

基于模型嵌入循环神经网络的损伤识别方法

翁顺¹,雷奥琦¹,陈志丹^{1†},于虹²,颜永逸²,余兴胜²

(1. 华中科技大学 土木与水利工程学院,湖北 武汉 430074;

2. 中铁第四勘察设计院集团有限公司,湖北 武汉 430063)

摘要:目前,绝大多数基于深度学习的结构损伤识别方法依靠深度神经网络自动提取结构的损伤敏感特征,并通过损伤状态之间特征的差异实现模式分类识别.然而,这些方法面临着损伤量化难度大的挑战,并且需要大量的模型训练数据.本文提出基于模型嵌入循环神经网络(Model-Embedding Recurrent Neural Network, MERNN)的损伤识别方法.首先,通过数据驱动的卷积神经网络(Convolutional Neural Network, CNN)建立荷载-响应之间的映射关系,然后,利用龙格库塔法改进传统的循环神经网络,建立基于循环神经网络架构的数值计算单元.最后,基于结构响应计算值与实测响应残差构成的损失函数与神经网络的自动微分机制来实现结构刚度参数的更新,进而实现结构损伤识别.数值模拟框架与实验室的3层剪切型框架的损伤识别结果表明,本文提出的方法能基于少量响应数据准确量化结构损伤.

关键词:循环神经网络;龙格库塔法;损伤识别

中图分类号:TU317

文献标志码:A

Model-Embedding based Damage Detection Method for Recurrent Neural Network

WENG Shun¹, LEI Aoqi¹, CHEN Zhidan^{1†}, YU Hong², YAN Yongyi², YU Xingsheng²

(1. School of Civil and Hydraulic Engineering, Huazhong University of Science and Technology, Wuhan 430074, China;

2. China Railway Siyuan Survey and Design Group Co., Ltd., Wuhan 430063, China)

Abstract: Currently, the majority of structure damage identification methods based on deep learning rely on deep neural networks to automatically extract damage-sensitive features of structures and achieve pattern classification recognition through the differences in features between damage states. However, these methods face challenges in the accurate quantification of damage and require a large amount of data for model training. This article proposes a damage detection method based on a model-embedding recurrent neural network (MERNN). Firstly, a data-driven convolutional neural network was used to establish the mapping relationship between load and response.

* 收稿日期:2023-09-04

基金项目:国家重点研发计划资助项目(2023YFC3805700), National Key R&D Program of China (2023YFC3805700); 中铁第四勘察设计院集团有限公司课题(KY2023014S, KY2023126S), Research Fund of China Railway Siyuan Survey and Design Group Co., Ltd. (KY2023014S, KY2023126S); 华中科技大学交叉研究支持计划(2023JCYJ014), Interdisciplinary Research Support Program of HUST(2023JCYJ014)

作者简介:翁顺(1982—),女,湖北黄冈人,华中科技大学教授,博士

† 通信联系人, E-mail: czd@hust.edu.cn

Then, the traditional recurrent neural network was improved using the Runge-Kutta method to create a numerical computing unit based on the recurrent neural network architecture. Finally, based on the loss function composed of the residual errors between measured responses and computed responses, the structural stiffness parameters were updated with the automatic differentiation mechanism of the neural network to achieve structural damage identification. Damage identification results of a numerical three-layer frame and a laboratory-scale shear-type frame indicate that the proposed method can accurately quantify structural damage based on the limited amount of response datas.

