

Journal of System Simulation

Volume 36 | Issue 5

Article 4

5-15-2024

Research on Path Planning of Warehouse Robot with Improved Harris Hawks Algorithm

Xu Lei

School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China, xulei@chd.edu.cn

Jingyi Chen

School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China

Xiaoyang Chen

School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>

 Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation. For more information, please contact xtfzxb@126.com.

Research on Path Planning of Warehouse Robot with Improved Harris Hawks Algorithm

Abstract

Abstract: To improve the path planning efficiency of warehouse mobile robots in static environments, and to solve the problems of slow convergence and local optimum of traditional Harris Hawk (HHO) algorithm in path planning, a Harris Hawk optimization algorithm based on Tent chaotic mapping fused with Cauchy's back-learning variant (TCLHHO) is proposed. The population diversity is increased by Tent Chaotic mapping to speed up convergence. An exponential prey escape energy updating strategy is proposed to balance the global search and local exploitation capabilities of the algorithm. The optimal individual is disturbed by Cauchy mutation operator and inverse learning strategy to expand the search range and enhance the global optimization capability. A two-dimensional grid mapping model is built according to the warehousing environment, and a comparison simulation experiment is carried out with Matlab. The results showed that the proposed algorithm had a better performance in planning speed, path length and number of turning points compared with other algorithms, which verifies the feasibility and robustness of the improved HHO algorithm for path planning in the intelligent storage environment.

Keywords

mobile robots, path planning, Harris Hawks optimization(HHO) algorithm, grid maps, multistrategy improvement

Recommended Citation

Lei Xu, Chen Jingyi, Chen Xiaoyang. Research on Path Planning of Warehouse Robot with Improved Harris Hawks Algorithm[J]. Journal of System Simulation, 2024, 36(5): 1081-1092.

改进哈里斯鹰算法的仓储机器人路径规划研究

雷旭, 陈静夷, 陈潇阳

(长安大学 电子与控制工程学院, 陕西 西安 710064)

摘要: 为提高静态环境下仓储移动机器人路径规划效率, 解决传统哈里斯鹰(Harris Hawks optimization, HHO)算法在路径规划中存在收敛速度慢且易陷入局部最优的问题, 提出了一种基于Tent混沌映射融合柯西反学习变异的哈里斯鹰优化算法(HHO algorithm based on Tent chaotic mapping hybrid Cauchy mutation and inverse learning, TCLHHO)。通过Tent混沌映射增加种群多样性, 以提高算法的收敛速度; 提出指数型的猎物逃逸能量更新策略, 以平衡算法的全局搜索和局部开发能力; 通过柯西反学习变异策略对最优个体进行扰动, 扩大算法的搜索范围, 增强全局搜索能力。根据真实仓储环境搭建二维栅格环境模型, 并在Matlab中进行仿真对比实验。结果表明: 该算法的规划速度、最优路径长度以及最优路径转折次数较对比算法具有较好的效果, 验证了应用于智能仓储环境下改进的HHO路径规划问题的可行性和鲁棒性。

关键词: 移动机器人; 路径规划; 哈里斯鹰优化算法; 栅格地图; 多策略改进

中图分类号: TP391.9; TP242 文献标志码: A 文章编号: 1004-731X(2024)05-1081-12

DOI: 10.16182/j.issn1004731x.joss.23-0024

引用格式: 雷旭, 陈静夷, 陈潇阳. 改进哈里斯鹰算法的仓储机器人路径规划研究[J]. 系统仿真学报, 2024, 36(5): 1081-1092.

Reference format: Lei Xu, Chen Jingyi, Chen Xiaoyang. Research on Path Planning of Warehouse Robot with Improved Harris Hawks Algorithm[J]. Journal of System Simulation, 2024, 36(5): 1081-1092.

Research on Path Planning of Warehouse Robot with Improved Harris Hawks Algorithm

Lei Xu, Chen Jingyi, Chen Xiaoyang

(School of Electronic and Control Engineering, Chang'an University, Xi'an 710064, China)

Abstract: To improve the path planning efficiency of warehouse mobile robots in static environments, and to solve the problems of slow convergence and local optimum of traditional Harris Hawk (HHO) algorithm in path planning, a Harris Hawk optimization algorithm based on Tent chaotic mapping fused with Cauchy's back-learning variant (TCLHHO) is proposed. The population diversity is increased by *Tent Chaotic mapping to speed up convergence*. An exponential prey escape energy updating strategy is proposed to balance the global search and local exploitation capabilities of the algorithm. The optimal individual is disturbed by Cauchy mutation operator and inverse learning strategy to expand the search range and enhance the global optimization capability. A two-dimensional grid mapping model is built according to the warehousing environment, and a comparison simulation experiment is carried out with Matlab. The results showed that the proposed algorithm had a better performance in planning speed, path length and number of turning points compared with other algorithms, which verifies the feasibility and robustness of the improved HHO algorithm for path planning in the intelligent storage environment.

Keywords: mobile robots; path planning; Harris Hawks optimization(HHO) algorithm; grid maps; multi-strategy improvement

收稿日期: 2023-01-06 修回日期: 2023-03-23

基金项目: 贵州省科技计划(211432200042)

第一作者: 雷旭(1981-), 男, 博士, 正高级工程师, 研究方向为移动机器人定位及路径规划。E-mail: xulei@chd.edu.cn

0 引言

随着电商物流的兴起，移动机器人已被大量研究并广泛应用于工业自动化和智能工厂领域。物流配送具有品种多、批量大、周期短的特点，传统的人工操作难以适应电子商务的发展，更高效的智能化仓库逐渐成为仓储作业发展的新方向，如何规划出快速节能的搬运路径是提升仓储作业优化的重要环节^[1]。移动机器人路径规划问题作为典型的工程问题，在提升机器人定位与建图精确度方面，存在很大的探索空间^[2]。国内外专家学者从不同角度进行了广泛研究，大致可以分为传统算法和仿生类智能算法两大类^[3]。传统算法如人工势场法、A*算法、Dijkstra算法等，对解决理想环境下的路径规划问题具有一定优势。但是人工势场法易受到外界环境的干扰，存在路径长度和拐点数目增加的问题^[4]；A*算法的实时性较差，并且由于路径节点数量的增加，使算法搜索效率低下^[5]；Dijkstra算法存在效率低、计算复杂度高等问题^[6]。这些传统算法的局限性容易导致移动机器人在路径规划中出现局部最优、算法实时性差等问题。而通过对自然界生物习性的观察，模拟群体成员之间的生物特性而提出的仿生算法降低了对数学模型的依赖，具有较强的全局寻优能力和适应能力^[7]。因此，相较传统路径规划算法，智能优化算法的高效性和鲁棒性更适合解决大规模路径规划问题。

目前，群体智能算法在路径规划领域得到了广泛的应用，较为普遍的是遗传算法、粒子群算法和蚁群算法等。采用遗传算法进行路径规划时，容易受到环境栅格大小的影响，造成最优路径较长且转折点较多、收敛速度慢等问题^[8]；粒子群算法在迭代前期收敛速度较快，但在后期易陷入局部最优，导致生成的路径不平滑，造成最优路径的转弯数量较多^[9]；蚁群算法在迭代前期搜索时过于随机，使得算法搜索效率较低，而在后期集中搜索时将造成算法停滞，因此，算法运行时间较长且不适合大型复杂地图^[10]。真实仓储环境规模

