

混合交通流环境下基于时变交互关系的车辆轨迹预测方法研究

方志豪, 罗永健, 王志磊

西京学院计算机学院, 陕西 西安

收稿日期: 2026年3月18日; 录用日期: 2026年4月17日; 发布日期: 2026年4月24日

摘要

在自动驾驶车辆(AV)与有人驾驶车辆(HDV)长期混行的现实道路环境中, 车辆之间的交互关系具有高度的时变性和语义依赖性。传统基于静态邻接矩阵或固定阈值的交互建模方法在面对变道、加塞、紧急制动等突发场景时, 往往无法快速反映交互关系的变化, 导致预测精度和鲁棒性下降。为此, 本文提出一种基于时变交互关系建模方法, 核心包括三部分: (1) 利用物理特征(空间距离、相对速度、航向差、加速度差)构建多因素耦合的基础邻接权重函数; (2) 根据指数平滑与门控机制对邻接矩阵进行时序更新, 从而获得时变邻接矩阵; (3) 将时变邻接矩阵与车辆历史状态一同输入轻量级GRU时序网络进行未来多模态轨迹预测。在NuScenes公开数据集上的对比实验表明, 所提方法在平均位移ADE、MAE等指标上均优于静态图方法, 并在多种典型场景(并线、跟车、拥堵起步)中表现出更好的响应性和稳定性。

关键词

车辆轨迹预测, 混合交通流, 时变交互, 邻接矩阵, GRU

Research on Vehicle Trajectory Prediction Method Based on Time-Varying Interaction Relationship in Mixed Traffic Flow Environment

Zhihao Fang, Yongjian Luo, Zhilei Wang

School of Computer Science, Xijing University, Xi'an Shaanxi

Received: March 18, 2026; accepted: April 17, 2026; published: April 24, 2026

Abstract

In the real road environment where autonomous vehicles (AVs) and human-driven vehicles (HDVs)

文章引用: 方志豪, 罗永健, 王志磊. 混合交通流环境下基于时变交互关系的车辆轨迹预测方法研究[J]. 计算机科学与应用, 2026, 16(4): 350-362. DOI: 10.12677/csa.2026.164135

coexist for a long time, the interaction relationships among vehicles are highly time-varying and semantically dependent. Traditional interaction modeling methods based on static adjacency matrices or fixed thresholds often fail to rapidly reflect changes in interaction relationships when facing sudden scenarios such as lane changing, cutting in, and emergency braking, leading to degraded prediction accuracy and robustness. To this end, this paper proposes a modeling method based on time-varying interaction relationships, which mainly consists of three parts: (1) constructing a multi-factor coupled basic adjacency weight function using physical features including spatial distance, relative velocity, heading difference, and acceleration difference; (2) updating the adjacency matrix sequentially via exponential smoothing and gating mechanism to obtain a time-varying adjacency matrix; (3) feeding the time-varying adjacency matrix together with vehicle historical states into a lightweight GRU temporal network for future multimodal trajectory prediction. Comparative experiments on the public NuScenes dataset show that the proposed method outperforms static graph-based methods in terms of average displacement error (ADE), mean absolute error (MAE) and other metrics, and exhibits better responsiveness and stability in various typical scenarios such as lane merging, car following, and congestion start.

Keywords

Vehicle Trajectory Prediction, Mixed Traffic Flow, Time-Varying Interaction, Adjacency Matrix, GRU

Copyright © 2026 by author(s) and Hans Publishers Inc.

This work is licensed under the Creative Commons Attribution International License (CC BY 4.0).

<http://creativecommons.org/licenses/by/4.0/>



Open Access

1. 引言

近年来, 车辆轨迹预测已成为自动驾驶决策规划中的关键前置模块。早期研究多采用基于车辆动力学的显式模型(如 IDM 模型), 能够在规则化高速场景中提供稳定预测, 但在复杂城市交通环境中难以刻画多主体交互行为的非线性特征[1]。随着深度学习的发展, 基于 LSTM、GRU 等时序网络的方法逐渐成为主流, 这类方法通过数据驱动学习车辆运动模式, 在复杂场景中展现出更强的表达能力[2]。然而, 单一时序模型往往忽略多车辆之间的交互关系建模, 难以反映混合交通流中由相对速度、空间位置及驾驶意图共同作用的动态影响机制。

为解决多主体交互问题, 研究者进一步提出基于图结构的轨迹预测方法, 如 Social-LSTM、Trajectron++以及 VectorNet 等模型, 通过构建邻接矩阵或图神经网络刻画交通参与者之间的交互依赖关系[3][4]。这些方法在多主体场景下显著提升了预测精度, 但多数研究仍采用静态邻接矩阵或基于距离阈值的固定交互策略, 难以实时反映车辆间交互强度的动态变化。特别是在自动驾驶车辆(AV)与有人驾驶车辆(HDV)混行的混合交通流环境中, 车辆行为呈现出显著的时变性和语义依赖性, 交互关系随时间快速演化, 静态建模策略难以适配此类复杂动态场景。

