

基于改进蚁群算法的 AGV 路径规划研究

王鹏杰, 陶怡, 朱凯, 赵晨杰
(西安航天自动化股份有限公司, 西安 710000)

摘要:为解决蚁群算法在实现 AGV 路径规划时存在迭代速度慢、初期路径搜索盲目性大、路径拐点数量多、安全性较低等问题,提出一种改进的蚁群算法;该方法以栅格地图为 AGV 运行环境,在迭代初期引入势场力,将当前位置与目标点的势场力加入启发式信息中,解决路径初期搜索盲目性和算法迭代速度慢的问题;通过改进算法状态选择概率,提高获取优质解能力,避免算法陷入局部最优;提出一种基于路径长度、安全性和平滑性多目标约束的信息素更新规则,提高 AGV 行驶安全性;在此基础上,引入三次 B 样条路径平滑策略,使规划路径满足 AGV 需求,通过仿真实验可知,改进算法在收敛速度和稳定性方面表现效果较好,其收敛速度相较于传统算法提升 8 倍,路径长度较其他改进算法提升接近 20%。

关键词:路径规划;蚁群算法;路径平滑;人工势场;自动引导运输车

Research on AGV Path Planning Strategy Based on Improved Ant Colony Algorithm

WANG Pengjie, TAO Yi, ZHU Kai, ZHAO Chenjie
(Xi'an Aerospace Automation Co., Ltd., Xi'an 710000, China)

Abstract: In order to solve the problems of slow convergence speed, large blindness in initial path search, multiple paths turning points, and low safety for ant colony algorithms in automated guided vehicle (AGV) path planning, an improved ant colony algorithm is proposed. This method takes the grid map as the running environment for AGV, introduces the potential field force at the beginning of iteration, and adds the potential field force between the current position and the target point to the heuristic information to solve the problems of blind search in the initial stage of the path and slow convergence speed of the algorithm iteration. The state selection probability of the algorithm is used to obtain the optimal solution, avoiding local optima. Based on multiple objective constraints such as path length, safety, and smoothness, an information pheromone updating rule is proposed to improve the safety of AGV. On this basis, a cubic B-spline path smoothing strategy is introduced to ensure that the planned path meets the requirements of AGV. Through simulation experiments, the improved algorithm has better performances of convergence speed and stability. Its convergence speed is 8 times than that of the traditional algorithms, and the path length is improved by nearly 20% compared with other improved algorithms.

Keywords: path planning; ant colony algorithm; path smoothness; artificial potential field; AGV

0 引言

随着智能技术和物联网的飞速进步,自动引导运输车 (AGV, automated guided vehicle) 已在仓储、港口物流和智能工厂等众多领域得到了广泛应用。作为智能化进程中的关键环节,AGV 路径规划是当前学术界广泛关注的研究课题。

AGV 路径规划是指在具有障碍物的特定环境中,按

照目标函数约束(如距离最短约束等)规划出一条自出发点至目标点的安全路。目前,常用的启发式路径搜索算法有迷宫布线算法^[1]、Dijkstra 算法^[2]、A* 算法^[3]和 D* 算法^[4]等;随着智能化的发展,粒子群算法、遗传算法、蚁群算法、狼群算法^[5]等仿生算法也逐渐被广泛应用。其中,蚁群算法^[6]是一种基于模拟自然界蚂蚁觅食行为的启发式优化方法。该算法具有多项优势,包括较强的全局优化能力、能够解决复杂的优化问题、良好的

收稿日期:2023-11-24; 修回日期:2024-01-08。

作者简介:王鹏杰(1996-),男,硕士。

引用格式:王鹏杰,陶怡,朱凯,等.基于改进蚁群算法的 AGV 路径规划研究[J].计算机测量与控制,2025,33(1):194-203.

自适应性、分布式计算特性以及较高的鲁棒性。然而, 蚁群算法也存在一些不足之处, 例如计算效率较低、容易陷入局部最优解、对内存和计算资源的消耗较大, 以及收敛性难以保证等问题。针对蚁群算法在路径规划中存在的不足, 许多学者提出了多种优化策略, 以克服其在计算效率、局部最优解、资源消耗及收敛性等方面的问题。其中, 通过根据三角形原理简化路径点数、实现路径平滑效果的方法来解决路径不平滑问题^[7-9]; 利用混沌学原理建立机器人移动模型, 以减少过程的随机性, 从而提升算法的搜索效率^[10]; 通过改进过程点与终点之间的距离启发式函数, 增强算法的优化导向性, 克服盲区问题^[11]; 将熵权法与蚁群算法结合以实现 AGV 路径规划, 但存在折线点过多的问题^[12]; 通过引入 B 样条算法对运动轨迹进行平滑化处理, 更贴近实际应用^[13]; 通过优化人工势场算法中目标点不可达和局部极小值问题, 实现 AGV 在车间中的高效安全路径规划^[14]; 采用蚁群算法进行机器人路径规划, 并将安全性、距离等多重约束融入信息素更新机制, 以实现全局最优路径^[15]。

基于前人研究, 本文主要解决传统蚁群算法中初期迭代速度慢、易陷入局部最优、路径安全性差、路径转折点多等问题, 提出融合人工势场策略的混合蚁群算法。相较于传统蚁群算法, 混合蚁群算法在迭代初期引入人工势场力, 降低算法搜索盲目性, 提高算法迭代速度。为解决路径安全性问题, 在信息素更新机制中加入机器人安全领域约束, 使得规划路径能保障机器人安全运行。为避免算法后期陷入局部最优解, 改进蚁群算法选择概率, 在后期迭代中, 加大算法随机选择路径概率, 通过牺牲部分时间开销保障开发新路径。最后, 引入路径平滑性目标约束函数, 能够进一步使规划路径更短更平滑。

1 环境模型建立

构建合适的栅格坐标系对提高 AGV 路径规划效率有重要的影响, 为提高算法计算效率, 建立笛卡尔和序号坐标系可相互转化的栅格坐标系。其中, 一维序号标识是连续的正整数序号, 如图 1 (a) 所示; 二维标识坐标与矩阵轴模式相同, 用一组行列对标识栅格, 如图 1 (b) 所示。为保证栅格与地图中每个位置都能精准匹配及减少运算时间^[16], 将以笛卡尔坐标系为基础, 以轴正方向表示正东方向、轴正方向表示正北方向。具体转换关系如下:

