

基于深度学习的网联自主车辆换道轨迹预测方法

李文杰, 曲大义*, 张智, 韦良帅, 张文明

(青岛理工大学 机械与汽车工程学院, 青岛 266525)

摘要: 为了准确高效地获取周围车辆的运动信息状态, 网联自主车辆 (Connected Autonomous Vehicle, CAV) 应具备预测换道轨迹的能力。提出一种考虑车辆历史轨迹数据的长短时记忆 (Long Short-Term Memory, LSTM) 网络轨迹预测方法。筛选符合换道特征的轨迹数据, 构建多维度换道轨迹数据集; 采用 LSTM 的编码-解码器, 综合轨迹信息, 编码上下文向量; 解码上下文向量, 生成多目标换道轨迹预测结果。使用终点位移误差作为模型的评价指标, 本文模型与社交长短时记忆 (S-LSTM) 模型相比, 后 3 s 的终点位移误差分别降低了 12.5%、19.08%、18.68%; 与非局部社交长短时记忆 (NLS-LSTM) 模型相比, 后 3 s 终点位移误差分别降低了 6.44%、13.2%、13.95%, 提高了轨迹预测结果的准确性。

关键词: 网联自主车辆; 轨迹预测; 深度学习; 长短时记忆网络; 车辆历史轨迹

中图分类号: U491.1⁺4 **文献标志码:** A **文章编号:** 1673-4602(2026)02-0120-08

DOI: 10.3969/j.issn.1673-4602.2026.02.015

Lane changing trajectory prediction method for connected autonomous vehicles based on deep learning

LI Wenjie, QU Dayi*, ZHANG Zhi, WEI Liangshuai, ZHANG Wenming

(School of Mechanical and Automotive Engineering, Qingdao University of Technology, Qingdao 266525, China)

Abstract: In order to accurately and efficiently obtain the movement information status of surrounding vehicles, Connected Autonomous Vehicles (CAV) should have the ability to predict lane changing trajectories. A trajectory prediction method is proposed which is based on Long Short-term Memory (LSTM) network and considers vehicles' historical trajectory data. The trajectory data that conform to the characteristics of lane changing were screened to construct a multi-dimensional lane changing trajectory dataset. The LSTM encoding-decoder is used to synthesize the trajectory information and encode the context vector. The context dynamic vector is decoded to generate the prediction result of multi-objective lane changing trajectory. The endpoint displacement error is used as the evaluation index of the proposed method. Compared with the S-LSTM model, the endpoint displacement error of the proposed method in the last 3s is reduced by 12.5%, 19.08% and 18.68%, respectively; compared with the NLS-LSTM model, the endpoint displacement error of the proposed

收稿日期: 2024-08-19

基金项目: 国家自然科学基金 (52272311)

作者简介: 李文杰 (2000—), 男, 山东青岛人。硕士, 研究方向为车路协同。E-mail: 2302280952@qq.com。

* 通信作者: 曲大义 (1973—), 男, 山东青岛人。博士, 教授, 主要从事车路协同及安全控制方面的研究。

E-mail: dayiqu@qut.edu.cn。

method in the last 3s is reduced by 6.44%, 13.2% and 13.95%, respectively, which improves the accuracy of trajectory prediction results.

Key words: connected autonomous vehicle (CAV); trajectory prediction; deep learning; LSTM; vehicles' historical trajectory

网联自主车辆(Connected Autonomous Vehicle,CAV)已经成为自动驾驶领域中的重点,但是受到政策和价格等因素的影响,部分人还是会选择人工驾驶汽车(Human-driven Vehicle,HV),这就导致道路交通系统将长期处于人机混驾交通环境下^[1]。理想情况下的 CAV 能够实现对复杂交通场景的感知,融合车路云多维数据分析,执行合理驾驶决策。然而,受到驾驶员个人驾驶习惯和道路交通场景复杂性的影响,车辆轨迹无法直接获取,只能通过预测的手段来获取^[2]。

