

基于二进制混沌粒子群算法的认知决策引擎

于洋, 谭学治, 殷聪, 张闯, 马琳

(哈尔滨工业大学 电子与信息工程学院, 150080 哈尔滨)

摘要:为了解决不同通信模式下认知无线电发射机参数合理优化的问题,提出了一种基于二进制混沌粒子群算法(BCPSO)的认知决策引擎,该引擎利用粒子群优化算法收敛速度快和混沌运动全局遍历性的特点,使认知决策在多目标优化过程中有效地摆脱了局部极值点,提高了参数优化的精度和稳定性.基于认知正交频分复用(OFDM)系统的仿真结果表明,相对于现有认知引擎,该引擎具有平均适应度值高、对不同通信模式鲁棒性强的特点,实现了有效优化发射机参数的目的.

关键词: 认知无线电; 认知决策引擎; 多目标优化; 二进制混沌粒子群算法

中图分类号: TN914.3 **文献标志码:** A **文章编号:** 0367-6234(2014)03-0008-06

Cognitive decision engine based on binary chaotic particle swarm optimization

YU Yang, TAN Xuezhi, YIN Cong, ZHANG Chuang, MA Lin

(School of Electronics and Information Engineering, Harbin Institute of Technology, 150080 Harbin, China)

Abstract: To solve the problem of transmitter parameter optimization in different communication modes for cognitive radio (CR) systems, a cognitive decision engine based on binary chaotic particle swarm optimization (BCPSO) is proposed. The BCPSO algorithm has both the fast convergence of particle swarm optimization and global ergodic property of chaos. Therefore, the cognitive decision engine based on BCPSO can jump off the local extreme points effectively, which can improve the precision and stability of parameter optimization. The cognitive orthogonal frequency division multiplexing (OFDM) system is used for the performance analysis. And the simulation results show that the proposed cognitive decision engine, which has higher fitness value and stronger robustness for different communication modes, is better than the other existing engines. The proposed engine achieves the objective of parameter optimization effectively.

Keywords: cognitive radio; cognitive decision engine; multi-objective optimization; binary chaotic particle swarm optimization

为了能够高效地利用无线电频谱资源,认知无线电(cognitive radio, CR)技术应运而生^[1-2]. 美国联邦通讯委员会(FCC)更确切地把CR定义为基于与操作环境交互的、能动态改变其发射机参数的无线电,其具有环境感知和传输参数自我

调整的功能.在不同通信模式下,如何合理有效地优化发射机参数以满足不同服务质量(quality of service, QoS)要求,是认知决策引擎的主要任务. CR通过认知决策引擎制定最优传输策略以匹配信道当前状态,从而实现高效可靠的无线传输.

近些年,认知决策引擎的设计问题得到了越来越多的关注^[3-10]. 认知决策引擎需具备一定的智能性,因此各种人工智能(artificial intelligence, AI)技术被引入到其设计中. 因其固有的并行计算能力和良好的可扩展性,遗传算法(genetic algorithm, GA)被认知决策引擎大量采用^[3-6]. 模糊逻辑(fuzzy logic, FL)因其可进行模糊综合判

收稿日期: 2013-07-08.

基金项目: 国家自然科学基金委员会与中国民用航空局联合资助项目(61071104); 国家科技重大专项“宽带多媒体集群系统技术验证(中速模式)”(2011ZX03004-004).

作者简介: 于洋(1984—),男,博士研究生;
谭学治(1957—),男,教授,博士生导师.

通信作者: 谭学治, tanxuezhi_hit@163.com.

断,也被应用到认知决策引擎的设计中^[7].为了克服 GA 早熟等缺点,文献[8]提出了一种基于二进制粒子群(binary particle swarm optimization, BPSO)算法的认知决策引擎.通过量子理论改进算法,文献[9]提出了一种基于二进制量子粒子群(binary quantum particle swarm optimization, BQPSO)算法的认知决策引擎.针对认知单载波频域均衡(single carrier frequency domain equalization, SC-FDE)系统,文献[10]提出了一种适用于 SC-FDE 认知决策引擎的速率控制和自适应调制编码的联合算法.本文提出了一种二进制混沌粒子群(binary chaotic particle swarm optimization, BCPSO)算法,并将该算法引入到认知正交频分复用(orthogonal frequency division multiplexing, OFDM)系统的认知决策引擎中.由于利用了混沌系统的遍历性,基于 BCPSO 的认知决策引擎改善了参数优化的精度和鲁棒性.

