

DOI: 10.20035/j.issn.1671-2668.2025.01.001

引用格式: 许傲天, 彭永康, 杨炜. 仿驾驶人转向行为的无人车转向系统控制研究[J]. 公路与汽运, 2025, 41(1): 1-5.

Citation: XU Aotian, PENG Yongkang, YANG Wei. Research on steering system control of unmanned vehicle simulating steering behavior of driver[J]. Highways & Automotive Applications, 2025, 41(1): 1-5.

## 仿驾驶人转向行为的无人车转向系统控制研究\*

许傲天, 彭永康, 杨炜

(长安大学汽车学院, 陕西 西安 710064)

**摘要:** 针对单一神经网络的预测轨迹与实际轨迹偏差较大的问题, 同时为使智能无人车在双车道左转和单车道 U 形弯转向时具有仿熟练驾驶人的操作特性, 基于熟练驾驶人的转向习惯设计一种结合长短期记忆(Long Short-Term Memory, LSTM)及反向传播(Back Propagation, BP)神经网络的 LSTM-BP 转向轨迹预测模型。在 PreScan 中建立车辆模型与虚拟场景, 基于熟练驾驶人的操作习惯, 通过 G29 驾驶模拟器操纵车辆得到转向数据训练组合预测模型, 设计基于线性二次型调节(Linear Quadratic Regulator, LQR)的路径跟踪控制器, 并利用 Simulink-PreScan-CarSim 对双车道左转和 U 形弯行驶两种工况进行联合仿真试验, 验证该轨迹预测模型和轨迹跟踪控制器的准确性。

**关键词:** 汽车; 无人驾驶汽车; 转向系统; 转向行为; 熟练驾驶人; 神经网络; 轨迹预测; 轨迹跟踪控制

中图分类号: U463.4

文献标志码: A

文章编号: 1671-2668(2025)01-0001-05

熟练驾驶人在处理复杂工况时表现出近似一致的操作特征, 这与无人驾驶汽车决策期望高度契合。目前, 基于单个时间步或多个时间步的预测算法已广泛应用于驾驶员转向轨迹预测模型研究。Gu J. 等基于线性二次型调节器(Linear Quadratic Regulator, LQR)的最优控制, 通过多点预测控制算法优化了驾驶员转向控制模型, 仿真分析结果表明车辆在该模型控制下具有优异的驾驶性能, 但其控制性能受设定的车辆当前位置到预测轨迹上特定点距离的影响较大<sup>[1]</sup>。Tan Y. S. 等针对传统模型道路跟踪性能较差的问题, 基于远点和近点的两点预瞄算法, 提出了一种新的驾驶员方向控制模型, 该模型经过两点校正后具有更好的道路跟踪性能<sup>[2]</sup>。该类模型的控制性能受设定的预瞄距离影响较大, 且针对复杂工况, 由于传统识别算法自身的局限, 预测效果不佳。

在处理驾驶人行为数据和建立拟合模型时, 广泛采用深度学习中的神经网络算法。Dang H. Q. 等针对车辆变道预测这一复杂问题, 基于长短期记忆(Long Short-Term Memory, LSTM)神经网络架构, 提出了将车道预测问题转化为车道变化时间预

测的方法<sup>[3]</sup>。该方法具有较好的精度, 但单一神经网络无法有效处理复杂的数据模式, 可能无法满足转向精度的要求。为此, 本文提出一种基于熟练驾驶人转向特性, 同时结合 LSTM 和反向传播(Back Propagation, BP)两种神经网络的 LSTM-BP 组合预测模型, 该模型以熟练驾驶人的行驶轨迹数据进行训练来表征其转向操作特性, 使无人驾驶汽车在转向工况下表现出类似熟练驾驶人的特点。

### 1 基于 LSTM-BP 的转向轨迹预测模型

#### 1.1 熟练驾驶人的转向特征

##### 1.1.1 数据采集

(1) 试验对象。为使采用的数据具有多样性, 选取 10 位驾驶技能熟练的驾驶员作为试验对象, 他们均持有 C1 或以上驾驶证, 年龄、性别和驾龄各不相同, 男女比例均衡, 年龄为 20~40 岁, 驾龄为 6~12 年。

(2) 试验工况。鉴于数据需求量大、实地采集成本高且易受外界干扰, 选择在仿真平台进行试验。试验对象通过 G29 驾驶模拟器控制在 PreScan 仿

\* 基金项目: 交通运输部运输车辆运行安全技术交通行业重点实验室项目(KFKT2018-07)