车辆行驶轨迹是指在特定时间内走过的路径,这些路径可以用连续的坐标点表示^[3]。轨迹预测方法可以分为 2 个大类,分别是基于物理模型与数学公式的方法和基于深度学习的方法。前者是利用牛顿运动定律或者几何角度来拟合车辆的历史位置数据,以便于对车辆之后一段时间内的轨迹进行预测。NELSON^[4]于 1989 年首次提出利用极坐标多项式来拟合历史运动轨迹,并做出预测。HOUENOU 等^[5]构建了一个依赖于固定的横向摆动角速度与加速度的行为模式,将 CYRA 模式与基于驾驶目标识别的模式进行整合,从而达到对汽车行进路径的预测。黑凯先等^[6]采用随机森林决策树方法对多样本时窗下的换道行为进行连续识别,得出能够有效反映车辆运行状态的参数,从而识别出未来的换道行为。WANG 等^[7]认为每一个自主变道(Discretionary Lane-Change,DLC)轨迹都可以通过一个五次多项式来表示,且可以近似地拟合 NGSIM 数据集中的 DLC 轨迹。谢枫等^[8]结合高精地图,通过感知识别车辆行为,根据识别结果得到轨迹集合,最终通过车道线曲率作为约束得到最优轨迹。然而,HV 在行驶过程中受驾驶员等因素影响,使得基于物理模型与数学公式的两种方法,在长时域预测的结果中,未能得到令人满意的效果。

随着深度学习技术的快速发展,解决轨迹预测问题的研究人员越来越倾向于使用深度学习框架。这类方法依赖于大量数据的训练,利用庞大的数据集对驾驶行为不断学习,最后通过输入的历史轨迹预测出车辆未来的轨迹。方华珍等^[2]在常规解码方式中加入示教解码方式,在解码器中引入示教解码和学习率 α ,在解码时不再单一使用上一时间步预测值作为下一时间步输入,而是将真实值和预测值混合使用作为下一时间步的输入来预测轨迹。NIKHIL 等^[9]认为 CNN 在时间建模方面优于 LSTM,其使用卷积层和全连接层实现了车辆未来轨迹的预测。蔡国庆等^[10]提出了一种三通道神经网络轨迹预测模型,结合 GNN、LSTM 和 CNN 3 种网络,通过权重计算可以预测车辆未来的移动轨迹。高凯等^[11]将车辆的横向位置数据视为主要特征,同时将周围环境数据作为辅助特征,这些信息输入一个基于多头注意力机制的 CNN-LSTM 网络,用于预测车辆的变道行为。KIM 等^[12]在编码-解码结构中引入多头注意力机制。通过车辆注意层和车道注意层对过去轨迹和车道信息融合,输出车辆未来轨迹的分布。DEO 等^[13]将社交池化层融入 LSTM 编码和解码的技术中,并且根据驾驶者的意愿来推断车辆的未来路径。基于深度学习的方法更好地弥补了前者在长时域预测中的不足,并取得了较为不错的效果。

基于物理模型的方法,无法在长时域的预测中取得令人满意的效果。基于深度学习的轨迹预测方法虽然在长时域预测中可以取得不错的效果,但是,当前预测与历史预测之间是存在着相关性的,现有的方法鲜有考虑。为了解决这一问题,引入考虑车辆历史轨迹数据的机制,将车辆历史轨迹数据输入到当前预测中,模拟连续预测之间的相关性。通过对车辆历史行驶轨迹数据的运用,使预测轨迹的稳定性、精确性得到提高。

1 深度学习长短时记忆网络模型

长短时记忆网络(Long Short-Term Memory,LSTM)的出现,解决了循环神经网络(Recurrent Neural Network,RNN)在训练阶段梯度丧失或者梯度爆炸的问题。HOCHREITER 等^[14]在 RNN 的基础上,创新性地引入了 3 个关键的门控机制:遗忘门 f_t 、输入门 i_t 和输出门 o_t ,以及 1 个新的内部状态 c_t ,如

