

DOI:10.19651/j.cnki.emt.2212046

基于自适应蚁群算法的 AGV 路径规划优化^{*}

刘礼 刘勇 孙云权 郭涛

(四川轻化工大学自动化与信息工程学院 宜宾 644000)

摘要: 针对传统蚁群算法在 AGV 路径规划中存在拐点数目较多,运行能耗较高等问题,提出一种改进的自适应蚁群算法。首先采用自适应参数调整方法,在迭代过程中不断调整信息素浓度和启发式信息的相对重要性,以增强蚂蚁搜索的目的性;其次引入多目标路径性能评价指标,在路径长度的单一指标基础上引入路径风险指标和拐点数目,以实现 AGV 路径规划的全局综合优化;然后提出一种奖惩机制更新信息素增量,针对不同程度评价指标的路径提供不同的信息素更新规则,避免算法陷入早熟;最后引入准均匀三次 B 样条平滑策略,进一步优化最优解。在 20×20 和 30×30 不同复杂程度的环境下进行仿真实验,本文改进算法相比传统蚁群算法在转弯次数上减少了 $11.3\% \sim 38.2\%$,在收敛速度上提升了 $79.8\% \sim 87.9\%$,验证了本文改进算法的有效性、可行性和优越性。

关键词: 路径规划;蚁群算法;AGV;多目标评价指标;B 样条曲线平滑策略

中图分类号: TP18;TP242 文献标识码: A 国家标准学科分类代码: 510.8060

Path planning optimization of AGV based on adaptive ant colony algorithm

Liu Li Liu Yong Sun Yunquan Guo Tao

(School of Automation and Information Engineering, Sichuan University of Science & Engineering, Yibin 644000, China)

Abstract: In view of the shortcoming of traditional ant colony algorithm in path planning of AGV, such as a large number of inflection points and high operating energy consumption, an improvement adaptive ant colony algorithm is proposed in this paper. Firstly, the adaptive parameter adjustment method to continuously adjust the relative importance of pheromone concentration and heuristic information in the iterative process to enhance the direction of ant search; Secondly, the multi-objective path performance evaluation index is introduced. Based on the single index of path length, the path risk index and the steering times are introduced to achieve the global comprehensive optimization of AGV path planning; Then a reward and punishment mechanism is proposed to update the pheromone increment, which provides different pheromone update rules for the paths of different evaluation indicators to avoid the algorithm falling into premature; Finally, the quasi uniform cubic B-spline smoothing strategy is introduced to further optimize the optimal solution. At 20×20 and 30×30 Simulation experiments are carried out in different complexity environments. Compared with the traditional ACO, the steering times of improved ACO is reduced by $11.3\% \sim 38.2\%$, and the path optimization speed is increased by $79.8\% \sim 87.9\%$, which verifies the effectiveness, feasibility and superiority of the improved ACO.

Keywords: path planning; ant colony algorithm; AGV; multi-objective evaluation index; B-spline curve smoothing strategy

0 引言

随着社会的不断发展,智能制造得到了广泛的发展。物料运输是车间生产过程中不可或缺的一部分,也是车间作业调度问题的重要组成部分^[1]。在智能化生产车间,自动引导车(automated guided vehicle, AGV)用于解决 2 个问题,一个是任务调度,另一个是路径规划^[2],两者都是影

响车间绩效的重要部分。本文重点介绍路径规划部分,旨在为 AGV 找到最佳的运输路径,这对缩短转运距离、节省物料转运时间、降低物流成本、提高运营效率等发挥着重要作用。近年来,国内外学者提出了多种算法用于解决移动机器人路径规划的问题,包括 Dijkstra 算法^[3]、A* 算法^[4]、快速遍历随机树算法(rapidly-exploring random trees, RRT)^[5]等传统路径规划算法,和遗传算法^[6]、粒子群算

收稿日期:2022-11-11

*基金项目:四川省转移支付重点研发项目(21YZFZDYZF0021)资助

法^[7]、蚁群算法^[8]等启发式智能优化算法。其中,Dorigo等^[9]最早提出的蚁群算法,虽然有着算法结构比较简单、环境适应性较强以及较强的鲁棒性等优点,但也存在着收敛速度慢、容易陷入局部最优等缺陷。因此,研究传统蚁群算法并进行改进优化,对AGV的路径规划研究有着非常重要的意义。

Miao等^[10]通过引入角度引导因子和障碍物排除因子,以提高蚁群算法的全局搜索能力,再引入多目标性能指标,实现机器人路径规划的全局综合优化。赵静等^[11]通过改进启发函数和信息素挥发因子,提高了蚂蚁搜索的目的性和算法的搜索速度,根据迭代次数的变化从而动态的改变信息素挥发因子,使得在算法后期也能有较强的全局搜索能力。唐旭晖等^[12]提出一种局部分块优化策略,对局部区域存在的冗余折点状况有较好的改善,采用初始信息素差异化分布策略,使目标区域范围和其它区域范围的信息素存在一定的浓度差,从而提高算法前期的收敛精确度。Bai等^[13]提出了一种基于动态反馈A*搜索算法和改进蚁群算法的路径规划方法,通过优化初始信息素和实现参数动态闭环调整,使算法逃离局部最优的能力得到有效提高。杨立炜等^[14]提出一种多层次优化方法,通过引入平滑函数,增加蚂蚁路径搜寻时直行的概率,通过二次路径优化,去除不必要的拐点,使规划的路径平滑度得到进一步的提升。尽管上述学者通过对算法的改进,使路径寻优的能力得到提升,但针对AGV货物转运等实际问题仍然存在些许不足,如针对死锁现象的改进不够彻底;状态转移概率没有考虑角度的因素;规划的路径没有增加对拐弯次数的分析等。

