

基于长短期记忆网络的高速公路车辆 变道轨迹预测模型

孙宏贤, 徐 兰

(云南省交通科学研究院有限公司, 昆明 650000)

摘要: 高速公路车辆车速、车距、行驶方向等因素都是动态变化的, 受外界环境干扰, 采集到的目标车辆状态特征数据可能存在噪声, 导致车辆变道轨迹预测存在误差, 为此提出基于长短期记忆网络的高速公路车辆变道轨迹预测模型, 有效预测高速公路车辆变道轨迹, 改善车辆行驶条件, 保障其安全运行; 通过激光雷达、GPS 等装置采集目标车辆交通数据, 将其合理组合成目标车辆状态观测特征向量, 并构建相应的特征向量矩阵, 将所构建目标车辆状态观测特征向量矩阵作为 1 层卷积神经网络输入, 提取目标车辆状态观测特征向量潜在特征后, 以 1 层卷积神经网络输出结果为双向长短期记忆网络有效输入, 经过模型迭代训练后, 输出目标车辆变道轨迹预测结果; 实验结果表明: 该模型可有效预测高速公路车辆变道轨迹, 预测出的轨迹横纵坐标误差极低, 预测耗时较短; 能够得到较为理想的高速公路车辆变道轨迹预测结果。

关键词: 长短期记忆网络; 高速公路; 车辆变道; 轨迹预测; 卷积神经网络; 交通数据采集

Lane Change Trajectory Prediction Model of Expressway Vehicles Based on LSTM Networks

SUN Hongxian, XU Lan

(Yunnan Transportation Research Institute Co., Ltd., Kunming 650000, China)

Abstract: The factors of vehicle speed, distance, and direction of travel on highways are all dynamic changes and interfered with external environments. The collected data on the state characteristics of target vehicles perhaps contains noise, leading to errors in predicting lane-changing trajectories. To address this issue, a highway vehicle lane-changing trajectory prediction model based on long short-term memory (LSTM) networks is proposed to effectively predict lane-changing trajectories on highways, and improve driving conditions to ensure safe operation. The target vehicle traffic data is collected by using devices such as laser radar and GPS. These data are reasonably combined into the target vehicle state observation feature vectors and corresponding feature vector matrices. The constructed target vehicle state observation feature vector matrix is used as an input to a 1-layer convolutional neural network to extract the latent features of the target vehicle state observation feature vectors. The output result of the 1-layer convolutional neural network is then used as the effective input to a bidirectional LSTM network. After the iterative training of the model, the predicted lane-changing trajectories of the target vehicle are obtained. The experimental results show that the model can effectively predict the lane-changing trajectories of highway vehicles with extremely low errors in both horizontal and vertical coordinates. Moreover, the prediction time is relatively short. It can achieve desirable prediction results for the lane-changing trajectories of highway vehicles.

Keywords: short-term memory network; expressway; vehicle lane change; trajectory prediction; convolutional neural network; traffic data collection

0 引言

随着交通运输的发展, 高速公路逐渐成为人们出行的主要方式之一。在驾驶操作中, 车辆变道是比较关键的一种驾驶行为, 然而, 高速公路上车辆的变道行为对交通流的安全和效率具有重要影响, 变道成功可使车辆行驶条件获得良好地改善, 而变道失败则有可能给车辆行驶安全带来较大的安全隐患^[1-3]。在现代社会中, 高速公路为人们

提供了快速、便捷的交通方式因此, 准确预测车辆的变道轨迹对于提高交通管理和安全性非常关键。高速公路上的车辆变道行为受到多种因素的影响, 包括车速、车距、行驶方向等。这些因素都是动态变化的, 受外界环境干扰, 采集到的目标车辆状态特征数据可能存在噪声, 导致车辆变道轨迹预测存在误差。因此, 车辆变道轨迹的预测一直是一个具有挑战性的问题^[4-5]。

收稿日期: 2023-05-24; 修回日期: 2023-07-07。

基金项目: 云南省数字交通重点实验室(202205AG070008); 2021年云南交投科技创新计划项目(YCIC-YF-2021-10)。

作者简介: 孙宏贤(1984-), 男, 硕士, 高级工程师。

引用格式: 孙宏贤, 徐 兰. 基于长短期记忆网络的高速公路车辆变道轨迹预测模型[J]. 计算机测量与控制, 2023, 31(12): 316-321.

