

一种基于认知引擎的 t 分布变异萤火虫算法

刘俊彤 王可人 冯 辉 刘文涛

(电子工程学院 402 教研室, 合肥, 230037)

摘 要: 针对认知引擎中智能优化的问题, 提出了一种基于 t 分布变异萤火虫算法的认知无线电决策引擎技术, 分析了萤火虫算法的仿生原理, 从数学角度对算法实现优化过程进行了定义, 并设计了一种基于 t 分布随机扰动的变异方案。最后, 在多载波环境下对该算法进行了仿真实验, 结果表明与普通基于遗传算法的认知引擎相比, 该算法收敛速度快且具有较高的目标函数值, 并且在加入 t 分布变异之后, 算法的全局寻优能力进一步加强。

关键词: 认知无线电; 萤火虫算法; 认知引擎; t 分布变异

中图分类号: TN92 **文献标志码:** A

GSO Algorithm With t -distribution Mutation for Cognitive Engine

Liu Juntong, Wang Keren, Feng Hui, Liu Wentao

(Laboratory 402 Electronic Engineering Institute, Hefei, 230037, China)

Abstract: Considering the problem of cognitive radio intelligence optimization, a scheme of cognitive engine is proposed based on the glowworm swarm optimization with t distribution mutation. The bionic principle of firefly algorithm is analyzed. The optimization mechanism is defined by mathematics and a mutation plan is also designed with t distribution. Finally, the simulations are performed in the multi-carrier system. The results show that the algorithm has higher convergence speed and larger objective function value than the basic GA algorithm. Furthermore, the improved algorithm with t distribution mutation has the higher capability of the global optimization than that of the basic GSO algorithm.

Key words: cognitive radio; glowworm swarm optimization (GSO); cognitive engine; t distribution mutation

引 言

认知无线电(Cognitive radio, CR)^[1]通过感知外界环境变化, 利用人工智能技术进行环境学习, 有目的地实时改变某些操作参数, 以实现智能通信, 有效提高频谱利用率^[2]。认知引擎(Cognitive engine, CE)是认知无线电的智能核心, CE根据频谱感知获得的当前可用信道信息, 结合业务需求和制度限定等, 执行多目标优化, 给出一种配置策略来完成多条件约束的最佳工作参数配置。典型的多目标优化算法有遗传算法、粒子群算法、蚁群算法、模拟退火算法和神经网络等^[3]。尽管对智能优化算法的研究很

多,但仍存在诸如收敛速度慢、搜索效率低以及容易陷入局部最优和早熟收敛等问题,因此有必要进一步研究更加高效、智能的优化算法。人工萤火虫群优化算法(Glowworm swarm optimization, GSO)是由 Krishnanand 等人于 2005 年模拟自然界萤火虫求偶或觅食行为而提出的一种新的群智能算法^[4]。该算法近年来在计算智能领域引起了人们极大的关注并逐渐成为该领域一个新的研究热点,并且已经成功应用于传感器的噪声测试和模拟机器人等,而其在认知引擎当中的应用尚未被任何文献提及。GSO 的优势在于捕捉极值域速度快、捕捉效率高以及具有较强的通用性等优点,但同时也存在着容易过早陷入局部最优和收敛成功率低等缺点^[5]。本文提出基于 t 分布变异萤火虫算法(Glowworm swarm optimization with t distribution mutation, TDMGSO)的认知无线电决策引擎技术(Glowworm swarm optimization with t distribution mutation-cognitive engine, TDMGSO-CE),并在多载波系统中对此 CR 决策引擎算法进行了仿真分析。

1 人工萤火虫群优化算法

1.1 基本人工萤火虫群优化算法

在人工萤火虫算法中,萤火虫通过自身亮度和吸引度来彼此吸引^[6]。每一只萤火虫随机的散步在二维空间中,萤火虫带着荧光,荧光照亮的区域称之为决策域,荧光的大小与萤火虫所处的位置有关。萤火虫在各自照亮的区域中寻找邻居,愈亮的邻居拥有愈高的吸引力吸引此萤火虫往这个方向移动,此外,决策域范围的大小会受邻居数量影响,当邻居密度愈低,萤火虫的决策半径会加大以利于寻找更多的邻居,当邻居密度愈高,它的决策半径则会缩小。最后,大部分的萤火虫会聚集在多个位置上,即达到极值点。基本 GSO 算法流程图如图 1 所示。




