

DOI: 10.13382/j.jemi.B2306565

智能汽车拟人驾驶风险量化方法研究*

李海青¹ 李永福² 郑太雄¹ 李洪丞¹ 蔡小雨¹

(1. 重庆邮电大学先进制造工程学院 重庆 400065; 2. 重庆邮电大学智能空地协同控制重庆市高校重点实验室 重庆 400065)

摘要: 驾驶风险量化评估对智能汽车拟人驾驶决策至关重要, 针对复杂多任务场景下的驾驶风险量化问题, 提出了一种基于人类风险感知机理的智能汽车驾驶风险量化方法。首先, 利用传感器获取驾驶场景周围环境信息与行驶状态信息, 并根据人类驾驶经验对潜在冲突因素赋值代价, 生成驾驶场景代价地图; 其次, 根据车辆运动状态与拟人驾驶的基本原则, 利用高斯函数建立动态风险模型; 最后, 结合驾驶场景代价图与动态风险模型实时计算拟人驾驶风险量化值。仿真结果表明, 提出的方法能够基于人类驾驶经验, 计算出动态变化的驾驶风险量化值, 应用于智能汽车自动驾驶决策, 可产生拟人驾驶行为。

关键词: 拟人驾驶; 动态风险场; 量化方法; 智能汽车

中图分类号: U491.2; U471.1 文献标识码: A 国家标准学科分类代码: 460.40

Research on human-like driving risk quantification method for intelligent vehicles

Li Haiqing¹ Li Yongfu² Zheng Taixiong¹ Li Hongcheng¹ Cai Xiaoyu¹

(1. Advanced Manufacturing Engineering School, Chongqing University of Posts and Telecommunications, Chongqing 400065, China;

2. Key Laboratory of Intelligent Air-Ground Cooperative Control for Universities in Chongqing, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Conducting a quantize value of driving risk is crucial for the human-like driving decision of intelligent vehicles (IV). Aiming at the challenge of quantifying driving risks in complex multi-task scenarios, a method of driving risk quantification of IV based on human risk perceived mechanism is proposed. By utilizing vehicle or road sensors, measurements of the surrounding environment and state information have been obtained. And a cost map of the driving scene is created by assigning costs to potential collision factors such as roads, plants, and obstacles that the driver believes may occur in the first stage. Based on the fundamental principles of human driving and vehicle motion states, a dynamic risk model is established utilizing Gaussian functions. The real-time computation of driving risk with human-like characteristics is accomplished through the integration of the cost map for the driving environment and a dynamic risk model. The simulation results demonstrate the effectiveness of the proposed method in quantifying dynamic driving risk based on human driving experience, which is applicable to autonomous driving decision-making for IV and capable of generating human-like driving behavior.

Keywords: human-like driving; dynamic risk field; quantification method; intelligent vehicles

0 引言

随着自动驾驶技术的不断发展, 如何使智能汽车如

人类一般驾驶车辆已成为自动驾驶领域的重要研究内容^[1]。针对智能汽车驾驶决策, 主要基于大数据学习^[2-3]或通过逻辑条件切换^[4-5]多种驾驶模式。然而, 基于大数据学习的方法对复杂多任务的驾驶场景难以满足, 而基

收稿日期: 2023-05-28 Received Date: 2023-05-28

* 基金项目: 国家自然科学基金(62273067)、重庆市创新发展联合基金(CSTB2022NSCQ-LZX0025)、重庆市教委青年项目(KJQN202100644)、重庆市自然科学基金面上项目(cstc2020jcyj-msxmX0915)资助

于逻辑条件的方法只有在满足指定的开启逻辑条件下才能发挥作用,也难以覆盖全部驾驶场景,泛化性较差。在驾驶过程中,人类驾驶员并非遵循简单的逻辑法则,假设自动驾驶汽车采取最优换道策略,处于附近位置的人类驾驶员可能产生误判,从而发生交通事故,拟人驾驶能有效提高驾乘人员对智能汽车的信任度,避免因人机差异造成交通事故^[6]。自动驾驶在本质上是模仿人类驾驶行为的拟人驾驶^[7],而准确的驾驶风险评估是智能汽车实现拟人驾驶的基础^[8]。

驾驶风险评估方法主要可以分为3类:基于轨迹的单一目标碰撞检测评估方法^[9-12],基于区域的可达集碰撞检测评估方法^[13-14]与基于场论的无碰撞检测评估方法^[15-18]。基于轨迹的单一目标碰撞检测评估方法通过评价指标计算自车与某一目标物发生碰撞的风险。例如碰撞时间指标(time to collision, TTC)^[9],碰撞距离指标(distance to collision, DTC)^[10],该方法能快速评估碰撞风险且运算效率高,但由于忽略了车辆和障碍物的不确定性,其应用场景受到了一定限制。在此基础上,提出考虑驾驶行为不确定性^[11]和运动控制参数不确定性^[12]的碰撞概率性评估方法。该方法能更准确检测到汽车的碰撞风险,但由于考虑了更多的影响因素,计算成本更高。基于区域可达集碰撞检测评估方法通过每一个时间步长计算车辆将达到的状态集合,并用其大小表征风险。Söntges等^[13]提出了一种障碍物时变的车辆可行驱区域计算方法,而实际环境中存在的障碍物和道路边界的影响,利用可达集结合优化方法可保证汽车在得到的行驶区域中不发生碰撞^[14],但其求解困难、计算复杂,实时性差,影响了其应用。基于场论的无碰撞检测评估方法通过利用场景中的元素产生场强(排斥力),并利用斥力场大小来表征碰撞风险。Wu等^[15]提出了一种基于交通流场的车辆跟随风险排斥指标,直接用排斥力来量化风险水平。Wang^[16]等建立了考虑交通各因素影响的安全场模型,并利用该模型进行碰撞预警。朱乃宣等^[17]建立了障碍物的静态和动态风险场,并对车辆周围的风险进行评估。Luo等^[18]为了预测行车风险的动态变化,对传统势场模型进行了改进。基于场论的方法能更系统、全面地表征自车的驾驶风险,但模型中的系数难以直接获取,风险场不能随着转向而改变其形状。

