

文章编号: 1005-0523(2026)02-0028-10



联合分布式宏应变与机器学习的铁路 桥梁监测预警方法

吴必涛^{1,2}, 吴志鹏¹, 樊小林³, 周珍伟¹, 卢华喜¹

(1. 华东交通大学土木建筑学院, 江西 南昌 330013; 2. 华东交通大学山区土木工程安全与韧性全国重点实验室, 江西 南昌 330013; 3. 中铁桥隧技术有限公司, 江苏 南京 210061)

摘要: 探究随机列车荷载下联合分布式宏应变监测与机器学习的桥梁评估预警方法, 实现铁路桥梁分布式快速评估。建立列车-轨道-桥梁耦合振动三维精细化有限元模型, 应用荷载统计分析方法构建与实际列车运营相适应的随机车流模型, 基于分布式监测原理, 提出分布式宏应变影响线面积作为桥梁预警的指标设计预警区间评估预警方法; 进一步, 通过多种刚度退化工况仿真分析, 构建随机列车荷载下分布式宏应变监测数据样本库, 对比研究4种机器学习方法对桥梁损伤定量与定位的准确率。结果表明, 4种机器学习都能够对桥梁结构的局部损伤进行定位和定量, 平均识别准确率都达到了90.0%, 其中KNN模型和SVM模型在桥梁损伤定量的测试中表现最好, 识别准确率均为95.0%, SVM模型在桥梁结构损伤定位的测试中表现最好, 识别准确率为98.3%。联合分布式宏应变监测与机器学习的桥梁评估方法具有可行性, SVM模型在桥梁结构损伤定位的测试中表现最好, KNN模型和SVM模型在桥梁损伤定量的测试中表现最好, 综合分析, SVM在桥梁损伤定位与损伤定量分析表现最优。

关键词: 分布式宏应变; 桥梁健康监测; 机器学习; 安全预警; 损伤识别

中图分类号: U446

文献标志码: A

本文引用格式: 吴必涛, 吴志鹏, 樊小林, 等. 联合分布式宏应变与机器学习的铁路桥梁监测预警方法[J]. 华东交通大学学报, 2026, 43(2): 28-37.

Railway Bridge Monitoring and Early Warning Method Combining Distributed Macro-Strain and Machine Learning

Wu Bitao^{1,2}, Wu Zhipeng¹, Fan Xiaolin³, Zhou Zhenwei¹, Lu Huaxi¹

(1. School of Civil Engineering and Architecture, East China Jiaotong University, Nanchang 330013, China;

2. State Key Laboratory of Safety and Resilience of Civil Engineering in Mountain Area, East China Jiaotong University, Nanchang 330013, China; 3. China Railway Bridge and Tunnel Technology Co., Ltd., Nanjing 210061, China)

Abstract: In order to investigate the early warning method for bridge assessment under random train loading with joint distributed macro-strain monitoring and machine learning, and to realize the distributed rapid assessment of railroad bridges, this study establish a three-dimensional refined finite element model of vehicle-rail-bridge coupled vibration. It is also apply load statistical analysis methods to construct a stochastic traffic flow model that is suitable for actual train operation, and based on the principle of distributed monitoring, propose a distributed macro-strain influence line area as the indicator design warning interval evaluation warning method

收稿日期: 2025-01-13

基金项目: 国家自然科学基金项目(52368042); 江西省主要学科学术和技术带头人培养计划(20225BCJ23025); 江西省优秀青年基金项目(20242BAB22008)

for bridge warning; Furthermore, through simulation analysis of various stiffness degradation conditions, a distributed macro-strain monitoring data sample library under random train loads was constructed to compare and study the accuracy of 4 machine learning methods in quantifying and locating bridge damage. The results show that all 4 types of machine learning are able to localize and quantify the localized damage of bridge structures with an average recognition accuracy of 90.0%, with the KNN model and the SVM model performing the best in the test of quantifying bridge damage, both with 95.0% recognition accuracy, and the SVM model performing the best in the test of locating the damage of the bridge structure, with a recognition accuracy of 98.3%. The joint distributed macro-strain monitoring and machine learning approach for bridge assessment has feasibility, SVM model performs best in the test of bridge structure damage localization, KNN model and SVM model perform best in the test of bridge damage quantification, and in the comprehensive analysis, SVM performs best in bridge damage localization and damage quantification analysis.

Key words: distributed macro-strain; bridge health monitoring; machine learning; safety warning; damage identification

Citation format: WU B T, WU Z P, FAN X L, et al. Railway bridge monitoring and early warning method combining distributed macro-strain and machine learning[J]. Journal of East China Jiaotong University, 2026, 43 (2): 28-37.

