

# 基于逻辑运算的离散人工蜂群算法

朱冰莲<sup>1</sup>, 朱方方<sup>1</sup>, 苏红宏<sup>2</sup>, 石 锐<sup>1</sup>, 段青言<sup>1</sup>, 李 晶<sup>1,3</sup>

(1. 重庆大学通信工程学院, 重庆 400044; 2. 重庆大学航天航空学院, 重庆 400044; 3. 酒泉卫星发射中心, 甘肃酒泉 732750)

**摘 要:** 针对当前离散人工蜂群算法冗余度高、探索性能差、容易陷入早熟等问题, 提出一种基于逻辑运算的离散人工蜂群算法. 通过引入一系列的逻辑运算, 一方面解决了当前离散人工蜂群算法中存在的解不更新问题, 提高了算法的搜索效率; 另一方面, 很好地保证了搜索过程的中间解和最终解都封闭在原离散封闭集内, 有效地避开了实数集与离散集间的映射问题. 基于逻辑运算的离散人工蜂群算法计算简单、易于硬件实现, 在基于图论着色理论的频谱分配模型上进行验证, 取得了明显优于离散人工蜂群算法的收敛速度和优化性能.

**关键词:** 人工蜂群算法; 离散优化; 逻辑运算; 离散封闭集; 频谱分配

**中图分类号:** TP18      **文献标识码:** A      **文章编号:** 0372-2112 (2015)11-2161-06

**电子学报 URL:** <http://www.ejournal.org.cn>      **DOI:** 10.3969/j.issn.0372-2112.2015.11.004

## Discrete Artificial Bee Colony Algorithm Based on Logic Operation

ZHU Bing-lian<sup>1</sup>, ZHU Fang-fang<sup>1</sup>, SU Hong-hong<sup>2</sup>, SHI Rui<sup>1</sup>, DUAN Qing-yan<sup>1</sup>, LI Jing<sup>1,3</sup>

(1. Department of Communication Engineering, Chongqing University, Chongqing 400044, China;

2. Department of Aerospace Engineering, Chongqing University, Chongqing 400044, China;

3. Jiuquan Satellite Launch Center, Jiuquan, Gansu 732750, China)

**Abstract:** A discrete artificial bee colony algorithm based on logic operators was proposed to avoid some defects such as high redundancy, poor exploration and trapping into a local optimization etc. By introducing a series of logical operators, the problem that solutions don't update had been solved, so the solution searching efficiency was improved. Moreover, the intermediate and final solution is enclosed in the discrete closed set, avoiding the problem that mapping the real number to discrete set. The complexity of the discrete artificial bee colony algorithm based on logic operation is lower, and it is easily implemented in hardware. The proposed algorithm is validated on the spectrum allocation model based on graph coloring, obtaining a faster convergence speed and a higher optimized performance.

**Key words:** artificial bee colony (ABC); discrete optimization; logic operation; discrete closed set; spectrum allocation

## 1 引言

工程优化、VLSI 设计、经济决策、资源分配等约束优化问题<sup>[1]</sup>往往规模大、复杂度高, 采用枚举求解周期长, 而传统优化方法又极易陷入局优. 遗传算法、差分进化算法、粒子群算法、蚁群算法等群智能算法<sup>[2]</sup>的出现很好地解决了这类问题, 且具有较高稳定性<sup>[3]</sup>. 近年, Karaboga 模拟蜂群的采蜜行为提出了人工蜂群算法 (Artificial Bee Colony, ABC)<sup>[4]</sup>, 该算法参数设置简单, 寻优精度高、性能优越<sup>[5,6]</sup>, 被广泛应用于各类工程问题的优化<sup>[7]</sup>. 但这类算法大多基于连续域提出, 应用于离散优化, 不能保证最终解和中间解封闭在离散集中. 为了解

决这一问题, 大量的离散方法被提出, 其中 SF (Sigmoid Function) 法是一种比较常用的离散方法<sup>[8]</sup>, 该方法利用 Sigmoid 函数将任意  $(-\infty, +\infty)$  之间的实数映射到  $(0, 1)$  之间, 再以一定概率变换为 0 或 1. 二进制粒子群算法 (Binary Particle Swarm Optimization, BPSO)<sup>[9]</sup>、二进制差分进化算法 (Binary Differential Evolution, BDE)<sup>[10]</sup> 和离散人工蜂群算法 (Discrete Artificial Bee Colony, DABC)<sup>[11]</sup> 均是基于这种方法提出的.

