

文章编号:1672-3961(2024)02-0036-11 DOI:10.6040/j.issn.1672-3961.0.2023.230

# 基于图神经网络轨迹预测的合流区交通冲突预测方法

赵涛<sup>1</sup>,张宁<sup>2</sup>,王小超<sup>3</sup>,马川义<sup>2</sup>,田源<sup>1\*</sup>,张圣涛<sup>2</sup>,杨梓梁<sup>1</sup>

(1.山东大学齐鲁交通学院,山东 济南 250002; 2.山东高速集团有限公司,山东 济南 250014; 3.济南新旧动能转换起步区管理委员会,山东 济南 250000)

**摘要:**为保证高速公路合流区路段的交通安全,减少交通冲突,提出一种基于图神经网络轨迹预测的合流区交通冲突预测方法。该方法包括基于时空图卷积神经网络的轨迹预测方法以及基于预测轨迹的交通冲突预测方法。利用 Mirror-Traffic 数据集进行交通冲突指标阈值计算,并通过一定的轨迹数据处理方法得到适用的数据,进行网络模型训练和验证。结果表明,严重冲突的后侵入时间(post-encroachment time, PET)阈值为 2.0 s,轻微冲突的 PET 阈值为 5.36 s。该轨迹预测方法的平均位移误差为 1.5 m,最终位移误差为 2.1 m,时间成本为 0.59 s,与其他 4 种方法相比,本研究方法的轨迹预测整体效果最好。在交通冲突预测方面,采用准确率、精确率、召回率和  $F_1$  评价交通冲突预测模型,结果表明交通冲突预测效果较好。本研究提出的方法保证了预测的正确性,增强了预警系统下行车的安全性,提高了预警系统下的合流区通行效率。

**关键词:**图神经网络;轨迹预测;交通冲突预测;合流区;交通安全

**中图分类号:**U495 **文献标志码:**A

**引用格式:**赵涛,张宁,王小超,等.基于图神经网络轨迹预测的合流区交通冲突预测方法[J].山东大学学报(工学版),2024,54(2):36-46.

ZHAO Tao, ZHANG Ning, WANG Xiaochao, et al. A traffic conflict prediction method for merging areas based on trajectory prediction with graph neural network[J]. Journal of Shandong University (Engineering Science), 2024, 54(2):36-46.

## A traffic conflict prediction method for merging areas based on trajectory prediction with graph neural network

ZHAO Tao<sup>1</sup>, ZHANG Ning<sup>2</sup>, WANG Xiaochao<sup>3</sup>, MA Chuanyi<sup>2</sup>, TIAN Yuan<sup>1\*</sup>, ZHANG Shengtao<sup>2</sup>, YANG Ziliang<sup>1</sup>

(1. School of Qilu Transportation, Shandong University, Jinan 250002, Shandong, China; 2. Shandong High-Speed Co., Ltd., Jinan 250014, Shandong, China; 3. Governing Board of Jinan Start-up Area for Growth Drivers Transformation, Jinan 250000, Shandong, China)

**Abstract:** To ensure the traffic safety and reduce traffic conflicts in this section of the highway, a traffic conflict prediction method was proposed for the merging area based on the trajectory prediction with graph neural network. The method included a trajectory prediction method based on spatio-temporal graph convolutional neural network and a traffic conflict prediction method based on predicted trajectories. The Mirror-Traffic dataset was utilized for traffic conflict indicator threshold calculation. Applicable data were obtained through certain trajectory data processing methods for network model training and validation. The results showed that the PET threshold for severe conflicts was 2.0 s and that for minor conflicts was 5.36 s. The trajectory prediction method had an average displacement error of 1.5 m, a final displacement error of 2.1 m, and a time cost of 0.59 s. Compared with the other methods, the trajectory prediction of the proposed method had the best overall effect. For traffic conflict prediction, accuracy, precision, recall and  $F_1$  were used to evaluate the traffic conflict prediction model, and the results showed that the traffic conflict prediction was effective. The proposed method ensured the correctness of the prediction, enhanced the safety of traveling under the warning system, and improved the efficiency of the merging area under the warning system.

**Keywords:** graph neural network; trajectory prediction; traffic conflict prediction; merging area; traffic safety

收稿日期:2023-09-18

基金项目:国家自然科学基金资助项目(52002224);山东省重点研发计划重大科技创新工程项目(2020CXGC010118)

第一作者简介:赵涛(1999—),男,山东潍坊人,硕士研究生,主要研究方向为智慧交通。E-mail:202215419@mail.sdu.edu.cn

\*通信作者简介:田源(1990—),男,山东济宁人,助理研究员,硕士生导师,博士,主要研究方向为智慧交通。E-mail:yuantian@mail.sdu.edu.cn

## 0 引言

随着我国高速公路里程数不断增加,高速公路合流区的数量随之增多。据统计,高速公路合流区的事故发生率是其他路段的4~6倍<sup>[1]</sup>,车辆在合流区的合流行为是影响高速公路行车安全的重要因素。对高速公路合流区进行主动管控是控制交通冲突和事故发生的主要手段,而进行交通冲突预测是实现交通冲突精准管控的前提条件<sup>[2]</sup>。因此,高速公路合流区交通冲突预测对合流区的交通安全具有重要意义。

目前,交通冲突预测主要分为宏观交通冲突预测和微观交通冲突预测2个研究方向,宏观交通冲突预测指的是对某一路段区域某段时间内的交通冲突数量以及频率等信息进行预测;微观交通冲突预测则指的是针对某一辆车与其他车是否发生冲突,并确定冲突发生的具体位置和时间。实现交通冲突预测,需要利用冲突判别标准对交通冲突进行判断,冲突判别一是对是否发生冲突进行判断,二是对冲突严重程度进行判断<sup>[3]</sup>。交通冲突的衡量指标可归纳为基于距离、速度和时间的不同标准。然而,当前学界广泛应用的是基于时间的指标,这种选择更为可靠。在这一背景下,时间间隔决策工具如碰撞时间(time to collision, TTC)和后侵入时间(post-encroachment time, PET)等成为常见且备受关注的评估指标。在判别冲突严重程度方面,常用的模型有事故接近程度分布模型、钻石和金字塔分级模型<sup>[4-6]</sup>。本研究的目标是实现高速公路合流区中匝道车辆与主路车辆交通冲突的精准管控,旨在进行微观交通冲突的预测研究,通过采用适当的冲突指标评估潜在冲突的发生情况,进一步运用恰当的严重程度分级模型界定冲突的严重程度。为实现这一目标,常规做法涵盖对车辆轨迹的预测分析,借此推断是否可能发生交通冲突。车辆轨迹预测是指根据车辆历史轨迹信息和相关参数预测未来一段时间内的车辆轨迹,可分为短期预测和长期预测,短期预测的时间一般小于1s,可用运动学模型表征;长期预测则需要做意图预测,根据以往信息,预测出车辆轨迹的概率分布或多条轨迹或可能性最大的一条轨迹。短期预测的时间跨度有限,难以满足交通冲突预测时间长度的需求。因此,本研究聚焦长期预测方法,主要包括基于统计学、机器学习和深度学习的方法。其中,基于统计学的方法

