10^{-m} \dots + c_m^{i,j} 10^{-20} \\ \forall c_m^{i,j} \in [c_1^{i,j}, \dots, c_{20}^{i,j}], \forall b_m \in [0, \dots, 9] \quad (6)$$

$$T_{m_2}(x_{ef,(i,j)}) = \dots + c_n^{i,j} 10^{-m} \dots \\ + c_m^{i,j} 10^{-n} \dots + c_{20}^{i,j} 10^{-20} \\ \forall c_m^{i,j}, \forall c_n^{i,j} \in [c_1^{i,j}, \dots, c_{20}^{i,j}] \quad (7)$$

因此,变异算子可以描述为:

$$T_m(x_{es,(i,j)}) = \begin{cases} T_{m_1}(x_{es,(i,j)}) \text{ or} \\ T_{m_2}(x_{es,(i,j)}) \end{cases} \quad (8)$$

式中 $T_m(\cdot)$ 是变异算子, $m_1(\cdot)$ 是直接变异操作, $m_2(\cdot)$ 是交换变异操作;

而变异概率 p_m 采用了动态变异概率的形式,其遵循短时极端情况大概率变异原则^[12],变异概率如下式所示.

$$p_m(t) = \begin{cases} 1/D, & \text{if}(rand() \geq 0.99) \\ 5/D, & \text{others} \end{cases} \quad (9)$$

3.4 更新操作

更新操作目前一般采用贪婪策略,既是只有子代个体的适应度值大于父代时,子代个体取代父代个体.贪婪策略能够使种群迅速集中到目标函数最优解的附

近,增加了算法的寻优速度,但是会造成种群内模式的丢失,因此在 EACSC 中为了能够控制种群内模式的多样性,增加了一个更新多样性控制参数 p_g ,如果子代个体的适应度值大于父代时,子代个体取代父代个体;反之,当子代个体适应度值小于父代个体时,子代个体取代父代个体的概率为 p_g .更新操作可以描述为:

$$x_{ef,i}^t = x_{es,i}^t; \text{if}((f(x_{es,i}^t) > f(x_{ef,i}^t)) \text{ or } (rand() \leq p_g)) \quad (10)$$

更新多样性概率 p_g 其实质是反映了子代种群内的多样性,如果更新多样性概率 p_g 值增大则子代种群中的多样性增加,算法趋于随机搜索;反之,则子代种群中的多样性减少,算法趋于收敛.本文所研究算法的收敛性仅依赖式(10),而与具体策略和算子无关,其收敛性与通常的精英保留策略进化算法类似.

3.5 算法的伪码

- (1) 置算法参数:建议 $NP = 10, p_c = 0.7, p_g = 0.01$;
- (2) 群体初始化;
- (3) 获取群体中最优适应度值,并保存为杰出个体,更新记忆种群;
- (4) 判断是否满足停止条件,如果满足则跳转到步骤(5),否则执行步骤(4.1);
 - (4.1) 按式(9)计算变异概率 p_m ;
 - (4.2) 采用式(1)规则选取交配雄性种群个体;和交配雌性种群个体;
 - (4.3) 根据交叉概率 p_c 判断是否交叉,是则进入(4.3.1),否则进入(4.4);
 - (4.3.1) 进化子代种群中个体每维的环境学习变量按式(2)迭代修改;
 - (4.3.2) 进化子代种群中个体每维的参数值按式(4)迭代修改,执行步骤(4.5);
 - (4.4) 不发生交叉操作的进化子代种群个体基因随机从交配父体和母体中获取;
 - (4.5) 对于进化子代种群中所有个体的每维参数,按照式(8)进行变异操作;
 - (4.6) 计算进化子代种群中所有个体的适应度值,按照式(10)策略更新新一代进化父代种群,返回步骤(3);
- (5) 输出结果,结束程序.

4 计算测试及结果分析

测试环境为:WindowsXP 操作系统,2.0GHz CPU,2G 内存,VC++ 6.0 开发软件,EACSC 算法测试程序可以在 <http://www.74tiger.com/download.htm> 下载.

