

控制与决策

Control and Decision

多策略融合的改进麻雀搜索算法及其应用

付华, 刘昊

引用本文:

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.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2021.0582>

您可能感兴趣的其他文章

Articles you may be interested in

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>

基于动态行为选择的和声搜索算法

Harmony search algorithm based on dynamic behavior selection
控制与决策. 2021, 36(3): 577–588 <https://doi.org/10.13195/j.kzyjc.2019.0597>

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>

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>

多策略融合的改进麻雀搜索算法及其应用

付华[†], 刘昊

(辽宁工程技术大学 电气与控制学院, 辽宁 葫芦岛 125105)

摘要: 针对麻雀搜索算法易陷入局部最优、收敛速度慢等不足, 提出一种多策略融合的改进麻雀搜索算法. 采用精英混沌反向学习策略生成初始种群, 增强初始个体的质量和种群多样性, 实现对更多优质搜索区域的勘探以提升算法的局部极值逃逸能力和收敛性能; 结合鸡群算法的随机跟随策略, 优化麻雀搜索算法中跟随者的位置更新过程, 平衡算法的局部开发性能和全局搜索能力; 采用柯西-高斯变异策略提升算法的种群多样性保持能力和抗停滞能力. 对 10 个不同特征的基准测试函数进行寻优, 测试结果与 Wilcoxon 符号秩检验结果均表明改进算法具有更好的寻优精度、收敛性能和稳定性. 最后, 利用改进算法对最小二乘支持向量机的参数进行优化, 应用于煤与瓦斯突出危险性辨识, 通过实验进一步验证改进策略的有效性和改进算法的优越性.

关键词: 智能优化算法; 麻雀搜索算法; 多策略融合; 煤与瓦斯突出; 危险性辨识

中图分类号: TD713

文献标志码: A

DOI: 10.13195/j.kzyjc.2021.0582

开放科学(资源服务)标识码(OSID):



引用格式: 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.

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

FU Hua[†], LIU Hao

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

Abstract: Aiming at the shortcomings of the sparrow search algorithm, such as falling into local optimum easily and slow convergence speed, an improved sparrow search algorithm based on multi-strategy fusion is proposed. The elite chaotic reverse learning strategy is used to generate the initial population, which enhances the quality of the initial individuals and the diversity of the population, and realizes the exploration of more high-quality search areas to improve the local extremum escape ability and convergence performance of the algorithm. Combined with the random following strategy of the chicken swarm algorithm, the position updating process of the followers in the sparrow search algorithm is optimized, and the local development performance and global search ability of the algorithm are balanced. The Cauchy-Gauss mutation strategy is used to improve the ability of maintaining population diversity and resisting stagnation. Ten benchmark test functions with different characteristics are optimized. The test results and Wilcoxon's signed rank test results both show that the improved algorithm has better optimization accuracy, convergence performance and stability. Finally, the improved algorithm is used to optimize the parameters of the least square support vector machine and is applied to the identification of coal and gas outburst risk. The effectiveness of the improved strategy and the superiority of the improved algorithm are further verified by comparative experiments.

Keywords: intelligent optimization algorithm; sparrow search algorithm; multi-strategy integration; coal and gas outburst; identification of risk

0 引言

群体智能算法中的麻雀搜索算法^[1](sparrow search algorithm, SSA), 具有需调节参数少、寻优性能强等特点, 已成功应用于 CT 图像的部位检测^[2]、电池堆参数优化识别^[3]、机器学习算法的参数优化^[4]和无

人机航迹规划^[5-6]等实际问题. 但麻雀搜索算法仍存在对初始解依赖, 迭代后期种群多样性骤降、容易陷入局部最优值等不足.

为提升麻雀搜索算法的综合性能, 国内外学者对其进行了相关的改进研究, 主要的改进方法可分

收稿日期: 2021-04-07; 录用日期: 2021-07-29.

基金项目: 国家自然科学基金项目(51974151; 71771111); 辽宁省高等学校国(境)外培养项目(2019GJWZD002); 辽宁省高等学校创新团队项目(LT2019007); 辽宁省教育厅科技项目(LJ2019QL015).

责任编辑: 陈家伟.

[†]通讯作者. E-mail: fxfuhua@163.com.

为: 1) 改变种群初始化的方式. 文献[7]在麻雀种群初始化阶段引入反向学习方法; 文献[8]将混沌思想引入种群初始化过程, 并通过高斯变异和混沌扰动对种群进行调整, 实现种群质量的提升和搜索范围的扩大, 从而增强算法的局部最优规避能力. 2) 优化个体位置的更新过程. 文献[9]结合鸟群算法中的飞行思想改进麻雀个体的位置迭代公式, 避免因种群内个体的快速同化导致陷入局部最优; 文献[10]提出利用正余弦搜索策略、自适应局部策略等不同策略对跟随者和最优个体的位置更新进行优化, 有效提升了算法的寻优能力和收敛性能. 3) 引入变异算子. 文献[11]引入柯西变异算子和反向学习策略在最优解位置进行扰动变异, 增强算法跳出局部空间的能力; 文献[12]在搜索者的位置更新部分引入学习系数, 同时利用变异算子改进跟随者的位置更新, 避免算法陷入局部空间极值. 上述文献从不同角度对麻雀搜索算法进行改进, 虽然跳出局部空间的能力有所提升, 但收敛效果不理想、全局搜索能力和局部开发能力不协调的问题依然存在.

本文针对基本麻雀搜索算法的特性和不足, 提出一种融合精英混沌反向学习策略、随机跟随策略和柯西-高斯变异策略的改进麻雀搜索算法(improved sparrow search algorithm, ISSA). 通过实验对比分析, 证明ISSA能够更好地兼顾局部开发和全局勘探, 求解精度和收敛性能得到显著提升.

1 麻雀搜索算法的分析

标准麻雀搜索算法中初始麻雀个体都是在搜索空间内随机生成的, 迭代过程中逐渐聚集, 难以获取较好的种群多样性并保持在一定水平, 导致算法出现收敛性能差, 全局搜索能力与局部开发性能不协调的问题.

麻雀种群根据个体能力的不同, 分为搜索者、跟随者和警戒者. 跟随者的位置更新公式如下:

$$x_{i,d}^{t+1} = \begin{cases} Q \exp\left(\frac{X_{\text{worst}}^t - x_{i,d}^t}{i^2}\right), & i > \frac{N}{2}; \\ x_{p,d}^{t+1} + |x_{i,d}^t - x_{p,A}^{t+1}| A^+ L, & i \leq \frac{N}{2}. \end{cases} \quad (1)$$

其中: $x_{p,d}^{t+1}$ 表示 $t + 1$ 次迭代搜索者的最优位置; X_{worst}^t 表示当前全局最差位置; A 表示元素为1或-1的 d 维矩阵, $A^+ = A^T(AA^T)^{-1}$. 跟随者位置更新过程主要由 $x_{p,d}^{t+1}$ 和 X_{worst}^t 引导, 没有充分利用种群中大多数普通个体所携带的信息, 减小了有效勘探区域, 降低了算法在全局范围内的勘探能力.

