

基于二进制粒子群算法的认知无线电决策引擎^{*}

赵知劲¹⁾ 徐世宇¹⁾ 郑仕链^{2)†} 杨小牛²⁾

1) 杭州电子科技大学通信工程学院, 杭州 310018)

2) 中国电子科技集团公司第 36 研究所, 嘉兴 314033)

(2008 年 3 月 8 日收到, 2008 年 11 月 12 日收到修改稿)

提出了基于粒子群算法的认知无线电决策引擎, 并提出了一种种群自适应粒子群算法, 利用粒子群算法调整优化无线电参数, 运用多载波系统对算法性能进行了仿真分析. 实验结果表明基于二进制粒子群算法的认知决策引擎在收敛速度、收敛精度和算法稳定性上都要明显优于经典遗传算法, 基于种群自适应粒子群算法的决策引擎则能进一步提高算法初期性能, 满足认知无线电实时性要求.

关键词: 认知无线电, 粒子群算法, 遗传算法, 认知决策引擎

PACC: 9580D

1. 引 言

认知无线电(cognitive radio, CR)是一项能够检测、利用频谱空穴,大幅度改进通信效率的智能无线通信技术,它包含三大基本功能使其具有认知特性:感知功能、学习功能和适应性参数调整功能.文献[1]中构建了基于遗传算法(genetic algorithm, GA)的认知引擎用于实现CR基本功能,文献[2—4]则更详细地讨论了应用多目标GA的认知无线电参数调整功能的实现问题,验证了GA实现参数调整的有效性.文献[5,6]则使用简单加权和方法将多目标优化问题转换为单目标优化问题,使用简单的GA进行优化调整.针对经典GA的缺陷,文献[7]提出新的种群初始化方法,提高GA收敛速度,文献[8]提出基于模拟退火遗传算法的认知决策引擎,改进了GA中后期的爬上能力,文献[9]提出基于量子遗传算法的认知决策引擎,改进了算法的收敛速度、收敛精度和稳定性.然而,这些研究都还局限于遗传算法的范畴,本文则将粒子群算法(particle swarm optimization, PSO)引入认知无线电系统实现中,提出了基于二进制PSO的认知决策引擎,并在此基础上提出一种PSO种群初始化方法,以进一步改进算法性能.多载波系统仿真结果验证了本文所提出的算法的有效性.

2. 粒子群算法

2.1. 基本粒子群算法

PSO中,用粒子的位置表示待优化问题的解,每个粒子性能的优劣程度取决于当前粒子的位置对优化问题目标函数适应度的大小.每个粒子由一个速度矢量来决定粒子的飞行方向和速率大小.

设粒子群中粒子个数为 S ,则在一个 D 维的搜索空间中,粒子 i ($1 \leq i \leq S$)在第 k 次迭代时的位置信息可以表示为 $\mathbf{x}_i^k = [x_{i1}^k, x_{i2}^k, \dots, x_{iD}^k]$,速度信息表示为 $\mathbf{v}_i^k = [v_{i1}^k, v_{i2}^k, \dots, v_{iD}^k]$,粒子 i 到目前为止所经历的最好位置为 $\mathbf{p}_i^k = [p_{i1}^k, p_{i2}^k, \dots, p_{iD}^k]$,群体中所有粒子到目前为止所经历过的最好位置为 $\mathbf{p}^k = [p_{b1}^k, p_{b2}^k, \dots, p_{bD}^k]$,其中 b 为具有最优位置粒子的索引.在这里,所谓的“最好位置”即为适应度最高的解.采用这种表示方法后,粒子群算法的进化方程可描述为

$$v_{id}^{k+1} = \omega v_{id}^k + c_1 r_1 (p_{id}^k - x_{id}^k) + c_2 r_2 (p_{bd}^k - x_{id}^k) \quad (1)$$

$$x_{id}^{k+1} = x_{id}^k + v_{id}^{k+1} \quad (2)$$

其中, d 表示粒子的第 d 维($1 \leq d \leq D$), ω 为惯性权重, c_1 和 c_2 为学习因子(也称加速常数), r_1 和 r_2 为分布在 $[0, 1]$ 间的随机数.为了减少在进化过程中粒

^{*} 浙江省教育厅科技计划项目(批准号 20050543)和电科院预研基金(批准号 41101040102)资助的课题.

