

DOI: 10.19650/j.cnki.cjsi.J2108440

轮式智能车动-静随机障碍物避障研究*

吴宇¹, 郝万君², 卞长庚², 周嘉玉², 张正夫¹

(1. 苏州科技大学物理科学与技术学院 苏州 215009; 2. 苏州科技大学电子与信息工程学院 苏州 215009)

摘要:针对智能车传统A*算法存在拐点较多,不平滑,易发生碰撞问题,提出一种A*与DWA融合改进随机避障方法。在A*优化算法中通过计算节点间斜率,选择关键节点,剔除冗余节点,改进了评价函数,提高A*算法速度和路径平滑性。针对A*优化算法无法规避随机障碍物及DWA算法存在速度与安全性不兼顾问题,提出一种兼顾速度与安全性优化的DWA自适应算法。在每两个优化关键节点间采用自适应动态窗口法进行局部规避随机动-静态障碍物,使智能车自主、平滑、安全、高效规避障碍。实验显示:本文算法与A*、Dijkstra、改进A*与基本DWA融合算法相比,在3种环境下全局路径长度、拐点数、时间平均降低2.9%、36.2%、24.7%;2.9%、40.7%、30.9%;0.31%、23.8%、13.6%,能够实现随机避障且路径平滑,验证了本算法的有效性。

关键词:智能车;改进A*算法;改进DWA算法;避障;路径规划

中图分类号:TH166 TP242 **文献标识码:**A **国家标准学科分类代码:**510.80

Research on dynamic-static random obstacle avoidance for the wheeled smart car

Wu Yu¹, Hao Wanjun², Bian Changgeng², Zhou Jiayu², Zhang Zhengfu¹

(1. School of Physical Science and Technology, Suzhou University of Science and Technology, Suzhou 215009, China;
2. School of Electronic and Information Engineering, Suzhou University of Science and Technology, Suzhou 215009, China)

Abstract: The traditional A* algorithm for smart cars has many inflection points that are not smooth and prone to collision. To address these issues, a fusion of A* and DWA is proposed to improve the random obstacle avoidance method. In the A* optimization algorithm, by calculating the slope between nodes, key nodes are selected and redundant nodes are eliminated. The evaluation function is improved. The speed and path smoothness of the A* algorithm are enhanced. The A* optimization algorithm cannot avoid random obstacles and the DWA algorithm has the problems of imperfect speed and safety. To solve these problems, an optimized DWA adaptive algorithm is proposed, which considers speed and safety. Between each two optimized key nodes, an adaptive dynamic window method is used to locally avoid random dynamic-static obstacles. Therefore, smart cars can avoid obstacles autonomously, smoothly, safely and efficiently. Compared with the algorithm of A*, Dijkstra, the improved A* and the basic DWA fusion algorithm, experimental results show that the global path length, number of inflection points, and time are reduced by an average of 2.9%, 36.2%, and 24.7%; 2.9%, 40.7%, and 30.9%; 0.31%, 23.8%, and 13.6% in three environments. It can achieve random obstacle avoidance and smooth path, which verifies the effectiveness of this algorithm.

Keywords: smart car; improved A* algorithm; improved DWA algorithm; obstacle avoidance; path planning

0 引言

随着人工智能技术的发展,以无人车为代表的智能车得到了广泛应用^[1],在国防军事、生产生活、智能制造

等方面有着十分广阔的发展前景。其中路径规划可分为全局路径规划与局部路径规划^[2],为智能车提供安全、可靠的行进策略,是无人驾驶领域关键技术之一。但在实际复杂工作环境下,行进路线上不可避免的会存在随机障碍物的干扰,在全局路径上车辆就会发生碰撞。在进

收稿日期:2021-08-19 Received Date: 2021-08-19

* 基金项目:国家自然科学基金(51477109)项目资助

行全局规划路径的同时也要具备局部路径随机避障^[3-4]。此外,智能车路径规划效率不高也会严重影响任务完成质量。所以,研究一种兼具最优全局规划及局部随机避障结合的高效路径规划算法显得尤为重要^[5-6]。