DABC 算法是 ABC 算法在离散域的有效拓展, 取得了优于其它算法的优化性能<sup>[11]</sup>. 但 ABC 算法采用单维更新的种群更新策略<sup>[12]</sup>, 该策略决定了基于 SF 法的 DABC 算法必将存在解不更新的缺陷, 使得算法的开发

能力和探索能力<sup>[13]</sup>大大削弱,优化性能急剧下降.这种情况在连续域几乎不存在,但在解空间相对较小的离散领域却是大概率事件,尤其是二进制优化问题.鉴于以上考虑,本文针对解空间有限的离散优化问题提出了离散封闭集内基于逻辑运算的离散人工蜂群算法(以下简称 LDABC),算法主要采用逻辑运算,从根本上避免了中间解和最终解跳出原离散集.另一方面,针对当前 ABC 和 DABC 算法更新维度随机选取、缺乏导向性的问题,建立种群个体间的交流学习模型,根据种群个体间的差异度确定更新维度,更好地提高了算法的开发性能,加快了算法的收敛速度.最后,本文在基于图论着色理论的频谱分配模型上进行了验证,该模型已被证明是一种典型的 NP-hard 优化问题<sup>[14]</sup>.仿真实验表明,本文提出的 LDABC 算法能够获得明显优于 DABC 算法的寻优性能.

## 2 DABC 算法分析

### 2.1 ABC 算法简介

在 ABC 算法中存在三种类型的蜜蜂群体:雇佣蜂、守望蜂、侦察蜂.雇佣蜂负责探索蜜源质量较高的食物源并通过蜜蜂内部的信息传递方式——摇摆舞,将蜜源信息传递给守望蜂,守望蜂则根据雇佣蜂传递的信息挑选蜜源质量较高的食物源作进一步邻域开发.经过守望蜂与雇佣蜂多次开发,蜜源质量仍得不到提升的食物源将被抛弃,对应的食物源处出现侦察蜂,侦察蜂在搜索范围内随机寻找新的食物源.

假定种群的大小为  $SN$ ,食物源分布在一个  $D$  维的空间里,则雇佣蜂、守望蜂、食物源的数量均为  $SN$ ,且雇佣蜂与食物源存在一一对应的关系,每个食物源对应优化问题的一个解.以  $\mathbf{X}_i^t$  代表第  $i$  个食物源的当前位置,则

$$\mathbf{X}_i^t = (x_{i1}, x_{i2}, \dots, x_{iD}) \in \mathbf{R}^D \quad (1)$$

雇佣蜂和守望蜂均采用单维更新的邻域搜索策略,即从  $D$  维参数中随机抽取一个维度  $j$  作更新,而其它维度的取值保持不变,如式(2)所示.

$$x_{ij}^{t+1} = x_{ij}^t + \varphi_{ij}(x_{ij}^t - x_{kj}^t) \quad (2)$$

式中,  $x_{ij}^t$  代表当前种群中第  $i$  个食物源的第  $j$  维坐标,  $k$  是种群中随机抽取的与  $i$  不同的食物源 ( $k \neq i$ ),  $\varphi_{ij}$  为  $(0,1)$  之间的随机数.

