

doi: 10.7690/bgzd.2026.02.015

基于改进金丝猴算法的无人机 3 维路径规划方法

张鸿宇^{1,2}, 龚俊¹, 苏瑞¹, 戴怡君²

(1. 中国兵器装备集团自动化研究所有限公司特种计算机事业部, 四川 绵阳 621000;

2. 重庆大学计算机学院, 重庆 400045)

摘要: 针对传统群智能算法在解决无人机 3 维路径规划时易出现收敛精度不高和陷入局部最优解的问题, 提出一种基于改进金丝猴算法的无人机 3 维路径规划方法。引入混沌映射对种群进行初始化, 增强个体的随机性; 采用非线性递减模型以平衡算法的全局搜索和局部开发能力, 通过精英反向学习策略让个体能更好地跳出局部最优。实验结果表明: 相比于其他群智能算法, 改进的金丝猴算法具有更好的寻优能力。

关键词: 路径规划; 金丝猴算法; 精英反向学习; 混沌映射

中图分类号: V279 **文献标志码:** A

3D Path Planning Method for UAV Based on Improved Golden Monkey Algorithm

Zhang Hongyu^{1,2}, Gong Jun¹, Su Rui¹, Dai Yijun²(1. Department of Special Computer, Automation Research Institute Co., Ltd. of
China South Industries Group Co., Ltd., Mianyang 621000, China;

2. College of Computer Science, Chongqing University, Chongqing 400045, China)

Abstract: Aiming at the problems of low convergence accuracy and falling into local optimal solution in solving UAV 3D path planning by traditional swarm intelligence algorithm, a UAV 3D path planning method based on improved golden monkey algorithm is proposed. Chaotic mapping is introduced to initialize the population to enhance the randomness of individuals. Nonlinear decreasing model is used to balance the global search and local exploitation ability of the algorithm, and elite reverse learning strategy is used to make the individual better jump out of the local optimum. The experimental results show that compared with other swarm intelligence algorithms, the improved golden monkey algorithm has better optimization ability.

Keywords: path planning; golden monkey algorithm; elitist inverse learning; chaotic mapping

0 引言

随着无人机技术的快速发展, 其卓越的机动能力使其在军事侦察、农业监测、物流运输和环境监测等领域得到了广泛应用。面对日益复杂的飞行环境和任务需求, 无人机必须高效地规划出安全且合理的最短路径; 因此, 3 维路径规划成为无人机自主飞行的重要研究领域^[1]。

目前, 常见的无人机路径规划算法有: 1) 传统路径规划算法, 比如人工势场法、模拟退火算法等; 2) 群智能算法, 如粒子群算法、蚁群算法等; 3) 深度强化学习算法, 例如 DQN^[2], MADDPG^[3]等。传统的路径规划算法在 3 维空间的路径规划上容易陷入局部最优且收敛速度慢等问题。深度强化学习自出现以来被尝试应用于各个领域, 发展迅速但不够成熟, 在实际解决问题中存在较多的局限。相比于传统算法, 群智能算法在解决 3 维路径规划问题中

有更快更好的寻优能力; 相比于深度强化学习, 实现和应用更加容易, 不需要投入大量的训练成本; 因此, 笔者选用群智能算法来解决无人机的 3 维路径规划问题。

目前, 国内外众多学者已经对群智能算法进行了广泛而深入的研究, 涵盖了各个领域。这些研究不仅探讨了算法的基本原理和应用, 还针对不同问题提出了多种改进方案。文献[4]将狮群算法的思想引入到灰狼算法当中, 提高了灰狼算法在路径规划中的搜索能力; 文献[5]提出了一种高斯随机游走的历史最优回溯搜索策略, 改善了野马算法的搜索能力; 文献[6]在鲸鱼算法中引入了信息交流机制平衡局部收敛和全局搜索的能力; 文献[7]在蚁群算法中借助 A*算法增加初始信息素, 避免过多蚂蚁走入死路; 文献[8]将差分进化和灰狼算法结合, 改善了其局部搜索能力; 文献[9]使用了柯西变异算子对粒子

