

自动驾驶汽车连续测试场景复杂度评估方法

朱冰¹, 范天昕¹, 赵文博², 李伟男³, 张培兴¹

(1. 吉林大学汽车底盘集成与仿生全国重点实验室, 长春 130022; 2. 国汽(北京)智能网联汽车研究院有限公司, 北京 100176; 3. 中国第一汽车集团股份有限公司研发总院, 长春 130011)

摘要:连续测试场景是自动驾驶汽车测试体系的重要内容,其测试公平性一直受到较多的争议。为此,本文提出一种自动驾驶汽车连续测试场景复杂度评估方法,以期解决测试场景公平性难题。基于六层场景模型建立场景要素重要性评估体系;分析场景要素与感知、决策、执行系统间的复杂度映射关系,建立自动驾驶系统层级的场景复杂度量化评价方法;建立系统影响传递权重系数,实现场景复杂度综合计算。搭建仿真交通环境对两种自动驾驶系统行驶过程复杂度进行计算,两车场景复杂度对比结果分别为 1 和 0.765,与测试过程被测算算法遭遇的场景难度趋势一致,证明了本文方法的有效性。

关键词:车辆工程;自动驾驶汽车;连续测试场景;场景复杂度

中图分类号:U461 **文献标志码:**A **文章编号:**1671-5497(2025)02-0456-12

DOI:10.13229/j.cnki.jdxbgxb.20240874

Continuous test scenario complexity evaluation method for automated driving vehicles

ZHU Bing¹, FAN Tian-xin¹, ZHAO Wen-bo², LI Wei-nan³, ZHANG Pei-xing¹

(1. National Key Laboratory of Automotive Chassis Integration and Bionics, Jilin University, Changchun 130022, China; 2. China Intelligent and Connected Vehicles (Beijing) Research Institute Co., Ltd., Beijing 100176, China; 3. China First Automobile Corporation R&D Center, Changchun 130011, China)

Abstract: Continuous test scenario is an important content of automated driving vehicle scenario-based testing system, but its fairness has been disputed. For this reason, this paper proposes a real-time evaluation method for the continuous test scenario complexity of automated driving vehicle, with a view to solving the problem of test scenario fairness. Based on the six-layer scenario model, a scenario element importance assessment system is established; through analyzing the mapping relationship between scenario elements and perception, decision-making, and execution systems, a quantitative evaluation method of scenario complexity at the system layer is constructed; the impact transfer weighting coefficients of different system are calculated, which can be used to realize the comprehensive calculation of scenario

收稿日期:2024-08-05.

基金项目:国家自然科学基金项目(U22A20247, 5240120450);中国博士后科学基金项目(2023M741354);国家资助博士后研究人员计划项目(GZC20230945).

作者简介:朱冰(1982-),男,教授,博士.研究方向:智能汽车技术. E-mail: zhubing@jlu.edu.cn

通信作者:张培兴(1995-),男,助理研究员,博士研究生.研究方向:智能汽车测试技术.

E-mail: zhangpeixing@jlu.edu.cn

complexity in real time. The traffic circle continuous test scenario is selected to analyze the scenario complexity of two black-box automated driving systems, the results of the scenario complexity of the two vehicles are 1 and 0.765, which are consistent with the scenario complexity encountered by the two tested systems in the test process. The results can prove the effectiveness of the method proposed in this paper.

Key words: automotive engineering; automated driving vehicle; continuous test scenario; scenario complexity

0 引言

自动驾驶汽车技术发展需要科学完善的测试评价体系作为支撑^[1],当前,基于场景的测试方法已成为自动驾驶汽车性能验证的重要手段^[2]。连续测试场景相比独立测试场景更能准确反映被测自动驾驶汽车在真实服役条件下的综合性能,已经成为自动驾驶汽车场景测试体系中的重要内容^[3]。

然而,连续测试场景的测试公平性一直受到较多的争议^[4]。由于被测自动驾驶汽车策略行为的不同,不同测试过程的测试难度可能存在较大差异。虽然可以通过大量随机测试的方法基于大数定律获取相对公平的测试结果,例如平均接管里程^[5],但这一过程将浪费大量的测试成本。对连续测试场景的测试过程复杂度进行评估可以充分挖掘自动驾驶汽车性能表现与场景片段间的映射关系,解决测试场景公平性难题,受到了越来越多学者的关注。

当前测试场景复杂度分析方法多针对场景初始特征或仅考虑简单的车辆交互指标。在场景初始特征分析方面,王荣等^[6]通过信息熵和引力模型分别计算静、动态场景要素复杂度分值,实现了自动驾驶汽车道路测试场景复杂度的量化评价;李江坤等^[7]建立了场景内要素对自动驾驶系统的影响传递模型并赋予影响权重,实现了场景复杂度的评估;董汉等^[8]通过辅助驾驶系统采集的报警数据构建危险驾驶工况场景合并进行了复杂度评价。在简单车辆交互指标方面,Liu等^[9]从动态视频帧中提取场景静态、动态要素进行数量累加,构建了具有连续性的复杂度计算方法;还有一些学者直接使用碰撞时间(Time to collision, TTC)、车头时距等风险指标评价场景复杂度^[10,11]。分析现有研究可以发现,当前方法多局限于场景初始状态特征,难以描述场景时序变化过程中的车辆与场景要素间的交互;无法明确场景复杂度变化的深层特征,难以反映场景要素与

被测车辆之间的多维映射关系。

针对上述难题,本文提出一种考虑场景要素对自动驾驶汽车动态影响的连续测试场景复杂度评估方法。首先基于六层场景模型和层次分析方法建立场景要素重要性指标;随后考虑行驶过程场景要素与车辆子系统的动态交互,结合场景要素重要性指标建立感知识别、决策规划和控制执行系统的场景要素复杂度评价框架;最后根据场景要素自动驾驶系统影响传递模型,实现连续测试场景动态复杂度综合评价。搭建仿真交通环境对两种黑盒自动驾驶系统进行测试,验证本文方法的有效性。

1 场景复杂度评估框架

自动驾驶汽车连续测试场景复杂度评估方法可分为 3 部分内容:场景要素特征权重分析、要素-系统复杂度映射、场景复杂度耦合。具体评估框架如图 1 所示。

首先,参考自动驾驶测试场景六层模型(道路层、交通基础设施层、道路临时操作层、目标物层、天气层、数字信息层)^[12],本文通过分析不同场景要素与自动驾驶连续行驶过程之间的交互关系,重新建立了静态场景要素(道路层、基础设施层、暂时性操纵层)、动态场景要素(目标层),以及天气要素(自然环境层)的三层场景要素框架,如表