Key words: recurrent neural network; Runge-Kutta method; damage detection

结构健康监测系统在结构服役过程中积累了大量监测数据,基于监测数据的结构损伤识别和状态评估方法得到越来越多的关注.深度学习作为一种有效的数据特征提取方法,在结构损伤识别领域取得了丰富的成果.2017年,Lin等^[1]首次采用卷积神经网络自动提取结构响应中反映结构损伤的因子,基于提取的因子判断结构损伤对应的位置.Modarres等^[2]利用卷积神经网络强大的图像识别能力,通过识别蜂窝夹层板结构表面损伤的形状来实现损伤的分类.Shu等^[3]利用计算机视觉获得的结构位移结合CNN网络进行结构损伤的定位,并根据损伤定位的结果进行结构局部的有限元模型修正,从而得到结构的损伤程度.除此之外,为了考虑结构间差异并能充分利用训练的模型来识别无标签样本的损伤类型,许多研究者研究了基于模型迁移学习的结构损伤识别,如Teng等^[4]基于卷积神经网络提出了桥梁缩尺模型与实桥之间迁移的损伤识别算法.李佐强等^[5]提出了一种基于领域自适应支持向量机的跨域损伤识别方法,通过最小化源域与目标域之间的边缘概率分布和联合概率分布,保证了损伤分类模型在多个域上均具有良好效果.现有基于深度学习的结构损伤识别方法主要是利用损伤敏感特征进行分类决策,但大多仅限于判断结构是否损伤或进行小范围的损伤定位,无法直接实现端到端的高效损伤量化.

以有限元模型修正为代表的损伤识别方法具有有效量化损伤的能力.Zhu等^[6]提出了一种基于结构动力响应的荷载识别和损伤识别方法,并推导了结构参数和荷载参数对结构响应的灵敏度,用于指示

相关参数的优化方向.Chen等^[7]基于稀疏贝叶斯方法,提出了一种考虑损伤和荷载识别过程中不确定性的荷载和损伤同步识别方法,在此方法中,将未知的激励视作切比雪夫多项式的组合,通过动力响应对损伤和荷载参数的灵敏度进行未知参数的更新以实现损伤量化和未知荷载识别.上述示例已经表明在有限元模型修正方法的优化过程中加入模型约束如灵敏度条件,可以有效提升模型修正的效率和性能^[6].Guo等^[8]将结构频率与刚度参数之间的映射关系加入多层神经网络模型的损失函数中,在样本量较少的情况下,提出的物理约束神经网络可以有效识别结构参数.通过在数据驱动方法中引入基于有限元模型的约束,并利用神经网络的误差反向传播机制进行模型训练,以及充分利用深度学习强大的非线性拟合能力,结合物理意义明确的有限元模型修正方法,构建基于物理约束的深度学习方法,在样本量少的情况下进行损伤量化.

现有基于时域响应的损伤量化方法大多需要外荷载的先验知识如荷载形式等,且完成荷载识别过程时间长,无法直接从测得的结构响应中捕捉损伤-荷载-响应之间的关联性,存在计算效率低、参数多的问题.深度学习具有强大的非线性拟合和高维特征提取能力,可以直接从监测数据中捕捉荷载时间序列与响应时间序列的联系,实现不基于结构参数的荷载识别.卷积神经网络的参数共享机制,对提取多维特征向量中的相似特征并减少操作中的参数非常有利,被广泛用于响应重构、荷载识别等时间序列建模中.Li等^[9]通过卷积神经网络和U-net架构建立多类结构响应之间的联系,并在一个实验室缩

尺模型上验证了提出的方法对响应重构任务的有效性. Lei等^[10]基于卷积神经网络和生成对抗网络架构,通过引入一个判别网络来评估响应重构的效果. Rosafalco等^[11]通过卷积神经网络和U-net架构,利用结构响应进行荷载识别,取得了较好的识别效果. 这些研究表明数据驱动的卷积神经网络可以成功完成荷载识别任务.

本文提出了一种基于模型嵌入循环神经网络MERNN的结构损伤识别方法. 利用卷积神经网络建立多种结构响应与荷载之间的联系,然后建立基于循环神经网络架构的数值计算单元. 构建基于计算响应与实测响应残差的损失函数,通过神经网络的误差反向传播和自动微分机制来进行基准模型参数的更新,通过更新前后0参数的变化来实现结构损伤识别. 数值模拟框架与实验室的3层剪切型框架的损伤识别结果表明,本文提出的方法能基于少量响应数据准确量化结构损伤.

