

# 联合 CNN 与 LSTM 神经网络的斜拉索损伤识别方法

朱三凡<sup>1</sup>, 刘世凤<sup>2</sup>, 余印根<sup>3</sup>, 王志俸<sup>2</sup>, 夏樟华<sup>2</sup>

(1. 健研检测集团有限公司, 福建 厦门 361004;

2. 福州大学土木工程学院, 福建 福州 350116;

3. 福建省永正工程质量检测有限公司, 福建 福州 350001)

**摘要:** 索结构中, 拉索响应与损伤之间处于高度非线性状态, 常规数学模型对拉索损伤识别普遍存在精度欠佳问题。针对该问题创建了七丝钢绞线的拉索有限元模型, 提出基于组合指标的 CNN&LSTM 神经网络损伤识别方法。借助该拉索有限元模型模拟 4 类损伤工况, 分类提取响应。对比分析总能量变化率、频率、能量比偏差与能量比方差等不同指标对损伤程度的表征, 建立能量与频率相结合的组合损伤指标。对比分析联合 CNN&LSTM 神经网络面对各损伤指标, 以及传统中单独的卷积神经网络 (CNN) 与长短记忆法 (LSTM) 针对组合损伤指标的识别结果。研究发现, 基于组合指标的联合 CNN&LSTM 深度学习网络的拉索损伤识别准确率最高, 达到 96.67%, 高于 CNN 的 86.63% 及 LSTM 的 82.15%, 表明 CNN&LSTM 在斜拉索损伤识别应用中具有较大潜力。

**关键词:** 拉索有限元; 卷积神经网络; 长短记忆法; 损伤识别; 组合指标

中图分类号: U446.2

文献标志码: A

文章编号: 2097-3853(2024)04-0326-07

## A method for identifying cable damage in cable-stayed bridges by combining CNN and LSTM neural network

ZHU Sanfan<sup>1</sup>, LIU Shifeng<sup>2</sup>, YU Yingen<sup>3</sup>, WANG Zhifeng<sup>2</sup>, XIA Zhanghua<sup>2</sup>

(1. Jianyan Test Group Co., Ltd., Xiamen 361004, China;

2. College of Civil Engineering, Fuzhou University, Fuzhou 350116, China;

3. Fujian Yongzheng Construction Quality Inspection Co., Ltd., Fuzhou 350001, China)

**Abstract:** In cable structures, the cable response and damage are in a highly nonlinear state and the accuracy is often poor in conventional mathematical models for cable damage identification. A finite element model of a seven-wire strand cable was created to address this problem, and a CNN&LSTM neural network damage identification method based on the combination of indicators was proposed. The finite element model of the cable was used to simulate four types of damage conditions and extract response features for each. Different indicators such as the rate of total energy change, frequency, energy ratio deviation, and energy ratio variance were compared and analyzed for their representation of damage severity. A composite damage indicator combining energy and frequency was established. The recognition results of the combined damage indicator using the CNN & LSTM neural network were compared and analyzed against individual indicators using the conventional convolutional neural network (CNN) and long and short term memory (LSTM) network. Results reveal that the accuracy of cable damage identification using the combined indicators with the CNN & LSTM deep learning network is the highest, reaching 96.67%, which is higher than the accuracy of CNN alone (86.63%) and LSTM alone (82.15%). The results demonstrate that CNN & LSTM have great potential in cable damage identification in cable-stayed structures.

**Keywords:** cable finite element; convolutional neural network; long and short term memory; damage identification; composite indicators

收稿日期: 2024-01-23

基金项目: 福建省社会发展引导性(重点)项目(2022Y0046); 垒知创新基金(202201)

第一作者简介: 朱三凡(1982—), 男, 福建惠安人, 高级工程师, 博士, 研究方向: 桥梁检测与评价。

索结构是桥梁的主要形式之一,其拉索受荷载、环境侵蚀或自然灾害影响下的材料腐蚀、结构损伤和开裂、性能退化、功能失效等原因可能出现护套破裂、钢丝锈蚀、下锚头渗水、锚具锈蚀、护套内灌的水泥浆不饱满等拉索病害<sup>[1]</sup>。为确保索支撑桥梁的安全运行,有必要对拉索进行预防性维护和安全检查。目前主要的拉索无损检测方法有磁漏检测法、涡流检测、声发射检测等,然而这些方法都不能实时检测斜拉桥的健康状态。由于拉索腐蚀和断裂等局部损伤会影响其静态和动态性能,因此基于力学指标的深度学习损伤检测方法理论上可以克服当前无损检测方法的缺点。