针对上述蚁群算法在路径规划中存在的问题,本文提出一种基于自适应改进的蚁群算法。改进传统蚁群算法的启发式信息、状态转移概率和信息素更新规则,提高蚁群搜索的目的性和方向性,避免陷入局部最优;建立多目标路径性能评价指标,从多个约束角度构建安全可靠的最优路径;利用准均匀三次B样条曲线对规划的路径进行平滑策略处理,使路径平滑度得到进一步的优化。

1 蚁群算法

1.1 栅格环境建模

本文选择栅格法来建立AGV工作环境模型^[15]。一般在栅格环境中,使用0值表示环境地图中的可行区域,对应地图中的白色栅格;而1值用来表示环境地图中的障碍物区域,对应地图中的黑色栅格。如图1所示,本文采用直角坐标系与序号相结合的方法对栅格进行识别,每个栅格都有唯一的序列号和对应的位置坐标,栅格序号与对应坐标的变换关系如式(1)所示。

$$\begin{cases} x_i = a(\text{bmod}(i, N_x) - 0.5) \\ y_i = a\left(N_y + 0.5 - \text{ceil}\left(\frac{i}{N_y}\right)\right) \end{cases} \quad (1)$$

式中: (x_i, y_i) 为第 i 个栅格的位置坐标; $\text{mod}()$ 是冗余操

作符; $\text{ceil}()$ 表示朝正无穷大四舍五入; N_x 和 N_y 分别为横向和纵向的栅格数。

	1	2	3	4	5
4	6	7	8	9	10
3	11	12	13	14	15
2	16	17	18	19	20
1	21	22	23	24	25

图1 AGV栅格环境

如图2(a)所示,处于凹形障碍物内的可行区域不但会增加路径长度,还有增加死锁现象发生的概率^[16],降低了蚁群算法的路径搜索质量。从图2(a)可以看出,由栅格4到栅格16处,经过栅格11的长度比栅格10的路径长度长,由栅格7到栅格9处,经过栅格14的长度比栅格8的路径长度长,而且在栅格14处蚂蚁如果向栅格20、26移动,还会造成死锁现象的发生。本文改进算法会将凹形障碍物内的可行栅格更改为障碍物栅格,实现效果如图2(b)所示。

1	2	3	4	5	6
7	8	9	10	11	12
13	14	15	16	17	18
19	20	21	22	23	24
25	26	27	28	29	30
31	32	33	34	35	36

(a) 栅格环境处理前

1	2	3	4	5	6
7	8	9	10	11	12
13	14	15	16	17	18
19	20	21	22	23	24
25	26	27	28	29	30
31	32	33	34	35	36

(b) 栅格环境处理后

图2 栅格环境处理前后地图

1.2 状态转移概率

蚂蚁在觅食的过程中,会利用之前蚂蚁遗留下来的信息

息素,按照状态转移概率来进行不同路径的选择,同时分泌信息素影响后续的蚂蚁。假设蚂蚁 k 在时刻 t 位于第 i 个栅格,通过式(2)计算每条可选路径的转移概率,然后通过轮盘赌规则确定下一个栅格。

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t)]^\beta}{\sum_{s \in allowed_k} [\tau_{is}(t)]^\alpha [\eta_{is}(t)]^\beta}, & j \in allowed_k \\ 0, & \text{其他} \end{cases} \quad (2)$$

式中: $\tau_{ij}(t)$ 为 t 时刻从第 i 个栅格到第 j 个栅格的信息素浓度; α 为信息素浓度因子; β 为启发式因子; $s \in allowed_k$ 是蚂蚁 k 在当前第 i 个栅格周围可选的后续栅格集; $\eta_{ij}(t)$ 是时刻 t 从第 i 个栅格到第 j 个栅格的路径启发式信息,其计算如式(3)所示。

$$\eta_{ij}(t) = \frac{1}{d_{ij}} \quad (3)$$

式中: d_{ij} 为第 i 个栅格到第 j 个栅格的欧式距离。

1.3 信息素更新规则

信息素更新策略是蚁群算法不断实现正反馈的一个过程,蚁群正是通过这种方式来引导后代不断收敛并得到一条最优的路径。当代所有蚂蚁都到达目标后,每只蚂蚁将根据式(4)、(5)更新信息素浓度。

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

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

式中: ρ 是信息素挥发系数, $(1 - \rho)$ 是信息素残留因子; $\tau_{ij}(t)$ 为当前迭代路径 (i, j) 上的信息素, $\Delta\tau_{ij}(t)$ 为当前迭代路径 (i, j) 上的信息素增量; M 为蚂蚁总量, $\Delta\tau_{ij}^k(t)$ 为蚂蚁 k 在路径 (i, j) 上留下的信息素浓度。

采用 ant cycle system 模型计算信息素浓度值, $\Delta\tau_{ij}^k(t)$ 根据式(6)计算:

$$\Delta\tau_{ij}^k(t) = \begin{cases} \frac{Q}{L_k}, & ij \in L_k \\ 0, & \text{其他} \end{cases} \quad (6)$$

