

自动驾驶车辆基于风险场的盲区避障方法

佟 宁^{1,2}, 乔亚星¹, 蒋峻同¹, 王丽智¹

(1. 大连交通大学 轨道智能工程学院, 辽宁 大连 116028; 2. 大连交通大学 大连市区块链技术与应用重点实验室, 辽宁 大连 116028)

摘 要: 针对驾驶盲区场景下存在驾驶安全隐患的问题, 提出了基于碰撞风险场模型的车辆协同避障规划算法。考虑车-车通信持续性的影响, 构建了通信持续性风险场模型, 将构建的风险场纳入到路径动态规划算法中, 设计了基于通信持续性影响因子的自适应避障安全代价函数。仿真实验结果表明: 所提出的基于风险模型的避障规划算法能够准确反映驾驶盲区下的动态风险, 提高无人驾驶车辆在极端情况下的安全性。

关键词: 避障规划; 自动驾驶; 车车通信; 风险评估; 动态规划

中图分类号: U491.6 **文献标志码:** A **文章编号:** 1671-5497(2026)07-1894-10

DOI: 10.13229/j.cnki.jdxbgxb.20241264

Obstacle avoidance method for autonomous vehicles based on risk field in blind spot scenarios

TONG Ning^{1,2}, QIAO Ya-xing¹, JIANG Jun-tong¹, WANG Li-zhi¹

(1. School of Railway Transportation Intelligent Engineering, Dalian Jiaotong University, Dalian 116028, China;
2. Dalian Key Laboratory of Blockchain Technology and Application, Dalian Jiaotong University, Dalian 116028, China)

Abstract: To address the safety hazards in driving blind spot scenarios, a collaborative obstacle avoidance planning algorithm for vehicles based on a collision risk field model was proposed. Considering the impact of vehicle-to-vehicle communication continuity, a communication continuity risk field model is constructed. This risk field was incorporated into the dynamic path planning algorithm, and an adaptive obstacle avoidance safety cost function based on the communication continuity impact factor was designed. Simulation results demonstrate that the proposed risk model-based obstacle avoidance planning algorithm can accurately reflect dynamic risks in driving blind spots, enhancing the safety of autonomous vehicles in extreme situations.

Key words: obstacle avoidance planning; autonomous driving; vehicle-to-vehicle communication; risk assessment; dynamic programming

收稿日期: 2024-11-23.

基金项目: 国家自然科学基金项目(61902051); 辽宁省教育厅基本科研项目(JYTMS20230011); 辽宁省应用基础研究计划项目(2023JH2/101300188).

作者简介: 佟宁(1981-), 女, 副教授, 博士. 研究方向: 智慧交通, 大数据分析. E-mail: toni_tong@163.com

0 引言

随着路边云技术的发展,智能交通系统的潜力得到了显著提升^[1]。然而,在实际应用中,尤其是在偏远地区或车联万物(Vehicle to everything, V2X)基础设施尚未普及的地方,自动驾驶车辆在障碍物盲区场景下进行安全避障仍面临着挑战^[2]。这种挑战体现在自动驾驶系统难以量化评估由偶然不连续的信息造成的碰撞潜在风险并进行安全有效的轨迹规划。

为应对上述挑战,在驾驶盲区场景下,自动驾驶系统能否规划出一条高安全性的路径取决于避障规划算法的有效性。主要包括碰撞风险的量化评估以及规划算法的设计。驾驶盲区障碍物时空信息的获取是建立碰撞风险场模型的基础。车-车通信(Vehicle-to-vehicle communication, V2V)为其提供了解决方案。Wang等^[3]通过中断模式的随机速度预测方法提高了车辆驾驶安全。Jo等^[4]提出低复杂度的到达角度测距估计技术以提高V2V中车辆位置方向的精确定位。这些方法虽然在一定程度上可以获取盲区障碍物的时空信息进行避障,但都以信息完全得知为基础,一旦V2V探测到车辆信息缺失,就会导致盲区障碍物时空位置信息不完整,这种未知长尾的情况下,车辆无法获得全面的道路状况和交通信息,从而影响了驾驶决策的准确性和安全性。

碰撞风险场模型因其对动态信息的高敏感度,有效弥补了传统自动驾驶规划模块的不足,为路径规划提供了全面、准确的安全依据。陈吉清等^[5]通过分析潜在碰撞点的发生概率和严重程度,构建了风险量化模型。赵睿等^[6]设定车辆动态距离差阈值,并结合一级动态碰撞距离检测算法和二级群星区域碰撞检测算法进行驾驶潜在碰撞检测。郑讯佳等^[7]考虑了交通场景行人与车之间的关系,对现有风险场进一步研究,通过分析人-车和车-路之间的作用关系提出人-车-路驾驶风险场模型。文献[8]通过感知势场模型和潜在碰撞点评估遮挡区的碰撞风险。上述风险场均是基于稳定已知的数据进行建模,缺少对V2V非连续数据的风险评估,导致所建立的风险模型在驾驶盲区场景下适用性差。

