

DOI: 10.7511/jslx20240627001

基于 RIDLA 的卫星承重结构螺栓连接 非线性滞回建模

顾乃建¹, 刘坤¹, 武文华^{*1,2}, 郭杏林¹

(1. 大连理工大学 工业装备结构分析优化与 CAE 软件全国重点实验室, 大连 116024;
2. 大连理工大学宁波研究院, 宁波 315000)

摘要: 准确构建螺栓连接处的非线性滞回曲线模型对卫星承重结构的减振和安全性能评估至关重要。传统计算模型的时域分析方法需要大量时间成本, 典型的数据驱动模型难以构建高精度的滞回模型。针对上述挑战, 提出了一种新的残差改进的深度学习算法 RIDLA (Residual Improvement Deep Learning Algorithm), 用于构建螺栓连接处位移与力的滞回曲线模型。该算法充分利用长短期记忆 (LSTM) 神经网络拟合时间序列非线性关系的能力, 通过实测响应与计算残差之间的交互迭代, 构建了多级别的残差改进深度学习模型, 从而实现了螺栓连接处滞回模型的准确建模。使用某卫星承重结构的子部件循环加载实验数据验证了 RIDLA 方法的性能。结果表明 RIDLA 实现了对螺栓连接处的位移和力滞回曲线高度精确的预测。此外, RIDLA 方法有可能应用于预测其他复杂非线性系统的动态响应。

关键词: 承重结构, 螺栓连接, 滞回模型, 残差改进, 深度学习

中图分类号: V414; O317⁺.3

文献标志码: A

文章编号: 1007-4708(2025)05-0744-07

1 引言

承重结构是卫星系统的骨架, 起到保护内部器件、支撑和连接各组成部分的作用。卫星系统中的电子设备、精密仪器和灵敏传感器对振动极为敏感。随着卫星承重结构朝复杂和轻量化方向发展, 对其稳定性和可靠性的要求也日益提高^[1]。当前, 卫星承重结构主要采用蜂窝板复合材料, 通过大量螺栓结构连接而成。螺栓连接和复合材料使得承重结构整体呈现出明显的非线性动力学特性^[2,3], 这导致卫星整体结构的振动响应难以准确评估。螺栓连接结构接触面处的刚度和阻尼特性的复杂性, 为卫星服役质量的预测评估带来了挑战。研究表明, 连接方式的变化会显著改变卫星结构的动力学特性。预紧力和外载荷均会影响螺栓连接的性能, 导致连接刚度和能量耗散发生变化。

通常, 螺栓连接的结构特征引起的非线性行为表现为在加载和卸载过程中的滞回效应^[4]。力与位移的滞回曲线包含了连接节点处的弹性、塑性行

为、屈服点和能量耗散等信息。因此, 准确构建螺栓连接节点处的非线性滞回曲线模型对于结构的振动控制和评估具有重要意义。滞回模型的建立是分析螺栓连接结构滞回性能和结构非线性的重要环节^[5]。为了准确获得螺栓连接结构的非线性特性, 研究人员利用商业软件 (如 ANSYS) 建立了精细化的非线性接触模型, 这些模型能够准确模拟连接的能量耗散和滞回曲线。然而, 这些模型的静态分析计算时间成本高, 动态分析收敛性差, 限制了其在工程中的应用。考虑到连接节点的能量耗散和刚度变化, Iwan 模型^[6]和 Bouc-Wen 模型^[7]用来描述连接节点的非线性关系。然而, 这些模型需要多个参数来描述连接部位的非线性行为, 并且需要通过复杂的实验对参数进行辨识和校准。

近年来, 神经网络作为一种通用逼近器广泛应用于构建结构响应之间的关系模型^[8]。RNN 结构可以考虑响应数据间的时间相关性, 在构建结构的非线性滞回模型方面有巨大的应用潜力。由于训练过程中存在梯度消失和爆炸的问题, 使得 RNN

收稿日期: 2024-06-27; 修改稿收到日期: 2024-07-29.

基金项目: 国家重点研发计划 (2021YFA1003501); 航空科学基金 (2022Z061001) 资助项目.

作者简介: 武文华* (1973-), 男, 博士, 教授 (E-mail: lxyuhua@dlut.edu.cn).

引用本文: 顾乃建, 刘坤, 武文华, 等. 基于 RIDLA 的卫星承重结构螺栓连接非线性滞回建模 [J]. 计算力学学报, 2025, 42(5): 744-750.

GU Naijian, LIU Kui, WU Wenhua, et al. Nonlinear hysteresis modeling of bolt connections in satellite load-carrying structures using a Residual Improvement Deep Learning Algorithm [J]. *Chinese Journal of Computational Mechanics*, 2025, 42(5): 744-750.

