

DOI: 10.16544/j.cnki.cn43-1494/u.202305262024101978

文章编号: 1674-599X(2024)05-0120-07

引用格式: 保丽霞, 姜滢, 王丹, 等. 高速公路人机共驾接管反应时间估计方法[J]. 交通科学与工程, 2024, 40(5): 120-126.

Citation: BAO Lixia, JIANG Yan, WANG Dan, et al. An estimating method for take-over reaction time of human-machine co-driving on freeways [J]. Journal of Transport Science and Engineering, 2024, 40(5): 120-126.

高速公路人机共驾接管反应时间估计方法

保丽霞¹, 姜滢¹, 王丹², 吴志周², 高志波³

(1. 上海市城市建设设计研究总院(集团)有限公司, 上海 200125; 2. 同济大学 道路与交通工程教育部重点实验室, 上海 201804; 3. 长沙理工大学 交通运输工程学院, 长沙 410114)

摘要: 为推进高速公路的智慧化建设, 提升人机共驾的有效性和安全性, 提出了一种高速公路人机共驾接管反应时间估计方法。以高速公路封闭道路直线段为驾驶模拟试验场景, 选取驾驶行为特征变量, 基于随机森林法对接管反应时间进行估计。研究结果表明: 所提出模型的平均绝对百分比误差在 13.56% 以内, 与其他回归模型相比, 该模型的误差波动幅度和离散程度均处于较优水平; 对特征变量的重要性进行排序后发现, 接管反应时间预算对接管反应时间预测模型的影响最大, 其次为驾驶员熟练程度和周围有无车辆。研究成果可为智慧高速公路的发展和驾驶控制权接管策略的评价、设计和改进提供参考。

关键词: 交通工程; 高速公路; 人机共驾; 驾驶行为; 接管反应时间

中图分类号: U495

文献标志码: A

An estimating method for take-over reaction time of human-machine co-driving on freeways

BAO Lixia¹, JIANG Yan¹, WANG Dan², WU Zhizhou², GAO Zhibo³

(1. Shanghai Urban Construction Design and Research Institute (Group) Co., Ltd., Shanghai 200125, China;
2. Key Laboratory of Road and Traffic Engineering of Ministry of Education, Tongji University, Shanghai 201804, China; 3. School of Traffic and Transportation Engineering, Changsha University of Science & Technology, Changsha 410114, China)

Abstract: To promote the construction of freeway intelligence and improve the effectiveness and safety of human-machine co-driving, this study proposed an estimating method for the take-over reaction time of human-machine co-driving on freeways. A straight section of a closed freeway was used as the driving simulation scenario, and feature variables of the driving behavior were selected to estimate the take-over reaction time with the random forest method. The results show that the mean absolute percentage error of the proposed model is controlled within 13.56%, and its error fluctuation magnitude and dispersion degree are at better levels than those of other regression models. The importance of the feature variables was ranked, and it is found that the take-over reaction time budget has the greatest influence on the take-over reaction time prediction model, followed by driver proficiency and surrounding vehicle conditions. This research provides a reference for the development of smart freeways and the evaluation, design, and improvement of driving control take-over strategies.

收稿日期: 2023-05-26

基金项目: 交通运输部交通运输行业重点科技项目(2020-ZD3-025); 长沙市科技重大专项(kh2301004)

通信作者: 保丽霞(1978—), 女, 高级工程师, 主要从事智能交通方面的研究工作。E-mail: jlublx@163.com

投稿网址: <https://jtkxygc.csust.edu.cn/jtkxygc/home>

Key words: traffic engineering; freeway; human-machine co-driving; driving behavior; take-over reaction time

面对公众日益增长的通行需求,高速公路的管理和服务效能亟待提升,智慧高速作为一种新型的公路发展技术形态,将成为解决交通拥堵与驾驶安全等问题的重要手段^[1-2]。在高速公路智慧化发展的过程中,路侧设施逐步为车辆赋能,支撑车辆从非自动驾驶逐渐向部分自动驾驶、有条件自动驾驶、高度自动驾驶发展。然而,受限于交通系统的复杂性和技术发展的递进性,人与系统同时享有车辆控制权的人机共驾模式将成为智慧高速公路建设实施历程中的必经阶段,以保障驾驶的有效性和安全性。

