DOI:10.11918/202412028

智能网联车辆事故严重程度影响因素可解释性分析

吴 瑶[1],占志彬[1],张宜知[1],周继彪[2],刘 佩[3]

(1.南京邮电大学 现代邮政学院,南京 210003;2.宁波市高等级公路建设管理中心,浙江 宁波 315100;
3.东南大学 交通学院,南京 211189)

摘 要:为了研究外界环境对智能网联车辆事故严重程度的相关影响因素,采用美国2016—2023年DMV官网公开的智能网联车辆事故数据资料。首先,使用Boruta方法对交通事故数据进行处理,确定时间、地点、限速、天气等14个维度为输入变量集。其次,构建CatBoost多分类模型,并利用TPE优化方法调整超参数,得到了相对优超参数组合下的评估模型,该拟合模型的平均AUC值达到了0.86。最后,引入了SHAP解释模型,揭示显著影响因素对事故严重程度的全局影响及贡献程度,并探究了变量之间的交互效应。结果表明:道路类型、季节、车辆运动状态和交通事故类型与事故严重程度密切相关;追尾事故、恶劣的天气条件和路况会增加严重交通事故的风险。研究结果为智能网联车辆的安全评估提供了TPE-CatBoost-SHAP分析框架,有助于评估和改进当前智能网联车辆的安全性能。

关键词:智能交通;事故严重性;TPE-CatBoost-SHAP模型;智能网联车辆;机器学习
中图分类号:X703.1 **文献标志码**:A **文章编号**:0367-6234(2026)07-0097-12

Explainability analysis of influencing factors of accident severity of connected-automated vehicles

Wu Yao[1], Zhan Zhibin[1], Zhang Yizhi[1], Zhou Jibiao[2], Liu Pei[3]

(1. School of Modern Posts, Nanjing University of Posts and Telecommunications, Nanjing 210003, China;
2. Ningbo High-grade Highway Construction Management Center, Ningbo 315100, Zhejiang, China;
3. School of Transportation, Southeast University, Nanjing 211189, China)

Abstract: To investigate the factors influencing the severity of accident in CAVs(connected-autonomous vehicles), this study utilizes publicly available accident data from the DMV(U.S. Department of Motor Vehicles) website between 2016 and 2023. The Boruta method was first applied to process the traffic accident data, identifying 14 input variables such as time, location, speed limit, and weather conditions. A CatBoost multi-class classification model was then developed, and hyperparameters were optimized using the TPE(Tree-structured Parzen Estimator) method. The evaluation model achieved an average AUC(Area Under the Curve) of 0.86 under the optimal hyperparameter combination. Furthermore, the SHAP(SHapley Additive exPlanations explanation) model was utilized to reveal the global impact and contribution of significant factors to accident severity and explore the interactions between variables. The results show that road type, season, vehicle motion state, and accident type are strongly correlated with accident severity. Rear-end collisions, adverse weather, and poor road conditions increase the risk of severe accidents. This research provides a TPE-CatBoost-SHAP analysis framework for safety assessment in CAVs, offering insights into improving their safety performance.

Keywords: intelligent transportation; accident severity; TPE-CatBoost-SHAP model; connected-automated vehicles; machine learning

智能网联车辆的迅速发展为交通事故的减少带来了机遇,同时也为交通事故带来挑战。先前的研究表明,司机的失误是90%事故的主要原因,即使是由车辆、道路和环境条件引起的碰撞,也伴随着一些人为因素(例如,注意力不集中、分心或超速等)[1-2]。智能网联车辆的使用能够有效提升安全性和通行效率、降低能源消耗,减少人为错误,并可能减少碰撞[3-7]。但一些研究人员分析了现有的智能网联车辆事故数据集,发现智能网联车辆被传统车辆追尾的比例是传统车辆被追尾的4.03倍[8],因

收稿日期:2024-12-10;**录用日期**:2025-02-09;**网络首发日期**:2025-08-08
网络首发地址:https://link.cnki.net/urlid/23.1235.t.20250808.1303.005
基金项目:国家自然科学基金(52202382)
作者简介:吴 瑶(1986—),女,讲师,博士
通信作者:吴 瑶,wuyao@njupt.edu.cn

此,明确不同因素如何影响智能网联车辆碰撞的严重程度,对于全面提高智能网联车辆的安全性具有重要意义。

关于智能网联车辆道路安全的文献提供了智能网联车辆事故影响因素的研究实例,包括驾驶员、车辆、道路、环境和交通流量。自 2016 年起,越来越多的研究人员基于智能网联车辆事故报告开展统计分析和机器学习的研究[9-11],例如机器学习模型(逻辑回归模型[12]、分类与回归树(CART[13])),神经网络[14]和随机森林[15-16]已被用于确定导致涉及智能网联车辆的车祸严重程度的因素,定量分析了影响因素与事故类型或严重程度的相关关系[17-19]。一些调查研究了影响因素与 CAVs 碰撞频率或严重程度之间的关系[20-24]。智能网联车辆的驾驶方式、碰撞位置、路边停车、追尾碰撞和道路类型是导致智能网联车辆涉及事故严重程度的主要因素。

现有的智能网联车辆事故预测模型往往依赖于经验方法进行变量选择,缺乏科学的严谨性。此外,这些模型的黑盒性质限制了结果的可解释性。因此,需要开发具有高精度和强可解释性的新型预测模型来评估其事故条件。为了实现这一目标,本研究通过利用 DMV 公布的数据,采用了 Boruta 算法来选择最重要的输入变量,提出 CatBoost 并使用 TPE 优化进行优化得到最优超参,同时基于博弈论和局部解释的 SHAP 算法可以计算出每个属性对预测的相对重要性来解释机器学习模型的结果[25]。基于 SHAP 的 CAVs 事故严重程度分类模型的可解释方法可以为道路管理部门制定针对 CAVs 的安全改进政策提供见解,具有一定的实用价值。

1 研究方法

本研究基于 Boruta 方法识别输入变量集,构建了 CatBoost 模型,并借助 TPE 优化技术自动调整模型超参数,以确保模型性能的最优化。利用划分的训练集和测试集,验证模型的有效性。为进一步深化对模型特征重要性的理解,运用了 SHAP 分析方法,详细评估了各特征对模型预测结果的贡献和影响(图 1)。最终绘制了多个图表来可视化模型性能和特征解释。

1.1 Boruta 方法

在研究中,选择适当数量的变量对于确保准确预测路面性能和避免包含不相关的信息至关重要。Boruta 特征选择方法是一种有效的特征选择方法。该方法的主要目的是确定一组与因变量密切相关的综合特征,从而增强对影响 CAVs 的事故严重程度因素的理解[26-27]。Boruta 特征选择方法的主要步骤如下:

1)创建阴影特征。随机洗牌真实特征 R 以创建阴影特征 S,然后将真实特征和阴影特征相结合,创建一个新的训练特征矩阵 $\boldsymbol{N}=[R,S]$。

2)输入新创建的特征矩阵并训练基于树的模型以获得真实特征和阴影特征的 VIM(Vi improved)。

3)将每个真实特征的 Z_{score} 与阴影特征的最大 $Z_{\text{score}}(S_{\max})$ 进行比较。Z_{score} 大于 $S_{\max}$ 的实际要素被标记为“重要”,而 Z_{score} 小于或等于 $S_{\max}$ 的实际要素被标记为“不重要”。