综上所述,当前针对智能汽车拟人驾驶风险量化方法难以适应驾驶场景的复杂性和人类驾驶员的不确定性。为了智能汽车更好地融入人类驾驶生态,消除人类驾驶员对自动驾驶的不信任,本文提出了一种基于人类风险感知机理的智能汽车拟人驾驶风险的量化方法,通过融入人类驾驶经验来提高模型的普适性,其主要的创新点如下:

1) 不同于单一目标碰撞风险评估方法,本方法通过

人类驾驶经验给潜在冲突因素(道路、绿植与障碍车)赋值代价,生成移动的驾驶场景代价地图,避免了不确定的驾驶风险;2) 所提出的驾驶风险量化方法将人类驾驶行为的不确定性意识特征嵌入到动态风险模型中,避免了人机差异造成冲突;3) 算法能定量描述当前操纵的驾驶风险,应用于智能汽车驾驶决策,可产生拟人驾驶行为。

1 驾驶场景代价

1.1 驾驶风险感知理论

汽车行驶道路环境复杂多变,常伴随诸多冲突因素,如道路、绿植、障碍车等,人类驾驶员需时刻感知这些冲突因素,根据驾驶经验判断风险大小,并据此做出进一步决策,具体而言,驾驶员会事先给冲突因素设定一定的风险值,若实际感知到的风险大小和其可以接受的风险水平存在明显差异时,通过调整自己的行为(转向、加减速)来减少差异。驾驶风险感知是一项复杂的“驾驶技能”,是连接驾驶员知识和行为的纽带。有经验的驾驶员不仅需要掌握技术性,还需事先感知潜在危险并预防交通事故^[19]。

针对自动驾驶,大多数主流方案对多场景适应性弱,本文将人类驾驶风险感知机理阐释为驾驶员对视野范围内的冲突因素划分类型,并赋予对应的代价值,然后根据其与自车相对位置,自车运动状态做出最终的驾驶风险判断。具体的,首先通过生成驾驶场景代价图,模拟驾驶员对周围环境的初步风险感知;然后通过生成动态风险场,模拟驾驶员对自身运动状态的风险判断;最后将两者进行耦合计算驾驶风险。需要说明的是本方案主要是为了模拟真实驾驶员的风险感知过程,建模过程中忽略了天气状态,宏观时间信息等因素的影响,相关研究可参考文献^[20]。

1.2 场景代价

根据人类驾驶风险感知理论,在实际行驶过程中,驾驶风险感知的第1步为:驾驶员对汽车周围环境进行评估,并生成驾驶场景代价图,此时可先不对车辆行驶状态做出风险评估。具体的,1) 根据汽车驾驶场景周围环境信息,获取道路环境障碍物的初始地图;2) 根据障碍物类型定义代价,根据障碍物方位赋予代价;3) 根据各障碍物类型的代价和障碍物方位的代价乘积,得出相应的驾驶场景代价。

典型驾驶场景代价示意图如图1所示。图1中椭圆点表示自车位置,车道边界绿植的代价值记为 $Cost_1$,车道内障碍车的代价值记为 $Cost_2$,车道边界线代价值记为 $Cost_3$ 。本文不具体研究驾驶场景冲突因素的代价成本,模拟中的所有障碍车都是相同的,具体代价值可通过实

验确定,即对不同年龄、性别、驾驶年限的驾驶人的真实驾驶数据级进行分析,实验,学习,得出相对准确的代价值,这与个体驾驶员无关。

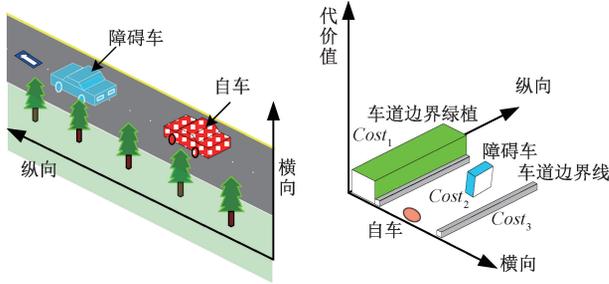


图 1 驾驶场景代价示意图

Fig. 1 Schematic of the driving scene cost

为模拟驾驶员对各类风险事物的方位判断,引入狄拉克 δ 函数构造方位矩阵 $T_{dir,i}$ 为:

$$T_{dir,i} = \frac{\text{sgn}(D_{dir,i}) + 1}{2} \quad (1)$$

其中, $T_{dir,i}$ 为方位矩阵,表征冲突因素相对于自车的位置信息; i 表示冲突因素的类型 ($i=1$ 代表树木, $i=2$ 代表障碍车, $i=3$ 代表自行车行驶车道以外区域, $i=4$ 代表自行车车道); dir 表示冲突因素相对于自车的不同方位, ($dir=1$ 代表前方, $dir=2$ 代表后方, $dir=3$ 代表左方, $dir=4$ 代表右方,道路只有左右方位); $D_{dir,i}$ 为方位初始矩阵,可通过当前驾驶区域上的所有网格点的坐标综合车辆位置、道路宽度、车辆转弯半径计算得出; sgn 为符号函数,其返回一个整型变量。

