

基于多源数据融合的高速公路交通事故黑点判别

龙科军^{1,2}, 邹道兴², 何石坚^{1,2}

(1. 长沙理工大学 智能道路与车路协同湖南省重点实验室, 湖南 长沙 410114;

2. 长沙理工大学 交通运输工程学院, 湖南 长沙 410114)

摘要:【目的】提高高速公路交通事故黑点判别精度。【方法】基于高速公路交通事故数据, 融合异常驾驶行为数据与高速公路特征点数据, 创建高速公路黑点特征数据集, 并将集成学习的 CatBoost 算法应用于 G4 高速公路湖南段交通事故黑点的判别。【结果】与支持向量机、随机森林和梯度提升决策树算法相比, CatBoost 在判别高速公路事故黑点上的准确率达到 81%, F_1 值为 0.88, A_{UC} 值分别提高了 17%、13% 和 17%, 说明其判别效果优于其他 3 种机器学习算法。【结论】基于多源数据融合的高速公路交通事故黑点判别方法能够有效判别出高速公路存在的事故黑点, 并能输出每个相关变量对事故结果的贡献值。研究成果可应用于高速公路事故黑点的筛查, 并指导管理人员制定相应的预防措施。

关键词: 交通安全; 数据挖掘; 事故黑点判别; 集成学习; CatBoost

中图分类号: U491

文献标志码: A

Identification of black spots in highway traffic accidents based on multi-source data fusion

LONG Ke-jun^{1,2}, ZOU Dao-xing², HE Shi-jian^{1,2}

(1. Hunan Key Laboratory of Smart Roadway and Cooperative Vehicle-Infrastructure Systems, Changsha University of Science & Technology, Changsha 410114, China; 2. School of Traffic and Transportation Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: [Purposes] The paper aims to improve the identification accuracy of black spots in highway traffic accidents. [Methods] Based on highway traffic accident data, abnormal driving behavior data and highway facility data were combined to create a highway black spot feature dataset, and the CatBoost algorithm for ensemble learning was applied to the black spots identification of G4 highway in Hunan Province. [Findings] Compared with the support vector machine, random forest and gradient boosting decision tree, CatBoost has an accuracy of 81% in identifying the black spots of highway accidents, the F_1 value is 0.88, and the A_{UC} value is increased by 17%, 13% and 17%, respectively, it shows that its identification effect is better than that of the other three machine learning algorithms. [Conclusions] The identification method of black spots in highway traffic accidents based on multi-source data

收稿日期: 2021-06-03

基金项目: 国家自然科学基金资助项目(51678076); 湖南省重点领域研发计划项目(2019SK2171); 长沙理工大学研究生科研创新项目(CX2020SS12)

通信作者: 龙科军(1974-), 男, 教授, 主要从事交通安全方面的研究。E-mail: Longkejun@csust.edu.cn

投稿网址: <http://cslgxbzk.csust.edu.cn/cslgdxxbzk/home>

fusion can effectively identify the black spots on the highway, and output the contribution of each accident-related variable to the results. The research results can be applied to screen black spots in highway accidents and guide managers to formulate preventative measures.

Key words: traffic safety; data mining; identification of accident black spots; ensemble learning; CatBoost

在较长的统计周期内,发生交通事故数量或事故伤亡人数、财产损失显著高于其他正常位置的道路位置被称为交通事故多发点,又称“事故黑点”。鉴别事故黑点并探究其事故多发的原因,对交通安全管理和事故预防具有重要意义^[1]。

