

文章编号: 1005-0523(2025)06-0017-14



## 基于深度学习的钢桥面板 U 肋-顶板节点 Lamb 波损伤检测

田 亮<sup>1,2,4</sup>, 宋鹏飞<sup>1</sup>, 张海顺<sup>2,3</sup>, 肖飞知<sup>2,3</sup>, 樊立龙<sup>2,3</sup>, 赵 健<sup>2,3</sup>

(1. 天津城建大学土木工程学院, 天津 300384; 2. 中国铁建大桥工程局集团有限公司, 天津 300300;  
3. 天津市装配式桥梁智能建造技术与装备重点实验室, 天津 300300; 4. 清华大学土木工程系, 北京 100084)

**摘要:** 针对钢桥面板等复杂结构中 Lamb 波多模态传播、频散效应及信号衰减导致的损伤特征识别困难问题, 本研究提出一种基于深度学习的钢桥面板 U 肋-顶板节点损伤检测方法。通过将挤压和激励(squeeze-excitation, SE)注意力机制与长短时记忆网络(long short-term memory, LSTM)嵌入卷积神经网络(convolutional neural networks, CNN), 并结合 Hilbert 变换提取包络曲线构建数据集, 实现钢桥面板 U 肋-顶板节点典型疲劳损伤的有效识别。研究结果表明: ① 损伤状态下直达波包相位呈现右移且幅值衰减, 验证信号时域变化特征在损伤检测上应用的可行性; ② SE-LSTM-CNN 模型在验证集与测试集分别达到 93.67% 与 95.00% 的准确率, 且各类损伤识别精度均超过 90%, 验证该模型在钢桥面板 U 肋-顶板节点损伤检测任务上有良好适用性; ③ SE-CNN 与 LSTM-CNN 模型的分类准确率较基础 CNN 模型分别提升 1.00% 与 3.33%; 而 SE-LSTM-CNN 模型的分类准确率较单一改进模型再提升 7.33% 与 5.00%, 验证 SE 注意力机制与 LSTM 的协同增效作用。此外, 使用包络曲线数据集使模型在验证集上的准确率较原始信号提升 21.33%, 说明该方法能有效增强 SE-LSTM-CNN 模型对 Lamb 波损伤特征的辨识能力; ④ 基于 MATLAB APP Designer 构建的智能检测软件实现了损伤检测全流程优化, 降低了人工干预误差。本研究有望为钢桥面板 U 肋-顶板节点的损伤检测提供新的技术方案。

**关键词:** 桥梁工程; 钢桥面板; Lamb 波; 深度学习; 数值仿真

**中图分类号:** [U24]; U441

**文献标志码:** A

**本文引用格式:** 田亮, 宋鹏飞, 张海顺, 等. 基于深度学习的钢桥面板 U 肋-顶板节点 Lamb 波损伤检测[J]. 华东交通大学学报, 2025, 42(6): 17-30.

## Research on Lamb Wave Damage Detection in U-Rib-Deck Joints of Steel Bridge Decks Based on Deep Learning

Tian Liang<sup>1,2,4</sup>, Song Pengfei<sup>1</sup>, Zhang Haishun<sup>2,3</sup>, Xiao Feizhi<sup>2,3</sup>, Fan Lilong<sup>2,3</sup>, Zhao Jian<sup>2,3</sup>

(1. College of Civil Engineering, Tianjin Chengjian University, Tianjin 300384, China; 2. China Railway Construction Bridge Engineering Bureau Group Co., Ltd., Tianjin 300300, China; 3. Tianjin Key Laboratory of Prefabricated Bridge Intelligent Construction Technology and Equipment, Tianjin 300300, China;  
4. Department of Civil Engineering, Tsinghua University, Beijing, 100084, China)

**Abstract:** To address the challenges in identifying damage characteristics caused by multimodal Lamb wave propagation, dispersion effects, and signal attenuation in complex structures like steel bridge decks, this study proposes a deep learning-based damage detection method for U-Rib-Deck joints in steel bridge decks. By embed-

收稿日期: 2025-05-27

基金项目: 天津市自然科学基金项目(24JCYBJC00850); 中国铁建股份有限公司科研重大专项(2023-A01); 中国铁建大桥局集团有限公司科技创新项目(DQJ-2024-B05)

ding squeeze-excitation (SE) attention mechanisms and long short-term memory (LSTM) networks into convolutional neural networks (CNN), combined with constructing datasets using Hilbert transform envelope curves, effective identification of typical fatigue damages in U-Rib-Deck joints is achieved. The research results demonstrate: ① Under damage conditions, the direct wave packet exhibits a rightward phase shift and amplitude attenuation, confirming the feasibility of using time-domain signal changes for damage detection. ② The SE-LSTM-CNN model achieved validation accuracy and test accuracy of 93.67% and 95.00%, respectively, with the recognition accuracy for all types of damage exceeding 90%, indicating the model's excellent applicability for damage detection tasks in steel bridge deck U-Rib-Deck joints. ③ The classification accuracy of the SE-CNN and LSTM-CNN models improved by 1.00% and 3.33%, respectively, compared to the baseline CNN model, while the SE-LSTM-CNN model further improved accuracy by 7.33% and 5.00% compared to the single-improvement models, validating the synergistic effectiveness of SE attention mechanism and LSTM for damage detection in steel bridge deck U-Rib-Deck joints; furthermore, using the envelope curve dataset increased the model's validation accuracy by 21.33% compared to raw signals, demonstrating this method's effectiveness in enhancing the SE-LSTM-CNN model's ability to identify Lamb wave damage features. ④ The intelligent detection software developed based on MATLAB APP Designer achieved full-process optimization for damage detection, reducing errors from human intervention. This research is expected to provide a new technical solution for damage detection in steel bridge deck U-Rib-Deck joints.

**Key words:** bridge engineering; steel bridge deck; Lamb waves; deep learning; numerical simulation

**Citation format:** TIAN L, SONG P F, ZHANG H S. Research on Lamb wave damage detection in U-Rib-Deck joints of steel bridge decks based on deep learning[J]. Journal of East China Jiaotong University, 2025, 42(6): 17-30.

随着交通基础设施服役年限增长与荷载复杂化程度加剧,桥梁结构健康监测已成为现代工程领域的重要研究方向。作为大跨度桥梁的主要承载构件,钢桥面板U肋-顶板焊接节点长期承受车辆循环荷载作用,即使荷载峰值低于材料屈服强度,仍易在几何突变或应力集中区域产生疲劳裂纹及隐性缺陷<sup>[1-3]</sup>。这类损伤具有隐蔽性强、扩展速率快的特点,若未能及时检出将严重影响桥梁结构安全性与服役寿命。因此,发展高效精准的损伤检测技术对保障桥梁安全运维具有重要工程价值。Lamb波检测技术因其无损检测特性及对微小损伤的高敏感性,在结构健康监测中展现出独特优势<sup>[4]</sup>。该技术通过捕获板结构中传播的弹性波与损伤相互作用引发的信号畸变,可有效识别微小裂纹、局部腐蚀等早期损伤。然而,传统方法依赖人工经验提取模态参数,难以有效处理多模态传播、散射效应及信号衰减带来的特征识别难题。CNN是一种常用的深度学习模型,将CNN与Lamb波检测相结合,可自动识别信号中的损伤特征<sup>[5]</sup>,有效避免传统方法依赖人工经验提取模态参数的局限,提升损伤

