

DOI: 10.7511/jslx20220726002

环境温度影响下基于 LSTM 神经网络识别结构损伤

黄炎, 葛思源, 翟慕赛, 常军*

(苏州科技大学 土木工程学院, 苏州 215011)

摘要: 环境温度的改变会引起模态参数的变化, 其变化程度会掩盖或部分掩盖损伤引起的变化量, 导致结构健康监测系统发出假阳性或假阴性的误判, 因此, 消除温度效应是提高损伤识别精度的关键。本文基于 LSTM 神经网络提出了一种环境温度影响下识别结构损伤的方法。充分利用 LSTM 神经网络的非线性映射优势, 建立多元温度-模态频率的相关模型, 在此基础上采用数据标准化方法消除温度效应, 并结合控制图判断模态频率异常变化以确定损伤状况。最后将所提方法在数值模型和实际桥梁中加以应用, 结果表明, 方法能够有效消除温度效应; 结合控制图能识别损伤时刻, 并具有一定的抗噪性; 在实桥数据分析中仍能表现出较好的损伤敏感性。

关键词: LSTM 神经网络; 结构健康监测; 温度; 模态频率; 变分模态分解

中图分类号: U441⁺.3; O346.5

文献标志码: A

文章编号: 1007-4708(2024)02-0248-08

1 引言

桥梁建成运营期间, 受自然环境因素或日益剧增交通量的影响, 造成桥梁结构老化、性能逐渐衰退, 健康监测系统能实时监测结构的动力特性, 有利于桥梁维护管养决策^[1], 如润扬长江大桥、苏通大桥和汀九桥^[2-4]等均安装了健康监测系统。模态参数的改变通常是结构损伤识别的依据, 但实际监测过程中, 模态参数会随环境因素的改变而变化^[5], 其变化程度会掩盖或部分掩盖结构损伤引起的变化。研究表明环境温度是引起模态频率变化的主要原因^[6,7], 如 Peeters 等^[8]分析 Z24 桥近一年的监测数据发现, 环境因素引起的频率变化高达 10%~17%; 然而, 切断 Z24 桥一根桥墩并使其下沉 95 mm, 梁底出现多条裂缝, 频率仅降低 6.4%~7.9%^[9]; 孙君等^[10]通过分析润扬大桥悬索桥模态频率变化, 发现模态频率日平均值最小变化为 0.649%, 最大为 2.186%, 高阶频率变化更明显。因此, 从环境温度影响下的结构动力特性中准确识别结构状态(损伤或未损伤), 避免假阴性和假阳性误判至关重要。

基于振动的结构损伤检测中, 消除环境温度效应的方法主要有两类。一类是非参数方法, 如因子

分析^[11]、鲁棒奇异值分解^[12]、主成分分析^[13]和基于子空间^[14]的方法; 另一类是参数方法, 根据桥梁健康监测系统同步监测信号建立环境温度与结构动力特性的相关模型, 如神经网络^[15,16]和支持向量回归^[17]方法。在参数方法中, 数据标准化^[18]在消除环境效应上十分有效, 旨在获得非平稳信号的一种平稳表示, 这种表示不包括环境效应, 因此能更加可靠地用于监测结构。

长短时记忆 LSTM(Long Short-Term Memory)神经网络是以 BP 神经网络(BPNN)为基础引入记忆的概念, 在处理前后相互关联的超长序列数据时处于相对优势的地位, 如处理长期同步监测的温度和模态频率等。本文基于 LSTM 神经网络, 提出了一种环境温度影响下识别结构损伤的方法。首先采用变分模态分解 VMD(Variational Mode Decomposition)预处理数据, 并采用网格搜索算法优选 LSTM 神经网络超参数; 然后建立温度-频率的神经网络模型, 通过数据标准化方法消除温度效应, 并结合控制图识别频率异常变化; 最后将该方法在数值模型和实际桥梁中加以应用。

2 LSTM 神经网络和变分模态分解

2.1 LSTM 神经网络基本原理

与传统 BPNN 相比, LSTM 神经网络同样包含输入层、隐藏层和输出层, 但 LSTM 神经网络在同一隐藏层(LSTM 层)神经元内部增加权重连接引入定向循环^[19], 如图 1 所示, 其输出不仅依赖当前输入, 还与之前的输入有关(又称记忆)。其中

收稿日期: 2022-07-26; 修改稿收到日期: 2022-09-19.