4)丢弃“不重要”特征以及所有影子变量。

5)重复步骤 1)~4),直到所有要素属性都标记为“重要”或“不重要”。

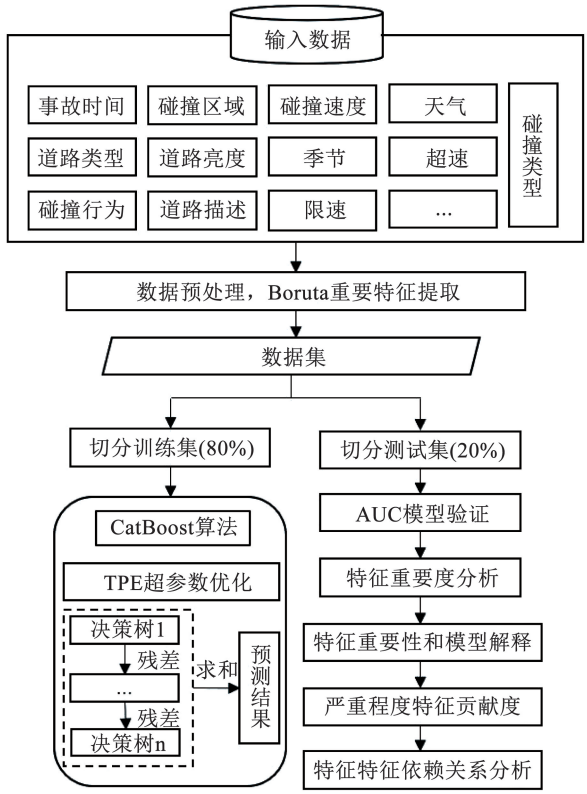


图 1 智能网联车辆事故严重程度分析流程

Fig. 1 Flowchart of accident severity analysis of connected-automated vehicle

1.2 CatBoost 模型

CatBoost 模型[28]作为一种改进的梯度提升树算法,可以很好地处理分类特征。CatBoost 方法的超参数使用贝叶斯优化进行优化事实[29]证明,这种优化对于优化目标函数的未标记大数据具有重要意义。贝叶斯优化与概率分布集成,用于调整每个超参数以生成最佳样本。

CatBoost 方法能基于 TS(target statistic)编码改进的一种编码方式。利用改进的目标变量统计法计算每个样本的标签 TS 值:

$$x_k^i = \frac{\sum_{x_j \in D_k} \prod_{\{x_j^i = x_k^i\}} y_j + ap}{\sum_{x_j \in D_k} \prod_{\{x_j^i = x_k^i\}} y_j + a} \tag{1}$$

式中：$D_k = \{(x_k, y_k)_{k=1,\cdots,n}\}$ 为训练集，其中 $\boldsymbol{x}_k = (\boldsymbol{x}_k^1, \cdots, \boldsymbol{x}_k^m)$ 为 m 个特征的向量；p 为先验值，a 为先验的权重，$y_k \in R$ 为目标；CatBoost 引入了训练样本的随机排列 σ。

采用 TS 方法将分类数据转化为数值时，数据分布会偏离原始形态导致输出偏差，这是传统 GBDT 方法不可避免的问题。为了避免梯度偏差，Prokhorenkova 等[28]创造了一种新技术，即有序提升。顺序梯度进行分类任务：式(2)说明了梯度提升技术是如何通过贪婪的方法修改先验估计，以创建序列 $F^t: \mathbb{R}^m \to \mathbb{R}$ 的近似值。

$$F^t = F^{t-1} + ah^t \tag{2}$$

式中：a 为步长；$t = 1, 2, \cdots$，函数 $F^t: \mathbb{R}^m \to \mathbb{R}$ 从函数系列 H 中挑选，以最小化预期损失，在第 t 轮迭代中选取的最优基学习器如式(3)所示。通常采用最小二乘法计算损失，如式(4)所示。

$$h^t = \operatorname{argmin}_{h \in H} \mathscr{L}(F^{i-1} + h) = \operatorname{argmin}_{h \in H} L(y, F^{i-1}(x) + h(x)) \tag{3}$$

$$h^t = \operatorname{argmin}_{h \in H} E(-g^t(x, y) - h(x))^2 \tag{4}$$

式中：$g^t(x, y) = \frac{\partial L(y, s)}{\partial S}|_S = F^{t-1}(x)$，但现实中的期望值是未知的，通常使用相同的数据集 D 来估计，如式(5)所示。

$$h^t = \operatorname{argmin}_{h \in H} \frac{1}{n} \sum_{k=1}^{n} (-g^t(x_k, y_k) - h(x_k))^2 \tag{5}$$

TPE 是对传统贝叶斯优化方法的一种增强与改进[29]。通过将配置空间转化为非参数密度分布，展现了其高度的灵活性。在确定超参数的粗略范围后，可以借助 Hyperopt 库中的 TPE 算法作为代理函数来搜索超参数的最佳组合，从而实现最佳模型性能。对于 CatBoost 而言，需要考虑的超参数的域如下：学习率、深度、迭代、正则化项和在迭代之后以最佳度量值继续训练的迭代次数。TPE 采用序贯的方式进行超参数搜索，每次只尝试一部分超参数组合，并根据已有的数据不断更新概率模型。这样可以在较少的实验次数内找到全局最优解。

1.3　模型评价

机器学习模型的性能评估是模型开发和优化过程中的关键环节。ROC (receiver operating characteristic)曲线，又称接受者操作特征曲线。该曲线最早应用于雷达信号检测领域，用于区分信号与噪声，后来人们将其用于评价模型的预测能力。ROC 曲线是基于混淆矩阵得出的，ROC 曲线的横坐标为伪阳性率 R_{fp}(判定为正例却不是真正例的概率，即真负例中判为正例的概率)，纵坐标为真阳性率 R_{tp}(判定为正例也是真正例的概率，即真正例中判为正例的概率)。其中伪阳性率、真阳性率这两类指标的计算方法如下。

$$R_{\text{fp}} = \frac{\text{FP}}{\text{FP} + \text{TN}} \tag{6}$$

$$R_{\text{tp}} = \frac{\text{TP}}{\text{TP} + \text{FN}} \tag{7}$$

式中：TP 为实际为正样本被模型正确预测为正样本的数量，FN 为实际为正样本被模型错误预测为负样本的数量，FP 为实际为负样本被模型错误预测为正样本的数量，TN 为实际为负样本被模型正确预测为负样本的数量。

AUC 是 ROC 曲线与坐标轴所围成的面积，指标值在 0 ~ 1 之间变化，提供了对所有可能的分类值的性能的综合衡量，通常认为指标值越高，模型效果越佳。对于多个分类器共同作用的复杂场景时，通常借助 AUC 的宏观平均值和微观平均值来综合考量，能够更加准确地评估分类模型性能。

$$\text{AUC} = \frac{\sum_{i \in p} \text{rank}_i - \frac{M(1+M)}{2}}{M \times N} \tag{8}$$

式中：M 为正样本个数；N 为负样本个数；n 为样本总量；p 为正样本的集合；rank 为根据排序后的列表，分配的 rank 值。

1.4　用于 CatBoost 解释的 SHAP 分析

2017 年，Lundberg 等[30]提出了 SHAP 模型，这一模型借鉴了博弈论中 Shapley 值的核心思想，旨在解释各类机器学习模型的预测行为。将 CAVs 事故挖掘与分析数据集 D 输入训练好的分类模型中，输出每种严重程度的预测值，利用 SHAP 解释工具对分类模型的输出结果转化为 SHAP 值进行可视化分析(式(9))，并探究变量之间的交互关系(式(10))。

$$\phi_i = \sum_{S \subseteq F \setminus \{i\}} \frac{|S|!(|F| - |S| - 1)!}{|F|!} [f_{S \cup \{i\}}(\boldsymbol{x}_{S \cup \{i\}}) - f_S(\boldsymbol{x}_S)] \tag{9}$$

$$\phi_{i,j} = \sum_{S \subseteq F \setminus \{i,j\} + f_S(\boldsymbol{x}_S)} \frac{|S|!(|F| - |S| - 2)!}{|F|!} [f_{S \cup \{i,j\}}(\boldsymbol{x}_{S \cup \{i,j\}}) - f_{S \cup \{i\}}(\boldsymbol{x}_{S \cup \{i\}})] \tag{10}$$

式中：S 为模型特征子集，$\boldsymbol{x}_j$ 为被解释样本的特征向量，p 为特征数，f_S 为特征组合 S 的模型输出值，$p!$ 为 p 个特征考虑顺序的特征组合数，ϕ_i 为特征 i 的 SHAP 值，$\phi_{i,j}$ 为特征 i 与特征 j 的 SHAP 交互值。若固定特征 j，余下共有 $(P - |S| - 1)!$ $S!$ 个特征组合组合。