A*算法是路径规划中经典的启发式全局路径规划算法^[7-8],具有较快的速度和较短的路径优点,但忽略了智能车的运动约束,规划出的路径曲率不连续,车辆容易在拐点处产生突变轨迹。依靠车辆实时传感器数据的局部路径规划算法有动态窗口法^[9-10](dynamic window approach, DWA)和人工势场法^[11]。王志中^[12]提出将人工势场和A*算法融合,能够在较为复杂环境下实现避障功能,但是人工势场法规划出的路径平滑性有待提高,曲率不连续的规划路线不利于智能车的行进。DWA算法规划出的路径简单,具备局部避障。王凡等^[13]提出A*与DWA算法融合,实验显示规划轨迹平滑,具备随机避障的能力,但在进行A*全局规划时,效率较低,无法满足实时性的要求。为了改善传统A*算法规划路径不平滑的弊端,一些学者对其进行了优化改进,取得了一定的成效。文献[14]提出利用求解微分方程的方法减小拐点数量,进行求解微分方程时计算量大,耗时久。文献[15]提出利用改进B样条曲线进行平滑处理,但此方法无法完成动态状况下的平滑处理,并且当行进路线中出现随机障碍物时规划出的路径就会失效,普适性较差。程传奇等^[16]提出优化了A*算法的启发函数,减少了冗余点。文献[17]提出圆弧-直线方法进行平滑处理,能够有效的减少锯齿拐点。劳彩莲等^[18]提出对基本A*算法关键点选取策略进行改进,融合了基本DWA算法进行机器人路径规划。徐玉琼等^[19]提出一种自适应蚁群路径规划算法,根据解的分布情况自适应地进行信息素的更新,在多种步长选择机制下选择最优步长,提高了全局搜索能力。然而,以上A*和蚁群优化算法仅适用于存在已知障碍物的智能车行进规划策略,不具备在复杂状况下随机动-静态障碍物的规避。

针对以上问题,本文提出一种A*与DWA融合改进随机避障算法。算法通过优化A*算法得到最优全局路径目标点后,使用改进自适应DWA算法在每两个相邻节点之间局部路径规划,智能车在路径上遇到随机动-静随机障碍物时,避开障碍,并回到全局规划路径上,保障算法能够让智能车及时避障且路径为最优路径,亦提高了算法的收敛速度。

1 A*算法优化

1.1 地图环境构建

将智能车看为二维平面上的圆点形状物体,行进轨迹在栅格地图中用坐标表示,地图由栅格图表示。栅格

图 N 由栅格单元 N_{ij} 组成,当 $N_{ij} = 0$ 表示无障碍物; $N_{ij} = 1$ 表示有障碍物; $N_{ij} = 2$ 表示智能车起点; $N_{ij} = -1$ 表示智能车行进目标点。

1.2 基本A*算法

A*算法是一种根据代价函数在静态环境中进行全局搜索最优路径的广度优先启发式算法,代价函数如式(1)所示。

$$f(n) = g(n) + h(n) \quad (1)$$

其中, $f(n)$ 表示当前节点的代价估计函数; $g(n)$ 表示从起始节点到达节点 n 的实际代价; $h(n)$ 表示启发函数,得到周围节点的代价值,选择最小代价作为下一个节点,如此重复,直至目标点。

基本A*算法在进行全局路径规划时只搜索从起始点到单个节点的路线,全局规划的路径存在大量拐点,曲率不连续,路线不平滑,会降低智能车行进稳定性。为此本文提出一种A*改进算法,先对采用基本A*算法规划出的全局路径进行拐点提取,然后依据一定规则剔除多余拐点并进行了减少路径长度的改进处理。

1.3 改进A*算法

1) 冗余拐点处理

如图1所示为冗余拐点删除示意图。




图1 冗余拐点删除示意图

Fig. 1 Schematic diagram of redundant inflection point deletion

(1)基本A*算法规划的路径节点坐标记作 $A_i, i = 1, 2, 3 \dots$ 从起始点到目标点依次将节点坐标至于坐标集合Road;栅格图中障碍物不可经过的坐标置于Hinder。

(2)起始点SP,分别计算节点 A_i 与SP的斜率 S_i 并进行后续斜率判断。

(3)如果 $S_{i+1} = S_i$,SP、 A_i 、 A_{i+1} 3节点共线,剔除 A_i ,计算 S_{i+2} ;如果 $S_{i+2} = S_i$,剔除节点 A_{i+1} ,计算 $S_{i+3} \dots$ 。

(4)如果 $\exists S_{i+j} \neq S_i$,对节点 S_{i+j} 进行以下处理:如果SP和 A_{i+j} 之间连线经过障碍物,则 A_{i+j-1} 是重要节点并将其置于集合I中,将 A_{i+j} 置为起始节点NEWSP,将 A_{i+j+1} 置为 A_i ,重复进行步骤(2)~(4)过程,直至到达目标节点;如果SP和 A_{i+j} 之间连线未过障碍物,则剔除该节点 A_{i+j} ,进行步骤(3)继续计算斜率 $S_{i+j+1} \dots$ 。