无法对长期结构响应进行建模,尤其是当响应中存在复杂的非线性关系时。长短期记忆(LSTM)神经网络是RNN的一种,通过引入门函数解决了RNN在训练过程中梯度消失或爆炸的问题^[9]。LSTM对时间序列有较强处理能力,已成功应用于非线性结构的响应预测^[10]和滞回模型的构建^[11]。Gu等^[12]提出了一种基于灵敏度分析的LSTM神经网络方法,用于提取结构行为特征并准确高效地建立结构的滞回模型。

虽然LSTM神经网络已成功应用于构建复杂结构的非线性滞回模型,但在构建强非线性系统的响应预测模型时,基于LSTM的预测模型与物理系统之间的差异仍可能导致结果误差超出预期。为了解决这一问题,本文提出了一种基于长短期记忆(LSTM)神经网络的新型残差改进深度学习算法(RIDLA),用于构建卫星承重结构螺栓连接处力与位移的非线性滞回模型。该算法通过残差数据的迭代训练,形成多级预测模型,从而准确构建非线性滞回曲线模型。因此,本文提出的RIDLA方法为评估卫星承重结构的稳定性和可靠性提供了一个可靠的工具。

2 基于RIDLA滞回曲线建模

2.1 滞回曲线预测模型构建方法

卫星承重结构螺栓连接结构在外载荷作用下力与位移响应存在非线性的滞回效应。理论上存在一个方程 Φ 可以描述结构力与位移之间的非线性关系。

$$y(t) = \Phi[x(t)] \quad (t = 1, 2, \dots, n) \quad (1)$$

式中 $x(t)$ 和 $y(t)$ 分别为 t 时刻的位移和力的响应值, n 为时间序列的长度。如果构建出满足式(2)中方程 Φ 的近似函数 $\tilde{\Phi}$,就可以通过输入测点位移响应 $x(t)$ 求解力的动态响应 $y(t)$ 。

$$\begin{cases} \tilde{\Phi}[x(t)] = \tilde{y}(t) \approx y(t) \\ |y(t) - \tilde{y}(t)| \leq \varepsilon \end{cases} \quad (2)$$

式中 $\tilde{y}(t)$ 是基于模型 $\tilde{\Phi}$ 预测的 t 时刻的响应, ε 为允许误差上限, $\varepsilon = 0.02$ 。构建卫星承重结构螺栓连接部位力与位移的滞回曲线模型的关键是求解非线性关系模型 $\tilde{\Phi}$,而从物理激励直接推导出模型 $\tilde{\Phi}$ 的表达式是非常困难的。考虑到力与位移存在明显的时间相关性,本文基于LSTM神经网络提出了一种新的残差改进的深度学习算法,用于构建螺栓连接处力与位移的非线性滞回曲线模型。

2.2 残差改进深度学习算法的框架

基于LSTM神经网络构建的预测模型虽考虑了输入和输出的时间相关性,具备拟合复杂非线性时间序列的能力,但训练的模型与物理实体之间的差异仍可能会导致预测结果的误差超出预期。本文提出了残差改进的深度学习算法(RIDLA),用于构建不同外载荷激励下力与位移的滞回效应预测模型,其具体步骤如图1所示。

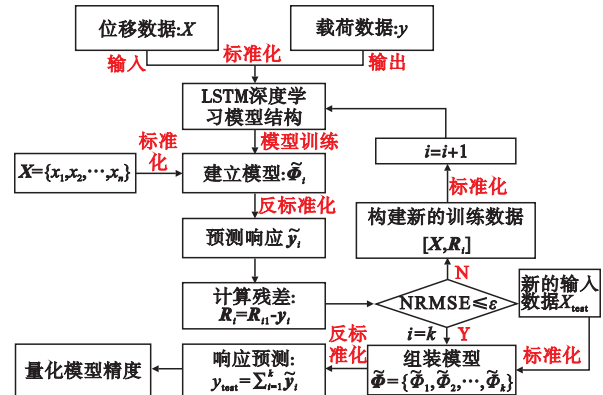


图1 残差改进的深度学习算法框架
Fig. 1 Residual Improvement Deep Learning Algorithm (RIDLA)

步骤1 通过实验获得力与位移的动态响应数据 $[X, y]$ 。 X 为位移数据(输入), y 为力响应数据(输出),其中 $X \in \mathbb{R}^{n \times p}$, $y \in \mathbb{R}^{n \times q}$, n 为训练样本的长度, p 和 q 分别为传感器的数量。

步骤2 构建LSTM神经网络模型。用于构建 X 与 R_{i-1} 的非线性关系 $\tilde{\Phi}_i$ 的LSTM神经网络模型如图2所示,主要包括输入层、隐藏层、全连接层和输出层。为兼并神经网络模型性能和训练时间,共设置3个LSTM隐藏层,并选择均方误差MSE(Mean Square Error)作为损失函数,优化器选择常用的Adam^[13]。采用正则化和丢弃操作防止模型训练过程出现过拟合现象,丢弃层设置在第2个LSTM隐藏层之后。