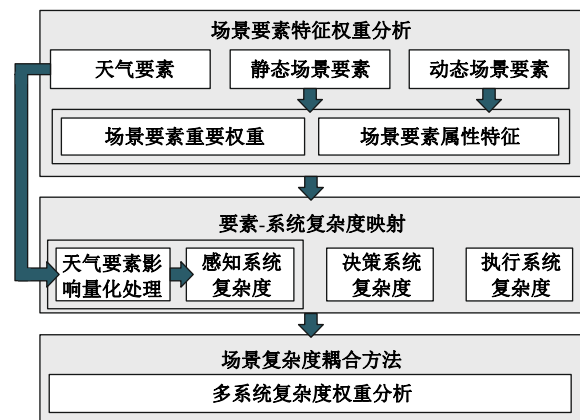


图 1 场景复杂度评估框架

Fig. 1 Scenario complexity evaluation framework

1 所示。在此基础上,本文通过层次分析法和主观赋值法获取场景要素的特征属性权值,作为后续自动驾驶汽车的场景复杂度评估基础。

随后,考虑场景要素和自动驾驶子系统间的实时交互过程,将场景要素的特征值与其对系统产生的影响相结合,建立场景要素与感知、决策和执行系统间的复杂度映射关系。

最后,基于影响传递关系计算自动驾驶各子系统的复杂度权重,耦合获取连续测试场景复杂度综合评价结果。

表 1 场景要素分类表

Table 1 Scenario elements classification table

一级分类	二级分类	三级分类
静态 场景 要素	道路层	道路类型
		道路质量
		车道数量
		道路标线
	交通设施层	……
		信号灯
		标志牌
		其他设施
		……
		……
临时操作层	交通事故	
	临时停放	
	道路施工	
	……	
动态 场景 要素	目标层	机动车
		非机动车
		行人
		……
天气要素	自然环境层	光照
		雨
		雪
		雾
		……

2 场景复杂度计算方法

2.1 场景要素特征权重分析

在连续场景中,随着自动驾驶汽车感知视角、行驶路径的不断变化,不同时刻与其产生实际交互的场景要素的类型和数量是随之变化的。由于不同场景要素属性不同,简单的叠加方法无法准确地描述要素复杂度,因此,需要逐一分析不同场景要素的类型和状态对自车、交通的重要性。

场景要素对自动驾驶汽车行驶过程的影响可以分为两部分:一部分为场景要素在该类要素中的重要权重,即相比该类别其他场景要素对于上级分类的重要性占比;另一部分为场景要素属性对场景复杂度的影响,即场景要素属性值。使用 S 表示自动驾驶汽车行驶过程中产生互动的场景

要素特征影响评分,具体评分如式(1)所示:

$$S_i = \left(\prod_{j=1}^3 u_j \right) \omega_i \quad (1)$$

式中: u_j 为元素对于上级分类的重要权重; ω_i 为场景要素属性值,使用主观赋值的方法确定,将其取值分为5个等级,分别对应赋值为1~5;下标*i*为第*i*个场景要素的参数或取值,例如标志牌为80 km/h限速标志;下标*j*为不同要素层级,例如表1中的静态场景要素(第一层)、道路层(第二层)、车道数量(第三层)。

对于天气要素,其主要与自动驾驶感知系统关联紧密,对决策系统和执行系统的影响主要通过路面质量得到体现,而路面质量具有单独的属性类别,因此,天气要素的特征权重评分 $S_{i(\text{weather})}$ 将在感知系统复杂度映射小节进行详细说明。

式(1)中 u_j 通过可拓层次分析法进行计算。可拓层次分析是在传统层次分析法建立专家经验相对权重矩阵、计算特征值的基础上,通过扩展相对权重矩阵以使结果精度更高的方法。可拓层次分析法首先构建场景要素类别集合的重要性关系判定矩阵 $A = (a_{pq})_{n_j \times n_j}$, 其中 $p, q = 1, 2, \dots, n_j$ 。 n_j 为第 j 个分类层级中场景要素类别数量。 $a_{pq} = [a^+_{pq}, a^-_{pq}]$ 为可拓区间数, a^+_{pq} 和 a^-_{pq} 为不同专家给出的相对权重取值区间的上下端点。分别求区间上端点构成的上判定矩阵 A^+ 和区间下端点构成的下判定矩阵 A^- 对应的归一化特征向量 x^+ 和 x^- , 并计算得到系数 k 和 m , 如式(2)(3)所示:

$$k = \sqrt{\sum_{q=1}^{n_k} \left(\sum_{p=1}^{n_k} a^+_{pq} \right)^{-1}} \quad (2)$$

$$m = \sqrt{\sum_{q=1}^{n_k} \left(\sum_{p=1}^{n_k} a^-_{pq} \right)^{-1}} \quad (3)$$

当满足 $0 \leq k \leq 1 \leq m$ 时,说明可拓判定矩阵具有良好的 consistency。由此,求出第 j 个分类层级的可拓区间数权重向量 $R_k = [kx^-, mx^+] = (R_1, R_2, \dots, R_{n_j})^T$ 。而后计算各区间数权重向量间的相对重要程度,使用 $V(R_a \geq R_b)$ 表示 R_a 大于 R_b 的可能性。如果对于 $\forall a, b = 1, 2, \dots, n_j$ 且 $a \neq b$, $V(R_a \geq R_b) \geq 0$, 则可以得到重要权重系数排序 u_a 和 u_b , 如式(4)所示:

$$\begin{cases} u_b = 1 \\ u_a = V(R_a \geq R_b) = \frac{2(R_a^+ - R_b^-)}{(R_b^+ - R_b^-) + (R_a^+ - R_a^-)} \end{cases} \quad (4)$$

