

基于图时空模式学习网络的路网实时 交通事件自动检测方法

柴树山¹, 周志强¹, 李海涛², 徐灵旻¹

(1. 公安部道路交通安全研究中心, 北京 100062; 2. 吉林大学 交通学院, 长春 130022)

摘要:为提升路网交通异常事件的检测精度并降低误报率,提出了一种基于图时空模式学习网络(GSTPL)的路网实时交通事件自动检测方法。将路网交通事件检测问题抽象为图结构异常检测任务;设计了交通时空融合图表达方法,筛选具有强时空依赖性与模式规律性的图节点信息作为网络输入;引入图时空卷积与图嵌入层对时空模式特征进行提取,构造多组件输入与融合预测结构对不同时间维的交通模式规律进行融合;设计了异常状态评估方法,通过对模型预测误差分布的学习,结合当前检测数据给出最终的异常事件判定结果。采用 2 个真实交通路网数据进行算法验证,实验结果表明,提出的 GSTPL 交通事件检测方法具有较高的检测精度、较低的误报率与更短的平均检测时间;在可接受误检率为 5% 与 10% 时,对异常交通事件的检测率可分别达到 91% 与 96% 以上。

关键词:交通运输系统工程;事件自动检测;图神经网络;模式学习;异常评估

中图分类号:U458 **文献标志码:**A **文章编号:**1671-5497(2025)07-2145-17

DOI:10.13229/j.cnki.jdxbgxb.20230875

Real-time road network traffic anomaly incident detection based on graph spatial-temporal pattern learning network

CHAI Shu-shan¹, ZHOU Zhi-qiang¹, LI Hai-tao², XU Jiong-yang¹

(1. Research Institute for Road Safety of the Ministry of Public Security, Beijing 100062, China; 2. College of Transportation, Jilin University, Changchun 130022, China)

Abstract: In order to improve the detection accuracy of road network traffic incidents and reduce the false alarm rate, a real-time automatic detection method of road network traffic incidents based on Graph Spatial-Temporal Pattern Learning Network (GSTPL) is proposed. Firstly, the traffic incident detection problem in the road network is abstracted into a graph structure anomaly detection task; a traffic spatial-temporal fusion graph representation method is designed to filter the road network graph node with strong spatial-temporal dependence and same pattern regularity as the input. Then, the graph spatial-temporal convolution and graph embedding layer are introduced to extract the spatial-temporal pattern features, and

收稿日期: 2023-08-17.

基金项目: 中央级公益性科研院所基本科研业务费专项资金项目(10111119041000009001230402); 宁夏回族自治区重点研发计划“揭榜挂帅”项目(2023BBF01004).

作者简介: 柴树山(1990-), 男, 助理研究员, 博士. 研究方向: 交通安全与风险评估. E-mail: sschai@foxmail.com

通信作者: 李海涛(1994-), 男, 在站博士后. 研究方向: 智能交通控制. E-mail: lihait@jlu.edu.cn

the multi-component input and fusion prediction structure are constructed to fuse traffic pattern rules in different time dimensions, and realize stable forecasts of graph node parameters. An abnormal state evaluation method is designed, and the final incident detection result is given by learning of the prediction error distribution and combining with the current detection data. Two real road networks datasets were used for validation experiments, and the proposed algorithm was compared with several typical traffic incident detection algorithms. The comparison results show that the proposed GSTPL has higher detection accuracy, lower false alarm rate and shorter average detection time. When the acceptable false positive rate is 5% and 10%, the detection rate of traffic incidents can reach more than 91% and 96% respectively.

Key words: engineering of communications and transportation system; automatic incident detection; graph neural network; pattern learning; abnormal evaluation

0 引言

随着路网交通载荷日益增加,异常交通事件成为加剧交通拥堵、影响道路安全的主要致因之一。异常事件通常指发生时间、地点无规律,且造成通行能力下降的随机偶发性事件,如交通事故、车辆故障、货物抛洒等,其影响会沿着车流在路网内蔓延,极易造成大范围的交通瘫痪。因此,交通事件自动检测(Automatic incident detection, AID)作为智能交通系统的重要环节,通过对异常事件的有效检测与及时预警,可缩短事故处置时间,促进排队车辆及时消散,避免二次事故发生,对提升道路安全与运行效率起着至关重要的作用^[1]。根据检测原理,AID可分为直接检测方法与间接检测方法:直接检测方法是通过对图像处理技术判断局部检测区域内是否存在异常事件,但由于其设备成本高且要求复杂,难以满足大范围的事件检测需求;间接检测方法则通过异常事件发生后交通流参数的变化判定被测道路交通状态,是实现路网实时交通事件自动检测的首选方式^[2]。

为了提升交通异常事件检测精度,各类统计方法与数据驱动模型被应用于AID间接检测算法设计中,根据其计算原理主要分为3类:①基于特征参数阈值的AID算法:选取具有异常区分能力的交通流参数特征,根据历史经验标定相应阈值,当特征变量检测值超过相应阈值时判定异常事件存在,典型代表有加州算法^[3]、动态阈值法^[4,5]等,但该类方法难以处理交通流时序动态特性,导致阈值设置复杂,算法移植性差,同时事件误报率较高;②基于特征统计分类的AID算法:以交通参数历史数据作为输入,通过参数统计或

训练分类器方式得到有无异常事件发生条件下参数先验分布,结合当前交通状态参数判定其所属类别,典型代表有贝叶斯概率分类^[6]、概率神经网络^[7,8]、随机森林^[1,9,10]和支持向量机^[11,12]等,但由于路网交通状态复杂多变,导致事故状态与正常状态之间的参数分类边界存在重叠,算法难以适用于不同交通状态,误报率较高;③基于参数预测回归的AID算法:将时序交通参数作为预测模型输入,对未来状态进行规律预测并比较实测值与预测值的差异,若检测参数偏离规律预测结果,则判定异常事件发生,典型代表有卡尔曼滤波^[13]、小波分析^[14]和神经网络预测^[15,16]等,该类方法能够捕捉交通流状态动态规律,并可对交通参数进行实时预测和异常评估,可满足异常事件检测的实时性需求^[2]。

综合分析可知,基于参数预测回归的AID算法是目前交通事件实时检测的主流趋势。区别于常规参数预测任务,交通事件检测要求算法不仅在正常状态下具有较好的预测性能,而且在异常事件发生时,依然能保持正常交通模式规律进行稳定预测,为异常评估提供对比标准^[17]。因此,提取交通流模式规律是基于预测回归的AID算法的核心。在实际路网环境中,各节点处的交通流时空运行规律复杂多样,如何从海量交通流数据中挖掘有效的交通流时空模式规律是实现路网交通事件检测任务的关键。

近年来,图神经网络凭借与实际交通路网结构适配性及其特征提取与表达能力,在路网交通流参数预测方面取得了突破性进展^[18-20],部分学者也开展了路网异常评估方面的尝试^[21-23]。Deng等^[22]设计了时空图卷积对抗网络(Spatio-temporal graph convolutional adversarial network,

STGAN)进行路网异常事件检测,通过构造时空图生成器学习交通流时空特征并预测参数正常模式趋势,进而构造一个时空图鉴别器用于判断预测结果与误差属于正常还是异常范畴。相关实验结果^[21-23]均验证了图神经网络模型能够更好地利用交通数据时空相关性,理论上可以获取更高的交通事件判断精度。

将图结构预测模型扩展到路网事件检测问题中依然存在如下问题:①现有图结构网络多采用固定物理连接结构^[19-22],该结构将导致路网中具有相同交通模式的节点数据缺乏有效利用,而更多的增益信息有助于交通模式规律学习效果的提升^[18];②基于预测回归的AID算法注重交通流模式规律的提取,如何通过结构设计充分利用交通流显示规律特性(如日周期与周周期特性)仍有待解决;③路网环境复杂性与车流运行不确定性导致交通流参数掺杂随机波动成分,如何区分并降低参数随机波动对交通异常事件评估过程的干扰,以降低异常事件误报率,也是亟需攻克的难题。

为解决上述问题并提升交通异常事件的判别精度,本文设计了一种基于图时空模式学习网络(Graph spatial temporal pattern learning network, GSTPL)的路网实时交通事件自动检测方法。首先,将路网环境下交通事件检测问题抽象为图结构异常检测任务;其次,构建新的时空融合图表达方法对具有强时空依赖性与模式规律性的图节点进行筛选,作为GSTPL网络输入;再次,对应设计了交通模式学习与预测模块和异常评估模块,实现路网交通流正常模式学习与预测过程以及基于预测结果的异常评估过程;最后,通过多阶段网络训练实现对路网异常交通事件的实时自检。采用2个真实路网交通数据集对本文方法进行验证,并与典型AID方法进行效能对比。

