

# 基于轨迹预测和极限梯度提升的驾驶意图识别

方华珍, 刘立, 顾青, 肖小凤, 孟宇

(北京科技大学机械工程学院, 北京 100083)

**摘要:**为实现智能网联车对周围车辆驾驶意图的准确辨识,提出了一种基于轨迹预测与极限梯度提升算法(XGBoost)的驾驶意图识别框架。首先,通过标注车辆历史轨迹的驾驶意图来建立离线训练数据集。其次,构建驾驶意图识别框架,通过混合示教的长短时记忆网络(LSTM)模块预测目标车辆的未来轨迹,XGBoost模块融合历史轨迹和未来轨迹来识别出驾驶意图。最后,采用实际道路数据集NGSIM(Next Generation SIMulation)US101和I-80路段来验证模型框架。实验结果表明:该方法在4 s历史轨迹预测3 s未来轨迹处识别准确率可达97.7%,表现出较强的驾驶意图识别能力。实现代码见网站:<https://gitee.com/fanghz-colin/lstm-xgboost.git>。

**关键词:**交通工程;长短时记忆网络;极限梯度提升;智能网联车;驾驶意图识别

**中图分类号:**U495 **文献标志码:**A **文章编号:**1671-5497(2025)02-0623-08

**DOI:**10.13229/j.cnki.jdxbgxb.20230479

## Driving intention recognition based on trajectory prediction and extreme gradient boosting

FANG Hua-zhen, LIU Li, GU Qing, XIAO Xiao-feng, MENG Yu

(School of Mechanical Engineering, University of Science and Technology Beijing, Beijing 100083, China)

**Abstract:** To achieve accurate identification of the driving intentions of surrounding vehicles by intelligent connected vehicles, a driving intention recognition framework based on trajectory prediction and extreme gradient boosting (XGBoost) algorithm is proposed. Firstly, we attach the driving intention label to the vehicle's historical trajectory sequence and build the offline training dataset. Then, a driving intention recognition framework is constructed. A mixed teacher force long short-term Memory (LSTM) module is used to predict the future trajectory. The XGBoost module concatenates the historical and future trajectory and recognizes driving intention (left lane change, lane keeping, and right lane change). Finally, the model is verified on the real road datasets Next Generation SIMulation (NGSIM) US101 and I-80 sections. The experimental results show that the proposed model outperforms the other methods in metrics precision, recall, F1 score, and accuracy. The recognition accuracy can reach 97.7% in the prediction of 4 s historical trajectory and 3 s future trajectory, which shows good performance in driving intention recognition. The code can be obtained at: <https://gitee.com/fanghz-colin/lstm-xgboost.git>.

**收稿日期:**2023-05-14.

**基金项目:**国家自然科学基金青年科学基金项目(52202505);国家重点研发计划项目(2019YFC0605300).

**作者简介:**方华珍(1996-),男,博士研究生.研究方向:驾驶意图识别,轨迹预测.E-mail:fhz\_colin@xs.ustb.edu.cn

**通信作者:**顾青(1982-),女,副教授,博士.研究方向:无人驾驶轨迹预测、规划和决策.E-mail:qinggu@ustb.edu.cn

**Key words:** traffic engineering; long short-term memory; extreme gradient boosting; intelligent connected vehicle; driving intention recognition

## 0 引言

智能网联车辆的主动安全系统能够有效减少交通事故及提升车辆通行效率,其实现依赖准确的对交通参与者运动趋势的预测,而驾驶意图识别是其研究重点之一<sup>[1]</sup>。

驾驶员意图识别本质是分类问题,一般可分为向左换道、车道保持和向右换道。当前驾驶意图识别的研究主要分为两大类:基于模型与基于学习的方法。基于模型的方法通常是根据车辆运动学模型建立辨识规则模型来识别车辆驾驶行为;基于学习的方法通过选取车辆轨迹等特征建立数据集,将意图识别任务建模为基于学习的分类问题。

(1)基于模型的方法:Houenou等<sup>[2]</sup>通过对车辆历史轨迹与车道中心线曲率的相似性来检测驾驶意图。谢枫等<sup>[3]</sup>根据感知获得的障碍物信息,结合高精地图提供的车道线信息,来识别车辆行为。Tsogas等<sup>[4]</sup>融合多源数据,基于证据推理(Dempster-shafer theory, D-S)来识别驾驶意图。基于模型的方法场景鲁棒性较差,准确率较低等特点限制了其应用的推广。

