

DOI: 10.13382/j.jemi.B2508137

基于车路云协同感知的车辆驾驶意图识别方法^{*}

李海青 雷宇铖 戴盈莹 禄 盛 罗久飞

(重庆邮电大学集成电路学院 重庆 400065)

摘 要:准确获取车辆驾驶意图对自动驾驶至关重要,针对单车智能在复杂交通场景存在感知能力不足等问题,提出了一种基于车路云协同感知的车辆驾驶意图识别方法。首先,通过车路云协同感知构建网联信息交互总体框架,解析车车、车路、路云协同信息流;其次,结合双向长短时记忆网络(Bi-LSTM)和XGBoost算法,建立车辆意图识别模型,通过融合车辆历史轨迹和周围环境车辆的动态特征,提升驾驶意图识别的准确性;最后,创新性引入了Bi-LSTM的双向序列处理机制,使模型能够同时捕捉正向与反向的时间依赖关系,并在数据处理方面进行优化,提高模型在复杂交通场景下的鲁棒性。在NGSIM数据集的测试表明,与传统XGBoost模型和LSTM-XGBoost模型相比,Bi-LSTM-XGBoost模型在换道意图识别中的整体识别准确率达到97.4%;模型在因果约束条件下仍保持97.2%的准确率。通过Sumo与Carla的联合仿真测试,分析了不同数量车辆对模型识别效率的影响,结果表明模型能够在100 ms内实时识别驾驶意图;在车路云协同感知道路下采集的实际数据进行测试,结果表明建立的模型具有较高的意图识别及轨迹预测能力,应用于自动驾驶,可显著增强车辆在复杂交通场景中的感知能力与适应性。

关键词:意图识别;车路云;协同感知;自动驾驶

中图分类号: U491.2;TN98 **文献标识码:** A **国家标准学科分类代码:** 460. 40

Vehicle driving intention recognition method based on vehicle-road-cloud collaborative perception

Li Haiqing Lei Yucheng Dai Yingying Lu Sheng Luo Jiufei

(School of Integrated Circuits, Chongqing University of Posts and Telecommunications, Chongqing 400065, China)

Abstract: Accurately recognizing vehicle driving intentions is crucial for autonomous driving. To address the issues of limited perception capabilities in complex traffic scenarios with single-vehicle intelligence, this paper proposes a vehicle driving intention recognition method based on Vehicle-Road-Cloud collaborative perception. First, an overall framework for information exchange is established through Vehicle-Road-Cloud collaborative perception, analyzing the information flow of vehicle-to-vehicle, vehicle-to-road, and road-to-cloud communication. Next, a vehicle intention recognition model is developed by combining Bi-LSTM and the XGBoost algorithm. By integrating the vehicle's historical trajectory data with the dynamic features of surrounding vehicles, the model enhances the accuracy of driving intention recognition. Finally, the innovative Bi-LSTM bidirectional sequence processing mechanism is introduced, allowing the model to simultaneously capture both forward and backward temporal dependencies, optimizing data processing and improving the model's robustness in complex traffic scenarios. Testing on the NGSIM dataset shows that, compared to traditional XGBoost and LSTM-XGBoost models, the Bi-LSTM-XGBoost model achieves an overall recognition accuracy of 97.4% in lane-change intention recognition and the model maintains an accuracy of 97.2% under causal constraints. Through co-simulation testing with Sumo and Carla, the impact of varying vehicle numbers on the model's recognition efficiency is analyzed, with results indicating that the model can recognize driving intentions in real-time within 100 ms. Further testing on a real-world dataset collected from a Vehicle-Road-Cloud collaborative perception system demonstrates that the model meets real-time requirements, exhibits high trajectory prediction capability, and enhances the perception and adaptability of autonomous vehicles in complex scenarios.

Keywords: intention recognition; vehicle-road-cloud; collaborative perception; autonomous driving

收稿日期:2025-01-22 Received Date: 2025-01-22

^{*} 基金项目:国家重点研发计划项目(2023YFB2504700)、重庆市教委科学技术研究项目(KJQN202500626)、重庆市研究生科研创新项目(CYS25483)资助

0 引言

近年来,自动驾驶技术快速发展,以单车智能为主的车辆在感知、决策和控制方面面临许多挑战^[1]。从感知角度来看,单车存在感知盲区,限制了自动驾驶从辅助驾驶阶段向全自动驾驶阶段的过渡。车路云一体化系统(vehicle-road-cloud integrated system, VRCIS)通过将车载单元(on-board unit, OBU)、路侧设备与云平台进行深度信息融合,实现了车路云之间的实时数据共享与智能决策^[2]。VRCIS 的基础是构建车路云协同感知框架(vehicle-road-cloud collaborative perception framework, VRCCPS),即 VRCIS 的感知部分,基于 VRCCPS 实现数据实时共享的车辆能够实现更高的感知精度,超越仅依赖车载传感器的自动驾驶车辆^[3]。在车路协同感知技术方面,已有多篇文献分别讨论了感知算法^[4]、通信方式^[5]、路侧传感布置^[6]、节点优化^[7]等问题,然而,专门针对 VRCCPS 及其相关技术的研究较为稀缺,当前还面临许多挑战,涉及从硬件部署到软件算法开发的多个方面^[2]。

在 VRCIS 中,驾驶意图是连接驾驶决策与交通环境动态变化的关键纽带,居于核心地位^[8]。虽然车辆的被动安全措施能够在交通事故发生后减轻伤害,但从源头预防事故,提前识别周车的换道意图,对于减少交通事故和提高交通效率至关重要^[9]。自动驾驶要求车辆能够主动感知周围环境的变化,准确识别短期内的换道意图,从而做出最优的换道决策,完成复杂驾驶场景任务^[10]。驾驶意图识别一直是国内外学者研究的重点领域,核心目标均是提升驾驶意图识别的准确性和实时性,以增强自动驾驶的安全性和可靠性。