图 1 所示。 c_t 负责以线性方式传递循环信息,并且将信息输出到隐藏层的外部状态 h_t 。遗忘门负责去除上一时刻无关的信息;输入门决定当前时刻输入多少信息;输出门控制当前时刻输出多少信息给外部状态。3 个门允许网络自主决定信息的流动,从而改善梯度消失或梯度爆炸的问题。

$$c_t = f_t \odot c_{t-1} + i_t \odot \tilde{c}_t \quad (1)$$

$$h_t = o_t \odot \tanh(c_t) \quad (2)$$

式中: \odot 为向量元素乘; c_{t-1} 为上一时刻的记忆单元状态; \tilde{c}_t 为通过非线性函数得到的候选状态。

$$f_t = \sigma(W_f x_t + U_f h_{t-1} + b_f) \quad (3)$$

$$i_t = \sigma(W_i x_t + U_i h_{t-1} + b_i) \quad (4)$$

$$o_t = \sigma(W_o x_t + U_o h_{t-1} + b_o) \quad (5)$$

$$\tilde{c}_t = \tanh(W_c x_t + U_c h_{t-1} + b_c) \quad (6)$$

式中: σ 为 sigmoid 激活函数,负责控制 3 个门的开合程度; \tanh 为双曲正切函数; W_f 、 W_i 、 W_o 、 W_c 和 U_f 、 U_i 、 U_o 、 U_c 分别为模型需要学习调整的 8 个权重矩阵; b_f 、 b_i 、 b_o 和 b_c 为模型需要学习的偏置项; x_t 为当前时间步的输入; h_{t-1} 为上一时刻的外部状态。

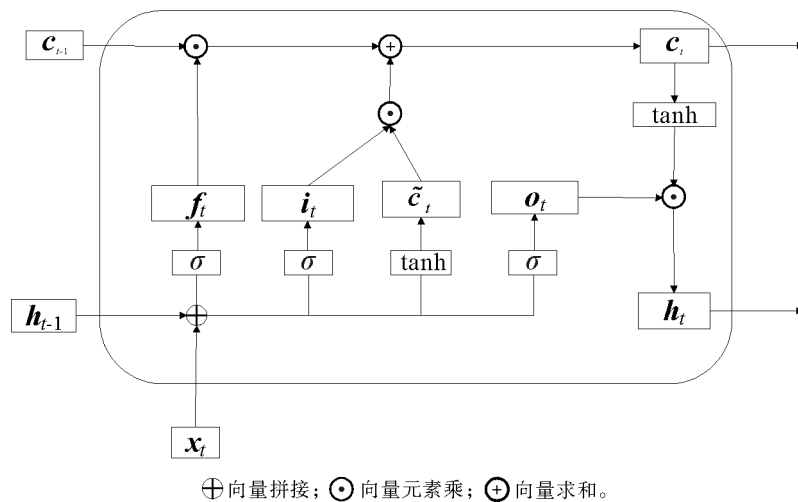


图 1 LSTM 框架

2 考虑车辆历史轨迹数据的 LSTM 换道轨迹预测模型

2.1 车辆历史轨迹数据机制

当一辆车稳定地行驶在直线路径时,连续预测的重叠部分几乎不变或者变化很小;当一辆车穿过繁忙的多车道十字路口时,连续预测可能非常不同,但是运动的目标是相同的。因此,连续预测之间的相关性会对轨迹预测的稳定性和准确性产生影响。在此,引入一种考虑车辆历史轨迹数据的机制,它将车辆历史轨迹数据纳入当前预测当中,通过输出的解码信息对连续预测之间的动态相关性进行建模。

解码器模块接收到编码器输出的上下文向量,对这些信息进行解码,最终输出预测的轨迹信息。在常规的 LSTM 解码训练中,解码器的初始状态设置为编码器输出的最后一个上下文向量,随后的每一步解码输入都是基于前一步的输出来生成,共循环 $\sigma - 1$ 步,最终输出长度为 σ 的轨迹预测序列,见图 2。这种方法虽然能够生成连续的预测序列,但在处理复杂的轨迹变化时,可能会因为忽略了车辆历史轨迹数据而影响预测的准确性。