(5) I 中的节点坐标从起始点到目标节点顺次连接起来即为优化 A^* 算法得到的全局最优路径。

2) 启发函数优化

基本 A^* 算法在进行路径规划时,搜索效率与启发函数的设计密切相关。若启发函数估计值小于实际代价值,虽然算法执行效率高,但关键节点少,最终路径难以是最佳路径;若启发函数估计值大于实际代价值,则搜索节点过多,进行较多的多余计算,造成执行效率低;若两者相等时,执行效率最高。因此,本文启发函数如式(2)所示。

$$f(n) = g(n) + \left(1 + \frac{d}{D} + \lg(P)\right) h(n) \quad (2)$$

其中, d 为当前节点 n 与目标点之间的距离; D 为起止点之间的距离; P 为起止点障碍率。

当前节点在距离目标点较远时,估计代价值远小于实际代价值,加快检索速度;当前节点在距离目标点较近时,估计代价值接近实际代价值降低检索速度;当环境中障碍率较大时,降低搜索速度,增加节点,防止发生碰撞;障碍率较小时增加搜索速度。

如图 2 所示,为基本 A^* 算法和本文改进 A^* 算法路径规划对比图,实线和虚线路径分别为基本 A^* 算法、本文改进算法结果。




图 2 路径规划对比图

Fig. 2 Path planning comparison chart

通过图 2 能够对比得到,基本 A^* 算法的转折节点为 7 个,优化后转折节点为 4 个且全局路径明显比未优化前更加平滑。

2 DWA 算法优化

2.1 基本 DWA 算法

DWA 算法将智能车的位置控制策略转换成速度控制,避障转换成两种速度空间集优化约束,通过预测智能

车实时运动情况预测行进路线,利用评价函数选择代价最小的轨迹作为实际行进策略。

如式(3)所示为智能车速度集合 V_s :

$$V_s = \{(v, \omega) \mid 0 \leq v \leq v_{\max}, -\omega_{\max} \leq \omega \leq \omega_{\max}\} \quad (3)$$

式中: v 为线速度; ω 为角速度。

车的行进路线可看作若干个圆弧构成,考虑到安全性,在某时刻不发生碰撞的允许速度 V_a , 如式(4)所示:

$$V_a = \{(v, \omega) \mid v \leq \sqrt{2 \cdot \text{dis}(v, \omega) \cdot \dot{v}},$$

$$\omega \leq \sqrt{2 \cdot \text{dis}(v, \omega) \cdot \dot{\omega}}\} \quad (4)$$

式中: $\text{dis}(v, \omega)$ 为下一时刻智能车与障碍物之间的距离,因为 v, ω 限制,下一时刻智能车当前角速度 ω_{now} 、线速度 v_{now} 在间隔时间 Δt 下,下一时刻的速度 V_{next} 满足式(5):

$$V_{\text{next}} = (v, \omega) =$$

$$\begin{cases} v_{\text{now}} - \dot{v}_{\max} \Delta t \leq v \leq v_{\text{now}} + \dot{v}_{\max} \Delta t \\ \omega_{\text{now}} - \dot{\omega}_{\max} \Delta t \leq \omega \leq \omega_{\text{now}} + \dot{\omega}_{\max} \Delta t \end{cases} \quad (5)$$

速度 V_{γ} 最终取值范围为 $V_{\gamma} = V_s \cap V_a \cap V_{\text{next}}$

评价函数 $\text{Score}(v, \omega)$ 为智能车进行下一时刻速度预测的依据,选择满足要求的最优速度。

评价函数如式(6)所示:

$$\text{Score}(v, \omega) = \alpha \text{heading}(v, \omega) + \beta \text{dis}(v, \omega) +$$

$$\gamma v(v, \omega) \quad (6)$$

其中, $\text{heading}(v, \omega)$ 为智能车运动方向与目的点角度之差; $\text{dis}(v, \omega)$ 为智能车预测位置与邻近障碍物欧式距离; α, β, γ 为加权系数。

智能车 DWA 预测轨迹如图 3 所示。






图 3 DWA 预测轨迹图

Fig. 3 DWA prediction trajectory chart

图 3 中, A: $(v_{\text{now}} + \dot{v} \cdot \Delta t, \omega_{\text{now}} - \dot{\omega} \cdot \Delta t)$ B: $(v_{\text{now}} - \dot{v} \cdot \Delta t, \omega_{\text{now}} + \dot{\omega} \cdot \Delta t)$ 。

