

基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策*

陈洁娜^{1,2,3}, 张铭茁^{1,2,3}, 杜德慧^{1,2,3}, 李 博^{1,2,3}, 聂基辉^{1,2,3}, 任婧瑶^{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: 为汽车自动驾驶提供安全高效的自动驾驶行为决策, 是汽车自动驾驶领域面临的挑战性问题之一。目前, 随着自动驾驶行业的蓬勃发展, 工业界与学术界提出了诸多自动驾驶行为决策方法, 但由于汽车自动驾驶行为决策受环境不确定因素的影响, 决策本身也要求实效性 & 高安全性, 现有的行为决策方法难以完全支撑这些要素。针对以上问题, 提出了一种基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法。首先, 基于领域本体分析自动驾驶场景元素之间的语义关系, 并结合 LSTM 模型预测场景中动态实体的意图, 进而为构建贝叶斯网络提供驾驶场景理解信息; 然后, 通过贝叶斯网络推理特定场景的自动驾驶行为决策, 并使用 RoboSim 模型的状态迁移承载行为决策的动态执行过程, 以减少贝叶斯网络推理的冗余操作, 提高了决策生成的效率。RoboSim 模型具有平台无关、能模拟仿真执行周期的特点, 并支持多种形式化的验证技术。为确保行为决策的安全性, 使用模型检测工具 UPPAAL 对 RoboSim 模型进行验证分析。最后, 结合变道超车场景案例, 进一步证实所提方法的可行性, 为设计安全、高效的自动驾驶行为决策提供了一种可行的途径。

关键词: 汽车自动驾驶; 行为决策; 贝叶斯网络; RoboSim; UPPAAL

中图法分类号: TP18

中文引用格式: 陈洁娜, 张铭茁, 杜德慧, 李博, 聂基辉, 任婧瑶. 基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策. 软件学报, 2023, 34(8): 3836–3852. <http://www.jos.org.cn/1000-9825/6594.htm>

英文引用格式: Chen JN, Zhang MZ, Du DH, Li B, Nie JH, Ren JY. Autonomous Driving Behavior Decision-making with RoboSim Model Based on Bayesian Network. Ruan Jian Xue Bao/Journal of Software, 2023, 34(8): 3836–3852 (in Chinese). <http://www.jos.org.cn/1000-9825/6594.htm>

Autonomous Driving Behavior Decision-making with RoboSim Model Based on Bayesian Network

CHEN Jie-Na^{1,2,3}, ZHANG Ming-Zhuo^{1,2,3}, DU De-Hui^{1,2,3}, LI Bo^{1,2,3}, NIE Ji-Hui^{1,2,3}, REN Jing-Yao^{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: The realization of safe and efficient behavior decision-making has become a challenging issue for autonomous driving. As autonomous driving industries develop vigorously, industrial professionals and academic members have proposed many autonomous driving behavior decision-making approaches. However, due to the influence of environmental uncertainties as well as requirements for effectiveness and high security of the decision, existing approaches fail to take all these factors into account. Therefore, this study proposes an autonomous driving behavior decision-making approach with the RoboSim model based on the Bayesian network. First, based on

* 基金项目: 国家自然科学基金 (61972153); 科技部重点项目 (2020AAA0107800)

本文由“智能系统的分析和验证”专题特约编辑明仲教授、张立军教授和秦胜潮教授推荐。

收稿时间: 2021-09-05; 修改时间: 2021-10-14; 采用时间: 2022-01-10; jos 在线出版时间: 2022-01-28

CNKI 网络首发时间: 2023-01-19

domain ontology, the study analyzes the semantic relationship between elements in autonomous driving scenarios and predicts the intention of dynamic entities in scenarios by the LSTM model, so as to provide driving scenario information for establishing the Bayesian network. Next, the autonomous driving behavior decision-making in specific scenarios is inferred by the Bayesian network, and the state transition of the RoboSim model is employed to carry the dynamic execution of behavior decision-making and eliminate the redundant operation of the Bayesian network, thus improving the efficiency of decision-making. The RoboSim model is platform-independent. In addition, it can simulate the decision-making cycle and support validation technologies in different forms. To ensure the safety of the behavior decision-making, this study uses a model checking tool UPPAAL to verify and analyze the RoboSim model. Finally, based on lane change and overtaking cases, this study validates the feasibility of the proposed approach and provides a feasible way to achieve safe and efficient autonomous driving behavior decision-making.

Key words: autonomous driving; behavior decision-making; Bayesian network; RoboSim; UPPAAL

近年来,自动驾驶引起了学术界和工业界的广泛关注.自动驾驶系统 (autonomous driving system, ADS) 包含“感知-决策-执行”这3大模块^[1],其中决策模块对感知模块获取的数据进行分析,并根据车辆自身状态及周围环境信息做出当前驾驶场景下的最优决策,然后将相应的指令传输给执行模块,以执行具体的决策动作.决策的优劣将直接影响自动驾驶的安全,因此研究高效可靠的行为决策方法对自动驾驶技术的发展具有重要的意义.

目前,由于自动驾驶行为决策的失效引发了一系列安全事故.例如,2021年3月11日,一辆特斯拉 Model Y 在美国底特律西南部一个十字路口撞上一辆正在行驶的车辆,而该自动驾驶车辆未采取任何减速或制动的行为决策^[2].这说明生成安全可信的行为决策作为自动驾驶中的关键技术仍面临诸多挑战.首先,自动驾驶场景具有高度的复杂性与不确定性^[3],如道路路网结构的复杂性、环境因素的多样性以及其他车辆、行人意图的不确定性等.因此,对自动驾驶场景元素之间的语义关系进行分析,并在决策算法中充分考虑环境的不确定性因素,是影响行为决策准确性的关键所在^[4].其次,自动驾驶车辆在行驶过程中应考虑决策执行的高效性,即对复杂的环境信息及时做出响应,并生成安全的行为决策.在同一自动驾驶场景中,驾驶车辆的状态以及周围的环境信息在一段连续时间内保持一致,若重复执行决策算法势必会产生诸多冗余计算.因此,如何对同一场景下的决策进行优化、重用,是提高决策生成效率的关键.此外,保证自动驾驶行为决策的安全性是自动驾驶车辆需考虑的首要问题.在行驶过程中,自动驾驶车辆会与其他交通参与者发生行为交互,错误的决策将造成严重的后果.因此,对自动驾驶决策的安全性进行验证分析也是目前亟需解决的问题之一.

针对上述自动驾驶行为决策生成存在的问题,本文提出了一种基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法.首先,利用领域本体^[5]对驾驶场景中的语义关系进行分析,并构建基于长短期记忆网络 (long short term memory, LSTM) 的他车意图预测模型^[6],为构建面向 ADS 行为决策的贝叶斯网络提供场景理解信息并利用贝叶斯网络进行最大后验概率推理得到当前场景下的最优决策.其次,以该场景下的车辆状态为状态节点,以贝叶斯网络生成的最优决策为迁移边上的动作,环境因素为迁移边上的条件,构建面向 ADS 行为决策的 RoboSim^[7]模型;结合我们前期的工作^[8],将 RoboSim 模型自动转化为 UPPAAL^[9]支持的时间自动机网络 (network of timed automata, NTA),借助模型检测技术验证分析 RoboSim 模型的安全性.若通过验证,则使用 RoboSim 模型进行决策,以减少使用贝叶斯推理产生决策的冗余操作,提高行为决策的效率;若该 RoboSim 模型未通过安全验证,则回溯修改贝叶斯网络参数,以优化决策模型.

综上,本文主要工作包括以下3部分内容.

(1) 提出一种面向 ADS 行为决策的贝叶斯网络模型,利用领域本体以及他车意图预测 LSTM 模型为构建贝叶斯网络提供驾驶场景信息,通过贝叶斯网络推理特定场景的自动驾驶行为决策.

