

# 控制与决策

Control and Decision

## 基于探采平衡的双搜索模式人工蜂群算法及其应用

王英聪, 李博, 孙军伟, 王延峰

引用本文:

王英聪, 李博, 孙军伟, 等. 基于探采平衡的双搜索模式人工蜂群算法及其应用[J]. 控制与决策, 2025, 40(2): 507–516.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2023.1727>

---

### 您可能感兴趣的其他文章

#### Articles you may be interested in

##### [求解约束优化问题的改进果蝇优化算法及其工程应用](#)

Improved fruit fly optimization algorithm for solving constrained optimization problems and engineering applications  
控制与决策. 2021, 36(2): 314–324 <https://doi.org/10.13195/j.kzyjc.2019.0557>

##### [基于多种群分解预测的动态多目标引力搜索算法](#)

Dynamic multi-objective gravitational searching algorithm based on multi-population decomposition prediction  
控制与决策. 2021, 36(12): 2910–2918 <https://doi.org/10.13195/j.kzyjc.2020.1002>

##### [具有重组学习和混合变异的动态多种群粒子群优化算法](#)

Dynamic multi-population particle swarm optimization algorithm with recombined learning and hybrid mutation  
控制与决策. 2021, 36(12): 2871–2880 <https://doi.org/10.13195/j.kzyjc.2020.0898>

##### [基于解空间反向跳跃和信息交互强化的新型混合蛙跳算法](#)

A new shuffled frog leaping algorithm based on reverse leaping in solution space and information interaction enhancement  
控制与决策. 2021, 36(1): 105–114 <https://doi.org/10.13195/j.kzyjc.2019.0719>

##### [基于阈值搜索的多目标人工蜂群算法](#)

A multi-objective artificial bee colony based on limit search strategy  
控制与决策. 2020, 35(8): 1793–1802 <https://doi.org/10.13195/j.kzyjc.2018.1512>

# 基于探采平衡的双搜索模式人工蜂群算法及其应用

王英聪, 李 博, 孙军伟, 王延峰<sup>†</sup>

(郑州轻工业大学 电气信息工程学院, 郑州 450002)

**摘要:** 人工蜂群算法具有结构简单、易于实现等优点,但由于其探索能力较强而开采能力较弱,同时也存在求解精度较低和收敛速度较慢等不足之处,提出一种基于探采平衡的双搜索模式人工蜂群算法,包含探采控制、探采执行和探采强化3个核心模块.在探采控制阶段,根据种群以探索为主并逐渐偏向开采的演化规律设计探采指标;在探采执行阶段,根据探索与开采的实现要点设计基于差异解信息引导的搜索方程;在探采强化阶段,令跟随蜂分别按照多样性排序和目标值排序选择优质食物源继续搜索.选取传统测试函数和CEC2013测试函数进行数值实验,并与8种近年来提出的高水平人工蜂群算法进行对比,结果表明所提出算法在解质量和收敛速度等方面有较强的竞争力.最后将所提出算法用于食管癌发病风险预测模型优化,获得了满意的结果.

**关键词:** 人工蜂群算法; 探采平衡; 函数优化; 食管癌预测

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2023.1727

引用格式: 王英聪, 李博, 孙军伟, 等. 基于探采平衡的双搜索模式人工蜂群算法及其应用[J]. 控制与决策, 2025, 40(2): 507-516.

## Dual search mode artificial bee colony algorithm based on exploration-exploitation tradeoff and its application

WANG Ying-cong, LI Bo, SUN Jun-wei, WANG Yan-feng<sup>†</sup>

(School of Electrical and Information Engineering, Zhengzhou University of Light Industry, Zhengzhou 450002, China)

**Abstract:** The artificial bee colony algorithm has the advantages of a simple structure and easy implementation. However, due to its strong exploration ability and weak exploitation capability, it also suffers from drawbacks such as low solution accuracy and slow convergence speed. To solve these problems, this paper proposes a dual search mode artificial bee colony algorithm based on exploration-exploitation tradeoff, which includes three core modules: exploration-exploitation control, exploration-exploitation execution, and exploration-exploitation reinforcement. In the control stage, we design an exploration-exploitation indicator based on the population's evolutionary dynamics, which initially emphasizes exploration and gradually shifts towards exploitation. In the execution stage, we design search equations guided by differential solution information, with a focus on the implementation points of exploration and exploitation. In the enhancement stage, the onlooker bees are instructed to select high-quality food sources for further search, using criteria such as diversity ranking and fitness ranking. Numerical experiments are conducted on traditional test functions and CEC2013 test functions. The results demonstrate that compared with eight high-level artificial bee colony algorithms proposed in recent years, the proposed algorithm exhibits strong competitiveness in terms of solution quality and convergence speed. Finally, the proposed algorithm is applied to optimize the risk prediction model for esophageal cancer, yielding satisfactory results.

**Keywords:** artificial bee colony algorithm; exploration-exploitation tradeoff; function optimization; esophageal cancer prediction

## 0 引言

传统的梯度下降等方法在解决复杂优化问题时难以获得令人满意的结果.为此,受自然界中进化规

律和集群行为等启发,研究者们提出了一系列基于种群搜索的智能优化算法,大致分为演化算法和群智能算法两类.遗传算法<sup>[1]</sup>和差分进化算法<sup>[2]</sup>是演化算

收稿日期: 2023-12-12; 录用日期: 2024-04-16.

基金项目: 国家自然科学基金项目(U1804262); 中原千人计划项目(204200510003); 河南省科技攻关项目(232102210012, 232102220053).

责任编辑: 阳春华.

<sup>†</sup>通讯作者. E-mail: yanfengwang@yeah.net.

法的典型代表,在搜索过程中强调适者生存.蚁群算法<sup>[3]</sup>和粒子群算法<sup>[4]</sup>是群智能算法的典型代表,在搜索过程中强调个体学习.与传统优化方法相比,这些算法具有与初始值无关、不依赖梯度信息、对函数要求低、求解性能良好等特点.

人工蜂群(artificial bee colony, ABC)算法是一种模拟自然界中蜂群觅食行为的群智能算法<sup>[5]</sup>,通过雇佣蜂、跟随蜂和侦查蜂的分工协作完成搜索任务,具有结构简单、易于实现、鲁棒性强和控制参数少等优点.同时,与遗传算法、差分进化算法、蚁群算法和粒子群算法相比,ABC算法在寻优能力和算法精度方面都具有较强的竞争力<sup>[6]</sup>,目前已在设施选址、卫星定位、软件测试等领域展现出了很高的潜力和竞争力<sup>[7]</sup>.

研究表明<sup>[8]</sup>,传统ABC算法存在探索能力较强而开采能力较弱的问题,导致其收敛速度较慢且收敛精度较低.研究者们针对这一不足提出了许多改进策略,大致可以分为3类<sup>[9]</sup>:解搜索方程的改进、多搜索策略的使用、与其他算法的混合.虽然上述策略提高了传统ABC算法的性能,但早熟收敛、探索和开采不平衡的问题仍然存在.为此,本文从探采控制、探采执行和探采强化3个方面出发,提出一种基于探采平衡的双搜索模式人工蜂群算法(dual search mode artificial bee colony algorithm based on exploration-exploitation tradeoff, DSMABC).

