

基于 Transformer-MLSTM 联合模型的 营运车辆行驶轨迹预测

杜宇程, 朱立伟, 李会民, 陈方华
(交通运输部公路科学研究院, 北京 100088)

摘要: 本文选取 NGSIM 数据集中的运营车辆行驶数据作为研究对象, 采用小波降噪方法处理干扰数据, 进而提出一种基于 Transformer-MLSTM 的车辆换道轨迹预测模型。该模型集成了 Transformer 模块的多头注意力机制和高效并行处理能力, 可对周边车辆运动轨迹特征进行权重计算; MLSTM 模块在捕获长期依赖的同时, 加强各层间的信息传递, 从而增强模型的整体表达能力。结果表明: 在 Transformer-MLSTM 联合模型最优超参数组合下, 预测车辆横向和纵向轨迹变化的 RMSE 值分别达到 0.364 和 1.492, 该模型的预测速度和准确度均优于采用 LSTM、MLSTM 和 Transformer 等方法建立的单一网络模型。

关键词: 行驶数据; NGSIM; 换道轨迹预测; LSTM; Transformer

中图分类号: U491.1⁺4; TP183 文献标志码: A DOI: 10.15917/j.cnki.1006-3331.2026.01.003

Prediction of Operating Vehicle Driving Trajectory Based on Transformer-MLSTM Joint Model

DU Yucheng, ZHU Liwei, LI Huimin, CHEN Fanghua
(Research Institute of Highway Ministry of Transport, Beijing 100088)

Abstract: This paper selects operational vehicle trajectory data from NGSIM dataset as the research subject, employs a wavelet denoising method to address data noise, and proposes a Transformer-MLSTM-based model for predicting vehicle lane-changing trajectories. The model integrates the multi-head attention mechanism and efficient parallel processing ability of the Transformer module to calculate the weight of the motion trajectory characteristics of the surrounding vehicles. Simultaneously, the MLSTM module captures long-term dependencies in trajectory sequences, enhancing information transfer and further improving model performance. The results show that under the optimal hyper-parameter combination of the Transformer-MLSTM joint model, the RMSE values for predicting the lateral and longitudinal trajectory changes of the vehicle reach 0.364 and 1.492, respectively. The prediction speed and accuracy of the model are better than the single network model established by LSTM, MLSTM and Transformer.

Key words: driving data; NGSIM; lane change trajectory prediction; LSTM; Transformer

道路交通事故之所以一直广受社会关注, 是因为事故一旦发生, 会立刻降低道路通行能力与效率, 并引发不同程度的交通拥堵^[1]。

根据交通事故统计数据, 驾驶员人为因素在道路交通事故成因中占比高达 80%。其中, 因变道操作不当而引发的交通事故尤为常见, 主要原因在于变道是

日常驾驶中最为频繁的动作之一^[2]。值得注意的是, 在各类车辆的变道操作中, 大型营运车辆引发的风险尤为突出。这主要源于大型车辆在外廓尺寸、载重、动力性能及车道空间占用等方面与乘用车存在显著差异。这些差异使得其在变道时需要更大的安全间隙和更广的视野, 然而在实际道路环境中, 这些条件

收稿日期: 2025-05-26。

第一作者: 杜宇程 (1992—), 男, 硕士, 助理研究员, 主要从事新能源商用车智能化、网联化、数字化等设计研发相关工作。
E-mail: yc.du@rioh.cn。

往往难以得到充分满足。因此,大型营运车辆变道时操作不当的概率相对更高;而一旦发生事故,其较大的质量与惯性又会导致更为严重的后果^[3]。基于此,若能预判车辆的换道趋势并准确预测其行驶轨迹,可有效帮助驾驶员提前识别风险,从而规避因操作不当或判断失误而引发的危险。

1 车辆行驶轨迹预测技术研究现状

目前,车辆轨迹预测的研究方法主要分为两类:基于物理模型的方法与数据驱动方法。基于物理模型的方法是依据车辆运动学或动力学建立数学模型,通过求解模型来解析车辆实时状态,进而推算出其未来运动轨迹。然而,这类方法存在固有局限:所构建的模型通常仅适用于特定交通场景,泛化能力不足;且当预测时域延长时,其预测精度会急剧下降。相比之下,数据驱动方法不依赖于物理方程,而是依靠从历史数据中学习规律进行预测。随着深度学习技术进步与多源异构数据采集能力提升,该方法已成为当前的研究重点。然而,传统机器学习模型(如支持向量机^[4]、隐马尔可夫模型^[5-6])受限于算法架构,通常只能处理单一时间序列预测任务,难以有效建模车辆间的动态交互。而多车协同预测本质上属于多序列联合预测任务,对模型的特征能力要求更高,传统模型因参数规模有限,难以适应复杂交通场景的建模需求。