(2) 构建 RoboSim 模型承载行为决策的动态执行,以减少贝叶斯网络推理的冗余操作,提高了决策生成的效率.

(3) 基于模型检测工具 UPPAAL 验证分析 RoboSim 模型的安全性,为自动驾驶提供安全可靠的决策依据.

本文第1节介绍基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法的总体框架.第2节阐述了 ADS 领域本体和他车意图预测 LSTM 模型为贝叶斯网络构建提供的驾驶场景理解信息,以及面向 ADS 行为决策的贝叶斯网络的构建和推理过程.第3节介绍如何基于贝叶斯网络生成的决策信息以及驾驶场景信息构建面向 ADS

行为决策的 RoboSim 模型, 并对其进行验证分析. 第 4 节通过变道超车这一自动驾驶典型场景对上述方法进行案例分析, 说明本文方法的可行性. 第 5 节对相关工作进行对比、分析. 最后, 总结全文的主要工作并对后续工作扩展进行了讨论.

1 总体框架

根据目前自动驾驶行为决策所存在的问题, 本文提出了一种基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法. 该方法的核心思想是利用 ADS 领域本体模型和他车意图预测 LSTM 模型, 为构建面向 ADS 行为决策的贝叶斯网络提供场景理解信息. 然后, 利用贝叶斯网络推理得到的决策信息、车辆状态信息和环境信息构建面向 ADS 行为决策的 RoboSim 模型. 最后, 借助模型转换技术生成 UPPAAL 支持的 NTA 模型并对其进行形式化验证分析. 本文的总体框架如图 1 所示.




图 1 基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法框架

(1) 面向 ADS 行为决策的贝叶斯网络

本文根据道路车辆预期功能安全标准 ISO 21448^[10], 在考虑驾驶场景的层次性与关联性的基础上, 分析驾驶

场景中的各个元素之间的语义关系,以构建 ADS 领域本体. 本文将自动驾驶场景因素分为 3 类,即车辆状态、环境因素和行为决策. 在此基础上,训练他车意图预测 LSTM 模型,以车辆历史轨迹数据作为输入,车辆意图的分类结果作为输出. 然后,根据本体模型为贝叶斯网络提供驾驶场景领域知识,为不同的场景选择合适的变量作为贝叶斯网络的节点;同时,将 LSTM 模型的预测结果作为贝叶斯网络中“其他车辆意图”节点的概率,基于驾驶经验与专家领域知识确定网络结构,通过仿真数据确定条件概率表 (conditional probability table, CPT). 最终,生成面向 ADS 行为决策的贝叶斯网络,该网络支持通过最大后验概率推理得到当前驾驶场景下的驾驶行为决策.

(2) 面向 ADS 行为决策的 RoboSim 模型构建及验证

结合仿真数据和已生成的贝叶斯网络,通过抽象状态和迁移,以车辆状态作为状态节点,环境作为边上的迁移条件,贝叶斯网络在该场景下推理得到的最优决策作为边上的迁移动作,可以得到面向 ADS 行为决策的 RoboSim 模型. 基于本课题组前期的工作,将 RoboSim 模型转换为 NTA 模型,使用 UPPAAL 对模型进行安全性验证分析,保证了该行为决策模型的安全性. 若未通过验证,说明决策模型存在问题,需要回溯优化贝叶斯网络,进而更新 RoboSim 决策模型.

基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法可以为自动驾驶提供准确、安全、高效的行为决策. 本文将重点讨论如何利用领域本体和 LSTM 来构建面向 ADS 行为决策的贝叶斯网络,以及如何进一步生成面向 ADS 行为决策的 RoboSim 模型并对其进行验证分析.

2 面向 ADS 行为决策的贝叶斯网络

自动驾驶车辆在进行决策的过程中,首先需要对驾驶环境有深层次的理解,不断对驾驶环境中的变化进行估计、判断和预测,再利用场景信息得到当前驾驶场景下的决策动作. 贝叶斯网络是一种结构灵活的概率图模型^[1],它的边表示变量之间的依赖关系,用概率分布表示依赖关系的强弱,从而将先验信息或领域知识与数据样本有机结合起来. 此外,贝叶斯网络能够结合来自不同来源的本地信息,从而在不确定性的环境下做出决策. 因此,本文通过 ADS 领域本体为贝叶斯网络提供驾驶场景因素之间的语义关系,为不同的场景选择合适的变量作为贝叶斯网络的节点并确定网络结构;同时利用 LSTM 对他车意图预测,得到的预测结果作为贝叶斯网络中“其他车辆意图”节点的概率;然后通过仿真数据确定条件概率表 (CPT);最后,通过贝叶斯概率推理得到当前驾驶场景下自动驾驶车辆的驾驶行为决策.

2.1 构建面向 ADS 行为决策的贝叶斯网络

本节将分别介绍 ADS 领域本体和基于 LSTM 的他车意图预测模型,并在此基础上构建面向 ADS 行为决策的贝叶斯网络模型.

2.1.1 ADS 领域本体

本体是对客观事物的系统化描述,能够表达特定领域中概念之间的语义关系. ADS 领域本体可以对驾驶场景中的各个元素及其关系进行语义描述,从而系统地指导贝叶斯网络节点选择以及节点之间的依赖关系构建,更好地把驾驶信息融入基于贝叶斯网络的行为决策算法中.

本文基于道路车辆预期功能安全标准 ISO 21448,在考虑驾驶场景的层次性与关联性的基础上,提取驾驶场景中的道路结构、交通标识和交通参与者等信息,将与决策相关的内容分为了以下 3 类:自身车辆类、行为类、环境类,并为其定义相应的数据属性、对象属性,得到面向 ADS 领域本体模型. 本体类的层次关系如下.

(1) 自身车辆类 (ego): 描述了 ego 车辆自身的状况,如当前车辆的速度、加速度、与障碍物之间的相对距离、当前所处车道以及车辆行驶方向.

(2) 行为类 (behavior): 行为类可以分为纵向行为与横向行为,其中纵向行为包括加速、减速、匀速行驶,横向行为包括向左转、右转、与保持当前车道.

(3) 环境类 (environment): 表示自动驾驶车辆中的环境因素,主要由障碍物、天气、路网结构组成. 其中障碍物分为行人 (pedestrian)、车辆 (vehicle),车辆描述其他车辆的驾驶状态,包括其他车辆的速度、加速度、与 ego

车辆的相对距离和方向、与当前车道之间的角度等. 天气描述当前的天气状况, 主要包括晴天、雨天、雾天和多云等. 路网结构表示自动驾驶车辆行驶道路的状况. 包括路口、车道、车道线、人行横道、路面标记、交通灯和交通标志等.

在给出类的定义之后, 所描述的对象属性和于其他对象的关系需要分别用数据属性和关系属性进行表达. 表 1 给出了自动驾驶场景中的部分关系属性与数据属性, 其中关系属性的定义域和值域都是类, 数据属性的定义域为类, 值域为数据类型. 如自动驾驶车辆 ego 具有横向驾驶行为与纵向驾驶行为, 故具有关系属性 decision, 其定义域为 ego, 值域为 behavior; 数据属性有 currentVelocity, 其定义域为 ego, 值域为 double.

表 1 自动驾驶领域本体部分关系属性和数据属性

属性种类	属性名称	定义域	值域
关系属性	decision	ego	behavior
	currentLane	ego	lane
	hasFrontObstacle	ego	vehicle
	hasLeftLane	lane	lane
	hasTrafficLight	RoadPart	TrafficLight
数据属性	currentVolecity	ego	double
	currentDirection	ego	double
	ObsIntension	Obstacle	string
	ObsVelocity	Obstacle	double

ADS 领域本体模型实现了对驾驶场景中类的状态和语义关系的系统性描述, 充分表达了驾驶场景中多元异构以及参与者之间的时空交互信息, 为后续贝叶斯网络根据驾驶场景信息得到最佳决策动作提供了场景理解信息.