基金项目: 国家自然科学基金(51908395); 江苏省高等学校自然科学研究项目(19KJB580004); 江苏省研究生科研与实践创新计划项目(SJCX22_1569)资助.

作者简介: 常军*(1973-), 男, 博士, 教授
(E-mail: changjun21@126.com).

LSTM 细胞是隐藏层核心,通过非线性激活函数控制的三道闸门实现添加或者删减信息,分别为输入门、遗忘门和输出门。三道闸门输出阈值均为 $(0,1)$,1 表示完全保留,0 表示完全舍弃。如式(1)所示,遗忘门由 f_t 控制从上一时刻细胞状态 C_{t-1} 传入当前细胞状态 C_t 的信息量;式(2,3)是输入门的两个组成部分,分别由 i_t 和 a_t 共同控制输入到当前细胞状态 C_t 的新信息量;当前细胞状态 C_t 的更新过程见式(4);基于更新的细胞状态 C_t ,由式(5)计算输出门 o_t ,由式(6)计算隐藏状态 h_t 。LSTM 神经网络工作过程包括前项传播和反向传播。在前向传播中,依次更新 $f_t, i_t, a_t, C_t, o_t, h_t$ 和 y_t ,其计算流程如式(1~7)所示;反向传播即通过梯度下降法迭代更新所有的参数。

$$f_t = \sigma(W_{hf} h_{(t-1)} + U_{xf} x_t + b_f) \quad (1)$$

$$i_t = \sigma(W_{hi} h_{(t-1)} + U_{xi} x_t + b_i) \quad (2)$$

$$a_t = \tanh(W_{ha} h_{(t-1)} + U_{xa} x_t + b_a) \quad (3)$$

$$C_t = C_{(t-1)} \cdot f_t + i_t \cdot a_t \quad (4)$$

$$o_t = \sigma(W_{ho} h_{(t-1)} + U_{xo} x_t + b_o) \quad (5)$$

$$h_t = o_t \cdot \tanh(C_t) \quad (6)$$

$$y_t = \sigma(V_{hy} h_t + b_y) \quad (7)$$

式中 下标 i, f 和 o 分别为输入门、遗忘门和输出门, $\sigma(\cdot)$ 为非线性激活函数, $W_{hf}, W_{hi}, W_{ha}, W_{ho}, U_{xf}, U_{xi}, U_{xa}, U_{xo}$ 和 V_{hy} 为权重矩阵, b_f, b_i, b_a, b_o 和 b_y 为偏置矩阵, $\tanh(\cdot)$ 为双曲正切函数, $h_{(t-1)}$ 和 h_t 为上一时刻和当前时刻 LSTM 细胞输出, x_t 和 y_t 为当前时刻网络的输入和输出。




图1 LSTM神经网络结构

Fig. 1 Structure diagram of LSTM neural network

2.2 LSTM神经网络参数优选

最优超参数可以提高 LSTM 神经网络学习的性能和效果,相较诸多的超参数优化方法(粒子群、随机搜索算法等),当待定的超参数较少时,网格搜索算法更简单高效^[20]。网格搜索算法是指定参数值的一种穷举搜索方法,预选各个参数可能的取值并进行排列组合,列出所有可能的组合形成网格,然后将各组合用于模型训练来确定最佳参数。LSTM 神经网络主要有 3 个重要的超参数,即隐藏层神经元数量,即状态向量大小 S_{state} ; 样本长度

L ; 控制网络调参幅度的学习率 α 。

2.3 变分模态分解

Dragomiretskiy 等^[21]提出 VMD 分解法,其是一种自适应信号处理方法,能将复杂信号分解为多个具有特定稀疏特性的模态函数。假设每个模态是具有不同中心频率的有限带宽,通过迭代搜寻变分模态的最优解,不断更新各模态函数及中心频率,最终将各个模态及相应的中心频率全部提取。VMD 需要指定一些参数,主要包括惩罚因子、模态个数、判别精度和保真系数^[22],其中判别精度和保真系数的影响相对于前两者小得多,因此可采用标准 VMD 中默认的参数值。目前,确定惩罚因子和模态个数的方法并没有统一标准,有采用中心频率法确定,也有先采用 VMD 分解再分析频谱的方法。由于温度数据中包含低频信号(年周期)和高频信号(日周期),导致结构产生对应频率的信号分量,根据 Worden 等^[23]研究可得,低频信号分量比高频信号分量表现出更强的损伤敏感性。因此,本文确定 VMD 参数的方法是以日温差效应对应的中心频率 ω_0 为基准,调整参数使得 VMD 分解出中心频率为 ω_0 的分量,即可去除日温差效应对应的分量,保留损伤效应的同时提升 LSTM 神经网络的效果。