早在1979年,Cawley<sup>[2]</sup>就提出了一种基于频率变化的损伤识别方法,将频率变化与结构损伤联系在一起。丁幼亮等<sup>[3-4]</sup>则从能量的角度出发将能量比偏差(ERVD)和能量比方差(ERVV)定义为损伤指标。随着研究的深入,郝亚坤<sup>[5]</sup>研究的结果表明,拉索损伤会引起小波包总能量的减小,小波包总能量对索损伤程度非常敏感。王琦<sup>[6]</sup>则进一步将总能量变化率(RES)引入损伤指标的定义中。然而,万拥军<sup>[7]</sup>研究表明小波能量损伤指标对在噪声作用下对结构的损伤识别误差较大。常军<sup>[8]</sup>研究表明频率对结构损伤并不敏感,以至于将频率作为损伤指标对结构的微小损伤难以识别。

在深度学习方面,李康烈等<sup>[9]</sup>开发了用于损伤定位的 CNN (convolutional neural network, CNN)模型,桥梁损伤程度严重时,识别损伤位置的准确率为87.3%,该准确率证明了深度学习在克服现有损伤定位技术局限性方面的潜力。辛浩辉等<sup>[10]</sup>进一步将 CNN 神经网络应用于声发射信号与拉索状态之间的关系建模。李升等<sup>[11]</sup>基于具有多个隐藏层的 CNN 模型,成功实现梁连续挠度所代表的桥梁损伤的自动提取和分类。除了 CNN,LSTM(long short term memory)网络也被广泛应用于结构损伤识别。李永强等<sup>[12]</sup>通过 LSTM 网络提高了模型的非线性拟合能力,并探索了最优超参数选择和训练策略选择的范式,展现了 LSTM 在损伤识别中的优越性。李光明等<sup>[13-14]</sup>将声发射信号与 LSTM 相结合,在真实拉索信号的模式识别上表现出较高的识别准确度。

虽然,CNN 和 LSTM 已被研究应用于工程实践,但 CNN 模型在训练结果会收敛于局部最小值

而非全局最小值,LSTM 在处理高维数据和局部信息的获取能力较差。本研究通过对比不同损伤指标的输入,探究 CNN、LSTM 及联合 CNN&LSTM 网络对拉索损伤的识别效果,提升拉索损伤识别的可行性和精度。

## 1 基本原理

### 1.1 长短期记忆(LSTM)

长短期记忆(LSTM)是典型的递归神经网络,使用3个独立的门控信号。如图1所示,在LSTM层中,通过 $x_t$ 重复输入和更新,最终获得状态向量 $h_t$ 与传输带 $C_t$ 。然后按 softmax 层和分类层映射到结构的损伤位置。根据每个样本输出与标签值之间的差异,调整模型中的参数,使损失函数 loss 达到最小值状态。LSTM 单元的数学表达式与损失函数如式(1)~(3)所示。

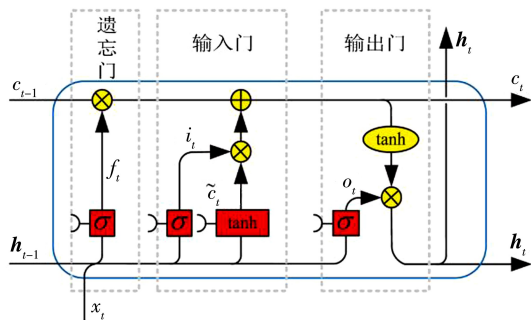


图1 LSTM 网络结构示意图

Fig.1 Schematic diagram of LSTM network structure

$$C_t = f_t \cdot C_{t-1} + i_t \cdot \tilde{C}_t \quad (1)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (2)$$

$$\begin{cases} f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \\ i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \\ \tilde{C}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c) \\ O_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \end{cases} \quad (3)$$

$$\text{loss} = \frac{1}{2} \sum_{n=1}^k (t_n - y_n)^2$$

式中, $\sigma$ 表示激活函数 Sigmoid 函数; $W$ 与 $b$ 分别表示权重矩阵与偏置,下标 $f, i, c, o$ 用于对应区分遗忘门、输入门、更新值、输出门; $[h_{t-1}, x_t]$ 表示将 $t$ 时刻的输入 $x_t$ 与之前数据进行结合; $C_{t-1}$ 为介于0和1之间的数字;tanh层也会创建一个更新值 $\tilde{C}_t$ ;  $k$ 表示样本数; $t_n$ 表示实际值; $y_n$ 是预测值。