早期研究主要利用简单的监督学习对驾驶意图进行建模,并且使用的输入参数较为有限。近年来,随着人工智能技术的迅猛发展,意图识别模型在方法上发生了显著变化^[11],从传统统计模型不断演进。生成模型以概率分布建模为核心,主要通过捕获驾驶行为的内部状态变化来预测驾驶意图。Liu 等^[12]利用隐马尔可夫模型对车辆的历史轨迹和动态特征进行离散或连续建模,结合周边车辆动态特征,提高了变道或保持车道意图预测的精度。Li 等^[13]结合隐马尔可夫模型与贝叶斯滤波,实现了换道意图的识别,左换道和右换道预测精度分别达到 93.5% 和 90.3%。Zhang 等^[14]提出了基于 XGBoost 的三步特征学习算法,综合特征重要性排序、指标筛选和递归特征消除,通过滑动窗口方法生成时间序列数据集,车道变更预测准确率达到 97.6%。

深度学习模型以自动特征提取和强大的非线性建模能力为特点,近年来成为驾驶意图识别的主流方向。季

学武等^[15]利用长短期记忆(LSTM)网络并结合混合密度网络进行车辆意图识别,提高了模型在复杂场景中的精度和鲁棒性。赵建东等^[16]将卷积神经网络(CNN)与门控循环单元(GRU)结合,并引入注意力机制优化特征权重分配,实现了换道前 2 s 内 89% 以上的预测准确率。方华珍等^[17]通过混合示教长短时记忆网络预测未来轨迹,并结合 XGBoost 算法建立驾驶意图分类识别模型,利用公开数据集进行测试验证,意图识别平均准确率达到 97.7%。Zhang 等^[18]提出基于互联环境的驾驶意图识别模型,将时间序列数据转换为图像,利用 Swin Transformer 算法进行高精度分类,实现换道前不同时间段的精准预测。

综上所述,当前驾驶意图识别大多依赖于有限的行为特征,未充分考虑驾驶环境的复杂性,且停留在公开数据集上进行测试验证。为了提高车辆驾驶意图识别准确性的同时,考虑复杂场景的时效性,本文利用车路云协同感知提出了一种基于双向长短时神经网络的意图识别模型,通过将车辆历史轨迹等数据作为模型输入,识别车辆驾驶意图,其主要的创新点如下:1)构建了车路云协同感知的驾驶意图识别框架,克服了单车智能在复杂场景中的感知局限,实现了更广泛、更可靠的环境感知与决策支持;2)创新性引入了 Bi-LSTM 结构融合双向时序特征提取机制,增强了对驾驶行为时序依赖关系的建模能力,提升了意图识别准确性与轨迹预测一致性;3)在 NGSIM 公开数据集、Sumo-Carla 联合仿真平台和真实 VRCIS 分别进行了多维度测试验证,模型能够有效识别车辆驾驶意图,且满足实时性要求。

1 车路云一体化系统

1.1 车路云协同感知框架

车路云协同感知系统主要涉及物理层的车端与路侧单元(road side unit, RSU)和网络层的云平台之间的数据感知、交互和智能协同,每一方有不同的功能和责任。VRCCPS 如图 1 所示。车端负责采集车辆状态信息,并通过车联网与环境中路侧单元和云端进行实时数据交互。RSU 设备安装在道路设施上,负责收集周围交通流量、交通标志、交通信号灯等信息。云端作为车路协同系统的“大脑”,汇集来自各车辆、路侧单元和传感器的数据。

1.2 VRCIS 信息交互机制

VRCIS 的核心在于通过实时数据交换提升交通效率与安全。交通流和车辆信息的实时共享显著提高了交通管理的精度和响应速度,有效解决了传统交通管理系统中的信息滞后问题^[19]。车辆通过 OBU 与云端进行实时

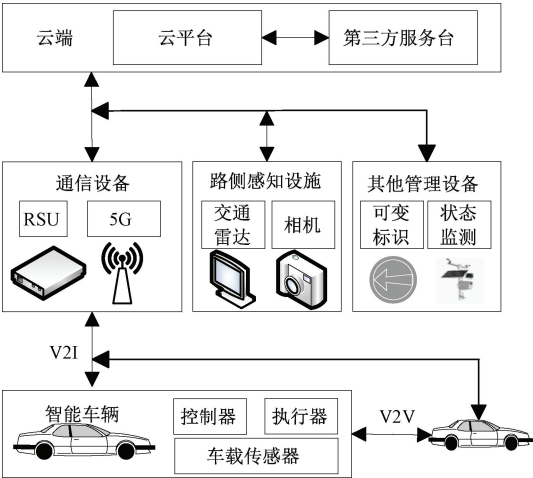


图 1 车路云协同感知框架
Fig. 1 The framework of VRCCPS

信息交互。OBU 负责采集车辆的状态信息,如速度、航向角、位置等,并通过 CAN 网络将这些信息传输给车载控制器。RSU 与云端通过 MQTT 协议连接,车端 OBU 与 RSU 通过 C-V2X(车-路通信)协议连接,同时车辆与路侧单元之间使用 PC5&Uu (LTE-V) 网络进行通信。车端与外部交互都在 OBU 上进行,OBU 接收外部信息后转送至车载协同控制器,同时 OBU 根据具体协同驾驶场景下的需要从车载协同控制获取信息转发至外部需求方。RSU 于路侧需接入通信范围内的网联车辆进行交互并配合 RCU 交互引导控制信息,同时也连接云端,接收其管控信息并上报路端信息。VRCIS 信息交互详细流程如图 2 所示。