现有的避障规划算法是基于实时传感器数据,从避障起点到终点之间规划出一条最优路径。如基于A*算法的路径优化算法^[9]、虚拟力场与模

型预测理论的结合算法^[10],以及结合快速行进树算法(Fast marching tree algorithm, FMT)的动态规划算法^[11]和区域采样随机树算法^[12](Region sampling rapidly-exploring random tree, RS-RRT),均在提高规划效率和稳定性方面取得了进展。然而,这些方法虽然在动态环境中可以实现避障和路径调整,以确保车辆可以应对简单突发情况,但大多采用简单的避障模型,同时对数据完整度的依赖过高,没有考虑V2V信息来源不稳定的情况,忽略由此造成的盲区潜在碰撞风险,在驾驶盲区场景下的表现较差。

综上,在驾驶盲区场景下,V2V协同中的非连续时间段信息对碰撞风险场模型及规划模块的影响尚未得到充分考虑,亟需建立三者间关系。针对上述问题,本文提出一种基于V2V通信持续性风险模型的避障规划算法(Risk model dynamic programming, RMDP),首先,将V2V探测传递的障碍物坐标信息转变为全局坐标,以便用于碰撞风险场模型的构建和路径规划的精准执行。然后,基于等效力思想^[13]构建考虑车辆运动状态和道路条件的碰撞风险模型以定量描述驾驶盲区场景下的碰撞风险。考虑到V2V传递信息的非连续性,设计通信持续性影响因子表示障碍物时空信息缺失的潜在风险,并将其以代价函数形式整合纳入避障规划算法中,从而提升自动驾驶系统的危险态势感知敏感度和规划效率。最后,通过联合仿真验证了本文方法的安全性和可靠性。

1 基于通信影响映射的风险场动态规划方法

在自动驾驶领域,V2V协同通信通过实时信息交换增强车辆环境感知能力,从而优化路径规划提高行车安全^[14]。实时信息的交换使得车辆能够区分动态障碍物信息和静态障碍物信息,前者随时间和空间的变化而变化,后者在时间变化下空间位置保持不变。V2V通信在传递动态障碍物信息时,受限于探测范围,可能导致信息的间断性。传统的解决方案侧重于通过联合感知技术为决策规划模块提供连续的信息流,以确保驾驶安全^[15]。但在车辆稀少或基础设施不完善的区域,决策规划模块缺少通过间断信息进行有效轨迹规划的方法。为解决这一问题,本研究提出了一种集成通信持续性风险场的避障规划算法,算法框架如图1所示。




图1 驾驶盲区下避障规划算法框架图

Fig. 1 Obstacle avoidance planning algorithm framework diagram under driving blind spot

该框架专门针对驾驶盲区中的动态障碍物避让问题,以提高避障效率。具体而言,该框架通过感知模块将信息传递给决策规划模块的动态规划(Dynamic programming, DP)单元,利用RMDP对离散化空间点进行风险评估和代价叠加,其中 S_f 、 C_o 和 τ_i 分别为传感器坐标、全局坐标和通信持续性影响因子,结合启发式方法搜索粗解建立凸空间,为二次规划(Quadratic programming, QP)单元提供初始解。QP单元在此基础上进行精细化轨迹规划,以确定最优轨迹,最终由控制模块执行。这一框架结合V2V通信和风险场模型,有效提升了自动驾驶车辆在复杂交通环境中避让盲区动态障碍物的效率和安全性。

2 VX2通信持续性风险场模型

2.1 障碍物坐标转换

在自动驾驶的路径规划和风险场建模中,全局坐标系提供了统一的信息框架,而V2V通信传递的传感器局部坐标系数据则依赖于各自的车辆参考点。这种差异导致起始锚点与计算夹角方向在全局坐标和传感器坐标中不一致。

令 S_θ 表示传感器坐标系内障碍物相对于车辆的方位角, θ_c 表示障碍物在全局坐标系中的夹角信息。根据全局坐标和传感器坐标的信息差异进行坐标转换。

首先,将障碍物传感器收集的障碍物信息定义为:

$$S_f = \begin{cases} S_d \\ S_\theta \\ S_s \\ S_h \end{cases} \quad (1)$$

式中: S_d 为障碍物到车辆的距离; S_θ 为障碍物与车辆轴线的夹角; S_s 为障碍物的速度; S_h 为障碍物速度的方向。

障碍物 Q 在全局坐标 C_o 下位置 P_3 、速度 P_{s3} 、速度方向 P_{h3} 的计算公式如下:

$$C_o = \begin{cases} P_3 = \begin{bmatrix} x_3 \\ y_3 \end{bmatrix} \\ P_{s3} = S_s \\ P_{h3} \end{cases} \quad (2)$$