为解决上述轨迹预测中交互建模与泛化能力不足的问题,本文基于开源数据集,研究多车信息交互机制及其对轨迹预测的影响,并提出一种集成 Transformer 与 Multi-LSTM 的建模方法(简称 Transformer-MLSTM)。该方法利用 Transformer 模块的多头注意力机制高效计算周边车辆轨迹的交互权重;同时,通过堆叠长短期记忆网络(Long Short-Term Memory, LSTM)模块捕获长期依赖、实现层级间并行信息传递,从而显著增强模型的表达能力,使其在车辆换道轨迹预测中表现更为精确与稳定。因此,对营运车辆轨迹预测进行深入研究,不仅有助于提升道路行驶安全,也可为降低事故发生率提供技术支持。主要研究内容如下:

1) 车辆轨迹数据预处理。首先,从下一代交通仿真(Next Generation Simulation, NGSIM)数据集中提取有效的车辆运动信息;随后,采用小波降噪方法对原始轨迹数据进行去噪处理;在此基础上,分析车辆

换道轨迹与特征量之间的关系,构建表征车辆间相互作用的交互矩阵,从而为后续模型训练提供高质量的数据基础。

2) 预测模型构建与验证。首先,基于 Transformer-MLSTM 架构,采用滑动时间窗方法构建车辆轨迹预测模型;随后,调节时间窗长度以优化模型输入结构,从而提升其性能;在此基础上,完成模型训练,并将其与多种基于单一模型的预测方法进行系统对比;最后,可视化和对比分析的综合结果表明,Transformer-MLSTM 在换道轨迹预测任务中的性能更优越。

2 数据预处理

2.1 变道轨迹数据筛选与提取

为构建模型所需的训练样本,本文基于 NGSIM 数据集,对车辆变道轨迹数据进行筛选与特征增强。首先对文中涉及的车辆进行定义:将正在执行变道操作的车辆称为主车;将与主车存在空间交互关系的车辆称为关联车辆。具体包括四类车辆:主车所在车道的前车与后车,以及目标车道的前车与后车。在此基础上,数据处理的具体步骤如下:

1) 数据重新编辑。依据轨迹预测任务的需求,从原始数据中筛选并整理关键信息,定义核心属性集。该集合主要包括:主车的车辆编号、车道编号、位置坐标(横纵坐标)、行驶速度、纵向加速度,以及关联车辆的行驶数据(位置、速度)和相关时间信息。

2) 增加有效数据信息。通过车辆的位置和时间信息进行二次计算,得到主车及关联车辆的横向速度和横向加速度。其中,车辆的横向瞬时加速度 a_{xi} 的计算公式如式(1)所示。

$$a_{xi} = (x_{i+1} - x_i) / \Delta t^2 \quad (1)$$

式中: x_i 与 x_{i+1} 为车辆当前时刻横向坐标与下一时刻的横向坐标; Δt 为两个相邻时刻的数据间隔时间, $\Delta t = 0.1 \text{ s}$ 。

3) 变道轨迹数据筛选。首先,依据车辆编号提取轨迹数据,识别并定位主车的变道时刻。其次,获取该时刻主车与所有关联车辆的编号,以建立完整的空间交互关系。然后,提取主车与关联车辆在对应时刻窗内的行驶数据。最后,为确保数据质量,过滤掉存在缺失值的车辆轨迹记录。

2.2 小波降噪

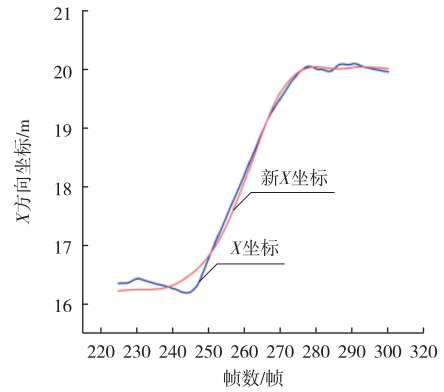
小波降噪基于其时频局部化能力,可在变换中同步保留信号的时频信息,其数学基础是连续小波变