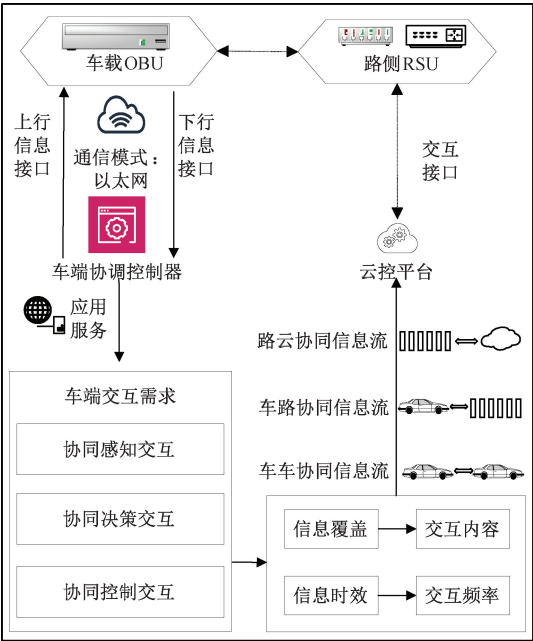


图 2 VRCIS 信息交互
Fig. 2 Information exchange of VRCIS

LTE-V 协议下车车、车路信息交互体类别如表 1 所示。车辆信息包括 BSM(基本安全信息)、SSM(感知共享信息)等,传输频率为 10 Hz。MQTT 协议下路云信息交互消息体如表 2 所示。

表 1 车车-车路信息交互消息体类别

Table 1 V2V and V2I message types	
消息体	说明
BSM	基本安全信息;车辆速度、位置等
SSM	感知共享信息
RSM	路侧视角道路交通参与者信息
ISM	车辆意图共享信息
MAP	路段、车道信息
RSC	路侧对车辆进行引导规划

表 2 路云信息交互消息体类别

Table 2 Message types of road-cloud interaction	
消息体	说明
RSU2CLOUD_STATUS	RSU 设备状态上报云端
RSU2CLOUD_BSM	RSU 接收范围内车辆 BSM 数据
RSU2CLOUD_RSI(MAP)	云端下发交通事件标志(地图)
RCU2CLOUD_STATUS	向云端上报 RCU 状态
RCU2CLOUD_OBJS	上报路侧感知对象

系统通过多个环节进行信息交互:1) RSU 与云平台之间通过 RSU2CLOUD_HEARTBEAT 发送心跳信息,确保连接的稳定性,云平台按需响应;同时,路侧设备通过 RSU2CLOUD_STATUS 向云平台报告设备状态,并按照 0.1 Hz 的频率每 10 s 更新一次数据;云平台进行相应的控制和调整。2) 车辆 OBU 上传 BSM 信息(如车辆状态、传感器数据等);并通过 RSU2CLOUD_BSM 转发至云平台;车辆 OBU 还将 RSM 信息上传至 RSU,RSU 再将数据上传至云平台,通过 RSU2CLOUD_RSM 进行处理,频率为 10 Hz。3) 车辆与路侧单元之间的安全与状态信息也在不断交换,帮助云平台做出动态决策;此外,车辆 OBU 上传的导航和控制信息,如 SSM 和地图数据,帮助车辆根据实时交通情况调整行驶路线,频率为 1 Hz。

通过这一系列信息流,VRCIS 实现了实时的决策支持与控制,确保了整个系统在复杂交通环境中的高效运作。

2 车辆驾驶意图识别

2.1 问题分析

驾驶意图与周围车辆的交互特征有较强的关联性,并且这种关联性通常表现出明显的时序特征。常用的循环神经网络(recurrent neural network, RNN)在处理序列信息方面有一定优势,但有“梯度消失”缺陷,需要对其单元结构进行进一步改进。LSTM 创新的引入了细胞状

态 (Cell State, c_t), 这个状态有助于保持长期记忆, 并能将早期数据传递到当前时刻。此外, LSTM 结构中還包含输入、输出与遗忘门。其中输入门控制新信息的接受程度, 遗忘门决定丢弃哪些无关紧要的信息, 输出门负责筛选这些信息, 准备传递到下一个时间点。这些机制克服了传统 RNN 面临的问题。

然而, LSTM 在历史信息向前传递的过程中, 主要依据前一时刻的序列数据来预测下一时刻的输出, 一些与当前时刻距离较远的“记忆”可能会因为权重较小而逐渐丢失。因此, 文献[20-21]使用双向 LSTM 网络模型 (bi-directional-LSTM, Bi-LSTM), 该网络模型的核心思想在于阅读一个连续时刻的序列样本时, 会有两个阅读过程: 从前向后阅读和从后向前阅读。也可以理解为有两个 LSTM 对输入分别提取正反双向的时间依赖关系, 模型最终的输出结果由这两个 LSTM 的输出结果进行处理后综合决定, 提高了模型在复杂交通流场景下的精度和鲁棒性。

2.2 模型构建

本文提出了一种基于 Bi-LSTM 网络的驾驶意图识别模型。由两个独立的 LSTM 网络组成。模型需要的参数由两部分组成, 分别通过正向和反向方式输入。每个 LSTM 网络都会独立提取特征向量, 然后将正向与反向的特征向量组合, 形成最终的特征向量。这样, 通过将正向 LSTM 与反向 LSTM 的输出向量结合, 包含了过去和未来的信息, 形成了 Bi-LSTM 网络的输出。这一结构的流程如图 3 所示。