真环境下建立的车辆模型, Simulink 模块监测 G29 电信号并转换为系统可识别信号进行采集。试验中驾驶人先调整姿态并熟悉场景和操作, 随后启动仿真软件及设备, 以 18 km/h、36 km/h、54 km/h 3 种车速分别进行 50 组双车道左转(工况 1)和 U 形弯行驶(工况 2), 得到 1 000 组数据。由于低车速工况下训练模型所需数据量较少, 为合理分配数据比例, 最终以 18 km/h 车速进行 10 组测试、36 km/h 和 54 km/h 车速各进行 20 组测试。

### 1.1.2 熟练驾驶人的驾驶习惯

根据所采集的数据, 大部分熟练驾驶人的驾驶轨迹一致。车速较慢时, 为避免与逆行车辆相撞, 会使车辆轨迹更靠近车道外侧; 车速较高时, 为避免车辆驶离车道, 会将车辆保持在车道分界线附近。

## 1.2 LSTM-BP 组合预测模型搭建

### 1.2.1 模型设计

鉴于车辆轨迹数据的时序性及非线性特征, 利用 LSTM 强大的时间序列建模能力提取轨迹数据中的时序特征<sup>[4]</sup>, 并预测未来的时序数据, 然后利用 BP 神经网络进一步提升模型的非线性能力<sup>[5]</sup>。组合模型结构见图 1。

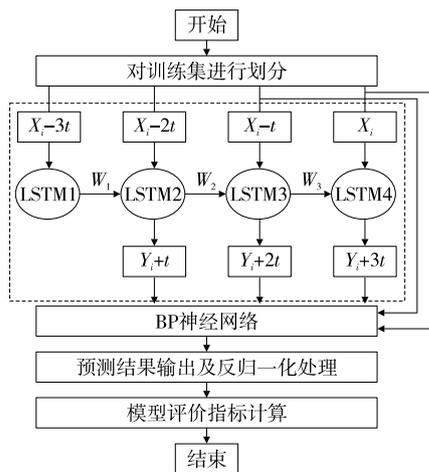


图 1 LSTM-BP 组合预测模型的架构

确定最优模型参数后, 保存模型并输入测试集。定义轨迹时间序列  $X = (x_1, x_2, x_3, x_4, x_5)$ , 将其作为模型的输入; 输入的轨迹经 LSTM 处理, 得到预测的时间序列因子  $Y = (y_1, y_2, y_3, y_4, y_5)$ , 将其作为 BP 层的输入; 最终输出预测轨迹。

### 1.2.2 模型参数确定

鉴于 LSTM 输入为四维特征参数, 输入层神经元设置为 4 个, 输出层设置为 3 个。设定迭代次数最多为 600 次, 批尺寸 (batch\_size) 为 30, 学习率为

0.001, 目标误差为 0.001。BP 层的输入为经 LSTM 处理得到的预测时间序列因子  $Y = (y_1, y_2, y_3, y_4, y_5)$ , 输出为未来时刻车辆位置的横纵坐标, 设定输入层神经元为 5 个、输出层神经元为 2 个。

经过评估, 设置模型在训练过程中一次性输入给模型的样本数量 batch\_size 为 30, 迭代次数为 1 000 次, 训练的误差容忍度阈值为 0.001。以均方误差和平均绝对误差为模型性能评估指标, 对随机梯度下降 (SGD)、自适应运动估计 (Adam) 及均方根反向传播法 (RMSProp) 3 种算法, 不同 BP 神经网络隐含层神经元个数, 不同 BP 神经网络隐含层与输出层激活函数组合 (见表 1), Traingd (基本梯度下降算法)、Traingda (自适应学习率梯度下降算法)、Traincgf (共轭梯度下降算法)、Trainlm (Levenberg-Marquardt 算法) 4 种训练函数的性能进行对比, 结果见图 2~5。

表 1 不同激活函数组合

组合编号	隐含层激活函数	输出层激活函数
1	Sigmoid	Sigmoid
2	ReLU	Sigmoid
3	Tanh	Sigmoid
4	Sigmoid	ReLU
5	ReLU	ReLU
6	Tanh	ReLU
7	Sigmoid	Tanh
8	ReLU	Tanh
9	Tanh	Tanh

