



基于因果干预与动态图学习的交通事故风险预测

孙翊文, 张艺驰, 陈嘉骐

引用本文:

孙翊文, 张艺驰, 陈嘉骐. 基于因果干预与动态图学习的交通事故风险预测[J]. *智能系统学报*, 2026, 21(4): 1030–1043.

SUN Yiwen, ZHANG Yichi, CHEN Jiaqi. Traffic accident risk prediction based on causal intervention and dynamic graph learning[J]. *CAAI Transactions on Intelligent Systems*, 2026, 21(4): 1030–1043.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202511031>

您可能感兴趣的其他文章

视觉协同的违规驾驶行为分析方法

A visual collaborative analysis method for detecting illegal driving behavior

智能系统学报. 2021, 16(6): 1158–1165 <https://dx.doi.org/10.11992/tis.202101024>

样本仿真结合迁移学习的声呐图像水雷检测

Detection of underwater mine target in sidescan sonar image based on sample simulation and transfer learning

智能系统学报. 2021, 16(2): 385–392 <https://dx.doi.org/10.11992/tis.202101030>

基于路网结构的交通事故短期风险预测方法

A short-term risk prediction method for urban traffic accidents based on road network

智能系统学报. 2020, 15(4): 663–671 <https://dx.doi.org/10.11992/tis.201910002>

基于小样本学习的LCD产品缺陷自动检测方法

An automatic small sample learning-based detection method for LCD product defects

智能系统学报. 2020, 15(3): 560–567 <https://dx.doi.org/10.11992/tis.201904020>

基于Faster R-CNN的人体行为检测研究

Research on human behavior detection based on Faster R-CNN

智能系统学报. 2018, 13(6): 967–973 <https://dx.doi.org/10.11992/tis.201801025>

基于深度学习的视频预测研究综述

Review of deep learning-based video prediction

智能系统学报. 2018, 13(1): 85–96 <https://dx.doi.org/10.11992/tis.201707032>

DOI: 10.11992/tis.202511031

网络出版地址: <https://link.cnki.net/urlid/23.1538.tp.20260407.1430.006>

基于因果干预与动态图学习的交通事故风险预测

孙翊文¹, 张艺驰², 陈嘉骥³

(1. 北京大学人工智能研究院, 北京 100871; 2. 百度在线网络技术有限公司, 北京 100193; 3. 中央民族大学信息工程学院, 北京 100081)

摘要: 针对城市交通事故风险预测中存在的泛化能力差、时空相关性建模不足的问题, 提出一种基于因果干预与动态图学习的交通事故风险预测网络。该网络在编码器-解码器框架中, 设计了输入门模块以融合多周期事故信号与外部协变量; 提出动态图学习模块, 通过通道注意力机制自适应刻画节点间时变的空间依赖; 并结合图卷积与门控循环单元联合建模时空演化规律。为进一步提升预测稳定性, 引入转移桥模块, 将历史时空状态映射至未来状态, 以缓解多步预测中的误差累积问题; 同时, 采用基于前门准则的因果干预机制, 从特征层面切断混杂因子路径, 增强模型的鲁棒性与可迁移性。在 NYC 和 Chicago 两个公开数据集上的实验结果表明, CIDGNet 在均方根误差、召回率和平均精度均值 3 项指标上均优于 4 个基线模型。消融实验进一步验证了动态图、输入门、转移桥等关键模块对性能提升的贡献, 证明了因果干预与动态图学习在复杂时空预测任务中的有效性。

关键词: 事故预防; 因果干预; 深度学习; 预测; 风险预测; 图神经网络; 时间序列; 长短期记忆网络; 交通控制; 卷积神经网络

中图分类号: TP391.4; U491.31 文献标志码: A 文章编号: 1673-4785(2026)04-1030-14

中文引用格式: 孙翊文, 张艺驰, 陈嘉骥. 基于因果干预与动态图学习的交通事故风险预测 [J]. 智能系统学报, 2026, 21(4): 1030-1043.

英文引用格式: SUN Yiwen, ZHANG Yichi, CHEN Jiaqi. Traffic accident risk prediction based on causal intervention and dynamic graph learning[J]. CAAI transactions on intelligent systems, 2026, 21(4): 1030-1043.

Traffic accident risk prediction based on causal intervention and dynamic graph learning

SUN Yiwen¹, ZHANG Yichi², CHEN Jiaqi³

(1. Institute for Artificial Intelligence, Peking University, Beijing 100871, China; 2. Baidu Online Network Technology Co., Ltd., Beijing 100193; 3. School of Information Engineering, Minzu University of China, Beijing 100081, China)

Abstract: To address the limited generalization ability and inadequate spatiotemporal dependency modeling in urban traffic accident risk prediction, this paper proposes a traffic accident risk forecasting network based on causal intervention and dynamic graph learning. Within an encoder-decoder framework, an input-gating module is designed to fuse multi-period accident signals with external covariates. A dynamic graph learning module is further introduced to adaptively characterize time-varying spatial dependencies among nodes via a channel-attention mechanism, while graph convolution and gated recurrent units are jointly employed to model spatiotemporal evolution patterns. To further improve forecasting stability, a transition-bridge module is incorporated to map historical spatiotemporal states to future states, thereby mitigating error accumulation in multi-step prediction. Meanwhile, a front-door-criterion-based causal intervention mechanism is adopted to sever confounding paths at the feature level, enhancing model robustness and transferability. Experiments on two public datasets, NYC and Chicago, demonstrate that CIDGNet outperforms four baseline models in terms of root mean square error, recall, and mean average precision. Ablation studies further verify the contributions of key components-including the dynamic graph, input gate, and transition bridge-to performance gains, confirming the effectiveness of causal intervention and dynamic graph learning for complex spatiotemporal forecasting tasks.

Keywords: accident prevention; causal intervention; deep learning; forecasting; risk prediction; graph neural networks; time series; long short-term memory; traffic control; convolutional neural networks

收稿日期: 2025-11-24. 网络出版日期: 2026-04-08.

基金项目: 国家自然科学基金青年基金项目 (62503015).

通信作者: 孙翊文. E-mail: sunyiwen@pku.edu.cn.

交通事故带来严重的人员与经济损失, 若能预测城市空间中的高风险区域, 就能通过预警、

干预和道路改造等措施有效降低事故发生率^[1]。目前,全球范围正加速部署并升级智慧交通管控系统,而事故风险预测是其核心环节。如何通过精准预测来减少交通事故,已成为智能交通领域重要的研究方向。

目前,交通事故风险预测研究方法大致可以分为三类,分别是基于统计方法的交通事故预测、基于机器学习的交通事故预测以及基于深度学习的交通事故预测。

早期的交通事故风险预测研究多依赖泊松和负二项等^[2-5]统计模型,虽能给出概率估计,但无法刻画事故的时空依赖性,预测效果非常有限。马永杰等^[6]系统综述了卷积神经网络在智能交通系统中的应用,指出传统统计方法难以适应复杂交通环境的动态特性。

基于机器学习的交通事故预测模型主要适用于特征较少、数据集规模较小的场景。Dong等^[7]提出了一种基于支持向量机的交通事故风险预测方法,重点考虑了跨区域的空间相关性。冯宁等^[8]针对交通流的时空特性,提出了多组件时空图卷积网络,通过近期、日周期、周周期3个组件有效捕获交通数据的时空相关性,为处理交通数据的周期性提供了新思路。Parsa等^[9]使用XGBoost模型并结合实时交通、天气等多源数据来检测交通事故。该方法采用基于博弈论的解释型机器学习方法解释预测结果,分析各个特征的重要性。Lin等^[10]提出了一种两阶段式的事故热点检测方法,该方法首先建立核密度估计图,然后根据密度阈值对事故分布进行空间单元划分,得到基础分析单元,最后,整合多源环境数据,并运用k-means算法对事故热点区域进行空间聚合与分类。虽然基于机器学习的预测模型在精度上已经超越了许多统计方法,但面对海量数据时难以充分挖掘时空关联特性。主要原因在于传统机器学习模型忽略了时间依赖性,无法有效建模复杂的非线性时空关系。另外,这类模型不仅依赖于大量的特征工程和领域专家知识,还需要手动筛选事故的影响因素,过程耗时且主观性强。

近年来,深度学习方法(如长短期记忆网络(long short-term memory, LSTM)、卷积神经网络)在视觉、语言等任务中取得突破性进展,核心在于它能从海量数据里自动挖掘出高阶特征,并用无监督或半监督的方式提炼内在规律^[11-13]。目前已有学者将深度学习方法应用到交通事故预测领域,空间依赖可用图卷积网络刻画,时间依赖则由门控循环单元捕捉^[14-31]。随着多源异构数据愈

