



交通运输工程学报

Journal of Traffic and Transportation Engineering

ISSN 1671-1637, CN 61-1369/U

《交通运输工程学报》网络首发论文

题目：考虑车道拓扑突变的作业区矢量化轨迹预测方法
作者：赵一静，张敏，王博，张驰，聂渝涵
DOI：10.19818/j.cnki.1671-1637.2026.392
收稿日期：2026-02-04
网络首发日期：2026-06-15
引用格式：赵一静，张敏，王博，张驰，聂渝涵. 考虑车道拓扑突变的作业区矢量化轨迹预测方法[J/OL]. 交通运输工程学报.
<https://doi.org/10.19818/j.cnki.1671-1637.2026.392>



网络首发：在编辑部工作流程中，稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定，且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式（包括网络呈现版式）排版后的稿件，可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定；学术研究成果具有创新性、科学性和先进性，符合编辑部对刊文的录用要求，不存在学术不端行为及其他侵权行为；稿件内容应基本符合国家有关书刊编辑、出版的技术标准，正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性，录用定稿一经发布，不得修改论文题目、作者、机构名称和学术内容，只可基于编辑规范进行少量文字的修改。

出版确认：纸质期刊编辑部通过与《中国学术期刊（光盘版）》电子杂志社有限公司签约，在《中国学术期刊（网络版）》出版传播平台上创办与纸质期刊内容一致的网络版，以单篇或整期出版形式，在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊（网络版）》是国家新闻出版广电总局批准的网络连续型出版物（ISSN 2096-4188，CN 11-6037/Z），所以签约期刊的网络版上网络首发论文视为正式出版。

考虑车道拓扑突变的作业区矢量化轨迹预测方法

赵一静¹, 张敏^{*1}, 王博², 张驰², 聂渝涵¹

(1. 长安大学 运输工程学院, 陕西 西安 710064; 2. 长安大学 公路学院, 陕西 西安 710064)

摘要：为解决传统车道结构假设的轨迹预测方法难以准确刻画受车道封闭与交通导改组织影响的车辆未来运动趋势问题，提出了一种考虑作业区车道拓扑突变场景的矢量化轨迹预测方法（WZ-VectorNet）。将目标车历史轨迹、关键相邻车历史轨迹及作业区车道拓扑突变信息统一为含语义标签的矢量多段线场景图，分别采用结构一致的子图编码网络并通过池化获得多段线级表征，进一步进行全局交互建模；构建恒速先验下的相对位移残差解码网络输出预测轨迹结果；最终利用西安市绕城高速公路作业区无人机视频数据进行验证。研究表明：WZ-VectorNet 预测方法相比基准模型在作业区车道拓扑突变场景中整体单模态预测精度最优，平均位移误差（ADE）为 0.61m、终点位移误差（FDE）为 1.51m；车道拓扑突变信息与恒速先验残差解码是 WZ-VectorNet 性能提升的关键，ADE 相较考虑车辆交互与一般车道几何信息降低约 3.3%；ADE 和 FDE 相较相对位移残差解码分别降低约 37.1%和 15.6%。区段与车道误差分析表明，预测轨迹的误差主要为纵向位置的提前或滞后，说明所提模型引入车道拓扑突变信息对横向约束特征的学习相对充分；上游过渡区较警告区预测结果表现出更明显的轨迹偏移，反映出车辆在车道拓扑突变位置具有更高的行为复杂性和不确定性。

关键词：交通工程；轨迹预测；深度学习；矢量化场景表征；高速公路作业区；车道拓扑突变
中图分类号：U495 **文献标志码：**A **DOI:** 10.19818/j.cnki.1671-1637.2026.392

Vehicle trajectory prediction in highway work zones considering lane topology disruptions

ZHAO Yijing¹, ZHANG Min^{*1}, WANG Bo², ZHANG Chi², NIE Yuhan¹

(1. School of Transportation Engineering, Chang'an University, Xi'an 710064, Shaanxi, China; 2. School of Highway, Chang'an University, Xi'an 710064, Shaanxi, China)

Abstract: To address the limitations of trajectory prediction methods based on fixed lane structure assumptions in capturing vehicle motion under lane closures and work zone layouts, a vectorized trajectory prediction model was proposed for highway work zones that explicitly accounts for lane topology disruptions, named WZ-VectorNet. The historical trajectories of the target vehicle and key neighboring vehicles, and work-zone lane topology mutation information were unified into a semantic-labeled vectorized polyline scene graph. Structurally consistent subgraph encoders were used, and the max pooling was applied to obtain polyline-level representations. Global interaction modeling was then performed. A residual decoder under a constant-velocity prior was constructed to output the predicted trajectories. The proposed model was finally validated by unmanned aerial vehicle (UAV) video data in highway work zones on the Xi'an Ring Expressway. Results show that WZ-VectorNet achieves the best overall accuracy under lane topology disruption scenarios among single-modal prediction models, with an average displacement error (ADE) of 0.61 m and a final displacement error (FDE) of 1.51 m. Lane topology disruption information and constant velocity prior residual decoding are the main contributors to performance gains. Compared with the model using vehicle interaction and general lane geometry information, ADE is reduced by about 3.3%. Compared with relative-displacement residual decoding, ADE and FDE are reduced by about 37.1% and 15.6%,

出版历程：2026-02-04 收稿，2026-03-21 修回；2026-05-27 录用

基金项目：国家自然科学基金面上项目（72371036）；陕西省社会科学基金项目（2025R018）；陕西省教育厅服务地方专项计划项目（24JE005）；中央高校基本科研业务费资助项目（自然科学类）（300102215206）

作者简介：赵一静（1999-），女，陕西渭南人，博士研究生。

*通信作者：张敏（1981-），女，广西柳州人，副教授，博士生导师，工学博士。

respectively. Segment- and lane-level error analyses demonstrate that the main source of trajectory prediction error is the lead or lag in longitudinal position. This indicates that lane topology disruption information enables WZ-VectorNet to learn lateral constraint features relatively well. More pronounced trajectory deviations are observed in the transition area than in the advanced warning area, reflecting the higher behavioral complexity and uncertainty of vehicles at locations with lane topology disruptions.

Keywords: traffic engineering; trajectory prediction; deep learning; vectorized scene representation; highway work zones; lane topology disruptions

Publication history: Received 2026-02-04; Received in revised form 2026-03-21; Accepted 2026-05-27

Funding: National Natural Science Foundation of China (72371036); Shaanxi Social Sciences Foundation Project (2025R018); the Special Project for Serving the Local Area of the Shaanxi Provincial Education Department (24JE005); the Fundamental Research Funds for the Central Universities (300102215206)

***Corresponding author:** ZHANG Min, associate professor, PhD.

0 引言

高速公路网的持续扩容与常态化养护施工是保障国家交通基础设施服务水平的必要举措。与一般路段不同,作业区受车道封闭与交通导改组织影响,成为交通流由常态通行转入受控通行的关键节点。高速公路作业区内有效通行空间沿行驶方向快速收缩,交通运行状态随之发生显著突变^[1]。在此条件下,车辆在速度选择、换道时机与车道占用等方面与一般路段呈现显著差异^[2-4],冲突风险与拥堵波动更易被触发,是道路交通效率提升与安全管理重点与难点^[5]。

作业区的突出特征在于车道拓扑结构突变,即在车道封闭和交通导改组织约束的作用下,原有一般路段中相对稳定的车道通行边界与有效通行通道被重新定义的过程。此时,车辆运行不再仅依赖稳定的车道边界线和中心线,而是同时受导改组织设置线、锥桶、水马等临时隔离设施与车道固定边界线叠加的共同约束。

沿车辆行驶方向看,作业区内通常划分为警告区、上游过渡区、缓冲区、作业区、下游过渡区和终止区等不同拓扑区段,不同区段在控制边界、可通行车道数量、车道连接关系及可行行驶路径等方面均存在明显差异,并会在较短纵向范围内快速变化。Shakouri 等人^[6]指出作业区构造与交通密度会显著影响驾驶人主观工作负荷。其中,上游过渡区是车道数量开始减少、车道功能由常态向受控状态演化的关键区段,车辆常沿上游过渡区形成连续的轨迹路径^[7]。Ma 等人指出上游过渡区设置与长度改变会进一步引发驾驶工作负荷与行为特征差异^[8]。这说明,区段差异性作业区车道拓扑突变的直接体现,也是影响车辆轨迹演化的重要来源。

进一步,作业区内部不同车道间还存在功能和语义上的异质性。由于封闭区域设置使得不同车道在通行功能、汇入压力与可用间隙约束上存在显著差异。部分车道承担强制汇入和路径偏移功能,其余车道维持主线连续通行,与封闭车道相邻的可通行车道功能呈逐级退化趋势^[9]。Zhao 等人^[10]在增强型元胞自动机与延迟强制换道模型的框架下,明确刻画了封闭车道承担被迫汇入、其余车道功能退化的机制。Wu 等人^[11]从驾驶人偏好角度揭示不同车道的道路环境会影响换道位置选择。Huang 等^[12]进一步从多尺度因素交互的角度分析了作业区内汇入行为的变化规律。因此,作业区内不同车道在行为约束和运行状态上的差异,进一步决定了车辆轨迹演化的异质性。综上,沿车辆纵向行驶方向的区段差异性与沿横向换道方向的车道异质性共同构成了作业区车道拓扑突变的核心特征。

