

DOI:10.19344/j.cnki.issn1671-5276.2026.01.043

基于螺旋觅食 DBO 算法的轮式巡检机器人路径避障

段晓亮,付丽琴,陈慧敏

(北京经济管理职业学院 人工智能学院,北京 100102)

摘要:为了解决常规轮式机器人路径避障规划方法容易出现收敛慢、易得局部最优及路径平滑性差的不足,提出一种基于螺旋觅食蛱蝶优化算法的机器人路径规划方法。引入 PWLCM 混沌映射与精英随机对立学习种群初始化、权重因子非线性递减、结合黏菌优化算法的螺旋觅食及 t 分布变异对算法搜索性能进行改进。以栅格地图为基础构建路径规划模型,兼顾路径长度及其平滑性设计评估个体搜索质量的适应度函数,并利用改进蛱蝶优化算法对最优路径迭代寻优。结果表明:改进算法路径长度更短且平滑性更好,求解效率更高,能有效解决轮式机器人路径规划问题。

关键词:轮式机器人;路径规划;蛱蝶优化算法; t 分布;对立学习

中图分类号:TP242 **文献标志码:**A **文章编号:**1671-5276(2026)01-0229-07

Path Obstacle Avoidance of Wheeled Inspection Robot Based on Spiral-feeding DBO Algorithm

DUAN Xiaoliang, FU Liqin, CHEN Huimin

(School of Artificial Intelligence, Beijing Institute of Economics and Management, Beijing 100102, China)

Abstract: To overcome the shortcomings of conventional path planning methods for wheeled robots, such as slow convergence, easy local optimization and poor path smoothness, a robot path planning method based on spiral-feeding dung beetle optimization algorithm was proposed. PWLCM chaotic mapping and elite random opposition-based learning for population initialization and nonlinear decreasing weight factor were introduced, and by combining slime mold optimization algorithm's spiral feeding and t -distribution mutation, the algorithm's search performance was improved. Based on raster map, the robot path planning model was constructed, and the fitness function was designed to evaluate the individual search quality of the population considering the path length and path smoothness, and the optimal path was iteratively optimized by the improved dung beetle optimization algorithm. The results show that the improved algorithm has shorter path length, better smoothness and higher solving efficiency, and can effectively solve the path planning problem of wheeled robots.

Keywords: wheeled robot; path plan; dung beetle optimization algorithm; t -distribution; opposite-learning

0 引言

轮式巡检机器人已成功应用在灾害探测、物流货运、军事作战和医疗保健等众多领域,且其具有重要的研究意义^[1]。路径避障规划是轮式机器人导航控制的关键环节,也是机器人智能化程度的体现;其本质是根据预设条件,在起点和终点间搜索一条安全避障的最短路径^[2]。目前,机器人路径规划方法分为两类,一类是人工势场法^[3]、A*算法^[4]、Voronoi 图法^[5]、可视图法^[6]等传统算法。另一类是基于生物启发式的智能优化算法。此类算法模拟了自然界种群的社会行为,具有启发式搜索机制。传统方法在处理场景规模及障碍物复杂分布场景下的路径规划体现搜索效率和搜

索精度的不足,从而使得智能优化算法逐渐显现优势。目前,蚁群优化算法(ACO)^[7]、遗传算法(GA)^[8]、粒子群优化算法(PSO)^[9]、灰狼算法(GWO)^[10]、乌燕鸥算法、鲸鱼算法(WOA)^[11]等都在路径规划上有所应用,但以上算法易于收敛局部最优,其全局搜索精度还有待提升。

蛱蝶优化算法(DBO)是一种新型元启发式算法^[12]。不同于传统灰狼优化算法和粒子群优化算法,BO 将种群划分为不同群体进行不同任务分工,在基准函数上搜索目标时具有比传统算法更高的搜索精度和更快的收敛速度。其性能已在特征选择^[13]、节点定位^[14-15]、 workflow 调度^[16]、电机参数辨识^[17]、故障诊断^[18]等领域得到有效验证。本文将设计一种基于螺旋觅食改进的蛱蝶