[†] E-mail: lianshizheng@126.com

子离开搜索空间的可能性,粒子速度通常限定在一定范围内,即 $v_{id}^k \in [-V_{\max}, +V_{\max}]$. 注意(1)式采用引入惯性权重后的更新方式^[10],最初提出的粒子群算法^[11]对应于 $\omega = 1$ 的情况.

(1)式的等式右边由三个部分组成,第一部分是粒子先前的速度,可以理解为粒子先前速度的惯性;第二部分为认知部分,表示粒子本身的思考,根据自身的最优认知结果来更新下一次搜索的位置;第三部分为社会部分,表示粒子间的信息共享与相互合作,表明了粒子通过对群体最优解的认知来改善自身下次搜索的位置.(2)式表示粒子以通过自身和群体认知得到的速度来更新下一次搜索的位置,因此粒子的速度也可以理解为粒子向群体最优和自身最优靠近的步长.

2.2. 二进制粒子群算法

最初的 PSO 主要针对解决连续空间函数优化问题,为解决工程实际中众多的组合优化问题, Kennedy 和 Eberhart 又提出了离散二进制粒子群优化算法^[12].

二进制 PSO 中,将粒子的每一维位置 x_{id}^k 和 p_{id}^k 都限定为 0 或 1,而对粒子的速度 v_{id}^k 则不作限制.速度的大小用来确定粒子在对应位置上为 0 或者为 1,速度大一些,表示对应位置选 1 的概率大,而较小的速度则意味着对应位置选 0 的概率较大.算法中采用 Sigmoid 函数将速度大小转换到 [0, 1] 之间的概率值:

$$\text{sig}(v_{id}^k) = \frac{1}{1 + \exp(-v_{id}^k)}. \quad (3)$$

从(3)式可以看出,速度 v_{id}^k 越大,则 $\text{sig}(v_{id}^k)$ 的值越接近于 1,而当速度很小时, $\text{sig}(v_{id}^k)$ 的值也相应越接近于 0,因此, $\text{sig}(v_{id}^k)$ 代表了 x_{id}^k 取值为 1 的概率.由此,与(2)式不同的是,二进制粒子群算法中粒子位置更新公式如下:

$$x_{id}^{k+1} = \begin{cases} 1, & r < \text{sig}(v_{id}^{k+1}), \\ 0, & r \geq \text{sig}(v_{id}^{k+1}), \end{cases} \quad (4)$$

其中, r 为均匀分布在 [0, 1] 之间的随机数.除了以上不同之外,二进制粒子群算法的其他部分与基本连续粒子群算法类似.

综上所述,本文讨论的二进制粒子群算法的流程如下:

1) 令 $k = 0$, 随机产生每个粒子的位置 x_{id}^k 和速度 v_{id}^k , 其中 $x_{id}^k \in \{0, 1\}$, $v_{id}^k \in [-V_{\max}, +V_{\max}]$, $1 \leq d$

$\leq D$.

2) 计算每个粒子的适应度值,设 $p_i^k = [x_{i1}^k, x_{i2}^k, \dots, x_{id}^k]$, 并使 $p_b^k = [x_{b1}^k, x_{b2}^k, \dots, x_{bd}^k]$, 其中 b 为具有最高适应度的粒子的索引.

3) 令 $k = k + 1$, 根据(1)式更新 v_{id}^k ; 如果 $v_{id}^k > V_{\max}$, 则令 $v_{id}^k = V_{\max}$, 如果 $v_{id}^k < -V_{\max}$, 则令 $v_{id}^k = -V_{\max}$.

4) 随机产生均匀分布于 [0, 1] 间的随机数 r , 根据(4)式更新 x_{id}^k .

5) 计算每个粒子的适应度值,对于粒子 i , 如果其适应度大于 p_i^{k-1} 的适应度, 则令 $p_i^k = [x_{i1}^k, x_{i2}^k, \dots, x_{id}^k]$, 否则 $p_i^k = p_i^{k-1}$; 如果其适应度大于 p_b^{k-1} 的适应度, 则令 $p_b^k = [x_{b1}^k, x_{b2}^k, \dots, x_{bd}^k]$; 如果没有哪个粒子的适应度大于 p_b^{k-1} 的适应度, 则令 $p_b^k = p_b^{k-1}$.