综合考虑不同类型冲突因素的代价值、方位信息与几何信息,驾驶场景代价 S_c 表示为:

$$S_c = \sum_i T_{dir,i} \cdot Cost_i \quad (2)$$

其中, S_c 表示驾驶场景代价, $Cost_i$ 表示冲突因素代价。

2 拟人驾驶动态风险场

拟人驾驶动态风险场主要用于预测和评估自行车行驶过程中的碰撞风险,将人类驾驶的基本原则(人类的不确定性意识)融入动态风险场模型中,并用于自动驾驶决策,系统将具备拟人驾驶特性。

2.1 动态风险场建模

为了描述汽车沿着行驶轨迹的动态风险,利用二维高斯函数^[21]建立前视时间内的动态风险模型 $R(x, y)$,可表示为:

$$\begin{cases} R(x, y) = \tau \cdot \exp\left(-\frac{(d(x, y) - r_o)^2}{2\sigma^2}\right) \\ d(x, y) = \left(\sqrt{(x - x_o)^2 + (y - y_o)^2}\right) \end{cases} \quad (3)$$

其中, $R(x, y)$ 表示网格点 (x, y) 的动态风险, τ, σ 分别表示高斯截面函数的高度、宽度, r_o 表示汽车的转弯半径, (x_o, y_o) 表示转弯半径网格点坐标。

高斯截面函数的高度可描述为:

$$\tau = \lambda (L - v \times T)^2 \quad (4)$$

其中, λ 代表抛物线的陡度, L 代表累计行驶路径长度, v 代表行驶速度。

高斯截面函数的宽度可描述为:

$$\sigma = (M + k_i |\delta|)s + \varepsilon \quad (5)$$

其中, M 代表风险场加宽或变窄的斜率, k_i 表示风险场的边沿, ($i=1$ 代表内边沿, $i=2$ 代表外边沿), ε 代表风险场的宽度修正参数。

假设转向角 δ 恒定,汽车在位置 (x_k, y_k) 绕旋转中心 (x_o, y_o) 以半径 r_c 旋转角度 ϕ , 旋转弧长 L , 则:

$$L = r_c \cdot \phi \quad (6)$$

经过时间步长 ΔT 后到达下一位置 (x_{k+1}, y_{k+1}) , 上述运动方程可表示为:

$$\begin{cases} x_{k+1} = x_k + \Delta T v \cos(\phi) \\ y_{k+1} = y_k + \Delta T v \sin(\phi) \end{cases} \quad (7)$$

式中: ΔT 为时间步长。

2.2 拟人驾驶原则

将人类驾驶行为的“不确定性意识”特征嵌入到驾驶风险场模型,引入 4 条拟人驾驶基本规则:

- 1) 动态风险场的宽度沿着汽车行驶的路径变宽,且比汽车的宽度尺寸更宽,使智能汽车在狭窄的道路上减速。
- 2) 动态风险场随着方向盘转角增加而变宽,使得智能汽车在较高曲率的弯道拥有更慢的行驶速度,保证汽车的操纵稳定性。
- 3) 动态风险场随着汽车行驶速度的增加而变宽、变长,使得智能汽车在弯道或减速行驶时保持恒定的时间间隔。
- 4) 动态风险场沿着行驶路径具有内外边沿不对称加宽特性,且内边沿小于外边沿,使得汽车在弯道处可以“切弯”行驶,不必始终沿车道中心行驶。

2.3 参数确定

拟人驾驶动态风险场模型参数决定了风险场的形状,且可以根据不同的风险偏好、行驶状态发生变化。分别基于文献中的历史数据以及实验数据,在尽可能的情况下,选择与模拟条件相似的自然驾驶数据,进行对比研究,确定模型参数^[22]并根据拟人驾驶原则进行优化,提高拟人驾驶风险场模型的准确性。

1) 宽度修正参数 ε

模型参数 ε 与汽车的宽度正相关,可由智能汽车的宽度直接确定, ε 的大小决定了风险场的宽度, ε 值越大,

风险场的宽度越大,一般可取 $\varepsilon = t_w/3$,其中 t_w 表示汽车的宽度。

2) 抛物线陡度 λ

抛物线陡度参数 λ 决定了风险场的高度,进而决定了风险场的大小, λ 越大,高斯截面函数的高度 τ 越大,具体可以利用实验数据,采用网格搜索算法进行估计。

3) 前视时间 T

前视时间 T 决定了风险场的高度,其值越大,风险场的预瞄路径长度 L 越大,高斯截面函数的高度 τ 越大,研究表明,保守的驾驶员前视时间长于激进的驾驶员, T 越大,驾驶越安全,通常在 1~3 s 范围选定。

