

混沌量子克隆优化求解认知无线网络决策引擎*

柴争义^{1)†} 刘芳¹⁾²⁾ 朱思峰¹⁾

1) (西安电子科技大学计算机学院, 西安 710071)

2) (智能感知与图像理解教育部重点实验室, 西安 710071)

(2011年1月11日收到; 2011年2月24日收到修改稿)

通过分析认知无线网络引擎决策, 给出了其数学模型, 并将其转化为一个多目标优化问题, 进而提出一种基于混沌量子克隆的优化求解算法, 并证明了该算法以概率 1 收敛. 算法采用量子编码, 利用 Logistic 映射初始化抗体种群, 设计了一种基于混沌扰动的量子变异方案. 最后, 在多载波环境下对算法进行了仿真实验. 结果表明, 与 QGA-CE(基于量子遗传算法的认知引擎) 算法相比, 本文算法收敛速度较快, 具有较高的目标函数值, 可以对无线参数优化调整, 满足认知引擎的实时性要求.

关键词: 混沌, 量子克隆, 认知无线网络, 引擎决策, 收敛性

PACS: 88.80.ht, 64.60.aq

1 引言

认知无线网络是一种智能的无线网络, 其智能主要来自认知引擎^[1]. 认知引擎的根本目的是根据信道条件的变化和用户需求智能调整无线参数, 给出最佳参数配置方案, 从而优化通信系统. 如何利用认知引擎得到最优决策引起了研究者的普遍关注. 从本质上看, 认知无线网络的引擎决策是一个多目标优化问题, 适合用智能方法求解, 因而, 不同的研究者提出了不同的解决方案^[2-6]. 文献[2]采用人工智能技术研究认知引擎, 并证明了遗传算法适合于无线参数的调整; 文献[3]提出了认知引擎决策的数学模型, 并通过标准遗传算法求解; 文献[4]采用量子遗传算法求解, 但求解效果还有待进一步优化.

基于此, 本文利用免疫算法较快的收敛速度和寻优能力、混沌搜索的遍历性和量子计算的高效性, 对认知引擎决策参数进行分析和调整, 并通过多载波环境进行了仿真. 结果表明, 本算法可以根据信道条件, 实时调整无线参数, 实现认知引擎决策优化.

2 认知无线网络的引擎决策分析和建模

认知无线网络中, 认知用户可以在不影响授权用户的情况下, 使用授权用户的空闲频谱, 并根据频谱环境的变化自适应地调整传输参数(如传输功率、调制方式等)以提高空闲频谱的使用性能(如更大化传输速率、更小化传输功率等), 从而达到最佳工作状态^[7]. 由此可见, 认知引擎决策需要动态地满足多个目标, 如必须适应具体的信道传输条件; 必须满足用户的应用需求; 必须遵守特定频段的频谱特性等, 因此, 其是一个动态多目标优化问题. 本文根据多载波频谱环境、用户需求以及频谱限制定义出以下 3 个认知引擎的优化目标函数并进行归一化^[2-6]:

1) 最小化传输功率

$$f_{\min\text{-power}} = 1 - \frac{p_i}{N \times P_{\max}},$$

其中, p_i 为子载波 i 的传输功率, P_{\max} 为子载波的最大传输功率, N 为子载波的数目.

2) 最小化误码率 BER(比特错误率)

$$f_{\min\text{-BER}} = 1 - \frac{\lg(0.5)}{\lg(p_{be})},$$

* 国家高技术研究发展计划(批准号: 2009AA12Z210), 国家自然科学基金(批准号: 61001202, 61072139, 61003199), 国家教育部博士点基金(批准号: 20090203120016, 20100203120008), 中央高校基本科研业务费专项资金(批准号: JY10000902001)和郑州市科技发展计划(批准号: 2010GYXM374)资助的课题.

† E-mail: super_chai@tom.com

其中, p_{be} 为 N 个子信道的平均误码率. 具体计算公式根据所采用的调制方式不同而不同, 具体见文献 [8].

3) 最大化数据率 (吞吐量)

$$f_{\max\text{-throughput}} = \frac{\frac{1}{N} \sum_{i=1}^N \log_2 M_i - \log_2 M_{\min}}{\log_2 M_{\max} - \log_2 M_{\min}},$$

其中, N 为子载波的数目, M_i 为第 i 个子载波对应的调制进制数, M_{\max} 为最大调制进制数, M_{\min} 为最小调制进制数.