由式(6)可知,传统 DWA 算法加权系数为定值,在速度参数 γ 较小时,行进步数多,时间久; γ 较大时,行进步数少,时间短,安全性低。固定的权值系数使得传统 DWA 算法难以胜任智能车复杂多变的工况环境。

如图 4、5 所示,分别为 γ 较小 ($\gamma = 3$) 和较大 ($\gamma = 30$) 时路径规划示意图。

图 4 $\gamma=3$ 时示意图Fig. 4 Schematic diagram with $\gamma=3$ 图 5 $\gamma=30$ 时示意图Fig. 5 Schematic diagram with $\gamma=30$

通过图 4 与 5 对比可看出:当 γ 较大时,轨迹离障碍物(图 4、5 中黑色区域)距离更近,安全性较低,图 4 路径长度为 29.064 m,时间为 44.189 6 s;图 5 路径长度为 28.998 m,时间为 43.817 1 s。

2.2 DWA 自适应参数优化

考虑到智能车复杂的工作环境,固定不变的权值系数对于复杂动态情况不能很好的适应,受到控制理论自适应算法的启发,本文提出 DWA 自适应参数优化算法,速度参数随着障碍物的不同情况自适应调整。将式(6)中的权值系数做归一化处理($[0,1]$)。

障碍物离智能车距离大于距离阈值,速度系数取最大,距离阈值 D_t 如式(7)所示。

$$D_t = \lambda \cdot (\nu_{\max} / \nu) \quad (7)$$

式中: λ 为参数,实验中取 0.7; $\nu_{\max}$ 为智能车最大线速度;障碍物离智能车距离小于 D_t , ν 的自适应权值 γ_s 与实际最短间距 $D_{\min}$ 之间单调递增, γ_s 如式(8)所示。

$$\gamma_s = \begin{cases} \gamma_{\min} + (\gamma_{\max} - \gamma_{\min}) \left(\frac{D_{\min}}{D_s} \right)^\alpha, & D_{\min} \leq D_s \\ \gamma_{\max}, & D_{\min} > D_s \end{cases} \quad (8)$$

式中: $\gamma_{\max}$ 、 $\gamma_{\min}$ 为防止权值过大或过小设置速度权值系数范围,规定: $\gamma_{\max}$ -DWA 算法以最快速度通过障碍物所对应的速度权值; $\gamma_{\min}$ -DWA 算法通过窄区域且安全性较高时对应的速度权值。因此本文改进 A* 与 DWA 自适

应参数调整融合算法的评价函数如式(9)所示。

$$Newscore(v, w) = \alpha heading(v, w) + \beta dis(v, w) + \gamma_s v(v, w) + \sigma path(v, w) + \delta goal(v, w) \quad (9)$$

其中, $path(v, w)$ 为 DWA 自适应参数调整算法在预测时间间隔 Δt 后的预测节点与 A* 优化算法规划的全局路径的最小距离; $goal(v, w)$ 为预测点与目标节点之间代价值; σ 、 δ 为加权系数。

3 改进 A* 与 DWA 自适应融合

在智能车复杂的工作环境下,一些固定障碍物如墙柱等,其相对位置已知,但在行进路线上仍有大量的随机障碍物情况。为了保障车辆的安全性,本文在 A* 优化算法规划的全局路径上,采用 DWA 自适应参数调整算法进行局部路径规划,依据智能车超声波传感器检测周围环境信息,实行动态局部路径规划,具有随机避障能力。

本文融合改进算法首先利用 A* 优化算法进行全局路径规划,降低拐点数量,增加路径平滑度,得到全局最优节点后,再采用 DWA 自适应参数调整算法在相邻两个节点之间进行局部路径规划,遇到随机障碍物时,参数自主调整,使其能够一条动态随机安全避障的最优平滑轨迹。

具体的算法步骤如下:

- 1) 初始化算法中各参数,建立含有障碍物信息的栅格地图。
- 2) 设置智能车行进任务,选择计算节点。
- 3) 根据式(2)计算下一节点 $f(n)$ 、 $g(n)$ 、 $h(n)$,更新访问节点,若到终点则进入 4),否则回到步骤 1)。
- 4) 提取关键节点,计算斜率,检验是否经过障碍物,更新节点坐标集合。
- 5) 再次进行是否到达终点判断,若到达终点进行下一步,否则返回步骤 4)。
- 6) 智能车按照更新节点运动,进行速度采样,轨迹预测,评价轨迹,按照最优路径行进。
- 7) 进行终点判断,若到达终点,则结束;否则,继续步骤 6) 行进,直到终点结束。