1 基于MERNN的损伤识别方法

线性动力学系统的动力响应方程可表示为如下形式:

$$\mathbf{M}\ddot{\mathbf{y}} + \mathbf{C}\dot{\mathbf{y}} + \mathbf{K}\mathbf{y} = \mathbf{F} \quad (1)$$

$$\ddot{\mathbf{y}} = \mathbf{M}^{-1}(\mathbf{F} - \mathbf{C}\dot{\mathbf{y}} - \mathbf{K}\mathbf{y}) \quad (2)$$

式中: $\mathbf{M}$ 、 $\mathbf{C}$ 、 $\mathbf{K}$ 分别为结构的质量矩阵、阻尼矩阵和刚度矩阵,瑞利阻尼通常可以表示为 $\mathbf{C} = \alpha_1\mathbf{M} + \alpha_2\mathbf{K}$,其中 α_1 和 α_2 为瑞利阻尼系数; $\mathbf{y}$ 、 $\dot{\mathbf{y}}$ 、 $\ddot{\mathbf{y}}$ 分别为结构的位移、速度和加速度响应; $\mathbf{F}$ 为结构上作用的荷载.

实际中,作用在结构上的外荷载往往为未知状态. 因此要按式(2)计算结构响应,需要先进行荷载识别,但由于结构损伤的存在,按基于模型的方法计算出的结构响应势必会与真实情况有一定的偏差,为了解决荷载-损伤相互耦合的问题,本文利用纯数据驱动的卷积神经网络来进行荷载解耦.

1.1 基于卷积神经网络的动力荷载识别

为了识别未知的动力荷载的时程 $f(t)$,本文采取传统的包含多层2D卷积层、池化层和全连接层的CNN架构来构建测得的结构响应 $y(t)$ 与外荷载之间的映射关系,根据估计的荷载 $\hat{f}(t)$ 和荷载的真实值

$f_{\text{true}}(t)$ 之间的差异计算荷载估计误差,利用误差更新网络的权重参数. 本文通过估计荷载和荷载真实值之间的均方误差来构建CNN荷载识别网络的损伤函数 L_{load} .

$$L_{\text{load}} = \frac{1}{n} \sum_{i=1}^n [\hat{f}(i) - f_{\text{true}}(i)]^2 \quad (3)$$

1.2 基于龙格库塔法改进的循环神经网络单元

通过卷积神经网络获得结构上作用的未知荷载参数后,使用常见的显式积分求解方法如Newmark- β 法或四阶龙格库塔法对数值微分方程[式(1)和式(2)]进行求解,得到结构的动力响应. 由于龙格库塔法具有良好的数值稳定性,并且仅需要一阶导数信息,易于编程实现,故在本文中主要采取四阶龙格库塔法进行结构动力响应的求解,原理如下:

$$\begin{cases} \mathbf{y}_{n+1} = \mathbf{y}_n + \frac{h}{6}(\mathbf{K}_1 + 2\mathbf{K}_2 + 2\mathbf{K}_3 + \mathbf{K}_4) \\ \mathbf{K}_1 = f(\mathbf{x}_n, \mathbf{y}_n) \\ \mathbf{K}_2 = f(\mathbf{x}_{n+\frac{1}{2}}, \mathbf{y}_n + \frac{h}{2}\mathbf{K}_1) \\ \mathbf{K}_3 = f(\mathbf{x}_{n+\frac{1}{2}}, \mathbf{y}_n + \frac{h}{2}\mathbf{K}_2) \\ \mathbf{K}_4 = f(\mathbf{x}_{n+1}, \mathbf{y}_n + h\mathbf{K}_3) \end{cases} \quad (4)$$

式中: $\mathbf{x}_n$ 、 $\mathbf{x}_{n+\frac{1}{2}}$ 、 $\mathbf{x}_{n+1}$ 分别代表第 n 个、第 $n+\frac{1}{2}$ 个和第 $n+1$ 个时间点; $\mathbf{y}_n$ 、 $\mathbf{y}_{n+1}$ 分别表示第 n 个时间点与第 $n+1$ 个时间点的结构响应; $\mathbf{K}_1$ ~ $\mathbf{K}_4$ 为龙格库塔法的数值计算点间的斜率; h 为步长.