高速铁路桥梁在线路运行期间通常要承受列车往来的动载荷,再加上化学腐蚀和材料老化等外部环境不利因素,都会对桥梁的某些部件造成不同程度的表面和内部损坏^[1]。因此,应该加强对高铁桥梁的病害鉴定,对桥梁的健康状况进行安全预警,实施科学、严谨的桥梁监测和评估技术,以保障列车的行车安全,保证高速铁路桥梁的可靠性、安全性、结构完整性和耐久性^[2]。

目前,随着传感器技术和机器学习算法的进步,桥梁结构预警技术正在快速发展。这些技术的广泛应用有助于及时发现可能存在的问题,实施适当的解决方案,并确保桥梁结构的安全运行^[3]。张耘^[4]基于泗安塘大桥的动态应变监测数据,利用长短期记忆神经网络构建了基于内力再分布效应的桥梁损伤预警系统。张远传^[5]研究了基于云计算技术的大跨度桥梁健康监测和预警系统。成功创建了健康监测和预警系统并提出了多指标预警技术。刘广逊^[6]对大跨度铁路桥的结构响应预警系统进行了研究。通过构建基于 PCA 的预警阈值、车辆荷载的 GPD 分布模型以及温度和结构反应的贝叶斯回归模型,实现了运营状态下结构响应的有效预警。曹晓龙^[7]对监测数据的时频域特性进行了统计分析以研究桥梁安全预警方法。通过建立时间序列 ARMA 模型、使用能谱预警技术和距离函数

指标,提出了桥梁多指标预警系统的基本设计方案。Ding 等^[8]研究利用大胜关大桥的长期横向振动数据建立了高速铁路桥梁列车安全预警方法。以主梁横向加速度均方根作为监测参数。使用 PCA 有效地消除了环境影响。所提出的方法可检测横向加速度的异常变化,适用于列车安全预警。Tan 等^[9]研究了一种斜拉桥健康状况动态预警方法,能够检测结构异常和确保安全运营,利用武汉某大桥的长期挠度监测数据,采用季节自回归集成移动平均(SARIMA)模型可预测温度效应并动态调整基准阈值。Li 等^[10]研究了一种考虑结构温度变化的斜拉桥异常索力的早期预警方法。该方法通过建立基准模型来描述健康索力与结构温度之间的正常关系,并通过分析识别索力与基准模型预测索力之间的残差来检测异常索力。建立了健康索力的频率-温度关系模型,构建了建模误差的均值控制图来检查预测误差,当预测误差超过控制限值时,将触发早期预警。

综上,虽然国内外学者对铁路桥梁健康监测技术进行了较多的研究,但大多数桥梁健康评估技术都是分析桥梁在当前状况下的整体刚度劣化情况或者以一个初始值进行分析,采用的监测方法均基于点式的应变传感器监测数据,无法实现分布式监测;另外,列车荷载的随机性对评估方法的精确性

有较大的影响,缺乏针对海量分布式监测数据的智能评估方法,随机列车荷载下铁路桥梁分布式监测评估方法有待进一步研究。为此,本文基于机器学习方法与分布式宏应变影响线原理,提出一种基于分布式宏应变与机器学习的桥梁健康监测与安全预警方法。通过将分布式宏应变影响线面积作为机器学习指标联合区间估计预警方法对模拟的损伤进行定位和定量,验证此方法在随机列车荷载下监测桥梁健康状况的可行性,对比研究了随机列车荷载下基于分布式宏应变监测的桥梁评估最优机器学习方法,基于分布式光纤光栅传感监测的应变数据,实现对高电磁干扰环境下铁路桥梁进行快速分布式监测评估,助力实现铁路桥梁损伤识别的简单化,快速化,高效化,为铁路桥梁的监测和安全预警提供借鉴参考。

1 基于分布式宏应变影响线的铁路桥梁损伤识别原理

光纤光栅传感技术由于抗电磁干扰、高精度、耐久性好、体积小、布设方便等优点广泛用于桥梁监测中,多个FBG传感器串联连接可实现分布式监测。传统点式的FBG传感器标距长度为3~10 cm,采用玄武岩纤维对传统点式的FBG传感器进行二次封装成为长标距应变传感器,传感器的监测标距长度可以达到1 m同时保持较高的监测精度,二次封装后的长标距传感器监测得到的应变被称为长标距应变或者宏应变^[8-10]。

如图1所示,简支梁全长为 L ,纵向弯曲刚度为 EI ,梁底布置 m 个标距为 l_e 的长标距FBG传感器,假设一单位移动荷载 P 从 A 端运动到 B 端。由材料力学知识可知正应力公式为 $\sigma = My/I$,由胡克定律 $\varepsilon = \sigma/E$,可得桥上任意一点的应变影响线表达式

$$\varepsilon(x) = \begin{cases} \frac{(L-x_i)yx}{EIL}, & 0 \leq x < x_i \\ \frac{(L-x)yx_i}{EIL}, & x_i \leq x \leq L \end{cases} \quad (1)$$




图1 长标距FBG传感器监测下的简支梁示意图
Fig. 1 Schematic diagram of simply supported beam monitored by long-gauge FBG sensor

