

基于量子计算模型的混合进化算法及其性能分析

游晓明, 刘 升, 王裕明

(上海工程技术大学电子电气工程学院, 上海 201620)

摘 要: 提出了基于量子动力学机制的混合进化算法, 该算法依据小生境机制将初始个体划分为实数编码染色体的子群, 种群内部采用自适应算子搜索局域的最优解, 种群之间则采用基于量子动力学机制的协同进化. 混沌系统生成的初始染色体序列实际上并不完全随机, 因此我们提出非对称区间产生混沌染色体序列并能生成更多的优秀个体. 为解决二进制算法所不能避免的精度与效率的冲突, 本文采用十进制编码染色体. 利用量子动力学机制的高度分布并行性, 本模型能更好的适应复杂的动态环境. 我们不仅证明了算法的收敛性而且分析了提高算法性能的策略, 仿真实验也验证了该算法的优越性.

关键词: 量子进化算法; 量子动力学机制; 协同进化; 多峰函数优化; 实数编码染色体

中图分类号: TP301.6 **文献标识码:** A **文章编号:** 0372-2112 (2012) 04-0856-05

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

DOI: 10.3969/j.issn.0372-2112.2012.04.039

Hybrid Evolutionary Algorithm Based on Quantum Computing and Performance Analysis

YOU Xiao-ming, LIU Sheng, WANG Yu-ming

(College of Electronic and Electrical Engineering, Shanghai University of Engineering Science, Shanghai 200065, China)

Abstract: A novel Hybrid Evolutionary Algorithm based on Quantum computing (HQEA) is proposed. In the algorithm population is divided into subpopulations by niche methods. Each subpopulation can obtain optimal solution by the self-adaptive operator and all subpopulations can co-evolve by quantum dynamic mechanism. Initialization chaotic sequence is not as well as random in homogeneity, so this approach proposes strategy of unsymmetrical area to obtain optimal solution more. This approach adopts real-coded chromosome to solve precision and efficiency problem of binary system. The algorithm can adjust to dynamic environment more because of the distributed and parallel characteristic based on quantum dynamic mechanism. The convergence of the HQEA is proved and the strategy for improving the performance of HQEA has been analyzed. Its superiority is shown by some simulation experiments in this paper.

Key words: quantum evolutionary algorithm; quantum dynamic mechanism; coevolutionary; multi-modal function optimization; real-coded chromosome

1 引言

自从生物进化的理论被人类接受之后^[1], 生物学上的研究成果就迅速被其它学科广泛应用. 其中遗传算法由 Holland 在 1975 年提出, 此算法为具有 NP 复杂性的问题提供有效的近似求解方法. 近年来, 一种被称为量子计算^[2]的新型搜索方法引起了人们广泛的关注, 理论研究表明, 量子计算具有高度分布并行性.

Han 首次将量子的概率幅表达引入遗传算法^[3]. 后来许多学者在算法上进行了改进, 并用实验结果证明性能更加良好^[10], 但进化算法容易陷入局部最优等问题还是不易克服. 特别对于多峰值函数的优化问题, 如何

确保搜索到尽可能多的优化解, 以及如何保持算法的稳定性, 一直是受到关注的热点和难点.

本文以求解多模态函数的优化问题为例, 对笔者在文献[7]中免疫量子进化算法做了相应改进, 并进一步讨论其中的理论基础和实现技术. 文献[7]算法中依据小生境机制将量子表达的初始种群划分为 m 个子群组 $G_i(0)$: 由预定义的半径 δ 克隆选择抗体; 由给定的抑制阈值 ϵ 抑制相似性抗体. 本文则依据混沌系统遍历的非均匀性质将克隆半径修改为非对称的区间, 然后, 每个子群 $G_i(0)$ 利用自适应搜索算子找出优化解, 各种群之间则采用基于量子动力学机制的协同进化. 为解决二进制算法所不可避免的精度与效率的冲突, 本文采用十进

制编码染色体,最终算法可保持所有优化解.利用量子动力学机制的高度分布并行性,本模型能更好的适应复杂的动态环境.文中分析了提高算法性能的策略,仿真实验也验证了改进后算法的优越性.