1 基于图结构的路网异常事件检测问题定义

异常交通事件通常产生于路段节点,其影响会沿着车流在路网内进行传播,导致其上下游交通流状态与参数产生不同程度的变化。因此,通过2个相邻断面检测器的参数异常波动可间接推断交通事件在路网内的发生位置^[2,21]。但异常事件对交通参数影响程度不仅与上下游断面交通流运行有关,更与其周围道路拓扑结构及局部路网状态有关。因此,本文将路网内任意2个相邻检

测断面定义为关键节点A与B,将关键节点及一定空间范围的路网抽象为无向图形式 $G=(V, E, A_0)$,其中: V 为节点集, $|V|=N$ 为节点个数; E 为边集; $A \in \mathbb{R}^{N \times N}$ 定义为图 G 的邻接矩阵,表示节点间关联程度。在交通路网图 G 中,每一个节点检测器在每个时间戳都会反馈 F 个交通流参数数据,即产生一个长度为 F 的特征向量;令 $x_t^{i,c}$ 表示节点 i 在时刻 t 的交通特征 c ,且 $c \in (1, 2, \dots, F)$ 。 $X_t=(x_t^1, x_t^2, \dots, x_t^N)^T \in \mathbb{R}^{N \times F}$ 表示在时刻 t 图 G 全部节点的所有特征。

路网交通异常事件判别过程可分为2个阶段:①在 t 时刻,给定路网图 G 所有节点的历史 n 时段内的交通参数信息,从中学习其稳定规律信息并对关键节点A、B的下一时刻参数进行预测,该过程可抽象为 $[\hat{y}_{t+1}^A, \hat{y}_{t+1}^B]=f(X_{t-n}, \dots, X_t; G)$,其中 $\hat{y}_{t+1}^A, \hat{y}_{t+1}^B \in \mathbb{R}^F$;②在 $t+1$ 时刻,由检测器反馈关键节点A、B的实际参数 x_{t+1}^A, x_{t+1}^B ,通过异常评估过程 E 计算模式预测值与实测值之间的差距,即 $Q=E((\hat{y}_{t+1}^A, x_{t+1}^A), (\hat{y}_{t+1}^B, x_{t+1}^B))$,其中 Q 表示发生异常交通事件的可能性。当其超过一定阈值,即 $Q \geq 1 - \epsilon$ 时,则判定关键节点A和B间存在异常交通事件。

2 基于GSTPL的交通异常事件检测算法

为了提高不同交通模式下异常事件检测准确率并降低误报率,本文提出了一种基于GSTPL的实时交通异常事件检测算法,其框架如图1所示。整体算法主要包含时空融合图构建、交通模式学习与预测、异常评估3个模块:①在时空融合图构建模块中,为了更充分利用交通流在路网中的时空依赖关系,构建了新的交通时空融合图表达方法;通过空间邻接矩阵与时间相似矩阵融合的方式,捕获图节点的时空依赖关系;在筛选具有强时空依赖性与模式规律性图节点的同时,剔除无关图节点的冗余信息,使整体网络模型轻量化;②在交通模式学习与预测模块,为了减少不相关历史信息的处理开销,针对交通流自身规律特性,设计了3个组件用于描述交通流参数的近期特性、日周期特性及周周期特性;引入空间维图卷积与时间维1D卷积对各组件进行相应模式规律的独立学习与特征提取;将三者捕获的规律特征统一输入多组件融合预测层,调整各模式特征权重

并对关键节点参数进行联合预测,获得关键节点的最终规律预测结果;③在异常评估模块中,为了减少交通流参数随机波动性对预测与事件判别过程的干扰,设计了异常状态评估算法,利用长范围预测误差分布与短范围预测误差分布间的 JS (Jensen-Shannon)散度作为异常状态可能性,并作为衡量是否存在异常事件的判别标准。此外,异常状态可能性会作为额外输入参数与预测部分的多组件融合预测层进行联合设计,调整各组件在不同交通状态与事件发生时的权重参数,通过二者迭代训练,最终交通模式学习与预测模块既具有正常交通状态下的精确预测能力以及异常事件发生时的规律保持能力,又能提升异常评估模块的事件辨识能力。

2.1 时空融合图构建模块

在现有交通预测与事件判别研究中,基于图结构的方法大多采用固定物理连接矩阵对交通网络进行图表达,该方式缺少对相同交通模式规律节点信息的有效利用,无法在数据层面有效表达图节点间的时空依赖性。为此,本文设计了基于数据驱动方式的交通时空融合图构建方法,通过空间邻接矩阵与时间相似矩阵的融合,筛选图 G 每个节点的空间相邻节点以及具有相同交通模式的节点信息,剔除无关节点的冗余信息,使整体深度学习模型轻量化。

空间邻接矩阵构建:将 $A_s \in \mathbb{R}^{N \times N}$ 定义为路网图 G 的归一化后的物理邻接矩阵,其中 $A_s(i, j)$ 反映 2 个检测器节点是否直接相连,若在实际路网中存在物理连接关系则为 1,否则为 0。

时间相似矩阵构建:在交通模式学习预测与异常评估任务中,除空间相邻节点外,具有相似交通模式的检测器数据同样有利用价值。因此,构造时间相似矩阵 $A_t \in \mathbb{R}^{N \times N}$ 用于筛选与当前检测节点具有相同交通模式的其他检测节点,并对其赋予更高的权重系数。引入动态时间规整(Dynamic time warping, DTW)^[24]衡量 2 个检测节点的时间模式相似性。给定路网图 G 中任意两检测器节点的交通参数时间序列 $X^a = (x_1^a, x_2^a, \dots, x_m^a)$ 与 $X^b = (x_1^b, x_2^b, \dots, x_m^b)$,其中 m 表示时间序列长度。通过欧氏距离计算 2 个序列每两点之间的距离 $M_{i,j} = |x_i^a - x_j^b|$,构造时序距离矩阵 $M_{m \times m}$,则两点间的累计时序距离可通过下式进行迭代计算:

$$M_c(i, j) = M_{i,j} + \min \{ M_c(i, j - 1), M_c(i - 1, j), M_c(i - 1, j - 1) \} \quad (1)$$

通过 i 与 j 迭代获得完整累计时序距离矩阵 M_c ,则序列 X^a 与 X^b 的时间相似度可表示为: $\text{dist}(X^a, X^b) = M_c(m, m)^{1/2}$,代表 2 个图节点时间序列的最佳对齐距离。DTW 的计算过程可抽象为对图 2 中距离最短路径的动态规划求解,常规 DTW 的计算复杂度为 $O(n^2)$ 。在实际应用中,由

