

DOI:10.19651/j.cnki.emt.2519162

改进旅鼠算法的机器人路径规划研究*

焦怀良 刘立群 何俊强 张政 吴青峰

(太原科技大学电子信息工程学院 太原 030024)

摘要:为解决旅鼠算法(ALA)收敛速度慢、收敛精度低、易陷入局部最优的问题,提出一种多策略改进旅鼠算法(IALA)。首先引入 Hammersley 序列对算法进行种群初始化,使初始种群具有更加优秀的搜索能力;然后利用反向差分变异机制,提高种群的多样性,增强算法逃离局部最优的能力;最后通过软霜冰搜索机制,让算法在优化过程中兼顾局部性和全局性,提高了算法的寻优能力和收敛速度。为验证改进算法的有效性,选取9个基准测试函数对改进算法进行对比测试,对比结果显示:IALA有着更快的收敛速度及更高的收敛精度。最后将改进算法应用于3种复杂程度地图的机器人路径规划仿真实验,结果表明:与原算法 ALA 进行比较,改进后的算法 IALA 在第1种地图中路径最优值下降0.64%,平均值下降2.86%;在第2种地图中路径最优值下降10.24%,平均值下降6.91%;在最后一幅地图中路径最优值下降2.02%,平均值下降2.6%。证明了改进后的算法具有更好的路径寻优能力。

关键词:旅鼠算法;Hammersley 序列;反向差分变异机制;软霜冰搜索;路径规划

中图分类号: TP301.6; TN965 **文献标识码:** A **国家标准学科分类代码:** 510.8050

Robot path planning research with improved artificial lemming algorithm

Jiao Huailiang Liu Liqun He Junqiang Zhang Zheng Wu Qingfeng

(School of Electronic Information Engineering, Taiyuan University of Science and Technology, Taiyuan 030024, China)

Abstract: In order to solve the problems of slow convergence speed, low convergence accuracy and easy to fall into local optimization of artificial lemmings algorithm (ALA), a multi strategy improved artificial lemmings algorithm (IALA) is proposed. Firstly, Hammersley sequence is introduced to initialize the population of the algorithm, so that the initial population has better search ability; then the reverse differential mutation mechanism is used to improve the diversity of the population and enhance the ability of the algorithm to escape from the local optimum; finally, through the soft frost ice search mechanism, the algorithm takes into account the local and global characteristics in the optimization process, which improves the optimization ability and convergence speed of the algorithm. In order to verify the effectiveness of the improved algorithm, nine benchmark functions are selected to compare the improved algorithm. The comparison results show that IALA has faster convergence speed and higher convergence accuracy. Finally, the improved algorithm is applied to the simulation experiment of robot path planning on three kinds of complex maps. The results show that compared with the original algorithm ala, the improved algorithm IALA in the first kind of map, the optimal value of path decreases by 0.64%, and the average value decreases by 2.86%; in the second map, the optimal value of path decreased by 10.24%, and the average value decreased by 6.91%; in the last map, the optimal value of the path decreased by 2.6%, and the average value decreased by 1.3%. It is proved that the improved algorithm has better path optimization ability.

Keywords: artificial lemming algorithm; Hammersley sequence; reverse differential mutation mechanism; soft frost ice search; path planning

0 引言

随着科技的飞速发展,人工智能技术越来越成熟,智能

机器人被广泛应用于社会的各行各业,其中最典型的就是物流运输机器人、救援机器人、智慧农业机器人等^[1]。而在智能机器人的实际运用中,路径规划是一个研究的热点及

收稿日期:2025-06-22

* 基金项目:山西省基础研究计划面上项目(202203021221153)、国家自然科学基金青年科学基金(61703297)资助

难点,它需要在保证机器人不碰撞到障碍物的前提下,从起点到终点之间规划出一条最优路径,并且要使这个规划过程更高效^[2-3]。智能机器人的路径规划方法可以分为两大类,一种是传统路径规划算法,另一种是智能路径规划算法。传统路径规划算法有模拟退火算法^[4](simulated annealing, SA)、禁忌搜索算法(tabu search, TS)、人工势场法^[5](artificial potential field, APF)等,这类算法应用广泛,但有着搜索效率不高、路径冗余等问题。智能路径规划算法有A*算法^[6]、粒子群算法^[7](particle swarm optimization, PSO)、蚁群算法^[8](ant colony algorithm, ACA)、遗传算法^[9](genetic algorithm, GA)、灰狼优化算法^[10](grey wolf optimizer, GWO)等,这类算法克服了传统算法搜索效率不高的问题,极大地增强了搜索能力,但却极易陷入局部最优,计算也十分复杂。

旅鼠算法(artificial lemming algorithm, ALA)是由Xiao等^[11]在2024年提出的一种新型的元启发式算法。它可以对自然界中旅鼠的4种不同行为进行数学建模:长途迁徙、挖洞、觅食和躲避捕食者。具体而言,长距离迁徙和挖洞行为致力于高度探索搜索域,而觅食和逃避捕食者行为在优化过程中提供利用。此外,ALA采用了一种能量减少机制,可以动态调整勘探和开发之间的平衡,从而更好地进行收敛。虽然ALA具有很多优点,但也有一定的不足之处,例如易陷入局部最优、勘探开发不平衡、过早收敛、收敛精度较差等。针对ALA勘探开发不平衡等问题,Zhu等^[12]通过引入混沌初始化、自适应扰动和混合突变对ALA进行改进,使其在具有现实障碍物约束的大中型环境中的无人机路径规划时,可生成更优路径,最大限度地减少长度、曲率和计算时间,同时保证避免碰撞。对于ALA过早收敛等问题,杨原等^[13]通过引入Halton序列初始化、非线性权重的黄金正弦策略并结合精英池策略与惯性权重来对ALA进行改进,抑制了ALA过早收敛的问题,并提高了局部搜索的精度与稳定性。针对ALA易陷入局部最优及全局寻优能力不足等问题,本文提出一种多策略改进旅鼠算法(IALA)。

1995年首次提出差分进化算法,该算法是一类基于群体的自适应全局优化算法,属于演化算法的一种。差分进化算法具有结构简单、容易实现、收敛快速、鲁棒性强等特点。王逸文等^[14]提出一种将反向学习与差分进化相结合的基于反向差分的种群变异机制,将其应用于算法中,使其能够生成更稳定、多样性更高的种群。Su等^[15]受自然界霜冰生长机制启发,在2023年提出霜冰优化算法(rime optimization algorithm, RIME),它通过改进的正向贪婪选择机制进行全局寻优。

为了使旅鼠算法(ALA)获得更强的搜索能力及更快的收敛速度和更高的收敛精度,本文将利用Hammersley序列^[16]对算法进行种群初始化,然后利用反向差分变异机制来提高种群多样性,最后在霜冰优化算法基础上提出

一种软霜冰搜索机制,增强算法逃离局部最优的能力,提高算法的寻优能力和收敛速度。最后进行模拟仿真,选择基准测试函数对改进算法的性能进行测试,并将其应用于智能机器人的路径规划中,以此来证明本文中改进算法的有效性。

