

面向自动驾驶系统的场景建模及边缘关键场景生成*

杜德慧^{1,2,3}, 叶振^{1,2,3}, 郑成行^{1,2,3}, 朱珍珍^{1,2,3}, 李家蕴^{1,2,3}



¹(华东师范大学 软件工程学院, 上海 200062)

²(上海市高可信重点实验室 (华东师范大学), 上海 200062)

³(教育部可信软件国际合作联合实验室 (华东师范大学), 上海 200062)

通信作者: 杜德慧, E-mail: dhdu@sei.ecnu.edu.cn

摘要: 自动驾驶中极端的场景、无法预测的人类行为等长尾问题逐渐成为制约自动驾驶系统 (autonomous driving system, ADS) 发展的关键要素, 因此有效地生成安全关键场景对于提高自动驾驶系统的安全性至关重要. 现有的自动驾驶场景生成主要依赖于大量的路采数据, 采用数据驱动式场景生成方法, 并结合场景泛化技术生成相应的驾驶场景. 该方法耗时耗力, 成本高, 而且难以有效生成边缘场景. 而模型驱动式场景建模方法通过构建逻辑场景模型, 能够建模复杂的场景特征并有效生成安全关键场景. 其面临的挑战性问题是如何设计一种基于领域知识的可视化场景建模语言, 支持抽象建模复杂驾驶场景, 并进一步有效地挖掘安全攸关的边缘关键场景. 针对以上问题, 提出一种基于 SML4ADS2.0 的自动驾驶场景建模及边缘关键场景生成方法. 该方法基于 ADS 领域本体建模场景, 并结合形式化量化评估与重要性采样实现边缘关键场景生成. 首先, 提出基于 SML4ADS2.0 模型驱动式场景建模方法, 设计一种基于 ADS 领域本体的自动驾驶场景建模语言 (scenario modeling language for autonomous driving system, SML4ADS2.0), 以构建自动驾驶场景模型; 其次, 通过模型转换规则实现场景模型到随机混成自动机 (stochastic hybrid automata, SHA) 的模型转换, 并使用模型检测工具 UPPAAL-SMC 对场景模型进行量化评估分析; 然后, 通过重要性采样技术在场景空间中快速检测到边缘场景, 实现逻辑场景到边缘关键具体场景的有效生成; 最后, 结合变道超车等典型场景, 进行案例展示. 实验结果表明该方法能够有效建模场景, 并解决 ADS 安全关键场景生成问题.

关键词: 自动驾驶系统; 场景建模; 重要性采样; 安全关键场景; UPPAAL-SMC

中图法分类号: TP311

中文引用格式: 杜德慧, 叶振, 郑成行, 朱珍珍, 李家蕴. 面向自动驾驶系统的场景建模及边缘关键场景生成. 软件学报, 2025, 36(8): 3512–3530. <http://www.jos.org.cn/1000-9825/7348.htm>

英文引用格式: Du DH, Ye Z, Zheng CH, Zhu ZZ, Li JY. Scenario Modeling and Edge-critical Scenario Generation for Autonomous Driving System. Ruan Jian Xue Bao/Journal of Software, 2025, 36(8): 3512–3530 (in Chinese). <http://www.jos.org.cn/1000-9825/7348.htm>

Scenario Modeling and Edge-critical Scenario Generation for Autonomous Driving System

DU De-Hui^{1,2,3}, YE Zhen^{1,2,3}, ZHENG Cheng-Hang^{1,2,3}, ZHU Zhen-Zhen^{1,2,3}, LI Jia-Yun^{1,2,3}

¹(Software Engineering Institute, East China Normal University, Shanghai 200062, China)

²(Shanghai Key Laboratory of Trustworthy Computing (East China Normal University), Shanghai 200062, China)

³(MOE International Joint Lab of Trustworthy Software (East China Normal University), Shanghai 200062, China)

Abstract: Extreme scenarios in autonomous driving, as well as unpredictable human behaviors, have become key factors limiting the development of autonomous driving systems (ADS). Therefore, effectively generating safety-critical scenarios is crucial for enhancing the

* 基金项目: 国家自然科学基金面上项目 (62272165)

本文由“形式化方法与应用”专题特约编辑陈明帅研究员、田聪教授、熊英飞副教授推荐.

收稿时间: 2024-08-26; 修改时间: 2024-10-14; 采用时间: 2024-11-26; jos 在线出版时间: 2024-12-10

CNKI 网络首发时间: 2025-04-17

safety of ADS. Existing methods for generating autonomous driving scenarios mainly rely on substantial road data collection and employ data-driven approaches combined with scenario generalization techniques. These methods are time-consuming, labor-intensive, and costly, making it difficult to effectively generate edge cases. In contrast, model-driven scenario modeling methods can construct logical scenario models to encapsulate complex scene features and effectively generate safety-critical scenarios. However, the challenge lies in designing a domain-knowledge-based visual scenario modeling language that supports the abstract modeling of complex driving scenarios and further explores edge-critical scenarios. To address these issues, this study proposes an approach for scenario modeling with SML4ADS2.0 and edge-critical scenario generation for autonomous driving systems. This method utilizes ontology-based modeling of scenarios within the ADS domain, combining formal quantitative evaluation with importance sampling to generate edge-critical scenarios. First, a model-driven scenario modeling method based on SML4ADS2.0 is proposed, using this language to construct models of autonomous driving scenarios. Second, the conversion of scenario models to stochastic hybrid automata (SHA) is implemented through model transformation rules and the model checking tool UPPAAL-SMC is used for quantitative evaluation and analysis of the scenario models. Subsequently, importance sampling techniques are employed to rapidly detect edge scenarios within the scenario space, effectively generating specific edge-critical scenarios from logical models. Finally, the method is demonstrated through case studies involving typical scenarios such as lane changes and overtaking. Experimental results indicate that this approach can effectively model scenarios and address the generation of safety-critical scenarios for ADS.

Key words: autonomous driving system (ADS); scenario modeling; importance sampling (IS); safety-critical scenario; UPPAAL-SMC

自动驾驶汽车将成为未来交通领域的重要发展方向,在提高交通安全性、优化交通效率等方面具有极大的潜力,引起了全球政府部门、行业组织与学术机构的广泛关注。目前,L4级自动驾驶仍处于研发阶段,其安全性和可靠性是制约自动驾驶汽车大量投入市场的首要问题。实车道路测试成本高昂,并且具有潜在的风险,据美国兰德公司研究报告显示,车辆需要在自然驾驶环境(naturalistic driving environment, NDE)测试数亿,甚至数千亿千米,才能验证自动驾驶汽车比人类驾驶员更具安全性。由于自动驾驶汽车安全性能验证的低效率,严重阻碍了其产业化的进程。为了有效提高测试效率,仿真场景测试已成功应用于工业界。仿真场景测试技术通过模拟真实驾驶场景和交通环境,对自动驾驶系统进行复杂环境建模与测试,有效提高测试效率,降低测试成本。场景测试旨在通过大量的场景测试,发现ADS系统中潜在的错误,而其面临的挑战是如何有效地挖掘罕见的安全关键场景。“稀有诅咒(curse of rarity, CR)”^[1]指在仿真驾驶场景中发现边缘关键场景,以保证测试的全面性并提高测试效率。因此,研究面向自动驾驶的场景建模方法、边缘关键场景生成技术是设计、研发汽车自动驾驶系统面临的主要挑战之一。

根据抽象粒度由粗到细的划分原则,自动驾驶的场景模型分为3个抽象层次:功能场景、逻辑场景和具体场景^[2]。功能场景和逻辑场景在两个不同的抽象层次上描述场景空间,而具体场景是特定场景的参数化表示,每个具体场景都是逻辑场景的实例。操作设计域(operational design domain, ODD)^[3]本质上定义了ADS的运行环境,通过ODD定义的输入,功能场景将被参数化为具有所有参数及其取值范围的逻辑场景。逻辑场景利用采样或优化方法,通过朴素搜索或引导式搜索方法实现具体场景的实例化。目前,自动驾驶场景建模方法主要分为两类:数据驱动式场景建模^[4]和模型驱动式场景建模。前者利用大量路采数据,通过数据工程处理和数字孪生构建具体场景模型,实现场景仿真。难点在于如何有效利用路采数据实现场景1:1还原,并解决成本高且难以覆盖全工况的问题。模型驱动式场景建模采用领域特定建模语言,依据功能场景需求,设计面向ADS的场景建模语言,构建具有语义信息的逻辑场景模型,以实现在抽象层次上进行场景仿真、测试和验证。关键技术包括设计并实施场景建模语言,结合场景ODD、道路交通场景及交通法规,遵循国际标准ASAM OpenXOntology和ISO 3450X标准系列进行场景描述。其面临的挑战在于缺乏有效的场景建模语言和工具,实现与多种自动驾驶仿真器的集成,以便进行自动驾驶系统场景建模和仿真。

自动驾驶环境非常复杂,现有自动驾驶场景建模语言缺乏足够的领域知识指导,场景建模元素的表达能力不足。同时,自动驾驶的长尾效应导致虚拟场景测试面临“稀有诅咒”挑战,罕见的安全关键场景严重制约自动驾驶测试的效率。因此,复杂自动驾驶场景的建模、边缘关键场景生成对于提高ADS系统的安全性至关重要,能够有效提高场景仿真、测试及验证分析的有效性。针对以上ADS场景建模、边缘关键场景生成面临的挑战性问题,本文提出一种基于SML4ADS2.0的自动驾驶场景建模与边缘关键场景生成方法,如图1所示,基于ASAM OpenXOntology

和 ISO 3450X 标准, 提出了基于本体的场景建模语言 SML4ADS2.0, 增强对复杂自动驾驶场景的建模能力, 并基于 UPPAAL-SMC 形式化验证与重要性采样技术, 实现边缘关键场景的生成. 该方法有效地解决复杂自动驾驶场景建模与边缘关键场景生成问题.




