

DOI: 10.19650/j.cnki.cjsi.J2514490

异质自适应 ACO: 角度惩罚与精英策略融合 *

曾宪阳, 梁远生, 于 浩, 刘 畅, 杨红莉

(南京工程学院工程训练中心应用技术学院 南京 211167)

摘要:针对传统蚁群算法(ACO)在路径规划中收敛速度慢、易陷入局部最优和路径拐点多等局限性,提出了一种改进的ACO算法。该算法融合了异质自适应机制、角度惩罚与精英策略,并系统验证其泛化性能。通过构建异质-同质双种群协同架构,将两类不同特征的蚂蚁种群结合,增强了算法在多种环境下的全局搜索能力,有效避免种群的过早收敛;引入方向感知的角度惩罚因子,通过在路径规划中加入角度惩罚,避免了不必要的路径拐点,优化了路径平滑性,并提升了算法对复杂地形的适应性;采用精英加权信息素更新策略,使得优秀解的影响力在信息素更新过程中得到更大的体现,加速了收敛过程并提高了稳定性。在多规模栅格地图的对比实验中,所提算法展现出了优异的泛化性能与鲁棒性:在 50×50 复杂环境下,相较于传统ACO算法,路径长度减少14.1%,拐点降低69.4%;相较于现有改进算法,路径长度缩短8.4%,拐点减少66.6%,迭代次数下降82.6%。自动导引车(AGV)实车实验进一步验证了算法在真实场景中的泛化能力,路径长度缩短11.1%,拐点减少78.2%。创新性地提出了种群异质自适应调度机制、方向感知的角度惩罚策略和精英信息素加权更新方法,显著提升了ACO算法的泛化性能,为移动机器人导航系统的实际应用提供了可靠的技术支撑。

关键词: 蚁群算法; 路径规划; 泛化性能; 异质种群; 角度惩罚

中图分类号: TH701 文献标识码: A 国家标准学科分类代码: 520.60

Heterogeneous adaptive ACO: Integration of angle penalty and elite strategy

Zeng Xianyang, Liang Yuansheng, Yu Hao, Liu Chang, Yang Hongli

(Engineering Training Center & School of Applied Technology, Nanjing Institute of Technology, Nanjing 211167, China)

Abstract: This paper addresses the limitations of traditional ant colony optimization (ACO) in path planning, such as slow convergence, susceptibility to local optima, and numerous path inflection points, by proposing an improved ACO algorithm. This algorithm integrates a heterogeneous adaptive mechanism, angle penalty, and an elite strategy, and systematically verifies its generalization performance. By constructing a heterogeneous-homogeneous dual-population collaborative architecture, combining two ant populations with different characteristics, the algorithm's global search capability in various environments is enhanced, effectively avoiding premature convergence. Introducing a direction-aware angle penalty factor avoids unnecessary path inflection points, optimizes path smoothness, and improves the algorithm's adaptability to complex terrain by adding angle penalties to path planning. The elite-weighted pheromone update strategy allows the influence of excellent solutions to be more fully reflected in the pheromone update process, accelerating the convergence process and improving stability. In the comparative experiment of multi-scale grid maps, the algorithm proposed in this paper showed excellent generalization performance and robustness: in a complex 50×50 environment, compared with the traditional ACO algorithm, the path length was reduced by 14.1% and the inflection point was reduced by 69.4%; compared to existing improved algorithms, the path length was shortened by 8.4%, the inflection point was reduced by 66.6%, and the number of iterations was reduced by 82.6%. The real vehicle experiment of the automated guided vehicle (AGV) further verified the generalization ability of the algorithm in the real scene, the path length was shortened by 11.1%, and the inflection point was reduced by 78.2%. This study innovatively proposed a population heterogeneous adaptive scheduling mechanism, a direction-aware angle penalty strategy, and an elite pheromone weighted

update method, which significantly improved the generalization performance of the ACO algorithm and provided reliable technical support for the practical application of mobile robot navigation systems.

Keywords: ant colony optimization; path planning; generalization performance; heterogeneous population; angle penalty

0 引言

路径规划是自主导航的核心技术,旨在为移动体寻找最优或较为理性可行路径,已广泛应用于物流、自动驾驶和自动导引车(automated guided vehicle, AGV)等领域^[1]。仿生算法在该领域展现出显著优势,其中蚁群算法(ant colony optimization, ACO)因具有分布式计算、强鲁棒性和全局搜索能力等特点,成为研究热点^[2-3]。

1999 年 ACO 由 Dorigo 等^[4]提出,模拟蚂蚁通过信息素寻找食物的行为机制。然而,传统 ACO 存在收敛速度慢、易陷入局部最优和路径拐点多等缺陷^[5]。针对这些问题,研究者提出了多种改进策略。2023 年 Liu 等^[6]通过优化初始信息素分布和引入方向判断启发函数,减少无效搜索和转弯次数;Li 等^[7]提出混合蚁群与人工蜂群算法,采用两阶段协同策略提升解的质量;Tang 等^[8]采用自适应状态转移规则和动态信息素更新机制提高收敛速度;2025 年 Li 等^[9]通过非均匀信息素初始化和多目标启发策略避免早熟收敛;Fang 等^[10]通过引入随机步长与随机放大系数两项关键参数作用于信息素更新机制中,有效增强了算法突破局部最优解的能力,提升了全局搜索性能。Yu 等^[11]提出了一种基于空间爆炸与长短期记忆的异质引导蚁群算法,该算法通过结合异质蚁群机制和引导策略,优化了传统蚁群算法在路径规划中的搜索性能。与传统的单一蚁群策略不同,异质蚁群机制允许不同的蚂蚁群体在同一系统中采用不同的搜索策略,提升了全局搜索能力和环境适应性。引入的空间爆炸和长短期记忆机制进一步增强了算法的学习能力和记忆能力,使得算法能够在复杂环境中更高效地进行路径搜索。Chen 等^[12]提出了一种跳跃点搜索改进的蚁群算法混合算法,旨在提高路径寻优精度并减少转弯次数。首先,算法通过引入跳跃点的初始信息素分布,以引导蚁群更高效地找到路径,进而加速了初期迭代速度。其次,设计了启发式函数中的转弯成本因子,以提升路径的平滑度。最后,结合了自适应奖励惩罚因子和最大最小蚁群系统,增强了算法的迭代速度和全局搜索能力。Cui 等^[13]提出了一种多策略自适应蚁群优化算法,该算法通过 4 项设计改进提升了 ACO 的性能。首先,提出了一种方向引导机制,优化了节点选择性能;其次,引入了自适应启发式函数,减少了路径的长度和转弯次数;此外,采用了确定性状态转移概率规则,促进了 ACO 的收敛速度;最后,通过非均匀信息素初始化增强了 ACO 选择有利区域的能力。

现有改进方法多集中于信息素更新和启发函数优化,并通过精准地调控信息素浓度以及启发式信息的权重比例等关键参数,以增强算法的探索能力和收敛特性。但参数调优过程复杂且环境依赖性较强,且多数研究未能有效解决路径平滑性问题。基于此,本研究提出一种基于异质自适应机制的改进 ACO 算法,主要创新包括:构建异质-同质双种群协同架构维持种群多样性;引入角度惩罚因子优化状态转移概率减少路径拐点;采用精英蚂蚁线性加权沉积策略加速算法收敛。实验结果表明,本算法在路径长度、平滑性和收敛速度方面均优于对比算法。

1 问题描述

在当今先进的智能制造及智能物流体系架构之中,自动导引车发挥着至关重要的作用,主要承担着物料搬运等关键任务^[14]。而其中尤为关键的核心技术环节便是路径规划^[15],该技术聚焦于在既定的环境条件下,精准地为 AGV 规划出从起始点至目标点的有效通行路线^[16]。在此过程中,需充分考量障碍物的规避需求,同时致力于对一系列性能指标进行优化,其中包括路径的总长度、拐点的数量等因素,以实现高效且稳定的运行效果^[17]。

在开展本项研究过程中,为了实现高效的建模及精准的求解操作,采用栅格地图对环境进行离散化表示。所谓栅格地图,是将连续的工作空间划分为 $M \times N$ 的规则二维单元格矩阵,每一个独立的单元格 $cell(i, j)$ 都对应着一个特定的位置状态,若某个单元格与障碍物区域重叠,便会被赋予标记值 1,以此表明该区域属于不可通行的范围;反之,若不存在此类重叠情形,则将其标记为 0,意味着此区域是可供通行的可行区域,如图 1 所示。