2.1.2 基于 LSTM 的他车意图预测模型

自动驾驶场景中, ADS 行为决策系统需要处理许多难以避免的不确定性因素, 其中最重要的因素之一就是周围车辆未来的运动状态的随机性. 目前, 车载传感器只能对自动驾驶车辆周边的交通参与者进行状态监测, 但无法对其未来的运动状态进行预测. 由于车辆历史轨迹数据是时间序列信息, 而 LSTM 模型对时序数据具有强大的信息挖掘能力与深度表征能力, 并引入“门”机制保存信息, 能有效处理长序列, 因此, 本文基于 LSTM 模型对自动驾驶车辆周围车辆进行意图预测. 模型框架如图 2 所示. 该模型主要由 3 个部分组成.




图 2 基于 LSTM 的他车意图预测模型

- (1) 输入层: 为每个时间步长目标车辆的历史轨迹信息, 用特征向量 X_t 表示.
- (2) LSTM 层: 在每一个时刻 t , LSTM 单元体接收此刻的输入 X_t 和上一个时刻历史轨迹信息的隐藏状态 X_{t-1} , 以更新当前的历史轨迹信息的隐藏状态 h_t .
- (3) 全连接层: 接收 LSTM 层的输出并对其做分类, 将最后一个节点 $y_{seq_length} = (y_1, y_2, y_3)$ 作为分类输出结果, y_1, y_2, y_3 分别表示左转、右转、执行的概率, 并将其作为贝叶斯网络节点车辆意图的参数.

2.1.3 基于 ADS 领域本体和 LSTM 模型构建贝叶斯网络

在 ADS 领域本体知识的指导下, 自动驾驶中的多元异构信息及其层次关系能够被充分反映在贝叶斯决策网

络中; 而基于 LSTM 的他车意图预测模型为贝叶斯决策网络提供了场景中的车辆意图的不确定性信息, 两者结合能够有效构建 ADS 行为决策贝叶斯网络. 贝叶斯网络可以用一个二元组 $B = \langle G, P \rangle$ 来表示, 其中 $G = \langle N, E \rangle$ 为一个有向无环图, N 为节点集合, E 为边的集合, 代表两个节点之间有直接依赖关系. 因此, 贝叶斯网络的构建主要分为两步.

(1) 确定节点及节点之间的依赖关系: 基于本体中类的分层结构, 本文将贝叶斯的节点分为 3 类并为其设计分层结构, 分别为车辆状态节点、环境因素节点、行为决策节点, 其中在环境因素节点内添加了关于车辆意图预测节点, 以 LSTM 他车意图预测模型得到的分类结果作为意图预测节点上的概率分布, 并基于驾驶经验与专家领域知识确定网络结构.

(2) 参数学习: 即确定各个节点的 CPT. 在数据集完整时, 贝叶斯网络参数学习的主要方法为最大似然估计方法和贝叶斯方法. 在具体实现中, 本文选择了 GeNIe^[12] 工具作为可视化构建贝叶斯网络的工具并进行参数学习.

2.2 基于贝叶斯网络的行为决策推理

在确定贝叶斯网络结构以及参数后, 下一步的工作就是进行概率推理. 贝叶斯网络推理是指利用确定的贝叶斯网络结构以及节点的 CPT, 输入当前驾驶环境的实时信息计算决策节点的后验概率.

在计算最大后验概率的过程中, 设影响某节点 X 的节点集合为 ϵ , 则 $X = x_i$ 的后验概率可以表示为: $P(x_i|\epsilon) = \alpha\lambda(x_i)\pi(x_i)$, 其中 α 为归一项, 保证 $\sum_{\{x_i\}} P(x_i|\epsilon) = 1$, $\lambda(x_i)$ 表示沿着有向边由 X 的父节点传送给 X 的消息, $\pi(x_i)$ 表示由 X 沿着有向边的反方向传递给其他节点的消息. 算法 1 给出了实现贝叶斯概率推理的伪代码, 第 4 行与第 5 行将车辆以及环境相关的信息输入对应的贝叶斯节点中, 第 6 行根据车辆与环境信息计算决策节点的最大后验概率, 第 7 行将取值最大的值作为当前环境下采取的横向驾驶动作与纵向驾驶动作. 实现贝叶斯推理决策的具体效果, 本文将在第 4.2 节展开具体描述.

算法 1. 面向 ADS 的贝叶斯网络行为决策推理算法.

输入: 自动驾驶仿真数据集 *DataSet*, 已知结构和参数的贝叶斯网络 *Bayesian*, LSTM 预测结果 *LSTM_output*;
输出: 决策节点置信度.

```

1. begin
2.   for all data ∈ DataSet do:
3.     //将与 ego 车相关的信息离散化并输入到车辆状态节点
4.     ego_data = Discretize(data.ego);
5.     //将与环境相关的信息以及 LSTM 预测结果输入到对应的环境状态节点
6.     environment_data = Discretize(data.env, LSTM_output);
7.     //车辆状态节点与环境状态节点向其子孙节点传递消息, 并计算决策节点的最大后验概率
8.     Decision(t) = Propagate(ego_data, environment_data);
9.     //将最大后验概率对应的决策状态作为当前环境下采取的横向驾驶动作与纵向驾驶动作
10.    Set_Maximum(Decision(t));
11.  end for
12. end

```

3 基于贝叶斯网络的 RoboSim 模型构建及验证

若直接通过训练好的贝叶斯网络对自动驾驶行为进行概率推理做出决策, 不考虑缓存相似场景的行为决策, 会产生一系列冗余计算, 导致计算效率下降. 基于此, 本节讨论如何构建面向 ADS 行为决策的 RoboSim 模型, 以承载贝叶斯网络行为决策的动态执行, 具体地, 以其内部的状态机作为行为决策的载体, 抽象出面向特定场景的车

辆状态、环境约束及行为决策动作,从而大幅减少决策过程中的冗余操作,提高计算效率。

作为平台无关的仿真建模语言,RoboSim 可以很好地捕捉仿真执行中的周期语义,且其支持多种形式化验证技术对模型的安全性进行验证分析,包括支持 CSP 验证的 FDR^[13],概率模型验证工具 PRISM^[14],以及实时系统验证工具 UPPAAL 等。此外,RoboSim 的支撑工具 RoboTool^[15]实现了其元模型设计、图形化和文本化建模、形式化模型转换等功能,为模型的构建及验证提供了有效的技术支持。其中,将 RoboSim 模型自动转换为 NTA 模型,结合规约语言时间计算树逻辑 (timed computation tree logic, TCTL)^[16],并利用 UPPAAL 工具对其进行形式化验证分析为本团队的前期工作积累^[8]。因此,本文选择使用 UPPAAL 工具对生成的 RoboSim 模型进行验证分析,以确保生成决策的安全性。

3.1 机器人仿真建模语言 RoboSim

RoboSim 是一个平台无关的机器人仿真建模语言,拥有结构良好的图形化和文本化语法,并支持多种形式化验证技术。

基于仿真建模的特性,RoboSim 融入了仿真执行周期的概念。一个仿真执行周期可表示为寄存器读、执行、寄存器写 3 个操作。因此,RoboSim 模型不仅可以用于机器人仿真,也能用于自动驾驶仿真。由于仿真数据为指定采样周期的离散数据,本文把数据的采样周期抽象为一个 RoboSim 的仿真执行周期,具体表现为:寄存器读用于读取车辆初始状态和当前环境参数,寄存器写用于根据当前环境信息输出车辆行为决策,以让车辆的物理执行器进一步执行。基于 RoboSim 的周期执行过程如图 3 所示。




