

自动驾驶车辆对人工驾驶车辆跟驰行为影响分析

鲁光泉^{1,2}, 谭海天^{1,2}, 张浩^{1,3}

(1. 交通运输部 运输车辆运行安全技术交通行业重点实验室, 北京 100088; 2. 北京航空航天大学 交通科学与工程学院, 北京 102206; 3. 交通运输部 公路科学研究所, 北京 100088)

摘要: 针对自动驾驶车辆(automated vehicle, AV)与人工驾驶车辆(manual vehicle, MV)组成的混行跟驰环境, 基于 Waymo 公开数据集研究混行环境中 AV 前车对 MV 后车跟驰行为的影响。首先, 探究混行环境中期望安全裕度模型和智能驾驶人模型的建模能力和模型参数变化, 研究表明, 混行环境中 MV 跟驰行为的机制没有发生变化, 但是 MV 驾驶人的减速敏感程度更低。其次, 从跟驰安全性、稳定性和环境效应 3 个方面对混行跟驰行为进行进一步分析得到, 混行环境中的 MV 跟驰行为的稳定性和环境效应得到了改善, 但是安全性并没有发生变化。最后, 通过对前车速度波动性进行讨论发现, AV 前车主要是通过降低自身速度波动性, 从而抑制 MV 后车的速度波动性, 改善 MV 后车在稳定性及环境效应方面的表现。

关键词: 交通工程; 跟驰行为特征; 自然驾驶数据; 人工驾驶车辆; 自动驾驶车辆; 混行交通环境

中图分类号: U 491.2 文献标志码: A

Analysis of the impact of automated vehicle on the car-following behavior of manual vehicle

LU Guangquan^{1,2}, TAN Haitian^{1,2}, ZHANG Hao^{1,3}

(1. Key Laboratory of Operation Safety Technology on Transport Vehicles, Ministry of Transport, Beijing 100088, China; 2. School of Transportation Science and Engineering, Beihang University, Beijing 102206, China; 3. Research Institute of Highway, Ministry of Transport, Beijing 100088, China)

Abstract: Aiming at the mixed car-following environment composed of automated vehicles (AV) and manual vehicles (MV), the impact of AV on car-following behavior of MV based on Waymo open dataset was studied. The modeling ability and model parameter changes of the desired safety margin model and the intelligent driver model in the mixed driving environment were explored, and the results showed that the mechanism of car-following behavior of MV in the mixed driving environment did not change, but the MV driver was less sensitive to deceleration. In addition, the MV car-following behavior of the mixed environment in terms of safety, stability and environmental performance was further analyzed, and the results showed that the stability and environmental performance were improved, but the safety did not change. Moreover, the speed volatilities of the leading vehicles were discussed, and

收稿日期: 2023-04-16

基金项目: 运输车辆运行安全技术交通行业重点实验室开放课题(KFKT2017-02); 国家自然科学基金重点资助项目(52131204)

第一作者: 鲁光泉(1974-), 男, 教授。研究方向: 车路协同技术、交通安全分析、驾驶行为建模。E-mail: luggq@buaa.edu.cn

the results showed that the leading vehicles of AV mainly suppressed the speed volatility of the rear vehicles of MV by reducing its own speed volatility, so as to improve the performance of the rear vehicles of MV in terms of stability and environmental performance.

Keywords: *traffic engineering; car-following behavior characteristics; naturalistic driving data; manual vehicle; automated vehicle; mixed traffic environment*

自动驾驶是未来最具潜力的技术之一，能有效保障交通安全，提高驾驶舒适性和节约能源^[1]。但是在短期内，自动驾驶车辆(automated vehicle, AV)并不能完全替代目前交通环境中的人工驾驶车辆(manual vehicle, MV)，做到100%的市场渗透率^[2-3]。在AV和MV共同存在的混行网联交通环境中，AV控制策略可能会对MV行为产生影响，导致MV行为参数发生变化^[4-5]。因此，明确混行网联交通环境中MV行为参数差异以及分布情况是对智能网联交通进行控制和仿真的基础。车辆跟驰是最基础的驾驶行为，目前已有部分研究对AV渗透条件下MV的跟驰行为及AV-MV混合交通流的稳定性和运行特性进行了探索^[6]。

Ye等^[7]使用一个两状态安全-速度模型^[8]和一个自适应巡航控制模型^[9]，构建了一个仿真的混行环境，对混行环境受AV市场渗透率的影响进行了研究，其分析结果表明，AV市场渗透率的增加，能够明显提高MV后车的安全性和稳定性。但是，Sinha等^[10]基于VISSIM交通仿真软件模拟了混行环境中的MV行为，使用van Arem等^[11]提出的车辆跟驰模型作为AV控制策略，其分析结果却表明AV前车并没有显著性改善MV后车的安全性。在这些研究中，通常默认其中的MV车辆的行为特征机理与传统跟驰环境中的保持一致^[12]。但是由于AV跟驰控制策略的差异，真实环境中MV后车的行为与理论研究中的模型假设可能存在差异，这导致该部分的研究结果有待验证^[10]。

考虑到交通仿真实验无法准确反映MV后车真实的跟驰反应，部分研究通过招募驾驶人进行实车实验来进行^[4-5]。Mahdinia等^[5]通过设计实车实验分析AV控制策略对MV后车跟驰行为的影响，运用van Arem等^[11]提出的车辆跟驰模型作为AV控制策略，并考虑了5种不同的跟驰速度场景。分析结果表明，AV前车能够改善MV后车跟驰过程的安全性、稳定性和环境影响方面相关指标。Zhao等^[4]通过设计实车实验分析AV前车的外表类型对MV后车跟驰行为的影响。AV前车的外表类型分为两种：一种是可以基于车辆外表辨

认其为AV，另一种是无法基于车辆外表辨认其为AV。研究发现：当前车为无法基于外表分辨的AV时，MV后车的行为不会发生显著改变；当前车为可以基于外表分辨的AV时，MV后车行为的变化取决于MV后车驾驶人对AV的信任程度。

