

基于多策略改进旅鼠优化算法的机器人路径规划方法

侯俊涛¹ 钱璐² 曹菁菁² 赵强伟²

(1. 中铁第六勘察设计院集团有限公司, 天津 300000)

(2. 武汉理工大学 交通与物流工程学院, 武汉 430063)

摘要:【目的】针对传统旅鼠优化算法(Artificial Lemming Algorithm, ALA)在移动机器人路径规划中初始种群分布不均、易陷局部最优、局部开发方向性不足的问题,提出基于多策略改进的旅鼠优化算法(Improved Artificial Lemming Algorithm, IALA)。**【方法】**首先,采用拉丁超立方抽样初始化种群,提升全局探索起点质量;其次,在探索阶段引入反捕食策略,嵌入到算法的长距离迁徙和掘洞行为之后,强制个体偏离当前局部最优区域,扩大搜索范围;最后,在开发阶段提出浣熊上树策略,在Lévy飞行基础上融合浣熊优化算法的线性推进更新方式,增强算法中后期定向推进能力与收敛稳健性。为验证所提算法的有效性,选取6个标准测试函数及2组栅格地图进行了实验。**【结果】**试验结果表明,IALA寻优精度与稳定性均优于对比算法;在20×20和40×40栅格地图路径规划试验中,其最优路径长度相较于标准旅鼠优化算法分别缩短1.17和3.82;同时,标准差更小、路径更平滑,验证了IALA算法的稳定性和可靠性。

关键词:人工旅鼠优化算法;路径规划;拉丁超立方;反捕食策略;浣熊上树策略

中图分类号: TP212; TP242 **DOI:** 10.16578/j.issn.1004.2539.XXXX.XX.001

0 引言

近年来,随着人工智能、传感技术和自动控制等领域的持续突破,机器人在生产与生活中的应用愈加广泛。作为实现机器人自主移动的核心环节,路径规划需要依据最短路径等特定指标,在存在障碍的环境中为机器人寻找一条从起点到终点、既能安全避障又整体最优的行动路线^[1]。路径规划对提升导航效率、保障系统安全和优化资源使用具有重要意义,已广泛应用于工业制造、智慧物流、无人驾驶及服务机器人等多个领域,成为推动智能化发展的重要组成部分。

目前,路径规划算法可分为3种:①基于搜索的算法,包括A*算法^[2-3]、Dijkstra算法^[4]等,如赵倩等^[5]提出的一种结合改进A*算法与动态窗口法,可用于提升自动导引车(Automated Guided Vehicle, AGV)在复杂环境中的实时路径规划与动态避障性能。②基于采样的路径规划算法,包括快速探索随

机数(RRT)算法^[6-7]等。③启发式搜索算法,涵盖粒子群算法^[8]、沙猫群优化算法^[9]、黏菌优化算法^[10]、天牛群算法^[11]等。

在上述方法体系中,群智能算法因其参数易于实现、全局搜索能力较强、适用于高维非线性优化问题等特点,近年来在复杂环境路径规划中受到越来越多关注。相比传统搜索与采样方法,群智能算法在处理不规则障碍、非凸空间和多目标约束方面表现出较大潜力。然而,由于其本质依赖群体协同搜索机制,该类算法在实际应用中仍面临如收敛速度有限、易陷入局部最优、参数设置敏感等问题。为此,不少研究致力于提升其全局探索与局部开发能力。韩涛等^[12]针对河马算法全局搜索及探索能力低,综合了Lévy飞行、成长比例机制及自适应学习率进行改进,试验表明,在3种不同复杂度的丘陵地形无人机路径规划任务中,所获路径长度更短。原慧琳等^[13]针对角蜥蜴优化算法存在的易陷入局部最

收稿日期: 2025-11-19 修回日期: 2026-01-22

基金项目: 国家自然科学基金项目(52305033)

作者简介: 侯俊涛,男,1988年生,硕士研究生,高级工程师;主要研究方向为机械故障诊断与机器人路径规划; juntaohou@163.com。

曹菁菁(通信作者),女,1984年生,湖北黄石人,博士,副教授;主要研究方向为机器学习和模式识别; bettycao@whut.edu.cn。

引用格式: 侯俊涛,钱璐,曹菁菁,等.基于多策略改进旅鼠优化算法的机器人路径规划方法[J].机械传动,XXXX,XX(XX):1-11.
HOU Juntao, QIAN Lu, CAO Jingjing, et al. Robot path planning method based on a multi-strategy improved artificial lemming optimization algorithm[J]. Journal of Mechanical Transmission, XXXX, XX(XX): 1-11.



免费获取

优、收敛速度慢和搜索精度较差的问题,引入了精英反向区域学习、非线性收敛因子与双路径逃逸策略、以及随机分形分层优化共3项改进。改进后的算法在二维栅格地图路径规划中求得的路径更短、稳定性更好。黄开启等^[14]针对鲸鱼优化算法收敛速度慢、易陷入局部最优的问题,通过融合 Logistic-Tent 复合混沌映射与反向学习策略改进种群初始化,引入非线性收敛因子和自适应惯性权重以平衡算法探索与开发能力,并加入随机差分策略增强全局搜索。改进后的鲸鱼算法在路径规划仿真中获得更短路径、更少拐点和更短耗时,有效提升了算法的优化性能和实用性。