1.1 一维标识与二维标识

$$i = \begin{cases} \text{mod}(N, n) & \text{mod}(N, n) \neq 0 \\ n & \text{mod}(N, n) = 0 \end{cases} \quad (1)$$

$$j = \text{ceil}(N/n) \quad (2)$$

$$N = (j - 1) * n + i \quad (3)$$




图 1 栅格坐标系示意图

1.2 一维标识与直角坐标系

$$x = \text{len} * (\text{ceil}(N/n) - 0.5) \quad (4)$$

$$y = \begin{cases} \text{len} * (n - (\text{mod}(N, n)) - 0.5) & \text{mod}(N, n) \neq 0 \\ \text{len} * 0.5 & \text{mod}(N, n) = 0 \end{cases} \quad (5)$$

1.3 二维标识与直角坐标系

$$x = (j - 0.5) * \text{len} \quad (6)$$

$$y = (n - i + 0.5) * \text{len} \quad (7)$$

$$i = n - y/\text{len} + 0.5 \quad (8)$$

$$j = x/\text{len} + 0.5 \quad (9)$$

式中, n 为栅格矩阵 G 的维度, N 为一维标识坐标系下的栅格序号, i, j 为二维标识坐标系下的栅格行列对, len 为实际地图与栅格地图之间的边长缩放比, mod 为取余函数, ceil 为取整函数。

2 改进的蚁群算法

2.1 蚁群算法机理

蚁群算法机理为在任意时刻下, 蚂蚁从当前路径点选择任意路径点的概率由和决定, 路径转移概率如下:

$$p_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha * [\eta_{ij}(t)]^\beta}{\sum_{s \in \text{allowedk}} [\tau_{is}(t)]^\alpha * [\eta_{is}(t)]^\beta}, & s \in \text{allowedk} \\ 0, & s \notin \text{allowedk} \end{cases} \quad (10)$$

式中, $p_{ij}^k(t)$ 为时刻下第 k 只蚂蚁从点 i 选择点 j 的概率, α 和 β 为信息启发式因子和期望值启发式因子的重要程度, τ_{ij} 为路径点间的信息素数值, η_{ij} 为路径点间的路径长度, τ_{is} 为从点 i 到点 s 的信息素数值, η_{is} 为从点 i 到点 s 的路径长度, $\text{allowedk} = \{0, 1, 2, \dots, m-1\}$ 为点 i 可选择的路径点集合。

假设路径点 i 的坐标为 (x_i, y_i) , 点 j 的坐标为 (x_j, y_j) , 公式中的启发式函数值 η_{ij} 等于两路径点间欧式距离的倒数, 启发式函数如公式所示:

$$\eta_{ij}(t) = \frac{1}{D_{ij}} \quad (11)$$

$$D_{ij} = \sqrt{(x_i - x_j)^2 + (y_i - y_j)^2} \quad (12)$$

第 k 只蚂蚁在路径点 i, j 之间信息素更新机制计

算公式如下：

$$\tau_{ij}(t+1) = (1 - \rho)\tau_{ij}(t) + \Delta\tau_{ij}(t) \quad (13)$$

$$\Delta\tau_{ij}(t) = \sum_{k=1}^m \Delta\tau_{ij}^k(t) \quad (14)$$

式中， ρ 为信息素挥发系数， $\Delta\tau_{ij}(t)$ 为第 t 时刻后路径 (i, j) 信息素的增加量，且 $\Delta\tau_{ij}(0) = 0$ ， $\Delta\tau_{ij}^k(t)$ 表示蚂蚁 k 在 t 时刻通过路径 (i, j) 时残留的信息素数值，如公式所示。

$$\Delta\tau_{ij}^k(t, t+1) = \begin{cases} \frac{Q}{L_k}, & \text{第 } k \text{ 只蚂蚁从 } i \text{ 访问 } j \\ 0, & \text{其他} \end{cases} \quad (15)$$

式中， Q 为信息素强度常量， L_k 为蚂蚁在当前迭代中的 AGV 运动路径。

2.2 基于人工势场的混合蚁群算法

为了提高传统蚁群算法的收敛速度，可以引入势场力。势场力可以帮助蚂蚁更快地找到最优路径，并避免陷入局部最优、发生碰撞和目标不可达等问题。

混合蚁群算法是将蚁群算法和人工势场法相结合的一种路径规划策略。蚁群算法具有良好的可拓展性，可以在全局范围内搜索最优路径；而人工势场法适用于局部路径规划，可避免与障碍物碰撞。

混合蚁群算法的基本思想是利用蚁群算法进行全局路径搜索，然后在局部路径规划中引入人工势场法来辅助蚂蚁进行路径选择。具体步骤如下：

- 1) 建立环境模型，包括起点、终点和障碍物的位置。
- 2) 初始化蚁群算法的参数，如蚂蚁数量、信息素初始浓度、信息素挥发速率等。
- 3) 迭代执行以下步骤：
 - (1) 蚂蚁根据信息素浓度和启发函数选择下一步移动的位置。
 - (2) 根据蚂蚁的移动轨迹和路径长度更新信息素浓度。
 - (3) 判断蚂蚁是否到达终点，如果是，则记录路径信息。
 - (4) 引入人工势场法，在局部路径规划中根据障碍物和目标位置计算势场力，并将其加入到路径选择的过程中。
 - (5) 判断是否满足终止条件，如达到最大迭代次数或找到满意的最优路径。
- 4) 根据迭代结果得到当前最优路径。

混合蚁群算法策略的引入可以提高蚁群算法的收敛速度，并解决传统蚁群算法的初始搜索盲目性问题。然而，需要注意的是，人工势场法本身也存在一些问题，如易陷入局部最优、发生碰撞和目标不可达等情况，因此在具体应用中需要综合考虑各种因素，进行参数调节

和优化，以获得更好的路径规划效果。

由于传统蚁群算法存在初始搜索盲目性问题，为提高算法的收敛速度，故在迭代初期引入了势场力。混合蚁群算法可有效解决蚁群算法初始搜索盲目性，但人工势场法自身却存在易陷入局部最优、发生碰撞和目标不可达等问题，如图 2 所示。根据蚁群算法的可拓展性和人工势场法适合局部路径规划的特点^[17]，提出混合蚁群算法策略。