综上所述，目前研究AV前车对MV后车行为影响的分析结果存在较大差异。其原因可能是由于缺乏实际的混行场景数据，只能通过仿真实验或驾驶实验进行相关研究，而不同研究中AV的控制模型、参数设计、实验场景或相关假设存在差异^[7]。实验设计也无法保障能够全面反映真实的混行驾驶环境。此外，在已有部分研究中直接使用了传统环境中的跟驰模型，并没有讨论这些模型在混行环境中是否仍然适用以及模型参数可能存在的差异^[4-5]。

因此，本文基于Waymo公开数据集从真实的混行环境中提取所需的跟驰案例，探索已有经典跟驰模型在混行环境中对MV跟驰行为的描述能力以及模型参数的差异和分布，此外，借助不同的性能指标评估AV前车对MV后车行为在安全性、稳定性和环境效应3个方面的影响。

1 数据提取


本文使用的数据集为Waymo公开数据集中的感知数据集部分。该数据集是Waymo自动驾驶车辆通过其搭载的高精度传感器(1个中程激光雷达、4个短程激光雷达、5个摄像头)在实际道路上采集的自然驾驶数据。相较于以往的数据集，其在传感器质量和数据集大小等方面都有着较大的提升。该数据集包含1950个自动驾驶的视频片段，每段视频包括20 s的连续驾驶画面，在画面中对汽车、行人、自行车、交通标识这4类要素进行了标识，可以用于驾驶行为以及机器视觉的相关研究。该数据集的采集地点涵盖了美国的菲尼克斯、柯克兰、芒廷维尤、旧金山等地区的市中心和郊区，涉及了各种驾驶条件下的数据。每个数据场景中包含一辆Waymo的AV和周围若干

MV。在该数据集发布之后, Hu 等^[13]通过研究证明, 该数据集拥有比 NGSIM 数据集更高的数据精度, 并从该数据集中提取了 1500 组左右跟驰案例对跟驰过程进行分析, 每个跟驰案例时长约为 20 s, 采样频率为 10 Hz。为了对额外变量进行控制, 本文在 Hu 等^[13]提取的跟驰案例基础上, 进一步引入约束条件对数据进行筛选, 得到所需的 MV 跟驰 MV 场景和 MV 跟驰 AV 场景下的数据, 两个场景分别简称为 MV 场景和 AV 场景。约束条件如下:

a. 车辆类型。后车类型为 MV, 前车类型为 MV 或 AV。

b. 车辆长度。为剔除其他大型车辆带来的干扰, 对前后车辆的长度引入约束

$$3 < L_L < 6 \tag{1}$$
$$3 < L_F < 6 \tag{2}$$



式中, L_L 和 L_F 分别为前后车车辆长度, m。

c. 车头时距。为保证车辆处于跟驰状态, 对案例的最大车头时距引入约束^[14]

$$\max(t_{THW}(t)) < 5 \tag{3}$$

式中, $t_{THW}(t)$ 为车头时距, s。

d. 车辆速度。为排除车辆长时间停车及怠速行驶的非跟驰状态数据的影响, 对前后车的平均速度引入约束:

$$\text{mean}(v_L(t)) > 3 \tag{4}$$
$$\text{mean}(v_F(t)) > 3 \tag{5}$$

式中, $v_L(t)$ 和 $v_F(t)$ 分别为前后车速度, m/s。

通过筛选分别得到 291 个 MV 场景案例和 108 个 AV 场景案例, 每个案例长度约为 20 s, 案例示意图如图 1 所示, 案例的相关特征统计结果如表 1 所示。




图 1 MV 场景和 AV 场景案例示意图

Fig.1 Case diagrams of MV and AV scenarios

表 1 提取案例的统计结果

Tab.1 Statistical results of extracted cases

统计指标	MV场景				AV场景			
	前车		后车		前车		后车	
	速度/(m·s ⁻¹)	加速度/(m·s ⁻²)	速度/(m·s ⁻¹)	加速度/(m·s ⁻²)	速度/(m·s ⁻¹)	加速度/(m·s ⁻²)	速度/(m·s ⁻¹)	加速度/(m·s ⁻²)
均值	12.95	0.07	12.87	0.06	14.27	0.02	14.40	0.02
标准差	6.37	0.57	6.30	0.59	6.45	0.55	6.41	0.54
最小值	0.00	-3.53	1.45	-4.46	0.82	-3.03	2.11	-3.28
最大值	30.76	3.16	32.58	1.50	29.69	2.72	31.84	1.50

2 跟驰行为模型

目前学者们从人因和交通工程两个角度对车

辆跟驰行为进行了大量研究, 构建了一系列的车辆跟驰模型。人因角度方面, Lu 等^[15]通过结合动态风险平衡理论和刺激反应理论构建了期望安全

裕度 (desired safety margin, DSM) 模型, 该模型基于驾驶人感知的安全裕度和期望的安全裕度的差来计算车辆加速度。该模型在计算车辆运动的过程中通过参数设置充分考虑了驾驶人对于加速和减速行为不同的敏感程度, 其模型参数具有较好的可解释性, 并且能够较好地反映驾驶人的行为特征。因此, 本文选择 DSM 模型为代表进行分析。交通工程角度方面, 本文选择了经典的智能驾驶人模型 (intelligent driver model, IDM) 作为代表进行分析。IDM 通过考虑速度与期望速度的比值以及期望车间隙与车间隙的比值来计算车辆加速度, 能够有效描述自由车流以及拥挤车流情况下车辆的跟驰行为^[16]。然而, IDM 只包含少量物理意义明确且易于标定的参数, 目前该模型常被用来作为自动驾驶车辆的跟驰模型。因此, 本文以 DSM 模型和 IDM 为代表, 分析经典跟驰模型对混行环境跟驰行为的描述能力以及模型参数的差异和分布。

