文章编号：0253-374X(2025)10-1553-11

DOI：10.11908/j.issn.0253-374x.24165

山区高速公路自动驾驶车道检测失效分析

陈志贵[1,2]，王雪松[1]，孙雨宸[1]

(1. 同济大学 道路与交通工程教育部重点试验室，上海 201804；2. 江南造船(集团)有限责任公司，上海 201913)

摘要：自动驾驶车辆在山区高速公路行驶时需要感知不断变化的道路线形、路段特征以及环境等因素，并解析安全行驶边界。针对山区高速公路，测试了基于激光雷达的感知性能，分析了车道线感知失效的影响因素。研究采用同济大学车载全息信息采集系统，实车测试路段为贵州省贵都高速公路，全程多次往返测试累计3 200 km。基于CatBoost模型和沙普利加和解释(SHAP)方法解释了11个特征变量对感知失效的影响。研究结果表明，存在以下特征时会检测出更高概率的感知失效，例如下游曲率最大值越大、坡度变化率越大、出口和入口路段、路面有纵向和横向减速标线等地面标线、天气不良、自车行驶速度越大等。该研究的结果不仅可以为山区高速公路提供更适合自动驾驶安全运营的措施，更好地适应自动驾驶车辆，而且还能为制定自动驾驶的运行设计域提供参考。

关键词：交通工程；自动驾驶；CatBoost模型；山区高速公路；车道线感知

中图分类号：U491.2　　**文献标志码**：A

Reliability Analysis of Autonomous Driving Lane Detection on Mountainous Freeways

CHEN Zhigui[1,2], *WANG Xuesong*[1], *SUN Yuchen*[1]

(1. Key Laboratory of Road and Traffic Engineering of the Ministry of Education, Shanghai 201804, China; 2. Jiangnan Shipyard (Group) Co., Ltd., Shanghai 201913, China)

Abstract: Autonomous vehicles need to perceive constantly changing road alignments, section characteristics, and environmental factors when driving on mountainous freeways, and analyze safe driving boundaries. This paper focuses on testing the lane detection performance of autonomous vehicles based on LiDAR in mountainous freeway environments and analyzes the influencing factors of lane perception failure. Using the Road and Traffic Holographic Data Acquisition System of Tongji University, the on-road vehicle test was conducted on the Guidu freeway in Guizhou Province, with multiple round trips totaling 3 200 kilometers. The impact of 11 feature variables on perceived failure was explained based on the CatBoost model and Shapley Additive exPlanations (SHAP). The research results indicate that weather factors have the most significant impact on the perception failure of lane markings, followed by the influence of road alignments. Specifically, a higher probability of perceptual failure will be detected when there are the following characteristics: larger maximum curvature, larger grade change rate, exit, and entrance sections, longitudinal deceleration markings, lateral deceleration markings, higher driving speed, etc. The results of this paper can not only provide measures more suitable for the safe operation of autonomous driving on mountainous highways, adapting better to autonomous vehicles, but can also serve as a reference for establishing the operational design domain for autonomous driving.

Keywords: transportation engineering; autonomous driving; CatBoost model; mountainous freeway; lane line perception

山区地形和地质条件复杂，导致高速公路设计特征复杂，道路几何线形设计常采用规范中的极限值。受复杂线形等因素影响，人类驾驶员会出现车道偏移等危险行为。随着自动驾驶技术的发展，越来越多汽车厂商开始进行实车测试，美国加州发布了自动驾驶脱离事件报告[1]，发现发生在高速公路上的事故往往会有更大的安全风险。因此，有必要针对山区高速公路开展自动驾驶的行车安全性评价，发现影响安全性的道路、交通、环境等因素，以便进行针对性的自动驾驶安全性改善，为山区高速公

收稿日期：2024-05-10
基金项目：国家自然科学基金面上项目(52372335)
第一作者：陈志贵，工学博士，主要研究方向为交通安全。E-mail：zgchen@tongji.edu.cn
通信作者：王雪松，教授，博士生导师，工学博士，主要研究方向为交通安全。E-mail：wangxs@tongji.edu.cn

论文拓展介绍

路引入高级别自动驾驶车辆做好设施准备。

在山区高速公路上,自动驾驶车辆的安全行驶依赖于准确可靠的感知、规划决策和控制过程。其中,环境感知是自动驾驶车辆运行基础,通过环境感知,自动驾驶车辆可以获得周围环境中道路、标志标线、环境车、障碍物等信息,感知结果的准确性直接影响后续决策控制系统的表现[2]。在山区高速公路行车时,不断变化的道路几何线形要求自动驾驶车辆获得准确的安全行驶边界[3],保证车辆行驶在安全的范围内,以避免与周围车辆或道路设施发生碰撞[4]。美国加州自动驾驶脱离事件报告中指出了车道检测失效是车辆脱离的根本原因之一[1]。自动驾驶车辆会基于感知得到的车道线范围,标定安全行驶边界作为规划控制的基础[2],因此,车道线检测的准确性可以描述自动驾驶感知是否存在失效[5]。车道线检测的宽度是车道线感知结果的直接量化体现,可以作为车道线感知的定量评价指标[4]。

激光雷达主要利用电磁波反射原理,生成3D点云地图的方式感知物体,因其基本不受光照等条件的影响[6],常被应用于自动驾驶车辆的车道线感知[7]。然而,激光雷达也存在受环境影响而引起感知失效的情况,已有研究从天气角度分析降雨的环境会引起激光雷达感知有效性的降低[8],自动驾驶车辆前方环境中的水滴颗粒不仅会吸收和散射激光束,而且还会增加激光雷达激光束探测的噪声,从而影响精度。平纵变化的曲线会使激光雷达感知范围、角度发生变化,道路几何线形也被认为会影响激光雷达感知精度[9]。总之,虽然激光雷达已具备较好的车道线检测性能,但山区高速公路的环境依旧可能会造成其感知失效,已有的研究多从单一角度,如天气、几何线形、车辆运行等角度分析感知失效,缺乏山区高速公路实车测试以及系统的影响因素分析。

因此,本文基于山区高速公路的实车测试,研究了高速公路设计和环境特征,对基于激光雷达的自动驾驶车道检测性能的影响。测试设备为同济大学车载全息信息采集系统,测试道路为贵州省贵都高速公路,全程多次往返测试累计3 200 km,涵盖不同天气、光照以及行驶车道。因变量为激光雷达传感器的车道线感知失效事件,自变量包括5种特征类型,包括道路线形、路段类型、地面标线、环境和车辆运行。本文对比了两种模型,根据模型预测的召回率和精确度结果,选择了表现更优的CatBoost模型,并基于沙普利加和解释(Shapley Additive exPlanations, SHAP)方法分析了特征变量与感知失效关系。