4.1 方向预测算子分析

选择 CEC'2012^[13] 竞赛测试函数集中的 F_{20} 函数

来检测方向预测算子的作用.分别采用有和无方向预测算子 EACSC 对 F_{20} 在 100, 500, 1000 维优化, 终止条件 $FES = D * 5000$, 连续测试 25 次, 统计误差 ($e = f(\mathbf{x}) - f(\mathbf{x}^*)$) 测试结果.

由表 1 ~ 表 3, 可以发现方向预测算子在算法中起到了改善算法寻优的质量, 不仅提高了算法的发现高质量优化解集的能力, 并且也明显改善了多次测试下解集的分布情况.

表 1 方向预测算子分析数据表 $D = 100$

方向预测算子	1 st	25 th	Mean	Std
无	2.1e-10	3.3e-04	1.5e-05	6.6e-05
有	7.1e-12	7.5e-08	6.6e-09	1.7e-08

表 2 方向预测算子分析数据表 $D = 500$

方向预测算子	1 st	25 th	Mean	Std
无	3.9e-03	3.6e+02	1.1e+02	1.3e+02
有	8.6e-07	1.6e+02	3.4e+01	5.4e+01

表 3 方向预测算子分析数据表 $D = 1000$

方向预测算子	1 st	25 th	Mean	Std
无	5.4e+02	9.0e+03	1.9e+03	5.3e+03
有	3.6e+02	1.1e+03	7.2e+02	2.0e+02

4.2 EACSC 算法复杂度测试

选取 CEC'2008 测试函数 F_1 - F_6 , 测试维数从 50 维 ~ 500 维, 每次递增量为 50 维, 停止条件是误差值小于 $0.1((e = f(\mathbf{x}) - f(\mathbf{x}^*) < 0.1)$, 每个函数连续测试 10 次, 求出其平均时间消耗值. 为了给出 EACSC 算法的平均计算消耗时间与维数变化之间相互关系图, 将图的 y 坐标按下式计算:

$$t_{\text{comp}, k} = \frac{t_k - t_0}{t_0}; k = 1, \dots, 10 \quad (11)$$

通过图 1, 发现 EACSC 算法的复杂度与待测问题相关, 并与优化问题的维数相关; 测试函数 F_2 的计算代价与维数关系可以认为是按指数形式增加, 而测试函数 F_1 、 F_5 、 F_6 则是类似与线性, 测试函数 F_3 、 F_4 则比相对较复杂.




图 1 测试函数 F_1 - F_6 的平均消耗时间增量与维数关系图, $D=50-500$, $step=50$

4.3 EACSC 算法参数分析

EACSC 算法所需要手工设置的参数共有 3 个, 分别

是群体规模 NP 、交叉概率 p_c 、更新多样性概率 p_g , 其中群体规模已经有许多参考文献研究, 本文不再讨论. 为了对比其他两个参数对算法的影响, 选取了如下两个函数进行测试.

$$F_{11}(x_i) = \text{Min} \left(\sum_{i=1}^D x_i^2 \right) \quad (12)$$

$$F_{12}(x_i) = \text{Min}(\text{Max}(x_i)) \quad (13)$$

测试函数 F_{11} 具有较好梯度信息, 而测试函数 F_{12} 则没有梯度信息可以利用. 两个函数的测试维数均为 100 维, 终止条件为 $FES = 5.0e + 05$, p_g 从 0.0 到 0.8, 增加步距为 0.2, p_c 从 0.05-0.75 增加步距为 0.05; 测试结果如图 2 和图 3 所示.




图 2 F_{11} 测试函数参数分析图, $D=100$, $Fes=500,000$




图 3 F_{12} 测试函数参数分析图, $D=100$, $Fes=500,000$

通过测试函数参数分析图发现: 对于 F_{11} 具有较好梯度信息的函数, 当 $p_g = 0$ 时 EACSC 算法解集质量要明显好于 $p_g \neq 0$ 的情况; 而对于 F_{12} 没有梯度信息的函数, 当 $p_g = 0$ 时 EACSC 算法解集质量要明显差于 $p_g \neq 0$ 的情况, 所以对于没有较好梯度信息的函数时, 合适的 p_g 值会改善 EACSC 最优解集的质量. 交叉概率 p_c 与更新多样性概率 p_g 存在着一定耦合关系, 在大部分情况下取值范围在 $[0.1, 0.7]$ 之间, 一般认为 p_g 越大算法全局搜索能力越强, 而 p_c 越大局部搜索能力越好.

