

基于改进蚁群-动态窗口融合算法的室内服务机器人路径规划

马伟杰, 姚舜才, 马敏毓, 蔚鹏飞

(中北大学电气与控制工程学院, 山西 太原 030000)

摘要: 针对无法规避动态障碍的全局规划及可能陷入局部最优解的局部规划问题, 提出一种应用于室内服务机器人的改进蚁群 (ant colony optimization, ACO)-动态窗口 (dynamic window approach, DWA) 融合的路径规划算法。首先, 针对蚁群算法搜索速度较慢的缺陷, 对启发因子进行优化, 并基于差速机器人运动模型优化搜索邻域, 以提高搜索效率; 其次, 针对蚁群算法形成路径无法保证安全距离等缺陷, 引入新的避障策略, 对路径进行折线优化操作; 最后, 融合改进蚁群算法与动态窗口算法, 确保机器人实现精确动态避障。实验结果证明, 改进后的融合算法相较于蚁群-动态窗口算法, 能够更好地保证机器人在有随机障碍物的路段安全通行。

关键词: 室内服务移动机器人; 路径规划; 动态避障; 改进蚁群-动态窗口算法

中图分类号: TP242.6

文献标志码: A

doi: 10.11959/j.issn.2096-6652.ZNKX26031

Path planning for indoor service robots using an improved ACO-DWA hybrid algorithm

Ma Weijie, Yao Shunca, Ma Minyu, Yu Pengfei

School of Electrical and Control Engineering, North University of China, Taiyuan 030000, China

Abstract: To address the limitation that global path planning algorithms struggle with dynamic obstacle avoidance and local path planning algorithms were susceptible to local optima, an improved hybrid algorithm was proposed combining the ant colony optimization (ACO) and dynamic window approach (DWA) for indoor service robots. Firstly, aiming at the low search efficiency of the traditional ACO algorithm, the heuristic factors were optimized, and the search neighborhood was reconstructed based on the differential drive robot motion model to enhance the global searching efficiency. Secondly, a novel obstacle avoidance strategy and path polyline optimization method were adopted to solve the deficiency that the original ACO-generated paths fail to guarantee reliable safety distances around obstacles. Finally, the improved ACO algorithm was integrated with the dynamic window approach to achieve accurate and stable dynamic obstacle avoidance. Experimental results demonstrate that compared with the conventional ACO-DWA algorithm, the proposed hybrid algorithm enables service robots to travel safely in complex scenarios with random dynamic obstacles.

Key words: indoor service mobile robot, path planning, dynamic obstacle avoidance, improved ACO-DWA

0 引言

在技术迭代加速的当下, 机器人技术展现出巨大的应用潜力, 室内服务型机器人凭借其场景适配性, 已成为机器人领域的研究热点^[1]。但随着室内环境愈发复杂, 路径规划作为保障机器人自主移动

的核心技术, 正面临诸多待解难题, 例如, 如何实时规避动态障碍物、怎样提升路径规划的整体效率等^[2]。

室内路径规划算法基本分为两大类: (1) 全局路径规划算法, 传统的路径规划算法包括 Dijkstra 算法、A* 算法、蚁群算法等, 近年来, 基于采样

收稿日期: 2026-03-11; 修回日期: 2026-06-01

通信作者: 姚舜才, yaoshunca@nuc.edu.cn

的新型方法（如RRT、RRT*）以及机器学习方法也开始得到广泛应用^[3]，该类算法以环境地图全局信息已知为前提，通过系统性搜索策略找到从起点到目标点的可行路径，是自主移动设备（如机器人、无人机）导航的核心基础；（2）局部路径规划算法，目前主要有动态窗口算法、人工势场算法等，该类算法通过对当前环境中存在的固定障碍物或移动障碍物进行识别与实时路径规划，实现在复杂环境中的动态避障功能^[4]。

全局路径规划算法和局部路径规划算法均存在显著局限性：前者依赖全知的静态环境地图，虽能结合起止点生成相对较优的全局路径，但对动态障碍物缺乏实时响应能力，遇到突发移动障碍或未更新的临时障碍时原路径易失效，且大规模环境中搜索效率会明显下降；后者虽能通过实时感知环境识别固定与移动障碍物，实现动态避障，但受限于局部视野的“短视性”，往往难以兼顾全局目标，不仅容易陷入局部最优陷阱，还可能因过度避让近距离障碍产生迂回路径，降低导航效率，甚至因感知盲区引发碰撞风险^[5]。

近年来，随着人工智能技术的迭代，数据驱动与智能学习赋能的路径规划方法成为研究热点，逐步弥补传统几何搜索、群智能优化算法在动态适应性、未知环境泛化性方面的局限性。基于深度学习的路径规划方法，如卷积神经网络（CNN）、图神经网络（GNN）、Transformer等架构，通过海量环境数据集训练实现端到端路径决策，能够自主挖掘环境特征与避障逻辑，对未知复杂环境的适应性显著提升，但此类方法高度依赖大规模标注数据集与算力支撑，模型泛化能力严重受场景分布限制，在室内非结构化、动态扰动频繁的环境中易出现决策漂移，且模型推理计算复杂度高，难以满足低成本嵌入式机器人平台的实时性避障需求；基于强化学习的规划方法，如深度Q网络（DQN）、近端策略优化（PPO）等经典算法，通过机器人与动态环境的持续交互试错优化决策策略，无须预设环境模型即可自主学习避障规则，具备较强的在线自适应与动态响应能力，然而此类方法普遍存在训练周期冗长、奖励函数设计难度大、样本利用效率低等问题，在密集动态障碍物场景中易出现策略震荡与收敛不稳定，且训练所得策略缺乏全局最优性约束，难以兼顾路径最优性与避障安全性，在室内服务机器人标准化、低成本部署场景中适

用性受限^[6]。

文献[2]虽已开展改进蚁群与动态窗口融合的机器人路径规划研究，但其仅采用简单串行拼接架构，将蚁群算法生成的全局路径直接交由动态窗口算法跟踪，既未结合室内服务机器人的安全距离约束与差速运动模型进行针对性优化，也未从安全导向层面重构蚁群启发因子与信息素奖惩机制，在室内狭窄通道、人员流动密集的动态场景中易存在安全距离不足、路径迂回及算法切换振荡等缺陷；针对传统全局规划难以应对动态障碍、局部规划易陷入局部最优，以及深度学习、强化学习等前沿智能方法依赖海量数据集与高算力、室内场景泛化性不足的共性短板，本文以蚁群全局规划算法与动态窗口局部规划算法为研究基础，分别解决蚁群算法易早熟收敛、陷入局部最优以及动态窗口算法缺少全局路径约束引导的固有问题，完成双算法协同改进与深度融合，并基于MATLAB搭建仿真环境开展对比实验，验证本文改进融合算法的有效性与优越性，旨在为室内服务机器人提供一种兼顾路径全局最优、高精度动态避障与工程高效部署的路径规划解决方案。