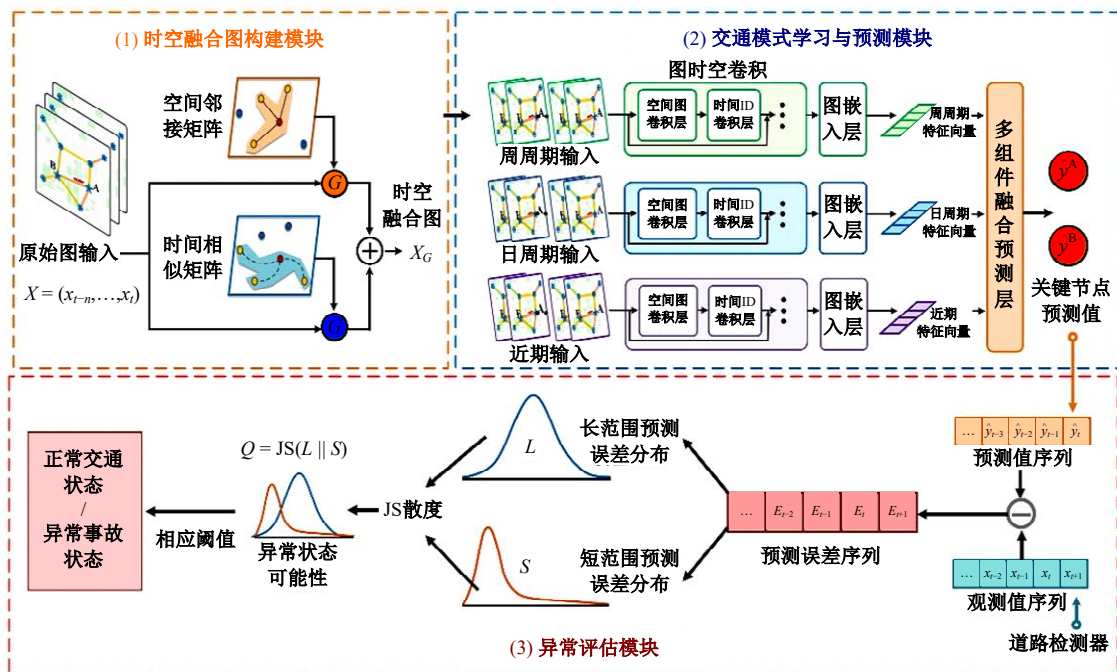


图 1 基于 GSTPL 的交通异常事件检测网络框架

Fig. 1 Traffic incident detection network framework by GSTPL

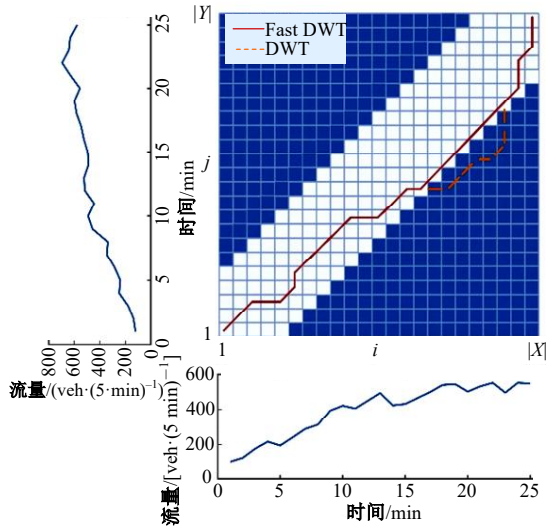


图 2 基于 DTW 与 Fast-DTW 的时间序列相似性度量

Fig. 2 Two time series similarity measure by DTW and Fast-DTW algorithm

于交通流时间序列较长且路网图 G 的节点数众多,致使常规 DTW 计算复杂度过高,动态求解时间较长,无法满足实时性需求。本文通过搜索空间限制方式加速 DTW 计算,称为 Fast-DTW (见图 2),通过搜索长度 T 限定距离最短路径 $M_c(m, m)$ 的搜索空间:

$$\omega_k = (i, j), |i - j| \leq T \quad (2)$$

因此, Fast-DTW 的计算复杂由 $O(n^2)$ 降至 $O(Tn)$, 加速两检测器节点的时间相似度 $\text{dist}(X^a, X^b)$ 求解效率。

将上述过程拓展至整个路网图 G 中, 获得任意节点与路网其他节点组成的 $\text{dist}(X^a, X^b)$ 向量集合, 从中筛选距离最小的前 K 个节点作为具有相似交通时间模式的检测器节点, 并将时间相似矩阵 A_T 对应位置元素标定为 1, 最终获得完整时间相似矩阵 $A_T \in \mathbb{R}^{N \times N}$ 。

空间邻接矩阵 A_S 表示路网图 G 中节点间的空间连接关系, 为 0-1 矩阵; 时间相似矩阵 A_T 表示节点间的时序规律关联关系, 同样为 0-1 矩阵。二者所隐含的节点时空关系是实现后续交通模式

学习预测以及异常状态评估的主要依据。因此, 路网图 G 邻接矩阵 A 采用 A_S 与 A_T 的并集形式进行时空关系融合, 即 $A = A_S \cup A_T$, 后续图结构数据均采用时空融合图邻接矩阵 A 表示。

2.2 交通模式学习与预测模块

2.2.1 多组件输入

在交通异常事件检测任务中, 参数预测部分需要挖掘并利用更全面的交通模式规律信息, 对交通参数进行合理稳定预测。对于一段给定交通流参数数据, 相同星期相同时段、每一天相同时段、同日临近时段的数据信息对于规律预测任务的贡献较高, 而其他时段信息价值则相对较弱, 甚至造成信息干扰与模型开销。因此, 根据参考文献 [19] 中的相关设定, GSTPL 采用近期、日周期、周周期 3 个组件作为网络模型输入, 分别学习不同时间维的交通模式规律。假设采样频率为每天 q 次, 即时间序列每天包含 q 个数据点。假设当前时间为 t_0 , 沿时间轴分别截取长度为 T_h 、 T_d 和 T_w 的 3 个时间序列片段作为模型的近期、日周期、周周期 3 个组件的输入, 如图 3 所示, 时间片段分别如下。

(1) 近期片段: $X_h = (X_{t_0 - T_h + 1}, X_{t_0 - T_h + 2}, \dots, X_{t_0}) \in \mathbb{R}^{F \times N \times T_h}$, 即与预测时段直接相邻的一段历史时间序列片段, 该时间范围内数据呈现出交通模式的强趋势性。

(2) 日周期片段: $X_d = (X_{t_0 - (T_d/T_p)q + 1 - T_p/2}, \dots, X_{t_0 - (T_d/T_p)q + 1 + T_p/2}, X_{t_0 - (T_d/T_p - 1)q + 1 - T_p/2}, \dots, X_{t_0 - (T_d/T_p - 1)q + 1 + T_p/2}, \dots, X_{t_0 - q + 1 - T_p/2}, \dots, X_{t_0 - q + 1 + T_p/2}) \in \mathbb{R}^{F \times N \times T_d}$, 由预测时段之前若干天中与预测目标时段相同且前后相邻 (T_p) 的序列片段组成, 日周期组件的目的是便于捕捉交通数据中以天为单位的周期模式。

(3) 周周期片段: $X_w = (X_{t_0 - 7 \times (T_d/T_p)q + 1 - T_p/2}, \dots, X_{t_0 - 7 \times (T_d/T_p)q + 1 + T_p/2}, X_{t_0 - 7 \times (T_d/T_p - 1)q + 1 - T_p/2}, \dots, X_{t_0 - 7 \times (T_d/T_p - 1)q + 1 + T_p/2}, \dots, X_{t_0 - 7q + 1 - T_p/2}, \dots, X_{t_0 - 7q + 1 + T_p/2}) \in \mathbb{R}^{F \times N \times T_w}$




图 3 多组件输入时序片段示例

Fig. 3 Multi-component input sequence segment diagram

$X_{t_0-t_q+1+t_p/2} \in \mathbb{R}^{F \times N \times T_w}$, 由预测时段之前的若干周中与预测目标星期属性相同、时段相同且前后相邻(T_p)的序列片段组成, 周周期组件的目的是便于捕捉交通数据中以周为周期的变化规律。

在交通模式学习与预测模块中, 3个组件采用由图时空卷积层与图嵌入层组成的相同网络结构完成周周期、日周期与近期模式特征的提取, 并利用融合预测层将3个组件的模式特征进行融合, 获得相应关键节点交通参数预测结果。

2.2.2 图时空卷积层

图时空卷积层的作用是对各输入组件中隐含的时空规律特征进行提取, 参考文献[21]中的相关设定, GSTPL的图时空卷积层包括: 空间维图卷积操作, 从节点空间邻域中提取数据间的空间关联性; 时间维1D卷积操作, 从时间邻域中提取序列的时间关联性, 其结构示意图如图4所示。

空间维图卷积: 为了提取图节点间的空间相关性, 采用频谱图理论对每个时间切片的空间图

G 进行处理, 通过傅里叶变换将图信号转化至谱域(正交特征空间)中进行卷积运算, 捕获图谱空间中有意义的模式特征, 再进行傅里叶逆变换处理, 实现图卷积操作, 其计算过程参考文献[25]。空间图卷积层可抽象为:

$$X_{GCN} = \text{ReLU}(g_{\theta * G} X) = \text{ReLU}(g_{\theta}(L) X) \in \mathbb{R}^{C_r \times N} \quad (3)$$

式中: X 为图卷积层输入参数; $g_{\theta * G}$ 为图卷积核; g_{θ} 为经傅里叶变换后的卷积核; $L \in \mathbb{R}^{N \times N}$ 为图 G 的归一化拉普拉斯矩阵; C_r 为卷积核数量; ReLU为激活函数。图卷积层的作用是实现路网交通流空间规律的无监督提取。

时间维1D卷积: 为了提取交通参数序列的时间相关性, 将图节点信息沿时间维进行展开, 并采用1D卷积操作对相邻时间交通信息进行合并处理, 以实现交通流时间模式规律的提取。如图4所示, 时间维1D卷积层可抽象为:




图4 图时空卷积层结构

Fig. 4 Graph spatial-temporal convolution layer structure

$$X_{TCN} = \text{ReLU}(\Phi * X) \in \mathbb{R}^{T_r \times N} \quad (4)$$

式中: X 为1D卷积层输入参数; $*$ 为标准卷积运算; Φ 为1D卷积核; T_r 为卷积核数量。

GSTPL中图时空卷积层采用图卷积层与1D卷积层叠加结构, 多组件依然采用相同的层结构处理, 因此整体计算过程可以抽象为:

$$\begin{cases} \chi_h = \text{ReLU}(\Phi * (\text{ReLU}(g_{\theta * G} X_h))) \in \mathbb{R}^{C_r \times T_r \times N} \\ \chi_d = \text{ReLU}(\Phi * (\text{ReLU}(g_{\theta * G} X_d))) \in \mathbb{R}^{C_r \times T_r \times N} \\ \chi_w = \text{ReLU}(\Phi * (\text{ReLU}(g_{\theta * G} X_w))) \in \mathbb{R}^{C_r \times T_r \times N} \end{cases} \quad (5)$$

通过多层图时空卷积层, 各组件特征图 χ_h 、 χ_d 和 χ_w 可以学习隐含在各输入组件中的空间与时间规律信息。值得注意的是, 特征图 χ 依然为图结构形式。

2.2.3 图嵌入层

为了实现对关键节点参数的预测, 引入图嵌入操作将特征图 χ 转化为低维特征向量, 便于后续模型预测。在 GSTPL 中, 图嵌入层起到数据结构转换与特征降维的作用, 本文引入文献[26]中的 DeepWalk 算法构造图嵌入层, 其计算过程抽象为:

$$F = \text{Embedding}(\chi) \in \mathbb{R}^E \quad (6)$$

式中: E 为特征向量的长度。3组件特征图 χ_h, χ_d 和 χ_w 将转化为低维且长度统一的近期特征向量 F_h 、日周期特征 F_d 向量与周周期特征向量 F_w 。

2.2.4 多组件融合预测层

多组件融合预测层作用是对各组件提取的低维特征 F 进行融合,并稳定预测关键节点的交通流参数。由于STGPL是基于预测结果进行异常事件检测的模型,需要模型在不同交通状态下,对各组件特征给予不同程度的侧重。例如,在正常状态下,需要提升预测精度以降低后续事件判别的难度,此时近期组件特征向量 F_h 比其他组件特征对预测结果的价值更高;当异常事件发生时,模型需要具有正常模式规律的保持能力,使预测结果依然保持正常交通运行规律,作为事件判别的对比标准,此时日周期组件特征 F_d 与周周期组件特征 F_w 的预测利用价值更高。因此,在多组件融合过程中,需要考虑算法对交通事件的判别结果 Q 以调整各部件权重。本文采用前馈注意力机制分配不同组件特征权重,多组件融合预测层结构如图5所示。

$$\hat{\alpha} = f(F_w, F_d, F_h, Q) \quad (7)$$

$$\alpha_i^e = \frac{\hat{\alpha}_i^e}{\sum_{j \in \{w, d, h\}} \hat{\alpha}_j^e} \quad (8)$$

$$\hat{y} = W \times \sum_{i=w, d, h} \alpha_i F_i + b \quad (9)$$

式中: $f(\cdot)$ 为全连接层; $\hat{\alpha} \in \mathbb{R}^{3 \times E}$ 为注意力权重矩阵; α_i^e 为归一化后的注意力权重; e 为特征向量

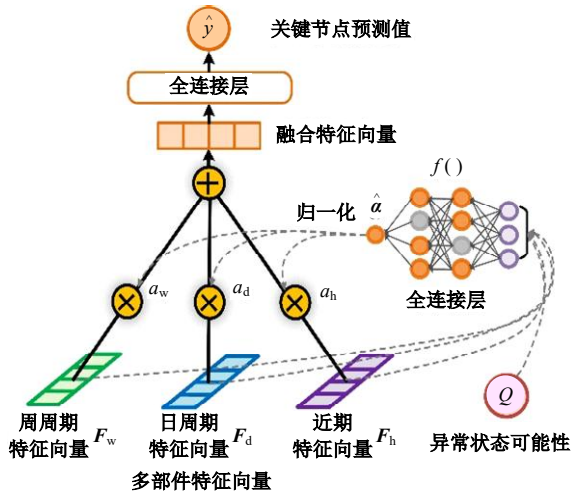


图 5 多组件融合预测层结构

Fig. 5 Multi-component fusion prediction layer structure

$F \in \mathbb{R}^E$ 中第 e 维特征; W 与 b 为全连接层的权重与偏置; \hat{y} 为关键节点融合后的最终预测值。需要说明的是, Q 为异常状态可能性指标,对各组件权重起调节指导作用。

2.3 异常评估模块

2.3.1 预测误差计算

经过交通模式学习与预测,GSTPL模型可以获得关键节点A和B交通参数的预测结果 $\hat{y}_{i+1}^A, \hat{y}_{i+1}^B \in \mathbb{R}^F$ 。异常评估模块的功能是计算下一时刻交通参数的实际检测值 x_{i+1}^A, x_{i+1}^B 与预测值 $\hat{y}_{i+1}^A, \hat{y}_{i+1}^B$ 间的偏差,并判断是否发生异常交通事件。为了降低参数数值差异对异常评估结果的影响,选用相对误差作为预测误差评价指标:

$$\begin{cases} R_{i+1}^A = \frac{|y_{i+1}^A - x_{i+1}^A|}{x_{i+1}^A} \in \mathbb{R}^F \\ R_{i+1}^B = \frac{|y_{i+1}^B - x_{i+1}^B|}{x_{i+1}^B} \in \mathbb{R}^F \end{cases} \quad (10)$$

2.3.2 异常状态可能性

预测误差表示模型对当前输入数据可预测性的瞬时度量。但由于实际交通流运行存在随机波动性,致使交通参数包含不可预测的随机成分,会干扰预测结果的瞬时度量,进而影响异常事件的评估过程。若采用预测误差设置阈值的方式将导致较高的误警率,并且阈值设置也需要针对性调整,将极大降低模型的通用普适性。

为解决该问题,参考文献[27]中的相关设定,将预测误差作为间接指标,利用预测误差分布计算当前状态的异常可能性,即异常状态可能性 Q 为基于历史预测结果判定当前状态异常程度的概率度量。给定关键节点的特征参数预测误差序列,利用一个长范围滑动窗口 L_w 记录与当前状态临近且处于 L_w 范围内的预测误差,通过高斯核密度估计方法求解长范围误差分布 $L(x)$,分布函数为:

$$L(x) = \frac{1}{L_w} \sum_{i=1}^{L_w} \frac{1}{\sqrt{2\pi} h} \exp\left(-\frac{(x-x_i)^2}{2h^2}\right) \quad (11)$$

式中: x_i 为 L_w 范围内的预测误差值; h 为高斯核带宽,其决定着概率密度函数的平滑性。同时,利用一个短范围滑动窗口 S_w 记录与当前状态临近且处于 S_w 范围内的预测误差,同样采用高斯核密度估计方法求解短范围误差分布 $S(x)$ 为:

$$S(x) = \frac{1}{S_w} \sum_{i=1}^{S_w} \frac{1}{\sqrt{2\pi} h} \exp\left(-\frac{(x-x_i)^2}{2h^2}\right) \quad (12)$$

$L(x)$ 是模型对交通参数预测效果的长期累

计估计,其中正常状态样本数量远大于事故状态样本数据,因此 $L(x)$ 可以作为正常交通状态下的预测误差总体分布。在正常状态下,短期误差分布 $S(x)$ 应大体服从于长期误差分布 $L(x)$,分布差异性并不显著;但在异常事件下,短期误差分布会存在明显增加和波动情况,导致 $S(x)$ 与 $L(x)$ 间差异较为显著。因此,通过衡量 $L(x)$ 与 $S(x)$ 的分布差异可以有效判断当前是否处于交通状态。本文通过JS散度衡量二者分布的差异性,并作为异常状态可能性指标。

$$\hat{Q} = JS(S||L) = \frac{1}{2} \int S(x) \lg \left(\frac{2S(x)}{S(x)+L(x)} \right) dx + \frac{1}{2} \int L(x) \lg \left(\frac{2L(x)}{S(x)+L(x)} \right) dx \quad (13)$$

式中: \hat{Q} 为异常状态可能性,其值域范围为 $[0,1]$ 。

正常状态下交通参数可预测性较高,模型预测误差相对稳定且服从整体误差分布;而在异常事件状态下,交通参数可预测性较低,模型预测误差不符合整体误差分布。结合式(13)计算原理,当 \hat{Q} 接近0时,说明 $L(x)$ 与 $S(x)$ 一致,当前属于正常状态;当 \hat{Q} 接近1时,说明 $L(x)$ 与 $S(x)$ 分布明显不同,当前状态发生异常事故可能性较高。综合考虑异常事件检测效果与防控级别,设置合理阈值作为异常事件判断标准;当 \hat{Q} 大于一定阈值时,即 $\hat{Q} \geq 1 - \epsilon$,则判定当前状态属于异常事故状态。