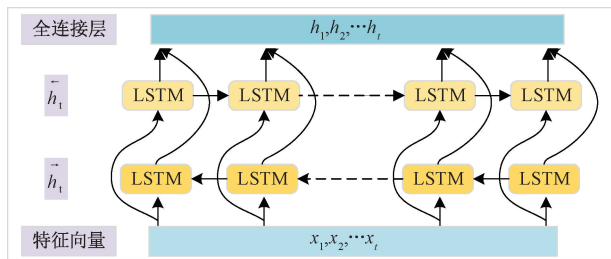


图 3 Bi-LSTM 网络

Fig. 3 Bidirectional LSTM network

将其输出向量结合在一起, 即为网络的输出 H_t , 即:

$$H_t = (\vec{h}_t, \overleftarrow{h}_t) \quad (1)$$

式中: \vec{h}_t 为正向运算过程; \overleftarrow{h}_t 为反向运算过程。

轨迹预测如图 4 所示。

采用 Bi-LSTM 编码-解码:

$$Y = f_{\text{Bi-LSTM}}(X) \quad (2)$$

模型输入为历史轨迹等特征信息, 即:

$$X = [x_1, x_2, \dots, x_{t-1}, x_t] \quad (3)$$

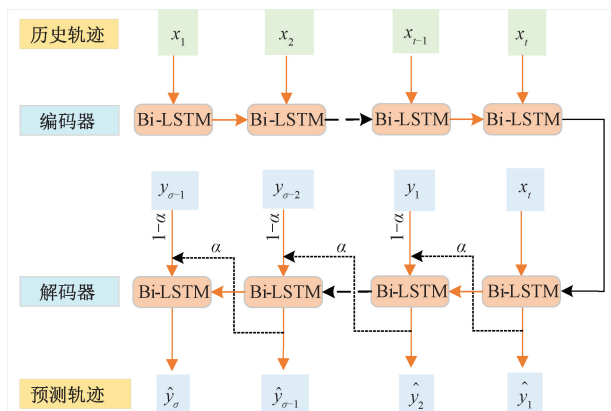


图 4 Bi-LSTM 轨迹预测

Fig. 4 Bi-LSTM for trajectory prediction

式中: x 表示特征向量; t 表示长度。

预测的未来轨迹表示为:

$$\hat{Y} = [y_1, y_2, \dots, y_{\sigma-1}, y_{\sigma}] \quad (4)$$

式中: y 为输出特征向量; σ 为预测轨迹长度。

由于参数 α 存在最优解, 此处采用网格搜索的方法对 α 进行寻优。基于 XGBoost 算法构建驾驶意图识别模块, 如图 5 所示。




图 5 XGBoost 算法

Fig. 5 XGBoost algorithm

将 X 与 \hat{Y} 组合, 构成向量 X' 。XGBoost 算法识别出意图信息 I , 并进行编码: 向左变道、车道跟驰、向右变道, 最后通过循环迭代拟合模型的残差。

$$I = f_{\text{XGBoost}}(X') \quad (5)$$

设车辆驾驶意图识别数据集 $D = \{(x_i, y_i)\}$, 其中, x_i 为特征状态, y_i 为意图标签。

驾驶意图识别模型的输出结果如下:

$$\hat{y}_i = \sum_{k=1}^K f_k(x_i), f_k \in \text{Tree} \quad (6)$$

式中: x_i 为第 i 个样本; f_k 为第 k 棵树模型; K 为回归树的

总数; $Tree$ 为包含所有回归树的函数空间。

基于前一次迭代的残差, XGBoost 通过迭代, 产生新的回归树, 初始值为常数, 因此该模型的迭代式可以表达如下:

$$\begin{cases} \hat{y}_i^{(0)} = 0 \\ \hat{y}_i^{(1)} = f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \hat{y}_i^{(2)} = f_1(x_i) + f_2(x_i) = \hat{y}_i^{(1)} + f_2(x_i) \\ \vdots \\ \hat{y}_i^{(k)} = \sum_{k=1}^K f_k(x_i) = \hat{y}_i^{(k-1)} + f_k(x_i) \end{cases} \quad (7)$$

式中: $\hat{y}_i^{(k)}$ 为第 k 次迭代第 i 个样本的预测值; $f_k(x_i)$ 是第 k 棵树的。

XGBoost 目标函数由损失函数与正则化两个部分构成。损失函数主要是预测意图类别和真实意图类别之间的差, 正则化则用于控制每棵树的复杂程度, 防止过拟合。目标函数为:

$$O^{(k)} = \sum_{k=1}^K l(y_i, \hat{y}_i^{(k)}) + \sum_{k=1}^K W(f_k) \quad (8)$$

式中: $l(y_i, \hat{y}_i^{(k)})$ 为损失函数; $W(f_k)$ 为正则化部分,

$$W(f_k) = \gamma L + \lambda \frac{1}{2} \sum_{j=1}^L \omega_j^2 \quad (9)$$

式中: f_k 为第 k 棵树; L 为第 k 棵树的叶子节点数; γ 为惩罚项系数; λ 为正则化惩罚系数; ω_j 为叶子节点分数;

$\frac{1}{2} \sum_{j=1}^L \omega_j^2$ 为子节点分数的 L_2 正则化。

迭代后更新的目标函数为:

$$O^{(k)} = \sum_{k=1}^K l(y_i, \hat{y}_i^{(k-1)} + f_k(x_i)) + \sum_{k=1}^K W(f_k) \quad (10)$$

将上式进行二阶展开后, 合并整理得目标函数为:

$$O^{(k)} = -\frac{1}{2} \sum_{i=1}^T \frac{G_i^2}{H_i + \lambda} + \gamma T \quad (11)$$

