

控制与决策

Control and Decision

求解大规模优化问题的改进麻雀搜索算法

顾清华, 姜秉佼, 常朝朝, 李学现

引用本文:

顾清华, 姜秉佼, 常朝朝, 李学现. 求解大规模优化问题的改进麻雀搜索算法[J]. *控制与决策*, 2023, 38(7): 1960–1968.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.2082>

您可能感兴趣的其他文章

Articles you may be interested in

[混合改进策略的黑猩猩优化算法及其机械应用](#)

Chimp optimization algorithm based on hybrid improvement strategy and its mechanical application

控制与决策. 2023, 38(2): 354–364 <https://doi.org/10.13195/j.kzyjc.2021.1108>

[多策略融合的改进麻雀搜索算法及其应用](#)

Improved sparrow search algorithm with multi-strategy integration and its application

控制与决策. 2022, 37(1): 87–96 <https://doi.org/10.13195/j.kzyjc.2021.0582>

[融合柯西折射反向学习和变螺旋策略的 WSN 象群定位算法](#)

Cauchy refraction opposition-based learning and variable helix mechanism of elephant herding localization algorithm in WSN

控制与决策. 2022, 37(12): 3183–3189 <https://doi.org/10.13195/j.kzyjc.2021.0315>

[嵌入 Circle 映射和逐维小孔成像反向学习的鲸鱼优化算法](#)

Whale optimization algorithm for embedded Circle mapping and one-dimensional oppositional learning based small hole imaging

控制与决策. 2021, 36(5): 1173–1180 <https://doi.org/10.13195/j.kzyjc.2019.1362>

[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>

求解大规模优化问题的改进麻雀搜索算法

顾清华[†], 姜秉佼, 常朝朝, 李学现

(西安建筑科技大学 资源工程学院, 西安 710000)

摘要: 针对麻雀搜索算法在求解大规模优化问题时存在收敛速度慢、寻优精度低和易陷入局部极值的缺点, 提出一种基于精英反向学习策略的萤火虫麻雀搜索算法(ELFASSA)。首先, 通过反向学习策略初始化种群, 为全局寻优奠定基础; 其次, 利用萤火虫扰动策略提高算法跳出局部最优的能力并加速收敛; 最后, 在麻雀位置更新后引入精英反向学习策略以获取精英解及动态边界, 使精英反向解可以定位在狭窄的搜索空间中, 有利于算法收敛。通过选取 10 个高维标准测试函数进行仿真实验, 将其与麻雀搜索算法(SSA)及 4 种先进的改进算法进行性能对比, 并与 3 种单一策略改进的麻雀搜索算法进行改进策略的有效性分析, 仿真结果表明, ELFASSA 算法在收敛速度和求解精度两方面明显优于其他对比算法。

关键词: 大规模优化问题; 麻雀搜索算法; 精英反向学习; 萤火虫扰动策略; 动态边界; 5G 网络基站部署

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.2082

引用格式: 顾清华, 姜秉佼, 常朝朝, 等. 求解大规模优化问题的改进麻雀搜索算法[J]. 控制与决策, 2023, 38(7): 1960-1968.

An improved sparrow search algorithm for solving large-scale optimization problems

GU Qing-hua[†], JIANG Bing-jiao, CHANG Zhao-zhao, LI Xue-xian

(College of Resource Engineering, Xi'an University of Architecture and Technology, Xi'an 710000, China)

Abstract: Aiming at the disadvantages of slow convergence, low optimization accuracy and easy to fall into local extremum in the sparrow search algorithm for solving large-scale optimization problems, sparrow search algorithm based on the elite reverse learning strategy and firefly strategy(ELFASSA) is proposed. Firstly, the population is initialized using the reverse learning strategy to lay the foundation for global optimization. Then, the firefly perturbation strategy is used to improve the ability of the algorithm to jump out of the local optimum and accelerate the convergence. Finally, after the sparrow position is updated, the elite reverse learning strategy is introduced to obtain the elite solution and dynamic boundary, so that the elite reverse solution can be located in the narrow search space, which is conducive to the convergence of the algorithm. By selecting 10 high-dimensional standard test functions for simulation experiments, its performance is compared with the sparrow search algorithm (SSA) and four advanced improved algorithms, and the effectiveness of the improved strategy is analyzed with three single strategy improved sparrow search algorithms. The simulation results show that the ELFASSA algorithm is obviously superior to other comparison algorithms in convergence speed and solution accuracy.

Keywords: large scale optimization problem; sparrow search algorithm; elite reverse learning; firefly disturbance strategy; dynamic boundary; 5G network base station deployment

0 引言

现实生活中许多科学和工程应用优化问题往往需要处理大量的决策变量, 如交通车辆调度、路由问题网络、生物基因识别^[1]等, 这类问题被称为大规模优化问题, 即 large-scale global optimization (LSGO).

这类问题在求解过程中主要面临两个难题: 一是问题的复杂度在求解过程中会随着搜索空间维数的增加呈指数增长, 表现出典型的“维数灾难”^[2]; 二是局部最优解众多, 使得算法很难跳出局部最优解。针对求解这类问题面临的两个难点, 已经有许多研究工

收稿日期: 2021-11-29; 录用日期: 2022-03-15.

基金项目: 国家自然科学基金面上项目(52074205); 陕西省自然科学基金杰出青年基金项目(2020JC-44).

责任编辑: 李登峰.

[†]通讯作者. E-mail: qinghuagu@126.com.

作:针对“维数灾难”,现有的解决方法主要分为协同进化方法与非协同进化方法两大类^[3].协同进化方法的基本思想是将大规模问题分解为小规模问题以降低求解问题的难度,然后运用优化算法对小规模问题进行优化求解.文献[4]提出了随机动态的协同进化策略,将其加入动态多种群粒子群优化算法中,实现维数和种群的双分组;文献[5]根据预先定义的分组长度的决策变量进行分组,再进行优化;文献[6]提出了快速独立搜索策略,判断决策变量是否可分;文献[7]提出了使用 K 聚类分组的方法,将决策变量分成了不同的低维水平进而求解.以上研究均是将决策向量分解成多组变量,分别进行优化.非协同进化方法则是将大规模全局优化的问题中的决策变量当作整体处理,进行全局优化.因此,相比于协同进化方法,非协同进化方法对算法的性能要求更高.文献[8]通过集成策略改进蝙蝠算法,采用不同的策略构建策略库求解高维优化问题;文献[9]将一种新的变异规则引入差分进化算法,有效地平衡种群的探索和开发;文献[10]提出了一种基于狼群搜索的混合改进算法WPS-PSO,在不影响全局搜索能力的前提下提高粒子群算法的局部搜索能力,能较好地解决多维优化问题;文献[11]针对大规模优化问题,提出了一种基于灰狼算法的混合优化算法,该算法能够防止灰狼个体陷入局部最优,提高求解速度和求解精度.

