

doi: 10.7690/bgzdh.2024.05.009

智能驾驶车辆轨迹预测方法综述

龙皓明^{1,2}, 薛振锋^{1,2}, 陈卓³, 刘勇^{1,2}

(1. 湖州师范学院信息工程学院, 浙江 湖州 313000; 2. 浙江大学湖州研究院, 浙江 湖州 313002;
3. 中国船舶集团有限公司系统工程研究院, 北京 100094)

摘要: 针对目前车辆轨迹预测难点, 对车辆轨迹预测方法的分类和研究现状进行综述。根据模型实现预测时域的不同, 将现有算法分为短时域和长时域的车辆轨迹预测方法; 介绍短时域的基于物理模型和传统机器学习预测方法的基本概念及研究现状, 总结对比长时域的基于深度学习、神经网络和基于车辆驾驶行为意图识别的预测方法。分析结果表明: 长时域方法能够解决车辆轨迹预测难点问题, 保证智能车辆高效、安全驾驶。

关键词: 智能驾驶; 车辆轨迹预测; 深度学习; 意图识别

中图分类号: U461.91; TP273 **文献标志码:** A

A Survey of Vehicle Trajectory Prediction Methods for Intelligent Driving

Long Haoming^{1,2}, Xue Zhenfeng^{1,2}, Chen Zhuo³, Liu Yong^{1,2}

(1. School of Information Engineering, Huzhou University, Huzhou 313000, China;

2. Huzhou Institute of Zhejiang University, Huzhou 313002, China;

3. Institute of System Engineering, China State Shipbuilding Corporation Limited, Beijing 100094, China)

Abstract: In view of the difficulties of vehicle trajectory prediction, the classification and research status of vehicle trajectory prediction methods are reviewed. According to the different prediction time domain of model implementation, the existing algorithms are divided into short time domain and long time domain vehicle trajectory prediction methods; the basic concepts and research status of short time domain prediction methods based on physical model and traditional machine learning are introduced, and the long time domain prediction methods based on deep learning, neural network and vehicle driving behavior intention recognition are summarized and compared. The analysis results show that the long time domain method can solve the difficult problem of vehicle trajectory prediction and ensure the efficient and safe driving of intelligent vehicles.

Keywords: intelligent driving; vehicle trajectory prediction; deep learning; intention recognition

0 引言

随着信息化和智能化的飞速发展, 人工智能在汽车行业的应用和实现得到青睐, 促使车辆智能化水平获得显著提升, 学者们纷纷开始致力于汽车智能化的进一步发展^[1]。在人工智能技术和硬件计算能力不断提升的助力下, 自动驾驶汽车相关技术迎来了突破, 并取得了一定的发展成果, 产业界涌现出了具有部分智能功能、适应局部情境下的自动驾驶系统^[2]。自动驾驶系统的核心功能主要包括感知模块、规划模块和控制模块。其中感知模块中的轨迹预测技术可以预测车辆自身轨迹或者附近运动对象的未来轨迹。预测的轨迹对规划模块来说是必不可少的, 直接影响汽车的驾驶行为。为了安全运行, 安全系统必须能够预测在不久的将来车辆周围环境会发生什么, 并实施提前计划。如果车辆的预计轨迹可用, 系统可以及时做出决定, 及时提醒危险以避免或警告潜在的碰撞, 从而实现更安全、更高效

的驾驶作业^[3]; 因此, 准确的轨迹预测是汽车安全驾驶的关键, 有着至关重要的作用, 是自动驾驶的核心技术。车辆的轨迹预测是根据车辆现有的运动趋势结合感知信息和高精度地图等有效数据预测车辆未来可能的行驶位置和运动趋势。将精准有效的运动预测结果传输给决策规划层, 有助于决策规划作出合理的运动决策, 从而大大提高交通的安全性^[4]。根据目前自动驾驶领域的轨迹预测研究, 总结了车辆轨迹预测的难点主要集中在 4 方面:

1) 感知模块中车载传感器只能直接得到车速、方向、位置、距离等数值数据, 这些数据可能存在一定误差; 同时, 对于车辆本身、驾驶员的驾驶意图以及周围环境目标等抽象数据无法直接获取, 只能通过得到的数据进行深入理解推测, 这可能导致误差进一步扩大。

2) 车辆轨迹预测过程中的周围环境信息复杂多变, 车辆的行驶意图不仅受车辆本身的影响, 同

收稿日期: 2024-01-23; 修回日期: 2024-02-27

第一作者: 龙皓明(1997—), 男, 湖南人, 硕士。

时还和周围车辆和其他移动目标和静态障碍物等有着重要关系，以及对于车对车 (vehicle-to-vehicle, V2V)^[5]和车对基础设施 (vehicle-to-infrastructure, V2I) 交互通信来说，可将车辆的感知范围扩展到远远超出其车载传感器的限制^[6]，但想有效地将这些交互关系进行建模分析还存在很大困难，在真实场景中复杂的情况会增加轨迹预测的不确定性，从而导致轨迹预测的精确度下降。

3) 车辆预测轨迹的结果呈现多模态的现象，如在十字路口的场景下，同一时刻同一道路上的车辆，它们的历史轨迹相同，但是实际情况下的动作可能不同，这就需要根据不同的行车意图进行建模预测轨迹。

4) 车辆轨迹预测结果的可解释性和可靠性^[4]。传统预测模型只依据数据进行预测，能够得到较好的解释性，但基于深度神经网络的模型，无法明确模型内容的具体作用，其可解释性难以阐述；同时，输出结果的可靠性也至关重要，关系交通行驶的安全性，这对于自动驾驶来说极富挑战性。

1 车辆轨迹预测方法

车辆轨迹的高动态性、场景复杂性以及和其他目标的交互性使轨迹预测面临巨大的挑战，对车辆轨迹预测的研究非常必要，是实现自动驾驶规划决策安全、稳定、可靠的重要保障。近年来，随着自动驾驶技术的不断发展，国内外关于车辆轨迹预测的研究逐渐增多，如图 1 所示。




图 1 车辆轨迹预测分类

1.1 短时域的车辆轨迹预测方法

短时域的车辆轨迹预测是指在短时间内基于当前目标状态信息预测未来一段时间的轨迹。一般是根据短时间内的数据信息进行状态预测或者结合对车辆动力学和运动学的建模来展开对车辆未来的状态和轨迹预测的，由此可以分为基于传统概率统计的模型和基于物理运动规律的模型 2 大类，通常都是相互结合进行应用的。

