

自动驾驶拟人连续交互测试场景生成方法*

朱冰¹, 范天昕¹, 赵健¹, 张培兴¹, 宋东鉴¹, 薛越¹, 赵文博²

(1. 吉林大学, 汽车底盘集成与仿生全国重点实验室, 长春 130025;

2. 北汽(北京)智能网联汽车研究院有限公司, 北京 102600)

[摘要] 基于场景的仿真测试方法是自动驾驶汽车安全性验证的重要手段,然而当前测试场景生成方法多输出独立场景片段,如何模拟真实人类驾驶过程生成具有一定挑战的连续交互测试场景已成为自动驾驶测试评价亟须攻克的难题。本文提出了一种自动驾驶拟人连续交互测试场景生成方法。首先建立自动驾驶拟人连续交互测试场景生成架构,并基于HighD数据集进行车辆运动行为分析;在此基础上,基于轨迹相似性特征分析被测自动驾驶汽车当前行为,并通过状态转移矩阵预测其未来轨迹;基于轨迹交互规则确定测试场景中交通车未来行为类型,通过Transform网络架构生成交通车拟人连续交互轨迹;最后,在仿真环境中对生成测试场景的危险性、拟人性等关键性能进行评估,证明了本文方法的有效性。

关键词: 自动驾驶;连续交互测试场景;轨迹预测;拟人交互轨迹生成

Generation Method for Anthropomorphic Continuous Interactive Test Scenarios of Automated Driving

Zhu Bing¹, Fan Tianxin¹, Zhao Jian¹, Zhang Peixing¹, Song Dongjian¹,
Xue Yue¹ & Zhao Wenbo²

1. Jilin University, National Key Laboratory of Automotive Chassis Integration and Bionics, Changchun 130025;

2. China Intelligent and Connected Vehicles (Beijing) Research Institute Co., Ltd., Beijing 102600

[Abstract] Scenario-based simulation test method is an important means of automated driving vehicle safety verification; however, current test scenarios generation methods are mostly for independent scenarios. How to simulate the human real driving process to generate continuous interactive test scenario with challenges has become a problem that needs to be solved urgently in automated driving test evaluation. In this paper, an automated driving anthropomorphic continuous interactive test scenarios generation method is proposed. Firstly, the architecture for anthropomorphic continuous interactive test scenarios generation is established, and the vehicle motion behavior analysis is conducted based on the HighD dataset. On this basis, the current behavior of tested automated driving vehicle based on the trajectory similarity feature is analyzed, and the prediction of the future trajectory through the state transfer matrix is realized. Then, the type of the future behaviors of the traffic vehicles based on the trajectory interaction rules are determined, and the specific trajectory is generated by Transform network. Finally, the key performance indicators such as danger and anthropomorphism of the generated test scenarios are evaluated in simulation test environment, which proves the effectiveness of the method proposed in this paper.

Keywords: automated driving; continuous interactive test scenario; trajectory prediction; anthropomorphic interactive trajectory generation

* 国家自然科学基金(U22A20247)、国家重点研发计划项目(2022YFB2503402)、中国博士后科学基金(2023M741354)和国家资助博士后研究人员计划(GZC20230945)资助。

原稿收到日期为2024年07月01日,修改稿收到日期为2024年07月24日。

通信作者:张培兴,助理研究员,博士,E-mail:zhangpeixing@jlu.edu.cn。

前言

自动驾驶汽车是汽车科技发展的潮流与趋势,科学完善的测试评价体系是保障自动驾驶汽车安全上路的基础^[1-2]。基于场景的测试方法已成为自动驾驶汽车性能验证的重要手段^[3-4],其核心在于如何生成丰富的测试场景。然而当前测试场景生成方法多输出独立场景片段,如何生成连续交互测试场景从而验证自动驾驶汽车在实际交通环境中的表现已得到越来越多的关注^[5]。

连续交互测试场景是指在自动驾驶汽车测试过程中通过预测被测车辆行为而主动控制交通车产生具有连续交互特性的测试场景。由于具有长时序特征,连续交互测试场景相比独立测试场景更能准确反映被测自动驾驶汽车决策控制策略在真实服役条件下的综合性能,同时还能有效避免独立测试场景初始状态不可达的问题^[6]。国内外学者已对相关内容开展了一些初步研究,李江坤等^[7]提出了一种基于场景动力学和强化学习的连续场景生成方法并筛选了其边缘场景;Feng等^[8]将自然驾驶场景参数重要性进行分类并在交通环境中进行场景连续生成;Rodrigo等^[9]针对自动驾驶汽车连续测试建立了交通车交互控制模型;潘春燕^[10]基于连续交通流完成了自动驾驶汽车的测试评价。上述方法以筛选危险场景为最终目标实现自动驾驶汽车连续测试场景生成,但其生成过程缺乏考虑车辆运动交互过程的拟人性,导致边缘场景可能与自动驾驶汽车上路后的真实驾驶过程不符^[11-12]。综上,在交通车拟人交互的基础上提升场景的危险性,生成可有效验证自动驾驶汽车性能边界的连续交互测试场景是解决自动驾驶汽车测试难题的重要方式。