2 量子计算模型及混沌系统

混沌是自然界中一种较为普遍的现象,具有随机性、遍历性及规律性等特点^[8,9].混沌优化过程分两个阶段进行:首先,在变量的取值范围内依次遍历经过各点,接受较好点作为最优点,然后,以当前最优点为中心,附加混沌扰动,附加小扰动可进行细搜索寻找最优点,附加大扰动则可作为避免陷入局部极小的优化搜索机制,恰好可以弥补遗传算法易陷入局部最优,收敛速度慢的缺陷.

经典计算机的存储单元是比特,它只有两种状态,或者为0,或者为1.在量子信息论中,信息的载体是一个一般的二态量子体系,它的态空间有两个基,记为 $|0\rangle$ 和 $|1\rangle$.如果有 n 位的量子位,可同时表示 2^n 种状态,因而在对量子比特计算时,一次运算相当于对 2^n 种状态同时操作,这就是量子并行性的由来.

量子的动力学机制^[5]是研究分布式智能处理模型的核心.由波粒二象性概念,自然界所有的粒子(如光子、电子或是原子),都能用一个微分方程,如薛定谔方程来描述.这个方程的解即为波函数,它描述了粒子的状态.波函数具有叠加性,它们能够像波一样互相干涉和衍射;波函数也被解释为描述粒子出现在特定位置的几率幅.这样,粒子性和波动性就统一在同一个解释中.

3 基于量子动力学机制的混合进化算法

3.1 算法描述

基于量子动力学机制的混合进化算法(HQEA)用于求解多模态函数优化问题,其结构可描述如下:

```

HQEA()
{
  初始  $Q(0)$ ;
  由  $Q(0)$ 生成  $R(0)$ 并评价  $R(0)$ ;
  生成  $m$ 个记忆抗体  $R'(0) = \{r_1, r_2, \dots, r_m\}$ ;
  依据小生境方法由  $R'(0)$ 产生  $m$ 个子群组  $G_i(0)$ 
  {以  $r_i$ 为局部最优点由预定义的半径  $\delta$ 采用非对称区间克隆混沌抗体;
  由给定的抑制阈值  $\epsilon$ 抑制相似性抗体;}
  For 每个子群组  $G_i(0)$ 
  While(not termination-condition)do
  {  $t = t + 1$ ;
  子群  $G_i(t)$ 间采用基于量子动力学机制的协同进化;
  对  $G_i(t)$ 实施免疫算子: {细胞交叉、变异;记忆抗体产生;}
  评价  $G_i(t)$ ;
  保存  $G_i(t)$ 中的最优解;
  }
}

```


3.2 染色体编码

量子表达的染色体转换为十进制编码,具体做法如下:每个参数用一个量子位 $q_i = \alpha_i|0\rangle + \beta_i|1\rangle$ 表示,观察 q_i 的状态产生十进制解 X_i ,即产生 $[0, 1]$ 随机数 R_i ,若 R_i 大于 $|\beta_i|^2$ 则 X_i 取值为 $|\beta_i|^2$,否则 X_i 取值为 $|\alpha_i|^2$.

同样实数编码染色体转换成量子的概率幅表达,具体做法如下:设 $l \leq X_j \leq h$,令 $\omega_j = \arcsin(\frac{X_j - l}{h - l})$,则 $q_j = \cos(\omega_j)|0\rangle + \sin(\omega_j)|1\rangle$ 为实数 X_j 的量子概率幅表示染色体.

