

# 融合学习差分进化和粒子群优化算法的认知决策引擎

张煜培<sup>1</sup> 赵知劲<sup>1,2</sup> 郑仕铤<sup>2</sup>

(杭州电子科技大学浙江省数据存储传输及应用技术研究重点实验室 杭州 310018)<sup>1</sup>

(中国电子科技集团第 36 研究所通信系统信息控制技术国家级重点实验室 浙江 嘉兴 314001)<sup>2</sup>

**摘要** 为了提高认知无线电系统的参数决策速度和性能,提出一种融合粒子群和学习差分进化算法的认知无线电决策引擎(HPSO-BLDE)。首先,对学习差分进化算法引入自适应变异机制,使得每条染色体随个体适应度和平均适应度进行自适应变异,提高其局部寻优能力。然后,改进粒子群算法的学习因子,并加入扰动项,防止算法早熟;选用更合适的变换函数,将正反向速度转换为相同概率更新粒子位置,提高最优解的精度,从而提高粒子群算法的全局寻优能力。最后,在认知引擎模型中并行地运行改进的粒子群算法(IBPSO)和差分进化算法(IBMDE),每隔固定的迭代次数后,融合两种算法的最优个体信息,得到 HPSO-BLDE 算法,使 IBPSO 算法和 IBMDE 算法的种群兼具二者的优点,从而提高了最优解的求解精度并加快了收敛速度。多载波通信系统的参数决策仿真结果表明,IBPSO 算法、IBMDE 算法和 HPSO-BLDE 算法的性能优于已有的爬山遗传(HGA)算法、量子粒子群算法(BQPPO)和二进制学习差分进化算法(BLDE),其中 HPSO-BLDE 算法的性能最优。

**关键词** 认知无线电,认知决策引擎,重配置,差分进化,粒子群优化

中图分类号 TN929.5 文献标识码 A DOI 10.11896/j.issn.1002-137X.2019.06.013

## Cognitive Decision Engine of Hybrid Learning Differential Evolution and Particle Swarm Optimization

ZHANG Yu-pei<sup>1</sup> ZHAO Zhi-jin<sup>1,2</sup> ZHENG Shi-lian<sup>2</sup>

(Zhejiang Provincial Key Lab of Data Storage and Transmission Technology of Hangzhou Dianzi University, Hangzhou 310018, China)<sup>1</sup>

(State Key Lab of Information Control Technology in Communication System, No. 36 Research Institute

of China Electronic Technology Corporation, Jiaxing, Zhejiang 314001, China)<sup>2</sup>

**Abstract** In order to increase the speed and performance of parameter decision in cognitive radio system, a cognitive radio decision engine (HPSO-BLDE) based on hybrid particle swarm optimization and learning differential evolution algorithm was proposed. First, the adaptive mutation mechanism is introduced into the learning differential evolution algorithm, so that each chromosome adaptively varies with individual fitness and average fitness to improve its local optimization capability. Then, the learning factor of particle swarm optimization algorithm is modified and the perturbation is added to prevent the premature. The more appropriate transform function is selected to convert the forward and backward velocity to the same probability to update the particle position and improve the precision of the optimal solution, thus improving the global optimization solution. Finally, the improved binary particle swarm optimization (IBPSO) and the improved binary differential evolution algorithm (IBMDE) are run in parallel in the cognitive engine model, and the best individual information of the two algorithms is fused after a fixed number of iterations to obtain the HPSO-BLDE algorithm. The populations of IBPSO algorithm and IBMDE algorithm have the both advantages, thus the optimal solution accuracy and convergence speed of the HPSO-BLDE algorithm are enhanced. Parameter decision simulation results of multi-carrier communication system shows that the IBPSO algorithm, IBMDE algorithm and HPSO-BLDE algorithm have better performance than hilling genetic algorithm (HGA), binary quantum particle swarm algorithm (BQPPO) and binary learning differential evolution algorithm (BLDE), and HPSO-BLDE algorithm has the best performance among these algorithms.

**Keywords** Cognitive radio, Cognitive decision engine, Reconfiguration, Differential evolution, Particle swarm optimization

到稿日期: 2018-05-27 返修日期: 2018-08-13 本文受“十二五”国防预研项目基金(41001010401)资助。

张煜培(1995-),男,硕士生,主要研究方向为认知无线电, E-mail: 1354136083@qq.com; 赵知劲(1959-),女,博士,教授,博士生导师,主要研究方向为认知无线电、通信信号处理, E-mail: zhaozj03@hdu.edu.cn(通信作者); 郑仕铤(1984-),男,博士,高级工程师,主要研究方向为认知无线电、压缩感知、进化算法。