3 基于 LSTM 识别结构损伤的方法

3.1 模态特征标准化和损伤指标

将温度和频率数据作为 LSTM 训练的输入和输出向量,建立温度-频率的网络模型,由式(8)得到消除温度效应的模态频率 f_i^N ,并计算其均值 \bar{f}_i^N ,定义频率实测值 f_i^{lab} 与网络仿真值 f_i^{pre} 的残差 e 占 \bar{f}_i^N 的百分比为异常指标 e_{pi} ,见式(9)。

$$f_{i,j}^N = f_{i,j}^{lab} - \Delta f_{i,j}^T = f_{i,j}^{lab} - (f_{i,j}^{pre} - f_i^R) \quad (8)$$

$$e_{pi,j} = \frac{e}{\bar{f}_i^N} = \frac{f_{i,j}^{pre} - f_{i,j}^{lab}}{\bar{f}_i^N} \quad (9)$$

式中 Δf_i^T 为频率的温度影响量, f_i^R 模态频率参考值,即指定参考温度对应的频率实测值; i 和 j 分别为模态频率阶数和序列中的样本顺序。

采用均值控制图对模态频率的异常变化进行统计模式识别。均值控制图是一种统计方法设计的图,包含中心线(CL)、上控制线(UCL)、下控制线(LCL)和一系列样本点的描述序列^[10]。其中上下控制线是按照一定的置信度得到的置信区间。若样本点在控制线之间,则认为该样本点正常;反之,则认为该样本点异常。

3.2 损伤识别流程

损伤识别流程如图2所示,具体步骤如下。

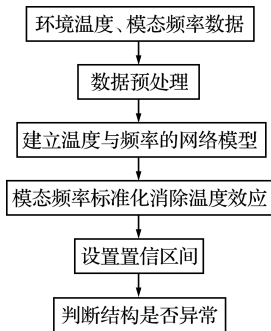


图2 结构损伤识别流程

Fig. 2 Flow chart of structural damage identification

(1) 数据预处理。采用 VMD 分解温度和频率数据,并通过 Z-Score 函数消除数据量纲影响,有利于 LSTM 梯度下降求最优解,即

$$x^* = (x - \bar{x}) / s \quad (10)$$

式中 x^* 为消除量纲的数据, x 为 VMD 分解后的数据, \bar{x} 和 s 分别为 x 的均值和标准差。

(2) 建立 LSTM 神经网络模型。首先采用网格搜索算法优选 LSTM 超参数;然后根据训练集和验证集建立温度与频率的神经网络模型;最后将温度向量 \mathbf{T} 输入模型,得到对应的频率仿真值。

(3) 模态频率标准化。将平均温度对应的频率仿真值指定为参考频率 f_i^R , 并根据式(8)得到 f_i^N 。

(4) 结构损伤识别。由式(9)计算 $e_{i,p}$, 根据训练集和验证集确定置信区间,将测试集作为未知状态判断结构是否异常。

4 数值算例

4.1 算例模型

根据某实桥温度监测数据,包括 1 个空气温度传感器 AT 和 6 个布置在结构内的温度传感器 (TS1, TS2, ..., TS6), 截面尺寸及传感器位置如图 3(a) 所示,顶板和底板厚 0.2 m,腹板厚 0.4 m,以传感器分布情况将截面分成 6 个区域,假定每个区域内温度一致且等于传感器数值,建立混凝土箱型简支梁桥数值模型,跨径 30 m,划分 30 个单元,如图 3(b) 所示。混凝土密度为 2500 kg/m^3 ,温度线膨胀系数为 1.0×10^{-5} [6],拟定混凝土弹性模量-温度关系曲线,如图 4 所示。图 5 是每小时记录一次的温度数据,共 5000 组,图 6 为前 5 阶模态频率,其中前 4600 h 为结构健康状态,4601 h~4800 h 模拟梁四分点(第 8 单元)发生 5% 的损伤,4801 h~5000 h 模拟结构修复后恢复健康状态。

