基于车辆轨迹数据的驾驶人跟驰行为风格划分方法

杨天麟[1,2]，王卫杰[3]，李宇涵[1,2]，李嘉洋[4]

（1. 同济大学 道路与交通工程教育部重点实验室，上海 201804；2. 同济大学 交通学院，上海 201804；3. 南京工业大学 交通运输工程学院，南京 211816；4. 上海市城市建设设计研究总院（集团有限公司），上海 200120）

摘　要：为对人类驾驶环境下的交通流建模研究等提供可靠的跟驰行为描述，在拥有快速路车辆时空轨迹数据的前提下，基于“模型参数标定-参数重要度识别-聚类分析”构建了一整套基于规则类跟驰模型的驾驶人跟驰行为风格划分方法。首先，选择适合国内交通流状况的智能驾驶人模型（IDM）作为所研究的跟驰模型，在参数标定阶段，利用在城市快速路采集的车辆时空轨迹数，提取143组跟驰行为样本数据，随后选用前后车辆的跟驰间距和后车速度作为性能指标，采用粒子群优化算法标定了143组跟驰行为样本数据的IDM模型参数。其次，在参数重要度识别阶段，利用主成分分析统计方法获取了研究场景下IDM模型参数的主要属性和次要属性。最后，利用改进的K-means++聚类算法将143组跟驰行为样本数据划分为3类，并结合IDM模型参数的重要度进行量化分析，最终得到激进型、中庸型、保守型3种不同风格跟驰行为的IDM模型参数表征。结果表明：与不考虑模型参数重要度的分析过程相比，本文方法能更直观地划分驾驶人跟驰行为风格。在仿真分析中，本文从安全性和排放性分析了各风格驾驶员比例占主导时对交通系统的影响，从而探究所划分和定义的3种跟驰风格的可解释性。本文研究结果有助于更准确刻画驾驶人跟驰行为异质性，对进一步提高驾驶行为仿真精度和设计符合人类特征的自动驾驶策略具有借鉴意义。

关键词：轨迹数据；K-means++算法；跟驰行为；参数标定；主成分分析

中图分类号：U491.2　　**文献标志码**：A　　**文章编号**：1671-5497(2026)06-1564-16

DOI：10.13229/j.cnki.jdxbgxb.20241195

Classification of driver car-following behavior style based on vehicle trajectory data

YANG Tian-lin[1,2], WANG Wei-jie[3], LI Yu-han[1,2], LI Jia-yang[4]

(1. *The Key Laboratory of Road and Traffic Engineering, Ministry of Education, Tongji University, Shanghai* 201804, *China*; 2. *College of Transportation, Tongji University, Shanghai* 201804, *China*; 3. *College of Transportation Engineering, Nanjing Tech University, Nanjing* 211816, *China*; 4. *Shanghai Urban Construction Design and Research Institute (Group) Co., Ltd., Shanghai* 200120, *China*)

收稿日期：2024-11-06.

基金项目：国家重点研发计划项目（2023YFB4301900）；国家自然科学基金项目（52372319，52302414）；湖南省重点研发计划项目（2023SK2052）.

作者简介：杨天麟（1995-），男，博士研究生. 研究方向：数据驱动的道路交通管控. E-mail：yangtianlin@tongji.edu.cn

Abstract: To provide a reliable description of the car-following behavior for the traffic flow modeling research in the human driving environment, under the premise of vehicle spatiotemporal trajectory data of expressway, based on the "model parameter calibration-parameter importance recognition-cluster analysis", a complete set of car-following behavior style classification methods based on the rule-based car-following model was constructed. First, the Intelligent Driver Model (IDM), which is suitable for the domestic traffic flow condition, was selected as the car-following model based on the existing researches, and in the parameter calibration stage, 143 sets of sample data on car-following behavior were extracted using the number of vehicle spatiotemporal trajectories collected on urban expressways, and subsequently the following distance and the speed of the rear vehicle are chosen as the performance indexes, the particle swarm optimization algorithm was used to calibrate the parameters of the IDM model for 143 sets of sample data on car-following behavior. Secondly, in the parameter importance identification stage, the primary attributes and secondary attributes of the IDM model parameters in the research scenario of this paper were obtained using the principal component analysis statistical method. Finally, the improved K-means plus clustering algorithm was used to classify the 143 sets of car-following behavior sample data into three categories and quantitatively analyze them in combination with the importance of the IDM model parameters, and ultimately obtain the characterization of the IDM model parameters of the three different car-following behavior styles: aggressive, modest and conservative. The results show that the proposed method can more intuitively classify drivers car-following behavior styles than the process without considering the importance of model parameters. In the simulation analysis, the impacts on traffic systems in terms of safety and emissions when one driving style accounts for the dominant proportion of drivers are analyzed, so as to explore the interpretability of the three car-following styles classified and defined. The results can help to more accurately portray the heterogeneity of driver car-following behavior, which is of guiding significance for further improving the accuracy of driving behavior simulation and designing automatic driving strategies that conform to human characteristics.

Key words: trajectory data; *K*-means++ algorithm; car-following behavior; parameter calibration; principal component analysis

0　引　言

道路交通系统是由人、车、路构成的复杂巨系统,驾驶人是其中最核心且最复杂的组成部分[1]。由于个人驾驶经验、行为习惯、受教育程度及身体状态等多方面因素的差异性,人类驾驶行为会呈现难以解析且不确定性强的特点。Elander等[2]在1993年提出了驾驶风格的概念,并将驾驶风格定义为驾驶人选择或者习惯的驾驶方式,强调驾驶风格受到驾驶人的车速控制、驾驶意识、风险评估、驾驶技能等众多因素的影响。

从交通安全研究角度,针对人工驾驶车辆,由于驾驶人的驾驶风格差异性和人类意图的不确定性,导致人机混驾环境中自动驾驶车辆难以准确地预测人工驾驶车辆的行为,从而造成交通系统存在安全隐患[3,4]。除了普通的驾驶行为外,驾驶人的多种危险驾驶姿态更是影响交通事故死亡率的重要因素[5]。为全面解析驾驶人的驾驶行为和进行驾驶风险评估,国内外研究者普遍采用驾驶人行为量表[1]和行为问卷[6]等工具进行驾驶风格主观度量,近年来神经工效学的发展也使得驾驶风格可以从认知-控制的角度进行划分。从衡量驾驶风格以及驾驶行为模型参数精细化的角度,加速度、速度和前后两车的安全时间间隔等驾驶行为相关变量是衡量驾驶风格的常用参数,基于获取的驾驶行为相关变量,研究者利用贝叶斯分类算法[7]、支持向量机和*K*-means聚类算法相结合的方法[8]、基于规则的方法[9]等进行不同类型驾驶风格的定义。近年来,也有不少研究者开始探究不同行为下驾驶风格的差异性,例如自由行驶行为、跟驰行为、换道行为、超车行为等[10-12]。其中,跟驰行为作为微观交通仿真中最核心的微观驾驶行为,占据总驾驶时长的80%以上[13],是

交通流理论研究和高等级自适应巡航控制系统开发的关键所在。因此,对驾驶人跟驰行为异质性进行精细化定义,会更准确模拟再现驾驶人的行为反应过程,从而设计适当的前撞预警系统报警策略[14]。同时也可实现更高精度的交通流仿真,并依据仿真所输出的各方面结果为高级自动驾驶设计规范化的驾驶行为。

跟驰模型根据建模方法可分为两类:一类是基于规则的模型;另一类是基于学习的模型。其中,基于规则的模型将领域知识和专家经验通过解析数学模型进行形式化表达,能够清晰地体现影响因素及其影响作用,并得到相关关系的解析表达式,被广泛用于各个主流交通流仿真软件中,常用的规则类跟驰模型主要有全速度差模型(Full velocity difference,FVD)模型[15]、GHR(Gazis-Herman-Rothery)模型[16]、通用车辆(General motor,GM)模型[17]、Wiedemann模型[18]、Gipps模型[19]和智能驾驶员模型(Intelligent driver model,IDM)模型[20],为进行高可信度的微观交通仿真,通常需要依据实际交通场景的车辆轨迹数据进行模型参数标定,且不同的参数分布特点可以用于表征不同类的驾驶行为。Kim等[21]提出了一种稳健的方法用于标定具有完全随机系数的GM型跟驰模型,其中异质性以数学结合的方式处理,但仍需要微观模拟实验才能得出合理的结论。Taylor等[22]通过标定出行中随时间变化的响应时间和临界车头间距,探索了驾驶人之间的异质性。Hoogendoorn等[23,24]使用7个车辆跟驰模型评估了驾驶风格和引导车辆-跟驰车辆组成的异质性,表明不同驾驶者的跟驰模型参数有所不同,然而并没有提供精确的方法对不同风格驾驶人的模型进行参数标定。

以往研究中的规则类跟驰模型参数标定虽然考虑了驾驶人跟驰行为风格的异质性,但通常是对各个参数进行同等重要度考虑,这种方法可能会造成工作量繁琐、驾驶风格划分结果矛盾和参数之间的信息量冗余等问题。为此,本文构建了一整套车辆时空轨迹数据条件下基于规则类跟驰模型的跟驰行为风格划分方法。首先,在拥有高精度车辆时空轨迹数据集的基础上,以IDM模型为例,对驾驶风格异质性的表现特征展开量化研究,选用跟驰间距和后车速度参数,采用粒子群优化算法标定了143组跟驰样本数据的IDM模型参数。其次,利用主成分分析方法获取了模型参数的属性重要性,结合改进的K-means++聚类算法得到3种不同类别的跟驰行为风格IDM模型参数表征。最后,采用仿真分析方法,从安全性和排放性两种角度分析了各风格驾驶员比例占主导时对交通系统的影响,以提升所划分和定义的3种跟驰风格的可解释性。

