

# 基于 Social GAN 网络与自注意力机制的车辆轨迹预测方法\*

祝朗千<sup>1</sup> 马时俊<sup>1</sup> 刘明剑<sup>1,2</sup> 李沐阳<sup>1</sup> 郝昌盛<sup>1</sup>

(1.大连海洋大学信息工程学院,大连 116032;2.大连海洋大学设施渔业教育部重点实验室,大连 116023)

**【摘要】**针对车辆行驶中时间特征与交通环境空间影响车辆轨迹预测精度的问题,基于社交生成式对抗网络(Social GAN),提出一种融合多头自注意力与社交池化的车辆轨迹预测方法。首先,通过目标车辆自身轨迹数据的时间关联性,使用多头自注意力机制提取历史轨迹特征;然后,根据目标车辆与周围车辆的空间位置关系,采用社交池化机制提取目标车辆的空间维度特征;最后,通过编码器-解码器获得目标车辆的预测轨迹。使用NGSIM数据集进行模型训练与对比试验,结果表明:在高速公路场景下,提出方法在车辆轨迹预测中具有更高的预测精度和效率。

**关键词:**智能车辆 轨迹预测 生成式对抗网络 社交池化机制 自注意力机制

**中图分类号:**TP183;U461.91 **文献标志码:**A **DOI:** 10.19620/j.cnki.1000-3703.20240867

## Vehicle Trajectory Prediction Method Based on Social GAN Network and Self-Attention Mechanism

Zhu Langqian<sup>1</sup>, Ma Shijun<sup>1</sup>, Liu Mingjian<sup>1,2</sup>, Li Muyang<sup>1</sup>, Hao Changsheng<sup>1</sup>

(1. College of Information Engineering, Dalian Ocean University, Dalian 116023; 2. Key Laboratory of Environment Controlled Aquaculture, Ministry of Education, Dalian Ocean University, Dalian 116023)

**【Abstract】**To address the issue that temporal features and spatial factors of the traffic environment affect the accuracy of vehicle trajectory prediction in vehicle driving, this paper proposes a vehicle trajectory prediction method integrating temporal multi-head self-attention and social pooling based on the Social Generative Adversarial Network (SMA-GAN). Firstly, the historical trajectory features are extracted by the temporal correlation of the target vehicle's own trajectory data using the multi-head self-attention mechanism. Then, the spatial dimensional features of the target vehicle are extracted by the social pooling mechanism based on the spatial positional relationship between the target vehicle and the surrounding vehicles. Finally, the predicted trajectory of the target vehicle is obtained by the encoder-decoder. Model training and comparison tests are conducted using the NGSIM dataset, and the results show that the SMA-GAN model has higher prediction accuracy and efficiency in the highway scene.

**Key words:** Intelligent vehicle, Trajectory prediction, Generative Adversarial Network (GAN), Social pooling mechanism, Self-attention mechanism

**【引用格式】**祝朗千,马时俊,刘明剑,等.基于Social GAN网络与自注意力机制的车辆轨迹预测方法[J].汽车技术,2025(6):8-14.

ZHU L Q, MA S J, LIU M J, et al. Vehicle Trajectory Prediction Method Based on Social GAN Network and Self-Attention Mechanism[J]. Automobile Technology, 2025(6): 8-14.

## 1 前言

随着智能交通系统的迅速发展,车辆轨迹预测技术能够感知复杂交通环境中的潜在风险因素,结合驾驶辅

助系统的应用<sup>[1]</sup>,对于提升行车安全具有重要意义。

目前,多数研究根据车辆特征和驾驶员意图预测未来车辆轨迹,主要分为传统机器学习方法与深度学习方。对于传统机器学习方法方面,Abbas等<sup>[2]</sup>将道路车辆

\*基金项目:国家自然科学基金项目(61802046);辽宁省属本科高校基本科研业务费专项(2024JBQNZ007);辽宁省教育厅基本科研项目(LJ212410158018)。

通信作者:刘明剑(1984—),讲师,主要研究方向为多智能体协作,liumingjian@dlou.edu.cn。

划分为5种运动状态并预测车辆轨迹,文献[3]~文献[5]使用无监督聚类算法对不同驾驶风格进行识别,并通过模型生成特定车辆的驾驶风格。但对于复杂的交通场景,模型难以分辨车辆行为,容易影响模型分类的准确性。

