

基于时空 Transformer 网络的隧道交通运行风险动态辨识方法

李振江¹, 万利¹, 周世睿², 陶楚青¹, 魏巍²

(1. 山东省交通规划设计院集团有限公司 隧道与地下工程设计分院, 济南 250000; 2. 吉林大学 交通学院, 长春 130022)

摘要: 为了及时发现、评估与应对高速公路隧道交通风险隐患, 确保隧道运行安全通畅, 本文构建了基于时空 Transformer 网络的隧道运行风险状态动态辨识方法。以隧道交通流全域检测数据与关键断面集计数据为输入, 通过空间 CNN 卷积与时序 LSTM 对隧道车流不同运行状态的时空分布特征进行无监督提取; 利用大样本训练 Transformer 网络层参数, 以捕获隧道交通运行状态在高维风险特征空间的分布与差异, 实现隧道交通状态的风险划分与评估。采用真实隧道交通检测数据验证了本文方法的有效性, 对隧道运行风险评估精度约为 96%。

关键词: 交通运输工程; 隧道交通安全; 动态评估; 深度学习; 时序卷积网络

中图分类号: U458 **文献标志码:** A **文章编号:** 1671-5497(2025)04-1336-10

DOI: 10.13229/j.cnki.jdxbgxb.20230689

Dynamic estimation of operational risk of tunnel traffic flow based on spatial-temporal Transformer network

LI Zhen-jiang¹, WAN Li¹, ZHOU Shi-rui², TAO Chu-qing¹, WEI Wei²

(1. Tunnel and Underground Engineering Design Branch, Shandong Provincial Communications Planning and Design Institute Group Company Limited, Jinan 250000, China; 2. College of Transportation, Jilin University, Changchun 130022, China)

Abstract: To promptly detect, evaluate, and address potential traffic risks in highway tunnels, ensuring the safe and efficient operation of tunnels, a dynamic estimation method for tunnel operational risk states was proposed based on spatial-temporal Transformer network. Tunnel traffic flow holographic detection and key cross-section aggregation information as inputs was utilized, the spatial convolution and temporal LSTM was employed by proposed model for unsupervised extraction of spatiotemporal distribution features of different tunnel traffic operational states. Through extensive sample training of Transformer network layer parameters, it aims to capture the distribution and variances of tunnel traffic states in a high-dimensional risk feature space. This facilitates the estimation of operational risk of tunnel traffic flow. The effectiveness of the proposed method is verified by using real tunnel traffic detection data, and the accuracy

收稿日期: 2023-06-01.

基金项目: 国家重点研发计划项目(2019YFB1600500); 山东省交通运输厅科技计划项目(KJ-2019-SDSJTT-04).

作者简介: 李振江(1965-), 男, 研究员. 研究方向: 隧道安全设计. E-mail: jnlzj@163.com

通信作者: 魏巍(1978-), 男, 高级工程师, 博士. 研究方向: 交通视频检测. E-mail: weiwei@jlu.edu.cn

of tunnel operation risk estimation is about 96%.

Key words: traffic transport engineering; tunnel traffic safety; dynamic evaluation; deep learning; time series convolutional network

0 引言

高速公路隧道由于其封闭的特殊环境、不同尺寸车型混行通行状态与驾驶人随机驾驶行为,易诱发车辆行车速度突变、车间不规则行为等现象,进而增加隧道内车辆运行不稳定性与风险。由隧道事故统计分析可以得出,隧道内交通事故发生概率与隧道交通运行状态存在显著映射关系。当隧道内部交通流呈现不稳定流或饱和流状态时,事故发生概率会大幅增加^[1]。因此,通过对隧道内部车辆运行状态的模式学习,挖掘隧道交通运行状态与事故间潜在关联,设计隧道运行风险动态评估方法,对提升隧道安全管理水平、保障人员生命安全与交通顺畅具有重要意义。

常规的交通流运行参数(如流量、速度、占有率)能够反映隧道的动态交通状态,如牛文静^[2]分析了高速公路隧道交通运行影响因素与参数特征并建立了隧道交通三参数关系模型。Tadaki等^[3]通过对隧道交通参数的统计分析,验证了正常状态、拥堵状态与事故状态交通参数分布间存在显著差异。周林英等^[4]分析了交通事故状态下高速公路隧道群交通流三参数的时空变化特性。倪娜^[5]分析了隧道密集段的数据采集分布特征并设计了隧道交通安全保障策略。Tian等^[6]采用模糊C均值聚类方法对隧道交通流参数进行聚类,划分隧道安全状态区域。但通过关键断面的交通流参数对交通运行状态描述其本质属于集计统计性质描述,无法对每个车辆在隧道内的运行状态(空间位置、行驶速度与轨迹)进行精细刻画与动态表述^[7]。

随着隧道智能化监控系统的普及,全域毫米波雷达检测与多相机连续跟踪技术的普及应用为隧道内部车辆运行状态精确感知提供了数据支撑^[8-11]。现有研究主要通过隧道全检测信息提供的车辆运行轨迹进行安全性分析。贾磊等^[12]建立了基于监控视频的隧道交通冲突预测方法,分析了隧道不同区域车辆轨迹分布并利用随机森林方法进行轨迹冲突预测。Chen等^[13]利用隧道车辆轨迹数据,建立了由潜在场、动力场与环境场组

