

应急情景下融合改进 D*Lite 算法和 DWA 算法的 无人驾驶汽车路径规划

刘连玉^{1,2,3}, 巩在武^{1,2,3†}, 张雪^{1,2,3}, 吴穹^{1,2,3}

(1. 南京信息工程大学 气象灾害预报预警与评估协同创新中心, 南京 210044;

2. 南京信息工程大学 风险治理与应急决策研究院, 南京 210044;

3. 南京信息工程大学 管理工程学院, 南京 210044)

摘要: 针对传统路径规划算法在无人驾驶应急场景中存在的环境建模失真、路径搜索效率以及安全性不足等局限, 提出一种基于高精度城市电子地图的“全局-局部”耦合路径规划框架. 该框架通过融合改进 D*Lite 算法和动态窗口法 (DWA), 能够实现全局路径动态优化与局部避障协同控制. 在全局规划中, 使用五邻域搜索策略替代八邻域搜索, 可有效避免路径曲折问题; 同时, 结合风险系数构造多目标代价函数, 能够显著降低路径累积风险值. 在局部规划中, 设计一种基于风险感知机制的动态评价函数, 增强局部避障的实时性和安全性. 仿真结果表明, 与现有文献相比, 所提出耦合算法在路径规划效率、路径安全性、平滑度等方面均有显著的提升. 进一步地, 通过交通事故规避、突发乘客需求响应等典型应急场景验证所提出算法的鲁棒性, 为无人驾驶安全行驶提供了理论支持.

关键词: 无人驾驶; 应急路径规划; “全局-局部”耦合算法; D*Lite 算法; 动态窗口法

中图分类号: TP273 **文献标志码:** A

DOI: 10.13195/j.kzyjc.2025.0009

引用格式: 刘连玉, 巩在武, 张雪, 等. 应急情景下融合改进 D*Lite 算法和 DWA 算法的无人驾驶汽车路径规划 [J]. 控制与决策, 2025, 40(10): 2985-2994.

Fusion of improved D*Lite algorithm and DWA algorithm for driverless vehicle path planning in emergency scenarios

LIU Lian-yu^{1,2,3}, GONG Zai-wu^{1,2,3†}, ZHANG Xue^{1,2,3}, WU Qiong^{1,2,3}

(1. Collaborative Innovation Center on Forecast and Evaluation of Meteorological Disasters, Nanjing University of Information Science and Technology, Nanjing 210044, China; 2. The Research Institute for Risk Governance and Emergency Decision-Making, Nanjing University of Information Science and Technology, Nanjing 210044, China; 3. School of Management Science and Engineering, Nanjing University of Information Science and Technology, Nanjing 210044, China)

Abstract: To address the limitations of traditional path planning algorithms in autonomous driving emergency scenarios, such as environmental modeling distortion, insufficient path search efficiency and safety deficiencies, this paper proposes a high-precision urban electronic map-based “global-local” coupled path planning framework. By integrating an improved D*Lite algorithm with the dynamic window approach (DWA), the framework achieves coordinated control of dynamic global path optimization and local obstacle avoidance. In global planning, a five-neighborhood search strategy replaces conventional eight-neighborhood search to prevent path tortuosity, while a multi-objective cost function incorporating risk coefficients significantly reduces cumulative path risks. For local planning, a risk-aware dynamic evaluation function is designed to enhance the real-time performance and safety of obstacle avoidance. Simulation results demonstrate that compared with existing methods, the proposed coupled algorithm achieves significant improvements in path planning efficiency, path safety, and trajectory smoothness. Further verification through typical emergency scenarios including traffic collision avoidance and sudden passenger demand responses confirms the algorithm's robustness, providing theoretical support for safe navigation of autonomous

收稿日期: 2025-01-04; 录用日期: 2025-05-21.

基金项目: 国家自然科学基金项目 (72371137).

责任编委: 黄敏.

†通信作者. E-mail: zwgong26@163.com.

vehicles.

Keywords: self-driving; contingency path planning; “global-local” coupling algorithm; D*Lite algorithm; dynamic window approach

0 引言

随着无人驾驶技术的发展,越来越多的城市开始引入无人驾驶车辆,许多专家学者提出将无人驾驶技术应用于公共交通系统^[1-2],建立了混合公交系统协调优化的双层规划模型.这些研究丰富了无人驾驶汽车路径规划的研究成果,但是,在无人驾驶应用中却很少讨论由乘客需求引发的车辆应急问题.因此,针对应急情景下无人驾驶汽车路径规划的研究成为当前亟需解决的问题.

路径规划是无人驾驶的基础和关键核心技术之一,是连接环境感知和运动控制的桥梁.传统的路径规划算法可分为全局路径规划算法和局部路径规划算法:全局路径规划也称静态路径规划,旨在已知环境中生成一条起点到终点的全局参考路径,如传统 D*Lite 算法^[3]、A*算法^[4]、蚁群算法^[5]、RRT 算法^[6]等;局部路径规划也称动态路径规划,侧重于局部环境信息,规划的路径具有较高的鲁棒性,包括动态窗口法(DWA)^[7]、人工势场法^[8]等.全局路径规划与局部路径规划的主要区别在于规划路径的环境信息不同:全局路径规划根据整体环境信息规划路径,但是面对未知障碍物时易出错;局部路径规划由于缺少全局信息可能无法发现可行路径.因此,许多学者提出了“全局-局部”耦合算法来减轻单一算法的局限性.Wang 等^[9]使用全局路径规划生成了稀疏路径点,进一步整合了局部路径规划躲避车辆路径规划过程中不可预见的障碍物,通过组合全局路径规划算法和局部路径规划算法得到多种可能的耦合算法;赖荣荣等^[10]提出了将改进 A*算法与动态窗口法相融合;魏立新等^[11]针对复杂环境中移动机器人动态

路径规划问题提出了改进蚁群算法与 DWA 的混合策略;Wang 等^[12]进一步结合粒子群算法与人工势场法,提升了复杂海域路径规划的效率,拓展了耦合路径规划算法的应用.