1 粒子群算法

1.1 粒子群算法

粒子群(particle swarm optimization, PSO)算法于 1995 年提出^[11-12].因该算法具有收敛速度快、鲁棒性好、简单易于实现等优点,目前已在函数优化、信号处理、模式识别等领域得到了广泛应用.PSO 算法将每个个体视为 D 维搜索空间中的一个没有体积和质量的粒子(particle).该粒子具有自学习和社会学习的能力.通过每个粒子对自身速度和位置的逐代更新,最终整个种群在搜索空间中找到全局最优解.

假设某种群中有 I 个粒子,第 i 个粒子在 D 维空间的第 k 次迭代后速度和位置分别表示为 $\mathbf{x}_i^k = [x_{i1}^k, x_{i2}^k, \dots, x_{iD}^k]$ 和 $\mathbf{v}_i^k = [v_{i1}^k, v_{i2}^k, \dots, v_{iD}^k]$.粒子的速度和位置更新公式为

$$\mathbf{v}_{id}^{k+1} = w\mathbf{v}_{id}^k + c_1r_1(\mathbf{p}_{id}^k - \mathbf{x}_{id}^k) + c_2r_2(\mathbf{p}_{gd}^k - \mathbf{x}_{id}^k), \quad (1)$$

$$\mathbf{x}_{id}^{k+1} = \mathbf{x}_{id}^k + \mathbf{v}_{id}^{k+1}. \quad (2)$$

式中: w 是惯性权重,体现了速度本身的记忆性; c_1, c_2 分别是自学习因子和社会学习因子,为使算法收敛; $0 < c_1, c_2 < 2$; r_1, r_2 是 2 个介于 $[0, 1]$ 之间服从均匀分布的随机数;粒子 i 在第 d 维第 k 次迭代后经历过的最优位置由 \mathbf{p}_{id}^k 表示,整个种群在第 d 维第 k 次迭代后经历过的最优位置为 \mathbf{p}_{gd}^k .

为了解决离散空间中目标优化的问题,PSO 算法的离散二进制形式——BPSO 算法被提出^[13].该算法速度更新公式不变,如式(1)所示.但其位置由于被离散化为 0 或 1,相应的更新公式需做以下调整:

$$\mathbf{x}_{id}^{k+1} = \begin{cases} 1, & \xi < S(\mathbf{v}_{id}^{k+1}); \\ 0, & \xi \geq S(\mathbf{v}_{id}^{k+1}). \end{cases} \quad (3)$$

式中: ξ 是介于 $[0, 1]$ 之间服从均匀分布的随机数, $S(\mathbf{v}_{id}^{k+1})$ 为将连续取值的速度离散化为 0 或 1 的 Sigmoid 函数

$$S(\mathbf{v}_{id}^{k+1}) = 1/(1 + \exp(-\mathbf{v}_{id}^{k+1})). \quad (4)$$

1.2 二进制混沌粒子群算法

本文提出的二进制混沌粒子群算法由于吸收了混沌系统具有的全局遍历性的优点,因此提高了优化算法的效率.BCPSO 算法采用的混沌系统为 Logistic 方程:

$$z_{t+1} = \mu z_t(1 - z_t), \quad t = 0, 1, 2, \dots, m \quad (5)$$

式中: μ 为控制参数, m 为混沌迭代次数, $\mathbf{Z} = [z_0, z_1, \dots, z_m]$ 为混沌序列矢量.若控制参数 $\mu = 4$,且初值 $z_0 \in [0, 1]$,则系统完全处于混沌状态,且所有混沌变量均介于 $[0, 1]$ 之间.