1 改进蚁群融合动态窗口算法

1.1 蚁群算法的基本原理

在现实中，蚂蚁寻找食物时会释放信息素，同时能够感知其他蚂蚁释放的信息素。路径上信息素的浓度代表了路径的吸引力，浓度越高则路径越短。一般来说，蚂蚁倾向于选择浓度较高的路径，并在其经过的路径上释放信息素，从而增强该路径的吸引力，形成一种正反馈机制^[7]。最终，通过这种协作与竞争的过程，蚂蚁能够找到从源到目的地的最佳路径，即最短路径^[8]。蚁群概率转移表达式为：

$$p_{ij}^k(n) = \begin{cases} \frac{[\tau_{ij}(n)]^\alpha [\eta_{ij}(n)]^\beta}{\sum_{s \in J_k(i)} [\tau_{is}(n)]^\alpha [\eta_{is}(n)]^\beta}, & j \in J_k(i) \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中， α 表示信息素相对重要的程度； β 表示启发因子的相对重要程度； J_k 表示蚂蚁 k 在点 i 时下一步允许选择的方块集合； τ 表示从第 i 个目标点到第 j 个目标点间路径的信息素浓度； η 表示启发因子的大小，其值为路径长度的倒数； n 为当前迭代

次数； $\eta_{ij}(n)$ 其值为该点到终点距离的倒数，即：

$$\eta_{ij}(n) = \frac{1}{L_k(j, \text{end})} \quad (2)$$

所有可选目标点的转移概率计算完毕后，使用轮盘赌算法进行最终的选择，表达式为：

$$q_j = \sum_{j=1}^M p_{ij}^k(n) \quad (3)$$

其中， q 相当于转盘上的跨度，跨度越大的区域越容易选到； M 代表下一步可选路径的数量。

$$\tau_{ij}(n+1) = (1-\rho)\tau_{ij}(n) + \Delta\tau_{ij} \quad (4)$$

$$\Delta\tau_{ij} = \sum_{k=1}^m \Delta\tau_{ij}^k \quad (5)$$

$$\Delta\tau_{ij}^k = \frac{\lambda Q}{L_k(j, \text{end})} \quad (6)$$

其中， τ 表示从第*i*个栅格点到第*j*个栅格点中间路径上的信息素； m 表示蚂蚁种群一个世代的迭代数量； ρ 为信息素挥发因子，模拟真实蚂蚁信息素在自然环境下的挥发，因此其取值范围为(0, 1)； Q 为一个正实数，代表蚂蚁体内携带的信息素总储量，走完路径后全部释放在沿途路段； λ 表示第*k*只蚂蚁是否走过*i*到*j*这条路，若走过则为1，否则为0。当所有蚂蚁完成一个世代的迭代后，更新各条路径上的信息素。

依托上述状态转移、轮盘选择、信息素更新三大迭代运算规则，蚁群算法会在多次迭代中不断收敛至近似最优解^[9]。

1.2 改进蚁群算法

机器人的感知、决策环节存在天然误差，安全距离可作为“容错缓冲”，避免这些误差演变为安全事故，而室内服务机器人更需要对人类安全负责，因此本文通过改进启发因子 η_{ij} ，让蚂蚁更倾向于选择更安全的节点^[10]。

设“安全距离”为 d_{safe} ，本文根据分层安全约束体系、动态切换机制与系统设计容限，预处理障碍物信息，快速计算节点与障碍物的距离。设定蚁群全局规划层，其中： $d_{\text{safe}}=0.5$ m是包含全链路容限的几何安全基准，表示路径上的点与任何障碍物的最小允许距离。

蚁群路径规划阶段将机器人抽象为质点模型，约束 $D_{\text{obs}} \geq 0.5$ m限制的是全局路径中心线到静态障碍物轮廓的最小几何距离。该阈值并非单纯的安全距离要求，而是预先设定了一定的安全容限。系统

安全容限量化分解与权值分配见表1^[11]，其中，上容限为安全距离向上对应误差的典型值，下容限为安全距离向下系统可承受的最大误差值，最大总预留容限取各分项下容限之和。

表1 系统安全容限量化分解与权值分配

容限分项	容限		权值
	上容限/m	下容限/m	
传感器测量容限	0.05	0.05	0.25
执行器响应容限	0.03	0.03	0.25
环境扰动容限	0.01	0.02	0.25
局部调整容限	0.05	0.1	0.25

从表1可以看出，以上各容限权值一致，其核心作用是生成一条与障碍物保持一定安全距离的全局参考轨迹，为下层局部避障预留充足的动态调整空间，经实际安全距离各容限量化计算， $0.3 \text{ m} \leq d_{\text{safe}} \leq 0.64 \text{ m}$ ，可避免全局路径本身贴近障碍物导致局部规划无可行解。结合全链路容限的几何安全基准与实际安全距离，各容限量化计算结果可得 $0.3 \text{ m} \leq d_{\text{safe}} \leq 0.5 \text{ m}$ ，既从根源上避免全局路径本身贴近障碍物导致局部规划无可行解，又为动态窗口算法局部执行层预留了0.2 m的动态调整区间，允许其在0.3~0.5 m内根据狭窄通道、动态障碍物等实时场景自适应调整轨迹，实现了安全性与通行能力的动态平衡。

对区域中所有可通行节点（非障碍物节点），预计算其到最近障碍物的距离，存储在矩阵 $D_{\text{obs}}(i, j)$ 中（ i, j 为节点坐标）。若节点 (x, y) 到最近障碍物的距离 $D_{\text{obs}}(x, y) < d_{\text{safe}}$ ，则该节点为“不安全节点”，蚂蚁不可选择；若 $D_{\text{obs}}(x, y) \geq d_{\text{safe}}$ ，则为“安全节点”，蚂蚁可选择。

蚁群算法中，蚂蚁从当前节点*i*选择下一个节点*j*时，需从“可选集合*J*”中挑选（*J*包含非障碍物、未走过的节点）。加入安全距离后，需对*J*增加安全约束，表达式为：

$$J = \{j | j \notin \text{障碍物}, j \notin \text{已走过路径}, D_{\text{obs}}(j) \geq d_{\text{safe}}\} \quad (7)$$

在蚂蚁每次选择下一个节点前，先过滤掉所有“不安全节点”（距离障碍物小于 d_{safe} ），仅保留安全节点作为候选。这一步确保蚂蚁完全避开可能碰撞的区域。

原启发因子 η_{ij} 通常仅考虑节点*j*到终点的距离

(如距离终点 $\eta_{ij} = \frac{1}{L_k(j, \text{end})}$)。加入安全因素后, 可将 η_{ij} 定义为“目标导向”与“安全导向”的乘积, 表达式为:

$$\eta_{ij} = \left(\frac{1}{L_k(j, \text{end})} \right) \left(\frac{D_{\text{obs}}(j)}{d_{\text{safe}}} \right)^\gamma \quad (8)$$

其中, $\gamma > 0$ 为安全因子的权重 (γ 越大, 蚂蚁越倾向于选择远离障碍物的节点); $\frac{D_{\text{obs}}(j)}{d_{\text{safe}}}$ 表示节点 j 的“安全冗余度”(大于或等于 1, 值越大越安全)。本文通过引入 $\left(\frac{D_{\text{obs}}(j)}{d_{\text{safe}}} \right)^\gamma$, 让安全冗余度更高的节点 j 拥有更高的选择概率。