1 车辆时空轨迹数据

由于本文研究对象是驾驶人的跟驰行为,因此获取连续流环境下具有一定持续时间的跟驰行为是本文工作的关键。快速路由于驾驶环境稳定、行驶条件连续,易于提取同一车道前后连续两辆车的跟驰行为,因此本文选择快速路作为数据采集环境,时间为2022年11月10日的7:30~8:00早高峰时段,地点为南京市浦口区的浦口大道,该路段限速为80 km/h,属于双向八车道类型快速路。数据采集过程为:使用大疆mini2型号无人机航拍车辆运行视频,并随后通过视频处理提取车辆时空轨迹数据,具体过程如图1所示。



图1 基于视频的车辆时空、轨迹数据提取

Fig. 1 Video-based extraction of vehicle spatio-temporal trajectory data

本文最终用于提取车辆时空轨迹数据的有效视频时长为17分45秒,视频帧率为30 Hz。随后,通过YOLO目标检测算法和DeepSort目标跟踪算法从视频中提取了机动车时空轨迹数据,该方法也是目前主流的基于视频的目标轨迹跟踪手段[25]。提取后的某车道时空轨迹图样例如图2所示,图中各条车辆轨迹的平滑性也显示了提取方法的有效性。数据字段的描述如表1所示。该车辆时空轨迹数据集所覆盖的路段长度为280 m,一共包含双向8个车道中1 476个小型车辆。特别说明的是,由于在本视频中小汽车的交通量占比高达97.81%,为保证本文研究所涉及车辆类型的一致性,在视频处理过程中只提取了小型车辆的轨迹数据用于后续跟驰行为特性研究。

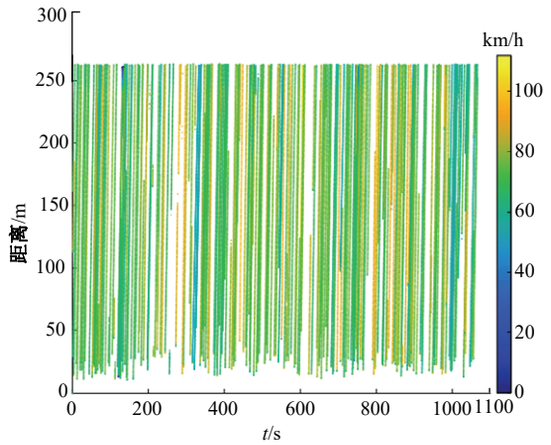


图 2　车辆时空轨迹图样例

Fig. 2　Sample vehicle spatio-temporal trajectory map

表 1 车辆时空轨迹数据集的数据字段说明

Table 1　Data descriptions for the vehicle spatio-temporal trajectory dataset

编号	名称	描述	单位
1	car_id	车辆编号	—
2	lane_id	车道编号	—
3	time	时刻	s
4	latitude	车辆横向位置	m
5	longitude	车辆纵向位置	m
6	speed	车辆速度	km/h
7	acceleration	车辆加速度	m/s^2
8	length	车辆长度	m
9	width	车辆宽度	m

2　跟驰模型的选择和标定

2.1　跟驰样本数据提取

为研究跟驰行为的异质性，并对其风格进行划分，需要从车辆时空轨迹数据集中提取出符合位置、间距、持续时间等要求的跟驰行为样本数据，其中，跟驰间距要保证位于一定区间范围，过大会减弱前车对后车的影响，过小便近似于交通拥堵状况；在跟驰时间上也要满足一定的持续性，具体筛选条件如表 2 所示[26,27]。

表 2 跟驰行为样本数据的筛选条件

Table 2　Filtering conditions for sample data on car-following behavior

筛选条件	具体描述
跟驰间距	5～75 m
跟驰持续时间	10 s 及以上
车道保持	前、后车辆均无换道行为

按照该标准对第 1 节的车辆时空轨迹数据集进行筛选和提取后，从 1 476 个车辆 id 中获得 143 组跟驰样本数据，涉及 8 个车道中的 253 个车辆 id。

2.2　跟驰模型选择与参数标定

国内外驾驶人无论在微观驾驶行为，还是在宏观交通流特性上都存在显著差异[28,29]。Zhang 等[30]和王雪松等[31]分别利用上海快速路和高速公路环境下的自然驾驶数据，基于目前公认较好的 IDM 模型及各个主流交通流仿真软件中最常用的 3 类模型（VISIIM 所采用的 Wiedemann 模型、TransModeler 所采用的 GHR 模型、AIMSUN 所采用的 Gipps 模型）进行参数标定及结果评价，结果均表明，IDM 模型与实际运行情况具有最小的误差，在仿真上与国内驾驶人在高速行驶环境下的跟驰行为契合度最高。由于本文所选择的实际道路场景来源于国内的快速路环境，因此，本文选择 IDM 模型作为后续研究的模型。

IDM 模型最早由 Treiber 等[20]在 2000 年提出，该模型将车辆跟驰运动类比为在多种社会力作用下产生的加速度，包含驱动力和阻力。驱动力源于驾驶者追求期望速度的心理需求，阻力源于前导车辆运动对跟驰车辆构成的约束。模型表达式如下：

$$a_i(t)=a_{\max}\left[1-\left(\frac{v_i(t)}{v_f}\right)^{\delta}-\left(\frac{s_i^*(t)}{s_i(t)}\right)^2\right] \tag{1}$$

$$s_i^*(t)=s_0+s_1\sqrt{\frac{v_i(t)}{v_f}}+T_i v_i(t)+\frac{v_i(t)[v_i(t)-v_{i-1}(t)]}{2\sqrt{a_{\max}b_{comf}}} \tag{2}$$

式中：$a_i(t)$为车辆 i 在 t 时刻跟驰车辆的加速度；$a_{\max}$为最大加速度；b_{comf}为舒适减速度的绝对值；$v_i(t)$为车辆 i 在 t 时刻跟驰车辆的速度；$s_i(t)$为车辆 i 在 t 时刻跟驰车辆与前导车辆的间距；$v_{i-1}(t)$为车辆 $i-1$ 在 t 时刻前导车辆的速度；v_f为期望速度；$s_i^*(t)$为 t 时刻跟驰车辆 i 与前导车辆 $i-1$ 的期望间距；s_0为静止安全间距；δ为加速度系数（一般取为 4）；T_i为车辆 i 的安全跟驰时距；s_1为系数（一般取为 0）。在所有变量中，s_0、T_i、$a_{\max}$、b_{comf}、v_f为本文待标定参数。

在确定跟驰模型结构的基础上，本文首先根据前导车辆时空轨迹数据，由 IDM 模型仿真后得出跟驰车辆的轨迹；其次，比较仿真出的跟驰车辆轨迹与实际跟驰车辆轨迹的误差，再次寻找使误差指标最小化的模型参数，即为标定得到的该模型的最优参数。跟驰模型参数的标定过程主要有以下 3 个关键组成部分。

(1)性能指标

跟驰模型参数标定常用的性能指标主要有跟驰车辆加速度、跟驰车辆速度、跟驰间距、跟驰车辆位置等。Punzo等[32]通过仿真实验发现,考虑车头间距的性能指标可以获得最小的仿真误差。本文受此启发,为更加精确标定参数,同时采用了跟驰间距和跟驰车辆速度这两个性能指标用于构造拟合优度函数。

(2)拟合优度函数

拟合优度函数用于衡量性能指标的每时刻仿真值与每时刻实际值之间的误差的累加结果,也称为此优化问题的目标函数,常用的拟合优度函数主要有平均绝对误差(Mean absolute error, MAE)[33]、均方根误差(Root mean square error, RMSE)[34]、均方根百分比误差(Root mean square percentage error, RMSPE)[35]、Thiel′s U。由于RMSPE既考虑了相对误差及比重,又允许采取不同量纲的性能指标确定总体拟合优度函数,故本文选取RMSPE作为拟合优度函数来比较IDM模型仿真结果与实际轨迹数据之间的误差。拟合优度函数如下所示:

$$f_{\mathrm{obj}}=s_{\mathrm{RMSPE}}+v_{\mathrm{RMSPE}}=\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\frac{s_i^{\mathrm{sim}}-s_i^{\mathrm{obs}}}{s_i^{\mathrm{obs}}}\right)^2}+\sqrt{\frac{1}{N}\sum_{i=1}^{N}\left(\frac{v_i^{\mathrm{sim}}-v_i^{\mathrm{obs}}}{v_i^{\mathrm{obs}}}\right)^2} \tag{3}$$

式中:f_{obj}为最小化拟合优度函数;s_{RMSPE}和v_{RMSPE}分别为跟驰间距和跟驰车辆速度的均方根百分比误差;N为某跟驰样本中包含的时间帧数;s_i^{sim}和s_i^{obs}分别为该跟驰样本第i个时刻仿真和实际的跟驰间距;v_i^{sim}和v_i^{obs}分别为该跟驰样本第i时刻仿真和实际的跟驰车辆速度。

(3)优化算法

在解决模型参数标定这类优化问题时,所选择的优化算法应有强大的全局搜索能力,从而避免陷入局部最优,导致参数标定的结果与实际相差较大。为满足上述要求,本文选择粒子群算法作为求解时的优化算法,该算法是一种启发式算法,因受到鸟群觅食行为的启发而提出,利用群体中的个体对信息的共享,使整个群体的运动在问题求解空间中产生从无序到有序的演化过程,从而获得问题的最优解。

本文利用Matlab编写粒子群算法进行优化求解,其中所需参数的设置如表3所示,算法的流程如图3所示。其中,由于启发式算法具有一定随机性,对于本文第2部分提取的143组跟驰样本数据,每组数据的参数标定过程重复10次,取目标函数值最小的一次为最终结果。根据文献[36],对于快速路上的车辆时空轨迹数据进行IDM模型参数标定时,各个参数取值范围如表4所示。

