

基于时空图神经网络的异构交通参与者风险预测*

孟相浩¹, 牛凌², 席军强¹, 陈丹妮¹, 吕超¹

(1. 北京理工大学机械与车辆学院, 北京 100081; 2. 清华大学深圳国际研究生院, 深圳 518055)

[摘要] 有效预测驾驶员视野下的多交通参与者未来风险指标是为人类驾驶员提供风险预警, 规避潜在碰撞风险的关键。大多数现有对风险的研究仅考虑场景中单一个体与本车之间的成对交互关系, 并从评估而非预测的角度展开研究, 而忽略异构交通参与者之间不同的交互关系及未来风险状态。本文提出了一种基于时空图卷积神经网络的异构多目标风险预测方法 Risk-STGCN, 通过图卷积及时间卷积分别对单帧场景图信息与时序信息进行学习, 结合多层时序预测网络对多目标风险指标 TTC 进行预测。在开源 BLVD 与实车自采数据集上进行了训练验证, 并与常用序列预测模型进行对比。实验结果表明, 所提模型在不同数据集上的平均 TTC 误差均在 0.95 s 以下, 多实验指标均优于文中所提到的其他模型, 具有良好的鲁棒性, 同时提升了复杂交通场景下风险预测的可解释性。

关键词: 智能汽车; 多交通参与者; 交互表征; 风险预测; 时空图神经网络

Risk Prediction of Heterogeneous Traffic Participants Based on Spatio-Temporal Graph Neural Networks

Meng Xianghao¹, Niu Ling², Xi Junqiang¹, Chen Danni¹ & Lü Chao¹

1. School of Mechanical Engineering, Beijing Institute of Technology, Beijing 100081;

2. Tsinghua Shenzhen International Graduate School, Shenzhen 518055

[Abstract] Effectively predicting the future risk indicators of multiple traffic participants under the driver's field of vision is the key to providing risk warnings to human drivers and avoiding potential collision risk. Most existing research on risk only considers the pairwise interaction between a single individual and the vehicle in the scene, and conducts research from the perspective of evaluation rather than prediction, while ignoring the different interaction between heterogeneous traffic participants and future risk status. This paper proposes a heterogeneous multi-objective risk prediction method Risk-STGCN based on spatiotemporal graph convolutional neural network, using graph convolution and temporal convolution to learn single-frame scene graph information and timing information respectively, combined with multi-layer timing prediction network to predict the multi-objective risk indicator TTC. Training and verification are conducted on the open source data set BLVD and the real vehicle self-collected data set, which is then compared with commonly used sequence prediction models. The experimental results show that the average TTC error of the proposed model on different data sets is less than 0.95 s, with multiple experimental indicators better than other models mentioned in this paper. The proposed model has good robustness and improves the interpretability of risk prediction in complex traffic scenarios.

Keywords: intelligent vehicles; multiple traffic participants; interactive representation; risk prediction; spatio-temporal graph neural network

* 科技创新 2030——“新一代人工智能”重大项目(2022ZD0115503)和国家自然科学基金(52372405)资助。

原稿收到日期为 2024 年 02 月 20 日, 修改稿收到日期为 2024 年 03 月 27 日。

通信作者: 吕超, 副教授, E-mail: chaolu@bit.edu.cn。

前言

随着城市化进程的不断推进和交通运输系统的日益复杂化,交通安全问题逐渐成为人们关注的焦点之一^[1-2]。现代城市交通系统由各类交通参与者(如汽车、行人、骑行者等)共同构成。在复杂场景中,提前预知交通参与者的风险状态,并对其中危险的个体赋予更多关注,这一高级辅助驾驶功能可以使驾驶员提前采取合适的驾驶策略,提升通行效率,规避潜在的碰撞^[3]。研究者通过预测风险指标开发主动安全系统用以解决此问题,其中风险指标预测是关键之一^[4]。

在针对交通参与者的风险研究领域,先前的方法多集中于对已采集数据的处理分析,并使用复杂的运动学模型进行建模评估,如聚类方法^[5-6]、场景线性动态系统^[7-9]等。这些方法通过分析参与者的位置、速度、加速度等运动特征,局限于对现有数据的研究,无法提供对未来碰撞风险指标的预测,这在实际交通场景中尤为关键。在风险指标的研究历程中,研究者们开发了多种风险评估指标,如碰撞概率^[10]、最小安全距离^[11]等,以量化交通环境中的潜在风险。在这些指标中,碰撞时间(time-to-collision, TTC)因其直观性和实用性而受到广泛关注^[12],它衡量的是在当前速度和相对方向下发生碰撞前的时间,为驾驶员或自动驾驶系统提供了采取避险措施的宝贵时间窗口。例如在城市场景中发生追尾事故的主要原因是驾驶员没有足够的时间对危险做出反应,错误地把握了制动时机^[13]。根据Daimler-Benz^[14]的一项研究,如果提前0.5 s向驾驶员发出警告,60%的碰撞就不会发生;如果提前1.5 s警告驾驶员,那么可以阻止90%的碰撞。因此,对于主车视野中交通参与者风险指标超过驾驶员反应时间(0.4-1.0 s)^[15]的预测并发出提醒可以为驾驶员提供充足的反应时间做出下一步的决策判断,规避潜在的碰撞风险。