图 3 RoboSim 的周期执行过程

一个 RoboSim 模型可定义为一个二元组 $(module, Interface)$, 其中:

- **module**: 表示一个模块,用于指定执行周期、物理平台的接口以及并行运行的控制器,它可以表示为一个三元组 $(cycle, platform, Controller)$ 。其中, *cycle* 表示仿真执行周期; *platform* 表示物理平台提供或定义的接口,以接收外部环境参数和发送内部控制信息; *Controller* 表示并行运行的控制器集合,每个控制器 *controller* 由一个或多个状态机 (state machine) 组成,每个状态机类似 UML 中的状态机模型,用于建模内部控制逻辑,包含了状态机体 (state machine body) 和输入输出接口等,状态机体用于表示状态的迁移。

- **Interface**: 表示接口的集合,接口中声明了操作和事件,操作代表物理平台提供的服务,并由控制器和状态机获取;事件用于各个组件之间的交互。

相比于传统的 UML 状态机模型,采用 RoboSim 模型除了可以很好地模拟自动驾驶车辆的执行周期,还能够方便地转换至其他仿真或验证平台进行仿真及验证分析,为抽象自动驾驶行为决策模型提供了较好的载体。

3.2 构建面向 ADS 行为决策的 RoboSim 模型

根据上一节针对 RoboSim 模型的定义,一个完整的面向 ADS 行为决策的 RoboSim 模型包括模块、接口、控制器、状态机等。除状态机中的状态机体外,其余组件的构建与自动驾驶行为决策的关联性不大,故本文不作赘述。下面将重点介绍如何构建 RoboSim 模型中的状态机体,以承载由车辆状态信息、环境信息及贝叶斯网络推理得到的决策信息。

一个 RoboSim 状态机体可定义为 $(State, Transition)$, 分别表示状态和迁移的集合。其中,单个状态和单条迁移定义如下。

- **state**: 唯一标识了当前车辆的状态信息 *ego_state*, 包括车辆当前运行速度、转向角度、车道信息、与其他车辆的相对距离信息等;

- **transition**: 由元组 $(source, target, condition, action)$ 组成。其中 *source* 和 *target* 为迁移的起始和终止状态;

condition 标识了当前的环境信息, 需要扩展为以 $\wedge$ (合取) 连接的表达式, 并通过提供接口由上层组件输入; *action* 标识了当前的行为决策信息, 并通过定义接口传递给上层组件. 决策信息表示为 $\$decision(acc, angle)$ 表达式, 其中 $\$$ 指操作不立即通过接口传递, 而是等到周期结束时传递, *acc* 和 *angle* 分别用具体的决策值替换. 此外, 该状态机体在每一个决策动作结束后, 通过 RoboSim 中的特殊事件 *exec* 标识当前执行周期的结束和下一执行周期的开始.

算法 2 给出了 RoboSim 模型中状态机体的状态及迁移关系生成的伪代码, 以自动驾驶仿真数据集和训练好的面向 ADS 决策的贝叶斯网络为输入, 输出 RoboSim 模型的状态机体中包含的状态及迁移关系. 算法的执行大致流程为: 遍历仿真数据集中的每一条数据, 根据贝叶斯网络推理得到的决策信息以及环境信息和车辆的当前状态信息, 计算车辆下一时刻的状态, 并将新的状态信息存入状态集合中, 同时构建迁移边, 并将新的迁移边信息存入迁移集合中. 算法中还加入了为贝叶斯网络优化方法所保留的接口, 以保证通过 RoboSim 模型所做的决策不会导致车辆进入不安全状态, 即当识别到车辆的下一个状态 *next_state* 为不安全状态时, 会调用该优化方法调整贝叶斯网络, 并重做当前决策, 直到下一个状态安全为止. 该回溯优化将作为下一阶段的工作重点进行探讨, 本文不予讨论.

算法 2. RoboSim 状态机体的状态及迁移生成算法.

输入: 数据集 *DateSet*, 训练好的贝叶斯网络 *Bayesian*;

输出: 状态集合 *State*, 迁移条件集合 *Transition*.

```

1. begin
2. create an initial junction init;
3. create a set State; //状态集合, 用于存储 RoboSim 状态机体中的状态
4. create a set Transition; //迁移边集合, 用于存储 RoboSim 状态机中的迁移
5. create a state next_state; // 用于记录下一个状态的状态信息
6. for all data  $\in$  DateSet do:
7.   if data is initial data then //如果为场景的初始状态
8.     state = data.ego_state; //则将数据集中的车辆状态信息作为当前状态
9.     if not State.has(state) then
10.      State.add(state);
11.     end if
12.     if Transition.has((init, state, null, null)) then
13.      Transition.add((init, state, null, null));
14.     end if
15.   else
16.     state = next_state; //保存由上一个循环计算出的下一个状态;
17.   end if
18.   decision = Bayesian(state, data.env); //利用贝叶斯网络根据当前车辆状态信息和环境信息推理出决策
19.   next_state = count(state, decision); //根据决策计算出下一个状态
20.   if not State.has(next_state) then
21.     if next_state is not a safe state then
22.      //若进入不安全状态, 回溯优化贝叶斯网络
23.      Backtracking and optimizing the Bayesian network;
24.     else
25.      State.add(next_state);
26.     end if

```

```

27. end if
28. if not Transition.has((state, next_state, env, decision)) then
29.     Transition.add((state, next_state, data.env, decision));
30. end if
31. end for
32. end

```

3.3 基于 UPPAAL 的 RoboSim 模型验证及分析

UPPAAL 是一种支持实时系统建模及验证的模型检测工具, 其输入模型为 NTA 模型, 并使用 TCTL 进行性质规约. 通过已实现的模型转换技术, 可以直接将生成的面向 ADS 行为决策的 RoboSim 模型转换为 UPPAAL 支持的 NTA 模型. 该 NTA 包含了表示 RoboSim 模型中模块、控制器和状态机 3 个组件执行周期的时间自动机 (timed automata, TA) 模型, 由状态机体转换生成的 TA 模型以及相应的变量和通道声明. 其中, $\$decision(acc, angle)$ 作为一个函数被写进全局声明中. 此外, 通过模型转换方法, 还能自动生成一些待验证的 TCTL 性质规约, 包括无死锁性, 无输出冲突和所有状态的可达性. 最后, 使用 UPPAAL 工具对模型进行形式化验证分析, 以确保所建立的面向 ADS 行为决策 RoboSim 模型的安全性.

4 案例分析

本节以变道超车场景为例, 讨论如何基于贝叶斯网络和 RoboSim 模型进行自动驾驶行为决策. 首先, 在 ADS 领域本体的指导下, 以贝叶斯网络建模工具 GeNI 作为可视化载体构建贝叶斯网络, 通过自动驾驶仿真模拟器 CARLA (center for advanced research on language acquisition)^[17]生成的仿真数据对贝叶斯网络进行参数学习, 并进一步生成面向 ADS 行为决策的 RoboSim 模型, 最后对其进行形式化验证分析. 实验部分代码详见 https://github.com/mzdachuizhang/Decision_Making_Using_Bayesian-RoboSim.git.

4.1 变道超车场景

由于本文方法需尽可能考虑到环境中的不确定性因素, 如天气、周围车辆信息等. 近年来虚拟仿真技术的发展可以实现真实场景的逼真模拟. 使用 CARLA 仿真器生成自动驾驶数据集, 包括自动驾驶车辆的位置信息、速度信息以及车道信息等, 并可定制行人、其他车辆和天气等环境因素信息. CARLA 生成的变道超车场景如图 4 所示.