在给定初始状态后,显式迭代运算可以得到结构在每个时刻的位移等响应.

为了嵌入结构响应计算方法,本文中选择使用四阶龙格库塔法代替循环神经网络的内部计算流程. LSTM单元是经典的循环神经网络单元,通过遗忘门、输入门和输出门控制状态向量和输出向量在网络中的流动,解决了梯度消失问题.

MERNN单元首先基于每个时刻的初位移和初速度向量按式(2)计算结构的加速度向量,按式(5)和式(6)计算下一个时间子步下结构的位移和速度向量.

$$\mathbf{y}_k(i) = \mathbf{y}(i-1) + \mathbf{A}[k] \times \dot{\mathbf{y}}_k(i-1) \times \Delta t \quad (5)$$

$$\dot{\mathbf{y}}_k(i) = \dot{\mathbf{y}}(i-1) + \mathbf{A}[k] \times \ddot{\mathbf{y}}_k(i-1) \times \Delta t \quad (6)$$

式中: $k \in [1, 2, 3, 4]$; $\mathbf{y}_k(i)$ 、 $\dot{\mathbf{y}}_k(i)$ 、 $\ddot{\mathbf{y}}_k(i)$ 分别为第 i 个

时间点与第 $i+1$ 个时间点上第 k 个子步的位移、速度和加速度; $y(i-1)$ 、 $\dot{y}(i-1)$ 分别为第 $i-1$ 个时间点的位移和速度; $A = [0, \frac{1}{2}, \frac{1}{2}, 1]$; Δt 为时间间隔.

计算出两个时间点内四个子步的位移、速度和加速度向量后,如式(7)所示使用一求和算子来获取数值计算单元的输出:

$$R(i) = R(i-1) + B \times R(i)^T \times \Delta t \quad (7)$$

式中: $R(i)$ 可表示为结构的位移、速度或加速度向量, $R = [R_1(i), R_2(i), R_3(i), R_4(i)]$; B 为一系数矩阵, $B = [\frac{1}{6}, \frac{1}{3}, \frac{1}{3}, \frac{1}{6}]$.

传统的长短时记忆网络或循环神经网络可以表示一种显式迭代计算过程,因此可以使用显式的四阶龙格库塔法即式(5)~式(7)中的计算来替代神经网络内部的数据计算过程.通过上述的方式将传统的响应计算方法引入作为有限元模型约束,使循环神经网络层转化为结构响应计算层,传统 LSTM 单元与提出的基于循环神经网络架构的 MERNN 单元的对比和 MERNN 层的计算流程如图 1 所示.




图1 基于循环神经网络架构的响应计算单元

Fig.1 Response calculation cell based on RNN architecture

其中 MERNN 层中的 MERNN 单元将 CNN 模型识别到的荷载 F 作为输入,将结构响应作为输出.在数值计算单元中,此时荷载 F_i 项等效于 LSTM 单元中的单元输入,由结构的位移和速度组成的状态向量 y_i 等效于 LSTM 单元中的记忆向量,改进后的循环神经网络可以用于结构响应的计算.

