

doi: 10.3969/j.issn.1002-0268.2025.05.004

智能车辆连续换道模糊宽度学习决策模型

邓超^{*1,2}, 刘港¹

(1. 武汉科技大学 汽车与交通工程学院, 湖北 武汉 430065;

2. 武汉科技大学 智能汽车工程研究院, 湖北 武汉 430065)

摘要:【目标】连续换道是一种危险的驾驶行为,相较于单次换道更加复杂,对道路安全有重要影响,因此有必要对连续换道行为的预测方法进行研究。【方法】首先,采用小波去噪法对高速公路数据集NGSIM进行降噪处理,提取出连续换道事件,把事件分为有等待时间的连续换道和无等待时间的连续换道行为;然后,以车辆首次接触分道线前0.1 s作为换道预测时刻,提取车辆在当前车道和目标车道的11个行驶状态特征变量,对变量进行归一化处理;最后,基于模型宽度学习方法建立连续换道决策系统,并对系统有效性进行验证。【结果】模型宽度学习决策模型以82.35%的精度超越了支持向量机、BP神经网络、朴素贝叶斯等模型,模型的训练时间仅为0.03 s,在保证精度的同时,快速地做出了预测,取得了突出的效果;同时,剔除本车与目标车道车辆速度差等2个特征变量,保留本车速度、加速度等9个特征变量时,模型宽度学习模型精度仍超越其余模型,保持在较高的水平。【结论】所提出的换道模型研究深入到连续换道的层面,通过等待时间将换道的连续性进行了划分,模型较好地刻画了连续换道轨迹特点,解释了连续换道行为机理,提出的换道决策模型表现出色,为复杂动态环境下的智能车自主决策方法提供了参考。

关键词:智能交通;换道决策模型;模糊宽度学习系统;连续换道;NGSIM;训练时间

中图分类号:U461

文献标识码:A

文章编号:1002-0268(2025)05-0036-07

Fuzzy broad learning decision-making model for intelligent vehicle continuous lane-changing

DENG Chao^{*1,2}, LIU Gang¹

(1. School of Automobile and Traffic Engineering, Wuhan University of Science and Technology, Wuhan, Hubei 430065, China;

2. Intelligent Vehicle Engineering Research Institute, Wuhan University of Science and Technology, Wuhan, Hubei 430065, China)

Abstract: [Objective] Continuous lane-changing is a type of risk driving behavior. Compared with single lane-changing, it is more complex and has significant impact on road safety. Therefore, it is necessary to study the methods for continuous lane-changing behavior prediction. [Method] First, the de-noising processing of NGSIM expressway dataset was performed by using the wavelet de-noising method. The continuous lane-changing events were extracted. The continuous lane-changing behaviors were divided into the events with and without waiting time. Then, taking the moment of 0.1 s before a vehicle first touching lane line as the standard lane-changing prediction time. 11 driving state feature variables on current and

收稿日期:2023-06-13 修改日期:2024-08-26

基金项目:国家自然科学基金项目(52002298);湖北省自然科学基金计划项目(2020CFB118);湖北省教育厅科学技术研究计划青年人才项目(Q20201107);教育部产学研合作协同育人项目(202102580026);武汉科技大学大学生创新创业训练计划项目(22Z079, 22Z081)

作者简介(*通讯作者):邓超:(1986-),男,湖北武汉人,博士,副教授,研究方向为交通运输。(woec@wust.edu.cn)

引用格式:邓超,刘港.智能车辆连续换道模糊宽度学习决策模型[J].公路交通科技,2025,42(5):36-42. DENG Chao, LIU Gang. Fuzzy broad learning decision-making model for intelligent vehicle continuous lane-changing[J]. Journal of Highway and Transportation Research and Development, 2025, 42(5): 36-42.

