

融合逻辑判断机制的 CNN-GRU 换道意图识别方法

任立海¹, 康钰泽¹, 刘煜², 蒋成约^{1†}

(1. 重庆理工大学 汽车零部件先进制造技术教育部重点实验室, 重庆 400054;
2. 中国汽车工程研究院股份有限公司, 重庆 401122)

摘要:为了提升驾驶辅助系统的可靠性, 进而确保行车安全, 准确地识别车辆的换道意图是一个关键策略。为此提出一种基于卷积神经网络(convolutional neural network, CNN)和门控循环单元(gated recurrent unit, GRU)并融合逻辑判断机制的换道意图识别方法, 能够对车辆换道意图进行有效识别。首先, 基于驾驶模拟器记录了20名志愿者的驾驶行为信息, 涵盖了左换道、右换道和直行3类数据, 用于构建换道意图样本集。其次, 采用车辆行驶特征和驾驶员行为数据构建CNN-GRU模型, 通过CNN层提取特征并作为GRU层的输入。最后, 在意图识别网络中融合了逻辑判断层, 通过设置概率阈值的方式, 解决换道意图在时间序列上的前后依赖问题。为了验证所提方法的有效性, 与融合了CNN的长短时记忆(long short-term memory, LSTM)网络和GRU进行对比分析。研究结果显示, 提出的模型在识别左换道、右换道和直行行为时, 准确率分别达到了98.5%、96.7%和95.2%, 相比其他模型展现出更高的识别精度。

关键词:汽车工程; 汽车安全; 主动安全系统; 深度学习; 卷积神经网络

中图分类号:U491 **文献标志码:**A

Recognition Method of Lane Change Intention Based on CNN-GRU Integrated with Logic Judgment Mechanism

REN Lihai¹, KANG Yuze¹, LIU Yu², JIANG Chengyue^{1†}

(1. Key Laboratory of Advanced Manufacturing Technology for Automobile Parts, Ministry of Education, Chongqing University of Technology, Chongqing 400054, China;
2. China Automotive Engineering Research Institute Co., Ltd., Chongqing 401122, China)

Abstract: Accurately identifying the lane change intention of vehicles is a key strategy for improving the reliability of driving assistance systems and ensuring road safety. A novel method that combines convolutional neural network (CNN) and gated recurrent unit (GRU), integrated with a logic judgment mechanism, was proposed to effectively recognize the lane change intentions of vehicles. First, test data from twenty volunteers were recorded

* 收稿日期:2024-01-16

基金项目:国家自然科学基金资助项目(51405050), National Natural Science Foundation of China(51405050); 汽车噪声振动和安全技术国家重点实验室开放基金资助项目(NVHSKL-202004), Open Foundation of State Key Laboratory of Vehicle NVH and Safety Technology (NVHSKL-202004); 重庆市技术创新与应用发展专项面上项目(cstc2019jscx-msxmX0412), General Project of Chongqing Technology Innovation and Application Development (cste2019jscx-msxmX0412); 重庆理工大学研究生教育高质量发展行动计划资助成果(gzlx20222119), Chongqing University of Technology Action Plan for Quality Development of Graduate Education (gzlx20222119).

作者简介:任立海(1986—), 男, 山东菏泽人, 重庆理工大学副教授, 博士

† 通信联系人, E-mail: jiangchengyue@cqu.edu.cn

using a driving simulator including three categories: left lane change, right lane change, and straight driving. The data was used to construct a sample set of lane change intention. Secondly, a CNN–GRU model was built using vehicle driving characteristics and driver behavior data, with the CNN layer being employed to extract features as input to the GRU layer. Finally, a logic judgment layer was integrated into the intention recognition network to address the temporal dependencies of lane change intentions by setting probability thresholds. To validate the validity of the method in this study, the model was compared and analyzed with a CNN that was integrated with long short-term memory (LSTM) and GRU. The results show that the proposed model achieved recognition accuracies of 98.5% for left lane changes, 96.7% for right lane changes, and 95.2% for straight driving, demonstrating higher accuracy compared with other models.

Key words: automotive engineering; vehicle safety; active safety systems; deep learning; convolutional neural networks

道路交通伤亡是一个有着巨大社会影响力的公共健康问题,我国交通事故统计数据显示,2021年全国有34万人因交通事故伤亡^[1].在近年来的研究中,高级驾驶辅助系统(advanced driving assistance system, ADAS)在预防交通事故和提高驾驶安全性能方面发挥了重要作用.在道路交通领域,若能精准地识别驾驶员的行为意图,将有助于ADAS作出更优的决策和提供更安全的辅助行为.相关数据报告表明,在所有的严重碰撞事故中,约有17%是由换道引起的^[2],不当的换道行为对道路交通安全有着严重危害.因此,驾驶员换道意图的有效识别,对车辆辅助系统至关重要,对ADAS的发展和应用具有重要意义.