本文主要贡献如下:1)设计一种基于种群演化的探采控制策略,使得种群在前期侧重探索,中期兼顾探索与开采,后期偏向开采;2)设计一种基于信息引导的探采执行策略,引入随机解和邻域解信息实现种群探索,利用精英解和最优解信息引导种群开采;3)设计一种基于排序选择的探采强化策略,在跟随蜂阶段分别利用多样性排序和目标值排序增强探索和开采.在数值优化问题上的对比结果显示,本文算法在解质量、非参数检验和收敛速度3个方面有一定的优势.在食管癌预测问题上的对比结果显示,本文算法在准确率、敏感性、特异性和 $F_1$ 分数4个方面有较强的竞争力.

## 1 基本ABC算法

ABC算法模仿蜂群的觅食行为来解决优化问题,其中蜜蜂的食物来源代表优化问题的解,食物源的蜜量对应解的质量<sup>[5]</sup>.求解优化问题时,ABC算法从初始化开始,然后进入3种蜜蜂的循环搜索阶段,直至满足停止条件为止.

### 1.1 初始化阶段

与其他基于种群搜索的算法一样,ABC算法采用随机方式初始化种群.设食物源(雇佣蜂或跟随蜂)的个数为SN,搜索空间的维数为 $D$ ,则食物源 $X_i = (x_{i1}, x_{i1}, \dots, x_{iD})$ 对应问题的一个解.按照下式生成 $X_i$ :

$$x_{ij} = x_{ij}^{\min} + \text{rand}(x_j^{\max} - x_j^{\min}). \quad (1)$$

其中: $i = 1, 2, \dots, \text{SN}$ ;  $j = 1, 2, \dots, D$ ;  $x_j^{\min}$ 和 $x_j^{\max}$ 分别为第 $j$ 维分量的下界和上界;rand为 $[0, 1]$ 之间均匀分布的随机数.

### 1.2 雇佣蜂阶段

对于每一只雇佣蜂,其都在对应的食物源 $X_i$ 附近,按照下式搜索一个新的食物源 $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ :

$$v_{ij} = x_{ij} + \varphi_{ij}(x_{ij} - x_{kj}). \quad (2)$$

其中: $k, j$ 为随机选取的下标,满足 $k \in (1, 2, \dots, \text{SN})$ ,  $j \in (1, 2, \dots, D)$ ,  $k \neq i$ ;  $\varphi_{ij}$ 为 $[-1, 1]$ 之间均匀分布的随机数.若 $V_i$ 优于 $X_i$ ,说明食物源得到改进,则 $V_i$ 代替 $X_i$ ;反之,说明食物源未得到改进,保留 $X_i$ 不变.

### 1.3 跟随蜂阶段

当所有雇佣蜂都进行一次搜索后,它们会通过摇摆舞向跟随蜂分享食物源信息.跟随蜂将选择较优的食物源继续搜索,且适应度越高的食物源被选择的概率越大.与食物源 $X_i$ 对应的选择概率为

$$P_i = \text{fit}_i / \sum_{m=1}^{\text{SN}} \text{fit}_m, \quad (3)$$

其中 $\text{fit}_i$ 为食物源 $X_i$ 的适应度.一旦 $X_i$ 被选中,则跟随蜂将按照式(2)搜索一个新的食物源 $V_i$ ,并在二者之间进行贪婪选择.

### 1.4 侦查蜂阶段

如果雇佣蜂对应的食物源连续limit次未得到改进,则表明该食物源已被耗尽.此时,雇佣蜂将转变为侦查蜂,根据式(1)在搜索空间内重新生成一个新的食物源.除了种群规模和搜索次数这两个公共参数外,limit是ABC算法中唯一的控制参数.

## 2 基于探采平衡的双搜索模式ABC算法

### 2.1 改进思路

针对传统ABC算法中探索与开采的不平衡以及由此导致的求解精度较低和收敛速度较慢等问题,本文提出一种基于探采平衡的双搜索模式ABC(DSMABC)算法.DSMABC算法在执行过程中依次包含探采控制、探采执行和探采强化3个模块,如图1所示.首先,根据演化规律设计探采指标,以概

率的形式决定种群执行探索还是开采;其次,采用多信息引导的方式设计搜索方程,分别实现探索和开采;最后,为跟随蜂设计基于多样性和目标值排序的食物源选择策略,进一步强化探索和开采.




图1 DSMABC算法核心思路

### 2.2 基于种群演化的探采控制策略

对基于种群搜索的算法而言,调整搜索方程中的参数值是控制探索与开采的一种有效手段.比如,Shi等<sup>[10]</sup>令粒子群算法搜索方程中的惯性权重随迭代次数线性减小,使得算法在初期具有较强的探索能力,在后期具有较强的开采能力. Mirjalili等<sup>[11]</sup>在设计鲸鱼优化算法时,令搜索方程中的距离控制参数  $a$  随着迭代次数增加从2减小到0 ( $a \geq 1$ 时处于探索阶段,  $a < 1$ 时处于开采阶段). Han等<sup>[12]</sup>引入惯性权重  $\zeta$ 改进人工蜂群算法的搜索方程时,令其随着迭代次数增加从0.9减至0.4 ( $\zeta$ 大时探索能力强,  $\zeta$ 小时开采能力强). 上述研究表明,算法在前期应侧重探索,后期应偏向开采. 受此启发,本文设计如下基于种群演化的探采指标:

$$f(t) = 1 - (t/\text{Max}_t)^\gamma. \quad (4)$$

其中:  $t$  为当前迭代次数,  $\text{Max}_t$  为最大迭代次数,  $\gamma$  为衰减系数.

利用探采指标进一步设计如下控制策略:

$$\begin{cases} \text{rand} \leq f(t), \text{第}t\text{次迭代进行探索;} \\ \text{rand} > f(t), \text{第}t\text{次迭代进行开采.} \end{cases} \quad (5)$$

其中  $\text{rand}$  为  $[0, 1]$  之间的随机数. 由式(4)和(5)可知,探索与开采将贯穿整个搜索过程,其中前期以较大概率执行探索,中期兼顾二者,后期以较大概率进行开采,如图2所示.




图2 种群演化视角下的探采选择

### 2.3 基于信息引导的探采执行策略

Chen等<sup>[13]</sup>指出,探索是不依赖经验获取信息的搜索过程,开采是依赖经验利用信息的搜索过程. 由于随机解信息较少依赖于历史经验,而最优解信息是搜索经验的直接体现,学者们经常利用随机解信息指引探索,使用最优解信息引导开采<sup>[14]</sup>. 然而,过度依赖随机解会导致随机搜索,过度依赖最优解会造成早熟收敛. Cui等<sup>[15]</sup>利用精英解平衡最优解过大的引导作用,取得了较好的效果. 杜振鑫等<sup>[16]</sup>在搜索方程中综合考虑随机解、精英解和最优解,达到了兼顾加速收敛与避免早熟的目的. 从解的质量看,一般满足随机解 < 精英解 < 最优解,也大致满足随机解 < 邻域最优解 < 精英解 < 最优解. 考虑到精英解能用于平衡最优解,利用邻域最优解平衡随机解也具有一定的合理性. 受此启发,本文设计了如图3所示的探索/开采实现方式,其主要思路是:在探索过程中利用邻域最优解平衡随机解的引导作用,在开采过程中利用精英解平衡最优解的引导作用.