4 实验仿真及结果分析

为验证本文所提算法的有效性、普适性与安全性,利用 MATLAB2018a,分别在 20×20 、 25×25 、 30×30 3 种大小栅格图环境下进行静态障碍物与动态障碍物实验仿真。

4.1 A* 优化算法仿真

本文 A* 优化算法分别与传统 A* 算法、Dijkstra 算法,以及文献[18]中算法在 3 种不同大小环境下的地图中进行对比实验,起点均为左上方,目标点均为右下方

处,环境一、二、三中障碍率 P 分别为 0.192、0.186、0.222,如图 6~8 所示。




图6 环境一下4种算法全局路径规划图
Fig. 6 Environment 1 global path planning diagram of four algorithms




图7 环境二下4种算法全局路径规划图
Fig. 7 Environment 2 global path planning diagram of four algorithms




图8 环境三下4种算法全局路径规划图
Fig. 8 Environment 3 global path planning diagram of four algorithms

从图 6~8 可看出,在不同障碍率和不同地图大小环境下,基本 A* 算法、Dijkstra 算法、文献[18]算法和本文算法均能够进行全局路径规划。如表 1~3 所示,给出了 3 种环境下,4 种不同算法性能参数。从表 1~3 可得出:

在环境一下,本文算法较基本 A* 算法在路径长度、拐点数、时间方面分别降低了 0.6%、50%、23.5%;较 Dijkstra 算法在路径长度、拐点数、时间方面分别降低了 0.6%、62.5%、35.2%;较文献[18]算法在路径长度、拐点数、时间方面分别降低了 0.3%、40%、12.7%。

在环境二下,本文算法较基本 A* 算法在路径长度、拐点数、时间方面分别降低了 3.7%、30%、39.3%;较 Dijkstra 算法在路径长度、拐点数、时间方面分别降低了 4.0%、36.4%、42.4%;较文献[18]算法在路径长度、拐点数、时间方面分别降低了 0.52%、22.2%、20.1%。

在环境三下,本文算法较基本 A* 算法在路径长度、拐点数、时间方面分别降低了 4.3%、28.6%、11.3%;较 Dijkstra 算法在路径长度、拐点数、时间方面分别降低了 4.2%、23.1%、15.1%;较文献[18]算法在路径长度、拐点数、时间方面分别降低了 0.11%、9.1%、8.1%。

通过上述分析可看出本文算法在路径规划长度、拐点数、时间方面比基本 A* 算法和 Dijkstra 算法都有较大降低;在路径长度方面与文献[18]算法相差无几,但本文算法的拐点数和文献[18]算法时间方面在 3 种障碍物地图环境下均比算法有较为明显优化。综上分析,本文 A* 优化算法规划的全局路径有进一步的改善,且路线更

加平滑,离障碍物距离更远,相较于传统 A* 和 Dijkstra 算法而言更加安全。

表 1 20×20 ($P=0.192$) 环境路径规划性能对比表

Table 1 20×20 ($P=0.192$) environmental path planning performance comparison table

算法	路径长度/m	拐点数	时间/s
基本 A* 算法	30.384 8	6	0.024 3
Dijkstra 算法	30.384 8	8	0.028 7
文献[18]算法	30.265 1	5	0.021 3
本文 A* 优化算法	30.176 8	3	0.018 6

表 2 25×25 ($P=0.186$) 环境路径规划性能对比表

Table 2 25×25 ($P=0.186$) environmental path planning performance comparison table

算法	路径长度/m	拐点数	时间/s
基本 A* 算法	37.455 8	10	0.035 4
Dijkstra 算法	37.584 8	11	0.037 3
文献[18]算法	36.265 1	9	0.026 9
本文 A* 优化算法	36.076 8	7	0.021 5

表 3 30×30 ($P=0.222$) 环境路径规划性能对比表

Table 3 30×30 ($P=0.222$) environmental path planning performance comparison table

算法	路径长度/m	拐点数	时间/s
基本 A* 算法	44.526 9	14	0.036 2
Dijkstra 算法	44.484 3	13	0.037 8
文献[18]算法	42.657 4	11	0.034 9
本文 A* 优化算法	42.610 5	10	0.032 1

4.2 本文改进融合算法随机避障效果仿真

分别设置无随机障碍物、1 个随机静态障碍物、2 个随机静态障碍物和静态-动态混合随机障碍物 4 种不同的环境进行本文融合算法动态随机避障性能测试。起点为地图左上角处,终点为右下角,虚线为本文 A* 优化算法规划出的全局最优行进策略,虚线上星点为关键节点,在全局路径规划完成后对智能车速度进行采样,利用 DWA 参数自适应算法进行实时动态避障路径规划,保证智能车全局最优路线。相关参数设置如下:智能车最大线速度 2.5 m/s,最大角速度 $20(^{\circ})/s$,加速度 $0.2 m/s^2$,线速度分辨率 0.02 m/s,角速度分辨率 $2(^{\circ})/s$ 。实验效果如图 9~12 所示。