2 事故数据来源与处理

在智能网联车辆事故的研究中,选择合适的变量并对其进行深入分析是理解事故致因和制定有效预防措施的关键。本文采用 DMV 官网公开的数据集,获取 2016 年 1 月份—2023 年 7 月份 8 年多共计 1 496 事故案例。考虑到 CatBoost 模型对样本量的需求和数据源的可用性,对数据进行清洗与处理,共获取 658 条人工驾驶车辆与智能网联车辆交通事故数据集,作为本论文研究的基础数据库。CAVs 事故严重程度根据人员伤亡情况分为 5 级(包括无损失、轻微损失、中等损失、严重损失和致命损失),旨在全面揭示不同严重程度 CAVs 事故发生的各种影响因素。

通过对已有研究和 Boruta 重要特征的综合分析,选定了一组关键变量作为研究的基础,这组变量涵盖了环境条件(月份、时间、天气、照明)、道路特征(类型、平整度、状况、限速)、车辆状态(车辆运动、车辆速度)等多个方面(表 1)。旨在全面揭示不同严重程度智能网联车辆与人工驾驶车辆交互事故的各种影响因素。具体而言,影响智能网联车辆的因素包括:环境特征、道路特征、智能网联车辆状态;影响人工驾驶车辆的因素包括:环境特征、道路特征、人工车辆状态。为了深入探究这些因素,将 14 个不同事故属性编码为 14 个分类变量。在处理这些变量时,根据变量的特性采取了不同的编码方式。对于本身为连续变量以及具有有序离散性质的变量(如事故时间、行驶速度、季节)等保留了其原始形式;而其余离散的多类别变量均通过 CatBoost 模型 TS 编码功能进行了处理,以保证结果输出的准确性。

表 1 智能网联车辆事故致因变量描述表

Tab. 1 Description table of dependent variables caused by accidents of CAVs

因素	描述	定义
环境特征	Season	Spring、Summer、Autumn、Winter
	Weather	Clear、Cloudy、Other、Rain、Snow、Unknown
	Lighting	Dark-Lighted、Dark-Not Lighted、Dark-Unknown Lighting、Dawn (Dusk)、Daylight、Other, see Narrative、Unknown
道路特征	Roadway Type	Highway(Freeway)、Intersection、Parking Lot、Rural Road、Street、Traffic Circle、Unknown
	Roadway Description	No Unusual Conditions、Other, see Narrative、Traffic Incident、Unknown、Work Zone
	Roadway Surface	Dark-Lighted、Dark-Not Lighted、Dark-Unknown Lighting、Dry、Other,see Narrative、Snow(Slush、Ice)、Unknown、Wet
车辆因素	CP Pre-Crash Movement	Backing、Changing Lanes、Entering Traffic、Lane(Road Departure)、Making Left Turn、Making U-Turn、Merging、NM Crossing Roadway、NM in Roadway-Other、Other,see Narrative、Parked、Proceeding Straight、Stopped、Unknown
	SV Pre-Crash Movement	Backing、Changing Lanes、Entering Traffic、Lane(Road Departure)、Making Left Turn、Making U-Turn、Merging、NM Crossing Roadway、NM in Roadway-Other、Other,see Narrative、Parked、Proceeding Straight、Stopped、Unknown
	Speeding	Yes、NO
其他因素	CP Contact Area	Bottom、Front、Front Left、Front Right、Left、Rear、Rear Left、Rear Right、Right、Top、Unknown、Empty
	SV Contact Area	Bottom、Front、Front Left、Front Right、Left、Rear、Rear Left、Rear Right、Right、Top、Unknown、Empty
	Posted Speed Limit($m \cdot h^{-1}$)	0、5、10、15、20、25、30、35、40、45、50、55、60、65、70、75、80、Unknown

图 2 呈现了关于 CAVs 事故连续变量描述。图 2(a)所示,当中午 12:00 时和下午 18:00 时,事故发生率攀升至高峰。这是因为上下班时刻车辆密集度的增加无疑提升了事故发生的概率,值得注意的是当晚上 22:00 时也会出现顶峰。这一现象揭示了多辆车的卷入和高密度交通是导致人身伤害事故的主要因素[31]。智能网联车辆事故主要以追尾为主[8],如图 2(b)所示,当智能网联车辆面临危险时,车辆紧急制动,后车反应不及时,这无疑增加智能网联车辆低速碰撞次数。

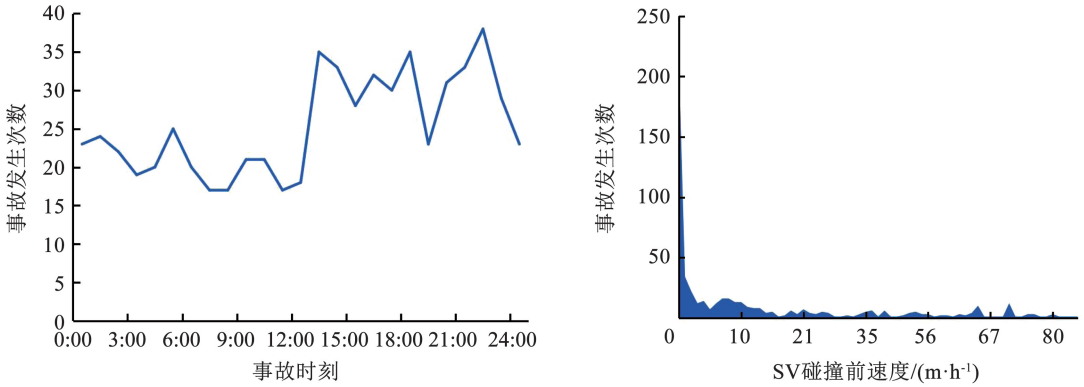


图 2　智能网联车辆事故连续变量

Fig. 2　Continuous variables of CAVs accidents

3　模型检验和模型分析

3.1　CatBoost 参数调优结果和模型评估

数据分为训练数据集和测试数据集。从预处理过的数据集中随机抽取 80% 数据集用于模型训练，以确保模型能够充分学习数据的内在规律和模式；20%用于模型测试集，以评估模型的泛化能力和拟合准确性。通过 TPE 五重交叉验证确定了模型的超参数，得出模型最佳输出参数。

AUC 图，即接收者操作特征曲线（ROC 曲线）下的面积，是衡量模型性能的重要指标。经过训练和验证，得出了各类别的 AUC 值，其中（Class 0 表示没有无损失，Class1 表示轻微损失，Class2 表示中度损失，Class3 表示严重损失，Class4 表示致命损失）。该五分类的 AUC 平均值达到 0.86（图 3）。

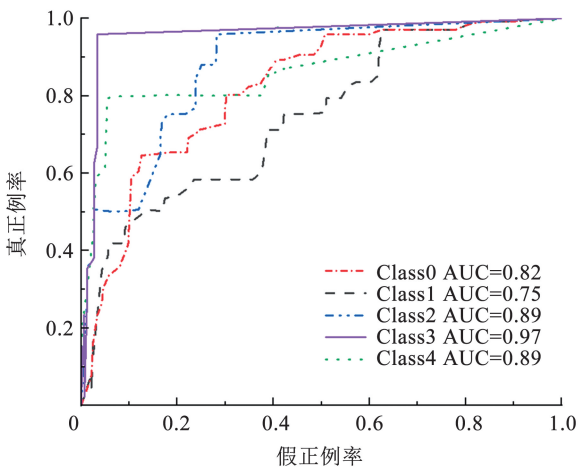


图 3　智能网联车辆模型拟合 AUC 评估曲线

Fig. 3　CAVs model fits the AUC evaluation curve

为防止 AUC 出现过拟合或欠拟合等情况，因此本研究还引入 3 个性能指标：1）精确率，正确预测的车辆事故类型相对于预测为其车辆事故类型总数的比例；2）召回率，正确预测的车辆事故类型相对于实际其车辆事故类型总数的比例；3）准确率，正确预测数量占总数量的比例，经过训练和验证，该模型精确率为 0.72 、召回率为 0.74、准确率为 0.74，模型效果较好。

研究结果显示，TPE-CatBoost 模型在预测不同事故严重程度方面具有出色的性能，在模型中提取的主题与碰撞严重性之间存在着紧密的相关性。因此，可以利用该模型来深入分析智能网联车辆中影响事故严重程度的各种因素。