旅鼠优化算法(Artificial Lemming Algorithm, ALA)^[15]是2025年提出的一种新型群智能优化算法,常应用于连续函数优化问题。但是,标准ALA算法仍存在寻优精度低、易陷入局部最优的不足。因此,本文提出一种多策略改进ALA的移动机器人路径规划算法(Improved Artificial Lemming Algorithm, IA-LA)。首先,采用拉丁超立方采样方法初始化种群,提高全局探索的起点质量;接着,在算法探索阶段引入反捕食策略,该策略嵌入于长距离迁徙和掘洞行为之后,能够强制个体偏离当前局部最优区域,有效扩大全局搜索范围;然后,在开发阶段提出浣熊上树策略,以弥补单一Lévy扰动在方向性上的不足;最后,通过多种模型与不同复杂度的场景地图进行试验分析,以检验优化后算法的性能提升。

1 旅鼠优化算法

1.1 初始化

在人工旅鼠算法中,初始化阶段是整个优化过程的起点。在该阶段,算法通过在搜索空间内随机初始化种群中的每个个体的位置,保证初始解覆盖整个搜索空间。每个个体的初始位置 $z_{i,j}$ 被随机设置在指定的搜索空间边界 B_{lj} 和 B_{uj} 之间,表示为

$$z_{i,j} = B_{lj} + R(B_{uj} - B_{lj}), \quad (1)$$

$$i = 1, \dots, N; \quad j = 1, \dots, D$$

式中, B_{lj} 和 B_{uj} 分别为第 j 维的下界和上界; R 为在区间 $[0, 1]$ 上的均匀随机数; N 为种群的大小, D 为问题的维度。

1.2 探索阶段

探索阶段是人工旅鼠算法的关键部分。在该阶段,算法模拟旅鼠的探索行为,进行广泛的搜索,寻找潜在的最优解。旅鼠在寻找食物和栖息地时会进行广泛的迁徙和探索,因此,算法通过长距离迁

徙和掘洞这两种行为来模拟旅鼠的自然习性,帮助算法跳出局部最优解。

1) 长距离迁徙

在长距离迁徙阶段,算法模拟旅鼠通过随机扩散方式在广阔的区域内寻找新的栖息地。该阶段的核心思想是使用布朗运动模型来模拟个体在搜索空间中的随机运动。迁徙的更新公式为

$$\vec{Z}_i(t+1) = \vec{Z}_{\text{best}}(t) + F \overrightarrow{BM} \{ \vec{R} \cdot [\vec{Z}_{\text{best}}(t) - \vec{Z}_i(t)] + (1 - \vec{R}) \cdot [\vec{Z}_i(t) - \vec{Z}_a(t)] \} \quad (2)$$

式中, $\overrightarrow{BM}$ 为布朗运动的随机步长,表示个体的随机游走。更新过程结合了两个因素:朝向当前最优解的方向 $[\vec{Z}_{\text{best}}(t)]$ 和随机游走的方向 $[\vec{Z}_a(t)]$,通过动态权重 $\vec{R}$ 控制两个方向的影响力。布朗运动的概率密度 f 为

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

式中, $\vec{Z}_i(t)$ 为第 i 个个体在第 t 代的位置; $\vec{Z}_{\text{best}}(t)$ 为当前最优解的位置; $\vec{Z}_a(t)$ 为从种群中随机选择的个体位置。

$\vec{R}$ 为随机权重向量,用于控制朝向最优解或随机个体的比例。

$$\vec{R} = 2 \times \text{rand}(1, D) - 1 \quad (4)$$

式中, $\text{rand}(1, D)$ 为生成1行、 D 列的随机向量。

长距离迁徙帮助算法在广阔的搜索空间内进行全面的探索,避免早期收敛到局部最优。

2) 掘洞

在旅鼠的自然行为中,掘洞是寻找栖息地的常见行为。在算法中,掘洞行为模拟了个体在已知区域内深入探索的过程。通过在最优解周围进行局部搜索,个体能够更精细地搜索潜在的优质解。更新公式为

$$\vec{Z}_i(t+1) = \vec{Z}_i(t) + FL(t) [\vec{Z}_{\text{best}}(t) - \vec{Z}_b(t)] \quad (5)$$

式中, $\vec{Z}_b(t)$ 为从种群中随机选择的个体位置; F 为方向标志; $L(t)$ 为随时间变化的步长,用于控制搜索幅度,有

$$L(t) = R(1 + \sin \frac{t}{2}) \quad (6)$$

式中, R 为均匀随机数。步长 $L(t)$ 以周期性变化的方式调整搜索的范围,确保个体在探索过程中不会陷入单一位置。

掘洞行为使算法能够在局部区域进行深度探索,寻找更优的解。

1.3 开发阶段

开发阶段是算法的精细化过程, 模拟了旅鼠在找到食物后, 围绕已知资源进行细致搜寻的行为。在该阶段, 算法通过觅食和规避天敌两种机制实现局部优化。

1) 觅食

觅食行为模拟了旅鼠在找到食物后围绕食物进行的螺旋式寻找。在该阶段, 个体在最优解附近进行精细的局部搜索。更新公式为

$$\vec{Z}_i(t+1) = \vec{Z}_{\text{best}}(t) + F_s(t)R\vec{Z}_i(t) \quad (7)$$

式中, 螺旋路径可表示为

$$s(t) = r(t) [\sin(2\pi R) + \cos(2\pi R)] \quad (8)$$

$$r(t) = \sqrt{\sum_{j=1}^D [z_{\text{best},j}(t) - z_{i,j}(t)]^2} \quad (9)$$

式中, $r(t)$ 为个体当前位置到全局最优解的欧氏距离; $s(t)$ 控制螺旋步长; 该公式通过螺旋式的随机游走, 有效地引导个体在最优解附近进行微调, 逐步逼近全局最优。

