

基于 LSTM 神经网络和残余力向量法的 结构损伤识别

宋福春,杨子豪,付聿旻,崔福和,白祥鸽

(沈阳建筑大学交通与测绘工程学院,辽宁 沈阳 110168)

摘要 目的 为减少传统残余力向量法的工作量,提高计算效率,提出一种采用 LSTM 神经网络与残余力向量法相结合方法。方法 以结构损伤后的残余力作为 LSTM 神经网络的损伤识别指标,建立输入与输出之间模型,同时运用分步损伤识别法,对可能存在损伤的结构进行判断,并通过简支梁模型进行验证。结果 LSTM 神经网络对简支梁损伤情况判断较为准确,在样本数为 350 组的情况下,其分类准确率为 97%,训练结果的均方根误差值为 0.64,预测结果的最大误差为 3.7%;噪声水平在 10% 及以下时,最大误差为 6.8%,噪声水平在 15% 及以下时仍可对单损伤做出较为准确的判断,最大误差为 9.4%,抗噪性较好。结论 所设计的基于残余力 LSTM 神经网络对结构损伤定位与程度识别效果较好,具有一定可行性。

关键词 结构损伤识别;LSTM 神经网络;残余力向量法;损伤评估

中图分类号 TU311.4;TP183

文献标志码 A

Structural Damage Recognition Based on LSTM Neural Network and Residual Force Vector Method

SONG Fuchun, YANG Zihao, FU Yumin, CUI Fuhe, BAI Xiangge

(School of Transportation and Geomatics Engineering, Shenyang Jianzhu University, Shenyang, China, 110168)

Abstract: In order to reduce the workload of the traditional residual force vector method and improve the computational efficiency, a combination method using LSTM neural network and residual force vector method is proposed. The residual force of the structure after damage is used as the damage identification index of the LSTM neural network, and a model between input and output is established, while the step-by-step damage identification method is applied to determine the structure that may have damage, which is verified by the simple-supported beam model. The LSTM neural network is more accurate in judging damage of the simple beam, with a classification accuracy of 97%, a root mean square error value of 0.64 for the training results and a maximum error of 3.7% for the prediction results when the sample data is 350 groups; the maximum error is

收稿日期:2022-09-15

基金项目:“十三五”国家重点研发计划重点项目(2018YFC0809600,2018YFC0809606)

作者简介:宋福春(1971—),男,副教授,博士,主要从事桥梁组合结构等方面研究。

6.8% when the noise level is 10% and below, and it can still make a single damage when the noise level is 15% and below. The maximum error is 9.4%, which is a good noise immunity. The designed residual force-based LSTM neural network is effective in localising and identifying the extent of structural damage, and has a certain degree of feasibility.

Key words: structural damage identification; LSTM neural network; residual force vector method; damage assessment

建筑物或构筑物在服役期间,外部荷载长期作用会使其结构造成不同程度的损伤。为保证结构安全,需要及时确定损伤的位置和损伤的程度,以便合理精准评估结构的可靠性^[1]。近年来,学者们对损伤引起的结构动力特性参数及其衍生量变化做了许多研究^[2-4]。基于结构振动学理论,当结构出现损伤时会引起刚度、质量和阻尼等结构物理参数的改变,因频率、振型等结构模态参数是结构物理参数的函数,故损伤也一定会引起结构模态参数的变化,因此多数研究方法采用模态参数作为损伤指标,D. C. Zimmerman 等^[5]提出了残余力向量法的概念。S. W. Doebling 等^[6]提出并改进一种新方法,称为最小秩修正方法(Minimum Rank Element Update, MREU)。

神经网络是一种复杂的多层结构,由众多神经元相互连接而成,具备强大的信息处理和计算能力。常见的神经网络包括 BP 神经网络、RNN 神经网络和 CNN 神经网络等。结构损伤识别可以视为一种模式识别问题,主要分为三个步骤:数据采集、特征提取和特征分类。通过统计或信号处理技术,将数据拟合到测量的结构响应数据中,并选择出损伤敏感的特征值,然后利用选定的特征值对神经网络进行训练,使其能够判断损伤的存在、位置和严重程度。基于神经网络处理复杂信息的能力,该方法在土木工程等相关领域得到广泛应用^[7]。徐长哲等^[8]将信息融合技术与 BP 神经网络相结合,训练后的神经网络对损伤识别的准确率高于 90%。李雪松等^[9]用加速度数据对卷积神经网络进行训练,同时考虑了噪声以及不同荷载作用下的影响,结果表明,该方法能在相对较小的