1 数据采集

1.1 车载全息信息采集系统

本研究采用同济大学车载全息信息采集系统进行数据采集,图1为配备有采集设备的测试车辆(BUICK SGM7247ATA),车辆高度为1.49 m,采集设备总高为1.85 m。采集系统是一套以激光雷达为主传感器,配合毫米波雷达、高清摄像头、实时动态差分定位(real-time kinematic, RTK)与惯性导航组合系统的传感器评测系统。其中,主激光雷达为一个128线的RS-Ruby,最大有效探测范围为200 m;补盲激光雷达由两个32线激光雷达组成;两个毫米波雷达作为感知传感器,可以实现周围360°环境感知;另有6个Leopard相机以及一个Mobileye EQ4。采集系统的采集频率是10 Hz。

图1 同济大学车载全息信息采集系统

Fig. 1 Road and Traffic Holographic Data Acquisition System of Tongji University

在本研究中的车道线检测和拟合数据来自速腾聚创(RoboSense)的激光雷达。激光雷达的感知求解算法提供两个分段拟合函数,分割点设置为测试车辆下游40 m,分别为下游0~40 m和40~200 m范围内的路段提供车道拟合方程。此深度学习方法可得出更好的车道拟合结果和更小的预测偏差,表现为鲁棒性较强,适合复杂且计算量大的环境。

1.2 测试道路

本研究选择位于贵州省的贵都高速公路作为实车测试对象。贵都高速公路里程为80 km,本研究全程往返测试20次。测试路段符合山区高速公路的特征,共有18条隧道、54座桥梁以及5座互通式立交,平曲线最小半径为700 m,竖曲线最大坡度为

±4.8 %，双向4车道。全线除隧道段限速100 km·h^{-1}，隧道内限速80 km·h^{-1}。

为了确保测试数据集包含不同环境和行驶车道，其中有8次测试包含雨天环境，4次测试为夜间进行。另外，主要行驶车道为内侧车道（靠近中央分隔带）以及外侧车道的次数分别是12次及8次。

1.3　因变量处理

本研究选择车道检测能力作为自动驾驶感知的评价指标，使用车道线宽度检测误差反映检测能力。因变量为每一帧车道线宽度感知是否失效，数据格式为二分类数据。每一帧中感知系统检测的车道线宽度为w_d，实际车道线宽度为w_r。则车道线宽度感知误差为ε_w，计算方式如式(1)，正值表示高估实际宽度，负值表示低估实际宽度。

$$\varepsilon_w = w_d - w_r \tag{1}$$

将低估车道线宽度的误差安全阈值定义为ε_{under}，高估车道线宽度的误差安全阈值定义为ε_{over}。将车道线宽度感知误差ε_w超过安全阈值的帧，定义为感知失效帧，因变量取值为1。感知失效帧判定条件为满足$\varepsilon_w < \varepsilon_{under}$或$\varepsilon_w > \varepsilon_{over}$。

将车道线宽度感知误差在安全阈值内的帧，定义为感知未失效帧，因变量取值为0。感知未失效帧判定条件为满足$\varepsilon_{under} \leqslant \varepsilon_w \leqslant \varepsilon_{over}$。

车道线宽度检测误差安全阈值ε_{over}、ε_{under}的设定，需首先满足超过阈值会增加自动驾驶车辆运行风险。因此，本研究将车道线宽度感知误差造成测试车辆横向边缘超过实际车道边界时的临界条件，设定为安全阈值确定依据[10]。

其次，安全阈值设定需满足失效判定过程标准统一。如图2所示，在基于失效临界状态的计算阈值时，设定一侧检测车道线与实际车道线重合，检测车道宽度与实际车道宽度的相对关系唯一，可根据检测宽度误差得出确定的因变量取值。设定车辆位于检测车道中心线，可减少车辆相对位置不确定带来的误判，使判定标准统一。

因此，根据图2中临界状态的变量关系，低估车道线宽度的误差安全阈值ε_{under}由式(2)计算得到：

$$\varepsilon_{under} = w_v - w_r \tag{2}$$

高估车道线宽度的临界条件可以得出式(3)，进一步推导得出ε_{over}计算式(4)：

$$\frac{w_d}{2} + \frac{w_v}{2} = w_r \tag{3}$$

$$\varepsilon_{over} = w_r - w_v \tag{4}$$

式(3)—(4)中：w_v为车辆宽度，由于车辆宽度越大，检测误差安全阈值越严格，为了扩大研究结果适用性，w_v为乘用车、客车、货车的最大允许宽度，根据《汽车、挂车及汽车列车外廓尺寸、轴荷及质量限值》(GB1589—2016)[11]中规定，w_v取为2.55 m。测试高速公路的实际车道宽度w_r为3.75 m。

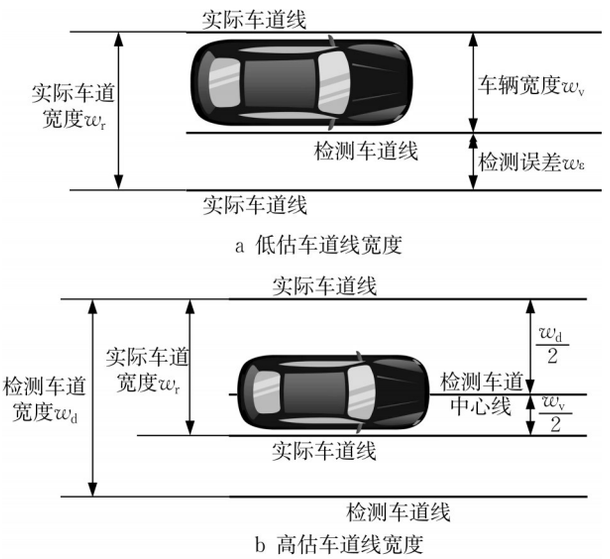

图2　车道线感知失效临界状态

Fig. 2　Critical state of lane detection failures

1.4　自变量处理

本文考虑的影响因素包括道路几何线形、路段特征、地面标线、环境和车辆运行。在自变量选取过程中，首先参考了针对激光雷达感知失效的研究结论，这些研究涉及外部环境和道路几何线形等因素[8-9]；另一方面，基于激光雷达激光束探测原理，选择对探测性能有影响的山区高速公路潜在因素。这5类自变量数据来源包括采集系统、高速公路设计图纸、视频和现场人工记录，以下为5类自变量的具体内容。