6) 如果达到最大迭代次数, 算法终止; 否则, 跳至 3).

3. 基于二进制 PSO 的认知决策引擎

3.1. 认知决策引擎

认知决策引擎遵循的基本过程是调整自身参数来实现某一期望的(最优的)性能组合,该过程可以描述为多目标优化问题.设认知无线电需要调整的参数为 $k = [k_1, k_2, \dots, k_m]$, m 为参数个数,其要实现各个目标函数表示为 $f = [f_1, f_2, \dots, f_n]$, n 为目标函数个数,则认知决策引擎所要解决的优化问题可以描述为

$$\min/\max\{f(k)\} = [f_1(k), f_2(k), \dots, f_n(k)] \quad (5)$$

约束条件

$$k = [k_1, k_2, \dots, k_m] \in K,$$

$$f = [f_1, f_2, \dots, f_n] \in F.$$

其中 K 和 F 分别为 k 和 f 所要满足的约束空间,约束条件主要由无线监管约束和无线电系统硬件条件限定.

为反映不同链路条件、不同用户需求对不同目标函数的偏好信息,设权重向量 $w = [w_1, w_2, \dots, w_n]$ 表示各个目标函数的权重,其中 w_i ($1 \leq i \leq n$) 表示系统对目标函数 f_i 的偏好程度,其值越大,偏好程度越强.各个权重满足如下约束条件:

$$\begin{aligned} w_i &\geq 0, i = 1, 2, \dots, n \\ w_1 + w_2 + \dots + w_n &= 1. \end{aligned} \quad (6)$$

另外,如果各个目标函数可以进行归一化处理,则该优化问题可以进一步简化.为表示方便,仍使用 $f = [f_1 \ f_2 \ \dots \ f_n]$ 表示已经过归一化处理的目标函数,并使各个目标函数的优化方向一致,均转换为最大化问题.引入权重向量并将目标函数归一化后,就可以采用简单加权和方法^[13]将(5)式所示的优化问题转化为简单的单目标优化问题,单目标函数表示为

$$f(k) = \sum_{i=1}^n w_i f_i(k). \quad (7)$$

由此,认知决策引擎所要完成的任务即在给定权重向量、目标函数和参数空间的情况下,调整待优化参数的取值以实现(7)式所示目标函数的最大化.

当各个目标函数的权重确定后,决策引擎的优化方向也就确定,这也正是在给定环境下试图找到最优解的期望特性.一旦权重发生变化,决策引擎则需要立即寻找另一个最优解.例如,假设认知无线电



图1 粒子 i 的位置结构

在适应度评价上,本算法直接将认知无线电的目标函数作为衡量粒子性能的适应度函数,无需对适应度进行任何尺度变换.随着粒子位置的不断更新,当达到最大迭代次数时,算法终止,此时 $p_i^k = [x_{i1}^k \ x_{i2}^k \ \dots \ x_{iD}^k]$ 即对应于认知决策引擎优化得到的参数配置.

3.3. 种群自适应

以上 PSO 中,初始粒子群中每个粒子的位置随机产生,以使初始解均匀分布于寻优空间,保证至少有一个粒子接近于最优解.然而,根据问题域的信息,可以改进初始化技术来提高 PSO 性能.对于无线信道环境,可以假设环境参数缓慢变化,所以上一个认知环中 PSO 优化所得到的解在当前环境下仍然较优,因此将上一个认知环的解作为当前初始种群的一部分可以明显提高当前环境下找到最优解的概率.本文将采用这种种群初始化方式的 PSO 称为种群自适应 PSO(PA-PSO),其图示如图 2 所示.图中,圆点表示随机分布的初始解,实心正方形表示上一认知环优化得到的最优解,菱形表示当前环境下寻优空间的理想最优解.由于环境变化缓慢,两个相

当前工作在最大化流量模式下,这时能够实现较高数据速率的参数配置所对应的目标函数值必定较高.当无线电检测到电源功率较低时,就会改变权重切换到低功耗模式,这种模式下实现低功率传输的参数配置则具有较高的目标函数值.因此,权重反映了无线电的优化方向,仅通过简单调整权重向量就可以切换系统的工作模式,从而满足各种应用以及环境需求.