环境地图可以形式化如式(1)所示。

$$\begin{aligned} \text{Map} = & \{cell(i, j) \mid 1 \leq i \leq M, 1 \leq j \leq N\}, cell(i, j) \\ & \in \{0, 1\} \end{aligned} \quad (1)$$

在栅格地图体系下,AGV 遵循八邻域规则实现路径规划与位移操作。记偏移集合如式(2)所示。

$$\Delta = \{(dx, dy) \mid dx, dy \in \{-1, 0, 1\}, (dx, dy) \neq (0, 0)\} \quad (2)$$

机器人在位置 (x, y) 的八邻域定义如式(3)所示。

$$N_8(x, y) = \{(x + dx, y + dy) \mid (dx, dy) \in \Delta\} \quad (3)$$

其中,仅当邻居节点位于地图边界内且不属于障碍单元格时,才属于有效邻域。

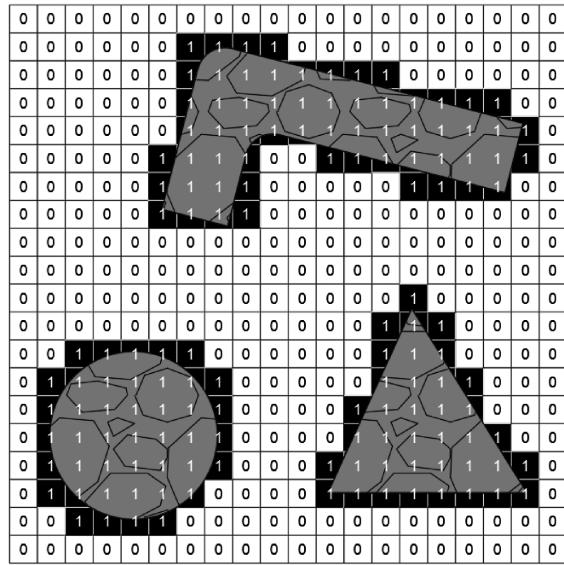


图 1 地图栅格化

Fig. 1 Map rasterization

基于上述栅格地图建模,可将该环境抽象表述为一个有向图结构: $G = (V, E)$, 其中, V 为所有自由单元格构成的节点集合, E 为节点间的可行连接关系。AGV 的路径定义如式(4)所示。

$$P = \{v_0, v_1, \dots, v_i, \dots, v_k\}, v_0 = s; v_k = g; v_i \in V \quad (4)$$

并且满足 $(v_i, v_{i+1}) \in E, i = 0, 1, \dots, k - 1$ 。

在 AGV 基于栅格地图开展路径规划的相关研究中, 其路径优化工作涵盖多项关键考量因素, 诸如路径长度、平滑程度、安全性能以及能耗状况等。其中, 路径长度堪称衡量路径质量的核心要素之一, 对 AGV 的运行效率及能耗表现具有决定性影响^[18]。一般而言, 更为短直的路径可有效缩短行驶时长, 进而实现能源消耗与任务执行成本的双重降低。鉴于栅格地图的特殊构造特点, 所生成的路径多呈现为由诸多折线段拼接而成形态, 倘若其中拐点设置过多, 那么 AGV 在行进过程中便需频繁实施转向动作^[19]。此种情况不仅会增大控制系统的操作复杂度、延长任务执行时间, 还会因频繁转向引发更高的能量损耗以及机械设备的磨损加剧。特别是在实际作业场景里, 相较于直线行驶, AGV 完成转弯动作所需耗费的能量与时间均显著增加。鉴于此, 为使优化方案更契合工程实践需求, 本研究聚焦于路径总长度与拐点数量两项关键参数作为优化目标, 旨在构建兼具高效性与可实施性的最优路径方案。路径长度和拐点个数函数如式(5)所示。

$$\begin{cases} L(P) = \sum_{k=0}^{k-1} d(v_i, v_{i+1}) \\ C(P) = \sum_{i=1}^{k-1} \delta(\theta_i) \end{cases} \quad (5)$$

其中, $d(v_i, v_{i+1})$ 表示相邻节点间的欧氏距离, θ_i 为路径在节点 v_i 的转角, 若方向发生变化则 $\delta(\theta_i) = 1$, 否则为 0, 拐点数越少, 路径越平滑, 可执行性越强。因此 AGV 路径规划问题可以形式化如式(6)所示。

$$P^* = \arg \min_p (L(P) + C(P)), P \cap \{cell(i, j) = 1\} = \emptyset \quad (6)$$

即在栅格地图中寻找一条从起点到目标点的最优路径 P^* , 路径必须避开障碍物, 并在满足可行性约束的条件下最小化代价函数 $L(P) + C(P)$ 。

为了对本文的改进蚁群算法进行全面评估, 引入多目标评价值, 包括路径长度和能源损耗^[2]。能源损耗计算如式(7)所示。

$$E(P) = \vartheta_1 \times \sum_{i=1}^{n-1} \alpha(l_{i-1}, l_i) + \vartheta_2 \times C(P) \quad (7)$$

其中, ϑ_1, ϑ_2 为转弯角度和拐点个数的权重因子, 取值分别为 0.63 和 0.37, $\alpha(l_{i-1}, l_i)$ 为路径中第 $i - 1$ 段线段 l_{i-1} 与第 i 段线段 l_i 之间的夹角。多目标评价值为路径长度与能源损耗构成的权重组合, 计算公式如式(8)所示。

$$J(P) = k_L \times L(p) + k_E \times E(p) \quad (8)$$

其中, k_L 为路径长度权重系数, 该值为 0.7, k_E 为能源损耗权重系数, 该值为 0.3。

2 传统蚁群算法

蚁群算法作为一种极具代表性的群体智能优化技术, 其核心机制在于模拟自然界中蚂蚁群体借助信息素进行路径探索与决策的过程。该算法依托信息素的正反馈作用, 持续强化优质路径的选择倾向, 进而实现对全局最优解的有效探寻与收敛^[20]。每只人工蚂蚁在构造解时严格遵循特定的概率规则来确定下一个访问节点, 其状态转移概率定义如式(9)所示。

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha \cdot [\eta_{ij}(t)]^\beta}{\sum_{l \in allowed_k} [\tau_{il}(t)]^\alpha \cdot [\eta_{il}(t)]^\beta}, & j \in allowed_k \\ 0, & \text{其他} \end{cases} \quad (9)$$

其中, $P_{ij}^k(t)$ 表示第 k 只蚂蚁在 t 代从节点 i 转移到节点 j 的概率; $\tau_{ij}(t)$ 为边 (i, j) 上在迭代 t 时刻的信息素浓度; $allowed_k$ 表示第 k 只蚂蚁当前可选择的候选节点集合; $\eta_{ij}(t)$ 为启发因子, 其值如式(10)所示。

$$\eta_{ij}(t) = 1 / \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (10)$$

其中, α 和 β 分别表示信息素浓度和启发式信息的重要程度。

当路径构建工作顺利完成之后, 算法将着手对所经路径上的信息素开展更新操作^[21]。此信息素更新机制

包含两个关键组成部分, 分别是信息素的自然挥发过程以及基于特定条件的增量沉积行为, 如式(11)所示。

$$\tau_{ij}(t+1) = (1 - \rho) \cdot \tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (11)$$

其中, $\rho \in (0,1)$ 表示信息素挥发系数, 用于防止信息素无限积累, $\Delta\tau_{ij}(t)$ 表示在第 t 代中所有蚂蚁对边 (i,j) 的信息素增量, 通常定义为:

$$\begin{cases} \Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t) \\ \Delta\tau_{ij}^k(t) = \begin{cases} \frac{Q}{L_k}, & tour(i,j) \in tourk \\ 0, & tour(i,j) \notin tourk \end{cases} \end{cases} \quad (12)$$

其中, m 为蚂蚁数量, L_k 为蚂蚁 k 的路径长度, Q 为信息素强度参数。

3 改进蚁群算法

3.1 异质自适应蚂蚁设计

在蚁群算法领域, 参数配置作为关键技术环节, 其合理与否直接决定了算法的整体效能与优化效果, 文献[22]通过控制变量法开展系统性实验, 先通过固定 α 、 ρ 、 Q 和 m 的取值, 聚焦于 β 参数展开专项测试以获取其最优解, 随后基于此结果逐步推进其他参数的优化确定工作。文献[23]采用一种改进型自适应参数贪婪策略, 该策略使 α 与 β 参数能够依据当前迭代进程呈非线性动态调整, 此种设计有效强化了算法对全局空间的探索能力, 同时显著降低了陷入局部极小值的风险。而文献[24]则深入剖析了蚁群算法的应用特性, 指出针对不同类型问题需采用差异化的参数方案; 传统依赖人工经验或大量重复实验进行参数调优的方式存在效率低下且普适性不足的缺陷。此外, 该算法在搜索进程中展现出鲜明的阶段性特征: 迭代初期主要依托启发式信息引导路径选择, 赋予算法较强的探索潜力; 随着迭代推进至后期阶段, 则逐步转向以信息素浓度为核心决策依据, 推动解空间向收敛方向发展^[25]。