ABC 算法中,守望蜂根据雇佣蜂传递的各食物源的蜜源质量信息,选择优质食物源作进一步邻域开发,文献[15]提供了一种计算各食物源被选中概率的方法,如式(3)所示:

$$p_i = 0.9 \times \frac{f_i}{f_{\text{best}}} + 0.1 \quad (3)$$

式中,  $p_i$  表示第  $i$  个食物源被选中的概率;  $f_i$  表示第  $i$  个食物源的蜜源质量;  $f_{\text{best}}$  表示种群中最优食物源的蜜源质量.

当某一食物源被侦察蜂和雇佣蜂最多  $\text{limit}$  次开发后,其蜜源质量仍得不到提升,则相应的食物源出现侦察蜂,以一定策略随机地寻找新的食物源,策略如式(4)所示:

$$x_{ij} = x_{ij}^{\text{min}} + \varphi(x_{ij}^{\text{max}} - x_{ij}^{\text{min}}) \quad (4)$$

式中,  $x_{ij}^{\text{min}}$  表示解第  $j$  维参数的下限值;  $x_{ij}^{\text{max}}$  表示解第  $j$  维参数的上限值;  $\varphi$  为  $(0,1)$  之间的随机数.

### 2.2 SF 离散法的 DABC 算法

经过式(2)的新食物源位置  $\mathbf{X}_i^{t+1}$  的第  $j$  维参数  $x_{ij}^{t+1}$  是一个连续实数,但在二进制离散优化问题中,参数属于二进制集  $\{0,1\}$ .文献[11]采用 SF 法将其映射回二进制集  $\{0,1\}$ ,如公式(5)所示:

$$x_{ij} = \begin{cases} 1, & \text{rand}(1) < \text{sig}(x_{ij}) \\ 0, & \text{rand}(1) \geq \text{sig}(x_{ij}) \end{cases} \quad (5)$$

其中,  $\text{sig}(x_{ij})$  为 Sigmoid 函数,如式(6):

$$\text{sig}(x_{ij}) = \frac{1}{1 + \exp(-x_{ij})} \quad (6)$$

### 2.3 DABC 算法分析

基于 SF 离散法的 DABC 算法能够实现 ABC 算法向二进制优化问题的拓展,这从原理上看没有任何问题.但实际上 SF 离散法在 DABC 算法中是冗余而不必要的.原因如下:和 ABC 算法一样,DABC 算法也是单维更新,即一次更新中仅有一个维度的取值可能变化.在二进制优化问题中,  $\mathbf{X} \in \{0,1\}^D$ ,即解  $\mathbf{X}$  中每一维参数的值非 0 即 1.更新维度一旦确定,新解只有两种情况:该维度上的取值要么是对旧解取反,要么不变.而当该维度取值不变时,说明解并没有得到更新,故没有必要进行式(2)所示的连续域处理,更不需要通过式(5)和(6)即采用 SF 离散法映射回  $\{0,1\}$  二进制集,解的更新仅需对该维度的值取反即可.如果采用 SF 离散法,会导致大量的解不更新现象出现,作者在基于图论着色理论的频谱分配模型<sup>[14,16]</sup>上进行 1000 次迭代仿真实验,结果显示解不更新率达到 56.26%.

## 3 基于逻辑运算的离散人工蜂群算法

二进制优化问题是离散优化问题中的重要分支<sup>[8]</sup>,也存在很多共通之处.本文提出一种适用于一般离散优化问题的 LDABC 算法框架,并对其在二进制优化问题中的具体形式进行了详细介绍.与 DABC 算法相比,LDABC 算法有效地避免了解不更新,同时引入了种群个体间的学习交流模型,具有更强的开发、探索性能.

### 3.1 种群初始化

初始种群的优劣直接关系算法的收敛速度<sup>[5]</sup>. 对于先验知识丰富的问题, 初始解应尽量分布在最优解附近; 对于先验知识匮乏的问题, 初始解分布应尽可能均匀.

对于一般  $n$  值有限离散集  $D$  维优化问题, 定义  $n$  值有限离散集如式(7):

$$S = \{S_1, S_2, \dots, S_n\} \quad (7)$$

式中,  $S_i$  为离散集内元素, 其取值依具体问题不同而不同.