对于大规模优化问题的局部最优解数目太大,算法很难跳出局部最优解这一难点,文献[12]通过变异算子改进了麻雀搜索算法中加入者的位置更新,避免了算法陷入局部极值;文献[13]引入自主学习粒子,以两个粒子的混合信息指引萤火虫算法中的普通粒子,使算法跳出局部最优;文献[14]引入一类基于粒子空间特性的事件触发策略降低粒子群算法陷入局部最优的可能性.

文献[15]根据麻雀的觅食特点与反捕食行为提出的麻雀搜索算法(SSA)是一种新型群体智能优化算法.与其他群体智能优化算法相比,SSA算法具有搜索精度高、收敛速度快、鲁棒性强等特点,在函数优化问题方面,已被证明在求解精度和收敛速度等性能方面明显优于PSO算法、灰狼算法(GWO)等群智能优化算法,在求解中小规模(30维)优化问题中具有良好的应用效果^[16-20].但SSA算法在求解大规模优化问题方面鲜有研究.针对SSA在求解大规模优化问题时出现收敛速度慢、寻优精度低和易陷入局部极值的缺点,提出了基于精英反向学习策略的萤火虫麻雀搜索算法(ELFASSA),使用反向选择策略增强种群的多样性,利用萤火虫扰动策略对麻雀进行扰动提高其搜

索性,在算法迭代后期通过动态边界不断缩小搜索空间,提高算法收敛速度.将改进麻雀搜索算法应用于求解大规模优化问题,通过测试来验证改进算法处理大规模优化问题的有效性.

1 麻雀搜索算法

SSA算法的基本思想是将麻雀种群中的个体抽象表示为麻雀搜索算法中的发现者、加入者和侦察者,算法寻优过程中,适应度值高的发现者优先发现食物并为加入者提供觅食区域与方向.麻雀搜索算法中作为发现者的位置更新公式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{i,j} \exp\left(-\frac{i}{\alpha \cdot \text{iter}_{\max}}\right), & R_2 < \text{ST}; \\ X_{i,j} + QL, & R_2 \geq \text{ST}. \end{cases} \quad (1)$$

其中: t 为当前迭代数, $j = 1, 2, \dots, d$; iter_{\max} 为最大的迭代次数; $X_{i,j}$ 为第 i 个麻雀在第 j 维中的位置信息; $\alpha \in [0, 1]$ 为一个随机数; $R_2 \in [0, 1]$ 和 $\text{ST} \in [0, 1]$ 分别为预苟值和安全值; Q 为服从正态分布的随机数; L 为一个 $1 \times d$ 的矩阵,该矩阵内每个元素全部为1.当 $R_2 < \text{ST}$ 时,表明当前麻雀所处的觅食环境周围没有捕食者,发现者可以进行广泛搜索操作;当 $R_2 \geq \text{ST}$ 时,表明种群中的部分个体发现危险,并向种群中的其他个体发出警报,此时种群中所有麻雀都需要迅速飞到其他安全的地方进行觅食.对于加入者,其位置更新受发现者的影响,公式为

$$X_{i,j}^{t+1} = \begin{cases} Q \cdot \exp\left(\frac{X_{\text{worst}}}{\alpha \cdot \text{iter}_{\max}}\right), & i \geq n/2; \\ X_P^{t+1} + |X_{i,j} + X_P^{t+1}|A^+L, & \text{otherwise}. \end{cases} \quad (2)$$

其中: X_P 是当前发现者所处的最优位置,则 X_{worst} 表示当前种群中最差的位置; A 表示一个 $1 \times d$ 的矩阵,其中每个元素随机赋值为1或-1,并且 $A^+ = A^T(AA^T)^{-1}$.当 $i > n/2$ 时,表明适应度值较低的第 i 个加入者没有获得食物,处于十分饥饿的状态,此时需要飞往其他地方受食,以获得更多的能量.作为侦察者的麻雀在发现危险时会立即发出警报,同时迅速地向安全区域移动,从而脱离危险获取更好位置.若在搜索过程中警报值超出安全阈值时,则发现者需要将种群中其他麻雀带离危险区.侦察麻雀的初始位置是在种群中随机产生的,其数学表达式如下:

$$X_{i,j}^{t+1} = \begin{cases} X_{\text{best}}^t + \beta|X_{i,j}^t - X_{\text{best}}^t|, & f_i > f_g; \\ X_{i,j}^t + K\left(\frac{X_{i,j}^t - X_{\text{worst}}^t}{(f_i - f_w) + \varepsilon}\right), & f_i = f_g. \end{cases} \quad (3)$$

其中: X_{best} 是当前的全局最优位置; β 作为步长控制参数, 是服从均值为0、方差为1的正态分布的随机数; $K \in [0, 1]$ 是一个随机数; f_i 是当前麻雀个体的适应度值, f_g 和 f_w 分别是当前全局最佳和最差的适应度值; ε 是常数, 以避免分母出现零. 当 $f_i > f_g$ 时, 表示此时的麻雀正处于种群的边缘, 极易受到捕食者的攻击. X_{best} 表示这个位置的麻雀是种群中最好的位置, 也是十分安全的. $f_i = f_g$ 时, 表明处于种群中间的麻雀意识到了危险, 需要靠近其他的麻雀以此尽量减少它们被捕食的风险. K 表示麻雀移动的方向同时也是步长控制参数.

2 基于精英反向学习策略的萤火虫麻雀搜索算法

2.1 算法流程

基于反向学习策略、改进萤火虫扰动策略以及精英策略动态边界改进而成的ELFASSA算法的具体步骤如下.

step 1: 初始化参数. 设置种群规模 N , 初始值上下边界为 lb 和 ub , 最大迭代次数 Maxiter , 设置预警值、发现者、侦察者比例及数量;

step 2: 利用反向学习策略初始化种群, 生成反向种群 P' ;

step 3: 计算最初种群 P 和反向种群 P' 的适应度值 f_i 并排序, 选取适应度高的 N 个个体作为最终的初始种群;

step 4: 根据式(1)~(3)更新发现者、加入者、侦察者位置并重新计算适应度值 f_i , 选取当前最优适应度值 f_g 及最劣适应度值 f_w ;

step 5: 利用改进萤火虫扰动策略进行麻雀位置更新;

Step 6: 取麻雀种群中适应度排名前10%作为精英解, 同时根据 $\alpha_j = \max(X_{i,j})$, $\beta_j = \min(X_{i,j})$ 求取动态边界, 利用精英反向学习策略求解反向解;

step 7: 计算适应度值并更新麻雀位置;

step 8: 判断算法是否满足停止条件, 满足则退出, 输出结果, 否则, 重复执行 step 3 ~ step 7.

