

基于 PSO-GRU 模型的车辆换道意图识别

郭瑞军, 范超冉, 付明迪

(大连交通大学 交通工程学院, 辽宁 大连 116028)

摘要: 针对传统神经网络模型进行车辆换道意图识别时, 手动调整超参数耗时、效率低下且求解空间有限的问题, 提出了一种基于 PSO-GRU 的换道意图识别模型。首先, 针对 NGSIM 数据集横、纵向轨迹的特点提出了多步轨迹平滑方法。然后, 对轨迹数据进行参数挖掘并将其重构到数据集中, 构建车辆换道轨迹数据库, 使用随机森林 (RF) 算法评估数据库特征的重要性。最后, 建立了基于 PSO-GRU 的换道意图识别组合模型, 使用粒子群优化 (PSO) 算法优化门控循环单元 (GRU) 网络的超参数, 以找到最佳的网络配置。结果表明, 相较于传统深度学习算法和机器学习算法, 本文提出的 PSO-GRU 换道意图识别组合模型具有更高的识别准确率和更稳定的性能。

关键词: 交通运输系统工程; 换道意图识别; 多步轨迹平滑; 随机森林算法; 深度学习; 粒子群优化算法

中图分类号: U495 **文献标志码:** A **文章编号:** 1671-5497(2026)08-2084-11

DOI: 10.13229/j.cnki.jdxbgxb.20250008

Vehicle lane change intention recognition based on PSO-GRU model

GUO Rui-jun, FAN Chao-ran, FU Ming-di

(School of Transportation Engineering, Dalian Jiaotong University, Dalian 116028, China)

Abstract: To address the issues of low efficiency and limited solution space caused by manual hyperparameter tuning when using traditional neural network models for vehicle lane-changing intention recognition, a lane-changing intention recognition model based on PSO-GRU was proposed. First, a multi-step trajectory smoothing method was developed considering the characteristics of horizontal and vertical trajectories in the NGSIM dataset. Next, the trajectory data were mined for parameters and reconstructed into the dataset to establish a vehicle lane-changing trajectory database. The importance of features in the database was evaluated using the random forest algorithm. Finally, a combined model for lane-changing intention recognition based on PSO-GRU was built, with the PSO algorithm used to optimize the hyperparameters of the GRU network to find the optimal configuration. The results demonstrate that, compared to traditional deep learning and machine learning algorithms, the proposed PSO-GRU model exhibits higher recognition accuracy and more stable performance.

收稿日期: 2025-01-04.

基金项目: 辽宁省兴辽英才计划项目 (XLYC2411087); 2025 年度辽宁省科协科技创新智库项目 (LNKX2025XK03).

作者简介: 郭瑞军 (1977-), 男, 教授, 博士. 研究方向: 交通运输系统分析, 道路交通管理与控制. E-mail: rjguo@163.com

Key words: engineering of communications and transportation system; lane change intention recognition; multi-step trajectory smoothing; random forest algorithm; deep learning; particle swarm optimization algorithm

0 引言

在车辆驾驶过程中,驾驶员错误识别其他车辆的驾驶意图常导致交通事故。为提升道路的安全性和通行效率,精确识别车辆的换道意图成为现代驾驶领域的研究热点之一。驾驶意图是驾驶员在一段时间内综合考量环境信息而生成的,这就要求换道意图识别模型能够捕捉车辆历史时间序列数据的依赖关系,而深度学习模型擅长处理复杂高维车辆信息的非线性关系,可实现换道意图的精准识别。张海伦等^[1]采用自然驾驶数据集对双向长短期记忆(Bidirectional long short-term memory, Bi-LSTM)模型的有效性进行测试验证。David等^[2]建立了基于人工神经网络的状态机驾驶行为识别模型,以实现驾驶意图识别。季学武等^[3]设计了一种基于长短期记忆(Long short-term memory, LSTM)的驾驶意图识别模型,发现考虑周围车辆的交互信息能有效提高模型准确性。宋晓琳等^[4]通过在LSTM中引入注意力机制分配信息权重以提高换道意图的识别性能。赵建东等^[5]建立基于CNN-GRU的换道意图识别模型,使用NGSIM数据集训练模型。近年来,基于数据驱动的方法已成为换道意图识别研究的一个重要方向。部分研究者依赖模拟数据,张洪加等^[6]基于驾驶模拟器开展驾驶试验。随着研究的深入,越来越多的真实数据集被引入,NGSIM数据集和HighD数据集等因其高质量和丰富的交通场景数据被广泛应用。