图 4 变道超车场景

图 4 中场景主要包含了天气信息和 4 个动态实体, 即作为决策主体的当前车辆 veh_e 以及周围车辆: 当前车道前方车辆 veh_f0 , 左车道后方车辆 veh_b1 , 左车道前方车辆 veh_f1 . 首先, veh_e 在 lane0 车道上直线行驶, 并希望通过变道超车的方式超过前方车辆 veh_f0 , 且与周围车辆保持安全距离. 受天气、周围车辆意图的不确定性影响, 变道超车动作并非在任何时刻都适合. 因此 veh_e 需要通过当前环境判断应该采取何种决策, 才能在保证安全

的情况下进行变道超车或维持原状态.

4.2 面向变道超车行为决策的贝叶斯网络

面向变道超车场景行为决策的贝叶斯网络构建步骤如下: 首先, 结合第 2 节所提到的面向 ADS 的领域本体模型以及基于 LSTM 的他车意图预测模型, 为贝叶斯网络提供驾驶场景理解信息, 以定义针对该场景的行为决策中所需的贝叶斯网络节点; 然后, 通过 CARLA 得到的场景仿真数据, 使用贝叶斯网络工具 GeNIe 对数据进行结构学习和参数学习, 最终得到基于变道超车场景行为决策的贝叶斯网络.

根据面向 ADS 的领域本体定义的类, 本文将变道超车场景因素分为 3 类, 包括车辆状态、环境因素和行为决策, 由此确定贝叶斯网络应包含的节点, 具体节点以及节点含义如表 2 所示. 其中, 车辆状态节点中的 *is_safe_id* 节点表示通过车辆当前速度和相对距离所计算出的 ego 车和其他实体车辆在当前速度下是否保持安全距离, 其值可取 *safe* 或 *unsafe*; 环境因素节点中 *id_intension* 节点表示动态实体车辆的驾驶意图, 该节点的值根据第 2.1.2 节所介绍的基于 LSTM 的他车行为意图预测算法实时计算得出, 并能够动态地影响最终的行为决策.

表 2 变道超车场景行为决策的贝叶斯网络节点及含义

节点类型	节点名称	节点含义
车辆状态节点	ego_lane	veh_e所在车道
	ego_speed	veh_e车行驶速度
	ego_dirac	veh_e车与当前车道中心轴线夹角
	rel_f0	veh_e车与veh_f0之间的相对距离
	is_safe_f0	veh_e车和veh_f0车在当前速度下是否保持安全距离
	rel_b1	veh_e车与veh_b1之间的相对距离
	is_safe_b1	veh_e车和veh_b1车在当前速度下是否保持安全距离
	rel_f1	veh_e车与veh_f1之间的相对距离
环境因素节点	is_safe_f1	veh_e车和veh_f1车在当前速度下是否保持安全距离
	f0_intension	veh_f0车辆驾驶意图, 由LSTM模型预测得到
	f0_speed	veh_f0车行驶速度
	f0_acc	veh_f0车当前加速状况
	b1_intension	veh_b1车辆驾驶意图, 由LSTM模型预测得到
	b1_speed	veh_b1车行驶速度
	b1_acc	veh_b1车当前加速状况
	f1_intension	veh_f1车辆驾驶意图, 由LSTM模型预测得到
	f1_speed	veh_f1车行驶速度
	f1_acc	veh_f1车当前加速状况
行为决策节点	weather	当前天气状况
	dec_longti	veh_e车辆可能采取的纵向驾驶动作
	dec_lateral	veh_e车辆可能采取的横向驾驶动作

本次实验选择使用通过 CARLA 的仿真引擎生成的数据, 数据共包括 200 组变道超车场景, 基本涵盖变道超车的所有可能的情况, 每组场景的采样间隔为 0.2 s. 首先, 使用 LSTM 对环境中的动态实体车辆 (即 *veh_f1*, *veh_f0* 和 *veh_0b*) 进行驾驶意图预测, 将预测结果一并加入数据集中. 然后, 使用 GeNIe 工具构建贝叶斯网络并基于仿真数据进行参数学习, 得到如图 5 所示的面向超车变道场景行为决策的贝叶斯网络, 可以直观地看出各因素之间的依赖关系, 且各节点最终均会对 *veh_e* 车的行为决策即节点 *dec_longti* 和节点 *dec_lateral* 产生直接或间接的影响.

输入一组驾驶数据, 将自动驾驶车辆以及周围环境因素输入对应的贝叶斯网络节点中, 然后通过贝叶斯最大后验概率推理计算车辆可能采取的动作的概率, 概率值最大的即为车辆在当前环境下要采取的横向驾驶动作与纵向驾驶动作. 一次贝叶斯推理决策过程如图 6 所示, *veh_e* 当前处于右侧车道, 行驶速度适中, 与当前车道中心轴线

夹角偏左, 并且与 veh_f0、veh_b1、veh_f1 均处于安全距离, 周围车辆以 veh_f0 为例, 其速度较低, 保持匀速状态, 有 64% 的概率保持直行. 在该驾驶环境下, 通过贝叶斯网络推理得到, 横向驾驶行为保持当前车速的概率为 73%, 加速概率为 8%, 减速概率为 19%; 纵向驾驶行为中, 左转概率为 67%, 右转概率为 16%, 保持直行概率为 16%. 因此, 当前自动驾驶情况在该驾驶环境做出的最优决策为保持当前速度与左转.




图5 超车变道场景行为决策的贝叶斯网络




图6 根据驾驶场景信息进行贝叶斯决策推理

4.3 面向变道超车行为决策的 RoboSim 模型

根据变道超车场景的仿真数据集及第 4.2 节生成贝叶斯网络, 利用算法 2 构建面向变道超车场景行为决策的 RoboSim 模型, 并基于我们前期的工作^[8]将其自动转换为 NTA 模型, 以使用形式化验证工具 UPPAAL 对该模型进行验证分析. 图 7 展示了面向变道超车场景行为决策的 RoboSim 模型, 可见如下内容.







图 7 面向变道超车场景行为决策的 RoboSim 模型

(1) 图 7(a) 为模型中定义的接口、事件、操作及枚举类型。接口包括环境因素接口 `EnvI`、ego 车状态接口 `EgoStateI` 和决策接口 `DecisionI`。其中, `EnvI` 中定义了所有环境因素事件, 包括动态实体车辆的速度、转向、道路、加速情况以及天气状态, 这些事件将通过车辆的物理平台 `CarPlatform` 传递给 `RoboSim` 模型的内部控制器和状态机; `EgoStateI` 中定义了 ego 车的状态; `DecisionI` 定义了一个决策操作 `decision`, 该操作即用于为车辆下一时刻的加速情况和转向角度提供决策建议。枚举类型 `Speed` 等用于定义变量的取值, 如 `Speed` 类型中定义了 4 个值 `stop`, `low`, `mid` 和 `fast`, 用于表示车辆的当前速度区间, `stop` 表示车辆的当前速度为 0。

(2) 图 7(b) 为 Module 模型, 车辆物理平台 CarPlatform 和控制器 OverTakingController 通过接口 EnvI 中的事件异步连接, 将从物理平台读取的环境信息传递给控制器, 此外, CarPlatform 提供的接口 DecisionI 用于接受由控制器传来的车辆决策操作。

(3) 图 7(c) 为 Controller 模型, 控制器和内部状态机 OverTakingSTM 也通过接口 EnvI 中的事件异步连接, 将环境信息传递给内部状态机, 并通过接口 DecisionI 接受来自状态机的车辆决策操作。

(4) 图 7(d) 为状态机模型示意图, 由于篇幅所限, 这里只列举了其中的部分状态和迁移. 状态机的控制流运行流程如下: 初始化即车辆进入变道超车场景时, 控制流便会从 `initial` 节点出发到达 `s_0` 节点, 随后, 控制流会根据车辆的当前状态和环境条件进行判断并进入合适的安全状态节点, 并在每个执行周期结束时将决策通过 `Decision1`

传出. 图 7(d) 中展示了一条从状态 s_1 到状态 s_2 的迁移, 斜杠前为 condition 条件部分, 斜杠后为决策部分, 当满足 condition 所列条件时, 则会触发 action 动作, 最后通过 exec 结束当前执行周期.