连续优化问题解的一般形式如式(1), 对于离散优化问题, 解的一般形式表示如式(8):

$$X_i = (x_{i1}, x_{i2}, \dots, x_{id}) \in S^D \quad (8)$$

式中,  $X_i$  为  $S$  内元素构成的  $D$  维空间内的向量.

基于以上定义, 初始解生成的一般公式可表示如式(9):

$$X_i = RAND(D; S, P(S)) \quad (9)$$

式中,  $P(S) = \{P(S_1), P(S_2), \dots, P(S_n) \mid \sum_{i=1}^n P(S_i) = 1\}$ ,  $P(S_i)$  表示  $S_i$  被选中为解某一维参数值的概率.  $RAND$  为随机生成操作符, 表示依次以概率  $P(S)$  从  $S$  抽取元素生成一个  $D$  维行向量.

对应于二进制优化问题, 具体的  $S$  集、初始解的生成公式如式(10)(11):

$$S = \{0, 1\} \quad (10)$$

$$X_i = RAND(D; \{0, 1\}, \{1-p, p\}) \quad (11)$$

式中,  $p$  为向量元素取 1 的概率, 式(11)表示生成一个由 0、1 组成的  $D$  维向量.

### 3.2 邻域搜索策略

ABC 算法采用高精度的单维更新, 即雇佣蜂与守望蜂改变单个维度上的参数值进行邻域搜索. 对于一般  $n$  值离散优化问题, 某一维解的新解可能有  $n-1$  种不同情况, 需要以一定策略从其它  $n-1$  个离散值中选择一个, 即:

$$x_{ij}^{t+1} = N RAND(S, x_{ij}^t) \quad (12)$$

式中,  $N RAND$  表示以一定概率选择  $S$  中与当前  $x_{ij}^t$  不同的元素作为第  $j$  维的值, 若无先验知识可随机选择.

对于二进制优化问题, 如前所述, 简单的取反操作即是最优策略. 它既保证了每一次更新中新解与旧解的差异, 又摒弃了 SF 法带来的复杂指数运算, 更利于硬件实现. 但更新参数维度随机选取, 缺乏导向性, 忽略了种群个体间存在的相互交流学习的的能力, 算法的开发性能弱. 为此, 本算法进一步引入海明距离, 建立群间学习模型, 用海明距离来表征当前解与随机选取的种群中的另一解之间的差异度, 在存在差异的维度

上选取更新维度.

差异度向量的确定公式如式(13):

$$d = COMPARE(X_i, X_k) \quad (13)$$

式中,  $d$  为  $X_i$  与  $X_k$  ( $k \neq i$ ) 的差异度向量, 与  $X_i$  维数相同,  $d$  中值为 1 的维度, 代表该维度  $X_i$  与  $X_k$  的值不同;  $COMPARE$  为比较操作符, 在某一维上不同则返回 1, 相同则返回 0.

差异度值大小计算公式如式(14):

$$l = \sum_{i=1}^D d_i \quad (14)$$

式中,  $l$  为差异度值, 表示  $d$  中元素 1 的个数.

由公式(13)、(14)即可得到食物源  $i$  与邻近食物源  $k$  之间的差异度值  $l$ . 为更好地平衡算法的开发能力与探索能力, 本文根据  $l$  的大小制定相应的策略选取更新维度, 决定新解  $X_i^{t+1}$  靠近还是远离旧解  $X_i^t$ , 策略如下:

设置合理阈值  $th$ , 当  $l > th$  时, 随机抽取  $d$  中元素值为 1 的某一维度更新; 当  $l \leq th$  时, 随机抽取  $d$  中元素值为 0 的某一维度更新.

对应于二进制优化问题, 公式(12)、(13)可简化为式(15)(16):

$$x_{ij}^{t+1} = \sim x_{ij}^t \quad (15)$$

$$d = X_i \oplus X_k \quad (16)$$

式中, “ $\sim$ ”表示取反; “ $\oplus$ ”表示两同维向量对应位异或.