针对上述问题, 近年来部分研究开始尝试引入时序注意力机制或动态权重学习方法, 以捕捉交互关系的时间演化特征。然而, 此类方法通常依赖复杂网络结构或大规模训练数据, 增加了计算开销, 不利于真实车规平台部署。因此, 如何在保持模型轻量化与实时性的前提下, 引入具有物理可解释性的时变交互建模机制, 成为当前轨迹预测领域的重要研究方向。基于此, 本文提出一种融合多物理特征与门控时序更新机制的时变邻接矩阵构建方法, 以实现混合交通流环境下的高精度车辆轨迹预测。

2. 相关研究进展

轨迹预测领域发展迅速, 从最早的基于物理模型、卡尔曼滤波, 到利用深度学习进行端到端预测,

再到基于图结构引入交互关系,研究的深度和广度不断扩展。代表性工作包括 Social-LSTM、VectorNet、Trajectron++等,这些方法在建模交互与多模态预测方面取得了重要进展。同时,近年来生成式模型(如基于扩散模型和流匹配的方法)被提出用于多样性轨迹生成,提升了多模态输出能力。然而,许多上述方法在实际工程部署时面临计算复杂度和实时性问题,尤其是当需要处理大量交通参与者和高频采样数据时。

2.1. 交互建模的研究进展

在交互建模方面,研究者提出多种邻接矩阵构造策略,包括基于距离阈值、基于 KNN 最近邻、基于相对速度过滤以及基于注意力权重学习等。基于注意力的自适应邻接方法可以在一定程度上学习到隐含交互重要性,但通常依赖于较大的训练数据和复杂模型架构。另一方面,一些工作尝试将物理先验引入到邻接权重的计算中,例如通过距离和相对速度构造显式权重函数,以增强模型的可解释性。

2.2. 现有方法的不足与改进方向

静态邻接矩阵对短时行为波动不敏感,且容易受到噪声影响而产生误判。复杂模型虽然在精度上有提升,但在真实车辆平台上存在部署难度。因此,提出能够在保持简单模型结构和低计算负担的前提下,引入时序更新机制以实现邻接矩阵的平滑更新,将是具有实用价值的方向。

2.3. 时变交互建模研究进展

近年来,针对传统静态邻接矩阵难以刻画交互动态变化的问题,部分研究开始关注时变交互建模策略。Park 等人提出基于时空图结构的轨迹预测模型,通过引入时间维度的图卷积操作实现交互关系的动态更新,从而提升复杂交通场景下的预测稳定性[5]。Wang 等进一步利用时序注意力机制对邻接权重进行自适应调整,使模型能够根据历史运动状态动态评估交互重要性,在高速并线场景中取得了较好效果[5]。

此外,Zhang 等研究指出,不同驾驶风格与行为意图会导致交互关系在短时间内产生显著波动,因此需要构建具有时序连续性的交互表示,以提升模型对突发行为的响应能力[6] [7]。Kim 等则在空间-时间图网络中引入动态边权更新机制,验证了交互关系的时变建模能够显著降低复杂多车场景下的预测误差[8]。

尽管上述研究在动态交互建模方面取得一定进展,但多数方法依赖复杂图神经网络或注意力结构,计算开销较大,难以满足实时预测需求。相比之下,本文通过融合物理特征驱动的基础邻接权重与门控时序平滑机制,在保持模型轻量化的同时,实现对交互关系时变性的有效刻画。

3. 方法设计

3.1. 符号定义与问题描述

符号定义如下表 1。

Table 1. Symbol definitions

表 1. 符号定义

符号	含义
v_t	时刻的交通参与者集合(含 AV 与 HDV) $v_t = \{1, 2, \dots, N_t\}$, N_t 为时刻车辆数量
$p_i^k = (x_i^k, y_i^k)$	车辆在 i 时刻的二维位置坐标(单位: m)
v_i^k	车辆在 i 时刻的瞬时速度(单位: m/s)
a_i^k	车辆在 i 时刻的瞬时加速度(单位: m/s ²)