较大且货物摆放规则，针对仓储环境下的路径规划问题，研究机器人快速有效地完成货物运输任务，成为当前研究的重点。

哈里斯鹰优化(Harris Hawks optimization, HHO)算法^[11]作为一种新型的生物启发式算法，具有稳定性好、搜索精度高、收敛速度快等优点，在图像处理^[12]、参数估计优化^[13]、路径规划^[14-15]等领域应用广泛。然而，HHO算法同其他智能算法一样存在初始种群多样性不足、易陷入局部最优等问题，国内外对此进行了大量的研究，并提出多种解决方法。先后有学者提出通过融合多种算法策略，提升算法的全局搜索能力，文献[16]将HHO与GWO相结合更新下一代个体位置；文献[17]将帝国主义竞争与HHO混合算法相结合，提升算法局部搜索能力。混合算法改进策略是对固有缺陷的统筹改进，虽然在全局寻优性能方面有所提升，但没有充分考虑到种群多样性对算法陷入局部最优的影响，算法的综合性能提升不明显。为此，在改善种群多样性方面，文献[18]受突变操作增加多样性的思想启发，构建了可变邻域学习策略以平衡HHO算法的全局探索和局部开发，以避免算法陷入局部最优，但无法保证变异后个体适应度的优劣；文献[19]提出变异策略的动态HHO算法，通过修改动态控制参数策略，有效平衡了算法全局搜索与局部开发，但并未考虑个体位置的多样性分布；文献[20]采用反向学习策略，改善初始种群的多样性，并先后引入混沌局部搜索和自适应策略，加快算法的收敛性能，但同时增加了算法的计算复杂度，全局搜索和开发能力不协调的问题依然存在。

HHO被广泛应用在移动机器人路径规划领域。为解决基本HHO在路径规划应用中出现的局部最优、收敛性差等问题，文献[14]在UAV路径规划问题上，对传统HHO个体位置采用GWO进行更新，提高了无人机的能量利用效率，减少了路径的平均误差，但对算法全局寻优能力缺乏考虑；文献[15]引入正弦-余弦算法和柯西变异策

略, 提高了算法的局部开发能力, 在解决复杂三维环境中 UAV 路径规划问题方面具有一定的优势, 但该方法并没有解决实际环境中动态障碍的干扰问题; 文献[21]针对多机器人路径规划问题提出一种采用 K-means 聚类和 HHO 的融合算法, 有效提高了算法的收敛速度, 降低了算法的计算量, 为采用云计算远程管理的多机器人路径规划提供了一种新的思路; 文献[22]将混沌映射引入到 HHO 算法中, 以保证初始种群的均匀分布, 在车联网路径寻优问题中验证了改进的算法在收敛速度和精度上均有显著的提高, 但该方法并未充分考虑混沌算法对全局开发和局部探索两个阶段之间的影响, 在实际问题中具有一定的局限性。

针对静态环境下仓储移动机器人的路径规划问题, 上述解决方法并不具有良好的通用性, 优化算法存在搜索效率低、全局探索与局部开发不协调、易陷入局部最优等问题, 会影响移动机器人的规划效率。本文提出一种基于 Tent 混沌映射的多策略融合 HHO 优化算法, 以期提升初始种群多样性, 优化猎物逃逸能量调控策略, 并避免陷入局部最优。根据真实仓储建立不同规模的仿真环境模型, 将改进 HHO 算法与灰狼算法和蚁群算法作路径规划仿真实验对比。通过建立最优路径长度、迭代时间、转折次数等评价指标, 综合评价算法路径规划性能。

1 HHO 算法

HHO 算法作为一种新型生物启发式算法, 是对哈里斯鹰合作捕食行为的模拟优化。该算法主要分为 3 个阶段: 全局探索阶段、探索向开发转变阶段和局部开发阶段。

在 HHO 探索阶段, 哈里斯鹰根据式(1)两种策略探测猎物。

$$X(t+1) = \begin{cases} X_{\text{rand}}(t) - r_1 |X_{\text{rand}}(t) - 2r_2 X(t)|, & q \geq 0.5 \\ (X_{\text{rabbit}}(t) - X_m(t)) - r_3 (b_L + r_4 (b_U - b_L)), & q < 0.5 \end{cases} \quad (1)$$

式中: t 为种群迭代次数; $X(t)$ 为哈里斯鹰当前迭代时的位置; $X_{\text{rand}}(t)$ 为哈里斯鹰种群随机位置; $X_{\text{rabbit}}(t)$ 为猎物位置; $X_m(t)$ 为种群内所有个体的平均位置; r_1, r_2, r_3, r_4, q 均为 $[0, 1]$ 内的随机数; b_U, b_L 为种群搜索空间的上下限。

HHO 算法根据猎物的逃逸能量因子 E 实现全局探索向局部开发阶段的转变。当 $|E| > 1$ 时, HHO 算法进入全局探索阶段, 否则进入局部开采阶段。

$$E = 2E_0(1 - t/T) \quad (2)$$

式中: E_0 为猎物的初始能量, 取 $[-1, 1]$ 内的随机数; T 为种群最大迭代次数。

根据猎物的逃跑行为和哈里斯鹰的围捕策略, 结合猎物的逃逸能量因子 E , HHO 算法在开发阶段提出 4 种策略来模拟哈里斯鹰的攻击行为。用 λ 表示猎物逃脱的概率, 当 $\lambda \geq 0.5$ 时, 表示猎物逃脱失败; 当 $\lambda < 0.5$ 时, 猎物成功逃脱概率较高。

(1) 软包围

当 $1 > |E| \geq 0.5$ 且 $\lambda \geq 0.5$ 时, 猎物有足够的能量, 但未成功突破包围。哈里斯鹰的位置更新为

$$X(t+1) = X_{\text{rabbit}}(t) - E |JX_{\text{rabbit}}(t) - X(t)| \quad (3)$$

式中: J 为猎物在逃脱过程中的随机跳跃, 取 $[0, 2]$ 之间的随机数。

(2) 硬包围

当 $|E| < 0.5$ 且 $\lambda \geq 0.5$ 时, 猎物的逃逸能量不足。哈里斯鹰的位置更新为

$$X(t+1) = X_{\text{rabbit}}(t) - E |X_{\text{rabbit}}(t) - X(t)| \quad (4)$$

(3) 渐进式快速俯冲的软包围

当 $1 > |E| \geq 0.5$ 且 $\lambda < 0.5$ 时, 猎物有足够的能量, 且有机会成功逃脱围捕。将 Levy 飞行函数集成在 HHO 算法中, 模拟猎物的逃跑模式和跳跃动作, 哈里斯鹰的位置更新策略为

$$X(t+1) = \begin{cases} Y, & f(Y) < f(X(t)) \\ Z, & f(Z) < f(X(t)) \end{cases} \quad (5)$$