经过归一化处理,第 j 个分类层级中要素的

重要权重系数为 $U_j = (u_j^1, u_j^2, \dots, u_j^{n_j})^T$ 。

2.2 要素-系统复杂度映射

不同场景要素通过对与其相关的自动驾驶汽车子系统产生影响,进而影响车辆在场景中的行驶状态。考虑到当前最普遍的自动驾驶三层系统,本文从感知、决策、执行3个子系统的角度探讨场景要素与自动驾驶子系统之间的复杂度映射关系。首先,分析不同系统的具体工作过程,在此基础上,分析对自动系统工作过程可能产生影响的关键场景要素,在获取关键要素的基础上通过数据分析或机理分析确定不同场景要素对自动驾驶子系统的复杂度映射关系。

2.2.1 感知系统复杂度映射

场景要素对感知系统的影响除了与传感器本身的硬件特征相关外,还与自动驾驶汽车的行驶状态相关,例如不同相对速度、不同相对距离等也会显著影响识别精度。本文选择相机、毫米波雷达、激光雷达3种常用的传感器类型讨论场景要素对感知系统的影响,其他类型传感器可参照这三类传感器进行分析。由于本文仅考虑天气要素对感知系统的影响,此处还将基于感知系统特征计算天气要素的特征权重评分 $S_{r(weather)}$ 。

(1) 相机感知系统

考虑相机的成像特征,单帧成像可近似等效于小孔成像原理,而对于多帧成像而言还需考虑成像光线残留。基于此,本文定义的相机感知系统关键影响场景要素包括相对距离及相对速度两部分,前者主要影响成像在感光元件上的大小,后者则主要影响光线残留,即成像运动模糊。

对于相对距离影响而言,参相机成像原理将目标场景要素和自车的相对距离等效为某一时刻目标场景要素在图像中的分布情况,进而对相机系统的识别难度进行表征,如式(5)所示。目标物距离相机焦点位置越远,则其在相机感光元件上的成像越小,特征越难以被识别。

$$I_{dis} = \frac{p_a}{P_{target}} = 2d \times \tan\left(\frac{FOV}{2}\right) \times p_{target}^{-1} \quad (5)$$

式中: I_{dis} 为某一时刻相机传感器捕捉到的图像中目标场景要素实际尺寸占据整体成像结果的比例,占比越低表示当前距离下场景要素的实际体量对传感器识别效果的影响越大; P_{target} 为目标场景要素的实际尺寸; p_a 为当前时刻相机传感器在目标场景要素位置的视野范围; d 为目标场景要

素与被测车辆的相对距离; FOV 为相机传感器的视场角。

对于车道线等连续型场景要素, I_{dis} 可通过计算其在图像中的可视长度与图像尺寸的比值获得。

对于相对速度影响而言,目标物与相机之间的相对距离越大,成像产生的运动模糊越显著。场景要素在三维空间中产生的图像模糊长度可表示为相机自身参数和目标场景要素与相机的相对速度、相对距离以及运动方向夹角的函数^[13]。本文引入弹性系数 ϵ , 针对与被测自动驾驶汽车距离较近且高速移动的动态场景要素进行识别难度的分析。

综合考虑相对距离及相对速度的干扰,本文计算的场景要素对相机传感器的总影响如式(6)所示:

$$I_c = 2 - \max\left[\min\left(\sqrt{I_{dis}} - \epsilon, 1\right), 0\right] \quad (6)$$

$$\epsilon = \min\left[\max\left(\frac{\Delta v_{c,y} \cdot T_p}{d_{o,y}}, \frac{\Delta v_{c,x} \cdot T_p}{d_{o,x}}\right), 1\right] \quad (7)$$

式中: I_c 为场景要素对相机感知系统的复杂度映射结果, I_c 越大表明该场景要素对相机感知系统而言越复杂; Δv_c 为目标物在相机成像单元上的运动速度,该值与目标物相对速度的比值等于相机成像单元到焦点距离与目标物到相机焦点的距离的比值; d_o 为目标物在相机成像单元上的长度,下标 x 和 y 分别代表速度和长度在成像单元 x 轴和 y 轴的分量。

(2) 毫米波雷达感知系统

对于毫米波雷达系统感知过程而言,目标物测量误差主要与雷达系统本身的调频带宽、调频线性度、调频周期等固定参数相关,与目标物相对速度、相对距离等相关程度较小^[14]。但是,当目标数量增加、密度增大时,雷达的虚警目标数量将激增^[15],因此,本文主要讨论近距离多目标对毫米波雷达检测准确度的影响。考虑车辆尺寸外形,定义当毫米波雷达探测范围内,雷达与运动目标连线的垂直方向,目标物与其他物体间的距离小于目标物探测长度时,易对毫米波雷达感知过程产生影响,标记其为近距离目标。引入系数 I_m 对影响程度进行量化,如式(8)所示:

$$I_m = \frac{2n - 1}{n} \quad (8)$$

式中: I_m 越大表明该场景要素对相机感知系统而

言越复杂; n 为毫米波雷达探测范围内近距离运动目标数量。

(3)激光雷达

对于激光雷达系统,其感知结果受场景要素与自车间相对速度的干扰较小,因此,主要考虑相对距离与目标遮挡对激光雷达造成的影响。

随着目标场景要素与自车相对距离的逐渐变远^[16],分布点云将呈现逐渐稀疏的趋势,远处的交通目标轮廓逐渐趋于不完整,这将影响激光雷达的检测精度。本文通过分析 DAIR-V2X 数据集中 100 帧真实激光雷达的点云数据,通过近似拟合得到的点云密度 D_s 与相对距离的关系如图 2 中红色曲线所示。图中蓝色曲线为真实点云密度曲线。




图 2 点云密度与相对距离的关系曲线图

Fig. 2 Point curve diagram of the relationship between point cloud and relative distance

