

赵盛, 王嘉文, 王明炯, 等. 基于 FCNN 神经网络的多驾驶风格车辆换道预测[J]. 智能计算机与应用, 2024, 14(5): 199-204.
DOI: 10.20169/j.issn.2095-2163.240527

基于 FCNN 神经网络的多驾驶风格车辆换道预测

赵盛¹, 王嘉文¹, 王明炯², 魏来²

(1 上海理工大学 管理学院, 上海 200093; 2 上海市城市建设设计研究总院(集团)有限公司, 上海 200125)

摘要: 在未来复杂的智能交通环境中, 自动驾驶车辆与人类驾驶车辆混合共享道路成为可能。在这种混合交通流的背景下, 准确预测人类车辆的换道行为对于自动驾驶系统的安全性和效率至关重要。本研究针对车辆换道的主要影响因素—周围环境和驾驶风格, 提出了一种基于 FCNN 神经网络的人工车辆多驾驶风格换道决策预测方法。首先, 通过应用 K 均值聚类算法对驾驶员的驾驶风格进行分类, 从而综合考虑驾驶风格的差异。然后, 将分类结果作为 FCNN 神经网络的输入变量, 用于预测人类车辆的换道行为。该方法基于真实车辆轨迹构建的下一代仿真数据集进行训练和测试, 并取得了 91.80% 的准确率。实验结果表明, 通过结合驾驶风格分类和 FCNN 神经网络, 能够更准确地预测人类车辆在不同驾驶风格下的换道行为。本研究的成果对于混合交通流下自动驾驶车辆预测人类车辆的换道行为具有重要的实际应用价值, 并为未来进一步改进和拓展提供了新的思路。

关键词: 智能交通; 换道预测; K 均值聚类算法; FCNN; 智能车辆; 驾驶风格

中图分类号: U491.2+55 文献标志码: A 文章编号: 2095-2163(2024)05-0199-06

Prediction of lane changing with multiple driving styles for intelligent vehicles based on FCNN neural network

ZHAO Sheng¹, WANG Jiawen¹, WANG Mingjiong², WEI Lai²

(1 Business School, University of Shanghai for Science and Technology, Shanghai 200093, China;
2 Shanghai Urban Construction Design Research Institute(Group) Co., Ltd., Shanghai 200125, China)

Abstract: In the future complex intelligent traffic environment, the coexistence of autonomous vehicles and human-driven vehicles on the road becomes a possibility. In the context of this mixed traffic flow, accurately predicting the lane-changing behavior of human-driven vehicles is crucial for the safety and efficiency of autonomous driving systems. This study proposes a prediction method for lane-changing decisions of human-driven vehicles with multiple driving styles, based on the FCNN (Fully Convolutional Neural Network), focusing on the key factors of lane-changing: the surrounding environment and driving styles. Firstly, by applying the K-means clustering algorithm to classify driving styles of drivers, the variations in driving styles are comprehensively considered. Subsequently, the classified results are utilized as input variables for the FCNN neural network to predict the lane-changing behavior of human-driven vehicles. The method is trained and tested on a next-generation simulation dataset constructed from real vehicle trajectories, achieving an accuracy rate of 91.80%. Experimental results demonstrate that by combining driving style classification and FCNN neural network, it is possible to more accurately predict the lane-changing behavior of human-driven vehicles under different driving styles. The findings of this research is of significant practical value for predicting the lane-changing behavior of human-driven vehicles in the context of mixed traffic flow with autonomous vehicles. Additionally, it provides new insights for future improvement and expansion of this approach.

Key words: intelligent traffic; lane change prediction; K-means clustering algorithm; FCNN; intelligent vehicles; driving styles

0 引言

当前, 智能车辆换道行为的预测是备受关注的研究领域。随着自动驾驶技术的快速发展, 未来将

出现自动驾驶车辆与传统人工驾驶车辆混合共享道路的交通场景。在这种背景下, 能够准确预测人工车辆的换道行为对于自动驾驶系统的安全性和效率至关重要^[1]。

作者简介: 赵盛(1996-), 男, 硕士研究生, 主要研究方向: 智能车辆预测和决策的优化方法; 王嘉文(1989-), 男, 副教授, 硕士生导师, 主要研究方向: 交通控制与管理, 交通系统设计, 智能交通系统。