1.3 结构损伤识别方法

改进的 MERNN 层和常规的神经网络层一样,可以在内部设置可训练的参数,故首先将未损伤结构的质量矩阵、刚度矩阵和阻尼矩阵作为基准模型参

数引入网络,在模型训练的过程中基于卷积神经网络预测出的荷载与结构参数计算出结构响应,与真实的结构响应进行对比,根据时域响应之间的差异对结构的刚度参数进行更新.基于计算响应与真实响应之间的误差构建 MERNN 网络的损失函数 L_{response} ,如式(8)所示.依据损失函数利用误差反向传播算法,更新网络中的可训练参数如框架结构的侧向刚度,对比更新后的刚度参数与基准模型的刚度参数即可确定结构的损伤位置与损伤程度 DI.

$$L_{\text{response}} = \frac{1}{n} \sum_{i=1}^n [X_{\text{measure}}(i) - X_{\text{updated}}(i)]^2 \quad (8)$$

$$g_{k_i} = \frac{\partial L_{\text{response}}}{\partial k_i} = \frac{\partial ([X_{\text{measure}} - X_{\text{updated}}]^2)}{\partial k_i} \quad (9)$$

$$\hat{k} = k - \alpha \times g_k \quad (10)$$

$$\text{DI} = \frac{\hat{k} - k}{k} \quad (11)$$

式中: X_{measure} 和 X_{updated} 分别为实测响应和计算响应; k 、 $\hat{k}$ 分别为参数更新前刚度、参数更新后刚度; g_{k_i} 表示第 i 个参数的梯度; α 代表使用的学习率.

通过上述的方式即可在神经网络中建立可训练的结构局部刚度参数,利用误差反向传播算法对由于损伤引起的结构刚度变化进行量化,实现损伤识别,整体的损伤识别流程如图 2 所示.

首先,基于结构实测响应结合卷积神经网络进行荷载识别,之后基于无损结构的刚度、质量、阻尼矩阵对 MERNN 进行初始化,其中部分结构刚度参数作为网络中的可训练参数,网络结合荷载估计值可以计算出结构响应,利用计算结构响应和实测结构响应的差异对可训练参数进行更新,通过更新前后刚度参数的对比即可实现结构损伤量化.

2 数值模拟

采用一个 3 层剪切型钢框架来验证提出的方法,每一层柱的高度为 600 mm,柱的几何尺寸为 4 mm×50 mm,横梁的长度为 800 mm,横梁的几何尺寸为 40 mm×50 mm,框架的钢材的弹性模量为 190 GPa,密度为 7 850 kg/m³,泊松比为 0.3,柱的侧向刚度为 2.815 kN/m,经计算结构的前 3 阶频率分别为: $f_1 = 1.633$ Hz; $f_2 = 3.045$ Hz; $f_3 = 4.201$ Hz

为了验证提出的方法对不同类型的荷载均有良好的效果,按照荷载形式的不同设置了两种不同的




图2 整体架构图

Fig.2 Overall framework of proposed method

工况,具体的工况形式如下:

1) 工况一(周期荷载工况):对底层柱的侧向刚度 k_1 折减 40% 来模拟损伤,即有 $k_1' = 0.6k_1$,在第 3 层梁柱节点处施加周期荷载 $F_1 = c \sin(d\pi t)$,采样频率为 100 Hz,采样时间取 10 s,为生成网络训练用的数据集,通过改变周期荷载的幅值和频率来生成数据,荷载相关参数满足 $c \in [11, 12, \dots, 100]$, $d \in [10, 20, 30, 40, 50]$. 使用第 2 层和第 3 层框架节点的位移响应和外荷载时程作为训练数据,共有 450 个训练样本.

2) 工况二(冲击荷载工况):结构损伤状态与工况一相同,荷载施加位置相同,荷载的大小满足 $F_{\text{impact}} = c \sin(20\pi t)$,冲击荷载的作用时间为第 a 秒到第 $a+0.05$ 秒,采样频率为 100 Hz,采样时间为 10 s,通过改变冲击荷载的大小和作用时间生成数据,荷载相关参数满足 $c \in [11, 12, \dots, 100]$, $a \in [0, 0.1, 0.2, 0.3, 0.4]$. 共有 500 个训练样本,每一条时间序列包含 1 000 个数据点.


通过卷积神经网络可以充分捕捉荷载和结构响应之间的映射关系,对周期荷载和冲击荷载均具有良好的识别效果.周期荷载均方估计误差为 0.009,冲击荷载的均方估计误差为 0.005.