© The Author(s) 2025. This is an open access article under the CC-BY 4.0 License. (<https://creativecommons.org/licenses/by/4.0/>)

target lanes were extracted and normalized. Finally, a continuous lane-changing decision-making system was established based on the fuzzy broad learning, and the effectiveness of system was verified. [Result] With an accuracy of 82.35%, the fuzzy broad learning based decision-making model surpasses some other models (e.g., support vector machine, BP neural network, naive Bayesian model. The training time is only 0.03 s. The model achieves outstanding result with quick prediction while ensuring accuracy. Simultaneously, when removing 2 feature variables (i.e., speed difference between current lane and target lane, etc.), and retaining 9 feature variables (i.e., speed, acceleration, etc.), the fuzzy broad learning based model still outperforms other models. [Conclusion] The proposed lane-changing model has been deeply studied at the level of continuous lane-changing. The continuity of lane-changing has been divided according to waiting time. The model well characterizes the continuous lane-changing trajectories, and explains the mechanism of continuous lane-changing behavior. The proposed lane-changing model performs excellent, providing a reference for autonomous decision-making methods for intelligent vehicles in complex dynamic environments.

Key words: intelligent transport; lane-changing decision-making model; fuzzy broad learning system; continuous lane-changing; NGSIM; training time

0 引言

频繁、不合理的连续换道易诱发安全事故,据统计,高速公路上60%的交通事故是由换道引起的^[1]。因此有必要对换道特别是连续换道行为进行更深入研究。已有的换道行为研究大多是针对单次换道,鲜有对连续换道以及多次换道的关注。连续换道行为的过程复杂,受交通流、驾驶员行为特征以及周围车辆相互作用的影响,数据采集同样受到技术制约,且连续换道行为的内部机理不明确。

模型宽度学习系统因其网络结构的优越性,常应用于分类和回归问题的研究。李润泽^[2]依据模糊宽度学习对光伏发电进行了预测,克服了传统方法的模型复杂、网络参数多等缺点。陈万生^[3]将模糊宽度学习技术应用于远近雨水的去除任务中,取得良好效果的同时提升了训练速度。基于NGSIM数据,国内外学者做了大量的研究,Toledo^[4]依据NGSIM数据,建立了小型汽车换道持续时间对数回归模型。Yang^[5]基于随机效用理论建立换道行为模型,将换道过程分为换道决定、目标车道选择及选择可接受间隙执行换道。齐龙^[6]通过NGSIM数据建立了强制换道和协作换道模型。目前针对换道决策的建模研究已取得较多的成果。黄开启^[7]提出换道决策模型,他将决策归纳为综合考虑了可能性、必要性、安全性的结果。陈亮^[8]提出了一种基于Multi-class SVM的换道识别模型,通过粒子群优化算法标定惩罚参数和核参数,较好地达到了识别的目的。陈力^[9]提出了一种以7个参数为输入的BP神经网络预测模型,利用非线性问题的处理能力,取得了较

好的识别效果。徐兵^[10]采用梯度提升决策树进行特征变换来建立融合换道决策模型,提升了模型的识别精度。周贝妮^[11]通过高斯混合模型计算出换道分类结果与实际分类结果的误差仅为9.1%,体现了模型的优越性。

在车辆连续换道过程中,驾驶员为追求安全,一般会有短暂的等待。上述决策模型在进行换道行为建模时多剔除了危险性更高的连续换道。因此引入一种模糊宽度学习预测方法,以预测连续换道过程中是否存在等待行为。以模型宽度学习为基础,描述了连续换道行为,并论述了数据的处理和筛选,提取了影响决策的特征变量,进而进行建模分析,与其他常用的换道决策模型进行了对比和分析,验证了该模型的优越性。本研究为车辆高效安全的连续换道提供了理论依据。

1 基于模型宽度学习的网络模型

1.1 模型宽度学习系统

Feng^[12]提出了一种新的神经-模糊模型,即模型宽度学习系统。该模型保持了宽度学习系统的基本结构,以多组模糊子系统取代了标准宽度学习系统的特征节点。其网络结构如图1所示。

模糊宽度学习系统去除了宽度学习系统特征节点层中用于微调权重的稀疏自动编码器,以降低网络结构的复杂度,使其拥有较好的泛化能力和鲁棒性,并提高了预测性能,具体结构如图2所示。

假设一个模糊宽度学习系统中有 n 个模糊子系统和 m 组增强节点,一阶TS模糊系统的输入数据为 $\mathbf{X} = (x_1, x_2, \dots, x_N)^T \in R^{N \times M}$, 其中 $x_s = (x_{s1}, x_{s2}, \dots,$