异常交通事件的发生会对上下游节点交通参数产生不同程度的影响。例如,事故发生时,上游节点由于车辆排队聚集导致流量降低,占有率升高,车流运行速度降低;而下游节点由于通过车辆数较少导致流量降低,占有率降低,但车速略有提升。将上述判定过程拓展至关键节点A和B以及不同交通参数特征 F (流量、速度与占有率等),通过相邻节点多参数预测结果的协同互补,以提升异常事件的最终判别精度,因此采用联合计算方式获得最终异常状态可能性 Q 为:

$$Q = g \left(\prod_{n=A,B} \prod_{i=1}^F \hat{Q}_i^n \right) \quad (14)$$

式中: $g()$ 为归一化函数。当计算获得异常状态可能性大于一定阈值时,即 $Q \geq 1 - \epsilon$,判定当前状态属于异常事故状态。同时, Q 将作为多组件融合预测层输入,指导不同状态下各组件特征融合预测过程的权重分配。

2.4 GSTPL网络训练策略

结合图1可知,GSTPL将采用分阶段训练策略,将训练过程分为多组件预测训练阶段、误差分布学习与组件权重联调阶段。

2.4.1 多组件预测训练阶段

该阶段任务是对GSTPL中近期、日周期与周周期3个具有相同结构的网络组件参数进行训练。在此阶段,将多组件融合预测层中注意力权重矩阵 $\hat{\alpha}$ 设置为单位矩阵,以固定各组件特征权重,并以关键节点参数预测误差最小为训练目标,对交通模式学习与预测模块网络参数进行训练,确保相应组件具备对交通状态参数变化趋势的预测能力,预测误差计算公式为:

$$E_c = \sum_{n=1}^N (\hat{y}_{t+1,n} - x_{t+1,n})^2 \quad (15)$$

式中: N 为批训练样本数量; \hat{y}_{t+1} 和 x_{t+1} 分别为关键节点特征预测值与检测值。虽然模块整体进行参数学习,但由于各组件特征权重已固定,该阶段训练实质是各组件以最小化预测误差为目标独立计算并优化网络组件参数,最终各组件可以实现对路网交通流近期、日周期、周周期模式规律的提取。

2.4.2 误差分布学习与组件权重联调阶段

该阶段通过多组件融合预测层获得关键节点A、B的融合预测结果,并将其输入异常评估模块学习预测误差的长短期误差分布范围并计算相应异常状态可能性 Q ,再将 Q 作为输入参数指导多组件融合预测层的权重更新。通过多次迭代训练,模型最终可以根据 Q 自动调整各组件特征权重;在正常状态下,模型保持良好的预测精度与较小的 Q 值;在异常事件状态下,模型依然能够调整不同组件特征权重并进行稳定预测,且此时 Q 值较大。该过程提高了 Q 值对于异常交通事件与正常交通状态的区分鉴别能力,同时降低交通参数随机干扰造成的误报率。其具体训练过程如下。

(1)随机初始化多组件融合预测层参数, Q 的初始值设置为0.5,计算其相应的长短期预测误差分布及相应 Q 值。

(2)根据 Q 值调整多组件融合预测层中各组件特征的权重系数。为了增大异常事件状态与正常状态 Q 值差距并降低样本失衡影响,采用Fo-

cal Loss^[24]训练多组件融合预测层网络参数,计算公式为:

$$E_t = \begin{cases} -(1-Q)^\gamma \ln Q, & \text{事故样本} \\ -Q^\gamma \ln(1-Q), & \text{正常样本} \end{cases} \quad (16)$$

式中: γ 为调整系数,以平衡事故样本与正常样本的重要程度。以 E_t 作为损失函数训练融合预测层参数,会令事故样本的 Q 值越趋近于1损失越小,令正常样本的 Q 值越趋近于0损失越小,以此调整各组件特征权重。

(3)利用更新后的多组件层融合预测,重新计算长短期预测误差分布与 Q 值。通过步骤(2)与(3)的迭代训练,最终 E_t 、多组件融合预测层参数、预测误差分布与 Q 值均趋近于收敛稳定。

3 实验与对比分析

3.1 实验数据来源与评价指标

本文实验选取2个真实路网交通流参数与事故数据集验证GSTPL模型的异常事件评估性能。
①美国西雅图数据集:来自DRIVENet开放数据集(<http://wsdot.uwdrive.net>),空间范围选取美国西雅图I90号与I405号州际公路作为测试路网,共包含31个道路断面检测器采集的交通流流量、速度及占有率,如图6(a)所示,时间范围选取2015年1月1日至2015年12月31日,采样间隔为5 min;对应事故数据同样来自该数据集,提供了准确的发生里程号、事故发生时刻与事故终止时刻。
②国内某市数据集:交通流参数信息来自该市某快速路49个断面卡口视频检测器,包括流量、速度及占有率,其检测位置如图6(b)所示,时间范围选取2017年12月5日至2018年1月30日,采样间隔为5 min;对应的交通事故数据

来自交通管理部门,包括事故发生位置经纬度、事故发生时间等。实验中选取总样本的70%作为网络训练数据集,10%作为验证集,20%作为测试集。

AID算法性能主要体现在对交通异常事件的检测精度与效率两方面。通常选用检测率(Detection rate, DR)与误警率(False alarm rate, FAR)度量算法对交通事件的检测精度,选用平均检测时间(Mean time-to-detect, MTTD)度量算法的检测效率^[2]。其中,检测率 D_t 指算法在一定时间内交通事件数与实际发生的引起交通能力下降的交通事件总数的比值,即:

$$D_t = D_N / A_N \quad (17)$$

式中: D_N 为算法检测的交通事件数; A_N 为实际发生的交通事件数。误检率 F_{AR} 是指在一定时间内算法误检的事件次数与算法检测到的交通事件总数的比值,即:

$$F_{AR} = F_N / D_N \quad (18)$$

式中: F_N 为误检的交通事件数。平均检测事件 M_{TTD} 是指一定时间内,事件发生时刻到算法检测到该事件时刻之间时间差的算术平均值,即:

$$M_{TTD} = \frac{1}{n} \sum_{i=1}^n T_1(i) - A_T(i) \quad (19)$$

式中: $A_T(i)$ 为算法检测到事件 i 的检测时刻; $T_1(i)$ 为被算法检测到事件 i 的实际发生时刻。

考虑到数据采样间隔与实际应用对事件响应效率的要求,当算法对任一交通事件的检测时间超过20 min(即4个时间间隔)时,标记为算法漏检,即使此后算法对该事件进行了异常判定,仍标记为误检。上述3种评价指标存在相互关联,若提高事件的检测率,必然会带来更多误检次数;相



(a)美国西雅图数据集

(b)国内某市数据集

图 6 实验路网检测器布设位置

Fig. 6 Detector layout position of experimental road network

反,若算法产生误检率较低,相应的检测率也会降低。

为了动态描述算法对误检率与检测率的敏感性,本文采用接受者操作特征曲线(Receiver operation characteristic curve, ROC)和曲线下面积(Area under the curve, AUC)评价 AID 算法性能。ROC 曲线以误检率为横轴,检测率为纵轴,根据不同(F_{AR}, D_r)连接形成一条曲线;AUC 为 ROC 曲线下面积,其理论取值为 0.5~1.0,0.5 对应对角线下的面积,1.0 对应整个 ROC 平面面积。ROC 越逼近左上角,AUC 越接近 1,说明算法的总体识别性能越好。

3.2 GSTPL 参数设置

GSTPL 模型参数会影响最终交通异常事件的判别精度,实验通过网格搜索方式确定最佳的模型参数。在融合图构建模块中,模型输入历史时段长度 n 设置为 6,时间相似矩阵中搜索长度 T 设置为 3。在交通模式学习与预测模块中,通过搜索确定 $T_h=6, T_d=3, T_w=3, T_p=2$ 为多组件最佳输入尺寸组合;参考文献[19]对图时空卷积层的设置方式,空间维卷积使用 32 个相同尺寸卷积核,沿空间维卷积步长为 1,时间维 1D 卷积同样采取 32 个相同尺寸卷积核,沿时间维卷积步长为 3,图时空卷积层数设置为 3 层;图嵌入层参考文献[26]中的 DeepWalk 方法,游走长度设置为 3,输出特征向量长度为 32;融合预测层采用 3 层全连接层,节点数分别为 32、16、32。为了得到最佳异常事件评估效果,采用文献[28]中的粒子群优化方法对 GSTPL 训练超参数进行优化,表 1 给出了其他参数设置结果。

