

文章编号: 1671-251X(2025)03-0131-07

DOI: 10.13272/j.issn.1671-251x.2024100014

# 基于改进人工蜂群算法的矿井风量按需调控智能决策

张浪<sup>1,2,3</sup>, 雷爽<sup>1,2,3</sup>, 李伟<sup>2,3</sup>, 刘彦青<sup>2,3</sup>

(1. 煤炭科学研究总院, 北京 100013; 2. 煤科通安(北京)智控科技有限公司, 北京 100013;  
3. 煤炭智能开采与岩层控制全国重点实验室, 北京 100013)

**摘要:** 针对现有元启发式算法求解矿井风量调控无约束优化数学模型存在收敛速度较慢的问题, 提出了一种基于改进人工蜂群算法(ABC)的矿井风量按需调控智能决策方法。以矿井调节分支风阻为决策变量、各分支实际风量与需风量相符合为约束条件, 以目标用风分支风量与理想风量差距最小为目标, 建立了矿井风量按需调控智能决策模型; 运用拉格朗日松弛方法优化模型的约束条件, 采用冲突数方法优化模型的目标函数, 利用随机搜索方法和启发式算法优化模型的搜索策略。针对人工蜂群算法(ABC)利用能力不足的问题, 提出了一种改进 ABC 算法, 并将其用于求解矿井风量按需调控智能决策模型。该算法在采蜜蜂局部寻优时引入群体历史最优解引导采蜜行为, 并利用一般反向学习策略保存侦查蜂的搜索经验, 良好地平衡了算法的探索和利用能力。实验结果表明: 与粒子群优化(PSO)算法、ABC 算法、基于全局最优的人工蜂群(GABC)算法和基于一般反向学习的人工蜂群(GABC-GOBL)算法相比, 改进 ABC 算法能更加快速、稳定地求解出矿井风量按需调控最优方案, 且风量调控精度可达  $0.49 \text{ m}^3/\text{s}$ 。

**关键词:** 矿井通风; 风量按需调控; 风量智能决策; 人工蜂群算法; 风阻  
中图分类号: TD724 文献标志码: A

## Intelligent decision-making for mine airflow on demand based on the improved artificial bee colony algorithm

ZHANG Lang<sup>1,2,3</sup>, LEI Shuang<sup>1,2,3</sup>, LI Wei<sup>2,3</sup>, LIU Yanqing<sup>2,3</sup>

(1. China Coal Research Institute, Beijing 100013, China;  
2. CCRI Tong'an(Beijing) Intelligent Control Technology Co., Ltd., Beijing 100013, China;  
3. State Key Laboratory of Intelligent Coal Mining and Strata Control, Beijing 100013, China)

**Abstract:** To address the issue of slow convergence speed in solving the unconstrained optimization mathematical model of mine airflow control using existing metaheuristic algorithms, an intelligent decision-making method for mine airflow on demand based on an improved Artificial Bee Colony (ABC) algorithm was proposed. The decision variable was the mine ventilation branch resistance adjustment, with the constraint that the actual airflow in each branch matched the required airflow. The objective was to minimize the difference between the target branch airflow and the ideal airflow. A mine airflow on-demand control intelligent decision-making model was established. The Lagrange relaxation method was used to optimize the model's constraint conditions, the conflict count method was used to optimize the objective function of the model, and random search methods combined with heuristic algorithms were used to optimize the search strategy of the model. To address the issue of insufficient utilization capability in the ABC algorithm, an improved ABC algorithm was proposed and applied to solve the mine airflow on-demand control intelligent decision-making model. The algorithm introduced the

收稿日期: 2024-10-10; 修回日期: 2025-03-21; 责任编辑: 盛男。

基金项目: 国家自然科学基金青年科学基金资助项目(52304224)。

作者简介: 张浪(1978—), 男, 内蒙古乌兰察布人, 研究员, 硕士研究生导师, 硕士, 研究方向为矿井智能通风, E-mail: [lnzhanglang@163.com](mailto:lnzhanglang@163.com)。通信作者: 雷爽(1999—), 男, 四川绵阳人, 硕士研究生, 研究方向为矿井智能通风、智能优化算法, E-mail: [l18874244070@163.com](mailto:l18874244070@163.com)。

引用格式: 张浪, 雷爽, 李伟, 等. 基于改进人工蜂群算法的矿井风量按需调控智能决策[J]. 工矿自动化, 2025, 51(3): 131-137.

ZHANG Lang, LEI Shuang, LI Wei, et al. Intelligent decision-making for mine airflow on demand based on the improved artificial bee colony algorithm[J]. Journal of Mine Automation, 2025, 51(3): 131-137.