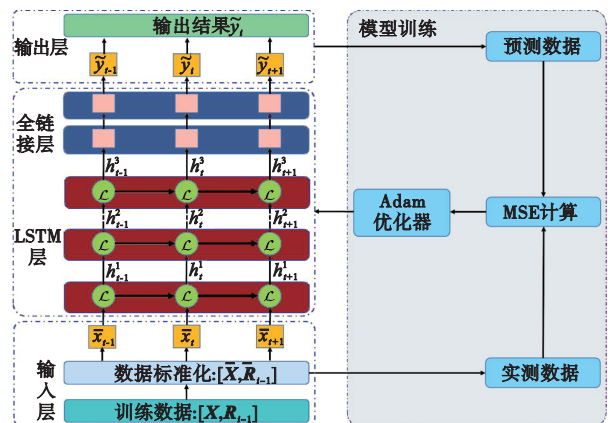


图2 LSTM神经网络模型结构
Fig. 2 Architecture of the LSTM neural network model

步骤3 令 $i=1$, 训练步骤2的LSTM神经网络模型, 得到响应反演回归模型 $\tilde{\Phi}_i$ 。模型 $\tilde{\Phi}_i$ 的训练数据是 $[\mathbf{X}, \mathbf{R}_{i-1}]$, 其中 $\mathbf{R}_0 = \mathbf{y}$ 。

步骤4 将训练的位移数据 \mathbf{X} 输入到模型 $\tilde{\Phi}_i$, 得到力响应的预测数据 \tilde{y}_i 。

步骤5 根据步骤4预测的数据 \tilde{y}_i 计算残差数据: $\mathbf{R}_i = \mathbf{R}_{i-1} - \tilde{y}_i$, 并基于残差数据 \mathbf{R}_i 计算其标准化均方根误差(NRMSE)。可通过式(3)计算得

$$\text{NRMSE} = \frac{\sqrt{\frac{1}{n} \sum_{i=1}^n (R_i)^2}}{\max(\mathbf{R}_i) - \min(\mathbf{R}_i)} \quad (3)$$

步骤6 计算NRMSE的值。如果 $\text{NRMSE} \leq \epsilon$, 则停止迭代, 令 $i=k$, 组装构建结构的滞回模型: $\tilde{\Phi} = \{\tilde{\Phi}_1, \tilde{\Phi}_2, \dots, \tilde{\Phi}_k\}$; 否则, 构造新的训练数据集 $[\mathbf{X}, \mathbf{R}_i]$, 令 $i=i+1$, 返回步骤3重复上述步骤。残差数据的迭代训练过程如图3所示。




图3 RIDLA方法的数据交互迭代

Fig. 3 Data interactive iteration of the RIDLA method

步骤7 将新的位移数据 \mathbf{X}_{test} 作为测试数据, 通过构建的滞回模型 $\tilde{\Phi}$ 预测结构载荷的动态响应数据: $\tilde{\mathbf{y}}_{\text{test}} = \sum_{i=1}^k \tilde{y}_i$ 。

步骤8 引入均方根误差(RMSE)和相关性系数 R^2 定量评估滞回模型 $\tilde{\Phi}$ 的精度。

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \tilde{y}_i)^2} \quad (4)$$

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \tilde{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y}_i)^2} \quad (5)$$

式中 n 为样本的长度, \tilde{y}_i 为模型 $\tilde{\Phi}$ 在 i 时刻的预测值, \bar{y}_i 为 y_i (实测值) 的平均值, 其中 $i=1, 2, \dots, n$ 。

2.3 LSTM神经网络

除了输入层和输出层之外, 标准的LSTM神经网络模型还包括多个隐藏层(LSTM层和全连接层)。LSTM层包含一组LSTM单元(如图4所示), 并将层的输入序列映射到层的输出序列。

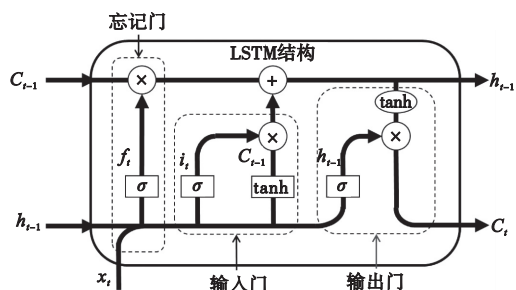


图4 LSTM单元结构[14]