$$Y = X_{\text{rabbit}}(t) - E |JX_{\text{rabbit}}(t) - X(t)| \quad (6)$$

$$Z = Y + \mathbf{S} \times \text{Levy}(D) \quad (7)$$

式中: D 为问题的维数; \mathbf{S} 为 D 的行向量; $f(\cdot)$ 为

适应度函数。

(4) 演进式快速俯冲的硬包围

当 $|E| < 0.5$ 且 $\lambda < 0.5$ 时, 猎物有机会逃脱, 但逃逸能量不足。哈里斯鹰建立的位置更新策略为

$$X(t+1) = \begin{cases} Y, & f(Y) < f(X(t)) \\ Z, & f(Z) < f(X(t)) \end{cases} \quad (8)$$

$$Y = X_{\text{rabbit}}(t) - E |JX_{\text{rabbit}}(t) - X_m(t)| \quad (9)$$

$$Z = Y + \mathbf{S} \times \text{Levy}(D) \quad (10)$$

HHO 算法通过不同时刻猎物的逃逸能量 E 和逃脱概率 λ , 调节种群的围捕策略, 从而实现问题的优化。

2 改进的TCLHHO算法

2.1 Tent混沌映射

传统 HHO 算法在求解优化问题时, 常采用随机生成的方式初始化, 难以均匀分布在搜索空间中, 导致种群多样性具有不确定性。混沌映射因具有随机性和遍历性的典型特征, 应用于优化问题中, 不仅能有效保持种群的多样性, 还有利于算法跳出局部极值区^[22]。因此, 本文提出利用混沌映射对种群初始化进行改进, 以提高种群多样性。其中, Tent 混沌映射可生成在 $[0,1]$ 内均匀分布的初始值, 在搜索空间中具有更好的遍历性和均匀性^[23]。利用该特性初始化种群, 可有效解决 HHO 算法种群多样性不足的问题, 提升算法的全局搜索能力。

基于 Tent 混沌映射生成的混沌序列为

$$Z_{I+1}^k = \begin{cases} Z_I^k/u, & 0 < Z_I^k \leq u \\ (1-Z_I^k)/(1-u), & u < Z_I^k \leq 1 \end{cases} \quad (11)$$

式中: k 为种群数量; I 为当前迭代次数; u 为 $(0,1)$ 内的随机数。

结合 Tent 混沌映射得到的混沌序列及种群个体位置在搜索空间内的最大值 $X_{I,\max}^k$ 和最小值 $X_{I,\min}^k$, 进一步生成种群在搜索空间内哈里斯鹰个体的初始位置为

$$X_I^k = X_{I,\min}^k + Z_I^k (X_{I,\max}^k - X_{I,\min}^k) \quad (12)$$

在种群规模 $N=50$, 随机数 $u=0.5$ 的初始条件

下, 建立初始化种群对比图, 如图 1 所示。

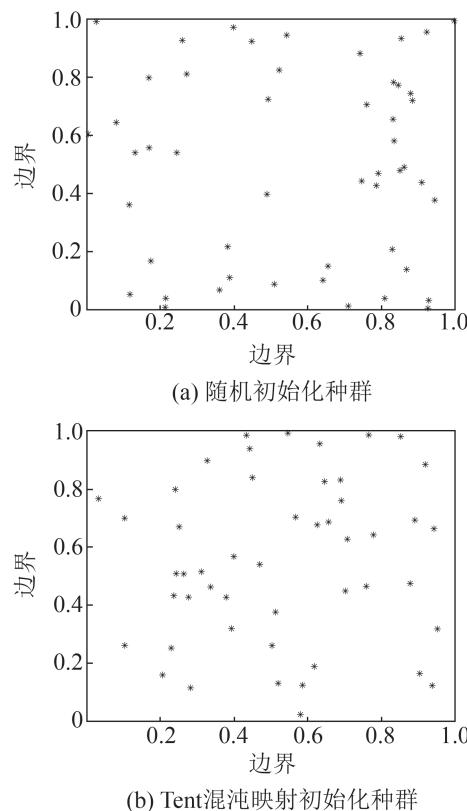


图 1 初始种群分布对比

Fig. 1 Comparison of initialized population distribution

根据对比分析可知, 图 1(a) 中存在种群个体聚集现象, 且在空间中心区域分布较为离散; 图 1(b) 中种群个体均匀分布于搜索空间, 种群多样性较高。因此, 采用 Tent 混沌映射初始化种群分布能在一定程度上提高种群的多样性。

2.2 逃逸能量调控机制

在 HHO 算法中, 哈里斯鹰根据猎物的能量 E_1 控制算法由全局搜索过渡到局部开发阶段。随着迭代次数的增加, 猎物能量因子 E_1 由最大值 2 单周期线性递减到最小值 0。然而, 在自然界哈里斯鹰围捕猎物的过程中, 猎物能量的变化并不能被准确描述为线性递减函数。因此, 本文提出猎物逃逸能量调控机制, 采用非线性函数拟合猎物逃跑时的能量变化, 将指数函数融入猎物逃逸能量 E 的衰减过程:

$$E_1 = 2 \times \left(1 - (t/T)^{e^a}\right) \quad (13)$$

$$E = E_0 \times E_1 \quad (14)$$

在改进算法中, a 取 1.2。图 2~3 分别表示最大迭代次数 $T=500$ 时, 猎物的能量因子 E_1 和逃逸能量因子 E 的变化曲线。

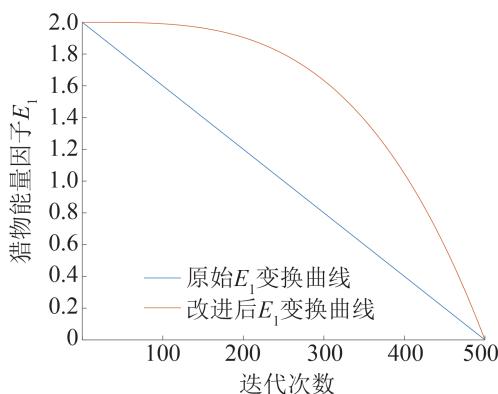
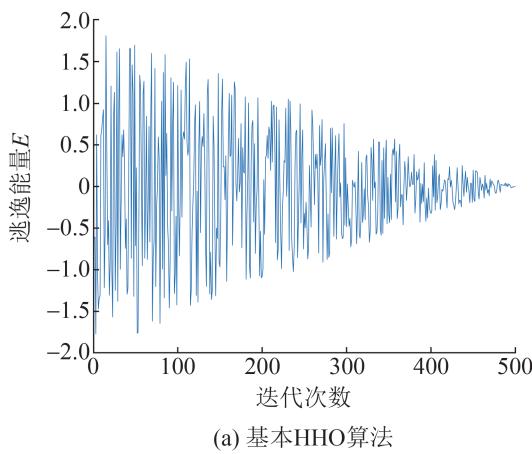
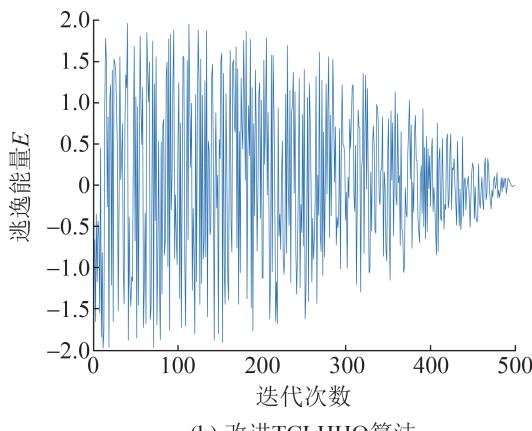