综上,现有研究在使用数据训练模型前未对轨迹数据进行平滑或平滑不充分,因此,本文提出了多步轨迹平滑方法,针对横、纵向轨迹的不同特点,分别应用了不同的平滑方法。此外,虽对于意图识别的研究方法在不断创新,但在应用深度学习识别车辆换道意图时,仍依赖人工调参,不仅过于依靠经验,而且耗费大量时间和资源,因此,本文提出了基于粒子群优化算法(Particle swarm optimization, PSO)与门控循环单元(Gated recurrent unit, GRU)的组合模型。首先,对NGSIM数据进行参数挖掘;然后,使用多步轨迹平滑方法分

别平滑横、纵向轨迹数据;再通过随机森林算法评估特征值的重要性;最后,搭建PSO-GRU换道意图识别模型,使用PSO算法搜索GRU模型的最优参数,从而提高模型的识别精度。

1 轨迹数据预处理

1.1 实验数据

本文所用NGSIM数据主要参数如表1所示,其中,1 ft=0.304 8 m。实验数据基于数据集中的US-101路段,经统计,该路段的数据中小汽车占比96.82%,远高于摩托车和大型车,为研究车辆换道行为提供了充足的样本,因此选取1~5车道自由换道的小汽车作为研究对象。

表1 NGSIM主要参数

Table 1 Main parameter of NGSIM

字段	说明	单位及描述
Vehicle_ID	车辆编号	—
Frame_ID	数据帧号	1/10 s
Local_X	采集区域车辆的横坐标	ft
Local_Y	采集区域车辆的纵坐标	ft
v_Class	车辆类型	1-摩托车;2-小汽车; 3-大型车
v_Vel	车辆速度	ft/s
v_Acc	车辆加速度	ft/s ²
Lane_ID	所在车道	—
Preceding	跟驰前车编号	—
Following	跟驰后车编号	—
Location	路段名称	—

虽然NGSIM数据集在研究中展现了较高的实际应用价值,但仍然存在一定误差。分析误差产生的原因:首先,通过设置摄像头采集视频并提取的观测数据,由于测量误差而与实际存在偏差。其次,在数据处理阶段,通过纵向位置的差分计算得到的速度和加速度包含许多极端值,被人为设定阈值去除,导致速度和加速度的分布不一致,差分后部分数据超出车辆性能和人体的承受范围^[7]。此外,现有研究对于NGSIM的平滑方法单一^[8],仅使用单种平滑方法,未对异常值做单独处理,表现为除异常不足;过度平滑数据失去原有趋势,表现为去噪过度。因此,需重构数据集,重新

差分横、纵向位置,再根据横、纵数据特点采取不同的平滑方式。

1.2 多步轨迹平滑法

(1) 横向轨迹数据单步平滑

由于横向车辆轨迹信息是换道执行过程中的重要数据,要注意过度平滑问题,因此对于横向车辆轨迹信息使用单步卡尔曼滤波平滑方法。如图1所示,平滑后的数据既能保持原有的轨迹趋






图1 车辆横向数据平滑效果对比

Fig. 1 Comparison of lateral data smoothing effects

势,又能有效去除尖峰值和异常值。

(2) 纵向轨迹数据多步平滑

由于纵向轨迹存在较多的异常值和噪声,要注意去噪不足的问题,因此对于纵向轨迹信息应使用多步平滑方法。首先,识别超出车辆和人体承受极限 $[-8, 5] \text{ m/s}^2$ 的加速度异常值;然后,使用三次样条插值法对相应的纵向位置进行插值修正;再重新差分得到修正后的速度和加速度值,循环至最后,使用移动平均法进行平滑处理。如图2所示,对比移动平均法的不同窗口大小并最终确定为10,该窗口大小既能适应平滑数据,又不会过度偏离原始数据,保留数据整体趋势。




