

DOI:10.19651/j.cnki.emt.2105919

机器人路径规划的改进粒子群-蚁群算法

张真诚

(青岛科技大学 自动化与电子工程学院 青岛 266061)

摘要:针对传统蚁群算法的易陷入局部最优、求解精度低的缺点,提出了一种改进的粒子群-蚁群算法进行最优路径的求解。该算法采用具有线性递减惯性权重系数的粒子群算法进行路径预规划,由此得到蚁群算法的初始信息素分布;同时,通过在蚁群算法中引入了新的启发函数、线性递减的挥发系数和按路径长度排序的信息素增量系数,使算法的收敛速度得到提高。实验结果表明,该算法在两种环境下路径长度的误差分别为0%和0.9297%,与传统算法相比,该算法具有更高的求解精度。

关键词:路径规划;粒子群算法;蚁群算法;启发函数;信息素增量系数

中图分类号:TP242.6 文献标识码:A 国家标准学科分类代码:510.8050

Improved particle swarm optimization and ant colony algorithm for robot path planning

Zhang Zhencheng

(College of Automation and Electronic Engineering, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: Aiming at the shortcomings of traditional ant colony algorithm, such as easy to fall into local optimum and low precision of solution, this paper proposes an improved particle swarm optimization and ant colony algorithm to calculate the optimal path. In this algorithm, particle swarm optimization algorithm with linear decreasing inertia weight coefficient is used for path pre-planning, so as to obtain the initial pheromone distribution of ant colony algorithm. At the same time, by introducing new heuristic function, linear decreasing volatility coefficient and pheromone increment coefficient arranged according to path length into ant colony algorithm, the convergence speed of the algorithm is improved. Experimental results show that the path length error of the algorithm in two environments is 0% and 0.9297% respectively. Compared with the traditional algorithm, this algorithm has higher accuracy.

Keywords: path planning; particle swarm optimization; ant colony algorithm; heuristic function; pheromone increment coefficient

0 引言

机器人的路径规划问题一直是一个热点研究方向,其主要任务是寻找一条从起点到终点的无碰撞最优路径。路径规划算法主要有势场算法^[1]、神经网络算法^[2]、遗传算法^[3]、粒子群算法^[4]、蚁群算法^[5]等。粒子群算法是由Eberhart和Kennedy于1995年提出的源于鸟群捕食行为的全局优化算法,蚁群算法是由Dorigo等于1991年提出的模仿蚂蚁在寻找食物时发现路径的启发式全局优化算法。

对于解决路径规划问题,两种算法都具有一定的局限性,需要对传统算法进行改进。文献[6]在死区循环、参数优化、激励因素等方面进行了改进,有效地提高了算法的鲁

棒性。文献[7]通过动态分配每一条蚁群路径,提高了蚂蚁选择正确方向的概率。此外,将自适应策略^[8]、避障策略和优质蚂蚁信息素更新策略^[9]引入蚁群算法中,可以提高算法的收敛性、稳定性和求解精度。在此基础上,采用多种算法结合的方法,可以取得更好的路径规划效果,如文献[10]将独狼算法和蚁群算法相结合,通过设计自适应增强函数并构造信息素优化机制,降低算法陷入局部最优的可能性。文献[11]构造了模糊规划器并优化了蚁群算法的概率选择公式和信息素更新公式,提高了算法的效率和路径规划能力。

虽然上述文献能够有效解决路径规划问题,但在算法的启发函数、挥发系数和信息素增量系数方面还可以继续改进。本文首先利用粒子群算法进行路径预规划得到最优

参考路径,然后将该路径转化为蚁群算法的初始信息素分布,最后在不同环境下对本文算法和传统蚁群算法进行仿真对比实验,实现了算法求解精度和路径规划效果的提高,为蚁群算法的改进提供了新的思路。

1 粒子群算法的路径规划

1.1 粒子群算法

粒子群算法的所有粒子根据自己的个体最优值和粒子群的全局最优值,对自己的速度和位置进行更新,其速度和位置的更新公式如下^[12]:

$$v_t = \omega v_{t-1} + c_1 r_1 (p_{t-1} - x_{t-1}) + c_2 r_2 (g_{t-1} - x_{t-1}) \quad (1)$$

$$x_t = x_{t-1} + v_t \quad (2)$$

其中, p_{t-1} 为该粒子上一时刻的个体最优值; g_{t-1} 为上一时刻的全局最优值; ω 为惯性权重系数; c_1 和 c_2 为分别为自身学习因子和社会学习因子; r_1 和 r_2 为介于(0,1)之间的随机数。