荷载激励下对损伤进行有效的识别。M. Nobahari 等^[10]将遗传算法与残余力向量法结合,以残余力作为指标确定出损伤所在位置,再用遗传算法计算单元的损伤程度。Z. R. Lu 等^[11]引入残余应变能的概念,结合灵敏度分析的模型更新方法,准确地识别出了损伤的位置和程度。刘济科^[12]、杨秋伟^[13]针对模型缩聚带来的误差,对残余力向量法的计算进行了优化。韦灼彬等^[14]提出虚拟残余力向量的概念,降低了计算误差和噪声的影响。张增军等^[15]以残余力作为目标函数,用遗传算法对损伤系数进行迭代优化,最后通过结果来确定损伤位置与损伤程度。

在此基础上,笔者提出一种以残余力作为 LSTM 神经网络(Long Short Term Memory, LSTM)输入的结构损伤识别方法,残余力可通过结构损伤前的质量矩阵和刚度矩阵以及少量低阶模态参数信息求得,以结构损伤后的残余力作为损伤识别指标,发挥 LSTM 神经网络处理序列数据的能力,针对输入与输出之间复杂关系建立模型,从而对损伤情况进行判断,最后通过一个简支梁模型对其进行验证,结果证明,损伤定位与程度识别效果较好。

1 基本理论

1.1 残余力向量法

依据动力学理论,忽略阻尼的多自由度结构运动方程为

$$M\ddot{x} + Kx = 0. \tag{1}$$

式中: M 为无损状态下的结构质量矩阵; K 为无损状态下结构的刚度矩阵; \ddot{x} 为加速度; x 为位移。

相对应的特征值方程为

[K-λ_iM]ϕ_i=0. (2)

式中:λ_i 为无损状态的结构特征值;ϕ_i 为无损状态的结构特征向量。

若结构损伤,对于第 n 阶特征值 λ_{in} 和振型 ϕ_{in},应满足方程:

[(K-ΔK)-λ_iⁿ(M-ΔM)]ϕ_iⁿ=0. (3)

式中:ΔK 为刚度变化矩阵;ΔM 为质量变化矩阵;λ_iⁿ 为损伤状态的结构第 n 阶特征值;ϕ_iⁿ 为损伤状态的结构第 n 阶特征向量。

假设损伤前后质量不变,整理可得残余力向量 R:

R=(K-λ_iⁿM)ϕ_iⁿ=ΔKλⁿ. (4)

1.2 LSTM 神经网络

LSTM 神经网络是循环神经网络(Recurrent Neural Network,RNN)中一个特殊的类型。由 S. Hochreiter 和 J. Schmidhuber^[16] 提出,之后很多学者对其改进。在循环神经网络中,神经元能接受其他神经元和自身的信息,形成具有环路的网络结构,RNN 可以通过反向传播算法按照时间的逆序将误差依次向前传递。但是当输入序列数据较长时,会存在梯度爆炸和消失问题,称为长程依赖问题。因此,研究人员对 RNN 进行了改进,门控机制便是最为有效的一种措施,LSTM 神经网络就是在这个基础上诞生的。RNN 具有简单的记忆功能,其隐状态存储了每一次运行时的历史信息;LSTM 同样依靠内部记忆单元 C_t 用来捕捉和储存特定的信息,从而完成一次循环信息传递,因为记忆单元中保存信息的生命周期要长于短期记忆,但又远远短于长期记忆,因此称为长短期记忆。

LSTM 网络在 RNN 的基础上引入门控机制(Gating Mechanism),从而提高了简单循环神经元的记忆能力,将“门”引入到单元中,通过三个“门”,用以保护和控制单元状态,这三个“门”分别为

①遗忘门 f_t,使记忆单元进行对前一时

f_t=σ(W_{xf}x_t+W_{hf}h_{t-1}+b_f). (5)

②输入门 i_t,对正在运行的记忆单元进行信息更新和储存:

i_t=σ(W_{xi}x_t+W_{hi}h_{t-1}+b_i). (6)