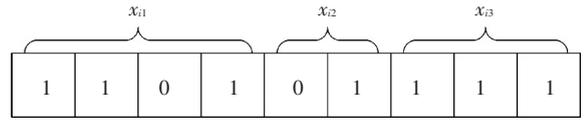


图 1 第 i 个粒子的二进制编码

在 BCPSO 算法中,粒子的维度 E 应等于可调决策变量的个数.假设存在 3 个可调决策变量,则粒子的维度为三维.此时,粒子 i 由 3 个决策变量 x_{i1}, x_{i2} 和 x_{i3} 组合而成,其二进制编码如图 1 所示.若 E 个决策变量经二进制编码后其长度分别为 $l_{i1}, l_{i2}, \dots, l_{iE}$,则搜索空间的维度 D 为

$$D = \sum_{q=1}^E l_{iq}. \quad (6)$$

BCPSO 算法在混沌优化时,需进行如下的映射和逆映射处理:

$$\eta_q^0 = (x_{gq}^k - a_q)/(b_q - a_q), \quad 1 \leq q \leq E \quad (7)$$

$$x_{gq}^t = a_q + \eta_q^t(b_q - a_q), \quad 1 \leq q \leq E, \quad 1 \leq t \leq m. \quad (8)$$

式中: x_{gq}^k 为第 k 次迭代后最优位置 \mathbf{p}_{gd}^k 中第 q 个决策变量的实数值; b_q 和 a_q 分别为第 q 个决策变量取值的最大、最小值; x_{gq}^t 为经 t 次混沌迭代后第 q 个决策变量的实数值.为了将最优位置映射到式(5)中的区间 $[0, 1]$ 内,需采用式(7).反之,当混沌迭代结束后,需用式(8)将所得混沌变量序列逆映射回原解空间.

BCPSO 算法具体实现流程如下:

1) 初始化算法参数和种群.初始化的参数包括最大迭代次数 K 、惯性权重 w 、学习因子 c_1 和 c_2 .初始化种群即随机产生 I 个粒子的 D 维位置初矢量 $\mathbf{x}_i^0 = [x_{i1}^0, x_{i2}^0, \dots, x_{iD}^0]$ 和速度初矢量 $\mathbf{v}_i^0 =$

$[v_{i1}^0, v_{i2}^0, \dots, v_{iD}^0]$. 位置初矢量 \mathbf{x}_i^0 的每个元素均是0或1. 粒子 i 的最优位置 $\mathbf{p}_i^0 = [p_{i1}^0, p_{i2}^0, \dots, p_{iD}^0]$ 设为 $\mathbf{x}_i^0 = [x_{i1}^0, x_{i2}^0, \dots, x_{iD}^0]$.

2) 对初位置矢量 $\mathbf{x}_i^0 = [x_{i1}^0, x_{i2}^0, \dots, x_{iD}^0]$ 进行二进制译码, 得到 E 个决策变量的实数值. 计算种群的适应度值, 保存最大的适应度值 $FBest$, 并将其对应的位置设为全局最优位置 $\mathbf{p}_g^0 = [p_{g1}^0, p_{g2}^0, \dots, p_{gD}^0]$. 同时将各粒子此时的适应度值设为粒子的历史最优值 $FLbest_i$ 并保存.

3) 根据式(1)和(2)分别对粒子的速度和位置进行更新. 对更新后的位置进行二进制译码, 得到 E 个决策变量的实数值. 计算种群的适应度值, 如果粒子 i 的适应度值优于 $FLbest_i$, 则将此时粒子 i 的位置设为粒子 i 的最优位置 $\mathbf{p}_i^k = [p_{i1}^k, p_{i2}^k, \dots, p_{iD}^k]$, 同时更新 $FLbest_i$; 如果此时种群的适应度最大值优于 $FBest$, 则该最大值所对应的位置设为全局最优位置 $\mathbf{p}_g^k = [p_{g1}^k, p_{g2}^k, \dots, p_{gD}^k]$, 同时更新全局最优值 $FBest$.

