

文章编号: 1674-8190(2023)05-061-09

基于神经网络的翼盒结构响应重构方法应用

王显浩¹, 程伟¹, 杨云熙¹, 王鹏辉², 周畅²

(1. 北京航空航天大学 航空科学与工程学院, 北京 100191)

(2. 中国运载火箭技术研究院 北京强度环境研究所, 北京 100076)

摘要: 翼盒结构复杂, 航行中承载条件恶劣, 利用有限测点信息重构其他位置响应对于实时健康监测具有现实意义。通过误差反向传播神经网络训练得到响应之间的非线性关系, 建立基于神经网络的响应重构方法, 开展有限元分析对其进行数值仿真验证, 并将该方法应用于实测随机激励环境下翼盒典型承力结构的响应重构及损伤定位与判断分析。结果表明: 采用该方法预测响应功率谱密度的均方根相对误差不超过 1.90 dB, 主要频点误差小于 10%; 判断出翼盒关键测点 e 的损伤或故障发生在所截取片段数据 3 s 后, 其故障特征频率为 240 Hz 左右, 该方法应用于响应重构预测及健康监测分析具有可行性。

关键词: 神经网络; 翼盒; 随机振动; 响应重构; 健康监测

中图分类号: V214.1

文献标识码: A

DOI: 10.16615/j.cnki.1674-8190.2023.05.08

Application of response reconstruction method of wing box structure based on neural network

WANG Xianhao¹, CHENG Wei¹, YANG Yunxi¹, WANG Penghui², ZHOU Chang²

(1. School of Aeronautical Science and Engineering, Beihang University, Beijing 100191, China)

(2. Beijing Institute of Structure and Environment Engineering, China Academy of Launch Vehicle Technology, Beijing 100076, China)

Abstract: It is of great practical significance for real-time health monitoring to reconstruct other position responses by using limited measuring point information of wing box structure in complex navigation with harsh bearing conditions. The nonlinear relationship between the responses is obtained by training the back propagation neural network, and the response reconstruction method based on neural network is established and verified by numerical simulation through finite element analysis. The method is applied to the response reconstruction, damage location and judgment analysis of typical load-bearing structures of wing boxes under measured random excitation environment. The results show that the root mean square relative error of the predicted response power spectral density reconstructed by this method is less than 1.90 dB and the main frequency error is less than 10%. The damage or fault of the key measuring point e of the wing box occurred 3 s after the intercepted fragment data, and its fault characteristic frequency is about 240 Hz. The method is feasible to response reconstruction prediction and health monitoring analysis.

Key words: neural network; wing box; random vibration; response reconstruction; health monitoring

收稿日期: 2022-10-14; 修回日期: 2023-03-03

通信作者: 杨云熙, buaa_yyx@buaa.edu.cn

引用格式: 王显浩, 程伟, 杨云熙, 等. 基于神经网络的翼盒结构响应重构方法应用[J]. 航空工程进展, 2023, 14(5): 61-69.

WANG Xianhao, CHENG Wei, YANG Yunxi, et al. Application of response reconstruction method of wing box structure based on neural network[J]. Advances in Aeronautical Science and Engineering, 2023, 14(5): 61-69. (in Chinese)

0 引言

航空飞行器在航行过程中会处于复杂多变的振动环境,可通过布置传感器获得结构响应数据用于进行实时健康监测。结构响应数据的获取,一方面由于测点的布置位置受限于结构局部空间分布、采集测量条件等现实因素;另一方面大型结构的服役时间远超出测量其动态响应的传感器寿命,导致部分响应数据可能会因传感器损坏而丢失。这两方面原因使得某些关键测点响应无法获取,从而无法完成结构对环境的适应性及结构性能的有效评估。此外,飞机在大多数任务剖面历程中承受的气动载荷为随机激励,每次飞行气动载荷均不相同,从而导致每次测量的响应数据不同,只能通过其统计参量进行载荷特征描述。因此,在随机激励下通过已知测点振动响应对其余未知振动响应进行重构具有重要的意义。

近年来,由于神经网络在非线性问题处理方面具有很强的优势及并行运算能力,使得其在载荷识别领域已有很大的进展^[1-4]。神经网络的非线性处理原理可简单表述为:将训练好的网络结构的输入层与输出层之间的非线性映射关系存储下来,用于后续预测^[5-8],具有准确性高、误差小的优点,在众多领域得到运用^[9-12]。现有的响应重构技术有基于模态分析或传递率思想的方法,需建立已知点和重构点之间的传递关系;基于卡尔曼滤波算法的响应重构方法。例如,A. M. R. Ribeiro等^[13]首先提出传递率的概念,并用于单自由度系统及多自由度系统的位移响应重构;Zhang X H等^[14]基于传递率思想研究了梁模型双重传感器下的结构应变、位移响应重构;朱昱达等^[15]提出基于响应传递比的航空发动机转子叶片动应变重构方法,即在频域获得应变—应变响应传递比关于模态振型的解析表达式,建立叶片已知测点应变与不可测应变的映射关系;Xu Y L等^[16]使用卡尔曼滤波算法对二维桁架的应变和位移响应进行重构。基于模态分析或传递率的方法需要结构精确的有限元模型才能推导出响应间的解析表达式,而基于卡尔曼滤波算法则为一种不确定性的方法。随着神经网络的发展,研究者开始将神经网络引入响应重构中,并取得了较好的效果。朱长春等^[17-18]利用神经网络对难以直接测量的直升机自动倾斜器的竖向振动响应进行了间接识别,表