③输出门 O_t,控制当前时刻记忆单元并将信息输出到 h_t:

O_t=σ(W_{xo}x_t+W_{ho}h_{t-1}+b_o). (7)

C_t=C_{t-1}f_t+C_ti_t. (8)

h_t=O_ttanh(C_t). (9)

式中所有 σ 层的激活函数为 Sigmoid 函数,输出范围为(0,1)。当输出值为 0 时,记忆单元将对历史信息全部进行清理;当输出值为 1 时,记忆单元将对历史信息进行完整保留。tanh 激活函数的输出范围为(-1,1),W 和 h 为权重和偏置,随网络运行不断进行更新,直至训练目标实现后终止。

图 1 为 LSTM 神经网络的循环单元结构简图。循环单元读取上一个神经元细胞输出的外部状态向量 h_{t-1}和当前神经元的输入向量 x_t,遗忘门将读取的信息进行处理,该层将对无关信息进行遗忘。读取的信息同时也会进入输入门中,这时会创建一个备选状态 C_t,这一层决定哪些信息应该加入到新的细胞状态中去。上述过程计算结束后,用遗忘门和输入门的计算结果对当前的记忆单元 C_t 进行更新,最后通过输出门输出当前细胞状态的隐向量 h_t。




图 1 LSTM 神经网络循环单元结构
Fig. 1 The recurrent unit structure of LSTM neural network

1.3 分步损伤识别法

损伤通常发生在结构的局部区域,其余

未损伤区域的刚度和质量几乎不会发生变化,采用子结构分析的方法将整体结构拆分成独立的子结构,将复杂的整体结构问题转化为多个相对简单的子问题,从而更容易进行计算分析,由于子结构的尺寸小于整体结构,将耗时较多的计算和分析限制在局部子结构内,这有助于避免对整体结构进行运算,减少模型分析时间,保证损伤识别高精度的同时提高损伤识别的效率。故采取分步损伤识别法判断结构的损伤情况,具体步骤如下。

第一步,为了定位损伤所在的区域,将结构划分成多个子结构,在建立 LSTM 神经网络模型后,将结构损伤后的残余力作为神经网络的输入,输出即为不同的分类标签。其中向量中每一元素对应一个子结构,当元素值为 1 时,即表示该子结构内可能存在损伤单元;当元素值为 0 时,表示该子结构内无损伤单元,即(1,0,0,0,0)表示第一个子结构内存在损伤,其分类标签记为 1。

第二步,在确定损伤所在子结构后,进一

步确定损伤单元的具体信息。由于受损单元已经确定,避免了从整个结构中搜索的操作,从而可以在一定程度上减轻神经网络的训练负担,这一步仍以结构损伤后的残余力作为输入,输出的数据即为单元的实际损伤程度。

最后,将全部子结构组合成一个完整结构,从而得出整体结构的识别结果。

2 损伤识别验证

2.1 简支梁数值模拟

图 2 为模拟的简支梁结构示意图。梁长 6 m,梁横截面积为 0.15 m²,弹性模量为 200 GPa,体积密度为 7 860 kg/m³。将整梁划分为 20 个单元,预设损伤单元在 2~19 单元,采用刚度折减的方式来模拟损伤情况,定义刚度减小量 5%、10%、15% 分别对应单处损伤、两处损伤、三处损伤时的损伤程度,共 350 组数据。子结构划分如下:单元 1 到 4 为子结构 1,单元 5 到 8 为子结构 2,单元 9 到 12 为子结构 3,单元 13 到 16 为子结构 4,单元 17 到 20 为子结构 5。




图 2 简支梁模型示意图

Fig. 2 The model diagram of simple beam

为了避免模型的记忆功能影响训练效果,将通过模态分析计算得到的 350 组训练样本进行乱序处理。随机选取损伤位置(单元),并在这个单元上随机赋予损伤程度,每种损伤程度各设 3 组,共 9 组损伤工况,用来测试训练好的神经网络的识别能力(见表 1)。

2.1.1 简支梁损伤位置确定

在训练完损伤定位网络后,测试网络的性能。首先将以上待识别工况的模态信息转换成残余力输入到网络中,以分类标签为输出,通过标签来确定具体的损伤子结构。其中单处损伤的分类标签为 1~5;两处损伤分