图2 平滑窗口对比

Fig. 2 Comparison of smoothing windows

平滑前后的纵向位置、速度、加速度数据如图3所示,可以看出,使用经过多步平滑后的数据有效去除了尖峰值和异常值,曲线更加平滑。由于原始数据中车辆纵向位置比较稳定,无异常波动,所以拟合结果与原始情况基本一致,但速度、加速度值得到有效修正,其值在人体和车辆可接受的阈值内。

1.3 参数指标挖掘

为提高数据的利用价值,对数据进行参数指标挖掘。对于目标车,添加车辆横向偏角这一能够反映车辆行驶方向变化的关键指标;对于周围环境车,挖掘与目标车辆关联的车辆交互数据,有助于研究车辆换道规律。车辆偏角为 θ_n ,则车辆相较于直线行驶的方向角度为 $90^\circ - \theta_n$ 。 θ_n 的计算公式为:

$$\theta_n = \arctan\left(\frac{y_{n+1} - y_n}{x_{n+1} - x_n}\right) \quad (1)$$

式中: x_n, y_n 分别为当前时刻的车辆横、纵坐标。

车辆横向偏角统计如图4所示,可见 θ_n 接近 $\pm 90^\circ$ 的频率最多,则车辆相较于直线行驶的方向角度 $90^\circ - \theta_n$ 接近 0° ,属于车辆的直线行驶阶段;




图 3 车辆纵向数据平滑效果对比

Fig. 3 Comparison of longitudinal data smoothing effects

θ_n 接近 $\pm 85^\circ$ 的频率次之,则车辆相较于直线行驶的方向角度 $90^\circ - \theta_n$ 在 5° 左右,属于车辆调整方向或存在换道行为的阶段; θ_n 接近 0° 的频率最少,则车辆相较于直线行驶的方向角度 $90^\circ - \theta_n$ 接近 90° ,车辆行驶方向几乎垂直于其原来的行驶轨迹,属于急转弯迅速改变车道的车辆行驶阶段。平滑后的车辆横、纵向位置仍符合车辆实际运行情况,数据参数挖掘符合实际。

在高速动态复杂的交通场景中,驾驶意图是目标车辆状态和与周围车辆交互共同作用的结




图 4 车辆横向偏角统计图

Fig. 4 Statistics of vehicle lateral offset

果。针对车辆在三车道的驾驶环境,挖掘周围环境的车辆信息(包括当前车道、左右车道上的前后车交互信息),如图 5 所示。




图 5 关联车辆示意图

Fig. 5 Schematic diagram of associated vehicles

1.4 驾驶数据截取和打标

根据 NGSIM 数据集的统计结果^[9],换道动作执行阶段的时长为 6 s,且在两车道上的执行时间均为 3 s,因此截取换道点前 3 s 历史长度的换道数据作为车辆行驶轨迹数据集,并对此数据集提取关联车辆信息。在换道数据打标分类时,如果车道 ID 变小,则为向左换道,标记为 1;如果车道 ID 不变,则为直行数据,标记为 2;如果车道 ID 变大,则为向右换道,标记为 3。

由于数据样本不均衡,对数据进行混合采样,对于向右换道的车辆,使用 I-80 路段的向右换道车辆进行扩充,并随机打乱样本顺序,保留 3 种换道类型的车辆行驶轨迹各 283 组,最终共提取 849 辆车的数作为模型的输入数据,按 8:2 划分训练集和测试集。

2 基于随机森林算法的换道意图识别和特征评估

2.1 基于随机森林算法的换道意图识别

输入自身车辆及关联车辆的特征,如表 2 所

示,为随机森林(Random forest, RF)算法设置不同数量的树,训练 Z-Score 标准化前、后的数据进行换道意图分类,分类准确率如表 3 所示。

由表 3 数据可得出以下结论:①标准化后的意图分类准确率更高。准确率最高为 60.53%,增长幅度最高为 7.60%,因此,标准化后的数据能够提高模型的识别精度。②增加树的数量,模型准确率无明显提升。树的数量从 100 递增至 150,标准化后的数据准确率先有所提升而后下降,在 120 棵树时达到最高点(60.53%),之后略有下降,模型性能在 120 棵树左右达到性能最优。因此,在后续基于 RF 做特征重要度评估时,树的数量宜设置为 120。③随机森林的换道意图分类准确率较低,在车辆换道意图识别中表现不佳,应采用能够捕捉长时间序列信息的深度学习模型,对车辆换道意图识别任务进行建模。