收稿日期: 2023-08-24

通过精准地预测车辆的换道行为,自动驾驶车辆可以提前识别驾驶人的意图,并为自身做出更精准的交通行为预测信息^[2]。这样的交通行为预测信息可以帮助自动驾驶系统做出更合理的路径规划、速度调整以及与其他车辆的协同等,从而有效降低交通事故风险,提高自动驾驶的安全性。同时,精准的交通行为预测也可以优化交通流的平滑性和效率,避免突然的车道变更,减少交通拥堵和交通冲突,提高道路的通行效率和舒适性^[3]。

近年来,国内外学者对车辆换道预测做了大量研究,目前换道预测模型主要是基于机器学习和深度学习的模型^[4]。陈力等学者^[5]提出了基于BP神经网络的智能车辆换道决策模型,可以正确识别和预测智能车辆的变道行为。李振等学者^[6]提出了一种换道概率累积分布函数的车辆换道行为预测方法。密俊霞等学者^[7]提出了基于MLP-SVM的模型,通过驾驶车辆信息和周围交通环境信息建立驾驶员换道行为预测模型,能更早预测到换道行为。Feng等学者提出对车辆实际变道过程进行识别建模和车辆横向运动轨迹预测分析,提取变道相关变量数据;然后,提出一种基于网格搜索-PSO的变道识别模型^[8]。高凯等学者^[9]首先对NGSIM数据集进行处理,提取车辆横向位置信息和周围环境信息,然后输入基于多头注意力(Multi-headattention)的CNN-LSTM模型,提高对输入序列特征的提取能力和预测精度。Wang等学者^[10]提出一种结合模糊推理系统的LSTM神经网络预测模型,使用FIS模拟驾驶员对驾驶环境的认知过程,根据驾驶员的认知制定模糊规则,然后将驾驶环境信息转化为变道可行性,该策略可以显著提高驾驶过程中在处理变道行为方面的性能。Xiang等学者^[11]提出一个基于隐马尔可夫模型(HMM)的系统,根据车辆周围的行驶环境参数判断当前环境是否适合变道;然后根据车辆的行驶状态,提出一种基于学习的先预测后判断模型,实现对智能网联汽车变道行为的预测。

然而,目前研究尽管已取得一定成果,由于未来混合交通场景的复杂性,传统模型在未来复杂的混合交通场景中可能受到一定限制。许多现有的换道预测模型仅仅考虑车辆的基础参数,未能充分考虑不同驾驶员的驾驶风格对换道决策的影响,可能对换道预测模型的准确性产生影响^[12]。

因此,本研究提出了一种全新的、基于FCNN神经网络的换道预测模型,旨在充分考虑驾驶风格对车辆换道行为的影响^[13]。研究中利用驾驶员的驾

驶风格分类结果作为模型的额外的特征输入变量,并结合自车和周围车辆的特征信息,通过训练和优化FCNN网络,构建了一种准确预测车辆换道行为的模型,从而提高预测的准确性和适用性。为了验证模型的准确性和泛化能力,研究使用NGSIM数据集进行训练和验证。

1 研究对象

为了清晰地描述复杂场景下车辆的行为,需要构建经典的换道场景。在这个场景中,自动驾驶车辆(AV)是本文需要预测主要车辆的目标车辆,其周围的车辆(SV)可以大致分为6类。研究表明,车辆的换道行为涉及到周围多台车辆的相互影响^[14]。驾驶员通常通过评估周围车辆的相对距离、相对速度等因素来判断换道的可行性,如图1所示,其中车辆的参数及解释见表1。




图1 换道场景

Fig. 1 Lane change scenarios

表1 换道场景参数解释

Table 1 Explanation of lane change scenarios parameters

参数	解释
AC	进行换道预测的主车
LF/LB	主车左边车道的前车和后车
MB/MF	主车自身车道的前车和后车
RB/RF	主车右边车道的前车和后车
$D_{LB}/V_{LB}/A_{LB}$	左后车和主车的相对距离、速度、加速度
$D_{LF}/V_{LF}/A_{LF}$	左前车和主车的相对距离、速度、加速度
$D_{MB}/V_{MB}/A_{MB}$	后车和主车的相对距离、速度、加速度
$D_{MF}/V_{MF}/A_{MF}$	前车和主车的相对距离、速度、加速度
$D_{RB}/V_{RB}/A_{RB}$	右后车和主车的相对距离、速度、加速度
$D_{RF}/V_{RF}/A_{RF}$	右前车和主车的相对距离、速度、加速度