(2)基于学习的方法:Wang等<sup>[5]</sup>通过融合车辆运行参数、环境信息和驾驶员视觉特征,在不同情绪下使用支持向量机(Support vector machines, SVM)预测出加减速意图和换道意图。祝伶俐等<sup>[6]</sup>提取车辆状态信息,对数据进行归一化和主成分分析处理,最后通过SVM进行驾驶行为分类。Berndt等<sup>[7]</sup>基于车辆和环境信号,利用隐马尔可夫(Hidden Markov model, HMM)模型研究早期驾驶员意图推断。Liu等<sup>[8]</sup>基于非线性多项式回归(Nonlinear polynomial regression, NPR)和HMM,提出一种递归隐半马尔可夫模型的意图识别方法。刘志强等<sup>[9]</sup>融合SVM和HMM模型来进行意图识别。Fang等<sup>[10]</sup>采用深度神经网络(Deep neural network, DNN),融合目标车辆和周围车辆历史轨迹来进行换道意图识别。季学武等<sup>[11]</sup>基于长短时记忆网络(Long short-term memory, LSTM)设计了换道意图识别模型,最后利用Softmax函数输出换道概率。Chandra

等<sup>[12]</sup>基于LSTM预测城市交通场景中的加速、减速等行为。赵健等<sup>[13]</sup>使用双向长短时记忆网络进行换道意图识别。赵建东等<sup>[14]</sup>采用一种基于卷积神经(Convolutional neural network, CNN)与门控循环神经网络(Gated recurrent unit neural network, GRU)并融合注意力机制的换道识别模型,识别准确率较高,但模型复杂导致迭代时间较长。Guo等<sup>[15]</sup>采用Transformer编码器加池化层进行换道意图预测。Zhang等<sup>[16]</sup>先采用特征工程对输入数据进行处理,然后通过XGBoost实现对换道意图的分类。

虽然上述方法在驾驶意图识别上取得了一定的成果,但仍存在以下问题:①在特征提取方面,难以获取高质量且有效的特征;②车辆驾驶意图标注于连续的历史轨迹上,若将准确的未来轨迹特征融入识别模型,则能有效提升识别准确率。当前方法均仅从历史轨迹中挖掘,尚未考虑未来轨迹。

高速公路驾驶意图识别场景中,智能网联车被视为自车,并通过与道路基础设施(如摄像头)的通信来获取目标车辆和周围车辆的轨迹数据,自车利用这些数据来识别目标车辆驾驶意图。本文针对智能网联车周围车辆驾驶意图识别问题,提出了一种基于轨迹预测和极限梯度提升的驾驶意图识别算法。主要贡献如下:

(1)基于轨迹预测的特征提取:将目标车辆的历史轨迹数据、周围车辆的历史轨迹数据与环境信息整合作为模型的输入,采用混合示教长短时神经网络(Mixed teacher force long short-term memory, MTF-LSTM)提取车辆未来轨迹特征。

(2)基于极限梯度提升算法(Extreme gradient boosting, XGBoost)的驾驶意图识别:通过XGBoost融合历史和未来轨迹综合识别驾驶意图,并对比分析了不同轨迹长度对预测精度的影响,以获得识别准确率最高的模型。

## 1 模型描述

### 1.1 整体描述

本文提出的驾驶意图识别框架由基于混合示教长短时神经网络的轨迹预测模块(简称LSTM

模块)和基于极限梯度提升算法的驾驶意图识别模块(简称 XGBoost 模块)组成,如图 1 所示。LSTM 模块通过 LSTM 编码解码网络构建轨迹预测模块,将目标车辆、周围车辆的历史轨迹及道路信息作为输入,输出未来的轨迹。

将模型输入设为  $T_h$ ,则 LSTM 模块输出  $T_p$  为:

$$T_p = f_{\text{LSTM}}(T_h) \quad (1)$$

驾驶意图识别模块基于 XGBoost 算法构建。将历史轨迹信息  $T_h$  与预测的输出  $T_p$  相结合,构成

新的向量。XGBoost 模块结合轨迹预测的结果,识别车辆驾驶意图  $D$ ,将其编码为左换道(0)、车道保持(1)、右换道(2)。

$$D = f_{\text{XGBoost}}\left(\left[T_h, T_p\right]\right) \quad (2)$$

## 1.2 轨迹预测模块

轨迹预测采用混合示教 LSTM 编码器-解码器模型,图 1 所示为轨迹预测模块。模型输入为历史轨迹等特征信息  $X = [x^{(1)}, x^{(2)}, \dots, x^{(\tau-1)}, x^{(\tau)}]$ ,其中,  $x$  为特征向量,  $\tau$  为历史轨迹长度。