本文提出一种自动驾驶拟人连续交互测试场景生成方法。首先分析自然驾驶数据获取真实人类驾驶过程中车辆的运动轨迹;在此基础上,建立被测自动驾驶汽车轨迹预测模型;然后,建立交通车拟人交互轨迹模型,实现拟人连续交互测试场景生成;最后,在Prescan环境中对交互测试场景生成交互效果进行验证,分析本文提出方法在生成场景拟人性及危险性方面的有效性。

1 算法架构及数据分析

1.1 算法架构

本文提出的自动驾驶拟人连续交互测试场景生

成架构如图1所示,包括车辆运动行为分析、自动驾驶汽车轨迹预测、交通车拟人交互轨迹生成3部分。

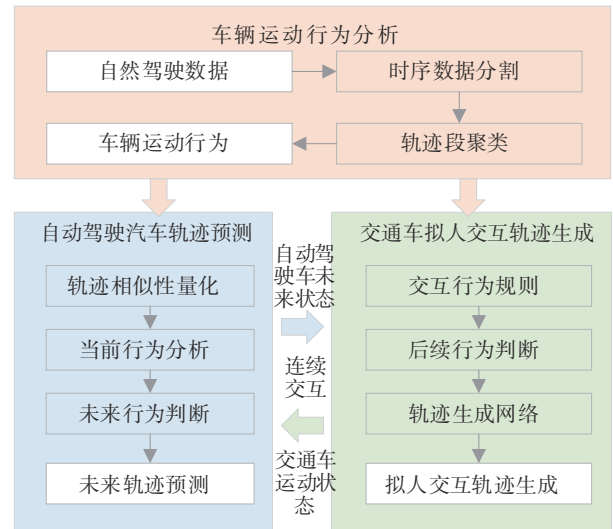


图1 拟人连续交互测试场景生成架构

车辆运动行为分析是进行自动驾驶汽车轨迹预测与交通车轨迹生成的基础。本文首先基于时序数据分割及聚类方法对自然驾驶数据中隐含的车辆运动行为进行分析,获取不同车辆运动行为对应的轨迹段特征。随后,基于欧式距离对被测自动驾驶汽车当前运动行为进行分析,并根据自然驾驶数据中的车辆运动行为转换概率对自动驾驶汽车未来的状态及位置进行预测。针对被测自动驾驶汽车未来的不同行为及交通车对应自动驾驶汽车的相对位置,本文建立交通车行为规则以生成具有对被测自动驾驶汽车交互影响的交通车行为,并基于自然驾驶数据中的车辆运动行为使用Transformer网络建立不同车辆运动行为对应的轨迹生成模型,通过被测自动驾驶汽车与交通车之间位置的循环迭代,实现连续交互测试场景的生成。

由于交通车行为规则的目标在于与被测自动驾驶汽车产生轨迹交互,这可以提升被测自动驾驶汽车与交通车之间的碰撞风险,从而提升场景的风险性;此外,由于交通车轨迹生成模型是基于人类驾驶数据训练的Transformer网络,这可以确保交通车行为符合人类驾驶特征,即保证了连续测试场景的拟人性。

1.2 车辆运动行为分析

车辆运动行为分析是进行拟人连续交互测试场景生成的第一步。由于自然驾驶数据具有典型的时

间持续特征,本文首先基于时序数据分割算法对自然驾驶时序数据进行分割,在此基础上通过轨迹段聚类方法将具有相似特征的轨迹进行聚类,从而获取车辆运动行为。HighD数据集是进行车辆运动轨迹分析的常用数据集,本节分析内容基于HighD中的数据展开。

1.2.1 自然驾驶时序数据分割

自然驾驶时序数据分割的目的在于将自然驾驶连续道路行驶轨迹进行切割,获得独立的车辆运动行为片段,为后续车辆运动行为聚类及分析提供基础。

本文选择基于贪心的贝叶斯凝合式序列分割(bayesian model-based agglomerative sequence segmentation, BMASS)算法^[9]进行时序数据分割。