在此背景下,能够感知并刻画车道拓扑突变问题的作业区车辆短时未来轨迹预测,成为作业区安全与效率提升的基础。在主动安全层面,作业区的汇入冲突^[9]、追尾风险与侧向刮擦^[13]多由车辆间短时交互触发。相较于依赖历史运动状态的被动识别,Cao 等人^[14]指出基于轨迹预测的冲突识别能够更早地反映未来时空的交互风险,可为早期冲突预警提供支持。在效率提升层面,作业区内个别车辆的急减速^[15]与换道行为^[16]容易引发速度扰动,若能基于短时轨迹预测结果提前识别车辆运行趋势,并进一步实施主动速度引导或交通控制,则有助于缓解交通振荡现象并改善运行效率^[17]。因此,明晰作业区车道拓扑突变约束,构建兼顾预测精度与物理环境一致性的车辆轨迹预测模型,对于作业区安全与效率提升具有重要的理论价值与工程意义。

车辆轨迹预测旨在根据车辆的历史运动状态推演其未来位置序列,方法体系经历了从物理规则到数据驱动的演进。早期研究依赖跟驰模型^[18]、换道模型^[19-21]与元胞自动机模型^[4,10,22]等物理驱动与规则模型揭示车辆轨迹行为机理与交通波演化特征。这一类物理与规则模型通过显式结构,清晰揭示了高速公路瓶颈路段形成、强制汇入和交通震荡等现象的产生机理,但在面对受车道拓扑突变影响的复杂轨迹模式时,模型结构往往需要高度简化,泛化能力有限^[5]。

随着数据驱动技术的成熟,轨迹预测逐步转向深度学习框架,重点在于同时刻画多车交互与道路约束^[23,24]。特别是长短期记忆网络(LSTM)^[25]、自注意力机制(Transformer)^[26]与图神经网络(GNN)^[27]的引入,有效提升了多车交互行为的建模能力。基于这些通用结构,学者们提出了面向交通场景的专用轨迹预测模型。Che等人^[23]通过多模态对抗 Informer 实现了高速公路换道轨迹预测;李立等^[28]提出了面向群体行驶场景的时空信息融合轨迹预测方法;贾兴利等人^[29]从综述视角总结了时空图神经网络在交通预测中的发展路径。总体来看,基于深度学习的方法在开放交通场景下能够有效提取多车交互模式与道路约束特征,在预测精度和对交互行为的刻画能力方面取得了显著进展。对于作业区而言,车道封闭与交通导改组织设置使得车辆必须在有限时空窗口内完成汇入,车辆交互是在车道拓扑突变场景下的被动交互^[30,31]。利用深度学习框架引入作业区场景下被动交互特征与道路约束能够有效提升车辆短时轨迹预测精度。

作业区车道拓扑突变场景下的地图要素表征是约束车辆轨迹演化的关键要素。现有的轨迹地图表征方法经历了从图神经网络定义地图邻接关系(GNN)到矢量化表征车道拓扑的演进。GNN 通常将道路环境抽象为相对稳定的图结构,通过节点与边的关系刻画车辆与地图间的空间关联^[27]。而矢量化表征方法则将高精地图与车辆轨迹统一表示为矢量多段线并进行层次编码,从而提升了场景结构表达能力与编码效率^[32]。胡杰等人^[33]在此基础上,进一步引入结构化道路约束和多模态信息融合,提升了对道路结构的利用效率。总体而言,矢量化方法相比于传统 GNN 方法在结构表达和编码效率上具有优势,能够显式引入车道拓扑结构,但已有研究中将车道视为语义同质的静态要素,缺少对作业区中车道拓扑随区段变化、车道功能随场景演变的细致刻画,因此在作业区中车辆短时轨迹预测精度有限。

此外,在作业区这一约束场景下,车辆加减速与转向更频繁,未来轨迹非线性更强^[5,9]。使用传统位置残差解码方式直接回归未来绝对坐标容易产生累积误差与局部抖动,难以保证运动学平滑性与物理一致性。相比之下,车辆短时运动具有明显惯性保持特征^[34],未来轨迹可表述为线性惯性演化与轨迹地图干扰引起的偏离量叠加。利用这一物理先验有助于降低解空间复杂度,并提高长时域预测的稳定性。

综上所述,尽管现有轨迹预测研究在多车交互建模和道路表征方面已取得一定进展,但在高速公路作业区这一强制约束且结构快速变化的场景中仍存在明显不足:一是多数研究建立在常规路段拓扑相对稳定的假设之上,难以显式刻画作业区内因车道封闭与交通导改组织设置所引起的有效通行空间收缩、车道连接关系调整及可行行驶路径重构,因而对警告区、上游过渡区、缓冲区分段及作业区等关键区段中的轨迹演化特征反映不足。二是现有方法通常将同一断面各车道视为几何意义上近似同质的通行单元,缺乏对作业区内不同车道在通行功能、汇入压力、约束强度及行为诱导上的语义异质性的细致表征,难以准确反映不同车道车辆轨迹演化的差异。三是针对作业区内频繁加减速、转向与强制汇入所导致的非线性轨迹变化,现有预测框架多采用直接位置回归或一般残差解码方式,对车辆短时运动中的惯性保持特征及道路约束下的偏离机制利用不足,因而在预测稳定性、轨迹平滑性及物理一致性方面仍有提升空间。

为了解决上述问题,构建面向高速公路作业区车道拓扑突变下的矢量化轨迹预测框架(WZ-VectorNet),将目标车辆历史轨迹、关键相邻车辆历史轨迹与作业区车道拓扑突变信息统一编码为带语义标签的矢量多段线场景图,在模型中显式嵌入车道收缩、导改组织设置及封闭车道等拓扑突变区段语义信息。通过多层感知机与分层交互建模模块联合挖掘多车、多车道、多区段间的时空依赖关系,构建同时刻画车道功能语义与作业区区段属性的高维表示;在解码端引入恒速先验残差预测策略,对未来位置序列进行多步预测。所提模型在西安市绕城高速公路作业区无人机实测轨迹数据上进行了训练和验证,证明了此模型比现有模型具有更高的轨迹预测精度。最后,从区段和车道两个维度对预测结果开展系统评估与误差分解分析,用以验证显式建模车道拓扑突变场景对作业区车辆轨迹的整体形态与终点行为的刻画能力。

1 研究问题

1.1 问题定义

在高速公路常规路段, 车道数量、车道间连通关系、车辆行驶路径与通行边界在一定路段内保持稳定, 可视为车道拓扑状态平稳。而在作业区内, 因车道封闭、交通导改、临时标线与隔离设施的设置, 原有车道的数量、连通关系、有效通行区域及车辆可达路径在短距离内发生非连续改变, 此现象定义为车道拓扑突变。为突出作业区车道拓扑突变的特点, 将车道拓扑状态定义为车辆在位置 x 处所面临的局部通行结构, 即

$$T(x) = \langle L(x), C(x), R(x) \rangle \quad (1)$$

式中: $L(x)$ 为位置 x 处的有效通行车道集合; $R(x)$ 表示下游可达车道集合; $C(x)$ 为有效通行车道之间及其与下游车道之间的连通关系。

若存在位置 x_w 处, 对任意充分小的 $\delta_1, \delta_2 > 0$, 存在

$$T(x_w - \delta_1) \neq T(x_w + \delta_2) \quad (2)$$

则在位置 x_w 处发生车道拓扑突变。区别于合流区等高速公路固定结构的车道拓扑突变问题, 作业区的车道拓扑突变并非道路几何形态的连续变化, 而是由车道封闭、交通导改组织叠加后控制边界和有效通行通道变化共同引起的局部通行结构变化。

因此, 作业区场景下车道拓扑突变处目标车辆未来轨迹的形成同时受到三类因素共同影响: 一是目标车辆的历史运动轨迹, 二是在受限道路条件下邻近车辆对可用间隙与速度选择的约束, 三是由作业区车道拓扑突变引起的控制边界限制与有效通行空间诱导。重点关注上游过渡区及其前后邻近断面的车道拓扑突变关键区段内的轨迹演化规律, 在可获得目标车辆历史轨迹、关键相邻车辆历史轨迹以及作业区道路几何与交通组织设置要素的前提下, 建立能够刻画车辆间交互与道路限制约束共同作用的轨迹预测模型, 输出目标车辆未来时域内的位置序列。

为描述该问题, 设车辆的历史轨迹数据采样频率为 f , 观测时长为 T_{obs} , 预测时长为 T_{pre} 。相应地, 观测步数与预测步数分别为 $N_{obs} = \lceil fT_{obs} \rceil$ 与 $N_{pre} = \lceil fT_{pre} \rceil$ 。对任一目标车辆, 以观测末帧位置作为局部坐标原点, 对目标车辆历史轨迹、关键邻车历史轨迹与车道拓扑突变处地图要素进行统一的平移与尺度归一化处理, 从而得到同一局部坐标系下的多源输入表征。给定观测窗内目标车辆历史轨迹、局部相邻车辆集合历史轨迹以及作