## 1.2 卷积神经网络

典型的 CNN 由 3 个阶段组成:(1)卷积层通过产生一组线性激活来得到一些特征映射(输出),将线性激活转换为非线性激活,这个转换阶段称为检测阶段;(2)使用池函数来减少给定激活特征图的空间位置,以此来产生一种新的输出;(3)最后一层通常包含一个或多个完全连接层。从给定输入中提取的特征最终在这些完全连接层中进行处理;这些层执行像前馈神经网络,因为它们有密集的连接。在 CNN 中,完全连接层占据了网络的大部分参数。

## 1.3 CNN&LSTM 模型及识别流程

联合 CNN&LSTM 模型对拉索损伤进行识别。CNN 模块负责特征提取,使用 2 个卷积层来挖掘输入数据的隐藏特征,涉及 2 个池化层来减少特征维度,减小了 LSTM 的计算成本。LSTM 单元对来自 CNN 的时间依赖性特征进行回归或分类,同时在 LSTM 单元中设置多个神经元进行计算,引入更多控制参数来克服 RNN 的梯度消失和爆炸的问题,并应用 Dropout 层以减少过度拟合的发生。其识别方法的流程如图 2 所示。

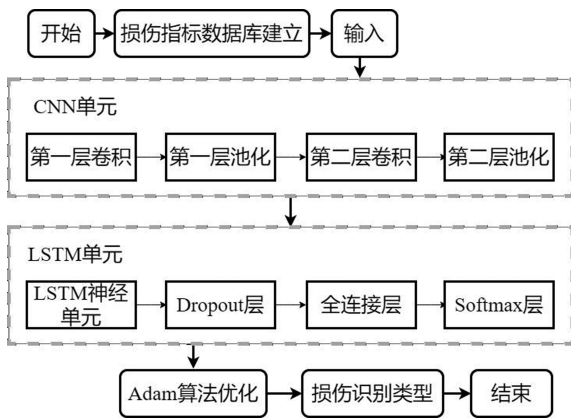


图 2 CNN&LSTM 损伤识别方法的流程图

Fig.2 Flowchart of CNN&LSTM damage identification method

## 1.4 评价指标

单根拉索的损伤识别是通过回归的方式进行训练和测试。决定系数( $R$ -Square,  $R^2$ )值在评估模型好坏的同时,纳入对残差均值与方差的考虑,选用为联合 CNN&LSTM 模型在拉索损伤识别效果的评估指标。 $R^2$  值越接近 1,表明模型识别效果越好。 $R^2$  值表达式如(4)所示。

$$\begin{cases} R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \\ \bar{y} = \frac{1}{n} \sum_{i=1}^n y_i \end{cases} \quad (4)$$

式中, $y_i$  表示实际损失程度; $\hat{y}_i$  表示预测损失程度; $\bar{y}$  表示测试工况的平均损失程度。

## 2 获取拉索有限元模型数据

### 2.1 索结构的基本假设及在 ANSYS 中的实现

有限元分析软件 ANSYS 中没有单独的索单元,鉴于二节点的 LINK10 单元模拟索单元无法适用实际拉索长度的情况下,本研究中拉索的有限元模型(如图 3 所示)通过建立特殊布置的梁单元和弹簧单元,分别模拟拉索中的钢丝以及钢丝间的相互作用。在建模过程中,采用了 3 个基本假设:(1)各个单元遵守平截面假定;(2)不考虑拉索的塑性发展;(3)所有的拉索均由相同的材料制成。




图 3 七丝钢绞线的有限元模型

Fig.3 Finite element modelling of seven-wire strand cable

在 ANSYS 中,梁单元采用 PIPE16 单元,该单元是一种具有拉伸、压缩、扭转和弯曲性能的单轴元件,以三维梁单元理论为基础,每个节点有 6 个自由度。七丝钢绞线拉索的一端受轴向拉力作用,另一端节点受完全约束作用。在对七丝钢绞线实体模型进行网格划分时,采用扫掠方法进行网格划分。

