

基于行车风险场的弯道切入场景生成与分析^{*}

张广松 钟武昌 周召高 余 荣

(广东工业大学自动化学院 广州 510006)

摘要: 自动驾驶领域中,仿真测试是识别和处理长尾问题的重要手段。本文针对弯道切入场景,提出了一种考虑道路曲率半径的行车风险场模型,并结合 Prescan/Simulink 的仿真平台和遗传算法,构建了自动化的风险场景生成框架。该框架以相对驾驶安全系数(RDSI)为优化目标,解决了传统风险指标在复杂场景下无法及时识别前车切入风险的问题。通过仿真生成不同道路曲率半径下的前车切入场景,并从中选取典型测试用例进行分析。结果表明,RDSI指标的预警成功率相比于碰撞时间(TTC)指标高出 65.6%,能够更早地识别潜在风险。此外,实验还显示不同道路曲率半径对碰撞风险有显著影响。

关键词: 自动驾驶;场景生成;行车风险场;遗传算法;切入

中图分类号: U467.1;TN06 **文献标识码:** A **国家标准学科分类代码:** 580.80

Generation and analysis of cut-in scenarios at curves based on driving risk field

Zhang Guangsong Zhong Wuchang Zhou Zhaogao Yu Rong

(School of Automation, Guangdong University of Technology, Guangzhou 510006, China)

Abstract: In the field of autonomous driving, simulation-based testing is an important means for identifying and addressing long-tail problems. This paper proposes a driving risk field model that considers road curvature radius for cut-in scenarios at curves. By integrating Prescan/Simulink simulation platform and genetic algorithms, an automated risk scenario generation framework is constructed. The framework uses the relative driving safety index (RDSI) as the optimization objective, which overcomes the limitations of traditional risk indicators that fail to promptly recognize cut-in risks by preceding vehicles in complex scenarios. Various cut-in scenarios under different road curvature radii are generated through simulation, and typical test cases are selected for analysis. The results show that the RDSI indicator achieves a 65.6% higher warning success rate compared to the time-to-collision (TTC) indicator and can identify potential risks earlier. Additionally, experiments reveal that different road curvature radii significantly impact collision risk.

Keywords: autonomous driving; scene generation; driving risk field; genetic algorithm; cut-in

0 引言

在自动驾驶技术迅猛发展的背景下,如何确保自动驾驶系统的安全性和可靠性成为了研究的核心问题。特别是在复杂的交通场景下,如弯道切入和交叉路口^[1]等,自动驾驶车辆需要准确检测和感知周围环境,实时评估风险并做出及时反应^[2-3]。近年来,众多研究通过优化深度学习模型和融合多模态数据来提升自动驾驶中的目标检测和环境感知性能^[4-7]。尽管这些技术显著提升了系统的感知能力,但在实际应用中,开放道路测试仍然面临着测试周期冗长、风

险性高、成本昂贵等挑战。因此基于场景的虚拟仿真测试已受到广泛的研究和应用^[8]。其中,聚焦于关键场景的加速测试方法成为了优化测试成本、缩减测试规模以及有效解决场景长尾问题的重要途径^[9]。

在各类道路交通场景中,自动驾驶车辆频繁遭遇的变道与切入行为,对道路的通行效率及安全性构成了显著的负面影响。参照 2023 年北京自动驾驶路测报告^[10],自动驾驶系统在遭遇需人类接管的情况中,有高达 32%的比例是由切入行为所引发。因此,高效构建车辆切入的关键场景,对于自动驾驶技术的研发以及智能网联汽车的安全保

障具有重要的意义。

在构建关键场景时,许多学者将交通车辆之间的交互建模为优化求解的问题。Klück等^[11]通过对比多种优化算法,验证了遗传算法在智能驾驶系统测试中能够以最少的测试次数有效生成高风险边界场景。Klischat等^[12]通过对比差分进化算法和粒子群优化方法在搜索关键场景中的表现,发现粒子群优化方法在复杂交叉口场景下展现出更快的收敛速度和更优的解。Tuncali等^[13]提出了一种基于模拟退火算法的方法,通过生成关键测试场景来识别车辆行为中的潜在错误。文献[14-17]提出了一种基于遗传算法的框架,用于生成包括跟车、切入以及复杂交通流在内的高风险自动驾驶测试场景。

以上文献主要将安全距离、碰撞时间(time to collision, TTC)、车头时距等距离或时间指标作为优化目标函数,这些指标能够快速评估风险并具备较高的实时性,但在对相邻车道车辆给主车造成的风险进行评估时存在较大难度,并且没有考虑静态场景要素和道路条件带来的影响^[18]。因此,有学者提出采用基于行车风险场模型的方法来评估风险,该方法能够综合考虑多个场景元素,适用于更复杂的驾驶场景。Wang^[19]等通过研究人-车-路之间的相互作用,提出了行车风险场的概念,将行车风险评估细分为势能场、动能场和行为场3个组成部分,并通过计算场景中的场强来量化潜在风险。这一方法为复杂交通环境下的风险评估提供了一种系统化的框架。陈浩等^[20]利用中国道路事故统计数据,对行车风险场模型参数进行了标定,并验证了模型在不同场景下进行风险评估中的有效性。Li等^[21]提出了一个基于动态驾驶风险势场模型的跟车模型,并验证了其在复杂交通环境中的有效性。Wu等^[22]提出了一个基于轨迹预测的行车安全场模型,用于评估行人与车辆碰撞的风险。然而,上述研究主要集中在直行道路的风险评估上,忽略了不同道路曲率对风险评估的重要影响。