发丰富,深度学习已成为交通事故预测的主流研究方法。目前有代表性的工作有:户佐安等^[14]全面综述了图神经网络在交通预测中的应用,分析了不同图卷积架构的优缺点,指出图神经网络能够有效建模道路网络的空间拓扑关系。谷振宇等^[15]设计了时空图卷积循环神经网络,通过融合图卷积与循环神经网络实现了对路网交通流的精准预测,验证了时空联合建模的有效性。Ren等^[16]提出一种基于递归神经网络的交通事故风险预测框架,仅利用历史事故记录训练模型以捕捉时间演化规律,因缺乏多源交通数据支撑,预测性能受限。Chen等^[17]构建堆叠去噪自编码模型,通过多层BP神经网络从大规模出行数据中提取高层特征,并训练通用模型实现事故风险实时推演。Bao等^[18]设计时空卷积-长短期记忆网络,融合事故、出租车GPS、天气及路网等多源异构数据,以提升短时事故风险预测精度。上述方法虽引入外部信息,但未对区域内及区域间随时间演化的相关性进行显式建模。为此,Yuan等^[19]提出面向时空异构数据的深度预测模型,借助长短期记忆网络同时刻画事故的时间依赖与空间异质性,实现未来时段事故分布推断。赵文竹等^[20]提出了多视角融合的时空动态图卷积网络(graph convolutional network, GCN),通过动态调整图结构适应交通状态的时变特性,为建模动态空间相关性提供了有效方案。包银鑫等^[21]构建了改进的时空残差卷积神经网络,通过融合多源交通数据与时空特征,有效提升了城市路网短时交通流预测的精度,其多源数据融合策略对处理异构交通数据具有借鉴意义。Zhou等^[22]构建分钟级城市事故预测框架:首先采用协同感知策略估计全局交通状态,并通过数据增强缓解零膨胀问题;继而依据时变全局相关特性建模动态子区域关联,辅以差分特征生成器量化交通状态变化与事故发生的映射关系,以应对空间异质难题。Wang等^[23]提出融合多语义信息的预测模型,通过构建多视图表征,从地理与语义双维度捕获事故空间关联。Bhardwaj等^[24]设计加权上下文模型,整合卷积操作、堆叠双向门控循环单元及多图卷积网络,显式建模邻接区域时空交互,并引入时间注意力机制抽取关键时空特征。Tirrat等^[25]构建事故风险预测框架,基于时间与地理相关性分析揭示危险驾驶行为与事故的关联,进而提出融合多注意力模块的多视图图卷积网络。Zhang等^[26]提出了融合外部因素的动态图注意力网络,该网络通过多头注意力机制动态学习路网节点间的时变关联,

并集成实时天气与事件数据。HU 等^[27]设计了轻量化时空图卷积网络,采用分离式卷积与知识蒸馏技术,在保持预测性能的前提下大幅降低计算开销。Chen 等^[28]提出了一种面向流式数据的交通事故风险预测框架。该方法以多图层次化时空网络为核心,通过构建多种语义图(如空间邻接图、功能相似图、交通模式图等)来刻画道路之间的复杂关联关系。Zou 等^[29]通过构建多种静态图结构,在统一的多图时空神经网络中进行联合学习,以充分挖掘交通事故风险在空间和时间上的传播模式。模型通常采用 GCN 或其变体来建模空间依赖关系,并结合时序神经网络来捕捉时间动态变化。邹慧琪等^[30]系统总结了基于图神经网络的复杂时空数据挖掘方法,展望了未来发展方向,指出动态图与因果推断的结合是重要研究趋势;吴永庆等^[31]提出了解耦合动态时空卷积循环网络,通过解耦时空依赖性显著提升了预测性能。与上述工作不同,本文的动态图学习模块并非简单解耦时空特征,而是通过通道注意力机制将外部条件特征(天气、流量等)与时空状态深度融合,自适应刻画节点间随环境变化的动态空间依赖,实现了外部条件驱动的图结构动态演化。

上述研究成果虽然在预测精度上都得到很大提高,但是目前的交通事故预测仍然存在以下两个方面的不足:

其一,混杂因子干扰:现有模型在建模过程中往往直接集成多种外部信息(如天气、时间、交通流量等),试图通过增加输入维度来提升模型性能。然而,这类方法会引入大量的混杂因子,使模型在数据提取过程中存在虚假相关性^[32],导致模型的泛化能力受限。并且这类方法通常依赖于大量标注数据,通过学习这些数据中的特征来构建模型。然而它无法像人类一样辨别出哪些是具

有鲁棒性的因果特征,哪些是具有干扰性的特征。另外,随机对照试验往往需要高昂的成本,是难以实现的。相比之下,因果推断方法通过因果图、因果干预等技术,可以从观测数据中推断出现实世界中无法直接观察到的结果。

其二,动态时空建模不足:准确建模时空相关性至关重要,但现有研究多侧重区域间的静态关系,而忽视交通流、天气、节假日等动态因素的时变作用。实际数据表明,不同时间段内区域间的相关性会显著变化,静态图难以反映这种动态依赖。近年来,动态图在交通流预测等研究中已展现出良好的效果^[33-34]。与静态图相比,它能够根据不同时空条件灵活调整区域间的关系,从而更准确地反映交通状态的变化。然而,在交通事故风险预测领域,动态图的优势尚未得到充分利用,其潜在价值仍有待深入挖掘。

为解决上述问题,本文提出基于因果干预与动态图学习的交通事故风险预测网络(causal intervention and dynamic graph learning, CIDGNet):一方面利用因果干预理论在特征提取阶段去除混杂因子,避免模型过度依赖历史固定模式,从而更真实地捕获时空因果结构;另一方面设计动态图学习模块,通过动态调整节点间关系来建模时变的时空相关性,使模型能够灵活适应不同时间段与特殊环境下的风险变化。两者结合旨在提高模型的预测准确性与泛化能力,从而增强交通事故风险预测的实际应用价值。

1 基于因果干预与动态图学习的交通事故风险预测方法设计

本文提出的 CIDGNet 以因果干预理论为基础,旨在剔除混杂因子对交通事故建模的干扰,其整体架构如图 1 所示。




图 1 CIDGNet 模型架构

Fig. 1 CIDGNet model architecture diagram

该模型采用编码器-解码器框架,两端结构对称,并由转移桥模块衔接。以编码器为例,其由输入门模块、动态图学习模块与时空图卷积模块顺序堆叠而成。输入门模块接收周期性事故数据及外部协变量,输出多时间粒度的节点表征;动态图学习模块以上述表征与上一时刻的时空状态为输入,通过自适应机制刻画节点间关联的动态演化;时空图卷积模块则并置图卷积网络与门控循环单元(gate recurrent units, GRU),分别建模邻域空间依赖与事故时序演变规律;最终,转移桥模块将历史时空状态映射为未来时空状态,并递送至解码器完成预测。以下对4个模块作逐一阐述。

在数学和统计学领域,有一个重要的原则是:相关性并不等同于因果性^[35]。相关性用来衡量两个变量之间的关联程度,但它不足以证明变量之间是否存在因果联系。因果关系的建立需要更深入的理论分析和实验设计,仅凭相关性分析可能会出现误导性的结论。

相关性示意图如图2(a)所示, A、B、C、D分别表示同一事件的4个变量。当任一变量的值发生变化时,其他变量也随之变动,这表明它们之间存在相关性,但是相关性并不能直接推断出因果性。如图2(b)所示,若保持变量A和B的值不变,修改变量C的值,如果变量D随之发生变化则可以认为变量C与变量D之间存在因果性。从公式角度定义相关性和因果性:两个变量X和Y的相关性一般使用 Pearson 相关系数来度量,定义为 $r = \frac{\text{Cov}(X,Y)}{\sigma_X \sigma_Y}$, 其中 $\text{Cov}(X,Y)$ 是X和Y的协方差, σ_X 和 σ_Y 分别是X和Y的标准差;因果性指存在 $x_1 \neq x_2$, 使 $P(Y|\text{do}(X=x_1)) \neq P(Y|\text{do}(X=x_2))$ 。其中, $P(Y=y|\text{do}(X=x))$ 表示对所有样本进行 $X=x$ 的干预后, 对应样本中 $Y=y$ 的概率。这类似于随机对照试验, 需要控制无关变量, 干预研究变量。



图2 相关性与因果性定义示意

Fig. 2 Diagram of definitions for correlation and causation

因果学习包括因果发现和因果推断两个研究方向, 本文仅关注研究因果推断。传统机器学习方法通常依赖于大量标注数据, 通过学习这些数据中的特征来构建模型。然而它无法像人类一样辨别出哪些是具有鲁棒性的因果特征, 哪些是具有干扰性的特征。另外, 随机对照试验往往需要