本文采用线性形式的信息素奖惩函数, 核心设计逻辑为适配室内服务机器人路径规划的核心目标——在满足安全距离约束的前提下, 兼顾路径最优性、算法收敛稳定性与嵌入式平台的实时计算需求。相较于二次型、指数型及分段型奖惩函数, 线性形式的核心优势如下。

(1) 平衡安全性与路径最优性: 线性奖惩的力度与节点安全冗余度的偏差呈恒定梯度正相关, 可引导算法优先选择高安全冗余路径, 同时避免过度奖惩; 二次型奖惩易使算法过度偏向迂回路径、增加路径长度; 指数型奖惩对安全冗余变化过于敏感, 易过度压缩可行搜索空间, 甚至在狭窄室内场景中无可行解。

(2) 保障算法收敛稳定性: 线性函数梯度恒定, 迭代过程中信息素更新平稳, 可避免收敛震荡, 降低陷入局部最优的概率, 匹配本研究针对蚁群的改进目标; 二次型、指数型奖惩的梯度随偏差剧烈变化, 易导致信息素分布极端化, 削弱算法全局搜索能力。

为了让算法长期倾向于选择安全路径, 可在信息素更新时对“安全路径”给予额外奖励, 对“边缘安全路径”(刚好满足安全距离)进行适当惩罚^[12]。

对“安全路径”给予额外奖励措施, 蚂蚁完成路径后, 若路径上所有节点的安全冗余度 $\frac{D_{\text{obs}}(j)}{d_{\text{safe}}} \geq \theta$ ($\theta > 1$), 则在信息素更新时额外增加信息素浓度, 表达式为:

$$\tau_{ij} = (1 - \rho)\tau_{ij} + \sum_k \frac{Q}{L_k} \left(1 + \omega \cdot \max \left(0, \frac{D_{\text{obs}}(j)}{d_{\text{safe}}} - \theta \right) \right) \quad (9)$$

其中, $\omega > 0$ 为奖励系数, 安全冗余度越高, 奖励越多。

对“边缘安全路径”给予惩罚措施, 若路径上存在节点 j 满足 $d_{\text{safe}} \leq D_{\text{obs}}(j) < \theta \cdot d_{\text{safe}}$ (“边缘安全”), 则降低其信息素更新量, 表达式为:

$$\tau_{ij} = (1 - \rho)\tau_{ij} + \sum_k \frac{Q}{L_k} \left(1 - \omega \left(1 - \frac{D_{\text{obs}}(j)}{d_{\text{safe}}} \theta \right) \right) \quad (10)$$

蚂蚁从节点 i 到 j 的转移概率 P_{ij}^k 表达式为:

$$P_{ij}^k = \frac{(\tau_{ij})^\alpha (\eta_{ij})^\beta}{\sum_{s \in J} (\tau_{is})^\alpha (\eta_{is})^\beta} \quad (11)$$

加入安全惩罚后, 可修改为:

$$P_{ij}^k = \frac{(\tau_{ij})^\alpha (\eta_{ij})^\beta \left(\frac{D_{\text{obs}}(j)}{d_{\text{safe}}} \right)^\gamma}{\sum_{s \in J} (\tau_{is})^\alpha (\eta_{is})^\beta \left(\frac{D_{\text{obs}}(s)}{d_{\text{safe}}} \right)^\gamma} \quad (12)$$

对路径折线平滑优化数学模型如下。

设原始离散路径序列为 $\{p_1, p_2, \dots, p_n\}$, 取连续 3 点 p_i, p_{i+1}, p_{i+2} , 线段 $p_i p_{i+2}$ 的最小安全距离判定条件为:

$$\min_{p \in p_i p_{i+2}} D_{\text{obs}}(p) \geq d_{\text{safe}} \quad (13)$$

若满足式 (13), 则删除冗余拐点, 完成路径拉直, 即:

$$P_{\text{smooth}} = P_{\text{raw}} - \{p_{i+1}\} \quad (14)$$

迭代遍历全部路径点, 最终输出全局最短平滑安全路径。

1.3 动态窗口算法

动态窗口算法 (DWA) 是基于预测控制理论的一种方法, 动态窗口算法的核心思想是根据移动机器人当前的位置状态和速度状态, 在速度空间 ($\mathbf{v}, \boldsymbol{\omega}$) 中确定一个满足移动机器人硬件约束的采样速度空间, 然后计算移动机器人在这些速度情况下移动一定时间内的轨迹, 并通过评价函数对该轨迹进行评价, 最后选出评价最优的轨迹所对应的速度作为移动机器人运动速度, 如此循环直至移动机器人到达目标点^[13]。

动态窗口算法主要包括 3 个步骤: 速度采样、轨迹预测、轨迹评价。

受限于移动机器人硬件、结构和环境等条件, 移动机器人的速度采样空间有一定的范围限制。该限制主要分为3类。

(1) 速度边界限制

根据移动机器人的硬件条件和环境限制, 移动机器人的速度存在边界限制, 此时可采样的速度空间为:

$$V_m = \left\{ (\mathbf{v}, \boldsymbol{\omega}) \mid \mathbf{v} \in [v_{\min}, v_{\max}], \boldsymbol{\omega} \in [\omega_{\min}, \omega_{\max}] \right\} \quad (15)$$

其中, $v_{\min}$ 和 $v_{\max}$ 分别为移动机器人最小线速度和最大线速度, $\omega_{\min}$ 和 $\omega_{\max}$ 分别为移动机器人最小角速度和最大角速度。

(2) 加速度限制

由于移动机器人驱动电机的限制, 移动机器人线加速度和角加速度均存在边界限制, 假设最大加速度和减速度数值相等, 故考虑加速度时可采样的速度空间为:

$$V_d = \left\{ (\mathbf{v}, \boldsymbol{\omega}) \mid \mathbf{v} \in [v_c - a_{v_{\max}} \Delta t, v_c + a_{v_{\max}} \Delta t], \right. \\ \left. \boldsymbol{\omega} \in [\omega_c - a_{\omega_{\max}} \Delta t, \omega_c + a_{\omega_{\max}} \Delta t] \right\} \quad (16)$$

其中, v_c 、 ω_c 分别为移动机器人当前时刻的线速度和角速度, $a_{v_{\max}}$ 、 $a_{\omega_{\max}}$ 分别为移动机器人最大线加速度和最大角加速度。

(3) 环境障碍物限制

局部规划还需要考虑动态实时的避障功能。考虑机器人周围的障碍物因素, 某一时刻移动机器人不与周围障碍物发生碰撞的可约束条件为:

$$V_d = \left\{ (\mathbf{v}, \boldsymbol{\omega}) \mid \mathbf{v} \in [v_{\min}, \sqrt{2 \cdot \det(\mathbf{v}, \boldsymbol{\omega}) \cdot a_{v_{\max}}}], \right. \\ \left. \boldsymbol{\omega} \in [\omega_{\min}, \sqrt{2 \cdot \det(\mathbf{v}, \boldsymbol{\omega}) \cdot a_{\omega_{\max}}}] \right\} \quad (17)$$