收稿日期: 2024-11-20; 修回日期: 2024-12-25

基金项目: 四川省科技计划项目(2025ZNSFSC0513)

第一作者: 张鸿宇(2000—), 男, 四川人, 硕士。

群算法进行改进，优化了粒子群算法的搜索能力。

2024 年，Zhou 等^[10]提出了一种新的群智能算法——金丝猴优化算法 (rhinopithecus swarm optimization, RSO)。RSO 算法灵感来自于金丝猴群中成年个体、青年个体和幼年个体各自不同的社会行为。算法通过各自不同的搜索策略和特定的学习目标，使群体中的个体能够从多个角度探索解空间，从而增加搜索空间的覆盖范围；但是，算法存在收敛精度不够，易陷入局部最优的问题。

针对 RSO 的缺陷，笔者提出一种改进的金丝猴优化算法，应用于无人机 3 维路径规划当中，以高效且合理地规划出无人机的安全飞行路径。通过仿真实验与其他群智能算法做对比，验证了该算法在寻优能力上的优越性。

1 RSO 算法

RSO 是一种新颖的群智能优化算法，模拟金丝猴的垂直迁移、协同搜索和模仿的社会行为，并设计了 3 种对应的搜索策略，使个体能探索到的解空间的范围得到扩大。种群中每个个体的位置映射为优化问题的可行解，个体位置与迁移目的地的距离越近则适应度越高，依据适应度排序将种群分为成年个体、青年个体和幼个体 3 类，其分布如图 1。

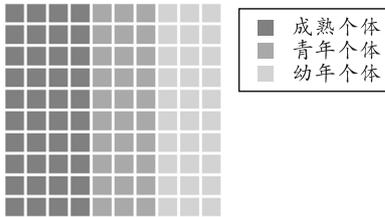


图 1 种群个体分布

1.1 成年个体

成年的金丝猴具有一定的空间认知能力，能记住曾经居住在高海拔和低海拔条件下的最佳位置，如式(1)所示。其中适应度最高的个体被选为猴王，猴王和其他成年个体对迁徙过程有更丰富的经验和空间认知，在种群迁移中起着领导作用：

$$\begin{aligned} \text{King}R &= [\text{King}R, \text{King}R_1, \text{King}R_2]; \\ MR &= [MR, MR_1, MR_2]. \end{aligned} \quad (1)$$

成年个体在寻找新的位置时在结合自己的历史经验的同时会向猴王靠拢，其搜索策略如式(2)所示：

$$\begin{aligned} \alpha &= (\text{King}R_a + MR_b)/2; \quad \beta = |\text{King}R_a - MR_b|; \\ \text{Candi}MR &= \text{Gausi}(\alpha, \beta), \quad a, b \in [0, 2]. \end{aligned} \quad (2)$$

式中 $\text{Gausi}(a, \beta)$ 为期望是 a ，方差是 β 的高斯分布

随机生成的函数值。

1.2 青年个体

青年个体还处于成长阶段，其空间认知能力不如成年个体，只能记住一个历史最优位置。

$$AR = [AR_1, AR_2]. \quad (3)$$

在迁移过程中还需要向成年个体和猴王传达其历史位置的相关信息从而分别获得指导，然后平等地采纳这 2 种指导进行位置的更新。

$$\begin{aligned} \gamma &= (\text{King}R_a + AR_c)/2; \quad \epsilon = (MR_b + AR_c)/2; \\ \delta &= |\text{King}R_a - AR_c|; \quad \zeta = |MR_b - AR_c|; \\ \text{Candi}AR &= (\text{Gausi}(\gamma, \delta) + \text{Gausi}(\epsilon, \zeta))/2; \\ a, b &\in [0, 2], \quad c \in [0, 1]. \end{aligned} \quad (4)$$