另外在个体风险评估层面,先前的研究主要集中在对特定类别或个体交通参与者的风险评估上^[16],例如单一类型的汽车^[17]、行人^[18-19]等,而缺乏对场景中多种类别交通参与者共同存在时的全面同时评估能力。这在城市交通环境中是一个至关重要的问题,因为不同类型的交通参与者往往在同一时空环境中相互交织,其行为相互影响,各自的运动状

态也有一定的关联^[20]。常用的概率模型^[21]和贝叶斯网络^[22],虽然能够提供特定场景下个体相对准确的概率推断,处理不确定性信息,但也存在着一些明显的缺陷,这些方法往往难以应对复杂交通场景,特别是在高噪声环境下,其性能可能会显著下降。行车风险场^[23]的理论被提出用于评估场景动态风险,从“场”的概念入手建立统一模型,同时也因为“场”的范围模糊边际,对相对位置进行考虑时短时间内的变化不够明显。此外,一些通过数据驱动^[12]或非线性运动模式^[24]评估风险的方法适用性也较为有限,难以对参与者的复杂交互行为进行准确建模与学习。图神经网络(graph neural network, GNN)因其在处理复杂交互关系方面的优势而受到研究者的青睐,最近的研究中social-BiGAT^[25-26]依靠图表示来建模交互关系,由于图的拓扑是表示场景中交通参与者之间交互的自然方式,展示了“图”在捕捉交通参与者间交互关系方面的潜力,这是一种更直接、直观和有效的方式来建模交互行为。然而该模型并未充分利用图结构信息,仅将其当作循环模块中的池化机制,直接导致模型参数爆炸性增长引发的训练和调优相对复杂。

综上所述,本文提出了针对主车视角下多种交通参与者共存的风险时空图神经网络(risk-spatio-temporal graph convolutional networks, Risk-STGCN),对各自风险指标(TTC)进行同时多帧(12帧)预测。Risk-STGCN通过图的方式对复杂场景信息进行表征,包含不同的交通参与者及之间的交互关系建模,创新性引入不同的核函数对轨迹信息与速度信息进行交互映射,然后利用图卷积和时间卷积的方式分别对场景中的图信息及动态时序信息进行学习,充分考虑场景中不同种类交通参与者的交互演化,最后通过需要更少参数的时序推理卷积模块对各参与者的碰撞指标进行预测输出。该模型对于交互场景的动态信息预测具有良好的性能,并且在实车采集的主车视角数据集与开源BLVD数据集上开展实验,与先前模型进行对比,从而验证了本模型的有效性。

1 问题定义与模型框架

本文中对驾驶员视角数据进行了采集与处理;通过时空图神经网络与对主车视角多交通参与者数据进行学习;最后,通过时间推理网络对多交通参与

者的风险状态进行预测,实现了驾驶员视角下多交通参与者的同时、多帧预测。基于以上内容,本文将待解决的问题定义如下:在城市复杂交通场景中,对于任意时刻 t ,车辆观察到的交通参与者 n 由在一个相对坐标系中的状态序列特征 $\mathbf{x}_{(t)}^n = (p_{x(t)}^n, p_{y(t)}^n, v_{x(t)}^n, v_{y(t)}^n)$ 来表示,包括相对位置和相对纵、横向速度。数据流由0时刻到 T_{seq} 时刻观察到的交通参与者 n 的特征 $\mathbf{X}_{(T_{\text{seq}})}^n$,其中包含交通参与者自身状态序列特征如下:

$$\mathbf{X}_{(T_{\text{seq}})}^n = [\mathbf{x}_{(1)}^n, \mathbf{x}_{(2)}^n, \dots, \mathbf{x}_{(T_{\text{seq}})}^n]^T \quad (1)$$

通过对主车视野中多种交通参与者状态序列 $\mathbf{X}_{(T_{\text{seq}})}^n$ 及其各自交互关系的学习,时间推理模块将会对输出该交通参与者从时间 $T_{\text{seq}+1}$ 到 T_{obs} 的未来状态序列 $\mathbf{Y}_{(T_{\text{obs}})}^n$,即

$$\mathbf{Y}_{(T_{\text{obs}})}^n = [\mathbf{x}_{(T_{\text{seq}+1})}^n, \mathbf{x}_{(T_{\text{seq}+2})}^n, \dots, \mathbf{x}_{(T_{\text{obs}})}^n]^T \quad (2)$$

此外,本文采用公认的碰撞安全指标TTC^[27]来

描述交通参与者的碰撞风险,其计算公式为

$$TTC = \frac{\sqrt{p_{x(t)}^n{}^2 + p_{y(t)}^n{}^2}}{\sqrt{v_{x(t)}^n{}^2 + v_{y(t)}^n{}^2}} \quad (3)$$