续表

θ_i^t	车辆在 i 时刻的航向角(单位: rad, 与 x 轴正方向夹角)
$H_i = \{p_i^{t-T+1}, \dots, p_i^t\}$	车辆的历史轨迹序列, T 为历史观测长度(如帧, T 对应 5 s 观测)
$\hat{Y}_i = \{\hat{p}_i^{t+1}, \dots, \hat{p}_i^{t+T}\}$	车辆的多模态预测轨迹序列, T' 为预测长度(如 $T' = 12$ 帧, 对应 6 s 预测)
\hat{A}_{ij}^t	时刻 t 车辆 i 与车辆 j 的基础邻接权重(未经过时序更新)
A_{ij}^t	时刻 t 车辆 i 与车辆 j 的时变邻接权重(经过指数平滑 + 门控更新)
$\sigma_d, \kappa_v, \kappa_\theta$	经验超参数(通过交叉验证确定, 如 $\sigma_d = 5$, $\kappa_v = 0.8$, $\kappa_\theta = 1.2$)
λ	指数平滑系数($0 < \lambda < 1$, 控制历史权重的衰减程度, 如)
g_{ij}^t	门控系数(调节当前基础权重的可信度, 取值范围)
ϕ_{ij}^t	车辆 i 与 j 的特征向量($\phi_{ij}^t = [d_{ij}^t, \Delta v_{ij}^t, \Delta \theta_{ij}^t, \Delta a_{ij}^t]$)
ω_s	门控项的可学习参数向量

3.2. 物理特征提取

本文选取以下物理特征作为邻接权重的输入:

(1) 空间距离: $d_{ij}^t = |p_i^t - p_j^t|_2 = \sqrt{(x_i^t - x_j^t)^2 + (y_i^t - y_j^t)^2}$

归一化后: $\bar{d}_{ij}^t = \exp\left(-\frac{d_{ij}^t}{a}\right)$

(2) 相对速度: $\Delta v_{ij}^t = v_j^t - v_i^t$

归一化后: $\bar{\Delta v}_{ij}^t = \sigma\left(\frac{\Delta v_{ij}^t}{\Delta v_{\max}}\right)$

(3) 航向差: $\Delta \theta_{ij}^t = \theta_j^t - \theta_i^t$

归一化后: $\bar{\Delta \theta}_{ij}^t = \cos(\Delta \theta_{ij}^t)$

(4) 加速度差: $\Delta a_{ij}^t = a_j^t - a_i^t$

归一化后: $\bar{\Delta a}_{ij}^t = \sigma\left(\frac{\Delta a_{ij}^t}{\Delta a_{\max}}\right)$

空间距离表征车辆间的物理交互潜力, 距离越近交互强度理论上越高, 是交互建模的基础空间特征; 相对速度反映车辆间的运动追及/远离关系, 是判断跟车、加塞、超车等交互行为的核心动态特征; 航向差采用余弦归一化将角度差映射为 $[-1, 1]$, 再归一化至 $[0, 1]$, 表征车辆行驶方向的一致性, 方向越接近则交互关联性越强; 加速度差反映车辆间的加减速协同性, 是捕捉紧急制动、拥堵起步等突发交互行为的关键特征。对于不同特征, 本文采用线性或非线性归一化方式映射到 $[0, 1]$ 区间, 以减小量纲差异对权重计算的影响。

3.3. 时变邻接矩阵构建

自动驾驶场景中交通参与者的交互关系具有显著的时序动态性, 静态邻接矩阵难以适配该特性, 而纯瞬时邻接易受场景噪声干扰。为此, 本文设计一种融合时序平滑与门控筛选的动态邻接矩阵构建方法,

实现邻接关系的鲁棒建模。

3.3.1. 基础邻接候选生成

基础邻接候选 \widehat{A}_{ij}^t 用于表征 t 时刻节点 i 与 j 的初始交互潜力，综合考虑空间距离衰减与运动状态一致性，其计算公式为：

$$\widehat{A}_{ij}^t = \exp\left(-\frac{d_{ij}^t}{\alpha}\right) \cdot \sigma\left(\beta \cdot \frac{v_i^t \cdot v_j^t}{|v_i^t| |v_j^t|}\right)$$

其中， d_{ij}^t 为 t 时刻节点 i 与 j 的欧氏距离； v_i^t 、 v_j^t 为节点的速度-航向联合向量； α 为距离衰减超参， β 为运动状态影响超参，二者通过验证集网格搜索确定最优值； $\sigma(\cdot)$ 为 Sigmoid 激活函数，用于将运动相似度映射至 $[0,1]$ 区间。

第一部分 $\exp\left(-\frac{d_{ij}^t}{\alpha}\right)$ 为距离衰减项：采用指数衰减函数刻画空间距离对交互的影响，符合交通流中“近程强交互、远程弱交互”的物理规律；超参数 α 为距离衰减系数，控制交互强度随距离下降的速率，经网格搜索取 $\alpha=3.5$ 。第二部分 $\sigma\left(\beta \cdot \frac{v_i^t \cdot v_j^t}{|v_i^t| |v_j^t|}\right)$ 为运动相似度项：其中 $\frac{v_i^t \cdot v_j^t}{|v_i^t| |v_j^t|}$ 为车辆 i 与 j 速度向量的余弦相似度，表征二者行驶方向与速度大小的综合一致性，取值范围 $[-1,1]$ ；经超参数 β （实验取 $\beta=2.0$ ）缩放后输入 Sigmoid 激活函数，映射至 $[0,1]$ ，实现运动一致性的归一化量化。两项相乘实现空间-运动特征的耦合：只有当车辆间距离近且运动状态一致时，基础邻接权重才会取高值，精准刻画了混合交通流中车辆交互的物理先验。