目前,事故黑点的判别主要有静态和动态两种方法。对于静态方法,孙晴晴等^[2]将事故率作为评价指标,并提出用谱聚类分析对事故黑点进行判别;符铎砂等^[3]考虑多重因素,建立了包括两级指标的事故黑点治理紧迫性评价体系,用 BP 神经网络对事故黑点治理的紧迫性进行排序。除静态的事故黑点判别方法外,动态的判别方法也受到了研究者的关注。马德明等^[4]根据事故数据时空属性的特点,利用深度学习等相关技术分别从时间和空间维度进行建模,搭建时空混合残差网络用于事故黑点的判别;FAN 等^[5]发现流量变量和天气对黑点识别的结果会产生较大的影响,并采用支持向量机和深度神经网络构建不同流量和天气下的动态学习模型,最终使黑点识别的准确性得以提高。以上研究分别从静态、动态角度出发对黑点进行判别,有效提高了判别精度。然而无论是动态还是静态的判别方法,由于事故黑点路段在道路总长中占比较小,高速公路上的事故黑点与非黑点的比例严重不均衡,导致现有的方法容易产生过拟合现象,这在很大程度上影响了判别效率^[6],因而需要提出一种新的方法来降低过拟合的影响。

CatBoost 算法是一种基于梯度提升决策树 (gradient boosting decision tree,GBDT) 的机器学习框架,以对称树作为基学习器,并在排序目标统计量、排序提升梯度估计方面对传统梯度提升决策树进行了改进,能有效解决传统机器学习方法由于目标泄露、预测偏移等造成的过拟合^[7-8]。基于以上考虑,本研究将 CatBoost 算法抑制过拟合能力较强的特点运用到事故黑点的判别中,并通过数据融合的方式,综合考虑异常驾驶行为和高速公路特征点的

影响来提升事故黑点判别的准确性。

1 数据预处理及数据融合

1.1 数据描述与预处理

本研究的数据包含 3 部分:第 1 部分为 2016 年 1 月 1 日—2018 年 12 月 31 日由交通管理部门记录的京港澳高速公路湖南段的所有事故数据。剔除含有缺失值的数据条目后,3 年间,京港澳高速公路湖南段共发生简易交通事故(指事故发生后 7 天内无事故原因导致的人员死亡)10 088 起,一般交通事故(事故发生后 7 天内有事故原因导致的人员死亡)252 起,事故数据的字段描述见表 1;第

表 1 高速公路事故数据的字段描述

Table 1 Field description of highway accident data				
字段类别	字段名称	示例	事故数量/起	事故概率/%
道路条件	在道路横断面的位置	机动车道	9 952	96.24
		紧急停车带	63	0.61
		其他	326	3.15
	中央隔离设施	绿化带	1 982	19.16
		混凝土护栏	2 273	22.04
		波形护栏	5 673	54.86
		金属护栏	72	0.70
		隔离墩(柱)	310	3.24
	路面结构	沥青	10 096	97.64
		水泥	504	2.36
	道路线型	平直	8 996	87.10
		一般弯	517	5.18
		一般坡	310	3.86
		急弯	308	2.90
		陡坡	60	0.58
连续下坡		40	0.38	
环境	地形	平原	9 719	93.97
		丘陵	542	5.24
		山区	93	0.79

2 部分为 2018 年 6 月 1 日—2018 年 12 月 31 日由高德导航软件记录的京港澳高速公路湖南段异常驾驶行为数据,包括急加速、急减速、急左变道、急右变道共 4 种异常驾驶行为及行为发生的经纬度坐标、发生时间以及事件发生时的道路形态和道路类型。其中,异常驾驶行为数据条目共计 372.873 1 万条,包括急左变道 76 866 条,急右变道 78 491 条,急减速 1 789 504 条,急加速 1 783 870 条;第 3 部分为京港澳高速公路湖南段特征点信息,主要包括 18 座桥梁、39 个出入口、185 个港湾、33 个收费站的里程、路线编码、名称、编号、桩号经纬度等信息。

1.2 数据融合

1.2.1 路段单元划分

进行数据融合前,需要划分路段单元,以提取研究单元并生成路段 ID 作为数据聚合的基础。对路段进行划分的常见方法有路段特征法和固定长度法^[9-10]。路段特征法考虑路段平纵线型或交通量变化特征的影响,但忽略了特征点对驾驶员和车辆的影响,而且划分的路段长度常常在 10 km 以上,这样做能否保证大区段内路段的同质性,值得讨论;固定长度法已被证明在事故预测、黑点判别方面效果较好^[11]。为实用起见,本研究将研究路段划分为若干长度为 1 km 的区段,并将每个区段作为一个独立的研究单元,如图 1 所示。