求解式(11), 得 ω_i^* :

$$\omega_i^* = -\frac{G_i}{H_i + \lambda} \quad (12)$$

式中: G_i, H_i 分别表示叶子节点 i 的一阶与二阶偏导数之和; λ, γ 为控制模型复杂度的超参数; T, ω_i 分别表示叶子节点个数与权重。

3 模型及算法验证

3.1 公开数据集测试

选用公开数据集 NGSIM(next generation simulation) 中 US-101 和 I-80 场景下数据, 如图 6 所示。

该数据提供了高速公路环境下的车辆轨迹数据, 包

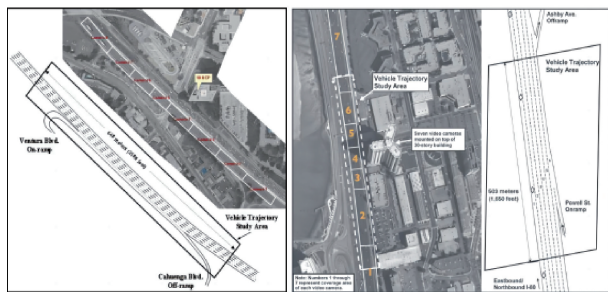


图 6 US-101 与 I-80 路段

Fig. 6 US-101 and I-80 section

含大量的车辆换道、车道跟驰等驾驶行为数据, 用作驾驶意图识别模型的离线训练数据。

1) 数据集处理

数据集处理包括数据滤波、特征筛选和标注^[17]。

(1) 数据滤波。由于摄像机收集的数据存在一定偏差, 如轨迹漂移和重叠等问题, 特别是在横向速度的误差较为显著, 因此需要对数据进行平滑处理。研究表明^[22], 基于卡尔曼滤波和粒子滤波的融合技术能够有效提高车辆速度、位置等关键参数的估计精度, 显著提升在复杂和动态环境中的状态识别能力。使用小波分解方法对轨迹数据进行滤波。

$$X_{Local} = A_n + D_1 + D_2 + \dots + D_n \quad (13)$$

式中: A_n 和 D_n 分别为第 n 次分解所得的低高频信号。

滤波前后对比如图 7 所示。显然, 经过滤波处理的数据更加平滑, 能够为模型提供更接近实际的高速公路车辆行驶数据。




图 7 滤波前后对比

Fig. 7 Comparison before and after filtering

(2) 特征筛选。数据通过采用鸟瞰摄像头采集, 频率为 10 Hz, 主要的特征信息包含车辆编号、车辆前部中心位置的横纵坐标、车辆类型、车辆瞬时速度、车辆瞬时加速度等信息, 如表 3 所示。

将目标车辆前后 50 m 范围内的 6 辆车视为环境车辆。车辆轨迹预测的输入包含历史轨迹信息(目标车辆、

环境车辆与车道),共 44 维特征,如图 8 所示,具体输入特诊如表 4 所示。

表 3 车辆特征

Table 3 Vehicle features

特征名称	特征描述	单位
Vehicle_ID	车辆 ID	-
Frame_ID	该条数据在某一时刻的帧	-
Local_X	车辆中心位置的横向坐标	feet
Local_Y	车辆中心位置的纵向坐标	feet
v_Class	类型:1 摩托车 2 汽车 3 卡车	-
v_Val	车辆瞬时速度	feet/s
Vacca	车辆瞬时加速度	feet/s ²
Lane_ID	车道编号,行驶方向最左侧为 1	




图 8 目标车辆周围车辆

Fig. 8 Surrounding vehicles around the target vehicle

表 4 模型输入特征描述

Table 4 Description of model input features

特征组	特征描述	维度
目标车辆	横向位移 x 、纵向位移 y (原始数据获取)	2
	横向速度 v_x 、纵向速度 v_y	2
	$v_x = 10(x_{i+1} - x_i), v_y = 10(y_{i+1} - y_i)$	
	横向加速度 a_x 、纵向加速度 a_y	2
	$a_x = 10(v_{x_{i+1}} - v_x), a_y = 10(v_{y_{i+1}} - v_y)$	
环境车辆	环境车辆 j 与目标车辆 i 的纵横相对距离	12
	$\Delta x^j = x^j - x^i, \Delta y^j = y^j - y^i$	
	环境车辆 j 自身的历史瞬时速度	12
	$v_x^j = 10 \cdot (x_{t}^j - x_{t-1}^j), v_y^j = 10 \cdot (y_{t}^j - y_{t-1}^j)$	
环境车辆	环境车辆 j 的历史瞬时加速度	12
	$a_x^j = 10 \cdot (v_{x,t}^j - v_{x,t-1}^j), a_y^j = 10 \cdot (v_{y,t}^j - v_{y,t-1}^j)$	
车道	目标车辆相邻车道编号 (1 存在, 0 则否)	2
		44

(3)数据标注。公开数据集的车辆驾驶意图标签缺失,因此需自行标注。目前大多采用车辆的横纵向运动参数标注换道意图,但由于其波动性小,难以做出准确的判断。本文采用航向角来作为换道的判断依据^[23]。首先,按照时间顺序,对同一编号车辆所在车道进行遍历,将所有车辆车道发生改变的时间点记为变道点;通过横纵向速度计算出航向角:

$$\theta = \arctan\left(\frac{v_y}{v_x}\right)$$

(14)

若车辆在某一帧之后,连续 1 s 时间内航向角都大于所设置的航向角阈值,则将该点记为起始点,具体如图 9 所示。




图 9 车辆变道

Fig. 9 Lane changing of vehicles

2) 训练过程

在一台搭载 NVIDIA GeForce RTX 4060ti GPU、32 G 内存电脑上,使用深度学习框架 PyTorch 模型进行训练。NGSIM 数据集上共提取到 128 136 条有效数据,其中车道跟驰占绝大部分,故将 3 种类型的数据平衡,并从中抽取 50 000 条数据,作为数据集,并按 8 : 2 划分训练集和测试集,训练参数如表 5、6 所示。

表 5 Bi-LSTM 参数设置

Table 5 Bi-LSTM parameter settings

参数	值
Batch size	1 024
损失函数	MSE
优化器	Adam
学习率	0.001
权重衰减	0.000 1
Dropout	0.2
隐藏层	128
计划抽样比例	0.4