1 旅鼠算法

旅鼠算法(ALA)是一种新型的元启发式算法,它在2024年被首次提出,该算法主要灵感来源于旅鼠在自然界中的4种不同行为:长途迁徙、挖洞、觅食和躲避捕食者。根据这4种行为可将算法的原理分为两个阶段:一是长途迁徙和挖洞(勘探阶段),二是觅食和躲避捕食者(开发阶段)。

1.1 初始化

在初始化阶段,旅鼠算法在搜索空间内首先会生成一个随机种群作为初始种群,然后开始算法的优化过程。初始总体的计算公式为:

$$z_{i,j} = LB_j + rand \times (UB_j - LB_j), i = 1, 2, \dots, N; j = 1, 2, \dots, Dim \quad (1)$$

其中,rand为0~1的随机值,LB_j为第j维的下限,UB_j为第j维的上限。

1.2 长途迁徙(勘探)

在第1种行为中,在旅鼠的数量太多而导致食物不够时,他们会随机进行长距离迁徙。在这里,旅鼠会根据目前的位置和种群中随机个体的位置来探索搜索空间,寻找食物资源丰富的栖息地,从而获得更好的生存条件和资源。同时值得注意的是,旅鼠迁徙的方向和距离并不是固定的或者随机的,而是受生态环境等多种因素的影响。为了模拟这种行为,提出了以下公式:

$$\vec{Z}_i(t+1) = \vec{Z}_{best}(t) + F \times \overrightarrow{BM} \times \left(\vec{R} \times (\vec{Z}_{best}(t) - \vec{Z}_i(t)) + (1 - \vec{R}) \times (\vec{Z}_i(t) - \vec{Z}_a(t)) \right) \quad (2)$$

其中,Z_i(t+1)表示第i个搜索代理在t+1次迭代时的位置。其中,Z_{best}(t)表示当前最优解。F作为改变搜索方向的标志,由式(4)计算,可以避免局部最优,为搜索代理严格扫描问题域提供更高的机会。BM代表表征布朗运动的随机数向量,它利用动态和均匀的步长来探索搜索空间中的一些潜在区域。标准布朗运动的步长是通过方差为1,均值为0的正态分布的概率密度函数得到的,如式(3)所示。R是一个大小为1×Dim的向量,其元素是均匀分布在区间[-1,1]内的随机数,该向量控制种群中当前最优个体和随机个体的移动,并用于表示迁移过程中个体之间的相互作用。Z_i(t)表示第i个搜索代理的当前位置。Z_a(t)表示从总体中随机选择的搜索个体,a是1~n之间的整数索引。

$$f_{BM}(x; 0, 1) = \frac{1}{\sqrt{2\pi}} \times \exp\left(-\frac{x^2}{2}\right) \quad (3)$$

$$F = \begin{cases} 1, [2 \times rand + 1] = 1 \\ -1, [2 \times rand + 1] = 2 \end{cases} \quad (4)$$

$$\vec{R} = 2 \times rand(1, Dim) - 1 \quad (5)$$

其中, $[\cdot]$ 表示向下取整函数。

1.3 挖洞(勘探)

旅鼠的第 2 种行为是在它们的栖息地挖洞, 形成复杂的隧道, 为它们提供安全的避难所和储存食物的地方。旅鼠会根据洞穴的当前位置和种群中随机个体的位置随机挖掘新的洞穴。这种设计帮助它们快速逃离捕食者的威胁, 更有效地寻找食物。该行为在式(6)中进行了模拟:

$$\vec{Z}_i(t+1) = \vec{Z}_i(t) + F \times L \times (\vec{Z}_{best}(t) - \vec{Z}_i(t)) \quad (6)$$

其中, L 是与当前迭代次数相关的随机数。其中, Z_b 表示从种群中随机选择的搜索个体, b 是 $1 \sim n$ 之间的随机整数指标值。 L 和 Z_b 用于描述旅鼠个体在挖新洞时的相互作用。 L 的值计算公式如下:

$$L = rand \times (1 + \sin(\frac{t}{2})) \quad (7)$$

1.4 觅食(开发)

在第 3 种行为中, 旅鼠在其栖息地的洞穴内广泛而随意地移动, 依靠其敏锐的嗅觉和听觉来定位食物来源。旅鼠通常在其栖息地内建立一个相对较小的觅食区域, 这取决于食物的丰富程度和可用性。为了摄取尽可能多的食物, 旅鼠会在觅食区域内随意游荡。考虑螺旋缠绕机制来模拟这一阶段为:

$$\vec{Z}_i(t+1) = \vec{Z}_{best}(t) + F \times spiral \times rand \times \vec{Z}_i(t) \quad (8)$$

式中: 螺旋表示觅食过程中随机搜索的螺旋形状, 由式(9)和(10)计算:

$$spiral = radius \times (\sin(2 \times \pi \times rand) + \cos(2 \times \pi \times rand)) \quad (9)$$

$$radius = \sqrt{\sum_{j=1}^{Dim} (z_{best,j}(t) - z_{i,j}(t))^2} \quad (10)$$

1.5 躲避捕食者(开发)

在最后一个阶段, 建模的重点是旅鼠在遇到危险时的回避和保护行为。这个洞穴是旅鼠的避难所。一旦发现敌人, 旅鼠就会利用它们特殊的奔跑能力逃回洞穴。与此同时, 旅鼠也会做出欺骗性的动作来逃避捕食者的追捕。相应的数学表达式如式(11)所示。

$$\vec{Z}_i(t+i) = \vec{Z}_{best}(t) + F \times G \times Levy(Dim) \times (\vec{Z}_{best}(t) - \vec{Z}_i(t)) \quad (11)$$

$$G = 2 \times (1 - \frac{t}{T_{max}}) \quad (12)$$

式中: G 为旅鼠的逃逸系数, 表示旅鼠的逃逸能力, 随迭代次数的增加而减小, 如式(12)所示。 T_{max} 表示最大迭代次数。 $Levy$ 是莱维飞行函数^[17], 用来模拟旅鼠逃跑时的欺骗动作。莱维飞行函数表示为:

$$\begin{cases} Levy(x) = 0.01 \times \frac{u \times \sigma}{|v|^{\frac{1}{\beta}}} \\ \sigma = (\frac{\Gamma(1+\beta) \times \sin(\frac{\pi\beta}{2})}{\Gamma(\frac{1+\beta}{2}) \times \beta \times 2(\frac{\beta-1}{2})})^{\frac{1}{\beta}} \end{cases} \quad (13)$$

其中, u 和 v 是 $0 \sim 1$ 的随机值, β 是等于 1.5 的常数。

1.6 从勘探到开发的过渡

为了保持勘探和开采之间的平衡, 设计了一个能量因子, 使其在迭代过程中减少。当旅鼠有足够的能量时, 它们会选择性地迁移或挖洞; 否则, 它们就四处觅食, 躲避捕食者。能量因子的计算公式如下:

$$E(t) = 4 \times \arctan \left[1 - \frac{t}{T_{max}} \right] \times \ln\left(\frac{1}{rand}\right) \quad (14)$$