图 2 人工势场缺陷示意图

引力势场函数与距离 $d(P, T)$ 成正比，当 $d(P, T)$ 较大时，引力值会趋近无穷大，从而增加 AGV 与障碍物发生碰撞的风险。为避免碰撞，当 $d(P, T \leq q_{att})$ ，使引力值与 $d(P, T)^2$ 成反比；当 $d(P, T > q_{att})$ 时，使引力值与 $d(P, T)$ 成正比，以限制影响范围。改进后的引势场函数如下所示：

$$U_{att} = \begin{cases} \frac{1}{2}K_{att}d^2(P, T), & d(P, T) \leq q_{att} \\ q_{att}K_{att}d(P, T), & d(P, T) > q_{att} \end{cases} \quad (16)$$

式中， K_{att} 是引力势场的系数，用于控制引力的强度， $d(P, T)$ 为 AGV 到目的地的距离， q_{att} 为引力势场函数的影响分界线。

与此同时，斥力函数值与 $d(P, O)$ 成正比，当目的地附近存在多障碍物时，会出现斥力值大于引力值，使 AGV 无法抵达目的地。所以，当 AGV 即将达目的地时，将斥力势场函数值设置为 0，可保证 AGV 能顺利到达目的地。斥力势场函数改进如下所示：

$$U_{rep} = \begin{cases} \frac{1}{2}d^2(P, G)K_{rep}e^{-\frac{1}{d(P, O) - \frac{1}{2}d_o}}, & d(P, O) < d_o \\ 0, & d(P, O) \geq d_o \end{cases} \quad (17)$$

式中， $d(P, O)$ 为 AGV 到障碍物位置的距离， K_{rep} 为斥力势场函数系数， d_o 为障碍物影响范围值。

在改进后混合蚁群算法中，引力 F_{att} 和 F_{rep} 的矢量合力为 F_{tot} ，具体形式如下式所示。

$$F_{tot} = F_{att} + F_{rep} \quad (18)$$

通过优化引力势场函数和斥力势场函数，改进后的混合蚁群算法能够提高算法的收敛速度和路径规划效果，避免了传统蚁群算法迭代速度慢的问题。

2.3 混合蚁群算法改进策略

2.3.1 启发式信息的改进

在混合蚁群算法中, 启发式信息的改进至关重要。启发式信息作为一种启发式函数, 直接影响着蚂蚁在路径选择时的决策概率, 进而对算法的收敛速度和最终结果的质量产生影响。在传统蚁群算法中, 启发式信息仅与节点 i 和 j 间的欧式距离 D_{ij} 有关。当 D_{ij} 数值较小时, 启发式信息数值越大, 使蚁群算法常忽略各障碍物对路径规划的影响, 从而使规划结果陷入局部最优值。因此, 本文在原有启发式信息的基础上加入势场力对启发式信息的引导性, 用 v_s 表示。其表达式具体如下:

$$v_s = \alpha^{F_{\text{tot}}-s} \quad (19)$$

式中, α 为大于 1 的常数, F_{tot} 为势场中引力与斥力的合值, θ 为 AGV 可前进路径与合力 F_{tot} 间的夹角值。

据混合蚁群算法原理可知, 在迭代初期, 由于信息素和启发式信息对转移概率的影响效果较小, 此时应加入人工势场启发信息加强对 AGV 路径规划的引导作用, 使搜索具有目的导向性。在迭代后期, 信息素浓度处于较高水平且各路径间启发信息出现明显差距, 此时可取消启发式信息的引导功能, 因此引入人工势场影响系数控制人工势场的影响范围。改进后的启发式信息如下:

$$\eta_{ij}(t) = \begin{cases} \frac{\alpha^{F_{\omega} \cos \theta}}{d^2(i, j)} * \frac{N_{\max} - \lambda * N_{\text{cur}}}{N_{\max}}, & \lambda * N_{\text{cur}} \leq N_{\max} \\ \frac{\alpha^{F_{\omega} \cos \theta}}{d^2(i, j)}, & \lambda * N_{\text{cur}} > N_{\max} \end{cases} \quad (20)$$

当 $\lambda * N_{\text{cur}} \leq N_{\max}$ 时, 定义为算法迭代初期, 此时加入 η_s , η_s 的影响作用随着迭代次数增加而减小。当 $\lambda * N_{\text{cur}} > N_{\max}$ 时, 取消 η_s 对启发式信息的影响, 采取初始启发式信息式。

式中, N_{cur} 为当前迭代次数, N_{\max} 为最大迭代次数, 将初始启发式信息修改为原来的二次方倍, 可增强路径长度对算法的引导性。

2.3.2 伪随机选择概率的改进

传统蚁群算法中的概率选择公式中, 常以信息素浓度和启发式信息的乘积作为轮盘赌的选择概率^[18], 称之为偏向探索 (BE, bias exploration)。该方法存在忽视已有的有效路径问题, 导致算法的时间复杂度增加。针对该问题, 算法引入随机变量 q 和固定参数 q_0 来优化选择概率。当 $q \leq q_0$ 时, 将启发式信息与信息素浓度的乘积作为评估标准, 优先选择那些乘积值更高的路径。当 $q > q_0$ 时, 则采用基础算法的轮盘赌方法决定选择几率。通过这种改进的几率公式, 可以在开拓现有路径和探索新路径之间实现一种平衡。具体的改进转移几率公式如下所述:

$$p_{ij}^k(t) = \begin{cases} \arg \max_{s \in \text{allowedk}} \{[\tau_{ij}(t)]^\alpha * [\eta_{ij}(t)]^\beta\}, & q \leq q_0 \\ \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{s \in \text{allowedk}} [\tau_{is}(t)]^\alpha [\eta_{is}(t)]^\beta}, & s \in \text{allowedk} \\ 0, & s \notin \text{allowedk}, q > q_0 \end{cases} \quad (21)$$

式中, q 的其取值范围为 $[0, 1]$, q_0 的取值范围为 $(0, 1)$, q 和 q_0 的具体取值通常由前人经验和反复实验确定, $\text{allowedk} = \{0, 1, 2, \dots, m-1\}$ 的含义为路径点 i 下一时刻可选择的路径点。