识别的自动化水平与检测效率,为钢桥面板智能化检测提供新的技术途径。

近年来,国内外科研人员对超声Lamb波与深度学习相融合的无损检测技术发展及应用进行了广泛研究。何存富等<sup>[6]</sup>对Lamb波在管道、板状结构及复合材料检测中的应用进行研究,得出Lamb波在其中的频散求解、模态选择及传感激励方法;蔡建等<sup>[7]</sup>针对Lamb波多模态干扰问题,提出Lamb波双面激励方法,通过理论建模与试验验证,有效抑制多模式特性,提升近邻损伤监测精度,为结构健康监测提供了新方法;PANDEY P等<sup>[8]</sup>构建一维卷积神经网络(1D-CNN)对铝板损伤信号进行分类识别,证明了Lamb波时域波形识别损伤的可行性;Akshay R等<sup>[9]</sup>在1D-CNN模型中融入多头注意力机制对铝板Lamb波损伤信号分类,通过特征通道权重重构提升了非线性特征的提取能力;Jun W等<sup>[10]</sup>将连续小波变换与CNN模型相结合,将Lamb波信号转换为时频图像,通过深度卷积神经网络实现复合材料层间损伤的自动识别与在线定位;Shang L等<sup>[11]</sup>提出CNN-LSTM混合模型,对金属管道超声导



波信号进行特征提取与时序建模,实现了94.80%的损伤检测准确率,相较于基础的CNN和LSTM模型,CNN-LSTM模型准确率更高,并验证了该模型优异的抗噪声性能;田亮等<sup>[12]</sup>通过Lamb波对钢桥面板U肋-顶板节点疲劳损伤检测数值仿真分析,论证了200 kHz Lamb波信号时频分布差异明显,且能量分布愈加集中,更利于实现损伤的检测;石林泽等<sup>[13]</sup>从数值仿真和实桥试验两方面研究了Lamb导波在钢桥面板中的传播机理,论证了采用Lamb波检测钢桥面板疲劳裂纹的可行性。

当前基于Lamb波与深度学习相结合的无损检测技术研究仍主要集中于板状结构和理论分析,在处理钢桥面板等较为复杂工程结构时,目前仍面临多重挑战,包括多模态传播、频散效应以及信号衰减等问题。特别是在损伤特征识别方面,现有方法对钢桥面板典型疲劳损伤的识别准确率仍难以满足工程需求。针对上述问题,本研究提出基于SE-LSTM-CNN模型的钢桥面板Lamb波损伤检测方法:首先基于Lamb波频散方程计算钢桥面板顶板频散曲线,确定最优激励频率后,通过数值仿真构建包含无损伤及三种不同损伤程度的Lamb波传播信号数据集;其次设计SE-LSTM-CNN模型,利用CNN提取局部信号特征,结合LSTM层建模Lamb波信号时序相关性,引入SE注意力机制实现损伤信息通道的自适应增强;进一步设计消融实验验证所引入模块的协同增效作用,同时对比SE-LSTM-CNN模型在原信号与Hilbert变换包络曲线数据集的识别准确率,验证Hilbert变换包络曲线对损伤特征识别的增强效果;最终利用训练完成的模型实现钢桥面板U肋-顶板节点的损伤检测,并基于MATLAB APP Designer完成检测程序封装。该研究成果有望丰富结构健康监测领域的研究内容,为钢桥面板的安全评估和维护提供技术支持。

## 1 数值仿真与数据集构建

### 1.1 有限元建模

正交异型钢桥面板主要由顶板、U型加劲肋及横隔板等构件组成,其产生的疲劳裂纹主要集中于三个区域:U肋与顶板及横隔板连接焊缝的焊趾附近区域、横隔板弧形切口处以及U肋-顶板对接焊缝部位<sup>[14]</sup>。其中,U肋-顶板连接部位焊趾处萌生的疲劳裂纹常规目视检测手段难以有效识别,

为此,本文针对该连接部位开展损伤识别分析研究。采用有限元软件Abaqus建立无损伤与含预设损伤钢桥面板节段有限元模型如图1所示,材料参数如表1所示,模型采用C3D8R减缩积分单元,通过显式动力分析模拟Lamb波在钢桥面板顶板上传播过程。




图1 钢桥面板有限元模型

Fig. 1 Finite element model of a steel bridge deck

表1 钢桥面板材料性质

Tab.1 Steel bridge deck material properties

| 顶板厚度  | 弹性模量    | 泊松比 | 密度                      |
|-------|---------|-----|-------------------------|
| 16 mm | 210 GPa | 0.3 | 7 850 kg/m <sup>3</sup> |

根据Lamb波在板状结构中的传播特性,其振动位移场在板厚方向呈现特定的对称性分布,据此可将振动模态划分为对称模态(S模式)与反对称模态(A模式)两类基本形式,如图2所示。并且其在传播过程中具有明显的频散现象,即相速度与群速度随频率改变而发生变化,导致不同频率成分的波包产生时延差异。不同模态的波可能因相位匹配而叠加,导致振幅显著增大<sup>[15]</sup>。Lamb波相速度 $c_p$ 频散曲线公式如下

对称模式

$$4pq \tan \frac{\pi f d q}{c_p} + (p^2 - 1)^2 \tan \frac{\pi f d q}{c_p} = 0 \quad (1)$$

反对称模式

$$4pq \tan \frac{\pi f d p}{c_p} + (p^2 - 1)^2 \tan \frac{\pi f d q}{c_p} = 0 \quad (2)$$

由相速度频散曲线可确定群速度 $c_g$ 频散曲线公式如下

$$c_g = c_p^2 \left[ c_p - f d \frac{dc_p}{d(fd)} \right] \quad (3)$$




图2 Lamb波传播示意

Fig. 2 Lamb wave propagation schematic

式中:  $c_p$  为 Lamb 波相速度,  $c_g$  为 Lamb 波群速度,  $fd$  为频厚积,  $p^2 = \omega^2/c_l^2 - k^2$ ,  $q^2 = \omega^2/c_t^2 - k^2$ , 其中  $c_l$  为纵波速度,  $c_t$  为横波速度,  $\omega = 2\pi f$  为角频率,  $k$  为波数。

根据钢桥面板的材料属性, 运用 MATLAB 软件求解 Lamb 波频散方程, 可绘制出 Lamb 波在钢桥面板顶板中传播的频散曲线<sup>[12]</sup>, 如图 3 所示。

由图 3 频散曲线可知, 随着频厚积的增大,

Lamb 波高阶模态逐渐显现。为确保钢桥面板顶板中仅稳定存在 S0 和 A0 模态, 并有效实现 Lamb 波的能量集中与分散效应抑制, 本文选用中心频率为 200 kHz 的 5 周期 Hanning 窗函数作为激励信号, 如图 4 所示。该频率设置可避免激发高阶模态, 同时 Hanning 窗的频谱特性有利于提升信号能量集中度<sup>[12]</sup>, Hanning 窗函数调制激励信号  $F(t)$  表达式如下