式中: $\sqrt{p_{x(t)}^n{}^2 + p_{y(t)}^n{}^2}$ 表示对应交通参与者与主车的欧氏距离; $\sqrt{v_{x(t)}^n{}^2 + v_{y(t)}^n{}^2}$ 则表示该交通参与者与主车对应距离方向上的相对速度。

图1为Risk-STGCN模型的总体流程。首先,通过一系列车载传感器对驾驶员视角下多交通参与者状态数据进行采集及预处理。其次,将该状态信息作为图卷积神经网络和时间卷积网络的输入对场景空间信息和动态时序信息进行学习。最后,通过多层时间推理神经网络对状态信息进行预测计算,输出将来时刻场景中各交通参与者的风险指标TTC值,从而实现基于驾驶员视角下的多交通参与者风险预测并识别出场景中最危险的个体。

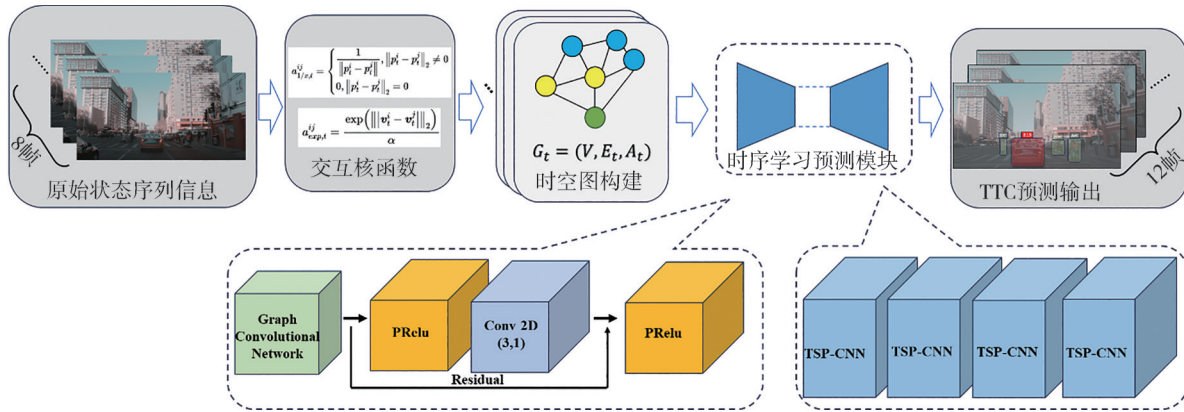


图1 Risk-STGCN模型总体框架

2 数据采集与模型方法

2.1 数据采集与预处理

针对提及的研究内容,本文从开源BLVD^[28]数据集与实车自采数据集上展开实验。BLVD数据集主要侧重于车辆自身周围物体有意义的动态变化,是一个大规模的5D(3D+时间+交互式)语义基准,为自动驾驶的交互识别与意图预测研究提供了数据基础,近年来在行为识别^[29]、轨迹预测^[30]等领域广泛应用。数据示例如图2所示。

在自采数据层面,本文通过一系列车载传感器开展对北京市海淀区典型路况的数据采集。该系统包含一个安装在汽车顶部的32线激光雷达、一个惯

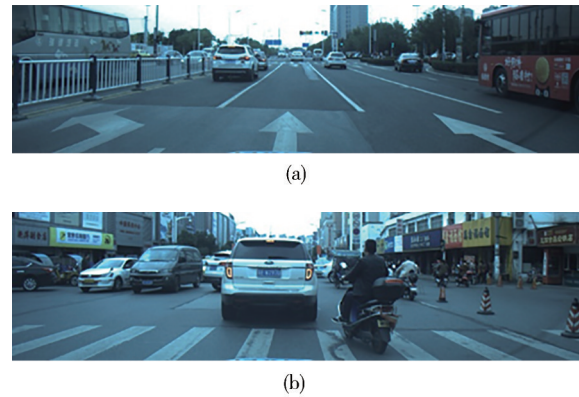


图2 BLVD数据示例

性导航模块、一个安装在车辆前窗玻璃上的地平线相机以及一个工控机,布局如图3所示。工控机中

装有场景检测和定位程序,根据相机中的目标检测算法与激光雷达点云数据融合,提供交通参与者相对主车的状态序列信息。数据采集频率为10 Hz,具有可靠的采样频率以满足后续数据处理分析精确度的需要。




图3 车载传感器系统

为了获得足够可靠的多交通参与者交互数据完成模型的训练与验证,本文制定了如下的数据采集方案:选择工作日10:00-17:00作为数据采集的时间,主要考虑这一时段的交通参与者数量适量,避免早晚高峰过多的车流和人流导致过度遮挡或者行车不畅数据采集效率低的问题。此外数据采集场景中交通参与者的密度在一天中的不同时段是不一样的,例如早上10点到中午12点人流和车流密度较高,而下午2点以后人流和自行车流会出现减少现象,这样可以采集到不同交通参与者密度下的交叉路口信息,增加数据的多样性。在场景上同样以交互多样性优先,选择魏公村路段及其周边交叉路口,交叉路口又可以分为十字交叉路口、T型交叉路口等,包含左转、直行和右转多种行车场景,其中直行场景居多。数据采集由多名经验丰富的驾驶员轮流驾驶完成。行驶路线如图4所示。