基金项目:北京市教育教学改革研究项目(2022077);北京经济管理职业学院博士资助项目(20BSA03)

第一作者简介:段晓亮(1981—),男,山西晋中人,讲师,博士,研究方向为智能机器人、图像识别, better_most@ sina.com。

优化算法(SFDBO),同时以栅格地图为基础构建机器人路径规划模型,利用改进蜣螂优化算法对最优路径迭代寻优。

1 机器人路径规划避障模型

1.1 基于栅格地图的机器人路径避障规划

利用栅格地图建立移动机器人的路径规模环境。以矩阵 C_{ij} 表示栅格地图, $i, j=1, 2, \dots, n$, 栅格规模为 $n \times n$ 。若矩阵元素 $C_{ij}=0$, 表示机器人可通行栅格; 若 $C_{ij}=1$, 表示障碍物栅格, 机器人通行会与障碍物发生碰撞。将栅格地图进行如图 1 所示的编号, 可知栅格序号与其坐标的映射关系为

$$\begin{cases} x_i = \begin{cases} a[\text{mod}(i, N_x) - a/2], & \text{mod}(i, N_x) \neq 0 \\ N_x - a/2, & \text{mod}(i, N_x) = 0 \end{cases} \\ y_i = a[\lceil (i/N_y) \rceil - a/2] \end{cases} \quad (1)$$

式中: N_x, N_y 为对应栅格的行号和列号; (x_i, y_i) 为栅格坐标; a 为栅格边长。图 1(a) 为 6×6 栅格地图, 黑色栅格为障碍物栅格; 图 1(b) 为地图二维矩阵编码。规定机器人在栅格地图内的移动方向为八向移动(本刊为黑白印刷, 相关疑问请咨询作者)。




图 1 栅格地图及地图编码

1.2 路径规划目标

路径长度定义为

$$d_{is} = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (2)$$

式中 (x_i, y_i) 、 (x_{i+1}, y_{i+1}) 分别为对应栅格单元 P_i 、 P_{i+1} 的坐标。

则路径总长度为

$$L_{\text{length}} = \sum_{k=0}^{d_{\text{im}}-1} d_{is,k} \quad (3)$$

式中 d_{im} 为经过栅格单元的总数。

路径平滑性。令两段相邻路径的夹角为 θ , 根据转角大小, 设置平滑性为

$$\zeta = \begin{cases} \sigma_1, & \theta = 45^\circ \\ \sigma_2, & \theta = 90^\circ \\ \sigma_3, & \theta = 135^\circ \\ \sigma_4, & \theta = 180^\circ \end{cases} \quad (4)$$

式中 σ_i 为相应平滑度奖励值, $i=1, 2, 3, 4$ 。

则整个路径平滑性为

$$S_{\text{smooth}} = \sum_{i=1}^{d_{\text{im}}-2} \zeta_i \quad (5)$$

路径规划目标函数以权重形式定义为

$$\text{fit} = w_1 \times L_{\text{length}} + w_2 \times \frac{1}{S_{\text{smooth}}} \quad (6)$$

式中 w_1, w_2 为路径长度和路径平滑性的权重系数, $w_1 + w_2 = 1, 0 < w_1, w_2 < 1$ 。

2 蜣螂优化算法

1) 滚球蜣螂

滚球蜣螂的位置更新方式为

$$\begin{cases} x_i(t+1) = x_i(t) + \alpha \times k \times x_i(t-1) + b \times \Delta x \\ \Delta x = |x_i(t) - X_w| \end{cases} \quad (7)$$

式中: $x_i(t)$ 为 t 次迭代的个体位置; $x_i(t+1)$ 为个体的新位置; α 为自然系数, 等于 -1 或 1 ; $b \in (0, 1)$ 为随机数, 取 0.3 ; $k \in (0, 0.2]$ 为偏转系数; X_w 为种群最差解; Δx 为个体位置与最差位置的间距。