换, 如式(2)所示。相比之下, 传统傅里叶变换主要提供全局频域表征, 难以刻画非稳态信号的局部瞬态特征。因此, 在非稳态信号的降噪任务中, 小波降噪的精度通常高于傅里叶变换^[7]。


$$W_{\Psi}(a, b) = \frac{1}{\sqrt{|a|}} \int_{-\infty}^{\infty} f(t) \Psi^* \left(\frac{t-b}{a} \right) dt \quad (2)$$

式中: $W_{\Psi}(a, b)$ 为小波变换的系数, 表示信号在尺度 a 和位置 b 处的分量; $f(t)$ 为输入信号; a 为尺度因子, 控制小波的伸缩程度; b 为平移因子, 控制小波的位置; $\frac{1}{\sqrt{|a|}} \cdot \Psi^* \left(\frac{t-b}{a} \right)$ 为能量归一化后的小波函数。

在进行小波变换时, 小波基函数需要根据实际需求选取。常用的小波基函数有 Haar 函数、Daubechies 函数、Symlets 函数和 Morlet 函数等。通过对比不同小波基函数对车辆轨迹数据的降噪效果, 发现采用 Symlets 函数并将滤波器长度设置为 11 时, 降噪性能最优。基于该最优配置对部分车辆换道轨迹开展处理, 随机选取车辆 1 和车辆 2 作为分析对象, 经滤波算法平滑后, 两车在左、右换道工况下的横向坐标轨迹如图 1 所示。经小波降噪处理后, 轨迹曲线的平滑性显著提升, 波动性得到有效抑制。同时, 该方法在去除噪声的过程中, 完整保留了轨迹的整体变化趋势与有效特征。




(c) 车辆 1 左换道




(d) 车辆 2 左换道

图 1 滤波算法平滑后的横向坐标轨迹



(a) 车辆 1 右换道



(b) 车辆 2 右换道

3 模型整体架构

为提升车辆轨迹预测的准确性与对复杂交互场景的适应能力, 本研究构建了 MLSTM 与 Transformer 的联合模型, 其整体框架如图 2 所示。该模型旨在综合二者的互补优势: 一方面利用 Transformer 固有的高效并行计算能力, 对关联车辆的上下文交互关系进行建模, 以提取周边车辆的轨迹特征; 另一方面借助 MLSTM 捕捉轨迹序列中的长期时间依赖, 完成精细化序列建模。模型采用级联设计, 即将 MLSTM 置于 Transformer 之后作为序列处理模块。其工作流程如下: 首先, 由 Transformer 网络提取关联车辆轨迹的上下文特征; 随后, 将其输出特征作为 MLSTM 的输入, 进一步捕捉序列中的长距离依赖关系。该设计使得两者形成协同工作机制, 共同增强了模型在多车协同换道预测中的整体性能。

模型搭建的具体实现步骤如下: ①数据准备。整合预处理后的车辆轨迹信息, 构成模型输入的基础数

据集。②输入结构化。依据车辆位置编码对数据进行排序与对齐,构建为规范的时序输入序列。③模型构建与特征处理。搭建 Transformer 与 MLSTM 的级联架构。在该架构中,先由 Transformer 编码器提取

上下文交互特征,再将此特征输入 MLSTM 网络,以进行时序重构与长程依赖建模。④轨迹输出。通过全连接层及非线性激活函数对处理后的特征进行解码,输出主车在各时刻的平面坐标位置。