式中: Q 为信息素强度; L_k 表示第 k 只蚂蚁在本次迭代过程中所探索的路径总长度。

2 改进蚁群算法

2.1 改进启发函数和转移概率

在蚁群算法中,由于启发式信息只考虑当前栅格与待选栅格之间的距离,导致蚂蚁在算法早期搜索时毫无头绪。因此在启发式信息的改进中额外考虑选定栅格与目标栅格之间的距离。此外,在算法后期,为了弱化启发式信息的作用,平衡算法的全局搜索能力和收敛速度,引入了一个自适应调整因子。改进启发式信息如式(7)所示。

$$\eta_{ij}(t) = \lambda \left(\frac{1}{\omega_1 d_{ij} + \omega_2 d_{jG}} \right) \quad (7)$$

式中: d_{ij} 为第 i 个栅格到第 j 个栅格的距离; d_{jG} 为待选第

j 个栅格与目标栅格 G 之间的距离, ω_1, ω_2 为距离权重系数, $\omega_1 + \omega_2 = 1$; λ 是一个自适应调整因子。在算法早期,由于 λ 接近于 1,可以加强启发式信息的作用,从而加快算法的收敛速度;在后期,由于 λ 远小于 1,可以弱化启发式信息的作用,从而使算法的全局搜索能力得到增强。 λ 的计算如式(8)所示。

$$\lambda = \frac{2}{1 + \exp(k/K)} \quad (8)$$

式中: k 为当前迭代次数, K 为最大迭代次数。

由于算法前期的信息素分布无差异化,会使蚂蚁在路径搜索过程中目的性较差,不能朝着目标点前进以至死锁现象的造成,减慢算法收敛速度^[17]。因此在启发式信息的基础上增添引导因子,蚂蚁在进行下一位置选择时增加对角度的考虑,引导蚁群向着终点移动,引导因子为 $\omega^{\cos\varphi_{jiE}}$ 。当前节点 i 与目标节点 E 的连线和 i 点与下一点 j 的连线的夹角如式(9)所示。

$$\varphi_{jiE} = \arccos \frac{(jx - ix) \times (Ex - ix) + (jy - iy) \times (Ey - iy)}{L_{ij} \times L_{iE}} \quad (9)$$

式中: L_{ij} 为 i, j 两节点的欧式距离, L_{iE} 为 i, E 两节点的欧式距离。当 2 个方向的夹角越小时, $\cos\varphi_{jiE}$ 就越接近于 1, 引导函数在状态转移概率中所起到的作用也就越大。

改进状态转移概率如式(10)所示。

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\alpha [\eta_{ij}(t) \omega^{\cos\varphi_{jiE}}]^\beta}{\sum_{s \in allowed_k} [\tau_{is}(t)]^\alpha [\eta_{is}(t) \omega^{\cos\varphi_{is}}]^\beta}, & j \in allowed_k \\ 0, & \text{其他} \end{cases} \quad (10)$$

由于蚁群算法的信息素会不断增加,影响后代蚂蚁的搜索性能,导致在迭代后期寻得更优路径时,也易因为不同路径的信息素浓度差过大,从而使算法易陷入局部最优^[18]。本文采用一种改进自适应贪婪策略,随着迭代次数的增加,信息素浓度和启发式信息的相对重要性不断调整。如式(11)、(12)所示,随着迭代次数的增加,信息素浓度因子逐渐增大,而启发式因子逐渐减小,从而有效提高了算法逃离局部最优的能力。

$$\alpha = \alpha_{\min} + (\alpha_{\max} - \alpha_{\min}) \times \left(\frac{k}{K} \right) \quad (11)$$

$$\beta = \beta_{\max} - (\beta_{\max} - \beta_{\min}) \times \left(\frac{k}{K} \right) \quad (12)$$

式中: $\alpha_{\max}, \alpha_{\min}$ 为信息素浓度因子的最大值和最小值, $\beta_{\max}, \beta_{\min}$ 为启发式因子的最大值和最小值, k 表示当前迭代次数, K 表示最大迭代次数。

同时,为了提高蚁群算法的搜索质量,避免陷入局部最优,本文采用参数自适应伪随机转移策略,如式(13)、(14)所示。

$$j = \begin{cases} \operatorname{argmax}\{[\tau_{ij}(t)]^a [\eta_{ij}(t) \omega^{\cos\varphi_{jiE}}]^{\beta}\}, & q \leq q_0 \\ P_{ij}^k(t), & \text{其他} \end{cases} \quad (13)$$

$$q_0 = \delta_0 \times \cos\left(\frac{k\pi}{4K}\right) \quad (14)$$

式中: q_0 为伪随机状态转移概率的切换值; δ_0 为比例系数; q 是均匀分布在[0,1]中的随机变量。 q_0 随着算法的迭代逐渐减小,易于前期的全局搜索和后期的随机搜索,减小状态转移的盲目性。