本文采用线性递减的惯性权重系数,该方法能够平衡算法的全局寻优能力和局部寻优能力,其公式如下:

$$\omega = \omega_{\min} + \frac{T-t}{T} \cdot (\omega_{\max} - \omega_{\min}) \quad (3)$$

其中, $\omega_{\max}, \omega_{\min}$ 为惯性权重系数的最大值和最小值; T 为总迭代次数; t 为当前迭代次数。

本文的适应度值函数为从起点到终点的无碰撞路径的长度,其公式如下:

$$f = \sum_{i=1}^n \sqrt{(x_{i+1} - x_i)^2 + (y_{i+1} - y_i)^2} \quad (4)$$

其中, (x_i, y_i) 和 (x_{i+1}, y_{i+1}) 分别为路径上相邻两点的坐标; (x_1, y_1) 和 (x_{n+1}, y_{n+1}) 分别为路径的起点坐标和终点坐标。

1.2 粒子群算法流程

本文改进的粒子群算法的主要步骤如下:

- 1) 环境建模,确定起点、终点和所有障碍物的坐标;
- 2) 初始化粒子群算法参数:粒子数 N_{pop} ,最大迭代次数 T ,学习因子 c_1, c_2 ,惯性权数最大值和最小值 $\omega_{\max}, \omega_{\min}$;
- 3) 初始化所有粒子的速度和位置;
- 4) 根据式(4),计算每个粒子的适应度值函数,更新个体最优值和全局最优值;
- 5) 根据式(3),计算当前的惯性权重系数,并根据式(1)和(2),更新每个粒子的速度和位置;
- 6) 重复步骤 4)~5),直至达到算法的最大迭代次数;
- 7) 保存粒子群算法搜索到的最优参考路径。

2 粒子群-蚁群算法的路径规划

2.1 粒子群算法和蚁群算法的衔接

本文的粒子群-蚁群算法是利用粒子群算法进行路径

预规划,转化后得到蚁群算法的初始信息素分布。首先根据环境信息得到信息素的初始值 τ_{ij}^S ,并将粒子群算法得到的最优参考路径转化为信息素加强值 $\Delta\tau_{ij}^{PSO}$,从而得到蚁群算法的初始信息素分布 τ_{ij}^0 ^[13]。其公式如下:

$$\tau_{ij}^0 = \tau_{ij}^S + \Delta\tau_{ij}^{PSO} \quad (5)$$

蚁群算法可以在粒子群算法找到的最优参考路径的基础上对路径进行更细致的探索和优化,避免出现在算法迭代初期由于各路径上的信息素浓度相差不大导致蚂蚁盲目搜索的情况,提高了算法的收敛速度和搜索能力。

2.2 概率选择公式

利用蚁群算法进行路径规划时,位于某栅格的蚂蚁对下一可行栅格的选择取决于两栅格间路径上的信息素浓度值与启发函数值,两数值越大的栅格被蚂蚁选择的概率更大。蚂蚁从当前栅格 i 移动到下一栅格 j 的概率选择公式如下^[14]:

$$p_{ij} = \begin{cases} \frac{\tau_{ij}^\alpha \cdot \eta_{ij}^\beta}{\sum_{j \in J_i} \tau_{ij}^\alpha \cdot \eta_{ij}^\beta}, & j \in J_i \\ 0, & \text{其他} \end{cases} \quad (6)$$

其中, α 为信息素启发因子; β 为期望启发因子; τ_{ij} 为路径 $Path_{ij}$ 上的信息素浓度; η_{ij} 为路径 $Path_{ij}$ 上的启发函数; J_i 为当前栅格 i 的所有下一可行栅格的集合。

2.3 启发函数的改进

在算法的迭代初期,由于初始信息素的浓度差较小,故蚂蚁对下一可行栅格的选择主要依赖于蚂蚁到周围栅格的启发函数值。对于传统蚁群算法,其启发函数如下:

$$\eta = \frac{1}{D_{ig}} \quad (7)$$

其中, D_{ig} 为当前栅格到目标栅格的距离。

由上式可知,传统蚁群算法中相邻栅格的启发函数值差异较小,蚂蚁在寻找路径时具有盲目性。为了提高路径搜索的目的性,本文对传统蚁群算法的启发函数进行优化,引入了当前栅格到下一可行栅格的距离和下一可行栅格到目标栅格的距离^[15]。本文改进的启发函数如下:

$$\eta_{ij} = \frac{1}{(\lambda D_{ij} + \mu D_{jG})^2} \quad (8)$$

其中, D_{ij} 为当前栅格到下一可行栅格的距离; D_{jG} 为下一可行栅格到目标栅格的距离; λ 和 μ 分别为 D_{ij} 和 D_{jG} 的权重系数。