3.3 基于量子动力学机制的协同进化

把每个子群抽象为粒子,它们在力场中间运动(图1).每个粒子在力场中的垂直坐标位置,与该粒子所对应子群所获得的收益有关,力场中粒子受到力场本身的向上引力的作用,由此产生的垂直向上的运动分量,表示粒子力求增加全局收益的程度.同一力场中的粒子之间的相互作用力,产生垂直向上或者向下的运动分量,表示粒子之间的合作、竞争等交互作用的影响程度.广义粒子模型中的粒子不仅受到外力的作用,而且还具有自身的驱动力,它表示该粒子追求自身最大收益的程度.粒子在力场引力、粒子间相互作用力、自身驱动力的共同作用下,向上的合力越大,粒子在力场中向上的运动越快.这种动态调节将相互影响,共同决定着力场中粒子的运动学和动力学状态^[5].



$$\text{给定优化问题模型: } \begin{cases} \min f(X) \\ \text{st. } h(X) \end{cases} \quad (1)$$

定义1 在时刻 t ,粒子 S_i 的效益函数 $U_i(t)$ 及粒子的总效益函数 $J_D(t)$ 分别定义为^[5]:

$$\begin{aligned} \text{fitness}(t) &= \exp(f(X)); U_i(t) = 1 - \exp(-\text{fitness}(t)); \\ J_D(t) &= \gamma \sum_{i=1}^n U_i(t), 0 < \gamma < 1 \end{aligned} \quad (2)$$

定义2 力场中粒子受到其它粒子的作用力产生的交互势能函数 $Q_i(t)$ 以及力场中粒子之间相互作用力产生的总交互势能函数 $Q_D(t)$ 分别定义为^[5]:

$$\begin{aligned} Q_i(t) &= \sum_j \int_0^{U_j(t)} \{ [1 + \exp(-\zeta_{ij}^t x)]^{-1} - 0.5 \} dx; \\ Q_D(t) &= \sum_i Q_i(t) \end{aligned} \quad (3)$$

ζ_{ij}^t 为粒子 i 和粒子 j 间的合作和竞争强度系数,如果相互竞争,则 $\zeta_{ij}^t > 0$;如果相互合作,则 $\zeta_{ij}^t < 0$;如果它们之

间没有作用,则 $\zeta_i^j = 0$.

定义 3 在时刻 t , 力场 F 本身对粒子的向上引力产生的势能函数 $P(t)$ 定义为^[5]:

$$P(t) = l^2 \ln \left(\frac{\sum_i \exp(-U_i(t)^2 / (2 \times l^2))}{n} \right), 0 < l < 1 \quad (4)$$

n 为粒子的总数目.

定义 4 粒子距力场 F 的坐标原点的距离记为 $S_i(t)$, 它们的运动学和动力学方程分别定义如下^[5]:

$$\begin{aligned} \frac{dS_i(t)}{dt} &= \lambda 1 \frac{dU_i(t)}{dt} + \lambda 2 \frac{dJ_D(t)}{dt} - \lambda 3 \frac{dP(t)}{dt} \\ &\quad - \lambda 4 \frac{dQ_D(t)}{dt} \\ &= \left(\lambda 1 + \lambda 2 \frac{\partial J_D(t)}{\partial U_i(t)} - \lambda 3 \frac{\partial P(t)}{\partial U_i(t)} - \lambda 4 \frac{\partial Q_D(t)}{\partial U_i(t)} \right) \\ &\quad \cdot \frac{dU_i(t)}{dt} \\ &= g(S_i(t), U_i(t)), \\ &\quad 0 \leq \lambda 1, \lambda 2, \lambda 3, \lambda 4 \leq 1; \end{aligned}$$

$$\begin{aligned} \frac{dU_i(t)}{dt} &= \exp(-\text{fitness}(t)) \times \text{fitness}'(t) \\ &= (1 - U_i(t)) \times \text{fitness}'(t) \\ &= g_1(S_i(t), U_i(t)) \end{aligned}$$

g, g_1 是由式(2)~(4)得到的关于 $S_i(t), U_i(t)$ 的函数.