表 2 输入参数指标

Table 2 Input parameter indicators

特征名称		特征描述
自身 车辆	Local_X	车辆横坐标/m
	Local_Y	车辆纵坐标/m
	v_x	车辆横向速度/($\text{m}\cdot\text{s}^{-1}$)
	v_y	车辆纵向速度/($\text{m}\cdot\text{s}^{-1}$)
	a_x	车辆横向加速度/($\text{m}\cdot\text{s}^{-2}$)
	a_y	车辆纵向加速度/($\text{m}\cdot\text{s}^{-2}$)
关联 车辆	angle	车辆偏角/($^{\circ}$)
	FY	前车纵向位置差/m
	FV	前车纵向速度差/($\text{m}\cdot\text{s}^{-1}$)
	BY	后车纵向位置差/m
	BV	后车纵向速度差/($\text{m}\cdot\text{s}^{-1}$)
	LFY	左前车纵向位置差/m
	LFV	左前车纵向速度差/($\text{m}\cdot\text{s}^{-1}$)
	LBV	左后车纵向位置差/m
	LBV	左后车纵向速度差/($\text{m}\cdot\text{s}^{-1}$)
	RFY	右前车纵向位置差/m
	RFV	右前车纵向速度差/($\text{m}\cdot\text{s}^{-1}$)
	RBV	右后车纵向位置差/m
	RBV	右后车纵向速度差/($\text{m}\cdot\text{s}^{-1}$)

2.2 基于随机森林算法的特征重要性评估

如果特征在模型中很重要,那特征的值被随机扰动时,袋外错误率会显著下降。因此,通过比较引入噪声前、后的错误率可以评估每个特征对模型性能的影响,即特征的重要性。使用随机森林算法对标准化后的数据进行特征重要性评估,其重要性得分的热力图 and 归一化后的相对重要性得分如图 6 所示。

表 3 随机森林分类准确率

Table 3 Random forest classification accuracy

树的数量	未标准化分类准确率/%	标准化分类准确率/%	增幅/%
100	53.24	60.10	6.86
110	53.08	60.24	7.16
120	52.93	60.53	7.60
130	52.65	60.22	7.57
140	53.08	60.33	7.25
150	53.02	60.39	7.37





图 6 基于随机森林算法的特征重要度评估

Fig. 6 Feature importance assessment based on random forest algorithm

由图 6 可以看出:①RF 算法的特征重要性评估结果符合车辆行驶的动力学特性,在换道过程中,RFY、Local_X、LFY 为最重要的前 3 个特征,符合换道需满足空间安全条件的驾驶逻辑;②本文构建的车辆行驶轨迹数据库具有有效性,保留的 19 个数据特征相对重要性得分都均接近平均值 0.05,对识别换道意图有显著贡献,属于有效特征,数据格式满足机器学习模型的输入要求;③挖掘关联车辆的交互特征对换道任务有重要贡

献。在后续研究中,应将车辆自身特征以及周围车辆的相关特征标准化处理后作为模型的输入,进行深度学习模型的分类任务训练。

3 本文方法

3.1 门控循环单元

门控循环单元(Gated recurrent unit networks, GRU)是LSTM的一种变体,其结构更简单且计算效率更高,利用重置门和更新门控制轨迹信息的传递,重置门允许信息的通过或屏蔽,更新门控制着从上一时刻隐藏状态传入的信息量,其计算公式分别如式(2)~式(5)所示:

$$r_t = \sigma(w_r[h_{t-1}, x_t]) \quad (2)$$

$$\tilde{h}_t = \tanh(w_z[r_t h_{t-1}, x_t]) \quad (3)$$

$$z_t = \sigma(w_z[h_{t-1}, x_t]) \quad (4)$$

$$h_t = h_{t-1}(1 - z_t) + z_t \tilde{h}_t \quad (5)$$

式中: r_t 为 t 时刻的重置门值; σ 为sigmoid激活函数; h_t 为 t 时刻的候选隐藏单元值; x_t 为 t 时刻的输入数据; $\tilde{h}_t$ 为候选隐藏单元值; w_r 、 w_z 均为权重系数; z_t 为 t 时刻的更新门值。

