

动态路网下城市交通事故风险预测模型研究与实现

董婉青, 赵子榕, 廖惠敏, 肖晖, 张晓亮

引用本文

董婉青, 赵子榕, 廖惠敏, 肖晖, 张晓亮. 动态路网下城市交通事故风险预测模型研究与实现[J]. 计算机科学, 2024, 51(6A): 230500118-10.

DONG Wanqing, ZHAO Zirong, LIAO Huimin, XIAO Hui, ZHANG Xiaoliang. [Research and Implementation of Urban Traffic Accident Risk Prediction in Dynamic Road Network](#) [J]. Computer Science, 2024, 51(6A): 230500118-10.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[融合多源图特征的Kcore-GCN反欺诈算法研究](#)

Study on Kcore-GCN Anti-fraud Algorithm Fusing Multi-source Graph Features
计算机科学, 2024, 51(6A): 230600040-7. <https://doi.org/10.11896/jsjcx.230600040>

[一种基于异构图神经网络和文本语义增强的实体关系抽取方法](#)

Method for Entity Relation Extraction Based on Heterogeneous Graph Neural Networks and Text Semantic Enhancement
计算机科学, 2024, 51(6A): 230700071-5. <https://doi.org/10.11896/jsjcx.230700071>

[基于改进GraphSAGE算法的浏览器指纹追踪](#)

Browser Fingerprint Tracking Based on Improved GraphSAGE Algorithm
计算机科学, 2024, 51(6): 409-415. <https://doi.org/10.11896/jsjcx.230400003>

[基于图神经网络的乳腺癌病理图像分析方法综述](#)

Survey of Breast Cancer Pathological Image Analysis Methods Based on Graph Neural Networks
计算机科学, 2024, 51(6): 172-185. <https://doi.org/10.11896/jsjcx.230400106>

[面向前提选择的新型图约简表示与图神经网络模型](#)

New Graph Reduction Representation and Graph Neural Network Model for Premise Selection
计算机科学, 2024, 51(5): 193-199. <https://doi.org/10.11896/jsjcx.230300193>

动态路网下城市交通事故风险预测模型研究与实现

董婉青¹ 赵子榕² 廖惠敏³ 肖 晖⁴ 张晓亮⁴

1 北京市交通运输综合执法总队 北京 100044

2 北京小马智行科技有限公司 北京 100094

3 北京市交通运输综合执法总队执法保障中心 北京 100044

4 中路高科交通科技集团有限公司 北京 100088

(dongwanqing@jtw.beijing.gov.cn)

摘要 通过图卷积神经网络对交通事故进行风险预测是交通领域的研究热点。然而,现有的使用图卷积神经网络对交通事故进行风险预测的研究存在着缺乏语义邻接性的构造、无法进行图权重的自适应学习的问题。针对以上问题,文中基于多源交通大数据,构建了数据驱动的多粒度、多视角的时空拓扑图,实现了交通网络中时空关联性和依赖性的精准建模。图上的结点从时间和空间两个维度对路段结点的交通状态进行综合描述,边则从地理邻接性和语义邻接性两个视角表现了路段之间的抽象邻接关系。在时空拓扑图的基础上,文中设计了基于动态时空图网络的交通事故风险预测模型,实现了路段级交通事故风险的准确预测。该模型引入了具有多头注意力机制的空间图网络层对空间关联性进行学习,同时采用了基于一维扩张卷积的时间学习单元捕获短时依赖性与长时周期性。在北京地区的实际交通数据集上进行大规模实验,所提方法的召回率达到 0.899, F1-Score 达到 0.860,其他指标与主流方法相比也均有所提升。

关键词: 交通事故风险预测;图神经网络;时空数据挖掘

中图分类号 TP391

Research and Implementation of Urban Traffic Accident Risk Prediction in Dynamic Road Network

DONG Wanqing¹, ZHAO Zirong², LIAO Huimin³, XIAO Hui⁴ and ZHANG Xiaoliang⁴

1 Beijing Transportation Comprehensive Enforcement Corps, Beijing 100044, China

2 Beijing Pony. Ai Science and Technology Co., Ltd., Beijing 100094, China

3 Support Center of Beijing Transportation Comprehensive Enforcement Corps, Beijing 100044, China

4 RIOH High Science and Technology Group, Ltd., Beijing 100088, China

Abstract Accident risk prediction of traffic accidents through graph convolution networks is a research hotspot in the transportation field. However, the existing researches on using graph convolution networks for accident risk prediction lack semantic adjacency in graph construction and unable to perform adaptive learning of graph weights. To address these problems, a data-driven, multi-granularity and multi-view spatio-temporal topology graph is constructed based on multi-source traffic big data to realize the accurate modeling of spatio-temporal correlation and dependency in traffic network. The nodes on the graph provide a comprehensive description of the traffic state from time and space two dimensions, while the edges show the abstract adjacency relationship between roadways from geography and semantics two perspectives. Then, a dynamic spatio-temporal graph network based on the spatio-temporal topology graph is designed to achieve accurate prediction of roadway-level traffic accident risk. The model introduces spatial graph network layers with multi-headed attention mechanism to learn spatial correlations, while temporal learning units based on 1-D dilated convolution are used to capture short-time dependencies and long-time periodicity. According to large-scale experiments carried out on real traffic data in Beijing area, our method achieves the recall of 0.899 and the F-1 Score of 0.860. Meanwhile, there are also improvements in other indicators comparing to mainstream methods.

Keywords Traffic accident risk prediction, Graph neural network, Spatio-Temporal data mining

1 引言

交通事故的预测研究一直是交通安全领域的研究热点。然而,交通事故具有随机性,且人为的主观因素占比较大,其

相关特征难以在交通事故发生前及时获取,因此交通事故仅能利用客观数据进行“风险预测”。早期的事故预测方法通常采用概率模型分析交通事故发生的可能性与道路特征、年平均交通量等宏观因素的关系,并基于此对道路的交通事故发

基金项目:北京市交通行业科技项目(0686-2241B1251414Z)

This work was supported by the Beijing Transportation Industry Science and Technology Project(0686-2241B1251414Z).

通信作者:张晓亮(zhangxiaoliang@hstg.com.cn)

生概率进行预测。但是此类方法忽略了影响因子的动态变化对交通事故发生情况的影响,因此预测的准确度较低,也无法满足现实场景中实时预测的需求。

交通事故的影响因素错综复杂,而交通网络作为其载体,拓扑结构含有丰富的地理信息及语义信息。深度学习的方法在交通预测这类复杂问题的建模上具有天然的优越性。然而,在对交通网络的空间关系进行建模时,大部分的研究^[1-4]采取了将研究区域划分成网格的方式。用网格划分法解决交通事故风险预测问题存在以下缺点:1)交通事故大多发生在道路区域,而网格化的分区方式会导致区域中包含大量非道路区域,如住宅区、办公区等,引入无关噪声;2)网格化分区强行将路网数据在欧几里得(Euclidean)空间中表示,导致路网拓扑信息丢失,在很大程度上影响了预测性能;3)以网格区域为交通事故风险的预测单元,不能满足驾驶员通过参考事故风险预测指数选择出行路线的需要。