粒子之间存在的竞争、协作、学习等社会交互行为, 可用粒子之间相应方向和大小的力表示, 例如两个粒子间的竞争行为和协作行为分别产生使两粒子延缓和加速相应方向的力, 而且不同的力的大小系数可以表达竞争或协作的强度. 同一粒子场中的粒子, 它们都并行地进行演化, 当它们从初始状态逐步演化到某种平衡状态时, 即: $\frac{dU_i(t)}{dt} = 0, \frac{dS_i(t)}{dt} = 0$ 时, 我们就将这种平衡状态反映为问题的满意解.

4 基于量子动力学机制的混合进化算法性能分析

定理 1 基于量子动力学机制的混合进化算法(HQEA)的种群序列 $\{A(n), n \geq 0\}$ 是有限齐次马尔可夫链.

证明 (略, 参考文献[4]).

设 S 为状态空间, 设 f^* 是 S 中优化问题的最优解, 令: $A^* = \{A \mid \max(f(A)) = f^*, \forall A \in S\}$

定义 5 $\{A(n), n \geq 0\}$ 是种群序列, 如果对于任意的初始分布 $S_0 \in S$, 均有 $\lim_{k \rightarrow \infty} P\{A(k) \in A^* \mid A(0) = S_0\} = 1$, 则称算法收敛^[6].

该定义表明, 算法收敛是指当算法迭代到足够多的次数后, 群体中包含全局最佳个体的概率接近于 1,

这种定义即为通常所说概率 1 收敛的.

记 $P\{A(k) \in A \mid A(0) = S_0\}$ 为 P_k , 则

$$P_k = \sum_{i \in A^*} P\{A(k) = i \mid A(0) = S_0\};$$

记 $P\{A(k) = i \mid A(0) = S_0\}$ 为 $P_{si}(k, 0)$, 则

$$P_k = \sum_{i \in A^*} P_{si}(k, 0) \quad (5)$$

算法采用了精英保留策略(记忆抗体产生算子), 所以转移概率 $P_{ij}(k, 0) = P\{A(k) = j \mid A(0) = i\}$ 有两种特殊情况:

$$\text{当 } i \in A^*, j \notin A^* \text{ 时, } P_{ij}(k, 0) = 0 \quad (6)$$

$$\text{当 } i \in A^*, j \in A^* \text{ 时, } P_{ij}(k, 0) = 1 \quad (7)$$

定理 2 HQEA 是概率 1 收敛的.

证明 由式(5) $P_k = \sum_{i \in A^*} P_{si}(k, 0)$, 由转移概率的

性质: $\sum_{j \in A^*} P_{ij}(k+1, k) + \sum_{j \notin A^*} P_{ij}(k+1, k) = 1$, 故

$$\begin{aligned} P_k &= \sum_{i \in A^*} P_{si}(k, 0) \\ &= \sum_{i \in A^*} P_{si}(k, 0) \left(\sum_{j \in A^*} P_{ij}(k+1, k) + \sum_{j \notin A^*} P_{ij}(k+1, k) \right) \\ &= \sum_{i \in A^*} P_{si}(k, 0) \sum_{j \in A^*} P_{ij}(k+1, k) \\ &\quad + \sum_{i \in A^*} P_{si}(k, 0) \sum_{j \notin A^*} P_{ij}(k+1, k). \end{aligned}$$

由式(6) $\sum_{i \in A^*} P_{si}(k, 0) \sum_{j \notin A^*} P_{ij}(k+1, k) = 0$,

故 $P_k = \sum_{i \in A^*} P_{si}(k, 0) \sum_{j \in A^*} P_{ij}(k+1, k)$,

由转移概率的性质:

$$\begin{aligned} P_{k+1} &= \sum_{i \in A^*} \sum_{j \in A^*} P_{si}(k, 0) P_{ij}(k+1, k) \\ &\quad + \sum_{i \in A^*} \sum_{j \notin A^*} P_{si}(k, 0) P_{ij}(k+1, k), \end{aligned}$$