表3 粒子群优化算法主要参数设置

Table 3 Particle swarm optimization algorithm main parameter settings

参数符号	描述	取值
SwarmSize	种群数量	50 (一般为变量个数10倍)
MaxIterations	最大迭代次数	1 000
C1	个体学习因子	2
C2	社会学习因子	2
w	惯性权重	0.9
vmax	粒子最大速度	1.2
lb	待求解变量的下界	见表4
ub	待求解变量的上界	见表4

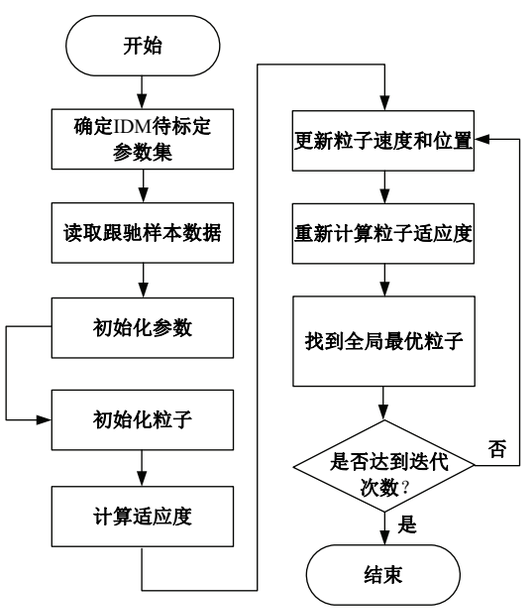


图3 基于粒子群算法的参数标定流程

Fig. 3 Parameter calibration process based on particle swarm optimization algorithm

表4 IDM模型待标定参数的取值范围

Table 4 Range of values of the parameters to be calibrated for the IDM model

参数符号	描述	单位	标定取值
s_0	静止安全距离	m	[0.2,2.0]
T	安全时间间隔	s	[0.8,2.0]
$a_{\max}$	最大加速度	m/s^2	[0.5,4.0]
b_{comf}	舒适减速度	m/s^2	[0.5,4.0]
v_{f}	期望速度	km/h	[60,80]

经过上述参数标定过程，143组跟驰样本数据的143组IDM参数标定结果的分布如图4所示，可以看到在目标函数考虑车头间距和后车速度的双性能指标下的RMSPE之和基本在0.1以下，且143组样本的双指标RMSPE之和的平均值为0.045 3，说明标定的参数总体精确度达到了95.47%。对143组跟驰样本数据进行参数标定后的均值和标准差计算如表5所示。

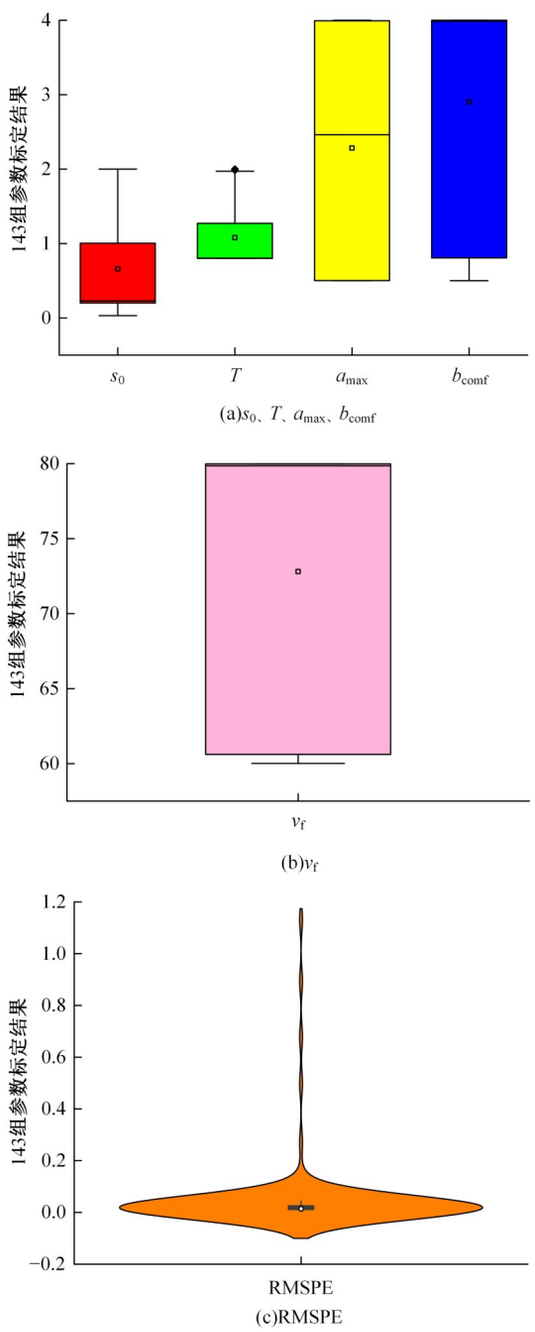


图4　143组跟驰样本的参数标定结果

Fig. 4　Parameter calibration results for 143 sets of car-following samples

表5　143组跟驰样本参数标定的均值和标准差

Table 5　Means and standard deviations of parameter calibrations for 143 sets of car-following sample

参数	静止安全距离 s_0/m	安全时间间隔 T/s	最大加速度 a_{max}/(m·s^{-2})	舒适减速度 b_{comf}/(m·s^{-2})	期望速度 v_f/(km·h^{-1})
均值	0.660 7	1.078 5	2.283 5	2.904 7	72.807 5
标准差	0.698 4	0.443 3	1.538 0	1.537 3	8.701 5

3　基于主成分分析的IDM模型参数重要度识别

在对基于IDM模型对跟驰风格进行分类时，如果考虑所有参数进行驾驶行为的特性分析，便会保留所有驾驶行为信息，但是各个参数之间通常存在一定相关性，例如同一类驾驶人的期望速度与最大加速度通常成正比，全面地对参数进行分析可能会使包含的信息冗余，并且不同实际场景下模型参数的重要程度也不一定相同。因此，直接使用所有模型参数对驾驶行为风格分析会影响结论的可靠性。采用主成分分析(Principal component analysis，PCA)方法可以最大程度囊括变量的信息，减少数据丢失，同时有效减小特征变量的维度。根据本文143组跟驰样本数据的参数标定结果构成143×5的初始矩阵，计算得到第1～5主成分的贡献率和累计贡献率如图5所示(彩图参见电子版，后文同)。

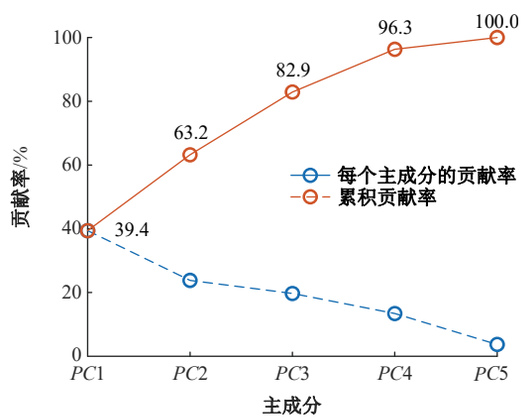


图5　主成分的贡献率和累计贡献率

Fig. 5　Contribution and cumulative contribution of principal components

主成分的提取要求为累计贡献率大于80%，前3个主成分的累计贡献率已经达到82.9%，可包含原始IDM模型参数特征的绝大部分信息，因此每个跟驰样本数据的IDM模型参数都可以用3个新主成分表征。根据计算结果，所提取3个新

的主成分计算公式如下所示:

$$\begin{cases} PC1 = -0.6554s_0 - 0.6588T - 0.1782a_{\max} + \\ \qquad 0.0257b_{\text{comf}} + 0.3224v_{\text{f}} \\ PC2 = -0.0954s_0 - 0.0701T + 0.6811a_{\max} - \\ \qquad 0.7161b_{\text{comf}} + 0.0966v_{\text{f}} \\ PC3 = -0.1179s_0 + 0.1742T - 0.3932a_{\max} - \\ \qquad 0.4459b_{\text{comf}} - 0.7762v_{\text{f}} \end{cases} \tag{4}$$

在得到3个主成分变量之后,通过计算其与原始IDM模型各参数之间的相关系数(即因子载荷系数,如图6所示),便可得知$PC1$、$PC2$、$PC3$与原始IDM模型各参数的关系强弱。

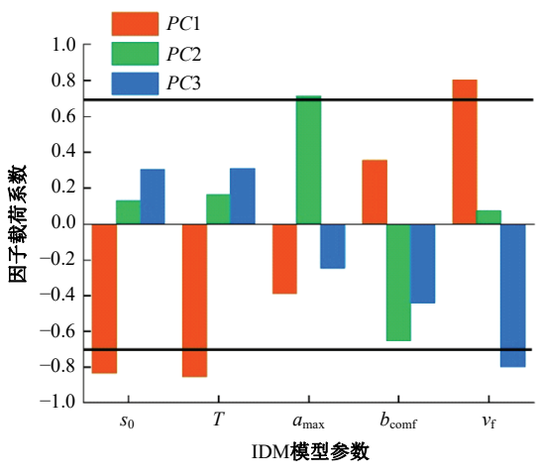


图6 主成分与原模型参数的因子载荷系数

Fig. 6 Factor loading coefficients of principal components and original model parameters

