

文章编号: 1674-8190(2024)05-048-10

# 基于 LSTM-CNN 的结构固有频率激励下 正弦载荷识别方法研究

何文博<sup>1</sup>, 孙含宇<sup>1</sup>, 解江<sup>1</sup>, 张晓强<sup>2</sup>

(1. 中国民航大学 民航航空器适航审定技术重点实验室, 天津 300300)

(2. 西南科技大学 信息工程学院, 绵阳 621010)

**摘要:** 当外载荷频率达到或接近结构固有频率时, 传统载荷识别方法(比如截断奇异值分解法)的识别精度会降低。为此, 通过卷积网络的特征提取和长短期记忆网络的长时记忆功能建立 LSTM-CNN 载荷识别模型, 提出一种基于 LSTM-CNN 模型的载荷识别方法, 对 GARTEUR 飞机模型开展载荷时域波形识别研究。通过采集结构的响应数据和激励数据进行模型训练和载荷识别, 并与截断奇异值分解(TSVD)方法、长短期记忆网络(LSTM)方法和深度卷积神经网络(DCNN)方法的识别结果进行对比分析。结果表明: 基于 LSTM-CNN 模型的载荷识别方法可以有效应用于结构固有频率激励下正弦载荷识别问题, 具有较高的识别精度和抗噪能力。

**关键词:** LSTM-CNN; 固有频率; 载荷识别; GARTEUR 飞机模型

中图分类号: V215.1

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.2024.05.04

## Research on sinusoidal load identification method under structural natural frequency excitation based on LSTM-CNN

HE Wenbo<sup>1</sup>, SUN Hanyu<sup>1</sup>, XIE Jiang<sup>1</sup>, ZHANG Xiaoqiang<sup>2</sup>

(1. Key Laboratory of Civil Aviation Aircraft Airworthiness Certification Technology, Civil Aviation University of China, Tianjin 300300, China)

(2. School of Information Engineering, Southwest University of Science and Technology, Mianyang 621010, China)

**Abstract:** Addressing the challenge of low identification accuracy in traditional load identification methods based on the truncated singular value decomposition (TSVD) method, especially when the external load frequency approaches or reaches the natural frequency of the structure, the LSTM-CNN load identification model is proposed in this paper. This model combines the feature extraction capabilities of the convolutional neural network (CNN) with the long-term memory function of the long short-term memory network (LSTM). The load identification method based on the LSTM-CNN model is then applied to research load time domain waveform identification on the GARTEUR aircraft model. For model training and load identification, the response data and excitation data from the structure are corrected. The identification results are compared with the TSVD method, LSTM method, and DCNN method. Results show that the load identification method based on the LSTM-CNN model proves effective for sinusoidal load identification problems, especially under the natural frequency excitation of the structure. The method exhibits high identification accuracy and robust noise resistance capabilities.

**Key words:** LSTM-CNN; natural frequency; load identification; GARTEUR aircraft model

收稿日期: 2023-09-25; 修回日期: 2023-12-13

基金项目: 天津市航空装备安全性与适航技术创新中心开放基金(JCZX-2023-KF-03); 中国民航大学民航航空器适航审定技术重点实验室开放基金(SH2020112706)

通信作者: 解江(1982-), 男, 博士, 副研究员。E-mail: xiejiang5@126.com

引用格式: 何文博, 孙含宇, 解江, 等. 基于 LSTM-CNN 的结构固有频率激励下正弦载荷识别方法研究[J]. 航空工程进展, 2024, 15(5): 48-57.  
HE Wenbo, SUN Hanyu, XIE Jiang, et al. Research on sinusoidal load identification method under structural natural frequency excitation based on LSTM-CNN[J]. Advances in Aeronautical Science and Engineering, 2024, 15(5): 48-57. (in Chinese)

## 0 引言

在实际工程问题中,动载荷引起的振动响应会对结构的安全性产生影响。当动载荷的频率接近或达到结构固有频率时,会发生共振现象,对结构造成更大的危害。因此,为了减少振动可能会给结构带来的不良影响,必须在设计阶段了解其所受的动载荷状态。因此,准确识别结构所受振动载荷已成为结构动力学领域的一个热门问题<sup>[1]</sup>,具有重要意义。

传统的载荷识别方法包括直接求逆法、截断奇异值分解(TSVD)方法和Tikhonov方法<sup>[2]</sup>等。传统载荷识别方法的求解思路是根据已知结构模型的传递函数和响应来反演出载荷。然而,这些方法往往会面临计算过程复杂和矩阵条件数过大导致求逆时出现的矩阵病态问题<sup>[3]</sup>。随着计算机技术的发展,神经网络算法作为一种可以通过大量数据实现自适应学习的算法逐渐被广泛应用于各个领域<sup>[4]</sup>。神经网络通过建立结构输入和输出数据之间的映射关系、进行大量数据的网络训练以及根据外部信息对网络参数的调整,实现对数据的预测和处理<sup>[5]</sup>。