## 1 概述

认知无线电(Cognitive Radio, CR)是实现动态频谱接入的一项关键技术。CR系统具备感知环境变化、主动学习、自适应参数调整等特点,并能主动检测频谱空洞,利用空闲的频谱资源<sup>[1]</sup>。认知决策引擎(Cognitive Decision Engine, CDE)是CR系统的智能核心,主要作用是根据环境的变化配置相应的无线电参数<sup>[2-3]</sup>,包括信号的调制方式、调制阶数、发射功率和编码速率等,以满足最大化吞吐率、最小化功耗和最小化干扰等要求。以上参数配置是多维问题,复杂度较高。机器学习及人工智能技术被广泛应用于CDE中,包括基于案例的系统<sup>[4-5]</sup>(Case Base System, CBS)、神经网络<sup>[6-7]</sup>(Artificial Neural Network, ANN)和智能优化算法等。CBS的缺点是过分依赖存储于案例库中的案例,一旦CBS中存储了错误的信息,就可能对新的案例产生影响。ANN在应用于CDE之前,需要大量的训练集,如何获取真实环境中的大量训练数据是一个难题。自文献[8]提出利用遗传算法(GA)解决CDE后,涌现出一大批利用智能优化解决CDE问题的算法。文献[9]提出量子遗传算法(QGA),采用量子比特编码,通过量子门更新,与GA相比,收敛速度和收敛精度都有很大提升;文献[10]和文献[11]分别采用二进制粒子群(BPSO)和爬山遗传(HGA)算法;文献[12]提出量子粒子群算法(BQP-SO),该算法被证明比BPSO更有效。但是,HGA和BPSO算法的全局寻优能力不如局部寻优能力。文献[13-14]提出改进BPSO算法,文献[13]的TV-PSO算法通过时变转换函数提高了全局寻优能力,但是寻优速度有待提高;文献[14]的BMPSO-GSA算法将PSO和引力搜索结合,提高了算法的搜索速度,但是寻优精度不高。二进制学习差分进化算法<sup>[15]</sup>(Binary Learning Differential Evolution, BLDE)是新近提出的一种解决离散问题的差分进化算法,该算法优于经典的BinDE和AQDE算法,在绝大多数离散问题中表现优异,其全局寻优能力较强,但是局部寻优能力较弱。针对这些问题,本文首先改进BPSO和BLDE,提出求解认知决策引擎的HPSO-BLDE算法,在该引擎模型中,HPSO-BLDE算法根据认知无线电系统的性能要求,对需要调整的参数求解最优解,并将这些参数输出给发射机和接收机;最后将所提算法与文献[11]的HGA、文献[12]的BQP-SO、文献[15]的BLDE、IBPSO和IBLDE算法进行比较,证明了HPSO-BLDE算法的收敛速度更快,寻优精度更高。

## 2 认知决策引擎

图1为认知无线电决策引擎的结构图。认知无线电决策引擎综合考虑用户需求、外界环境变化和OSI五层协议等,执行通信系统重构所必须的建模、学习和优化处理,并输出网络各层参数的配置信息。

假设CR系统是一个具有可调发射功率和调制方式的多载波OFDM系统。当外部环境发生变化时,系统会工作在与以前不同的频率上,因此,新的工作信道参数必须与不同服务相适应。这些信道参数总体上可以分为两大类<sup>[16]</sup>:环境参数

和传输参数。环境参数主要表示无线电环境特征,包括固定路径损耗、信噪比SNR等,它们作为CR的输入,用以确定合适的传输参数,如发射功率 $p$ 、调制类型和调制进制数等。因此,认知决策引擎对这些参数的优化求解可以表述为:根据已知的环境参数确定合适的传输参数,实现所确定的目标。这些目标通常是尽量减小发射功率 $f_{\min\text{-power}}$ 和误码率 $f_{\min\text{-ber}}$ ,而最大化数据速率 $f_{\max\text{-data rate}}$ ,其归一化数学表达式为<sup>[9-11]</sup>:

$$f_{\min\text{-power}} = \frac{\bar{p}}{p_{\max}} \quad (1)$$

$$f_{\min\text{-ber}} = \frac{\log_{10}(0.5)}{\log_{10}(\bar{p}_{be})} \quad (2)$$

$$f_{\max\text{-data rate}} = \frac{\frac{1}{N} \sum_{i=1}^N \log_2 M_i - \log_2 M_{\min}}{\log_2 M_{\max} - \log_2 M_{\min}} \quad (3)$$

其中, $p_{\max}$ 是最大化发射功率, $\bar{p}$ 是 $N$ 个子载波的平均功率; $\bar{p}_{be}$ 是平均误比特率; $M_i$ 是第 $i$ 个子载波的调制进制数, $M_{\min}$ 和 $M_{\max}$ 分别是最小和最大的调制进制数。




图1 认知决策引擎的结构

Fig. 1 Structure of cognitive decision engine

为了将目标函数一致表示为最大化问题,将3个目标函数线性加权转化为单目标函数,即:

$$fit = \omega_1 \left(1 - \frac{\bar{p}}{p_{\max}}\right) + \omega_2 \left(1 - \frac{\log_{10}(0.5)}{\log_{10}(\bar{p}_{be})}\right) + \omega_3 \left(\frac{\frac{1}{N} \sum_{i=1}^N \log_2 M_i - \log_2 M_{\min}}{\log_2 M_{\max} - \log_2 M_{\min}}\right) \quad (4)$$

其中, $\omega_1, \omega_2$ 和 $\omega_3$ 满足:

$$\sum_{i=1}^3 \omega_i = 1, 0 \leq \omega_i \leq 1 \quad (5)$$

其目的是调节通信参数,最大化适应度函数 $fit$ 。权重矢量 $w = [\omega_1 \ \omega_2 \ \omega_3]$ 决定通信模式,具体设置如表1所列<sup>[17]</sup>。