高昂的成本, 是难以实现的。相比之下, 因果推断方法通过因果图、因果干预等技术, 可以从观测数据中推断出现实世界中无法直接观察到的结果。

因果图是一种用来描述数据生成过程, 明确变量之间因果关系的概率图, 它表示为 $G=\{N,E\}$, 其中 N 代表变量集合, E 则表示变量之间的因果关系。例如, 有向边 $X \rightarrow Y$ 表示变量 X 是变量 Y 的直接原因, 即 Y 的变化是由 X 直接引起的。

图3(a)给出了一个简单的因果图示例, 描述了运动频率与其他变量之间的因果关系。运动频率 E 一方面受健康状况 H 的直接影响, 另一方面通过中介变量 A 受到年龄 A 的间接影响。从年龄变量 A 出发有两条边: $A \rightarrow E$ 表示不同年龄段的运动频率可能存在差异。例如, 随着年龄的增长, 人们因身体机能下降而减少了运动频率。 $A \rightarrow H$ 表示随着年龄的增长, 人体的健康状况逐渐变差。从中可以观察到健康状况 H 和运动频率 E 之间存在相关性, 但这并不意味着两者之间存在直接的因果关系。这种相关性中包含了由混杂变量 A 引起的虚假关联。若要研究健康状况和运动频率之间真实的因果关系, 则需要对健康状况进行基于后门准则的因果干预, 剔除年龄对健康状况的影响, 即阻断 $A \rightarrow H$ 的路径, 如图3(b)所示。




图3 运动频率因果关系

Fig. 3 Causal relationship of exercise frequency

当存在混杂因素时, 利用因果干预来识别一个变量对另一个变量的真实因果效应。年龄变量 A 作为健康状况 H 和运动频率 E 之间的混杂因素, 即 H 和 E 之间除了真实因果关系外, 还可能存在由 A 引入的虚假关联。这意味着无法仅通过条件概率 $P(E|H)$ 来表示因果关系, 因为 $P(E|H)$ 并不总等于 $P(E|H,A)$ 。为了解决这一问题, 使用后门调整来估计干预分布。当对某一变量应用 do 算子(即 $\text{do}(\cdot)$)时, 所有指向该变量的边将被切断, 使其独立于父节点。例如, 在图3(b)中, $\text{do}(H)$ 表示忽略所有影响 H 的其他变量(即切断边 $A \rightarrow H$), 从而能够正确地估计 H 对 E 的因果效应。在满足后门准则的前提下, 可以通过如下公式估计干预分布:

$$P(E|\text{do}(H)) = \sum_A P(E|H,A)P(A)$$

当潜在混杂因素无法被观测或调整时, 无法

直接应用后门调整,前门准则提供了一种有效的替代方法。它的核心思想是利用一个完全中介变量 M 来间接估计因果效应,无需直接控制混杂变量。如图3(c)所示,假设 H 对 E 的影响完全通过中介变量 M 传递,且 M 仅受 H 的影响,同时不存在未观测的混杂变量影响 $M \rightarrow E$ 路径,则可以通过前门调整来计算 H 对 E 的因果效应。前门准则要求满足以下两个条件:1) M 是 H 与 E 之间的完全中介变量,即 H 仅能通过 M 影响 E ;2) M 对 E 的影响不受 H 之外的未观测混杂因素影响。在满足这些条件的情况下,可以使用公式计算干预分布:

$$P(E|\text{do}(H)) = \sum_M P(E|M)P(M|H)$$

其中 $P(E|M)$ 和 $P(M|H)$ 都可以从观测数据中获得,避免了直接调整混杂变量的困难。相比后门准则,前门准则适用于更复杂的因果结构,特别是在混杂因素难以控制的情况下。

本文通过因果图描述交通事故的因果关系,从因果角度深入挖掘交通事故风险值 X_t 、外部条件 C_t 、空间特征 S_t 、时间特征 T_t 和时空状态 H_t 之间的内在关联,进而预测下一时刻的事故风险值 $\hat{Y}_{t+1}$,如图4(a)所示。




图4 交通事故预测的因果图

Fig. 4 Causal graph for traffic accident prediction

图4中, X_t 表示 t 时刻的交通事故风险值,受到外部条件 C_t 的影响,同时直接作用于空间特征 S_t 和时间特征 T_t 的产生。 C_t 表示 t 时刻的外部环境条件,包括交通流量、天气状况、路况信息以及地图上标记的有用或兴趣点(point of interest, POI)等。 C_t 不仅直接作用于 X_t ,还通过时空状态 H_t 间接影响未来的交通事故风险。空间特征 S_t 反映了交通事故在空间上的聚集性和传播性。时间特征 T_t 表示交通事故在时间上的周期性和趋势性。 S_t 和 T_t 可以从 X_t 中解耦出来,并进一步集成为时空状态 H_t 。 H_t 作为中间变量,不仅受到 X_t 、 S_t 和 T_t 的影响,还直接作用于未来时刻的交通事故风险 $\hat{Y}_{t+1}$ 。

外部条件 C_t 对输入数据 X_t 和时空状态 H_t 具有显著的影响。然而,由于数据自身的不平衡特性,

模型在学习时空状态 H_t 时,可能会过度依赖数据中常见的模式,忽略具体的环境特征,导致模型在预测时产生不公平的偏差。又因为外部条件 C_t 具有无穷多种可能的取值,无法被完全覆盖,因此无法根据路径 $X_t \leftarrow C_t \rightarrow H_t$ 进行后门调整。为解决这一问题,采用基于路径 $C_t \rightarrow X_t \rightarrow S_t, T_t \rightarrow H_t \leftarrow C_t$ 的前门准则,如图4(b)所示,切断 $C_t \rightarrow X_t$ 的直接影响路径,使 X_t 能够更公平地处理不同的环境因素,并将其融入到时空状态 H_t ,提升预测结果的可靠性。

$$P(H_t|\text{do}(X_t)) = \sum_{S_t, T_t} P(S_t, T_t|\text{do}(X_t))P(H_t|\text{do}(S_t, T_t)) = \sum_{S_t, T_t} P(S_t, T_t|X_t') \sum_{X_t'} P(H_t|S_t, T_t, X_t')P(X_t'|X_t)$$

如上述公式, CIDGNet 模型使用输入门模块拟合 $P(X_t|X_t')$,它表示输入数据 X_t 的先验分布。 $P(S_t, T_t|X_t')$ 描述了从数据和噪声中提取时空特征 S_t 、 T_t 的过程。为实现这一过程,本文设计了动态图学习模块,将学习到的时空相关性嵌入到动态图中,从而更精准地建模复杂的时空依赖关系。 $P(H_t|S_t, T_t, X_t')$ 表示从特征中生成时变的时空状态,以刻画数据中固有的时空模式,这一功能通过时空图卷积模块实现。

1.1 输入门模块

交通事故在时间维度上展现出了显著的长期周期性和短期邻近性。为了深入分析这些特性,图5和图6分别绘制了部分区域连续几周的每日交通事故风险曲线和连续3个星期五的每小时事故风险曲线。




图5 每日交通事故风险曲线

Fig. 5 Daily traffic accident risk curve

在图5中,不同周次的每日交通事故风险曲线呈现出周期性波动,整体上表现为工作日风险较高、周末风险较低的趋势。然而,各周之间存在一定差异,例如,第2周的事故风险曲线图在周三有所下降,而第1周和第3周均保持上升趋势。这表明,尽管整体趋势具有周期性,但不同

周次内的交通事故风险可能会受到外部因素的影响而产生个别差异。在图6中,3个周五的每小时交通事故风险曲线表现出明显的时间序列相关性。从上述分析可以看出,交通事故的时间规律蕴含着短期邻近性和长期周期性的特点。因此,交通事故预测模型不仅需要捕捉短期时间依赖性(如每日和每小时的变化规律),也需要捕获长期周期性来提高模型的准确性和时效性。




图6 每小时交通事故风险曲线

Fig. 6 Hourly traffic accident risk curve

为了捕捉交通事故在时间维度上的短期邻近性和长期周期性,输入门模块的输入数据分为三部分:1)前 p 周同一时间段的事故风险值 $\mathbf{X}_{t-p+1:t}^{\text{week}} \in \mathbb{R}^{N \times p \times d_1}$; 2)前 p 天同一时间段的事故风险值 $\mathbf{X}_{t-p+1:t}^{\text{day}} \in \mathbb{R}^{N \times p \times d_1}$; 3)前 p 小时的事故风险值 $\mathbf{X}_{t-p+1:t}^{\text{hour}} \in \mathbb{R}^{N \times p \times d_1}$ 。其中 d_1 表示事故风险特征的维数, p 表示历史时间步长, N 表示城市网格数量。此外,模型还采集了对应时间段的外部数据,包括天气、流量、POI等。这些外部数据也按周、天、小时分别聚合,表示为 $\mathbf{C}_{t-p+1:t}^{\text{week}} \in \mathbb{R}^{N \times p \times d_2}$ 、 $\mathbf{C}_{t-p+1:t}^{\text{day}}$ 、 $\mathbf{C}_{t-p+1:t}^{\text{hour}}$,其中 d_2 表示外部特征的维数。