表 1 简支梁损伤测试工况

Table 1 The damage test conditions of simple beam

损伤工况	损伤位置(单元)	损伤程度(刚度减小)
1	5	5%
2	10	10%
3	15	15%
4	5,10	5%,10%
5	8,15	10%,15%
6	10,15	5%,15%
7	4,7,10	5%,10%,15%
8	7,10,16	15%,15%,10%
9	6,13,17	10%,15%,15%

类标签为 6~15;三处损伤分类标签为 16~25,共有 25 个分类标签。图 3 为简支梁损伤

定位结果。从图3中看出,除第8组工况外,其余8组工况的神经网络实际输出与期望输出一致,第8组工况所识别的结果为第2、3、5子结构,实际的损伤为第2、3、4子结构,除了第三处损伤位置判断错误外,前两处都与实际损伤位置一致。

损伤所在的子结构是有效的。




图3 简支梁损伤定位结果
Fig.3 The damage localization results of simple beam

图4为损伤定位网络训练进度变化结果。从图4中可以看出,所设计网络的预测分类准确率为97%,基本可以正确识别出损伤所在的子结构,可以判断该网络对定位结




图4 损伤定位网络训练进度图
Fig.4 The training progress of impairment localization network

2.1.2 简支梁损伤程度预测

仍以结构损伤后的残余力作为网络的输入,与损伤定位不同,损伤程度中的残余力是损伤定位识别出的子结构的残余力,输出结果为结构的具体损伤程度,将每组损伤工况组合成一个完整结构。图5为简支梁损伤程度预测结果。

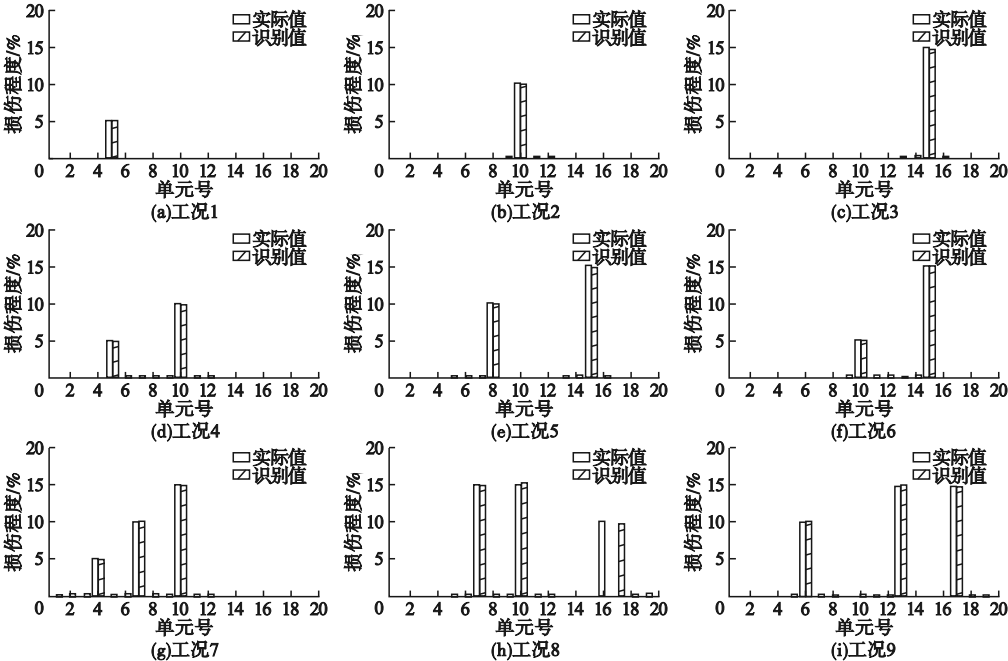


图5 简支梁损伤程度预测结果
Fig.5 The damage prediction results of simple beam

图 5 中,以百分比的形式表示损伤程度,可以看出预测结果较为准确。经计算,最大误差为 3.7%,第 8 组工况的预测结果在数值上与实际情况较为接近,但预测的第三处损伤位置位于 17 单元,实际损伤位置位于 16 单元。除了对第 8 组工况的损伤位置进行了误判之外,其余损伤工况预测结果与实际情况十分接近。