图 1 路段单元划分示意图

Fig. 1 Schematic diagram of road unit division

1.2.2 事故黑点确定

G4 京港澳高速公路在湖南省内为南北走向。本研究对 G4 高速公路湖南段从北到南从起点开

始划分路段。表 2 为《公路交通事故多发点段及严重安全隐患排查工作规范(试行)》中对于事故黑点等级的划分标准。本研究统计了发生在每个路段单元的简易交通事故数、一般交通事故数及伤亡人数,若事故数和伤亡人数等满足表 2 中的数量标准,则可确定为对应的事故黑点类别,否则该路段单元为非黑点。在对京港澳高速公路湖南段的事故黑点进行确定时,一类和二类事故黑点在事故黑点数据集中所占的比例不到 1%,故对一类至三类事故黑点进行合并。被判定为事故黑点的路段对应的数据条目标签取值为 1,非黑点路段取值为 0。

表 2 事故黑点等级划分标准

Table 2 Classification standard of accident black spots

类别	事故描述	事故数量/起
一类	近 3 年内,单起事故死亡人数 ≥ 5	≥ 1
	近 3 年内,单起事故死亡人数 ≥ 3	≥ 2
	近 3 年内,死亡事故 受伤事故	> 6 —
二类	近 3 年内,单起事故死亡 3~4 人	1
	近 3 年内,死亡事故	3~5
	近 3 年内,死亡事故和受伤事故	> 6
三类	近 3 年内,死亡事故	1~2
	近 3 年内,死亡事故和受伤事故	3~5
	一定时间内,发生道路交通事故 (含简易事故)情况突出的	—

1.2.3 异常驾驶行为数据与事故数据位置匹配

事故数据的空间信息仅包含事故发生里程,而用户手机获取的异常驾驶行为数据仅包含经纬度信息。由于两种空间信息不匹配,无法直接对异常驾驶行为数据和事故数据进行聚合。为此,本研究利用地理信息系统软件将异常驾驶行为的经纬度信息与事故发生点的里程桩号相匹配。具体操作如下:

步骤 1:在软件中导入 G4 高速公路湖南段的矢量数据,将各路段单元由矢量数据表示的长度与实际里程进行对比并修正,使各路段单元由矢量数据表示的长度和实际里程相等,最终获得每个异常驾驶行为事件发生的桩号。

步骤 2:在路线里程桩号范围内,生成 5 000 个随机数,并根据这些随机数确定高速公路线要

素对应的桩号。将这些桩号对应的点作为基准点,输出每个基准点的桩号和经纬度坐标。将基准点桩号与事故桩号就近匹配,对事故经度和纬度坐标进行线性插值,最后获得每个事故点的经纬度坐标。

位置匹配完成后,根据里程桩号统计出每个路段单元各类异常驾驶行为的数量,并在原有数据集中增加字段“急减速数”“急加速数”“急左变道数”和“急右变道数”。

1.2.4 高速公路特征点融合

桥梁、隧道、服务区、出入口等数据包含自身编码、路线编码、路线名称、编号、桩号、经纬度等字段,桥梁数据的描述见表3。在融合特征点数据后,在原有数据集中增加字段“紧急停车带”“出入口”“服务区”。在表1的基础上,融合后的数据集中新增字段的描述见表4。

表3 桥梁数据的描述
Table 3 Description of bridge data

字段名	数据示例
桥梁编码	G0401430000L0010
路线编码	G0401430000
路线名称	长沙绕城高速
路段序列号	1
桥梁编号	L0010
桥梁名称	杨梓冲互通主线1号桥
建成时间	2013
中心桩号	1 310.425
桥梁经度	113.081
桥梁纬度	28.314