3.2. 算法描述

本文提出的基于 PSO 的认知决策引擎采用二进制粒子群算法,粒子 i 的位置表示如图 1 所示,描述了认知无线电需优化的 m 个参数与粒子位置之间的关系.图 1 中, L_j 表示对 k_j 进行二进制编码所需的位数, $1 \leq j \leq m$. L_j 数值由 k_j 的取值范围和所需求解精度决定.取值范围越大、求解精度越高,则 L_j 数值越大.

邻认知环的理想最优解基本保持不变^[7].因为上一认知环优化得到的解(实心正方形)与理想最优解非常接近,所以在当前认知环中实心正方形与菱形也非常接近.而随机产生的解(圆点)则均匀分布于整个寻优空间,与菱形非常接近的概率很小^[14].所以,包含实心正方形的当前种群具有更高的概率在算法初期接近理想最优解.环境变化量由环境变化因子 σ 度量,其定义为变化了的环境参数占总的环境参数个数的百分比. σ 越大,则环境变化越大,上一认知环的解在当前环境下的优越性越弱.相反, σ 越小,则环境变化越小,上一认知环的解在当前环境下的优越性越强.

4. 仿真及结果分析

4.1. 多载波认知无线电系统仿真设计

算法仿真实验使用类似于文献[6]中的多载波系统,子载波数为 32. 系统可调参数包括发射功率和调制方式.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

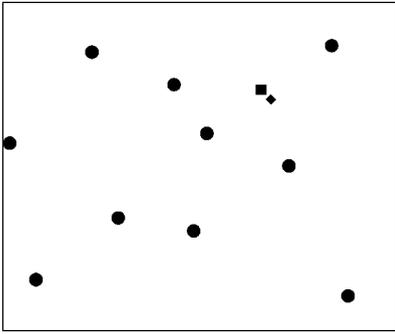
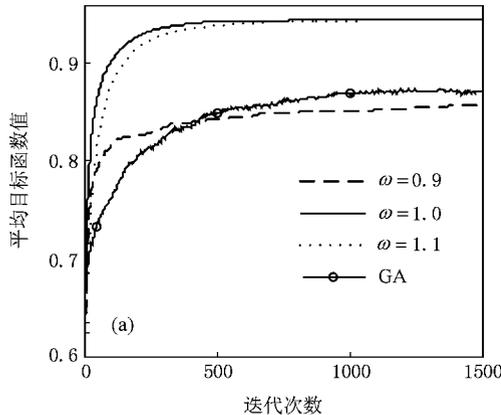


图 2 PA-PSO 种群初始化

包括 BPSK, QPSK, 16QAM 和 64QAM. 每个子载波信道均可选择不同的发射功率和调制方式. 这种多载波系统参数调整寻优空间为 256^{32} , 数量级为 10^{77} . 之所以选择这么大的寻优空间是为了测试算法的寻优能力. 仿真中认知无线电要实现的目标函数包括最小化发射功率、最小化 BER 和最大化数据速率. 各个目标函数使用如下归一化形式:

$$f_{\text{min-power}} = 1 - \bar{P}/P_{\text{max}}, \quad (8)$$



$$f_{\text{min-ber}} = 1 - \frac{\log_{10}(0.5)}{\log_{10}(\bar{P}_{\text{be}})}, \quad (9)$$

$$f_{\text{max-data-rate}} = \frac{\frac{1}{N} \sum_{i=1}^N \log_2 M_i - \log_2 M_{\text{min}}}{\log_2 M_{\text{max}} - \log_2 M_{\text{min}}}, \quad (10)$$

其中 \bar{P} 为所有载波发射功率平均值, P_{max} 为最大可能发射功率, \bar{P}_{be} 为所有载波比特错误率平均值, M_{min} 为最小调制进制数, M_{max} 为最大调制进制数, M_i 为第 i 个载波对应的调制进制数, N 为载波数. 假设信道类型为加性高斯白噪声 (additive white Gaussian noise, AWGN) 信道, 噪声功率为 -70 dBm, 发射端到接收端的固定路径损耗为 70 dB. 除固定损耗之外, 每个子载波还分配一个随机数 (取值范围为 $0-1$) 用来表示该载波对应的信道衰减, 从而模拟动态信道. 每个子载波信道的损耗为固定损耗与对应的信道衰减之和. 星座图采用格雷码分配. 给定各个目标函数权重, 可将三个目标函数归为如下单目标函数:

$$f = w_1 f_{\text{min-power}} + w_2 f_{\text{min-ber}} + w_3 f_{\text{max-data-rate}}. \quad (11)$$

由此, 认知无线电决策引擎要实现的任务即为调整各个载波参数实现 (11) 式所示目标函数的最大化.