1.3 幼年个体

幼年个体尚未完全掌握如何适应环境，不具备任何记忆历史位置的能力；因此，在幼年阶段的个体会依赖种群其他成员，尤其是青年个体和成年个体，来指导进行位置的迁移。在搜索迁移的过程中，幼年个体会向青年和成年个体传达其当前的位置，然后综合考虑它们的历史经验来确定自己的下一迁移地点。

$$\begin{aligned} \eta &= (MR_b + IR)/2; \quad l = (AR_c + IR)/2; \\ \theta &= |MR_b - IR|; \quad \kappa = |AR_c - IR|; \\ \text{Candi}IR &= (\text{Gausi}(\eta, \theta) + \text{Gausi}(l, \kappa))/2; \\ b &\in [0, 2], \quad c \in [0, 1]. \end{aligned} \quad (5)$$

1.4 算法流程

在 RSO 中，将前 40% 的个体归类为成熟个体，将 40% 至 70% 的金丝猴排名为青年个体，而其余的个体则根据其表现位置为幼年个体。在种群中拥有最佳生存位置的个体被称为猴王，通常是从成熟的个体中出现的。算法的输入包括最大迭代次数 T ，适应度函数 F ，金丝猴群 X 。具体步骤如下：

步骤 1：随机生成金丝猴群 X 的初始位置。

步骤 2：通过适应度函数 F 计算 X 中个体的适应度。

步骤 3：初始化迭代次数： $t=0$ 。

步骤 4：循环迭代，当 $t < T$ 时执行：1) 对种群按照适应度排序；2) 从成熟个体中选出猴王；3) 将种群 X 按比例分为成熟个体、青年个体和幼年个体；4) 按照式(1)-(2)更新成年个体位置；5) 按照式(3)-(4)更新青年个体位置；6) 按照式(5)更新幼年个体位置；7) 迭代次数 $t=t+1$ 。

2 改进的 RSO 算法

2.1 改进的 Tent 映射

在解决无人机 3 维路径规划时，使用随机生成的初始种群会出现分布不均和多样性不足的问题，这将导致算法容易陷入局部最优。此外，不合适的初始化种群的选择还可能对算法的后续参数的设置造成影响导致鲁棒性降低。针对这个问题，目前常用混沌映射进行种群初始化，如 Logistic 映射、Bernoulli 映射、PWCLM 映射和改进的 Tent 映射。这些映射均具有分布均匀的特点，如图 2 所示。

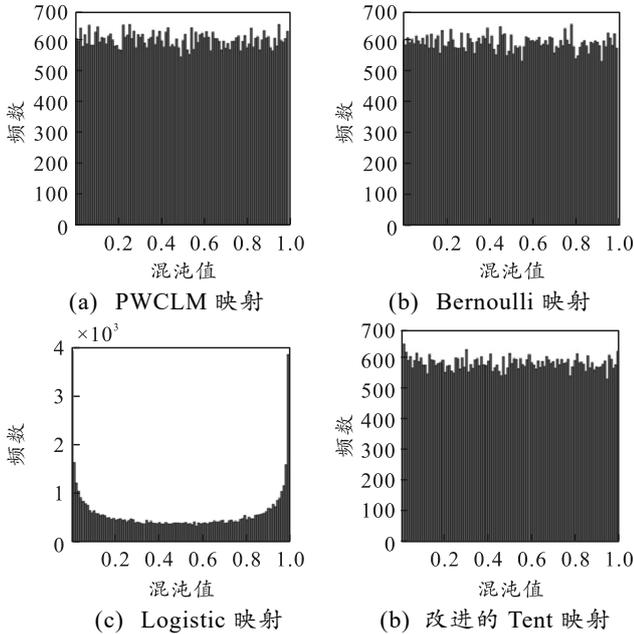


图 2 4 种映射分布

根据标准差和计算复杂度的综合考虑，笔者选取改进的 Tent 混沌映射，其定义如下：

$$y_{i+1} = \begin{cases} 2y_i + \gamma/N, & 0 \leq y_i < 0.5 \\ 2(1-y_i) + \gamma/N, & 0.5 \leq y_i \leq 1 \end{cases} \quad (6)$$