式中: x_i 为测点距 A 端的距离, x 为荷载距 A 端的距离, y 为应力点到中性轴的垂直距离, I 为截面对中性轴的惯性距。

长标距FBG传感器监测的是覆盖范围内的平均应变,因此第 m 个传感器标距范围内的宏应变影响线表达式需要对上式在 $0 \leq x_i \leq L$ 区间进行积分并取均值,简化后得到

$$\bar{\varepsilon}_m(x) = \begin{cases} \frac{[2L - (2m-1)l_e]yx}{2(\bar{EI})_m L}, & 0 \leq x < (m-1)l_e \\ \frac{y}{2(\bar{EI})_m L} \left\{ -\frac{L}{l_e}x^2 + \left[\frac{2mL}{(m-1)l_e} - (2m-1) \right]x - (m-1)^2 l_e \right\}, & (m-1)l_e \leq x < ml_e \\ \frac{(2m-1)(L-x)yl_e}{2(\bar{EI})_m L}, & ml_e \leq x \leq L \end{cases} \quad (2)$$

式中: $(\bar{EI})_m = \frac{1}{l_e} \int_{(m-1)l_e}^{ml_e} (EI)_i dx_i$ 为第 m 个传感器标距范围内桥梁的等效平均抗弯刚度。

由式(2)可知,第 m 标段宏应变影响线由三部分组成:第一部分为初始直线段,第二部分为中间曲线段,第三部分为末端直线段。当第 m 个传感器标距覆盖区域梁段出现局部刚度变化时,由式(2)可知该区域的宏应变影响线幅值与梁段平均抗弯刚度成反比,即单位移动荷载 P 从 A 端运动到 B 端时,长标距FBG传感器测得的宏应变影响线幅值较之未发生损伤所测得的幅值整体增大,如图2所示。




图2 损伤前后桥梁宏应变影响线图
Fig. 2 Macro-strain influence line diagram of bridge before and after damage

从图2可知,第 m 标段发生损伤时桥梁宏应变影响线面积值随之发生变化,因此可以用宏应变影响线面积的增量(macro-strain area increment, MSAI)作为评估指标,判断该区域的等效抗弯刚度是否出现退化

$$MSAI = \frac{A^* - A}{A} \times 100\% \quad (3)$$

式中: $A = P \int_0^l \varepsilon_m(x) dx_i$ 为荷载 P 作用下第 m 标段的宏应变影响线面积; A^* 为刚度退化后的宏应变影响线面积。

2 仿真模型及宏应变数据库建立

2.1 车-轨-桥耦合模型

本文车-轨-桥耦合振动模型中主梁截面尺寸数据参考高铁简支梁箱型截面,主梁跨径为 32 m,桥上铺设 CRTS II 板式无砟轨道,如图 3 所示。




图3 车辆桥梁截面示意图

Fig. 3 Schematic diagram of vehicle bridge section

桥梁主梁采用 BEAM188 梁单元模拟,无砟轨道为 CRTS II 型板式,扣件间距为 0.5 m。模拟中使用 COMBIN14 单元模拟线弹性弹簧-阻尼器。为了提高计算速度,模型中轨道板、CA 砂浆层、混凝土底座板采用 BEAM188 单元模拟,桥梁轨道板扣件弹簧下节点通过 MPC184 与桥梁中心刚接实现荷载和变形传递,具体模型如图 4 所示。

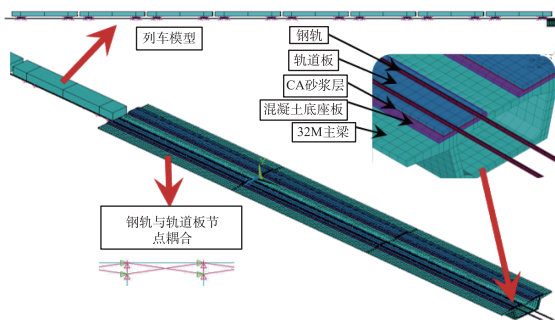


图4 车-轨-桥耦合振动模型

Fig. 4 Vehicle-rail-bridge coupling vibration model

为了验证模型的准确性和可靠性,本文在沪昆线进贤-南昌段一跨 32 m 简支梁桥梁底布置了桥梁健康监测系统^[11],健康监测系统由 21 根标距为 1 m 的长标距光纤光栅传感器组成,布置为两个信号通道,通道内传感器根据波长的大小顺序串联,布设在梁底中心线位置,如图 5 所示。当列车通过时开






图5 长标距FBG传感器布置图

Fig. 5 Long-gauge FBG sensor layout

始进行数据采集,列车驶出测量区域后停止数据采集,对桥梁健康监测系统和有限元模型不同位置的宏应变时程进行对比,采样频率为 1 000 Hz。图 6 为实测宏应变时程和模拟宏应变时程曲线对比。图中,列车的过桥时间为 2.5 s,四分之一跨的宏应变峰值在 $10 \mu\epsilon$ 左右,二分之一跨的宏应变峰值在 $12 \mu\epsilon$ 左右。实测与模拟的宏应变峰值之间存在差异,这种差异可能是由实测与模拟轴重的不同造成的。但通过宏应变时程曲线对比可以观察到,时程曲线均有 2 个小峰值和 7 个大峰值,实测与模拟的宏应变时程曲线趋势吻合,证明了本文模型的准确性。