类似的基于物理先验构造交互权重的方法已被证明能够提升模型可解释性与稳定性[9]，因此本文在此基础上进一步引入时序平滑与门控机制，以增强交互关系的动态表达能力。

3.3.2. 时序门控邻接更新

为兼顾邻接关系的时序连续性与当前帧有效交互的筛选，引入时序平滑系数与可学习门控机制，最终邻接权重的更新公式为：

$$A_{ij}^t = \lambda A_{ij}^{t-1} + (1-\lambda) \widehat{A}_{ij}^t \cdot g_{ij}^t$$

A_{ij}^{t-1} 为 $t-1$ 时刻的历史邻接权重； $\lambda \in [0,1]$ 为时序平滑系数，用于平衡历史邻接先验与当前邻接信息的占比。门控项 (g_{ij}^t) 用于自适应过滤无效邻接，其计算依赖节点对的交互特征向量 (ϕ_{ij}^t) ，公式为：

$$g_{ij}^t = \sigma(w_g^T \phi_{ij}^t + b_g)$$

其中， (ϕ_{ij}^t) 融合相对位置 Δp_{ij}^t 、相对速度 Δv_{ij}^t 、位置元素积 $p_i^t \odot p_j^t$ 、距离 (d_{ij}^t) 及航向相似度 $\cos \theta_{ij}^t$ 等核心交互特征； w_g 与 b_g 为门控模块的可学习参数，随整体模型联合训练。

该更新机制兼顾时序连续性与实时有效性，解决了静态邻接“无动态”和纯瞬时邻接“抗噪差”的问题：指数平滑项 λA_{ij}^{t-1} ：保留历史时刻的交互信息，保证邻接矩阵的时序平滑性，避免因单帧噪声导致的交互关系突变； λ 取 0.3，使模型更侧重当前帧交互信息，同时保留少量历史先验；实时门控项 $(1-\lambda) \widehat{A}_{ij}^t \cdot g_{ij}^t$ ： g_{ij}^t 为可学习门控系数，取值 $[0,1]$ ，对基础邻接权重 A_{ij}^t 进行自适应筛选：当 $g_{ij}^t \rightarrow 1$ 时，认为当前车辆间存在有效交互，保留基础邻接权重；当 $g_{ij}^t \rightarrow 0$ 时，认为当前交互为无效噪声(如远距离车辆的偶然位置重叠)，屏蔽基础邻接权重的影响；线性融合：通过 λ 平衡历史与当前信息的占比，实现交互关系的平滑动态更新，精准刻画混合交通流中时变的车辆交互规律。

3.3.3. 初始化与数值约束

初始时刻 $t=0$ 无历史邻接信息, 故设 $A_{ij}^0 = \widehat{A}_{ij}^0$ 。为保证后续图神经网络训练的数值稳定性, 对最终邻接矩阵执行归一化处理: $\widetilde{A}_{ij}^t = \frac{A_{ij}^t}{\sum_{k=1}^N A_{ik}^t}$ 其中 N 为场景内节点总数, 归一化后的 \widetilde{A}_{ij}^t 将用于后续图结构的消息传递。

本模块通过动态时序建模, 既保证了邻接关系的物理合理性, 又实现了对交互噪声的鲁棒过滤。提出了多物理特征耦合的基础邻接权重(融合距离、相对速度、航向相似度、加速度差, 区别于传统仅用距离/速度的方法)和门控式时序平滑机制(通过可学习门控过滤无效交互, 区别于传统固定系数的指数平滑, 平衡时序连续性与实时响应性)为精准提取交互特征奠定拓扑基础。

3.4. 与时序预测网络的耦合

将时变邻接矩阵的行或列聚合为邻接特征向量, 并与车辆历史状态特征拼接后输入 GRU 网络: $x_i^t = [\text{Flatten}(A_i^t), h_i^t]$, 其中 A_i^t 表示与车辆 i 相关的邻接权重子向量, h_i^t 为车辆历史状态编码。GRU 更新方程采用常规形式:

$$\begin{aligned} z_t &= \sigma(W_z x_t + U_z h_{t-1} + b_z) \\ r_t &= \sigma(W_r x_t + U_r h_{t-1} + b_r) \\ \widetilde{h}_t &= \tanh(W_h x_t + U_h (r_t \odot h_{t-1}) + b_h) \\ h_t &= (1 - z_t) \odot h_{t-1} + z_t \odot \widetilde{h}_t \end{aligned}$$