式中： N 为种群大小； γ 为 $0 \sim 1$ 之间的随机数。引入参数 γ 是为了改进传统 Tent，避免其陷入不动点影响初始化^[11]。

2.2 自适应学习策略

2.2.1 基于余弦的非线性递减模型

为了平衡算法前期的探索能力和后期的开发能力，引入了非线性递减模型 p 。

$$p(t) = p_0 \left(\frac{1 + \cos(\pi t/T)}{2} \right)^k \quad (7)$$

式中： t 为当前的迭代次数； T 为算法总迭代次数； k 为控制曲线变化偏平程度的参数， $k=2$ 。 p_0 为初始值， $p_0=1$ 。随迭代次数 p 值的变化曲线如图 3

所示。

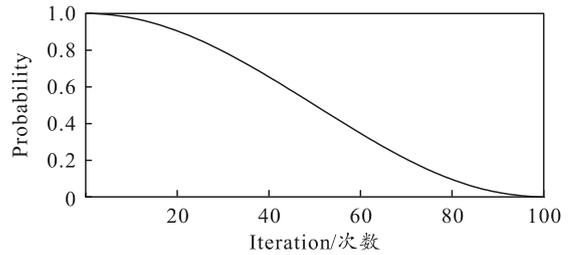


图 3 非线性递减模型

图 3 中可以看出： p 值在前后期均能保持一段时期的稳定，对后续 IRSO 算法的前期全局搜索和后期的局部开发将带来帮助。

2.2.2 自适应学习目标选择

在青年个体和幼年个体的学习策略中，选取合适的学习目标将有助于提高算法的搜索能力。对于青年个体来说，其学习目标分别是猴王和成年个体。对于幼年个体来说，其学习目标分别是成年个体和青年个体。以幼年个体为例，如果从群体里盲目随机选择一个成年个体和一个青年个体进行位置更新可能会导致学习效率低下，难以收敛到最优解；如果仅向最优的成年个体和青年个体学习又可能导致算法陷入局部最优解。笔者在学习目标选择上，采用带有爆冷概率的锦标赛选择策略。

以幼年个体为例，设幼年个体为 IR_i ，爆冷概率使用非线性递减模型 p 。选择成年个体作为学习目标步骤如下：

步骤 1：从成年个体中按照适应度大小的概率采样 k 个个体 $S = \{MR_1, MR_2, \dots, MR_k\}$ 。

步骤 2：以 $1-p$ 的概率选择 S 中适应度最优的个体作为学习目标，而以 p 的概率发生“爆冷事件”，即从 S 中随机选择一个个体作为学习目标。

2.2.3 自适应学习权重

在个体的位置更新中，RSO 算法的 3 种个体都是平等地考虑历史经验，例如式(5)幼年个体从成年个体和青年个体获得的指导都是相同权重。这种静态权重的设置可能导致算法迭代前期对空间搜索不充分，在迭代后期又收敛缓慢；因此，IRSO 使用了非线性递减模型 p 动态调整迭代过程中的学习权重。

青年个体的位置更新公式为：

$$\text{CandiAR} = (1-p)\text{Gausi}(\gamma, \delta) + p \cdot \text{Gausi}(\epsilon, \zeta) \quad (8)$$

幼年个体的位置更新公式为：

$$\text{CandiIR} = (1-p)\text{Gausi}(\eta, \theta) + p \cdot \text{Gausi}(l, k) \quad (9)$$