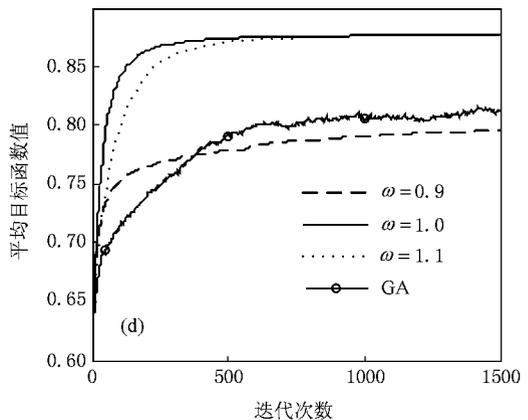
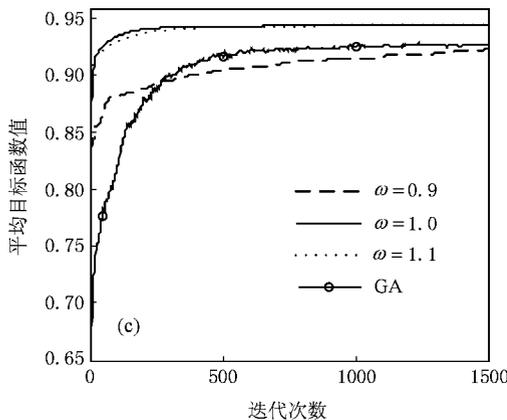
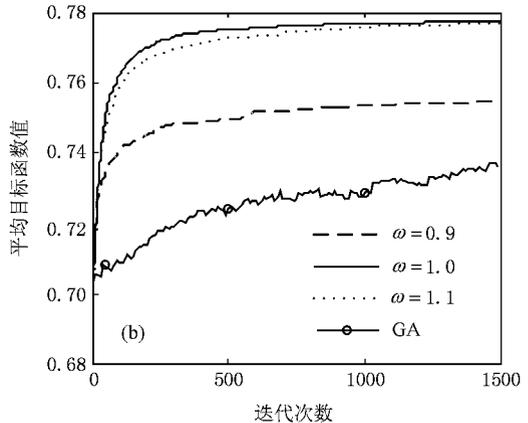


图 3 PSO 和 GA 性能比较 (a) 模式 1 (b) 模式 2 (c) 模式 3 (d) 模式 4

4.2. 仿真与分析

仿真中对基于 GA 和基于 PSO 的认知决策引擎性能进行比较. PSO 参数设置为 $S = 30$, $c_1 = c_2 = 2$, $V_{\max} = 4$, 最大迭代次数为 1500. 惯性权重 ω 采用不同设置: 1, 0.9 和 1.1. GA 采用二进制编码方式, 染色体中基因为各个子载波信道对应的发射功率和调制方式, 包含比特位数为 256, 采用轮盘赌选择、两点交叉和基本位变异, 参数设置如下: 交叉概率为 0.6, 变异概率为 0.001, 种群规模为 30, 最大进化代数为 1500. 目标函数对应的权重设置采用表 1 所示的四种模式. 模式 1 适用于低功耗情况, 模式 2 适用于可靠性要求高的应用, 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, 模式 4 则对各个目标函数的偏好相同.

表 1 目标函数权重设置

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

对四种模式分别进行 10 次独立实验, 每次实验记录每一代种群中最大适应度个体目标函数值, 再 10 次实验结果取平均, 所得平均目标函数值随进

化代数的变化曲线如图 3 所示. 由图可知, PSO 性能明显优于 GA. 不同惯性权重下 PSO 性能有所差异, $\omega = 1$ 是较为理想的选择. 需要指出的是, 由于认知决策引擎寻优问题复杂, 惯性权重设置较小时将严重影响算法性能.