将卷积神经网络识别的荷载和实测结构响应 X_{measure} 一起作为后续 MERNN 损伤识别网络的输入,


3 层框架模型的柱的侧向刚度 k_1, k_2, k_3 作为 MERNN 中可训练的参数,以无损情况下的 3 层框架基准模型的刚度、质量、阻尼矩阵作为网络的初始化参数,结合荷载估计值,损伤识别网络通过对比基准模型计算的响应和实测响应,对神经网络中可训练的柱侧向刚度参数进行更新.

图 3(b)和 3(e)分别展示了结构在进行参数更新前后两类荷载作用下的位移响应情况,在刚度参数更新前,无损结构响应与实测响应之间存在明显的差异,随着参数的更新,损失函数值逐渐减小,计算响应与实测响应之间的差异逐渐变小.通过余弦相似度 SI 来衡量网络训练前后的计算响应与实测响应数据之间的相似度,对工况一而言结构响应相似度 SI 从训练前的 15.67% 提升到 95.62%,对工况二而言相似度 SI 从 1.2% 提升到 97.01%,最终 MERNN 网络中可训练的 3 个参数值即为识别到的真实响应对应的结构刚度参数,通过比较基准模型刚度参数与识别的刚度参数值,按式(11)可计算结构的损伤程度.


由图 3(c)和图 3(f)结果可知,识别到的一层柱的侧向刚度相对于基准模型分别折减了 36% 和 38%,其余各层柱的侧向刚度与基准模型的差异均小于 5%,与实际底层柱损伤 40% 的情况较为吻合,可知 MERNN 可以利用结构时域响应数据有效进行损伤量化.




(a) 工况一周期荷载识别结果




(b) 工况一参数更新前后的第3层节点位移响应对比




(c) 工况一结构损伤识别结果




(d) 工况二冲击荷载识别结果



(e) 工况二参数更新前后的第3层节点位移响应对比



(f) 工况二损伤识别结果



(g) 工况一中损失函数的变化情况

图3 3层剪切型框架荷载和损伤识别结果

Fig.3 Identification results of load and damage detection of three-story frame

3 3层框架试验

为了进一步验证提出方法的有效性,利用实验室的3层钢框架进行研究.如图4所示,框架层高为0.6 m,跨度为0.6 m,柱截面宽度为50 mm,厚度为3 mm,梁单元宽为50 mm,厚度为8 mm,钢密度为7 850 kg/m³,钢的初始弹性模量假设为200 GPa,试

验中利用加速度传感器测量第 3 层、第 2 层梁柱节点在锤击下的加速度响应,利用视频结合视觉分析^[12]获得结构的位移响应.




图 4 试验结构与损伤位置
Fig.4 Experiment structure and damage location

由于初始模型与试验模型存在一定程度的误差,直接进行基于时域数据的模型修正和损伤识别困难较大,故此处先基于采集到的加速度响应进行基于频域的模式修正,通过敲击框架第 3 层右侧梁柱节点,得到的加速度响应如图 5 所示. 利用随机子空间法对获取的加速度数据进行分析,获取结构多阶频率和振型,试验测得的前三阶频率如表 1 所示,将柱的各层刚度作为修正参数,对框架的各层柱侧向刚度进行修正.




图 5 试验中测得的加速度响应
Fig.5 Acceleration response sampled from test

修正前各层柱的侧向刚度均为 1.287 5 kN/m,修正后从上到下的侧向刚度分别为 0.907 6 kN/m、1.281 7 kN/m 和 1.409 0 kN/m. 如表 1 所示,修正后模型的前三阶频率与试验测试值的最大误差仅为 1.55%,修正后模型能较好地反映结构的频域特征.