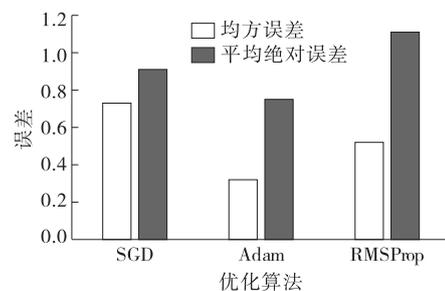


图 2 不同优化算法误差对比

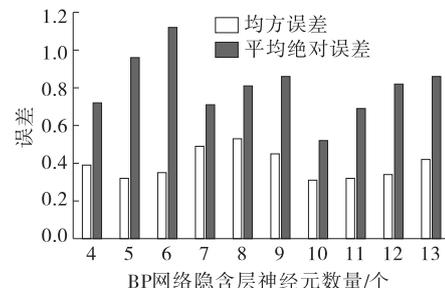


图 3 不同 BP 网络隐含层神经元个数误差对比

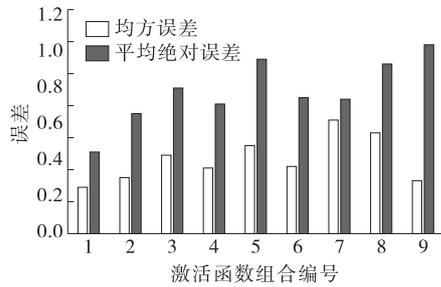


图 4 不同 BP 网络隐含层与输出层激活函数组合误差对比

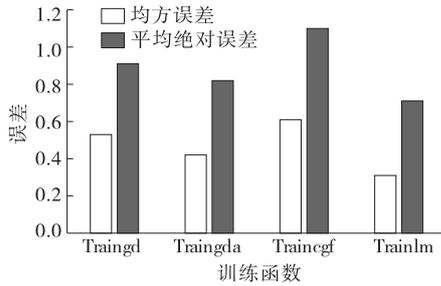


图 5 不同训练函数误差对比

根据图 2~5 所示均方误差和平均绝对误差确定模型参数如下:优化算法采用 Adam 算法;BP 网络隐含层神经元数量为 10 个;LSTM 隐含层数量为 1, 神经元数量为 50 个;激活函数采用双 Sigmoid, 训练函数采用 Levenberg-Marquardt 算法。

1.2.3 模型性能验证

对 LSTM-BP、LSTM、BP 3 种神经网络转向轨迹模型在左转、U 形弯工况下的均方误差和平均绝对误差进行对比,评价其性能,结果见表 2、表 3。

表 2 左转工况下 3 种神经网络转向轨迹模型误差对比

模型	均方误差	平均绝对误差
LSTM-BP	0.237 1	0.405 9
LSTM	0.853 1	1.071 5
BP	0.510 7	0.637 1

表 3 U 形弯工况下 3 种神经网络转向轨迹模型误差对比

模型	均方误差	平均绝对误差
LSTM-BP	0.573 2	0.719 4
LSTM	1.392 7	1.712 4
BP	1.101 3	1.551 6

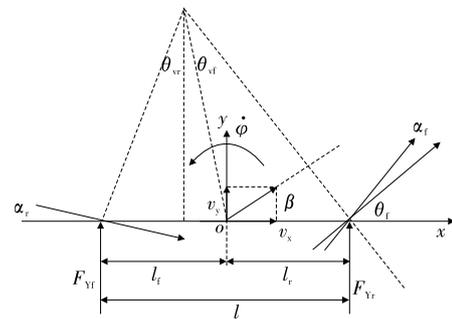
由表 2、表 3 可知:3 种神经网络轨迹预测模型的误差都较小,都能准确预测车辆轨迹。相较于

LSTM 模型和 BP 模型,左转工况下,LSTM-BP 组合预测模型的均方误差分别减小 0.616 0、0.273 6,平均绝对误差分别减小 0.665 6、0.231 2;U 形弯工况下,LSTM-BP 模型的均方误差分别减小 0.819 5、0.528 1,平均绝对误差分别减小 0.993 0、0.832 2。LSTM-BP 组合模型结合了 LSTM 网络和 BP 网络的特点,能更有效地挖掘数据中有效信息,学习到更复杂的转向轨迹特征,其误差最小,性能更好,与实际熟练驾驶人的行驶轨迹最接近。