表 2 给出了不同进化代数时 PSO 优化得到的 10 次独立实验的目标函数平均值以及 10 次实验收敛目标函数值的标准差, GA 的实验结果作为对比. 从表中可知, 四种权重设置模式下, PSO 在不同进化代数优化得到的平均目标函数值均要明显大于 GA 优化得到的平均目标函数值. 在进化代数较小为 50, 100 时, PSO 就能获得较优解, 说明了 PSO 搜索的高效性. 值得指出的是, PSO 在进化代数为 50 时所优化得到的平均目标函数值与 GA 在 1500 代时优化得到的平均目标函数值接近相同, 这对实时性要求高的 CR 决策引擎来说具有重要意义. CR 决策引擎计算量主要集中在目标函数计算上, 以适应度评价为计算复杂度的衡量标准, 则意味着 PSO 能在 GA 搜索 1/30 的时间内实现与 GA 性能接近一致的参数调整结果. 另外, 当进化代数为 1500 时, PSO 10 次独立实验所得最终目标函数值的标准差明显小于 GA, 因此基于 PSO 的认知决策引擎算法比基于 GA 的决策引擎稳定.

表 2 平均目标函数值比较

迭代次数	模式 1		模式 2		模式 3		模式 4	
	GA	PSO	GA	PSO	GA	PSO	GA	PSO
50	0.7323	0.8574	0.7084	0.7510	0.7771	0.9251	0.6939	0.7978
100	0.7608	0.9000	0.7093	0.7620	0.8175	0.9342	0.7124	0.8392
500	0.8487	0.9415	0.7241	0.7751	0.9178	0.9440	0.7908	0.8741
1500	0.8718	0.9444	0.7373	0.7776	0.9271	0.9444	0.8132	0.8765
标准差	0.0085	10^{-16}	0.0067	0.0014	0.0038	10^{-5}	0.0088	10^{-16}

为验证 PA-PSO 的性能, 图 4 和图 5 分别给出了环境变化因子 $\sigma = 10\%$ 和 $\sigma = 90\%$ 时的仿真结果, 标准 PSO 的情况作为对比. 仿真中假设上一认知环和当前认知环所处的优化模式相同. 环境参数包括噪声功率和各个子信道的衰减因子. PA-PSO 初始种群中包含上一个认知环的解占总的粒子数的 10%. 为满足实时性要求, 假设上一认知环的解为上一认知环 PSO 运行至 100 代时的最优解. 从图 4、图 5 可以看出, PA-PSO 在迭代初期的性能明显优于 PSO, 这是由于 PA-PSO 初始种群就包含了上一认知环的最优配置, 虽然环境参数发生变化, 但由于模式相同,

优化方向仍然相同, 故上一认知环的解在当前认知环中仍然具有明显的优越性. 由此可知, 基于 PA-PSO 的 CR 决策引擎能更好地满足 CR 的实时性要求.

5. 结 论

本文提出了基于 PSO 的 CR 决策引擎, 并提出了一种种群自适应 PSO 算法, 实现 CR 自适应参数调整功能. 仿真结果表明, 采用 PSO 的 CR 决策引擎在搜索效率、收敛精度和算法稳定性方面均明显优