当蜣螂滚球时遭遇障碍物时, 位置更新方式为

$$x_i(t+1) = x_i(t) + \tan\theta |x_i(t) - x_i(t-1)| \quad (8)$$

式中 θ 为偏转角, $\theta \in [0, \pi]$, 即算法以切线函数模拟跳舞行为, 且 $\theta = 0, \pi/2, \pi$ 时, 个体位置不更新。

2) 繁殖蜣螂

DBO 设计了一种边界选择策略模拟雌性蜣螂的产卵区域, 定义为

$$\begin{cases} L_b^* = \max(X_b \times (1-R), L_b) \\ U_b^* = \min(X_b \times (1+R), U_b) \end{cases} \quad (9)$$

式中: X_b 为种群最优位置; L_b, U_b 为最优搜索下界、上界; L_b^*, U_b^* 为产卵区域下界、上界; 权重因子 $R = 1 - t/T_{\text{max}}$, T_{max} 为最大迭代次数。

产卵区域是随着算法迭代次数而动态变化的, 位置更新方式为

$$B_i(t+1) = X_b + b_1 \times (B_i(t) - L_b^*) + b_2 \times (B_i(t) - U_b^*) \quad (10)$$

式中: $B_i(t)$ 为卵球位置; b_1, b_2 为独立随机 $1 \times D$ 向量; D 为维度。

3) 觅食蜣螂

成熟蜣螂孵化后会组群觅食, 最优觅食区域为

$$\begin{cases} L_{b,f} = \max[X_b \times (1-R), L_b] \\ U_{b,f} = \min[X_b \times (1+R), U_b] \end{cases} \quad (11)$$

式中: $L_{b,f}$ 、 $U_{b,f}$ 为最优觅食区域下界、上界。蜣螂位置更新方式为

$$x_i(t+1) = x_i(t) + c_1 \times [x_i(t) - L_{b,f}] + c_2 \times [x_i(t) - U_{b,f}] \quad (12)$$

式中 c_1 、 $c_2 \sim N(0,1)$ 均为随机数。

4) 偷窃蜣螂

种群内部分蜣螂还会实施偷盗,围绕最佳觅食位置 X_b 从其他蜣螂处偷粪球。其位置更新方式为

$$x_i(t+1) = X_b + s \times g \times |x_i(t) - X_b| + |x_i(t) - X_b| \quad (13)$$

式中: X_b 为种群最优位置,表示食物源位置; g 为服从正态分布的 $1 \times D$ 随机矢量; s 为常量,且 $s=0.5$ 。

3 螺旋觅食改进蜣螂优化算法

3.1 策略一: PWLCM 混沌与精英随机对立学习

DBO 对于目标位置没有先验认识,其初始种群随机生成,这不能保证个体均匀分布及对解空间的遍历性。混沌映射具有更好的遍历性,是目标空间搜索的常用方法^[19]。PWLCM 映射是一种基于分段模型的线性混沌映射系统,比较 Logistic、Cubic 混沌映射方式,其具有更好的均匀分布和收敛快的优势。PWLCM 映射方式为

$$z(t+1) = f(z(t), \mu) = \begin{cases} \frac{z(t)}{\mu}, & 0 \leq z(t) \leq \mu \\ \frac{z(t) - \mu}{0.5 - \mu}, & \mu \leq z(t) \leq 0.5 \\ 0, & z(t) = 0.5 \\ f(1 - z(t), \mu), & 0.5 \leq z(t) < 1 \end{cases} \quad (14)$$

式中: μ 为混沌因子,且 $\mu \in (0, 0.5)$; $z(t) \in [0, 1]$ 。

本文利用 PWLCM 映射进行种群初始化,定义种群初始位置生成方式为

$$x_i = L_b + (U_b - L_b) \times z(i) \quad (15)$$

经过 PWLCM 混沌映射生成初始种群后,利用精英随机对立学习^[20]继续优化初始种群结构,提高解的质量。随机对立学习精英个体定义为

$$X' = (L_b + U_b) \cdot R_{\text{and}} - X \quad (16)$$

式中: X 为个体原位置; X' 为 X 的对立位置; R_{and} 为 $(0, 1)$ 间随机数。

3.2 策略二: 非线性蜣螂繁殖策略

DBO 的蜣螂繁殖阶段, R 决定了蜣螂的产卵区域和最佳觅食区域。迭代前期, R 较大,利于扩大全局搜索;迭代后期, R 较小,逐步收缩产卵和觅食区域,便于精细开采。然而,当因子 R 以相同