扫码移动阅读

population's historical optimal solution to guide the foraging behavior of the honeybees during local optimization and used a general reverse learning strategy to preserve the scout bees' search experience, which effectively balanced the exploration and exploitation capabilities of the algorithm. Experimental results showed that, compared with the Particle Swarm Optimization (PSO) algorithm, the ABC algorithm, the Gbest-guided artificial bee colony (GABC) algorithm, and artificial bee colony with generalized opposition-based learning (ABC-GOBL) algorithm, the improved ABC algorithm could solve the optimal solution of mine airflow on-demand control more quickly and stably, with an airflow control accuracy of up to 0.49 m<sup>3</sup>/s.

**Key words:** mine ventilation; airflow on-demand control; intelligent airflow decision-making; artificial bee colony algorithm; air resistance

## 0 引言

矿井通风系统是煤矿安全的重要保障系统,担负着将新鲜空气送入井下、保证人员正常呼吸、稀释并排出有害气体、调节作业场所温湿度等作用<sup>[1]</sup>。要实现上述作用,必须保证矿井内各用风地点风量时刻满足需风量要求。然而,开采作业是动态变化过程,随着矿井周围环境变化,各巷道实际风量和需风量都是不断改变的,当巷道实际风量不满足需风量要求时,存在安全隐患。随着煤矿智能化发展,如何快速、智能地确定安全、高效、准确的风量调控方案,是矿井通风领域亟待解决的重大问题<sup>[2]</sup>。

近年来,元启发式算法由于其无需梯度信息、鲁棒性强等特点,被广泛应用于矿井风量调控优化问题。Wang Jinmiao 等<sup>[3]</sup>以通风机功率最小为目标,建立了矿井通风系统网络优化的无约束数学模型,并利用黑燕鸥优化算法进行模型求解。吴新忠等<sup>[4]</sup>以目标用风分支风量可调最大化为目标,建立了风量调控数学模型,结合风网灵敏度的衰减特征<sup>[5-7]</sup>,确定了模型中待优化风量的最优调节分支集及其风阻调节范围,缩小了可行域范围,提高了模型解算速度,同时提出了多策略融合麻雀搜索算法对模型进行求解。Li Junqiao 等<sup>[8]</sup>通过引入权重系数,提出了基于通风机最小功耗和目标用风分支最大风量需求的目标函数,并应用改进粒子群优化(Particle Swarm Optimization, PSO)算法进行求解,在尽可能降低通风系统功率消耗的同时,增大了目标用风分支的风量。此外,灰狼优化算法<sup>[9]</sup>、鲸群优化算法<sup>[10]</sup>等元启发式算法也被应用于求解矿井风量调控优化模型。但采用元启发式算法求解无约束优化数学模型存在收敛速度较慢的问题。

本文提出了一种基于改进人工蜂群(Artificial Bee Colony, ABC)算法的矿井风量按需调控智能决策方法。构建以目标用风分支风量与理想风量差距最小为目标的矿井风量按需调控智能决策模型,利用拉格朗日松弛方法<sup>[11]</sup>、冲突数方法<sup>[12]</sup>、随机搜索方法<sup>[13]</sup>和元启发式算法<sup>[14]</sup>对模型进行优化,并采用

改进 ABC 算法求解模型,可实现对矿井风量的快速、精准调控。

## 1 矿井风量按需调控智能决策模型

### 1.1 矿井风量按需调控智能决策需求

为方便分析,将矿井巷道分为 3 类:目标用风分支、其他用风分支和一般分支。目标用风分支即需要通过风量调控决策使该分支风量达到预定值的巷道;其他用风分支即除目标用风分支外的采煤工作面、掘进工作面、独立通风硐室等用风地点需风量要求严格的巷道;一般分支即行人巷道、行车巷道和辅运巷等对风量不做要求的巷道。

矿井风量调控的目的是改变某一条或某几条目标用风分支的风量,使其满足安全生产需求。为达到该目的,在矿井的日常风量调控中,在总风量满足需求时,常通过调控风窗面积以改变巷道风阻,从而实现对目标用风分支的风量调节。因此,在保证其他用风分支和一般分支风量满足需风量要求的前提下,求解符合目标用风分支理想风量的矿井风阻调控方案,即矿井风量按需调控智能决策的实质。