2) 规避天敌

规避天敌模拟了旅鼠在受到威胁时的迅速反应。通过 Lévy 飞行, 个体能够进行长距离的跳跃, 以逃避局部极值的困扰。更新公式为

$$\vec{Z}_i(t+1) = \vec{Z}_{\text{best}}(t) + FG(t)\text{Levy}(D)[\vec{Z}_{\text{best}}(t) - \vec{Z}_i(t)] \quad (10)$$

式中, 逃逸系数 $G(t)$ 随时间逐步减小, 有

$$G(t) = 2(1 - \frac{t}{T_{\text{max}}}) \quad (11)$$

Lévy 飞行步长为

$$\text{Levy}(x) = 0.01 \frac{u\sigma}{|v|^{1/\beta}}, \quad (12)$$

$$\sigma = \left[\frac{\Gamma(1+\beta)\sin(\pi\beta/2)}{\Gamma(\frac{1+\beta}{2})\beta \cdot 2^{(\beta-1)/2}} \right]^{1/\beta} \quad (13)$$

式中, $\text{Levy}(D)$ 为 Lévy 飞行函数; $\beta = 1.5$, 为 Lévy 分布的指数; $G(t)$ 用于控制逃逸力度, 随着时间逐渐减小; u 和 v 均为在 $[0, 1]$ 范围内均匀分布的随机数。Lévy 飞行赋予个体以偶发的长跳跃能力, 帮助它们突破局部极值区域, 避免陷入不良局部最优解。

1.4 探索—开采过渡的能量调度

为实现从广泛探索到局部开发的平滑过渡, ALA 引入了能量因子 $E(t)$, 通过能量衰减来调节不同阶段的行为。初期能量较高时, 算法会执行更多的探索性行为, 而当能量降低时, 算法则转向局部精化过程。能量因子的计算公式为

$$E(t) = 4 \arctan(1 - \frac{t}{T_{\text{max}}}) \ln(\frac{1}{R}) \quad (14)$$

随着时间的推移, 能量逐渐衰减, 算法逐步从全局搜索过渡到局部优化。这一过程通过能量因子的动态变化确保了算法在全局探索与局部利用之间的有效平衡。

2 多策略改进的人工旅鼠优化算法

2.1 拉丁超立方种群初始化

在传统的旅鼠优化算法中, 由于对目标函数缺少先验, 初始种群通过伪随机方式生成。虽然能满足基本的初始化要求, 但其在多维空间中容易出现样本聚集和覆盖不足的问题, 使得种群对搜索空间的整体覆盖能力下降。初始分布不均衡使算法在早期阶段难以有效探索全部潜在区域, 从而降低了接近全局最优区域的概率, 进而影响后续迭代的寻优精度与稳定性。为了解决这一问题, 本文引入了一种基于拉丁超立方抽样 (Latin Hypercube Sampling, LHS) 的种群初始化方法。拉丁超立方抽样作为一种多维分层抽样技术, 能够有效地增强初始种群的多样性与全局搜索能力^[15]。

拉丁超立方抽样的核心思想是将每个维度的搜索空间均匀划分为多个子区间, 并在每个子区间内独立地进行均匀抽样^[16]。与传统的随机抽样不同, LHS 能够避免样本的聚集, 确保初始种群能够均匀覆盖整个搜索空间, 进而提高算法的全局探索能力。在具体实现上, 对于每个维度 $j (j = 1, \dots, d)$, 首先生成一个长度为 n_s 的随机排列 $\pi_j^{(i)}$ ($i = 1, \dots, n_s$), 然后在该排列的基础上, 结合独立的均匀随机数 $u_j^{(i)} \sim (0, 1)$, 通过以下公式生成归一化样本:

$$\tilde{x}_j^{(i)} = \frac{\pi_j^{(i)} + u_j^{(i)}}{n_s}, i = 1, \dots, n_s; j = 1, \dots, d \quad (15)$$

接着, 将归一化样本映射到原始搜索空间中, 即


$$x_j^{(i)} = a_j + (b_j - a_j) \cdot \tilde{x}_j^{(i)} \quad (16)$$

式中, a_j 和 b_j 分别为第 j 维的最小值和最大值; n_s 为种群规模。


图 1 所示为随机抽样与拉丁超立方抽样在一维空间上各取 100 个样本的分布对比。可以看出, 随机抽样存在明显的样本集中现象, 而拉丁超立方抽样样本分布均匀且无重叠, 覆盖整个区间。直方图更直观地展示了不同初始化方法之间的差异。统计数据显示, 采用 LHS 初始化方法能够在搜索空间内实现更均匀的数值分布。

2.2 反捕食策略


在人工旅鼠优化算法中,探索阶段的搜索通常是基于随机的步长和当前位置进行的,但这可能导致个体过早收敛,无法有效探索全局解空间,尤其是在复杂的多峰优化问题中。为了解决这个问题,反捕食策略(Anti-predator Strategy, APS)^[17]被引入到了ALA的探索阶段,以增加种群的多样性和搜索范围。反捕食策略的灵感来源于自然界中蛇类在遭遇捕食者时的逃避行为。当蛇类在寻找食物时遇到捕食者的威胁时,它们会主动改变位置、远离捕食者,以保障自己的安全。这一行为有效地扩大了蛇类的活动范围,也帮助它们避免在局部区域长期停留。同样地,反捕食策略的引入使得ALA在探索过程中能够持续打破种群在某一狭小区域的聚集状态,显著增加搜索空间的覆盖广度,提升算法的全局搜索能力。