2.2 基于反向学习的初始化种群策略

初始化种群的多样性能够奠定麻雀搜索算法搜索效率的基础, 减少算法的计算时间, 同时提高算法的全局收敛性^[21]. 反向学习策略^[22] 是用于扩大算法搜索区域的一种策略, 通过已有个体位置生成新的个体位置, 达到增加初始种群多样性的目的. 目前已在GA、DE、ACO和BBO等多种群体智能优化算法中得到应用. 反向点的定义如下: 假设在 $[l, u]$ 上存在数 x ,

则 x 的反向点定义为 $x' = l + u - x$. 将反向点的定义扩展到 D 维空间, 设 $p = (x_1, x_2, \dots, x_D)$ 为 D 维空间中的一个点, 其中 $x_i \in [l_i, u_i]$, $i = 1, 2, \dots, D$, 则其反向点 $p' = (x'_1, x'_2, \dots, x'_D)$, $x'_i = l_i + u_i - x_i$.

根据上述定义, 反向学习策略在基于精英反向学习策略的萤火虫麻雀搜索算法(ELFASSA)中初始化种群的步骤为:

1) 均匀随机地生成一个初始种群 P 并根据初始种群生成反向种群 P' ;

2) 通过适应度函数计算最初种群 P 和反向种群的适应度值并排序;

3) 选取适应度高的 N 个个体作为最终的初始种群.

2.3 改进的萤火虫扰动策略

为了避免麻雀算法在求解过程中陷入局部最优, 将改变步长的萤火虫扰动策略对麻雀进行扰动, 提高算法搜索能力. 在原始萤火虫扰动策略中, 对种群中一切个体采用一个固定的步长, 存在求解速度低的缺点. 因而采用改变步长的方法, 为每个个体设置动态步长, 以此来提高算法的求解速度. 萤火虫扰动策略的相关公式如下.

萤火虫的相对荧光亮度为

$$I = I_0 e^{-\gamma_{i,j}}. \quad (4)$$

其中: I_0 为萤火虫的最大荧光亮度, 与目标函数相关, 目标函数值越优自身亮度越高; γ 为光强吸收系数, 荧光会随着距离的增加和传播媒介的吸收逐渐减弱; $r_{i,j}$ 为萤火虫 i 和 j 之间的空间距离.

萤火虫的吸引度为

$$\beta = \beta_0 e^{-r_{i,j}^2}. \quad (5)$$

其中: β_0 为最大吸引度, γ 为光强吸收系数, $r_{i,j}$ 为萤火虫 i 与 j 之间的空间距离. 萤火虫 i 被吸引向萤火虫 j 移动的位置更新公式如下:

$$X_i = X_i + \beta(X_j - X_i) + \alpha(\text{rand} - 1/2). \quad (6)$$

其中: x_i, x_j 为萤火虫 i 和 j 所处的空间位置; rand 为 $[0, 1]$ 上服从均匀分布的随机数; α 为步长因子, 具体步长设置公式为

$$\begin{aligned} \alpha_i(t+1) = \\ \alpha_i(t) - (\alpha_i(t) - \alpha_{\min}) e^{-|x_{\text{gbest}}(t) - x_{i,\text{best}}(t)| \frac{t}{\text{Maxiter}}}. \end{aligned} \quad (7)$$

其中: t 为当前迭代次数; α_{\min} 为最小步长, 范围为 $[0, 1]$; x_{gbest} 表示当前全局最优位置; $x_{i,\text{best}}(t)$ 为第 i 个个体至目前为止求出的最优位置; Maxiter 为最大

迭代次数. 具体操作如下: 1) 计算萤火虫的相对亮度 i 和吸引度 β , 根据相对亮度决定个体的移动方向; 2) 更新麻雀个体的空间位置, 对处在最佳位置的麻雀进行随机移动; 3) 根据更新后的麻雀位置, 重新计算萤火虫亮度 I_0 .

2.4 精英反向动态边界

在算法迭代后期引入精英反向动态边界不断缩小搜索空间^[23], 提高麻雀算法的收敛速度. 可以定义

$$P_{i,j}^e = K(\alpha_j + \beta_j) - X_{i,j}^e. \quad (8)$$

其中: K 为在 $(0, 1)$ 上的 d 维空间; $X_{i,j}^e \in [\alpha_j, \beta_j]$, $\alpha_j = \max(X_{i,j})$, $\beta_j = \min(X_{i,j})$ 为动态边界, 可以克服固定边界的缺点以保存搜索经验, 使精英反向解可以定位在狭窄的搜索空间中, 有利于算法收敛. 具体操作如下: 1) 对种群中的每个个体根据式(4)对前 10%^[18] 优秀个体进行反向求解, 获取精英个体并添加到反向种群 OP 中; 2) 根据 $\alpha_j = \max(X_{i,j})$, $\beta_j = \min(X_{i,j})$ 计算个体的当前搜索边界; 3) 将当前种群和反向种群中的个体进行适应度排序, 选取适应度值较好的优良个体作为下一代种群; 4) 利用随机生成的方法进行边界处理, 防止动态边界操作使得 $X_{i,j}^e$ 越界成为非可行解, 重置方式如下:

$$X_{i,j}^e = \text{rand}(\alpha_j, \beta_j). \quad (9)$$

2.5 ELFASSA 算法收敛性分析

本文将 ELFASSA 算法的寻优过程分为两个阶段, 即全局搜索阶段和最优区域搜索阶段.

2.5.1 全局搜索阶段

假设麻雀 X_i 每一步的转移概率为

$$P(X_i \rightarrow D_{\max}) = p \sum_{k=1}^N \frac{d \cap ik}{Nd_{ik}} \neq 0. \quad (10)$$

其中: D_{\max} 为函数值低于最大值并高于次大值的取值范围; N 为种群大小; p 为寻得食物的概率; X_i 与 X_k 之间的距离记为 d_{ik} , 两者之间路径重叠长度记为 $d_{\cap ik}$; 对于任意麻雀 X_i 在经过 n 次迭代后无法转移到 D_{\max} 区域的概率为

$$\lim_{n \rightarrow \infty} \prod_{i=m}^n (1 - P(X_i \rightarrow D_{\max})) = \lim_{n \rightarrow \infty} \left(1 - p \sum_{k=1}^N \frac{d \cap ik}{Nd_{ik}} \right)^n = 0. \quad (11)$$

当麻雀 X_i 陷入局部最优时, X_i 转变为侦查者, 此时

$$P(X_i \rightarrow D_{\max}) = p \frac{d_{\max}}{d}, \quad (12)$$

$$\lim_{n \rightarrow \infty} \prod_{i=m}^n (1 - P(X_i \rightarrow D_{\max})) =$$

$$\lim_{n \rightarrow \infty} \left(1 - p \frac{d_{\max}}{d} \right)^{n-m} = 0. \quad (13)$$

因此, 麻雀 X_i 在经过一定次数的迭代后必然可以转移到 D_{\max} 区域.