输入门模块首先结合每个时间粒度的事故数据和环境数据,如 $\mathbf{X}_{t-p+1:t}^{\text{week}} \parallel \mathbf{C}_{t-p+1:t}^{\text{week}}$ ($\parallel$ 表示连接操作)。然后,分别通过全连接层得到各时间粒度的特征表示 $\mathbf{H}^{\text{week}}$ 、 $\mathbf{H}^{\text{day}}$ 、 $\mathbf{H}^{\text{hour}}$ 。最后,将这些特征整合为特征张量 $\mathbf{X}_t^{\text{in}} = \mathbf{H}^{\text{week}} \parallel \mathbf{H}^{\text{day}} \parallel \mathbf{H}^{\text{hour}}$,并通过门控机制进行特征融合,具体表达如下:

$$\mathbf{X}_t' = (\mathbf{X}_t^{\text{in}} \Theta_a + a) \odot \sigma(\mathbf{X}_t^{\text{in}} \Theta_b + b)$$

其中 Θ_a 、 Θ_b 、 a 、 b 是模型的可学习参数, $\sigma(\cdot)$ 表示 Sigmoid 激活函数, $\mathbf{X}_t' \in \mathbb{R}^{N \times d}$ 表示节点嵌入; $\odot$ 表示逐元素相乘。门控信号 $\sigma(\mathbf{X}_t^{\text{in}} \Theta_b + b)$ 动态调整信息流 $(\mathbf{X}_t^{\text{in}} \Theta_a + a)$ 的通过比例,从而在捕获重要信息的同时过滤噪声。

1.2 动态图学习

交通事故的发生原因复杂多样,不仅受到区域内部和其他邻域的事故数据的影响,还受到天气、交通流量等多种外部条件的动态影响。然

而,现有研究大多聚焦于节点之间的静态空间相关性,未能充分考虑外部条件随时间变化而产生的动态影响,导致模型在捕捉事故风险的动态变化时存在局限性。尤其在面对复杂多变的交通环境时,预测性能往往难以满足实际需求。为此,本文提出了一个动态图学习模块,将时空状态与外部条件特征紧密耦合,如图7所示。




图7 动态图学习模块

Fig. 7 Dynamic graph learning module

在 t 时刻,动态图学习模块的输入为节点嵌入 $\mathbf{X}_t'$ 和前一时间步的时空状态 $\mathbf{H}_{t-1}$,具体表示为

$$\mathbf{I}_t = (\mathbf{X}_t' \parallel \mathbf{H}_{t-1}) \Theta_{\text{dyn}} + b_{\text{dyn}}$$

其中, $\parallel$ 表示级联操作, Θ_{dyn} 和 b_{dyn} 是模型的可学习参数, $\mathbf{I}_t \in \mathbb{R}^{N \times d}$ 表示融合后的节点特征, d 是特征通道的数量。

为了进一步增强模型的特征表示能力,本文在节点维度上引入了通道注意力机制。该机制通过生成节点的重要性感知向量动态调整特征权重,增加有用特征的权重,并抑制无用特征。

首先,通过全局平均池化将全局信息压缩到节点描述符中,捕捉图结构的整体特征。这一过程的公式表示为

$$\mathbf{z}_s = F_{\text{sq}}(\mathbf{I}_t) = \frac{1}{d} \sum_{c=1}^d \mathbf{I}_t[:, c] \in \mathbb{R}^N$$

其中 $\mathbf{z}_s$ 是压缩后的节点描述符。

然后,引入门控机制并根据节点间的依赖关系动态调整节点的重要性,从而激发节点的特异性,增强模型对关键特征的捕捉能力。

$$\mathbf{z}_e = F_{\text{ex}}(\mathbf{z}_s) = \sigma(\Theta_{\text{ex2}} \text{ReLU}(\Theta_{\text{ex1}} \mathbf{z}_s)) \in \mathbb{R}^N$$

其中 $\Theta_{\text{ex1}} \in \mathbb{R}^{16 \times N}$ 和 $\Theta_{\text{ex2}} \in \mathbb{R}^{N \times 16}$ 是可学习参数。

通过为每个节点分配权重,生成节点的动态潜在表示 $\mathbf{X}_{Dt}$,使每个节点能够更好地适应时空上下文的变化。例如,在雨天条件下,模型可以自动增强与湿滑路面相关的特征权重,来模拟特殊场景下的事故风险波动。

$$\mathbf{X}_{D_t} = F_{\text{scale}}(\mathbf{I}_t, \mathbf{z}_e) = \mathbf{I}_t \odot \mathbf{z}_e \in \mathbb{R}^{N \times d}$$

最后,借助自注意力机制的思想计算节点间的相似度,并将动态依赖关系嵌入到图结构中。具体公式为

$$\mathbf{A}_t^{\text{dyn}} = \text{ReLU} \left(\phi \left(\frac{\mathbf{X}_{D_t}}{\sqrt{d}} \right) \right) \in \mathbb{R}^{N \times N}$$

其中: $\mathbf{A}_t^{\text{dyn}}$ 表示 t 时刻节点之间的动态时空依赖关系, $\phi(\cdot)$ 是双曲正切函数。通过此过程,模型能够捕获节点间的动态关系,为图结构提供更丰富的语义信息。例如,在交通网络中,某一路段事故可能会对邻近路段产生连锁反应,而通道注意力机制能够自动捕捉这种动态传播效应,帮助模型更准确地模拟交通网络复杂的相互作用。

1.3 时空图卷积模块

静态相似图和动态图从不同角度揭示了节点间的关系。为了更好地建模节点间的复杂关系,本文还引入了 3 种类型的相似性图: 风险相似图 $\mathbf{A}^{\text{risk}}$ 、道路相似图 $\mathbf{A}^{\text{road}}$ 和 POI 相似图 $\mathbf{A}^{\text{poi}}$ 。以 POI 相似图为例,每个节点代表一个网格区域,边则表示区域之间 POI 向量的相似度。

模块的输入由当前时间步的节点表示 $\mathbf{X}_t$ 和上一时间步的隐藏状态 $\mathbf{H}_{t-1}$ 组成:

$$\mathbf{X}_t^{(0)} = (\mathbf{X}_t \| \mathbf{H}_{t-1}) \in \mathbb{R}^{N \times 2d} \quad (1)$$

式中: $\mathbf{X}_t^{(0)}$ 表示该模块的初始化状态,通过递归更新方式学习空间信息。递归更新方式表示为

$$\begin{aligned} \mathbf{X}_t^{(n)} = & \alpha_0 \mathbf{X}_t^{(n-1)} + \alpha_1 \tilde{\mathbf{A}}^{\text{risk}} \mathbf{X}_t^{(n-1)} + \alpha_2 \tilde{\mathbf{A}}^{\text{road}} \mathbf{X}_t^{(n-1)} + \\ & \alpha_3 \tilde{\mathbf{A}}^{\text{poi}} \mathbf{X}_t^{(n-1)} + \alpha_4 \tilde{\mathbf{A}}^{\text{dyn}} \mathbf{X}_t^{(n-1)} \in \mathbb{R}^{N \times 2d} \end{aligned} \quad (2)$$

式中: α_0 、 α_1 、 α_2 、 α_3 、 α_4 是可学习的贡献系数, n 是传播深度, $\mathbf{X}_t^{(n)}$ 表示第 n 层的节点特征表示。 $\tilde{\mathbf{A}}^{\text{risk}}$ 、 $\tilde{\mathbf{A}}^{\text{road}}$ 、 $\tilde{\mathbf{A}}^{\text{poi}}$ 、 $\tilde{\mathbf{A}}^{\text{dyn}}$ 表示归一化矩阵,归一化的公式为 $\tilde{\mathbf{A}} = \mathbf{D}^{-1} \mathbf{A}$, $\mathbf{D}_{ii} = \sum_j \mathbf{A}_{ij}$ 。

经过多层递归,所有层的输出状态通过全连接层处理得到最终输出:

$$\tilde{\mathbf{X}}_t^{\text{out}} = \text{ReLU} \left(\sum_{k=0}^n \mathbf{X}_t^{(k)} \mathbf{W}^{(k)} + \mathbf{b}^{(k)} \right) \in \mathbb{R}^{N \times 2d} \quad (3)$$