目前,国内外在驾驶员意图识别领域已有一定研究进展,主要分为两大类:基于模型的识别方法和基于数据驱动的识别方法.基于模型的识别方法目前已有较多研究,如支持向量机(support vector machine, SVM)和隐马尔可夫模型(hidden markov model, HMM)等.毕胜强等^[3]通过驾驶模拟器采集车辆动态参数和驾驶人行为参数,建立SVM换道意图识别模型.Li等^[4]基于流形学习并结合SVM作为分类器,可以通过视频数据来识别驾驶员换道行为.Huang等^[5]通过高斯混合模型,可以有效识别车辆的驾驶意图.由于分类器只能对当前状态进行识别,而驾驶过程是一个连续的时间序列,因此HMM也被广泛用于换道意图识别的研究中,其对时间序列的建模克服了传统分类器的不足^[6-7].除此之外,一些研究中所采用的方法也归类于基于模型的识别

方法的范畴,Xie等^[8]采用分布式遗传算法对动态贝叶斯网络进行结构优化,可以更好地推断换道驾驶行为.王亚伦等^[9]提出了一种基于条件随机场的驾驶意图识别模型,用于改善HMM的标注偏置问题,对直行、左换道和右换道三种意图识别的 F_1 分数分别达到了95.26%、96.46%和95.19%.基于模型的识别方法可能会因先验假设的偏差而不够准确,且识别精度有限,提升难度较大.

近年来,由于计算机算法和算力的不断发展与提升,基于数据驱动的识别方法也受到了更多的关注,其主要体现在深度学习方面的应用.Mammeri等^[10]对样本数据进行人工标记,并通过卷积神经网络(convolutional neural network, CNN)训练模型用于驾驶意图的识别.然而意图识别是一个时间序列问题,鉴于循环神经网络(recurrent neural network, RNN)对时序问题的处理能力,Li等^[11]考虑了周围车辆的交互数据,通过RNN预测高速公路的换道行为.长短期记忆(long short-term memory, LSTM)网络作为RNN的变体,解决了梯度消失问题的同时也有着优秀的时序处理能力,因此也被研究者用于驾驶意图识别的相关研究^[12].例如,季学武等^[13]设计了一种基于LSTM网络的驾驶意图识别方法,可以对换道和直行进行有效预测.宋晓琳等^[14]通过LSTM网络构建意图识别模型,并引入了条件随机场,对左换道、右换道和直行三种意图的识别准确率都达到了90%以上.Dang等^[15]将意图识别作为回归问题,通过LSTM预测车辆越过车道线的时间.Han等^[16]先通过聚类提取特征,再通过LSTM构建意图识别模型.Guo

等^[17]建立了一种融合注意力机制的双向长短期记忆网络,可以在换道前3 s达到93.33%的识别准确率。相比于LSTM来说,门控循环单元(gated recurrent unit, GRU)内部结构参数更少,模型运算效率更高。赵建东等^[18]构建了一个融合注意力机制的CNN-GRU网络模型,该模型能够提前2 s较为准确地识别出换道意图,他们的研究发现,与LSTM相比,GRU展现出了更高的识别准确率。此外,还有学者通过将时间序列特征转换为图像,利用深度学习对图像进行识别,以达到换道意图识别的目的^[19]。

然而,鉴于驾驶过程的时序特性,在处理换道意图识别问题时,模型的输入和输出应当展现出时间上的前后依赖性。然而,前述研究在构建模型时往往未能兼顾输入与输出的双重时序关联。此外,部分研究中采用的公开数据集往往只考虑了车辆行驶特征,缺少对驾驶员行为数据的关注。鉴于深度学习在特征提取与模型构建方面的优势,为进一步提高驾驶员换道意图识别的准确率,本文将逻辑判断机制与深度学习相结合,建立了一种换道意图识别模型,并命名为CNN-GRU-Thre:通过驾驶模拟器展开志愿者实验,采集车辆行驶特征与驾驶员行为数据用于模型构建;在网络模型的基础上,引入了逻辑判断层,同时考虑模型输入和输出在时序上的前后依赖性,能够有效将意图识别的历史信息与当前状态进行关联。

1 模型框架与模块介绍

CNN和GRU是深度学习中的两种网络结构,能够对输入信息进行逐层转换,从而保证数据特征的提取和表达。CNN具有特征提取能力,可以有效应用于分类问题,但其在特征提取中不具备识别时间序列前后相关性的能力。而GRU网络在时间序列数据分析方面表现更为出色,在本研究中可以有效处理车辆行驶轨迹等序列数据。因此,为了更精确地识别车辆换道意图,本研究将CNN和GRU进行结合,构建换道意图识别模型。

1.1 整体框架

本文所提出的CNN-GRU-Thre车辆换道意图识别模型由输入模块、识别模块和逻辑判断模块3部分组成。整体框架如图1所示。输入模块指目标车辆行驶特征与驾驶员行为数据的输入,包括位置信

息、速度信息、方向盘转角等。然后将输入信息传递给识别模块处理,通过CNN层、GRU层和Softmax分类层,输出车辆的换道意图概率。最后再根据逻辑判断层,对当前输出的换道意图概率进行判断并与历史信息交互,输出最终的车辆换道意图。