随着图神经网络(Graph Neural Network, GNN)^[5]的发展,交通数据的图建模成为了研究人员的关注焦点。然而,尽管有些研究^[6-7]在将图结构纳入预测模型方面已取得显著的进步,但它们仍存在以下一些缺陷。1)缺乏语义邻接性的构造。例如,城市中一些距离较远的路段可能共享相似的“时间模式”。但部分现有的模型仅基于路网的地理连接关系建立图结构,忽略了结点之间的语义相似性。2)无法进行图权重的自适应学习。以往的研究大多基于图卷积神经网络(Graph Convolution Networks, GCN)^[8],而图卷积时对所有邻居结点均一视同仁,不能根据结点的重要性分配不同的权重。

针对以上两个问题,本文提出如下解决方案:

1)基于包括交通事故数据、出租车轨迹数据、气候观测数据、城市兴趣点数据以及路网数据等在内的城市交通异质大数据,对多元时空特征进行分析与提取,构建数据驱动的交通网络时空拓扑图。

2)在时空拓扑图的基础上,设计了一个深度时空网络自适应地捕捉路段与路段之间、特征与特征之间复杂的依赖关系及关联关系,通过对时空特征的学习与融合来实现城市路段级事故发生风险的精确预测。

2 相关技术

2.1 基于图神经网络的空间建模技术

不同应用场景下的空间关系建模方式不尽相同,但总体上,可以依据数据类型划分为两大类:“面向欧氏数据的空间建模方法”与“面向图数据的空间建模方法”。对于图像分类、视频处理等任务,其数据通常是在欧几里得空间中进行表示的,多采用卷积神经网络(Convolutional Neural Networks, CNN)进行空间建模。对于非欧几里得数据,例如人与人之间的社交网络、城市间的物流网络等,它们可被抽象为包含复杂依赖关系和关联关系的图(Graph)。图数据的复杂性给现有的机器学习方法带来了重大挑战。基于此,一些学者尝试将传统的深度学习方法扩展到图数据,图神经网络应运而生。

图神经网络最早由 Scarselli 等^[5]提出。图中的一个结点可以通过其特征及关联结点进行定义。图神经网络的目标是学习图中每个结点的状态表征,并基于此生成输出向量,用于

作为预测结点标签的分布等。图可以定义为 $G=(V, E)$, 其中, V 表示图中所有结点的集合, E 表示图中所有边的集合。定义一个局部转移函数 f , 用于根据邻居结点的状态对目标结点 v 进行更新; 定义一个局部输出函数 g , 用于生成结点的输出状态 o_v 。

$$h_v = f(x_v, x_{co[v]}, h_{ne[v]}, x_{ne[v]}) \quad (1)$$

$$o_v = g(h_v, x_v) \quad (2)$$

其中, x 表示输入特征, h 表示隐含状态。 $co[v]$ 表示与结点 v 相连的所有边的集合, $ne[v]$ 表示与结点 v 相邻的所有结点的集合。将以上两个公式扩展到所有结点,即可计算出下一层的隐状态。

尽管 GNN 是一个用于建模图数据的强大模型,但一般的 GNN 模型仍存在一些缺陷:1)图上结点的隐含状态更新较为低效;2)图上边的一些信息特征并没有被有效建模。因此,在 GNN 的基础上,又演化出了 GCN。

GCN 将用于传统欧氏数据的卷积操作应用到图数据中,其核心思想在于学习一个函数,结合结点的自身特征和邻居的特征获得结点的融合表征。多个图卷积层通过聚合相邻结点的特征信息来封装每个结点的隐层表征,并在特征聚合后对结果进行非线性变换。通过图卷积层的堆叠,每个结点的最终隐层表征可以接收到更远的邻居信息。

2.2 时序预测技术

时序预测技术在包括气候预报、商业决策、交通监管等在内的多个领域均发挥着重要作用。通常情况下,时序预测模型预测一个给定实体 i 在时间 t 的目标值 $y_{i,t}$, i 代表一个包含某类时序信息的逻辑实体,例如交通场景下承载交通流速信息的各个路段,或者医学场景下承载生命体征信息的不同病人等。时序预测问题可定义为:

$$\hat{y}_{i,t+1} = \xi(y_{i,t-k:t}, x_{i,t-k:t}, s_i) \quad (3)$$

其中, $\hat{y}_{i,t+1}$ 表示实体 i 在时间 $t+1$ 的预测结果, $x_{i,t-k:t} = \{x_{i,t-k}, \dots, x_{i,t}\}$, $y_{i,t-k:t} = \{y_{i,t-k}, \dots, y_{i,t}\}$ 分别表示回溯窗口大小为 k 时的历史输入值与其对应的目标值, s_i 表示与实体 i 关联的静态特征(例如传感器位置), $\xi(\cdot)$ 表示模型经过学习得到的预测函数。

现有的基于深度学习的时序预测技术,主要基于以下 3 类基础组件:循环神经网络(Recurrent Neural Network, RNN)^[9]、因果卷积网络(Causal Convolution Neural Network)^[10]及注意力机制(Attention Mechanism)^[11]。

2.2.1 基于循环神经网络的方法

循环神经网络在多种自然语言处理任务中均有优越的表现,是序列建模中最为常用的一类模型方法。如图 1 所示,每个 RNN 单元包含一个内部记忆状态,作为历史时序信息的紧凑表征。记忆状态在每个时间步上都会根据新的输出结果递归更新。




图 1 RNN 模型的结构

Fig. 1 Architecture of RNN model

由于对回溯的历史窗口不设限制,传统的 RNN 方法在学习数据的长时依赖性时可能会产生梯度爆炸或梯度消失的问题。长短期记忆网络(Long Short-Term Memory Network, LSTM)^[12]在原有 RNN 的基础上,通过改进网络中的梯度流来解决这一问题。

2.2.2 基于因果卷积网络的方法

传统的卷积神经网络主要应用于图像数据集,它可以提取跨空间维度不变的局部关系。为了使得 CNN 适应时序预测问题,研究人员设计了多层因果卷积。图 2 给出了具有两个因果卷积层的神经网络结构,每层卷积操作对应的卷积核大小和步长均不相同。可以看出,因果卷积是一种特殊的一维卷积,其在一维卷积的基础上确保网络仅使用历史信息进行预测。




图 2 因果卷积神经网络的结构

Fig. 2 Architecture of causal convolutional network

由于卷积网络中参数的数量直接与感受野的大小成正比,因此在时间序列长期依赖性很强的情况下,使用标准卷积层会消耗大量算力,给模型训练带来挑战。为了缓解这一问题,一些学者尝试采用扩张卷积层^[13-14],通过增加每一层的扩张率,扩张卷积可以逐步聚合不同时间步的信息,从而以更高效的方式使用更多的历史信息。

2.2.3 基于注意力机制的方法

注意力机制的发展推动了序列长时依赖性的学习,基于注意力机制的深度学习模型在多个自然语言学习任务中实现了最佳性能^[11,15]。如图 3 所示,注意力层利用动态生成的注意力权重聚合时序特征,使得网络可以直接关注到过去时间步中更为重要的信息。

从原理上看,注意力机制是一种基于给定的查询(Query)向量进行键值(Key-value)查找的机制:

$$h_t = \sum_{\tau=0}^k \alpha(k_t, q_t) v_{t-\tau} \quad (4)$$

其中,键向量 k_t , 查询向量 q_t 和值向量 $v_{t-\tau}$ 是由神经网络的浅层在某时间步上产生的中间特征。 $\alpha(k_t, q_t) \in [0, 1]$ 表示时刻 t 对于历史时间步 $t-\tau$ 生成的注意力权重, h_t 表示注意力层的上下文输出向量。