在所有下一可行栅格中,最接近目标的栅格,其距离最短,故该路径上的启发函数值最大,蚂蚁选择该栅格的概率最大,蚂蚁可以快速地以最短的距离到达目标栅格。

2.4 信息素更新公式的改进

当所有蚂蚁搜索完毕后,对信息素进行更新:减少一部分旧信息素,增加一部分新信息素。随着迭代次数的增加,最优路径上的信息素浓度不断提高,最终找到全局最优路径。本文的信息素更新策略如下:

$$\tau_{ij}^k = (1 - \rho)\tau_{ij}^{k-1} + \gamma \Delta\tau_{ij}^k \quad (9)$$

其中, τ_{ij}^{k-1} 为上次迭代路径 $Path_{ij}$ 上的信息素浓度; $\Delta\tau_{ij}^k$ 为本次迭代路径 $Path_{ij}$ 上的信息素增量; ρ 为旧信息素的挥发系数; γ 为新信息素的增量系数。

传统蚁群算法的挥发系数为定值, 算法的全局搜索能力较差并且收敛速度较慢^[16]。本文提出了随迭代次数线性递减的挥发系数, 解决了蚁群算法的全局搜索能力较和收敛速度不平衡的问题, 其公式如下:

$$\rho = \frac{MK}{K+k} \quad (10)$$

其中, K 为总迭代次数; k 为当前迭代次数; M 为正常数。

在算法初期, 算法搜索到的路径较差, 挥发系数较大, 信息素的挥发较多, 可以减少较差路径对于算法后续路径搜索的干扰, 提高算法的搜索能力。在算法后期, 算法找到的路径接近全局最优路径, 此时挥发系数较小, 保留较多的信息素, 不断加大最优路径和其他路径上的信息素浓度差, 从而提高算法的收敛速度。

本文提出了按路径长度排序的信息素增量系数, 该方法可以避免所有路径上的信息素增量没有差异的情况发生。通过增大当前最优路径与其他路径的信息素增量差值, 从而在经过多次迭代后, 有效提高各路径上的信息素浓度差, 使得算法可以快速找到全局最优路径。其公式如下:

$$\gamma = \sqrt{\frac{n_{order}}{N_{path}}} \quad (11)$$

其中, n_{order} 为所有到达目标栅格的路径按长度从大到小排列的序号; N_{path} 为所有到达目标栅格的路径个数。

2.5 改进粒子群-蚁群算法流程

本文改进的蚁群算法的主要步骤如下:

- 1) 利用栅格地图法进行环境建模;
- 2) 初始化蚁群算法参数: 蚂蚁数 N , 最大迭代次数 K , 起始栅格 S , 目标栅格 G , 信息素启发因子 α , 期望启发因子 β , D_{ij} 的权重系数 λ , D_{jG} 的权重系数 μ , 常数 M ;
- 3) 根据粒子群算法搜索到的最优参考路径和栅格环境的信息素初始值, 得到蚁群算法的初始信息素分布;
- 4) 将蚂蚁放在起始栅格位置, 并根据式(8), 计算启发函数, 开始搜索路径;
- 5) 根据式(6), 确定蚂蚁接下来要移动的栅格, 其中已通过栅格和障碍物栅格不能被选择, 直至抵达目标栅格;
- 6) 重复步骤 4)~5), 下一只蚂蚁开始进行路径的搜索, 直至蚁群对路径搜索完毕后, 对路径长度进行从大到小排序, 根据式(10)和(11), 计算挥发系数和信息素增量系数, 并根据式(9)进行信息素更新;
- 7) 保存蚂蚁搜索到的路径及其长度;
- 8) 重复步骤 4)~7), 达到最大迭代次数后, 得到全局最优路径。

3 仿真实验

3.1 实验参数设置

粒子群算法的参数设置为: 两种环境的粒子数量 $N_{pop} = 20, 40$; 两种环境的最大迭代次数 $T = 40, 60$; 自身学习因子 $c_1 = 2$, 社会学习因子 $c_2 = 2$; 惯性权数最大值 $\omega_{max} = 0.9$, 最小值 $\omega_{min} = 0.6$ 。

蚁群算法的参数设置为: 蚂蚁数量 $N = 50$; 最大迭代次数 $K = 100$; 起始栅格 $S = 1$, 两种环境的目标栅格 $G = 400, 1600$; 信息素启发因子 $\alpha = 1$, 期望启发因子 $\beta = 7$; D_{ij} 的权重系数 $\lambda = 1$, D_{jG} 的权重系数 $\mu = 3$; 常数 $M = 0.5$ 。