故 $P_{k+1} = \sum_{i \in A^*} \sum_{j \in A^*} P_{si}(k, 0) P_{ij}(k+1, k) + P_k > P_k$,

所以, $1 \geq \dots \geq P_{k+1} > P_k > P_{k-1} > P_{k-2} \dots \geq 0$, 又 P_k 为实数, 且序列 $\{P_n, n \geq 0\}$ 的上确界为 1, 故 $\lim_{k \rightarrow \infty} P_k = 1$. 由定义 5, HQEA 是概率 1 收敛的, 于是定理 2 得证.

本文算法中我们采用非对称的区间克隆选择抗体, 混沌系统虽然具有遍历性, 但混沌系统生成的初始种群染色体实际上并不完全随机(见图 2), 图 2 中显示混沌变量在边界的分布更加密集. 因此, 为了能生成更多亲和度较高的染色体, 我们采用非对称区间产生混沌染色体序列, 即: 若局部最优解为 X^* , 则混沌搜索区间为 $(X^* - \frac{1}{4}\delta, X^* + \frac{7}{4}\delta)$, 故围绕 X^* 附近的染色体的到达频率增加, 从而能生成更多更高亲和度的染色体. 所以, 采用非对称的区间克隆选择抗体可以加快收敛速度, 我们用抗体首次达到最优解所需的进化代数 τ

作为衡量收敛速度的标准^[11].

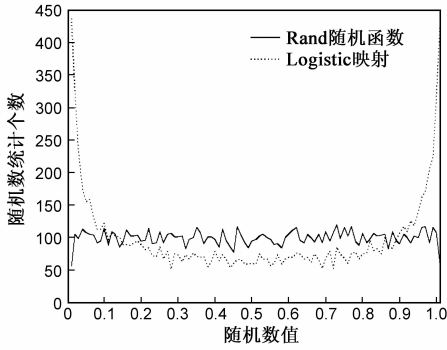


图2 Logistic映射迭代10000次在[0,1]区间上的统计结果及其和Rand随机函数的比较

上述优化问题模型式(1)中:设 S 表示全体抗体, A^* 表示最优解抗体, 转移概率 $P_{ij}(k, t) = P\{A(k+t) = j | A(t) = i\}$. 由文献[11]设

$$V(x) = \min\{|f(x) - f(y)|; y \in A^*\} \quad (8)$$

$$E[V(\xi_t) - V(\xi_{t+1}) | \xi_t = x] = V(x) - \sum_{y \in S} P_{xy}(1, t) V(y),$$

$$\tau = \min\{t \geq 0; \xi_t \in A^*\} \quad (9)$$

$$E[\tau | \xi_0] \leq \frac{V(\xi_0)}{C}, C \text{ 为常数} \quad (10)$$

由于非对称的区间克隆选择抗体能生成更多更高亲和度的染色体 ξ_0 , 根据式(8), $V(\xi_0)$ 的值会更小, 由式(10), $E[\tau | \xi_0]$ 的值也可能相应减小. 后面的仿真实验验证了此搜索区间的优越性.

5 仿真实验

多模态函数的优化问题研究层出不穷, 笔者在文献[7]中也提出求解多模态函数优化问题的免疫量子进化算法(MIQEA)并由测试函数说明了优越性. 本文则进一步采用多模测试函数^[12]来证明算法 HQEA 的性能, 并和上述相关算法 MIQEA 和 QEA 进行比较. 测试函数如下:

$$f_1(x_1, x_2) = \left(1 + (x_1 + x_2 + 1)^2 \times (19 - 14x_1 + 3x_1^2 - 14x_2 + 6x_1x_2 + 3x_2^2)\right) \times \left(30 + (2x_1 + 3x_2)^2 \times (18 - 32x_1 + 12x_1 + 48x_2 - 36x_1x_2 + 27x_2^2)\right) \\ - 2 \leq x_i \leq 2;$$

$$f_2(x_1, x_2) = \sum_{i=1}^n (x_i^2 - 10\cos(2\pi x_i) + 10), \\ - 5.12 \leq x_i \leq 5.12; \quad n = 6;$$

f_1 是具有少数局域优化解的多模函数, f_2 为具有许多局域优化解的多模函数. 多模态函数的优化算法主要比较以下参数:

(1) 搜索成功率 R : 搜索到全部最优解的次数与实

际运行次数之比.

(2) 算法计算量 C : 其中算法计算量采用评价个体的累计数, 对一个个体算法循环一次, 记为评价一次, 即 $C = N * T$ (N 为群体规模, T 为迭代次数).

实验结果如表 1 所示, 由于量子计算的天然并行性和免疫算法的完全自适应搜索, HQEA、MIQEA 算法均能以较高的搜索成功率 R 搜索到函数的全局最优解, 由于十进制编码染色体的算法解决了二进制算法所不能避免的精度与效率的冲突, 非对称的区间克隆选择抗体导致优秀个体的增加, HQEA 算法所需计算量比同类算法大大减少.

表 1 不同算法对测试函数的仿真结果比较

函数	算法	找到最优解的次数	搜索成功率 R	算法计算量 C
f_1	HQEA	20	100%	2400
f_1	MIQEA	20	100%	3000
f_1	QEA	17	85%	3600
f_2	HQEA	18	90%	5700
f_2	MIQEA	18	90%	5700
f_2	QEA	16	80%	7020

图 3 和图 4 还分别给出了函数 f_1 和 f_2 运用 HQEA、MIQEA 算法搜索全部最优解所需要的迭代次数, 实验结果为 20 次独立运行算法(种群个数 $n = 3$, 每个初始种群 $N = 20$, $\xi_i^j = -\frac{1}{3}, i \neq j, 1 \leq i, j \leq 3$)的平均值. 图 3 中显示 f_1 函数应用 HQEA 算法只需要 40 次迭代, 算法计算量 $C = 2400$, 而应用 MIQEA 算法需要 50 次迭代, 计算量 $C = 3000$. 图 4 中结果还表明对于 f_2 函数两算法的差别并不明显, 均需要迭代 95 次左右, 但 HQEA 算法获得的解质量更高. f_1 是具有少数局域优化解的多模函数, 采用非对称区间生成的混沌染色体序列能有更多的机会产生优化解, 就能很快地找到所有最优解. 而 f_2 为具有许多局域优化解的多模函数, 结构较复杂, 还需探索增加种群多样性的操作算子. 算法 HQEA 与 MIQEA 相比较结果如下:

- (1) HQEA 的混沌操作能产生更多优秀个体.
- (2) HQEA 的染色体十进制表示能提高解质量.




