

doi: 10.19562/j.chinasae.qcgc.2024.11.002

面向智能驾驶测试的可变跟驰特性交通车建模方法*

赵健, 李文旭, 朱冰, 张培兴, 汤瑞, 李嘉胜
(吉林大学, 汽车仿真与控制国家重点实验室, 长春 130022)

[摘要] 提出一种面向智能驾驶测试的可变跟驰特性交通车建模方法。首先,通过对自然驾驶数据聚类分析,建立高真实交互个性化的跟驰模型,并利用模型输出耦合赋予多元权值,构建可用于智能驾驶测试的可变跟驰特性交通车模型;然后,通过建立交通车轨迹评价方法验证模型输出轨迹的合理性、多样性及真实性;最后,搭建联合仿真平台进行了所构建交通车模型对自动紧急制动(autonomous emergency braking, AEB)算法的应用测试。结果表明,本文构建的交通车模型可以输出不同跟驰特性下合理、多样且真实的轨迹,当轨迹数量达到60 000条时与真实自然驾驶速度轨迹匹配的平均均方根误差为0.427 m/s,且在不同交通车轨迹特性下待测系统行为响应不尽相同,通过权值系数的变化可以揭示待测系统响应的演化规律,并可实现待测系统性能的针对性测试。

关键词: 智能驾驶测试; 交通车建模; 可变跟驰特性; Transformer网络; 多元权值分配

A Modeling Method for Traffic Vehicle with Variable Car Following Characteristic for Intelligent Driving System Testing

Zhao Jian, Li Wenxu, Zhu Bing, Zhang Peixing, Tang Rui & Li Jiasheng

Jilin University, State Key Laboratory of Automotive Simulation and Control, Changchun 130022

[Abstract] A variable following characteristic traffic vehicle modeling method for intelligent driving system testing is proposed in this paper. Firstly, by clustering and analyzing natural driving data, a highly realistic interactive personalized car following model is established, and the model output coupling is used to assign multiple weights to construct a traffic vehicle model with variable car following characteristics that can be used for intelligent driving system testing. Then, by establishing the traffic vehicle trajectory evaluation method, the rationality, diversity and authenticity of the model's output trajectory are verified. Finally, a joint simulation platform is built to test the application of the constructed traffic vehicle model to the Automatic Emergency Braking (AEB) algorithm. The results show that the traffic vehicle model constructed in this paper can output reasonable, diverse, and realistic trajectories under different car following characteristics. When the number of trajectories reaches 60 000, the average root mean square error matched with the real natural driving speed trajectory is 0.427 m/s. Moreover, the behavioral response of the tested system varies under different traffic vehicle trajectory characteristics. By changing the weight coefficients, the evolution law of the tested system response can be revealed, and targeted testing of the tested system performance can be achieved.

Keywords: intelligent driving system testing; traffic vehicle modeling; variable car following characteristic; Transformer network; multiple weight allocation

* 国家重点研发计划项目(2022YFB2502904)资助。

原稿收到日期为2024年02月19日,修改稿收到日期为2024年04月09日。

通信作者:朱冰,教授,工学博士,E-mail:zhubing@jlu.edu.cn。

前言

智能驾驶系统在实际应用前的性能验证至关重要,尤其在复杂多变的真实交通环境中确保安全可靠。在智能汽车完全部署之前,过渡阶段将由智能汽车和人类驾驶车辆共享道路^[1],在混合交通环境中智能汽车将与不同风格的驾驶员进行交互,驾驶风格的多变性导致智能汽车的行为响应也不尽相同,须对其进行全面可靠的性能测试以保证安全性。基于场景的仿真测试方法是智能驾驶系统性能验证的重要手段^[2],能够有效加快测试进程,提高测试效率。

基于场景的仿真测试方法主要分为两类:一类关注于构建与真实交通环境相近的仿真交通流^[3-4],然而其常用于测试融入智能驾驶系统后混合交通环境的通行效率、交通流稳定性及拟真度,难以高效获取改进待测系统性能的高价值场景数据,测试效率较低;另一类关注于危险场景参数生成以提高测试效率。Xie等^[5]通过模型预测控制引导交通车运动,直接为主车创建关键场景。Feng等^[6]通过密集强化学习建模交通车,实现了与现实环境中相一致的等效加速测试。Zhu等^[7-8]通过设计高效优化算法探索智能驾驶系统在指定参数空间下的危险场景。上述方法均能高效获取大量危险场景以改进系统性能,但在测试过程中交通车轨迹特性类别单一且缺乏明确定义。

现有方法在测试智能驾驶系统时交通车轨迹特性单一,而在相同的场景初始状态下,交通车不同的

轨迹特性会使得待测系统产生不同的行为响应,从而难以全面测试系统的性能;同时,当前研究交通车轨迹特性定义模糊导致难以精准对应交通车特性与待测系统性能响应之间的关系,在测试过程中盲目性较大,无法通过交通车不同轨迹特性反映出待测系统性能的演化规律,从而难以实现高效且针对性的性能测试。因而需要一种轨迹特性动态可调且调节系数与输出特性精准对应的交通车模型,将交通车轨迹对待测系统的影响考虑到测试过程当中,深入理解交通车轨迹特性并准确评估其对待测系统性能的影响。

车辆的跟驰行为是复杂交通场景下的重要组成部分,跟驰模型能够对车辆跟驰行为进行建模以描述车辆之间的纵向交互过程。针对上述问题,本文提出一种面向智能驾驶测试的可变跟驰特性交通车建模方法,构建具有高真实交互特性的个性化跟驰模型(personalized car following model, PCFM)对车辆跟驰过程进行动态建模,通过个性化跟驰模型输出耦合方法实现多元权值分配,得到具有可变跟驰特性的交通车模型,建立权值系数与输出特性间的对应关系,并构建模型输出轨迹评价方法,进而探究交通车不同输出特性对智能驾驶系统性能响应的影响,以实现更高覆盖度的系统性能测试。