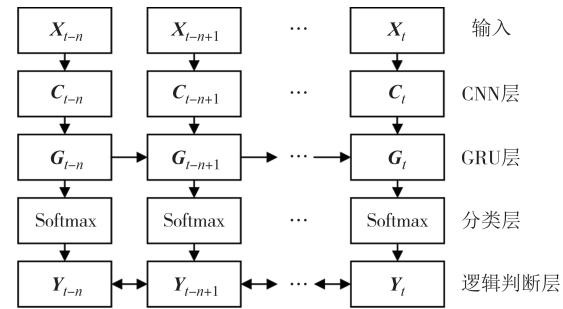


图1 CNN-GRU-Thre模型整体框架

Fig.1 System framework of CNN-GRU-Thre model

为建立驾驶员换道意图识别模型,主要输入参数为主车行驶特征与驾驶员行为数据信息。设 X 为模型的输入数据,对于时间步长为 $n+1$ 的输入序列,可表示为:

$$X = (X_{t-n}, X_{t-n+1}, \dots, X_{t-1}, X_t) \quad (1)$$

式中: X_t 为在 t 时刻输入的固定历史长度特征矩阵,可表示为:

$$X_t = \begin{bmatrix} d_{t-w} & v_{x(t-w)} & v_{y(t-w)} & a_{x(t-w)} & a_{y(t-w)} & h_{t-w} & s_{t-w} \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ d_{t-1} & v_{x(t-1)} & v_{y(t-1)} & a_{x(t-1)} & a_{y(t-1)} & h_{t-1} & s_{t-1} \\ d_t & v_{xt} & v_{yt} & a_{xt} & a_{yt} & h_t & s_t \end{bmatrix} \quad (2)$$

式中: d_t 为主车横向车道线偏移量; v_{xt} 为主车纵向速度; v_{yt} 为主车横向速度; a_{xt} 为主车纵向加速度; a_{yt} 为主车横向加速度; h_t 为主车航向角; s_t 为主车方向盘转角; w 为历史输入矩阵的采样帧数。

模型经过Softmax分类层后的输出为左换道、右换道和直行3种驾驶意图类别的概率,代表了3种意图发生的可能性,可表示为:

$$[w_1, w_2, w_3] = P([c_1, c_2, c_3] | X) \quad (3)$$

式中: w_1, w_2, w_3 分别代表意图左换道、右换道和直行的概率; c_1, c_2, c_3 分别为左换道、右换道和直行三种意图类别。

最后,输出的概率结果经过逻辑判断层处理后转化为One-Hot向量形式,以表示最终的左换道、右换道和直行三种驾驶意图类别。

1.2 卷积神经网络(CNN)

卷积神经网络近年来常被用于分类和预测等领

域, 可以对原始数据进行逐层的特征提取, 不但可以降低数据复杂度, 也可以更好地挖掘车辆行驶特征. 卷积神经网络通常由输入层、卷积层、池化层、全连接层和输出层组成, 其网络结构如图2所示.

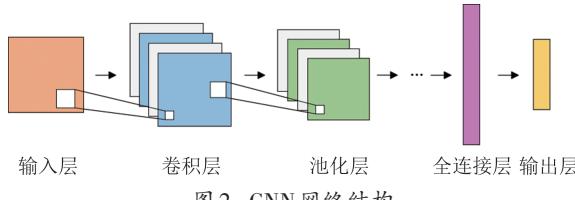


Fig.2 Network structure of CNN

1.3 门控循环单元(GRU)

GRU网络于2014年由Cho等^[20]提出, 该网络是对LSTM的改进, 其本质上也是通过门控结构对数据的输出和遗忘进行控制. 不同于LSTM的是, GRU只包含重置门和更新门来传递信息, 其网络结构如图3所示.

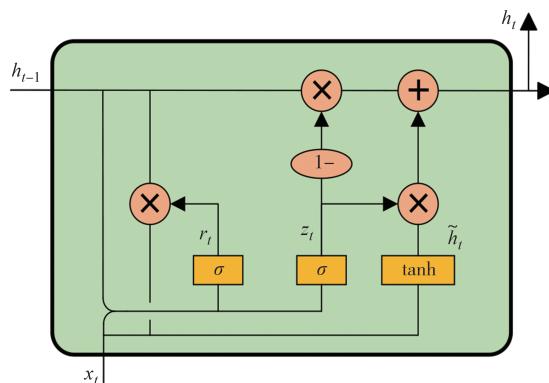


图3 GRU网络结构

Fig.3 Network structure of GRU

GRU的重置门用于控制数据的遗忘, 其值大小表示了上一时刻信息保留的多少, 而更新门用于控制当前时刻的隐藏状态. 给定时间步长 t 的输入 x_t , 则用于控制网络的门控阈值和序列输出特征可表示为:

$$r_t = \sigma(x_t \mathbf{W}_{xr} + h_{t-1} \mathbf{W}_{hr}) \quad (4)$$

$$z_t = \sigma(x_t \mathbf{W}_{xz} + h_{t-1} \mathbf{W}_{hz}) \quad (5)$$

$$\tilde{h}_t = \tanh[x_t \mathbf{W}_{xh} + (r_t \odot h_{t-1}) \mathbf{W}_{hh}] \quad (6)$$

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \quad (7)$$

式中: r_t 为重置门的门控阈值; z_t 为更新门的门控阈值; h_t 和 h_{t-1} 分别为当前时刻和上一时刻的状态记忆变量; σ 表示激活函数; $\mathbf{W}_{xr}, \mathbf{W}_{hr}, \mathbf{W}_{xz}, \mathbf{W}_{hz}, \mathbf{W}_{xh}, \mathbf{W}_{hh}$ 分别为训练权重参数矩阵; \tilde{h}_t 为候选隐藏状态.