对于深度学习方面,长短时记忆(Long Short-Term Memory, LSTM)网络可有效捕捉特征间长期依赖关系而被广泛应用。文献[6]~文献[9]将LSTM与卷积神经网络结合,充分提取多辆车间历史轨迹的交互信息;朱云鹤等<sup>[10]</sup>利用编解码器和滑动窗口,提取行驶车辆的历史特征向量;季学武等<sup>[11]</sup>使用LSTM模型识别驾驶员意图,利用解码器输出预测轨迹。为了描述不同行人对目标车辆的作用,Alahi等<sup>[12]</sup>利于社交池化(Social Pooling)层将空间位置网格化,网格内行人轨迹的隐藏状态视为空间的社交影响。Gupta等<sup>[13]</sup>基于生成对抗网络(Generative Adversarial Network, GAN)<sup>[14]</sup>提出了Social-GAN模型,根据多个行人的相对距离和隐藏状态提取最显著的特征,生成符合行人运动规律的轨迹。Qin等<sup>[15]</sup>使用网格地图描述其空间和时间的流动性分布。上述方法虽能提取车辆间空间关系,但车辆历史轨迹中关键时序特征的特征仍显不足。

为了进一步分析车辆特征,可通过注意力机制捕捉车辆交互关系与关键时序特征。文献[16]~文献[19]将LSTM网络结合注意力机制,提高了轨迹预测精度;李文礼等<sup>[20]</sup>通过构建车辆间影响力场函数,利用轨迹间的时空特征实现车辆轨迹预测;Yang等<sup>[21]</sup>分析道路线形对车辆换道意图的影响,提出了意图卷积混合注意网络;Sun等<sup>[22]</sup>利用Transformer模型<sup>[23]</sup>的多头注意力(Multi-Head Attention, MHA)提取融合车辆与环境特征,提高了预测精度。虽然注意力机制能够提升对车辆特征的建模能力,但难以量化周围车辆对目标车辆的影响关系与历史轨迹特征,容易导致预测精度下降。

通过结合周围车辆数据的时空关联性,提高较长时域中车辆轨迹的预测精度,本文提出了一种基于生成对抗网络融合时间多头自注意力与社交池化(Social pooling and Multi-head Self-Attention Generative Adversarial Networks, SMA-GAN)的车辆轨迹预测模型。采用时间自注意力模块,提取目标车辆的历史轨迹特征;构建社交池化模块,捕捉周围车辆的影响关系;融合时空特征,利用编码器-解码器结构生成目标车辆的未来轨迹。同时,通过消融试验和对比试验,验证本文模型的有效性。

## 2 基于时空融合的轨迹预测模型

### 2.1 车辆轨迹预测形式化定义

在城市道路行驶过程中,车辆根据周车和行人动态修

正前进的方向和速度,进而改变车辆行驶轨迹。在一段时间内,当前时刻的车辆位置变化与上一时刻的车辆位置、环境存在较强关联性。因此,本文将车辆轨迹预测问题视为时间序列问题,探究车辆轨迹的时间、空间的关联性。

以当前场景假定为平面坐标系,对于各场景的目标车辆,定义各时刻的所有车辆坐标,目标车辆集合为:

$$C = \{c_i | 1 \leq i \leq n, i \in N^+\} \quad (1)$$

式中: $c_i$ 为第*i*个目标车辆。

车辆在*t*时刻的状态向量为:

$$c_i = (t_i, x_i, y_i, v_i, a_i, \theta_i) \quad (2)$$

式中: $x_i, y_i$ 分别为车辆所在坐标系的横、纵坐标, $v_i$ 为车辆行驶速度, $a_i$ 为车辆加速度, $\theta_i$ 为车辆的转向角。

将预测过程的时间集合分为历史时间集合和未来轨迹预测时间集合,目标车辆的时间集合为:

$$T_i = \{t_j | t_0 \leq t_j \leq t_{\text{end}}, j \in N\} \quad (3)$$

$$T_i^{\text{his}} = \{t_j | t_0 \leq t_j \leq t_{\text{obs}} - 1, j \in N\} \quad (4)$$

$$T_i^{\text{pre}} = \{t_j | t_{\text{obs}} \leq t_j \leq t_{\text{end}}, j \in N\} \quad (5)$$

式中: $T_i$ 为车辆所有时间集合, $t_j$ 为第*j*时刻, $T_i^{\text{his}}, T_i^{\text{pre}}$ 分别为历史时间集合和预测时间集合, $t_0, (t_{\text{obs}} - 1)$ 分别为历史轨迹的起始时间和终止时间, $t_{\text{obs}}, t_{\text{end}}$ 分别为预测轨迹的起始时间和终止时间。

在训练过程中,目标车辆状态集合、历史轨迹状态集合、预测轨迹状态集合分别为:

$$P_i = \{c_j | c_i \in C, t_j \in T_i, i, j \in N^+\} \quad (6)$$

$$P_i^{\text{his}} = \{c_j | c_i \in C, t_j \in T_i^{\text{his}}, i, j \in N^+\} \quad (7)$$

$$P_i^{\text{pre}} = \{c_j | c_i \in C, t_j \in T_i^{\text{pre}}, i, j \in N^+\} \quad (8)$$

