

基于移动车辆荷载作用下锚固点振动响应结合 机器学习的斜拉索损伤识别研究

曾有艺,杜家锐,张家滨,王金昊,樊继荣

(长沙理工大学 土木与环境工程学院,湖南 长沙 410114)

摘要:移动车辆荷载作用下采集的桥面振动响应数据,包含了很多桥梁的几何参数信息,能有效地对结构损伤进行识别。机器学习算法能够挖掘响应数据中的关键信息,捕捉其中线性关系。该文以韶州大桥为背景,建立斜拉桥有限元模型,将多种不同车辆参数的两轴货车荷载作用在不同斜拉索小损伤工况下的斜拉桥模型上,模拟计算移动荷载作用下斜拉桥模型的振动响应。采用主成分分析(PCA)技术对加速度数据降维压缩,并结合贝叶斯优化后的最小二乘法支持向量机模型(BO-LSSVM),开展不同荷载组合下斜拉索的损伤定位与定量分析。针对多根拉索损伤预测不准确的情况,提出了将定位标签整合到损伤数据中的方法。结果表明:基于大量的损伤响应数据,BO-LSSVM模型能寻找到最佳的超参数组合,有效分析复杂响应数据,利用移动车辆荷载实现拉索损伤程度的监测分析。利用PCA对加速度响应数据进行降维压缩,在保证预测精度的同时,提高了机器学习的计算效率,节约了计算资源。且在多损伤数据特征数据中添加定位标签方法有效提高了损伤识别的准确性。该研究为实际工程中的损伤实时监测提供了模型参考与技术理论基础。

关键词:斜拉桥;车桥耦合;振动响应;数据压缩;贝叶斯优化;最小二乘法支持向量机;损伤识别
中图分类号:U441 **文献标志码:**A

Identification of Cable-Stayed Bridge Damage Based on Anchor Point Vibrations Caused by Moving Vehicle Loads and Through Machine Learning

ZENG Youyi, DU Jiarui, ZHANG Jiabin, WANG Jinhao, FAN Jirong

(School of Civil and Environmental Engineering, Changsha University of Science & Technology, Changsha, Hunan 410114, China)

Abstract: The vibration response data on the bridge deck under the load of moving vehicles contains a wealth of information about the geometric parameters of the bridge, enabling effective identification of structural damage. Machine learning can extract key information from the response data and capture linear relationships within it. Taking the Shaozhou Bridge as the research background, this study established a finite element model for a cable-stayed bridge and applied loads from two-axle trucks with various vehicle parameters to the cable-stayed bridge model under different small damage conditions to simulate the vibration response of the cable-stayed bridge model under moving load. Principal component analysis (PCA) was employed for dimensionality reduction and compression of acceleration data, and Bayesian-optimized least squares support vector machine (BO-LSSVM) was used to analyze both damage localization and quantification of the cable-stayed bridge under different load combinations. Additionally, in response to inaccuracies in predicting damage for multiple cables, a method was proposed to integrate localization labels into the damage data. The results indicate that, through a substantial amount of damage response data, the BO-LSSVM model can identify the optimal hyperparameter combinations, effectively analyzing complex response data and monitoring cable damage levels using moving vehicle loads. Utilizing PCA for dimensionality reduction and compression of acceleration response data maintains predictive accuracy while enhancing the computational efficiency of machine learning, thus conserving computational resources. Furthermore, the method of adding localization labels to multiple damage

收稿日期:2024-10-23 修回日期:2025-09-20

基金项目:国家自然科学基金资助项目(编号:52278141);国家级创新训练项目(编号:202213635003)

作者简介:曾有艺,男,博士,副教授.E-mail:864442055@qq.com

feature data can improve damage identification accuracy. This study provides a model reference and theoretical basis for real-time monitoring of damage in practical engineering.

Keywords: cable-stayed bridge; vehicle-bridge coupling; vibration response; data compression; Bayesian optimization; least squares support vector machine; damage identification

0 引言

斜拉桥拉索刚度的监测可及时发现索缆是否存在拉伸不均匀、腐蚀、断裂等问题。这些问题不及时发现,可能导致索缆受力不均匀、失效或破坏,从而影响桥梁的安全性^[1-2]。因此,有效的拉索刚度监测可以帮助发现潜在的问题并及时修复,从而延长斜拉桥的使用寿命,减缓桥梁结构的老化速度,保持其良好的运行状态。

拉索刚度与桥梁的振动特性直接相关^[3-5]。当拉索刚度发生变化时,桥梁的振动特性也会相应地发生变化。通过对动态振动数据进行分析 and 处理,可以提取出桥梁结构的振动特征,包括自然频率、振型等信息。将这些信息与数值模拟结果进行对比和验证,能有效评估桥梁结构的健康状态,识别拉索刚度的变化情况^[6-9]。

然而,响应信息复杂,影响因素较多。普通的人工分析具有很高的难度,不同车重、车速下的数据差异性较大,大部分方法在识别过程中容易出现截断性误差、抗噪能力差,且很难从中提取有效的指标函数分析结构损伤。所以结合机器学习的方法进行响应数据的分析很有必要。近年来,机器学习的使用体现在各个领域^[10-13],在结构工程中的信号处理和结构健康监测方面的应用已十分广泛。Santaniello等^[14]、Hajjalizadeh^[15-16]、Song等^[17]将收集损伤模拟后的加速度信号数据预处理后,转换为三维RGB格式图像,放入不同方式优化下的CNN神经网络中进行训练,最终实现桥梁在不同损伤场景下的损伤识别;Sarwar等^[18]收集多个不同的车辆在不同时间通过四跨钢筋混凝土箱梁结构时的车速和垂直加速度数据,提出了Kullback-Leibler散度作为损伤指标评估损伤程度,采用一维卷积神经网络和长短时记忆递归神经网络的架构构建了深度编码器进行损伤预测;Marafini^[19]基于振动监测方法理论的成熟性提出了考虑损伤层级、提取特征类型、损伤指标度和模型构建的损伤分类框架;Li等^[20-21]、Lan等^[22]利用梅尔频率倒谱系数(MFCCs)对采集到的过桥车辆的振动数据频率响应从赫兹刻度投影到梅尔刻度上,有