### 3.3 侦察蜂策略

$limit$  次开发后, 适应度值仍得不到提升的食物源处出现侦察蜂, 侦察蜂在算法中(尤其是算法接近收敛的后期)有促进算法跳出局优的作用. 连续优化问题中的侦察蜂产生策略不能直接用于离散优化问题, 在这里给出离散优化问题中侦察蜂的生成策略如式(17):

$$X_i = X_{\text{worst}} \cdot (\sim COMPARE(X_{\text{worst}}, X_{\text{best}})) + RAND(D; S, P(S)) \cdot COMPARE(X_{\text{worst}}, X_{\text{best}}) \quad (17)$$

式中, “ $\cdot$ ”表示两同维向量对应位相乘;  $X_{\text{worst}}$  为当前种群适应度最差解;  $X_{\text{best}}$  为当前种群适应度最优解; 第二项表示  $X_{\text{worst}}$ 、 $X_{\text{best}}$  之间存在差异的维度的值以概率  $P(S)$  从  $S$  集中选取.

对于二进制优化问题, 式(17)简化如式(18):

$$X_i = (X_{\text{worst}} \& (\sim (X_{\text{worst}} \oplus X_{\text{best}}))) \mid (RAND(D; [0, 1], [1-p, p]) \& (X_{\text{worst}} \oplus X_{\text{best}})) \quad (18)$$

式中, “ $\&$ ”表示将两同维向量对应位相与; “ $\mid$ ”表示将两同维向量对应位相或.

### 3.4 LDABC 算法与 DABC 算法复杂度对比

从 LDABC 和 DABC 算法的详细步骤中可看出, 算

法的空间复杂度主要由问题规模和种群大小确定,当采用相同的数据结构存储解时,LDABC算法与DABC算法的空间复杂度是相当的。

时间复杂度的不同主要体现在邻域搜索策略的不同和所需迭代次数的不同.在此,对两种算法一次迭代中的有差异部分作算法复杂度对比分析.DABC算法中,邻域搜索策略主要由式(4)~(6)组成,算法复杂度为 $O(M(n))$ ,其中 $M(n)$ 表示二进制精度为 $n$ 位的浮点指数运算复杂度,依据文献[17]有式(19):

$$M(n) = n \cdot \log_2^2(n) \cdot \log_2(\log_2(n)) \quad (19)$$

对于LDABC算法,在二进制优化问题中的邻域搜索策略主要由式(14)~(16)组成,完全采用的二进制加法或逻辑运算,最坏的情况下,时间复杂度为 $O(D)$ .当 $D < M(n)$ 时,LDABC算法单次迭代的时间复杂度低于DABC算法.对单精度浮点数,如7位十进制有效位,对应23位二进制有效位,即 $n = 23$ 时, $M(n) \approx 1025$ ,一般 $D$ 的典型量级在 $10^2$ ,因此典型情况下LDABC算法单次迭代时间复杂度比DABC算法低.此外,由于LDABC算法采用绝对更新策略,保证了每一次更新中新解与旧解的差异,有更快的收敛速度(更小的迭代次数),因此问题求解的总体时间复杂度低于DABC算法。

## 4 仿真实验结果及分析

认知无线电技术是解决当前频谱资源紧缺的有效技术,频谱的合理高效分配是认知无线电的关键<sup>[18]</sup>.文献[14]给出了基于图论着色理论的频谱分配模型,并证明了该模型为典型的NP-hard优化问题.下面将LDABC算法应用于该模型,并与DABC算法<sup>[11,16]</sup>进行比较。