3.2 实验结果及分析

为了验证改进算法的路径规划效果, 在 MATLAB R2017a 的仿真环境下, 本文分别在 20×20 (环境 1), 40×40 (环境 2)的栅格地图中对传统算法和本文算法进行了 15 次仿真对比实验。

两种算法的最优路径对比图和收敛曲线对比图如图 1~4 所示。两种算法的路径长度和运行时间的实验数据如表 1~4 所示。

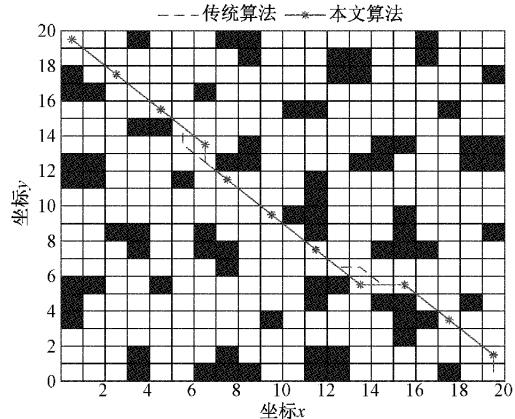


图 1 环境 1 下的最优路径对比图

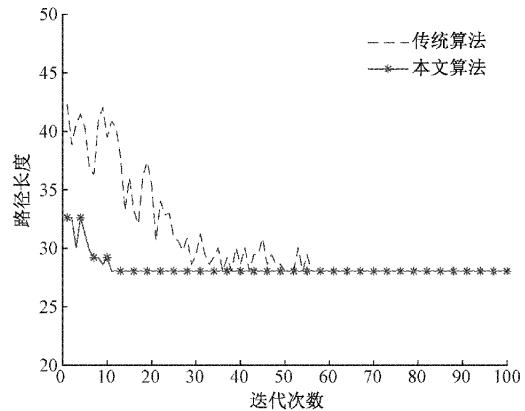


图 2 环境 1 下的收敛曲线对比图

由图 1、2 可知, 对于相对简单的环境 1, 传统蚁群算法可以搜索到全局最优路径, 但需要在迭代 55 次左右才能收

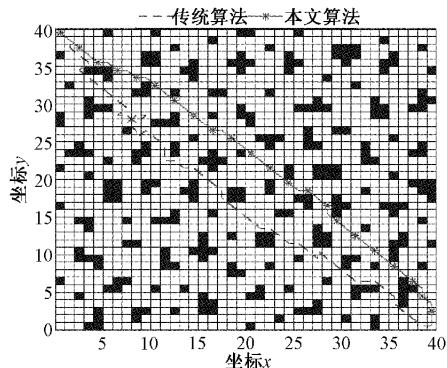


图 3 环境 2 下的最优路径对比图

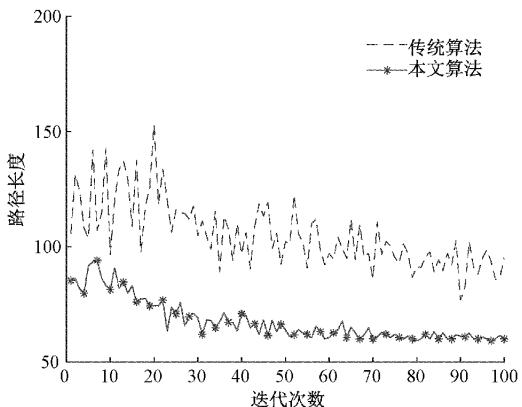


图 4 环境 2 下的收敛曲线对比图

表 1 环境 1 路径长度

算法	路径长度		
	最优长度	平均长度	最差长度
传统算法	28.041 6	28.041 6	28.041 6
本文算法	28.041 6	28.041 6	28.041 6

表 2 环境 1 运行时间

算法	运行时间/s		
	最短时间	平均时间	最长时间
传统算法	10.397 6	12.409 7	14.218 6
本文算法	3.721 2	4.107 0	4.562 2

表 3 环境 2 路径长度

算法	路径长度		
	最优长度	平均长度	最差长度
传统算法	65.497 5	72.722 0	77.982 8
本文算法	58.083 3	58.623 3	59.840 6

表 4 环境 2 运行时间

算法	运行时间/s		
	最短时间	平均时间	最长时间
传统算法	151.504 1	154.788 7	157.156 8
本文算法	144.327 7	149.013 8	153.837 4