综上所述,本文以弯道前车切入为研究对象,引入道路曲率半径以模拟真实世界的复杂驾驶环境。通过结合行车风险场理论框架,构建了一个以相对驾驶安全系数(relative driving safety index, RDSI)为基础的优化目标函数,并利用遗传算法与软件在环仿真平台实现了风险场景的自动化生成。最后,本文对比分析了RDSI指标与传统指标TTC的效果,以及不同道路环境下的行车风险,发现RDSI指标的预警成功率相比于TTC指标提升65.6%,验证了所提方法的有效性。

1 行车风险场模型构建

1.1 行车风险场理论概述

行车风险场是一种基于场论的行车风险评估方法,能够综合考虑车辆、道路、环境和驾驶人等多个因素的影响。其核心思想是将场景中的各交通元素(如其他车辆、行人、障碍物等)视作风险源,它们在空间中的分布和特性决定了

相应的风险场的生成。在多种风险场的综合影响下,车辆会面临来自不同交通要素所带来的风险作用,这些风险场叠加后所形成的总体效应被定义为“行车风险场”。

依据文献[19],行车风险场 E_s 的构建涉及3个主要的组成部分:由静态交通参与者构成的势能场 E_R 、动态交通参与者构成的动能场 E_V 和行为场 E_D ,公式表示如下:

$$E_{s_j} = E_{R_j} + E_{V_j} + E_{D_j} = \sum_n E_{R_{nj}} + \sum_p E_{V_{pj}} + \sum_q E_{D_{qj}} \quad (1)$$

$$F_j = E_{s_j} M_j R_j \exp[-k_2 v_j \cos(\theta_j)] (1 + DR_j) \quad (2)$$

式中: j 表示场景中的主车, n 表示场景中的静态元素(如道路标志、障碍物等), p 表示场景中的动态参与者(如其他车辆、行人等), q 表示场景中所有驾驶人; E_{s_j} 为主车 j 位置处的总行车风险场强合矢量, E_{R_j} 、 E_{V_j} 、 E_{D_j} 分别为势能场、动能场和行为场在主车 j 位置处的合成场强向量; F_j 表示主车 j 当前驾驶状态的风险程度; M_j 为主车 j 的等效质量; R_j 为在位置 (x_j, y_j) 处的道路条件影响因子; k_2 为待定常数; v_j 为主车 j 的速度; θ_j 为主车 j 速度方向与总场强矢量 E_{s_j} 方向之间的夹角; DR_j 为主车 j 中驾驶人员的驾驶风险因子。

根据势能场的特征,道路上静止的物体可以划分为两大类:第一类是那些在与车辆相撞时可能会引发重大损害的物体。位于 (x_a, y_a) 处的第一类静止物体 a 在 (x_j, y_j) 处产生的势能场场强矢量 $E_{R1,aj}$ 如下:

$$E_{R1,aj} = E_{R1,aj}(R_a, M_a, \mathbf{r}_{aj}) = \frac{K \cdot R_a \cdot M_a}{|\mathbf{r}_{aj}|^{k_1}} \cdot \frac{\mathbf{r}_{aj}}{|\mathbf{r}_{aj}|} \quad (3)$$

式中: $E_{R1,aj}$ 为第1类静态物体 a 产生的势能场场强; \mathbf{r}_{aj} 为从物体 a 质心位置指向 (x_j, y_j) 的距离矢量; R_a 为在位置 (x_a, y_a) 处的道路条件影响因子; M_a 为物体 a 的等效质量; K 和 k_1 均为大于零的待定常数。

第2类静止物体为不会引发碰撞但会对车辆行为产生约束的物体,即车道线 a 形成的势能场在 (x_j, y_j) 处形成的势能场场强矢量 $E_{R2,aj}$ 如下:

$$E_{R2,aj} = E_{R2,aj}(LT_a, R_a, D, \mathbf{r}_{aj}) = LT_a \cdot R_a \cdot \left(\frac{D}{2} - |\mathbf{r}_{aj}| \right)^{k_2} \cdot \frac{\mathbf{r}_{aj}}{|\mathbf{r}_{aj}|} \quad (4)$$

式中: $E_{R2,aj}$ 为第二类静态物体车道线 a 产生的势能场场强; \mathbf{r}_{aj} 为从车道线 a 指向车辆的质心位置 (x_j, y_j) 的距离矢量; R_a 为在车道线处的道路条件影响因子; LT_a 为车道线 a 类型, D 为车道宽度; k_2 为待定常数。

位于 (x_b, y_b) 处的动态交通参与者 b 形成的动能场在 (x_j, y_j) 处的场强如下:

$$E_{V,bj} = E_{V,bj}(R_b, M_b, \mathbf{r}_{bj}, \mathbf{v}_b) = \frac{K \cdot R_b \cdot M_b \cdot k_3}{(k_3 - |\mathbf{v}_b| \cos \theta_b) \cdot |\mathbf{r}_{bj}|^{k_1}} \cdot \frac{-\nabla E_{V,bj}}{|\nabla E_{V,bj}|} \quad (5)$$

式中: $E_{V,bj}$ 为动态交通参与者 b 在 (x_j, y_j) 产生的动能场

场强; \mathbf{r}_{bj} 为从物体 b 质心位置指向 (x_j, y_j) 的距离矢量; R_a 为在物体 b 处的道路条件影响因子; M_b 是物体 b 的等效质量; \mathbf{v}_b 表示物体 b 的速度矢量; θ_b 为 b 的速度方向与 \mathbf{r}_{bj} 的夹角; $\nabla \mathbf{E}_{v,bj}$ 为 $\mathbf{E}_{v,bj}$ 的梯度向量; K, k_1 与 k_3 均为大于零的待定常数。