(a) 拉丁超立方初始化



(b) 随机初始化



(c) 拉丁超立方初始化直方图



(d) 随机初始化直方图

图1 种群初始化分布图

Fig. 1 Population initial distribution map

具体来说,在探索阶段,先经过长距离迁徙和掘洞得到新的位置 $\vec{Z}_i(t+1)$,接着,通过反捕食策略进行位置更新方式,促使其偏离当前局部最优解,扩大搜索空间。具体的更新公式为

$$\vec{Z}_{i}^{\text{ap}}(t+1) = \vec{Z}_i(t+1) - \varphi [b_{\text{api}}^{\text{L}} + R(b_{\text{api}}^{\text{U}} - b_{\text{api}}^{\text{L}})] \quad (17)$$

式中, $\vec{Z}_i(t)$ 为当前个体的位置; φ 为由混沌系统生成的随机正整数(1或2),用于引导个体的反捕食行为; $b_{\text{api}}^{\text{L}}$ 和 $b_{\text{api}}^{\text{U}}$ 分别为个体在逃避捕食时的下界和上界,定义了逃逸范围; R 为一个范围在[0, 1]之间的随机数,用于引入不确定性、模拟逃避行为。

最终,将由反捕食策略生成的候选位置 $\vec{Z}_{i}^{\text{ap}}(t+1)$ 与当前位置 $\vec{Z}_i(t+1)$ 按适应度比较,取较优者作为探索阶段最终 $\vec{Z}_i(t+1)$ 。即

$$\vec{Z}_i(t+1) = \begin{cases} \vec{Z}_i(t+1), & \text{if } f_i < f_{\text{ap}} \\ \vec{Z}_{i}^{\text{ap}}(t+1), & \text{else} \end{cases} \quad (18)$$

2.3 浣熊上树策略

在ALA的开发阶段,单纯依赖Lévy扰动虽然可以通过偶发长跳跃在一定程度上缓解局部极小困境,但在浅局部极小附近常出现方向性不足与大步跳后回退的问题。随着迭代推进,步长衰减还会导致后期沿优质解方向的推进减弱。针对上述问题,本文在保持原有Lévy机制不变的前提下,引入来源于浣熊优化算法(Coati Optimization Algorithm, COA)^[18]的线性推进策略,并在每次开发更新时根据固定概率0.5在原有Lévy飞行与线性推进之间进行选择。线性推进的更新公式为

$$\vec{Z}_i(t+1) = \vec{Z}_i(t) + \alpha [\vec{Z}_{\text{best}}(t) - I\vec{Z}_i(t)] \quad (19)$$

式中,向量 $\alpha = (\alpha_1, \dots, \alpha_d)$ 满足 $0 < \alpha_j < 1$, d 为优化问题的维度; I 为1或2的随机整数。当 $I = 1$ 时,更新在每一维沿 $\vec{Z}_{\text{best}}(t) - \vec{Z}_i(t)$ 实现收缩,有利于在

最优附近稳定前进; 当 $l = 2$ 时, 更新在同一方向允许适度外推, 保持足够的位移幅度。为保持可行性, 对更新得到的 $\vec{Z}_i(t)$ 执行上下界截断。该策略在计算复杂度上基本不增加负担, 同时, 在统计与几何特性层面补齐了单一 Lévy 扰动的不足, 使算法在中后期具备更强的定向推进能力与更稳健的收敛表现。

2.4 算法流程图

图2为本文改进人工旅鼠优化算法流程图。

3 算法性能对比试验与分析

3.1 测试函数仿真试验

为验证改进ALA算法的有效性, 本文基于标准

测试函数进行仿真试验, 详细函数信息如表1所示。

选择传统人工旅鼠优化算法ALA、不实野燕麦优化算法(Animated Oat Optimization algorithm, AOO)、灰雁优化算法(Greylag Goose Optimization, GGO)、PID搜索优化算法(PID-based Search Algorithm, PSA)和高斯量子粒子群算法(Gaussian Quantum-behaved Particle Swarm Optimization, GQPSO)作为对照组, 来验证收敛精度。试验中, 种群大小设定为30, 最大迭代次数为500。为了减少随机因素的影响, 每种算法分别进行30次独立试验, 评价指标包括最差值、最优值、平均值和标准差。6种算法的寻优测试结果如表2所示。




图2 改进旅鼠优化算法流程图

Fig. 2 Flowchart of the improved lemming optimization algorithm

表1 测试函数详细信息

Tab. 1 Test function details

测试函数表达式	搜索范围	全局最优解
$F_1(x) = \sum_{i=1}^n x_i^2$	$[-100, 100]$	0
$F_2(x) = \sum_{i=1}^n x_i + \prod_{i=1}^n x_i $	$[-10, 10]$	0
$F_3(x) = \sum_{i=1}^n (\sum_{j=1}^i x_j)^2$	$[-100, 100]$	0
$F_4(x) = \max_{1 \leq i \leq n} x_i $	$[-100, 100]$	0
$F_5(x) = \sum_{i=2}^n 100(x_i - x_{i-1}^2)^2 + (1 - x_i)^2$	$[-30, 30]$	0
$F_6(x) = \sum_{i=1}^n (x_i + 0.5)^2$	$[-100, 100]$	0

从试验结果可以看出, 与对比算法相比, IALA 求解的目标函数精度及稳定性方面都表现更好, 其最优值和平均值接近于0, 标准差也保持在较小范围。具体而言, 对于 $F_1(x)$ 到 $F_4(x)$, IALA 基于拉丁超立方初始化在迭代早期就能实现种群的均匀分布, 使得算法能够迅速接近全局最优区域; 同时, 反捕

食策略有效避免了早期陷入局部极值, 从而保证了目标函数值快速下降。试验结果显示, IALA 在这些函数上基本能够达到理论最优解, 其平均值与标准差均远低于其他算法。在 $F_5(x)$ 、 $F_6(x)$, IALA 的优势同样明显, IALA 的浣熊上树狩猎策略进一步强化了局部精细开发, 使得算法在全局搜索与局部挖掘之间保持良好平衡。在 $F_6(x)$ 上, IALA 的结果不仅精度较高, 而且波动较小, 体现出较强的稳定性。