2 改进旅鼠算法

2.1 Hammersley 序列初始化种群

旅鼠算法在初始化生成种群时, 采用的是随机数函数, 生成的种群具有很大的不确定性和随机性, 对后续算法的优化过程有很大的影响。如果初始化能够生成分布均匀的种群, 那就能够为算法后续的迭代打下坚实的基础, 能够使算法得到更好的收敛速度和求解精度。 Hammersley 序列是一种低差异序列, 可以增加种群多样性, 生成均匀分布的点集, 它比随机初始化更加优越可靠。本文将 Hammersley 序列应用于旅鼠算法的种群初始化阶段, 其数学描述为:

对于任意非负整数 i 和素数基 p , 定义:

$$i = \sum_{k=0}^r a_k p^k \quad (15)$$

式中: $a_k \in [0, p-1]$ 。

$$\Phi_p(i) = \sum_{k=0}^r \frac{a_k}{p^{k+1}} \quad (16)$$

由式(15)和(16)确定的 $\Phi_p(i) \in (0, 1)$ 。在 D 维空间中, 取互异素数序列 p_1, p_2, \dots, p_{D-1} , 对应序列 $\Phi_{p_1}, \Phi_{p_2}, \dots, \Phi_{p_{D-1}}$, 则第 i 个 Hammersley 点为:

$$x_i = (\frac{i}{N}, \Phi_{p_1}(i), \Phi_{p_2}(i), \dots, \Phi_{p_{D-1}}(i)) \quad (17)$$

利用随机数和 Hammersley 序列分别产生 100 个随机数, 通过结果可以看出由 Hammersley 序列产生的随机数要比随机序列产生的随机数有着更加优秀的均匀性, 结果如图 1 所示。

2.2 反向差分变异机制

原始旅鼠算法通过随机初始化来生成种群, 通过 Hammersley 序列解决了它分布不均的问题, 但它还有种群不稳定、多样性低等问题。为了避免因为这些问题而导致算法陷入局部最优, 本文引入基于反向差分的种群变异机制, 以此来改善算法的初始化种群。这种机制将反向学习和差分进化的优点结合在一起, 使算法在初始化种群时




图1 随机数分布

Fig.1 Random number distribution

有着更好的效果。

有研究表明反向学习产生的解比随机解更接近全局最优解,并且其优势概率可达50%。它通过对称映射扩大搜索范围,避免种群聚集在局部区域。因此在机制的第1阶段采用反向学习来提升种群的质量。反向解 x' 可表示为:

$$x' = a + b - x, x \in [a, b] \quad (18)$$

其中, a 和 b 分别表示搜索空间的上界和下界。

同样在高维搜索空间中,若 $x_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 为高维搜索空间的一个可行解,则其反向解为:

$$x'_{ij} = a_{ij} + b_{ij} - x_{ij}, x_{ij} \in [a_j, b_j], j \in [1, D] \quad (19)$$

反向学习优化后的种群仍需避免早熟收敛,因此在机制的第2步引入差分进化机制,通过变异、交叉和选择操作动态调整种群,进一步提高种群的多样性。首先采用随机差分策略对种群进行变异操作:

$$v_i^{t+1} = M_{r_1}^t + \beta(M_{r_2}^t - M_{r_3}^t), r_{1,2,3} \in (1, 2, \dots, N), \beta \in [0, 1] \quad (20)$$

其中, r_1, r_2, r_3 为随机选择的互异个体索引, β 为缩放的比例因子,控制差分向量的扰动强度。接着通过二项式交叉生成试验个体来进行交叉操作:

$$\mu_{ij}^t = \begin{cases} v_{ij}^{t+1}, & \text{rand} \leq P_c \\ M_{ij}^t, & \text{rand} > P_c \end{cases} \quad (21)$$

其中, rand 为 $[0, 1]$ 的随机数, P_c 为交叉概率。最后采用精英保留政策,仅当试验个体更优时更新种群:

$$M_i^{t+1} = \begin{cases} \mu_i^t, & f(\mu_i^t) \leq f(M_i^t) \\ M_i^t, & f(\mu_i^t) > f(M_i^t) \end{cases} \quad (22)$$

其中, M_i^{t+1} 为替换后的种群, $f(\cdot)$ 表示适应度值。

2.3 软霜冰搜索机制

模拟软霜粒子在霜冻冰中的运动,本文提出了一种逐步搜索和开发的软霜冰搜索机制,用于探索算法。这种机制允许算法在大范围探索和小范围开发之间切换,从而实现高效和高精度的优化。每个未凝结的霜冰粒子都会遵

循一定的规律运动,在软冰附近一定范围内的自由粒子会凝结,超过这个范围的粒子则保持自由状态,不会凝结。每个粒子会在软冰的形成过程中因为随机性而导致凝结面积增大,最终在环境的影响下达到一个稳定状态。针对霜冰粒子的运动性质,霜冰粒子的位置为:

$$R_{ij}^{new} = R_{best,j} + r_1 \times \cos\theta \times \beta \times [h(b_{Uij} - b_{Lij})] \quad (23)$$

$$\theta = \pi \times \frac{t}{10 \times T} \quad (24)$$

$$\beta = 1 - \left[\frac{\omega \times t}{T} \right] / \omega \quad (25)$$

式中: R_{ij}^{new} 为粒子更新后的位置, $R_{best,j}$ 为种群中最佳的第 j 个粒子,参数 r_1 为范围 $(-1, 1)$ 中的随机数,并且 r_1 控制粒子运动的方向; $\cos\theta$ 将随着迭代次数的变化而改变; β 为环境因子,跟随迭代次数以模拟外部环境的影响,并用于确保算法的收敛; h 为黏附度,它是 $(0, 1)$ 范围内的随机数,用于控制两个粒子中心之间的距离; b_{Uij} 和 b_{Lij} 分别为逃逸空间的上界和下界,为了限制粒子运动的有效区域。 t 为当前迭代次数, T 为算法最大迭代次数。 β 的数学模型为阶梯函数, $[\cdot]$ 表示四舍五入, ω 用于控制阶梯函数的分段数量。

随着软冰凝结面积的增大,它会产生强随机性和覆盖范围广的特点,能够让算法在搜索过程中更加迅速地覆盖整个空间,从而使算法在优化过程中兼顾了全局性和局部性。并且在迭代过程中,粒子之间实现交叉互换,普通粒子和最佳粒子进行维度交换,避免了局部最优,提高了算法的收敛性及解的精度。

2.4 IALA 算法流程

将改进点融入原旅鼠算法,改进后的旅鼠算法流程为:

- 1) 设置参数。主要包括种群规模、最大迭代次数等。
- 2) 初始化种群。利用 Hammersley 序列进行种群初始化,并利用反向差分变异机制对初始种群进行进一步