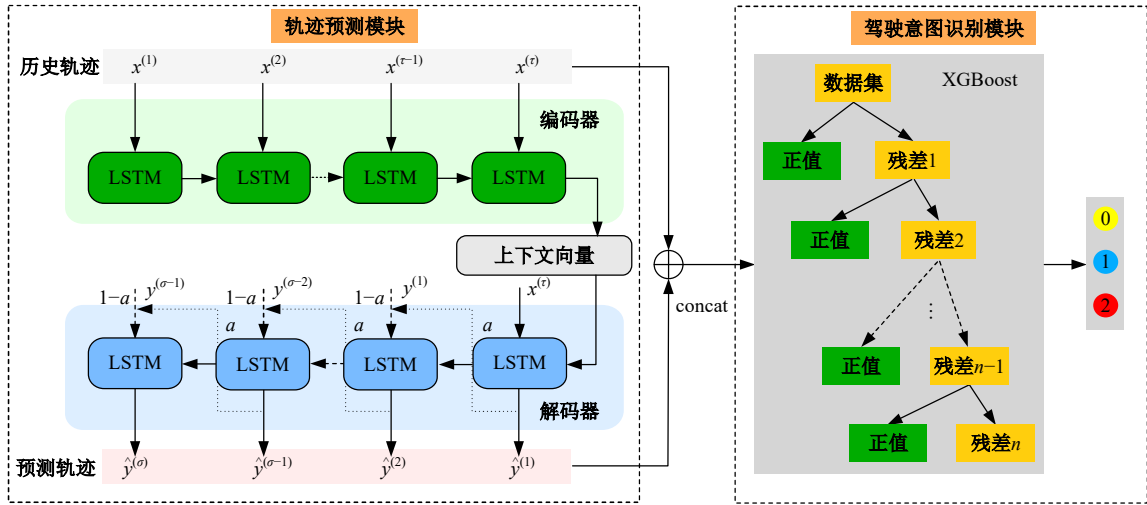


图 1 驾驶意图模型整体框架

Fig. 1 Overall framework of the driving intention recognition model

编码器将输入编码为上下文向量,解码器采用混合示教的方式,以  $\alpha$  的概率采用示教解码,以  $1 - \alpha$  的概率采用递归解码的模式,动态解码为未来轨迹  $Y = [y^{(1)}, y^{(2)}, \dots, y^{(\sigma-1)}, y^{(\sigma)}]$ ,其中,  $y$  为输出特征向量,  $\sigma$  为预测轨迹长度。

## 1.3 驾驶意图识别模块

如图 1 所示,驾驶意图识别模块基于极限梯度提升<sup>[17]</sup>算法构建,模型通过在数据中构建多个弱评估器,集成为强评估器,以获取比单个模型更好的回归和分类效果。其原理是通过不断迭代、生成新的树分类器来拟合当前模型的残差,驾驶意图识别模型建立步骤如下。

对于给定意图识别数据集  $D = \{(x_i, y_i)\}$ ,式中  $x_i$  为轨迹等特征信息,  $y_i$  为意图标签。模型的预测输出如下:

$$\hat{y}_i = \sum_{f=1}^K f_i(x_i), f_i \in F \quad (3)$$

式中:  $\hat{y}_i$  为模型预测值;  $K$  为总分类树的数量;  $f_i$  为单一分类树结构向量;  $F$  为所有树的集合。模型迭代如式(4)所示,从常数预测开始,每步迭代是

在原有模型的基础上加入新的分类树,用新的树函数去拟合上一迭代步结果的残差,以此不断改善意图识别结果。

$$\begin{cases} \hat{y}_i^{(0)} = 0 \\ \hat{y}_i^{(1)} = f_1(x_i) = \hat{y}_i^{(0)} + f_1(x_i) \\ \vdots \\ \hat{y}_i^{(t)} = \sum_{f=1}^K f_i(x_i) = \hat{y}_i^{(t-1)} + f_t(x_i) \end{cases} \quad (4)$$

本文设计的目标函数如下:

$$X_{\text{obj}} = \sum_{i=1}^n l(y, \hat{y}) + \sum_{k=1}^K \Omega(f_k) \quad (5)$$

$$\Omega(f_k) = \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 \quad (6)$$