损伤工况设置在底层柱处,如图 4 所示,利用打磨机将单元切口,柱每侧切口深度为 1 cm,切口高度

表 1 模型修正后框架频率
Tab.1 Frequency of frame after model updating

模态阶数	实测频率/Hz	修正前频率/Hz	修正后频率/Hz	误差/%
1	1.94	2.19	1.97	1.55
2	5.68	5.88	5.65	0.53
3	8.62	8.50	8.62	0.00

为层高的 20%,根据单元截面惯性矩计算公式 $I = bh^3/12$ 可知,截面惯性矩与受弯方向的宽度成正比,损伤后的单元截面惯性矩为未损时的 60%. 此处不考虑结构损伤前后弹性模量的变化,同时为了简化模型,将结构的损伤分配到整个底层左柱上. 已有的研究表明,可以通过最小化损伤均摊前后局部结构刚度矩阵对应的特征值残差来实现刚度的等效^[13],即以式(12)建立目标函数来进行逐步优化. 将损伤分配后,底层左柱的等效宽度为 45.6 mm,即底层左柱的侧向刚度为 $\bar{k}_1 = 0.912k_1$.

$$b' = \min_{\arg \{b'\}} \left[\text{eig} \left(\sum_{i=1}^5 k_{i_before}^e \right) - \text{eig} \left(\sum_{i=1}^5 k_{i_after}^e \right) \right] \quad (12)$$

式中: b' 为等效宽度; $\text{eig}(\cdot)$ 为矩阵的特征值; $k_{i_before}^e$ 与 $k_{i_after}^e$ 分别为等效前后的单元刚度矩阵.




图 6 切口柱的等效侧向刚度
Fig.6 Equivalent lateral stiffness of column with cut

首先利用冲击荷载下的数值模型的位移响应加上部分实测数据训练 CNN 荷载识别网络,训练样本生成方式与第 2 节类似,本例中采样频率取 30 Hz,采样时间取为 20 s,网络的学习率取为 1×10^{-3} ,荷载识别效果如图 7(a)所示,在本算例中,由于仅设置了

单侧损伤,故相对于第2节中的算例,此时将每个柱的侧向刚度作为网络中可训练的参数,损伤识别结果如图7(c)所示.




图7 荷载及损伤识别结果

Fig.7 Result of load and damage identification

由于识别到的荷载和真实荷载的差异、框架模型简化带来的误差,模型参数更新后位移响应依旧与实测响应存在一定的差异,但参数更新后,实测响应与更新后位移响应的相位贴合程度提高,计算位移响应与实测位移响应的相似度SI从27.32%增长

到97.1%. 损伤识别结果表明底层左柱的侧向刚度相对于经过频域模型修正后的侧向刚度基准值折减了8%,其他柱的刚度与基准值的差别均小于4%,与底层柱损伤均摊后的结果近似. 由于CNN网络识别的荷载与实际荷载之间的误差以及学习率等超参数未精细调整等原因,参数更新后模型的响应与实测响应并未完全对齐,因此在损伤识别中引入了部分误差,但该方法仍能有效识别结构的损伤位置和程度.

通过上述算例可知,利用卷积神经网络获得结构的荷载信息后,基于MERNN的损伤识别网络构成了一个基于时域数据的模型嵌入-数据驱动的有限元模型修正模块. 基于神经网络的误差反向传播机制和Tensorflow中的自动微分机制,在模型训练的过程中,会根据模型输出值和目标值显式计算时域响应偏差关于模型可训练参数的梯度,根据式(9)、式(10)可知参数的梯度,可以有效指导模型参数修正的方向,从而有效降低模型输出值的偏差,起到结构响应灵敏度指示模型修正优化方向的效果.

4 结论

本文提出基于MERNN网络的结构损伤识别方法,通过传统的卷积神经网络构建响应与外荷载之间的联系,进而建立模型嵌入循环神经网络进行结构局部刚度参数的更新,通过局部刚度参数的变化来实现损伤量化. 3层剪切型框架损伤识别算例显示,本文提出的方法对周期荷载和冲击荷载均有良好的识别效果,面对结构损伤程度较大的工况,有着良好的损伤识别效果. 本文得到的主要结论如下:

1) 本文提出的方法在荷载识别步中通过网络学习结构响应与荷载之间的映射关系,无须明确的结构参数,且有良好的抗噪性能,可以解决传统荷载识别与损伤识别相互耦合的问题.