斜率线性递减时,无法适应种群目标搜索的规律。为了使算法更好地维系搜索范围与开发力度间的均衡性,将权重因子 R 进行非线性改进,定义为

$$R(t) = \frac{\arcsin 2(2t/T_{\text{max}} - 1)}{\pi} \quad (17)$$

3.3 策略三: 螺旋觅食机制

DBO 中,蜣螂觅食行为以最优觅食区域为导向,这种方式容易导致种群在短时间内连续汇聚,削弱种群多样性,生成早熟解。黏菌优化算法(SMA)^[21]在搜索目标位置时利用了黏菌静脉宽度随食物浓度情况变化的方式指引种群搜索区域,具有更强的全局搜索能力。本文引入 SMA 的搜索策略,同步利用改进螺旋搜索算子提升蜣螂对食物源的搜索精度。改进后,觅食蜣螂位置更新公式为

$$x_i(t+1) = x_i(t) + r_{\text{ot}}(v) \times c_1 \times (W \times x_i(t) - L_{b,f}) + r_{\text{ot}}(v) \times c_2 \times (W \times x_i(t) - U_{b,f}) \quad (18)$$

式中 $r_{\text{ot}}(v)$ 为螺旋搜索算子。

3.4 策略四: t 分布扰动变异

DBO 迭代时,种群搜索将受适应度最优的精英个体 X_b 牵引,逐步汇聚于最优解邻域,容易导致多样性缺失带来的局部最优解。为此,SFDBO 引入一种针对精英个体的 t 分布变异策略。

t 分布^[22]的概率密度函数为

$$p_t(x) = \frac{\Gamma\left(\frac{m+1}{2}\right)}{\sqrt{m\pi} \times \Gamma\left(\frac{m}{2}\right)} \times \left(1 + \frac{x^2}{m}\right)^{-\frac{m+1}{2}}, \quad -\infty < x < \infty \quad (19)$$

式中 $\Gamma\left(\frac{m+1}{2}\right) = \int_0^{+\infty} x^{\frac{m+1}{2}-1} e^{-x} dx$, 为第二型欧拉积分。对于 t 分布而言,当自由度参数 $m=1$ 时, $t(m=1) = C(0, 1)$, $C(0, 1)$ 为 $(0, 1)$ 柯西分布^[23], 即 t 分布为柯西分布;当 m 趋于 ∞ 时, $t(m \rightarrow \infty) \rightarrow N(0, 1)$, 此时 t 分布为高斯分布。

为避免 DBO 陷入局部最优,将 t 分布引入改进算法,生成新解方式定义为

$$X_i^* = X_i + X_i \times t(T) \quad (20)$$

式中: X_i 为变异前位置; X_i^* 为变异后位置; $T(t)$ 为以迭代次数 T 为自由度的 t 分布变异算子。

4 基准函数测试

4.1 实验设置

本节利用基准函数对改进算法进行数值分析

实验,函数说明如表 1 所示, $F1—F3$ 为高维单峰函数,其特征是仅有唯一全局最优解, $F4—F6$ 为高维多峰函数,其特征是存在多个局部最优解。实验选取 PSO、GWO、WOA、DBO 与本文提出的 SFDBO 进行对比。算法的公共参数设置方面,最

大迭代次数设置为 500,种群规模统一为 30。SFDBO 中 $b=0.3, k=0.1, s=0.5, \mu=0.3$ 。实验结果统计所有算法独立运行 20 次时所求解的目标函数最优解、平均值及标准差,以此避免算法寻优过程中偶然性导致的搜索偏差。