优化。

3)目标值计算。计算每个旅鼠个体的适应度值,并进行排序。

4)行为模拟阶段。适应度较差的个体以一定概率进行随机迁徙(全局搜索),部分个体跟随适应度较好的领导者(局部搜索),部分个体进行小范围随机游走(保持多样性)。

5)更新阶段。利用软霜冰搜索机制更新每个旅鼠的位置及适应度值,保留最优解。

6)结束阶段。如果达到最大迭代次数或满足收敛条件,则终止算法,否则返回流程 2)继续迭代。最后输出问

题最优解。

3 IALA 性能验证

3.1 测试说明

本文实验平台为:MatlabR2024b(Intel(R) Core(TM) i5-12450H CPU@2.00 GHz)。本文选取 8 个基准测试函数进行测试对比实验。其中,F1~F3 为单峰测试函数,注重算法的局部寻优能力;F4~F6 为多峰测试函数,注重算法的全局寻优能力;F7~F8 为复合测试函数,注重算法的局部寻优能力和全局寻优能力的平衡。8 个基准测试函数信息如表 1 所示。

表 1 测试函数
Table 1 Test functions

编号	函数	维度	取值范围	理论最优值
F1	$f(x) = \sum_{i=1}^n x_i^2$	30	$[-100, 100]$	0
F2	$f(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	30	$[-100, 100]$	0
F3	$f(x) = \sum_{i=1}^{n-1} [100(x_{i+1} - x_i^2)^2 + (x_i - 1)^2]$	30	$[-30, 30]$	0
F4	$f(x) = \sum_{i=1}^n -x_i \sin(\sqrt{ x_i })$	30	$[-500, 500]$	-12 569.5
F5	$f(x) = \sum_{i=1}^n [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-5.12, 5.12]$	0
F6	$f(x) = \frac{1}{4000} \sum_{i=1}^n x_i^2 - \prod_{i=1}^n \cos(\frac{x_i}{\sqrt{i}}) + 1$	30	$[-600, 600]$	0
F7	$f(x) = \sum_{i=1}^{11} \left[a_i - \frac{x_1(b_i^2 + b_i x_2)}{b_i^2 + b_i x_3 + x_4} \right]^2$	4	$[-5, 5]$	0.000 307 5
F8	$f(x) = \left[\frac{1}{500} + \sum_{j=1}^{25} \frac{1}{j + \sum_{i=1}^2 (x_i - a_{ij})^6} \right]^{-1}$	2	$[-65.536, 65.536]$	1

3.2 IALA 稳定性分析

为了充分证明本文提出的改进旅鼠算法的有效性,选用原始的旅鼠算法(ALA)、红嘴蓝鹊优化算法^[18](red-Billed blue magpie optimization, RBMO)、PID 搜索算法^[19](PID-based search algorithm, PSA)、金豺优化算法^[20](golden jackal optimization, GJO)及灰狼优化算法与本文的改进旅鼠算法进行对比,主要通过 8 个基准测试函数的测试结果进行分析。为确保结果的合理性,所有算法的参数设置为:种群数量为 30,最大迭代次数为 500,并且每个算法都将独立运行 50 次,得到的结果如表 2 所示。

由表 2 中的数据可得出:在对单峰函数求解时,IALA 的各项数据均优于其他算法,比其他算法更加接近理论最优值,尤其是 F3 函数,其余几个算法的结果都和理论最优

值差距非常大,只有 IALA 的结果比较接近理论最优值,这说明在单峰函数上,本文算法的改进效果显著;在对多峰函数求解时,在 F4 函数上,每个算法的搜索精度都不是很好,标准差都很大,说明每次运行的结果差别都很大,但是相比较来说,IALA 的结果更接近理论最优值,标准差也是最小的,在 F5 和 F6 函数上,IALA 和 GJO 每次都能寻到理论最优值,GWO 在 50 次运行中寻到过理论最优值但不是每次都能,其余 3 个算法都不能寻到理论最优值,这 3 个函数的数据说明在多峰函数上 IALA 有着更优秀的性能,改进点在多峰函数上有着更大的优势;在对复合函数求解时,在 F7 函数上,RBMO 是表现最好的算法,且 RBMO 和 PSA 每项数据都优于本文的 IALA,但本文的 IALA 要优于原来的 ALA,说明 IALA 在复合函数上的性

表2 测试函数对比结果

Table 2 Comparison results of test functions

函数	结果	IALA	ALA	RBMO	PSA	GJO	GWO
F1	最优值	4.204×10^{-119}	3.18899×10^{-7}	3.74911×10^{-5}	0.035 147 814	1.06892×10^{-56}	5.14644×10^{-29}
	标准差	3.20664×10^{-94}	2.17913×10^{-5}	0.001 283 151	0.047 291 538	1.66363×10^{-54}	5.18052×10^{-27}
	平均值	1.43405×10^{-94}	1.23734×10^{-5}	0.000 730 429	0.079 628 235	7.78274×10^{-55}	4.74292×10^{-27}
	中值	3.6641×10^{-107}	2.79637×10^{-6}	0.000 195 751	0.066 898 975	3.42814×10^{-56}	3.00123×10^{-27}
	最差值	7.17027×10^{-94}	5.11086×10^{-5}	0.003 020 214	0.144 647 034	3.75407×10^{-54}	1.28716×10^{-26}
F2	最优值	1.2111×10^{-165}	0.000 257 523	103.395 639 5	1 209.384 31	1.14078×10^{-21}	1.92682×10^{-7}
	标准差	8.1227×10^{-129}	0.000 586 482	173.700 355	2 285.471 536	5.40684×10^{-15}	1.95162×10^{-6}
	平均值	5.9594×10^{-129}	0.000 893 167	257.920 295 3	2 749.897 875	2.4738×10^{-15}	2.04912×10^{-6}
	中值	3.9137×10^{-130}	0.000 726 8	193.774 677 8	1 919.708 744	9.54402×10^{-17}	2.00564×10^{-6}
	最差值	1.6823×10^{-128}	0.001 824 136	501.187 462 3	6 797.004 985	1.21454×10^{-14}	5.17183×10^{-6}
F3	最优值	8.00337×10^{-5}	25.004 511 98	26.575 900 34	88.108 606 61	27.187 315 35	26.239 729 39
	标准差	0.003 995 446	0.819 389 999	0.929 957 821	260.112 517 6	0.634 937 081	0.716 053 666
	平均值	0.003 480 734	26.108 370 22	28.089 568 01	249.751 863 8	27.475 077	27.261 102 96
	中值	0.002 264 576	26.080 380 62	28.281 273 77	144.607 541	27.192 678 54	27.138 400 29
	最差值	0.010 367 077	27.317 681 96	29.058 002 25	706.417 753	28.610 878 67	27.965 211 47
F4	最优值	-12 332.609 29	-11 130.288 2	-9 318.200 36	-10 751.866 8	-4 859.792 09	-6 933.972 39
	标准差	52.967 031 508 817	1 042.990 001	294.390 234 6	541.862 306 4	798.013 212 5	628.371 545 2
	平均值	-12 308.921 15	-10 065.463 4	-9 055.060 41	-10 177.694 4	-3 469.070 41	-6 030.293
	中值	-12 332.608 37	-10 601.698 9	-9 182.347 98	-10 096.453 3	-3 222.883 88	-5 896.967 81
	最差值	-12 214.170 84	-8 875.003 29	-8 622.893 45	-9 517.287 62	-2 826.974 07	-5 345.504 99
F5	最优值	0	7.29713×10^{-6}	37.913 494 24	40.352 039 29	0	5.68434×10^{-14}
	标准差	0	0.545 148 843	21.563 020 05	16.469 339 88	0	0.965 190 402
	平均值	0	0.398 134 607	51.280 528 72	60.270 705 42	0	0.636 561 439
	中值	0	2.16823×10^{-5}	44.391 640 2	59.742 111 91	0	5.68434×10^{-13}
	最差值	0	0.995 339 559	89.225 631 32	84.703 756 72	0	2.177 616 68
F6	最优值	0	1.75032×10^{-6}	0.000 263 902	0.035 929 423	0	0
	标准差	0	4.67169×10^{-6}	0.022 101 423	0.032 840 627	0	0.009 179 972
	平均值	0	7.01114×10^{-6}	0.014 258 199	0.073 624 962	0	0.004 105 408
	中值	0	7.66718×10^{-6}	0.002 116 56	0.062 843 974	0	0
	最差值	0	1.16683×10^{-5}	0.052 361 861	0.112 422 782	0	0.020 527 041
F7	最优值	0.000 307 697	0.000 307 486	0.000 307 486	0.000 307 688	0.000 319 245	0.000 307 5
	标准差	0.000 180 866	0.000 409 508	4.64242×10^{-12}	0.000 413 722	0.000 113 74	0.000 387 402
	平均值	0.000 500 136	0.001 040 036	0.000 307 486	0.000 801 608	0.000 481 396	0.000 550 096
	中值	0.000 556 793	0.001 223 173	0.000 307 486	0.000 737 229	0.000 466 827	0.000 379 146
	最差值	0.000 665 919	0.001 223 173	0.000 307 486	0.001 223 173	0.000 613 405	0.001 226 564
F8	最优值	0.998 003 838	0.998 003 838	0.998 003 838	0.998 003 838	2.982 105 157	0.998 003 838
	标准差	1.086 737 049	1.11022×10^{-16}	1.11022×10^{-16}	2.22045×10^{-16}	3.479 802 756	4.855 814 671
	平均值	1.791 644 365	0.998 003 838	0.998 003 838	0.998 003 838	4.538 320 259	5.499 700 248
	中值	0.998 003 838	0.998 003 838	0.998 003 838	0.998 003 838	2.982 105 157	2.982 105 157
	最差值	2.982 105 157	0.998 003 838	0.998 003 838	0.998 003 838	10.763 180 67	10.763 181 67