Fig. 4 Loop structure of the LSTM cell

输入数据 $\mathbf{X} = \{x_1, x_2, \dots, x_t, \dots, x_n\} \in \mathbb{R}^{n \times p}$ 和输出数据 $\mathbf{Y} = \{y_1, y_2, \dots, y_t, \dots, y_n\} \in \mathbb{R}^{n \times q}$ 分别为通过实验测量的位移和力的时程数据。在 t 时刻 ($t=1, \dots, n$, 其中 n 为时间步长总数), LSTM单元的前向传播过程可用式(6~11)表示。

$$f_t = \sigma(\mathbf{W}_f[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_f) \quad (6)$$

$$i_t = \sigma(\mathbf{W}_i[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_i) \quad (7)$$

$$o_t = \sigma(\mathbf{W}_o[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_o) \quad (8)$$

$$\tilde{C}_t = \tanh(\mathbf{W}_c[\mathbf{h}_{t-1}, \mathbf{x}_t] + \mathbf{b}_c) \quad (9)$$

$$C_t = f_t * C_{t-1} + i_t * \tilde{C}_t \quad (10)$$

$$h_t = o_t * \tanh(C_t) \quad (11)$$

式中 \mathbf{W} 为不同门函数(输入门 i_t 、输出门 o_t 、遗忘门 f_t) 输入不同 \mathbf{x}_t 对应的权重矩阵, \mathbf{b} 为相应的偏置向量。 C_t 是当前的存储单元状态, \tilde{C}_t 为当前的候选单元状态。 \tanh 是双曲正切函数。 σ 是对数sigmoid函数。LSTM单元在整个时间空间内不断重复上述过程, 形成一个链状结构来捕捉长短期时间依赖关系, 如图5所示。




图5 单层LSTM序列架构

Fig. 5 Single-layer LSTM sequential architecture

3 非线性6DOF弹簧振子响应预测

3.1 6DOF弹簧振子计算模型

通过非线性6DOF弹簧振子(如图6所示)的计算数据验证提出的残差改进深度学习算法(RIDLA)的可行性和准确性。非线性系统的动态控制方程为

$$\mathbf{M}\ddot{\mathbf{X}} + \mathbf{C}\dot{\mathbf{X}} + \mathbf{K}(\mathbf{X}, t)\mathbf{X} + \mathbf{G}(\mathbf{X}, t) = \mathbf{F} + \boldsymbol{\Sigma}\boldsymbol{\Psi} \quad (12)$$

式中 \mathbf{M} 、 \mathbf{C} 和 $\mathbf{K}(\mathbf{X}, t)$ 分别为非线性系统的质量、阻尼和刚度阵, 其中 $\mathbf{M} = \text{diag}[m_1, \dots, m_6] \in \mathbb{R}^{6 \times 6}$, $\mathbf{C} = \text{diag}[c_1, \dots, c_6] \in \mathbb{R}^{6 \times 6}$, $m_i = 5 \text{ kg}$, $c_i = 0.05$ 。

结构的刚度矩阵与每个弹簧在 t 时刻的伸长量相关,其变化是非线性的。 \mathbf{X} 为 6DOF 系统质量块的位移响应矩阵, $\mathbf{X}=[x_1^t, \dots, x_6^t] \in \mathbb{R}^6$ 。 \mathbf{F} 为 6DOF 系统受的外部激励。 Ψ 为在噪声强度矩阵 Σ 下的随机噪声向量。 $\Psi=[\psi_1, \dots, \psi_6] \in \mathbb{R}^6$, $\Sigma=[\sigma_1, \dots, \sigma_6] \in \mathbb{R}^{6 \times 6}$, 其中 $\psi_i = \text{rand}n(1, n)$, $n=50000$, $\sigma_i=0.2$ 。 $\mathbf{G}(\mathbf{X}, t)$ 是 6DOF 系统计算模型中引入的另一个非线性因素, $\mathbf{G}(\mathbf{X}, t)=[g_1^t, \dots, g_6^t] \in \mathbb{R}^6$ 。




图 6 6DOF 弹簧振子非线性系统
Fig. 6 DOF spring oscillator nonlinear system

$$\mathbf{K}(\mathbf{X}, t) = \begin{bmatrix} k_1^t + k_2^t & -k_2^t & & & & \\ -k_2^t & k_2^t + k_3^t & -k_3^t & & & \\ & -k_3^t & k_3^t + k_4^t & -k_4^t & & \\ & & -k_4^t & k_4^t + k_5^t & -k_5^t & \\ & & & -k_5^t & k_5^t + k_6^t & -k_6^t \\ & & & & -k_6^t & k_6^t \end{bmatrix} \quad (13)$$

$$k_i^t = \begin{cases} 10 & (|\Delta x_i^t| \geq x_e) \\ 1000 & (\text{else}) \end{cases} \quad (14)$$

$$g_i^t = \begin{cases} 1000x_i^t + 10(\Delta x_i^t - x_i^t) & (\Delta x_i^t \geq x_e) \\ -1000x_i^t + 10(\Delta x_i^t + x_i^t) & (\Delta x_i^t < -x_e) \\ 1000\Delta x_i^t & (\text{else}) \end{cases} \quad (15)$$