图 1 基于 SML4ADS2.0 的自动驾驶场景建模与边缘关键场景生成框架

本文的主要工作如下.

(1) 针对自动驾驶逻辑场景建模问题, 提出了一种基于 ADS 本体的自动驾驶场景建模语言 SML4ADS2.0. 该语言遵循 ASAM OpenXOntology 和 ISO 3450X 标准, 提供丰富场景建模元素, 增强对复杂自动驾驶场景的建模能力.

(2) 针对安全关键场景的“稀有诅咒”问题, 提出基于 UPPAAL-SMC 的场景验证方法. 通过模型转换技术将 SML4ADS2.0 建模的逻辑场景模型自动转换为 SHA, 实现逻辑场景模型的形式化语义抽象建模. 基于 UPPAAL-SMC 验证分析 ADS 的逻辑场景模型, 并根据量化评估结果确定安全关键逻辑场景.

(3) 针对边缘关键场景生成问题, 提出一种基于重要性采样 (importance sampling, IS) 的边缘关键场景生成方法. 该方法能够提高边缘场景采样效率, 发现发生概率较低的安全关键场景. 并结合变道超车等案例, 在仿真器 CARLA 中生成相应的边缘关键具体场景.

本文第 1 节介绍基础知识. 第 2 节提出基于 SML4ADS2.0 模型驱动式场景建模方法, 通过描述 SML4ADS2.0 构建场景的理论方法, 设计其抽象语法、语义以及基于树形结构的智能体行为动态规划, 为 ADS 逻辑场景建模奠定基础. 第 3 节提出基于 UPPAAL-SMC 的逻辑场景验证分析及边缘关键场景生成方法, 通过基于 UPPAAL-SMC 验证分析逻辑场景, 实现对场景中的关键参数范围导致危险发生的概率进行量化评估分析, 并且使用重要性采样技术生成边缘关键的具体场景, 从而高效生成安全关键场景用于场景测试及验证分析. 第 4 节结合典型场景——变道超车案例, 给出其相应的场景模型、边缘关键场景生成过程等. 第 5 节进行相关工作比较. 第 6 节总结全文, 并对未来值得关注的研究方向进行初步探讨.

1 基础知识

1.1 场 景

在自动驾驶场景建模中, 场面 (scene) 描述了驾驶环境的快照, 包括静态和动态元素, 以及实体的自我表征和

关系. 场景 (scenario) 描述了一系列场面的时序关系, 每个场景都从一个初始场面开始, 通过指定动作“action”以及目标“goals”来表征场景中的这种时序关系, 由多个场面按照时序情形依次发生的过程^[2]. 其相关定义如下.

定义 1. 场面 (scene). $scene=(scenery, actors, SA, relationships, observers)$, 其中 scenery 表示驾驶环境, 包括静态路网结构、静态元素、环境条件等; actors 表示交通参与者等动态元素; SA 表示动态元素的状态 (速度、位置等) 及属性; relationships 表示实体间的拓扑关系; observers 表示观察者, 能够通过传感器采集环境的状态信息.

定义 2. 场景 (scenario). $scenario=(I, T, A, G)$, 其中 I 表示初始场面即 initial scene; T 表示场景时序关系; A 表示智能体所有可能的行为 (actions) 集合, 例如车辆进行左变道、加速直行等; G 表示交通参与者短期与长期驾驶目标 (goals).

定义 3. 安全关键场景 (safety-critical scenario). 安全关键场景是指高危险的具体场景, 即当场景中的危险触发条件满足时, 可能会产生危险的场景. 通常, 此类场景跟安全相关的性质及危险触发条件相关, 是自动驾驶场景测试的关键, 能够有效发现风险, 从而加速测试. 安全关键场景定义如下:

$$\hat{\theta} = \operatorname{argmax}_{x \sim p_{\theta}(x)} [g(F, x)].$$

场景 x 服从参数为 θ 的分布, 安全关键场景可根据上面的公式生成. 其中 g 是度量场景风险程度及安全相关的性质 (如碰撞率、偏离道路的距离等) 的度量函数. F 是运行在场景 x 中的自动驾驶系统, 并输出控制信号的序列. 本文的重点是如何使用形式化验证方法评估风险度量函数 g , 并生成关键场景 x .

1.2 随机混成自动机

UPPAAL-SMC^[5] 是 UPPAAL^[6] 的最新扩展版本, 通过随机混成自动机 SHA^[7] 来建模具有复杂的物理行为及环境的系统, 除支持传统的实时系统建模外, 还支持建模复杂的连续物理过程和随机行为. SHA 是自动机的一种扩展版本, 可以定义为一个八元组: $SHA=(Loc, Loc_0, Q, Var, Inv, A, G, T)$. 其中,

- Loc : 表示状态的有限集合;
- Loc_0 : $Loc_0 \in Loc$, 表示初始状态;
- Q : 表示连续变量的集合;
- Var : 表示离散变量的集合;
- Inv : 表示状态 Loc 上的不变式集合;
- A : 表示动作的有限集合;
- G : 表示迁移条件的有限集合;
- T : 表示状态迁移的有限集合. 迁移边包括迁移条件、行为动作、离散变量、连续变量和迁移概率等.

UPPAAL-SMC 能够验证系统的定性性质 $P=? [F \text{ “error”}]$, 例如, 安全性、活性、可达性等. 同时, 其验证引擎使用了统计模型检测算法, 支持对 SHA 模型进行多种概率性质的验证, 能够定量评估系统出错的概率区间. 与传统形式化验证方法相比, UPPAAL-SMC 无需遍历整个状态空间, 而是通过随机采样技术分析有限数量的系统仿真运行, 从而显著降低模型检测的时间和空间复杂度, 有效地减少内存和时间开销. 具体而言, UPPAAL-SMC 将系统的状态空间划分为两类: 可达状态和不可达状态. 对于可达状态, UPPAAL-SMC 采用蒙特卡罗抽样方法^[8], 通过样本分析来估计满足性质的概率; 对于不可达状态, 则通过模型检测器识别并进行剪枝, 以减少状态空间的规模. 此外, UPPAAL-SMC 支持使用常微分方程 (ordinary differential equation, ODE) 表达式来建模时钟速率, 因此也适用于非线性混成系统的建模.

1.3 重要性采样

重要性采样是一种蒙特卡罗积分方法, 由 Marshall^[9] 于 20 世纪 50 年代提出, 在概率密度函数难以采样或需要采样多次的情况下, 通过选取合适的采样分布, 对原积分式进行重写, 从而提高采样的效率. 重要性采样常用于计算较为复杂的积分, 例如高维积分、边缘分布等. 同时, 重要性采样在深度学习^[10]、计算机视觉^[11]、图形学^[12]等领域也有广泛应用, 同时它被用来估计期望值、计算复杂积分、进行贝叶斯推断等. 通过引入重要性权重, 重要性采样能够在复杂问题中得到有效的估计结果, 提高计算的准确性和效率.

$$E[f(x)] = \int \frac{f(x)p(x)}{q(x)} q(x) dx.$$

假设计算一个随机变量 X 的期望 $E[f(X)]$, 其中 X 服从概率分布 $p(x)$. 其中, $\frac{p(x)}{q(x)}$ 为重要性权重, 用于调整因为提议分布 $q(x)$ 与目标分布 $p(x)$ 不匹配而引入的偏差. 然后, 通过从 $p(x)$ 中采样 N 个样本 $\{x_i\}_{i=1}^N$, 用加权样本均值来估计 $E[f(X)]$:

$$\hat{E}[f(x)] = \frac{1}{N} \sum_{i=1}^N \frac{f(x_i)p(x_i)}{q(x_i)},$$

其中, x_i 是从 $q(x)$ 分布中抽取的第 i 个样本, $\frac{p(x_i)}{q(x_i)}$ 是相应的重要性权重值. 重要性采样的优势在于它能够减少估计的方差, 尤其是当某些区域的 $f(x)p(x)$ 远大于其他区域而在 $p(x)$ 下的采样概率却很小时, 因此选择一个好的提议分布 $q(x)$, 使其尽可能接近 $f(x)p(x)$, 可以显著提高估计的效率和准确性. 然而, 选择一个合适 $q(x)$ 很具挑战性, 需要对问题有深入的理解.