图3所示为IALA在6个函数上的收敛曲线, 进一步验证了IALA的优越性。在大部分测试函数上, IALA 中加入了拉丁超立方初始化提供的更优质的初始解, 从迭代开始时生成的适应度值就更为精确, 随迭代下降更快, 能更快接近全局最优。反捕食策略增强了算法调出局部最优解的能力, 在其他算法遇到局部最优开始停滞时, IALA 仍能继续收敛到更小的数量级。在迭代的后期, 浣熊上树策略能够提供更精细的搜索进一步提升算法的寻优精度。

由试验结果可知, IALA 在寻找最优解的过程中

表现出优于其他算法的性能,特别是在标准差、平均值、最优值和最差值方面。IALA 不仅展现了卓越的解质量,还在稳定性和迭代效率上优于其他算法。此外,图4中的箱线图进一步表明,IALA 的性能稳定性在整个过程中表现出极小的偏差,且一致性极佳。

表2 不同算法在测试函数上的优化结果

Tab. 2 Optimization results of different algorithms on test functions

函数	算法	最差值	最优值	平均值	标准差
$F_1(x)$	IALA	3.5×10^{-101}	1.7×10^{-124}	1.2×10^{-102}	3.5×10^{-101}
	ALA	1.77×10^{-5}	6.12×10^{-7}	6.6×10^{-6}	1.77×10^{-5}
	AOO	0.003 283	1.91×10^{-5}	0.000 347	0.003 283
	GGO	1.6×10^{-32}	4.14×10^{-49}	5.33×10^{-34}	1.6×10^{-32}
	PSA	0.321 222	0.002 297	0.082 02	0.321 222
	GQPSO	0.017 074	8.26×10^{-5}	0.002 125	0.017 074
$F_2(x)$	IALA	3.6×10^{-56}	7.32×10^{-64}	1.55×10^{-57}	6.68×10^{-57}
	ALA	0.002 807	0.000 191	0.000 897	0.000 574
	AOO	0.015 115	0.000 753	0.006 449	0.003 911
	GGO	1.14×10^{-21}	1.53×10^{-28}	8.85×10^{-23}	2.29×10^{-22}
	PSA	20.205 72	0.028 076	1.250 34	4.019 824
	GQPSO	0.117 318	0.000 751	0.012 996	0.023 077
$F_3(x)$	IALA	1.46×10^{-61}	3.35×10^{-81}	4.86×10^{-63}	2.66×10^{-62}
	ALA	0.003 417	6.45×10^{-6}	0.001 036	0.000 768
	AOO	65.626 51	1.730 052	23.153 26	16.946 99
	GGO	0.001 171	1.33×10^{-17}	4.49×10^{-5}	0.000 213
	PSA	6 239.212	662.425 5	2 128.166	1 103.113
	GQPSO	20 315.67	5 004.891	10 092.58	3 917.544
$F_4(x)$	IALA	6.91×10^{-45}	1.18×10^{-52}	5.15×10^{-46}	1.42×10^{-45}
	ALA	0.036 742	0.005 797	0.014 32	0.007 595
	AOO	6.514 502	0.066 823	0.745 364	1.132 76
	GGO	1.6×10^{-14}	8.01×10^{-22}	8.33×10^{-16}	2.93×10^{-15}
	PSA	20.111 3	5.892 309	13.103 34	3.348 967
	GQPSO	13.866 66	3.102 72	6.892 414	2.521 18
$F_5(x)$	IALA	25.344 19	4.5×10^{-5}	24.046 15	4.549 39
	ALA	26.380 33	23.744 11	25.504 85	0.519 316
	AOO	28.951 77	26.747 67	27.826 01	0.633 14
	GGO	28.786 1	27.427 8	28.405 64	0.384 279
	PSA	3 002.282	59.856 54	380.634 3	641.907 2
	GQPSO	525.859 5	21.595 45	159.897 2	115.013 9
$F_6(x)$	IALA	6.24×10^{-7}	1.05×10^{-10}	9.44×10^{-8}	1.16×10^{-7}
	ALA	0.263	7.8×10^{-6}	0.023 643	0.071 397
	AOO	0.008 462	0.001 048	0.003 451	0.002 131
	GGO	2.105 588	0.243 869	0.806 44	0.458 043
	PSA	1.876 266	0.002 841	0.114 642	0.348 749
	GQPSO	0.030 158	0.000 126	0.003 8	0.006 371

3.2 Wilcoxon 秩和检验

Wilcoxon 秩和检验是一种非参数统计方法,广泛应用于检验两个独立组之间的差异。本文采用

Wilcoxon 秩和检验评估改进后的人工旅鼠优化算法与其他优化算法之间是否存在显著统计学差异。为计算 p 值,每个算法独立运行 30 次,若 p 值小于 0.05,则表示两种算法之间存在显著差异。试验结果如表 3 所示。从表 3 数据中可以看出,在 6 个标准测试函数中,绝大多数 p 值均小于 0.05,表明 IALA 算法与其他对比算法在 0.05 显著性水平下存在显著差异,从统计学角度验证了 IALA 算法的可靠性与有效性。


表3 Wilcoxon 秩和检验 P 值

Tab. 3 P value of the Wilcoxon rank-sum test


函数	ALA	AOO	GGO	PSA	GQPSO
$F_1(x)$	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
$F_2(x)$	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
$F_3(x)$	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
$F_4(x)$	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}
$F_5(x)$	7.09×10^{-8}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	5.07×10^{-10}
$F_6(x)$	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}	3.02×10^{-11}