1.1.1 基于物理模型的预测方法

基于物理模型的预测方法主要是根据车辆的动力学或运动学约束进行建模，进而预测车辆未来的运动状态；但由于动力学模型涉及车辆的许多车辆内部参数^[7]，这些参数不能被外部传感器观察到。相比之下运动学模型更为简单直接，它不考虑车辆内部参数和可能影响运动的力，仅基于运动参数之间的数学关系来描述车辆的运动。应用于车辆的运动学模型主要有线性运动模型和曲线模型共 7 种，前者包括恒速 (constant velocity, CV) 模型和恒定加速 (constant accelerations, CA) 模型，这些模型假设车辆为直线运动，不考虑旋转 (特别是偏航速率)^[8]。后者包括恒转速和速度 (constant turn rate and velocity, CTRV) 模型、恒转速和加速 (constant turn rate and acceleration, CTRA) 模型、恒定转向角和

速度 (constant steering angle and velocity, CSAV) 模型、恒定转向角和加速度 (constant steering angle and acceleration, CSAA) 模型、常曲率和恒加速度 (constant curvature and acceleration, CCA) 模型^[9]，这些曲线模型从几何学的角度假设车辆在圆形轨道上移动 (无论是恒速还是加速) 以及假设车辆遵循回旋曲线 (CTRA 模型)，非常准确地描述了道路车辆的运动，多用于预测自主车辆本身的运动。Huang 等^[10]在车辆配备 DGPS 定位系统的情况下，考虑以当前横摆角速度和纵向加速度作为输入以及在偏航速度变化很快的情况下，考虑偏航加速度，以此建立运动学模型并使用 Kalman 算法预测车辆的未来轨迹。Lytrivis 等^[11]利用基于无线通信的 V2V 技术，收集所有车辆的位置以及经过卡尔曼平滑后的速度和偏航率测量值，使用 CTRA 模型来计算车辆未来的行驶路径。Mattias 等^[12]使用 CA 车辆模型，完成对目标位置和方向等状态参数估计，以此实现对其未来行驶轨迹的预测计算。Zhang 等^[13]通过对车联网 (internet of vehicles, IOV) 中障碍车辆的位置进行变换，计算出相对位置、距离和速度，运用卡尔曼滤波 (Kalman filter, KF) 和基于 CV 的车辆模型预测障碍车辆的轨迹，可以进行碰撞预警，提高驾驶安全性。Xie 等^[14]通过结合基于物理和机动的方法，提出一种集成的车辆轨迹预测方法，即交互式

多模型轨迹预测 (interactive multiple model trajectory prediction, IMMTP) 方法, 实现了在短期内准确预测, 并尝试了在长期内以更高的视野进行预测, 这种综合方法具有长期预测的能力, 预测误差比传统方法小。Xiao 等^[15]提出了一种基于运动模型和机动模型融合的交互式多模型车辆轨迹预测方法, 首先采用 CTRA 运动模型和无迹卡尔曼滤波 (unscented Kalman filter, UKF) 对未来不确定的车辆轨迹进行预测; 然后利用车辆历史轨迹与车道线的时空关系, 基于简化的机动识别模型进行车辆轨迹预测; 最后将运动模型和机动模型与交互式多模型 (interacting multiple model, IMM) 相结合进行车辆轨迹预测。在短时间段内, 通过运动学模型得到的轨迹预测误差较小, 精度较高, 但随着预测时间增加, 其误差大幅增加, 且与目标的运动趋势不符。

1.1.2 基于传统机器学习的预测方法

基于传统机器学习的车辆轨迹预测方法通过关联车辆历史轨迹数据与预测轨迹数据建立相应算法的数学模型进行预测。考虑到短时间内的车辆状态和轨迹不会剧烈改变; 因此, 通过状态估计及序列数据概率预测等方式构建数学模型可对轨迹进行预测。

1) 卡尔曼滤波预测法。

KF 是车辆根据上一时刻的状态, 来预测当前时刻的状态, 将预测状态与当前时刻的测量值进行加权, 加权后的结果则为当前时刻下的状态的最优估计。BARTH 等^[16]根据不同场景 (例如线性运动、曲线运动或转弯机动) 参数化的卡尔曼滤波器应用于短距离的车辆轨迹预测。Xu 等^[17]采用了卡尔曼滤波器对除自动驾驶车辆外的其他交通参与者的未来状态进行概率预测。乔少杰等^[18]运用卡尔曼滤波设计了动态轨迹预测算法来连续预测位置, 但预测轨迹的误差较大, 平均误差为 12.5 m。针对使用 GPS 接收器获取位置信息, 车辆估计的未来位置不是一条直线而结果不准确的问题, Barrios 等^[19]使用综合卡尔曼滤波器以处理汽车可能处于的不同识别状态中的不准确性, 结合交互多模型系统, 可提前 3 s 提供汽车的预测未来位置。Schulz 等^[20]提出一种多模型无迹卡尔曼滤波器, 在状态空间中包含所有车辆, 进而考虑车辆间的交互来进行轨迹预测。针对真实道路场景复杂化和车辆状态多样化的问题, Abbas 等^[21]根据车辆所有可能的状态提出了 5 种不

同的扩展卡尔曼滤波模型, 将扩展卡尔曼滤波与 IMM 框架相结合, 用于数学模型的建立和模型的概率计算, 估计出车辆未来的位置。而 Lefkopoulos 等^[22]提出的一种基于交互多模型卡尔曼滤波器 (IMM-KF) 的多车辆运动预测方案, 结合了基于物理、基于机动和交互感知方法的思想, 通过假设通过车辆优先级列表编码的层次结构来解决多车辆的运动估计和预测。KF 处理无噪声点的轨迹数据时预测效果较好, 短时间内预测能力稳定且准确, 但长时间的轨迹预测误差很大。现今一般将卡尔曼滤波运用做前期数据处理, 平滑相关数据, 再结合其他方法进行预测。

2) 贝叶斯网络预测法。

贝叶斯网络 (Bayesian network) 是基于概率推理的图形化网络, 通过建模预测车辆的状态, 并描述这些状态如何与概率相关联。Schreier 等^[23]提出一种基于机动的轨迹预测和临界评估的集成贝叶斯方法, 通过贝叶斯检测交通场景中每辆车的机动分布, 再根据机动进行车辆的轨迹预测。Schulz 等^[24]提出基于动态贝叶斯网络的概率预测框架, 结合交互感知行为, 对网络的估计状态进行概率前向模拟, 进而生成预测轨迹。为解决 EM 算法有时无法计算概率分布的缺陷, Ma 等^[25]提出了基于变分贝叶斯 (variational Bayesian, VB) 的轨迹预测算法, 在相同参数设置下, VB 算法的轨迹预测精度比 EM 提高了 87.3%。在 IOV 的跟车工况下, 张金辉等^[26]基于贝叶斯网络对前方车辆运动速度进行预测, 为车辆轨迹规划预测提供了数据参考。Rio 等^[27]提出了一种基于贝叶斯网络的移动模型, 用隐藏马尔可夫链对每辆车的轨迹进行建模, 再使用维特比算法识别出最可能的轨迹。贝叶斯网络对小规模数据表现很好, 但需要假设的先验概率在一定程度上会导致预测效果不理想。