2.2 多目标路径性能评价指标

针对食用单一的路径长度指标进行路径规划,提出多目标路径性能评价指标,在现有的基础上增添路径风险指数和拐点数目,以获得更精准有效的路径。

1)路径长度

路径长度指标直接影响AGV的运行时间。总路径长度 $L(p)$ 如式(15)、(16)所示。

$$L(p) = \sum_{i=1}^{n-1} d(p_i, p_{i+1}) \quad (15)$$

$$d(p_i, p_{i+1}) = \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (16)$$

其中, n 为路径上的栅格数; p_i 是路径上的第*i*个栅格, (x_i, y_i) 是 p_i 的坐标值; $d(p_i, p_{i+1})$ 是 p_i 到 p_{i+1} 的欧式距离。

2)路径风险指数

路径风险指数保证AGV尽可能远离障碍物获得一条无碰撞的路径,与通行路径和最近的障碍物之间的距离直接相关。安全指数的计算公式如下:

$$S(p) = \sum_{i=1}^{n-1} \sqrt{(x_o - x_i)^2 + (y_o - y_i)^2} \quad (17)$$

式中: $S(p)$ 为AGV所处环境的风险指数; (x_o, y_o) 是最接近 p_i 的障碍物的坐标值。

3)拐点数目

尽量少的转弯次数能够保证AGV尽可能地获得平滑的路径, N_{turn} 为拐点数目。

在实际应用中,一些性能指标可能会引起AGV路径优化冲突。例如,最小化路径长度会增加路径风险指数,而最小化路径风险指数会增加路径长度。因此,在AGV路径优化中采用加权的方法来平衡性能指标,如式(18)所示。

$$J(p) = \omega_l \times L(p) + \omega_s \times \frac{1}{S(p)} + \omega_n \times N_{turn} \quad (18)$$

式中: $\omega_l, \omega_s, \omega_n$ 分别为路径长度、路径风险指数和拐点数目的权重系数。3个权重系数的取值一般根据AGV的工作环境和实际经验设置。

2.3 改进信息素更新规则

为解决蚁群算法的信息素更新不能及时引导蚂蚁寻找最优解的问题,基于最大最小蚂蚁模型和精英蚂蚁模型,提出一种奖惩机制更新信息素增量,使蚂蚁更偏向于在最优路径方向的一定范围内搜索,可以有效提高算法的收敛速

度和搜索质量。改进的信息素浓度更新公式如式(19)所示。

$$\Delta\tau_{ij}^k(t) = \begin{cases} \frac{Q}{J_{best}} \times \frac{J_{best} + J_{worst}}{4}, & ij \in p_{bs} \\ -\frac{Q}{J_{worst}}, & ij \in p_{ws} \\ \frac{Q}{J_k}, & \text{其他} \end{cases} \quad (19)$$

式中: J_k 为蚂蚁*k*当前迭代路径的多目标路径性能评价指标,可以使规划路径的综合性能更好。 J_{best} 为本次迭代最优路径的多目标值; J_{worst} 为本次迭代最差路径的多目标值; p_{bs} 为本次迭代的最优路径; p_{ws} 为本次迭代的最差路径。

在蚁群算法搜索最优解的过程中,除了信息素浓度的更新规则外,信息素挥发因子也会对算法的性能产生很大的影响。本文采用自适应信息素挥发系数 ρ 来调节算法的全局性质和收敛速度,如式(20)所示。

$$\rho = \epsilon \times \exp\left(\frac{1}{2} \times \frac{k}{k+K}\right) \quad (20)$$

式中: ϵ 为调整系数。在算法初期 ρ 值较小,因此各路径信息素浓度差也较小,此时蚁群的引导功能不是很强,从而使得蚂蚁的全局搜索能力得到提升,进而提高算法的精度。随着迭代次数的增加,挥发系数 ρ 迅速增大,各路径信息素浓度差增大,蚁群的引导功能增强、搜索速度提高,使得算法快速收敛。

2.4 准均匀三次B样条平滑策略

文献[19]在得到最优路径后,采用Bezier曲线进行平滑处理,但Bezier曲线还存在无法更改阶次、无法进行局部修改、当拐点较多时获得的曲线不够平滑等不足。B样条曲线除了保持Bezier曲线所具有的优点外,还弥补了上述所有的缺陷。B样条曲线由 $P_0, P_1, P_2, \dots, P_n$ 共*n*+1个控制点组成,这些控制点用于定义样条曲线的走向、界限范围,*k*阶B样条曲线的数学表达式如式(21)所示。

$$P(u) = [P_0 \ P_1 \ \dots \ P_n] \begin{bmatrix} B_{0,k}(u) \\ B_{1,k}(u) \\ \vdots \\ B_{n,k}(u) \end{bmatrix} = \sum_{i=0}^n P_i B_{i,k}(u) \quad (21)$$

式中: $B_{i,k}(u)$ 是第*i*个*k*阶B样条基函数,与控制点 P_i 相对应, $k \geq 1$, u 是自变量。

基函数具有如式(22)德布尔-考克斯递推式:

$$B_{i,k}(u) = \begin{cases} \begin{cases} 1, & u_i \leq u \leq u_{i+1} \\ 0, & \text{其他} \end{cases}, & k = 1 \\ \frac{u - u_i}{u_{i+k-1} - u_i} B_{i,k-1}(u) + \frac{u_{i-k} - u}{u_{i+k} - u_{i+1}} B_{i+1,k-1}(u), & k \geq 2 \end{cases} \quad (22)$$