效降低了输入数据的维度;随后又针对原始信号进行了主成分分析(PCA),发现PCA和MFCCs可以很好地解决信号降维问题;李延强等^[23]以索梁锚固点的加速度时程响应的小波包能量变化率作为支持向量机的输入参数,识别出了斜拉桥损伤情况;蒋雍建等^[24]统计了随机车流作用下不同拉索损伤工况下应变响应数据,采用应变响应差值,并结合随机森林和梯度提升决策树等机器学习的方式进行损伤定位与定量评估。

机器学习模型在经过大量数据训练后,能够高效、准确地进行数据回归预测。然而,在实际工程中,由于行车安全、成本等因素,损伤试验难以在斜拉桥上实施。因此,需要建立精细化的模型,模拟工程实际状况储存损伤数据。以往的文献中,作用在斜拉桥上的车辆荷载参数单一,不能够实现车辆荷载的多样化,得到的振动响应数据不够复杂。对桥梁的损伤模拟基本是高程度损伤,而实际工程中,在恶劣条件影响下的损伤程度并不高,大部分只会产生细微的小程度损伤,这些小损伤的积累是导致桥梁结构损坏的重要原因。此外,面对复杂、庞大的振动响应数据量,如何在压缩数据减小机器学习数据量的同时,又能够不失去原始信号的特征性是非常重要的。因此,模拟不同车辆参数的移动荷载,将其作用在小程度损伤的斜拉桥模型上,以获取桥梁测点的振动响应,进而寻找一种能代表数据复杂性的特征值指标,并结合机器学习方法,构建一套完整的桥梁健康检测系统具有重要意义。

基于上述研究思路,本文以车桥耦合作用下桥梁多测点位置的振动响应为已知信息,以贝叶斯优化后的最小二乘法支持向量机模型(Bayesian Optimization for Least Squares Support Vector Machine, BO-LSSVM)为核心算法,开展斜拉索的损伤定位与定量分析。通过数值模拟,将多种不同车辆参数的两轴货车荷载作用在不同斜拉索小损伤工况下的斜拉桥模型上,模拟计算移动荷载作用下斜拉桥模型的加速度响应。随后,对主跨10个位置测点数据进行PCA降维处理,提取11个主成分进行数据压缩。采用训练集压缩数据样本,结合贝叶斯寻

找最优超参数,建立性能最优的最小二乘支持向量机模型,利用该模型处理测试集样本数据,实现单根或多根拉索同时损伤情况下的损伤识别。本文提出了一种将定位标签整合到损伤数据特征样本的方法,以提高机器学习在结构损伤预测中的精度。最后以韶州大桥的有限元模型为案例,验证了该方法的有效性。

1 车桥耦合训练模型

1.1 车辆模型

本文将车辆简化为两轴车力学模型,采用弹簧阻尼系统模拟车体与车轮之间的连接及车轮与桥面的相互作用,其刚度系数与阻尼系数如图1所示。各参数的物理意义如表1所示。




图1 车辆模型图

Figure 1 Vehicle model

表1 车辆模型参数及其物理意义

Table 1 Vehicle model parameters and their physical significance

车辆参数	单位	物理意义	车辆参数	单位	物理意义
m_1	kg	后轮质量	m_3	kg	车体质量
m_2	kg	前轮质量	J	$\text{kg} \cdot \text{m}^2$	车体转动惯量
k_1	kN/m	刚度系数	c_1	kN · s/m	阻尼系数
k_2	kN/m		c_2	kN · s/m	
k_3	kN/m		c_3	kN · s/m	
k_4	kN/m		c_4	kN · s/m	
l_1	m	后轴与质心距离	l_2	m	前轴与质心距离

该模型包含8个自由度,包括车体质心处位移及转角 y_c, θ , 车体两端的位移 y_3, y_4 , 车轮竖向位移 y_1, y_2 , 车轮与桥面接触的位移 Y_{v1}, Y_{v2} 。将车体等效为刚体,根据几何关系,可将 y_c, θ 表示为:

$$y_c = \frac{y_3 l_1 - y_4 l_2}{l}, \theta = \frac{y_3 - y_4}{l} \quad (1)$$

1.2 桥梁模型

本文以广东省韶州市的一座拱形独塔双索面混合梁斜拉桥为背景进行数值模拟,韶州大桥从北到南跨径组合为:33 m(混凝土梁段)+102 m(钢箱梁段)+183 m(钢箱梁段),斜拉索在主塔两侧分别有13对索共52根,其中混凝土段斜拉索共7对,间距为6 m,其余钢箱梁段的斜拉索间距为12 m,主塔上斜拉索间距为2 m。假设南侧上游斜拉索编号依次为E1~E13,南侧下游斜拉索编号依次为W14~W26,具体桥梁布置如图2所示。