成的综合安全场评估隧道限速标志、前车与照明条件对行车风险的影响,并建立了隧道车辆安全跟驰模型,能够对车辆风险驾驶行为进行动态估计。陈丰等^[14]通过大流量隧道口车辆运行时空轨迹分析,建立了基于碰撞时间的隧道口追尾隐患概率模型。该方向研究多针对个体车辆运行特性进行安全分析与建模^[15-18],缺乏隧道交通整体运行状态与事故风险潜在关联解析,也未充分发挥隧道全域检测数据对车辆分布特性精细刻画的优势,限制了隧道内运行风险状态评估效果与实际工程应用价值。

本文面向隧道交通风险辨识与主动防控的应用需求,构建时空Transformer网络对隧道运行风险进行动态辨识。该模型以隧道交通流全息检测与关键断面集计数据为输入;通过空间卷积与时序LSTM,对隧道交通流不同运行状态下时空分布特征进行无监督提取;利用Transformer网络大样本训练,以捕获隧道交通状态在高维风险特征空间中的分布与差异;整体实现对隧道内风险状态的动态评估,采用真实隧道交通运行数据数据验证方法对隧道运行风险评估的有效性。

1 隧道交通流运行风险动态评估方法

本文提出了基于时空Transformer网络的隧道交通运行风险动态辨识方法,其整体框架如图1所示。该方法分别以隧道全域交通流检测数据与关键断面参数集计统计数据为输入以获取不同层面的交通运行状态特征;隧道全域交通流检测数据通过空间信息栅格化处理,对隧道内运行车辆位置进行实时表达,然后通过CNN的空间特征卷积与长短时记忆网络(LSTM)的时序规律提取隧道内车辆分布的全域时空特征;关键断面参数集计统计数据将通过多通道LSTM独立提取不同断面交通参数的时许特征,利用特征拼接与全连接层特征降维,获得隧道内交通流关键点集计统计融合特征;最后将全域时空特征与集计统计特征联合输入Transformer网络中,通过大样本训练在不同交通状态下的运行特征在高维空间中分

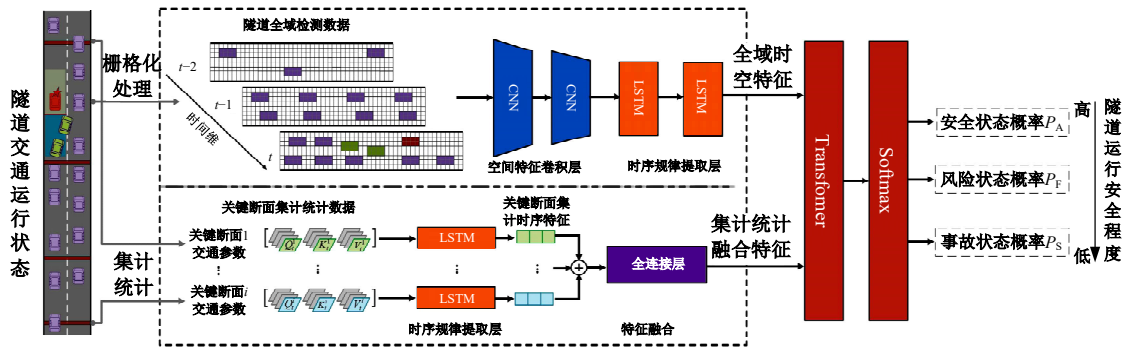


图 1 基于时空 Transformer 网络的隧道运行风险评估框架

Fig. 1 Tunnel safety evaluation framework based on spatial-temporal Transformer network

布差异,并利用 Softmax 层输出最终的运行状态评估结果。

1.1 隧道交通运行数据预处理

本文方法所用隧道交通运行数据包括两类:一是由全域毫米波雷达或多相机连续跟踪技术采集的隧道全域检测数据,该数据能够对每个车辆在隧道内的运行状态(包括空间位置、行驶速度等)进行精细刻画与动态表述。二是由隧道关键断面检测设备提供的断面集计统计数据,该数据能够反映隧道不同断面交通流统计参数。两类数据协同输入能够提供更全面且精确的隧道交通状态信息,为风险辨识提供信息基础。

(1)隧道全域检测数据栅格化处理

为了便于后续网络模型计算与特征学习,首先需要对隧道风险评估区域范围进行栅格化处理。根据隧道几何条件,采用固定空间滑窗 l 对整个隧道监控区域进行栅格化处理抽象,可将整个隧道整体抽象为 $S \times L$ 尺寸的矩阵,其中 $L = \text{隧道长度}/l, S = \text{隧道宽度}/l$ 。滑动窗口大小由检测区域范围与风险状态检测需求决定,建议空间滑窗 l 取值为 $1 \sim 5 \text{ m}$ 。在 t 时刻,由检测器获取的隧道信息经栅格化处理可转化为:

$$\begin{cases} \mathbf{X}_t = \begin{bmatrix} x_{1,1} & \cdots & x_{1,L} \\ \vdots & & \vdots \\ x_{s,1} & \cdots & x_{s,L} \end{bmatrix} \\ x_{s,L} = \begin{cases} 0, \text{无车辆占据} \\ 1, \text{有车辆占据} \end{cases} \end{cases} \quad (1)$$

栅格矩阵 \mathbf{X}_t 为后续深度时序卷积网络输入的基础数据;当给定一组时序矩阵数据 $[\mathbf{X}_{t-m}, \mathbf{X}_{t-m+1}, \dots, \mathbf{X}_t]$,能够反映时间范围 m 隧道内部车辆的运行状况,包括各车辆的空间位置、相对距离以及速度等信息。