考虑车辆历史轨迹数据机制的长短时记忆网络解码训练模型如图 3 所示。与常规的 LSTM 网络一样,初始状态为编码器输出的最后一项上下文向量,其核心改进在于它不仅考虑了上一时刻的输出,而且将之前所有时刻的车辆历史轨迹数据都纳入考虑。这种机制使得解码器能够在每一步生成预测时,都利

用到更全面的历史信息。此外,模型还能较好地捕捉到轨迹之间的相互依赖关系,每个解码器的输出都为后续的解码过程提供了丰富的车辆历史轨迹数据,从而提高了预测的连续性和稳定性。




图 2 LSTM 网络解码训练模型




图 3 考虑车辆历史轨迹数据机制的 LSTM 网络解码训练模型

2.2 换道轨迹预测模型建立

由于车辆在道路上行驶产生的轨迹数据为时间序列数据,LSTM 因为出色的时间序列处理能力,并且具备高效捕捉与记忆长期依赖特征的能力,所以 LSTM 在车辆轨迹预测中应用较广。模型以 LSTM 作为核心架构,加入了车辆历史轨迹数据机制,分为编码器和解码器两部分,见图 4。

编码器负责接收信息并对信息进行初步处理。接收的信息包括自车历史轨迹信息、周围车辆轨迹信息以及道路信息,这些数据不仅有位置坐标,还包括自车速度、加速度以及与周围车辆的相对位移、绝对速度和绝对加速度等。编码器将接收到的这些信息编码成一个能够用于当前交通环境综合状态的上下文向量。

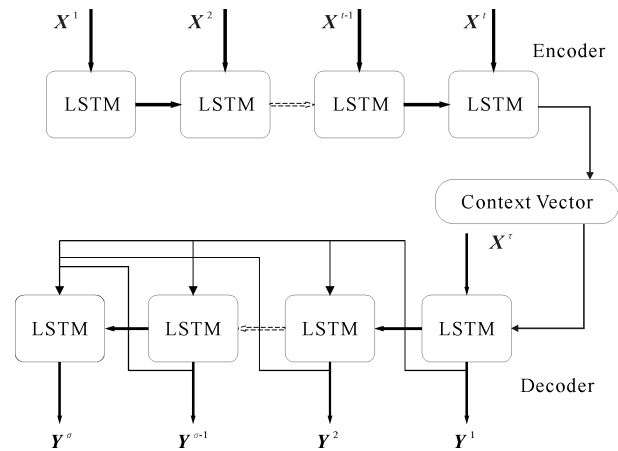


图 4 模型框架

解码器负责接收这些上下文向量,生成对未来一段时间内车辆的预测轨迹。模型在解码过程中,首先,接收编码器的最后一个上下文向量作为初始输入。然后,第 1 个解码器的输出不仅作为后一个解码器的输入,同时也作为后续所有解码器的输入。第 2 个解码器输出的信息,作为后面所有解码器的输入,依此类推。每一个解码器输出的信息,都作为后面所有解码器的输入。模型通过循环 $\sigma-1$ 步的解码过程,最终生成长度为 σ 的轨迹预测序列。将所有的轨迹预测序列连接起来,则生成了 1 条完整的车辆预测轨迹。考虑车辆历史轨迹数据机制的解码模式,不仅提高了预测的准确性,而且在处理复杂和多变的轨迹数据时,展现出了更强的鲁棒性。

3 数据处理

采用美国发布的公开数据集 NGSIM 对模型进行验证。根据研究内容选取数据集中 2 段高速公路的数据。该数据集记录了车辆的坐标位置、车辆速度、车辆加速度、当前车道位置、车辆类型和车辆编号等信息。数据集中的换道数据较少,以直线行驶轨迹数据为主,因此,要对数据集进行预处理,提取出需要的换道数据,增加车辆换道数据的比例。