因此, 本文所要优化的目标为

$$y = (f_{\min\text{-power}}, f_{\min\text{-BER}}, f_{\max\text{-throughput}}).$$

实际中, 不同的链路条件、不同的用户需求导致目标函数的重要性也不尽相同. 如邮件发送用户希望有最小的误码率; 而视频用户则希望有最大化的数据速率. 因此, 本文使用 $w = [w_1, w_2, w_3]$ 分别表示最小化发射功率、最小化误码率和最大化数据率的权重. 权值越大偏好程度越强, 并且权重满足 $w_i \geq 0 (1 \leq i \leq 3)$, 且 $\sum_{i=1}^3 w_i = 1$. 给定各个目标函数的权重之后, 可将三个目标函数转化为如下单目标函数:

$$f = w_1 f_{\min\text{-power}} + w_2 f_{\min\text{-BER}} + w_3 f_{\max\text{-throughput}}. \quad (1)$$

从上面的分析可知, 影响优化目标的主要参数为各个子载波的发射功率和调制方式. 因此, 本文的认知引擎决策问题即转化为: 通过对上述参数的合理调整, 实现 (1) 式所示目标函数的最大化.

3 算法关键技术 with 具体实现

3.1 关键技术

3.1.1 编码方式

由于决策引擎主要是对参数进行调整, 本文使用二进制对每个子载波的调制方式和发射功率进行编码. 调制方式包括 BPSK, QPSK, 16 QAM 和 64 QAM 四种, 发射功率共有 64 种可能取值, 范围设置为 0—25.2 dBm, 间隔为 0.4 dBm^[2-6]. 假设用 c_1 表示对四种, 调制方式的编码, 则需要 2 位二进制进行编码, 取值为 0, 1, 2, 3, 依次对应 BPSK, QPSK, 16 QAM, 64 QAM; 用 c_2 表示对发射功率的编码, 由于有 64 种可能取值, 故编码位数为 6, 编码与发射功率的大小依次对应. 因此, 抗体长度由 c_1 和 c_2 的编码串联而成, 共 8 位. 例如调制方式为 16 QAM, 发射功率为 24.4 dBm, 则对应的抗体

编码为 10111100.

3.1.2 亲和度函数

免疫算法中, 把问题映射为抗原, 把问题的解映射为抗体, 解的优劣由亲和度函数来衡量. 由于本文的目的是要得到满足优化目标所需的参数配置, 因此, 直接将 (1) 式所示目标函数作为衡量个体性能的亲和度函数.

3.2 算法基本流程

算法基本流程如图 1 所示.

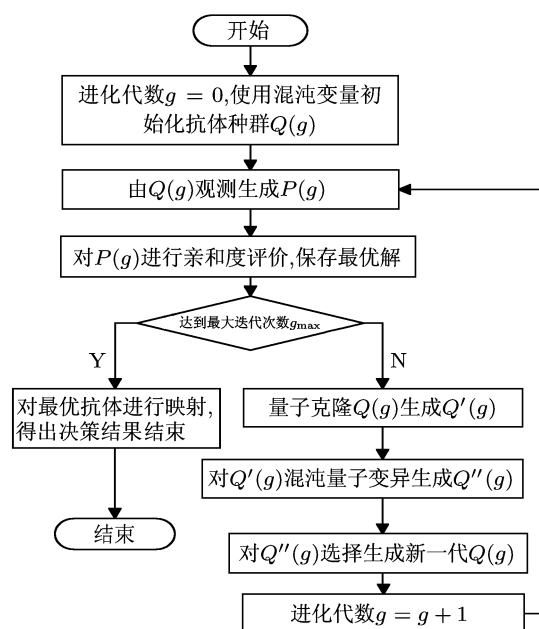


图 1 算法基本流程图

3.3 算法具体步骤

本文设计的算法基本步骤如下 (步骤 1—步骤 8) (注: Q 表示量子种群, q 表示一个量子抗体, P 表示普通抗体种群, p 表示一个普通抗体):

步骤 1 初始化

设进化代数 g 为 0, 抗体种群记作 Q , 规模为 n , 抗体编码长度为 l , 则初始化种群 $Q(g) = \{q_1^g, q_2^g, \dots, q_n^g\}$. 其中, 第 i 个抗体 $q_i = \begin{bmatrix} \alpha_i^1 \alpha_i^2 \dots \alpha_i^l \\ \beta_i^1 \beta_i^2 \dots \beta_i^l \end{bmatrix} (i = 1, 2, \dots, n)$, 并且满足 $|\alpha_i^j|^2 + |\beta_i^j|^2 = 1 (1 < j < l)$. 为了确保抗体产生的随机性并避免可能出现的冗余, 并遍历所有抗体空间, 本文初始抗体种群的产生使用 Logistic 映射: $x_{i+1}^j = \mu x_i^j (1 - x_i^j)$. 其中, $i = 1, 2, \dots, n, j = 1, 2, \dots, l, x_i^j (0 < x_i^j < 1)$

为混沌变量, $\mu = 4$, 此时系统处于完全混沌状态, 其状态空间为 $(0,1)^{[9]}$. 具体如下: 分别给定混沌变量不同的初始值, 利用上式产生 l 个混沌变量 x_i^j , 然后用这 l 个混沌变量初始化种群中第一个抗体上的量子位, 本文将 $\alpha_i^j, \beta_i^j (1 < j < l)$ 分别初始化为 $\cos(2x_i^j\pi) \sin(2x_i^j\pi)$.