在自动驾驶场景生成领域, 重要性采样可用于提高场景生成、采样的效率. Zhao 等人^[13]使用重要性采样技术来加速自动驾驶车辆在换道场景中安全性的评估, 采用偏向于更多危险场景的分布, 显著减少了评估自动驾驶车辆安全性能所需的模拟测试数量. 清华大学 Feng 等人^[14]提出构建一个同时具有自然和对抗特性的驾驶环境, 将重要性采样技术应用于特定时刻执行特定的对抗性动作, 提高自动驾驶的测试效率. Arief 等人^[15]提出了“深度概率加速评估”框架, 通过结合支配点概念和深度学习来学习稀有事件集实现重要性采样, 验证智能驾驶算法的安全性. 在 ADS 场景生成过程中, 安全关键场景发生概率低, 采用传统蒙特卡罗采样算法生成关键场景效率低, 而通过重要性采样可以显著提高采样的效率.

2 基于 SML4ADS2.0 模型驱动式场景建模

本文前期工作^[16]从模型驱动工程角度, 基于专家知识分析自动驾驶场景的关键内容与建模要素, 设计并实现了面向自动驾驶场景的领域特定建模语言 (scenario modeling language for autonomous driving system, SML4ADS), 以灵活地建模 ADS 的特定驾驶场景. 随着 ADS 系统的安全性需求日益增强, SML4ADS 在构建复杂、准确的自动驾驶逻辑场景模型仍然存在局限性, 因缺乏领域知识指导和参数动态变化导致场景建模表达能力不足, 限制其工业化应用. 为了解决复杂场景建模问题, 本文提出基于 ASAM OpenXOntology 和 ISO 3450X 标准, 通过使用本体概念和参数概率分布, 增强对复杂自动驾驶场景的建模能力, 实现了场景建模语言 SML4ADS2.0 版本. 本节将简要介绍基于 SML4ADS2.0 的模型驱动式场景建模方法, 重点介绍其语言结构, 抽象语法、语义及其基于树形结构的行为规划模型, 这也是本文的主要创新点之一.

2.1 场景建模 SML4ADS2.0 的结构与理论方法

根据 OpenXOntology 标准自动驾驶领域知识与 ISO 34501 标准自动驾驶测试场景中的关键术语和定义, 识别自动驾驶场景的关键内容以及建模元素, 借助模型驱动软件开发的思想, 设计 SML4ADS2.0 的抽象语法、具体语法以及语义. 此外, 为了有效提高场景建模效率, 避免文本语法冗余和复杂的结构问题, 方便设计者以可视化的方式建模场景, 本文设计、实现了 SML4ADS2.0 的可视化建模工具.

根据模型驱动理论, 构建自动驾驶领域场景建模语言, 我们设计该建模语言的抽象语法、具体语法及语义模型. 详细技术细节请参见团队前期的工作^[16,17], 其语言结构如图 2 所示, 该语言采用了文本形式刻画静态场景信息, 例如车辆位置、地图等, 并支持以图形化的方式建模车辆的行为, 这两种方式的结合, 为用户定义场景的静态和动态信息提供了便捷的途径. 最终, 用户构建的 SML4ADS2.0 场景模型, 以 JSON 文件的格式存储, 可用于模型验证及仿真.

图 2 所示为 SML4ADS2.0 场景建模的结构与理论方法. 场景建模语言 SML4ADS2.0 包括抽象语法、具体语法以及语义. 其中, 抽象语法是基于自动驾驶本体领域知识, 抽象场景建模语言的关键元素以及元素之间的关系.

具体语法是模型的可视化建模呈现形式, 主要包括文本和图形化的形式. 本文采用文本形式建模自动驾驶 scene, 包括自动驾驶地图, 以及实体的状态与属性; 同时, 可采用图形化形式描述车辆在场景中的动态行为过程, 从而实现基于静态 scene 构建动态 scenario.




图2 基于 SML4ADS2.0 场景建模方法

2.2 场景建模语言 SML4ADS2.0

与之前设计的建模语言不同, SML4ADS2.0 根据 OpenXOntology 标准中的自动驾驶领域本体知识, 构建自动驾驶场景元模型, 以表达其抽象语法, 从而增强其对复杂场景的建模能力. 新增加的内容包括: 引入 ASAM OpenXOntology 和 ISO 3450X 标准定义自动驾驶场景建模元素, 针对自动驾驶环境、交通参与者和驾驶行为这 3 个方面构建自动驾驶元模型, 不仅支持丰富的静态场景建模元素, 而且支持灵活的基于树形结构的行为建模, 提高了自动驾驶场景建模语言的建模能力, 并能够与仿真器实现无缝集成.

1) SML4ADS2.0 的抽象语法

自动驾驶环境复杂多变, 是影响 ADS 系统安全的重要因素. 环境因素不仅包含天气, 还涵盖了光照、能见度、颗粒度等多个维度. 为了全面拓展自动驾驶环境描述能力, 本节依据 OpenXOntology 中描述 ADS 环境条件的子本体, 构建自动驾驶环境元模型, 使得 SML4ADS2.0 能够全面地描述自动驾驶场景中的环境条件, 从而为模拟真实世界提供了更加丰富的建模元素. 为了有效描述自动驾驶场景中智能体与其他交通参与者的交互, 本节依据 Traffic-Participant 本体描述的多种形式交通参与者, 构建自动驾驶交通参与者元模型, 使得其支持更全面地覆盖和描述各类交通参与者, 这些参与者包括但不限于行人、各类车辆等. 为了能够对驾驶状态进行全面、精确地描述, 包括但不限于超车 (overtake)、通过 (pass)、交叉 (cross) 等复杂的驾驶行为, 本节依据 OpenXOntology 中的 TrafficActivity 子本体, 构建自动驾驶行为元模型, 使得对驾驶状态变化进行真实地建模, 更全面地模拟实际道路交通情况. 元模型如图 3 所示.

2) SML4ADS2.0 的语义

本文主要通过 SML4ADS2.0 构建树形结构的行为规划模型 (behavior planning model, BPM) 来描述 scenario 的动态特性, 因此本节重点介绍行为规划模型的形式化语义与操作语义. 在 SML4ADS2.0 中, 自动驾驶车辆的动态行为主要通过行为规划模型中树形结构的迁移边、触发条件以及行为进行刻画. SML4ADS2.0 行为规划模型的形式化语义定义为一个五元组 $BPM=(N, T, A, \rightarrow, O)$:

- N : 表示状态节点的有限集合, n 可以用 $(type, t, vars, loc, o)$ 表示, $n \in N$. 其中 $type=\{behaviorNode \mid branchPoint\}$, 用于表示当前节点的类型. t 是时钟, 用于表示在当前节点的持续时间. $vars$ 表示当前节点的参数集合, 可以表示为 $(roadId, laneId, speed, acceleration, x, y, targetSpeed, currentBehavior)$. loc 表示当前节点在抽象行为规划模型中的位置, $o \in O$, 表示与当前节点绑定的常微分方程 ODE;

- T : 表示触发器 (trigger) 的有限集合. 每个 trigger 由条件表达式组成, 其中 trigger 在运行时可被评估为真

true 或假 false;

- A : 表示动作 act 的有限集合, $act \in A$;
- $\rightarrow$: 表示状态迁移的有限集合, 每个迁移边表示为 $n \xrightarrow{trigger, act, w} n'$. 其中 $n, n' \in N$, $trigger \in T$, $act \in A$, w 为离散概率分布, 用于表示相应迁移边上的权重;
- O : 表示 ODE 等式的集合, 通过 ODE 描述车辆执行相应驾驶行为而改变自身状态的过程.




图3 SML4ADS2.0 的元模型

基于行为规划模型的形式化语义, 为了刻画 scenario 中车辆的动态行为特性, 我们设计了 SML4ADS2.0 行为规划模型操作语义规则, 从而支持场景树迁移边的动作迁移、无需事件触发的动作迁移以及概率动作迁移. 其中, 行为节点处执行 ODE 等式刻画物理状态的连续变化; 迁移边用来刻画车辆驾驶行为的改变. 我们定义 E_n 表示以行为节点/分支节点为源节点 n 的迁移边 e , $T(e)$ 表示树形结构中迁移边 e 上的触发器 $trigger$ 条件评估取值是否为真, end_n 表示当前行为节点满足状态结束条件, 如超出时限 t 等. 具体操作语义规则定义如下.

规则 1: 动作迁移.

$$\frac{((n \in N \wedge (\exists E_n \wedge T(e) \models trigger))) \vdash n' \in N \wedge type(n') \models behaviorNode}{n_{(type, t, vars, loc, o)} \xrightarrow{trigger, act} n'_{(type', t', vars', loc', o')}}.$$

规则 1 表示, 如果存在以 n 为源节点的迁移边 e 迁移到目标节点为 n' 的行为节点上, 并且迁移边 e 上的触发器 $trigger$ 取值为 $true$ 时, 当前车辆状态 n 将触发状态迁移, 执行动作 act , 改变到车辆状态 n' .