(2)关键断面交通参数集计统计

以任一隧道断面 i 为例,计算该断面时间间隔 $m \times$ 内的交通流量 Q 、时间占有率 K 与车辆平均速度 V ;将其按顺序拼接为一组交通流参数向量 $[Q^i, K^i, V^i]$,反映了时刻 t 断面 i 的交通参数统计描述。对于隧道各断面交通参数,均按相同时间间隔与拼接顺序处理,并作为模型输入。

1.2 时空 Transformer 网络与计算原理

图 1 给出时空 Transformer 网络框架,能够实现隧道内车辆运行特性无监督提取与学习,达到实时交通风险评估的目的。其网络基本单元层主要包括 CNN 空间特征卷积层、LSTM 时序规律提取层、全连接特征融合层、Transformer 风险评估层与 Softmax 状态分类层,其具体网络层计算原理如下。

(1)CNN空间特征卷积层

图 2 给出了 CNN 空间特征卷积层的卷积操作过程示意图,给定原始栅格矩阵 \mathbf{X}_t 时,通过卷积核与原始矩阵的滑动卷积运算实现隧道内车辆运行空间特征的提取,并通过多层 CNN 卷积层^[19]叠加操作,获得更大的空间感受野与更深层次的空间特征。本文采用 CNN 空间特征卷积层的计算过程可抽象为式(2)(3)。

$$S(u, v) = \sum_{s=-\infty}^{\infty} \sum_{l=-\infty}^{\infty} x_{s+u, l+v} \cdot \psi_{s, l} \cdot \chi(s, l) \quad (2)$$

$$\chi(s, l) = \begin{cases} 1, & 0 \leq s, l \leq n \\ 0, & \text{其他} \end{cases} \quad (3)$$

式中: $S(u, v)$ 为空间特征矩阵中 (u, v) 位置特征值; x 为隧道栅格矩阵 \mathbf{X}_t 对应元素值; ψ 为卷积核; χ 为通过卷积尺寸 n 控制卷积范围。通过不断调整 ψ 参数,实现对不同空间方向与特征的提取。

(2)LSTM时序特征提取层

长短时记忆网络-LSTM^[20]是目前处理时序




图 2 CNN 空间特征卷积层结构

Fig. 2 CNN-space feature convolution layer structure

信息最为广泛的单元层结构,其通过链式循环结构与门控操作实现对数据时间规律的提取,因此引入本文时空 Transformer 网络中用于时序特征提取。

图 3 给出了本文网络中的时序特征提取结构示意图,以经 CNN 卷积操作提取后的空间特征序列为输入,并通过 LSTM 中的输入门 i_t 、遗忘门 f_t 、输出门 o_t 间的信息交互,以及单元状态 θ_t 的迭代传递,对 t 时刻空间特征矩阵 S_t 中的时序特征进行提取,其计算过程可抽象为以下公式:

$$f_t = \sigma(W_f \cdot [F'_{t-1}, S_t] + b_f) \quad (4)$$

$$i_t = \sigma(W_i \cdot [F'_{t-1}, S_t] + b_i) \quad (5)$$

$$o_t = \sigma(W_o \cdot [F'_{t-1}, S_t] + b_o) \quad (6)$$

$$\theta_t = f_t \cdot \theta_{t-1} + i_t \cdot \sigma(W_\theta \cdot [F'_{t-1}, S_t] + b_\theta) \quad (7)$$

$$F'_t = o_t \cdot \tanh(\theta_t) \quad (8)$$

式中: f 、 i 、 o 、 θ 分别对应相应的遗忘门、输入门、输出门以及单元状态; W 为相应权重向量; b 为相应偏置项; $\sigma(\cdot)$ 为激活函数; F' 为经 LSTM 处理后的时序特征。其实质是对隧道内交通运行过程中模式特征的提取,为后续的隧道运行风险状态评估,提供更有效的深层特征与更准确的判定依据。




图 3 LSTM 时序特征提取层结构

Fig. 3 LSTM-sequence feature extraction layer structure

(3) 全连接特征融合层

全连接层设置目的是对多个关键断面经 LSTM 处理后的集计时序特征进行融合与降维。

当关键卡口 i 交通流参数向量 $[Q_i^t, K_i^t, V_i^t]$ 经过 LSTM 时序特征提取得到对应时序特征 F_i^t , 将全部断面时序特征进行拼接组合得到集计特征 F_i^{all} 作为全连接层输入,其计算过程可抽象为如下公式:

$$F_i^{\text{AGG}} = \sigma(W_{\text{FC}} \cdot F_i^{\text{all}} + b_{\text{FC}}) \quad (9)$$

式中: F_i^{AGG} 为集计统计融合特征; W_{FC} 与 b_{FC} 为全连接层权重向量与偏置项。

(4) Transformer 风险评估层

Transformer 模型是一种用于处理序列数据的深度学习结构,优势在于通过自注意力机制 (Self-Attention) 可以处理输入序列中任意位置特征间的依赖关系,并采用编解码结构提高输入信息的提取与表达能力^[21]。

图 4 给出了本文 Transformer 网络结构,将全域时空特征 F_i^{SP} 与集计统计特征 F_i^{AGG} 拼接形成联合特征 $F_i = [F_i^{\text{SP}}, F_i^{\text{AGG}}]$ 作为输入。Transformer 层计算过程可以抽象为如下步骤:

Query 位置编码 Q^{Tr} 、Key 键编码 K^{Tr} 、值编码 V^{Tr} 计算式为:

$$Q^{\text{Tr}} = F_i W_{Q^{\text{Tr}}}, K^{\text{Tr}} = F_i W_{K^{\text{Tr}}}, V^{\text{Tr}} = F_i W_{V^{\text{Tr}}} \quad (10)$$

计算注意力分数:

$$\text{Att}(Q^{\text{Tr}}, K^{\text{Tr}}) = \text{Softmax} \left(\frac{Q^{\text{Tr}}(K^{\text{Tr}})^{\text{T}}}{\sqrt{d_{\text{key}}}} \right) \quad (11)$$

特征加权和计算输出:

$$\tilde{F}_i = \text{Att}(Q^{\text{Tr}}, K^{\text{Tr}}) \cdot V^{\text{Tr}} \quad (12)$$

式中: W 为相应权重向量; d_{key} 为 Key 键编码维度; \tilde{F}_i 为自注意力后特征。

通过图 4 的多层注意力叠加与编码-解码结构,可提升最后高维特征输出的交通风险表达能力。

(5) Softmax 风险状态分类层

经 Transformer 风险评估层输出的高维特征输出 F 已经具备交通风险表达与区分能力,将其输入 Softmax 层给出多分类结果。其风险状态划分过程抽象为:

$$\hat{y}_i = S(F)_i = \frac{e^{F_i}}{\sum_{j=1}^C e^{F_j}} \quad (13)$$

式中: C 为风险状态分类数; \hat{y}_i 为不同类别的概率值,取值范围为 $[0, 1]$ 。这里需要注意的是,隧道

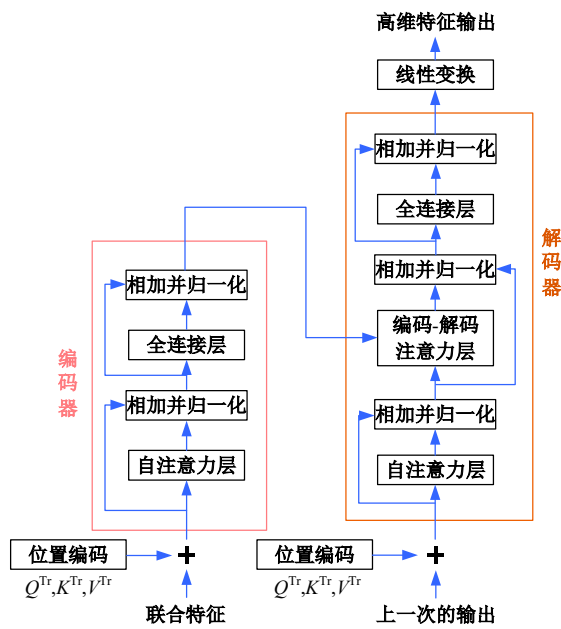


图 4 Transformer 风险评估层结构

Fig. 4 Transformer risk evaluation layer structure

风险状态评估实质是多分类问题, Softmax 最终将给出不同类别对应所属概率值, 而分类数 C 是由隧道风险划分的粒度需求设定的。

(6) 目标函数设置

网络训练目标是令时空 Transformer 模型对隧道风险状态预测结果与实际风险状态结果越接近越好, 通过大样本网络训练最终可以使整体网络模型依据隧道交通运行时空特征对隧道风险状态的准确估计。因此, 网络目标函数设置为:

$$\Phi = \sum_{j=1}^N [y_j - \max(\hat{y}_{j,1}, \dots, \hat{y}_{j,c})] \quad (14)$$

式中: N 为训练样本数; y_j 为样本 j 真实风险状态类别; $\max(\hat{y}_{j,1}, \dots, \hat{y}_{j,c})$ 为模型对于样本 j 的预测风险类别。

1.3 基于时空 Transformer 网络的隧道风险评估流程

本文提出的基于时空 Transformer 网络的隧道交通运行风险评估流程如下。

步骤 1 数据处理与组织: 隧道全域检测数据与关键断面集统计数据是本文方法风险评估主要依据; 按 1.1 节预处理方法分别处理相应数据, 选取二者采用频率最小公倍数作为风险评估模型评估频率, 并对两类数据按时序向量形式组织数据。

步骤 2 数据风险标注: 在网络训练前需要根据实际隧道内部风险状态划分等级需求, 给定

隧道风险状态划分类别 C , 然后对历史样本标定其相应的类别标签。本文模型将风险类别分为 3 类: 安全状态、风险状态与事故状态。隧道内发生存在事故至事故处置完成的交通数据标记为事故状态。根据文献[22]的相关研究, 事故发生前 30 min 内的交通参数蕴含风险信息, 标记为风险状态, 同时考虑隧道交通饱和度越高, 车流密度也越大, 车辆间相互干扰也越强, 发生交通事故概率也越高, 将实际交通量超过 70% 隧道通行能力的饱和状态, 同样标记为风险状态。对未发生交通事故的隧道畅通状态标记为安全状态。

步骤 3 风险评估网络训练: 以最小化 Φ 为优化目标, 利用大样本历史数据对时空 Transformer 网络模型进行训练, 使网络参数能够对不同隧道车辆运行状态的潜在特征进行学习, 并能够完成交通状态特征与风险类别的高维映射。

步骤 4 动态风险辨识: 将实时隧道全域检测数据与关键断面集统计数据按步骤 1 进行组织, 输入步骤 3 训练好的时空 Transformer 网络模型中, 给出相应的隧道风险状态。