1 基于PCFM的交通车建模方法

1.1 基于PCFM的交通车建模方法架构

基于PCFM的交通车建模方法架构如图1所示。

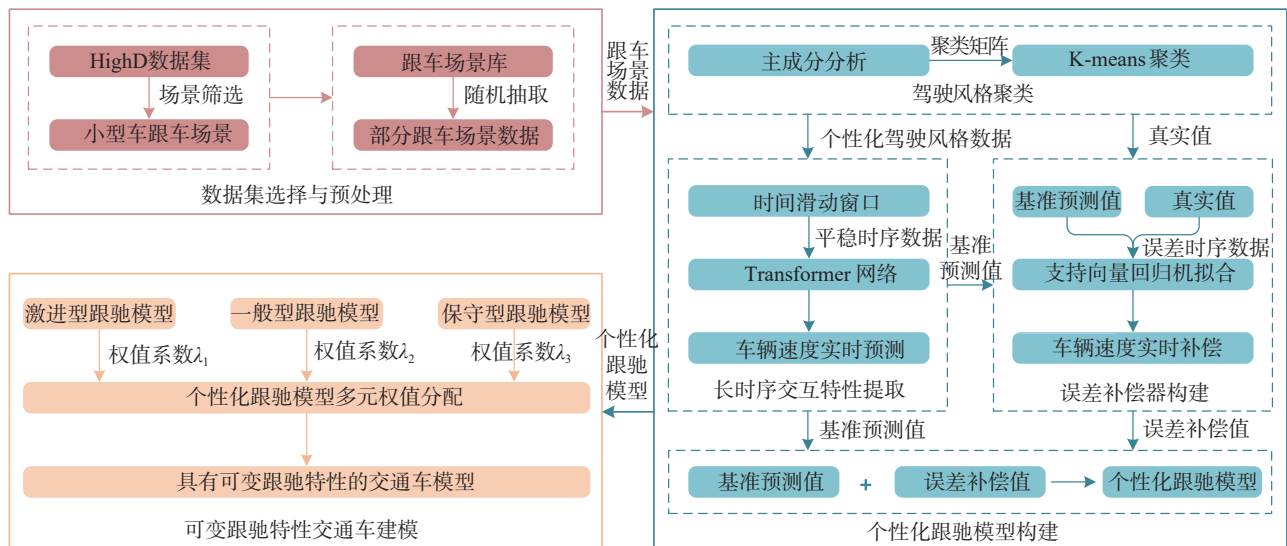


图1 基于PCFM的交通车建模方法架构

选择自然驾驶数据集并预处理,以聚类得到的不同驾驶风格数据为输入构建长时序交互特性提取架构,并构建误差补偿器,得到具有高真实交互特性的个性化跟驰模型,进而通过可变多元权值分配得到具有可变跟驰特性的交通车模型。

1.2 数据集选择与预处理

本文选择 HighD 数据集^[9]进行不同驾驶风格数据的聚类,HighD 数据集在德国高速公路上以无人机俯瞰视角精确测量车辆的位置和运动,采集频率为 25 Hz,包含多种场景工况。

在数据集中根据规则提取跟车场景,并对车辆形式进行筛选,以排除车辆类型对于驾驶风格的影响,本文以小型车的跟车数据为基础,在其中随机选取 60 000 条场景作为驾驶风格聚类的数据输入。

1.3 个性化跟驰模型构建

1.3.1 驾驶风格聚类

为获取不同驾驶风格的跟车场景数据,须对自然驾驶数据进行驾驶风格聚类,选择能够反映车辆行驶激进程度的特征变量,如表 1 所示,以特征变量值大小来衡量不同驾驶风格之间的差异。

表 1 特征变量

序号	特征变量	单位
1	X_1 -纵向速度绝对值的均值	$\text{m}\cdot\text{s}^{-1}$
2	X_2 -纵向速度绝对值的标准差	$\text{m}\cdot\text{s}^{-1}$
3	X_3 -纵向加速度绝对值的均值	$\text{m}\cdot\text{s}^{-2}$
4	X_4 -纵向加速度绝对值的标准差	$\text{m}\cdot\text{s}^{-2}$
5	X_5 -纵向冲击度的均值	$\text{m}\cdot\text{s}^{-3}$
6	X_6 -纵向冲击度的标准差	$\text{m}\cdot\text{s}^{-3}$

其中冲击度为加速度的导数,如式(1)所示。

$$J = \frac{da}{dt} \quad (1)$$

式中: J 为车辆冲击度; a 为车辆加速度; t 为时间。

特征变量之间较强的相关性会增加数据的冗余程度,为简化数据以提高聚类效果,采用主成分分析法^[10]对原始数据进行降维处理。

首先对不同量纲的特征变量进行归一化处理得到标准化的样本矩阵 X ,计算标准化样本的协方差矩阵 R 。

$$\left\{ \begin{array}{l} r_{ij} = \frac{1}{n-1} \sum_{k=1}^n (X_{ki} - \bar{X}_i)(X_{kj} - \bar{X}_j) \\ R = \begin{bmatrix} r_{11} & r_{12} & \cdots & r_{1p} \\ r_{21} & r_{22} & \cdots & r_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ r_{p1} & r_{p2} & \cdots & r_{pp} \end{bmatrix} \end{array} \right. \quad (2)$$

式中: X 为样本矩阵; R 为样本协方差矩阵。

计算协方差矩阵 R 的特征值 λ 及对应的特征向量,以特征值为基础计算主成分贡献率及累计贡献率,如式(3)所示。选择累计贡献率超过 85% 的 3 个主成分,如表 2 所示,并对 3 个主成分系数进行分析,如表 3 所示。结果表明贡献率高达 51.9% 的单一主成分与 X_2 、 X_3 、 X_4 、 X_6 等特征变量具有较强的相关性。

$$\left\{ \begin{array}{l} \text{贡献率} = \frac{\lambda_i}{\sum_{k=1}^p \lambda_k} \quad (i = 1, 2, \dots, p) \\ \text{累计贡献率} = \frac{\sum_{k=1}^i \lambda_k}{\sum_{k=1}^p \lambda_k} \quad (i = 1, 2, \dots, p) \end{array} \right. \quad (3)$$