表4 数据融合后新增字段的描述

Table 4 Description of fields added after data fusion

字段名称	含义	示例
紧急停车带	路段单元内是否存在紧急停车带	1 表示存在, 0 表示不存在
服务区	路段单元内是否存在服务区	1 表示存在, 0 表示不存在
出入口	路段单元内是否存在出入口	1 表示存在, 0 表示不存在
桥梁	路段单元内是否存在桥梁	1 表示存在, 0 表示不存在
急减速数	路段单元内急减速事件发生数	103 次
急加速数	路段单元内急加速事件发生数	201 次
急左变道数	路段单元内急左变道事件发生数	1 034 次
急右变道数	路段单元内急右变道事件发生数	1 122 次

对所有基础数据剔除无关字段,例如:审核单位、审核人、完工时间等,只保留相应道路的几何信息、桩号、编号、所在道路名、经纬度等。然后,将每个特征点的桩号与路段单元的范围进行匹配。若该特征点的桩号在路段单元范围内,则将该路段单元在事故黑点数据集中对应的数据条目的相应字段取值为1,否则为0。

2 事故黑点判别

2.1 CatBoost 算法

CatBoost 是一种基于对称决策树算法的参数少、能自动处理类别型变量和高鲁棒性的 GBDT 算法框架^[11]。GBDT 算法每构建一棵新树都会近似计算当前模型的梯度,但在每一步迭代过程中,其损失函数都使用相同的数据集计算得到当前模型的梯度,然后训练得到基学习器,这会导致梯度的估计偏差和模型的过拟合问题。相对于经典梯度提升算法,CatBoost 算法主要在3个方面有所改进,增强了算法抗过拟合的能力。

首先,针对传统目标统计量(target statistics, TS)方法中,由于创建的数值型特征与标签值相同而导致的模型过拟合问题,CatBoost 算法引入先验概率 p 对目标统计量进行平滑,这种目标统计量的计算方法被称为 Greedy TS。Greedy TS 的计算公式为:

$$\hat{x}_{i,k} = \frac{\sum_{j=1}^n [x_{j,k} = x_{i,k}] \cdot Y_j + a\rho}{\sum_{j=1}^n [x_{j,k} = x_{i,k}] + a} \tag{1}$$

式中: n 为数据量; $\hat{x}_{i,k}$ 为由 $x_{i,k}$ 生成的数值型变量; $x_{i,k}$ 为第 i 类数据中的第 k 个样本类别,当 $x_{j,k} = x_{i,k}$ 时, $[x_{j,k} = x_{i,k}]$ 值为1,否则为0; Y_j 为第 j 个数据标签变量的值; p 为先验值,取数据集目标变量的均值; a 为先验概率的权重, $a > 0$ 。

其次,在经典梯度提升算法中,由于每次迭代都采用相同的数据,在训练时容易导致过拟合。为了避免梯度偏差并缓解过拟合,CatBoost 算法每次迭代都使用不包含当前样本的训练集对每一个样本进行单独训练,并得到该样本的梯度估计。

最后,CatBoost 算法采用对称树作为基学习器,这样,树的同一层可以采用相同的分裂标准。

这种改进进一步减小了模型过拟合的概率,加快了模型的训练速度。

2.2 评价标准

准确率是评价机器学习模型性能的重要标准,但考虑到高速公路黑点数据集中正负样本的不平衡性,需要选取更加合适的指标对模型的性能进行评估。除准确率外,本研究选取常用的 F_1 分值和 A_{UC} 值作为模型性能的评价标准。

F_1 分值综合反映了精确度和召回率,其值越大说明模型的效果越理想。精确度在数值上等于判别为正确的正样本数与判别为正样本数的比值;召回率等于判别为正确的正样本数与实际正样本数的比值。 F_1 的计算公式如下:

$$F_1 = \frac{2PR}{P + R} \tag{2}$$

式中: P 为模型的精确度; R 为模型的召回率。 F_1 分值为 1 时,模型的效果最佳。

对于受试者工作特征(receiver operating characteristic,ROC)曲线,横轴为假反例率,表示正样本被错误分类的比率;纵轴为真反例率,表示负样本被正确分类的比率。根据不同的分类阈值,可以得到不同的假反例率和真反例率,从而可以绘制出连续的 ROC 曲线。 A_{UC} 即为 ROC 曲线的下面积,常被用来评价二分类器的优劣。一般 A_{UC} 值越大,说明模型的效果越理想。