2.5.2 最优区域搜索阶段

麻雀种群进入 D_{\max} 区域之后的搜索阶段被称为最优区域搜索阶段 $D_{x-\max}$, 个体在此阶段转移至最大值范围(近似全局最优)的概率为

$$(X_i \rightarrow D_{x-\max}) = p \sum_{k=1}^* \frac{d_{nx-\max}}{Nd_{ik}}. \quad (14)$$

其中 $d_{nx-\max}$ 是 X_i 、 X_k 之间的区域与 $D_{x-\max}$ 之间重叠部分的长度. 此时, 麻雀 X_i 每一步的转移概率为

$$P(X_i \rightarrow X_j) = \begin{cases} p/2, & f(X_i) \leq f(X_k); \\ \frac{d_{\Delta p}}{2d_{ik}}, & f(X_i) > f(X_k). \end{cases} \quad (15)$$

其中: d_{Δ} 是 X_i 与 X_k 两点之间适应度值大于 X_i 的函数表现在横坐标轴上的长度. 如果种群在区域 D_{\max} 的离散度足够大, 则 $d_{nx-\max}$ 将并不全为 0, 此时的 $P(X_i \rightarrow D_{x-\max})$ 也就不为 0. 而如果种群离散度不够大导致 $d_{nx-\max}$ 全为 0, 则此时所有麻雀必然全部集中于 X_{\max} 的左半边或右半边, 且此时麻雀从状态 X_i 转移到 X_j 的概率变为

$$P(X_i \rightarrow X_j) = \frac{p}{2}. \quad (16)$$

由式(16)可得, 麻雀从状态 X_i 转移到 X_j 的一步概率变为 1/2, 会出现以下两种结果: 1) 随着 X_i 迭代次数的增加, 蜂群离散度变大, $d_{nx-\max}$ 重新变得不全为 0; 2) X_i 到达限制次数, 转变为侦查者. 在情况 1) 中, 若 $d_{nx-\max} \neq 0$, 则 $P(X_i \rightarrow D_{x-\max}) \neq 0$. 此时, 对于 X_i 有

$$\lim_{n \rightarrow \infty} P\{X_i \rightarrow X_j \parallel \geq \varepsilon\} = \lim_{n \rightarrow \infty} \prod_{n=1}^{\infty} \left(1 - P \sum_{k=1}^N \frac{d_{nx-\max}}{Nd_{ik}} \right) = 0, \quad (17)$$

X_i 转移概率为 1 收敛于 X_{\max} , X_i . 在情况 2) 中, $P(X_i \rightarrow D_{x-\max}) = 2p\varepsilon/d$, 其一步转移概率 $P(X_i \rightarrow X_j) = d_{\Delta p}/d$, 其中 d_{Δ} 是目标函数值大于 $f(X_i)$ 区域长度, 因此无法转移到下一个位置的概率为 0, 经过一定次数的迭代, 必然可以向更优的位置转移, 找到全局最优.

3 仿真实验与分析

为验证 ELFASSA 算法求解大规模优化问题时的性能, 本节采用 10 个基准测试函数进行了数值仿真实验. 其中 $F_1 \sim F_5$ 是单峰测试函数, $F_6 \sim F_{10}$ 是多峰测试函数. 其中第 1 组实验将 ELFASSA 算法与 SSA 算法、TSSA 算法^[24]、HGPSO 算法^[25]、BASSA 算

法^[26]、HGGWA算法^[27]进行对比分析,第2组实验将ELFASSA算法与只加入某一种策略的SSA算法进行寻优效果对比分析.

3.1 参数设置

所有算法最大迭代次数为1000,种群大小设置为50^[15],具体参数设置如表1所示.

表1 算法参数设置

算法名称	参数
ELFASSA	$p_{Num} = 20\%, s_{Num} = 20\%, ST = 0.8$
SSA	
TSSA	
HGPSO	$p = 0.5$
BASSA	$c_1 = c_2 = 1.49$
HGGWA	$rand \in [0, 1], \omega_{max} = 0.9, \omega_{min} = 0.4$
	$P_c = 0.8, P_m = 0.01$

为了避免单次运行结果的偏差,实验中在100

维、500维、1000维的维度下分别运行30次以获得目标函数的均值和标准差.在相同的标准测试函数下,平均值可以反映出算法的收敛精度,标准差则反映出算法寻优能力的稳定性.

3.2 实验结果及分析

3.2.1 在单峰测试函数上的优化对比

单峰测试函数在定义范围内只有一个全局最优解而没有局部解,因此用它来检测算法的收敛速度和寻优能力.多峰函数在函数的定义区间内存在大量局部极值,可以用来检测算法全局搜索和跳出局部最优解的能力.表2给出了运行30次独立实验,ELFASSA与其他5种算法在不同维度下单峰测试函数的优化结果.

表2 单峰测试函数优化结果

函数	维度	SSA		TSSA		HGPSO		BASSA		HGGWA		ELFASSA	
		平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差
F_1	100	7.66e-03	6.61e-03	2.63e-92	1.39e-91	2.39e-34	2.60e-34	8.00e-03	6.86e-03	4.10e-25	2.21e-24	0.00e+00	0.00e+00
	500	3.25e+04	2.29e+03	0.00e+00	0.00e+00	2.78e-14	1.34e-14	3.26e+04	3.08e+03	3.62e-168	0.00e+00	0.00e+00	0.00e+00
	1000	1.04e+05	1.17e+05	0.00e+00	0.00e+00	4.79e-10	1.70e-10	1.20e+05	5.32e+03	3.34e-86	1.80e-85	4.71e-261	0.00e+00
F_2	100	1.30e+01	3.35e+00	1.58e-47	8.37e-47	2.71e-34	3.40e-34	6.59e-03	7.32e-03	4.31e-143	2.32e-142	0.00e+00	0.00e+00
	500	3.39e+02	1.57e+01	3.28e-242	0.00e+00	2.34e-14	1.31e-14	3.28e+04	2.44e+03	3.48e-137	1.87e-136	0.00e+00	0.00e+00
	1000	8.10e+02	8.50e+02	2.57e-303	0.00e+00	6.01e-10	2.23e-10	1.19e+05	4.57e+03	6.53e-51	3.52e-50	5.00e-223	0.00e+00
F_3	100	2.22e+04	1.07e+04	6.92e-92	3.60e-91	1.59e-34	1.56e-34	7.75e-03	6.19e-03	1.29e-211	0.00e+00	0.00e+00	0.00e+00
	500	3.39e+02	3.20e+05	0.00e+00	0.00e+00	2.35e-14	1.35e-14	3.12e+04	3.04e+03	1.74e-117	9.38e-117	1.08e-299	0.00e+00
	1000	9.85e+05	2.54e+06	4.63e-184	0.00e+00	5.04e-10	1.31e-10	1.19e+05	5.82e+03	1.03e-31	5.56e-31	1.01e-264	0.00e+00
F_4	100	2.10e+01	2.63e+00	4.67e-36	2.51e-35	2.1e-34	1.97e-34	5.57e-03	4.17e-03	7.03e-212	0.00e+00	5.90e-304	0.00e+00
	500	3.18e+01	2.17e+00	8.10e-288	0.00e+00	2.46e-14	1.50e-14	3.23e+04	2.39e+03	7.79e-213	0.00e+00	0.00e+00	0.00e+00
	1000	3.28e+01	3.62e+01	1.40e-275	0.00e+00	5.81e-10	2.33e-10	1.17e+05	6.04e+03	4.21e-212	0.00e+00	0.00e+00	0.00e+00
F_5	100	4.99e+02	2.48e+02	3.42e-04	6.50e-04	2.52e-34	3.90e-34	6.50e-03	5.91e-03	6.77e-212	0.00e+00	6.15e-160	3.37e-159
	500	5.53e+06	8.28e+05	0.00e+00	0.00e+00	2.75e-14	1.10e-14	3.26e+04	2.80e+03	8.68e-34	4.68e-33	6.06e-263	0.00e+00
	1000	2.65e+07	3.00e+07	0.00e+00	0.00e+00	6.02e-10	2.07e-10	1.18e+05	5.35e+03	1.40e-208	0.00e+00	0.00e+00	0.00e+00