### 1.2 矿井风量按需调控智能决策模型建立

假设第  $x(x=1, 2, \dots, v, v$  为矿井风阻调控方案总数)个矿井风阻调控方案  $R_x = \{r_{x,1}, r_{x,2}, \dots, r_{x,n}\}$ , 其中  $r_{x,j}$  为第  $x$  个风阻调控方案中第  $j(j=1, 2, \dots, n, n$  为通风网络分支总数)个分支风阻,此时第  $x$  个矿井风阻调控方案中第  $j$  个分支的风量  $q_{x,j}$  与  $R_x$  存在函数关系  $f_j(\cdot)$ :

$$q_{x,j} = f_j(R_x) \tag{1}$$

矿井风量按需调控智能决策模型的目标函数可描述为

$$F(R_x) = \sum_{t=1}^z S_{x,t} \tag{2}$$

$$S_{x,t} = \begin{cases} \min(|f_i(R_x) - a_t|, |f_i(R_x) - b_t|) & f_i(R_x) < a_t \text{ 或} \\ & f_i(R_x) > b_t \\ 0 & a_t \leq f_i(R_x) \leq b_t \end{cases} \tag{3}$$

式中： $S_{x,t}$ 为第  $x$  个矿井风阻调控方案中第  $t(t=1, 2, \dots, z, z$  为目标用风分支总数) 个目标用风分支风量与其理想风量的差值； $f_i(R_x)$  为第  $x$  个矿井风阻调控方案中第  $t$  个目标用风分支风量； $a_t, b_t$  分别为第  $t$  个目标用风分支风量的下限和上限。

矿井风量按需调控智能决策模型可建立为

$$\begin{cases} \min F(R_x) \\ \text{s.t. } f_s(R_x) \leq b_s \quad s = 1, 2, \dots, n-z \\ l_s(R_x) \leq c_s \\ \sum_{j=1}^n d_{i,j} f_j(R_x) = 0 \quad i = 1, 2, \dots, m-1 \\ \sum_{j=1}^n e_{g,j} r_{x,j} |f_j(R_x)| - h_{N_j} = 0 \quad g = 1, 2, \dots, \\ n-m-1 \\ R_x \in G \end{cases} \quad (4)$$

$$d_{i,j} = \begin{cases} 1 & i \text{ 节点为 } j \text{ 分支端点且流量 } q_{x,j} \text{ 流入该节点} \\ -1 & i \text{ 节点为 } j \text{ 分支端点且流量 } q_{x,j} \text{ 流出该节点} \\ 0 & i \text{ 节点不属于 } j \text{ 分支的端点} \end{cases} \quad (5)$$

$$e_{g,j} = \begin{cases} 1 & j \text{ 分支在 } g \text{ 回路中且与 } g \text{ 回路同向} \\ -1 & j \text{ 分支在 } g \text{ 回路中且与 } g \text{ 回路反向} \\ 0 & j \text{ 分支不属于 } g \text{ 回路} \end{cases} \quad (6)$$

式中： $f_s(R_x)$  为第  $x$  个矿井风阻调控方案中第  $s$  个其他用风分支或一般分支风量； $b_s$  为第  $s$  个其他用风分支或一般分支风量上限； $l_s(R_x)$  为  $f_s(R_x)$  的负值； $c_s$  为第  $s$  个其他用风分支或一般分支风量下限  $a_s$  的负值； $m$  为通风网络节点数； $h_{N_j}$  为第  $j$  个分支自然风压； $G$  为矿井风阻调控方案集合， $G = \{R_1, R_2, \dots, R_v\}$ 。

### 1.3 矿井风量按需调控智能决策模型优化

#### 1.3.1 基于拉格朗日松弛方法的模型优化

式(4)中第3个和第4个约束可由通风网络解算方法<sup>[15-16]</sup>进行求解，第5个约束是对决策变量  $R_x$  取值的限制，且决策变量为连续变量。因此将第3个至第5个约束视为“简单”约束，第1个和第2个约束视为“难”约束。运用拉格朗日松弛方法，将难处理的约束通过拉格朗日乘子移到目标函数上，可将式(4)优化为

$$\begin{cases} \min F(R_x) + \sum_{s=1}^{n-z} \lambda_s (f_s(R_x) - b_s) + \sum_{s=1}^{n-z} \mu_s (l_s(R_x) - c_s) \\ \text{s.t. } \sum_{j=1}^n d_{i,j} f_j(R_x) = 0 \\ \sum_{j=1}^n e_{g,j} r_{x,j} |f_j(R_x)| - h_{N_j} = 0 \\ \lambda_s, \mu_s \geq 0 \\ R_x \in G \end{cases} \quad (7)$$

式中  $\lambda_s, \mu_s$  为第  $s$  个其他用风分支或一般分支对应的

拉格朗日乘子。

由式(7)可知，将式(4)中的第1个和第2个约束通过拉格朗日乘子移到目标函数上后，可行解将不需满足其他用风分支和一般分支风量符合各自需风量这一约束。此时，矿井风量按需调控智能决策模型的一个可行解为一组处于  $G$  集合内，同时满足节点风量平衡定理和回路风压平衡定理的风阻集合。因此，该模型的可行域可利用通风网络解算中的 Scott-Hinsley 法进行刻画。