2.1 DSM 模型

DSM 模型中车辆加速度通过如下公式进行计算^[15]:

$$\gamma(t) = 1 - \frac{v_F(t)}{S_F(t)} - \frac{v_F^2(t) - v_L^2(t)}{1.5gS_F(t)} \quad (6)$$

$$a_F(t + \tau) = \begin{cases} \alpha_1(\gamma(t) - \gamma_{DH}), & \gamma(t) > \gamma_{DH} \\ \alpha_2(\gamma(t) - \gamma_{DL}), & \gamma(t) < \gamma_{DL} \\ 0, & \text{其他} \end{cases} \quad (7)$$

式中: $v_L(t)$ 和 $v_F(t)$ 分别为前车和后车的速度; $S_F(t)$ 为车辆间隙; g 为重力加速度, 取值为 $9.8 \text{ m} \cdot \text{s}^{-2}$; $\gamma(t)$ 为当前时刻安全裕度; τ 为驾驶人的反应时间; α_1 和 α_2 分别为驾驶人的加速和减速敏感系数; γ_{DH} 和 γ_{DL} 分别为驾驶人的安全裕度上限和下限。当驾驶人感知到的安全裕度大于其可接受的上限时, 驾驶人便会加速, 当感知到的安全裕度低于其可接受的下限时, 驾驶人便会减速。

2.2 IDM

IDM 模型中车辆加速度通过如下公式进行计算^[16]:

$$\tilde{S}_F(t) = S_{F, \text{jam}} + v_F(t) T_F - \frac{v_F(t)(v_L(t) - v_F(t))}{2\sqrt{a_{F, \text{max}} a_{F, \text{cof}}}} \quad (8)$$

$$a_F(t + \tau) = a_{F, \text{max}} \left[1 - \left(\frac{v_F(t)}{\tilde{v}_F(t)} \right)^\beta - \left(\frac{\tilde{S}_F(t)}{S_F(t)} \right)^2 \right] \quad (9)$$

式中: β 为模型参数; $\tilde{v}_F(t)$ 为车辆期望速度, 设置

为 $33.3 \text{ m} \cdot \text{s}^{-1}$; $\tilde{S}_F(t)$ 为期望车辆间隙; $S_{F, \text{jam}}$ 为拥挤交通状态下车辆的最小安全间隙; T_F 为安全的车头时距; $a_{F, \text{max}}$ 和 $a_{F, \text{cof}}$ 分别为车辆的最大加速度和舒适的减速度。

2.3 模型标定及指标

跟驰模型的参数标定是一个带约束的非线性优化问题, 在已有研究中, 通常使用遗传算法来进行参数标定^[17]。本文采用遗传算法对 DSM 模型中 τ , α_1 , α_2 , γ_{DH} 和 γ_{DL} 这 5 个参数以及 IDM 中 β , $S_{F, \text{jam}}$, T_F , $a_{F, \text{max}}$ 和 $a_{F, \text{cof}}$ 这 5 个参数进行标定, 分析两个模型对混行环境跟驰行为的建模能力和模型参数的变化。

在跟驰模型的相关研究中, 通常选用相对车间隙或后车速度的均方根误差 (root mean square error, RMSE) 来评价跟驰模型对跟驰行为的建模能力^[18]。Punzo 等^[19]从理论和案例两个方面证明了相对车间隙的 RMSE 相较于速度的 RMSE 更适合评价模型的建模能力。因此, 本文选择相对车间隙的 RMSE 作为遗传算法标定的目标函数以及模型拟合能力的评价指标, 计算公式为

$$\delta_{\text{RMSE}} = \sqrt{\frac{1}{n} \sum_{i=1}^n (S_{\text{obs}}(t) - S_{\text{sim}}(t))^2} \quad (10)$$

式中: $S_{\text{obs}}(t)$ 和 $S_{\text{sim}}(t)$ 分别为实际数据观测到的车间隙和通过模型拟合计算得到的车间隙; n 为该时序数据的总样本数。

3 性能指标

本文从安全性、稳定性以及环境效应 3 个方面选择合适的指标, 进一步补充分析混行环境中 MV 跟驰特性的变化。参考文献 [20-21], 本文在安全性方面选择了车头时距 (time headway, THW) 和安全裕度 (safety margin, SM) 两个指标, 在稳定性方面选择了速度随时间变化的随机波动性 (time-varying stochastic volatility, VolFi) 和加速度的平均绝对偏差 (mean absolute deviation, MAD) 两个指标, 在环境效应方面选了燃油消耗和排放两个指标^[5, 20-21]。

3.1 安全性指标

最小距离碰撞时间 (minimum time-to-collision, mTTC) 和平均 THW 是跟驰过程中两个最常用的安全性评价指标^[20]。本文所使用的案例平均时长为 20 s 左右, 且部分案例中前后两辆车的速度全程保

持相对一致,导致 mTTC 在部分案例中无法准确评价跟驰过程的安全性,影响安全性的分析结果。综合考虑后,选择平均 THW 作为安全性指标之一,THW 可以通过如下公式进行计算:

$$t_{\text{THW}}(t) = \frac{x_L(t) - x_F(t)}{v_F(t)} \tag{11}$$

式中, $x_L(t)$ 和 $x_F(t)$ 分别为前后车位置。

SM 同样是一个评价跟驰过程安全性的有效指标^[21-22]。该指标同时考虑了后车速度、相对速度和车间隙,通过比较实际车间隙和最小安全车间隙对跟驰风险进行评价,综合了 TTC 和 THW 的优势。因此,本文选择平均 SM 作为另一个分析的安全性指标,SM 可以通过式(6)计算得到。THW 和 SM 的值越大,跟驰过程的安全性越高。

3.2 稳定性指标

车辆速度和加速度的变化可以作为稳定性指标来表征行驶过程中的速度波动性^[23]。已有研究发现,速度的 VolFi 和加速度的 MAD 能够较好反映速度的波动性和加速度波动性^[5]。本文将其作为稳定性指标。