其中,钢绞线参数包括:中丝的网格密度确定为 0.5 mm,侧丝的网格密度为 0.4 mm,钢绞线实际直径 15.4 mm,公称直径 15.24 mm,侧丝直径 5.05 mm,中丝直径 5.30 mm,弹性模量 201 GPa,截面面积 142 mm<sup>2</sup>,泊松比 0.3,捻距 218 mm,断裂强度 1 993 MPa,螺旋角 8.5°。

### 2.2 有限元模型验证

为验证有限元模型与理论应力计算是否存在显著差异,对该模型分别施加了 200、400、600 MPa 的轴向拉应力,将有限元模型在各个荷载作用下的应力结果与 Feyrer 理论应力计算的结果进行对比。七丝钢绞线应力计算结果如表 1 所示。结果显示,最大的相对误差在 5% 以内,满足工程误差要求。同样,参考文献[15]的结果显示,施加 600 MPa 轴向应力,侧丝和中丝的应力为 616 MPa,误差在 5% 以内。上述结果表明拉索的有限元模型可较好的模拟实际拉索的动力响应。

表 1 有限元模型与理论应力计算结果对比

Tab.1 Comparison of finite element model and theoretical stress calculation results

截面等效应力 / MPa	本课题的计算结果		Feyre <sup>[16]</sup> 公式计算结果		误差/%	
	中丝应力/MPa	侧丝应力/MPa	中丝应力/MPa	侧丝应力/MPa	中丝	侧丝
200	206.7	196.4	204.3	197.7	1.175	0.657
400	414.3	391.4	408.2	394.3	1.483	0.735
600	625.4	589.6	617.6	597.4	1.263	1.306

### 2.3 加速度响应的获取

为了保证所获得的数据具有多样性,并验证单根拉索在不同的损伤位置是否会影响到损伤识别结果,本研究以索力、损伤程度作为拉索损伤的基本控制参数,选取长度为 10 m 的拉索,依次在施加荷载时间为 0.2 s,冲击力大小为 30.0、30.1、30.2、...、69.9 kN 下,获取拉索在索长为 1/7、2/7、3/7、4/7、5/7、6/7 处不同损伤程度的加速度信号。一般情况下,损伤可以看作是弹性模量的减少。假定拉索在完好状态下的弹性模量为  $E$ ,损坏后的弹性模为  $E^*$ ,然后用变量  $D$  来表示损伤程度, $D=0$  表示拉索没有损坏, $D=1$  表示完全损坏,可以表示如公式(5)。30 kN 下拉索 1/7 长度位置上的不同程度操作的加速度时程响应如图 4 所示。

$$D = \frac{E - E^*}{E} \quad (5)$$

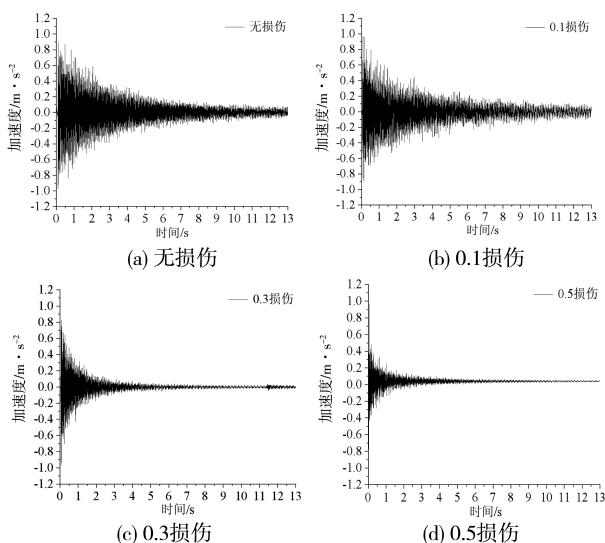


图 4 30 kN 作用下拉索 1/7 长度处不同损伤程度的加速度响应

Fig.4 Acceleration response of different damage degrees at 1/7 length of cable under action of 30 kN