2.3 精英反向学习策略

反向学习策略^[12](opposition-based learning, OBL)已用于多种优化算法中^[13-15],其核心思想是:对于一个可行解,计算出其反向解(即与当前解在搜索空间中相对立的解),评估原解和反向解,保留更好的解以提升搜索效率。反向学习具有一定的盲目性,对种群所有个体求解反向解会浪费算法搜索时间,此外在金丝猴群的“迁徙”过程中,成熟个体对种群起着重要领导作用,应当重视成熟个体的发展。针对这种情况,笔者引入了精英反向学习策略,将成熟个体前 50% 视为精英个体,通过对成熟个体进行反向学习提高种群多样性。反向解定义如下:

$$x_{ij}^* = k(a_{ij} + b_{ij}) - x_{ij} \quad (10)$$

式中: k 为精英反向系数,介于 0~1 的随机数; a_{ij} 和 b_{ij} 为当前迭代次数下成熟个体搜索空间的最大最小值。动态的边界能够避免迭代过程中由于忽略种群的分布情况导致生成无价值的反向解。

融合了精英反向学习策略的 IRSO 算法流程:

步骤 1: 改进的 Tent 映射生成金丝猴群 X 的初始位置。

步骤 2: 通过适应度函数 F 计算 X 中个体的适应度。

步骤 3: 初始化迭代次数: $t=0$ 。

步骤 4: 循环迭代,当 $t < T$ 时执行: 1) 对种群按照适应度排序; 2) 从成熟个体中选出适应度最高的个体作为猴王; 3) 更新非线性递减模型 p ; 4) 将种群 X 按比例分为成熟个体、青年个体和幼年个体; 5) 按照式(1)-(2)更新成年个体位置; 6) 求取动态边界,按照式(10)更新成熟个体; 7) 按照式(8)更新青年个体位置; 8) 按照式(9)更新幼年个体位置; 9) 迭代次数 $t = t + 1$ 。

3 实验仿真与结果分析

3.1 环境建模

山区是无人机进行路径规划的常见场景,笔者将使用指数函数模拟山峰作为障碍物。数学模型如下:

$$z(x, y) = \sum_{i=1}^N h_i \exp\left[\left(\frac{x-x_{ic}}{x_{si}}\right)^2 - \left(\frac{y-y_{ic}}{y_{si}}\right)^2\right] \quad (11)$$

式中: N 为生成山峰的个数; x 和 y 为水平坐标; h 为山峰高度; x_{ic} 和 y_{ic} 为山峰中心坐标; x_{si} 和 y_{si} 为山峰沿着 x 和 y 轴的变化率,用于控制坡度。

3.2 目标函数

最短航迹是航迹规划中最重要的衡量指标,更短的航迹意味着无人机能有更高的任务执行效率。本文中的航迹是通过插值法,将各相邻点之间的欧氏距离求和得出。同时还引入惩罚因子 c 避免无人机航迹发生碰撞:

$$f = c \sum_{i=1}^n \sqrt{(px_{i+1} - px_i)^2 + (py_{i+1} - py_i)^2 + (pz_{i+1} - pz_i)^2};$$

$$c = \begin{cases} 1, & \text{无碰撞} \\ 1000, & \text{发生碰撞} \end{cases} \quad (12)$$

3.3 实验仿真

无人机 3 维路径规划仿真共设置 2 种 3 维环境,其相关环境参数如表 1 所示。

表 1 环境参数设置

环境参数	10 峰环境	25 峰环境
峰数	10	25
起点/km	[1, 1, 1]	[1, 1, 1]
终点/km	[80, 90, 40]	[80, 90, 40]
地图范围/km	100 × 100 × 100	100 × 100 × 100
种群大小	100	100
迭代次数	100	100