Cao X等<sup>[6]</sup>以悬臂梁模型作为载荷识别对象,构建基于人工神经网络的载荷识别模型,并将该方法推广到机翼的载荷识别问题上;陈奇等<sup>[7]</sup>构建了基于BP(Back Propagation)神经网络模型的载荷识别方法,并利用飞行参数来识别机翼上的载荷,同时对识别方法的识别精度和泛化能力进行了探讨;窦春红等<sup>[8]</sup>将神经网络算法用于海洋平台的振动载荷识别,并与时域正演方法进行对比,通过仿真和实验证明基于神经网络的载荷识别方法相对于传统载荷识别方法具有更高的精度;黄秉钧等<sup>[9]</sup>基于卷积神经网络模型,建立立柱—甲板模型的砰击载荷识别方法,根据结构测点应变响应数据对砰击载荷进行识别,同时考虑数据噪声的影响,结果表明,相比传统的反向传播神经网络模

$$\ddot{x}_i(t) = \sum_{j=1}^P [h_{ij}(0) f_j(t) + h_{ij}(\Delta t) f_j(t - \Delta t) + \dots + h_{ij}(n\Delta t) f_j(t - n\Delta t)] \quad (2)$$

式中: $h_{ij}(n\Delta t)$ 为 $t = n\Delta t$ 时刻结构第 $i$ 个响应点与第 $j$ 个激励点之间的跨点脉冲响应函数; $n$ 为第 $n$ 个时刻<sup>[14]</sup>。

可以看出,任意时刻的结构动响应,不仅仅由

$$\ddot{x}_i(t) = \sum_{j=1}^P F[f_j(t), f_j(t - \Delta t), f_j(t - 2\Delta t), \dots, f_j(t - n\Delta t)] \quad (3)$$

型,卷积神经网络(CNN)模型的识别精度更高并具有良好的抗噪性;杨特等<sup>[10]</sup>针对线性时不变结构的平稳随机载荷识别问题,从结构的动力学响应求解原理出发,利用小波变换的特征提取能力和长短期记忆神经网络(LSTM)对时序问题的建模与映射能力,提出了一种基于样本特征提取的动载荷识别方法,降低了神经网络模型拟合的复杂程度,保证了神经网络的泛化能力;Shao B L等<sup>[11]</sup>在LSTM的基础上加入了卷积神经网络,构成多通道的LSTM-CNN方法用于化学过程的故障诊断,即将LSTM提取的时间特征输入到CNN中进行空间特征的提取,同时在卷积层引入使用不同尺寸的卷积核进行卷积的inception模块来构建多通道卷积,最后将不同的特征进行聚合,从而完成故障诊断,并通过实验证明该方法优于LSTM、CNN模型;Wan A P等<sup>[12]</sup>利用结合注意力机制的CNN-LSTM模型对短期电力负荷进行预测,解决了由于输入时间序列数据过长而导致的信息丢失问题,提高了短期电力负荷预测的准确性。

神经网络方法通过自适应学习建立动载荷与响应之间的关系来替代数学机理建模。针对结构固有频率激励下传统载荷识别方法精度低的问题,本文结合LSTM-CNN神经网络开展对结构固有频率激励下正弦载荷识别方法研究,并进行相应的试验验证。

## 1 时域动载荷—动响应关系

本文模型训练和识别所用到的激励数据和响应数据均为时域上的样本数据,其满足线性叠加原理,响应测点 $x$ 上的加速度响应与所受到的动载荷 $f(t)$ 之间存在卷积关系<sup>[13]</sup>:

$$\ddot{x}_i(t) = \sum_{j=1}^P \int_0^t h_{ij}(t - \tau) f_j(\tau) d\tau \quad (1)$$

将式(1)离散化之后可得:

该对应时刻的动载荷决定的,还会受到该时刻之前所有动载荷的影响。因此,结构响应与动载荷的关系可以表示为

从式(3)可以看出:某时刻  $t$  的振动响应是受到  $f(t)$  及其之前多个时刻的振动载荷共同影响的,因此对于某一时刻的待识别载荷同样也包含着多个时刻的振动响应信息。所以结构的动载荷识别问题可以如式(4)表示,通过结构振动响应数据与载荷数据训练神经网络,由此建立载荷识别模型。

$$f_j(t) = \sum_{i=1}^N G_i [\ddot{x}_i(t), \ddot{x}_i(t + \Delta t), \dots, \ddot{x}_i(t + n\Delta t)] \quad (4)$$

## 2 基于 LSTM-CNN 的识别模型

传统卷积神经网络能提取数据特定时刻的状态信息,但是会丢失长时信息的特征,而长短期记忆网络(LSTM)根据模型的结构可知,由于其本身所具有的门机制和权重共享的特性,使得 LSTM 可以进行长时记忆,解决高维度时序序列问题,这可以很好地用来分析线性与非线性系统数据的时间特性,建立载荷数据、响应数据与各参数之间的相关性,从而学习系统的长时状态特征。根据 CNN 结构的特点可知,其主要是通过选择合适尺寸的卷积核提取数据的局部特征。因此,根据卷积神经网络和长短期记忆网络的特点建立将 LSTM 和 CNN 进行模型融合的 LSTM-CNN 载荷识别模型。