规则 2: 无需事件触发的动作迁移.

$$\frac{((n \in N \wedge (\exists E_n \wedge \neg trigger) \wedge n \models end_n) \vdash n' \in N) \wedge type(n') \models behaviorNode}{n_{(type, t, vars, loc, o)} \xrightarrow{trigger, act} n'_{(type', t', vars', loc', o')}}.$$

规则 2 表示, 如果存在以 n 为源节点的迁移边 e 迁移到目标节点为 n' 的行为节点上, 并且迁移边 e 上不存在触发器 $trigger$, 当节点 n 达到结束条件时, 当前车辆状态 n 不需要评估 $trigger$, 即可进行状态迁移, 执行动作 act , 改变到车辆状态 n' .

规则 3: 概率动作迁移.

$$\frac{(((n \in N \wedge (\exists E_n \wedge T(e) \models trigger)) \vdash n' \in N) \wedge type(n') \models branchPoint \wedge (n' \in N \wedge \exists E_{n'})) \vdash n'' \in N}{n_{(type, t, vars, loc, o)} \xrightarrow{trigger, act, w} n''_{(type'', t'', vars'', loc'', o'')}}.$$

规则 3 表示, 如果存在以 n 为源节点的迁移边 e 迁移到目标节点为 n' 的分支节点上, 并且迁移边 e 上的触发器 $trigger$ 取值为 $true$, 同时存在以 n' 为源节点的迁移边 e' 迁移到目标节点为 n'' 的行为节点上时, 那么当前车辆状态 n 根据相应迁移边的权重 w , 概率执行相应动作 act , 改变到车辆状态 n'' . 该语义规则能够有效建模车辆的概率行为, 可用于分析车辆行为的危险性.

3) SML4ADS2.0 的行为规划模型

根据第 1.1 节定义, 我们使用静态的场面 $scene$ (阴影圆圈节点), 以树形结构定义连续场景 $scenario$ 中智能体的动态行为, 这种建模场景的方式称为场景树. 在实际使用过程中, 可以根据自动驾驶的历史数据, 使用机器学习算法对自动驾驶的轨迹数据进行深度挖掘, 构建出其相应的场景树, 这样可以有效建模 Ego 车在行驶过程中, 其周边车辆及环境的情况. 另一方面, Ego 车的行为规划主要用于描述 Ego 车的行为动作序列, 其规划的行为序列可以采用树形结构的语义模型, 如图 4 所示, 其中圆圈节点表示智能体的行为动作. 再结合场景建模语言, 可以构建相应的轨迹树, 抽象描述场景的动态变化过程. 智能体的行为控制策略随着其运行的场景树中场景变换及其行为规划进行动态编程, 以此种方式生成的智能体行为控制策略将更加灵活. 总之, 场景建模语言的语义模型及场景树模型为场景建模奠定了语义基础, 能够有效支持智能体的行为规划, 对于 ADS 系统的设计具有重要意义.




图 4 基于树形结构的行为规划模型

综上, 本文所提出的场景建模语言的语义模型, 不仅能够支持构建复杂场景模型, 而且能够灵活建模智能体的动作即行为轨迹树. 基于树形结构构建场景的动态演变, 充分建模了自动驾驶场景的时序动态变化过程. 这种场景的抽象语义模型, 能够有效建模 ADS 场景的不确定性及智能体的动态行为, 为智能体的动态行为规划奠定了语义基础. 其中, 智能体的行为轨迹树可以根据 SHA 的语义模型生成, 这种场景模型自带严格的语义模型, 为场景模型

的分析提供了统一的语义基础. 相比于已有的工作, 本文方法有助于自动驾驶场景建模并提供了丰富的动态行为语义模型, 为场景模型的测试、验证奠定了基础.

3 基于 UPPAAL-SMC 的逻辑场景验证分析及边缘关键场景生成

本节重点讨论在边缘关键场景的生成方面, 根据场景验证分析的结果, 得到安全关键的逻辑场景模型, 针对场景中关键参数与概率分布, 使用基于重要性取样的场景生成方法, 得到边缘关键的具体场景. 本文提出的边缘关键场景生成方法, 结合了基于 UPPAAL-SMC 的逻辑场景验证分析的优点, 能够高效地对场景的抽象状态空间进行搜索并对系统满足性质约束的概率区间进行评估, 能够评估场景中风险发生的概率区间, 进而锁定关键场景. 同时, 结合基于重要性采样的方法有效生成边缘关键具体场景.

基于重要性采样的边缘关键场景生成步骤如图 5 所示, 首先使用场景建模语言 SML4ADS2.0 构建逻辑场景模型并根据场景需求设计场景中关键参数的输入范围. 然后, 使用 UPPAAL-SMC 验证分析场景模型是否满足给定的性质约束, 以确定场景安全程度, 进而可以根据量化分析的结果评估、确定关键参数的取值范围; 最终输出的是调整后的参数范围, 也就是被认为更容易造成风险场景的关键参数域及其概率分布. 一旦确定了关键参数域及其概率分布, 使用重要性采样进行加速采样, 找出不易发生的安全关键场景. 原始的场景概率分布不均, 边缘的安全关键场景不容易生成, 通过新的提议分布替换概率分布, 从而提高边缘关键场景的发生概率. 根据提议概率分布, 通过标记函数 $g(x)$ 判断其是否为边缘关键场景, 如果是, 则将该边缘关键场景保存在场景数据库中. 记录好一个安全攸关具体场景后, 判断是否完成迭代, 是的话便结束整个流程. 迭代的判断依据是生成的待采样本集合. 该流程中的关键步骤是基于 UPPAAL-SMC 的逻辑场景验证分析与基于重要性采样的边缘关键场景生成, 从而实现逻辑场景到边缘关键具体场景的生成.




图 5 基于重要性采样的边缘关键场景生成

3.1 基于 UPPAAL-SMC 的逻辑场景验证分析

SML4ADS2.0 通过初始位置的概率分布设置以及树结构行为规划模型的分支特性, 从而支持建模场景中车辆

的随机行为. 而 UPPAAL-SMC 使用随机混成自动机模型支持随机混成行为的验证分析, 且具有较强的定量性能分析能力, 能够较好地反映出自动驾驶汽车的相对安全性. SML4ADS2.0 场景模型采用 JSON 作为数据交换的格式. 因此实现 SML4ADS2.0 到 UPPAAL-SMC 模型的转换首先需要对 JSON 格式的 SML4ADS2.0 场景模型实例按照具体的语法关键字进行解析, 得到原始数据信息. 这些数据信息主要包括 OpenDRIVE 地图、车辆信息、车辆行为规划模型以及待验证的性质规约字符串. 如图 6 所示, 将这些 SML4ADS2.0 场景模型中的原始数据转换到 UPPAAL-SMC 所支持的数据可以划分为以下 3 个部分.

1) OpenDRIVE 地图文件、天气以及车辆属性等静态场景元素的转换. 由于 UPPAAL-SMC 无法直接解析描述地图信息的 OpenDRIVE, 因此, 需要对 SML4ADS2.0 场景模型文件中引用的 OpenDRIVE 地图文件进行解析, 将路网的各个组成部分通过事先定义的数据结构声明模板转化为 UPPAAL-SMC 中可读的数据类型, 从而支持路网信息的描述. 但是 UPPAAL-SMC 中支持的数据结构有限, 转换过程中需要对相关数据进行一定的抽象处理.

2) 车辆行为规划模型到 SHA 自动机网络的转换. UPPAAL-SMC 借助随机混成自动机网络建模复杂系统的行为. 因此, 本文将一个车辆的树结构行为规划模型转化为一个混成自动机模型, 并根据场景模型中表示执行周期的 timeStep 属性, 构建了控制执行周期的自动机, 从而形成随机混成自动机的网络, 建模单位时间步长内 Ego 车移动的过程.

3) 待验证的性质规约的转换. 根据 SML4ADS2.0 关于车辆待验证性质规约的具体语法形式, 可以将其转化为 UPPAAL-SMC 中支持的时态逻辑表达式, 从而利用 UPPAAL-SMC 工具对转化后的场景模型进行验证分析.




图 6 SML4ADS2.0 到 UPPAAL-SMC 的自动转换

接下来如后文表 1, 针对 SML4ADS2.0 场景模型的模型转换设计具体模型转换规则. 包括静态数据的转换和车辆行为规划模型到 SHA 网络的转换, 以及部分在 UPPAAL-SMC 模型中需要使用的重要功能函数.

基于 SHA 的语义模型, 本文设计、实现了 SML4ADS2.0 的自动转换规则及算法实现, 具体实现细节请参见文献 [18], 当用户构建场景模型后, 可以自动实现场景模型到验证模型 SHA 的转换, 进而使用 UPPAAL-SMC 对场景模型进行验证分析.