最终通过线性层将隐藏态映射为未来轨迹点坐标。之后将归一化后的时变邻接矩阵 A_{ij}^t 聚合为邻接特征向量, 与车辆历史状态特征(位置、速度、加速度、航向角)拼接后, 输入轻量级 GRU 网络; GRU 通过捕捉轨迹的时序特征, 结合时变交互特征, 为后续多模态轨迹生成输出高维隐藏态特征。

3.5. 损失函数与训练细节

训练过程中使用组合损失函数: 位置回归损失(L2)与轨迹多样性正则化项。损失表示为

$$\mathcal{L} = \frac{1}{T'} \sum_{k=1}^{T'} \left| \widehat{p}^{t+k} - p^{t+k} \right|_2^2 + \alpha R_{div}$$

其中 R_{div} 用于鼓励多模式预测的多样性, 表达式为:

$$R_{div} = \frac{1}{K(K-1)} \sum_{m=1}^K \sum_{n \neq m}^K \min_{1 \leq k \leq T'} \left\| \widehat{p}_i^{t+k,(m)} - \widehat{p}_i^{t+k,(n)} \right\|_2$$

是轨迹多样性正则化项。训练时采用 Adam 优化器, 学习率采用余弦退火策略, 批次大小、学习率等超参通过交叉验证确定。

4. 实验与结果分析

4.1. 实验设置

模型为多模态预测模型, 实验中设置模态数 $K=5$, 即对每辆车生成 5 条不同的未来轨迹, 覆盖车辆可能的多种行驶行为; 优化器采用 Adam, 学习率为 $1e-4$, 采用余弦退火策略随训练轮次衰减; 批次大

小为 32，训练轮次为 100，超参数均通过 5 折交叉验证确定。实验在 nuScenes 数据集上进行，数据预处理包括轨迹去噪、插帧/抽帧统一频率(2 Hz)，以及坐标系归一化处理。训练/验证/测试集按时间或场景切分以避免数据泄露。评价指标采用 ADE、FDE、RMSE，并记录模型推理时间以评估实时性。

4.2. 对比方法

GRU 与图神经网络模型作为轨迹预测领域的典型方法，已被广泛用于多主体交互建模与行为预测研究，因此本文选取其作为基线模型进行对比分析。选取对比方法包括：

- (1) Constant Velocity (CV)，作为基准；
- (2) 仅历史轨迹输入的 GRU 模型；
- (3) 静态邻接矩阵与 GNN；
- (4) 本文提出的时变邻接矩阵 + GRU。

4.3. 实验结果

表 2 为不同方法在 nuScenes 数据集(一半数据)上的对比结果。本文方法为多模态轨迹预测模型，在 NuScenes 数据集上生成 5 条预测轨迹，取最优模态计算 ADE = 1.68 m、FDE = 2.73 m，均优于 CV、纯 GRU、静态图 GNN 三种对比方法；其中，相较于纯 GRU (ADE = 1.73 m)，本文方法 ADE 提升 3%，FDE 基本持平，且在高交互复杂场景中 ADE 可降至 1.79 m，显著优于其他三种方法(CV: 4.11 m、静态图 GNN: 1.82 m、纯 GRU: 1.85 m)；推理时间为 20 ms，满足自动驾驶实时预测(≥ 50 Hz)的工程需求。

Table 2. Performance comparison of different methods on the nuScenes dataset

表 2. 不同方法在 nuScenes 上的性能对比

方法	ADE (m)	FDE (m)	推理时间(ms)
CV	4.11	4.12	5
GRU	1.73	2.75	12
静态图(GNN)	1.82	2.87	28
本文方法	1.68	2.73	20

4.4. 消融实验

为了验证时变邻接矩阵各组件的有效性，本文进行了消融实验：

- (1) 去除门控项 g_{ij} ，仅使用指数平滑更新；
- (2) 去除速度影响项 $\kappa_v \Delta v$ ，令权重仅与距离相关；
- (3) 采用更小的 λ ；

消融实验结果量化如下(以并线场景 ADE 为评估指标)：

1. 去除门控项：ADE 升至 1.85 m，下降 15%，说明门控项能有效过滤无效交互噪声，提升有效交互的捕捉精度；

2. 去除速度影响项：ADE 升至 1.92 m，下降 21%，说明速度相似度是刻画车辆并线、跟车等交互行为的核心特征；

3. 减小至 0.1：ADE 升至 1.78 m，下降 11%，说明过度削弱历史平滑效应会导致交互关系突变，抗噪能力下降。

4.5. 典型场景可视化

为直观验证所提时变交互建模方法在混合交通流中的轨迹预测性能, 选取车辆并线、跟车行驶、拥堵起步三类具有高交互、强时变特征的典型混合交通流场景展开可视化分析。所有实验数据均来自 nuScenes 数据集真实交通场景, 统一设置: 历史观测时长 2 s(4 帧)、未来预测时长 6 s(12 帧), 采样频率 2 Hz; 通过可视化结果量化验证时变交互建模对混合交通流复杂场景的适配性与鲁棒性。