速度的 VolFi 可以通过如下公式进行计算:

$$V_{\text{Speed}} = \sqrt{\frac{1}{n-1} \sum_{t=1}^{n-1} (r(t) - \bar{r})^2} \tag{12}$$

$$r(t) = \ln\left(\frac{v_F(t+1)}{v_F(t)}\right) \times 100 \tag{13}$$

式中: $v_F(t)$ 和 $v_F(t+1)$ 分别为后车当前时刻和下一时刻的速度; $r(t)$ 为车辆速度变化的对数形式; $\bar{r}$ 为该对数形式的平均值。

加速度的 MAD 可以通过如下公式进行计算:

$$D_{\text{acc}} = \frac{1}{n} \sum_{t=1}^n |a_F(t) - \bar{a}_F| \tag{14}$$

式中: $a_F(t)$ 为后车当前时刻的加速度; $\bar{a}_F$ 为整个过程加速度的平均值。速度的 VolFi 和加速度的 MAD 越大,跟驰过程中的稳定性越差。

3.3 环境效应指标

精确的燃油消耗计算需要考虑大量复杂的因素,包括车辆速度、加速度、燃料类型、温度、传动、发动机效率等。由于本文所使用的案例在相同数据集中提取,车辆及其行车环境条件相对一致。此外,本文旨在分析相同车辆在不同前车类型情况下的行为差异。因此,假设影响燃油消耗的因素只有速度和加速度,其他关于燃油消耗

计算的假设与 Mahdinia 等^[5]的研究保持一致。燃油消耗可以通过如下公式进行计算^[24]:

$$F_v = c_0 + c_1 v_F(t) + c_2 v_F^2(t) + c_3 v_F^3(t) + a_F(t)(d_0 + d_1 v_F(t) + d_2 v_F^2(t)) \tag{15}$$

式中: F_v 为估计的瞬时燃油消耗, mL/s; 其他为模型参数,取值依次为 $c_0 = 0.1569$, $c_1 = 2.450 \times 10^{-2}$, $c_2 = -7.415 \times 10^{-4}$, $c_3 = 5.975 \times 10^{-5}$, $d_1 = 7.224 \times 10^{-2}$, $d_1 = 9.681 \times 10^{-2}$ 和 $d_2 = 1.075 \times 10^{-3}$ ^[25]。

车辆排放可以首先通过车比功率(vehicle-specific power, VSP)微观模型计算,然后通过查表得到车辆在该条件下不同物质的排放信息。VSP 模型通过回归的方式来计算排放,在计算过程中考虑了车辆速度、加速度和地形坡度的影响。不同 VSP 条件下车辆不同物质的排放信息如表 2 所示。本文假设地形坡度等于 0,并忽略其他影响因素,以便于更好地对比两种环境下后车行为的差异。VSP 和总排放可以通过如下公式进行计算:

$$\eta_{\text{VSP}} = v_F(t)(1.1a_F(t) + 0.132) + 0.000\,302v_F^3(t) \tag{16}$$

$$E = E_{\text{CO}_2}(\eta_{\text{VSP}}) \times t + E_{\text{CO}}(\eta_{\text{VSP}}) \times t + E_{\text{NO}_x}(\eta_{\text{VSP}}) \times t + E_{\text{HC}}(\eta_{\text{VSP}}) \times t \tag{17}$$

式中, $E_{\text{CO}_2}(\eta_{\text{VSP}})$, $E_{\text{CO}}(\eta_{\text{VSP}})$, $E_{\text{NO}_x}(\eta_{\text{VSP}})$ 和 $E_{\text{HC}}(\eta_{\text{VSP}})$ 分别为在当前 VSP 条件下, CO_2 , CO ,

表 2 不同 VSP 情况下平均排放率

Tab.2 Average emission rate under different VSP

车比功率	$E_{\text{CO}_2}(\eta_{\text{VSP}})/$ ($\text{g} \cdot \text{s}^{-1}$)	$E_{\text{CO}}(\eta_{\text{VSP}})/$ ($\text{mg} \cdot \text{s}^{-1}$)	$E_{\text{NO}_x}(\eta_{\text{VSP}})/$ ($\text{mg} \cdot \text{s}^{-1}$)	$E_{\text{HC}}(\eta_{\text{VSP}})/$ ($\text{mg} \cdot \text{s}^{-1}$)
$\eta_{\text{VSP}} < -2$	1.671	7.807	0.901	0.450
$-2 < \eta_{\text{VSP}} < 0$	1.458	3.908	0.628	0.257
$0 < \eta_{\text{VSP}} < 1$	1.135	3.347	0.346	0.406
$1 < \eta_{\text{VSP}} < 4$	2.233	8.335	1.173	0.432
$4 < \eta_{\text{VSP}} < 7$	2.920	10.959	1.706	0.530
$7 < \eta_{\text{VSP}} < 10$	3.525	17.013	2.368	0.705
$10 < \eta_{\text{VSP}} < 13$	4.107	20.026	3.103	0.822
$13 < \eta_{\text{VSP}} < 16$	4.635	29.222	4.234	0.976
$16 < \eta_{\text{VSP}} < 19$	5.161	35.531	5.069	1.112
$19 < \eta_{\text{VSP}} < 23$	5.633	55.068	5.865	1.443
$23 < \eta_{\text{VSP}} < 28$	6.535	113.824	7.623	2.061
$28 < \eta_{\text{VSP}} < 33$	7.585	207.586	12.149	3.373
$33 < \eta_{\text{VSP}} < 39$	9.024	441.775	15.456	4.857
$\eta_{\text{VSP}} > 39$	10.088	882.300	17.863	10.948