基于上述研究背景, 相关领域研究学者纷纷对高速公路车辆变道轨迹预测模型做出了研究, 并取得了一定的研究成果。李立^[6]等人提出面向群体行驶场景的时空信息融合高速公路车辆变道轨迹预测模型, 通过长短期记忆网络对群体车辆速度实施合理预测, 并以此为可靠依据获取各群体车间产生的速度差值。之后通过构建合理的 LSTM 编码器对高速公路车辆在行驶过程中产生的时间性序列特征实施有效捕捉, 并通过卷积神经网络对各群体车辆之间存在的依赖关系实施合理挖掘, 最终通过 LSTM 解码器对未来车量变道动作发生的概率以及相应轨迹实施预测, 将拥有最大概率的变道动作以及其轨迹当作高速公路车辆变道轨迹预测结果。韩皓^[7]等人提出基于注意力 Seq2Seq 网络的高速公路车量变道轨迹预测模型。后者使用 Next 数据集获取高速公路车辆变道过程中的重要特征, 并把碰撞时间以及避免碰撞减速度当作风险指标, 对其执行合理引入操作, 将目标车辆与其四周存在的车辆看作是一个完整的状态单元, 与此同时对该状态单元中包含各车辆的横纵空间状态特征执行有效补充操作, 以便实现对各车辆动态交互状态的合理刻画, 之后将各车辆拥有的连续窗口序列输入到长短期记忆网络中, 经有效的编码解码操作完成交织车辆运动轨迹预测, 在此基础上, 最终通过向长短期记忆网络中添加注意力模块的方式, 再现车辆变道行为, 完成高速公路车辆变道轨迹预测。二者均可有效预测高速公路车辆变道轨迹, 但是预测效果并不理想。

双向长短期记忆网络其内部所拥有的存储单元能够有效指示与表示输入到该网络中过往信息数据的遗忘时间与新信息数据的更新时间, 故可显著降低神经网络在进行网络学习时, 梯度消失问题发生的概率, 将其应用于高速公路车辆变道轨迹预测工作中, 可得到更好的高速公路车辆变道轨迹预测效果。为此, 本文提出基于长短期记忆网络的高速公路车辆变道轨迹预测模型, 以更好地满足实际需要。

1 高速公路车辆变道轨迹预测模型

1.1 高速公路车辆变道轨迹预测模型框架与实现流程

在高速公路车辆运行交通场景下, 针对行驶目标车辆的变道轨迹预测问题, 构建基于长短期记忆网络的高速公路车辆变道轨迹预测模型, 将该高速公路车辆变道轨迹预测模型表示为 f , f 的框架结构如图 1 所示。

向该模型输入 $t-2$ 时刻、 $t-1$ 时刻与 t 时刻的目标车辆状态观测特征向量构成的特征矩阵, 经 1 层卷积神经网络挖掘深层次特征后, 再交由长短期记忆网络执行有效学习操作, 可输出高速公路目标车辆在 $t+1$ 时刻的变道轨迹预测数据。