(a) 四分之一跨宏应变对比



(b) 二分之一跨宏应变对比

图6 监测与模拟宏应变时程对比图

Fig. 6 Comparison of macro-strain time history

本文的桥梁模型是针对高铁简支梁箱型截面构建,对于其他类型桥梁,需根据实际结构特点调整参数和单元类型。本文的车-轨-桥耦合振动系统的建模思路和部分建模方法是可借鉴的,后续研究可针对不同桥型进行拓展和验证。

2.2 荷载统计分析

本文对铁路桥梁的交通负荷数据进行统计分析得到随机车流。为了获得各特征参数的分布规律是否服从某一类型分布,利用柯尔莫哥洛夫-斯米尔诺夫检验(K-S)^[12]进行验证。对列车荷载做如下假设:列车型号选取CRH3型高速列车,空车车厢质量为40 000 kg,转向架质量为3 200 kg,车轮与轮轴质量之和2 400 kg。使用统计方法选择每节车厢的乘客质量和上座率,就能得出车厢的总质量。

使用统计软件SPSS对车厢质量样本数据进行非参数检验,如图7所示,检验结果显示该分布为正态分布。CRH3车厢质量的平均值为44 346 kg,标准差为1 106.8 kg。在 $\alpha=0.05$ 的显著性水平下进行K-S检验后,保留原假设。




图7 CRH3车厢质量分布和理论拟合

Fig. 7 Quality distribution and theoretical fitting of CRH3 carriage

列车车速受多方面因素影响,包括线路设计和速度限制、车辆性能和技术状态、天气和环境条件等众多因素。这些因素共同决定了列车的最大运行速度和平均运行速度,影响着铁路运输的安全性、效率性和准时性。故对收集到的车速数据进行检验,如图8所示,显示该分布为正态分布。CRH3车速均值为304.5 km/h,标准差为8.80 km/h。

交通需求的波动、天气和自然因素、交通管理措施以及驾驶员行为和选择等多种因素会改变随




图8 CRH3车速分布和理论拟合

Fig. 8 Speed distribution and theoretical fitting of CRH3 carriage

机车流模型中桥上运营列车的荷载特性。因此,这些随机因素应该采用蒙特卡罗法抽样来抽取,找到参数的分布类型和函数,然后利用蒙特卡罗法^[13]创建随机样本。

2.3 损伤工况

为验证基于机器学习评估桥梁损伤方法的可行性,对于刚度退化区域模拟设置单处、多处及全桥损伤三种损伤工况,并使用k近邻算法(KNN),RBF神经网络,决策树(DT)和支持向量机(SVM)4种机器学习模型对设置的损伤进行定量和定位。本文选取损伤程度基准值为5%、10%、15%分别对应一、二、三级损伤,即通过减小对应位置材料的弹性模量来实现不同等级的刚度退化。本文以单处损伤工况为例进行详细验证,如表1所示。建立随机车流工况样本库,一共有7种损伤的工况对应不同的损伤位置和刚度退化程度。C0表示主梁未出现局部刚度退化。模型中长标距FBG传感器的布

表1 主梁单处损伤工况

Tab.1 Single damage condition of main beam

工况编号	刚度退化程度/%				
	F5	F7	F11	F15	F17
C0	—	—	—	—	—
C1	—	—	5	—	—
C2	—	—	10	—	—
C3	—	—	15	—	—
C4	10	—	—	—	—
C5	—	10	—	—	—
C6	—	—	—	10	—
C7	—	—	—	—	10

置如前面图5所示,在梁底一共布置了21个长标距FBG传感器,编号分别为F1~F21。

3 基于分布式宏应变影响线面积与区间估计的桥梁安全预警

提取无损工况(C0)下,桥梁经过抽样得到的200次随机车流时的分布式宏应变数据,并计算分布式宏应变影响线所包围的面积,如图9所示。由于列车车流的随机性,图9中分布式宏应变影响线面积在不同列车质量下存在波动,因而可以选用区间估计的方法对分布式宏应变影响线面积进行预警^[14]。首先确立分布式宏应变影响线面积图的均值线,均值线一定程度上反映了列车轴重、车速、轴距等一些列车参数带来的波动。波动的阈值与分布式宏应变影响线面积均值线进行叠加,便可得到分布式宏应变影响线面积预警的上下限值。

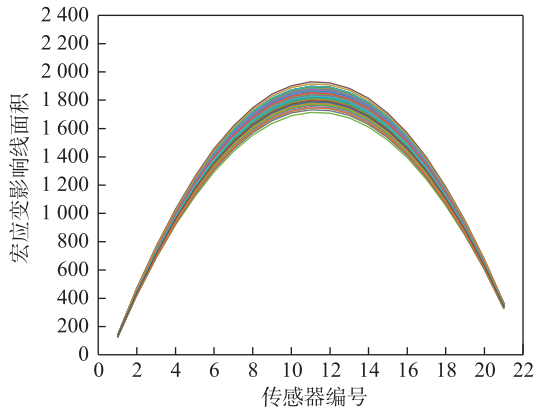


图9 200次列车分布式宏应变影响线面积曲线
Fig. 9 Area curve of distributed macro-strain influence line of 200 trains