由麻雀个体的迭代寻优过程可知, 麻雀搜索算法寻优能力的强弱受其种群个体质量和位置更新参数

的影响. 而且, 麻雀个体的更新主要依赖于个体间的跟随和相互作用, 个体的迭代更新过程缺少变异机制, 一旦陷入局部最优停滞, 难以跳出当前局部空间.

2 改进的麻雀搜索算法

鉴于上述分析, 对SSA算法从以下3个方面进行改进: 1) 提出精英混沌反向学习策略并引入麻雀种群初始化过程, 扩大全局勘探范围的同时避免初始种群的随机性引起算法的不确定性, 提升算法规避局部极值的能力和收敛速度; 2) 在跟随者位置更新过程引入随机跟随策略, 协调算法的全局搜索性能和局部开采能力; 3) 采用柯西-高斯变异策略提升算法的种群多样性保持能力和抗停滞能力, 帮助算法跳出局部最优.

2.1 种群初始化的改进

通过精英化思想将混沌解和反向解组合, 在更大的范围内选取精英个体, 实现对初始麻雀种群多样性和麻雀个体质量的提升.

2.1.1 初始种群多样化

选用均匀性更好的立方混沌映射初始化麻雀种群. 混沌算子^[13]具有随机性和规律性的优点, 能够在一定范围内对所有的状态不重复遍历, 公式如下:

$$2y_{i+1} = 4y_i^3 - 3y_i; \quad (2)$$

$$-1 < y_i < 1, y_i \neq 0, i = 0, 1, \dots, N; \quad (3)$$

$$x_i = X_{lb} + \frac{(X_{ub} - X_{lb})(y_i + 1)}{2}. \quad (4)$$

式(4)中: x_i 为映射后麻雀个体; X_{lb} 和 X_{ub} 分别对应解空间中的下界和上界. 混沌立方映射初始化麻雀种群的具体过程为: 随机在 $[-1, 1]$ 内生成一个 d 维向量作为初始个体, 然后代入式(2)对其每一维进行迭代生成 $N - 1$ 个新个体, 最后代入式(4)将立方映射产生的变量值映射到麻雀个体上.

2.1.2 初始种群精英化

通过透镜成像反向学习方法^[14]计算透镜成像反向解来扩大可选解的范围, 增加选取更优解的概率, 从而实现对初始种群个体质量的提升. 设 x_j 和 x_j^* 分别表示当前麻雀个体及其透镜成像反向后个体, 有

$$x_j^* = \frac{a_j + b_j}{2} + \frac{a_j + b_j}{2k} - \frac{x_j}{k}. \quad (5)$$

其中: a_j 和 b_j 分别表示当前种群第 j 维中的最小值和最大值, k 为透镜的缩放系数.

精英混沌反向学习策略初始化麻雀种群的具体过程为: 随机初始化个体数为 N 的初始麻雀种群 $X = [x_{i1}, \dots, x_{id}], i = 1, \dots, N, x_{id}$ 表示第 i 只麻雀在第 d 维的位置; 将种群 X 代入式(4)生成混沌种群

Y,同时将种群X代入式(5)生成透镜成像反向种群Z;将种群Y和种群Z内麻雀个体根据适应度值进行排序,选择前N个较优个体构成精英混沌反向种群P;种群P与原麻雀种群X根据个体适应度值排序选取前N个个体组成新的初始麻雀种群.

$$X' = [x'_{i1}, \dots, x'_{id}]. \quad (6)$$

2.2 跟随者位置更新的改进

标准SSA算法中的跟随者在向最优位置移动时,容易出现种群在短时间内迅速集聚的情况,虽然能够达到快速收敛的效果,但种群的多样性骤降,致使算法陷入局部最优的概率大大增加. 鸡群优化算法^[15]是一种具有优秀全局寻优能力的随机优化算法,其中的随机跟随策略是母鸡以一定概率向公鸡靠拢,既保证了收敛性,又没有降低种群多样性,能够很好地兼顾局部开发和全局搜索. 母鸡的位置更新公式如下:

$$X_{i,j}^{t+1} = X_{i,j}^t + S_1 \text{rand}(0,1)(X_{r,j}^t - X_{i,j}^t) + S_2 \text{rand}(0,1)(X_{r,j}^t - X_{i,j}^t), \quad (7)$$

$$S_1 = \exp\left(\frac{f_i - f_r}{|f_i| + \varepsilon}\right), \quad (8)$$

$$S_2 = \exp(f_s - f_i). \quad (9)$$

其中: r 表示母鸡配偶中任意第 r 只公鸡; s 表示鸡群内任意第 s 只公鸡或母鸡, $r \neq s$.

将随机跟随策略引入麻雀搜索算法中的跟随者位置更新过程,充分利用上一代个体的位置信息和概率性变化. 改进后跟随者位置更新公式如下:

$$x_{i,d}^{t+1} = \begin{cases} Q \exp\left(\frac{X_{\text{worst}}^t - x_{i,d}^t}{i^2}\right), & i > \frac{n}{2}; \\ X_{i,d}^t + S_3 \text{rand}(0,1)(x_{k,j}^t - x_{i,d}^t), & i \leq \frac{n}{2}. \end{cases} \quad (10)$$

其中: $S_3 = \exp(f_s - f_i)$, f_i 表示第 i 只麻雀的适应度值 $k \in [1, N]$,且 $k \neq i$.

2.3 引入柯西高斯变异策略

在基本SSA算法迭代的后期,麻雀个体的快速同化,导致容易出现局部最优停滞的情况. 为了解决这一问题,采用柯西-高斯变异策略^[16],选择当前适应度最好的个体进行变异,然后比较其变异前后的位置,选择较优的位置代入下一次迭代. 具体公式如下:

$$U_{\text{best}}^t = X_{\text{best}}^t [1 + \lambda_1 \text{cauchy}(0, \sigma^2) + \lambda_2 \text{Gauss}(0, \sigma^2)]. \quad (11)$$

$$\sigma = \begin{cases} 1, & f(X_{\text{best}}) < f(X_i); \\ \exp\left(\frac{f(X_{\text{best}}) - f(X_i)}{|f(X_{\text{best}})|}\right), & \text{otherwise}. \end{cases} \quad (12)$$

其中: U_{best}^t 表示最优个体变异后的位置; σ^2 表示柯西-高斯变异策略的标准差; $\text{cauchy}(0, \sigma^2)$ 是满足柯西分布的随机变量; $\text{Gauss}(0, \sigma^2)$ 是满足高斯分布的随机变量; $\lambda_1 = 1 - t^2/T_{\text{max}}^2$ 和 $\lambda_2 = t^2/T_{\text{max}}^2$ 是随迭代次数自适应调整的动态参数. 在寻优过程中, λ_1 逐渐减小, λ_2 逐渐增大,使算法可以跳出当前停滞,并协调其局部开发和全局探索的能力.