上述“全局-局部”耦合算法虽然增强了路径规划在复杂环境中的性能,但是,将其应用于无人驾驶领域却存在一些问题.首先,传统算法仅考虑了长度对于路径的影响,忽视了安全、风险和实时性等多因素的综合权衡.然而,在无人驾驶中,最短路径往往不是最优路径,必须考虑更广泛的环境因素.其次,大多数耦合算法中全局路径只发生一次,当环境发生剧烈变化时,全局路径对局部路径规划的引导作用会减弱甚至失效,失去了耦合算法的优势.

针对目前耦合路径规划算法在无人驾驶领域存在的问题,本文提出一种新的“全局-局部”耦合算法框架,该框架将改进的 D*Lite 算法与动态窗口法相结合. D*Lite 算法重用先前搜索信息的能力使其能够快速响应环境的变化来调整全局路径.同时,使用五邻域搜索策略替代传统 D*Lite 算法中八邻域搜索,可有效避免路径出现大角度转折,进一步引入风险系数指标改进算法的代价函数.此外,针对无人驾驶应用中存在的应急问题,本文在耦合算法中综合考虑 3 种典型应急情景,讨论该算法在应急情景下的鲁棒性和普适性.

1 环境建模

已有路径规划研究中往往是人为定义环境的可通行区域和障碍物区域,在无人驾驶中并不能反映真实的路况信息.因此,本文基于武汉某区域高精度电子地图进行建模,将电子地图的道路信息投影到




图1 简单栅格环境




图2 复杂栅格环境

栅格单元中, 构建了简单栅格环境 (以郊区为例, 假定植被区域为可通行区域) 和复杂栅格环境 (以市中心为例), 如图 1 和图 2 所示, 其中黑色为障碍物区域.

考虑到无人驾驶对于安全性的要求, 本文根据真实路况信息定义每个栅格的风险系数, 风险系数的大小与该栅格周围的障碍物数量有关, 具体可由下式推导得到:

$$R_{(i,j)} = \begin{cases} N, & (i,j) \notin \text{obs}; \\ \text{inf}, & (i,j) \in \text{obs}. \end{cases} \quad (1)$$

其中: $R_{(i,j)}$ 为 (i,j) 栅格的风险系数, obs 为障碍物集合, N 为 (i,j) 节点 8 个方向上邻接栅格中包含的障碍物数量.

2 改进 D*Lite 路径规划算法

2.1 五邻域搜索策略

传统路径规划算法中确定子节点一般采用八邻域搜索策略^[13], 如图 3 所示. 这种方法包含冗余节点, 增加了无人驾驶算法的运算量, 且会出现路径转折角度过大的风险. 为提高无人驾驶的安全性, 本文采用改进的五邻域搜索策略替代八邻域搜索策略, 以 P_2 方向为基准, 根据当前节点和目标点的连线与当




图3 八邻域搜索策略

表1 五邻域搜索节点方向选择表

夹角范围	保留节点	舍弃节点
$[22.5^\circ, 67.5^\circ)$	P_1, P_2, P_3, P_5, P_8	P_4, P_6, P_7
$[67.5^\circ, 112.5^\circ)$	P_2, P_3, P_5, P_7, P_8	P_1, P_4, P_6
$[112.5^\circ, 155.5^\circ)$	P_3, P_5, P_6, P_7, P_8	P_1, P_2, P_4
$[155.5^\circ, 202.5^\circ)$	P_4, P_5, P_6, P_7, P_8	P_1, P_2, P_3
$[202.5^\circ, 247.5^\circ)$	P_1, P_4, P_6, P_7, P_8	P_2, P_3, P_5
$[247.5^\circ, 292.5^\circ)$	P_1, P_2, P_4, P_6, P_7	P_3, P_5, P_8
$[292.5^\circ, 337.5^\circ)$	P_1, P_2, P_3, P_4, P_6	P_5, P_7, P_8
$[0^\circ, 22.5^\circ) \cup [337.5^\circ, 360^\circ)$	P_1, P_2, P_3, P_4, P_5	P_6, P_7, P_8

前节点和 P_2 方向连线的夹角确定保留的 5 个邻域, 假设顺时针方向为正方向, 节点方向选择如表 1 所示.

以 $[22.5^\circ, 67.5^\circ)$ 夹角范围为例, 节点选择策略如图 4 所示. 当目标点位于夹角范围时, 保留与目标方向一致性最高的 5 个节点, 舍弃剩余 3 个偏离方向的节点. 通过动态筛选使得汽车更快地到达目标点, 避免路径曲折, 降低了无人驾驶车辆的最大转向角度.




图4 五邻域搜索策略

2.2 多目标代价函数

传统 D*Lite 算法多采用欧氏距离或曼哈顿距

离表示路径成本. 然而, 路径规划算法在无人驾驶中不仅要考虑距离因素, 更要兼顾安全性的要求. 因此, 本文将风险系数 $r(s)$ 集成到代价函数中, 构建综合距离和风险的多目标代价函数, 具体如下所示:

$$c(s, s') = c_{\text{dis}}(s, s') + \lambda \cdot r(s). \quad (2)$$

其中: $c_{\text{dis}}(s, s')$ 为传统 D*Lite 算法的距离代价, λ 为保证距离与风险间一致性的权重.

