

基于结构动力特性的结构损伤 深度置信网络分层识别研究

常亮亮¹,姜文恺²,杨汉青³,孙星⁴,何伟³

(1. 许昌市建设投资有限责任公司,河南 许昌 461000; 2. 中铁第四勘察设计院集团有限公司,湖北 武汉 430063;
3. 华北水利水电大学 土木与交通学院,河南 郑州 450045; 4. 中铁十六局集团有限公司,北京 100018)

摘要:为了高效准确地识别结构损伤,将机器学习和智能算法相结合,提出一种基于结构动力特性的结构损伤深度置信网络分层识别方法,分层依次识别损伤位置与损伤程度。为识别损伤位置,利用结构前3阶竖向振动频率和单节点3阶模态位移建立六元向量,以此六元向量作为输入参数,通过深度置信网络识别损伤位置;为识别损伤程度,分别采用前3阶竖向振动固有频率和模态位移或6节点模态曲率差为参数输入深度置信网络识别损伤程度,并以简支梁为模型进行验证。结果表明:识别损伤位置时,即使噪声程度达到10%,仍可准确识别损伤位置;识别损伤程度时,基于6节点模态曲率差的深度置信网络抗噪性强,在15%噪声水平下对损伤程度预测最大相对误差不超过5.08%,均方差为0.4878。与BP神经网络相比,无噪声时,BP神经网络的预测能力优于深度置信网络;相同噪声水平下,深度置信网络的预测能力明显优于BP神经网络,体现了基于结构动力特性的结构损伤深度置信网络分层识别方法鲁棒性强,识别结果精度高。

关键词:深度置信网络;损伤识别;抗噪性;BP神经网络

中图分类号:TU311; TU18; TP183

文献标识码:A

Research on hierarchical identification of structural damage based on dynamic characteristics by deep belief networks

CHANG Liangliang¹, JIANG Wenkai², YANG Hanqing³, SUN Xing⁴, HE Wei³

(1. Xuchang Construction Investment Co., Ltd., Xuchang 461000, China; 2. China Railway Fourth Survey and Design Institute Group Co., Ltd., Wuhan 430063, China; 3. School of Civil Engineering and Transportation, North China University of Water Resources and Electric Power, Zhengzhou 450045, China; 4. China Railway 16th Bureau Group Co., Ltd., Beijing 100018, China)

Abstract: To identify structural damage efficiently and accurately, a hierarchical identification method of structural damage based on structural dynamic characteristics and deep belief network is proposed by combining machine learning with intelligent algorithm, and the damage position and degree are identified in turn. In order to identify the damage location, a 6-element vector is established by using the first three vertical vibration frequencies of the structure and the third modal displacement of a single node, and the damage location is identified by using the 6-element vector as input parameters. To identify the damage degree, the first three natural frequencies and modal displacements of vertical vibration or the 6 nodes modal curvature differences are used as parameters to input the depth confidence network to identify the damage degree. A simple-supported beam is taken as a model to verify it. It is shown that the damage position recognition accuracy can reach 100% even if the noise level reaches 10%. When identifying the damage degree, the deep belief network based on six-node modal curvature difference has strong noise resistance. The maximum relative error of damage degree prediction is less than 5.08% and the mean

收稿日期:2022-10-11; 修回日期:2023-05-17

基金项目:中铁十六局集团科技研发项目(K2020-7B);中铁第四勘察设计院集团科技研究开发项目(2020K161)

作者简介:常亮亮(1984—),男,工程师,主要从事路桥工程研究。E-mail:250684454@qq.com

通讯作者:杨汉青(1992—),男,硕士研究生,主要从事工程结构损伤识别研究。E-mail:1340282173@qq.com

square error is 0.4878 under the noise of 15%. Compared with BP neural network, the prediction ability of BP neural network is better than that of deep belief network when there is no noise. Under the same noise level, the prediction ability of depth belief network is obviously better than that of BP neural network, which shows that the hierarchical identification method of structural damage based on structural dynamic characteristics and deep belief networks has strong robustness and high accuracy of identification results.

Key words: deep belief networks(DBN); damage identification; noise immunity; BP neural network