模型的具体实现流程如图 2 所示。

获取目标车辆状态观测特征向量是完成高速公路车辆变道轨迹预测工作的首要前提, 观测特征向量中包含的交通数据在本文中主要通过激光雷达、GPS、毫米波雷达等装

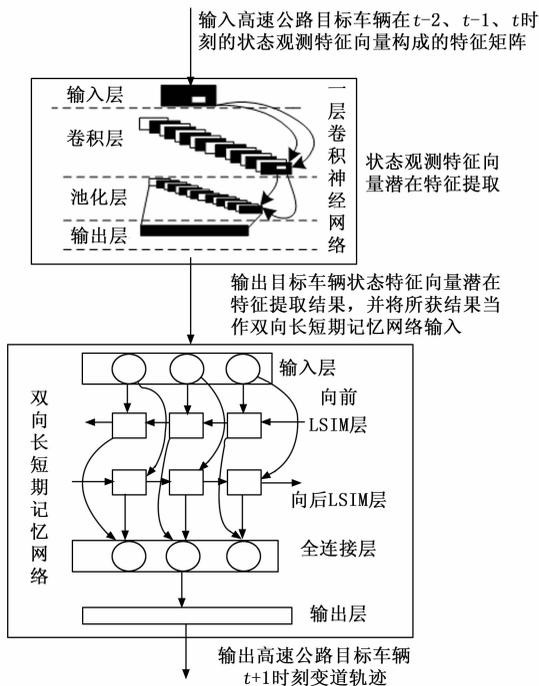


图 1 高速公路车辆变道轨迹预测模型架构

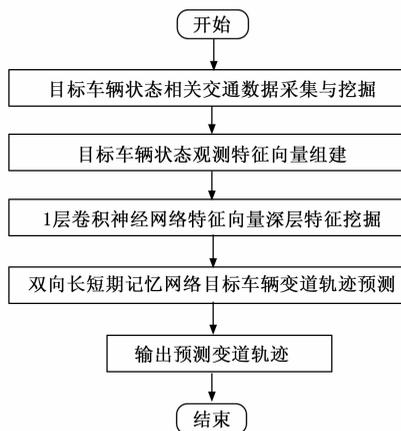


图 2 模型实现流程

置实现采集与挖掘, 采集与挖掘出相应的交通数据后, 将其以合理顺序组合在一起, 便可构成目标车辆状态观测特征向量; 完成目标车量状态观测特征向量获取工作后, 为收获更为理想的高速公路车辆变道轨迹预测结果, 需将其构成相应的特征矩阵并将其送入 1 层卷积神经网络结构中, 对其执行有效的潜在特征提取操作, 获取其深度特征, 该项操作完毕后, 将获得的目标车辆状态观测特征向量潜在特征输入到双向长短期记忆网络中, 经过有效学习, 便可输出高速公路目标车辆变道轨迹预测结果。

1.2 高速公路目标车辆状态观测特征向量获取

在实际的高速公路车辆变道轨迹预测工作中, 对目标车辆变道轨迹的预测多是依据目标车辆本身运行状态以及周围环境因素的时空关系来预测的^[8-9]。因而需要挖掘多种

交通数据构成目标车辆状态观测特征向量，通常该向量中包含的交通数据包括目标车辆车身长与宽、目标车辆的瞬时速度以及加速度、目标车辆与其周围车辆间的瞬时距离以及目标车辆与前车在运行期间产生的时距。

在本文中，目标车辆的长度以及宽度用 L, K 表示，在实际工作中通过对目标车辆测量获得或由目标车辆所有者提供；目标车辆与其周围车辆间的瞬时距离用 $D^{(t)}$ 表示，由车载激光雷达对点云距离阈值范围执行有效采集与筛选操作获得；目标车辆与前车在运行期间产生的时距用 $T^{(t)}$ 表示，由车载毫米波雷达获取与前车车距并瞬时有效碰撞时间获得；目标车辆预测轨迹在 t 时刻的横纵坐标分别用 $X^{(t)}, Y^{(t)}$ 表示，瞬时速度用 $v^{(t)}$ 表示，三者在实际工作中可被统称为定位信息，是高速公路车辆变道预测工作中非常关键的三个交通数据，均可通过在 GPS 定位装置中使用基于 ARM9 与 WindowsCE 的车辆 GPS 定位信息采集技术实时获取；目标车辆瞬时加速度用 $a^{(t)}$ 表示，通过对 $v^{(t)}$ 执行有效求导操作获得。基于 ARM9 与 WindowsCE 的车辆 GPS 定位信息采集技术架构如图 3 所示。

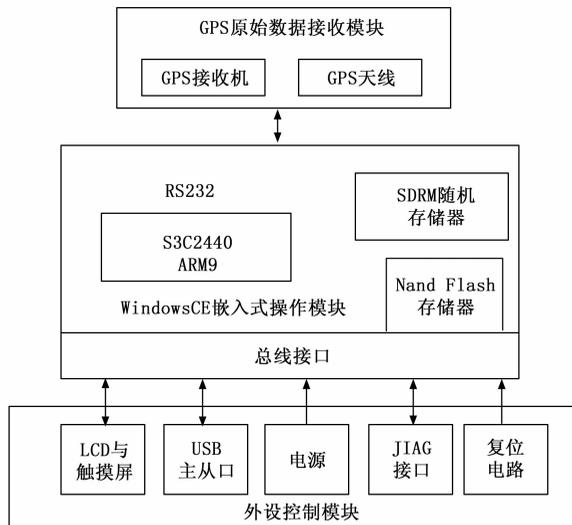


图 3 车辆 GPS 定位信息采集技术架构

该采集技术架构主要包含 GPS 原始数据接收模块、WindowsCE 嵌入式操作模块以及外设控制模块三部分。GPS 原始数据接收模块以 GPS 接收机以及 GPS 天线为主要构成。在实际的工作中，利用外接 GPS 接收机将接收的车载 GPS 原始定位信息，发送给以 S3C2440 ARM9 嵌入式处理器、SDRM 随机存储器等模块为主要构成的 WindowsCE 嵌入式操作模块，实施合理的数据解析，便可获得目标车辆的定位信息，即 $X^{(t)}, Y^{(t)}$ 与 $v^{(t)}$ 。之后可通过外设控制模块完成人机交互工作，可视化呈现所获得的 $X^{(t)}, Y^{(t)}$ 与 $v^{(t)}$ 。