式中 λ 为协方差矩阵的特征值。

表 2 主成分分析结果

主成分	特征值	贡献率	累计贡献率
1	3.113	51.9%	51.9%
2	1.067	17.8%	69.7%
3	0.970	16.2%	85.9%

表 3 主成分相关性

变量	主成分		
	1	2	3
X_1	0.011	-0.871	0.435
X_2	0.484	0.122	-0.017
X_3	0.518	-0.178	0.053
X_4	0.523	0.083	0.071
X_5	0.093	-0.425	-0.895
X_6	0.465	0.083	0.047

将主成分分析降维得到的 3 个主成分系数与原始特征矩阵相乘,得到用于聚类处理的矩阵,本文选取 K-means 算法^[11]对跟车场景数据进行聚类分析。

K-means 算法从样本集中随机选取 k 个样本作为聚类中心,计算所有样本与聚类中心的欧式距离,并将每一个样本划分到与之最近的聚类中心所在的簇中,并重新计算聚类中心,直至聚类中心不再发生移动或达到预定的迭代次数;K-means 算法以最小化样本与聚类中心的欧氏距离为目标,目标函数如式(4)所示。

$$F = \sum_{i=1}^n \sum_{j=1}^k r_{ij} \|x_i - \mu_j\|^2 \quad (4)$$

式中: x 为聚类的样本; μ_j 表示类别为 j 的聚类中心; r_{ij} 表示第 i 个样本是否属于第 j 个簇,是则取值为 1,

否则取值为0。

为生成3类驾驶风格数据,K-means算法的 k 设置为3,算法初始随机选择3个聚类中心,并不断迭代更新。不同驾驶风格数据的特征变量值如表4所示,保守型、一般型、激进型驾驶风格数据的特征变量值依次增大。

表4 不同驾驶风格数据特征变量值

特征变量	保守型	一般型	激进型
X_1 -纵向速度均值	23.182	31.007	36.739
X_2 -纵向速度标准差	0.839	0.872	0.888
X_3 -纵向加速度均值	0.189	0.252	0.293
X_4 -纵向加速度标准差	0.118	0.137	0.136
X_5 -纵向冲击度均值	0.003	0.004	0.006
X_6 -纵向冲击度标准差	0.143	0.151	0.153

1.3.2 长时序交互特性提取

为提取自然驾驶跟驰行为的动态交互特性,通过构建预测网络的方式对长时序交互行为进行建模,在本文中利用Transformer模型^[12]提取跟车场景中真实的交互特性。

经过聚类得到的3类驾驶风格数据时序长度不统一、数据质量较差,为提高时序数据的质量,本文采用时间滑动窗口方法对不同长度的时序数据进行处理,将滑动窗口长度设置为100,随机选择激进型、一般型、保守型跟驰模型训练的样本数量各50000条。

由于跟驰车辆的驾驶行为主要与两车辆的相对距离、相对速度和后车速度相关,因此将后车速度 v 、前车速度 v_1 、前车位置 r_1 、后车位置 r 作为四维时间序列输入,以后车速度 v 作为一维时间序列输出,将长时序交互特性提取转化为在给定训练网络 G 的情况下,由历史序列到未来状态的映射函数 f ,如式(5)所示。

$$v_{i+1} = f(G; v_{i-(T-1)}^i, v_{1i-(T-1)}^i, r_{i-(T-1)}^i, r_{1i-(T-1)}^i) \quad (5)$$

式中 v_i^{i+n} 表示从时间 i 到时间 $i+n$ 组成的时间序列 $(v_i, v_{i+1}, \dots, v_{i+n})$ 。

本文采取用于时序预测任务的Transformer模型结构,在此不做过多介绍。将时序数据按照8:2的比例划分为训练集与测试集,模型训练的参数设置如表5所示,其中学习率用来控制模型参数更新速度,隐藏神经元个数决定了模型的表达能力, $Dropout$ 可以提高模型的泛化能力, $Batch_Size$ 为模型训练时单批次输入的样本数。

表5 Transformer模型训练参数设置

参数	数值
输入序列维度	4
输出序列维度	1
d_model	128
注意力机制头数	8
学习率	0.0005
网络层数	3
隐藏层神经元个数	64
$Dropout$	0.1
迭代次数	30
$Batch_Size$	64

1.3.3 误差补偿器构建

为减小长时序交互特性提取时模型单步预测的累计误差,以展现更加准确的交互特征,采用支持向量回归机SVR^[13]作为误差补偿器,对模型的基准预测值进行实时补偿。

SVR模型本质将无法线性回归的样本映射到高维空间进行线性回归,回归函数如式(6)所示。

$$f(x) = w^T h(x) + b \quad (6)$$

支持向量回归机在加入松弛变量 $\xi_i, \tilde{\xi}_i$ 后的优化目标函数为

$$\min_{w,b} \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \tilde{\xi}_i) \quad (7)$$

约束条件为

$$\begin{cases} y_i - f(x_i) \leq \varepsilon + \xi_i \\ f(x_i) - y_i \leq \varepsilon + \tilde{\xi}_i \\ \xi_i, \tilde{\xi}_i \geq 0, i = 1, 2, \dots, n \end{cases} \quad (8)$$

式中 w 为尺寸权重向量; y_i 为输出变量; $\xi_i, \tilde{\xi}_i$ 为松弛变量; ε 为误差系数; c 为惩罚因子。

根据优化目标及约束条件构建拉格朗日函数为

$$\begin{aligned} L = & \frac{1}{2} \|w\|^2 + c \sum_{i=1}^n (\xi_i + \tilde{\xi}_i) + \\ & \sum_{i=1}^n \alpha_i (f(x_i) - y_i - \varepsilon - \xi_i) + \\ & \sum_{i=1}^n \tilde{\alpha}_i (y_i - f(x_i) - \varepsilon - \tilde{\xi}_i) - \\ & \sum_{i=1}^n \lambda_i \xi_i - \sum_{i=1}^n \tilde{\lambda}_i \tilde{\xi}_i \end{aligned} \quad (9)$$

式中 $\alpha_i, \tilde{\alpha}_i, \lambda_i, \tilde{\lambda}_i \geq 0$,为拉格朗日乘子。

利用Transformer模型基准预测值与真值比对获取误差时序数据,将其按照8:2的比例分为训练集与测试集,通过遍历测试寻找SVR模型惩罚因子 c 与RBF函数 $gamma$ 参数值的最佳组合,其中 c 代表