2.4 时间复杂度分析

时间复杂度^[17]是反映算法性能的一个重要指标. 假设麻雀种群规模为 N ,解空间为 D 维,求解目标函数所需的执行时间为 $f(D)$. 根据文献[11],SSA算法的时间复杂度为

$$T = O(D + f(D)). \quad (13)$$

在ISSA算法中,参数初始化所需执行时间为 η_0 ,每一维上生成随机数的时间为 η_1 ,按式(4)生成混沌种群的时间为 η_2 ,按式(5)生成反向种群所需时间为 η_3 ,则麻雀种群初始化阶段的时间复杂度为

$$T_1 = O(\eta_0 + Nf(D) + D(\eta_1 + \eta_2 + \eta_3)) = O(D + f(D)). \quad (14)$$

麻雀种群中发现者数量为 r_1N , r_1 为发现者比例,每一维进行位置更新的时间为 η_4 ,两个随机参数生成时间为 η_5 ,则发现者位置更新阶段时间复杂度为

$$T_2 = O(r_1N(\eta_4 + \eta_5 + \eta_5)D) = O(D). \quad (15)$$

麻雀种群中跟随者数量为 r_2N , r_2 为跟随者比例,每一维按式(10)进行位置更新的时间为 η_6 , k 为 $(0, N)$ 的随机数,其生成时间为 η_7 ,则该阶段的时间复杂度为

$$T_3 = O(r_2N(\eta_6 + \eta_7)D) = O(D). \quad (16)$$

麻雀种群中警戒者数量为 $(1 - r_1 - r_2)N$,每一维进行位置更新的时间为 η_8 ,两个正态分布随机参数更新的时间为 η_9 ,则这一阶段的时间复杂度为

$$T_4 = O((1 - r_1 - r_2)N(\eta_8 + \eta_9 + \eta_9)D) = O(D). \quad (17)$$

在柯西-高斯变异阶段,按式(11)更新麻雀最优个体所需的时间为 η_{10} ,生成随机变量 $\text{cauchy}(0, \sigma^2)$ 和 $\text{Gauss}(0, \sigma^2)$ 所需的时间分别为 η_{11} 和 η_{12} ,则此阶段的时间复杂度为

$$T_5 = O(N(\eta_{10} + \eta_{11} + \eta_{12})D) = O(D). \quad (18)$$

最大迭代次数为 iter_{max} ,ISSA算法的时间复杂度为

$$T' = T_1 + \text{iter}_{\max}(T_2 + T_3 + T_4 + T_5) = O(D + f(D)). \quad (19)$$

综上所述,ISSA与标准SSA算法的时间复杂度一致,针对SSA特性和不足所提出的改进策略没有增加算法的时间复杂度。

3 ISSA算法性能测试与分析

3.1 测试函数的选取

为了验证ISSA的优化效果和稳定性,利用10个单峰、多峰基准测试函数进行函数优化的对比测试。测试函数及其具体信息如表1所示。

表1 测试函数

类型	函数名称	测试函数	维数 D	搜索范围	最优值
单峰测试函数	Sphere	$F_1(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
	Schwefel 2.22	$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	30	$[-10, 10]$	0
	Schwefel 1.2	$F_3(x) = \sum_{i=1}^n \left(\sum_{j=1}^i x_j \right)^2$	30	$[-100, 100]$	0
	Schwefel 2.21	$F_4 = \max_i \{ x_i , 1 \leq i \leq n \}$	30	$[-100, 100]$	0
	Rosenbrock	$F_5(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-30, 30]$	0
	Step	$F_6(x) = \sum_{i=1}^n ([x_i + 0.5])^2$	30	$[-100, 100]$	0
	Quartic	$F_7(x) = \sum_{i=1}^n ix_i^4 + \text{random}[0, 1]$	30	$[-1.28, 1.28]$	0
多峰测试函数	Schwefel 2.26	$F_8(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	$-418.9829D$
	Rastrigin	$F_9(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
	Griewank	$F_{10}(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]$	0

3.2 ISSA与其他智能算法的对比

选取麻雀搜索算法、改进麻雀搜索算法、粒子群算法(particle swarm optimization, PSO)^[18]和灰狼优化算法(grey wolf optimizer, GWO)^[19]进行测试函数寻优对比,所有算法的共有参数保持一致,种群规模设置为50,最大迭代次数设置为500。各算法的参数设置如表2所示。

表2 各算法的参数设置

算法	参数
SSA	$p_{\text{Num}} = 0.2 \text{ NP}, s_{\text{Num}} = 0.2 \text{ NP}, R_2 = 0.8$
ISSA	$p_{\text{Num}} = 0.2 \text{ NP}, s_{\text{Num}} = 0.2 \text{ NP}, R_2 = 0.8$
PSO	$W = 0.729, C_1 = 1.49445, C_2 = 1.49445$
GWO	a 从2线性递减至0, $r_1, r_2 \in [0, 1]$

为了去除偶然性引起的误差,分别对10个测试函数进行30次独立试验。表3列出了麻雀搜索算法、改进的麻雀搜索算法、粒子群算法和灰狼优化算法在多个标准测试函数上进行30次独立运行后所得到的实验结果。

由表3分析可知:在相同测试约束条件下,ISSA算法对10组测试函数的统计结果明显优于其他3种对比算法。对于单峰测试函数 F_1 、 F_3 、 F_4 ,SSA算法

和ISSA算法都能找到其理论最优值,但ISSA在平均值和标准差的计算方面表现更好,寻优效果远超PSO算法和GWO算法;在 F_2 测试函数上,只有ISSA寻找到理论最优解,对比SSA算法寻优精度显著提高;对于单峰基准测试函数 F_5 、 F_6 、 F_7 ,虽然ISSA没有寻找到理论最优解,但3个评价指标要比其他算法优越几个数量级甚至十几个数量级。对于多峰测试函数 F_8 ,几种算法结果的差别不大,ISSA寻优效果略优于其他算法;对于 F_9 和 F_{10} ,SSA和ISSA都能稳定地寻找到最优值,表明其算法本身的优越性。不论是单峰函数还是多峰函数,ISSA在多次寻优的过程中,平均值和标准差均比其他算法更小,表明ISSA的稳定性和鲁棒性明显优于其他算法,更接近理论值的最优解,表明改进后的麻雀搜索算法能充分高效地探索搜索空间,并保证较强的全局寻优能力和局部探索能力。

在运行时间方面,PSO和GWO整体表现略优于SSA和ISSA,这是由算法的不同寻优机制所导致的。ISSA在测试函数 F_1 、 F_6 、 F_9 和 F_{10} 上所需的平均运行时间较SSA更短,在其余测试函数上的运行时间与SSA相差无几,验证了ISSA与标准SSA时间复杂度的一致性,体现出ISSA的优秀寻优性能。