3.2　事故特征重要性

3.2.1　严重程度特征重要度分析

SHAP 用于解释 CatBoost 相关因素与事故严重程度之间的关系[32-33]。SHAP 值是相加的，这意味着每个特征对最终预测的贡献可以独立计算[34]。在构建 CatBoost 模型对智能网联车辆事故严重程度进行拟合之后，进一步运用了 SHAP 方法对各个影响因子的贡献度进行了详细的量化分析，并全面探讨了这些特征在不同严重程度事故中所扮演的角色（图 4）。分析结果显示，在智能网联车辆事故中，碰撞伙伴 CP（Crash Partner）的碰撞前行为及其碰撞区域的重要性普遍且显著地超越其他特征，成为影响智能网联车辆事故严重程度的主导因素。此外，季节、时速限制（m/h）、光线条件以及智能网联车辆 SV（Subject Vehicles）的碰撞前速度（m/h）这 4 个因素，也对事故的最终后果产生了不可忽视的影响。它们共同构成了智能网联车辆事故复杂性的重要组成部分。

更为深入地，在导致致命损失的事故（class4）中，发现 SV 超速、CP 碰撞区域、CP 碰撞前行为、时速限制（m/h）和光线条件这 5 个因素的贡献尤为显著[35]。这一发现表明，这 5 个因素与事故致命损失之间存在着密切的联系，是预防智能网联车辆事故中致命损失的关键所在。

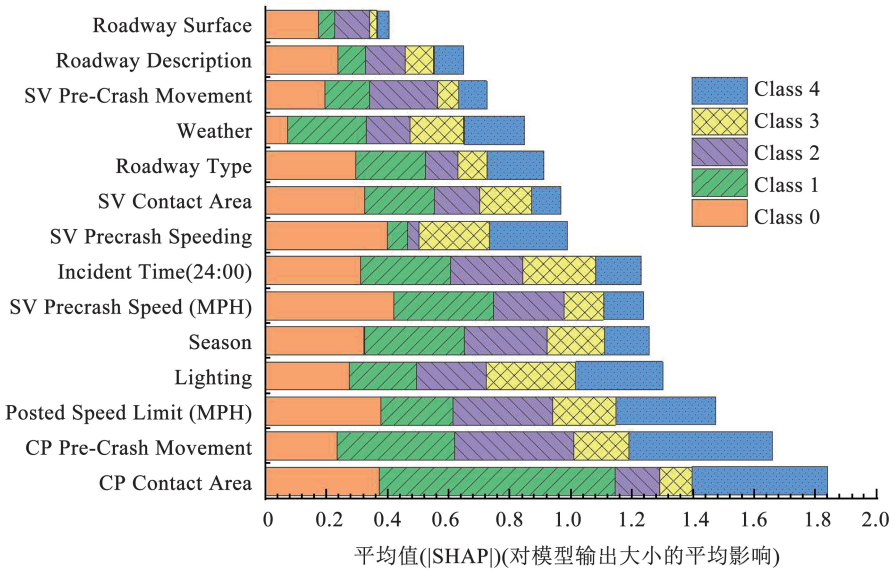


图 4 智能网联车辆不同严重程度交通事故的特征重要性

Fig. 4 The importance of the characteristics of traffic accidents of CAVs with different severity

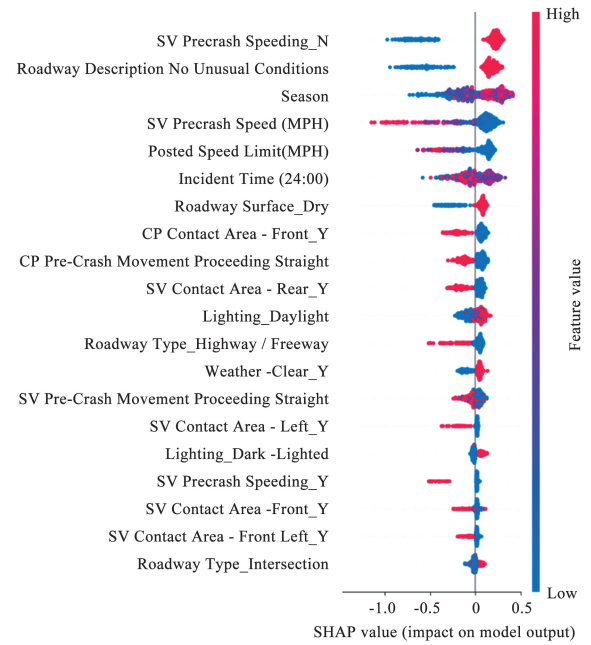
3.2.2 特征重要性和模型解释

深入探究特定特征对某一严重程度智能网联车辆事故的影响,对于预防此类事故的发生具有至关重要的意义。为了精准理解具体特征如何影响某一严重程度的事故,本节引入了 SHAP 蜂群图(图 5)进行详尽分析。x 轴上的每个点表示数据集实例的 Shapley 值,根据特征值从低(蓝色)到高(红色)着色。Shapley 值与特征对预测的影响成正比,其中正值会增加模型预测,而负值会降低预测。

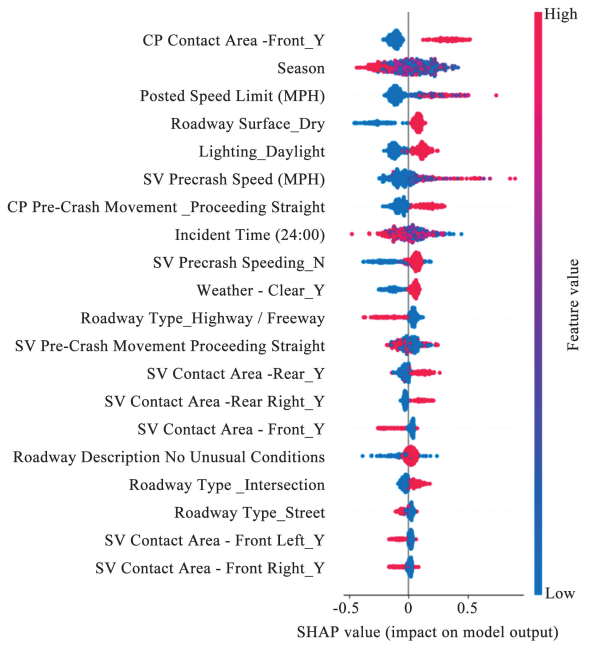
图 5(a) ~5(e)展示了各类特征在不同严重程度的智能网联车辆事故中发挥的作用。结果表明亮度、季节、CP 碰撞区域、Incident Time(24:00)出现在所有事件的十大最重要的特征中,是影响智能网联车辆事故严重程度的重要特征。

在图 5(a) ~5(e)中,SV Precrash Speeding_N 的特征表现存在显著差异。具体而言,与图 5(a)和图 5(b)相比,SV Precrash Speeding_N 在图 5(c)、5(d)、5(e)中的特征截然相反。当车辆超速时,该指标显示中度损失、严重损失及致命损失事故的发生率会有所上升,这与当前的研究一致,超速会增加严重损失及致命损失的风险。

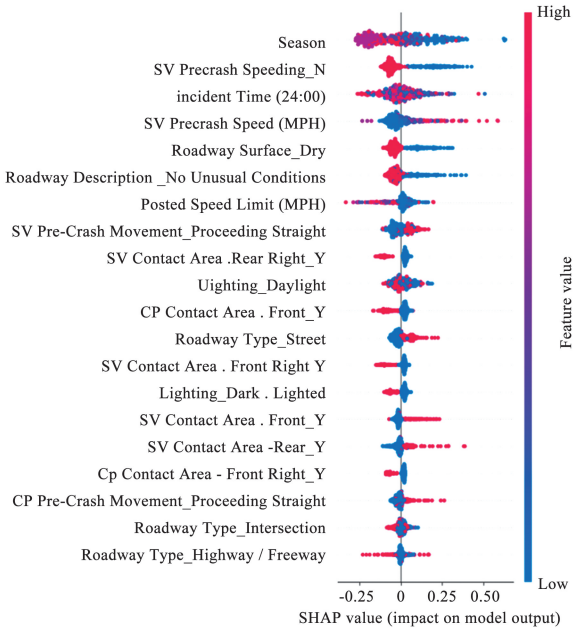
智能网联车辆在高速路段行驶时严重损失、致命损失图 5(d)、5(e)的 SHAP 值为正,表明智能网联车辆在高速路路段行驶时,智能网联车辆以高速运行[36],在紧急情况或道路障碍时反应更快,快速制动,加剧被追尾事故后果。