### 2.1 LSTM-CNN 网络构建

LSTM-CNN 载荷识别模型主要由三部分组成<sup>[15]</sup>:输入层、LSTM 层、CNN 层,如图 1 所示。

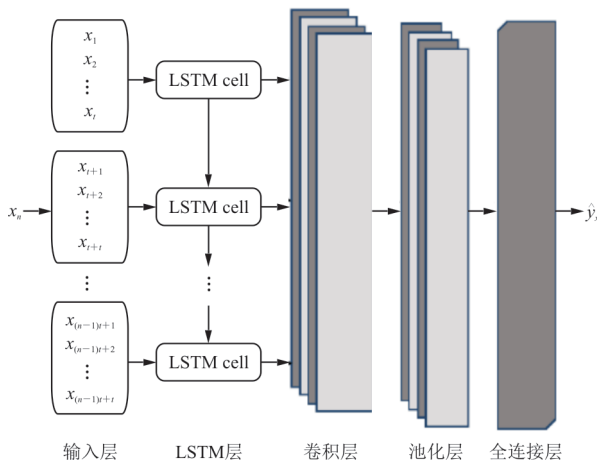


图 1 LSTM-CNN 结构图

Fig. 1 LSTM-CNN structure drawing

#### 1) 输入层

通过上述分析可知,该模型输入层的主要作用是对输入的时序数据进行分割处理,把一段长时的时序数据划分为多个短时数据段传输给 LSTM 层提取系统的短时特征。在输入层会将输入数据  $X$  分割成若干个长度为  $t$  的数据段  $[X_{(n-1)t+1,m}, \dots, X_{(n-1)t+t,m}]$ ,如式(5)所示。

$$X = \begin{bmatrix} x_{(n-1)t+1,1} & \cdots & x_{(n-1)t+1,m} \\ \vdots & \vdots & \vdots \\ x_{(n-1)t+t,1} & \cdots & x_{(n-1)t+t,m} \end{bmatrix} \quad (X \in R^{t \times m}) \quad (5)$$

#### 2) LSTM 层

LSTM 层的主要功能是对输入数据进行多参数相关性和时序性分析,从而得到各个短时数据段的短时状态特征。LSTM 网络结构如图 2 所示,通过使用 LSTM 的细胞单元对每一段输入数据进行时序分析,每一段短时输入数据会按时间顺序依次输入到 LSTM 单元中,即 LSTM 细胞单元中每一段短时时序数据都会有单独的状态信息  $C_t$  进行长期的信息状态保存并传输到下一层,同时引入遗忘门  $f_t$ 、输入门  $i_t$  和输出门  $o_t$  三个门限单元来控制状态信息的传递和更新,从而实现长时记忆。最终结果由隐含层  $H_t$  输出,并将最后一个时刻的输出  $H_1, \dots, H_t$  作为各个短时数据的短时状态特征输出向量。

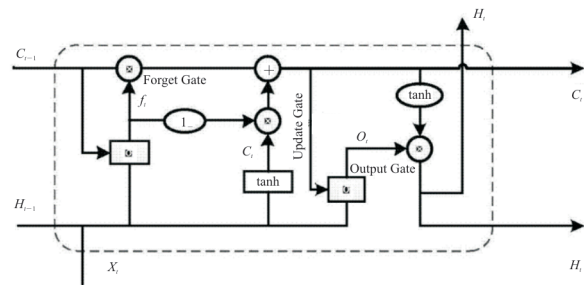


图 2 LSTM 层结构图

Fig. 2 LSTM structure drawing

#### 3) CNN 层

CNN 层为该模型的核心部分,其结构主要包括卷积层、池化层、全连接层和输出层,如图 3 所示,卷积结构的作用是分析从 LSTM 层中计算得到的系统各个短时状态之间的变化。其中,CNN 层的输入为 LSTM 层按顺序输出得到的矩阵,如式(6)所示。

$$H = [H_1, \dots, H_t]^T \quad (H \in R^{n \times n_1}) \quad (6)$$

卷积层是CNN的核心,通过特定尺寸的卷积核对输入数据进行卷积运算,并通过稀疏连接建立输入和输出单元的关系,其特有的权值共享特性可以使所有的输出单元共用一组参数与输入单元进行连接,极大地减少了模型所需训练参数,节省训练时间。再经过池化层对数据进行特征提取,在保留关键信息的基础上降低冗余信息,减少网络所需参数。

全连接层与输出层类似,对卷积和池化操作后的数据进行进一步的降维操作和特征提取,在此过程中选取合适的激活函数作为分类器,该模型使用Softmax函数作为分类器,Softmax函数的定义为

$$\text{Softmax}(x_i) = \frac{e^{x_i}}{\sum_{j=1}^{n+1} x_j} \quad (i=1, \dots, n) \quad (7)$$