式(5)第一项为预测意图类别与真实意图类别之间的惩罚项;第二项为正则项,用于平滑各叶子结点权重。式(6)中,  $\gamma, \lambda$  为控制模型复杂度的超参数;  $T$  为叶子结点的个数;  $\omega$  为叶结点的分数。模型采用加法训练方式来最小化目标函数。每步迭代更新目标函数为:

$$\tau^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}_i^{(t-1)} + f_t(x_i)) + \Omega(f_t) \quad (7)$$

将式(7)在 $f_i=0$ 处进行泰勒二阶展开,则可近似为:

$$\tau^{(t)} \simeq \sum_{i=1}^n \left[ l(y_i, \hat{y}_i^{(t-1)}) + g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \Omega(f_i) \quad (8)$$

$$g_i = \partial_{y_i^{(t-1)}} l(y_i, \hat{y}_i^{(t-1)}) \quad (9)$$

$$h_i = \partial_{y_i^{(t-1)}}^2 l(y_i, \hat{y}_i^{(t-1)}) \quad (10)$$

式中: $g_i$ 和 $h_i$ 分别为损失函数的一阶和二阶梯度。

移除常数项,简化目标函数为:

$$\tilde{\tau}^{(t)} = \sum_{i=1}^n \left[ g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \Omega(f_i) \quad (11)$$

将叶子结点 $j$ 中的样本编号集合定义如下:

$$I_j = \{i | q(x_i) = j\} \quad (12)$$

式中: $q(x_i)$ 为 $x_i$ 对应的叶子标签值。

综合式(6)(11)和(12)可得目标函数为:

$$\begin{aligned} \tilde{\tau}^{(t)} = & \sum_{i=1}^n \left[ g_i f_i(x_i) + \frac{1}{2} h_i f_i^2(x_i) \right] + \gamma T + \frac{1}{2} \lambda \sum_{j=1}^T \omega_j^2 = \\ & \sum_{j=1}^T \left[ \left( \sum_{i \in I_j} g_i \right) \omega_j + \frac{1}{2} \left( \sum_{i \in I_j} h_i + \lambda \right) \omega_j^2 \right] + \gamma T \quad (13) \end{aligned}$$

根据式(13)求解得最优叶子结点分数和目标函数值如下:

$$\omega_j^* = -\frac{G_j}{H_j + \lambda} \quad (14)$$

$$\tau_j^* = -\frac{1}{2} \sum_{i \in I_j} \frac{G_j}{H_j + \lambda} + \lambda T \quad (15)$$

式中: $G_j = \sum_{i \in I_j} g_i$ ,  $H_j = \sum_{i \in I_j} h_i$ 。模型训练过程中采用贪心算法选择增益最大的叶子结点。

## 2 数据预处理

本文采用的公开数据集源于美国联邦公路局开展的下一代道路仿真(Next Generation SIMulation, NGSIM)中US101和I-80路段,数据通过摄像头采集,采用鸟瞰视角。数据采集频率为10 Hz,包含多维特征,所关注的特征如表1所示。相对基于美国道路数据集NGSIM,基于中国道路数据由于在道路标识、交通规则、车速限制以及超车规则等方面存在差异,从而在换道行为的表现上呈现出不同的特征。针对这种情况,为了实现准确的驾驶意图识别,在不同场景中,可通过对相应场景的离线学习来改进模型性能。这种方法可以使模型更好地适应中国道路环境的特点,提高驾

表1 NGSIM原始数据

Table 1 Raw data of NGSIM

编号	特征名	特征描述	单位
1	Vehicle_ID	车辆编号	—
2	Frame_ID	帧数编号	—
3	Total_Frames	车辆在数据集中总帧数	—
4	Global_Time	全局时间(毫秒数)	ms
5	Local_X	横向相对位移	feet
6	Local_Y	纵向相对位移	feet
7	Lane_ID	车道编号	—

驶意图识别的质量与准确性。

### 2.1 特征筛选

在实际交通场景中,换道意图是环境信息、周围车辆信息及目标车辆状态等因素共同作用的结果。本文提出的换道意图识别模型的输入融合了目标车辆和周围车辆的历史轨迹特性及道路信息,将输入数据分为目标车辆特征(Target vehicle feature, TVF)、周围车辆特征(Surrounding vehicle feature, SVF)与道路环境特征(Road feature, RF),详细信息如表2所示。

