

DOI:10.20033/j.1003-7241.(2026)06-0118-06

基于 AMSSA 和改进 APF 的电力物资仓机器人路径规划方法

崔凌潇¹, 董铭², 徐宁¹, 孙振贺², 姚圣平¹, 黄从智²

(1. 国网山东省电力公司德州供电公司, 山东 德州 253011; 2. 华北电力大学 控制与计算机工程学院, 北京 102206)

摘要:随着电力物资仓储管理的自动化和智能化进程不断推进,取货机器人的应用日益增多。为了提高机器人在多目标路径规划的效率,提出一种基于自适应变异麻雀搜索算法和改进人工势场法的路径规划算法。首先,通过网格图法建立用于机器人路径规划的二维地图模型;之后,针对传统人工势场法中的目标点不可达和陷入局部最优问题,采取增设虚拟目标点等方法改进人工势场法;进一步,采用改进的人工势场法在起点和各个终点两两之间进行路径规划,将多目标路径规划问题转化为求解旅行商问题;然后,采用自适应变异麻雀搜索算法进行迭代寻优,找到全局最优路径;最后,利用仿真实验验证算法的有效性。实验结果表明,所提出的算法能够避免机器人陷入局部最优点,并且能够实现多目标点路径规划的全局最优。

关键词:电力物资仓;机器人;路径规划;自适应麻雀优化算法;改进人工势场法

中图分类号: TP242 **文献标志码:** A **文章编号:** 1003-7241(2026)06-0118-06

Power material warehouse robot path planning method based on adaptive mutation sparrow search algorithm and improved artificial potential field method

Cui Lingxiao¹, Dong Ming², Xu Ning¹, Sun Zhenhe², Yao Shengping¹, Huang Congzhi²

(1. State Grid Shandong Electric Power Company Dezhou Power Supply Company, Dezhou 253011, Shandong, China;

2. School of Control and Computer Engineering, North China Electric Power University, Beijing 102206, China)

Abstract: As the automation and intelligence of power material warehousing management continue to advance, the application of picking robots is increasingly widespread. To improve the efficiency of robots in multi-objective path planning, a path planning algorithm based on an adaptive mutation sparrow search algorithm and an improved artificial potential field method is proposed. First, a two-dimensional map model for robot path planning is established using the grid-based method. Then, to address the issues of unreachable target points and getting stuck in local optima in traditional artificial potential field methods, improvements are made by adding virtual target points and other techniques. Furthermore, the improved artificial potential field method is applied to perform path planning between the starting point and each of the target points, transforming the multi-objective path planning problem into a traveling salesman problem. Next, an adaptive mutation sparrow search algorithm is used for iterative optimization to find the global optimal path. Finally, simulation experiments are conducted to verify the effectiveness of the algorithm. The experimental results show that the proposed algorithm can avoid the robot getting stuck in local optima and achieve the global optimal path planning for multiple target points.

Keywords: power supply warehouse; robot; path planning; adaptive sparrow optimization algorithm; improved artificial potential field method

移动机器人路径规划是指移动机器人自主设计从起点到终点,寻找最短、耗时最短且安全无碰撞的路径^[1-2]。随着智能化和自动化技术的不断发展,取货机器人在电力物资仓库中的应用逐渐成为提升仓储作业效率的重要手段。传统的规划方法如人工势场法^[3]、粒子群优化算法^[4]、遗传算法^[5]以及蚁群优化算法^[6]等虽然有效,但在面对多障碍物环境与多目标规划时,常常陷入局部最优解,导致规划路径的质量和效率欠佳^[7]。

针对这些问题,众多学者提出了一些有效的改进方

案;Lin等^[8]提出了混合粒子群算法用于优化AGV路径规划,相比其他启发式算法,降低了陷入局部最优的可能性,提升了获取最佳全局解的效率;胡晓虎等^[9]通过筛选关键节点及引入平滑度函数的方法改进双向RRT算法,优化了路径搜索效率与路径长度;王霄^[10]提出了一种基于改进灰狼优化算法的仓储物流机器人路径规划方法,缩短了最终规划路径的长度;刘元华等^[11]提出了基于多启发蚁群算法的全局路径规划方法和基于滚动窗口的避障策略,使规划的路径长度更短、拐点更少、收敛更快,但该蚁群算