主要以朴素贝叶斯模型、负二项分布以及logistic回归模型<sup>[7-8]</sup>为主;基于机器学习的方法主要以传统的隐马尔可夫模型<sup>[9-10]</sup>为主,但是其精度不高;基于深度学习的方法主要包括循环神经网络(recurrent neural network, RNN)、图卷积神经网络(graph convolutional network, GCN)、自注意力模型(Transformer)以及生成对抗网络(generative adversarial network, GAN)。RNN由于处理语言模型和时间序列的能力较强,早期众多学者将其用于轨迹预测,它的2个变体——长短时记忆(long short-term memory, LSTM)神经网络和门控循环单元(gated recurrent unit, GRU)神经网络,是最常用的方法<sup>[11-14]</sup>。GCN作为近年来新兴的神经网络模型,于2020年开始用于行人和车辆的轨迹预测研究,文献[15]提出一种基于图卷积神经网络的用于自动驾驶的轨迹预测方法,并在Argoverse数据集上验证了该方法的先进性;文献[16]对行人交互做图建模,基于行人的历史轨迹信息,利用所提出的社会时空图卷积神经网络(Social-STGCNN)提取行人轨迹的空间和时间信息特征,输出预测的轨迹,与传统技术相比,在速度和精度上均有较大提升;Transformer是文献[17]中提出的模型,与RNN类似,主要用于处理自然语言,而后研究者们用来处理时间序列问题,例如轨迹预测问题;文献[18]利用Transformer模型,将周围车辆的位置、速度、加速度等信息输入到模型中,得到横向轨迹预测和纵向轨迹预测,并在NGSIM数据集上进行验证,准确性较高;文献[19]考虑了车辆速度、加速度、航向角等行驶参数以及车辆几何尺寸,建立车辆相互影响模型,提出了一种基于时空注意力机制的车辆轨迹预测方法。GAN也可用于时间序列模型,文献[20]首先将GAN模型用于解决时间序列问题,提出了一种Social GAN模型用于行人轨迹预测,使用一种新颖的聚合机制汇总不同人群的信息,通过对抗训练预测未来信息,并通过多样性损失鼓励多样化的预测,在准确性、避免碰撞和计算复杂性等方面均有优势;后有研究者也将GAN应用到车辆轨迹预测中<sup>[21-22]</sup>。综上所述,目前轨迹预测方面的研究较为成熟,但缺少在匝道控制中车辆轨迹预测的研究。

轨迹预测是实现交通冲突预测的基础。在交通冲突预测的应用中,早期的轨迹预测研究主要应用运动学模型、统计学模型以及机器学习模型<sup>[23-26]</sup>,这些模型在短期预测中具有一定效果,但

在长期预测中精度较低,不能准确反映驾驶意图。目前,基于深度学习的轨迹预测方法在交通冲突预测方面的应用较少,文献[27]利用 LSTM 模型预测每个车辆的未来轨迹,并计算在未来 9 s 内是否会发生冲突,但 LSTM 神经网络模型不能体现车辆之间的相互影响行为。要实现交通冲突预测和预警,需要使用警示装置前的数据预测未来的数据,且警示装置前记录的轨迹数据不是固定长度,而现有的轨迹预测网络模型大多是根据固定时长的轨迹数据预测未来固定时长的轨迹。因此,目前的相关研究无法适用于实际匝道控制场景,也不能满足本研究交通冲突预测和预警的需求。

针对高速公路合流区事故高发现象及现有研究的局限性,本研究提出了一种基于图卷积神经网络的轨迹预测方法,旨在实现匝道中行驶车辆与主路车辆之间交通冲突的有效预测。该方法在空间上考虑了主路和匝道车辆中的交互性,用模型中的邻接矩阵模拟车辆间的不同距离;在时间上利用 GRU 提取轨迹的时间特征。鉴于主路车辆之间的交通冲突无法通过匝道主动管控来控制,且风险相对较低,本研究不对主路车辆间的交通冲突展开探讨。相反,研究重点聚焦于匝道内车辆与主路车辆之间的交互情景。本研究提出了一种匝道主动管控方法,以实现对接道内车辆与

主路车辆之间交通冲突的预警与管控。基于冲突预警的目标,本研究从轨迹数据的提取出发,提出了基于时空图卷积神经网络的轨迹预测方法以及基于 PET 的交通冲突预测方法,实现轨迹预测至交通冲突预测的全面流程,提升交通冲突预测的准确性。此举进而有助于确保高速公路合流区内车辆行驶的安全性。

## 1 数据集及数据处理

### 1.1 Mirror-Traffic 数据集

本研究采用由清华大学苏州汽车研究院和江苏智能网联汽车创新中心合作创建的 Mirror-Traffic 数据集。该数据集包含了高速公路合流区的真实场景,其生成过程涵盖了对交通监控视频或无人机拍摄视频的细致处理。随后,运用图像处理与深度学习等技术,对所采集的视频材料进行处理,以实现车辆在不同场景下的准确识别与轨迹追踪。该数据集得到车辆的轨迹数据的精度为厘米级。该合流区数据集取自某高速公路,时长为 30 min,道路为东西走向,其左侧有两条主干道,匝道位于右侧,路段限速 80 km/h。道路模型与数据记录范围如图 1 所示。视频监控的帧率为 25,即 1 s 输出 25 帧,相邻帧之间的时间间隔为 0.04 s。




图 1 数据记录范围示意图

Fig.1 Schematic diagram of data logging range

### 1.2 轨迹数据提取与处理

本研究数据处理所用的车辆轨迹信息数据包括时间戳、车辆序列号(identity document, ID)、车辆坐标、车道编号以及车辆类型。本研究基于 Python 编写了轨迹数据处理代码,轨迹数据处理程序包括如下 3 步。

第 1 步,在数据集中划分历史轨迹和预测轨迹,需预先假设理想电警杆的位置,电警杆之前的数据为历史数据,电警杆之后的数据为预测的目标数据。利用这种数据模式训练的神经网络模型可根据车辆到达电警杆之前的轨迹数据,预测出未来的轨迹数据,进而根据预测的轨迹信息预测交通冲突,并将警示信息通过主动管控装置发布于驾驶员。