图3 不同解信息引导的探采实现

具体地,种群在探索模式下按照式(6)搜索一个新的食物源  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ ,有

$$v_{i,j} = x_{nbest,j} + \varphi_{ij}(x_{nbest,j} - x_{k,j}). \quad (6)$$

其中:  $X_{nbest}$  为  $X_i$  随机选择的5个邻居中的最优解;  $k, j$  为随机选取的下标,且满足  $k \in (1, 2, \dots, \text{SN}), j \in (1, 2, \dots, D), k \neq i; \varphi_{ij}$  为  $[-1, 1]$  之间的随机数.

种群在开采模式下按照下式搜索一个新的食物源  $V_i = (v_{i1}, v_{i2}, \dots, v_{iD})$ :

$$v_{i,j} = x_{e,j} + \varphi_{ej}(x_{e,j} - x_{k,j}) + \psi_{ij}(x_{gbest,j} - x_{e,j}). \quad (7)$$

其中:  $X_e$  为从种群中最好的5个个体中随机选择的精英解,  $X_{gbest}$  为当前最优解;  $k, j$  为随机选取的上下标,且满足  $k \in (1, 2, \dots, \text{SN}), j \in (1, 2, \dots, D), k \neq e; \varphi_{ej}$  为  $[-1, 1]$  之间的随机数;  $\psi_{ij}$  为  $[0, 1.5]$  之间的随机数. 此外, Ye等<sup>[17]</sup>指出,在探索阶段进行低维扰动有助于搜索整个空间,在开采阶段进行高维扰动有助于加速收敛. 受此启发,种群探索时执行单维搜索,开采时在  $[0, D/3]$  之间随机选取一个整数进行多维搜索.

## 2.4 基于排序选择的探采强化策略

Črepinšek 等<sup>[18]</sup>指出,探索与种群多样性正相关,多样性好表明算法探索能力强. Zhou 等<sup>[19]</sup>认为开采依赖于对最优或精英解的利用程度. 在传统ABC算法中,食物源的质量越好,被跟随蜂选中的概率越大,这种正反馈行为起到强化搜索的作用. 双模式搜索下一个自然的想法是:种群在探索模式下,令跟随蜂强化探索;种群在开采模式下,令跟随蜂强化开采. 考虑到探索与种群多样性正相关,开采与优良解的利用程度有关,一个可行的方法是:探索时令跟随蜂基于多样性选择食物源,开采时令跟随蜂基于目标值选择食物源.

在传统ABC算法中,跟随蜂根据适应度选择食物源. 适应度是目标值的反比例转换,该选择过程本质上是在强化开采. 然而,适应度的选择具有如下不足:当适应度差异较大时,会出现具有很大选择概率的超级个体,这使得算法容易陷入局部最优;当适应度差异较小时,所有个体的选择概率基本相同,这会导致算法收敛能力下降. 本文提出了基于适应度排序的选择方法,一定程度上解决了上述问题,但仍有两个局限性:当种群规模较大(如常见的50个个体)时,对除最优个体以外的其他优秀个体考虑不足;当函数值整体过大或过小时,对应的适应度差别不大,等同于随机选择. 为此,本文提出基于top5目标值排序的选择方法,一方面可以降低超级个体影响,防止早熟收敛现象的发生,另一方面能够增加优秀个体影响,从而避免随机搜索的趋势.

同样地,令跟随蜂采用基于top5多样性排序的选择方法来强化探索. 多样性反映了种群的分布情况,一般通过个体之间的差异来度量. 一种直接的方法是计算个体位置的差异(即个体之间的距离),但存在计算成本高的问题. 为了能够简单且有效地度量多样性,Cheng 等<sup>[20]</sup>设计了一种基于个体目标值的间接计算方法. 根据该方法,个体*i*的多样性为

$$d_i = |f_i - f_{\text{mid}}|. \quad (8)$$

其中: $f_i$ 为个体*i*的目标值, $f_{\text{mid}}$ 为中位个体的目标值.

## 2.5 算法流程

相较于传统的ABC算法,DSMABC算法的改进主要在于采用了双模式搜索,具体体现在以下3个方面:1)根据种群演化规律选择探索或开采搜索;2)利用探索和开采的特点设计相应搜索方程;3)在传统ABC算法的简易框架下进一步强化探索与开采. DSMABC算法流程如下.

step 1: 初始化参数SN、limit、 $\text{Max}_t$ 和 $\gamma$ ;

step 2: 根据式(1)建立初始种群;

step 3: 根据式(4)计算探采指标;

step 4: 根据式(5)确定探采模式;

step 5: 若种群执行探索,则令雇佣蜂和跟随蜂按照式(6)搜索新的食物源,其中跟随蜂基于top5多样性排序选择优质食物源;

step 6: 若种群执行开采,则令雇佣蜂和跟随蜂按照式(7)搜索相对食物源,其中跟随蜂基于top5目标值排序选择优质食物源;

step 7: 若蜜蜂的食物源连续limit次没有改进,则蜜蜂转化为侦查蜂,根据式(1)随机初始化一个食物源;

step 8: 记录全局最优值,若满足终止条件,则输出最优解和最优值,否则返回step 3.

## 3 数值实验

本节选取传统测试函数<sup>[21]</sup>和CEC2013测试集<sup>[22]</sup>对DSMABC算法进行数值实验,并与其他改进ABC算法做对比,以验证DSMABC算法的性能.

### 3.1 $\gamma$ 参数分析

考虑到传统测试函数具有明显的特点,适合用来研究算法中策略或参数的影响,本节选取其中部分函数( $f_1, f_2, f_7, f_8, f_{13}, f_{14}, f_{17}, f_{18}$ )对 $\gamma$ 进行敏感性分析.  $\gamma$ 为探采指标 $f(t)$ 中的衰减系数,用于控制算法的探采平衡. 由式(4)可知,随着迭代次数的增加,算法逐渐由探索为主转向开采为主, $\gamma$ 则控制这一转换过程. 具体而言, $\gamma$ 越大, $f(t)$ 衰减越慢,探索持续的时间越长; $\gamma$ 越小, $f(t)$ 衰减越快,算法越早转入开采阶段.