图 2 猎物能量因子 E_1 变换曲线
Fig. 2 Transformation curve of prey energy factor E_1



(a) 基本HHO算法



(b) 改进TCLHHO算法

图 3 逃逸能量因子 E 变换曲线
Fig. 3 Transformation curve of escape energy factor E

根据图 2 可知, 在迭代过程的前期和中期, 曲线变化较为缓慢, 能有效地平衡算法全局搜索和局部探索的能力, 迭代后期能量因子快速减少, 增强算法局部搜索性能。

在图 3 中, 改进算法在整个迭代过程中都能够进行全局搜索和局部开发, 且在迭代前期主要进行全局搜索, 后期在局部开发的同时增加算法全局搜索的可能。指数型逃逸能量调控机制对猎物能量的非线性拟合, 能够有效平衡 HHO 算法全局搜索和局部开发的能力, 增强算法逃离局部极值的能力。

2.3 柯西反学习变异策略

在 HHO 算法后期, 哈里斯鹰个体随迭代次数的增加而聚集, 最优个体因缺乏逃离局部极值的能力而易陷入局部最优。因此, 引入柯西反学习变异策略对当前最优解进行扰动处理, 增强种群的多样性和全局搜索能力, 避免算法陷入局部极值区^[24]。

标准的柯西分布函数峰值相对较小, 当算法通过柯西变异后, 能够使用较少的时间进行局部搜索, 提高算法的寻优性能。因此, 将 HHO 算法与柯西变异融合, 利用柯西变异扰动能力强的特点对当前最优解进行调控, 加快种群逼近最优位置。标准的柯西分布函数和更新最优解的数学模型为

$$\text{Cauchy}(0, 1) = \frac{1}{\pi} \left(\frac{1}{x^2 + 1} \right) \quad (15)$$

$$\mathbf{X}_{\text{newbest}} = \mathbf{X}_{\text{best}} + \mathbf{X}_{\text{best}} \times \text{Cauchy}(0, 1) \quad (16)$$

反向学习是在解空间内构造当前可行解的反向解, 通过对两者保留较优解的方式引导个体寻优, 以增加种群的多样性^[25]。反向学习策略数学模型为

$$\mathbf{X}' = K_1 (\mathbf{b}_U + \mathbf{b}_L) - \mathbf{X}_{\text{best}} \quad (17)$$

$$\mathbf{X}_{\text{newbest}} = K_2 (\mathbf{X}_{\text{best}} - \mathbf{X}') \quad (18)$$

式中: \mathbf{X}' 为种群在 t 时刻迭代最优解 \mathbf{X}_{best} 的反向解; K_1 、 K_2 为 $[0, 1]$ 之间的随机数; $\mathbf{X}_{\text{newbest}}$ 为更新后的种群位置。

根据随机概率选择不同的变异策略交替扰动

最优个体，帮助种群快速逃离局部极值区，加快算法的收敛速度。根据以上策略，建立柯西反学习变异策略为

$$\begin{aligned} \boldsymbol{X}_{\text{newbest}} = & \\ & \begin{cases} \boldsymbol{X}_{\text{best}} + \boldsymbol{X}_{\text{best}} \times \text{Cauchy}(0, 1), & P \geq 0.5 \\ \boldsymbol{K}_2(\boldsymbol{X}_{\text{best}} - (K_1(b_{\text{U}} + b_{\text{L}}) - \boldsymbol{X}_{\text{best}})), & P < 0.5 \end{cases} \end{aligned} \quad (19)$$

式中： P 为[0,1]之间的随机数，当 $P \geq 0.5$ 时，种群在获得最优个体后，通过柯西变异对种群进行扰动，增加算法搜索范围，帮助算法快速寻得全局最优解；当 $P < 0.5$ 时，算法以反向学习策略进行扰动，扩大种群的开采范围。通过随机选取变异策略，在一定程度上提升了算法寻优的速度和全局收敛能力。

2.4 TCLHHO算法流程

TCLHHO 算法伪代码如下。

算法1：TCLHHO 算法

Input: Harris Hawk population size N , dimension D , data upper limit b_{U} , data lower limit b_{L} , maximum iteration T

Output: The rabbit location and its fitness value

```

1 Initialize the harris hawks populations  $\boldsymbol{X}_0$ 
 $\boldsymbol{X}_0^k = \boldsymbol{X}_{0,\min}^k + Z_I^k (\boldsymbol{X}_{0,\max}^k - \boldsymbol{X}_{0,\min}^k)$ 
2 Calculate the fitness of harris hawks
locations  $f(\boldsymbol{X}_0) \rightarrow$  the best locations  $\boldsymbol{X}_{\text{best}}, \boldsymbol{X}_{\text{rabbit}}$ 
While  $t < T$ 
for  $i=1 \sim N$  do
     $E_i = 2 \times \left(1 - (t/T)^{\frac{c}{a}}\right)$ 
     $E = E_0 \times E_i$ 
    if ( $|E| \geq 1$ ) then
        if ( $p < 0.5$ ) then
             $\boldsymbol{X}_{\text{newbest}} = \boldsymbol{K}_2(\boldsymbol{X}_{\text{best}} - (K_1(b_{\text{U}} + b_{\text{L}}) - \boldsymbol{X}_{\text{best}}))$ 
        else if
             $\boldsymbol{X}_{\text{newbest}} = \boldsymbol{X}_{\text{best}} + \boldsymbol{X}_{\text{best}} \times \text{Cauchy}(0, 1)$ 
        end if
    else if  $|E| < 1$ 
        if  $\lambda \geq 0.5 \& |E| \geq 0.5$  then

```

$$X(t+1) = X_{\text{rabbit}}(t) - E | JX_{\text{rabbit}}(t) - X(t) |$$

else if $\lambda < 0.5 \&& |E| \geq 0.5$ then

$$Y = X_{\text{rabbit}}(t) - E | JX_{\text{rabbit}}(t) - X(t) |$$

$$Z = Y + S \times \text{LF}(D)$$

$$X(t+1) = \begin{cases} Y, & f(Y) < f(X(t)) \\ Z, & f(Z) < f(X(t)) \end{cases}$$

else if $\lambda < 0.5 \&& |E| < 0.5$ then

$$Y = X_{\text{rabbit}}(t) - E | JX_{\text{rabbit}}(t) - X_m(t) |$$

$$Z = Y + S \times \text{LF}(D)$$

$$X(t+1) = \begin{cases} Y, & f(Y) < f(X(t)) \\ Z, & f(Z) < f(X(t)) \end{cases}$$

else if ($\lambda \geq 0.5$) $\&& (|E| < 0.5)$ then

$$X(t+1) = X_{\text{rabbit}}(t) - E | X_{\text{rabbit}}(t) - X(t) |$$

end if

end if

end for

end While

3 基于TCLHHO算法的路径规划

3.1 环境模型的建立

通过栅格法模拟仓储移动机器人的运动环境，设定栅格边长为1个单位长度，黑色栅格表示障碍物所占区域，空白栅格表示移动机器人允许通过的区域，栅格之间相互独立^[26]。当二维栅格表示地图时，纵坐标为x轴，横坐标为y轴，第*i*个栅格坐标表示为(x_i, y_i)。