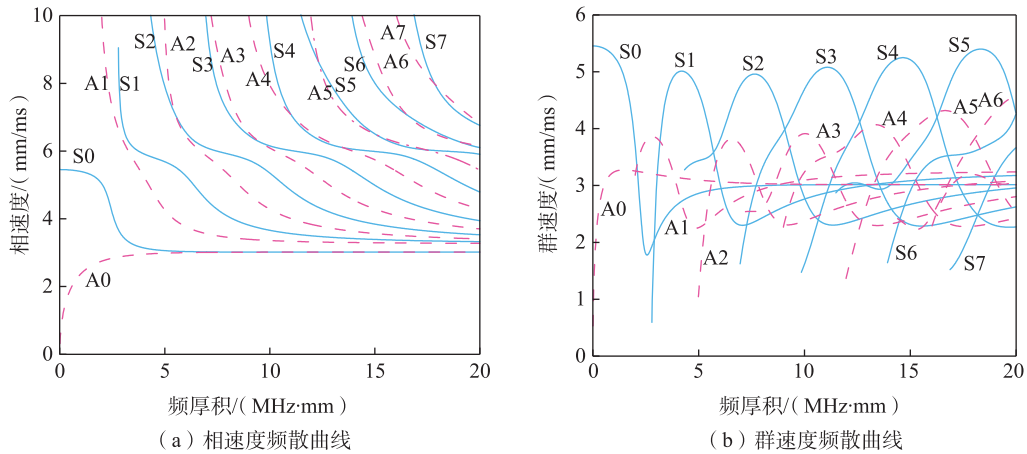


图3 Lamb波频散曲线

Fig. 3 Lamb wave dispersion curve




图4 Hanning窗调制Lamb波信号

Fig. 4 The Hanning window modulates the Lamb wave signal

$$F(t) = A \left[ H(t) - H\left(t - \frac{n}{f_c}\right) \right] \left[ 1 - \cos\left(\frac{2\pi f_c t}{n}\right) \right] \sin(2\pi f_c t) \quad (4)$$

式中:  $H(t)$  为 Heaviside 阶梯函数,  $t$  为时间,  $n$  为信号周期,  $f_c$  为信号中心频率,  $A$  为信号幅值。

在选定 200 kHz 中心频率后, 尽管抑制了高阶模态, 但 S0 和 A0 双模态仍共存。为解决多模态干扰问题, 需采用特定激励方式实现模态选择。如图

5 所示, 通过激励方式优化可实现模态分离, 单面激励因激发条件对称性缺失, 同时激励 S0 和 A0 双模态; 双面对称激励可抑制 A0 模态而保留 S0 单模态; 双面反对称激励则抑制 S0 模态而保留 A0 单模态<sup>[16]</sup>。本文通过在钢桥面板顶板上、下表面施加对称激励的集中力荷载获得 S0 单模态信号, 对无损伤与含损伤钢桥面板模型, 采用相同的激励点和接收点设置进行 Lamb 波传播模拟, 如图 6 所示。




图5 Lamb波激励方式

Fig. 5 Lamb wave excitation method




图6 激励点和接收点布置

Fig. 6 Arrangement of excitation and receiving points

Lamb 波本质上是纵波与横波在自由边界条件下通过多次反射叠加形成的稳定波形。为确保结构的位移随时间变化的稳定性, 同时减小数值计算中因网格大小引起的误差, 网格尺寸  $\Delta l$  和时间步长  $\Delta t$  应满足以下公式<sup>[17]</sup>

$$c_l = \sqrt{\frac{E(1-\sigma)}{\rho(1+\sigma)(1-2\sigma)}} \quad (5)$$

$$c_t = \sqrt{\frac{E}{2(1+\sigma)\rho}} \quad (6)$$

$$\Delta l \leq \frac{c_t}{10f_{\max}} \quad (7)$$

$$\Delta t \leq \frac{\Delta l}{c_l} \quad (8)$$

式中:  $E$  为板的弹性模量,  $\sigma$  为板的泊松比,  $\rho$  为板的密度,  $c_t$  为 Lamb 波横波速度,  $f_{\max}$  为激励信号中心频率,  $c_l$  为 Lamb 波纵波速度。

由式(7)和式(8)可确定钢桥面板 Lamb 波传播区域的网格尺寸为 1 mm, 时间步长为 0.1  $\mu\text{s}$ 。

## 1.2 数值仿真结果分析

Lamb 波在钢桥面板顶板传播特征如图 7 所示。波从激励点位置开始沿顶板传播, 形成近似圆形波并向周围扩散; 当波传播至顶板边界时会产生反射波; 当波遇到结构损伤时, 会向损伤区域周围散射并产生携带损伤信息的反射波, 其中与直达波传播方向相同的反射波分量将在接收点与后续直达波发生叠加。

通过对比相同激励-接收路径下 Lamb 波损伤信号与无损状态信号的时域特征(如图 8 所示), 可观察到显著差异: 相较于无损状态信号, 含损伤工况下信号曲线存在相位右移现象, 且初始直达波包络幅值明显降低, 波形与趋势均符合 Lamb 波实际传播特性<sup>[9-11]</sup>。

## 1.3 构建数据集

通过数值仿真分别建立四种损伤程度不同的钢桥面板 U 肋-顶板节点工况, 如表 2 所示, 开展 Lamb 波损伤特征信号采集。通过调整激励点和接收点在顶板上的位置, 针对每种损伤工况各采集 250 组有效 Lamb 波信号, 4 种工况共采集 1 000 个样本, 构建完整数据集。为增强模型特征识别能力, 对所有信号进行 Hilbert 变换并提取包络曲线<sup>[18]</sup>, 如图 9 所示。数据集经随机打乱后, 对数据集每个分类进行划分, 其中 700 条为训练集、300 条为验证集, 以使模型在整个训练过程中对各个分类的敏感度更加均匀。