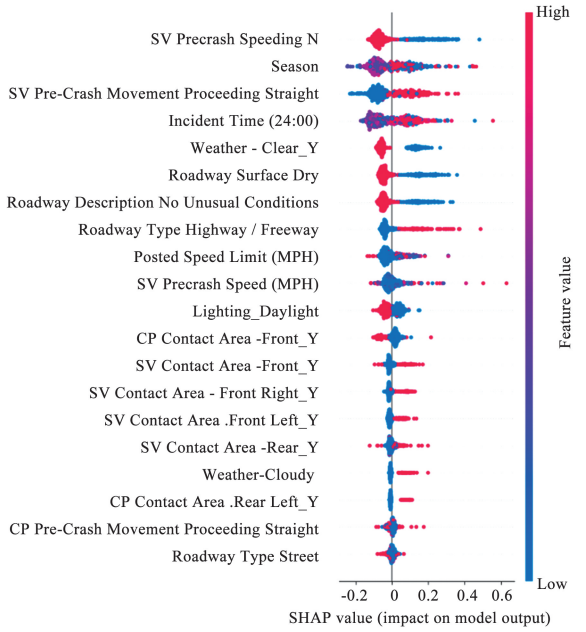
(a) 无损失事故



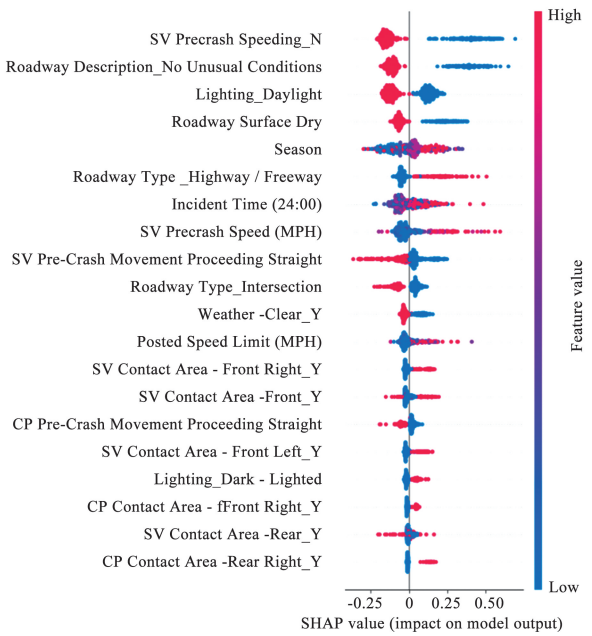
(b) 轻微损失事故



(c) 中等损失事故



(d) 严重事故



(e) 致命损失事故

图 5　智能网联车辆不同严重程度事故的 SHAP 摘要图

Fig. 5　SHAP summary diagram of accidents of different severity of CAVs

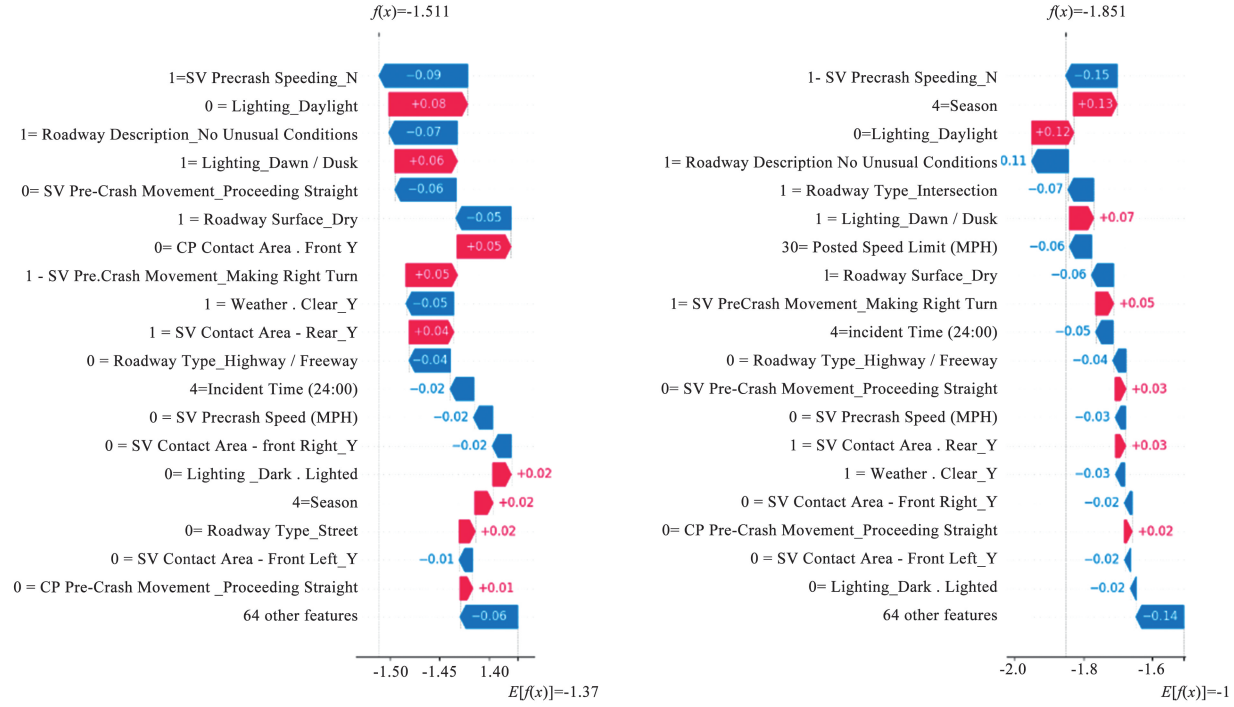
与 Gadepally 研究[37]不同，交叉路口作为交通事故发生的关键风险因素，智能网联车辆行进至交叉路口时，它们会预先进行减速操作，这一智能化行为使得车辆能够更加有效地应对与其他车辆的交互作用，从而降低事故损失。这一对比表明，在交叉路口的复杂环境中，智能网联车辆相较于传统车辆展现出了更高的车辆交互识别能力。这种能力有助于显著减少事故的发生，并有效降低事故的严重程度。

在探讨交通事故风险时，应需关注不同环境下的影响因素。对于智能网联车辆而言，即便它们在交叉路口能够提前减速以降低事故发生的可能性，但在不良光照条件下，如夜间或光线极弱的环境中，致命事故风险仍会显著增加。这主要是因为，在夜间或低光照条件下，行人和物体的可见度大大降低，智能网联车辆的感知系统（如摄像头）虽然相较于传统车辆已有显著提升，但仍可能受到一定限制。这意味着车辆可能无法及时、准确地识别出前方的障碍物或行人，从而无法对突发情况做出及时且安全的反应和处理。

3.2.3 严重程度特征贡献度

图 6 显示了数据的 SHAP 瀑布图。SHAP 瀑布图解释了与均值预测相比,该特征对模型预测的贡献。模型预测的输出值位于图的顶部,而平均预测值如底部所示。这里,红色的特征意味着它们将预测推向右,即更高,而蓝色的特征将预测推向左,即更低。此外,特定数据点的特征值位于特征名称的左侧,而特征的 SHAP 值位于箭头上(例如蓝色和红色箭头)。本文从 5 个事故严重程度中挑选重要的严重损失、致命损失两个指标。

观察图 6(a)与图 6(b),值得注意的是,在黎明(Dawn)与黄昏(Dusk)时段,会增加事故严重损失和致命损失的风险[38]。这可能归因于当处于黎明或黄昏时段时,阴影容易被误认为物体,不断变化的光线也会影响传感器的信号处理,导致系统算法出现混乱,无法准确识别障碍物。严重的情况下,系统甚至可能完全检测不到阴影中的物体,同时夜间行人和物体的能见度也大幅下降,从而加剧了碰撞的潜在后果。