3.2 路径规划模型的建立

在基于TCLHHO算法的路径规划中，设定哈里斯鹰种群每一次迭代更新的位置坐标，代表机器人的一条移动路线。通过TCLHHO优化算法，从二维栅格地图中找寻从起始点到目标点符合约束条件的最优路径。

(1) 地图边界和障碍物约束条件

机器人的移动路径必须限定在栅格地图边界内，并且在可移动区域内，机器人的移动路径禁止穿越障碍物节点。

(2) 路径连续条件

机器人在通行区域内的移动路径需避免路径重叠和迂回。假设移动机器人在 t 时刻位置坐标为 (x_t, y_t) , 则下一时刻机器人位置坐标 (x_{t+1}, y_{t+1}) 需满足 $x_{t+1} > x_t$ 或 $y_{t+1} > y_t$ 。

(3) 路径最短条件

为实现移动机器人路径规划, 机器人需在满足边界约束和路径连续条件的基础上, 寻找从起始点到目标点的最短路径。将路径的欧氏距离作为算法的适应度函数, 适应度最小的路径即为最优路径。路径长度计算式为

$$L = S + L(i) + F \quad (20)$$

$$\begin{cases} S = X^k(t, 1) - 1 \\ L(i) = \sum_{i=2}^c (\sqrt{(X^k(t, i) - X^k(t, i-1))^2 + 1} \\ F = X^k(t, \text{end}) - c \end{cases} \quad (21)$$

式中: L 为机器人移动路径的长度; $X^k(t)$ 为哈里斯鹰优化算法第 t 次迭代时第 k 行的种群位置; $X^k(t, 1)$ 为路径第一个节点的位置; $X^k(t, \text{end})$ 为路径最后一个节点的位置; c 为栅格地图的列数。

4 实验验证与结果分析

4.1 路径规划仿真实验设计

路径规划算法仿真实验基于 Matlab 2020a 软件平台, 计算机为 Windows 11 操作系统, Intel(R) Core(TM) i5-8265U CPU @ 1.6 GHz, 内存为 8 GB。

为了验证改进算法的优越性, 本文选取 HHO、TGWO(Tent-initialized GWO, TGWO)、GWO、ACA 算法作为参照。仿真实验算法种群规模 N 、搜索维度 D 、最大迭代次数 T 等参数设置如表 1 所示。GWO 及 TGWO 算法参数设定与 HHO 算法参数设定相同; ACA 算法中所有参数需按照经验自行设定, 设定最大迭代次数 $T=500$ 、蚁群个数为 10, $\alpha=1$, $\beta=7$, $\rho=0.35$, $Q=1$ 。

表 1 仿真实验算法参数设置

Table 1 Simulation experiment algorithm parameter setting

算法参数	参数值
种群规模 N	30
搜索维度 D	10(10×10 地图仿真实验) 30(30×30 地图仿真实验) 40(40×40 地图仿真实验)
最大迭代次数 T	500
逃逸能量调控因子 a	1.2
柯西反学习变异概率 p	0.5
搜索空间上界 b_u	10(10×10 地图仿真实验) 30(30×30 地图仿真实验) 40(40×40 地图仿真实验)
搜索空间下界 b_l	1

4.2 TCLHHO 路径规划仿真实验分析

为了测试不同规模的静态仓储环境下 TCLHHO 算法在全局路径规划问题中的寻优性能, 同时验证改进算法的优越性, 本文利用占据栅格模拟货架的分布情况, 建立具有固定货架的仓储环境模型, 在规模为 10×10、30×30 和 40×40 的二维栅格地图中测试算法的寻优结果。由于智能仓储货架排布均匀, 其分布具有一定的规则, 因此, 本文构建障碍物离散分布作环境对比, 测试改进算法的路径规划性能。为保证实验的客观性, 离散地图和仓储地图环境参数设定相同, 仅改变栅格地图中障碍物分布。除此之外, 考虑到偶然因素对实验结果的影响, 本文进行多次实验仿真, 测试实验中取 30 次平均最优路径长度、路径转折次数、路径标准差、运行时间和迭代次数综合评价算法在路径规划问题中的寻优结果, 测试算法在不同规模的二维栅格地图下路径规划实验结果如图 4~5 所示, 算法性能对比如表 2 所示。

平均最优路径长度为

$$L_{\text{mean}} = \frac{1}{N_0} \left(\sum_{i=1}^{N_0} L_i \right) \quad (22)$$

式中: N_0 为实验仿真次数; i 为当前实验次数; L 为最优路径长度。

平均路径转折次数为

$$P_{\text{mean}} = \frac{1}{N_0} \sum_{i=1}^{N_0} P_i \quad (23)$$

$$P_i = \sum_{l=1}^c (P_{l+1} - P_l) \quad (24)$$

$$P_{l+1} - P_l = \begin{cases} 0, & K_{l+1} = K_l \\ 1, & K_{l+1} \neq K_l \end{cases} \quad (25)$$

式中: K_l 、 K_{l+1} 分别为第 l 、 $l+1$ 步时路径的斜率。

路径长度标准差为

$$S_{\text{mean}} = \sqrt{\frac{1}{N_0} \sum_{i=1}^{N_0} (L_i - L_{\text{mean}})^2} \quad (26)$$

平均运行时间为

$$T_{\text{mean}} = \frac{1}{N_0} \sum_{i=1}^{N_0} \theta_i \quad (27)$$

式中: θ 为算法的运行时间。

平均迭代次数为

$$I_{\text{mean}} = \frac{1}{N_0} \sum_{i=1}^{N_0} I_i \quad (28)$$

式中: I 为算法的迭代次数。

算法相对性能为

$$\sigma = (x_0 - x_c) / x_c \times 100\% \quad (29)$$

式中: σ 为算法相对性能指标; x_0 为 TCLHHO 实验结果; x_c 为对比算法实验结果。

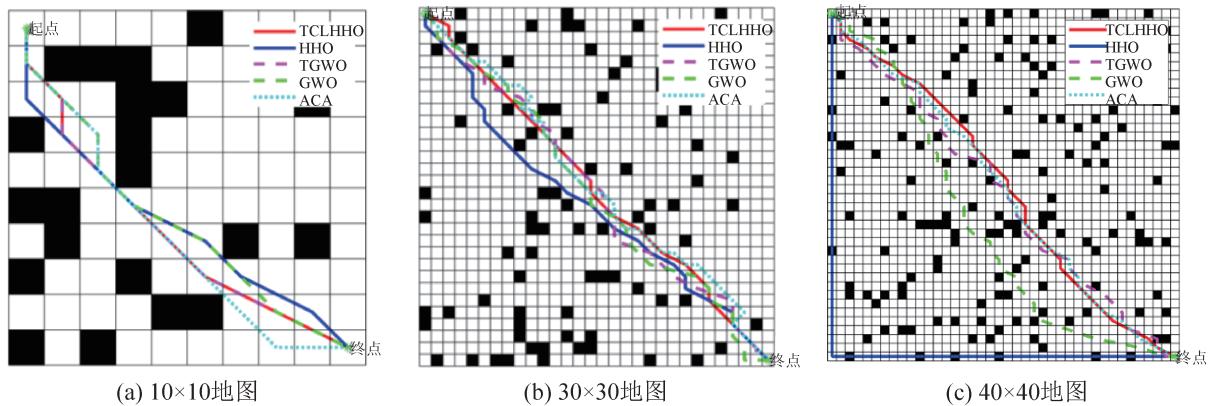


图4 5种算法在不同规模的障碍物稀疏环境下最优路径结果

Fig. 4 Optimal path results of 5 algorithms in different scale obstacle sparse environments