(1)道路几何线形

道路几何线形数据来自设计图纸，包括当前位置曲率绝对值、曲率变化率、平曲线类型，下游最大曲率等平面线形特征，以及当前位置坡度、坡度变化率、竖曲线类型，下游坡度最大值等纵断面线形特征。其中，曲率半径大于3 km时，定义为直线，反之为曲线；坡度大于等于3 %为上坡，坡度小于等于—3 %为下坡，在—3 %至3 %之间为平坡，上下游500 m范围内存在凸曲线或凹曲线，定义为凸曲线或凹曲线。

(2)路段类型

路段类型数据来自设计图纸以及现场记录，反映测试车辆当前所处的路段类型，包括一般主线、隧道、桥梁、入口、出口以及出口-入口中间段。图3为各类型路段的实例。

a 一般主线 b 桥梁 c 隧道

d 出口 e 入口 f 出口-入口中间段

图3 路段类型

Fig. 3 Road segment type

(3)地面标线

地面标线数据来自设计图纸以及视频记录,包括两侧车道线形式,本研究的测试道路共有双实线、左实右虚、左虚右实、双虚线、右侧加速车道、右侧减速车道等6种形式;测试车辆当前位置是否有纵向减速标线;以及测试车辆当前位置是否有横向减速标线、文字、箭头等其他地面标线。测试期间地面标线磨损情况基本一致,本研究忽略地面标线磨损差异。

(4)环境

环境数据包括天气和光照。天气数据来自现场人工记录,其中晴天、多云及阴天记录为良好,存在降雨的天气或者雾天记录为不良。光照数据来自现场人工记录,包括白天和夜晚。图4为降雨和夜晚的实例。

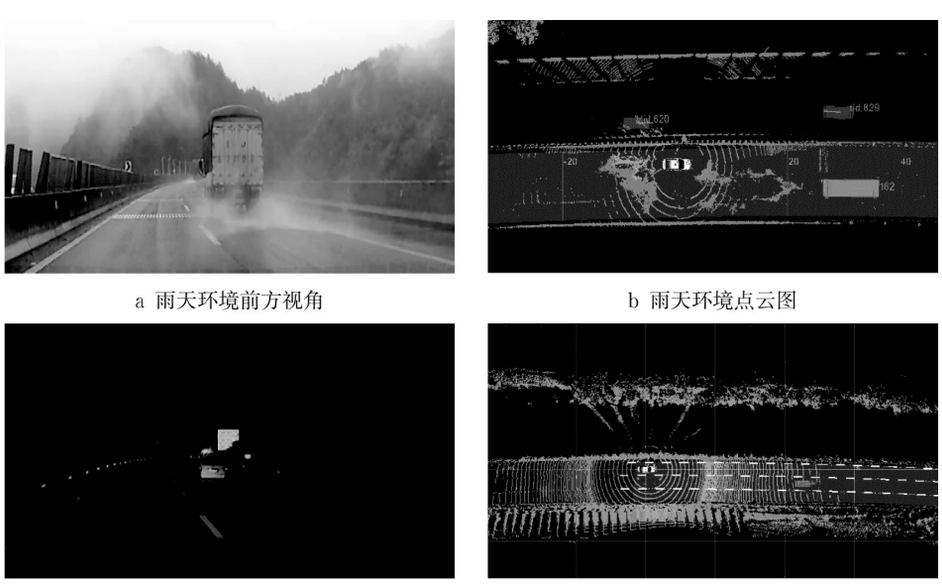

a 雨天环境前方视角 b 雨天环境点云图

c 夜间环境前方视角 d 夜间环境点云图

图4 降雨和夜晚环境

Fig. 4 Rainfall and night environment

(5)车辆运行

车辆运行数据包括自车行驶速度、前方最近大型车辆距离以及行驶车道。其中,自车速度来自RTK组合惯性导航系统记录;环境车指标主要考虑前方为大型车辆时的视线遮挡,采用前方最近大型车辆距离,数据是激光雷达和毫米波数据融合结果,

并处理为每5 m一个区间；测试车辆行驶车道数据来自现场人工记录，包括左侧（内侧）车道和右侧（外侧）车道。

2　分析模型

2.1　描述性统计

本研究共采集了128.2万帧车道检测数据，根据感知失效帧定义，有6.2万帧被判定为感知失效帧，即4.8 %的样本为失效，剩余95.2 %的样本为未失效。

针对自变量中连续变量的描述性统计如表1和图5所示。表1为变量分布特征。图5为具有不同曲率和坡度的路段感知失效率分布特征，分析样本为天气良好，结果显示随着曲率半径的增加，失效率降低；在上坡路段（坡度$G>0$），整体上表现出随着坡度的增加，失效率增加，在$G>3$ %时最高；在下坡路段，整体上表现出随着坡度的降低，失效率增加，在$G<-3$ %时最高。描述性统计结果反映出平曲线半径越小（弯道越急）以及上坡坡度越大、下坡坡度越小（纵坡越陡）时，感知失效率越高的趋势。本研究采集系统中激光雷达传感器的最大探测范围为200 m，因此自变量的下游（前方）计算长度为200 m。

表1　连续变量描述性统计

Tab. 1　Descriptive statistics of continuous variables

变量分类	变量名	单位	最小值	中值	平均值	最大值	标准差
道路线形	曲率	km^{-1}	0	0.23	0.33	1.43	0.35
	曲率变化率	km^{-2}	0	0	0.81	9.23	1.90
	下游曲率最大值	km^{-1}	0	0.25	0.36	1.43	0.36
	坡度	%	−4.78	0.23	0.07	4.78	2.43
	坡度变化率	%•km^{-1}	0	0	2.78	20.05	3.61
	下游坡度最大值	%	0.18	2.51	2.32	4.78	1.04
车辆运行	自车行驶速度	m•s^{-1}	8.34	24.33	24.01	32.46	2.94
	前方最近大型车辆距离	m	5.00	215.00	184.50	215.00	65.90