位于 (x_c, y_c) 处的车辆 c 的驾驶人形成的行为场在 (x_j, y_j) 处的场强如下:

$$E_{D,cj} = \mathbf{E}_{v,cj} \cdot \mathbf{DR}_c \quad (6)$$

式中: $\mathbf{E}_{v,cj}$ 是车辆 c 在 (x_j, y_j) 产生的动能场场强矢量; \mathbf{DR}_c (取值在 $(0, 1]$ 的无量纲的量) 是车辆 c 驾驶人的驾驶人风险因子; $E_{D,cj}$ 为车辆 c 驾驶人对周围环境所构成的潜在威胁。

安全势能 (safety potential energy, SPE) 是描述车辆在行车风险场中受到保守场力作用而具备的势能, 用于衡量车辆由于靠近其他交通参与者或静态物体所面临的风险, 规定当车辆距离场源无限远时, 其安全势能为零, 那么车辆 j 受物体 i 的影响而具备的安全势能 SPE_{ij} 及其随时间的变化的速率 \dot{SPE}_{ij} 可以由以下公式表示:

$$SPE_{ij} = - \int_{\infty}^{r_{ij}} F_{ij} \cdot d\mathbf{r} \quad (7)$$

$$\dot{SPE}_{ij} = - F_{ij} \cdot \frac{d\mathbf{r}}{dt} \quad (8)$$

行车安全指数 (driving safety index, DSI) 综合考虑了空间和时间维度上对车辆行车风险的影响, 引入权重因子 α , 如式 (9) 所示。

$$DSI_j = DSI(SPE_j, \dot{SPE}_j) = \alpha SPE_j + (1 - \alpha) \dot{SPE}_j \quad (9)$$

考虑到 DSI_j 指标数值的波动范围较大, 且为一个绝对指标, 将其用作预警指标则难以确定阈值。因此, 引入相对驾驶安全系数 (RDSI) 来解决这一问题, 如式 (10) 所示。

$$RDSI_j = \frac{DSI_j}{DSI^*} \quad (10)$$

其中 DSI^* 是特定场景中的标准驾驶安全系数, 其计算依据是基于跟车场景下 1 s 的车头时距 (THW) 和 4 s 的 TTC^[23]。

1.2 模型参数标定及验证

行车风险场模型中, 等效质量 M_i 、道路条件影响因子 R_i 和驾驶人风险因子 DR_c 可由式 (11)~(14) 表示。

$$M_i = \psi(T_i) \cdot m_i \cdot g(v_i) \quad (11)$$

$$R_i = \psi(\delta_i) \cdot \psi(\rho_i, \tau_i) \cdot \varphi(u_i) \quad (12)$$

$$DR_i = \psi(DR_{i_p}) + \psi(DR_{i_c}) + \psi(DR_{i_s}) + \psi(DR_{i_v}) \quad (13)$$

$$g(v_i) = 0.002\ 368v_i^4 - 0.322\ 4v_i^3 + 12.57v_i^2 - 149 \quad (14)$$

在本文中, 考虑到所有车辆并非由人类驾驶人执行, 因此, 驾驶人风险因子 DR_i 在模型中被设定为 0。文献 [20]

对式 (3)~(5)、(11)、(12) 的各个参数进行了标定。其中 $K=0.1$ 、 $k_1=1.5$ 、 $k_2=1$ 和 $k_3=160$ 。在本文场景中, 设定道路为平路, 路面干燥, 能见度大于 200 m, 且所涉及的车辆类型为汽车, 车辆质量均统一为 1 820 kg。由于道路曲率为本文场景的关键环境变量, 其值将依据道路环境的变化进行动态调整。

1.3 模型有效性验证

前车切入是指在主车跟车行驶时, 前方相邻车道的车辆突然变道并进入主车所在的车道, 从而对主车的正常行驶造成一定程度的干扰或阻碍。如图 1 所示, 本文选取切入场景下 4 个关键参数作为场景参数, 具体包括: 切入时刻主车的速度 v 、前车与主车的速度比 v_{rate} 、前车开始切入时与主车的纵向距离 D , 以及表征切入过程的切入时长 T 。




图 1 前车切入场景模型

Fig. 1 Cut-in scene model for preceding vehicle

根据上文提出的行车风险场模型, 并结合道路曲率半径, 选取场景用例绘制风险场图。图 2 和图 3 分别展示了立体视图和俯视图中行车风险场的场强分布。




图 2 行车风险场场强分布立体图

Fig. 2 Three-dimensional distribution of driving risk field intensity

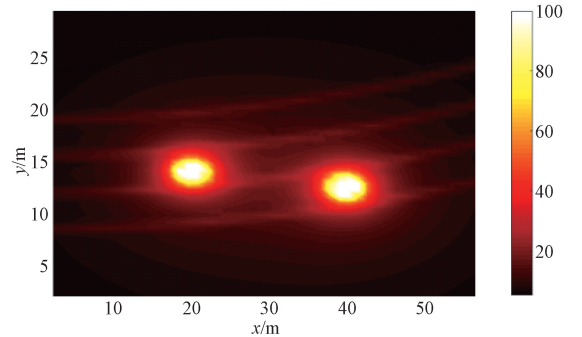


图 3 行车风险场场强分布俯视图

Fig. 3 Top-view distribution of driving risk field intensity

在该场景用例中,车辆的属性、运动状态以及模型的标定参数如表 1 所示。通过观察行车风险场的强度分布图可以发现,车道线和车辆周围均会形成风险场。当车辆偏离车道中心或两车靠近时,行车风险场的总场强增加,表明行车风险也随之增大。