与$PC1$的因子载荷系数绝对值大于0.7的原始参数(变量)为跟驰行为的主要关键属性;与$PC2$、$PC3$的因子载荷系数绝对值大于0.7的原始参数(变量)为跟驰行为的次要关键属性[37]。由图6可以看出,期望速度v_{f}、静止安全间距s_0、安全时间间隔T与PC1的因子载荷系数绝对值大于0.7;$a_{\max}$与PC2的因子载荷系数绝对值大于0.7。由此可以得出结论:本文所涉及的实际场景下,IDM模型标定参数中,期望速度v_{f}、静止安全间距s_0、安全时间间隔T为主要属性,最大加速度$a_{\max}$为次要属性,该结论可为后文跟驰行为聚类划分提供理论基础。

4 基于K-means算法的跟驰行为样本聚类及跟驰行为风格划分

经过主成分分析后,原始参数标定的数据可以转化为不同线性相关的新变量,将提取出的新变量作为本文的聚类对象。在众多聚类算法中,K-means++算法是一种简单、高效的聚类算法,也是K-means算法的改进版,其基本思想是通过最小化每个簇内样本与该簇质心的距离之和,使数据对象在各个簇中尽量相似,而不同簇之间尽量不同。此外,K-means++算法改善了"K-means算法对初始聚类中心敏感"这一缺陷,可提高聚类结果的质量和稳定性。因此,本文采用K-means++算法对第3节所提取的主成分进行分类。K-means++算法的步骤如下所示:

步骤1 随机选取一个样本作为首个聚类中心。

步骤2 计算每个样本与步骤1所确定的聚类中心的最短距离,该值越大则被选为聚类中心的概率越大,然后采取轮盘法选出下一个聚类中心。

步骤3 重复步骤2,直到选择出k个聚类中心,再继续使用标准K-means算法。

标准K-means算法的流程如图7所示。

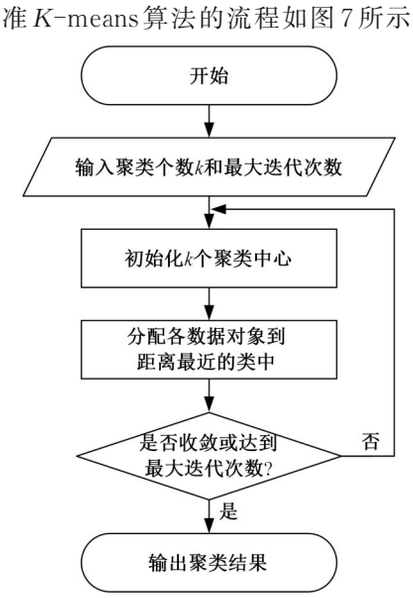


图7 标准K-means算法的流程

Fig. 7 Flow of the standard K-means algorithm

K-means++算法重点在于提前确定合适的聚类数量,即k值。目前,确定k值的方法主要为手肘法,该方法的思路是:将聚类的数量k从1开始取值到10,每次取值的步长为1,计算每个k取值下最终结果的误差平方总和(Sum of square errors,SSE),计算公式如下:

$$\text{SSE} = \sum_{i=1}^{k} \sum_{p \in C_i} |p - m_i|^2 \tag{5}$$

式中:C_i为第i个簇;p为C_i中的样本点;m_i为C_i

的质心（C_i中所有样本的均值）。

随着聚类数量k的逐渐增大，每个簇内的对象相似度也逐渐增大，SSE会逐渐减小。当k小于后来所确定的最佳簇数时，k的逐渐增大将极大增加每个簇的聚集度，SSE将大幅降低。但是，当k达到最佳簇数时再继续增大，SSE的降低趋势将变得缓慢并逐渐趋于平稳。上述过程导致SSE与k之间的折线关系图呈人体手肘的形状，与该手肘处相对应的k值即为认定的最佳数据簇数。

本文以第3节降维后的数据$PC1$、$PC2$、$PC3$为聚类样本数据，以样本距离作为聚类依据，对样本进行聚类。聚类的k值与SSE的手肘图如图8所示。由图8可以看出，本文所提取的跟驰样本数据最佳聚类数量为3，即当k=3时，聚类效果最好，因此后续研究中应当将所提取的第1、第2、第3主成分变量聚为3类，再依次对各类下的原模型参数进行特征分析。

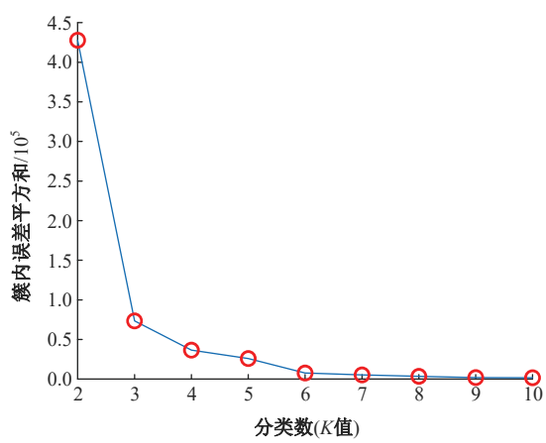


图8　分类数量的手肘图

Fig. 8　Elbow charts for categorized quantities

采用K-means++算法进行聚类分析后，得到143组跟驰样本数据3种聚类效果的三维可视化如图9所示，其中，聚类1共66个，聚类2共31个，聚类3共46个。同时，聚类后各类样本的轮廓系数如图10所示，可以看到各个样本的轮廓系数绝大多数位于0.6～0.8之间（轮廓系数越接近1越理想），因此保证聚类结果的一定有效性。由于主成分变量$PC1$、$PC2$、$PC3$均为原IDM模型所标定参数s_0、T、a_{max}、b_{comf}、v_f的线性组合，因此根据$PC1$、$PC2$、$PC3$的聚类效果便可以分析得到每一种聚类下的各参数分布特征。

为探究各个聚类中模型参数的具体分布情况，可以用常见的概率密度函数拟合各个聚类中

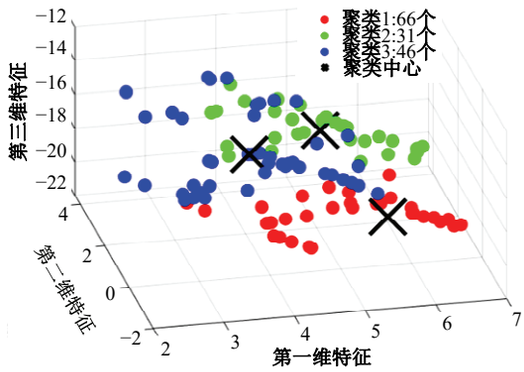


图9　143个跟驰样本数据聚类结果的空间可视化

Fig. 9　Spatial visualization of clustering results for 143 car-following sample data

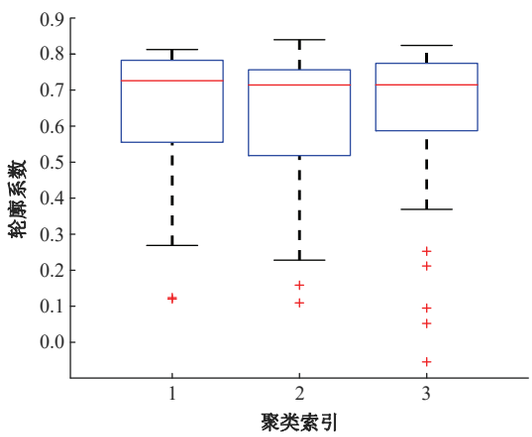


图10　聚类后各类样本的轮廓系数

Fig. 10　Profile coefficients for each sample category after clustering

原始模型参数的分布情况。根据实际各类参数的分布情况和拟合状况，本文最终采用的概率密度函数有正态分布、对数正态分布和指数分布。具体函数如表6所示。

表6 本文所采用的概率密度函数

Table 6　Probability density function used in this paper

概率密度函数	表达式	参数
正态分布	$f_1(x;u,\sigma)=\frac{1}{\sqrt{2\pi}\,\sigma}e^{-\frac{(x-u)^2}{2\sigma^2}}$	u,σ
对数正态分布	$f_2(x;u,\sigma)=\frac{1}{x\sqrt{2\pi}\,\sigma}e^{-\frac{(\ln x-u)^2}{2\sigma^2}}$	u,σ
指数分布	$f_3(x;\lambda)=\lambda e^{-\lambda x},x>0$	λ

通过频率分布直方图进行曲线拟合，3种聚类下的原IDM模型的5个标定参数分布分别如图11、图12、图13所示，其中拟合精度R^2表征了拟合的优劣程度，可以看出，本文拟合的概率密度函数曲线R^2均在0.8以上，拟合精度较高，提高了后文对参数分布特征分析所得结论的可靠性。