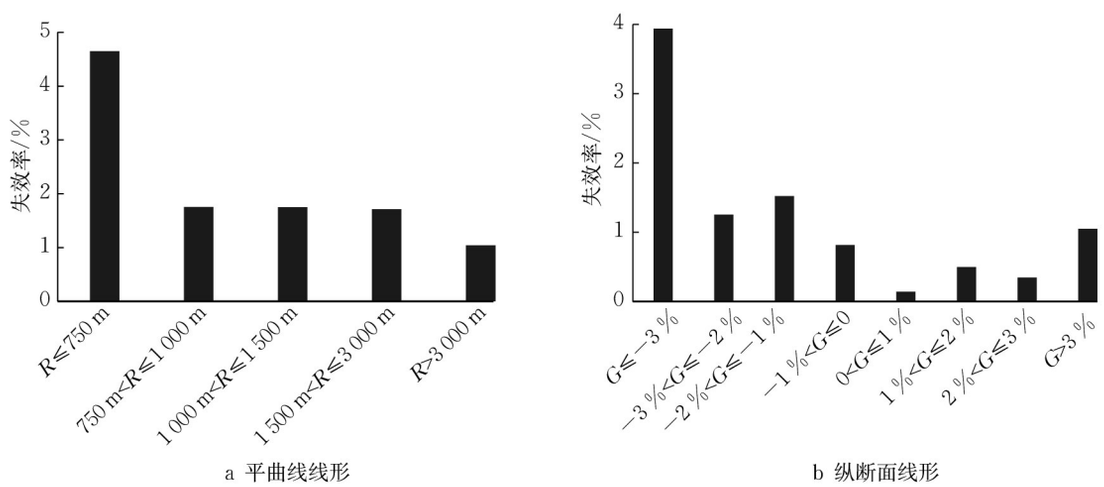

a 平曲线线形　　b 纵断面线形

图5　不同路段感知失效比例

Fig. 5　Proportion of perception failure by different road sections

针对分类变量的描述性统计如表2所示，包括样本占比与失效比例。结果表明：更复杂的线形、路段类型、地面标线、环境会有更高的失效率。如曲线路段失效率高于直线路段，凹曲线、凸曲线路段高于平坡路段，天气不良条件下高于天气良好等。

在针对不同路段设施类型分析时发现隧道内的样本失效率为1.7 %，显著低于其他5种设施，说明隧道内外检测结果存在较大差异。考虑到隧道内受天气影响小，且线形、地面标线相对于隧道外更简单，本文后续建模将隧道外的样本作为建模对象，占总样本的59.8%。

自变量间的多重共线性会导致模型估计失真或参数估计不准确。本文使用Pearson相关系数（r）检验特征间的相关性，对相关系数绝对值大于0.8的特征对进行筛选。结果表明，下游曲率最大值与曲率之间存在强相关性（$r=0.93$），在预分析时发现下

表2 分类变量描述性统计

Tab. 2 Descriptive statistics of categorical variables

变量类型	变量名	变量取值	样本占比/%	失效比例/%
道路线形	平曲线类型	直线	82.3	4.4
		曲线	17.7	6.8
	竖曲线类型	平坡	36.8	2.5
		上坡	4.7	5.8
		下坡	4.7	5.7
		凹曲线	23.5	6.3
		凸曲线	30.3	6.2
路段类型	车辆位置所属路段的类别	一般主线	27.1	6.8
		隧道	40.2	1.7
		桥梁	29.3	6.8
		入口	1.0	6.5
		出口	1.3	11.6
		出口-入口中间段	1.1	6.7
地面标线	车道线	双实	47.3	2.4
		左实右虚	35.6	5.8
		左虚右实	16.1	8.6
		双虚	0.1	6.7
		右侧加速车道	0.5	14.4
		右侧减速车道	0.4	29.0
	纵向减速标线	无	96.6	4.5
		有	3.4	13.9
	其他地面标线	无	88.2	4.2
		有	11.8	9.8
环境	光照	白天	79.5	5.6
		夜晚	20.5	1.8
	天气	良好	79.9	1.7
		不良	20.1	17.1
车辆运行	行驶车道	左侧车道(内侧)	70.0	4.0
		右侧车道(外侧)	30.0	6.7

游曲率最大值表现出更好的预测效果,因此建模时选择使用下游曲率最大值作为解释变量。平曲线类型与曲率、下游曲率最大值的相关性分别为0.47、0.43,表现出中等相关性,车道线类型与行驶车道也表现出中等相关性(r=0.54)。其余变量之间均表现为低相关性(r<0.3)。

2.2 分析模型

本研究属于分类变量的预测问题,选择二元逻辑回归模型和CatBoost模型作为分析方法,根据模型预测的召回率和精确度结果,选择表现更优的模型进行影响因素分析。

(1)逻辑回归

逻辑回归(logistic regression)是一种广义的线性回归算法,常用于二分类问题。通过使用逻辑函数将线性回归的输出映射到0~1之间的概率,从而预测一个事件的发生概率。逻辑回归的主要目的是求得最佳的权重参数,使得模型对于给定的输入数据可以最大限度地预测正确的类别,即模型的损失函数最小,拟合程度最好。逻辑回归模型简单、高效并易于解释,但它假设数据特征与对数几率是线性关系,这可能与实际问题存在一定偏差。

(2) CatBoost

集成学习(ensemble learning)是一种通过组合多个基学习器的预测结果来提升模型性能的方法,能够有效减少误差,提高准确性和稳健性。其中,CatBoost(categorical boosting)是由Prokhorenkova等[12]提出的一种梯度提升决策树(GBDT)算法的改进版,其核心设计包括一种对称决策树和有序提升(ordered boosting)技术,这些技术共同解决了传统GBDT在分类特征处理上的不足,并明显减少了模型训练过程中的过拟合风险。

CatBoost在处理分类特征的数据集时具有显著优势[13],能够直接处理分类变量,无需进行独热编码(one-hot encoding),从而减少模型计算复杂度,并且可以避免分类变量转换时的信息损失。在本研究中,潜在变量中有56.3 %为分类变量,包括道路线形、路段类型、地面标线和环境等。考虑到分类变量占比高的特征,相较于XGBoost和LightGBM等其他集成学习方法,CatBoost更适用于本研究。

(3) SHAP

SHAP(Shapley Additive exPlanations)是一种将复杂模型的预测结果解释得更清晰易懂的方法,它借鉴了博弈论中的Shapley值的概念[14]。Shapley值是一种公平分配合作游戏中收益的方法,Shapley值为每个玩家分配一个值,表示他们对游戏总收益的贡献。它考虑了每个人对项目成功的贡献,以确保每个人得到的奖金与他们的贡献成正比。Shapley值的计算公式如(5)所示[15]。

$$\phi_i=\sum_{S\in N\backslash\{i\}}\frac{|S|!(n-|S|-1)!}{n!}\left[v(S\cup\{i\})-v(S)\right] \tag{5}$$