4) 混沌初始化. 首先将全局最优位置 $\mathbf{p}_g^k = [p_{g1}^k, p_{g2}^k, \dots, p_{gD}^k]$ 进行二进制译码得到 E 个决策变量的实数值矢量 $\mathbf{x}_g^k = [x_{g1}^k, x_{g2}^k, \dots, x_{gE}^k]$. 然后根据式(7)将 \mathbf{x}_g^k 映射到 $[0, 1]$ 混沌空间, 得到混沌初值矢量 $\mathbf{H}^0 = [\eta_1^0, \eta_2^0, \dots, \eta_E^0]$.

5) 混沌优化. 根据式(5)进行混沌迭代, 得到混沌矢量序列 $\mathbf{H}^t (1 \leq t \leq m)$. 然后根据式(8)将 $\mathbf{H}^t (1 \leq t \leq m)$ 逆映射回 E 个决策变量的实数值矢量 $\mathbf{x}_g^t = [x_{g1}^t, x_{g2}^t, \dots, x_{gE}^t]$. 计算 $\mathbf{x}_g^t = [x_{g1}^t, x_{g2}^t, \dots, x_{gE}^t]$ 适应度值, 同时对其进行二进制编码, 得到原搜索空间的 m 个矢量 $\mathbf{p}_g^{kt} = [p_{g1}^{kt}, p_{g2}^{kt}, \dots, p_{gD}^{kt}]$. 若 m 个矢量的适应度最大值优于 $FBest$, 则将全局最优位置 $\mathbf{p}_g^k = [p_{g1}^k, p_{g2}^k, \dots, p_{gD}^k]$ 更新为对应于该适应度最大值的矢量, $FBest$ 更新为该适应度最大值. 用 \mathbf{p}_g^k 随机取代当前种群的一个粒子 i 的位置 \mathbf{x}_i^k .

6) 判断是否达到最大迭代次数 K : 若未达到 K , 则返回执行3); 若达到 K , 算法结束.

上述算法流程中步骤1)~3)与标准PSO算法相同. 但通过步骤4)~5), BCPSO算法引入了混沌优化过程, 该过程改善了原PSO算法跳离局部极值的能力, 有效提高了算法精度.

2 基于BCPSO的认知决策引擎

认知决策引擎进行决策的实质可以描述为: 利用智能优化算法合理调整可调发射机参数, 以达到某种性能组合的最理想实现. 即该过程实质

上是多目标优化问题.

假设认知无线电中有 E 个可调决策变量 $\mathbf{r} = r_i (i = 1, 2, 3, \dots, E)$ 和 λ 个目标函数 $\mathbf{f} = [f_1, f_2, \dots, f_\lambda]$. 任何不同表达形式的多目标函数优化问题都可以转化成统一的表达形式, 且通过将所有目标聚集可把多目标优化问题转换为单目标问题^[14]:

$$\operatorname{argmax}\{f(\mathbf{r})\} = \operatorname{argmax}\left\{\sum_{i=1}^{\lambda} \omega_i f_i(\mathbf{r})\right\}. \quad (9)$$

式中 $\omega_i (1 \leq i \leq \lambda)$ 为介于 $[0, 1]$ 之间的权重系数, 且需满足如下关系:

$$\sum_{i=1}^{\lambda} \omega_i = 1. \quad (10)$$

权重系数 ω_i 反映了不同 QoS 的服务对各目标函数的偏重程度. 如当终端处于省电模式下, 相应于最小化功率的权重系数 ω_i 就应该设置为最大; 再如当用户在观看多媒体时, 相应于最大化吞吐量的权重系数 ω_i 应该设为最大. 可以说, 权重系数决定了认知决策引擎的优化方向. 因此, 认知系统工作模式的切换可以通过调整权重系数加以实现. 通过不同权重系数的设置, 可以测试并分析在不同通信模式下认知决策引擎的性能.

利用二进制混沌粒子群算法提出的 BCPSO 算法, 可根据式(9)搜索到最优适应度值及其对应的发射机参数组合. 我们将该发射机参数组合称为最优传输方案. 认知决策引擎决策出最优传输方案, 并将该方案传递给认知系统硬件加以实施.

3 仿真结果与分析

本文的仿真结果均是基于认知 OFDM 系统得到的. 该仿真系统的具体参数如表1所示. 该系统发射功率值共有 64 个, 二进制编码后由 6 个比特组成; 调制方式 4 种, 由 2 个比特组成. 这样一个子载波由 8 比特组成, 32 个子载波共计有 256 个比特. 即粒子维度 $D = 256$.