对于一段驾驶时序数据 $seq = \{(x_1, y_1), (x_2, y_2), (x_3, y_3), \dots, (x_n, y_n)\}$, 其中 $x_i \in \mathbf{R}^{p \times 1}$ 为采样时间, $y_i \in \mathbf{R}^{q \times 1}$ 为时间序列数据。当 y 对 x 的回归只在某一段区间内服从某种斜率的线性回归模型,而在其他区间内则服从不同斜率的线性回归模型时,则可使用分段线性回归模型进行序列数据分析。这与自然驾驶轨迹分析具有较强的相似性。BMASS算法首先将所有时间点都看作一个独立线性回归模型,计算相邻段合并的边际似然值,将最大值产生的位置作为凝合点合并,并持续迭代,通过凝合迭代方式将序列段一一合并,直至对数似然为负数或所有段都已合并,从而完成自然驾驶数据分割。

对于序列 $seq = \{seq_1, seq_2, seq_3, \dots, seq_i\}$, 若将其中的 seq_i 与 seq_{i+1} 合并成 $seq_i \cup seq_{i+1}$, 则 seq 与其凝合后的序列 $seq_h = \{seq_1, seq_2, seq_3, \dots, seq_i \cup seq_{i+1}, \dots, seq_s\}$ 的边际似然为

$$p(seq | seq_h) = \frac{1}{(2\pi)^{nq/2}} \frac{\phi(seq_i \cup seq_{i+1})}{\phi_0^{s-1}} \prod_{j=1, j \neq i}^s \phi(seq_j) \quad (1)$$

式中: ϕ_0 为归一化常数,根据分段线性回归模型特征进行计算; $\phi_0(\cdot)$ 代表每个分段的后验归一化系数。

迭代过程中每个凝合点的似然为

$$p(seq_i \cup seq_{i+1}) = \lambda \phi_0 \frac{\phi(seq_i \cup seq_{i+1})}{\phi(seq_i)\phi(seq_{i+1})} \quad (2)$$

式中 λ 为凝合点与非凝合点的比例系数。

分割后的轨迹段时序长度分布如图2所示,图中横坐标为轨迹段的长度 s ,纵坐标为该长度的轨迹段数量。




图2 轨迹段长度分布

1.2.2 轨迹段聚类及分析

在完成轨迹段分割之后,通过聚类方法分析轨迹段之间的相似规律,从而获取典型的车辆运动行为,用于后续轨迹预测及生成过程。本文采用高斯混合模型-隐狄利克雷分配模型(Gaussian mixture model-latent Dirichlet allocation, GMM-LDA)将前文得到的轨迹段进行聚类^[10],其中GMM模块完成轨迹段数据的降维表征,LDA算法进行语义挖掘聚类。由于GMM当前已经较为成熟,此处不再进行赘述,后文重点介绍轨迹段聚类过程。

不同轨迹中各个基础交通行为类别的出现次数和不同基础交通行为类别中轨迹采样点的出现次数符合多项式分布:

$$t_m = Multi(n | \tau_m, N_m) = \binom{N_m}{n} \prod_{i=1}^K \tau_m^{n_i} \quad (3)$$

$$w_m = Multi(k | \gamma_k, K) = \binom{K}{k} \prod_{i=1}^K \gamma_k^{n_i} \quad (4)$$

式中: t_m 代表第 m 个轨迹段中的基础交通行为类别分布; w_k 代表第 k 个基础交通行为类别的采样点分布; τ_m 是 t_m 分布的分布参数; γ_k 是 w_k 分布的分布参数; N_m 代表第 m 个轨迹段中的采样点数量; K 代表所有基础交通行为的数量; V 代表所有采样点数量。

将 τ_m 和 γ_k 均设为狄利克雷分布,则所有基础交通行为集合的似然概率公式如下:

$$p(W) = \prod_{m=1}^M \prod_{n=1}^{N_m} \sum_{k=1}^K p(t_{m,n} = k | \tau_m) \cdot p(w_{k,n} | t_{m,n} = k, \gamma_k) \quad (5)$$

式中: $t_{m,n}$ 代表第 m 个轨迹段的第 n 个采样点; $w_{k,n}$ 代表第 k 个基础交通行为的第 n 个采样点。可以看出,求解轨迹段集合的似然概率需要累乘所有轨迹段中采样点生成概率,单个采样点的生成概率为采样点对应基础交通行为类别的边缘概率。