3.1 滤波处理

由于 NGSIM 数据集发布时间较长,考虑到当时数据采集手段存在局限性,数据采集时可能会受到环境因素的干扰,因此这里利用小波分解法对原始数据集进行了滤波处理,以减少测量偏差对数据结果的影响,尤其是横向运动信息的采集。横向运动正是车辆换道行为的直接体现,所以对数据进行滤波处理会减少原始数据偏差对最终结果的不利影响,同时还能消除噪声。以 US101 公路 07:50—08:35 时段的 2 号车为例,对其换道数据展示滤波平滑效果,如图 5 所示。

3.2 轨迹提取

车辆换道轨迹预测模型需要基于大量换道轨迹进行学习,所以需要将NGSIM数据集中的换道轨迹提取出来。除了换道轨迹模型需要学习之外,为了保证数据的平衡性,直行轨迹信息也同样需要学习。依据数据集中的信息,将车辆行驶轨迹分为保持直行、向左换道和向右换道3类。为了简化计算,只考虑自行车及自行车两侧前后最近的6辆车,包括横纵方向坐标、速度、加速度及与周围车辆的位置、相对速度和相对加速度,共计42个维度特征参数。同时,考虑左右车道标志位,存在记为1否则为0,因此输入特征参数共计44个维度。

因为NGSIM数据集以直行轨迹为主,所以数据处理重点在于换道轨迹的提取。首先,对应车辆编号与车道编号,当某一时刻同一车辆编号对应车道编号发生变化,说明此时车辆跨越车道中心线进行了车道变更,并将该点标记为换道临界点。然后,以临界点为中心向后提取5s轨迹,向前提取3s轨迹,共计8s作为一个完整的车辆换道轨迹。根据车道编号的命名方式和变化标注车辆换道方向,当车道编号变化后,大于原来车道编号为向右换道,小于原来车道编号则为向左换道。同理,提取车辆编号与车道编号未发生变化的8s轨迹作为车辆直行轨迹。每一辆车的的历史数据都包含了换道时刻前3s的历史轨迹数据和后5s的预测轨迹数据,如图6所示,本数据集采集频率为10 Hz,所以输入序列为30,输出序列为50。

3.3 数据筛选

在数据预处理时,发现车辆保持直行轨迹的数据远多于车辆换道的数据,车辆向左换道的数据远多于车辆向右换道的数据,所以在这里以向右换道为基准,对向左换道和保持直行的数据进行随机采样,利用这种方法从3种行为中均匀地提取出38 829条数据,共计116 487条数据样本,分为10个组,按照6:2:2的比例划分出训练集、验证集和测试集。

为了加快模型的收敛速度,参照文献[2]的方法,对提取出的数据进行正则化处理,采用数据差分去除轨迹趋势,再利用特征缩放消除不同量纲对模型的影响:

$$x_{\text{diff}} = x_t - x_{t-1} \quad (7)$$

$$x_{\text{new}} = \frac{2x_{\text{ori}} - (x_{\text{max}} + x_{\text{min}})}{x_{\text{max}} - x_{\text{min}}} \quad (8)$$

式中: x_{diff} 为数据差分后的结果; x_{new} 为特征缩放后的结果; x_{ori} 为数据差分后的原始值; x_{max} 为数据差分后的最大值; x_{min} 为数据差分后的最小值。

4 模型验证

4.1 模型评价标准

本模型选择使用预测轨迹位置与实际车辆轨迹位置之间的终点位移误差(Displacement Error, DE)作为评价标准。DE可以更直观地反映出预测位置与实际位置之间的误差(E_d)。