图1 模糊宽度学习系统网络结构

Fig. 1 Network structure of fuzzy broad learning system




图2 模糊子系统网络结构

Fig. 2 Fuzzy subsystem network structure

x_{sM}), $s=1, 2, \dots, N$ 。假设第 i 个模糊子系统具有 K_i 个模糊规则, 它的定义为:

$$z_{sk}^i = f_k^i(x_{s1}, x_{s2}, \dots, x_{sM}) = \sum_{t=1}^M \alpha_{kt}^i x_{st}, \quad (1)$$

式中, α_{kt}^i 为一种随机系数, 分布在 $[0, 1]$ 之间, 其中 $k=1, 2, \dots, K_i$; f_k^i 为 x_s 与 z_{sk}^i 的映射。

模糊子系统的另一个元素为加权强度系数, 定义为:

$$\omega_{sk}^i = \frac{\prod_{t=1}^M \mu_{kt}^i(x_{st})}{\sum_{k=1}^{K_i} \prod_{t=1}^M \mu_{kt}^i(x_{st})}, \quad (2)$$

式中, $\mu_{kt}^i(x_{st})$ 为高斯成员函数, 定义:

$$\mu_{kt}^i(x) = \exp\left[-\left(\frac{x - c_{kt}^i}{\sigma_{kt}^i}\right)^2\right], \quad (3)$$

式中, c_{kt}^i 为将 K -means 算法用于训练集, 通过聚类中心初始化高斯隶属度的中心; σ_{kt}^i 为训练集样本的标准差。为了简化模型, σ_{kt}^i 通常设置为 1。

为了尽可能多地保留输入数据背后的信息, 定义了一个由第 i 个模糊子系统中所有模糊规则的输出组成的向量, 然后将它们聚合为一个值, 作为模糊子系统的反模糊化输出。所有模糊子系统的中间向

量被馈送到增强节点层, 用于进一步的非线性变换。利用加权强度系数和模糊规则, 得到第 i 个模糊子系统的第 s 个训练样本的中间输出向量为:

$$Z_{si} = (w_{s1}^i z_{s1}^i, w_{s2}^i z_{s2}^i, \dots, w_{sK_i}^i z_{sK_i}^i). \quad (4)$$

第 i 个模糊子系统所有的训练样本的输出为:

$$Z_i = (Z_{1i}, Z_{2i}, \dots, Z_{Ni})^T \in R^{N \times K_i}, \quad i=1, 2, \dots, n. \quad (5)$$

为了保持符号的一致性, 最后将 n 个模糊子系统的中间输出矩阵表示为:

$$Z^n = (Z_1, Z_2, \dots, Z_n)^T \in R^{N \times (K_1 + K_2 + \dots + K_n)}. \quad (6)$$

利用得到的 Z^n , 发送到增强层 (m 组增强节点) 进行非线性变化, 假设在第 j 个增强节点有 L_j 个神经元, 则增强层的输出表示为:

$$H^m = (H_1, H_2, \dots, H_m)^T \in R^{N \times (L_1 + L_2 + \dots + L_m)}, \quad (7)$$

式中, 第 j 个增强节点组的输出矩阵 H_j 计算为:

$$H_j = \xi_j(Z_n W_{hj} + \beta_{hj}) \in R^{N \times L_j}, \quad j=1, 2, \dots, m, \quad (8)$$

式中, W_{hj} 和 β_{hj} 分别为中间输出 Z^n 的权重和偏置项, 随机分布在 0-1 之间。

最后, 综合模糊子系统和增强节点的输出, 得到模糊宽度学习系统的输出为:

$$\hat{Y} = [Z^n, H^m]^T W_F = N_{out} W_F, \quad (9)$$

式中, W_F 为连接输出层到模糊子系统和增强节点的权重。

$$W_F = (\lambda I + N_{out} N_{out}^T)^{-1} N_{out}^T \hat{Y}, \quad (10)$$

式中, I 为单位矩阵。

1.2 模型的可行性分析

影响车辆换道的因素有很多, 例如周围车辆的速度、加速度、横纵向位移差等。已有的研究多关注单次换道, 此类换道决策模型只有一个目标车道, 且两种样本的特征变量区别较明显。对于连续换道, 需考虑两个目标车道, 模型相对复杂, 传统的决策模型无法保证其预测精度, 且模型运行时间较长。因此, 本研究以模糊宽度学习为基础构建连续换道决策模型。