式中: x_3 、 y_3 为横纵坐标的具体数值。

将传感器坐标转为全局坐标便于计算全局信息,如下所示:

$$\begin{cases} \theta_c = -S_\theta \\ P_{h3} = -S_h + 90 \end{cases} \quad (3)$$

设 x 、 y 、 P_s 和 P_h 分别为车辆 V 在全局坐标 C_o 的横纵坐标信息、速度和速度方向, d_s 为传感器到车质点的距离, Q 为障碍物的位置,由于车辆和障碍物位于不同的坐标系中,通过式(4)(5)(6)将障碍物的坐标从局部坐标系转换到全局坐标系,以实现统一的坐标参考框架。

$$\begin{cases} \alpha = \theta_3 + P_{h3} \\ T = \begin{bmatrix} \cos(\alpha) & -\sin(\alpha) \\ \sin(\alpha) & \cos(\alpha) \end{bmatrix} \end{cases} \quad (4)$$

$$\begin{cases} Q' = \begin{bmatrix} x_T \\ y_T \end{bmatrix} = T \cdot \begin{bmatrix} S_d \\ 0 \end{bmatrix} \\ d_c = \begin{bmatrix} d_x \\ d_y \end{bmatrix} = T \cdot \begin{bmatrix} d_s \\ 0 \end{bmatrix} \end{cases} \quad (5)$$

$$Q'' = \begin{bmatrix} x_3 \\ y_3 \end{bmatrix} = Q' + d_c + V_2 \quad (6)$$

式中: θ_3 为车辆 V_2 在全局坐标系中的航向角; α 为局部坐标系相对于全局坐标系的旋转角; x_T 、 y_T 分别为障碍物经旋转变换后的横向坐标和纵向坐标; d_x 、 d_y 分别为传感器安装位置相对于车辆参考点的横向偏移量和纵向偏移量; V_2 为车辆在全局坐标系中的位置向量。

Q 和 d_s 通过式(4)的转换矩阵 T 得到转换坐

标下的信息格式 Q' 和 d_c , 如式(5)所示。式(6)合并车辆位置信息到的障碍物全局坐标下的位置信息 Q'' 。V2V 传输将 Q 以式(2)的形式传递给 V2V 接收端。

2.2 通信持续性风险场模型建立

风险场的构建通常基于多个关键参数,包括障碍物的位置、速度,车辆自身速度和行驶方向,以及周围环境的交通规则和路况信息。基于等效力思想,本文给出了车-车及人-车风险场的场力表达形式,如下所示:

$$\begin{cases} R_{V1} = M_1 P_{S1} \left(\frac{1}{2l_{V1}} \right) \\ R_Q = M_1 P_{SQ} \left(\frac{1}{2l_Q} \right) \end{cases} \quad (7)$$

式中: R_{V1} 为车辆对空间点的相互作用力; M_1 和 P_{S1} 为车辆的质量和速度; l_{V1} 为车辆位置到空间内点的距离; R_Q 为行人对空间点的相互作用力; P_{SQ} 为行人的速度; l_Q 为行人位置到空间内点的距离。

驾驶盲区场景下,在雷达信息传递过程中,将行人的风险场质量视为与车辆相同,以平等评估两者风险。

考虑到实际车辆行驶环境有着场力范围和车道线约束,不可无限扩散,范围约束如下所示:

$$R_{V1} = \begin{cases} 0, & l_{V1} \in (l_{\max}, +\infty) \\ \frac{1}{2} M_1 P_{S1} \delta \left(\frac{l_{\max}^2 - l_{V1}^2}{l_{V1}^2 l_{\max}^2} \right), & l_{V1} \in [l_{\min}, l_{\max}] \\ \frac{1}{2} M_1 P_{S1}, & l_{V1} \in [0, l_{\min}) \end{cases} \quad (8)$$

式中: $l_{\max}$ 为风险最大影响范围; $l_{\min}$ 为存在碰撞风险距离; δ 为驾驶人对风险的关注范围。

在真实环境中,车辆行驶方向的风险远大于车后方,假设 V_1 行驶方向为 X 轴,结合多普勒频移效应^[16]将 l_{V1} 分解为纵横方向:

$$l_{V1}^2 = \tau_x \Delta x^2 + \tau_y \Delta y^2 \quad (9)$$

式中: Δx 、 Δy 分别为 V_1 在 l 范围空间点纵向、横向和相对速度; τ_y 和 τ_x 为梯度调整系数,其中 τ_y 取值为 1, τ_x 表达式如下所示。

$$\tau_x = \frac{(S_{\max} - P_{S1} \alpha \varphi)^2}{(S_{\max} + P_{SQ} \alpha \varphi)^2} \quad (10)$$