0 引言

目前绝大多数结构损伤识别方法都是基于振动理论开展的,通过计算结构固有频率^[1-2]和振型^[3-5]等与结构自身特性有关的参数,比较结构损伤前后振动特性的差异,判定和识别结构的损伤情况^[6]。随着对结构损伤识别研究的逐渐深入,人们认识到仅使用结构振动信息的缺陷与局限^[7]。随着由人工神经网络发展而带来的深度学习和人工智能技术的进步,越来越多的学者将结构的振动特性与其结合,对梁结构的损伤情况进行识别。MASRI等^[8],WU等^[9]将神经网络与结构振动特性结合,研究了人工神经网络对有损伤结构的识别能力,该方法存在所需样本数量过多及当样本数量不足时,神经网络不能正常工作的问题。罗超^[10]将加速度响应作为卷积神经网络的输入参数,对有损伤钢梁的单损伤和多损伤工况进行了模拟识别,有较高的识别精度。但是该方法需要预先设定损伤函数大小阈值,且损伤识别结果的精确性与获取训练样本数据的模型精度相关,因此非高精度有限元模型可能导致较大的识别结果偏差。谢祥辉^[11]以加速度和曲率模态为指标,使用堆栈降噪自动编码器对简支梁和连续梁进行了损伤识别。该方法的缺点在于进行训练时,需要对无噪音信号添加噪声以得到损伤信号再输入网络,增加了模型的处理时间,降低了计算效率,影响了识别精度。李帛书^[12]使用径向基于神经网络(radial basis function, RBF)开展了斜拉桥损伤识别研究,建立有限元模型,以低阶曲率模态作为参数输入 RBF 网络,识别出主梁和拉索的损伤。GUO等^[13]以模态曲率差作为输入参数,分别构造 3 个受限玻尔兹曼机进行预训练,随后以一座连续梁桥作为研究对象,使用深度置信网络(deep belief network, DBN)识别其损伤情况,取得了良好的效果。因此,基于曲率模态与神经网络识别损伤方法是可行的,但由于实际工程中结构曲率模态无法直接测试得到,因而影响了方法的应用。徐秀丽等^[14]将声发射技术与深度置信网络结合,以声发射信号作为网络的输入参数,揭示了结构的损伤演化过程,识别了损伤程度。TENG等^[15]提出了一种使用深度学习算法和数字图像相关性的结构损伤识别方法,使用数字图像相关性方法获取兴趣点(point of interest, POI),将其与卷积神经网络结合,准确识别了结构损伤,计算性能和准确率高于 BP 神经网络。可以看出,现有研究显示运用机器学习或智能算法进行结构损伤识别的优势,但较少研究综合运用结构动力特性与深度置信网络的结构损伤识别方法。

本文将机器学习和智能算法相结合,提出基于结构动力特性的结构损伤深度置信网络分层识别方法,探讨深度置信网络在结构损伤识别方面的应用。

1 深度置信网络简介

深度置信网络^[16]是一种由人工神经网络发展而来的,以受限玻尔兹曼机(restricted Boltzman machine, RBM)为基本组成结构的一种深度神经网络。

1.1 受限玻尔兹曼机

受限玻尔兹曼机^[17]是在波尔兹曼机的基础上提出的一种随机神经网络,结构模型如图 1 所示。RBM 有可见层和隐藏层 2 层神经元,每个神经元随机取二进制数据 0 或 1,分别表示神经元的未激活与激活状态,由概率统计法则确定。由图 1 可知,RBM 同一层神经元之间无连接,可见层和隐藏层的神经元之间全连接,其连接方式使得 RBM 具有良好的性质^[18],当可见




图 1 RBM 结构模型图

Fig. 1 RBM structural model diagram

层神经元的激活状态确定时,隐藏层各个神经元的激活状态相互独立,反之亦然。RBM 是典型的无监督学习,在 DBN 中被当做特征提取器使用,被用来提取特征,对可见层进行重构。

图 1 中, v 和 h 分别为可见层和隐藏层; m 为可见层 v 中神经元的数量; n 为隐藏层 h 中神经元的数量; v_1, v_2, \dots, v_m 为可见层中的神经元; h_1, h_2, \dots, h_n 为隐藏层中的神经元,激活时取 1,未激活时取 0; b 和 c 分别为可见层和隐藏层的偏置值;分别用向量 $\mathbf{b} = (b_1, b_2, \dots, b_1, \dots, b_m)^T$, $\mathbf{c} = (c_1, c_2, \dots, c_j, \dots, c_n)^T$ 来表示可见层和隐藏层中神经元的偏置值。 \mathbf{W} 表示可见层和隐藏层之间的连接权重矩阵,具体表示形式如式(1)所示:

$$\mathbf{W} = \begin{bmatrix} w_{11} & w_{12} & \cdots & w_{1i} & \cdots & w_{1m} \\ w_{21} & w_{22} & \cdots & w_{2i} & \cdots & w_{2m} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ w_{j1} & w_{j2} & \cdots & w_{ji} & \cdots & w_{jm} \\ \vdots & \vdots & \ddots & \vdots & \ddots & \vdots \\ w_{n1} & w_{n2} & \cdots & w_{ni} & \cdots & w_{nm} \end{bmatrix} \quad (1)$$