在GRU网络序列中, 上一时刻的隐藏状态可影响当前时刻的特征计算, 即模型的输出是由之前的序列特征和当前的序列特征共同决定的, GRU网络可以有效处理时间序列问题.

1.4 逻辑判断层

CNN-GRU模型通过Softmax函数输出每一时刻的概率矩阵, 包括左换道、右换道和直行三种意图的概率, 但驾驶员在每一时刻实际上只会产生一种驾驶意图. 此外, 驾驶员在每一时刻的驾驶意图不是相互独立的, 有着一定的前后依赖关系. 因此, 为了更好地解决上述问题, 本文借鉴季学武等^[13]提出的概率判断阈值思想, 提出了CNN-GRU-Thre模型, 避免模型做出“保守”的预测. 通过设定概率阈值, 对输出的概率矩阵进行逻辑判断, 进一步满足时间序列上的前后依赖关系. 可表示为:

$$Y_t = \begin{cases} c_i, w_{ii} > \text{阈值} \\ c_{(t-1)i}, w_{ii} \leq \text{阈值} \end{cases} \quad (8)$$

式中: Y_t 为 t 时刻最终输出的意图类别; c_i 为 t 时刻第 i 个意图类别; $c_{(t-1)i}$ 为 $t-1$ 时刻第 i 个意图类别; w_{ii} 为 t 时刻第 i 个意图的概率.

即当输出的某一类型概率大于设定的阈值, 则认为输出的就是该时刻正确的意图. 若输出的概率小于该阈值, 则认为该时刻与上一时刻意图类别相同.

2 实验方案与数据处理

2.1 实验平台及场景

为了实时采集驾驶数据, 在保证安全的前提下展开志愿者实验. 通过罗技G29、PreScan和Simulink搭建驾驶模拟器, 以50 Hz的采样频率进行车辆行驶特征和驾驶员行为数据采集, 驾驶模拟器如图4所示.



图4 驾驶模拟器

Fig.4 Driving simulator

本文主要研究直行道路下的换道行为,通过PreScan搭建道路交通环境和障碍场景,以此为基础展开驾驶实验。如图5所示,驾驶场景道路为双向六车道,包含1300 m长的直行道路,以及交通标志、树木等其他道路环境元素。此外,还有3辆具有不同

位置和状态的障碍车,具体情况如下:

- 1)第一辆障碍车沿道路中心线行驶,速度为20 km/h;
- 2)第二辆障碍车位于500 m处,为静止状态;
- 3)第三辆障碍车位于900 m处,为静止状态。

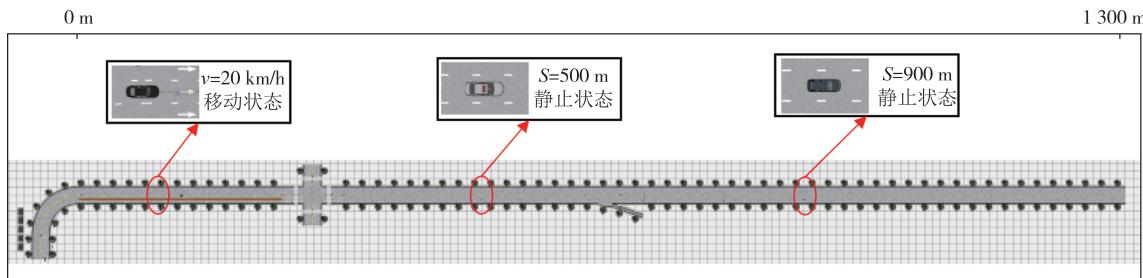


图5 实验场景

Fig.5 Test scene

本次实验共招募20名志愿者参加,包括14名男性志愿者和6名女性志愿者,平均年龄为23.35岁,所有志愿者均持有C1级驾驶证。在正式实验开始前,每位志愿者都进行了约10 min的驾驶测试,以熟悉驾驶模拟器的相关操作。实验中每位志愿者以40 km/h、50 km/h、60 km/h、70 km/h的车速分别进行驾驶实验,但不对速度做严格要求,没有太大的偏差即可。每位志愿者的任务主要为通过换道避开障碍物,并在超过障碍物保持一段直行后换回原车道,在驾驶过程中不对驾驶员做出任何干预。

2.2 数据处理与标注

将本次实验获得的数据进行轨迹提取,分别为左换道、右换道和直行3种情况,并利用滑动时窗法以0.1 s的窗口步长进行数据标注。以左换道为例,如图6所示,本文的车辆数据标注方法为:

- 1)寻找车辆轨迹跨过车道线的点C,定义为换道点;
- 2)从换道点C开始向后遍历,对横向坐标y进行判断,当 $y_{t+1} - y_t$ 的单调性第一次发生变化时,将该 y_t 点定义为换道终点D;
- 3)从换道点C开始向前遍历,对横向坐标y进行判断,当 $y_t - y_{t-1}$ 的单调性第一次发生变化时,将该 y_t 点定义为换道起点B;
- 4)从B点往前延长1.5 s,定为换道意图起点A。