人机共驾是一种新型的智能驾驶模式,允许人类驾驶员和自动驾驶系统在不同的道路和交通情况下协同控制车辆。在人机共驾模式下,当自动驾驶系统遇到无法处理的复杂场景时,需要将控制权交还给人类驾驶员,这一过程称为接管。在此过程中,车辆控制权的接管会带来与传统交通方式不同的人因问题,因此有必要对人机共驾车辆的接管行为进行研究。

接管过程是由一系列驾驶任务需求组成的。ZEEB等^[3]提出了人机共驾车辆处于非驾驶任务状态下的驾驶员接管过程模型,该模型通过预测驾驶环境的未来状态,做出是否由驾驶员接管车辆的决策。接管过程的绩效评价包含接管反应力(能否及时接管)和接管质量(接管是否稳定)两个维度。接管反应力是指系统发出接管请求后,驾驶员能及时转移注意力观察道路环境,并恢复对车辆操作的能力^[4]。GOLD等^[5]研究发现,在5 s反应时间预算下,驾驶员平均的注视反应时间、动作反应时间和操作反应时间分别为0.69、1.45和2.10 s,在7 s反应时间预算下则分别为0.94、1.79和2.89 s。接管质量的好坏是指驾驶员在接管后能否稳定地控制车辆的运行。徐超^[6]基于人机共驾虚拟试验平台设计了两种场景(系统预警、系统失效)下的接管试验,提出了人机共驾行为的评价方法,并得到了驾驶员接管可靠度的计算方法。NAUJOKS等^[7]设计了一个可切换控制权的控制水平专家评估系统,该系统用标准化的评估体系对驾驶场景、人机交互界面、控制情况等内容进行评价。

接管反应时间是影响人机共驾安全性和效率

的重要指标,也是评价接管策略优劣的关键要素,指从自动驾驶系统发出接管请求到人类驾驶员完成接管的时间。WANDTNER等^[8]基于Wickens的多资源理论假设进行了多变量系统分析,进行了非驾驶相关任务需求和接管反应时间估计。GOLD等^[9]设计了主要接管性能变量(包括接管反应时间、最小碰撞时间、制动应用和碰撞概率)的预测模型。SCATTURIN等^[10]提出了一个概念框架作为动态预测接管情况的认知模型。HWANG等^[11]建立了一个基于隐马尔可夫模型的回归模型,对接管反应时间进行预测。BERGHÖFER等^[12]构建了一个基于驾驶员注视活动和驾驶员特征(如年龄、性别、对高度自动驾驶的态度和以前的自动驾驶经验)的接管反应时间预测回归模型。由此可见,当前研究更多关注的是驾驶员状态和驾驶任务需求,缺乏对人机共驾接管驾驶环境和信息的关注。

综上所述,以往研究多集中在人机共驾接管场景、接管过程、接管质量、驾驶员特征等因素对接管行为的影响上,但是鲜有基于上述因素对接管行为进行预测的方法。因此,本文旨在提出一种基于随机森林模型的人机共驾接管反应时间估计方法,通过分析高速公路有条件自动驾驶模拟试验数据,提取影响接管反应时间的关键因素,并构建接管反应时间估计模型,以期为人机共驾系统控制权接管策略的评价、设计和优化提供参考。

1 模型构建

随机森林^[13](random forest, RF)是一种集成学习算法,以决策树为基学习器。本文之所以选取随机森林模型进行人机共驾接管反应时间的估计,是因为RF模型能够处理高维度和非线性数据,同时适用于人机共驾模拟试验数据的处理;能够提供变量重要性的评估,有助于分析影响接管反应时间的因素;能够输出预测结果的置信区间,有助于评估预测结果的可靠性。

决策树是一种基本的数据挖掘方法,所采用的分类回归树(classification and regression tree, CART)决策算法可以同时解决分类和回归问题。回归决策树模型呈二叉树结构,包含内部节点和叶节点,

其中内部节点将特征空间划分为若干个子空间,叶节点对应每个子空间的输出值。回归决策树模型的基本思想如下:

首先,假设 X 和 Y 分别为输入和输出变量,且 Y 为连续变量, $D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\}$ 为给定数据集,其中 $x_i = (x_i^{(1)}, x_i^{(2)}, x_i^{(3)}, \dots, x_i^{(n)})$, $y_i = (y_i^{(1)}, y_i^{(2)}, y_i^{(3)}, \dots, y_i^{(n)})$ ($i=1, 2, \dots, N$) 为特征变量, n 为特征数, N 为样本容量。假设决策树共有 M 个叶节点,即特征空间被划分为 M 个子空间,分别为 R_1, R_2, \dots, R_M , 则第 m 个子空间的输出值 O_m 为:

$$O_m = \arg \min \frac{1}{2} \sum_{x_i \in R_m} (y_i - O_m)^2 \quad (1)$$

然后,对特征空间的划分采用启发式方法,即每次划分时逐一考察当前集合中每个特征的所有取值,根据误差平方和最小准则选取划分特征 $x^{(j)}$ 及其所对应的值 s ,并将样本划分成两个区域 $R_1(j, s) = \{x | x^{(j)} \leq s\}$ 和 $R_2(j, s) = \{x | x^{(j)} > s\}$ 。为使这两个区域的误差平方和最小,遍历特征变量 $x^{(j)}$,求出能使下式达到最小的 (j, s) :

$$\min_{j, s} \sum_{x_i \in R_1(j, s)} (y_i - O_1)^2 + \sum_{x_i \in R_2(j, s)} (y_i - O_2)^2 \quad (2)$$

每个子空间的输出值为:

$$\hat{c}_1 = \frac{1}{N_1} \sum_{x_i \in R_1(j, s)} y_i \quad (3)$$

$$\hat{c}_2 = \frac{1}{N_2} \sum_{x_i \in R_2(j, s)} y_i \quad (4)$$

式中: N_1, N_2 均为子空间的样本容量。

对每个叶节点重复上述过程,直至满足停止条件,生成回归决策树。停止条件可以是决策树的最大深度、每个叶节点的最小样本数、误差平方和的减小值超过设定值等。

在此基础上,随机森林应用 Bagging 集成学习理论^[14]和随机子空间方法^[15],进行自助采样和随机特征选择,构建多棵决策树。不同决策树之间没有关联,最终结果由所有决策树的回归结果综合决定。与单一决策树模型相比,这种方法能够解决过拟合问题,模型方差更小,泛化能力更强,可以判断特征的重要程度,对缺失值、异常值均有很好的容忍性。

对每棵决策树进行随机抽样,即通过 Bootstrap 抽样法从原始数据集 D 中有放回地抽取 N 个样本,作为训练决策树的根节点样本,未被抽到的样本组成袋外数据(out of bag, OOB), K 棵决策树需要抽取

K 次。

另外,随机性还反映在特征变量的选取方面。假设原始数据集 D 具有 P 个特征变量,则在决策树形成过程中为每个节点随机选取 Q 个特征变量 ($Q < P$) 作为子特征集,并从中选取最优分裂特征和最优分裂点,直到子特征集不能继续分裂为止。这种方式增大了不同决策树之间的差异性,提高了模型的泛化能力。

2 试验设计

接管反应时间估计模型的基本思路如下:

1) 数据采集。设计基于驾驶模拟器的试验方案,采集 6 种接管场景、2 种接管方式下 12 名驾驶员的操作行为数据。

2) 数据处理。剔除异常数据。

3) 参数设置。调整关键参数 $P_{n_estimator}$ 和 P_{max_depth} , 优化模型。

4) 模型求解。将 OOB 数据输入每棵决策树,得到 K 个预测结果,取其平均值得到随机森林模型的最终结果。

5) 模型评价。选取平均绝对误差 E_{MAE} 、均方误差 E_{MSE} 、平均绝对百分比误差 E_{MAPE} 和均方根误差 E_{RMSE} 对模型预测效果进行评价。

$$E_{MAE} = \frac{1}{k} \sum_{i=1}^k |\hat{y}_i - y_i| \quad (5)$$

$$E_{MSE} = \frac{1}{k} \sum_{i=1}^k (\hat{y}_i - y_i)^2 \quad (6)$$

$$E_{MAPE} = \frac{100\%}{k} \sum_{i=1}^k \left| \frac{\hat{y}_i - y_i}{y_i} \right| \quad (7)$$

$$E_{RMSE} = \sqrt{\frac{1}{k} \sum_{i=1}^k (y_i - \hat{y}_i)^2} \quad (8)$$

式中: y_i, \hat{y}_i 分别为第 i 个样本的真实值和预测值; k 为样本数量。

6) 模型对比。与轻量梯度提升机器(light gradient boosting machine, LGBM)算法、支持向量回归(support vector regression, SVR)模型、误差反馈(back propagation, BP)神经网络和岭回归模型^[16-19]进行对比,验证接管反应时间估计模型的有效性。