表3 不同智能算法的寻优结果

统计量	算法	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}
最优值	SSA	0.00e+00	2.32e-28	0.00e+00	0.00e+00	2.38e-04	2.04e-07	8.17e-05	-1.09e+04	0.00e+00	0.00e+00
	ISSA	0.00e+00	0.00e+00	0.00e+00	0.00e+00	7.85e-07	8.72e-14	2.11e-05	-1.26e+04	0.00e+00	0.00e+00
	PSO	1.17e-01	3.67e-01	1.21 e-01	1.34 e-01	4.14 e+01	2.43e-01	7.77e-02	-6.71e+03	3.86e+01	4.81e-03
	GWO	2.06e-34	1.55e-20	1.25e-10	3.15e-09	2.61e+01	4.17e-05	2.90e-04	-7.14e+03	1.14e-13	0.00e+00
平均值	SSA	3.47e-35	1.15e-20	1.65e-26	2.65e-14	8.36e-02	1.58e-03	5.11e-04	-8.64e+03	0.00e+00	0.00e+00
	ISSA	1.13e-81	9.25e-49	6.28e-93	3.96e-56	9.16e-06	2.51e-07	3.20e-04	-1.26e+04	0.00e+00	0.00e+00
	PSO	2.03e-01	4.61e-01	2.15e-01	1.76e-01	5.33e+01	4.28e-01	2.12e-01	-6.65e+03	6.15e+01	1.02e-02
	GWO	2.75e-33	2.94e-19	1.56e-08	2.02e-08	2.67e+01	2.75e-01	8.75e-04	-6.45e+03	1.86e-13	2.83e-03
标准差	SSA	1.65e-34	4.57e-20	8.04e-26	1.22e-13	5.76e-02	1.71e-03	4.47e-04	1.46e+03	0.00e+00	0.00e+00
	ISSA	4.42e-81	3.20e-48	1.49e-92	1.32e-55	1.44e-05	8.30e-07	2.13e-04	2.70e-01	0.00e+00	0.00e+00
	PSO	6.62e-02	5.35e-02	7.18e-02	2.87e-02	8.29e+00	1.17e-01	1.82e-01	1.27e+02	1.52e+01	4.71e-03
	GWO	3.19e-33	3.78e-19	1.51e-08	1.37e-08	7.55e-01	1.85e-01	4.66e-04	3.87e+02	9.54e-14	5.70e-03
平均运行时间/s	SSA	0.653 8	0.587 1	0.891 6	0.580 2	0.711 5	0.535 2	0.572	0.535 7	0.581 6	0.602 2
	ISSA	0.563 4	0.636 8	0.905 6	0.624 9	0.731 2	0.522 1	0.608 4	0.589 1	0.532 1	0.576 1
	PSO	0.251 8	0.288 3	0.426 2	0.273 7	0.317 5	0.349	0.684 2	0.268 9	0.232 7	0.282 5
	GWO	0.407 7	0.380 5	0.562 9	0.370 1	0.501 4	0.236 8	0.390 0	0.355 0	0.320 6	0.387 9

为了进一步评估改进麻雀搜索算法的性能,在 $\alpha = 5\%$ 显著性水平下,对30次独立运算下的ISSA算法与其他3种算法的最佳结果进行Wilcoxon符号秩检验.符号“+”“-”“=”分别表示ISSA的性能优于、劣于和相当于对比算法,N/A表示算法结果接近,无法进行显著性判断.结果如表4所示,在10个基准测试函数中,ISSA的性能在8个测试函数上优于SSA,在10个测试函数上优于PSO,在9个测试函数上优于GWO,而且ISSA的 p 值基本都小于0.05,表明ISSA的优越性在统计上是显著的.

表4 Wilcoxon符号秩检验 p 值

函数	ISSA-GWO	ISSA-PSO	ISSA-SSA
F_1	4.32e-08	4.32e-08	1.80e-05
F_2	1.44e-07	4.32e-08	1.76e-05
F_3	4.32e-08	4.32e-08	1.76e-05
F_4	4.32e-08	4.32e-08	5.45e-06
F_5	1.61e-06	1.61e-06	1.61e-06
F_6	1.26e-06	1.26e-06	1.26e-06
F_7	8.21e-07	8.21e-07	1.7e-03
F_8	1.61e-06	1.61e-06	1.61e-06
F_9	4.32e-08	4.32e-08	N/A
F_{10}	N/A	4.32e-08	N/A
+ / = / -	9 / 1 / 0	10 / 0 / 0	8 / 2 / 0

通过对基准测试函数迭代收敛曲线的绘制,可进一步直观地对比各个算法的收敛性和算法跳出局部空间的能力.取测试中与结果平均值相近的一次绘制迭代收敛对比曲线,其中横轴表示迭代次数,纵轴表示适应度值.由图1~图6可知,对于不同类型的测试函数,在几种算法收敛到相同精度的情况下,ISSA所需的迭代次数最少,表明了精英混沌反向学习策略

的引入增加了种群中高质量个体所占的比例,提高了算法的收敛速度.随着迭代次数的增加,GWO算法和PSO算法的收敛曲线趋于平缓,存在不同程度的停滞,而且寻优精度相对较低.ISSA收敛曲线阶梯波动式下降,表明了柯西-高斯变异策略能够帮助算法有效脱离停滞,在全局范围内搜寻更优解.

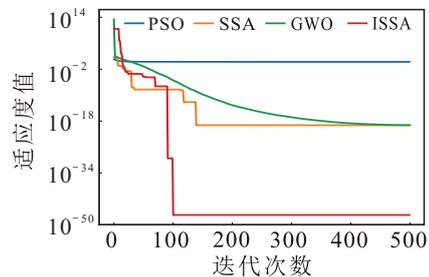


图1 函数 F_2 收敛曲线

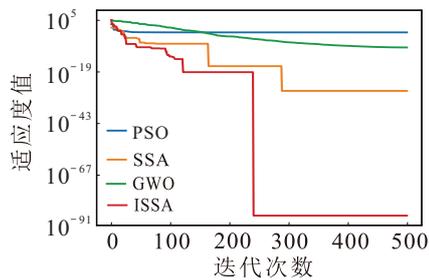


图2 函数 F_3 收敛曲线

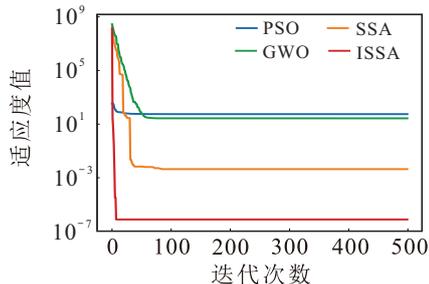


图3 函数 F_5 收敛曲线

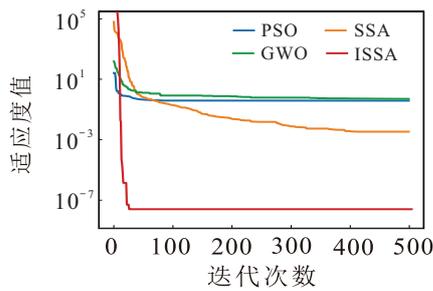


图4 函数 F_6 收敛曲线

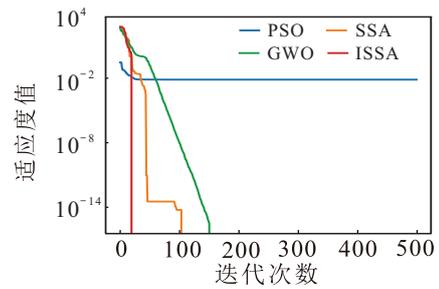


图6 函数 F_{10} 收敛曲线

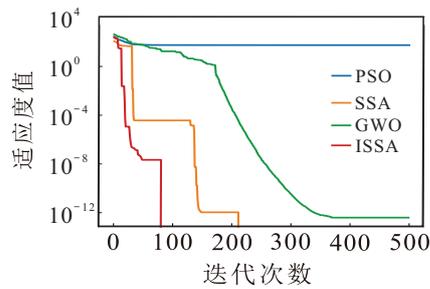


图5 函数 F_9 收敛曲线

算法和GWO算法具有更好的局部极值逃逸能力、整体寻优协同性和收敛性能。

3.3 ISSA 与不同改进SSA的对比

为进一步验证改进麻雀搜索算法的优越性,选取表1中的测试函数分别与文献[8-9, 11]中所提出的改进麻雀搜索算法CSSA、ISSA1、ISSA2进行寻优对比实验.通用条件以文献[8]为准,麻雀种群规模为30,迭代100次,各算法对每个测试函数独立运行30次得到寻优结果如表5所示。