3.2 GRU换道意图识别模型

GRU换道意图识别模型由输入层、GRU层、softmax层、classification层和输出层构成。输入层获取车辆及其关联车辆的历史行驶数据;循环层使用GRU单元对数据的时间序列特征进行学习;softmax层对数据进行概率估计,将模型不同换道意图输出转换为概率分布;classification层选取概率最大的换道意图作为最终结果;输出层输出换道意图识别结果。本文搭建的GRU换道意图识别网络结构如图7所示。




图7 GRU换道意图识别模型

Fig. 7 GRU lane change intention recognition model

3.3 PSO-GRU换道意图识别模型

深度学习模型的网络结构初始学习率 η 、隐藏神经元数 n 等参数通常无法设置到最优值,影响其准确度。PSO算法可以在规定搜索范围内搜索问题的最优解,且可以灵活结合其他优化算法,具有较少的控制参数,因此本文搭建的PSO-GRU换道意图识别模型,将GRU神经网络的超参数选择作为PSO算法要解决的问题。在模型中,PSO算法用于优化GRU网络的超参数,以找到最佳网络配置。GRU网络则负责从车辆的历史轨迹数据中学习,并预测车辆的换道行为,具体步骤如下所示。

(1)种群初始化:设置种群规模、搜索维度、认

知因子、社交因子等参数,随机初始化种群,将GRU模型测试集的损失值作为各粒子的适应度值,定义损失值最小为目标函数评估粒子的适应度。

(2)迭代更新:更新时采取权重线性递减法,以避免PSO的震荡问题,迭代更新包括速度更新和位置更新,种群中每个粒子的速度 $V_{i,d} = (v_{i1}, v_{i2}, \dots, v_{iD})^T$ 代表一组超参数的变化速率,在全局粒子的最优速度中找出最优值,将其更新为目前最优的速度;种群中每个粒子的位置 $X_{i,d} = (x_{i1}, x_{i2}, \dots, x_{iD})^T$ 代表一组超参数,根据初始适应度值确定初始的个体最优位置 $P_{i,d} = (p_{i1}, p_{i2}, \dots, p_{iD})^T$ 与全局最优位置 $P_{g,d} =$

$(p_{g1}, p_{g2}, \dots, p_{gD})^T$; $x_{iD}, v_{iD}, p_{iD}, p_{gD}$ 分别为每个维度空间粒子的位置、速度、个体最优值和全局最优值; 将全局粒子最优值更新为目前最优的位置, 即找到新的超参数组合。速度、位置更新公式分别为:

$$v_{i,d}^{t+1} = \omega v_{i,d}^t + c_1 r_1 (p_{i,d} - x_{i,d}^t) + c_2 r_2 (p_{g,d} - x_{i,d}^t) \quad (6)$$

$$x_{i,d}^{t+1} = x_{i,d}^t + v_{i,d}^{t+1} \quad (7)$$

式中: $i \in (1, 2, \dots, N)$, $d \in (1, 2, \dots, D)$; t 为当前迭代次数; ω 为惯性权重; c_1, c_2 均为学习因子; r_1, r_2 均为学习率。

r_2 均为学习率。

(3) 终止条件: 本模型设置终止条件为达到最大迭代次数 20 次, 若训练达到迭代终止条件, 则退出; 若未达到迭代终止条件, 则返回继续迭代。

(4) 训练模型: 将算法优化得到的超参数最优组合赋给 GRU 网络, 采用优化后的参数值建模并训练模型, 输出模型测试集评价指标。

PSO-GRU 换道意图识别模型的框架如图 8 所示。




图 8 PSO-GRU 换道意图识别模型框架

Fig. 8 PSO-GRU lane change intention recognition model framework

4 实验结果分析

4.1 模型评价指标

向左换道、保持直行、向右换道对应的分类标签分别为 1、2、3, 模型评价指标包括准确率 (Acc)、精确率 (Pre)、召回率 (Rec)、 F_1 值 (F_1), 其计算公式分别如下所示。