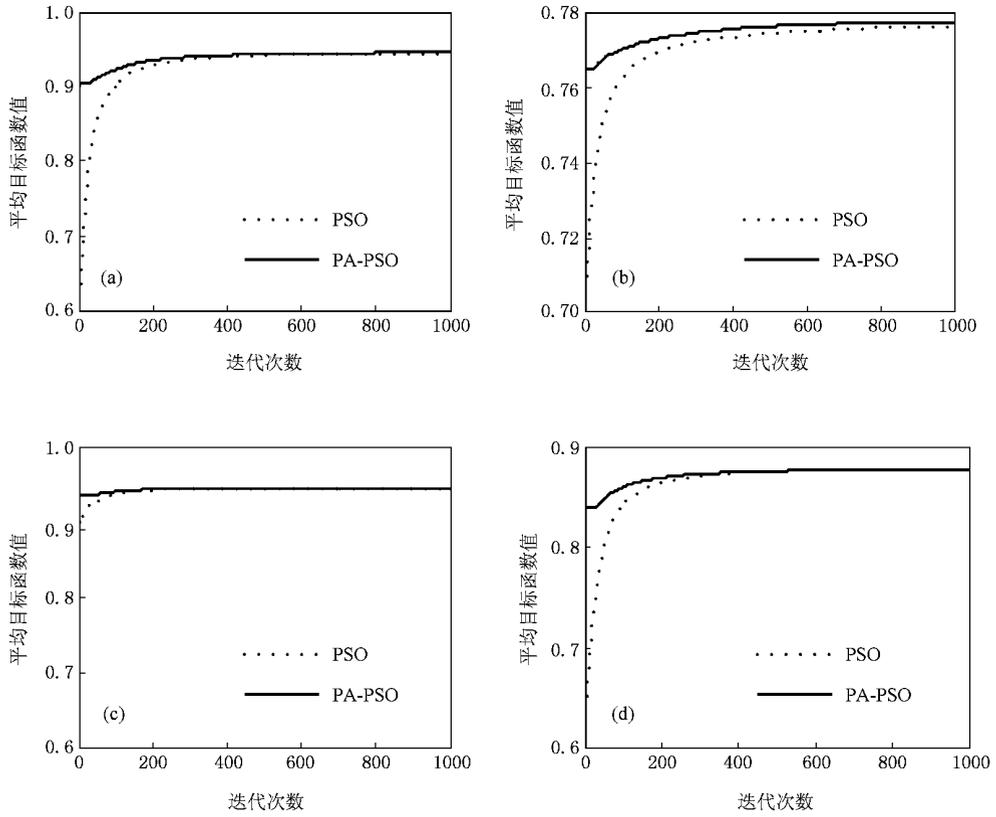


图 4 $\sigma = 10\%$ 时 PA-PSO 性能 (a) 模式 1 (b) 模式 2 (c) 模式 3 (d) 模式 4

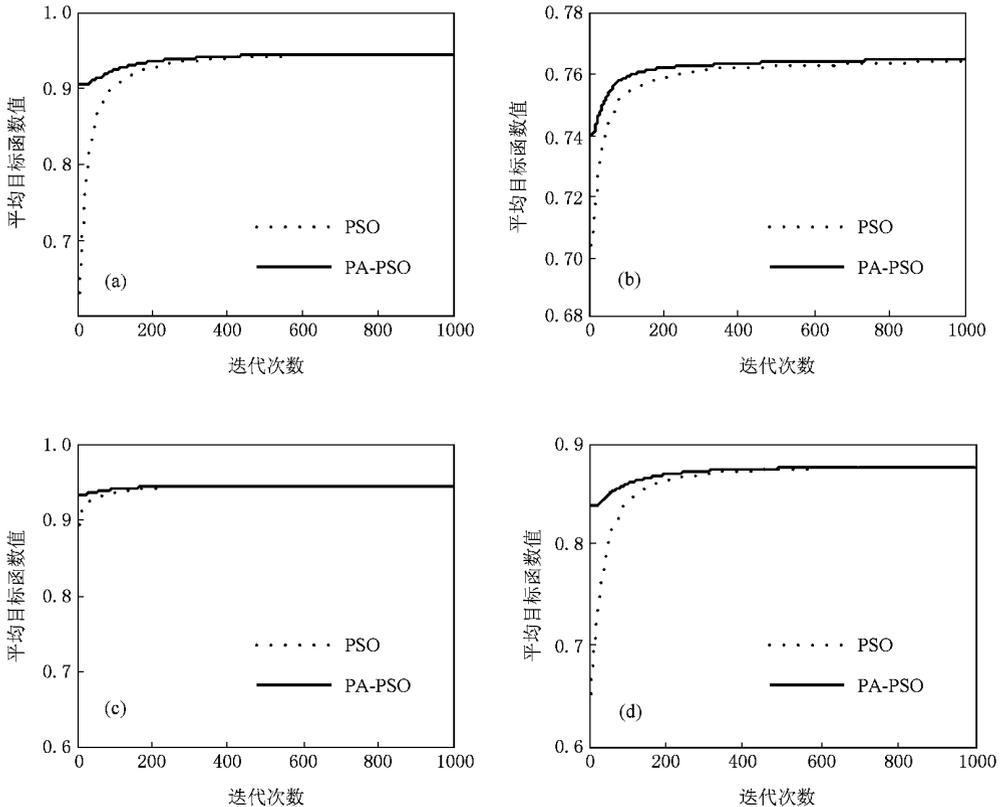


图 5 $\sigma = 90\%$ 时 PA-PSO 性能 (a) 模式 1 (b) 模式 2 (c) 模式 3 (d) 模式 4

于 GA ,它能在迭代初期找到满意解 ,从而降低决策时间.基于 PA-PSO 的 CR 决策引擎则能在不提高算

法复杂度的前提下进一步提高 PSO 算法在迭代初期的性能 ,更适合于实时性要求高的应用 .