实验设置如下:选取 $\gamma = 0.1, 0.3, 0.5, 0.7, 0.9, 1.1, 1.5, 2, 2.5$ 这9个典型值进行实验,函数维度 $D = 30$ ,种群规模 $\text{SN} = 50$ ,函数最大评估次数 $\text{MaxFes} = 5000D$ . DSMABC算法独立运行30次的实验结果如表1所示. 可以看出,对于一些单峰函数(如 $f_1, f_2$ ), $\gamma$ 取值越小,DSMABC算法表现越好;而对于一些多峰函数(如 $f_{13}, f_{14}$ ),DSMABC算法的表现则相反,其倾向于较大的 $\gamma$ 取值. 可能的原因是:对于单峰函数,一般需要充分利用优秀解来加速收敛. 当 $\gamma$ 取值较大时,算法过多地受随机解引导,导致收敛速度下降. 对于多峰函数,前期一般需要较多的探索,以发现更有前景的解. 当 $\gamma$ 取值较小时,算法探索不足,容易陷入局部最优. 此外,从表1中还可以看出, $\gamma$ 的取值对于一些函数不敏感(如 $f_7, f_8$ ),这可能与搜索方程的改进有关,也可能与函数有关. 实际上,这种情况经常发生,如文献[21]中的邻域大小控制参数 $k$ 对 $f_7, f_8$ 等函数并不敏感. 综合考虑下,本文设置 $\gamma = 0.1$ .

表1  $\gamma$ 取不同值时DSMABC算法在传统测试集上的实验结果

函数		$\gamma = 0.1$	$\gamma = 0.3$	$\gamma = 0.5$	$\gamma = 0.7$	$\gamma = 0.9$	$\gamma = 1.1$	$\gamma = 1.5$	$\gamma = 2$	$\gamma = 2.5$
$f_1$	Mean	5.97e-116	3.20e-111	1.27e-107	5.89e-104	2.25e-101	6.21e-99	5.09e-94	4.24e-89	2.66e-87
	Std	1.22e-115	7.23e-111	4.65e-107	1.55e-103	5.07e-101	1.51e-98	1.59e-93	2.04e-88	5.11e-87
$f_2$	Mean	7.63e-113	3.43e-108	1.20e-103	6.80e-101	1.80e-97	2.88e-95	7.12e-91	5.01e-87	5.86e-84
	Std	1.61e-112	9.94e-108	2.74e-103	1.18e-100	5.46e-97	5.03e-95	1.69e-90	1.52e-86	2.38e-83
$f_7$	Mean	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00
	Std	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00
$f_8$	Mean	7.18e-66	7.18e-66	7.18e-66	7.18e-66	7.18e-66	7.18e-66	7.18e-66	7.18e-66	7.18e-66
	Std	3.22e-81	3.22e-81	3.22e-81	3.22e-81	3.22e-81	3.22e-81	3.22e-81	3.22e-81	3.22e-81
$f_{13}$	Mean	6.23e-03	5.25e-03	3.12e-03	2.71e-03	9.03e-04	0.00e+00	0.00e+00	0.00e+00	0.00e+00
	Std	1.02e-02	7.91e-03	7.80e-03	5.50e-03	3.57e-03	0.00e+00	0.00e+00	0.00e+00	0.00e+00
$f_{14}$	Mean	7.90e+00	3.95e+00	3.95e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00
	Std	3.00e+01	2.16e+00	2.16e+01	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00
$f_{17}$	Mean	1.54e-33	1.50e-33	1.50e-33	1.50e-33	1.50e-33	1.50e-33	1.50e-33	1.50e-33	1.50e-33
	Std	2.25e-34	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00	0.00e+00
$f_{18}$	Mean	3.44e-15	1.51e-15	8.79e-16	4.02e-16	3.26e-16	1.63e-16	3.98e-16	3.42e-16	7.07e-16
	Std	2.26e-15	1.84e-15	1.07e-15	9.10e-16	6.23e-16	4.35e-16	9.14e-16	1.14e-15	1.81e-15

表2  $D = 30$ 时各算法在传统测试集上的实验结果

统计检验	检验结果	ABC	GABC	NABC	REABC	BENABC	KFABC	NSABC	RNSABC	DSMABC
Mean/std	+ / = / -	18/2/2	16/4/2	9/9/3	9/9/4	11/9/2	12/8/2	12/8/2	11/8/3	- / - / -
Friedman test	Mean ranking	8.11	6.51	5.07	4.95	3.93	4.36	4.35	4.57	3.08
Wilcoxon test	$R^+$	203.5	187	150	143	172	168	169	161	-
	$R^-$	49.5	66	103	110	81	85	84	92	-
	$p$ -value	2.00E-03	4.00e-03	1.01e-01	2.49e-01	1.00e-03	9.00e-03	8.00e-03	3.00e-02	-

表3  $D = 100$ 时各算法在传统测试集上的实验结果

统计检验	检验结果	ABC	GABC	NABC	REABC	BENABC	KFABC	NSABC	RNSABC	DSMABC
Mean/std	+ / = / -	20/1/1	18/2/2	12/4/6	13/4/5	15/4/3	15/3/4	17/3/2	13/4/5	- / - / -
Friedman test	Mean ranking	8.43	6.89	4.91	4.22	4.09	4.13	5.30	4.32	2.79
Wilcoxon test	$R^+$	213.5	202.5	150	150	182	172	188	169	-
	$R^-$	39.5	50.5	103	103	71	81	65	84	-
	$p$ -value	1.00e-03	2.00e-03	3.81e-01	3.81e-01	9.00e-03	4.80e-02	7.00e-03	6.40e-02	-

3.2 与其他改进ABC算法在第1个测试集上比较

为了测试 DSMABC 的性能, 选择 ABC<sup>[5]</sup>、GABC<sup>[23]</sup>、NABC<sup>[24]</sup>、REABC<sup>[25]</sup>、BENABC<sup>[26]</sup>、KFABC<sup>[27]</sup>、NSABC<sup>[21]</sup>和RNSABC<sup>[22]</sup>等8种近年来提出的国内外具有代表性的ABC作为对比算法. 为确保对比公平, 统一设置各算法的公共参数(SN = 50, limit = 100), 其余参数与原文献相同. 对于第1个测试集, 选择函数维度  $D = 30$ 和100, 函数最大评价次数MaxFEs = 5000D. 所有算法独立运行30次, 从均值与标准差、非参数检验和收敛速度3个

方面展开对比, 结果如表2、表3和图4所示.

表2给出了各算法在函数维度为30时的对比情况, 包括基于平均值和标准差的解质量对比与基于非参数检验的综合对比. 在进行解质量对比时, “+” “-” “=” 分别表示DSMABC算法的结果优于、劣于、相当于对比算法, 且最好结果以粗体显示. 从表2可以看出, DSMABC在17个函数上找到了最好的结果, 而在剩余5个函数上的表现也达到了中等以上水平. 进一步地, DSMABC分别在18、16、9、9、11、12、12、11个函数上优于ABC、GABC、NABC、

REABC、BENABC、KFABC、NSABC和RNSABC,而只在2~4个函数上差于这些算法.为了确保对比结果具有统计意义,采用Friedman和Wilcoxon两种非参数检验方法. Friedman检验以平均排名的方式给出算法的整体性能,排名值越小表明算法性能越好.表2的检验结果表明,DSMABC在所有算法中排名第一. Wilcoxon检验DSMABC与其他算法是否

存在显著差异,显著性水平设置为0.05,检验结果以“ $R^+$ ”“ $R^-$ ”和“ $p$ -value”的形式给出.其中:“ $R^+$ ”代表DSMABC在优势函数上的秩和,“ $R^-$ ”代表在劣势函数上的秩和.表2的检验结果表明,DSMABC在所有对比情况下所获得的“ $R^+$ ”均大于“ $R^-$ ”,且“ $p$ -value”均小于0.05,表明所提出算法显著优于对比算法.