右换道车辆数据标注方法与左换道相同,本试验共采集480条换道轨迹,包括左换道和右换道各240条。所有数据的换道距离和换道时间总体特征参

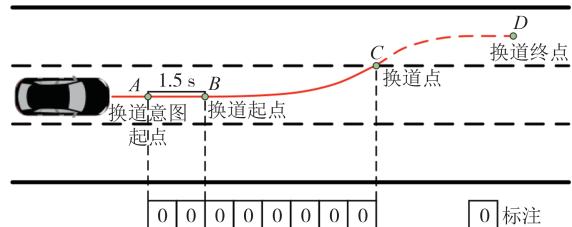


图6 左换道车辆数据标注示意图

Fig.6 Schematic diagram of the left lane change vehicle data labeling

数如表1所示。其中换道距离最大为224.14 m,最小为28.55 m;而换道时间最长为13.42 s,最短为1.88 s,换道时间与国内自然驾驶数据^[21]和NGSIM^[22]数据集中的统计结果是较符合的。图7和图8分别为换道距离和换道时间的直方图与分布曲线,可以看出数据总体上服从正态分布。

表1 换道距离和换道时间特征参数

Tab.1 Characteristic parameters of lane change distance and time

参数	距离/m		时间/s	
	左换道	右换道	左换道	右换道
均值	70.99	62.66	4.79	4.33
标准差	25.13	17.76	1.77	1.41
最大值	224.14	128.12	13.42	10.04
最小值	32.71	28.55	2.14	1.88

此外,在每次试验数据中截取了两条100 m的直行轨迹,共160条,并采用相同的窗口进行数据标注。将数据的80%作为训练集,20%作为测试集,对所有数据进行标准化处理,用于网络训练。

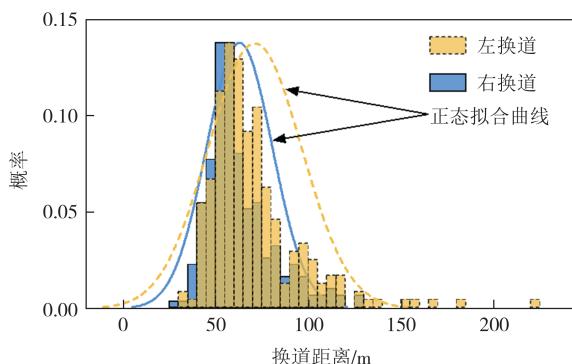


图 7 换道距离分布直方图

Fig.7 Distribution histogram of lane change distance

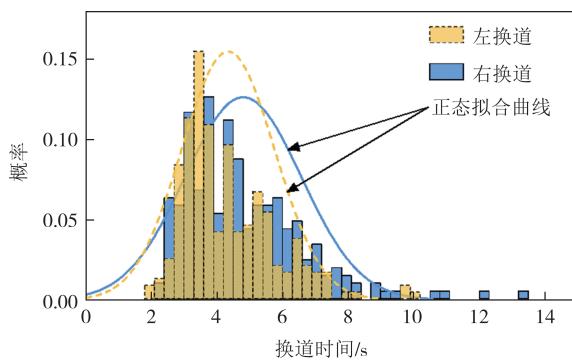


图 8 换道时间分布直方图

Fig.8 Distribution histogram of lane change time

3 模型评价与结果分析

3.1 模型评价指标

在利用训练集数据构建模型之后,我们需借助测试集数据对模型的分类结果进行评估分析。本文将采用以下指标来衡量模型性能:

1)模型的准确率 Accuracy, 表明在测试集中预测正确的样本占总数的比例, 用于评估模型整体的预测准确率, 其计算公式为

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (9)$$

式中: TP 为真实为正类且预测为正类的样本数; FP 为真实为负类但预测为正类的样本数; TN 为真实为负类且预测为负类的样本数; FN 为真实为正类但预测为负类的样本数。

2)模型的精确率 P 、召回率 R 和 F_1 分数, 其计算公式为

$$P = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (10)$$

$$R = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (11)$$

$$F_1 = 2 \times \frac{P \times R}{P + R} \quad (12)$$

3.2 模型结果与性能分析

意图识别模型的性能直接影响识别的结果, 本文建立的 CNN-GRU-Thre 模型由于在深度学习网络的基础上增加了逻辑判断层, 该层中需要设置阈值对 Softmax 输出的意图概率进行判断。因此, 阈值的大小在一定程度上影响了模型性能, 需要对不同阈值带来的影响进行分析评估。图 9 是在 CNN-GRU 网络基础上左换道、右换道和直行在不同判断阈值下的识别率。可以看出当阈值小于 0.9 时, 右换道随着阈值的增加, 识别率呈增高趋势, 而左换道和直行有一定程度的波动。而当阈值大于 0.9 时, 识别率大体上呈现先增高再降低的趋势。当阈值为 0.95 时, 模型整体有着最高的识别率, 故综合考虑后取判断阈值为 0.95。