约定 $0/0=0$ 。

式中: u_i 是一组被称为节点矢量的非递减序列的连续变化值, 首末值一般定义为 0 和 1, 该序列如式(23)所示。

$$[u_0, u_1, \dots, u_k, u_{k+1}, \dots, u_N, u_{N+1}, \dots, u_{N+k}] \quad (23)$$

因此, 本文利用准均匀三次 B 样条对最优路径进行平滑处理, 可以减少以转弯的不连续性造成对车身硬件的磨损, 满足 AGV 的运动学约束的同时, 进一步缩短路径长度。

2.5 算法步骤

基于自适应蚁群算法的路径规划具体流程如图 3 所示, 具体步骤如下:

1) 初始化参数。初始化蚂蚁数目 M , 最大迭代次数 K , 信息素浓度因子 α , 启发式因子 β , 信息素强度 Q , 距离权重系数 ω_1, ω_2 , 比例系数 δ_0 , 多目标权重系数 $\omega_l, \omega_s, \omega_n$ 等参数。

2) 路径选择。将蚂蚁放置在起点, 根据式(10)、(13)更新下一栅格节点。

3) 计算评价函数。每当有一只蚂蚁到达终点时, 根据多目标函数式(18)计算该蚂蚁的评价指标。

4) 更新全局信息素浓度。待所有蚂蚁完成路径规划后, 找到本次迭代中评价指标最优和最差的蚂蚁, 并根据式(19)进行信息素的更新, 根据式(20)进行信息素挥发系数 ρ 的更新。

5) 更新启发式信息。根据式(7)、(8)更新启发式信息, 信息素浓度和启发因子根据式(11)、(12)限制在合适的范围内。

6) 最优路径的输出。判断是否满足结束条件, 如果满足, 则输出最优路径; 否则转到步骤 2), 继续执行循环, 直到达最大迭代次数。

7) 路径优化。根据式(21)对寻得的最优路径进行准均匀三次 B 样条平滑。

3 仿真实验及数据分析

为验证基于自适应蚁群算法的优越性, 分别采用 20×20 和 30×30 这 2 种复杂程度不同的环境进行仿真实验。实验平台的计算机操作系统为 Win11(64 bit), 处理器为 Core(TM) i7-10750H, 内存为 8 GB, 仿真软件为 MATLAB R2019b。

仿真参数设置: 蚂蚁数目为 50, 最大迭代次数为 100, $Q=1$, $\omega_1=0.1$, $\omega_2=0.9$, $\alpha_{\max}=1.5$, $\alpha_{\min}=0.5$, $\beta_{\max}=8.5$, $\beta_{\min}=2.5$, $\delta_0=0.15$, $\omega_l=1$, $\omega_s=5.5$, $\omega_n=0.5$, $\epsilon=0.65$ 。

3.1 20×20 地图实验对比

在 20×20 的栅格地图中, 对本文改进算法与传统蚁群算法和文献[11]算法进行比较。3 种算法路径规划结果如图 4~6 所示, 改进算法路径平滑曲线如图 7 所示, 收敛曲线如图 8 所示。

由图 4~8 可知, 传统蚁群算法在迭代第 33 次时, 首次搜索到最短路径, 其长度为 29.8, 但由于其信息素分布较

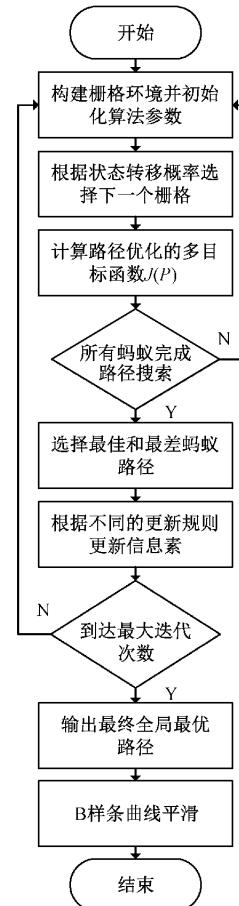


图 3 算法流程图

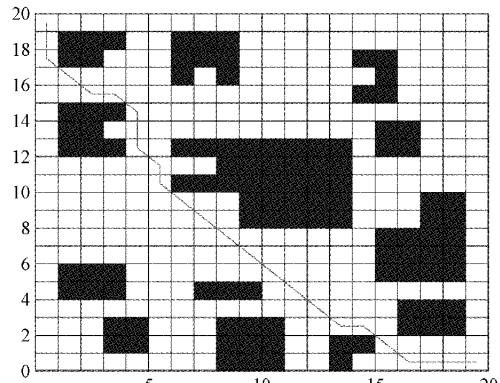


图 4 20×20 环境下传统蚁群算法路径仿真

为均匀, 最优路径的反馈能力较差, 导致其迭代至 69 次才收敛, 有时还会陷入局部最优解。文献[11]算法迭代次数达到 9 次时收敛, 得到的路径长度为 29.8, 该算法通过构建新的启发函数和挥发因子, 使收敛速度得到提升, 但由于其对地图搜索的目的性不够, 导致规划的最终路径拐点过多。本文改进算法在迭代至第 7 次时就达到收敛, 收敛的最短路径长度为 29.8, 其收敛速度和路径平滑度也都有了较大幅度的提升。