2) 基于MERNN的损伤识别网络本质上建立了一种基于时域响应数据的局部刚度参数修正方法,相对于传统基于优化算法和响应灵敏度结合的有限元模型修正方法,该方法通过神经网络的误差反向传播机制可以自动计算误差关于可训练参数的梯度,通过梯度直接指示结构参数的优化方向,该方法在一定程度上可以避免计算结构复杂的响应灵

敏度。

参考文献

- [1] LIN Y Z, NIE Z H, MA H W. Structural damage detection with automatic feature-extraction through deep learning[J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(12): 1025-1046.
- [2] MODARRES C, ASTORGA N, DROGUETT E L, et al. Convolutional neural networks for automated damage recognition and damage type identification[J]. Structural Control and Health Monitoring, 2018, 25(10): e2230.
- [3] SHU J P, ZHANG C G, CHEN X Y, et al. Model-informed deep learning strategy with vision measurement for damage identification of truss structures [J]. Mechanical Systems and Signal Processing, 2023, 196: 110327.
- [4] TENG S, CHEN X D, CHEN G F, et al. Structural damage detection based on transfer learning strategy using digital twins of bridges [J]. Mechanical Systems and Signal Processing, 2023, 191: 110160.
- [5] 李佐强, 翁顺, 朱宏平, 等. 基于领域自适应支持向量机的跨域损伤识别[J]. 建筑钢结构进展, 2023, 25(9): 91-100.
- LI Z Q, WENG S, ZHU H P, et al. Cross-domain damage identification based on domain adaption-support vector machine [J]. Progress in Steel Building Structures, 2023, 25(9): 91-100. (in Chinese)
- [6] ZHU H P, MAO L, WENG S. A sensitivity-based structural damage identification method with unknown input excitation using transmissibility concept [J]. Journal of Sound and Vibration, 2014, 333(26): 7135-7150.
- [7] CHEN Z D, WENG S, YU H, et al. Bayesian-based method for the simultaneous identification of structural damage and moving force[J]. Mechanical Systems and Signal Processing, 2023, 185: 109742.
- [8] GUO X Y, FANG S E. Structural parameter identification using physics-informed neural networks[J]. Measurement, 2023, 220: 113334.
- [9] LI Y X, NI P, SUN L M, et al. A convolutional neural network-based full-field response reconstruction framework with multitype inputs and outputs[J]. Structural Control and Health Monitoring, 2022, 29(7): 1-23.
- [10] LEI X M, SUN L M, XIA Y. Lost data reconstruction for structural health monitoring using deep convolutional generative adversarial networks [J]. Structural Health Monitoring, 2021, 20(4): 2069-2087.
- [11] ROSAFALCO L, MANZONI A, MARIANI S, et al. An autoencoder-based deep learning approach for load identification in structural dynamics[J]. Sensors, 2021, 21(12): 4207.
- [12] 韩建平, 张一恒, 张鸿宇. 基于计算机视觉的振动台试验结构模型位移测量[J]. 地震工程与工程振动, 2019, 39(4): 22-29.
- HAN J P, ZHANG Y H, ZHANG H Y. Displacement measurement of shaking table test structure model based on computer vision [J]. Earthquake Engineering and Engineering Dynamics, 2019, 39(4): 22-29. (in Chinese)
- [13] 左越. 基于贝叶斯概率抽样和灵敏度分析的有限元模型修正方法[D]. 武汉: 华中科技大学, 2016.
- ZUO Y. Bayesian based probabilistic sampling and sensitivity analysis to finite element model updating method [D]. Wuhan: Huazhong University of Science and Technology, 2016. (in Chinese)