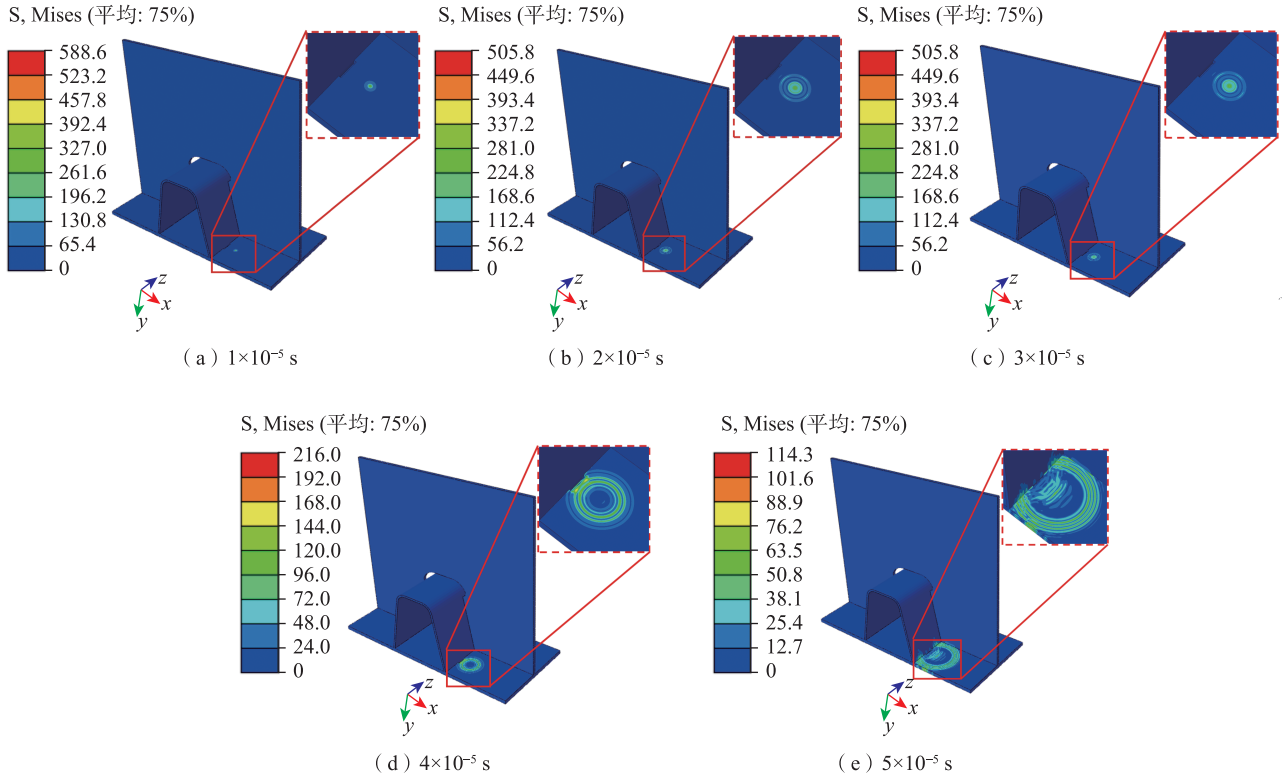


图7 Lamb波在钢桥面板上传播过程

Fig. 7 Lamb wave propagation process on steel bridge deck

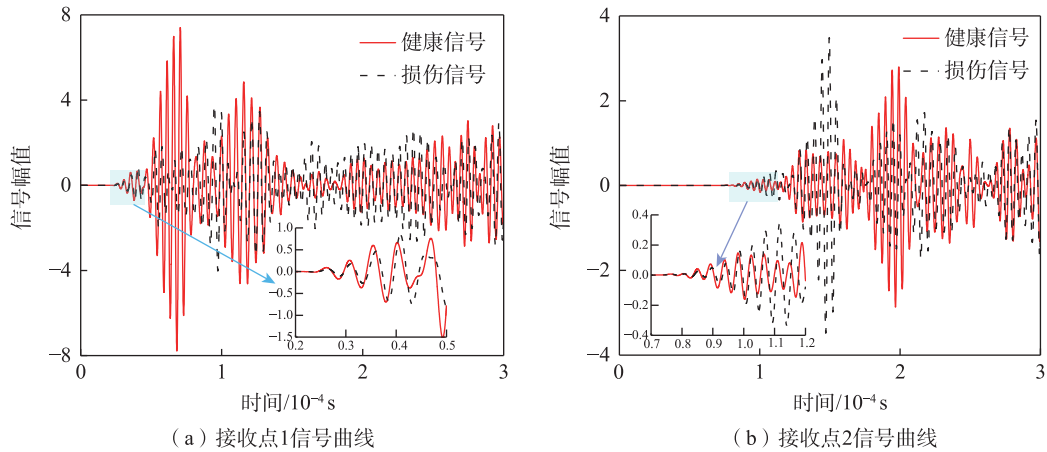


图8 Lamb波信号曲线

Fig. 8 Lamb wave signal curve

## 2 构建SE-LSTM-CNN模型

### 2.1 CNN

CNN是一种处理具有网格结构数据的深度学习模型,其通过卷积运算实现特征提取功能,广泛应用于图像分类、信号识别等领域<sup>[19]</sup>。根据输入数据的维度特性,CNN可分为一维、二维及三维三种

类型。针对Lamb波这类时域信号的一维序列特性,本文采用1D-CNN进行分析<sup>[20]</sup>,典型的1D-CNN架构如图10所示,由 $M$ 个卷积层、 $L$ 个全连接层及池化层、分类层等模块构成。

卷积层作为CNN的核心组件,其功能是通过可学习的卷积核对输入数据执行局部特征提取。该层的计算过程可分为两个关键步骤:首先






图9 Lamb波信号及包络图

Fig. 9 Lamb wave signal and envelope diagram

表2 数值仿真工况

Tab.2 Numerical simulation of working conditions

| 工况  | 损伤状况 (长×宽×深)/mm <sup>3</sup> |
|-----|------------------------------|
| 工况一 | 无损伤                          |
| 工况二 | 40×6×10                      |
| 工况三 | 20×3×7                       |

每一个卷积核沿着输入数据进行滑动,每次滑动后将对应的输入数据与卷积核内可训练的权值  $W_{ij}^l$  相乘,将所有乘积求和得到卷积运算结果,该运算过程常用  $*$  表示。随后将卷积运算结果引入可训练偏置  $b_{ij}^l$ ,并通过激活函数  $f^l(\cdot)$  映射,即可得到单次卷积输出结果,如图11所示。第  $l$  层卷积层第  $i$  个卷积核在输入数据上的第  $k$  位置处卷积输出结果  $H_{i,k}^l$  为

$$H_{i,k}^l = f^l(P_k^l * W_{ij}^l + b_{ij}^l) \quad (9)$$

式中:  $W_{ij}^l$ ,  $b_{ij}^l$  分别为第  $l$  层卷积层第  $i$  个卷积核的权值和偏置,  $P_k^l$  为第  $l$  层卷积层第  $k$  个位置处的输入数据。

所有卷积核在输入数据上滑动进行卷积操作后分别得出每个卷积核所对应的特征组,即下层池化层的输入数据  $H_{ij}^l$

$$H_{ij}^l = [H_{i,1}^l, H_{i,2}^l, \dots, H_{i,n^l-r^l}^l, H_{i,n^l-r^l+1}^l] \quad (10)$$

式中:  $n^l$ ,  $r^l$  分别为第  $l$  层卷积层的输入数据的元素个数和卷积核中的权值个数。

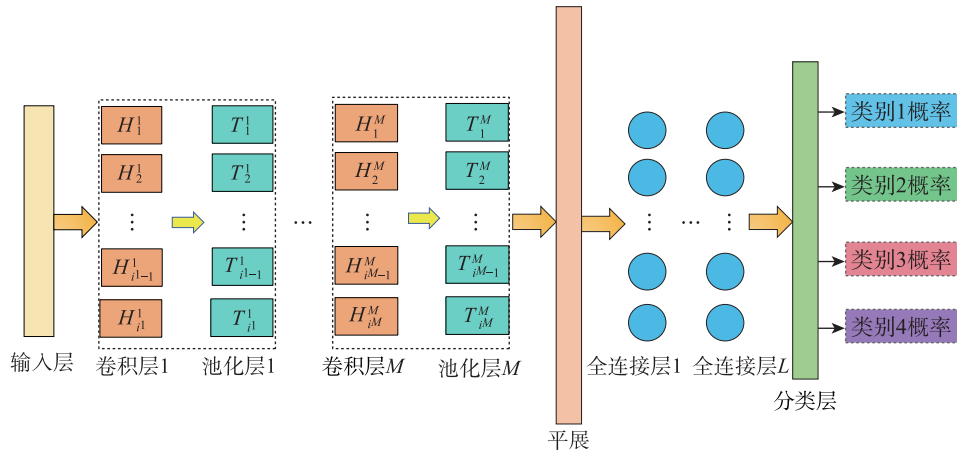


图10 CNN结构示意图

Fig. 10 Schematic diagram of the CNN structure

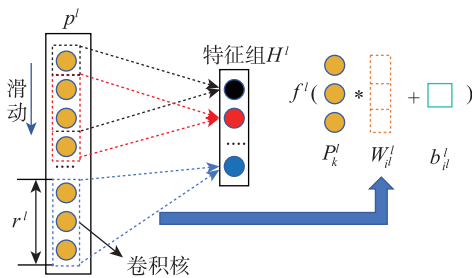


图11 卷积运算过程

Fig. 11 Convolution process

池化层通常会接续于卷积层之后,其核心功能是对卷积层特征组执行下采样操作。与卷积运算类似,下采样也是通过预设步长的滑动窗口在输入特征组上遍历,实现空间维度压缩。主流池化操作包含最大池化与平均池化两种:前者通过滑动池化窗口选取局部区域内的最大特征值作为输出,后者则计算该区域内特征值的算术平均值,如图12所示。若池化窗口的尺度为  $c$ ,则第  $l$  层卷积层第  $i$  个池化窗口在输入数据的第  $k$  个位置的平均化结果