此改进可以更好地平衡当前路径的开发和新路径的探索, 从而提高算法的搜索效率和收敛速度。

2.3.3 信息素更新阈值的改进

在传统蚁群算法中, 信息素初始浓度、蚂蚁数量和路径长度都会影响路径的剩余信息素浓度。经过多次迭代后, 某条路径可能被过多或过少的选择, 导致该路径与其他路径的信息素含量差距过大, 易使算法过早收敛、甚至停滞现象。为此, 对路径上的信息素含量实施阈值限制, 当信息素浓度低于 τ_{\min} 时, 将其调整为统一的浓度 τ_{\min} 。当信息素浓度高于 τ_{\max} 时, 将其调整为统一的浓度 τ_{\max} 。改进后的信息素约束范围为:

$$\tau = \begin{cases} \tau_{\min} & \tau \leq \tau_{\min} \\ \tau & \tau_{\min} < \tau < \tau_{\max} \\ \tau_{\max} & \tau_{\max} \leq \tau \end{cases} \quad (22)$$

式中, τ_{\min} 为信息素浓度的最小阈值, τ_{\max} 为信息素浓度的最大阈值。

2.3.4 信息素更新规则的改进

传统蚁群算法的信息素更新规则通常采用蚁周模型^[19], 该模型主要考虑信息素浓度和路径长度等因素。在实际的 AGV 路径规划中, 为确保路径的安全性、可用性和可行性, 还需考虑路径的安全性和平滑性。路径的安全性直接影响路径的可用性, 而平滑性则关系到 AGV 的动力学和运动学要求。因此, 为了得到符合多重约束的最优路径, 需在信息素更新规则中加入路径长度、安全性和平滑性等因素^[20]。具体改进如下:

$$\Delta \tau_{ij}^k(t) = \begin{cases} Q/\omega, & (i, j) \in \text{visited}_k \\ 0, & \text{其他} \end{cases} \quad (23)$$

$$\omega = \omega_1 PL + \omega_2 PS + \omega_3 PM \quad (24)$$

$$PL = \sum_{i=1}^{n-1} d(q_i, q_{i+1}) \quad (25)$$

$$PS = \sum_{i=1}^{n-1} S_{i,i+1} \quad (26)$$

$$PM = \sum_{i=1}^{n-2} |\theta(q_{i+1}, q_{i+1}) - \theta(q_i, q_{i+1})| \quad (27)$$

式中, PL 表示路径长度约束函数, PS 表示路径安全性约束函数, $S_{i,i+1}$ 衡量当前节点与下一个节点的安全性, 具体计算公式见公式 (26), 通过求和得到整条路

径的安全性值, PM 表示路径平滑度约束函数, 根据 PM 公式可知, 规划的 AGV 路径包含 n 个路径点, 即根据 $q_i(x_i, y_i)$, $q_{i+1}(x_{i+1}, y_{i+1})$, $q_{i+2}(x_{i+2}, y_{i+2})$ 路径点坐标, 利用反三角函数求取路径点之间的角度, 如公式 (27) ~ (29) 所示:

$$S_{i,i+1} = \begin{cases} 1, & S_{i,i+1} > S_{DA}(i, i+1) \\ 0.5, & S_{DA}(i, i+1)/2 \leq S_{i,i+1} \leq S_{DA}(i, i+1) \\ 0.1, & S_{i,i+1} < S_{DA}(i, i+1)/2 \end{cases} \quad (28)$$

$$\theta(q_i, q_{i+1}) = \begin{cases} \tan^{-1} \frac{y_{i+1} - y_i}{x_{i+1} - x_i} & x_{i+1} \neq x_i \\ \left| \frac{\pi}{2} \right| & x_{i+1} = x_i \end{cases} \quad (29)$$

式中, $S_{DA}(i, i+1)$ 为在路径点 i 和 $i+1$ 之间的 AGV 安全会遇距离, $S_{i,i+1}$ 可评价某一段路径的安全性程度。

2.3.5 三次 B 样条平滑策略

虽然改进的蚁群算法规划的路径符合经济性和安全性的要求, 但由于 AGV 的行驶环境是一个网格地图, 尽管该算法用于限制路径的转弯点数量, 仍然无法解决 AGV 转弯范围大的问题。因此, 引入了三次 B 样条路径平滑策略, B 样条的定义为: 假设 $n+1$ 有个控制点 $P_0, P_1, P_2, \dots, P_n$, 这些控制点将影响曲线的形状走向和曲线范围。其数学表达式公式 (30)、(31) 所示:

$$P(u) = [P_0, P_1, \dots, P_n] \begin{bmatrix} N_{0,k}(u) \\ N_{1,k}(u) \\ \dots \\ N_{n,k}(u) \end{bmatrix} \sum_i^n P_i N_{i,3}(u) \quad (30)$$

$$N_{i,p}(u) = \begin{cases} 1, u_i \leq u \leq u_{i+1}, & k = 1 \\ 0, \text{其他} & \\ \frac{u - u_i}{u_{i+k} - u_i} N_{i,k-1}(u) + \frac{u_{i+k+1} - u}{u_{i+k+1} - u_{i+1}} N_{i+1,k-1}(u), & k > 2 \end{cases} \quad (31)$$

式中, $P_i = (x_i, y_i)^T \in R^2, i = 0, 1, \dots, n$ 是 B 样条曲线的第 i 个控制点, $N_{i,k}(u) \in R[u]$ 是第 i 个 k 次的 B 样条基函数, u_i 是一组非递减序列节点矢量的数值, 该序列的数学表达形式为 $u_i = [u_0, u_1, \dots, u_k, u_{k+1}, \dots, u_{n+k}]$ 。

当选用三次 B 样条时, 根据公式 (30) 和 (31) 可推导出三次 B 样条的矩阵表达式如下:

$$P(u) = \frac{1}{6} [1 \quad u \quad u^2 \quad u^3] \begin{bmatrix} 1 & 4 & 1 & 0 \\ -3 & 0 & 3 & 0 \\ 3 & -6 & 3 & 0 \\ -1 & 3 & -3 & 1 \end{bmatrix} \begin{bmatrix} P_0 \\ P_1 \\ P_2 \\ P_3 \end{bmatrix} \quad (32)$$