步骤 2 由 $Q(g)$ 生成 $P(g)$

通过观察 $Q(g)$ 的状态, 生成一组普通解 $p(g) = \{p_1^g, p_2^g, \dots, p_n^g\}$. 每个 $P_i^g (1 < i < n)$ 是长度为 l 的二进制串, 由概率幅 $|\alpha_i^j|^2, |\beta_i^j|^2 (j = 1, 2, \dots, l)$ 观察得到. 在本文中, 观察方法如下: 随机产生一个 $[0,1]$ 数, 若它大于 $|\alpha_i^j|^2$, 则取 1, 否则, 取 0. 观察生成的每个抗体 $p_i^g (1 < i < n)$ 代表了一种可能的参数调整方案.

步骤 3 亲和度函数评价

根据 (1) 式的亲和度函数计算抗体种群的亲和度, 并按亲和度大小降序对抗体进行排列, 选择前 s 个最佳抗体, 保存到记忆种群 $M(g)$.

步骤 4 终止条件判断

如果达到最大迭代次数 g_{max} , 算法终止, 将记忆种群 $M(g)$ 中保存的亲和度最高的抗体通过编码方式进行映射, 即得到了最佳的参数调整方案 (调制方式和传输功率); 否则, 转步骤 5.

步骤 5 克隆扩增 $Q(g)$ 生成 $Q'(g)$

本文采取对记忆种群中 $M(g)$ 的 s 个抗体进行克隆. 具体克隆方法如下: 设 s 个抗体按亲和度降序排序为 $P_1^g, P_2^g, \dots, P_s^g$, 则对第 k 个抗体 $P_k^g (1 \leq k \leq s)$ 克隆产生的抗体数目为

$$N_k = \text{int} \int \left(n_c \times \frac{f(P_k^g)}{\sum_{k=1}^s f(P_k^g)} \right),$$

其中 $\text{int}(\cdot)$ 表示向上取整, $n_c > s$ 是控制参数, $f(\cdot)$ 表示抗体的亲和度. 上式表明, 抗体亲和度越高, 克隆产生的抗体个数越多.

步骤 6 对 $Q'(g)$ 进行混沌量子变异, 生成新种群 $Q''(g)$

本文中, 量子种群的变异通过量子旋转门改变抗体量子位的相位来实现. 转角的确切方法如下: $\Delta\theta_j^k = \lambda_k x_{i+1}^j$. 其中, λ_k 为克隆幅值. 混沌变量 x_{i+1}^j 计算公式为 $x_{i+1}^j = 8x_i^j(1 - x_i^j) - 1$, 这样 $\Delta\theta_j^k$ 遍历范围呈现双向性 $[-\lambda_k, \lambda_k]$. 对于需要变异的母体, 亲和度越高, 扩增时所叠加的混沌扰动越小. 因此, λ_k 可选为 $\lambda_k = \lambda_0 \exp((k-s)/s)$. 其中, λ_0 为控制参数, 表示对抗体所施加的混沌扰动的大小.

设第 k 个变异母体为

$$q_k = \begin{pmatrix} \cos(\theta_1^k) & \cos(\theta_2^k) & \dots & \cos(\theta_l^k) \\ \sin(\theta_1^k) & \sin(\theta_2^k) & \dots & \sin(\theta_l^k) \end{pmatrix}.$$

应用量子旋转门变异后的抗体为

$$q_{k\delta} = \begin{pmatrix} \cos(\theta_1^k + \Delta\theta_{1\delta}^k) & \dots & \cos(\theta_l^k + \Delta\theta_{l\delta}^k) \\ \sin(\theta_1^k + \Delta\theta_{1\delta}^k) & \dots & \sin(\theta_l^k + \Delta\theta_{l\delta}^k) \end{pmatrix},$$

其中, $\delta = 1, 2, \dots, N_k$.

步骤 7 克隆选择压缩 $Q''(g)$, 生成新个体 $Q(g)$

为了保持群体规模 n 稳定, 对变异后的量子抗体进行解变换, 将抗体按照亲和度大小排序, 取前 n 个抗体组成新的抗体种群 $Q(g)$.