2.3 二次路径优化

针对传统 D*Lite 算法路径存在大量转折和冗余节点的问题, 本文对全局路径进行了二次优化, 保留路径的关键节点, 减少路径长度, 提高平滑性. 同时, 考虑防碰撞要求设置安全距离 d_{safe} , 即车辆与障碍物间需要维持的最小距离, 与车辆动力学约束下的制动距离和转向半径有关, 计算表达式为

$$d_{\text{safe}} = \max\{d_{\text{brake}}, r_{\text{turn}}\}. \quad (3)$$

其中: d_{brake} 为车辆制动距离, r_{turn} 为转向半径, 两者由车辆动力学参数动态确定.

图 5 为二次路径优化原理. 以图 5 路径为例, D*Lite 算法规划的路径为 $S \rightarrow d_1 \rightarrow d_2 \rightarrow d_3 \rightarrow d_4 \rightarrow d_5 \rightarrow d_6 \rightarrow d_7 \rightarrow d_8 \rightarrow d_9 \rightarrow d_{10} \rightarrow d_{11} \rightarrow G$, 对于路径中任意两个不相邻的节点, 若它们之间的连线不穿过障碍物且障碍物到该连线的最小距离大于安全距离, 则删除这两个节点间的所有节点. 图 5 优化后路径为 $S \rightarrow d_9 \rightarrow G$.




图5 二次路径优化原理

3 改进动态窗口法

3.1 建立无人驾驶汽车运动学模型

在动态窗口法中, 建立无人驾驶汽车运动学模型是模拟汽车运动的基础. 常见的运动模型构建如图 6 所示.

图 6 中: x 和 y 为世界坐标系的坐标轴, x_{vehicle} 和 y_{vehicle} 为汽车当前移动的坐标轴, θ 为汽车移动方向与水平方向的夹角. 假设汽车在 t 时刻的位置坐标为 (x_t, y_t) , 则汽车在 $t + \Delta t$ 时刻的位置可表示为




图6 无人驾驶汽车运动学模型

$$\begin{bmatrix} x_{t+\Delta t} \\ y_{t+\Delta t} \\ \theta_{t+\Delta t} \end{bmatrix} = \begin{bmatrix} x_t + v_t \times \cos(\theta_t) \times \Delta t \\ y_t + v_t \times \sin(\theta_t) \times \Delta t \\ \theta_t + \omega_t \times \Delta t \end{bmatrix}. \quad (4)$$

其中: v_t 为 t 时刻汽车的线速度, ω_t 为 t 时刻汽车的角速度, Δt 为采样时间步长.

3.2 建立速度空间

由于无人驾驶汽车会受到环境和自身性能的限制, 需要约束采样速度的范围. 包括自身速度约束、动力学约束和安全约束, 具体如下.

1) 无人驾驶汽车自身速度约束为

$$V_m = \{(v, \omega) | v \in [v_{\min}, v_{\max}], \omega \in [\omega_{\min}, \omega_{\max}]\}, \quad (5)$$

其中 V_m 为速度空间中线速度和角速度的集合.

2) 无人驾驶汽车电机性能约束为

$$V_d = \{(v, \omega) | v \in [v_c - \dot{v}_b \Delta t, v_c + \dot{v}_a \Delta t], \omega \in [\omega_c - \dot{\omega}_b \Delta t, \omega_c + \dot{\omega}_a \Delta t]\}. \quad (6)$$

其中: v_c 和 ω_c 为汽车当前的线速度和角速度, \dot{v}_a 和 \dot{v}_b 为汽车当前线速度的最大加速度和最大减速度, $\dot{\omega}_a$ 和 $\dot{\omega}_b$ 分别为汽车当前角速度的最大加速度和最大减速度.

3) 无人驾驶汽车安全制动约束为

$$V_a = \{(v, \omega) | v \leq \sqrt{2 \cdot \text{dist}(v, \omega) \cdot \dot{v}_b}, \omega \leq \sqrt{2 \cdot \text{dist}(v, \omega) \cdot \dot{\omega}_b}\}, \quad (7)$$

其中 $\text{dist}(v, \omega)$ 为速度 (v, ω) 对应轨迹上距离障碍物的最近距离.

基于上述 3 类约束, 最终无人驾驶汽车的速度采样空间为 3 个速度空间的交集, 即

$$V = V_m \cap V_d \cap V_a. \quad (8)$$

3.3 优化轨迹评价函数

在采样速度空间中, DWA 算法以一定的间距均匀采样生成多条可行轨迹, 通过轨迹评价函数选取最优轨迹的速度作为驱动速度. 与 D*Lite 算法类似, 传统 DWA 算法的评价函数没有考虑到环境的风险差异, 因此, 本文在原有评价函数的基础上引入了风

险评价函数 $risk(v, \omega)$, 表示当前采样速度下产生的轨迹终点位置的风险值. 改进后的评价函数为

$$G(v, \omega) = \sigma(\alpha \cdot heading(v, \omega) + \beta \cdot dist(v, \omega) + \gamma \cdot velocity(v, \omega) + \delta \cdot risk(v, \omega)). \quad (9)$$

4 应急情景下耦合算法框架

为了应对目前耦合路径规划算法在无人驾驶应

急情景中的局限, 本文提出了一种融合改进 D*Lite 算法和动态窗口法的“全局-局部”耦合路径规划算法. 该算法考虑无人驾驶中 3 种应急情景, 使用改进 D*Lite 算法得到全局最优路径, 将优化后的路径关键节点替代改进 DWA 算法的局部目标点, 实现局部路径规划. 具体流程如图 7 所示.