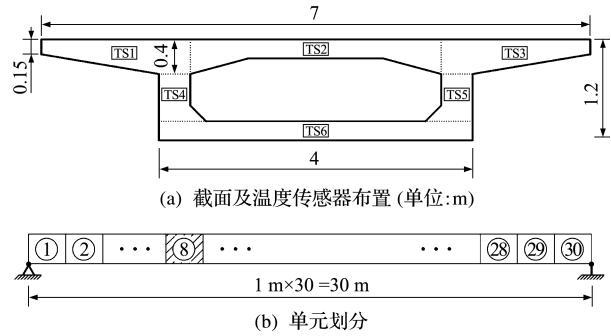


图3 简支梁

Fig. 3 Simply supported beam




图4 混凝土弹性模量随温度变化曲线

Fig. 4 Curve of Elastic Modulus of Concrete with temperature




图5 传感器温度曲线

Fig. 5 Temperature curve of sensors




图6 前5阶模态频率

Fig. 6 Modal frequencies for the first five modes

4.2 温度对模态频率影响量

以第 1 阶频率为例,取 AT 的平均值作为参考温度,并将此温度状态下的频率指定为参考值,当温度在 $-9.69 \text{ }^\circ\text{C} \sim 36.5 \text{ }^\circ\text{C}$ 变化时,模态频率变化

率如图 7 所示。为了模拟结构状态改变对结构动力特性的影响,以第 8 单元发生损伤为例,通过降低单元刚度分别模拟 5%,10%,...,45%,50% 的损伤程度。以无损时模态频率为参考值,不同损伤程度对应模态频率变化率如图 7 所示。显然温度影响量超过第 8 单元发生 50% 损伤导致的变化量,若在不剔除温度影响效应的情况下使用模态频率识别损伤,需要结构发生损伤引起的变化量大于环境温度引起的变化量,此时结构将会发生较大程度的损伤,因此需要剔除温度效应,才能准确识别结构发生的微小损伤。此外,由于温度引起的频率变化率与频率本身的变化一一对应,从图 7 可以看出,温度与频率变化率之间呈现较强的离散性,也即温度与频率之间具有较强的离散性关系。




图 7 第 1 阶模态频率变化率
Fig. 7 Change rate of the first modal frequency

4.3 建立 LSTM 神经网络模型

将 5000 组数据分为训练集(0,4000)、验证集(4001,4500)和测试集(4501,5000)。通过 VMD 分解信号,监测数据间隔为 1 h,日温差效应对应的中心频率约为 0.0416,以空气温度(AT)为例,

按照 2.3 节所述,将 VMD 分解的参数设置为,模态个数为 2,惩罚因子为 2000,其余参数采用标准 VMD 默认值。此时,中心频率最接近 0.0416 的分量分离出来,保留的分量与 AT 原始值如图 8 所示,可以看出采用 VMD 分解的方法能有效去除与损伤无关的高频波动。




图 8 VMD 分解的环境温度
Fig. 8 Ambient temperature of VMD decomposition

采用网格搜索算法优选 LSTM 神经网络超参数,先固定重要性相对较低的超参数 epochs = 100;再预设重要超参数的范围 $S_{state1} \in [32, 64, 128]$, $S_{state2} \in [32, 64, 128]$, $L \in [5, 10, 20, 30]$, $\alpha \in [0.01, 0.001, 0.0001]$ 。

确定最优超参数组合为 $S_{state1} = 128$, $S_{state2} = 64$, $L = 20$, $\alpha = 0.001$,使神经网络充分迭代 500 次,即 epochs = 500,并且每迭代 100 次学习率下降 0.0001。最后结合均方根误差、平均绝对值误差、平均相对误差及相关系数对分别对训练集和验证集进行定量评价,本文记作模型评定指标。由表 1 可知,通过 LSTM 神经网络得到的频率仿真值与测试值之间的相关性较高,其中第 3 阶和第 4 阶频率的模型回归效果最为理想。

表 1 训练集和验证集的回归误差及与实测结果的相关性

Tab. 1 Regression errors of training set and validation set and their correlation with measured results

	训练集					验证集				
	f_1	f_2	f_3	f_4	f_5	f_1	f_2	f_3	f_4	f_5
均方根误差($\times 10^{-3}$)/Hz	0.2365	0.6861	0.2019	0.2821	0.4359	0.6556	1.8203	0.466	0.7334	0.8131
平均绝对误差($\times 10^{-3}$)/Hz	0.1825	0.5273	0.1493	0.1682	0.326	0.5495	1.5347	0.3922	0.6269	0.7019
平均相对误差/%	0.007	0.0057	0.0011	0.001	0.0015	0.0213	0.0169	0.0029	0.0031	0.0032
相关系数	0.9857	0.9868	0.9985	0.9986	0.9872	0.974	0.975	0.9851	0.9845	0.9831