CO₂和HC的排放，单位为 g/s，具体数值通过表 2 进行查询。

4 结果分析

在对结果进行分析的过程中发现，跟驰模型的标定结果、标定参数以及分析指标中部分不服从正态分布，后续结果的统计分析主要采用非参数检验的方法进行。

4.1 跟驰模型拟合性能分析

通过遗传算法分别使用提取的 399 个案例 (291 个 MV 场景案例和 108 个 AV 场景案例)对 DSM 模型和 IDM 的参数进行标定。使用标定参数对所有案例进行拟合的统计结果如表 3 所示。在 MV 场景和 AV 场景下，DSM 模型的拟合误差分别为 0.70 m 和 0.68 m，IDM 的拟合误差分别为 0.74 m 和 0.77 m，其柱状图如图 2 所示。非参数检验的结果表明，两个场景下的 DSM 模型和 IDM 的拟合误差均不存在显著性的差异 ($Z=-0.120$, $p=0.904$; $Z=-0.347$, $p=0.729$)，DSM 模型和 IDM 在混行环境中同样具备对 MV 跟驰行为的建模能力，模型参数在混行环境中仍然能够反映驾驶人的行为特征。此外，DSM 模型有着相对于 IDM 更低的拟合误差 ($Z=-3.817$, $p=0.000$)。

4.2 跟驰模型拟合参数分析

通过遗传算法对两个模型参数进行标定的统计结果分别如表 4 和表 5 所示。非参数检验的结果表明，在两个场景中，两个模型的大部分参数均不存在显著性差异，只有 DSM 模型的减速度敏感系数值在 AV 场景中显著低于在 MV 场景中的值。该结果表明，两个场景下 MV 驾驶人的大部分行为特征参数分布不存在显著性差异，但是 MV 驾驶人在跟驰 AV 时其减速敏感程度更低 ($Z=-3.817$, $p=0.000$)。

4.3 安全性分析

安全性分析的统计结果如表 6 所示。在 MV 场景和 AV 场景下，后车的平均 THW 分别为 2.13 s 和 2.23 s，平均 SM 分别为 0.89 和 0.88，其柱状图如图 3 所示。非参数检验的结果表明，两个场景下的平均 THW 和 SM 不存在显著性的差异 ($Z=-1.386$, $p=0.166$; $Z=-1.296$, $p=0.195$)，混行环境下 AV 作为被跟驰的前车并没有显著性地提高 MV 后车的安全性能。

表 3 DSM 模型和 IDM 拟合误差的统计结果
Tab.3 Statistical results of fitting errors of DSM model and IDM

模型	前车类型	相对间隙的RMSE/m				显著性
		均值	标准差	最小值	最大值	
DSM	MV	0.70	0.69	0.07	4.41	0.904
	AV	0.68	0.64	0.05	5.05	
IDM	MV	0.74	0.57	0.08	4.74	0.729
	AV	0.77	0.55	0.09	2.40	




图 2 MV 场景和 AV 场景下模型误差
Fig.2 Model fitting errors in MV and AV scenarios

表 4 DSM 模型标定参数的统计结果
Tab.4 Statistical results of DSM model calibration parameters

模型参数	前车类型	均值	标准差	最小值	最大值	显著性
反应时间	MV	1.12	0.59	0.30	2.00	0.715
	AV	1.11	0.63	0.31	2.00	
安全裕度下限	MV	0.74	0.16	0.31	0.98	0.820
	AV	0.75	0.16	0.32	0.98	
安全裕度上限	MV	0.91	0.04	0.85	0.98	0.091
	AV	0.90	0.04	0.85	0.98	
减速敏感系数	MV	13.79	9.22	0.10	30.00	<0.001
	AV	10.15	9.04	0.10	29.99	
加速敏感系数	MV	10.65	9.41	0.10	30.00	0.087
	AV	8.98	8.34	0.10	30.00	

4.4 稳定性分析

稳定性分析的统计结果如表 6 所示。在 MV 场景和 AV 场景下，后车的速度 VolFi 分别为 0.54 m·s⁻¹ 和 0.44 m·s⁻¹，加速度 MAD 分别为 0.37 m·s⁻² 和 0.34 m·s⁻²，其柱状图如图 4 所示。非参数检验的结果表明，两个场景下的速度 VolFi 存在显著性的差异 ($Z=-2.480$, $p=0.013$)，加速度 MAD 不存在显著性的差异 ($Z=-1.419$, $p=0.156$)，混行环境下 AV

表 5 IDM 标定参数的统计结果

Tab.5 Statistical results of IDM calibration parameters						
模型参数	前车类型	均值	标准差	最小值	最大值	显著性
β	MV	4.95	3.05	1.00	8.00	0.607
	AV	4.72	3.01	1.00	8.00	
安全相对车间隙	MV	2.51	1.93	0.10	5.00	0.404
	AV	2.33	1.84	0.10	5.00	
安全车头时距	MV	1.27	0.77	0.10	3.99	0.665
	AV	1.25	0.83	0.10	3.78	
最大加速度	MV	1.07	0.71	0.10	2.00	0.484
	AV	0.99	0.66	0.10	2.00	
期望减速度	MV	2.09	1.65	0.10	4.00	0.076
	AV	2.33	1.61	0.10	4.00	

表 6 MV 后车性能指标的统计结果

Tab.6 Statistical results of performance indexes for the following MV						
指标	前车类型	均值	标准差	最小值	最大值	显著性
车头时距/s	MV	2.13	0.72	0.69	4.51	0.166
	AV	2.23	0.73	0.80	4.03	
安全裕度	MV	0.89	0.06	0.59	1.00	0.195
	AV	0.88	0.07	0.52	0.99	
速度VolFi/ (m·s ⁻¹)	MV	0.54	0.42	0.03	2.39	0.013
	AV	0.44	0.39	0.04	2.05	
加速度MAD/ (m·s ⁻²)	MV	0.37	0.21	0.03	1.42	0.156
	AV	0.34	0.19	0.05	0.88	
燃油消耗/ (L·100km ⁻¹)	MV	8.98	2.89	0.00	23.56	0.017
	AV	8.36	2.68	4.22	17.05	
车辆排放/ (g·km ⁻¹)	MV	196.57	89.16	41.42	537.16	0.003
	AV	168.04	78.05	32.96	421.95	