收稿日期:2025-08-08;录用日期:2025-09-10

基金项目:国网山东省电力公司科技项目(520608240008)

作者简介:崔凌潇(1992—),硕士,工程师,研究方向:电力物资智能调度。

通信作者:黄从智(1982—),博士,教授,博导,研究方向:人工智能算法及其新型电力系统应用。

引用本文:崔凌潇,董铭,徐宁,等.基于AMSSA和改进APF的电力物资仓机器人路径规划方法[J].自动化技术与应用,2026,45(6):118-123.
(Cui Lingxiao, Dong Ming, Xu Ning, et al. Power material warehouse robot path planning method based on adaptive sparrow optimization algorithm and improved artificial potential field method[J]. Techniques of Automation and Applications, 2026,45(6):118-123.)

法在处理多目标、长距离路径规划时,收敛速度会显著变慢,且对环境变化的适应性不足;Zheng等^[12]在人工势场法的应用中通过增设虚拟障碍物的方法帮助机器人离开受困区域,避免了大量的路径冗余;纪苏宁等^[13]提出一种基于模拟退火算法改进的人工势场法,通过在局部极小值附近添加随机目标点,使用模拟退火算法进行优化,从而跳出局部最小值。不过该改进人工势场法在复杂环境下,仍难以精准平衡全局与局部搜索能力,导致路径规划存在一定的不稳定性。

本文针对传统人工势场法路径规划中的局部最优点和目标点不可达问题,分别采用增设虚拟目标点和动态系数法加以解决;随后,运用改进的人工势场法在起点与各个终点间进行路径规划,将多目标路径规划问题转化为旅行商问题求解;最后,以减少路径长度为优化目标,采用自适应变异麻雀搜索算法进行迭代寻优,以找到全局最优路径。相较于现有方法,本文方法在复杂多障碍物环境下,能更高效、精准地规划出全局最优路径,有效提升取货机器人在电力物资仓库中的作业效率。

1 问题描述与空间建模

在电力物资仓库中,取货机器人被广泛应用于物料搬运和自动化作业,以提高仓库管理效率。为了完成取货任务,机器人需要根据仓库内的布局自主导航并完成路径规划。路径规划的前提则是需要构建一个能够反映仓库结构的地图,从而帮助机器人有效地规划从起点到目标位置的路径。

网格地图是一种常用于路径规划和机器人导航的环境表示方法,其中环境被划分为规则的离散网格,每个网格单元代表一个特定区域。地图中的每个位置可以包含不同的状态,如空地、障碍物或目标点。障碍物点被存储为坐标对,通过将障碍物的坐标值映射到网格的相应位置来实现。网格地图简化了复杂环境的建模,提供了高效、直观、易于实现的解决方案,广泛应用于路径规划和导航任务中。

如图1中所示为本文针对某仓库通过网格图法建立的环境模型。地图上映射的障碍物实际上就是仓库中的储物货架,所以目标点的选取都在障碍物的旁边,用以模拟机器人靠近货物取货这一过程。图1中圆点标注的为机器人起点(15,2),方块标注的为机器人需要遍历的多个目标点位置:(6,13)、(14,26)、(16,17)、(21,13)、(26,30)。在实际作业中,机器人需要从起点出发,遍历所有目标点后返回至起点位置。

2 改进 APF 算法

2.1 传统 APF 算法

人工势场法(artificial potential field method, APF)是一种广泛应用于机器人路径规划、避障和自主导航的经典算法。人工势场法的基本思想是在工作空间中构建虚拟