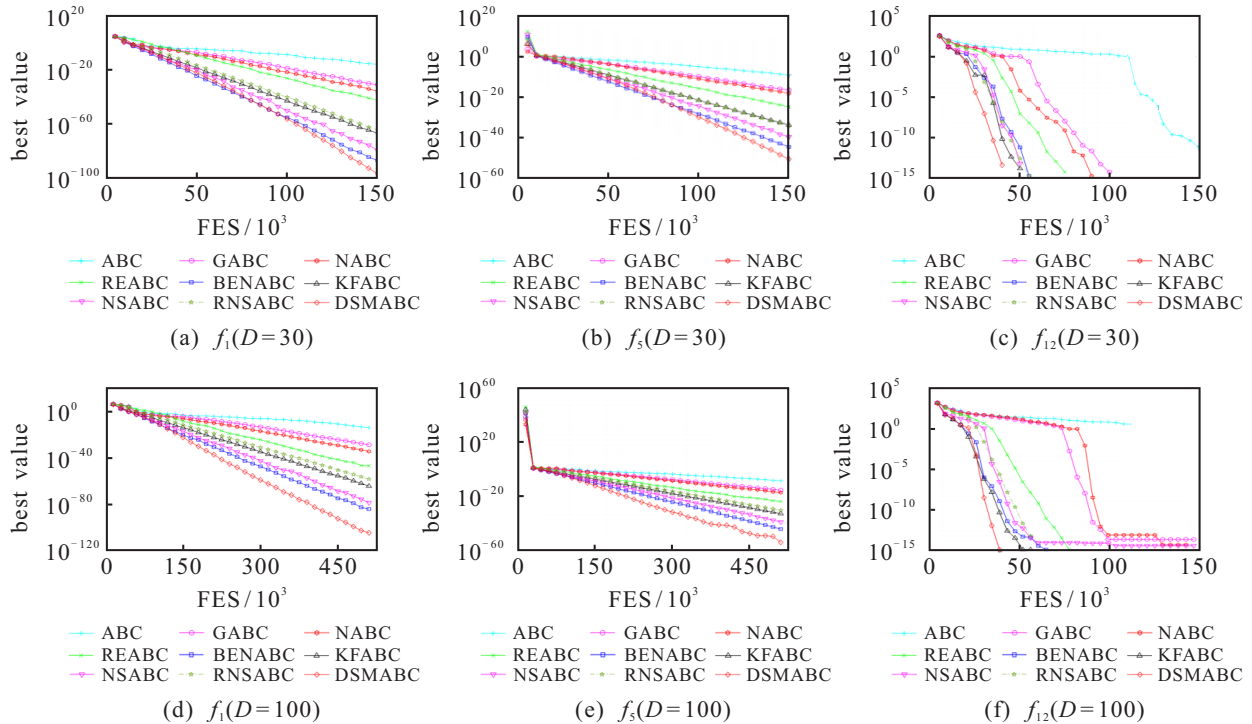


图4 所有算法在3个代表性传统测试函数的收敛曲线

表3给出了各算法在函数维度为100时的测试结果.对比表2和表3可以发现,函数维度由30增至100以后,对DSMABC与其他算法的性能对比影响不大.在解质量对比方面,DSMABC至少在12个函数上的表现优于对比算法,而最多在6个函数上表现不及对比算法.对于DSMABC未取得最优解的函数,其在大部分情况下表现出中等以上水平.在综合对比方面,Friedman检验时所有算法的排序结果为 $DSMABC < BENABC < KFABC < REABC < RNSABC < NABC < NSABC < GABC < ABC$ ,即DSMABC的整体性能排名第一. Wilcoxon检验时,DSMABC对比8个算法所得“ $R^+$ ”均大于“ $R^-$ ”,且“ $p$ -value”均小于0.05,表明DSMABC与这些算法存在显著性差异,即DSMABC优于这些算法.

为了更直观地显示本文算法的收敛速度,图4绘制了各算法在部分函数 $D = 30$ 和 $D = 100$ 下的收敛曲线(横轴为函数评价次数,纵轴为最优目标值).限于篇幅,仅选取 $f_1$ 、 $f_5$ 和 $f_{12}$ 三个函数.对于其

他大部分函数,也能得到类似的结果.由图4可见,对于不同类型的测试函数,DSMABC均具有较好的收敛性能.具体而言,对于函数 $f_1$ 和 $f_5$ ,DSMABC表现出最快的收敛速度和最高的收敛精度.换句话说,DSMABC在相同函数评价次数下能找到更好的解,或者DSMABC找到一定精度的解所需要的函数评价次数最少.对于函数 $f_{12}$ ,8个改进ABC算法均在 $D = 30$ 时找到了理论最优值0,REABC、BENABC、RNSABC和DSMABC则在 $D = 100$ 时找到了理论最优值0,但是DSMABC所需要的函数评价次数最少,即收敛速度最快(图中纵轴采用对数坐标轴,没有显示0).

### 3.3 与其他改进ABC算法在第2个测试集上比较

为了进一步测试DSMABC的性能,在CEC2013测试集上继续实验.选择函数维度 $D = 30$ 和 $D = 100$ ,各算法参数设置同上,基于51次独立运行的实验结果如表4、表5和图5所示.

从均值和标准差来看:在30维时,DSMABC在8

个函数上找到了最好结果,同时分别在19、18、15、16、18、14、12、16个函数上优于ABC、GABC、NABC、REABC、BENABC、KFABC、NSABC和RNSABC. 在100维时,DSMABC在13个函数上找到了最好结果,同时在23个函数上优于ABC和GABC,在20个函数上优于BENABC和KFABC,在18个函数上优于NABC、REABC和RNSABC,在15个函数上优于NSABC. 对于DSMABC未取得最好结果的函数,其在大部分情况下的表现处于中上水平.

从统计检验来看:由Friedman检验结果可知,对

于函数  $D = 30$  和  $D = 100$ ,DSMABC在9个算法中分别排名第三和第二,表明DSMABC算法的整体性能具有较强的竞争力. 由Wilcoxon检验结果可知,对于函数  $D = 30$  和  $D = 100$ ,DSMABC与ABC、GABC、REABC、BENABC相比所获得的“ $R^+$ ”均大于“ $R^-$ ”,且“ $p$ -value”均小于0.05,表明DSMABC显著优于这4种算法. 对于剩余4种算法,DSMABC在对比时所得“ $p$ -value”均大于0.05,说明DSMABC与NABC、KFABC、NSABC和RNSABC没有显著性差异,即算法性能相当.