$$\text{Acc} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{FP} + \text{TN} + \text{FN}} \quad (8)$$

$$\text{Pre} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (9)$$

$$\text{Rec} = \frac{\text{TP}}{\text{TP} + \text{FN}} \quad (10)$$

$$F_1 = \frac{2\text{Pre} \times \text{Rec}}{\text{Pre} + \text{Rec}} \quad (11)$$

式中: TP 为真正例; TN 为真负例; FP 为假正例; FN 为假负例。

4.2 平滑方法有效性验证

为验证本文多步轨迹数据平滑方法的有效性, 基于 GRU 模型进行对比实验, 使用相同的网络结构和超参数进行识别, 模型训练迭代图及实

验结果分别如图 9 和表 4 所示。

对于训练集,由图 9 可以看出,平滑后的数据识别效果更好。当训练数据迭代趋于平稳后,原始数据意图识别模型的训练集准确率接近 90%,而平滑后的数据训练集识别准确率提升至 91%左右,提升效果约为 2%,表明轨迹数据在经过多步轨迹平滑后,能够在训练集上表现出更好的性能。




图 9 未平滑数据与平滑数据训练迭代图对比

Fig. 9 Comparison of training iteration charts for unsmooth and smooth data

表 4 模型识别指标

Table 4 Model recognition metrics			
类别	准确率/%	精确率/%	召回率/%
未平滑	90.59	91.65	90.38
平滑后	92.35	92.94	92.47

对于测试集,由表 4 可知,平滑后的数据识别效果更好。未平滑的数据各项意图识别指标均在 90% 左右,而平滑后的数据各项指标均超过 92%,识别准确率提升 1.76%,表明轨迹数据在经过多步轨迹平滑后,能够在测试集上表现出更好的性能。

综上,本文多步轨迹平滑方法适用于处理车辆的行驶轨迹数据,能够使神经网络学习到更少的噪声,在意图识别时表现出更良好的性能。

4.3 GRU 网络结构优化

使用控制变量法对 GRU 换道意图识别模型的网络输入序列长度、模型结构和超参数进行调优,得到网络结构优化结果如表 5 所示。

表 5 GRU 换道意图识别模型网络结构优化

Table 5 Optimization of GRU lane change intention recognition model network structure		
参数	实验设定	数值
输入层	InputSize	19
GRU 层数	GruLayer	2
隐藏神经元数量	NumHiddenUnits	50
批次大小	batch size	128
学习率	learning rate	0.001
最大迭代次数	MaxEpochs	100
输出层	OutputSize	3

实验结果如图 10 和表 6 所示,GRU 模型的总体准确率为 92.35%,其他指标均在 90% 以上,表明模型具备较好的意图识别能力。与随机森林算法相比,GRU 模型的准确率提高约 30%。向左和向右换道的准确率较高,而保持直行的准确率较低,这是因为换道的横向轨迹更明显,而直行轨迹容易被误判。此外,人工调参的局限性可能导致 GRU 模型未能充分学习 3 种换道意图的特征。因此,本文将采用优化算法改进超参数,以提升模型性能。




图 10 GRU 换道意图识别模型混淆矩阵

Fig. 10 GRU lane change intention recognition model confusion matrix

表 6 GRU 换道意图识别模型评价指标

Table 6 GRU lane change intention recognition model evaluation metrics				
换道意图	精确率/%	召回率/%	F_1 /%	准确率/%
向左换道	93.88	100.00	96.84	92.35
保持直行	95.75	80.36	87.38	
向右换道	89.19	97.06	92.96	