表 1 基准函数

基准函数	函数表达式	搜索维度	搜索范围	全局最优解	函数类型
$F1$	$f(x) = \sum_{i=1}^d x_i^2$	30	$[-100, 100]$	0	高维单峰
$F2$	$f(x) = \sum_{i=1}^d [100(x_{i+1} - x_i^2)^2 + (x_i - 1)]$	30	$[-30, 30]$	0	高维单峰
$F3$	$f(x) = \sum_{i=1}^d x_i + \prod_{i=1}^d x_i $	30	$[-10, 10]$	0	高维单峰
$F4$	$f(x) = -20 \exp\left(-0.2 \sqrt{\frac{1}{d} \sum_{i=1}^d x_i^2}\right) - \exp\left(\frac{1}{d} \sum_{i=1}^d \cos(2\pi x_i)\right) + 20 + e$	30	$[-500, 500]$	0	高维多峰
$F5$	$f(x) = \sum_{i=1}^d [x_i^2 - 10 \cos(2\pi x_i) + 10]$	30	$[-32, 32]$	0	高维多峰
$F6$	$f(x) = \frac{1}{4000} \sum_{i=1}^d x_i^2 - \prod_{i=1}^d \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	30	$[-600, 600]$	0	高维多峰

4.2 寻优结果分析

表 2 给出了算法在基准函数上的搜索结果。对于 $F1、F2$,仅 SFDBO 寻得最优解,平均值、标准差也均为 0,稳定性更强。对于 $F3$,SFDBO 未找到理最优解,但其搜索精度最高,标准差指标也更小,表现更加稳定。对于 $F4$,仅有 SFDBO 和 DBO 搜索精度较高,GWO、WOA 低 3~5 个数量级,而 PSO 搜索精度离最优解相差较远。对于 $F5$,SFDBO 与 DBO、GWO、WOA 均有机会搜索到最优解,最优精度基本一致,但均值和标准差优于 WOA 和 PSO。对于 $F6$,SFDBO 可以稳定搜索到最优解,WOA、GWO 和 DBO 有机会搜索到最优解,但结果不稳定。以上结果反映出在处理高维单峰、高维多峰以及固维多峰函数上,SFDBO 的求解能力均得到了有效验证,其对目标解的全局搜索能力更强。

表 2 寻优结果

函数	算法	最优解	平均值	标准差
$F1$	PSO	1.23×10^{-28}	2.25×10^{-27}	5.15×10^{-27}
	WOA	9.26×10^{-86}	1.01×10^{-73}	3.77×10^{-73}
	GWO	1.19×10^{-179}	1.64×10^{-58}	5.08×10^{-58}
	DBO	7.84×10^{-160}	4.95×10^{-125}	1.61×10^{-124}
	SFDBO	0.00	0.00	0.00

续表2

函数	算法	最优解	平均值	标准差
$F2$	PSO	2.48×10^{-17}	7.15×10^{-17}	6.35×10^{-17}
	WOA	9.04×10^{-56}	1.04×10^{-51}	3.79×10^{-51}
	GWO	5.46×10^{-66}	2.11×10^{-31}	7.92×10^{-31}
	DBO	9.98×10^{-74}	3.34×10^{-60}	1.34×10^{-59}
	SFDBO	0.00	0.00	0.00
$F3$	PSO	8.05×10^{-4}	2.85×10^{-3}	9.27×10^{-4}
	WOA	4.61×10^{-4}	2.28×10^{-3}	3.05×10^{-3}
	GWO	4.32×10^{-5}	1.05×10^{-3}	1.32×10^{-3}
	DBO	3.18×10^{-5}	8.44×10^{-4}	7.16×10^{-4}
	SFDBO	4.46×10^{-6}	1.33×10^{-4}	9.58×10^{-5}
$F4$	PSO	4.35×10^{-2}	3.47×10^{-1}	3.46×10^{-1}
	WOA	3.11×10^{-11}	4.08×10^{-11}	1.28×10^{-11}
	GWO	2.35×10^{-11}	5.46×10^{-11}	3.54×10^{-11}
	DBO	6.55×10^{-14}	9.82×10^{-14}	5.19×10^{-14}
	SFDBO	4.62×10^{-16}	7.17×10^{-16}	9.64×10^{-16}
$F5$	PSO	69.30	112.01	20.18
	WOA	0.00	2.12	3.24
	GWO	0.00	9.37×10^{-15}	2.64×10^{-14}
	DBO	0.00	0.00	0.00
	SFDBO	0.00	0.00	0.00
$F6$	PSO	2.00	3.09	0.58
	WOA	0.00	5.74×10^{-3}	1.16×10^{-2}
	GWO	0.00	6.65×10^{-3}	3.61×10^{-2}
	DBO	0.00	3.38×10^{-2}	1.92×10^{-1}
	SFDBO	0.00	0.00	0.00