表1 目标函数权重的设置

Table 1 Setting of objective function weight

通信模式	$w = [\omega_1, \omega_2, \omega_3]$
低功耗模式(最小化功耗)	[0, 8, 0, 15, 0, 05]
紧急模式(最小化BER)	[0, 15, 0, 8, 0, 05]
多媒体模式(最大化吞吐率)	[0, 05, 0, 15, 0, 8]

## 3 差分进化算法和粒子群算法

### 3.1 改进学习差分进化算法

二进制学习差分进化算法(BLDE)<sup>[15]</sup>是在差分进化算法的基础上,把问题参数的二进制编码作为染色体,再利用迭代的方式进行变异等运算来交换种群中的染色体信息,最终得到离散优化问题的解。该算法中引入支撑集种群和实验解的概念,其基本实现步骤如下:

(1)种群初始化。随机产生 $N$ 个初始个体构成种群 $Q'$

和支撑集种群  $A'$ , 并评价  $Q'$  中每一个个体的适应度值, 选出全局最优个体  $g$ , 令迭代变量  $t=1$ 。

(2) 判断算法是否满足终止条件, 若满足条件, 则终止运算并输出结果; 否则执行以下步骤。

(3) 更新实验解  $tx'$ 。从  $Q'$  中随机选择 2 个染色体  $x'_j$  和  $x'_k$ , 从  $A'$  中随机选择一个染色体  $y'_i$ , 令  $x'_k = (x'_{k1}, x'_{k2}, \dots, x'_{kd})$ ,  $y'_i = (y'_{i1}, y'_{i2}, \dots, y'_{id})$ ,  $tx' = (tx'_1, tx'_2, \dots, tx'_D)$ ,  $g' = (g'_1, g'_2, \dots, g'_D)$ ,  $D$  是编码维度。  $tx' = \arg \max \{ fit(x'_k), fit(y'_i) \}$ ; 当  $x'_{kd} = y'_{id}$  且  $g'_d \neq x'_{kd}$  时, 令  $tx'_d = g'_d$ , 否则  $tx'_d$  以概率  $p_\delta$  随机变异。

$$p_\delta' = \begin{cases} p_{m \min} + (p_{m \max} - p_{m \min}) \sqrt{\frac{t}{I}} \exp\left(\frac{-fit_m^{nc}}{(fit_{\max} - fit_{\min})^{nc} + fit_{avg}^{nc}}\right), & fit_m \geq fit_{avg} \\ p_{m \min} + (p_{m \max} - p_{m \min}) \sqrt{\frac{t}{I}} \exp\left(\frac{-fit_m^{nc}}{(fit_{\max} - fit_{\min})^{nc} + fit_{\min}^{nc}}\right), & fit_m < fit_{avg} \end{cases} \quad (6)$$

其中,  $p_{m \min}$  和  $p_{m \max}$  分别为最小变异概率和最大变异概率;  $t$  和  $I$  分别为当前迭代次数和最大迭代次数;  $fit_{\max}$ ,  $fit_{\min}$ ,  $fit_{avg}$  和  $fit_m$  分别表示当前种群中最大、最小、平均和第  $m$  个个体的适应度值;  $nc$  为指数因子。IBLDE 算法的核心思想是: 当  $fit_m < fit_{avg}$  时, 说明该个体是种群中较差的个体, 应增大  $p_\delta'$ , 并且适应度值越小,  $p_\delta'$  越大, 以加快其寻找优秀基因的速度; 当  $fit_m \geq fit_{avg}$  时, 说明该个体是种群中的优秀个体, 应减小  $p_\delta'$ , 以维持种群中优秀个体的比例, 并且适应度值越大,  $p_\delta'$  越小, 以保护优秀基因。

### 3.2 改进粒子群算法

粒子群优化算法受鸟类群体活动的启发, 将寻找问题最优解的过程看作鸟类(抽象成粒子)寻找食物的过程。二进制粒子群算法(BPSO)被用于解决离散优化问题, 在迭代过程中, 每个粒子都在搜索可能的解。它们根据式(7)和式(8)更新速度即  $v_i = (v_{i1}, v_{i2}, \dots, v_{iD})$  和位置即  $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ ,  $D$  是搜索空间的维度,  $v_{ij}$  和  $x_{ij}$  分别表示第  $i$  个粒子在第  $j$  维的速度和位置。

$$v_{id}^{t+1} = v_{id}^t + c_1 * r_1 * (p'_{id} - x'_{id}) + c_2 * r_2 * (g'_d - x'_{id}) \quad (7)$$

$$x'_{id}^{t+1} = \begin{cases} 1, & rand() \leq \frac{1}{1 + e^{-v_{id}^t}} \\ 0, & \text{else} \end{cases} \quad (8)$$

其中,  $t$  表示第  $t$  次迭代;  $c_1$  和  $c_2$  是学习因子, 通常设置为 2;  $r_1$  和  $r_2$  是在  $[0, 1]$  上服从均匀分布的 2 个随机变量;  $p'_i = (p'_{i1}, p'_{i2}, \dots, p'_{iD})$  和  $g' = (g'_1, g'_2, \dots, g'_D)$  分别表示截至  $t$  代时第  $i$  个粒子搜索的局部最优解和所有粒子搜索的全局最优解。