3) 马尔可夫预测法。

马尔可夫模型是一种概率转移模型。它涉及的概率转移矩阵是能否进行准确预测的关键。彭曲等^[28]考虑城市交通网络特征, 利用统计并考虑历史轨迹信息, 提出了基于马尔可夫链的轨迹预测, 预测准确率达到 40% 左右。Gambis 等^[29]提出了基于移动马尔可夫链 (mobility Markov chain, MMC) 的轨迹预测, 使用 n-MMC 的模型来预测下一个位置, 2-MMC 的准确率能达到 70%~95%。为准确跟踪危险货物道路运输车辆, Malekian 等^[30]在智能车辆导航系统中使用基于隐马尔可夫模型的预测算法

提前预测路径。Ye 等^[31]通过挖掘车辆历史轨迹的双层隐状态,提出了基于双层隐状态隐马尔可夫模型的车辆轨迹预测算法,能够预测车辆行驶轨迹的近邻单元的 k 个阶段。马尔可夫模型的优点是能够计算出具有维修能力和多重降级状态系统的概率。但是其预测准确率比较低,一阶马尔可夫模型只考虑当前轨迹点对未来轨迹点的影响,不能充分地利用历史轨迹点数据;高阶马尔可夫预测模型增加了模型计算复杂度,不适用于海量轨迹数据的训练学习,同时对车辆轨迹的波动比较敏感,不适合系统中长期预测。

综上所述,短时域的车辆轨迹预测方法虽然能够实现短时间内的车辆运动状态及轨迹的预测,但其方法的局限性显然无法解决车辆轨迹预测难点问题,只能在长时域的车辆轨迹预测方法中寻求解决方案。

1.2 长时域的车辆轨迹预测方法

长时域的轨迹预测方法更侧重于交通车辆在长时间内的行驶趋势或路线,而非短期的运动状态。对交通车辆的轨迹预测所需信息主要包括历史观测信息、道路特征、其所处的交通环境及其表现出的驾驶行为等。长时域轨迹预测方法主要分为 2 种:

1) 利用大量的历史轨迹数据来寻找运动规律,然后估算并预测给定轨迹的未来变化情况; 2) 基于交通车辆的驾驶行为识别结果,结合当前道路信息,可以评估车辆长时间的行驶趋势,从而预测长期轨迹。

1.2.1 基于深度学习、神经网络的预测方法

基于深度学习、神经网络的预测方法依靠庞大网络的训练,结合一些上下文信息(地图、目标间交互信息),能够从历史轨迹数据学习到更多、更深的各种特征,同时也能够考虑更多的环境因素(如:并线/变道的高速与城市道路、带停车/让车标志的环形路、无保护左转路口等场景),从而实现更精准的车辆轨迹预测。主要包括单车辆的轨迹预测和多车辆考虑交互性的轨迹预测。前者只考虑周围环境信息(包括其他车辆)对被预测车辆的影响,然后对预测车辆进行预测轨迹,但不对其他车辆进行轨迹预测;后者不仅考虑其他相邻车辆对自主车辆的影响,建模车辆间的交互性,且预测所有相邻车辆的轨迹预测,进而对被预测车辆进行轨迹预测。

对于单车辆的轨迹预测,在深度学习中目前使用基于长短期记忆网络(long short-term memory, LSTM)编码器-解码器结构模型的居多,如图 2 所

示,因其能很好地解决循环神经网络(recurrent neural network, RNN)长时间学习产生的梯度消失和梯度爆炸的问题。前期研究主要通过 LSTM 编码车辆的历史轨迹来提取车辆的运动特征和周围环境信息,结合两者进行轨迹编码,再通过解码器输出预测的车辆运动轨迹。随着研究的逐步深入,为解决预测过程中更加复杂的问题,单一模型效果不再显著,基于混合模型的轨迹预测方法也逐步增多,这是未来的发展趋势之一。Deo 等^[32]提出了一种基于 LSTM 编码器-解码器模型的车辆轨迹预测方法,通过编码器来学习被预测车辆运动的动力学,采用卷积社交池化层捕获场景中周围目标运动的相互依赖性,两者结合解码输出被预测车辆的未来运动的多模态预测概率分布。受文献[32]启发,Mo 等^[33]以两层卷积神经网络(convolutional neural network, CNN)来分层提取车辆的交互特征,基于 CNN-LSTM 网络提出了一种交互感知方法,可预测自主车辆的未来轨迹,并考虑其与周围 8 辆车的交互。为解释历史轨迹和相邻车辆对目标车辆的影响,Lin 等^[34]基于文献[32]提出了一种具有时空注意机制的 LSTM 模型 STA-LSTM 用于车辆轨迹预测,模型提供的时空注意力权重增强了模型的可解释性。与文献[33-34]不同的是,Geisslinger 等^[35]提出了一种使用在线学习的车辆轨迹预测算法,在推理过程中使用观察结果来优化运行时的底层神经网络的权重,可改善预测结果,给未来研究提供了一个新的方向,如图 3 所示。Gu 等^[36]提出了无锚的端到端轨迹预测模型 Dense TNT,直接从密集目标候选中输出一组轨迹,规避了基于锚点的方法所具有的目标锚的质量问题,使用 Vector Net^[37]处理车道和目标的特征以及两者间的交互,通过引入离线模型产生多个未来的伪标签,用于在线模型训练,使用目标集预测器生成多个目标的轨迹。此模型在 2021 Waymo 开放数据集运动预测挑战赛中获得第 1 名(给定目标的 1s 历史轨迹,需要预测 8 s 的未来轨迹)。除了基于 LSTM 和 CNN 的方法,为进一步获取高精度、多维度数据以及关注提取有效信息,近年来基于图神经网络(graph neural network, GNN)、图卷积神经网络模型(graph convolutional network, GCN)和结合注意力机制的研究也逐渐增多,大多数模型设计都会将地图信息(如使用高清地图)合并到图结构中,如图 4 所示。Vector Net^[37]将目标轨迹和地图特征矢量化,创建了以地图信息作为附加节点的全局交互图,相较于于