使用三次 B 样条函数实现路径平滑策略的过程如下: 首先, 选择 4 个连续的离散路径点 $[P_0, P_1, P_2, P_3]$ 作为起始点和终点, 为了使起点和终点的位置更加平滑, 每个起点的两端添加一个控制点, 结果为 $[P_S, P_0, P_1, P_2, P_3, P_E]$ 。其次, 在处理后的路径序列中设置两个中间点 $M_1 = (P_0 + P_2)/2$ 、 $M_2 = (P_1 + P_3)/2$, 最终得到离散平滑结果如图 3 (a) 所示。经过三次 B 样条平滑后的最佳路径如图 3 (b) 所示。从图中可以看出, 在转弯处, 平滑策略将折线处理成曲线。这不仅使路径更短, 还使其与 AGV 的运行轨迹更加一致。




图 3 三次 B 样条路径平滑原理

2.4 路径安全性函数设计

前文针对直线路段, 采用相邻路径之间的角度值来评价路径平滑程度。若处理路径对象为曲线段时, 则可使用相邻路径之间的曲率半径或曲率值大小判断优化后的路径平滑程度^[21]。仅用曲率值判断路径平滑优劣具有片面性, 并且平滑后的路径可能会增加 AGV 与障碍物之间的碰撞危险。文章将综合考虑曲率值和路径安全度计算规划路径中的不安全路径点数。

2.4.1 路径平滑安全性函数

路径平滑后, 不同平滑策略将产生不同凹凸程度的轨迹。若在靠近障碍物的一侧路径凹凸程度过大可能会增加与障碍物之间的危险。为保障 AGV 行驶安全, 使用路径平滑安全性函数作为评估路径平滑优劣的指标是可行的。路径平滑安全性函数值越大说明路径平滑效果好; 反之, 则说明路径平滑效果较差。因此, 将分别求解路径平滑安全性函数值 f_{SM} 和初始规划路径安全性函数值 f_{PS} , 并以两者差值的绝对值作为路径平滑安全性函数:

$$f_{SM} = \sum_{i=1}^{n-1} SM_{i,i+1} \quad (33)$$

$$f_{PS} = \sum_{i=1}^{n-1} S_{i,i+1} \quad (34)$$

$$f_s = \left| \sum_{i=1}^n f_{sm}(i) - f_{ps} \right| \quad (35)$$

式中, S 为初始规划路径, SM 为平滑后的路径。

2.4.2 路径平滑弯曲性函数

在确保路径安全性的基础上, 路径的曲率和也是判断平滑效果优劣的标准。若路径曲率和过大, 不但会增加能量消耗, 而且还会造成机器设备负荷增加等问题。

路径的曲率和值与其平滑程度有紧密联系, 曲率和值越小说明轨迹越平滑; 反之, 则说明轨迹越曲折, 不符合要求。在此基础上, 将轨迹中离散点的曲率和定义为评价轨迹弯曲性优劣的函数:

$$f_{sm} = \sum_{i=1}^n |K_i| \quad (36)$$

式中, K_i 为路径点 i 处的曲率值。

曲率的含义是曲线上某点切线方向对弧长的转动率, 所以曲率可表示曲线偏离直线的程度, 也可以表示曲线在某一位置的弯曲程度值。曲线由参数方程 $x = \varphi(t), y = \omega(t)$ 给出, 曲率 $K(t)$ 可由下列公式计算求得。

$$K(t) = \frac{|\varphi'(t)\omega''(t) - \varphi''(t)\omega'(t)|}{|\varphi'^2(t) + \omega'^2(t)|^{3/2}} \quad (37)$$

综上, 将路径平滑安全性函数和路径平滑弯曲性函数线性加权后可得到路径点安全性评价函数。其表达式如下:

$$f_{ssm} = \omega_s f_s + \omega_{sm} f_{sm} \quad (38)$$

式中, ω_s 和 ω_{sm} 为各评价函数的权重值, ω_s 取值为 0.70, ω_{sm} 取值为 0.30。

2.5 算法实现步骤

改进蚁群路径规划算法 (IACA, improved ant colony algorithm) 实施步骤主要包括环境建模、算法参数初始化、信息素更新、路径平滑。改进蚁群 AGV 路径规划算法具体实施步骤如下。

步骤 1: 环境建模

建立环境模型, 确定机器人起点、终点和障碍物位置, 这些信息将被用于路径规划过程中的约束条件;

步骤 2: 算法参数初始化

初始化算法中的参数设置, 这些参数包括蚂蚁数量、信息素初始浓度、信息素挥发速率、启发函数权重等;

步骤 3: 信息素更新

根据公式计算各路径点信息素浓度;

步骤 4: 判断是否为真

判断 $\lambda * N_c \leq N_{max}$ 是否为真, 若为真则进入步骤 5;

步骤 5: 路径选择和移动

根据公式计算当前位置的转移概率, 并根据转移概率确定下一步的移动位置;

步骤 6: 路径记录和更新

确定位置更新禁忌表后, 判断蚂蚁是否到达终点, 若抵达终点则记录路径信息; 同时, 根据路径的质量评估方法, 更新信息素浓度和路径的禁忌表。禁忌表用于限制蚂蚁在搜索过程中重复经过某些路径, 以避免陷入局部最优解。