在数据预处理过程中,由于交通参与者状态信息(轨迹、速度)是具有时序特征的,因此通过插值与近邻填补法对其中跳变值进行平滑处理以及对缺失值进行补充。

2.2 风险时空图卷积(Risk-STGCN)模型

2.2.1 复杂场景交互图特征建模

在多种交通参与者共存的风险预测问题中,复杂场景中的数据具有相关性和异质性。相关性表现于数据在时间维度和空间维度上的自相关关系;异



图4 数据采集路线

质性表现于数据在不同时间或空间范围内表现为不同的模式,具体表现为在不同风险程度的交通场景中,各交通参与者表现出不同的交互模式。

时空图(spatio-temporal graph)是近年来兴起的一种用于表征几何数据间复杂的时空关系处理方式。本文采用时空图对复杂交通场景进行建模,对比风险评估领域常用的基于场理论的方法,基于时空图的方法考虑了不同交通参与者之间的交互关系,以及数据随着时间和空间演化过程。本文建立基于交互的时空图,并将时空图表示为


$$G_t = (V, E_t, A_t) \tag{4}$$

式中: V 是节点集合,用于表示场景中交通参与者; E_t 和 A_t 分别表示时刻 t 的边集和邻接矩阵,用于表示交通参与者间的交互关系。本文将交互的强弱量化为邻居节点间信息流的大小,并通过设计合适的径向核函数完成该过程。在对节点间的交互进行表征时,本文注意到交通参与者之间的交互增强总是发生在相对距离减少时,且这样的增强关系是非线性的,具体的表现是相隔较远的交通参与者存在较为微弱的交互关系,但是在相对距离变得很近时,交通参与者会采取紧急避障等措施,交互关系会急剧增强。另外交通参与者之间的交互增强总是发生在相对速度增大时,具体表现前车突然减速或者后车加速打算进行超车时,驾驶员会将注意力集中在这些与自身相对速度较大的交通参与者上,进行频繁的交互,同样这种交互增强的方式也是非线性的。为了能够较好地刻画上述交互规律,本文设计了两个径向核函数 $a_{1/a,t}^j$ 与 $a_{exp,t}^j$,分别通过轨迹和速度两个属性来构建邻接矩阵,量化节点间的交互强度:


$$a_{1/a,t}^j = \begin{cases} \frac{1}{\|p_t^i - p_t^j\|}, & \|p_t^i - p_t^j\|_2 \neq 0 \\ 0, & \|p_t^i - p_t^j\|_2 = 0 \end{cases} \tag{5}$$

$$\alpha_{exp,t}^{ij} = \frac{\exp\left(\left\|v_i^j - v_i^i\right\|_2\right)}{\alpha} \quad (6)$$

式中: $p_i^i, p_i^j, v_i^i, v_i^j$ 分别代表 t 时刻节点 i 和 j 的位置特征向量与速度特征向量; α 为超参数,用于数据归一化,抑制梯度消失与梯度爆炸现象。其中图数据提取输入演示如图5所示,通过场景中的交通参与者状态序列数据计算得到对应的交互权重大小,并在图中以“边”的粗细表示。



(a) 数据特征输入



(b) 交互图构建

图5 建图与特征输入

2.2.2 时空图卷积预测模块

将场景数据转化为图结构后,本文首先使用图卷积神经网络(graph convolutional network, GCN)提取单帧图结构的特征,完成空间图结构特征提取工作。接着通过时域卷积神经网络(temporal convolutional network, TCN)对时域特征进行表征,通过对时间特征图卷积和残差连接实现时域特征的提取。图特征学习表示如下:

$$\mathbf{A}_t = \mathbf{A}_t^{-\frac{1}{2}} \hat{\mathbf{A}}_t \mathbf{A}_t^{-\frac{1}{2}} \quad (7)$$

$$f(V^{(l)}, \mathbf{A}) = \sigma(\mathbf{A}^{-\frac{1}{2}} \hat{\mathbf{A}} \mathbf{A}^{-\frac{1}{2}} V^{(l)} \mathbf{W}^{(l)}) \quad (8)$$

式中: $\hat{\mathbf{A}}_t = \mathbf{A}_t + \mathbf{I}$; \mathbf{A}_t 为 $\hat{\mathbf{A}}_t$ 的对角节点度矩阵,是为了便于学习对邻接矩阵所进行的归一化; $\mathbf{W}^{(l)}$ 是第 l 层可训练参数矩阵;模型激活函数 σ 选择为PReLU激活函数。

时空图卷积学习的过程完成的是时空图结构的特征提取,即便这个网络已经具备了很强的空间和时间特征提取能力,针对预测任务还需要在模型中加入时间推理模块进行时间序列预测,常用方法包