2.3 结果分析

本研究将急加速数、急减速数、急左变道数、急右变道数、紧急停车带、出入口、服务区、桥梁、道路线型、地形、路面结构、中央隔离设施共计 12 个特征作为输入变量,对 CatBoost、随机森林(random forest, RF)、GBDT 和支持向量机(support vector machine, SVM)模型的事事故黑点的判别结果进行对比分析。

随机抽取数据集中 80% 的数据作为训练样本,剩余部分作为测试样本。采取网格搜索和十折交叉验证的方法,确定 RF、GBDT、SVM 和 CatBoost 算法的最优参数。各模型评价结果的对比见表 5。由表 5 可知,CatBoost 算法在验证集上的准确率达到 81%,高于 GBDT 模型;对于用于评估模型可靠性的 A_{UC} 值, CatBoost 算法比其他 3 种模型有较大的提升。图 2 所示为 CatBoost 算法的 ROC 曲线。

表 5 各模型评价结果的对比

Table 5 Comparison of evaluation results of each model

评价指标	RF	GBDT	SVM	CatBoost
准确率	0.80	0.80	0.77	0.81
F_1 分值	0.88	0.89	0.87	0.88
A_{UC}	0.67	0.63	0.67	0.80




图 2 CatBoost 算法的 ROC 曲线

Fig. 2 ROC curve of CatBoost algorithm

基于树模型的集成学习算法在模型训练结束后可以输出模型所使用的特征相对重要度,以便于进一步对预测结果有重要影响的因素进行分析。FRIEDMAN 等^[12]提出了一种评估树模型特征重要度的方法。在该方法中,特征的全局重要度通过特征在单棵树中重要度的平均值来衡量,重要度越高表示对预测结果的影响越大。特征 j 在单棵树中重要度的计算方法如下:

$$\hat{J}_j^2 = \sum_{t=1}^{L-1} \hat{i}_t^2[v_t = j] \tag{3}$$

式中: $\hat{J}_j$ 为特征 j 在单棵树中的重要度; L 为树的叶子节点的数量; $L-1$ 为树的非叶子节点的数量; v_t 为和节点 t 相关联的特征; $\hat{i}_t^2$ 为节点分裂后平方损失的减小值。当 $v_t = j$ 时, $[v_t = j]$ 为 1, 否则为 0。

算法结果中重要度排名前 10 的特征如图 3 所示。路段单元内各类异常驾驶行为数量是判别过程中较重要的指标,急加速数、急减速数、急左变道数和急右变道数在总特征重要度中约占 50%。分别将这 4 类异常驾驶行为的数量和黑点标签数据导入 SPSS 中进行肯德尔 tau-b 相关性检验。在显著性水平 $\alpha = 0.01$ 的情况下,急加速数、急减速数、急左变道数和急右变道数与黑点标签均通过了显著性检验,可以认为这 4 类异常驾驶行为与事故黑点的形成具有较高的相关性。出入口、中央隔离设施和服务区的特征相对重要度

均达到 10 以上。其中,高速公路出入口的特征相对重要度达到了 15.22,其作为车辆违法变道、违法停车两种危险行为的高发点,事故风险极高^[13-15],证明路段范围内的出入口是对事故黑点的形成影响较大的指标;中央隔离设施的特征相对重要度达到了 10.26,中央隔离设施能够吸收高速公路事故的巨大能量,有研究表明无中央隔离和路侧防护设施时,死亡事故发生概率分别是有这些设施时的 5.444 和 2.448 倍^[16-17];服务区的特征相对重要度为 10.22,由于许多车辆进入服务区后不能及时达到限制速度,司机忽略了对周围环境的观察,导致剐蹭、追尾、撞人等事故时有发生^[18-19]。以上结论充分说明相对重要度方法能够有效评估对事故黑点的形成有重要影响的特征。




图 3 事故黑点判别的特征相对重要度
Fig. 3 The feature relative-importance of black spot identification