式中: α 和 φ 分别为位置和速度的变化趋势。

$$\alpha = \begin{cases} 1, & \Delta x \geq 0 \\ -1, & \Delta x < 0 \end{cases} \quad (11)$$

$$\varphi = \begin{cases} 1, & \Delta S > 0 \\ 0, & \Delta S = 0 \\ -1, & \Delta S < 0 \end{cases} \quad (12)$$

利用式(9)建立车辆 V_1 位置(0,0)下的风险场,可知车辆风险场纵向范围不满足道路的形状。使用车道线作为风险场几何约束条件,确保风险评估与道路的实际布局相适应。考虑车辆的外形类似椭圆,以此建立风险场的纵横比 τ_r 为:

$$\tau_r = a^2/b^2 \quad (13)$$

式中: a 和 b 分别为椭圆长半轴和短半轴。

此时圆形上的点到车辆的距离也会产生变化,这个时候的 Δx 、 Δy 为:

$$\begin{cases} \Delta x = l' \cos(\theta' + P_{h3}) \\ \Delta y = l' \sin(\theta' + P_{h3}) \end{cases} \quad (14)$$

式中: θ' 为圆形上的点 P' 到车辆的距离 l' 与横坐标的夹角。

此时,椭圆风险场上点到车辆的距离为:

$$l_{V1}^2 = \tau_x \Delta x^2 + \tau_y \Delta y^2 \quad (15)$$

在交通场景中,具有移速的行人风险场与车辆风险场等同,均对交通安全构成动态影响。行人风险场建立公式如下:

$$R_Q = \begin{cases} 0, & l_Q \in (l_{\max}, +\infty) \\ \frac{1}{2} M_1 P_{SQ} \delta \left(\frac{l_{\max}^2 - l_Q^2}{l_Q^2 l_{\max}^2} \right), & l_Q \in [l_{\min}, l_{\max}] \\ \frac{1}{2} M_1 P_{SQ}, & l_Q \in [0, l_{\min}) \end{cases} \quad (16)$$

在车辆 V_1 视角下,建立行人 Q 的风险场模型,并考虑通信持续性可能引入的潜在风险。

通信持续性影响因子从 V2V 通信过程和车辆 V_1 与碰撞点的时空关系两个维度进行考量。在 V2V 通信开始时, V_1 距离碰撞点为 d_3 , 此时 Q 点尚未到达碰撞点,风险尚未形成,如图 2(a) 所示。V2V 通信中断后, V_1 已行驶 d_1 距离,剩余 d_2 距离未规划,风险存在于 d_2 的时空范围内,如图 2(b) 所示。空间上, V_1 需完成 d_3 全程,分为 d_1 的安全段和 d_2 的危险段。时间上,风险随 t_2 的增加而增加,与 t_2 成正比; t_1 增加则 t_2 减少,风险随之降低,与 t_1 成反比。因此,构建的函数需体现安全和危险两个阶段,并满足 t_1 与风险的反比关系。

建立通信持续性影响因子 τ_t 反映时空信息的变化,如下所示:

$$\tau_t = \int_0^{t_1} 1dt / \int_0^{t_3} 1dt \quad (17)$$

式中: t_1 和 t_3 分别为传输持续阶段传的时间、车驾驶至碰撞点所需的所有时间。

由于行人和车辆的运动方向不同,所以行人的位置变化趋势如下:

$$\alpha_Q = \begin{cases} -1, & \Delta y \geq 0 \\ 1, & \Delta y < 0 \end{cases} \quad (18)$$

基于车辆的风险场,行人风险场上的点到行人的距离为:

$$l_Q^2 = \tau_y \tau_r \Delta x^2 + \tau_x \tau_r \Delta y^2 \quad (19)$$




图2 通信持续性影响因子建立

Fig. 2 Establishment of communication persistence impact factor

3 基于风险模型的路径规划

为了安全、高效地避障,本文基于碰撞风险场模型提出新的DP算法。首先,将碰撞风险场模型加入到路径动态规划代价函数中,并设计基于通信持续性影响因子的自适应避障函数;进而将避障凸空间问题转化为非凸问题;最后,基于非凸空间进行路径二次规划。

3.1 集成通信持续性风险场的RMDP算法

动态规划的本质是正向求解、逆向寻优的过程,其目的是将行驶区域从非凸空间转为凸空间,为路径二次规划提供粗解。算法首先将行驶区域

离散化处理,其中每层SL中的每个节点代表一个特定的状态,进而将RMDP分解为多个阶段,每个阶段 i 表示行, j 表示列,总节点 $N = [SL_{i1}, SL_{i2}, SL_{i3}, \dots, SL_{ij}]$,对 N 中每个节点进行代价累计计算,并依据最小代价原则确定最优路径方案。本文路径动态规划代价函数主要考虑碰撞风险、路径平滑和参考线代价。