图 1 基本萤火虫算法流程图

Fig. 1 Flow chart of original GSO algorithm

步骤 1:初始化萤火虫个数 n , 每个萤火虫荧光素 l_0 , 决策域 γ_0 , 荧光素消失率 α , 荧光素更新率 β , 动态决策域更新率 γ , 初始化步 m , 迭代次数 T 。

步骤 2:(1) 更新萤火虫荧光素 $l_i(t)$

$$l_i(t) = (1 - \alpha) l_i(t - 1) + \beta J(x_i(t)) \quad (1)$$

式中: $l_i(t)$ 表示萤火虫 i 在 t 时刻的荧光素, $J(x_i(t))$ 表示萤火虫 i 在 t 时刻的目标函数值。

(2) 判断下一代路径移动方向的概率。

萤火虫在二维解空间中移动,采用基于一定策略的随机选择机制。萤火虫 i 向萤火虫 j 运动,需要满足两个条件:

(a) 萤火虫 j 在萤火虫 i 的决策域内; (b) 萤火虫 j 的荧光素大于萤火虫 i 的荧光素。满足上述两个条件 j 的集合设为 $N_i(t)$

$$N_i(t) = \{j; d_{ij}(t) < r_i(t); l_j(t) > l_i(t)\} \quad (2)$$

式中: $d_{ij}(t)$ 表示萤火虫 i 和萤火虫 j 在 t 时刻的距离; $r_i(t)$ 表示萤火虫 i 在 t 时刻的决策域。那么萤火虫到的路径移动概率 p_{ij} 可表示为

$$p_{ij} = \frac{l_j(t) - l_i(t)}{\sum_{k \in N_i(t)} l_k(t) - l_i(t)} \quad (3)$$

步骤 3:

(1) 更新萤火虫位置 $x_i(t+1)$

$$x_i(t+1) = x_i(t) + m \left(\frac{x_j(t) - x_i(t)}{x_j(t) - x_i(t)} \right) \quad (4)$$

(2) 更新决策域 $r_i(t+1)$

$$r_i(t+1) = \min\{r_{\max}, \max\{0, r_i(t) + \gamma(n_i - |N_i(t)|)\}\} \quad (5)$$

式中: n_i 是控制决策域内满足移动条件萤火虫个数的参数; $|N_i(t)|$ 是决策域内满足移动条件萤火虫的个数。

步骤 4:判断是否达到给定精度或迭代次数,若满足则停止运算,否则 $t=t+1$ 并转至步骤 2。

1.2 基于 t 分布变异的人工萤火虫群优化算法

与遗传算法、粒子群算法和神经网络算法等一些智能寻优算法类似,萤火虫算法也存在全局探索能力与局部开发之间的矛盾。通过改变某些参数可以提高算法的局部寻优能力,但是会导致算法全局探索能力的下降。为解决这类问题,国内外学者做了诸多努力来寻求更好的改进算法。文献[7]提出了一种新颖的加速进化算法,引入逆向学习策略,并将其用于群体初始化和跳出局部最优解。文献[8]提出了一种新的混沌粒子群嵌入优化算法,充分利用混沌运动的随机性、遍历性克服了粒子群优化算法容易陷入局部最优的缺点。文献[9]提出了一种基于高斯变异的 GSO 群优化算法,引入高斯变异算子,提高了算法局部收敛速度和收敛精度。

通过分析比较,一些学者提出的改进算法,笔者发现:柯西变异的全局探索能力较强,能够有效地保持种群的多样性;而高斯变异的局部开发能力较强,可以保证进化后期的收敛速度。为综合两者的优点,本文提出一种基于 t 分布变异的人工萤火虫群优化算法。 $t(n)$ 分布又称学生分布,含有参数自由度 n ,当 $n=1$ 时, $t(1)$ 服从柯西分布;当 $n \rightarrow \infty$ 时, $t(\infty)$ 服从标准高斯分布,一般 n 取值较大(>50)时即可认为 t 分布近似服从标准高斯分布。因此可以通过调节参数 n ,使算法前期具有良好的全局探索能力,而在进化后期又具备较优的局部开发性能,以此来提高算法的整体寻优能力。 t 分布变异萤火虫算法就是在原有的个体上附加一个服从 t 分布的随机扰动,即

$$X_i(t) = X_i(t) + k * X_i(t) * t(n) \quad (6)$$

t 分布变异首先用历史最优萤火虫替换当前最差萤火虫形成中间种群,然后对中间种群的萤火虫按式(6)变异,并计算当前萤火虫的目标函数值,而后继续执行 GSO 基本寻优运算。如此充分利用了当前个体的已知信息进行扰动,增加种群状态的多样性,并引入最佳保留,有利于算法进行全局搜索,同时也提高了算法的搜索速度。