式中:Φ_i为特征i的Shapley值;N为所有特征的集合;S为不包括特征i的特征子集;n表示特征的数量;$v(S)$为对集合S中特征值的预测。

由于CatBoost模型本身对预测结果的解释较为困难,本研究采用SHAP方法来进行模型解释。SHAP方法特别适用于解释基于树的模型,如CatBoost。通过计算各特征的SHAP值,可以量化每个特征在模型预测中的贡献。本研究具体采用SHAP的Tree计算方法,使用Tree Explainer来计算SHAP值。在预测模型中,SHAP值测量每个自变

量对预测结果的贡献大小，不仅可用于解释单个预测，还能帮助理解模型的整体行为，从而使模型的预测过程更具可解释性。

2.3　模型比选

本文随机选取数据集的70 %作为训练集，剩下30 %作为测试集。为了计算训练的模型性能，使用了混淆矩阵的概念。对于分类问题，根据实际类别和预测类别的组合，结果可分为4类：真阳性（TP）、假阳性（FP）、真阴性（TN）和假阴性（FN），分类结果的混淆矩阵见表3。在本文中，阳性样本为车道线感知失效，阴性样本为车道线感知未失效。

表3　混淆矩阵

Tab. 3　Confusion matrix

	预测正例	预测负例
实际正例	true positive（TP）	false negative（FN）
实际负例	false positive（FP）	true negative（TN）

在混淆矩阵基础上，本文采用模型评价指标为召回率、精确度和F1值。召回率（Recall）表示所有实际类别为正例的样本中，被预测正确的样本数所占的比例。精确度（Precision）表示所有被预测为正例的样本中，实际类别为正例的样本数所占的比例。F1分数综合考虑了精度和召回率，是精度和召回率的调和平均值。三者的值均在[0,1]之间，越接近1越好。本文采用网格搜索的方法确定具有最高召回分数的最优参数。针对测试集的具体评价结果如表4所示，结果表明经过训练的CatBoost具有更优的性能，测试集的召回率为0.88、精确度为0.93、F1值为0.90，因此本文使用CatBoost模型作为车道检测失效分析模型。

表4　评价结果

Tab 4　Evaluation results

模型	评价指标		
	召回率	精确度	F1值
逻辑回归	0.73	0.89	0.80
CatBoost	0.88	0.93	0.90

3　模型结果与分析

3.1　特征重要性

CatBoost模型结果包含道路线形、路段类型、地面标线、车辆运行和环境中11个自变量，为降低模型复杂度，同类特征变量选取预测效果最优的变量，如纵断面坡度变量选择坡度变化率。将每个自变量中所有样本SHAP值的绝对值取平均，得到11组样本的平均SHAP值。通过平均SHAP值分析特征重要性，平均值越大的特征越重要，影响越大。平均SHAP值的特征重要性排序表明：天气是最重要的特征，下游曲率最大值、自车行驶速度依次是第二、三重要的特征。本研究结论表明山区高速公路车道线感知失效影响因素包括环境、道路几何线形、车辆运行、路段类型以及地面标线。

3.2　特征解释

为了进一步分析每个特征的值与CatBoost模型预测结果之间的关系，本文提供了SHAP依赖图，图中每一个点代表一帧的车道线感知结果，x轴是特征，y轴是车道线感知的SHAP值，为该特征的车道线感知失效的对数几率，SHAP正值表示感知失效，而负值表示感知未失效。此外，SHAP值的绝对值越大，感知就越容易失效或越不容易失效。

（1）道路几何线形

图6显示了道路线形特征变量的结果。随着下游曲率最大值的增加，SHAP值随之增加，失效概率整体呈现出增加的趋势。下游曲率最大值大于0.6 km^{-1}时，失效概率表现出明显的增加。说明自动驾驶汽车在面对下游出现的小半径曲线时，车道线感知失效的可能性会增加。自变量描述性统计结果中，曲线路段失效占比比直线路段高54.6 %，与CatBoost模型结论一致。So等[9]研究也发现具有不良几何线形的路段，配备激光雷达的自动驾驶汽车依旧难以顺利通过，而当道路几何线形不太复杂时，自动驾驶系统的性能要求水平会增加。

激光雷达对车道线的感知依赖于精准有效的反射数据，而复杂的道路线形会引起感知数据的采样角度变化情况。在直线行驶时，激光雷达通常以相对固定的垂直距离检测车道线，而在曲线行驶时，这个距离会随着车辆沿曲线的移动而变化，因为雷达扫描到的车道线不再是正对车辆的，而是呈现出一定角度的，可能会增加系统判断车道宽度的误差。另一方面，前方远处的线形为曲线时，视距的降低可能会造成激光雷达采集数据的部分缺失，并且前方车道线反射的数据只会占据激光雷达测量结果的很少层，这种采样的不均匀也会影响对车道线宽度的预测精度[16]。

关于纵断面线形，纵断面坡度变化率的增加会带来感知失效的概率增加，纵断面坡度变化率反映的是竖曲线的凹凸程度，即竖曲线为平坡、上坡、下坡时，凹凸曲线程度低，失效概率也相对较低。当测试车辆位于凹曲线或凸曲线路段时，竖曲线的坡度

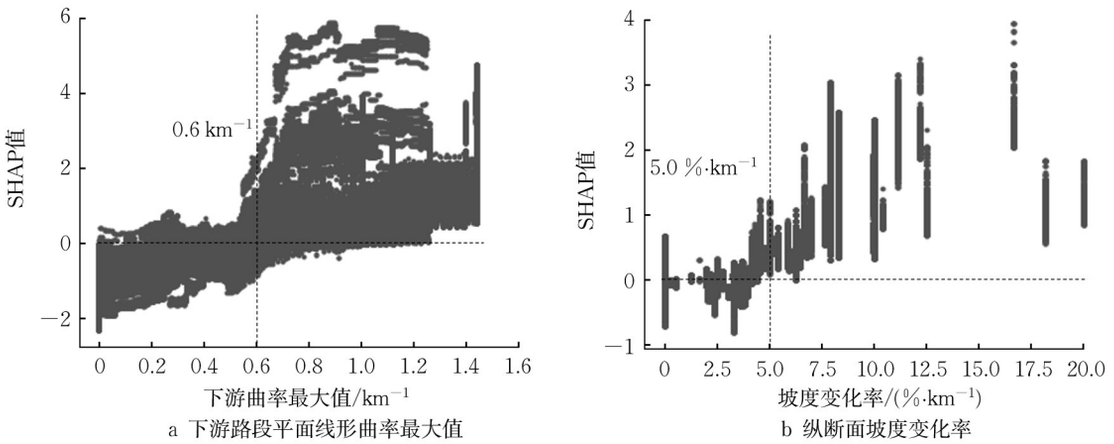

图6 道路线形特征的SHAP依赖图

Fig. 6 SHAP dependence plots for road alignment characteristics

变化率就会大于0。图6b为CatBoost模型结果,当坡度变化率大于5.0 %·km^{-1}时,SHAP值大于0,失效概率明显增加;且失效概率随着坡度变化率的增加而增加,说明纵断面凹凸程度越大,对感知失效的影响越大。