步骤 5 采取相应风险管控措施: 在实际应用中, 当步骤 4 模型计算当前隧道内车辆运行处于自由流安全状态时, 不需要对隧道运行采用额外调控措施; 当隧道内车辆处于风险状态时, 需要采取相应交通管控与诱导措施, 改善隧道内车辆运行状态, 降低隧道事故发生风险; 当隧道内车辆运行处于事故状态时, 需要采取合理救援措施进行事故援助, 并采取相应交通管制方案, 避免隧道二次事故发生。

2 实验数据分析

2.1 实验数据来源与标定

本文选用山东省济南至潍坊段某隧道全域交通运行数据用于试验验证, 隧道长度为 814 m, 隧道宽度为 8 m, 图 5 展示了该隧道交通全域监控过程。实验将空间滑窗设为 2 m, 因此隧道空间栅格矩阵的尺寸为 407×4 ; 交通流参数统计关键断面数量为 6, 平均间隔 140 m。数据采集范围选用 2022 年 10 月 1 日至 2023 年 6 月 30 日; 全域检测数据更新频率为 30 s 计算一次, 关键断面集统计频率为 2 min。

根据 1.3 节步骤 2 数据风险标注方式标注训练数据与测试数据。结合事故记录, 在数据统计




图5 隧道风险状态仿真示意图

Fig. 5 Simulation diagram of tunnel risk state

范围内,统计获得的有效事故状态样本为450组,将其随机划分为训练集(300组)与测试集(150组)。在实际中,有效的风险状态与安全状态样本远大于事故样本,为了避免网络模型训练过程的过拟合与欠学习,保证3类状态下特征提取与风险辨识效果,从风险状态与安全状态样本库中各自随机抽取900组,并将其随机划分为训练集(600组)与测试集(300组),即3类样本在训练与测试中的比例为2:2:1。

2.2 网络参数设定

深度时序卷积网络参数设置是影响隧道安全状态评估的关键,主要参数包括CNN空间卷积层数与节点数 n_{layer}^{CNN} 、 n_{node}^{CNN} , LSTM层数与节点数 n_{layer}^{LSTM} 、 n_{node}^{LSTM} , Transformer层的编解码层数 n_{layer}^{Trans} 、特征向量维度 d_F^{Trans} 、注意力查询个数 n_{Att}^{Trans} , Softmax全连接层数与节点数 $n_{layer}^{全连接}$ 、 $n_{node}^{全连接}$ 。为了使整体网络达到最佳的状态分类效果,实验网络参数采用网格搜索法进行优化,确定最佳参数组合为:
 $n_{layer}^{CNN} = 3$ 、 $n_{node}^{CNN} = 128 - 64 - 32$ 、 $n_{layer}^{LSTM} = 2$ 、 $n_{node}^{LSTM} = 32 - 32$ 、 $n_{layer}^{Trans} = 8 - 8$ 、 $d_F^{Trans} = 256$ 、 $n_{Att}^{Trans} = 3$ 、 $n_{layer}^{全连接} = 1$ 、 $n_{node}^{全连接} = 16$ 。其他参数的相关设置如表1所示。

表1 深度时序卷积网络其他相关参数设置

Table 1 Other parameters setting of deep sequential convolutional network

相关参数	设定值
激活函数 σ	Relu
网络学习率	0.001
最大训练次数 T_{train}	30 000
最小批训练尺寸	10
式(13)中分类数	3

2.3 评价指标

隧道运行风险评估属于典型的多分类任务,但对不同风险等级状态评估本身属于二分类问题。为了统一评价不同算法的评估性能,实验选

取混淆矩阵方法(见表2)对实验结果进行分析,利用精确率(PRE)、召回率(REC)、 F_1 分数(F_1 -score)与准确率(ACC)作为评价指标^[22],其计算公式如下:

$$PRE = \frac{TP}{TP + FP} \quad (15)$$

$$REC = \frac{TP}{TP + FN} \quad (16)$$

$$F_1\text{-score} = \frac{2PRE \cdot REC}{PRE + REC} \quad (17)$$

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \quad (18)$$

表2 隧道风险状态评估结果混淆矩阵

Table 2 Tunnel risk state evaluation result confusion matrix

真实类别	评估结果	
	正例	反例
正例	真正例 TP	假反例 FN
反例	假正例 FP	真反例 TN

2.4 对比实验分析

为了验证本文方法融合隧道全域数据与关键断面集计数数据对隧道交通风险评估的有效性,将本文方法与仅利用隧道全域数据或断面集计数数据的方法进行对比实验,如表3与图6所示。全面、准确描述隧道交通运行状态是提升风险评估效果的关键。通过图6中的混淆矩阵对比可以看出,仅依赖集计数数据风险评估存在风险状态与安全状态、事故状态的分类模糊情况,整体准确精度较差,是由于断面集计数数据仅能反映隧道交通流时空统计特性,会淹没车辆运行特征与行为信息;隧道全息数据则能够对隧道交通运行状况进行更为全面的描述,因此其对不同风险状态的分类评估效果更好。综合对比证明,本文方法的风险评估效果最好;其原因在于如图1的方法结构会充分融合两类数据对隧道交通运行的特征表达优势,

表3 不同数据利用情况隧道风险状态评估结果对比

Table 3 Comparison of tunnel risk state estimation results under different data utilization conditions