## 3 组合指标的提出

### 3.1 各损伤特征的拉索损伤样本库

以能量比偏差、能量比方差、总能量变化率与频率等不同指标为主导,通过计算和分解信号,构建展示拉索 1/7 长度位置在 2 种工况下用于神经网络训练所需要的损伤样本数据库,结果如图 5 所示。从图 5 可以看出,基于能量比偏差(ERVD)与能量比方差(ERVV)的损伤指标值随着拉索损伤的不同而有一定的变化,但是其变化的规律与外界激励以及损伤程度之间没有明显的规律,故不可直接通过能量比方差或能量比偏差的变化来确定拉索是否损伤。在索力不变的情况下,小波总能量变化率(RES)与拉索的前 6 阶频率随损伤程度的增加而增加,但是与拉索损伤之间并非一元线性关系。

### 3.2 组合指标的提出

通过将前 6 阶 RES 与结构频率进行组合,弥补二者在损伤识别的不足,提出组合指标  $C$ ,并构建损伤样本数据库如图 6,公式如(6)。

$$\begin{cases} E_t = \sum_i E_j = \sum_i \sum_j |f_{i,j}|^2 \\ RES = \frac{E_{tundam}}{E_{tdam}} \\ C = \{E, f\} = \{RES_A, \omega_1; RES_B, \omega_2; \dots, RES_F, \omega_6\} \end{cases} \quad (6)$$

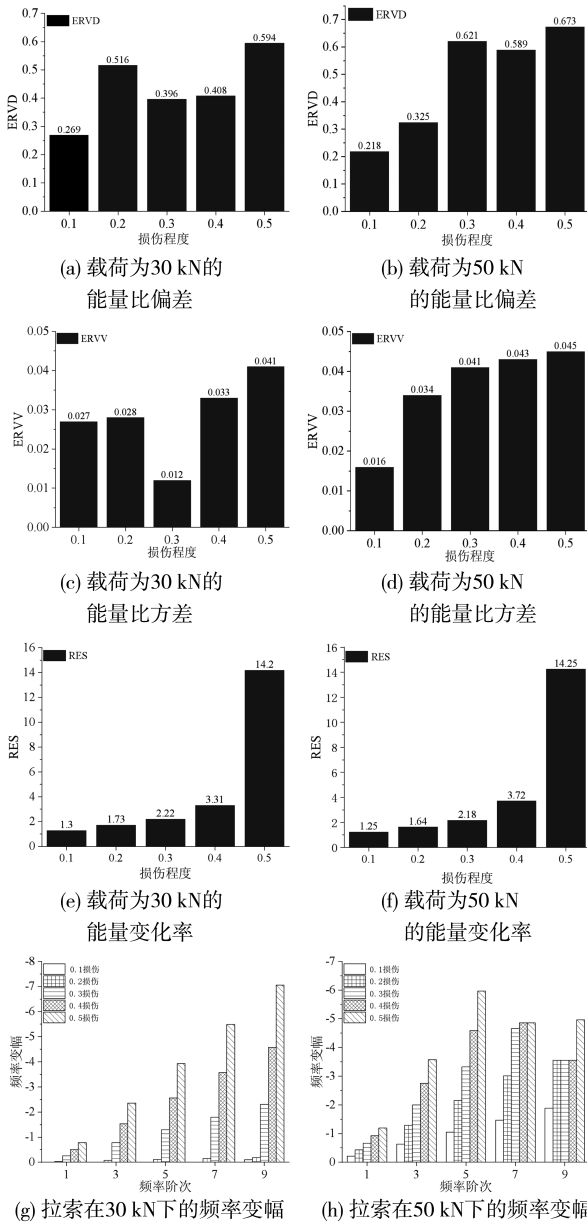



图 5 损伤指标示意图

Fig.5 Schematic diagram of damage indicators


式中,  $\omega_1, \omega_2, \dots, \omega_6$  为结构的固有圆频率;  $E_i$  为小波包分解的总能量;  $E_{tundam}$  是无损伤结构的小波包总能量;  $E_{tdam}$  是受损结构的小波包总能量;  $E_j$  是频带的能量分量;  $f_{i,j}$  是频带中小波包系数;  $i$  是频带数;  $j$  是频带中小波包系数的数量。

### 4 基于不同损伤特征的拉索损伤识别对比

设置联合 CNN&LSTM 的详细参数数据: 2 层卷积层、卷积核大小为 3、第 1 层卷积核 256 个、第 2 层卷积核 128 个、全连接层大小为 6、Dropout