表 1 行车风险场模型参数值

Table 1 Parameter values of the driving risk field model

模型参数/单位	参数值
车道数/条	3
车道宽度/m	3.75
道路曲率半径/m	200
车辆速度/(km·h ⁻¹)	10
车辆质量/kg	1 820
$\psi(T_i)$	1
$\psi(\delta_i)$	1
$\psi(\rho_i, \tau_i)$	1.277
$\varphi(u_i)$	1
DR_i	0

根据上文提出的行车风险场模型,并结合道路曲率半径,选取场景用例绘制风险场图。图 2 和图 3 分别展示了立体视图和俯视图中行车风险场的场强分布。

在该场景用例中,车辆的属性、运动状态以及模型的标定参数如表 1 所示。通过观察行车风险场的强度分布图可以发现,车道线和车辆周围均会形成风险场。当车辆偏离车道中心或两车靠近时,行车风险场的总场强增加,表明行车风险也随之增大。

2 基于遗传算法的高风险场景生成

2.1 算法寻优模块

遗传算法是一种模仿生物进化过程的优化算法,具备全局搜索和启发式迭代的能力。为了有效解决在连续空间中搜索最优解的问题,遗传算法常采用实数编码。鉴于高风险跟车切入场景的参数空间通常是连续且多维的,选择使用实数编码方式^[24]。

在遗传算法的适应度函数设计中,采用了相对驾驶安全系数(RDSI)作为评估指标。

对于选择方法,本文采用了轮盘赌的选择策略,场景的风险度越高,其被选中参与下一次进化迭代的概率越大。

对于交叉方法,本文采用了算术交叉处理,通过父代个体基因值的线性组合来创建新的子代个体。

对于变异方法,本文参照文献[24]的分析,采用了改进的自适应变化的变异算子,在进化的早期阶段,通过应用较大的变异范围来维持种群的多样性,后期则缩小变异范围以提升局部微调能力,有效的加快遗传算法的收敛速度。假设 x 为父代, x_{\max} 和 x_{\min} 分别为各参数取值的最大值和

最小值,则变异后的子代 x' 随机生成于区间 Ω :

$$\Omega = \{x - s(t)(x - x_{\min}), x + s(t)(x_{\max} - x)\} \quad (15)$$

其中,

$$s(t) = 1 - r \left[1 - \frac{t}{T} \right]^c \quad (16)$$

式中: T 为进化的最大迭代数, t 为当前迭代数, c 为参数,取值一般为 $2 \sim 4$, $r \in [0, 1]$ 。可以看出 $s(t)$ 决定了变异空间的大小,在迭代过程早期,变异空间较广;而在迭代过程的后半期,变异空间缩小,算法的局部寻优能力增强。

对于遗传算法所需要的其他参数,在本文中设定种群规模为 20 个个体,迭代次数定为 50 次,交叉概率和变异概率分别定为 0.8 和 0.1。遗传算法的伪代码模块如下:

算法 1: 自适应遗传算法场景生成模块

	种群大小 pop, 迭代次数 Iter, 交叉率 p_c , 变异率 p_m , 道路曲率 K, 主车速度范围 v_range, 两车速度比范围 rate_range, 切入时纵向距离范围 D_range, 换道时间范围 T_range
Input:	最优个体集合 bestIndividual
Output:	初始化 Prescan/Simulink 仿真平台;
1	初始化种群 P;
2	for i to pop do
3	随机生成主车速度 $v_i \in v_range$
4	随机生成两车速度比 $rate_i \in rate_range$
5	随机生成切入时纵向距离 $D_i \in D_range$
6	随机生成换道时间 $T_i \in T_range$
7	调用仿真平台计算个体 i 的适应度
8	FitnessCount(K, v_i , $rate_i$, D_i , T_i)
9	end for
10	for j to Iter do
11	子代种群 OP
12	for k to pop do
13	/* 轮盘赌选择操作 */
14	$p1 \leftarrow Roulette_Wheel_Selection(P)$
15	$p2 \leftarrow Roulette_Wheel_Selection(P)$
16	/* 算术交叉操作 */
17	$OP_k \leftarrow arithmetic_crossover(p1, p2, p_c)$
18	/* 自适应变异操作 */
19	$OP_k \leftarrow adaptive_mutation(OP_k, p_m)$
20	FitnessCount(K, v_k , $rate_k$, D_k , T_k)
21	end for
	/* 更新种群 */
	$P \leftarrow update_population(P, OP)$
	/* 每代最优个体存放 */
	$bestIndividual_j \leftarrow obtain_best(P)$
	end for

2.2 自动化仿真框架

结合上节中的遗传算法伪代码,本文构建的高风险仿真场景自动化生成框架如图 4 所示,首先在 Matlab 中构建遗传算法,基于给定的场景参数空间初始化场景参数,并将这些参数传递给仿真平台启动仿真实验。