关于周围车辆的选取准则,常见的有3种方法:①与目标车辆距离最近的3辆车<sup>[18,19]</sup>;②目标车辆所在车辆及相邻两车道前后6辆车<sup>[3,9,11]</sup>;③与②相同条件下的前后9辆车<sup>[20]</sup>。本文采用方法②,以目标车辆纵向位移的前后100 m内,如图2所示。

由于特定位置 $i$ 的周围车辆可能缺失,此时将其特征设置为:

$$\begin{cases} \Delta x^i = \text{sgn}[-1 + (i-1) // 2] d \\ \Delta y^i = (-1)^{i+1} \infty \\ v_x^i = v_x \\ v_y^i = v_y \\ a_x^i = a_x \\ a_y^i = a_y \end{cases} \quad (16)$$

式中:sgn为符号函数;//为地板除; $d$ 为车道宽度; $v_x$ 、 $v_y$ 、 $a_x$ 和 $a_y$ 分别为目标车辆的横向速度、纵向速度、横向加速度和纵向加速度。

### 2.2 轨迹滤波

鉴于NGSIM数据集在采集过程中存在一定误差,尤其是横向速度误差明显,因此,需要对其进行平滑处理<sup>[21]</sup>。本文采用小波分解来进行轨迹滤波。

$$V_{\text{lat}} = A_n + D_1 + D_2 + \dots + D_n \quad (17)$$

式中: $D_n$ 和 $A_n$ 分别为第 $n$ 次分解所得的高频和低

表 2 模型输入特征描述  
Table 2 Description of model input feature

组别	参数	特征描述	数量
TVF	$x_t, y_t$	目标车辆的横向和纵向位移	2
	$vx_t, vy_t$	目标车辆的横向和纵向速度,通过相邻轨迹点之间的位移可得: $vx_t = 10(x_{t+1} - x_t), vy_t = 10(y_{t+1} - y_t)$	2
	$ax_t, ay_t$	目标车辆的横向和纵向加速度,通过相邻轨迹点之间的速度可得: $ax_t = 10(vx_{t+1} - vx_t), ay_t = 10(vy_{t+1} - vy_t)$	2
SVF	$\Delta x_i^i, \Delta y_i^i$	周围车辆 $i$ 相对于目标车辆的横向与纵向位移,由公式可得: $\Delta x_i^i = x_i^i - x_t, \Delta y_i^i = y_i^i - y_t$	12
	$wx_i^i, vy_i^i$	周围车辆 $i$ 的横向与纵向绝对速度,通过其位移可得: $wx_i^i = 10(x_{t+1}^i - x_t^i), vy_i^i = 10(y_{t+1}^i - y_t^i)$	12
	$ax_i^i, ay_i^i$	周围车辆 $i$ 的横向与纵向加速度,通过其速度可得: $ax_i^i = 10(wx_{t+1}^i - wx_t^i), ay_i^i = 10(vy_{t+1}^i - vy_t^i)$	12
RF	$R_l, R_r$	$R_l, R_r$ 表示目标车辆左右车道标识位,如果其存在置为 1,否则为 0	2




图 2 周围车辆示意图

Fig. 2 Picture of surrounding vehicles

频信号,本文采用  $n = 5$ ,滤波函数为 sym11。

先通过横向位置和时间得到横向速度,然后将横向速度分解为  $n$  层,接着将  $D_1, D_2, \dots, D_{n-1}$  置为 0,最后重构信号完成滤波,滤波前后对比示例如图 3 所示。

2.3 换道数据标注

NGSIM 原始数据集中未提供车辆驾驶意图




图 3 NGSIM 轨迹滤波前后对比示意图

Fig. 3 Diagram of comparison NGSIM trajectory filtering

标签,故需要先给轨迹数据进行驾驶意图标注,换道标注如图 4、图 5 所示。标注步骤如下:

(1) 首先根据车辆所处车道变化筛选出所有换道车辆编号。

(2) 将车道变化的临界点作为换道点,如图 5 中车辆轨迹与车道边界线之间的交点所示。

(3) NGSIM 原始数据库无航向角,这里根据相邻轨迹点之间的位置来计算  $\theta = \arctan \frac{x_1 - x_0}{y_1 - y_0}$ 。