在这种情况下,驾驶员的不同驾驶风格对于建立准确的换道行为预测模型至关重要。考虑到驾驶员的驾驶风格可以更好地预测换道行为,并且驾驶风格与驾驶员的行为以及车辆周围环境相关。驾驶风格的分类可以基于前车距离、自车速度、自车加速度以及前车相对速度、相对加速度等因素,因此在本

文中,采用了K均值聚类算法对驾驶风格进行分类^[15]。通过对驾驶风格的精确分类,就能更准确地预测车辆的换道行为,并考虑到驾驶员的个体差异和行为习惯。

综上所述,建立一个能够考虑驾驶风格的车辆换道行为预测模型对于提高驾驶辅助系统的性能具有重要意义。因此,首先需要对驾驶风格进行分类,然后将驾驶风格作为输入变量与FCNN网络模型相结合,凭此来建立车辆换道预测模型。接下来,本文将详细介绍驾驶风格分类方法和基于FCNN网络的换道预测模型的建立过程,并使用NGSIM数据集进行实验和验证,以验证模型的准确性和泛化能力。

2 换道预测模型

2.1 驾驶风格分类

驾驶风格 ds 是指驾驶员在行驶过程中表现出的个体差异和行为习惯。在车辆换道行为的预测中,驾驶员的驾驶风格对于准确预测换道行为至关重要。驾驶风格与多个因素相关,包括前车距离、自车速度、自车加速度、前车相对速度和相对加速度等^[16]。

为了对驾驶风格进行分类,本文采用了K均值聚类算法,并利用肘部法来确定最佳的簇数 k 。K均值聚类算法是一种迭代聚类算法,通过寻找 k 个簇的划分方案,使得聚类结果对应的损失函数最小化^[16]。

在驾驶风格分类中,将样本表示为具有多个特征的数据点,例如前车距离、自车速度、自车加速度等。具体而言,K均值聚类算法的步骤如下。

(1)初始化:随机选择 n 个样本作为初始簇中心点。

(2)分配:计算每个样本到各个簇中心点的距离,并将样本分配到距离最近的簇中心点所在的簇。

(3)更新:更新每个簇的中心点为该簇中所有样本的平均值。

(4)重复步骤(2)和步骤(3),直到簇中心点不再改变或达到预定的迭代次数。通过迭代计算,K均值聚类算法能够将样本划分为 k 个簇,每个簇代表一种驾驶风格。而每个样本的簇分配结果取决于其与簇中心点之间的距离,使得同一簇内的样本具有相似的驾驶风格特征。

为了确定最佳的簇数 k ,研究使用肘部法。肘部法基于损失函数的变化情况,通过计算不同簇数下的损失函数值(如 SSE),找到使损失函数值下降

速度放缓的拐点。该拐点对应的簇数可以被认为是最优的 k 值,这样一来就能够在保持较低的损失的同时避免过度拟合。这一过程可由式(1)来描述:

$$SSE = \sum_{i=1}^k \sum_{p \in C_i} |P - m_i|^2 \quad (1)$$

其中, k 表示簇数; C_i 表示第 i 个簇; P 表示 C_i 中的样本点; m_i 表示 C_i 的质心; SSE 是所有样本的聚类误差,代表了聚类效果的好坏。

综上所述,驾驶风格 ds 分类是通过K均值聚类算法对驾驶人的行为特征进行聚类,并利用肘部法确定最佳的簇数 k ,将驾驶风格 ds 分为 k 个不同的取值。这种分类方法能够为后续的换道行为预测提供基础,同时也充分考虑了驾驶员的个体差异。