2 基于 TDMGSO 的 CR 决策引擎

认知引擎的基本任务是通过自适应地调整无线电系统的可调参数,最优化通信系统自身参数以达到适应环境变化和满足用户需求之目的^[10]。图 2 给出了 TDMGSO-CE 的基本原理。



图 2 TDMGSO 认知引擎原理

Fig. 2 Principle diagram of TDMGSO cognitive engine

假设认知无线电的可调整参数集为 $X = \{x_1, x_2, \dots, x_n\}$, 其中 n 为参数的个数, 具体的可调参数要根据系统的特性选取, 如中心频率、发射功率、调制方式、频带宽度和符号速率等。因同时受到外部环境和用户要求的制约, CR 决策引擎要对多个目标函数进行优化, 假设 CR 系统中待优化的目标函数集为 $f = \{f_1, f_2, \dots, f_m\}$, m 为目标函数的个数, 如频带利用率、平均发射功率、数据速率和误码率等均可作为待优化的目标函数。

为检验该认知引擎的性能, 将所设计的 TDMGSO-CE 应用于一个具体的多载波 CR 系统参数调整问题中。在该多载波 CR 系统中, 设子载波数为 32, 系统可调节的参数包括调制方式和发射功率。发射功率共有 64 种可能, 范围设置为 $0 \sim 31.5$ dbm, 步进为 0.5 dbm, 调制方式可选 BPSK, QPSK, 16QAM 和 64QAM。因此, 此多载波 CR 系统整体的寻优空间为 $(64 \times 4)^{32}$, 数量级为 10^{77} 。假设此 CR 系统要完成的优化目标包括最小化发射功率、最小化误码率和最大化数据率, 对各目标函数进行无量纲归一化处理, 则归一化目标函数可表示为

$$f_1 = 1 - \frac{\bar{P}}{P_{\max}} \quad (7)$$

$$f_2 = 1 - \frac{\lg(0.5)}{\lg(P_{be})} \quad (8)$$

$$f_3 = \frac{\frac{1}{N} \sum_{i=0}^N \log_2 M_i - \log_2 M_{\min}}{\log_2 M_{\max} - \log_2 M_{\min}} \quad (9)$$

式中: N 为载波数, \bar{P} 为发射功率平均值, P_{\max} 为最大可能发射功率, \bar{P}_{be} 为 N 个信道误码率的平均值, M_i 为第 i 个子信道调制进制数, M_{\max} 为最大调制进制数, M_{\min} 为最小调制进制数。假设信道类型为 AWGN 信道, 噪声功率 N_0 为 0dBm, 符号速率为 1Msps。比特错误率计算公式参考文献[11]。由于不同外部环境和用户需求, 各目标函数的重要性也有所不同, 因此给各目标函数设置一个可调节的权重系数, 可将 3 个目标函数归为如下单目标函数

$$f = \omega_1 f_1 + \omega_2 f_2 + \omega_3 f_3 \quad (10)$$

其中 $\omega_1 + \omega_2 + \omega_3 = 1$, 该 CR 系统认知引擎要实现的功能即为调整信号的调制方式和发射功率, 以实现目标函数 f 值的最大化, 本文使用 TDMGSO 实现 CR 决策引擎, 将式(10)所示的目标函数作为衡量群体优化过程中个体的适应度函数, 寻求满足当前目标函数需求的参数配置。

3 仿真及分析

仿真实验首先对采用 GSO 算法和 GA 算法的 CR 决策引擎进行比较, 两种算法的初始种群均采用二进制编码方式, 种群中每个初始个体包含 32 路子载波, 每个子载波包含有 4 种调制方式信息和 64 种调制功率信息, 进而可用 8 位二进制码对每一路子载波进行编码, 因此包含有 32 路子载波的初始个体的比特位数为 256。每个子载波分配一个随机数 μ ($\mu \in [0, 1]$), 用来表示该载波对应的信道衰落因子, 以动态地模拟信道的变化。基本 GA 算法的参数设置如下: 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 1 000。基本 GSO 算法参数设置如下: 初始化萤火虫个数 $n = 50$, 初始化荧光素 l_0 为 5, 决策域 r_0 由目标函数解空间的标准欧几里德范数确定, 即 $r_0 = 2/3$ 解空间, 荧光素消失率 $\alpha = 0.4$, 荧光素更新率 $\beta = 0.6$, 动态决策域更新率 $\gamma = 0.06$, 初始化步长 $m = 0.2$, 迭代次数 $T = 1 000$ 。在对 GSO 算法进行变异操作时, 取 $n=1$ 时, 变异类型为柯西变异, 取 $n=100$ 时, 变异类型为高斯变异。仿真模式设置为低功耗模式, 权重参数的取值为 $\omega_1 = 0.6, \omega_2 = 0.2, \omega_3 = 0.2$, 改变权重参数来调整系统工作模式并不影响算法对参数优化的能力, 因此本文首先对低功耗模式进行分析, 讨论算法的寻优能力, 进而找出一种较优的算法, 对其在不同工作模式下的参数配置进行仿真分析。