3.2 基于重要性采样的边缘关键场景生成

本文针对边缘关键具体场景的生成问题, 提出基于重要性采样的边缘关键场景生成方法, 本质上是根据 UPPAAL-SMC 验证分析的结果, 获取关键参数域与概率分布 $p(x)$, 得到 ADS 安全关键逻辑场景. 根据概率分布特性, 通过传统蒙特卡罗均匀采样对逻辑场景的参数范围均匀地随机选点, 不仅很多样本会落在对计算结果贡献不大的区域, 而且通过蒙特卡罗均匀采样虽然能得到大量的具体场景, 但是样本数量仍然非常大, 其中包含大量非安全关键的场景. 因此, 本节基于重要性采样方法, 通过设计一个风险事件发生概率更高的混合高斯提议分布代替原有的分布, 引入重要性权重函数 $w(x)$ 减少两个分布的方差, 从而获得边缘关键具体场景^[19].

表 1 SML4ADS2.0 场景模型到 UPPAAL-SMC 的模型转换规则

原始数据	SML4ADS2.0	UPPAAL-SMC模型
OpenDRIVE 地图数据	道路列表roads	Road结构体
	道路段列表laneSections	LaneSection结构体
	车道列表lanes	Lane结构体
	junctions	Junction结构体
	connections	Connection结构体
	laneLinks	LaneLink结构体
节点 BehaviorName B_ID		
行为 规划模型	$\frac{((n \in N \wedge (\exists E_n \wedge T(e) \models trigger)) \vdash n' \in N) \wedge type(n') \models behaviorNode}{n_{(type,t,vars,loc,o)} \xrightarrow{trigger.act} n'_{(type',t',vars',loc',o')}}}$	
	$\frac{((n \in N \wedge (\exists E_n \wedge \neg trigger)) \wedge n \models end_n) \vdash n' \in N) \wedge type(n') \models behaviorNode}{n_{(type,t,vars,loc,o)} \xrightarrow{trigger.act} n'_{(type',t',vars',loc',o')}}}$	
	$\frac{(((n \in N \wedge (\exists E_n \wedge T(e) \models trigger)) \vdash n' \in N) \wedge type(n') \models branchPoint \wedge (n' \in N \wedge \exists E_{n'})) \vdash n'' \in N}{n_{(type,t,vars,loc,o)} \xrightarrow{trigger.act,w} n''_{(type'',t'',vars'',loc'',o')}}}$	
	车辆名称.属性	cars[index].属性
待验证	require always Expression	A[] Expression
性质规约	require eventually Expression	E<> Expression

算法 1 给出重要性采样生成 ADS 边缘关键场景的主要过程. 算法详细描述如下: 算法第 1 行输入是待采样的样本数量 N , 变量 x 表示 ADS 逻辑场景的一个关键参数, $p(x)$ 表示变量 x 满足的安全概率分布, 标记函数 $g(x)$ 表示变量是否满足阈值的判定函数, $q(x)$ 表示变量 x 的提议概率分布. 算法的第 2 行输出是估计值 $\hat{P}(x)$ 和样本集 *Dataset*, 分别表示通过采样计算得到的估计值和生成的样本集. 算法的第 3 行初始化变量的值, 设置满足标记函数的样本点的数量 *cnt*, 初始化为 0, 并初始化边缘关键场景集合为空, 定义重要性权重 $w(x)$ 和采用提议分布后的新标记函数 $g(x)$. 算法第 4–10 行循环处理采样过程, 每次循环中首先通过 *sampler* 采样器对概率分布 $q(x)$ 进行采样得到一个样本 $sample_i$, 然后代入计算标记函数的值 $g'(x_i)$. 如果该值为真, 则该样本是边缘关键场景样本, 边缘关键场景样本数量加 1.

算法 1. 基于重要性采样的边缘关键场景生成算法.

输入: 采样样本数量 N , 变量 x 的安全概率分布 $p(x)$, 标记函数 $g(x)$, 变量 x 提议概率分布 $q(x)$;

输出: 估计值 $\hat{P}'(x) = \frac{cnt}{N}$, 边缘关键样本集合 $Dataset$.

1. 初始化: 满足标记函数的采样点数量 $cnt = 0$, 边缘关键样本集合 $Dataset = \emptyset$, 重要性权重 $w(x) = \frac{p(x)}{q(x)}$, 定义新的标记函数 $g'(x) = g(x) \cdot w(x)$;
2. **for** $i = 1, \dots, N$ **do**
3. 对变量 x 的提议概率分布 $q(x)$ 进行一次采样得到 $sample_i$;
4. 代入 $sample_i$ 计算标记函数值 $g(x_i)$;
5. **if** $g'(x_i)$ 为真 **then**
6. $cnt \leftarrow cnt + 1$;
7. $Dataset \leftarrow Dataset \cup \{sample_i\}$;
8. **end if**
9. **end for**

4 案例展示及分析

本节将通过一个较为复杂的变道超车场景, 展示自动驾驶场景建模语言 SML4ADS2.0 的场景建模能力、场景模型测试以及安全关键场景生成支持. 该研究建模实现了超车场景、跟车场景等多种复杂 ADS 场景, 其中超车场景来源于文献 [20] 中提到的变道场景. 本节将应用 SML4ADS2.0 对超车场景进行抽象建模, 并基于 UPPAAL-SMC 对逻辑场景验证分析和重要性采样实现边缘关键场景生成. 我们所设计和实现的 SML4ADS2.0 建模工具可参见: <https://github.com/D-Sketon/SML4ADS.js>.

4.1 场景建模

图 7 为变道超车的功能场景示意图, 其中, Ego 车将根据场景中其他车辆的情况进行变道超车, 为了保证两车之间不会碰撞, 需要满足纵向距离公式: 若 a 车位于 b 车之前, 则 $x_a - x_b \geq c + 1.5 \times v_b$. 其中 x_a 和 x_b 分别表示 a 车以及 b 车的纵向距离, v_a 表示 a 车的速度, v_b 表示 b 车的速度, c 为常数. 因此, Ego 车在选择变道到 lane1 时, 需要满足 $x_{Ego} - x_{B1} \geq c + 1.5 \times v_{B1}$, 其中 c 设置为常量 2. 同理, Ego 车在选择变道返回 lane2 时, 需要满足 $x_{F1} - x_{Ego} \geq c + 1.5 \times v_{F1}$. 该公式的引用是为了模拟车辆变道后, 需要给后方车辆留有一定的反应空间. 而位于 Ego 车同车道的前方则没有这种反应空间的需求, 因此本案例中设计为 Ego 车在选择变道到 lane1 加速超过 F1 的前提条件为 Ego 车与 F1 车距离超过 15 m, 即若在 15 m 内仍然没有满足上述的变道条件, 则认为超车失败, 只好选择跟车行驶.




图 7 变道超车的功能场景描述

根据以上的场景描述, 我们使用 SML4ADS2.0 进行逻辑场景建模, 并根据 Ego 车及 F2 车的行为规划, 设计了相应的行为规划树模型如图 8 所示, 其中, 每个圆圈表示车当前的状态信息, 例如, “keep”状态表示车子保持车速行驶, 并持续 2 个时间单位 ($duration=2$). F2 车的行为轨迹树中虚线箭头表示离散的概率选择, 50% 的概率保持车

速、10% 的概率减速且目标速度是 12、40% 的概率加速, 且目标速度是 20. 通过这种图形化的建模方式, 为设计者定义车的行为轨迹提供了方便. 超车场景具体实验细节参见: <https://github.com/Term-inator/SML4ADS>, 此外, 其他场景建模的案例也可参见该链接.




图 8 变道超车场景中车的树形结构行为规划模型

根据我们提出的 SML4ADS2.0 到 SHA 的模型转换方法, 可以得到变道超车场景的 SHA 模型如后文图 9 所示. 这些 SHA 模型准确建模了场景中关键组件的动态行为, 其中, Ego 车的行为最为复杂, 需要根据周边环境的变化, 执行不同的动作. 图 9(d) 为 Ego 车的 SHA 模型.

4.2 边缘关键场景生成

该案例的自动机网络模型及其需要满足的度量区间逻辑 (metric interval temporal logic, MITL) 性质规约, 可使用 UPPAAL-SMC 工具进行形式化验证分析. 本文从 Ego 车的角度, 验证、分析了关于 Ego 车是否超车成功的相关性质规约, 如下.

1) 性质 1: $\Pr[<=400;200] ([(cars[0].laneId == cars[1].laneId \ \&\& \ alltime > 0) \ imply (cars[0].offset - cars[1].offset \geq 20 + 1.5 \times cars[1].speed))$.

该性质规约用于评估在 400 个时间单位内, 对系统进行 200 次仿真实验, 当 Ego 车与 B1 车在同一条车道时, Ego 车与 B1 车是否能够一直满足安全距离. UPPAAL-SMC 评估系统模型满足该性质规约的概率区间为 [0.30297, 0.440946], 表明该场景下两车距离满足安全距离的概率区间较小, 即两车相撞的概率较大, 因此, 该场景属于安全关键场景.

2) 性质 2: $\Pr[<=400;200] ([(cars[0].laneId == cars[1].laneId \ \&\& \ alltime > 0 \ \&\& \ cars[0].offset > cars[1].offset) \ imply (cars[0].offset - cars[1].offset \geq 20 + 1.5 \times cars[1].speed))$.