图 3 基于注意力机制的神经网络结构图

Fig. 3 Architecture of attention based neural network

2.3 交通预测技术

交通预测在智能交通系统的成功构建过程中起到至关重

要的作用。交通预测类问题属于天然的时序动态图的预测问题。基于神经网络对交通大数据进行预测,一直是相关领域学者研究的重点。纵观这些研究,大都采用神经网络的多种变体对交通数据中的空间关联性进行建模,而根据其对于时序依赖性的建模,可以大致分为以循环网络为主体的方法和以卷积网络为主体的方法。

以循环网络为主体的方法,如扩散卷积循环神经网络(Diffusion Convolutional Recurrent Neural Network, DCRNN)^[16],通常采用序列到序列(Sequence to Sequence, Seq2Seq)的框架结构,通过图卷积进行循环单元中的门控计算,或者通过作用在所有结点上的循环神经网络同时捕捉时空依赖性及相关性。这种方法的优点在于可兼容变长的输入序列和输出序列,使用场景更为灵活;缺点在于循环神经网络在迭代运算的过程中算力消耗较大,且为了解决梯度消失问题,需要额外设计一些复杂的机制,模型不够简洁高效。

以卷积网络为主体的方法,如时空图卷积网络(Spatio-temporal Graph Convolutional Networks, STGCN)^[17],通常将时间维度上的因果卷积和空间维度上的图卷积通过不同的组合方式交替使用,同时捕捉时空依赖性及关联性。这种方法的优点在于卷积运算相比循环神经网络的迭代运算更为高效,且不容易产生梯度衰减的问题。而该方法的缺点在于无法兼容变长的输入序列和输出序列,使用场景不够灵活。

综上所述,利用图神经网络解决交通预测的相关问题,一般是先计算得到观测点之间的拓扑关系,然后基于历史状态、地理位置、语义信息、气象观测等内外部特征,设计嵌入图神经网络的复合模型对交通时空依赖关系进行学习,进而预测未来的交通演化趋势。

3 基于时空拓扑图的交通网络建模方法

3.1 交通网络建模问题定义和形式化

首先对本节中交通网络的相关术语进行定义。

定义 1(路段) 路段是交通路网中道路模型的原子单位,一条道路由多个路段连接构成。每条路段的信息包括起始点和终止点的位置、路段编号、路段长度等属性。

定义 2(路网) 路网指一定区域内,以道路为基本元素,交织连接成网状分布的道路系统。如图 4 所示,路网直观上可视为一张以道路为边的无向图。无向图的结点为道路与道路之间的交叉点、连接点以及道路的起点和终点等。




图 4 路网结构示意图

Fig. 4 Architecture of road network

定义 3(交通网络) 交通网络依托于路网,指包含交通线路、交通运行状态、交通设施分布等信息在内的开放式复杂网络。交通网络具有动态性和语义性。交通网络的合理建模是研究交通预测类问题的前提和基础。

定义 4(路段速度) 路段速度指在一个时间窗口内经过

某路段的车辆的平均速度,在本文中其是衡量路段运行状态的主要指标。

定义 5(交通事故发生频次) 交通事故发生频次指在一个时间窗口内某路段交通事故发生的总次数,在本文中其是衡量路段运行状态的主要指标。

定义 6(时空拓扑图) 时空拓扑图指包含时间属性和空间属性的一类抽象图网络结构。交通网络具有丰富的时间信息和空间信息,如何将复杂的交通网络抽象成时空拓扑图的形式,对其时空依赖关系进行精准建模,是本节研究的主要内容。

给定初始路网 $G'_{road} = (V'_{road}, E'_{road})$, V'_{road} 表示道路之间的交叉点、连接点以及道路的起点和终点集合, E'_{road} 表示路段集合。由于本文的目标是路段级别的交通事故风险预测,因此在交通路网建模时,将对原有的路网 G'_{road} 进行重构,得到以路段为结点 V_{road} , 路段与路段之间的连接关系为边 E_{road} 的新路网 $G_{road} = (V_{road}, E_{road})$ 。

由于路网 G_{road} 的拓扑结构十分庞大,在整张路网上直接进行建模和分析并不现实。因此,本文将基于当前路网结构和多元时空影响因子 X , 抽取拓扑子图,建立多视图、多粒度的交通网络时空拓扑图 G_s 。假设 $|V_{road}| = N$, $|\cdot|$ 表示集合的范数, G_s 为 $v_i \in V$ 路段的时空拓扑子图,其建模过程可形式化为 $g(G_{road}, X)$:

$$G_s = \{G_s^1, G_s^2, \dots, G_s^N\} \quad (5)$$

$$G_s^i = g(G_i, X) \quad (6)$$

3.2 时空特征分析与提取

交通网络建模的关键点之一在于,如何对其复杂的时空特性进行描述。交通网络的时空特性是由一系列交通状态影响因子决定的,交通状态的影响因子纷繁多样,其选择方式主要取决于交通预测的目标。本文以交通事故风险预测为例,对其相关的时空影响因子进行分析及特征提取,以建立可用于解决交通事故风险预测问题的交通网络时空拓扑图。

本文将多元时空影响因子 X 分为 3 类。

1) 路网的时空特征 X^s

路网的时空特征表示为 $X^s \in \mathbb{R}^{N \times D_s}$, 其中 $N = |V|$ 为交通网络中路段的数目, D_s 为空间特征的维度。路网的时空特征用于描述每个路段的静态空间属性,主要包括路段自身的属性及路段周围的环境属性,其直接或间接影响了道路交通事故的发生概率。

2) 局部的时序特征 X^t

局部的时序特征表示为 $X^t \in \mathbb{R}^{N \times T \times D_t}$, 其中 T 为历史时间片的数目, D_t 为特征的维度。局部的时序特征用于描述每个路段的交通时序属性,主要包括路段历史的交通流状态及交通事故发生情况。由于作用在路网上,局部的时序特征兼具时间特性和空间特性。局部的时序特征体现了道路交通的演进方向,在一定程度上影响未来的交通行为,与交通事故的发生情况有较为直接的关系。

3) 全局的外部特征 X^e

全局的外部特征表示为 $X^e \in \mathbb{R}^{D_e}$, 其中 D_e 为外部特征的维度。全局的外部特征主要指在较大的尺度上对整个交通网络产生影响的外部特征,主要包括气象特征和日期特征。所有的路段在同一时刻共享全局的外部特征。

3.2.1 路网的时空特征

在交通事故风险预测问题中,路段所处的位置、路段的结构特性和周围的环境特征都直接决定了该路段的交通模式特点,从而间接影响交通事故风险预测的结果。

有研究指出,事故发生位置与城市道路网络具有很强的相关性。交通枢纽路段的事故发生频次较高,且会对邻接的路段产生影响;偏远路段与其他路段较少相交,且行驶车辆少,因此交通事故发生频次明显低于核心路段。

此外,路段周围的环境属性是决定其交通状况的关键信息,如办公区、商务区往往在上下班时有着较高的流量,而购物中心等娱乐场所主要需求量集中在晚上和周末。当道路流量较高时,更容易产生交通事故。城市 POI 直接反映了区域的功能属性,表 1 列出了北京市数量排名前十的 POI 统计情况,涵盖了购物、餐饮、公司企业、生活服务等类别。不同种类的 POI 其发生事故的频率也存在差异,例如位于餐饮密集区的路段事故发生频率远高于位于政府机构及社会团体附近的路段事故发生频率。