明神经网络应用于航空大型结构的振动环境试验的响应预测方法的有效性和可行性;Ding Guoping等^[19]针对航空复合材料层压板结构中可变层压板的不连续刚度和强度,提出将神经网络应用于复合材料层压板的变形重构方法中。

本文在前人研究的基础上,建立基于神经网络的响应重构方法,该方法主要利用已训练好的神经网络模型,通过向其输入已知响应重构得到未知响应。首先介绍相关理论基础,随后建立响应重构方法并对其开展数值仿真验证;将该方法用于随机振动环境下飞机翼盒典型承力结构的振动加速度响应重构,开展误差分析;在此基础上,对翼盒易损部位测点对比分析其重构响应和实测响应,定位损伤或故障发生时刻及判断其类型。

1 随机振动基础

结构动力学理论中,对于线性系统,其传递特性函数即指系统受到激励产生响应时,响应与激励之间的只与系统本身特征参数和激励类型有关的函数^[7]。对于多自由度系统,设有限自由度系统的惯性矩阵为 M ,阻尼矩阵为 C ,刚度矩阵为 K ,令位移输出矢量为 $\mathbf{y}(t)=\{y_1, y_2, \dots, y_n\}^T$,力输入矢量为 $\mathbf{x}(t)=\{x_1, x_2, \dots, x_n\}^T$,则系统的运动微分方程为

$$\left(M \frac{d^2}{dt^2} + C \frac{d}{dt} + K \right) \mathbf{y} = \mathbf{x} \quad (1)$$

方程解为线性的,设 $y_j(t)=y_{j0}e^{i\omega t}$, $j=1, 2, \dots, n$, $x_k(t)=x_{k0}e^{i\omega t}$, $k=1, 2, \dots, n$,于是整理得到:

$$\mathbf{y}(\omega) = \mathbf{H}(\omega) \mathbf{x}(\omega) \quad (2)$$

而对于多自由度系统受到随机激励作用的情况,由于系统的单位脉冲函数矩阵为

$$\mathbf{h}(t) = [\mathbf{h}_{jk}(t)]_{n \times n} = \frac{1}{2\pi} \int_{-\infty}^{+\infty} \mathbf{H}(\omega) e^{i\omega t} d\omega \quad (3)$$

传递函数矩阵为

$$\mathbf{H}(\omega) = [\mathbf{H}_{jk}(\omega)]_{n \times n} = \int_0^{\infty} \mathbf{h}(t) e^{-i\omega t} dt \quad (4)$$

在时域中:

$$\mathbf{y}(t) = \int_{-\infty}^{+\infty} \mathbf{h}(\theta) \mathbf{x}(t - \theta) d\theta \quad (\theta \geq 0) \quad (5)$$

则系统响应自相关函数矩阵为

$$\mathbf{R}_{yy}(\tau) = [\mathbf{R}_{y_j y_k}(\tau)] = E[\mathbf{y}(t) \mathbf{y}^T(t + \tau)] \quad (6)$$

$$\mathbf{R}_{y_j y_k}(\tau) = E[y_j(t) y_k(t + \tau)] \quad (7)$$

式中: $j, k = 1, 2, \dots, n$ 。

由式(3)和式(7)得到:

$$R_{yy}(\tau) = E \left\{ \left[\int_{-\infty}^{+\infty} \mathbf{h}(\theta_1) \mathbf{x}(t - \theta_1) d\theta_1 \right] \cdot \left[\int_{-\infty}^{+\infty} \mathbf{h}(\theta_2) \mathbf{x}^T(t + \tau - \theta_2) d\theta_2 \right] \right\} = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} \mathbf{h}(\theta_1) \mathbf{R}_{xx}(\tau + \theta_1 - \theta_2) \mathbf{h}^T(\theta_2) d\theta_1 d\theta_2 \quad (8)$$

式中: $\mathbf{R}_{xx}(\tau) = E[\mathbf{x}(t)\mathbf{x}^T(t + \tau)]$ 为输入相关函数矩阵。根据维纳-辛钦公式, $\mathbf{y}(t)$ 的功率谱密度函数矩阵可表示为

$$S_{yy}(\omega) = \left[\int_{-\infty}^{+\infty} \mathbf{h}(\theta_1) e^{i\omega\theta_1} d\theta_1 \right] \cdot \left[\frac{1}{2\pi} \int_{-\infty}^{+\infty} \mathbf{R}_{xx}(\tau + \theta_1 - \theta_2) \cdot e^{-i\omega(\tau + \theta_1 - \theta_2)} d\tau \right] \cdot \left[\int_{-\infty}^{+\infty} \mathbf{h}^T(\theta_2) e^{-i\omega\theta_2} d\theta_2 \right] \quad (9)$$

整理公式(9), 得到随机激励与响应之间的关系:

$$S_{yy}(\omega) = H(\omega) S_{xx}(\omega) H^H(\omega) \quad (10)$$

式中: $S_{yy}(\omega)$ 为各被测点响应之间的互功率谱密度矩阵, $S_{yy}(\omega) = \mathbf{Y}\mathbf{Y}^T$, \mathbf{Y} 为响应傅里叶变换后的每个频点值的矩阵; $S_{xx}(\omega)$ 为各随机激励之间的互

功率谱密度矩阵。对于每个已知点响应 r 与未知点响应 p , 其中 $r = 1, 2, \dots, n, p \neq r$, 关系如式(11)~式(12)所示。

$$Y_r Y_r^T = H_r(\omega) S_{xx}(\omega) H_r^H(\omega) \quad (11)$$

$$Y_p Y_p^T = H_p(\omega) S_{xx}(\omega) H_p^H(\omega) \quad (12)$$

响应与响应之间存在以下非线性关系:

$$Y_p = f(Y_r, H_r, H_r^H, H_p, H_p^H) \quad (13)$$

实际情况下, 对于简单系统可根据上述公式直接求解出响应之间的非线性关系, 但对于飞机翼盒等大型复杂结构而言, 求解过程相对困难。考虑到神经网络对非线性问题具有较强的处理能力, 因此使用神经网络进行翼盒响应之间非线性关系的模拟, 完成利用已知点对未知点的响应重构。