表 6 XGBoost 参数设置

Table 6 XGBoost parameter settings

参数	值
分类器数量	110
树最大深度	6
学习率	0.2
采样比例	1

3) 测试结果

使用精确率、召回率、准确率^[24]和 F1-score 作为评价指标。并利用 LSTM-XGBoost 模型与 XGBoost 的模型进行对比分析:(1)传统 XGBoost 模型,直接处理原始数据进行识别;(2)LSTM-XGBoost 模型:采用 LSTM 进行轨

迹预测的 XGBoost 模型; (3) Bi-LSTM-XGBoost 模型: 本文提出采用 Bi-LSTM 网络进行轨迹预测(图 10)的 XGBoost 模型。表 7 为各模型识别指标的结果对比。

由表 7 可知,Bi-LSTM-XGBoost 模型的各项指标均较高,尤其在右变道任务中,且在所有 3 个指标上表现突出,最终整体准确率达到了 97.4%。这主要得益于 Bi-LSTM 能更好地处理时序特征,双向结构能更好地捕捉换道意图初期那些微弱但关键的横向运动特征,从而更早、更准确地识别意图,而 LSTM-XGBoost 虽然表现稳健,但在精准率和 F1 得分上有所欠缺。

此外,为验证 Bi-LSTM 架构本身的有效性,排除其性能提升源于‘窥探’未来信息的可能性,补充了因果性对比实验,结果如表 8 所示。通过 Mask 技术,确保反向 LSTM 在计算时刻 t 的特征时,无法访问 $t+1$ 时刻之后的未来信息,模拟其真实部署场景。




图 10 采用 Bi-LSTM 网络的轨迹预测对比
Fig. 10 Trajectories comparison by Bi-LSTM

表 7 各模型识别指标对比
Table 7 Comparison of recognition metrics for different models

意图	精确率			召回率			F1		
	LSTM-XGBOOST	XGBoost	Bi-LSTM-XGBoost	LSTM-XGBOOST	XGBoost	Bi-LSTM-XGBoost	LSTM-XGBOOST	XGBoost	Bi-LSTM-XGBoost
跟驰	0.959	0.957	0.969	0.956	0.958	0.961	0.957	0.957	0.965
左变道	0.969	0.971	0.975	0.971	0.970	0.976	0.970	0.970	0.975
右变道	0.978	0.977	0.979	0.979	0.977	0.985	0.979	0.977	0.982

表 8 因果推理条件下模型性能对比
Table 8 Performance comparison under causal inference

模型	准确率/%	跟驰 (F1)	左变道 (F1)	右变道 (F1)
LSTM-XGBOOST	96.8	0.957	0.970	0.979
Bi-LSTM-XGBoost-Causal	97.2	0.963	0.973	0.981

由表 8 可知,即使在因果律的推理条件下,模型的整体准确率仍保持高准确率 97.2%,说明 Bi-LSTM 性能的提升主要源于其强大的双向架构本身能更有效地从历史序列中提取关键特征,而非单纯依赖于未来信息。在训练阶段接触完整序列,使得 Bi-LSTM 学习到了更丰富的上下文特征表示,这种表征能力在因果推理模式下得以保留,获得了性能提升。

3.2 联合仿真测试

搭建基于真实城市两车道仿真场景,Sumo 负责模拟宏观交通流环境,提供整体车流特征;Carla 进行微观驾驶行为仿真,提供高精度的感知信息和个体交互数据,模拟车路云协同感知;路侧 RSU 实时将感知范围车辆状态信息和道路信息作为数据输入,频率为 10 Hz,对意图识别模型进行 Sumo 与 Carla 联合仿真。仿真过程中,将意图结果进行编号,其中。左换道标记为 0,车道跟驰记为

1,右换道记为 2,持续输出意图编号结果,输出频率为 10 Hz。随机选择其中 5 辆车进行测试,车辆的实时驾驶意图随时间变化如图 11 所示,模型检测到车辆换道意图时,持续输出对应意图直至换道完成,通过这种意图编号方式,能直观的展现车辆之间的意图交互过程。




图 11 驾驶意图随时间变化
Fig. 11 Driving intentions over time

图 12 所示为联合仿真过程中目标车辆(Car 1)的一次左换道意图与轨迹预测结果。换道初期模型持续输出左换道意图(0)直至换道结束保持车道跟驰(1)。对应

的驾驶意图变化也在图 11 中有所体现。同时,预测轨迹与行进轨迹高度吻合,证明了本文模型能捕捉驾驶意图与轨迹动态特征。




图 12 车辆左换道与轨迹预测结果

Fig. 12 Vehicle left lane change and trajectory prediction

在复杂交通场景中,若要实时获取车辆的意图和预测轨迹,必须确保单次识别的耗时低于系统的输出频率(100 ms)。因此,需要对意图识别模型在同时处理不同数量车辆时的耗时情况进行模拟分析。表 9 为感知范围内车辆数量与单次识别耗时的关系。可以看出,随着感知范围内车辆数量的增加,模型的耗时也随之增加。在同时识别 15 辆左右车时,能够满足 100 ms 以内的时延要求。而当范围车辆超过 20 辆时,耗时大幅增加,超过了 100 ms,若持续同时识别超 20 辆车,将无法保证意图识别的实时性与准确性。分析原因,在高密度交通流下,车辆之间的交互关系过于复杂,导致模型输入特征维数大幅上升,处理更长序列的计算复杂度增加。模型同时处理的信息过多达到了瓶颈,导致时延增加。同时过多的数据对计算资源的消耗增加,同样会导致时延。

表 9 感知范围内车辆数与耗时关系

Table 9 Relationship between number of vehicles in perception range and time consumption