模型对于误差的容忍程度, γ 决定了数据在高维空间上的分布。

参数 c 、 γ 取值范围设置为 $(-5, 5)$, 对不同的组合参数值进行评分, 评分结果越接近 1 表明模型对数据的拟合效果越好, 为减小模型运算量的同时保证模型较好的拟合效果, 最终选取 SVR 模型组合参数值: $c=2.0$ 、 $\gamma=2.0$, 损失函数设置为 ϵ -SVR, 径向基函数设置为 $\exp(-\gamma \times |u - v|^2)$, 误差系数 ϵ 的值设置为 0.1。

1.4 可变跟驰特性交通车建模

为获得可变跟驰特性的交通车模型, 并建立模型系数与输出特性之间的对应关系, 对 3 类个性化跟驰模型输出结果进行多元权值分配, 以不同的权值系数控制交通车的跟驰特性, 如式(10)所示。

$$v'_{\text{combination}} = v'_{\text{radical}} \cdot \lambda_1 + v'_{\text{medium}} \cdot \lambda_2 + v'_{\text{conservative}} \cdot \lambda_3 \quad (10)$$

式中: v'_{radical} 、 v'_{medium} 、 $v'_{\text{conservative}}$ 分别为激进型、一般型、保守型跟驰模型在 t 时刻的输出结果; λ_1 、 λ_2 、 λ_3 分别为激进型、一般型、保守型跟驰模型权值系数, 且 $\lambda_1 + \lambda_2 + \lambda_3 = 1$; $v'_{\text{combination}}$ 为 t 时刻模型的组合加权结果。

通过多元权值分配的方式构建交通车模型, 能够产生更加多样化的跟驰行为, 且通过调节不同的权值系数, 交通车模型能够输出不同跟驰特性的轨迹信息。

至此, 通过 Transformer 与 SVR 模型间的协同配合, 能够保证模型在大部分高速公路场景下输出轨迹的高真实性, 同时在原有训练数据的基础上, 通过多元权值分配进一步扩大了模型输出覆盖范围, 但应注意不合理的权重系数将会使交通车产生现实世界中不存在的驾驶行为, 因而须剔除不合理的权重系数, 并对交通车模型进行全方位的性能评价。

2 交通车模型性能评价方法及验证

2.1 交通车模型性能评价方法

2.1.1 个性化跟驰模型交互效果评价

个性化跟驰模型的交互效果将会直接影响到交通车模型的跟驰特性, 为此需要对 3 类个性化跟驰模型的交互效果进行验证。

利用均方根误差 (root mean square error, RMSE) 评价个性化跟驰模型输出轨迹与真实轨迹之间的相似度, 如式(11)所示。

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (r_i - y_i)^2} \quad (11)$$

式中: r_i 为真实值; y_i 为预测值; m 为轨迹的时序长度。

2.1.2 交通车模型轨迹合理性评价

多元权值分配的输出耦合方法可能导致交通车模型轨迹在连续时序范围内发生较大变动, 而车辆实际驾驶行为的变化程度不应过于剧烈, 可能导致交通车输出轨迹的合理性有所下降。

为此以交通车轨迹的平滑程度来评价轨迹的合理性, 首先对不同轨迹进行平滑处理, 通过计算平滑后轨迹与原始轨迹的距离对轨迹的平滑程度进行量化评估, 如式(12)所示。

$$T_{\text{smooth}} = 1 - \sum_{i=1}^{t_{\text{count}}} \frac{NDis(X_i, X_i^*)}{t_{\text{count}}} \quad (12)$$

式中: T_{smooth} 代表交通车输出轨迹的平滑程度; $NDis(\cdot)$ 为归一化后的距离函数, 用于计算平滑前与平滑后轨迹的相对距离, 其中 $Dis(X, Y) = \sum_i |X_i - Y_i|$; t_{count} 为轨迹的数量; X 代表原始轨迹; X^* 代表平滑后轨迹。

2.1.3 交通车模型轨迹多样性评价

个性化跟驰模型多元权值分配应保证交通车模型在不同场景参数、不同权值系数下均能输出不同的轨迹, 为此对模型输出轨迹的多样性进行评价, 以避免产生大量的同质化轨迹。

交通车模型轨迹的多样性应同时考虑轨迹的形状相似性及轨迹数值分布的相似性, 为此以动态时间规整 (dynamic time warping, DTW) 为基础来衡量不同轨迹之间的多样性, 如式(13)所示。

$$T_{\text{various}} = \sum_{i=1}^{t_{\text{count}}} \sum_{j=1, j \neq i}^{t_{\text{count}}} \frac{NDTW(X_i, X_j)}{(t_{\text{count}} - 1) \cdot t_{\text{count}}} \quad (13)$$

式中: T_{various} 代表交通车输出轨迹的多样性; $NDTW(\cdot)$ 为两条轨迹之间动态时间规整归一化后的量化值。DTW(\cdot) 计算方法如式(14)所示。

$$DTW(X_1, X_2) = D(i, j) + \min \left\{ \begin{array}{l} D(i-1, j-1) \\ D(i-1, j) \\ D(i, j-1) \end{array} \right\} \quad (14)$$

式中: $D(\cdot)$ 为欧氏距离计算函数; i 、 j 分别代表时序数据 X_1 、 X_2 的长度。通过不断的动态计算得到两条时序数据的 DTW 量化值。

2.1.4 交通车模型轨迹真实性评价

交通车模型输出轨迹的高真实性是后续用于智能驾驶系统测试的必要前提, 因而须对轨迹真实性

进行量化评估,本文采用的轨迹真实性量化评估方法如式(15)所示。

$$T_{\text{real}} = \sum_{i=1}^{t_{\text{count}}} \frac{RMSE(X_i, Y_i)}{t_{\text{count}}} \quad (15)$$

式中: T_{real} 代表模型轨迹的真实性量化评价结果; X_i 为交通车模型轨迹; Y_i 为自然驾驶数据库中与 X_i 均方根误差最小的匹配轨迹。 T_{real} 的值越小代表模型轨迹与真实轨迹匹配效果越好,模型输出轨迹的真实性越高。