力场,使机器人沿势场的负梯度方向移动,避开障碍物,趋向目标点^[14]。在人工势场法中,系统通过计算环境中每个点的势能来决定机器人在当前状态下的运动方向。势能的来源可以分为两部分,吸引势能和排斥势能。吸引势能是目标点对机器人的吸引力。目标是机器人需要到达的点,机器人会被目标吸引而朝目标方向移动。排斥势能是障碍物对机器人的排斥力。障碍物会对机器人产生排斥作用,防止机器人与其发生碰撞。障碍物的排斥力与距离障碍物的远近有关。




图1 网格地图

Fig. 1 Grid map

吸引势能用于模拟目标点对机器人的吸引力,通常设计为距离目标点越近,吸引力越强。在传统人工势场法中,吸引力计算公式为

$$U_{att}(P) = \frac{1}{2} k_{att} \| P - P_t \|^2 \quad (1)$$

式中, $U_{att}(P)$ 表示当前点 P 的吸引势能; k_{att} 是吸引力系数,控制吸引力的强度; $\| P - P_t \|^2$ 是当前位置 P 与目标位置 P_t 的欧几里得距离。

该势能形式的设计使得机器人总是朝着目标点移动,且随着距离目标的减小,势能逐渐减小,机器人受到的吸引力会减小。

排斥势能用于模拟障碍物对机器人的排斥力。障碍物会影响机器人,使其远离障碍物,避免碰撞。排斥势能的设计使得机器人在距离障碍物较近时会受到较强的排斥力,而在远离障碍物时,排斥势能趋近于零。在传统人工势场法中,吸引力计算公式为

$$U_{rep}(P) = \begin{cases} \frac{1}{2} k_{rep} \left(\frac{1}{\| P - P_o \| - r_o} \right)^2, & \| P - P_o \| < r_o \\ 0, & \| P - P_o \| \geq r_o \end{cases} \quad (2)$$

式中, $U_{rep}(P)$ 是当前位置 P 的排斥势能; k_{rep} 是排斥势能的增益系数,控制排斥力的强度; $\| P - P_o \|^2$ 是当前位置 P 与障碍物位置 P_o 之间的欧几里得距离; r_o 是障碍物的影响范围,通常设置为障碍物的安全距离。

排斥势能在障碍物较远时为零,随着障碍物的靠近而增大,达到障碍物时会出现一个极大值,从而促使机器人远离障碍物。

总势能是吸引势能和排斥势能的加权和,反映了机器人在当前位置的总“势能”状态。机器人会沿着总势能最小的方向移动。总势能的表达式为

$$U_{\text{total}}(P) = U_{\text{att}}(P) + U_{\text{rep}}(P) \quad (3)$$

式中, $U_{\text{total}}(P)$ 是总势能; $U_{\text{att}}(P)$ 是吸引力势能; $U_{\text{rep}}(P)$ 是排斥力势能。

机器人会根据当前总势能的梯度来更新其位置。一般来说,机器人沿着势能下降最快的方向运动,即沿着总势能的负梯度方向运动。

由于传统人工势场法采用虚拟力控制机器人的运动,在仓库仓储环境中,该算法主要面临两点问题。

1) 如果机器人、障碍物和目标点在同一条直线上,机器人受力控制只能在直线上反复运动,却不能到达目标点。

2) 如果障碍物位于目标点附近,将可能出现排斥力大于吸引力,导致目标不可达问题。

2.2 改进措施

在特定仓储环境下,传统的 APF 算法极易陷入问题一中的局部极小值情况,如图 2 为采用传统人工势场法进行路径规划时,机器人从起点 (15, 2) 前往目标点 (6, 13) 时陷入局部最优的示意图。




图 2 机器人陷入局部最优

Fig. 2 The robot is stuck in the local best of the best

针对上述情况,采用增设虚拟目标点引导机器人避开陷入局部最优陷阱的方法。采用直接采用检测起点和目标点之间的最短路径是否穿过障碍物的方式,通过计算路径与障碍物的交集,若路径在某一区域与障碍物相交,则认为路径被阻挡。具体的判断方式是

$$\text{check intersection}(P_{\text{start}}, P_{\text{goal}}, O_{\text{obstacle}}) = \text{True} \quad (4)$$