基于上述研究现状与问题, 构建了异质自适应蚂蚁模型, 该模型通过将蚁群划分为两个功能互补的子群体——异质蚁群与同质蚁群来实现算法性能提升。其中, 异质蚁群中的个体被赋予差异化的信息素敏感度参数 α 及启发式权重系数 β , 这种参数配置方式有效模拟了自然界蚂蚁行为的生物多样性特征, 从算法架构层面显著增强了全局搜索空间的覆盖能力与环境适应机制。在迭代过程中, 系统优先激活异质蚁群执行路径探索任务。当完成初步搜索后, 筛选出当前最优路径对应的精英个体, 将其特有的 α 、 β 参数组合同步至同质蚁群, 使后者转化为具备即时优势特征的“克隆体”继续深化搜索进程。为维持种群进化动力, 每完成 5 次迭代周期后实施动态调整策略:

基于所有异质个体的平均路径指标进行优劣势评估, 剔除表现最差的末端个体; 同时对最优个体施加高斯扰动生成变异后代并纳入种群体系。这种基于统计特性的动态更新机制不仅实现了蚁群结构的自适应演化, 还通过引入可控随机性有效平衡了局部精细开发与全局广泛探索的双重目标, 成功规避了传统算法易陷入早熟收敛的问题。图 2 为本方法的主要思想迭代过程图。

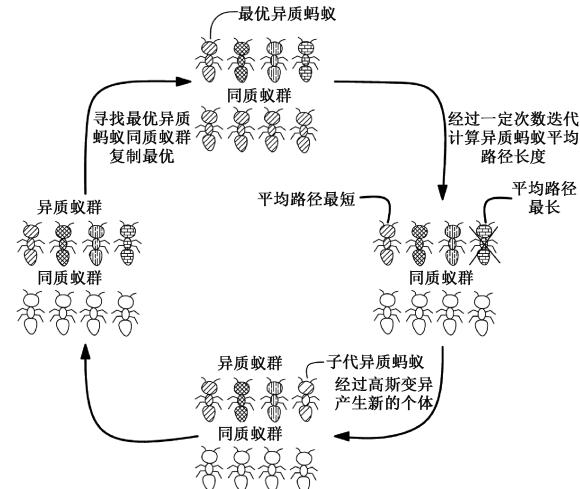


图 2 异质自适应方法迭代过程

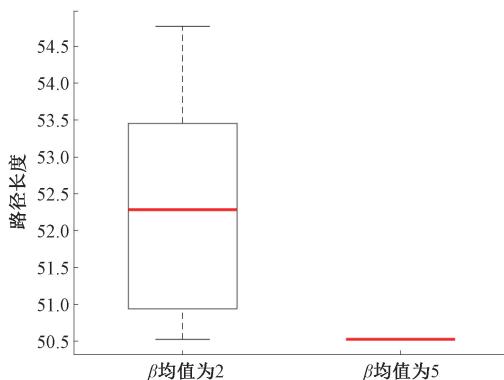
Fig. 2 Iterative procedure of the heterogeneous adaptive method

本文蚁群算法的状态转移概率公式如式(13)所示。

$$P_{ij}^{(k)}(t) = \begin{cases} \frac{[\tau_{ij}(t)]^{\alpha_k} \cdot [\eta_{BFS,ij}(t)]^{\beta_k} \cdot \kappa_{ij}}{\sum_{l \in allowed_k} [\tau_{il}(t)]^{\alpha_k} \cdot [\eta_{BFS,il}(t)]^{\beta_k} \cdot \kappa_{il}}, & j \in allowed_k \\ 0, & \text{其他} \end{cases} \quad (13)$$

其中, $P_{ij}^{(k)}(t)$ 和 $\tau_{ij}(t)$ 与式(9) 中对应项相同, $\eta_{BFS,ij}(t)$ 以及 κ_{ij} 后续再详细介绍。

在异质蚁群模型中, 个体蚂蚁的信息素更新系数 α 与启发式因子 β 呈现非均匀特性。相较于均匀随机赋值方式, 采用正态分布进行参数初始化可显著提升算法性能^[26]。早期研究基于大量旅行商问题(traveling salesman problem, TSP)实例验证, 推荐使用 $\alpha=1$ 、 $\beta=2$ 的组合配置; 而近期有学术成果则倾向于将参数设置为 $\alpha=1$ 、 $\beta=5$, 该设置已在 TSP 求解及路径规划领域展现出优异的应用效果^[27]。为系统评估不同 β 值对算法性能的影响, 本研究在 map3 测试环境中设计了对照实验: 分别设置两组独立运行的试验组, 其 β 均值分别为 2 和 5, 每组均执行 20 次完整迭代过程。最终获取的路径长度统计数据以箱线图形式呈现如图 3 所示, 直观反映了不同参数配置下的算法稳定性与寻优能力差异。

图3 不同 β 均值箱线图Fig. 3 Boxplots of mean values for different β settings

在本次实验中,当 β 的均值设定为2时,所得到的路径平均值达到52.352,其中最长路径值为54.769,最短路径值为50.527;而当 β 的均值提升至5时,经过20次重复实验,所有结果均稳定收敛于50.527这一数值。基于上述实验数据与结论,本研究最终确定将参数 α 的均值设置为1, β 的均值设定为5,异质蚂蚁的 α 与 β 取值为:

$$\begin{cases} \alpha_k \sim TN(1, 0.2^2; [0, 10]) \\ \beta_k \sim TN(5, 0.2^2; [0, 10]) \end{cases} \quad (14)$$

平均路径最优异质蚂蚁产生“子代”的 α 和 β 为:

$$\begin{cases} \alpha_{\text{child}} = \text{clip}(\alpha_k^{\text{best}} + \delta, [0, 10]) \\ \beta_{\text{child}} = \text{clip}(\beta_k^{\text{best}} + \delta, [0, 10]) \\ \delta \sim N(0, 0.05^2) \end{cases} \quad (15)$$

3.2 状态转移概率优化

在传统蚁群算法中,其启发信息的设定存在明显局限性,仅以当前节点与待选节点之间距离的倒数作为依据,鉴于这些节点间距离差异微小,致使启发信息所发挥的作用极为有限。同时,该算法未将待选节点到目标点的距离纳入考量范畴,使得蚂蚁缺乏对整体环境的感知能力,难以迅速锁定目标^[28]。针对此弊端,本文提出采用具备障碍物感知特性的余程估计来充当启发信息。具体操作是从目标点着手,运用广度优先搜索(breadth-first search,BFS)算法,预先为每个可达网格点精准计算出抵达终点的最短路径步长 $h_{\text{est}}(j)$,该过程具体步骤为:

1) 创建一个与地图大小相同的矩阵 H_{est} ,初始矩阵所有元素全为 $+\infty$,将终点坐标 g 的 $h_{\text{est}}(g)$ 设置为0,将其加入队列;

2) 从队列中取出当前节点 u 扫描它的八邻域节点,对于未访问过的邻居节点 v ,执行 $h_{\text{est}}(v) = h_{\text{est}}(u) + 1$;

3) 队列为空时结束,若某节点仍是 $+\infty$,则该节点不可达。

$h_{\text{est}}(j)$ 表示的是可达节点 $j = (x, y)$ 到终点 $g = (x_g, y_g)$ 的最短路径距离估计,该数值是依据地图所呈现的拓扑结构以及环境中障碍物的分布情况,经过计算得出的估计步数距离。在此基础上,本文对传统的启发式函数进行了优化改进,改进后的启发函数如式(16)所示。

$$\eta_{\text{BFS},ij}(t) = \frac{1}{1 + h_{\text{est}}(j)} \quad (16)$$

此设计方案致力于引导蚂蚁在路径抉择过程中,优先选取那些具备更高可行性且在拓扑结构上与终点更为邻近的路线。通过这种优化机制,能够有效规避因障碍物存在而产生的误导性指引,从而显著降低算法陷入局部最优解的可能性,提升整体路径规划的效率与准确性。