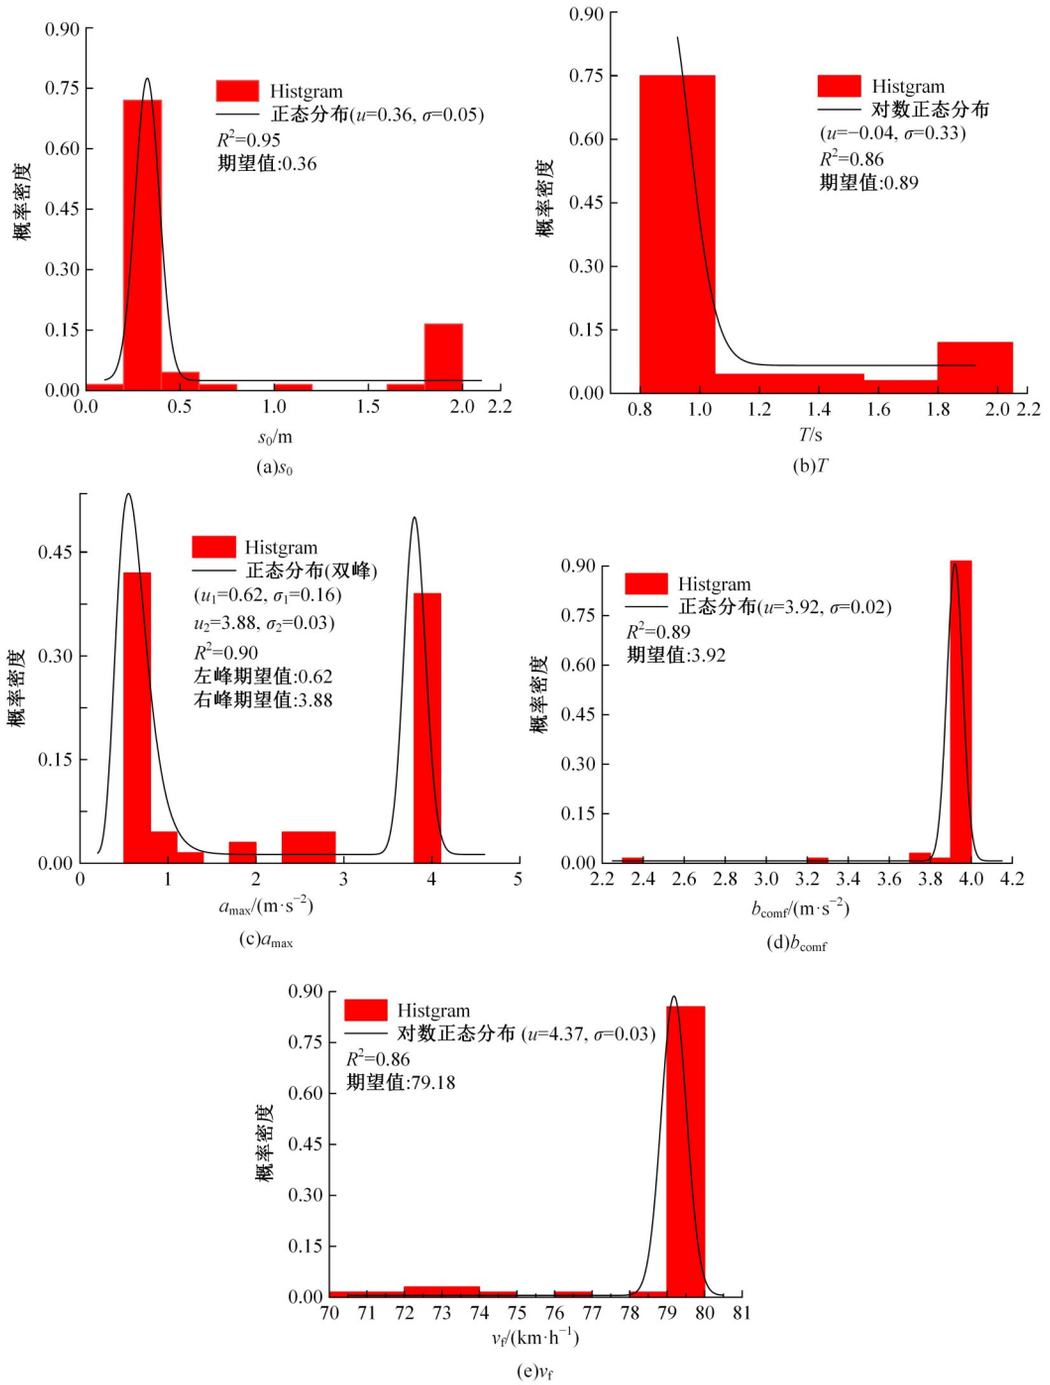


图11 第一类跟驰样本数据的IDM模型参数分布

Fig. 11 Distribution of IDM model parameters for the first type of car-following sample data

在对本文第4节各个聚类参数进行分析时,如果事先未知图11~图13中所包含的5个参数的重要度顺序,那么在基于IDM模型进行跟驰行为风格划分时,对于现有5个标定参数的分布特点需要全面地综合分析,即同等重要度分析和判断。初步对比跟驰样本聚类1、聚类2、聚类3的各个参数期望值及其相对比较结果,如表7所示,对于两两比较的跟驰样本而言,若其中一类比另一类在跟驰行为上更为激进,那么该类的静止安全间距s_0和安全时间间隔T的期望值应一致明显小于另一类(或无明显差别),而最大加速度a_{max}、舒适减速度b_{comf}和期望速度v_f应一致明显大于等于另一类(或无明显差别),在这种各个参数同等重要度比较原则下,表7中3个聚类之间的两两比较显然造成了一定的矛盾,不便于从相对激进或保守的角度对各个聚类跟驰样本做进一步跟驰行为风格划分。

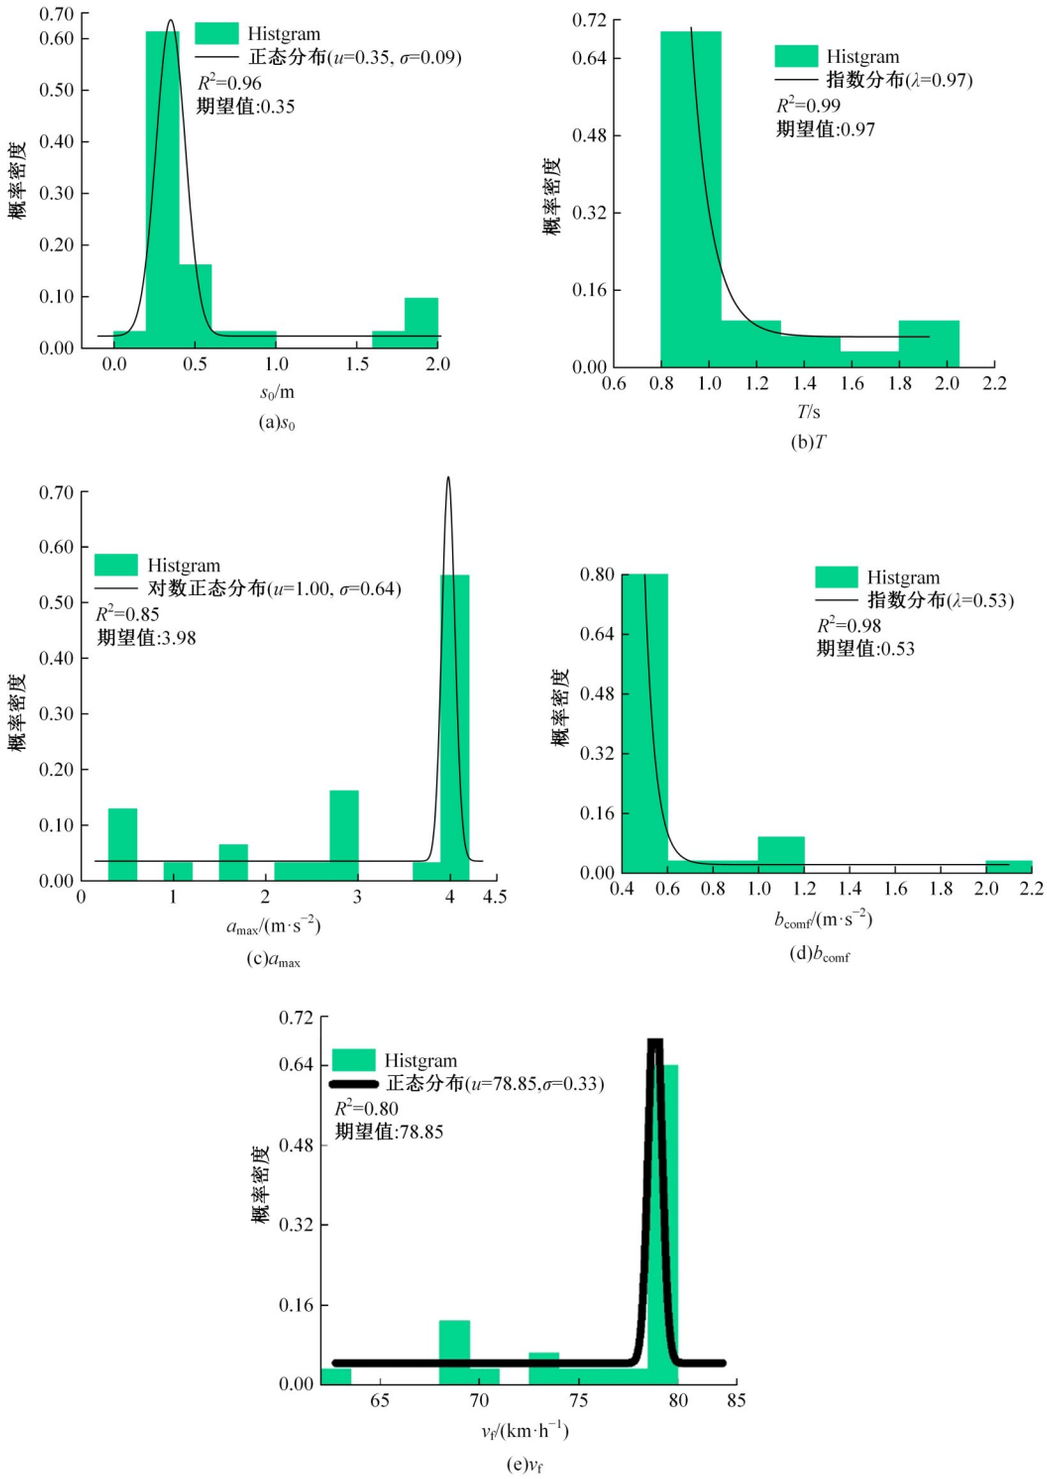


图 12　第二类跟驰样本数据的 IDM 模型参数分布

Fig. 12　Distribution of IDM model parameters for the second type of car-following sample data

因此，根据第 3 节的结论，本文主要依据期望速度 v_f、静止安全间距 s_0、安全时间间隔 T 分析 3 种聚类的跟驰行为特性，其次再考虑最大加速度 a_{max}，分析过程如下。