3.3 Friedman 检验

为进一步验证 IALA 与其他算法之间的显著性差异,本文在 6 个标准测试函数上对 IALA 及其对比算法进行了 30 次独立运行,并对所得的平均值数据进行了 Friedman 检验。Friedman 检验结果如图 5 所示。



(a) $F_1(x)$



(b) $F_2(x)$




图3 6个测试函数最优迭代曲线图

Fig. 3 Optimal iteration curve diagram for six test functions




图4 6个测试函数的箱型图

Fig. 4 Boxplots of six test functions

由图5可知, 给出了各算法在6个测试函数上的平均秩排名, 秩值越小表示算法整体性能越优。同时, 检验得到的 P 值为 3.838×10^{-8} , 远小于显著性水

平0.01, 表明各算法之间存在极显著统计差异, 且IALA在平均秩排名上最优, 进一步验证了其综合性能优势。




图5 Friedman 检验平均排名

Fig. 5 Average rankings of the Friedman test

4 IALA 在机器人路径规划中的应用

为了验证IALA在机器人路径规划中的性能，本文构建了20×20和40×40两种规模的栅格地图，对算法进行了验证。试验设定了两个场景：场景1为障碍物较少且分布密集的无规则简单地图；场景2则具有较多障碍物且分布较为稀疏，算法在该场景中容易陷入局部最优解。在试验中，采用相同的参数配置，统计算法运行30次后的均值结果进行分析。

4.1 路径规划流程

在路径优化过程中，IALA算法通过优化策略选择一条最优路径，确保路径满足以下规划约束：

1) 路径连续性条件：移动路径应避免不必要的迂回，确保机器人从当前节点 (x_1, y_1) 移动到下一节点 (x_2, y_2) 时，必须满足以下条件之一： $|x_2 - x_1| > e$ 或 $|y_2 - y_1| > e$ ，其中， e 为一个预设的最小阈值，这里设置为0，保证路径的连续性。

2) 环境边界与障碍物约束条件：移动路径必须严格保持在预设的地图边界内，且路径经过的所有节点及其连接线不得穿越任何障碍物栅格。确保路径的合法性，避免机器人进入不可达区域。

3) 目标路径最短条件。在满足1)、2)的前提下，根据适应度函数计算路径长度，适应度值最小即为最优路径。适应度函数可表示为

$$f(\boldsymbol{x}; G) = \begin{cases} \sum_{i=1}^{K-1} \|p_{i+1} - p_i\|_2, & n_B(\boldsymbol{x}; G) = 0 \\ mn n_B(\boldsymbol{x}; G), & n_B(\boldsymbol{x}; G) > 0 \end{cases} \quad (20)$$

式中， $\boldsymbol{x}$ 为决策向量； G 为栅格地图，并且有 $G \in \{0, 1\}^{m \times n}$ ，若 $G_{i,j} = 1$ ，则该位置为障碍，若 $G_{i,j} = 0$ 则为可通单元； n_B 为碰撞次数。

起点固定在左下角 $S = (1, 1)$ ，终点固定在右上

角 $E' = (m, n)$ 。给定决策向量 $\boldsymbol{x}$ ，通过逐列指定路径的行坐标，可以得到一条从点 S 到点 E' 的离散折线路径。路径在经过连续化与平滑处理后，得到点列 $\{p_1, p_2, \dots, p_K\}$ 。如果路径在生成过程中未与任何障碍单元相交，即 $n_B(\boldsymbol{x}; G) = 0$ ，则适应度取为折线总长度；如果路径与障碍发生交叉，则适应度取为地图规模 mn 与碰撞次数 n_B 的乘积，从而对不可行路径施加强烈惩罚。

4.2 路径规划仿真

首先，在20×20的环境栅格地图中，对IALA算法与其他两种算法的最优值、平均值和标准差进行对比分析。随后，在障碍物分布更加密集的40×40环境栅格地图中，重新进行对比试验。在试验中，所有算法的种群数量设定为30，并进行30次独立重复试验。试验的测试结果如表4所示，路径规划结果和算法收敛如图6~图9所示。

表4 30次路径规划试验算法性能对比

Tab. 4 Performance comparison of algorithms in 30 path planning tests

场景	算法	最优值	平均值	标准差
20×20	IALA	30. 970 6	35. 913 7	2. 83
	ALA	32. 142 1	36. 648 7	3. 477 3
	AOO	32. 476	76. 998 8	110. 612 3
40×40	IALA	68. 432	72. 563	3. 053 2
	ALA	72. 248 6	74. 549 1	2. 769
	AOO	74. 667 5	84. 146 5	8. 770 7




图6 20×20地图路径规划结果

Fig. 6 Path planning results on a 20×20 map

从表4中的试验数据来看，在20×20和40×40两种场景下，3种算法IALA、ALA、AOO的性能差异显著且整体趋势保持一致。其中，IALA算法的综合表现最为突出，其寻优精度显著优于对比算法。具体而言，在20×20栅格地图中，IALA的最优路径长度为30.970 6，相较于标准ALA算法缩短了1.17；

在 40×40 栅格地图中, IALA 的最优路径长度为 68.432, 相较于标准 ALA 算法的 72.248 6 缩短了 3.82, 验证了改进策略在复杂环境下的有效性。此外, IALA 算法的标准差在两种场景下分别为 2.83 和 3.053 2, 数值始终较小, 说明其不仅能稳定找到较优路径, 性能波动也较小, 稳定性表现良好。ALA 算法的性能仅次于 IALA, 其最优值和平均值在两种场景下均略高于 IALA, 不过在 40×40 场景中, 该算法的标准差达到 2.769, 甚至略低于 IALA。相比之下, AOO 算法的表现明显落后, 无论是 20×20 场景还是 40×40 场景, 其最优值和平均值均为三者中最高, 尤其是 20×20 场景下平均值达到 76.998 8, 40×40 场景下平均值也高达 84.146 5, 且该算法的标准差在两种场景下分别为 110.612 3 和 8.770 7, 远大于 IALA 和 ALA 算法。