2 轨迹跟踪控制器设计

2.1 车辆横向动力学模型

在横向控制中,主要考虑车辆横向运动特性。为便于进行实时跟踪控制计算,将汽车简化为图 6 所示自行车模型,该模型简单且具有一定的稳定性和鲁棒性<sup>[6]</sup>。



$\theta_{vr}$  为后轮速度方向角; $\theta_{vf}$  为前轮速度方向角; $\dot{\varphi}$  为汽车横摆角速度; $\alpha_f, \alpha_r$  分别为车辆的前后轮侧偏角; $v_y, v_x$  分别为车辆质心的横向和纵向速度; $\beta$  为车辆质心侧偏角; $\theta_f$  为前轮转角; $F_{yf}, F_{yr}$  为前后轮所受侧向力; $l$  为汽车轴距; $l_f, l_r$  分别为质心到前后轴的距离

图 6 线性二自由度车辆动力学模型

由图 6 可得车辆动力学模型为:

$$m(v_y + v_x \dot{\varphi}) = 2k_1 \left( \theta_{vf} - \frac{v_y + l_f \dot{\varphi}}{v_x} \right) + 2k_2 \left( -\frac{v_y - l_r \dot{\varphi}}{v_x} \right) \quad (1)$$

$$I_z \ddot{\varphi} = 2l_f k_1 \left( \theta_{vf} - \frac{v_y + l_f \dot{\varphi}}{v_x} \right) - 2l_r k_2 \left( -\frac{v_y - l_r \dot{\varphi}}{v_x} \right) \quad (2)$$

式中: $m$  为车辆质量; $I_z$  为车辆绕  $z$  轴转动的转动惯量; $\ddot{\varphi}$  为横摆角加速度; $k_1, k_2$  分别为前后轮的侧偏刚度。

联合式(1)、式(2),可得车辆横向动力学模型:

$$\frac{d}{dx} \begin{pmatrix} y \\ \dot{y} \\ \varphi \\ \dot{\varphi} \end{pmatrix} = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & -\frac{2k_1+2k_2}{m\dot{x}} & 0 & -\dot{x} - \frac{2k_1l_f-2k_2l_r}{m\dot{x}} \\ 0 & 0 & 0 & 1 \\ 0 & -\frac{2k_1l_f-2k_2l_r}{I_z\dot{x}} & 0 & -\frac{2k_1l_f^2+2k_2l_r^2}{I_z\dot{x}} \end{pmatrix} \cdot \begin{pmatrix} y \\ \dot{y} \\ \varphi \\ \dot{\varphi} \end{pmatrix} + \begin{pmatrix} 0 \\ \frac{2k_1}{m} \\ 0 \\ \frac{2k_1l_f}{I_z} \end{pmatrix} \theta_f \quad (3)$$

$$\frac{d}{dx} \begin{pmatrix} e_1 \\ \dot{e}_1 \\ e_2 \\ \dot{e}_2 \end{pmatrix} = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0 & -\frac{2k_1+2k_2}{mv_x} & \frac{2k_1+2k_2}{m} & \frac{-2l_fk_1+2l_rk_2}{mv_x} \\ 0 & 0 & 0 & 1 \\ 0 & -\frac{2l_fk_1-2l_rk_2}{l_zv_x} & \frac{2l_fk_1-2l_rk_2}{l_z} & \frac{2l_f^2k_1+2l_r^2k_2}{l_zv_x} \end{pmatrix} \cdot \begin{pmatrix} e_1 \\ \dot{e}_1 \\ e_2 \\ \dot{e}_2 \end{pmatrix} + \begin{pmatrix} 0 \\ \frac{2k_1}{m} \\ 0 \\ \frac{2l_fk_1}{I_z} \end{pmatrix} \theta_f + \begin{pmatrix} 0 \\ \frac{2l_fk_1-2l_rk_2}{mv_x} - v_x \\ 0 \\ -\frac{2l_f^2k_1+2l_r^2k_2}{I_zv_x} \end{pmatrix} \varphi_{\text{exp}} \quad (7)$$