#### 1.3.2 基于冲突数方法的模型优化

式(7)中的目标函数反映的是各分支风量与其风量上下限(需风量范围)之间的函数关系。为简化该式，引入冲突数的概念：在矿井风量按需调控智能决策模型中，冲突数可理解为矿井风阻调控方案下，风量不处于其需风量范围的分支数。若某分支的风量不处于其需风量范围，则认为该分支的风量与实际需风量发生了冲突，此时该分支的冲突数  $T_{x,j}$  为1，反之为0。总冲突数  $P(R_x)$  表示在第  $x$  个矿井风阻调控方案下矿井所有分支发生冲突情况的总数，当  $P(R_x)$  为0时，代表在第  $x$  个矿井风阻调控方案下，通风网络中每条分支风量均处于其需风量范围中，此时对应的矿井风阻调控方案即为最优的矿井风量按需调控决策。

运用冲突数方法可将式(7)中的目标函数改进为

$$P(R_x) = \sum_{j=1}^n T_{x,j} \quad (8)$$

$$T_{x,j} = \begin{cases} 1 & f_j(R_x) \notin [a_j, b_j] \\ 0 & f_j(R_x) \in [a_j, b_j] \end{cases} \quad (9)$$

则式(7)可优化为

$$\begin{cases} \min P(R_x) \\ \text{s.t. } \sum_{j=1}^n d_{i,j} f_j(R_x) = 0 \\ \sum_{j=1}^n e_{g,j} r_{x,j} |f_j(R_x)| - h_{N_j} = 0 \\ R_x \in G \end{cases} \quad (10)$$

#### 1.3.3 基于随机搜索方法的模型优化

由于式(1)的函数关系是假设的，目前并没有一个方程能够准确描述  $q_{x,j}$  与  $R_x$  之间的关系，所以难以讨论式(10)中目标函数和约束条件的凹凸性、导数信息、KKT 条件的约束规范、有效集等性质，导致无法利用矿井风阻调控方案  $R_x$  对应的矿井风量  $Q_x = \{q_{x,1}, q_{x,2}, \dots, q_{x,n}\}$  的变化趋势精确求解矿井风阻

调控方案  $R_x$  的搜索方向和搜索步长, 不能通过最速下降法和共轭梯度法求解矿井风量按需调控智能决策模型。因此, 采用无需利用  $q_{x,j}$  与  $R_x$  之间的函数关系, 也可获得矿井风阻调控方案  $R_x$  的搜索方向和搜索步长的随机搜索方法, 将式(10)优化为

$$\left\{ \begin{array}{l} \min P(Q_x) \\ \text{s.t.} \sum_{j=1}^n d_{i,j} q_{x,j} = 0 \\ \sum_{j=1}^n e_{g,j} r_{x,j} |q_{x,j}| - h_{N_j} = 0 \\ R_x \in G \end{array} \right. \quad (11)$$

### 1.3.4 基于元启发式算法的模型优化

由式(8)和式(9)可知, 当任何分支风量不处于该分支的需风量范围时, 都会使目标函数值增加 1, 即式(8)并不能体现出目标用风分支、其他用风分支和一般分支这 3 类巷道的区别。由式(8)计算出的目标函数值并不会引导寻优方案优先向使目标用风分支满足其需风量范围的可行解移动。为使目标函数值在目标用风分支维度下降得更迅速, 对不同类型的分支依据其需风量范围, 引入权重系数  $p_j$ , 最终将式(11)优化为

$$\left\{ \begin{array}{l} \min P(Q_x) \\ \text{s.t.} \sum_{j=1}^n d_{i,j} q_{x,j} = 0 \\ \sum_{j=1}^n e_{g,j} r_{x,j} |q_{x,j}| - h_{N_j} = 0 \\ R_x \in G \end{array} \right. \quad (12)$$

$$P(Q_x) = \sum_{j=1}^n p_j T_{x,j} \quad (13)$$

## 2 矿井风量按需调控智能决策

### 2.1 基于 ABC 算法的矿井风量按需调控智能决策

ABC 算法是通过模拟自然界蜜蜂分工采蜜行为而得到的一种元启发式算法, 具有结构简单、控制参数少、鲁棒性强等优点<sup>[17]</sup>, 在应对高维度非线性优化问题上表现出优秀的求解能力<sup>[18]</sup>。

将矿井风量按需调控智能决策模型中的矿井风阻调控方案  $R_x$  视为蜜源位置, 目标函数  $P(Q_x)$  视为蜜源质量(由式(12)可知  $P(Q_x)$  越小, 蜜源质量越优), 则基于 ABC 算法的矿井风量按需调控智能决策的寻优过程如下:

1) 种群初始化。通过初始化方程生成矿井风阻调控方案集合  $G$ 。

$$r_{x,j} = r_{j\min} + \text{rand}(0, 1)(r_{j\max} - r_{j\min}) \quad (14)$$

式中:  $\text{rand}(0, 1)$  为  $[0, 1]$  上的随机数;  $r_{j\max}, r_{j\min}$  分别为第  $j$  个分支风阻的上下限。

2) 采蜜行为。采蜜蜂在可行域内局部搜索新的矿井风阻调控方案, 具体搜索方程可表示为

$$r'_{x,j} = r_{x,j} + \phi(r_{x,j} - r_{k,j}) \quad (15)$$

式中:  $r'_{x,j}$  为经搜索后的第  $x$  个新的矿井风阻调控方案  $R'_x$  中第  $j$  个分支的风阻,  $R'_x = \{r'_{x,1}, r'_{x,2}, \dots, r'_{x,n}\}$ ;  $\phi$  为  $[-1, 1]$  上均匀分布的随机数;  $r_{k,j}$  为随机选出的第  $k(k \neq x)$  个矿井风阻调控方案中第  $j$  个分支的风阻。

若  $R'_x$  的目标函数值优于  $R_x$ ,  $R'_x$  将取代原矿井风阻调控方案  $R_x$ , 否则继续以  $R_x$  作为矿井风阻调控方案。

3) 跟随行为。当采蜜蜂完成搜索后, 会将新的蜜源信息分享给跟随蜂, 每一只跟随蜂都会根据每个矿井风阻调控方案的目标函数值, 以一定的概率选择适应度值较大的优质矿井风阻调控方案, 在其周围采用搜索方程(式(15))进行局部搜索。每个矿井风阻调控方案的适应度函数  $H(R_x)$  及跟随蜂选择对应优质矿井风阻调控方案的概率  $w_x$  分别为

$$H(R_x) = \frac{1}{1 + P(Q_x)} \quad (16)$$

$$w_x = \frac{H(R_x)}{\sum_{x=1}^v H(R_x)} \quad (17)$$

4) 侦察行为。若某一矿井风阻调控方案在经历  $L$  只蜜蜂搜索后仍未找到比它适应度值更大的优质矿井风阻调控方案, 此时认为该矿井风阻调控方案为局部最优解。为跳出局部最优解, 采蜜蜂会转变为侦察蜂, 利用式(14)在整个可行域搜索新的矿井风阻调控方案, 直到找到目标函数值更优的矿井风阻调控方案。

### 2.2 基于改进 ABC 算法的矿井风量按需调控智能决策

由于 ABC 算法中引入了较多的随机因子, 导致该算法的探索能力较强而利用能力不足, 在求解矿井风量按需调控智能决策模型时存在收敛速度较慢的问题。为平衡 ABC 算法的探索能力和利用能力, 结合 PSO 算法<sup>[19]</sup>和一般反向学习 (Generalized Opposition-based Learning, GOBL) 策略<sup>[20]</sup>对 ABC 算法进行改进。

#### 2.2.1 采蜜行为改进

PSO 算法的灵感来源于鸟群或鱼群通过群体协助进行觅食的行为, 在 PSO 算法中粒子根据个体历

史最优值和群体历史最优值调整搜索方向, PSO 算法拥有很强的利用能力, 因此在蜜蜂的采蜜行为中引入群体历史最优值对搜索方向进行引导, 将采蜜行为的搜索方程改进为

$$r'_{x,j} = r_{x,j} + \phi(r_{x,j} - r_{k,j}) + \varphi(r_{best,j} - r_{x,j}) \quad (18)$$

式中:  $\varphi$  为  $[0, 1.5]$  上均匀分布的随机数;  $r_{best,j}$  为当前最优的矿井风阻调控方案  $R_{best}$  在第  $j$  个分支的风阻。

### 2.2.2 侦察行为改进

GOBL 策略的核心机制: 针对当前种群中的候选解, 同步生成其一般反向解, 通过贪婪准则选择适应度值更优的解作为下一代种群个体。该策略可提升算法的探索能力, 从而提高算法收敛到全局最优解的概率。为保留原局部最优解的有用信息, 将侦察行为的搜索方程改进为

$$\tilde{r}_{x,j} = \text{rand}(0, 1)(r_{j\min} + r_{j\max}) - r_{x,j} \quad (19)$$

式中  $\tilde{r}_{x,j}$  为第  $x$  个矿井风阻调控方案的反向解  $\tilde{R}_x$  中第  $j$  个分支的风阻。

若一般反向解  $\tilde{r}_{x,j}$  未在边界调节范围  $[r_{j\min}, r_{j\max}]$  内, 则采用随机生成的方法进行重置:

$$\tilde{r}_{x,j} = \text{rand}(r_{j\min}, r_{j\max}) \quad (20)$$

式中  $\text{rand}(r_{j\min}, r_{j\max})$  为区间  $[r_{j\min}, r_{j\max}]$  上的随机数。

将一般反向解和利用式(14)产生的随机解进行比较, 择优选择新蜜源的位置, 该过程可表示为

$$R_x = \begin{cases} \tilde{R}_x & P(\tilde{R}_x) < P(R_x) \\ R_x & \text{其他} \end{cases} \quad (21)$$