引入风险场概念时,风险视为一个重要的性能指标,RMDP算法的本质是将风险场加入到路径规划中,并以此为基础构建安全代价函数,使得RMDP算法不仅考虑路径的直接成本,还会考虑潜在的安全风险,从而优化出一条既经济又安全的行驶路线。RMDP融入风险场代价的公式为:

$$C_{DP}(g(S)) = C_{comf}(g) + C_{ref}(g) + C_{R_q}(g) \quad (20)$$

式中: C_{DP} 为成本函数,此函数由曲线平滑代价 $C_{comf}(g)$ 、参考线代价 $C_{ref}(g)$ 和总障碍物代价 $C_{R_q}(g)$ 组成; $g(S)$ 为每个节点之间相连5次多项式曲线,用于计算两点之间曲线路径, $g(S) = k + k_1 S + k_2 S^2 + k_3 S^3 + k_4 S^4 + k_5 S^5$ 。

$$C_{comf}(g) = \epsilon_1 \int (g'(S))^2 dS + \epsilon_2 \int (g''(S))^2 dS + \epsilon_3 \int (g'''(S))^2 dS \quad (21)$$

式(21)通过 $g(S)$ 斜率、曲率和曲率变化率评估路线的平滑程度,并以该指标代表路线的舒适性, $\epsilon_1, \epsilon_2, \epsilon_3$ 为这3个评估的权重。

针对RMDP存在多解性的问题,且并非所有解都可取,而自动驾驶寻求的是一条最优路径。RMDP方法在开辟凸空间进行路径优化时,通常以一条参考线为基准,围绕该参考线探索次优解。参考线的代价评估通过一个特定的式子进行量化,如下所示:

$$C_{ref}(g) = \int (g(S) - h(S))^2 dS \quad (22)$$

式中: $h(S)$ 为参考路径函数,规划路径与参考路径之间的距离越大,代价越大,越应该避免。

单纯地采纳参考路径并不总能确保获得全局最小代价,因为这一策略未能充分考虑障碍物对路径规划的影响。需将障碍物带来的风险纳入考量。障碍物风险如下所示:

$$C_{R_q}(g) = \begin{cases} C_{obs}(l), & \tau_t = 1 \\ R_Q + C_{obs}(l), & \tau_t \in (0, 1) \end{cases} \quad (23)$$

式中: $C_{R_q}(g)$ 包括障碍物代价 $C_{obs}(l)$ 和风险场

代价 R_Q 。

当 V2V 通信开始,即 $\tau_i=1$,没有通信不需要计算潜在风险时,只需要计算障碍物代价 $C_{\text{obs}}(l)$,具有距离约束的障碍物代价有助于规划模块专注于局部区域内的障碍物,从而提高路径规划的效率和准确性。当 $\tau_i \in (0, 1)$ 时,需要额外考虑过时信息带来的潜在危险,即 R_Q 风险场代价,如图 3 所示(彩图参见电子版,后文同),RMDP 开辟的凸空间(红色区域)因考虑到未知时间内行人可能存在加速行为而更大,因此规划的路线更加安全;DP 规划采用过时信息开辟凸空间,因此规划路线存在碰撞的可能性。RMDP 算法通过调整车辆的行驶策略,应对不断变化的交通环境和潜在的碰撞风险,确保自动驾驶车辆在复杂环境中实现高效、安全的驾驶。

3.2 基于 RMDP 凸空间的二次规划

如图 3 所示,RMDP 算法通过评估从初始状态至目标状态的所有可能路径,并选取代价最小的路径作为最优解,将路径规划问题从非凸优化问题转化为凸优化问题。然而,由于 RMDP 算法基于离散点信息,其在驾驶盲区等场景下规划的路径可能缺乏平滑性,且未能充分考虑动态安全性。因此,有必要在 RMDP 算法确定的凸空间内进行路径二次规划,以优化路径的平滑度和动态安全性^[17,18]。




图 3 RMDP 开辟凸空间
Fig. 3 Convex space creation in RMDP

QP 算法定义一个成本代价函数,该函数基于二阶连续可导目标函数,在给定的凸空间和约束条件下,可以有效地求解路径规划问题。QP 算法利用目标函数的一阶和二阶导数信息,通过数值优化方法,寻找满足约束条件的全局最优解。QP 的成本代价函数为:

C_{QP} = C_{smooth} + C_{ref} + C_{DP} (24)