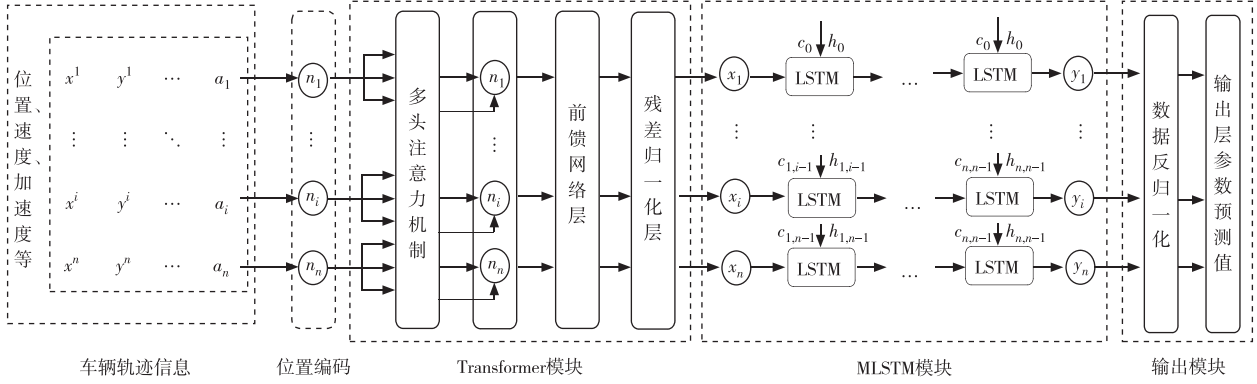


图2 模型整体框架

3.1 Transformer 神经网络模型

针对换道场景中多车交互的复杂性,本模块采用多头注意力机制对多车辆特征进行动态建模。该机制通过并行多个注意力头,同时捕捉主车和关联车辆间的相对速度、距离、航向角等特征的时空关联,从而准确评估主车对关联车辆轨迹的影响。在此基础上,模块引入残差连接结构,将注意力层的输出与原始输入特征逐元素相加,以此确保底层行驶参数(如加速度、角速度)能够无损传递至后续网络层,保障了关键信息在复杂交互建模过程中的完整性与可用性。

1) 多头注意力机制层。为更全面地捕捉车辆间的复杂交互,模型采用多头注意力机制,该机制通过将矩阵 Q 、 K 、 V 并行映射到多个子空间,以提取不同子空间中的互补轨迹特征。其中,矩阵 Q 、 K 、 V 由车辆输入信息的位置编码和其权重矩阵相乘得出,多头注意力机制计算如式(3)所示。

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) W^O \quad (3)$$

式中: h 为注意力头总数;矩阵 W_i^Q 、 W_i^K 、 W_i^V 为第 i 个注意力头 ($i=1, \dots, h$) 的线性投影矩阵; head_i 为第 i 个注意力头的输出, $\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V)$, for $i=1, \dots, h$; Concat 运算是将 h 个注意力头的输出 $\text{head}_1, \dots, \text{head}_h$ 在特征维度上拼接起来; W^O 为输出投影矩阵,用于将拼接后的特征线性变换回模型原始维度。多头注意力机制示意图如图3所示。

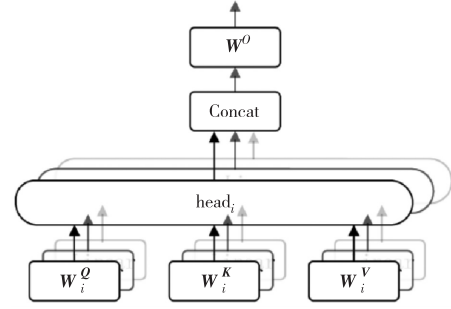


图3 多头注意力机制示意图

2) 前馈网络层。前馈网络层包含两层全连接层,可将 Transformer 模块提取到的车辆运动轨迹特征输出成适合 MLSTM 模块使用的信息,其计算公式见式(4)。

$$\text{FFN}(X) = \max(0, XW_1 + b_1) W_2 + b_2 \quad (4)$$

式中: X 为数据特征输入; W_1 和 W_2 分别为第一层和第二层全连接的权重矩阵; b_1 和 b_2 分别为第一层和第二层全连接的偏置向量。

3) 残差归一化层。该层包含残差连接和层标准化两部分。残差连接旨在防止模型训练中出现梯度消失问题,其实现方式是将网络输出的车辆运动轨迹特征与原始输入特征直接相加。层标准化函数可减小数据偏差,防止出现拟合情况,其计算如式(5)~式(7)所示。

$$\text{LayerNorm}(X) = \gamma \cdot \frac{X - \mu}{\sqrt{\delta^2 + \epsilon}} + \beta \quad (5)$$

$$B = \text{LayerNorm}(\text{MultiHead}(A) + A) \quad (6)$$

$$m = \text{LayerNorm}(\text{FFN}(B) + B) \quad (7)$$

式中: γ 为缩放参数; β 为网络参数; μ 和 δ^2 分别为输入 X 的均值和方差; ε 为极小值常数; B 为前馈网络的输入; A 为多头注意力模块的输入特征张量; m 为残差归一化层的输出, $m = [m_{i-N+1} \cdots m_{i-1} m_i]^T$ 。