图 9 无随机障碍物下融合算法规划图

Fig. 9 Planning diagram of fusion algorithm without random obstacles




图 10 一个随机静态障碍物下融合算法规划图

Fig. 10 A planning diagram of the fusion algorithm under a random static obstacle

从图 9~12 可看出,在无随机障碍物、一个静态障碍物、两个静态障碍物和混合动-静态障碍物情况下时,本

文的 A* 与 DWA 融合改进算法均能规划出从起点到终点的一条全局路径。




图 11 两个随机静态障碍物下融合算法规划图

Fig. 11 A planning diagram of the fusion algorithm under two random static obstacle

在行进路线上添加一个随机障碍物如图 10 箭头①所指栅格部分时,智能车在快到静态障碍物时速度降低、改变方向,从而绕过障碍物继续在全局路径上行进直到目标点停止运动。随着随机障碍物数量的增加如图 12 中箭头③所指移动栅格为动态随机障碍物,虚线尾迹线为其行进轨迹,行进策略仍然能够很好的避开障碍物。本文 A* 优化算法无法绕开突然出现的随机障碍物,但智能车在融合了 DWA 参数自适应算法后,通过局部调整路径绕开动-静态随机障碍物并回到全局最优路径上运动到目标点,通过实验可看出本文融合后的算法可以避开障碍物,安全性较好,整体规划路线平滑。如表 4 所示,为融合改进算法路径规划参数性能表。





图 12 混合动-静态障碍物下融合算法规划图

Fig. 12 Planning diagram of fusion algorithm under mixed dynamic-static obstacles

表 4 本文融合改进算法路径规划性能表

Table 4 The path planning performance table of the fusion improved algorithm in this article

地图环境	路径长度/m	时间/s
无随机障碍物	42.495 0	351.2
一个静态随机障碍物	42.592 6	346.4
两个随机障碍物	42.604 8	329.9
混合动-静态随机障碍物	42.560 5	348.5

通过表 4 可看出,在无混合动-静态随机障碍物时:随着障碍物数量的增加路径长度呈增加趋势,但时间降低。这是由于本文 DWA 优化算法在车辆接近障碍物时,速度降低绕开障碍物避免发生碰撞,在绕开后进行提速回到最优全局路径上,形成平均速度比无随机障碍物时高,导致总体时间降低。如图 12 所示在混合动-静态障碍物(共 3 个随机障碍物)环境下,理应路径长度在实验中最长,但实验结果显示长度反而比两个随机障碍物情况下短,时间耗费较久。这是由于动态障碍物行进轨迹与智能车全局行进轨迹有较长时间重合,智能车行进到动态障碍物附近时,速度降低,从图 12 可看出,在规避时,周围可安全通过空间较狭小,车辆以较长时间低速行进绕开动态障碍物从而时间耗费更久;由于动态障碍物的向前运动,导致车在规避时要比仅静态障碍物情况下

绕更大的圈,因此导致路径长度较长。

综上,本文所提的 A^* 与 DWA 参数自适应融合改进算法能够在复杂环境下的动态随机避障目的,并且规划出的路径平滑,安全性、实时性和普适性较好。

5 实际论证

为了验证在实际工作环境下算法有效性、安全性和可靠性,将本文的 A^* 与 DWA 参数自适应融合改进避障算法应用到图 13 中的激光雷达轮式 ROS 智能车中,进行实际论证。轮式智能车参数如表 5 所示,利用激光雷达对周围环境进行扫描建图,环境扫描地图如图 14 所示。



图 13 轮式智能车

Fig. 13 Wheeled smart car



图 14 激光雷达扫描地图

Fig. 14 Lidar scan map

表 5 轮式智能车硬件表

Table 5 Wheeled smart car hardware table

硬件名称	具体型号
激光雷达	思岚科技 A1 激光雷达
深度相机	Astra Pro 深度相机
ROS 主机	英伟达 Jetson Nano
地盘控制	STM32F405RGT6
惯导测量单元	维特九轴陀螺仪传感器
电机	直流有刷电机