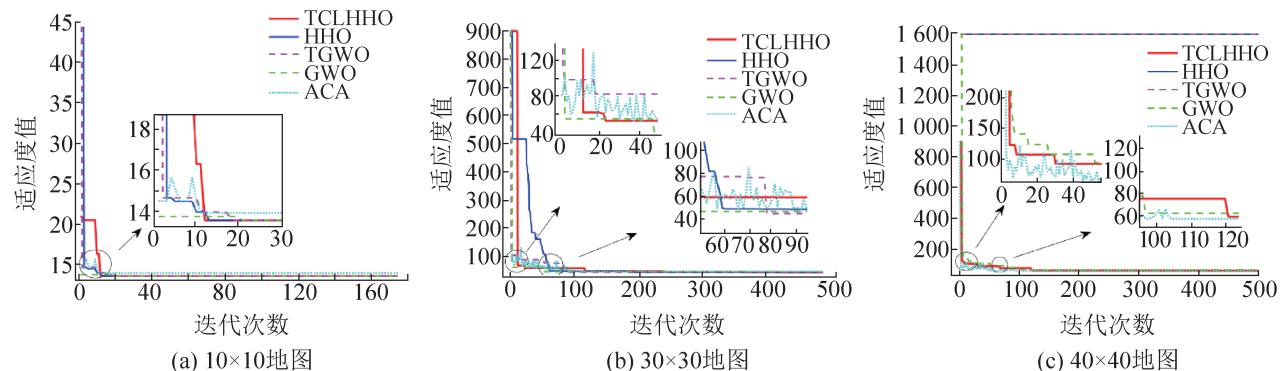


图5 5种算法在不同规模的障碍物稀疏环境下最优迭代曲线

Fig. 5 Optimal iterative curve of 5 algorithms in different scale obstacle sparse environments

在图5中, TCLHHO 算法在平均收敛次数方面明显优于其它算法, 在搜索前期第 17 代即可全局收敛。最优路径相较 ACA 算法缩短了 2.63%, 转弯次数相较 HHO、GWO 和 ACA 算法分别减少了 20%、33.33% 和 20%。在 TCLHHO 算法仅需要

11 次转弯即可寻得最优路径, 其最优路径长度为 43.459 9, 较其余对比算法最优路径分别缩短了 1.84%、2.49%、3.91% 和 8.71%。转弯次数分别减少了 31.25%、26.67%、47.62% 和 56%。而在图5(c) 所示的 40×40 大规模离散地图下, TCLHHO 算

法虽平均迭代次数略有缓慢, 但TCLHHO算法寻得的平均最优路径长度相比GWO和ACA算法分别减少了10.64%和1.61%, 转弯次数减少了37.93%和21.7%。结合多次实验结果显示, HHO和TGWO算法存在路径穿越障碍物的情况, 从而路径无效。虽然ACA算法具有最佳平均迭代次数, 但需要较长的运行时间, 在算法搜索效率和全局寻优能力上略逊于TCLHHO。

表2 基于30次实验下不同规模的离散栅格地图中5种算法性能对比

Table 2 Performance comparison of 5 algorithms in discrete raster maps of different scales based on 30 experiments

地图规模	算法	L_{mean}	P_{mean}	S_{mean}	T_{mean}	I_{mean}
10	TCLHHO	13.543 2	4	0	0.323 8	17
	HHO	13.543 2	5	0	0.444 5	28
	TGWO	13.543 2	4	0	0.232 5	24
	GWO	13.543 2	6	0	0.251 3	34
	ACA	13.899 5	5	0	0.516 8	23
30	TCLHHO	43.459 9	11	0.578 4	0.367 5	136
	HHO	44.290 2	16	1.413 2	0.381 4	56
	TGWO	44.569 9	15	1.109 4	0.348 4	83
	GWO	45.226 2	21	0.673 1	0.324 6	67
	ACA	47.606 4	25	1.596 0	28.815 9	113
40	TCLHHO	56.364 1	18	1.332 6	0.615 2	128
	HHO	—	—	—	—	—
	TGWO	—	—	—	—	—
	GWO	63.077 2	29	9.648 9	0.4179	117
	ACA	57.283 7	23	1.351 1	79.6561	104

注: 在40×40的栅格地图下无法进行HHO和TGWO路径规划实验。

综合分析图4~5及表2得出, 传统的HHO算法搜索随机性较强, 但存在全局搜索路径不足、收敛速度慢等缺点; 对比GWO和TGWO算法在全局路径搜索性能上略逊于其他算法, 但能够有效缩短路径规划的运行时间; ACA算法在后期局部路径开发时呈现出最优路径不稳定的现象, 收敛曲线的波动程度随环境复杂度的增加而愈发明显, 从而大大增加了算法的收敛时间和次数; TCLHHO算法平均路径长度更短、平均迭代次数较少, 在算法的整体搜索性能和收敛速度上都呈现出一定的优势。

通过在离散栅格地图下进行路径规划测试, 验证了离散地图下算法的适用性。图6~7是仓储环境下5种算法在不同复杂程度的栅格地图下进行的路径规划测试, 通过仓库模型下货架规则摆放的特殊分布, 验证算法在仓储环境下路径规划的搜索能力, 算法性能对比如表3所示。

10×10小规模仓储环境下, TCLHHO算法寻得的最优路径更优, 平均最优路径分别减少了1.52%、9.51%、9.9%和2.03%; 对于平均迭代次数, TCLHHO算法仅需要2个转折路径节点, 因此, 对减少移动机器人路径因转弯产生的消耗较为明显。在算法平均收敛次数方面, TCLHHO算法在迭代前期第17代即可寻得最优路径, 除ACA算法在迭代次数方面略优于TCLHHO算法, 在第13代就能够全局收敛, 其余算法则需要更长的迭代次数。

30×30和40×40的地图环境下, TCLHHO算法都能够获得全局最优、转折次数最少、迭代次数较少的路径规划。在规模为30的仓储环境下, TCLHHO算法寻得的平均最优路径相比HHO和ACA所寻得的路径更优、转弯次数更少, 其长度缩短了1.89%和2.79%, 转弯次数减少了50%和86.67%。在平均迭代次数方面, TCLHHO算法收敛速度较快, 仅需要26次就能收敛至最优, 较HHO和ACA算法分别提升了31.6%和92.4%。

当栅格地图为40×40以及更大尺寸的时候, TCLHHO算法在全局寻优方面有了明显效果。相较传统HHO算法和ACA算法, TCLHHO算法获得的平均最优路径分别提升了8.9%和5.57%, 转弯次数减少了55.56%和77.78%。虽然地图环境规模增大, 但是TCLHHO算法的全局路径规划效率并未受到计算复杂度的影响, 仍保持较高的搜索效率。经过多次实验证, TGWO和GWO算法的最优路径收敛曲线在最大迭代次数范围内无法收敛, 因而无法规划出完整的路径, 路径规划无效。