表 1 GSTPL 网络设置相关参数

Table 1 Major parameters configurations of GSTPL model


模型参数	设置值或参数类型
最大训练次数	20 000
多组件预测训练阶段学习率	0.001
组件权重联调阶段学习率	0.000 1
网络优化器	Adam
长范围滑动窗口 L_w	3 000
短范围滑动窗口 L_s	6
式(11)与式(12)中高斯核带宽 h	0.2
式(16)中调整系数 γ	0.8
异常状态可能性判定阈值 ϵ	0.3

3.3 对比实验分析


分别以美国西雅图数据集与国内某市数据集作为输入,验证本文所提 GSTPL 的交通异常事件自动检测性能,并与各类典型的 AID 算法进行对比实验分析。为了满足异常事件检测的实时性要求,测试过程中每个 AID 算法将连续输入交通时序参数,并给出对应时刻的异常检测结果,与实际发生事件情况进行比较,分析其算法性能。

首先,分析本文 GSTPL 的异常事件自动检测效果。以西雅图数据集中 I90 公路的 6.67 检测点为例,图 7 给出了 GSTPL 算法各阶段的相关参数分布与异常事件评估效果,其中红点处表示异常交通事故。图 7(a)展示了 GSTPL 交通模式学习与预测部分的参数预测效果,可以看出,算法在正常模式下具有很好的预测效果,同时在事件发生时参数异常波动情况下依然能够保持正常模式的稳定预测趋势。图 7(b)给出了基于流量预测误差的异常评估效果,由于交通流参数自身掺杂随机波动成分,导致算法的预测误差频繁波动,这使其无法与真实交通事件发生时的预测误差波动进行有效区分,但整体预测误差依然满足特定分布。图 7(c)给出了基于异常状态可能性的异常评估结果,可以直观看出在真实异常事件发生时存在一个明显峰值,这也验证了采用预测误差分布作为间接指标评估异常事故可能性具有有效性,同时也证明了 GSTPL 能够对异常事件进行实时辨识。


为了对本文算法进行综合评价,实验选取了几种典型的 AID 算法进行对比验证:①标准正态偏差(Standard normal deviates, SND):文献[29]中经典单变量速度阈值计算方法,对同一断面不同日期相同时段的交通速度参数进行统计,以平均速度作为位置参数,以速度标准偏差作为比例参数,计算对应速度阈值;②中位数绝对偏差(Median absolute deviation, MAD):同样为单变量速度阈值计算方法,利用文献[4]的处理方式,以 MAD 作为比例参数,以速度中位数作为位置参数,从而确定相应速度阈值;③多元时空动态阈值法:利用文献[4]的方法,生成速度、流量、占有率的 SND、MAD 与四分位数偏差(Inter quartile deviation, IQD)的阈值热力图,采用双边滤波与全差分方式进行降噪处理,对特征阈值进行动态



(a)GSTPL交通模式学习与预测部分的参数预测效果



(b)基于流量预测误差的异常评估效果



(c)基于异常状态可能性的异常评估效果

图 7 GSTPL对异常交通事件的评估效果

Fig. 7 Discriminant effect of abnormal traffic incidents by GSTPL

调整与事件判别;④贝叶斯分类^[6]:通过对正常样本与事件样本的统计分析,计算对应状态的条件概率并以此估计实测样本的所属类别,给出相应

事件评估结果;⑤支持向量机^[11]:通过支持向量机的训练求解正常样本与时间样本的分类超平面,计算实测样本的所属范围并分配其对应类别;

⑥随机森林^[1]:通过历史数据对多分类树进行训练,并对实测数据进行分类判别,给出相应结果;
 ⑦卡尔曼滤波器^[13]:通过卡尔曼滤波器的迭代预测和修正,实现对交通流随机性抑制和参数的最优估计,并通过相应的阈值对异常事件进行判别;
 ⑧STGAN:采用文献[22]的方法构造一个时空图生成器学习交通流时空特征并预测参数正常模式趋势,并构造一个时空图鉴别器用于判断预测结果是正常还是异常;
 ⑨LSTM+异常评估:将本文框架中GSTPL预测模块替换为文献[30]中的长短时记忆网络LSTM,结合异常评估模块对是否发生异常事件进行判别;
 ⑩自适应时空图注意力网络(Adaptive spatial-temporal graph attention network,ASTGAT)+异常评估:将GSTPL预测模块替换为文献[31]中的ASTGAT网络,结合异常评估模块对是否发生异常事件进行判别;
 ⑪多头注意力时空卷积网络(Multi-head self-attention spatiotemporal graph convolutional network,MSASGCN)+异常评估:将GSTPL预测模块替换为文献[32]中的MSASGCN网络,并利用异常评估模块对是否发生异常事件进行判别;
 ⑫TCA+异常评估:采用文献[27]的方法,构造时间卷积自编码网络对节点交通参数进行模式学习与预测,并结合异常评估模块对异常事件进行评估。

对于每个对比模型,训练集和测试集与实验中的GSTPL一致,相应算法主要参数与相关文献中的设置一致并采用粒子群优化方法^[28]进行优化,以达到不同AID算法的最佳预测性能。图

8为西雅图数据集中不同算法对应的ROC曲线,表2分别给出了不同算法在美国西雅图与国内某市数据集中的性能表现。

结合表2与图8的实验结果,可得出如下结论:①与基于特征参数阈值和统计分类的AID算法相比,基于预测回归的AID算法(卡尔曼滤波、STGAN、LSTM+异常评估、ASTGAT+异常评估、MSASGCN+异常评估、TCA+异常评估、GSTPL)的异常事件误检率更低,检测性能更稳定。这是因为预测算法能够有效利用交通参数的时序规律,而非通过数理统计特征进行简单划分;②基于深度学习的AID算法(STGAN、LSTM+异常评估、ASTGAT+异常评估、MSASGCN+异常评估、TCA+异常评估、GSTPL)性能更优,检测率与误检率均有较大提升,其原因是深度学习模型可以学习到更多隐含的规律信息,并实现更加稳定的规律预测与更合理的事件评估,这也验证了基于预测回归的AID算法需要预测模型具有更好的交通模式规律的提取能力;③对比STGAN与GSTPL方法,二者均采用图结构网络对交通路网时空特征进行学习并对未来参数进行规律预测,但STGAN异常评估过程实质是直接利用预测值与真实值的误差判断,其误报率高于GSTPL,这也证明了GSTPL通过预测误差分布学习计算异常状态可能性的过程有效性;④对比LSTM+异常评估、TCA+异常评估和GSTPL方法,GSTPL对异常事件具有更好的检测效果,说明图结构网络能够有效地提取并利用交通流时空模式规律,验证了其结构优势;⑤对比AST-




图 8 不同 AID 算法 ROC 曲线对比

Fig. 8 ROC curve comparison of different AID algorithms

表 2 不同 AID 算法异常事件检测性能
Table 2 Abnormal incidents detection performance of different AID algorithms

评价指标		美国西雅图数据集											
模型	SND	MAD	多元时空 动态阈值	贝叶斯 分类	支持向 量机	随机森 林	卡尔曼 滤波	STGAN	LSTM+ 异常评估	AST- GAT+ 异常评估	MSAS- GCN+异 常评估	TCA+ 异常评 估	GSTPL
检测率 (误检率 5%)/%	78.21	80.52	82.79	86.92	84.68	79.25	89.26	89.61	91.34	90.78	91.62	93.15	94.52
检测率 (误检率 10%)/%	84.75	87.32	88.43	89.72	86.92	86.25	92.56	94.59	95.32	94.62	95.78	98.61	98.71
误检率 (检测率 90%)/%	28.76	25.93	24.81	18.85	20.15	27.74	8.51	7.06	4.40	6.17	34.832	3.52	3.12
误检率 (检测率 95%)/%	45.92	43.64	40.25	33.21	39.08	44.52	12.23	10.58	9.12	9.73	9.26	6.72	6.09
平均检测 时间/min	3.62	3.58	3.51	8.59	5.36	5.82	4.05	4.52	3.69	3.82	3.72	3.88	3.92
AUC	0.904 3	0.912 4	0.918 2	0.947 6	0.942 5	0.923 5	0.954	0.966 3	0.978 1	0.973 4	0.979 2	0.983 2	0.987 6
评价指标		国内某市数据集											
模型	SND	MAD	多元时空 动态阈值	贝叶斯 分类	支持向 量机	随机森 林	卡尔曼 滤波	STGAN	LSTM+ 异常评估	AST- GAT+ 异常评估	MSAS- GCN+异 常评估	TCA+ 异常评 估	GSTPL
检测率 (误检率 5%)/%	75.63	78.52	79.53	81.57	80.26	77.65	86.12	87.52	89.62	87.96	88.12	89.92	91.43
检测率 (误检率 10%)/%	81.45	82.46	84.43	87.46	85.17	83.14	89.35	91.92	94.68	93.42	93.62	95.03	96.54
误检率 (检测率 90%)/%	20.56	19.76	17.52	15.92	17.35	15.93	11.35	8.92	6.15	7.47	68.14	5.03	4.22
误检率 (检测率 95%)/%	41.62	37.92	38.72	31.54	34.17	29.25	17.62	12.59	10.25	11.38	10.75	9.83	8.23
平均检测 时间/min	6.38	5.78	5.12	8.92	7.78	7.52	6.38	6.74	5.53	5.73	5.61	5.42	5.24
AUC	0.853 6	0.861 7	0.8732	0.902 5	0.886 4	0.879 6	0.931 4	0.943 2	0.949 2	0.943 7	0.945 8	0.946 2	0.970 7