车辆数	耗时/ms
5	21. 85
11	48. 72
15	66. 83
23	150. 32

3.3 真实道路测试

在真实 VRCCPS 下,采集的实际数据集上进行了测试,选取一辆换道的车辆及其周围其他车辆的状态数据进行验证,如图 13 所示。图 14 所示为多车场景下,模型输出的车辆轨迹预测对比结果。

图 13 中,基于真实道路采集的车辆数据,其预测轨




图 13 车辆真实轨迹与预测对比

Fig. 13 Comparison of true and predicted vehicle trajectories

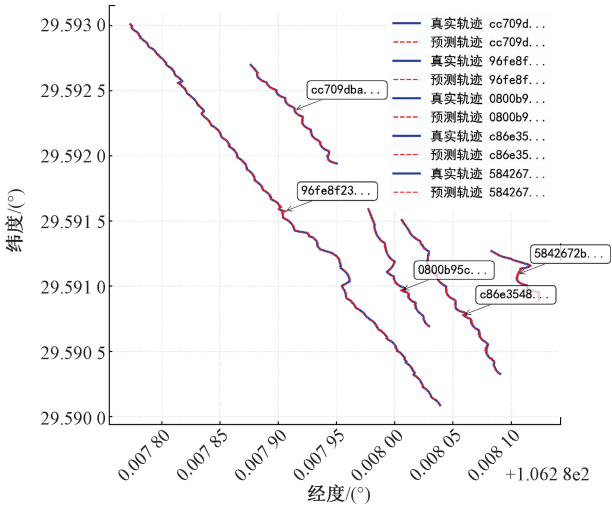


图 14 多车真实轨迹与预测对比

Fig. 14 Comparison of true and predicted trajectories for multiple vehicles

迹与真实轨迹在一个高精度的局部坐标系下进行了对比。横轴为经度偏移,纵轴为纬度偏移。由于真实道路采集的数据不可避免地受到传感器噪声、定位误差的干扰。微小的误差会被模型放大。此外 NGSIM 数据多为常规驾驶行为,对于某些特定或突发的起始条件,模型的泛化能力仍有提升空间。因此,预测轨迹与真实轨迹终存在微小偏差。然而,从宏观轨迹形态来看,Bi-LSTM 模型成功预测了车辆的总体行驶意图和路径走向。表明模型具备时序依赖关系学习能力和对驾驶策略的深层理解。

由图 14 可知,在多车交互的复杂真实环境下,Bi-LSTM 模型展现出较强的交互特性捕捉能力,对所有车辆的轨迹预测结果与其真实值吻合良好。该模型通过双向时序建模,准确捕捉了单车运动特征,理解了车辆之间隐含的动态相互作用关系,能够在整体上生成协调一致且无冲突的预测轨迹簇,从而准确模拟真实交通流中多智能体协同运动的动态过程,体现了其在复杂场景下较强的轨迹预测能力。

4 结 论

本文提出了一种基于车路云协同感知的车辆驾驶意图识别方法,通过构建车路云多源信息融合框架,结合 Bi-LSTM 网络与 XGBoost 算法,实现了对车辆驾驶意图的识别,并分别在 NGSIM 公开数据集、虚拟测试平台和车路云一体化系统进行了测试。1)构建了面向车路云协同感知的驾驶意图识别框架,实现了更广泛、更可靠的环境感知与决策支持;2)引入 Bi-LSTM 结构融合双向时序特征提取机制,提升了意图识别准确性与轨迹预测一致性;3)提出的 Bi-LSTM-XGBoost 模型在多车交互场景中表现出良好的鲁棒性和实用性,满足实时性要求。下一步将重点探索基于梯度直估的端到端训练框架,融合 CNN-LSTM 等深层网络结构,进一步提升模型在极端场景中的适应性和泛化性。

参考文献

- [1] 宋建辉,刘鑫,庄爽,等.面向无人驾驶的多任务环境感知算法研究[J].电子测量与仪器学报,2025,39(1):122-132.
SONG J H, LIU X, ZHUANG SH, et al. Research on multi-task environment perception algorithm for unmanned driving [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39 (01): 122-132.
- [2] GAO B, LIU J, ZOU H, et al. Vehicle-road-cloud collaborative perception framework and key technologies: A review [J]. IEEE Transactions on Intelligent Transportation Systems, 2024, 25(12): 19295.
- [3] CHU W, WUNIRI Q, DU X, et al. Cloud control system architectures, technologies and applications on intelligent and connected vehicles: A review[J]. Chinese Journal of Mechanical Engineering. 2021, 34(1):1-23.
- [4] CAILLOT A, OUEGHI S, VASSEUR P, et al. Survey on cooperative perception in an automotive context[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(9):14204-14223.
- [5] AHANGAR M, AHMED Q Z, KHAN F A, et al. A survey of autonomous vehicles; Enabling communication technologies and challenges[J]. Sensors, 2021, 21(3): 706.
- [6] 张长隆,鲍海兴,杜仙童,等.路侧感知在智能网联汽车中的应用与未来[J].人工智能,2019(1):58-66.
ZHANG CH L, BAO H X, DU X T, et al. The application and future of roadside perception in intelligent networked vehicles[J]. Artificial Intelligence, 2019 (1): 58-66.
- [7] VIJAY R, CHERIAN J, RIAH R, et al. Optimal placement of roadside infrastructure sensors towards safer autonomous vehicle deployments [C]. 2021 IEEE International Intelligent Transportation Systems Conference (ITSC). Indianapolis, USA: IEEE, 2021: 2589-2595.
- [8] 宗长富,代昌华,张东.智能汽车的人机共驾技术研究现状和发展趋势[J].中国公路学报,2021,34(6):214-237.
ZONG CH F, DAI CH H, ZHANG D. Human-machine interaction technology of intelligent vehicles: Current development trends and future directions [J]. China Journal of Highway and Transport, 2021, 34 (6): 214-237.
- [9] ROLISON J J, REGEV S, MOUTARI S, et al. What are the factors that contribute to road accidents? An assessment of law enforcement views, ordinary drivers' opinions, and road accident records [J]. Accident Analysis & Prevention, 2018, 115: 11-24.
- [10] ELGHAZALY G, FRANK R, HARVEY S, et al. High-definition maps: Comprehensive survey, challenges and future perspectives[J]. IEEE Open Journal of Intelligent Transportation Systems, 2023(4):527-550.
- [11] 付锐,张海伦,刘文晓,等.驾驶人意图识别综述[J].长安大学学报(自然科学版),2022,42(1):33-60.
FU R, ZHANG H L, LIU W X, et al. Review on driver intention recognition[J]. Journal of Chang'an University (Natural Science Edition), 2022,42(1):33-60.
- [12] LIU S, ZHENG K, ZHAO L, et al. A driving intention prediction method based on hidden Markov model for autonomous driving [J]. Computer Communications, 2020, 157: 143-149.
- [13] LI K, WANG X, XU Y, et al. Lane changing intention recognition based on speech recognition models [J]. Transportation research part C: Emerging Technologies, 2016, 69: 497-514.
- [14] ZHANG Y, SHI X, ZHANG S, et al. A XGBoost-based lane change prediction on time series data using feature engineering for autopilot vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23 (10): 19187-19200.
- [15] 季学武,费聪,何祥坤,等.基于 LSTM 网络的驾驶意图识别及车辆轨迹预测[J].中国公路学报,2019,32(6):34-42.
JI X W, FEI C, HE X K, et al. Intention recognition and trajectory prediction for vehicles using LSTM network. [J]. China Journal of Highway and Transport, 2019, 32(6): 34-42.