### 2.2 模型框架

基于生成对抗网络,结合自注意力机制与社交池化机制,本文提出一种基于时间与空间特征融合的车辆轨迹预测方法,模型的总架构如图1所示。

首先,考虑目标车辆行驶轨迹的时间相关性,将车辆历史轨迹信息输入轨迹生成器,经编码器处理后,传输至自注意力模块,生成车辆时间维度的特征向量;其次,量化周车对目标车辆的影响,将历史特征向量输入社交池化模块,得到空间维度的特征向量;然后,将时间特征向量与空间特征向量融合输入解码器,循环生成未来预测轨迹;最后,将车辆预测轨迹与真实轨迹输入轨迹判别器,生成判断概率,使生成轨迹分布更加接近车辆真实轨迹,令生成器与判别器共同进步。

#### 2.2.1 轨迹生成器

轨迹生成器包含编码器模块、时间多头注意力层、

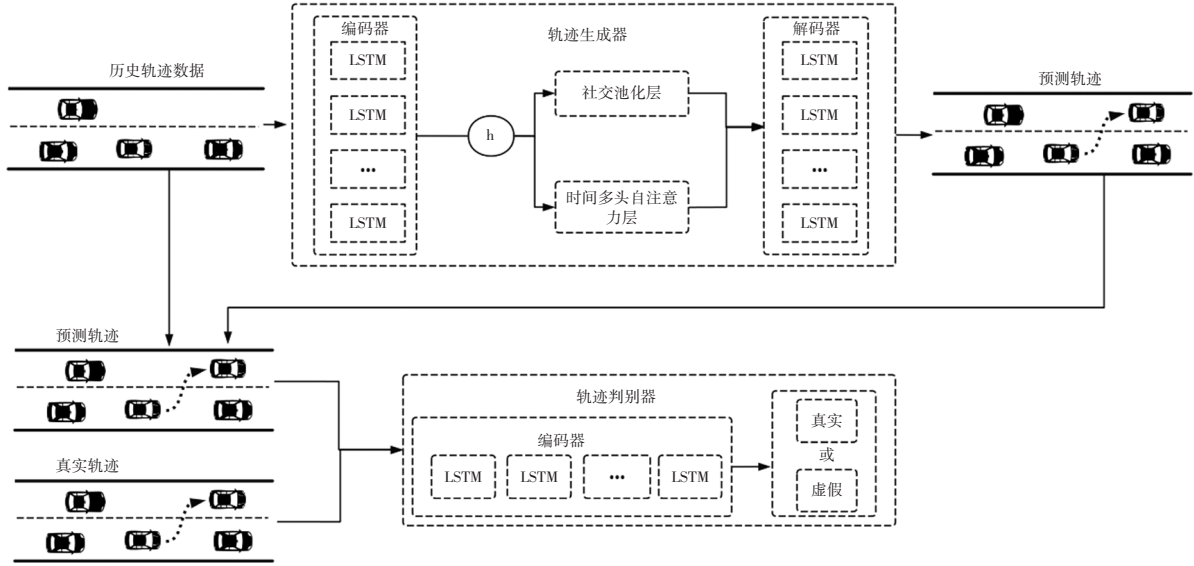


图1 SMA-GAN整体框架

社交池化层以及解码器模块。编码器模块利用 LSTM 对每辆车的历史轨迹序列建模,根据上一时刻的隐藏层状态和当前时刻的输入,输出车辆行驶历史轨迹的特征向量:

$$h_i' = LSTM(h_{i-1}'; W_e) \quad (9)$$

式中:  $W_e$  为 LSTM 层的可学习权重。

由于当前时刻车辆状态与过去时刻状态高度相关,为了使模型更好地学习车辆轨迹的时间特征,采用多头注意力模块,提取每辆车在时间维度的关联性,模块架构如图 2 所示。

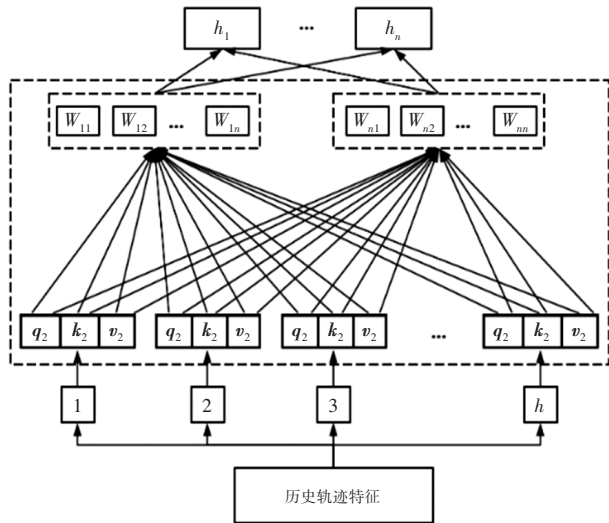


图2 时间多头自注意力模块

使用自注意力机制处理序列数据,能够考虑序列中所有位置,有效地捕捉车辆行驶数据特征。通过时间多头注意力机制,提取车辆历史轨迹数据的隐藏状态。将第  $i$  辆车的车辆行驶历史轨迹特征向量  $h_i'$  传输至时间多头注意力模块,相关过程为:

$$\begin{cases} q_i = h_i' \times W_q; W_q \in R \\ k_i = h_i' \times W_k; W_k \in R \\ v_i = h_i' \times W_v; W_v \in R \end{cases} \quad (10)$$

式中:  $W_q, W_k, W_v$  分别为自注意力中对应查询矩阵  $q_i$ 、关键矩阵  $k_i$  和数值矩阵  $v_i$  的权重参数。

计算当前时刻  $n$  个注意力头的车辆注意力值,并进行拼接,得到时间相关特征向量:

$$\begin{cases} h_n = \text{softmax}\left(\frac{q_i(k_i)^t}{\sqrt{d_k}}\right)v_i \\ h_i^{\text{rep}} = \text{Concat}(h_1, h_2, \dots, h_n) \end{cases} \quad (11)$$

式中:  $h_n$  为车辆  $i$  在任意时刻  $t$  的第  $n$  个自注意力特征值,  $d_k$  为关键矩阵的维度,  $h_i^{\text{rep}}$  为任意时刻拼接车辆  $n$  个注意力头的车辆时间特征向量集合。

为了量化车辆间的社交关系,利用社交池化层提取行驶车辆与周车的空间特征,如图 3 所示。以目标车辆为中心,选择当前时刻目标车辆所在车道及其左、右两侧车道中,与起始坐标位置相距不超过 60 m 的车辆,并提取其轨迹信息,将编码后的隐藏状态特征融合为全新的状态特征,作为车辆社交池化特征。




图3 社交池化模块

在解码器阶段,编码器隐藏态与该时刻社交池化向

量混合初始化解码器,由前一刻社交汇集向量和自注意力模块提取的特征共同组成汇聚向量,作为隐藏态传递。首先,通过位置信息进行车辆观测序列的社交分类,将同一时刻  $m$  个车辆状态向量  $\mathbf{h}_i^t$  依次输入社交池化层,得到社交池化向量  $\mathbf{s}_i^t$ 。然后,将  $\mathbf{s}_i^t$  与  $\mathbf{h}_i^{\text{ep}}$  融合输入多层感知机(Multi-Layer Perceptron, MLP),再与随机高斯分布噪声向量  $\mathbf{z}$  连接,作为解码器 LSTM 网络层的初始隐藏状态。解码器在  $t$  时刻预测轨迹时,利用前一刻的映射向量初始化 LSTM,得到后一刻车辆的预测点  $(\hat{x}_i, \hat{y}_i)$ 。

解码器循环见式(12),将车辆所有时刻预测轨迹数据更新至预测轨迹状态集合  $P_i^{\text{pre}}$ 。

$$\begin{cases} \mathbf{s}_i^t = \text{Pool}(\mathbf{h}_i^t, \mathbf{h}_{i+1}^t, \dots, \mathbf{h}_{i+m}^t) \\ \mathbf{e}_i^t = \text{MLP}(\mathbf{s}_i^t, \mathbf{h}_i^{\text{ep}}; \mathbf{W}_{\text{MLP}}) \\ \mathbf{h}_i^p = \text{LSTM}(\mathbf{e}_i^t, \mathbf{h}_i^{p-1}; \mathbf{W}_e) \\ (\hat{x}_i, \hat{y}_i) = \varphi(\mathbf{h}_i^p; \mathbf{W}_{\text{pre}}) \\ P_i^{\text{pre}} = \{(\hat{x}_i, \hat{y}_i), (\hat{x}_{i+1}, \hat{y}_{i+1}), \dots, (\hat{x}_{i+t}, \hat{y}_{i+t})\} \end{cases} \quad (12)$$