式中: C_{smooth} 为路径平滑代价; C_{ref} 为距离参考线代价; C_{DP} 为凸空间中央代价。

C_{smooth} 确保路径的几何平滑性避免急转弯,通常与路径的一阶导数(斜率)、二阶导数(曲率)和三阶导数(曲率变化率)有关。参考线代价 C_{ref} 用

于量化规划路径与预定义的参考路径之间的偏差。这个代价项鼓励路径规划算法生成的路径尽可能靠近参考线,以保持行驶的合理性和预测性。动态规划代价 C_{DP} 量化了凸空间内中央路线的偏差,预防车辆作为质点可能引发的边缘碰撞。二次规划(QP)在凸空间内通过二阶连续可导的目标函数,结合约束条件,精确地寻求成本函数的最小值,实现最优路径规划。目标函数的标准式为:

min f = 1/2 L^T H L + F^T L (25)

式中: L 为二次规划的决策向量; H 为目标函数二次项的 Hessian 权重矩阵; F 为目标函数一次项的权重向量。

等式约束和不等式约束为:

{ A1L = b1, A2 <= b2 (26)

在给定凸空间中,通过求解式(25)以最小化目标函数 L ,并求解满足式(26)中的连续性等式约束和碰撞不等式约束,最后通过 Frenet 与 Cartesian 坐标的转换,获得优化后的最终路径^[19,20]。

4 实 验

4.1 驾驶盲区场景设计

为了验证所提方法的有效性,本文采用 Prescan 搭建存在障碍物遮挡情况下的双车道十字路口场景。 V_1 和 V_2 两辆车与行人的行驶路径分别为 L_1 、 L_2 和 L_3 ,全局坐标系中, V_1 和 V_2 位置信息分别为 $PO_{V1}=(P_1, P_{s1}, P_{h1})$ 和 $PO_{V2}=(P_2, P_{s2}, P_{h2})$ 。通过路径和位置信息可知, L_1 与 L_3 可能发生碰撞,定义该区域为风险区(F)。 V_2 的传感器能够探测到行人,而 V_1 的传感器尚未探测到行人,但 V_1 已经进入 V_2 的 V2V 通信范围,接收到 V_2 传递的行人信息,包括位置、速度等。

根据上述场景的描述,仿真验证分为 3 部分,车辆通信存在中断风险仿真验证、避障路径规划仿真验证,仿真实验的车辆和行人参数设置如表 1 所示,风险场参数如表 2 所示。

表 1 Prescan 参数设置
Table 1 Prescan parameter settings

对象	速度/ (m·s ⁻¹)	加速度	动力学 模型	仿真频率/ Hz	仿真 步长
V ₁	15	可变	Carsim	20	1000
V ₂	10	0	Carsim	20	1000
Q	1	0	无	20	20

表 2 风险场参数设置

Table 2 Risk field parameter setting

参数	数值	描述
$l_{\max}/\text{m}$	30.451 1	风险场影响最大范围
$l_{\min}/\text{m}$	5.330 6	以车辆为中心的风险场边界
δ/m	32.970 7	跟车距离
M_1/kg	1 500	产生风险场的重力
$S_{\max}/(\text{m}\cdot\text{s}^{-1})$	55.56	车道最大限速
a/m	33.451 1	椭圆的长半轴
b/m	3.5	椭圆的短半轴

本文利用 Carsim 提供车辆动力学约束;使用 Matlab 进行算法实现。

4.2 仿真验证

(1) 车辆通信存在中断风险仿真验证

为验证本文建立的基于通信持续性风险模型的有效性,仿真建立了驾驶盲区环境。如图 4 所




图 4 V2V 接收端车辆 τ_i 的变化

Fig. 4 Changes in V2V receiving end vehicles

示, τ_i 反映了车车协同中断潜在风险的程度, τ_i 值越小, 表明车辆接收到障碍物信息的时间相对于通过潜在危险区域所需的时间更短, 这导致信息的及时性降低, 从而增加了潜在风险。因此, 基于 τ_i 进行风险场建模以达到有效的风险评估。如图 5 所示, 图(a1)(b1)(c1)是风险场随着 τ_i 的变化而产生相应的变化。为了更直观地观察场力分布, 图 5(a2)(b2)(c2)通过等高线表示了风险场行驶方向范围与 τ_i 的关系, 信息越不及时, 风险场




图 5 V2V 接收端车辆根据 τ_i 建立的隐藏障碍物风险

Fig. 5 V2V receiving vehicle establishes the risk of hidden obstacles based on τ_i