5 基于 SFDBO 的路径规划过程

1) 初始化参数:种群规模 N 、最大迭代数 $T_{\max}$ 、搜索边界 $[L_b, U_b]$ 和搜索维度 d_{im} 。

2) 建立栅格地图模型。对种群个体编码,表示为 $X_i = \{x_{i,1}, x_{i,2}, \dots, x_{i,d_{\text{im}}}\}, i \in [1, N], d_{\text{im}}$ 为路径节点数;同时设置机器人的起点和终点。

3) 利用 PWLCM 混沌与精英随机对立学习生成 N 条初始可行路径 $X_1, X_2, \dots, X_N$ 。

4) 根据式(6)计算个体适应度,保存最优路径。

5) 蜣螂滚球策略:若 $[0, 1]$ 随机量 $r < 0.9$, 根据式(7)更新路径解;否则,根据式(8)更新路径解。

6) 根据式(17)更新因子 R 。

7) 蜣螂繁殖策略为根据式(10)更新路径解;蜣螂觅食策略为根据式(18)更新路径解;蜣螂偷窃策略为根据式(13)更新路径解。

8) 重新计算个体适应度,并择优保留。

9) 根据 t 分布变异机制对精英个体进行变异扰动。

10) 对个体位置作越界判断,以搜索空间边界值修正个体位置。

11) 判断迭代终止条件,若满足,返回步骤 4;否则,返回最优解,算法终止。

6 仿真实验

设置算法种群规模 $N = 30$, 最大迭代次数 $T_{\max} = 500, \sigma_4 = 100, \sigma_3 = 50, \sigma_2 = 20, \sigma_1 = 5$, 适应度函数中权重 $w_1 = 0.6, w_2 = 0.4$ 。为了验证算法的可

行性及性能优势,设置不同规模及障碍物不同分布和不同复杂度的栅格地图开展路径规划的验证实验。

实验 1 构造 20×20 的栅格地图,模拟小型室内场景条件下障碍物稀疏、且不规则分布的地图。机器人起点在栅格单元 $(1, 1)$, 终点在栅格单元 $(20, 20)$ 。该场景中障碍物栅格占比约为总栅格单元数的 15%。图 2 所示为路径规划结果及搜索最优路径的收敛曲线。根据结果可知,PSO 明显全局搜索能力不足,迭代后期开采能力欠缺,算法最快收敛至局部最优路径,且后期无法跳离局部最优解。WOA 与 PSO 同样最早陷入局部最优。GWO 的收敛精度优于 PSO 和 WOA,收敛速度慢于这两种算法。DBO 的收敛精度优于以上 3 种算法,收敛速度与 GWO 相当。SFDBO 综合改进更优,初始路径在所有算法中最短,表明其生成的初始路径更短,其混沌机制对初始种群的改进有效。SFDBO 的收敛速度与 PSO、WOA 相当,但其收敛处路径长度最短,算法的整体收敛性和精度有所提升。