本文使用 CARLA 额外仿真了 200 个变道超车场景 (共计 24 113 条采样数据) 作为测试数据, 以比较使用贝叶斯网络和使用 RoboSim 模型进行决策的结果和效率. 通过对比决策结果, 发现两种方法的决策结果完全一致, 说明在本例中, RoboSim 模型完全承载了贝叶斯网络的决策信息; 此外, 两种方法在一个变道超车场景的决策效率对比如图 8 所示, 通过决策耗时比较可以看出, 使用 RoboSim 决策模型所做决策确实比直接使用贝叶斯网络进行决策效率更高.




图 8 贝叶斯网络与 RoboSim 模型决策效率对比图

除决策效率更高外, 使用 RoboSim 决策模型还支持进一步利用形式化方法进行验证分析, 以保证模型的安全性, 本文选择 UPPAAL 作为形式化验证工具以说明方法的可行性. 上述 RoboSim 模型可以通过模型转换自动生成如图 9 所示的时间自动机网络模型, 包括针对 RoboSim 模型中 Module 执行周期的 OverTakingModule_cycle (如图 9(a) 所示)、针对 RoboSim 模型中 Controller 执行周期的 OverTakingController_cycle (如图 9(b) 所示)、和针对 RoboSim 模型中状态机执行周期的 OverTakingSTM_cycle (如图 9(c) 所示). 这 3 个模型用于刻画寄存器读写和输出冲突判断等, 以及 RoboSim 模型中状态机所对应的时间自动机模型 OverTakingSTM (如图 9(d) 所示), 该模型实现了状态机的内部控制逻辑.




图 9 时间自动机网络模型

整个时间自动机网络模型可以结合 TCTL 性质规约通过 UPPAAL 工具进行形式化验证分析. 这里我们验证了死锁性、是否有输出冲突以及状态可达性等针对行为决策模型安全性的性质规约, 验证结果如表 3 所示. 验证结果表明, 上述生成的面向变道超车场景行为决策的 RoboSim 模型的内部逻辑是安全的.

表 3 针对变道超车场景的行为决策的 UPPAAL 模型验证结果

性质	性质描述	验证结果
A[] not deadlock	无死锁	满足
A[] not (OverTakingModule_cycle.OutputConflict && OverTakingController_cycle.OutputConflict && OverTakingSTM_cycle.OutputConflict)	无输出冲突	满足
E<> OverTakingSTM.entered_s_1	s_1 状态可达	满足
E<> OverTakingSTM.entered_s_2	s_2 状态可达	满足

5 相关工作

本文研究自动驾驶行为决策方法及其形式化验证, 相关工作主要包括自动驾驶决策生成方法、对自动驾驶行为决策的安全性验证方法以及 RoboSim 模型及相关验证方法 3 大部分.

5.1 自动驾驶行为决策方法

目前, 自动驾驶车辆的行为决策方法主要可以分为基于学习、基于博弈论、基于规则和基于概率统计模型 4 大类方法^[18,19]. 其中, 基于学习的算法即利用深度学习算法对环境样本进行自主学习, 产生端到端的行为决策方法, 如英伟达 (NVIDIA)^[20]研发的自动驾驶车辆采用卷积神经网络进行决策. 基于博弈论的方法将决策过程看作是智能体之间的动态交互行为, 代表工作有 Wang 等人^[21]结合动态博弈论预测车道变换以及跟车的驾驶行为.

其中基于规则的算法主要通过划分车辆状态, 建立驾驶环境与驾驶动作之间的映射关系, 进而进行决策, 其代表方法为状态机模型、基于知识推理的模型等. 针对状态机模型, 文献 [22] 中斯坦福大学团队研发的 Junior 无人车利用一个有限状态机进行行为决策, 但在实际场景测试中仍有状态机无法覆盖的情况; 文献 [23] 中, Odin 车队利用层次状态机区分不同的驾驶场景并采用竞争的机制得到行为决策. 针对基于知识推理的方法, Zhao 等人^[24]使用本体技术对自动驾驶环境场景进行建模, 将输入传感器的数据与知识库中的规则进行匹配再查询得到当前场景对应的决策. 基于规则的算法的优点是可解释性强, 但是无法考虑到环境中的不确定性因素, 且存在状态空间的组合爆炸问题.

基于概率统计模型的方法主要包括部分可观测马尔可夫决策过程 (partially observable Markov decision process, POMDP)、贝叶斯网络等. Liu 等人^[25]将在城区环境中的情境感知的决策问题建模为 POMDP 模型, 以处理由于周围物体运动意图和感知噪声所引入的不确定因素, 很好地解决了环境中不确定因素对决策带来的影响但存在状态空间爆炸问题. Ulbrich 等人^[26]提出一种基于非线性动态贝叶斯网络模型, 提高了自动驾驶车辆在不确定性环境下的自主变道的可靠性. 也有许多工作将深度学习算法与基于概率的模型进行结合. Ma 等人^[27]将驾驶系统分为场景识别模块和决策推理模块, 运用多任务学习神经网络提取驾驶员视角图像的特征值, 并将其作为以贝叶斯网络决策模块的输入. Gautam 等人^[28]利用概率卷积神经网络估计实际道路上数据的不确定性以及传感器的不确定性, 并将结果引入预先定义好的贝叶斯网络进行决策. 但以上方法难以充分表达驾驶场景信息以及自动驾驶领域知识, 且在同一驾驶场景下存在由于冗余计算导致计算效率下降的问题.

5.2 自动驾驶行为决策的安全性验证方法

在自动驾驶行为决策的安全性验证方面, Selvaraj 等人^[29]通过评估监督控制理论、模型检查和演绎验证等多种形式化技术, 得出自动驾驶车辆现有决策和控制软件需要多种形式化方法确保正确性的结论. Wongpiromsarn^[30]引入了周期性控制混成自动机 (periodically controlled hybrid automata, PCHA) 以及 LTL 进行系统规约, 使用模型检测的技术对判断自动驾驶决策系统是否满足安全性规约. 刘斌斌等人^[31]提出了验证驱动的基于代码自动生成

的自动驾驶车辆决策系统开发框架,并对决策系统进行环境建模,通过形式化验证发现系统设计过程中不易察觉的缺陷和错误. An 等人^[32]使用了机器学习的方法识别周围人类驾驶员的驾驶风格,定义了一种环境建模语言 *stohChart(p)* 以驾驶风格分类的结果作为参数,并将该建模语言自动转换为概率时间自动机网络,利用模型检测工具 UPPAAL-SMC 来分析驾驶行为的安全性. 我们前期的工作^[33,34]基于自动驾驶领域建模语言 ADSML 建模自动驾驶场景中的静态行为和动态行为,并将其自动转化为随机混成状态机,使用 UPPAAL 工具进行验证分析,在仿真过程中会实时判断自动驾驶汽车的安全性,为其提供大量的安全性分析.

本文所使用的 RoboSim 模型本身可以结合其他形式化技术和形式化验证工具进行验证分析. Filho 等人^[35]提出了一种将 RoboChart (RoboSim 的前序工作,但没有周期执行语义) 转换为 PRISM 概率建模语言的技术用于统计模型. Abba 等人^[36]将 RoboChart 中的 *tock-CSP* 转化为 UPPAAL 能够接收的时间自动机,但该工作仅针对 RoboChart 的 *tock-CSP* 语义,没有像本文这样考虑到 RoboSim 中详细的建模元素. 本研究组的前期工作^[8]提出一种将 RoboSim 模型转换为时间自动机网络的映射方法,从而在模型检测工具 UPPAAL 中进行安全性、可达性以及活性的验证.