3 结论

本研究以 1 km 为单位将高速公路划分为若干个路段单元,融合每个路段单元的事故数据、高德异常驾驶行为数据和桥梁、服务区、出入口、紧急停车带等路段特征点数据创建高速公路事故黑点特征数据集。针对事故黑点数据集常见的类别不平衡的问题,利用 CatBoost 算法抗过拟合能力强的特点提升了黑点判别方法的鲁棒性。主要结论如下:

1) 提出了一种性能更优的黑点判别方法。相对于经典的机器学习算法,CatBoost 算法在准确率、召回率和 A_{UC} 值上都得到了一定程度的提升,

也有效降低了判别错误率,能够有效地对黑点进行判别,且输出结果的可靠性优于传统的机器学习算法,可以为高速公路交通管理部门筛查事故黑点提供依据。

2) 得到了与事故黑点形成相关性较强的因素。CatBoost 算法输出的特征重要度说明异常驾驶行为的数量对事故黑点判别产生的影响较大。进一步对 4 类异常驾驶行为的数量与事故黑点的形成进行相关性检验,发现异常驾驶行为的数量与事故黑点的形成有较强的相关性。

本研究仅考虑了路段特征及异常驾驶行为数量等造成事故黑点的静态因素,事故黑点的形成还可能与天气、交通量等动态因素紧密相关。后续研究可以考虑造成事故的动态因素,并进一步深入挖掘异常驾驶行为与路段特征之间的交互影响,为研究事故诱因、黑点形成影响因素提供依据。此外,本研究将路段事故次数作为黑点判别方法的响应变量,未考虑事故造成的财产损失等因素,下一步的研究将综合考虑这些因素,以期得到更优的判别结果。

〔参考文献〕

[1] GHADI M, TÖRÖK Á. A comparative analysis of black spot identification methods and road accident segmentation methods[J]. Accident Analysis & Prevention, 2019, 128: 1-7.

[2] 孙晴晴,臧超. 基于谱聚类的交通事故黑点鉴别及预测[J]. 工业控制计算机, 2018, 31(3): 20-22.

SUN Qing-qing, ZANG Chao. Identification and prediction of black spots in traffic accidents based on spectral clustering[J]. Industrial Control Computer, 2018, 31(3): 20-22.

[3] 符铎砂,陈丹,钟时雨. 基于 BP 神经网络的事事故黑点治理紧迫性排序研究[J]. 公路工程, 2018, 43(1): 154-158.

FU Xin-sha, CHEN Dan, ZHONG Shi-yu. Research on urgency sorting of accident black-spot treatment based on BP neural network[J]. Highway Engineering, 2018, 43(1): 154-158.

[4] 马德明,梁宏斌. 基于时空混合残差网络的事事故黑点预测研究[J]. 交通运输工程与信息学报, 2020, 18(4): 68-75.