ResNet18 其计算量大大减少。Liang 等^[38]使用 Lane GCN 和 Actor Net 提取地图特征和目标运动特征，再利用 4 类交互组成的融合网络生成多模态轨迹预测。Messaoud 等^[39]提出了一种将基于网格的轨迹编码与 LSTM 和多头自注意力相结合的模型，多头注意力模块根据其重要性对目标车辆与相邻车辆之间的交互进行建模，解码器接收交互向量和目标车辆编码，并生成预测轨迹的分布。Da 等^[40]提出的路径感知图注意力机制能够在现有的图网络(如 GCN)中改进地图编码，促进教学中的学习来提升预测效果。Song 等^[41]提出车辆轨迹预测的新型架

构 Prime，结合车辆状态和 HD map 生成预测，并通过利用基于学习的评估器来选择未来的轨迹来实现准确的多模态预测。而 Schmidt 等^[42]和文献[43]从反向考虑，如果地图信息不可用、不是最新的角度提出了 CRAT-Pred，一种不依赖地图信息的基于非光栅化的多模态轨迹预测模型，使用 LSTM 对车辆特征进行时间编码，并结合 GNN 和多头自注意力来模拟社交互动，使用一个简单的线性残差层来生成轨迹预测。相较于文献[38]，其参数量大大减少，且预测效果更好，这对未来模型轻量化有参考意义。

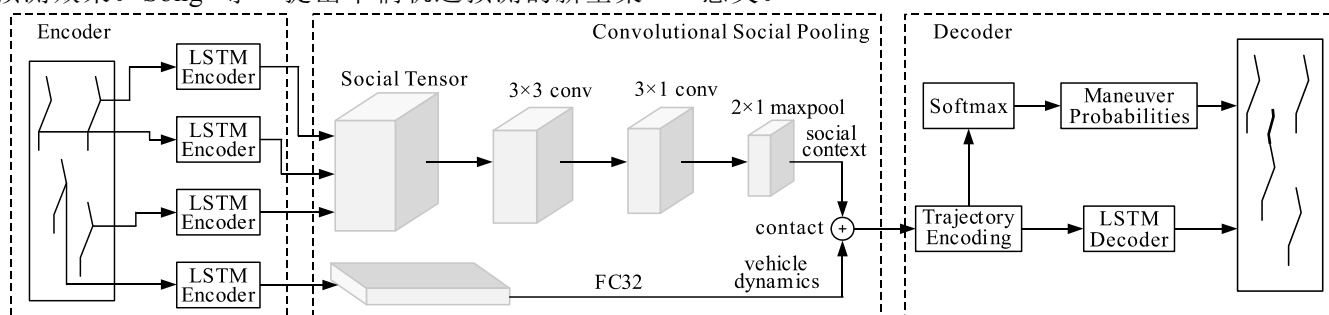


图 2 基于 LSTM 编码器-解码器模型的车辆轨迹预测方法^[32]

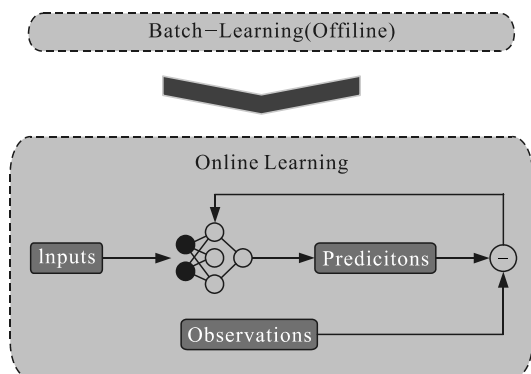


图 3 概率车辆轨迹预测在线学习方法的基本原理^[35]




图 4 高清地图合并到图结构中生成地图特征^[38]

对于轨迹预测来说，仅考虑周围车辆的历史轨迹是不够的，就车辆间交互性来说提取的信息作用有限，对自主车辆的轨迹预测效果提升不够；因此，考虑周围车辆甚至环境中的其他移动目标的未来轨迹对自主车辆的未来轨迹造成的影响十分必要。

Marchetti 等^[44]提出一种基于记忆增强神经网络的多轨迹预测新架构，可结合存储的历史轨迹和未来轨迹在线学习进行轨迹预测，解决了城市场景中多个车辆轨迹的预测问题，同时能实现多场景下

(如交叉路口和十字路口)的多模态轨迹预测。Song 等^[45]为解决多智能体环境下的轨迹预测问题，提出了基于规划的轨迹预测方法，此方法考虑所有的历史轨迹，预测周围车辆的未来轨迹同时纳入自主车辆的和规划轨迹，将预测过程与自主车辆规划相结合，经过评估后输出多模态轨迹。Rella 等^[46]提出一种以解码器为中心的基于注意力的运动轨迹预测方法，在解码器阶段融合了地图和社交互动进行轨迹预测，可输出多个车辆预测轨迹及其相对概率。Narayanan 等^[47]提出新型轨迹预测框架 ALAN 用超列描述符捕获交互，并以光栅化图像和每个目标车辆的车道锚的形式合并场景信息，从而在向前传递中提供多车辆轨迹输出。Yu 等^[48]通过预测周围车辆未来轨迹，基于将周围车辆的相对位置和速度等动力学数据转换为目标车辆的参考系，设计了基于注意力机制的 LSTM 车辆轨迹预测模型；同时，提出一种将道路几何形状线性化的方法，使模型可用于各种道路环境，提高了模型泛化能力。Yuan 等^[49]提出一种新的 trans former-agent Former，同时从时间和社会维度对 agent 进行联合建模，其包含的代理感知注意机制允许跨时间和车辆的特征交互影响实施对多车辆轨迹预测。Sheng 等^[50]提出了一种基于图的时空卷积网络(graph-based spatial-temporal convolutional network, GSTCN)来预测所有相邻车

辆未来的轨迹分布。该网络使用 GCN 来处理空间相互作用，并使用 CNN 来捕捉时间特征。时空特征由门控递归单元(gated recurrent unit, GRU)网络进行编码和解码，以生成未来的轨迹分布。

总之，随着深度学习的快速发展，基于深度学习的轨迹预测方法已成为研究热点。如表 1 所示，基于深度学习的方法基本可解决传统预测方法的车辆轨迹预测难点问题。随着数据集规模越来越大、社会交互场景信息越来越丰富、数据集所涵盖的边界情况(corner case)越来越完善，实验场景就会越来越接近于现实场景，结合多源数据增加数据量、合理有效地设计神经网络架构，对于车辆轨迹预测的效率及精度都会有很大的改善。