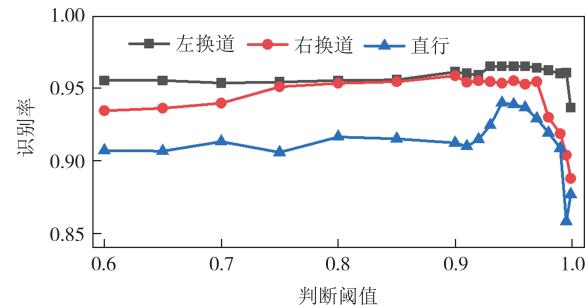


图 9 不同判断阈值下的识别率

Fig.9 Recognition rate of different thresholds

为了验证和评估本文所建立模型的有效性, 以及模型在意图识别上的性能, 采用相同的数据集分别建立以下多种模型进行对比分析相关指标:

1) CNN-LSTM 模型: 使用文献[14]中介绍的 LSTM 模型并在其基础上增加 CNN 网络层, 输入当前时刻与固定历史时刻的特征数据, 并通过 Softmax 函数输出不同意图的概率;

2) CNN-GRU 模型;

3) CNN-GRU-Att 模型: 采用文献[18]中所提出的模型, 在 GRU 层和全连接层之间加入注意力机制层。

各个模型的识别准确率 Accuracy、精确率 P 、召回率 R 和 F_1 分数结果如表 2 所示。由表 2 可知, CNN-LSTM 对于左换道、右换道和直行的识别准确率均低于 CNN-GRU, 说明在处理该类问题时 GRU 相较于 LSTM 有着更好的表现; 而融入了注意力机制的 CNN-GRU-Att 相较于前两者识别准确率也更

高,平均为95.8%,这与赵建东等^[18]的研究结果相似.而本文所提出的CNN-GRU-Thre模型的精确率、召回率和 F_1 相较于其他模型都更高,且对于左换道、右换道和直行的识别准确率分别为98.5%、96.7%、95.2%,相较于其他模型有着更好的识别效果.

表2 换道意图识别结果

Tab.2 Results of lane change intention recognition

模型	换道意图	P	R	F_1	Accuracy	综合
CNN-LSTM	左换道	0.948	0.931	0.939	0.961	
	右换道	0.880	0.909	0.894	0.934	0.932
	直行	0.870	0.860	0.865	0.901	
CNN-GRU	左换道	0.973	0.954	0.963	0.976	
	右换道	0.907	0.933	0.920	0.950	0.952
	直行	0.906	0.900	0.903	0.929	
CNN-GRU-Att	左换道	0.969	0.957	0.963	0.976	
	右换道	0.925	0.950	0.938	0.961	0.958
	直行	0.921	0.910	0.916	0.938	
CNN-GRU-Thre	左换道	0.988	0.965	0.977	0.985	
	右换道	0.938	0.955	0.946	0.967	0.968
	直行	0.934	0.939	0.936	0.952	

综上所述,引入逻辑判断层后,将驾驶意图识别在输入和输出上进行前后关联,能够在一定程度上提升模型的精确度,对于换道意图的识别尤为有效.

图10为四种模型的混淆矩阵,可以看出本文所提出的模型对左换道、右换道和直行均有着较高的识别精度,均超过了90%.左换道和右换道之间极少发生相互的错误识别情况,这是由于左、右换道时车辆行驶特征与驾驶员行为数据有着较明显的差异,因此不易识别成相反的类型.但换道和直行之间容易发生误识别情况,这是由于直行时车辆不是完全的直线行驶,车身有一定程度的左、右偏转,特征差异不够明显,因此更易识别错误.从图10可以看出,本文所提出的CNN-GRU-Thre模型不但提高了左、右换道和直行意图的识别准确率,也减少了换道和直行之间的误识别情况,对于换道意图的识别有更好的效果.

图11~13分别为不同模型对左换道、右换道和直行3种驾驶行为识别的受试者工作特征曲线(receiver operating characteristic, ROC).由图中可以看出,CNN-GRU网络模型的ROC曲线优于CNN-LSTM,而本文所提出的CNN-GRU-Thre模型相较于其他模型有着更好的表现,左换道、右换道和直行