3.2 LSTM 模块

LSTM 模块由不同数量的记忆单元组成, 可筛选输入的 vehicle 运动轨迹特征信息。该记忆单元通过遗忘门、输入门和输出门对 vehicle 运动特征信息进行筛选、更新与输出^[8]。

MLSTM 模块由多个 LSTM 网络层叠加而成。该模块既能获取 vehicle 信息的长期持续记忆, 也能实现更精准的运动轨迹预测。本文模型建立的核心是利用 Transformer 模块中的多头注意力机制对 vehicle 运动轨迹特征进行权重计算。MLSTM 模块在捕获长期依赖的同时, 加强各层间的信息传递, 增强模型的整体表达能力, 以提升周边 vehicle 换道轨迹预测的精确性和稳定性。

4 验证与分析

4.1 NGSIM 轨迹数据

NGSIM 数据集通过同步数字摄像机网络, 采集了位于美国不同地区 4 种路段上的 vehicle 轨迹信息, 包括洛杉矶的 US-101 公路、旧金山的第 80 号 (I-80) 州际公路、洛杉矶的 Lankershim 公路及乔治亚州的 Peachtree 公路。其中, 前 2 种路段均为双向十车道的高速公路; 后 2 种路段均为双向八车道的普通公路; 4 种路段的采样频率均为 10 Hz。该数据集广泛应用于交通车辆驾驶行为研究。上述 4 个路段的基本情况见表 1。

表 1 数据采集情况

路面名称	研究路段长度/m	数据采样频率/Hz	观测车数量
US-101	600	10	6 205
I-80	500	10	4 980
Lankershim	500	10	3 506
Peachtree	600	10	3 780

本文研究高速公路营运车辆的换道行为, 需要能够体现复杂交通流, 特别是城市快速路混合运行特征的轨迹数据。US-101 路段因其包含主线、辅路及交织区等复合结构, 交通状态复杂, 能较好地满足这一要求。因此, 选取其轨迹数据作为主要研究对象。

4.2 轨迹输入数据构建

为服务于模型训练, 需对 vehicle 轨迹数据进行结构化处理。具体处理流程如下: 首先, 依据已定义的 vehicle 角色 (主车与关联 vehicle) 对轨迹数据进行区分; 随后, 提取并融合这两类数据的特征, 以构建能够表征 vehicle 间交互场景的输入信息。特征融合后的整体构成矩阵 S , 如式 (8) 所示。

$$S = \{V_0^{(t)}, V_{0,a}^{(t)}, V_{0,b}^{(t)}, V_{1,a}^{(t)}, V_{1,b}^{(t)}\} \quad (8)$$

式中: $V_0^{(t)}$ 为 t 时刻主车的运动信息; $V_{0,a}^{(t)}$ 为 t 时刻主车所在车道后车的运动信息; $V_{0,b}^{(t)}$ 为 t 时刻主车所在车道前车的运动信息; $V_{1,a}^{(t)}$ 为 t 时刻目标车道后车的运动信息; $V_{1,b}^{(t)}$ 为 t 时刻目标车道前车的运动信息。

在 t 时刻 vehicle 的行驶特征信息 $V_a^{(t)}$ 如式 (9) 所示。

$$V_a^{(t)} = \{x^{(t)}, y^{(t)}, a_x^{(t)}, a_y^{(t)}, v_x^{(t)}, v_y^{(t)}\} \quad (9)$$

式中: $x^{(t)}$ 和 $y^{(t)}$ 分别为主车 t 时刻在路段参考坐标系中的横坐标和纵坐标; $a_x^{(t)}$ 和 $a_y^{(t)}$ 分别为主车 t 时刻的横向加速度与纵向加速度; $v_x^{(t)}$ 和 $v_y^{(t)}$ 分别为 t 时刻主车的横向速度和纵向速度。