步骤 8 $g = g + 1$; 转步骤 2.

3.4 算法特点和优势分析

1) 抗体采用量子编码, 一个抗体上带有多个状态信息, 带来了丰富的种群; 采用随机观察的方式由量子抗体产生新的个体, 能较好保持群体的多样性, 有效克服早熟收敛; 并且量子具有较好的并行性, 所需抗体群体规模较小.

2) 克隆算子使得当前最优个体的信息能够很容易的扩大到下一代来引导变异, 具有高效的局部寻优能力, 加快了收敛速度. 因此, 算法将全局搜索和局部寻优进行了有机的结合.

3) 在量子变异中, 根据亲和度的不同施加不同的混沌扰动, 增强了局部优化的遍历性. 对于转角方向的确定, 避免了传统基于查询表的方式^[10], 克服了传统的量子非门变异旋转大小固定, 方向单一, 缺乏遍历性的缺陷.

3.5 算法收敛性分析

定理 1 混沌量子克隆算法 (chaos quantum clonal algorithm, CQCA) 的种群序列 $\{X_g, g \geq 0\}$ 是有限齐次马尔可夫链.

证明 由于 CQCA 采用量子比特抗体 Q , 抗体的取值是离散的 0 和 1. 本文中抗体的长度为 l , 种群规模为 n , 种群所在的状态空间大小为 $n \times 2^l$. 因而, 种群是有限的, 而算法中采用的克隆算子 (变异、选择等) 都与 g 无关^[11,12]. 因此, X_{g+1} 只与 X_g 有关, 即 $\{X_g, g \geq 0\}$ 是有限齐次马尔可夫链.

定理 1 得证.

设 $X(g) = \{x_1, x_2, \dots, x_n\}$, 下标 g 表示进化

代数, $\mathbf{X}(g)$ 表示在第 g 代时的一个种群, \mathbf{x}_i 表示第 i 个体. 设 f 是 $\mathbf{X}(g)$ 的亲密度函数, 令

$$B^* = \mathbf{x} | \max(f(\mathbf{x})) = f^* \{ \mathbf{x} \in \mathbf{X}(g) \},$$

称 B^* 为最优解集, 其中 f^* 为全局最优值, 则有如下定义.

定义 设 $f_g = \max\{f(\mathbf{x}_i) : i = 1, 2, \dots, n\}$ 是一个随机变量序列, 该变量代表在时间步 g 状态中的最高亲密度. 当且仅当

$$\lim_{g \rightarrow \infty} p\{f_g = f^*\} = 1,$$

则称算法收敛. 也就是, 当算法迭代到足够多的次数后, 群体中包含全局最优解的概率接近 1.

定理 2 本文量子免疫克隆算法 CQCA 以概率 1 收敛.

证明 本算法的状态转移由马尔可夫链来描述. 将规模为 n 的群体认为是状态空间 U 中的某个点, 用 $u_i \in U$ 表示 u_i 是 U 中的第 i 个状态. 相应的, 本算法的 $u_i = \{bx_1, x_2, \dots, x_n\}$. 显然, \mathbf{X}_g^i 表示在第 g 代种群 \mathbf{X}_g 处于状态 u_i , 其中随机过程 $\{\mathbf{X}_g\}$ 的转移概率为 $p_{ij}(g)$, 则

$$p_{ij}(g) = p\{\mathbf{X}_{g+1}^j / \mathbf{X}_g^i\}.$$

由于本算法中采用保留最优个体进行克隆选择, 因此, 对任意的 $g \geq 0$, 有 $f(\mathbf{X}_{g+1}) \geq f(\mathbf{X}_g)$. 即种群中的任何一个个体都不会退化.

设 $I = \{i | u_i I \cap B^* \neq \emptyset\}$, 则

1) 当 $i \in I, j \notin I$, 有

$$p_{ij}(g) = 0, \tag{2}$$

即当父代出现最优解时, 最优解不论经过多少代都不会退化.

2) 当 $i \notin I, j \in I$, 因为 $f(\mathbf{X}_{g+1}^j) \geq f(\mathbf{X}_g^i)$, 所以

$$p_{ij}(g) > 0. \tag{3}$$

设 $p_i(g)$ 为种群 \mathbf{X}_g 处在状态 u_i 的概率, $p(g) = \sum_{i \notin I} p_i(g)$, 则由马尔可夫链的性质, 有

$$p(g+1) = \sum_{u_i \in U} \sum_{j \notin I} p_i(g) p_{ij}(g) = \sum_{i \in I} \sum_{j \notin I} p_i(g) p_{ij}(g) + \sum_{i \notin I} \sum_{j \notin I} p_i(g) p_{ij}(g). \tag{4}$$