参考相关研究^[11],将基础交通行为类别数量设定为5,聚类得到的基础交通行为横纵向速度加速

度统计信息如表1所示。

表1 基础交通行为横纵向速度加速度统计表

行为类别	统计量	纵向速度	横向速度	纵向加速度	横向加速度
类别1	均值	22.72	-0.0001	-0.03	-0.0105
	方差	21.69	0.0109	0.02	0.0046
	中位数	24.12	0.0013	-0.06	0.0000
类别2	均值	27.29	0.0026	0.08	-0.0029
	方差	236.19	0.0119	0.04	-0.0046
	中位数	31.13	0.0102	0.08	0.0000
类别3	均值	24.16	-0.0061	0.03	0.0000
	方差	1.71	0.0066	0.01	0.0026
	中位数	24.17	0.0114	0.03	0.0100
类别4	均值	31.73	0.0612	0.15	0.0028
	方差	3.57	0.2487	0.09	0.0035
	中位数	31.96	0.0400	0.15	0.0100
类别5	均值	25.63	-0.0736	0.23	0.0057
	方差	11.74	0.2675	0.16	0.0398
	中位数	25.36	-0.0397	0.16	0.0100

基础交通行为1是一类纵向速度较低、纵向加速度变化范围较大、横向速度加速度变化范围均很小的类型,可描述成一种低速直道行驶的驾驶策略;行为2是一类纵向速度较高、纵向加速度变化范围较大、横纵向速度加速度变化范围均很小的类型,可以抽象描述成一种高速直道行驶的轨迹片段;行为3是一类纵向速度较低、纵向加速度变化范围较小、横向速度加速度变化范围均很小的类型,抽象描述成一种低速车道保持的轨迹片段;行为4是一类纵向速度较高、纵向加速度变化范围较大、横向速度加速度的变化范围也较大的类型,抽象描述成一类高速变道的轨迹片段;行为5是一种纵向速度较低、纵向加速度与横向速度加速度变化范围均较大的类型,抽象描述成一类低速变道的轨迹片段。

2 被测自动驾驶汽车轨迹预测

2.1 当前行为分析

当前交通行为分析是自动驾驶汽车未来行为预测的基础与前提,本文通过计算当前自动驾驶汽车3s的行驶轨迹与1.2节中分割获取的自然驾驶轨迹的相似性获取其当前交通行为。

通过欧氏距离计算轨迹相似度的方法主要计算两条轨迹序列每个时间步下对应点的欧氏距离均

值,如式(6)所示:

$$EU = \frac{1}{n} \sum_{k=1}^n \sqrt{(p_{k,x}^A - p_{k,x}^B)^2 + (p_{k,y}^A - p_{k,y}^B)^2} \quad (6)$$

式中: $p_{k,x}^A$ 、 $p_{k,x}^B$ 分别代表曲线A和曲线B在k时刻的x方向位置; $p_{k,y}^A$ 、 $p_{k,y}^B$ 分别代表曲线A和曲线B在k时刻的y方向位置。使用欧式距离计算轨迹的相似度要求两条轨迹在时间和采样个数上相同。

由于一些距离近的位置点可以轻易地补偿距离远的位置点,为使距离远的位置点难以补偿,进一步使用欧氏距离四次方的均值作为相似度的评价指标:

$$EU_{\text{quartic}} = \frac{1}{n} \sum_{k=1}^n \left((p_{k,x}^A - p_{k,x}^B)^2 + (p_{k,y}^A - p_{k,y}^B)^2 \right)^2 \quad (7)$$

由于车辆轨迹的横向位置和纵向位置尺度变化较大,若直接进行相似度求解,会使得横纵向位置对结果的影响差别较大,所以在实际计算过程中还需要根据轨迹段横纵向长度将轨迹横纵向归一化处理。

2.2 未来交通行为预测

统计1.2节中获取到的不同基础交通行为持续时长及该行为后续所连接的基础交通行为类型,建立基础交通行为转换矩阵。

当前基础交通行为自转移概率为

$$A_{ii} = n_{\text{end}} / n_{\text{all}} \quad (8)$$

式中: n_{end} 为该类基础交通行为持续时长低于该行为当前持续时长的轨迹段数量; n_{all} 为该类基础交通行为为所有的轨迹段数量。

由该类基础交通行为转变为其它某类基础交通行为的转移概率为

$$A_{ij} = (1 - A_{ii}) \times n_{ij} / n_{\text{all}} \quad (9)$$

式中 n_{ij} 为第i类基础交通行为为后序为j类基础交通行为的轨迹段数量。

选择状态转移矩阵中最高的3类作为预期行为备选,并通过Transform网络(transform网络及训练过程在3.2节中进行详细介绍)生成对应轨迹。由于自动驾驶汽车总是趋向于较小的行驶风险,因此假设交通车维持当前驾驶行为,分别计算3类预期驾驶行为与交通车轨迹间的最小距离 E_{min} 和平均距离 EU 。将最小距离大于阈值且平均距离最大的预期行为备选作为预测轨迹,该轨迹可认为是自动驾驶选择的最安全的行驶路径。若所有最小距离均小于