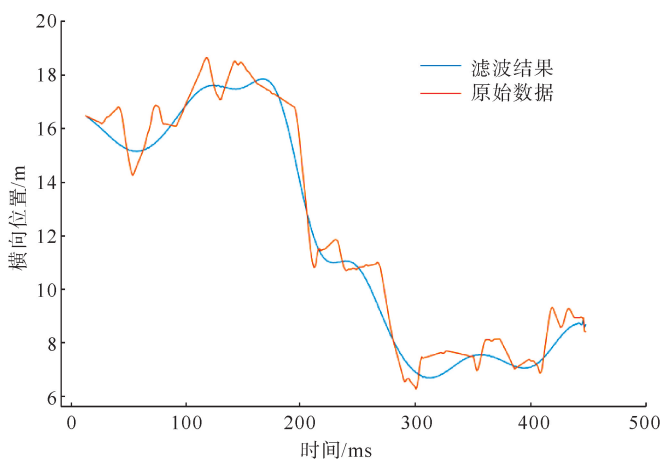


图5 小波分解法滤波平滑效果

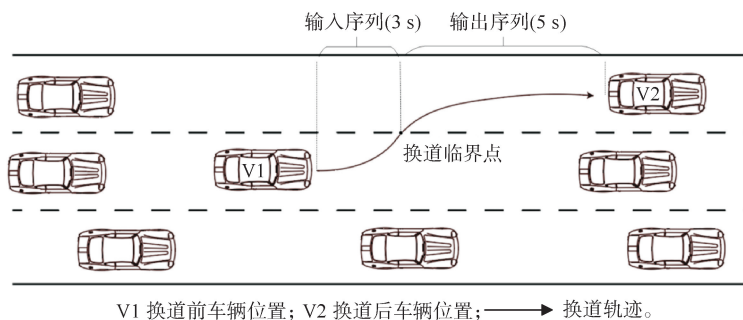


图6 换道轨迹序列提取示意

$$E_d = \sqrt{(x_t - \hat{x}_t)^2 + (y_t - \hat{y}_t)^2} \quad (9)$$

式中: x_t, y_t 为目标车辆在 t 时刻的实际轨迹位置; \hat{x}_t, \hat{y}_t 为目标车辆在 t 时刻的预测轨迹位置。

4.2 实验环境及模型参数

在基于 Python3.9 和 Pytorch2.0 的环境中对本模型进行构建和训练,并搭配了 NVIDIA GeForce RTX 4060(8G) GPU 和第 12 代英特尔处理器 i5-12600KF 和 32G 内存的硬件环境。

模型编码器与解码器层数均为 4 层,隐藏层为 128 层,特征参数 44 个维度,数据批次(batch_size)为 1024,训练的迭代次数(epochs)设置为 150 次,使用自适应矩估计(Adam)优化器,学习率为 0.001,输入序列长度为 30,输出序列长度为 50,损失函数选用均方误差(Mean Square Error, MSE)。为了减少计算时间和传播过程出现过拟合,在模型计算时加入 dropout,但是,过大的 dropout 值会导致模型过于随机,过小会导致模型过于依赖特定的神经元,综合考虑 dropout 取值 0.2。通过损失函数曲线来展示模型在训练集和测试集上的性能,如图 7 所示。在训练集和测试集中,当模型的迭代次数不断提升时,其损失值会逐步减少,直至达到一个稳定的状态,这说明在进行了训练之后模型可以更有效地用于预测。




图 7 损失变化曲线

4.3 实验结果分析

为了验证提出模型的预测是否准确,将本文提出的方法与现有模型进行对比:

社交长短时记忆(Social Long Short-Term Memory, S-LSTM)网络^[15]:引入社交池化层,允许近端序列的隐藏状态彼此共享。

卷积社交池化长短时记忆(Convolutional Social Pooling Long Short-Term Memory, CSP-LSTM)网络^[13]:在 S-LSTM 的基础上,加入了卷积层。

多模态长短时记忆(Multimodal Long Short-Term Memory, M-LSTM)网络^[16]:将融合驾驶行为加入到 LSTM 编码解码器中。

非局部社交长短时记忆(Non-Local Social Pooling Long Short-Term Memory, NLS-LSTM)网络^[17]:基于 LSTM 编码解码器的非局部社交汇聚机制,引入多头注意力机制。