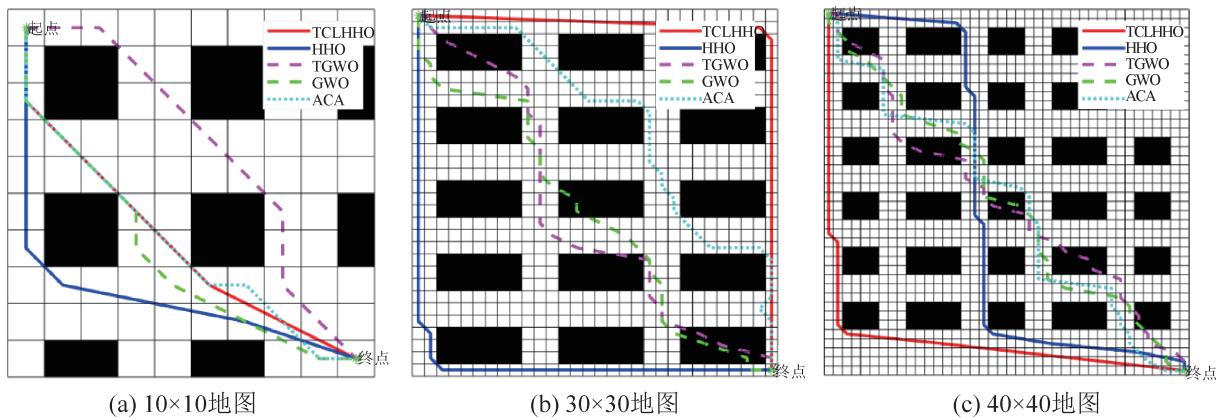


图6 5种算法在不同规模的仓储环境下最优路径结果

Fig. 6 Optimal path results of 5 algorithms in different scale warehouse environments

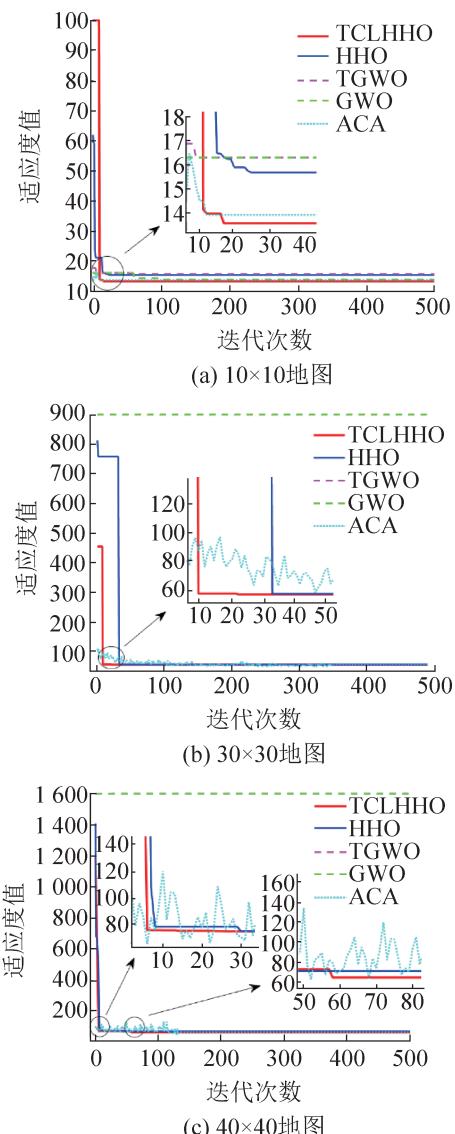
图7 5种算法在不同规模的仓储环境下最优迭代曲线
Fig. 7 Optimal iteration curves of 5 algorithms in different scale warehouse environments

表3 基于30次实验下不同规模的仓储环境中5种算法性能对比

Table 3 Performance comparison of 5 algorithms in regular raster maps of different scales based on 30 experiments

地图规模	算法	L_{mean}	P_{mean}	S_{mean}	T_{mean}	I_{mean}
10	TCLHHO	13.756 4	2	2.022 8	0.505 8	17
	HHO	13.969 7	2	2.697 2	0.569 7	32
	TGWO	15.202 2	3	4.849 1	0.233 7	20
	GWO	15.268 7	4	3.913 1	0.305 2	63
	ACA	14.041 0	4	1.341 6	0.827 1	13
30	TCLHHO	55.633 7	2	3.029 1	0.546 2	26
	HHO	56.709 5	4	0.572 9	0.568 1	38
	TGWO	—	—	—	—	—
	GWO	—	—	—	—	—
40	ACA	57.229 8	15	8.366 7	26.476 4	342
	TCLHHO	64.989 1	4	6.581 7	0.973 4	58
	HHO	71.341 1	9	2.468 4	1.085 0	43
	TGWO	—	—	—	—	—
	GWO	—	—	—	—	—
	ACA	68.825 9	18	10.279 1	78.314 9	137

注：在30×30和40×40的栅格地图下无法进行TGWO和GWO路径规划实验。

综合对比在不同规模和障碍物分布环境下的路径规划实验可以得出，地图规模和障碍物分布等因素都影响着算法的寻优避障能力和路径寻优的准确度。当地图环境规模较小时，不同算法都具有较强的搜索性能和避障能力，但大规模地图环境和规则障碍物分布，往往影响算法的规划性能，对算法路径寻优能力提出了更高的要求。

在不同规格的规则地图和离散地图下，

TCLHHO 算法在平均路径长度、平均路径转折次数、路径长度标准差、平均运行时间, 以及平均迭代收敛次数指标中, 相较于传统的 HHO 算法都呈现出一定的优势。迭代前期收敛速度较快且较为平滑, 即将陷入局部最优时, 通过融合改进的策略, 表现出更佳的局部开发能力, 有效缩短算法在局部停滞的时间, 提高了算法的全局搜索能力, 降低迭代收敛次数和路径转折次数; 在不同复杂环境中, 所获得的路径平滑性更好, 具有更好的鲁棒性和环境适用性, 并且这种优势随着环境地图规模的增大和计算复杂度的增加, 变得更加突出。因此, 通过融合多策略的 TCLHHO 算法能够有效改进传统 HHO 算法存在的不足, 验证了改进的 TCLHHO 算法较 HHO 算法在整体收敛性能和全局探索能力方面有一定的提高, 能够较好适应仓储移动机器人实时、高效的路径规划需要。

5 结论

为求解仓储移动机器人全局路径规划问题, 本文提出一种改进的 TCLHHO 算法, 主要对 HHO 算法做如下改进:

(1) 将 Tent 混沌映射引入 HHO 算法, 对初始种群分布不均的缺陷进行改进, 提高了种群的多样性, 加快了算法的收敛速度。

(2) 提出了逃逸能量调控机制, 通过改进传统 HHO 算法中全局搜索和局部开发相互转换的策略, 一定程度上提高了算法的综合勘探能力。

(3) 引入柯西反学习变异策略更新最优个体的位置, 扩大了算法的搜索范围, 避免算法“早熟”, 能较为准确地得到路径寻优的全局最优解。

不同算法的对比实验证明了 TCLHHO 算法具有较强的全局搜索能力和局部探索能力, 在不同规模的地图下进行路径规划都具有良好的适用性和寻优能力。在后续研究中, 考虑将 TCLHHO 算法与动态避障技术相结合, 提高移动机器人在仓储路径规划中的可靠性和稳定性。