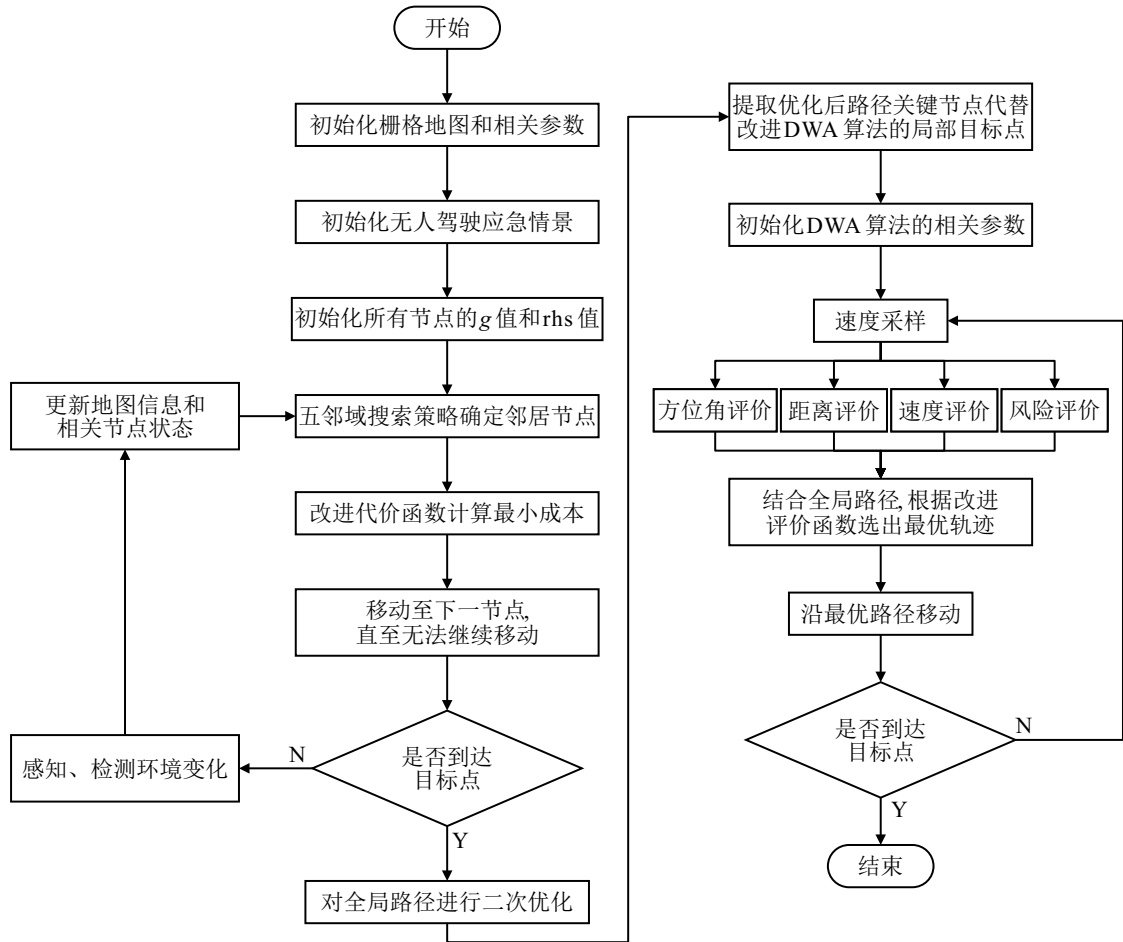


图7 耦合算法流程

耦合算法的实现步骤如下.

step 1: 建立无人驾驶汽车应急情景下的工作环境. 初始化所有节点的 g 值和 rhs 值, 令 $rhs_{goal} = 0$, 其余节点的 g 值= rhs 值= 0 , 计算所有节点的启发值.

step 2: 拓展节点, 从目标点开始采用五邻域搜索策略计算前继节点的 rhs 值和 key 值, 将其按照大小放入队列 U , 取出 U 中最小值对应的节点作为最优节点, 并更新该点的 g 值.

step 3: 使用结合距离和 risk 的多目标代价函数计算节点成本, 规划全局路径.

step 4: 对全局路径进行二次优化, 去除路径中冗余节点, 将优化后的路径关键节点替代动态窗口法的局部目标点, 用改进的评价函数评价不同速度采样的轨迹, 选择最优的速度控制作为输出.

step 5: 判断车辆是否到达目标点, 若到达目标点, 则结束算法, 输出最终路径; 否则, 继续对速度采样, 直至到达全局目标点.

5 仿真与分析

为验证所提出改进算法的有效性, 通过设置对比实验分别比较改进 D*Lite 算法与耦合算法的性能, 每个实验重复 10 次来验证结果的稳定性. 初始化无人驾驶汽车属性和耦合算法参数设置如表 2 所示.

5.1 改进 D*Lite 算法仿真实验分析

为验证所提出改进 D*Lite 算法的性能, 将所提出改进后的 D*Lite 算法与文献 [14] 改进 D*Lite 算法、基于仿生的改进蚁群算法^[11]和深度强化学习算法^[15]进行对比. 以前文环境建模中搭建的栅格地图为例. 其中: 简单环境的障碍物覆盖率为 15.5%, 复

杂环境的覆盖率为 25%. 4 种算法在不同环境的规划结果如图 8 所示, 性能对比如表 3 所示. 路径规划的起点为 (0.5, 0.5), 终点为 (29.5, 29.5).