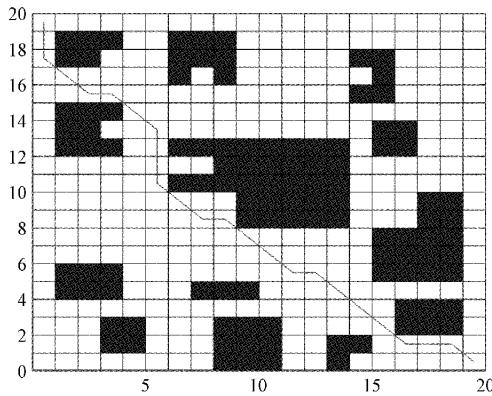


图5 20×20环境下文献[11]算法路径仿真

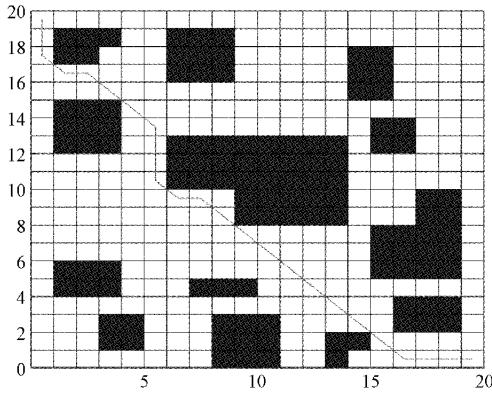


图6 20×20环境下本文改进算法路径仿真

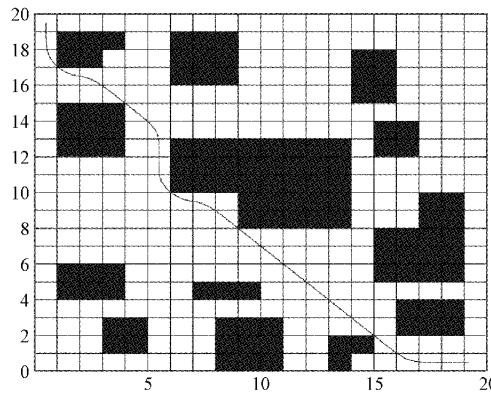


图7 本文改进算法路径平滑曲线

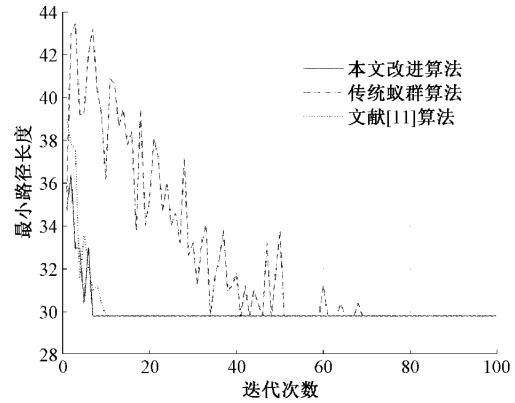


图8 各算法收敛曲线变化趋势

对3种算法分别进行50次仿真实验,统计各算法的路
径长度、迭代次数和拐点个数,统计结果如表1所示。

表1 各算法在路径规划中的结果比较

算法	路径长度			迭代次数			拐点数目		
	最优值	平均值	标准差	最优值	平均值	标准差	最优值	平均值	标准差
传统蚁群算法 ^[9]	29.8	30.2	0.4	28	62.3	20.8	8	9.7	1
文献[11]算法	29.8	30.1	0.4	7	19.4	8.1	9	12.9	2.1
本文改进算法	29.8	29.8	0.1	3	7.5	1.3	6	8.6	1

由表1可知,3种算法虽然都可以搜索到最短路径,但本文改进算法路径长度的平均值比传统蚁群算法和文献[11]算法分别缩短了1.3%和1.0%,标准差也均下降了0.3,达到了稳定的0.1,说明在较为简单的地图环境中,该改进算法具有良好且稳定的寻优能力。迭代次数的平均值比传统蚁群算法和文献[11]算法分别减少了87.9%和61.3%,其标准差分别下降了19.5和6.8,也进一步说明了改进方向对算法的迭代速度能力方面有了较大的提升。平均拐点数目比传统蚁群算法和文献[11]算法分别减少了11.3%和33.3%。说明传统蚁群算法由于启发式信息仅和下一节点的距离有关,导致在进行路径探索时全局观念较差,并且在信息素更新时,蚁群算法的正反馈会使次优解很快占据优势,就算在一次迭代过程中寻得更优路径,也由于局部最优路径信息素的积累,导致无法跳出

局部最优。而文献[11]算法的启发式函数还引入了目标节点的信息,迭代次数得到大幅减少,但仍存在拐点过多的情况。本文改进算法由于多目标路径性能评价指标的引入,拐点数目减少,最终规划的路径也更加平滑,且由于在路径规划前对栅格环境的处理,使得死锁现象大大减少,且最短路径和平均路径长度相等,说明该改进算法每次都能搜索到最优路径,拥有在简单环境中跳出局部最优的能力。

3.2 30×30地图实验对比

为进一步验证本文改进算法也能适应复杂环境,在各项参数不变的情况下,在30×30复杂栅格地图进行仿真实验。其路径规划和收敛曲线如图9~13所示。对3种算法分别进行50次仿真实验,统计各算法的路径长度、迭代次数和拐点个数,统计结果如表2所示。