在传统蚁群算法模型中,个体运动决策遵循基于信息素轨迹强度及启发式因子的联合作用机制,即 $P(i \rightarrow j) \propto (\tau_{ij})^\alpha \cdot (\eta_{ij})^\beta$,该机制虽然能够逐步引导蚂蚁向最短路径靠拢,但是易导致路径规划结果包含冗余拐点,显著增加实际运行成本。针对此缺陷,对状态转移模型实施改进,融入转角约束因子,当蚂蚁处于节点 i 时,通过计算当前行进方向矢量 \vec{d}_{ki} 与候选分支方向矢量之间的夹角 θ_{ij} ,如图4所示。

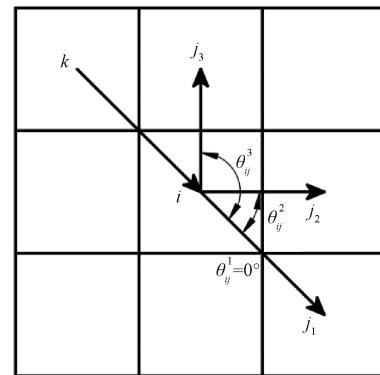


图4 方向拐角示意图

Fig. 4 Turning-angle schematic

采用指数衰减函数对大角度转向进行概率惩罚,实现从决策层面优化路径平滑度。该设计有效降低了路径几何复杂度,使算法生成的轨迹更趋近于工程应用所需的高效路线。

转角惩罚因子如式(17)所示。

$$\begin{cases} \kappa_{ij} = \exp\left(-\frac{\theta_{ij}}{90^\circ}\right) \\ \theta_{ij} = \arccos\left(\frac{\vec{d}_{ki} \cdot \vec{d}_{ij}}{\|\vec{d}_{ki}\| \cdot \|\vec{d}_{ij}\|}\right) \end{cases} \quad (17)$$

当 $\theta_{ij} = 0^\circ$ 时, $\kappa_{ij} = 1$,直行不受惩罚;当 $\theta_{ij} = 45^\circ$ 时, $\kappa_{ij} \approx 0.607$,有效抑制拐弯;当 $\theta_{ij} = 135^\circ$ 时, $\kappa_{ij} \approx 0.223$,

显著抑制拐弯。引入该因子后算法得到路径的拐点数量明显减少。

3.3 改进信息素更新策略

在蚁群算法的运行机制中, 其关键在于借助信息素的正反馈作用以及蒸发机制, 来引导蚁群持续优化并最终获得理想解。文献[9]基于标准更新式框架, 引入随机步长与随机放大系数两项关键参数。其中, 随机步长作用于每只蚂蚁的路径长度, 实现动态调整; 随机放大系数则针对信息素增量进行随机缩放处理。通过上述双重随机化机制, 有效增强了算法突破局部最优解的能力, 提升了全局搜索性能。本次研究中, 经过改进后的蚁群算法面临着一个问题, 即存在数量众多的异质蚂蚁, 其中适应性较弱的蚂蚁所得到的解的质量相较于适应性强的蚂蚁而言, 往往存在较大差距。基于此, 本文在进行信息素更新操作时, 仅引入精英个体予以强化, 同时还采用了名次加权机制, 旨在有效提升算法的全局收敛速度。为确保算法具备持续的探索能力、防止信息素过度累积, 每次迭代结束后都会执行信息素蒸发与补充程序, 本文算法在完成信息素蒸发步骤之后, 仅选取部分优质路径作为信息素补充的来源, 以此加强对高质量解的导向作用。假设在第 t 次迭代中得到的可行路径集合为 $P(t)$, 依路径长度进行排序后, 选取其中前 K 条最短的精英路径作为重点强化对象, 对于每条精英路径 k , 若其长度为 L_k , 则在路径边 (i, j) 上的增量如式(18)所示。

$$\left\{ \begin{array}{l} \Delta\tau_{ij}^k = \frac{\omega_k \cdot Q}{L_k} \\ \omega_k = \frac{K - r + 1}{\sum_{s=1}^K (K - s + 1)} \cdot K \end{array} \right. \quad (18)$$

其中, ω_k 为基于路径长度排名的权重, r 为精英路径集合中第 k 条路径的排名 $r \in \{1, \dots, K\}$, 信息素矩阵的更新公式如式(19)所示。

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \sum_{k=1}^K \Delta\tau_{ij}^k \quad (19)$$

在算法运行过程中, 本文采用特定的信息素更新策略, 即精英强化与名次加权相结合的方式, 这种策略具备显著优势, 一方面能够有效维持解的多样性, 避免陷入局部最优; 另一方面可着重强化优质路径所发挥的贡献, 从而显著加快算法的收敛速度, 提升整体运算效率与效果。

3.4 算法流程图

改进蚁群算法的整体执行流程如图 5 所示。首先, 在栅格地图上设定起点和终点, 初始化信息素矩阵以及异质种群蚂蚁的参数。然后, 利用 BFS 算法从终点出发预估各可行网格到目标的最短步长。随后算法进入迭代循环: 在每一次迭代中, 异质蚁群依据改进的状态转移概率公式逐步构造从起点到终点的可行路径, 同质蚁群则

继承当前精英异质个体的参数进行强化搜索; 完成一代搜索后, 先对全体路径进行性能评估与排序, 在信息素挥发的基础上仅对精英路径采用名次加权规则进行信息素沉积。并且每隔 5 次迭代还对异质蚁群执行“劣质个体淘汰-最优个体高斯扰动复制”的自适应调度操作, 维持种群多样性与搜索活性。上述过程反复迭代, 直至达到最大迭代次数, 最终输出路径长度与拐点数均较优的规划结果。

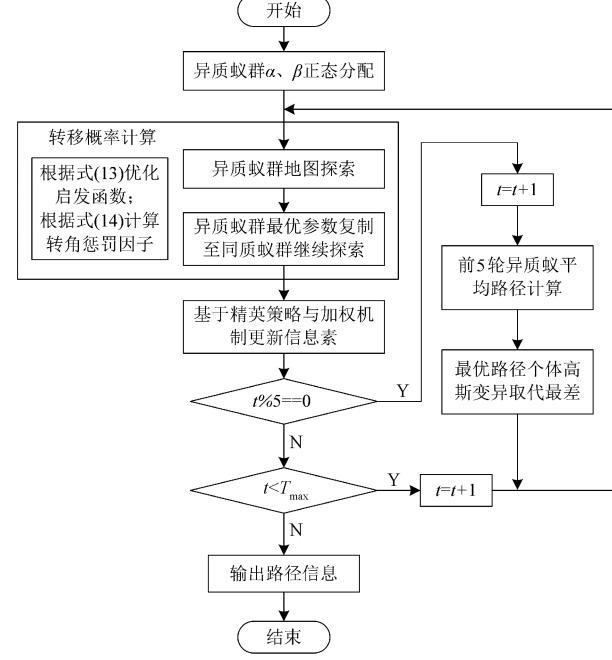


图 5 改进蚁群算法

Fig. 5 Improved ACO algorithm

4 仿真及泛化实验分析

为全面、严谨地评估本文算法的综合性能, 重点考察其泛化能力与鲁棒性, 本研究基于 MATLAB 2023b 平台开展了系统的仿真实验。为科学确保结果的可靠性并有效排除偶然因素干扰, 实验设计了多组不同规模的测试场景, 涵盖 20×20 规格的栅格地图(命名为 map1)、 30×30 规格的栅格地图(命名为 map2)、 40×40 规格的栅格地图(命名为 map3)以及 50×50 规格的栅格地图(命名为 map4)。每个场景均重复进行 20 次独立实验, 以全面评估算法在不同复杂度下的泛化表现及稳定性。作为对照, 本文选取了传统 ACO 算法以及文献[9]中所提及的改进 ACO 算法进行对比分析。相关算法的具体参数设置详见表 1 所示内容。

4.1 20×20 栅格地图

针对 map1 场景开展了 3 种蚁群算法的性能评估与

表 1 仿真实验参数

Table 1 Simulation experiment parameter

算法	α	β	Q	ρ	m
传统 ACO	1	5	100	0.5	50
文献[9]	0.98	3	1	0.3	50
本文算法	式(14)	式(14)	10	0.2	50