第 2 步,在数据集中先划分训练集和验证集,并

对第 1 步得到的数据进一步处理。在训练集和验证集中,本研究需要根据车道编号找到在匝道中运行的车辆,记录车辆 ID。然后记录该车辆出现的第 1 个时刻的帧 ID,判断主路中是否有车辆在该时刻经过监控区域。进而记录该帧 ID 时刻下主路行驶车辆的 ID,并提取出这些车辆在该帧 ID 以后的所有轨迹信息,废弃该帧 ID 之前的轨迹数据。根据其位置在电警杆前或后将轨迹信息划分为历史轨迹和预测的目标轨迹,实现训练集和验证集的划分。现有的轨迹预测网络模型大多是根据固定时长的数据预测未来固定时长的轨迹。本研究的数据结构为使用电警杆前的数据预测未来的数据,而电警杆前的数据不是固定长度的。换言之,这些数据的时间长度是不同的,无法像现有的轨迹预测方法一

样,利用固定时长的数据预测固定时长的轨迹。因此,本研究输入和输出的轨迹数据具有特殊性。

第 3 步,针对数据的特殊性,对轨迹数据进一步处理。在训练模型之前,需对训练集和验证集数据进行进一步处理。经过对每辆车的时间序列时长统计,Mirror-Traffic 数据集中每个车辆轨迹的时间长度为 130~290 帧。这些差异是由车辆速度不同以及视频设备对不同车辆的初始位置识别的差异导致的。根据第 1 步中划分的历史轨迹和预测目标轨迹,历史轨迹的时间长度为 50~130 帧。为了统一长度,将所有历史轨迹均划分为 20 段,取每一段的第 1 个数据。预测的目标轨迹的时间长度为 80~160 帧,将其划分为 40 段,取每一段的第 1 个数据。即用 20 个历史时刻点数据预测 40 个目标时刻点的数据。通过上述轨迹处理方法,实现了所有轨迹时间维度上的统一,方便后续将轨迹数据输入到神经网络模型中进行训练和验证。

## 2 方法

由于本研究的目标是实现匝道中的精准管控,为了使匝道中行驶的驾驶员观察到警示信息,则需在车辆到达管控装置前显示警示信息。因此本研究提出了在匝道中利用电警杆搭载视频监控设备和信息发布装置,视频监控用来记录车辆的轨迹数据,信息发布装置用来发布警示信息。在实际应用中,需要利用电警杆之前的轨迹信息,预测未来的轨迹信息。基于此,则能够根据预测的轨迹信息预测出是否发生交通冲突,并将警示信息通过主动管控装置发布给驾驶员,进而达到控制效果,减少交通冲突发生。整体控制流程如图 2 所示,该流程中的设备布置位置符合 Mirror-Traffic 数据集场景。在实际应用中,该位置可作为参考,具体位置可根据实际情况选择。

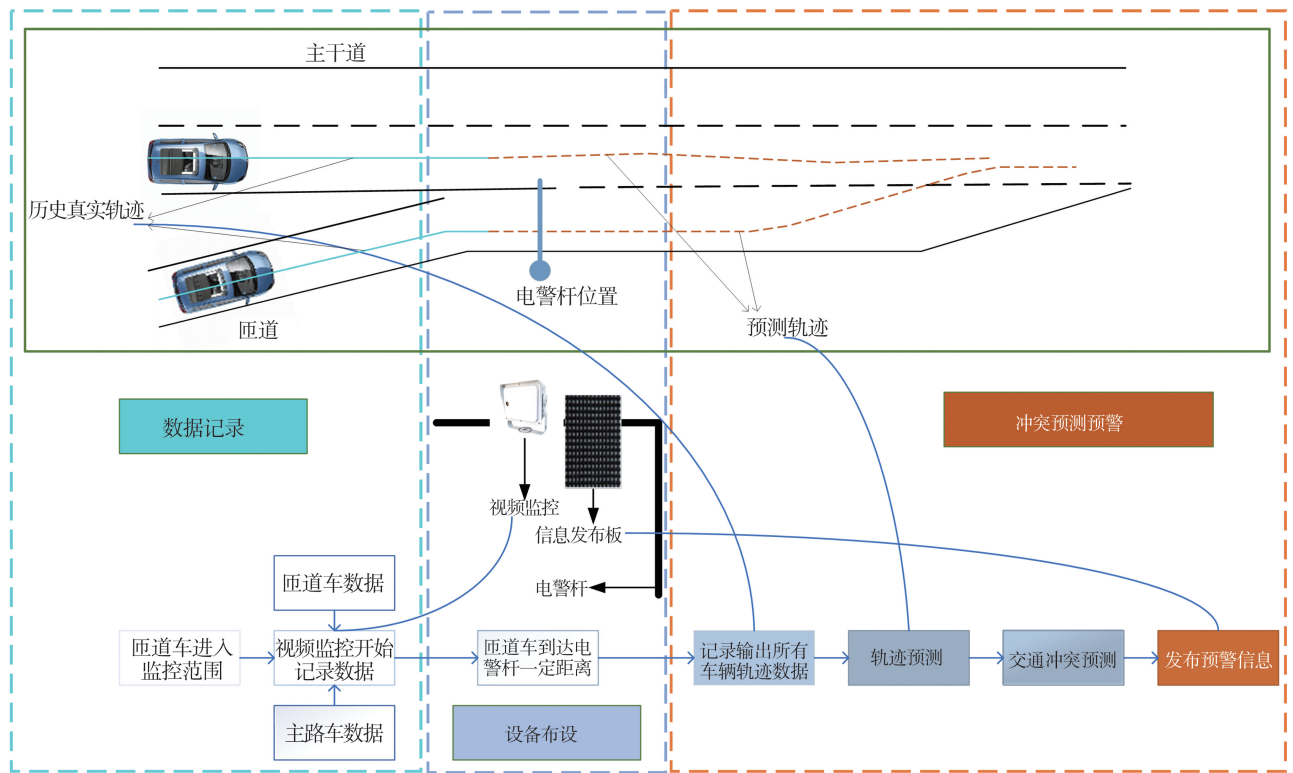


图 2 技术路线图  
Fig.2 Technological route

### 2.1 轨迹预测网络模型

本研究针对合流区车辆之间的交互性,提出一种时空图卷积神经网络模型预测车辆轨迹。将在影响范围内的所有车辆的轨迹信息坐标  $(x, y)$  作为模型输入的基础。其中每辆车作为一个节点,根据车辆距离关系构建邻接矩阵。首先进行时空图卷积操作提取车辆之间的特征,然后将每个节点的特