式中 Δx_i^t 为弹簧 i 在 t 时刻的伸长量, x_i^t 为质量块 i 在 t 时刻的位移。 x_e 为弹簧伸长量的阈值, 其中 $x_e=1 \text{ mm}$ 。6DOF 系统动力学控制方程中的 $\mathbf{F}=[f_1, \dots, f_6] \in \mathbb{R}^6$, 各个质量点受到正弦载荷的幅值和周期均不相同, 表 1 给出了各质量点所受正弦载荷的幅值和角速度, 式(16)给出了各质量点载荷激励的数学表达:

$$f_i = \lambda_i \sin(\pi t / \omega_i) \quad (16)$$

表 1 正弦载荷的幅值与角速度
Tab. 1 Amplitude and angular velocity of sinusoidal load

编号 i	1	2	3	4	5	6
λ_i	0.5	0.4	0.2	0.4	3.0	2.5
ω_i	50	30	20	10	50	60

3.2 6DOF 系统关注点响应预测

通过 Runge-Kutta 方法计算得到 6 个质量块的 50000 组位移数据, 其中 80% 作为训练数据集, 20% 作为测试数据集。假设 1# 质点为结构的关注点, 2#~6# 质量点为结构的可测点。图 7 为 6 个质量点位移在时域的相关分析。质点 1# 位移与 2#~6# 点的位移时序数据相关系数分别为 0.03、0.23、0.09、0.17、0.01, 相关系数较低。2#~6# 质点位移时间数据之间的相关性也较低。

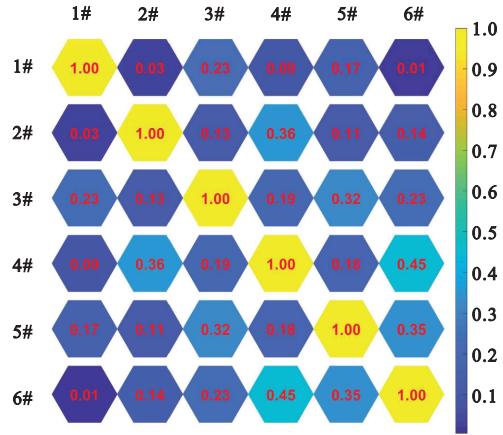


图 7 位移数据的互相关系数
Fig. 7 Correlation analysis of displacement data

训练过程中通过调整初始学习率和隐藏层神经元数量, 以寻求合适的超参数组合使得训练的回归模型的性能最优。其中, 每个隐藏层的神经元数量介于 16 和 256 之间尝试, 初始学习率介于 0.008 和 0.032 之间尝试, 最大迭代次数设置为 600。LSTM 模型的其余超参数设置列入表 2^[15]。通过调整神经网络的超参数, 最终优化 LSTM 神经网络模型的最大迭代次数为 600, 初始学习率为 0.016, 第 1 层设置 64 个隐藏神经元, 第 2 层和第 3 层分别设置 128 个和 64 个隐藏神经元。为了保证响应预测模型的精度, 误差阈值 ϵ 设置为 0.02。

表 2 LSTM 神经网络超参数
Tab. 2 Hyperparameters of the LSTM neural network model

神经网络超参数	参数值
梯度衰减因子(Gradient decay factor)	0.9000
学习率下降系数(Learning rate drop factor)	0.5000
学习率下降周期(Learning rate drop period)	100
L_2 正则化系数 (L_2 regularization)	1e-4

图 8 给出了从测试数据集中随机选择一段关注点位移的预测结果。可以看出, 相比于 LSTM 神经网络预测模型, 使用提出的残差改进深度学习

算法(RIDLA)构建的预测模型的计算精度有显著提高。计算出两个模型的响应结果的 RMSE、NRMSE 和相关系数 R^2 列入表 3。从 LSTM 到基于 RIDLA 模型的预测结果, RMSE 从 5.90 mm 下降到 0.30 mm, NRMSE 从 0.114 下降到 0.006, 相关系数 R^2 从 0.861 增加到 0.999。计算结果表明, 使用 RIDLA 模型预测的关注点的位移数据的精度有了显著提高。