步骤 7: 迭代终止与结果输出

迭代次数 $N_c = N_c + 1$, 判断 N_c 是否等于 N_{max} , 若相等则得到当前最优路径。

根据上述步骤描述, 可绘制的路径规划算法流程图, 以便更好地理解 and 实施该算法, 如图 4 所示。

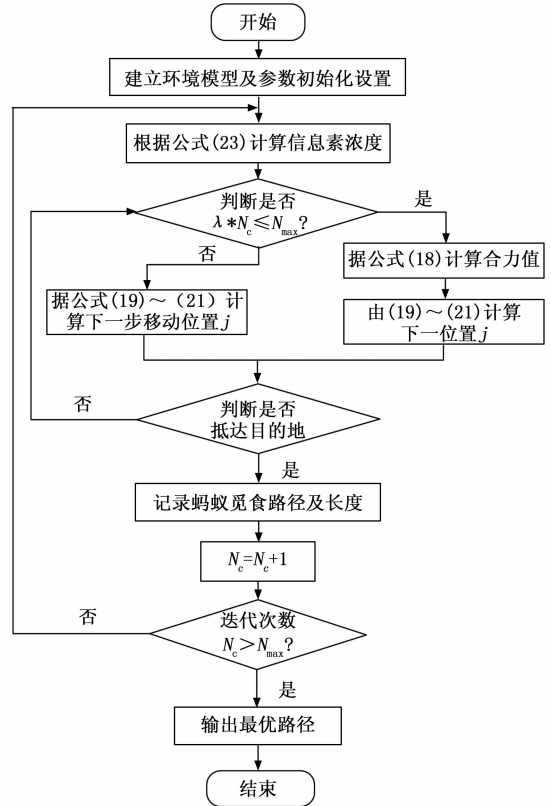


图 4 混合蚁群静态路径规划算法流程图

3 仿真实验及结果分析

为验证改进蚁群路径规划算法 (IACA) 的可行性, 在 MATLAB 2014b 进行仿真实验。本文主要从以下几方面进行仿真验证。1) 对蚁群算法中主要参数进行敏感性分析; 2) 在相同的参数组合下, 分别在 $30 * 30$ 简单栅格环境和 $50 * 50$ 复杂栅格环境仿真实验, 验证算法可行性和有效性; 3) 为验证算法的优越性, 在与 2) 相同的仿真参数及环境下, 分别使用传统蚁群算法、文献 [11] 基于路径长度和路径平滑约束的改进算法、文献 [12] 基于初始信息素分布不均改进算法和本文 IACA 算法进行对比仿真验证。

3.1 蚁群算法参数敏感度分析

本文采用控制变量法, 分别对蚁群算法中蚂蚁数量、信息启发式因子、期望值启发因子和挥发系数进行仿真实验, 其中原始参数设置为 $m=50, \alpha=1, \beta=7, \rho=0.25, Q=20$, 迭代次数为 60。为保证实验结果可靠性, 对每组参数都重复 50 次实验求得平均值, 并通过改变参数值分析路径长度的变化情况, 各参数仿真结

果如图 5~8 所示。




图 5 参数 m 对路径长度的影响




图 6 参数 α 对路径长度的影响




图 7 参数 β 对路径长度的影响




图 8 参数 ρ 对路径长度的影响

由图 5 可知, 当 m 在 $[20\ 50]$ 之间时, 算法搜索路径长度接近最优解; 由图 6 可知, 当 $\alpha < 1$ 时, 随着

数值不断增加, 路径逐渐趋向最优解; 由图 7 可知 β 取值不宜过小; 由图 8 知, ρ 取值不宜过大过小。

通过对算法主要参数进行敏感性分析后, 本文的仿真参数设置为 $m=40$, $\alpha=1$, $\beta=6$, $\rho=0.20$, $Q=20$, $\tau_{min}=10$, $\tau_{max}=50$, $K_{att}=2.0$, $K_{rep}=2.0$ 。

3.2 30 * 30 简单环境对比仿真实验

为验证混合蚁群算法实现 AGV 路径规划的效果, 选择 3030 的机器人行驶栅格环境, 并将传统蚁群算法、文献 [11-12] 与 IACA 算法的路径结果进行对比分析。简单环境下, 经过算法迭代后, 各算法得到的最优路径如图 9 所示, 算法迭代速度如图 10 所示。此外, 对算法的各项性能指标进行分析, 分析结果如表 1 所示。

表 1 简单环境下 4 种算法仿真结果

| 算法 | 路径特征值 | | | 收敛代数 | 时间/s | 不安全点 |
|----------|-------|-------|------|------|-------|------|
| | 最优值/m | 平均值/m | 拐点数量 | | | |
| 基本蚁群算法 | 64.28 | 88.52 | 31 | 无 | 42.29 | 6 |
| 文献[11]算法 | 52.35 | 58.60 | 21 | 26 | 25.35 | 1 |
| 文献[12]算法 | 45.90 | 48.09 | 15 | 12 | 9.80 | 11 |
| IACA 算法 | 46.28 | 46.75 | 14 | 8 | 5.16 | 0 |

由图 9 分析可知, 4 种算法都能找到各自的最优路径。根据表 1 数据可知, 在当前环境下, 机器人规划的最短路径为 45.9, 由文献 [11] 求得。然而, IACA 算法加入了机器人安全性约束, 该约束保证机器人路径不与障碍物任意边有交集。在满足路径安全性约束的前提下, IACA 算法得到的最优路径长度为 46.76, 且不存在不安全路径点 (即路径与障碍物相交的情况)。而文献 [12] 不安全路径点个数为 11 个, 由此可知, IACA 算法相较于文献 [12] 算法能充分协调 AGV 路径长度和安全性约束之间的关系。

3.3 50 * 50 复杂环境对比仿真实验

为进一步验证在复杂环境中改进蚁群算法的稳定性, 本次实验将扩大仿真范围及加入更多数量的障碍物, 所以选择 5050 的栅格仿真环境, 并将传统蚁群算法、文献 [11]、文献 [12] 与 IACA 算法的路径规划结果进行对比分析。其中, 在复杂环境下, 经过算法迭代后的最优路径的规划结果如所图 11 示, 通过比较不同算法的路径规划结果, 评估它们在复杂环境中的性能表现。此外, 同时分析了算法的迭代速度, 结果如图 12 所示。通过观察迭代速度的变化, 了解各算法在优化过程中的收敛情况和效率。算法各性能指标的分析结果如表 2 所示。