表 1 北京市 TOP 10 POI 统计表
Table 1 Top 10 POI in Beijing

POI 类型	POI 编号	POI 数目	举例
购物服务	7	67781	购物中心
餐饮服务	2	51612	餐厅、奶茶店
公司企业	9	50125	办公楼、产业基地
生活服务	8	43789	超市、服务中心
商务住宅	14	26700	旺铺、居民小区
政府机构及社会团体	3	17901	市政府办公厅
科教文化服务	4	17271	文化宫、科技园
公共设施	0	16485	公园、公共厕所
交通设施服务	5	15933	红绿灯、防护栏
医疗保健服务	13	10770	医院、诊所

基于以上分析,交通网络的时空特征定义为 $X^s = [X^{rod}, X^{poi}]$, 包括路段的结构特征 $X^{rod} \in \mathbb{R}^{N \times D_{rod}}$ 和路段周围的环境特征 $X^{poi} \in \mathbb{R}^{N \times D_{poi}}$ 。其中, D_{rod}, D_{poi} 为路段特征维度。路段 $v_i \in V$ 的结构特征表示为 x_i^{rod} , 本文将邻居路段数目、路段长度、路段位置等作为路段的结构特征。路段 $v_i \in V$ 的环境特征表示为 x_i^{poi} , 主要从路段周围的 POI 数据中进行提取。

$$x_i^{poi} = \{ | \{ p \in P_j \wedge dist(v_i, p) \leq d_p \} |, 1 \leq j \leq D_{poi} \} \quad (7)$$

其中, P_j 表示类型编号为 j 的 POI 集合, $dist(v_i, p)$ 表示路段 v_i 和兴趣点 p 之间的距离, d_p 表示每个路段 v_i 局部环境视野的阈值。

3.2.2 局部的时序特征

直观上,交通流的速度与交通事故的发生概率密切相关。由于出租车数据规模庞大,对每个路段逐段遍历计算每个时间片的平均交通速度成本高昂且不可行。因此,本文采用网格划分法对该数据进行处理。首先将研究区域划分为大小为 $r \times r$ 的网格,并计算每个网格在每个时间片 $t \in T$ 的出租车平均速度 (T 为历史时间窗口大小);然后将每个路段 $v_i \in V$ 分配到它所属的网格中;最后将网格的速度分配给目标路段作为其自身的交通流速度特征 $x_i^{spd} = \{ x_i^{spd,t} \} (1 \leq t \leq T)$ 。

除交通流速外,历史的交通事故发生情况也会对未来交通事故的发生与否有一定的关联。一个之前频繁发生交通事故

故的路段,在一定程度上会比之前较少发生交通事故的路段在未来更容易再次发生事故。

综上,交通网络的局部时序特征定义为 $X^t = [X^{spd}, X^{acd}]$,包括路段的历史流速特征 $X^{spd} \in \mathbb{R}^{N \times T \times 1}$ 和历史交通事故特征 $X^{acd} \in \mathbb{R}^{N \times T \times 1}$ 。 X^{spd} 由网格平均法进行提取, X^{acd} 通过计算每个路段 $v_i \in V$ 在每个时间片 $t \in T$ 的交通事故发生频次得到。

3.2.3 全局的外部特征

事故的发生是具有周期性的。日期特征以星期和时间点作为主要表现。图5从“天”和“小时”两个粒度展现了北京地区的交通事故发生情况。从图5(a)中可以看出,周末两天的交通事故发生情况较为相似,与工作日有着明显的差别。同时,在5个工作日之中,周一和周五更容易发生交通事故,而周二到周四较为稳定。图5(b)更细粒度地展现了北京地区每小时的交通事故发生情况,从图中可以看出,相比随日期的变化,交通事故的发生频次随小时的变化差异性更大,呈现明显的早晚高峰特性。具体地,早8点—10点和晚16点—18点的交通事故发生频次升高显著。此外,早高峰相对于晚高峰更容易发生交通事故。

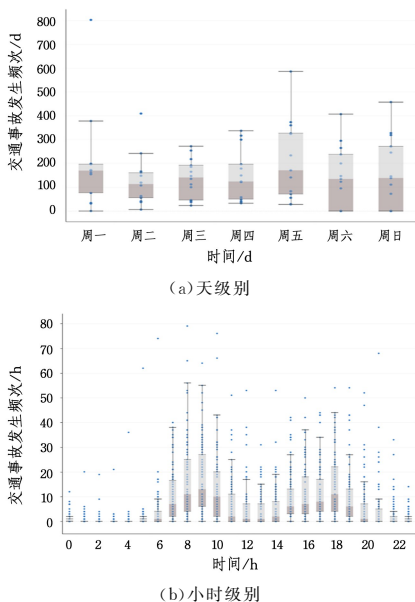


图5 北京地区交通事故发生频次图

Fig. 5 Frequency of traffic accidents in Beijing area

除此之外,气象状况通过影响驾驶员视线、状态及道路环境等主客观因素,从而影响交通事故的发生。图6展现了不同天气下交通事故的发生频率,从该图可以看出,相对于晴天,刮风、多雾等恶劣的天气情况下更容易发生交通事故。

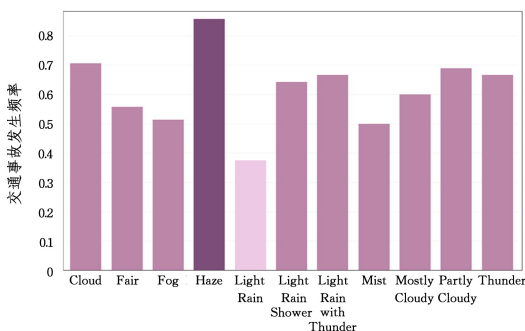


图6 不同天气下交通事故发生频率图

Fig. 6 Frequency of traffic accidents under different weathers

基于以上分析,交通网络的全局外部特征定义为 $X^e = [X^{weh}, X^{cld}]$,包括气象特征 $X^{weh} \in \mathbb{R}^{D_{weh}}$ 和日期特征 $X^{cld} \in \mathbb{R}^{D_{cld}}$ 。全局特征在同一时刻对所有路段来说是相同的。本文考虑天气类型、天气温度、露点、湿度、气压、风速、风向和室温等8个气象因素。其中天气类型和风向为分类属性,利用独热(one-hot)编码来表示,其余为数值属性。 X^{cld} 包含月、日、周、小时以及“是否为周末”5个信息。

3.3 时空拓扑图构建

3.3.1 时空拓扑图构建方法概览

本文将交通路网的建模形式化为多层次、多粒度、多视角的时空拓扑图 \mathcal{G} 的构建。每个路段的时空拓扑子图 \mathcal{G}_s 依赖于路网的原始拓扑结构 \mathcal{G}_{road} 及多元时空影响因子 $X = \{X^s, X^t, X^e\}$ 。如前文所述,路网的空间特征 X^s 描述了道路的局部空间性质;局部的时序特征 X^t 表示历史的交通状态;全局的外部特征 X^e 表示影响交通网络的整体外部因素。

时空拓扑子图 \mathcal{G}_s 的构建主要涉及到两个关键点:1)图上包含的语义信息;2)图上结点的连接方式。图上包含的语义信息可分为局部的语义信息和全局的语义信息。局部的语义信息主要通过图上结点的属性进行描述。对于时空拓扑子图 \mathcal{G}_s ,其结点属性包含静态空间属性和动态时序属性两种,分别由 X^s 和 X^t 决定。全局的语义信息无关于结点,由 X^e 决定。对于路网来说,结点之间是否有边由路段之间的地理邻接情况直接决定。但是时空拓扑图是描述交通网络的抽象图,其边不仅代表了路段与路段的连接关系,更多的是体现了路段之间复杂的关联关系。本文中, \mathcal{G}_s 的边同时考虑到“地理邻接性”和“语义邻接性”,分别由 E_{road} 和 X^t 决定。