(a) 严重损失 (b) 致命损失

图 6 智能网联车辆不同严重程度事故 SHAP 瀑布图

Fig. 6 SHAP waterfall chart of accidents of different severity of CAVs

当智能网联车辆与其他车辆发生事故时,车辆的运动状态往往会进一步加剧事故的风险。特别是,智能网联车辆执行右转操作时,伴随的减速操作可能导致后车的追尾,从而可能引发严重甚至致命的损失。在智能网联车辆所涉及的所有事故类型中,被追尾事故尤为常见[17,22],这主要是因为智能网联车辆在面临紧急情况时,可能传统车辆无法迅速执行诸如减速等必要的制动操作,进而加剧了事故的严重程度。

良好的天气条件有助于减轻碰撞的严重程度[39]。在晴朗且气象条件优越的环境下,智能网联车辆的环境识别能力显著增强。面对突发状况时,这些车辆能够迅速响应,采取有效措施,从而显著降低事故发生的风险。季节变化与智能网联车辆事故中的严重损失和致命损失之间存在着正相关关系。具体而言,冬季时节的阴暗天气和湿滑路面会导致刹车距离显著增加。在这种条件下,当智能网联车辆需要紧急制动时,由于制动距离过长,往往会加剧事故的严重性。

3.3 特征依赖关系分析

SHAP 交互效应依赖图作为一种有力的分析工具,能够清晰地展示不同特征之间的内在联系,并深入揭示两个变量如何协同作用于模型输出。如图 7 所示,可视化了连续变量在不同严重程度智能网联车辆交通事故中的交互效应。

在无损失事故的情形下,如图 7(a)、7(b)、7(c)所示,干路面与特定时间段的结合显著加剧了无损失事故的风险。具体来说,干路面增强了智能网联车辆与道路之间的摩擦力,这一物理特性的改善有助于减少严重损失事故的发生概率。然而,当

车辆处于行驶的高峰时段时，尽管交通环境复杂多变，智能网联车辆环境感知能力难度加大，但智能网联车辆通过更加谨慎的驾驶策略，依然能够有效降低严重事故发生的潜在风险。

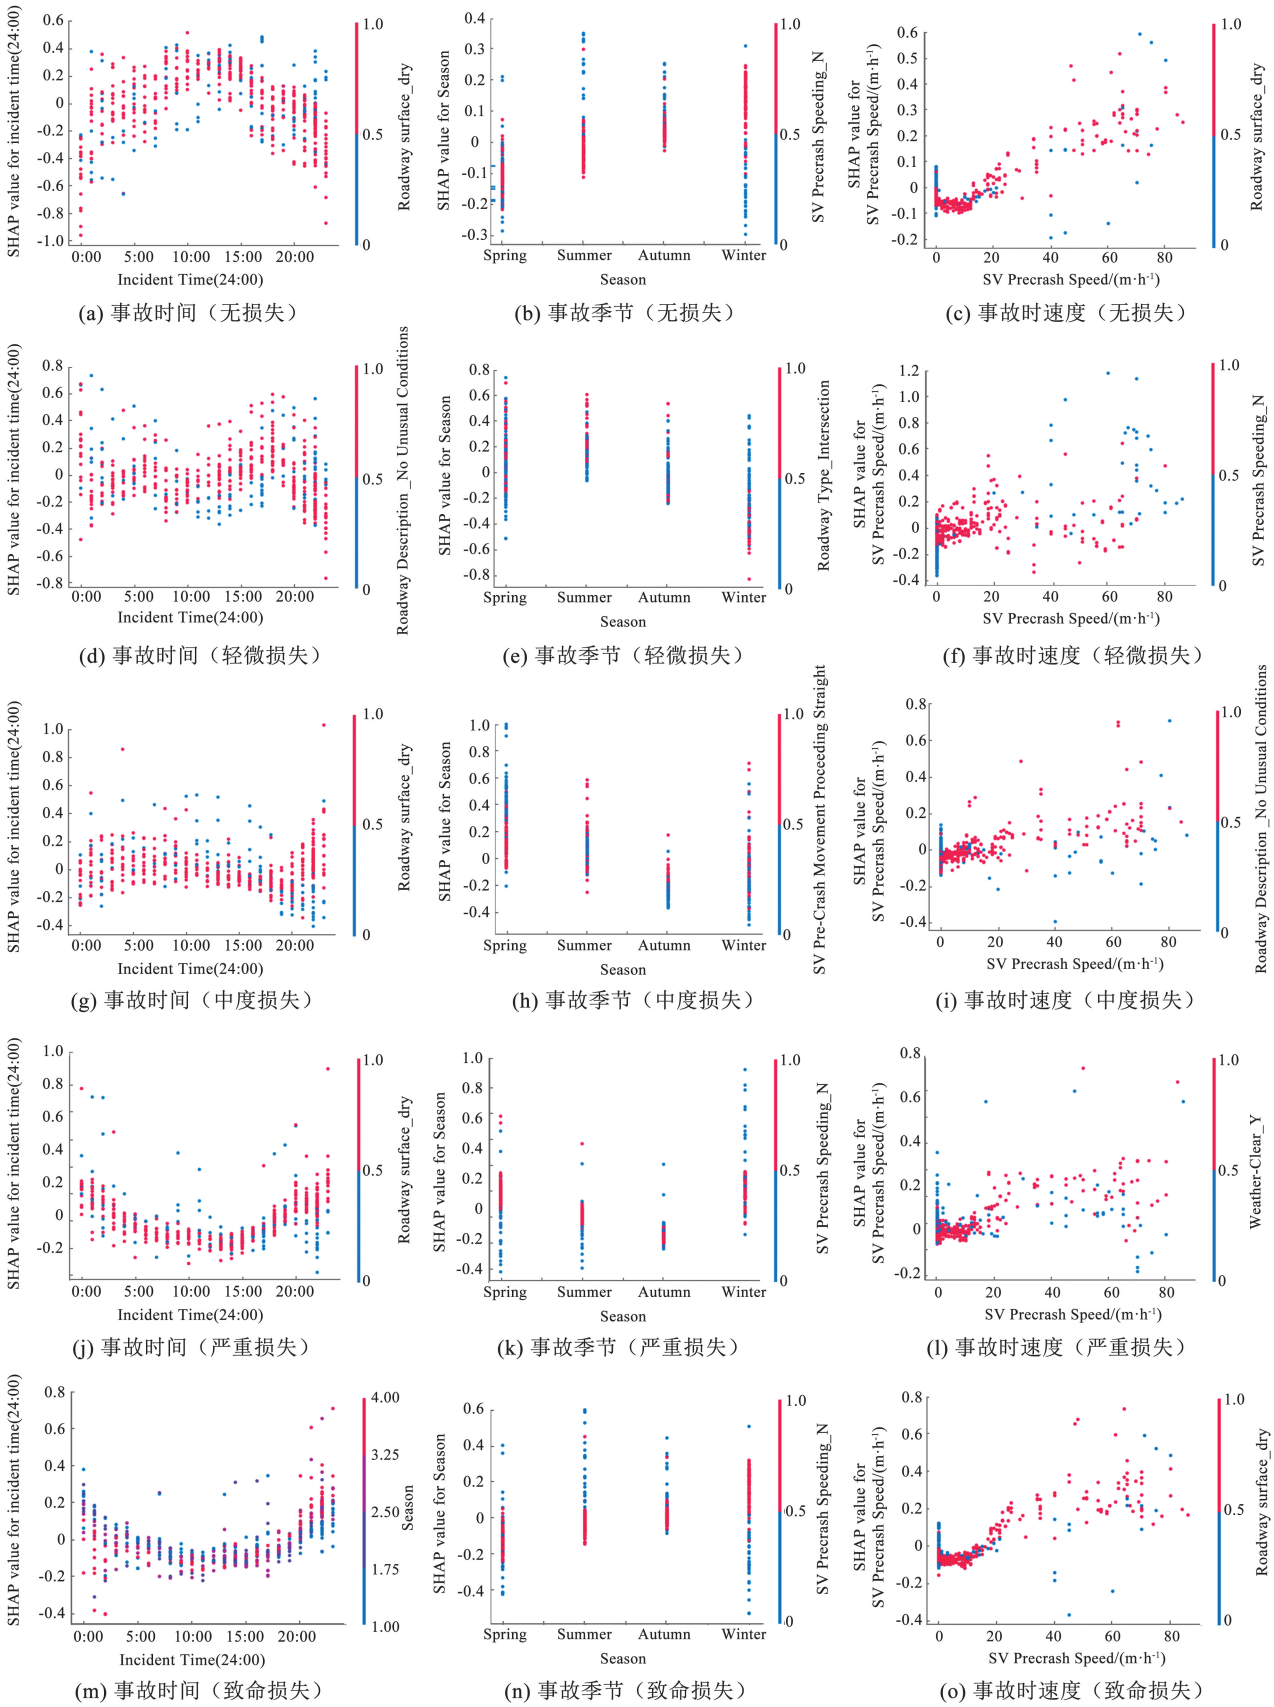


图 7　智能网联车辆不同严重程度事故 SHAP 特征依赖图

Fig. 7　SHAP feature dependency diagram of accidents of different severity of CAVs