区间估计方法是將分布式宏应变影响线面积图-传感器编号图分为多个区段,在每一个区间段内都能够估计到一个均值与方差的波动区间 $[\mu_{ja}, \mu_{jb}]$, $[\sigma_{ja}, \sigma_{jb}]$, 区间估计方法的预警步骤如下。

1) 设定分布式宏应变影响线面积均值线序列为 A_s^m 。均值线的设置采用每个传感器区间内的分布式宏应变影响线面积均值,点的连线就是分布式宏应变时程面积均值线。

2) 分布式宏应变影响线面积点 A_s 与均值线的距离为 $F_A = A_s - A_s^m$ 。

3) 将面积峰值的波动分为 m 个区间, $F_A = [F_{As1}, \dots, F_{Asj}, \dots, F_{Asm}]$ 。

4) 均值与方差的波动区间满足下式

$$\begin{cases} \mu_{ja} = \bar{X}_j - \frac{S_j}{n/m} t_{\alpha/2}(n/m-1) \\ \mu_{jb} = \bar{X}_j + \frac{S_j}{n/m} t_{\alpha/2}(n/m-1) \end{cases} \quad (4)$$

$$\begin{cases} \sigma_{ja} = \sqrt{n/m-1} S_j / \sqrt{\chi_{\alpha/2}^2(n/m-1)} \\ \sigma_{jb} = \sqrt{n/m-1} S_j / \sqrt{\chi_{1-\alpha/2}^2(n/m-1)} \end{cases} \quad (5)$$

式中: \bar{X}_j 为第 j 个区间的平均值; S_j 为第 j 个区间的标准差; $t_{\alpha/2}(n/m-1)$ 为 t 分布上 $n/m-1$ 个样本的分位数值; $\chi_{\alpha/2}(n/m-1)$ 和 $\chi_{1-\alpha/2}(n/m-1)$ 分别为卡方分布上 $n/m-1$ 个样本的分位数点 $\alpha/2$ 和分位数点 $1-\alpha/2$ 的值。

5) 每个子区间的波动区间为

$$F_{ja} = \mu_{ja} - r\sigma_{ja}, \quad F_{jb} = \mu_{jb} + r\sigma_{jb} \quad (6)$$

式中: F_{ja} 和 F_{jb} 分别为第 j 个子区间的波动区间的上限和下限; r 是基于经验的修正系数,描述了波动的离散程度。

6) 每个子区间的上下界为中线与波动区间的阈值叠加,区间内中值线的平均值用 \bar{A}_{sj}^m 表示

$$I_{wja} = \bar{A}_{sj}^m + F_{ja}, \quad I_{wjb} = \bar{A}_{sj}^m + F_{jb} \quad (7)$$

7) 分布式宏应变影响线面积预警区间的上界和下界为

$$\begin{cases} I_{wa} = [I_{w1a}, I_{w2a}, \dots, I_{wja}, \dots, I_{wma}] \\ I_{wb} = [I_{w1b}, I_{w2b}, \dots, I_{wjb}, \dots, I_{wmb}] \end{cases} \quad (8)$$

利用区间估计理论可以获取桥梁分布式宏应变影响线面积图-传感器编号图的上界和下界,显著性水平 α 设置为0.05,采用95%的置信区间上限和95%的置信区间下限作为200组随机车流下置信区间的阈值,如图10所示。若传感器对应的宏应变影响线面积数值在置信区间内,则对应区域没有发生损伤,在置信区间以上判定为发生损伤。

3.1 基于分布式宏应变影响线与机器学习的桥梁损伤定量评估

为验证基于机器学习评估桥梁损伤程度方法的可行性,提取C1至C3损伤工况下分布式宏应变数据,并计算得到分布式宏应变影响线面积,如图11所示。从图中可以看出,损伤位置处的宏应变影响线面积数值偏离置信区间,且随着刚度退化程度的不断增加,分布式宏应变影响线面积值与无损状态下的差值也越来越大。

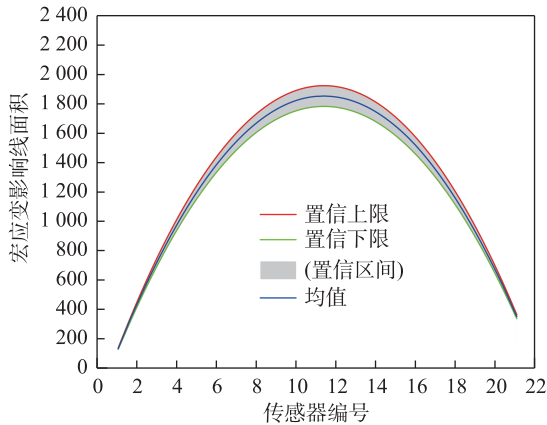


图 10 分布式宏应变影响线面积预警图
Fig. 10 Distributed macro-strain impact line area warning diagram