- [16] 赵建东, 赵志敏, 屈云超, 等. 轨迹数据驱动的车辆换道意图识别研究[J]. 交通运输系统工程与信息, 2022, 22(4): 63-71.
ZHAO J D, ZHAO ZH M, QU Y CH, et al. Vehicle lane change intention recognition driven by trajectory data[J]. Journal of Transportation Systems Engineering and Information Technology, 2022, 22(4): 63-71.
- [17] 方华珍, 刘立, 顾青, 等. 基于轨迹预测和极限梯度提升的驾驶意图识别[J]. 吉林大学学报(工学版), 2025, 55(2): 623-630.
FANG H ZH, LIU L, GU Q, et al. Driving intention recognition based on trajectory prediction and extreme gradient boosting [J]. Journal of Jilin University (Engineering and Technology Edition), 2025, 55(2): 623-630.
- [18] ZHANG H, GUO D, GUO Y, et al. A novel method for the driver lane-changing intention recognition[J]. IEEE Sensors Journal, 2023, 23(17): 20437-20451.
- [19] 左志强, 刘正璇, 王一晶. 基于车路云一体化的混合交通系统优化控制综述[J]. 控制与决策, 2023, 38(3): 577-594.
ZUO ZH Q, LIU ZH X, WANG Y J. A survey of optimal control for mixed traffic system with vehicle-road-cloud integration[J]. Control and Decision, 2023, 38(3): 577-594.
- [20] HUANG Z, XU W, YU K. Bidirectional LSTM-CRF models for sequence tagging [J]. Computer Science, 2015.
- [21] ZHAO R, YAN R, WANG J. Learning to monitor machine health with convolutional Bi-Directional LSTM networks[J]. Sensors, 2017, 17(2): 273.
- [22] WANG Z, WU Y, NIU Q. Multi-sensor fusion in automated driving: A survey[J]. IEEE Access, 2020, 8: 2847-2868.
- [23] 李琳, 赵万忠, 王春燕. 基于 Bi-GLSTM 网络的车辆驾驶意图分析与识别[J]. 机械工程学报, 2024, 60(10): 51-63.
LI L, ZHAO W ZH, WANG CH Y. Driving intention recognition model based on Bi-GLSTM network [J]. Journal of Mechanical Engineering, 2024, 60(10):

51-63.

- [24] 胡悦, 范建华, 胡永扬, 等. 面向非视距环境的智能车多传感鲁棒融合定位[J]. 电子测量与仪器学报, 2025, 39(5): 1-10.

HU Y, FAN J H, HU Y Y, et al. Robust multi-sensor fusion positioning for intelligent vehicles in non-line-of-sight environments [J]. Journal of Electronic Measurement and Instrumentation, 2025, 39(5): 1-10.

作者简介



李海青, 2019 年于南京航空航天大学获得博士学位, 现为重庆邮电大学讲师, 主要研究方向为智能网联汽车与智能机器人。
E-mail: lihq@cqupt.edu.cn

Li Haiqing received his Ph. D. degree from Nanjing University of Aeronautics and Astronautics in 2019. Now he is a lecturer at Chongqing University of Posts and Telecommunications. His main research interests include intelligent connected vehicles and intelligent robots.



雷宇铨, 2022 年于重庆科技大学获得学士学位, 现为重庆邮电大学硕士研究生, 主要研究方向为智能网联汽车与编队控制。
E-mail: leiyu8888@163.com

Lei Yucheng received his B. Sc. degree from Chongqing University of Science and Technology in 2022. Now he is a M. Sc. candidate at Chongqing University of Posts and Telecommunications. His main research interests include intelligent connected vehicles and formation control.



禄盛 (通信作者), 2009 年于韩国仁荷大学获得博士学位, 现为重庆邮电大学教授, 主要研究方向为人工智能与数值计算、制造工艺智能感知决策。
E-mail: lusheng@cqupt.edu.cn

Lu Sheng (Corresponding author) received his Ph. D. degree from Inha University, South Korea in 2009. Now he is a professor at Chongqing University of Posts and Telecommunications. His main research interests include artificial intelligence and numerical computation, intelligent perception and decision-making in manufacturing processes.