式中: $n$ 为输出层节点个数; $x_i$ 为未经过Softmax函数的第*i*个节点的隐含层输出。

将特征向量通过输出层分类器后得到最后的预测输出:

$$\hat{y}(X) = \text{Softmax}(W_y \hat{y}_x + b_y) \quad (8)$$

式中: $\hat{y}(X)$ 为模型的预测结果; $\hat{y}_x$ 为全连接层输出值; $W_y$ 和 $b_y$ 分别为权值矩阵和偏置。




图3 CNN层结构图

Fig. 3 CNN structure drawing

## 2.2 识别精度判别方法

为进一步定量分析本文提出的载荷识别方法的有效性和准确性,引入Person相关系数( $R$ )和整体相对误差( $e_{RE}$ )<sup>[16]</sup>判别振动载荷的识别效果:

$$R = \frac{\text{Cov}(\tilde{F}, F)}{\sqrt{\text{Var}(\tilde{F})\text{Var}(F)}} \quad (9)$$

$$e_{RE} = \frac{\|F - \tilde{F}\|_2}{\|F\|_2} \times 100\% \quad (10)$$

相关系数 $R$ 用来衡量识别载荷序列 $\tilde{F} = [\hat{f}_1, \hat{f}_2, \dots, \hat{f}_n]$ 与真实载荷序列 $F = [f_1, f_2, \dots, f_n]$ 之间的关系, $R$ 的值越接近1,表示两组数据之间的相

关性越强;整体相对误差 $e_{RE}$ 用来衡量真实载荷与识别载荷之间的误差大小, $e_{RE}$ 数值越小表示测量的可信程度越高。

## 2.3 结构参数设定

### 1) 激活函数

神经网络模型在训练过程中会出现梯度消失和梯度爆炸问题,梯度消失会使网络模型学习停滞不前,梯度爆炸会使网络模型无法从训练数据中学习特征,且无法更新权重值,因此选择合适的激活函数对网络训练十分重要。

Sigmoid激活函数会将输入数据映射到 $[0, 1]$ 区间内,当处于未激活时状态为0,完全饱和时状态为1。Sigmoid函数的数学表达式如式(11)~(12)所示,在神经网络计算过程中沿梯度下降的反向传播算法需要对激活函数求导,Sigmoid函数可以用自身表示求导结果,有利于较少计算量的模型。但Sigmoid函数容易陷入饱和,当梯度趋近于0时,反向传播的梯度也趋近于0,会影响网络模型权重的更新;且如果输入值都为正,那么求得的局部梯度值也为正,当模型进行反向梯度传播时,只会向同方向更新,产生捆绑效果,使模型收敛速度变慢,影响训练。

$$f(x) = \frac{1}{1 + e^{-x}} \quad (11)$$

$$f'(x) = \frac{e^{-x}}{(1 + e^{-x})^2} = f(x)[1 - f(x)] \quad (12)$$

Tanh激活函数会将输入数据映射到 $[-1, 1]$ 区间内,如式(13)~式(14)所示,解决了Sigmoid函数输出不以0为中心的问题,但是当输入值较大或较小时,输出平滑且梯度较小,不利于权重的更新;且随着网络层数增多,反向梯度传播过程中经过多次链式求导,使函数进入饱和区,逐层传递出现梯度消失。

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (13)$$

$$\text{Tanh}(x) = 2\text{sigmoid}(2x) - 1 \quad (14)$$

ReLU激活函数在计算梯度下降模型时的收敛速度比Sigmoid和Tanh快得多,其数学表达式如式(15)所示,使用Sigmoid函数或Tanh函数的模型需要进行大量指数计算,而ReLU函数只需要通过设定合适阈值就可以得到激活值,极大地减少了计算量;且ReLU函数在输入值为正时是线性



的,可以完整传递梯度,能够有效避免链式求导和梯度相乘引起的梯度消失和梯度爆炸,计算成本低,收敛速度快。

$$f(x) = \max(0, x) \quad (15)$$

故本文基于 LSTM-CNN 的载荷识别模型选取 ReLU 函数作为激活函数。

## 2) 特征模块

基于 LSTM-CNN 模型的载荷识别方法核心为 CNN 层的特征提取部分,其中卷积层与输入数据进行卷积运算从而提取特征,通过设置不同维度的 filter 来提取数据不同的局部特征,形成空间特征表示。LSTM-CNN 模型采用尺寸  $1 \times 1$  的卷积核对一维时序序列进行卷积运算,设置包含两种不同维度 filter 的四层一维卷积对数据进行多次卷积工作,对试验数据深层次多角度特征提取以提高识别准确率。

对于大量的样本数据,在卷积层后增加池化层对其进行二次特征提取处理,改变卷积层和池化层参数并重复此过程,从而减少数据长度和计算量,提高网络计算效率,并对数据进行标准化处理,最终得到模型预测输出。参数设置如表 1 所示。

表 1 特征模块参数设置

Table 1 Parameter settings for feature module

参数	设置
2组 Conv1D	2组 filters=32、kernel_size=1
Pool	MaxPooling1D
2组 Conv1D	2组 filters=64、kernel_size=1
Pool	GlobalMaxPool1D
FC	$n=64$