接管反应时间估计模型的流程图见图 1。本文选取的特征变量包括接管反应时间预算、驾驶熟练程度、周围有无车辆、驾驶员性别、有无视觉接管信息、有无听觉接管信息(表 1)。

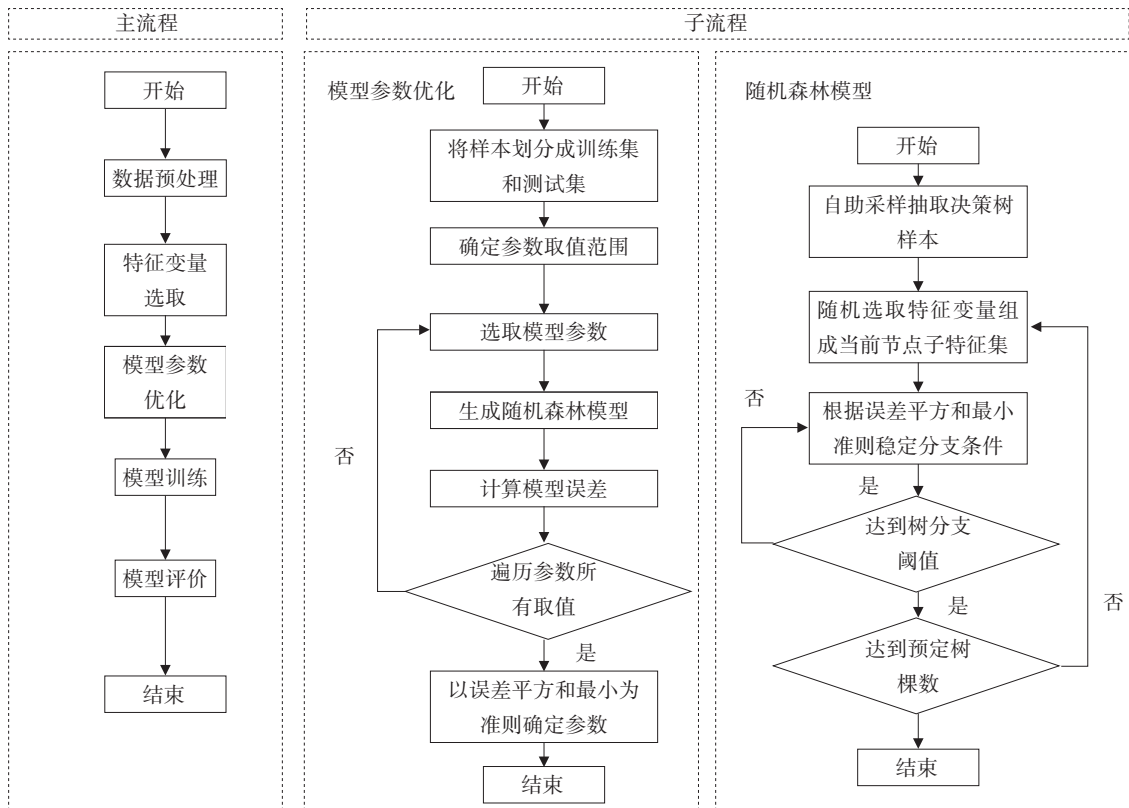


图1 接管反应时间估计模型流程图

Fig. 1 Flow chart of take-over reaction time estimation model

表1 特征变量赋值及含义

Table 1 Assignments and meanings of feature variables

特征变量	赋值编码	含义
接管反应时间预算	0	无接管反应时间预算
	5	5 s接管反应时间预算
	7	7 s接管反应时间预算
驾驶熟练程度	0	新手
	1	熟练
周围有无车辆	0	周围无车
	1	周围有车
驾驶员性别	0	女性
	1	男性
有无视觉接管信息	0	无
	1	有
有无听觉接管信息	0	无
	1	有

3 参数设置

在选取特征变量前,需对试验数据进行预处理,即遵循 3σ (σ 为标准差)原则剔除不合理的异常值。 3σ 原则是指在样本服从正态分布的情况下,数值分布在区间 $(\mu - \sigma, \mu + \sigma)$ 中的概率为0.682 6(μ