### 4.1 仿真环境及算法主要参数设置

本文仿真计算机配置如下:处理器:Core(TM)2 Duo CPU T6500,主频:2.10GHz,内存:2.00G,仿真平台为MATLAB R2010a.采用文献[16]的参数设置,如表1所示,即: $M = 22$ , $N = 20$ , $SN = 20$ , $limit = 10$ , $th = 1$ ,最大迭代次数为300. $L$ :随机生成的0,1矩阵; $B$ :元素值为从1到10之间随机选取的实数; $C$ :可看作 $M$ 个 $N \times N$ 的二维矩阵,各二维矩阵为随机生成的0,1二元对称矩阵.为保证公平性,LDABC、DABC算法在每次实验中作相同的初始化,为避免偶然性,各算法仿真30次取平均效益。

基于表1参数,该模型最大化网络总效益目标函数如式(20)所示:

$$f = \sum_{n=1}^N \sum_{m=1}^M a_{n,m} \times b_{n,m} \quad (20)$$

在频谱分配问题中,求解目标是频谱分配矩阵 $A$ . $A$ 是一个 $N \times M$ 的二维矩阵,直接对 $A$ 编码,求解范围大,冗余度高,文献[19]对 $A$ 进行降维去冗余处理,将 $A$ 映射到 $1 \times D$ 的 $D$ 维空间, $D$ 的大小由 $L$ 中1元素的

个数决定,即有 $D = \sum_{n=1}^N \sum_{m=1}^M l_{n,m}$ ,显然, $D \leq N \times M$ .本文参考文献[19]方法进行解编码。

表1 频谱分配主要参数

参数名	描述	取值
可用频谱数 $M$	当前环境中可用频谱数	$[0, +\infty]$
认知用户数 $N$	当前环境中认知用户总数	$[0, +\infty]$
可用性矩阵 $L$	$N \times M$ 矩阵, $l_{n,m} = 1$ : 信道 $m$ 对用户 $n$ 可用	$\{0, 1\}$
效益矩阵 $B$	$N \times M$ 矩阵, $b_{n,m}$ : 用户 $n$ 使用信道 $m$ 能获得的网络效益	$[1, 10]$
干扰矩阵 $C$	$N \times N \times M$ 矩阵, $c_{n,k,m} = 1$ : 用户 $n$ 和 $k$ 不能同时使用信道 $m$	$\{0, 1\}$
分配矩阵 $A$	$N \times M$ 矩阵, $a_{n,m} = 1$ : 信道 $m$ 分配给用户 $n$	$\{0, 1\}$

## 4.2 仿真实验与分析

### 4.2.1 迭代次数分析

迭代次数是收敛速度的重要评价标准,到达最优解所需要的迭代次数越小,反映算法的收敛性越好.以迭代次数为横轴,效益值为纵轴,DABC、LDABC算法重复30次取平均,得到收敛性曲线如图1.




图1 迭代次数比较曲线

由图1可以看出,LDABC在第77次迭代已经找到最优适应度,而DABC算法在120次之后才渐渐收敛到局优解.可见,采用直接取反的解更新策略,有效地避免了解不更新现象,提高了算法的探索能力,加快了收敛速度;另一方面,引入群间差异比较学习策略,根据群间差异度确定更新维度,增强了算法的开发能力;此外,侦查蜂的产生以当前最优解与最坏解为先验知识,更好地利用了群体搜索积累的知识,在开发能力和探索能力上达到了很好的平衡。

### 4.2.2 计算时间分析

实际中工程往往需要在短时间内找到最优解(如频谱分配模型是基于某一瞬间信道环境参数不变的假设).以时间为横轴,效益值为纵轴,DABC、LDABC算法重复30次取平均,得到计算时间比较曲线如图2.




图2 计算时间比较曲线

由图 2 可以看出,LDABC 算法在 0.1s 已经收敛,而 DABC 算法在 1s 后仍然保持一个慢速的增长.这是因为:一方面,基于 SF 离散法的 DABC 每一次新解的计算都需要进行复杂的指数运算,而 LDABC 算法主要是逻辑运算,单次迭代的时间更少;另一方面,基于 SF 离散法的 DABC 大量存在解不更新现象,而 LDABC 算法通过绝对的更新策略保证了每一次更新中新解与旧解的差异,提高了搜索效率,进一步减少了搜索时间.