MA De-ming, LIANG Hong-bin. Accident black spot

- prediction based on spatio-temporal heterogeneous residual network[J]. *Journal of Transportation Engineering and Information*, 2020, 18(4): 68-75.
- [5] FAN Z, LIU C, CAI D, et al. Research on black spot identification of safety in urban traffic accidents based on machine learning method[J]. *Safety Science*, 2019, 118: 607-616.
- [6] MUJALLI R O, LÓPEZ G, GARACH L. Bayes classifiers for imbalanced traffic accidents datasets[J]. *Accident Analysis & Prevention*, 2016, 88: 37-51.
- [7] DENG K Y, ZHANG X Y, CHENG Y J, et al. A remaining useful life prediction method with long-short term feature processing for aircraft engines [J]. *Applied Soft Computing*, 2020, 93: 106344.
- [8] 吴佩洁, 孟祥海, 崔洪海. 面向 NSM 的高速公路大路段事故风险预测方法[J]. *交通信息与安全*, 2018, 36(4): 7-14.
- WU Pei-jie, MENG Xiang-hai, CUI Hong-hai. A crash prediction method for long segments on free-ways based on road network traffic safety management[J]. *Journal of Transport Information and Safety*, 2018, 36(4): 7-14.
- [9] 孟祥海, 张晓明, 郑来. 基于线形与交通状态的山区高速公路追尾事故预测[J]. *中国公路学报*, 2012, 25(4): 113-118.
- MENG Xiang-Hai, ZHANG Xiao-ming, ZHENG Lai. Prediction of rear-end collision on mountainous expressway based on geometric alignment and traffic conditions[J]. *China Journal of Highway and Transport*, 2012, 25(4): 113-118.
- [10] BIL M, ANDRÁŠIK R, JANOŠKA Z. Identification of hazardous road locations of traffic accidents by means of kernel density estimation and cluster significance evaluation[J]. *Accident Analysis and Prevention*, 2013, 55(1): 265-273.
- [11] HANCOCK J, KHOSHGOFTAAR T M. Medicare fraud detection using CatBoost [C]//2020 IEEE 21st International Conference on Information Reuse and Integration for Data Science (IRI). New York: IEEE, 2020: 97-103.
- [12] FRIEDMAN J H, MEULMAN J J. Multiple additive regression trees with application in epidemiology[J]. *Statistics in Medicine*, 2003, 22(9): 1 365-1 381.
- [13] 田伟, 王文星. 公路隧道设计阶段风险评估中的问题与对策[J]. *公路与汽运*, 2020(1): 134-138.
- TIAN Wei, WANG Wen-xing. Problems and countermeasures in risk assessment of highway tunnel design stage[J]. *Highways & Automotive Applications*, 2020(1): 134-138.
- [14] 郭强, 丛浩哲, 王俊骅. 高速公路出入口危险行车事件监控与预警研究[J]. *交通信息与安全*, 2010, 28(4): 99-102.
- GUO Qiang, CONG Hao-zhe, WANG Jun-hua. Monitoring and warning of dangerous driving behaviors at expressway entrances and exits[J]. *Journal of Transport Information and Safety*, 2010, 28(4): 99-102.
- [15] 陈赞, 陈玉斌, 刘湘慧. 基于 CDBT 和 KNN 的地铁施工坍塌事故应急措施生成研究[J]. *长沙理工大学学报(自然科学版)*, 2021, 18(3): 45-54.
- CHEN Yun, CHEN Yu-bin, LIU Xiang-hui. Generation study on emergency measures of subway collapse based on CDBT and KNN[J]. *Journal of Changsha University of Science & Technology (Natural Science)*, 2021, 18(3): 45-54.
- [16] 李晓虎, 范炜, 袁浩, 等. 车速限制下高速公路临时路肩使用条件研究[J]. *交通科学与工程*, 2020, 36(3): 67-73.
- LI Xiao-hu, FAN Wei, YUAN Hao, et al. Research on temporary applicable conditions of expressway shoulder under speed limit[J]. *Journal of Transport Science and Engineering*, 2020, 36(3): 67-73.
- [17] 杨慧敏, 石琴, 陈一锴, 等. 基于混合聚类的农村公路单车事故影响因素分析[J]. *中国安全科学学报*, 2020, 30(8): 129-136.
- YANG Hui-min, SHI Qin, CHEN Yi-kai, et al. Influencing factors for single vehicle accidents on rural highways based on hybrid clustering approach[J]. *China Safety Science Journal*, 2020, 30(8): 129-136.
- [18] 范宝文, 向红艳. 山区高速公路路段危险度计算模型[J]. *长沙理工大学学报(自然科学版)*, 2013, 10(3): 39-43.
- FAN Bao-wen, XIANG Hong-yan. Calculation model of mountainous highway risk [J]. *Journal of Changsha University of Science & Technology (Natural Science)*, 2013, 10(3): 39-43.
- [19] 孟祥海, 刘振博. 基于 Tobit 回归的山区高速公路事故率分析模型[J]. *中外公路*, 2020, 40(2): 294-299.
- MENG Xiang-hai, LIU Zhen-bo. Analysis model of mountain expressway accident rate based on Tobit regression[J]. *Journal of China & Foreign Highway*, 2020, 40(2): 294-299.

(编辑 石月珍)