式中:  $\mathbf{s}_i^t$  为  $\mathbf{h}_i^t$  经过处理的社交池化向量,  $\mathbf{e}_i^t$  为使用多层感知机融合  $\mathbf{e}_i^t$  与  $\mathbf{s}_i^t$  的特征向量,  $\mathbf{W}_{\text{MLP}}$  为多层感知机的权重参数,  $\mathbf{h}_i^p$  为车辆  $i$  在  $t$  时刻的解码器 LSTM 隐藏状态向量,  $\mathbf{W}_e$  为解码器 LSTM 权重参数,  $\mathbf{W}_{\text{pre}}$  为输出层网络参数,  $(\hat{x}_i, \hat{y}_i)$  为车辆的预测位置。

### 2.2.2 轨迹判别器

轨迹判别器由一个单独的编码器以及 MLP 层组成,用于对输入轨迹进行真伪判断,以促进轨迹生成器更好地学习真实轨迹分布,其结构如图4所示。

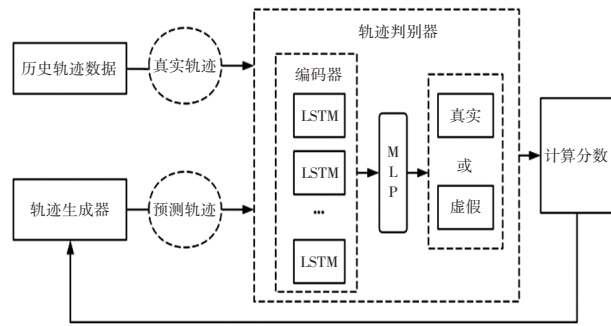


图4 轨迹判别器

编码器将输入的真实轨迹数据和轨迹生成器生成的虚假轨迹数据,通过多个 LSTM 编码映射为高维特征向量  $\mathbf{H}_d$ ,再将其输入到 MLP 层,得到输入轨迹的真实性概率:

$$\begin{cases} \mathbf{H}_d = \text{LSTM}(P_i^{\text{pre}}, P_i^{\text{his}}; \mathbf{W}_d) \\ p = \text{MLP}(\mathbf{H}_d; \mathbf{W}_m) \end{cases} \quad (13)$$

式中:  $\mathbf{W}_d$  为轨迹判别器中编码器 LSTM 权重参数,  $\mathbf{W}_m$  为多层感知机权重参数,  $p$  为判定输入轨迹为真实轨迹的

概率。

### 2.2.3 损失函数

本文的损失函数  $L$  主要由 2 部分构成:一是轨迹生成器需要生成更加真实的车辆轨迹,采用 L2 范式构建轨迹生成器的损失函数  $L_{12}$ ;二是轨迹判别器需要更准确地判定输入轨迹的真伪,采用交叉熵损失函数  $L_{\text{GAN}}$ 。

$$\begin{cases} L = L_{\text{GAN}}(G, D) + L_{12}(G) \\ L_{\text{GAN}}(G, D) = \min_G \max_D E_{r \sim D}[\log D(r)] + E_{z \sim D}[\log(1-D)G(z)] \\ L_{12}(G) = \min_k \sqrt{\frac{1}{n} \sum_{i=1}^n [(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2]} \end{cases} \quad (14)$$

式中:  $G, D$  分别为轨迹生成器和轨迹判别器的输出,  $r$  为输入真实轨迹数据,  $z$  为输入满足高斯分布的噪声向量,  $E$  为期望值,  $k$  为生成器的采样次数,  $(x_i, y_i)$  为车辆的真实位置。

## 3 试验环境设置

将车辆历史行驶轨迹数据在 SMA-GAN 和其他先进轨迹预测模型中进行迭代预训练。在输入前 3 s 的历史轨迹数据,分别输出 1~5 s 预测结果的情况下,通过对比试验以及消融试验,验证本文模型的有效性。

### 3.1 数据集与参数

本文试验使用公开数据集 NGSIM(Next Generation Simulation)中 IUS-101 数据集,通过提取车辆 ID、车辆局部坐标、车辆速度、加速度和车辆转向角信息作为模型的输入。本文数据集共包含 4 680 辆车的轨迹数据,按照 8:1:1 分为训练集、验证集和测试集。其中,训练集包含 3 744 辆车的轨迹数据,模型训练迭代 200 次。

在 Windows 10 操作系统下进行试验,图像处理器采用英伟达 RTX 3090 Ti,显存容量为 24 GB,将 Python 作为编程语言。模型的编码器维度设置为 64,批大小为 32,采用自适应矩估计(Adam)优化器,生成器与鉴别器的学习率分别设置为 0.000 5 和 0.001。