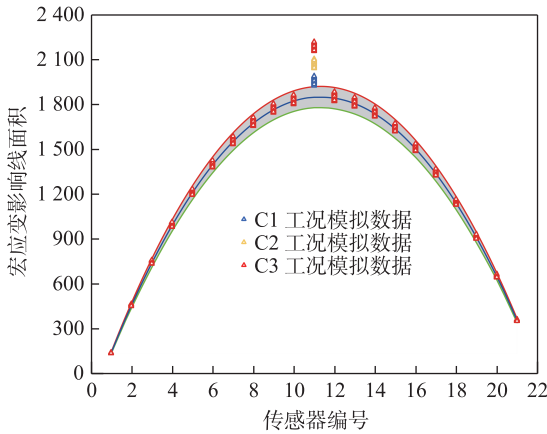



图 11 C1~C3 分布式宏应变影响线面积分布
Fig. 11 C1~C3 Distributed macro-strain influence line area distribution

将桥梁 21 个传感器的宏应变影响线面积数据作为机器学习样本的输入量, 损伤程度 0、5%、10%、15% 分别对应设置的 4 种标签。选取置信区间内的 C0 工况下的分布式宏应变影响线面积数据以及在 C1、C2、C3 工况下随机列车荷载模型中抽样的 30 次列车荷载模拟数据, 每个工况随机选择 10 组数据作为测试集, 其余的数据作为训练集。使用识别准确率来度量机器学习模型的损伤定量效果。


$$A = \frac{N_T}{N} \times 100\% \quad (9)$$

式中: A 为模型准确率; N_T 为识别正确的样本数量; N 为总的测试样本数量。


4 种机器学习模型损伤程度识别的识别结果如图 12 所示。由图 12 分析可知 KNN 模型与 SVM 模




(a) RBF模型单损定量识别结果



(b) KNN模型单损定量识别结果



(c) DT模型单损定量识别结果



(d) SVM模型单损定量识别结果

图 12 4 种机器学习模型单损定量识别结果
Fig. 12 Quantitative identification results of single damage under 4 types of machine learning

型对于单处刚度退化的损伤程度识别准确率较高,DT模型的识别准确率较低。DT模型的识别结果中75%的误差来源于将C3工况错误识别为C2工况。对于不同损伤程度,同一机器学习模型的识别准确率存在些许差别,整体而言4种机器学习模型的损伤识别准确率均在90.0%以上,可以较好地识别损伤。

为了能够直观地对比4种机器学习模型在损伤定量评估中的性能,将4种机器学习模型对损伤程度识别的识别准确率进行统计,结果如图13所示。分析结果可知4种机器学习模型对于损伤情况桥梁的损伤定量平均准确率都达到了90.0%,分别为92.5%、95.0%、90.0%、95.0%。其中KNN模型和SVM模型的识别准确率最高,均达到95.0%,说明利用分布式宏应变影响线面积作为机器学习损伤识别的指标可靠度很高。

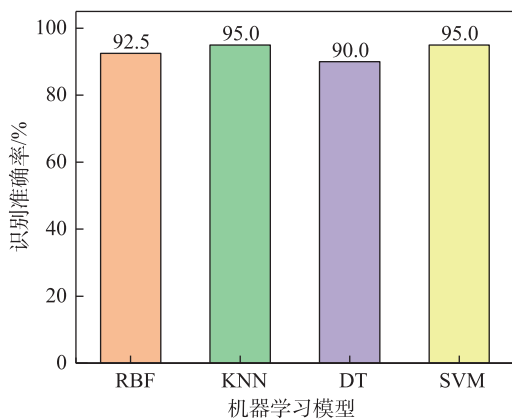


图13 4种机器学习模型损伤程度识别准确率
Fig. 13 Accuracy of damage level recognition under 4 types of machine learning

3.2 基于分布式宏应变影响线与机器学习的桥梁损伤定位评估

为验证基于机器学习评估桥梁损伤位置方法的可行性,提取C2、C4~C7工况下的分布式宏应变数据,并计算得到分布式宏应变影响线面积,如图14所示。分析可知,出现损伤时对应位置传感器测得的宏应变影响线面积会变大,传感器F5、F7、F11、F15、F17处宏应变影响线面积增幅分别为215、137、174、178、145,跨中损伤时分布式宏应变影响线面积超出健康置信区间最多,沿着桥梁两端偏离健康置信区间程度减小。

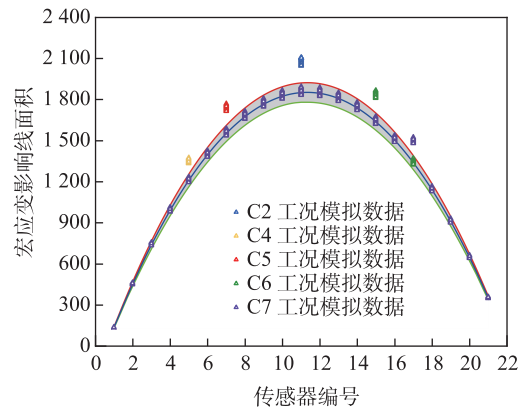


图14 C2、C4~C7分布式宏应变影响线面积分布
Fig. 14 C2, C4~C7 Distributed macro-strain influence line area distribution

将桥梁21个传感器的宏应变影响线面积数据作为机器学习样本的输入量,损伤工况C0、C2、C4、C5、C6、C7分别对应设置6种标签。选取置信区间内的C0工况下的10组分布式宏应变影响线面积数据以及在C2、C4、C5、C6、C7工况下随机列车荷载模型中抽样30次模拟数据中随机选择的10组数据作为测试集,其余的数据作为训练集对模型进行训练。4种机器学习模型损伤位置的识别结果如图15所示。