上述更新中,  $c_1$  和  $c_2$  分别表示粒子对个体经验和社会经验的认可程度, 决定了粒子的飞行速度和飞行方向, 影响着 PSO 算法的收敛速率和收敛精度。只利用  $p'_i$  和  $g'$  更新粒子速度能加快算法的收敛速度, 但是容易早熟<sup>[18]</sup>。对此, 本文选用更合适的变换函数, 将正反向速度转换为相同的位置取“1”的概率, 以提高最优解的精度; 改进学习因子, 加入扰动项, 防止算法早熟。

用式(10)和式(11)的指数形式对式(7)的学习因子  $c_1$  和  $c_2$  进行改进。

(4) 更新种群  $Q'$ 。将种群  $Q'$  中的每条染色体  $q'_i$  与  $tx'$  进行比较, 若  $tx'$  的适应度大于  $q'_i$ , 令  $q'_i = tx'$ 。

(5) 更新种群  $A'$ 。令  $t=t+1, A' = Q'^{-1}$ 。

(6) 转步骤(2)。

BLDE 算法具有良好的全局搜索能力, 并且通过学习上代种群加快了寻优速度, 但是在进化后期的搜索效率较低。因此, 本文将上述算法步骤(3)中固定变异概率  $p_\delta$  修改为式(6)所示的自适应变异概率  $p_\delta'$ , 使得每条染色体根据个体适应度和平均适应度的差值自适应变异, 得到改进的二进制学习差分进化算法(IBLDE)。

$$c' = c_f \frac{t}{I} \quad (9)$$

$$c'_1 = \epsilon * e^{\left(\frac{g'_d}{I}\right)} \quad (10)$$

$$c'_2 = 1 - c'_1 \quad (11)$$

其中,  $0 < c_f < 1$ ,  $I$  是迭代总次数,  $\epsilon$  是  $[0, 1]$  上的随机变量。这样设置的目的是, 在迭代过程中使得种群迅速跳出局部最优解, 搜索解空间, 以增强寻优能力。

式(7)利用全局最优解  $g'$  指导粒子飞行, 会加速陷入局部最优<sup>[19]</sup>。本文加入扰动项  $p'_{i1} - p'_{i2}$ , 以增加速度变化的多样性, 克服过早收敛的问题, 因此改进粒子速度的更新如式(12)所示。

$$v_{id}^{t+1} = v_{id}^t + c'_1 * r_1 * (p'_{id} - x'_{id}) + c'_2 * r_2 * [(g'_d - x'_{id} + p'_{i1} - p'_{i2})] \quad (12)$$

其中,  $p'_{i1}$  和  $p'_{i2}$  是随机从种群中选择的两个粒子的个体最优值。

式(8)采用 Sigmoid 函数将粒子速度值变换为其位置取“1”的概率, 但是当速度负向增大时, 取“1”的概率趋近于 0, 会影响最优解的精度, 因此本文利用式(13)所示的“V”型函数来更新粒子的位置。当速度绝对值增大时, 取“1”的概率增大。

$$T(v) = \left| \frac{2}{\pi} \arctan\left(\frac{\pi}{2} v\right) \right| \quad (13)$$

于是, 粒子位置的更新如式(14)所示:

$$x'_{ij} = \begin{cases} 1 - x'_{ij}, & rand < T(v'_{ij}) \\ x'_{ij}, & rand \geq T(v'_{ij}) \end{cases} \quad (14)$$

因此, 得到本文提出的改进二进制粒子群算法(IBPSO)的基本步骤如下:

(1) 初始化粒子种群, 计算每个粒子的适应度;

(2) 利用式(9)一式(11)计算学习因子  $c'_1$  和  $c'_2$ , 然后根据式(12)一式(14)更新粒子的速度和位置;

(3) 计算个体历史适应度的最大值, 将该个体确定为  $p'_i$ , 计算种群中所有个体历史适应度的最大值, 将该个体确定为全局最优个体  $g'$ ;

(4) 检测终止条件, 然后决定是转步骤(2)还是结束进程, 输出结果。

## 4 认知决策引擎的 HPSO-BLDE 算法

在保持 BLDE 算法较好的全局搜索能力的基础上,IBLDE 提高了 BLDE 的局部搜索能力;在保持 BPSO 算法的局部搜索能力的基础上,IBPSO 提高了 BPSO 算法的全局寻优能力。将这两种算法的优点结合起来,独立并行运行 IBLDE 算法和 IBPSO 算法,每隔  $T$  次迭代后,将 IBLDE 算法中  $k$  个最差的个体用 IBPSO 算法中  $k$  个最好的个体替代,同时,将 IBPSO 中  $k$  个最差的个体用 IBLDE 算法中  $k$  个最好的个体替代;若迭代次数为  $I$ ,则需替换  $\lfloor \frac{I}{T} \rfloor$  次,  $\lfloor \cdot \rfloor$  表示向下取整,即得本文的 HPSO-BLDE 算法。