2 响应重构方法

2.1 神经网络模型

神经网络的基本结构如图1所示, 其结构分为输入层, 隐含层(中间层)以及输出层, 输入层的神经元乘以相应的权重 w 后加上对应的阈值 a , 然后结合相应的激活函数, 得到隐含层的输入; 隐含层的输入乘以相应的权重 v 并加上对应的阈值 b 后, 然后结合相应的激活函数, 得到最终的输出值。

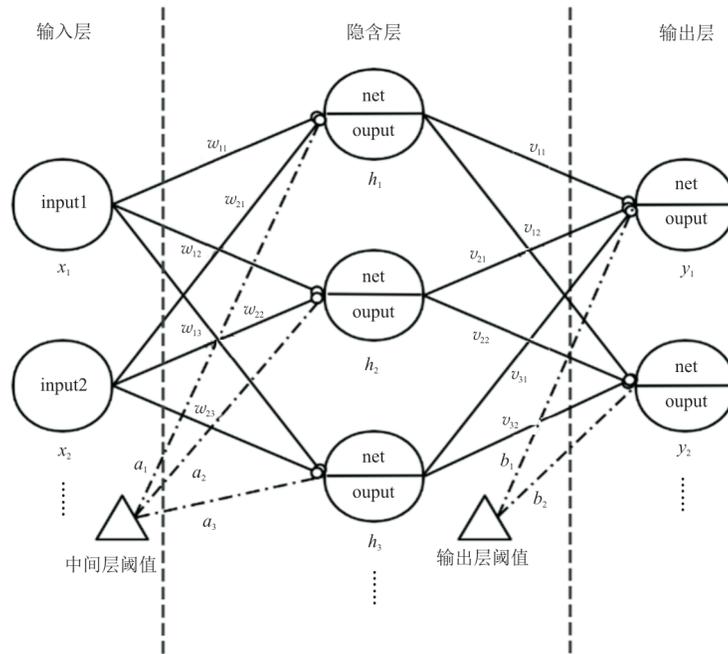


图1 三层神经网络示意图

Fig. 1 Schematic diagram of three-layer neural network

本文使用误差反向传播(Back Propagation,简称BP)神经网络^[11]进行未知测点的加速度响应预测,激活函数选用 Logistic 函数 $f(x) = \frac{1}{1 + e^{-x}}$,其学习的过程为:通过信号的正向传播和误差的反向传播,对各连接权值以及所有功能神经元的阈值进行动态调整,使得网络预测值与实测值之间的总误差变小。其中权值的调整规则采用梯度下降法策略,其网络的学习流程如图 2 所示。

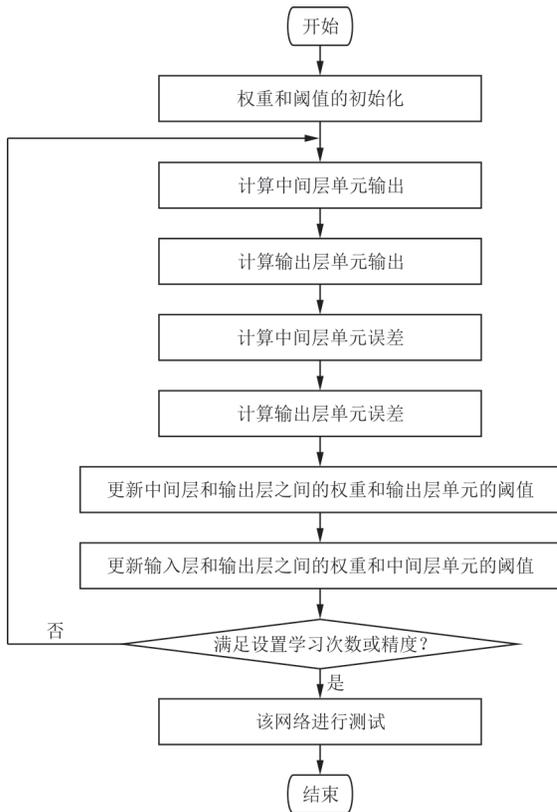


图 2 神经网络学习流程图

Fig. 2 Neural network learning flowchart

对于给定的训练集 (x_k, y_k) ,设用神经网络训练得到的输出为 $\hat{y}_k = (\hat{y}_1, \hat{y}_2, \dots, \hat{y}_l)$,即有:

$$\hat{y}_k = f\left(\sum_{i=1}^l \omega_{ip} x_i - \beta_p\right) \quad (14)$$

神经网络在 (x_k, y_k) 上的均方误差为

$$E_k = \frac{1}{2} \sum_{j=1}^l (\hat{y}_j^k - y_j^k)^2 \quad (15)$$

基于梯度下降法可以推导得到相应的权值以及阈值调整公式,如式(16)~式(19)所示。

$$\begin{aligned} \omega_{rp}^{\text{new}} &= \omega_{rp}^{\text{old}} - \eta \frac{\partial E_k}{\partial \omega_{rp}} = \omega_{rp}^{\text{old}} - \eta \hat{y}_{p(\text{net})}^k (1 - \hat{y}_{p(\text{net})}^k) \cdot \\ &\quad (y_p^k - \hat{y}_{p(\text{out})}^k) h_{r(\text{out})} \end{aligned} \quad (16)$$