由于

$$\begin{aligned} & \sum_{i \notin I} \sum_{j \in I} p_i(g) p_{ij}(g) + \sum_{i \notin I} \sum_{j \notin I} p_i(g) p_{ij}(g) \\ &= \sum_{i \notin I} p_i(g) = p_g, \end{aligned} \tag{5}$$

所以

$$\sum_{i \notin I} \sum_{j \notin I} p_i(g) p_{ij}(g) = p_g - \sum_{i \notin I} \sum_{j \in I} p_i(g) p_{ij}(g). \tag{6}$$

把 (6) 式代入 (4) 式, 同时利用 (2) 式和 (3) 式, 可得

$$0 \leq p_{g+1} < \sum_{i \in I} \sum_{j \notin I} p_i(g) p_{ij}(g) + p_g = p_g,$$

因此, $\lim_{g \rightarrow \infty} p_g = 0$. 又因为

$$\lim_{g \rightarrow \infty} \{f_g = f^*\} = 1 - \lim_{g \rightarrow \infty} \sum_{i \notin I} p_i(g) = 1 - \lim_{g \rightarrow \infty} p_g,$$

所以

$$\lim_{g \rightarrow \infty} \{f_g = f^*\} = 1,$$

即包含在全局最优状态中的概率收敛为 1. 证毕.

4 仿真实验及结果分析

为了验证本文算法的性能, 在 windows 环境下, 使用 Matlab7.0 对算法进行编程实现, 在多载波系统中对算法性能进行了仿真分析. 算法参数设置如下: 子载波数 $N = 32$, 每个子载波信道可独立选择不同的发射功率和调制方式; 动态信道通过给每个子载波分配一个 0—1 之间的随机数表示该载波对应的信道衰落因子来模拟; 信道类型为 AWGN 信道, 噪声功率初始为 0.01 mW(用于计算 p_{be})^[13]; 发射功率共有 64 种可能取值, 范围设置为 0—25.2 dBm 间隔为 0.4 dBm; 可选调制方式包括 BPSK, QPSK, 16QAM 和 64QAM 四种, 因而, 抗体编码长度 $l = 8$, 总抗体编码长度为 $N \times l = 256$. 其他更多的调制方式只影响 BER 计算公式, 并不影响模拟结果^[14,15].

为了便于比较, 与文献 [4] 参数设置保持一致: 最大进化代数 $g_{max} = 1000$; 种群规模 $n = 12$, 记忆单元规模 $s = 0.3 \times n$. 文献 [4] 中, 量子门旋转角度从 0.1π 到 0.005π . 通过反复实验调整, 本算法的其他参数设置如下: 克隆控制系数 $n_c = 20$, 混沌扰动系数 $\lambda_0 = 2$.

表 1 权重设置

权重	模式 1	模式 2	模式 3	模式 4
w_1	0.80	0.15	0.05	1/3
w_2	0.15	0.80	0.15	1/3
w_3	0.05	0.05	0.80	1/3

算法权重的设置与文献 [4] 相同. 实验中设置四种权重模式, 用来验证不同用户需求下, 算法运行性能. 模式 1 适用于低发射功率 (低功耗) 情

况(带宽低、速率低,如文件传输);模式2适用于可靠性要求高的应用(要求误码率较低)如保密通信;模式3适用于高数据速率要求的应用,如视频通信(宽带视频通信);模式4则对各个目标函数的偏好相同.权重具体设置如表1所示.

实验中,在四种模式下分别进行10次独立的实验,记录每一代中亲密度最大的目标函数值,再

对10次实验结果取平均,即得到平均目标函数值.平均目标函数值越大,说明解的质量越好且稳定.图2中分别给出了在模式1到模式4下,随迭代代数的变化平均目标函数值的变化情况.并将本文算法CQCA-CE(chaos quantum clonal algorithm for cognitive engine)与基于量子遗传算法的认知引擎实现(QGA-CE)^[4]作了对比分析.

