



## 自动驾驶系统逻辑场景全覆盖测试用例生成方法

闵海涛 张志强 范天昕 张培兴 张诚 曲歌

### Full Coverage Test Cases Generating Method for Automated Driving System in Logical Scenario

MIN Hai-Tao, ZHANG Zhi-Qiang, FAN Tian-Xin, ZHANG Pei-Xing, ZHANG Cheng, QU Ge

在线阅读 View online: <https://doi.org/10.16383/j.aas.c250347>

---

## 您可能感兴趣的其他文章

### 面向自动驾驶测试的危险变道场景泛化生成

Generalization Generation of Hazardous Lane-changing Scenarios for Automated Vehicle Testing

自动化学报. 2023, 49(10): 2211–2223 <https://doi.org/10.16383/j.aas.c220772>

### 基于平行测试的认知自动驾驶智能架构研究

An Intelligent Architecture for Cognitive Autonomous Driving Based on Parallel Testing

自动化学报. 2024, 50(2): 356–371 <https://doi.org/10.16383/j.aas.c220820>

### 面向可信自动驾驶策略优化: 一种对抗鲁棒强化学习方法

Toward Trustworthy Policy Optimization for Autonomous Driving: An Adversarial Robust Reinforcement Learning Approach

自动化学报. 2025, 51(11): 2473–2485 <https://doi.org/10.16383/j.aas.c250193>

### 城市固废焚烧智能算法测试与验证模块化半实物平台

Modular Hardware-in-loop Platform of Intelligent Algorithm Testing and Verification for Municipal Solid Waste Incineration

自动化学报. 2024, 50(12): 2432–2461 <https://doi.org/10.16383/j.aas.c230762>

### 二氧化锡传感器对挥发性有机物的动态测试方法研究

Study on Dynamic Testing Method of Volatile Organic Compounds by Tin Dioxide Sensor

自动化学报. 2022, 48(3): 926–934 <https://doi.org/10.16383/j.aas.c190561>

### 基于驾驶员转向模型的共享控制系统

Shared Control System Based on Driver Steering Model

自动化学报. 2022, 48(7): 1664–1677 <https://doi.org/10.16383/j.aas.c190486>

# 自动驾驶系统逻辑场景全覆盖测试用例生成方法

闵海涛<sup>1</sup> 张志强<sup>1,2</sup> 范天昕<sup>1</sup> 张培兴<sup>1</sup> 张诚<sup>2</sup> 曲歌<sup>2</sup>

**摘要** 基于场景的测试方法是验证自动驾驶系统安全性的主流手段,然而逻辑场景使用参数空间的形式对场景进行描述,当被测系统性能存在差异时,第三方检测机构难以使用同样的测试用例在保证测试公平性的同时兼顾测试覆盖率.为此,提出一种基于测试用例代表性的自动驾驶系统逻辑场景全覆盖测试用例生成方法.首先建立自动驾驶系统全覆盖测试用例生成框架;其次提出综合分析自然驾驶概率分布及危险情况的测试用例代表性量化评价方法;最后开发一种基于热驱动层次贪心算法和遗传算法的差异化样本组合空间全覆盖问题优化求解方法,获取测试用例参数组合,实现逻辑场景参数空间全覆盖.使用前车切入场景对提出的方法进行验证.结果表明,提出的方法在逻辑场景参数空间覆盖率(100%)、测试边界拟合误差(0.08)方面均显著优于当前主流的蒙特卡洛方法(覆盖率84.3%、拟合误差0.19)与组合测试方法(覆盖率86.5%、拟合误差0.14),可有效帮助检测机构建设公平、高效的测试场景生成框架.

**关键词** 自动驾驶系统; 测试场景; 全覆盖测试; 测试用例代表性

**引用格式** 闵海涛, 张志强, 范天昕, 张培兴, 张诚, 曲歌. 自动驾驶系统逻辑场景全覆盖测试用例生成方法. 自动化学报, 2026, 52(3): 441-450

**DOI** 10.16383/j.aas.c250347 **CSTR** 32138.14.j.aas.c250347

## Full Coverage Test Cases Generating Method for Automated Driving System in Logical Scenario

MIN Hai-Tao<sup>1</sup> ZHANG Zhi-Qiang<sup>1,2</sup> FAN Tian-Xin<sup>1</sup> ZHANG Pei-Xing<sup>1</sup> ZHANG Cheng<sup>2</sup> QU Ge<sup>2</sup>

**Abstract** The scenario-based testing method is the mainstream means to verify the safety of the automated driving system (ADS). However, the logical scenario uses the form of parameter space to describe the scenario. It is difficult for the third-party detection organizations to use the same test case to ensure the test fairness and test coverage when the performance of the system under test is different. For this reason, this paper proposes a full coverage test cases generating method for ADS in logical scenario based on the test case representativeness. First, a systematic full coverage testing framework tailored for ADS is established. Subsequently, a quantitative evaluation method is introduced to assess the representativeness of test cases by jointly analyzing naturalistic driving probability distributions and hazardous event characteristics. Finally, an optimization calculation method for achieving full coverage of the differentiated sample combination space is developed, based on a heat-driven hierarchical greedy algorithm integrated with a genetic algorithm, enabling the efficient acquisition of representative parameter combinations that achieve full coverage of the logical scenario parameter space. The proposed approach is empirically validated using a lead-vehicle cut-in scenario. The results indicate that the proposed method achieves a logical scenario parameter space coverage rate of 100% and a boundary fitting error of 0.08, both of which significantly outperform current mainstream approaches, including the Monte Carlo method (coverage rate: 84.3%, fitting error: 0.19) and combinatorial testing (coverage rate: 86.5%, fitting error: 0.14). These findings demonstrate the method's potential to effectively support testing organizations in developing a fair and efficient scenario generation framework.

**Keywords** automated driving system; test scenario; full coverage testing; test case representativeness

**Citation** Min Hai-Tao, Zhang Zhi-Qiang, Fan Tian-Xin, Zhang Pei-Xing, Zhang Cheng, Qu Ge. Full coverage test cases generating method for automated driving system in logical scenario. *Acta Automatica Sinica*, 2026, 52(3): 441-450

收稿日期 2025-07-25 录用日期 2025-12-03  
Manuscript received July 25, 2025; accepted December 3, 2025  
国家自然科学基金(52402496),吉林省科技发展计划(20250102122JC)资助  
Supported by National Natural Science Foundation of China (52402496) and Science and Technology Development Plan of Jilin Province (20250102122JC)  
本文责任编辑 许斌  
Recommended by Associate Editor XU Bin  
1. 吉林大学汽车底盘集成与仿生全国重点实验室 长春 130025  
2. 中汽研汽车检验中心(天津)有限公司 天津 300399  
1. State Key Laboratory of Automotive Chassis Integration

基于场景的测试方法已逐渐成为自动驾驶系统性能验证的主流<sup>[1]</sup>,其中逻辑场景使用参数空间对场景特征进行描述,是场景库建设的主体,亦是第三方检测机构定义测试范围的重要参照<sup>[2]</sup>.然而在不同自动驾驶系统进行性能验证的过程中,检测机构需要建立标准化、规范化的测试用例库以完成逻辑

and Bionics, Jilin University, Changchun 130025 2. Automotive Testing Center, China Automotive Engineering Research Institute Co., Ltd., Tianjin 300399

辑场景参数空间的测试<sup>[3]</sup>. 这种测试用例生成过程需要在保证测试公平性的同时兼顾测试覆盖率, 这一要求已经成为第三方测试的重要阻碍.