(a) 拉索在 30 kN 下的组合损伤指标



(b) 拉索在 50 kN 下的组合损伤指标

图 6 组合损伤指标示意图

Fig.6 Schematic diagram of combined damage indicators

系数为 0.3、epochs 为 1 000、最小批处理数量为 128、学习率为 0.001。将基于频率、总能量变化率与组合损伤指标的样本数据库分别导入已训练好的 CNN&LSTM 模型中,其  $R^2$  值输出分别为 0.853 3、0.885 6 与 0.967 7。基于频率的损伤识别  $R^2$  结果,表明频率对拉索的损伤识别具有较为不错的效果,但是损伤程度为 0.2、0.3 时,基于频率指标易将实际损伤程度识别为较低的情形;基于总能量变化率相对于基于频率的损伤识别准确率有一定提升,但是在损伤误差高于 0.1 的情形中,大部分结果是将实际损伤预测为较低的损伤;基于组合损伤指标对拉索的损伤识别的效果相对于基于总能量变化率和频率的损伤指标更具有普适性, $R^2$  的大幅提升表明了基于组合损伤指标对拉索损伤识别是可行的。基于不同损伤特征对 1/7、2/7、3/7、4/7、5/7、6/7 这 6 个位置的  $R^2$  值进行计算,结果汇总如表 2 所示,1/7 位置处的结果展示见图 7。




图 7 1/7 长度处不同损伤特征的拉索损伤识别对比

Fig.7 Comparison of damage identification of cables at 1/7 length with different damage characteristics

表 2 各特征识别拉索各位置损伤的  $R^2$  值结果汇总

Tab.2 Summary of  $R^2$  values for each feature in identifying damage at different positions of the cable

索长度位置	频率/Hz	总能量变化率	组合损伤指标
1/7	0.910 4	0.927 7	0.952 8
2/7	0.817 1	0.883 3	0.927 4
3/7	0.774 7	0.925 4	0.959 1
4/7	0.821 0	0.870 1	0.984 1
5/7	0.892 2	0.850 9	0.921 2
6/7	0.741 2	0.862 8	0.969 3

## 5 不同神经网络损伤识别的对比

将组合损伤指标的样本数据库导入已训练好的 CNN 模型、LSTM 模型与 CNN&LSTM 模型中,基于组合损伤指标对拉索的损伤的识别效果见图 8, CNN 损伤识别  $R^2$  值为 0.866 3, LSTM 损伤识别  $R^2$  值为 0.826 3,相对于 CNN&LSTM 的  $R^2$  值 0.967 7 有较大幅度下降。在损伤程度为 0.1、0.5 时, LSTM 具有不错的识别效果,但损伤程度为 0.2、0.3、0.4 时,其识别效果发生大幅度下降;基于 CNN 损伤识别中,在损伤程度为 0.3 时,较多工况下的拉索损伤识别为损伤程度较轻的情形,说明了 CNN 相对于联合 CNN&LSTM 模型的稳定性较弱。