表 1 基于深度学习的轨迹预测方法对比

方法	优点	缺点	研究方向	解决难点
CSP-LSTM ^[32]	社交池化	信息不足	感知交互	多模态预测
CNN-LSTM ^[33]	卷积交互	场景固定	感知交互	交互性
STA-LSTM ^[34]	时空注意	局部交互	注意机制	可解释性
Wale-Net ^[35]	推理优化	依赖超参	在线学习	优化误差
DenseTNT ^[36]	离线优化	算力开销	在线学习	优化误差
VectorNet ^[37]	高阶交互	依赖地图	图交互	交互性
LaneGCN ^[38]	交互融合	地图单一	地图融合	多模态预测
MHA-LSTM ^[39]	高阶交互	场景固定	注意机制	多模态预测
PAGA ^[40]	优化编码	计算效率	地图融合	多模态预测
CRAT-Pred ^[43]	参数量少	特征单一	模拟社交	交互性
Prime ^[42]	隐式交互	依赖地图	感知交互	多模态预测
Pip ^[45]	结合规划	泛化不足	交互建模	多模态预测
DF-RNN ^[46]	多车预测	信息限制	地图融合	多模态预测
ALAN ^[47]	多样感知	依赖地图	车道锚点	环境复杂
Yu 等 ^[48]	场景泛化	地图限制	注意机制	环境复杂
Yuan 等 ^[49]	特征交互	时间开销	感知注意	交互性
GSTCN ^[50]	时空特征	数据单一	空间依赖	交互性

1.2.2 基于车辆驾驶意图行为识别的预测方法

对动态车辆的驾驶意图预测方法能够描述较长一段时间后动态车辆的驾驶行为，对交通车辆驾驶行为识别有助于提高对动态环境的理解及预测能力，实现长时间的预测以提升智能决策能力，是对环境变化更深层次的认识，故驾驶行为识别对于环境感知具有重要意义。驾驶行为可分为驾驶员行为和车辆驾驶行为，驾驶员行为识别根据驾驶员行为特征和交通环境状态预测其驾驶意图，主要关注主车驾驶员的驾驶意图；而车辆行为根据交通车辆运动信息和交通环境状态来预测交通车辆驾驶行为。

Yuan 等^[49]基于 Agent Former 提出的多智能体轨迹预测模型，对所有车辆未来轨迹进行联合建模，所有车辆的潜在意图也被联合建模，允许跨时间和车辆的直接特征交互，以产生多样化且具有 socially-ware 的多车辆未来轨迹。Zyner 等^[51]提出

一种具有概率分布的多模态轨迹预测来预测交叉路口驾驶员意图的方法，基于 RNN 输出多模态轨迹，并通过聚类根据概率排序，判断驾驶员在交叉路口可能做出的相关意图。季学武等^[52]在使用基于 LSTM 的意图识别模块识别驾驶意图，并输出(左、右)换道和直线行驶的概率。谢枫等^[53]结合感知系统和高清地图提供的车辆状态信息(具体包括位置、速度、加速度、航向角和横摆角速度)进行车辆行为识别。Lee 等^[54]采用 CNN 预测高速公路场景下的车辆换道意图，网络的输入是俯视的栅格图，输出则是前方车辆的可能出现的会道行为。这种方法先确定会道行为的概率，再通过前方车辆距离自动驾驶车辆车道的阈值来确定意图车辆。Lenz 等^[55]基于全连接深度网络训练高斯混合模型参数，用以预测高速场景车辆行为。实验证明，该方法比卷积神经网络以及传统预测方法 IDM 效果更好。Bahram 等^[56]提出了一种物理模型结合意图预测(learning-based)的方法，使用启发式的方法集成专家知识，简化了交互模型，在意图预测的分类模型中加入了博弈论思想。王培丞^[57]采用交互式的方法对车辆意图进行预测，不仅考虑到了传统的意图预测的特征，还考虑车辆之间的联系，使得模型描述更为全面。对车道序列概率评估的准确率达到 90% 以上，能够以 10 Hz/s 的频率预测车辆未来 8 s 的行驶轨迹且平均误差可控制在±5 m。Zhao 等^[58]提出了目标驱动框架轨迹预测模型(target-driveN trajectory predictio, TNT)，这是一种以目标导向的三阶段端到端训练的轨迹预测方法，使用监督学习对车辆进行多轨迹回归，最终输出多个未来轨迹的行为预测，同时通过轨迹打分机制明确各个轨迹可能性。Chandra 等^[59]提出了一种基于规则的行为预测算法，根据心理学文献[60-61]中的交通行为分类来预测道路其他车辆是超速(激进)、低速(保守)还是中性。Phan-Minh 等^[62]提出了使用轨迹集的多模态行为轨迹预测模型 Cover Net，使用车辆状态(速度、加速度、偏航角)生成轨迹集来近似所有可能的运动行为；同时，结合车辆状态和光栅化高清地图通过卷积神经网络生成轨迹概率模型，最后输出可行轨迹。Girase 等^[63]提出的 LOKI 数据集为长期轨迹预测和短期意图预测提供基础，提出联合轨迹和意图预测框架，构建场景图以允许目标(车辆和行人)共享轨迹信息、意图和长期目标，通过轨迹解码器输出预测轨迹。Wang 等^[64]对自主车辆的交互车

辆并构建了语义图(semantic graph, SG), 将 SG 输入到高级语义图网络(SGN)推理车辆之间的关系并预测意图信号, 使用编码器解码器网络(encoder decoder network, EDN)接收每辆车的历史状态和意图信号, 预测它们的未来轨迹。Tolstaya 等^[65]对路图、目标状态和目标的未来轨迹进行输入编码, 结合这 3 方面信息基于 GNN 输出意图类别和轨迹。Li 等^[66]将交叉口意图预测表述为目标车辆和地图元素之间的匹配问题, 使用 2 个互助注意力模块来计算每个级别意图的匹配分数, 输出得分最高的目标意图和车道意图, 给定目标意图和车道意图可对每个可能的意图生成多模式的未来轨迹。当意图可被充分捕获时, 其模型可以预测任意复杂十字路口的意图。

如表 2 所示, 基于车辆驾驶意图行为识别的轨迹预测方法能够处理复杂场景的相关意图行为识别, 探索高阶、低阶信息交互, 联合意图行为预测和车辆轨迹预测, 在线调整行为和意图, 在预测的初始阶段其预测精度较差, 但长期效果较好。