现有测试用例生成方法可概括为两种: 以发现被测系统性能边界为目标的在线优化方法和以预先生成测试用例库为目标的离线优化方法<sup>[4]</sup>.

在线优化方法通过将被测自动驾驶系统嵌入仿真闭环中, 利用优化搜索、重要性采样等方式加速发现被测系统的性能边界. 例如同济大学提出基于改进优化算法的自动驾驶危险测试场景生成方法<sup>[5]</sup>, Mullins 等<sup>[6]</sup>提出自动驾驶系统逻辑场景危险边界搜索方法, 密歇根大学提出基于重要性采样的自动驾驶系统事故率加速测试方法<sup>[7]</sup>. 这些方法大多以优化算法为核心, 在测试过程中通过概率采样等手段实时生成场景参数, 测试过程存在较大的随机性, 不同自动驾驶系统由于性能的差异且测试过程所采样的测试用例参数存在较大不同<sup>[8]</sup>, 导致测试过程难以满足第三方测试的公平性需求, 同时难以保证测试场景覆盖全部参数空间<sup>[9]</sup>.

离线优化方法不考虑被测自动驾驶系统的性能差异, 以均匀采样或随机采样为核心, 生成相同的测试用例建立测试场景库进而完成测试过程, 可以满足第三方检测机构的公平性需求. 如赵文博<sup>[10]</sup>提出基于组合测试的相机感知系统测试场景生成方法, Duan 等<sup>[11]</sup>提出基于复杂性组合测试的测试用例参数生成方法, Gambi 等<sup>[12]</sup>提出基于蒙特卡洛的测试用例生成方法, Li 等<sup>[13]</sup>提出基于拉丁超立方采样的测试用例生成方法. 这些方法虽然可以保证逻辑场景采样的公平性, 但方法通常需要预定义参数离散步长, 所选步长过大难以覆盖逻辑场景全部参数空间, 而所选步长过小则将生成过多测试用例导致测试过程效率低下<sup>[14]</sup>.

针对现有方法存在的问题, 本文提出一种以场景代表性为核心的自动驾驶系统逻辑场景参数空间全覆盖测试方法. 该方法通过建立量化的测试用例代表性评估模型, 并开发对应的非均匀空间覆盖求解方案, 以少量测试用例实现逻辑场景参数空间的全覆盖, 从而兼顾测试过程公平性与测试效率.

本文首先提出基于场景代表性的自动驾驶系统逻辑场景全覆盖测试框架; 其次建立基于场景危险性和自然驾驶概率的场景代表性量化评价方法; 最后提出一种基于贪心算法的差异化样本组合空间全覆盖问题优化求解方法, 获取可覆盖全参数空间的最少数量测试用例组合. 使用前车制动场景、前车切入场景对本文提出的方法进行了验证. 结果表明, 本文提出的方法在逻辑场景参数空间覆盖率

(100%)、测试边界拟合误差 (0.08) 方面均显著优于当前主流的蒙特卡洛方法 (覆盖率 84.3%、拟合误差 0.19) 与组合测试方法 (覆盖率 86.5%、拟合误差 0.14).

## 1 自动驾驶系统全覆盖测试框架

为了保证被测自动驾驶系统在逻辑场景参数空间中的全覆盖测试, 本文提出如图 1 所示的测试用例生成方法.

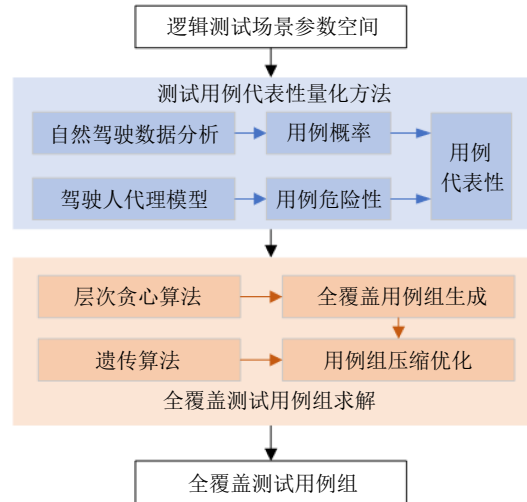


图 1 全覆盖测试用例生成框架

Fig. 1 Full coverage test case generation framework

首先建立基于用例概率和用例危险性的用例代表性量化评价方法, 其中用例概率通过统计自然驾驶过程中不同参数的概率分布进行获取, 用例危险性通过构建驾驶人代理模型进行估算. 其次在得到用例代表性的基础上, 使用热度驱动的层次贪心算法提取可完全覆盖参数空间的测试用例组合, 进而使用遗传算法对冗余测试用例参数进行剔除, 获得规模更小但覆盖完整的测试用例集.

## 2 用例代表性量化方法

逻辑场景参数空间中, 在不考虑被测自动驾驶系统性能差异化的前提下, 测试用例的代表性应由两方面固有属性共同决定: 概率和危险性, 前者指该用例在真实自然驾驶过程中的发生频次, 后者表明该用例在真实驾驶环境中的事故情况. 对于既具有较高风险, 又在自然驾驶数据库中频繁出现的用例, 其测试结果对安全验证至关重要, 难以由邻近用例直接替代, 因此应被赋予更高的关注度与测试密度, 在用例覆盖率计算过程中辐射范围应较小, 用例代表性应较低. 而对于风险较低或出现概率较

小的用例, 在覆盖度计算策略中可通过较大的辐射范围减少冗余采样, 对应的用例代表性应较强。

## 2.1 用例代表性模型

基于上述用例代表性基本概念, 本文提出一种风险-概率联合驱动的用例代表性量化函数, 自适应地确定每个测试用例在参数空间中的辐射范围, 从而为后续的测试点选取与覆盖优化提供合理的空间结构约束。