在采集与挖掘完上述目标车辆交通数据后，对其实施合理组合，便可获取到目标车辆的状态观测特征向量。 t 时刻的目标车辆状态观测特征向量用公式可被描述为：

$$\mathbf{B}^{(t)} = [L, K, X^{(t)}, Y^{(t)}, v^{(t)}, a^{(t)}, D^{(t)}, T^{(t)}] \quad (1)$$

同理，也可将 $t - 2$ 时刻的目标车辆状态观测向量 $\mathbf{B}^{(t-2)}$ 、 $t - 1$ 时刻的目标车辆状态观测特征向量 $\mathbf{B}^{(t-1)}$ 表示成式 (1) 形式。

1.3 目标车辆状态观测特征向量潜在特征提取

有效挖掘各特征向量间的潜在关系，获得双向长短期记忆网络的有效输入，是能够完成高速公路车辆变道轨迹预测的关键^[10]。目标车辆状态观测特征向量潜在特征提取是指从目标车辆状态观测特征向量中识别和捕获其中的潜在模式和特征的过程。该步骤旨在提取最具信息量的相关特征，以用于预测目标车辆的变道轨迹。

在所提出的模型中，潜在特征提取是通过一个 1 层卷积神经网络 (CNN) 来完成的。该 CNN 将构建的目标车辆状态观测特征向量矩阵作为输入，并应用一系列卷积操作来提取有意义的空间和时间特征。通过潜在特征提取，目标车辆状态观测特征向量中的重要信息和特征被有效地捕获和表示。这些潜在特征将作为后续步骤的输入，用于预测目标车辆的变道轨迹。通过合理的潜在特征提取，能够更准确地捕捉目标车辆状态的关键特征，从而提高模型的预测性能和准确度。

基于卷积神经网络在数据深度特征提取方面的优势^[11-13]，本文使用一层卷积神经网络，对目标车辆状态观测特征向量的潜在特征执行有效提取操作。具体的潜在特征提取流程可简单归结如下：

1) 将获取的 $t - 2$ 时刻、 $t - 1$ 时刻与 t 时刻的目标车辆状态观测特征向量 $\mathbf{B}^{(t-2)}$ 、 $\mathbf{B}^{(t-1)}$ 、 $\mathbf{B}^{(t)}$ 联立在一起，构成目标车辆状态观测特征向量矩阵，并将该矩阵表示为 \mathbf{x} 。

2) 将构建的目标车辆状态观测特征向量矩阵 \mathbf{x} 输入到图 1 中显示的 1 层卷积神经网络的卷积层中，对目标车辆状态观测特征向量矩阵中各数据元素间的潜在关系实施有效挖掘。该潜在关系的获取主要是通过卷积层拥有的卷积核对上层输出执行有效卷积操作获得的。其获取过程用公式可描述成：

$$x'_j = G(\mathbf{B}^{(t)}) \sum x_i^{t-1} k_{ij} + b'_j \quad (2)$$

其中：第 l 层的第 j 个卷积核的第 i 个权重系数、网络偏置系数、输出矩阵分别用 k'_{ij} 、 b'_j 以及 x'_j 表示；卷积函数与第 l 层的第 i 个输入矩阵分别用 G 、 x_i^{t-1} 表示。

3) 通过步骤 2) 获取到目标车辆状态观测特征向量矩阵中的数据元素潜在关系后，通过激活函数对所获潜在关系执行特征提取操作，得到目标车辆状态观测特征向量潜在特征。在本文中 Sigmoid 函数当作激活函数使用，Sigmoid 激活函数用公式可被描述成：

$$\text{Sigmoid}(x) = x'_j \left[1 + \left(\frac{1}{e^x} \right) \right] \quad (3)$$

其中： \mathbf{x} 表示目标车辆状态观测特征向量矩阵； e 表示欧拉常数。

1.4 双向长短期记忆网络车辆变道轨迹预测

双向长短期记忆网络相较于其他神经网络，其内部所拥有的存储单元能够有效指示与表示输入到该网络中过往

信息数据的遗忘时间与新信息数据在更新时的时刻, 从而有效降低神经网络在执行向后传播操作时, 由产生误差造成的梯度消失或爆炸问题^[14-15]。基于此, 在实际工作中, 可充分利用其超强的长距离依赖关系捕获能力, 较为完美地完成对序列类数据或向量的有效学习工作, 因而十分适合用于解决各种轨迹预测问题。基于双向长短期记忆网络在轨迹预测方面的优势, 本文使用该网络将由一层卷积神经网络输出的目标车辆状态观测特征向量潜在特征当作有效输入, 输入到长短期记忆网络中进行有效学习, 完成高速公路车辆变道轨迹预测工作。