表 2 基于车辆驾驶意图行为识别的轨迹预测方法对比

方法	优点	缺点	研究方向	解决难点
Yuan Y 等 ⁴⁹	意图建模	时间开销	多车轨迹	交互性
RNN-FF ⁵¹	多模轨迹	场景固定	驾驶意图	多模态预测
季学武等 ⁵²	驾驶意图	场景固定	驾驶意图	多模态预测
谢枫等 ⁵³	换道预测	场景固定	行为识别	多模态预测
Lee 等 ⁵⁴	会道行为	依赖网格	换道意图	交互性
Lenz 等 ⁵⁵	低维潜层	场景单一	车辆行为	交互性
Bahram M ⁵⁶	简化交互	单一目标	驾驶意图	交互性
王培丞等 ⁵⁷	车辆交互	时间开销	车辆意图	交互性
TNT ⁵⁸	目标导向	预定义锚	行为预测	可解释性
Chandra R 等 ⁵⁹	空间交互	场景固定	行为预测	多模态预测
CoverNet ⁶²	近似行为	信息限制	运动行为	多模态预测
Girase H ⁶³	异构联合	数据限制	意图理解	环境复杂
HATN ⁶⁴	建图推理	交互不足	驾驶行为	交互性
CBP ⁶⁵	多元输入	车辆交互	驾驶交互	交互性
LiF 等 ⁶⁶	泛化推广	地图限制	驾驶意图	多模态预测

2 车辆轨迹预测方法应用场景

目前, 我国的自动驾驶技术已经进入到产品过渡期, 主流应用场景早已开始落地技术测试。车辆轨迹预测技术作为自动驾驶的核心技术之一, 应用场景十分丰富; 同时, 不同场景对轨迹预测提出的要求也不一样。根据应用场景是否开放划分为交通开放式场景和园区封闭式场景。交通开放式场景主要包括自动驾驶公共交通(公交车、出租车)场景、道路无人环卫场景、干线物流场景; 园区封闭式场景主要包括港口运输场景、园区无人环卫场景、矿区运输场景、园区物流作业场景、末端配送(快递、

外、生鲜卖等)场景、景区观光场景。交通开放式场景主要由城市主干路场景和高速公路场景组成, 园区封闭式场景主要为主干道路场景。两者可进一步划分为十字路口等交叉路口场景、换道场景和其他场景。

交通开放式场景对车辆轨迹预测技术要求较高, 因为其场景更为复杂, 需要考虑的因素较多。城市主干路静态场景需考虑交通信号灯、道路障碍物、道路标志、车道线、人行道、道路形状等各种道路参数。同时, 在动态场景中, 需考虑路段其他移动目标, 如行人、车辆等。高速公路场景相对来说要简单一些, 静态场景包括指示牌、匝道路口等; 动态场景则包括高速道路上的移动车辆、车辆换道行为等。此场景环境复杂多变, 车辆驾驶行为操作非常频繁, 交通事故频发, 应用车辆轨迹预测技术可提前估计、规划可行路线, 缓解交通压力, 从而有效地提高车辆反应时间, 减少交通事故的发生。

园区封闭式场景比较简单, 主要考虑自身行驶目的、园区内的行人、车辆等移动目标, 交叉路口、换道场景等道路环境信息。此场景是低速、精准、安全运营的场景, 使用车辆轨迹预测技术能够保证精准的行驶路线、提升工作的实效性和质量, 具有经济可行、便利服务、高效增收的优势。

3 车辆轨迹预测方法研究展望

当前阶段, 简单的基于传统机器学习和物理学模型轨迹预测方法精度较低, 需要更多地与交互感知模型结合才能保证一定的精度要求。随着大数据时代的来临和计算硬件的不断更新换代, 大量轨迹数据为基于深度学习、神经网络的轨迹预测研究提供了数据基础, 同时也获得一定的研究成果。但是, 基于深度学习的车辆轨迹预测方法模型庞大, 考虑场景复杂和各影响参数较多, 导致训练速度缓慢, 预测效果依赖于模型训练的优劣, 实际情况复杂多变时, 精准度和时效性亟须进一步提高。而基于车辆驾驶行为识别的轨迹预测方法需分析驾驶人的驾驶行为和驾驶需求, 因每个人的驾驶习惯存在不同会导致分析困难, 还需进一步根据不同驾驶人的驾驶特点进行更精细的识别以达到更理想的预测精度。综上所述, 对未来的车辆轨迹预测方法研究展望如下:

1) 车辆轨迹预测模型框架轻量化。

车辆轨迹预测方法最终是需要应用到智能驾驶汽车当中的, 主要在嵌入式设备相关平台上运行;

因此,需满足模型轻量化要求,计算量小、运行时间短、高实时性和高精度才能够在设备上稳定、高效地运行。

2) 多平台多元数据融合预测。

现有方法数据大多来源于已经处理好的数据集,少量研究基于车联网环境,获取周围车辆提供数据,或者仅基于自身传感系统;但是,数据的丰富程度决定是否能够得到更多信息,未来通过车联网、车路网甚至是车城网等数据平台,将车辆位置、道路信息、高精地图、路测感知、城市数据、交通数据等多元数据融合起来,可提供更有效、更准确的数据给模型使用,得到更丰富、更具体的特征,形成极强的前瞻性,大幅提高车辆轨迹预测精度。

3) 轨迹预测方法的泛化性、迁移性。

目前研究的车辆轨迹预测方法框架,一般基于对实际道路场景环境的简单模拟或者实际应用领域的特定场景(例如十字路口场景,两行车道换道场景),要实现全场景覆盖非常困难,但未来要想在复杂的现实环境下真正实现 L5 级自动驾驶,必须思考如何提高方法的泛化性和迁移性。如可在线学习、训练的模型^[35-36,44],通过离线模型提供基础预测能力,不断地吸收当前观察到的有效信息来更新模型,增强模型泛化性、迁移性。

4 结束语

综上分析,短时域方法存在局限性,轨迹预测效果一般,难以解决难点问题;而长时域方法基于大数据及深度学习算法,学习融合多源数据,可捕获场景多目标交互信息和车辆驾驶行为意图,应用到诸多实际场景中能较好地解决当前轨迹预测难点问题,但仍需要进一步突破相关挑战,从而更好地保证智能驾驶车辆高效、安全的运行。

参考文献:

[1] LEI H E. Driving intention recognition and behaviour prediction based on a double-layer hidden Markov model [J]. Journal of Zhejiang University SCIENCE C, 2012, 13(3): 208-217.