括多层感知器(multilayer perceptron, MLP)、卷积神经网络(convolutional neural network, CNN)和长短期记忆网络(long short-term memory, LSTM)等。时空图卷积网络提取出的是一组时空特征图,卷积神经网络由于具有局部连接和权值共享两大特性,可以充分利用模型前端的特征空间,与循环神经网络和LSTM等网络相比具有更小的计算量。另外本文目标是表征交通参与者未来的状态序列信息及风险指标TTC值,卷积神经网络与预期输出的维度相匹配,因而采用一系列卷积和残差链接构成TTC时间卷积预测模块,并通过通道数的扩张实现多帧预测。

以上则是关于模型对异构交通参与者的建模与风险预测过程,通过学习交通参与者的历史行为和交互模式,能够预测这些复杂交互对未来风险的影响。模型不仅依赖于TTC标签进行训练,而且还通过图结构学习到交通参与者之间的复杂关系。此外,本文模型通过时序预测网络捕捉长期依赖关系,从而提供更为全面的风险评估。

3 实验与分析

3.1 实验设置

参考轨迹预测中平均位移误差(average displacement error, ADE)和最终位移误差(final displacement error, FDE)的评价指标,本文提出采用平均TTC误差(average time-to-collision error, ATE)与最终TTC误差(final time-to-collision error, FTE)来评价风险预测模型。ATE表示预测序列中所有预测值与实际值的平均欧式误差, FTE则表示最终预测风险值与对应的真值之间的欧式误差。二者的值越小则预测效果越好。公式如下:

$$ATE = \frac{\sum_{n \in N} \sum_{t \in T_p} \left\| \widehat{TTC}_t^n - TTC_t^n \right\|_2}{N \times T_p} \quad (9)$$

$$FTE = \frac{\sum_{n \in N} \left\| \widehat{TTC}_t^n - TTC_t^n \right\|_2}{N}, t = T_p \quad (10)$$

式中: N 代表预测的交通参与者数量; T_p 代表预测序列的最终长度; \widehat{TTC}_t^n 表示 t 时刻的第 n 个交通参与者相对主车的TTC预测值; TTC_t^n 则是第 n 个交通参与者与主车的TTC真值。

为验证本文提出的多交通参与者风险预测模型效果,使用两种经典序列预测网络与其进行对比,展示各个模型的性能。

(1)门控循环单元(gate recurrent unit, GRU):循环神经网络的变种,通过更新门和重置门对序列信息进行处理预测,为解决长期记忆和反向传播中的梯度问题而提出。

(2)LSTM:采用长短期记忆网络进行序列预测,引入3个门来控制信息传递,选择性对信息进行遗忘,提升预测速度。

(3)图注意力网络(graph attention networks,

GAT):利用注意力机制着重考虑图顶点特征之间的相关性。

(4)Risk-STGCN:即本文所提出的风险预测方法。

通过对比上述几种模型,验证本文所提出模型的有效性。值得注意的是,LSTM与GRU多用于轨迹预测任务,本文对于该模型做了相应的调整,使其能够进行风险指标预测。本文模型设置超参数如表1所示。

表1 超参数设置

优化器	激活函数	学习率	Batch大小	Epoch	α	GCN层数	TSP层数
SGD	PReLU	0.01/0.002	128	250	1	1	5

3.2 定量分析及对比

在模型的训练测试中,本文主要以2.1节所提到的BLVD数据集和自采实车数据集的展开,选择了9170条节点样本数据进行实验。训练集、验证集、测试集按照8:1:1的比例进行划分,在验证集上观察模型的训练过程,之后在测试集上进行模型评估。对风险指标预测输出采用均方误差(mean squared error, MSE)函数来进行损失计算和反向传播过程。模型训练初期为确定超参数 α 的取值,文中使用较小batch_size,并使用Adam优化器进行初始训练及交叉验证,最终确定了高斯核函数中超参数 α 的取值为1。在后续进行大规模数据集计算时,使用了收敛效果更好的SGD优化器,并设置batch_size=128,epoch=250来展开训练。在学习率的设置方面,为了兼顾模型前期训练效率以及训练后期的准确度,将初始学习率设置为0.01,150个epoch后将其修改为0.002。

验证结果如图6所示。对比评价指标可知,GRU的表现结果最差,这表明了GRU在面临过去信息和当前信息只能二选一时带来的负面影响。LSTM模型相对较好,GAT的结果较为可观。Risk-STGCN的ATE值和FTE值最小,其中ATE值低于0.85s,预测效果最佳。

为进一步验证本文模型在不同时域下预测风险指标的能力,补充了预测未来12个时间步的分步结果实验,图7展示了不同时间域范围内场景中指定车辆FTE的结果对比图。可以看出3个模型的FTE值都随时间步的增加而增大,这符合时序预测的基本规律:随时域增长,误差会增大。本文提出的Risk-STGCN模型在全部时间步范围内的FTE指标都小于其他模型。