RBM 模型是一个基于能量的模型,任何一种状态都对应一个能量。对图 1 所示模型,若可见层 v 和隐藏层 h 的状态都确定,那么对于这样一个由 v 和 h 共同组成的状态,RBM 模型所具有的能量 E 为

$$E(\mathbf{v}, \mathbf{h} | \theta) = - \sum_{i=1}^m a_i v_i - \sum_{j=1}^n b_j h_j - \sum_{i=1}^m \sum_{j=1}^n h_j w_{ji} v_i \quad (2)$$

式中: θ 为模型中的 b, c, W 这 3 个参数;向量 $\mathbf{v} = (v_1, v_2, \dots, v_i, \dots, v_m)^T$;向量 $\mathbf{h} = (h_1, h_2, \dots, h_j, \dots, h_n)^T$ 。

由统计力学可知,式(2)表示的状态的联合分布的概率为

$$P(\mathbf{v}, \mathbf{h} | \theta) = \frac{1}{Z(\theta)} e^{-E(\mathbf{v}, \mathbf{h} | \theta)} \quad (3)$$

式中 $Z = \sum_{\mathbf{v}, \mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})}$ 。

对式(3)取边缘分布可以得到可见层 v 和隐藏层 h 的概率分布,其表达式为

$$P(\mathbf{v} | \theta) = \frac{1}{Z(\theta)} \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h} | \theta)} \quad (4)$$

$$P(\mathbf{h} | \theta) = \frac{1}{Z(\theta)} \sum_{\mathbf{v}} e^{-E(\mathbf{v}, \mathbf{h} | \theta)} \quad (5)$$

式(4)、式(5)称为似然函数,式(4)表示输入样本的概率分布。

由上述 RBM 的性质可知,若可见层中所有的神经元状态已知,则隐藏层中神经元 h_j 的激活概率为

$$P(h_j = 1 | \mathbf{v}, \theta) = S\left(c_j + \sum_{i=1}^m w_{ji} v_i\right) \quad (6)$$

同理,当隐藏层中的所有神经元的状态已知时,则可见层中某个神经元 v_i 的激活概率为

$$P(v_i = 1 | \mathbf{h}, \theta) = S\left(b_i + \sum_{j=1}^n w_{ji} h_j\right) \quad (7)$$

式(6)、式(7)中的 S 为 Sigmoid 函数,其表达式为

$$\text{Sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (8)$$

对 RBM 进行训练,确定 θ 中的 3 个参数,以便对训练数据实现拟合,即使式(4)所表示的概率分布可以最大程度地表示输入样本。设有 N 个训练样本,样本集合为 $S = (S_1, S_2, \dots, S_k, \dots, S_N)$,每个样本都含有 m 个数据,样本之间符合独立同分布,式(4)可以表示为

$$L = \prod_{k=1}^N P(S_k) \quad (9)$$

对式(9)等式两边取对数得到对数似然函数,联立式(4)且对 θ 求偏导,应用链式求导法则和贝叶斯公式可得

$$\frac{\partial \ln(L)}{\partial \theta} = \sum_{k=1}^N \left(- \sum_{\mathbf{h}} P(\mathbf{h} | S_k) \frac{\partial E(S_k, \mathbf{h})}{\partial \theta} + \sum_{\mathbf{v}, \mathbf{h}} P(\mathbf{v}, \mathbf{h}) \frac{\partial E(\mathbf{v}, \mathbf{h})}{\partial \theta} \right) \quad (10)$$

对式(10),将 θ 分别取为 b 、 c 、 W ,计算可得

$$\frac{\partial \ln(L)}{\partial b_i} = \sum_{k=1}^N (S_{ki} - \sum_v P(v) v_i) \quad (11)$$

$$\frac{\partial \ln(L)}{\partial c_j} = \sum_{k=1}^N (P(h_j = 1 | S_k) - \sum_v P(v) P(h_j = 1 | v)) \quad (12)$$

$$\frac{\partial \ln(L)}{\partial w_{ji}} = \sum_{k=1}^N (P(h_j = 1 | S_k) S_{ki} - \sum_v P(v) P(h_j = 1 | v) v_i) \quad (13)$$

式中, S_{ki} 为第 k 个样本中的第 i 个数据。

对于式(11)~式(13)中的 $\sum_v P(v) P(h_j = 1 | v)$,采用 Gibbs 采样和 CD-K 算法^[19]($K=1$)可以得到其近似值,分别如式(14)~式(16)所示:

$$\frac{\partial \ln(L)}{\partial b_i} \approx \sum_{k=1}^N (S_{ki}^0 - S_{ki}^1) \quad (14)$$

$$\frac{\partial \ln(L)}{\partial c_i} \approx \sum_{k=1}^N (P(h_j = 1 | S_k^0) - P(h_j = 1 | S_k^1)) \quad (15)$$

$$\frac{\partial \ln(L)}{\partial w_{ji}} \approx \sum_{k=1}^N (P(h_j = 1 | S_k^0) S_{ki}^0 - P(h_j = 1 | S_k^1) S_{ki}^1) \quad (16)$$