图2 桥梁立面布置图

Figure 2 Bridge elevation layout

考虑到车桥耦合模型计算复杂,长时间大样本计算耗时较长,文中建立一个有限元简化模型,进行分析计算,该模型动力特性与实桥近似。桥梁Ansys有限元模型如图3所示。其中:主梁、主塔采用Beam 188单元模拟,拉索采用Link 180单元模拟,全桥共有3784个节点,3519个单元。桥面不平顺等级采用三角级数叠加法模拟,分为5个等级,本文采取的路面等级为“极好”。桥梁结构的结构阻尼根据Rayleigh阻尼假设设定^[25],拉索损伤通过刚度折减法模拟。针对拉索损伤程度在0~10%内的不同损伤工况,建立了相应的桥梁模型。最后选择拉索与主梁的锚固点为模拟测点,从Ansys中导出该点在不同位置拉索、不同损伤工况下的振动响应数据。




图3 桥梁有限元模型

Figure 3 Finite element model of bridge

1.3 车辆激励下的桥梁振动响应求解与验证

根据车桥耦合理论^[26],并假设车辆与桥面始终接触,建立车桥耦合振动方程:

$$\begin{bmatrix} M_{bb} & 0 \\ 0 & M_{vv} \end{bmatrix} \begin{Bmatrix} \ddot{Y}_b \\ \ddot{Y}_v \end{Bmatrix} + \begin{bmatrix} C_{bb} & C_{bv} \\ C_{vb} & C_{vv} \end{bmatrix} \begin{Bmatrix} \dot{Y}_b \\ \dot{Y}_v \end{Bmatrix} + \begin{bmatrix} K_{bb} & K_{bv} \\ K_{vb} & K_{vv} \end{bmatrix} \begin{Bmatrix} Y_b \\ Y_v \end{Bmatrix} = \begin{Bmatrix} F_b \\ F_v \end{Bmatrix} \quad (2)$$

式中: M 、 C 、 K 分别表示质量、阻尼和刚度矩阵; \ddot{Y} 、 \dot{Y} 、 Y 表示节点加速度、速度、位移向量; F 表示节点力向量;下标 v 代表车辆;下标 b 代表桥梁。

采用Newmark- β 积分法求解每个时刻前后车轮的竖向位移和桥面的竖向位移。计算得到车轮与桥面之间的相互作用力后,将其作用在Ansys桥梁模型的车道上,通过瞬态分析模态叠加法求解拉索锚固点的振动响应。

为验证模型的准确性,将模拟结果与现场实测数据进行对比。如图4~6所示,现场测试依托韶州大桥上的健康监测系统,使用索振动加速度计、高速动态地秤等设备,采集一辆实际车重为20 t、车辆速度为20 km/h、30 km/h的货车的过桥响应数据。同时,选择近似同等车辆参数的货车模型,以相同速度在有限元模型的第7车道上行驶,并收集相应测点位置中的加速度信号。韶州大桥E4锚固点模拟获得的加速度数据与实测的加速度响应曲线对比如图7所示。




图4 加速度传感器现场安装示意图

Figure 4 Field installation of acceleration sensor



图5 高速动态地秤系统

Figure 5 High-speed dynamic weighing system



图6 实际车辆测试现场

Figure 6 Actual vehicle test site

由图7可以看出:车桥耦合模拟下的振动响应曲线与实测的振动响应曲线吻合较好。以此模型为基础,通过不断的模型修正无限地向工程实际靠拢,从而为建立大规模损伤数据库,最终实现基于实时监测数据的损伤识别与预警提供支持。

2 基于BO-LSSVM的损伤识别模型构建

2.1 数据压缩

车桥耦合模型的分析是长时间的振动响应时间历程,数据规模较大,庞大的数据量放入机器学习模型中会减慢学习效率且识别精度不佳。通过对数据的压缩,提取数据有效样本,可以极大地减小目标数据量。本文结合PCA降维技术对每个测点的加速度数据进行降维,主成分分析是一种有效的统计方法,它通过衡量标准化后数据集各个数据特征之间的协方差矩阵,评估出最有价值主要成分方向,捕捉数据中最显著的特征。本文生成11个主成分,它们累计解释了91.1567%的方差。

图8为车重15 t、车速60 km/h条件下,E7拉索发生不同损伤时,测点E1加速度数据经PCA降维后的压缩数据随损伤程度的变化趋势。由图8可知:①对于单损伤数据集,经过PCA降维压缩后,特征数据与损伤程度大致呈线性关系;②对于多损伤特征数据,由于存在两个损伤变量关系,在经过PCA降维后的压缩指标与各拉索的损伤程度之间呈现复杂的非线性关系,因此,很难将损伤程度与压缩指标进行耦合。

2.2 BO-LSSVM模型构建

由数据压缩样本可知,振动响应特征值随损伤程度和车速的变化十分复杂。人工寻找其关系需要耗费很大的精力,利用振动响应数据反推刚度的折减程度也极为困难。因此,需要结合机器学习,输入




图7 E4锚固点模拟与实测振动加速度响应曲线对比

Figure 7 Comparison of simulated and measured vibration acceleration response curves at E4 anchorage point




图8 第1、7主成分下的压缩指标随损伤程度的变化趋势
Figure 8 Variation trend of compression index with damage degree under 1st and 7th principal components

足够的拉索锚固点振动响应样本,以探索其中的非线性映射关系。

2.2.1 LSSVM模型构建

最小二乘支持向量机(Least Squares Support Vector Machine, LSSVM)是支持向量机(Support

Vector Machine, SVM)的一种变体,旨在利用训练集找到合适的拟合函数去预测数据。与SVM采用二次规划求解不同,LSSVM通过构造最小二乘损失函数,并将不等式约束转换为等式约束,极大地简化了求解过程。这一改进使其在数据回归任务中计算更高效,尤其擅长处理非线性问题,同时对异常值也具有较好的鲁棒性。在构建过程中,本文选择径向基函数作为核函数构建LSSVM,该函数将数据映射到高维空间中的高斯分布特征空间,更好地捕捉数据之间的非线性关系。通过调整高斯带宽,并最小化一个包括数据拟合项和正则化项的目标函数求解,使其得到更好的拟合关系。