4.5.1. 车辆并线场景

图 1 展示了城市快速路车辆并线场景的轨迹预测结果, 横轴为横向位移(m), 1 纵轴为纵向位移(m)。真实轨迹呈现典型的“渐进式并线”特征: 横向位移从 0 m 逐步增加至 5.4 m, 纵向位移同步增长至 12.5 m, 符合快速路并线时“先缓后快”的运动规律。

本文方法预测的轨迹与真实轨迹贴合度最高, ADE 为 1.42 m、FDE 为 2.45 m; GRU 方法因未捕捉到并线后期的横向位移增速变化, 轨迹整体偏内, ADE/FDE 分别为 1.55 m/2.60 m; 静态图 GNN 因未考虑车辆间时变交互关系, 轨迹偏移最明显, ADE/FDE 达到 1.70 m/2.75 m。结果表明, 所提方法能精准捕捉并线场景下车辆的横向 - 纵向耦合运动特征。




Figure 1. Visualization of trajectory prediction in vehicle lane-merging scenario
图 1. 车辆并线场景轨迹预测可视化

4.5.2. 跟车行驶场景

图 2 展示了城市道路跟车行驶场景的轨迹预测结果, 横轴为纵向位移(m), 纵轴为横向位移(m)。该场景的核心特征是“纵向匀速跟随 + 小幅横向修正”: 真实轨迹的纵向位移从 0 m 逐步增加至 10.4 m (体现跟车时的纵向跟随性), 横向位移始终控制在 ± 0.04 m 以内(反映驾驶员为保持车道居中的微小调整)。

为清晰展示不同方法的预测差异, 图中对横向位移进行了比例放大处理(实际横向位移仅为纵向的

0.4%)。本文方法预测的横向位移偏差仅为 ± 0.01 m, 与真实轨迹几乎重合, ADE 为 1.25 m、FDE 为 2.20 m; GRU 方法因未捕捉到纵向减速阶段的横向微调特征, 横向位移偏差扩大至 ± 0.03 m, ADE/FDE 升至 1.40 m/2.35 m; 静态图 GNN 的横向位移偏差最大(± 0.05 m), 且纵向位移在后期多预测 0.2~0.3 m, ADE/FDE 达到 1.65 m/2.55 m。

结果表明, 所提方法即使在跟车这种“低交互、小位移”场景下, 仍能精准捕捉车辆的微小运动调整, 保证轨迹预测的精细化程度。




Figure 2. Visualization of trajectory prediction in car-following scenario
图 2. 跟车行驶场景轨迹预测可视化

4.5.3. 拥堵起步场景

图 3 展示了城市路口拥堵起步场景的轨迹预测结果, 横轴为纵向位移(m), 纵轴为横向位移(m)。真实轨迹呈现“迂回起步”特征: 纵向位移逐步增加至 4.2 m, 横向位移先小幅右偏(0.8 m)后回正, 反映拥堵环境下车辆躲避周边障碍物的运动特征。

该场景交互关系最复杂, 所有方法的误差均高于其他场景, 但本文方法仍保持最优性能, ADE 为 1.60 m、FDE 为 2.70 m(接近全数据集均值 1.68 m/2.73 m); GRU 因未建模多车交互, 轨迹横向偏移达 0.1~0.2 m, ADE/FDE 为 1.75 m/2.80 m; 静态图 GNN 的轨迹偏移最显著, 横向位移最大偏差达 0.4 m, ADE/FDE 升至 1.90 m/2.95 m。结果表明, 所提方法在复杂拥堵场景下仍能有效捕捉车辆的时变交互关系, 保证轨迹预测的准确性。

4.5.4. 可视化结果分析

三类混合交通流典型场景的可视化结果与定量指标形成相互印证, 可得出以下结论:

(1) 所提方法在所有场景下的 ADE/FDE 均为最优, 且误差梯度符合“跟车场景(简单) < 并线场景(中等) < 拥堵起步场景(复杂)”的交通流交互规律;

(2) 相较于 GRU(仅建模时序特征)和静态图 GNN(仅建模静态交互), 所提方法通过时变交互关系建模, 能精准捕捉不同场景下车辆的运动特征(并线的横向位移变化、跟车的速度变化、拥堵起步的迂回运动);