本文定义的测试用例代表性量化评价如式 (1) 所示。

$$r_i^{(j)} = \beta \cdot \left( \frac{\max \xi}{\xi_i} \right)^\lambda \cdot \left[ \lg \left( \frac{1}{A_i + \varepsilon} + 1 \right) \right]^\delta \cdot \omega_j^{-1} \quad (1)$$

式中,  $r_i^{(j)}$  为第  $i$  个具体场景在参数空间第  $j$  个维度上的辐射范围, 即代表性;  $\xi_i$  为第  $i$  个场景的危险性指数 (详见第 2.3 节);  $A_i$  为第  $i$  个测试用例的用例概率指数 (详见第 2.2 节);  $\lambda$  为危险性缩放指数, 用于控制危险性指数在代表性计算中的权重;  $\delta$  为概率函数的缩放指数, 用于调节场景发生概率对代表性半径的影响程度;  $\varepsilon$  为概率正则化常数, 仅用于防止当  $A_i$  接近零时出现对数发散;  $\beta$  为全局影响范围缩放系数, 用于控制实际计算半径, 使其与特定逻辑参数空间的大小、离散化步长及外部约束 (如测试算力) 保持一致;  $\omega_j$  为第  $j$  个维度的权重系数。其中, 各参数并不存在统一的推荐范围或默认最优值, 其设定应结合目标场景类型、风险分布特征与算力约束进行情境化调整, 以在特定实验条件下获得稳定且具有代表性的覆盖效果。

在式 (1) 中, 由于逻辑场景参数空间通常经过离散化处理, 测试点之间的间距以固定步长划分, 使用连续型或小数形式的影响范围结果可能导致邻近点是否被覆盖存在模糊边界, 降低模型的可操作性与稳定性, 因此限定  $r_i^{(j)}$  的影响范围向下取整数, 确保在实际测试点选择与空间搜索过程中具备可控的结构边界与计算开销。同时, 设定全局影响范围最小值  $r_{\min}$ , 防止因概率过高或风险等级过低导致点状影响区域; 最大值  $r_{\max}$  用于防止边缘场景概率极低导致影响范围无限膨胀。  $(\max \xi / \xi_i)^\lambda$  用于对风险等级参数的归一化, 使高风险用例对影响范围的收缩更加显著, 同时避免因等级设定差异导致的跨逻辑场景影响范围不一致。对于  $\omega_j$  而言, 由于各参数维度对测试结果的影响程度存在显著差异, 这种维度间的异质性在参数空间内表现为不同的风险梯度。因此, 本文在测试点影响范围自适应函数中引入各维度独立的权重系数  $\omega$ , 以调节不同方向上的

扩展能力, 使影响范围能够更准确地匹配各测试用例实际重要性。

需要注意的是, 实际逻辑场景参数体系中包含连续型参数与离散型参数。前者具有数值连续性, 适合通过用例代表性进行全覆盖测试参数分析; 而后者则以枚举方式呈现, 维度之间不存在直接的数值可比性。为此, 提出以离散型参数组合作为分类标签, 将整个逻辑场景参数空间划分为若干子逻辑场景, 在各子场景内部独立进行测试场景的代表性评估与筛选, 而后进行结果的整合, 避免了跨类型变量干扰模型结构。

## 2.2 用例概率指数

对于式 (1) 中的用例概率指数  $A$ , 本文使用高斯分布进行建模。现实交通行为中, 驾驶员对环境变化的响应具有一定的规律性和集中性, 大多数操作及动力学参数往往围绕某一典型值聚集分布, 这种特性使得自然驾驶采集得到的参数样本在统计上符合正态分布假设<sup>[15]</sup>。因此, 本文使用高斯模型可有效刻画测试场景在逻辑参数空间中的概率分布。用例概率指数  $A$  的计算方式如式 (2) 所示。

$$A_i = \frac{1}{(2\pi)^{\frac{g}{2}} |\Sigma|^{\frac{1}{2}}} \exp \left[ -\frac{1}{2} (X - \mu)^T \Sigma^{-1} (X - \mu) \right] \quad (2)$$

式中,  $g$  为参数维度,  $\Sigma$  为用来描述各类型参数相关性的协方差矩阵,  $\mu$  为各参数变量的均值向量,  $X$  为测试用例参数向量。

## 2.3 用例危险性指数

对于式 (1) 的用例危险性指数  $\xi$ , 本文考虑碰撞与非碰撞两种情况进行计算。对于碰撞场景, 本文根据碰撞时刻两车相对速度划分为严重碰撞、一般碰撞和轻微碰撞三类, 其中严重碰撞指碰撞时两车相对速度大于 65 km/h, 一般碰撞为 20 km/h 至 65 km/h, 轻微碰撞为小于 20 km/h<sup>[16]</sup>。对于非碰撞场景, 本文基于碰撞时间 TTC (time to collision) 的倒数进行计算, 如式 (3) 所示。

$$TTC^{-1} = \frac{\Delta v}{\Delta dis} \quad (3)$$

式中,  $\Delta dis$  为前后两车之间的车间距,  $\Delta v$  为两车之间的相对速度。现有研究一般将  $TTC$  小于 1.5 s 视作车辆即将发生碰撞<sup>[17]</sup>, 本文将  $0.7 \text{ s}^{-1}$  作为接近碰撞与安全场景的  $TTC^{-1}$  边界。综合考虑碰撞、非碰撞两种情况, 本文将场景危险指数  $\xi$  定义为 5 类风险等级, 其中严重碰撞为 1.0、一般碰撞为 0.8、轻微碰撞为 0.6、接近碰撞为 0.4、安全场景为 0.2。

对于用例危险性指数而言,其难以通过统计现有数据的方式提取,因此本文提出使用代理模型的方式对未知的场景危险指数进行推断,进而得到不同测试用例的危险指数。

驾驶人代理模型分为纵向和横向两部分,其中纵向代理模型使用长短时记忆网络(long short-term memory, LSTM)进行建模,横向代理模型使用换道势能模型和蒙特卡洛树搜索(Monte Carlo tree search, MCTS)的方式。纵向代理模型使用的数据来源为HighD数据集,其训练模型参数如表1所示,模型训练效果如图2所示。

表1 LSTM模型训练参数  
Table 1 Training parameters of the LSTM model

参数	值
输入特征维度	5
输出特征维度	1
LSTM隐藏层单元	64
LSTM层数	3
学习率	0.001
Dropout	0.1
迭代次数	20
Batch size	8
Attention类型	—