2.2 交通车模型性能验证

2.2.1 个性化跟驰模型交互效果验证

选取HighD数据集中3类驾驶风格的长时序跟车数据,前车被赋予自然驾驶数据中真实的运动状态,后车分别采用本文提出的跟驰模型、智能驾驶模型(intelligent driver model, IDM)^[14]、长短时记忆网络(long short term memory, LSTM)构建的跟驰模型^[15],选定场景初始状态,跟驰模型通过历史运动参数实时更新车辆运动状态,将个性化跟驰模型的运动信息与真实信息进行比较来验证模型的交互效果。

为公平地在本文使用的数据集上进行比较,选取IDM模型、LSTM构建跟驰模型的参数分别如表6和表7所示。

不同跟驰模型的运动信息如图2所示。利用RMSE来衡量不同跟驰模型运动信息与真实运动信

表6 IDM模型参数设置

参数	激进型	一般型	保守型
$a/(m \cdot s^{-2})$	3.0	1.5	1.0
$b/(m \cdot s^{-2})$	1.0	1.0	1.0
T/s	1.9	1.9	1.9
$v_0/(m \cdot s^{-1})$	39.4	28.8	24.0
s_0/m	2.0	2.0	2.0

表7 LSTM模型训练参数设置

参数	数值
输入序列维度	4
输出序列维度	1
隐藏层神经元个数	128
学习率	0.0005
网络层数	3
Dropout	0.1
迭代次数	30
Batch_Size	64

息之间的差异, RMSE信息统计如表8所示。

结果表明,本文构建的个性化跟驰模型能够有效提取出自然驾驶数据中真实的交互特性,且3类个性化跟驰模型的交互效果均好于IDM和LSTM模型,以此验证了模型的交互效果。应当指出,虽然Transformer模型部分结果的RMSE与LSTM模型较为相近,但前者提取的交互特性与实际驾驶状态更加相符,细节表达更加充分。

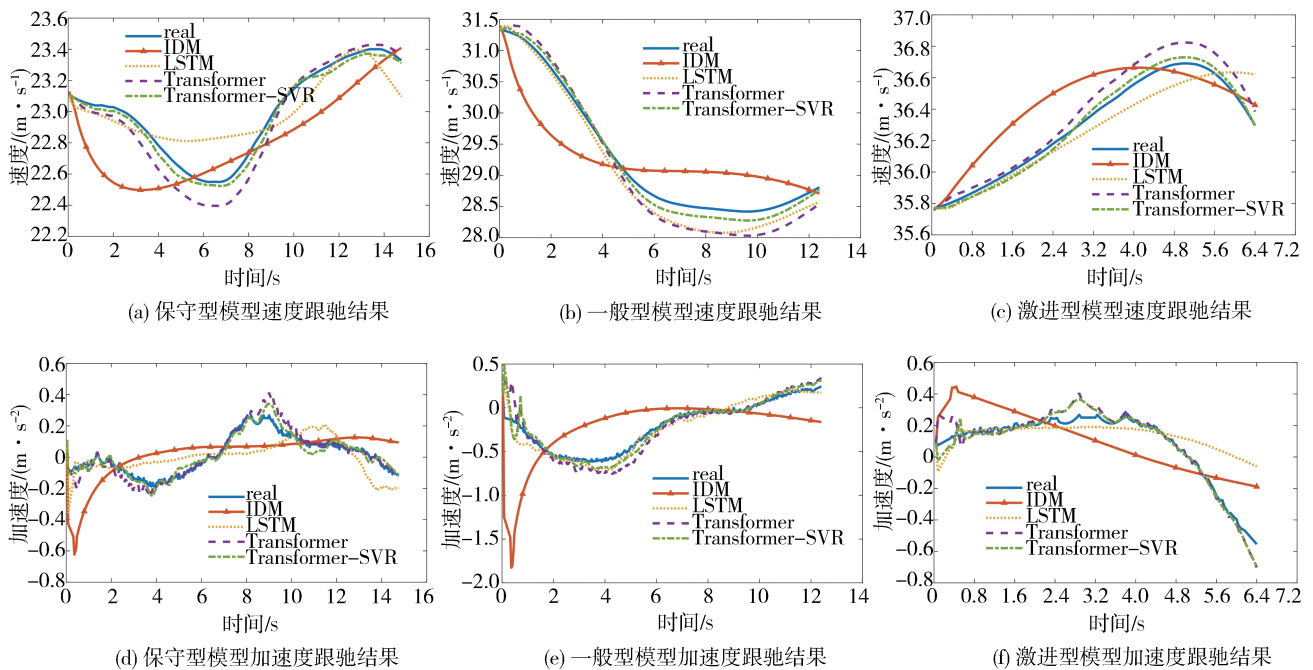


图2 跟驰模型交互效果验证结果

表8 RMSE信息统计

模型	速度RMSE			加速度RMSE		
	激进型	一般型	保守型	激进型	一般型	保守型
IDM	0.196	0.596	0.247	0.173	0.405	0.155
LSTM	0.100	0.238	0.139	0.163	0.080	0.110
Transformer	0.094	0.279	0.100	0.057	0.107	0.043
Transformer-SVR	0.033	0.109	0.035	0.046	0.084	0.033

2.2.2 交通车模型轨迹合理性验证

在评价交通车轨迹合理性前,须由前车及场景初始状态作为激励,使交通车生成大量轨迹数据,场景如图3所示。 x_{bv} 为交通车位置, x_{front} 为前车位置, v_{bv} 为交通车速度, v_{front} 为前车速度, d 为两车间的距离。从自然驾驶跟车场景库中随机选取6000条跟车场景作为原始数据,并将跟车场景的时序长度统一为4s,以交通车初始位置 x_{bv0} 、前车初始位置 x_{front0} 、前车全时序速度 v_{front} 及交通车初始速度 v_{bv0} 作为输入激励,通过赋予个性化跟驰模型一组固定的权值系数($\lambda_1, \lambda_2, \lambda_3$)作为交通车的跟驰策略,以此跟随前车运动并得到动态场景数据,每组权值系数在原始场景数据的基础上生成等量的场景数据。




图3 交通车跟驰场景

本文通过随机赋予1、3、6、10组不同的权重系数,使得交通车模型分别生成6000条、18000条、36000条、60000条轨迹数据,分别标记为 $G=N$ 、 $G=3N$ 、 $G=6N$ 、 $G=10N$,用以验证交通车轨迹的合理性。