征作为每个 GRU 的输入,通过 GRU 的内部计算输出所有车辆的预测轨迹。模型结构如图 3 所示。

该模型的构建包括构建图结构作为输入、构建时空图卷积神经网络和 GRU 形成整体模型以及模型参数的选择调优。

#### 2.1.1 车辆轨迹的图结构

首先构造一个空间图  $G_t = (V_t, E_t)$ ,表示在每个

时间步下的车辆位置。其中,  $\mathbf{V}_t$  表示图结构的顶点集, 将所有同时出现的每个车辆  $\mathbf{v}_t^i$  当作图的一个顶点, 即  $\mathbf{V}_t = \{\mathbf{v}_t^i | i \in \{1, 2, \dots, N\}\}$ , 每个车辆  $\mathbf{v}_t^i$  包含的属性特征即为车辆的坐标信息  $(x_t^i, y_t^i)$ ;  $\mathbf{E}_t$  表示顶点之间边的集合, 0 代表两顶点之间无关联, 1 代表两点

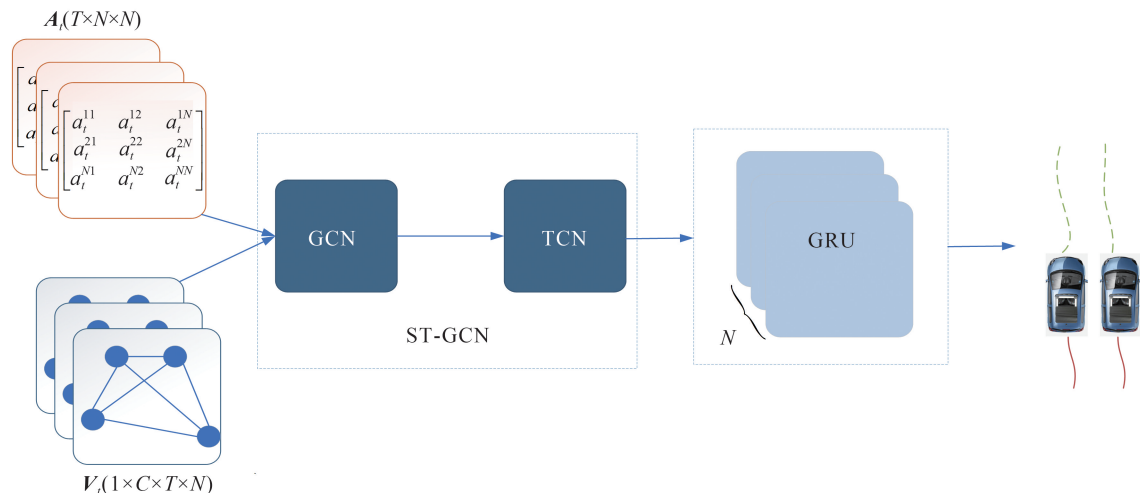


图3 轨迹预测网络模型整体结构图

Fig.3 Overall structure of the trajectory prediction network mod

邻接矩阵

$$\mathbf{A}_t = \begin{bmatrix} a_t^{11} & a_t^{12} & a_t^{1N} \\ a_t^{21} & a_t^{22} & a_t^{2N} \\ a_t^{N1} & a_t^{N2} & a_t^{NN} \end{bmatrix}, \quad (1)$$

式中,  $a_t^{ij}$  代表车辆间的接近程度,

$$a_t^{ij} = \begin{cases} 1/\|\mathbf{v}_t^i - \mathbf{v}_t^j\|_2, & \|\mathbf{v}_t^i - \mathbf{v}_t^j\|_2 > 1 \\ 1, & \text{其他} \end{cases}.$$

### 2.1.2 时空图卷积神经网络

图卷积的操作是将图结构中每个节点邻近的节点信息进行采样求和, 然后与参数矩阵  $\mathbf{W}$  相乘得到新一层的节点特征, 公式为:

$$\mathbf{v}_t^{i(t+1)} = \sigma\left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \sum_{\mathbf{v}_t^{j(t)} \in C(\mathbf{v}_t^{i(t)})} p(\mathbf{v}_t^{i(t)}, \mathbf{v}_t^{j(t)}) \mathbf{W}^{(l)}(\mathbf{v}_t^{i(t)}, \mathbf{v}_t^{j(t)})\right), \quad (2)$$

式中,  $\tilde{\mathbf{A}}$  是邻接矩阵  $\mathbf{A}_t$  与单位矩阵相加得到的新矩阵,  $\tilde{\mathbf{D}}$  是  $\tilde{\mathbf{A}}$  的度矩阵,  $p(\cdot)$  是将  $\mathbf{v}_t^i$  邻接节点信息聚合的采样函数,  $\mathbf{W}(\cdot)$  是参数矩阵,  $\sigma$  是激活函数,  $C(\mathbf{v}_t^{i(t)})$  是与  $\mathbf{v}_t^i$  邻接的所有节点的集合。该部分的操作是将邻接矩阵归一化, 对于详细的图卷积神经网络原理可参考文献[28]。

在时空图卷积神经网络中, 将得到的数据构建为图结构  $\mathbf{V}_t(1 \times C \times T \times N)$ ,  $N$  为图结构的节点数,  $C$  为特征维度, 即车辆的  $(x, y)$  坐标,  $T$  为时间序列长度。邻边关系根据车辆之间的距离确定, 构建邻接

之间有关联。为了强调车辆之间影响程度的不同, 本研究根据两顶点之间的距离不同加入了变化的邻接矩阵  $\mathbf{A}_t$ , 研究思路为车辆间的距离越大, 相互影响程度越小, 其邻接矩阵中的数值越小。反之距离越小, 相互影响程度越大, 邻接矩阵中的数值越大。

矩阵  $\mathbf{A}_t(T \times N \times N)$ 。时空图卷积神经网络需要图结构和邻接矩阵作为输入。因此在本研究中, 图结构  $\mathbf{V}_t(1 \times C \times T \times N)$  和邻接矩阵  $\mathbf{A}_t(T \times N \times N)$  作为模型的输入。先对空间图结构  $\mathbf{V}_t(1 \times C \times T \times N)$  进行式(3)的卷积操作, 提取高维度空间特征, 输出  $\mathbf{V}_t(1 \times C' \times T \times N)$ 。其中  $C'$  是卷积操作后的特征维度, 对输出的结果进行卷积操作, 提取时间特征, 输出  $\mathbf{V}_t(1 \times C' \times N \times T)$ 。将输出的特征继续输入到后续的 GRU 中。