图 6 为损伤程度预测网络训练结果。从图 6 可以看出,最终的均方根误差 (RMSE) 值为 0.64, LSTM 神经网络对损伤程度的判断结果与真实值较为接近,确定该网络可以准确识别损伤程度。




图 6 损伤程度预测网络训练进度图

Fig. 6 The impairment degree of prediction network

2.2 噪声影响

在实际测量过程中会有外界因素的干扰,在真实环境中,噪声很复杂,来源不同,且复合叠加,具有随机性以及正态分布的特性,所以在数值模拟中将外界因素的影响视为正态分布的高斯白噪声。在实际测量中发现,外界因素的噪声水平一般在 5% ~ 17%^[17-18],故噪声水平分别取 5%, 10%, 15%, 20%。对所测数据添加一定水平的高斯白噪声,来模拟噪声的影响,将处理后的模拟数据作为神经网络输入参数,同时考虑不同噪声水平对结果的影响,得到:

$$\phi_{in}^n = \phi_i^n \times (1 + \varepsilon S_n). \tag{10}$$

式中: ϕ_i^n 为损伤后的第 n 阶振型; ϕ_{in}^n 为添加白噪声后的第 n 阶振型; S_n 为第 n 阶振型噪声元素; ε 为噪声水平的大小,分别取 5%, 10%, 15%, 20%。

图 7 为噪声影响下损伤定位结果。




图 7 噪声影响下损伤定位结果

Fig. 7 The damage localization results under the influence of noise

从图 7 中可以看出,在噪声水平为 5% 和 10% 时,定位结果并未受到明显影响,都对工况 8 的损伤情况进行了错误地判断。这说明在较低水平噪声的影响下,神经网络的定位仍保持准确;当噪声水平为 15% 时,多损伤情况下的工况 5、工况 8 和工况 9 都被错误地定位;在噪声水平达到 20% 时,多损伤情况下的工况 4、工况 6、工况 8 和工况 9 均被误判。这表明随着噪声水平的上升,特别是在存在多个损伤情况下,损伤定位的准确性开始下降。

随着噪声水平的增强和损伤位置的增多,损伤定位的效果进一步降低。尽管在高噪声环境下和多损伤情况下,损伤定位的效果有所降低,但对于单一损伤的情况仍然能够准确判断。这表明神经网络在单处损伤识别方面具有一定的抗噪性能。

图 8 为不同程度噪声影响下的各测试工况识别结果与实际情况的对比图。从图 8 的分析中可以得出以下结果:在噪声水平为 5% 和 10% 的情况下,神经网络仍然能够准确判断损伤的程度。经过计算,最大误差仅

为6.8%,在一定程度上噪声下,神经网络的识别能力仍然可靠。当噪声水平增加到15%时,尽管神经网络能够正确定位损伤所在的子结构,但是在具体损伤位置和程度方面存在一定的差距。通过计算,可以得出最大误差为21.4%。这表明随着噪声的增加,神经网络的精确性受到了一定程度的影响。当噪声水平达到20%时,神经网络对损伤所在的子结构判断变得不再准确,不仅在损伤位置方面存在更多误判,而且对损伤程度的识别误差也进一步扩大,在识别位置与实际损伤位置一致的前提下,最大误差高达

35.7%。这清楚地表明了随着噪声水平的加大,神经网络的识别能力逐渐下降。

综合分析可得,当噪声水平在15%及以下时,所设计的神经网络仍然能够对单处损伤状况做出相对准确的判断,最大误差为9.4%。然而,当结构出现多个损伤位置时,噪声的干扰影响变得更加显著,导致无法准确地判断出损伤位置和损伤程度。这进一步表明了噪声对于多损伤情况下损伤识别的不利影响。这需要在实际应用中加以考虑,要进一步的对神经网络进行优化以提高其鲁棒性。