通过将主车和关联 vehicle 的运动信息按照时间顺序编码成矩阵 H , 将 vehicle 轨迹数据组合成一个包含对应时刻轨迹信息的矩阵, 该矩阵不仅记录了 vehicle 的运动轨迹信息, 还包含了 vehicle 周围环境信息, 以便后续的输入与模型训练。变量矩阵 H 信息示例如式 (10) 所示。

$$H = \begin{bmatrix} x^{(1)} & \cdots & x^{(n)} \\ y^{(1)} & \cdots & y^{(n)} \\ a_x^{(1)} & \ddots & a_x^{(n)} \\ a_y^{(1)} & \ddots & a_y^{(n)} \\ v_x^{(1)} & \cdots & v_x^{(n)} \\ v_y^{(1)} & \cdots & v_y^{(n)} \end{bmatrix} \quad (10)$$

式中: $x^{(1)} \cdots x^{(n)}$ 为 n 个 vehicle 的横坐标信息; $y^{(1)} \cdots y^{(n)}$ 为 n 个 vehicle 的纵坐标信息; $a_x^{(1)} \cdots a_x^{(n)}$ 为 n 个 vehicle 的横向加速度信息; $a_y^{(1)} \cdots a_y^{(n)}$ 为 n 个 vehicle 的纵向加速度信息; $v_x^{(1)} \cdots v_x^{(n)}$ 为 n 个 vehicle 的横向速度信息; $v_y^{(1)} \cdots v_y^{(n)}$ 为 n 个 vehicle 的纵向速度信息。

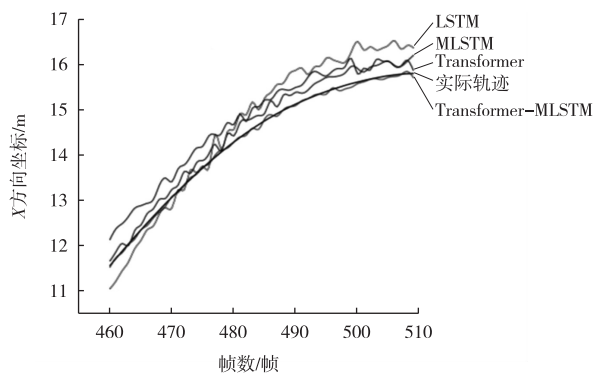
5 预测结果评价

5.1 定性分析

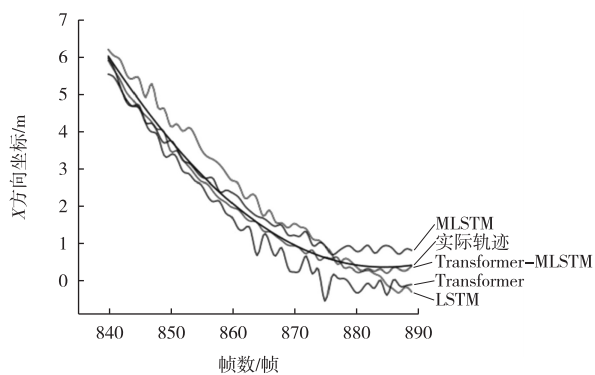
为对比基于 Transformer-MLSTM 网络与单一网络模型对 vehicle 换道轨迹预测的效果, 并验证联合模型

是否对轨迹预测起到实际作用,分别比较联合网络和单一网络模型的预测精度。由于不同网络模型的最优超参数组合存在差异,基于各不同参数的模型精度比较不仅会失去公平性,也会因参数不当而影响训练效率^[9]。因此,分别选取各模型相同的超参数组合,随机选取数据集中轨迹进行预测,以横向坐标的轨迹预测结果进行直观对比。

随机选取某车辆一条向左换道与向右换道的轨迹预测结果,对比未来50个时刻的主车换道轨迹预测结果和车辆实际的换道轨迹。通过对比各模型预测结果(图4)可知,Transformer-MLSTM模型对车辆换道轨迹的预测与实际轨迹最为接近,这表明其在预测准确度上优于单一模型。而单一模型的轨迹预测精度相对较差,主要原因在于其未将不同车辆进行区分处理,导致车辆的轨迹预测结果误差较大。



(a) 左换道



(b) 右换道

图4 不同模型轨迹预测结果对比

同时,分析发现向左换道的轨迹预测结果较向右换道更贴近实际轨迹。历史数据显示,车辆向左换道的轨迹在曲率变化与加速度波动上更为平缓,即轨迹平滑度更高。这一差异可能与驾驶场景及行为有关:在靠右行驶的交通规则下,车辆向左换道通常需要穿越或汇入车速更高的车流,因而驾驶员的操作会更加