### 3.2 评价指标

为了评估模型性能,选择均方根误差(Root Mean Square Error, RMSE)、平均位移误差(Average Displacement Error, ADE)、最终位移误差(Final Displacement Error, FDE)作为性能评价指标。其中, RMSE 反映整体预测轨迹与真实轨迹间偏离程度; ADE 衡量整个预测过程中各预测点与对应真实点间欧氏距离的平均值,体现轨迹的整体预测精度; FDE 仅关注预测终点与真实

终点间欧氏距离,用于评估最终位置的预测准确性。

$$\begin{cases} I_{\text{RMSE}} = \sqrt{\frac{1}{T} \sum_{i=1}^T (x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \\ I_{\text{ADE}} = \frac{1}{T} \sum_{i=1}^T \sqrt{(x_i - \hat{x}_i)^2 + (y_i - \hat{y}_i)^2} \\ I_{\text{FDE}} = \sqrt{(x_{\text{end}} - \hat{x}_{\text{end}})^2 + (y_{\text{end}} - \hat{y}_{\text{end}})^2} \end{cases} \quad (15)$$

式中: $T$ 为预测时间步数, $(x_{\text{end}}, y_{\text{end}})$ 、 $(\hat{x}_{\text{end}}, \hat{y}_{\text{end}})$ 分别为真实轨迹和预测轨迹的终点位置。

## 4 试验与结果分析

### 4.1 消融试验

为了验证本文模型中各模块的有效性,对 SMA-GAN 模型进行消融试验,时域  $t_c$  内模型预测结果如表 1 所示。

表 1 消融试验 RMSE 指标结果

模型	RMSE/m				
	$t_c=1\text{ s}$	$t_c=2\text{ s}$	$t_c=3\text{ s}$	$t_c=4\text{ s}$	$t_c=5\text{ s}$
GAN	0.77	1.68	2.75	4.01	5.14
GAN+Social Pooling	0.62	1.45	2.32	3.29	4.46
GAN+MHA	0.59	1.33	2.10	3.07	4.13
SMA-GAN	0.56	1.18	1.85	2.68	3.71

由表 1 可知,以 GAN 网络为基线,由于社交池化模

块考虑时间动态特征, MHA 捕捉车辆间的空间交互信息,使模型预测精度均有所提升。融合时间和空间特征后,模型的预测性能表现优异,证明了综合考虑时空特征的重要性。

### 4.2 对比试验

在 NGSIM 数据集上,将本文提出的 SMA-GAN 模型与其他主流的车辆轨迹预测模型进行对比试验,对比模型包括社交池化与长短时记忆(Social Long Short-Term Memory, S-LSTM)模型<sup>[12]</sup>、卷积社交池化与长短时记忆(Long Short-Term Memory with Convolutional Social pooling, CS-LSTM)模型<sup>[6]</sup>、社交池化与生成对抗网络(Social Generative Adversarial Network, S-GAN)模型<sup>[13]</sup>、非局部社交池化与长短时记忆(Non-Local Social Long Short-Term Memory, NLS-LSTM)模型<sup>[24]</sup>,结果如表 2 和表 3 所示。

表 2 不同模型 RMSE 指标对比结果

模型	RMSE/m				
	$t_c=1\text{ s}$	$t_c=2\text{ s}$	$t_c=3\text{ s}$	$t_c=4\text{ s}$	$t_c=5\text{ s}$
CS-LSTM	0.61	1.27	2.09	3.10	4.37
S-LSTM	0.65	1.31	2.16	3.25	4.55
S-GAN	0.57	1.32	2.22	3.26	4.40
NLS-LSTM	0.56	1.22	2.02	3.03	4.30
SMA-GAN	0.56	1.18	1.85	2.68	3.71

表 3 不同模型 ADE 和 FDE 指标对比结果

模型	ADE/m					FDE/m				
	$t_c=1\text{ s}$	$t_c=2\text{ s}$	$t_c=3\text{ s}$	$t_c=4\text{ s}$	$t_c=5\text{ s}$	$t_c=1\text{ s}$	$t_c=2\text{ s}$	$t_c=3\text{ s}$	$t_c=4\text{ s}$	$t_c=5\text{ s}$
CS-LSTM	0.44	0.92	2.05	3.16	4.95	0.89	1.36	2.52	3.86	5.78
S-LSTM	0.53	1.09	2.36	4.25	5.87	1.09	1.58	3.12	4.83	7.42
S-GAN	0.39	0.81	1.65	2.51	3.71	0.85	1.21	2.25	3.34	4.78
SMA-GAN	0.40	0.75	1.66	2.45	3.47	0.82	1.13	2.32	3.12	4.45