因此本文提出的基于贝叶斯网络构建 RoboSim 模型的自动驾驶行为决策方法,能够基于本体分析复杂的驾驶环境条件,通过建立 LSTM 模型对其他动态实体进意图预测,进行有效互动,减少环境的不确定性因素给决策带来的影响,最后以 RoboSim 中的状态机作为贝叶斯推理行为决策的载体以提高决策效率. 同时,该模型能够自动转化为多种形式化语言,以形式化方法验证分析以确保决策的安全性,这是本文与以往工作的不同之处.

6 总结与展望

汽车自动驾驶技术的飞速发展,衍生出了大量的自动驾驶行为决策方法. 然而,大部分方法暂未考虑自动驾驶场景中动态实体的未来运动状态,且没有缓存相似场景的行为决策,导致大量冗余计算. 此外,针对决策的安全性并未纳入考量范畴,难以保证采取行为决策后的本车仍处于安全状态. 针对以上问题,本文创新地提出了一种基于贝叶斯网络和 RoboSim 模型的面向汽车自动驾驶的行为决策方法,该方法通过贝叶斯网络生成决策,并将相同的环境因素及车辆状态归入同一集合,构建面向自动驾驶行为决策的 RoboSim 模型,最后使用形式化验证技术对所生成的模型进行安全性验证分析,在保证决策正确的前提下,尽量减少做出决策的冗余操作. 以上工作为汽车自动驾驶行为决策提供了一种有效的方法.

未来工作将继续探索基于 RoboSim 模型的自动驾驶行为决策方法. 目前本文采用的贝叶斯网络在训练完成后,参数和结构不会再发生动态改变,后期我们将探索如何利用反例回溯优化贝叶斯网络,以及强化学习、因果推理等方法在本文提出的框架中的应用. 其次,本文仅对决策模块进行安全性的验证与分析,下一阶段我们将结合自动驾驶场景建模语言 ADSML (autonomous driving system modeling language) 对自动驾驶安全场景进行建模,实现面向汽车自动驾驶安全场景的决策建模及验证分析. 最后,在实验部分,将本文方法与其他自动驾驶决策生成方法进行对比,以证明本文方法的高效安全性与通用性.

References:

- [1] Yurtsever E, Lambert J, Carballo A, Takeda K. A survey of autonomous driving: Common practices and emerging technologies. *IEEE Access*, 2020, 8: 58443–58469. [doi: 10.1109/ACCESS.2020.2983149]
- [2] Xin ZY. Tesla accident. 2021 (in Chinese). <http://finance.sina.com.cn/tech/csj/2021-03-13/doc-iknncsci3397448.shtml>
- [3] Zhang MH, Du DH, Zhang MZ, Zhang L, Wang Y, Zhou WT. Spatio-temporal trajectory data-driven autonomous driving scenario meta-modeling approach. *Ruan Jian Xue Bao/Journal of Software*, 2021, 32(4): 973–987 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6226.htm> [doi: 10.13328/j.cnki.jos.006226]
- [4] Artuñedo A, Villagra J, Godoy J, Del Castillo MD. Motion planning approach considering localization uncertainty. *IEEE Trans. on Vehicular Technology*, 2020, 69(6): 5983–5994. [doi: 10.1109/TVT.2020.2985546]
- [5] Zhao LH, Ichise R, Liu Z, Mita S, Sasaki Y. Ontology-based driving decision making: A feasibility study at uncontrolled intersections. *IEICE Trans. on Information and Systems*, 2017, E100(7): 1425–1439. [doi: 10.1587/transinf.2016EDP7337]
- [6] Tang L, Wang HY, Zhang WH, Mei ZY, Li L. Driver lane change intention recognition of intelligent vehicle based on long short-term

- memory network. *IEEE Access*, 2020, 8: 136898–136905. [doi: [10.1109/ACCESS.2020.3011550](https://doi.org/10.1109/ACCESS.2020.3011550)]
- [7] Gucwa KJ, Cheng HH. RoboSim: A simulation environment for programming virtual robots. *Engineering with Computers*, 2018, 34(3): 475–485. [doi: [10.1007/s00366-017-0553-7](https://doi.org/10.1007/s00366-017-0553-7)]
 - [8] Zhang MZ, Du DH, Sampaio A, Cavalcanti A, Filho MC, Zhang MH. Transforming RoboSim models into UPPAAL. In: *Proc. of the 2021 Int'l Symp. on Theoretical Aspects of Software Engineering (TASE)*. Shanghai: IEEE, 2021. 79–86. [doi: [10.1109/TASE52547.2021.00037](https://doi.org/10.1109/TASE52547.2021.00037)]
 - [9] Behrmann G, David A, Larsen KG. A tutorial on uppaal. *Formal Methods for the Design of Real-time Systems*. Bertinoro: Springer, 2004. 200–236. [doi: [10.1007/978-3-540-30080-9_7](https://doi.org/10.1007/978-3-540-30080-9_7)]
 - [10] ISO. Road vehicles-safety of the intended functionality. ISO/CD 21448. 2022.
 - [11] Niedermayer D. An introduction to Bayesian networks and their contemporary applications. In: Holmes DE, Jain LC, eds. *Innovations in Bayesian networks*. Berlin: Springer, 2008. 117–130. [doi: [10.1007/978-3-540-85066-3_5](https://doi.org/10.1007/978-3-540-85066-3_5)]
 - [12] BayesFusion LLC. GeNIe modeler. User Manual. 2017. <https://www.bayesfusion.com/genie/>
 - [13] Fischer C, Wehrheim H. Model-checking CSP-OZ specifications with FDR. In: *Proc. of the 1st Int'l Conf. on Integrated Formal Methods*. Springer, 1999. 315–334. [doi: [10.1007/978-1-4471-0851-1_17](https://doi.org/10.1007/978-1-4471-0851-1_17)]
 - [14] Kwiatkowska M, Norman G, Parker D. PRISM: Probabilistic symbolic model checker. In: *Proc. of the 12th Int'l Conf. on Modelling Techniques and Tools for Computer Performance Evaluation*. London: Springer, 2002. 200–204. [doi: [10.1007/3-540-46029-2_13](https://doi.org/10.1007/3-540-46029-2_13)]
 - [15] Woodcock J, Foster S, Mota A, Ye KF. RoboStar technology: Modelling uncertainty in RoboChart using probability. In: Cavalcanti A, Dongol B, Hierons R, Timmis J, Woodcock J, eds. *Software Engineering for Robotics*. Cham: Springer, 2021. 413–465. [doi: [10.1007/978-3-030-66494-7_13](https://doi.org/10.1007/978-3-030-66494-7_13)]
 - [16] Penczek W, Woźna B, Zbrzezny A. Towards bounded model checking for the universal fragment of TCTL. In: *Proc. of the 7th Int'l Symp. on Formal Techniques in Real-time and Fault-tolerant Systems*. Oldenburg: Springer, 2002. 265–288. [doi: [10.1007/3-540-45739-9_17](https://doi.org/10.1007/3-540-45739-9_17)]
 - [17] Dosovitskiy A, Ros G, Codevilla F, López AM, Koltun V. CARLA: An open urban driving simulator. In: *Proc. of the 1st Annual Conf. on Robot Learning*. Mountain View: PMLR, 2017. 1–16.
 - [18] Xiong L, Kang YC, Zhang PZ, Zhu CY, Yu ZP. Research on behavior decision-making system for unmanned vehicle. *Automobile Technology*, 2018(8): 1–9 (in Chinese with English abstract). [doi: [10.19620/j.cnki.1000-3703.20180752](https://doi.org/10.19620/j.cnki.1000-3703.20180752)]
 - [19] Schwarting W, Alonso-Mora J, Rus D. Planning and decision-making for autonomous vehicles. *Annual Review of Control, Robotics, and Autonomous Systems*, 2018, 1: 187–210. [doi: [10.1146/annurev-control-060117-105157](https://doi.org/10.1146/annurev-control-060117-105157)]
 - [20] Bojarski M, Del Testa D, Dworakowski D, Firner B, Flepp B, Goyal P, Jackel LD, Monfort M, Muller U, Zhang JK, Zhang X, Zhao J, Zieba K. End to end learning for self-driving cars. *arXiv:1604.07316*, 2016.
 - [21] Wang M, Hoogendoorn SP, Daamen W, Van Arem B, Happee R. Game theoretic approach for predictive lane-changing and car-following control. *Transportation Research Part C: Emerging Technologies*, 2015, 58: 73–92. [doi: [10.1016/j.trc.2015.07.009](https://doi.org/10.1016/j.trc.2015.07.009)]
 - [22] Montemerlo M, Becker J, Bhat S, *et al.* Junior: The stanford entry in the urban challenge. *Journal of Field Robotics*, 2008, 25(9): 569–597. [doi: [10.1002/rob.20258](https://doi.org/10.1002/rob.20258)]
 - [23] Bacha A, Bauman C, Faruque R, *et al.* Odin: Team victortango's entry in the darpa urban challenge. *Journal of Field Robotics*, 2008, 25(8): 467–492. [doi: [10.1002/rob.20248](https://doi.org/10.1002/rob.20248)]
 - [24] Zhao LH, Ichise R, Sasaki Y, Liu Z, Yoshikawa T. Fast decision making using ontology-based knowledge base. In: *Proc. of the 2016 IEEE Intelligent Vehicles Symp. (IV)*. Gothenburg: IEEE, 2016. 173–178. [doi: [10.1109/IVS.2016.7535382](https://doi.org/10.1109/IVS.2016.7535382)]
 - [25] Liu W, Kim SW, Pendleton S, Ang MH. Situation-aware decision making for autonomous driving on urban road using online POMDP. In: *Proc. of the 2015 IEEE Intelligent Vehicles Symp. (IV)*. Seoul: IEEE, 2015. 1126–1133. [doi: [10.1109/IVS.2015.7225835](https://doi.org/10.1109/IVS.2015.7225835)]
 - [26] Ulbrich S, Maurer M. Towards tactical lane change behavior planning for automated vehicles. In: *Proc. of the 18th IEEE Int'l Conf. on Intelligent Transportation Systems*. Gran Canaria: IEEE, 2015. 989–995 [doi: [10.1109/ITSC.2015.165](https://doi.org/10.1109/ITSC.2015.165)]
 - [27] Ma JC, Xie H, Song K, Liu H. A Bayesian driver agent model for autonomous vehicles system based on knowledge-aware and real-time data. *Sensors*, 2021, 21(2): 331. [doi: [10.3390/s21020331](https://doi.org/10.3390/s21020331)]
 - [28] Gautam V, Gheraibia Y, Alexander R, Hawkins R. Runtime decision making under uncertainty in autonomous vehicles. In: *Proc. of the 2021 AAAI's Workshop on Artificial Intelligence Safety (SafeAI 2021)*. 2021. Paper 17.
 - [29] Selvaraj Y, Ahrendt W, Fabian M. Verification of decision making software in an autonomous vehicle: An industrial case study. In: *Proc. of the 24th Int'l Workshop on Formal Methods for Industrial Critical Systems*. Amsterdam: Springer, 2019. 143–159. [doi: [10.1007/978-3-030-27008-7_9](https://doi.org/10.1007/978-3-030-27008-7_9)]
 - [30] Wongpiromsarn T. Formal methods for design and verification of embedded control systems: Application to an autonomous vehicle