## 2.2 基于 LQR 的弯道仿人轨迹跟踪控制器设计

### 2.2.1 路径跟踪误差动力学模型

式(3)为车辆位置和速度随时间的变化规律,给定车辆的前轮转角,可计算横向位移、横向速度、横摆角和横摆角速度。横向跟踪控制是用来减小系统输出与参考信号之间的差异,包括横向距离误差  $e_1$ 、航向误差  $e_2$  及其变化率。为设计有效的横向跟踪控制器,分析给定前轮转角的跟踪误差响应,其状态方程转换如下:

$$\dot{\varphi}_{\text{exp}} = \frac{v_x}{R} \quad (4)$$

式中:  $\dot{\varphi}_{\text{exp}}$  为转至期望角度的角速度;  $R$  为转弯半径。

期望的横向加速度  $a_{y\text{exp}}$  为:

$$a_{y\text{exp}} = \frac{v_x^2}{R} = v_x \dot{\varphi}_{\text{exp}} \quad (5)$$

期望的横向加速度  $a_{y\text{exp}}$  与车辆的实际横向加速度的误差  $\ddot{e}_1$  为:

$$\ddot{e}_1 = a_y - a_{y\text{exp}} = (\ddot{y} + v_x \dot{\varphi}) - \frac{v_x^2}{R} = \ddot{y} + v_x (\dot{\varphi} - \dot{\varphi}_{\text{exp}}) \quad (6)$$

式中:  $a_y$  为车辆的实际横向加速度。

航向角的期望值与实际值之间的插值即为航向误差。

代入式(2)、式(3),并将得到的基于误差的横向动力学模型的状态方程进行化简,得:

将式(7)简写为:

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}_1\theta_f + \mathbf{B}_2\dot{\varphi}_{\text{exp}} \quad (8)$$

式中:  $\dot{\mathbf{x}}$  为误差  $e_1, \dot{e}_1, e_2, \dot{e}_2$  的导数构成的目标矩阵;  $\mathbf{A}$  为  $e_1, \dot{e}_1, e_2, \dot{e}_2$  的系数矩阵;  $\mathbf{B}_1$  为  $\theta_f$  的系数矩阵;  $\mathbf{B}_2$  为  $\dot{\varphi}_{\text{exp}}$  的系数矩阵。

进一步忽略  $\dot{\varphi}_{\text{exp}}$  项,得:

$$\dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}\theta_f \quad (9)$$

式中:  $\mathbf{B}$  的含义与  $\mathbf{B}_1$  相同。

式(9)即为前轮转角控制输入  $\theta_f$  影响下横向控制所需路径跟踪偏差状态方程。

### 2.2.2 LQR 控制器设计

LQR 的目标函数是状态变量和控制变量的二次型函数,旨在获得适当的输入,使车辆平稳跟随预期的参考路径行驶。目标函数为跟踪过程中积累的跟踪偏差及控制输入的加权和:

$$J = \int_0^{\infty} \mathbf{x}^T \mathbf{Q} \mathbf{x} + \mathbf{u}^T \mathbf{R} \mathbf{u} dt \quad (10)$$

式中:  $\mathbf{x}$  为误差;  $\mathbf{Q}$  为半正定状态权重矩阵;  $\mathbf{R}$  为正定的控制加权矩阵;  $\mathbf{u}$  为控制输入。

求解目标优化函数:

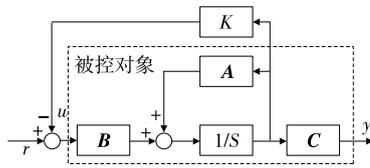
$$\mathbf{u} = -[\mathbf{R} + \mathbf{B}^T \mathbf{P} \mathbf{B}]^{-1} \mathbf{B}^T \mathbf{P} \mathbf{A} \cdot \mathbf{x} \quad (11)$$

通过求解黎卡提方程,得到矩阵  $\mathbf{P}$ :

$$\mathbf{A}^T \mathbf{P} + \mathbf{P} \mathbf{A} - \mathbf{P} \mathbf{B} \mathbf{R}^{-1} \mathbf{B}^T \mathbf{P} + \mathbf{Q} = 0 \quad (12)$$

状态反馈控制器见图 7,最优控制量  $\mathbf{u}$  和最优反馈增益  $\mathbf{K}$  用于实现最优控制,可利用状态反馈实

现最优控制。



$r$ 、 $y$  分别为输入和输出; $u$  为最优控制量; $A$ 、 $B$  分别为系统矩阵和输入矩阵; $x$  为状态变量,定义系统的状态;  
 $C$  为输出矩阵; $K$  为最优反馈增益

图 7 LQR 控制器的结构

LQR 控制器的最终控制率为:

$$K = R^{-1} B^T P \quad (13)$$

选择合适的权重矩阵  $Q$  和控制加权矩阵  $R$ , 通过求解黎卡提矩阵代数方程, 求解状态反馈控制增益矩阵  $K$  值, 使控制系统的性能达到最佳状态。