由表 2 可知,与 CS-LSTM、S-LSTM、S-GAN 和 NLS-LSTM 模型相比, SMA-GAN、NLS-LSTM 模型在短预测时域(1 s)内的 RMSE 均为最低且预测效果接近;在中长预测时域(2~5 s), SMA-GAN 的 RMSE 最低;在 5s 的预测时域中,相较于 NLS-LSTM, SMA-GAN 的 RMSE 降低了 13.8%,说明本文模型的时间多头自注意力模块能够有效提取车辆行驶过程中的时间相关性,更精准地预测车辆的轨迹位置。

由表 3 可知, SMA-GAN 模型在短预测时域(1 s)的预测时域中的 ADE 指标和 FDE 指标略低于 S-GAN 模型。而在中长时间预测(4~5 s)中, SMA-GAN 模型的 ADE 指标和 FDE 指标明显优于其他模型。在 5 s 的预

测时域中, SMA-GAN 模型和 S-GAN 模型的 ADE 指标低于 4 m,且 SMA-GAN 模型比 S-GAN 精准度提升了 6.5%,表现出更高的预测精度,进一步说明社交池化模块与时间多头自注意力模块融合,提取周围行驶车辆的时空特征,比仅考虑提取车辆的空间特征更具优势。

为了进一步验证本文模型性能,对比 CS-LSTM、S-LSTM、S-GAN 与 SMA-GAN 的运行时间,各模型运行结果分别为 18.16 ms、12.30 ms、11.79 ms、14.08 ms。仅采用社交池化的 S-GAN 模型表现最优,引入时间多头自注意力模块的 SMA-GAN 模型,虽然其运行速度相较于 S-GAN 有所下降,但仍然保持着良好的运行效率。

因此, SMA-GAN 车辆轨迹预测方法相较于其他主

流车辆轨迹预测模型,在均方根误差、最小平均位移误差和最小终点位移误差指标上总体为最优,预测出的车辆行驶轨迹准确性最高。

### 4.3 预测轨迹可视化

在测试数据集中,选取4种驾驶场景,分别为直线行驶、左换道行驶、右换道行驶和多换道行驶。将本文预测结果进行可视化,分析不同驾驶场景下模型的性能,如图5所示。




图5 不同场景模型预测性能

由图5可知,本文模型能够在复杂的车路环境中,相对准确地预测行驶车辆对周车的行驶轨迹,保证车辆的安全行驶。车辆直行时,模型预测度与实际轨迹贴合度较高,能够为智能汽车的决策提供依据。但当车辆出现转向、变道等转变方向的行驶条件下,特别在车辆行驶途中发生多次转向换道的情况下,模型无法准确预测到转向点。尽管模型预测效果在车辆发生转向的情况下略有下降,但仍然保持了较好的预测能力。

## 5 结束语

本文基于时空多头注意力的社交生成对抗网络(SMA-GAN)的车辆轨迹预测方法,充分挖掘目标车辆历史轨迹的时间依赖性,量化周围车辆的空间交互影响,增强了轨迹预测的准确性。通过生成器与判别器的对抗训练机制,使预测轨迹在保持连贯性的同时,更贴近真实交通行为的分布。

鉴于道路交通行驶场景复杂多变,本文模型训练轨迹数据多为高速公路行车场景,后续将重点关注模型的泛化性,以适应更多典型的交通场景。

### 参考文献

- [1] ZHANG J N, WEI Z W, LIU B X, et al. Cloud-Edge-Terminal Collaborative AIGC for Autonomous Driving[J]. IEEE Wireless Communications, 2024, 31(4): 40-47.
- [2] ABBAS M T, JIBRAN M A, AFAQ M, et al. An Adaptive Approach to Vehicle Trajectory Prediction Using Multimodel Kalman Filter[J]. Transactions on Emerging Telecommunications Technologies, 2020, 31(5).
- [3] XING Y, LV C, CAO D. Personalized Vehicle Trajectory Prediction Based on Joint Time-Series Modeling for Connected Vehicles[J]. IEEE Transactions on Vehicular Technology, 2019, 69(2): 1341-1352.
- [4] JIANG Y D, ZHU B, YANG S Y, et al. Vehicle Trajectory