如图 15 所示,为实验验证过程图。圆圈为轮式智能车,箭头为车行进的方向,在全局路径上设置一随机障碍物,为避免发生碰撞,对障碍物做膨胀处理。

起点为图 15(a)中①所指横线处,设置好后,智能车规划出全局路径,激光雷达已检测到随机障碍物的存在接近障碍物时,进行减速同时转变方向成功绕开障碍物后回到全局路径上继续向目标点行进。规避随机障碍物智能车轨迹如图 15(c)中②所指轨迹和图 15(d)中③所指轨迹所示,可看出规避障碍物时轨迹平滑,符合车辆转向动力学特点。




图 15 轮式智能车行进策略轨迹图

Fig. 15 The trajectory diagram of the wheeled smart car's travel strategy

实际行进过程中采集到的智能车姿态实时数据利用 MATLAB2018a 进行离线绘制,如图 16 所示,为智能车实时姿态图。在 5~10 s 时,智能车的速度、角速度和角度发生急剧变化,车有明显减速和转向的过程。

综上,在实际环境测试中,轮式智能车采用本文算法能够有效进行随机避障,路线平滑,符合全局最优路径,达到了预期效果。




图16 智能车实时姿态图

Fig. 16 Real-time posture diagram of the smart car

6 结 论

针对基本A*算法收敛速度欠佳、冗余节点较多的情况,本文对其进行优化。根据节点之间斜率情况,寻找关键拐点,剔除较多冗余拐点;对评价函数进行了改进,通过仿真实验与基本A*、Dijkstra和文献[18]算法进行了对比,本文A*优化算法路径更加平滑、速度更快。

针对复杂环境下基本A*算法无法进行动态随机避障以及DWA算法存在距离障碍物较近不安全的问题,本文将DWA速度权值系数进行自适应参数设计,并与优化A*算法进行融合,对融合算法进行仿真实验显示,本文智能车A*与DWA自适应参数融合改进算法能够安全有效的避开动-静态随机障碍物,行进策略更加平滑贴近真实车辆规避。

本文利用ROS轮式智能车进行算法实际测试,测试效果显示,在复杂真实环境下智能车也能够安全、快捷且平滑的进行随机障碍物规避,达到了预期目标。

综上,本文所提随机避障融合算法能够为智能车行为决策提供安全、平滑和可行的驾驶策略,在一定程度上为智能驾驶随机避障提供理论基础。

参考文献

[1] 江明,王飞,葛愿,等. 基于改进蚁群算法的机器人路径规划研究[J]. 仪器仪表学报,2019,40(2): 113-121.
JIANG M, WANG F, GE Y, et al. Research on path planning of mobile robot based on improved ant colony algorithm[J]. Chinese Journal of Scientific Instrument,

2019, 40(2): 113-121.

[2] 李宁,魏登,曹裕捷,等. 自动驾驶电动汽车避障控制算法[J]. 仪器仪表学报,2021,42(5): 199-207.

LI N, WEI D, CAO Y J, et al. Obstacle avoidance control algorithm for self-driving electric vehicles [J]. Chinese Journal of Scientific Instrument, 2021, 42(5): 199-207.

[3] ZHU Q J, MA K, RONG Y L, et al. A path planning method using adaptive polymorphic ant colony algorithm for smart wheelchairs [J]. Journal of Computational Science, 2018, 25(5): 162-171.

[4] DOOPALAM T, BYAMBAA D, DEOK J L, et al. Hybrid motion planning method for autonomous robots using kinect based sensor fusion and virtual plane approach in dynamic environments [J]. Journal of Sensors, 2015, 2015(5): 1123-1139.

[5] 李志锟,黄宜庆,徐玉琼. 改进变步长蚁群算法的移动机器人路径规划[J]. 电子测量与仪器学报, 2020, 34(8): 15-21.

LI ZH K, HUANG Y Q, XU Y Q. Path planning of mobile robot based on improved variable step size ant colony algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(8): 15-21.

[6] 张旭,程传奇,郝向阳,等. 一种兼顾全局与局部特性的机器人动态路径规划算法[J]. 测绘科学技术学报, 2018, 35(3): 315-320.

ZHANG X, CHENG CH Q, HAO X Y, et al. A robot dynamic path planning algorithm considering global and local characteristics [J]. Journal of Surveying and Mapping Science and technology, 2018, 35(3): 315-320.

[7] 王殿君. 基于改进A*算法的室内移动机器人路径规划[J]. 清华大学学报(自然科学版), 2012, 52(8): 1085-1089.

WANG D J. Path planning of indoor mobile robot based on improved A* algorithm [J]. Journal of Tsinghua University (NATURAL SCIENCE EDITION), 2012, 52(8): 1085-1089.