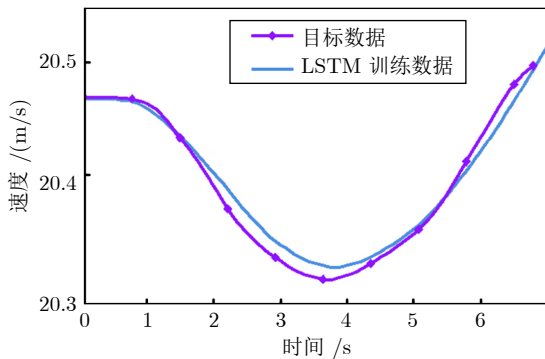


图2 纵向代理模型控制结果

Fig.2 Longitudinal proxy model control results

为了量化纵向代理模型效果与真实车辆运动之间的差异,采用均方根误差作为代理模型精度评价指标,最终结果为0.030,可以满足本文的代理需求。

对于横向代理模型而言,换道势能模型量化驾驶员对当前行驶环境的“满意度”,为换道规划提供了动态意图输入;MCTS通过模拟多种可能的换道路径,探索最优换道策略。

本文定义的换道势能模型综合考虑车辆速度、质量、前车相对信息、道路附着条件,如式(4)所示。本文中定义的产生换道意图的 $U$ 阈值为0.15。

$$U = \frac{I \cdot W \cdot M_i}{r_{ij}^{l_1}} \cdot \exp[l_2 \cdot \Delta v \cdot \cos \theta_{ij}] \quad (4)$$

式中, $I$ 为常数,用于调整势能的量级,本文中取0.001; $M_i$ 为目标车辆的等效质量,本文取5000 kg; $r_{ij}$ 为主车与目标车辆之间的相对距离; $\Delta v$ 为相对速度(主车速度与目标车速度的差值); $\theta_{ij}$ 为主车速度方向与目标车连线方向的夹角; $l_1$ 和 $l_2$ 分别为衰减因子,用于描述距离与速度对势能的指数影响,本文分别取1和0.05。在式(4)中,环境感知权重 $W$ 根据不同行驶环境下的道路附着系数进行调整,在低附着系数条件下,驾驶人会主动减少车辆动态响应,从而减缓势能累积,如式(5)所示。

$$W = \frac{1}{1 + e^{-\rho(o-o_0)}} \quad (5)$$

式中, $\rho$ 为常数,用于调整环境感知权重的影响; $o$ 为路面附着系数; $o_0$ 为路面附着条件基准值,本文设置 $o_0=0.7$ 。

在产生换道意图之后,使用MCTS搜索最优的换道路径。MCTS方法分为如下4个步骤:

1) 选择. 从根节点开始沿着蒙特卡洛树形结构选择一个最优的子节点,选择的目标是最大化决策策略的“价值”。

2) 扩展. 在选择节点阶段,如果选择到尚未完全展开的节点(该节点尚未包含所有可能的子节点),该节点将会进行扩展,并生成新的子节点。

3) 模拟. 模拟阶段从扩展节点开始,进行向下随机模拟,来估算从该节点出发的后续路径的期望回报。

4) 回溯. 在回溯阶段,将模拟结果 $R$ 从叶子节点传回根节点,更新经过树路径上的节点的统计奖励信息。

通过不断模拟不同的换道路径,评估其效果,并通过回溯更新节点价值,最终实现换道轨迹的最优。MCTS的搜索结果示意如图3所示。

### 3 全覆盖测试用例组求解

不同的用例代表性意味着不同测试用例可辐射的范围不同,测试用例生成的核心任务便是在保证逻辑场景参数空间全面覆盖的前提下有效压缩测试用例组合数量,从而提升自动驾驶系统验证的效率与资源利用率。这可转化为差异化样本组合空间全覆盖的优化求解问题。

本文构建了基于热度驱动的层次贪心算法(hierarchical greedy coverage optimization, H-GCO),该算法通过在空间中评估各用例组合的边际覆盖增益,分块执行用例组合的生成,实现逻辑




图3 MCTS 搜索结果示意图

Fig.3 Schematic diagram of MCTS search results

场景参数空间的全覆盖. 在此基础上, 进一步引入基于遗传算法的压缩优化策略, 在参数空间全覆盖的前提下尽可能减少用例数量.

### 3.1 全覆盖测试用例组生成

贪心算法是一种通过局部最优驱动整体优化的启发式方法. 在每一步迭代中, 算法从当前候选解中选择能带来“最大边际收益”的元素加入解集, 以此逐步构建出近似最优的全局解. 基于此, 本文提出一种基于热度的层次贪心算法, 以生成可以全面覆盖逻辑场景参数空间的测试用例组合, 整体流程如图4所示. 步骤一, 通过均匀分割的方式将整个逻辑场景参数空间依据参数维度的离散步长划分为多个子区域, 在每个局部空间内独立运行贪心搜索实现并行化计算加速; 步骤二, 对于每个单独的子区域, 通过预设驾驶人能力边界计算不同测试用例

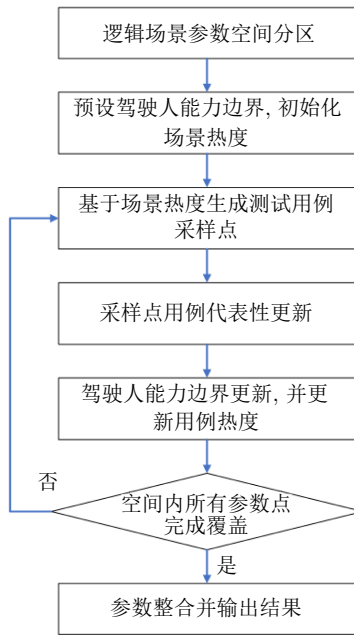


图4 全覆盖测试用例组生成流程

Fig.4 Full coverage test case group generation process

参数的用例热度; 步骤三, 计算不同测试用例参数固定半径内的用例热度和, 并将其最大结果中心位置的测试用例作为当前的采样点; 步骤四, 使用代理模型获取该采样点真实用例代表性; 步骤五, 基于测试结果对预设的驾驶人能力边界进行更新, 进而对参数空间中不同测试用例的热度进行更新; 步骤六, 循环步骤三至步骤五, 直至将参数空间全面覆盖; 最后将步骤一中的参数分区进行全局整合, 输出全覆盖测试用例组合.

为了便于参数空间覆盖度计算、减少覆盖度计算时的算力消耗, 本文首先将逻辑场景参数空间经过离散处理, 生成  $n$  维测试用例参数组合的集合, 如式(6)所示.

$$G = \{x \in \mathbf{Z}^n \mid x \in \Omega \subset \mathbf{R}^n\} \quad (6)$$

式中  $x$  表示参数空间离散后的位置格点. 当  $x$  成为场景测试点时, 可通过用例代表性模型获取其辐射半径  $r_i \in \mathbf{Z}_+^n$ , 其中  $r_i = [r_i^{(1)}, r_i^{(2)}, \dots, r_i^{(n)}]$ , 表示其在每个维度上可覆盖的距离.