4) 加宽斜率 M

加宽斜率 M 是反映汽车直行时,风险场的加宽特性参数。对于 $\delta=0$, M 值越大,高斯截面函数的宽度 σ 越大,但不宜过大,参数 M 一般设定在 0.001~0.01 范围内。

5) 边沿参数 k_i

边沿参数 k_i 反映高斯截面函数的内外边沿的宽度,若 $k_i > 0$,则风险场加宽;若 $k_i < 0$,则风险场宽度变窄。 k_1 表示风险场的内边沿, k_2 表示风险场的外边沿,若 $k_1 < k_2$,则表示高斯函数内边沿窄于外边沿,表现出允许汽车在弯道处“切弯”行驶;若 $k_1 = k_2$,则表示高斯函数内边沿宽度与外边沿相等,表现出汽车沿着中心线行驶;若 $k_1 > k_2$,则表示高斯函数内边沿宽于外边沿,汽车在弯道处飞出,通常 $k_1 < k_2$ 。

3 拟人驾驶风险量化

综合考虑驾驶场景的冲突因素,与车辆运动状态,采取将驾驶场景代价与动态风险场相乘,并对驾驶区域内所有网格点求和方式进行风险量化,并与驾驶员的风险阈值进行对比,可做出拟人驾驶决策。

3.1 驾驶区域代价地图

为了模拟驾驶员视野范围,以驾驶区域有限范围内的网格点构造网格地图,且随自车移动。假设智能汽车以速度 v 行驶,以自车为中心生成宽 vT 的正方形区域,在正方形区域内,均匀划分网格点,间隔取 0.5。

在确定的驾驶区域内的每个网格点处存储该处驾驶场景代价数值信息,得到驾驶场景的代价地图矩阵。本文构建的驾驶场景代价地图矩阵具有两个特点:一是可表征各类冲突因素的几何与物理信息,即冲突因素的体积、方位、大小等;二是方便驾驶场景代价图进行更新,即直接以当前时刻的网格点信息进行更新,不需要再重新构建代价图。

3.2 驾驶风险量化方法

在建立驾驶场景代价地图的基础上,结合动态风险

场模型,可计算出此刻汽车的驾驶风险的量化值,拟人驾驶风险量化方法如图 2 所示。

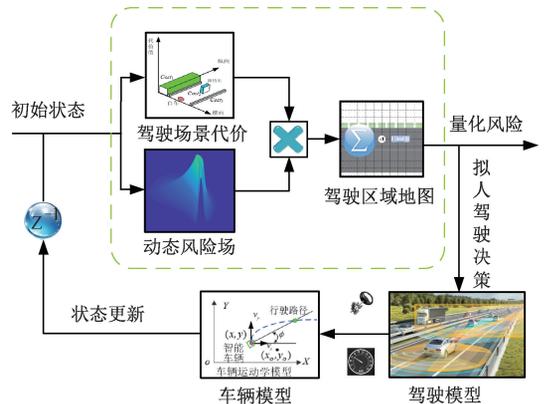


图 2 拟人驾驶风险量化方法

Fig. 2 Human-like driving risk quantification method

量化的驾驶风险 R_k 可以表示为:

$$R_k = \sum_{(x,y)}^{meshgrids} R(x,y) \times S_c \tag{8}$$

其中, R 为网格点 (x, y) 处的风险场。

3.3 拟人驾驶风险阈值

不同风格的驾驶员面对相同的量化驾驶风险 R_k ,往往也有不同的决策方案,表现为对同一驾驶场景的危险认知不同,即保守型驾驶员视为“危险”(应改变驾驶策略),而激进型驾驶员视为“安全”(无需调整驾驶策略)。对于拟人驾驶风险感知,则表现为风险阈值不同。

利用蒙特卡洛方法^[23],计算不同驾驶风格的风险阈值。首先建立典型驾驶情景,根据不同的冲突因素类型做出随机过程;然后建立 3 种不同驾驶风格(激进型、一般型、保守型)的危险感知的规律表,感知结果以“安全”或“危险”表示;接着对不同驾驶员分别进行模拟,并得出对应的量化的驾驶风险,若该类型驾驶员能对模拟场景中的危险感知规律进行正确区分,则赋值 1,否则赋值为 0;最后统计得出获得最多 1 的阈值作为该类型驾驶员的风险阈值的近似值。

完整的拟人驾驶风险量化方法流程总结如下:

- 步骤 1) 利用传感器获取汽车驾驶场景周围环境信息、车辆行驶状态信息(假设需要的信息都能获取);
- 步骤 2) 根据已获取的环境信息(冲突因素的类型、方位)分别定义代价,得出相应的代价;
- 步骤 3) 确定驾驶区域范围,将其划分为多个网格;
- 步骤 4) 在确定的驾驶区域内的网格点处存储该处驾驶代价数值信息,得到驾驶场景区域的代价地图;
- 步骤 5) 根据已获取的汽车状态信息,利用二维高斯函数建立动态风险场;
- 步骤 6) 将拟人驾驶的 4 条基本原则融入动态风险

场模型,并确定风险场的模型参数值;