图7 20×20地图算法收敛图

Fig. 7 Convergence plot of the 20×20 map




图8 40×40路径规划结果图

Fig. 8 Path planning results on a 40×40 map

由图6、图7可以看出, 在 20×20 场景中, 3种算法都能搜索到与障碍物无碰撞的可行路径, 但存在明显差异。ALA 算法路径拐点相对较多, 导致路径较长; AOO 算法路径在部分路段有一定绕行, 搜索精准度有待提高; IALA 算法路径拐点最少, 更平

滑且长度最短。结合收敛曲线, IALA 算法的适应度函数值下降速度较快, 在迭代前期就迅速降低, 且更早趋于稳定, 说明其收敛速度快、寻优能力强。

进一步在 40×40 场景中验证 IALA 算法的优越性, 从图8、图9的试验结果可以看出, ALA、AOO 算法的路径围绕边缘区域, 曲折程度高, 致使路径长度较长, 而 IALA 算法的路径更为顺畅, 拐点数量少, 而且其路径长度在3种算法中最短。收敛曲线图中 IALA 算法的适应度函数值下降速率仅次于 ALA, 在迭代初期就急剧降低, 且很早就进入稳定状态。




图9 40×40地图算法收敛图

Fig. 9 Convergence plot of the 40×40 map

5 结论

提出并验证了一种多策略改进的人工旅鼠优化算法(IALA), 展示了其在移动机器人路径规划任务中的显著优势。IALA 采用拉丁超立方抽样初始化在高维搜索空间中提供更均匀的种群分布, 显著提升了算法的全局探索起点质量和收敛一致性; 引入反捕食策略, 嵌入探索阶段的长距离迁徙与掘洞行为之后, 通过强制个体偏离当前局部最优区域, 有效扩大了搜索范围, 增强了算法跳出局部极值的能力; 提出浣熊上树策略, 弥补了单一 Lévy 扰动在方向性上的不足, 提升了算法中后期的定向推进能力和收敛稳健性。

上述3项系统的试验结果全面验证了 IALA 的卓越性能。首先, 针对6个标准测试函数上的仿真结果表明, IALA 在寻优精度、稳定性及收敛速度方面均优于传统 ALA、AOO、GGO、PSA 和 GQPSO 等对比算法; 其次, Wilcoxon 秩和检验与 Friedman 检验结果一致表明, IALA 在统计意义上显著优于其他算法, 进一步证明了其改进策略的有效性与可靠性; 最后, 在 20×20 和 40×40 栅格地图的路径规划试验

中,IALA 在最优路径长度、平均路径长度和标准差等指标上均显著优于 ALA 和 AOO 算法,路径更短、拐点更少、平滑性更好,充分体现了其在实际机器人路径规划任务中的高效性与实用性。