2.2.2 结合贝叶斯优化LSSVM模型

最小二乘支持向量机是一种强大的机器学习算法,在算法中核函数参数 g 和惩罚函数参数 c 这两个重要的超参数控制了模型的核函数类型以及对训练误差和模型复杂度的平衡。需要调整后才能展现出最佳的学习状态。贝叶斯优化是一种强大的优化方法,它的融合可以自动找到最佳的超参数配置,从而提高了LSSVM模型的性能。相比于传统的网格搜索或随机搜索方法可能需要大量的计算资源和时间来搜索超参数空间,贝叶斯优化的高斯过程在搜索中考虑了之前的结果,可以更快地收敛到最佳超参

数配置^[27]。LSSVM模型算法流程图如图9所示。

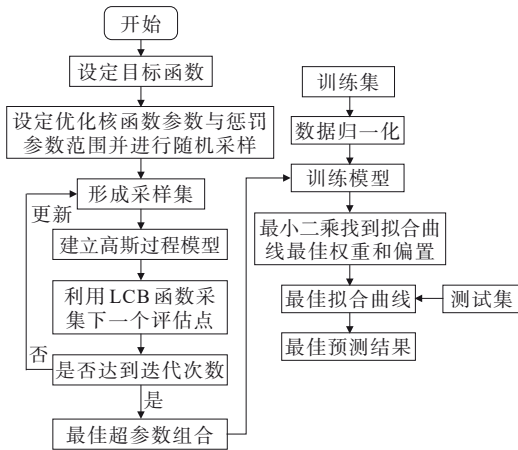


图9 BO-LSSVM算法流程图

Figure 9 Flowchart of BO-LSSVM algorithm

(1) 超参数优化准备

鉴于超参数 g 、 c 对 LSSVM 模型性能至关重要, 本文设定了其搜索范围, 以寻找最优参数组合。优化目标是使模型的预测结果尽可能接近真实值。为此, 选取了预测损伤程度与真实损伤程度之间误差的均方根值作为目标函数, 并通过优化算法寻找该函数值最小的超参数, 实现最精准的损伤程度预测。

(2) 概率代理模型

为建立一个初始的目标函数输出和超参数之间的关系。首先针对 LSSVM 模型中的超参数在指定的参数范围内随机采样, 通过采样集 D_{Initial} 中的数据 x_{Initial} 及其误差均方根值结果 f_{Initial} 对目标函数拟合曲线的大致分布趋势作出多种预测。随后根据初始化过程中随机采样点及其结果对目标函数拟合曲线的多种预测结果, 建立一个如式(3)所示包括均值函数和协方差函数的高斯过程模型:

$$f(x) \sim N(\mu(x), \sigma^2(x)) \quad (3)$$

式中: $\mu(x)$ 为输入超参数 x 处的目标函数均值即对目标函数在超参数为 x 处的预测, 估计了目标函数的大致分布曲线; $\sigma^2(x)$ 为超参数 x 处的目标函数方差, 它提供了目标函数在不同输入点处的不确定性估计, 方差越大即预测越不确定。它是一个不固定参数数量的非参数代理模型。

(3) 采集函数

结合采集函数能够选择下一个具有潜力的评估点, 指导下一个最有希望的超参数配置的选择, 以便最大化优化目标函数的可能性。本文选用置信下限 (Lower Confidence Bound, L_{CB}) 作为采集函数, 该算

法的核心思想是在不确定性和已知信息之间寻找平衡, 在尽量减小不确定性的同时, 最大化得到期望数值。如式(4)所示:

$$L_{\text{CB}}(x) = \mu(x) - \kappa \sigma(x) \quad (4)$$

式中: $\mu(x)$ 为候选点 x 的均值估计, 表示已知数据中目标函数在 x 处的平均值; $\sigma(x)$ 为代表目标函数在 x 点处的预测标准差, 这是模型对于目标函数在该点的不确定性的一种度量; κ 为一个用户定义的调整参数, 它控制了对不确定性的重视程度, 本文根据迭代次数自适应地调整 κ 的取值。

选择具有最大 L_{CB} 的候选点作为下一个评估点: $x_{\text{next}} = \text{argmax}_x L_{\text{CB}}(x)$, 并获得其目标函数值 f_{next} , 将最佳评估点 ($x_{\text{next}}, f_{\text{next}}$) 添加到采样集 D_{Initial} 中, 构造新的高斯过程模型, 更好拟合目标函数的分布曲线。

重复上述工作, 设定迭代次数为 1 000 次时停止模型更新, 输出最佳的超参数值, 将超参数组合代入机器学习模型中, 建立最优模型。

3 模型训练与预测

3.1 数据集来源

本文对主跨拉索进行了损伤模拟, 为确保研究结果的普适性, 选择 E1、E2、E4、E5、E6、E7、E9、E10、E12、E13、W15、W18、W21、W24 这 14 根拉索进行损伤模拟。选择这些位置是为了涵盖易受损伤的拉索位置, 并能够判别相邻损伤位置拉索的损伤情况, 具有良好的位置覆盖性。选取车速在 40 km/h、50 km/h、60 km/h, 车重在 15 t、17.5 t 的 6 种车辆参数下的车辆行驶在桥梁模型的第 7 车道上。