凹凸路面引起高度变化,可能导致激光雷达波束在垂直方向上的反射点距离发生变化,点云数据中表现为车道线位置的波动,从而影响宽度测量。在凸起的路面部分,车道线可能会在雷达波束的扫描路径之外,导致激光雷达无法探测到车道线的全部信息,也可能将凸起的路面检测为障碍物。在凹曲线的路段,激光束可能在凹陷区域内发生多路径反射,即激光束反射多次才回到传感器,已有研究针对多路径反射提出优化算法,但感知算法在凹曲线路段的干扰增加仍可能导致距离测量误差。另一方面,激光雷达在水平方向向上的检测角度是决定自动驾驶可用视距的关键因素[17],由于普通激光雷达的最大垂直检测角度在10°~50°之间(本研究为40°),因此激光雷达的有限垂直检测角度也是在凹曲线失效的影响因素。

(2)路段类型

图7显示了路段类型特征变量的结果。将一般主线路段SHAP值Φ_{base}作为参照,$\Phi_b < \Phi_{base}$说明桥梁路段比一般主线路段表现出更低的失效概率;$\Phi_{enex} \approx \Phi_{base}$说明出入口之间路段与一般主线路段有着相似的失效概率;出口、入口路段则表现出明显的高失效概率,其中$\Phi_{ex} > \Phi_{en}$说明出口路段失效概率更大,这与描述性统计中出口路段失效占比比入口路段高70.6 %的结论一致。

激光雷达是依据采集到的点云数据进行分析,而点云数据中的噪声会对感知结果的精度产生影响[18]。在桥梁路段驾驶时,周围环境相对简单且变化不大,点云数据中噪声相对较少,分析结果表现为更低的失效概率。在出入口之间路段驾驶的环境与一般主线类似,如图3所示,二者周围环境并不存在明显的差异。而在出入口路段,车道线会出现分叉或合并,车道内会出现箭头、文字等信息,并且路面宽度也会剧烈变化,这些快速变化可能会增加感知数据中噪声的数量,从而间接干扰激光雷达的车道线宽度感知精度。

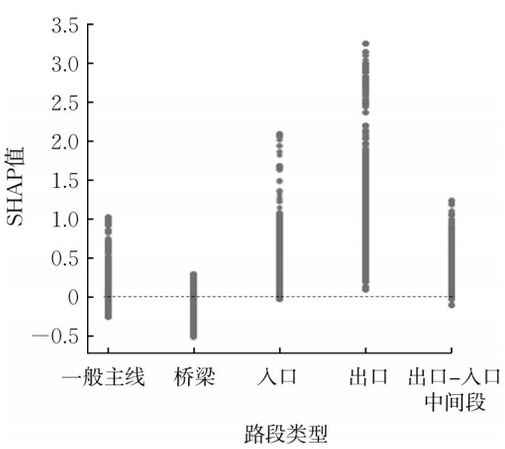

图7 路段类型的SHAP依赖图

Fig.7 SHAP dependence plots for road segment type

(3)地面标线

图8a为车道线类型特征变量的模型结果。将两侧车道线为双实线的SHAP值Φ_{base}作为参照,左实线右虚线、左虚线右实线以及双虚线的SHAP值与Φ_{base}基本一致,车道线感知失效概率没有表现出明显的偏高或偏低的趋势,表明测试车辆行驶在这4类车道线类型时的车道线感知结果具有相似的特征。然而,当行驶在右侧有加速车道线以及减速车

道线的路段时，$\Phi_{acc} > \Phi_{base}$ 且 $\Phi_{dec} > \Phi_{base}$。同样，描述性统计中加速及减速车道线的路段失效占比分别是双实线路段的6.0和12.1倍。表明右侧为加速和减速车道线时，相较于双实线，车道线形式明显变化，感知能力会出现下降，会出现短暂的失效情况。右侧存在加速或减速车道与本节上文中出入口路段是同一路段，因此右侧车道线的快速显著变化带来的点云数据噪声可能造成了感知失效[18]。

除了车道线，山区高速公路地面标线还包括纵向减速标线，以及横向减速标线、箭头、文字等其他地面标线。图8b和8c分别是纵向减速标线以及其他地面标线的模型结果。结果表明，当测试车辆行驶路段具有纵向减速标线或者其他地面标线时，感知失效的概率都出现了显著的增加。这些地面标线出现时会反映在激光雷达的点云数据中，相对于路面仅有车道线的场景，会增加自动驾驶系统处理和解释数据的复杂性。