对比分析。其中,图 6 直观呈现了各算法在此地图下的路径规划成效,图 7 则展示了对应的迭代收敛过程。

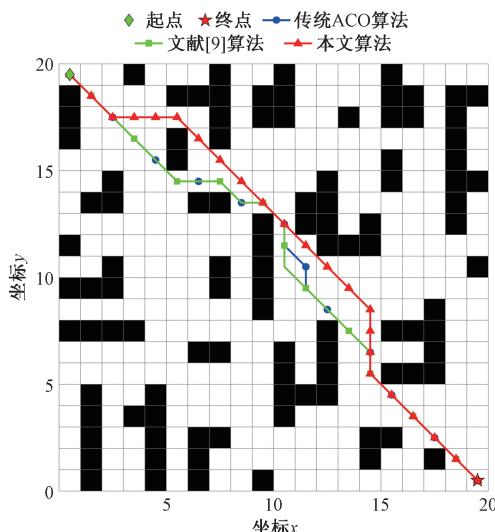


图 6 map1 路径规划结果对比

Fig. 6 Comparison of path-planning results on map1

具体而言,传统 ACO 算法表现出明显的绕行特征,所规划路径曲折复杂。其在迭代初始阶段虽能实现快速

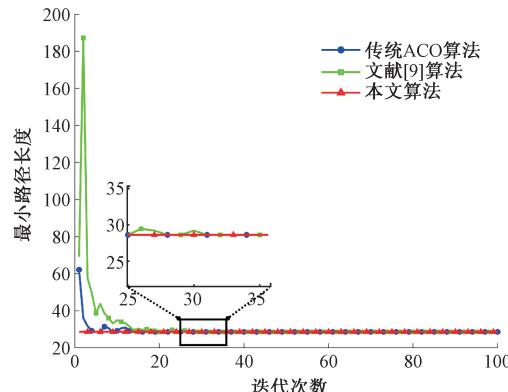


图 7 map1 迭代收敛

Fig. 7 Iteration convergence plot for map1

下降,然而一旦收敛,路径长度便固定于 29.213,未能达成最优解。文献[9]提出的算法相较于传统 ACO 算法有所改进,冗余路径得到一定缩减且成功寻得最优解,但该算法存在路径拐点过多的问题,同时前期路径长度波动剧烈,反映出搜索过程稳定性欠佳;尽管后期能够收敛至最优解,但收敛速度相对迟缓。而本文所提出的算法展现出显著优势,不仅成功找到全局最优解,而且在拐角惩罚机制与启发式信息的引导下,规划出的路径更为平滑、拐点数量大幅减少。尤其在小型栅格地图环境下,本文算法仅需一次迭代即可锁定最优解,兼具高效的收敛速度与良好的稳定性。

表 2 呈现的数据结果显示,在开展的 20 次实验过程中,传统 ACO 算法、文献[9]所提出的算法以及本文算法均成功找到最短路径。

表 2 map1 环境实验结果

Table 2 Experimental results in the map1 environment

算法	路径长度			本文算法 减小率/%	迭代次数			本文算法 减小率/%	拐点个数			本文算法 减小率/%	$J(p)$
	最大值	最小值	平均值		最大值	最小值	平均值		最大值	最小值	平均值		
传统 ACO	30.041	28.627	29.500	2.96	61	12	18.90	94.4	13	6	9.3	55.9	27.09
文献[9]	28.627	28.627	28.627	0.00	30	16	25.90	95.9	11	5	7.9	48.1	25.68
本文算法	28.627	28.627	28.627		2	1	1.05		5	4	4.1		22.86

从性能指标对比来看,本文算法展现出显著优势:其平均路径长度较原版算法降低了 2.96%;在拐点均值方面,相较于传统 ACO 算法减少了 55.9%,与文献[9]算法相比也降低了 48.1%。尤为突出的是,在这 20 次实验里,本文算法有 19 次仅需一次迭代便能精准定位到最优解,充分彰显了该算法的高效性与稳定性。

4.2 30×30 栅格地图

蚁群算法的性能评估与对比分析。其中,图 8 清晰呈现了 3 种蚁群算法在该地图上的路径规划结果;图 9 则直观展示了 3 种算法各自的迭代收敛情况。

依据表 3 所列数据进行分析可知,传统 ACO 算法所得最短路径长度为 47.113,并未找到最短路径。与之形成对比的是,文献[9]提出的算法以及本文所阐述的算法均成功找到了最优路径。进一步比较可知本文算法路径平均值较传统 ACO 算法降低了 2.43%,相较于文

本文针对 map2 场景下的路径规划任务进行了不同

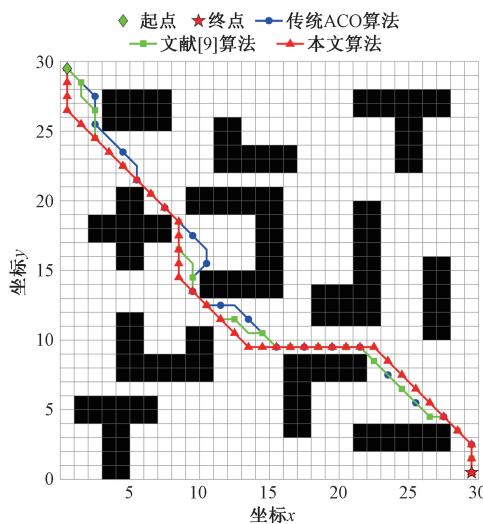


图 8 map2 路径规划结果对比

Fig. 8 Comparison of path-planning results on map2

献[9]算法也减少了 1.38%；在迭代次数方面，分别比传

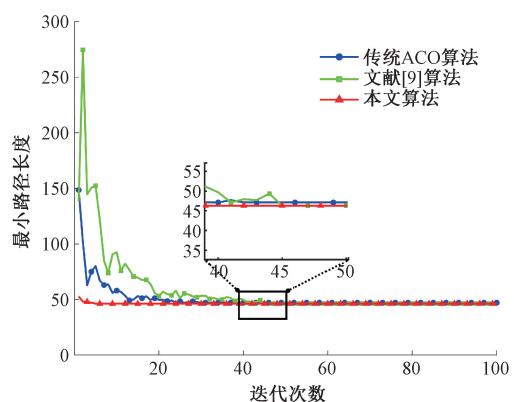


图 9 map2 迭代收敛

Fig. 9 Iteration convergence plot for map2

统 ACO 和文献[9]算法缩减了 85.2% 与 88.7%；在拐点个数这一指标上同样表现优异，分别比两者减少了 58.3% 和 61.3%。

表 3 map2 环境实验结果

Table 3 Experimental results in the map2 environment

算法	路径长度				迭代次数				拐点个数				$J(p)$
	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	本文算法减小率	
传统 ACO	48.284	47.113	47.437	2.43%	60	28	41.00	85.2%	22	11	15.6	58.3%	43.99
文献[9]	50.042	46.284	46.913	1.38%	73	44	53.60	88.7%	21	11	16.8	61.3%	44.83
本文算法	46.284	46.284	46.284		8	5	6.05		8	6	6.5		36.63

4.3 40×40 栅格地图

图 10 展示了 3 种蚁群算法在 map3 环境下的路径规划结果对比情况，图 11 则呈现了它们各自的迭代收敛态势，表 4 记录了此次实验所获得的各项数据。

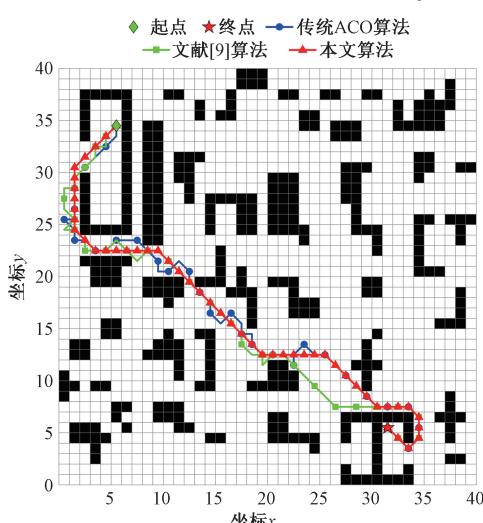


图 10 map3 路径规划结果对比

Fig. 10 Comparison of path-planning results on map3

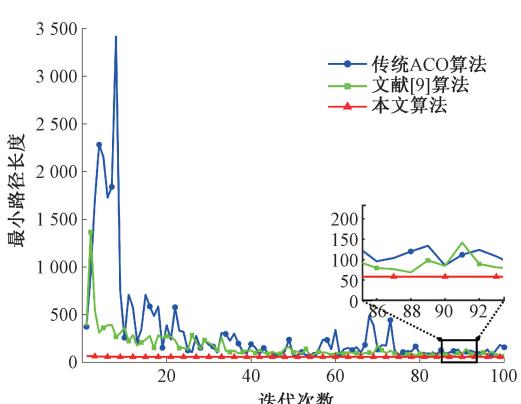


图 11 map3 迭代收敛

Fig. 11 Iteration convergence plot for map3

传统 ACO 算法在 map3 环境中未能实现收敛，其所得最短路径长度达 68.012，而文献[9]所提算法可能因参数设置与带凹槽结构的地图适配性欠佳，同样未达成收敛状态，与之形成对比的是，本文算法 20 次实验均收敛到 58.355，稳定性较强。相较于传统 ACO 算法及文献[9]算法，本文算法在平均路径长度上分别缩减