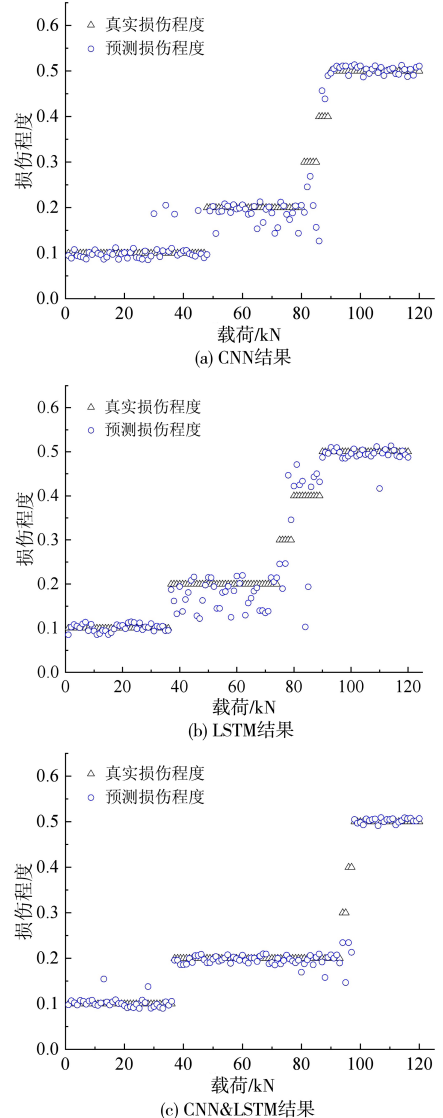


图 8 不同神经网络对拉索损伤识别的结果展示

Fig.8 Results of different neural networks for cable damage recognition

## 6 结论

1)建立了七丝钢绞线有限元模型。经验证,数字计算应力与理论计算值的相对误差满足工程误差要求,拉索的有限元模型可较好地模拟实际受力状态。

2)提出了总能量变化率和频率组合损伤指标。测试效果结果显示,所提组合损伤指标对拉索损伤的灵敏性最高,其次为总能量变化率和频率,组合指标与损伤之间具有明显的正相关。

3)提出了 CNN&LSTM 拉索损伤方法。研究发现,将组合损伤指标分别导入相同训练参数的 CNN 模型、LSTM 模型与 CNN&LSTM 模型中, CNN&LSTM 的  $R^2$  值 0.967 7,该模型在拉索损伤识别效果优于 CNN 模型和 LSTM 模型。

目前的规范要求根据不少于前 5 阶特征频率来计算索力的平均值,但是预应力吊杆、体外索等损伤对频率不敏感,本研究提出的小波总能量变化率和频率的组合指标具有更好的适用性,后续可结合实践验证准确性和应用范围。

## 参考文献:

- [1] DENG L, YAN W C, NIE L. A simple corrosion fatigue design method for bridges considering the coupled corrosion-overloading effect[J]. *Engineering Structures*, 2019, 178: 309-317.
- [2] CAWLEY P, ADAMS R D. The location of defects in structures from measurements of natural frequencies[J]. *The Journal of Strain Analysis for Engineering Design*, 1979, 14(2): 49-57.
- [3] 丁幼亮,李爱群,缪长青. 基于小波包能量谱的结构损伤预警方法研究[J]. *工程力学*, 2006, 23(8): 42-48.
- [4] DING YL, LI A Q, LIU T. A study on the WPT-based structural damage alarming of the ASCE benchmark experiments[J]. *Advances in Structural Engineering*, 2008, 11(1): 121-127.
- [5] 郑亚坤. 基于小波总能量相对变化的桥梁结构损伤识别研究[D]. 杭州:浙江大学, 2017.
- [6] 王琦. 基于小波包分析与神经网络的拉索损伤识别方法[D]. 福州:福州大学, 2018.
- [7] 万拥军. 基于小波包能量变化率的结构损伤识别方法研究[D]. 郑州:郑州大学, 2009.
- [8] 常军. 在役桥梁结构损伤位置识别的综合指标方法研究[J]. *振动与冲击*, 2011, 30(10): 87-90, 135.
- [9] LEE K, BYUN N, SHIN D H. A damage localization approach for rahmen bridge based on convolutional neural network[J]. *KSCE Journal of Civil Engineering*, 2020, 24(1): 1-9.
- [10] XIN HH, CHENG L, DIENDER R, et al. Fracture acoustic emission signals identification of stay cables in bridge engineering application using deep transfer learning and wavelet analysis[J]. *Advances in Bridge Engineering*, 2020, 1(1): 6.
- [11] LI S, SUN L Z. Detectability of bridge-structural damage based on fiber-optic sensing through deep-convolutional neural networks[J]. *Journal of Bridge Engineering*, 2020, 25(4): 04020012.
- [12] LI Y Q, ZHAO H W, YUE Z X, et al. Real-time intelligent prediction method of cable's fundamental frequency for intelligent maintenance of cable-stayed bridges[J]. *Sustainability*, 2023, 15(5): 4086.
- [13] 丁鹤鸣. 基于 LSTM 的桥梁拉索断丝信号识别[D]. 济南:山东大学, 2022.
- [14] LI G M, DING H M, LI Y H, et al. Signal identification of wire breaking in bridge cables based on machine learning[J]. *Mathematics*, 2022, 10(19): 3690.
- [15] 王亚娟. 多井联动排采设备钢丝绳力学性能分析[D]. 西安:西安石油大学, 2015.
- [16] FEYRER K, SCHFFNER G. Torque and torsional stiffness of wire rope - part II[J]. *Wire*, 1987, 37(1): 23-27.

(责任编辑:方素华)