$$\begin{aligned} v_{ir}^{\text{new}} &= v_{ir}^{\text{old}} - \eta \frac{\partial E_k}{\partial v_{ir}} = v_{ir}^{\text{old}} - \eta h_{r(\text{net})} (1 - h_{r(\text{net})}) x_i \cdot \\ &\quad \sum_{j=1}^n \hat{y}_{j(\text{net})}^k (1 - \hat{y}_{j(\text{net})}^k) (y_j^k - \hat{y}_{j(\text{out})}^k) \omega_{jp} \end{aligned} \quad (17)$$

$$\beta_p^{\text{new}} = \beta_p^{\text{old}} - \eta \hat{y}_{p(\text{net})}^k (1 - \hat{y}_{p(\text{net})}^k) (y_p^k - \hat{y}_{p(\text{out})}^k) \quad (18)$$

$$\begin{aligned} \alpha_r^{\text{new}} &= \alpha_r^{\text{old}} - \eta h_{r(\text{net})} (1 - h_{r(\text{net})}) \sum_{j=1}^n \hat{y}_{j(\text{net})}^k \cdot \\ &\quad (1 - \hat{y}_{j(\text{net})}^k) (y_j^k - \hat{y}_{j(\text{out})}^k) \omega_{jp} \end{aligned} \quad (19)$$

式中: ω_{jp} 为输入层与隐含层的权重; v_{ir} 为隐含层与输出层之间的权重; α_r 为隐含层的阈值; β_p 为输出层的阈值; η 为学习率; $h_{r(\text{out})}$ 和 $h_{r(\text{net})}$ 分别为隐含层的输出和输入; $\hat{y}_{j(\text{out})}^k$, $\hat{y}_{j(\text{net})}^k$ 分别为输出层的输出和输入。

2.2 响应重构设计

响应重构时,首先需要获取被测对象的响应数据,对样本数据进行处理,分为训练集、验证集及测试集;然后利用神经网络进行训练,并对训练好的网络合理性进行验证;最后对未知点进行响应重构。其响应重构方法如图 3 所示。

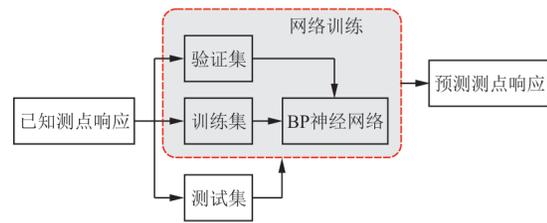


图 3 响应重构方法示意图

Fig. 3 Schematic diagram of response reconstruction method

2.3 响应重构方法验证

对简单的悬臂梁结构使用 Workbench 平台进行随机振动分析,为方便后续验证分析,选取分别距离固支端 1/4 长的 20 号节点,1/2 长的 360 号节点及端部的 240 节点的响应加速度功率谱密度,其具体位置如图 4 所示。为获取足够多的时域数据,利用 Monte-Carlo 技术^[16]进行 20 次时域模拟,得到其时域数据,并将其按照 6:2:2 的比例分为训练集、验证集及测试集,将 20 号节点与 360 号节点响应作为输入层,240 号节点响应作为输出层,然后对提出的响应重构方法进行验证,最终得到其预测值,如图 5 所示,可以看出:主要特征频点与实测

值对应,且其功率谱密度的趋势也能较好重合,验证了利用神经网络进行响应重构的可行性。

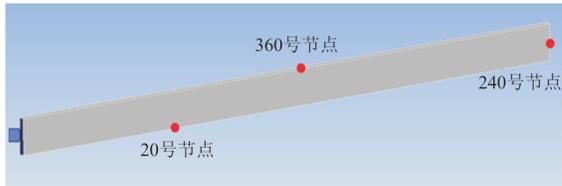


图 4 悬臂梁响应测点

Fig. 4 Response point of cantilever beam

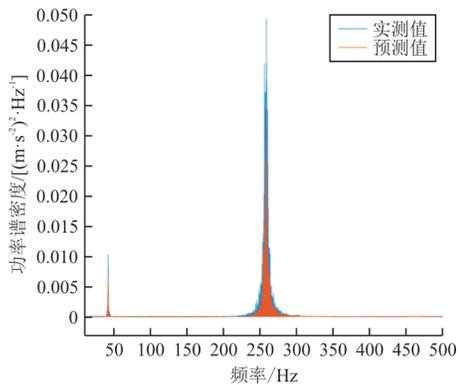


图 5 悬臂梁 240 号节点响应预测结果

Fig. 5 Response prediction results of 240 node of the cantilever beam

3 工程实践应用

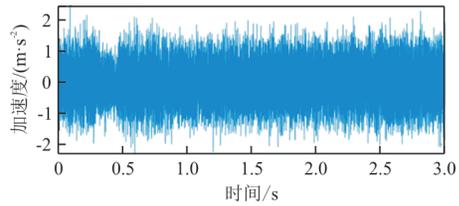
3.1 振动响应测试

在翼盒典型承力结构上布置 6 个测点获取其飞行过程中的振动加速度数据,翼盒的各位置垂向振动加速度的测点编号及响应类型如表 1 所示。为直观描述其各测点的垂向振动加速度及测点部位结构特性,选取了翼盒测点 *b* 和 *f* 的局部 3 s 加速度数据,绘制其加速度时域以及对应的功率谱密度图,如图 6~图 7 所示,各测点在翼盒上位置如图 8 所示。