表1 认知 OFDM 系统参数

参数	子载波数 N	调制方式	发射功率 范围/dbm	发射功率 间隔/dbm
取值	32	BPSK QPSK 16QAM 64QAM	0~25.2	0.4

每个子载波有 2 个决策变量: 调制方式和功率. 这样 32 个子载波共有 64 个决策变量, 即 $E = 64$. 背景噪声为加性高斯白噪声, 噪声功率 -60 dbm, 路径损耗 60 dB. 假设仿真系统的目标函数分别为最小化发射功率、最小化误码率 (bit

error rate, BER) 和最大化吞吐量.各目标函数归一化表达式为

$$f_{\min\text{-power}} = 1 - \frac{\bar{P}}{P_{\max}}, \quad (11)$$

$$f_{\min\text{-BER}} = 1 - \frac{\log_{10}(0.5)}{\log_{10}(\bar{p}_e)}, \quad (12)$$

$$f_{\max\text{-throughput}} = \frac{\frac{1}{N} \sum_{y=1}^N \log_2(M_y) - \log_2(M_{\min})}{\log_2(M_{\max}) - \log_2(M_{\min})}. \quad (13)$$

式中: \bar{P} 为 1 个粒子所有载波发射功率均值; P_{\max} 为最大发射功率,其值为 25.2 dbm; \bar{p}_e 为所有载波的平均 BER, M_{\max} 和 M_{\min} 分别为最大、最小调制数,取值分别为 64 和 2; M_y 为第 y 个子载波对应的调制数; N 为载波数,其取值为 32. 计算载波的平均 BER \bar{p}_e 时,需利用各种调制方式的 BER p_e 的近似表达式^[15]:

$$p_e = \begin{cases} Q\left(\sqrt{\frac{2E_b}{N_0}}\right) & \text{BPSK 和 QPSK;} \\ \frac{3}{4}Q\left(\sqrt{\frac{4E_b}{5N_0}}\right) & \text{16QAM;} \\ \frac{7}{12}Q\left(\sqrt{\frac{2E_b}{7N_0}}\right) & \text{64QAM.} \end{cases} \quad (14)$$

其中

$$Q(x) = \int_x^{+\infty} \frac{1}{2\pi} \exp\left(-\frac{\vartheta^2}{2}\right) d\vartheta. \quad (15)$$

将式(11)~(13)表示的目标函数聚集为如下单目标函数:

$$f = \omega_1 f_{\min\text{-power}} + \omega_2 f_{\min\text{-BER}} + \omega_3 f_{\max\text{-throughput}}. \quad (16)$$

式中 f 即为适应度函数,其反映了系统对发射功率、误码率和吞吐量的综合需求,用以评价发射参数优化配置的好坏.

假设认知 OFDM 系统工作在以下 3 种模式:低功耗模式、紧急模式和多媒体模式.3 种通信模式相应的权重系数如表 2 所示.在表 2 的低功耗模式下,系统对发射功率的要求较高,为此,反映功率的子目标函数 $f_{\min\text{-power}}$ 的权重系数 ω_1 被设为最大,为 0.8;同理,紧急模式和多媒体模式分别对反映误码率的子目标函数 $f_{\min\text{-BER}}$ 的权重系数 ω_2 和反映吞吐量的子目标函数 $f_{\max\text{-throughput}}$ 的权重系数 ω_3 设为最大.

文中提出的 BCPSO 算法的具体参数如表 3 所示.为了进行性能对比,文中也对分别基于 GA^[3]、BPSO 算法^[8] 和 BQPSO 算法^[9] 的认知引

擎进行了仿真.其中 GA 采用轮盘赌选择,单点交叉,交叉概率为 0.6,变异概率为 0.001.而 BPSO 算法和 BQPSO 算法的参数与表 3 所示的前 7 列一致.