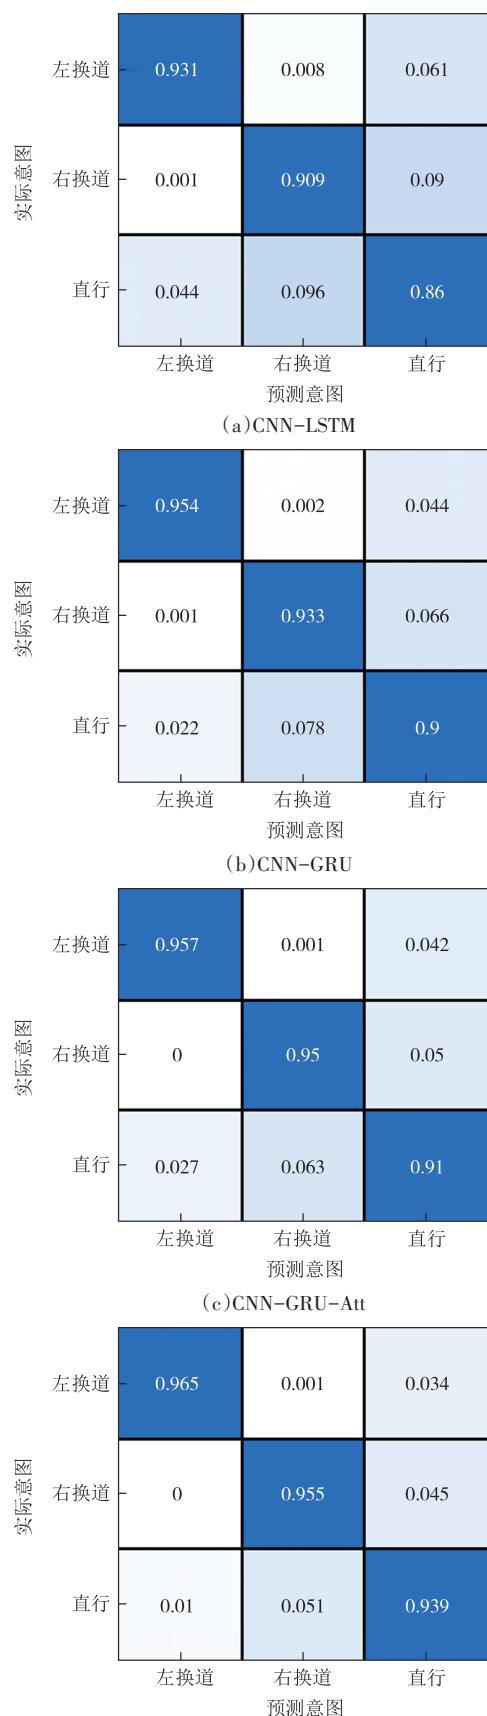


图10 模型的混淆矩阵

Fig.10 Confusion matrix of models

的曲线下面积(area under curve, AUC)值分别为0.995、0.991和0.979,说明本文提出的模型具有较好的意图识别能力.

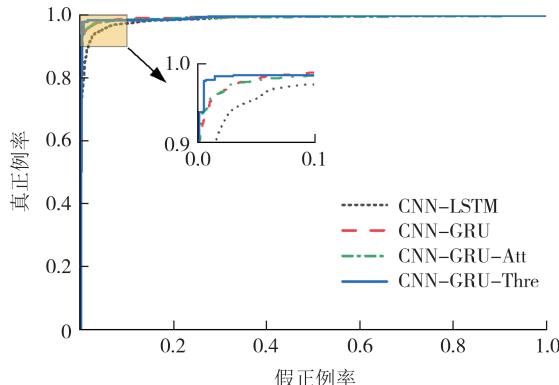


图11 左换道ROC曲线

Fig.11 ROC curve of left lane change

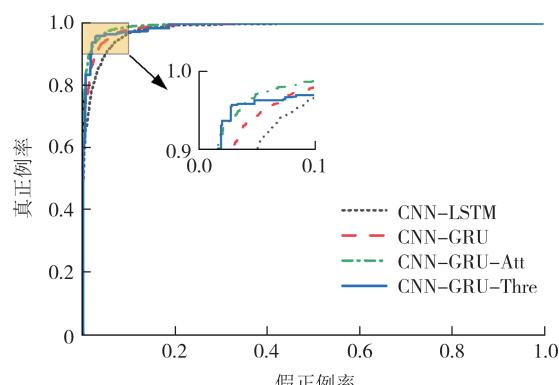


图12 右换道ROC曲线

Fig.12 ROC curve of right lane change

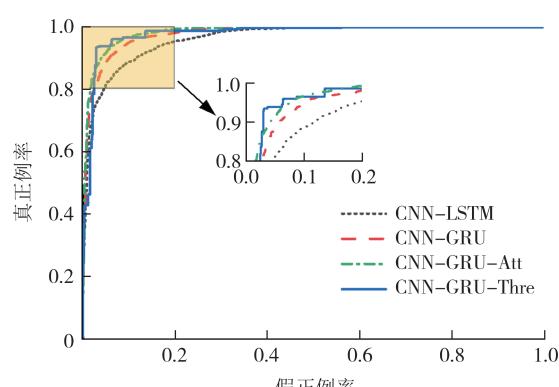


图13 直行ROC曲线

Fig.13 ROC curve of straight driving

4 结论

1)本文提出了一种有效识别车辆换道意图的方法,并构建了一个模型,该模型能够预测驾驶员的左

换道、右换道以及直行意图.本文设计了CNN-GRU-Thre模型,通过在深度学习网络基础上增加逻辑判断层,使得意图识别模型在时序上有着更好的前后关联性,提高了时间序列问题分类的精度.

2)本文模型采用驾驶模拟实验数据进行构建,同时考虑了车辆行驶特征和驾驶员行为数据,结果表明本文所提出的模型在识别准确率、 F_1 分数和AUC值等方面都有着较好的结果,相比于以往的模型对于换道意图识别更加准确.

3)本文的模型是针对直行工况中的换道行为进行研究的,故适用范围有一定局限性.在今后的研究中将尝试更多的工况和道路类型,如转弯和路口等.此外,也会在未来工作中构建多样的时序网络模型,通过进一步比对与分析,以期对意图识别有更好的识别效果.