图 8 使用 LSTM 模型和 RIDLA 模型预测响应

Fig. 8 Predicting responses using LSTM model and RIDLA model

表 3 预测结果精度对比

Tab. 3 Comparison of prediction accuracy

模型	RMSE /mm	NRMSE	R^2
LSTM	5.90	0.114	0.861
RIDLA	0.30	0.006	0.999

4 滞回预测模型实验验证

4.1 残差改进深度学习算法的框架

所用实验结构为某卫星的承重结构部件, 如图 9 所示。




图 9 卫星承重结构和实验结构

Fig. 9 Satellite load-carrying and experimental structures

该实验结构为 T 型结构, 两块铝蜂窝夹层板由两个螺栓连接。通过实验获得力与位移的数据, 其实验细节如图 10 所示。实验件通过夹具固定在试验台上。试验件的上部固定一个激光位移传感器, 其测量精度达到 $0.1 \mu\text{m}$ 。下部安装一个压力传感器, 其量程为 5000 N。压力传感器与位移激励器之间通过强度较高的钢杆件连接, 实验过程视为刚体。实验结构受到正弦波位移激励, 通过压力

传感器测得力的时程变化数据, 激光位移传感器则用于测量位移数据。最后, 应用不同峰值的正弦波位移激励, 获得相应的力-位移响应数据。图 11 展示了在不同峰值正弦波激励下测得的力与位移的滞回曲线。可以观察到, 随着正弦波峰值从 1.0 mm 增加到 2.5 mm, 力与位移的滞回曲线形状从梭形变为反 S 形。卫星承重结构的螺栓连接部位表现出较为复杂的非线性滞回效应。



图 10 力与位移加载试验

Fig. 10 Force and displacement loading test

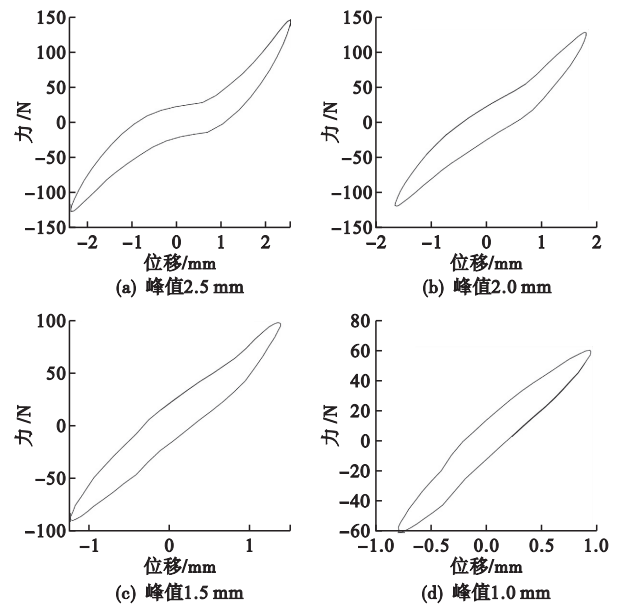


图 11 不同峰值激励的力与位移滞回曲线

Fig. 11 Hysteresis loops of force and displacement under different peak excitations

4.2 RIDLA 滞回模型的构建

训练过程中通过调整初始学习率和隐藏层神经元数量, 以寻求合适的超参数组合使得训练的回归模型 $\tilde{\Phi}_i$ 的性能最优。其中, 每个隐藏层的神经元数量介于 16 和 256 之间尝试, 初始学习率介于

0.008 和 0.032 之间尝试,最大迭代次数设置为 600。通过调整神经网络的超参数,最终优化 LSTM 神经网络模型的初始学习率为 0.016,第 1 层设置 32 个隐藏神经元,第 2 层和第 3 层分别设置 64 个和 32 个隐藏神经元。

利用 RIDLA 方法构建卫星承力结构力与位移之间的非线性滞回模型,其中位移响应作为输入,力响应作为输出,并与多层感知机 MLP(Multilayer Perception,)、深度神经网络(DNN)和 LSTM 等通用神经网络方法进行了对比,结果如图 12 所示。对比上述三种方法,本文提出的 RIDLA 构建的滞回模型具有更高的精度。表 4 给出了不同模型的预测精度,从 LSTM 模型到 RIDLA 的模型, RMSE 从 16.80 N 下降到 0.945 N, NRMSE 从 0.060 下降到 0.003, 相关系数从 0.963 上升到 0.999。MLP 和 DNN 方法的预测精度相对较低,主要是因为 MLP 和 DNN 神经网络无法考虑数据间的时间相关性,导致滞回模型的精度较低。