- Prediction Considering Driver Uncertainty and Vehicle Dynamics Based on Dynamic Bayesian Network[J]. IEEE Transactions on Systems, Man, and Cybernetics, 2023, 53(2): 689–703.
- [5] SU J Y, LI M Y, ZHU L Q, et al. Vehicle Trajectory–Prediction Method Based on Driver Behavior–Classification and Informer Models[J]. World Electric Vehicle Journal, 2024, 15(6).
- [6] 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, UT, USA: IEEE, 2018: 1468–1476.
- [7] MUKHERJEE S, WANG S, WALLACE A. Interacting Vehicle Trajectory Prediction with Convolutional Recurrent Neural Networks[C]// 2020 IEEE International Conference on Robotics and Automation (ICRA). Paris, France: IEEE, 2020: 4336–4342.
- [8] XU D W, SHANG X T, LIU Y W Z, et al. Group Vehicle Trajectory Prediction with Global Spatio–Temporal Graph[J]. IEEE Transactions on Intelligent Vehicles, 2022, 8(2): 1219–1229.
- [9] SHI J, SUN D X, GUO B C. Vehicle Trajectory Prediction Based on Graph Convolutional Networks in Connected Vehicle Environment[J]. Applied Sciences, 2023, 13(24): 13192–13192.
- [10] 朱云鹤, 刘明剑, 祝朗千, 等. SW–SAN: 基于 Seq2Seq 结合注意力机制与滑动窗口的车辆轨迹预测模型[J]. 现代电子技术, 2024, 47(11): 175–180.
- ZHU Y H, LIU M J, ZHU L Q, et al. SW–SAN: Vehicle Trajectory Prediction Model Based on Seq2Seq Combined with Attention Mechanism and Sliding Window[J]. Modern Electronics Technique, 2024, 47(11): 175–180.
- [11] 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.
- JI X W, FEI C, HE X K, et al. Intention Recognition and Trajectory Prediction for Vehicles Using LSTM Network[J]. China Journal of Highway and Transport, 2019, 32(6): 34–43.
- [12] 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, NV, USA: IEEE, 2016: 961–971.
- [13] GUPTA A, JOHNSON J, FEI–FEI L, et al. Social GAN: Socially Acceptable Trajectories with Generative Adversarial Networks[C]// Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition. Salt Lake City, UT, USA: IEEE, 2018: 2255–2264.
- [14] CRESWELL A, WHITE T, DUMOULIN V, et al. Generative Adversarial Networks: An Overview[J]. IEEE Signal Processing Magazine, 2018, 35(1): 53–65.
- [15] QIN Y, GUAN Y L, YUEN C. Spatiotemporal Capsule Neural Network for Vehicle Trajectory Prediction[J]. IEEE Transactions on Vehicular Technology, 2023, 72(8): 9746–9756.
- [16] LIN L, LI W Z, BI H K, et al. Vehicle Trajectory Prediction Using LSTMs with Spatial–Temporal Attention Mechanisms[J]. IEEE Intelligent Transportation Systems Magazine, 2022, 14(2): 197–208.
- [17] CHEN X B, ZHANG H J, ZHAO F, et al. Intention–Aware Vehicle Trajectory Prediction Based on Spatial–Temporal Dynamic Attention Network for Internet of Vehicles[J]. IEEE Transactions on Intelligent Transportation Systems, 2022, 23(10): 19471–19483.
- [18] MESSAOUD K, YAHIAOUI I, VERROUST–BLONDET A, et al. Attention Based Vehicle Trajectory Prediction[J]. IEEE Transactions on Intelligent Vehicles, 2020, 6(1): 175–185.
- [19] GUO H Y, MENG Q Y, CAO D P, et al. Vehicle Trajectory Prediction Method Coupled with Ego Vehicle Motion Trend under Dual Attention Mechanism[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1–16.
- [20] 李文礼, 韩迪, 石晓辉, 等. 基于时–空注意力机制的车辆轨迹预测[J]. 中国公路学报, 2023, 36(1): 226–239.
- LI W L, HAN D, SHI X H, et al. Vehicle Trajectory Prediction Based on Spatial–Temporal Attention Mechanism[J]. China Journal of Highway and Transport, 2023, 36(1): 226–239.
- [21] YANG M X, ZHANG B L, WANG T T, et al. Vehicle Interactive Dynamic Graph Neural Network Based Trajectory Prediction for Internet of Vehicles[J]. IEEE Internet of Things Journal, 2024, 22(11): 35777–35790.
- [22] SUN D X, GUO H L, WANG W H. Vehicle Trajectory Prediction Based on Multivariate Interaction Modeling[J]. IEEE Access, 2023, 11: 131639–131650.
- [23] VASWANI A, SHAZEER N, PARMAR N, et al. Attention Is All You Need[EB/OL]. (2023–08–02) [2025–01–16]. <https://arxiv.org/abs/1706.03762>.
- [24] MESSAOUD K, YAHIAOUI I, VERROUST–BLONDET A, et al. Non–Local Social Pooling for Vehicle Trajectory Prediction[C]// 2019 IEEE Intelligent Vehicles Symposium (IV). Paris, France: IEEE, 2019: 975–980.

(责任编辑 瑞 秋)

修改稿收到日期为 2025 年 1 月 16 日。