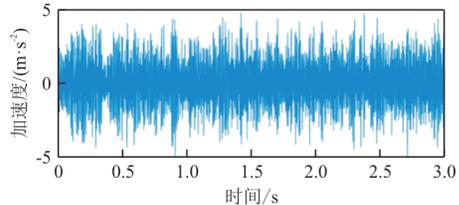
表 1 加速度数据参数说明

Table 1 Parameter description of acceleration data

测点编号	响应类型
翼盒测点 <i>a</i>	翼盒加强肋 1 垂向振动加速度
翼盒测点 <i>b</i>	翼盒前梁垂向振动加速度
翼盒测点 <i>c</i>	翼盒普通肋 2 垂向振动加速度
翼盒测点 <i>d</i>	翼盒长桁 1 垂向振动加速度
翼盒测点 <i>e</i>	翼盒后梁垂向振动加速度
翼盒测点 <i>f</i>	翼盒长桁 2 垂向振动加速度



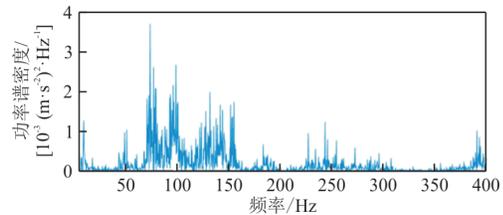
(a) 测点 *b*



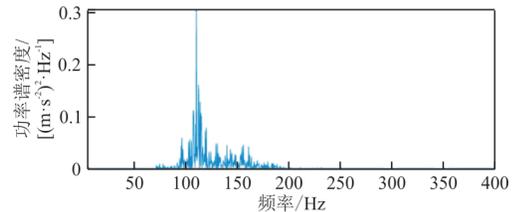
(b) 测点 *f*

图 6 测点 *b* 和 *f* 的加速度时域曲线

Fig. 6 Time domain curves of acceleration at measuring points *b* and *f*



(a) 测点 *b*



(b) 测点 *f*

图 7 测点 *b* 和 *f* 的加速度功率谱密度曲线

Fig. 7 Acceleration power spectral density curves of measurement points *b* and *f*

从图 6~图 7 可以看出:飞行过程中测点响应属于随机振动,频带较宽,功率谱密度在主要频点附近有明显的幅值放大现象。

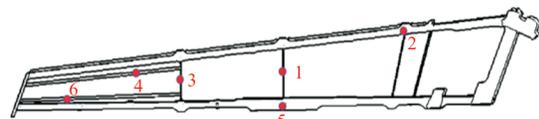


图 8 翼盒各测点位置示意图

Fig. 8 Schematic diagram of each measuring point position of wing box

3.2 响应重构与分析

利用神经网络完成对翼盒典型承力结构响应

的重构,将表 1 中的翼盒测点 a, c, d, f 的垂向振动加速度响应作为网络的输入层(即已知测点响应),将翼盒测点 b 和 e 的垂向振动加速度响应作为网络的输出层(即未知测点响应)。

首先在 Visual Studio 环境中使用 C++ 语言对神经网络进行结构搭建,本文搭建 3 层 BP 神经网络。神经网络结构的输入层用 4 个神经元以模拟已知点,输出层用 2 个神经元模拟重构点,隐含层神经元数量可根据学习情况进行调节。然后对所有测点响应数据在 MATLAB 中使用 $\bar{y}_i = \frac{y_i - y_{\min}}{y_{\max} - y_{\min}}$ 公式进行归一化处理^[20](由于神经网络激活函数输入区间的限制),并将归一化的数据前 75% 作为训练集、后 25% 作为测试集,将训练集输入神经网络,开展神经网络的训练。为了保证所训练的网络具有很好的泛化能力,不宜使其训练误差过于太小,通过对网络学习率和隐含层节点数不断调整,得到的参数变化图如图 9 所示,最佳隐含层节点数为 6,最优学习率为 0.45。最后利用训练好的网络进行响应的重构,获取未知测点的响应数据,其响应重构流程如图 10 所示。

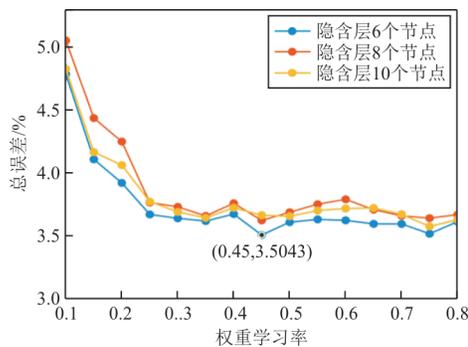


图 9 总误差随神经网络参数变化图
Fig. 9 Variation of total error with neural network parameters

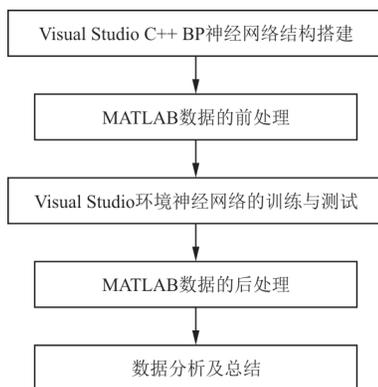


图 10 响应重构流程图
Fig. 10 Response reconfiguration flow chart

对使用神经网络重构获得的垂向振动加速度在 MATLAB 中进行反归一化处理,计算得到其加速度功率谱密度,将得到相应的预测值与实测值进行对比分析,截取的两个预测点 10~400 Hz 范围的加速度功率谱密度如图 11~图 12 所示。

