

# DBC 优化算法在瓦斯突出预测中的应用<sup>①</sup>

彭继慎, 聂 苓

(辽宁工程技术大学 电气与控制工程学院, 葫芦岛 125105)

**摘 要:** 针对煤矿瓦斯突出因素的复杂性, 提出一种新的智能优化算法-双混沌搜索蜂群(DBC)优化算法, 应用于煤矿瓦斯突出的预测中. DBC 优化算法对人工蜂群算法进行有效改进, 在人工蜂群算法的基础上, 将混沌优化机制引入蜂群的寻优过程中, 利用混沌序列初始化食物源, 以提高食物源的质量, 防止算法的早熟收敛; 同时利用混沌搜索机制进行局部搜索, 以改善蜂群的区域搜索能力, 解决算法易陷入局部极小值的问题. 最后, 利用 DBC 对 MLPNN 进行训练, 建立瓦斯突出预测模型. 实验结果表明, 该方法对瓦斯突出具有较好的预测结果.

**关键词:** 双混沌搜索蜂群算法; 神经网络; 混合算法; 瓦斯突出预测

## Application of DBC Optimization Algorithm in Gas Outburst Prediction

PENG Ji-Shen, NIE Ling

(School of Electrical and Control Engineering, Liaoning Technical University, Huludao 125105, China)

**Abstract:** Aiming at the characteristics of the gas outburst disasters, the double chaos search bee colony (DBC) algorithm for gas outburst prediction is proposed. DBC algorithm improves ABC by introducing the chaos optimization idea in the process of population evolutionary. The chaos method generates initial population in order to improve the quality of the food source, to prevent premature convergence of the algorithm. Meanwhile, chaos idea is introduced to the bee swarm local search. Through the method, this drawback of getting in local minima is resolved. Then DBC is merged with MLPNN to construct a gas outburst prediction model by using DBC to train the weights and thresholds. The predicted results show that the method is accurate.

**Key words:** double chaos search bee colony algorithm; neural network; coupled algorithm; gas outburst prediction

人工蜂群(ABC)算法是一种基于蜜蜂群智能搜索行为的优化算法<sup>[1]</sup>. 其控制参数少、计算简洁, 已成功的应用于解决函数的数值优化问题, 而且在人工神经网络训练、网络优化、工程预测、生产调度等工程领域取得了良好的效果.

虽然 ABC 算法在很多优化问题中都表现出优于蚁群(AC)、支持向量机(SVM)等算法的性能<sup>[2,3]</sup>, 但由于寻优方式和选择机制的影响, 其在处理问题时, 仍旧存在着易陷入局部极值和早熟收敛的问题.

因此, 为了提高 ABC 算法的寻优能力、克服早熟收敛的问题, 本文提出一种改进的蜂群算法—双混沌搜索蜂群(DBC)优化算法. 其主要思想是: 利用混沌序列产生初始食物源, 以提高食物源的多样性, 防止

算法的早熟收敛; 同时将混沌搜索机制引入侦查蜂的区域搜索中, 当某个解陷入局部最优时, 使其快速跳出局部最优, 以提高蜂群的搜索精度. 最后将 DBC 应用于 MLPNN 的训练中, 对 MLPNN 的连接权值和阈值进行寻优, 建立瓦斯突出预测模型.

## 1 ABC算法的基本原理

在 ABC 算法中, 蜜蜂群的内部工种分为三类: 引领蜂、观察蜂和侦察蜂. 引领蜂先出去寻找食物源; 观察蜂在舞蹈区等待引领蜂带回食物源的相关信息, 并且根据信息选择食物源; 侦察蜂则完全随机寻找新的食物源. 一个食物源对应一个引领蜂, 也就是说, 食物源的个数等于引领蜂的个数. 如果某个食物源被引

<sup>①</sup> 收稿时间:2013-03-20;收到修改稿时间:2013-09-20

引领蜂和观察蜂丢弃,那么和这个食物源对应的引领蜂就变为侦查蜂。

ABC 算法中,一个食物源的位置代表优化问题的一个可能解,食物源的花蜜数量代表解的质量(适应度)。首先,ABC 算法生成含有  $N$  个解(食物源)的初始种群,然后,蜜蜂对所有的食物源进行循环搜索。引领蜂先对对应的食物源(解)进行一次邻域搜索,并选择花蜜数量多也就是适应度较高的食物源(解)。所有的引领蜂完成搜索之后,在舞蹈区把食物源的信息传达给观察蜂。观察蜂根据得到的信息按照概率值  $P_i$  选择食物源,  $P_i$  根据表达式(1)计算:

$$P_i = \frac{f(n_i)}{\sum_{p=1}^N f(n_p)} \quad (1)$$

式中,  $n_i$  为第  $i$  个食物源,  $f(n_i)$  为第  $i$  个食物源的适应度值,  $i \in \{1, 2, \dots, N\}$ ,  $N$  为食物源总数。花蜜越多的食物源,被选择的概率越大。观察蜂选定一个食物源后也在其邻域内搜索,若新的食物源优于原食物源,则其角色转变为引领蜂,并记忆相关信息。当个体经过若干次循环而食物源没有更新时,则放弃该食物源,对应的引领蜂转换为侦查蜂寻找新的食物源。ABC 算法就是通过如此反复搜索,最终搜寻到最优解。

## 2 DBC算法描述

对于 ABC 算法,其初始种群的生成是随机的,即随机产生若干个个体组成初始群体,因此食物源的质量无法得到保证,如果初始种群不够理想,将极易导致算法早熟收敛;而且 ABC 算法经常出现某个解经过  $limit$  次循环后没有得到改善,陷入局部最优的情况,这时就必须随机产生新解来替换它,因此搜索精度不高,收敛速度较慢。DBC 算法对 ABC 算法进行改进,将混沌优化思想引入蜂群的寻优过程中,提高了算法的收敛速度和收敛精度。

### 2.1 DBC 算法基本原理

混沌是自然界中广泛存在的一种非线性现象,它看似混乱,却有着精致的内在结构,具有伪随机性、遍历性等特点,在一定范围内能按其自身的规律不重复地遍历所有状态<sup>[4]</sup>,利用其产生初始食物源能大幅提高食物源的多样性和质量,抑制算法的早熟收敛;当蜂群经过若干次循环搜索而没有食物源更新时,利用

混沌搜索策略来实现侦查蜂的搜索,能使侦查蜂快速跳出局部最优点,产生局部最优解的许多邻域点,帮助蜂群找到全局最优解。

采用著名的一维 Logistic 方程<sup>[5]</sup>产生混沌序列,其形式如下:

$$X_s^{k+1} = 4X_s^k(1 - X_s^k) \quad (2)$$

式中,  $s \in \{1, 2, \dots, N\}$ ,  $k = 0, 1, \dots, K - 1$ 。  $X_s^{k+1}$  是  $X_s^0$  第  $k+1$  次迭代之后的值,  $K$  为混沌迭代次数。当  $X_s^0 \in (0, 1)$  时,系统处于完全混沌状态,  $X_s^k$  会在  $(0, 1)$  内遍历。

将侦查蜂所在位置  $N_i$  按下式映射到 Logistic 方程的定义域  $[0, 1]$  上

$$X_{i,s} = \frac{X_s^i - L_s}{U_s - L_s} \quad (3)$$

其中,  $[L_s, U_s]$  为定义的第  $s$  维变量  $X_s^i$  附近的邻域范围。

利用(2)式迭代  $K$  次,得到混沌序列:  $X_s^1, X_s^2, \dots, X_s^K$ , 然后将混沌序列按照式(4)映射到搜索空间。

$$X_{i,s}^k = L_s + X_s^k(U_s - L_s), \quad k=1, 2, \dots, K \quad (4)$$

即可得到混沌搜索后产生的  $K$  个待选食物源  $P_i^k = (X_{i,1}^k, \dots, X_{i,s}^k, \dots, X_{i,N}^k)$ , 计算这  $K$  个食物源的适应度,并与原解进行比较,选择出适应度最高的食物源予以保留。

### 2.2 DBC 算法步骤

(1) 初始化蜜蜂种群。随机产生一个  $D$  维且每个分量数值均在  $(0, 1)$  的向量  $z_1 = (z_{11}, z_{12}, \dots, z_{1D})$ ,  $D$  为解空间的维数。

根据公式(2)迭代  $M$  次得到  $M$  个向量,  $z_1, z_1 \dots z_M$ 。将  $z_1, z_1 \dots z_M$  按照式(4)载波到对应变量的取值区间,得到初始种群的  $M$  个候选解,从中选择  $N$  个适应度值较高的解作为初始食物源。