式中, P_{start} 和 P_{goal} 分别是起点和目标点; O_{obstacle} 是障碍物的位置数据。通过计算路径和障碍物的交集,判断路径是否穿越障碍物。

生成虚拟目标点时,不仅需要避免障碍物,还需要选择能够使路径更短的点,优化路径规划。生成虚拟目标点规则为

$$P_{\text{virtual}} = \arg \min_{P_{\text{virtual}} \in S} \text{length}(P_{\text{start}}, P_{\text{virtual}}) + \text{length}(P_{\text{virtual}}, P_{\text{goal}}) \quad (5)$$

式中, S 是虚拟目标点的候选区域,范围为障碍物所在直线上且距离障碍物的最小距离大于或等于 1; $\text{length}(P_1, P_2)$ 表示点 P_1 和 P_2 之间的距离,目标是选择一个使得路径总长度最小的虚拟目标点。

通过上述方法生成虚拟目标点的示例如图 3 所示。通过采用增设虚拟目标点的方法,不仅保证了路径的可行性,还优化了路径的长度,使得机器人能够更加高效地避开障碍物。




图 3 虚拟目标点生成

Fig. 3 Virtual target point generation

在仓储作业中,机器人不可避免地需要靠近货架拿取货物,这就可能导致出现目标不可达的问题。为此,本文采用动态系数法改进传统的 APF 算法。本文中改进的吸引力计算公式为

$$U_{\text{att}}(P) = \mu_d \cdot \frac{P - P_t}{\|P - P_t\| + \varepsilon} \quad (6)$$

$$\mu_d = \frac{\mu_0}{1 + \|P - P_t\|} \quad (7)$$

式中, μ_d 为动态吸引力系数; $\|P - P_t\|$ 为当前位置和目标点之间的距离; ε 为一个取值较小的常数,防止除零; μ_0 为基础吸引力系数。

式中吸引力系数随着目标距离的减小而增大,使得机器人能够到达靠近障碍物的目标点。

本文中改进的斥力计算公式为

$$U_{\text{rep}}(P) = \lambda_d \cdot \left(\frac{1}{r_0} - \frac{1}{\|P - P_o\|} \right) \cdot \frac{\|P - P_o\|}{r_0^2} \quad (8)$$

$$\lambda_d = \frac{\lambda_0 \|P - P_o\|}{r_0} \quad (9)$$

式中, λ_d 为动态斥力系数; r_0 是障碍物的影响范围; $\|P - P_o\|$ 为当前位置和障碍物之间的距离; λ_0 为基础斥力系数。

3 引入自适应变异麻雀搜索算法

麻雀搜索算法(sparrow search algorithm, SSA)是2020年提出的一种新兴的元启发式算法,麻雀搜索算法仿效了麻雀觅食过程中的搜寻、摄食和交流等行为,旨在通过这些行为模式来探索并发现问题的最优解。为改善传统麻雀搜索算法在前期易陷入局部极值点和后期寻优精度不高的问题,唐延强等^[15]提出一种新的自适应变异麻雀搜索算法(adaptive mutation sparrow search algorithm, AMSSA)。本文引入自适应变异麻雀搜索算法,优化中间点的位置,避免路径规划中出现局部最优的情况,从而提高路径规划的效率和精度。

首先,使用猫映射混沌序列生成初始种群,确保种群具有较好的随机性和遍历性。每个个体的位置用坐标表示,确保在可行域内。设种群中有 n 只麻雀,则由所有个体组成的种群可表示为 $\mathbf{X} = [x_1, x_2, \dots, x_N]^T$, 种群之中每个个体各自对应的适应度函数为 $\mathbf{F} = [f(x_1), f(x_2), \dots, f(x_N)]^T$, 具体表示为