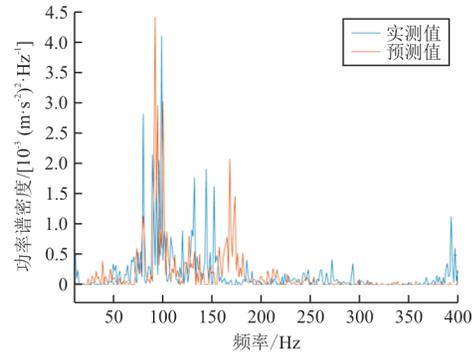


图 11 翼盒测点 b 振动加速度神经网络预测对比图
Fig. 11 Comparison of vibration acceleration prediction of wing measurement point b by neural network

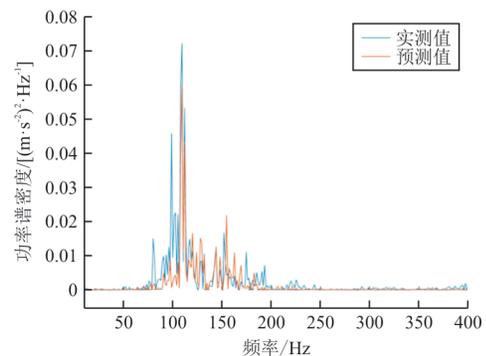


图 12 翼盒测点 e 振动加速度神经网络预测对比图
Fig. 12 Comparison of vibration acceleration prediction of wing measurement point e by neural network

功率谱密度总均方根误差结果如表 2 所示,可以看出:通过神经网络训练重构得到的数据与实际测量的数据在主要的波形上能较好地重合,重构数据的整体走势与实测数据吻合程度较高;通过神经网络训练重构的两个测点响应的功率谱密度总均方值相对误差绝对值分别为 1.902 8 dB 和 0.531 2 dB,其量化误差在可接受的范围内。

表 2 功率谱密度总均方根误差统计
Table 2 Total RMS error statistics of power spectral density

测点编号	功率谱密度总均方根误差/dB
翼盒测点 b	1.902 8
翼盒测点 e	0.531 2

在频域范围内给出两个测点的主要频率对应的峰值误差和频率误差,如表3所示,可以看出:各峰值处的误差都小于31%,主要频点处的误差均

小于10%。说明神经网络在对飞机翼盒典型承力结构加速度响应的重构方面具有较好的应用效果。

表3 主要频点误差统计
Table 3 Error statistics of main frequency points

预测点	实测主要频点/Hz	预测主要频点/Hz	频点误差/%	峰值实测值/ [(m·s ⁻²) ² ·Hz ⁻¹]	峰值预测值/ [(m·s ⁻²) ² ·Hz ⁻¹]	峰值误差/%
<i>b</i>	98.67	92.00	6.76	0.002 7	0.002 9	7.41
	152.00	167.00	9.87	0.001 1	0.001 4	27.27
<i>e</i>	109.33	109.50	0.01	0.048 0	0.039 8	17.08
	152.00	154.67	1.76	0.011 1	0.014 5	30.63

3.3 翼盒健康监测

基于神经网络的响应重构方法能够用于对翼盒的健康监测,针对关键部位监测点,利用其他部位测点数据使用神经网络对其进行实时响应重构,对比分析重构数据与实测数据,定位其损伤或故障发生时刻,进一步通过时域数据分析其损伤或故障类型,健康监测流程如图13所示。

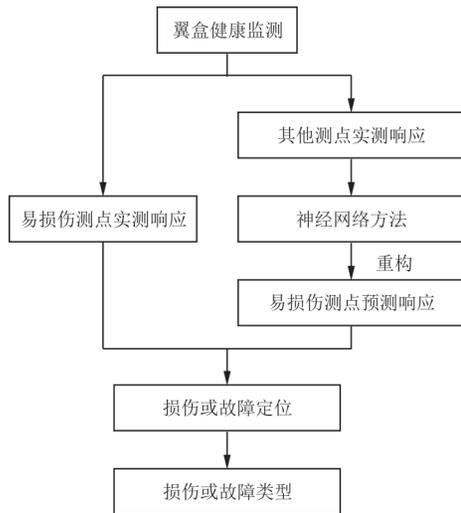


图13 基于神经网络的响应重构方法在健康监测中的应用流程图

Fig. 13 Flow chart of application of response reconstruction method based on neural network in health monitoring

在实际应用时,截取翼盒上实测6个测点的加速度响应的局部6 s数据,其中测点*b*和*e*为易损伤的关键监测部位,其响应数据如图14所示,从时域图中无法直观评判其损伤或故障是否存在。为此

将*a, c, d, f*四个测点的实测数据归一化后作为神经网络输入层参数,利用已训练好的网络模型进行预测,并将预测值进行反归一化处理,得到测点*b*和*e*的重构数据。

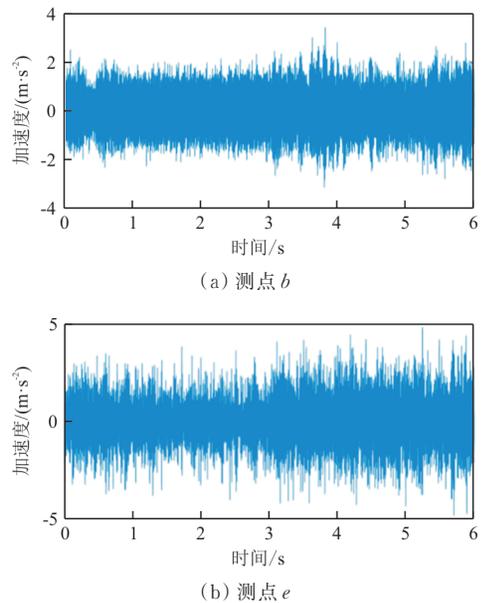


图14 翼盒测点*b*和*e*实测响应局部6 s数据
Fig. 14 The local 6 s data measured by measuring points *b* and *e* of the wing box