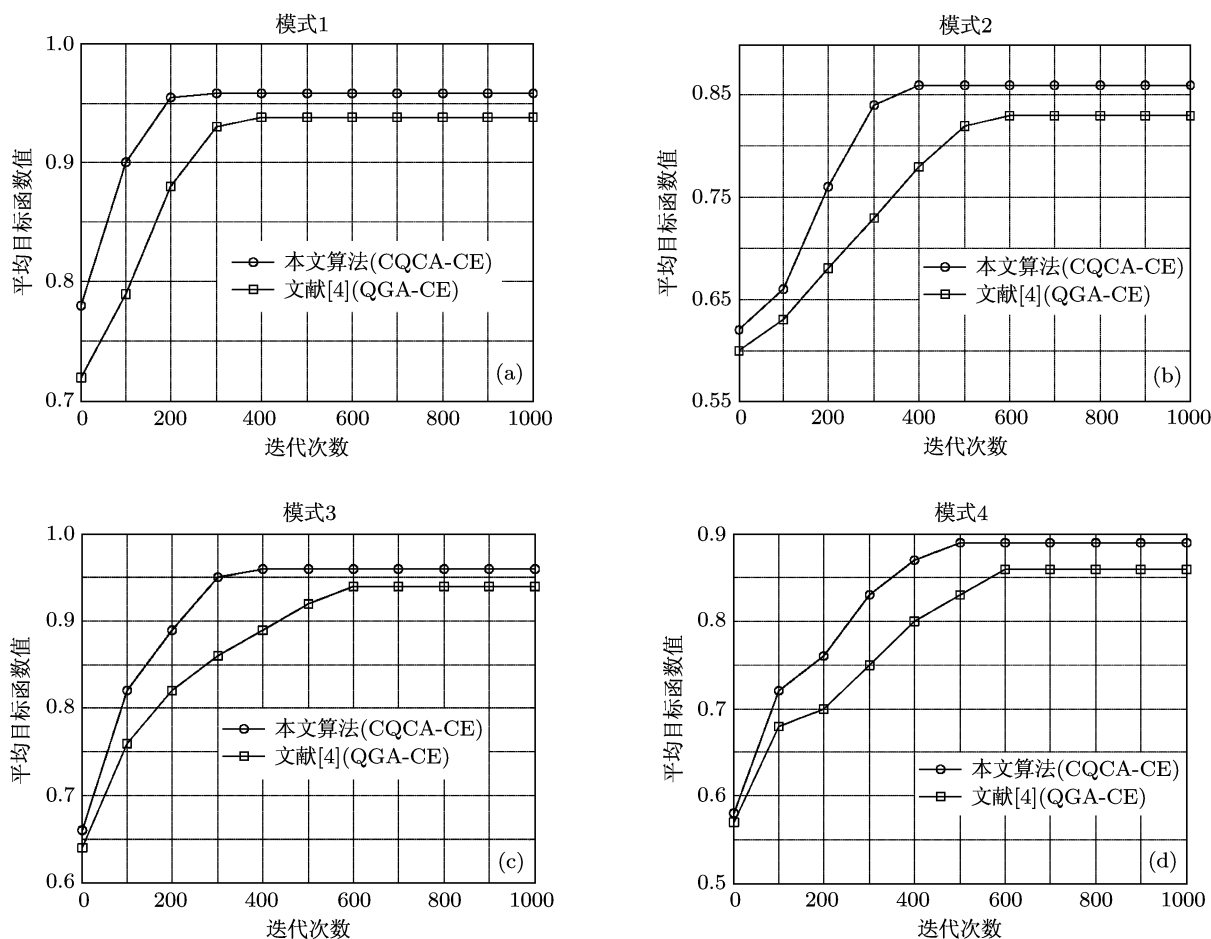


图2 相关算法目标函数值对比

表2 平均目标函数值

模式	文献4(QGA-CE)	本文算法(CQCA-CE)
模式1	0.932	0.960
模式2	0.820	0.846
模式3	0.942	0.958
模式4	0.858	0.898

从图2中可以看出,在四种不同的模式下,本文算法求得的目标函数值明显优于文献[4]算法,同时,本算法收敛速度较快,说明算法有较好的寻优能力.本文算法在运行400代左右的时候就可以收敛,并且可以得到较高的目标函数值,而文献[4]

算法约在600代左右收敛,且目标函数值较小.原因在于:算法采用的免疫克隆算子、混沌扰动提高了算法的收敛速度和寻优效果.这对实时性要求较高的决策引擎具有重要意义.

表2给出了相关算法在状态稳定后达到的平均目标函数值,进一步验证了本文算法的优越性.

图3给出了在上述参数设置下,本算法具体调整结果.其中,各个载波对应的信道衰落因子由计算机随机产生.图3(a)中给出了模式1下的调整结果.其中发射功率平均值为0.156 dBm明显小于其他模式,说明本算法可以很好的实现模式1下对

最小化发射功率的偏好,同时,算法兼顾了最小化误码率和最大化数据率的要求(误码率为0.11%,数据率为5.25 Mbps).图3(b)给出了模式2下的调整结果(调制方式基本上为BPSK).其中,最小化误码率为0.02%,小于模式1、模式3、模式4的误码率,说明本算法实现了模式2下要求误码率最小的目标要求,同时,也兼顾了发射功率较小和数据率较大的目标(发射功率为10.23 dBm,数据率为2.026 Mbps).图3(c)给出了模式3下的调

整结果.其中,平均数据率为6 Mbps(调制方式均为64 QAM),说明本算法达到了模式3下对最大化数据率的目标要求.图3(d)给出了模式4下的调整结果(调制方式均为64 QAM).模式4对各个目标的权重相同,但从结果看,算法更倾向于实现发射功率最小化和数据率最大化.这是因为:误码率最小化与发射功率最小化和数据率最大化存在冲突,同时保证发射功率最小化和数据率最大化的抗体亲和度高于要求误码率最小的抗体亲和度.