如表2所示,在函数维度为100维的实验中,ELFASSA对单峰测试函数 F_1 、 F_2 、 F_3 寻找到了最优值,虽然在 F_4 、 F_5 上没有寻找到最优解,但从得到的平均值能够看出,ELFASSA的收敛精度要明显优于其他5种算法,且ELFASSA对单峰函数的寻优精度未随着维度的增加而降低,而SSA、HGPSO、BASSA、HGGWA的寻优精度均随着维度的增加而降低.单峰测试函数的实验结果表明,ELFASSA在求解高维复杂函数时,其收敛速度与寻优能力均优于其他对比算法.

3.2.2 多峰测试函数上的优化对比

多峰函数在函数的定义区间内存在大量局部极值,可以用来检测算法全局搜索和跳出局部最优解的能力.表3给出了运行30次独立实验,ELFASSA与其他5种算法在不同维度下在多峰测试函数的优化结

果.

通过分析表3可知,在多峰测试函数的实验中,对于测试函数 F_6 、 F_7 ,无论哪种维度条件下,ELFASSA都能够寻得最优值.对于函数 F_8 ,在函数维度为500维的条件下,ELFASSA算法的寻优效果略逊于TSSA算法但优于其他对比算法.对于函数 F_9 、 F_{10} ,ELFASSA算法虽未能寻得全部的最优值,但其搜索能力优于其余5种对比算法,且通过表格可以看出,ELFASSA算法在对多峰测试函数的求解过程中,依旧保持着良好的搜索能力,其寻优效果并未随着维度的增加而减弱.总体而言,在100维、500维和1000维的实验条件下,ELFASSA算法表现出比SSA、TSSA、HGPSO、BASSA、HGGWA五种算法更好的寻优效果,验证了ELFASSA算法求解大规模优化问题的有效性.

表3 多峰测试函数优化结果

函数	维度	SSA		TSSA		HGPSO		BASSA		HGGWA		ELFASSA	
		平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差
F_6	100	-2.42e+04	1.69e+03	-7.27e+04	1.75e+04	3.56e-34	6.91e-34	1.28e-02	1.40e-02	1.88e-210	0.00e+00	0.00e+00	0.00e+00
	500	-8.85e+04	3.88e+03	0.00e+00	0.00e+00	2.75e-14	1.40e-14	3.22e+04	2.23e+03	1.56e-11	8.11e-11	0.00e+00	0.00e+00
	1000	-1.35e+05	8.58e+03	0.00e+00	0.00e+00	4.96e-10	1.92e-10	1.18e+05	6.16e+03	2.86e-193	0.00e+00	0.00e+00	0.00e+00
F_7	100	1.41e+02	3.60e+01	0.00e+00	0.00e+00	1.95e-34	2.16e-34	1.54e-02	1.85e-02	1.67e-204	0.00e+00	0.00e+00	0.00e+00
	500	1.98e+03	1.28e+02	0.00e+00	0.00e+00	2.66e-14	1.47e-14	3.16e+04	3.22e+03	2.97e-79	1.60e-78	0.00e+00	0.00e+00
	1000	5.59e+03	1.96e+02	0.00e+00	0.00e+00	5.11e-10	1.57e-10	1.19e+05	5.44e+03	4.79e-173	0.00e+00	0.00e+00	0.00e+00
F_8	100	5.27e+00	9.40e-01	8.88e-16	0.00e+00	3.05e-34	3.35e-34	8.56e-03	7.44e-03	1.79e-210	0.00e+00	1.15e-304	0.00e+00
	500	1.23e+01	2.85e-01	0.00e+00	0.00e+00	2.82e-14	8.85e-15	3.28e+04	1.94e+03	1.60e-65	8.63e-65	2.25e-242	0.00e+00
	1000	1.28e+01	2.08e-01	9.30e-98	5.09e-97	5.69e-10	2.06e-10	1.18e+05	4.83e+03	5.35e-181	0.00e+00	8.21e-308	0.00e+00
F_9	100	1.07e-01	2.89e-02	1.45e+01	8.66e+00	2.33e-34	2.97e-34	1.08e-02	1.20e-02	4.33e-79	2.33e-78	5.08e-253	0.00e+00
	500	2.94e+02	2.74e+01	8.46e-186	0.00e+00	2.59e-14	1.14e-14	3.30e+04	2.70e+03	4.57e-164	0.00e+00	0.00e+00	0.00e+00
	1000	1.08e+03	4.87e+01	1.01e-95	5.52e-95	5.42e-10	1.79e-10	1.18e+05	4.61e+03	7.08e-131	3.81e-130	4.20e-277	0.00e+00
F_{10}	100	1.11e+01	3.93e+00	3.05e-08	9.08e-08	2.03e-34	1.62e-34	8.64e-03	7.54e-03	1.61e-13	8.66e-13	1.91e-269	0.00e+00
	500	1.99e+02	6.34e+02	6.56e-288	0.00e+00	2.30e-14	1.18e-14	3.24e+04	2.74e+03	7.68e-13	4.14e-12	0.00e+00	0.00e+00
	1000	6.89e+04	5.22e+04	2.90e-83	1.59e-82	5.13e-10	1.79e-10	1.19e+05	5.87e+03	3.48e-133	1.87e-132	0.00e+00	0.00e+00