表2 实验参数设置

参数	数值	参数	数值
最大线速度 $v_{\max}/(\text{m/s})$	1.0	方位角评价系数 α	0.4
最大角速度 $\omega_{\max}/(^{\circ}/\text{s})$	20	距离评价系数 β	0.1
线加速度 $\dot{v}_a/(\text{m/s}^2)$	0.2	速度评价系数 γ	0.2
角加速度 $\dot{\omega}_a/(^{\circ}/\text{s}^2)$	50	风险评价系数 δ	0.3
线速度分辨率 $d_v/(\text{m/s})$	0.01	采样时间 $\Delta t/\text{s}$	0.3
角速度分辨率 $d_\omega/(^{\circ}/\text{s})$	1.0	风险系数 λ	0.3

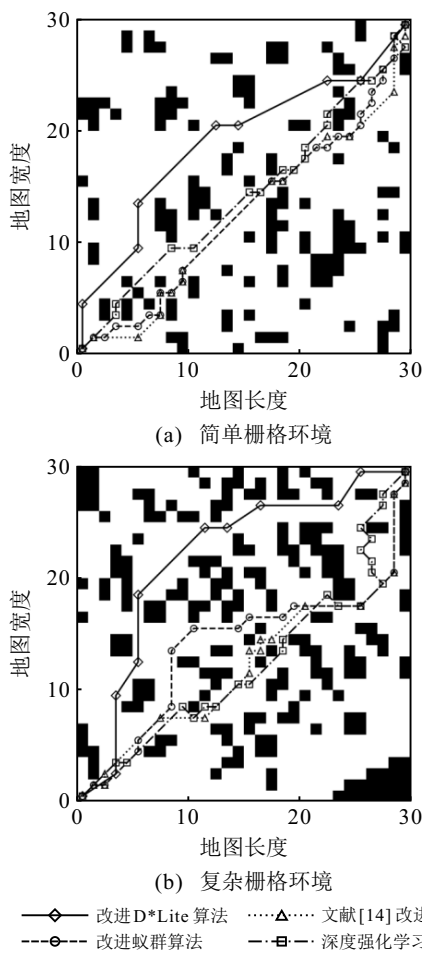


图8 不同环境规模下 4 种算法路径规划对比

本文在改进 D*Lite 算法的代价函数中引入了风险系数, 由图 8 可见, 相比于其他 3 种算法, 改进算法规划的路径风险更小, 满足无人驾驶安全性的要求. 由表 3 可知: 在简单栅格环境中, 改进 D*Lite 算法的平均风险值较其他算法分别降低了 30.74%、36.20%、25.52%; 在复杂栅格环境中, 分别降低了 23.44%、25.00%、12.24%. 在路径长度方面, 由于改进算法的代价函数是融合最短路径和最小风险的多目标代价函数, 所提出算法在路径长度上并没有优势, 但是在无人驾驶中, 相比于最短路径, 安全性显得更为重要.


5.2 耦合算法仿真实验分析

无人驾驶汽车所处的环境信息并非一成不变, 有效的路径规划算法应能够及时识别环境的变化, 动态躲避障碍物. 为验证所提出“全局-局部”耦合框架在无人驾驶应急情景中的适用性, 将所提出耦合算法与 A*-DWA 耦合算法在动态环境中规划的路径进行对比, 多次实验以探究两种算法的避障能力以及避障稳定性. 其中: 黑色区域为静态障碍物, 灰色区域为动态障碍物. 某次仿真结果如图 9 和图 10 所示, 耦合算法的性能对比如表 4 所示.


由图 10(b) 可知, 耦合算法通过局部路径规划实现了动态避障. 进一步比较图 9 与图 10 可见: 由于 A*算法的全局路径规划只发生一次, 当路径中出现多个障碍物时, 全局路径关键节点对局部路径规划的引导作用减弱, 使得 A*-DWA 耦合算法过度依赖局部路径规划, 规划的路径更曲折, 不符合安全行驶的要求. 相反, 本文提出了使用改进的 D*Lite 算法作为耦合框架中全局路径规划组件, 当算法检测到障碍物时, D*Lite 算法会重新规划全局路径避开障碍物, 为 DWA 算法提供更新后的关键节点. 通过多次实验得到两种算法的性能, 发现改进 D*Lite-DWA 耦合算法相比于 A*-DWA 耦合算法在规划时间上减少了 35.10%, 路径迭代次数减少了 34.98%. 在路径长度方面, 所提出算法提升较小, 但是所提出耦合算法各项指标的标准差均小于 A*-DWA 算法, 验证

表3 4 种算法性能对比


地图类型	算法类型	路径长度均值±标准差	迭代次数均值±标准差	转折点数均值±标准差	风险累积均值±标准差
简单栅格环境	改进D*Lite算法	30.559 ± 6.562	22.40 ± 3.747	5.40 ± 2.059	17.80 ± 6.359
	文献[14]算法	29.990 ± 6.572	25.60 ± 5.200	7.20 ± 2.750	25.70 ± 9.089
	改进蚁群算法	30.566 ± 6.696	26.30 ± 5.349	6.90 ± 2.071	27.90 ± 9.575
	深度强化学习算法	31.501 ± 5.825	24.50 ± 4.455	12.70 ± 3.466	23.90 ± 9.679
复杂栅格环境	改进D*Lite算法	31.160 ± 8.165	18.70 ± 6.100	5.90 ± 2.773	29.40 ± 13.055
	文献[14]算法	30.238 ± 7.776	26.80 ± 6.258	10.80 ± 3.919	38.40 ± 13.951
	改进蚁群算法	30.822 ± 8.092	27.80 ± 6.720	10.60 ± 3.720	39.20 ± 14.696
	深度强化学习算法	31.190 ± 6.491	23.90 ± 4.969	12.30 ± 3.195	33.50 ± 13.937