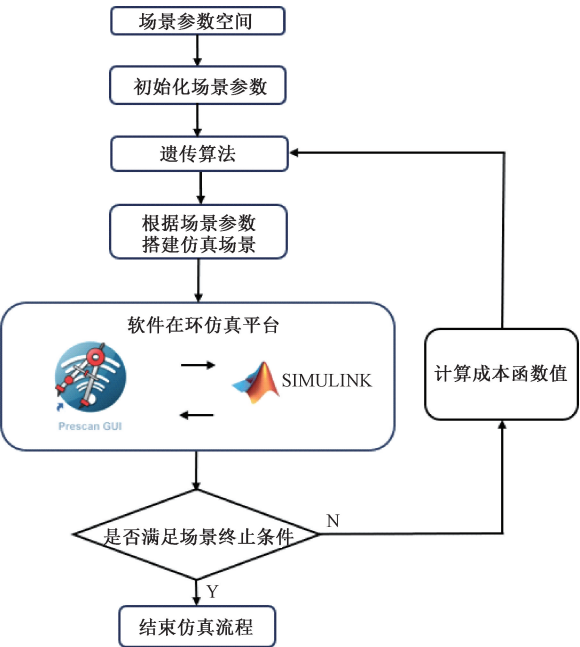


图 4 高风险仿真场景自动化生成框架

Fig. 4 Framework for automated generation of high-risk simulation scenarios

仿真实验是在基于 Prescan 和 Simulink 的软件在环仿真平台上进行的,鉴于本文专注于前车切入这一特定的功能场景,Prescan 根据场景参数搭建仿真环境,包括道路拓扑、车辆属性以及前车切入的具体行驶轨迹等关键要素;Simulink 中为主车搭载了自动紧急制动系统(autonomous emergency braking system,AEBS),用于模拟主车在前车切入情况下的避撞反应,并收集原始的仿真数据。

在每次仿真实验结束后,遗传算法会根据仿真所得的成本函数(即适应度函数)的计算结果进行分析,以产生下一迭代周期所需的优化场景参数。随后,这些更新后的参数再次输入到仿真平台,用于重新构建仿真对象并触发新一轮的仿真实验。此过程不断循环,直至满足预设的终止条件,例如达到规定的最大迭代次数。在仿真流程结束时,将生成一系列具体场景的参数集合。在本文中,发生碰撞的场景被定义为高风险场景,用于后续的风险评估和分析。

2.3 弯道切入场景建模

由于本文聚焦于弯道下的前车切入场景,因此在道路构建中引入了道路曲率,以增加工况的复杂性和真实性。并且在实际驾驶中,驾驶人通常会在进入弯道时主动降低车速,以确保安全通行。因此,在不同曲率半径的路段下,逻辑场景中的主车速度范围也应相应调整。

依据《国家公路设计规范》(JTGD20—2017)的规定,表 2 列出了在不同行驶速度条件下所需的最小道路曲率半径。在车辆转弯时,必须确保道路曲率的实际半径超过该速度对应的最小曲率半径值。

表 2 弯道工况的设计标准

车速/(km·h ⁻¹)	40	60	80	100	120
最小曲率半径/m	100	200	400	700	1 000

综合考虑上文中提到的前车切入场景模型中的场景参数以及道路曲率半径,并参考文献,确定逻辑场景参数范围如表 3 所示,其中 v_{\max} 为对应道路曲率半径下的最大车速。

表 3 逻辑场景参数范围

场景参数/单位	参数范围
车道数/条	3
车道宽度/m	3.75
道路曲率半径/m	{100,200,400,700,1 000}
切入时刻主车速度/(km·h ⁻¹)	$[30, v_{\max}]$
前车与主车的速度比	$[0.55, 0.9]$
前车开始切入时与主车的纵向距离/m	$[5, 35]$
切入时长/s	$[1, 6]$

3 实验验证和分析

3.1 方案设计

基于本文提出的弯道前车切入高风险场景生成方法,并按照 2.2 节中的自动化仿真框架,分别在 5 种不同的曲率半径(100、200、400、700 和 1 000 m)下进行了实验。每次实验的终止条件为 50 次迭代,每代种群规模为 20 个个体,总计生成了 5 000 个测试场景。

由于在行车风险场的模型参数标定过程中,不同道路线形的标定值有所差异。根据中国道路交通安全数据集^[25],道路线形道路线形被划分为 3 种类型:直路、一般弯道和急弯道。因此,在针对上述 5 种不同曲率半径的实验路段进行模型参数标定时,并依据国家公路设计规范 JTG D20—2017,将曲率半径为 100 和 200 m 的实验路段划分为急弯,而曲率半径为 400 和 700 m 的路段则被划分为一般弯。至于曲率半径为 1 000 m 的路段,由于其曲率半径较大,接近直道的特性,因此将其视为直道进行标定。

3.2 风险场景生成结果

5 组不同曲率半径条件下的每轮迭代进化曲线如图 5 所示。通常在弯道行驶条件下,车辆所面临的风险往往比直线路段更高。然而本文考虑了实际行驶中,驾驶人在驶入急弯路段会减速的情况。尽管急弯路段的道路条件影响因子较高,但主车速度的减小也使得行车风险场模型中的

等效质量 M_i 数值减小,从而使得场景风险值也相应降低。相比之下,直线路段虽然具有较低的道路条件影响因子,但车辆行驶速度更快,延长了制动距离,从而使得直线路段的总体风险度仍然较高。




图 5 不同曲率半径下的最大适应度曲线

Fig. 5 Maximum fitness curves under different curvature radii

对各组生成的仿真场景做进一步分析,发现在不同曲率半径的路段下,两车发生碰撞的场景数量存在显著差异,如表 4 所示。这一现象的主要原因在于,在迭代前期,随着曲率半径的减小,逻辑场景中主车速度的范围也相应缩小,较低的车速使得 AEBS 系统的响应效果能够更迅速且有效,碰撞发生的可能性也就越低。然而,随着迭代次数的增加,遗传算法通过其自适应变异算子逐渐缩小了变异搜索的空间范围,使得场景参数逐渐集中于某一特定范围。因此,在迭代后期所生成的场景多为极端风险的碰撞场景。