由图15分析可知SVM模型对于单处刚度退化的损伤位置识别准确率较高,KNN模型的识别准确率较低。进一步分析识别误差分布的区域,所有的识别误差都分布在C4-C6工况。对于不同损伤位置,同一机器学习模型的识别准确率也存在些许差别,整体而言4种机器学习模型对于单处刚度退化的识别准确率均在90%以上,识别效果明显。

为了能够直观地对比4种机器学习模型在损伤定位评估中的性能。将4种机器学习模型对损伤位置识别的识别准确率进行统计,结果如图16所示。分析结果可知4种机器学习模型对于损伤情况桥梁的损伤定位平均准确率都达到了90.0%,分别为95.0%、90.0%、93.3%、98.3%。其中KNN模型在损伤定位中表现较差,但识别准确率也能达到90.0%,SVM模型的识别准确率最高,达到98.3%,说明利用分布式宏应变影响线面积作为机器学习损伤识别的指标可靠度很高。

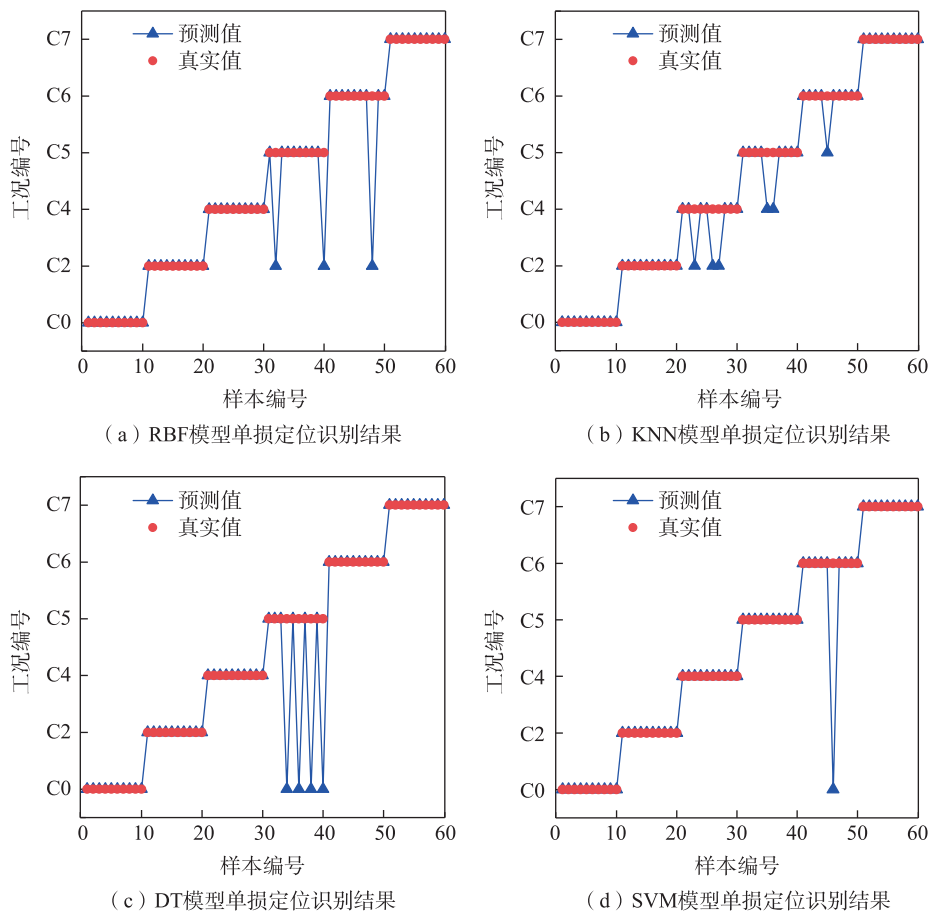


图 15 4种机器学习模型单损定位识别结果

Fig. 15 Location identification results of single damage under 4 types of machine learning

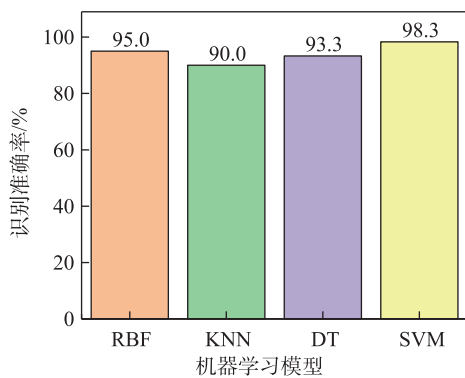


图 16 4种机器学习模型损伤定位识别准确率

Fig. 16 Accuracy of damage localization recognition under 4 types of machine learning

4 结论

本文研究了联合分布式宏应变监测与机器学习的桥梁监测与安全预警方法。首先,建立了车-轨-桥耦合振动三维有限元模型,其次,构造了随机


列车荷载模型,通过大量列车荷载工况计算,构建了铁路桥梁宏应变样本库,在多种损伤工况下利用分布式宏应变影响线面积作为指标,使用4种机器学习模型对设置的损伤进行定量和定位试验,得出以下结论:

1) 移动列车荷载下,无损伤桥梁分布式宏应变影响线面积为二次抛物线分布,当桥梁出现局部损伤时,损伤处的分布式宏应变影响线面积幅值随之增大,在分布曲线上呈现明显的凸起,凸起程度与损伤程度正相关,这一现象可以用来进行桥梁损伤定位与定量评估。

2) 4种机器学习都能够对桥梁结构的局部损伤进行定位和定量,平均识别准确率都达到了90%,其中KNN模型和SVM模型在桥梁损伤定量的测试中表现最好,识别准确率均为95.0%,SVM模型在桥梁结构损伤定位的测试中表现最好,识别准确率为98.3%,综合分析,SVM在桥梁损伤定位与损伤定量分析表现最优。

参考文献:

- [1] 孟伟宁. 包神线铁路桥梁病害检测及养护维修技术研究[D]. 兰州: 兰州交通大学, 2023.
MENG W N. Study on disease detection and maintenance technology of railway bridges on Baoshen line[D]. Lanzhou: Lanzhou Jiatong University, 2023.
- [2] 郝龙, 邵慧, 姜丹. 北斗系统桥梁变形监测和预警研究[J]. 交通科技与管理, 2023, 4(18): 7-9.
HAO L, SHAO H, JIANG D. Research on bridge deformation monitoring and early warning of Beidou system [J]. 1, 2023, 4(18): 7-9.
- [3] 梅大鹏. 基于深度学习的大跨度高铁桥梁健康监测预警方法研究[D]. 成都: 西南交通大学, 2022.
MEI D P. Research on health monitoring and early warning method of long-span high-speed rail bridge based on deep learning[D]. Chengdu: Southwest Jiaotong University, 2022.
- [4] 张耘. 基于内力重分布效应的桥梁损伤预警方法研究[D]. 南京: 东南大学, 2022.
ZHANG Y. Research on bridge damage warning method based on internal force redistribution effect[D]. Nanjing: Southeast University, 2022.
- [5] 张远传. 融合云计算技术的大跨度桥梁健康监测预警方法研究[D]. 广州: 华南理工大学, 2022.
ZHANG Y C. Research on health monitoring and early warning method of long-span bridges based on cloud computing technology[D]. Guangzhou: South China University of Technology, 2022.
- [6] 刘广逊. 大跨铁路桥梁预警方法研究[D]. 石家庄: 石家庄铁道大学, 2022.
LIU G X. Research on early warning method of long-span railway bridge[D]. Shijiazhuang: Shijiazhuang Tiedao University, 2022.
- [7] 曹晓龙. 基于监测数据时频域特征统计分析的桥梁安全预警研究[D]. 大连: 大连理工大学, 2021.
CAO X L. Research on bridge safety early warning based on statistical analysis of time-frequency domain characteristics of monitoring data[D]. Dalian: Dalian University of Technology, 2021.
- [8] DING Y L, SUN P, WANG G X, et al. Early-warning method of train running safety of a high-speed railway bridge based on transverse vibration monitoring[J]. Shock and Vibration, 2015, 2015: 518689.
- [9] TAN D M, GUO T, LUO H, et al. Dynamic threshold cable-stayed bridge health monitoring system based on temperature effect correction[J]. Sensors, 2023, 23(21): 8826.
- [10] LI J X, YI T H, QU C X, et al. Early warning for abnormal cable forces of cable-stayed bridges considering structural temperature changes[J]. Journal of Bridge Engineering, 2023, 28(2): 04022137.
- [11] WU B T, WU G, YANG C Q. Parametric study of a rapid bridge assessment method using distributed macro-strain influence envelope line[J]. Mechanical Systems and Signal Processing, 2019, 120: 642-663.
- [12] 汪涛, 任伟新, 杨栋, 等. 基于随机子空间法的异步实测桥梁模态识别[J]. 合肥工业大学学报(自然科学版), 2023, 46(3): 333-340.
WANG T, REN W X, YANG D, et al. Asynchronously measured bridge modal identification based on stochastic subspace method[J]. Journal of Hefei University of Technology (Natural Science), 2023, 46(3): 333-340.
- [13] OTAKE S, NAKAMURA H, IWABUKI H, et al. Study on localization of low-frequency noise induced by road traffic vibration in steel plate girder bridges and countermeasures of bridge vibration focused on the second vertical vibration mode[J]. INTER-NOISE and NOISE-CON Congress and Conference Proceedings, 2019, 259(7): 2266-77.
- [14] WU B T, LIN Z C, LIANG Y X, et al. An effective prediction method for bridge long-gauge strain under moving trainloads with experimental verification[J]. Mechanical Systems and Signal Processing, 2023, 186: 109855.



通信作者: 吴必涛(1986—), 男, 博士, 教授, 博士生导师, 研究方向为桥梁结构健康监测与加固。E-mail: wubitao@ecjtu.edu.cn。

(责任编辑: 李根)