## 3) 数据集

对于神经网络来说,关键在于其对样本的学习能力,通过对训练样本的学习,尽可能地把所有潜在样本的普遍规律。然而,若模型对训练样本的学习过于深入,可能导致将训练样本的特征误认为所有潜在样本的通用特征,即发生过拟合的问题;如果学习不充分,则会影响识别效果。因此通常将已有的数据集划分为训练集和测试集两部分,其中训练集用来训练模型,测试集用来评估模型对于新样本的判别能力。在网络模型中,将测试集的响应数据作为输入,通过该网络模型识别载荷,即网络输出。

研究不同比例的训练集对 LSTM-CNN 方法识别结果的影响,如表 2 所示,可以看出:当划分前 70% 的数据作为训练集时,整体相对误差相较于其他方案最小,在保证较高识别精度的前提下节约训练成本。

表 2 不同比例训练集识别结果

Table 2 Identification results of different proportional training

训练集/%	激振频率/Hz	整体相对误差/%	相关系数	训练时长/s
50	6.4	8.89	0.988 6	220
	35.8	4.56	0.998 4	550
	48.5	2.59	0.999 6	606
60	6.4	5.66	0.998 7	466
	35.8	4.73	0.998 9	575
	48.5	1.59	0.999 8	724
70	6.4	0.52	0.999 9	486
	35.8	1.22	0.999 8	615
	48.5	1.03	0.999 9	763
80	6.4	3.55	0.998 2	762
	35.8	2.95	0.999 2	660
	48.5	2.59	0.999 7	761
90	6.4	3.23	0.999 3	1 114
	35.8	2.11	0.999 7	673
	48.5	2.49	0.999 7	881

## 3 L 曲线准则

TSVD 方法实现良好识别效果的前提是正则化参数的准确选取,正则化解如式(16)所示,截断系数  $k$  作为正则化参数,如果取值过大会使过多的奇异值被截断导致准确性降低;如果取值过小则无法有效抑制噪声信号导致的扰动。

$$\tilde{f} = H_k^+ (\mathbf{y} + \mathbf{y}_{\text{noise}}) = \sum_{i=1}^k \frac{\mathbf{u}_i^T \mathbf{y}}{\sigma_i} \mathbf{v}_i + \sum_{i=1}^k \frac{\mathbf{u}_i^T \mathbf{y}_{\text{noise}}}{\sigma_i} \mathbf{v}_i \quad (16)$$

L 曲线准则是工程中被广泛证明有效的正则化参数选取方法<sup>[17]</sup>,其基本思想是在解范数  $\|\tilde{f}\|_2$  和误差范数  $\|\mathbf{y} - H\tilde{f}\|_2$  之间取平衡,使正则化解能够同时兼顾准确性和稳定性。以解范数和误差范数为坐标轴,以正则化参数为自变量绘制对数曲线,如图 4 所示。隅角位置则为所对应的最优正则化参数  $k^*$  的取值,满足条件:

$$L(k^*) = \min_{k > 0} L(k) \quad (17)$$




图 4 L 曲线示意图

Fig. 4 Drawing of L-curve

## 4 试验研究

### 4.1 数据获取

GARTEUR 飞机模型由 6 根矩形截面铝制梁组成,如图 5 所示。




图 5 GARTEUR 飞机模型设计图

Fig. 5 GARTEUR model design drawing

整个机身长为 1.5 m,翼展为 2.0 m,材料选用 2024-T3 铝合金,各部件采用螺接的方式进行连接,机身和机翼采用转接板连接<sup>[18]</sup>,该模型具有真实飞机的高柔度、低模态频率且密集的特点。

将加速度传感器放置在飞机前部,模拟驾驶舱的位置,以采集结构的振动响应数据,如图 6 所示。同时,在机翼根部施加激励器激励,以模拟飞行中可能受到的飞行载荷。在激振力的作用下,测试系统通过传感器采集时域响应信号,为了进行数据分析和建模,再将传感器采集到的载荷数据和响应数据划分为训练集和测试集用于网络训练和识别。




图 6 激励、响应位置示意图

Fig. 6 Excitation and response positions drawing

固有频率是结构的固有特性,通常通过模态测试获得,通过快速傅里叶变换将时域信号转换为频域信号,即可得到系统的频率响应函数,如图 7 所示。




图 7 频响函数幅值曲线

Fig. 7 Frequency response function amplitude curve

最终使用测得的频率响应函数来估计模态参数,采用峰值拾取法选择多个可能的固有频率点,并通过模态置信准则(MAC)<sup>[19]</sup>评估每一阶模态的相关性和准确性。尽管连续体在理论上具有无限多个阶次的固有频率,但通常只对低阶固有频率或特定阶次的固有频率感兴趣,这是因为固有频率越低,越容易被外力激发<sup>[20]</sup>。根据频响函数幅

值曲线选取频率为 6.4、35.8、48.5 Hz 三阶固有频率作为正弦载荷的激励频率。

## 4.2 载荷识别分析

为了进行对比分析,分别选取以截断奇异值分解(TSVD)为例需要求解系统传递函数的传统载荷识别方法、基于 DCNN(深度卷积神经网络)的载荷识别方法<sup>[21]</sup>、基于 LSTM(长短期记忆神经网络)的载荷识别方法和基于 LSTM-CNN 的载荷识别方法,对 GARTEUR 飞机模型进行正弦载荷识别对比分析,在激励位置分别施加 6.4、35.8、48.5 Hz 的正弦载荷激励,识别结果如图 8 所示,载荷识别误差如表 3 所示。