表 2 3 种通信模式的权重系数

通信模式	ω_1	ω_2	ω_3
低功耗模式	0.80	0.15	0.05
紧急模式	0.05	0.80	0.15
多媒体模式	0.05	0.15	0.80

表 3 中粒子维度 D 的取值与决策变量个数及取值个数有关,惯性权重 w 、自学习因子 c_1 、社会学习因子 c_2 的选取均为 PSO 算法的经典取值,混沌控制参数 μ 取值为 4 可以保证混沌系统完全处于混沌状态.种群大小 I 、最大迭代次数 K 和混沌最大迭代次数 m 其取值与具体系统要求有关.若系统对实时性要求很高,则上述 3 个参数应取较小值;反之,当系统对实时性不敏感,而对适应度性能要求较高时,则上述参数可取较大值以保证性能要求.对仿真系统的实时性和性能要求进行折中,从而确定表 3 中种群大小 I 、最大迭代次数 K 和混沌最大迭代次数 m 的相应取值.粒子速度最大值 $V_{\max} = 4$ 为仿真经验值.另外,最大迭代次数 K 的选取需要通信的双方相互反馈确定.离线状态下进行系统仿真,可得到一次迭代的时间代价,认知无线电系统将这一参数存储到 CR 知识库中.在线状态时,认知系统通过信道认知引擎感知到当前信道的信道相干时间等状态信息,并将该信息传递给认知决策引擎.认知决策引擎根据获得的信道相干时间和 CR 知识库提供的一次迭代的时间代价,据此确定最大迭代次数 K 的取值.由于信道认知引擎和 CR 知识库超出了文中研究范畴,相关具体内容可参见文献[16].

表 3 BCPSO 算法参数

参数	I	D	w	c_1	c_2	w_{\max}	K	μ	m
取值	300	224	1	2	2	4	1 000	4	20

表 4 给出了在 3 种通信模式下,通过基于 BCPSO 的认知决策引擎优化后的平均发射机参数.如表 4 所示,在低功耗模式下,认知决策引擎通过减小平均发射功率的方式以保证用户功耗达到最低.在紧急模式下,为了保证系统的高可靠性传输,需使系统平均 BER 达到最小.为此,认知决策引擎通过提高发射功率和降低调制阶数的方式加以实现.在多媒体模式下,为使系统平均吞吐量达到最大,认知决策引擎使平均调制阶数达到最

大.由此可见,通过改变目标函数中的权重系数,文中提出的认知决策引擎可以沿着不同的方向进行优化,以保证不同通信模式不同 QoS 服务的实际需求.

表 4 3 种通信模式下的 BCPSO 的平均发射机参数

通信模式	平均发射功率/dbm	平均调制阶数
低功耗模式	0.662 5	1.718 8
紧急模式	18.52 5	2.218 8
多媒体模式	19.437 5	6.000 0

图 2~4 分别给出了低功耗模式、紧急模式和多媒体模式下 4 种算法的平均归一化适应度值性能曲线.在上述 3 种通信模式下,每种算法经 1 000 次迭代后的平均适应度值如表 5 所示.不同算法的收敛性能如表 6 所示.

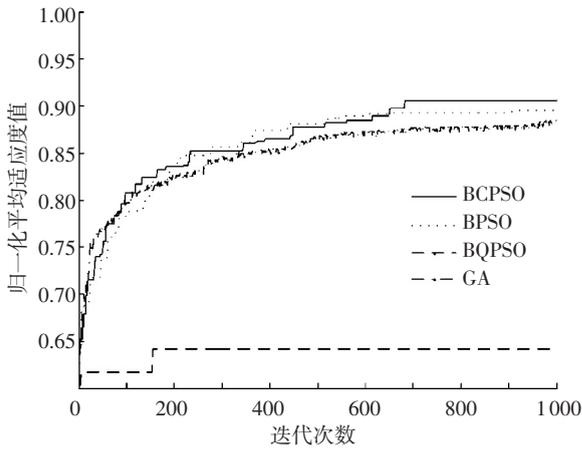


图 2 低功耗模式下性能对比

表 5 3 种通信模式下的平均适应度值

通信模式	BCPSO	BPSO	GA	BQPSO
低功耗模式	0.907	0.896	0.883	0.641
紧急模式	0.773	0.746	0.763	0.738
多媒体模式	0.942	0.938	0.937	0.806