图6 BLVD数据集模型对比

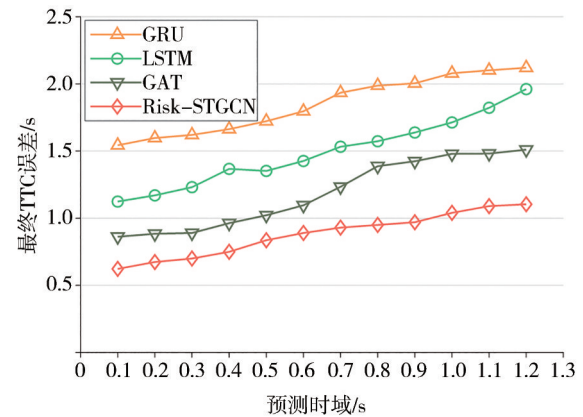


图7 各模型多时域预测对比

另外值得一提的是,Risk-STGCN模型可以同时预测场景中的多种交通参与者,相比于挖掘数据本身特征的GRU、LSTM等模型具有更大的优势与可解释性。

3.3 实车数据验证

经过前一节的模型对比展示了本文提出模型的性能,本节则通过实车自采数据分场景及目标展开

验证,从而对模型的鲁棒性进行说明。选中数据为城市交通场景十字路口的左转、直行、右转工况,保证场景中多交通参与者同时存在的复杂情况。采样频率为 10 Hz,即对应模型观测时间步长为 0.8 s,预测时间步长为 1.2 s。数据集同样按照 8:1:1 的比例拆分为训练集、验证集和测试集。实车数据验证对比结果如图 8 所示。

由图 8 可得,在实车自采数据集下 Risk-STGCN 的 ATE 值与 FTE 值分别为 0.916 与 1.519 s,相比于其他模型依旧处于较小值。

在分场景及目标的验证中,本文通过开源 BLVD 数据集的直行场景车辆、行人,实车自采数据集中的城市十字路口左转、右转、直行中的车辆及行人风险指标预测结果进行展示,从而就模型对多交通参与

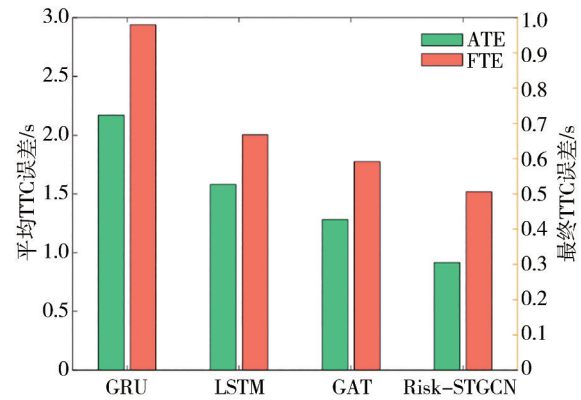


图 8 实车数据集模型对比

者风险指标的预测能力及鲁棒性进行说明,实验结果如图 9 所示。具体预测精度数据如表 2 所示。




图 9 分场景预测结果

表 2 模型鲁棒性结果

场景	车辆		行人	
	ATE/s	FTE/s	ATE/s	FTE/s
BLVD 直行	0.982	1.274	0.690	0.934
实车左转	1.376	2.032	0.832	1.712
实车直行	0.755	1.247	0.671	1.017
实车右转	1.071	1.672	0.791	1.434

从图表中可以看出:Risk-STGCN 在直行场景下的预测效果要好于转弯场景,这是因为转弯场景有着更高的运动不确定性;各个场景下模型对于行人的预测效果要优于对车辆的预测,对行人的风险平均预测误差均在 0.85 s 以下,实车直行场景下的行

人 ATE 达到 0.671 s,车辆 ATE 达到 0.755 s。

为更好地展示风险预警模型输出,示意驾驶员视野下多交通参与者风险热度序列图,如图 10 所示,可以为驾驶员更好地甄别未来一段时间场景中风险最大的个体,并且本文给出了个体相对主车的移动过程中纵横向风险指标预测矢量拆解结果,从而使驾驶员采取更合理预防风险的措施——制动规避或转向规避,更好地规避潜在的碰撞风险。顶端数值代表综合风险值,左右分别代表纵横向拆分值,其中较风险个体及维度用红色标出。