步骤 7)将动态风险场与驾驶场景代价地图相乘得到拟人驾驶风险的量化值。

步骤 8)将驾驶风险量化值与风险阈值进行比较,做出相应的决策,并进行循环,实现智能汽车拟人驾驶。

4 仿真分析

4.1 驾驶场景代价图

设置一个典型的驾驶场景如图 1 所示,包含车道、道路旁树木、前方障碍车。驾驶场景代价图与道路、障碍物(障碍车、绿植)有关,道路(宽度、长度、直道、弯道)具有明显差异性,道路上障碍物也具有不同的分布。因此,将驾驶场景代价图分为道路代价图、绿植代价图与障碍车代价图,利用 MATLAB 生成道路地图、绿植地图和障碍车地图,驾驶场景代价图随着道路的生成与移动。

可能造成碰撞事故的冲突因素有:绿树、障碍车、车道及车道以外区域。其中,车道宽度设置为 3 m,由于树木受力面远小于车辆,通常情况下撞击树木的代价大于撞击障碍车,本节将绿树的危险代价 $Cost_1$ 赋值为 5,障碍车的危险代价 $Cost_2$ 赋值为 2.5,车道之外的其他区域危险代价 $Cost_3$ 设置为 1,自车道行驶危险代价 $Cost_4$ 设置为 0。冲突因素的具体代价参数如表 1 所示。典型驾驶场景代价图如图 3 所示。

表 1 冲突因素代价参数

Table 1 Cost parameter of conflict factors

冲突因素	类型 i	代价值 $Cost_i$
绿树	1	5.0
障碍车	2	2.5
车道以外区域	3	1.0
自车车道	4	0

4.2 拟人驾驶动态风险场分析

在典型的驾驶场景下(图 1),假设自车以中高速(60 km/h)直行和转弯,动态风险场模型参数如表 2 所示,生成的直行和转向两种工况下的拟人驾驶动态风险场如图 4 所示,模型参数对拟人驾驶动态风险场的影响如图 5 所示。

表 2 动态风险场模型参数

Table 2 Parameters of dynamic risk field model

模型参数	数值
抛物线陡度 λ	0.006 4
前视时间 T/s	3
加宽斜率 M	0.01
边沿参数 k_1, k_2	0, 2.5
车辆长度 l/m	4.7
车辆宽度 t_w/m	1.5
自车车速 $v/(m \cdot s^{-1})$	17

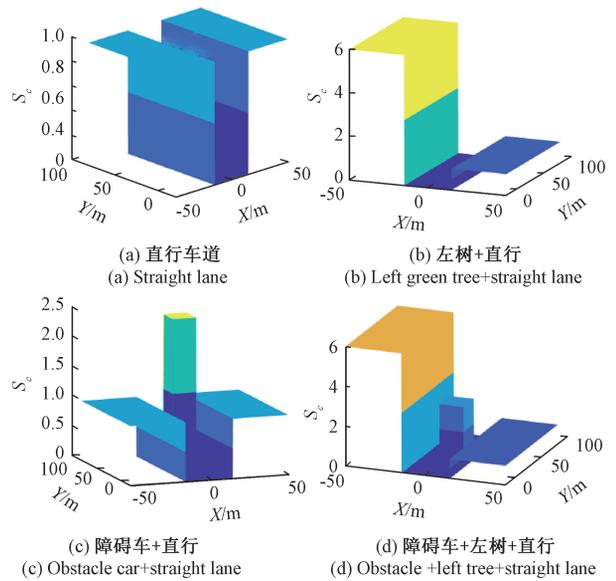


图 3 典型驾驶场景代价图

Fig. 3 Cost map of typical driving scenario

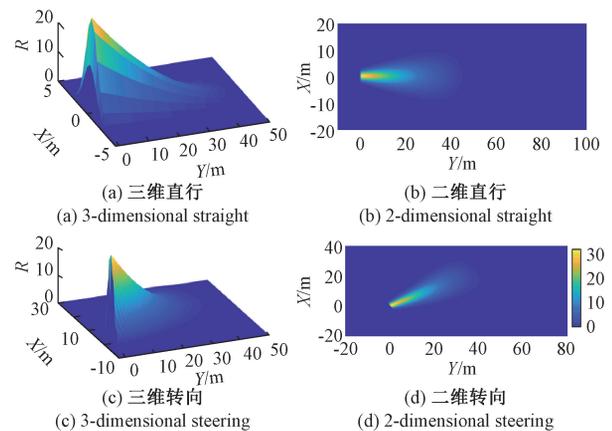


图 4 拟人驾驶动态风险场

Fig. 4 Dynamic risk field of human-like driving

从图 4 可知,动态风险场 R 在三维视图中呈现沙漏型,沿纵向距离呈幂律降低,并在转向时呈现不对称的高斯函数截面,符合真实驾驶情况。该风险仅基于运动状态生成,而与视野内的冲突因素无直接关系。

由图 5(a)可以看出,抛物线陡度 λ 越大,高斯截面函数的高度 τ 越大;由图 5(b)可以看出,前视时间 T 越大,高斯截面函数的高度 τ 越大;由图 5(c)可以看出,当边沿参数 $0 < k_1 < k_2$,高斯函数内边沿宽度 σ_1 明显窄于外边沿宽度 σ_2 ;由图 5(d)可以看出,行车车速 v 越大,动态风险场影响范围越大。