### 4.1 编码及个体更新

设 OFDM 系统中有  $N$  个子载波,选取载波的功率、调制方式作为决策变量。IBLDE 染色体和 IBPSO 的粒子位置编码方式如图 2 所示,共有  $N$  个编码段,代表  $N$  个子载波的配置情况;每个编码段又分成 2 部分,代表 2 个决策变量。显然,每个染色体或粒子位置代表一种 OFDM 系统参数配置方案。每次迭代过程中,分别独立并行地根据 3.1 节和 3.2 节的方法对 IBLDE 和 IBPSO 个体进行更新。




图 2 个体编码

Fig. 2 Individual encoding

### 4.2 个体交换

每隔  $T$  次迭代更新后,对 IBLDE 种群个体和 IBPSO 种群个体分别进行适应度大小的排序,将 IBPSO 中  $k$  个最小值对应的个体用 IBLDE 中  $k$  个最大值对应的个体替换,同时,将 IBLDE 中  $k$  个最小值对应的个体用 IBPSO 中  $k$  个最大值对应的个体替换,从而得到新的 IBLDE 和 IBPSO 种群。

### 4.3 算法步骤

综上所述,所提 HPSO-BLDE 算法的基本步骤如下:

(1)初始化。分别产生种群大小为  $N_i$  的 IBPSO 种群  $S'$  和 IBLDE 种群  $Q'$  以及支撑集种群  $A'$ ,设置迭代次数  $I$  和间隔代数  $T$ ,令  $t=1$ 。

(2)评价个体。根据式(4)分别计算 IBPSO 和 IBLDE 的第  $i$  个个体的适应度值  $fit(s'_i)$  和  $fit(q'_i)$ 。

(3)更新个体。利用式(9)一式(12)、式(13)一式(14)对 IBPSO 个体的速度和位置进行更新,并确定全局最优个体;利用式(6)计算自适应变异概率  $p'_\delta$ ,执行 3.1 节 BLDE 算法的步骤(3)一步(5),对种群  $Q'$  和  $A'$  进行更新。

(4)判断  $\text{mod}(t, T) = 0$  是否成立,若成立则执行步骤(5),否则转步骤(2),其中  $\text{mod}$  是取模函数。

(5)分别对  $fit(s'_i)$  和  $fit(q'_i)$  排序,将  $fit(s'_i)$  中  $k$  个最小值对应的个体用  $fit(q'_i)$  中  $k$  个最大值对应的个体替换,同理,将  $fit(q'_i)$  中  $k$  个最小值对应的个体用  $fit(s'_i)$  中  $k$  个最大值对应的个体替换,从而得到新的  $S'$  和  $Q'$ 。

(6)判断  $t \leq I$  是否成立,若成立,  $t=t+1$ ,转步骤(2);否则转步骤(7)。

(7)将  $fit(s'_i)$  和  $fit(q'_i)$  中的最大值输出,并将其作为最终结果。

## 5 算法仿真与性能分析

本节通过仿真分析比较本文提出的 HPSO-BLDE 与 HGA<sup>[11]</sup>, BQPSO<sup>[12]</sup>, BLDE<sup>[15]</sup>, IBPSO 和 IBLDE 算法对 OFDM 系统参数的认知决策性能。

### 5.1 参数设置

OFDM 系统具有 32 个子载波,为每个子载波随机分配一个  $[0, 1]$  的数以模拟信道衰落情况。仿真系统的参数设置如表 2 所列。每个子载波包括发射功率和调制方式,共需 8 bit。整个系统需要 256 bit,寻优空间为  $2^{256}$ 。3 种调制方式的误比特率的计算参考文献[3]。

表 2 参数设置

Table 2 Parameter settings

参数	参数说明
发射功率	0~25.2 dBm, 步进 0.4, 6 bit 编码
数据率	1 Mbps
调制方式	BPSK, QPSK, 16QAM 和 64QAM, 2 bit 编码
噪声	加性高斯白噪声, 功率为 -80 dBm
路径损耗	85 dB
种群规模	30
迭代次数	300
BLDE 算法	$p_\delta = 0.05$ (参考文献[15])
BQPSO 算法	$\alpha = 0.6$ (参考文献[12])
HGA 算法	交叉概率为 0.6, 变异概率为 0.001 (参考文献[11])
HPSO-BLDE	$T = 20, k = 6, p_{m \max} = 0.01, p_{m \max} = 0.003,$ $nc = 2, c_f = 0.5$

### 5.2 仿真分析

#### (1) IBPSO 算法性能分析

目前已有许多 BPSO 改进算法,为了分析本文提出的 IBPSO 算法的有效性,将其与文献[13]的 TV-PSO 和文献[14]的 BMPSO-GSA 算法进行比较,其中种群规模和迭代次数同 5.1 节,其余参数设置参考文献[13-14]。应用这 3 种算法的认知决策引擎在低功耗模式、紧急模式和多媒体模式下的适应度曲线如图 3—图 5 所示,每条曲线都是 10 次独立实验的平均值。由图 3—图 5 可知,IBPSO 算法在迭代初期就表现出较强的寻优性能,仅在紧急模式下的适应度精度略低于 TV-PSO,总体性能表现优异,这是因为本文加入的扰动项、指数变化的学习因子和“V”型函数增强了粒子的全局寻优能力。