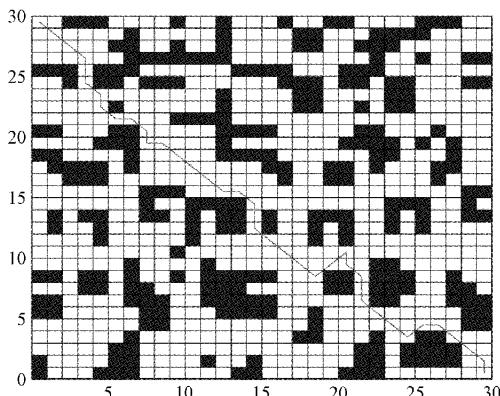


图 9 30×30 环境下传统蚁群算法路仿真

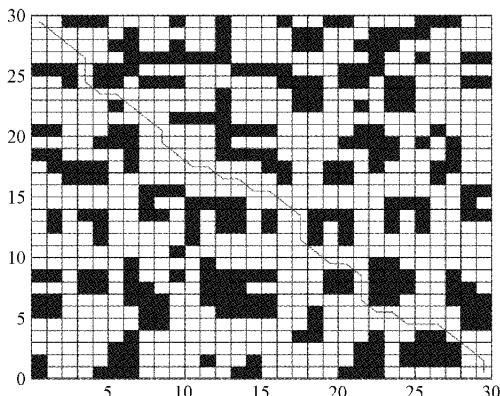


图 10 30×30 环境下文献[11]算法路径仿真

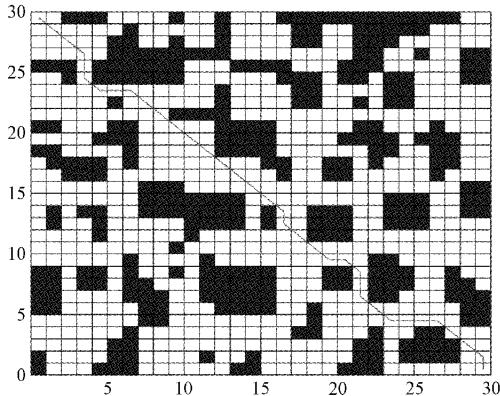


图 11 30×30 环境下本文改进算法路径仿真

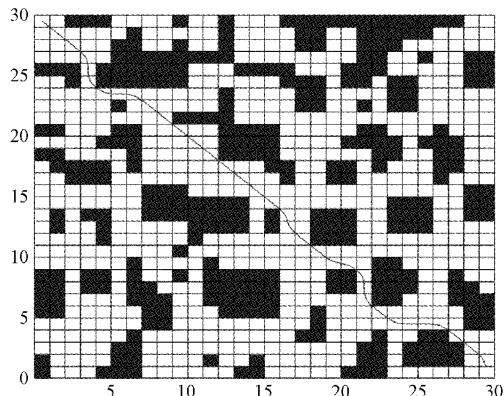


图 12 本文改进算法路径平滑曲线

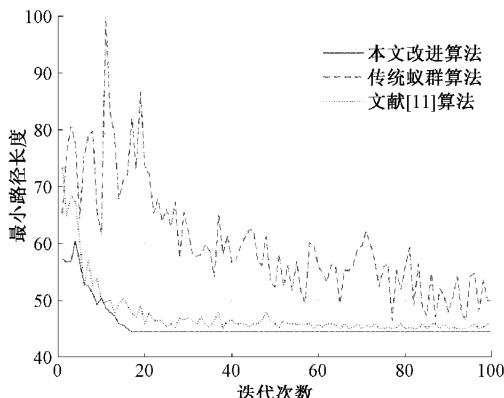


图 13 各算法收敛曲线变化趋势

从仿真的结果图中可以看出,随着地图环境的复杂化程度增加,传统蚁群算法的寻优能力显著下降,规划的路径过于曲折,且迭代无法收敛,易陷入局部最优。说明传统蚁群算法信息素的正反馈函数性能不强,启发式信息的方向性较弱。文献[11]算法虽能搜索到最短路径,但收敛速度很慢,且有时在一个范围内不断波动,无法收敛。相比于简单环境,寻优能力存在很大的下降,且最终规划的路径还存在拐点过多的缺点。本文改进算法在迭代至第 17 次时搜索到最短路径长度为 44.53。平均迭代次数比文献[11]算法减少了 62.1%,而传统蚁群算法由于环境复杂未能收敛,路径长度的平均值比传统蚁群算法和文献[11]算法分别缩短了 8.4% 和 1.8%,其标准差为 0.38,较另外

表 2 各算法在路径规划中的结果比较

算法	路径长度			迭代次数			拐点数目		
	最优值	平均值	标准差	最优值	平均值	标准差	最优值	平均值	标准差
传统蚁群算法 ^[9]	44.53	49.85	2.54	43	83	16.06	16	23.64	3.51
文献[11]算法	44.53	45.66	0.68	10	44.38	22.98	14	19.6	2.64
本文改进算法	44.53	44.86	0.38	11	16.8	2.95	11	14.62	1.8