阈值,则选择状态转移最高的行为及轨迹作为预测轨迹。

$$E_s = \sqrt{(p_{k,x}^A - p_{k,x}^B)^2 + (p_{k,y}^A - p_{k,y}^B)^2} \quad (10)$$

3 交通车拟人交互轨迹生成

在第2节完成被测自动驾驶汽车未来轨迹预测的基础上,通过设定交通车与自动驾驶汽车间轨迹的交互进而实现具有一定风险的拟人连续测试场景生成。首先明确交通车所采取的交通行为及轨迹长度,然后在给定行为及轨迹长度的基础上完成轨迹生成。

3.1 交通车交互行为类型生成

连续场景生成的关键在于交通车与自动驾驶汽

车之间的积极交互,为了避免交通车主动撞击被测自动驾驶汽车,须制订交通车行为选择及轨迹长度计算规则。本文设定的交通车行为选择规则及预期轨迹点位置如表2所示。表中首行表示被测自动驾驶汽车预测得到的未来交通行为(该行为通过2.2节获取),首列表示当前交通车与自动驾驶汽车的相对位置。即综合考虑被测自动驾驶汽车的预期行为及相对位置确定交通车的行为状态。

规则表中交通车行为规则包含两部分:交通车可能采取的行为;采取该行为后的预期轨迹终点。对于存在多类行为备选的情况,交通车随机选择其中一种。例如当自动驾驶汽车选择行为1,交通车处于自动驾驶汽车侧方时,交通车可随机选择1.2节中聚类得到的行为1或行为5,二者概率分别为50%。

表2 交通车交互行为规则表

行为	1	2	3	4	5
侧方	行为1/5(前侧/靠近自动驾驶方向纵向向前)	行为2/4(前侧/靠近自动驾驶方向纵向向前)	行为1/5(前侧/靠近自动驾驶方向纵向向前)	行为2/4(纵向重叠/靠近自动驾驶方向纵向重叠)	行为1/5(纵向重叠/靠近自动驾驶方向纵向重叠)
正前	行为1/3(前间距缩短/前)	行为2(前间距缩短)	行为1/3(前间距缩短/前)	行为2/4(纵向重叠/靠近自动驾驶方向纵向重叠)	行为1/5(纵向重叠/靠近自动驾驶方向纵向重叠)
正后	行为5(侧向纵向重叠)	行为4(侧向纵向重叠)	行为5(侧向纵向重叠)	行为2(侧向纵向重叠)	行为1(侧向纵向重叠)

以三车道作为演示示例对表2中的规则进行介绍,其它区域行为规则与表2类似。

选择交通车处于自动驾驶汽车侧方位置,自动驾驶汽车预测轨迹为换道时的交通车行为选择分析进行举例分析。如表2所示,此时交通车选择的所有情况如图3所示。从图中可以看出,交通车大多数情况均预期可与被测自动驾驶汽车产生积极交互(图中红色点位置),即使未发生实际交互也可保证不低于当前的风险水平。




图3 交通车轨迹交互规则示意

3.2 交通车拟人轨迹生成

在完成交通车行为类型选择及轨迹终点判断后,便可生成其具体轨迹。由于交通车轨迹生成过程中须考虑其操作特征符合人类驾驶操作,即保证轨迹的拟人性,本文选择Transform网络作为交通车

行为生成的框架^[12]。对2.2节中不同基础交通行为分别训练Transformer轨迹生成模型。本文选择的Transformer轨迹生成网络参数如表3所示,输入数据为车辆横纵向位置信息。

表3 Transformer网络参数表

网络参数	数值	网络参数	数值
Input_size	2	Output_size	1
Embedding_size	8	N_head	8
Dim_feedforward	2 048	Dropout	0
Batch_size	512	Initial_learning_rate	0.001
Gamma	0.995	Epoch	1 000

损失函数为预测值与掩码矩阵对应位置相乘后和标签值的均方误差损失,公式如下:

$$MSE_{\text{mask}} = \frac{1}{n} \sum_{i=1}^n (y_i - \lambda \hat{y}_i)^2 \quad (11)$$