-
- [1] Rieser C J 2004 *Biologically Inspired Cognitive Radio Engine Model Utilizing Distributed Genetic Algorithms for Secure and Robust Wireless Communications and Networking* (Blacksburg : Virginia Tech)
- [2] Rondeau T W , Rieser C J , Bostian C W 2004 *SDR Forum Technical Conference* C-3
- [3] Zhao Z J , Zheng S L , Xing G J , Shang J N 2007 *Piezoelectrics and Acoustooptics* **29** 90 (in Chinese) [赵知劲、郑仕链、邢国际、尚俊娜 2007 压电与声光 **29** 90]
- [4] Rondeau T W , Le B , Maldonado D , Scaperoth D , Bostian C W 2006 *The first International Conference on Cognitive Radio Oriented Wireless Networks and Communication*
- [5] Hauris J F 2007 *IEEE International Symposium on Computational Intelligence in Robotics and Automation* 427
- [6] Newman T R , Barker B A , Wyglinski A M , Agah A , Evans J B , Minden G J 2007 *Wiley Wireless Communications and Mobile Computing* **7** 1129
- [7] Newman T R , Rajbanshi R , Wyglinski A M , Evans J B , Minden G J 2007 *The second International Conference on Cognitive Radio Oriented Wireless Networks and Communications*
- [8] Zhao Z J , Zheng S L , Xu C Y 2007 *WSEAS Transactions on Communications* **6** 773
- [9] Zhao Z J , Zheng S L , Shang J N , Kong X Z 2007 *Acta Phys . Sin .* **56** 6760 (in Chinese) [赵知劲、郑仕链、尚俊娜、孔宪正 2007 物理学报 **56** 6760]
- [10] Shi Y , Eberhart R 1998 *IEEE International Conference on Evolutionary Computation* 69
- [11] Kennedy J , Eberhart R 1995 *IEEE International Conference on Neural Networks* **4** 1942
- [12] Kennedy J , Eberhart R 1997 *The Conference on Systems , man , and Cybernetics* 4104
- [13] Ishibuchi H , Murata T 1998 *IEEE Transactions on Systems , Man , and Cybernetics-Part C : Applications and Reviews* **28** 392
- [14] Fette B 2006 *Cognitive Radio Technology* (Boston : Elsevier Newnes) p256

Cognitive radio decision engine based on binary particle swarm optimization *

Zhao Zhi-Jin¹⁾ Xu Shi-Yu¹⁾ Zheng Shi-Lian^{2)†} Yang Xiao-Niu²⁾

1 *Telecommunication School, Hangzhou Dianzi University, Hangzhou 310018, China*

2 *The 36th Research Institute of China Electronic Technology Group Corporation, Jiaxing 314033, China*

(Received 8 March 2008 ; revised manuscript received 12 November 2008)

Abstract

Cognitive radio decision engine based on particle swarm optimization is proposed. A population adaptive particle swarm optimization is also proposed to improve the convergence rate. Particle swarm optimization and population adaptive particle swarm optimization are used to adapt radio parameters respectively, and multi-carrier system is used for the performance analysis. Results show that cognitive decision engine based on binary particle swarm optimization has better convergence, precision and stability than the classic genetic algorithm, and population adaptive particle swarm optimization can further improve the performance at the initial stage of the search to meet real time requirement of cognitive radio.

Keywords : cognitive radio, particle swarm optimization, genetic algorithm, cognitive decision engine

PACC : 9580D

* Project supported by the Science and Technology Program of the Education Department of Zhejiang Province (Grant No. 20050543) and the Pre-Research Foundation of Electronics Science Research Institute (Grant No. 41101040102).

† E-mail : lianshizheng@126.com