由表 2 分析可知, 在当前环境下 AGV 规划最短路径 74.6 为 IACA 算法求得。与此同时, 由图 11 可知,

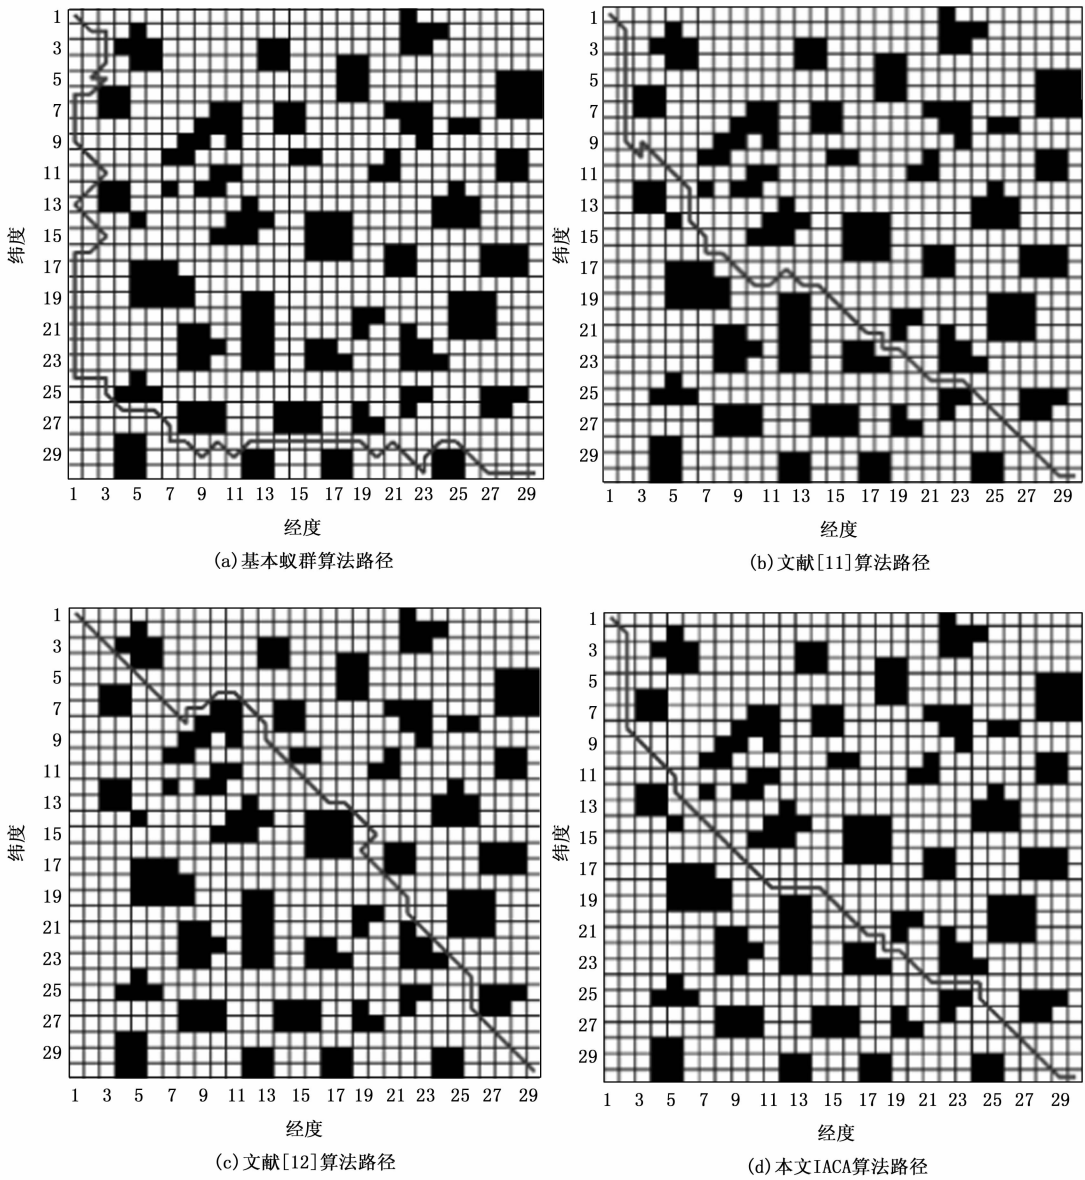


图 9 简单环境下算法的最优路径




图 10 简单环境算法的迭代收敛图

基本蚁群算法无法完成收敛, 文献 [11]、文献 [12] 和 IACA 算法均可收敛。IACA 算法在第 8 代达到了收敛状态, 而文献 [11] 和文献 [12] 则在 21 代和 20 代之后分别实现了收敛。与文献 [11] 算法和文献 [12]

表 2 复杂环境下 4 种算法仿真结果

| 算法 | 路径特征值 | | | 收敛代数 | 时间 /s | 不安全路径点 |
|------------|--------|--------|------|------|-------|--------|
| | 最优值 /m | 平均值 /m | 拐点数量 | | | |
| 基本蚁群算法 | 150.7 | 207.1 | 62 | 无 | 522.1 | 9 |
| 文献[11]算法 | 112.6 | 180.9 | 43 | 21 | 126.7 | 3 |
| 文献[12]算法 | 84.7 | 104.9 | 21 | 20 | 24.2 | 9 |
| 本文 IACA 算法 | 74.6 | 80.3 | 20 | 8 | 7.1 | 0 |

算法相比, 复杂的环境条件几乎不会对 IACA 算法的安全性产生影响。根据表 2 可知, 通过路径长度、收敛速度、安全性和算法收敛代数 4 维度评价指标的取值对 IACA 算法、基本蚁群算法、文献 [11] 和文献 [12] 横向对比分析可知, 复杂环境中 IACA 算法在评价指标中均取得最优运行结果。因此, 通过在复杂环境中的仿




图 11 复杂环境下算法的最优路径




图 12 复杂环境算法的迭代收敛图

真实验进一步验证了 IACA 算法的稳定性和有效性。

5 结束语

文章中介绍了一种针对 AGV 路径规划的蚁群算法, 该算法基于改进的势场, 并利用势场力来解决蚁群算法在初期的盲目迭代和容易陷入局部最优解的问题。为了让规划的路径更贴近实际需求, 我们对状态转移概率、信息素更新阈值进行了优化, 并将路径长度、安全性和平滑性等约束因素整合到信息素更新规则中, 并综

合考虑交通规则约束。经过仿真实验证明, 在相同实验环境下, 本文路径规划算法迭代速度相对传统蚁群算法提高 8 倍、拐点数量和不安全路径点数量也均少于其他算法, 证明了本文算法的简洁高效和安全可靠性。

参考文献:

[1] SZLAPCZYNSKI R. A unified measure of collision risk derived from the concept of a ship domain [J]. The Journal of Navigation, 2006, 59 (3): 477 - 490.

[2] ZHU D, SUN J. A new algorithm based on Dijkstra for vehicle path planning considering intersection. D-star Lite algorithm and its experimental study on dynamic path planning [J]. Microcomput, 2015, 34 (7): 16 - 19.

[3] SINGH Y, SHARMA S, SUTTON R, et al. A constrained A* approach towards optimal path planning for an unmanned surface vehicle in a maritime environment containing dynamic obstacles and ocean currents [J]. Ocean Engineering, 2018, 169: 187 - 201.

[4] REN Z, RATHINAM S, LIKHACHEV M, et al. Multi-objective path-based D* lite [J]. IEEE Robotics and Automation Letters, 2022, 7 (2): 3318 - 3325.