图3 测试函数 f_1 和迭代次数

(3)HQEA 的量子动力学机制对于有效逃离局部最优解更有意义,故两算法虽然对 f_2 函数的进化速度差别不大,但 HQEA 算法获得的解质量更高。

因此作为结构较复杂的多维函数,探索增加种群多样性的自适应策略,也是下一步继续研究的方向。

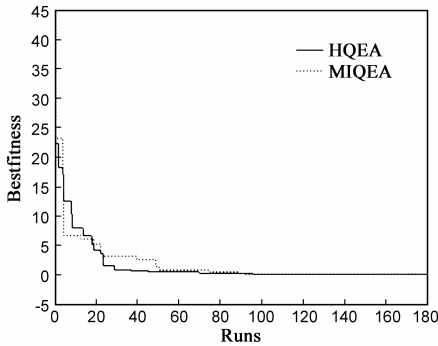


图4 测试函数 f_2 和迭代次数

6 结束语

本文研究了量子计算理论及量子动力学机制,针对多峰值函数的特点,提出改进的基于量子动力学机制的混合进化算法(HQEA).利用混沌理论中混沌系统生成的初始种群染色体实际上并不完全随机,我们提出非对称区间产生混沌染色体序列,为解决二进制算法所不能避免的精度与效率的冲突,本文采用十进制编码染色体.利用量子动力学机制的高度分布并行性,本模型能更好的适应复杂的动态环境.我们证明了算法的收敛性并对其收敛速度进行了分析探讨.仿真实验表明,此算法不仅能搜索到函数的所有全局最优解,而且计算量比同类算法大大减少,下一步工作是研究基于量子动力学机制的并行演化模型,以及它在复杂动态环境下的性能,进一步探索增加种群多样性的自适应进化策略。

参考文献

- [1] Goldberg D E, Richardson J. Genetic algorithms with sharing for multi-modal function optimization [C]. Grefenstette Eds. Proceedings of the second International Conference on Genetic Algorithms, NJ USA: Lawrence Erlbaum Associates, 1987. 41 - 49.
- [2] Narayanan A, Moore M. Quantum-inspired genetic algorithm [C]. Proc of IEEE International Conference on Evolutionary Computation, Piscataway: IEEE Press, 1996. 61 - 66.
- [3] Han KH, Kim JH. Genetic quantum algorithm and its application to combinatorial optimization problems [C]. //in Proc of IEEE International Conference on Evolutionary Computation, Piscataway: IEEE Press, 2000. 1354 - 1360.
- [4] You XM, Liu S, Shuai DX. On parallel immune quantum evolutionary algorithm based on learning mechanism and its con-

vergence [C]. //In: L. Jiao et al Eds, proc of ICNC06, PT1 4221, Berlin Heidelberg: Springer-Verlag, 2006. 903 - 912.

- [5] 帅典勋, 宫睿. ATM网络带宽动态优化的广义粒子模型和算法[J]. 计算机学报, 2007, 30(3): 380 - 396.
- [6] 潘正君, 康立山, 陈毓屏. 演化计算[M]. 北京: 清华大学出版社, 1998.
Pan Z J, Kang L S, Chen Y P. Evolutionary Computation [M]. Beijing: Tsinghua University Press, 1998. (in Chinese)
- [7] 游晓明, 刘升, 帅典勋. 求解多峰函数优化问题的免疫量子进化算法[J]. 石油化工高等学校学报. 2007, 20(3): 45 - 49.
- [8] 王孙安, 郭子龙. 混沌免疫优化组合算法[J]. 控制与决策, 2006, 21(2): 205 - 209.
- [9] 张伟, 胡昌华, 焦李成. Bootstrap-自适应混沌克隆网络与陀螺漂移预测[J]. 电子学报, 2009, 9: 2035 - 2040.
- [10] 刘芳, 李阳阳. 量子克隆进化算法[J]. 电子学报, 2004, 31 (B12): 2066 - 2070.
- [11] He J and Yao X. A study of drift analysis for estimating computation time of evolutionary algorithms [J]. Natural Computing, 2004, 3: 21 - 35.
- [12] X Yao, ed., Evolutionary Computation: Theory and Applications [M]. Singapore: World Scientific Publishing Co., 1999.

作者简介



游晓明 女, 1963 年出生, 博士, 上海工程技术大学电子电气工程学院教授, 主要从事分布式人工智能、分布式并行智能处理的理论及应用。

E-mail: yxm6301@163.com



刘升 男, 1966 年出生, 博士, 上海工程技术大学教授, 主要从事智能计算、智能信息处理的理论及应用。E-mail: ls6601@163.com



王裕明 男, 1962 年出生, 硕士生导师, 上海工程技术大学电子电气工程学院院长/教授, 主要从事信息处理的理论及应用。

E-mail: wangyuming@sues.edu.cn