2.2 FCNN换道预测模型构建

为了建立车辆换道行为预测模型,并结合驾驶风格的影响,文中采用了一个基于全连接神经网络(Fully Connected Neural Network,FCNN)的模型^[17]。该模型的输入是车辆换道的相关特征,包括与周围车辆的相对距离、相对速度和相对加速度、以及驾驶风格特征。输出层则表示车辆的换道意图,即向左换道或向右换道。这里将展开论述如下。

(1)输入层:车辆换道的相关特征, D_{LF} 为左前车和主车相对距离, V_{LF} 为左前车和主车相对速度, A_{LF} 为左前车和主车相对加速度; D_{MF} 为前车和主车相对距离, V_{MF} 为前车和主车相对速度, A_{MF} 为前车和主车相对加速度; D_{RF} 为右前车和主车相对距离, V_{RF} 为右前车和主车相对速度, A_{RF} 为右前车和主车相对加速度; D_{LB} 为左后车和主车相对距离, V_{LB} 为左后车和主车相对速度, A_{LB} 为左后车和主车相对加速度; D_{MB} 为后车和主车相对距离, V_{MB} 为后车和主车相对速度, A_{MB} 为后车和主车相对加速度; D_{RB} 为右后车和主车相对距离, V_{RB} 为右后车和主车相对速度, A_{RB} 为右后车和主车相对加速度;驾驶风格特征为 ds 。

第一层输入特征变量为:

$$X = [D_{LF}, V_{LF}, A_{LF}, D_{MF}, V_{MF}, A_{MF}, D_{RF}, V_{RF}, A_{RF}, D_{LB}, V_{LB}, A_{LB}, D_{MB}, V_{MB}, A_{MB}, D_{RB}, V_{RB}, A_{RB}, ds] \quad (2)$$

(2)隐含层:通过多个隐含层的组合,模型可以学习更抽象和高级的特征表示,从而更好地捕捉换道行为的关键信息。

(3)激活函数:选用 $ReLU$ 作为隐含层的激活函数。 $ReLU$ 函数在输入为正时保持线性,而在输入为负时输出为0,这样可以提供非线性建模的能力,有

助于模型学习更复杂的特征表示。

(4)输出层:输出层的激活函数选择为 *softmax* 函数,用于将输出转换为每个类别(向左换道 *L* 和向右换道 *R*) 的概率分布:

$$y = [L, R] \quad (3)$$

通过 *softmax* 函数,可以获得换道预测结果的概率分布,从而进行决策和规划。

3 实验方法与结果分析

3.1 训练数据提取

为了评估本文提出的换道预测方法的性能,研究使用了下一代模拟(NGSIM)数据集进行训练和测试。NGSIM 数据集提供了丰富的车辆轨迹数据,包括横向坐标、纵向坐标、速度、加速度以及车辆当前车道位置等信息。NGSIM 数据集涵盖了不同的交通流量和车速情况,从而确保了所提出方法的不同场景下的通用性^[18]。研究从该数据集中选取了 I-80 和 US-101 两条道路,提取了涉及不同换道行为的数据,其中有作为训练数据和测试数据的 I-80 道路、总共 1 396 个样本,作为验证模型泛化能力的 US-101 道路、总共 1 613 个样本。并分别对其进行分类和标准化处理。

3.2 驾驶风格分类

为了考虑驾驶员个体差异和行为习惯的影响,研究采用 K 均值聚类算法对换道数据进行驾驶风格的分类,聚类样本为:

$$x_i = (v, a, v_r, a_r) \quad (4)$$

其中, v 表示自车速度; a 表示自车加速度; v_r 表示和前车相对速度; a_r 表示和前车相对加速度。通过肘部法确定聚类簇数 k 的取值,当聚类样本数 x_i 增加时, SSE 会逐渐降低,当下降幅度明显减缓时,取该点对应的 k 值,如图 2 所示。在本研究中,通过肘部法确定驾驶风格分类的 k 值为 3,并将驾驶风格分为激进型、正常型和保守型,如图 3 所示。