$$\mathbf{X} = \begin{bmatrix} x_{1,1} & x_{1,d} & \dots & \dots & x_{1,D} \\ x_{i,1} & x_{i,d} & \dots & \dots & x_{i,D} \\ \vdots & \vdots & \vdots & \vdots & \vdots \\ x_{N,1} & x_{N,d} & \dots & \dots & x_{N,D} \end{bmatrix} \quad (10)$$

$$\mathbf{F} = \begin{bmatrix} f([x_{1,1} & x_{1,d} & \dots & \dots & x_{1,D}]) \\ f([x_{i,1} & x_{i,d} & \dots & \dots & x_{i,D}]) \\ \vdots \\ f([x_{N,1} & x_{N,d} & \dots & \dots & x_{N,D}]) \end{bmatrix} \quad (11)$$

式中, $i = 1, 2, \dots, N$ 表示第 1 到第 N 只麻雀; $d = 1, 2, \dots, D$ 表示每个麻雀第 1 到第 D 维的位置; $x_{i,d}$ 表示第 i 只麻雀在第 d 维的位置。

针对 Logistic 映射和 Tent 映射的缺点,通过猫映射来生成改进算法的初始种群。猫映射表达式为

$$\begin{bmatrix} y_{i+1} \\ w_{i+1} \end{bmatrix} = \begin{bmatrix} 1 & a_1 \\ b_1 & a_1 b_1 + 1 \end{bmatrix} \begin{bmatrix} y_i \\ w_i \end{bmatrix} \bmod 1 \quad (12)$$

式中, a_1 与 b_1 为任意实数; mod1 表示求 a_1 小数部分。由于猫映射结构简单,不易陷入小循环周期和不动点,通过该映射产生初始种群具有更好的遍历均匀性。

根据个体适应度值,将个体分为探索者、跟随者和预警者。探索者适应度高,负责寻找食物区域;跟随者跟随适应度高的探索者;预警者负责监视环境并发出警报。探索者引导着整个麻雀群体的流动,可在任何地方寻找食物,其位置更新为

$$x_{i,d}^{t+1} = \begin{cases} x_{i,d}^t \cdot \frac{2}{\exp\left(\frac{4i}{\alpha \cdot \text{iter}_{\max}}\right)}, & R_2 < ST \\ x_{i,d}^t + QL, & R_2 \geq ST \end{cases} \quad (13)$$

式中, t 表示当前迭代次数, iter_{\max} 为迭代次数的最大值; α 为区间 $(0, 1]$ 的随机数; Q 为服从正态分布的随机数, m 的选择控制探索者对于全局和局部搜索之间的平衡关

系; L 为 $1 \times d$ 的矩阵,其中每个元素均为 1; R_2 表示警报值, ST 为安全阈值。当 $R_2 < ST$ 时,表示周围区域安全,探索者麻雀将采用宽搜索模式;当 $R_2 \geq ST$ 时,则表示有麻雀发现周围存在天敌,所有麻雀需要转移至安全区域。

跟随者跟随探索者寻找食物,跟随着还会与探索者抢夺食物,增加自己的捕食率,其位置更新为

$$x_{i,d}^{t+1} = \begin{cases} Q \exp\left(\frac{x_{\text{worst}_d^t - x_{i,d}^t}{i^2}\right), & i > N/2 \\ x_{\text{best}_d^{t+1}} + \frac{1}{D} \sum_{d=1}^D (|x_{i,d}^t - x_{\text{best}_d^{t+1}}| \cdot \text{rand} \{-1, 1\}), & i \leq N/2 \end{cases} \quad (14)$$

式中, $x_{\text{worst}_d^t}$ 为第 t 次迭代时麻雀个体在第 d 维的最差位置; $x_{\text{best}_d^{t+1}}$ 为第 $t + 1$ 次迭代时探索者在第 d 维的最优位置; rand 表示随机赋值。 $i > N/2$ 时,第 i 个跟随着最有可能饿死; $i \leq N/2$ 时,第 i 个跟随着会在最佳位置周围随机寻找一个位置觅食。