基于图 2 的结果,使用 I_{r1} 系数量化相对距离对激光雷达感知过程的影响程度,如式(9)所示。式中 e 为自然常数。随着目标物相对距离逐渐增加,雷达点云密度 D_s 逐渐降低,可用于识别同一目标物的点云特征越少,场景复杂程度越高。

$$I_{r1} = 1 + e^{-D_s} \quad (9)$$

当车流量较大时,存在某帧或者多帧点云数据中部分远车道的车辆被其他近车道的目标所遮挡的情况,这将导致激光雷达获取到的目标场景要素的部分点云数据缺失,从而导致目标感知识别受到影响。与毫米波雷达类似,本文引入系数 I_{r2} 表征激光雷达探测范围内近距离运动目标数量对激光雷达的影响程度,如式(10)所示:

$$I_{r2} = \frac{2n - 1}{n} \quad (10)$$

式中: n 为激光雷达探测范围内近距离运动目标

数量,近距离目标物的选择方法与毫米波雷达中的定义相同。

综合考虑场景要素目标物相对距离及近距离目标遮挡的影响,得到场景要素对激光雷达传感器的总影响系数结果如式(11)所示:

$$I_r = (I_{r1} + I_{r2}) / 2 \quad (11)$$

式中: I_r 为场景要素对激光雷达感知系统的复杂度映射结果, I_r 越大表明该场景要素对激光雷达感知系统而言越复杂。

(4)天气要素复杂度映射及特征权重

分别探讨天气要素对 3 类传感器的影响效果。

常见的车载相机对光照的变化比较敏感,图像欠曝光和过曝光都会严重降低成像品质影响检测识别^[17]。同时空气中的雨、雪、雾也会给图像带来大量噪声,影响传感器的工作性能^[18,19]。

毫米波雷达对大多数的天气具有良好的适应性,受杂波影响较小,对一般的不良天气也具有较强的抗干扰能力。但是仍然要考虑大雨、大雪等极端天气出现时对毫米波雷达检测性能的影响^[20-22]。

激光雷达不受光照变化的影响,但是在雨天、雪天、雾天等不良天气下传感器的工作性能也会受到很大的限制^[23-25]。

本文综合分析文献[17-25]中天气要素对传感器感知特征的量化影响结果,得到天气要素复杂度映射结果 I_w 如表 2 所示。

由于天气场景要素类别较为独立且几乎不会同时出现在同一场景中,因此,在计算天气要素特征权重评分时省略重要权重的赋值过程,仅结合

表 2 天气要素影响系数分布

Table 2 Distribution table of influence coefficients of weather elements %

天气要素	传感器类型	传感器类型		
		相机	毫米波雷达	激光雷达
光照	小	10	—	—
	中	0	—	—
	大	5	—	—
雨	小	40	25	30
	中	70	47	70
	大	75	53	80
雪	小	20	5	50
	中	40	32	80
	大	60	60	90
雾	小	10	10	50
	中	25	20	80
	大	60	40	90

表2中的影响系数计算具体评分 $S_{i(\text{weather})}$,如式(12)所示:

$$S_{i(\text{weather})} = 1 + I_w \quad (12)$$

综合各场景要素对相机、毫米波雷达、激光雷达的影响,得到场景要素与感知系统的复杂度映射关系 $E_{\text{perception}}$,结果如式(13)所示:

$$E_{\text{perception}} = \sum S_i \left(\frac{1}{T_i} \int I_{\beta} dt \cdot \Pi S_{i(\text{weather})\beta} \right) \Big|_{\beta=c,m,r} \quad (13)$$

式中: T_i 为场景要素 i 被感知系统 β 捕捉到的总时长; $S_{i(\text{weather})\beta}$ 为对感知系统 β 产生影响的天气要素特征权重评分。

若场景要素 i 由多类感知系统通过感知融合进行识别,该要素对应的感知系统复杂度 $E_{\text{perception}}$ 依照融合传感器类别数量取均值。

2.2.2 决策系统复杂度映射

本文提出决策规划裕度的概念对场景要素与决策系统间的复杂度映射结果进行量化,决策规划裕度指自动驾驶汽车在较短时间内可规划行驶的区域范围。决策规划裕度越小表明自动驾驶决策系统操作空间越小,当前时刻场景要素组合对决策系统的影响越大。

决策规划裕度计算过程分为车辆行驶势场和车辆可达域两部分,前者为周围交通环境对自动驾驶汽车决策的影响,后者为自动驾驶汽车自身动力学限制导致的行驶范围。

(1) 车辆行驶势场

车辆可操作空间通过势场模型进行计算。包含静态场景要素势场及动态场景要素势场两部分。静态场景要素可以细分为场景静态物以及约束类设施。

场景静态物如暂时操纵层中的交通事故、临时停放等要素,对于自动驾驶汽车而言均具备碰撞风险,因此,其在决策规划过程中对交通安全的影响程度较大。用 C_{p_i} 表征场景静态物要素的势场,计算过程如式(14)所示:

$$C_{p_i} = \frac{S_i r_i}{|r_i|^{k_1+1}} \quad (14)$$

式中: S_i 为场景要素特征权重评分; r_i 为自动驾驶汽车和场景要素之间的相对距离; k_1 为固定常数。

约束类设施如信号灯、限速牌、道路标线等,其更倾向于交通法规约束,与涉及生命财产损失等严重风险的相关关系较弱,因此,其在决策规划过程中对交通安全的影响程度相对较小。本文将

约束类设施归类为速度约束要素和位置约束要素,对其分别构建势场模型。使用 $C_{d_{si}}$ 表征车道线等位置约束要素的势场,其计算过程如式(15)所示。使用 $C_{d_{vi}}$ 表示限速牌、信号灯等速度约束要素的势场,其计算过程如式(16)所示,当场景要素为信号灯红灯时认为限速为0 m/s,场景要素为信号灯绿灯时认为限速为本车当前车速。

$$C_{d_{si}} = \frac{S_i r_i}{|r_i|} \left(\frac{D_i}{2} - r_i \right)^{k_2} \quad (15)$$

$$C_{d_{vi}} = \frac{S_i r_i}{|r_i|} (v_{di} - v_i)^{k_3} (x_i - r_i)^{k_4} \begin{cases} v_{di} = 0 \\ v_{di} = v_i \\ v_{di} = v_d \end{cases} \quad (16)$$

式中: D_i 为车道宽度; x_i 为目标场景要素的纵向位置; v_i 为自动驾驶汽车的行驶速度; v_{di} 为约束要素对应的速度; k_2, k_3, k_4 为固定常数。

对于动态场景要素,其可认为是具有运动特征的场静态物,参照式(14),动态场景要素的势场表征如式(17)所示。

$$C_{p_i} = \frac{S_i r_i}{|r_i|^{k_5+1}} \cdot \exp(k_6 v_i \cos \theta) \quad (17)$$

式中: v_i 为目标场景要素的移动速度; θ 为自动驾驶汽车和场景要素运动方向的夹角; k_5, k_6 为固定常数。

将静态和动态场景要素势场叠加,得到当前场景的总势场 $E_{\text{potential}}$,如式(18)所示:

$$E_{\text{potential}} = \sum C_{i\lambda} \Big|_{\lambda=D_s, D_v, p_i} \quad (18)$$