为了引导贪心算法在参数空间内对于测试用例组合的生成过程, 本文引入了用例热度的概念. 用例热度指该测试用例距离真实驾驶人能力边界的距离, 由于常规测试的目的在于发现被测系统的性能边界, 因此本文定义的贪心算法优先生成用例热度高的区域位置参数. 用例热度  $h$  的计算过程如式(7)所示.

$$h_0(x_i) = \exp(-\alpha \cdot \text{dist}(x_i, \Psi_0)) \quad (7)$$

$$\text{dist}(x_i, \Psi_0) = \sqrt{(x_1 - x'_1)^2 + \dots + (x_n - x'_n)^2} \quad (8)$$

式中,  $x_i$  为参数空间中未被覆盖的参数点;  $\Psi_0$  为根据专家经验或实验数据预先定义的真实驾驶人能力边界;  $x'_i$  为  $x_i$  上距离  $x_i$  最近的参数点;  $\alpha$  为控制边界邻域热度衰减速度的正数, 通过改变其数值增强或削弱对边界位置的区分度, 本文取  $\alpha = 1$ .

H-GCO 算法的目标是使得所有位置格点均被至少一个测试用例所覆盖, 具体表示如式(9)所示.

$$N(x, r_i) = \left\{ y \in G \mid \forall j \in [1, n], |x_j - y_j| \leq r_i^{(j)} \right\} \quad (9)$$

式中,  $N(x, r_i)$  为以点  $x$  为中心、辐射半径为  $r_i$  的离散邻域集合;  $y$  为参数空间内待覆盖的位置格点, 若  $y$  在所有维度上与  $x$  的距离均不超过对应的半径阈值, 则认为该点已被测试用例  $x$  所覆盖, 所有的位置格点  $y$  共同构成了  $x$  的邻域  $N$ .

在每轮贪心算法的参数组合选取中, 基于当前的热度数值  $h_k(x_i)$ , 对全部未被覆盖的候选测试用

例参数计算其周围的热度和, 如式 (10) 所示. 具体的几何示意如图 5 所示.

$$\hat{s}(x_i) = \sum_{y \in N(x_i, r_i^{\text{est}})} h_k(y) \cdot (1 - c(y)) \quad (10)$$

式中,  $r^{\text{est}}$  为计算热度和的范围, 本文取  $r^{\text{est}} = 5$ ;  $k$  为贪心算法轮次;  $c(y) \in \{0, 1\}$  为覆盖指示函数, 将参数空间中已被覆盖的点赋值为 1. 算法选择增益最大的点作为本轮场景生成点, 如式 (11) 所示.

$$x^* = \arg \max \hat{s}(x_i) \quad (11)$$

完成参数组合选择后, 以  $x^*$  创建测试用例并通过代理模型获取用例风险结果, 同时结合对应点位的概率密度参数得到该测试点真实用例代表性  $r^*$ , 并据此更新其真实覆盖范围内的参数点覆盖指示器状态, 即令  $c^*(y) = 1$ .

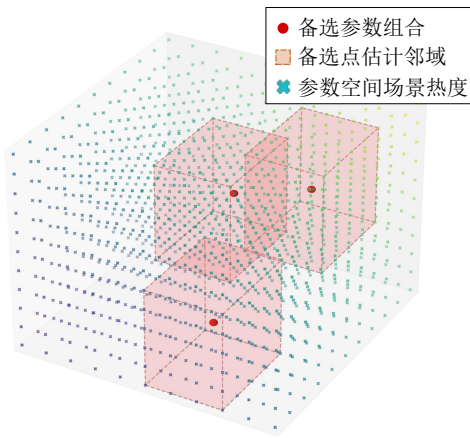


图 5 候选点估计边际增益几何示意图

Fig. 5 Geometric illustration of marginal gain estimation for candidate points

随着贪心搜索迭代和代理模型测试的进行, 可以得到当前参数组合下驾驶人模型真实的碰撞结果. 然而作为数据先验的能力边界也逐渐无法精确描述场景的碰撞不确定性, 因此需要结合少量已知测试点的真实风险参数, 对边界函数进行精细化调整. 本文提出一种结构函数驱动边界修正方法, 通过在原始边界基础上构造连续的结构函数, 结合迭代中新获取的测试点及其真实风险参数, 对先验边界函数进行局部差异判断并实时更新.

首先, 基于初始先验碰撞-安全边界构建符号化距离函数, 如式 (12) 所示.

$$d(x) = \begin{cases} + \min_{z \in \Psi} \|x - z\|, & x \in \text{安全区域} \\ - \min_{z \in \Psi} \|x - z\|, & x \in \text{碰撞区域} \end{cases} \quad (12)$$

式中,  $z$  为能力边界上的采样点.

以距离函数为基础, 建立结构函数, 如式 (13) 所示.

$$B(x) = (1 + \exp(-\sigma \cdot d(x)))^{-1} \quad (13)$$

式中,  $\sigma$  为平滑调节系数, 控制结构函数在边界附近的变化程度, 本文取  $\sigma = 1$ . 当  $d(x) = 0$  即参数点位于碰撞-安全边界上时, 结构函数  $B(x) = 0.5$  为边界函数的表征; 当参数点逐渐远离边界时, 结构函数  $B(x)$  分别平滑地趋近于高风险和安全场景参数表征.

构建风险-结构映射函数  $R(\xi)$ , 用于将观测到的真实场景危险指数  $\xi$  映射为结构空间中的期望值, 如式 (14) 所示.

$$R(\xi) = \exp(-\tau(1 - \xi)) \quad (14)$$

式中,  $\tau$  为控制风险等级, 映射非线性程度的正数.

在第  $k+1$  次贪心算法迭代中, 参数点  $x_{k+1}$  的结构误差如式 (15) 所示.

$$\Delta_{k+1} = B_k(x_{k+1}) - R(\xi_{k+1}) \quad (15)$$

式中,  $B_k(x_{k+1})$  为当前结构函数对该参数点的结构值判断;  $R(\xi_{k+1})$  为真实场景危险指数所期望的结构值;  $\Delta_{k+1}$  正值表示结构值偏高, 负值表示结构值偏低.

为了使结构函数在空间中局部修正, 引入以  $x_{k+1}$  为中心的高斯核函数:

$$K(x, x_{k+1}) = \exp(-\gamma \cdot \|x - x_{k+1}\|^2) \quad (16)$$

式中,  $\gamma$  为表示带宽的正数, 控制影响范围, 本文取  $\gamma = 1$ ;  $K(x, x_{k+1})$  表示能力边界上的点  $x$  受到测试点  $x_{k+1}$  修正影响的强度.