综合以上实验结果可知,本文所提出的 Risk-STGCN 能够针对多交通参与者同时存在的复杂情

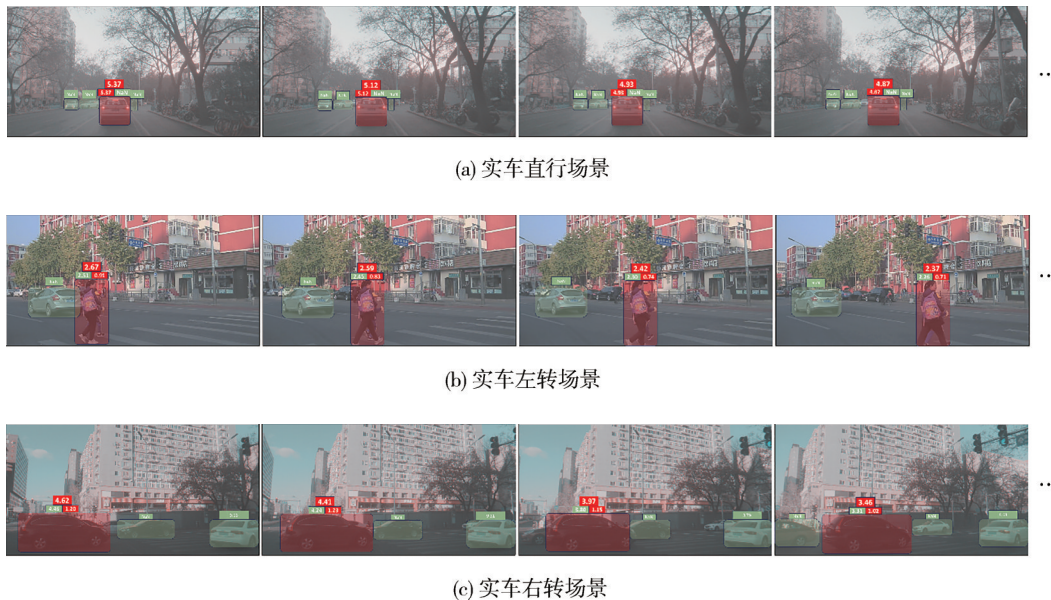


图10 驾驶员视野预警标识图

况下对各目标做出较好的风险预测,并且在不同的数据集上都具有优势,有较好的鲁棒性,在建模阶段通过图的方法相较于传统数据驱动的方式具有更好的可解释性。但同时该模型可能在其他类型的交通场景中存在局限性。例如,在高速公路或乡村道路上,由于交通流的动态特性和参与者行为模式的差异,模型可能需要额外的调整或重新训练以适应这些场景。未来研究中将探索模型迁移学习的方法,使模型能够快速适应新的交通环境。这可能涉及到使用领域自适应技术来调整模型权重,以便在新场景中保持高性能。

4 结论

本文聚焦复杂交通场景的风险预测问题,提出了一种针对多交通参与者同时存在的风险指标预测模型,通过对场景中多目标状态序列特征及不同的核函数表征提取图模型交互关系,使用图卷积和时间卷积的方式充分考虑了不同种类节点状态之间影响异构多目标风险预测的时空交互,有效解决了对异构多目标个体的差异化建模。结合交通参与者的历史特征序列信息与多层时间推理卷积网络,预测场景中各目标未来一段时间每一时间步的风险指标TTC值,为驾驶员提供大于驾驶反应时间的风险预警。基于开源BLVD和实车自采数据集上的对比实验验证了所提方法在异构场景中预测单目标和多目

标时都有优异的效果。在未来的研究中,场景信息诸如车道线、路径曲率、交通信号装置等道路约束也应被更多地考虑,通过先验知识和模型相结合的手段进一步提升预测性能与模型全面性,并且目标对模型内部的演进过程展开研究,对其可解释性进一步说明。

参考文献

- [1] PUGACHEV I, KULIKOV Y, CHEGLOV V. Features of traffic organization and traffic safety in cities [J]. *Transportation Research Procedia*, 2020, 50: 766-772.
- [2] GUO J, KURUP U, SHAH M. Is it safe to drive? an overview of factors, metrics, and datasets for driveability assessment in autonomous driving [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2019, 21(8): 3135-3151.
- [3] BUCSUHÁZY K, MATUCHOVÁ E, ZŮVALA R, et al. Human factors contributing to the road traffic accident occurrence [J]. *Transportation Research Procedia*, 2020, 45: 555-561.
- [4] KATRAKAZAS C, QUDDUS M, CHEN W H. A new integrated collision risk assessment methodology for autonomous vehicles [J]. *Accident Analysis & Prevention*, 2019, 127: 61-79.
- [5] YU M Y, VASUDEVAN R, JOHNSON-ROBERSON M. Risk assessment and planning with bidirectional reachability for autonomous driving [C]. *2020 IEEE International Conference on Robotics and Automation (ICRA)*, 2020: 5363-5369.
- [6] RYAN C, MURPHY F, MULLINS M. End-to-end autonomous driving risk analysis: a behavioural anomaly detection approach [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 22(3): 1650-1662.