表4  $D = 30$ 时各算法在CEC2013测试集上的实验结果

统计检验	检验结果	ABC	GABC	NABC	REABC	BENABC	KFABC	NSABC	RNSABC	DSMABC
Mean/std	+ / = / -	22/0/6	21/0/7	16/0/12	19/0/9	21/1/6	16/0/12	13/0/15	18/0/10	- / - / -
Friedman test	Mean ranking	6.77	10.27	4.41	5.61	4.71	3.87	3.19	4.98	4.32
Wilcoxon test	$R^+$	297.5	305.5	216	275	282	222	189	262.5	-
	$R^-$	108.5	100.5	190	131	124	184	218	143.5	-
	$p$ -value	1.10e-02	9.00e-03	7.41e-01	4.00e-02	1.60e-02	5.87e-02	6.89e-01	1.31e-01	-

表5  $D = 100$ 时各算法在CEC2013测试集上的实验结果

统计检验	检验结果	ABC	GABC	NABC	REABC	BENABC	KFABC	NSABC	RNSABC	DSMABC
Mean/std	+ / = / -	23/0/5	24/0/4	18/1/9	19/1/8	21/0/7	20/0/8	15/0/13	19/0/9	- / - / -
Friedman test	Mean ranking	6.96	7.30	4.43	5.63	5.15	3.86	3.13	4.89	3.66
Wilcoxon test	$R^+$	319	334	265	298	307	276	190	275	-
	$R^-$	87	72	141	108	99	130	216	131	-
	$p$ -value	5.00e-03	2.00e-03	1.36e-01	2.20e-02	1.20e-02	7.90e-02	7.55e-01	8.40e-01	-

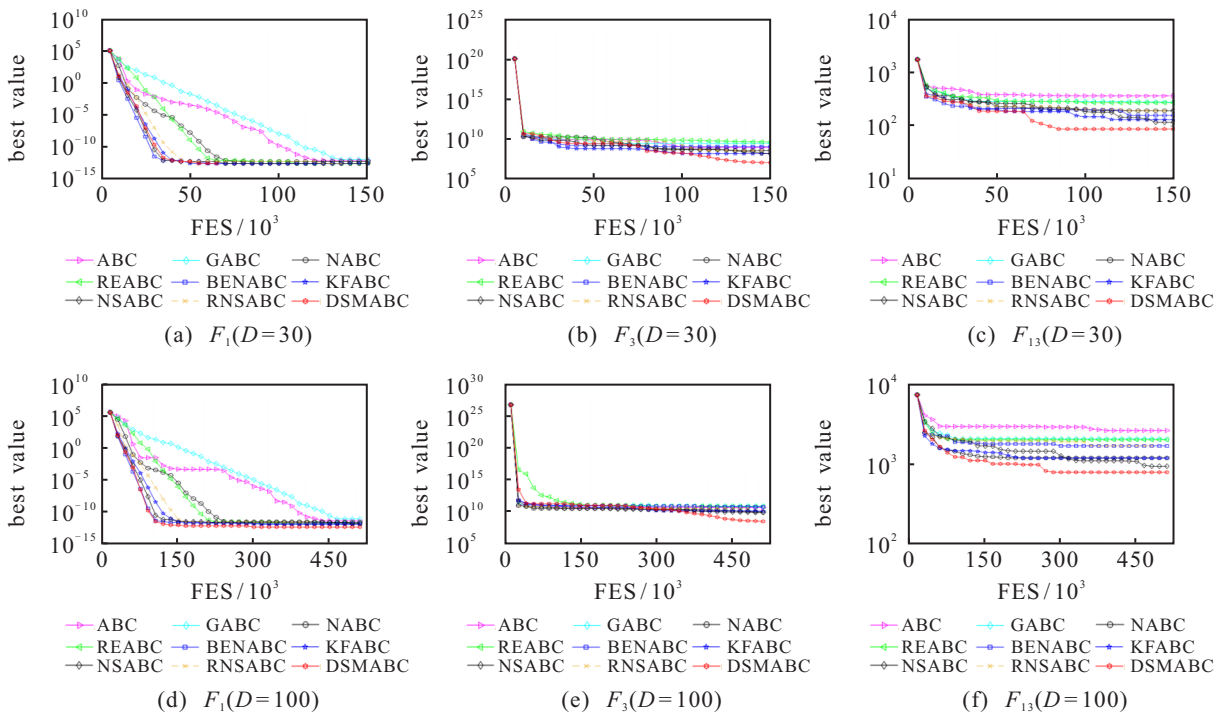


图5 所有算法在3个代表性CEC2013测试函数的收敛曲线

图5绘制了所有算法在3个代表性函数上的收敛曲线,可以看出DSMABC的整体收敛性能较好.对于函数 $F_1$ ,DSMABC在前期能快速收敛到最优解附近;对于函数 $F_3$ ,DSMABC在后期仍具有一定的收敛能力;对于函数 $F_{13}$ ,DSMABC在整个过程中都表现出较快的收敛速度.

#### 4 食管癌发病风险预测

为了验证DSMABC算法在实际问题中的优化效果,进一步将其应用于食管癌发病风险预测模型的优化.首先利用蛋白质样本数据和支持向量机(support vector machine, SVM)建立食管癌发病风险预测模型,然后利用DSMABC算法对SVM进行参数寻优,并与其他改进ABC算法进行对比.

##### 4.1 DSMABC-SVM预测模型

所用蛋白质样本来自郑州大学省部共建食管癌防治国家重点实验室,包含60例食管癌患者和60例正常人.每个样本包含23 035个蛋白质数据,通过构建蛋白质相互作用网络识别关键蛋白,筛选出81个食管癌潜在标志物.选择高斯核函数构建基于SVM的食管癌发病风险预测模型,此时,模型性能主要取决于惩罚参数 $c$ 和核参数 $g$ .其中: $c$ 影响模型的拟合程度, $g$ 决定原始特征空间映射到高维特征空间的分布情况.为了寻找最优的 $c$ 和 $g$ ,利用DSMABC算法进行参数寻优.在具体优化过程中,SVM模型的输入为81个食管癌标志物,输出为患病或正常,目标函数为预测准确率,有

$$\max f(c, g) = \frac{TP + TN}{TP + FP + FN + TN}. \quad (9)$$

其中:TP表示实际为患病且预测也是患病的样本个数,FP表示实际为正常而预测是患病的样本个数,FN表示实际为患病而预测是正常的样本个数,TN表示实际为正常且预测也是正常的样本个数.