损伤组合如表 2 所示, 在单根索的损伤识别研究中对每根斜拉索分别模拟损伤, 共计 14 种损伤情况。在多根索的损伤研究中, 对 E1、E4、E7、E10、E13、W15、W18、W21、W24 这 9 根作了随机两两组合的形式选取损伤拉索共 36 种不相邻损伤情况, 又选择了 E1 和 E2, E5 和 E6, E9 和 E10, E12 和 E13 两两一组共 4 种的相邻损伤, 共计 40 种拉索损伤组合。通过刚度折减的方式进行损伤模拟, 每种车辆参数下模拟了 90 种 0~10% 损伤程度内的损伤工况。收集 E1、E4、E7、E10、E13、W14、W17、W20、W23、W26 这 10 个测点在每个损伤工况下的振动响应数据, 如表 3 所示, 单根拉索损伤的损伤数据共计模拟了 75 600 组加速度数据。多损伤情况共计模拟了 216 000 组加速度数据。均按照 9:1 的比例划分训练集和测试集, 训练

集的损伤程度在 Matlab 中采用 0~10% 内随机数的形式进行选取,单损伤测试集的损伤程度选取 1%、2%、3%、4%、5%、6%、7%、8%、9% 共 9 种损伤程度进行模拟计算。多损伤测试集损伤 1 号和 2 号拉索的损伤程度选取为 1% 和 9%、2% 和 8%、3% 和 7%、4% 和 6%、5% 和 5%、6% 和 4%、7% 和 3%、8% 和 2%、9% 和 1% 9 种损伤组合。

结合 2.1 中的内容介绍针对加速度数据建立 PCA 压缩数据样本,10 个测点每个主成分下的数据集作为机器学习的输入,拉索的损伤位置、损伤程度作为输出。选择其中第 1、3、5、7、9、11 这 6 个主成分展开研究。

3.2 单损伤识别

3.2.1 损伤定位

为对斜拉桥主跨部分拉索的损伤进行精准定位,建立了 BO-LSSVM 分类模型。按照表 2 中单根损伤拉索组合的损伤情况分为 14 种类别,类别 1 代表斜拉索 E1 损伤类别,2 代表斜拉索 E2 损伤,以此类推,直到类别 14 代表斜拉索 W24 损伤。10 个测点加速度响应 PCA 压缩数据样本作为输入集,损伤种类作为输出。经过贝叶斯优化后核函数参数与惩罚参数的最佳参数组合如表 4 所示。由表 4 可知:在单损

伤识别中,每个主成分压缩样本下核函数参数的最优值分布于 $1 \times 10^5 \sim 1 \times 10^6$,惩罚参数的最优值分布于 $1 \times 10^{-6} \sim 1 \times 10^{-4}$ 。这表明贝叶斯优化能够在极大的寻优范围内找到最具有价值的评估点,使得预测效果达到最佳。损伤定位准确率结果如表 4 和图 10 所示,在最佳超参数组合下,机器学习结合损伤数据的定位识别准确率均达到了 100%。

3.2.2 损伤预测

构造单输出的 BO-LSSVM 数据回归模型,针对每个成分下的数据集,经过贝叶斯优化后得到的核函数参数与惩罚参数的最佳参数组合如表 5 所示,由表 5 可知:在经过 1 000 次寻优后,算法能够在区间内找到最佳超参数组合。单损伤识别中每个主成分压缩样本下核函数参数的最优值分布于 $1 \times 10^{10} \sim 1 \times 10^{12}$,惩罚参数的最优值分布于 1~100,为实际工程中单损伤预测更快速地找到最佳超参数组合提供了基础。6 个主成分下的单根拉索损伤预测均方根值误差如表 5 所示。结果表明:基于足够损伤工况的拉索锚固点的加速度响应数据,结合机器学习进行小程度的损伤识别是可行的。PCA 降维后的数据巧妙地保留了原始信号的关键特征,LSSVM 模型在预测

表 2 拉索损伤组合

Table 2 Cable damage combinations

单根拉索损伤位置				多根拉索损伤位置组合						
E1	E2	E4	E1,E4	E1,E7	E1,E10	E1,E13	E1,W15	E1,W18	E1,W21	E1,W24
E5	E6	E7	E4,E7	E4,E10	E4,E13	E4,W15	E4,W18	E4,W21	E4,W24	E7,E10
E9	E10	E12	E7,E13	E7,W15	E7,W18	E7,W21	E7,W24	E10,E13	E10,W15	E10,W18
E13	W15	W18	E10,W21	E10,W24	E13,W15	E13,W18	E13,W21	E13,W24	W15,W18	W15,W21
W21	W24		W15,W24	W18,W21	W18,W24	W21,W24	E1,E2	E5,E6	E9,E10	E12,E13

表 3 拉索损伤数据集组成

Table 3 Composition of cable damage dataset

损伤工况	训练集数据	测试集数据	合计
单根拉索损伤	$81 \times 6 \times 14 \times 10 = 68\ 400$	$9 \times 6 \times 14 \times 10 = 7\ 560$	$90 \times 6 \times 14 \times 10 = 75\ 600$
多根拉索损伤	$81 \times 6 \times 40 \times 10 = 194\ 400$	$9 \times 6 \times 40 \times 10 = 21\ 600$	$90 \times 6 \times 40 \times 10 = 216\ 000$

表 4 单损伤模式下各主成分训练集的最优超参数与该最优参数下测试集定位准确率

Table 4 Optimal hyperparameters of training set for each principal component under single damage mode and localization accuracy of test set under these optimal parameters