图 3 3 种算法在低功耗模式下的适应度曲线

Fig. 3 Fitness curves of three algorithms in low power mode

(2) HPSO-BLDE 算法性能分析

本文提出的 HPSO-BLDE 与 HGA<sup>[11]</sup>, BQPSO<sup>[12]</sup>, BL-DE<sup>[15]</sup>, IBPSO 和 IBLDE 算法在低功耗模式、紧急模式和多媒体模式下的适应度曲线如图 6—图 8 所示, 每条曲线都是 10 次独立实验的平均值。




图 4 3 种算法在紧急模式下的适应度曲线

Fig. 4 Fitness curves of three algorithms in emergency mode

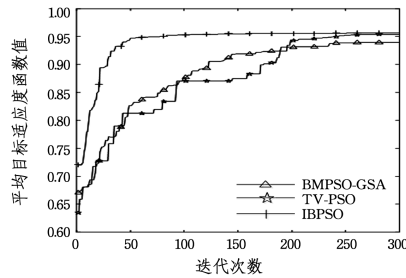


图 5 3 种算法在多媒体模式下的适应度曲线

Fig. 5 Fitness curves of three algorithms in multimedia mode




图 6 6 种算法在低功耗模式下的适应度曲线

Fig. 6 Fitness curves of six algorithms in low power mode

由图 6—图 8 可知, 6 种算法的适应度值都随迭代次数的增加而增大, 最后逐渐收敛, 说明 6 种算法应用于认知决策引擎问题中均是有效的。在 3 种模式下, 本文提出的 IBLDE 和

IBPSO 算法分别比 BLDE 和 BQPSO 的收敛速度快, 平均目标适应度值更高, 达到了提高 BLDE 局部搜索能力和 BPSO 全局搜索能力的目的。将二者融合后的 HPSO-BLDE 算法继承了二者的优点, 进一步提高了收敛速度和最优值的精度, 在 3 种模式下的性能稳定, 仅需要不到 30 次的迭代, 平均目标适应度值就达到最大, 说明算法的收敛速度较快。




图 7 6 种算法在紧急模式下的适应度曲线

Fig. 7 Fitness curves of six algorithms in emergency mode




图 8 6 种算法在多媒体模式下的适应度曲线

Fig. 8 Fitness curves of six algorithms in multimedia mode

6 种算法第一次达到的最优化适应度值及对应的迭代次数如表 3 所列。由表 3 可知, 6 种算法中 HPSO-BLDE 算法的适应度函数值最大, 寻优精度最高, 其所需的迭代次数比 BLDE, BQPSO, HGA 和 IBPSO 少得多, 仅稍多于 IBLDE。例如, 当系统工作于紧急模式下时, HPSO-BLDE 的适应度值达到 0.9301, 比 BLDE, BQPSO, HGA, IBPSO 和 IBLDE 分别高出 0.0140, 0.0389, 0.1566, 0.0186 和 0.012, 并且在迭代 27 次以后就可以得到较满意的解; 虽然 IBLDE 算法的收敛速度快于 HPSO-BLDE, 但其最优解的精度不如后者。相比较而言, 基于 HPSO-BLDE 算法可以实时、高性能地配置传输参数。

表 3 6 种算法在 3 种模式下得到的最优适应度值及相应的迭代次数

Table 3 Optimal fitness values and corresponding iterations for six algorithms in three modes

	优化次数						适应度值					
	BQPSO	BLDE	HGA	IBPSO	IBLDE	HPSO-BLDE	BQPSO	BLDE	HGA	IBPSO	IBLDE	HPSO-BLDE
低功耗模式	275	107	294	134	10	22	0.9498	0.9329	0.9344	0.9559	0.9444	0.9594
紧急模式	265	167	268	298	10	27	0.8912	0.9161	0.7735	0.9115	0.9181	0.9301
多媒体模式	204	206	248	136	28	25	0.9505	0.9266	0.9431	0.9561	0.9463	0.9791

表 4 列出了 6 种算法在低功耗模式、紧急模式、多媒体模式下的参数配置结果。由表 4 可以看出, HPSO-BLDE 在 3 种模式下的参数配置性能优于其他算法。以低功耗模式为例, 该模式下需要减小发射功率, HPSO-BLDE 的平均发射功率为

0.0125 dbm, 比 BLDE, BQPSO, HGA, IBPSO 和 IBLDE 分别减少到 1/35, 1/8, 1/35, 1/2 和 1/20, 并且具有较小的误码率和较大的吞吐率。以上结果说明本文算法成功实现了最小化传输功率这一主要优化目标, 同时也兼顾了另外两个优化目标。

表 4 6种算法在3种模式下的参数配置结果的对比

Table 4 Comparison of parameter configuration results of six algorithms in three modes