2 数据处理和筛选

2.1 连续换道行为描述

车辆在目标路段内只发生一次且朝相同方向多次跨越车道线的变道行为, 依据是否存在换道等待现象, 分为无等待的连续换道和有等待的连续换道^[13]。多次换道有明显的换道等待时间, 以 5 s 为

界限,若等待时间超过 5 s,则为多次换道;否则为有等待的连续换道,视为连续换道。

通过已有研究发现,当车辆横向速度小于 0.2 m/s 时,车辆的横向运动不明显,接近直线行驶;假设车辆以 0.2 m/s 的横向速度完成一个车道宽度的横向位移,至少需要 18.3 s 的时间,而单次换道持续时间均值为 8~10 s,大致为该值的一半,其所对应的横向速度约为 0.35~0.45 m/s,大致为 0.2 m/s 的 2 倍,即绝大多数驾驶员不可能采用这样的横向速度完成单次换道行为,即在连续换道过程中不会采用这样的横向速度^[13]。所以以驶出当前车道且进入最终车道之前在 0.5 s 的搜索区间内是否出现平均横向速度小于 0.2 m/s 作为在连续换道中是否存在等待的判断。

2.2 数据来源

NGSIM 包含 I-80、US-101、Prototype、Lankershim、Peachtree 这 5 组数据集,其中的 I-80 和 US-101 为高速公路的数据集,其余为城市道路的数据集^[14]。选取 NGSIM 数据 US-101 和 I-80 两个数据集为对象,两路段均由 2 条匝道、1 条集散车道、5 条主干道组成,如图 3 所示。该数据集包含通畅、半通畅、拥挤 3 个时间段,每个时间段 15 min,共计 45 min。该数据集是采用 0.1 s/帧来记录车辆的特征数据以及轨迹,包含了速度、加速度、坐标等 18 个参数。




图3 采集路段示意图

Fig. 3 Schematic diagrams of data collection road section

2.3 数据筛选

NGSIM 数据采集中包括小型汽车、大型货车和摩托车,为了保证数据量和提高模型精度,以小汽车为例。对连续换道起止点做如下处理^[15]:轨迹的提取以 0.5 s 作为搜索区间,换道起始点 t_{begin} 是以 5 个时刻的平均横向车速进行判断,即 V_x 大于 0.2 m/s 的第 1 帧为换道开始点。

对于原始数据的处理和提取,首先筛选出汽车类型为小汽车且有连续换道行为的车辆(车道编号发生过至少两次的变化)。依据连续换道的定义,将数据进一步划分为有等待时间和无等待时间的连续换道。匝道和辅道之间不存在连续换道行为,剔除连续换道中包含匝道的数据。利用 Python 的 pandas 库对满足条件的数据进行筛选,共筛选出 230 条可用于连续换道决策的样本。其中,169 条连续换道有等待的样本,61 条连续换道无等待的样本,共计 22 732 条数据。将筛选后的数据样本附上标签,将执行了无等待连续换道的标注为 1,作为数据集的正样本;执行有等待连续换道的标注为 0,作为负样本。

在实际的连续换道过程中,大多数车辆为追求安全会降低横向速度,在获取周围车辆的信息后,再进行换道。筛选的两个数据集中两种样本量比例约为 1:2.77,符合驾驶员进行连续换道习惯,且并未出现样本量严重失衡,因此保留全部样本数据,无需进行均衡处理。

2.4 车辆换道轨迹提取

NGSIM 数据在采集中因测量误差会表现出很多白噪声,存在位置、速度、加速度在内的很多异常值。常见的滤波方法有移动平均法^[16]、卡尔曼滤波^[17]、小波去噪^[18],选用小波去噪对数据集进行处理。

在 python 环境下选用小波去噪算法,使用 Db8 基波进行小波分解及重构,阈值函数使用软阈值函数,位置数据阈值为 0.08,速度和加速的阈值为 0.02,均分解到最大层次,平均在 3~4 次,得到去噪后数据。选取 US-101 数据集中车辆编号为 98 的位置轨迹数据进行分析,如图 4 所示, x 为纵向位移, y 为横向位移, t 为时间。由图 4 可以看出,去噪后的车辆换道行驶轨迹变得更加平滑,因此选取处理后的特征数据替换原始数据。