引领蜂被随机地分配到搜索空间的食物源位置上,并计算相应食物源的适应度。

(2) 引领蜂进行食物源邻域搜索,根据食物源位置更新公式(5)产生新的食物源,与当前食物源比较,保留收益度高的食物源。

$$x_i^j = x_{\min}^j + rand(0, 1)(x_{\max}^j - x_{\min}^j) \quad (5)$$

(3) 引领蜂更新位置后通过舞蹈的方式向观察蜂传递食物源的信息,观察蜂根据轮盘赌策略选择引领蜂所在的食物源,并在其邻域内搜索新的食物源。

(4) 搜索到的新食物源与原食物源比较,若适应度高于观察蜂所在的食物源,则保留新食物源并进入(6),反之继续搜索。若达到最大搜索次数,仍没有新

解, 则观察蜂转变为侦察蜂进行混沌搜索, 寻找最优解, 其思路如下:

① 设置混沌搜索次数  $K$ ;

② 将侦察蜂所在的食物源按(3)式映射到混沌空间, 利用式(2)进行  $K$  次迭代, 得到混沌序列, 按式(4)将混沌序列映射到原搜索空间, 得到新的食物源, 并计算其适应度;

③ 将步骤②中得到的食物源与(4)中观察蜂所对应的食物源进行比较, 保留适应度最高的食物源替代(4)中观察蜂的食物源。

(5) 算法满足循环终止条件时, 输出最优食物源。

### 2.3 DBC 算法性能分析

为了验证改进后算法的性能, 将本文所提的 DBC 算法与 ABC 算法进行对比实验. 由于篇幅所限, 选取文献[6]中的测试函数 1、2、4、6 进行仿真测试, 并根据函数性质分为具有单个极小点(单模态)和多个局部极小点(多模态)两大类,

$f_1, f_2$  是单模态函数, 主要用来测试算法的寻优精度;  $f_4, f_6$  是复杂的非线性多模态函数, 具有许多局部极值点, 一般算法都较难找到全局最优值, 因此可用来检验算法的全局搜索性能. 测试函数取 100 维, 在固定的迭代次数下, 通过对测试函数的均值、方差、最优值和最差值的考察来对算法进行评估, 仿真结果如表 1 所示. 可以看出, 在搜索性能上, DBC 算法有非常显著的提高, 可以有效的避免局部收敛, 表明针对 ABC 算法固有缺陷进行的改进, 取得了良好的效果。

表 1 仿真结果比较

函数	算法	均值	方差	最优值	最差值
1	ABC	5.3536e-13	1.0621e-12	5.0089e-12	1.1022e-14
	DBC	1.3623e-33	1.4216e-33	5.2268e-33	1.7624e-34
2	ABC	2.4761e+00	3.5207e-01	3.1642e+00	1.8539e+00
	DBC	2.5312e-01	5.1326e-02	4.0168e-01	1.8321e-01
4	ABC	9.3054e-13	1.5448e-12	6.2430e-12	1.0880e-14
	DBC	1.3578e-16	2.9280e-16	1.3652e-15	0.0000e+00
6	ABC	8.1718e-13	1.2802e-12	4.3979e-12	5.5511e-15
	DBC	7.3258e-17	1.2526e-16	4.4035e-16	0.000e-00

## 3 DBC-MLPNN 混合算法

### 3.1 MLPNN 基本原理

多层感知器神经网络(MLPNN)是由多个神经元通过一定方式相互连接组成的系统<sup>[7]</sup>, 一般有输入层、隐

含层和输出层三层结构, 其模型如图 1 所示, 各层神经元数量不等, 外部信号由这三层依次传递, 由输出层输出最终结果. 图中  $X = (x_1, x_2, \dots, x_m)$  为输入矢量;  $w_{ij}$  为第  $i$  个输入对第  $j$  个神经元作用的权值;  $\theta_j$  为阈值.  $Y = (y_1, y_2, \dots, y_n)$  为输出矢量.




图 1 MLPNN 模型

任何一个神经网络模型要实现某种功能的操作, 就必须先对它进行训练. 训练的目的在于调整各层的权重系数及阈值, 使输出误差达到某个要求的精度(理想情况误差应达到零). 由于 MLPNN 结构的复杂性, 不同权值和阈值对同一样本的收敛速度不同, 从而使 MLPNN 存在着学习速度慢、精度低和鲁棒性差等缺陷, 无法满足工程应用的需要. 而 DBC 算法的搜索能够遍及整个解空间, 容易得到全局最优解, 因此, 将擅长全局搜索的 DBC 算法与 MLPNN 进行有机结合, 形成 DBC-MLPNN 混合算法, 能有效提高 MLPNN 的辨识性能。