由图 3 可以看出,在低功耗模式下各种进化算法的性能表现:GA 容易出现早熟现象,性能相对较差;GSO 算法继承了该算法捕捉极值域速度快、捕捉效率高的优点,搜索速度和整体寻优能力均优于 GA 算法;高斯变异 GSO 中期收敛速度较快,且寻优能力较基本 GSO 算法有所提高;柯西变异 GSO 收敛速度较慢,但全局搜索能力强。

图 4 给出了带柯西变异的 GSO 认知引擎分别对 4 种模式的参数调整结果。图 4(a)中,载波的平均发射功率为 0.296 875 dBm,实现了低功耗的要求。图 4(b)中,载波平均发射功率为 14.156 25 dBm,调制方式大多为 BPSK,平均误码率约为 10^{-3} ,实现了低误码率的要求。图 4(c)中,载波平均发射功率为 0.656 25 dBm,调制方式均为 64QAM,实现了数据率最大化的主要目标。图 4(d)中,调制方式大多为 64QAM,平均发射功率为 0.906 25 dBm,虽然此模式为均衡模式,各个目标函数享有同样的权值,但目标函数内部存在关联,因此同时实现发射功率最小和数据率最大(0 dBm,64QAM)的个体适应度高。




图 3 4 种算法性能比较

Fig. 3 Performance comparison of four kinds of algorithms

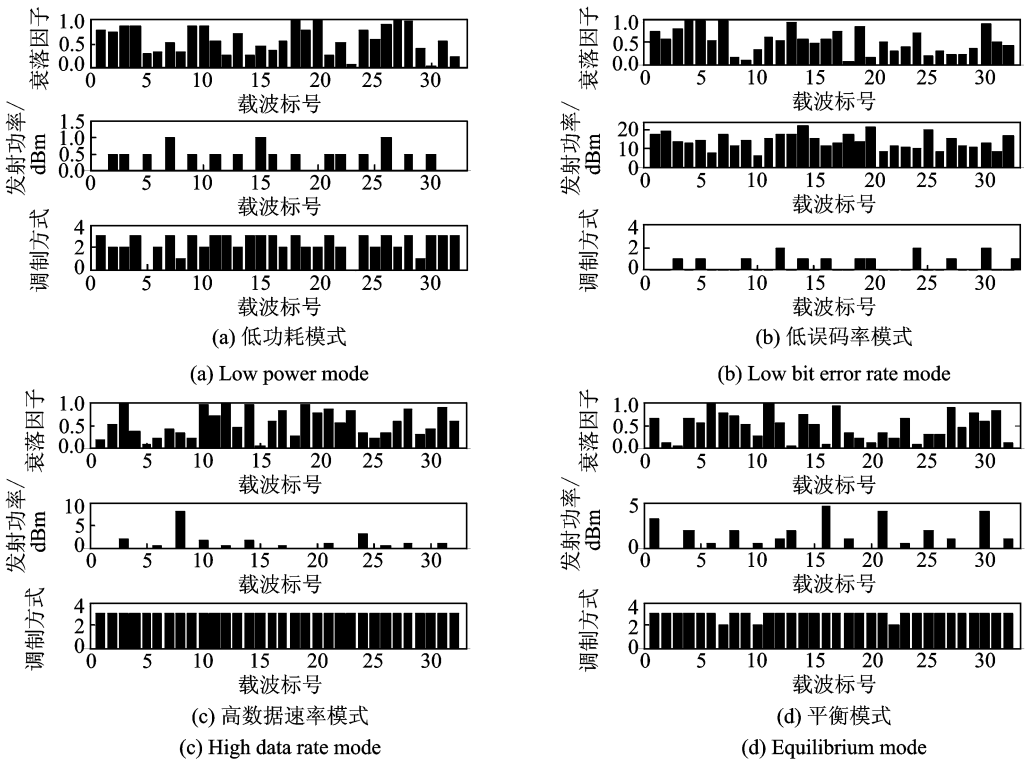


图 4 带柯西变异的 GSO 参数调整结果

Fig. 4 Parameter adjustment results of GSO with Cauchy mutation

4 结束语

本文提出基于 GSO 的 CR 决策引擎,实现了 CR 多参数优化的功能。仿真结果表明,采用 GSO 的

CR 决策引擎在搜索速度和搜索效率方面均优于基本 GA 算法,并且在加入 t 分布变异之后,GSO 算法的寻优能力得到了进一步的提升。通过对多载波信号参数优化问题的仿真实验,表明了 GSO 算法在认知引擎中多参数优化的可行性和有效性,具有良好的运用前景。引入 t 分布变异,提高了算法的寻优能力,但整体复杂度也随之增加,同时兼顾精度和复杂度要求的改进方法还有待于进一步研究。

参考文献:

- [1] Wang Beibei, Liu K J R. Advances in cognitive radio networks: A survey[J]. *IEEE Journal of Selected Topics in Signal Processing*, 2011, 5(1):5-23.
- [2] 胡晓宁, 作国锋, 胡捍英. 认知无线电系统协作频谱感知机制优化[J]. *数据采集与处理*, 2011, 37(18):67-70.
Hu Xiaoning, Wu Guofeng, Hu Hanying. Optimization for cooperative spectrum sensing mechanism in cognitive radio system[J]. *Journal of Data Acquisition and Processing*, 2011, 37(18):67-70.
- [3] He A, Bae K K, Newman T R, et al. A survey of artificial intelligence for cognitive radios[J]. *IEEE Transactions on Vehicular Technology*, 2005, 59(4):1578-1592.
- [4] Krishnanand K N, Ghose D. Glowworm swarm optimization: A new method for optimizing multi-modal functions [J]. *International Journal of Computational Intelligence Studies*, 2009, 1(1):93-119.