双向长短期记忆网络的隐含层均是由 LSTM 单元构成的, LSTM 单元又以输入与输出门、遗忘门以及记忆单元几个门控单元为主要构成, 在实际工作中, 对输入到网络中的目标车辆状态观测特征向量潜在特征流向的有效控制, 是通过这些门控单元实现的。遗忘门主要决定目标车辆状态观测特征向量潜在特征中包含的哪些信息要素应该从记忆细胞中被移除, 遗忘掉; 输入门主要负责对上一时刻输出的有效数据以及现下输入的有效数据, 对网络中记忆细胞输入产生的影响执行有效控制操作; 记忆细胞承担的主要职责是对细胞当前情况下所产生的状态向量执行有效存储操作。LSTM 单元中诸多变量间的关系可用公式描述如下:

$$f_{j,t} = \sigma(\xi_j^f[h_{t-1}, x_t]) + \sigma(b_j^f) \quad (4)$$

$$i_{j,t} = \sigma(\xi_j^i[h_{t-1}, x_t]) + \sigma(b_j^i) \quad (5)$$

$$o_{j,t} = \sigma(\xi_j^o[h_{t-1}, x_t]) + \sigma(b_j^o) \quad (6)$$

$$\tilde{C}_{j,t} = \sigma(\xi_j^c[h_{t-1}, x_t]) + \sigma(b_j^c) \quad (7)$$

$$C_{j,t} = f_{j,t} \circ C_{j,t-1} + i_{j,t} \circ \tilde{C}_{j,t} \quad (8)$$

$$h_{j,t} = o_{j,t} \cdot \tanh C_{j,t} \quad (9)$$

其中: j 表示 LSTM 单元, 其在当前时刻的遗忘门、输出与输入门向量以及记忆细胞所显示的状态向量分别用 $f_{j,t}$ 、 $o_{j,t}$ 、 $i_{j,t}$ 以及 $C_{j,t}$ 表示; 记忆细胞输入以及输出细胞向量分别用 $\tilde{C}_{j,t}$ 、 $h_{j,t}$ 表示; h_{t-1} 表示上一时刻的隐含层输出向量; x_t 表示现下时刻输入的目标车辆状态观测特征向量潜在特征; j 所拥有的遗忘门的有效权重矩阵以及偏置项分别用 ξ_j^f 与 b_j^f 表示; 输入门的有效权重矩阵以及偏置项分别用 ξ_j^i 、 b_j^i 表示; 输出门的有效权重矩阵以及偏置项分别用 ξ_j^o 、 b_j^o 表示; 记忆细胞的有效权重矩阵以及偏置项分别用 ξ_j^c 、 b_j^c 表示; \circ 表示哈达玛积; $\sigma(\cdot)$ 表示激活函数。

在实际工作中, 一层卷积神经网络通过 Sigmoid 函数实现目标车辆状态观测特征向量潜在特征提取, 并将其送入图 1 中显示的双向长短期记忆网络后, 通过向前与向后的 LSTM 层执行对目标车辆状态观测特征向量潜在特征执行有效的流向控制以及捕获操作, 最终可输出相应的车辆变道轨迹预测结果, 最终的输出用公式可描述成:

$$y_t = \xi_{\bar{i}} \vec{h}_t + \xi_{\bar{o}} \vec{h}_t + b_y \quad (10)$$

其中: y_t 表示由双向长短期记忆网络输出的高速公路车辆变道轨迹预测结果; $\xi_{\bar{i}}$ 表示向前 LSTM 层与输出层之间的有效权重; $\xi_{\bar{o}}$ 表示向后 LSTM 层与输入层之间的有效权

重; b_y 表示目标车辆状态观测特征向量潜在特征在双向长短期记忆网络隐藏单元存在的有效偏置。

2 实验与分析

2.1 实验环境及实验方法设置

为验证所提基于长短期记忆网络的高速公路车辆变道轨迹预测模型的有效性, 搭建的智能汽车实验平台实施高速公路车辆变道轨迹预测实验。搭建的智能汽车实验平台集成了激光雷达、惯导系统 GPS 定位装置等多种硬件设备, 利用上、下位机对集成的各种硬件设备实施有效控制, 完成相关实验操作。智能汽车实验平台概况如图 4 所示。