式中: S_k^0 为某1个样本,上标0为此样本的初始值,下标 k 为此样本是第 k 个样本; S_{ki}^0 中的下标 ki 为第 k 个样本中的第 i 个数据; S_k^1 为第 k 样本经过 CD-K($K=1$)算法后可见层的第一次重构值。

至此 RBM 完成对输入数据特征提取。

1.2 深度置信网络结构模型

目前常用的深度置信网络结构模型如图2所示。深度置信网络由数个 RBM 堆叠而成,根据具体问题的不同改变最后一层的激活函数以及神经元的个数,可以分别实现分类和预测问题。图2所示的模型中最后一层为 Softmax 激活函数,且输出层单元多于1个,基于该模型可解决分类问题。

DBN 的训练过程分为两步,首先需要对底层的 RBM 进行预训练,预训练是逐层贪婪无监督训练,其目的是得到神经元之间的连接权重和偏置值,使得在训练好的权重和偏置下,RBM 可以更准确、更高精度地提取出训练样本的特征。随后将底层 RBM 的隐藏层作为下一个 RBM 的可见层逐个对 RBM 进行训练,直至完成所有 RBM 的预训练。第二步是在 DBN 的最后一层添加反向传播神经网络,以对整个 DBN 网络进行微调,微调阶段属于有监督学习。




图2 DBN 结构模型图

Fig. 2 DBN structure model diagram

2 结构损伤位置的识别

结构动力特性包括固有频率和振型等。当结构损伤时,其动力特性也会发生相应的变化。本文采用结构的固有频率和振型的组合作为深度置信网络的输入,以损伤位置作为对应的输出,识别结构的损伤位置。

2.1 模型的建立

以长6m的10号工字钢简支梁为例验证本文提出方法的可行性。钢梁横截面如图3所示,其弹性模量取 2.11×10^5 MPa,密度取 7800 kg/m^3 ,泊松比取0.3。采用有限元软件 ANSYS 建立钢梁有限元模型,选用 Beam188 单元模拟钢梁,共划分为20个单元,单元和节点分布如图4、图5所示。




图 3 10号工字钢横截面

Fig.3 Cross section of No.10 I-beam



图 4 单元分布图

Fig.4 Elements distribution diagram




图 5 节点分布图

Fig.5 Nodes distribution diagram

采用对单元的弹性模量进行折减的方式依次模拟每个单元的损伤。假设某个单元的原始弹性模量为 E_u , 损伤后的弹性模量为 E_d , 则该单元的损伤程度为 $1-E_d/E_u$ 。

2.2 样本选取与参数设定

限于篇幅,以梁跨 1/6、2/6、3/6、4/6、5/6 这 5 个位置处的单元为例进行说明,分别对应为 3、6、10、14、17 号单元。损伤程度从 1%~25%,以 1%为增量,则本例共有 125 种损伤工况,每种工况对应一个样本。样本的输入 X 按式(17)所示形式构造六元向量:

$$X = [f_1, f_2, f_3, y_1^{(9)}, y_2^{(9)}, y_3^{(9)}] \tag{17}$$

式中, f 和 y 分别为结构的固有频率和节点模态位移,下标为结构竖向振动的阶数,上标为选取的节点号。

样本的输出 Y 为一个 1×5 的由 0、1 组成的单位列阵。其中 1 对应相应的损伤单元。损伤单元与标签的对应情况如表 1 所示,样本的部分数据如表 2 所示。

表 1 损伤单元与损伤位置标签

Table 1 Labels of damage elements and damage locations

损伤单元号	3	6	10	14	17
输出 Y	(1,0,0,0,0)	(0,1,0,0,0)	(0,0,1,0,0)	(0,0,0,1,0)	(0,0,0,0,1)
标签号	1	2	3	4	5

表 2 部分样本数据

Table 2 Partial sample data

样本	输入 X						标签号
	一阶频率	二阶频率	三阶频率	一阶模态位移	二阶模态位移	三阶模态位移	
1	9.3617	37.177	83.557	0.88946	0.76841	0.08696	5
2	9.3864	37.452	84.276	0.89040	0.77686	0.09625	5
3	9.3130	37.255	84.704	0.88734	-0.78600	-0.10180	4
4	9.3984	37.587	84.639	0.89085	0.78116	0.10094	5
5	9.2589	37.607	83.608	0.88686	-0.77740	0.09508	3

以 2 号样本为例, Y 表示标签 5 对应的单元有损伤,即第 17 号单元有损伤。由于数据之间数值差异较大,为避免数值“淹没”,可以对输入 X 按式(18)进行归一化处理^[8]:

$$x = \frac{x_p - x_{\min}}{x_{\max} - x_{\min}} \quad (18)$$

将上述 125 个样本划分为 100 个训练样本和 25 个测试样本,对 RBM 的预训练与拓展为 BP 神经网络后的 DBN 训练参数分别如表 3 和表 4 所示。