表4 map3环境实验结果

Table 4 Experimental results in the map3 environment

算法	路径长度			迭代次数			拐点个数			本文算法减小率	$J(p)$	
	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	
传统 ACO	113.330	68.012	81.702	28.6%	-	-	-	-	74	36	46.3	73.7%
文献[9]	76.012	66.012	70.711	17.5%	-	-	-	-	37	30	32.6	62.6%
本文算法	58.355	58.355	58.355		16	9	12.8		14	11	12.2	48.89

28.6%与17.5%;拐点数量均值相较于二者亦显著下降,降幅分别为73.7%和62.6%。

4.4 50×50栅格地图

图12为3种蚁群算法在map4中的路径规划结果对比图,图13清晰描绘了3种算法于map4地图上的迭代收敛态势,而表5记录了此次实验的各项具体结果。

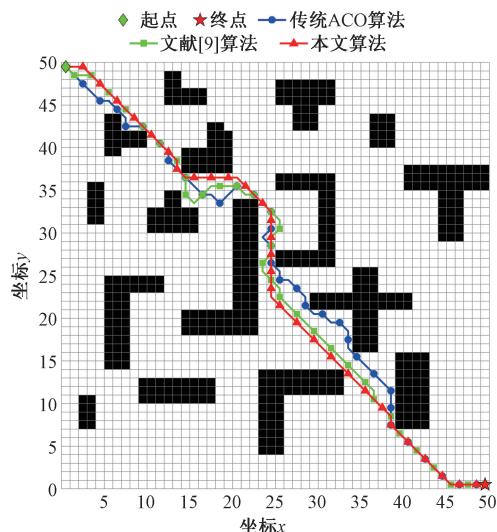


图12 map4路径规划结果对比

Fig. 12 Comparison of path-planning results on map4

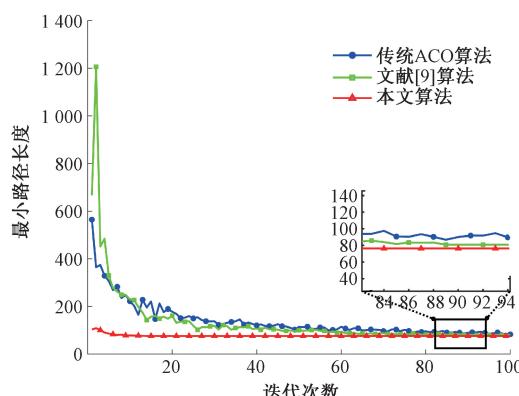


图13 map4迭代收敛

Fig. 13 Iteration convergence plot for map4

传统ACO算法20次实验均未实现收敛,且未能成功探寻到最短路径。文献[9]所提出的算法虽在迭代进程的后期达到了收敛状态,但同样未能获取最短路径。本文算法在map4中20次实验均快速收敛并找到最短路径。依据表5中的统计数据可知,与传统ACO算法相比,本文算法的路径平均值降低了14.1%,拐点个数平均值减少了69.4%;相较于文献[9]算法,本文算法的路径平均值降低8.4%,拐点个数平均值减少66.6%,同时平

表5 map4环境实验结果
Table 5 Experimental results in the map4 environment

算法	路径长度			迭代次数			拐点个数			本文算法减小率	$J(p)$	
	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	
传统 ACO	110.29	83.154	88.857	14.1%	-	-	-	-	41	30	35.6	69.4%
文献[9]	89.740	81.154	83.368	8.4%	92	68	81.2	82.6%	43	24	32.6	66.6%
本文算法	76.326	76.326	76.326		17	10	14.1		12	10	10.9	60.48

均迭代次数缩减了82.6%。这些数据充分表明,本文算法在路径规划性能上具有明显提升。

4.5 50×50迷宫地图

为了验证本文算法在复杂障碍物环境中的性能,本文

设置了 50×50 的迷宫环境 (map5) 对改进蚁群算法进行验证。在 20 次的实验中传统 ACO 算法与文献 [9] 算法均未找到可行路径 (图中不再显示), 本文算法 20 次规划中 14 次均找到了可行路径, 本文算法具有较好的泛化能力与稳定性。路径规划结果如图 14 所示, 图 15 描绘了算法的迭代收敛态势。表 6 记录了此次实验所获得的各项数据。

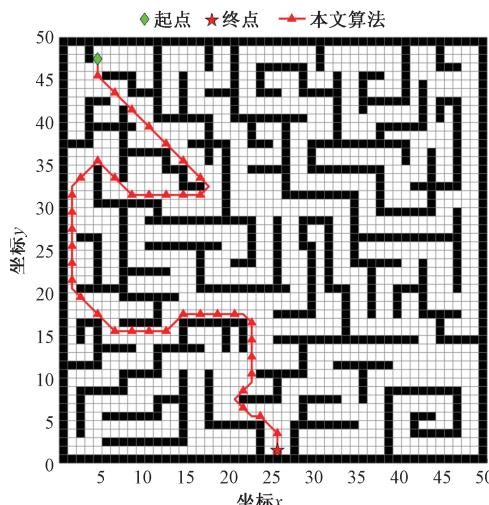


图 14 map5 路径规划结果对比

Fig. 14 Comparison of path-planning results on map5

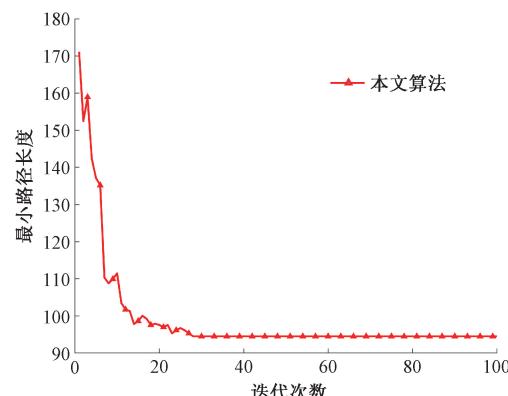


图 15 map5 迭代收敛图

Fig. 15 Iteration convergence plot for map5

5 真实环境试验验证

为切实检验所提算法于实际应用场景中的效能表现, 开展了基于激光雷达装备的移动平台实车测试验证工作。实验载体选用配备 N10 型激光雷达的差速驱动轮式机器人平台, 其结构参数如下: 双主驱动轮间距设定为 185 mm, 前后各配置一组万向辅助轮, 两组万向轮之

表 6 map5 环境实验结果
Table 6 Experimental results in the map5 environment

算法	路径长度			迭代次数			拐点个数			本文算法减小率	$J(p)$	
	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	本文算法减小率	最大值	最小值	平均值	
传统 ACO	-	-	-	-	-	-	-	-	-	-	-	
文献[9]	-	-	-	-	-	-	-	-	-	-	-	
本文算法	96.15	94.50	94.97		45	22	32.71		21	17	18.57	78.72

间的中心距为 120 mm, 如图 16 所示。实验所处场地的具体布局详见图 17, 其整体面积大致为 $4 \text{ m} \times 5 \text{ m}$ 的方形区域。在该场地上设置的障碍物均由不同规格尺寸的纸箱构成。开展实验时, 需率先运用激光雷达设备对整个试验区域进行全面扫描, 借助即时定位与地图构建 (simultaneous localization and mapping, SLAM) 技术来获取并生成相应的地图数据, 以此作为后续导航操作的基础支撑。在此过程中, 选用基于粒子滤波的栅格建图算法 (grid-based fastSLAM, GMapping) 来完成地图创建工作, 最终所形成的全局地图呈现为三色样式, 如图 18 所示。

在本次实车实验中, 设定移动机器人的起始位置为原点, 其目标终点坐标为 $(3.186 \text{ m}, -2.893 \text{ m})$ 。针对此次路径规划, 分别采用了传统 ACO 算法以及本文