图 4 智能汽车实验平台概况

在图 4 搭建的智能汽车实验平台下, 设置高速公路车辆变道轨迹预测模型实验环境参数如下:

- 1) 高速公路道路条件: 在搭建的智能汽车实验平台下, 选择一段高速公路进行实验, 确保道路平坦、无明显障碍物, 并设置合适的车道宽度和车流量。
- 2) 数据采集装置: 在实验车辆上安装激光雷达、GPS 等传感器, 并连接到数据采集装置, 用于采集目标车辆的交通数据。

实验数据是基于同一实验车所获取的智能车辆交通数据, 采集地点为某省 F 市的环城高速公路, 实验中将激光雷达数据采集周期设置为 0.6 s, 所使用车载 GPS 定位装置的各项技术参数状况如表 1 所示。

表 1 GPS 定位装置参数情况

参数名称	参数值
型号	J01A
产品规格	79 mm * 29 mm * 17 mm
产品重量	35.6 g
定位方式	GPS+LBS 双模定位
GSM 频段	850/900/1 800/1 900 MHz
GPS 芯片	AT6558T
GPS 灵敏度	-162 dBm
精准度	3~30 m
定位时间	小于 30 s
电池类型	聚合物电池
电压范围	9~100 V
工作温度	-20~55 °C

在上述实验环境及参数设置的基础上，设计实验步骤如下：

1) 数据采集：在高速公路上驾驶实验车辆，通过激光雷达和 GPS 等传感器，采集目标车辆的交通数据，包括车速、车距、行驶方向等信息。将这些数据保存为样本数据集，用于训练和测试模型。

2) 数据预处理：对采集到的交通数据进行预处理，包括数据清洗、特征提取和标准化等步骤，以得到适合模型输入的数据格式。

3) 模型训练：使用长短期记忆网络 (LSTM) 作为基础模型，将预处理后的数据作为输入，通过迭代训练来优化模型的权重和参数，以实现高速公路车辆变道轨迹的预测功能。

4) 模型评估：使用测试数据集对训练好的模型进行评估，计算预测结果与真实变道轨迹之间的误差，并分析模型的准确性和鲁棒性。

5) 实验结果分析：根据评估结果和误差分析，对模型的有效性和可靠性进行验证和分析，并与其他方法进行比较，以验证所提出的基于 LSTM 的高速公路车辆变道轨迹预测模型的优势和性能。

通过以上实验环境参数设置和实验方法步骤，可以在智能汽车实验平台上进行高速公路车辆变道轨迹预测实验，并评估所提出的模型的有效性和性能。这将为交通管理和智能交通系统的发展提供重要参考，并为改善车辆行驶条件和保障交通安全提供技术支持。

2.2 实验结果分析

在上述实验环境及参数的应用下，利用本文模型采集到的部分智能汽车交通数据如表 2 所示。

表 2 智能汽车交通数据

编号	目标车辆预测轨迹在 t 时刻的横坐标 /m	目标车辆预测轨迹在 t 时刻的纵坐标 /m	瞬时速度 / $m \cdot s^{-1}$	目标车辆瞬时加速度 / $m \cdot s^{-2}$	目标车辆与其周围车辆间的瞬时距离 /m	目标车辆与前车在运行期间产生的时距/s
1	43.012	31.072	28.37	0	2.17	1.08
2	42.865	35.076	28.37	0	2.65	1.07
3	42.567	39.021	28.37	0	3.18	1.06
4	42.434	42.569	28.37	0	3.86	1.05
5	42.431	46.532	28.37	0	2.58	1.04
6	42.212	50.123	28.37	4.87	2.51	1.04
7	42.203	54.116	28.69	6.12	3.13	1.01
8	42.198	58.014	28.97	4.69	3.75	0.97
9	42.195	62.053	29.53	1.43	3.21	0.93
10	42.175	66.015	30.01	-0.12	2.66	0.91

从表 2 可以看出，应用本文模型能够有效采集高速公路车辆交通数据，可为高速公路车辆变道轨迹预测工作提供可靠的数据保障。

根据表 2 所获车辆交通数据，应用本文模型对实验用

智能汽车实施有效车辆变道轨迹预测，并引入文献 [6] 提出的面向群体行驶场景的时空信息融合高速公路车辆变道轨迹预测模型，文献 [7] 提出的基于注意力 Seq2Seq 网络的高速公路车量变道轨迹预测模型作为实验对照组，获得车辆变道轨迹横纵坐标预测对比结果如图 5 所示。