GAT+ 异常评估、MSASGCN+ 异常评估和 GSTPL 方法,三者均采用图神经网络进行交通流参数预测,虽然 ASTGAT 与 MSASGCN 的预测能力较好,其正常状态与异常事件发生时预测误差均较小,易造成对异常事件的误判,其误报率相对 GSTPL 较高。这也说明,对于异常事件检测任务,AID 算法预测模块不仅在正常状态下具有较好的预测性能,在异常事件发生时,依然能保

持正常交通模式规律进行稳定预测,直接证明了 GSTPL 算法对交通流模式规律学习的有效性与预测的稳定性。⑥通过综合比较,本文提出的 GSTPL 在 2 个数据集上均具有异常事件评估的最佳性能,检测精度更高,误检率更低,平均事件检测时间相对较短,体现了本文方法对不同交通条件的自适应性与稳定性。

为了验证所设计的时空融合图模块的有效

性,本文分别设计了不同图结构输入(空间图、时间图与时空融合图)与 GSTPL 网络组合的对比实验,其实质就是将空间邻接矩阵 A_s 、时间相似矩阵 A_T 与时空融合矩阵 A 分别作为交通路网图 G 的邻接矩阵,对交通路网进行图结构表达,其对比结果见表 3。通过对比可知,基于空间图的 GSTPL 算法的检测率最低,其原因在于 A_s 未能有效利用路网中具有相同交通模式的节点信息,

致使其对交通模式规律的提取并不稳定,存在较高的误报率。基于时间图的 GSTPL 算法的检测性能与时空融合图方式较为接近,通过参数分析发现 A_T 在大多数情况下与 A 的矩阵元素一致,反映了空间邻接节点具有较高的时间相似性。基于时空融合图的 GSTPL 整体上具有最佳的异常事件评估效果,验证了本文提出的时空融合图表达方式的有效性。

表 3 时空融合图结构验证实验

Table 3 Validation experiment of spatial-temporal graph structure input

评价指标	美国西雅图数据集			国内某市数据集		
	空间图	时间图	时空融合图	空间图	时间图	时空融合图
	+GSTPL	+GSTPL	+GSTPL	+GSTPL	+GSTPL	+GSTPL
检测率(误检率 5%)/%	92.16	93.72	94.52	89.51	90.17	91.43
检测率(误检率 10%)/%	96.43	98.32	98.71	93.54	95.26	96.54
误检率(检测率 90%)/%	4.92	4.31	3.12	6.91	4.92	4.22
误检率(检测率 95%)/%	8.52	7.16	6.09	10.31	9.73	8.23
平均检测时间/min	3.82	3.96	3.92	5.53	5.42	5.24
AUC	0.965 4	0.980 2	0.987 6	0.941	0.953 6	0.970 7

为了验证 GSTPL 交通模式学习与预测模块多组件输入结构的有效性,本文分别设计了近期 X_h 、日周期 X_d 、周周期组件 X_w 不同输入组合的对比实验,其对比结果如表 4 所示。通过对比分析发现,单组件输入对异常事件的检测效果劣于组合输入,两者问题原因存在差别。对于近期组件输入,以连续时序片段 X_h 作为输入,通过 GSTPL 中图时空卷积与图嵌入层优越的特征提取能力,使其近期输入的预测结果在正常状态与异常事件下的预测误差均较小,易造成对异常事件的误判,误报率相对较高;对于日周期与周周期组件输入,由于 X_d 与 X_w 具有不同时间维的交通模式,相应的

预测结果更为稳定,这造成正常状态与异常事件下预测误差的波动性较强,同样易产生对异常事件的误判。综合分析可知,GSTPL 采用的多组件输入融合预测的方式,能够使模型既具有正常状态下较好的预测性能,又能在异常事件状态下具有稳定预测的能力,验证了该网络结构的有效性。

为了验证 GSTPL 异常评估模块的有效性,本文采用固定阈值与动态阈值方式代替异常评估模块进行交通异常事件的检测,其中固定阈值选取预测误差的四分位距(Interquartile range, IQR)进行异常判断,即超出 $\pm 1.5IQR$ 则判定为

表 4 GSTPL 多组件输入结构验证实验

Table 4 Validation experiment of multi-component input structure of GSTPL

评价指标	美国西雅图数据集						国内某市数据集					
	近期	日周期	周周期	近期十日	近期十周	本文	近期输	日周期	周周期	近期十日	近期十周	本文
	输入	输入	输入	周期输入	周期输入	方法	入	输入	输入	周期输入	周期输入	方法
检测率 (误检率 5%)/%	92.56	91.28	89.18	93.47	92.35	94.52	89.63	87.12	86.51	90.15	89.94	91.43
检测率 (误检率 10%)/%	95.76	95.32	94.42	96.54	95.72	98.71	94.18	93.27	92.34	95.13	94.36	96.54
误检率 (检测率 90%)/%	4.95	4.92	6.62	4.38	4.76	3.12	6.94	8.82	9.32	4.92	6.35	4.22
误检率 (检测率 95%)/%	9.42	9.87	10.16	8.61	9.63	6.09	10.31	11.25	12.63	9.28	10.18	8.23
平均检测时间/min	3.61	4.37	4.53	4.01	3.84	3.92	5.04	5.73	5.76	5.62	5.13	5.24
AUC	0.961 3	0.951 6	0.943 2	0.976 1	0.963 2	0.987 6	0.950 3	0.948 1	0.942 6	0.952 5	0.962 3	0.970 7

存在交通事件;动态阈值参考文献[4]处理方式,使用预测误差的MAD作为比例参数,以同时段输入特征中位数作为位置参数,从而确定相应判定阈值。对比结果如表5所示,可固定阈值与动态阈值方式的误检率相对较高,其问题实质是交

通参数随机性会造成模型预测效果不稳定,进而影响异常事件评估过程。对比结果也证明了本文方法所设计的异常评估模块通过对误差分布的学习与度量,有效降低了参数随机波动对事件评估的干扰,减少了事件误报率。

表5 GSTPL异常评估模块验证实验

Table 5 Validation experiment of anomaly evaluation module of GSTPL

评价指标	美国西雅图数据集			国内某市数据集		
	GSTPL+ 固定阈值	GSTPL+ 动态阈值	本文方法	GSTPL+ 固定阈值	GSTPL+ 动态阈值	本文方法
检测率(误检率5%)/%	84.76	90.31	94.52	85.72	88.49	91.43
检测率(误检率10%)/%	92.15	94.67	98.71	89.67	93.84	96.54
误检率(检测率90%)/%	8.92	4.98	3.12	10.43	8.92	4.22
误检率(检测率95%)/%	14.67	10.37	6.09	13.62	11.36	8.23
平均检测时间/min	3.79	3.83	3.92	5.16 min	5.49 min	5.24 min
AUC	0.951 1	0.965 7	0.987 6	0.941 3	0.962 4	0.970 7