4.4 结构损伤识别

采用 3.1 节所述方法对模态频率的异常变化进行判别分类,基本步骤如下。

(1) 选定模态频率参考值 f_i^R (AT 平均温度对应模态频率仿真值),采用式(8)得到去除温度影响的模态频率 f_i^N 。以第 1 阶频率为例, f_1^N 与频率

f_1^{lab} 如图 9 所示。可以看出, f_1^N 是 f_1^{lab} 的一种平稳表示,不包含温度效应。

(2) 选择回归效果最好的第 3 阶和第 4 阶频率,基于训练集和验证集数据,由式(9)结合控制图确定置信区间。

(3) 将测试集作为未知状态,计算 e_p ,并与式

(2)的控制图绘制在一起,如图10所示。可以看出,在4601时刻附近发生跳跃,持续约200 h回归正常范围,符合假定的4601 h~4800 h发生损伤,并且结构修复后方法仍可用于结构损伤识别。




图9 第1阶频率原始值与标准化

Fig. 9 Original value and normalization of the first modal frequency




图10 全部样本均值控制

Fig. 10 Mean value control chart of all samples

4.5 噪声对损伤识别的影响

由于受环境噪声影响,指标识别结果往往会产生较大误差,为了验证方法的抗噪性能,采用式(11)考虑20%的高斯白噪声^[25],考虑噪声之后的控制如图11所示。可以看出,相较于不考虑噪声时,置信区间内样本波动幅度增大,但并不影响结构损伤识别的效果,表明方法具有良好的抗噪鲁棒性。

$$\hat{f}_i = f_i + \frac{k}{100} \mathbf{n}_{\text{noise}} \sigma(f_i) \quad (11)$$

式中 f_i 和 \hat{f}_i 分别为无噪声和考虑噪声的模式频率时间序列, $\sigma(f)$ 和 k 分别为 f_i 的标准差和噪声水平 ($k=20$), $\mathbf{n}_{\text{noise}}$ 是与 f_i 相同长度的符合标准正态分布的随机自变量向量。




图11 20%噪声水平下的均值控制

Fig. 11 Mean value control chart at 20% noise

通过数值模拟,考虑了截面温度的不均匀分布,结果表明方法能有效消除环境温度效应,识别结构损伤时刻,并能用于修复后的结构健康监测。在考虑20%噪声的情况下,仍能识别损伤,本文结合工程实例分析该方法的可行性。

5 实例分析

5.1 工程概况

以香港汀九桥健康监测同步监测的温度和模态频率为例^[26]。如图12所示,汀九桥是一座多跨斜拉桥,有三个塔柱。两个主跨分别为448 m和475 m,两个侧跨均为127 m。该桥健康监测系统中共有83个温度传感器,分别用于监测五个温度类别,(1)钢梁温度;(2)混凝土桥面内部温度;(3)塔腿温度;(4)沥青路面温度;(5)大气温度。此外,在桥面、纵向拉索、三座塔的顶部和中塔底部共安装了24个单轴加速度计、20个双轴加速度计和1个三轴加速度计,温度传感器和加速度计在汀九桥的布置情况如图13所示。



图12 汀九桥

Fig. 12 Ting Kau Bridge




图13 汀九桥温度传感器和加速度计布置

Fig. 13 Deployment of temperature sensors and accelerometers on Ting Kau Bridge

表 2 训练集误差及相关性
Tab. 2 Error and correlation of training data set

	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8
均方根误差($\times 10^{-3}$)/Hz	0.159	0.065	0.155	0.164	0.051	0.346	0.116	0.061
平均绝对误差($\times 10^{-3}$)/Hz	0.110	0.042	0.123	0.118	0.030	0.277	0.083	0.046
平均相对误差/%	0.066	0.018	0.047	0.041	0.010	0.087	0.023	0.012
相关系数	0.983	0.986	0.988	0.990	0.994	0.988	0.993	0.991