实验采用 PSO、RSO、DBO^[16]和笔者提出的 IRSO 算法进行比较。在该场景下各算法的航迹规划结果如图 4—7 所示。

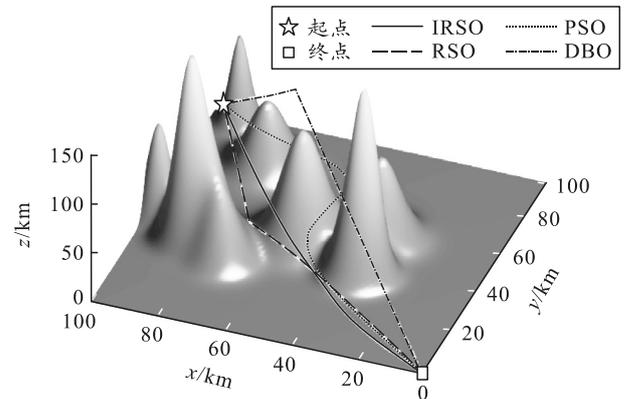


图 4 10 峰 4 种算法规划路线

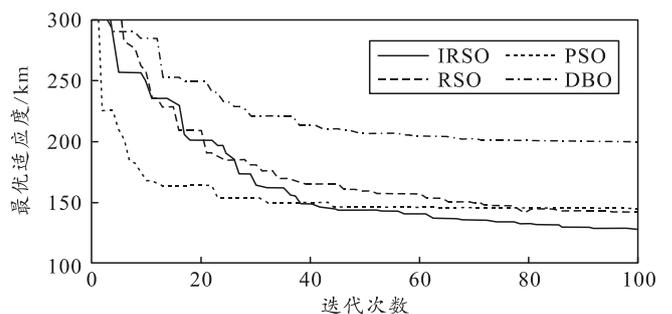


图 5 10 峰 4 种算法收敛曲线

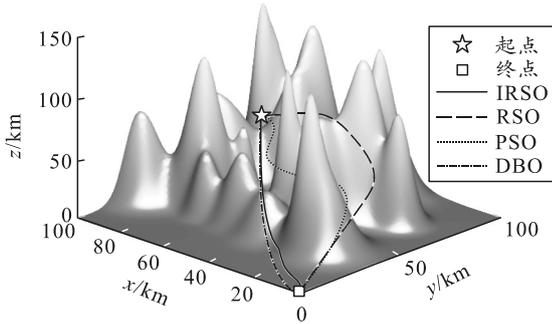


图 6 25 峰 4 种算法规划路线

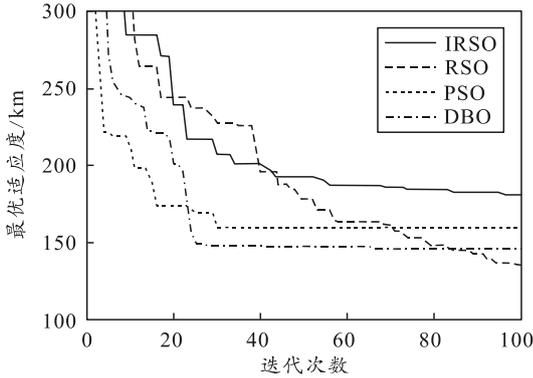


图 7 25 峰 4 种算法收敛曲线

从单次实验结果来看，IRSO 算法有更优的寻优能力。为了避免随机性对实验的影响，每个算法独立在 2 个环境运行 60 次。该实验结果如图 8—9 和表 2 所示。