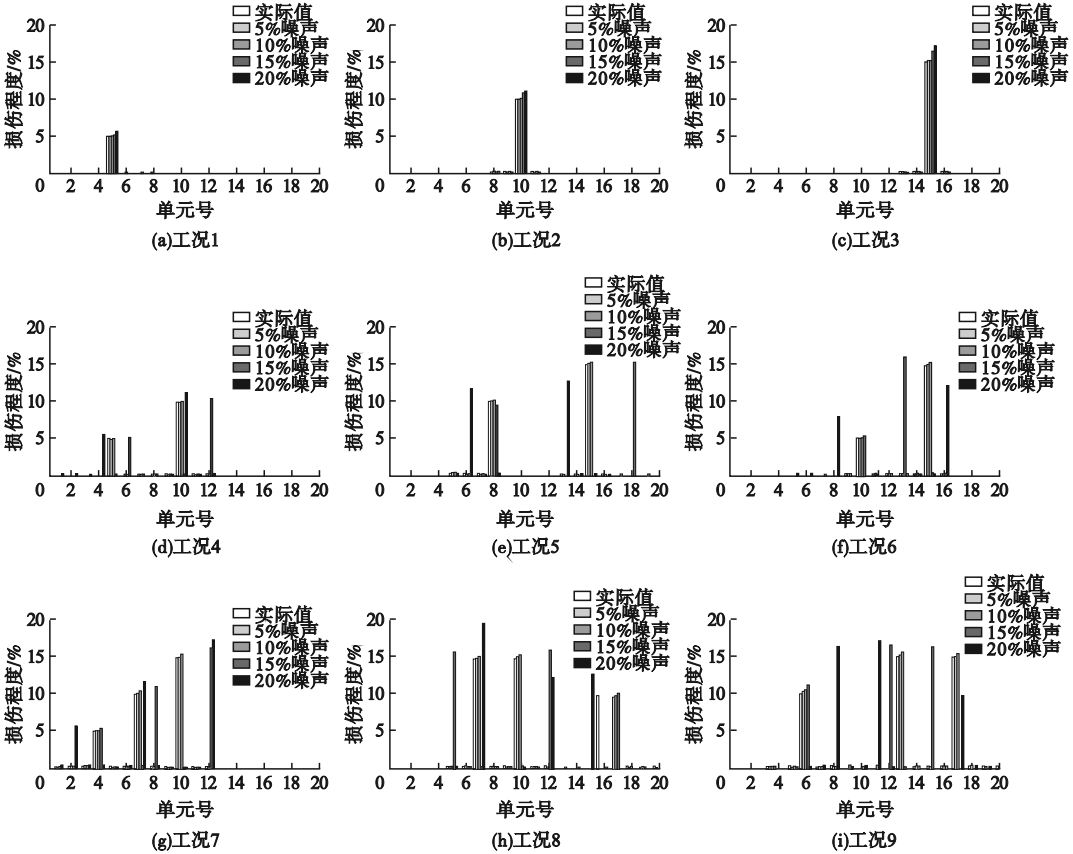


图8 噪声影响下损伤程度预测结果

Fig. 8 The prediction results of damage degree under the influence of noise

3 结 论

(1)将结构受损后的残余力作为损伤识别指标,具有一定的敏感性,结合 LSTM 神经网络可对结构的损伤位置以及损伤程度进

行精准识别。

(2)在样本数为350组的情况下选取9种工况并对其添加噪声进行测试,损伤子结构的预测分类准确率达97%,均方根误差为0.64,最大预测误差仅为3.7%,在噪声水平