图 2 肘部法则确定最佳 k 值

Fig. 2 Elbow method for determining the optimal value of k



图 3 驾驶风格分类

Fig. 3 Driving style classification

3.3 换道预测模型性能评价指标

本文所提出的换道预测模型是一个分类预测模型,因此采用准确率(*Accuracy*)作为评估模型性能的指标。准确率定义为正确预测换道数量 T 与样本总量 N 的比值。可由式(5)运算求得:

$$Accuracy = \frac{T}{N} \quad (5)$$

其中, T 表示正确预测换道的数量, N 表示样本总量。

为了最小化预测分布与真实分布之间的差异,选择交叉熵函数作为损失函数。交叉熵函数在分类任务中具有更高的有效性,并能缓解梯度消失的问题。损失函数的定义如下:

$$Loss = - \sum_{i=1}^N y_i \log \hat{y}_i \quad (6)$$

其中, y_i 表示真实的换道输出; \hat{y}_i 表示神经网络换道预测输出; i 表示样本索引; N 表示样本数量。

对损失函数的偏导是:

$$\frac{\partial L}{\partial \omega_n} = \frac{\partial L}{\partial (ReLU(\omega_n^T x_n + b_n))} (ReLU(\omega_n^T x_n + b_n)) x_n \quad (7)$$

其中, L 表示误差; ω_n 表示节点权重; b_n 表示偏置; x_n 表示样本数量。通过误差反向传播算法,可以不断更新节点权重和偏置,以降低损失函数,提高模型的性能。

3.4 换道预测模型结果和泛化能力

在本文中,先对是否考虑驾驶风格的 2 种换道预测模型进行对比分析。首先,是经典的机器学习的 BP 神经网络换道预测模型,并且绘制了该模型的准确率和损失函数曲线,如图 4 所示。未考虑驾驶风格变量的原始 FCNN 模型,该模型用于预测车辆的换道行为,并且绘制了该模型的准确率和损失函数曲线,如图 5 所示。然后,第二种是更准确地预

测车辆换道行为,并考虑驾驶风格的影响的车辆换道预测模型,在输入变量中加入了经过驾驶风格分类的结果,使得模型能够综合考虑不同驾驶风格的差异,绘制了此模型的准确率和损失函数曲线,如图 6 所示,其换道预测模型的预测结果如图 7 所示。最后,在 US-101 道路上验证模型的泛化能力,将模型应用于 US-101 的数据集中,其准确率和损失函数如图 8 所示。通过分析这些模型的准确率,得到的换道模型性能比较见表 2。分析发现加入驾驶风格的 FCNN 模型相较于原始 FCNN 模型具有更高的准确率和更低的损失函数,未加入驾驶风格的模型准确率为 87.8%,加入驾驶风格的模型准确率为 91.8%,这表明考虑驾驶风格的模型对换道预测的性能有积极影响,测试不同道路下的泛化能力是,其准确率为 89.3%,说明该模型泛化能力较好,可以适用于不同的道路上。




图 4 BP 神经网络换道预测模型

Fig. 4 Lane change prediction model results based on BP neural network




图 5 未加入驾驶风格的换道预测模型

Fig. 5 Lane change prediction model results without driving styles




图 6 加入驾驶风格的换道预测模型

Fig. 6 Lane change prediction model results with driving styles

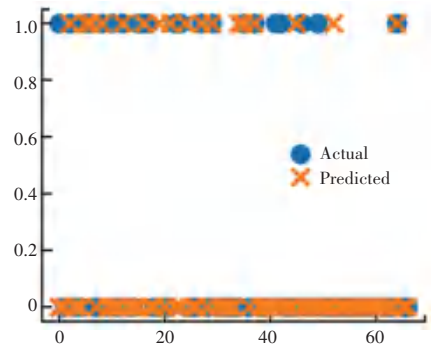


图 7 加入驾驶风格的换道模型预测结果

Fig. 7 Comparison of lane change prediction model results with driving styles




图 8 模型泛化能力测试

Fig. 8 Testing model generalization capability

表 2 换道模型性能比较

Table 2 Comparison of lane change model performance

模型	准确率/%
BP 神经网络换道预测模型	84.6
未加入驾驶风格的换道预测模型	87.8
考虑驾驶风格的换道预测模型	91.8
考虑驾驶风格换道预测模型的泛化能力测试	89.3

4 结束语

本文通过分析车辆换道时刻的场景和考虑驾驶员风格的因素,提出了一种考虑驾驶风格的智能车辆换道行为预测的模型。根据在下一代模拟(NGSIM)数据集的训练与测试,得到以下结论:

(1)在驾驶风格分类方面,采用了聚类样本,并将驾驶风格分为激进型、稳重型和保守型。这种考虑驾驶员个体差异和行为习惯的方法,为换道预测模型增加了准确性和可靠性。

(2)通过评价指标的准确率和损失函数的交叉熵,对2种不同模型进行了比较。一种是原始的未考虑驾驶风格的FCNN模型,另一种是加入驾驶风格分类的模型。实验结果表明,考虑驾驶风格的模型准确率达到了91.80%,而不考虑驾驶风格的模型准确率为87.80%,传统BP神经网络为84.6%,这表明加入驾驶风格变量的换道预测模型具有更好的准确性。

参考文献

- [1] 胡晨曦,韩印,王嘉文,等.考虑自动驾驶车队的高速公路双车道混合交通流行驶模型[J].智能计算机与应用,2022,12(5):50-55,60.
- [2] 胡鑫.基于函数分布特性的智能车辆换道行为识别[J].智能计算机与应用,2021,11(7):91-94,101.
- [3] 董俊一.考虑驾驶风格的智能驾驶换道决策模型研究[J].长春:吉林大学,2023.
- [4] 聂琳真,黄灏然,尹智帅.基于RBF神经网络的高速公路车辆换道行为决策模型研究[J].武汉理工大学学报,2019,41(9):18-24,53.
- [5] 陈力,殷时蓉,罗天洪,等.基于BP神经网络的智能车辆换道决策模型研究[J].汽车工程学报,2022,12(1):83-89.
- [6] 李振,陈学文.交通车辆换道行为预测方法[J].重庆理工大学学报(自然科学),2022,36(12):50-57.
- [7] 密俊霞,于会龙,席军强.基于MLP-SVM的驾驶员换道行为预测[J].兵工学报,2022,43(12):3020-3029.
- [8] LI C, HUANG Y, WU H, et al. Multiple recursive projection twin support vector machine for multi-class classification [J]. International Journal of Machine Learning and Cybernetics, 2016, 7(5): 729-740.
- [9] 高凯,李勋豪,胡林,等.基于多头注意力的CNN-LSTM的换道意图预测[J].机械工程学报,2022,58(22):369-378.
- [10] WANG Weida, QIE Tianqi, YANG Chao, et al. An intelligent lane-changing behavior prediction and decision-making strategy for an autonomous vehicle [J]. IEEE Transactions on Industrial Electronics, 2022, 69(3): 2927-2937.
- [11] XIANG Wei, DU Luyao, CHEN Wei, et al. A novel intelligent approach to lane-change behavior prediction for intelligent and connected vehicles [J]. Computational Intelligence and Neuroscience, 2022, 2022: 9516218.
- [12] 郑奇.智能驾驶中驾驶员风格识别及车辆行为预测研究[D].杭州:浙江大学,2022.
- [13] 刘思源,喻伟,刘洁莹,等.考虑驾驶风格的车辆换道行为及预测模型[J].长沙理工大学学报(自然科学版),2019,16(1):28-35.
- [14] REN Y Y, ZHAO L, ZHENG X L, et al. A method for predicting diverse lane-changing trajectories of surrounding vehicles based on early detection of lane change [J]. IEEE Access, 2022, 10: 17451-17472.
- [15] 刘冠颖,郭凤香,申江卫,等.基于数据特征的驾驶风格分类与识别方法研究[J].昆明理工大学学报(自然科学版),2023,48(3):165-173.
- [16] CAPO M, PEREZ A, LOZANO J A A. An efficient Split-Merge restart for the K-means algorithm [J]. IEEE Transactions on Knowledge and Data Engineering, 2022, 34(4): 1618-1627.
- [17] PRATT H, WILLIAMS B, COENEN F, et al. FCNN: Fourier convolutional neural networks [C]//Machine Learning and Knowledge Discovery in Databases; European Conference, ECML PKDD 2017. Skopje, Macedonia: Springer International Publishing, 2017: 786-798.
- [18] COIFMAN B, LI Lizhe. A critical evaluation of the Next Generation Simulation (NGSIM) vehicle trajectory dataset [J]. Transportation Research Part B: Methodological, 2017, 105: 362-377.