为保证网络训练初期更大的更新幅度及训练后期更精确的最优解,在模型训练过程使用学习率衰减,衰减策略为指数衰减,指数衰减公式如下:

$$lr = lr_{\text{initial}} \gamma^{\text{epoch}} \quad (12)$$

式中:lr为当前轮的学习率;lr_{initial}表示初始学习率;γ为0.995;epoch为当前轮的轮次。

以行为5为例,其轨迹生成网络训练的损失曲线如图4所示,可以看到在大约300轮训练后Transform模型已经基本达到收敛。




图4 轨迹生成网络损失曲线

图5为基于训练好的网络模型所完成的轨迹生成结果,可以发现训练好的模型与真实人类驾驶轨迹间具有较高的相似性。




图5 轨迹生成结果示例

在生成交通车轨迹时,首先根据3.1节的内容选择对应的交通车基础交通行为轨迹生成网络,并将当前轨迹作为训练好的Transformer网络输入。将生成结果使用Savitzky-Golay滤波器进行平滑处理,并将其微分结果输入至仿真环境,控制相应交通车行为。当交通车运动行为发生改变后,被测自动驾驶汽车会根据其自身策略进行行为修正,从而触发了新的交通车行为生成。通过被测自动驾驶汽车与交通车之间的行为迭代,实现拟人交互测试场景持续生成。

4 试验验证

在Prescan软件中搭建仿真环境对所构建的连续场景生成方法有效性进行验证,验证内容包括生成连续场景的危险性及拟人性。

4.1 结果生成示意

用本文方法共进行了50 km长度的三车道拟人

连续交互测试场景生成测试,自动驾驶汽车轨迹由被测系统实时生成,交通车轨迹通过本文建立的方法生成。部分行驶轨迹状态如图6和图7所示。图中红棕色线为本文方法生成的轨迹,蓝线为被测自动驾驶汽车行驶的轨迹。从图中可以发现,在较短的路段内被测自动驾驶汽车与交通车之间发生了较多换道交互。




图6 拟人连续测试场景生成轨迹1




图7 拟人连续测试场景生成轨迹2

4.2 场景拟人性评价

行驶拟人性是保证测试场景符合真实驾驶过程的重要参考指标,本文中场景拟人性评价主要通过交通车轨迹片段在自然驾驶过程中的相似性进行判断。若自然驾驶数据库存在与场景轨迹相似度较高的自然驾驶轨迹,则表明交通车轨迹具有真实的自然驾驶特征。场景轨迹拟人性量化表征方法如式(13)所示:

$$T_{\text{real}} = \sum_{i=1}^{t_{\text{count}}} \frac{RMSE(X_i, Y_i)}{t_{\text{count}}} \quad (13)$$

$$\text{其中: } RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (r_i - y_i)^2} \quad (14)$$

式中: T_{real} 代表场景轨迹的拟人性量化结果; t_{count} 为场景轨迹片段的数量; X_i 为某段场景轨迹; Y_i 为自然驾驶数据库中与 X_i 均方根误差最小的自然驾驶匹配轨迹; r_i 为自然驾驶值; y_i 为生成值; m 为轨迹的时序长度。

T_{real} 的值越小代表场景轨迹与真实轨迹匹配效果越好。将1.2节中获取的自然驾驶数据段作为对比基准,生成的50 km连续测试场景中交通车轨迹

的拟人性指标为 0.328,生成的连续场景具有较好的拟人性结果。

4.3 场景危险性评价

由于本文生成交互测试场景的主要目的在于评估被测自动驾驶汽车在面对危险场景时的反应,因此还须对本文方法生成的交互测试场景危险性进行计算。

碰撞时间是衡量行驶场景危险性最常用的指标之一,本文取其倒数作为场景碰撞风险的量化指标。通过定义碰撞风险阈值,将行驶过程中被测自动驾驶汽车与周围交通车碰撞风险超过阈值的总里程与总行驶里程的百分比作为场景危险性的评价指标。若存在多个交通车或障碍物,分别计算自动驾驶汽车与每个目标物的碰撞风险并选择最大的碰撞风险作为此时的场景风险。碰撞风险 c_i 计算公式为

$$c_i = \frac{|v_1 - v_2| \cdot \cos \theta}{s} \quad (15)$$

式中: v_1 为交通车当前的速度矢量; v_2 为自动驾驶汽车当前的速度矢量; θ 为交通车和自动驾驶汽车当前车辆中心连线的夹角; s 为交通车和自动驾驶汽车当前车辆中心连线的长度。