### 2.1.3 GRU

GRU 和 LSTM 是循环神经网络 RNN 的 2 个不同变种, 都是处理时序数据的经典深度学习算法。GRU 在结构上比 LSTM 简单, 因此在训练效率上优于 LSTM, 在结果输出时用时较短, 更能满足本研究实时轨迹预测和预警的需求。因此, 本研究使用 GRU 作为 STGCN 的解码器, 输出轨迹。GRU 内部结构如图 4 所示。




图4 GRU 内部结构图

Fig.4 Internal structure of GRU

其具体原理如下:GRU的输入包含当前的输入 $x_t$ 和上一节点传递下来的隐藏状态 $h_{t-1}$ ,隐藏状态包含了之前节点的所有信息。将这2个数据输入到GRU结构中,得到传递给下一节点的隐藏状态 $h_t$ 和该隐藏节点的输出 $y_t$ 。具体计算过程为:

$$z_t = \sigma(\mathbf{W}_z \cdot [h_{t-1}, x_t]), \quad (3)$$

$$r_t = \sigma(\mathbf{W}_r \cdot [h_{t-1}, x_t]), \quad (4)$$

$$\tilde{h}_t = \tanh(\mathbf{W} \cdot [r_t * h_{t-1}, x_t]), \quad (5)$$

$$h_t = (1 - z_t) * h_{t-1} + z_t * \tilde{h}_t, \quad (6)$$

式中: $\sigma$ 为Sigmoid函数,通过Sigmoid函数可将数据的值域确定为 $[0, 1]$ ,因此 $z_t$ 和 $r_t$ 的值域为 $[0, 1]$ , $z_t$ 控制更新, $r_t$ 控制重置; $\tilde{h}_t$ 包含了当前输入 $x_t$ 的信息,并对上一节点隐藏态 $h_{t-1}$ 进行重置,针对性地选择 $h_{t-1}$ 的信息,相当于记忆了当前时刻的状态;式(6)通过 $z_t$ 控制信息更新, $z_t$ 越接近于1, $\tilde{h}_t$ 权重越高,记忆当前时刻的信息越多,反之则遗忘的信息越多。

#### 2.1.4 模型参数选择

模型的超参数将会影响模型效果。因此,本研究通过遍历超参数组合,选择了模型效果最优的组合方案。本研究的参数选择范围以及最终参数的选择如表1所示。此外,优化器和损失函数选择了最常用的Adam(adaptive moment)和MSE(mean square error)。

表1 模型参数选择  
Table 1 Selection of the parameters

参数名称	参数值	本研究选取值
hidden size (GRU)	1,2,3,4,5,6,12,18	2
number layer (GRU)	1,2,3,4,5	2
batch size	2,4,8,12,16,24	4
训练次数	50,100,200	100
时间步长	6,12,24	12
训练集比例	70%,80%	70%
测试集比例	30%,20%	30%

#### 2.2 交通冲突预测方法

实现交通冲突预测,首先要选择一个交通冲突判别指标,最常用的交通冲突指标有TTC和PET。TTC假设冲突车辆的速度和角度不变时发生碰撞所需的时间,记为 $T_{TTC}$ ,这种指标更适用于同一车道中的追尾冲突。PET是后侵入时间,指前车尾部离开冲突断面与后车头部到达冲突断面的时间差,记为 $T_{PET}$ ,该指标更适用于不同车道的侧向冲突,也适用于追尾冲突和横穿冲突。高速公路合流区中匝道车与主路车的交通冲突大多为侧向冲突和追尾冲突,因此本研究选择 $T_{PET}$ 作为交通冲突判别指标。假设匝道车经过某一截面的时刻点为 $t$ ,另一经过同一截面的主路车的时刻点为 $t_1$ ,则 $T_{PET}$ 计算公式为:

$$T_{PET} = |t - t_1|。 \quad (7)$$

根据轨迹预测神经网络模型输出的车辆轨迹,首先计算匝道车与其他所有车辆之间所有时刻的距离 $d$ ,公式为:

$$d = \sqrt{(x_t^i - x_{t_1}^i)^2 + (y_t^i - y_{t_1}^i)^2}, \quad (8)$$

式中,上标 $i$ 代表车辆序号,下标 $t$ 和 $t_1$ 分别为匝道车在 $(x, y)$ 处的时刻和第 $i$ 辆车在 $(x, y)$ 处的时刻。

本研究目的是根据两轨迹的距离 $d$ 判断两车辆是否经过同一截面。由于需要考虑车辆长度的差异以及离散的轨迹数据基本不可能重叠的特性,因此 $d$ 不为定值。需要根据车辆类型(长度)和车辆所在的前后位置设定不同的阈值,由于车辆的轨迹信息是基于车头的,因此假设在前面的车的车长为 $x$ ,则 $d$ 的阈值为 $x$ 。判断 $d$ 是否小于阈值,若小于阈值,则判断为两车经过同一截面。若不小于阈值,则判断为两车不经过同一截面。若判断为经过同一截面,则继续判断该轨迹数据所对应的时刻点,计算 $T_{PET}$ 。若 $T_{PET}$ 小于一定阈值,则判定为存在交通冲突;反之,则没有交通冲突。交通冲突按照等级划分为严重冲突、一般冲突和轻微冲突。目前大多研究对交通冲突阈值的确定方法采用累积频率曲线法。一般选取 $T_{TTC}$ 或 $T_{PET}$ 的15%分位作为严重冲突的判定阈值,85%分位作为轻微冲突的阈值,15%~85%为一般冲突<sup>[4]</sup>。一般认为 $T_{PET}$ 超过6s为无冲突<sup>[29]</sup>。因此,本研究中每个等级的 $T_{PET}$ 范围利用累积频率法确定。

#### 2.3 评价指标

在轨迹预测方面,常用的评价指标为平均位移误差(average displacement error, ADE)和最终位移误差(final displacement error, FDE),分别记为 $E_{ADE}$ 、 $E_{FDE}$ ,计算公式为:

$$E_{ADE} = \frac{\sum_{n \in N} \sum_{t \in t_p} \|\hat{p}_t^n - p_t^n\|_2}{N \times t_p}, \quad (9)$$

$$E_{FDE} = \frac{\sum_{n \in N} \|\hat{p}_{t_p}^n - p_{t_p}^n\|_2}{N}, \quad (10)$$

式中, $t_p$ 为最终时刻, $n$ 为某轨迹的序号, $t$ 为某时刻, $N$ 为轨迹的总数, $\hat{p}_t^n$ 为轨迹 $n$ 在 $t$ 时刻的预测位置, $p_t^n$ 为轨迹 $n$ 在 $t$ 时刻的真实位置, $\hat{p}_{t_p}^n$ 为轨迹 $n$ 在最终时刻的预测位置, $p_{t_p}^n$ 为轨迹 $n$ 在最终时刻的真实位置。