4.4 EACSC 算法性能对比

EACSC 测试了 CEC'2012 会议中大规模全局优化竞赛中的测试函数, 测试方法完全按照竞赛要求. 选取 DECC-G^[14]、DECC-G*、MLCC^[15] 优化结果与 EACSC 进行了对比, 如表 4 所示.

通过对比数据表 4 可以发现 EACSC 在 20 个体测试函数中有 10 个 ($F_2, F_4, F_6, F_7, F_8, F_{12}, F_{13}, F_{18}, F_{19}, F_{20}$) 在 4 种算法中排名第一, 优化结果要好于具有先验知识 DECC-G* 算法. 在处理有偏移的可分离大规模优化函数 ($F_1 - F_3$) 时, EACSC 综合性能排名第二, 其对 1000 维的 F_1, F_3 优化函数结果均值也分别达到 10^{-18} 和 10^{-8} ; 在处理单组 m 维不可分离函数 ($F_4 - F_8$) 时, EACSC 的性能最好, 其中 $F_6 - F_7$ 的优化结果以数量级形式高于其他三种算法; 在处理 $D/2m$ 分组 m 维不可分离优化函数 ($F_9 - F_{13}$) 时, EACSC 算法综合性能排名第二, 排在有先验知识的 DECC-G* 算法之后, 但与其性能差距不大; 在处理 D/m 分组有偏移 m 维不可分离函数时 ($F_{14} - F_{18}$) 时, EACSC 有 F_{18} 测试函数排名第一, 如果不考虑 DECC-G* 算法, EACSC 的综合性能要好于其他两个算法; 在处理不可分离函数 ($F_{19} - F_{20}$) 时, EACSC 性能最好, 其优化结果高出其他三种算法一个数量级以上.

表 4 CEC'2012 结果对比表

	F_1	F_2	F_3	F_4
EACSC	1.14e-18	1.99e-01	1.48e-08	3.86e+11
DECC-G	2.93e-07	1.31e+03	1.39e+00	1.70e+13
DECC-G*	8.81e-12	4.42e+02	3.30e-08	2.29e+12
MLCC	1.53e-27	5.57e-01	9.88e-13	9.61e+12
	F_5	F_6	F_7	F_8
EACSC	4.33e+08	2.12e-07	2.79e-10	6.38e+05
DECC-G	2.63e+08	4.96e+06	1.63e+08	6.44e+07
DECC-G*	2.45e+08	8.77e-03	1.10e+07	6.14e+07
MLCC	3.84e+08	1.62e+07	6.89e+05	4.38e+07
	F_9	F_{10}	F_{11}	F_{12}
EACSC	4.23e+07	5.25e+03	1.97e+02	5.34e+00
DECC-G	3.21e+08	1.06e+04	2.34e+01	8.93e+04
DECC-G*	1.41e+07	2.48e+03	3.52e-02	7.87e+01
MLCC	1.23e+08	3.43e+03	1.98e+02	3.49e+04
	F_{13}	F_{14}	F_{15}	F_{16}
EACSC	2.03e+02	1.36e+08	1.03e+04	3.94e+02
DECC-G	5.12e+03	8.08e+08	1.22e+04	7.66e+01
DECC-G*	5.50e+02	2.91e+07	3.88e+03	4.01e-01
MLCC	2.08e+03	3.16e+08	7.11e+03	3.76e+02
	F_{17}	F_{18}	F_{19}	F_{20}
EACSC	6.76e+02	9.48e+02	1.60e+05	7.23e+02
DECC-G	2.87e+05	2.46e+04	1.11e+06	4.06e+03
DECC-G*	1.03e+02	1.08e+03	1.14e+06	3.33e+03
MLCC	1.59e+05	7.09e+03	1.36e+06	2.05e+03

5 结论

本文在复杂系统思想激励下设计了一种新型的用于全局优化的进化算法, 进而分析两个主要参数对 EACSC 算法性能的影响, 并测试了 CEC'2012 大规模全局优化竞赛中函数集合, 对比了测试结果, 其结果表

明: 本文所设计的复杂系统进化算法在全局高维优化中具有很好的性能, 体现了较强的全局和局部搜索能力, 其综合性能要强于所有的对比算法.