其中, $\det(\mathbf{v}, \boldsymbol{\omega})$ 表示当前速度下对应模拟轨迹与障碍物之间的最近距离。在无障碍物的情况下 $\det(\mathbf{v}, \boldsymbol{\omega})$ 会是一个很大的常数值。当机器人运行采样速度在式 (17) 范围内时, 能够以最大减速度的约束实现安全减速直至避开障碍物^[14]。

结合上述3类速度限制, 最终确定的移动机器人速度采样空间是3个速度空间的交集^[15], 即:

$$V_s = V_m \cap V_d \cap V_a \quad (18)$$

完成速度采样空间筛选后, 对窗口内每一组线速度与角速度组合, 基于差速驱动机器人的运动学特性, 以当前位姿为起点向前推演固定时长的运动过程, 生成对应的离散预测轨迹。后续方位角、障

碍物距离、行驶速度及全局轨迹贴合度4项评价指标, 均以该预测轨迹为计算依据。在此基础上, 本文构建四元加权综合评价函数, 融合方位角、障碍物距离、行驶速度、全局轨迹贴合度4项指标, 对预测轨迹进行综合评价, 评价价值越高代表轨迹综合性能越优。评价函数表达式为:

$$G(\mathbf{v}, \boldsymbol{\omega}) = k_{\theta} G_{\theta}(\mathbf{v}, \boldsymbol{\omega}) + k_{\text{obs}} G_{\text{obs}}(\mathbf{v}, \boldsymbol{\omega}) + k_v G_v(\mathbf{v}, \boldsymbol{\omega}) + k_t G_t(\mathbf{v}, \boldsymbol{\omega}) \quad (19)$$

其中, k_{θ} 、 k_{obs} 、 k_v 、 k_t 分别为方位角、障碍物距离、速度、全局轨迹贴合度的权重系数。

(1) 方位角评价项

方位角评价项 $G_{\theta}(\mathbf{v}, \boldsymbol{\omega})$ 表征预测轨迹航向与目标方向的契合程度, 计算式为:

$$G_{\theta}(\mathbf{v}, \boldsymbol{\omega}) = 1 - \frac{|\Delta\theta|}{\pi} \quad (20)$$

其中, $\Delta\theta$ 为机器人预测姿态角与目标航向角的差值, 航向偏差越小, 该项取值越大。

(2) 障碍物距离评价项

$G_{\text{obs}}(\mathbf{v}, \boldsymbol{\omega})$ 表征预测轨迹的避障安全裕度, 计算式为:

$$G_{\text{obs}}(\mathbf{v}, \boldsymbol{\omega}) = \begin{cases} \frac{d_{\text{real}}}{d_{\text{max}}}, & d_{\text{real}} \geq d_{\text{safe}} \\ 0, & d_{\text{real}} < d_{\text{safe}} \end{cases} \quad (21)$$

其中, d_{real} 为预测轨迹与最近障碍物的实时距离, d_{max} 为机器人最大障碍检测距离。当轨迹距离小于安全距离阈值时, 该项置0, 直接排除该组速度。

(3) 速度评价项

速度评价项 $G_v(\mathbf{v}, \boldsymbol{\omega})$ 表征轨迹的通行效率, 计算式为:

$$G_v(\mathbf{v}, \boldsymbol{\omega}) = \frac{v}{v_{\max}} \quad (22)$$

其中, v 为当前采样线速度, $v_{\max}$ 为机器人最大线速度, 速度越高该项取值越大。

(4) 全局轨迹贴合度评价项

全局轨迹贴合度评价项 $G_t(\mathbf{v}, \boldsymbol{\omega})$ 用于约束局部规划轨迹跟踪改进蚁群算法输出的全局参考路径, 避免局部规划偏离导航主线, 计算式为:

$$G_t(\mathbf{v}, \boldsymbol{\omega}) = 1 - \frac{\bar{L}}{L_{\text{total}}} \quad (23)$$

其中, $\bar{L}$ 为预测轨迹与全局参考路径的平均欧氏距离, L_{total} 为全局参考路径总长度。平均距离越小, 局部轨迹与全局路径贴合度越高, 该项评价价值越大。

为实现改进蚁群全局规划与动态窗口局部规划的稳定协同切换, 本文建立了基于障碍物安全距离阈值的分层调度数学判据。设机器人实时检测得到的最近障碍物距离为 d_{real} , 预设机器人安全防护距离为 d_{safe} , 当满足 $d_{\text{real}} \geq d_{\text{safe}}$ 时, 室内环境无安全隐患, 机器人以改进蚁群算法输出的平滑全局路径为基准, 进入全局轨迹跟踪模式, 依靠动态窗口算法完成速度优化与轨迹微调, 保证导航路径的最优性与高效性; 当传感器检测到未知静态障碍或动态移动障碍侵入安全范围, 满足 $d_{\text{real}} < d_{\text{safe}}$ 时, 判定当前区域存在碰撞风险, 立即暂停全局轨迹跟踪任务, 切换为局部紧急避障模式, 优先利用动态窗口算法的实时环境响应能力规避障碍物。直至机器人驶离危险区域、实时障碍物距离重新满足 $d_{\text{real}} \geq d_{\text{safe}}$, 系统自动复位全局跟踪状态, 继续沿最优全局路径完成导航任务^[16-17]。

1.4 改进蚁群-动态窗口融合算法实现伪代码

改进蚁群-动态窗口融合算法的实现伪代码如下算法1所示。

算法1 改进蚁群-动态窗口融合算法

输入 栅格地图、机器人差速运动约束、蚁群与动态窗口算法超参数、安全距离阈值 d_{safe}

输出 全局最优路径、实时导航轨迹、路径长度、运行时间等性能指标

1) 初始化模块

2) initialize 栅格地图、机器人差速运动约束、算法超参数与安全阈值

3) initialize 初始信息素浓度、最大迭代次数、路径起点与终点位姿

4) 环境预处理模块

5) preprocess 全局障碍物信息, 计算各节点到最近障碍物的距离矩阵 D_{obs}

6) 筛选满足 $D_{\text{obs}} \geq d_{\text{safe}}$ 的可行节点集合, 剔除危险栅格

7) 改进蚁群全局路径规划模块

8) while 迭代次数未达到最大值

9) 清空当前迭代所有蚂蚁的路径解集

10) for 每一只蚂蚁

11) initialize 蚂蚁禁忌表与当前行走路径

12) while 蚂蚁未到达终点

13) 基于差速运动模型构建扇

形可行搜索邻域

14) 计算节点安全冗余系数, 构建安全-距离融合启发函数

15) 计算改进状态转移概率, 轮盘赌算法选取下一安全节点

16) 更新蚂蚁行走路径与禁忌集合

17) end while

18) 记录本次迭代最优路径长度

19) end for

20) 根据路径安全等级执行自适应信息素奖惩更新

21) 完成信息素挥发与全局迭代更新

22) end while

23) 路径折线平滑优化模块:

24) for 遍历全局离散路径的所有连续3点序列

25) if 跨拐点连线全程满足安全约束 $D_{\text{obs}} \geq d_{\text{safe}}$

26) 删除冗余拐点, 完成路径拉直优化

27) end if

28) end for

29) 输出平滑后的全局最优参考路径

30) 动态窗口局部融合导航模块:

31) while 机器人未抵达终点

32) 实时采集机器人位姿与环境障碍物距离

33) 构建多约束速度采样空间

34) 融合方位、避障、速度、全局轨迹贴合度评价最优轨迹

35) if $d_{\text{real}} < d_{\text{safe}}$

36) 执行局部紧急动态避障

37) else

38) 跟踪改进蚁群全局平滑路径

39) end if

40) 更新机器人差速运动位姿

41) end while

42) 返回: 路径长度、运行时间等导航性能指标

2 算法参数与实验环境设置

本文将改进的蚁群-动态窗口融合算法应用于室内服务机器人路径规划，以验证算法的可行性及有效性。实验环境为 Windows 10、Matlab R2022a，处理器为 Intel Core i5-11400H，主频为 2.70 GHz，内存为 16 GB。

本文的实验为仿真实验，由于驱动系统和机械结构的限制，室内服务型机器人的运动参数存在明确约束，本文指定机器人参数特性见表2，其中最大线速度、最大线加速度由机器人电机决定，最大角速度受差速驱动结构限制^[18]，对应最小转弯半径 0.3 m，最小转弯半径由轮距（250 mm）与最大角速度共同决定，适配室内 90°直角转弯（通道宽度≥800 mm），运动闭环 PID 控制，确保低速（<0.5 m/s）下轨迹跟踪误差≤±30 mm^[19]。

表2 机器人参数特性

参数	数值
最大线速度/(m·s ⁻¹)	1.2
最小线速度/(m·s ⁻¹)	0
最大角速度/(rad·s ⁻¹)	±1.5
最小转弯半径/m	0.3(最小)
最大线加速度/(m·s ⁻²)	0.8
最大线减速度/(m·s ⁻²)	0.8
最大角加速度/(rad·s ⁻²)	±2.5
障碍检测范围/m	0.1~5.0
速度控制精度	±5%

改进蚁群算法参数见表3，具体介绍如下。 m 代表蚂蚁数量，决定搜索范围与并行性，决定算法种群搜索规模与并行寻优能力； m 过小会导致种群多样性不足，算法易陷入局部最优、早熟收敛； m 过大会增加单次迭代的计算量，大幅提升路径规划耗时，降低算法实时性。 α 为信息素启发因子，控制蚂蚁对信息素浓度的依赖； α 取值越大，蚂蚁越信任过往优质路径，算法局部利用能力越强，但全局探索能力减弱； α 取值过小，则信息素引导作用弱化，算法搜索随机性过强，收敛速度大幅降低。 β 为期望启发因子，决定对启发式信息的重视程度； β 越大，蚂蚁越倾向于选择距离目标更近的路径，路径寻优效率越高，但取值过大会使算法过度贪婪，忽略安全约束与可行路径，易陷入障碍物死区；取值过小则路径

迂回、收敛速度缓慢。 γ 为安全因子，用于调控蚂蚁的避障偏好权重，引导算法优先搜索远离障碍物的可行路径，平衡路径长度与安全冗余。 ω 为安全奖励系数，对高安全冗余的无障碍路径施加额外信息素奖励，强化优质安全路径的正向引导作用，有效解决蚁群过度追求最短路径、忽略避障安全的问题。 ρ （ $0<\rho<1$ ）为信息素挥发系数，控制信息素衰减以平衡探索与利用。 τ_0 为初始信息素浓度，决定算法迭代初期所有路径的信息素基准水平，直接影响初始搜索的均匀性；合理的初始浓度可避免算法初期搜索偏聚，保证种群初始搜索的多样性。 N_c 为最大迭代次数，作为终止条件之一^[20-21]。

表3 改进蚁群算法参数

参数	数值
m	50
α	1
β	7
γ	0.1
ω	1
ρ	0.1
τ_0	1
N_c	100

动态窗口算法参数见表4，其中，方位角评价系数 k_θ 用于表征机器人运动轨迹与目标航向的偏差程度，障碍物距离评价系数 k_{obs} 用于衡量预测轨迹与周边障碍物的最小安全距离，速度评价系数 k_v 用于表征机器人行进速度的优劣程度，全局轨迹贴合度系数 k_t 用于调控机器人实际行驶轨迹与全局参考路径的跟随精度^[22]。本文采用控制变量单因素敏感性分析法对动态窗口算法4项核心系数进行定量分析：固定其余参数不变，仅遍历单一参数合理取值区间，以实际运行路径长度、运行时间、平均安全距离为评价指标，探究各参数对机器人导航性能的影响规律，取表4所示参数进行多次实验。

表4 动态窗口算法参数

参数	敏感性分析实验数值	评价函数权重系数
k_θ	0.05	7.69%
k_{obs}	0.2	30.77%
k_v	0.3	46.15%
k_t	0.1	15.38%

方位角系数 k_θ 单因素敏感性分析见表5, 固定 $k_{\text{obs}}=0.2$ 、 $k_v=0.3$ 、 $k_t=0.1$, 含5组梯度取值的完整性性能数据。

表5 方位角系数 k_θ 单因素敏感性分析

k_θ	路径长度/m	运行时间/s	平均安全距离/m
0.01	24.86	122.56	0.41
0.03	24.35	119.23	0.43
0.05	24.11	117.94	0.45
0.07	24.28	120.15	0.44
0.09	24.53	123.42	0.42

方位角评价系数 k_θ 主要影响机器人航向指向性与轨迹平稳性。当取值较小时, 机器人对目标方向的约束较弱, 规划路径易出现迂回冗余; 当取值过大时, 航向校正过于频繁, 运动轨迹产生明显抖动与震荡。在合理区间内随着 k_θ 增大, 路径长度与运行时间先减小后增大, 平均安全距离呈现先升后降趋势, $k_\theta=0.05$ 时航向跟踪精度、轨迹平滑度与通行效率达到最佳匹配。

障碍物距离系数 k_{obs} 单因素敏感性分析见表6, 固定 $k_\theta=0.05$ 、 $k_v=0.3$ 、 $k_t=0.1$, 含5组梯度取值的完整性性能数据。

表6 障碍物距离系数 k_{obs} 单因素敏感性分析

k_{obs}	路径长度/m	运行时间/s	平均安全距离/m
0.1	23.95	115.68	0.32
0.2	24.11	117.94	0.45
0.3	24.42	121.36	0.53
0.4	24.75	125.82	0.61
0.5	25.13	130.45	0.68

障碍物距离评价系数 k_{obs} 是决定机器人避障安全冗余的核心参数。当取值偏小时, 机器人对障碍物约束权重低, 行驶轨迹贴近障碍物, 安全余量不足, 存在潜在碰撞风险; 随着取值增大, 机器人避让意识增强, 平均安全距离持续提升, 但同时产生过度避让行为, 导致路径拉长、运行耗时明显增加。综合安全距离与通行效率, $k_{\text{obs}}=0.2$ 既能保持充足安全间隔, 又不会产生不必要的绕行。

速度评价系数 k_v 参数单因素敏感性分析见表7, 固定 $k_\theta=0.05$ 、 $k_{\text{obs}}=0.2$ 、 $k_t=0.1$, 含5组梯度取值的完整性性能数据。