表 3 验证集误差及相关性
Tab. 3 Error and correlation of verification data set

	f_1	f_2	f_3	f_4	f_5	f_6	f_7	f_8
均方根误差($\times 10^{-3}$)/Hz	0.396	0.124	0.337	0.271	0.107	0.786	0.263	0.104
平均绝对误差($\times 10^{-3}$)/Hz	0.307	0.104	0.248	0.206	0.091	0.603	0.214	0.084
平均相对误差/%	0.185	0.046	0.095	0.071	0.060	0.189	0.030	0.022
相关系数	0.955	0.965	0.941	0.971	0.963	0.914	0.973	0.978

5.2 数据的选取与处理

取弱风条件下(每小时平均风速小于 2 m/s)的 770 组模态频率(前 8 阶)及同步监测的温度数据,从五类监测温度中每一类选择四个温度传感器,即不同部位的 20 个温度传感器,详细数据描述参照文献^[26]。770 h 分别为 2 月份 185 h,3 月份 35 h,6 月份 95 h,7 月份 208 h,8 月份 95 h,12 月份 152 h。将 770 组模态频率和温度数据以时间顺序排列,按奇偶分成两部分,前一部分的 385 组数据为训练集,后一部分 1/2,即 193 组数据为验证集,另外 192 组数据为测试集。

采用 3.2 节流程判别结构是否损伤,通过 VMD 分解法预处理数据,并采用网格搜索算法确定 LSTM 神经网络的最优超参数组合($S_{state1} = 128, S_{state2} = 32, L = 3, \alpha = 0.0005, epochs = 2000$)。用模型评定指标分别对训练集、验证集进行定量评价,列入表 2 和表 3。由表 2 和表 3 可知,模态频率仿真值与测试值之间的相关性较高,其中第 7 阶和第 8 阶频率的模型回归效果最为理想。根据这两阶频率的训练集和验证集确定置信区间,测试集作为未知状态,与正常状态下的样本点绘制在同一幅控制图(图 14),可以看出测试集所有样本点均在置信区间内,即结构未发生损伤,与汀九桥实际运营情况相符。




图 14 汀九桥全部样本均值控制
Fig. 14 Mean value control chart of all samples of Ting Kau Bridge


5.3 模拟损伤

为了考察该方法应用于结构损伤识别的效果,对测试集样本最后 40 组实测模态频率数据按式(14)施加一定的变化,用以模拟结构损伤对模态频率的影响^[10]


$$f_i = f_i^{lab} - \epsilon \bar{f}_i^{lab} \quad (14)$$

式中 f_i^{lab} 为第 i 阶模态频率实测值, f_i 为模拟损伤后第 i 阶模态频率值, ϵ 为模拟损伤程度,取 0.2% 和 0.3%; \bar{f}_i^{lab} 为第 i 阶模态频率实测值的平均值。

如图 15 所示,当结构损伤引起模态频率发生 0.2% 的变化时,均值控制图不能明确判别结构异常;但结构损伤引起模态频率发生 0.3% 的变化时,后 40 个样本点明显偏离均值控制线,并且大部分样本已超出控制范围,可以判定结构发生异常。文献^[27]对汀九桥案例研究表明,当损伤引起的频



(a) 模态频率 0.2% 的变化



(b) 模态频率 0.3% 的变化

图 15 结构损伤状态下的均值控制
Fig. 15 Mean value control chart of the damaged structure

率变化小于1%时,无法检测到损伤的发生。相比之下,所提方法对结构损伤引起的异常变化更敏感。

6 结 论

在役桥梁由于环境温度的影响,频率发生波动是不可避免的。基于 LSTM 神经网络建立的温度-模态频率相关模型,采用数据标准化方法消除温度效应,结合控制图判别结构异常变化,为桥梁维护策略的制定提供有效依据。主要结论如下。

(1) LSTM 神经网络能较准确描述温度-频率的非线性关系,有效去除频率中的温度效应。

(2) 结合控制图能识别模态频率的微小异常变化。数值模拟结果表明方法能识别结构损伤时刻,并具有一定的抗噪能力。

(3) 将方法用于分析实际工程数据,结果表明具有一定的损伤敏感性。

参考文献(References):