表 3 RBM 训练参数

Table 3 RBM training parameters

迭代次数	批处理数目	学习率	动量	激活函数	输入层单元数	RBM 层数	隐层神经元数目
1000	1	0.01	0.01	Sigmoid	6	1	20

表 4 DBN 训练参数

Table 4 DBN training parameters

迭代次数	批处理数目	学习率	动量	激活函数	输出层神经元数目
1000	1	0.1	0.05	Softmax	5

2.3 结果分析与评价

首先使用 100 个训练样本对网络进行训练,然后将 25 个测试样本输入经过训练的网络可以得到预测值,表 5 中的预测值表示在该样本输入下,预测各个单元的损伤概率,将概率最大值对应的单元作为预测的损伤单元;期望值表示样本的实际输出值,即期望网络对该样本的输出值。对比预测值与期望值判断预测结果正确性。以第一个样本为例,预测的 5 个单元各自损伤的概率分别为(0.000 19,0.000 25,0.000 00,0.999 55),由此可判断第 5 个单元发生损伤。

在上述样本划分、输入特征的选取和参数设定下,DBN 对于 25 个预测样本的识别正确率为 100%。

表 5 部分样本预测结果与期望值

Table 5 Prediction results and expected values of some samples

样本	预测值					期望值					标签
	单元 1	单元 2	单元 3	单元 4	单元 5	单元 1	单元 2	单元 3	单元 4	单元 5	
1	0.000 19	0.000 25	0.000 00	0.000 00	0.999 55	0	0	0	0	1	5
2	0.000 00	0.000 00	1.000 00	0.000 00	0.000 00	0	0	1	0	0	3
3	0.000 00	0.000 03	0.000 00	0.999 96	0.000 00	0	0	0	1	0	4
4	0.000 01	0.000 08	0.000 01	0.999 90	0.000 00	0	0	0	1	0	4
5	0.000 00	0.000 00	1.000 00	0.000 00	0.000 00	0	0	1	0	0	3

2.4 抗噪性研究

在实际工程中进行数据采集时往往会受到噪声的干扰,导致数据失真,因此需要探讨 DBN 的抗噪性。

对于上述样本划分,使用无噪声添加的 100 个训练样本对网络进行训练,在 25 个预测样本中,以式(19)所示形式对式(17)中的参数添加噪声为

$$\tilde{Z} = Z(1 + \varepsilon R) \quad (19)$$

式中: Z 为式(17)中的 6 个参数与无损伤时对应数据的差值; ε 为噪声水平; R 为区间 $[0,1]$ 之间的随机数; \tilde{Z} 为添加噪声后的输入参数。

在噪声程度为 10%时,其中 5 个样本的预测值与期望值的具体数值如表 6 所在,对于 25 个预测样本,DBN 对于损伤位置的预测正确率为 100%,表明该方法具有好的抗噪性。

表 6 10%噪声下部分预测值与期望值

Table 6 Partial predicted values and expected values under 10% noise

样本	预测值					期望值					标签
	单元 1	单元 2	单元 3	单元 4	单元 5	单元 1	单元 2	单元 3	单元 4	单元 5	
1	0.000 16	0.000 10	0.000 03	0.000 00	0.999 71	0	0	0	0	1	5
2	0.999 52	0.000 00	0.000 03	0.000 00	0.000 44	1	0	0	0	0	1
3	0.000 00	0.999 86	0.000 00	0.000 12	0.000 02	0	1	0	0	0	2
4	0.000 19	0.000 07	0.000 03	0.000 00	0.999 72	0	0	0	0	1	5
5	0.000 00	0.000 00	0.000 00	1.000 00	0.000 00	0	0	0	1	0	4

3 结构损伤程度的识别

为识别损伤程度,分别采用前 3 阶竖向振动固有频率和模态位移或 6 个节点模态曲率差构建六元向量,作为深度置信网络的输入,实际损伤程度作为对应的输出来预测结构的损伤程度。

3.1 样本选取与参数设定

对于上节所述工字钢梁模型,对梁跨中(10 号)单元模拟损伤,损伤程度区间取为从 0.2%~25%,以 0.2%为增量,共 125 个样本,对应 125 种损伤工况。

对损伤程度的预测属于回归问题,故样本由输入 X 和标签 Y 两部分组成。

对每个工况提取所需节点第一阶竖向模态位移,经过 2 次差分得到曲率。深度置信网络的样本输入参数 X 分别按照式(17)和式(20)所示形式构造:

$$X = [\Delta\theta_1, \Delta\theta_2, \Delta\theta_3, \Delta\theta_4, \Delta\theta_5, \Delta\theta_6] \tag{20}$$