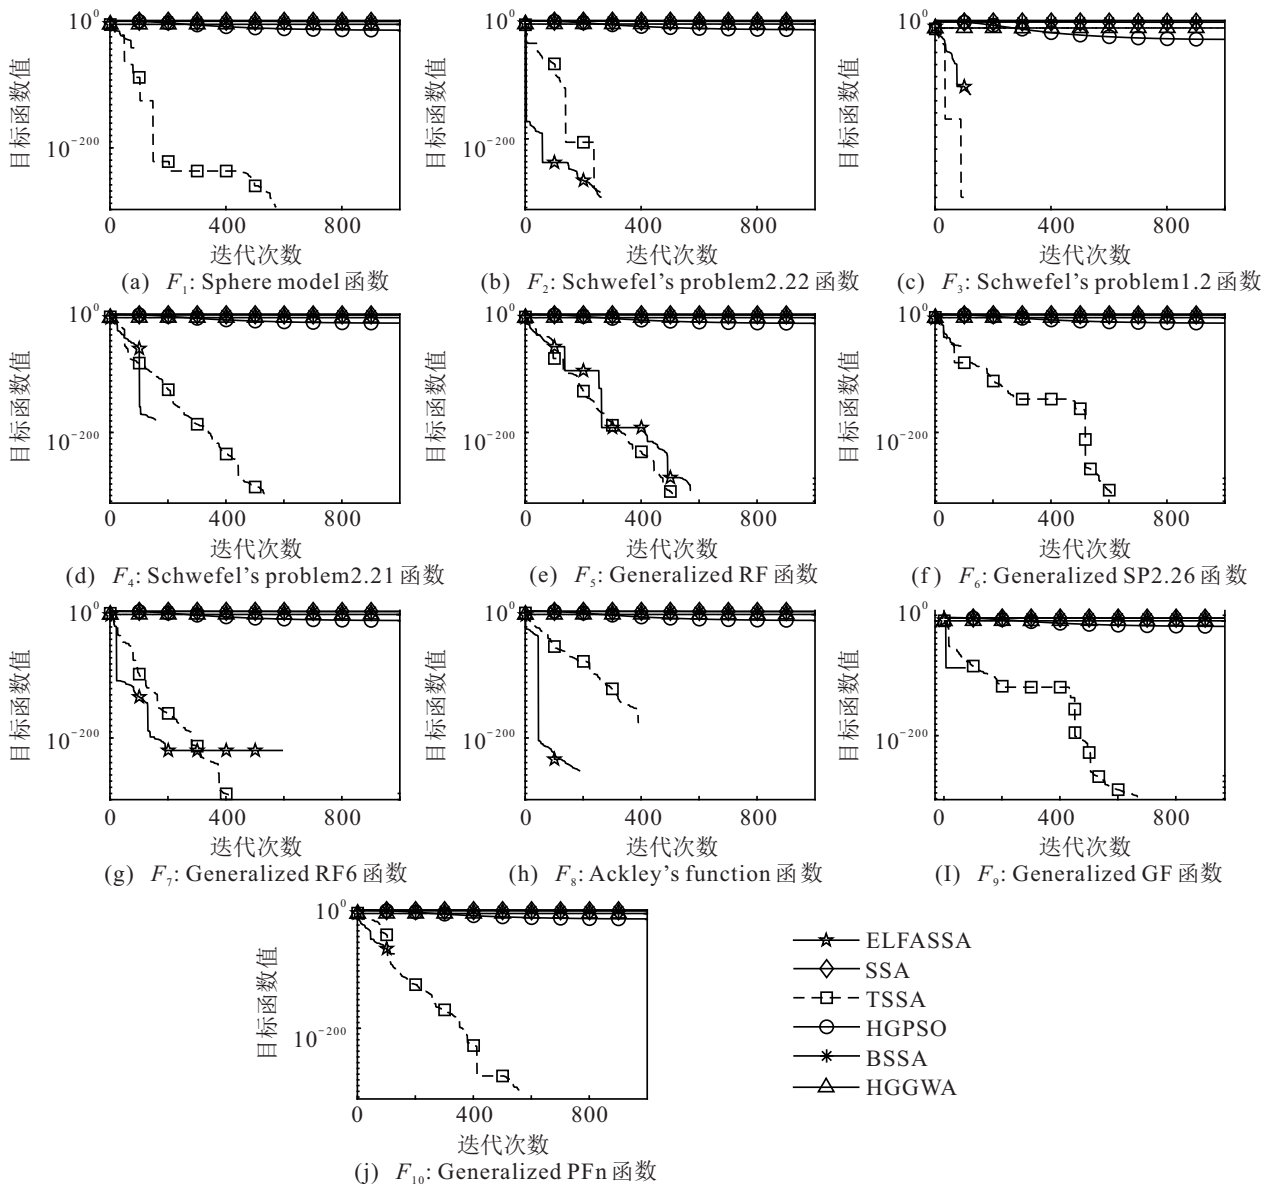


图1 6种算法在10个测试函数上的收敛曲线 ($D = 1000$)

3.2.3 收敛曲线分析

为了直观地比较6种算法的收敛速度,将10个测试函数的适应度曲线在1000维的情况下进行对比。

由图1可以看出,在高维条件下,ELFASSA的收敛速度具有绝对优势,能够快速收敛到最优值,明显优于5种对比算法。并且从 F_1 、 F_3 、 F_4 、 F_6 、 F_8 、 F_9 、 F_{10} 测试函数的收敛曲线图中可以观察到,ELFASSA在迭代初始阶段就已经获得了较好的适应度值,大约经过200次迭代后,收敛到较好的值。而HGPSO、SSA、BSSA、HGGWA迭代过程中均陷入局部最优,其寻优能力远不及TSSA算法及本文提出的ELFASSA算法。可以得出结论:对于所选取的5个多峰测试函数,所提出的ELFASSA比其他5种群智能优化算法具有更快的收敛速度。如图1所示,ELFASSA在处理高维复杂的问题时具有较快的收敛速度和较好的探索未知区域的能力。

4 改进SSA算法在露天矿5G网络部署中的应用

5G通信网络对露天矿的智能化、无人化技术至关重要,基站的选址是基站网络规划中非常重要的一部分。为了有效节省工程成本、提升露天矿通信网络的覆盖能力,露天矿5G基站优化选址具有十分重要的现实意义。本文将改进的ELFASSA算法与SSA算法、TSSA算法、HGPSO算法、BASSA算法、HGGWA算法应用于优化露天矿5G基站的分布并进行对比分析,进一步验证改进ELFASSA算法的实用性。

4.1 应用模型

假设 n 个5G基站随机部署在露天矿内,面积为 $S = L_1 \times L_2$ 。基站点集定义为 $Z = \{Z_1, Z_2, \dots, Z_n\}$, Z_i 的位置坐标为 $(x_i, y_i), i = 1, 2, \dots, n$ 。每个基站节点的覆盖半径为 R_S ,通信半径为 R_C 。为了便于计算,将信号覆盖区域分为 $m \times n$,设置像素节点集合为 $H_j = (x_j, y_j), j \in \{1, 2, \dots, m \times n\}$ 。基站点 Z_i 与节点 H_j 之间的距离定义为

$$d(z_i, H_j) = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2}. \quad (18)$$