低于 10% 时适用性强,能准确判断损伤位置和程度,最大误差 6.8%,具备一定鲁棒性和抗噪性,针对误判单元可采取增加训练样本方法以减少误判率。

(3) 将该方法应用到结构损伤识别领域效果较好,可推广到类似研究领域,具有一定的工程应用潜力,可以降低人力成本和维修成本。

参考文献

- [1] 李惠,鲍跃全,李顺龙,等. 结构健康监测数据科学与工程[J]. 工程力学,2015,32(8):1-7.
(LI Hui, BAO Yuequan, LI Shunlong, et al. Data science and engineering for structural health monitoring [J]. Engineering mechaics, 2015, 3(8):1-7.)
- [2] 朱宏平,余璟,张俊兵. 结构损伤动力检测与健康监测研究现状与展望[J]. 工程力学,2011,28(2):1-11.
(ZHU Hongping, YU Jing, ZHANG Junbing. A summary review and advantages of vibration-based damage identification methods in structural health monitoring [J]. Engineering mechanics, 2011, 28(2):1-11.)
- [3] 赵一男,公茂盛,杨游. 结构损伤识别方法研究综述[J]. 世界地震工程,2020,36(2):73-84.
(ZHAO Yi'nan, GONG Maosheng, YANG You. A review of structural damage identification methods [J]. World earthquake engineering, 2020, 36(2):73-84.)
- [4] 单德山,罗凌峰,李乔. 桥梁健康监测 2019 年度研究进展[J]. 土木与环境工程学报(中英文),2021(增刊1):129-134.
(SHAN Deshan, LUO Lingfeng, LI Qiao. State-of-the-art review of the bridge health monitoring in 2019 [J]. Journal of civil and environmental engineering, 2021(S1):129-134.)
- [5] ZIMMERMAN D C, KAOUK M. Eigenstructure assignment approach for structural damage detection [J]. AIAA journal, 1992(7):1848-1855.
- [6] DOEBLING S W. Minimum-rank optimal update of elemental stiffness parameters for structural damage identification [J]. AIAA journal, 1996, 34(12):2615-2621.
- [7] 杜德润,仇德伦,李爱群,等. 神经网络技术在土木结构健康监测中的应用[J]. 无损检测,2004,26(8):383-387.
(DU Derun, QIU Delun, LI Aiqun, et al. Application of artificial neural network on structural health monitoring in civil engineering [J]. Nondestructive testing, 2004, 26(8):383-387.)
- [8] 徐长哲,余庆林,杨青松. 基于 BP 神经网络的结构损伤识别技术[J]. 应用科技,2020,47(3):63-68.
(XU Changzhe, YU Qinglin, YANG Qingsong. Structural damage identification technology based on BP neural network [J]. Applied science and technology, 2020, 47(3):63-68.)
- [9] 李雪松,马宏伟,林逸洲. 基于卷积神经网络的结构损伤识别[J]. 振动与冲击,2019,38(1):159-167.
(LI Xuesong, MA Hongwei, LIN Yizhou. Structural damage identification based on convolutional neural network [J]. Journal of vibration and shock, 2019, 38(1):159-167.)
- [10] NOBAHARI M, GHASEMI M R, SHABAKHTY N. Truss structure damage identification using residual force vector and genetic algorithm [J]. Steel & composite structures, 2017, 25(4):485-496.
- [11] LU Z R, ZHU J J, OU Y J. Structural damage identification using incomplete static displacement measurement [J]. Structural engineering & mechanics, 2017, 63(2):251-257.
- [12] 刘济科,杨秋伟. 基于残余力向量的结构损伤识别两步法[J]. 中山大学学报(自然科学版),2004,43(4):1-4.
(LIU Jike, YANG Qiuwei. A two-step method for structural damage identification based on residual force vector [J]. Acta scientiarum naturalium universitatis sunyatseni, 2004, 43(4):1-4.)
- [13] 杨秋伟,刘济科. 损伤识别一种改进的残余力向量法[J]. 固体力学学报,2006,27(1):83-85.
(YANG Qiuwei, LIU Jike. An improved method for structural damage identification based on residual force vector [J]. Acta mechanica solida sinica, 2006, 27(1):83-85.)
- [14] 韦灼彬,吴森. 基于残余力向量法的结构损伤位置识别[J]. 中外公路,2011,31(1):177-180.
(WEI Zhuobin, WU Sen. Structural damage location identification based on residual force vector [J]. Journal of China and foreign highway, 2011, 31(1):177-180.)
- [15] 张增军,张猛,张子富. 利用残余力概念进行结构损伤识别[J]. 中国铁道科学,2006,27(4):68-70.
(ZHANG Zengjun, ZHANG Meng, ZHANG Zifu. Method for structure damage detection by using the concept of residual forces [J]. China railway science, 2006, 27(4):68-70.)
- [16] HOCHREITER S, SCHMIDHUBER J. Long short-term memory [J]. Neural computation, 1997, 9(8):1735-1780.
- [17] HUANG H B, YI T H, LI H N. Sensor fault diagnosis for structural health monitoring based on statistical hypothesis test and missing variable approach [J]. Journal of aerospace engineering, 2017, 30(2):1-14.
- [18] HERNANDEZ-GARCIA M R, MASRI S F. Application of statistical monitoring using latent-variable techniques for detection of faults in sensor networks [J]. Journal of intelligent material systems and structures, 2013, 25(2):121-136.
(责任编辑:王国业 英文审校:范丽婷)