能还有待提高,在F8函数上,ALA、RBMO、PSA的性能表现都很好,IALA要稍差一点,但是在多次试验中也能有十

分接近最优值的表现,GJO和GWO在这个函数上的表现就有点差强人意,这也进一步说明了IALA在复合函数上

的寻优性能还有很大的提升空间。

3.3 IALA 收敛性分析

为了进一步分析 IALA 的性能,根据上文的 8 个基准

测试函数来得到算法的收敛曲线,根据各算法收敛曲线的对比,可以更直观地看出它们性能上的优劣。各算法收敛曲线及箱线图对比如图 2 所示。

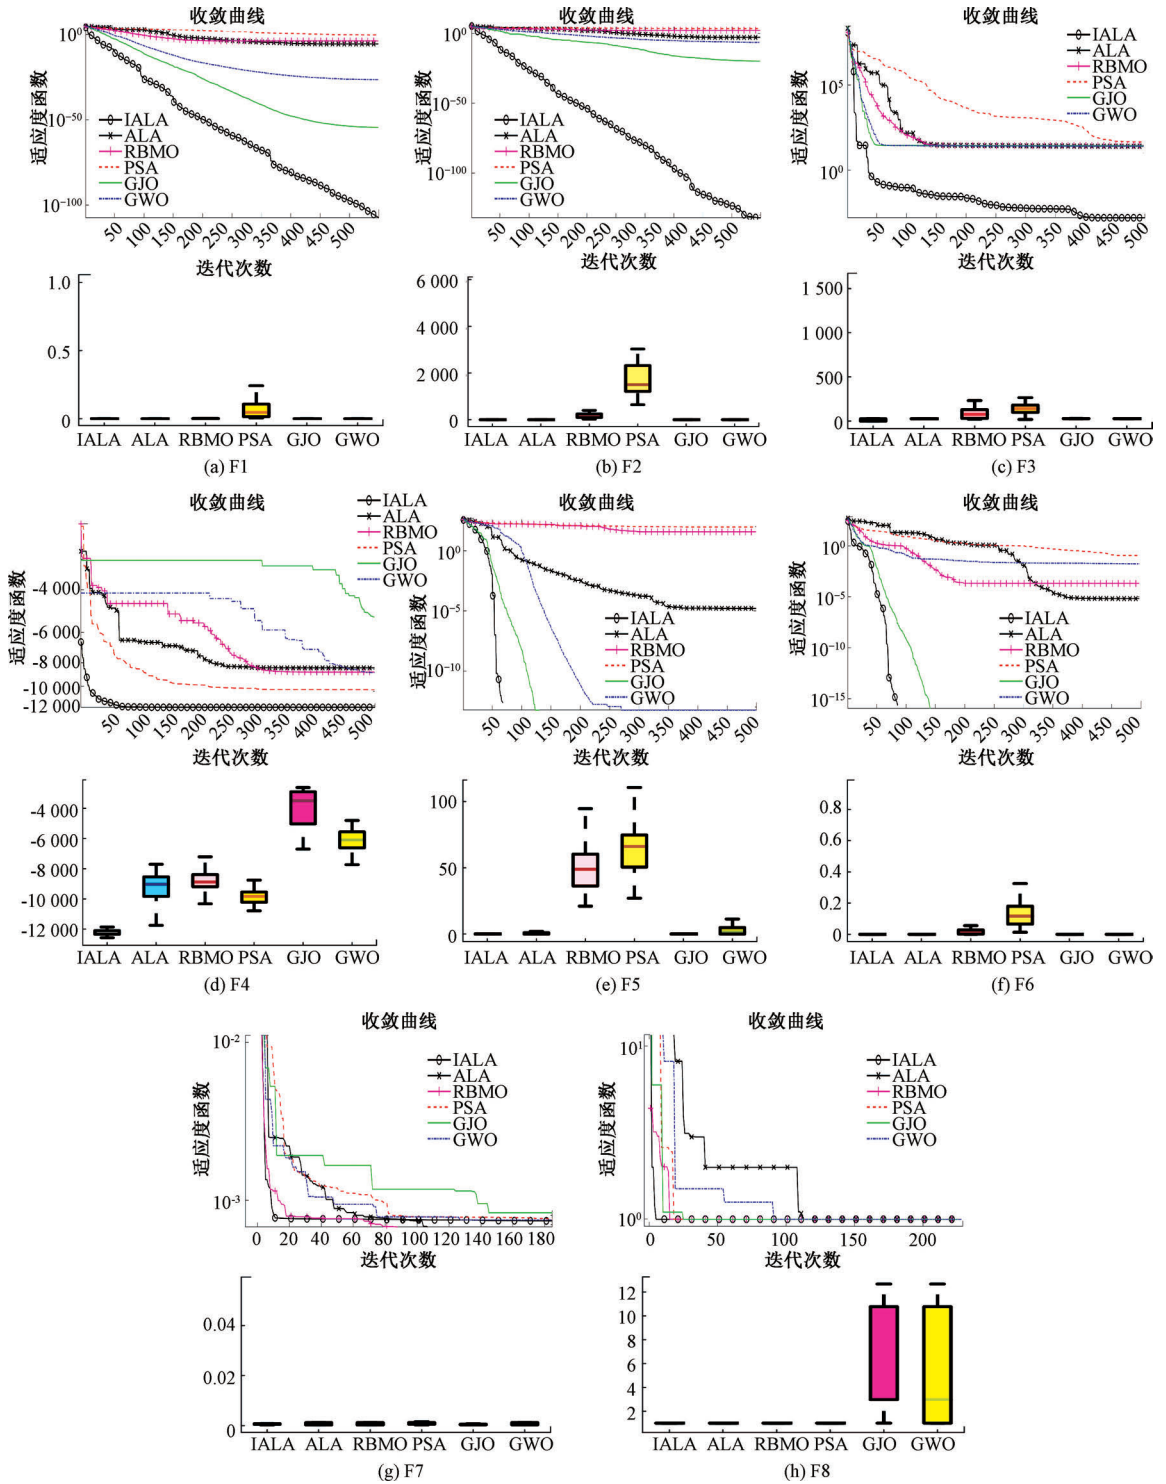


图 2 基准测试函数的收敛曲线及箱线图

Fig. 2 Convergence curve and box diagram of benchmark function

由图 2 可以明显看出,在单峰函数和多峰函数上,IALA 的收敛速度远远快于其他几个算法,最后也能达到

更小的适应度值,并且原旅鼠算法 ALA 在好几个函数上都是在迭代次数很少的时候就陷入了局部最优,IALA 却

没有这个问题,也证实了本文利用 Hammersley 序列及反向差分变异机制对初始种群进行优化的有效性,而更小的适应度值也证明了本文提出的软霜冰搜索机制的优越性,收敛速度和收敛精度都有明显提升。但是在复合函数上, F7 函数上 GWO 表现不太好, F8 函数上 GJO 表现不太好,IALA 和其他算法相比并没有特别明显的优势,这也进一步说明了 IALA 在复合函数上还有很大的提升空间。

4 IALA 在机器人路径规划中的应用

4.1 机器人路径规划实验准备

路径规划是当今智能机器人导航和自主移动的核心技术之一,它是指机器人在特定环境中找出一条从起点到终点的最优或者最可行路线,并且不能碰到路径中间的障碍。接下来将 IALA 及上文中的几个算法应用于机器人路径规划实验,进一步证明本文改进算法的有效性及其优越性。

适应度函数是可以直观地反映出算法的优化程度,而

机器人路径规划是要在起点和终点之间找到一条最短的路径,故根据路径长度设计如下的适应度函数:


$$F = \omega(E1 \times E2) + \sum_{i=1}^{N-1} \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (26)$$

其中, ω 为障碍物数量, $E1$ 为起点坐标, $E2$ 为终点坐标, x_i 和 y_i 为横纵坐标。


4.2 实验