为均值),数值分布在区间 $(\mu - 2\sigma, \mu + 2\sigma)$ 中的概率为0.954 4,数值分布在区间 $(\mu - 3\sigma, \mu + 3\sigma)$ 中的概率为0.997 4。本文统计了12名驾驶员在12个接管场景下的接管反应时间,并绘制了散点图、正态分布曲线与直方图,如图2~3所示。接管反应时间样本的均值 μ 为1.647 s,标准差 σ 为0.684 s,根据 3σ 原则保留位于区间 $[0.279, 3.015]$ 中的数据,如图4所示。图4中两条虚线之间的数据即为用于接管反应时间预测的数据。




图2 驾驶员接管反应时间散点图

Fig. 2 Scatter plot of driver take-over reaction time




图3 接管反应时间正态分布曲线与直方图

Fig. 3 Normal distribution curve and histogram of take-over reaction time




图4 接管反应时间样本的上下界

Fig. 4 Bounds of take-over reaction time samples

将试验中所采集的数据以4:1的比例划分为训练集和测试集,调试参数 $P_{n_estimator}$ 和 P_{max_depth} 。

$P_{n_estimator}$ 是基学习器的最大迭代次数,也就是决策树的最大棵数。如果 $P_{n_estimator}$ 过小,模型容易欠拟合,且模型的学习速度慢;如果 $P_{n_estimator}$ 过大,模型容易过拟合,此时模型的稳定性和泛化能力差。通过试验发现,当 $P_{n_estimator}$ 为600时,模型对应的 E_{MAE} 、 E_{MSE} 、 E_{MAPE} 和 E_{RMSE} 均最小,说明此时模型的泛化能力最强。 $P_{n_estimator}$ 的调参结果见表2。

表2 $P_{n_estimator}$ 调参结果Table 2 Hyperparameters tuning of $P_{n_estimator}$

$P_{n_estimator}$	E_{MAE}	E_{MSE}	E_{RMSE}	$E_{MAPE}/\%$
5 000	0.207	0.089	0.298	13.69
3 000	0.208	0.089	0.298	13.68
2 000	0.207	0.089	0.298	13.67
1 500	0.207	0.089	0.298	13.66
1 000	0.206	0.089	0.298	13.60

表2 (续)

Table 2 (Continued)

$P_{n_estimator}$	E_{MAE}	E_{MSE}	E_{RMSE}	$E_{MAPE}/\%$
975	0.206	0.089	0.298	13.60
950	0.206	0.088	0.297	13.59
900	0.206	0.088	0.297	13.62
800	0.207	0.089	0.299	13.63
750	0.206	0.089	0.298	13.59
700	0.206	0.089	0.298	13.56
600	0.206	0.088	0.297	13.56
500	0.207	0.088	0.297	13.65
400	0.207	0.088	0.297	13.69
200	0.209	0.089	0.299	13.85
100	0.206	0.091	0.307	13.67
50	0.210	0.095	0.307	13.96
20	0.218	0.100	0.311	14.43
10	0.224	0.100	0.316	14.78
5	0.259	0.119	0.345	16.67
2	0.237	0.116	0.341	15.22

P_{max_depth} 为决策树分类的最大深度,可以通过调整 P_{max_depth} 值来控制模型的复杂度和准确度。增大 P_{max_depth} 有利于提高模型的准确度,但 P_{max_depth} 过大会导致模型过度拟合,从而降低了模型的泛化能力。表3为 P_{max_depth} 的调参结果。由表3可知,当 P_{max_depth} 取值为5时,模型结果最佳。

表3 P_{max_depth} 调参结果Table 3 Hyperparameters tuning of P_{max_depth}

P_{max_depth}	E_{MAE}	E_{MSE}	E_{RMSE}	$E_{MAPE}/\%$
None(最大值)	0.206	0.088	0.297	13.56
20	0.206	0.087	0.297	13.56
10	0.206	0.087	0.297	13.56
6	0.206	0.087	0.297	13.56
5	0.206	0.087	0.297	13.56
4	0.214	0.096	0.309	14.65
3	0.224	0.094	0.308	15.72
2	0.215	0.087	0.294	15.44

4 模型对比

图5展示了RF模型预测值与真实值的对比情况。为了验证RF模型的效果,本文将LGBM算法、SVR模型、BP神经网络、岭回归模型与RF模型进行了对比,结果见表4。




图5 真实值和预测值对比

Fig. 5 Comparison of true and estimated values

表4 各模型预测结果对比

Table 4 Comparison of model estimation results

模型	E_{MAE}	E_{MSE}	E_{RMSE}	$E_{MAPE}/\%$
RF	0.206	0.089	0.298	13.60
LGBM	0.239	0.089	0.298	17.23
SVR	0.387	0.209	0.457	25.19
BP神经网络	0.345	0.185	0.430	30.34
岭回归	0.226	0.085	0.291	16.67