表 4 不同曲率半径下的两车碰撞次数

Table 4 Number of collisions between two vehicles at different curvature radii

道路曲率半径/m	100	200	400	700	1 000
碰撞次数	753	824	852	901	913

这些碰撞场景主要可以分为两种类型:一种是当前车换道迅速且两车间相对速度较大时,会使得 AEBS 识别和响应的时间窗口极短,从而引发碰撞事故,如图 6 所示;另一种是前车换道过程冗长,换道意图模糊不清,使得 AEBS 系统的触发时刻延迟,最终造成碰撞,如图 7 所示。

3.3 典型用例分析

为了验证 RDSI 指标的合理性并分析不同曲率半径条件下前车切入的风险,从生成的场景中选择了速度范围 30~60 km/h 的工况,并针对 5 种不同曲率半径的道路条件进行了试验分析。在不同工况下,每组用例的场景参数(除主车速度外)均保持一致,唯一的变量是道路的曲率半径,且主车速度上限也随道路曲率半径的不同而相应调整。

试验结果如图 8 所示,系统的响应时刻会随着道路曲率半径的减小而逐渐延迟。并且,随着主车速度的增加,主




图 6 换道时间短两车致碰撞示意图

Fig. 6 Schematic diagram of collision due to short lane-changing time between two vehicles



图 7 换道时间长两车致碰撞示意图

Fig. 7 Schematic diagram of collision due to extended lane-changing duration between two vehicles

车与前车之间的相对速度也随之增大,导致 AEB 系统触发的时刻相应延迟。这是因为在 AEBS 的触发条件中,系统主要基于自车道前方的障碍物检测,如图 9 所示,在前车切入的过程中,只有当前车越过车道线并进入自车道一定距离时,AEBS 才会启动制动。因此,曲率半径的减小和主车速度的增加,使得避撞失败的风险显著提高。




图 8 AEB 触发时刻时的 TTC 对比

Fig. 8 Comparison of TTC at the moment of AEB activation

在 60 km/h 的工况下,4 组用例中仅曲率半径为 200 m 的弯道发生碰撞,而其他用例未发生碰撞,故选用该工况下的用例做 RDSI 指标的分析。由于 TTC 指标常用于自动




图 9 AEB 触发区域

Fig. 9 AEB activation zone


驾驶决策算法的评估,因此采用 TTC 的倒数作为 RDSI 的对比参考指标,记为 $TTCi$,如式(17)所示。

$$TTCi = \frac{1}{TTC} = \frac{v_{rear} - v_{front}}{D} \quad (17)$$


其中, v_{rear} 为后车的速度, v_{front} 为前车的速度, D 为两车之间的相对距离,即前车尾部与后车头部之间的距离。

RDSI* 的计算是基于文献[26]提出的最小纵向安全距离换道模型,将其作为为场景划分的阈值。若 RDSI 值超过预设阈值 RDSI*,则主车的行驶状态被认定为危险;反之,若 RDSI 值低于 RDSI*,则主车的行驶状态被视为安全。

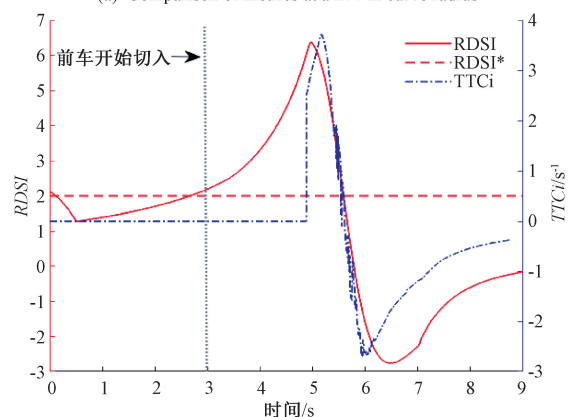
如图 10 所示,通过对比这 4 个场景用例的仿真结果可以看出,在仿真初期,由于 $TTCi$ 仅考虑同车道车辆,其值保持为 0 不变,而 RDSI 则随着两车之间间距的逐渐减小而逐步增加;当前车开始切入时,RDSI 指标迅速上升,而 $TTCi$ 仅在前车切入至自车道一定距离后才开始显著增加,这也导致了 AEBS 系统可能因反应不及时而无法避免碰撞。




(a) 200 m 弯道半径下的指标对比
(a) Comparison of metrics at a 200 m curve radius



(b) 400 m 弯道半径下的指标对比
(b) Comparison of metrics at a 400 m curve radius



(c) 700 m 弯道半径下的指标对比
(c) Comparison of metrics at a 700 m curve radius



(d) 1000 m 弯道半径下的指标对比
(d) Comparison of metrics at a 1000 m curve radius

图 10 60 km/h 工况下不同曲率半径下的 RDSI 与 $TTCi$ 对比Fig. 10 Comparison of RDSI and $TTCi$ at 60 km/h under different curvature radii

并且,随着曲率半径的减小,RDSI 和 $TTCi$ 的最大值增大,表明碰撞风险增加。在图 10(a)中,主车与前车发生了碰撞,具体的碰撞场景如图 11 所示。这是由于在弯道半径小的情况下,前车切入时由于切入角度大,容易出现横向摆动,由于 $TTCi$ 指标对相邻车道的敏感性较