以上述交通车轨迹数据为基础对轨迹合理性进行评价,利用移动平均法对原始参数曲线进行平滑处理,窗口大小设置为20,由此分别计算 $G=N$ 、 $G=3N$ 、 $G=6N$ 、 $G=10N$ 时交通车输出轨迹的合理性,评价结果依次为0.918、0.898、0.883、0.862。

结果表明,随着交通车轨迹数量增加,交通车轨迹的合理性并未出现明显降低,说明多元权值分配方式并未使交通车模型输出的轨迹出现剧烈变动,能够生成符合实际驾驶情况的轨迹。

2.2.3 交通车模型轨迹多样性验证

利用上述交通车轨迹数据对轨迹多样性进行评价,以此得到轨迹多样性量化评价结果: $G=N$ 、 $G=3N$ 、 $G=6N$ 、 $G=10N$ 时交通车轨迹多样性分别为0.449、0.598、0.654、0.702。

随着轨迹数量的增加,交通车模型轨迹的多样性得到了提高,表明通过多元权值分配的方式交通车模型产生了更加多样化的驾驶行为,并未输出趋于均值的同质化轨迹,轨迹的多样性得到了保证。

2.2.4 交通车模型轨迹真实性验证

利用上述交通车轨迹数据对轨迹真实性进行评价,以此得到轨迹真实性量化评价结果: $G=N$ 、 $G=3N$ 、 $G=6N$ 、 $G=10N$ 时交通车轨迹真实性分别为0.205、0.254、0.315、0.427,并在图4中绘制模型轨迹与自然驾驶轨迹匹配结果。

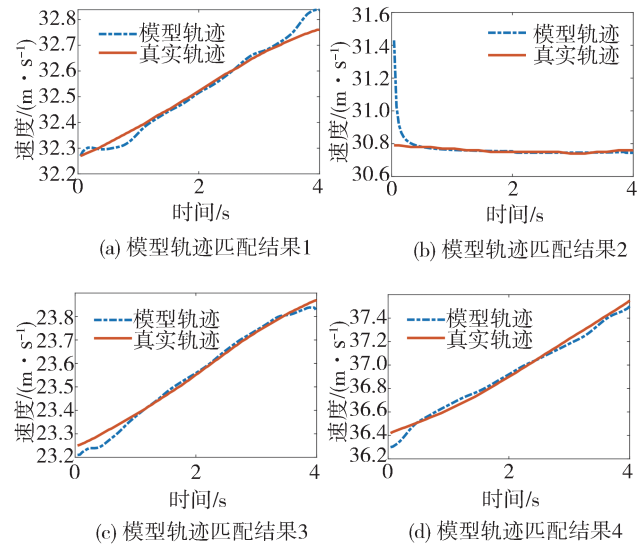


图4 模型轨迹与自然驾驶轨迹匹配结果

由量化评价结果可以看出,当轨迹数量达到 $G=10N$ 时,交通车速度轨迹与真实自然驾驶速度轨迹匹配的平均RMSE为0.427 m/s,表明模型轨迹能够与真实轨迹进行较好地匹配,模型轨迹真实性得到了有效保障,但由于权值耦合的方式,模型在某些初始状态下的运动可能会存在过渡阶段,因而会导致轨迹匹配的RMSE增大,如图4(b)所示,待模型达到稳定跟驰状态后仍可与真实轨迹进行匹配。

2.2.5 交通车模型输出轨迹效果

为展示交通车模型在不同权值系数下的跟驰特性,同样采取如图3所示的跟驰场景,选取一段长达10s的前车运动轨迹,如图5所示。




图5 前车速度变化曲线

接下来选择场景初始状态:交通车初始速度 $v_{b,0}=34$ m/s、两车间初始距离 $d=60$ m,交通车分别采取 $(0.1, 0.1, 0.8)$ 、 $(0.3, 0.3, 0.4)$ 、 $(0.8, 0.1, 0.1)$ 3组权值系数,不同权值系数下的交通车跟驰效果如图6所示。

由图6可以看出,具有不同权值系数的交通车模型具有明显不同的跟驰特性,激进型跟驰模型被赋予较高的系数时,倾向于与前车在较小跟驰距离且相对较大的速度下进行交互,交互行为也更加激进,而保守型跟驰模型在赋予较高的系数时表现则相反。应当指出,不同特性的交通车模型均会经历一个过渡阶段,交通车速度迅速变化至对应于其驾驶风格的速度值附近以保持与前车之间的距离,之后不断调整自身驾驶行为与前车在一定的跟驰距离

范围进行交互。

3 面向智能驾驶测试的模型应用

为验证交通车模型具有不同的轨迹输出特性时会使智能驾驶系统产生不同的行为响应,搭建 PreScan/MATLAB/Simulink 联合仿真平台,将交通车模型用于待测系统的性能测试,考虑到智能驾驶系统首先要保证其安全性能,因而本文选择自动紧急制动系统作为待测对象。

采用的 AEB 功能如下:通过传感器检测前方车辆,实时计算与前车之间的碰撞时间 (time to collision, TTC) 来调整算法的工作模式,根据不同的 TTC 范围存在 3 种工作模式:(1)未触发制动,当 $TTC < 0$ 或 $TTC \geq 1.8$ s 时, AEB 未触发制动行为,主车以 -0.5 m/s² 的减速度匀减速行驶;(2)部分制动,当 0.8 s \leq $TTC < 1.8$ s 时, AEB 触发 40% 制动;(3)完全制动,当 $0 \leq$ $TTC < 0.8$ s 时, AEB 触发 100% 制动。

考虑如图7所示的跟驰场景,前前车固定运动状态引导不同权值系数的交通车输出不同跟驰特性的轨迹参数,以公平比较待测系统性能响应的差异,从左至右依次为具有 AEB 算法的主车、前车(本文提出的交通车模型)、前前车, x_{ego} 为主车位置, x_{front} 为前车位置, x_{lead} 为前前车位置, v_{ego} 为主车速度, v_{front} 为