速度评价系数 k_v 主要调控机器人行进速度与避障安全性之间的平衡。当取值偏小时, 机器人偏

表7 速度评价系数 k_v 单因素敏感性分析

k_v	路径长度/m	运行时间/s	平均安全距离/m
0.1	24.10	135.72	0.46
0.2	24.10	124.38	0.45
0.3	24.11	117.94	0.45
0.4	24.28	118.25	0.40
0.5	24.26	117.63	0.35

好低速行驶, 运动过于保守, 任务完成时间显著增加; 取值逐步增大后, 行进效率明显提升, 但过高的速度权重会使机器人盲目追求快速通行, 削弱对障碍物的避让优先级, 平均安全距离下降, 动态避障响应变差。实验表明, $k_v=0.3$ 可在保证安全避障的基础上实现较高的导航效率。

全局轨迹贴合度系数 k_t 单因素敏感性分析见表8, 固定 $k_\theta=0.05$ 、 $k_{\text{obs}}=0.2$ 、 $k_v=0.3$, 含5组梯度取值的完整性性能数据。

表8 全局轨迹贴合度系数 k_t 单因素敏感性分析

k_t	路径长度/m	运行时间/s	平均安全距离/m
0.03	24.52	122.37	0.41
0.06	24.28	119.85	0.43
0.1	24.11	117.94	0.45
0.15	24.34	119.72	0.42
0.2	24.82	122.08	0.38

全局轨迹贴合度系数 k_t 用于调控机器人实际行驶轨迹与全局参考路径的跟随精度, 是平衡局部避障灵活性与全局路径一致性的核心参数。当取值偏小时, 全局路径约束作用较弱, 机器人局部避障自由度高, 易出现偏离参考路径的迂回绕行, 导致路径总长度与运行时间增加; 随着取值增大, 轨迹对全局路径的贴合度持续提升, 路径长度与运行耗时逐步缩短, 但过高的贴合权重会压缩局部避障的调整空间, 使机器人在障碍区域的避让幅度不足, 平均安全距离下降, 复杂场景下的通行安全性降低。实验表明, 当 $k_t=0.1$ 时, 全局路径跟踪精度与局部避障安全性达到良好平衡, 既保证了整体导航的路径一致性, 又预留了充足的局部避障调整余量, 适配室内人员密集的运行场景。

综合参数敏感性规律、室内安全约束与通行效率多指标折中优选, 最终通过归一化确定表4所示参数组合, 既能保证机器人平稳朝向目标行进, 又可在预留充足安全距离的前提下实现合理避障与高效通行^[23-24]。




图3 全局规划路径




图4 全局路径规划算法迭代性能

算法和改进A*算法的动态窗口融合算法仿真过程。

通过对比图6和图7可以发现,应用了改进后的蚁群-动态窗口融合算法的服务机器人在面对障

碍物时能够更好地把控安全距离。机器人在行驶至目标点的过程中,使用两种对比算法时,在第一次遇到静态障碍物时都能实现智能转向,沿着既定路线继续前进;当遇到移动障碍物时,机器人路径规划决策会优先考虑保障行程安全,实现紧急制动,直到移动障碍物经过后,机器人会继续按照全局规划路径前行,最终安全到达目标点。对比实验结果,应用改进后的算法规划路径效率更高,规划性能更优。

通过对比图7和图8可以发现,面对复杂障碍物环境时,搭载改进蚁群-动态窗口融合算法的服务机器人能够更为安全、高效地抵达目标位置。由于全局路径规划策略存在差异,改进A*-动态窗口融合算法在行进过程中多次出现激进避障行为,机器人与障碍物的安全距离过小,运动安全性无法得




图5 加入移动障碍物的全局路径规划算法

到有效保障。综合仿真结果表明,改进蚁群-动态窗口融合算法的整体规划效果优于改进A*-动态窗口融合算法。

针对3种算法分别开展10次独立重复仿真实验,结果如表9所示。采用均值 $\pm$ 标准差统计方式规避蚁群算法随机性带来的单次结果偏差,同时引入平均安全距离、最小安全距离作为安全性定量评价指标,从路径长度、规划耗时、通行效率、避障安全多维度进行对比分析。

与蚁群-动态窗口算法相比,改进蚁群-动态窗

口融合算法全局路径长度减少1.83 m,优化幅度为6.66%;全局路径规划时长降低10.4%;仿真路径长度减少2.046 m,优化幅度为7.82%;运动仿真用时缩短18.38 s,效率提升13.48%。在安全性能层面,平均安全距离由0.36 m提升至0.45 m,最小安全距离由0.24 m提升至0.31 m,机器人与障碍物碰撞风险有效降低。

相较于改进A*-动态窗口融合算法,本文算法全局路径长度减少1.54 m,优化幅度为5.67%;仿真路径长度减少1.861 m,优化幅度为7.16%;运


表9 3种算法路径规划性能指标对比(10次独立重复实验,均值 $\pm$ 标准差)

算法	全局路径长度/m	全局路径规划时长/s	仿真路径长度/m	运动仿真用时/s	平均安全距离/m	最小安全距离/m
蚁群-动态窗口	27.47 $\pm$ 0.32	0.817 $\pm$ 0.042	26.155 $\pm$ 0.28	136.32 $\pm$ 3.15	0.36 $\pm$ 0.02	0.24 $\pm$ 0.03
改进蚁群-动态窗口	25.64 $\pm$ 0.25	0.732 $\pm$ 0.035	24.109 $\pm$ 0.21	117.94 $\pm$ 2.68	0.45 $\pm$ 0.02	0.31 $\pm$ 0.02
改进A*-动态窗口	27.18 $\pm$ 0.30	0.729 $\pm$ 0.038	25.970 $\pm$ 0.26	133.34 $\pm$ 2.92	0.38 $\pm$ 0.02	0.26 $\pm$ 0.03


动仿真时间缩短 15.4 s, 通行效率提升 11.5%, 仅全局路径规划耗时小幅增加 0.003 s, 对实时性几乎无影响。安全指标上, 平均安全距离与最小安全

距离均高于改进 A* 融合算法, 避障约束更严格、运行更安全。


从标准差结果可以看出, 改进蚁群-动态窗口




(a) 初始导航状态




(b) 靠近动态障碍物




(c) 避让动态障碍物



(d) 开阔地带行驶



(e) 静态障碍绕行




(f) 抵达目标终点


图6 蚁群-动态窗口融合算法仿真过程

融合算法各指标标准差整体更小,说明算法多次运行结果波动低、收敛稳定性与鲁棒性更强。综合路径最优性、规划实时性、通行效率及避障安全冗余


4项维度,改进蚁群-动态窗口融合算法相比传统对比算法优势明显,更适配室内服务机器人动态复杂环境下的自主导航需求。




(a) 初始导航状态




(b) 靠近动态障碍物




(c) 检测到移动障碍



(d) 避让动态障碍物



(e) 狭窄地带通行



(f) 抵达目标终点

图7 改进蚁群-动态窗口融合算法仿真过程




图8 改进A*-动态窗口融合算法仿真过程

3.2 复杂环境中的改进蚁群-动态窗口仿真实验

为了验证改进蚁群-动态窗口算法在复杂动态环境中的有效性,在 30×30 的栅格区域进行模拟实验,复杂环境模拟结果如图9所示。为了仿真更真

实且更具挑战性的场景,本文加入了更多的移动障碍物和狭窄通道,生成 30×30 栅格模拟室内空间,黑色方块表示固定障碍物,每个正方形栅格的边长为1 m,设置坐标(2,2)为路径起点,坐标(29,