## 3 实验与分析

### 3.1 实验参数

实验目标: 求解使目标用风分支风量调节至  $32 \text{ m}^3/\text{s}$  的风量调控决策。实验所用通风网络拓扑如图 1 所示, 该通风网络初始数据见表 1, 各分支类型、风阻和风量调节范围见表 2。为验证改进 ABC 算法性能, 与 ABC 算法、PSO 算法、基于全局最优的人工蜂群(Gbest-guided Artificial Bee Colony, GABC)算法<sup>[21]</sup>和基于一般反向学习的人工蜂群(Artificial Bee Colony with Generalized Opposition-Based Learning, ABC-GOBL)算法<sup>[22]</sup>进行对比。各算法主要参数设置: 种群规模为 100, 最大抛弃次数为 60, 最大迭代次数为 200。

### 3.2 实验结果分析

实验中每个算法独立运行 30 次, 不同算法的迭代收敛曲线如图 2 所示, 不同算法下模型求解结果见表 3。




图 1 通风网络拓扑

Fig. 1 Ventilation network topology

表 1 通风网络初始数据

Table 1 Ventilation network initial data

分支编号	风阻/ ( $\text{N}\cdot\text{s}^2\cdot\text{m}^{-8}$ )	风量/ ( $\text{m}^3\cdot\text{s}^{-1}$ )	分支编号	风阻/ ( $\text{N}\cdot\text{s}^2\cdot\text{m}^{-8}$ )	风量/ ( $\text{m}^3\cdot\text{s}^{-1}$ )
1	0.006 455	129.50	9	0.114 862	12.32
2	0.004 709	29.96	10	0.085 501	14.27
3	0.009 727	20.85	11	0.001 561	62.09
4	0.001 339	73.38	12	0.001 391	73.38
5	1.572 439	5.31	13	0.015 521	50.81
6	0.001 562	62.10	14	0.005 727	129.50
7	0.232 000	11.28	15	0	129.50
8	0.013 821	35.51			

表 2 通风网络各分支类型、风阻和风量调节范围

Table 2 Branch types, air resistance, and airflow regulation range of the ventilation network

分支编号	分支类型	风阻调节范围/ $(\text{N}\cdot\text{s}^2\cdot\text{m}^{-8})$	风量调节范围/ $(\text{m}^3\cdot\text{s}^{-1})$
1	一般分支	0.006 455	129.50
2	其他用风分支	0.004 709	26.96~32.96
3	其他用风分支	0.009 727	18.77~22.94
4	一般分支	0.001 339	3.94~126.00
5	一般分支	1.572 439	3.94~126.00
6	一般分支	0.001 562	3.94~126.00
7	其他用风分支	0.040 940~0.884 324	10.15~12.41
8	一般分支	0.013 821~0.844 314	3.94~126.00
9	其他用风分支	0.016 615~0.577 616	11.09~13.55
10	目标用风分支	0.085 501	31.50~32.50
11	一般分支	0.001 561	3.94~126.00
12	一般分支	0.001 391	3.94~126.00
13	一般分支	0.004 964~0.714 323	3.94~126.00
14	其他用风分支	0.005 727	129.50
15	虚拟分支	0	129.50




图 2 不同算法的迭代收敛曲线

Fig. 2 Iterative convergence curves of different algorithms

表 3 不同算法下模型求解结果

Table 3 Model solution results under different algorithms

算法	算法成功率/%	平均收敛代数	平均寻优时间/s
改进ABC	100	42	132.72
GABC	87	53	167.48
ABC-GOBL	100	122	385.52
ABC	100	158	516.68
PSO	0	—	—

由图 2 和表 3 可知:改进 ABC 算法能在 132.72 s 稳定将目标函数值收敛到 0,这是由于改进 ABC 算法在引入全局最优解对搜索方向进行引导的同时,加入一般反向解保留搜索经验,能使算法在保持较高探索能力的同时,提高算法的利用能力;GABC 算法虽然能在 167.48 s 实现寻优,但在解算时会出现早熟现象,这是由于 GABC 算法虽然采用全局最优解提高了算法的利用能力,但在求解矿井风量按需调控模型时仍存在不能跳出局部最优解的情况;ABC-GOBL 算法和 ABC 算法均能稳定收敛但速度较慢,平均收敛时间分别为 385.52 s 和 516.68 s,而 ABC-GOBL 算法收敛速度快于 ABC 算法,这是由于该算法在侦查蜂阶段保留了种群记忆;PSO 算法无法正常求解矿井风量按需调控智能决策模型,这是由于 PSO 算法同时利用个体最优解和全局最优解引导搜索,过度提升了算法的利用能力,导致该算法容易陷入局部最优解。