对于 E_{MAE} ,各模型从小到大的排序为:RF、岭回归、LGBM、BP神经网络、SVR;对于 E_{MAPE} ,各模型从小到大的排序为:RF、岭回归、LGBM、SVR、BP神经网络;对于 E_{MSE} 、 E_{RMSE} ,各模型从小到大的排序为:岭回归、RF(LGBM)、BP神经网络、SVR。由此可见,RF模型的误差波动幅度明显比其他模型的小,其误差离散程度也仅比岭回归模型的略高,说明RF模型具有较好的估计精度。

根据所有分类节点平均基尼系数减小值,对各特征变量的重要程度进行排序,结果如图6所示。从图6可以看出,6个特征变量的重要程度从大到小的排序为:接管反应时间预算、驾驶熟练程度、周围有无车辆、有无视觉接管信息、驾驶员性别、有无听觉接管信息。这一结果表明,随机森林模型在处理高维数据方面表现出色,能够有效评估各特征的重要性及相互影响,说明随机森林模型在预测性能上具有独特优势,优于其他模型。




图6 特征变量重要程度

Fig. 6 Importance degree of feature variables

5 结论

本研究构建了一种高速公路人机共驾接管反应时间估计模型,旨在为智慧高速公路的推进及接管策略设计提供评价和改进依据。研究结果表明:

1) 所构建的估计模型具有良好的预测精度,其平均绝对百分比误差控制在13.56%以内。

2) 与其他回归模型的对比结果显示,随机森林模型在误差波动幅度和离散程度上表现优秀,具有良好的应用效果。

3) 在各特征变量中,接管反应时间预算对接管反应时间估计模型的影响最大,其次是驾驶熟练程度和周围有无车辆。

综上所述,本研究为高速公路人机共驾系统的接管反应时间提供了有效的预测工具,对智慧高速公路的未来发展具有重要的指导价值。

参考文献(References):

- [1] 龙科军, 邹道兴, 何石坚. 基于多源数据融合的高速公路交通事故黑点判别[J]. 长沙理工大学学报(自然科学版), 2022, 19(1): 89-95. DOI: 10.19951/j.cnki.1672-9331.2022.01.011.
LONG Kejun, ZOU Daoxing, HE Shijian. Identification of black spots in highway traffic accidents based on multi-source data fusion[J]. Journal of Changsha University of Science & Technology (Natural Science), 2022, 19(1): 89-95. DOI: 10.19951/j.cnki.1672-9331.2022.01.011.
- [2] 郭丽苹, 朱晓东, 高佳宁, 等. 基于VisSim仿真的高速公路客货分道动态控制[J]. 交通科学与工程, 2021, 37(4): 108-116. DOI: 10.3969/j.issn.1674-599X.2021.04.015.