参考文献:

- [1] Nils Boysen, René de Koster, Felix Weidinger. Warehousing in the E-commerce Era: A Survey[J]. European Journal of Operational Research, 2019, 277(2): 396-411.
- [2] 朱大奇, 颜明重. 移动机器人路径规划技术综述[J]. 控制与决策, 2010, 25(7): 961-967.
Zhu Daqi, Yan Mingzhong. Survey on Technology of Mobile Robot Path Planning[J]. Control and Decision, 2010, 25(7): 961-967.
- [3] 庞燕, 罗华丽, 邢立宁, 等. 车辆路径优化问题及求解方法研究综述[J]. 控制理论与应用, 2019, 36(10): 1573-1584.
Pang Yan, Luo Huali, Xing Lining, et al. A Survey of Vehicle Routing Optimization Problems and Solution Methods[J]. Control Theory & Applications, 2019, 36 (10): 1573-1584.
- [4] Seyyed Mohammad Hosseini Rostami, Arun Kumar Sangaiah, Wang Jin, et al. Obstacle Avoidance of Mobile Robots Using Modified Artificial Potential Field Algorithm[J]. EURASIP Journal on Wireless Communications and Networking, 2019, 2019(1): 70.
- [5] 赵晓, 王铮, 黄程侃, 等. 基于改进A*算法的移动机器人路径规划[J]. 机器人, 2018, 40(6): 903-910.
Zhao Xiao, Wang Zheng, Huang Chengkan, et al. Mobile Robot Path Planning Based on an Improved A* Algorithm[J]. Robot, 2018, 40(6): 903-910.
- [6] Shaher Alshammrei, Sahbi Boubaker, Lioua Kolsi. Improved Dijkstra Algorithm for Mobile Robot Path Planning and Obstacle Avoidance[J]. Computers, Materials & Continua, 2022, 72(3): 5939-5954.
- [7] Arpan Kumar Kar. Bio Inspired Computing—A Review of Algorithms and Scope of Applications[J]. Expert Systems with Applications, 2016, 59: 20-32.
- [8] Milad Nazarahari, Esmaeel Khanmirza, Samira Doostie. Multi-objective Multi-robot Path Planning in Continuous Environment Using an Enhanced Genetic Algorithm[J]. Expert Systems with Applications, 2019, 115: 106-120.
- [9] Fatin H Ajeil, Ibraheem Kasim Ibraheem, Mouayad A Sahib, et al. Multi-objective Path Planning of an Autonomous Mobile Robot Using Hybrid PSO-MFB Optimization Algorithm[J]. Applied Soft Computing, 2020, 89: 106076.
- [10] Liu Jianhua, Yang Jianguo, Liu Huaping, et al. An Improved Ant Colony Algorithm for Robot Path Planning [J]. Soft Computing, 2017, 21(19): 5829-5839.
- [11] Ali Asghar Heidari, Seyedali Mirjalili, Hossam Faris, et al. Harris Hawks Optimization: Algorithm and Applications[J]. Future Generation Computer Systems, 2019, 97: 849-872.

- [12] Rodríguez-Esparza, Laura A Zanella-Calzada, Diego Oliva, et al. An Efficient Harris Hawks-inspired Image Segmentation Method[J]. *Expert Systems with Applications*, 2020, 155: 113428.
- [13] Jiao Shan, Chong Guoshuang, Huang Changcheng, et al. Orthogonally Adapted Harris Hawks Optimization for Parameter Estimation of Photovoltaic Models[J]. *Energy*, 2020, 203: 117804.
- [14] Egemen Belge, Aytaç Altan, Rifat Hacıoğlu. Metaheuristic Optimization-based Path Planning and Tracking of Quadcopter for Payload Hold-release Mission[J]. *Electronics*, 2022, 11(8): 1208.
- [15] Zhang Ran, Li Sen, Ding Yuanming, et al. UAV Path Planning Algorithm Based on Improved Harris Hawks Optimization[J]. *Sensors*, 2022, 22(14): 5232.
- [16] Ayani Nandi, Vikram Kumar Kamboj. A Canis Lupus Inspired Upgraded Harris Hawks Optimizer for Nonlinear, Constrained, Continuous, and Discrete Engineering Design Problem[J]. *International Journal for Numerical Methods in Engineering*, 2021, 122(4): 1051-1088.
- [17] Kaveh A, Rahmani P, A Dadras Eslamlou. An Efficient Hybrid Approach Based on Harris Hawks Optimization and Imperialist Competitive Algorithm for Structural Optimization[J]. *Engineering with Computers*, 2022, 38(2): 1555-1583.
- [18] Qu Chiwen, Zhang Lupeng, Li Jinlong, et al. Improving Feature Selection Performance for Classification of Gene Expression Data Using Harris Hawks Optimizer with Variable Neighborhood Learning[J]. *Briefings in Bioinformatics*, 2021, 22(5): bbab097.
- [19] Jia Heming, Lang Chunbo, Diego Oliva, et al. Dynamic Harris Hawks Optimization with Mutation Mechanism for Satellite Image Segmentation[J]. *Remote Sensing*, 2019, 11(12): 1421.
- [20] Abdelazim G Hussien, Mohamed Amin. A Self-adaptive Harris Hawks Optimization Algorithm with Opposition-based Learning and Chaotic Local Search Strategy for Global Optimization and Feature Selection[J]. *International Journal of Machine Learning and Cybernetics*, 2022, 13(2): 309-336.
- [21] Aida A Nasr. A New Cloud Autonomous System as a Service for Multi-mobile Robots[J]. *Neural Computing and Applications*, 2022, 34(23): 21223-21235.
- [22] Amin Abdollahi Dehkordi, Sadiq A S, Seyedali Mirjalili, et al. Nonlinear-based Chaotic Harris Hawks Optimizer: Algorithm and Internet of Vehicles Application[J]. *Applied Soft Computing*, 2021, 109: 107574.
- [23] 滕志军, 吕金玲, 郭力文, 等. 一种基于Tent映射的混合灰狼优化的改进算法[J]. 哈尔滨工业大学学报, 2018, 50(11): 40-49.
Teng Zhijun, Lü Jinling, Guo Liwen, et al. An Improved Hybrid Grey Wolf Optimization Algorithm Based on Tent Mapping[J]. *Journal of Harbin Institute of Technology*, 2018, 50(11): 40-49.
- [24] Wang Wenchuan, Xu Lei, Chau K W, et al. Yin-yang Firefly Algorithm Based on Dimensionally Cauchy Mutation[J]. *Expert Systems with Applications*, 2020, 150: 113216.
- [25] 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 Qing, Lin Jie, Xu Hang. Hybrid Cauchy Mutation and Uniform Distribution of Grasshopper Optimization Algorithm[J]. *Control and Decision*, 2021, 36(7): 1558-1568.
- [26] Shi Kangjing, Huang Li, Jiang Du, et al. Path Planning Optimization of Intelligent Vehicle Based on Improved Genetic and Ant Colony Hybrid Algorithm[J]. *Frontiers in Bioengineering and Biotechnology*, 2022, 10: 905983.