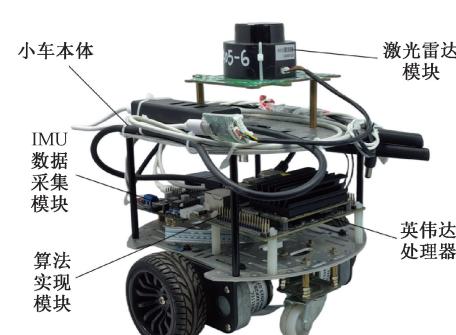


图 16 搭载激光雷达的差速小车

Fig. 16 Differential-drive wheeled robot with onboard LiDAR

所提出的算法进行求解, 相应的规划结果如图 19 和 20 所示。



图 17 实验场景

Fig. 17 Experimental scenario

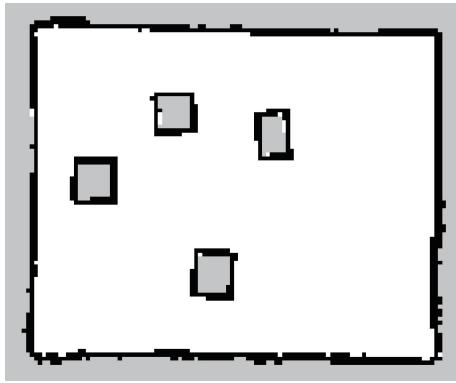


图 18 栅格地图

Fig. 18 Grid map

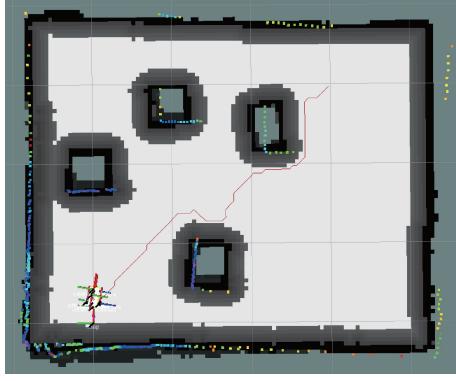


图 19 传统 ACO 算法规划结果

Fig. 19 Planning results of the conventional ACO

经对比分析可知,本文算法所规划出的路径具备显著优势:路径总长度为 4.283 m,相较于传统 ACO 算法得出的 4.820 m,路径长度缩减了 11.1%;同时,在拐点数量方面表现也较为优异,本文算法仅产生 5 个拐点,而传统 ACO 算法则多达 23 个,拐点数量减少了 78.2%。在真实实验环境下,本文算法依然能够保持良好的性能表现,具有一定的实用性。

为了验证本文算法在具有动态、静态新增障碍物条

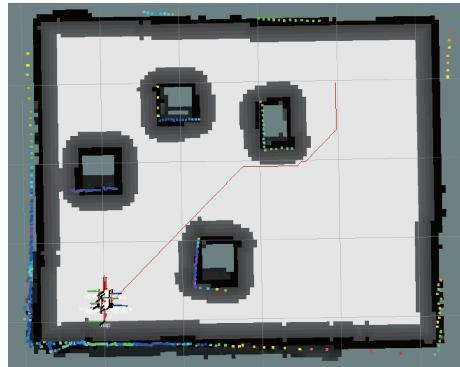


图 20 本文算法规划结果

Fig. 20 Results planned by the proposed method

件下的鲁棒性,本文设置了以下实验:在已经创建完成的栅格地图中新增一个静态障碍物一个动态障碍物,算法的运行情况如图 21~25 所示。

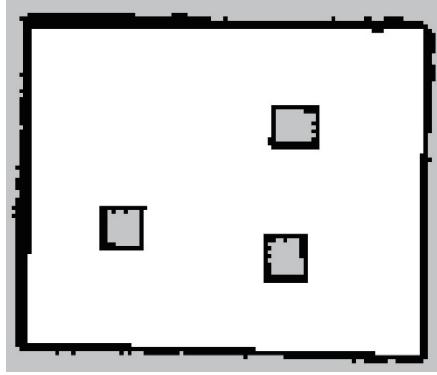


图 21 栅格地图

Fig. 21 Grid map

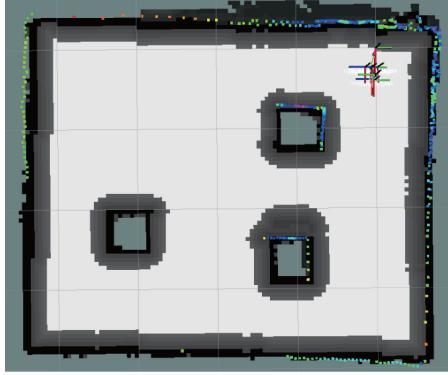


图 22 Rviz 中加载的地图

Fig. 22 Maps loaded in Rviz

图 21~25 中实线线框圈出的障碍物为新增静态障碍物,虚线线框圈出的障碍物为新增动态障碍物,虚线为小车的移动路线,实线为本文算法计算得到的路径,从图中可以看到,即使地图中存在新增静态或存在动态障碍

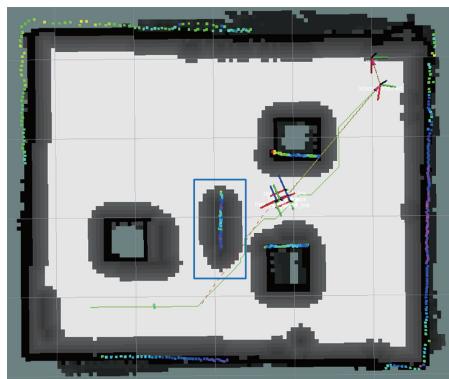


图 23 检测到新增静态障碍物

Fig. 23 New static obstacles detected



图 24 检测到新增动态新增障碍物

Fig. 24 New dynamic obstacles detected

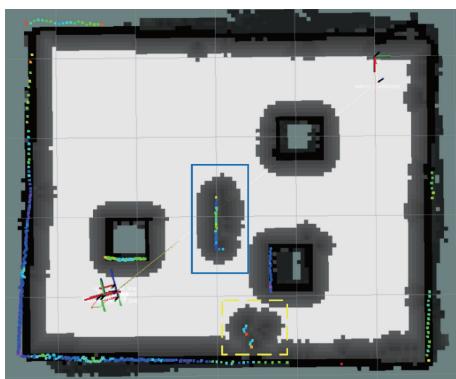


图 25 到达目标点附近

Fig. 25 Arrive near the target point

物, 小车依旧可以导航成功, 本文算法具有较好的鲁棒性。

6 结 论

传统 ACO 算法参数敏感、搜索效率低, 且难以兼顾路径长度与平滑性。为此, 本研究提出了一种集成异质

自适应机制、角度惩罚因子与精英策略的改进 ACO 算法。通过构建异质—同质双种群协同进化框架, 增强全局探索与局部开发能力; 引入方向感知的角度惩罚因子, 有效抑制无效拐弯; 采用精英路径加权沉积策略, 加速正反馈收敛过程。

仿真与实验结果表明, 所提算法在多种栅格环境 ($20 \times 20 \sim 50 \times 50$) 中均表现出优异性能。与原始 ACO 及文献[9]算法相比, 本文算法在路径长度、拐点数量和收敛迭代次数等方面均有显著提升。在 50×50 地图中路径长度缩短 8.4%, 拐点减少 66.6%, 迭代次数降低 82.6%; 真实场景实验也验证了其有效性, 路径长度减少 11.1%, 拐点下降 78.2%。结果表明, 本算法具有良好的稳定性、实用性和泛化能力。

本研究的主要创新体现在: 1) 提出异质自适应种群调度机制, 平衡探索与开发矛盾; 2) 融合方向感知与角度惩罚策略, 显著提升路径平滑性; 3) 设计精英加权信息素更新方式, 改善收敛效率。研究成果不仅为 ACO 路径规划提供了新思路, 也为 AGV、移动机器人等智能系统的工程应用提供了可靠的技术支撑, 具备较高的理论价值与良好的应用前景。

参考文献

- [1] 陈正升, 田楚开, 刘凯旋, 等. 基于 MBIT* 的移动机器人渐进最优路径规划 [J]. 仪器仪表学报, 2025, 46(5): 352-364.
- CHEN ZH SH, TIAN CH K, LIU K X, et al. MBIT* for asymptotically optimal path planning of mobile robot [J]. Chinese Journal of Scientific Instrument, 2025, 46(5): 352-364.
- [2] 张彪, 李永强. 基于动态寻优蚁群算法的移动机器人路径规划 [J]. 仪器仪表学报, 2025, 46(3): 74-85.
- ZHANG B, LI Y Q. Path planning of mobile robot based on the dynamic optimization ant colony algorithm [J]. Chinese Journal of Scientific Instrument, 2025, 46(3): 74-85.
- [3] 方敏, 金世俊. 基于蚁群算法和蝙蝠算法的多点路径规划 [J]. 电子测量技术, 2024, 47(18): 47-53.
- FANG M, JIN SH J. Multi-point path planning based on ant colony algorithm and bat algorithm [J]. Electronic Measurement Technology, 2024, 47(18): 47-53.
- [4] DORIGO M, DI CARO G, GAMBARDELLA L M. Ant algorithms for discrete optimization [J]. Artificial Life, 1999, 5(2): 137-172.
- [5] 邓冬冬, 许建民, 孟寒, 等. 基于蚁群算法与人工势场法融合的移动机器人路径规划 [J]. 仪器仪表学报, 2025, 46(2): 1-16.
- DENG D D, XU J M, MENG H, et al. Mobile robot path planning based on the fusion of ant colony algorithm and artificial potential field method [J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 1-16.