- [5] 邓腾飞. 基于改进狼群算法的船舶路径规划 [D]. 哈尔滨: 哈尔滨工程大学, 2020.
- [6] DORIGO M, MANIEZZO V, COLORNI A. Ant system: optimization by a colony of cooperating agents [J]. *IEEE Transactions on Systems, Man, and Cybernetics, Part B (Cybernetics)*, 1996, 26 (1): 29-41.
- [7] LIU X, LI Y, ZHANG J, et al. Self-adaptive dynamic obstacle avoidance and path planning for USV under complex maritime environment [J]. *IEEE Access*, 2019, 7: 114945-114954.
- [8] 刘新宇, 谭力铭, 杨春曦, 等. 未知环境下的蚁群-聚类自适应动态路径规划 [J]. *计算机科学与探索*, 2019, 13 (5): 846-857.
- [9] 刘新宇. 机器人动态路径规划及其在海上交通中的仿真应用 [D]. 昆明: 昆明理工大学, 2019.
- [10] DENTLER J, ROSALIE M, DANOY G, et al. Collision avoidance effects on the mobility of a UAV swarm using chaotic ant colony with model predictive control [J]. *Journal of Intelligent & Robotic Systems*, 2019, 93: 227-243.
- [11] 岳春播, 黄俊, 邓乐乐. 改进蚁群算法在 AGV 路径规划上的研究 [J]. *计算机工程与设计*, 2022, 43 (9): 2533-2541.
- [12] 李传奇, 黄卫华, 章政, 等. 基于改进蚁群算法的 AGV 多目标路径规划 [J]. *组合机床与自动化加工技术* (上接第 193 页)
- [9] 练鑫鑫. 基于被动测量的网络拓扑推断及可视化研究 [D]. 西安: 西安电子科技大学, 2018.
- [10] HA S, LEE W, KANG J, KANG J. Cooperative spectrum sensing in non-time-slotted full duplex cognitive radio networks [C] // Las Vegas; *IEEE*, 2016: 820-823.
- [11] CHEN J, LI R, WANG J. Movable platform-based topology detection for a geographic routing wireless sensor network [J]. *Sensors (Switzerland)*, 2020, 20 (13): 1.
- [12] 严文博. 基于 Traceroute 的多路径拓扑主动发现算法的设计与实现 [D]. 成都: 电子科技大学, 2022.
- [13] SIVAGAMINATHAN V, SHARMA M, HENGE S K. Intrusion detection systems for wireless sensor networks using computational intelligence techniques [J]. *Cybersecurity*, 2023, 6 (27): 1-12.
- [14] 潘楠, 王勇, 陶晓玲. 基于 OSPF 协议的网络拓扑发现算法 [J]. *计算机工程与设计*, 2011, 32 (5): 1550-1553.
- [15] 邵豪. 无线通信网拓扑结构识别技术研究 [D]. 长沙: 国防科学技术大学, 2019.
- [16] AMMAR M A, ABDEL-LATIF M S, BADRAN K M, et al. 2021 Tenth international conference on intelligent computing and information systems (ICICIS) [C] //Cairo, Egypt; *IEEE*, 2021: 41-50.
- 术, 2021, 572 (1): 1-5.
- [13] 李二超, 齐款款. B 样条曲线融合蚁群算法的机器人路径规划 [J]. *计算机应用*, 2021, 41 (12): 3558-3564.
- [14] 李钧泽, 孙咏, 焦艳菲, 等. 基于改进人工势场的 AGV 路径规划算法 [J]. *计算机系统应用*, 2022, 31 (3): 269-274.
- [15] WANG W, ZHAO J, LI Z, et al. Smooth path planning of mobile robot based on improved ant colony algorithm [J]. *Journal of Robotics*, 2021, 20: 1-10.
- [16] 李伟. 基于电机效率的电动汽车 AMT 换挡规律优化 [D]. 成都: 西华大学, 2014.
- [17] 许万, 程兆, 朱力, 等. 一种基于改进人工势场法的局部路径规划算法 [J]. *电子测量技术*, 2022, 45 (19): 83-88.
- [18] 程亮, 干宏程, 刘勇. 基于改进蚁群算法的 CVRP 问题研究 [J]. *重庆工商大学学报 (自然科学版)*, 2021, 38 (5): 81-86.
- [19] 张立, 范馨月. 蚁群算法下的巡逻重点路线规划 [J]. *数学的实践与认识*, 2020, 50 (16): 144-152.
- [20] 张靖雯. 基于蚁群算法的智能汽车轨迹控制方法研究 [J]. *工业仪表与自动化装置*, 2022, 288 (6): 41-44.
- [21] 龚铭凡, 徐海祥, 冯辉, 等. 基于改进蚁群算法的智能船舶路径规划 [J]. *武汉理工大学学报 (交通科学与工程版)*, 2020, 44 (6): 1072-1076.
- [17] 刘子彤, 丁国如, 王威, 等. 面向非合作无线网络的拓扑感知技术分析 [J]. *指挥与控制学报*, 2021, 7 (2): 153-159.
- [18] CAI R, LIU Y, HUANG Z, et al. Granger causality discovery algorithm for topological Hawkes processes with priori-constraints. [J]. *Application Research of Computers*, 2022, 39 (6): 1668-1672.
- [19] EICHLER M, DAHLHAUS R, DUECK J. Graphical modeling for multivariate hawkes processes with nonparametric link functions [J]. *Journal of Time*, 2016, 38 (2): 1-22.
- [20] LAGHATE M, CABRIC D. Learning wireless networks' topologies using asymmetric granger causality [J]. *IEEE Journal on Selected Topics in Signal Processing*, 2018, 12 (1): 233-247.
- [21] 宋叶辉, 丁国如, 徐承龙, 等. 面向非合作无人机通信网络的通联拓扑推理技术 [J]. *电子与信息学报*, 2022, 44 (3): 924-939.
- [22] SHEN Y, FU X, et al. Topology identification of directed graphs via joint diagonalization of correlation matrices [J]. *IEEE Transactions on Signal and Information Processing over Networks*, 2020, 6 (99): 271-283.
- [23] ENRICO T, ANDREA G. Blind wireless network topology inference [J]. *IEEE Transactions on Communications*, 2021, 69 (2): 1109-1120.