由改进 ABC 算法求解出的最优矿井风阻调控方案见表 4。可看出当分支风阻  $r_7, r_8, r_9, r_{13}$  分别为 0.871 307, 0.209 715, 0.571 217, 0.051 381  $N \cdot s^2/m^8$  时,目标用风分支(第 10 个分支)的风量由 14.27  $m^3/s$  增加至 31.51  $m^3/s$ ,该风量满足目标用风分支的需风量(31.50~32.50  $m^3/s$ )要求,与目标用风分支的期望风量 32  $m^3/s$  仅有 0.49  $m^3/s$  的误差,且调控后各分支风量均能满足需风量要求。

表 4 改进 ABC 算法求解出的最优矿井风阻调控方案

Table 4 Optimal mine ventilation resistance control scheme solved by the improved artificial bee colony algorithm

分支编号	风阻/ ( $N \cdot s^2 \cdot m^{-8}$ )	风量/ ( $m^3 \cdot s^{-1}$ )	分支编号	风阻/ ( $N \cdot s^2 \cdot m^{-8}$ )	风量/ ( $m^3 \cdot s^{-1}$ )
1	0.006 455	129.50	9	0.571 217	12.21
2	0.004 709	27.25	10	0.085 501	31.51
3	0.009 727	18.96	11	0.001 561	64.23
4	0.001 339	74.83	12	0.001 391	74.83
5	1.572 439	8.49	13	0.051 381	46.21
6	0.001 562	64.23	14	0.005 727	129.50
7	0.871 307	10.60	15	0	129.50
8	0.209 715	20.51			

#### 4 结论

1) 以目标用风分支风量与理想风量差距最小为目标,建立了矿井风量按需调控智能决策模型,并运用拉格朗日松弛方法优化模型的约束条件,采用冲突数方法优化模型的目标函数,利用随机搜索方法和元启发式算法优化模型的搜索策略。

2) 针对 ABC 算法探索能力和利用能力不平衡的问题,在采蜜蜂局部寻优时引入群体历史最优解引导采蜜行为,并利用 GOBL 策略保存侦查蜂的搜索经验,提出了一种改进 ABC 算法。

3) 将改进 ABC 算法用于求解矿井风量调控决策模型,相较于 PSO, ABC, GABC, ABC-GOBL 等算法具有更高的收敛速度和稳定性,且寻优精度高。

#### 参考文献(References):

[1] 卢新明,尹红. 矿井通风智能化理论与技术[J]. 煤炭学报, 2020, 45(6): 2236-2247.  
 LU Xinming, YIN Hong. The intelligent theory and technology of mine ventilation[J]. Journal of China Coal Society, 2020, 45(6): 2236-2247.

[2] 张浪,刘彦青. 矿井智能通风与关键技术研究[J]. 煤炭科学技术, 2024, 52(1): 178-195.  
 ZHANG Lang, LIU Yanqing. Research on technology of key steps of intelligent ventilation in mines[J]. Coal Science and Technology, 2024, 52(1): 178-195.

[3] WANG Jinmiao, XIAO Jun, XUE Yan, et al. Optimization of airflow distribution in mine ventilation networks using the modified sooty tern optimization algorithm[J]. Mining, Metallurgy & Exploration, 2024, 41(1): 239-257.

[4] 吴新忠,韩正化,魏连江,等. 矿井风流智能按需调控算法与关键技术[J]. 中国矿业大学学报, 2021, 50(4): 725-734.  
 WU Xinzhong, HAN Zhenghua, WEI Lianjiang, et al.