4 结束语

本文提出了一种基于图时空模式学习网络(GSTPL)的路网实时交通事件自动检测算法。为了更充分利用交通流在路网中的时空依赖关系,构建了新的交通时空融合图结构表达方法,通过空间邻接矩阵与时间相似矩阵融合构造方式,筛选具有强时空依赖性与模式规律性的图节点,用以构建GSTPL输入,在剔除无关图节点冗余信息的同时,使整体网络模型输入与计算轻量化。本文设计了多组件输入与融合预测层结构,对不同时间维(近期、日周期、周周期)模式规律进行独立学习,引入图时空卷积与图嵌入对模式规律进行无监督提取,实现对路网图节点参数的稳定预测。为降低交通流参数随机波动对异常评估的影响,提出了基于预测误差分布的异常状态可能性计算方法,以长期预测误差分布与短期预测误差分布的距离作为异常评估指标,减少了交通事件误报情况。利用真实路网交通检测数据进行算法验证,并与典型AID算法进行对比分析,实验结果验证了所提出的基于GSTPL的事件检测方法具有较高的准确率、较低的误报率和较短的平均检测时间,可满足大范围路网场景与不同交通状态的事件检测需求。在后续的研究中,可以在固定检测器数据的基础上,增加浮动车所提供的实时轨迹信息,对路网交通状态进行更细粒度与尺度的刻画;同时,可以设计更为有效的交通流时空

模式特征提取方法,以提升交通异常事件的判别精度。

参考文献:

- [1] 刘擎超, 陆建, 陈淑燕. 基于随机森林的交通事件检测方法设计与分析[J]. 东南大学学报: 英文版, 2014, 30(1): 88-95.
Liu Qing-chao, Lu Jian, Chen Shu-yan. Design and analysis of traffic detection based on random forest[J]. Journal of Southeast University (English Edition), 2014, 30(1): 88-95.
- [2] Evans J, Waterson B, Hamilton A. Evolution and future of urban road incident detection algorithms[J]. Journal of Transportation Engineering, Part A: Systems, 2020, 146(6): No. 03120001.
- [3] Payne H J, Tignor S C. Freeway incident-detection algorithms based on decision trees with states [J]. Transportation Research Record, 1978, 682: 30-37.
- [4] Chakraborty P, Hegde C, Sharma A. Data-driven parallelizable traffic incident detection using spatio-temporally denoised robust thresholds[J]. Transportation Research Part C: Emerging Technologies, 2019, 105: 81-99.
- [5] 程小洋. 交通事件检测算法的阈值自适应调整与优化[D]. 南京: 东南大学交通学院, 2021.
Cheng Xiao-yang. Threshold adaptive adjustment and optimization of traffic incident detection algorithm[D]. Nanjing: School of Transportation, South-

- east University, 2021.
- [6] Liu Q C, LU J, Chen S Y, et al. Multiple naive bayes classifiers ensemble for traffic incident detection[J]. *Mathematical Problems in Engineering*, 2014, 2014: No. 383671.
- [7] Srinivasan D, Jin X, Cheu R L. Evaluation of adaptive neural network models for freeway incident detection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2004, 5(1): 1-11.
- [8] Liu G W, Jin H L, Li J Z, et al. A Bayesian deep learning method for freeway incident detection with uncertainty quantification[J]. *Accident Analysis & Prevention*, 2022, 176: No. 106796.
- [9] 商强, 林赐云, 杨兆升, 等. 基于变量选择和核极限学习机的交通事件检测[J]. *浙江大学学报: 工学版*, 2017, 51(7): 1339-1346.
Shang Qiang, Lin Ci-yun, Yang Zhao-sheng, et al. Traffic incident detection based on variable selection and kernel extreme learning machine[J]. *Journal of Zhejiang University (Engineering Science)*, 2017, 51(7): 1339-1346.
- [10] Dogru N, Subasi A. Traffic accident detection using random forest classifier[C]//The 15th Learning and Technology Conference: L&T, Jeddah, Saudi Arabia, 2018: 40-45.
- [11] Wang L L, Ngan H Y T, Yung N H C. Automatic incident classification for large-scale traffic data by adaptive boosting SVM[J]. *Information Sciences*, 2018, 467: 59-73.
- [12] Xiao J L. SVM and KNN ensemble learning for traffic incident detection[J]. *Physica A: Statistical Mechanics and Its Applications*, 2019, 517: 29-35.
- [13] Wang R, Work D B, Sowers R. Multiple model particle filter for traffic estimation and incident detection[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2016, 17(12): 3461-3470.
- [14] 尹春娥, 陈宽民, 万继志. 基于小波方程的高速公路交通事故自动检测方法[J]. *中国公路学报*, 2014, 27(12): 106-112.
Yin Chun-er, Chen Kuan-min, Wan Ji-zhi. Automatic detection method for expressway traffic accidents based on wavelet equation[J]. *China Journal of Highway and Transport*, 2014, 27(12): 106-112.
- [15] Adeli H, Samant A. An adaptive conjugate gradient neural network - wavelet model for traffic incident detection[J]. *Computer-Aided Civil and Infrastructure Engineering*, 2000, 15(4): 251-260.
- [16] Lu J, Chen S Y, Wang W, et al. A hybrid model of partial least squares and neural network for traffic incident detection[J]. *Expert Systems with Applications*, 2012, 39(5): 4775-4784.
- [17] Tang S M, Gao H J. Traffic-incident detection-algorithm based on nonparametric regression[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2005, 6(1): 38-42.
- [18] Jiang W W, Luo J Y. Graph neural network for traffic forecasting: A survey[J]. *Expert Systems with Applications*, 2022, 207: 117921.
- [19] 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 Sheng-nan, Song Chao, et al. Multi-component spatial-temporal graph convolution networks for traffic flow forecasting[J]. *Journal of Software*, 2019, 30(3): 759-769.
- [20] Cui Z Y, Henrickson K, Ke R M, et al. Traffic graph convolutional recurrent neural network: A deep learning framework for network-scale traffic learning and forecasting[J]. *IEEE Transactions on Intelligent Transportation Systems*, 2020, 21(11): 4883-4894.
- [21] 李海涛. 基于深度学习的交通流运行风险评估方法研究[D]. 长春: 吉林大学交通学院, 2021.
Li Hai-tao. Research on traffic flow operation risk evaluation based on deep learning[D]. Changchun: College of Transportation, Jilin University, 2021.
- [22] Deng L Y, Lian D F, Huang Z Y, et al. Graph convolutional adversarial networks for spatiotemporal anomaly detection[J]. *IEEE Transactions on Neural Networks and Learning System*, 2022, 33(6): 2416-2428.
- [23] Zhang H Y, Zhao S Y, Liu R H, et al. Automatic traffic anomaly detection on the road network with spatial-temporal graph neural network representation learning[J]. *Wireless Communications & Mobile Computing*, 2022: No. 4222827.
- [24] Keogh E, Ratanamaharana C A. Exact indexing of dynamic time warping[J]. *Knowledge and Information Systems*, 2005, 7(3): 358-386.
- [25] Ge L, Li S Y, Wang Y Q, et al. Global spatial-temporal graph convolutional network for urban traffic speed prediction[J]. *Applied Sciences*, 2020, 10(4): 1509.
- [26] Qiu J, Dong Y, Ma H, et al. Network embedding as matrix factorization: unifying deepwalk, line, PTE, and node2vec[C]//The 11th ACM Interna-

- tional Conference on Web Search and Data Mining. New York: ACM, 2018: 459-467.
- [27] 李海涛,李志慧,王鑫,等. 基于时间卷积自编码网络的实时交通事件自动检测方法[J]. 中国公路学报, 2022, 35(6): 265-276.
- Li Hai-cao, Li Zhi-hui, Wang Xin, et al. Real-time automatic method of detecting traffic incidents based on temporal convolutional autoencoder network[J]. China Journal of Highway and Transport, 2022, 35(6): 265-276.
- [28] Wang J J, Kumbasar T. Parameter optimization of interval Type-2 fuzzy neural networks based on PSO and BBBC methods[J]. IEEE/CAA Journal of Automatica Sinica, 2019, 6(1): 247-257.
- [29] Balke K, Conrad L D, Christopher E M. Using probe-measured travel times to detect major freeway incidents in Houston, Texas[J]. Transportation Research Record, 1996, 1554(1): 213-220.
- [30] Zhao Z, Chen W H, Wu X M, et al. LSTM network: a deep learning approach for short-term traffic forecast[J]. IET Intelligent Transport Systems, 2017, 11(2): 68-75.
- [31] Kong X, Zhang J, Wei X, et al. Adaptive spatial-temporal graph attention networks for traffic flow forecasting[J]. Applied Intelligence, 2021, 52: 4300-4316.
- [32] Cao Y, Liu D T, Yin Q Z, et al. MSASGCN: Multi-head self-attention spatiotemporal graph convolutional network for traffic flow forecasting[J]. Journal of Advanced Transportation, 2022: 1-15.