观察图 11 和图 12 可以得知：聚类 1 与聚类 2 相比，在主要属性期望速度 v_f、静止安全间距 s_0、安全时间间隔 T 的期望值上无明显差别。从次要属性最大加速度 a_{max} 来看，聚类 1 的 a_{max} 呈现双峰正态分布（u_1=0.62，u_2=3.88），说明聚类 1 中 a_{max} 一部分集中在 0.62 m/s² 左右，另一部分集中在 3.88 m/s² 左右，而聚类 2 的 a_{max} 只是呈现单正态分布，且期望值为 3.98 m/s²，因此总体上聚类 2

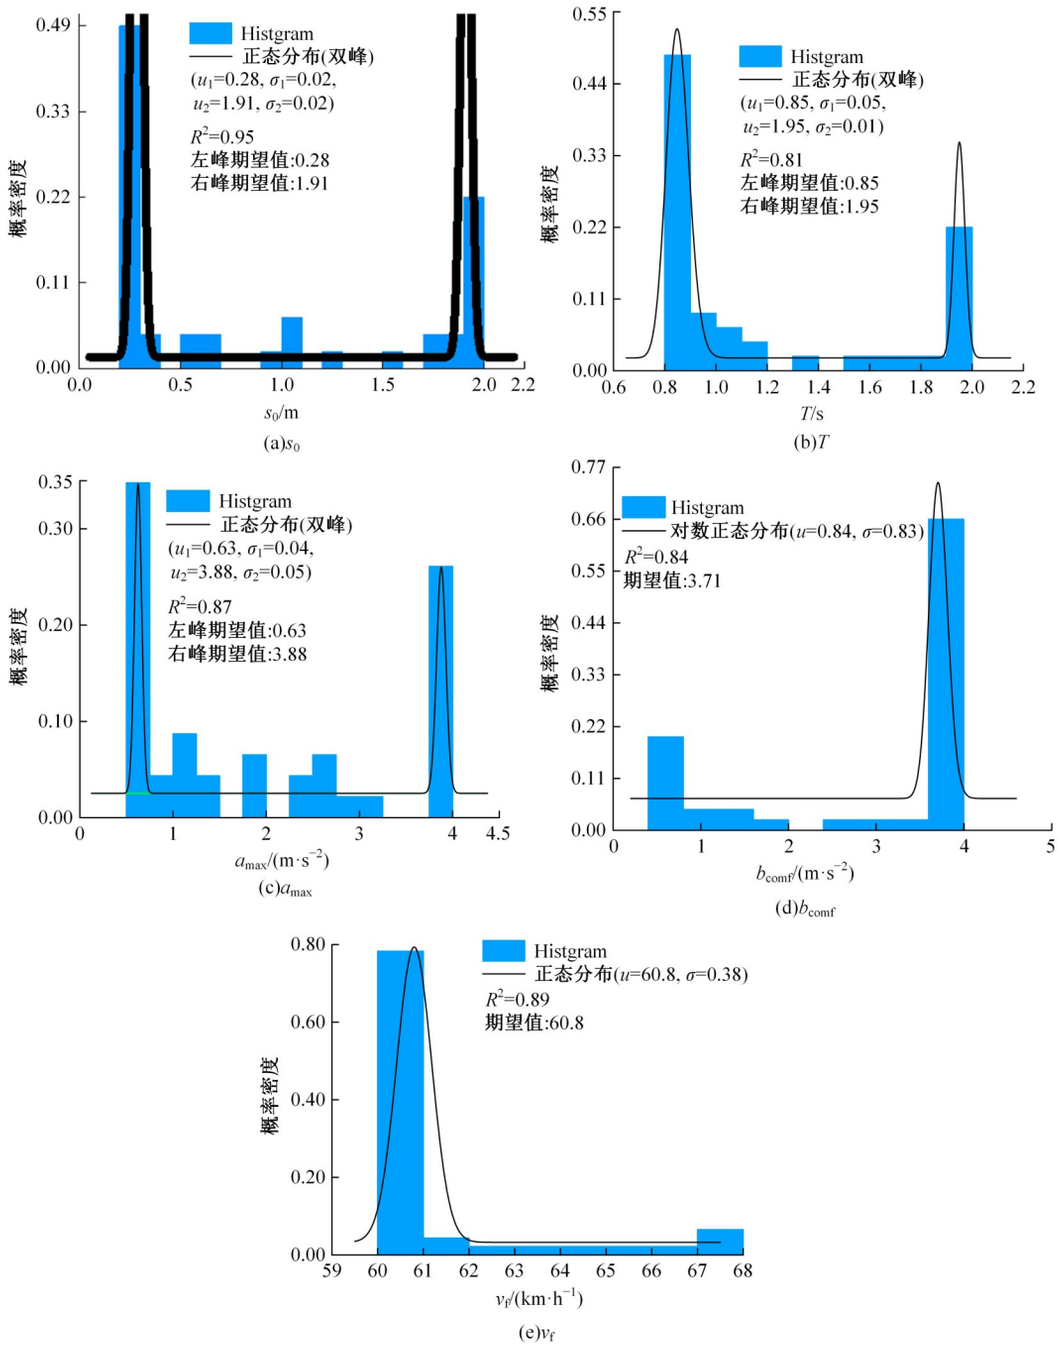


图13 第三类跟驰样本数据的IDM模型参数分布

Fig. 13 Distribution of IDM model parameters for the third type of car-following sample data

中a_{max}比聚类1偏大,即在聚类2中,车辆在跟驰行为上整体偏好更大的加速度,由此说明聚类2的跟驰风格比聚类1更为激进。

同时观察图11~图13可以得知:在主要属性静止安全间距s_0、安全时间间隔T的期望值上,聚类3均呈现双峰正态分布(s_0:u_1=0.28,u_2=1.91,T:u_1=0.85,u_2=1.95),而这两个参数聚类1和聚类2中均呈现单峰正态分布,在聚类3中整体分布偏大,即聚类3中的车辆在跟驰行为上整体偏好更大的静止安全间距和安全时间间隔。此外,聚类3中车辆期望速度v_f的期望值为60.80 km/h,远小于聚类1和聚类3中车辆期望速度v_f的期望值(聚类1中v_f的期望值为79.18 km/h,聚类2中v_f的期望值为78.85 km/h),即聚类3中的车辆在跟驰行为上整体偏好更小的期望速度。因此,聚类3所代表的跟驰风格发生交通事故的可能性更低,由此说明聚类3的跟驰风格比聚类1、聚类2更为保守。

综合上述分析，在跟驰行为风格划分上，聚类2划分为激进型跟驰风格，聚类1划分为中庸型跟驰风格，聚类3划分为保守型跟驰风格。结合图11、图12、图13，整理出不同跟驰行为风格下的IDM模型参数表征如表8所示，以清晰量化3类跟驰行为风格的参数差异。

表7 不同跟驰行为风格的IDM参数表征

Table 7　Characterization of IDM parameters for different car-following behavior styles

跟驰行为风格划分	IDM模型参数	概率分布类型				
		正态分布		对数正态分布		指数分布
		u	σ	u	σ	λ
激进型	s_0/m	0.35	0.09	—	—	—
	T/s	—	—	—	—	0.97
	a_{max}/(m·s^{-2})	—	—	1.00	0.64	—
	b_{comf}/(m·s^{-2})	—	—	—	—	0.53
	v_f/(km·h^{-1})	78.85	0.33	—	—	—
中庸型	s_0/m	0.36	0.05	—	—	—
	T/s	—	—	−0.04	0.33	—
	a_{max}/(m·s^{-2})	$u_1=0.62$ $u_2=3.88$	$\sigma_1=0.16$ $\sigma_2=0.03$	—	—	—
	b_{comf}/(m·s^{-2})	3.92	0.02	—	—	—
	v_f/(km·h^{-1})	—	—	4.37	0.03	—
保守型	s_0/m	$u_1=0.28$ $u_2=1.91$	$\sigma_1=0.02$ $\sigma_2=0.02$	—	—	—
	T/s	$u_1=0.85$ $u_2=1.95$	$\sigma_1=0.05$ $\sigma_2=0.01$	—	—	—
	a_{max}/(m·s^{-2})	$u_1=0.63$ $u_2=3.88$	$\sigma_1=0.04$ $\sigma_2=0.05$	—	—	—
	b_{comf}/(m·s^{-2})	—	—	0.84	0.83	—
	v_f/(km·h^{-1})	60.80	0.23	—	—	—

表8 聚类1、聚类2、聚类3的各个参数期望值及其相对比较结果

Table 8　Expected values of each parameter of cluster 1, cluster 2, cluster 3 and their relative comparison results

参数	聚类1和聚类2	聚类1和聚类3	聚类2和聚类3
s_0/m	无明显差别(0.35和0.36)	聚类3相对较大，呈双峰正态分布[0.35和(0.28, 1.91)]	聚类3相对较大，呈双峰正态分布[0.36和(0.28, 1.91)]
T/m	无明显差别(0.97和0.89)	聚类3相对较大，呈双峰正态分布)[0.97和(0.85, 1.95)]	聚类3相对较大，呈双峰正态分布[0.89和(0.85, 1.95)]
a_{max}/(m·s^{-2})	聚类1总体相对较小，呈双峰正态分布[(0.62,3.88)和3.98]	无明显差别[(0.62, 3.88)和(0.63, 3.88)]	聚类3相对较小，呈双峰正态分布[3.98和(0.63, 3.88)]
b_{comf}/(m·s^{-2})	聚类1相对较大(3.92和0.53)	无明显差别(3.92和3.71)	聚类3相对较大，呈双峰正态分布(0.53和3.71)
v_f/(km·h^{-1})	无明显差别(79.18和78.85)	聚类3相对较小(79.18和60.8)	聚类3相对较小(78.85和60.8)