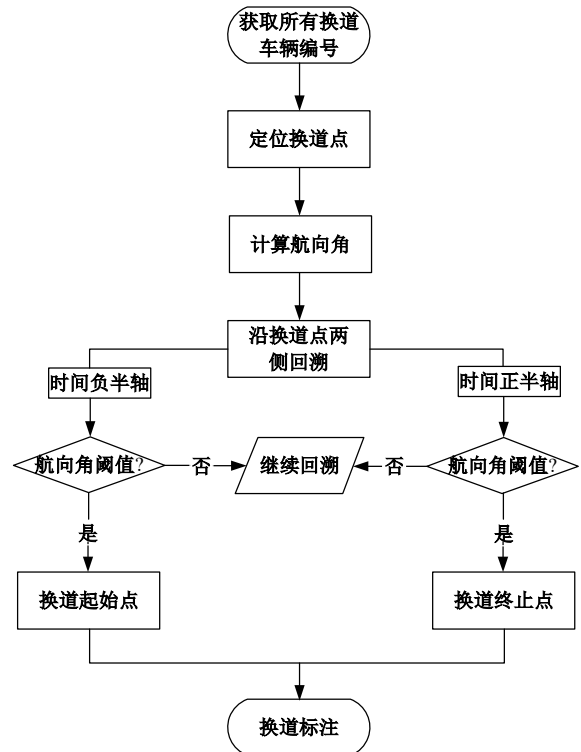


图 4 换道意图标注流程图

Fig. 4 Flow of lane change intention labeling




图 5 换道意图标注示意图

Fig. 5 Picture of lane change intention labeling

(4) 沿着换道点两侧回溯,以航向角为指标。沿着时间负半轴回溯,若连续 3 个相邻轨迹点的航向角满足  $|\theta| < \theta_{\text{Threshold}}$ , 则最后满足的点为换道起始点,同理沿着时间正半轴的为换道终止点。

(5) 将换道起始点与换道终止点之间的轨迹点标注为右换道(2),同理标注为左换道(0),剩余的轨迹点标注为车道保持(1)。

### 2.4 轨迹序列提取

本文采用滑动窗口法来提取轨迹序列集合。选取轨迹序列长度为 80,滑动窗口长度为 1。将轨迹子序列 5 s 处的换道标签作为整个序列换道意图,最终得到的轨迹序列数如表 3 所示。由表 3 可知,车道保持的数据占据绝大多数,远大于左换道与右换道的数据量,左换道数据量次之,右换道数据量最少。为保证用于训练和测试数据的均匀性,本文保留全部右换道数据,随机选取相同数量的左换道与车道保持数据最终组成整个数据集,数据如表 4 所示。

表 3 换道序列提取结果

Table 3 Result of lane change sequence extraction

标签	左换道	车道保持	右换道
数据	149 215	1 205 655	38 829

表 4 换道序列选取结果

Table 4 Result of lane change selection extraction

标签	左换道	车道保持	右换道
数据	38 829	38 829	38 829

## 3 模型验证

### 3.1 轨迹预测模块性能分析

轨迹预测模块的性能影响整体驾驶意图识别的准确性,将本文 MTF-LSTM 模型与融合注意力机制的 LSTM 模型(MHA-LSTM)<sup>[21]</sup>进行对比,以均方根误差(Root mean square error, RMSE)为指标来衡量轨迹预测的准确性。

实验在 NVIDIA GeForce RTX 3090 GPU 上

进行,轨迹预测代码在深度学习框架 PyTorch 下实现。训练迭代次数为 100,批次为 1 024,损失函数为均方误差(Mean square error, MSE),优化器为 Adam,学习率为 0.001,权重衰减为 0.000 1。编码器与解码器的 LSTM 模块结构相似,层数均为 4 层,隐藏层为 128,dropout 为 0.2。本文采用 5 s 历史轨迹预测 3 s 未来轨迹,结果如表 5 所示。

由表 5 可知,MHA-LSTM 模型在短时预测( $< 1$  s)精度略占优,随着预测时域增大,误差逐渐增大。而 MTF-LSTM 在 3 s 内的均方误差均处于较低水平,说明其具有良好的轨迹预测性能。

### 3.2 整体模型性能分析

模型输入与轨迹预测输出结合所得的数据集  $D = \{(x_i, y_i)\}$ 。其中  $x_i$  为特征数据,形状为  $(n, m, 44)$ ;  $y_i$  为换道标签,  $n$  为样本数,  $m$  为轨迹长度。

根据 XGBoost 算法对数据输入的要求,需进行展开,如图 6 所示。将每组按照 8:2 的比例划分为训练集和测试集,通过在训练集上的 5 折交叉验证来评价模型。通过网格搜索,确定超参数:弱分类器的数量为 110,学习率为 0.2,叶子结点分裂增益阈值为 1,弱分类器最大树深度为 6,采