在轻微损失事故的情形下,如图 7(d)、7(e)、7(f)所示,季节与交叉路口的交互作用特征之间呈现一种先增后减的趋势,冬季与交叉路口的相互作用表现为负向,意味着在冬季条件下,智能网联车辆反而能够降低交叉路口的安全隐患。相反,夏季与交叉路口之间相互作用为正,夏季时智能网联车辆在交叉路口可能会增加轻微损失事故的安全隐患。这很可能归因于夏季天气状况良好,导致第三方人工驾驶的驾驶员都可能在一定程度上放松了警惕,从而增加了事故的风险。

在中度损失事故的情形下,如图 7(g)、7(h)、7(i)所示,事故发生的时间与干路面特征之间存在着显著的相互作用。具体而言,在夜间昏暗的光线条件下,中度损失事故的风险有所增加;而与此同时,行驶干路面状况更是进一步加剧了中度损失事故的发生风险,这可能是由于在干路面上,车辆往往能够以更快的速度行驶,从而在一定程度上加剧了中度损失事故的发生风险。

在重度损失事故的情形下,如图 7(j)、7(k)、7(l)所示,事故发生的时间与干路面特征之间呈现 U 型相互作用。具体而言,智能网联车辆在黎明、夜间照明不足和行驶道路表面的干燥状况会增加严重事故的风险[37],夜间照明不足会降低智能网联车辆和人类的能见度,使其识别和判断路况和其他交通参与者变得更困难,同时行驶干燥道路表面,会增加智能网联车辆行驶速度加快的可能,这进一步加剧了交通冲突和事故的可能性。另值得注意的是,冬季往往会加剧事故的严重程度,这与人工驾驶车辆相似,季节与恶劣的行驶环境密切相关[40]。由于冬季的行驶条件十分苛刻,道路表面容易出现低摩擦状况,这种不利的条件极易引发严重事故的发生。

图 7(m)、7(n)、7(o)反映了事故发生的时间与季节特征之间的相互作用,时间特征在重度损失事故方面展现出相似的趋势。智能网联车辆在夜间因照明不足而面临的风险中,致命事故的发生率显著上升。然而,与重度损失事故一个显著的区别在于,当冬季与夜间条件相互作用时,这种风险被进一步放大,导致致命事故的风险显著增加。同时,图 7(e)表明,车辆超速会增加事故的致命风险,值得注意的是,当冬季时,车辆不超速也会增加事故的致命风险,这可能与冬季的环境有关。

4 结 论

智能网联车辆有望显著提升交通系统的安全性和效率[41],在实现“零伤亡愿景”中扮演关键角色。本研究结合了 CatBoost 多分类机器学习模型和 SHAP 工具,构建了一个可解释的智能网联车辆事故严重程度影响因素模型。为智能网联车辆的安全评估和风险缓解策略提供了全新的分析视角,有助于优化和提升现有智能网联车辆的安全性能。得出结论如下:

1)为了探究所提取主题与智能网联车辆碰撞严重性之间的关联性,本论文构建了一个 CatBoost 模型。模型评估结果显示,其 AUC(曲线下面积)达到了 0.86,这表明了所提取的主题与碰撞严重性之间存在着紧密的关联。这一发现不仅验证了主题提取的有效性,也为进一步分析智能网联车辆事故的原因及预防策略的制定提供了有力的数据支持。

2)SHAP 蜂群图揭示了多个关键因素与事故严重程度之间的紧密联系。具体而言,道路类型、季节变化、车辆的运动状态以及事故类型本身都被确认为影响事故严重性的重要变量。尤为值得注意的是,追尾事故、不利的天气条件以及糟糕的路况、超速这些因素均会显著提升发生严重事故的风险。这些发现为以后深入理解事故发生的复杂机制,以及制定针对性的预防措施提供了宝贵的洞察。

3)特征贡献分析表明,黎明与黄昏时段,智能网联车辆事故严重程度增加,可能与昏暗光线和能见度下降有关。智能网联车辆与其他车辆事故中,右转操作和被追尾事故尤为危险,前者因可能形成人工驾驶车辆盲点,后者因人工驾驶车辆紧急制动反应缓慢,这些运动状态加剧了事故风险。晴朗天气有助于智能网联车辆减轻事故严重程度,但季节变化,尤其是冬季阴暗和湿滑路面,会增加严重和致命事故的风险,因制动距离过长而加剧事故严重性。这些因素共同影响着智能网联车辆的安全性能。

4)特征依赖关系分析揭示了在无损失至致命损失事故中,干路面、事故时间段、季节与智能网联车辆事故风险密切相关。干路面与高峰时段结合虽增感知难度,但低速行驶时其抓地力成安全保障,有效减少严重事故风险。夜间昏暗加剧中度损失风险,而重度损失事故在黎明、夜间风险更高[37],冬季恶劣条件加剧事故严重性。夜间与冬季相互作用显

著增加致命事故风险，晴朗天气下高速驾驶因驾驶人员放松警惕及反应不及，同样提升致命事故风险。

参考文献

[1] Fagnant D J, Kockelman K. Preparing a nation for autonomous vehicles: opportunities, barriers and policy recommendations[J]. Transportation Research Part A: Policy and Practice, 2015, 77: 167

[2] Parsa A B, Movahedi A, Taghipour H, et al. Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis[J]. Accident Analysis & Prevention, 2020, 136: 105405

[3] Cicchino J B. Effectiveness of forward collision warning and autonomous emergency braking systems in reducing front-to-rear crash rates[J]. Accident Analysis & Prevention, 2017, 99: 142

[4] Guériau M, Billot R, El-Faouzi N E, et al. How to assess the benefits of connected vehicles? A simulation framework for the design of cooperative traffic management strategies[J]. Transportation Research Part C: Emerging Technologies, 2016, 67: 266

[5] Wang L, Zhong H, Ma W, et al. How many crashes can connected vehicle and automated vehicle technologies prevent: a meta-analysis[J]. Accident Analysis & Prevention, 2020, 136: 105299

[6] Mccarthy R L. Autonomous vehicle accident data analysis: California OL 316 reports: 2015—2020[J]. ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering, 2022, 8(3): 034502

[7] Pamidimukkala A, Kermanshachi S, Patel R. An exploratory analysis of crashes involving autonomous vehicles[C]//International Conference on Transportation and Development. Austin: International Conference on Transportation and Development, 2023: 343

[8] 刘倩，王雪松. 交叉口自动驾驶车辆事故前场景生成与致因分析[J]. 中国公路学报，2024，37(4)：297
Liu Qian, Wang Xuesong. Pre-crash scenario generation and causation analysis for autonomous vehicle crashes at intersections[J]. China Journal of Highway and Transport, 2024, 37(4): 297

[9] Boggs A M, Wali B, Khattak A J. Exploratory analysis of automated vehicle crashes in California: a text analytics & hierarchical Bayesian heterogeneity-based approach[J]. Accident Analysis & Prevention, 2020, 135: 105354

[10] Ashraf M T, Dey K, Mishra S, et al. Extracting rules from autonomous-vehicle-involved crashes by applying decision tree and association rule methods[J]. Transportation Research Record, 2021, 2675(11): 522