5　仿真分析

5.1　路段仿真模型构建

为进一步探究本文所划分和定义的3种跟驰行为风格的合理性及其对交通系统的影响，本部分采用SUMO仿真软件，根据车辆轨迹数据采集地点所在的南京市浦口大道路段建立了如图14所示的SUMO路段仿真模型，其中，图中的数字表示所调查的该方向上的早高峰交通需求量(与车辆轨迹数据采集时段相同)。两个方向的主路均为4车道，长度均为2 200 m，车道宽度均为3.75 m，其右侧各有2个入口匝道和2个出口匝道(其中一个暂时封闭，流量为0)，在汇入区和汇出区均存在辅助车道。在限速方面，主路最大限速均为80 km/h，匝道限速为40 km/h。同时为提高仿真的真实性，在入口匝道的加速车道上设置了禁止外车道向右换道，在出口匝道的减速车道上设置了禁止该车辆向左换道。

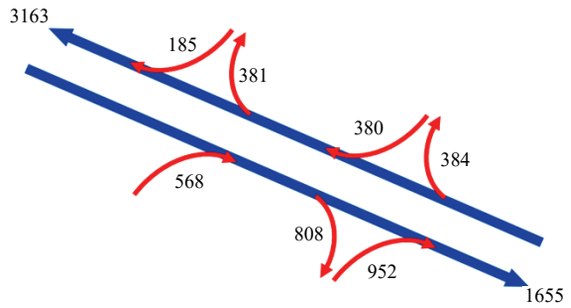


图14 路段仿真模型示意图

Fig. 14 Schematic diagram of roadway simulation model

在车辆类型输入上,由图11~图13提供的信息,依据各类跟驰行为风格的5个参数期望值定义了3种带有不同IDM模型参数的车辆类型,即激进型驾驶员、中庸型驾驶员和保守型驾驶员。在车辆组成比例上,分别设置了激进型驾驶员占交通流主导(比例分别为60%、70%、80%、90%、100%,其他两种风格驾驶员比例之和分别为40%、30%、20%、10%、0%)、中庸型驾驶员占交通流主导(比例分别为60%、70%、80%、90%、100%,其他两种风格驾驶员比例之和分别为40%、30%、20%、10%、0%)、保守型驾驶员占交通流主导(比例分别为60%、70%、80%、90%、100%,其他两种风格驾驶员比例之和分别为40%、30%、20%、10%、0%)的流量输入,以此探究本文所划分的驾驶员跟驰异质性及其比例对交通系统的影响。

5.2 交通系统影响分析

在交通系统安全性分析上,选用碰撞时间(Time to collision,TTC)作为冲突分析指标,一般认为0 s<TTC≤1.5 s为严重冲突,1.5 s<TTC≤3 s为一般冲突,TTC>3 s为无冲突[38],因此本文选择每次仿真过程中"TTC≤3 s的次数"作为评价指标,仿真输出的具体结果如图15所示。

由图15可以看出,在早高峰场景下,由于带有相对较大的跟驰期望速度、最大加速度和较小的安全跟驰时距,当激进型驾驶员占比较高时,仿真过程中TTC≤3 s的次数最多,交通系统安全性最低;反之,由于带有相对较小的跟驰期望速度、最大加速度和较大的安全跟驰时距,当保守型驾驶员占比较高时,仿真过程中TTC≤3 s的次数最少,交通系统安全性最高;当中庸型驾驶员占比较高时,交通系统安全性处于二者中间水平。

在交通系统排放性分析上,汽车尾气污染物

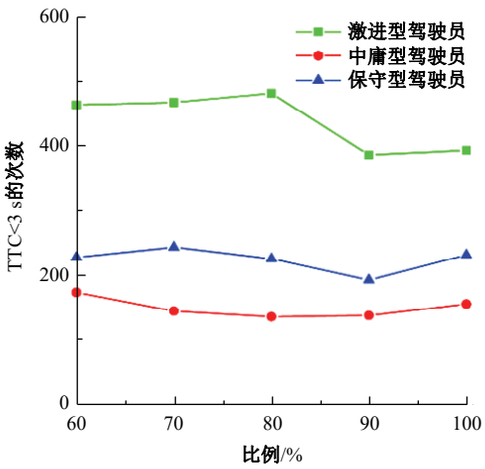


图15 不同比例的异质驾驶员条件下的TTC≤3 s的次数

Fig. 15 Number of times TTC≤3 s for different ratios of heterogeneous driver conditions

排放主要在加速和减速时产生,且常用比功率(Vehicle specific power,VSP)表征车辆的瞬态排放状态,同时研究表明众多污染物的排放率均与VSP呈正相关关系[39]。SUMO仿真可输出所有车辆的瞬时速度和瞬时加速度,代入式(6)便可计算车辆VSP。因此,本文以仿真时间内的车辆平均VSP作为排放评价指标,平均VSP越高,代表排放量越大。仿真输出的具体结果如图16所示。

$$\mathrm{VSP}=v(1.1a+0.132)+0.000\,302v^3 \quad (6)$$

式中:v为车辆速度,m/s;a为车辆加速度,m/s^2。

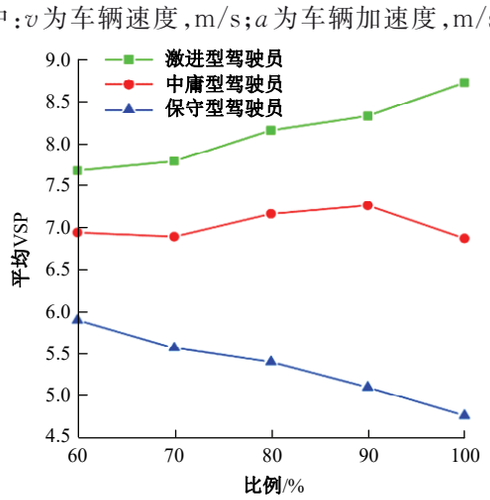


图16 不同比例的异质驾驶员条件下的平均VSP

Fig. 16 Mean VSP for different ratios of heterogeneous driver conditions

由图16可以看出:首先,当激进型驾驶员占比较高时,交通系统的平均VSP最高,这种趋势在其比例不断增加时体现得越来越明显;其次,当中庸型驾驶员占比较高时,其本身最大加速度属性相对于激进型驾驶员较小[(0.62,3.88)和

3.98]，但二者的期望速度属性无明显差别(79.18和78.85)，由于式(6)表明了速度对VSP影响较大，因此使得该情况下的平均VSP处于中等水平，但随着中庸型驾驶员比例的增加，平均VSP并无明显变化趋势；最后，当保守型驾驶员占比较高时，由于期望速度属性远低于其他两者(60.8和79.18，60.18和78.85)，因此该类情况下，平均VSP比其他两种驾驶员占主导时相对较小，而且随着保守型驾驶员比例逐渐增大，平均VSP逐渐降低，即交通系统的排放量越来越小。

6　结　论

(1)本文在拥有实际车辆时空轨迹数据的前提下，基于“参数标定-参数重要度识别-聚类分析”，构建了一整套车辆时空轨迹数据下的基于规则类跟驰模型(以IDM为例)的跟驰行为风格划分方法，该方法主要优势在于：在研究实测场景下的跟驰行为风格分类时，可有效识别所依赖模型的参数重要度，减少了因众多参数间相关性导致的信息冗余，也便于在跟驰样本数据分类后，依据参数重要度顺序进行量化分析。除了IDM模型以外，该方法也可适用于FVD、GHR、Gipps、Wiedemann(如Wiedemann99模型中，初始待标定和分析的参数多达10个)等规则类跟驰模型下的跟驰行为风格分类工作。在仿真分析部分，本文进一步探究了所用驾驶行为划分方法的可解释性及其对交通系统的影响，研究结果有助于更准确刻画驾驶人跟驰行为异质性，对进一步提高驾驶人仿真精度和设计符合人类特征的自动驾驶策略具有借鉴意义。

(2)本文在驾驶行为风格划分时仅依赖于车辆的跟驰行为，虽然跟驰行为是驾驶行为中的主体部分，但换道行为同样是影响交通流特性的重要因素，且过程更加复杂，后续在驾驶行为划分的研究上有必要结合换道行为特征进行驾驶人异质性分析。同时，在本文涉及的实际道路场景中，有97.81%的交通参与者为小型车辆，因此忽略了车辆类型这一因素，未来研究中有必要纳入车辆类型因素进行探索。

(3)聚类算法的聚类效果是本文驾驶风格划分前的关键工作，本文采用的K-means++算法作为K-means算法的改进版，通过改进初始聚类中心的选择策略保证了分类结果的质量和稳定性，在后续研究中可将多个聚类算法用于其他开源数据集的驾驶风格分类研究，并结合数据采集的实际状况加以比较，从而探究各个聚类算法对驾驶风格分类研究的适应性。

参考文献：

[1] Zhu H, Zhu S, Iryo-Asano M, et al. Investigating driver reactions to movements of autonomous vehicle in permitted right turn through driving simulator experiments[J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2022, 89: 385-398.

[2] Elander J, West R, French D. Behavioral correlates of individual differences in road-traffic crash risk: an examination of methods and findings[J]. Psychological Bulletin, 1993, 113(2): 279-294.

[3] Liu X, Hang P, Wang Y, et al. A cooperative decision-making method for CAVs from the perspective of opinion dynamics[J]. Transportation Research Part C: Emerging Technologies, 2026, 182: No. 105412.

[4] 郭景华，何智飞，罗禹贡，等. 人机混驾环境下基于深度学习的车辆切入轨迹预测[J]. 汽车工程，2022，44(2)：153-160，214.
Guo Jing-hua, He Zhi-fei, Luo Yu-gong, et al. Vehicle cut-in trajectory prediction based on deep learning in a human-machine mixed driving environment [J]. Automotive Engineering, 2022, 44(2): 153-160, 214.