参 考 文 献

- [1] Dian S Y, Zhong J N, Guo B, et al. A smooth path planning method for mobile robot using a BES-incorporated modified QPSO algorithm [J]. Expert Systems with Applications, 2022, 208: 118256.
- [2] 高九州,刘育航. 基于改进 A* 算法和再优化的避障路径规划[J]. 电子测量技术, 2024, 47(21): 21-27.
Gao Jiuzhou, Liu Yuhang. Obstacle avoidance path planning based on improved A* algorithm and re-optimization [J]. Electronic Measurement Technology, 2024, 47(21): 21-27.
- [3] 王宇斌,沈振军,王昱宸,等. 基于 A* 算法的四面体机器人路径规划研究[J]. 机械传动, 2024, 48(2): 42-47.
Wang Yubin, Shen Zhenjun, Wang Yuchen, et al. Research on path planning for tetrahedral robots based on A* algorithm [J]. Journal of Mechanical Transmission, 2024, 48(2): 42-47.
- [4] 郭建,曾志豪,黄熙航,等. 融合改进 Dijkstra 算法和 MPC 的单舵轮机器人路径规划[J]. 组合机床与自动化加工技术, 2024(6): 18-23.
Guo Jian, Zeng Zhihao, Huang Xihang, et al. Path planning of single-wheeled robot based on improved dijkstra algorithm and model prediction [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2024(6): 18-23.
- [5] 赵倩,石宇强. 融合改进 A* 算法与 DWA 的 AGV 实时路径规划及避障研究[J]. 现代制造工程, 2025(5): 91-98.
Zhao Qian, Shi Yuqiang. Research on real time path planning and obstacle avoidance of AGV by integrating improved A* algorithm and DWA [J]. Modern Manufacturing Engineering, 2025 (5): 91-98.
- [6] 丁建军,梁甲杭,胡志明,等. 多向人工势场法引导的 RRT-connect 路径规划算法研究[J]. 机电工程, 2026, 43(3): 499-513.
Ding Jianjun, Liang Jiahang, Hu Zhiming, et al. RRT-Connect path planning algorithm guided by multi-directional artificial potential field [J]. Journal of Mechanical & Electrical Engineering, 2026, 43(3): 499-513.
- [7] 陈小龙,李明智,张橙橙,等. 基于多策略改进 RRT 算法的无人船路径规划[J]. 舰船科学技术, 2026, 48(4): 155-161.
Chen Xiaolong, Li Mingzhi, Zhang Chengcheng, et al. Unmanned vessel path planning based on multi-strategy improved RRT algorithm [J]. Ship Science and Technology, 2026, 48(4): 155-161.
- [8] 景会成,张冰珂,张靖轩,等. 基于改进粒子群算法的焊接机械臂轨迹规划方法[J]. 现代制造工程, 2025(6): 67-72.
Jing Huicheng, Zhang Bingke, Zhang Jingxuan, et al. Welding robot arm trajectory planning method based on improved particle swarm algorithm [J]. Modern Manufacturing Engineering, 2025 (6): 67-72.
- [9] 杨宇鸽,郝杨杨,王逸文. 基于威布尔飞行和警戒机制的沙猫群优化算法及应用[J]. 计算机工程与应用, 2025, 61(2): 145-157.
Yang Yuge, Hao Yangyang, Wang Yiwen. Sand cat swarm optimization algorithm based on weibull flight and warning mechanism and its application [J]. Computer Engineering and Applications, 2025, 61(2): 145-157.
- [10] 杨红,李生明. 改进黏菌优化的移动自导引机器人路径规划控制算法[J]. 机械设计与研究, 2025, 41(3): 359-366.
Yang Hong, Li Shengming. A path planning control algorithm for mobile self-guided robots based on improved slime mold optimization [J]. Machine Design & Research, 2025, 41(3): 359-366.
- [11] 欧阳鹏,邝先验,叶景贞. 基于改进天牛群算法和三次样条插值的路径规划[J]. 电子测量与仪器学报, 2025, 39(7): 259-268.
Ouyang Peng, Kuang Xianyan, Ye Jingzhen. Path planning based on improved beetle swarm optimization algorithm and cubic spline interpolation [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(7): 259-268.
- [12] 韩涛,李婷婷,黄友锐. 基于改进河马算法的农业无人机路径规划[J]. 农业机械学报, 2026, 57(1): 339-347.
Han Tao, Li Tingting, Huang Yourui. Agricultural UAV path planning based on improved hippopotamus optimization algorithm [J]. Transactions of the Chinese Society for Agricultural Machinery, 2026, 57(1): 339-347.
- [13] 原慧琳,王霄,白嘉鑫,等. 多策略改进角蜥蜴优化算法的避障路径规划[J]. 组合机床与自动化加工技术, 2025(7): 10-14, 19.
Yuan Huilin, Wang Xiao, Bai Jiaxin, et al. Obstacle avoidance path planning based on multi strategy improvement of horned lizard optimization algorithm [J]. Modular Machine Tool & Automatic Manufacturing Technique, 2025(7): 10-14, 19.
- [14] 黄开启,许军. 多策略改进鲸鱼优化算法的移动机器人路径规划[J]. 传感器与微系统, 2025, 44(7): 121-125.
Huang Kaiqi, Xu Jun. Multi-strategy improved whale optimization algorithm for mobile robot path planning [J]. Transducer and Microsystem Technologies, 2025, 44(7): 121-125.
- [15] Xiao Y N, Cui H, Abu Khurma R, 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.
- [16] 赵聪,杨定邦,汤可宗. 融合拉丁超立方采样的改进麻雀搜索算法[J]. 福建电脑, 2025, 41(8): 1-7.
Zhao Cong, Yang Dingbang, Tang Kezong. Improved sparrow search algorithm fused with Latin hypercube sampling [J]. Journal of Fujian Computer, 2025, 41(8): 1-7.
- [17] Zhu Y W, Huang H S, Wei J N, et al. ISO: an improved snake optimizer with multi-strategy enhancement for engineering optimization [J]. Expert Systems with Applications, 2025, 281: 127660.
- [18] Dehghani M, Montazeri Z, Trojovská E, et al. Coati Optimization Algorithm: a new bio-inspired metaheuristic algorithm for solving optimization problems [J]. Knowledge-Based Systems, 2023, 259: 110011.

Robot path planning method based on a multi-strategy improved artificial lemming optimization algorithm

HOU Juntao¹ QIAN Lu² CAO Jingjing² ZHAO Qiangwei²

(1. China Railway Liuyuan Group Co., Ltd., Tianjin 30000, China)

(2. School of Transportation and Logistics Engineering, Wuhan University of Technology, Wuhan 430063, China)

Abstract: [Objective] To address the issues of uneven initial population distribution, susceptibility to local optima, and insufficient directionality in local exploration within traditional artificial lemming algorithm (ALA) for mobile robot path planning, a multi-strategy improved artificial lemming algorithm (IALA) was proposed in this paper. [Methods] Firstly, Latin hypercube sampling was employed to initialize the population, enhancing the quality of global exploration starting points. Secondly, an anti-predation strategy was introduced during the exploration phase. Embedded after the algorithm's long-distance migration and burrowing behaviors, it forces individuals to deviate from current local optima, expanding the search scope. Finally, a raccoon tree-climbing strategy was proposed for the exploitation phase. This strategy combines the linear advancement update method from the raccoon optimization algorithm with Lévy flight, enhancing the algorithm's directional advancement capability and convergence robustness in the mid-to-late stages. To validate the proposed algorithm's effectiveness, experiments were conducted using six standard test functions and two sets of grid maps. [Results] Test results demonstrate that IALA achieves superior optimization accuracy and stability compared to the comparison algorithms. In path planning tests on 20×20 and 40×40 grid maps, its optimal path lengths were reduced by 1.17 and 3.82 units, respectively, compared to the standard lemming optimization algorithm. Additionally, IALA exhibited smaller standard deviations and smoother paths, validating its stability and reliability.

Key words: Artificial lemmings optimization algorithm; Path planning; Latin hypercube sampling; Anti-predation strategy; Raccoon tree-climbing strategy

(编辑: 刘欢欢)