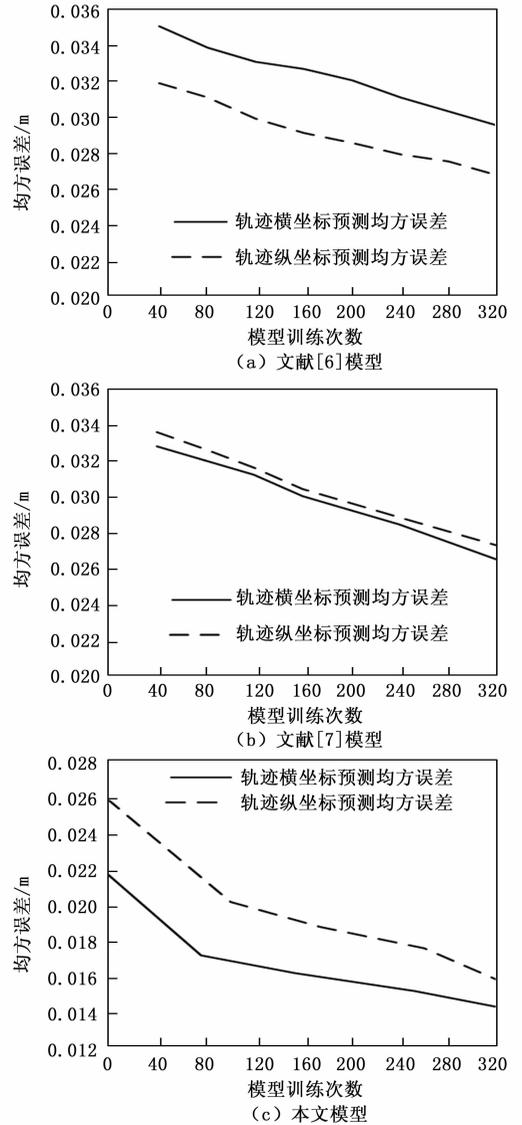


图 5 车辆变道轨迹横纵坐标预测结果

分析图 5 可知，应用文献 [6] 模型对智能汽车实施高速公路车辆变道轨迹横纵坐标预测，横坐标预测均方误差高于纵坐标，最高误差为 0.035 m；应用文献 [7] 模型对智能汽车实施高速公路车辆变道轨迹横纵坐标预测，纵坐标预测均方误差高于横坐标，最高误差为 0.034 m；应用本文模型对该智能汽车实施高速公路车辆变道轨迹横纵坐标预测，获得的均方误差均较低，虽然纵坐标预测均方误差要高于横坐标预测误差，但在模型训练的过程中，最高误差也仅为 0.026 m。实验结果表明，本文模型可较为准确地完成高速公路车辆变道轨迹预测工作，在实际工作中具有

较好的应用效果。得出该结果的原因为, 本文方法通过构建相应的特征向量矩阵, 更全面地考虑车辆行驶状态的动态变化, 并将其作为输入层的卷积神经网络, 有效提取目标车辆状态观测特征向量的潜在特征。在此基础上引入了双向长短期记忆网络, 将卷积神经网络的输出结果作为其有效输入。经过模型的迭代训练, 最终能够输出目标车辆变道轨迹的预测结果。

在此基础上, 测试 3 种方法对高速公路车辆变道轨迹预测的效率, 实验结果如图 6 所示。

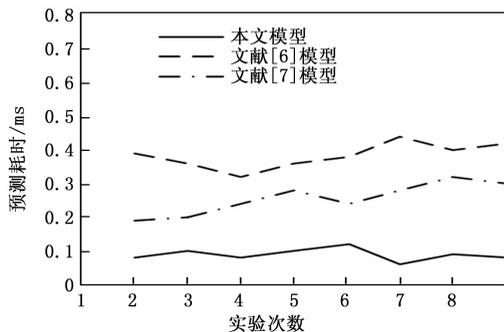


图 6 车辆变道轨迹预测效率结果

分析图 6 结果可知, 应用文献 [6] 模型对智能汽车实施高速公路车辆变道轨预测, 预测耗时平均值为 0.40 ms; 文献 [7] 模型的预测耗时平均值为 0.25 ms; 应用本文模型的预测耗时平均值为 0.09 ms。实验结果表明, 本文模型对高速公路车辆变道轨迹预测的耗时较短。可以实时地进行变道轨迹预测, 帮助驾驶员在提前感知到其他车辆的行为, 增加驾驶员的反应时间, 从而提高交通流的安全性。并可及时将预测结果应用于交通管理系统中, 从而提高交通的效率。