$E_{ADE}$ 、 $E_{FDE}$ 能够反映真实轨迹和预测轨迹之间的平均误差和终点误差,能整体反映轨迹预测的精度。因此,本研究采用 $E_{ADE}$ 、 $E_{FDE}$ 对轨迹预测的精度

进行评价。

在交通冲突预测方面,本研究根据真实轨迹计算并统计出各个冲突等级所包含的冲突数量,根据预测轨迹计算并统计出各个冲突等级所包含的冲突,由此建立混淆矩阵。混淆矩阵的评价指标包括准确率  $A$  (Accuracy)、精确率  $P$  (Precision)、召回率  $R$  (Recall) 与  $F_1$  值 ( $F_1$ -score), 准确率的意义是预测正确的数量占总数量的比值,精确率的意义是模型预测正例的所有结果中预测正确的比例。召回率的意义是真实值是正例的所有结果中模型预测正确的比例,  $F_1$  指标综合了精确率和召回率,取值为  $[0, 1]$ ,越接近于 1 说明模型效果越好。因此本研究通过上述 4 个指标评价模型效果,其计算公式分别为:

$$A = \frac{T_p + T_N}{T_p + F_p + F_N + T_N}, \quad (11)$$

$$P = \frac{T_p}{T_p + F_p}, \quad (12)$$

$$R = \frac{T_p}{T_p + F_N}, \quad (13)$$

$$F_1 = \frac{2P \cdot R}{P + R}, \quad (14)$$

式中,  $T_p$  是模型预测正确的正例数量,  $F_N$  是模型预测错误的正例数量,  $F_p$  是模型预测错误的负例数量,  $T_N$  是模型预测正确的负例数量。

## 3 结果

### 3.1 交通冲突等级划分结果

本研究基于 Python 编写了根据轨迹信息计算  $T_{PET}$  的代码,选取了  $T_{PET}$  小于 6 s 的所有值,累积频率曲线如图 5 所示。




图 5 PET 累积频率曲线图

Fig.5 PET cumulative frequency curve

计算得到,15%分位的  $T_{PET}$  为 2.00 s,85%分位的  $T_{PET}$  为 5.36 s。具体冲突等级与  $T_{PET}$  范围对应关系如表 2 所示。

表 2 冲突等级与  $T_{PET}$  范围对应关系

Table 2 Correspondence between conflict level and  $T_{PET}$  range

冲突等级	严重冲突	一般冲突	轻微冲突	无冲突
$T_{PET}/s$	$[0, 2.00]$	$(2.00, 5.36]$	$(5.36, 6.00]$	$(6.00, \infty)$

### 3.2 轨迹预测结果

在 Mirror-Traffic 数据集中,共有 62 条合流轨迹信息。本研究利用 62 条匝道车辆轨迹以及与此同时出现的主路车辆轨迹,作为轨迹预测的对象。其中,一条合流轨迹和其他同时出现的主路车辆轨迹作为一组数据,即得到 62 组数据。由于每组数据中主路车辆出现的数量不同,因此每一组的轨迹数量不同。首先将 62 组数据划分为训练集和验证集,根据 1.2 节提到的轨迹数据处理方法,在训练集和验证集划分先验轨迹和预测目标轨迹。在训练模型时,将训练集的先验轨迹输入到模型中,预测得出轨迹信息。利用真实轨迹以及损失函数和反向传播校正预测轨迹。其中损失函数为均方误差 (mean square error, MSE),优化器为 Adam,设置迭代次数为 100。采用早停法训练模型,即损失降到一定数值时停止迭代,本研究选择将损失值降到 1.5 以下则停止迭代,然后保存模型。将验证集的数据输入到训练好的模型中,得到预测轨迹,与真实轨迹进行对比评价。

基于本研究轨迹数据结构长度不定的特殊性,无法像现有的轨迹预测方法一样,利用固定时长的数据预测固定时长的轨迹。因此,将本研究提出的用于高速公路合流区的轨迹预测模型与其他较为经典的且经过一定处理后适用于本研究数据结构的轨迹预测模型进行对比,利用  $E_{ADE}$  和  $E_{FDE}$  比较模型的预测精度,比较结果如表 3 所示,不同模型对同一轨迹的预测结果如图 6 所示。

表 3 模型精度对比

Table 3 Comparison of model accuracy

模型	$E_{ADE}/m$	$E_{FDE}/m$	时长/s
LSTM	5.4	8.5	0.86
GRU	5.6	8.4	<b>0.52</b>
LSTM-attention	5.0	6.7	1.07
GRU-attention	4.8	6.8	0.70
Transformer	5.2	7.2	0.92
GCN	4.6	6.2	0.54
STGCN-GRU	<b>1.5</b>	<b>2.1</b>	0.59




图6 不同模型轨迹预测效果示例

Fig.6 Example of the effect of different model trajectory prediction

由表3可以看出,常用的时间序列预测模型LSTM与GRU的精度基本一致,加入注意力机制后精度有提升,本研究提出的STGCN-GRU模型的预测精度最高,其 $E_{ADE}$ 为1.5 m, $E_{FDE}$ 为2.1 m,即平均相对误差为1.5 m,最终位移误差为2.1 m。高速公路行驶的车辆速度一般在20 m/s以上,若误差为2.1 m, $T_{PET}$ 误差最多则为0.1 s,可以忽略。因此,在

高速公路合流区交通冲突预测中,本模型车辆轨迹预测的误差是可以接受的,能够满足交通冲突预测的需求。在预测时长方面,本模型的预测所用时长为0.59 s,在GRU的基础上增加了0.07 s。虽然时长评价中不是最佳的,但也能满足实时要求。综合来看,本模型的效果与LSTM、GRU、LSTM-attention、GRU-attention、Transformer以及GCN相比是最好的。

轨迹预测效果如图7所示,并进一步对其特殊性作如下实例解释。当车辆编号为170的匝道车出现在(虚拟)电警杆位置之前时,编号为175的主路车辆也出现在了监控区域,而编号为182的主路车辆在这时间段内并没有出现。因此,只需要预测车辆编号为170的匝道车与编号为175的主路车的轨迹,当匝道车离开数据记录区域后,即刻停止记录数据。将记录的所有车辆的轨迹数据进行处理并进行轨迹预测,即利用电警杆之前记录的轨迹数据(因为车辆速度和车辆出现时间的不同,每辆车被记录的轨迹时长不同),预测未来的轨迹。