业区车道拓扑突变处地图要素集合, 轨迹预测问题可定义为

$$\hat{Y} = f_{\theta}(V_i, V_j, M) \quad (3)$$

式中: V_i 为目标车辆矢量化历史轨迹表征; V_j 为目标车辆第 j 个局部相邻车辆的矢量化历史轨迹表征; M 为作业区车道拓扑突变处地图要素矢量化表征集合; 模型输出未来 N_{pre} 步的位置序列

$Y = \{d_t\}_{N_{obs}}^{N_{obs}+N_{pre}-1}$ 。以单模态轨迹作为输出形式, 用以刻画作业区内主导行为模式下的最可能轨迹演化。

1.2 研究假设

基于作业区车辆轨迹数据与道路几何信息的可获得性, 假设现有数据与场景表征能够支撑作业区车道拓扑突变场景的矢量化车辆轨迹预测研究。具体适用假设如下:

(1) 所提方法主要面向存在车道数减少和交通导改组织的高速公路作业区运行过程, 不直接扩展至城市道路、普通公路或无施工管制且车道拓扑结构稳定的通用轨迹预测情形。

(2) 所提方法构建的作业区矢量化表征预测框架能够兼容任意车道数高速公路, 并具备向内侧封闭、外侧封闭及多车道封闭等多种工况拓展的能力。

(3) 所提方法要求作业区的交通导改组织与几何参数是能够可靠获取的, 且可近似视为在预测时间窗内空间位置固定不变, 不适用于导改组织与车道拓扑随时间动态推移的移动作业区场景。

2 考虑车道拓扑突变的作业区矢量化轨迹预测方法

2.1 方法框架

作业区的轨迹预测涉及车道封闭与交通组织设置导致的车道拓扑突变问题。因此, 提出考虑车道拓扑突变的作业区矢量化轨迹预测方法 (WZ-VectorNet, 见图 1)。首先, 将目标车辆轨迹、相邻车辆历史轨迹与作业区车道拓扑突变地图要素统一表示为矢量化特征。各要素线由若干向量段组成, 向量段特征同时包含几何信息与语义信息。其次, 将车辆轨迹多段线与地图多段线分别采用结构一致的子图编码网络进行局部编码, 并通过最大池化聚合获得多段线级表征。接着, 通过全局交互建模, 对车辆与地图要素进

行统一交互建模，既突出作业区车道语义异质性与分区分段差异性对车辆轨迹演化的约束，同时刻画相邻车辆对目标车纵向跟驰与横向换道的耦合影响。最后，通过恒速先验残差轨迹预测解码，预测未来时域内车辆轨迹。

2.2 车辆与地图矢量化特征表示

为统一刻画车辆轨迹运动与作业区车道拓扑突变地图要素，以定长矢量段序列构造各要素。

2.2.1 目标车辆运动的向量段特征表示

不同于传统将历史点序列直接输入网络的做法，建模时以观测末帧位置作为局部坐标原点，采用向量段统一刻画车辆的局部位移与方向变化。具体而言，目标车辆历史相邻轨迹由相邻时刻位置点对组成运动向量段

$$\bar{\mathbf{v}}_t = [\mathbf{x}_t, \mathbf{y}_t, \mathbf{x}_{t+1}, \mathbf{y}_{t+1}], t = 0, 1, \dots, N_{obs} - 1 \quad (4)$$

式中： $\bar{\mathbf{v}}_t$ 为相邻时刻位置组成的向量段； $\mathbf{x}_t$ 指车辆在时刻 t 的相对纵向位置，即道路行驶方向坐标； $\mathbf{y}_t$ 指车辆在时刻 t 的相对横向位置，即垂直

于行驶方向的侧向坐标； $\mathbf{x}_{t+1}$ 指车辆在时刻 $t+1$ 的相对纵向位置； $\mathbf{y}_{t+1}$ 指车辆在时刻 $t+1$ 的相对横向位置。

进一步，将车道变化趋势作为附加维度引入，以突出作业区车道拓扑突变处换道行为的可区分性。设 $l_t \in \{1, 2, \dots, N_{lane}\}$ 为车辆在时刻 t 所处的车道编号，其中 N_{lane} 为道路一般结构下的实际总车道数，按由内向外的顺序对车道进行编号。以观测末帧的车道位置 $l_{ref} = l_{N_{obs}}$ 为参考，定义车辆换道行为变化的相对车道差为

$$\Delta l_t = l_{ref} - l_t \quad (5)$$

将 Δl_t 作为第 t 个向量段的附加分量，得到车辆运动的5维特征向量段表示

$$\mathbf{v}_t = [\bar{\mathbf{v}}_t, \Delta l_t] \quad (6)$$

以观测窗内前 $N_{obs}-1$ 个向量段作为目标车辆的输入。从而，目标车辆 i 的历史轨迹观测特征可写为

$$\mathbf{V}_i = \{\mathbf{v}_t\}_{t=0}^{N_{obs}-1} \in \mathbb{R}^{(N_{obs}-1) \times 5} \quad (7)$$




图1 考虑车道拓扑突变的作业区矢量化轨迹预测方法

Fig.1 A framework for vectorized trajectory prediction in work zones considering lane topology disruptions

2.2.2 相邻车辆提取与特征表示

作业区内由于封闭区域的设置,车辆倾向于驶入未封闭、可持续通行的车道,将其定义为目标车道。尽管作业区车道拓扑突变使得车辆行驶场景较一般路段更为复杂,但车辆驾驶行为往往仅与车辆周边的少量关键车辆最相关,即主要受起始车道前车、目标车道前和后车制约^[35]。以目标车辆观测末帧为局部坐标原点,目标车辆观测末帧车道位置 l_{Nobs-1} 与观测起始帧位置 l_0 的相对车道差 Δl_0 判断目标车辆的相邻车辆集合 J

$$J = \begin{cases} \{J_{cf}, J_{lf}, J_{tb}\}, & \text{if } \Delta l_0 = 0 \\ \{J_{lf}, J_{cf}, J_{cb}\}, & \text{if } \Delta l_0 > 0 \\ \{J_{rf}, J_{cf}, J_{cb}\}, & \text{if } \Delta l_0 < 0 \end{cases} \quad (8)$$

式中:当 $\Delta l_0=0$ 时表示目标车辆在历史观测时段内维持同车道行驶,此时目标车辆主要受同车道前车 J_{cf} , 目标车道前车 J_{lf} , 目标车道后车 J_{tb} 的影响;当 $\Delta l_0>0$ 时表示目标车辆在历史观测时段内驶入右侧方向车道,此时目标车辆主要受紧邻左侧车道前车 J_{lf} , 同车道前车 J_{cf} , 同车道后车 J_{cb} 的影响;当 $\Delta l_0<0$ 时表示目标车辆在历史观测时段内驶入左侧方向车道,此时目标车辆主要受紧邻右侧车道前车 J_{rf} , 同车道前车 J_{cf} , 同车道后车 J_{cb} 的影响。

以目标车辆观测末帧为局部坐标原点,与目标车辆的历史轨迹观测特征相同,对第 j 个相邻车辆在观测时间窗内各时刻的相对位置构造其观测向量段特征

$$\mathbf{V}_j \in \mathbb{R}^{(Nobs-1) \times 5} \quad (9)$$

同时,当第 j 个相邻车辆不存在时,以零向量补齐。

2.2.3 作业区车道拓扑突变处地图特征表示

作业区的车道拓扑突变是由控制边界和有效通行通道变化共同引起的局部通行结构变化。为将作业区车道拓扑突变作为地图特征进行表征,定义位置 x 处的几何约束状态为

$$\mathbf{G}_w(x) = \langle \mathbf{W}(x), \mathbf{A}(x) \rangle \quad (10)$$

式中: $\mathbf{W}(x)$ 为作业区在位置 x 处的控制边界集合,包含车道边界线和交通导改组织线; $\mathbf{A}(x)$ 为有效通行空间中心线集合。

车道边界线提供与一般路段近似的车道通行的约束边界,交通导改组织设置线刻画封闭车道引起的作业区通行空间收缩。设道路一般结构

下车道数为 N_{lane} , 车道宽度为 w 。那么控制边界集合 $\mathbf{W}(x)$ 为

$$\mathbf{W}(x) = \{B_l(x) | l = 0, 1, \dots, N_{lane}\} \cup \{D(x)\} \quad (11)$$

$$B_l(x) = y_l^b(x) = lw, \quad l = 0, 1, \dots, N_{lane} \quad (12)$$

$$D(x) = y^d(x) \quad (13)$$

式中: $B_l(x)$ 表示在纵向位置 x 处的第 l 条车道边界线; $y_l^b(x)$ 表示在纵向位置 x 处的第 l 条车道边界线的横向位置; $D(x)$ 表示在纵向位置 x 处交通导改组织设置线; $y^d(x)$ 表示在纵向位置 x 处交通导改组织线的横向基准位置,通过观测数据获取。