图 12 池化操作

Fig. 12 Pooling operations

$T_{i,k}^l$  可表示为

$$T_{i,k}^l = \frac{H_{i,k}^l + H_{i,k+1}^l + \dots + H_{i,k+c-1}^l}{c} \quad (11)$$

最大池化结果  $T_{i,k}^l$  可表示为

$$T_{i,k}^l = \max(H_{i,k}^l, H_{i,k+1}^l, \dots, H_{i,k+c-1}^l) \quad (12)$$

池化窗口进行池化操作后得出所对应的特征组  $T_{i,1}^l$ , 即下层的输入数据  $T^l$

$$T^l = [T_{i,1}^l, T_{i,2}^l, \dots, T_{i,n^l-r^l+1}^l] \quad (13)$$

式中:  $n^l, r^l$  分别为第  $l$  层池化层的输入数据的元素个数和池化窗口长度。

全连接层和分类层位于 CNN 的最后, 全连接层将输入的特征组进行映射和激活函数激活后输出为一维向量。最后由分类层对全连接层的输出向量映射到区间  $(0,1)$ , 得到每个样本归属于各类别的概率值。本文采用 softmax 分类器, 对于全连接层输出的一维向量  $\mathbf{P}$  在第  $i$  个分类上的概率  $a_i$  可表示为

$$a_i = \frac{e^{\theta_i}}{\sum_{i=1}^z e^{\theta_i}} \quad (14)$$

式中:  $\theta$  为  $[w, b]$  权值参数矩阵,  $z$  为样本的总分类数。

Softmax 分类器通过计算输入数据在每个分类的概率值, 最终选择概率值最大的分类作为输出, 从而完成多分类任务。

## 2.2 SE 注意力机制

注意力机制 (attention mechanism) 是深度学习领域中的一种重要技术, 它通过模仿人类的注意力过程, 为输入数据的不同部分分配不同的权重。SE 注意力机制是一种轻量型通道注意力机制, 可无缝嵌入现有 CNN 架构中。该机制通过动态调整各通道特征权重, 实现增强关键通道并抑制次要通道, 使网络能够自适应聚焦于更具任务相关性的特征表

征<sup>[21]</sup>。如图 13 所示, SE 注意力机制包括三个步骤:

1) 挤压: 通过全局平均池化操作对输入特征图进行空间维度降维。对每个通道的二维特征图执行全局平均池化, 将宽高维度的局部特征信息聚合为单个标量值。此过程实现了对输入特征的空间特征压缩, 将每个通道的全局信息融合到一个数值中。

2) 激励: 采用包含瓶颈结构的两层全连接网络: 首先将通道维度非线性压缩至较低维空间, 再通过升维映射恢复原始通道数。在特征转换过程中, 利用 Sigmoid 激活函数生成归一化的通道注意力权重值, 表示每个通道的权重, 量化各通道对当前任务的贡献度。

3) 加权: 将训练出的通道权重与原始输入特征组进行逐通道相乘, 完成特征组的自适应加权, 使输出特征组在保留原始空间结构的同时, 其各通道权重特征分布得到优化, 使网络聚焦于与任务相关的关键特征。




图 13 SE 注意力机制

Fig. 13 SE attention mechanism

## 2.3 LSTM

LSTM 是一种特殊的循环神经网络, 核心创新在于引入细胞状态与三重门控机制, 通过动态调控信息流动, 实现了对序列数据中 long-term dependencies 的精准识别。如图 14 所示, LSTM 在处理每个时间步时, 将当前时间步输入  $x_t$  和前一时间步隐藏状




图14 LSTM结构图

Fig. 14 Schematic illustration of the LSTM structure

态  $h_{t-1}$  拼接, 作为3个门控机制的输入。遗忘门通过 Sigmoid 函数生成  $[0,1]$  区间值, 决定旧细胞状态中的保留信息  $f_t$ ; 输入门首先通过 Sigmoid 函数筛选出新细胞状态中的信息  $i_t$ , 随后利用  $\tanh$  函数生成候选记忆值  $g_t$ ; 输出门通过 Sigmoid 函数决定当前细胞状态向隐藏状态的暴露程度  $o_t$ , 将  $o_t$  与更新后的细胞状态  $C_t$  生成当前时间步隐藏状态  $h_t$ , 并输出至下一个时间步, 相关计算公式如下

$$f_t = \sigma(W_{xf}x_t + W_{hf}h_{t-1} + b_f) \quad (15)$$

$$i_t = \sigma(W_{xi}x_t + W_{hi}h_{t-1} + b_i) \quad (16)$$

$$g_t = \tanh(W_{xg}x_t + W_{hg}h_{t-1} + b_g) \quad (17)$$

$$o_t = \sigma(W_{xo}x_t + W_{ho}h_{t-1} + b_o) \quad (18)$$

$$C_t = f_t C_{t-1} + i_t g_t \quad (19)$$

$$h_t = o_t \tanh(C_t) \quad (20)$$

式中:  $\sigma$  为 Sigmoid 激活函数, 如式(21)所示;  $\tanh$  表示双曲正切激活函数, 如式(22)所示

$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (21)$$

$$\tanh(x) = \frac{\sin x}{\cos x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (22)$$

LSTM 通过遗忘门动态筛选历史信息, 输入门控制新信息输入, 输出门调节状态暴露, 三者协同实现跨时间步的信息筛选与传递, 可对 Lamb 波信号进行时序建模, 精准捕捉波包到达时间、幅值衰减等时序特征<sup>[11]</sup>。

## 2.4 模型架构设计

本文构建的 SE-STM-CNN 模型由 3 个卷积层、3 个池化层、SE 注意力机制、LSTM 层、全连接层及分类层组成, 其模块化设计采用“损伤特征提取-调整通道权重-建模时序关系”的流程逐步处理 Lamb 波信号, 如图 15 所示。