4.3 驾驶风险量化分析

利用蒙特卡洛方法,对标准双向行驶车道的 11 种典

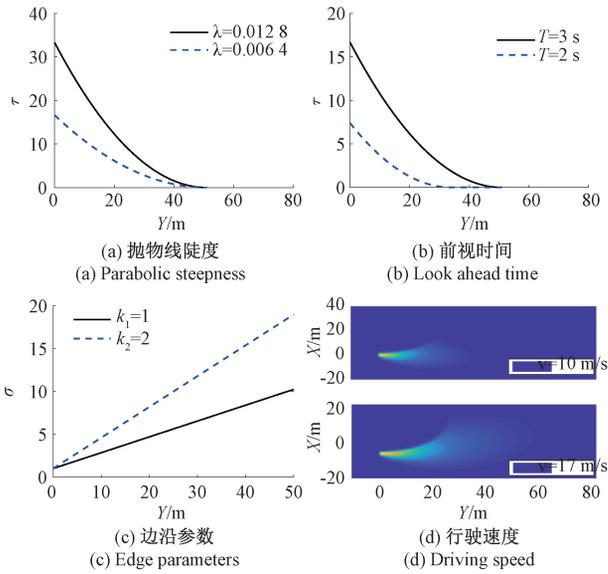


图 5 驾驶动态风险场影响因素

Fig. 5 Influence factor of dynamic risk field

型驾驶情景做出随机过程模拟,冲突因素分为自车车道前方是否有障碍车,车道边沿是否有树木以及面对危险驾驶场景,自车采取的不同操纵,即继续直行还是进行转向避障(左转向、右转向)。

障碍车的位置坐标为(0, 40),自车的初始位置坐标为(0, 0),车道宽度为 3 m,自车行驶速度为 17 m/s,典型场景下不同驾驶风格的风险感知规律如表 3 所示。

表 3 不同驾驶风格的风险感知规律

Table 3 Risk perception law of different driving styles

模拟场景	激进型	一般型	保守型
前障碍车+右树+直行	危险	危险	危险
前障碍车+右树+转右弯	危险	危险	危险
前障碍车+右树+转左弯	安全	危险	危险
前障碍车+无树+直行	危险	危险	危险
前障碍车+无树+转右弯	危险	危险	危险
前障碍车+无树+转左弯	安全	安全	危险
无障碍车+右树+直行	安全	安全	安全
无障碍车+右树+转左弯	安全	危险	危险
无障碍车+右树+转右弯	危险	危险	危险
无障碍车+无树+直行	安全	安全	安全
无障碍车+无树+转左弯	安全	危险	危险

假设所有模拟场景中量化的驾驶风险 R_k 独立同分布,在区间[300, 10 000]内生成整数并进行遍历,最终得出的不同驾驶风格的风险阈值如表 4 所示。

表 4 不同驾驶风格的风险阈值

Table 4 Risk threshold of different driving styles

驾驶风格	风险阈值 R_k
激进型	2 189
一般型	1 900
保守型	1 263

根据构建的动态风险场,结合驾驶场景区域的网格图,与对应位置冲突因素代价图相乘求和得到量化驾驶风险。典型驾驶场景下生成的驾驶风险场与对应的量化风险值如图 6 所示。其中,圆点表示自车位置,道路上左侧有树木,前方有障碍车,自车分别直行、右转、左转。