### 3 轨迹预测跟踪联合仿真分析

利用 Simulink-PreScan-CarSim 联合仿真平台进行试验。设置与熟练驾驶人转向特性数据采集中相同的车辆数据、车速及道路条件, 在工况 1 和工况 2 下进行模型跟踪性能仿真试验, 测试轨迹预测模型的准确性及轨迹跟踪控制模型的性能。

使用 Simulink 分别创建轨迹预测和轨迹跟踪模型, 使用 PreScan 进行场景构建; 控制车速, 使用 CarSim 建立仿真车辆的多自由度整车动力学模型。以 18 km/h、36 km/h、54 km/h 3 种车速在左转和 U 形弯工况下进行试验, 生成基于熟练驾驶人转向特性的 LQR 跟踪控制的跟踪轨迹。将熟练驾驶人的实际转向轨迹作为预测轨迹的参考。模型仿真轨迹和参考轨迹之间的横向偏差见表 4。

表 4 两种工况下模型仿真轨迹和参考轨迹之间的

横向偏差

车速/ (km · h <sup>-1</sup> )	不同工况下 $e_1$ /m		不同工况下 $e_2$ /m	
	左转	U 形弯	左转	U 形弯
18	0.118	0.231	0.097	0.144
36	0.175	0.297	0.125	0.178
54	0.224	0.395	0.153	0.213

注: $e_1$  为仿真轨迹和参考轨迹之间的横向最大偏差; $e_2$  为跟踪轨迹与参考轨迹之间的横向最大偏差。

由表 4 可知: 模型仿真轨迹与参考轨迹的误差较小, 吻合度高。其中横向误差在开始掉头时比其他位置大, 这是因为仿真过程中车辆由直线行驶转

向进入弯道时, 方向盘转角较大, 导致轨迹跟随效果稍有下降, 但在可接受范围内。车速增大时, 跟踪轨迹与参考轨迹的横向最大偏差有所增加, 但基本在一个较低值上下浮动, LQR 跟踪控制器的跟踪能力满足需求。尽管随着车速的增加, 横向最大偏差有所增大, 但整体上保持在较低水平。表明在左转和 U 形弯情况下基于 LSTM-BP 的转向轨迹预测模型具有较高的准确性。同时 LQR 跟踪控制器在跟踪能力方面表现出令人满意的效果, 进一步验证了仿人轨迹预测模型和跟踪控制算法的可行性和准确性。

### 4 结语

本文建立以模仿熟练驾驶员为基础的 LSTM-BP 神经网络转向轨迹预测模型, 利用 Simulink-PreScan-CarSim 联合仿真平台进行仿真试验, 结果表明: 该组合预测模型的预测精度比单一神经网络预测模型有较大提升, 且转向具有一定的仿人特性; 轨迹跟踪具有较好的准确性, 可以确保无人驾驶汽车具备安全可靠的稳定性。未来将使仿真场景更贴近实际情况, 以实现实时在线学习的功能, 提高仿人转向轨迹预测模型的精度和适用性。

### 参考文献:

- [1] GU J, MA A J. Research on optimal driver steering model based on Multi-Point preview [J]. Journal of Physics: Conference Series, 2017, 887(1): 10-15.
- [2] TAN Y S, SHEN H, Huang M H, et al. Driver directional control using two-point preview and fuzzy decision [J]. Journal of Applied Mathematics and Mechanics, 2016, 80(6): 459-465.
- [3] DANG H Q, FÜRNKRANZ J, BIEDERMANN A, et al. Time-to-lane-change prediction with deep learning [C] // IEEE. 2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC). Yokohama, Japan, 16-19 October 2017, IEEE: 1-9.
- [4] ZHAO Z, CHEN W H, WU X M, et al. LSTM network: a deep learning approach for short-term traffic forecast [J]. Iet Intelligent Transport Systems, 2017, 11(2): 68-75.
- [5] 张志威. 基于前车换道意图识别与车车通信的汽车防撞预警模型研究 [D]. 西安: 长安大学, 2021.
- [6] 王毅, 马臣斌. 基于模糊 PID 的无人驾驶车辆横向控制方法 [J]. 公路与汽运, 2024(2): 11-14.

收稿日期: 2024-01-14