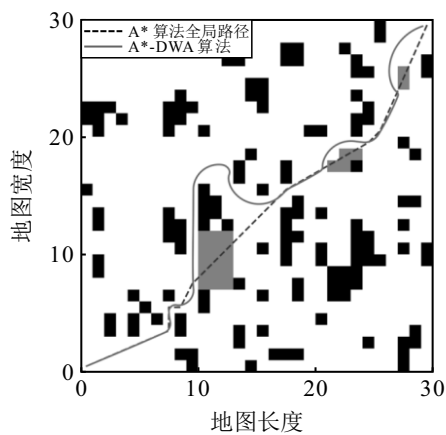
(a) 静态环境规划路径



(b) 避开第1个障碍物




(c) 避开第2个障碍物




(d) 避开第3个障碍物

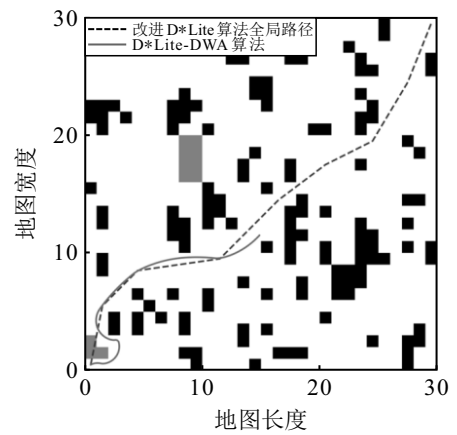
图9 A*-DWA 耦合算法避障结果




(a) 静态环境规划路径



(b) 避开第1个障碍物



(c) 避开第2个障碍物



(d) 避开第3个障碍物

图10 改进D*Lite-DWA 耦合算法避障结果

表4 耦合算法性能对比

算法类型	路径长度均值±标准差	规划时间均值±标准差	迭代次数均值±标准差
D*Lite-DWA	48.73 ± 1.667	583.26 ± 75.12	1 050 ± 125
A*-DWA	49.55 ± 4.042	898.50 ± 121.73	1 615 ± 199

了该算法在复杂环境中的鲁棒性.

5.3 基于无人驾驶平台验证分析

为进一步验证所提出耦合算法在无人驾驶应用的性能,使用 Carla 仿真平台搭建城市交通环境用于算法的训练和验证. Carla 是用于自动驾驶研究的开源模拟器,提供了多样化的地图和车辆模型,允许用户对车辆、交通、天气等参数进行设置,同时集成了车辆动力学模型,图 11(a) 为不同传感器的可视化数据. 本文主车车辆速度设定为 50 km/h, 在环境中随机生成 80 个 npc 车辆模拟交通环境, npc 车辆的速度在 30 km/h ~ 60 km/h 间随机选择.

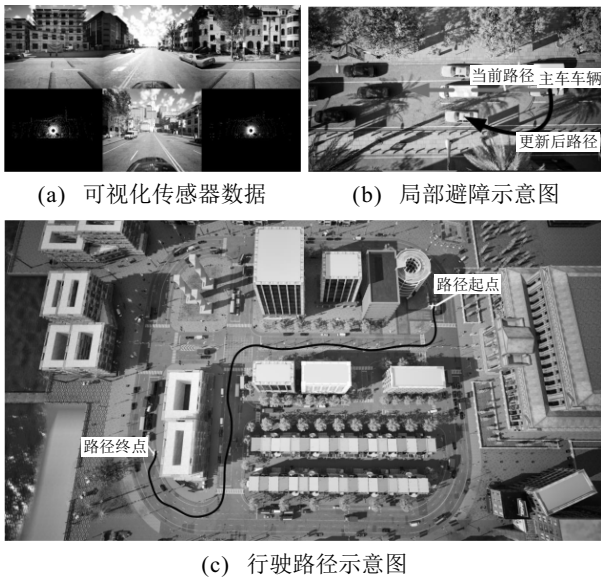


图11 Carla 平台验证分析

首先,初始化主车车辆,在当前环境中进行全局路径规划,待路径生成后将运动指令传送给汽车;然后,车辆按照全局路径规划关键节点进行局部路径规划行驶,当传感器探测到障碍物时,将距离数据传送到控制台,重新规划路径从而避开动态车辆,如图 11(b) 所示;最后,主车车辆到达目标点,实际行驶的路径如图 11(c) 所示.

6 应急情景下耦合算法应用

应急情景通常指突发性、不可预测的事件(如交通事故、突发乘客需求响应、交通管制等),需要快速调整路径以满足安全性和时效性,这对路径规划能力提出了更高的要求. 因此,本文讨论了几种典型的应急情景以及路径规划算法在这些情景中的应用.

6.1 路径必经区约束

无人驾驶汽车的路径规划往往只考虑在宏观上找到一条从起点到终点的全局路径,然而,在实际应用中,还存在一类带有必经区约束的应急路径规划问题,如汽车在多地接送乘客、乘客在到达目的地前指定停靠点等应急情景. 因此,针对无人驾驶中存在的必经区问题,本文在改进 D*Lite-DWA 耦合算法中加入了必经区约束,基于距离优先策略对必经区进行排序处理,将排序后的必经区作为路径规划的临时目标点,实现多路径节点的路径规划.

以图 12 的路径规划环境为例,基于所提出算法规划出一条经过 N_1 、 N_2 、 N_3 区域的全局路径,该路径综合考虑了全局路径规划和应急情景下路径必经区约束,增强了汽车在复杂环境中的应对能力,从而为乘客提供更加可靠和舒适的出行体验.