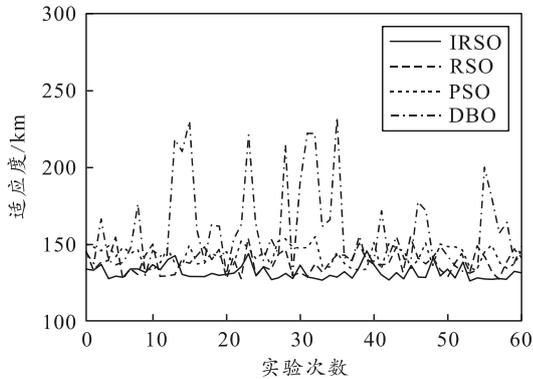


图 8 10 峰 60 次实验结果

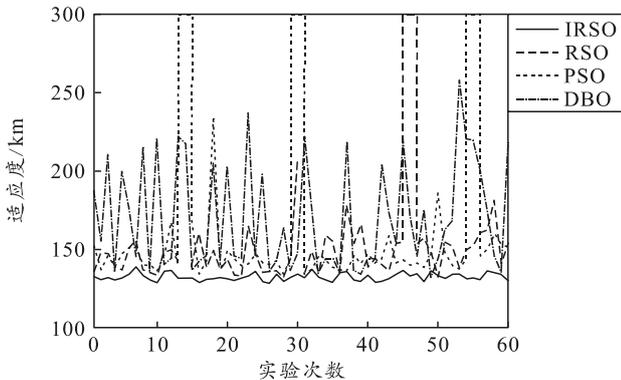


图 9 25 峰 60 次实验结果

表 2 各算法对比

规模	算法	平均 适应度/km	适应度 标准差	IRSO 适应 度占比/%	规划碰 撞次数
10 峰 环境	DBO	160.13	28.588 1	82.51	0
	PSO	143.06	6.434 2	92.35	0
	RSO	138.67	7.397 3	95.27	0
	IRSO	132.11	4.543 7	100.00	0
25 峰 环境	DBO	170.70	34.422 3	77.70	0
	PSO	146.58	14.781 4	89.72	3
	RSO	147.83	13.439 7	90.48	1
	IRSO	132.63	5.366 9	100.00	0

结合图 8 和表 2 可见：在 10 峰环境下，IRSO 算法在适应度表现方面显著优于其他算法，其平均适应度达到 132.11，且适应度标准差最低 (4.543 7)，表明该算法在多次规划任务中具有较高的稳定性。此外，RSO 算法在解空间较为平滑、局部极值较少的环境下，凭借其较强的全局搜索能力，实现了优于 PSO 算法的规划效果。

在更复杂的 25 峰环境 (图 9 和表 2) 中，IRSO 算法依然保持稳健的优化性能，即使在不可行解较多的情况下，仍能维持较高的寻优能力，并与其他算法拉开显著差距。相比之下，RSO 算法在该环境下的平均适应度大幅上升，同时鲁棒性明显下降。此外，RSO 和 PSO 算法在该环境下均出现了规划失败发生碰撞的问题，进一步验证了其在复杂环境中的局限性。

综上所述，笔者提出的 IRSO 算法在不同复杂度的环境中均表现出较强的鲁棒性、更高的收敛精度以及更优的跳出局部最优解的能力，能够高效且合理地规划出优化的 3 维路径，展现出广泛的应用潜力。

4 结束语

笔者提出一种改进的金丝猴优化算法，并将其应用于无人机 3 维航迹规划问题。通过引入改进的 Tent 混沌映射、自适应学习策略以及精英反向学习策略，对原算法进行了多维改进。与其他 3 种算法进行对比，实验的结果证明：在 3 维环境下的无人机路径规划问题中，改进的金丝猴优化算法 (IRSO) 展现出了更佳的鲁棒性和更高的收敛精度。未来的研究将集中于使算法能够根据环境的复杂度自适应地调整航迹点数量，以提高航迹规划的鲁棒性。

参考文献：

[1] 王哲胜, 杨柳庆, 张勇. 无人机 3 维航迹规划仿真平台[J]. 兵工自动化, 2025, 44(1): 76-81.
 [2] 余子杰, 郑征, 李清东, 等. 基于深度强化学习的太阳能无人机航迹规划[J]. 航空学报, 2025, 46(12):