如图 2 和表 5 所示,低功耗模式下,在算法精度方面,提出 BCPSO 算法最好,以下依次为 BPSO 算法、GA 和 BQPSO 算法. BCPSO 算法的平均适应度值为 0.907,高过次优的 BPSO 算法 0.011.如图 2 和表 6 所示,在收敛性方面, BQPSO 算法在 155 次迭代后即收敛,但由于其适应度值较差,可以看出 BQPSO 算法出现了“早熟”现象.除了 BQPSO 算法,文中提出的 BCPSO 算法的收敛速度明显比 GA 和 BPSO 算法更快.

如图 3 和表 5 所示,紧急模式下,提出 BCPSO 算法在精度方面有显著优势.此时该算法的平均适应度值为 0.773,高过次优的 GA 0.01.如图 3 和表 6 所示,除“早熟”的 BQPSO 算法外,

BPSO 算法收敛最快,其次 BCPSO 算法,最差的是 GA. BCPSO 算法精度性能的优势是以牺牲部分收敛性能为代价的.

表 6 3 种通信模式下的收敛性能

通信模式	BCPSO	BPSO	GA	BQPSO
低功耗模式	683	919	960	155
紧急模式	749	632	1 000	29
多媒体模式	442	240	385	107

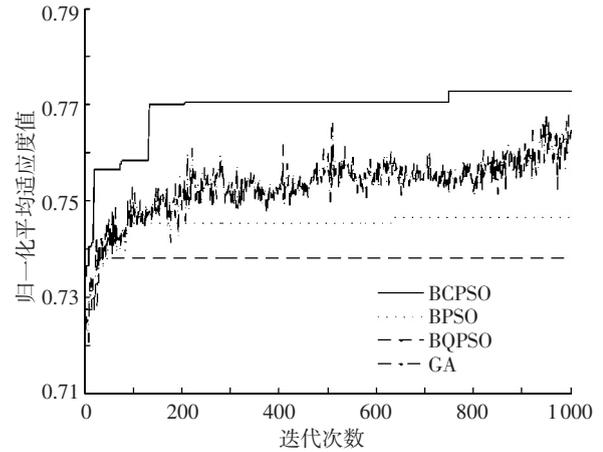


图 3 紧急模式下性能对比

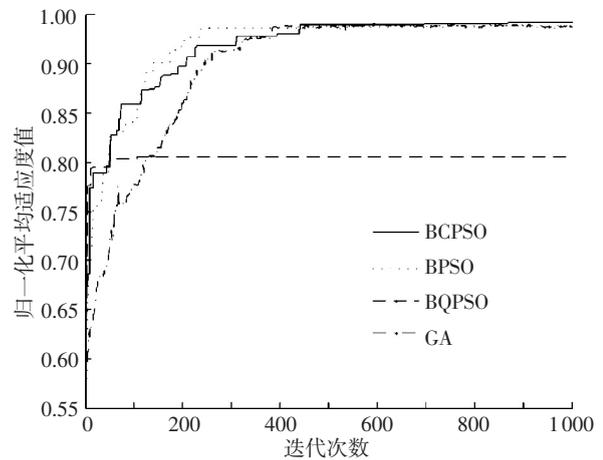


图 4 多媒体模式下性能对比

如图 4 和表 5 所示,在多媒体模式下,在算法精度方面,提出 BCPSO 算法最好,以下依次为 BPSO 算法、GA 和 BQPSO 算法.但前 3 者的平均适应度值非常接近.如图 4 和表 6 所示,不考虑“早熟”的 BQPSO 算法,文中提出的 BCPSO 算法收敛性能不如 GA 和 BPSO 算法.