本文方法:本文提出的考虑车辆历史轨迹数据的 LSTM 车辆轨迹预测方法。

将从 NGSIM 数据集提取的数据输入上述模型中,并进行对比验证,得到的结果如表 1 所示。

表 1 不同模型的评价指标结果

数据集	预测时域/s	S-LSTM	CSP-LSTM	M-LSTM	NLS-LSTM	本文方法
NGSIM	1	0.65	0.61	0.58	0.56	0.48
	2	1.31	1.27	1.26	1.22	1.19
	3	2.16	2.09	2.12	2.02	1.89
	4	3.25	3.10	3.24	3.03	2.63
	5	4.55	4.37	4.66	4.30	3.70

通过表1可知,现有的LSTM轨迹预测模型在3 s内的预测结果与实际轨迹差距较小,在3~5 s的预测结果与实际轨迹差距较大,但是与其他模型对比,本文模型在3~5 s内的预测结果要更为接近实际轨迹。模型在3 s内的左右换道预测实时性与准确率关系如图8所示。可见,将已输出的车辆历史轨迹用于后续解码,在解码时考虑更多的轨迹信息,提高了模型的预测精度,实时性上随着临近行为发生时刻越近,准确率越高,在1.5 s后更加精准。也说明了考虑车辆历史轨迹数据的解码方式具有一定的应用价值。




图8 实时性与准确率关系

5 结论

本文提出了一种考虑车辆历史轨迹数据的LSTM网络车辆轨迹预测模型,在解码的过程中,将当前一步解码后输出的信息作为后续每一步解码的输入,通过车辆历史轨迹数据来提高预测结果的稳定性和准确性。借助NGSIM数据集对模型进行了训练和验证,并与现有的模型进行横向对比分析,结果表明,本模型在相同时域内预测结果精度有所提高,3~5 s的预测结果精度提升更加明显。与效果较差的S-LSTM相比,后3 s的终点位移误差分别降低了12.5%、19.08%、18.68%;与除本文模型外效果最好的NLS-LSTM相比,后3 s的终点位移误差分别降低了6.44%、13.2%、13.95%。虽然预测结果准确性有所提高,但是在长时域的预测当中误差依然较大,仍旧需要继续改进。

参考文献(References):

- [1] LI L, OTA K, DONG M. Humanlike driving: Empirical decision-making system for autonomous vehicles[J]. IEEE Transactions on Vehicular Technology, 2018, 67(8): 6814-6823.
- [2] 方华珍, 刘立, 肖小凤, 等. 混合示教长短时记忆网络的车辆轨迹预测研究[J]. 交通运输系统工程与信息, 2023, 23(4): 80-87.
FANG Huazhen, LIU Li, XIAO Xiaofeng, et al. Vehicle trajectory prediction based on mixed teaching force long short-term memory[J]. Journal of Transportation Systems Engineering and Information Technology, 2023, 23(4): 80-87.
- [3] 韩天立, 马驰, 胡林治. 基于GCN-Transformer的车辆换道行为建模与轨迹预测方法[J]. 建模与仿真, 2024, 13(3): 2754-2771.
HAN Tianli, MA Chi, HU Linzhi. A vehicle lane-changing behavior modeling and trajectory prediction method based on GCN-Transformer[J]. Modeling and Simulation, 2024, 13(3): 2754-2771.
- [4] NELSON W. Continuous-curvature paths for autonomous vehicles[C]//IEEE International Conference on Robotics and Automation, Scottsdale, 1989: 1260-1264.
- [5] HOUENOU A, BONNIFAIT P, CHERFAOUI V, et al. Vehicle trajectory prediction based on motion model and maneuver recognition[C]//IEEE International Conference on Intelligent Robots and Systems. Tokyo, 2013: 4363-4369.
- [6] 黑凯先, 曲大义, 周警春, 等. 基于随机森林决策树的行驶车辆换道行为识别[J]. 青岛理工大学学报, 2020, 41(1): 115-120.
HEI Kaixian, QU Dayi, ZHOU Jingchun, et al. Lane-changing behavior recognition of running vehicles based on random forest[J]. Journal of Qingdao University of Technology, 2020, 41(1): 115-120.
- [7] WANG Q, LI ZH, LI L. Investigation of discretionary lane-change characteristics using next-generation simulation data sets[J]. Journal of Intelligent Transportation Systems, 2014, 3(18): 246-253.
- [8] 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 Jingtao, 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.
- [9] NIKHIL N, MORRIS B T. Convolutional neural network for trajectory prediction[C]//European Conference on Computer Vision Workshops. Munich, 2018: 186-196.