为确定交通组织边界线的设置位置,依据《道路交通标志和标线 第4部分:作业区》(GB 5768.4—2017)对作业区进行分区段表示,以分界点集合 $\{x_z\}_{z=0}^3$ 描述所属作业区区段 q ,定义警告区 $\Omega_w=[x_0, x_1]$, 上游过渡区 $\Omega_t=(x_1, x_2]$, 缓冲区与工作区布设特征相似将其统一表示 $\Omega_z=(x_2, x_3]$ 。当 $D(x)$ 的横向基准位置在第 l 条车道边界线以内时,以 $D(x)$ 作为实际控制边界。因此,交通导改组织设置线 $D(x)$ 在警告区 Ω_w 和缓冲区与工作区 Ω_z 中与车道边界线 $B_l(x)$ 重合。在上游过渡区 Ω_t 内,交通导改组织设置线 $D(x)$ 在封闭车道内线性渐变设置,实现对车道通行条件约束目的。

其次,将有效通行空间中心线集合 $\mathbf{A}(x)$ 定义为

$$\mathbf{A}(x) = \{C_k(x) | C_k(x) \in R(x), k = 1, 2, \dots, N_{lane}\} \quad (14)$$

式中: $C_k(x)$ 表示在纵向位置 x 处的第 k 条车道有效通行中心线,提供期望车辆行驶基准参考; $R(x)$ 为由车道控制边界集合 $\mathbf{W}(x)$ 界定的有效通行区域。

对任一线集合 (B_l, D, C_k) 按在第 q 个区段内,构造联合特征表示

$$\mathbf{m}^q = [x_s^q, y_s^q, x_e^q, y_e^q, \mathbf{e}_q, \text{id}] \quad (15)$$

式中: (x_s^q, y_s^q) 与 (x_e^q, y_e^q) 分别表示线要素在第 q 个区段内的向量段起点与终点坐标; $\mathbf{e}_q \in \{0, 1\}$ 为作业区第 q 个区段的标识信息,分别对应警告区 Ω_w 、上游过渡区 Ω_t 、缓冲区与工作区 Ω_z , 仅所属区段对应维度取 1, 其余维度为 0; id 为几何线要素的标识信息,区别车道边界线 $B_l(x)$ 、车道中心线 $C_k(x)$ 和交通导改组织设置线 $D(x)$ 。由此得到分区段矢量化地图要素集合 $\mathbf{M}$, 作为后续车

辆与地图交互建模的地图特征输入。

2.3 向量段内部子图编码网络

设 n 个向量段组成的连续序列视为一条多段线，当多段线为车辆历史轨迹或相邻车辆轨迹时，对应轨迹多段线 V ；当多段线为作业区车道拓扑突变处地图要素集合时，对应地图要素线 m 。以轨迹多段线 V 为例，那么多段线的输入可写为矩阵

$$V = [v_1, v_2, \dots, v_n] \in \mathbb{R}^{d \times n} \quad (16)$$

式中： v_n 为第 n 个向量段的特征向量； d 为输入特征维数，对车辆轨迹多段线 $d=5$ ，对作业区地图要素多段线 $d=8$ 。

随后，对轨迹多段线 V 和作业区地图要素多段线 m 分别采用结构一致的子图编码网络进行局部特征提取。子图编码网络由三层同结构编码层串联构成，每层先对向量段做线性映射与归一化激活，再以最大池化层形成多段线全局特征，并将该全局特征复制回每个向量段与其局部表示拼接。第 i 层的计算定义为

$$e_n^i = \sigma(\text{LN}(W^i h_n^{i-1})) \quad (17)$$

$$g^i = \max e_n^i \quad (18)$$

$$h_n^i = [e_n^i, g_p^i] \quad (19)$$

式中： $h_n^0 = v_1$ ； W^i 为第 i 层线性变换矩阵；LN 为层归一化算子； σ 为 ReLU 激活函数； $\max$ 表示对向量段维度做逐元素最大池化；最终拼接结果 h_n^i 使得每层输出维数翻倍。具体地，每层先映射到 64 维，再与 64 维的多段线全局特征拼接，得到 128 维向量段表示。三层堆叠后，通过对最终向量段表示做最大池化得到多段线级表示

$$p = \max h_n^3 \in \mathbb{R}^{128} \quad (20)$$

式中： p 为多段线的定长编码向量，将作为全局交互模块的节点特征输入。

2.4 全局交互建模与轨迹解码

在将输入特征以多段线表示的基础上构建全连接注意力交互网络，将目标车辆历史轨迹多段线与相邻车辆历史轨迹多段线、作业区车道拓扑突变处地图要素多段线置于统一要素集合中，通过注意力权重自适应学习不同要素对目标车辆轨迹预测的贡献强度。

2.4.1 全局注意力交互编码

要素集合由目标车辆多段线、最多三条邻车

多段线以及全部地图要素多段线构成，要素总数为 N 。将多段线表示按要素顺序堆叠为

$$P = [p_1, p_2, \dots, p_N] \in \mathbb{R}^{128 \times N} \quad (21)$$

$$\bar{p}_n = \frac{p_n}{\|p_n\|_2} \quad (22)$$

式中： p_n 为第 n 个要素的多段线表示； $\bar{p}_n$ 为其二范数归一化结果； $\|\cdot\|_2$ 为二范数。

注意力交互使用查询 q_n 、键 k_n 、值 v_n 三组映射

$$q_n = \sigma(W_q (\bar{p}_n)^T) \quad (23)$$

$$k_n = \sigma(W_k (\bar{p}_n)^T) \quad (24)$$

$$v_n = \sigma(W_v (\bar{p}_n)^T) \quad (25)$$

式中： W_q 、 W_k 和 W_v 为可学习参数矩阵。

随后计算各要素间的相关性分数定义，并对目标要素根据 softmax 归一化得到注意力权重，得到最终的交互信息更新结果

$$z_n = \sum_{j=1}^N \alpha_{nj} v_j + q_n \quad (26)$$

式中： z_n 为更新后的目标车辆要素表示； α_{nj} 表示要素 j 对要素 n 的信息贡献权重； v_j 为要素 j 的值映射； q_n 为要素 n 的查询映射。在后续解码中，仅使用 z_n 为目标车辆的融合表示，从而将邻车信息与地图要素信息以注意力加权方式汇聚到目标车辆的轨迹预测中。

2.4.2 恒速先验残差的轨迹解码

为避免车辆短时预测中直接回归未来轨迹容易产生累积误差与局部抖动问题，引入恒速先验残差解码机制。目标车辆未来轨迹可表述为线性惯性演化与轨迹地图干扰引起的偏离量叠加。

首先，定义目标车辆观测末帧速度为

$$v_{cv} = f(d_{N_{obs}} - d_{N_{obs}-1}) \quad (27)$$

式中： v_{cv} 为观测末向量段速度估计； f 为轨迹数据采样频率； $d_{N_{obs}}$ 为目标车辆观测末帧位置；

$d_{N_{obs}-1}$ 为目标车辆观测末帧的前一帧位置。

基于目标车辆轨迹恒速假设，设目标车辆的预测轨迹步数为 N_{pre} ，未来轨迹在第 τ 步的恒速先验位置为

$$d_{\tau,cv} = d_{N_{obs}} + \frac{\tau}{f} v_{cv}, \quad \tau = 1, \dots, N_{pre} \quad (28)$$

定义残差为真实轨迹与恒速先验轨迹之差：

$$r_{\tau} = d_{\tau} - d_{\tau,cv} \quad (29)$$

式中： d_{τ} 为目标车辆在第 τ 步的真实轨迹位置， $d_{\tau,cv}$ 为未来轨迹在第 τ 步的恒速先验位置。

解码器学习该残差的估计值 $\hat{r}_{\tau}$ ，得到目标车辆最终轨迹预测结果

$$d_{\tau} = d_{\tau,cv} + \hat{r}_{\tau} \quad (30)$$

式中： d_{τ} 为目标车辆未来第 τ 步预测位置。

这一残差相对恒速的解码方式，能够在目标车辆运动中的历史惯性运动趋势基础上学习作业区内车辆交互扰动与作业区交通导改设施带来的偏离量，使得目标车辆的轨迹预测更加契合作业区的车道收缩与驾驶行为的规律。

2.4.3 训练目标与正则项

为优化目标车辆预测轨迹解码结果，采用均方误差作为主要的训练目标函数。该损失函数度量了目标车辆预测轨迹与真实轨迹的逐步差异。

$$\mathcal{L}_{traj} = \frac{1}{N_{pre}} \sum_{\tau=1}^{N_{pre}} \|d_{\tau} - d_{\tau}^*\|_2^2 \quad (31)$$

除了轨迹预测位置的回归损失外，为了保证轨迹的平滑性，避免不合理的轨迹跳跃或突变，引入基于增量差分的平滑正则项。

$$\mathcal{L}_{smooth} = \frac{1}{N_{pre}-1} \sum_{\tau=2}^{N_{pre}-1} \|\delta_{\tau} - \delta_{\tau-1}\|_2^2 \quad (32)$$

式中： δ_{τ} 为第 τ 步的预测位移增量。平滑项确保相邻预测点之间的变化不至于过大，从而避免轨迹的剧烈波动。

综合而言，最终的训练目标损失函数为

$$\mathcal{L} = \mathcal{L}_{traj} + \lambda \cdot \mathcal{L}_{smooth} \quad (33)$$

式中： λ 为平滑项的权重，根据验证集调参确定，避免过度惩罚位移增量导致难以预测出作业区车辆的加减速特征。最终损失函数综合了轨迹精度与平滑性，确保了模型不仅在精度上满足需求，还能生成符合物理规律且合理平滑的轨迹。