谨慎。这种行为模式使得实际产生的换道轨迹更为稳定且规律,从而为模型提供了噪声更低、模式更清晰的学习样本,最终提升了预测精度。

5.2 定量分析


5.2.1 模型超参数选择

在神经网络模型训练中,超参数(如学习率、模型训练轮次、一次训练数据数、隐藏神经元、多头注意力机制、LSTM堆叠层个数等)会对神经网络模型的学习和预测结果产生影响。超参数调优旨在为神经网络模型选择一组能够最大化性能指标的最优参数,这是训练过程中至关重要的一环。


本文针对Transformer-MLSTM模型的特点,选取一次训练样本数(批量大小)与LSTM堆叠层数进行组合试验。试验设计主要基于以下两方面考量:一方面,批量大小是影响训练效率的关键超参数,直接影响模型效果与GPU/内存利用率。另一方面,LSTM网络的深度需审慎权衡。增加层数可增强长期依赖建模能力,但会带来梯度问题、训练耗时增加及过拟合等风险,性能并非随深度单调提升。通过对这两类参数的组合寻优,以期在模型容量、训练效率与泛化性能之间取得最佳平衡。

为探究不同超参数对神经网络性能的影响,本文针对Transformer-MLSTM网络模型设计了24组超参数组合并进行训练。所有模型在设定的训练轮次内均达到收敛状态。在此基础上,本文采用均方根误差(Root Mean Square Error, RMSE)作为评价指标,对各超参数组合下模型预测的车辆换道轨迹结果进行评估,并依据RMSE结果选取最优的超参数组合。

通过对比不同超参数组合下模型预测结果的RMSE值(见图5),发现当Transformer-MLSTM模型中LSTM堆叠层数为2、单次训练数据量为3000时,其预测性能最佳:车辆横向与纵向轨迹变化的RMSE值分别为0.364和1.492,均处于较低水平。



(a) 横向轨迹变化



(b) 纵向轨迹变化

图 5 换道轨迹变化 RMSE 值

5.2.2 不同时间窗长度下的车辆换道轨迹预测结果对比

从确保行车安全的角度出发, 驾驶员需要尽早识别出周围车辆的换道意图, 从而预留充足反应时间以规避风险。因此, 车辆换道轨迹预测模型需在保证预测精度的前提下, 基于尽可能短的历史观测数据(即更短的输入时间窗), 实现对车辆未来更长时段轨迹的准确预测。根据文献[10]可知, 高速公路场景下营运车辆完成一次换道的时间为 3~7 s(普遍比乘用车耗时更长), 其平均时长约为 5 s。基于此, 在模型构建中, 将一次完整的 8 s 换道轨迹划分为两部分: 前 3 s 作为历史输入轨迹, 后 5 s 作为待预测的目标轨迹。基于 10 Hz 的采样频率, 可计算得出模型输入序列长度为 30 个时间点, 预测输出序列长度为 50 个时间点。为进一步研究不同时间窗长度与预测得到的车辆换道轨迹结果之间的关系, 分别选择 2 s、3 s、4 s 时间窗对车辆向左换道时的车辆轨迹进行预测, 图 6 为不同时间窗模型计算得到的车辆预测轨迹与真实轨迹的偏差距离对比图。




图 6 不同时间窗长度下平均偏差距离

在预测时长一定的情况下, 时间窗长度设定越长, 得到的轨迹预测偏差距离越小。根据上述结果, 在其他参数设定相同的情况下, 应尽可能设置较长的

时间窗长度, 通过增加时间窗长度来提升轨迹预测的精准度。然而, 时间窗长度设定越长, 所需的历史换道轨迹数据越多。同时, 在车辆刚开始换道时, 车辆的历史轨迹数据基本为直行轨迹特征, 对模型的换道轨迹预测影响相对较小。因此, 考虑模型在换道开始时采用合适长度的时间窗, 通过较少的历史数据, 换取更快的预测速度, 以便尽早提醒驾驶员换道。