探索者麻雀和跟随着麻雀的数量采用自适应调整策略,随着迭代次数的累积,探索者数目减少而跟随着数目增多,将全局搜索逐步转为局部精确搜索,提高算法收敛速度。探索者和跟随着数目调整策略公式为

$$r = b \left(\tan\left(-\frac{\pi t}{4 \text{iter}_{\max}} + \frac{\pi}{4}\right) - k \cdot \text{rand}(0, 1) \right) \quad (15)$$

$$p\text{Num} = rN \quad (16)$$

$$s\text{Num} = (1 - r)N \quad (17)$$

式中, $p\text{Num}$ 为探索者数量; $s\text{Num}$ 为跟随着数量, b 为比例系数, k 为扰动因子。

预警者麻雀的初始位置随机生成,其数学模型为

$$x_{i,d}^{t+1} = \begin{cases} x_{\text{best}_d^t} + \beta |x_{i,d}^t - x_{\text{best}_d^t}|, & f_i \neq f_g \\ x_{i,d}^t + K \left(\frac{|x_{i,d}^t - x_{\text{worst}_d^t}|}{|f_i - f_w| + \varepsilon} \right), & f_i = f_g \end{cases} \quad (16)$$

式中, β 为步长控制参数,服从均值为 0、方差为 1 的随机正态分布; K 为 $[-1, 1]$ 之间的随机数; f_i 表示当前个体适应度值、 f_g 表示当前全局最佳适应度值、 f_w 表示当前全局最差适应度值; ε 为最小常数,用以避免零分误差。

为了提高算法的全局搜索能力、跳出局部极值、增强种群多样性以及提高收敛速度,引入 Tent 混沌扰动和柯西变异扰动策略。Tent 混沌映射位置表达式为

$$z_{i+1} = \begin{cases} \frac{2z_i + \text{rand}(0, 1)}{N}, & 0 \leq z_i \leq \frac{1}{2} \\ \frac{2(1 - z_i) + \text{rand}(0, 1)}{N}, & \frac{1}{2} < z_i \leq 1 \end{cases} \quad (19)$$

式中, z_i 为 $[0, 1]$ 之间的随机数, z_{i+1} 为经混沌映射的扰动值。贝努利移位变换后的表达式为

$$z_{i+1} = 2z_i \bmod 1 + \frac{\text{rand}(0, 1)}{K_p} \quad (20)$$

式中, K_p 为序列内粒子个数。柯西变异式为

$$m(x) = x(1 + \tan(\pi(u - 0.5))) \quad (21)$$

式中, $m(x)$ 为变异后个体位置; x 为原来个体位置; u 为

(0,1)区间的随机数。

4 算法融合

遗传算法的迭代优化需要进行大量的计算,为了节约资源并减少算法运行时间,本文首先采用改进的 APF 算法规划出机器人起点和各目标点两两之间的最优路径,并储存这一路径代价。如图 4 所示为采用改进 APF 算法规划的局部路径示意图。




图 4 局部路径规划

Fig. 4 Local path planning

通过采用改进 APF 算法完成局部路径规划,将机器人的多目标路径规划问题转换为旅行商问题求解。将机器人遍历所有目标点的总路程作为优化目标,使用 AMSSA 算法进行迭代寻优。综上所述,本文采用的算法流程如图 5 所示。