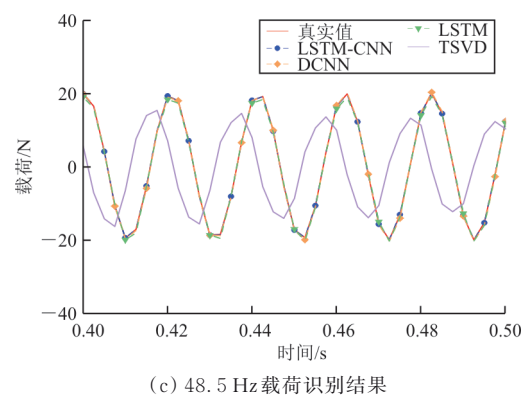
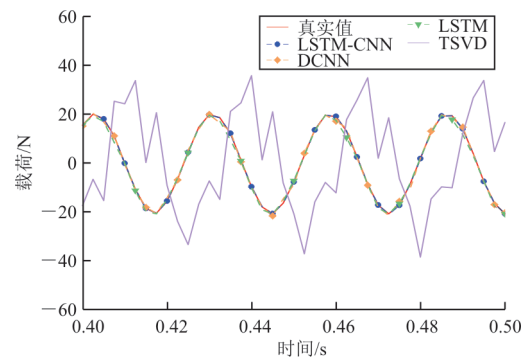



图 8 载荷识别结果对比

Fig. 8 Comparison of Load identification results

表 3 载荷识别误差

Table 3 Load identification error

激励频率/ Hz	整体相对误差/%				相关系数			
	LSTM-CNN	DCNN	LSTM	TSVD	LSTM-CNN	DCNN	LSTM	TSVD
6.4	0.52	1.24	3.85	264.81	0.999 9	0.999 9	0.999 8	0.119 8
35.8	1.22	2.89	3.29	132.48	0.999 8	0.999 1	0.998 2	0.207 9
48.5	1.03	2.13	3.88	125.30	0.999 9	0.999 8	0.999 4	0.112 8


从表 3 可以看出:三种基于神经网络的载荷识别方法的识别效果明显优于 TSVD 方法,整体相对误差均在 5% 以下,相关系数均接近 1,识别载荷与真实载荷波形基本吻合,激励与响应之间的线性关系良好,具有较高的识别精度;而 TSVD 方法的识别整体相对误差均超过 100%,识别载荷波形的幅值和相位与真实载荷波形的幅值和相位对比均出现了较大的偏移,激励与响应的线性关系不再成立,从而干扰了识别结果,识别精度差。

通过上述识别结果可以得出结论:在三种不同激励频率下,基于神经网络的载荷识别方法能够对结构固有频率激励下动载荷进行高精度的识


别,且识别精度明显高于 TSVD 方法。

然而在实际工程应用中,信号中会夹杂其他的干扰噪声信号,下面将对基于 DCNN 的载荷识别方法、基于 LSTM 的载荷识别方法和基于 LSTM-CNN 的载荷方法的抗噪性进行研究。在响应数据中分别添加 20%、50% 和 80% 的高斯白噪声,载荷识别结果如图 9~图 11 所示,载荷识别误差如表 4~表 6 所示,可以看出:三种基于神经网络载荷识别方法在一定水平的噪声情况下,仍然能够有效识别结构固有频率激励下动载荷,但是 DCNN 方法的识别精度受噪声影响较大,识别波形在 50% 和 80% 的噪声水平下均出现了较大的偏差;LSTM 与 LSTM-CNN 方法依靠长短期记忆


网络对时序数据的长时记忆功能和门控机制,可以更好地对时间序列数据建模,为网络训练保留更多的数据特征,从而保证较高的识别精度;而 LSTM-CNN 方法融合了长短期记忆网络对时序数据的建模能力和卷积网络的特征提取优势,保留关键时序特征、剔除冗余信息,载荷识别误差均小于 DCNN、LSTM 方法,波形拟合效果良好,方法抗噪性强。