项目	寻优区间	各主成分下的超参数值					
		1	3	5	7	9	11
核函数参数 g	$[1 \times 10^3, 1 \times 10^{12}]$	$4.498\ 4 \times 10^5$	$3.477\ 2 \times 10^5$	$4.980\ 6 \times 10^5$	$9.939\ 4 \times 10^5$	$6.797\ 7 \times 10^5$	$8.193\ 7 \times 10^5$
惩罚参数 c	$[0, 100]$	$5.214\ 3 \times 10^{-5}$	$8.491\ 0 \times 10^{-6}$	$3.177\ 1 \times 10^{-5}$	$6.904\ 5 \times 10^{-6}$	$2.392\ 0 \times 10^{-5}$	$1.710\ 8 \times 10^{-5}$
损伤程度	准确率/%	100	100	100	100	100	100

任务中显现出卓越的准确性。




图 10 第 5 主成分下损伤定位混淆矩阵图

Figure 10 Damage localization confusion matrix under 5th principal component

表 5 单损伤模式下各主成分训练集的最优超参数与该最优参数下测试集损伤定量均方根误差

Table 5 Optimal hyperparameters of training set for each principal component under single damage mode and root mean square error of damage quantification in test set under these optimal parameters

项目	寻优区间	各主成分下的最佳参数组合					
		1	3	5	7	9	11
核函数参数 g	$[1 \times 10^3, 1 \times 10^{12}]$	9.9985×10^{11}	2.7023×10^{11}	4.5182×10^{11}	2.6807×10^{11}	1.1863×10^{11}	1.0793×10^{10}
惩罚参数 c	$[0, 100]$	23.143	10.379	1.7116	1.0074	4.4694	5.5119
损伤程度	均方根误差/%	0.0598	0.0554	0.0620	0.0601	0.0576	0.0556

表 6 多损伤模式下各主成分训练集的最优超参数与该最优参数下测试集定位准确率

Table 6 Optimal hyperparameters of training set for each principal component under multi-damage mode and localization accuracy of test set under these optimal parameters

项目	寻优区间	各主成分下最佳超参数组合					
		1	3	5	7	9	11
核函数参数 g	$[1 \times 10^3, 1 \times 10^{12}]$	9.8317×10^6	9.9581×10^6	5.6726×10^6	6.7325×10^6	9.2952×10^6	9.9533×10^6
惩罚参数 c	$[0, 100]$	0.002727	0.0080585	0.003051	0.004255	0.002491	0.003002
损伤程度	准确率/%	99.954	99.861	99.861	99.768	100.000	99.907




图 11 第 5 主成分下的部分多损伤定位混淆矩阵图

Figure 11 Partial multi-damage localization confusion matrix under 5th principal component

3.3 多损伤识别

3.3.1 损伤定位

构建LSSVM分类模型对斜拉桥主跨部分拉索的损伤进行精准定位,同样按照表2中多根损伤拉索组合的损伤情况分为40种类别,类别1代表斜拉索E1、E4损伤,类别2代表斜拉索E1、E7损伤,以此类推直到类别40代表斜拉索E12、E13损伤。结合40种组合下的216000个PCA压缩数据样本进行分类,经过贝叶斯优化后核函数参数与惩罚参数的最佳参数组合如表6所示,损伤定位结果如表6和部分定位结果混淆矩阵如图11所示。结果表明:多损伤定位中每个主成分压缩样本下核函数参数的最优值分布在 $1 \times 10^6 \sim 1 \times 10^7$,惩罚参数的最优值分布在0.001~0.01,在最优超参数组合下基本可以做到无误差定位。

3.3.2 损伤预测

针对40种多损伤组合下的压缩数据构造LSSVM多输出模型,在识别过程中发现将216000个压缩数据输入机器学习模型中,识别结果如图11所示,由于不同多根损伤拉索的振动响应之间存在显著的相关性,且多根拉索同时受损包含多个变量,数据呈现出复杂的非线性关系,最终使得识别效果并不理想。因此提出结合定位标签整合到压缩数据集中再定损的方法,结合3.3.1中的损伤定位后的定位信息,将定位结果作为附加的

标签信息融入数据集中。这一步骤不仅丰富了数据的特征空间,而且提供了损伤位置的关键信息,使LSSVM能够更有效地区分不同类型和程度的拉索损伤。每种主成分下的损伤预测结果如表7和图12、13所示,这种结合了定位信息标签的方法在损伤识别中能够显著提升预测的准确性。每个主成分压缩样本下,核函数参数的最优值分布于 $1 \times 10^{10} \sim 1 \times 10^{11}$,惩罚参数的最优值分布于0.1~10,在最佳模型下结合数据实现了有效的损伤程度预测。

表7 多损伤模式下各主成分训练集的最优超参数与该最优参数下测试集损伤定量均方根误差
Table 7 Optimal hyperparameters of training set for each principal component under multi-damage mode and root mean square error of damage quantification in test set under these optimal parameters

项目	寻优区间	各主成分下最佳超参数组合					
		1	3	5	7	9	11
核函数参数 g	$[1 \times 10^3, 1 \times 10^{12}]$	9.119 1 $\times 10^{10}$	1.015 7 $\times 10^{10}$	9.127 1 $\times 10^{10}$	9.695 9 $\times 10^{10}$	9.983 4 $\times 10^{10}$	4.146 8 $\times 10^{10}$
惩罚参数 c	[0,100]	2.091 4	0.233 4	0.806 3	0.693 4	1.423 5	1.186 1
L1*	均方根误差/%	0.425 8	0.268 5	0.289 6	0.549 1	0.269 8	0.304 4
L1	均方根误差/%	1.629 6	1.473 6	1.510 5	1.518 2	1.581 5	1.535 5
L2*	均方根误差/%	0.424 9	0.269 9	0.285 5	0.343 7	0.268 3	0.294 1
L2	均方根误差/%	1.631 5	1.475 5	1.512 1	1.522 4	1.579 2	1.540 2