4.4 PSO-GRU 网络结构优化

PSO-GRU 模型迭代 20 次后终止算法并输出最优参数,模型参数和粒子迭代损失值如表 7 和图 11 所示。

人工调参的控制变量法存在较大局限性,不

表 7 PSO-GRU 车辆换道意图识别模型参数

Table 7 PSO-GRU vehicle lane change intention recognition model parameters	
参数	数值及描述
种群规模	5
搜索维度	3
认知因子	2
社交因子	2
惯性权重	[0.4,0.9]
终止条件	迭代 20 次




图 11 PSO-GRU 模型粒子损失值迭代图

Fig. 11 Iteration chart of particle loss values for PSO-GRU model

仅主观性、局限性强,而且消耗计算资源,难以得到最优结构。因此,本文使用 PSO 算法进行模型超参数寻优,在全局搜索找到模型最佳结构,最终得到的 PSO-GRU 换道意图识别模型最优网络结构如表 8 所示。

表 8 PSO-GRU 最优网络结构

Table 8 PSO-GRU optimal network architecture		
参数	实验设定	数值
输入层	InputSize	19
GRU 层数	GruLayer	2
隐藏神经元数量	NumHiddenUnits	76
批次大小	batch size	64
学习率	learning rate	0.01
最大迭代次数	MaxEpochs	100
输出层	OutputSize	3

换道意图识别的混淆矩阵和评价指标结果如图 12 和表 9 所示。PSO-GRU 换道意图识别模型在识别测试样本时,仅有 5 组样本被错误识别,具有较高的准确率。经计算,3 种行驶意图识别的各项指标均在 90% 以上,相比于手动调参,自动优化的模型具有更大的寻优空间和更强的学习能力。向左和向右换道的识别准确率高干保持直行,这是因为换道行为轨迹特征变化更明显。分析误判样本,可能是因为换道轨迹平滑或环境扰动导致车辆状态波动,使得换道被误判为直行。

4.5 对比实验分析

为验证本文 PSO-GRU 意图识别模型的有效性,选择常用于时间序列数据预测的神经网络进行对比分析,分别建立了 LSTM、BiLSTM、GRU 换道意图识别模型,使用同一数据集对换道意图进行预测。首先,使用控制变量法对超参数调优




图 12 PSO-GRU 换道意图识别模型混淆矩阵

Fig. 12 PSO-GRUGRU lane-change intention recognition model confusion matrix

表 9 PSO-GRU 换道意图识别模型性能评价指标

Table 9 GRU lane-change intention recognition model performance evaluation metrics

换道意图	精确率/%	召回率/%	F_1 /%	准确率/%
向左换道	97.83	97.83	97.83	
保持直行	94.74	96.43	95.58	97.06
向右换道	98.51	97.06	97.78	

以找到模型的最佳结构;然后,训练模型并对比分析模型的性能指标。为避免实验存在偶然性,对每种意图识别模型分别进行 10 次训练,记录其准确率的箱线图,如图 13 所示。




图 13 模型准确率箱线图

Fig. 13 Model accuracy boxplot

由图 13 可知,PSO-GRU 模型在所有测试中表现出较高且稳定的识别准确率,明显优于其他 3 种模型。具体而言,LSTM 和 BiLSTM 波动性较大,整体稳定性较差,且 3 种模型的准确率整体低于 PSO-GRU 的平均水平。从图 13 中可以清晰地看出,PSO-GRU 的中位数和上下四分位数均优于其他模型,进一步证明了其在换道意图识别中的优越性和稳定性。

综上所述,相比于单一的深度学习模型,PSO-GRU 更适合应用于换道意图的识别任务。

为全面评估本文 PSO-GRU 意图识别模型的有效性,以准确率为指标,使用相同数据集,将本文 PSO-GRU 换道意图识别模型与 RF 算法、LSTM、BiLSTM、GRU 进行对比分析,同时与研究者常进行实验的机器学习算法(KNN、决策树、BP 神经网络)进行对比分析^[10]。通过表 10 所示各模型准确率可以看出:相较于单一的深度学习模型和机器学习算法,本文模型在换道意图识别方面表现出更优越的性能。