- [10] 蔡国庆,刘玲,张冲,等. 基于 GNN-LSTM-CNN 网络的 6G 车辆轨迹预测算法[J]. 西安电子科技大学学报,2023,50(3):50-60.
CAI Guoqing,LIU Ling,ZHANG Chong, et al. Algorithm for prediction of the 6G vehicle trajectory based on the GNN-LSTM-CNN network[J]. Journal of Xidian University,2023,50(3):50-60.
- [11] 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.
GAO Kai,LI Xunhao,HU Lin, et al. Lane change intention prediction of CNN-LSTM based on multi-head attention[J]. Journal of Mechanical Engineering,2022,58(22):369-378.
- [12] KIM H,KIM D,KIM G, et al. Multi-head attention based probabilistic vehicle trajectory prediction[C]//IEEE Intelligent Vehicles Symposium. Las Vegas,2020:1720-1725.
- [13] 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. Salt Lake City,2018:1468-1476.
- [14] HOCHREITER S,SCHMIDHUBER J. Long short-term memory[J]. Neural Computation,1997,9(8),1735-1780.
- [15] ALAHI A,GOEL K,RAMANATHAN V, et al. Social LSTM: Human trajectory prediction in crowded spaces[C]//Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Las Vegas,2016:961-971.
- [16] CUI H,RADOSAVLJEVIC V,CHOU F C, et al. Multimodal trajectory predictions for autonomous driving using deep convolutional networks[C]//IEEE International Conference on Robotics and Automation. Montreal,2019:2090-2096.
- [17] MESSAOUD K,YAHIAOUI I,VERROUST-BLONDET A, et al. Non-local social pooling for vehicle trajectory prediction[C]//IEEE Intelligent Vehicles Symposium. Paris,2019:975-980.

(责任编辑 张晓靖;英文校审 程文华)

(上接第 107 页)

- [18] ZHANG Q,XU G Y,IWAI K. Effect of an AC magnetic-field on the dead-zone range of inclusions in the circular channel of an induction-heating tundish[J]. ISIJ International,2022,62(1):56-63.
- [19] SONG S Y,ZHOU X,LI L, et al. Numerical simulation and experimental validation of SiC nanoparticle distribution in magnesium melts during ultrasonic cavitation based processing of magnesium matrix nanocomposites[J]. Ultrasonics Sonochemistry,2015,24:43-54.
- [20] 李晓谦,邓静,林森. 7050 铝合金超声空化气泡动力学数值模拟[J]. 特种铸造及有色合金,2013,33(5):395-399.
LI Xiaoqian,DENG Jing,LIN Sen. Dynamics numerical simulation of ultrasonic cavitation bubble in 7050 aluminum alloy[J]. Special Casting & Nonferrous Alloys,2013,33(5):395-399.
- [21] VIVÈS C. Effects of forced electromagnetic vibrations during the solidification of aluminum alloys;Part II. Solidification in the presence of colinear variable and stationary magnetic fields[J]. Metallurgical and Materials Transactions B,1996,27(3):457-464.
- [22] VIVÈS C. Grain refinement in aluminum alloys by means of electromagnetic vibrations including cavitation phenomena[J]. Journal of Metals,1998,50(2):1-9.
- [23] 张艾萍,杨钊,夏荣涛,等. 超声频率和管型对超声空化效应的影响研究[J]. 化工机械,2016,43(4):517-521.
ZHANG Aiping,YANG Zhao,XIA Rongtao, et al. Influences of ultrasonic frequency and tube types on ultrasonic cavitation effect[J]. Chemical Engineering & Machinery,2016,43(4):517-521.

(责任编辑 赵金环;英文校审 刘成龙)