[5] Tan C, Zhou N, Wang F, et al. Real-time prediction of vehicle trajectories for proactively identifying risky driving behaviors at high-speed intersections[J]. Transportation Research Record, 2018, 2672(38): 233-244.

[6] Jiao Y J, Wang X S, Hurwitz D, et al. Revision of the driver behavior questionnaire for Chinese drivers′ aberrant driving behaviors using naturalistic driving data[J]. Accident Analysis&Prevention, 2023, 187: No. 107065.

[7] Kedar-Dongarkar G, Das M. Driver classification for optimization of energy usage in a vehicle[J]. Procedia Computer Science, 2012, 1: 388-393.

[8] Ly M V, Martin S, Trivedi M M. Driver classification and driving style recognition using inertial sensors [C]//IEEE. Proceedings of the Intelligent Vehicles Symposium, New York, 2013: 1040-1045.

[9] Lin C C, Jeon S, Peng H, et al. Driving pattern recognition for control of hybrid electric trucks[J]. Vehicle System Dynamics, 2004, 42(1/2): 41-58.

[10] 骆旅舟,谈超鹏,唐克双. 基于电警数据的单点自适应信号控制优化方法[J]. 同济大学学报:自然科学版,2022,50(12):1798-1808.
Luo Lyu-zhou, Tan Chao-peng, Tang Ke-shuang. Adaptive signal control optimization for isolated intersections based on E-police data[J]. Journal of Tongji University(Natural Science), 2022, 50(12): 1798-1808.

[11] 肖雪,李克平,彭博,等. 基于决策-规划迭代框架的智驾车换道行为建模[J]. 吉林大学学报:工学版,2023,53(3):746-757.
Xiao Xue, Li Ke-ping, Peng Bo, et al. Integrated lane-changing model of decision making and motion planning for autonomous vehicles[J]. Journal of Jilin University (Engineering and Technology Edition), 2023, 53(3): 746-757.

[12] Luo L, Wu H, Liu J, et al. A probabilistic approach for queue length estimation using license plate recognition data: considering overtaking in multi-lane scenarios[J]. Transportation Research Part C: Emerging Technologies, 2025, 173: No. 105029.

[13] 张铎,饶红玉,刘佳琦,等. 基于自然驾驶数据的驾驶人跟驰行为内在异质性预测与建模[J]. 交通运输系统工程与信息,2023,23(5):33-44.
Zhang Duo, Rao Hong-yu, Liu Jia-qi, et al. Intra-driver heterogeneity prediction and modeling based on naturalistic driving experiment[J]. Journal of Transportation Systems Engineering and Information Technology, 2023, 23(5): 33-44.

[14] 金辉,李昊天. 基于驾驶风格的前撞预警系统报警策略[J]. 汽车工程,2021,43(3):405-413.
Jin Hui, Li Hao-tian. Alarm strategy for frontal crash warning system based on driving style[J]. Automotive Engineering, 2021, 43(3): 405-413.

[15] Jiang R, Wu Q S, Zhu Z J. Full velocity difference model for a car-following theory[J]. Physical Review E, 2001, 64(1): 7101-7104.

[16] Gazis D C, Herman R, Rothery R W. Nonlinear follow-the-leader models of traffic flow[J]. Operations Research, 1961, 9(4): 545-567.

[17] Gazis D C. The origins of traffic theory[J]. Operations Research, 2002, 50(1): 69-77.

[18] Wiedemann R. Simulation of road traffic in traffic flow[D]. Karlsruhe: University of Karlsruhe, 1974.

[19] Gipps P G. A behavioural car-following model for computer simulation[J]. Transportation Research Part B: Methodological, 1981, 15(2): 105-111.

[20] Treiber M, Hennecke A, Helbing D. Congested traffic states in empirical observations and microscopic simulations[J]. Physical Review E, 2000, 62(2): 1805-1824.

[21] Kim I, Kim T, Sohn K. Identifying driver heterogeneity in car-following based on a random coefficient model[J]. Transportation Research Part C: Emerging Technologies, 2013, 36: 35-44.

[22] Taylor J, Zhou X S, Rouphail N M, et al. Method for investigating intradriver heterogeneity using vehicle trajectory data: a dynamic time warping approach [J]. Transportation Research Part B: Methodological, 2015, 73: 59-80.

[23] Hoogendoorn S P, Hoogendoorn R. Generic calibration framework for joint estimation of car-following models by using microscopic data[J]. Transportation Research Record: Journal of the Transportation Research Board, 2010, 2188(1): 37-45.

[24] Ossen S, Hoogendoorn S P, Gorte B G H. Interdriver differences in car-following: a vehicle trajectory - based study[J]. Transportation Research Record: Journal of the Transportation Research Board, 2006, 1965(1): 121-129.

[25] 金沙沙,龙伟,胡灵犀,等. 多目标检测与跟踪算法在智能交通监控系统中的研究进展[J]. 控制与决策,2023,38(4):890-901.
Jin Sha-sha, Long Wei, Hu Ling-xi, et al. Research progress of detection and multi-object tracking algorithm in intelligent traffic monitoring system[J]. Control and Decision, 2023, 38(4): 890-901.

[26] Zhu M, Wang X, Tarko A. Modeling car-following behavior on urban expressways in Shanghai: a naturalistic driving study[J]. Transportation Research Part C, 2018, 93: 425-445.

[27] 宋东鉴,赵健,朱冰,等. 考虑风险时空分布特征的跟驰工况行车风险预测[J]. 汽车工程,2024,46(5):766-775,753.
Song Dong-jian, Zhao Jian, Zhu Bing, et al. Driving risk prediction under car-following conditions considering risk spatiotemporal distribution characteristics[J] Automotive Engineering, 2024, 46(5): 766-775, 753.

[28] Sun J, Zhao L, Zhang H M. Mechanism of early-onset breakdown at on-ramp bottlenecks on Shanghai, China, expressways[J]. Transportation Research Record: Journal of the Transportation Research Board, 2014, 2421(1): 64-73.

[29] Sun J, Zhang J, Zhang H M. Investigation of the early-onset breakdown phenomenon at urban express-

way bottlenecks in Shanghai[J]. Transportmetrica B: Transport Dynamics, 2014, 2(3): 215-228.

[30] Zhang D, Chen X, Wang J, et al. A comprehensive comparison study of four classical car-following models based on the large-scale naturalistic driving experiment [J]. Simulation Modelling Practice and Theory, 2021, 113: No. 102383.

[31] 王雪松, 孙平, 张晓春, 等. 基于自然驾驶数据的高速公路跟驰模型参数标定[J]. 中国公路学报, 2020, 33(5): 132-142.
Wang Xue-song, Sun Ping, Zhang Xiao-chun, et al. Calibrating car-following models on freeway based on naturalistic driving data[J]. China Journal of Highway and Transport, 2020, 33(5): 132-142.

[32] Punzo V, Simonelli F. Analysis and comparison of microscopic traffic flow models with real traffic microscopic data[J]. Transportation Research Record, 2005, 1934(1): 53-63.

[33] 伉沛喆, 张承志, 吴浩, 等. 基于电警数据的干线自适应协调控制优化方法[J]. 中国公路学报, 2023, 36(10): 251-268.
Kang Pei-zhe, Zhang Cheng-zhi, Wu Hao, et al. Optimization method for adaptive arterial coordinated signal control based on E-police data[J]. China Journal of Highway and Transport, 2023, 36(10): 251-268.

[34] Tang K S, Liu J H, Cao Y M, et al. Enhancing path flow estimation on signalized arterials with a hybrid model: integrating sparse vehicle data and automatic vehicle identification under low coverage[J]. Journal of Transportation Engineering, Part A: Systems, 2025, 151(4): No. 04025010.

[35] 郭景华, 李文昌, 罗禹贡, 等. 基于深度强化学习的驾驶员跟车模型研究[J]. 汽车工程, 2021, 43(4): 571-579.
Guo Jing-hua, Li Wen-chang, Luo Yu-gong, et al. Driver car-following model based on deep reinforcement learning automotive engineering[J] Automotive Engineering, 2021, 43(4): 571-579.

[36] 叶颖俊. 快速路汇入区瓶颈交通流建模仿真与失效机理研究[D]. 上海: 同济大学交通运输工程学院, 2023.
Ye Ying-jun. Traffic flow breakdown at urban expressway merging bottleneck: modeling, simulation and mechanism analysis[D]. Shanghai: College of Transportation Engineering, Tongji University, 2023.

[37] 杨泽. 考虑驾驶行为异质性的微观交通流建模与交通影响分析[D]. 成都: 西南交通大学交通运输与物流学院, 2021.
Yang Ze. Microscopic traffic flow modeling considering heterogeneous driving behaviors and traffic impact analysis[D]. Chengdu: School of Transportation and Logistics, Southwest Jiaotong University, 2021.

[38] 马庆禄, 闫浩, 聂振宇, 等. 匝道合流区智能网联车辆协同控制方法[J]. 吉林大学学报: 工学版, 2024, 54(5): 1332-1346.
Ma Qing-lu, Yan Hao, Nie Zhen-yu, et al. Cooperative control method for intelligent networked vehicles in ramp confluence area[J]. Journal of Jilin University (Engineering and Technology Edition), 2024, 54(5): 1332-1346.

[39] 项俊平, 唐克双, 陶晶晶. 周期与流量对交叉口排放和延误的影响[J]. 同济大学学报: 自然科学版, 2017, 45(11): 1629-1639.
Xiang Jun-ping, Tang Ke-shuang, Tao Jing-jing. Impacts of cycle length and volume on traffic emissions and delay at signalized intersections[J]. Journal of Tongji University(Natural Science), 2017, 45(11): 1629-1639.