式中: $\mathbf{W}^{(k)}$ 和 $\mathbf{b}^{(k)}$ 表示第 k 层的可学习参数。为了简化计算,引入了扩散卷积^[36]。该方法有效地传播了图中每个节点的流入和流出信息,加速了对节点之间空间依赖关系的捕捉。最后将式(1~3)简化为

$$\tilde{\mathbf{X}}_t^{\text{out}} = \boldsymbol{\Theta} * \mathbf{G}(\mathbf{X}_t \| \mathbf{H}_{t-1}) = \boldsymbol{\Theta}_1 * \mathbf{G}(\mathbf{X}_t^{(0)}, \mathbf{A}) + \boldsymbol{\Theta}_2 * \mathbf{G}(\mathbf{X}_t^{(0)}, \mathbf{A}^{\text{T}})$$

交通事故除了具有空间相关性,在时间维度上表现出双重特性:短期内呈现出连续性变化,长期具有周期性规律。为了捕捉空间特征的时间特性,本文将 GRU 与 GCN 紧密结合在一起,将

GCN 的输出作为 GRU 内每个门控的输入,具体公式为

$$\begin{aligned} \mathbf{r}_t &= \sigma(\boldsymbol{\Theta}_r * \mathbf{G}(\mathbf{X}_t \| \mathbf{H}_{t-1}) + \mathbf{b}_r) \\ \mathbf{z}_t &= \sigma(\boldsymbol{\Theta}_z * \mathbf{G}(\mathbf{X}_t \| \mathbf{H}_{t-1}) + \mathbf{b}_z) \\ \tilde{\mathbf{h}}_t &= \phi(\boldsymbol{\Theta}_h * \mathbf{G}(\mathbf{X}_t \| (\mathbf{r}_t \odot \mathbf{H}_{t-1})) + \mathbf{b}_h) \\ \mathbf{H}_t &= \mathbf{z}_t \odot \mathbf{H}_{t-1} + (1 - \mathbf{z}_t) \odot \tilde{\mathbf{h}}_t \end{aligned}$$

式中: $\boldsymbol{\Theta}_r$ 、 $\boldsymbol{\Theta}_z$ 、 $\boldsymbol{\Theta}_h$ 、 $\mathbf{b}_r$ 、 $\mathbf{b}_z$ 和 $\mathbf{b}_h$ 是可学习的参数, $* \mathbf{G}$ 是之前定义的图卷积操作, $\mathbf{r}_t$ 和 $\mathbf{z}_t$ 是更新门和重置门, $\tilde{\mathbf{h}}_t$ 是候选状态, $\mathbf{H}_t$ 是 GRU 在 t 时刻的隐藏状态, σ 和 ϕ 分别指 Sigmoid 函数和 tanh 函数。最后,时空图卷积模块将提取到的历史潜在时空状态传递给转移桥模块,作为转移桥模块的输入。

1.4 转移桥模块

传统的时序预测方法通常采用递归结构,使模型在生成未来时间步的预测值时依赖前一时间步的输出,从而导致误差在多步预测过程中不断累积。为缓解这一问题,本文设计了转移桥模块。由于外部条件具有一定的周期性和稳定性,该模块通过学习历史外部条件与未来外部条件之间的映射关系,来弥补预测过程中的信息缺失,并减少了对历史时空状态的过度依赖。具体方法如下:

首先,引入自注意力机制方法^[37],将历史时间步和未来时间步的外部数据作为输入,经过全连接层得到历史外部特征表示 $\mathbf{C}^{\text{his}}$ 和未来外部特征表示 $\mathbf{C}^{\text{pred}}$,并分别将其映射为注意力机制的键向量和查询向量,再将历史时空状态 $\mathbf{H}^{\text{his}}$ 作为值向量。具体的变换公式为

$$\begin{aligned} \mathbf{K} &= \mathbf{C}^{\text{his}} \mathbf{W}^K \in \mathbb{R}^{N \times P \times d} \\ \mathbf{Q} &= \mathbf{C}^{\text{pred}} \mathbf{W}^Q \in \mathbb{R}^{N \times Q \times d} \\ \mathbf{V} &= \mathbf{H}^{\text{his}} \mathbf{W}^V \in \mathbb{R}^{N \times P \times d} \end{aligned}$$

其中: $\mathbf{W}^K$ 、 $\mathbf{W}^Q$ 、 $\mathbf{W}^V$ 分别是历史外部特征、未来外部特征、历史时空状态的权重矩阵, $\mathbf{H}^{\text{his}}$ 表示过去所有时间步的时空状态集合。

在完成数据映射后,模块根据缩放点积注意力机制计算历史外部条件与未来外部条件之间的注意力得分,并将其加权到历史时空状态上,得到未来时空状态 $\mathbf{H}^{\text{pred}}$ 。具体计算过程为

$$\mathbf{H}^{\text{pred}} = \text{softmax} \left(\frac{\mathbf{Q} \mathbf{K}^T}{\sqrt{d}} \right) \mathbf{V} \in \mathbb{R}^{N \times Q \times d}$$

其中: d 是特征通道的数量; $\sqrt{d}$ 用于缩放点积结果,防止因注意力值过大而造成梯度不稳定。直观上,转移桥模块通过这种方式,能够动态捕捉历史外部条件与未来外部条件之间的相似部分,有效突出重要的历史特征。 $\mathbf{H}^{\text{pred}}$ 作为解码器的初始化输入,进行下一时刻的事故风险预测。因为

解码器和编码器结构一致,这里不再赘述。

1.5 训练过程

受文献[23]的启发,本文采用加权损失函数来更新模型参数。该函数对交通事故风险较高的区域赋予更高的权重,避免模型在预测过程过度倾向于零值。具体而言,将事故风险等级分为4个类别: $I = \{0, 1, 2, \geq 3\}$ 。最终损失函数可表示为

$$L(Y, \hat{Y}) = \frac{1}{2} \sum_{i \in I} \beta_i (Y(i) - \hat{Y}(i))^2$$

其中: $Y(i)$ 表示实际事故风险等级为 i 的标签值; $\hat{Y}(i)$ 表示对应样本的预测值; β_i 是超参数,表示交通事故风险等级为 i 的样本权重。

2 实验及结果分析

为了验证本文创新工作的有效性和先进性,这里将分别在两个公开数据集上进行两个方面的实验:①将本文提出的 CIDGNet 网络模型与目前具有代表性的8种方法进行对比,验证本文提出方法的先进性;②通过消融实验分别验证本文提出的 CIDGNet 网络模型中创新部分的有效性。

2.1 数据集描述

本文采用的数据集是来自于美国纽约市(NYC)和芝加哥市(Chicago)的两个公开数据集,围绕“事故-流量-天气-POI”4类信息收集与处理展开。

数据集中的事故数据提供了事故发生的时间戳、地理坐标和风险等级;交通流量以出租车订单为代表,出租车数据记录了乘客上下车的时间和位置信息;天气数据包括5类天气状况,分别是晴天、雨天、雪天、多云、雾天;POI数据包括7种,分别是商业区、学校、住宅区、社会服务、娱乐、交通枢纽、文化设施。值得注意的是,公开的芝加哥数据集没有POI数据。上述两个公开数据集的详细信息见表1。

表1 数据集信息
Table 1 Dataset information

数据集	NYC	Chicago
时间范围	2013年1月1日— 2013年12月31日	2016年2月1日— 2016年9月30日
交通事故数/ 10^3	147	44
出租车订单数/ 10^3	173 179	1 744
是否获取POI数据	是	否

2.2 实验设置

2.2.1 评估指标

根据交通事故预测文献[23],本文从回归和

排序两个角度评估模型。从回归的角度来说,采用均方根误差(E_{RMS})作为评估指标,衡量模型对交通事故风险的整体评估能力。 E_{RMS} 的计算公式表示为

$$E_{\text{RMS}} = \sqrt{\frac{1}{T} \sum_{t=1}^T (Y_t - \hat{Y}_t)^2}$$

式中: Y_t 指在时间步 t 内所有网格区域的实际事故风险值, $\hat{Y}_t$ 指在时间步 t 内所有网格区域的事故风险预测值。从排序的角度来看,本文采用召回率 R 和平均精度均值 P_{MA} 来评估模型识别高风险区域的能力。具体而言, R 衡量预测高风险区域与实际发生事故区域的交集比例。 P_{MA} 用于评估模型对高风险区域的排序性能,要求模型将事故高发区域尽可能排在前列。两者的计算公式为

$$R = \frac{1}{T} \sum_{t=1}^T \frac{S_t \cap R_t}{|R_t|}$$

$$P_{\text{MA}} = \frac{1}{T} \sum_{t=1}^T \frac{\sum_{j=1}^{|R_t|} \text{pre}(j) \times \text{rel}(j)}{|R_t|}$$