		BLDE	BQPSO	HGA	IBPSO	IBLDE	HPSO-BLDE
低功耗模式	传输功率/dbm	0.4375	0.1000	0.437	0.0259	0.2500	0.0125
	BER	0.0595	0.0710	0.052	0.0934	0.0527	0.0891
	吞吐量/Mbps	4.7810	5.1870	4.500	6	4.5938	5.8750
紧急模式	传输功率/dbm	2.5875	5.2875	12.563	2.6250	1.500	0.500
	BER	$8.2 \times 10^{-9}$	$7.8 \times 10^{-7}$	0.0029	$8.4 \times 10^{-9}$	$5.6 \times 10^{-9}$	$4.8 \times 10^{-9}$
	吞吐量/Mbps	1.4688	1.5313	2.5313	1.5625	1.1250	1.1250
多媒体模式	传输功率/dbm	20.750	8.4000	12.925	14.2875	19.6125	0.9125
	BER	0.0179	0.0486	0.035	0.0299	0.0208	0.0833
	吞吐量/Mbps	5.870	5.950	5.8750	6.082	6	6.250

### (3)不同权重下 HPSO-BLDE 算法的性能

为了分析本文算法的健壮性,将低功耗模式、紧急模式和多媒体模式下的权重  $\omega$  分别设置为  $[0.70, 0.20, 0.10]$ ,  $[0.10, 0.70, 0.20]$  和  $[0.10, 0.20, 0.70]$ 。其他参数的设置同 5.1 节,得到的 6 种算法在 3 种模式下的适应度曲线如图 9—图 11 所示。




图 9 改变权重下 6 种算法低功耗模式下的适应度曲线

Fig. 9 Fitness curves of six algorithms in low power mode by changing weight

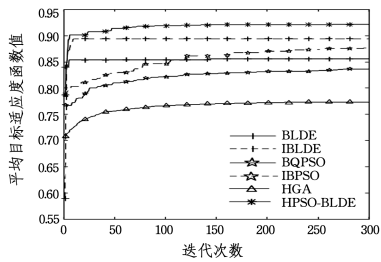


图 10 紧急模式下的适应度曲线

Fig. 10 Fitness curves of six algorithms in emergency mode by changing weight

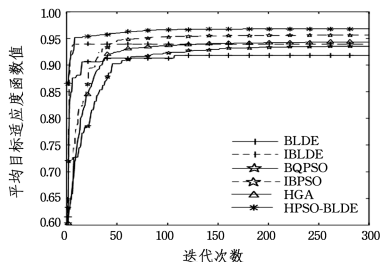


图 11 多媒体模式下的适应度曲线

Fig. 11 Fitness curves of six algorithms in multimedia mode by changing weight

但是易过早熟;IBPSO, HGA 和 BQPSO 算法的收敛速度较慢;在收敛速度和最优值精度上, HPSO-BLDE 仍优于其他 5 种算法,这是由于提出的 HPSO-BLDE 算法采用了 IBPSO 和 IBLDE 的种群融合策略,增加了优秀个体的比例,有效提升了算法性能。

### (4)算法时间复杂度分析

BLDE 算法中主要包括种群初始化、实验解更新和种群更新等过程,其中复杂度主要集中在实验解的更新上。对每个个体的实验解更新一次,需要的复杂度为  $O(D)$ ,当  $N_i$  个个体迭代  $I$  次时,IBLDE 的复杂度为  $C_{px1} = O(IDN_i)$ 。

IBLDE 算法将固定变异策略变成自适应变异策略,相比于 BLDE,仅增加了计算自适应变异概率  $p_o'$  的时间  $O(IN_i)$ ,因此 IBLDE 算法的复杂度为  $C_{px2} = O(IDN_i + IN_i)$ 。

BPSO 算法中主要包括粒子群初始化,计算个体适应度,寻找个体最优解和全局最优解,以及更新粒子速度和位置等步骤,其中复杂度主要集中于粒子群的速度和位置更新步骤。设编码维度为  $D$ ,则对每个粒子更新一次需要的复杂度为  $O(D)$ ,当粒子种群为  $N_i$ ,迭代次数为  $I$  时,IBPSO 的复杂度也为  $C_{px1}$ 。

相比于 BPSO, BQPSO 算法在位置更新公式中增加了计算平均最优位置的时间,该步骤需要增加的复杂度为  $O(IN_i)$ ,因此 BQPSO 算法的复杂度为  $C_{px2}$ 。

相较于 BPSO, IBPSO 的改进之处在于:1)将 Sigmoid 变换函数改为“V”型变换函数,该步骤不增加额外的复杂度;2)改进粒子速度更新公式,该步骤增加的复杂度为  $O(I)$ 。因此,IBPSO 算法的复杂度为  $C_{px3} = O(IDN_i + I)$ 。

HGA 算法相较于传统遗传算法的改进之处在于:在经过染色体选择、交叉和变异后,继续用爬山算法对求得的最优染色体进行优化。其复杂度主要集中于染色体的选择、交叉和变异步骤,该步骤的复杂度为  $O(IDN_i)$ ,因此 HGA 算法的复杂度为  $C_{px1}$ 。