图 3 MV 场景和 AV 场景下安全性指标

Fig.3 Safety indexes in MV and AV scenarios

作为被跟驰的前车能够显著性地降低 MV 后车的速度波动性, 提高稳定性。

4.5 环境效应指标分析

环境效应指标分析的统计结果如表 6 所示。在




图 4 MV 场景和 AV 场景下稳定性指标

Fig.4 Stability indexes in MV and AV scenarios

MV 场景和 AV 场景下, 后车的燃油消耗分别为 8.98 L·100 km⁻¹ 和 8.36 L·100 km⁻¹, 车辆排放分别为 196.57 g·km⁻¹ 和 168.04 g·km⁻¹, 其柱状图如图 5 所示。非参数检验的结果表明, 两个场景下的燃油消耗和车辆排放均存在显著性的差异 (Z=-2.392, p=0.017; Z=-2.974, p=0.003), 混行环境下 AV 作为被跟驰的前车能够显著性地降低 MV 后车的燃油消耗和车辆排放。




图 5 MV 场景和 AV 场景下环境指标

Fig.5 Environmental indexes in MV and AV scenarios

5 讨论

5.1 DSM 模型的标定参数

针对本案例, DSM 模型有着相对于 IDM 更低的拟合误差。同时, DSM 模型的 5 个参数均具有一定的实际意义, 能够反映驾驶人的行为特征, 可以通过参数变化观察驾驶人行为特征是否发生了变化^[26-27]。其中, 反应时间表现在针对环境变化时, 驾驶人操作调整的及时性。反应时间越短, 驾驶人处理危机情况的能力越高。安全裕度上下限反映驾驶人对跟驰过程中风险的接受区间, 表征驾驶人主观的可承受风险。当安全裕度上下限增加时, 通常意味着驾驶人采取了更加安全的跟驰策略。加减速敏感系数表现在针对相同风险情况, 驾驶人采取加速和制动操作的幅度, 反映驾驶人的操作特性。通常加减速敏感系数越小, 驾驶人的操作越平缓, 跟驰过程中的

稳定性越好。因此,本文主要对DSM模型5个参数的标定结果进行进一步讨论分析。

在MV场景和AV场景下,反应时间分别为1.12 s和1.11 s。非参数检验的结果表明,两个场景下的反应时间不存在显著性的差异($Z=-0.365$, $p=0.715$)。混行环境下AV作为被跟驰的前车不会影响到MV后车驾驶人的反应时间。MV驾驶人对危机情况的处理能力没有发生显著性的变化。

在MV场景和AV场景下,安全裕度下限分别为0.74和0.75,安全裕度上限分别为0.91和0.90。非参数检验的结果表明,两个场景下的安全裕度下限和上限均不存在显著性差异($Z=-0.228$, $p=0.820$; $Z=-1.693$, $p=0.091$)。混行环境下AV作为被跟驰的前车不会影响到MV后车驾驶人的主观可接受风险,具体表现在其跟驰安全性不会发生显著性的变化,这与前文基于安全性指标的分析结果保持一致。

在MV场景和AV场景下,减速敏感系数分别为13.79和10.15,加速敏感系数分别为10.65和8.98。非参数检验的结果表明,两个场景下的加速敏感系数不存在显著性差异($Z=-0.1711$, $p=0.087$),但减速敏感系数存在显著性差异($Z=-3.606$, $p=0.000$)。混行环境下,AV作为被跟驰的前车能够显著地降低MV后车驾驶人的减速度敏感系数。该系数的降低反映MV的减速过程趋于平缓,速度波动减弱,稳定性提高,与前文基于稳定性指标的分析结果保持一致。

5.2 性能指标

结合前文分析结果可以发现,AV作为跟驰车辆的前车能够改善后车的跟驰稳定性以及环境方面相关性能。在已有研究中,针对AV前车能否改善MV后车安全性的问题,Mousavi等^[28]和Sinha等^[10]得到了相反的分析结果。其原因可能是在驾驶实验或仿真实验中AV前车模型及参数设计或相关假设存在差异^[7]。但是,本文从Waymo自然驾驶数据集中并没有发现AV前车对MV后车安全性产生显著影响。

已有研究发现,更低的速度波动性通常意味着更低的燃油消耗和排放^[29]。本文发现AV前车降低了MV后车的速度波动性和燃油消耗量,该结果与已有研究相符。通过对DSM模型的标定参数进行进一步分析发现,AV作为被跟驰的前车降低了MV后车的减速敏感系数和加速敏感系数,其中,减速敏感系数的降低存在显著性。因此,

AV作为被跟驰的前车可能通过自身的控制策略,影响了MV后车减速的程度,抑制了后车速度波动性,进而降低了燃油消耗和车辆排放。为了验证该假设,本文对前车的速度波动性进行进一步讨论。

5.3 前车速度波动性

AV作为被跟驰的前车可能是通过合适的控制策略来降低自车的速度波动性,从而影响后车行为。为了验证该假设,本文首先分析前后车的速度波动性是否存在相关性。将前车(分别为MV和AV)与后车(均为MV)的速度VolFi进行相关性检验,其结果表明,前车和后车的速度VolFi存在较强的正向相关性($r=0.786$, $p<0.001$)。

随后,本文进一步分析AV场景前车的速度波动性是否显著低于MV场景前车的速度波动性。MV场景和AV场景前车的速度波动性分别为 $0.54\text{ m}\cdot\text{s}^{-1}$ 和 $0.42\text{ m}\cdot\text{s}^{-1}$ 。非参数检验的结果表明,MV场景下前车的速度波动性显著高于AV场景下前车的速度波动性($Z=-1.981$, $p=0.048$)。AV前车可能是通过合适的控制策略降低了自车的速度波动性,从而影响后车行为,改善后车的跟驰稳定性和环境指标。