- [7] OLMUŞ H, ERBAŞ S. Analysis of traffic accidents caused by drivers by using Log-linear models[J]. *Promet-Traffic&Transportation*, 2012, 24(6): 495-504.
- [8] QIAO C, POLLMEYER S, WANG Y, et al. Model predictive trajectory planning of autonomous vehicles considering dynamic driving constraints [C]. 2020 4th CAA International Conference on Vehicular Control and Intelligence (CVCI), 2020: 136-141.
- [9] MIGLANI A, KUMAR N. Deep learning models for traffic flow prediction in autonomous vehicles: a review, solutions, and challenges[J]. *Vehicular Communications*, 2019, 20: 100184.
- [10] JOERER S, SEGATA M, BLOESSL B, et al. A vehicular networking perspective on estimating vehicle collision probability at intersections [J]. *IEEE Transactions on Vehicular Technology*, 2013, 63(4): 1802-1812.
- [11] CHEN C, LÜ N, LIU L, et al. Critical safe distance design to improve driving safety based on vehicle-to-vehicle communications [J]. *Journal of Central South University*, 2013, 20(11): 3334-3344.
- [12] 张哲雨, 吕超, 李景行, 等. 基于车辆视角数据的行人轨迹预测与风险等级评定[J]. *汽车工程*, 2022, 44(5): 675-683.
ZHANG Zheyu, LÜ Chao, LI Jinghang, et al. Pedestrian trajectory prediction and risk grade assessment based on vehicle-perspective pedestrian data [J]. *Automotive Engineering*, 2022, 44(5): 675-683.
- [13] KUSANO K D, GABLER H C. Safety benefits of forward collision warning, brake assist, and autonomous braking systems in rear-end collisions [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2012, 13(4): 1546-1555.
- [14] BOARD N. Special investigation report-highway vehicle and infrastructure-based technology for the prevention of rear-end collisions[J]. NTSB Number SIR-OI/II, 2001.
- [15] 李霖, 朱西产, 马志雄. 驾驶员在真实交通危险工况中的制动反应时间[J]. *汽车工程*, 2014, 36(10): 1225-1229.
LI Lin, ZHU Xichan, MA Zhixiong. Driver brake reaction time under real traffic risk scenarios [J]. *Automotive Engineering*, 2014, 36(10): 1225-1229.
- [16] LEFÈVRE S, VASQUEZ D, LAUGIER C. A survey on motion prediction and risk assessment for intelligent vehicles[J]. *ROBOMECH Journal*, 2014, 1(1): 1-14.
- [17] GUO M, ZHAO X, YAO Y, et al. A study of freeway crash risk prediction and interpretation based on risky driving behavior and traffic flow data [J]. *Accident Analysis & Prevention*, 2021, 160: 106328.
- [18] ZHANG L, YUAN K, CHU H, et al. Pedestrian collision risk assessment based on state estimation and motion prediction [J]. *IEEE Transactions on Vehicular Technology*, 2021, 71(1): 98-111.
- [19] SHEN X, RAKSINCHAROENSAK P. Pedestrian-aware statistical risk assessment [J]. *IEEE Transactions on Intelligent Transportation Systems*, 2021, 23(7): 7910-7918.
- [20] LI Z, GONG J, LU C, et al. Interactive behavior prediction for heterogeneous traffic participants in the urban road: a graph-neural-network-based multitask learning framework [J]. *IEEE/ASME Transactions on Mechatronics*, 2021, 26(3): 1339-1349.
- [21] RUMMELHARD L, NÈGRE A, PERROLLAZ M, et al. Probabilistic grid-based collision risk prediction for driving application [C]. *Experimental Robotics: The 14th International Symposium on Experimental Robotics*, 2016: 821-834.
- [22] ROTH M, FLOHR F, GAVRILA D M. Driver and pedestrian awareness-based collision risk analysis [C]. 2016 IEEE Intelligent Vehicles Symposium (IV), 2016: 454-459.
- [23] 王建强, 吴剑, 李洋. 基于人-车-路协同的行车风险场概念, 原理及建模[J]. *中国公路学报*, 2016, 29(1): 105-114.
WANG Jianqiang, WU Jian, LI Yang. Concept, principle and modeling of driving risk field based on driver-vehicle-road interaction [J]. *China Journal of Highway and Transport*, 2016, 29(1): 105-114.
- [24] JASOUR A, HUANG X, WANG A, et al. Fast nonlinear risk assessment for autonomous vehicles using learned conditional probabilistic models of agent futures [J]. *Autonomous Robots*, 2022: 1-14.
- [25] MOHAMED A, QIAN K, ELHOSEINY M, et al. Social-stgcn: a social spatio-temporal graph convolutional neural network for human trajectory prediction [C]. *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2020: 14424-14432.
- [26] KOSARAJU V, SADEGHIAN A, MARTÍN-MARTÍN R, et al. Social-bigat: multimodal trajectory forecasting using bicycle-gan and graph attention networks [J]. *Advances in Neural Information Processing Systems*, 2019, 32.
- [27] ANAYA J J, MERDRIGNAC P, SHAGDAR O, et al. Vehicle to pedestrian communications for protection of vulnerable road users [C]. 2014 IEEE Intelligent Vehicles Symposium Proceedings, 2014: 1037-1042.
- [28] XUE J, FANG J, LI T, et al. BLVD: building a large-scale 5D semantics benchmark for autonomous driving [C]. 2019 International Conference on Robotics and Automation (ICRA), 2019: 6685-6691.
- [29] ZHANG H, NAN Z, YANG T, et al. A driving behavior recognition model with bi-LSTM and multi-scale CNN [C]. 2020 IEEE Intelligent Vehicles Symposium (IV), 2020: 284-289.
- [30] YANG T, NAN Z, ZHANG H, et al. Traffic agent trajectory prediction using social convolution and attention mechanism [J]. arXiv preprint arXiv:2007.02515.