以 4.1 节中生成的图 7 所示的连续场景为例,其实时碰撞风险分布如图 8 所示。以 1 作为碰撞风险阈值,对该场景中超过碰撞阈值的总里程进行加和,图 8 中 3 km 的路程被测汽车与交通车交互过程超过阈值的总里程为 1.314 km,危险里程占据总里程的百分比为 43.8%。总行驶里程 50 km 共发生超过阈值的交互总里程为 20.91 km,危险里程占据总里程的百分比为 41.8%。




图 8 拟人连续测试场景 2 碰撞风险

此外,自动驾驶系统认为行驶过程存在风险时经常采取制动行为,因此可以通过判断车辆行驶减速度超过阈值的次数来对行驶风险进行判断。本文选择纵向速度的阈值 -2 m/s^2 作为危险情况筛选条件,图 7 中对应的纵向减速度变化情况如图 9 所示。图 9 中大约 200 s 的行驶过程发生减速度超过阈值的情况共计 11 次。总行驶里程 50 km 共发生超过阈值的情况 198 次,远大于正常道路行驶过程的制动

情况。




图 9 拟人连续测试场景 2 行驶减速度

综合碰撞时间倒数及行驶过程减速度情况可以发现,本文所提方法生成的场景具有较高的危险情况,可有效应用于自动驾驶系统安全功能的测试过程。

5 结论

针对自动驾驶汽车连续交通仿真测试所面临的场景生成难题,本文提出了一种基于轨迹交互的自动驾驶汽车拟人连续交通流生成方法。该方法通过将连续测试场景解构为自动驾驶汽车轨迹预测及交通车交互轨迹生成,在保证场景拟人性的同时提升了场景的危险性,具有良好的应用价值。由于计算条件及数据库的限制,当前连续场景生成过程仅考虑了直线三车道及 1 个交通车的测试环境,未来将继续深入探索不同道路环境,不同数量交通车、不同数量被测自动驾驶汽车条件下更为复杂的连续交通场景生成方法。

参考文献

[1] 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(60):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(60): 1-19.

[2] LIU M, OUYANG X, LU R, et al. An evaluation method for automotive technical and comprehensive performance[J]. Automotive Innovation, 2023, 6: 231-243.

[3] 徐向阳,胡文浩,董红磊,等.自动驾驶汽车测试场景构建关键技术综述[J].汽车工程,2021,43(4):610-619.
XU X, HU W, DONG H, et al. Review of key technologies for autonomous vehicle test scenario construction[J]. Automotive Engineering, 2021, 43(4): 610-619.

[4] ZHAO S, DUAN J, WU S, et al. Genetic algorithm-based sotif scenario construction for complex traffic flow[J]. Automotive Innovation, 2023, 6: 531-546.

[5] 蒋渊德,朱冰,赵祥模,等.面向自动驾驶汽车测试的交通车辆交互过程建模[J].汽车工程,2022,44(12):1825-1833.
JIANG Y D, ZHU B, ZHAO X M, et al. Modeling of traffic vehi-