综合上述分析,在 3 种不同通信模式下,虽然文中提出的 BCPSO 算法有时收敛性能不是最好,但其以牺牲部分收敛性能为代价,换来了精度的提高.此外,3 种通信模式下,该算法的精度性能始终保持最高,也体现了算法自身较强的鲁棒性.这表明文中提出的 BCPSO 算法和基于该算法的

认知决策引擎能够保证认知 OFDM 系统在不同通信模式下高效可靠地自适应传输。

4 结 语

本文首先提出了一种新型智能优化算法,称为 BCPSO 算法.在此基础上,提出了基于 BCPSO 的认知决策引擎.该引擎吸收了混沌理论的全局遍历性,使其在多目标优化过程中摆脱了局部极值的不利影响,有效提高了优化性能.由基于认知 OFDM 系统的仿真结果可以看出,本文提出的认知决策引擎能够高效地对发射机参数进行优化配置.其优化的适应度值更高,且针对不同通信模式其鲁棒性也更好.这表明本文提出的认知决策引擎能够满足认知系统对发射机参数合理优化的需求.

参考文献

- [1] MITOLA J, MAGUIRE G. Cognitive radio: making software radios more personal [J]. IEEE Personal Communications Magazine, 1999, 6(4): 13-18.
- [2] MITOLA J. Cognitive radio for flexible mobile multimedia communications [C]//Proceedings of IEEE International Workshop on Mobile Multimedia Communications'99. San Diego: IEEE, 1999: 3-10.
- [3] RIESER C J. Biologically inspired cognitive radio engine model utilizing distributed genetic algorithm for secure and robust wireless communications and networking [D]. Blacksburg: Virginia Polytechnic Institute and State University, 2004: 35-57.
- [4] RIESER C J, RONDEAU T W, BOSTIAN C W, et al. Cognitive radio testbed: further details and testing of distributed genetic algorithm based cognitive engine for programmable radios [C]//Proceedings of IEEE Military Communication Conference. Monterey: IEEE, 2004: 1437-1443.
- [5] AYMAN A E, MAHAMOD I, MOHD A M A, et al. Development of a cognitive radio decision engine using multi-objective hybrid genetic algorithm [C]//Proceedings of the 2009 IEEE 9th Malaysia International Conference on Communications. Kuala Lumpur: IEEE, 2009: 343-347.
- [6] WU Di, WANG Feng, YANG Shengyao. Cognitive radio decision engine based on priori knowledge [C]//Proceedings of the 3rd International Symposium on Parallel Architecture, Algorithm and Programming. Dalian: Conference Publishing Services (CPS), 2010: 255-259.
- [7] KHEDR M, SHATILA H. A cognitive radio approach for WiMAX systems [C]//Proceedings of the 7th IEEE/ACS International Conference on Computer Systems and Applications. Rabat: IEEE, 2009: 550-554.
- [8] 赵知劲,徐世宇,郑仕链,等. 基于二进制粒子群算法的认知无线电决策引擎[J]. 物理学报, 2009, 58(7): 5118-5125.
- [9] 张静,周正,高万鑫,等. 基于二进制量子粒子群算法的认知无线电决策引擎[J]. 仪器仪表学报, 2011, 32(2): 451-456.
- [10] YU Yang, TAN Xuezhi, CHI Yonggang, et al. A joint rate control and AMC algorithm for adaptive transmission systems [J]. Journal of Harbin Institute of Technology (New Series), 2013, 20(2): 12-16.
- [11] EBERHART R, KENNEDY J. A new optimizer using particle swarm theory [C]//Proceedings of the 6th IEEE International Symposium on Micro Machine and Human Science. Piscataway: IEEE, 1995: 39-43.
- [12] KENNEDY J, EBERHART R. Particle swarm optimization [C]//Proceedings of IEEE International Conference on Neural Networks. Perth: IEEE, 1995: 1942-1948.
- [13] KENNEDY J, EBERHART R. A discrete binary version of the particle swarm algorithm [C]//Proceedings of IEEE International Conference on Computational Cybernetics and Simulation. Orlando: IEEE, 1997: 4104-4108.
- [14] 郑金华. 多目标进化算法及其应用[M]. 北京: 科学出版社, 2007: 2-10.
- [15] GOLDSMITH A. Wireless Communications [M]. Cambridge: Cambridge University Press, 2005: 130-131.
- [16] 于洋,谭学治. 基于信道分类和自适应调制编码的认知无线电决策引擎[J]. 电子与信息学报, 2014, 36(2): 371-376.

(编辑 苗秀芝)