为了验证 IALA 在机器人路径规划中的性能表现,本文将 IALA 和 ALA、RBMO、PSA、GJO 以及 GWO 放在一起进行对比实验。实验在相同的栅格地图中进行,左下角圆点为路径起点,右上角圆点为路径终点,并且将算法的种群数量设置为 50,最大迭代次数为 100,每个算法将独立运行 50 次。







首先在 20×20 栅格地图中进行实验,图 3 为该实验的适应度迭代曲线、路径长度箱线图及路径规划仿真图,表 3 为该实验各算法的实验数据。



(a) 适应度迭代曲线
(a) Fitness iteration curve



(b) 路径长度箱线图
(b) Path length box diagram



(c) 路径规划结果
(c) Path planning result

图 3 20×20 地图实验结果

Fig. 3 Experimental results of 20×20 map

由图 3 可知,在寻找最优路径时,GJO 和 GWO 明显路线复杂,拐点较多,剩下 4 个算法路径重合部分较多,路

径图中表现的差距不够明显,但在迭代曲线图中,很明显能看出 IALA 能够用更少的迭代次数达到最小的适应度

表 3 20×20 地图实验数据


Table 3 Experimental data of 20×20 map

算法	最优值	标准差	平均值	中值	最差值
IALA	28.605 0	0.848 8	30.550 2	30.977 7	31.411 7
ALA	28.834 5	2.329 6	31.778 2	31.331 3	37.863 9
RBMO	29.776 5	1.985 2	32.835 4	33.544 4	35.347 2
PSA	28.834 5	1.438 7	31.175 1	30.938 7	34.464 8
GJO	30.948 1	3.723 9	35.778 1	36.291 6	42.258 0
GWO	31.915 5	4.587 1	36.948 5	36.148 9	47.311 0


值。由表 3 中数据也可以直观地看出,IALA 的每项数据都是最好的。IALA 和原算法 ALA 相比,最优路径长度减少了 0.64%,平均路径长度减少了 3.86%,和 RBMO 相比,分别减少了 2.93%、6.96%,和 PSA 相比,分别减少了 0.64%、2%,和 GJO 相比,分别减少了 7.57%、14.61%,

和 GWO 相比,分别减少了 10.37%、17.32%,这也证明了本文算法改进的有效性以及在机器人路径规划中的可行性。

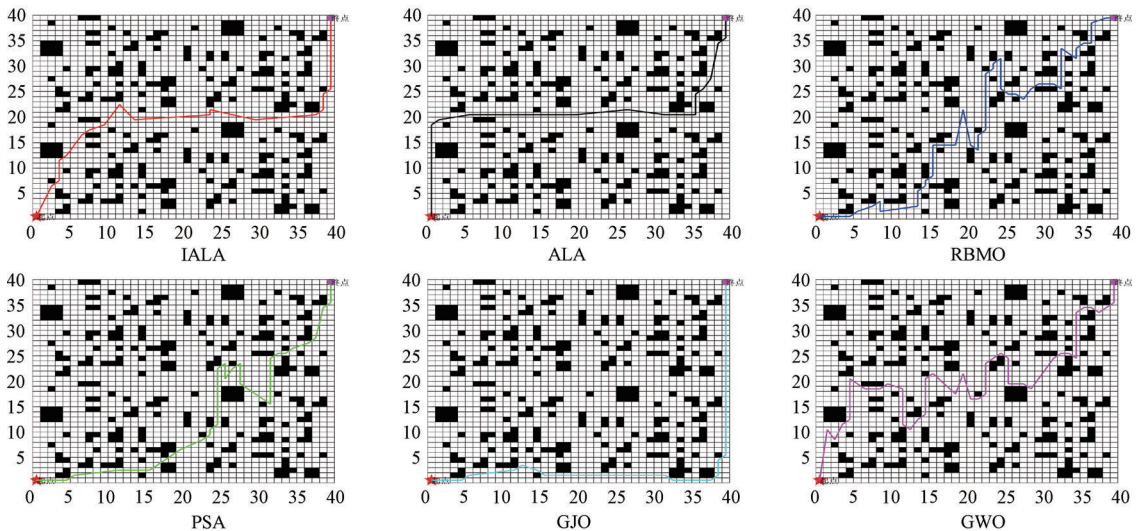
然后在 40×40 的栅格地图中进行第 2 次实验,实验的结果如图 4 和表 4 所示。