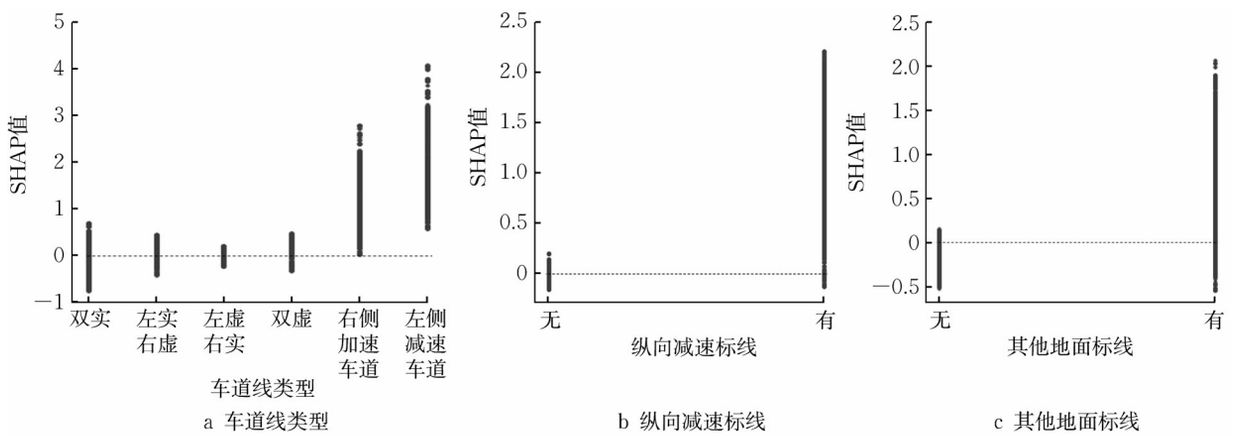

a 车道线类型　　b 纵向减速标线　　c 其他地面标线

图8　地面标线的SHAP依赖图

Fig. 8　SHAP dependence plots for marking type

(4)环境

环境特征变量包括天气和光照。图9a为天气特征对感知失效的影响结果，$\Phi_{bad} > \Phi_{good}$ 表明不良的天气，即存在降雨和雾天的天气，相对于天气良好的场景，感知失效的概率会显著增加。描述性统计中天气不良样本失效占比是天气良好的10.1倍，与CatBoost模型结论一致。已有研究中有相似的结论[8]，均发现雨雾天气会影响激光雷达的感知能力，造成更高的失效概率。在雨雾天气，测试车辆前方空气中的水滴会吸收和散射激光束，导致部分激光能量丢失，从而减少返回到激光雷达传感器的反射信号强度，增加反射率信息熵[19]，并且，这些水滴本身也可能被激光雷达系统检测为障碍物，从而在数据中添加噪声。当路面存在积水时，会造成激光的折射或反射，也会影响传感器的性能。因此，在本研究中，天气不良对感知失效的影响较大。

关于光照对车道线感知失效的影响结果如图9b所示，本研究结果表明夜晚环境相对于白天，感知失效概率均没有明显的增加或减少趋势，夜晚采集的数据没有体现出更高的失效概率，两种类型的SHAP均大致均匀分布在0值上下，这可能由于激光雷达受光线影响较小[7]。图中夜晚的SHAP值相对分散可能是因为夜间采集的数据集中其他因素影响较大，在考虑光照特征时表现出较高的变化性。

(5)车辆运行

车辆运行的特征变量包括自车行驶速度、前方最近大型车辆距离以及行驶车道。图10a为自车行驶速度的模型结果，整体上表现出随着速度增加感知失效概率也随之增加的趋势。随着行驶速度的增加，激光雷达需要在更短的时间内完成对周围环境的扫描和处理，要求系统具有足够的能力来准确地检测和跟踪高速移动的物体，往往随着物体移动速度的增加，系统出错的可能性也会增加。GARCÍA也得出相似的总体趋势，在大多数情况下车道检测系统的失效概率随着速度的增加而增加[20]。

关于前方最近大型车辆距离，在绘制单变量SHAP图时未发现对感知失效概率有明显影响趋势。然而，在与天气特征交叉分析时(图10b)，发现前方最近大型车辆距离小于30 m且天气为不良时的样本SHAP值明显大于0，说明这种场景会对感知失效产生正影响。进一步分析这种场景发现，当测试车辆与前方大型车辆跟车距离较近时，大型车辆

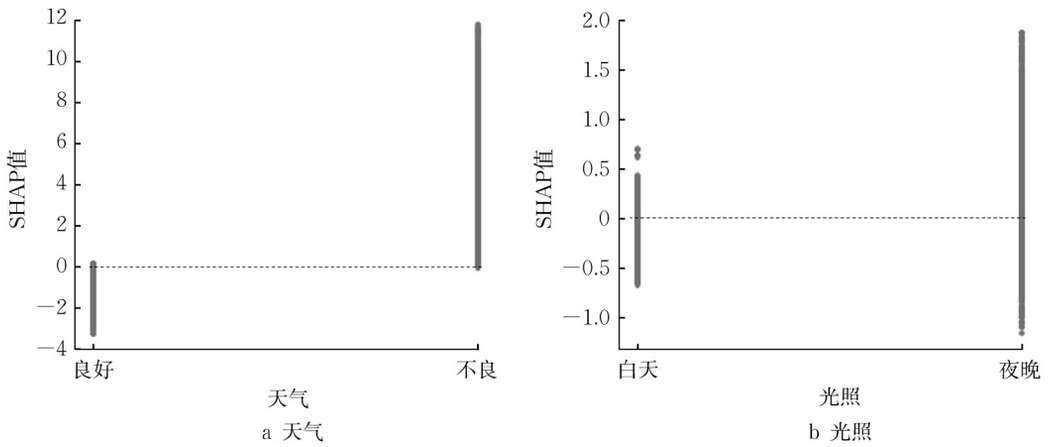

图9 环境特征的SHAP依赖图

Fig. 9 SHAP dependence plots for environmental characteristics

会卷起地面上的积水,扬起水雾,如图4中所示,这些水雾会出现在测试车辆正前方,而雾化现象会明显降低激光雷达的表现,造成点云数量削减和反射率削减[19],引发更高概率的失效。

关于测试车辆行驶车道对感知失效的影响,结果表明当行驶在右侧车道时,相对于左侧车道,车道线感知失效概率整体更高(图10c)。这与本研究中山区高速公路的特征相符,该路单向有两条车道,左侧车道仅供大型车辆超车使用,因此大多数情况下右侧车道有着更多的大型车辆。并且右侧车道行驶时才会出现右侧车道线为加速或减速车道的情况。因此,结合地面标线以及车辆运行部分的分析,行驶在右侧车道具有更高的感知失效概率具有可解释性。