综合上述实验结果可知, 基于长短期记忆网络的高速公路车辆变道轨迹预测模型能够准确预测轨迹纵横坐标, 且预测耗时较短。应用本文模型可以及时将预测结果传输给其他车辆或交通管理系统。有助于优化智能交通系统的运行, 提高车辆之间的协同性和整体效能。

3 结束语

本文提出了一种基于长短期记忆网络的高速公路车辆变道轨迹预测模型。基于激光雷达、GPS 等装置采集目标车辆交通数据, 应用 1 层卷积神经网络和双向长短期记忆网络构建的高速公路车辆变道轨迹预测模型。利用 LSTM 网络对车辆变道轨迹进行预测, 实现了对车辆变道行为的准确预测和监控。这种方法的创新之处在于将多种不同的数据源进行整合, 并通过卷积神经网络和双向长短期记忆网络的结合, 实现了对目标车辆变道轨迹的准确预测。通过采集的交通数据和特征向量的构建, 可以更全面地考虑车辆行驶状态的动态变化, 从而提高了预测模型的精度和鲁棒性。实验结果表明, 应用本文模型可有效采集高速公路车辆交通数据, 将其作为可靠依据, 进一步完成相关的

车辆变道轨迹预测工作, 预测的车辆变道轨迹纵横坐标均方误差均较低, 可更好满足实际工作需要。该模型具有预测精度高、适用性强等优点, 应用该模型可以提高交通流的安全性和效率, 优化智能交通系统的运行, 并为改善车辆行驶条件和保障交通安全提供技术支持。

参考文献:

- [1] 梁军, 王珊珊, 陈龙, 等. 面向紧急变道行为的协同避撞控制模型 [J]. 华中科技大学学报 (自然科学版), 2022, 50 (1): 13-19, 25.
- [2] 杨文彦, 张希, 陈浩, 等. 基于社会力的自动驾驶汽车行人轨迹预测模型 [J]. 公路交通科技, 2020, 37 (8): 127-135.
- [3] 郭烈, 王旭, 胥林立, 等. 基于状态空间采样的高速公路智能网联车辆轨迹动态规划 [J]. 中国公路学报, 2022, 35 (12): 253-267.
- [4] 李嘉, 周湖伟, 周正, 等. 基于改进型目标重识别算法的高速公路车辆轨迹还原 [J]. 计算机应用研究, 2021, 38 (11): 3382-3386.
- [5] 赖金萍, 李浩, 石英, 等. 基于 DDPG 算法的无人车辆防碰撞控制策略 [J]. 武汉理工大学学报, 2021, 43 (10): 68-76.
- [6] 李立, 平振东, 朱进玉, 等. 面向群体行驶场景的时空信息融合车辆轨迹预测 [J]. 交通运输工程学报, 2022, 22 (3): 104-114.
- [7] 韩皓, 谢天. 基于注意力 Seq2Seq 网络的高速公路交织区车辆变道轨迹预测 [J]. 中国公路学报, 2020, 33 (6): 106-118.
- [8] 郭应时, 张瑞宾, 陈元华, 等. 基于观测数据潜在特征与双向长短期记忆网络的车辆轨迹预测 [J]. 汽车技术, 2022, 558 (3): 21-27.
- [9] 孙倩, 郭忠印. 基于长短期记忆神经网络方法的车辆跟驰模型 [J]. 吉林大学学报 (工学版), 2020, 50 (4): 1380-1386.
- [10] 聂枝根, 王万琼, 赵伟强, 等. 基于轨迹预瞄的智能汽车变道动态轨迹规划与跟踪控制 [J]. 交通运输工程学报, 2020, 20 (2): 147-160.
- [11] 谭紫阳, 高忠文, 邓宇. 基于改进极限学习机和深度神经网络融合的车辆轨迹长期预测 [J]. 汽车技术, 2020, 542 (11): 16-20.
- [12] 徐佳晨, 祖炳锋, 周建伟, 等. 基于横向稳定的减速变道轨迹与跟踪控制 [J]. 公路交通科技, 2022, 39 (2): 183-190.
- [13] 罗锦才, 刘瞰东. 基于增强学习的车辆转弯制动横向轨迹控制 [J]. 计算机仿真, 2021, 38 (7): 107-110.
- [14] 李文书, 邹涛涛, 王洪雁, 等. 基于双尺度长短期记忆网络的交通事故量预测模型 [J]. 浙江大学学报 (工学版), 2020, 54 (8): 1613-1619.
- [15] 李文礼, 韩迪, 任勇鹏, 等. 基于交互车辆轨迹预测的自动驾驶车辆轨迹规划 [J]. 计算机应用研究, 2023, 40 (2): 519-525, 538.