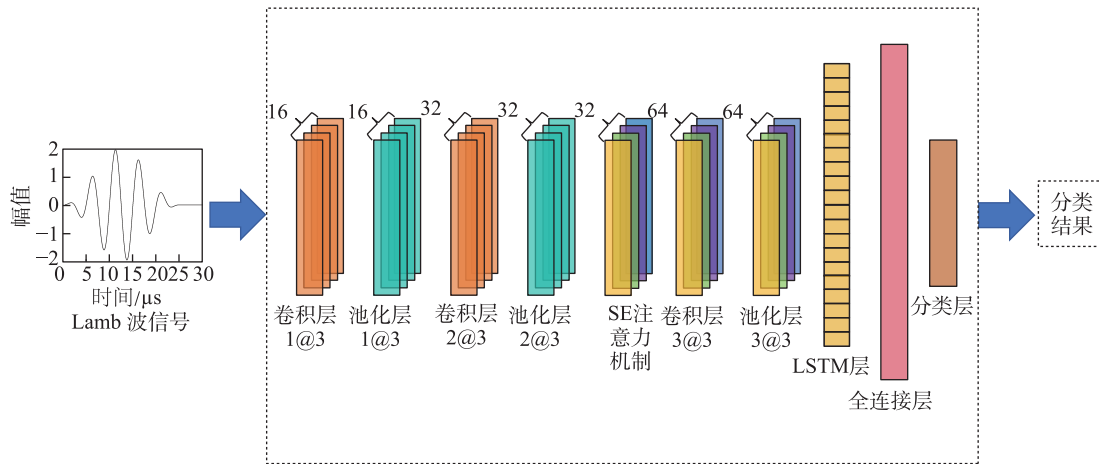


图15 SE-LSTM-CNN模型

Fig. 15 SE-LSTM-CNN model

模型通过多模块协同实现损伤特征识别: 卷积层采用  $3 \times 1$  大小的卷积核, 步长 1 在 Lamb 波信号上滑动, 通过多组卷积核捕捉 Lamb 波信号中由损伤引起的局部波形变化, 并采用 ReLU 函数增强特征表达能力; 池化层执行  $3 \times 1$  最大池化操作, 通过步长为 1 的池化窗口增强模型对信号时移误差及传感器

偏差的容错能力; 在第 2 个池化层之后续接 SE 注意力机制, 通过全局平均池化汇总压缩通道信息, 再通过全连接网络计算各通道的重要程度, 让与损伤相关的频段和传播路径特征更突出, 同时减弱噪声干扰; LSTM 层接收第 3 个池化层输出的加权特征组, 利用其门控结构记录波包到达时间、相位变化

等时序特征,选择性地保留重要信息,同时遗忘无关信息;分类层将全连接层处理好的特征转换为分类结果,通过 Softmax 分类器输出最终的损伤预测结果。该模型中,卷积部分负责捕捉局部特征,LSTM 部分专注于时序规律,SE 模块优化各通道权重,三者协同优化损伤特征表达能力。

### 3 训练结果分析与消融实验

#### 3.1 训练结果分析

运用 MATLAB 软件与构建的 SE-LSTM-CNN

模型对划分好的数据集进行训练。优化策略采用 Adam 算法,设置最大训练轮次为 1 000 轮,初始学习率配置为 0.01。为提升训练效率并增强泛化性能,实施分阶段学习率衰减机制,每完成 500 轮训练周期,将当前学习率按比例缩减至原有值的十分之一。

训练结果如图 16 所示,训练集准确率接近 100%时,验证集准确率为 93.67%,各分类准确率均超过 90%,如表 3 所示,表明 SE-LSTM-CNN 模型在该任务上表现出良好的适用性。

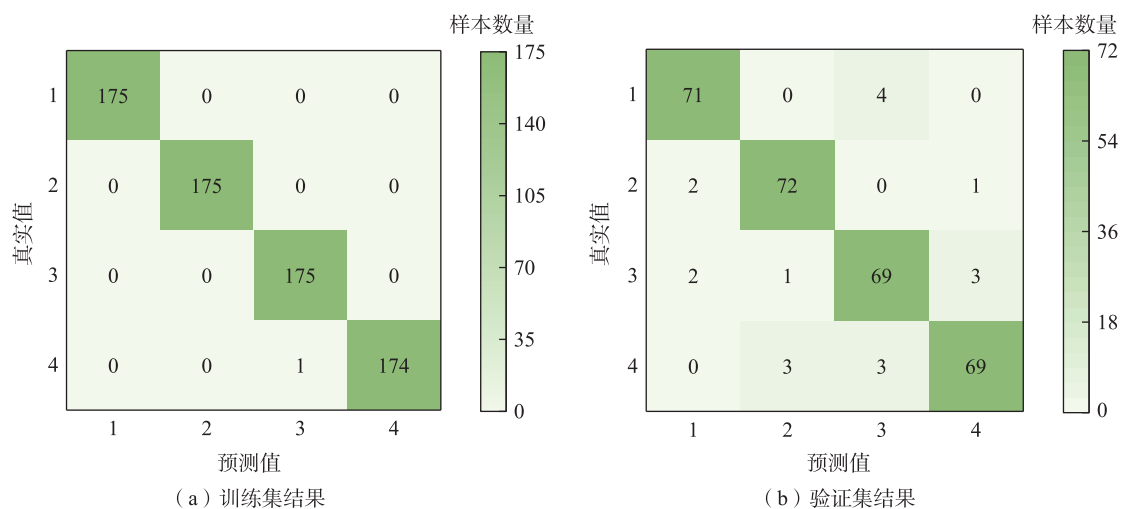


图 16 SE-LSTM-CNN 模型训练结果

Fig. 16 SE-LSTM-CNN model training results

表 3 各工况验证集准确率

Tab.3 The accuracy of the validation set for each working condition

| 分类号 | 损伤状况 (长×宽×深)/mm <sup>3</sup> | 验证集准确率 |
|-----|------------------------------|--------|
| 1   | 无损伤                          | 94.67% |
| 2   | 40×6×10                      | 96.00% |
| 3   | 20×3×7                       | 92.00% |
| 4   | 10×1×4                       | 92.00% |

#### 3.2 消融实验

为验证 CNN 中 SE 注意力机制与 LSTM 层在钢桥面板 Lamb 波损伤检测任务中的有效性,设计消融实验,保持各参数与数据集划分不变,分别构建以下对照模型进行训练:CNN、SE-CNN 及 LSTM-CNN 模型。同时,为验证 Hilbert 变换对损伤特征提取的增益作用,在相同参数下运用原始信号与包络曲线信号分别训练 SE-LSTM-CNN 模型。训练

结果如图 17 所示。

将上述结果对比可以得出如表 4 所示,SE 注意力机制与 LSTM 分别使 CNN 模型在钢桥面板 Lamb 波损伤检测任务上的准确率提升 1.00%与 3.33%,而二者协同作用时准确率提升达 8.33%;此外,Hilbert 变换预处理将 SE-LSTM-CNN 模型的准确率提高 21.33%,验证了对采集到的 Lamb 波信号进行 Hilbert 变换提取包络曲线更有利于 SE-LSTM-CNN 模型识别信号中的损伤特征。

#### 3.3 测试结果分析

为验证模型对信号变化的适应能力,改变传感器布置方式,将激励点与接收点的位置重新排列,形成与原始数据不同的检测布局<sup>[22]</sup>。基于新布局采集了 40 条 Lamb 波信号作为测试数据,在 MATLAB 平台上开发检测程序后,使用训练好的模型进行预测测试。如图 18 所示,在钢桥面板损伤检测任