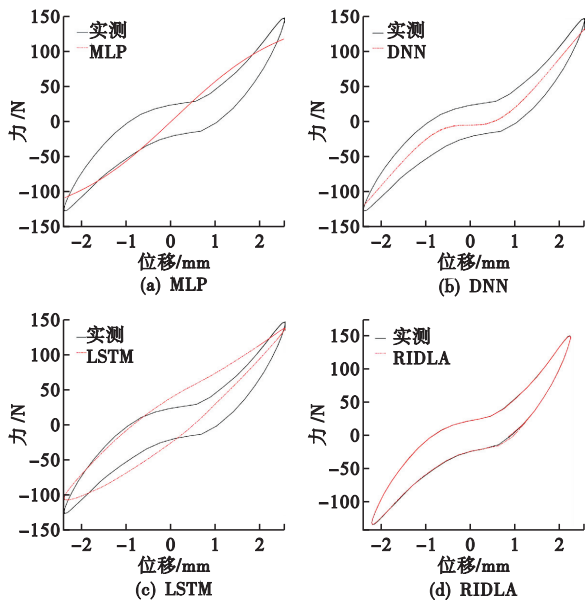


图 12 不同滞回模型预测结果(峰值 2.5 mm)
Fig. 12 Predictions of different hysteresis models (peak 2.5 mm)

表 4 预测结果对比分析

Tab. 4 Comparative analysis of prediction accuracy

模型	RMSE/(N)	NRMSE	R^2
MLP	27.92	0.999	0.899
DNN	19.89	0.071	0.949
LSTM	16.80	0.060	0.963
RIDLA	0.945	0.003	0.999

图 13 显示了基于 RIDLA 方法构建的不同位峰峰值激励下的滞回模型预测结果。RIDLA 方法

可以高精度地构建不同峰值正弦波激励的滞回模型,其预测结果与实验数据具有较高的一致性。因此,本文提出的 RIDLA 方法可以用于构建卫星承重结构螺栓连接部位力与位移关系的滞回效应。

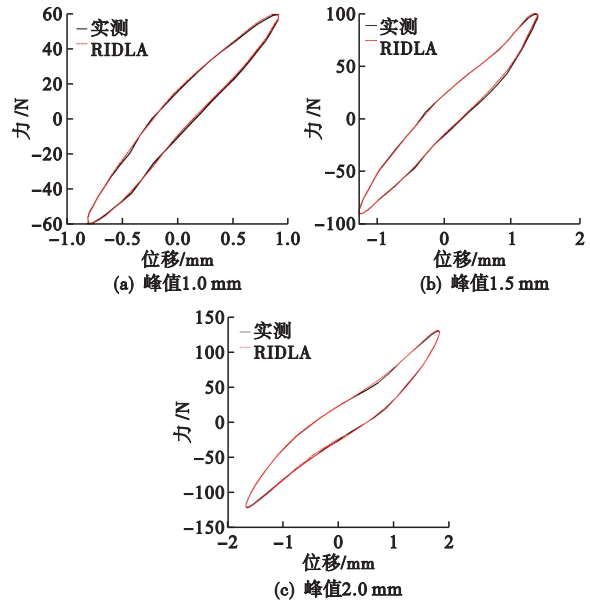


图 13 RIDLA 滞回模型的预测结果
Fig. 13 Prediction results of RIDLA hysteresis model

5 结论

本文研究了卫星承重结构螺栓连接部位的力与位移非线性滞回关系,提出了一种基于残差改进的深度神经网络(RIDLA)用于构建滞回曲线模型,并通过 6DOF 非线性系统的计算数据和实验数据验证了该方法的可行性和准确性。主要结论如下。

6DOF 非线性系统响应预测。相比于传统的 LSTM 神经网络响应预测模型,预测结果与计算数据的均方根误差(RMSE)从 5.9 mm 下降至 0.3 mm,标准均方根误差(NRMSE)从 0.114 降低至 0.006,相关系数 R^2 由 0.861 上升至 0.999。

残差改进的深度神经网络(RIDLA)。RIDLA 算法在 LSTM 基础上通过残差数据的迭代训练显著提升了模型精度。实验验证表明,对比于 LSTM 模型的预测结果,RIDLA 构建滞回模型的 RMSE 从 16.80 N 降低至 0.945 N, NRMSE 从 0.06 下降到 0.003, R^2 从 0.963 上升至 0.999, 显示了该方法在复杂非线性关系建模中的优越性。

综上所述,本文发展的 RIDLA 方法不仅能够准确捕捉螺栓连接部位的非线性滞回效应,还具备较高的预测精度和实际应用潜力,为复杂结构的动力学特性研究提供了新的思路和方法。

参考文献(References):