##### 4.2 实验结果与分析

为了评估DSMABC-SVM预测模型的性能,将其与ABC<sup>[5]</sup>、GABC<sup>[23]</sup>、NABC<sup>[24]</sup>、REABC<sup>[25]</sup>、BENABC<sup>[26]</sup>、KFABC<sup>[27]</sup>、NSABC<sup>[21]</sup>和RNSABC<sup>[22]</sup>等8种算法优化的SVM模型进行对比.所有算法参数设置与上节保持一致,函数最大评价次数MaxFEs设为10 000.采用十折交叉验证进行实验,即将数据集随机等分成10份,轮流将其中9份作为训练数据,1份作为测试数据.除了准确率,医疗诊断预测领域还经常使用敏感性、特异性、 $F_1$ 分数等指标来评价预测效果.敏感性的计算公式为

$$\text{Sensitivity} = TP / (TP + FN),$$

代表模型从患者中准确分类出患者的能力.特异性的计算公式为

$$\text{Specificity} = TN / (TN + FP),$$

代表模型从正常人中准确分类出正常人的能力. $F_1$ 分数可以平衡模型的准确性和识别能力,使其兼顾正类别的识别率和负类别的识别率,有

$$F_1 = 2TP / (2TP + FP + FN).$$

表6为9种模型进行十折交叉验证后的平均预测结果.可以看出,DSMABC-SVM的预测结果在所有模型中排名第一.在准确率方面,DSMABC-SVM达到了88.33%,比排名第二的NSABC-SVM和ABC-SVM分别提高了7.07%和15.21%.在敏感性方面,DSMABC-SVM达到了85.60%,比排名第二的NSABC-SVM和ABC-SVM分别提高了10.21%和15.57%.在特异性方面,DSMABC-SVM达到了94.23%,比排名第二的RNSABC-SVM和ABC-SVM分别提高了1.54%和6.49%.在 $F_1$ 分数方面,DSMABC-SVM达到了87.53%,比排名第二的NSABC-SVM和ABC-SVM分别提高了10.43%和17.57%.为了进一步比较各模型的稳定性,图6绘制了十折交叉验证的预测结果分布.由图6可知,对于4种评价指标,从最大值、最小值、中位数及上下四分位数5个方面看,DSMABC算法在大部分情况下均优于其他ABC算法,表现出较好的预测稳定性.

表6 9种ABC-SVM预测模型的平均对比结果 %

模型	正确率	敏感性	特异性	$F_1$
ABC-SVM	76.67	74.07	88.49	74.45
GABC-SVM	72.50	71.61	87.15	69.91
NABC-SVM	78.33	73.43	90.93	74.19
REABC-SVM	80.00	74.52	91.90	78.06
BENABC-SVM	78.33	72.91	90.48	75.91
KFABC-SVM	75.83	76.63	86.81	73.75
NSABC-SVM	82.50	77.67	92.14	79.26
RNSABC-SVM	79.17	75.89	92.80	77.77
DSMABC-SVM	88.33	85.60	94.23	87.53

## 5 结论

对基于种群搜索的算法而言,探索与开采是一对矛盾但又必不可少的搜索过程.ABC算法作为一个经典的群智能优化算法,具有较强的探索能力,但其开采能力相对较弱.本文从平衡探索与开采的角度,提出一种改进算法DSMABC,根据种群演化规律设计探采指标,使得算法前期侧重探索,中期兼顾二者,

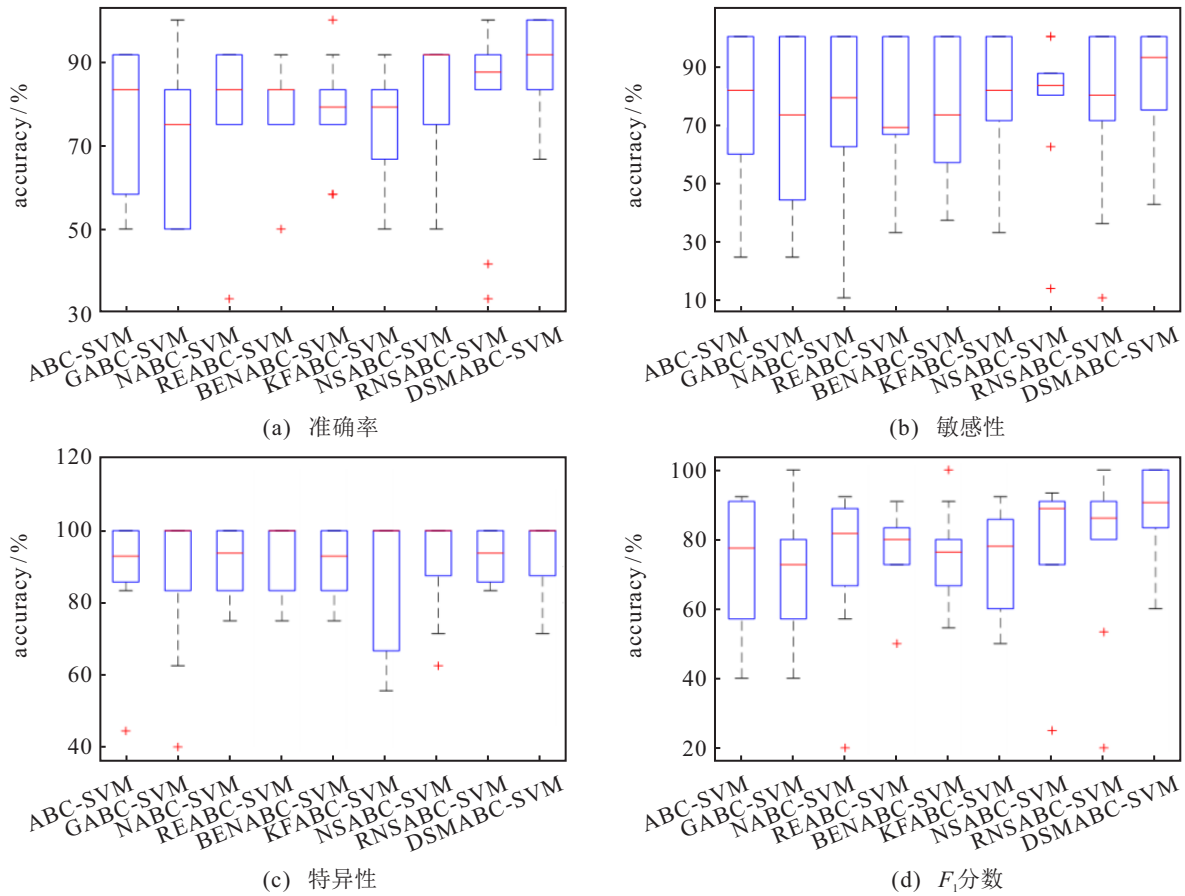


图6 9种ABC-SVM模型的预测结果分布

后期偏向开采. 当算法处于探索状态时, DSMABC为蜂群设计了基于随机解和邻域解引导的搜索方程, 并在跟随蜂阶段通过多样性排序选择增强探索. 当算法处于开采状态时, DSMABC为蜂群设计了基于精英解和最优解引导的搜索方程, 并在跟随蜂阶段通过目标值排序选择强化开采. 在50个典型的测试函数上进行数值实验, 从解质量、非参数检验和收敛速度3个方面检验算法性能, 并与8种近年来提出的高水平ABC算法进行对比, 结果表明DSMABC具有较强的竞争力. 最后, 在食管癌发病风险预测问题上进一步验证了DSMABC的有效性.

后续研究工作可从以下两个方面展开: 一是尝试将DSMABC用于求解更多实际优化问题, 如图像分割问题、光伏电池参数辨识问题等; 二是在ABC算法框架下尝试其他方式实现探采平衡, 如借助种群形状、邻域结构、惯性权重、维度扰动等.

参考文献(References)

[1] Katoch S, Chauhan S S, Kumar V. A review on genetic algorithm: Past, present, and future[J]. Multimedia Tools and Applications, 2021, 80(5): 8091-8126.  
 [2] 孙倩, 王磊, 徐庆征, 等. 一种基于超粒子引导的自适应知识迁移多任务差分进化算法[J]. 控制与决策, 2024, 39(1): 26-38.