HPSO-BLDE 算法是独立并行运行 IBPSO 和 IBLDE 算法,在间隔固定迭代次数时,种群进行个体交换,其复杂度约为  $2C_{px1}$ 。

由以上分析可知,几种算法的复杂度近似,均为  $O(IDN_i)$ 。

**结束语** 在认知无线电系统中,认知用户需要在不干扰主用户的前提下动态使用频谱空穴,并且根据复杂多变的信道环境实时做出决策,优化传输参数。为了提高利用 BLDE,

由图 9—图 11 可知,IBLDE 虽然提高了全局搜索能力,

BPSO 等算法求解 CDE 问题的收敛速度和收敛精度,IBPSO 算法改进了学习因子和位置更新方式,增强了 BPSO 算法的全局搜索能力;具有自适应变异能力的 IBLDE 算法增强了 BLDE 算法的局部寻优能力;并行运行 IBPSO 和 IBLDE 算法,交叉融合最优解和最差解,得到一种离散的融合粒子群和差分进化(HPSO-BLDE)的认知决策引擎算法。OFDM 多载波系统的仿真结果表明:HPSO-BLDE 算法的寻优能力强,收敛快,准确性高。本文研究的目标函数主要针对物理层,下一步将研究跨层认知决策引擎。

### 参 考 文 献

- [1] LUO Y Y,SUN Z F. Cognitive radio decision engine based on adaptive ant colony optimization[J]. *Computer Science*, 2011, 38(8):253-256. (in Chinese)  
罗云月,孙志峰.基于自适应蚁群优化算法的认知决策引擎[J]. *计算机科学*, 2011, 38(8):253-256.
- [2] YOU X, HE X, HAN X, et al. A novel cross-layer decision engine for cognitive radio based on quick-CQABC algorithm and channel gain information[J]. *Journal of Computational Information Systems*, 2015, 11(14):5227-5242.
- [3] PARASKEVOPOULOS A, DALLAS P I, SIAKAVARA K, et al. Cognitive radio engine design for IoT using real-coded biogeography-based optimization and fuzzy decision making[J]. *Wireless Personal Communications*, 2017, 97(2):1-21.
- [4] CLANCY T C. Dynamic spectrum access using the interference temperature model[J]. *Annals of Telecommunications-Annales Des Télécommunications*, 2009, 64(7-8):573-592.
- [5] BKASSINY M, LI Y, JAYAWEEERA S K. A survey on machine-learning techniques in cognitive radios[J]. *IEEE Communications Surveys & Tutorials*, 2013, 15(3):1136-1159.
- [6] DONG X, LI Y, WU C, et al. A learner based on neural network for cognitive radio[C]//*IEEE International Conference on Communication Technology*. IEEE, Nanjing, China, 2010:893-896.
- [7] YIN L, YIN S X, HONG W, et al. Spectrum behavior learning in Cognitive Radio based on artificial neural network[C]//*2011-MILCOM, 2011 Military Communications Conference*. IEEE, Baltimore, MD, USA, 2012.
- [8] RIESER C J. Biologically inspired cognitive radio engine model utilizing distributed genetic algorithms for secure and robust wireless communications and networking[M]. Virginia Polytechnic Institute and State University Press, 2004.
- [9] ZHAO Z J, ZHENG S L, SHANG J N, et al. A study of cognitive radio decision engine based on quantum genetic algorithm[J]. *Acta Physica Sinica*, 2007, 56(11):6760-6766. (in Chinese)  
赵知劲,郑仕链,尚俊娜,等.基于量子遗传算法的认知无线电决策引擎研究[J]. *物理学报*, 2007, 56(11):6760-6766.
- [10] ZHAO Z J, XU S Y, ZHENG S L, et al. Cognitive radio decision engine based on binary particle swarm optimization[J]. *Acta Physica Sinica*, 2009, 58(7):5118-5125. (in Chinese)  
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.
- [11] XU H, ZHOU Z. Hill-climbing genetic algorithm optimization in cognitive radio decision engine[C]//*IEEE International Conference on Communication Technology*. IEEE, Guilin, China, 2014:115-119.
- [12] ZHANG J, ZHOU Z, GAO W, et al. Cognitive radio adaptation decision engine based on binary quantum-behaved particle swarm optimization[C]//*International ICST Conference on Communications and Networking in China*. IEEE, Harbin, China, 2011:221-225.
- [13] ISLAM M J, LI X, MEI Y. A Time-varying transfer function for balancing the exploration and exploitation ability of a binary PSO[J]. *Applied Soft Computing*, 2017, 20(5):1-43.
- [14] SARHANI M, AFIA A E, FAIZI R, et al. Facing the feature selection problem with a binary PSO-GSA Approach[M]//*Recent Developments in Metaheuristics*. Springer International Publishing, Rabat, Morocco, 2018.
- [15] CHEN Y, XIE W, ZOU X. A binary different evolution algorithm learning from explored solutions[J]. *Neurocomputing*, 2015, 149:138-1047.
- [16] YOU X, HE X, HAN X. A novel solution to the cognitive radio decision engine based on improved multi-objective artificial bee colony algorithm and fuzzy reasoning[J]. *Intelligent Automation & Soft Computing*, 2017, 23(4):1-9.
- [17] KAUR K, RATTAN M, PATTERH M S. Biogeography-based optimisation of Cognitive Radio system[J]. *International Journal of Electronics*, 2014, 101(1):24-36.
- [18] RATNAWEERA A, HALGAMUGE S K, WATSON H C. Self-organizing hierarchical particle swarm optimizer with time-varying acceleration coefficients[J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8(3):240-255.
- [19] CHENG R, JIN Y. A competitive swarm optimizer for large scale optimization[J]. *IEEE Transactions on Cybernetics*, 2015, 45(2):191.