图12 考虑必经区约束路径规划

6.2 固定化方向节点

在无人驾驶中,当遇到交通拥堵或交通事故时,存在交警指挥车辆行驶路线的可能,因此,会出现固定化方向节点的情况. 针对这种突发现象,本文对栅格引入了参数 Q 来模拟交警指挥的情况,在满足该参数的栅格中不再采用邻域搜索算法,而是听从交警指示选择路径方向. 图 13 为未固定方向节点和固定方向节点的求解路径.

图 13 中,灰色栅格为固定化方向节点. 其中: $Q(0.5, 0.5) = (1, 0)$, 表示在坐标 $(0.5, 0.5)$ 处不采用邻域搜索算法,而是直接选择 $(1, 0)$ 方向的节点作为子节点;同理, $Q(1.5, 0.5) = (0, 1)$, 表示选择 $(0, 1)$ 方向的节点作为 $(1.5, 0.5)$ 的子节点. 图 13(a) 中: 规划的路径不能识别强制转向信息,无法应对突发事件,在无人驾驶中会产生极大的交通压力;图 13(b) 引入了参数 $Q(x, y)$, 使得规划的路径更安全,符合无人驾驶应急情景下的实际应用.




图13 固定化方向节点示意图

6.3 信号灯影响的最短时间约束

在应急情景下, 当乘客需要快速到达目的地以应对紧急事务时, 长时间的红灯等待成为影响出行效率的关键因素. 因此, 本文考虑到信号灯影响下的最短时间约束, 旨在通过实时分析交通信号灯的状态、周期以及车辆当前的位置, 计算出一条最短时间的路径. 设定汽车在栅格环境中以 0.05 格/s 的速度保持匀速行驶, 交通信号灯设置为绿灯显示 30 s, 红灯显示 60 s. 图 14 模拟了无人驾驶汽车考虑信号灯影响的最短时间约束路径规划. 其中: S 为路径起点, G 为路径终点, $L_1 \sim L_6$ 为交通信号灯.

首先, 基于所提出改进耦合算法规划初始全局路径, 如图 14(a) 所示, 发现该路径经过信号灯 L_4 、 L_5 、 L_6 . 然后, 当汽车行驶至 L_4 信号灯时监测信号灯此时的状态, L_4 为绿灯, 汽车可直接通过; 当汽车行驶至 L_5 信号灯处, 此时 L_5 为红灯且剩余时间为 16 s, 汽车将考虑生成新的路径避开该红灯. 图 14(c) 中: 点线为重规划路径, 计算发现新路径总时间为 520 s, 大于原路径的 496 s, 因此, 汽车将等待一段时间后通过 L_5 信号灯. 最后, 汽车行驶至 L_6 信号灯处, L_6 为红灯且剩余时间为 51 s, 同样重规划路径并比较新路径与原路径的总时间, 结果新路径需要 520 s, 小

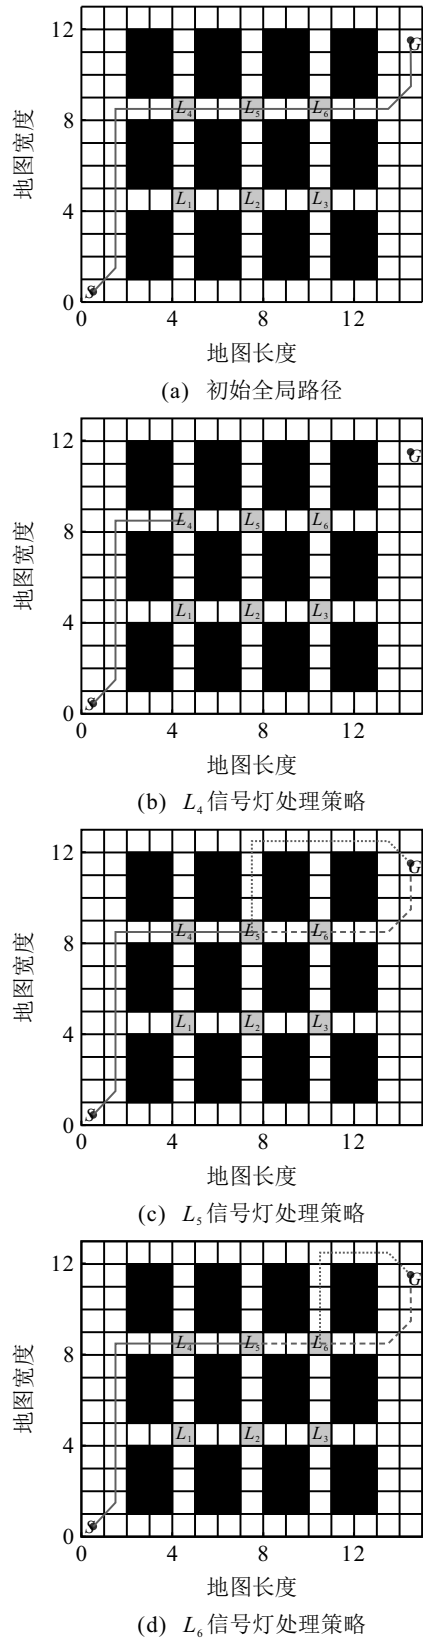


图14 不同信号灯影响下的路径规划

于原路径的 531 s, 此时汽车调整路径, 避开 L_6 信号灯, 最终成功到达终点 G .