- 280-300.
- [3] 尹华一, 尤雅丽, 黄新栋, 等. 基于 MADDPG 的多 AGVs 路径规划算法[J]. 厦门理工学院学报, 2024, 32(1): 37-46.
- [4] 王海群, 邓金铭, 张怡, 等. 基于改进混合灰狼优化算法的无人机三维路径规划[J]. 无线电工程, 2024, 54(4): 918-927.
- [5] 李高扬, 黎向锋, 赵康, 等. 全粒子推动野马优化算法的无人机三维路径规划[J]. 系统仿真学报, 2024, 36(3): 595-607.
- [6] 郭启程, 杜晓玉, 张延宇, 等. 基于改进鲸鱼算法的无人机三维路径规划[J]. 计算机科学, 2021, 48(12): 304-311.
- [7] 周晓晖, 李研强, 王勇, 等. 基于双启发式信息蚁群算法的机器人路径规划[J]. 系统仿真学报, 2025, 37(5): 1280-1289.
- [8] YU X, JIANG N, WANG X. A hybrid algorithm based on grey wolf optimizer and differential evolution for UAV path planning[J]. Expert Systems with Applications, 2023, 215: 119327.
- [9] 朱润泽, 赵静, 蒋国平, 等. 基于改进粒子群算法的无人机三维路径规划[J]. 南京邮电大学学报(自然科学
- 版), 2024, 44(6): 120-127.
- [10] ZHOU G, WANG D, ZHOU G, et al. A rhinopithecus swarm optimization algorithm for complex optimization problem[J]. SCIENTIFIC REPORTS, 2024, 14(1): 1-27.
- [11] 刘苗苗, 张玉莹, 郭景峰, 等. 融合多策略改进的自适应狮群优化算法[J]. 北京邮电大学学报, 2024, 47(1): 85-93.
- [12] TIZHOOSH H R. Opposition-based learning: A new scheme for machine Intelligence[J]. Computational Intelligence for Modelling, 2005, 1: 695-701.
- [13] 冯增喜, 李诗妍, 赵锦彤, 等. 基于精英反向学习策略的麻雀搜索算法[J]. 计算机仿真, 2023, 40(1): 378-381, 393.
- [14] 白宇鑫, 陈振亚, 石瑞涛, 等. 基于改进哈里斯鹰算法的机器人路径规划研究[J]. 系统仿真学报, 2024, 37(3): 742-752.
- [15] 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.
- [16] XUE J, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization[J]. Journal of Supercomputing, 2023, 79(7): 7305-7336.

(上接第 69 页)

同样根据最大隶属度原则, 安防建设工程项目的模糊综合评价结果为“较低风险”。

5 结束语

安防建设工程项目自身存在的专业涵盖面广、工程内容复杂、隐蔽工程较多等特点, 致使这类项目在质量管理方面存在较大难度。笔者以安防建设工程项目质量风险识别问题为出发点, 以熵权值法和模糊综合评价法相结合的方式进行研究, 并采取模拟仿真的方式对该方法进行了论证, 证明了熵权值和模糊综合评价法相结合的方式是安防建设工程项目质量安全风险识别的有效方法, 能为安防建设工程的质量水平提升作出贡献。

参考文献:

- [1] 陈维银. 建筑智能化系统安防工程技术应用研究[J]. 科技, 2022(6): 46-47.
- [2] 吕建兴. 浅析建筑智能化系统安防工程技术应用[J]. 信息化建设, 2019(8): 327-328.
- [3] 余煜华. 建筑安防工程施工技术应用探究[J]. 工程技术与应用, 2020(3): 57-58.
- [4] 刘译泽, 寇林, 陈继祥. 基于 BIM 的安防工程设计优化和校验[J]. 技术平台, 2021(8): 54-57.
- [5] 谢冬辉, 黄锐, 梁炳荣, 等. 基于模糊综合评价装配式建筑质量的研究[J]. 城市建筑, 2023(10): 204-207.
- [6] 安子樱, 胡淋翔, 李伟. 基于 AHP-模糊综合评价法的应急装备灾害适应性评估[J]. 工业安全与环保, 2023(2): 6-9.
- [7] 黄华. 基于 AHP-模糊综合评价法的深基坑施工安全风险评价研究[J]. 江西建材, 2023(1): 373-378.
- [8] 刘宇. 基于 AHP-模糊综合评价的新能源建设项目安全风险评价研究[J]. 项目管理技术, 2022(10): 123-127.