- and artificial potential field method [J]. Chinese Journal of Scientific Instrument, 2025, 46(2): 1-16.
- [6] LIU CH, WU L, XIAO W SH, et al. An improved heuristic mechanism ant colony optimization algorithm for solving path planning [J]. Knowledge-Based Systems, 2023, 271: 110540.
- [7] LI G X, LIU CH, WU L, et al. A mixing algorithm of ACO and ABC for solving path planning of mobile robot [J]. Applied Soft Computing, 2023, 148: 110868.
- [8] TANG K Z, WEI X F, JIANG Y H, et al. An adaptive ant colony optimization for solving large-scale traveling salesman problem [J]. Mathematics, 2023, 11(21): 4439.
- [9] LI P, WEI L, WU D S. An intelligently enhanced ant colony optimization algorithm for global path planning of mobile robots in engineering applications [J]. Sensors, 2025, 25(5): 1326.
- [10] FANG SH K, DENG ZH W, LI P, et al. Improved strategy of ant colony optimization for path planning via stochastic pheromone updating and cyclic initialization [J]. Journal of Mechanical Science and Technology, 2025, 39(4): 2051-2062.
- [11] YU J, YOU X M, LIU SH. A heterogeneous guided ant colony algorithm based on space explosion and long-short memory [J]. Applied Soft Computing, 2021, 113: 107991.
- [12] CHEN T, CHEN S F, ZHANG K R, et al. A jump point search improved ant colony hybrid optimization algorithm for path planning of mobile robot [J]. International Journal of Advanced Robotic Systems, 2022, 19(5): 17298806221127953.
- [13] CUI J G, WU L, HUANG X D, et al. Multi-strategy adaptable ant colony optimization algorithm and its application in robot path planning [J]. Knowledge-Based Systems, 2024, 288: 111459.
- [14] 谷依田, 张涛, 张亮, 等. 面向多无人车的目标点分配和协同路径规划算法 [J]. 仪器仪表学报, 2024, 45(3): 263-274.
- GU Y T, ZHANG T, ZHANG L, et al. Goal allocation and cooperative path finding for multiple UGVs [J]. Chinese Journal of Scientific Instrument, 2024, 45(3): 263-274.
- [15] 曾宪阳, 张加旺. 改进 A 算法融合 DWA 机器人路径规划研究 [J]. 电子测量技术, 2025, 48(6): 20-27.
- ZENG X Y, ZHANG J W. Path planning for robots with improved A algorithm and fused DWA [J]. Electronic Measurement Technology, 2025, 48(6): 20-27.
- [16] 王勤, 魏利胜. 基于改进 HLO 和动态窗口的 AGV 动态避障路径规划算法 [J]. 电子测量与仪器学报, 2025, 39(2): 213-221.
- WANG Q, WEI L SH. Dynamic obstacle avoidance path planning algorithm for AGVs based on improved HLO and dynamic windows [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(2): 213-221.
- [17] TAN Y SH, OUYANG J, ZHANG ZH, et al. Path planning for spot welding robots based on improved ant colony algorithm [J]. Robotica, 2023, 41(3): 926-938.
- [18] 曾宪阳, 于浩, 梁远生, 等. LIO-SAM 改进: 自适应降采样与特征筛选优化 [J]. 仪器仪表学报, 2025, 46(7): 288-296.
- ZENG X Y, YU H, LIANG Y SH, et al. Improved LIO-SAM: Adaptive downsampling and feature selection optimization [J]. Chinese Journal of Scientific Instrument, 2025, 46(7): 288-296.
- [19] WANG H X, WANG SH H, YU T. Path planning of inspection robot based on improved ant colony algorithm [J]. Applied Sciences, 2024, 14(20): 9511.
- [20] LIANG CH D, PAN K, ZHAO M, et al. Multi-node path planning of electric tractor based on improved whale optimization algorithm and ant colony algorithm [J]. Agriculture, 2023, 13(3): 586.
- [21] 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.
- [22] 张恒, 何丽, 袁亮, 等. 基于改进双层蚁群算法的移动机器人路径规划 [J]. 控制与决策, 2022, 37(2): 303-313.
- ZHANG H, HE L, YUAN L, et al. Mobile robot path planning using improved double-layer ant colony algorithm [J]. Control and Decision, 2022, 37(2): 303-313.
- [23] 肖金壮, 余雪乐, 周刚, 等. 一种面向室内 AGV 路径规划的改进蚁群算法 [J]. 仪器仪表学报, 2022, 43(3): 277-285.
- XIAO J ZH, YU X L, ZHOU G, et al. An improved ant colony algorithm for indoor AGV path planning [J]. Chinese Journal of Scientific Instrument, 2022, 43(3): 277-285.
- [24] TUANI A F, KEEDWELL E, COLLETT M. Heterogeneous adaptive ant colony optimization with 3-opt local search for the travelling salesman problem [J]. Applied

- Soft Computing Journal, 2020, 97: 106720.
- [25] LI H M, LI P. Self-adaptive ant colony optimization for construction time-cost optimization [J]. Kybernetes, 2013, 42(8): 1181-1194.
- [26] 王鸿浩,王辉. 基于竞争协作的蚁群算法云计算任务调度[J]. 火力与指挥控制,2024,49(12):180-186,201.
- WANG H H, WANG H. Cloud computing task scheduling based on competitive-cooperative ant colony algorithm[J]. Fire Control & Command Control, 2024, 49(12):180-186,201.
- [27] LIN B CH, MEI Y, ZHANG M J. Automated design of state transition rules in ant colony optimization by genetic programming: A comprehensive investigation[J]. Memetic Computing, 2025, 17(1): 1-22.
- [28] FU X W, ZHAO H, LI H Y, et al. Elite quantum ant colony algorithm based on double chain encoding for static optimization problems [J]. Applied Intelligence, 2025, 55(17):1106-1129.

作者简介



曾宪阳,2003 年于襄樊学院获学士学位,2009 年于浙江师范大学获硕士学位,2018 年于南京大学获博士学位。现为南京工程学院教授,主要研究方向为智能机器人控制、电工电子技术。
E-mail:zxymcu@163.com

Zeng Xianyang received his B. Sc. degree from Xiangfan

University in 2003, his M. Sc. degree from Zhejiang Normal University in 2009, and his Ph. D. degree from Nanjing University in 2018. He is currently a professor at Nanjing Institute of Technology. His main research interests include intelligent robot control, electrical and electronic technology.



梁远生(通信作者),2022 年于获得机
械工程学士学位,目前正在南京理工大学紫
金学院攻读硕士学位。主要研究方向为路
径规划、SLAM、机械结构设计。
E-mail:1789353609@qq.com

Liang Yuansheng (Corresponding author)

received his B. Sc. degree from Nanjing University of Science and Technology Zijin College in 2022. He is currently pursuing his master's degree at Nanjing University of Science and Technology. His main research interests include path planning, SLAM, mechanical structure design.



杨红莉,2003 年于山西大学获学士学
位,2009 年于南京大学获博士学位,现为南
京工程学院副教授,主要研究方向为数值
分析。

E-mail:yanghongli1016@163.com

Yang Hongli received her B. Sc. degree from Shanxi University in 2003, and her Ph. D. degree from Nanjing University in 2009. She is currently an associate professor at Nanjing Institute of Technology. Her main research interest includes numerical analysis.