综上所述,ISSA算法相比于标准SSA算法、PSO

表5 不同改进SSA算法的寻优结果

统计量	算法	F_1	F_2	F_3	F_4	F_5	F_6	F_7	F_8	F_9	F_{10}
最优值	CSSA	0.00e+00	5.23e-74	0.00e+00	2.67e-80	4.15e-05	8.35e-07	1.92e-04	-1.11e+04	0.00e+00	0.00e+00
	ISSA1	2.24e-67	1.64e-26	1.86e-65	1.69e-45	1.71e-03	4.09e-04	3.52e-04	-1.23e+04	0.00e+00	0.00e+00
	ISSA2	7.38e-41	4.32e-20	4.64e-39	1.05e-22	1.09e-05	1.41e-07	5.70e-04	-9.12e+03	0.00e+00	0.00e+00
	ISSA	0.00e+00	0.00e+00	0.00e+00	0.00e+00	2.44e-06	1.27e-07	1.09e-04	-1.26e+04	0.00e+00	0.00e+00
平均值	CSSA	7.16e-35	4.03e-18	1.05e-35	6.56e-19	6.73e-03	2.46e-05	1.08e-03	-9.24e+03	0.00e+00	0.00e+00
	ISSA1	9.39e-21	1.97e-15	5.50e-12	3.20e-18	1.89e-01	8.02e-03	2.86e-03	-9.86e+03	0.00e+00	0.00e+00
	ISSA2	3.17e-20	6.60e-10	1.26e-18	2.36e-09	1.39e-02	7.25e-05	1.88e-03	-5.77e+03	0.00e+00	0.00e+00
	ISSA	3.80e-79	2.07e-46	1.59e-75	3.06e-48	8.51e-03	6.69e-06	9.26e-04	-9.35e+03	0.00e+00	0.00e+00
标准差	CSSA	2.77e-34	4.03e-18	4.07e-35	2.15e-18	1.19e-02	3.11e-05	8.22e-04	1.36e+03	0.00e+00	0.00e+00
	ISSA1	3.64e-20	3.41e-15	2.13e-11	9.55e-18	4.30e-01	6.78e-03	2.44e-03	2.04e+03	0.00e+00	0.00e+00
	ISSA2	9.31e-20	2.36e-09	4.78e-18	9.10e-09	2.37e-02	9.84e-05	1.21e-03	1.81e+03	0.00e+00	0.00e+00
	ISSA	1.47e-78	8.03e-46	6.14e-75	1.18e-47	1.24e-02	1.23e-05	5.82e-04	1.85e+03	0.00e+00	0.00e+00

与其他3种改进SSA相比,ISSA从种群初始化、个体迭代和突变更新3个角度出发,提出更符合麻雀算法的高效改进策略.在种群初始化阶段,ISSA1和基本SSA算法都采用随机选取的方式,ISSA2和CSSA引入混沌映射,ISSA利用精英化思想将效果更好的立方混沌映射与透镜反向学习组合,以实现在更大范围内获取更优秀的初始麻雀种群.在个体的迭代过程中,对比ISSA1引入鸟群算法中的飞行思想,ISSA创新性地引入鸡群算法中的随机跟随策略引入跟随者的位置更新过程.在对种群内最优个体的变异扰动中,ISSA在ISSA2中的柯西变异的基础上进一步提出了柯西-高斯变异策略.通过多策略融合的方式,增强初始种群的多样性和质量,充分利用麻雀个体间信息交互以实现平衡算法的局部开发和全

局搜索,同时提升算法的局部极值逃逸能力。

由表5可知:ISSA算法在对10个函数的寻优中,其中6个测试函数能够收敛到理论最优解,并且10个函数的最优值均表现最佳,说明ISSA在30次的独立寻优中具有优秀的整体寻优水平和较好的单次寻优精度.ISSA在9个函数上具有更好的平均值和标准差,反映出ISSA相比CSSA、ISSA1和ISSA2具有较高的收敛精度和鲁棒性.具体来说,对于单峰函数 F_1 和 F_3 ,CSSA和ISSA都有能力收敛到理论最优值,但CSSA的平均值和标准差与ISSA相差几十个数量级.对于单峰函数 F_2 和 F_4 ,只有ISSA算法寻找到理论最优解,并且具备更小的平均值和标准差.对于单峰函数 F_5 、 F_6 和 F_7 ,在4种算法无法求解到理论最优值的情况下,ISSA在几种算法中表现出更好的收敛

精度和稳定度. 对于多峰测试函数 F_8 , ISSA 能够找到最接近理论最优值的解, 4种算法的平均值和标准差都在同一数量级. 对于多峰函数 F_9 和 F_{10} , 4种改进算法的寻优结果的最优值、平均值和标准差都是理论最优值, 说明了 SSA 算法本身全局搜索能力的优越性.

综上, 与 CSSA、ISSA1 和 ISSA2 相比, ISSA 的寻优性能具有显著性的优势, 表明根据标准 SSA 的不足所提出的改进策略更具有有效性和优越性.

3.4 改进策略的有效性分析

为了进一步分析3种改进策略的有效性以及对 ISSA 算法性能的影响, 将标准 SSA、仅采用精英混沌反向学习策略的 SSA(ECSSA)、仅采用随机跟随策略的 SSA(RSSA)、仅采用柯西-高斯变异策略的 SSA(CGSSA) 和 ISSA 对表1中的测试函数进行寻优实验, 各算法的参数设置与基本 SSA 保持一致, 迭代次数为 500.