### 3.2 DBC-MLPNN 预测模型

将 MLPNN 的连接权值和阈值相应地映射为引领峰搜索到的食物源, 即每一个食物源代表 MLPNN 的一个权重系数. 利用 DBC 算法在这个由神经网络连接权值和阈值组成的问题空间中寻优, 即寻找最好的一组连接权值和阈值, 使模型的预测能力最好。

## 4 DBC-MLPNN 预测模型在瓦斯突出预测中的应用

将 DBC-MLPNN 预测模型应用到矿井的瓦斯突出预测中. 采用文献[8]中的瓦斯突出统计数据作为数据来源进行仿真研究. 经分析比较, 决定以巷道类型( $S$ )、垂深( $L$ )、瓦斯放散初速度( $T$ )、煤的坚固系数( $H$ )、煤层瓦斯压力( $P$ )为瓦斯突出区域预测指标. 将统计数据分为训练数据和测试数据, 从中随机选取 35 个实际突出时的数据及 65 个没有发生突出时的数据作为训练样

本, 从剩余的数据中选取 6 组数据作为测试样本, 分别编号为 1、2、3、4、5、6.

在 MLPNN 中, 输入层神经元个数为 6, 隐藏层神经元个数为 9, 输出层神经元个数为 1, MLPNN 的连接权值和阈值可以编码为一个 73 维的向量, 即  $D=73$ . 在 DBC 中,  $M=60$ , 引领蜂和观察蜂的数目均为  $N=40$ , 混沌迭代次数  $K=50$ , 算法最大循环代数  $G=2000$ . 利用训练样本对 DBC-MLPNN 预测模型进行训练, 取目标误差值为 0.01, 训练结果如图 2 所示, 可以看出, 无论是前期的收敛速度还是后期的收敛精度上, DBC-MLPNN 预测模型均表现良好, 满足实际预测要求.




图 2 DBC-MLPNN 模型收敛误差曲线

利用测试样本对训练好的 DBC-MLPNN 模型进行测试, 预测结果如表 2 所示, 实际结果与预测结果中“0”代表不突出、“1”代表突出. 从中可以看出, 预测结果准确率达 100%, 表明经 DBC 优化得到的预测模型有很高的预测精度, 满足煤矿安全生产的要求.

## 5 结论

本文在人工蜂群算法的基础上, 提出一种改进的蜂群算法—双混沌搜索蜂群优化算法, 通过对较复杂的全局优化问题的仿真结果表明, 该算法收敛速度更

快、搜索精度更高, 其全局搜索与跳出局部最优的能力均强于人工蜂群算法. 将 DBC 用于训练 MLPNN, 构建瓦斯突出预测模型, 其实验结果表明, 此方法切实可行, 具有预测决策的意义.

表 2 DBC-MLPNN 模型预测结果

编号	1	2	3	4	5	6
S	0.7892	0.1213	0.7865	0.2011	0.1217	0.2216
L	0.3584	0.1384	0.3041	0.3813	0.2976	0.4574
T	0.1672	0.3416	0.2105	0.8986	0.9521	0.8903
H	0.8983	0.0509	0.9407	0.2832	0.0586	0.4322
P	0.1426	0.2587	0.2694	0.6312	0.5534	0.5792
实际	0	1	0	1	1	1
预测	0	1	0	1	1	1

## 参考文献

- 1 Karaboga D, Basturk B. A powerful and efficient algorithm for numerical function optimization: artificial bee colony (ABC) algorithm. *Journal of Global Optimization*, 2007, 39(3): 459-471.
- 2 丁海军, 冯庆娴. 基于 boltzmann 选择策略的人工蜂群算法. *计算机工程与应用*, 2009, 45(31): 53-55.
- 3 袁晓辉, 袁艳斌, 王乘. 一种新型的自适应混沌遗传算法. *电子学报*, 2006, 34(4): 708-712.
- 4 高尚, 杨静宇. 混沌粒子群优化算法研究. *模式识别与人工智能*, 2006, 19(2): 266-270.
- 5 罗均, 李研. 具有混沌搜索策略的蜂群优化算法. *控制与决策*, 2010, 25(12): 1913-1916.
- 6 暴励, 曾建潮. 一种双种群差分蜂群算法. *控制理论与应用*, 2011, 28(2): 266-272.
- 7 李伟强, 徐建城, 殷建锋. 蜜蜂群优化算法用于训练前馈神经网络. *计算机工程与应用*, 2009, 45(24): 43-45.
- 8 于不凡. 煤矿瓦斯灾害防治及利用技术手册. 北京: 煤炭工业出版社, 2000.