据此, 结构函数修正表达式为:

$$B_{k+1}(x) = B_k(x) - \lambda_1 \cdot \Delta_{k+1} \cdot K(x, x_{k+1}) \quad (17)$$

式中,  $\lambda_1$  为修正步长参数, 控制每轮迭代的调整幅度, 本文取  $\lambda_1 = 0.5$ .

边界的更新则体现在结构函数的等值面随之改变, 即边界函数通过结构函数的更新得到修正, 具体如式 (18) 所示.

$$\Psi_{k+1} = \{x \in \mathbf{R}^n \mid B_{k+1}(x) = 0.5\} \quad (18)$$

由此可以计算各未被覆盖参数点的用例热度, 完成贪心搜索的新一轮迭代, 直至逻辑场景参数空间内全部参数点均被覆盖.

### 3.2 测试用例组合压缩优化

本文通过热度驱动的层次贪心算法实现了覆盖逻辑场景参数空间的初始测试用例组合的生成, 其虽然能够满足空间内所有区域全部被有效覆盖的约

束,但由于贪心策略本质上为局部最优选择,所得到的测试点集通常存在一定的冗余.为进一步减少测试成本、优化点集配置,在不破坏覆盖性的前提下,有必要对点集进行压缩.本文引入遗传算法对冗余测试点进行剔除,获得规模更小但覆盖完整的测试方案.

遗传算法的基本思想源于自然选择与遗传机制,其通过个体间的“选择-交叉-变异”操作演化出更优解.首先,以层次贪心算法获取的全部场景参数组合作为初始化输入,如式(19)所示:

$$Q_0 = \{q_1, q_2, \dots, q_m\}, \quad q_i \in \mathbf{R}^n \quad (19)$$

式中,  $m$  为初始测试用例组合的数量.

令染色体表示为:

$$c = (c_1, c_2, \dots, c_m), \quad c_i \in \{0, 1\} \quad (20)$$

式中,  $c$  表示某一可行的测试点子集配置,若  $c_i = 1$  则保留对应测试点  $q_i$ ,若  $c_i = 0$  则去除对应测试点,初始种群由在  $Q_0$  中随机去除部分点生成.

遗传算法的优化目标为尽可能减少保留点数,具体的目标函数如式(21)所示.

$$\min f(c) = \sum_{i=1}^m c_i \quad (21)$$

式中,适应度函数  $f(c)$  即为个体的“基因长度”,表示实际保留的测试点数量.为了保证所有参数空间点均被覆盖,需引入可行性约束,要求在测试场景的完整参数空间经过离散处理后生成的集合  $G$  中,任一参数点  $x_j$  至少被某一保留测试点  $q_i$  所覆盖.具体约束表达为:

$$\forall x_j \in G, \exists i : c_i = 1, \|q_i - x_j\| \leq r_i \quad (22)$$

若某个染色体不满足上述覆盖性约束,将其直接剔除.

首先,根据当前种群中每个个体的适应度值,通过轮盘赌方式进行个体选择.个体适应度越低(提取参数组合点数越少),被选中作为父代的概率越高.随后按照预设的交叉概率  $p_c$  (本文取  $p_c = 0.6$ ),在已选父代之间进行单点交叉操作.对两个父代染色体  $c^{(1)}$ 、 $c^{(2)}$ ,在随机位置  $k \in \{1, \dots, m-1\}$  处执行基因片段交换,生成两个子代,如式(23)~(24)所示.

$$c'^{(1)} = (c_1^{(1)}, \dots, c_k^{(1)}, c_{k+1}^{(2)}, \dots, c_m^{(2)}) \quad (23)$$

$$c'^{(2)} = (c_1^{(2)}, \dots, c_k^{(2)}, c_{k+1}^{(1)}, \dots, c_m^{(1)}) \quad (24)$$

交叉后的子代进一步接受变异操作.设变异概率为  $p_m$  (本文取  $p_m = 0.01$ ),对每个位点  $c_i$  按式(25)的规则独立变异:

$$c'_i = \begin{cases} 1 - c_i, & \text{以概率 } p_m \\ c_i, & \text{以概率 } 1 - p_m \end{cases} \quad (25)$$

由于交叉与变异可能破坏覆盖完整性,因此随后对新个体进行可行性检测,并在不满足全空间覆盖约束的情况下执行修复.修复策略基于贪心回补原则:从未被覆盖的网格点中选取所需最少的原始点补入,使其能够满足可行性约束.

最终,在每代种群中保留当前适应度最优的个体,以保证解的单调改进过程.算法在达到最大迭代次数或最优解长期不变时终止,输出当前最优染色体对应的压缩优化点集  $c^*$  作为最终测试参数组合的提取集合.

## 4 实验验证

本文从 HighD 公开数据集提取晴天条件下单向三车道前车切入场景作为本文提出方法的测试实例,测试场景如图6所示.前车切入逻辑场景参数类型及参数空间分别为初始相对速度  $\Delta v \in [-10, 20]$  m/s、初始相对距离  $\Delta d \in [10, 100]$  m、切入稳定时间  $\Delta t \in [2, 5]$  s.




图6 切入测试场景示意图

Fig.6 Cut-in test scenario diagram

根据 HighD 自然驾驶数据中的统计结果,预设两种场景参数空间中的驾驶人能力边界.场景参数空间内各场景点位的概率分布根据式(2)近似获取.

### 4.1 测试场景覆盖率验证

在场景生成前,首先将逻辑场景参数空间进行网格化离散处理.对于前车切入场景,主车与前车之间的初始相对速度、初始相对距离和切入稳定时间分别按 2 m/s、2 m 和 0.2 s 的步长划分,最终获得总计 11776 个需要覆盖的测试用例参数.

采用本文提出的压缩优化提取方法对参数空间中的测试用例进行选择提取.前车切入场景中,相对速度、相对距离和切入稳定时间的权重系数分别取值 0.4、0.3 和 0.3.测试用例生成参数(红色点)及邻域覆盖结果(蓝色)如图7所示.




图 7 前车切入场景参数提取结果  
Fig.7 Parameter extraction results for lead vehicle cut-in scenario

对于前车切入场景而言, 本文方法提取的测试场景数量为 482 个, 相比全空间遍历测试 (11 776 个) 节省超过 96% 的测试成本. 从图 7 还可以发现, 本文方法提取的测试场景邻域集合可将参数空间全部测试用例包含在内, 有效实现逻辑场景参数空间的全覆盖.

为进一步验证本文所提出方法在测试效率与测试全面性方面的优势, 本文选取了当前第三方检测机构常用的测试场景生成方法: 蒙特卡洛方法、组合测试方法, 在相同逻辑场景参数空间中开展对比实验. 蒙特卡洛方法是一种基于概率统计与随机抽样原理的数值方法, 在自动驾驶测试中常用于大规模测试场景的快速生成与分布特征估计; 组合测试方法则基于交互覆盖原理, 通过系统地选取变量组合, 以尽可能少的测试样本覆盖参数之间的交互关系, 常用于构建具有代表性的测试场景子集.