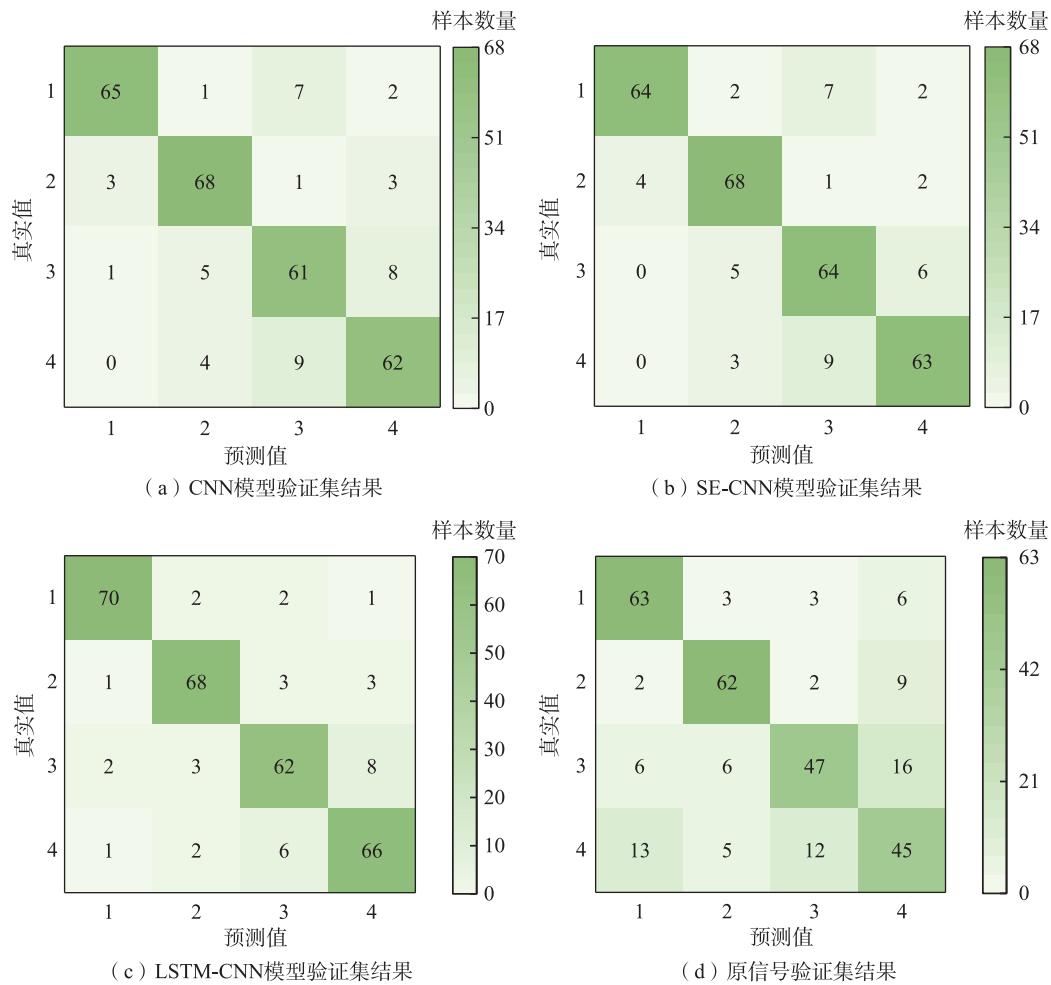


图 17 消融实验结果

Fig. 17 Results of ablation experiments

表 4 各模型验证集准确率

Tab.4 The accuracy of each model validation set

| 数据集  | 模型          | 验证集准确率 |
|------|-------------|--------|
| 包络曲线 | CNN         | 85.33% |
| 包络曲线 | SE-CNN      | 86.33% |
| 包络曲线 | LSTM-CNN    | 88.67% |
| 包络曲线 | SE-LSTM-CNN | 93.67% |
| 原信号  | SE-LSTM-CNN | 72.33% |

务中,模型对全新采集的信号数据保持了95%的检测准确率。测试结果表明,即使面对传感器位置变动带来的信号特征变化,SE-LSTM-CNN模型仍能保持稳定的检测性能,证明该模型对信号变化具有较强的抗干扰能力,在钢桥结构健康监测场景中具备良好的实际应用潜力。

### 3.4 软件封装

如图 19 所示,采用 MATLAB APP Designer 将





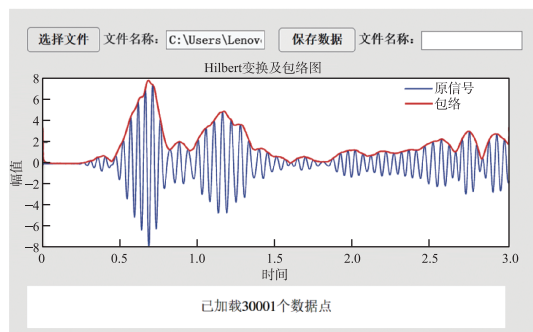
图 18 测试集结果

Fig. 18 Test set results

Lamb波信号调制、Hilbert变换算法、钢桥面板损伤检测代码进行系统整合,构建钢桥面板损伤智能检



(a) 信号调制界面



(b) Hilbert变换提取包络曲线界面



(c) 损伤识别界面

图 19 软件操作界面

Fig. 19 Software operation interface

测软件。该软件可实现从信号调制到损伤检测的自动化处理,有效抑制了多环节误差传递效应,在保障检测精度的同时,降低了对专业人员的操作依赖,提升了检测效率。

## 4 结论

本文采用深度学习与Lamb波检测技术结合的方法,对钢桥面板U肋-顶板节点的损伤检测进行研究,得到以下结论:

1) 通过对比相同激励-接收路径下损伤与无损状态下的Lamb波信号曲线,发现损伤信号直达波包的相位呈现显著右移现象,且幅值出现明显衰

减,表明损伤会导致信号时域特性发生可量化的改变,验证了利用深度学习模型训练Lamb波信号实现钢桥面板损伤检测的可行性。

2) 提出的SE-LSTM-CNN模型在训练集准确率接近100%的情况下,验证集准确率达到93.67%,各类损伤分类准确率均超过90.00%,且在新测试集上的准确率为95.00%。表明该模型对钢桥面板U肋-顶板节点的损伤检测具有较高精度与适用性。

3) 通过消融实验对比分析发现:SE-CNN与LSTM-CNN模型在损伤特征识别准确率方面较基础CNN模型分别提升1.00%与3.33%,SE-LSTM-CNN融合模型的分类准确率较单一改进模型再提升5.00%与7.33%,验证了多模块协同优化的有效性。此外,基于Hilbert变换提取的包络曲线数据集训练时,模型验证集准确率较原始信号数据集提高21.33%,表明Hilbert变换后的信号包络曲线更有利于深度学习模型捕获Lamb波中的损伤信息。

4) 通过整合Lamb波信号调制、Hilbert变换及损伤检测算法,基于MATLAB APP Designer构建钢桥面板损伤智能检测软件。实现了从原始信号调制、预处理、特征分析到损伤识别的全流程优化,缩短检测周期,降低人工干预,有望为钢桥面板的快速、低成本维护提供技术支持。