表 10 各模型性能指标对比

Table 10 Comparison of performance indicators for various models

算法	模型	准确率/%
传统机器学习	RF 算法	60.53
	KNN	69.09
	BP	84.36
	决策树	86.33
深度学习	BiLSTM	91.76
	LSTM	92.35
	GRU	92.35
	PSO-GRU	97.06

相比单一的换道意图识别深度学习模型(BiLSTM、LSTM、GRU),PSO-GRU 换道意图组合模型识别准确率分别提升了 5.3%、4.7%、4.7%;相比传统机器学习算法(RF 算法、KNN、BP、决策树)换道意图识别模型,PSO-GRU 换道意图组合模型识别准确率分别提升了 36.53%、27.97%、12.7%、10.73%。

5 结 论

(1)本文提出的多步轨迹平滑方法适用于处理车辆的行驶轨迹数据,有效去除了尖峰值和异常值,使轨迹曲线更加平滑且加速度在人体与车辆可接受的阈值内,在换道意图识别时表现出良好的性能。

(2)随机森林算法显示,本文构建的车辆行驶轨迹数据库特征有效,不仅符合车辆的动力学特性,还能满足机器学习模型的输入要求。此外,随机森林算法无法捕捉时间序列关系,换道意图分类任务表现不佳。

(3)结合了智能优化算法的 PSO-GRU 换道意图组合模型更适用于识别驾驶意图。相较于传

统机器算法,准确率最高提升了36.53%;相较于单一的深度学习算法,准确率最高提升了5.3%,在换道意图识别中具有优越性和稳定性。

参考文献:

- [1] 张海伦,付锐.高速场景相邻前车驾驶行为识别及意图预测[J].交通运输系统工程与信息,2020,20(1):40-46.
Zhang Hai-lun, Fu Rui. Driving behavior recognition and intention prediction of adjacent preceding vehicle in highway scene[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(1): 40-46.
- [2] David R, Rothe S, Soffker D. Lane changing behavior recognition based on artificial neural network-based state machine approach[C] //Proceedings of IEEE Conference on Intelligent Transportation Systems, Indianapolis, Indiana, USA, 2021: 3444-3449.
- [3] 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 Xue-wu, Fei Cong, He Xiang-kun, et al. Intention recognition and trajectory prediction for vehicles using LSTM network[J]. China Journal of Highway and Transport, 2019, 32(6): 34-42.
- [4] 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 Xiao-lin, Zeng Yan-bing, Cao Hao-tian, et al. Lane change intention recognition method based on an LSTM network[J]. China Journal of Highway and Transport, 2021, 34(11): 236-245.
- [5] 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 Jian-dong, Zhao Zhi-min, Qu Yun-chao, 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.
- [6] 张洪加,郭应时,高松,等.网联与非网联环境下驾驶人换道意图识别研究[J].中国公路学报,2023,36(9):257-270.
Zhang Hong-jia, Guo Ying-shi, Gao Song, et al. Driver lane-changing intention recognition in connected and non-connected environments[J]. China Journal of Highway and Transport, 2023, 36(9): 257-270.
- [7] Montanino M, Punzo V. Trajectory data reconstruction and simulation-based validation against macroscopic traffic patterns[J]. Transportation Research Part B: Methodology, 2015, 80: 82-106.
- [8] 李依,赵建有,叶云涛.NGSIM轨迹重构研究综述[J].汽车实用技术,2021,46(4):204-208.
Li Yi, Zhao Jian-you, Ye Yun-tao, et al. A review of NGSIM trajectory reconstruction[J]. Automobile Applied Technology, 2021, 46(4): 204-208.
- [9] 刘阳林.无人驾驶车辆局部换道决策与换道轨迹规划算法研究[D].长春:吉林大学汽车工程学院,2023.
Liu Yang-lin. Research on local lane change decision and lane change trajectory planning algorithm of driverless vehicle[D]. Changchun: College of Automotive Engineering, Jilin University, 2023.
- [10] 赵志敏.数据驱动的车辆换道意图识别及轨迹预测研究[D].北京:北京交通大学交通运输学院,2022.
Zhao Zhi-min. Data-driven vehicle lane change intention recognition and trajectory prediction[D]. Beijing: School of Traffic and Transportation, Beijing Jiaotong University, 2022.