3 特征选择

3.1 连续换道决策分析

车辆连续换道决策行为会受到主体车辆、周围




图4 位置降噪图

Fig. 4 De-noising location diagram

车辆以及交通拥挤情况的综合影响,因此选取合适的决策特征变量以及决策点至关重要。主体车辆的连续换道示意图见图5。




图5 主体车辆连续换道示意图

Fig. 5 Schematic diagram of vehicle continuous lane-changing

首先选取连续换道开始点作为决策点,提取周围6辆车以及本车的特征数据建立模型,观察结果发现预测效果较差。分析原因是驾驶员在连续换道过程中为追求安全会做出是否在目标车道1等待的决策,因此决策是在换道过程中而不是在起点做出的。综合考虑车辆安全性及预测精度,选取车辆行驶中第1次接触分道线的前1帧(即前0.1s)作为决策点进行预测,同时提取同一帧数下的周围车辆信息,如图5所示的位置2。

3.2 特征变量计算

在Gu^[19]、Liu^[20]、徐兵^[10]研究基础上,综合考虑速度、加速度、位置,选取了以下11个特征变量:

- (1) v 为主体车辆的速度。
- (2) a 为主体车辆的加速度。
- (3) y_1 为主体车辆与目标车道1前车的纵向距离。 $y_1 = y_{1前} - y$, 式中 $y_{1前}$ 和 y 分别为目标车道1前车的纵向位置和主体车辆的纵向位置。
- (4) v_1 为主体车辆与目标车道1前车的速度差。 $v_1 = v - v_{1前}$, 式中 $v_{1前}$ 为目标车道1前车的速度。
- (5) a_1 为主体车辆与目标车道1前车的加速度差。 $a_1 = a - a_{1前}$, 式中 $a_{1前}$ 为目标车道1前车的加

速度。

(6) y_2 为主体车辆与目标车道1后车的纵向距离。 $y_2 = y - y_{1后}$, 式中 $y_{1后}$ 为目标车道1后车的纵向位置。

(7) v_2 为主体车辆与目标车道1后车的速度差。 $v_2 = v - v_{1后}$, 式中 $v_{1后}$ 为目标车道1后车的速度。

(8) a_2 为主体车辆与目标车道1后车的加速度差。 $a_2 = a - a_{1后}$, 式中 $a_{1后}$ 为目标车道1后车的加速度。

(9) y_3 为主体车辆与目标车道2后车的纵向距离。 $y_3 = y - y_{2后}$, 式中 $y_{2后}$ 为目标车道2后车的纵向位置。

(10) v_3 为主体车辆与目标车道2后车的速度差。 $v_3 = v - v_{2后}$, 式中 $v_{2后}$ 为目标车道2后车的速度。

(11) a_3 为主体车辆与目标车道2后车的加速度差。 $a_3 = a - a_{2后}$, 式中 $a_{2后}$ 为目标车道2后车的加速度。

4 模型验证及结果分析

4.1 模型参数优化

实际中,车辆速度、加速度、位置这些特征变量具有不同的量纲,数据维度之间数值差异也较大,因此在模型训练和测试之前需进行归一化处理。具有较大变化范围的特征变量数据可能会降低部分特征变量对模型的作用,致使模型精度降低。此外,数据集大范围的变化会增加模型的复杂度和训练时间。对数据进行归一化会使最优解的寻优过程变得更加平缓,降低了快速准确搜索到最优解的难度。采用min-max归一化处理方法,将所有特征变量值转换到 $[0, 1]$ 之间,归一化公式:

$$x' = (x - x_{\min}) / (x_{\max} - x_{\min}), \quad (11)$$

式中, x' 为归一化后数据; x 为原始数据; $x_{\min}$ 和 $x_{\max}$ 分别为该维特征数据在归一化之前的最小值和最大值。

4.2 模型验证及分析

为了验证模糊宽度学习预测连续换道决策行为的准确性,将筛选出的特征数据划分为训练集和测试集,其中训练集占比85%,测试集占比15%,进而得到模型预测的准确率。

模糊宽度学习的参数对于模型精度和训练时间至关重要,包括每个模糊子系统中模糊规则的数量(N_r)、模糊子系统个数(N_l)、增强节点个数(N_e)。通过网格搜索^[21]不断试验,得到结果的具体参数设置见表1。