综上, $v_i \in V$ 路段的时空拓扑子图 \mathcal{G}_s 可表示为:

$$\mathcal{G}_s = (V_i(V_{road}, X^s, X^t), E_i(E_{road}, X^t), X^e) \quad (8)$$

由于不同时间片下 X^t 会产生变化,从而引起拓扑结构的变化,因此生成的时空拓扑图具有动态性。

3.3.2 时空拓扑图的地理邻接性

当一条道路发生交通事故或者交通拥塞时,会对和它相连的其他道路的路况产生影响。因此,邻近道路的交通状态通常存在较强的相关性,其交通事故发生概率也存在较强的相关性。对于路段 v_i 来说,其时空拓扑子图构建的最直接依据是路段的连通性,即地理邻接性。根据大规模路网 G_{road} 的邻接矩阵抽取目标路段 v_i 的所有 K -hop邻居结点,并将这些结点与 v_i 的连接关系加入 G_s^i 的地理拓扑子图 G_{geo}^i 中,由此完成路段之间地理关联性的捕获:

$$\mathcal{G}_{geo}^i = \left\{ (v_a, v_b) \left| \begin{array}{l} v_a, v_b \in V_{road} \\ HOP(v_i, v_a) \leq K \\ HOP(v_i, v_b) \leq K \end{array} \right. \right\} \quad (9)$$

其中, $HOP(v_i, v_a)$ 表示 v_i 到达 v_a 需要经过的跳数, K -hop邻居节点是基于 K 最短路径定义的。如果 v_i 和 v_a 直接相连,则 $HOP(v_i, v_a) = 1$ 。 K 为可调节超参数,其决定了路段地理邻居的视野域大小。

3.3.3 时空拓扑图的语义邻接性

时空特征相似的路段在交通状态演化上往往存在一定的相似性,但这些路段在空间上不一定邻近。例如,在高峰时段,大多数处于办公楼附近的道路都会发生交通拥堵,使得这些道路在该时段的交通事故发生模式趋于相似。因此,本文

考虑引入语义邻接性,对此类距离较远的相似路段的关联关系进行建模。由于这种相似性同时涉及到时间维度和空间维度,需要选用一个语义信息丰富的综合特征进行衡量。交通流速的历史序列,在很大程度上反映了一个路段的交通历史状态以及未来演化趋势,可以从整体上描述某一路段的时空特性。针对路段 v_i , 衡量其自身的交通流速度特征 $x_i^{spd} = \{x_i^{spd,t}\} (1 \leq t \leq T)$ 与路网中其他结点的相似度,对于相似度较高的结点,在它们之间建立一条语义邻接边。

语义邻接性建模的关键在于路段之间历史流速的相似性度量。传统的距离计算方式(如欧氏距离)无法对可能存在偏移的时间序列之间的相似性进行有效建模。本文引入了动态时间规整算法(DTW),其规整机制可以很好地解决偏移性的问题,从而更加灵活地对两个时间序列之间的距离进行计算。

DTW 的核心是在相似点配对的基础上,利用动态规划算法寻找一条最优的规整路径 Ω :

$$\Omega = (\eta_1, \eta_2, \dots, \eta_p), T \leq p \leq 2T, \eta_k = (a, b) \quad (10)$$

其中, $\eta_k = (a, b)$ 指 $x_i^{spd,a}$ 和 $x_j^{spd,b}$ 的配对。如图 7 所示,上下两条实线分别表示路段 v_i 与路段 v_j 的历史流速序列,中间的虚线代表两个序列之间相似点的配对情况。




图 7 DTW 示意图

Fig. 7 Illustration of DTW

由此可以建立路段 v_i 的语义拓扑图 G_{sem} :

$$G_{sem} = \{(v_i, v_j) | w_{ij} \geq S\} \quad (11)$$

其中, S 为控制语义邻居稀疏性的超参数。 w_{ij} 为通过 DTW 算法得到的相似性权值。最后将地理拓扑图 G_{geo} 和语义拓扑图 G_{sem} 融合,求得时空拓扑图 G_{st} ,用于交通预测问题的综合求解:

$$G_{st} = G_{geo} \cup G_{sem} \quad (12)$$

图 8 给出了时空拓扑图融合的完整过程。首先在整张路网拓扑图上对所有结点的相似度进行成对度量,形成语义全连接矩阵,再利用相似性阈值将全连接的语义关系图进行稀疏化,保留与目标结点语义相似度高的其他结点作为其邻居结点的一部分;邻居结点的另一部分由目标结点在路网拓扑图上的直接或间接地理邻居结点构成(图中以 2-hop 为例)。




图 8 时空拓扑图融合示意图

Fig. 8 Diagram of spatio-temporal topological map fusion

4 基于动态时空图网络的事故风险预测

4.1 交通事故风险预测问题形式化

引起交通事故的因素有很多,包括驾驶员状态、年龄、驾驶技能等主观因素及道路交通状态、环境、天气等客观因素。交通事故在大部分情况下是由主观因素主导的,而主观因素不可实时获取。因此,对于交通事故的预测,主要利用可实时观测的客观因素进行风险预测。

交通事故风险预测指通过对交通事故相关数据的分析与建模,预估未来 $T+1$ 时间片某一特定路段 $v_i \in V$ 的交通事故发生的可能性。然而,与包括交通流速预测、出租车需求量预测等在内的传统交通预测类问题不同,交通事故作为小概率事件具有一定的离散性和稀疏性。因此,部分研究^[18-20]将交通事故预测按照常规的时序预测方式处理是不够合理的。因为建立时序预测模型的前提是假设交通事故是连续介质流,而交通事故并不符合。同时,由于构建的交通事故历史序列中包含大量的 0(即不发生交通事故),因此会导致时序预测模型更趋向于在下一时间片给出 0 的预测结果,这与预测的初衷相违背。

因此,本文将交通事故风险预测定义为一个分类问题。图 9 整体展现了本文对于交通事故风险预测的解决方案。首先如第 3 章所述,结合多源异质交通时空数据,分析与提取相关时空特征 X , 构建多粒度的时空拓扑图 G_{st} 。在此基础上,构建动态时空图网络模型,对交通事故发生的概率进行预测。

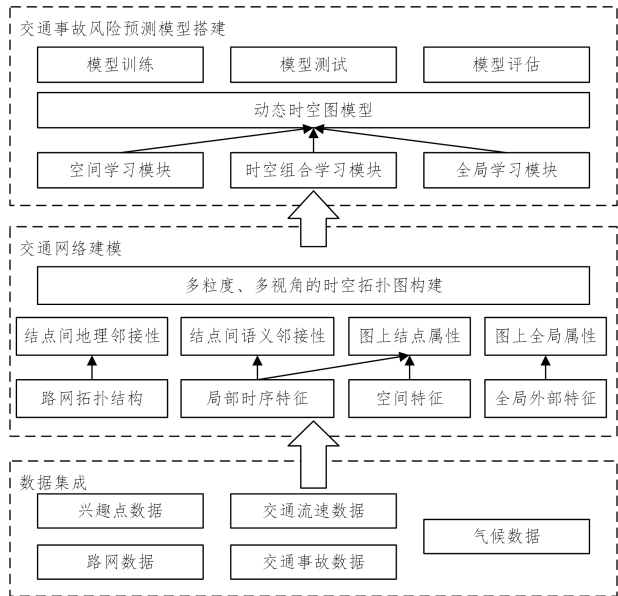


图 9 交通事故风险预测方法概览

Fig. 9 Overview of traffic accident risk prediction method

4.2 模型架构

该模型基于第 3 章为每个路段建立的时空拓扑图,分别学习图上的 3 类特征,并将其进行高维融合,用于下一时段交通事故风险的预测。

对于路网空间特征 X^s , 本文利用堆叠的空间学习单元进行处理。空间学习单元通过在图卷积神经网络的基础上引入注意力机制来对邻居结点的信息进行聚合,实现了对不同邻居的权值自适应匹配。多个空间学习单元堆叠成为一个大的空间学习模块,每一个空间学习模块之间使用残差连接,可以