图2 作业区车道拓扑突变处采集范围示意

Fig.2 The collection range at lane topology disruptions in the work zone



图3 作业区车道拓扑突变处实地数据示意

Fig.3 The field data location at lane topology disruptions in the work zone

3 试验设计与结果分析

3.1 数据集概况

3.1.1 数据采集

为了对所提 WZ-VectorNet 模型进行验证,需获取高速公路作业区内具有一定规模的车辆轨迹数据。由于现有公开车辆轨迹数据集主要面向常规高速公路或城市道路场景,包含施工作业区车道封闭、临时导改及车道拓扑突变等关键交通组织特征的开放数据较为稀缺^[36],难以与本文研究问题形成一致的问题定义。因此,试验数据采集自中国西安市绕城高速公路封闭最内侧车道的短期作业区,该路段在数据采集时段内单向设置三条行驶车道,由内向外分别为超车道、行车道与慢车道。

西安绕城高速公路是联系主城区城市道路网络与公路系统之间的关键通道。经过多年的运营,该高速公路的道路基础设施存在一定程度的老化与损坏情况。为了改善其技术状况并保持足够的服务水平,西安绕城高速公路经常进行短期维护工作。鉴于该高速公路的日均交通量较大,且在高峰时段(上午 7:00~9:00 以及下午 5:30~7:30)常常存在严重的拥堵情况,这些短期维护作业通常安排在非高峰的白天时段进行,以尽量减少交通干扰。

短期作业区的布局通常遵循相关国家标准与法规的规定,并辅以精细化的交通管理策略。这些策略包括临时警示诱导标志、分隔设施和车道使用计划,旨在引导驾驶员提前调整其行为。作业区实地视频数据通过 DJI Air3 无人机拍摄记录。无人机已在现有研究中广泛应用于复杂交通场景的数据采集与状态观测^[37-39],可提供作业区车道拓扑突变位置的全局观测视角。该无人机的覆盖范围约为 400 米,故而一次性难以拍摄作业区内完整区域。相比于其他区域,警告区及过渡区中频繁地换道行为易引发严重拥堵与事故,属于作业区车道拓扑突变处。因此,拍摄对象选取为部分警告区、过渡区、缓冲区以及工作区,如图 2 所示。

选择天气晴朗、风速在 2.5~3.5 米/秒的非高峰时段前往作业区拍摄,每块电池可悬停录制时长约 15 分钟。到达拍摄地点后,无人机设备迅速组装完成,并与智能手机连接进行校准。采用了垂直拍摄方式,将无人机的飞行高度设定为约 300 米,录制的分辨率为 3840×2160 像素,帧率为 30 帧/秒,确保在视频中能够清晰识别到作业

区内的交通锥、车辆和车道标线。所采集数据集为最内侧车道因维护而关闭的作业区(图 3),录制时长累计为 1 小时。

3.1.2 数据处理

所采集得到的无人机视频数据利用 DataFromSky 开放处理平台进行车辆轨迹提取^[40]。DataFromSky 是一个开源的视频处理平台,专为提取车辆轨迹而设计,被认为是可靠的车辆轨迹数据提取方法并广泛应用于交通流研究^[41]。所提取车辆轨迹数据利用 DataFromSky Viewer 软件进行轨迹可视化,并导出逐帧车辆行为轨迹进一步分析。

首先,车辆的相对位置难以与其车道位置相匹配,因此在图像坐标中拟合道路参考线,将车辆点投影至参考线的法向上。其次,将所提取轨迹数据利用像素率进行校准,像素率指在画面中的标线像素间距与实际长度之比。最后,转换得到采集范围内在道路坐标内的车辆轨迹数据与作业区布设信息。车辆轨迹数据包含车辆 ID、车辆类型、车辆行驶相对位置、速度、加速度、以及根据车道宽度判定车道编号等;作业区布设信息包含所采集的警告区长度、上游过渡区长度、以及缓冲区和作业区长度。表 1 中示出了作业区长度、分车道交通流量。

表 1 数据集作业区布设长度、分车道交通流量
Table 1 The work zone layout length and traffic flow of lanes

作业区布设长度/m			流量/(veh h ⁻¹)		
警告区	上游过渡区	缓冲区和作业区	超车道	行车道	慢车道
165	130	38	522	948	970

根据表 1 的流量统计,在作业区警告区内,三车道总流量为 2440veh/h,这部分汇入需求被强制压缩至两条可通行车道中,导致缓冲区和作业区的平均单车道流量骤增至 1220veh/h/lane。依据《公路工程技术标准》(JTG B01-2014)及作业区通行能力折减规律^[42,43],该路段随着车道封闭的物理收缩,服务水平在空间上发生从二级向四级突变,可以满足作业区内考虑车道拓扑突变的车辆轨迹预测模型实证验证需求。

为了减少无人机视频中高频噪声波动等误差,应用了移动平均法来平滑车辆速度数据。使用 1 秒的滑动时间窗口对每个帧的速度进行平均计算。这种平滑过程确保了速度值更加稳定,并能更准确地反映车辆随着时间推移的真实行驶行为。其次,在画面边缘位置处由于边界效应

与车辆识别几何误差的叠加使得速度往往偏小或抖动明显，剔除画面边缘处各 25 米的轨迹数据。

3.2 试验设置

3.2.1 试验流程与参数设置

为平衡轨迹平滑性与计算效率，将原始轨迹采样频率从 30 帧/秒下采样至 10 帧/秒。每个车辆轨迹样本由连续 8 秒的轨迹序列构成，其中前 5 秒为观测时长，后 3 秒为预测时长。为保证作业区内预测准确，随机在三个车道中分别按照 80%、10%与 10%的比例划分为训练集、验证集与测试集。在此基础上，在车辆轨迹中以固定步长滑动生成多个样本窗口。

车辆轨迹以观测末帧作为局部坐标原点，并进行尺度归一化处理，以消除不同路段尺度差异对模型训练的影响。同时，地图包含作业区分区段的车道边界线、车道中心线与交通导改组织设置线三类要素。所有地图要素与轨迹采用统一的局部坐标系表示，并与车辆轨迹进行同步归一化。

模型基于 PyTorch 深度学习框架搭建实验环境，并在配备 NVIDIA GeForce RTX 3080 Ti 显卡的工作站上完成模型训练。训练过程共持续 30 个周期，批次大小设定为 8。训练与评估均固定随机种子，并采用确定性设置控制随机性来源。详细试验超参数配置列于表 2。

表 2 超参数设计

Table 2 Design of hyperparameters

超参数	数值	超参数	数值
输入数据频率	10Hz	优化器类型	Adam
历史观测时长	5s	初始学习率	5×10^{-4}
轨迹预测时长	3s	衰减比例	0.5
尺度归一化系数	50	最小学习率	1×10^{-6}
训练周期	30	平滑项权重	0.005
批次大小	8	随机种子	44

3.2.2 评价指标

选取平均位移误差 (Average Displacement Error, ADE) 与终点位移误差 (Final Displacement Error, FDE) 作为核心评价指标。指标的计算均还原至真实物理尺度的坐标数值，单位统一为米。平均位移误差 (ADE) 为预测轨迹位置与真实轨迹位置在所有预测时间步上的平均欧几里得距离，反映了轨迹拟合的整体贴合度。终点位移误差 (FDE) 为最终时刻轨迹预测位置与真实轨迹位置之间的欧几里得距离，更侧重于评估预测结果对未来趋势判断的准确性。

$$\begin{cases} \text{ADE} = \frac{1}{N} \sum_{i=1}^N \frac{1}{T} \sum_{t=1}^T \|d_t - d_i\|_2 \\ \text{FDE} = \frac{1}{N} \sum_{i=1}^N \|d_T - d_i\|_2 \end{cases} \quad (34)$$

式中：N 为测试样本总数，T 为预测时间长度；

d_t 与 d_i 分别表示第 i 个样本在 t 时刻的预测轨迹位置与真实轨迹位置； d_T 与 d_i 分别表示第 i 个样本在最终时刻的预测轨迹位置与真实轨迹位置。

3.2.3 基准模型选择

为了验证所提出的考虑车道拓扑突变的作业区矢量化轨迹预测方法，将所提 WZ-VectorNet 与以下基准模型进行对比。

(1) 恒速度外推 (CV)^[44]：恒速度外推假设目标车辆短时速度保持不变，利用目标车辆末两帧位置估计速度并线性外推未来位置。该方法不使用邻车信息与作业区地图要素，无需训练。

(2) 恒加速度外推 (CA)：恒加速度外推在恒速度假设基础上进一步引入加速度项，利用末三帧估计速度变化趋势并进行二阶外推。该方法同样不依赖邻车信息与作业区地图要素，无需训练。

(3) LSTM^[25]：以目标车历史轨迹序列为输入，通过门控循环结构建模时间依赖并逐步生成未来轨迹。仅利用目标车历史状态，不显式引入邻车信息与作业区地图要素，用于评估纯数据驱动时间建模在作业区场景中的能力边界。

(4) LaneGCN^[45]：将车道中心线及其拓扑关系构建为图结构，通过车道图上的信息传播获得车道上下文表示，并与车辆运动状态融合输出未来轨迹。模型训练与超参数设置与 WZ-VectorNet 一致，以保证车道表示与训练强度可比。