表6给出了5种算法各自独立运行30次在10维、

30维和100维下对部分函数的测试结果. 当函数的维度从10维到30维再增加至100维时, 各算法的求解精度、稳定性和鲁棒性均有所下降, 这是由于维度的增加, 对函数的求解也更加复杂. 对于单峰测试函数 F_1 , SSA、ECSSA、RSSA 和 ISSA 的最优值都能达到理论最优值, ECSSA、ISSA 和 RSSA 分别在维度为 10、30 和 100 时, 平均值和标准差表现更好. 对于单峰测试函数 F_2 , 在维度 10 和 30 下, SSA、ECSSA、RSSA 和 ISSA 的最优值都能达到理论最优值, 在维度 100 下, SSA、ECSSA 和 ISSA 的最优值都能达到理论最优. 在3个维度下共9个评价指标量中, ISSA 表现最好的数量为7个, ECSSA 表现最好的数量为5个, 表明了引入精英混沌反向学习策略对算法收敛性能的提升. 对于单峰函数 F_5 和多峰函数 F_8 , 几种算法都没能收敛到理论最优值, 在3个维度下共9个评价指标量中, ISSA 表现最好的数量都为6个. CGSSA 在多峰函数 F_8 的寻优中, 对比 SSA、ECSSA 和 RSSA 算法表现突出, 表明柯西-高斯变异策略能够有效改善 SSA 算法易陷入局部最优的问题.

表6 不同改进策略的寻优结果

统计量	算法	D = 10			D = 30			D = 100		
		最优值	平均值	标准差	最优值	平均值	标准差	最优值	平均值	标准差
F_1	SSA	0.00e+00	5.31e-39	2.06e-38	0.00e+00	3.36e-59	1.30e-58	0.00e+00	7.23e-52	2.71e-51
	ECSSA	0.00e+00	5.76e-93	2.23e-92	0.00e+00	5.73e-76	2.27e-75	0.00e+00	1.35e-50	5.09e-50
	RSSA	0.00e+00	1.88e-58	5.36e-58	0.00e+00	1.38e-64	5.32e-64	0.00e+00	1.05e-85	4.06e-85
	CGSSA	5.96e-79	2.70e-43	1.14e-42	3.12e-96	4.06e-51	1.07e-50	9.96e-121	1.21e-45	4.38e-45
	ISSA	0.00e+00	3.79e-89	1.11e-88	0.00e+00	5.72e-83	2.14e-82	0.00e+00	2.22e-77	8.58e-77
F_2	SSA	0.00e+00	1.07e-28	4.13e-28	0.00e+00	7.10e-31	2.75e-30	0.00e+00	1.39e-27	5.39e-27
	ECSSA	0.00e+00	1.87e-29	7.22e-29	0.00e+00	2.32e-33	8.99e-33	0.00e+00	1.29e-46	5.01e-46
	RSSA	0.00e+00	7.43e-22	2.88e-21	0.00e+00	2.17e-23	6.82e-23	8.62e-157	6.80e-31	2.63e-30
	CGSSA	1.71e-47	3.51e-17	1.36e-16	3.55e-69	5.67e-30	2.10e-29	1.36e-44	5.29e-29	1.96e-28
	ISSA	0.00e+00	2.97e-62	1.14e-61	0.00e+00	2.60e-36	1.00e-35	0.00e+00	9.34e-33	3.49e-32
F_5	SSA	2.59e-04	2.03e-03	3.23e-03	7.29e-03	2.04e-02	1.04e-02	6.61e-02	2.44e-01	2.33e-01
	ECSSA	8.97e-06	7.95e-04	6.11e-04	8.29e-06	1.63e-02	1.54e-02	3.01e-02	2.35e-01	2.35e-01
	RSSA	7.91e-05	8.77e-04	8.16e-04	7.36e-05	2.78e-02	2.46e-02	8.98e-03	2.16e-01	1.78e-01
	CGSSA	1.24e-11	5.76e-05	1.77e-04	1.85e-11	2.54e-04	3.51e-04	1.21e-09	2.69e-03	6.03e-03
	ISSA	3.03e-09	3.56e-05	4.69e-05	2.13e-08	8.23e-05	1.59e-04	6.13e-06	2.14e-03	2.01e-03
F_8	SSA	-3.76e+03	-2.86e+03	5.29e+02	-1.26e-04	-8.58e+03	2.52e+03	-4.05e+04	-3.29e+04	7.81e+03
	ECSSA	-3.75e+03	-2.65e+03	5.43e+02	-1.26e-04	-8.50e+03	2.76e+03	-4.06e+04	-3.59e+04	6.56e+03
	RSSA	-3.71e+03	-2.80e+03	6.13e+02	-1.26e-04	-8.20e+03	2.63e+03	-4.15e+04	-3.19e+04	9.25e+03
	CGSSA	-4.19e+03	-2.67e+03	6.35e+02	-1.26e-04	-1.12e+04	1.26e+03	-4.19e+04	-3.80e+04	3.24e+03
	ISSA	-4.19e+03	-3.73e+03	4.42e+02	-1.26e-04	-9.81e+03	2.22e+03	-4.19e+04	-3.97e+04	2.13e+03

相比于基本 SSA, 分别引入3种改进策略的改进 SSA 算法, 在寻优结果的最优值、平均值和标准差上都有几量级到几十量级不同程度的提升. 但是, 单一策略对 SSA 的提升有限, 对于不同函数的寻优效果不能保持在较高水平. 融合3种改进策略的 ISSA 算法在整体上呈现出更好的求解性能, 在10维、30维

和100维下大部分寻优精度和稳定性明显优于其他4个对比算法, 验证了多策略融合对算法的全方位提升. 其中, 精英反向学习策略和柯西-高斯变异策略对标准 SSA 性能的提升起主导作用, 随机跟随策略协调算法的局部开发和全局搜索能力, 进一步提升了算法的寻优性能.

3.5 ISSA的种群多样性分析

为验证改进策略对种群多样性和种群质量的影响,选取 Sphere 函数^[20]进行寻优实验,问题维度为三维,并绘制ISSA迭代过程中精英混沌反向学习初始种群、迭代10次、50次后的麻雀个体位置分布图和SSA迭代50次后麻雀个体位置分布图如图7~和图11所示.图中红点表示全局最优点,蓝点表示麻雀个体,种群个数为50.为进一步分析全局最优解附近的麻雀个体多样性,将50次迭代图进行局部放大. Sphere公式如下:

$$F(x) = \sum_{i=1}^n x_i^2. \tag{20}$$

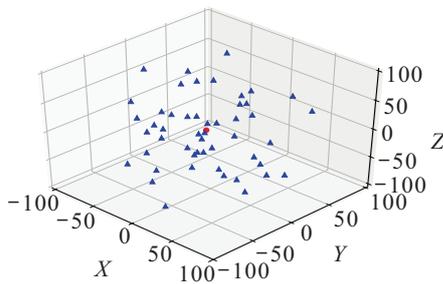


图7 ISSA精英混沌反向初始种群

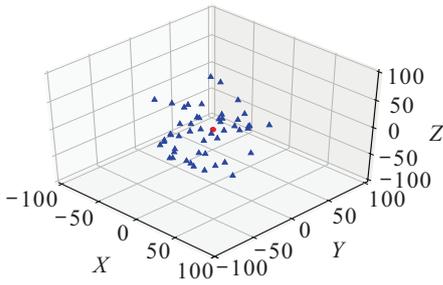


图8 ISSA迭代10次后种群

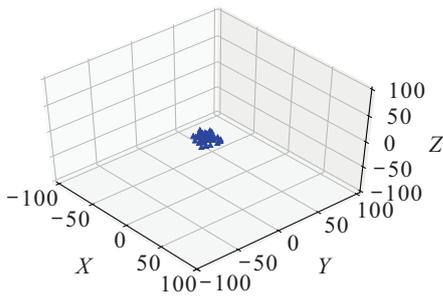


图9 ISSA迭代50次后种群

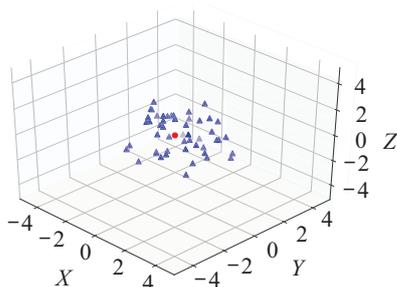


图10 ISSA迭代50次后种群局部放大

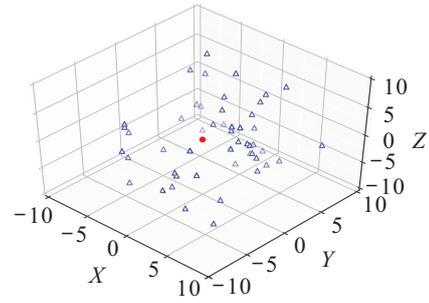


图11 SSA迭代50次后种群局部放大

由图7~图11可以看出,经精英混沌反向学习策略初始化的种群具有良好的多样性,麻雀个体均匀分布在最优值附近,为算法迭代寻优奠定了良好的基础.随着迭代次数的增加,精英麻雀个体引导种群以较快的速度靠近最优解,而且,与图11中麻雀个体分布进行对比,图10中麻雀种群在一定范围内保持均匀分布,验证了改进策略对种群多样性和种群质量的有效提升.

4 LSSVM优化对比实验

最小二乘支持向量机(least squares support vector machine, LSSVM)^[21]中的惩罚因子和核函数参数的选取直接影响LSSVM的抗干扰能力和泛化能力.选取ISSA算法、PSO算法、GWO算法和SSA算法分别对上述两个参数进行优化,采用煤与瓦斯突出相关数据进行仿真实验,通过所得煤与瓦斯突出危险性辨识结果的优劣反映改进算法在实际应用中的效果.

4.1 实验数据选择

实验数据来自某矿井工作面的历史监测数据,筛选出90组实测数据作为研究对象,从中随机抽取60组数据作为训练样本,剩余数据作为测试样本.根据煤与瓦斯突出的特性及有关研究^[22],结合矿区的实际情况,选取包括煤的瓦斯放散初速度 X_1 (mL/s)、煤的破坏类型 X_2 、煤的坚固性系数 X_3 、瓦斯含量 X_4 (m³/t)、瓦斯解吸量 X_5 (mL/(g·min^{0.5}))、钻屑量 X_6 (kg/m)、与地质构造带距离 X_7 (m)、煤层埋藏深

表7 煤与瓦斯突出影响因素部分数据

序号	1	2	3	4	5	6	7	8	9	类别
1	15.5	3	0.4	7.78	0.29	3.2	36	351	2.4	1
2	15.7	3	0.4	7.76	0.16	3.4	62	366	2.4	1
3	15.8	2	0.36	7.81	0.19	3.2	78	366	2.4	1
4	15.6	2	0.36	7.3	0.38	3.8	47	367	2.4	1
5	17.6	3	0.36	10.6	0.21	3.2	47	365	2.4	2
6	18.6	3	0.36	9.84	0.19	3.4	43	368	2.1	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
87	16.4	3	0.36	9.63	0.32	3.2	26	366	2.1	2
88	16.6	3	0.36	10.1	0.22	3.2	15	366	2.1	2
89	16.7	3	0.3	13.9	0.36	3.2	9	368	2.1	3
90	16.2	3	0.3	12.9	0.38	3.2	0	370	0	3

度 $X_8(m)$ 、煤的厚度 $X_9(m)$ 共9个指标,突出类别根据突出危险性分为无危险、一般危险和严重危险3类,分别用1、2、3表示.部分数据如表7所示,训练及测试样本数据的分布参照表8和表9.

表8 训练样本的分布

突出类别	无危险	一般危险	严重危险
测试样本数	20	20	20

表9 测试样本的分布

突出类别	无危险	一般危险	严重危险
测试样本数	10	10	10

4.2 仿真结果与分析

在 Matlab 上进行仿真实验,各算法对 LSSVM 参数优化后得到煤与瓦斯突出危险性辨识结果如图 12~图 16 所示.由辨识图 12~图 16 可知,LSSVM、PSO-LSSVM、GWO-LSSVM、SSA-LSSVM 和 ISSA-LSSVM 的煤与瓦斯危险性辨识准确度分别约为 80%、86.67%、90%、93.33% 和 96.67%.经 ISSA 优化后的 LSSVM 辨识准确率最高,表明 ISSA 算法相比

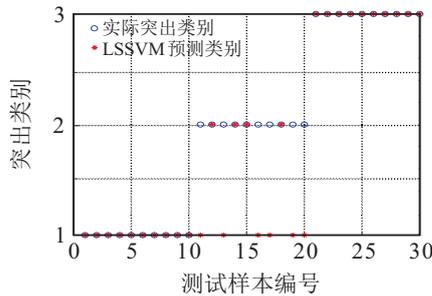


图 12 LSSVM 辨识结果

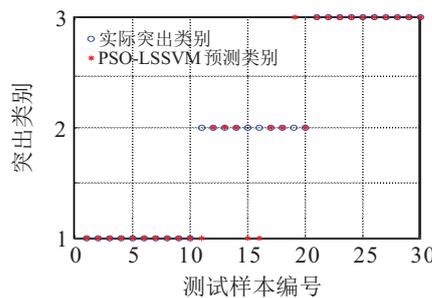


图 13 PSO-LSSVM 辨识结果

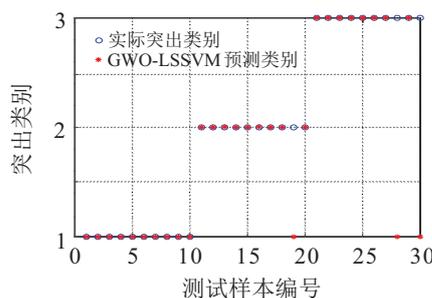


图 14 GWO-LSSVM 辨识结果

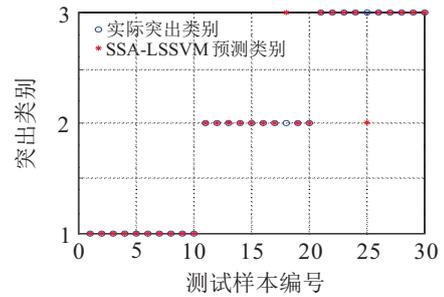


图 15 SSA-LSSVM 辨识结果

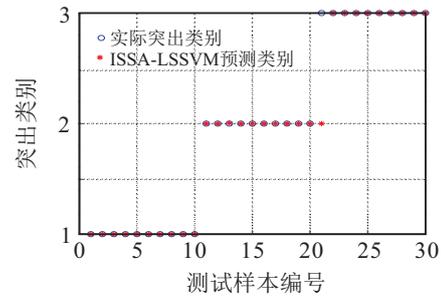


图 16 ISSA-LSSVM 辨识结果

于其他算法对 LSSVM 参数的优化效果更好,较优化前辨识率提升约 16.67%,表明了 ISSA 算法的优秀寻优能力.