[2] 李峻翔. 无人车规划及车辆运动预测研究[D]. 长沙: 国防科技大学, 2019.

[3] GOLESTAN K, SOUA R, KARRAY F, et al. Situation awareness within the context of connected cars: A comprehensive review and recent trends[J]. Information Fusion, 2016, 29: 68-83.

[4] 胡灵. 基于 LSTM 的自动驾驶车辆轨迹预测方法研究[D]. 桂林: 桂林电子科技大学, 2021.

[5] HARDING J, POWELL G, YOON R, et al. Vehicle-to-vehicle communications: readiness of V2V technology for application[R]. United States. National Highway Traffic Safety Administration, 2014.

[6] ANDREWS S. Vehicle-to-vehicle(v2v) and vehicle-to-infrastructure(v2i) communications and cooperative driving[J]. in Handbook of Intelligent Vehicles, 2012, 16: 1121-1144.

[7] 刘文营, 刘伟, 崔晓川. 二自由度车辆动力学模型的扩展研究[J]. 中国测试, 2016, 42(S2): 76-79.

[8] SCHUBERT R, RICHTER E, WANIELIK G. Comparison and evaluation of advanced motion models for vehicle tracking[C]//2008 11th international conference on information fusion. IEEE, 2008: 1-6.

[9] FARDI B, SEIFERT I, WANIELIK G, et al. Motion-based pedestrian recognition from a moving vehicle[C]//2006 IEEE Intelligent Vehicles Symposium. IEEE, 2006: 219-224.

[10] HUANG J, TAN H S. Vehicle future trajectory prediction with a DGPS/INS-based positioning system[C]//American Control Conference. IEEE, 2006.

[11] LYTRIVIS P, THOMAIDIS G, AMDITIS A. Cooperative Path Prediction in Vehicular Environments[C]//Intelligent Transportation Systems, 2008. ITSC 2008. 11th International IEEE Conference on. IEEE, 2008.

[12] BRANNSTROM M, COELINGH E, SJOBERG J. Model-Based Threat Assessment for Avoiding Arbitrary Vehicle Collisions[J]. IEEE Transactions on Intelligent Transportation Systems, 2010, 11(3): 658-669.

[13] ZHANG R, CAO L, BAO S, et al. A method for connected vehicle trajectory prediction and collision warning algorithm based on V2V communication[J]. International Journal of Crashworthiness, 2017, 22(1): 15-25.

[14] XIE G, GAO H, QIAN L, et al. Vehicle trajectory prediction by integrating physics-and maneuver-based approaches using interactive multiple models[J]. IEEE Transactions on Industrial Electronics, 2017, 65(7): 5999-6008.

[15] XIAO W, ZHANG L, MENG D. Vehicle trajectory prediction based on motion model and maneuver recognition model and maneuver model fusion with interactive multiple models[J]. SAE International Journal of Advances and Current Practices in Mobility, 2020, 2: 3060-3071.

[16] BARTH A, FRANKE U. Where will the oncoming vehicle be the next second[C]//Proceedings of the 2008 IEEE Intelligent Vehicles Symposium. IEEE, 2008: 1068-1073.

[17] XU W, PAN J, WEI J, et al. Motion planning under uncertainty for on-road autonomous driving[C]//2014 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2014: 2507-2512.

[18] 乔少杰, 韩楠, 朱新文, 等. 基于卡尔曼滤波的动态轨迹预测算法[J]. 电子学报, 2018, 46(2): 418-423.

[19] BARRIOS C, MOTAI Y. Improving estimation of

- vehicle's trajectory using the latest global positioning system with Kalmanfiltering[J]. *IEEE Transactions on Instrumentation and Measurement*, 2011, 60(12): 3747–3755.
- [20] SCHULZ J, HUBMANN C, LÖCHNER J, et al. Multiple model unscented kalman filtering in dynamic bayesian networks for intention estimation and trajectory prediction[C]//2018 21st International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2018: 1467–1474.
- [21] ABBAS M T, JIBRAN M A, AFAQ M, et al. An adaptive approach to vehicle trajectory prediction using multimodelKalmanfilter[J]. *Transactions on Emerging Telecommunications Technologies*, 2020, 31(5): e3734.
- [22] LEFKOPOULOS V, MENNER M, DOMAHIDI A, et al. Interaction-aware motion prediction for autonomous driving: A multiple model kalmanfiltering scheme[J]. *IEEE Robotics and Automation Letters*, 2020, 6(1): 80–87.
- [23] SCHREIER M, WILLERT V, ADAMY J. An integrated approach to maneuver-based trajectory prediction and criticality assessment in arbitrary road environments[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(10): 2751–2766.
- [24] SCHULZ J, HUBMANN C, LÖCHNER J, et al. Interaction-aware probabilistic behavior prediction in urban environments[C]//2018 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2018: 3999–4006.
- [25] MA X, LIU G, HE B, et al. Trajectory Prediction Algorithm Based on Variational Bayes[C]//2018 IEEE CSAA Guidance, Navigation and Control Conference (CGNCC). IEEE, 2018: 1–6.
- [26] 张金辉, 李克强, 罗禹贡, 等. 基于贝叶斯网络的联网环境中跟车工况下的前车运动状态预测[J]. *汽车工程*, 2019, 41(3): 245–251, 274.
- [27] RIO P, OLIVEIRA R. Vehicle Trajectory Estimation based on Dynamic Bayesian Networks[C]//2020 IEEE 91st Vehicular Technology Conference (VTC2020Spring). IEEE, 2020: 1–5.
- [28] 彭曲, 丁治明, 郭黎敏. 基于马尔可夫链的轨迹预测[J]. *计算机科学*, 2010, 37(8): 189–193.
- [29] GAMBS S, KILLIJIAN M O, CORTEZ M N D P. Next place prediction using mobility markov chains[C]//Proceedings of the first workshop on measurement, privacy, and mobility. ACM, 2012: 1–6.
- [30] MALEKIAN R, KAVISHE A F, MAHARAJ B T, et al. Smart vehicle navigation system using hidden Markov model and RFID technology[J]. *Wireless Personal Communications*, 2016, 90(4): 1717–1742.
- [31] YE N, ZHANG Y, WANG R, et al. Vehicle trajectory prediction based on Hidden Markov Model[J]. *KSI Transactions on Internet and Information Systems*, 2016, 10(7): 3150–3170.
- [32] DEO N, TRIVEDI M M. Convolutional social pooling for vehicle trajectory prediction[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops. IEEE, 2018: 1468–1476.
- [33] MO X, XING Y, LV C. Interaction-aware trajectory prediction of connected vehicles using cnn-lstm networks[C]//IECON 2020 The 46th Annual Conference of the IEEE Industrial Electronics Society. IEEE, 2020: 5057–5062.
- [34] LIN L, LI W, BI H, et al. Vehicle trajectory prediction using LSTMs with spatial-temporal attention mechanisms[J]. *IEEE Intelligent Transportation Systems Magazine*, 2022, 14(2): 197–208.
- [35] GEISSLINGER M, KARLE P, BETZ J, et al. Watch-and-Learn-Net: Self-supervised Online Learning for Probabilistic Vehicle Trajectory Prediction[C]//2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). IEEE, 2021: 869–875.
- [36] GU J, SUN C, ZHAO H. Densentn: End-to-end trajectory prediction from dense goal sets[C]//Proceedings of the IEEE /CVF International Conference on Computer Vision. IEEE, 2021: 15303–15312.
- [37] GAO J, SUN C, ZHAO H, et al. Vector net: Encoding hd maps and agent dynamics fromvectorized representation[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 11525–11533.
- [38] LIANG M, YANG B, HU R, et al. Learning lane graph representations for motion forecasting[C]//European Conference on Computer Vision. Springer, Cham, 2020: 541–556.
- [39] MESSAOUD K, YAHIAOUI I, VERROUSTB A, et al. Attention based vehicle trajectory prediction[J]. *IEEE Transactions on Intelligent Vehicles*, 2020, 6(1): 175–185.
- [40] DA F, ZHANG Y. Path-Aware Graph Attention for HD Maps in Motion Prediction[C]//2022 International Conference on Robotics and Automation (ICRA). IEEE, 2022.
- [41] SONG H, LUAN D, DING W, et al. Learning to predict vehicle trajectories with model-based planning[C]//Conference on Robot Learning. PMLR, 2022: 1035–1045.
- [42] SCHMIDT J, JORDAN J, GRITSCHNEDER F, et al. CRAT-Pred: Vehicle Trajectory Prediction with Crystal Graph Convolutional Neural Networks and Multi-Head Self-Attention[C]//2022 International Conference on Robotics and Automation (ICRA). IEEE, 2022.
- [43] MERCAT J, GILLES T, ZOGHBY N, et al. Multi-head attention for multi-modal joint vehicle motion forecasting [C]//2020 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2020: 9638–9644.
- [44] MARCHETTI F, BECATTINI F, SEIDENARI L, et al. Mantra: Memory augmented networks for multiple trajectory prediction[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 7143–7152.