- [1] 李宏男,李东升. 土木工程结构安全性评估、健康监测及诊断述评[J]. 地震工程与工程振动, 2002, **22**(3): 82-90. (LI Hong-nan, LI Dong-sheng. Safety assessment, health monitoring and damage diagnosis for structures in civil engineering[J]. *Earthquake Engineering and Engineering Dynamics*, 2002, **22**(3): 82-90. (in Chinese))
- [2] 李爱群,缪长青,李兆霞,等. 润扬长江大桥结构健康监测监测系统研究[J]. 东南大学学报(自然科学版), 2003, **33**(5): 544-548. (LI Ai-qun, MIAO Chang-qing, LI Zhao-xia, et al. Health monitoring system for the Runyang Yangtze River Bridge[J]. *Journal of Southeast University(Natural Science Edition)*, 2003, **33**(5): 544-548. (in Chinese))
- [3] 余波,邱洪兴,王浩,等. 苏通大桥结构健康监测系统设计[J]. 地震工程与工程振动, 2009, **29**(4): 170-177. (YU Bo, QIU Hong-xing, WANG Hao, et al. Health monitoring system for Sutong Yangtze River Bridge[J]. *Journal of Earthquake Engineering and Engineering Vibration*, 2009, **29**(4): 170-177. (in Chinese))
- [4] Wong K Y. Instrumentation and health monitoring of cable-supported bridges[J]. *Structural Control and Health Monitoring*, 2004, **11**(2): 91-124.
- [5] Sohn H. Effects of environmental and operational variability on structural health monitoring[J]. *Philosophical Transactions of the Royal Society of London Series A*, 2007, **365**(1851): 539-560.
- [6] Xia Y, Hao H, Zanardo G, et al. Long term vibration monitoring of an RC slab: Temperature and humidity effect[J]. *Engineering Structures*, 2006, **28**(3): 441-452.
- [7] 杨鸥,刘洋,李惠,等. 时变环境与损伤耦合下桥梁结构频率及阻尼比的统计分析[J]. 计算力学学报, 2010, **27**(3): 457-463. (YANG Ou, LIU Yang, LI Hui, et al. Cable bridge modal parameter statistical analysis under the time varying environment coupled with damage[J]. *Chinese Journal of Computational Mechanics*, 2010, **27**(3): 457-463. (in Chinese))
- [8] Peeters B, de Roeck G. One-year monitoring of the Z24-Bridge: Environmental effects versus damage events[J]. *Earthquake Engineering & Structural Dynamics*, 2001, **30**(2): 149-171.
- [9] Maeck J, de Roeck G. Description of Z24 benchmark[J]. *Mechanical Systems and Signal Processing*, 2003, **17**(1): 127-131.
- [10] 孙君,李爱群,丁幼亮,等. 润扬大桥悬索桥模态频率-温度的季节相关性研究及其应用[J]. 工程力学, 2009, **26**(9): 50-55. (SUN Jun, LI Ai-qun, DING You-liang, et al. Research on correlation of modal frequency and seasonal temperature of Runyang suspension bridge[J]. *Engineering Mechanics*, 2009, **26**(9): 50-55. (in Chinese))
- [11] Kullaa J. Elimination of environmental influences from damage-sensitive features in a structural health monitoring system[A]. Proceedings of the first European workshop on structural health monitoring[C]. 2002.
- [12] Vanlanduit S, Parloo E, Cauberghe B, et al. A robust singular value decomposition for damage detection under changing operating conditions and structural uncertainties[J]. *Journal of Sound and Vibration*, 2005, **284**(3-5): 1033-1050.
- [13] Giraldo D F, Dyke S J, Caicedo J M. Damage detection accommodating varying environmental conditions[J]. *Structural Health Monitoring*, 2006, **5**(2): 155-172.
- [14] Basseville M, Bourquin F, Mevel L, et al. Handling the temperature effect in vibration monitoring: Two subspace-based analytical approaches[J]. *Journal of Engineering Mechanics*, 2010, **136**(3): 367-378.
- [15] Ni Y Q, Zhou H F, Ko J M. Generalization capability of neural network models for temperature-frequency correlation using monitoring data[J]. *Journal of Structural Engineering*, 2009, **135**(10): 1290-1300.
- [16] Zhou H F, Ni Y Q, Ko J M. Performance of neural networks for simulation and prediction of temperature-induced modal variability[A]. Proceedings of SPIE—The International Society for Optical Engineering[C]. 2005.
- [17] 雷勇志,黄民水,顾箭峰,等. 环境温度影响下基于支持向量机与强化飞蛾扑火优化算法的结构稀疏损伤识别[J]. 计算力学学报, 2022, **39**(2): 170-177. (LEI Yong-zhi, HUANG Min-shui, GU Jian-feng, et al. Structural sparse damage identification considering