的范围越大。由此表明,本文提出的基于通信持续性影响因子的风险场能够表示潜在风险的影响,为路径规划提供了安全依据。

(2) 避障路径规划仿真验证

基于驾驶盲区场景,本文考虑风险模型的动态规划RMDP与期望驾驶模型(EM)^[21],与EM相比,RMDP可提前预知风险并避障,解决驾驶盲区问题,提前避障规划。

图6为不同时刻的DP和QP规划路线。图6(a)(c)表明,传感器探测到障碍物之前($t=6.99$ s),RMDP算法已经开始对潜在风险区域进行建模,并为QP提供了更广阔的规划空间和更充裕的时间。相比之下,图6(b)(d)表明,EM模型算法直到传感器实际探测到障碍物时($t=9.09$ s)才开始规划避障路径,导致QP在紧急情况下规划的避障路线危险高且抖动,从而降低了安全性。

(3) 驾驶安全性及舒适性验证

自动驾驶舒适性的重要性仅次于安全性,合




图6 车辆分别在EM和RMDP算法系统中DP和QP规划
Fig. 6 Vehicle DP and QP planning in EM and RMDP algorithm systems respectively

格算法需要兼备这两个方面。采用横向加速度和速度作为舒适度的评价指标。加速度和速度变化越平缓,则表明驾驶过程越舒适。

图7(a)表明:RMDP算法系统在6~8 s期间进行了平缓的加速和减速,显示出较小的加速度变化。而EM模型算法在9~10 s左右进行了急剧的减速,导致加速度变化大且变化时间短,显示出陡峭的加速度变化。此外,速度变化的幅度也影响舒适性,图7(b)中,RMDP算法系统的速度变化小,且更接近规定的速度15 m/s,而EM模型算法的速度变化大,偏离规定速度较远。




图7 车辆分别在EM和RMDP算法系统中行驶各参数的变化

Fig. 7 Changes in various parameters of vehicles driving in EM and RMDP algorithm systems respectively

安全性方面,主要通过车辆与障碍物之间的距离以及风险值来衡量。车辆与障碍物的距离越远,风险值越低,表示驾驶越安全。图7(c)所示,RMDP算法系统在与障碍物的相对距离上比EM模型算法更远,显示出更高的安全性。在风险值对比实验中,图7(d)的RMDP算法系统比EM模型算法通过风险区域的时间短,风险值低,进一步证明了其在安全性方面的优势。

实验结果显示,RMDP 算法系统相较于传统的 EM 模型算法,在规划的路线上提供了更高的舒适性和安全性。通过车辆以自身建立的风险场

可以明显观察到,V2V 结束后障碍物风险场产生了变化,车辆确实根据变化过后的风险场进行有效的避障,如图 8 所示。




图 8 驾驶动态全局风险场

Fig. 8 Icicle driving dynamics global risk field

5 结束语

本文针对驾驶盲区场景下存在驾驶安全隐患的问题,提出了基于碰撞风险场模型的车辆协同避障规划算法。受不完整信息的影响,本文考虑 V2V 通信持续性的影响,构建了通信持续性风险场模型,以提高自动驾驶车辆的安全性和信息利用率。同时,将构建的风险场纳入到 DP 算法中,设计了基于通信持续性影响因子自适应的避障安全代价函数,提高车辆在驾驶盲区场景下的安全性。同时,为了减少在避障过程中的抖动,在二次规划中考虑了平滑性成本代价,以提高乘车过程中的舒适性。实验结果表明:①构建的通信性持续性风险场通过量化车辆动态信息和环境因素,增强了自动驾驶系统对不稳定 V2V 通信的鲁棒性。该模型在 V2V 通信干扰或中断时,可确保车辆准确预测环境变化,提升安全性和效率。②提出的 RMDP 算法在提供安全、平滑且舒适的驾驶

体验方面,优于期望驾驶系统。RMDP 与 EM 相比,可计算潜在风险,做到提前避障,能够解决驾驶盲区问题。

参考文献:

- [1] Li H M, Dong X, Rasheed I, et al. A software-defined networking roadside unit cloud resource management framework for vehicle ad hoc networks[J]. Journal of Advanced Transportation, 2022, 2022: 1-13.
- [2] Lu J Y, Peng Z X, Shi R W, et al. A quantitative blind area risks assessment method for safe driving assistance[J]. Journal of Systems Architecture, 2024, 150: 1-15.
- [3] Wang L H, Zhang F Q, Cui Y H, et al. Stochastic velocity prediction for connected vehicles considering V2V communication interruption[J]. IEEE Transactions on Intelligent Transportation Systems, 2023, 24(11): 11654-11667.
- [4] Jo J H, Shim J N, Kim B, et al. AoA-based position