表1 模糊宽度学习系统的参数设置

Table 1 Parameters setting of fuzzy broad learning system

N_r	N_l	N_e	测试集精度/%	训练时间/s
13	6	18	82.352 9	0.026 72
14	7	12	82.352 9	0.032 66
10	6	10	79.411 8	0.024 62
13	6	12	79.411 8	0.028 45

比较表1中结果,最终选取 $N_r = 13$, $N_l = 6$, $N_e = 18$ 作为连续换道中是否需要等待时间决策的参数。

为验证算法的有效性,进行特征选择试验,随机剔除特征变量。当删除 v_2 和 v_3 选取其余9个特征变量时,模型精度为76.47%;当删除 v_1 和 a_3 时,模型精度为79.41%,均取得了较好的效果。

为进一步验证新方法在连续换道决策中的优越性,与目前主流的BP神经网络^[9]、支持向量机^[8]和朴素贝叶斯^[11]等方法进行比较。对比结果见表2。

表2 不同算法的结果精度对比

Table 2 Accuracy comparison with different algorithms

算法	支持向量机/ %	BP神经网络/ %	朴素贝叶斯/ %	模糊宽度 学习/%
精度	73.53	72.94	70.59	82.35

综合表1和表2,模糊宽度学习算法在精度上比其他3个算法分别提高了8.82%, 9.41%, 11.76%,证明可以在短时间内获得更高的精度,使得驾驶员在车辆连续换道过程中可以更加快速准确地做出决策。

5 结论

首次将模糊宽度学习分类算法应用在车辆连续换道行为的预测中,依据对连续换道行为的描述,通过提取本车以及两个目标车道的车辆信息,找出影响连续换道行为的特征变量,当选取了本车速度等11个特征变量时,达到最优效果。对比模型计算结果表明模糊宽度学习算法具有更加突出的表现,以82.35%的预测精度超越了其他换道决策模型,同时运算效率高,能够对换道行为进行快速准确的预判。

未来,将会挖掘更多影响车辆连续换道行为的特征变量,例如碰撞时间、驾驶员特性等,同时将从异常数据的处理及连续换道轨迹数据的采集方面做更加细致的研究。

参考文献:

References:

- [1] HABEL L, SCHRECKENBERG M. Asymmetric lane change rules for a microscopic highway traffic model [C] //International Conference on Cellular Automata. Cham: Springer, 2014: 620-629.
- [2] 李润泽, 郭黎, 李保平, 等. 基于模糊宽度学习模型的光伏发电预测方法 [J]. 控制工程, 2020, 7 (11): 2016-2022.
LI Runze, GUO Li, LI Baoping, et al. A photovoltaic power prediction method based on fuzzy broad learning system [J]. Control Engineering of China, 2020, 27 (11): 2016-2022.
- [3] 陈万生. 基于非局部及模糊宽度学习的单幅图像去雨研究 [D]. 上海: 上海师范大学, 2020.
CHEN Wansheng. Study on rain removal from single image based on non-local and fuzzy broad learning [D]. Shanghai: Shanghai Normal University, 2020.
- [4] TOLEDO T, ZOHAR D. Modeling duration of lane changes [J]. Transportation Research Record, 2007, 1999 (1): 71-78.
- [5] YANG Q, OVERTON R, HAN L D, et al. The influence of curbs on driver behaviors in four-lane rural highways: A driving simulator based study [J]. Accident Analysis & Prevention, 2013, 50: 1289-1297.
- [6] 齐龙, 郝艳军, 徐婷, 等. 多车道高速合流区车辆换道识别及轨迹分析 [J]. 公路交通科技, 2024, 41 (2): 173-181.
QI Long, HAO Yanjun, XU Ting, et al. Lane changing identification and trajectory analysis in confluence area of multi-lane expressway [J]. Journal of Highway and Transportation Research and Development, 2024, 41 (2): 173-181.
- [7] 黄开启, 瞿桃欢, 黄明禹, 等. 基于演化博弈的车辆换道研究 [J]. 公路交通科技, 2024, 41 (8): 31-39.
HUANG Kaiqi, QU Taohuan, HUANG Mingyu, et al. Study on vehicle lane-changing based on evolutionary game [J]. Journal of Highway and Transportation Research and Development, 2024, 41 (8): 31-39.
- [8] 陈亮, 冯延超, 李巧茹. 基于 Multi-class SVM 的车辆换道行为识别模型研究 [J]. 安全与环境学报, 2020, 20 (1): 193-199.
CHEN Liang, FENG Yanchao, LI Qiaoru. Probe into the Multi-class SVM-based recognition model for the vehicle lane-altering behaviors [J]. Journal of Safety and Environment, 2020, 20 (1): 193-199.
- [9] 陈力, 殷时蓉, 罗天洪, 等. 基于 BP 神经网络的智