低^[20],无法准确评估主车的行车风险。当发生碰撞时, $TTCi$ 的值已经显著降低接近于 0,而 RDSI 的值虽然也有所下降,但其下降速率较慢,且仍大于危险阈值 RDSI*。这表明在前车切入场景中,RDSI 相比 $TTCi$ 能够更早地识别潜在风险且能准确反映实际的行车风险。



图11 200 m 弯道半径下两车碰撞图

Fig. 11 Collision diagram of two vehicles at a 200 m curve radius

由于本文中主车搭载的 AEBS 系统是基于 TTC 模型,因此在前车切入过程中,如果 RDSI 始终大于设定的安全阈值 $RDSI^*$,则认为 RDSI 指标成功预警了车辆风险;相反,如果车辆能够通过 AEBS 系统的干预成功避免与前车的碰撞,则认为 TTC 指标成功预警了车辆风险^[27]。对 3.2 节中所生成的高风险场景进行统计分析,并去除掉重复场景。分析结果显示,基于 RDSI 指标的预警成功率为 100%,而基于 TTC 指标的预警成功率为 34.4%。由此可见,基于行车风险场模型的自动化场景生成框架在评估和生成不同道路曲率半径下的前车切入风险场景方面表现出了更高的有效性。

4 结 论

本文以典型的前车切入场景为例,引入道路曲率以模拟真实世界的复杂驾驶环境,提出了一种基于行车风险场模型的弯道切入风险场景的自动化生成方法。该方法将软件在环仿真平台与优化算法相结合,将风险场景生成转化为优化搜索问题,并采用 RDSI 作为行车风险评估指标。与传统的基于 TTC 或其他单一指标的方法相比,RDSI 能够更全面地考虑多种场景元素对行车风险的影响,从而更细致地评估主车的风险。通过改进的变异算子,算法能够快速迭代生成不同道路曲率半径下的风险场景。在 Prescan 和 Simulink 中对生成的仿真场景进行测试发现,RDSI 指标的预警成功率相比于 TTC 提升 65.6%,能够更快地识别横向运动物体的潜在风险,验证了其有效性。同时,实验结果还显示,不同道路曲率半径下的碰撞风险存在显著差异。

本文的研究对象主要聚焦于弯道前车切入场景,对于其他类型的交通场景(如多车交互、复杂交叉路口等)的适用性尚未充分验证。在后续研究中,将扩展到更复杂的交通场景,并尝试结合更多场景元素(如天气条件、障碍物、路面附着系数等),以模拟更加真实的驾驶环境。

参考文献

[1] 姬雨初, 闫宗吉. 机坪行车道交叉口特种车辆运行控制策略[J/OL]. 电子测量与仪器学报, 1-10[2025-01-

11]. <http://kns.cnki.net/kcms/detail/11.2488.tn.20250303.1026.006.html>.

JI Y CH, YAN Z J. Special vehicle operation control strategy at the intersection of apron lanes [J/OL]. Journal of Electronic Measurement and Instruments, 1-10 [2025-01-11]. <http://kns.cnki.net/kcms/detail/11.2488.tn.20250303.1026.006.html>.

[2] 杨文慧, 杨宜菩, 杨帆, 等. 基于先验距离约束的 3D 卷积毫米波雷达目标检测方法[J]. 电子测量技术, 2023, 46(23): 85-96.

YANG W H, YANG Y P, YANG F, et al. 3D convolutional millimeter wave radar target detection method based on prior distance constraints [J]. Electronic Measurement Technology, 2023, 46(23): 85-96.

[3] 宋绍京, 陆婷婷, 孙翔, 等. 面向自动驾驶的多任务环境感知算法[J]. 电子测量技术, 2023, 46(24): 157-163.

SONG SH J, LU T T, SUN X, et al. Multi-task environment perception algorithm for autonomous driving [J]. Electronic Measurement Technology, 2023, 46(24): 157-163.

[4] 金宇锋, 陶重彝. 基于 Transformer 的融合信息增强 3D 目标检测算法[J]. 仪器仪表学报, 2023, 44(12): 297-306.

JING Y F, TAO CH B. Fusion information enhanced method based on transformer for 3D object detection[J]. Chinese Journal of Scientific Instrument, 2023, 44(12): 297-306.

[5] 涂新奎, 郑少武, 于善虎, 等. 基于对称形状生成的三维目标检测网络[J]. 仪器仪表学报, 2023, 44(6): 252-263.

XU X K, ZHENG SH W, YU SH H, et al. 3D object detection network based on symmetric shape generation [J]. Chinese Journal of Scientific Instrument, 2023, 44(6): 252-263.

[6] 范宜标, 卢玮, 傅智河. 自动驾驶场景下的鲁棒车辆检测[J]. 电子测量与仪器学报, 2018, 32(12): 60-65.

FAN Y B, LU W, FU ZH H. Robust vehicle detection for automatic driving [J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(12): 60-65.

[7] 张纪友, 李俊, 郭霏霏, 等. 用于几何信息学习的图结构运动分割方法[J]. 电子测量与仪器学报, 2025, 39(2), 123-135.