[11] Kutela B, Das S, Dadashova B. Mining patterns of autonomous vehicle crashes involving vulnerable road users to understand the associated factors[J]. Accident Analysis & Prevention, 2022, 165: 106473

[12] Ma C, Zhou J, Yang D. Causation analysis of hazardous material road transportation accidents based on the ordered logit regression model[J]. International Journal of Environmental Research and Public Health, 2020, 17(4): 1259

[13] Dong S, Zhou J. A comparative study on drivers' stop/go behavior at signalized intersections based on decision tree classification model[J]. Journal of Advanced Transportation, 2020, 2020(1): 1250827

[14] Jeong H, Jang Y, Bowman P J, et al. Classification of motor vehicle crash injury severity: a hybrid approach for imbalanced data[J]. Accident Analysis and Prevention, 2018, 120: 250

[15] Liu Z, Chen H, Li Y, et al. Taxi demand prediction based on a combination forecasting model in hotspots[J]. Journal of Advanced Transportation, 2020, 2020(1): 1302586

[16] Liu Z, Chen H, Sun X, et al. Data-driven real-time online taxi-hailing demand forecasting based on machine learning method[J]. Applied Sciences, 2020, 10(19): 6681

[17] Favarò F M, Nader N, Eurich S O, et al. Examining accident reports involving autonomous vehicles in California[J]. PLoS One, 2017, 12(9): e0184952

[18] Almaskati D, Kermanshachi S, Pamidimukkula A. Autonomous vehicles and traffic accidents[J]. Transportation Research Procedia, 2023, 73: 321

[19] Leilabadi S H, Schmidt S. In-depth analysis of autonomous vehicle collisions in California[C]//2019 IEEE Intelligent Transportation Systems Conference(ITSC). Auckland: IEEE, 2019: 889

[20] Wang S, Li Z. Exploring the mechanism of crashes with automated vehicles using statistical modeling approaches[J]. PloS One, 2019, 14(3): e0214550

[21] Wang S, Li Z. Exploring causes and effects of automated vehicle disengagement using statistical modeling and classification tree based on field test data[J]. Accident Analysis & Prevention, 2019, 129: 44

[22] Boggs A M, Wali B, Khattak A J. Exploratory analysis of automated vehicle crashes in California: a text analytics & hierarchical Bayesian heterogeneity-based approach[J]. Accident Analysis & Prevention, 2020, 135: 105354

[23] Zhu S, Meng Q. What can we learn from autonomous vehicle collision data on crash severity? A cost-sensitive CART approach[J]. Accident Analysis & Prevention, 2022, 174: 106769

[24] Xu C, Ding Z, Wang C, et al. Statistical analysis of the patterns and characteristics of connected and autonomous vehicle involved crashes[J]. Journal of Safety Research, 2019, 71: 41

[25] Liu P, Guo Y, Zhang M, et al. Understanding the influence factors for CAV crash severity based on CatBoost and SHAP analysis[C]//CICTP 2023. Beijing: CICTP, 2023: 1204

[26] Merow C, Smith M J, Edwards Jr T C, et al. What do we gain from simplicity versus complexity in species distribution models? [J]. Ecography, 2014, 37(12): 1267

[27] Belanche-Muñoz L, Blanch A R. Machine learning methods for microbial source tracking[J]. Environmental Modelling & Software, 2008, 23(6): 741

[28] Prokhorenkova L, Gusev G, Vorobev A, et al. CatBoost: unbiased boosting with categorical features[J]. Advances in Neural Information Processing Systems, 2018, 31: 6638

[29] Mockus A, Mockus J, Mockus L. Bayesian approach adapting stochastic and heuristic methods of global and discrete optimization [J]. Informatica, 1994, 5(1/2): 123

[30] Lundberg S M, Lee S I. A unified approach to interpreting model predictions [J]. Advances in Neural Information Processing Systems, 2017, 30: 4756

[31] Zhang J, Xu C. Investigating the typical scenarios and contributory factors to crash severity of autonomous vehicle involved collisions using association rule analysis [C]//Proceedings of the 100th Annual Meeting of the Transportation Research Board. Washington DC: Transportation Research Board (TRB), 2021: 5

[32] Yang E, Yang Q, Li J, et al. Establishment of icing prediction model of asphalt pavement based on support vector regression algorithm and Bayesian optimization[J]. Construction and Building Materials, 2022, 351: 128955

[33] 孙国锋, 景云, 李和壁, 等. 基于可解释机器学习框架的列车乘车区段客流分布预测方法[J]. 交通运输系统工程与信息, 2024, 24(2): 249
Sun Guofeng, Jing Yun, Li Hebi, et al. An interpretable machine learning framework-based approach for predicting passenger flow distribution in train riding sections[J]. Journal of Transportation Systems Engineering and Information Technology, 2024, 24(2): 249

[34] Li P, Wu K, Cheng Y, et al. How does C-V2X perform in urban environments? Results from real-world experiments on urban arterials[J]. IEEE Transactions on Intelligent Vehicles, 2023, 9(1): 2520

[35] Houseal L A, Gaweesh S M, Dadvar S, et al. Causes and effects of autonomous vehicle field test crashes and disengagements using exploratory factor analysis, binary logistic regression, and decision trees[J]. Transportation Research Record, 2022, 2676(8): 571

[36] 梁国华, 石权, 李瑞, 等. 高速公路合流区主要参数对自动驾驶车辆的影响[J]. 哈尔滨工业大学学报, 2021, 53(9): 62
Liang Guohua, Shi Quan, Li Rui, et al. Impact of main parameters of merging area in highway on autonomous vehicles[J]. Journal of Harbin Institute of Technology, 2021, 53(9): 62. DOI: 10.11918/202009089

[37] Gadepally V, Krishnamurthy A, Özgüner Ü. A framework for estimating long term driver behavior[J]. Journal of Advanced Transportation, 2017, 2017(1): 3080859

[38] Abdel-Aty M, Ding S. A matched case-control analysis of autonomous vs human-driven vehicle accidents [J]. Nature Communications, 2024, 15(1): 4931

[39] Yu X, Marinov M. A study on recent developments and issues with obstacle detection systems for automated vehicles [J]. Sustainability, 2020, 12(8): 3281

[40] 王健宇, 陈献天, 焦朋朋, 等. 考虑建成环境的交通事故严重程度致因交互效应研究[J]. 交通运输系统工程与信息, 2024, 24(2): 272
Wang Jianyu, Chen Xiantian, Jiao Pengpeng, et al. Interactive effect on traffic accident severity considering built environment[J]. Journal of Transportation Systems Engineering and Information Technology, 2024, 24(2): 272

[41] Fan R, Lu J, Wang D Z W, et al. Adaptive speed optimization strategy at signalized intersections based on the penetration rate of connected automated vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(10): 13122

封面图片说明

封面图片来自本期论文“大跨度悬索桥吊索连接件叉形耳板磨损对其疲劳寿命的影响”,图片为大跨度悬索桥吊索连接件叉形耳板足尺疲劳试验示意,论文首先调查分析了吊索连接件磨损产生的机理,然后利用 Archard 模型分析了吊索连接件耳板的磨损深度,最后深入研究了连接件耳板磨损对其疲劳寿命的影响。研究结果表明:吊索连接件褐红色磨屑的主要成分是 Fe_2O_3,主要来源于叉形耳板与箱梁耳板之间的磨损,未检测到关节轴承的磨屑,吊索退扭和缆梁相对运动是造成耳板磨损的根本原因;吊索连接件纵桥向相对转角主要位于 $-3°\sim3°$之间,且符合高斯分布;该桥运营 5 年后叉形耳板磨损深度约为 0.207 mm,随时间的增长磨损深度不断增大,但增长速度不断减小;该桥运营 5、10、15、20、25、30 年后,吊索连接件叉形耳板疲劳寿命分别损失了 7.59%、13.08%、18.89%、23.75%、28.54%、33.23%。研究结果可为其他桥梁的前期设计与后期养护提供参考。

(图文提供:王小鹏,周勇军,侯培源,李毅,刘一力,王博。长安大学公路学院)