在露天矿中,任意一个像素节点都可以被多个基站节点同时感知,其联合感知概率 $p(Z, H_j)$ 定义为

$$p(Z, H_j) = 1 - \prod_{i=1}^N [1 - p(z_i, H_j)]. \quad (19)$$

区域覆盖比 R_{cov} 的定义为

$$R_{cov} = \frac{\sum_{j=1}^{m \times n} p(Z, H_j)}{m \times n}. \quad (20)$$

式(20)为解决5G基站部署优化问题的目标函数。

4.2 参数设置

实验参数设计如下。

表4 算法参数设置

参数	数值
区域覆盖面积	$S = 100 \text{ m} \times 100 \text{ m}$
网格数	1000×1000
基站数	$V = 8$
通信半径	$R_c = 250 \text{ m}$

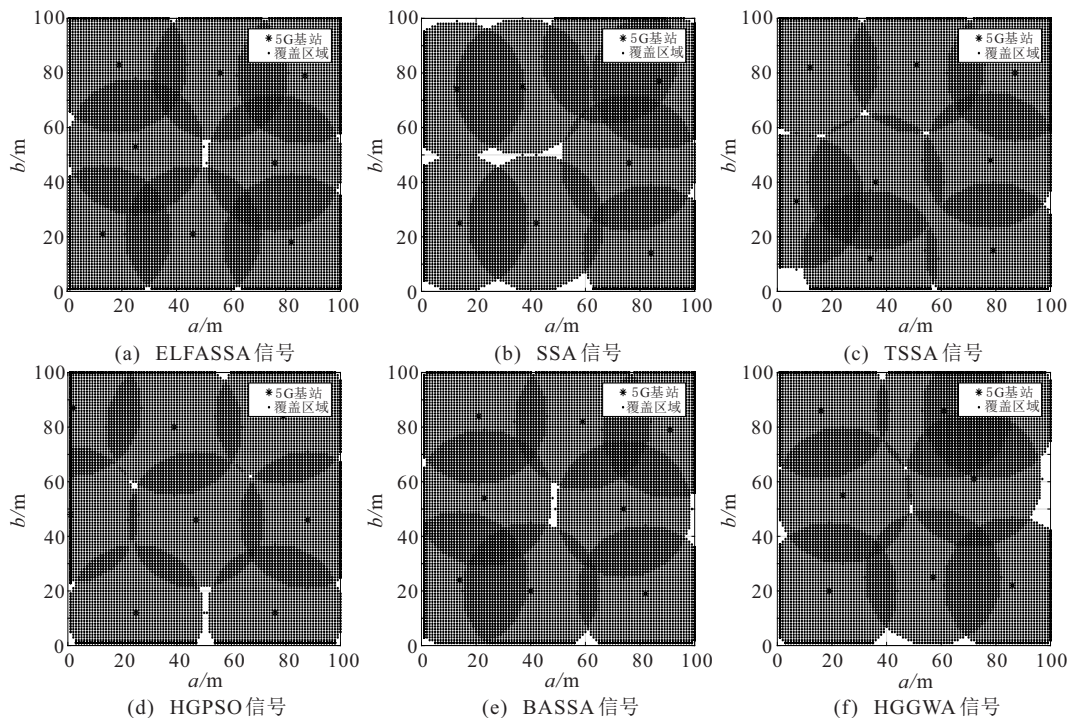


图2 算法信号覆盖图

4.3 实验结果及分析

4.3.1 算法在测试问题上的优化对比

为减少随机性对实验结果的干扰, 采用ELFASSA算法与SSA算法、TSSA算法、HGPSO算法、BASSA算法、HGGWA算法对区域进行20次优化, 并比较最优覆盖率。

4.3.2 实验结果

图2为通过6种算法优化后该地区5G基站的分布和信号覆盖情况。表5为6种算法平均覆盖率优化结果的比较。如表5所示, 在相同的测试条件下, ELFASSA的20次优化运行的覆盖率最优。

表5 覆盖率优化结果对比

算法	最佳覆盖率(运行20次)/%
ELFASSA	99.52
SSA	96.96
TSSA	98.85
HGPSO	98.97
BASSA	98.92
HGGWA	96.91

5 结论

针对SSA算法求解大规模优化问题时存在收敛速度慢、寻优精度低和易陷入局部极值的缺点, 本文对麻雀搜索算法做出以下改进: 采用反向学习策略初始化种群, 增加种群多样性, 为全局寻优奠定基础; 通过萤火虫扰动策略对麻雀位置细分优化, 避免算法陷入局部最优并加速收敛; 引入精英反向动态边界, 更好地提高算法的搜索能力。仿真结果表明, 相比较SSA算法, 本文所提出的ELFASSA算法的寻优性能得到了极大的提高。与3种单一策略改进的SSA算法的寻优效果对比, 验证了ELFASSA算法的有效性。最后将ELFASSA算法应用于露天矿5G基站选址, 结果表明, 基于ELFASSA算法的露天矿5G基站覆盖盲区更小, 进一步验证了改进算法的优越性。

参考文献(References)

[1] Mahdavi S, Rahnamayan S, Shiri M E. Multilevel framework for large-scale global optimization[J]. *Soft Computing*, 2017, 21(14): 4111-4140.

[2] Wang H, Wu Z J, Rahnamayan S. Enhanced opposition-based differential evolution for solving high-dimensional continuous optimization problems[J]. *Soft Computing*, 2011, 15(11): 2127-2140.

[3] Potter M A, Jong K A. A cooperative coevolutionary approach to function optimization[C]. *International Conference on Parallel Problem Solving from Nature*. Berlin, Heidelberg: Springer, 1994: 249-257.

[4] 梁静, 刘睿, 于坤杰, 等. 求解大规模问题协同进

化动态粒子群优化算法[J]. *软件学报*, 2018, 29(9): 2595-2605.

(Liang J, Liu R, Yu K J, et al. Dynamic multi-swarm particle swarm optimization with cooperative coevolution for large scale global optimization[J]. *Journal of Software*, 2018, 29(9): 2595-2605.)

[5] Omidvar M N, Li X D, Yao X. Cooperative Co-evolution with delta grouping for large scale non-separable function optimization[C]. *IEEE Congress on Evolutionary Computation*. Barcelona, 2011: 1-8.

[6] Ge H W, Sun L, Yang X, et al. Cooperative differential evolution with fast variable interdependence learning and cross-cluster mutation[J]. *Applied Soft Computing*, 2015, 36: 300-314.

[7] Mahdavi S, Rahnamayan S, Shiri M E. Multilevel framework for large-scale global optimization[J]. *Soft Computing*, 2017, 21(14): 4111-4140.

[8] Cai X J, Zhang J J, Liang H, et al. An ensemble bat algorithm for large-scale optimization[J]. *International Journal of Machine Learning and Cybernetics*, 2019, 10(11): 3099-3113.

[9] Mohamed A W, Suganthan P N. Real-parameter unconstrained optimization based on enhanced fitness-adaptive differential evolution algorithm with novel mutation[J]. *Soft Computing*, 2018, 22(10): 3215-3235.