(Sun Q, Wang L, Xu Q Z, et al. A super-particle guided multifactorial differential evolution algorithm with adaptive knowledge transfer[J]. Control and Decision, 2024, 39(1): 26-38.)  
 [3] 毛文平, 李帅永, 谢现乐, 等. 基于自适应机制改进蚁群算法的移动机器人全局路径规划[J]. 控制与决策, 2023, 38(9): 2520-2528.  
 (Mao W P, Li S Y, Xie X L, et al. Global path planning of mobile robot based on adaptive mechanism improved ant colony algorithm[J]. Control and Decision, 2023, 38(9): 2520-2528.)  
 [4] 张祥银, 夏爽, 张天. 基于自适应遗传学习粒子群算法的多无人机协同任务分配[J]. 控制与决策, 2023, 38(11): 3103-3111.  
 (Zhang X Y, Xia S, Zhang T. Adaptive genetic learning particle swarm optimization based cooperative task allocation for multi-UAVs[J]. Control and Decision, 2023, 38(11): 3103-3111.)  
 [5] Karaboga D. An idea based on honey bee swarm for numerical optimization[R]. Kayseri: Erciyes University, 2005.  
 [6] Karaboga D, Gorkemli B, Ozturk C, et al. A comprehensive survey: Artificial bee colony (ABC) algorithm and applications[J]. Artificial Intelligence Review, 2014, 42(1): 21-57.  
 [7] Akay B, Karaboga D, Gorkemli B, et al. A survey on the

- artificial bee colony algorithm variants for binary, integer and mixed integer programming problems[J]. *Applied Soft Computing*, 2021, 106: 107351.
- [8] Singh A, Deep K. Exploration-exploitation balance in artificial bee colony algorithm: A critical analysis[J]. *Soft Computing*, 2019, 23(19): 9525-9536.
- [9] Song X Y, Zhao M, Xing S Y. A multi-strategy fusion artificial bee colony algorithm with small population[J]. *Expert Systems with Applications*, 2020, 142: 112921.
- [10] Shi Y, Eberhart R C. Empirical study of particle swarm optimization[C]. *Proceedings of the 1999 Congress on Evolutionary Computation*. Washington DC, 1999: 1945-1950.
- [11] Mirjalili S, Lewis A. The whale optimization algorithm[J]. *Advances in Engineering Software*, 2016, 95(C): 51-67.
- [12] Han Z L, Chen M, Shao S Y, et al. Improved artificial bee colony algorithm-based path planning of unmanned autonomous helicopter using multi-strategy evolutionary learning[J]. *Aerospace Science and Technology*, 2022, 122: 107374.
- [13] Chen J, Xin B, Peng Z H, et al. Optimal contraction theorem for exploration-exploitation tradeoff in search and optimization[J]. *IEEE Transactions on Systems, Man, and Cybernetics—Part A: Systems and Humans*, 2009, 39(3): 680-691.
- [14] Kiran M S, Hakli H, Gunduz M, et al. Artificial bee colony algorithm with variable search strategy for continuous optimization[J]. *Information Sciences: An International Journal*, 2015, 300(C): 140-157.
- [15] Cui L Z, Li G H, Lin Q Z, et al. A novel artificial bee colony algorithm with depth-first search framework and elite-guided search equation[J]. *Information Sciences: An International Journal*, 2016, 367(C): 1012-1044.
- [16] 杜振鑫, 刘广钟, 韩德志, 等. 基于全局无偏搜索策略的精英人工蜂群算法[J]. *电子学报*, 2018, 46(2): 308-314.  
(Du Z X, Liu G Z, Han D Z, et al. Artificial bee colony algorithm with global and unbiased search strategy[J]. *Acta Electronica Sinica*, 2018, 46(2): 308-314.)
- [17] Ye T Y, Wang H, Wang W J, et al. Artificial bee colony algorithm with an adaptive search manner and dimension perturbation[J]. *Neural Computing and Applications*, 2022, 34(19): 16239-16253.
- [18] Črepinšek M, Liu S H, Mernik M. Exploration and exploitation in evolutionary algorithms: A survey[J]. *ACM Computing Surveys*, 2013, 45(3): 35.
- [19] Zhou X Y, Song J Y, Wu S X, et al. Artificial bee colony algorithm based on online fitness landscape analysis[J]. *Information Sciences: An International Journal*, 2023, 619(C): 603-629.
- [20] Cheng J C, Pan Z B, Liang H, et al. Differential evolution algorithm with fitness and diversity ranking-based mutation operator[J]. *Swarm and Evolutionary Computation*, 2021, 61: 100816.
- [21] Wang H, Wang W J, Xiao S Y, et al. Improving artificial Bee colony algorithm using a new neighborhood selection mechanism[J]. *Information Sciences*, 2020, 527: 227-240.
- [22] Ye T Y, Wang W J, Wang H, et al. Artificial bee colony algorithm with efficient search strategy based on random neighborhood structure[J]. *Knowledge-Based Systems*, 2022, 241: 108306.
- [23] Zhu G P, Kwong S. Gbest-guided artificial bee colony algorithm for numerical function optimization[J]. *Applied Mathematics and Computation*, 2010, 217(7): 3166-3173.
- [24] Peng H, Deng C S, Wu Z J. Best neighbor-guided artificial bee colony algorithm for continuous optimization problems[J]. *Soft Computing*, 2019, 23(18): 8723-8740.
- [25] 孔德鹏, 常天庆, 戴文君, 等. 基于排序选择和精英引导的改进人工蜂群算法[J]. *控制与决策*, 2019, 34(4): 781-786.  
(Kong D P, Chang T Q, Dai W J, et al. An improved artificial bee colony algorithm based on the ranking selection and the elite guidance[J]. *Control and Decision*, 2019, 34(4): 781-786.)
- [26] 孟红云, 位冰可. 基于精英解和随机个体邻域信息的改进人工蜂群算法[J]. *控制与决策*, 2020, 35(9): 2169-2174.  
(Meng H Y, Wei B K. An improved artificial bee colony algorithm based on elite solution and random individual neighborhood information[J]. *Control and Decision*, 2020, 35(9): 2169-2174.)
- [27] Wang H, Wang W J, Zhou X Y, et al. Artificial bee colony algorithm based on knowledge fusion[J]. *Complex & Intelligent Systems*, 2021, 7(3): 1139-1152.

## 作者简介

王英聪(1987—), 男, 副教授, 博士, 硕士生导师, 主要研究方向为群体智能、疾病预测、复杂系统建模, E-mail: ying\_cong\_wang@163.com;

李博(1997—), 男, 硕士生, 主要研究方向为群智能算法, E-mail: 350245658@163.com;

孙军伟(1984—), 男, 教授, 博士, 硕士生导师, 主要研究方向为群智能算法、数据处理, E-mail: junweisun@yeah.net;

王延峰(1973—), 男, 教授, 博士, 博士生导师, 主要研究方向为生物启发计算、生物信息处理、复杂系统建模, E-mail: yanfengwang@yeah.net.