- [Ph.D. Thesis]. Pasadena: California Institute of Technology, 2010.
- [31] Liu BB, Liu WW, Mao XG, Dong W. Correctness verification of rules for unmanned vehicles' decision system. Computer Science, 2017, 44(4): 72–74, 113 (in Chinese with English abstract). [doi: [10.11896/j.issn.1002-137X.2017.04.015](https://doi.org/10.11896/j.issn.1002-137X.2017.04.015)]
- [32] An DD, Liu J, Zhang M, Chen XH, Chen MS, Sun HY. Uncertainty modeling and runtime verification for autonomous vehicles driving control: A machine learning-based approach. Journal of Systems and Software, 2020, 167: 110617. [doi: [10.1016/j.jss.2020.110617](https://doi.org/10.1016/j.jss.2020.110617)]
- [33] Wang Y. Modeling, simulation and verification of autonomous driving scenario based on model-driven [MS. Thesis]. Shanghai: East China Normal University, 2020 (in Chinese with English abstract).
- [34] Du DH, Chen JN, Zhang MZ, Ma MJ. Towards verified safety-critical autonomous driving scenario with ADSML. In: Proc. of the 45th IEEE Annual Computers, Software, and Applications Conf. (COMPSAC). Madrid: IEEE, 2021. 1333–1338. [doi: [10.1109/COMPSAC51774.2021.00187](https://doi.org/10.1109/COMPSAC51774.2021.00187)]
- [35] Filho MSC, Marinho R, Mota A, Woodcock J. Analysing RoboChart with probabilities. In: Proc. of the 21st Brazilian Symp. on Formal Methods. Salvador: Springer, 2018. 198–214. [doi: [10.1007/978-3-030-03044-5_13](https://doi.org/10.1007/978-3-030-03044-5_13)]
- [36] Abba A, Cavalcanti A, Jacob J. Temporal reasoning through automatic translation of tock-CSP into timed automata. In: Proc. of the 24th Brazilian Symp. on Formal Methods. Springer, 2021. 70–86. [doi: [10.1007/978-3-030-92137-8_5](https://doi.org/10.1007/978-3-030-92137-8_5)]

附中文参考文献:

- [2] 新智元. 惨烈!特斯拉再次撞上白色卡车, 两名乘客急送ICU. 2021. <http://finance.sina.com.cn/tech/csj/2021-03-13/doc-ikknscsi3397448.shtml>
- [3] 张梦寒, 杜德慧, 张铭茁, 张雷, 王耀, 周文韬. 时空轨迹数据驱动的自动驾驶场景元建模方法. 软件学报, 2021, 32(4): 973–987. <http://www.jos.org.cn/1000-9825/6226.htm> [doi: [10.13328/j.cnki.jos.006226](https://doi.org/10.13328/j.cnki.jos.006226)]
- [18] 熊璐, 康宇宸, 张培志, 朱辰宇, 余卓平. 无人驾驶车辆行为决策系统研究. 汽车技术, 2018(8): 1–9. [doi: [10.19620/j.cnki.1000-3703.20180752](https://doi.org/10.19620/j.cnki.1000-3703.20180752)]
- [31] 刘斌斌, 刘万伟, 毛晓光, 董威. 无人驾驶汽车决策系统的规则正确性验证. 计算机科学, 2017, 44(4): 72–74, 113. [doi: [10.11896/j.issn.1002-137X.2017.04.015](https://doi.org/10.11896/j.issn.1002-137X.2017.04.015)]
- [33] 王耀. 基于模型驱动的自动驾驶场景建模、仿真与验证方法研究 [硕士学位论文]. 上海: 华东师范大学, 2020.



陈洁娜(1999—), 女, 硕士生, CCF 学生会员, 主要研究领域为可信软件.



李博(1998—), 男, 硕士生, CCF 学生会员, 主要研究领域为可信软件.



张铭茁(1997—), 男, 硕士生, 主要研究领域为可信软件.



聂基辉(1998—), 男, 硕士生, 主要研究领域为可信软件.



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.



任婧瑶(2000—), 女, 本科生, 主要研究领域为可信软件.