- [5] 祝华正, 何登旭. 一种小规模多种群萤火虫群优化算法[J]. *计算机工程与应用*, 2011, 47(23):48-50.
Zhu Huazheng, He Dengxu. Small-scale and multi-population glowworm swarm optimization algorithm[J]. *Computer Engineering and Applications*, 2011, 47(23):48-50.
- [6] Yang Xinshe, Deb S. Eagle strategy using levy walk and firefly algorithms for stochastic optimization [J]. *Studies in Computational Intelligence*, 2010, 284:101-111.
- [7] Rahnamayan S, Tizhoosh H R, Salama M M A. Opposition-based differential evolution[J]. *IEEE Computational Intelligence Society*, 2008, 12(1):64-79.
- [8] 华容. 一种混沌粒子群嵌入优化算法及其仿真[J]. *数据采集与处理*, 2010, 25(1):102-106.
Hua Rong. Chaos embedded particle swarm optimization algorithm and its simulation[J]. *Journal of Data Acquisition and Processing*, 2010, 25(1):102-106.
- [9] 莫愿斌, 刘付永, 张宇楠. 带高斯变异的人工萤火虫优化算法[J]. *计算机应用研究*, 2013, 30(1):121-124.
Mo Yuanbin, Liu Fuyong, Zhang Yunan. Artificial glowworm swarm optimization algorithm with Gauss mutation[J]. *Application Research of Computers*, 2013, 30(1):121-124.
- [10] 赵知劲, 郑仕链, 尚俊娜. 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.
Zhao Zhijing, Zheng Shilian, Shang Junna. A study of cognitive radio decision engine based on quantum genetic algorithm [J]. *Chinese Journal of Physics*, 2007, 56(11):6760-6766.
- [11] John G P. *Digital communication*[M]. Fourth edition. Beijing: Publishing House of Electronics Industry, 2006. 254-282.

作者简介:




刘俊彤 (1990-), 男, 硕士生, 研究方向: 智能算法、认知无线电, E-mail: liujun-tong61@126.com。



王可人 (1957-), 男, 教授, 研究方向: 无线通信、信号处理, E-mail: wangker-en0510@sina.com。



冯辉 (1978-), 男, 讲师, 研究方向: 无线通信、智能信号处理, E-mail: fenghui@sina.com。



刘文涛 (1991-), 男, 硕士生, 研究方向: 认知无线通信、信号识别; E-mail: 784848973@qq.com。