(a) 适应度迭代曲线
(a) Fitness iteration curve



(b) 路径长度箱线图
(b) Path length box diagram



(c) 路径规划结果
(c) Path planning result

图 4 40×40 地图实验结果

Fig. 4 Experimental results of 40×40 map

由图 4 可以看出,在地图变复杂以后,能够更加直观得看到 IALA 的路线比别的算法路线更短,并且拐点也少,证明路径更优。由表 4 可以看出在 5 项数据中,IALA

的标准差要比 ALA 稍微差一点,其他 4 项数据都是最优。IALA 和原算法 ALA 相比,最优路径长度减少了 10.24%,平均路径长度减少了 6.91%,和 RBMO 相比,

表4 40×40 地图实验数据


Table 4 Experimental data of 40×40 map

算法	最优值	标准差	平均值	中值	最差值
IALA	61.621 9	3.489 5	68.596 6	68.623 0	74.371 6
ALA	68.648 5	2.626 9	73.686 7	73.313 7	77.414 2
RBMO	84.772 9	16.879 1	111.647 6	113.556 8	133.915 2
PSA	75.266 4	16.249 9	92.527 1	88.810 4	124.462 8
GJO	73.510 8	22.885 2	105.181 2	101.049 8	136.246 6
GWO	101.345 2	464.712 9	279.491 5	134.293 6	1 600.000 0


分别减少了 27.31%、38.56%，和 PSA 相比，分别减少了 18.13%、25.86%，和 GJO 相比，分别减少了 16.17%、34.78%，和 GWO 相比，分别减少了

39.2%、75.46%。

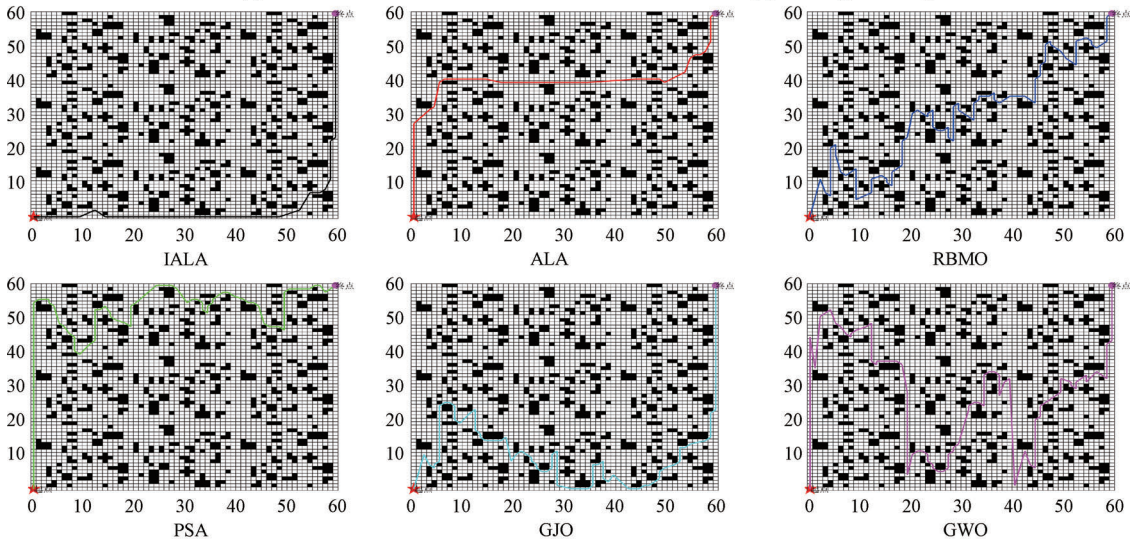
最后在 60×60 的地图中进行第 3 次实验，实验的结果如图 5 和表 5 所示。



(a) 适应度迭代曲线
(a) Fitness iteration curve



(b) 路径长度箱线图
(b) Path length box diagram



(c) 路径规划结果
(c) Path planning result

图5 60×60 地图实验结果

Fig. 5 Experimental results of 60×60 map

由图 5 可以看出，在地图更加复杂之后，IALA 依旧保持着优势，比其他算法的路径更加简短，而 ALA 的表现也很不错，路径也就比 IALA 复杂一点，但是能够明显看出优于其他 4 种算法。表 5 中的数据则能直观看出 IALA 的先进性，各项数据皆是最优。IALA 和原算法 ALA 相比，

最优路径长度减少了 2.02%，平均路径长度减少了 2.6%，和 RBMO 相比，分别减少了 24.18%、55.04%，和 PSA 相比，分别减少了 42.56%、55.04%，和 GJO 相比，分别减少了 46.06%、95.64%，和 GWO 相比，分别减少了 51.46%、97.92%。

表 5 60×60 地图实验数据

Table 5 Experimental data of 60×60 map

算法	最优值	标准差	平均值	中值	最差值
IALA	109.110 5	1.534 2	112.568 4	112.965 2	115.064 5
ALA	111.255 8	2.384 6	115.568 5	116.065 4	117.094 5
RBMO	143.904 3	44.015 9	250.373 3	264.627 3	288.713 1
PSA	189.962 8	34.584 4	250.360 1	248.309 9	328.110 0
GJO	202.265 1	1 634.992 7	2 584.578 4	3 600.000 0	3 600.000 0
GWO	224.762 6	3 015.847 6	5 422.476 3	5 400.000 0	10 800.000 0

5 结 论

针对旅鼠算法(ALA)存在的收敛速度慢、收敛精度低及易陷入局部最优等问题,提出了一种改进旅鼠算法(IALA)。首先该算法通过引入 Hammersley 序列及反向差分变异机制,极大地增强了初始种群的多样性,使初始种群更加优秀,为后续迭代打下坚实基础;接着又提出软冰霜搜索机制,增强算法后期的寻优能力,也更能避免其陷入局部最优。然后通过选取 8 个基准测试函数将 IALA 与别的算法在一起进行对比测试,IALA 在单峰函数和多峰函数上均表现优异,突出了它优秀的收敛速度、收敛精度及寻优能力。最后将 IALA 及别的算法应用于智能机器人路径实验,实验选用 20×20 和 40×40 以及 60×60 的栅格地图,再一次证明了 IALA 的优越性,且地图越复杂,IALA 的性能表现越好。测试函数对比结果及机器人路径规划实验结果都证明了本研究算法改进的有效性,并且能很好地应用于智能机器人的路径规划。

参考文献

- [1] SHENTU S, GONG ZH, LIU X J, et al. Hybrid navigation system based autonomous positioning and path planning for mobile robots[J]. Chinese Journal of Mechanical Engineering, 2022,35(5): 235-247.
- [2] 采国顺,刘昊吉,冯吉伟,等. 智能汽车的运动规划与控制研究综述[J]. 汽车安全与节能学报, 2021, 12(3): 279-297.
CAI G SH, LIU H J, FENG J W, et al. Review on the research of motion planning and control for intelligent vehicles[J]. Journal of Automotive Safety and Energy Conservation, 2021,12(3): 279-297.
- [3] DAS P K, BEHERA H S, JENA P K, et al. An intelligent multi-robot path planning in a dynamic environment using improved gravitational search algorithm[J]. International Journal of Automation and Computing, 2021,18(6):1032-1044.
- [4] 朱翠,罗宇豪,王占刚,等. 基于改进蚁群算法的步行街火灾疏散路径规划[J]. 电子测量技术, 2024,47(16): 73-82.