- cle interaction for autonomous vehicle testing[J]. *Automotive Engineering*, 2022, 44(12):1825-1833.
- [6] 郭景华,李克强,王进,等.基于危险场景聚类分析的前车随机运动状态预测研究[J].*汽车工程*, 2020, 42(7):847-853, 859. GUO J H, LI K Q, WANG J, et al. Study on prediction of preceding vehicle's stochastic motion based on risk scenarios clustering analysis [J]. *Automotive Engineering*, 2020, 42 (7) : 847-853, 859.
- [7] 李江坤,邓伟文,任秉韬,等.基于场景动力学和强化学习的自动驾驶边缘测试场景生成方法[J].*汽车工程*, 2022, 44(7): 976-986. LI J K, DENG W W, REN B T, et al. Automatic driving edge scene generation method based on scene dynamics and reinforcement learning [J]. *Automotive Engineering*, 2022, 44 (7) : 976-986.
- [8] FENG S, SUN H, YAN X, et al. Dense reinforcement learning for safety validation of autonomous vehicles [J]. *Nature*, 2023, 615: 620-627.
- [9] RODRIGO Q, DIVIT S, RICARDO C, et al. A driver-vehicle model for ADS scenario-based testing[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2024, 25(8): 8641-8654.
- [10] 潘春燕.基于自然交通流生成的自动驾驶车辆测试评价研究[D].长春:吉林大学, 2022. PAN C Y. Research on test and evaluation of autonomous vehicles based on natural traffic flow generation [D]. Changchun: Jilin University, 2022.
- [11] 王博洋,龚建伟,张瑞增,等.基于真实驾驶数据的运动基元提取与再生成[J].*机械工程学报*, 2020, 56(16):155-165. WANG B Y, GONG J W, ZHANG R Z, et al. Motion primitives extraction and regeneration based on real driving data [J]. *Journal of Mechanical Engineering*, 2020, 56(16):155-165.
- [12] TAN Y, YANG Y, REN H, et al. Survey on traffic flow-based autonomous driving simulation tests[C]. 2023 IEEE 32nd Asian Test Symposium, New York: IEEE, 2023:100-105.
- [13] 刘宇翔.基于驾驶行为基元的换道风格分类方法研究[D].长春:吉林大学, 2024. LIU Y X. Research on the lane-changing style classification method based on driving behavior primitives [D]. Changchun: Jilin University, 2024.
- [14] 万志成,郑静.基于狄利克雷过程高斯混合模型的变分推断[J].*杭州电子科技大学学报(自然科学版)*, 2011, 41(5): 54-61. WAN Z C, ZHENG J. Variational inference for gaussian mixture model based on dirichlet process [J]. *Journal of Hangzhou Dianzi University(Natural Sciences)*, 2011, 41(5): 54-61.
- [15] BENDER A, AGAMENNONI G, WARD J, et al. An unsupervised approach for inferring driver behavior from naturalistic driving data[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2015, 16(6): 3325-3336.
- [16] XU P, ZHU X, CLIFTON D. Multimodal learning with transformers: a survey[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2023, 45(10): 12113-12132.

(上接第 1599 页)

- [6] MA F W, YANG Y, WANG J W, et al. Eco-driving-based cooperative adaptive cruise control of connected vehicles platoon at signalized intersections [J]. *Transportation Research Part D: Transport and Environment*, 2021, 92:1-17.
- [7] ZHAI C J, CHEN C Q, ZHENG X L, et al. Ecological cooperative adaptive cruise control for heterogeneous vehicle platoons subject to time delays and input saturations [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2023, 24(3): 2862-2873.
- [8] HALDER K, MONTANARO U, DIXIT S, et al. Distributed H-infinity controller design and robustness analysis for vehicle platooning under random packet drop [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022, 23(5): 4373-4386.
- [9] ZHAO W M, DONG N, SIMON S, et al. A platoon based cooperative eco-driving model for mixed automated and human-driven vehicle at a signalised intersection [J]. *Transportation Research Part C: Emerging Technologies*, 2018, 95: 802-821.
- [10] CHEN C Y, WANG J W, XU Q, et al. Mixed platoon control of automated and human-driven vehicles at a signalized intersection: dynamical analysis and optimal control [J]. *Transportation Research Part C: Emerging Technologies*, 2021, 127: 1-19.
- [11] ZHANG H Y, DU L L. Platoon-centered control for eco-driving at signalized intersection built upon hybrid MPC system, online learning and distributed optimization part I: modeling and solution algorithm design [J]. *Transportation Research Part B: Methodological*, 2023, 172: 174-198.
- [12] ZHANG H Y, DU L L. Platoon-centered control for eco-driving at signalized intersection built upon hybrid MPC system, online learning and distributed optimization part II: theoretical analysis [J]. *Transportation Research Part B: Methodological*, 2023, 172: 199-216.
- [13] HAO P, WU G Y, BORIBOONSOMSIN K, et al. Eco-approach and departure (EAD) application for actuated signals in real-world traffic [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 22(12): 7837-7849.
- [14] QI X W, WANG P, WU G Y, et al. Connected cooperative eco-driving system considering human driver error [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2018, 19(8): 2721-2733.
- [15] HELBING D, TILCH B. Generalized force model of traffic dynamics [J]. *Physical Review E*, 1998, 58(1): 133-138.
- [16] AKCELIK R. Efficiency and drag in the power-based model of fuel consumption [J]. *Transportation Research Part B: Methodological*, 1989, 23(5): 376-385.
- [17] WANG Y, BOYD S. Fast model predictive control using online optimization [J]. *IEEE Transactions on Control Systems Technology*, 2010, 18(2): 267-278.
- [18] HOMCHAUDHURI B, VAHIDI A, PISU P. Fast model predictive control-based fuel efficient control strategy for a group of connected vehicles in urban road conditions [J]. *IEEE Transactions on Control Systems Technology*, 2017, 25(2): 760-767.