7 结论

本文针对传统“全局-局部”耦合路径规划算法在无人驾驶应急情景中的问题展开了研究, 提出了

基于电子地图环境下融合改进 D*Lite 算法和改进动态窗口法的“全局-局部”耦合算法, 并对应急情景下该算法的应用进行了讨论. 该算法使用改进 D*Lite 算法作为全局路径规划的组件, 显著提升了算法效率和路径安全性. 通过仿真实验可知, 所提出改进 D*Lite 算法在简单环境中的风险值累积较其他算法分别降低了 30.74%、36.20%、25.52%, 在复杂环境中分别降低了 23.44%、25.00%、12.24%. 在此基础上, 讨论了 3 种典型应急情景, 并针对应急情景下的特殊需求提出了有效的应对策略, 增强了无人驾驶汽车在不同交通环境下的适用性, 对优化无人驾驶汽车的路径规划具有现实意义.

参考文献 (References)

- [1] Huang D, Hu Z T, Tian J Y, et al. Improving conventional transit services with modular autonomous vehicles: A bi-level programming approach[J]. *Travel Behaviour and Society*, 2025, 39: 100939.
- [2] Xu Q, Chen C Y, Chang X Y, et al. Modeling and analysis of mixed traffic networks with human-driven and autonomous vehicles[J]. *Chinese Journal of Mechanical Engineering*, 2024, 37(1): 134.
- [3] Li X M, Lu Y, Zhao X Y, et al. Path planning for intelligent vehicles based on improved D*Lite[J]. *The Journal of Supercomputing*, 2024, 80(1): 1294-1330.
- [4] Hart P E, Nilsson N J, Raphael B. A formal basis for the heuristic determination of minimum cost paths[J]. *IEEE Transactions on Systems Science and Cybernetics*, 1968, 4(2): 100-107.
- [5] Tan Y S, Ouyang J, Zhang Z, et al. Path planning for spot welding robots based on improved ant colony algorithm[J]. *Robotica*, 2023, 41(3): 926-938.
- [6] 许万, 杨晔, 余磊涛, 等. 一种基于改进 RRT* 的全局路径规划算法[J]. *控制与决策*, 2022, 37(4): 829-838. (Xu W, Yang Y, Yu L T, et al. A global path planning algorithm based on improved RRT*[J]. *Control and Decision*, 2022, 37(4): 829-838.)
- [7] Lin Z A, Taguchi R. Faster implementation of the dynamic window approach based on non-discrete path representation[J]. *Mathematics*, 2023, 11(21): 4424.
- [8] Zhao S E, Leng Y, Zhao M J, et al. A novel dynamic lane-changing trajectory planning for autonomous vehicles based on improved APF and RRT algorithm[J]. *International Journal of Automotive Technology*, 2025, 26(2): 451-461.
- [9] Wang N, Xu H W. Dynamics-constrained global-local hybrid path planning of an autonomous surface vehicle[J]. *IEEE Transactions on Vehicular Technology*, 2020, 69(7): 6928-6942.
- [10] 赖荣燊, 窦磊, 巫志勇, 等. 融合改进 A* 算法和动态窗口法的移动机器人路径规划[J]. *系统仿真学报*, 2024, 36(8): 1884-1894. (Lai R S, Dou L, Wu Z Y, et al. Fusion of improved A* and dynamic window approach for mobile robot path planning[J]. *Journal of System Simulation*, 2024, 36(8): 1884-1894.)
- [11] 魏立新, 张钰锴, 孙浩, 等. 基于改进蚁群和 DWA 算法的机器人动态路径规划[J]. *控制与决策*, 2022, 37(9): 2211-2216. (Wei L X, Zhang Y K, Sun H, et al. Robot dynamic path planning based on improved ant colony and DWA algorithm[J]. *Control and Decision*, 2022, 37(9): 2211-2216.)
- [12] Wang Z, Li G F, Ren J. Dynamic path planning for unmanned surface vehicle in complex offshore areas based on hybrid algorithm[J]. *Computer Communications*, 2021, 166: 49-56.
- [13] 徐菱, 付文浩, 江文辉, 等. 基于 16 方向 24 邻域改进蚁群算法的移动机器人路径规划[J]. *控制与决策*, 2021, 36(5): 1137-1146. (Xu L, Fu W H, Jiang W H, et al. Mobile robot path planning based on 16-direction 24-neighbourhood improved ant colony algorithm[J]. *Control and Decision*, 2021, 36(5): 1137-1146.)
- [14] 黄鲁, 周非同. 基于路径优化 D*Lite 算法的移动机器人路径规划[J]. *控制与决策*, 2020, 35(4): 877-884. (Huang L, Zhou F T. Path planning of moving robot based on path optimization of D*Lite algorithm[J]. *Control and Decision*, 2020, 35(4): 877-884.)
- [15] Zhang Y Y, Li C H, Zhang G S, et al. Research on the local path planning for mobile robots based on PRO-dueling deep Q-network (DQN) algorithm[J]. *International Journal of Advanced Computer Science and Applications*, 2023, 14(8): 1020-1029.

作者简介

刘连玉 (2002-), 男, 硕士生, 主要研究方向为路径规划和应急管理, E-mail: liulianyu0214@163.com;

巩在武 (1975-), 男, 教授, 博士, 博士生导师, 主要研究方向为决策分析、应急管理和偏好学习, E-mail: zwgong26@163.com;

张雪 (2001-), 女, 硕士生, 主要研究方向为决策分析和应急管理, E-mail: sherry_zx0909@163.com;

吴穹 (1988-), 男, 讲师, 博士生, 主要研究方向为路径规划和大数据分析, E-mail: 819058555@qq.com.