表 5 轨迹预测性能评估

Table 5 Performance evaluation of trajectory prediction

模型	未来轨迹/s		
	1	2	3
MHA-LSTM	0.41	1.01	1.74
MTF-LSTM	0.48	0.89	1.47




图 6 特征数据展开图

Fig. 6 Picture of feature data expansion

样比例为 1。

为了验证不同历史和预测轨迹长度对驾驶意图的影响,通过网格搜索,以准确率(Accuracy)为指标来获取最佳的模型,结果如表 6 所示。

由表 6 可知,随着历史轨迹和预测轨迹长度的增加,准确率均呈现上升趋势,且上升速率逐渐趋缓。综合计算量和准确率,在历史轨迹长度为 4 s、预测轨迹长度为 3 s 处准确率最高且计算量相对较小。

为了更好地验证本文模型的性能,本文采用精确率(Precision)、召回率(Recall)、 $F_1$ -Score 和准确率等指标,与 3 种基于 XGBoost 的模型进行比较。3 种模型如下:

(1) XGBoost 模型:原始数据直接输入 XGBoost 算法。

(2) S-XGBoost 模型<sup>[16]</sup>:原始数据先经过特征工程后,然后输入 XGBoost 算法。

(3) LSTM-XGBoost 模型:本文提出的融合 LSTM 轨迹预测的 XGBoost 算法。

模型对比结果如表 7 所示,本文提出的

表 6 不同长度轨迹模型性能

Table 6 Performance of different length of trajectory

历史轨迹长度/s	预测轨迹长度/s		
	1	2	3
1	0.961	0.966	0.969
2	0.965	0.970	0.972
3	0.968	0.972	0.975
4	0.971	0.974	0.977
5	0.971	0.973	0.977

表 7 不同模型意图识别性能

Table 7 Performance of different model in driving intention recognition

指标	模型	驾驶意图		
		左换道	车道保持	右换道
精确率	XGBoost	0.973	0.960	0.975
	S-XGBoost	0.950	0.963	0.948
	LSTM-XGBoost	0.984	0.965	0.983
召回率	XGBoost	0.971	0.959	0.978
	S-XGBoost	0.953	0.943	0.963
	LSTM-XGBoost	0.976	0.976	0.980
$F_1$ Score	XGBoost	0.972	0.959	0.977
	S-XGBoost	0.952	0.953	0.955
	LSTM-XGBoost	0.980	0.971	0.981
准确率	XGBoost	0.969		
	S-XGBoost	0.953		
	LSTM-XGBoost	0.977		

LSTM-XGBoost 模型在精确率、召回率、 $F_1$ -Score 和准确率等指标上全面领先 XGBoost 模型和 S-XGBoost 模型,表现出良好的驾驶意图识别能力。此外,LSTM-XGBoost 模型左换道(0.984)和右换道(0.983)的精确率均明显高于车道保持(0.965),分析可能是左、右换道数据特征相较于车道保持更为明显,故其两类相互识别的可能性低;而车道保持数据特征介于两者之间,识别为其他两类的可能性相同。

## 4 结束语

本文提出一种基于轨迹预测与极限梯度提升算法的周围车辆驾驶意图识别模型,能够识别出车辆左换道、车道保持和右换道的驾驶意图。模型输入为目标车辆与周围车辆的历史轨迹信息及道路环境,采用混合示教长短时神经网络来预测未来轨迹,XGBoost 模块融合历史和未来轨迹识别驾驶意图。采用实际道路数据集进行模型验证,多组对比分析实验结果表明,本文所提方法在精确率、召回率、 $F_1$ -Score 和准确率上具有优越性,平均准确率达 97.7%。

对于驾驶意图识别任务,未来将采用更高效的特征提取方法来更换本文中的 LSTM 模块,例如基于注意力机制的 Transformer,进一步提高识别的准确率。

## 参考文献:

- [1] Xing Y, Lyu C, Wang H, et al. Driver lane change intention inference for intelligent vehicles: framework, survey, and challenges[J]. IEEE Transactions on Vehicular Technology, 2019, 68(5): 4377-4390.
- [2] Houenou A, Bonnifait P, Cherfaoui V, et al. Vehicle trajectory prediction based on motion model and maneuver recognition[C]// IEEE/RSJ International Conference on Intelligent Robots and Systems, Tokyo, Japan, 2013: 4363-4369.
- [3] 谢枫, 娄静涛, 赵凯, 等. 基于行为识别和曲率约束的车辆轨迹预测方法研究[J]. 汽车工程, 2019, 41(9): 1036-1042.  
Xie Feng, Lou Jing-tao, Zhao Kai, et al. A research on vehicle trajectory prediction method based on behavior recognition and curvature constraints[J]. Automotive Engineering, 2019, 41(9): 1036-1042.
- [4] Tsogas M, Polychronopoulos A, Floudas N, et al. Situation refinement for vehicle maneuver identification and driver's intention prediction[C]// 10th Interna-