5 结论

1) 根据对麻雀搜索算法迭代寻优过程的分析,得出麻雀种群初始化过程和麻雀个体位置的更新过程存在不足,并且麻雀个体不具备变异机制,限制了算法跳出局部空间的能力.

2) 在基准函数的寻优实验中,结果表明改进策略具有一定的协作互补性,ISSA 算法具有更好的收敛性能、整体寻优协同能力与求解稳定性,相较 SSA 算法综合性能提升显著.

3) 经 ISSA 优化后 LSSVM 的煤与瓦斯危险性辨识准确率高达 96.67%,较 LSSVM 辨识率提升约 16.67%,进一步验证了改进算法的优越性.

参考文献 (References)

- [1] Xue J K, Shen B. A novel swarm intelligence optimization approach: Sparrow search algorithm[J]. Systems Science & Control Engineering, 2020, 8(1): 22-34.
- [2] Zhang J N, Xia K W, He Z P, et al. Semi-supervised ensemble classifier with improved sparrow search algorithm and its application in pulmonary nodule detection[J]. Mathematical Problems in Engineering, 2021, 2021: 1-18.
- [3] Zhu Y L, Yousefi N. Optimal parameter identification of PEMFC stacks using adaptive sparrow search algorithm[J]. International Journal of Hydrogen Energy, 2021, 46(14): 9541-9552.
- [4] Li H M, Zhang Y. Study of transformer fault diagnosis based on sparrow optimization algorithm[C]. 2020

- International Conference on Control, Robotics and Intelligent System. Xiamen, 2020: 63-66.
- [5] 汤安迪, 韩统, 徐登武, 等. 基于混沌麻雀搜索算法的无人机航迹规划方法[J]. 计算机应用, 2021, 41(7): 2128-2136.
(Tang A D, Han T, Xu D W, et al. Path planning method of unmanned aerial vehicle based on chaos sparrow search algorithm[J]. Computer Application, 2021, 41(7): 2128-2136.)
- [6] Liu G, Shu C, Liang Z, et al. A modified sparrow search algorithm with application in 3d route planning for UAV[J]. Sensors, 2021, 21(4): 1224.
- [7] Liu T, Yuan Z, Wu L, et al. An optimal brain tumor detection by convolutional neural network and enhanced sparrow search algorithm[J]. Proceedings of the Institution of Mechanical Engineer—Part H: Journal of Engineering in Medicine, 2021, 235(4): 459-469.
- [8] 吕鑫, 慕晓冬, 张钧, 等. 混沌麻雀搜索优化算法[J]. 北京航空航天大学学报, 2021, 47(8): 1712-1720.
(Lv X, Mu X D, Zhang J, et al. Chaos sparrow search optimization algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(8): 1712-1720.)
- [9] 吕鑫, 慕晓冬, 张钧. 基于改进麻雀搜索算法的多阈值图像分割[J]. 系统工程与电子技术, 2021, 43(2): 318-327.
(Lyu X, Mu X D, Zhang J. Multi-threshold image segmentation based on improved sparrow search algorithm[J]. Systems Engineering and Electronics, 2021, 43(2): 318-327.)
- [10] 欧阳城添, 朱东林. 融合 K -means 的多策略改进麻雀搜索算法研究[J/OL]. (2021-01-27)[2021-04-07]. <http://kns.cnki.net/kcms/detail/41.1227.tn.20210127.0910.004.html>.
(OuYang C T, Zhu D L. Research on multi-strategy improved sparrow search algorithm based on K -mean[J/OL]. (2021-01-27)[2021-04-07]. <https://kns.cnki.net/kcms/detail/41.1227.tn.20210127.0910.004.html>.)
- [11] 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.)
- [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] 张达敏, 陈忠云, 辛梓芸, 等. 基于疯狂自适应的樽海鞘群算法[J]. 控制与决策, 2020, 35(9): 2112-2120.
(Zhang D M, Chen Z Y, Xin Z Y, et al. Salp swarm algorithm based on craziness and adaptive[J]. Control and Decision, 2020, 35(9): 2112-2120.)
- [14] 龙文, 伍铁斌, 唐明珠, 等. 基于透镜成像学习策略的灰狼优化算法[J]. 自动化学报, 2020, 46(10): 2148-2164.
(Long W, Wu T B, Tang M Z, et al. Grey wolf optimizer algorithm based on lens imaging learning strategy[J]. Acta Automatica Sinica, 2020, 46(10): 2148-2164.)
- [15] Osamy W, El-Sawy A A, Salim A. CSOCA: Chicken swarm optimization based clustering algorithm for wireless sensor networks[J]. IEEE Access, 2020, 8: 60676-60688.
- [16] Wang W C, Xu L, Chau K W, et al. Yin-Yang firefly algorithm based on dimensionally Cauchy mutation[J]. Expert Systems With Applications, 2020, 150: 113216.
- [17] 刘景森, 袁蒙蒙, 左方. 面向全局搜索的自适应领导者樽海鞘群算法[J]. 控制与决策, 2021, 36(9): 2152-2160.
(Liu J S, Yuan M M, Zuo F. Global search-oriented adaptive leader salp swarm algorithm[J]. Control and Decision, 2021, 36(9): 2152-2160.)
- [18] 钱晓宇, 方伟. 基于局部搜索的反向学习竞争粒子群优化算法[J]. 控制与决策, 2021, 36(4): 779-789.
(Qian X Y, Fang W. Opposition-based learning competitive particle swarm optimizer with local search[J]. Control and Decision, 2021, 36(4): 779-789.)
- [19] 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.)
- [20] 何庆, 林杰, 徐航. 混合柯西变异和均匀分布的蝗虫优化算法[J]. 控制与决策, 2021, 36(7): 1558-1568.
(He Q, Lin J, Xu H. Hybrid Cauchy mutation and uniform distribution of grasshopper optimization algorithm[J]. Control and Decision, 2021, 36(7): 1558-1568.)
- [21] Bemani A, Xiong Q G, Baghban A, et al. Modeling of cetane number of biodiesel from fatty acid methyl ester (FAME) information using GA-, PSO-, and HGAPSO-LSSVM models[J]. Renewable Energy, 2020, 150: 924-934.
- [22] Wang C, Li X, Xu C, et al. Study on factors influencing and the critical value of the drilling cuttings weight: An index for outburst risk prediction[J]. Process Safety and Environmental Protection, 2020, 140: 356-366.

作者简介

付华(1962—),女,教授,博士生导师,从事智能优化算法、智能系统的优化与控制等研究, E-mail: fxfuhua@163.com;

刘昊(1997—),男,硕士生,从事智能优化算法、智能系统的优化与控制的研究, E-mail: 2353733765@qq.com.

(责任编辑: 孙艺红)