[10] Chen H R, Cui L J, Guo Q, et al. Improved particle swarm optimization using wolf pack search[J]. *Journal of Physics: Conference Series*, 2019, 1176: 052009.

[11] Dong R Y, Wang S S, Wang G Y, et al. Hybrid optimization algorithm based on wolf pack search and local search for solving traveling salesman problem[J]. *Journal of Shanghai Jiaotong University: Science*, 2019, 24(1): 41-47.

[12] Yuan J H, Zhao Z W, Liu Y P, et al. DMPPT control of photovoltaic microgrid based on improved sparrow search algorithm[J]. *IEEE Access*, 2021, 9: 16623-16629.

[13] 赵嘉, 陈文平, 肖人彬, 等. 面向多峰优化问题的自主学习萤火虫算法[J]. *控制与决策*, 2022, 37(8): 1971-1980.

(Zhao J, Chen W P, Xiao R B, et al. Firefly algorithm based on self-learning for multi-peak optimization problem[J]. *Control and Decision*, 2022, 37(8): 1971-1980.)

[14] 王闯, 韩非, 申雨轩, 等. 基于事件触发的全信息粒子群优化器及其应用[EB/OL]. [2021-10-25]. <http://kns.cnki.net/kcms/detail/11.2109.TP.20201209.1114.002.html>.

(Wag C, Han F, Shen Y X, et al. Firefly algorithm based on self-learning for multi-peak optimization

- problem[EB/OL]. [2021-10-25]. <http://kns.cnki.net/kcms/detail/11.2109.TP.20201209.1114.002.html>.)
- [15] Xue J K, Shen B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. *Systems Science & Control Engineering*, 2020, 8(1): 22-34.
- [16] 陈刚, 林东, 陈飞, 等. 基于 Logistic 回归麻雀算法的图像分割[J]. *北京航空航天大学学报*, DOI: 10.13700/j.bh.1001-5965.2021.0268. (Chen G, Lin D, Chen F, et al. Image segmentation based on logistic regression sparrow algorithm[J]. *Journal of Beijing University of Aeronautics and Astronautics*, DOI: 10.13700/j.bh.1001-5965.2021.0268.)
- [17] 付华, 刘昊. 多策略融合的改进麻雀搜索算法及其应用[J]. *控制与决策*, 2022, 37(1): 87-96. (Fu H, Liu H. Improved sparrow search algorithm with multi-strategy integration and its application[J]. *Control and Decision*, 2022, 37(1): 87-96.)
- [18] 毛清华, 张强. 融合柯西变异和反向学习的改进麻雀算法[J]. *计算机科学与探索*, 2021, 15(6): 1155-1164. (Mao Q H, Zhang Q. Improved sparrow algorithm combining cauchy mutation and opposition-based learning[J]. *Journal of Frontiers of Computer Science and Technology*, 2021, 15(6): 1155-1164.)
- [19] 宁爱平, 张雪英. 人工蜂群算法的收敛性分析[J]. *控制与决策*, 2013, 28(10): 1554-1558. (Ning A P, Zhang X Y. Convergence analysis of artificial bee colony algorithm[J]. *Control and Decision*, 2013, 28(10): 1554-1558.)
- [20] 国强, 朱国会, 李万臣. 基于混沌麻雀搜索算法的 TDOA/FDOA 定位[EB/OL]. [2021-11-19]. <http://kns.cnki.net/kcms/detail/22.1341.t.20210901.1814.023.html>. (Guo Q, Zhu G C, Li W C. TDOA/FDOA location based on chaotic sparrow search algorithm[J]. [2021-11-19]. <http://kns.cnki.net/kcms/detail/22.1341.t.20210901.1814.023.html>.)
- [21] 原永亮, 郭正刚, 王鹏, 等. 基于改进蜻蜓算法的斗轮取料机多目标优化[J]. *机械工程学报*, 2021, 57(6): 211-223. (Yuan Y L, Guo Z G, Wang P, et al. Multi-objective optimization of bucket wheel reclaimer based on improved dragonfly algorithm[J]. *Journal of Mechanical Engineering*, 2021, 57(6): 211-223.)
- [22] Tizhoosh H R. Opposition-based learning: A new scheme for machine intelligence[C]. *International Conference on Computational Intelligence for Modelling, Control and Automation and International Conference on Intelligent Agents, Web Technologies and Internet Commerce (CIMCA-IAWTIC'06)*. Vienna, 2006: 695-701.
- [23] 逯苗, 何登旭, 曲良东. 非线性参数的精英学习灰狼优化算法[J]. *广西师范大学学报: 自然科学版*, 2021, 39(4): 55-67. (Lu M, He D X, Qu L D. Grey wolf optimization algorithm based on elite learning for nonlinear parameters[J]. *Journal of Guangxi Normal University: Natural Science Edition*, 2021, 39(4): 55-67.)
- [24] 黄敬宇. 融合 t 分布和 Tent 混沌映射的麻雀搜索算法研究[D]. 兰州: 兰州大学, 2021. (Huang J Y. Research on sparrow search algorithm based on fusion of t distribution and tent chaotic mapping 2[D]. Lanzhou: Lanzhou University, 2021.)
- [25] 周蓉, 李俊, 王浩. 基于灰狼优化的反向学习粒子群算法[J]. *计算机工程与应用*, 2020, 56(7): 48-56. (Zhou R, Li J, Wang H. Reverse learning particle swarm optimization based on grey wolf optimization[J]. *Computer Engineering and Applications*, 2020, 56(7): 48-56.)
- [26] 杨兴, 郭明昊, 方霞, 等. 基于天牛须搜索自适应的樽海鞘算法[J]. *计算机技术与发展*, 2021, 31(6): 1-6. (Yang X, Guo M H, Fang X, et al. Salp swarm algorithm based on beetle antennae search and adaptive[J]. *Computer Technology and Development*, 2021, 31(6): 1-6.)
- [27] 顾清华, 李学现, 卢才武, 等. 求解高维复杂函数的遗传-灰狼混合算法[J]. *控制与决策*, 2020, 35(5): 1191-1198. (Gu Q H, Li X X, Lu C W, et al. Hybrid genetic grey wolf algorithm for high dimensional complex function optimization[J]. *Control and Decision*, 2020, 35(5): 1191-1198.)

作者简介

顾清华(1981—), 男, 教授, 博士生导师, 从事运筹与管理、系统优化理论与应用等研究, E-mail: qinghuagu@126.com;

姜秉佼(1996—), 女, 硕士生, 从事智能优化算法的研究, E-mail: 820433765@qq.com;

常朝朝(1982—), 男, 博士生, 从事矿山生产调度优化、矿山设计优化的研究, E-mail: changzz2018@xauat.edu.cn;

李学现(1993—), 男, 博士生, 从事智能优化算法的研究, E-mail: lixuexian2019@163.com.