使用前车切入场景进行对比实验. 为确保实验的公平性与一致性, 蒙特卡洛方法和组合测试方法均提取测试场景 482 个, 并采用与本文相同的场景邻域覆盖表征方法, 对测试结果进行客观评估. 两种方法提取的测试用例参数及覆盖情况如图 8、图 9 所示. 三种测试用例生成方法生成的场景覆盖结果如表 2 所示.

在生成的测试用例数量 (482 个) 及需要覆盖的测试用例总数 (11 776 个) 相同的前提下, 蒙特卡洛方法生成的场景邻域共可覆盖测试用例 9 926 个, 覆盖率为 84.3%; 组合测试方法生成的场景邻域共可覆盖测试用例 10 185 个, 覆盖率为 86.5%, 两者均无法实现参数空间的全面覆盖.

#### 4.2 性能边界拟合效果验证

以前车切入场景为例, 从图 7 至图 9 可以直观




图 8 蒙特卡洛方法用例生成结果  
Fig.8 Case generation results using Monte Carlo method




图 9 组合测试方法用例生成结果  
Fig.9 Case generation results of combination testing method

表 2 不同方法的覆盖率对比  
Table 2 Coverage rate comparison of different methods

用例生成方法	用例数量 (个)	参数空间覆盖率 (%)
本文方法	482	100.0
蒙特卡洛方法	482	84.3
组合测试方法	482	86.5

观察到, 本文生成的用例在参数空间中呈现高风险区域的聚集性 (初始相对距离与初始相对速度较小的区域), 符合高频率测试、高风险用例的普遍测试原则; 而蒙特卡洛方法和组合测试方法所生成的测试用例在参数空间中的分布呈现出显著的均匀分布特征, 难以与用例重要性分布相一致. 这种差异将导致均匀采样方法在被测自动驾驶系统性能拟合过程中存在不足.

为了量化这种场景有效性差异, 本文搭建了基于 Python、PreScan 以及 CarSim 的联合仿真平台, 通过被测自动驾驶系统真实性能边界 (遍历测试获取) 与三种方法场景拟合获取的边界间的均方根误差 (各维度归一化处理)<sup>[18]</sup>, 量化衡量三种方法生成场景在获取自动驾驶系统性能边界方面的有效性. 被测自动驾驶系统真实边界与三种方法离散场景拟合得到的性能边界如图 10 所示, 三种方法对应的均方根误差如表 3 所示.




图 10 前车切入场景性能边界拟合结果

Fig. 10 Performance boundary fitting results for lead vehicle cut-in scenario

表 3 不同方法性能边界拟合均方根误差

Table 3 Root mean square error of performance boundary fitting for different methods

测试用例生成方法	均方根误差
本文方法	0.08
蒙特卡洛方法	0.19
组合测试方法	0.14

从上述数据可以发现, 由于本文的用例生成方法在高危险区域生成了更多数量的测试用例, 距自动驾驶性能边界较近的参数点更多, 因此拟合得到的自动驾驶系统性能边界更精确, 相比蒙特卡洛方法和组合测试方法, 拟合得到的性能边界均方根误差分别降低了 0.11 和 0.06.

## 5 结束语

针对现有逻辑场景参数空间采样过程测试覆盖率低、测试公平性差的难题, 本文提出一种基于用例代表性的自动驾驶系统逻辑场景参数空间全覆盖测试用例生成方法. 其通过用例代表性量化评价、

差异化样本组合空间全覆盖问题优化求解, 实现了少量测试用例对逻辑场景参数空间的全面覆盖. 使用前车切入场景对本文提出的方法进行对比实验, 验证了本文方法在测试场景生成覆盖率、测试效率、性能边界拟合精度方面的优势. 通过生成统一规范的测试用例库, 可以保证测试过程的公平性, 对第三方检测机构建立标准化测试场景具有重要的工程意义. 本文方法在理论上不依赖特定维度, 可通过要素权重调整与参数分区扩展至多车交互等高维场景, 但当前研究主要面向逻辑场景, 未涉及长时序连续交互场景. 未来将针对连续测试场景生成问题进一步拓展本文提出的场景代表性建模与全覆盖方法架构.

## 参考文献

- Zhao Xiang-Mo, Zhao Yu-Yu, Jing Shou-Cai, Hui Fei, Liu Jian-Bei. Generalization generation of hazardous lane-changing scenarios for automated vehicle testing. *Acta Automatica Sinica*, 2023, **49**(10): 2211–2223 (赵祥模, 赵玉钰, 景首才, 惠飞, 刘建蓓. 面向自动驾驶测试的危险变道场景泛化生成. *自动化学报*, 2023, **49**(10): 2211–2223)
- Wang Xiao, Zhang Xiang-Yu, Zhou Rui, Tian Yong-Lin, Wang Jian-Gong, Chen Long, et al. An intelligent architecture for cognitive autonomous driving based on parallel testing. *Acta Automatica Sinica*, 2024, **50**(2): 356–371 (王晓, 张翔宇, 周锐, 田永林, 王建功, 陈龙, 等. 基于平行测试的认知自动驾驶智能架构研究. *自动化学报*, 2024, **50**(2): 356–371)
- Lin Yue-Tong, Wang Fei-Yue, Xiao Jing, Wang Zhi-Xue. Design and implementation of a neuro-fuzzy based control system intelligent vehicles. *Acta Automatica Sinica*, 2001, **27**(4): 531–542 (林粤彤, 王飞跃, 肖靖, 王知学. 基于模糊神经网络的智能车辆个性自动驾驶系统的设计与实现. *自动化学报*, 2001, **27**(4): 531–542)
- Riedmaier S, Ponn T, Ludwig D, Schick B, Diermeyer F. Survey on scenario-based safety assessment of automated vehicles. *IEEE Access*, 2020, **8**: 87456–87477
- Xing Xing-Yu, Wu Xu-Yang, Liu Li-Hao, Chen Jun-Yi, Yu Zhuo-Ping. Automatic testing method based on optimization algorithms for the decision and planning system of autonomous vehicles. *Journal of Tongji University (Natural Science)*, 2021, **49**(8): 1162–1169 (邢星宇, 吴旭阳, 刘力豪, 陈君毅, 余卓平. 基于目标优化的自动驾驶决策规划系统自动化测试方法. *同济大学学报 (自然科学版)*, 2021, **49**(8): 1162–1169)
- Mullins G, Stankiewicz P, Gupta S. Automated generation of diverse and challenging scenarios for test and evaluation of autonomous vehicles. In: *Proceedings of the IEEE International Conference on Robotics and Automation (ICRA)*. New York, USA: IEEE, 2017. 1443–1450
- Zhao D, Huang X, Peng H, Lam H, LeBlanc D J. Accelerated evaluation of automated vehicles in car-following maneuvers. *IEEE Transactions on Intelligent Transportation Systems*, 2018, **19**(3): 733–744
- Liu H, Zhang L, Sastry S K, Zhao J. Safety-critical scenario generation via reinforcement learning based editing. In: *Proceedings of the IEEE International Conference on Robotics and Automation*. New York, USA: IEEE, 2024. 14405–14412
- Cai J, Yang S, Guang H. A review on scenario generation for testing autonomous vehicles. In: *Proceedings of the IEEE Intelligent Vehicles Symposium*. Jeju Island, South Korea: IEEE, 2024. 3371–3376
- Zhao Wen-Bo. Research on Camera-in-the-loop Test Method for