图7 轨迹预测效果图

Fig.7 Effectiveness of trajectory prediction

### 3.3 交通冲突预测结果

为了验证本研究所提出的轨迹预测模型在高速公路合流区交通冲突预测的有效性,本研究经过数据处理,先根据真实轨迹计算 $T_{PET}$ ,统计各个冲突等级所包含的冲突数量,后根据预测轨迹计算 $T_{PET}$ ,统计出各个冲突等级所包含的冲突数量。最后建立混淆矩阵,采用准确率、召回率以及精确率评价预测模型的有效性。本研究最终获取到的合流轨迹为62条,与合流车辆同时出现的轨迹为152条,本研究验证的是62条合流轨迹与152条主路轨迹的冲突数量。根据本研究冲突计算方法,该数据集中共有严重冲突12次,一般冲突55次。具体的真实和预测结果的混淆矩阵如图8所示。

	严重冲突	一般冲突	轻微冲突
严重冲突	10	5	0
一般冲突	2	47	7
轻微冲突	0	3	78
	真实冲突		

图8 整体冲突混淆矩阵

Fig.8 Overall conflict confusion matrix

由图8可以看出,所有真实的严重冲突只有2个预测为一般冲突,没有一个预测为轻微冲突,极大避免了严重冲突下的预警系统误报,保证了预警系统下行车的安全性。所有真实的轻微(无)冲突有7个识别为一般冲突,其他全部正确识别为轻微(无)冲突,极大避免了轻微冲突下的预警系统误报,这保证了预警系统下的合流区通行效率。由混淆矩阵及式(11)计算整体的准确率为88.82%,说明了该交通冲突预测模型的准确率比较可靠,通过上述分析,预测不准确的结果大多是趋向系统更安全的方向,同时保证了通行效率。各个冲突等级的二分混淆矩阵如图9所示。

本研究分别验证严重冲突、一般冲突以及轻微冲突的评价指标,以严重冲突的二分混淆矩阵为例,根据式(11)~(14)计算其准确率、精确率、召回率以及  $F_1$ , 分别为95.07%、66.67%、83.33%以及74.08%。




图9 各个冲突等级的二分混淆矩阵

Fig.9 Dichotomous confusion matrix for each conflict level

根据以上原理,计算一般冲突以及轻微冲突的准确率、精确率、召回率以及  $F_1$ , 计算得一般冲突的准确率为88.82%、精确率为83.93%、召回率为85.45%、 $F_1$  为84.68%;轻微冲突的准确率为93.10%、精确率为96.30%、召回率为91.76%、 $F_1$  为93.98%,具体计算结果如表4所示。

表4 各冲突等级评价指标



Table 4 Indicators for evaluating each conflict level

单位:%				
冲突等级	A	P	R	$F_1$
严重冲突	95.07	66.67	83.33	74.08
一般冲突	88.82	83.93	85.45	84.68
轻微冲突	93.10	96.30	91.76	93.98

根据表4可以看出,模型预测严重冲突的准确率最高,但是其  $F_1$  却最小。主要原因是数据集中严重冲突的样本较少,影响了评价结果。一般冲突在数据集中的样本较多,其准确率和  $F_1$  基本相似,轻微冲突亦是如此。但模型对于预测轻微冲突的效果比预测一般冲突的效果好,主要原因是一般冲突的  $T_{PET}$  与严重冲突和轻微冲突的  $T_{PET}$  都接近,而轻微冲突仅与一般冲突接近。因此,一般冲突的预测值有更大的概率落入其他类别中。

## 4 结束语

本研究考虑到高速公路合流区的危险性以及该区域交通冲突预警的特殊性,提出了一种适用于高速公路合流区冲突预警的交通冲突预测模型,其中包括了基于时空图卷积网络的轨迹预测模块和基于轨迹预测的交通冲突预测模块,并基于 Mirror-Traffic 数



数据集分别验证了轨迹预测模块和交通冲突预测模块的有效性。在PET 阈值方面,本研究采用了常用的累积频率方法,计算结果与其他权威文献对冲突等级的划分范围基本一致;在轨迹预测方面,针对数据时长不固定的特殊性,提出了适用的轨迹预测模型,并与其他经典模型作对比,证明了本模型在精度和实时性方面的优势;在交通冲突预测方面,本研究建立了混淆矩阵,并通过准确率、精确率、召回率以及  $F_1$  评价了模型的有效性。验证了本研究所提出的用于高速公路合流区的交通冲突预测模型效果较好。因此,本研究保证了预测的正确性和预警系统下行车的安全性,同时保证了预警系统下的合流区通行效率。

本研究还存在以下不足:数据集中的合流轨迹较少,且严重冲突的数量较少。未来可自建数据库,增加数据量,一方面能提高轨迹预测的精度,进而提高交通冲突预测的精度,另一方面能提高交通冲突预测评价的可靠性并增强说服力。本研究虽提出了预警方法,并实例化了虚拟电警杆以及监控、信息发布板等设备布设位置。但本研究还未实现现场布设,未来可通过现场布设和智能网联,实现高速公路合流区的交通冲突预测和预警,采集并比较系统布设前和布设后的交通冲突数量,验证系统对现场交通冲突的控制效果。