由于已训练好的神经网络表示的是翼盒响应之间无损伤时的非线性关系,为此可将重构得到的数据与实测数据进行对比分析,采用式(20)描述其响应相对误差指数,并可根据指数*E(k)*随时间变化情况定位其损伤或故障的大致发生时刻。

$$E_i(k) = \frac{R_i(k) - \hat{R}_i(k)}{R_i(k)} \quad (20)$$

$$R_i(k) = \text{Var}(x_{r \rightarrow r+M}) \quad (21)$$

$$\hat{R}_i(k) = \text{Var}(\hat{x}_{r \rightarrow r+M}) \quad (22)$$

式中: $R_i(k)$ 为实测响应局部方差; $\hat{R}_i(k)$ 为神经网络预测局部响应方差; 下标 i 为测点的编号; k 为第 k 时刻对应的数据; $\text{Var}(\cdot)$ 为计算对应区间的响应方差; M 为局部方差取值区间的的数据点数, 本文取 2 048; N 为总采样的点数, 其中 $r=1, 2, 3, \dots, N-M$ 。

由公式(20)得到的翼盒测点 b 和 e 的相对误差指数如图 15 所示, 可以看出: 测点 b 的相对误差指数在整个时间段内表现为持续平稳的波动, 而测点 e 在 2.96 s 附近出现明显的尖峰, 故判断在该时刻附近测点 e 部位可能出现损伤或故障。

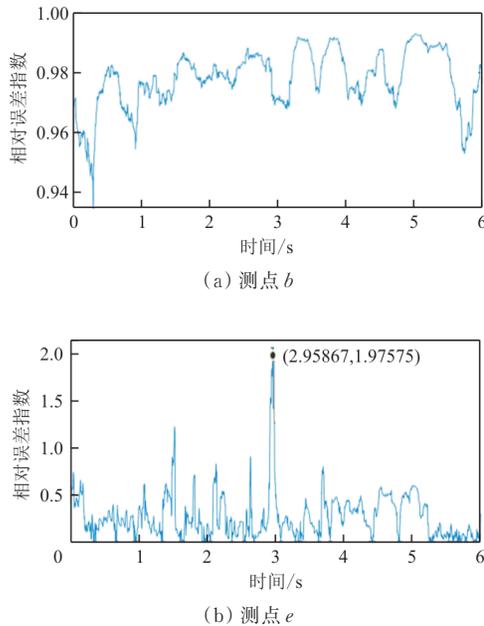


图 15 翼盒测点 b 和 e 相对误差指数
Fig. 15 Relative error index of measuring points b and e of the wing box

将测点 e 的时域数据分为前 3 s 与后 3 s, 分别求其在 10~400 Hz 的功率谱密度, 如图 16 所示, 可以看出: 在前 3 s 内, 神经网络预测值与实测值的趋势能较好地重合, 且在主要频点处能相互对应; 而在后 3 s 实测功率谱密度在 230~250 Hz 范围内出现局部峰值区间, 与用无损伤时的神经网络模型预测出的分布不同, 故判断在 3 s 时刻, 后翼盒测点 e 部位发生的损伤或故障特征频率为 240 Hz 左右。

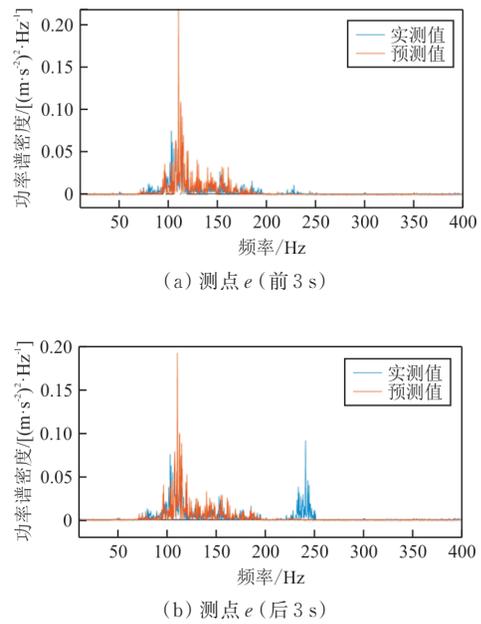


图 16 翼盒测点 e 实测与预测响应功率谱密度对比
Fig. 16 Comparison of the measured and predicted power spectral density of the measuring point e of the wing box

4 结 论

1) 预测加速度的功率谱密度与实测功率谱密度具有很好的逼近性, 且其功率谱密度的均方根误差在可接受的范围内。

2) BP 神经网络能将结构的振动响应之间的非线性映射关系很好地表现出来, 且具有方法简单、精度较高、分析频带较宽和不需要动力学模型的优点, 这对飞机其他结构响应的数据重构具有重要参考意义。

3) 基于 BP 神经网络建立的响应重构方法可用于翼盒结构的健康监测, 通过对比神经网络预测值及实测值的误差能够定位损伤或故障发生时刻, 并据此判断其损伤或故障的类型。

参 考 文 献

- [1] COOPER S B, DARIO D. Static load estimation using artificial neural network: application on a wing rib[J]. *Advances in Engineering Software*, 2018, 125: 113-125.
- [2] ZHOU J M, DONG L L, GUAN W, et al. Impact load identification of nonlinear structures using deep recurrent neural network[J]. *Mechanical Systems and Signal Processing*, 2019, 133: 106292.
- [3] WANG Cheng, CHEN Dalei, CHEN Jianwei, et al. Deep regression adaptation networks with model-based transfer learning for dynamic load identification in the frequency domain[J]. *Engineering Application of Artificial Intelligence*,