- [1] 董彦芝, 盛 聪, 曾惠忠, 等. 嫦娥五号轻量化高精度上升器结构设计[J]. 宇航学报, 2021, **42**(8): 953-960 (DONG Yanzhi, SHENG Cong, ZENG Huizhong, et al. Design of lightweight and high precision structure of Chang'e-5 ascender[J]. *Journal of Astronautics*, 2021, **42**(8): 953-960. (in Chinese))
- [2] 李伦绪, 陈 果, 于平超, 等. 止口螺栓连接结构非线性刚度机理分析及数值仿真[J]. 航空动力学报, 2021, **36**(2): 358-368. (LI Lunxu, CHEN Guo, YU Pingchao, et al. Nonlinear stiffness mechanism analysis and numerical simulation of rabbet-bolted connection structure [J]. *Journal of Aerospace Power*, 2021, **36**(2): 358-368. (in Chinese))
- [3] 芦 旭, 王 平, 王建男, 等. 含剪力销(锥)螺栓法兰连接结构非线性特性[J]. 计算力学学报, 2015, **32**(4): 503-511. (LU Xu, WANG Ping, WANG Jianan, et al. Nonlinear behavior of bolted flange connections containing shear pin(CONE)[J]. *Chinese Journal of Computational Mechanics*, 2015, **32**(4): 503-511. (in Chinese))
- [4] Mei A, Gusella F, Orlando M. A steel bracing system dissipating energy through moment-rotation hysteresis loops [J]. *Engineering Structures*, 2023, **280**: 115640.
- [5] Ning C L, Wang L P, Du W Q. A practical approach to predict the hysteresis loop of reinforced concrete columns failing in different modes[J]. *Construction and Building Materials*, 2019, **218**: 644-656.
- [6] Iwan W D. A distributed-element model for hysteresis and its steady-state dynamic response[J]. *Journal of Applied Mechanics*, 1966, **33**(4): 893-900.
- [7] Wen Y K. Equivalent linearization for hysteretic systems under random excitation[J]. *Journal of Applied Mechanics*, 1980, **47**(1): 150-154.
- [8] Ghaboussi J, Garrett J H Jr, Wu X. Knowledge-based modeling of material behavior with neural networks [J]. *Journal of Engineering Mechanics*, 1991, **117**(1): 132-153.
- [9] LeCun Y, Bengio Y, Hinton G. Deep learning[J]. *Nature*, 2015, **521**(7553): 436-444.
- [10] 顾乃建, 武文华, 郭杏林. 一种星-箭连接动态界面力的深度学习反演方法[J]. 宇航学报, 2022, **43**(12): 1618-1628. (GU Naijian, WU Wenhua, GUO Xinglin. A deep learning inversion method for dynamic interface force of satellite-rocket connection[J]. *Journal of Astronautics*, 2022, **43**(12): 1618-1628. (in Chinese))
- [11] Yazdanpanah O, Chang M, Park M, et al. Seismic response prediction of RC bridge piers through stacked long short-term memory network [J]. *Structures*, 2022, **45**: 1990-2006.
- [12] Gu Y, Lu X Z, Xu Y J. A deep ensemble learning-driven method for the intelligent construction of structural hysteresis models[J]. *Computers & Structures*, 2023, **286**: 107106.
- [13] Kingma D P, Ba J. Adam: A method for stochastic optimization[EB/OL]. 2014; arXiv: 1412. 6980. <https://arxiv.org/abs/1412.6980>
- [14] Zhou J, 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.
- [15] Gu N J, Wu W H, Guo X L, et al. A novel residual improved deep learning indirect measurement algorithm (RIDLA) for nonlinear dynamic responses[J]. *Mechanics Research Communications*, 2023, **129**: 104087.

Nonlinear hysteresis modeling of bolt connections in satellite load-carrying structures using a Residual Improvement Deep Learning Algorithm

GU Naijian¹, LIU Kun¹, WU Wenhua^{*1,2}, GUO Xinglin¹

(1. State Key Laboratory of Structural Analysis, Optimization and CAE Software for Industrial Equipment, Dalian University of Technology, Dalian 116024, China;

2. Ningbo Research Institute of Dalian University of Technology, Ningbo 315000, China)

Abstract: Accurately constructing the nonlinear hysteresis loop model at the bolt connection is crucial for the vibration reduction and safety performance evaluation of a satellite load-carrying structure. Traditional time-domain analysis methods of computational models require substantial time costs, and typical data-driven models struggle to construct high-precision hysteresis models. To address these challenges, a novel Residual Improvement Deep Learning Algorithm (RIDLA) is proposed for constructing the hysteresis loop model of displacement and force at the bolt connection. The algorithm fully leverages the capacity of Long Short-Term Memory (LSTM) neural networks to fit nonlinear relationships in time series. It adopts an innovative approach by creating a multi-level residual improvement deep learning model that iteratively refines predictions based on measured responses, resulting in highly accurate modeling of hysteresis at bolt connections. The performance of the RIDLA method is validated using experimental data from cyclic loading of a subcomponent of a satellite load carrying structure. The findings demonstrate that RIDLA achieves highly accurate predictions of the displacement and force hysteresis loop at the bolt connection. Additionally, the RIDLA method could be applied to predict the dynamic responses of other complex non-linear systems.

Key words: load-carrying structure; bolt connection; hysteresis model; residual improvement; deep learning