(5) TNT^[46]：意图驱动的多模态轨迹预测框架，将目标车辆未来运动分解为目标点预测与条件轨迹生成两阶段。模型先在候选目标集合上学习目标分布，再在给定目标条件下生成对应轨迹。在作业区场景中，由于车道封闭与导改组织对车辆意图具有较强约束，车辆未来行为分支相对收敛，主导行为模式更为明确。为展示 TNT 模型最好能力，输出 10 条候选下最小轨迹的误差进行对比。

3.3 试验结果

3.3.1 基准模型对比分析

表 3 给出了所提模型与基准模型在作业区场景下的整体轨迹预测性能对比，并展示了 ADE 和 FDE 评价指标的对比结果。

表 3 WZ-VectorNet 与基准模型对比结果
Table 3 The comparison results of the WZ-VectorNet with baseline models

模型	ADE/m	FDE/m
CV	0.74	1.71
CA	0.98	2.13
LSTM	0.72	1.67
LaneGCN	0.72	1.58
TNT	0.64	1.21
WZ-VectorNet	0.61	1.51

结果表明，基准模型与 WZ-VectorNet 在采集数据集上呈现出符合模型复杂度与建模能力预期的性能分层，从侧面验证了数据集的可用性、任务相关性与一定程度上的有效性。传统的运动学模型 CV 与 CA 误差均较大，说明在作业区内车辆运动明显偏离恒速或恒加速度假定，仅依赖简单外推难以刻画受交通导改组织影响的车辆频繁加减速、换道、让行等复杂行为。深度学习基线模型在一定程度上改善了预测精度。LSTM 引入时间依赖建模后整体性能有所提升，但由于缺乏显式道路结构和交互信息，轨迹预测终点误差仍然较高。LaneGCN 进一步利用了车道拓扑与邻车交互，FDE 降至 1.58 米，较 LSTM 降低约 5.4%，验证了道路几何信息和多主体交互对终点预测的重要性。然而，其 ADE 结果表明整体轨迹拟合能力的提升有限。为展示 TNT 模型最好能力，在其候选轨迹最小误差的条件下，其 ADE 结果降为 0.64 米，FDE 最低达到 1.21 米，说明基于车道候选的目标导向建模对作业区整体轨迹有益。然而在单模态预测的同一评价框架下，TNT 的多模态最小结果依赖真值筛选，不能反映实际单次预测可用性能。相比之下，WZ-VectorNet 取得了最优性能，ADE 为 0.61 米，FDE 为 1.51 米。这一改进不仅来自于作业区车道拓扑突变特征输入与车道语义的显式建模，也与解码阶段对运动先验的处理方式密切相关。WZ-VectorNet 将 CV 作为先验而非预测结果本身，由恒速轨迹提供一个物理上合理的初始外推，再由网络学习预测相对于该先验的残差。该策略在形式上继承了 CV 在短时预测中的稳定性，同时避免了在作业区场景下误差不可控的问题。

3.3.2 消融试验分析

为评估考虑作业区车道拓扑突变处建模方法与解码策略对作业区轨迹预测性能的贡献，构建了以特征消融与解码器消融为核心的对照实验。图 4 与图 5 分别示出了 ADE 和 FDE 的评价结果。图中纵坐标为相对位移残差解码与叠加恒速先验的两类解码器。横坐标依次为仅使用目标车历史轨迹，在此基础上逐一叠加关键相邻车辆交互信息、一般车道几何信息和作业区车道拓扑突变信息的完整输入。




图 4 WZ-VectorNet 消融试验的 ADE 结果

Fig.4 The ADE results of the ablation experiment




图 5 WZ-VectorNet 消融试验的 FDE 结果

Fig.5 The FDE results of the ablation experiment

解码器消融结果表明，在不同特征输入配置下，恒速先验残差解码在 ADE 与 FDE 上整体优于相对位移残差解码，体现出更稳定的预测精度。以完整输入特征信息为例，恒速先验残差解码的 ADE 为 0.61 米，低于相对位移残差解码的 0.97 米，误差降低 37.1%，FDE 从 1.79 米降至 1.51 米，误差降低 15.6%。这一结果说明，作业区车辆在短时预测范围内具有较强的惯性延续特征，恒速先验能够为未来轨迹提供合理的基础运动趋势，而残差分支主要学习车辆受换道决策、邻

车干扰及导改约束引起的局部偏离,从而降低了恒速先验直接回归完整轨迹所带来的累积误差。

特征消融结果表明,多源特征信息对作业区车辆轨迹预测精度具有一定影响,考虑车道拓扑突变的建模方法使得作业区车辆轨迹预测结果精度提升。以仅输入目标车辆历史轨迹为基线,在采用恒速先验残差解码方式下,引入相邻车辆交互信息的单项贡献最为显著, ADE 误差降低 6.0%, FDE 上升 7.8%。这是因为作业区车道封闭迫使车辆交互更加复杂。引入一般车道几何信息后, ADE 变化不显著, FDE 误差降低约 3.4%。这表明周边车辆交互和一般车道几何信息能够改善目标车辆终点位置预测结果。进一步引入车道拓扑突变信息建模后, ADE 下降至 0.61 米,误差降低约 3.3%, FDE 变化不显著。其原因在于,通过显式引入导改组织作用下区段车道连通关系与横向可达方向,能够捕捉作业区车道拓扑突变处道路连通性的演变逻辑,提供更强的结构化约束,从而优化换道过程中的整体预测结果的横向贴合度。而多源特征信息在车道拓扑突变位置对车辆横向运动约束较强,使得终点轨迹预测

偏于保守。考虑到这一差异处于统计波动范围内,可认为完整特征输入在保持终点精度稳定的同时实现了整体轨迹精度最优。因此, WZ-VectorNet 通过考虑车道拓扑突变信息与恒速先验残差解码设计,有效实现作业区内车道拓扑突变影响的车辆轨迹预测。

3.3.3 误差分析

考虑到高速公路作业区内车辆运动受到的车道拓扑突变的影响,精确的横向位置预测对于评估关键换道行为尤为重要。因此,为全面、深入地分析 WZ-VectorNet 在作业区场景下的预测能力,将评价指标严格沿道路行驶方向(纵向误差)与垂直于道路行驶方向(横向误差)进行分解。表 4 给出了作业区不同区段与不同车道条件下的分方向轨迹预测误差结果,并给出了在预测时间 1 秒、2 秒和 3 秒步长下 ADE 与 FDE 的变化规律。由于数据集中轨迹预测起始位置均在警告区与上游过渡区内,因此结果中未呈现缓冲区与作业区的误差分析。

表 4 作业区内分区分段分车道分方向对比结果

Table 4 The comparison results of the areas, lanes, and directions within the work zone

作业区区段	车道	纵向（道路行驶方向）						横向（垂直于道路行驶方向）					
		ADE/m			FDE/m			ADE/m			FDE/m		
		1 秒	2 秒	3 秒	1 秒	2 秒	3 秒	1 秒	2 秒	3 秒	1 秒	2 秒	3 秒
警告区	超车道	0.15	0.42	0.86	0.27	0.97	2.36	0.05	0.11	0.18	0.09	0.24	0.48
	行车道	0.11	0.26	0.48	0.16	0.62	1.24	0.06	0.08	0.13	0.08	0.13	0.26
	慢车道	0.11	0.16	0.35	0.14	0.39	0.86	0.05	0.09	0.12	0.08	0.15	0.24
上游过渡区	超车道	0.16	0.41	0.75	0.31	0.87	1.81	0.06	0.10	0.18	0.09	0.23	0.42
	行车道	0.13	0.31	0.57	0.20	0.74	1.45	0.05	0.11	0.12	0.07	0.15	0.36
	慢车道	0.13	0.20	0.53	0.20	0.64	1.36	0.05	0.10	0.14	0.06	0.17	0.27
缓冲区与作业区	/	/	/	/	/	/	/	/	/	/	/	/	/

以分方向预测结果来看, WZ-VectorNet 在作业区内的纵向误差整体高于横向误差。以最终预测时间 3 秒的预测结果为例,纵向 ADE 为 0.48-0.86 米,纵向 FDE 为 0.86-2.36 米;相比之下横向误差始终保持在较低水平,横向 ADE 仅为 0.12-0.18 米,横向 FDE 控制在 0.24-0.48 米。这说明车辆沿道路行驶方向的速度调整、跟驰演化及换道博弈使其未来位置具有更强不确定性,而模型通过考虑了车道拓扑突变影响的交通导改组织约束与有效通行空间中心线参考,因此对换道行为的横向轨迹演化、车道转移趋势以及换道行为发生过程预测较为稳定。此外,随着预测时长由 1 秒增加至 3 秒,纵、横向误差均呈增长

趋势,但纵向误差增长更为显著,表明长期预测中车辆纵向状态演化是影响整体预测精度的主要因素。

为了进一步分析 WZ-VectorNet 在不同车道上的预测性能差异,统计完整预测时间 3 秒内的预测结果后,示出了超车道、行车道和慢车道在纵横向的 ADE 与 FDE 箱型图,如图 6 所示。从图 6 可以看出,不同车道之间的预测误差存在一定差异。其中,超车道车辆的纵向误差整体高于行车道和慢车道,其纵向误差中位数约为 0.7 米 (ADE) 和 2 米 (FDE),行车道纵向误差中位数约为 0.5 米 (ADE) 和 1.2 米 (FDE),慢车道纵向误差中位数相比之下最低,约为 0.3 米