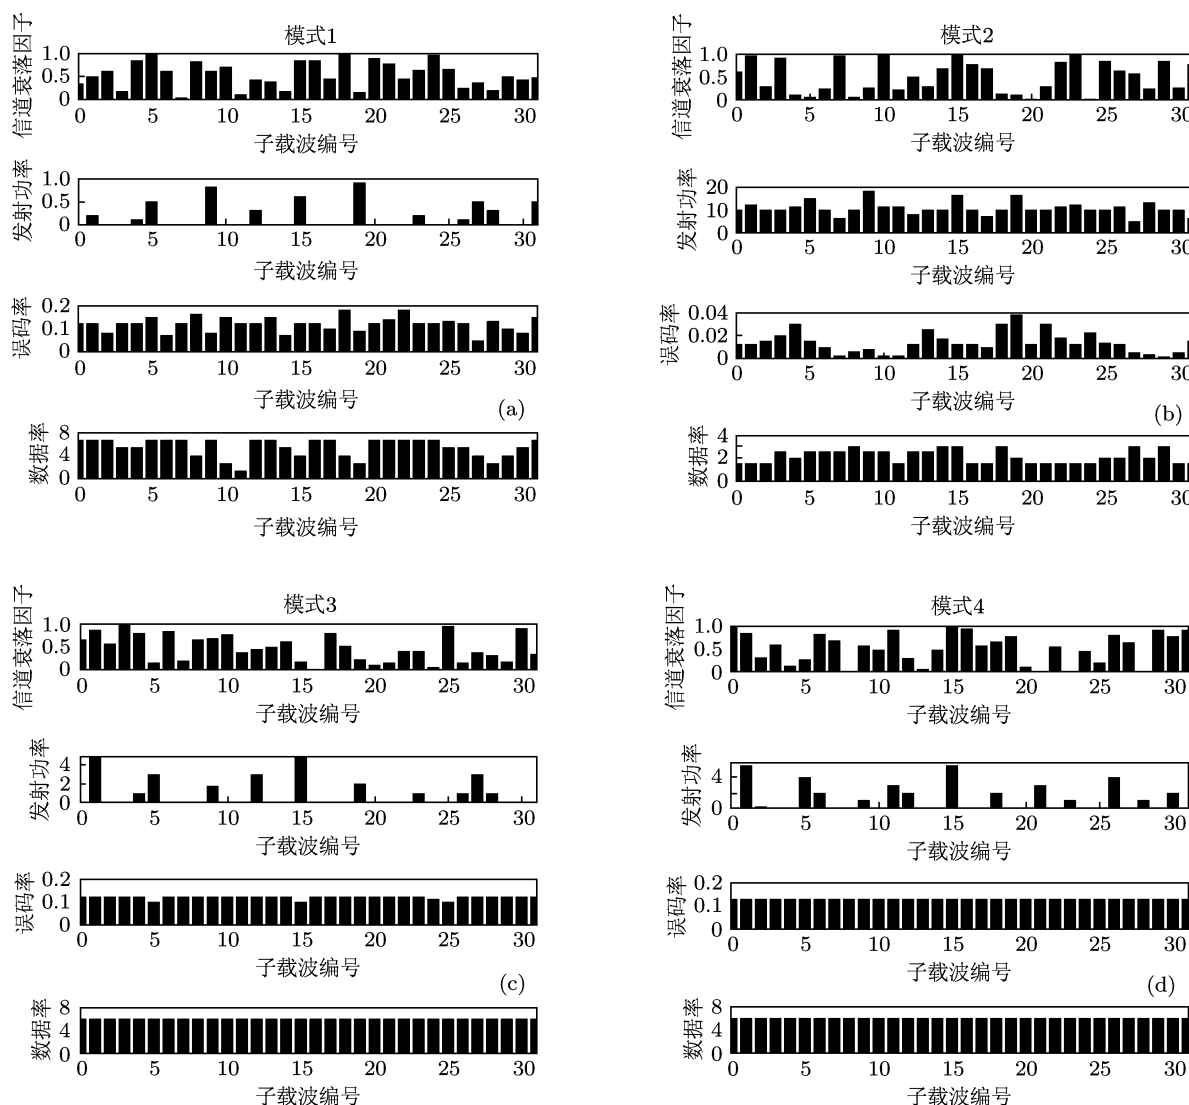


图3 本文算法调整结果

5 结论

文章分析了认知无线网络认知引擎问题,将其转化为一个多目标优化问题,并通过混沌量子克隆

算法求解.仿真实验表明:本算法收敛速度较快,可以得到较高的目标函数值,具有较强的寻优能力,参数调整结果与优化目标偏好一致,并兼顾其它目标函数值,适合实时性要求较高的认知引擎决策.