敛, 收敛速度较慢; 本文算法在 10 代左右即可搜索到全局最优路径, 算法的稳定好, 收敛速度相对较快。由图 3、4 可知, 对于相对复杂的环境 2, 传统蚁群算法无法找到全局最优路径并且存在路径曲折和反复经过同一个点的现象, 且算法不能收敛, 波动较大; 而本文算法能够在迭代 90 次左右搜索到全局最优路径, 其路径比较平滑, 算法的稳定性较好, 路径搜索能力较强。

由表 1~4 可知, 对于环境 1, 两种算法的路径长度与实际最优路径的长度 28.041 6 相同, 误差都为 0%, 但本文算法平均运行时间为 4.107 0 s 远小于传统算法的 12.409 7 s, 算法的快速性较好; 对于环境 2, 实际最优路径长度为 58.083 3, 本文算法的平均路径长度为 58.623 3 远小于传统算法的 72.722 0, 本文算法的误差为 0.929 7% 也远小于传统算法的 25.202 9%, 故本文算法的求解精度较高, 同时本文算法的平均运行时间为 149.013 8 s, 与传统算法的 154.788 7 s 相比略有减少。

4 结 论

本文提出了一种改进的粒子群-蚁群算法。采用线性递减的惯性权重系数, 提高了粒子群算法的路径搜索能力; 引入了新的启发函数、线性递减的挥发系数和按路径长度排序的信息素增量系数, 提高了蚁群算法的求解精度和收敛速度。实验结果表明, 本文算法与传统算法相比效果较好。但本文算法在复杂环境下, 还存在迭代次数较多且多次实验得到最优路径长度不完全相同的问题, 还需要对算法进行改善。

参 考 文 献

- [1] 朱颖, 李元鹏, 张亚婉, 等. 基于改进人工势场法的搬运机器人路径规划[J]. 电子测量技术, 2020, 43(17): 101-104.
- [2] 陈秋莲, 郑以君, 蒋环宇, 等. 基于神经网络改进粒子群算法的动态路径规划[J]. 华中科技大学学报(自然科学版), 2021, 49(2): 51-55.
- [3] 段建民, 陈强龙. 基于改进人工势场-遗传算法的路径规划算法研究[J]. 国外电子测量技术, 2019, 38(3): 19-24.
- [4] 刘晓欢, 张德干, 张捷, 等. 一种基于粒子群优化改进策略的智能驾驶车辆路径规划方法[J]. 北京交通大学学报, 2020, 44(5): 87-97.
- [5] 梁凯, 毛剑琳. 基于改进蚁群算法的室内移动机器人路径规划[J]. 电子测量技术, 2019, 42(11): 65-69.
- [6] DING Y F, PAN Q. Path planning for mobile robot search and rescue based on improved ant colony optimization algorithm [J]. Applied Mechanics and Materials, 2011, 1326: 1039-1044.
- [7] SONG C H. Global path planning method for USV system based on improved ant colony algorithm [J].

- Applied Mechanics and Materials, 2014, 3252: 785-788.
- [8] 徐玉琼, 娄柯, 李婷婷, 等. 改进自适应蚁群算法的移动机器人路径规划[J]. 电子测量与仪器学报, 2019, 33(10): 89-95.
- [9] 江明, 王飞, 葛愿, 等. 基于改进蚁群算法的移动机器人路径规划研究[J]. 仪器仪表学报, 2019, 40(2): 113-121.
- [10] 张毅, 权浩, 文家富. 基于独狼蚁群混合算法的移动机器人路径规划[J]. 华中科技大学学报(自然科学版), 2020, 48(1): 127-132.
- [11] WANG M C, ZHU C Y, WANG F Y, et al. Multi-factor of path planning based on an ant colony optimization algorithm [J]. Annals of GIS, 2020, 26(2): 101-112.
- [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.
- [13] 张玮, 马焱, 赵捍东, 等. 基于改进烟花-蚁群混合算法的智能移动体避障路径规划[J]. 控制与决策, 2019, 34(2): 335-343.
- [14] 朱艳, 游晓明, 刘升. 基于启发式机制的改进蚁群算法[J]. 信息与控制, 2019, 48(3): 265-271.
- [15] 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.
- [16] 王雷, 石鑫. 基于改进蚁群算法的移动机器人动态路径规划[J]. 南京理工大学学报, 2019, 43(6): 700-707.

作者简介

张真诚,硕士研究生,主要研究方向为移动机器人路径规划。
E-mail:1608865228@qq.com