缓解消失梯度问题并增强特征传递,更好地对特征进行学习和融合。这些空间学习模块以 $X^s \in \mathbb{R}^{N \times D_s}$ 为输入,以 $X^{os} \in \mathbb{R}^{N \times D_{os}}$ 为输出,其中 D_{os} 表示空间学习层的输出维度。

对于局部时序特征 X^t ,由于其兼有空间性和时间性,本文利用时空组合模块进行处理。每个时空组合模块由堆叠的空间学习单元和一个时间学习单元构成,时空组合模块之间同样使用残差连接。这些时空组合模块以 $X^t \in \mathbb{R}^{N \times D_t \times T}$ 为输入,以 $X^{ot} \in \mathbb{R}^{N \times D_{ot} \times T}$ 为输出,其中 D_{ot} 表示时空组合模块的输出维度。最后, X^{ot} 需要经过一个池化单元,对输出的时序特征进行进一步聚合,以得到更为紧凑的时序表征。

对于全局外部特征 X^e ,由于提取的高维外部特征中可能存在一些噪声,本文利用几个堆叠的全连接单元对 X^e 进行降维,学习到更有意义的全局低维表征 $X^{oe} \in \mathbb{R}^{D_{oe}}$,其中 D_{oe} 表示全局外部特征输出的维度。

最后,将 X_i^{os} , X_i^{ot} 及 X_i^{oe} 拼接成一个更加紧凑的表征,并输入全连接单元,得到模型的输出结果。

4.3 核心组件设计

4.3.1 堆叠的空间学习单元

模型的空间学习单元旨在捕获交通网络的空间关联性,并据此对邻居结点进行聚合,得到目标结点的空间融合表征。经典的 GCN 方法中,各个邻居结点被等同地看待,然而在交通事故风险预测的场景中,不同的邻居路段对目标路段的预测起着不同的作用,即不同的邻居结点的重要性是有差异的。

一个空间学习单元由一个基于多头注意力机制的空间图网络层、一个批归一化 (Batch Normalization, BN) 层和一个 ReLU 激活层构成。其中,空间图网络层为空间学习单元的核心,通过多头注意力机制,它可以完成对结点之间空间关联度的自适应学习。堆叠的空间学习单元之间采用残差连接,残差模块除了可以缓解梯度衰减问题,还可以对底层模块的特征提取结果进行一定程度的补偿,得到更加紧凑、丰富的融合表征。

4.3.2 基于多头注意力的空间图网络层

对于空间关系的建模,本文采用了基于多头注意力的空间图网络层,在 GCN 的基础上引入注意力机制,以实现对不同邻居权值的自适应匹配,从而提高模型的准确性。注意力机制可以根据先验知识,如交通连通性、语义相似性等,在构建的邻接矩阵的基础上自适应地学习到其他结点对目标结点的贡献度,并由此为每个邻居分配不同的权重,使其能够更精准地刻画路段与路段之间真实的依赖关系。

对于路段 v_i 来说,一个直接基于 GCN 的空间学习单元在构建的邻接矩阵的基础上,通过产生邻居结点特征的归一化来实现邻居结点的特征融合。为了更好地融合不同贡献度的邻居结点的特征,同时考虑到自注意力 (self-attention) 的学习过程不稳定^[21],本文最终选择采用多头注意力 (multi-head attention) 代替 GCN 中静态的归一化卷积运算。

4.3.3 基于扩张卷积的时间学习单元

除了不同结点之间的空间关联性之外,结点本身的时序依赖性也很重要。尽管基于循环神经网络的模型被广泛应用于时间序列的分析与建模,但其仍然存在包括迭代耗时、梯度

不稳定、对动态变化的响应延迟等一些固有的缺点。

对于时序依赖性的学习,本文尝试采用一种基于因果卷积的时间学习单元,其将所有的输入数据以时间维度为轴看作一维向量,对所有的输入向量进行卷积操作。因果卷积在某时刻的预测值仅仅和历史时刻的值相关,与预测的未来值无关。由于没有递归连接,基于因果卷积的模型训练速度比基于循环神经网络的模型快得多。

对于时序依赖性的捕获,不仅需要考虑到短期内相邻的时间数据的影响,也要考虑到长期的时间周期性的影响。然而,对于因果卷积来说,如果要提取很久以前的信息,就需要很多层或者很大的滤波器来增加卷积的感受野,但卷积层数的增加常常会引起梯度消失、训练复杂度过高等问题。为了解决这个问题,本文在因果卷积的基础上引入了扩张卷积。扩张卷积通过在标准的卷积核中加入空洞,来增加卷积核的提取范围。较小的扩张率往往关注的是短距离的特征,而较大的扩张率往往关注的是长距离的特征。

4.4 实验与分析

4.4.1 数据源说明

本节对实验所用到的数据源进行说明,包括路网数据、交通事故数据、POI 数据、出租车 GPS 轨迹打点数据及气候观测数据。

路网数据集包含了北京市道路网络的基本信息,例如路段名称、路段位置(经纬度)、路段的交叉点等,共有 109973 条数据。路网是其他各种交通数据的载体,通过路网数据集,可以对北京市交通网络进行细粒度的观测及建模。

交通事故数据集包含了北京地区 2018-08-01 到 2018-10-31 之间发生的交通事故的基本信息,例如事故发生位置(经纬度)、事故时间等,共有 14874 条数据。根据事故发生位置可以将事故与发生事故的路段进行匹配。交通事故数据集在本文中有两个用途,一个是作为样本真值,另一个是作为局部的时序特征。

POI 数据集是地图上特定功能的点集合。每个 POI 都对应了现实生活中的一个功能实体,包含该实体的位置、类别以及个性化属性等信息。本文采用北京地区的 POI 数据集进行实验,数据集包含 20 个种类的 362028 个 POI。

出租车轨迹数据集主要记录了出租车的打点信息。出租车的车载 GPS 设备会按照固定的频率进行打点,并记录每次打点的时间戳、地理位置、行驶方向、行驶速度以及载客情况等。本文采用北京市 2018-08-01 到 2018-10-31 之间收集的出租车 GPS 轨迹数据进行实验,该数据集的日平均数据量约为 54000000。

气候数据集是从世界气候公开网站 wunderground¹⁾ 上爬取生成的,该网站记录了世界各地的气候观测数据。本文采用的是北京市气候观测站 2018-08-01 到 2018-10-31 之间的气候观测数据,每条数据的观测间隔为 1h,共 2208 条数据。