该性质规约增加了一个前提条件约束 $cars[0].offset > cars[1].offset$, 表示 Ego 车的纵向偏移距离大于 B1 的纵向偏移, 此时能够满足两车最大安全距离约束的概率区间为 [0.605346, 0.739374], 在 Ego 车变道的过程中, B1 车还在向前行驶, 因此可能会存在 Ego 车变道时满足安全距离公式, 但是变道到 lane1 时, B1 车向前行驶, 可能会导致 Ego 车变道完成后与 B1 的距离小于安全距离公式. 通过分析该性质规约, 我们发现如果要确保两车保持安全距离的概率大于 0.6, 需要特别关注 Ego 车与被超车辆之间的距离. 通过这种量化分析、评估方法, 影响 ADS 场景

安全性的关键参数可以得到详细的分析, 并可有针对性地调整其取值范围, 最终帮助设计人员生成多种形式的關鍵场景。




图 9 变道超车的 SHA 模型

根据场景验证分析的结果, 在超车变道场景中, 两车距离是影响安全的关键参数, 不同情形下, 车距的参数范围对安全性的影响不同, 我们结合 UPPAAL-SMC 的量化分析结果, 根据系统对安全性要求的概率区间, 对车距的参数范围进行调整, 当初步确定范围后, 使用算法 1 通过重要性采样实现边缘关键具体场景的生成技术, 得到边缘关键具体场景集合, 并使用仿真器 CARLA 进行具体场景的模拟仿真. 关键危险场景生成的结果, 如图 10 所示, 其中, 图 10(a) 是变道超车的正常情况下的模拟, 借助 UPPAAL-SMC 对其相应的逻辑场景进行分析, 逐步明确场景中的关键参数车距的取值范围, 然后, 使用重要性采样技术, 并使用新的提议概率分布替换原始概率分布, 多次模拟生成安全关键场景. 图 10(b) 表示 Ego 车变道时未能正确判断与在变道车道行驶的后方 B1 车辆的距离, 导致变道过程中撞车. 图 10(c) 当 Ego 车变道时未能正确判断与车道正前方车辆 F1 的距离与相对速度, 导致追尾撞车. 图 10(d) 表示 Ego 车变道时未能正确估计与变道后车道前方车辆 F2 的距离与相对速度, 导致追尾撞车。




图 10 变道超车场景及生成的安全关键场景在 CARLA 中的仿真结果 (俯视图)

5 相关工作

近年来, 针对 ADS 长尾效应问题, 在 ADS 场景建模、安全关键场景生成方面已经取得了较大的进展. 本节梳理了 ADS 逻辑场景建模与场景生成方面的研究工作, 分析了现有研究在场景建模中缺乏领域知识指导、场景生成性能与安全关键场景“稀有诅咒”等方面存在的不足, 并进一步指出本文在该领域的创新与贡献.

在逻辑场景建模方面, 主要分为对场景静态元素和动态元素的建模. 静态元素建模方面, OpenDRIVE^[21]是一种用于描述道路网络的开放文件格式, 它是自动驾驶和驾驶模拟领域中用于道路元素和环境建模的标准之一. OpenDRIVE 专注于精确描述道路的几何形状、拓扑结构、交通规则和道路属性. OpenCRG^[22]是一种文件格式和数据交换标准, 专门用于描述道路表面的精细细节. CRG (curved regular grid) 是一种用于道路表面微观几何的数字化表示形式, 包括坡度、倾斜和不规则性等特征. 这种格式被设计用于精确模拟道路表面特性, 以便在车辆动力学模拟和自动驾驶系统测试中使用. RoadXML^[23]是一种用于道路和环境模拟的数据格式, 它被设计用于驾驶模拟器和自动驾驶系统测试环境. 这种格式专门用来描述虚拟环境, 包括道路的布局、交通标志、信号灯、各种路面标记以及其他静态和动态的环境特征. OpenStreetMap^[24]是一个开源项目, 旨在创建和提供免费的、可编辑的世界地图. 它由全球志愿者社区创建, 类似于维基百科, 用户可以添加、修改和删除地图上的数据. OpenStreetMap 的数据可以被用于各种应用, 从传统的地图查看和导航到复杂的空间数据分析和城市规划等. 动态元素建模方面, CommonRoad^[25]是一个用于自动驾驶和运动规划研究的开放源代码项目, 它提供了一个共享和比较运动规划算法的平台. 该项目汇集了多种道路网络、交通场景和车辆轨迹, 其目的是创建一个基准测试环境, 研究人员和开发人员可以在这个环境中测试和验证他们的运动规划策略. OpenSCENARIO^[26]是一种标准化的语言和文件格式, 用于描述汽车仿真中的驾驶场景和驾驶员行为. 它是由自动化及测量系统标准协会 ASAM 开发的一部分, 旨在与 OpenDRIVE 等其他标准共同工作, 提供一套全面的工具, 以支持自动驾驶和驾驶辅助系统的开发和测试. Scenic^[27]是一种领域特定语言, 用于生成随机的、结构化的场景描述, 这些场景描述可以用于测试和验证自动驾驶汽车和其他智能系统. Scenic 的目标是使研究人员能够方便地编写描述复杂交通场景的规范, 同时保持足够的灵活性来表达随机性, 以模拟真实世界中的不确定性. SML4ADS^[16]是本团队提出的一种用于场景表示和建模的领域特定建模语言, 它简化了场景的描述, 支持对车辆的随机行为进行建模, 并支持在 CARLA^[28]中生成可执行仿真的场景. 然而, 上述场景建模方法缺乏领域知识指导、无法支持建模带有参数概率分布的逻辑场景, 从而无法描述具有复

杂特性的逻辑场景, 因此, 亟需在现有场景建模语言的基础之上进行扩展, 从而支持自动驾驶复杂场景的建模。

目前自动驾驶场景生成方法主要分为 3 类: 基于场景组合的场景生成方法、基于优化搜索的场景生成方法和基于强化学习的场景生成方法^[19]。基于场景组合的生成方法本质上是 将场景生成问题转换为组合测试的问题, Menzel 等人^[29]提出基于 V 模型场景开发的功能、逻辑和具体场景这 3 个抽象级别进行场景的开发与具体化, 并进行危害分析和风险评估得到所需的测试场景用例。Chen 等人^[30]提出基于本体自动生成高速公路 ADS 测试用例方法, 通过定义高速公路、天气和车辆这 3 层本体层次结构概念化和描述测试用例。Elgharbawy 等人^[31]提出了一种基于本体和数据挖掘技术的自动驾驶功能自适应验证框架, 利用基于本体的测试场景, 综合使用自动驾驶功能的硬件在环联合仿真平台识别边界场景。基于优化搜索的场景生成方法主要是通过设计合理的优化目标函数引导式搜索生成场景。Hungar 等人^[32]提出一种由碰撞时间和车头时距结合的分段连续可微临界性指标生成场景测试用例。Klischat 等人^[33]提出了一种基于进化算法来生成复杂交通状况的关键场景, 主要通过可驾驶区域的临界度指标, 使用非线性优化来提高场景危险性生成危险场景。Tuncali 等人^[34]基于运行模拟计算稳健性值, 并通过优化算法找到安全场景与碰撞场景的边界条件, 实现安全关键测试用例的自动生成。Klück 等人^[35]通过影响 ADS 系统故障程度判定场景危险性, 并通过碰撞时间生成危险场景。基于强化学习的场景生成方法主要是将场景生成的过程抽象为一个智能体, 通过智能体的不断探索, 从而搜索场景的边界条件。Du 等人^[36]提出了通过领域知识增强自适应压力测试的奖励函数, 使用蒙特卡罗树搜索引导求解器发现更多样的轨迹集。Corso 等人^[37]通过引入责任敏感安全策略纳入奖励函数, 同时引入差异性指标, 发现并生成导致 ADS 失效、更具表现力的场景。Ding 等人^[38]提出一种基于流的多模式安全关键场景生成器并设计基于梯度的采样提高采样效率, 通过评估决策算法的鲁棒性来生成安全关键场景。李江坤等人^[39]提出一种基于场景动力学和强化学习的边缘场景生成方法, 通过微分方程描述随时间动态变化的场景模型, 然后采用神经网络构建场景控制器并通过强化学习实现边缘场景控制器的优化求解, 从而解决小概率高风险的边缘测试场景生成问题。

上述方法各有优缺点, 基于场景组合的生成方法多依靠知识驱动实现参数空间的组合, 生成的效率低并且场景包含大量不合理的场景; 优化搜索的方法虽然提高了生成的效率, 但是只能从当前的目标中生成危险场景, 难以发现更多的危险因素; 强化学习方法则依赖于自然驾驶数据集, 难以生成与数据集不相关的场景。因此, 需要深入探索如何提高场景生成方法的性能, 特别是针对边缘关键场景。如何有效地根据场景建模, 并结合场景生成算法, 得到路采方法难以获得的边缘关键场景。