ZHANG J Y, LI J, GUO F F, et al. Graph structure motion segmentation method for geometric

- information learning [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(2): 123-135.
- [8] HUANG W L, WANG K, LYU Y, et al. Autonomous vehicles testing methods review [C]. 2016 IEEE 19th International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2016: 163-168.
- [9] ZHANG X H, TAO J B, TAN K G, et al. Finding critical scenarios for automated driving systems: A systematic mapping study[J]. IEEE Transactions on Software Engineering, 2022, 49(3): 991-1026.
- [10] 北京智能车联, 中关村智通联盟, 北京市自动驾驶测试管理小组. 北京市自动驾驶车辆道路测试报告[R]. 北京: 北京智能车联, 2023.
Beijing Intelligent Vehicle Association, Zhongguancun Zhitong Alliance, Beijing Autonomous Driving Test Management Group. Beijing autonomous vehicle road test report [R]. Beijing: Beijing Intelligent Vehicle Association, 2023.
- [11] KLÜCK F, ZIMMERMANN M, WOTAWA F, et al. Genetic algorithm-based test parameter optimization for ADAS system testing [C]. 2019 IEEE 19th International Conference on Software Quality, Reliability and Security (QRS). IEEE, 2019: 418-425.
- [12] KLISCHAT M, ALTHOFF M. Generating critical test scenarios for automated vehicles with evolutionary algorithms [C]. 2019 IEEE Intelligent Vehicles Symposium(IV). IEEE, 2019: 2352-2358.
- [13] TUNCALI C E, FAINEKOS G, ITO H, et al. Simulation-based adversarial test generation for autonomous vehicles with machine learning components [C]. 2018 IEEE Intelligent Vehicles Symposium(IV). IEEE, 2018: 1555-1562.
- [14] ZHOU R, LIU Y P, ZHANG K, et al. Genetic algorithm-based challenging scenarios generation for autonomous vehicle testing[J]. IEEE Journal of Radio Frequency Identification, 2022, 6: 928-933.
- [15] 丁浩天, 王国权. 基于风险场景搜索的自动驾驶测试方法[J]. 电子测量技术, 2024, 47(8): 37-44.
DING H T, WANG G Q. Autonomous driving testing approach based on risky scenario search[J]. Electronic Measurement Technology, 2024, 47(8): 37-44.
- [16] WU S Y, WANG H, YU W H, et al. A new SOTIF scenario hierarchy and its critical test case generation based on potential risk assessment[C]. 2021 IEEE 1st International Conference on Digital Twins and Parallel Intelligence(DTPDI). IEEE, 2021: 399-409.
- [17] ZHAO S, DUAN J, WU S, et al. Genetic algorithm-based SOTIF scenario construction for complex traffic flow [J]. Automotive Innovation, 2023, 6(4): 531-546.
- [18] LI Y, LI K Q, ZHENG Y, et al. Threat assessment techniques in intelligent vehicles: a comparative survey[J]. IEEE Intelligent Transportation Systems Magazine, 2020, 13(4): 71-91.
- [19] WANG J Q, WU J, LI Y. The driving safety field based on driver-vehicle-road interactions [J]. IEEE Transactions on Intelligent Transportation Systems, 2015, 16(4): 2203-2214.
- [20] 陈浩, 王红, 李维汉, 等. 基于行车安全场理论的预期功能安全场景风险评估[J]. 汽车工程, 2022, 44(11): 1636-1646.
CHEN H, WANG H, LI W H, et al. Risk assessment of safety of the intended functionality scenes based on driving safety field theory [J]. Automotive Engineering, 2022, 44(11): 1636-1646.
- [21] LI L H, GAN J, JI X K, et al. Dynamic driving risk potential field model under the connected and automated vehicles environment and its application in car-following modeling [J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 23(1): 122-141.
- [22] WU R F, ZHENG X J, XU Y N, et al. Modified driving safety field based on trajectory prediction model for pedestrian-vehicle collision [J]. Sustainability, 2019, 11(22): 6254.
- [23] 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.
- [24] 朱冰, 汤瑞, 赵健, 等. 基于代理遗传优化的智能驾驶系统加速测试方法[J]. 同济大学学报(自然科学版), 2024, 52(4): 501-511.
ZHU B, TANG R, ZHAO J, et al. Accelerated test method of intelligent driving system based on surrogate genetic optimization model[J]. Journal of Tongji University (Natural Science), 2024, 52(4): 501-511.
- [25] 中国公安部交通运输部. 2010—2016 年中华人民共和国道路交通事故统计年报[G]. 北京: 人民交通出版社, 2017.
Transportation Bureau of the Ministry of Public Security of the PRC. 2010—2016 annals of road traffic accidents statistics[G]. Beijing: People's Republic of

China,2017.

[26] 李林恒,甘婧,曲栩,等. 智能网联环境下基于安全势场理论的车辆换道模型[J]. 中国公路学报, 2021, 34(6): 184-195.

LI L H,GAN J,QU X, et al. Lane-changing model based on safety potential field theory under the connected and automated vehicles environment [J]. China Journal of Highway and Transport, 2021, 34(6):184-195.

[27] 薛先斌,谭北海,余荣,等. 基于行车风险场的交通冲突风险预警方法[J]. 电子测量技术, 2024, 47(6): 1-7.

XUE X B, TAN B H, YU R, et al. Traffic conflict risk warning method based on driving risk field[J]. Electronic Measurement Technology, 2024, 47(6): 1-7.

作者简介

张广松(通信作者), 硕士研究生, 主要研究方向为自动驾驶仿真测试、车联网等。
E-mail:gszhang947@126.com

钟武昌, 博士研究生, 主要研究方向为车联网、语义通信。

周召高, 硕士研究生, 主要研究方向为车联网、多模态感知。

余荣, 教授, 博士生导师, 主要研究方向为车联网及边缘计算。