(ADE) 和 0.9 米 (FDE)。各车道的横向误差整体较小, 且不同车道之间差异不明显。这表明 WZ-VectorNet 在车辆横向位置短时预测方面具有较好的稳定性, 而纵向预测误差则更易受到车辆速度变化和交通交互行为的影响。特别是在数据集场景下, 封闭区域位于超车道范围内, 超车道车辆具有更高的运行速度和更强的机动性, 车辆更容易受到车道收缩、合流以及相邻车辆行为的影响, 从而导致纵向运动不确定性增加。

其次, 为探究 WZ-VectorNet 在车道拓扑突变区域处不同区段的预测性能差异, 同样统计完整预测时间 3 秒内的预测结果后, 示出了警告区、上游过渡区处的纵横向的 ADE 与 FDE 箱型图, 如图 7 所示。

根据图 7 示出的各区段 ADE 与 FDE 的整体趋势来看, 两类评价指标在不同区段之间表现出

一致的变化趋势, 即纵向误差普遍高于横向误差, 上游过渡区误差高于警告区误差。具体来看, 在 ADE 结果中, 警告区 ADE 中位数分别约为 0.4 米和 0.5 米。在 FDE 结果中, 两类区段的纵向误差差异进一步体现, 警告区与上游过渡区的纵向 FDE 中位数分别约为 1.0 米和 1.2 米。而在不同区段的横向误差中, 不论是 ADE 与 FDE 的中位数均维持在 0.1-0.4 米范围内。结合作业区车道拓扑突变的特点来分析, 警告区内道路结构基本保持稳定, 车辆主要处于提前感知与减速阶段, 行驶行为相对稳定, 因此轨迹预测误差较小。而在上游过渡区内, 由于车道封闭和交通导改逐渐开始发挥作用, 车辆需要进行主动变道与速度调整, 车辆之间的交互行为更加复杂, 从而增加了车辆纵向运动的不确定性, 并导致轨迹预测误差有所增加。




图 6 WZ-VectorNet 在各车道的误差分布
Fig.6 Error distribution of WZ-VectorNet in lanes




图 7 WZ-VectorNet 在各区段的误差分布
Fig.7 Error distribution of WZ-VectorNet in different areas




图 8 WZ-VectorNet 在超车道不同区段的可视化结果

Fig.8 Visual results of WZ-VectorNet in different areas of the innermost lane




图 9 WZ-VectorNet 在行车道不同区段的可视化结果

Fig.9 Visual results of WZ-VectorNet in different areas of the middle lane




图 10 WZ-VectorNet 在慢车道不同区段的可视化结果

Fig.10 Visual results of WZ-VectorNet in different areas of the outermost lane

图 8-图 10 示出了 WZ-VectorNet 在各车道、各区段与误差分布相对应具有代表性的可视化结果。整体来看, 预测轨迹与真实轨迹在空间形态上基本一致, 横向位置与真实轨迹趋势较为贴合, 在纵向方向随预测时长出现一定终点偏差, 这表明所提模型引入车道拓扑突变信息对横向约束特征的学习相对充分, 而对车辆纵向速度调整和交互博弈的刻画仍存在不足。上游过渡区预测结果较警告区结果表现出更明显的轨迹偏移, 反映出车辆在作业区车道拓扑条件下具有更高的行为复杂性和不确定性。

4 结 语

(1) 面向高速公路作业区车道拓扑结构突变场景, 提出考虑车道拓扑关键区段和车道语义异质性的作业区矢量化轨迹预测方法 (WZ-VectorNet)。基于西安市绕城高速作业区无人机轨迹数据的实验结果表明, WZ-VectorNet 与基准模型相比在单模态轨迹预测中取得整体最优的轨迹预测性能, ADE 和 FDE 分别为 0.61 米和 1.51 米。

(2) 考虑车道拓扑突变和恒速先验残差解码是提升作业区轨迹预测精度的关键。与仅采用一般车道几何信息相比, 能够在保持 FDE 预测精度稳定的同时 ADE 降低约 3.3%; 在考虑车道拓扑突变条件下, 相比仅采用相对位移残差解码, 恒速先验残差解码在 ADE 和 FDE 分别降低约 37.1%和 15.6%。

(3) 整体来看, 预测轨迹与真实轨迹在空间形态上基本一致, 横向位置与真实轨迹趋势较为贴合, 在纵向方向随预测时长出现一定终点偏差; 超车道的纵向误差整体高于行车道和慢车道; 上游过渡区预测结果较警告区结果表现出更明显的轨迹偏移。这表明所提模型引入车道拓扑突变信息对横向约束特征的学习相对充分, 而对车辆纵向速度调整和交互博弈的刻画仍存在不足。

(4) 需要指出的是, 受限于当前公开可获得的作业区微观轨迹数据较为匮乏, 因此尚未在与研究问题严格一致的开放数据集上开展跨数据集验证。未来工作可引入更贴近作业区特征的开放数据集资源并在问题定义和评价标准一致的前提下开展补充验证, 从而更系统地评估模型

的泛化能力。其次,所提方法误差主要来源于车辆纵向速度调整刻画不足,究其原因现有模型仅依赖交互车辆历史轨迹建模,难以充分描述多车行为在未来时域的演化过程。未来工作可进一步探索作业区内车辆间协同交互轨迹预测建模方法,从而进一步提高轨迹预测精度。

参考文献:

References:

- [1] ZHANG J, LI X, WANG R, et al. Traffic bottleneck characteristics caused by the reduction of lanes in an optimal velocity model[J]. *Physica A: Statistical Mechanics and its Applications*, 2012, 391(7): 2381-2389.
- [2] RAYAPROLU P, ISHAK S, QI Y, et al. Operational assessment of joint and conventional lane merge configurations for freeway work zones[J]. *Journal of Intelligent Transportation Systems*, 2013, 17(4): 255-267.
- [3] WENG J, MENG Q. Incorporating work zone configuration factors into speed-flow and capacity models[J]. *Journal of Advanced Transportation*, 2015, 49(3): 371-384.
- [4] CHENG W, ZHANG P, ZHU H, et al. Analysis of construction area's impacts on traffic flow: A case study on Hangzhou Bay Bridge in China[J]. *Physica A: Statistical Mechanics and its Applications*, 2023, 610: 128393.
- [5] 曾强, 吴献, 王雪松, 等. 道路作业区驾驶行为与交通安全研究综述[J/OL]. *中国公路学报*, 2025[2026-01-09]. <https://kns.cnki.net/KCMS/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=ZGGL20251205009>.
ZENG Qiang, WU Xian, WANG Xu-song, et al. Review of research on driving behavior and traffic safety in road work zone[J/OL]. *China Journal of Highway and Transport*, 2025[2026-01-09]. <https://kns.cnki.net/KCMS/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=ZGGL20251205009>.
- [6] SHAKOURI M, IKUMA L H, AGHAZADEH F, et al. Effects of work zone configurations and traffic density on performance variables and subjective workload[J]. *Accident Analysis & Prevention*, 2014, 71: 166-176.
- [7] DIFEI J, CANCAN S, ZHONGYIN G, et al. Influence of the median opening length on driving behaviors in the crossover work zone—A driving simulation study[J]. *Transportation Research Part F: Traffic Psychology and Behaviour*, 2021, 82: 333-347.
- [8] MA S, HU J, WANG R. Impact of transition areas on driving workload and driving behavior in work zones: A naturalistic driving study[J]. *Applied Sciences*, 2023, 13(21): 11669.
- [9] ZHANG C, WANG B, YANG S, et al. The driving risk analysis and evaluation in rightward zone of expressway reconstruction and extension engineering[J]. *Journal of Advanced Transportation*, 2020, 2020(1): 8943463.
- [10] ZHAO Y, WANG B, ZHANG M, et al. Optimising work zones with enhanced cellular automata and delayed mandatory lane-changing modelling[J]. *Transportmetrica A: Transport Science*, 2025, 0(0): 1-36.
- [11] WU B, ZOU C, LI Y, et al. Impact of road environment on drivers' preference to merging location selection in freeway work zone merging areas[J]. *Journal of Advanced Transportation*, 2022, 2022(1): 2996081.
- [12] HUANG L, REN Z, MENG X. Changing regularity of the interaction effects of multi-scale factors on drivers' merging behaviors in the highway work zone[J]. *Transportation Research Record: Journal of the Transportation Research Board*, 2024, 2678(8): 277-293.
- [13] WANG B, CHEN T, ZHANG C, et al. Toward safer highway work zones: An empirical analysis of crash risks using improved safety potential field and machine learning techniques[J]. *Accident Analysis & Prevention*, 2024, 194: 107361.
- [14] CAO Q, ZHAO Z, ZENG Q, et al. Real-time vehicle trajectory prediction for traffic conflict detection at unsignalized intersections[J]. *Journal of Advanced Transportation*, 2021, 2021: 1-15.
- [15] 邵长桥, 黄群龙. 高速公路改扩建施工区交通流特性[J]. *北京工业大学学报*, 2021, 47(9): 1036-1047.
SHAO Chang-qiao, HUANG Qun-long. Traffic characteristics of reconstruction and extension of expressway work zone[J]. *Journal of Beijing University of Technology*, 2021, 47(9): 1036-1047.
- [16] 张思扬, 赵驰, 张旗. 城市占路施工影响下车辆换道行为研究[J/OL]. *武汉理工大学学报(交通科学与工程版)*, 2025[2025-07-15]. <https://kns.cnki.net/KCMS/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=JTKJ20250319022>.