图9 复杂环境模拟结果




图11 加入移动障碍物和随机移动障碍物的全局路径规划结果

29) 为路径终点。

全局路径规划结果如图10所示,在30×30复杂环境中根据改进蚁群-动态窗口融合算法生成,以坐标(2,2)为路径起点到坐标(29,29)为路径终点的曲线表示全局路径规划结果,可以安全且快捷地实现从起点到终点的规划过程。




图10 全局路径规划

图11为复杂环境中加入固定移动障碍物和随机移动障碍物的全局路径规划结果。其中,坐标(10,19)的三角形为移动障碍物运动起始点,坐标(17,19)的圆圈为障碍物运动终止点;坐标(5,5)和坐标(8,13)的两个三角形对应坐标(25,24)和坐标(22,12)的圆圈,分别为随机生成的两个移动障碍物的起始点。改进蚁群-动态窗口融合算法仿真过程如图12所示。

由图12可以看出,改进蚁群-动态窗口融合算法驱动下的服务机器人在复杂场景中呈现出连贯且安全的路径规划动态运行过程。机器人在向目标点行驶的过程中,可自主感知周边障碍环境,在感应到静态障碍物时,能够完成智能转向操作,在合理把控安全距离的前提下平稳规避障碍,随后继续沿规划路线稳定前行。由图12(a)~图12(d)可知,当机器人在开阔空间中遇到移动障碍物时,会进行智能转向躲避障碍物安全通过;由图12(e)、图12(f)可知,在狭小空间遇到移动障碍物时,机器人路径规划系统会将行程安全作为核心决策依据,立即执行紧急制动指令,直至移动障碍物完全通过安全区域,再重新衔接全局规划路径持续行进;由图12(g)、图12(h)可知,机器人可沿全局规划路径稳定行进,最终成功实现从起点到终点的自主导航。整个运行过程中,机器人始终保持稳定的避障响应与路径跟踪能力,无碰撞、无路径偏离或运行中断情况,最终平稳、安全地抵达目标点。

4 结束语

本文针对室内服务机器人采用蚁群算法进行全局路径规划时,易陷入局部最优、收敛速度偏慢,且面对室内动态障碍物(如行人、临时摆放物品)时规避能力不足、安全系数较低的问题,结合室内服务场景对路径安全性、高效性的核心需求,提出针对性改进策略:通过引入适配室内布局的改进启发因子 η_{ij} ,设置贴合室内障碍物分布特点的安全距离阈值 d_{safe} ,确保机器人在走廊、房间等室内空




图12 改进蚁群-动态窗口融合算法仿真过程

间中可选路径的安全性; 通过设计信息素奖励与惩罚机制, 强化算法对室内环境中“既短又安全”路径(如避开拥堵区域、狭窄通道的最优路线)的长期记忆。其次, 将改进蚁群算法与动态窗口算法进行融合, 得到的融合算法弥补了单一静态规划算法无法让室内服务机器人安全通过室内随机出现障碍物的全局路径规划缺陷, 适配室内环境的动态变化特性。最后, 通过模拟室内复杂布局的仿真实验, 充分验证了改进融合算法的适配性与性能。对比蚁群-动态窗口算法, 改进后的融合算法针对室内服务机器人的全局规划路径长度优化幅度为6.66%, 全局规划时长降低10.4%, 室内场景下的仿真路径长度优化幅度为7.82%, 运动仿真效率提升13.48%, 平均安全距离由0.36 m提升至0.45 m, 最小安全距离由0.24 m提升至0.31 m, 机器人与障碍物的安全冗余显著增大, 碰撞风险有效降低。与改进A*-动态窗口融合算法相比, 本文算法全局路径长度优化幅度为5.67%, 仿真路径长度优化幅度为7.16%, 通行效率提升11.5%; 安全指标上, 平均安全距离与最小安全距离均高于改进A*融合算法, 避障约束更严格、运行更安全。结果表明, 相较于传统算法和改进A*-动态窗口融合算法, 改进蚁群-动态窗口融合算法更适配室内服务机器人的工作场景, 显著提升了其在室内动态环境中的路径规划效率与安全通行能力。尽管本研究改进蚁群-动态窗口融合算法在仿真实验中展现出优异的性能, 但其在理论特性与工程应用层面仍存在不可忽视的局限性, 例如, 由于计算复杂度与算力约束的局限性, 全局路径规划耗时略长于A*算法, 对初始参数与环境建模具有强敏感性, 因此对服务机器人的内存需求较高。

为进一步提升算法的适用性, 后续工作将围绕室内服务场景的核心需求开展算法优化, 搭建多传感器融合的实体机器人实验平台, 在真实办公、商场等室内场景中验证算法的实际鲁棒性。

参考文献:

- [1] Yang H Q. Analysis and study on path planning algorithms in the further mobile action[J]. Journal of Physics: Conference Series, 2024, 2824(1): 012006.
- [2] Song B Y, Tang S M, Li Y. A new path planning strategy integrating improved ACO and DWA algorithms for mobile robots in dynamic environments[J]. Mathematical Biosciences and Engineering, 2024, 21(2): 2189-2211.
- [3] 李海亮, 李宗刚, 宁小刚, 等. 基于蚁群算法引导深度Q网络的移动机器人路径规划算法[J]. 兵工学报, 2025, 46(11): 65-78.
- [4] 张伟民, 徐森生, 张月. 基于改进A*算法的室内巡检机器人路径规划研究[J]. 机械工程学报, 2024, 60(20): 315-326.
- [5] Zhang W M, Xu S S, Zhang Y. Research on path planning for indoor inspection robots based on improved A* algorithm[J]. Journal of Mechanical Engineering, 2024, 60(20): 315-326.
- [6] 蒋华扬, 吴涛, 任建鑫, 等. 基于改进DWA算法的移动机器人局部路径规划[J]. 机械设计与研究, 2024, 40(5): 229-234.
- [7] Jiang H Y, Wu T, Ren J X, et al. Research on local path planning of mobile robot based on improved dwa algorithm[J]. Machine Design and Research, 2024, 40(5): 229-234.
- [6] 洪东洋, 张慧, 张译匀, 等. 车路群智协同感知方法综述[J]. 智能科学与技术学报, 2025, 7(2): 143-164.
- [7] Hong D Y, Zhang H, Zhang Y Y, et al. A survey on vehicle-road collaborative perception methods[J]. Chinese Journal of Intelligent Science and Technology, 2025, 7(2): 143-164.
- [7] 陈旭飞, 胡耀炜, 丛培龙, 等. 面向路径规划的双向交互多步蚁群算法研究[J]. 计算机工程与应用, 2025, 61(3): 166-176.
- [8] Chen X F, Hu Y W, Cong P L, et al. Research on bidirectional interactive multi-step ant colony algorithm for path planning[J]. Computer Engineering and Applications, 2025, 61(3): 166-176.
- [8] Sari D W, Dwijayanti S, Suprpto B Y. Integration of regression-based guidance ant for enhanced exploration and convergence in ant colony optimization (ACO)[J]. IEEE Access, 2025, 13: 107621-107630.
- [9] 时维国, 宁宁, 宋存利, 等. 基于蚁群算法与人工势场法的移动机器人路径规划[J]. 农业机械学报, 2023, 54(12): 407-416.
- [9] Shi W G, Ning N, Song C L, et al. Path planning of mobile robots based on ant colony algorithm and artificial potential field algorithm[J]. Transactions of the Chinese Society for Agricultural Machinery, 2023, 54(12): 407-416.
- [10] 钱平, 顾才东, 鲜学丰, 等. 基于改进蚁群算法的水下机器人路径规划研究[J]. 制造业自动化, 2022, 44(12): 181-184, 208.
- [10] Qing P, Gu C D, Xian X F, et al. Research on path planning for underwater vehicles based on improved ant colony algorithm[J]. Manufacturing Automation, 2022, 44(12): 181-184, 208.
- [11] 田晓航, 霍鑫, 周典乐, 等. 基于蚁群信息素辅助的Q学习路径规划算法[J]. 控制与决策, 2023, 38(12): 3345-3353.
- [11] Tian X H, Huo X, Zhou D L, et al. Ant colony pheromone aided Q-learning path planning algorithm[J]. Control and Decision, 2023, 38(12): 3345-3353.
- [12] 朱佳莹, 高茂庭. 融合粒子群与改进蚁群算法的AUV路径规划算法[J]. 计算机工程与应用, 2021, 57(6): 267-273.
- [12] Zhu J Y, Gao M T. AUV path planning based on particle swarm optimization and improved ant colony optimization[J]. Computer Engineering and Applications, 2021, 57(6): 267-273.
- [13] 王志伟, 邹艳丽, 刘唐慧美, 等. 基于改进Q-learning算法和DWA的路径规划[J]. 传感器与微系统, 2023, 42(9): 148-152.
- [13] Wang Z W, Zou Y L, Liu T H M, et al. Path planning based on improved Q-learning algorithm and DWA[J]. Transducer and Microsystem Technologies, 2023, 42(9): 148-152.
- [14] 姜佩贺, 王敬, 桑忠启, 等. 改进A*与DWA的室内服务机器人路径规划研究[J]. 计算机工程与应用, 2024, 60(15): 327-335.
- [14] Jiang P H, Wang J, Sang Z Q, et al. Research on indoor service robot path planning based on improved A* and DWA[J]. Computer Engineering and Applications, 2024, 60(15): 327-335.

- [15] 韩晓庆, 姜媛媛, 刘延彬. 基于凸优化平滑动态窗口法的运动规划方法[J]. 电子测量与仪器学报, 2023, 37(8): 234-240.
Han X Q, Jiang Y Y, Liu Y B. Motion planning method based on convex optimally smoothed dynamic window approach[J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(8): 234-240.
- [16] 付龙, 沈震, 陶浩, 等. 基于A*与动态窗口法的无人船路径规划[J]. 智能科学与技术学报, 2025, 7(2): 184-199.
Fu L, Shen Z, Tao H, et al. Path planning of unmanned ships based on A* and dynamic window approach[J]. Chinese Journal of Intelligent Science and Technology, 2025, 7(2): 184-199.
- [17] 唐炜, 谭啸, 孙宇, 等. 基于A*与动态窗口法的物料传输平台路径规划研究[J]. 智能科学与技术学报, 2023, 5(4): 515-524.
Tang W, Tan X, Sun Y, et al. Research on path planning of material transmission platform based on A* and dynamic window method[J]. Chinese Journal of Intelligent Science and Technology, 2023, 5(4): 515-524.
- [18] 胡子牛, 陈鑫鹏, 杨泽宇, 等. 具有多型避障方式的智能车辆路径规划[J]. 汽车工程, 2025, 47(3): 402-411.
Hu Z N, Chen X P, Yang Z Y, et al. Path planning with multiple obstacle-avoidance modes for intelligent vehicles[J]. Automotive Engineering, 2025, 47(3): 402-411.
- [19] Li M Z, Li B, Qi Z G, et al. Optimized APF-ACO algorithm for ship collision avoidance and path planning[J]. Journal of Marine Science and Engineering, 2023, 11(6): 1177.
- [20] Zhu W Y, Cai W Z, Kong H. Optimal path planning based on ACO in intelligent transportation[J]. International Journal of Cognitive Computing in Engineering, 2025, 6: 441-450.
- [21] 张天瑞, 吴宝库, 周福强. 面向机器人全局路径规划的改进蚁群算法研究[J]. 计算机工程与应用, 2022, 58(1): 282-291.
Zhang T R, Wu B K, Zhou F Q. Research on improved ant colony algorithm for robot global path planning[J]. Computer Engineering and Applications, 2022, 58(1): 282-291.
- [22] Noh G, Park J, Kim J, et al. Real-time path re-planning to deal with dynamic obstacles using a parallel probabilistic roadmap[J]. International Journal of Aeronautical and Space Sciences, 2025, 26(2): 748-759.
- [23] 韩彦岭, 吕金科, 周国峰, 等. 基于灰狼优化的自适应混合A*和人工势场的无人矿卡路径规划研究[J]. 智能科学与技术学报, 2025, 7(2): 246-256.
Han Y L, Lyu J K, Zhou G F, et al. Research on unmanned mining truck path planning based on grey wolf optimization adaptive hybrid A* and artificial potential field[J]. Chinese Journal of Intelligent Science and Technology, 2025, 7(2): 246-256.
- [24] 张可琨, 鲍久圣, 艾俊伟, 等. 基于改进A*与DWA算法的井下搬运机器人自主行走路径规划[J]. 煤炭科学技术, 2024, 52(11): 197-213.

Zhang K K, Bao J S, Ai J W, et al. Autonomous walking path planning of underground handling robot based on improved A* and DWA algorithm[J]. Coal Science and Technology, 2024, 52(11): 197-213.

- [25] 田旭光, 左钦文, 王丁, 等. 基于融合A*启发式搜索的深度强化学习路径规划算法研究[J]. 兵工学报, 2025, 46(S2): 313-325.
Tian X G, Zuo Q W, Wang D, et al. A path planning algorithm based on deep reinforcement learning with integrated a heuristic search[J]. Acta Armamentarii, 2025, 46(S2): 313-325.

[作者简介]



马伟杰 (2001-), 男, 中北大学电气与控制工程学院硕士生, 主要研究方向为机器人路径规划算法。



姚舜才 (1974-), 男, 博士, 中北大学电气与控制工程学院副教授, 主要研究方向为电机电磁场分析、电机与电器技术、非线性系统动态建模、统计学习与智能控制。



马敏毓 (2001-), 女, 中北大学电气与控制工程学院硕士生, 主要研究方向为图像处理与深度学习。



蔚鹏飞 (2001-), 男, 中北大学电气与控制工程学院硕士生, 主要研究方向为智能机器人导航、目标识别与抓取。