两种算法分别下降了 2.16 和 0.3,说明随着地图环境的复杂化,该改进算法寻优能力的优势得到进一步的展现。拐

点数目的平均值比传统蚁群算法和文献[11]算法分别减少了 38.2% 和 25.4%,标准差也分别下降了 1.71 和 0.84。

这是由于改进启发式信息和伪状态转移概率使得蚂蚁在复杂环境中也能有明确的方向性,改进信息素更新规则能够提高脱离局部最优的能力,多目标路径性能评价指标能够有效减少拐点数目。而传统算法由于启发信息较弱,在路径搜索时,受障碍物的影响较大,容易造成拐点数目较多,环绕障碍物行走等缺点,从而造成路径长度和迭代次数的增加。文献[11]算法的启发式函数引入了目标节点的信息,减少搜寻过程中的盲目性,但由于地图过于复杂,信息素的更新不够具有针对性与差异性,导致其迭代次数过高。

总之本文改进算法在最短路径,收敛速度和拐点数目等方面都优于传统蚁群算法和文献[11]算法。

4 结 论

针对 AGV 路径规划收敛速度慢,寻优能力差等问题,提出了一种自适应蚁群算法。该算法首先通过对栅格环境的处理,减少死锁现象的发生;然后引入启发式自适应调整因子和自适应信息素挥发因子,增强路径搜索的方向性和目的性,提高算法的收敛速度和寻优能力;再引入多目标路径性能指标和准均匀三次 B 样条平滑策略,有效减少拐点数目,在得到最优解的基础上进一步优化。但在改进策略的过程中,引入了较多的控制参数,从而导致该算法的参数敏感度有了一定程度的提高。最后通过在不同复杂程度栅格地图下进行仿真实验,实验表明本文改进算法能够快速、高质量地规划出最短路径。在后续的研究中,会尝试将该改进算法应用于移动机器人的路径规划,也会考虑结合其他群智能优化算法,进一步实现对传统蚁群算法的改进。

参考文献

- [1] LI J Q, LIU Z M, LI C D, et al. Improved artificial immune system algorithm for type-2 fuzzy flexible job shop scheduling problem[J]. IEEE Transactions On Fuzzy Systems, 2021, 29(11): 3234-3248.
- [2] 曹红倩. 应用改进 Q-learning 算法解决柔性作业车间调度问题[J]. 国外电子测量技术, 2022, 41(4): 164-169.
- [3] ALSHAMMREI S, BOUBAKER S, KOLSI L. Improved dijkstra algorithm for mobile robot path planning and obstacle avoidance [J]. Computers, Materials & Continua, 2022, 72(3): 5939-5954.
- [4] CHEN J X, LUO Y. Dynamic path planning for mobile robots based on the improved a-star algorithm [J]. Academic Journal of Computing & Information Science, 2021, DOI:10.25236/AJCIS.2021.040814.
- [5] 陈都,侯明,张学东. 改进 RRT 结合 B 样条的移动机器人路径规划研究[J]. 电子测量技术, 2022, 45(23): 38-44.
- [6] SURESH K S, VENKATESAN R. Mobile robot path planning using multi-objective genetic algorithm in industrial automation [J]. Soft Computing, 2022, 26(15): 7387-7400.
- [7] 张红柱,蒋奇. 基于改进离散粒子群优化算法的路径规划[J]. 计算机仿真, 2022, 39(9): 462-466, 496.
- [8] 刘沛,蒋超. 蚁群算法优化 PID 的机器人位置伺服控制[J]. 国外电子测量技术, 2021, 40(6): 59-63.
- [9] DORIGO M, MANIEZZO V, COLORNI A. Ant system: Optimization by a colony of cooperating agents[J]. IEEE Transactions on SMC-Part B, 1996, 26(1): 29-41.
- [10] MIAO C W, CHEN G Z, YAN C L, et al. Path planning optimization of indoor mobile robot based on adaptive ant colony algorithm [J]. Computers & Industrial Engineering, 2021, 156, DOI:10.1016/J.CIE.2021.107230.
- [11] 赵静,汤云峰,蒋国平,等. 基于改进蚁群算法的移动机器人路径规划[J]. 南京邮电大学学报(自然科学版), 2019, 39(6): 73-78.
- [12] 唐旭晖,辛绍杰. 改进蚁群算法的移动机器人路径规划[J]. 计算机工程与应用, 2022, 58(5): 287-295.
- [13] BAI L, DU C L. Design and simulation of a collision-free path planning algorithm for mobile robots based on improved ant colony optimization[J]. Ingénierie des Systèmes d'Information, 2019, 24(3): 331-336.
- [14] 杨立炜,付丽霞,王倩,等. 多层优化蚁群算法的移动机器人路径规划研究[J]. 电子测量与仪器学报, 2021, 35(9): 10-18.
- [15] 吕成,崔濛,吴刚. 基于 Dijkstra 算法的极区船舶航线规划方法[J]. 船舶工程, 2022, 44(6): 10-19.
- [16] 张国林. 未知环境下移动机器人路径规划算法研究[D]. 南京:南京信息工程大学, 2022.
- [17] 王猛,邢关生. 基于改进蚁群算法的机器人路径规划[J]. 电子测量技术, 2020, 43(24): 52-56.
- [18] 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.
- [19] 李二超,齐款款. 贝塞尔曲线融合双向蚁群算法的移动机器人路径规划[J]. 陕西师范大学学报(自然科学版), 2022, 50(3): 79-88.

作者简介

刘礼,硕士研究生,主要研究方向为路径规划与任务调度。

E-mail:775067172@qq.com

刘勇,副教授,博士研究生,主要研究方向为白酒智能化酿造。

E-mail:islil1123@163.com