- ambient temperature variations based on support vector machine and enhanced moth-flame optimization [J]. *Chinese Journal of Computational Mechanics*, 2022, **39**(2):170-177. (in Chinese)
- [18] Farrar C, Sohn H, Worden K. Data Normalization: A Key for Structural Health Monitoring [R]. Los Alamos National Lab. (LANL), 2001.
- [19] 闫翠平. 基于深度学习的桥梁健康状态检测方法研究 [D]. 北京交通大学, 2020. (YAN Cui-ping. Research on Bridge Health Condition Detection Method based on Deep Learning [D]. Beijing Jiaotong University, 2020. (in Chinese))
- [20] Hsu C, Chang C C, Lin C. A practical guide to support vector classification [EB/OL]. <https://www.csic.ntu.edu.tw/~cjlin/papers/guide/guide/pdf>, 2017-03-20.
- [21] Dragomiretskiy K, Zosso D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, **62**(3):531-544.
- [22] 李宏坤, 侯梦凡, 唐道龙, 等. 基于POVMD和CAF的低转速齿轮箱故障诊断 [J]. 振动、测试与诊断, 2020, **40**(1):35-42, 201. (LI Hong-kun, HOU Meng-fan, TANG Dao-long, et al. Low speed gearbox fault diagnosis based on POVMD and CAF [J]. *Journal of*
- Vibration, Measurement & Diagnosis*, 2020, **40**(1):35-42, 201. (in Chinese))
- [23] Worden K, Cross E J, Antoniadou I, et al. A multiresolution approach to cointegration for enhanced SHM of structures under varying conditions—An exploratory study [J]. *Mechanical Systems and Signal Processing*, 2014, **47**(1-2):243-262.
- [24] Chang Y S, Chiao H T, Abimannan S, et al. An LSTM-based aggregated model for air pollution forecasting [J]. *Atmospheric Pollution Research*, 2020, **11**(8):1451-1463.
- [25] He W Y, Ren W X, Zhu S Y. Damage detection of beam structures using quasi-static moving load induced displacement response [J]. *Engineering Structures*, 2017, **145**:70-82.
- [26] Zhou H F, Ni Y Q, Ko J M. Constructing input to neural networks for modeling temperature-caused modal variability: Mean temperatures, effective temperatures, and principal components of temperatures [J]. *Engineering Structures*, 2010, **32**(6):1747-1759.
- [27] Zhou H F, Ni Y Q, Ko J M. Eliminating temperature effect in vibration-based structural damage detection [J]. *Journal of Engineering Mechanics*, 2011, **137**(12):785-796.

Structural damage identification based on LSTM neural networks under ambient temperature variations

HUANG Yan, GE Si-yuan, ZHAI Mu-sai, CHANG Jun*

(School of Civil Engineering, Suzhou University of Science and Technology, Suzhou 215011, China)

Abstract: The change of ambient temperature will cause the change of modal parameters, and the degree of change will cover up or partially cover up the change caused by damage, resulting in the misjudgment of false positive or false negative issued by the structural health monitoring system. Therefore, eliminating the temperature effect is the key to improve the accuracy of damage identification. Based on LSTM neural network, this paper proposes a method to identify structural damage under the impact of ambient temperature. By making full use of the nonlinear mapping advantage of LSTM neural network, the correlation model of multivariate temperature and modal frequencies is established. On this basis, the data normalization method is used to eliminate the temperature effect, and the control chart is used to judge the abnormal change of modal frequencies to determine the damage condition. Finally, the proposed method is applied to a numerical model and an actual bridge. The results show that the method can effectively eliminate the temperature effect. Combined with the control chart method, it can identify the damage time and has a certain noise resistance. In the real bridge data analysis, it can still show good damage sensitivity.

Key words: LSTM neural network; structural health monitoring; temperature; modal frequency; variational mode decomposition

引用本文/Cite this paper:

黄炎, 葛思源, 翟慕赛, 等. 环境温度影响下基于LSTM神经网络识别结构损伤 [J]. 计算力学学报, 2024, **41**(2):248-255.

HUANG Yan, GE Si-yuan, ZHAI Mu-sai, et al. Structural damage identification based on LSTM neural networks under ambient temperature variations [J]. *Chinese Journal of Computational Mechanics*, 2024, **41**(2):248-255.