注:L代表拉索,如L1代表损伤1号拉索,*代表添加定位标签数据。




图12 损伤拉索1在每个主成分下预测均方根误差图
Figure 12 Root mean square error of prediction for damage cable 1 under each principal component

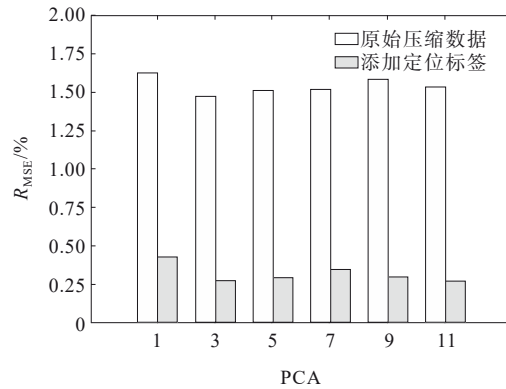


图13 损伤拉索2在每个主成分下预测均方根误差图
Figure 13 Root mean square error of prediction for damage cable 2 under each principal component

4 结论

本文针对斜拉桥的重要构件——斜拉索的损伤识别问题进行了研究,建立车桥耦合模型并进行车辆激励下的斜拉桥响应计算分析,在完成大规模参数的计算基础上,利用不同移动荷载作用下损伤斜拉索锚固点振动响应数据,通过PCA降维技术压缩

加速度数据,获得数据压缩样本;基于BO-LSSVM方法进行损伤定位与损伤预测,最后通过一座斜拉桥算例验证了该方法的可行性。得到以下主要结论:

- (1) PCA降维技术展现出卓越的数据压缩能力,不仅成功地减少了特征维度,更重要的是在降维的过程中保留了原始数据的关键信息,有效地捕获了

数据内在的变化趋势。降维后的特征集能够充分代表原始数据的特征,节约计算资源的同时实现了精准预测。

(2) 在大规模的数据类型下,构建 LSSVM 模型能够有效地解析复杂的压缩数据样本,提取响应数据中所包含的几何信息,实现损伤斜拉索的损伤定位与定量识别。贝叶斯优化能够自动帮助 LSSVM 寻找到最优核函数参数与惩罚参数的超参数组合,提高 LSSVM 的预测精度,同时有效降低了调参复杂性。

(3) 在损伤定位研究中,核函数参数的最优值为 $1 \times 10^5 \sim 1 \times 10^7$,惩罚参数的最优值小于 0.01。定量的研究中,核函数参数的最优值为 $1 \times 10^{10} \sim 1 \times 10^{12}$,惩罚参数的最优值为 0.1~10。该结果为实际工程中损伤识别更快速地找到最佳超参数组合提供了研究基础。

(4) 在多根拉索损伤的损伤数据识别研究中,将整组压缩后的数据放入机器学习中的训练效果并不理想。因此,提出了结合定位标签作为机器学习中的一组特征值的方法,定位标签的融入有效提高了在大规模多根拉索损伤数据下进行损伤预测的精度。

参考文献:

References:

- [1] 徐郁峰,张展涛,谢云飞,等.大跨度斜拱曲梁桥施工监控关键技术研究[J].中外公路,2025,45(3):121-129.
XU Yufeng, ZHANG Zhantao, XIE Yunfei, et al. Research on key construction monitoring technology of long-span skewed arch and curved beam bridge[J]. Journal of China & Foreign Highway,2025,45(3):121-129.
- [2] 刘洪双,翟文强,曾国良.斜拉桥结构变形监测数据温度时滞效应消除方法[J].中外公路,2024,44(6):148-158.
LIU Hongshuang, ZHAI Wenqiang, ZENG Guoliang. Elimination method of temperature lag effect in deformation monitoring data of cable stayed bridge structures[J]. Journal of China & Foreign Highway,2024, 44(6):148-158.
- [3] 邓露,何维,俞扬,等.公路车-桥耦合振动的理论和应用研究进展[J].中国公路学报,2018,31(7):38-54.
DENG Lu, HE Wei, YU Yang, et al. Research progress in theory and applications of highway vehicle-bridge coupling vibration[J]. China Journal of Highway and Transport,2018,31(7):38-54.
- [4] 单德山,罗凌峰,李乔.桥梁健康监测 2019 年度研究进展[J].土木与环境工程学报(中英文),2020,42(5):115-125.
SHAN Deshan, LUO Lingfeng, LI Qiao. State-of-the-art review of the bridge health monitoring in 2019[J]. Journal of Civil and Environmental Engineering, 2020, 42(5): 115-125.
- [5] AN Y H, CHATZI E, SIM S H, et al. Recent progress and future trends on damage identification methods for bridge structures[J]. Structural Control and Health Monitoring, 2019,26(10):2416
- [6] 战家旺,夏禾,陈上有,等.基于车激响应和灵敏度分析的桥梁结构损伤识别方法研究[J].工程力学,2011,28(11): 38-44.
ZHAN Jiawang, XIA He, CHEN Shangyou, et al. Damage detection of bridges based on train-induced bridge response and sensitivity analysis[J]. Engineering Mechanics, 2011,28(11):38-44.
- [7] FENG D M, FENG M. Output-only damage detection using vehicle-induced displacement response and mode shape curvature index[J]. Structural Control and Health Monitoring,2016,23:1088-1107.
- [8] KIM C W, ZHANG F L, CHANG K C, et al. Ambient and vehicle-induced vibration data of a steel truss bridge subject to artificial damage[J]. Journal of Bridge Engineering,2021,26(7):04721002
- [9] ZHANG H, ZHONG Z X, DUAN J M, et al. Damage identification method for medium- and small-span bridges based on macro-strain data under vehicle-bridge coupling [J]. Materials,2022,15(3):1097.
- [10] 王智文,毛永嘉,丁幼亮.基于 Matlab JAVA 融合的桥梁健康监测数据分析与预警平台[J].中外公路,2023,43(4): 137-140.
WANG Zhiwen, MAO Yongjia, DING Youliang. Data analysis and early warning platform for bridge health monitoring based on Matlab JAVA fusion[J]. Journal of China and Foreign Highway,2023,43(4):137-140.
- [11] 张荣,李伟平,莫同.深度学习研究综述[J].信息与控制, 2018,47(4):385-397,410.
ZHANG Rong, LI Weiping, MO Tong. Review of deep learning[J]. Information and Control, 2018, 47(4): 385-397,410.
- [12] 郭桥,梁柱,沈国栋,等.基于知识图谱及机器学习的桥梁病害智能诊断方法[J].公路,2023,68(10):329-334.
Guo Qiao, Liang Zhu, Shen Guodong, et al. An intelligent diagnosis method for bridge diseases based on knowledge graph and machine learning [J]. Highway, 2023, 68(10): 329-334.
- [13] 刘军华,刘宾,曹海峰,等.基于机器学习的高温下混凝土力学性能研究[J/OL].中外公路,1-17(2025-06-27)[2025-08-22]. <https://link.cnki.net/urlid/43.1363.U.20250627.1412.010>.
LIU Junhua, LIU Bin, CAO Haifeng, et al. Research on mechanical properties of concrete under high temperatures based on machine learning[J/OL]. Journal of China & Foreign Highway, 1-17(2025-06-27) [2025-08-22]. <https://link.cnki.net/urlid/43.1363.U.20250627.1412.010>.
- [14] SANTANIELLO P, RUSSO P. Bridge damage identification using deep neural networks on time-frequency signals