式中, $\Delta\theta$ 为有损伤工况与无损伤工况的曲率模态差,下标表示取 6 个节点曲率数据,由工字钢梁上除两端节点外等距离选取任意 6 个节点的模态位移得到。

以式(17)和式(20)所示参数分别作为网络的输入时,部分样本数据如表 7 和表 8 所示,样本标签 Y 为 X 所对应的实际损伤程度。

将 125 个样本随机划分为 100 个训练样本和 25 个预测样本,训练参数的设定如表 9 和表 10 所示。

表 7 基于式(17)网络样本数据输入与输出

Table 7 Input and output of network sample data based on formula (17)

样本	输入 X						输出 Y
	一阶频率	二阶频率	三阶频率	一阶模态位移	二阶模态位移	三阶模态位移	
1	9.325	37.619	84.134	0.888 76	-0.779 80	-0.098 64	14.4
2	9.353	37.624	84.362	0.889 58	-0.780 83	-0.100 07	9.6
3	9.367	37.626	84.469	0.889 96	-0.781 31	-0.100 73	7.2
4	9.375	37.628	84.538	0.890 21	-0.781 62	-0.101 15	5.6
5	9.294	37.613	83.884	0.887 86	-0.778 66	-0.097 07	19.2

表 8 基于式(20)网络样本数据输入与输出

Table 8 Input and output of network sample data based on formula (20)

样本	输入 X						输出 Y
	节点 1	节点 2	节点 3	节点 4	节点 5	节点 6	
1	0.002 662	0.002 869	-0.009 998	-0.009 963	0.002 891	0.002 869	8.8
2	0.006 439	0.006 869	-0.023 887	-0.023 963	0.007 002	0.007 091	19.0
3	0.003 439	0.003 646	-0.012 554	-0.012 519	0.003 668	0.003 646	10.8
4	0.005 550	0.005 980	-0.020 776	-0.021 074	0.006 224	0.006 091	17.0
5	0.008 995	0.009 646	-0.033 443	-0.033 852	0.010 113	0.009 646	25.0

表 9 RBM 训练参数

Table 9 RBM training parameters

迭代次数	批处理数目	学习率	动量	激活函数	输入层单元数	RBM 层数	隐层神经元数目
1 000	1	0.001	0.001	Sigmoid	6	1	30

表 10 DBN 训练参数

Table 10 DBN training parameters

迭代次数	批处理数目	学习率	动量	激活函数	输出层神经元数目
1 000	1	0.1	0	Linear	1

3.2 结果分析与评价

与损伤位置的识别相同,首先使用 100 个训练样本训练网络,随后将 25 个预测样本输入网络进行预测。

以式(17)和式(20)分别作为输入参数式,25个样本的预测结果如图6和图7所示,均方差分别为0.0105和0.0072,可以看出,以上述2种参数作为DBN的输入均能对损伤程度进行精确地预测。




图6 基于式(17)样本预测结果

Fig. 6 Sample prediction results based on formula (17)




图7 基于式(20)样本预测结果

Fig. 7 Sample prediction results based on formula (20)

以图7中前5个样本的具体数据及其误差为例,对预测效果进行进一步说明。

由表11可知,以式(20)作为输入参数时,预测绝对误差最大仅为0.38%,但除样本3外,相对误差最大为-0.435%。样本3相对误差较大,一方面是由于该样本实际损伤程度小,仅为0.2%,另一方面是该样本所对应的实际损伤程度为样本区间的下限。

表11 部分样本预测值、期望值及其误差

Table 11 Predicted values, expected values and errors of partial samples %

样本	预测值	期望值	绝对误差	相对误差
1	22.00	22.00	0.00	-0.00
2	19.07	19.00	0.07	0.39
3	0.58	0.20	0.38	191.05
4	24.10	24.20	-0.10	-0.43
5	12.44	12.40	0.04	0.29

3.3 抗噪性研究

在上述研究的基础上,对输入参数按式(19)添加噪声,与损伤位置的识别中的抗噪性研究相同,仅在预测样本上添加噪声。

当以式(17)作为输入参数时,在其中频率和模态位移上分别施加0.1%和1%程度的噪声,预测结果如图(8)所示。

图8所示的均方差为94.2398,可以看出,在极小程度的噪声下,该参数就已经无法对损伤程度进行准确的预测。说明考虑噪音影响时,基于结构振动频率与模态位移的深度置信网络不能识别结构损伤程度。

在式(20)所示参数上施加噪声,噪声水平 ε 依次取为5%、10%、15%,预测结果分别如图9、图10、图11所示,均方差分别为0.0559、0.1640、0.4878。




图8 含噪声时基于式(17)样本预测结果

Fig. 8 Sample prediction results based on formula (17) in noise condition




图9 5%噪声下DBN的预测值与期望值

Fig. 9 Predicted values and expected values of DBN in 5% noise condition




图 10 10%噪声下 DBN 的预测值与期望值
Fig. 10 Predicted values and expected values of DBN in 10% noise condition