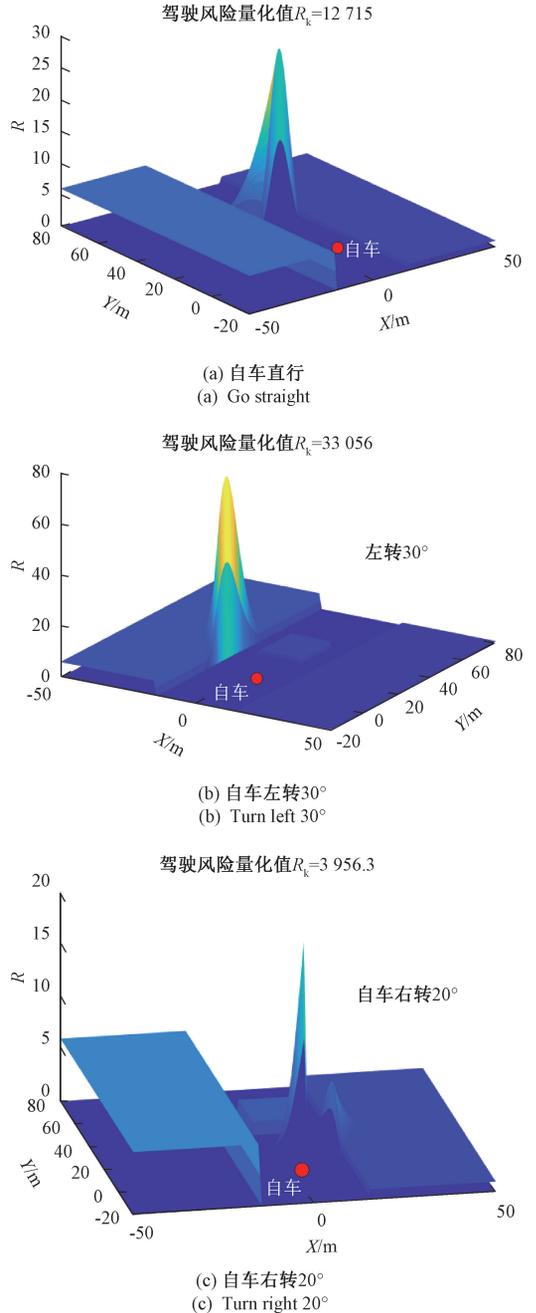


图 6 驾驶风险量化结果

Fig. 6 Driving risk quantification results

由图 6 可以看出,首先驾驶风险场能直观显示驾驶场景中的冲突因素(道路边界、左侧树木、前方障碍车)生成的代价;其次,驾驶风险场能根据车辆行驶状态直观

显示自车的动态风险;最后,驾驶风险场能表达冲突因素影响下的动态驾驶风险。

根据驾驶风险的量化结果,由图 6(b)可以看出,由于更可能撞上树木和前方行车,左转的量化风险值最高;由图 6(c)可以看出,由于更可能躲避前方障碍车和树木,右转的量化风险值最低,然而,由于此路段不允许右转换道,所以这 3 种场景的风险值都大于所有驾驶员的风险阈值,需进一步改变车辆行驶状态。

4.4 拟人驾驶避障

为了验证本文提出的拟人驾驶风险量化方法的有效性,建立避障场景与简单的驾驶模型^[24],并将拟人驾驶风险量化值 R_k 作为驾驶模型的决策依据,通过与风险值 R_s 进行比较,进行转向控制,具体为:当 $R_k < R_s$ 时,进行路径跟踪控制;当 $R_k > R_s$ 时,可以通过转向减小 R_{k+1} ,使得 $R_k < R_s$,若不能满足,则最小化 R_{k+1} ,并进行减速。

不同驾驶风格的避障效果如图 7 所示,其中,矩形条为障碍车,实线、点虚线、长虚线分别代表激进型、一般型和保守型驾驶风格的避障轨迹。

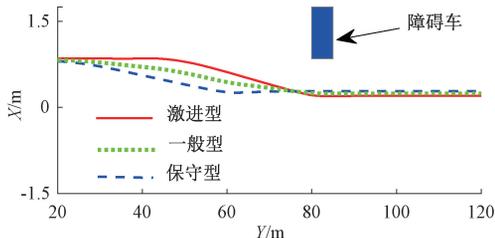


图 7 基于拟人驾驶风险量化方法的避障效果

Fig. 7 Obstacle avoidance by human-like driving risk quantification method

由图 7 可以看出,保守型风格车辆最先做出避障反应,即通过转向避障减小驾驶风险,因为保守型驾驶风格的风险阈值最小,对避障车更加敏感;激进型驾驶员倾向于在即将接近障碍车时才做出转向,且转向激烈,换道迅速,因为激进型驾驶风格的风险阈值最大;一般型驾驶风格介于二者之间。

仿真试验结果表明,提出的拟人驾驶风险量化方法能够有效计算出动态变化的驾驶风险量化值,应用于智能汽车驾驶决策,可产生符合驾驶人风格特征的拟人驾驶行为。

5 结论

本文提出了一种基于人类风险感知机理的智能汽车拟人驾驶风险量化方法,利用蒙特卡洛方法划分了 3 种驾驶风格的风险阈值,并进行了拟人驾驶避障试验。将智能汽车拟人驾驶风险分解为周围冲突因素的代价与自

车的动态风险,建立了包含冲突因素与自车运动状态的拟人驾驶风险感知模型;分析了模型参数与车辆状态对驾驶风险的影响,动态风险场在三维视图中呈现沙漏型,沿纵向距离呈幂律降低,并在转向时呈现不对称的截面特性;提出的方法能有效计算出量化的驾驶风险,应用于自动驾驶避障决策,可产生拟人驾驶行为。

参考文献

- [1] 宋东鉴,朱冰,赵健,等. 基于驾驶行为生成机制的智能汽车类人行为决策[J]. 汽车工程, 2022, 44(12): 1797-1808.
SONG D J, ZHU B, ZHAO J, et al. Human-like behavior decision-making of intelligent vehicles based on driving behavior generation mechanism[J]. Automotive Engineering, 2022, 44(12): 1797-1808.
- [2] 田彦涛,季言实,唱寰,等. 深度强化学习智能驾驶汽车增广决策模型[J]. 吉林大学学报(工学版), 2023, 53(3): 682-692.
TIAN Y T, JI Y SH, CHANG H, et al. Deep reinforcement learning augmented decision-making model for intelligent driving vehicles[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(3): 682-692.
- [3] 王玉龙,裴锋,刘文如,等. 基于开关式深度神经网络的拟人化自动驾驶决策算法[J]. 中国机械工程, 2021, 32(6): 689-696.
WANG Y L, PEI F, LIU W R, et al. Human-imitative autonomous driving decision-making algorithm based on switched deep neural networks[J]. China Mechanical Engineering, 2021, 32(6): 689-696.
- [4] 杨威,郑玲,李以农. 基于高斯混合模型的个性化自动驾驶决策控制研究[J]. 机械工程学报, 2022, 58(16): 280-289.
YANG W, ZHENG L, LI Y N. Personalized automated driving decision based on the Gaussian mixture model[J]. Journal of Mechanical Engineering, 2022, 58(16): 280-289.
- [5] 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.
- [6] YANG Z, FENG Y H, LIU H X. A cooperative driving framework for urban arterials in mixed traffic conditions[J]. Transportation Research Part C: Emerging Technologies, 2021, 124(1): 102918.
- [7] ZHANG Y X, HE G L, LI X, et al. Precise decision-making learning for automated vehicles in lane-change scenario based on parameter description[J]. Journal of Tongji University (Natural Science), 2021, 49(S1):