其中: R_t 表示在时间步 t 内真实发生交通事故的区域集合; S_t 表示模型预测的事故风险排名前 $|R_t|$ 的区域集合;函数 $\text{pre}(j)$ 用于计算预测结果的前 j 个高风险区域与真实发生事故的区域比例,反映了模型的局部预测精度; $\text{rel}(j)$ 作为二元变量,用于标记区域 j 在时间步 t 内是否发生事故, $\text{rel}(j) = 0$ 表示未发生, $\text{rel}(j) = 1$ 表示发生。

为了更全面地评估模型性能,本文采用多维度评价体系:首先,采用上述3个指标评估模型在全天时段(0:00~24:00)的综合表现。其次,针对交通事故高发时段,设置早高峰(7:00~9:00)和晚高峰(16:00~19:00)两个评估窗口,通过相同的指标体系评估模型在关键时段的预测能力。

2.2.2 实验环境和参数配置

本实验采用 PyTorch 深度学习框架,实验环境的具体硬件配置和软件版本见表2。数据集按照时间顺序被划分训练集(60%)、验证集(20%)、测试集(20%)。将研究区域划分成 20×20 的网格,并将1 d的时间划分为24个时间段,每个时间段为1 h。

超参数的设置如下:批次大小设置为32,初始学习率为0.0002,随机丢弃概率设为0.1,历史时间步长为4;图卷积网络采用2层结构,每层卷积核维度设置为64;GRU设置5层隐藏层,每层包含256个隐藏单元。在损失函数中,风险等级权重分别为{0.05,0.2,0.25,0.5}。在训练过程中,采用早停止机制避免过拟合。

表2 实验环境
Table 2 Experimental environment

硬件及软件	参数
CPU	Intel(R) Xeon(R) Silver
内存	125 GB
GPU	RTX 4090
操作系统	Ubuntu 22.04
Cuda版本	12.4
Nvidia driver 版本	550.54
Python 版本	3.8

2.2.3 对比模型

为了评估 CIDGNet 模型的先进性, 选取了 8 种具有代表性及先进性的模型进行对比实验。其中, 历史平均法 (historical average, HA)^[38] 代表

经典的时间序列预测方法; 极端梯度提升 (extreme gradient boosting, XGBoost)^[39]、多层感知机 (multilayer perceptron, MLP)^[40] 和 GRU^[41] 分别代表机器学习、基础深度学习和序列建模方法; ConvLSTM^[42]、Graph WaveNet^[43]、地理与语义时空网络 (geographical and semantic spatial-temporal network, GSNet)^[23] 和地形加权上下文类别网络 (topographic-weighted context category network, TWC-Cnet)^[24] 则是当前最为先进的时空预测模型。

2.2.4 模型的先进性验证与分析

表3和表4分别给出了各模型在 NYC 和 Chicago 数据集上的性能结果。每一列最好的结果用粗体表示, 次好的结果用下划线表示, *表示模型在高峰时段的性能表现。

表3 NYC 数据集上的性能对比
Table 3 Performance comparison on the NYC dataset

模型	$E_{\text{RMS}} \downarrow$	$R/\% \uparrow$	$P_{\text{MA}} \uparrow$	$E_{\text{RMS}}^* \downarrow$	$R^*/\% \uparrow$	$P_{\text{MA}}^* \uparrow$
HA	10.3243	24.43	0.1049	9.4994	26.94	0.1258
XGBoost ^[36]	11.0165	23.14	0.1008	10.1730	25.22	0.1119
MLP ^[40]	8.4289	27.28	0.1196	7.6379	29.51	0.1338
GRU ^[41]	8.3375	28.09	0.1228	7.3546	30.76	0.1301
ConvLSTM ^[42]	7.9505	30.99	0.1526	7.2554	32.61	0.1557
Graph WaveNet ^[43]	7.7358	31.78	0.1623	7.0958	33.04	0.1647
GSNet ^[23]	7.6599	<u>33.01</u>	0.1785	6.8263	34.05	<u>0.1772</u>
TWCCnet ^[24]	<u>7.5945</u>	32.69	<u>0.1808</u>	<u>6.7816</u>	33.07	0.1715
CIDGNet (本文)	7.1560	33.35	0.1865	6.7336	34.50	0.1810

注: 加粗表示结果在该列最好。

表4 Chicago 数据集上的性能对比
Table 4 Performance comparison on the chicago dataset

模型	$E_{\text{RMS}} \downarrow$	$R/\% \uparrow$	$P_{\text{MA}} \uparrow$	$E_{\text{RMS}}^* \downarrow$	$R^*/\% \uparrow$	$P_{\text{MA}}^* \uparrow$
HA	14.9581	13.80	0.0572	10.2564	15.89	0.0644
XGBoost ^[36]	15.6946	12.58	0.0545	10.3685	15.22	0.0614
MLP ^[40]	12.5116	17.53	0.0631	8.9500	18.93	0.0748
GRU ^[41]	12.6482	17.83	0.0664	9.0421	18.66	0.0758
ConvLSTM ^[42]	11.1309	18.84	0.0789	8.5254	20.30	0.0925
Graph WaveNet ^[43]	<u>11.0835</u>	18.95	0.0805	<u>8.4484</u>	20.42	0.0933
GSNet ^[23]	11.2346	<u>20.29</u>	<u>0.0856</u>	8.5628	21.81	0.1070
TWCCnet ^[24]	11.3092	20.21	0.0850	8.4832	<u>21.85</u>	<u>0.1146</u>
CIDGNet (本文)	10.2810	21.23	0.1004	8.1382	22.36	0.1255

注: 加粗表示结果在该列最好。

从这两个表格中可以看出:

1) CIDGNet 模型表现优异: 本文提出的 CIDGNet 模型在所有对比模型中表现最优, 其预测精

度均优于其他基线模型。

2) 在对比模型中: GRU 在捕捉事故数据的时间相关性时表现出了显著优势。该模型通过独特

的门控机制,能够同时建模短期邻近依赖和长期周期模式,进一步证明了时间相关性建模在交通事故风险预测中的关键作用;MLP将输入数据展平成一维向量,这种操作缺乏对时间和空间相关性的动态建模,导致信息丢失;HA和MLP的表现也不佳,主要是因为它们无法有效捕捉数据中的时空相关;XGBoost模型效果最差,原因在于其无法有效捕捉时空数据的复杂性,导致模型预测性能较弱。

3) 时空预测模型的提升:与传统模型相比,时空预测模型在预测效果上有了显著提升,其中本文提出的CIDGNet的效果最好,GSNet和TWCCNet模型效果次之,ConvLSTM和Graph WaveNet模型相对较差。这种性能差异主要源于模型架构设计的局限性:Graph WaveNet通过GCN和空洞卷积捕获区域间的静态空间依赖关系,未能有效建模区域间随时间变化的动态交互特征。GSNet虽然从地理和语义方面挖掘了交通事故的时空关联性,但是没有考虑混杂因子对事故预测的消极影响,导致模型性能略差。

4) 高峰时段的预测精度:本文提出的CIDGNet模型在高峰时段的预测精度较全天时段更为精确,预测精度均优于其他对比模型。这主要是因为高峰时段交通事故发生的频率较高,且具有更显著的周期性特征,使模型更容易捕捉到潜在的事故发生规律。

总之,从实验结果可以看出,本文提出的CIDGNet模型通过构建不同类型的静态相似图和动态图,从静态和动态两个角度捕获事故时空依赖关系,并使用基于前门准则的因果干预框架消除混杂因子,在交通事故风险预测任务中取得最优结果。特别地,CIDGNet模型在高峰时段的预测精度较全天时段更为精确。

2.2.5 消融实验

为进一步验证CIDGNet模型中创新部分的有效性与合理性,这里从3个角度展开消融实验,包括:子模块的消融实验、4种图结构的消融实验、不同特征的消融实验。通过对模型结构进行有针对性的调整与对比,可以分析各模块在整体性能提升中的作用,并揭示不同设计在时空建模与风险预测中的贡献程度。

需要说明的是,因果干预机制部分未被单独纳入消融实验。这是因为该机制并非独立的网络结构,而是贯穿整个模型训练与推理过程的全局性设计。其核心思想是通过前门准则调整输入变量与预测结果之间的信息流路径,从而削弱虚假

相关的影响,提升模型的可解释性与泛化能力。若在实验中直接去除该机制,模型的输入分布、损失函数以及优化目标都会发生根本性变化,使得实验结果失去可比性,也无法反映单一结构变化带来的性能差异。

因此,本文采用间接验证的方式来评估因果干预的效果:通过对比在不同特征组合与图结构设置下模型的性能变化,观察模型在消除虚假相关与保持预测稳定性方面的表现,从而间接体现因果干预机制的有效性。