表 3 统计了简单场景中路径长度最优解、长度平均值和标准差、迭代平均数、路径最优拐点数及拐点平均数以及算法平均运行时间。在路径长度最优解上, SFDBO 相比 DBO、WOA、GWO 和 PSO 分别可以降低 6.31%、16.37%、14.13%、16.37%。同时算法标准差更小,表明求解更加稳定。在路径最优拐点数上, SFDBO 相比 DBO、WOA、GWO 和 PSO 分别可以减少 5 个、6 个、4 个、6 个。而在算法运行时间上, SFDBO 也保持了更高的搜索效率。




图 2 实验 1 路径规划结果及收敛曲线

表 3 小规模地图场景下的统计数据

算法	路径长度最优解/m	路径长度平均值/m	标准差	迭代平均数	最优拐点数	拐点平均数	平均运行时间/s
PSO	32.69	33.71	3.28	9	10	14.5	3.48
GWO	31.84	32.52	2.57	18	8	10.1	2.33
WOA	32.69	32.95	1.89	14	10	13.6	2.09
DBO	29.18	29.87	0.58	12	9	11.2	1.85
SFDBO	27.34	27.59	0.32	10	4	5.6	1.23

实验 2 构造 50×50 的栅格地图,模拟室外大型场景下障碍物无规则且密集分布的地图。起点在栅格单元(1,1),终点在栅格单元(50,50)。该场景中障碍物栅格占比约为总栅格单元数的 40%,因此可行路径相对更少,更加考验算法的全局搜索能力。图 3 所示为路径规划结果及各算法搜索最优路径的收敛曲线。可见,SFDBO 面对复杂的障碍物场景依然展现出较强的搜索能力,能有效减小规划路径长度,其路径平滑性更好,直线路径居多,所以拐点更少。迭代曲线上看,SFDBO 的初始路径长度依然最短,初始种群构造质量更高。PSO 依然收敛最快,但结果是局部最优路径。

WOA 收敛与 PSO 相近,收敛速度略慢于 PSO。GWO 约在 23 次迭代时收敛,精度略优于以上两种算法。DBO 全局搜索能力略有不足,但收敛精度有明显提升。SFDBO 收敛速度慢于 PSO 约 5 次迭代,但其收敛最高,路径长度最短。

表 4 为统计场景 2 中路径长度最优解、长度均值和标准差、路径最优拐点数及拐点平均数表现。路径长度最优解上,SFDBO 相比 DBO、WOA、GWO 和 PSO 分别可以降低 8.58%、14.69%、11.04%、14.77%。可见,在地图场景规模变大且变得更加复杂后,改进算法性能优势得到了进一步提升。




图 3 实验 2 路径规划结果及收敛曲线

表 4 大规模地图场景下的统计数据

算法	路径长度最优解/m	路径长度平均值/m	标准差	迭代平均数	最优拐点数	拐点平均数	平均运行时间/s
PSO	85.94	88.17	4.54	18	27	30.7	14.11
GWO	82.34	87.49	3.38	25	25	29.6	13.07
WOA	85.86	87.32	2.64	23	24	28.4	10.89
DBO	80.12	81.64	2.07	18	23	25.8	6.35
SFDBO	73.25	75.09	1.85	14	22	25.1	5.12

7 结语

本文提出了一种基于螺旋觅食蜣螂优化算法的轮式机器人路径规划方法,以此解决常规路径规划易得局部最优路径的不足。为了提升算法搜索能力,设计 PWLCM 混沌映射与精英对立学习结合的种群初始化方法、权重因子非线性递减、黏菌优化算法的螺旋觅食机制及 t 分布变异提升算法搜索性能。结果表明:改进算法在解决轮式机器人导航路径控制问题上有效可行,生成路径长度更短,路径平滑性也更优。

参考文献:

- [1] 陶树林,刘祚时,唐雨. 基于SLAM 物流移动机器人导航技术研究[J]. 机电工程技术, 2024, 53(6): 100-104.
- [2] 刘尚俊男,刘书海,肖华平. 改进灰狼算法的移动充电机器人路径规划[J]. 现代制造工程, 2024(4): 49-56.
- [3] 倪建云,杜合磊,谷海青,等. 改进人工势场法的移动机器人路径规划研究[J]. 重庆理工大学学报(自然科学), 2023, 37(11): 247-256.
- [4] 石英托,陈华,张连新,等. 基于改进 A^* 算法的 AGV 转运机器人路径规划研究[J]. 制造技术与机床, 2022(5): 19-22.
- [5] 黄莲花,李光明. 基于 Voronoi 图和快速行进的移动机器人导航路径规划[J]. 机械设计与制造, 2023(11): 87-92.
- [6] 黄荣杰,王亚刚. 基于可视图与改进遗传算法的机器人平滑路径规划[J]. 控制工程, 2024, 31(4): 678-686.
- [7] XIE X L, YAN Z X, ZHANG Z H, et al. Hybrid genetic ant colony optimization algorithm for full-coverage path planning of gardening pruning robots [J]. Intelligent Service Robotics, 2024, 17(3): 661-683.
- [8] MA K K, WANG L, CAI J C, et al. Robot path planning using fusion algorithm of ant colony optimization and genetic algorithm[J]. International Journal of Modeling, Simulation, and Scientific Computing, 2023, 14(6): 2341032.
- [9] JIA L X, LI J J, NI H J, et al. Autonomous mobile robot global path planning: a prior information-based particle swarm optimization approach [J]. Control Theory and Technology, 2023, 21(2): 173-189.
- [10] OU Y, YIN P F, MO L P. An improved grey wolf optimizer and its application in robot path planning [J]. Biomimetics, 2023, 8(1): 84.
- [11] SI Q, LI C Y. Indoor robot path planning using an improved whale optimization algorithm [J]. Sensors, 2023, 23(8): 3988.
- [12] XUE J K, SHEN B. Dung beetle optimizer: a new meta-heuristic algorithm for global optimization [J]. The Journal of Supercomputing, 2023, 79(7): 7305-7336.
- [13] 李珺,徐秦. 面向特征选择任务的改进蜣螂优化算法[J]. 电子测量技术, 2024, 47(1): 79-86.
- [14] 彭铎,陈江旭,张倩,等. 多策略改进的蜣螂搜索算法优化 3DDV-Hop 节点定位[J]. 重庆邮电大学学报(自然科学版), 2024, 36(3): 438-449.
- [15] 潘志远,卜凡亮. 基于蜣螂算法优化的 DV-Hop 定位算法[J]. 电子测量与仪器学报, 2023, 37(7): 33-41.
- [16] 吴宏伟,江凌云. IIoT 环境下基于蜣螂优化的雾工作流调度算法[J]. 计算机工程与应用, 2024(6): 1-15.
- [17] 赵强,王昊洁,谢春丽. 基于改进蜣螂优化算法的永磁同步电机参数辨识[J]. 重庆交通大学学报(自然科学版), 2024, 43(6): 102-108.
- [18] 赵鑫,王东丽,彭泓,等. 基于多策略改进蜣螂算法优化的变压器故障诊断[J]. 电力系统保护与控制, 2024, 52(6): 120-130.
- [19] 田博文,朱姿娜,刘瑞,等. 基于混沌映射和差分进化的改进蜻蜓算法[J]. 上海工程技术大学学报, 2024, 38(3): 341-348.
- [20] 杨淼. 混沌与对立学习正余弦算法及多阈值图像分割[J]. 计算机工程与设计, 2022, 43(11): 3177-3186.
- [21] LI S M, CHEN H L, WANG M J, et al. Slime mould algorithm: a new method for stochastic optimization [J]. Future Generation Computer Systems, 2020, 111: 300-323.
- [22] 张莲,贾浩,张尚德,等. 融合自适应 t 分布和随机游走策略的松鼠优化算法的研究[J]. 计算机与数字工程, 2024, 52(8): 2343-2347, 2410.
- [23] 吴辰文,王莎莎,曹雪同. 结合柯西分布和蚁狮算法改进的模糊聚类算法[J]. 计算机工程与应用, 2023, 59(17): 91-98.

收稿日期: 2025-03-24