- and orientation estimation using lens MIMO in cooperative vehicle-to-vehicle systems[J]. IEEE Journal on Selected Areas in Communications, 2023, 41(12): 3719-3735.
- [5] 陈吉清, 翁楚滨, 兰凤崇. 智能车辆换道潜在冲突分析与风险量化方法[J]. 汽车工程, 2021, 43(11): 1565-1576, 1586.
- Chen Ji-qing, Weng Chu-bin, Lan Feng-chong. Potential conflict analysis and risk quantification method of intelligent vehicle lane change[J]. Automotive Engineering, 2021, 43(11): 1565-1576, 1586.
- [6] 赵睿, 李云, 胡宏宇, 等. 基于V2I通信的交叉口车辆碰撞预警方法[J]. 吉林大学学报: 工学版, 2023, 53(4): 1019-1029.
- Zhao Rui, Li Yun, Hu Hong-yu, et al. Vehicle collision warning method at intersection based on V2I communication[J]. Journal of Jilin University(Engineering and Technology Edition), 2023, 53(4): 1019-1029.
- [7] 郑讯佳, 蒋骏皓, 黄荷叶, 等. 行车风险量化新方法及其防控策略仿真研究[J]. 机械工程学报, 2024, 60(10): 207-221.
- Zheng Xun-jia, Jiang Jun-hao, Huang He-ye, et al. Novel quantitative approach for assessing driving risks and simulation study of its prevention and control strategies[J]. Journal of Mechanical Engineering, 2024, 60(10): 207-221.
- [8] Lee M, Jo K, Sunwoo M. Collision risk assessment for possible collision vehicle in occluded area based on precise map[C]//IEEE International Conference on Intelligent Transportation Systems, Yokohama, Japan, 2017: 1-6.
- [9] 封硕, 吉现友, 程博, 等. 融合动态障碍物运动信息的路径规划算法[J]. 计算机工程与应用, 2022, 58(21): 279-285.
- Feng Shuo, Ji Xian-you, Cheng Bo, et al. Path planning algorithm based on dynamic obstacle movement information[J]. Computer Engineering and Applications, 2022, 58(21): 279-285.
- [10] 任玥, 郑玲, 张巍, 等. 基于模型预测控制的智能车辆主动避撞控制研究[J]. 汽车工程, 2019, 41(4): 404-410.
- Ren Yue, Zheng Ling, Zhang Wei, et al. A study on active collision avoidance control of autonomous vehicles based on model predictive control[J]. Automotive Engineering, 2019, 41(4): 404-410.
- [11] Szczepanski R. Safe artificial potential field-novel local path planning algorithm maintaining safe distance from obstacles[J]. IEEE Robotics and Automation Letters, 2023, 8(8): 4823-4830.
- [12] 韩小健, 赵伟强, 陈立军, 等. 基于区域采样随机树的客车局部路径规划算法[J]. 吉林大学学报: 工学版, 2019, 49(5): 1428-1440.
- Han Xiao-jian, Zhao Wei-qiang, Chen Li-jun, et al. Local path planning of bus based on RS-RRT algorithm[J]. Journal of Jilin University(Engineering and Technology Edition), 2019, 49(5): 1428-1440.
- [13] Zheng Xun-jia, Zhang Di, Gao Hong-bo, et al. A novel framework for road traffic risk assessment with HMM-based prediction model[J]. Sensors, 2018, 18(12): 4313-4327.
- [14] Liu Fang-ming, Chen Jian, Zhang Qi-xia, et al. On-line MEC offloading for V2V networks[J]. IEEE Transactions on Mobile Computing, 2023, 22(10): 6097-6109.
- [15] Meng Zong-lin, Xia Xin, Xu Run-sheng, et al. HY-DRO-3D: hybrid object detection and tracking for cooperative perception using 3D LiDAR[J]. IEEE Transactions on Intelligent Vehicles, 2023, 8(8): 4069-4080.
- [16] Ke X C, Ho K C. Localization by doppler derivatives and doppler-shifted frequencies[J]. IEEE Transactions on Signal Processing, 2024, 72: 2890-2904.
- [17] Fomeni F D. A lifted-space dynamic programming algorithm for the quadratic knapsack problem[J]. Discrete Applied Mathematics, 2023, 335: 52-68.
- [18] Zhang Lin, Wu Da-de, Zhao Ming-jing, et al. Uncertainty relation and the constrained quadratic programming[J]. Physica Scripta, 2024, 99(6): 1-35.
- [19] Reiter R, Nurkanovic A, Frey J, et al. Frenet-Cartesian model representations for automotive obstacle avoidance within nonlinear MPC[J]. European Journal of Control, 2023, 74: 1-8.
- [20] Yoon S, Kwon Y, Ryu J, et al. Reinforcement-learning-based trajectory learning in frenet frame for autonomous driving[J]. Applied Sciences-Basel, 2024, 14(16): 1-14.
- [21] Zhang Yi-xiao, Hao Rui, Zhang Ting-ting, et al. A trajectory optimization-based intersection coordination framework for cooperative autonomous vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9): 14674-14688.