以双车道为例,道路中包含静态红绿灯及运动车辆,其势场结果如图3所示。

(2) 车辆可达域

车辆可达域指自动驾驶汽车未来短时间内由车辆动力学及考虑决策任务影响的可达到的道路区域,包括车辆可操作空间和车辆决策事件区域两部分。

车辆由动力学限制决定的可操作空间包含纵向和横向两部分。将纵向跟驰理论中车辆在一定速度下行驶到车辆制动停止的最小安全制动距离定义为自动驾驶汽车可操作空间的纵向极限距离,表达式如式(19)所示:

$$D_{\min} = \frac{v^2}{2a} \quad (19)$$

式中: a 为自动驾驶汽车最大减速度,取 $a=10 \text{ m/s}^2$; v 为车辆制动前的瞬时速度。

考虑车辆最大车轮转角,将静态前轮最大转




图3 场景要素势场示意图

Fig. 3 Schematic diagram of the potential field of scenario elements

角 $\beta=40^\circ$ 作为车辆转弯极限,进而获取横向可操作空间。

结合纵向及横向操作极限,计算自动驾驶汽车理论上可以进行运动的空间。在计算过程中,考虑在此时间段内周围场景要素尤其是动态场景要素的位置变化对场景要素势场的影响,本文选择假设本车减速至静止的时间内动态场景要素同样以最大减速度制动所产生的位置偏移作为动态要素最终的势场中心,进行后续决策裕度的计算。

决策事件区域指自动驾驶汽车短时决策过程需要考虑的周围车辆的范围。在同一场景中,车辆待决策任务区域是随车辆行驶过程不断变化的,通常和目标场景要素与车辆的相对距离有关。例如,某些场景要素虽然已经被自车传感器感知识别,但是其与自车的相对距离内有更近距离的场景要素对自车的行驶产生影响,则暂时不将其划分在决策事件区域内。由于一般将碰撞时间小于 2 s 作为危险场景的判断依据,本文选取 2 s 为时间边界,将自动驾驶汽车的决策事件区域定义为以自车车头为

圆心的半径 $R=2|v|$ 的半圆形范围。

将车辆可操作空间和车辆决策事件区域结合,基于实际道路边界得到自动驾驶汽车的可达域 $E_{\text{permission}}$,如图 4 中蓝色区域所示。

(3) 车辆决策规划裕度

设置危险度等级 Risk(图 3 中的 z 轴)小于等于危险度等级阈值 r 的势场区域作为自动驾驶汽车的安全行驶区域,其与车辆可达域的重叠部分面积可表示在当前时刻自动驾驶汽车可实现的较为安全的行驶路径所在区域,即车辆的决策规划裕度 E_{decision} 。以双车道为例,车辆决策规划裕度示意如图 5 中黄色与蓝色重叠区域的红色部分所示。

E_{decision} 的详细计算过程如式(20)所示:

$$E_{\text{decision}} = \frac{1}{T} \int E_{\text{potential}} |_{Risk \leq r} \cap E_{\text{permission}} \quad (20)$$

式中: T 为车辆行驶总时长。

2.2.3 执行系统复杂度映射

执行系统主要考虑车辆运动特征与轮胎-道




图4 自动驾驶汽车可达域

Fig. 4 Map of reachable areas for automated driving vehicles




图5 自动驾驶汽车决策规划裕度示意图

Fig. 5 Schematic diagram of decision planning margins for automated driving vehicles

路间的相互作用。对于车辆运动而言,轮胎是车辆与地面间接触的唯一媒介。根据轮胎魔术公式,其所能产生的侧向力和纵向力呈拮抗关系,其中一个维度的增加将导致另一维度的减少,因此,后备轮胎力可综合反映车辆剩余的可进行制动或转向的能力。本文基于后备轮胎力计算执行系统复杂度映射指标 $E_{\text{implement}}$, 剩余可利用轮胎力越小,认为当前车辆的运动状态更为极限,越难以对其进行操纵。将后备可利用轮胎力简化为当前车辆加速度与道路质量要素特征权重评分的乘积表示 $E_{\text{implement}}$, 如式(21)所示:

$$E_{\text{implement}} = \frac{1}{T} \int S_{\text{p}} \dot{v} \quad (21)$$

式中: S_{p} 为道路层中道路质量要素的特征权重评分; v 为被测车辆行驶速度。

2.3 场景复杂度耦合方法

由于自动驾驶系统中感知系统、决策系统和执行系统间固有的逻辑关系,场景与各子系统的复杂度映射关系并不是相互独立的,场景要素可以通过上层子系统间接对下层子系统产生影响,影响关系传递规则如图 6 所示。

将感知、决策和执行系统间的影响传递关系作为权重系数 θ_i 引入场景总复杂度的耦合过程,如式(22)所示:

$$\theta_i = \frac{l_i}{\sum_{i=1}^3 l_i} \quad (i = 1, 2, 3) \quad (22)$$

式中: l_i 为传递系数, $l_1=3, l_2=2, l_3=1$ 。

最终得到多系统场景复杂度耦合评价结果 E , 如式(23)所示:




图 6 自动驾驶子系统影响传递关系图

Fig. 6 Subsystem impact flowchart diagram for automated driving vehicles

$$E = \theta_1 E_{\text{perception}} + \theta_2 E_{\text{decision}} + \theta_3 E_{\text{implement}} \quad (23)$$

3 试验验证

通过 PreScan/Matlab 联合仿真平台对连续测试场景复杂度评估方法进行验证。在 PreScan 中创建仿真虚拟测试环境,包含环岛、复杂弯道、十字路口等道路场景的城市交通流模型,具体的道路模型如图 7 所示。在 Matlab 中搭建被测车辆和交通车的控制策略。本文采用驾驶策略存在差异的两种自动驾驶系统 A 和 B 进行验证。

首先,不考虑场景复杂度结果,仅基于车辆运动状态建立被测自动驾驶系统 A、B 性能评估体系。选取避障时平均车速表征行驶安全性,平均变道时间表征行驶效率,避障平均最小 TTC、车道保持距离道路中线最大距离表征行驶智能性,纵向加速度最大值、横向加速度最大值表征行驶舒适性。结合各指标的权重系数计算自动驾驶系统的综合评分^[26]。建立的被测系统性能评分指标及具体权重如表 3 所示。