图6 不同权值系数下的交通车跟驰效果

前车速度, v_{lead} 为前前车速度, d_1 为主车与前车间的距离, d_2 为前车与前前车的距离。

前前车的运动参数提前给定, 采用时长 10 s 且速度从 35 到 25 m/s 的匀减速运动曲线, 对前车设置不同的权值系数 (0.1, 0.1, 0.8)、(0.3, 0.3, 0.4)、




图7 智能驾驶系统跟驰场景




图8 交通车不同输出特性下主车安全性量化结果

由图8(a)可以看出, 交通车采用较为保守的权重系数时, 交通车在较低速度、较大跟驰距离下与前前车交互, 而与主车距离相对较近, 主车速度较低时也可能产生较高的风险, 危险性较高的场景参数主要集中于主车初始速度在 30~44 m/s、两车间距离在 13~50 m 的区域, 如图8(c)所示。当交通车采用较为激进的权重系数时, 交通车在较高速度、较小跟驰距离下与前前车交互, 而与主车距离相对较远, 主车速度较低时风险性较小, 危险性较高的场景参数主要集中于主车初始速度在 34~44 m/s、两车间距离在 13~25 m 的区域, 且当交通车轨迹特性由保守向激进变化时, 危险区域存在明显的演化规律。

上述结果表明, 在不同的交通车轨迹特性激励下, 主车会产生明显不同的行为响应, 相较于交通车单一轨迹特性, 利用本文构建的可变跟驰特性交通车模型能够实现更高覆盖度的性能测试。同时, 通过权值系数的变化能够改变交通车轨迹特性进而揭示待测系统安全性能的变化规律, 建立交通车权值

(0.8, 0.1, 0.1), 用于测试主车 AEB 算法的输出行为响应, 其他场景初始参数设置如下: 前车与前前车的初始距离 d_{20} 为 50 m, 前车初速度 v_{front0} 为 35 m/s。

接下来设定一个场景参数空间, 主车初速度 v_{ego0} 取值为 [20 m/s, 44 m/s], 间隔为 3 m/s, 主车与前前车的初始距离 d_{10} 取值为 [13 m, 79 m], 间隔为 3 m, 在该场景参数空间下遍历测试交通车 3 组不同特性的轨迹对主车安全性能的影响, 不同权值系数下的主车安全性响应如图8所示。当 $TTC_{max} < 0$ 时, 表明在场景时序过程中主车速度始终小于交通车, 不会发生危险, 在图8中以较大的正向 TTC_{min} 值进行代替, 以方便展示不同场景参数下主车安全性的量化结果。

系数与给定参数空间下危险区域的映射关系, 能够有效指导智能驾驶系统的性能测试。

同时通过多场景要素的耦合作用, 即模型合理、多样且真实的轨迹与主车初速度、两车间初始距离等参数相互组合, 能够模拟典型场景乃至极端驾驶场景, 不断测试待测系统的极限性能, 提升其性能边界, 以确保现实世界应用时足够可靠。

本文中以 $TTC_{min} = 1.6$ s 作为场景关键性阈值, 在如图8所示的场景参数空间中以红色矩形框包含所有 $0 < TTC_{min} < 1.6$ s 的关键场景, 将其视为有效测试区域。由图8可以看出, 在测试过程中可以根据前车轨迹特性对应选取主车待测试的场景参数空间大致范围, 特别是对于高维场景参数空间, 能够有效避免算力浪费, 极大提高测试效率。

进一步地, 重点关注主车在有效测试区域场景参数下行为响应的差异, 在有效测试区域内主车跟随不同输出特性交通车行驶时, 触发主车不同响应模式的概率如图9所示。




图9 交通车不同输出特性下主车响应模式统计

由图9可以看出,在有效测试区域内即介于危险与安全之间的边界场景附近,主车触发不同响应模式的概率明显不同,在前车轨迹特性较为保守时,主车未触发制动概率最高,且在多数情况下仅触发或首先触发40%制动行为,较少出现直接触发100%制动的紧急情况,而在前车行驶特性较为激进时,边界场景附近主车的行驶速度较高且会受到前车激进交互行为的影响,未触发制动概率最低,且大多数情况下直接触发100%制动以应对前车激进的驾驶行为。

图9进一步说明在不同轨迹特性的激励下,主车在边界场景附近的响应模式不尽相同,根据前车轨迹特性高效选取场景参数空间范围,能够快速发现大量的边界场景,可以更加有针对性、高效地测试智能驾驶系统不同维度上的潜在性能缺陷,确保智能驾驶系统能够面对复杂交通环境。

4 结论

针对现有测试进程中交通车轨迹特性单一的问题,提出一种面向智能驾驶测试的可变跟驰特性交通车建模方法,基于PCFM构建输出特性可调节的交通车模型,且交通车能够输出合理、多样且真实的动态时序轨迹数据;通过搭建联合仿真平台并引入待测AEB算法,探究交通车模型不同输出特性对智能驾驶系统性能的影响,结果表明不同轨迹特性激励下的待测系统会产生明显不同的行为响应,且不同轨迹特性对待测系统性能的影响具有明显的演化规律,未来研究将交通车模型拓展用于自适应巡航系统(adaptive cruiser control, ACC)性能的测试验证。本文具体贡献如下。

(1)通过分析现有跟驰模型的局限性,以Transformer架构为基础,配合SVR误差补偿器构建了3类具有高真实交互特性的个性化跟驰模型,并通过个性化跟驰模型的多元权值分配,得到具有可变跟驰特性的交通车模型,以权值系数控制交通车模型的输出特性。

(2)建立了交通车模型输出轨迹合理性、多样性及真实性评价方法,结果表明交通车模型输出轨迹能够保持较高的合理性、多样性及真实性,且不同权值系数下的输出轨迹能够明显展现出不同的跟驰特性。