- 能车辆换道决策模型研究 [J]. 汽车工程学报, 2022, 12 (1): 83-89.
- CHEN Li, YIN Shirong, LUO Tianhong, et al. Research on lane-changing decision model for intelligent vehicles based on BP neural network [J]. Chinese Journal of Automotive Engineering, 2022, 12 (1): 83-89.
- [10] 徐兵, 刘潇, 汪子扬, 等. 采用梯度提升决策树的车辆换道融合决策模型 [J]. 浙江大学学报 (工学版), 2019, 53 (6): 1171-1181.
- XU Bing, LIU Xiao, WANG Ziyang, et al. Fusion decision model for vehicle lane change with gradient boosting decision tree [J]. Journal of Zhejiang University (Engineering Science), 2019, 53 (6): 1171-1181.
- [11] 周贝妮, 韩皓, 李易. 基于能量场的城市道路车辆交互强度研究 [J]. 公路交通科技, 2024, 41 (2): 203-211.
- ZHOU Beini, HAN Hao, LI Yi. Study on vehicle interaction strength on urban road based on energy field [J]. Journal of Highway and Transportation Research and Development, 2024, 41 (2): 203-211.
- [12] FENG S, CHEN C L P. Fuzzy broad learning system: A novel neuro-fuzzy model for regression and classification [J]. IEEE Transactions on Cybernetics, 2018, 50 (2): 414-424.
- [13] 汪猛. 基于高精度数据的换车道行为特征研究 [D]. 长沙: 湖南大学, 2017.
- WANG Meng. Characteristics analysis of lane-changing behavior based on high-resolution data [D]. Changsha: Hunan University, 2017.
- [14] COIFMAN B, LI L. A critical evaluation of the next generation simulation (NGSIM) vehicle trajectory dataset [J]. Transportation Research Part B: Methodological, 2017, 105: 362-377.
- [15] 刘思超. 智能车辆换道决策及跟踪控制研究 [D]. 太原: 太原科技大学, 2021.
- LIU Sichao. Study on intelligent vehicle lane-changing decision-making and tracking control [D]. Taiyuan: Taiyuan University of Science and Technology, 2021.
- [16] OSSEN S, HOOGENDOORN S P. Validity of trajectory-based calibration approach of car-following models in presence of measurement errors [J]. Transportation Research Record, 2008, 2088 (1): 117-125.
- [17] PUNZO V, FORMISANO D J, TORRIERI V. Nonstationary Kalman filter for estimation of accurate and consistent car-following data [J]. Transportation Research Record, 2005, 1934 (1): 2-12.
- [18] 马艳锋. 基于NGSIM数据的高速公路出入口强制换道车辆执行及后调整行为研究 [D]. 西安: 长安大学, 2020.
- MA Yanfeng. Research on vehicles' mandatory lane change behavior in execution and post-adjustment period on multi-lane freeway based on NGSIM trajectory data [D]. Xi'an: Chang'an University, 2020.
- [19] GU X P, HAN Y P, YU J F. A novel lane-changing decision model for autonomous vehicles based on deep autoencoder network and XGBoost [J]. IEEE Access, 2020, 8: 9846-9863.
- [20] LIU Y G, WANG X, LI L, et al. A novel lane change decision-making model of autonomous vehicle based on support vector machine [J]. IEEE Access, 2019, 7: 26543-26550.
- [21] CHICCO D. Ten quick tips for machine learning in computational biology [J]. BioData Mining, 2017, 10 (1): 1-17.