1) 子模块的消融实验

为评估CIDGNet模型各组件的有效性,本文设计了5种不同的模型变体,并分别在NYC数据集上进行实验。具体描述如下:

① 去除压缩-激励机制的动态图生成器(dynamic graph generator without squeeze-and-excitation, DGG-SE):从动态图学习模块中删除通道注意力机制;

② 去除历史时空状态动态图生成器(DGG-H):从动态图学习模块中删除前一个时间步的时空状态;

③ 去除节点嵌入的动态图生成器(DGG-X):去除动态图学习模块中的节点嵌入;

④ 基于全连接网络的输入门(input gate with fully connected network, IG w/ FC):将输入门模块替换成全连接网络;

⑤ 转移桥(TransBri):去掉转移桥模块,并使用编码器的最后时空状态代替。

消融实验结果如表5所示,CIDGNet模型的整体性能表现最优异,表明模型内部各组件之间的协同作用提升了模型的预测性能。对于动态图学习模块,动态图集成了事故周期性特征和外部环境特征,模拟了跨区域的交互式进化过程。从表中可以观察到DGG-H的指标比DGG-SE和DGG-X差,表明历史时空状态的缺失对模型的影响较大,进一步证实了时间维度上的长期依赖信息可以有效辅助模型挖掘未来事故发生规律。针对输入门模块,IG w/ FC的评估指标比CIDGNet差,这表明利用输入门模块进行特征提取是有效的。此外,本实验使用 E_{RMS} 来评估模型对随机波动的抵抗能力,去除输入门会显著增加 E_{RMS} ,表明该模块通过融合周期性事故数据和外部环境特征,提取具有上下文感知的信息,从而抵抗外部环境波动。针对转移桥模块,-TransBri变体的消融结果变差,表明该模块在后续解码器的激活过程中,起到了缓冲和信息整合的关键作用。

表 5 CIDGNet 变体在 NYC 数据集上的实验结果
Table 5 Experimental results of the CIDGNet variants on the NYC dataset

模型	$E_{RMS} \downarrow$	$R/\% \uparrow$	$P_{MA} \uparrow$	$E_{RMS}^* \downarrow$	$R^*/\% \uparrow$	$P_{MA}^* \uparrow$
DGG-SE	7.2154	31.69	0.1603	6.7625	32.05	0.1569
DGG-H	7.2148	31.56	0.1585	6.7608	32.02	0.1568
DGG-X	7.2138	31.83	0.1620	6.7636	32.05	0.1576
IG w/ FC	7.2558	31.58	0.1769	6.8013	33.24	0.1751
-TransBri	7.3025	31.64	0.1723	6.8519	33.21	0.1693
CIDGNet	7.1560	33.35	0.1865	6.7336	34.50	0.1810

注: *表示模型在高峰时段的性能, 加粗表示结果在该列最好。

2) 4 种图结构的消融实验

为了研究不同图结构对模型性能的影响, 构建了 4 个模型变体: CIDGNet- A^{risk} (去除风险相似图)、CIDGNet- A^{road} (去除道路相似图)、CIDGNet-

A^{poi} (去除 POI 相似图) 和 CIDGNet- A^{dyn} (去除动态图), 每个变体仅移除一种图结构, 其余设置与 CIDGNet 模型保持一致。4 种图结构的消融实验结果可视化如图 8 所示。




图 8 不同图结构的消融实验结果

Fig. 8 Ablation experiment results of different graph structures

从图 8 中可以观察到, 动态图起到了较为突出的作用。去掉动态图后所有指标效果明显变差, 证明动态图的引入可以显著提升模型性能, 因为它提供了静态拓扑图无法提取的动态时空关系。此外, 在 3 种静态图中, CIDGNet- A^{risk} 的表现最差, 表明某一区域的交通事故风险与具有相似事故风险模式的区域最相关。CIDGNet- A^{poi} 的表现略差于 CIDGNet- A^{road} , 表明具有相似 POI 特征的区域更可能共享相似的事故风险模式。总体来说, CIDGNet 取得了最佳性能, 强调了从多语义角度进行时空建模的必要性。

3) 不同特征的消融实验

为了验证模型是否消除了特征之间的虚假相

关性, 进行了 4 次针对不同特征的消融实验: CIDGNet-poi (去掉 POI 特征)、CIDGNet-weather (去掉天气特征)、CIDGNet-flow (去掉交通流量特征)、CIDGNet-time (去掉时间特征)。每次实验仅去除一种特征, 其余设置与 CIDGNet 模型保持一致。

根据 NYC 数据集上的实验结果, 分析模型是否消除了虚假相关性, 实验结果可视化如图 9 所示。过多的特征集成到模型中, 如果不经专门的处理可能会导致模型性能下降, 因为随着特征维度的增多会使特征之间产生虚假相关性。CIDGNet 模型专门利用输入门模块处理外部环境数据和交通事故数据, 得到原始数据的先验分

布,再结合动态图学习模块和时空图卷积模块来进一步消除特征之间的虚假相关性。由不同特征的消融实验结果可以发现,CIDGNet模型在6个实验指标上均优于其他变体,尤其是在Chicago

数据集上,提升幅度达到了8.5%。证明该模型能够利用外部环境特征辅助交通事故预测,有效消除了特征之间的虚假相关性并实现了性能提升。




图9 不同特征的消融实验结果

Fig. 9 Ablation experiment results of different features

3 结束语

本文构建了一个因果图,从因果视角描述交通事故风险预测问题。由于不完全观测的干扰,在特征提取过程中会产生伪相关性。为此,提出了一种基于因果干预与动态图学习的交通事故风险预测模型。根据前门准则将编(解)码器分解为多个子项,并相应地设计了输入门、动态图学习模块、时空图卷积模块来实现因果干预的功能。动态图学习模块是最关键的组件,它将区域间的动态空间相关性嵌入到动态图中,使模型能够捕捉交通系统的动态变化规律。为解决长时间序列预测的误差累积问题,利用转移桥模块将历史时空状态转换成未来时空状态。实验结果表明,本文提出的CIDGNet模型显著优于现有模型,证明了该模型在交通事故预测任务中的先进性。未来,为了进一步提升模型效率,可以改进模块结构或引入轻量化策略。在确保预测精度的前提下,减少模型参数规模并降低计算复杂度,从而增强模型的实用性与可扩展性。

参考文献:

- [1] DOYCHEVA K. Global status report on road safety 2018[M]. [S. l.]: World Health Organization, 2019.
- [2] JOSHUA S C, GARBER N J. Estimating truck accident rate and involvements using linear and Poisson regression models[J]. *Transportation planning and technology*, 1990, 15(1): 41–58.
- [3] 陈昭明, 徐文远. 基于负二项分布的高速公路交通事故影响因素分析[J]. *交通信息与安全*, 2022, 40(1): 28–35.
CHEN Zhaoming, XU Wenyuan. An analysis of factors influencing freeway crashes with a negative binomial model[J]. *Journal of transport information and safety*, 2022, 40(1): 28–35.
- [4] IHUEZE C C, ONWURAH U O. Road traffic accidents prediction modelling: an analysis of Anambra State, Nigeria[J]. *Accident analysis & prevention*, 2018, 112: 21–29.
- [5] LI Wei, ZHAO Xujian, LIU Shiyu. Traffic accident prediction based on multivariable grey model[J]. *Information*, 2020, 11(4): 184.
- [6] 马永杰, 程时升, 马芸婷, 等. 卷积神经网络及其在智能交通系统中的应用综述[J]. *交通运输工程学报*, 2021, 21(4): 48–71.
MA Yongjie, CHENG Shisheng, MA Yunting, et al. Review of convolutional neural network and its application in intelligent transportation system[J]. *Journal of traffic and transportation engineering*, 2021, 21(4): 48–71.
- [7] DONG Ni, HUANG Helai, ZHENG Liang. Support vec-