- Intelligent on-demand adjustment algorithm and key technology of mine air flow[J]. *Journal of China University of Mining and Technology*, 2021, 50(4): 725-734.
- [5] 贾进章, 刘剑, 倪景峰. 通风系统可靠性稳定性及灵敏性数学模型[J]. *辽宁工程技术大学学报(自然科学版)*, 2003, 22(6): 725-727.
- JIA Jinzhang, LIU Jian, NI Jingfeng. Mathematical models for reliability stability and sensitivity of ventilation system[J]. *Journal of Liaoning Technical University (Natural Science)*, 2003, 22(6): 725-727.
- [6] CHATTERJEE A, ZHANG Lijun, XIA Xiaohua. Optimization of mine ventilation fan speeds according to ventilation on demand and time of use tariff[J]. *Applied Energy*, 2015, 146: 65-73.
- [7] JIA Peng, JIA Jinzhang, SONG Lei, et al. Theory of RPOD adjustment of air volume for mine intelligent ventilation[J]. *International Journal of Ventilation*, 2022, 21(4): 316-329.
- [8] LI Junqiao, LI Yucheng, ZHANG Wei, et al. Multi-objective intelligent decision and linkage control algorithm for mine ventilation[J]. *Energies*, 2022, 15(21). DOI: [10.3390/en15217980](https://doi.org/10.3390/en15217980).
- [9] 吴新忠, 张芝超, 王凯, 等. 基于 DE-GWO 算法的矿井风网风量调节方法[J]. *中南大学学报(自然科学版)*, 2021, 52(11): 3981-3989.
- WU Xinzong, ZHANG Zhichao, WANG Kai, et al. Method for adjusting air volume of mine ventilation network based on DE-GWO algorithm[J]. *Journal of Central South University (Science and Technology)*, 2021, 52(11): 3981-3989.
- [10] 许嘉琳. 改进鲸鱼算法在矿井风量智能调控中的研究[D]. 徐州: 中国矿业大学, 2023.
- XU Jialin. Research on improved whale algorithm in intelligent regulation of mine air volume[D]. Xuzhou: China University of Mining and Technology, 2023.
- [11] 孙小玲, 李端. 整数规划[M]. 北京: 科学出版社, 2010.
- SUN Xiaoling, LI Duan. *Integer programming*[M]. Beijing: Science Press, 2010.
- [12] 张步忠, 程玉胜, 王一宾. 求解 N 皇后问题的片上多核并行混合遗传算法[J]. *计算机工程*, 2015, 41(7): 199-203.
- ZHANG Buzhong, CHENG Yusheng, WANG Yibin. On-chip multi-core parallel hybrid genetic algorithm for solving N-Queens problem[J]. *Computer Engineering*, 2015, 41(7): 199-203.
- [13] 王燕军, 梁治安, 崔雪婷. 最优化基础理论与方法[M]. 2 版. 上海: 复旦大学出版社, 2018.
- WANG Yanjun, LIANG Zhi'an, CUI Xueting. Basic theory and method of optimization[M]. 2nd ed. Shanghai: Fudan University Press, 2018.
- [14] CHENG Shi, SHI Yuhui, QIN Quande, et al. Population diversity maintenance in brain storm optimization algorithm[J]. *Journal of Artificial Intelligence and Soft Computing Research*, 2014, 4(2): 83-97.
- [15] 李伟, 霍永金, 张浪, 等. 矿井通风实时网络解算技术研究[J]. *中国矿业*, 2016, 25(3): 167-170.
- LI Wei, HUO Yongjin, ZHANG Lang, et al. Research on ventilation real time network solution[J]. *China Mining Magazine*, 2016, 25(3): 167-170.
- [16] 刘彦青. 基于巷道摩擦阻力系数 BP 神经网络预测模型的矿井风网风量预测研究[J]. *矿业安全与环保*, 2021, 48(2): 101-106.
- LIU Yanqing. Study on the air quantity of mine ventilation network based on BP neural network prediction model of friction resistance coefficient in roadway[J]. *Mining Safety & Environmental Protection*, 2021, 48(2): 101-106.
- [17] KARABOGA D, AKAY B. A comparative study of artificial bee colony algorithm[J]. *Applied Mathematics and Computation*, 2009, 214(1): 108-132.
- [18] YANG Jingyuan, CUI Jiangtao, XIA Xiaofang, et al. An artificial bee colony algorithm with an adaptive search strategy selection mechanism and its application on workload prediction[J]. *Computers & Industrial Engineering*, 2024, 189. DOI: [10.1016/j.cie.2024.109982](https://doi.org/10.1016/j.cie.2024.109982).
- [19] SHI Y, EBERHART R. A modified particle swarm optimizer[C]. *IEEE International Conference on Evolutionary Computation*, Anchorage, 1998: 69-73.
- [20] WANG Hui, WU Zhijian, RAHNAMAYAN S, et al. Enhancing particle swarm optimization using generalized opposition-based learning[J]. *Information Sciences*, 2011, 181(20): 4699-4714.
- [21] ZHU Guopu, KWONG S. Gbest-guided artificial bee colony algorithm for numerical function optimization[J]. *Applied Mathematics and Computation*, 2010, 217(7): 3166-3173.
- [22] 周新宇, 吴志健, 邓长寿, 等. 一种邻域搜索的人工蜂群算法[J]. *中南大学学报(自然科学版)*, 2015, 46(2): 534-546.
- ZHOU Xinyu, WU Zhijian, DENG Changshou, et al. Neighborhood search-based artificial bee colony algorithm[J]. *Journal of Central South University (Science and Technology)*, 2015, 46(2): 534-546.