6 结束语

本文基于 Transformer-MLSTM 网络构建换道轨迹预测模型。该模型采用滑动时间窗方法处理历史轨迹数据, 并据此预测车辆未来的行驶轨迹。模型分别针对向左及向右换道轨迹进行训练与验证。结果表明, 该模型在预测精度上优于 LSTM、MLSTM 及 Transformer 等单一网络模型。此外, 通过比较不同超参数组合训练下模型所预测轨迹与真实轨迹间的 RMSE 值差异, 确定了最优超参数组合。最后, 对比分析不同时间窗长度的预测结果可知: 长时间窗的优势在于包含信息更全面, 预测精度更高; 短时间窗的优势在于所需历史数据更少, 预测启动更及时。后续研究将结合驾驶意图分类预测与轨迹预测结果, 构建多源融合的预测模型, 并通过实车试验, 进一步验证模型的实际部署效果。这将有效辅助营运车辆驾驶员提前决策和采取措施, 规避潜在的安全风险。

参考文献:

[1] 贺玉龙, 刘磊, 迟佳欣. 高速公路车辆换道行为风险研究[J]. 重庆交通大学学报(自然科学版), 2021, 40(4): 26-33.

[2] 丁华, 上官兴兴, 刘来. 考虑驾驶意图的车辆换道轨迹预测研究[J]. 农业装备与车辆工程, 2023, 61(12): 1-6.

[3] 赵红专, 王可怡, 李文勇, 等. 基于 MSIGJO 的网联商用车换道轨迹规划方法[J]. 重庆交通大学学报(自然科学版), 2024, 43(8): 133-142.

[4] AOUBE S G, LUDERS D B, LEE K H K, et al. Threat assessment design for driver assistance system at intersections[C]// 13th International IEEE Conference on Intelligent Transportation Systems. IEEE, 2010: 1855-1862.

[5] DENG Q, SÖFFKER D. Improved driving behaviors prediction based on fuzzy logic-hidden Markov model (FL-hMM)[C]// 2018 IEEE Intelligent Vehicles Symposium (IV). IEEE, 2018: 2003-2008.

真方法具有较高的可靠性,各出口平均风速的偏差小于20%,二者分布规律基本一致。

3) 基于仿真分析,提出了针对性的结构优化方案(如局部阻流与导流)。方案实施后,送风道的均匀指数由1.29显著降至0.43,有效提升了送风均匀性及客室舒适度。

参考文献:

- [1] 钟凌生,张陈林,刘彪,等. 人机工程在多编组铰接电车驾驶室设计中的应用[J]. 客车技术与研究,2023,45(5):39-43.
- [2] 冯江华,肖磊,胡云卿. 智能轨道快运系统[J]. 控制与信息技术,2020(1):1-12.
- [3] 郭凡,刘芳忠,刘永福. 客车空调风道及导流板设计对气流的影响研究[J]. 客车技术与研究,2022,44(2):41-43.
- [4] 刘灿,王硕祺. 城市客车常用风道结构分析[J]. 安徽科技,2019(1):49-50.
- [5] 袁博,张杰,张永利. 地铁车辆风道系统 CFD 数值模拟优化与试验验证[J]. 电力机车与城轨车辆,2017,40(5):10-13.
- [6] 龚惠华,王正,聂文斌,等. 有轨电车空调送风均匀性研究及优化[J]. 铁道机车与动车,2024(4):29-34.
- [7] 李俊义,刘彪,李京,等. 智轨电车客室空调机组制冷量的计算及验证[J]. 技术与市场,2024,31(8):62-67.
- [8] 刘洋,易柯,李颖明. 地铁车辆风道系统出风均匀性设计[J]. 电力机车与城轨车辆,2011,34(1):48-50.
- [9] 宁宝焕,于海飞,屠小娥,等. 地铁列车风道送风均匀性优化研究[J]. 制冷技术,2024,44(2):75-80.
- [10] 袁心怡,卞世敏,邵峥达,等. 某地铁车辆空调送风道出风性能仿真优化及分析[J]. 城市轨道交通研究,2021,24(8):140-144.

(上接第21页)

- [6] DEO N, RANGESH A, TRIVEDI M M. How would surround vehicles move? A unified framework for maneuver classification and motion prediction[J]. IEEE Transactions on Intelligent Vehicles, 2018, 3(2):129-140.
- [7] 侯钧杰,邵双运,郭学谦,等. 小波函数在内源光信号去噪中的应用[J]. 中国医疗设备,2020,35(2):81-85.
- [8] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [9] 陈磊. 基于深度学习的压载系统实时调载策略研究[D]. 大连:大连理工大学,2022.
- [10] 乔阳. 基于元胞自动机的公交车进站换道行为研究[D]. 西安:长安大学,2018.