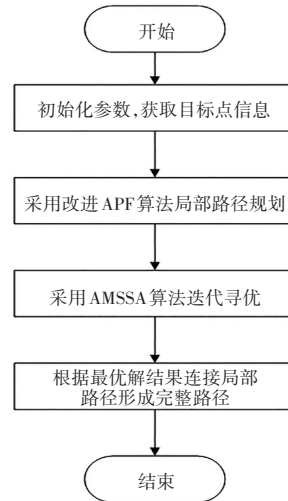



图 5 算法流程


Fig. 5 Algorithmic flow

5 仿真实验


本文中仿真实验在 Python3.11 环境下进行,同时本文中所涉及的改进 APF 算法和自适应变异麻雀算法的初始化参数设置如下。基础吸引力系数 $\mu_0 = 5$,基础斥力系数 $\lambda_0 = 20$,障碍物最大影响距离 $r_0 = 1$,设定步长为 0.1,单次规划最大步数 = 1 000,种群数目 POP = 40,种群纬度 Dim = 4,预警值 ST = 0.6,发现者比例 PD = 0.7,意识到有危险的麻雀比例 SD = 0.3,最大迭代次数 $T = 500$,设定机器人起点为 (15, 2),机器人目标点位置为 (6, 13)、(14, 26)、(16, 17)、(21, 13)、(26, 30)。为了验证本文算法的有效性,选取传统 APF 算法与改进 APF 算法在相同环境下的进行对比实验。如图 6 为传统 APF 算法、改进 APF 算法以及 AMSSA+改进 APF 算法在相同环境下进行路径规划后的结果展示。



(a) 传统 APF 算法路径长度:∞



(b) 改进 APF 算法路径长度:137.60



(c) AMSSA+改进 APF 算法路径长度:109.00

图 6 3 种算法路径规划结果

Fig. 6 Three algorithm path planning results

由图6中可知,当传统人工势场法遇到机器人、障碍物和目标点共线的情况时,轨迹点会前往局部最优点,并在局部最优点附近徘徊,直到耗尽设定的最大规划步数为止。而改进的人工势场法可以通过增设虚拟目标点的方法逃逸局部最优陷阱,完成全局路径规划,并且路径更为平滑。但本文提出的AMSSA+改进APF算法在相比之下,实现了目标点顺序的寻优,进一步优化了全局路径,使得全局路径长度由137.60缩短到109.00。

为进一步说明本文提出的结合自适应变异麻雀算法

表1 五种算法结果对比

Tab. 1 Comparison of the results of the five algorithms

| 目标点个数 | AMSSA | | SSA | | WOA | | CESMA | | GOOSE | |
|-------|--------|--------|--------|--------|--------|--------|--------|--------|--------|--------|
| | 最短长度 | 平均长度 | 最短长度 | 平均长度 | 最短长度 | 平均长度 | 最短长度 | 平均长度 | 最短长度 | 平均长度 |
| 6 | 118.80 | 120.70 | 118.80 | 125.60 | 118.80 | 126.20 | 118.80 | 123.50 | 118.80 | 121.60 |
| 7 | 126.50 | 130.60 | 126.50 | 135.70 | 126.50 | 140.10 | 126.50 | 132.60 | 126.50 | 133.20 |
| 8 | 130.20 | 138.10 | 130.20 | 143.90 | 130.20 | 141.40 | 130.20 | 139.20 | 130.20 | 140.70 |

由表1的实验数据可见,在30次重复实验中,上述五种算法均能搜索到全局最优路径。进一步对比可知,AMSSA算法所规划路径的平均长度在五种算法中最小,这一结果表明AMSSA算法在路径规划问题上具有更优的性能表现,体现出其先进性。

6 结论

本文以某仓库中的仓储机器人的路径规划问题为研究对象,首先针对传统人工势场法所存在的目标不可达和局部最优点问题做了详细分析,并分别提出了改进方法。随后使用改进的APF算法在起点和各个终点两两之间进行路径规划,将多目标路径规划问题转化为求解旅行商问题。最后采用AMSSA算法进行迭代寻优,求解全局最优方案。同时在Python3.11环境下进行仿真实验,以验证本文提出的AMSSA+改进APF算法,能够避免机器人陷入局部最优点,并且能够实现多目标点路径规划的全局最优。尽管该算法在仿真实验中取得了较好的效果,但仍然存在一些局限性,如参数设置较为敏感,在动态环境中适应性较差。因此,未来的研究可以专注于将该算法拓展到动态环境中,以提高该算法的适应性。