[8] 王洪斌,尹鹏衡,郑维,等. 基于改进的A*算法与动态窗口法的移动机器人路径规划[J]. 机器人, 2020, 42(3): 346-353.

WANG H B, YIN P H, ZHENG W, et al. Mobile robot path planning based on improved A* algorithm and dynamic window method [J]. Robot, 2020, 42(3): 346-353.

[9] BEOMJOO K, JOELLE P. Socially adaptive path planning in human environments using inverse reinforcement learning[J]. International Journal of Social

- Robotics, 2016, 8(1): 23-32.
- [10] 高明,唐洪,张鹏. 机器人集群路径规划技术研究现状[J]. 国防科技大学学报, 2021, 43(1): 127-138.
GAO M, TANG H, ZHANG P. Research status of robot cluster path planning technology [J]. Journal of National University of Defense Science and Technology, 2021, 43 (1): 127-138.
- [11] DUHE J F, VICTOR S, MELCHIOR P. Contributions on artificial potential field method for effective obstacle avoidance [J]. Fractional Calculus and Applied Analysis, 2021, 24(2): 325-334.
- [12] 王志中. 复杂动态环境下自主机器人路径规划研究[J]. 组合机床与自动化加工技术, 2018, 4(1): 64-68.
WANG ZH ZH. Research on path planning of autonomous robot in complex dynamic environment [J]. Modular Machine Tool and Automatic Processing Technology, 2018, 4(1): 64-68.
- [13] 王凡,李铁军,刘今越,等. 基于 BIM 的建筑机器人自主路径规划及避障研究[J]. 计算机工程与应用, 2020, 56(17): 224-230.
WANG F, LI T J, LIU J Y, et al. Research on autonomous path planning and obstacle avoidance of construction robot based on BIM [J]. Computer Engineering and Application, 2020, 56 (17): 224-230.
- [14] TROCATOK J, DORSTL O. Differential A* [J]. IEEE Transactions on Knowledge and Data Engineering, 2002, 14(6): 1218-1229.
- [15] VIACHESLAV V, MARINA Z, EVGENII S, et al. Investigators from iowa state university zero in on robotics (time-optimal path planning with power schedules for a solar-powered ground robot) [J]. Journal of Engineering, 2017, 4(5): 203-217.
- [16] 程传奇,郝向阳,李建胜,等. 融合改进 A* 算法和动态窗口法的全局动态路径规划[J]. 西安交通大学学报, 2017, 51(11): 137-143.
CHENG CH Q, HAO X Y, LI J SH, et al. Global dynamic path planning based on improved A* algorithm and dynamic window method [J]. Journal of Xi'an Jiaotong University, 2017, 51 (11): 137-143.
- [17] 张文,刘勇,张超凡,等. 基于方向 A* 算法的温室机器人实时路径规划[J]. 农业机械学报, 2017, 48(7): 22-28.
ZHANG W, LIU Y, ZHANG CH F, et al. Real time path planning of greenhouse robot based on direction A* algorithm [J]. Journal of Agricultural Machinery, 2017, 48 (7): 22-28.
- [18] 劳彩莲,李鹏,冯宇. 基于改进 A* 与 DWA 算法融合的温室机器人路径规划[J]. 农业机械学报, 2021, 52(1): 14-22.
LAO C L, LI P, FENG Y. Path planning of greenhouse robot based on improved A* and DWA algorithm [J]. Journal of Agricultural Machinery, 2021, 52 (1): 14-22.
- [19] 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.
XU Y Q, LOU K, LI T T, et al. Mobile robot path planning based on improved adaptive ant colony algorithm [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33 (10): 89-95.

作者简介



吴宇, 2020 年于九江学院获得学士学位, 现为苏州科技大学硕士研究生, 主要研究方向为智能机器人导航与路径规划。

E-mail: 2046094725@qq.com

Wu Yu received his B.Sc. degree from Jiujiang University in 2020. He is currently a master student at Suzhou University of Science and Technology. His main research interests include intelligent robot navigation and path planning.



郝万君 (通信作者), 1990 年于北京科技大学获得学士学位, 1999 年于东北大学获得硕士学位 2006 年于哈尔滨工业大学获得博士学位, 现为苏州科技大学教授, 主要研究方向为智能机器人控制与导航。

E-mail: Hao_wanjun@163.com

Hao Wanjun (Corresponding author) received his B.Sc. degree from Beijing University of Science and Technology in 1990, received his M.Sc. degree from Northeast University in 1999, and received his Ph.D. degree from Harbin Institute of Technology in 2006. He is currently a professor at Suzhou University of Science and Technology. His main research interests include intelligent robot control and navigation.