- [45] SONG H, DING W, CHEN Y, et al. Pip: Planning-informed trajectory prediction for autonomous driving[C]//European Conference on Computer Vision. Springer, Cham, 2020: 598–614.
- [46] RELLA E M, ZAECH J N, LINIGER A, et al. Decoder fusion rnn: Context and interaction aware decoders for trajectory prediction[C]//2021 IEEE/RSJ International Conference on Intelligent Robots and Systems (IROS). IEEE, 2021: 5937–5943.
- [47] NARAYANAN S, MOSLEMI R, PITTALUGA F, et al. Divide-and-conquer for lane-aware diverse trajectory prediction[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2021: 15799–15808.
- [48] YU D, LEE H, KIM T, et al. Vehicle trajectory prediction with lane stream attention-based LSTMs and road geometry linearization[J]. *Sensors*, 2021, 21(23): 8152.
- [49] YUAN Y, WENG X, OU Y, et al. AgentFormer: Agent-Aware Transformers for Socio-Temporal Multi-Agent Forecasting[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. IEEE, 2021: 9813–9823.
- [50] SHENG Z, XU Y, XUE S, et al. Graph-based spatial-temporal convolutional network for vehicle trajectory prediction in autonomous driving[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2022(EarlyAccess): 1–12.
- [51] ZYNER A, WORRALL S, NEBOT E. Naturalistic driver intention and path prediction using recurrent neural networks[J]. *IEEE transactions on intelligent transportation systems*, 2019, 21(4): 1584–1594.
- [52] 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.
- [53] 谢枫, 姜静涛, 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.
- [54] LEE D, KWON Y P, MCMAINS S, et al. Convolution Neural Network-based Lane Change Intention Prediction of Surrounding Vehicles for ACC[C]//2017 IEEE 20th International Conference on Intelligent Transportation Systems (ITSC). IEEE, 2018: 1–6.
- [55] LENZ D, DIEHL F, LE M T, et al. Deep neural networks for Markovian interactive scene prediction in highway scenarios[C]//2017 IEEE Intelligent Vehicles Symposium (IV). 2017: 685–692.
- [56] BAHRAM M, HUBMANN C, LAWITZKY A, et al. A combined model and learning-based framework for interaction-aware maneuver prediction[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(6): 1538–1550.
- [57] 王培丞. 车道中动态车辆轨迹预测方法研究[D]. 西安: 长安大学, 2020.
- [58] ZHAO H, GAO J, LAN T, et al. Tnt: Target-driven trajectory prediction[C]//4th Conference on Robot Learning (CoRL 2020), Cambridge MA, USA, 2020.
- [59] 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.
- [60] FENG Z X, LIU J, LI Y Y, et al. Selected model and sensitivity analysis of aggressive driving behavior[J]. *China Journal of Highway and Transport*, 2012, 25(2): 106–112.
- [61] DAHLEN E R, EDWARDS B D, TUBRÉ T, et al. Taking a look behind the wheel: An investigation into the personality predictors of aggressive driving[J]. *Accident Analysis & Prevention*, 2012, 45: 1–9.
- [62] PHAN-MINH T, GRIGORE E C, BOULTON F A, et al. Covernet: Multimodal behavior prediction using trajectory sets[C]//Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition. IEEE, 2020: 14074–14083.
- [63] GIRASE H, GANG H, MALLA S, et al. LOKI: Long Term and Key Intentions for Trajectory Prediction[C]//Proceedings of the IEEE/CVF International Conference on Computer Vision. 2021: 9803–9812.
- [64] WANG L, HU Y, SUN L, et al. Hierarchical Adaptable and Transferable Networks (HATN) for Driving Behavior Prediction[J]. *arXiv*, 2021(11): 2111.00788.
- [65] TOLSTAYA E, MAHJOURIAN R, DOWNEY C, et al. Identifying driver interactions via conditional behavior prediction[C]//2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021: 3473–3479.
- [66] LI F, LI X, LUO J, et al. Open-set Intersection Intention Prediction for Autonomous Driving[C]//2021 IEEE International Conference on Robotics and Automation (ICRA). IEEE, 2021: 13092–13098.