Pedestrian Collision Avoidance System of Intelligent Vehicle [Master thesis], Jilin University, China, 2021.

(赵文博. 智能汽车行人碰撞系统相机在环测试方法研究 [硕士学位论文], 吉林大学, 中国, 2021.)

- 11 Duan J, Gao F, He Y. Test scenario generation and optimization technology for intelligent driving systems. *IEEE Intelligent Transportation Systems Magazine*, 2022, 14(1): 115–127
- 12 Gambi A, Mueller M, Fraser G. Automatically testing self-driving cars with search-based procedural content generation. In: Proceedings of the 28th ACM SIGSOFT International Symposium on Software Testing and Analysis. Beijing, China: Association for Computing Machinery, 2019. 318–328
- 13 Li S, Li W, Li P H, Ma P, Yang M. Novel test scenario generation technology for performance evaluation of automated vehicle. *International Journal of Automotive Technology*, 2023, 24(6): 1691–1694
- 14 Zhu B, Zhang P X, Zhao J, Deng W W. Hazardous scenario enhanced generation for automated vehicle testing based on optimization searching method. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(7): 7321–7331
- 15 Liu R, Zhao X, Zhu X C, Ma J. Statistical characteristics of driver acceleration behaviour and its probability model. *Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering*, 2022, 236: 395–406
- 16 Zhu Bing, Fan Tian-Xin, Zhao Jian, Zhang Pei-Xing, Sun Yu-Hang. Accelerated test method of automated driving system based on hazardous boundary search. *Journal of Jilin University (Engineering and Technology Edition)*, 2023, 53(3): 704–712  
(朱冰, 范天昕, 赵健, 张培兴, 孙宇航. 基于危险边界搜索的自动驾驶系统加速测试方法. 吉林大学学报(工学版), 2023, 53(3): 704–712)
- 17 Quante L, Zhang M, Preuk K, Schiebl C. Human performance in critical scenarios as a benchmark for highly automated vehicles. *Automotive Innovation*, 2021, 4(3): 274–283
- 18 Sun J, Zhou H J, Xi H C, Zhang H, Tian Y. Adaptive design of experiments for safety evaluation of automated vehicles. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(9): 14497–14508



**闵海涛** 吉林大学汽车底盘集成与仿生全国重点实验室教授。主要研究方向为数据驱动的智能新能源汽车测试技术。

E-mail: [minht@jlu.edu.cn](mailto:minht@jlu.edu.cn)

(**MIN Hai-Tao** Professor at the State Key Laboratory of Automotive Chassis Integration and Bionics, Jilin University.

His main research interest is data-driven testing technology for intelligent new energy vehicles.)



**张志强** 吉林大学汽车底盘集成与仿生全国重点实验室博士研究生。主要研究方向为基于场景的自动驾驶汽车加速测试与多维评价技术。

E-mail: [zhangzhiqiang@catarc.ac.cn](mailto:zhangzhiqiang@catarc.ac.cn)

(**ZHANG Zhi-Qiang** Ph.D. candidate at the State Key Laboratory of Automotive Chassis Integration and Bionics, Jilin University. His research interests include scenario-based

acceleration test and multi-dimensional evaluation technology of autonomous vehicle.)

acceleration test and multi-dimensional evaluation technology of autonomous vehicle.)



**范天昕** 吉林大学汽车底盘集成与仿生全国重点实验室博士研究生。主要研究方向为数字-物理融合建模的自动驾驶汽车多平台联动加速测试技术。

E-mail: [fantx19@mails.jlu.edu.cn](mailto:fantx19@mails.jlu.edu.cn)

(**FAN Tian-Xin** Ph.D. candidate at the State Key Laboratory of Automotive Chassis Integration and Bionics, Jilin University. Her main research interest is digital-physical fusion modeling of autonomous vehicle multi-platform linkage acceleration test technology.)

Her main research interest is digital-physical fusion modeling of autonomous vehicle multi-platform linkage acceleration test technology.)



**张培兴** 吉林大学汽车底盘集成与仿生全国重点实验室副教授。主要研究方向为基于场景的自动驾驶汽车虚拟仿真加速测试与评价方法。本文通信作者。

E-mail: [zhangpeixing@jlu.edu.cn](mailto:zhangpeixing@jlu.edu.cn)

(**ZHANG Pei-Xing** Associate professor at the State Key Laboratory of Automotive Chassis Integration and Bionics, Jilin University. His main research interest is scenario-based virtual simulation acceleration test and evaluation method for autonomous vehicles. Corresponding author of this paper.)

His main research interest is scenario-based virtual simulation acceleration test and evaluation method for autonomous vehicles. Corresponding author of this paper.)



**张诚** 中汽研汽车检验中心(天津)有限公司高级工程师。主要研究方向为基于场景的自动驾驶汽车加速测试评价技术。

E-mail: [zhangcheng@catarc.ac.cn](mailto:zhangcheng@catarc.ac.cn)

(**ZHANG Cheng** Senior engineer at Automotive Testing Center, China Automotive Engineering Research Institute Co., Ltd. His main research interest is scenario-based acceleration test and evaluation technology for autonomous vehicles.)

His main research interest is scenario-based acceleration test and evaluation technology for autonomous vehicles.)



**曲歌** 中汽研汽车检验中心(天津)有限公司工程师。主要研究方向为基于场景的自动驾驶汽车加速测试评价技术。

E-mail: [quge@catarc.ac.cn](mailto:quge@catarc.ac.cn)

(**QU Ge** Engineer at Automotive Testing Center, China Automotive Engineering Research Institute Co., Ltd. Her main research interest is scenario-based acceleration test and evaluation technology for autonomous vehicles.)

Her main research interest is scenario-based acceleration test and evaluation technology for autonomous vehicles.)