模型	精确率	召回率	F_1 分数	准确率/%
全域数据+时空Transformer	0.941 3	0.931 5	0.937 7	93.12
断面数据+时空Transformer	0.910 2	0.898 1	0.904 2	90.37
本文方法	0.960 3	0.963 2	0.964 1	96.18




图 6 不同数据利用情况隧道风险状态评估混淆矩阵

Fig. 6 Confusion matrix of tunnel risk state estimation results under different data utilization conditions

学习不同交通状态在风险特征空间中的分布与差异,其风险评估结果相较单一数据更为准确且稳定。

由于目前隧道风险评估方法主要侧重于单一数据应用,为客观验证本文方法的先进性,对比实验将在统一数据输入条件下进行。

在输入数据为隧道全域检测数据情况下,将本文方法与支持向量机(SVM)^[23]、极端梯度提升决策树(XGBoost)^[24]进行对比实验分析。为了进一步验证本文网络模型对空间与时序特征的有效性,额外进行了网络结构破坏实验,包括:删除CNN空间特征提取层,保留时序规律提取与风险状态评估部分(LSTM+Transformer);与删除LSTM时序规律提取层,保留空间特征提取与风险状态评估部分(CNN+Transformer),以式(1)隧道栅格化后的全域交通数据作为模型输入。表

4给出了不同算法在全域数据上的隧道风险状态评估表现。从横向对比实验结果可以看出,基于深度学习的分类方法的风险状态评估性能要显著优于常规分类方法(SVM、XGBoost),其原因是常规分类算法无法较好地处理维度较高的隧道全域数据,而深度学习模型可以对原始数据进行高维特征提取,在降低数据维度的同时捕捉更有区分能力的隧道交通运行风险特征。同时,通过本文方法与CNN、LSTM分别结合Transformer的结构变体的对比,可以得出针对隧道全域检测数据设置的CNN空间特征提取层与LSTM时序特征提取层的结构合理,能够在提取隧道交通时序特征的同时,提升风险评估的有效性。此外,图7给出了不同算法的混淆矩阵,证明了本文方法即使在仅利用全域检测数据情况下,对在不同隧道运行风险等级下,仍具有可接受的稳定预测性能,能灵敏反映不同隧道风险的潜在差异。通过表4实验结果也证明了隧道全域检测数据的时空特征提取越精确全面,风险评估精度越高。

表 4 不同方法隧道风险状态评估结果对比(全域数据)

Table 4 Comparison of tunnel risk state estimation results of different methods(Holographic detection data)

模型	精确率	召回率	F ₁ 分数	准确率/%
SVM	0.773 2	0.763 1	0.771 5	77.32
XGBoost	0.738 7	0.753 6	0.752 2	75.57
CNN+Transformer	0.879 8	0.858 1	0.868 8	87.02
LSTM+Transformer	0.895 2	0.905 3	0.892 4	90.24
本文方法(全域数据)	0.941 3	0.931 5	0.937 7	93.12

在输入数据为隧道关键断面集数据情况下,隧道风险评估等同于基于交通流参数的异常状态检测方法。实验选取了如下4种典型的检测方法进行对比验证:①贝叶斯分类^[25]:利用正常、风险与事故样本参数统计分析,计算对应条件概率以此估计测试样本所属类别隶属度与状态;②随机森林^[26]:通过集成学习思想对多分类树进行训练,并对测试样本进行分类判别;③XGBoost^[24]:利用梯度提升思想,通过迭代地训练一系列弱学习器并将它们组合起来进行分类;④LSTM+Softmax:删除本文方法Transformer层,直接利用LSTM提取时序特征进行分类。表5给出了不同算法在断面集数据上的隧道风险状态评估表现。相较于浅层特征学习模型(贝叶斯分类、随机森林),XGBoost、LSTM+Softmax与本