4.2.3 多次实验性能比较

为了观察算法在不同信道环境下的表现,用 20 种不同的  $L$ 、 $B$ 、 $C$  矩阵,每次两种算法均采用一样的初始解,20 种不同信道环境下的最大总效益如图 3 所示.可以看出,LDABC 算法在 20 次不同信道环境的仿真中均能找到更优秀的解,获得更大的效益值.




图3 不同信道环境下的最大效益

4.2.4 算法统计性能比较

对两种算法在不同规模下,以不同初值进行 30 次试验,得到总效益的均值、方差如表 2,可以看出,随着  $N$ 、 $M$  取值的增大,两种算法的方差不再为零,这时由于当规模较小时,每次试验都获取到全局最优解,因此方差为 0,而随着规模的增大,获得全局最优解的概率下降,每次试验可能获得不同的局部最优解,因此表现出方差不为 0.但 LDABC 相对于 DABC 算法均能获得更大均值,且方差更小.因此,LDABC 算法的统计性能优于 DABC 算法.

5 结论

低复杂度、高性能的优化算法一直是各类工程优化

表 2 两种算法下的统计性能分析表

		$N = 5$ $M = 5$	$N = 7$ $M = 8$	$N = 10$ $M = 12$	$N = 12$ $M = 14$	$N = 16$ $M = 18$	$N = 20$ $M = 22$
DABC	EX	28.75	59.33	205.53	195.21	308.83	489.09
	DX	0.00	0.00	4.62	4.76	10.28	16.06
LDABC	EX	28.75	59.33	213.26	206.29	359.84	590.07
	DX	0.00	0.00	0.00	0.00	2.33	7.67

注:‘EX’指均值,‘DX’指方差.

问题所追求的.LDABC 算法是 ABC 算法在离散域的拓展,本文主要通过如下三方面的措施保证了 LDABC 算法的优化性能:(1)放弃通过 SF 法建立离散域与连续域映射关系的经典做法,提出直接在离散封闭集内进行运算的 LDABC 算法,在一般情况下,可降低计算复杂度;(2)引入群间个体的交流学习模型,根据种群个体间的差异度确定更新维度,增强了算法的开发能力;(3)对选取的更新维度采取绝对的更新策略,即 NRAND 操作,保证了新解与旧解的不同,提高了算法的探索性能.此外,算法大部分采用逻辑运算或类逻辑运算,利于硬件实现.在基于图论着色理论的频谱分配模型上进行仿真验证,结果表明,本文提出的 LDABC 算法在减小计算量、提高收敛速度的同时,取得了明显优于 DABC 算法的优化性能.

参考文献

- [1] Karaboga D, Akay B. A modified artificial bee colony (ABC) algorithm for constrained optimization problems [J]. Applied Soft Computing, 2011, 11(3): 3021 – 3031.
- [2] Gao Wei-feng, Liu San-yang. Improved artificial bee colony algorithm for global optimization [J]. Information Processing Letters, 2011, 111(17): 871 – 882.
- [3] Gazi V, Passino K M. Swarm Stability and Optimization [M]. Springer, 2011. 3 – 14.
- [4] Karaboga D, Basturk B. On the performance of artificial bee colony (ABC) algorithm [J]. Applied Soft Computing, 2008, 8(1): 687 – 697.
- [5] 高卫峰,刘三阳,黄玲玲.受启发的人工蜂群算法在全局优化问题中的应用 [J]. 电子学报, 2012(12): 2396 – 2403. Gao Wei-feng, Liu San-yang, Huang Ling-ling. Inspired artificial bee colony algorithm for global optimization problems [J]. Acta Electronica Sinica, 2012(12): 2396 – 2403. (in Chinese)
- [6] 王生生,杨娟娟,柴胜.基于混沌鲶鱼效应的人工蜂群算法及应用 [J]. 电子学报, 2014(9): 1731 – 1737. Wang Sheng-sheng, Yang Juan-juan, Chai Sheng. Artificial bee colony algorithm with chaotic catfish effect and its application [J]. Acta Electronica Sinica, 2014(9): 1731 – 1737. (in Chinese)