参考文献

[1] Qin H, Shao S, Wang T, et al. Review of autonomous path planning algorithms for mobile robots[J]. Drones, 2023, 7(3):211.
 [2] Liu L, Wang X, Yang X, et al. Path planning techniques for mobile robots: Review and prospect[J]. Expert Systems with Applications, 2023(227):120254.
 [3] Qin P, Liu F, Guo Z, et al. Hierarchical collision-free trajectory planning for autonomous vehicles based on improved artificial potential field method[J]. Transactions of the Institute of Measurement and Control, 2024, 46(4): 799-812.
 [4] Wu H, Zhang Y, Huang L, et al. Research on vehicle obstacle avoidance path planning based on APF-PSO[J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile

和改进人工势场法的混合算法的有效性,分别采用麻雀搜索算法^[16]、鲸鱼优化算法^[17](whale optimization algorithm, WOA)、混沌精英黏菌优化算法^[18](chaotic elite slime mold optimization algorithm, CESMA)和鹅优化算法^[19](goose optimization algorithm, GOOSE)等4种算法替换AMSSA算法,并在表1中的3种任务条件下进行实验。设定最大迭代次数均为500,每种算法重复实验30次,记录各算法找到的路径长度,得到仿真结果如表1所示。

Engineering, 2023, 237(6): 1391-1405.
 [5] Li D, Wang L, Cai J, et al. Research on path planning of mobile robot based on improved genetic algorithm[J]. International Journal of Modeling, Simulation, and Scientific Computing, 2023, 14(6): 2341030.
 [6] 聂清彬. 基于动态自适应蚁群优化算法的移动机器人路径规划[J]. 计算机应用, 2024, 44(增刊1):351-354.
 [7] 胡啸, 张呈越, 卞炜, 王健安, 董朋涛. 基于改进哈里斯鹰优化算法的动态路径规划研究[J]. 控制工程, 2024, 31(4):591-600.
 [8] Lin S, Liu A, Wang J, et al. An intelligence-based hybrid PSO-SA for mobile robot path planning in warehouse[J]. Journal of Computational Science, 2023(67): 101938.
 [9] 胡晓虎, 白永忠, 李旭, 等. 基于双向RRT的风电场巡检路径规划算法[J]. 自动化技术与应用, 2025, 44(3):25-28.
 [10] 王霄. 基于改进灰狼优化算法的仓储物流机器人路径规划方法[J]. 自动化技术与应用, 2022, 41(12):23-27.
 [11] 刘元华, 李超群, 郭乙运. 仓储物流机器人多启发蚁群路径规划与避障[J]. 机械设计与制造, 2024(11):296-300.
 [12] Zheng Y, Shao X, Chen Z, et al. Improvements on the virtual obstacle method[J]. International Journal of Advanced Robotic Systems, 2020, 17(2):1-9.
 [13] 纪苏宁, 曹景胜, 刘世江, 等. 基于改进人工势场法的避障路径规划研究[J]. 现代电子技术, 2025, 48(1):117-122.
 [14] Rostami S M H, Sangaiah A K, Wang J, et al. Obstacle avoidance of mobile robots using modified artificial potential field algorithm[J]. EURASIP Journal on Wireless Communications and Networking, 2019(1): 1-19.
 [15] 唐延强, 李成海, 宋亚飞, 等. 自适应变异麻雀搜索优化算法[J]. 北京航空航天大学学报, 2023, 49(3): 681-692.
 [16] 李江华, 王鹏晖, 李伟. 一种混合多策略改进的麻雀搜索算法[J]. 计算机工程与科学, 2024, 46(2):303-315.
 [17] You D, Kang S, Yu J, et al. Path Planning of Robot Based on Improved Multi-Strategy Fusion Whale Algorithm[J]. Electronics, 2024, 13(17): 3443.
 [18] Miao H, Qiu Z, Zeng C. Multi-strategy improved slime mould algorithm and its application in optimal operation of cascade reservoirs[J]. Water Resources Management, 2022, 36(9): 3029-3048.
 [19] Hamad R K, Rashid T A. GOOSE algorithm: a powerful optimization tool for real-world engineering challenges and beyond[J]. Evolving Systems, 2024, 15(4):1249-1274.