针对 ADS 的逻辑场景建模与边缘关键场景生成方面的不足, 本文提出基于 SML4ADS2.0 的自动驾驶场景建模与边缘关键场景生成方法。如表 2 所示, 在 ADS 逻辑场景建模中缺乏领域知识指导与参数动态变化导致场景建模表达能力不足方面, 本文引入 ASAM OpenXOntology 和 ISO 3450X 标准等, 提出了基于 Ontology 的场景建模语言 SML4ADS2.0, 增强了对 ADS 基于本体领域知识场景建模的可信性、动态行为的不确定性与可视化建模复杂性等方面的能力; 在自动驾驶安全关键场景的“稀有诅咒”, 难以高效生成边缘关键场景方面, 提出基于 UPPAAL-SMC 的逻辑场景验证分析及边缘关键场景生成方法, 通过结合形式化量化评估与重要性采样提高边缘关键场景生成效率, 从而有效解决自动驾驶的长尾效应问题。综上, 本文所提的研究方法及技术框架, 有效解决自动驾驶逻辑场景建模、安全关键场景生成等方面的问题, 为面向 ADS 的场景建模、仿真、验证分析提供了有效的途径, 能够有效解决目前场景驱动的 ADS 系统测试、场景库建设面临的主要问题, 为大规模场景测试奠定了基础, 对于提高 ADS 系统的安全性与工业化应用具有重要意义。

表 2 场景生成方法比较

SGM	ON	PR	SA	AU	EF	COM	EX
Ontology hierarchy ^[30]	√	√	√	×	√	×	√
Ontology data mining ^[31]	√	×	√	√	√	√	√
Evolutionary algorithms ^[33]	×	×	√	√	×	√	×
Stochastic optimization methods ^[34]	×	×	√	√	×	√	√
RSS-AST ^[37]	×	×	√	√	√	×	×

表 2 场景生成方法比较 (续)

SGM	ON	PR	SA	AU	EF	COM	EX
Dynamics-RL ^[39]	×	×	√	√	×	×	×
FES (our work)	√	√	√	√	√	√	√

注: √: 支持; ×: 不支持; SGM: scene generation method; ON: Ontology; PR: probability; SA: safety; AU: authenticity; EF: efficiency; COM: complexity; EX: extensibility

6 总结与展望

自动驾驶系统的研发随着 AI 技术的发展正在如火如荼地展开,然而 ADS 系统的复杂性及运行环境的开放、不确定性使得此类系统的安全问题日益严峻.安全关键场景的“稀有诅咒”严重阻碍自动驾驶系统的开发与部署,已经成为限制自动驾驶汽车落地的关键因素.本文针对自动驾驶场景建模及边缘关键场景生成问题,提出一种基于 SML4ADS2.0 的自动驾驶场景建模与边缘关键场景生成方法.该方法集成逻辑场景建模及形式化验证技术,对逻辑场景的安全性进行量化评估,并根据验证结果结合重要性取样技术,加速自动驾驶边缘关键场景的生成.本文所提的研究方法及技术框架,为面向 ADS 的场景建模、仿真、验证分析提供了有效的途径,能够有效解决目前场景驱动的 ADS 系统测试、场景库建设面临的主要问题,特别地,使用基于 UPPAAL-SMC 的逻辑场景评估与基于重要性采样的边缘关键场景生成方法,有效解决安全关键场景的“稀有诅咒”问题,高效生成边缘关键场景,为大规模场景测试奠定了基础,对于提高 ADS 系统的安全性具有重要意义.

在未来的研究中,我们将继续针对自动驾驶安全关键场景的长尾效应,探讨安全关键场景的“稀有诅咒”问题,尤其是发生概率较小的边缘关键场景.如何设计一个检测风险事件发生概率较小的分布是难点,因此需要结合领域知识、样本数据分析与更多尾部分布搜索算法,将在未来工作中进一步生成更多的典型边缘关键具体场景.同时,如何结合本体及本体推理技术,有效地构建 ADS 的场景本体和基于本体推理边缘关键场景,并结合场景库构建方法,设计、实现面向 ADS 的安全关键场景库,用于支持场景仿真、测试、验证分析.

References:

[1] Feng S, Sun HW, Yan XT, Zhu HJ, Zou ZX, Shen SY, Liu HX. Dense reinforcement learning for safety validation of autonomous vehicles. *Nature*, 2023, 615(7953): 620–627. [doi: 10.1038/s41586-023-05732-2]

[2] Zhang XH, Tao JT, Tan KG, Törngren M, Sánchez JMG, Ramli MR, Tao X, Gyllenhammar M, Wotawa F, Mohan N, Nica M, Felbinger H. Finding critical scenarios for automated driving systems: A systematic mapping study. *IEEE Trans. on Software Engineering*, 2023, 49(3): 991–1026. [doi: 10.1109/TSE.2022.3170122]

[3] Sun C, Deng ZJ, Chu WB, Li S, Cao DP. Acclimatizing the operational design domain for autonomous driving systems. *IEEE Intelligent Transportation Systems Magazine*, 2022, 14(2): 10–24. [doi: 10.1109/IMITS.2021.3070651]

[4] Cai JK, Deng WW, Guang HR, Wang Y, Li JK, Ding J. A survey on data-driven scenario generation for automated vehicle testing. *Machines*, 2022, 10(11): 1101. [doi: 10.3390/machines10111101]

[5] David A, Larsen KG, Legay A, Mikučionis M, Poulsen DB. UPPAAL SMC tutorial. *Int’l Journal on Software Tools for Technology Transfer*, 2015, 17(4): 397–415. [doi: 10.1007/s10009-014-0361-y]

[6] Behrmann G, David A, Larsen KG. A tutorial on UPPAAL. In: *Proc. of the 2004 Formal Methods for the Design of Real-time Systems, Int’l School on Formal Methods for the Design of Computer, Communication and Software Systems*. Bertinoro: Springer, 2004. 200–236. [doi: 10.1007/978-3-540-30080-9_7]

[7] Aubry JF, Brinzei N. Stochastic hybrid automaton. In: *Aubry JF, Brinzei N, eds. Systems Dependability Assessment: Modeling with Graphs and Finite State Automata*. Hoboken: John Wiley and Sons Inc., 2015. [doi: 10.1002/9781119053996.ch7]

[8] Hammersley J. *Monte Carlo Methods*. Springer Science & Business Media, 2013.

[9] Marshall AW. The use of multi-stage sampling schemes in Monte Carlo computations. 1954. <https://searchworks.stanford.edu/view/9136039>

[10] Katharopoulos A, Fleuret F. Not all samples are created equal: Deep learning with importance sampling. In: *Proc. of the 35th Int’l Conf. on Machine Learning*. Stockholm: PMLR, 2018. 2525–2534.

[11] Wang LK, Gong Y, Ma XJ, et al. IS-MVSN: Importance sampling-based MVSN. In: *Proc. of the 17th European Conf. on Computer*