图 11 15%噪声下 DBN 的预测值与期望值
Fig. 11 Predicted values and expected values of DBN in 15% noise condition

由图 9~图 11 可知,预测值与期望值之间规律一致,吻合较好。但随着噪声水平的逐渐增加,预测值与期望值之间的偏差逐渐增大。

由表 12 可知,对于损伤程度为 12% 的样本,随着噪声程度的增加,绝对误差和相对误差均随之增大,在 10% 的噪声下,相对误差为 -1.00%,由此可见,使用 DBN 对损伤程度进行预测时,具有很好的抗噪能力,即使在 15% 噪声水平下预测样本对损伤程度预测最大相对误差不超过 5.08%,说明考虑噪声影响时,基于测点曲率模态差的深度置信网络也能较好地识别结构损伤程度,鲁棒性好。

表 12 12%损伤程度在不同水平噪声下预测结果

Table 12 Prediction results of 12% damage degree under different levels of noise %

噪声水平	预测值	绝对误差	相对误差
无噪声	11.98	-0.02	-0.17
5	12.05	0.05	0.42
10	11.89	-0.12	-1.00
15	12.61	0.61	5.08

3.4 DBN 与 BP 神经网络对比

以式(12)作为 DBN 的输入参数,在与 DBN 相同的参数设置下,使用 BP 神经网络对结构的损伤程度进行预测,在不同噪声水平下的预测结果如图 12~图 14 所示,以全体预测样本的均方差作为预测能力的评价标准,DBN 和 BP 神经网络对损伤程度的预测结果对比如表 13 所示。

分别将图 9~图 11 和图 12~图 14 做比较,结合表 13 可以看出,在无噪声时,对于 25 个预测样本,BP 神经网络的预测能力要优于深度置信网络,其均方差为 0.0003,而在应用深度置信网络时均方差为 0.0072。但当存在噪声时,在相同噪声水平下,深度置信网络的预测能力要明显优于 BP 神经网络,随着噪声水平的增加,BP 神经网络的预测精度明显降低,当噪声水平为 10% 时,BP 神经网络的均方差为 0.6537, DBN 的均方差为 0.164,而使用 DBN 时噪声程度为 15% 时均方差为 0.4878。当噪声水平为 15% 时,BP 神经网络的均方差为 1.1586, DBN 的均方差为 0.4878。考虑噪声影响时 DBN 识别结果稳定性更好。




图 12 5%噪声下 BP 神经网络的预测值与期望值
Fig. 12 Predicted values and expected values of BP neural network in 5% noise condition




图 13 10%噪声下 BP 神经网络的预测值与期望值

Fig. 13 Predicted values and expected values of BP neural network in 10% noise condition




图 14 15%噪声下 BP 神经网络的预测值与期望值

Fig. 14 Predicted values and expected values of BP neural network in 15% noise condition

表 13 DBN 与 BP 神经网络预测结果

Table 13 Prediction results of DBN and BP neural networks

噪声水平/%	均方差	
	BP 神经网络	DBN
无噪声	0.0003	0.0072
5	0.1735	0.0559
10	0.6537	0.1640
15	1.1586	0.4878

4 结论

本文将机器学习和智能算法相结合,提出了一种根据结构动力特性及其变化的基于深度置信网络的结构损伤分层识别方法。以工字钢梁为例验证了该方法的可行性,主要结论如下:

1) 以结构前 3 阶竖向振动频率和单节点 3 阶模态位移作为 DBN 的输入参数时,该方法能准确识别结构的损伤位置;即使添加 10% 程度的噪声,依然能准确识别损伤位置。

2) 以结构前 3 阶竖向振动频率和位移模态的组合参数作为输入,在无噪声时能够精确预测损伤程度;在考虑噪声影响时预测损伤程度精度较低。

3) 以 6 节点曲率模态差作为深度置信网络的输入,无噪声时可以精确预测结构的损伤程度;在噪声程度达到 15% 时仍可以准确预测结构损伤程度。与 BP 神经网络相比,基于结构动力特性的结构损伤深度置信网络分层识别方法识别精度高、抗噪性强、鲁棒性好。

参考文献:

- [1] 吴琪强, 郭帅平, 王钢, 等. 基于固有频率的风力机叶片裂纹精确定位与程度识别[J]. 振动与冲击, 2019, 38(24): 18-27.
WU Qiqiang, GUO Shuaiping, WANG Gang, et al. Accurate location and degree identification of wind turbine blade cracks based on natural frequency[J]. Journal of Vibration and Shock, 2019, 38(24): 18-27. (in Chinese)
- [2] 刘文光, 郭隆清, 贺红林, 等. 基于固有频率的呼吸式裂纹梁损伤识别方法[J]. 中国机械工程, 2017, 28(6): 702-707, 713.
LIU Wenguang, GUO Longqing, HE Honglin, et al. A damage identification method of a breathing cracked beam by natural frequency[J]. China Mechanical Engineering, 2017, 28(6): 702-707, 713. (in Chinese)
- [3] 王盟, 翁顺, 余兴胜, 等. 基于时变模态振型小波变换的结构损伤识别方法[J]. 振动与冲击, 2021, 40(16): 10-19.
WANG Meng, WENG Shun, YU Xingsheng, et al. Structural damage identification based on time-varying modal mode shape of wavelet transformation[J]. Journal of Vibration and Shock, 2021, 40(16): 10-19. (in Chinese)
- [4] 黄民水, 雷勇志. 基于模态参数的结构损伤识别应用综述[J]. 武汉工程大学学报, 2021, 43(4): 417-427.
HUANG Minshui, LEI Yongzhi. Review of structural damage identification methods based on modal parameters[J]. Journal of Wuhan Institute of Technology, 2021, 43(4): 417-427. (in Chinese)
- [5] 康灵果. 基于振型曲率差的损伤识别方法振动台试验[J]. 建筑结构, 2021, 51(增刊 1): 1728-1733.

- KANG Lingguo. Shaking table test of damage identification method based on curvature difference of vibration mode[J]. *Building Structure*, 2021, 51(S1): 1728-1733. (in Chinese)
- [6] 杨秋伟. 基于振动的结构损伤识别方法研究进展[J]. *振动与冲击*, 2007, 26(10): 86-91, 100, 190.
YANG Qiuwei. A review of vibration-based structural damage identification methods[J]. *Journal of Vibration and Shock*, 2007, 26(10): 86-91, 100, 190. (in Chinese)
- [7] 韩大建, 王文东. 基于振动的结构损伤识别方法的近期研究进展[J]. *华南理工大学学报(自然科学版)*, 2003, 31(1): 91-96.
HAN Dajian, WANG Wendong. Overview of vibration-based damage identification methods[J]. *Journal of South China University of Technology (Natural Science)*, 2003, 31(1): 91-96. (in Chinese)
- [8] MASRI S F, NAKAMURA M, CHASSIAKOS A G, et al. Neural network approach to detection of changes in structural parameters[J]. *Journal of Engineering Mechanics*, 1996, 122(4): 350-360
- [9] WU X, GHABOUSSI J, GARRETT J H. Use of neural networks in detection of structural damage[J]. *Computers & Structures*, 1992, 42(4): 649-659.
- [10] 罗超. 卷积神经网络在桥梁损伤识别中的应用研究[D]. 西宁: 青海大学, 2020.
LUO Chao. Application of convolutional neural network in bridge damage identification[D]. Xining: Qinghai University, 2020. (in Chinese)
- [11] 谢祥辉. 基于深度学习理论的桥梁损伤识别研究[D]. 成都: 西南交通大学, 2018.
XIE Xianghui. Research on bridge damage Identification based on deep learning [D]. Chengdu: Southwest Jiaotong University, 2018. (in Chinese)
- [12] 李昂书. 基于优化智能算法与低阶曲率模态的斜拉桥损伤识别[D]. 重庆: 重庆大学, 2019.
LI Boshu. Damage identification of cable-stayed bridges based on optimized intelligent algorithms and low-order curvature modes[D]. Chongqing: Chongqing University, 2019. (in Chinese)
- [13] GUO Q, FENG L, ZHANG R Y, et al. Study of damage identification for bridges based on deep belief network[J]. *Advances in Structural Engineering*, 2020, 23(8): 1562-1572.
- [14] 徐秀丽, 张勇, 李雪红, 等. 基于声发射和深度置信网络的钢筋混凝土梁损伤识别方法研究[J]. *建筑结构学报*, 2018, 39(增刊 2): 400-407.
XU Xiuli, ZHANG Yong, LI Xuehong, et al. Research on damage identification method of reinforced concrete beams based on acoustic emission and depth confidence network[J]. *Journal of Building Structures*, 2018, 39(S2): 400-407. (in Chinese)
- [15] TENG S, CHEN G F. Vibration signal-based structural damage detection through deep learning and digital image correlation[J]. *IOP Conference Series: Earth and Environmental Science*, 2021, 719(2): 022047.
- [16] HINTON G E. Deep belief networks[J]. *Scholarpedia*, 2009, 4(5): 5947.
- [17] HINTON G E. Boltzmann machine[J]. *Scholarpedia*, 2007, 2(5): 68-75.
- [18] FREUND Y, HAUSSLER D. Unsupervised learning of distributions of binary vectors using 2 layer networks[J]. *Advances in Neural Information Processing Systems*, 1991, 4: 912-919.
- [19] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. *Neural Computation*, 2006, 18(7): 1527-1554.