5.4 基于动态时间序列规整法的匹配案例分析

在上述讨论结果的基础上,本文继续探究当AV场景下前车的速度波动性和MV场景下前车的速度波动性保持几乎一致时,AV场景下后车的行为是否仍然与MV场景下后车的行为存在显著差异。

动态时间序列规整法(dynamic time warping, DTW)是一种基于动态规划来识别时间序列数据相似性的方法^[30]。该方法通过计算和寻找具有最小欧氏距离的两条时间序列数据来寻找最相似的两条时间序列数据。对于时间序列数据 $Q=[q_1, q_2, \dots, q_n]$ 和 $C=[c_1, c_2, \dots, c_m]$,其中, n 和 m 分别为两个时间序列数据的长度,可以对应一个 $n\times m$ 的新矩阵,矩阵中 (i, j) 处的元素表示为 q_i 和 c_j 之间的距离 $d(q_i, c_j)$ 。采用动态规划的方式在该 $n\times m$ 的距离矩阵中寻找一条能够从起点到终点的规整路径, $W=w_1, w_2, \dots, w_k$, $\max(n, m) \leq K \leq n+m-1$,其中 K 是该规整路径包含的线段数量。DTW的目标则是寻找具有最短距离的规整路径,即

$$D_{\text{DTW}}(Q, C) = \min \left\{ \sqrt{\sum_{k=1}^K w_k / K} \right\} \quad (18)$$

通常使用动态规划的方式来寻找该最短路径

径, 动态规划的递归函数为

$$g(i,j)=d(i,j)+$$
$$\min(g(i-1,j),g(i,j-1),g(i-1,j-1)) \quad (19)$$

式中, $g(i,j)$ 为时间序列两点间距离 $d(i,j)$ 的累计求和值。

本文通过 DTW 法在 291 个 MV 场景案例和 108 个 AV 场景案例中基于前车的速度变化曲线进行案例配对, 得到前车速度波动相似的 MV 场景和 AV 场景配对跟驰案例组。在配对的案例组中选择配对效果较好的 50 组 MV 场景和 AV 场景配对案例重复前文分析, 其中两个配对案例的前车速度变化曲线如图 6 所示。DSM 模型的参数、速度

VolFi 和燃油消耗的配对样本非参数检验结果如表 7 所示。其结果表明, 当 AV 场景下前车的速度波动性和 MV 场景下前车的速度波动性保持一致时, 两个场景下 MV 后车的 DSM 模型的减速敏感系数、速度 VolFi 和燃油消耗不再存在显著性差异 ($Z=-0.237, p=0.813$; $Z=-0.468, p=0.640$; $Z=-0.565, p=0.572$)。该分析结果进一步表明, AV 前车可以通过合适的控制策略降低自车的速度波动性, 从而影响后车行为, 改善后车的跟驰稳定性和环境指标。当 AV 前车的控制策略与 MV 前车相似时, AV 前车并不会对 MV 后车的行为产生额外的影响。




图 6 配对案例前车速度变化曲线

Fig.6 Curve of the leading vehicle speed change in paired cases

表 7 配对案例 MV 后车模型参数和性能指标的统计结果

Tab.7 Statistical results of model parameters and performance indexes of the following MV in paired cases

指标	前车类型	均值	标准差	最小值	最大值	显著性
减速敏感系数	MV	15.39	9.45	0.10	30.00	0.546
	AV	13.85	9.83	0.10	30.00	
速度VolFi/(m·s ⁻¹)	MV	0.50	0.36	0.09	2.11	0.813
	AV	0.48	0.33	0.07	1.83	
燃油消耗/(L·100 km ⁻¹)	MV	8.72	1.88	5.32	13.75	0.640
	AV	8.64	2.28	4.48	14.48	

6 结 论

本文基于 Waymo 公开数据集分析了混行环境中 AV 对 MV 跟驰行为的影响。分析结果表明, 混行环境中 MV 跟驰行为的机制并没有发生显著的变化, 传统的跟驰模型仍然能够应用于混行环境 MV 的跟驰行为研究。大部分模型参数分布也没有发生显著性改变。但是, 在混行环境中, MV 驾驶人对减速度的敏感程度显著性降低。

AV 前车可以通过其控制策略降低自车的速度波动性, 从而影响后车行为, 改善后车的跟驰稳定性和环境效应。本文的研究结果为智能网联交通控制和仿真研究奠定了理论基础, 为 AV 的车车交互系统设计与优化提供了有效参考。后续研究将在换道和交叉口等场景中继续探讨 AV 对 MV 行为的影响, 并进一步考虑 MV 驾驶人特征属性的差异, 进而分析不同类型驾驶人在 AV 影响下的不同行为调整模式。

参考文献:

- [1] QU X B, YU Y, ZHOU M F, et al. Jointly dampening traffic oscillations and improving energy consumption with electric, connected and automated vehicles: a reinforcement learning based approach[J]. *Applied Energy*, 2020, 257: 114030.
- [2] 梁军, 徐鹏, 蔡英凤, 等. 人机混驾环境下混行车辆雾模型研究 [J]. *中国公路学报*, 2021, 34(11): 255–264.
- [3] 胡永辉, 金旭峰, 王亦兵, 等. 智能网联混行动力异构交通流生态驾驶 [J]. *中国公路学报*, 2022, 35(3): 15–27.
- [4] ZHAO X M, WANG Z, XU Z G, et al. Field experiments on longitudinal characteristics of human driver behavior following an autonomous vehicle[J]. *Transportation Research Part C:Emerging Technologies*, 2020, 114: 205–224.
- [5] MAHDINIA I, MOHAMMADNAZAR A, ARVIN R, et al. Integration of automated vehicles in mixed traffic: evaluating changes in performance of following human-driven vehicles[J]. *Accident Analysis & Prevention*, 2021, 152: 106006.
- [6] WEN X, CUI Z Y, JIAN S S. Characterizing car-following behaviors of human drivers when following automated vehicles using the real-world dataset[J]. *Accident Analysis & Prevention*, 2022, 172: 106689.
- [7] YE L H, YAMAMOTO T. Evaluating the impact of connected and autonomous vehicles on traffic safety[J]. *Physica A:Statistical Mechanics and its Applications*, 2019, 526: 121009.
- [8] TIAN J F, LI G Y, TREIBER M, et al. Cellular automaton model simulating spatiotemporal patterns, phase transitions and concave growth pattern of oscillations in traffic flow[J]. *Transportation Research Part B:Methodological*, 2016, 93: 560–575.
- [9] CALVERT S C, SCHAKEL W J, VAN LINT J W C. Will automated vehicles negatively impact traffic flow?[J]. *Journal of Advanced Transportation*, 2017, 2017: 3082781.
- [10] SINHA A, CHAND S, WIJAYARATNA K P, et al. Comprehensive safety assessment in mixed fleets with connected and automated vehicles: a crash severity and rate evaluation of conventional vehicles[J]. *Accident Analysis & Prevention*, 2020, 142: 105567.
- [11] VAN AREM B, VAN DRIEL C J G, VISSER R. The impact of cooperative adaptive cruise control on traffic-flow characteristics[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2006, 7(4): 429–436.
- [12] GONG S Y, DU L L. Cooperative platoon control for a mixed traffic flow including human drive vehicles and connected and autonomous vehicles[J]. *Transportation Research Part B:Methodological*, 2018, 116: 25–61.
- [13] HU X W, ZHENG Z D, CHEN D J, et al. Processing, assessing, and enhancing the waymo autonomous vehicle open dataset for driving behavior research[J]. *Transportation Research Part C:Emerging Technologies*, 2022, 134: 103490.
- [14] Transportation Research Board. HCM2010: highway capacity manual[M]. Washington: Transportation Research Board, 2010.
- [15] LU G Q, CHENG B, WANG Y P, et al. A car-following model based on quantified homeostatic risk perception[J]. *Mathematical Problems in Engineering*, 2013, 2013: 408756.
- [16] TREIBER M, HENNECKE A, HELBIG D. Congested traffic states in empirical observations and microscopic simulations[J]. *Physical Review E*, 2000, 62(2): 1805–1824.
- [17] LI L, CHEN X Q, ZHANG L. A global optimization algorithm for trajectory data based car-following model calibration[J]. *Transportation Research Part C:Emerging Technologies*, 2016, 68: 311–332.
- [18] TAN H T, LU G Q, LIU M M. Risk field model of driving and its application in modeling car-following behavior[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(8): 11605–11620.
- [19] PUNZO V, MONTANINO M. Speed or spacing? Cumulative variables, and convolution of model errors and time in traffic flow models validation and calibration[J]. *Transportation Research Part B: Methodological*, 2016, 91: 21–33.
- [20] 龙文民, 鲁光泉, 石茜, 等. 基于驾驶人跟驰特性的前撞预警指标与阈值确定方法 [J]. *汽车工程*, 2022, 44(9): 1339–1349.
- [21] LU G Q, CHENG B, LIN Q F, et al. Quantitative indicator of homeostatic risk perception in car following[J]. *Safety Science*, 2012, 50(9): 1898–1905.
- [22] ZHAO X M, LI Q, XIE D F, et al. Risk perception and the warning strategy based on microscopic driving state[J]. *Accident Analysis & Prevention*, 2018, 118: 154–165.
- [23] KAMRANI M, ARVIN R, KHATTAK A J. Extracting useful information from basic safety message data: an empirical study of driving volatility measures and crash frequency at intersections[J]. *Transportation Research Record:Journal of the Transportation Research Board*, 2018, 2672(38): 290–301.
- [24] KAMAL A S, MUKAI M, MURATA J, et al. Model predictive control of vehicles on urban roads for improved fuel economy[J]. *IEEE Transactions on Control Systems Technology*, 2013, 21(3): 831–841.

[25] KAMAL M A S, MUKAI M, MURATA J, et al. Ecological vehicle control on roads with up-down slopes[J]. [IEEE Transactions on Intelligent Transportation Systems](#), 2011, 12(3): 783–794.

[26] ZHANG J J, WANG Y P, LU G Q. Impact of heterogeneity of car-following behavior on rear-end crash risk[J]. *Accident Analysis & Prevention*, 2019, 125: 275–289.

[27] WANG Y P, ZHANG J J, LU G Q. Influence of driving behaviors on the stability in car following[J]. [IEEE Transactions on Intelligent Transportation Systems](#), 2019, 20(3): 1081–1098.

[28] MOUSAVI S M, OSMAN O A, LORD D, et al. Investigating the safety and operational benefits of mixed traffic environments with different automated vehicle market penetration rates in the proximity of a driveway on an urban arterial[J]. *Accident Analysis & Prevention*, 2021, 152: 105982.

[29] RIOS-TORRES J, LIU J, KHATTAK A. Fuel consumption for various driving styles in conventional and hybrid electric vehicles: integrating driving cycle predictions with fuel consumption optimization[J]. [International Journal of Sustainable Transportation](#), 2019, 13(2): 123–137.

[30] KEOGH E, RATANAMAHATANA C A. Exact indexing of dynamic time warping[J]. [Knowledge and Information Systems](#), 2005, 7(3): 358–386.

(编辑: 丁红艺)



[上接第 320 页]

[118] POLYDOROPOULOU A, PAGONI I, TSIRIMPA A, et al. Prototype business models for Mobility-as-a-Service[J]. [Transportation Research Part A: Policy and Practice](#), 2020, 131: 149–162.

[119] 杨晓光, 郝正博, 杨正, 等. 智能交通主动管理与服务系统 (ATMaaS) 框架体系 [C]//交通治理与空间重塑——2020 年中国城市交通规划年会论文集. 北京: 中国建筑工业出版社, 2020: 2055–2063.

(编辑: 丁红艺)