4.4.2 实验设置

本模型利用 PyTorch 开源机器学习框架来实现,在北京地区 2018-08-01 到 2018-10-31 时间范围内的多源异质交通数据集上进行大规模实验。

¹⁾ <https://www.wunderground.com/>

模型中所涉及的超参数的设置如下:计算交通流平均速度所划定的网格大小 r 为 222 m,约等于 0.002 经度或纬度;表示地理邻接性的 K -hop 邻居中的 K 为 5,该值是通过网格搜索得到的;控制语义邻居稀疏性的阈值 S 为 0.5,该值同样是通过网格搜索得到的。

实验的具体设置如下:按 7:1:2 的比例划分训练集、验证集和测试集;使用 Z-score 对输入数据进行归一化;训练的 epoch 为 64;初始的学习率设置为 1×10^{-3} ,从第 20 个 epoch 开始,每 10 个 epoch 减少为原来的 1/10;优化器为 Adam,损失函数为带 L2 正则项的交叉熵。

4.4.3 评价指标

本文采用皮尔逊相关系数 PCC 、精确率 $Precision$ 、召回率 $Recall$ 、均衡平均数 $F1-Score$ 和 ROC 曲线下面积 AUC 5 项指标对本文方法进行全面的评估。

PCC 用于衡量两个序列之间的相关性,其范围为 $[-1, 1]$ 。 PCC 的绝对值越大,代表两个序列越相关。当 PCC 大于 0 时,表示两个序列呈正相关;当 PCC 小于 0 时,表示两个序列呈负相关。 PCC 的计算式如下:

$$PCC = \frac{\sum_{i=1}^{\zeta} (\hat{y}_i^{T+1} - \bar{\hat{y}}^{T+1})(y_i^{T+1} - \bar{y}^{T+1})}{\sqrt{\sum_{i=1}^{\zeta} (\hat{y}_i^{T+1} - \bar{\hat{y}}^{T+1})^2} \sqrt{\sum_{i=1}^{\zeta} (y_i^{T+1} - \bar{y}^{T+1})^2}} \quad (13)$$

其中, \hat{y}_i^{T+1} 和 y_i^{T+1} 分别表示第 i 个测试样本在 $T+1$ 时间步的预测风险值和真实值; $\bar{\hat{y}}^{T+1}$ 和 \bar{y}^{T+1} 分别表示所有测试样本的预测风险平均值和真实平均值; ζ 表示测试样本的总数。

$Precision$ 和 $Recall$ 是二分类问题常用的评价指标。 $Precision$ 从预测结果的角度出发,计算预测为正例的样本中有多少为真; $Recall$ 从原始样本的角度出发,计算样本中的正例有多少被预测成功。 $F1-Score$ 是 $Precision$ 和 $Recall$ 的加权调和平均,综合了两者的结果。它们的计算式分别如下:

$$Precision = \frac{TP}{TP + FP} \quad (14)$$

$$Recall = \frac{TP}{TP + FN} \quad (15)$$

$$F1-Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (16)$$

其中, TP 表示真正例的测试样本数目, FN 表示假负例的测试样本数目, FP 表示假正例的测试样本数目。

此外,在现实场景下,交通事故正例和负例的个数并不是均衡的。由于事故是小概率事件,负样本的数目要远大于正样本, $Precision$ 和 $Recall$ 易受数据分布的影响,导致不客观。而 AUC 衡量的是分类器对于正负样本的分类能力,其对于分类器优劣性的评价不受样本平衡性的影响,适用于本文的应用场景。 AUC 的计算式如下:

$$AUC = \frac{\sum_{i \in \text{positive}(\zeta)} rank_i - \frac{M \times (M+1)}{2}}{M \times N} \quad (17)$$

其中, M 表示所有测试样本中正样本的个数, N 表示所有测试样本中负样本的个数,且 $\zeta = M + N$; $rank_i$ 表示第 i 个测试样本的排序序号,即针对每个样本最终输出的概率得分从小到大的排序,第 i 个测试样本排在 $rank_i$ 的位置; $\sum_{i \in \text{positive}(\zeta)} rank_i$ 表示所有正样本的排序序号之和。

4.4.4 对比模型

为了验证方法的有效性和先进性,本文提出的动态时空图网络模型将与现有的交通事故风险预测方法进行比较,主要包括几种常用的机器学习(LR, SVM, DT, XGBoost)及近几年该领域先进的深度学习模型(SDAE, TARPML, DSTGCN),对比方法的原理及核心思想如下。

LR^[22]:基于统计的机器学习模型。使用一个逻辑函数(Logistic Function)对二元因变量进行建模。

SVM^[23]:基于几何的机器学习模型。通过在特征空间中寻找间隔最大的分离超平面使数据得到高效的二分类。

DT^[24]:经典的机器学习模型。决策树是一种决策支持工具,它使用树状的决策结构,通过条件控制语句帮助确定最有可能实现目标的策略。

XGBoost^[25]:工业界最受推崇的机器学习分类模型。XGBoost 是 GBDT 算法的工程化实现,其核心为分布式和并行化,可以很好地解决工业界大规模数据的问题。

SDAE^[1]:先进的深度学习模型。SDAE 模型通过堆叠去噪自编码器形成深度网络学习输入数据的层次化特征表征,然后将学习到的特征输入逻辑回归层,对交通事故风险进行预测。

TARPML^[3]:先进的深度学习模型。TARPML 模型在获取到交通事故的动态影响因素及静态影响因素后,采用全连接网络处理静态信息,采用 LSTM 单元捕获动态信息。

DSTGCN^[7]:先进的深度学习模型。DSTGCN 模型在对交通事故的空间影响因素和时序影响因素进行充分分析后,利用 GCN 学习空间关联性,利用 CNN 学习时序依赖性。

4.4.5 对比实验分析

本文在测试集上对这些常用的交通事故风险预测模型以及动态图时空网络模型分别进行测试,并采用 5 种评价指标 PCC , $Precision$, $Recall$, $F1-Score$ 和 AUC 进行评价。对比实验的结果如表 2 所列。从表中可以看出,本文提出的动态时空图网络模型在 5 种评价指标下的表现均为最优。

表 2 对比实验结果

Table 2 Results of comparative experiment

	PCC	$Precision$	$Recall$	$F1-Score$	AUC
DT	0.681	0.796	0.873	0.833	0.839
LR	0.564	0.738	0.863	0.795	0.778
SVM	0.598	0.747	0.888	0.812	0.794
XGBoost	0.733	0.804	0.876	0.838	0.850
SdAE	0.684	0.791	0.892	0.838	0.819
TARPML	0.712	0.802	0.894	0.846	0.837
DSTGCN	0.745	0.821	0.897	0.857	0.851
Our Model	0.748	0.825	0.899	0.860	0.854

4.4.6 消融实验分析

为了进一步验证各个组件在本模型中的效果,本文在原始模型的基础上做了一些变体,并将这些变体模型与原始的完整模型进行对比。本文主要从 3 个角度设置消融实验:1)多元特征引入的有效性;2)多组件联合预测的优越性;3)多视角构建拓扑图的重要性。实验的具体设置如下:

1)对于多元特征引入的有效性验证,本文设计了不考虑空间特征的 Model-s、不考虑时间特征的 Model-t 以及不考虑外部特征的 Model-e 3 个模型,与考虑所有特征的原始模型

进行特征消融实验的对比。

2)对于多组件联合预测的优越性验证,本文设计了不考虑空间学习组件的 Model-S,不考虑时序学习组件的 Model-T 以及不考虑外部学习组件的 Model-E 3 个模型,与使用所有组件的原始模型进行组件消融实验的对比。