- 2021, 102: 104244.
- [4] YANG Hongji, JIANG Jinhui, CHEN Guoping, et al. A recurrent neural network-based method for dynamic load identification of beam structures [J]. *Materials*, 2021, 14: 7846.
- [5] ZENG P. Artificial neural networks principle for finite element method [J]. *Zeitschrift fur Angewandte Mathematik und Mechanik*, 1996, 76(s5): 565-566.
- [6] 王磊. 人工神经网络原理、分类及应用 [J]. *科技资讯*, 2014(3): 240-241.
- WANG Lei. Principle, classification and application of artificial neural networks [J]. *Science and Technology Information*, 2014(3): 240-241. (in Chinese)
- [7] 杨智春, 贾有. 动载荷的识别方法 [J]. *力学进展*, 2015, 45(2): 30-54.
- YANG Zhichun, JIA You. Dynamic load identification method [J]. *Advances in Mechanics*, 2015, 45(2): 30-54. (in Chinese)
- [8] 何坚强. 基于人工神经网络模型优化的研究及应用 [J], *电子质量*, 2020(2): 32-35.
- HE Jianqiang. Research and application of model optimization based on artificial neural network [J]. *Electronic Mass*, 2020(2): 32-35. (in Chinese)
- [9] 张驰, 郭园, 黎明. 人工神经网络模型发展及应用综述 [J]. *计算机工程与运用*, 2021, 57(11): 57-69.
- ZHANG Chi, GUO Yuan, LI Ming. Review of development and application of artificial neural network models [J]. *Computer Engineering and Applications*, 2021, 57(11): 57-69. (in Chinese)
- [10] KUMARAVEL A, MUTHU K, DEENADAYALAN N. A view of artificial neural network models in different application areas [C] // 2021 E3S Web of Conferences. [S.l.: s.n.], 2021: 1-8.
- [11] 夏正洪, 贾鑫磊. 离港航空器滑出时间的BP神经网络预测模型 [J]. *航空工程进展*, 2022, 13(2): 99-106.
- XIA Zhenghong, JIA Xinlei. BP neural network prediction model of departure aircraft skid-out time [J]. *Advances in Aeronautical Science and Engineering*, 2022, 13(2): 99-106. (in Chinese)
- [12] 彭玉酌, 唐朕, 肖启之. 飞行载荷神经网络代理模型研究 [J]. *航空工程进展*, 2023, 14(1): 90-97.
- PENG Yuzhuo, TANG Zhen, XIAO Qizhi. Research on neural network proxy model of flight load [J]. *Advances in Aeronautical Science and Engineering*, 2023, 14(1): 90-97. (in Chinese)
- [13] RIBEIRO A M R, SILVA J M M, MAIA N M M. On the generalization of the transmissibility concept [J]. *Mechanical Systems and Signal Processing*, 2000, 14(1): 28-35.
- [14] ZHANG X H, XU Y L, ZHU S Y, et al. Dual-type sensor placement for multi-scale response reconstruction [J]. *Mechatronics*, 2014, 24(4): 376-384.
- [15] 朱昱达, 乔百杰, 符顺国, 等. 基于响应传递比的转子叶片动应变重构 [J]. *航空动力学报*, 2021, 36(8): 1690-1701.
- ZHU Yuda, QIAO Baijie, FU Shunguo, et al. Dynamic strain reconstruction of rotor blades based on response transfer ratio [J]. *Journal of Aerodynamics*, 2021, 36(8): 1690-1701. (in Chinese)
- [16] XU Y L, ZHANG X H, ZHU S Y, et al. Multi-type sensor placement and response reconstruction for structural health monitoring of long-span suspension bridges [J]. *Science Bulletin*, 2016, 61(4): 313-329.
- [17] 朱长春, 张景绘, 赵江楠, 等. 直升机自动倾斜器竖向振动的神经网络识别 [J]. *机械强度*, 2001(1): 72-76.
- ZHU Changchun, ZHANG Jinghui, ZHAO Jiangnan, et al. Identification of vertical vibration of helicopter automatic tilter by neural network [J]. *Mechanical Strength*, 2001(1): 72-76. (in Chinese)
- [18] 朱长春. 振动环境试验响应的神经网络预测方法 [J]. *振动与冲击*, 2007, 26(4): 42-45.
- ZHU Changchun. Neural network prediction method for vibration environment test response [J]. *Journal of Vibration and Shock*, 2007, 26(4): 42-45. (in Chinese)
- [19] DING Guoping, JIANG Siyuan. Strain-deformation reconstruction of carbon fiber composite laminates based on BP neural network [J]. *Materials Research*, 2019, 22(5): 393.
- [20] 柳小桐. BP神经网络输入层数据归一化研究 [J]. *机械工程与自动化*, 2010(3): 122-123.
- LIU Xiaotong. Research on data normalization of BP neural network input layer [J]. *Mechanical Engineering and Automation*, 2010(3): 122-123. (in Chinese)

作者简介:

王显浩(1998—),男,硕士研究生。主要研究方向:结构动力学。

程伟(1961—),男,博士,教授。主要研究方向:结构动力学,微振动测试平台研制,航天器微振动测试与分析等。

杨云熙(1994—),男,博士研究生。主要研究方向:结构动力学,载荷识别。

王鹏辉(1982—),男,硕士,研究员。主要研究方向:结构动力学。

周畅(1995—),男,硕士,工程师。主要研究方向:结构动力学。

(编辑:丛艳娟)