随后考虑场景复杂度评估结果,对两种策略下自动驾驶汽车行驶过程中的行驶表现进行评价。

计算连续场景复杂度评估结果。以道路层三级分类中的道路类型、道路质量、道路数量、道路标线为例,通过可拓层次分析法求解 4 类场景要素在当前层级类别中的影响权重系数。根据专家



图 7 连续测试场景图

Fig. 7 Continuous test scenario

表 3 自动驾驶汽车综合性能评价指标表

Table 3 Comprehensive Performance evaluation index table for automated driving vehicles

总指标层	权重	指标层	权重	系统 A	系统 B
安全性	0.48	避障平均车速	1	18.19	14.89
效率	0.16	平均变道时间	1	5.44	8.72
智能性	0.07	避障平均最小 TTC	0.34	8.40	12.56
		车道保持距离道路中线最大距离	0.66	0.72	0.63
舒适性	0.29	纵向加速度最大值	0.62	2.57	2.10
		横向加速度最大值	0.38	2.06	1.53

调研结果构造重要性关系判定矩阵 A 。

$$A = \begin{bmatrix} \langle 1, 1 \rangle & \langle 2, 4 \rangle & \langle 1, 2 \rangle & \langle 1, 2 \rangle \\ \left\langle \frac{1}{4}, \frac{1}{2} \right\rangle & \langle 1, 1 \rangle & \left\langle \frac{1}{3}, \frac{1}{2} \right\rangle & \left\langle \frac{1}{3}, \frac{1}{2} \right\rangle \\ \left\langle \frac{1}{2}, 1 \right\rangle & \langle 2, 3 \rangle & \langle 1, 1 \rangle & \langle 1, 1 \rangle \\ \left\langle \frac{1}{2}, 1 \right\rangle & \langle 2, 3 \rangle & \langle 1, 1 \rangle & \langle 1, 1 \rangle \end{bmatrix} \quad (24)$$

进而求得区间上端点构成的上判定矩阵 A^+ 和区间下端点构成的下判定矩阵 A^- 对应的归一化特征向量 x^+ 和 x^- 和系数 k, m 。

$$\begin{cases} x^+ = [0.3801 \ 0.1146 \ 0.2527 \ 0.2527]^T \\ x^- = [0.3281 \ 0.1124 \ 0.2797 \ 0.2797]^T \\ k = \sqrt{\sum_{q=1}^4 \left(\sum_{p=1}^4 a_{pq}^+ \right)^{-1}} = 0.9061 \\ m = \sqrt{\sum_{q=1}^4 \left(\sum_{p=1}^4 a_{pq}^- \right)^{-1}} = 1.0896 \end{cases} \quad (25)$$

计算结果满足 $0 \leq k \leq 1 \leq m$, 说明可拓判定矩阵具有良好的 consistency。由此, 求出该分类层级的可拓区间数权重向量和归一化后的重要权重系数排序

$$U_3 = (0.3565 \ 0.1136 \ 0.2650 \ 0.2650)^T \quad (26)$$

同理, 分别计算二级分类和三级分类中其余场景要素类型的重要权重系数, 得到的权重结果以及对应的场景要素属性特征等级主观评分如表 4 所示。

通过要素重要权重和属性特征评分获取场景要素的复杂度数值, 并结合自动驾驶系统的实际行驶过程分别计算场景要素与感知、决策、执行系统复杂度映射 $E_{\text{perception}}$ 、 E_{decision} 和 $E_{\text{implement}}$ 。

表 4 场景要素评分表

一级分类	二级分类	重要权重系数	三级分类	重要权重系数	属性特征评分		
静态场景要素	道路层	0.1748	道路类型	0.356 5	3		
			道路质量	0.113 6	1		
			车道数量	0.265 0	2		
			道路标线	0.265 0	1		
	交通设施层	0.0828	信号灯	0.722 9	2		
			标志牌	0.201 1	2		
			其他设施	0.076 0	—		
			交通事故	0.439 1	—		
			临时操作层	0.0667	临时停放	0.318 7	—
					道路施工	0.242 2	—
动态场景要素	目标层	0.6757	机动车	0.128 8	3		
			非机动车	0.260 9	4		
			行人	0.610 3	3		

在计算场景要素-决策系统复杂度映射关系时, 为消除决策规划裕度在不同时刻车辆行驶状态差距较大导致总体评价产生偏差的问题, 使用当前测试场景下自动驾驶汽车最大速度对应的车辆可达域对决策规划裕度进行归一化处理。同时, 本文假设自动驾驶汽车在行驶过程中未出现跨越实线车道线、闯红灯等违反交通规则的行为, 选取危险度 $r=0.3$ 作为安全行驶区域阈值, 对不同时刻车辆决策规划裕度进行划分和计算, 得到结果如图 8 所示, 图中标注了裕度值波动较大位置的车辆行为, 通过整体趋势可以得出, 相比于自动驾驶系统 B 中较为平缓 and 保守的行驶规则, 自动驾驶系统 A 在自身的决策系统下, 通常留给自车的未来可操作空间较小。

为了表明场景复杂度计算过程的有效性, 针对图 8 中的决策差异结果进行详细解释。分别挑选搭载 A、B 自动驾驶系统的车辆行驶至相似路段时相机传感器采集视频的截取信息进行说明。

图 9(a)(b) 为车辆行驶在图 7 所示路段(1)附近, 图 9(a) 为 A 系统于 5.5 s 时的位置示意, 此时自动驾驶汽车对应图 8 中的①超车行为; 图 9(b) 为 B 系统于 8.6 s 时的位置示意, 此时自动驾驶汽车对应图 8 中的②超车行为。

图 9(c)(d) 为车辆行驶在图 7 所示路段(2)附近, 图 9(c) 为搭载 A 系统车辆于 9.3 s 时的位置示意, 此时自动驾驶汽车与前方多车距离较近, 并在随后完成对应图 8 中的③超车行为; 图 9(d) 为搭载 B 系统车辆遭遇相同多车场景的位置示意, 此时自动驾驶汽车选择远距离跟随策略。