参考文献

- [1] 国家统计局.中国统计年鉴2022[M/OL].北京:中国统计出版社, 2022 [2024-01-16]. <http://www.stats.gov.cn/sj/ndsj/2022/indexch.htm>.
- [2] SHAWKY M. Factors affecting lane change crashes[J]. IATSS Research, 2020, 44(2): 155-161.
- [3] 毕胜强,梅德纯,刘志强,等.面向驾驶行为预警的换道意图辨识模型研究[J].中国安全科学学报, 2016, 26(2): 91-95.
- [4] BI S Q, MEI D C, LIU Z Q, et al. Research on lane change intention identification model for driving behavior warning [J]. China Safety Science Journal, 2016, 26(2): 91-95. (in Chinese)
- [5] LI J H, LU C, XU Y Z, et al. Manifold learning for lane-changing behavior recognition in urban traffic [C]/2019 IEEE Intelligent Transportation Systems Conference (ITSC). October 27-30, 2019, Auckland, New Zealand. IEEE, 2019: 3663-3668.
- [6] HUANG R L, LIANG H W, ZHAO P, et al. Intent-estimation-and motion-model-based collision avoidance method for autonomous vehicles in urban environments[J]. Applied Sciences, 2017, 7(5): 457.
- [7] LI K Q, WANG X, XU Y C, et al. Lane changing intention recognition based on speech recognition models [J]. Transportation Research Part C: Emerging Technologies, 2016, 69:497-514.
- [8] 徐婷,温常磊,张香,等.基于GMM-CHMM的城市道路换道行为识别[J].交通运输系统工程与信息, 2020, 20(1):61-67.
- [9] XU T, WEN C L, ZHANG X, et al. Lane changing behavior identification of urban road based on GMM-CHMM [J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(1):61-67. (in Chinese)
- [10] XIE G T, GAO H B, HUANG B, et al. A driving behavior

- awareness model based on a dynamic Bayesian network and distributed genetic algorithm [J]. International Journal of Computational Intelligence Systems, 2018, 11(1):469–482.
- [9] 王亚伦,陈焕明,赵岩. 基于条件随机场的驾驶意图识别研究[J]. 青岛大学学报(工程技术版),2021,36(4):88–94, 114.
WANG Y L, CHEN H M, ZHAO Y. Research on driving intention recognition based on conditional random field [J]. Journal of Qingdao University (Engineering & Technology Edition), 2021, 36(4): 88–94, 114. (in Chinese)
- [10] MAMMERI A, ZHAO Y H, BOUKERCHE A, et al. Design of a semi-supervised learning strategy based on convolutional neural network for vehicle maneuver classification [C]//2019 IEEE International Conference on Wireless for Space and Extreme Environments (WiSEE). October 16–18, 2019, Ottawa, ON, Canada. IEEE, 2019: 65–70.
- [11] LI L, ZHAO W Z, XU C, et al. Lane-change intention inference based on RNN for autonomous driving on highways [J]. IEEE Transactions on Vehicular Technology, 2021, 70(6):5499–5510.
- [12] KHAIRDOOST N, SHIRPOUR M, BAUER M A, et al. Real-time driver maneuver prediction using LSTM [J]. IEEE Transactions on Intelligent Vehicles, 2020, 5(4): 714–724.
- [13] 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. (in Chinese)
- [14] 宋晓琳,曾艳兵,曹昊天,等. 基于长短期记忆网络的换道意图识别方法[J]. 中国公路学报, 2021, 34(11): 236–245.
SONG X L, ZENG Y B, CAO H T, et al. Lane Change Intention Recognition Method Based on an LSTM Network [J]. China Journal of Highway and Transport, 2021, 34(11): 236–245. (in Chinese)
- [15] DANG H Q, FÜRNKRANZ J, BIEDERMANN A, et al. Time-to-lane-change prediction with deep learning [C]//2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC). October 16–19, 2017, Yokohama, Japan. IEEE, 2017: 1–7.
- [16] HAN T, JING J B, OZGUNER U. Driving intention recognition and lane change prediction on the highway [C]//2019 IEEE Intelligent Vehicles Symposium (IV). June 9–12, 2019. Paris, France. IEEE, 2019: 957–96.
- [17] GUO Y S, ZHANG H J, WANG C, et al. Driver lane change intention recognition in the connected environment [J]. Physica A: Statistical Mechanics and Its Applications, 2021, 575: 126057.
- [18] 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 Z M, QU Y C, 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. (in Chinese)
- [19] ZHANG H J, GUO D, GUO Y S, et al. A novel method for the driver lane-changing intention recognition [J]. IEEE Sensors Journal, 2023, 23(17): 20437–20451.
- [20] CHO K, VAN MERRIENBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation [C]//Proceedings of the 2014 Conference on Empirical Methods in Natural Language Processing (EMNLP). Doha, Qatar. Stroudsburg , PA, USAACL, 2014: 1724–1734.
- [21] 王琳. 城市道路车辆换道行为特性研究[D]. 北京:北京交通大学,2014.
WANG L. Study on lane-changing behavior characteristics of urban road vehicles [D]. Beijing: Beijing Jiaotong University, 2014. (in Chinese)
- [22] 张颖达,邵春福,李慧轩,等. 基于NGSIM轨迹数据的换道行为微观特性分析[J]. 交通信息与安全, 2015, 33 (6) : 19–24, 32.
ZHANG Y D, SHAO C F, LI H X, et al. Microscopic characteristics of lane-change maneuvers based on NGSIM [J]. Journal of Transport Information and Safety, 2015, 33(6): 19–24, 32. (in Chinese)