3)对于多视角构建拓扑子图的重要性验证,本文设计了在构建拓扑子图时,不考虑物理邻接性的 Model-Geo 和不考虑语义邻接性的 Model-Sem 两个模型,与考虑两种邻接性的原始模型进行拓扑子图构建消融实验的对比。

多特征引入的有效性验证实验结果如表 3 所列。表 3 分别对比了 5 种评价指标体系下,Model-s, Model-t, Model-e 这 3 个特征消融模型和引入全部特征的原始模型的性能表现。从表中可以看出,特征的引入对模型的预测性能有十分积极的促进作用。

表 3 特征消融实验结果

Table 3 Results of feature ablation study

	<i>PCC</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>AUC</i>
Model-s	0.712	0.801	0.878	0.837	0.839
Model-t	0.722	0.795	0.889	0.839	0.842
Model-e	0.709	0.793	0.884	0.836	0.837
Our Model	0.748	0.825	0.899	0.860	0.854

多组件联合预测的优越性验证实验结果如表 4 所列。表 4 分别对比了 5 种评价指标体系下,Model-S, Model-T, Model-E 这 3 个组件消融模型和多组件联合预测的原始模型的性能表现。从表中可以看出,多组件联合预测的方式在 5 个评价指标上均表现出了优越性。

表 4 组件消融实验结果

Table 4 Results of module ablation study

	<i>PCC</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>AUC</i>
Model-S	0.705	0.784	0.88	0.829	0.816
Model-T	0.732	0.811	0.887	0.847	0.831
Model-E	0.719	0.807	0.893	0.848	0.837
Our Model	0.748	0.825	0.899	0.860	0.854

多视角构建拓扑子图的重要性验证实验结果如表 5 所列。表 5 分别对比了 5 种评价指标体系下,Model-Geo 和 Model-Sem 两个拓扑图构建消融模型和包含完整拓扑图构建方式的原始模型的性能表现。从表中可以看出,对于每一个评价指标,包含完整拓扑图构建方式的原始模型的性能均优于其他两种消融模型。多视角构建拓扑子图的重要性验证实验结果充分说明了第 3 章提出的交通网络构建方法的有效性。

表 5 拓扑图构建消融实验结果

Table 5 Results of topology map construction ablation study

	<i>PCC</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>AUC</i>
Model-Geo	0.695	0.798	0.889	0.841	0.837
Model-Sem	0.732	0.815	0.894	0.853	0.845
Our Model	0.748	0.825	0.899	0.860	0.854

结束语 本文在分析了多元时空影响因子对交通事故产生的影响后,提取了包括路网空间特征、局部时序特征、全局外部特征在内的 3 类时空特征,并以此为基础构造了以路段为结点,路段之间的关联关系为边的多粒度、多视角时空拓扑图,实现了交通网络中时空关联关系的精准建模。本文设计

了基于动态图时空网络的交通事故风险预测模型,通过将多头注意力机制引入图神经网络中,实现空间关联关系的自适应学习,通过基于一维扩张卷积的时间学习单元实现时序特征的长短时依赖性捕获,最后结合全局特征学习组件,实现了时空关系的联合学习,最终完成了城市交通事故的准确预测。

参考文献

- [1] CHEN Q, SONG X, YAMADA H, et al. Learning deep representation from big and heterogeneous data for traffic accident inference[C] // AAAI Conference on Artificial Intelligence, 2016:338-344.
- [2] CHEN C, FAN X, ZHENG C, et al. SDCAE: stack denoising convolutional autoencoder model for accident risk prediction via traffic big data[C] // International Conference on Advanced Cloud and Big Data, 2018:328-333.
- [3] REN H. A deep learning approach to the citywide traffic accident risk prediction[C] // 2018 21st International Conference on Intelligent Transportation Systems (ITSC). Maui, United States, 2018:3346-3351.
- [4] BAO J, LIU P, UKKUSURI S V. A spatiotemporal deep learning approach for citywide shortterm crash risk prediction with multi-source data[J]. Accident Analysis & Prevention, 2019, 122:239-254.
- [5] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model[J]. IEEE Transactions on Neural Networks, 2008, 20(1):61-80.
- [6] ZHOU Z, WANG Y, XIE X, et al. RiskOracle: a minutelevel citywide traffic accident forecasting framework[C] // AAAI Conference on Artificial Intelligence, 2020.
- [7] YU L, DU B, HU X, et al. Deep spatio-temporal graph convolutional network for traffic accident prediction[J]. Neurocomputing, 2021, 423:135-147.
- [8] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks[J]. arXiv:1609.02907, 2016.
- [9] MIKOLOV T, KARAFI Á T M, BURGET L, et al. Recurrent neural network based language model[C] // Interspeech, 2010: 1045-1048.
- [10] BAI S, KOLTER J Z, KOLTUN V. An empirical evaluation of generic convolutional and recurrent networks for sequence modeling[J]. arXiv:1803.01271, 2018.
- [11] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. Advances in Neural Information Processing Systems, 2017, 30.
- [12] HOCHREITER S, SCHMIDHUBER J. Long short-term memory[J]. Neural Computation, 1997, 9(8):1735-1780.
- [13] OORD A, DIELEMAN S, ZEN H, et al. Wavenet: A generative model for raw audio[J]. arXiv:1609.03499, 2016.
- [14] BOROVYKH A, BOHTE S, OOSTERLEEC W. Conditional time series forecasting with convolutional neural networks[J]. arXiv:1703.04691, 2017.
- [15] DEVLIN J, CHANG M W, LEE K, et al. Bert: Pre-training of deep bidirectional transformers for language understanding[J]. arXiv:1810.04805, 2018.
- [16] LI Y, YU R, SHAHABI C, et al. Diffusion convolutional recur-

- rent neural network: Data-driven traffic forecasting[J]. arXiv: 1707.01926, 2017.
- [17] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[J]. arXiv: 1709.04875, 2017.
- [18] CALIENDO C, GUIDA M, PARISI A. A crash-prediction model for multilane roads[J]. *Accident Analysis & Prevention*, 2007, 39(4): 657-670.
- [19] BERGEL-HAYAT R, DEBBARH M, ANTONIOU C, et al. Explaining the road accident risk: Weather effects[J]. *Accident Analysis & Prevention*, 2013, 60: 456-465.
- [20] EISENBERG D. The mixed effects of precipitation on traffic crashes[J]. *Accident Analysis & Prevention*, 2004, 36(4): 637-647.
- [21] VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks[J]. arXiv: 1710.10903, 2017.
- [22] WALKER S H, DUNCAN D B. Estimation of the probability of an event as a function of several independent variables[J]. *Biometrika*, 1967, 54(1/2): 167-179.
- [23] CORTES C, VAPNIK V. Support-vector networks[J]. *Machine Learning*, 1995, 20(3): 273-297.
- [24] QUINLAN J R. Induction of decision trees [J]. *Machine Learning*, 1986, 1(1): 81-106.
- [25] CHEN T, GUESTRIN C. Xgboost: A scalable tree boosting system[C] // *Proceedings of the 22nd ACM Sigkdd International Conference on Knowledge Discovery and Data Mining*. 2016: 785-794.



DONG Wanqing, born in 1989, master, senior engineer. Her main research interests include intelligent transportation and big data.



ZHANG Xiaoliang, born in 1983, Ph.D. Her main research interests include intelligent transportation technology, transportation big data mining and applications.