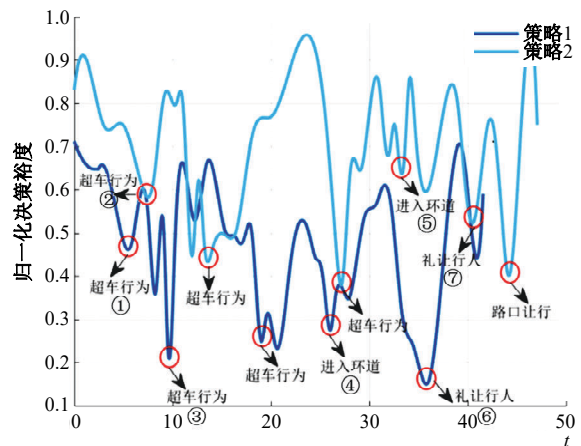


图 8 归一化自动驾驶汽车决策规划裕度图

Fig. 8 Normalized decision planning margin diagram for automated driving vehicles




图 9 自动驾驶汽车行驶路段对比图

Fig. 9 Comparison chart of road segments of automated driving vehicles

图 9(e)(f)为车辆行驶在图 7 所示路段(3)环岛附近,图 9(e)为搭载 A 系统车辆位置示意,此时对应图 8 中的④进入环岛;图 9(f)为搭载 B 系统车辆位置示意,此时对应图 8 中的⑤进入环岛,由于前期 A、B 系统的策略差异,可以很明显地看出二者进入相同路段的时刻不同,因此,与之产生交互的场景要素不同。

图 9(g)(h)为车辆行驶在图 7 所示路段(4)附近,图 9(g)为搭载 A 系统车辆位置示意,此时相机尚未识别行人,在车辆摆正姿态并进入直行路段后刚好与行人产生交互,对应图 8 中的⑥礼让行人;图 9(h)为搭载 B 系统车辆位置示意,车辆进入直行路段时行人已经几乎完成横穿车道的行为,因此,车辆选择了换道而不是制动策略,对应图 8 中的⑦礼让行人,同时在前方路口信号灯处的场景要素集合也是不同的,车辆将面对完全不同的行驶任务和交互行为。

通过上述分析可以发现,虽然被测车辆在同

样的环境(见图 6)中进行行驶,但是由于行为决策的差异,其所遭遇的场景是不同的,正是这些差异导致了图 8 中决策规划裕度的变化,并同时影响了两车的复杂度差异。通过统计分析,在本文创建的连续场景中,除沿路设施、道路标线等静态场景要素外,共计包含动态交通车 47 辆,与搭载 A 系统车辆产生实际交互 33 辆,与搭载 B 系统车辆产生实际交互 29 辆,还包含动态行人 1 人。A 系统所遭遇的场景更为复杂。图 8 中标注了多次换道超车行为、进出环岛、礼让行人、路口让行等复杂工况,均对自动驾驶感知、决策和执行系统复杂度映射关系产生了较为明显的影响,意味着通过这些场景要求自动驾驶系统具备相应的性能水平,也印证了 A、B 系统的策略区别导致遭遇场景的差异性决定了二者复杂度的不同。

综上,通过本文建立的计算过程依次计算每帧中的场景复杂度映射结果,最终综合得到场景要素相对于感知系统、决策系统和执行系统的复杂度映射如表 5 所示。

为比较两种自动驾驶系统的表现差异性,本文选取相对计分的方式对评价结果进行计算。最终得到自动驾驶系统 A、B 所在场景相对复杂度,将场景复杂度与前文得到的自动驾驶汽车综合评价得分相结合,得到本文评价方法下的相对得分,如表 6 所示。

从表 6 的数据可以看出,虽然一般连续场景自动驾驶汽车综合性能评价方法下自动驾驶系统 B 获得更高分数,但是通过连续测试场景复杂度评估方法可以发现,相比于自动驾驶系统 B 中较

表 5 要素-系统复杂度映射表

Table 5 Scenario elements-system complexity mapping relationship table

复杂度	系统 A	系统 B
感知系统	8.030 2	6.849 7
决策系统	0.525 1	0.295 8
执行系统	1.478 4	1.327 0

表 6 自动驾驶汽车性能综合评价表

Table 6 Comprehensive performance evaluation table for automated driving vehicles

评价项目	系统 A	系统 B
不考虑场景复杂度的评分	0.84	0.94
场景相对复杂度	1	0.765
考虑场景复杂度的评分	0.84	0.72

为平缓和保守的行驶风格,系统 A 的策略更激进果断。这使系统 A 在具有不确定性的连续场景中产生与更多场景要素交互的机会,同时也面临更频繁的行驶风险,意味着自动驾驶系统需要具备更高的性能。通过计算连续测试场景的复杂度评估结果,可以将被测自动驾驶汽车的行驶场景融入性能评价过程,从而平衡场景难度的差异造成的性能评价结果不公性,实现自动驾驶汽车性能全面、精准的评估。

4 结束语

本文面向自动驾驶汽车创建了一种连续测试场景的复杂度评估方法。将场景要素特征权重与自动驾驶各子系统与场景要素间的映射关系进行耦合,得到随被测车辆行驶状态变化的场景复杂度。通过 PreScan/Matlab 联合仿真平台构建的连续测试场景对评估方法进行了验证,与仅关注自动驾驶被测车辆结果级指标的评价方法比较,具备更好的公平性和全面性,为连续测试场景的测试评价提供了可借鉴的评判框架。

参考文献:

- [1] 赵祥模教授国家重点研发计划(2021YFB2501200)团队. 自动驾驶测试与评价技术研究进展[J]. 交通运输工程学报, 2023, 23(6): 10-77.
Zhao Xiang-mo's team supported by the National Key Research and Development Program of China(2021YFB2501200). Research progress in testing and evaluation technologies for autonomous driving[J]. Journal of Traffic and Transportation Engineering, 2023, 23(6): 10-77.
- [2] 朱冰, 张培兴, 赵健, 等. 基于场景的自动驾驶汽车虚拟测试研究进展[J]. 中国公路学报, 2019, 32(6): 1-19.
Zhu Bing, Zhang Pei-xing, Zhao Jian, et al. Review of scenario-based virtual validation methods for automated vehicles[J]. China Journal of Highway and Transport, 2019, 32(6): 1-19.
- [3] Shadrin S S, Ivanov A M, Makarova D A. Methods of parameter verification and scenario generation during virtual testing of highly automated and autonomous vehicles[C]//Intelligent Technologies and Electronic Devices in Vehicle and Road Transport, New York, USA, 2022: 1-6.
- [4] Amirul I A B, Mohd A A, Mohd F M S. Synthesis of autonomous vehicle guideline for public road-testing sustainability[J]. Sustainability, 2022, 14(3): 1-18.
- [5] Dixit V V, Chand S, Nair D J. Autonomous vehicles: disengagements, accidents and reaction times [J]. Plos One, 2016, 11(12): 1-14.
- [6] 王荣, 孙亚夫, 宋娟. 自动驾驶汽车道路测试场景评价方法与试验验证[J]. 汽车工程, 2021, 43(4): 620-628.
Wang Rong, Sun Ya-fu, Song Juan. Evaluation method and test verification of road test scenes for autonomous vehicles[J]. Automotive Engineering, 2021, 43(4): 620-628.
- [7] 李江坤, 邓伟文, 任秉韬, 等. 一种智能汽车测试场景复杂度的评估方法[C]//中国汽车工程学会年会论文集, 北京, 中国, 2020: 106-113.
- [8] 董汉, 舒伟, 陈超, 等. 危险驾驶工况场景的复杂度评估方法研究[J]. 汽车工程, 2020, 42(6): 808-814.
Dong Han, Shu Wei, Chen Chao, et al. Research on complexity evaluation method of dangerous driving scenes[J]. Automotive Engineering, 2020, 42(6): 808-814.
- [9] Liu Y K, Hansen J H L. Towards complexity level classification of driving scenarios using environmental information[C]//IEEE Intelligent Transportation Systems Conference, New York, USA, 2019: 810-819.
- [10] Kim I Y, Kang D Y, Jeong H. Method of evaluating multiple scenarios in a single simulation run for automated vehicle assessment[J]. Sensors, 2023, 23(19): 1-19.
- [11] Lu C R, Dong J, Houchin A. Incorporating the standstill distance and time headway distributions into freeway car-following models and an application to estimating freeway travel time reliability[J]. Journal of Intelligent Transportation Systems, 2021, 25(1): 21-40.
- [12] Winner H, Lemmer K, Form T, et al. Pegasus-first steps for the safe introduction of automated driving[C]//Road Vehicle Automation 5, Heidelberg, Germany, 2019: 185-195.
- [13] Xu T F, Zhao P. Image motion-blur-based object's speed measurement using an interlaced scan image[J]. Measurement Science and Technology, 2010, 21(7): 1-10.
- [14] 王战古. 不良天气条件下车辆检测方法研究[D]. 长春:吉林大学汽车工程学院, 2022.
Wang Zhan-gu. Research on vehicle detection method under adverse weather conditions[D]. Changchun: College of Automotive Engineering, Jilin University, 2022.

- [15] 李鑫. 面向汽车智能驾驶的毫米波雷达建模与仿真研究[D]. 长春: 吉林大学汽车工程学院, 2020.
Li Xin. Research on modeling and simulation of millimeter wave radar for vehicle intelligent driving[D]. Changchun: College of Automotive Engineering, Jilin University, 2020.
- [16] 赵轩. 基于路侧激光雷达的交通目标感知方法与实现[D]. 西安: 西安工业大学电子信息工程学院, 2023.
Zhao Xuan. Roadside lidar-based traffic target sensing method and implementation[D]. Xi'an: College of Electronic Information Engineering, Xi'an Technological University, 2023.
- [17] 葛平淑, 郭烈, 齐国栋, 等. 变光照环境下车道标识线的识别方法[J]. 激光与光电子学进展, 2020, 57(16): 1-6.
Ge Ping-shu, Guo Lie, Qi Guo-dong, et al. Lane marker line identification method in variable light environment[J]. Laser and Optoelectronics Progress, 2020, 57(16): 1-6.
- [18] 蒋渊德, 孙朋朋, 秦孔建, 等. 雨雪天气对自动驾驶视觉图像质量的影响[J]. 中国公路学报, 2022, 35(3): 307-316.
Jiang Yuan-de, Sun Peng-peng, Qin Kong-jian, et al. Influence of rain and snow on autonomous vehicles' camera[J]. China Journal of Highway and Transport, 2022, 35(3): 307-316.
- [19] Elizabeth E, Andrew B, Bani H N, et al. Experimental investigation of the effects of fog on optical camera-based VLC for a vehicular environment[C]// 15th International Conference on Telecommunications, New York, USA, 2019: 1-5.
- [20] Zang S Z, Ding M, Smith D, et al. The impact of adverse weather conditions on autonomous vehicles: how rain, snow, fog, and hail affect the performance of a self-driving car[J]. IEEE Vehicular Technology Magazine, 2019, 14(2): 103-111.
- [21] 白雪松, 邓伟文, 任秉韬, 等. 一种自动驾驶仿真场景要素的提取方法[J]. 汽车工程, 2021, 43(7): 1031-1036.
Bai Xue-song, Deng Wei-wen, Ren Bing-tao, et al. An extraction method of scenario elements for autonomous driving simulation[J]. Automotive Engineering, 2021, 43(7): 1031-1036.
- [22] Keisuke Y, Naoki S, Ryo Y, et al. Automated driving recognition technologies for adverse weather conditions[J]. IATSS Research, 2019, 43: 253-262.
- [23] 孙朋朋, 赵祥模, 蒋渊德, 等. 降雨条件对车载激光雷达性能影响的试验研究[J]. 中国公路学报, 2022, 35(11): 318-328.
Sun Peng-peng, Zhao Xiang-mo, Jiang Yuan-de, et al. Experimental study of influence of rain on performance of automotive lidar[J]. China Journal of Highway and Transport, 2022, 35(11): 318-328.
- [24] 何俊南, 姜京秀, 孙朋朋. 降雪环境对激光雷达性能的影响分析与试验研究[J]. 时代汽车, 2023, 12: 20-22.
He Jun-nan, Jiang Jing-xiu, Sun Peng-peng. Analysis and experimental research on the influence of lidar performance in snowfall environment[J]. Auto Time, 2023, 12: 20-22.
- [25] Kuttila M, Pyykönen P, Holzhüter H, et al. Automotive lidar performance verification in fog and rain[C]// 21st International Conference on Intelligent Transportation Systems, New York, USA, 2018: 1695-1707.
- [26] Wang W, Wu L G, Li X, et al. An evaluation method for automated vehicles combining subjective and objective factors[J]. Machines, 2023, 11(6): 1-22.