参考文献

- [1] 何宏, 谭永红. 一种基于动态遗传算法的聚类新方法[J]. 电子学报, 2012, 40(2): 254 - 259.
HE Hong, TAN Yong-hong. A novel clustering method based on dynamic genetic algorithm [J]. Acta Electronica Sinica, 2012, 40(2): 245 - 259. (in Chinese)
- [2] 李军华, 黎明. 噪声环境下多模态函数优化的遗传算法[J]. 电子学报, 2012, 40(2): 327 - 330.
LI Jun-hua, LI Ming. Genetic algorithm for multi-modal function optimization in noisy environments [J]. Acta Electronica Sinica, 2012, 40(2): 245 - 259. (in Chinese)
- [3] 程祥, 张忠宝, 等. 基于粒子群优化的虚拟网络映射算法[J]. 电子学报, 2011, 39(10): 2240 - 2244.
CHENG Xiang, ZHANG Zhong-bao, et al. Virtual network embedding based on particle swarm optimization [J]. Acta Electronica Sinica, 2011, 39(10): 2240 - 2244. (in Chinese)
- [4] Martin A Nowak, A Five rules for the evolution of cooperation [J]. Science, 2006, 314(12): 1560 - 1563.
- [5] V Itousek PM, Moon Eyha, Lubchenco J, Melillo JM. Human domination of earth's ecosystems [J]. Science, 1997, 277(25): 494 - 299.
- [6] Rechenberg I. Evolutions Strategie: Optimierung Technischer Systeme Nach Prinzipien Der Biologischen Evolution [M]. Frommann-Holzboog Verlag, 1973.
- [7] 庄健, 杨清宇, 等. 一种高效的复杂系统遗传算法[J]. 软件学报, 2010, 21(11): 2791 - 2802.
ZHUANG Jian, YANG Qing-Yu, et al. High efficient complex system genetic algorithm [J]. Journal of Software, 2010, 21(11): 2791 - 2802. (in Chinese)
- [8] J Kennedy. Stereotyping: Improving particle swarm performance with cluster analysis [A]. Proceedings of the Congress Evolutionary Computation [C]. CA, San Diego: IEEE, 2000. 1507 - 1512.
- [9] J J Liang, P N Suganthan. Dynamic multi-swarm particle swarm optimizer [A]. Proceedings of IEEE International Swarm Intelligence Symposium [C]. USA: IEEE, 2005. 124 - 129.
- [10] R Albert, H Jeoung, A-L Barabasi. Diameter of the world wide web [J]. Nature, 1999, 401(9): 130 - 131.
- [11] K N Laland, F J Odling-Smee, M W Feldman. Evolutionary consequences of niche construction and their implications for eecology [J]. PNAS, 1999, 96(18): 10242 - 10247.
- [12] Dirk Thierens. Adaptive mutation rate control schemes in genetic algorithms [A]. Proceedings of the IEEE Congress on

Evolutionary Computation[C]. USA: IEEE, 2002. 980 – 985.

[13] Evolutionary Computation for Large Scale Global Optimization [OL]. <http://staff.ustc.edu.cn/~ketang/cec2012/cec2012lsgo.htm.pdf>. 2012.

[14] Zhenyu Yang, Ke Tang, X Yao. Large scale evolutionary optimization using cooperative convolution[J]. Information Sci-

ences, 2008, 178(15): 2985 – 2999.

[15] Zhenyu Yang, Ke Tang, Xin Yao. Multilevel cooperative convolution for large scale optimization[A]. Proceedings of the IEEE Congress on Evolutionary Computation (CEC) [C]. Washington, DC, USA: IEEE, 2008. 1663 – 1670.

作者简介



郝海青 女. 1977年9月生, 山西寿阳人. 2001年毕业于西安交通大学, 现为广州大学土木工程学院教师, 主要从事优化算法, 微机电系统的无线能量传输技术等相关研究.

E-mail: hqhao2006@163.com



马航 男. 1974年6月出生, 江苏南通人. 1997年毕业于南通医学院临床医学系, 现为江苏省南通市第一人民医院呼吸内科副主任医师. 主要从事智能诊断方法在呼吸疾病中的应用等研究工作.