- ZHANG Si-yang, ZHAO Chi, ZHANG Qi. Study of vehicle lane-changing behavior under the influence of urban work zones[J/OL]. Journal of Wuhan University of Technology (Transportation Science & Engineering), 2025[2025-07-15].
<https://kns.cnki.net/KCMS/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=JTKJ20250319022>.
- [17] STERN R E, CUI S, DELLE MONACHE M L, et al. Dissipation of stop-and-go waves via control of autonomous vehicles: Field experiments[J]. Transportation Research Part C: Emerging Technologies, 2018, 89: 205-221.
- [18] MAI M, WANG L, PROKOP G. Advancement of the car following model of Wiedemann on lower velocity ranges for urban traffic simulation[J]. Transportation Research Part F: Traffic Psychology and Behaviour, 2019, 61: 30-37.
- [19] MA C, LI D. A review of vehicle lane change research[J]. Physica A: Statistical Mechanics and its Applications, 2023, 626: 129060.
- [20] TOLEDO T, KOUTSOPOULOS H N, BEN-AKIVA M E. Modeling integrated lane-changing behavior[J]. Transportation Research Record: Journal of the Transportation Research Board, 2003, 1857(1): 30-38.
- [21] HAO W, ZHANG Z, GAO Z, et al. Research on mandatory lane-changing behavior in highway weaving sections[J]. Journal of Advanced Transportation, 2020, 2020(1): 3754062.
- [22] HOU G, CHEN S. An improved cellular automaton model for work zone traffic simulation considering realistic driving behavior[J]. Journal of the Physical Society of Japan, 2019, 88(8): 084001.
- [23] CHE C, LUO S, ZONG W, et al. Multimodal adversarial informer for highway vehicle lane-changing trajectory prediction[J]. Physica A: Statistical Mechanics and its Applications, 2024, 654: 130158.
- [24] 朱玉全, 刘国庆, 刘擎超, 等. 面向自动驾驶轨迹预测的多尺度注意力与自适应波形学习方法[J/OL]. 交通运输工程学报, 2026[2026-04-20].
<https://kns.cnki.net/KCMS/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=JYGC2026033000B>.
ZHU Yu-quan, LIU Guo-qing, LIU Qing-chao, et al. Multi-scale attention and adaptive waveform learning for trajectory prediction in autonomous driving[J/OL]. Journal of Traffic and Transportation Engineering, 2026[2026-04-20].
<https://kns.cnki.net/KCMS/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=JYGC2026033000B>.
- [25] SHI X, CHEN Z, WANG H, et al. Convolutional LSTM network: A machine learning approach for precipitation nowcasting[EB/OL]. arXiv, 2015.
<http://arxiv.org/abs/1506.04214>.
- [26] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[EB/OL]. arXiv, 2023.
<http://arxiv.org/abs/1706.03762>.
- [27] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2009, 20(1): 61-80.
- [28] 李立, 平振东, 朱进玉, 等. 面向群体行驶场景的时空信息融合车辆轨迹预测[J]. 交通运输工程学报, 2022, 22(3): 104-114.
LI Li, PING Zhen-dong, ZHU Jin-yu, et al. Vehicle trajectory prediction based on spatio-temporal information fusion in crowded driving scenario[J]. Journal of Traffic and Transportation Engineering, 2022, 22(3): 104-114.
- [29] 贾兴利, 曲远海, 朱浩然, 等. 交通预测中的时空图神经网络研究综述: 从模型解构到发展路径[J]. 交通运输工程学报, 2026, 26(1): 46-74.
JIA Xing-li, QU Yuan-hai, ZHU Hao-ran, et al. Research review on STGNN in traffic prediction: from model deconstruction to development path[J]. Journal of Traffic and Transportation Engineering, 2026, 26(1): 46-74.
- [30] WU W, ZHAN Y, YANG L, et al. Optimization of lane-changing advisory of connected and autonomous vehicles at a multi-lane work zone[J]. International Journal of Modern Physics C, 2022, 33(02): 2250020.
- [31] HUANG Z, SMIRNOVA M N, BI J, et al. Analyzing roadway work zone effects on vehicular flow in a freeway ring[J]. International Journal of Modern Physics C, 2023, 34(04): 2350051.
- [32] GAO J, SUN C, ZHAO H, et al. VectorNet: Encoding HD maps and agent dynamics from vectorized representation[EB/OL]. arXiv, 2020.
<http://arxiv.org/abs/2005.04259>.
- [33] 胡杰, 吴作伟, 张志凌, 等. 基于结构化道路的车辆多模态轨迹预测方法[J]. 中国公路学报, 2025, 38(2): 286-295.

- HU Jie, WU Zuo-wei, ZHANG Zhi-ling, et al. Multi-modal vehicle trajectory prediction method based on structured road[J]. China Journal of Highway and Transport, 2025, 38(2): 286-295.
- [34] RHOADES C, WANG X, OUYANG Y. Calibration of nonlinear car-following laws for traffic oscillation prediction[J]. Transportation Research Part C: Emerging Technologies, 2016, 69: 328-342.
- [35] WENG J, LI G, YU Y. Time-dependent drivers' merging behavior model in work zone merging areas[J]. Transportation Research Part C: Emerging Technologies, 2017, 80: 409-422.
- [36] GHOSH A, ZHENG S, TAMBURO R, et al. ROADWork: A dataset and benchmark for learning to recognize, observe, analyze and drive through work zones[EB/OL]. arXiv, 2025. <http://arxiv.org/abs/2406.07661>.
- [37] 马涛, 吴俊, 唐樊龙, 等. 基于多源数据与大模型的无人机巡航风险识别技术[J]. 交通运输工程学报, 2026, 26(3): 75-88.
- MA Tao, WU Jun, TANG Fan-long, et al. Unmanned aerial vehicle cruise risk identification technology based on multi-source data and large models[J]. Journal of Traffic and Transportation Engineering, 2026, 26(3): 75-88.
- [38] 刘越, 梁国华, 陈咨羽, 等. 无人机协同的入口匝道交织区吸波驾驶策略[J]. 交通运输工程学报, 2026, 26(3): 171-184.
- LIU Yue, LIANG Guo-hua, CHEN Zi-yu, et al. UAV-assisted jam-absorption driving strategy for on-ramp weaving sections[J]. Journal of Traffic and Transportation Engineering, 2026, 26(3): 171-184.
- [39] 高铭, 陈鑫, 蒋烁, 等. 基于自适应微调的露天矿山低空无人机旋转目标检测[J]. 交通运输工程学报, 2026, 26(3): 291-302.
- GAO Ming, CHEN Xin, JIANG Shuo, et al. Rotated object detection using low-altitude UAVs for open-pit mines with adaptive fine-tuning[J]. Journal of Traffic and Transportation Engineering, 2026, 26(3): 291-302.
- [40] ADAMEC V, SCHULLEROVA B, BABINEC A, et al. Using the DataFromSky system to monitor emissions from traffic[M]//Transport Infrastructure and Systems. CRC Press, 2017.
- [41] 徐进, 罗松, 陈礼彪, 等. 高速公路应急车道开放工况车辆运行特性[J]. 交通运输系统工程与信息, 2025, 25(03): 372-382.
- XU Jin, LUO Song, CHEN Li-biao, et al. Operating characteristics of vehicles under hard shoulders opening conditions on expressways[J]. Journal of Transportation Systems Engineering and Information Technology, 2025, 25(03): 372-382.
- [42] LI Y, LI L, NI D. Comparative univariate and regression survival analysis of lane-changing duration characteristic for heavy vehicles and passenger cars[J]. Journal of Transportation Engineering, Part A: Systems, 2022, 148(12): 04022109.
- [43] 孟祥海, 张龙钊, 李生龙. 四车道高速公路部分占用超车道交通控制区交通特性及通行能力研究[J]. 交通运输系统工程与信息, 2020, 20(2): 218-224.
- MENG Xiang-hai, ZHANG Long-zhao, LI Sheng-long. Traffic characteristics and capacity of overtaking lane partly occupied traffic control zone of four-lane freeway[J]. Journal of Transportation Systems Engineering and Information Technology, 2020, 20(2): 218-224.
- [44] CHANG M F, LAMBERT J, SANGKLOY P, et al. Argoverse: 3D Tracking and Forecasting with Rich Maps[EB/OL]. arXiv, 2019. <http://arxiv.org/abs/1911.02620>.
- [45] LIANG M, YANG B, HU R, et al. Learning Lane Graph Representations for Motion Forecasting[C]//VEDALDI A, BISCHOF H, BROX T, 等. Computer Vision – ECCV 2020. Cham: Springer International Publishing, 2020: 541-556.
- [46] ZHAO H, GAO J, LAN T, et al. TNT: Target-driven trajectory prediction[EB/OL]. arXiv, 2008. <https://arxiv.org/abs/2008.08294>.