- [1] Haykin S 2008 *IEEE J. Sel. Area Comm.* **23** 201
- [2] Rieser C J 2006 *Ph. D. Dissertation* (Virginia: Virginia Tech)
- [3] Tim R N, Brett A B, Alexander M 2008 *Wirel. Commun. Mob. Com.* **7** 1129
- [4] Zhao Z Z, Zheng S L, Shang J N, Kong X Z 2009 *Acta. Phys. Sin.* **58** 6760 (in Chinese) [赵知劲, 郑仕链, 徐世宇, 孔宪正 2009 物理学报 **58** 6760]
- [5] Muha W, Anni C 2009 *Fifth International Conference on Wireless and Mobile Communications*, Dy SPAN, July 2–6, 2009 p143
- [6] Zhao Z Z, Xu S Y, Zheng S L, Yang X N 2009 *Acta. Phys. Sin.* **58** 6760 (in Chinese) [赵知劲, 徐世宇, 郑仕链, 杨小牛 2009 物理学报 **58** 5118]
- [7] Ycek T, Arslan H 2009 *IEEE Comm.* **1** 116
- [8] Newman T R, Evans J B 2008 *The 3rd IE-EE Symposium on New Frontiers in Dynamic Spectrum Access Networks*, Chicago, March 10–12 p1
- [9] Du, H F, Gong M G, Liu R C 2009 *Sci. China Ser. F* **19** 237
- [10] Wu Q Y, Jiao L C, Li Y Y 2009 *Prog. Nat. Sci.* **19** 1341
- [11] Gong M G, Jiao L C, Liu F, Ma W P 2010 *Knowl. Inf. Syst.* **25** 523
- [12] Yang D D, Jiao L C, Gong M G, Feng J 2010 *Comput. Intell.* **26** 359
- [13] Zhang P, Feng Z Y 2010 *Cognitive Wireless Network* (Beijing: posts and telecomm press) p210–215 (in Chinese) [张平, 冯志勇 2010 认知无线网络 (北京: 人民邮电出版社) 第 210—215 页]
- [14] Zhou J, Zu Y X 2010 *Acta. Phys. Sin.* **59** 7508 (in Chinese) [周杰, 祖云霄 2010 物理学报 **59** 7508]
- [15] Zu Y X, Zhou J 2010 *Chin. Phys. B* **19** 119501

Chaos quantum clonal algorithm for decision engine of cognitive wireless network*

Chai Zheng-Yi^{1)†} Liu-Fang¹⁾²⁾ Zhu Si-Feng¹⁾

1) (School of Computer Science and technology, Xidian University, Xi'an 710071, China)

2) (Key Laboratory of Intelligent Perception and Image Understanding of Ministry of Education, Xi'am 710071, China)

(Received 11 January 2011; revised manuscript received 24 February 2011)

Abstract

By analyzing engine decision of cognitive wireless network, the mathematical model of engine decision is given, and then it is converted into a multi-objective optimization problem. A Chaos quantum clonal algorithm is proposed to solve the problem, and the algorithm convergent with probability 1 is proved, in which the quantum coding and logistic mapping are used to initialize the population. A quantum mutation scheme is designed with chaotic disturbances. Finally, the simulation experiments are done to test the algorithm under a multi-carrier system. The results show that compared with QGA-CE (quantum genetic algorithm based cognitive engine), this algorithm has a good convergence and an objective function value. It can adapt the parameter configuration and meet the real-time requirement for cognitive engine.

Keywords: chaos, quantum clonal, cognitive wireless network, engine decision

PACS: 88.80.ht, 64.60.aq

* Project supported by the National High Technology Research and Development Program (863 Program) of China (Grant No. 2009AA12Z210), the National Natural Science Foundation of China (Grant Nos. 61001202, 61072139, 61003199), the National Research Foundation for the Doctoral Program of Higher Education of China (Grant Nos. 20090203120016, 20100203120008), the Fundamental Research Funds for the Central Universities (Grant No. JY10000902001), and the Science and Technology Development Program of Zhengzhou (Grant No. 2010GYXM374).

† E-mail: super_chai@tom.com