- ZHU C, LUO Y H, WANG ZH G, et al. Fire evacuation route planning for pedestrian streets based on improved ant colony algorithm [J]. Electronic Measurement Technology, 2024,47(16):73-82.
- [5] 姜龙腾,迟瑞娟,熊泽鑫,等. 基于优化人工势场法的插秧机绕障策略研究[J]. 农业机械学报, 2022, 53(S1): 20-27.
JIANG L T, CHI R J, XIONG Z X, et al. Obstacle winding strategy of rice transplanter based on optimized artificial potential field method [J]. Transactions of the Chinese Society for Agricultural Machinery, 2022,53(S1):20-27.
 - [6] 熊勇刚,李波,姚焘,等. 改进 A* 算法的机器人全局路径规划[J]. 电子测量技术, 2024,47(5):31-36.
XIONG Y G, LI B, YAO T, et al. Global path planning of mobile robot with improved A* algorithm [J]. Electronic Measurement Technology, 2024, 47(5): 31-36.
 - [7] 张震,方群,宋金丰,等. 基于协同粒子群算法的航天器集群动态路径规划算法研究[J]. 西北工业大学学报, 2021,39(6):1222-1232.
ZHANG ZH, FANG Q, SONG J F, et al. Research on dynamic path planning algorithm of spacecraft cluster based on cooperative particle swarm algorithm [J]. Journal of Northwestern Polytechnical University, 2021,39(6):1222-1232.
 - [8] SONG T, SUN Y Q, YUAN J P, et al. Lunar robot path planning based on improved ant colony algorithm [J]. Transactions of Nanjing University of Aeronautics and Astronautics, 2022,39(6): 672-683.
 - [9] 蒋一波,周泽宝,李强,等. 基于遗传算法的低碳导向的物流中心配送优化[J]. 计算机科学, 2024, 51(S2): 80-85.
JIANG Y B, ZHOU Z B, LI Q, et al. Optimization of low-carbon oriented logistics center distribution based on genetic algorithm [J]. Computer Science, 2024, 51(S2):80-85.
 - [10] 宋宇,高岗,梁超,等. 基于多策略改进灰狼算法的无

- 人机路径规划[J]. 电子测量技术, 2025, 48(1): 84-91.
- SONG Y, GAO G, LIANG CH, et al. UAV path planning based on multi-strategy improved gray wolf algorithm[J]. Electronic Measurement Technology, 2025, 48(1): 84-91.
- [11] XIAO Y N, CUI H, KHURMA R A, et al. Artificial lemming algorithm: A novel bionic meta-heuristic technique for solving real-world engineering optimization problems [J]. Artificial Intelligence Review, 2025, 58(3): 84.
- [12] ZHU X M, JIA CH CH, ZHAO J D, et al. An enhanced artificial lemming algorithm and its application in UAV path planning[J]. Biomimetics, 2025, 10(6): 377.
- [13] 杨原, 陈明霞, 陆俊良, 等. 多策略改进的人工旅鼠算法及工程应用[J]. 电子测量技术, 2025, 48(22): 98-111.
- YANG Y, CHEN M X, LU J L, et al. Multi-strategy improved artificial lemming algorithm and engineering applications[J]. Electronic Measurement Technology, 2025, 48(22): 98-111.
- [14] 王逸文, 王维莉, 杨宇鸽, 等. 多策略融合改进的海洋捕食者算法及其工程应用[J]. 计算机集成制造系统, 2025, 31(7): 2591-2604.
- WANG Y W, WANG W L, YANG Y G, et al. Improved marine predators algorithm with multi-strategy fusion and its engineering applications [J]. Computer Integrated Manufacturing Systems, 2025, 31(7): 2591-2604.
- [15] SU H, ZHAO D, HEIDARI A A, et al. RIME: A physics-based optimization [J]. Neurocomputing, 2023, 532: 183-214.
- [16] 李梓源, 于剑桥, 李佳讯. 基于 H-BSO 算法的导弹敏捷转弯弹道优化[J]. 战术导弹技术, 2023(3): 32-41.
- LI Z Y, YU J Q, LI J X. Ballistic optimization of missile agile turning based on H-BSO algorithm[J]. Tactical Missile Technology, 2023(3): 32-41.
- [17] 丁瑞成, 周玉成. 引入莱维飞行与动态权重的改进灰狼算法[J]. 计算机工程与应用, 2022, 58(23): 74-82.
- DING R CH, ZHOU Y CH. Improved grey wolf optimization algorithm based on Levy flight and dynamic weight strategy [J]. Computer Engineering and Applications, 2022, 58(23): 74-82.
- [18] 严一跲, 陈明霞, 杨原, 等. 多策略改进的红嘴蓝鹊优化算法及其应用[J]. 电子测量技术, 2025, 48(10): 84-92.
- YAN Y CH, CHEN M X, YANG Y, et al. Multi-strategy improved red-billed blue magpie optimizer and application[J]. Electronic Measurement Technology, 2025, 48(10): 84-92.
- [19] 彭艺, 雷云揆, 杨青青, 等. 改进 PID 搜索算法的山地环境无人机路径规划[J]. 系统仿真学报, 2025, 37(12): 3075-3086.
- PENG Y, LEI Y K, YANG Q Q, et al. Improved PID search algorithm for UAV path planning in mountainous terrain [J]. Journal of System Simulation, 2025, 37(12): 3075-3086.
- [20] 朱兴淋, 汪廷华, 赖志勇. 混合策略改进的金豺优化算法[J]. 计算机工程与应用, 2024, 60(4): 99-112.
- ZHU X L, WANG T H, LAI ZH Y. Hybrid-strategy improved golden jackal optimization [J]. Computer Engineering and Applications, 2024, 60(4): 99-112.

作者简介

焦怀良, 硕士研究生, 主要研究方向为机器人智能控制等。

E-mail: 1924980548@qq.com

刘立群(通信作者), 教授, 博士生导师, 主要研究方向为智能电网、光伏发电、风力发电及其混合发电系统等。

E-mail: llqd2004@163.com