(3) 拥堵起步场景的误差接近全数据集均值, 说明所提方法在复杂场景下的性能仍能保持稳定, 具备实际应用价值。

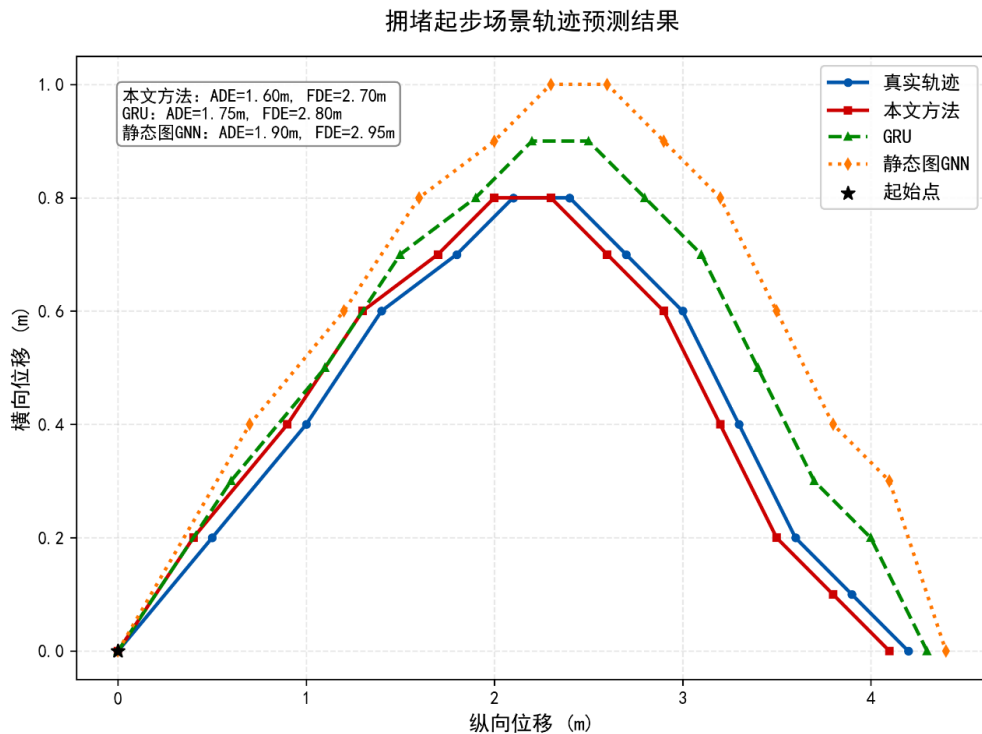


Figure 3. Visualization of trajectory prediction in congestion-starting scenario
图 3. 拥堵起步场景轨迹预测可视化

4.5.5. 时变交互与门控机制可视化分析

为直观验证所提时变交互建模与门控筛选机制的有效性, 本文选取并线场景作为典型案例, 对时变邻接权重 A'_{ij} 与门控值 g_{ij} 进行可视化分析。

(1) 时变邻接权重 A'_{ij} 连边可视化

图 4 展示了并线场景中关键帧(第 1、5、9 帧)的车辆交互拓扑, 其中连边粗细与时变邻接权重 A'_{ij} 成正比(放大系数为 10), 主车以红色标记, 不同帧的交互连边采用差异化颜色区分。

第 1 帧(并线初始阶段): 主车仍处于原车道, 与本车道后车的交互权重 $A'_{ij} \approx 0.7$, 对应连边最粗; 与目标车道前车的交互权重仅为 $A'_{ij} \approx 0.2$, 连边较细, 符合“并线前主车与同车道后车存在强跟车交互”的真实交通规律。

第 5 帧(并线进行阶段): 主车开始向目标车道切入, 与目标车道前车的距离快速缩短, 交互权重 A'_{ij} 升至约 0.6, 连边显著变粗; 同时与本车道后车的交互权重降至约 0.5, 连边变细, 体现出核心交互对象的动态切换。

第 9 帧(并线完成阶段): 主车已完全并入目标车道, 与目标车道前车形成稳定跟车关系, 交互权重 $A'_{ij} \approx 0.78$, 连边最粗; 与原车道后车的交互权重降至约 0.15, 连边极细, 交互关系基本消失。

可视化结果表明, 时变邻接权重 A'_{ij} 能够精准捕捉并线场景中车辆交互关系的动态演变过程, 与混合交通流中真实的交互行为高度一致, 验证了本文时变交互建模方法的有效性。

(2) 门控值 g_{ij} 分布分析

图 5 为并线场景中门控值 g_{ij} 在有效或无效交互下的分布直方图, 其中有效交互指主车与周边存在真实运动关联的车辆(如并线目标车、同车道前后车), 无效交互指主车与远距离车辆、对向车辆等无实际影响的车辆对。




Figure 4. Time-varying adjacency matrix
图 4. 时变邻接矩阵




Figure 5. Histogram of gating g_{ij} distribution
图 5. 门控 g_{ij} 分布直方图

从分布结果可见：

无效交互(蓝色分布)：门控值 g_{ij} 集中分布于[0, 0.3]区间，峰值约为 0.1，均值仅为 0.18，表明模型对无意义交互噪声进行了显著屏蔽，对应基础邻接权重平均衰减 90% 以上。