- tional Conference on Information Fusion, Quebec City, Canada, 2007: No. 4408203.
- [5] Wang X, Guo Y, Bai C, et al. Driver's intention identification with the involvement of emotional factors in two-lane roads[J]. IEEE Transactions on Intelligent Transportation Systems, 2020, 22(11): 6866-6874.
- [6] 祝伶俐, 刘澜, 赵新朋, 等. 基于支持向量机的车辆驾驶行为识别研究[J]. 交通运输系统工程与信息, 2017, 17(1): 91-97.
- Zhu Li-ling, Liu Lan, Zhao Xin-peng, et al. Driver behavior recognition based on support vector machine [J]. Journal of Transportation Systems Engineering and Information Technology, 2017, 17(1): 91-97.
- [7] Berndt H, Emmert J, Dietmayer K. Continuous driver intention recognition with hidden markov models[C]// 11th International IEEE Conference on Intelligent Transportation Systems, Beijing, China, 2008: 1189-1194.
- [8] Liu Q, Xu S, Lu C, et al. Early recognition of driving intention for lane change based on recurrent hidden semi-Markov model[J]. IEEE Transactions on Vehicular Technology, 2020, 69(10): 10545-10557.
- [9] 刘志强, 吴雪刚, 倪捷, 等. 基于HMM和SVM级联算法的驾驶意图识别[J]. 汽车工程, 2018, 40(7): 858-864.
- Liu Zhi-qiang, Wu Xue-gang, Ni Jie, et al. Driving intention recognition based on hmm and svm cascade algorithm[J]. Automotive Engineering, 2018, 40(7): 858-864.
- [10] Fang H, Liu L, Gu Q, et al. Driving intention recognition of human drivers in mixed traffic flow[C]// IEEE 25th International Conference on Intelligent Transportation Systems, Macao, China, 2022: 153-157.
- [11] 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.
- [12] Chandra R, Guan T, Panuganti S, et al. Forecasting trajectory and behavior of road-agents using spectral clustering in graph-lstms[J]. IEEE Robotics and Automation Letters, 2020, 5(3): 4882-4890.
- [13] 赵健, 宋东鉴, 朱冰, 等. 数据机理混合驱动的交通车意图识别方法[J]. 汽车工程, 2022, 44(7): 997-1008.
- Zhao Jian, Song Dong-jian, Zhu Bing, et al. Traffic vehicles intention recognition method driven by data and mechanism hybrid[J]. Automotive Engineering, 2022, 44(7): 997-1008.
- [14] 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.
- [15] Guo H, Keyvan E M, Xie K. Lane change detection and prediction using real-world connected vehicle data [J]. Transportation Research Part C: Emerging Technologies, 2022, 142: No. 103785.
- [16] 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.
- [17] Chen T, Guestrin C. Xgboost: a scalable tree boosting system[C]// 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining, San Francisco, USA, 2016: 785-794.
- [18] Hu Y, Zhan W, Tomizuka M. Probabilistic prediction of vehicle semantic intention and motion[C]// IEEE Intelligent Vehicles Symposium (IV), Suzhou, China, 2018: 307-313.
- [19] Ding W, Chen J, Shen S. Predicting vehicle behaviors over an extended horizon using behavior interaction network[C]// International Conference on Robotics and Automation, Montreal, Canada, 2019: 8634-8640.
- [20] Altché F, Fortelle A. An LSTM network for highway trajectory prediction[C]// IEEE 20th International Conference on Intelligent Transportation Systems, Yokohama, Japan, 2017: 353-359.
- [21] 田彦涛, 黄兴, 卢辉迺, 等. 基于注意力与深度交互的周围车辆多模态行为轨迹预测[J]. 吉林大学学报: 工学版, 2023, 53(5): 1474-1480.
- Tian Yan-tao, Huang Xing, Lu Hui-qiu, et al. Vehicle multi-modal maneuvers and trajectory prediction based on attention mechanism with deep interaction [J]. Journal of Jilin University(Engineering and Technology Edition), 2023, 53(5): 1474-1480.