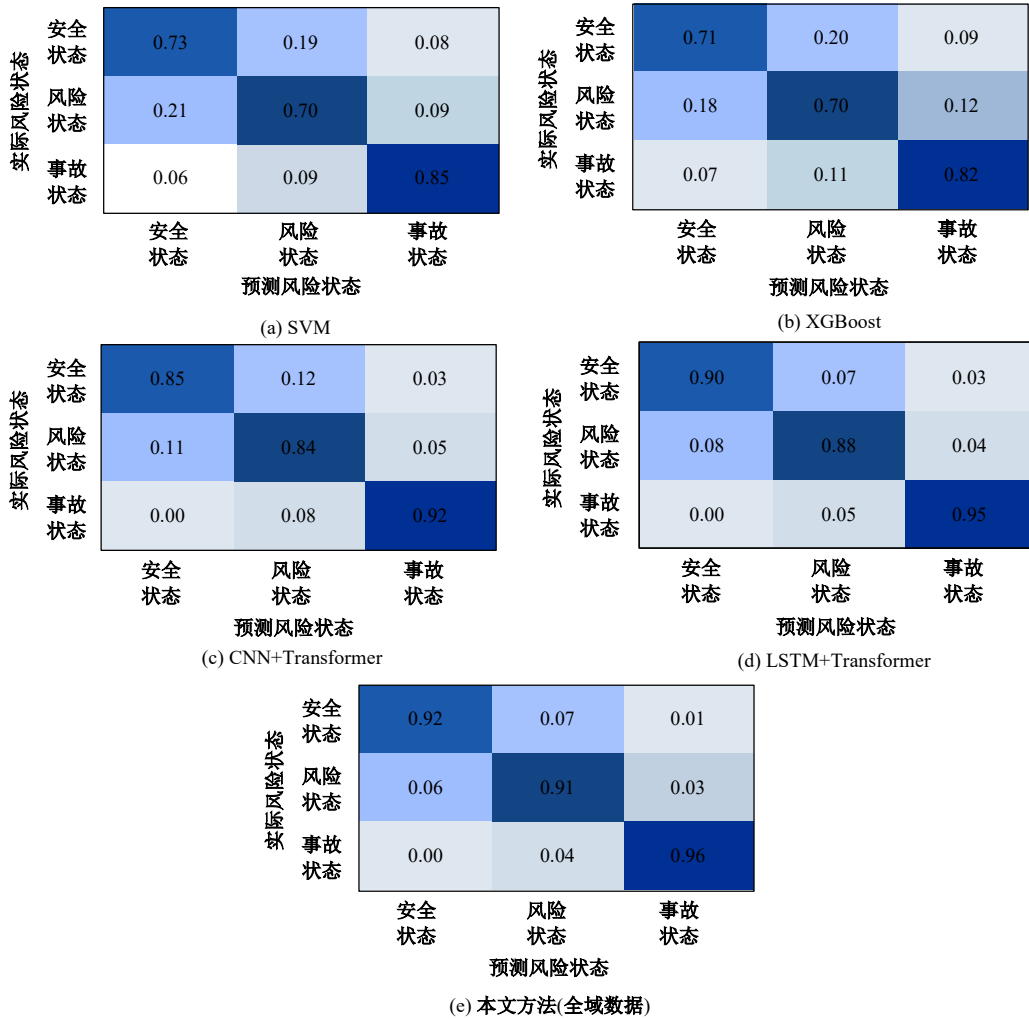


图 7 不同隧道风险状态评估方法的混淆矩阵(全域数据)

Fig. 7 Confusion matrix of different tunnel risk state estimation methods(Holographic detection data)

表 5 不同方法隧道风险状态评估结果对比
(断面集计数据)

Table 5 Comparison of tunnel risk state estimation results of different methods(Key cross-section aggregation data)

模型	精确率	召回率	F_1 分数	准确率/%
贝叶斯分类	0.798 2	0.815 4	0.806 7	80.57
随机森林	0.803 7	0.821 4	0.815 4	81.37
XGBoost	0.849 8	0.868 1	0.858 8	86.02
LSTM+Softmax	0.836 1	0.849 8	0.833 7	84.24
本文方法 (断面集计数据)	0.910 2	0.898 1	0.904 2	90.37

文方法能够挖掘断面集计数据中隐含的深层时序特征,其风险评估效果更好。相较于全域数据,在相同隧道交通状态下基于断面集计数据的风险评估精度更为稳定,是由于集计统计方式对交通流特征描述更显著直接,数据维度低对模型特征提

取能力要求不高。但是,当模型特征提取能力增强时,全域数据对于隧道交通风险评估的价值要优于断面集计数据。

综合来看,本文方法能够利用隧道全域数据与关键断面集计数据对隧道交通运行的特征表达优势,对不同风险状态能够进行差异化稳定区分,每类风险状态评估精度达 93% 以上,整体评估精度约为 96%。

3 结束语

本文结合隧道全域检测数据与关键断面集计数据,构建了基于时空 Transformer 网络的隧道运行风险状态动态辨识方法。该方法利用空间 CNN 卷积与时序 LSTM 实现隧道交通运行状态时空分布特征的有效提取,并利用 Transformer 实现对隧道交通风险划分与评估。利用真实隧道监测数据证明本文方法隧道交通风险评估精度约为

96%,能够更好地为隧道安全监控与事故预防提供参数支撑。本文隧道风险评估方法仅利用隧道交通流检测信息,未来可考虑引入光照、温湿度、烟感传感器数据对隧道运行安全进行更为全面评估,以提升隧道安全运营管理水平。

参考文献:

- [1] 周昱. 基于贝叶斯网的高速公路隧道交通事故预测及应急预案研究[D]. 西安:长安大学公路学院, 2018.
Zhou Yu. Research on traffic accident prediction and contingency plan of expressway tunnel based on Bayesian network[D]. Xi'an: Highway School, Chang'an University, 2018.
- [2] 牛文静. 高速公路隧道(群)交通流特征研究[D]. 西安:长安大学公路学院, 2012.
Niu Wen-jing. Research on the traffic flow characteristics of the freeway tunnel (group) [D]. Xi'an: Highway School, Chang'an University, 2012.
- [3] Tadaki S, Nishinari K, Kikuchi M, et al. Observation of congested two-lane traffic caused by a tunnel [J]. Journal of the Physical Society of Japan, 2002, 71(9): 2326-2334.
- [4] 周林英, 韩静, 赵忠杰. 事件状态下高速公路隧道群的交通流特性分析[J]. 中国科技论文, 2017, 12(7): 839-844.
Zhou Lin-ying, Han Jing, Zhao Zhong-jie. The traffic flow characteristics of highway tunnel groups based on cellular automata under the traffic incidents[J]. China Sciencepaper, 2017, 12(7): 839-844.
- [5] 倪娜. 山区高速公路隧道密集段交通特性及安全保障技术研究[D]. 西安:长安大学公路学院, 2017.
Ni Na. Research on traffic characteristics and security assurance technologies of tunnel intensive section in mountainous expressway[D]. Xi'an: Highway School, Chang'an University, 2017.
- [6] Tian L L, Jiang J C, Tian L. Safety analysis of traffic flow characteristics of highway tunnel based on artificial intelligence flow net algorithm[J]. Cluster Computing-The Journal of Networks Software Tools and Applications, 2019, 22: 573-582.
- [7] 李舒涵. 高速公路隧道交通状态判别研究[D]. 西安:长安大学公路学院, 2020.
Li Shu-han. Research on traffic state identification of highway tunnel[D]. Xi'an: Highway School, Chang'an University, 2020.
- [8] 张俊儒, 燕波, 龚彦峰. 隧道工程智能监测及信息管理系统的研究现状与展望[J]. 地下空间与工程学报, 2021, 17(2): 567-579.
Zhang Jun-ru, Yan Bo, Gong Yan-feng. Research status and prospects of intelligent monitoring technology and information management system for tunnel engineering[J]. Chinese Journal of Underground Space and Engineering, 2021, 17(2): 567-579.
- [9] Lu Y, Liu S, Tian F, et al. Studies and prospects of technologies for monitoring highway tunnel fire[J]. IOP Conference Series Earth and Environmental Science, 2021, 634(1): No. 012099.
- [10] Zhao Y, Zhang S, Ma C. Application of video detection technology in tunnel traffic safety monitoring system[J]. IPPTA: Quarterly Journal of Indian Pulp and Paper Technical Association, 2018, 30(8): 376-381.
- [11] Li S, Zhou Q, Wang K. Video-based tunnel luminance detection[J]. Automation in Construction, 2019, 107(11): No. 102900.
- [12] 贾磊, 李清勇, 俞浩敏. 基于监控视频的隧道交通冲突预测方法[J]. 北京交通大学学报, 2023, 47(3): 61-69.
Jia Lei, Li Qing-yong, Yu Hao-min. Method for predicting traffic conflicts in tunnels based on monitoring videos[J]. Journal of Beijing Jiaotong University, 2023, 47(3): 61-69.
- [13] Chen Z, Wen H. Modeling a car-following model with comprehensive safety field in freeway tunnels[J]. Journal of Transportation Engineering Part A-Systems, 2022, 148(7): No. 04022040.
- [14] 陈丰, 姜茗馨, 朱明, 等. 基于碰撞时间的大流量隧道口追尾隐患概率模型构建[J]. 北京交通大学学报, 2020, 44(6): 90-96.
Chen Feng, Jiang Ming-xin, Zhu Ming, et al. A rear-end collision probability model at heavy-traffic tunnel entrance based on time-to-collision[J]. Journal of Beijing Jiaotong University, 2020, 44(6): 90-96.
- [15] 陈娟娟. 公路隧道交通安全状态特征选择与评估方法研究[D]. 福州:福州大学土木工程学院, 2014.
Chen Juan-juan. Research on traffic safety status feature selection and evaluation methods of highway tunnel[D]. Fuzhou: School of Civil Engineering, Fuzhou University, 2014.
- [16] 王玉婷. 特长隧道交通事故车辆排队长度演变分析与建模[D]. 重庆:重庆交通大学交通运输学院, 2022.
Wang Yu-ting. Analysis and modeling of vehicle queuing length evolution by traffic accident of extra-long tunnel [D]. Chongqing: College of Traffic and

- Transportation, Chongqing Jiaotong University, 2022.
- [17] 郑凯. 基于多源数据的城市桥隧结合段交通运行风险预测方法研究[D]. 重庆: 重庆交通大学交通运输学院, 2019.
- Zheng Kai. Research on traffic operation risk prediction method for urban bridge tunnel combined sections based on multisource data[D]. Chongqing: College of Traffic and Transportation, Chongqing Jiaotong University, 2019.
- [18] Tympkianaki A, Koutsopoulos H N, Jenelius E. Anatomy of tunnel congestion: causes and implications for tunnel traffic management[J]. Tunnelling and Underground Space Technology, 2019, 83:498-508.
- [19] Gu J X, Wang Z H, Kuen J, et al. Recent advances in convolutional neural networks[J]. Pattern Recognition, 2018, 77, 354-377.
- [20] Hochreiter S, Schmidhuber J. Long short-term memory[J]. Neural Computation, 1997, 9(8): 1735-1780.
- [21] Tay Y, Dehghani M, Bahri D, et al. Efficient transformers: a survey[J]. ACM Computing Surveys, 2022, 55(6): 1-28.
- [22] 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.
- [23] 李晓璐, 于昕明, 杜崇. 基于权值优化的FCM-MSVM算法及其在高速公路状态判别中的应用[J]. 北京交通大学学报, 2018, 42(4): 72-78, 84.
- Li Xiao-lu, Yu Xin-ming, Du Chong. FCM-MSVM algorithm based on weight optimization and its application in state identification of freeway[J]. Journal of Beijing Jiaotong University, 2018, 42(4): 72-78, 84.
- [24] 张博. 基于机器学习的交通状态短时预测方法研究[D]. 长春: 吉林大学软件学院, 2018.
- Zhang Bo. Research on short-term prediction of traffic state based on machine learning[D]. Changchun: College of Software, Jilin University, 2018.
- [25] Liu Q, Lu J, Zhao K, et al. Multiple Naive bayes classifiers ensemble for traffic incident detection[J]. Mathematical Problems in Engineering, 2014(1): No. 383671.
- [26] 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 incident detection based on random forest[J]. Journal of Southeast University(English Edition), 2014, 30(1): 88-95.