- representation[J].Sensors,2023,23(13):6152.
- [15] HAJIALIZADEH D. Deep learning-based indirect bridge damage identification system[J]. Structural Health Monitoring,2023,22(2):897-912.
- [16] HAJIALIZADEH D. Machine-learning-based bridge damage detection using train-borne measurements[J]. Proceedings of the Institution of Civil Engineers-Smart Infrastructure and Construction,2023:1-15.
- [17] SONG X, DYOGI J, CHO C. Vibration-based bridge damage detection using image-based pre-trained deep learning network[C]//Dearborn: Proceedings of ASME 2022 Conference on Smart Materials, Adaptive Structures and Intelligent Systems,2022
- [18] SARWAR M Z, CANTERO D. Deep autoencoder architecture for bridge damage assessment using responses from several vehicles[J].Engineering Structures, 2021,246:113064.
- [19] MARAFINI F. A proposal of classification for machine-learning vibration-based damage identification methods [C]//Palermo: Theoretical and Applied Mechanics-AIMETA 2022,Materials Research Proceedings,2023.
- [20] LI Z K, LIN W W, ZHANG Y Q. Drive-by bridge damage detection using Mel-frequency cepstral coefficients and support vector machine[J]. Structural Health Monitoring, 2023,22(5):3302-3319.
- [21] LI Z K, LAN Y F, LIN W W. Investigation of frequency-domain dimension reduction for A²M-based bridge damage detection using accelerations of moving vehicles [J].Materials,2023,16(5):1872.
- [22] LAN Y F, LI Z K, LIN W W. A time-domain signal processing algorithm for data-driven drive-by inspection methods: An experimental study[J]. Materials, 2023, 16(7): 2624.
- [23] 李延强,刘得运.基于小波包分析与支持向量机的斜拉索损伤识别[J].石家庄铁道大学学报(自然科学版),2020, 33(2):118-123,129.
- LI Yanqiang, LIU Deyun. Damage identification of stay cables based on wavelet packet analysis and support vector machine[J]. Journal of Shijiazhuang Tiedao University (Natural Science Edition), 2020, 33(2): 118-123,129.
- [24] 蒋雍建,刘逸平,周立成,等.基于桥梁响应统计信息的智能损伤识别方法[J].合肥工业大学学报(自然科学版), 2019,42(12):1667-1671.
- JIANG Yongjian, LIU Yiping, ZHOU Licheng, et al. Intelligent damage recognition method based on bridge response statistical information[J]. Journal of Hefei University of Technology(Natural Science), 2019, 42(12): 1667-1671.
- [25] LEITÃO F N, DA SILVA J G S, DA S VELLASCO P C G, et al. Composite (steel-concrete) highway bridge fatigue assessment[J]. Journal of Constructional Steel Research, 2011,67(1):14-24.
- [26] 刘华全,杨得海,蔡成奇,等.高墩连续刚构桥车桥耦合振动分析[J].中外公路,2023,43(2):133-139.
- LIU Huaquan, YANG Dehai, CAI Chengqi, et al. Analysis on vehicle-bridge interaction of high-pier continuous rigid frame bridge[J]. Journal of China & Foreign Highway, 2023,43(2):133-139.
- [27] 崔佳旭,杨博.贝叶斯优化方法和应用综述[J].软件学报, 2018,29(10):3068-3090.
- CUI Jiaxu, YANG Bo. Survey on Bayesian optimization methodology and applications[J]. Journal of Software, 2018,29(10):3068-3090.