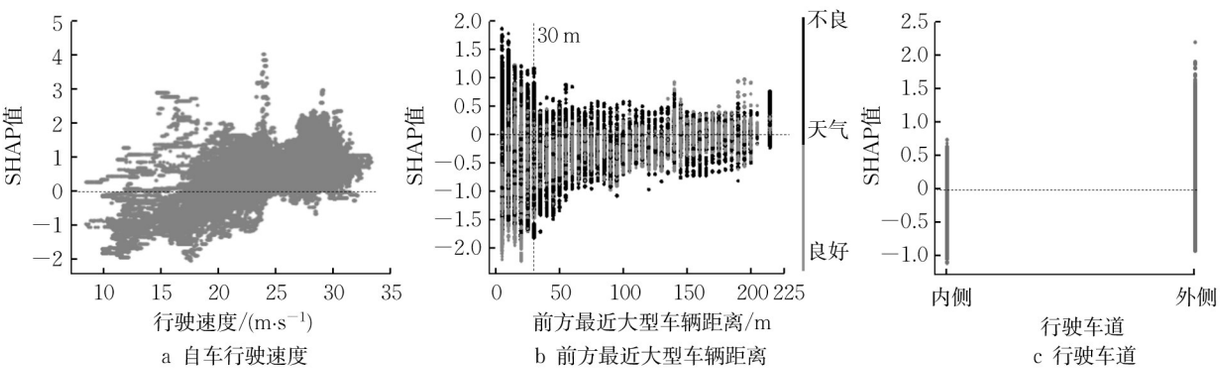

图10 车辆运行特征的SHAP依赖图

Fig. 10 SHAP dependence plots for vehicle operating characteristics

4 结语

车道检测功能作为自动驾驶车辆安全的关键环节,有必要评估山区高速公路对自动驾驶车辆的车道检测性能的适应程度。本文基于同济大学车载全息信息采集系统,实车测试了山区高速公路激光雷达的感知失效影响因素。研究对象为车道线宽度感知是否失效,在研究的所有样本中,4.8 %为失效,95.2 %为未失效。解释变量考虑了5种类型的特征,包括道路线形、路段类型、地面标线、环境和车辆运行。本文选择CatBoost作为分析模型,使用SHAP方法解释了各影响因素对车道线感知失效的具体影响,并对比现有研究成果,进一步分析了失效原因,如天气、道路线形等因素的影响可能与激光雷达的工作特点有关,失效原因包括采样角度、视距遮挡、数据噪声更大等。

本研究揭示的道路特征和感知失效之间的关系,可为山区高速公路设计提供了更适合自动驾驶安全运营的措施,如道路线形和道路标线设计。其次,为了降低车道检测失效的概率,本研究结论可为制定自动驾

驶的运行设计域提供参考。例如，建议基于激光雷达的自动驾驶车辆，减少在雨天环境下与前方大型车辆保持30 m以下的跟车距离。最后，自动驾驶车企和传感器制造商也可以参考本研究的结论，针对性优化面向山区高速公路环境下的测试。由于测试环境与场景的差异，本研究结论可能无法直接应用于与山区高速公路差异大的其他类型公路。进一步研究将考虑不同类型道路，如城市高速公路、一级公路等非高速公路，以提高研究成果的适用性。

作者贡献声明：

陈志贵：测试数据采集，数据处理，模型建立，论文撰写。

王雪松：论文构思，论文审阅与校订。

孙雨宸：测试数据采集与解析。

参考文献：

[1] California DMV. Autonomous vehicle collision reports [R]. Sacramento: California Department of Motor Vehicles, 2023.

[2] GAJJAR H, SANYAL S, SHAH M. A comprehensive study on lane detecting autonomous car using computer vision [J]. Expert Systems with Applications, 2023, 233: 120929.

[3] 赵健，李雅欣，朱冰，等. 基于激光雷达的纵向坡路动态可行驶性预测[J]. 中国公路学报，2019，32(6)：147.
ZHAO Jian, LI Yaxin, ZHU Bing, *et al*. Dynamic traversability prediction on a longitudinal ramp based on lidar [J]. China Journal of Highway and Transport, 2019, 32(6): 147.

[4] GARCíA A, CAMACHO-TORREGROSA F J, BAEZ P V P. Examining the effect of road horizontal alignment on the speed of semi-automated vehicles [J]. Accident Analysis & Prevention, 2020, 146: 105732.

[5] HAO W. Review on lane detection and related methods [J]. Cognitive Robotics, 2023, 3: 135.

[6] VAN BRUMMELEN J, O'BRIEN M, GRUYER D, *et al*. Autonomous vehicle perception: The technology of today and tomorrow [J]. Transportation Research Part C: Emerging Technologies, 2018, 89: 384.

[7] ZHANG X, LI Z, GAO X, *et al*. Channel attention in LiDAR-camera fusion for lane line segmentation [J]. Pattern Recognition, 2021, 118: 108020.

[8] ZHANG Y, CARBALLO A, YANG H, *et al*. Perception and sensing for autonomous vehicles under adverse weather conditions: A survey [J]. ISPRS Journal of Photogrammetry and Remote Sensing, 2023, 196: 146.

[9] SO J, HWANGBO J, KIM S H, *et al*. Analysis on autonomous vehicle detection performance according to various road geometry settings[J]. Journal of Intelligent Transportation Systems, 2023, 27(3): 384.

[10] CHAI C, LIU T, LIU J, *et al*. Surrogate evaluation model for assessing lane detection reliability of automated vehicles in complex road environments [J]. Transportation Research Record, 2023, 2677(7): 185.

[11] 中国汽车技术研究中心. 汽车、挂车及汽车列车外廓尺寸、轴荷及质量限值：GB1589—2016[S]. 北京：中国国家标准化管理委员会，2016.
China Automotive Technology and Research Center. Limits of dimensions, axle load and masses for motor vehicles, trailers and combination vehicles: GB1589—2016 [S]. Beijing: China National Standardization Administration, 2016

[12] PROKHORENKOVA L, GUSEV G, VOROBEV A, *et al*. CatBoost: Unbiased boosting with categorical features [J]. Advances in Neural Information Processing Systems, 2018, 31: 6638.

[13] HANCOCK J T, KHOSHGOFTAAR T M. CatBoost for big data: An interdisciplinary review [J]. Journal of Big Data, 2020, 7(1): 94.

[14] SHAPLEY L S. A value for n-person games[J]. Contributions to the Theory of Games, 1953, 2(28): 307.

[15] YANG C, CHEN M, YUAN Q. The application of XGBoost and SHAP to examining the factors in freight truck-related crashes: An exploratory analysis [J]. Accident Analysis & Prevention, 2021, 158: 106153.

[16] BENEDEK C, MAJDIK A, NAGY B, *et al*. Positioning and perception in LIDAR point clouds [J]. Digital Signal Processing, 2021, 119: 103193.

[17] YE X, WANG X, LIU S, *et al*. Feasibility study of highway alignment design controls for autonomous vehicles[J]. Accident Analysis & Prevention 2021, 159: 1.

[18] GUOQIANG W, HONGXIA Z, ZHIWEI G, *et al*. Bilateral filter denoising of Lidar point cloud data in automatic driving scene [J]. Infrared Physics & Technology, 2023, 131: 104724.

[19] 邢星宇，黄安，姜为，等. 降雨条件下车载激光雷达感知局限性[J]. 同济大学学报(自然科学版)，2023，51(5)：785.
XING Xingyu, HUANG An, JIANG Wei, *et al*. Perception Limitation of LiDAR sensor in autonomous vehicles under rainfall condition[J]. Journal of Tongji University (Natural Science), 2023, 51(5): 785.

[20] GARCíA A, CAMACHO-TORREGROSA F J, LLOPIS-CASTELLó D. Chapter-11 infrastructure impact of decision-making techniques for autonomous vehicles[M]. Amsterdam, Netherlands: Elsevier, 2023.