参考文献

- [1] HU X, ZHENG Z, CHEN D, 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.
- [2] 朱冰, 张培兴, 赵健, 等. 基于场景的自动驾驶汽车虚拟测试研究进展[J]. *中国公路学报*, 2019, 32(6): 1-19.
ZHU B, ZHANG P X, ZHAO J, et al. Review of scenario-based virtual validation methods for automated vehicles[J]. *China Journal of Highway and Transport*, 2019, 32(6): 1-19.
- [3] MA L, QU S, REN J, et al. Mixed traffic flow of human-driven vehicles and connected autonomous vehicles: string stability and fundamental diagram [J]. *Math. Biosci. Eng.*, 2023, 20: 2280-2295.
- [4] YAO Z, WU Y, WANG Y, et al. Analysis of the impact of maximum platoon size of CAVs on mixed traffic flow: an analytical and simulation method [J]. *Transportation Research Part C: Emerging Technologies*, 2023, 147: 103989.
- [5] XIE Y Z, ZHANG Y, DAI K P, et al. A real-time critical-scenario-generation framework for defect detection of autonomous driving system [J]. *IET Intelligent Transport Systems*, 2023: 1-15.
- [6] FENG S, SUN H, YAN X, et al. Dense reinforcement learning for safety validation of autonomous vehicles [J]. *Nature*, 2023, 615(7953): 620-627.
- [7] ZHU B, ZHANG P X, ZHAO J, et al. Hazardous scenario enhanced generation for automated vehicle testing based on optimization searching method [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(7): 7321-7331.
- [8] ZHU B, SUN Y, ZHAO J, et al. A critical scenario search method for intelligent vehicle testing based on the social cognitive optimization algorithm [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(8): 7974-7986.
- [9] KRAJEWSKI R, BOCK J, KLOEKER L, et al. The highd Dataset: a drone dataset of naturalistic vehicle trajectories on German highways for validation of highly automated driving systems [C]. 2018 21st International Conference on Intelligent Transportation Systems (ITSC), 2018.

(下转第1982页)

- arXiv: 2112.02604, 2021.
- [13] RASOULI A, KOTSERUBA I, KUNIC T, et al. Pie: a large-scale dataset and models for pedestrian intention estimation and trajectory prediction [C]. Proceedings of the IEEE/CVF International Conference on Computer Vision, 2019: 6262–6271.
- [14] WANG C, WANG Y, XU M, et al. Stepwise goal-driven networks for trajectory prediction [J]. IEEE Robotics and Automation Letters, 2022, 7(2): 2716–2723.
- [15] NEUMANN L, VEDALDI A. Pedestrian and ego-vehicle trajectory prediction from monocular camera [C]. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition, 2021: 10204–10212.
- [16] SU Y, LI Y, WANG W, et al. A unified environmental network for pedestrian trajectory prediction [C]. Proceedings of the AAAI Conference on Artificial Intelligence, 2024, 38(5): 4970–4978.
- [17] FU Z, JIANG K, XIE C, et al. Summary and reflections on pedestrian trajectory prediction in the field of autonomous driving [J]. IEEE Transactions on Intelligent Vehicles, 2024.
- [18] HASAN F, HUANG H. MALS-Net: a multi-head attention-based LSTM sequence-to-sequence network for socio-temporal interaction modelling and trajectory prediction [J]. Sensors, 2023, 23(1): 530.
- [19] 桑海峰, 赵梓杉, 王金玉, 等. 基于车辆轨迹预测对抗性攻击与鲁棒性研究 [J]. 汽车工程, 2024, 46(3): 407–417.
SANG H F, ZHAO Z S, WANG J Y, et al. Research on adversarial attacks and robustness in vehicle trajectory prediction [J]. Automotive Engineering, 2024, 46(3): 407–417.
- [20] DAI J, QI H, XIONG Y, et al. Deformable convolutional networks [C]. Proceedings of the IEEE International Conference on Computer Vision, 2017: 764–773.
- [21] DU J, WANG S, MIAO H, et al. Multi-channel pooling graph neural networks [C]. IJCAI. 2021: 1442–1448.
- [22] GROSSBERG S. Recurrent neural networks [J]. Scholarpedia, 2013, 8(2): 1888.
- [23] GRAVES A, GRAVES A. Long short-term memory [J]. Supervised Sequence Labelling with Recurrent Neural Networks, 2012: 37–45.
- [24] RASOULI A, KOTSERUBA I, TSOTSOS J K. Are they going to cross? a benchmark dataset and baseline for pedestrian crosswalk behavior [C]. Proceedings of the IEEE International Conference on Computer Vision Workshops, 2017: 206–213.
- [25] KOSARAJU V, SADEGHIAN A, MARTÍN-MARTÍN R, et al. Social-bigat: multimodal trajectory forecasting using bicycle-gan and graph attention networks [J]. Advances in Neural Information Processing Systems, 2019, 32.
- [26] YAO Y, XU M, WANG Y, et al. Unsupervised traffic accident detection in first-person videos [C]. 2019 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2019: 273–280.
- [27] HE Y, YANG Y, CAI Y, et al. Predicting pedestrian tracks around moving vehicles based on conditional variational transformer [J]. Proceedings of the Institution of Mechanical Engineers, Part D: Journal of Automobile Engineering, 2023: 09544070231175536.
- [28] RASOULI A, KOTSERUBA I. PedFormer: pedestrian behavior prediction via cross-modal attention modulation and gated multi-task learning [C]. 2023 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2023: 9844–9851.
- [29] WANG J, SANG H, CHEN W, et al. VOSTN: variational one-shot transformer network for pedestrian trajectory prediction [J]. Physica Scripta, 2024, 99(2): 026002.

~~~~~

(上接第1961页)

- [10] LABRIN C, URDINEZ F. Principal component analysis [M]. R for Political Data Science. Chapman and Hall/CRC, 2020: 375–393.
- [11] SANAGA K P, YANG M S. Unsupervised K-means clustering algorithm [J]. IEEE Access, 2020, 8: 80716–80727.
- [12] HAN K, XIAO A, WU E, et al. Transformer in transformer [J]. Advances in Neural Information Processing Systems, 2021, 34: 15908–15919.
- [13] OKK AN U, SERBES Z A. Rainfall-runoff modeling using least squares support vector machines [J]. Environmetrics, 2012, 23(6): 549–564.
- [14] TREIBER M, HENNECKE A, HELBING D. Congested traffic states in empirical observations and microscopic simulations [J]. Physical Review E, 2000, 62(2): 1805.
- [15] LIU L, FENG S, FENG Y, et al. Learning-based stochastic driving model for autonomous vehicle testing [J]. Transportation Research Record, 2022, 2676(1): 54–64.