(a) 6.4 Hz 载荷识别结果



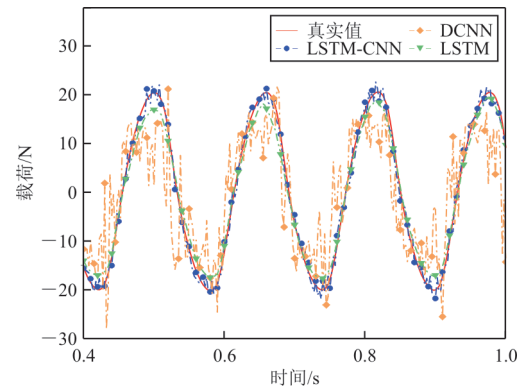
(b) 35.8 Hz 载荷识别结果




(c) 48.5 Hz 载荷识别结果

图 9 20% 噪声水平载荷识别结果


Fig. 9 20% noise level load identification results



(a) 6.4 Hz 载荷识别结果




(b) 35.8 Hz 载荷识别结果



(c) 48.5 Hz 载荷识别结果


图 10 50% 噪声水平载荷识别结果

Fig. 10 50% noise level load identification results




(a) 6.4 Hz 载荷识别结果





(b) 35.8 Hz 载荷识别结果



(c) 48.5 Hz 载荷识别结果

图 11 80% 噪声水平载荷识别结果

Fig. 11 80% noise level load identification results

表 4 20% 噪声水平载荷识别误差

Table 4 20% noise level load identification error

激振频率/Hz	整体相对误差/%			相关系数		
	LSTM-CNN	DCNN	LSTM	LSTM-CNN	DCNN	LSTM
6.4	2.68	24.82	9.81	0.999 8	0.969 1	0.998 3
35.8	2.81	9.33	10.51	0.999 8	0.988 0	0.990 8
48.5	5.22	10.16	8.66	0.989 4	0.978 8	0.996 3

表 5 50% 噪声水平载荷识别误差

Table 5 50% noise level load identification error

激振频率/Hz	整体相对误差/%			相关系数		
	LSTM-CNN	DCNN	LSTM	LSTM-CNN	DCNN	LSTM
6.4	13.68	68.90	18.41	0.980 9	0.725 2	0.978 6
35.8	14.09	24.09	18.66	0.980 1	0.969 7	0.970 1
48.5	8.91	19.84	17.29	0.996 0	0.980 2	0.976 3

表 6 80% 噪声水平载荷识别误差

Table 6 80% noise level load identification error

激振频率/Hz	整体相对误差/%			相关系数		
	LSTM-CNN	DCNN	LSTM	LSTM-CNN	DCNN	LSTM
6.4	28.65	75.23	37.64	0.952 4	0.661 3	0.927 0
35.8	22.91	36.13	27.84	0.973 5	0.932 6	0.961 7
48.5	19.84	39.05	26.36	0.980 2	0.920 8	0.971 8

通过对以上结果分析可以得出,在夹杂噪声信号的工况下,DCNN方法和LSTM方法的整体相对误差较高,相关系数呈明显下降趋势,识别载荷波形出现明显偏差,而LSTM-CNN方法通过其LSTM层的长时记忆功能和CNN层的特征提取、特征扩充特点,对数据进行时序特征提取和特征融合,剔除冗余信息,对夹杂噪声信号的时域动载荷有更好的识别效果,整体相对误差均小于DCNN方法和LSTM方法,识别载荷波形与真实载荷拟合效果更好,在噪声情况下识别效果更稳定,激励与响应间的线性关系良好,具有良好的识别精度和抗噪性。

## 5 结 论

1) 当外载荷频率达到或接近结构固有频率时,基于求解结构传递函数,以传递函数矩阵求逆为基础的TSVD载荷识别方法识别精度很低,已经不再适用于此工况的载荷识别,而三种基于神经网络的载荷识别方法可以对结构固有频率激励下正弦载荷进行有效识别,具有良好的识别效果和精度。

2) 相比于DCNN方法和LSTM方法,基于LSTM-CNN的载荷识别方法具有特征提取、特征扩充和对时序数据长时记忆的融合结构优势,可以在噪声情况下保证稳定的识别效果,具有良好的抗噪性和识别精度。

## 参 考 文 献

- [1] 杨智春,贾有. 动载荷的识别方法[J]. 力学进展, 2015, 45(1): 29-54.  
YANG Zhichun, JIA You. The identification of dynamic loads[J]. Advances in Mechanics, 2015, 45(1): 29-54. (in Chinese)
- [2] 郭荣,房怀庆,裘剡,等. 基于Tikhonov正则化及奇异值分解的载荷识别方法[J]. 振动与冲击, 2014, 33(6): 53-58.