- [7] Karaboga D, Gorkemli B, Ozturk C, et al. A comprehensive survey: artificial bee colony (ABC) algorithm and applications [J]. *Artificial Intelligence Review*, 2012; 1 – 37.
- [8] J Krause, J Cordeiro, R S Parpinelli, et al. A survey of swarm algorithms applied to discrete optimization problems[J]. *Swarm Intelligence and Bio-inspired Computation*, 2013: 169 – 191.
- [9] Kennedy J, Eberhart R C. A discrete binary version of the particle swarm algorithm [A]. *Proceedings of IEEE International Conference on Systems, Man, and Cybernetics*[C]. Bscataway, NJ: IEEE, 1997: 4104 – 4108.
- [10] Engelbrecht A P, Pampara G. Binary differential evolution strategies [A]. *Proceedings of the Congress on Evolutionary Computation*[C]. Singapore: IEEE, 2007: 1942 – 1947.
- [11] Marinakis Y, Marinaki M, Matsatsinis N. A hybrid discrete artificial bee colony-GRASP algorithm for clustering [A]. *Proceedings of the International Conference on Computers & Industrial Engineering*[C]. IEEE, 2009: 548 – 553.
- [12] Akay B. A study on particle swarm optimization and artificial bee colony algorithms for multilevel thresholding [J]. *Applied Soft Computing*, 2013, 13(6): 3066 – 3091.
- [13] Ćrepišček M, Liu S, Memik M. Exploration and exploitation in evolutionary algorithms: a survey [J]. *ACM Computing Surveys (CSUR)*, 2013, 45(3): 35.
- [14] Peng Chun-yi, Zheng Hai-tao, Zhao Ben-Y. Utilization and fairness in spectrum assignment for opportunistic spectrum access [J]. *ACM Mobile Networks and Applications (MONET)*, 2006, 11(4): 555 – 576.
- [15] D Karaboga, B Gorkemli. A combinatorial artificial bee colony algorithm for traveling salesman problem [A]. *Proceedings of the International Symposium on Innovations in Intelligent Systems and Applications (INISTA)* [C]. IEEE, 2011. 50 – 53.
- [16] 李鑫滨, 刘磊, 马锴. 基于离散人工蜂群算法的认知无线电频谱分配 [J]. *系统工程与电子技术*, 2012, 34(10): 2136 – 2141.
- Li Xin-bin, Liu Lei, Ma Kai. Cognitive radio spectrum allocation based on discrete artificial bee colony algorithm [J]. *Journal of Systems Engineering and Electronics* 2012, 34(10): 2136 – 2141. (in Chinese)
- [17] BRENT, R P. Fast multiple-precision evaluation of elementary functions [J]. *Journal of the ACM*, 1976, 23(2): 242 – 251.
- [18] 王钦辉, 叶保留, 田宇, 等. 认知无线网络中频谱分配算法 [J]. *电子学报*. 2012, 40(1): 147 – 154.
- Wang Qin-hui, Ye Bao-liu, Tian Yu, et al. Survey on spectrum allocation algorithms for cognitive radio networks [J]. *Acta Electronica Sinica*, 2012, 40(1): 147 – 154. (in Chinese)
- [19] Zhao Zhi-jin, Peng Zhen, Zheng Shi-lian, et al. Cognitive radio spectrum allocation using evolutionary algorithms [J]. *IEEE Transactions on Wireless Communications*, 2009, 8(9): 4421 – 4425.

#### 作者简介



朱冰莲 女, 1959 出生于四川富顺, 重庆大学教授, 主要研究方向为信号与信息处理、模式识别、图像处理等。

E-mail: zhubl@cqu.edu.cn



朱方方 男, 1989 年 12 月生于湖北省天门市, 现为重庆大学硕士研究生, 主要研究方向为智能优化算法及在认知无线电中的应用。