- Vision. Tel Aviv: Springer, 2022. 668–683. [doi: [10.1007/978-3-031-19824-3_39](https://doi.org/10.1007/978-3-031-19824-3_39)]
- [12] Müller T, McWilliams B, Rousselle F, Gross M, Novák J. Neural importance sampling. *ACM Trans. on Graphics (TOG)*, 2019, 38(5): 145. [doi: [10.1145/3341156](https://doi.org/10.1145/3341156)]
 - [13] Zhao D, Lam H, Peng H, Bao S, Leblanc DJ, Nobukawa K, Pan CS. Accelerated evaluation of automated vehicles safety in lane-change scenarios based on importance sampling techniques. *IEEE Trans. on Intelligent Transportation Systems*, 2017, 18(3): 595–607. [doi: [10.1109/TITS.2016.2582208](https://doi.org/10.1109/TITS.2016.2582208)]
 - [14] Feng S, Yan XT, Sun HW, Feng YH, Liu HX. Intelligent driving intelligence test for autonomous vehicles with naturalistic and adversarial environment. *Nature Communications*, 2021, 12(1): 748. [doi: [10.1038/s41467-021-21007-8](https://doi.org/10.1038/s41467-021-21007-8)]
 - [15] Arief M, Huang ZY, Kumar GKS, Bai YL, He SY, Ding WH, Lam H, Zhao D. Deep probabilistic accelerated evaluation: A robust certifiable rare-event simulation methodology for black-box safety-critical systems. In: *Proc. of the 24th Int'l Conf. on Artificial Intelligence and Statistics*. PMLR, 2021. 595–603.
 - [16] Li B, Du DH, Chen SC, Wei MJ, Zheng CH, Zhang XY. SML4ADS: An open DSML for autonomous driving scenario representation and generation. In: *Proc. of the 37th IEEE/ACM Int'l Conf. on Automated Software Engineering*. Rochester: ACM, 2022. 145. [doi: [10.1145/3551349.3561169](https://doi.org/10.1145/3551349.3561169)]
 - [17] Du DH, Li B, Zheng CH, Zhang XY. A novel and pragmatic scenario modeling framework with verification-in-the-loop for autonomous driving systems. In: *Proc. of the 45th IEEE/ACM Int'l Conf. on Software Engineering: New Ideas and Emerging Results*. Melbourne: IEEE, 2023. 84–89. [doi: [10.1109/ICSE-NIER58687.2023.00021](https://doi.org/10.1109/ICSE-NIER58687.2023.00021)]
 - [18] Li B. Research on modeling, simulation and verification of autonomous driving scenarios [MS. Thesis]. Shanghai: East China Normal University, 2022 (in Chinese with English abstract). [doi: [10.27149/d.cnki.ghdsu.2022.005494](https://doi.org/10.27149/d.cnki.ghdsu.2022.005494)]
 - [19] Deng WW, LI JK, Ren BT, Wang WQ, Ding J. A survey on automatic simulation scenario generation methods for autonomous driving. *China Journal of Highway and Transport*, 2022, 35(1): 316–333 (in Chinese with English abstract). [doi: [10.3969/j.issn.1001-7372.2022.01.027](https://doi.org/10.3969/j.issn.1001-7372.2022.01.027)]
 - [20] Nilsson J, Sjöberg J. Strategic decision making for automated driving on two-lane, one way roads using model predictive control. In: *Proc. of the 2013 IEEE Intelligent Vehicles Symp. Gold Coast: IEEE*, 2013. 1253–1258. [doi: [10.1109/IVS.2013.6629638](https://doi.org/10.1109/IVS.2013.6629638)]
 - [21] ASAM. OpenDRIVE Standard. 2021. <https://www.asam.net/standards/detail/opendrive/>
 - [22] Barsi A, Poto V, Tihanyi V. Creating OpenCRG road surface model from terrestrial laser scanning data for autonomous vehicles. In: *Proc. of the 2nd Vehicle and Automotive Engineering Conf. Miskolc: Springer*, 2018. 361–369. [doi: [10.1007/978-3-319-75677-6_30](https://doi.org/10.1007/978-3-319-75677-6_30)]
 - [23] Chaplier J, That TN, Hewatt M, Gallée G. Toward a standard: RoadXML, the road network database format. In: *Proc. of the 2010 Driving Simulation Conf. 2010*. 211–220.
 - [24] Haklay M, Weber P. OpenStreetMap: User-generated street maps. *IEEE Pervasive Computing*, 2008, 7(4): 12–18. [doi: [10.1109/MPRV.2008.80](https://doi.org/10.1109/MPRV.2008.80)]
 - [25] Althoff M, Koschi M, Manzing S. CommonRoad: Composable benchmarks for motion planning on roads. In: *Proc. of the 2017 IEEE Intelligent Vehicles Symp. Los Angeles: IEEE*, 2017. 719–726. [doi: [10.1109/IVS.2017.7995802](https://doi.org/10.1109/IVS.2017.7995802)]
 - [26] ASAM. OpenSCENARIO Standard. 2021. <https://www.asam.net/standards/detail/openscenario/v200/>
 - [27] Fremont DJ, Dreossi T, Ghosh S, Yue XY, Sangiovanni-Vincentelli AL, Seshia SA. Scenic: A language for scenario specification and scene generation. In: *Proc. of the 40th ACM SIGPLAN Conf. on Programming Language Design and Implementation*. Phoenix: ACM, 2019. 63–78. [doi: [10.1145/3314221.3314633](https://doi.org/10.1145/3314221.3314633)]
 - [28] Dosovitskiy A, Ros G, Codevilla F, Lopez A, Koltun V. CARLA: An open urban driving simulator. In: *Proc. of the 1st Annual Conf. on Robot Learning*. Mountain View: PMLR, 2017. 1–16.
 - [29] Menzel T, Bagschik G, Maurer M. Scenarios for development, test and validation of automated vehicles. In: *Proc. of the 2018 IEEE Intelligent Vehicles Symp. Changshu: IEEE*, 2018. 1821–1827. [doi: [10.1109/IVS.2018.8500406](https://doi.org/10.1109/IVS.2018.8500406)]
 - [30] Chen W, Kloul L. An ontology-based approach to generate the advanced driver assistance use cases of highway traffic. In: *Proc. of the 10th Int'l Joint Conf. on Knowledge Discovery, Knowledge Engineering and Knowledge Management*. SCITEPRESS, 2018. 75–83.
 - [31] Elgharawy M, Schwarzhaupt A, Frey M, Gauterin F. Ontology-based adaptive testing for automated driving functions using data mining techniques. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2019, 66: 234–251. [doi: [10.1016/j.trf.2019.07.021](https://doi.org/10.1016/j.trf.2019.07.021)]
 - [32] Hungar H. A concept of scenario space exploration with criticality coverage guarantees. In: *Proc. of the 9th Int'l Symp. on Leveraging Applications of Formal Methods*. Rhodes: Springer, 2020. 293–306. [doi: [10.1007/978-3-030-61467-6_19](https://doi.org/10.1007/978-3-030-61467-6_19)]
 - [33] Klischat M, Althoff M. Generating critical test scenarios for automated vehicles with evolutionary algorithms. In: *Proc. of the 2019 IEEE Intelligent Vehicles Symp. Paris: IEEE*, 2019. 2352–2358. [doi: [10.1109/IVS.2019.8814230](https://doi.org/10.1109/IVS.2019.8814230)]
 - [34] Tuncali CE, Pavlic TP, Fainekos G. Utilizing S-TaLiRo as an automatic test generation framework for autonomous vehicles. In: *Proc. of*

- the 19th IEEE Int'l Conf. on Intelligent Transportation Systems. Rio de Janeiro: IEEE, 2016. 1470–1475. [doi: [10.1109/ITSC.2016.7795751](https://doi.org/10.1109/ITSC.2016.7795751)]
- [35] Klück F, Zimmermann M, Wotawa F, Nica M. Genetic algorithm-based test parameter optimization for ADAS system testing. In: Proc. of the 19th IEEE Int'l Conf. on Software Quality, Reliability and Security. Sofia: IEEE, 2019. 418–425. [doi: [10.1109/QRS.2019.00058](https://doi.org/10.1109/QRS.2019.00058)]
- [36] Du P, Driggs-Campbell K. Finding diverse failure scenarios in autonomous systems using adaptive stress testing. SAE Int'l Journal of Connected and Automated Vehicles, 2019, 2(4): 241–251. [doi: [10.4271/12-02-04-0018](https://doi.org/10.4271/12-02-04-0018)]
- [37] Corso A, Du P, Driggs-Campbell K, Kochenderfer MJ. Adaptive stress testing with reward augmentation for autonomous vehicle validation. In: Proc. of the 2019 IEEE Intelligent Transportation Systems Conf. Auckland: IEEE, 2019. 163–168. [doi: [10.1109/ITSC.2019.8917242](https://doi.org/10.1109/ITSC.2019.8917242)]
- [38] Ding WH, Chen BM, Li B, Eun KJ, Zhao D. Multimodal safety-critical scenarios generation for decision-making algorithms evaluation. IEEE Robotics and Automation Letters, 2021, 6(2): 1551–1558. [doi: [10.1109/LRA.2021.3058873](https://doi.org/10.1109/LRA.2021.3058873)]
- [39] Li JK, Deng WW, Ren BT, Wang WQ, Ding J. Automatic driving edge scene generation method based on scene dynamics and reinforcement learning. Automotive Engineering, 2022, 44(7): 976–986 (in Chinese with English abstract). [doi: [10.19562/j.chinasae.qcgc.2022.07.004](https://doi.org/10.19562/j.chinasae.qcgc.2022.07.004)]

附中文参考文献:

- [18] 李博. 面向自动驾驶场景的建模、仿真生成及验证方法研究 [硕士学位论文]. 上海: 华东师范大学, 2022. [doi: [10.27149/d.cnki.ghdsu.2022.005494](https://doi.org/10.27149/d.cnki.ghdsu.2022.005494)]
- [19] 邓伟文, 李江坤, 任秉韬, 王文奇, 丁娟. 面向自动驾驶的仿真场景自动生成方法综述. 中国公路学报, 2022, 35(1): 316–333. [doi: [10.3969/j.issn.1001-7372.2022.01.027](https://doi.org/10.3969/j.issn.1001-7372.2022.01.027)]
- [39] 李江坤, 邓伟文, 任秉韬, 王文奇, 丁娟. 基于场景动力学和强化学习的自动驾驶边缘测试场景生成方法. 汽车工程, 2022, 44(7): 976–986. [doi: [10.19562/j.chinasae.qcgc.2022.07.004](https://doi.org/10.19562/j.chinasae.qcgc.2022.07.004)]



杜德慧(1979—), 女, 博士, 教授, 博士生导师, CCF 高级会员, 主要研究领域为可信软件, 信息物理融合系统建模与验证, 人工智能安全可信理论及验证.



朱珍珍(1995—), 女, 硕士生, 主要研究领域为可信软件, 自动驾驶场景生成.



叶振(1997—), 男, 博士生, 主要研究领域为人工智能系统的可信建模与验证, 自动驾驶系统测试, 多智能体强化学习.



李家蕴(1997—), 女, 硕士生, 主要研究领域为机器学习, 遗传算法, 自动驾驶场景生成.



郑成行(2000—), 男, 硕士生, 主要研究领域为深度学习, 优化算法, 自动驾驶场景生成.