- GUO Rong, FANG Huaiqing, QIU Shan, et al. Novel load identification method based on the combination of Tikhonov regularization and singular value decomposition [J]. *Journal of Vibration and Shock*, 2014, 33(6): 53-58. (in Chinese)
- [3] 周凤. 基于不同正则化的结构动载荷识别技术研究[D]. 成都: 西南交通大学, 2019.  
ZHOU Feng. Research on structural dynamic load identification technology based on different regularization[D]. Chengdu: Southwest Jiaotong University, 2019. (in Chinese)
- [4] LIU R X, DOBRIBAN E, HOU Z C, et al. Dynamic load identification for mechanical systems: A review [J]. *Archives of Computational Methods in Engineering*, 2022, 29(2): 831-863.
- [5] 罗志玉, 程伟, 孙利民, 等. 神经网络在载荷识别中的应用 [C]// 第八届全国振动理论及应用学术会议. 上海: 同济大学, 2003: 100.  
LUO Zhiyu, CHENG Wei, SUN Limin. Application of neural network in load identification [C]// The 8th National Symposium on Vibration Theory and Application. Shanghai: Tongji University, 2003: 100. (in Chinese)
- [6] CAO X, SUGIYAMA Y, MITSUI Y. Application of artificial neural networks to load identification [J]. *Computers & Structures*, 1998, 69(1): 63-78.
- [7] 陈奇, 安彦. 基于神经网络的机翼载荷识别 [J]. *中国高新技术*, 2020(24): 54-55.  
CHEN Qi, AN Yan. Wing load identification based on neural network [J]. *China High and New Technology*, 2020(24): 54-55. (in Chinese)
- [8] 窦春红, 林近山, 寇兴磊. 基于BP神经网络的海洋平台振动载荷识别 [J]. *石油矿场机械*, 2007, 36(7): 11-15.  
DOU Chunhong, LIN Jinshan, KOU Xinglei. Vibration load identification of offshore platform based on BP neural network [J]. *Oil Field Equipment*, 2007, 36(7): 11-15. (in Chinese)
- [9] 黄秉钧, 彭涛, 寇雨丰, 等. 基于卷积神经网络的波浪砰击载荷识别方法 [J]. *船舶工程*, 2023, 45(5): 42-48.  
HUANG Bingjun, PENG Tao, KOU Yufeng, et al. A wave slamming load identification method based on convolution neural network [J]. *Ship Engineering*, 2023, 45(5): 42-48. (in Chinese)
- [10] 杨特, 杨智春, 梁舒雅, 等. 平稳随机载荷的信号特征提取与深度神经网络识别 [J]. *航空学报*, 2022, 43(9): 225952.  
YANG Te, YANG Zhichun, LIANG Shuya, et al. Feature extraction and identification of stationary random dynamic load using deep neural network [J]. *Acta Aeronautica et Astronautica Sinica*, 2022, 43(9): 225952. (in Chinese)
- [11] SHAO B L, HU X L, BIAN G Q, et al. A multichannel LSTM-CNN method for fault diagnosis of chemical process [J]. *Mathematical Problems in Engineering*, 2019, 2019(1): 1-14.
- [12] WAN A P, CHANG Q, AL-BUKHAITI K, et al. Short-term power load forecasting for combined heat and power using CNN-LSTM enhanced by attention mechanism [J]. *Energy*, 2023, 282: 128274.
- [13] 夏鹏, 杨特, 徐江, 等. 利用时延神经网络的动载荷倒序识别 [J]. *航空学报*, 2021, 42(7): 224452.  
XIA Peng, YANG Te, XU Jiang, et al. Reversed time sequence dynamic load identification method using time delay neural network [J]. *Acta Aeronautica et Astronautica Sinica*, 2021, 42(7): 224452. (in Chinese)
- [14] 何文博, 许步锋, 冯振宇, 等. 利用冗余扩展余弦字典的复杂动载荷识别研究 [J]. *振动工程学报*, 2024, 37(3): 512-521.  
HE Wenbo, XU Bufeng, FENG Zhenyu, et al. Identification of complex dynamic load using redundant extended cosine transform dictionary [J]. *Journal of Vibration Engineering*, 2024, 37(3): 512-521. (in Chinese)
- [15] 李志鹏. 基于LSTM-CNN的飞机空调系统故障分析研究 [D]. 南京: 南京航空航天大学, 2021.  
LI Zhipeng. Fault analysis of aircraft air conditioning system based on LSTM-CNN [D]. Nanjing: Nanjing University of Aeronautics and Astronautics, 2021. (in Chinese)
- [16] 周明昌, 闫洁, 刘敬威. 检测与计量 [M]. 北京: 化学工业出版社, 2004.  
ZHOU Mingchang, YAN Jie, LIU Jingwei. Testing and measurement [M]. Beijing: Chemical Industry Press, 2004. (in Chinese)
- [17] 张彬, 倪国强. 一种基于L曲线准则的正则化图像复原算法 [J]. *北京理工大学学报*, 2014, 34(6): 627-631, 649.  
ZHANG Bin, NI Guoqiang. Regularized image restoration algorithm based on the L-curve criterion [J]. *Transactions of Beijing Institute of Technology*, 2014, 34(6): 627-631, 649. (in Chinese)
- [18] 冯振宇, 郝晓帆, 杨青青, 等. GARTEUR飞机模型的模态试验与模型修正技术 [J]. *科学技术与工程*, 2019, 19(25): 105-111.  
FENG Zhenyu, HAO Xiaofan, YANG Qingqing, et al. Modal test and dynamic model updating for GARTEUR aircraft model [J]. *Science Technology and Engineering*, 2019, 19(25): 105-111. (in Chinese)
- [19] 邹前, 王龙林. 基于振型模态置信准则的斜拉桥支承状态评定方法 [J]. *西部交通科技*, 2020(7): 151-153, 205.  
ZOU Qian, WANG Longlin. Evaluation method of supporting state of cable-stayed bridge based on modal confidence criterion [J]. *Western China Communications Science & Technology*, 2020(7): 151-153, 205. (in Chinese)
- [20] HE J J, GUAN X F, LIU Y M. Structural response reconstruction based on empirical mode decomposition in time domain [J]. *Mechanical Systems and Signal Processing*, 2012, 28: 348-366.
- [21] HE W B, ZHANG X Q, FENG Z Y, et al. Random dynamic load identification with noise for aircraft via attention based 1D-CNN [J]. *Aerospace*, 2022, 10(1): 16.

(编辑: 马文静)