#### 参考文献:

- [1] EUSTACE D, AYLO A, MERGIA W Y. Crash frequency analysis of left-side merging and diverging areas on urban freeway segments: a case study of I-75 through downtown Dayton, Ohio [J]. *Transportation Research Part C-Emerging Technologies*, 2015, 50: 78-85.
- [2] 吴建清,宋修广. 智慧公路关键技术发展综述[J]. *山东大学学报(工学版)*, 2020, 50(4): 52-69.  
WU Jianqing, SONG Xiuguang. Review on smart highways critical technology[J]. *Journal of Shandong University(Engineering Science)*, 2020, 50(4): 52-69.
- [3] 吴建清,王其峰,厉周缘,等. 互通式立交风险冲突识别与预警综述[J]. *山东大学学报(工学版)*, 2022, 52(6): 1-13.  
WU Jianqing, WANG Qifeng, LI Zhouyuan, et al. Review of risk conflict identification and early warning for interchange[J]. *Journal of Shandong University(Engineering Science)*, 2022, 52(6): 1-13.
- [4] ZHU Shunying, JIANG Ruoxi, WANG Hong, et al. Review of research on traffic conflict techniques [J]. *China Journal of Highway and Transport*, 2020, 33(2): 15-33.
- [5] HYDEN Christer. The development of a method for traffic safety evaluation: the swedish traffic conflicts technique [M]. Lund, Sweden: Bulletin Lund Institute of Technology Department, 1987:1-57.
- [6] SVENSSON Ase. A method for analysing the traffic process in a safety perspective[M]. Lund, Sweden: Lund Institute of Technology, 1998: 1-117.
- [7] 李万高,赵雪梅,孙德广. 基于改进贝叶斯方法的轨迹预测算法研究[J]. *计算机应用*, 2013, 33(7): 1960-1963.  
LI Wangao, ZHAO Xuemei, SUN Dechang. Prediction of trajectory based on modified Bayesian inference [J]. *Journal of Computer Applications*, 2013, 33(7): 1960-1963.
- [8] 张凯,熊家军,李凡,等. 基于意图推断的高超声速滑翔目标贝叶斯轨迹预测[J]. *宇航学报*, 2018, 39(11): 1258-1265.  
ZHANG Kai, XIONG Jiajun, LI Fan, et al. Bayesian trajectory prediction for a hypersonic gliding reentry vehicle based on intent inference [J]. *Journal of Astronautics*, 2018, 39(11): 1258-1265.
- [9] 剡鹏. 考虑时空约束的隐马尔可夫车辆轨迹预测方法[D]. 哈尔滨: 哈尔滨工业大学, 2021.  
YAN Peng. A HMM-based vehicle trajectory prediction method considering space-time constraints [D]. Harbin: Harbin Institute of Technology, 2021.
- [10] 张迎亚. 基于隐马尔可夫模型的车辆轨迹预测算法的研究[D]. 南京: 南京邮电大学, 2017.  
ZHANG Yingya. Research on the algorithm of vehicle trajectory prediction based on HMM [D]. Nanjing: Nanjing University of Posts and Telecommunications, 2017.
- [11] JI Xuewu, FEI Cong, HE Xiangkun, et al. Intention recognition and trajectory prediction for vehicles using LSTM network [J]. *China Journal of Highway and Transport*, 2019, 32(6): 34-42.
- [12] 蔡游游. 基于RNN-LSTM网络的车辆轨迹预测研究[D]. 长春: 吉林大学, 2021.  
CAI Youyou. Vehicle trajectory prediction based on RNN-LSTM network [D]. Changchun: Jilin University, 2021.
- [13] 武林. 基于GRU-ATT的车辆驾驶意图识别与轨迹预测[D]. 北京: 中国矿业大学, 2022.  
WU Lin. Vehicle driving intention recognition and trajectory prediction based on GRU-ATT [D]. Beijing: China University of Mining and Technology, 2022.
- [14] MENG Xianwei, TANG Jinjun, WANG Zhe. Trajectory prediction of vehicles based on LSTM-AdaBoost model considering lane-changing intention [J]. *Computer Engineering and Applications*, 2022, 280-287.
- [15] GAO Jiyang, SUN Chen, ZHAO Hang, et al. Vectornet: encoding hd maps and agent dynamics from vectorized representation [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2020: 11522-11530.

- [16] MOHAMED A, KUN Q, ELHOSEINY M, et al. Social-STGCNN: a social spatio-temporal graph convolutional neural network for human trajectory prediction [C]//2020 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Seattle, USA: IEEE, 2020: 14412-14420.
- [17] VASWANI Ashish, SHAZEER Noam, PARMAR Niki, et al. Attention is all you need [C]//Advances in Neural Information Processing Systems 30 (NIPS 2017). Long Beach, USA: NIPS, 2017.
- [18] 吴翊恺,胡启洲,吴啸宇. 车联网背景下的机动车辆轨迹预测模型[J]. 东南大学学报(自然科学版), 2022, 52(6): 1199-1208.  
WU Yikai, HU Qizhou, WU Xiaoyu. Vehicle trajectory prediction model in the context of internet of vehicles [J]. Journal of Southeast University (Natural Science Edition), 2022, 52(6): 1199-1208.
- [19] LI Wenli, HAN Di, SHI Xiaohui, et al. Vehicle trajectory prediction based on spatial-temporal attention mechanism [J]. China Journal of Highway and Transport, 2023, 36(1): 226-239.
- [20] GUPTA Agrim, JOHNSON Justin, LI Feifei, et al. Social GAN: socially acceptable trajectories with generative adversarial networks [C]//2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). Salt Lake City, USA: IEEE, 2018: 2255-2264.
- [21] WEN Huiying, ZHANG Weigang, ZHAO Sheng. Vehicle lane-change trajectory prediction model based on generative adversarial networks [J]. Journal of South China University of Technology (Natural Science Edition), 2020, 48(5): 32-40.
- [22] 赵小明. 基于生成对抗网络的车辆轨迹预测[D]. 长春: 吉林大学, 2022.  
ZHAO Xiaoming. Trajectory prediction of vehicles based on GAN [D]. Changchun: Jilin University, 2022.
- [23] 王文博,严锋. 基于贝叶斯模型的高速公路合流区交通冲突预测[J]. 公路, 2023, 68(7): 328-332.  
WANG Wenbo, YAN Feng. Prediction of traffic conflict in expressway merging area based on Bayesian model [J]. Highway, 2023, 68(7): 328-332.
- [24] 郑展骥,项乔君,李涵,等. 互通立交分流区交通冲突预测模型[J]. 中国安全科学学报, 2018, 28(6): 85-90.  
ZHENG Zhanji, XIANG Qiaojun, LI Han, et al. Model for predicting traffic conflict in interchange diverging area [J]. China Safety Science Journal, 2018, 28(6): 85-90.
- [25] XIANG Qiaojun, LU Chuan, WU Qun, et al. Research on traffic conflict prediction model of unsignalized highway intersection [J]. Journal of Highway and Transportation Research and Development, 2009, 26(5): 132-135.
- [26] DEDOMINICIS Dario, CONTE Claudia, MATTEI Fausta, et al. Trajectory prediction and conflict detection for unmanned traffic management: a performance comparison of machine-learning-based approaches [C]//2022 IEEE International Workshop on Metrology for Aerospace (IEEE MetroAerospace 2022). Pisa, Italy: IEEE, 2022: 633-638.
- [27] ISLAM Zubayer, ABDELATY Mohamed. Traffic conflict prediction using connected vehicle data [J]. Analytic Methods in Accident Research, 2023: 39.
- [28] YAN Sijie, XIONG Yuanjun, LIN Dahua, et al. Spatial temporal graph convolutional networks for skeleton-based action recognition [C]//Thirty-Second AAAI Conference on Artificial Intelligence / Thirtieth Innovative Applications of Artificial Intelligence Conference / Eighth AAAI Symposium on Educational Advances in Artificial Intelligence. New Orleans, USA: AAAI, 2018: 7444-7452.
- [29] 关志强. 基于交通冲突技术的高速公路施工区安全性研究[D]. 哈尔滨: 哈尔滨工业大学, 2011.  
GUAN Zhiqiang. Study on the safety of freeway work zone based on traffic conflict technique [D]. Harbin: Harbin Institute of Technology, 2011.

(编辑:郭少华)