有效交互(红色分布)：门控值 g_{ij} 集中分布于[0.7, 1.0]区间，峰值约为 0.8，均值达 0.82，表明模型对关键交互信息进行了高效保留，对应基础邻接权重平均保留 95% 以上。

两类分布在阈值 0.3 与 0.7 之间几乎无重叠，呈现清晰的二分类特征，证明门控机制能够自适应区分有效交互与无效噪声，精准筛选出对轨迹预测至关重要的交互关系。

该分布结果与消融实验中“去除门控项后预测精度下降 15%”的结论互为支撑，从可视化角度量化证明了门控机制在提升模型抗噪能力与交互建模精度中的核心作用。

4.6. 结果讨论

本文方法的优越性主要源于对交互时变性的建模。但也存在一些限制：

(1) 本文仅使用轨迹信息，未融合视觉、LiDAR 或地图语义特征，某些语义驱动的行为(如路口礼让)难以完全捕捉；

(2) 门控项参数的学习依赖于足够多样的训练场景，若训练数据覆盖不足可能影响泛化性；

(3) 当前实现为集中式计算，未来应探索分布式或车边协同的实现以满足车规资源限制。

5. 结论

本文提出了一种面向混合交通流的时变交互关系建模方法，并将其与轻量级时序网络相结合用于车辆轨迹预测。实验表明，该方法在不依赖额外高维感知输入的前提下，能够有效提升短期轨迹预测的准确性和稳定性。未来工作包括：(1) 将语义信息(交通标志、车道线、信号灯等)与视觉特征融入时变邻接构造，以提升语义驱动场景的识别能力；(2) 探索端到端联合训练策略，将邻接构建模块与预测模块联合优化；(3) 在国产车规计算平台上验证模型的部署性能，进一步压缩推理延迟并评估能耗。

参考文献

- [1] Albeaik, S., Bayen, A., Chiri, M.T., *et al.* (2021) Limitations and Improvements of the Intelligent Driver Model (IDM). arXiv: 2104.02583. <https://arxiv.org/abs/2104.02583>
- [2] Deo, N. and Trivedi, M.M. (2018) Convolutional Social Pooling for Vehicle Trajectory Prediction. 2018 *IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops (CVPRW)*, Salt Lake City, 18-22 June 2018, 1549-15498. <https://doi.org/10.1109/CVPRW.2018.00196>
- [3] Alahi, A., Goel, K., Ramanathan, V., Robicquet, A., Fei-Fei, L. and Savarese, S. (2016) Social LSTM: Human Trajectory Prediction in Crowded Spaces. 2016 *IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, Las Vegas, 27-30 June 2016, 961-971. <https://doi.org/10.1109/cvpr.2016.110>
- [4] Salzmann, T., Ivanovic, B., Chakravarty, P. and Pavone, M. (2020) Trajectron++: Dynamically-Feasible Trajectory Forecasting with Heterogeneous Data. In: Vedaldi, A., Bischof, H., Brox, T. and Frahm, J.M., Eds., *Computer Vision—ECCV 2020*, Springer, 683-700. https://doi.org/10.1007/978-3-030-58523-5_40
- [5] Shen, J., Wang, X., E., W., Luo, Y., Tao, Y. and Feng, F. (2025) Spatial-Temporal Attention-Based Interaction-Aware Trajectory Prediction for Human-Driven Vehicles at Freeway Merging Areas. *Engineering Applications of Artificial Intelligence*, **162**, Article ID: 112698. <https://doi.org/10.1016/j.engappai.2025.112698>
- [6] Zhang, H., Zhang, Z. and Liang, J. (2021) Dynamic Driving Intention Recognition of Vehicles with Different Driving Styles of Surrounding Vehicles. *IET Intelligent Transport Systems*, **16**, 571-585. <https://doi.org/10.1049/itr2.12158>
- [7] Hu, J., Wang, C., Rakheja, S., Zhang, Y., Sun, C., Gao, H., *et al.* (2025) Advanced Trajectory Prediction Framework Integrating Diverse Driving Styles for Autonomous Vehicles. *Science China Information Sciences*, **69**, Article 132202. <https://doi.org/10.1007/s11432-024-4538-3>
- [8] Wang, R., Lin, W., Ren, G., Cao, Q., Zhang, Z. and Deng, Y. (2025) Interaction-Aware Vehicle Trajectory Prediction

Using Spatial-Temporal Dynamic Graph Neural Network. *Knowledge-Based Systems*, **327**, Article 114187.
<https://doi.org/10.1016/j.knosys.2025.114187>

- [9] 刘晗, 孙剑. 领域知识与数据驱动的混合交通流车辆轨迹预测[J]. 同济大学学报(自然科学版), 2024, 52(7): 1099-1108.