## 参考文献:

- [1] 张清华,崔闯,卜一之,等. 正交异性钢桥面板足尺节段疲劳模型试验研究[J]. 土木工程学报, 2015, 48(4): 72-83.  
ZHANG Q H, CUI C, BU Y Z, et al. Experimental study on fatigue features of orthotropic bridge deck through full-scale segment models[J]. China Civil Engineering Journal, 2015, 48(4): 72-83.
- [2] 田亮,董熠鑫,肖飞知,等. 基于结构应力法的钢-UHPC组合桥面板RD节点疲劳性能分析[J]. 华东交通大学学报, 2025, 42(2): 54-65.  
TIAN L, DONG Y X, XIAO F Z, et al. Fatigue performance analysis of RD welded joint in steel-UHPC composite bridge deck based on structure stress method[J]. Journal of East China Jiaotong University, 2025, 42(2): 54-65.
- [3] 田亮,邢守航,樊立龙,等. 模拟轮载作用下钢桥面板RD节点疲劳寿命计算方法对比分析[J]. 华东交通大学学

- 报, 2023, 40(4): 76-85.
- TIAN L, XING S H, FAN L L, et al. Comparative analysis of fatigue life calculation methods for rib-to-deck joints in steel bridge decks under simulated wheel load[J]. Journal of East China Jiaotong University, 2023, 40(4): 76-85.
- [4] MEI H F, HAIDER M F, JAMES R, et al. Pure S0 and SH0 detections of various damage types in aerospace composites[J]. Composites Part B: Engineering, 2020, 189: 107906.
- [5] 程斌, 石林泽, 刘天成. 基于Lamb导波深度学习的钢桥面板疲劳裂纹智能监测研究[J]. 中国公路学报, 2023, 36(2): 120-128.
- CHENG B, SHI L Z, LIU T C. Research on intelligent monitoring of fatigue cracks in steel bridge decks based on deep learning of Lamb guided waves[J]. China Journal of Highway and Transport, 2023, 36(2): 120-128.
- [6] 何存富, 郑明方, 吕炎, 等. 超声导波检测技术的发展、应用与挑战[J]. 仪器仪表学报, 2016, 37(8): 1713-1735.
- HE C F, ZHENG M F, LYU Y, et al. Development, applications and challenges in ultrasonic guided waves testing technology[J]. Chinese Journal of Scientific Instrument, 2016, 37(8): 1713-1735.
- [7] 蔡建, 袁慎芳, 张逍越, 等. Lamb波双面激励方法及其在近邻损伤监测中的应用[J]. 南京航空航天大学学报, 2010, 42(1): 62-67.
- CAI J, YUAN S F, ZHANG X Y, et al. Lamb wave double side excitation and its application in adjacent damage monitoring[J]. Journal of Nanjing University of Aeronautics & Astronautics, 2010, 42(1): 62-67.
- [8] PANDEY P, RAI A, MITRA M. Explainable 1-D convolutional neural network for damage detection using Lamb wave[J]. Mechanical Systems and Signal Processing, 2022, 164: 108220.
- [9] RAI A, MITRA M. Lamb wave based damage detection in metallic plates using multi-headed 1-dimensional convolutional neural network[J]. Smart Materials and Structures, 2021, 30(3): 035010.
- [10] WU J, XU X B, LIU C, et al. Lamb wave-based damage detection of composite structures using deep convolutional neural network and continuous wavelet transform[J]. Composite Structures, 2021, 276: 114590.
- [11] SHANG L, ZHANG Z, TANG F J, et al. CNN-LSTM hybrid model to promote signal processing of ultrasonic guided Lamb waves for damage detection in metallic pipelines[J]. Sensors, 2023, 23(16): 7059.
- [12] 田亮, 王宇宁, 赵健, 等. 基于Lamb波的钢桥面板U肋-顶板节点疲劳损伤检测数值仿真分析[J]. 世界桥梁, 2024, 52(4): 114-121.
- TIAN L, WANG Y N, ZHAO J, et al. Numerical simulation analysis of fatigue damage detection of U rib-deck connection in steel bridge deck based on Lamb waves[J]. World Bridges, 2024, 52(4): 114-121.
- [13] 石林泽, 程斌. 钢桥面板疲劳裂纹监测的Lamb导波传播特征的机理研究[J]. 公路, 2022, 67(7): 151-156.
- SHI L Z, CHENG B. Study on propagation mechanism of Lamb guided waves for OSDs fatigue crack monitoring[J]. Highway, 2022, 67(7): 151-156.
- [14] 陈刚, 汪焮成. U肋全熔透角焊缝超声波相控阵检测方法研究[J]. 桥梁建设, 2020, 50(6): 33-38.
- CHEN G, WANG X C. Study of using phased array ultrasonic testing method to inspect U-rib full penetration fillet welds[J]. Bridge Construction, 2020, 50(6): 33-38.
- [15] 滕飞, 李大勇, 高桂丽. 超声兰姆波在铝合金薄板中的传播模式[J]. 无损检测, 2009, 31(6): 433-437.
- TENG F, LI D Y, GAO G L. The mode of Lamb wave transmitting in thin aluminum alloy plate[J]. Nondestructive Testing Technology, 2009, 31(6): 433-437.
- [16] 周凯, 徐新生, 武湛君. 基于压电传感器的单一模态Lamb波损伤检测[J]. 压电与声光, 2020, 42(1): 38-41.
- ZHOU K, XU X S, WU Z J. Damage detection with single mode Lamb wave based on piezoelectric transducers[J]. Piezoelectrics & Acousto-optics, 2020, 42(1): 38-41.
- [17] YANG C H, YE L, SU Z Q, et al. Some aspects of numerical simulation for Lamb wave propagation in composite laminates[J]. Composite Structures, 2006, 75(1/2/3/4): 267-275.
- [18] 田亮, 王宇宁, 樊立龙, 等. 单模态Lamb波检测板类结构损伤识别成像方法[J]. 交通运输工程学报, 2024, 24(6): 121-134.
- TIAN L, WANG Y N, FAN L L, et al. Imaging method for damage identification of plate structures detected by single mode Lamb waves[J]. Journal of Traffic and Transportation Engineering, 2024, 24(6): 121-134.
- [19] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述[J]. 计算机学报, 2017, 40(6): 1229-1251.
- ZHOU F Y, JIN L P, DONG J. Review of convolutional neural network[J]. Chinese Journal of Computers, 2017, 40(6): 1229-1251.
- [20] 骆勇鹏, 王林堃, 廖飞宇, 等. 基于一维卷积神经网络的结构损伤识别[J]. 地震工程与工程振动, 2021, 41(4): 145-156.

LUO Y P, WANG L K, LIAO F Y, et al. Vibration-based structural damage identification by 1-dimensional convolutional neural network[J]. Earthquake Engineering and Engineering Dynamics, 2021, 41(4): 145-156.

- [21] 余强, 韩静娴, 杨子梁, 等. 基于改进双重压缩和激励与多头特征注意力机制的电-热负荷协同预测[J]. 电力自动化设备, 2025, 45(3): 201-208.

YU Q, HAN J X, YANG Z L, et al. Collaborative forecasting of electricity-thermal load based on improved dual squeeze and excitation and multi-head feature attention mechanism[J]. Electric Power Automation Equipment, 2025, 45(3): 201-208.

- [22] 骆英, 毛雨欣. 一种基于Lamb波的智能结构损伤识别方法[J]. 实验力学, 2022, 37(3): 305-314.

LUO Y, MAO Y X. An intelligent structural damage identification method based on Lamb wave[J]. Journal of Experimental Mechanics, 2022, 37(3): 305-314.



通信作者: 田亮(1984—), 男, 副教授, 博士, 硕士生导师。研究方向为高性能钢桥结构、钢桥疲劳与断裂。E-mail: sjtu\_tl@126.com。

(责任编辑: 李根)