- GUO Liping, ZHU Xiaodong, GAO Jianing, et al. Dynamic control of passenger-cargo lane separation of expressway based on the VisSim simulation[J]. Journal of Transport Science and Engineering, 2021, 37(4): 108-116. DOI: 10.3969/j.issn.1674-599X.2021.04.015.
- [3] ZEEB K, BUCHNER A, SCHRAUF M. What determines the take-over time? An integrated model approach of driver take-over after automated driving[J]. Accident Analysis & Prevention, 2015, 78: 212-221. DOI: 10.1016/j.aap.2015.02.023.
- [4] VLAKVELD W, VAN NES N, DE BRUIN J, et al. Situation awareness increases when drivers have more time to take over the wheel in a level 3 automated car: a simulator study [J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2018, 58: 917-929. DOI: 10.1016/j.trf.2018.07.025.
- [5] GOLD C, DAMBÖCK D, LORENZ L, et al. "Take over!" How long does it take to get the driver back into the loop? [J]. Proceedings of the Human Factors and Ergonomics Society Annual Meeting, 2013, 57(1): 1938-1942. DOI: 10.1177/1541931213571433.
- [6] 徐超. 基于虚拟驾驶的切换型人机共驾行为评价[D]. 长春: 吉林大学, 2018.
XU Chao. Evaluation of cooperative driving behavior based on the virtual driving [D]. Changchun: Jilin University, 2018.
- [7] NAUJOKS F, WIEDEMANN K, SCHÖMIG N, et al. Expert-based controllability assessment of control transitions from automated to manual driving [J]. MethodsX, 2018, 5: 579-592. DOI: 10.1016/j.mex.2018.05.007.
- [8] WANDTNER B, SCHMIDT G, SCHOEMIG N, et al. Non-driving related tasks in highly automated driving-effects of task modalities and cognitive workload on take-over performance [C]//9th GMM-Symposium. Offenbach: VDE, 2018.
- [9] GOLD C, HAPPEE R, BENGLER K. Modeling take-over performance in level 3 conditionally automated vehicles [J]. Accident Analysis and Prevention, 2018, 116: 3-13. DOI: 10.1016/j.aap.2017.11.009.
- [10] SCATTURIN L, ERBACH R, BAUMANN M. Cognitive psychological approach for unraveling the take-over process during automated driving [C]//Proceedings of AutomotiveUI '19 Adjunct. Utrecht: Association for Computing Machinery, 2019. DOI: 10.1145/3349263.3351501.
- [11] HWANG S, BANERJEE A G, BOYLE L N. Predicting driver's transition time to a secondary task given an in-vehicle alert [J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(5): 4739-4745. DOI: 10.1109/TITS.2020.3018395.
- [12] BERGHÖFER F L, PURUCKER C, NAUJOKS F, et al. Prediction of take-over time demand in conditionally automated driving-results of a real world driving study [C]//Proceedings of the Human Factors and Ergonomics Society Europe. Santa Monica: Human Factors and Ergonomics Society, 2018: 69-81.
- [13] BREIMAN L. Random forests [J]. Machine Learning, 2001, 45: 5-32. DOI: 10.1023/A: 1010933404324.
- [14] BREIMAN L. Bagging predictors [J]. Machine Learning, 1996, 24(2): 123-140. DOI: 10.1023/A: 1018054314350.
- [15] HO T K. The random subspace method for constructing decision forests [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 1998, 20(8): 832-844. DOI: 10.1109/34.709601.
- [16] 郑长江, 孙凯, 沈金星, 等. 基于贝叶斯BWM的中小城市综合交通网络评价[J]. 交通科学与工程, 2023, 39(2): 95-104. DOI: 10.16544/j.cnki.cn43-1494/u.20211030001.
ZHENG Changjiang, SUN Kai, SHEN Jinxing, et al. Comprehensive evaluation of integrated transportation network in small and medium-sized cities based on Bayesian BWM [J]. Journal of Transport Science and Engineering, 2023, 39(2): 95-104. DOI: 10.16544/j.cnki.cn43-1494/u.20211030001.
- [17] 黄中祥, 胡望欣, 李志学. 考虑快捷性和舒适性出行偏好的网络混合均衡[J]. 交通科学与工程, 2022, 38(3): 121-127. DOI: 10.16544/j.cnki.cn43-1494/u.2022.03.012.
HUANG Zhongxiang, HU Wangxin, LI Zhixue. Mixed network equilibrium considering travel preferences of rapidity and comfort [J]. Journal of Transport Science and Engineering, 2022, 38(3): 121-127. DOI: 10.16544/j.cnki.cn43-1494/u.2022.03.012.
- [18] 曾岳凯, 周涛, 陈亚振. 基于仿真的多车道高速公路交通冲突分析[J]. 中外公路, 2023, 43(3): 270-274. DOI: 10.14048/j.issn.1671-2579.2023.03.043.
ZENG Yuekai, ZHOU Tao, CHEN Yazhen. Traffic conflict analysis of multilane expressway based on simulation [J]. Journal of China & Foreign Highway, 2023, 43(3): 270-274. DOI: 10.14048/j.issn.1671-2579.2023.03.043.
- [19] 杨松, 雷财林, 暨育雄, 等. 基于车辆互扰的高速公路车群识别方法研究[J]. 公路与汽运, 2024, 40(2): 20-26. DOI: 10.20035/j.issn.1671-2668.2024.02.005.
YANG Song, LEI Cailin, JI Yuxiong, et al. Research on expressway vehicle group identification method based on vehicle mutual interference [J]. Highways & Automotive Applications, 2024, 40(2): 20-26. DOI: 10.20035/j.issn.1671-2668.2024.02.005.

(责任编辑:石月珍)