- tor machine in crash prediction at the level of traffic analysis zones: Assessing the spatial proximity effects[J]. *Accident analysis & prevention*, 2015, 82: 192–198.
- [8] 冯宁, 郭晟楠, 宋超, 等. 面向交通流量预测的多组件时空图卷积网络[J]. *软件学报*, 2019, 30(3): 759–769.
- FENG Ning, GUO Shengnan, SONG Chao, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting[J]. *Journal of software*, 2019, 30(3): 759–769.
- [9] PARSA A B, MOVAHEDI A, TAGHIPOUR H, et al. Toward safer highways, application of XGBoost and SHAP for real-time accident detection and feature analysis[J]. *Accident analysis & prevention*, 2020, 136: 105405.
- [10] LIN Lei, WANG Qian, SADEK A W. A novel variable selection method based on frequent pattern tree for real-time traffic accident risk prediction[J]. *Transportation Research Part C: Emerging Technologies*, 2015, 55: 444–459.
- [11] DOYCHEVA K. GPU-enabled real-time pavement distress detection based on computer vision and deep learning[D]. Bochum: Ruhr University Bochum, 2020.
- [12] FAISAL M, ALBOGAMY F, ELGIBREEN H, et al. Deep learning and computer vision for estimating date fruits type, maturity level, and weight[J]. *IEEE access*, 2020, 8: 206770–206782.
- [13] GUPTA M, VARMA V, DAMANI S, et al. Compression of deep learning models for NLP[C]//Proceedings of the 29th ACM International Conference on Information & Knowledge Management. Virtual Event: ACM, 2020: 3507–3508.
- [14] 户佐安, 邓锦程, 韩金丽, 等. 图神经网络在交通预测中的应用综述[J]. *交通运输工程学报*, 2023, 23(5): 39–61.
- HU Zuoan, DENG Jincheng, HAN Jinli, et al. Review on application of graph neural network in traffic prediction [J]. *Journal of traffic and transportation engineering*, 2023, 23(5): 39–61.
- [15] 谷振宇, 陈聪, 郑家佳, 等. 基于时空图卷积循环神经网络的交通流预测[J]. *控制与决策*, 2022, 37(3): 645–653.
- GU Zhenyu, CHEN Cong, ZHENG Jiajia, et al. Traffic flow prediction based on STG-CRNN[J]. *Control and decision*, 2022, 37(3): 645–653.
- [16] REN Honglei, SONG You, WANG Jingwen, et al. A deep learning approach to the citywide traffic accident risk prediction[C]//2018 21st International Conference on Intelligent Transportation Systems. Maui: IEEE, 2018: 3346–3351.
- [17] CHEN Quanjun, SONG Xuan, YAMADA H, et al. Learning deep representation from big and heterogeneous data for traffic accident inference[C]//Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix: ACM, 2016: 338–344.
- [18] BAO Jie, LIU Pan, UKKUSURI S V. A spatiotemporal deep learning approach for citywide short-term crash risk prediction with multi-source data[J]. *Accident analysis & prevention*, 2019, 122: 239–254.
- [19] YUAN Zhuoning, ZHOU Xun, YANG Tianbao. Hetero-ConvLSTM: a deep learning approach to traffic accident prediction on heterogeneous spatio-temporal data[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London: ACM, 2018: 984–992.
- [20] 赵文竹, 袁冠, 张艳梅, 等. 多视角融合的时空动态 GCN 城市交通流量预测[J]. *软件学报*, 2024, 35(4): 1751–1773.
- ZHAO Wenzhu, YUAN Guan, ZHANG Yanmei, et al. Multi-view fused spatial-temporal dynamic GCN for urban traffic flow prediction[J]. *Journal of software*, 2024, 35(4): 1751–1773.
- [21] 包银鑫, 曹阳, 施佳. 基于改进时空残差卷积神经网络的城市路网短时交通流预测[J]. *计算机应用*, 2022(1): 258–264.
- BAO Yinxin, CAO Yang, SHI Quan. Improved spatio-temporal residual convolutional neural network for urban road network short-term traffic flow prediction[J]. *Journal of computer applications*, 2022(1): 258–264.
- [22] ZHOU Zhengyang, WANG Yang, XIE Xike, et al. RiskOracle: a minute-level citywide traffic accident forecasting framework[C]//Proceedings of the AAAI Conference on Artificial Intelligence. New York: AAAI, 2020, 34(1): 1258–1265.
- [23] WANG Beibei, LIN Youfang, GUO Shengnan, et al. GS-Net: learning spatial-temporal correlations from geographical and semantic aspects for traffic accident risk forecasting[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Virtual Event: AAAI, 2021, 35(5): 4402–4409.
- [24] BHARDWAJ N, PAL A, BHUMIKA, et al. Adaptive context based road accident risk prediction using spatio-temporal deep learning[J]. *IEEE transactions on artificial intelligence*, 2024, 5(6): 2872–2883.
- [25] TRIRAT P, YOON S, LEE J G. MG-TAR: multi-view graph convolutional networks for traffic accident risk prediction[J]. *IEEE transactions on intelligent transportation systems*, 2023, 24(4): 3779–3794.
- [26] ZHANG Jiaxun, GUAN Yanchen, WAGN Chengyue, et al. LATTE: a real-time lightweight attention-based traffic accident anticipation engine[J]. *Information fusion*, 2025, 122: 103173.

- [27] HU Junjie, BAI Jun, YANG Jiayu, et al. Crash risk prediction using sparse collision data: Granger causal inference and graph convolutional network approaches[J]. Expert systems with applications, 2025, 259: 125315.
- [28] CHEN Minxiao, YUAN Haitao, JIANG Nan, et al. SMGHSTN: towards an effective streaming traffic accident risk prediction framework[J]. IEEE transactions on knowledge and data engineering, 2025, 37(7): 4285–4298.
- [29] ZOU Guojian, ZHOU Zhiyong, WEIBEL R, et al. Multi-graph spatio-temporal network for traffic accident risk forecasting[J]. Pattern recognition, 2026, 172: 112784.
- [30] 邹慧琪, 史彬泽, 宋凌云, 等. 基于图神经网络的复杂时空数据挖掘方法综述[J]. 软件学报, 2025, 36(4): 1811–1843.
- ZOU Huiqi, SHI Binze, SONG Lingyun, et al. Survey on complex spatio-temporal data mining methods based on graph neural network[J]. Journal of software, 2025, 36(4): 1811–1843.
- [31] 吴永庆, 姜正宇. 基于解耦动态时空卷积循环网络的交通流预测[J]. 计算机工程, 2026, 52(5): 160–171.
- WU Yongqing, JIANG Zhengyu. Traffic flow prediction based on decoupled dynamic spatio-temporal convolutional recurrent network[J]. Computer engineering, 2026, 52(5): 160–171.
- [32] LIU Chang, SUN Xinwei, WANG Jindong, et al. Learning causal semantic representation for out-of-distribution prediction[C]//Neural Information Processing Systems. Virtual Event: NeurIPS, 2020.
- [33] YAN Haoyang, MA Xiaolei, PU Ziyuan. Learning dynamic and hierarchical traffic spatiotemporal features with transformer[J]. IEEE transactions on intelligent transportation systems, 2022, 23(11): 22386–22399.
- [34] WANG Yuhu, FANG Shen, ZHANG Chunxia, et al. TVGCN: Time-variant graph convolutional network for traffic forecasting[J]. Neurocomputing, 2022, 471: 118–129.
- [35] PEARL J. Causality[M]. Cambridge: Cambridge University Press, 2009.
- [36] LI Yaguang, YU R, SHAHABI C, et al. Diffusion convolutional recurrent neural network: data-driven traffic forecasting[EB/OL]. (2017–07–06)[2025–11–24]. <https://arxiv.org/abs/1707.01926>.
- [37] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[C]//Advances in Neural Information Processing Systems 30. Long Beach: NeurIPS, 2017: 5998–6008.
- [38] LIU Runpeng, SHIN S Y. A review of traffic flow prediction methods in intelligent transportation system construction[J]. Applied sciences, 2025, 15(7): 3866.
- [39] CHEN Tianqi, GUESTRIN C. XGBoost: a scalable tree boosting system[C]//Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. San Francisco: ACM, 2016: 785–794.
- [40] RUMELHART D E. Learning internal representations by error propagation[J]. Parallel distributed processing: explorations in the microstructure of cognition, 1986, 1: 319–362.
- [41] CHUNG J, GULCEHRE C, CHO K, et al. Empirical evaluation of gated recurrent neural networks on sequence modeling[EB/OL]. (2014–12–11)[2025–11–24]. <https://arxiv.org/abs/1412.3555>.
- [42] SHI Xingjian, CHEN Zhourong, WANG Hao, et al. Convolutional LSTM Network: a machine learning approach for precipitation nowcasting[C]//Proceedings of the 29th International Conference on Neural Information Processing Systems. Cambridge: ACM, 2015: 802–810.
- [43] WU Zonghan, PAN Shirui, LONG Guodong, et al. Graph WaveNet for deep spatial-temporal graph modeling [EB/OL]. (2019–06–31)[2025–11–24]. <https://arxiv.org/abs/1906.00121>.

作者简介:



孙翊文, 助理研究员, 博士, 主要研究方向为智能交通系统和自动驾驶。主持国家自然科学基金青年科学基金项目(C类)1项。发表学术论文10余篇。E-mail: sunyiwen@pku.edu.cn。



张艺驰, 硕士, 主要研究方向为交通事故预测和POI标签分类。E-mail: 17866548902@163.com。



陈嘉骐, 硕士研究生, 主要研究方向为自动驾驶和人工智能。E-mail: 15091795674@163.com。