- 132-140.
- [8] CHIA W M D, KEOH S L, GOH C, et al. Risk assessment methodologies for autonomous driving: A survey [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10):16923-16939.
- [9] KILICARSLAN M, ZHENG J Y. Predict vehicle collision by TTC from motion using a single video camera [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 20(2): 522-533.
- [10] 朱冰, 朴奇, 赵健, 等. 基于路面附着系数估计的汽车纵向碰撞预警策略 [J]. 汽车工程, 2016, 38(4): 446-452.
- ZHU B, PU Q, ZHAO J, et al. Vehicle longitudinal collision warning strategy based on road adhesive coefficient estimation [J]. Automotive Engineering, 2016, 38(4): 446-452.
- [11] KIM J, KUM D. Collision risk assessment algorithm via lane-based probabilistic motion prediction of surrounding vehicles [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(9): 2965-2976.
- [12] WANG H, LU B, LI J, et al. Risk assessment and mitigation in local path planning for autonomous vehicles with LSTM based predictive model [J]. IEEE Transactions on Automation Science and Engineering, 2022, 19(4): 2738-2749.
- [13] SÖNTGES S, ALTHOFF M. Computing the drivable area of autonomous road vehicles in dynamic road scenes [J]. IEEE Transactions on Intelligent Transportation Systems, 2018, 19(6): 1855-1866.
- [14] 周兴珍, 裴晓飞, 张鑫康. 基于可达集优化的智能汽车轨迹规划研究 [J]. 武汉理工大学学报, 2022, 44(6): 39-48.
- ZHOU X ZH, PEI X F, ZHANG X K. Trajectory planning of intelligent vehicle based on reachable set and optimization [J]. Journal of Wuhan University of Technology, 2022, 44(6): 39-48.
- [15] WU B, YAN Y, NI D H, et al. A Longitudinal car-following risk assessment model based on risk field theory for autonomous vehicles [J]. International Journal of Transportation Science and Technology, 2021, 10(1): 60-68.
- [16] WANG J Q, WU J, ZHENG X J, et al. Driving safety field theory modeling and its application in pre-collision warning system [J]. Transportation Research Part C: Emerging Technologies, 2016, 72: 306-324.
- [17] 朱乃宣, 高振海, 胡宏宇, 等. 基于交通风险评估的个性化换道触发研究 [J]. 汽车工程, 2021, 43(9): 1314-1321.
- ZHU N X, GAO ZH H, HU H Y. Research on personalized lane change triggering based on traffic risk assessment [J]. Automotive Engineering, 2021, 43(9): 1314-1321.
- [18] LUO J F, LI S J, LI H Q, et al. Intelligent network vehicle driving risk field modeling and path planning for autonomous obstacle avoidance [J]. Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science, 2022, 236(15): 8621-8634.
- [19] 秦雅琴, 李秋谷, 谢济铭. 驾驶人风险感知研究综述 [J]. 昆明理工大学学报 (自然科学版), 2021, 46(5): 125-138.
- QIN Y Q, LI Q G, XIE J M. A review of research on hazard perception [J]. Journal of Kunming University of Science and Technology (Natural Sciences), 2021, 46(5): 125-138.
- [20] 李晓雷, 唐伯明, 宋强辉. 高速公路雾区多气候耦合段概率风险分析 [J]. 西南交通大学学报, 2018, 53(5): 1039-1047.
- LI X L, TANG B M, SONG Q H. Probabilistic risk analysis of multi-climatic coupling sections of expressway in fog area [J]. Journal of Southwest Jiaotong University, 2018, 53(5): 1039-1047.
- [21] KOLEKAR S, WINTER J, ABBINK D. Human-like driving behaviour emerges from a risk-based driver model [J]. Nature Communications, 2020, 11(1): 4850.
- [22] DUNNING A, GHOREYSHI A, BERTUCCO M, et al. The tuning of human motor response to risk in a dynamic environment task [J]. Plos One, 2015, 10(4): e0125461.
- [23] RAMEBÄCK H, PERSSON L, EKBERG C, et al. A Monte Carlo method for calculation of the characteristic limits decision threshold and detection limit in low-level radioactivity measurements [J]. Applied Radiation and Isotopes, 2021, 178: 109959.
- [24] 李海青, 赵又群, 林荣, 等. 汽车高速紧急避障路径跟踪与主动防侧翻控制 [J]. 哈尔滨工业大学学报, 2019, 51(7): 135-143, 153.
- LI H Q, ZHAO Y Q, LIN F, et al. Research on high speed path tracking and rollover control for obstacle avoidance under emergency of vehicle [J]. Journal of Harbin Institute of Technology, 2019, 51(7): 135-143, 153.

作者简介



李海青 (通信作者), 2019 年于南京航空航天大学获得博士学位, 现为重庆邮电大学讲师, 主要研究方向为智能控制与先进检测技术。

E-mail: lihq@cqupt.edu.cn

Li Haiqing (Corresponding author)

received his Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 2019. Now he is a lecturer in Chongqing University of Posts and Telecommunications. His main research interests include intelligent control and advanced detection technology.