

DOI:10.13409/j.cnki.jdpme.20221010002

基于时频变换和卷积神经网络的结构损伤识别*

李治甫¹, 康帅¹, 王自法^{1,2}, 董正方¹, 赫中营¹

(1. 河南大学土木建筑学院, 河南 开封 475004; 2. 中震科建(广东)防灾减灾研究院有限公司, 广东 韶关 512000)

摘要:为了解决将单传感器时域数据直接作为卷积神经网络(CNN)的输入所引起的损伤识别精度不高的问题,提出基于小波包变换(DWPT)和快速傅里叶变换(FFT)的卷积神经网络识别方法。以短钢梁桥现场试验测得的数据集为例,将单传感器数据样本分别进行DWPT和FFT变换,使用变换后的特征训练1D-CNN网络,训练好的网络测试精度有明显的提升,其识别精度均高于多个传感器数据直接作为输入的识别精度。同时分析了对噪声样本和异源(结构上未曾参与网络训练的传感器)数据的识别情况,结果表明对含噪声样本先进行时频变换再训练网络能显著提升对噪声样本的识别精度,而且能改善训练好的网络难以对异源传感器数据进行识别的问题,最后通过卡塔尔大学看台现场试验数据进一步论证上述结论。

关键词: 损伤识别; 快速傅里叶变换; 小波包变换; 深度学习; CNN

中图分类号: TU391 **文献标识码:** A **文章编号:** 1672-2132(2023)06-1275-09

Structural Damage Identification Based on Time-frequency Transform and Convolutional Neural Network

LI Zhifu¹, KANG Shuai¹, WANG Zifa^{1,2}, DONG Zhengfang¹, HE Zhongying¹

(1. School of Civil Engineering and Architecture of Henan University, Kaifeng 475004, China;

2. Ceakj Adprhexa Inc, Shaoguan 512000, China)

Abstract: To solve the problem of low accuracy in damage identification caused by using single sensor time-domain data directly as input for a convolutional neural network, a convolutional neural network identification method based on wavelet packet transform and fast Fourier transform is proposed. Taking the dataset measured in the field experiment on a short steel bridge as an example, single sensor data samples are transformed using DWPT and FFT respectively, and the transformed data are used to train the 1D-CNN network. The test accuracy of the trained network is obviously improved, and its recognition accuracy is higher than that of multiple sensor data directly as input. At the same time, the recognition of noise samples and data from sensors that have not participated in network training in structure is analyzed. The results show that the time-frequency transformation of noise samples before training the network can significantly improve the recognition accuracy of noise samples, and can improve the problem that the trained network is difficult to identify data from the sensor that have not par-

* 收稿日期:2022-10-12;修回日期:2023-02-10

基金项目:国家自然科学基金面上项目(51978634)、河南省高等学校重点科研项目(21A560005)、河南省自然科学基金项目(222300420415)、甘肃省科技厅重大科技计划项目(19ZD2GA002)资助

作者简介:李治甫(1996—),男,硕士研究生。主要从事抗震研究。E-mail: LZF@henu.edu.cn

通讯作者:康帅(1983—),男,副教授,博士。主要从事抗震研究。E-mail: kangshuai@henu.edu.cn

icipated in network training. Finally, the above conclusions are further demonstrated by test data from the grandstand of Qatar University.

Keywords: damage identification; fast Fourier transform; wavelet packet transform; deep learning; CNN

0 引言

工程结构在服役过程中,由于长期受到外荷载的影响,内部损伤累计到一定程度往往会造成结构的破坏。结构损伤检测的目的就是能尽早识别出结构的异常状态,继而为后续的维修工作提供充足时间,从而把结构损伤所带来的损失降至最低。结构物理参数的改变直接影响结构的振动特性,进而影响测得的振动响应^[1],基于振动的损伤识别通过分析结构的振动响应来识别结构的损伤,是当下土木工程损伤识别领域的研究热点^[2]。但在实际应用中,结构的自振频率容易受到环境因素的影响,相关研究人员会产生经验偏差等问题都会影响到损伤识别的准确性。

随着人工智能和大数据逐渐成为各领域的应用热点,土木工程学科的发展也有了新的机遇^[3]。深度学习模型由于具有较好的泛化能力和适应性,能更好地处理工程中庞大的数据量。其中卷积神经网络(Convolutional Neural Networks, CNN)^[4]是当前深度学习领域中应用最为广泛的网络模型之一。O.Abdeljaber等^[5]提出一种基于自适应CNN的结构损伤识别方法,该方法可以对损伤进行实时的识别和定位。Q.H.Han等^[6]提出了一种基于时域数据和CNN网络的三步识别空间结构螺栓松动位置和严重程度的方法,并使用单层预制网架穹顶验证了该方法的有效性。S.Teng等^[7]使用卷积神经网络和基于数字图像相关测量技术进行损伤识别,实现了较为精准的识别效果。罗雨舟等^[8]对CNN提取特征时的抗噪性和鲁棒性进行分析,发现在不同噪声强度下CNN均能取得良好的识别效果。骆勇鹏等^[9]依据简支梁数值模型使用1D-CNN网络进行了结构损伤识别研究,并采用IABMAS BHM Benchmark数值模型验证了CNN识别结构损伤位置和程度的有效性。骆剑彬等^[10]考虑多传感器的数据融合,将分帧数据作为CNN的输入,该方法能对损伤位置和损伤程度进行精准识别。上述基于卷积神经网络的损伤识别研究都是将原始加速度

响应作为网络的输入,但网络的性能与训练样本形式有着必然的联系,原始加速度响应为时域特征,而将振动的频域特征作为网络输入的损伤识别研究还较少。李书进等^[11]以多层框架结构的振动时域信号和频域信号分别作为CNN输入,发现频域数据作为训练样本能使CNN收敛更快、更稳定。B.J.Zou等^[12]提出基于CNN的加筋板冲击损伤的识别方法,将冲击信号的FFT变换特征作为输入,可以快速准确的识别出损伤的位置和程度。

本文提出基于DWPT和FFT的时频变换来提高1D-CNN识别精度的方法,先将加速度样本进行DWPT变换和FFT变换,使用变换后的数据特征训练1D-CNN网络,对时域和频域两种样本形式作为网络输入的识别效果进行对比。并分析了基于时频变换的CNN识别方法的抗噪性及对异源(同一结构上未曾参与网络训练的传感器)数据样本的识别效果。

1 深度学习理论

1.1 卷积神经网络模型结构

卷积神经网络模型是一种多层非线性前馈神经网络,最初被用于复杂图像的特征识别和提取^[13],具有较好的非线性表达能力,已被广泛应用于语音识别、人脸识别、图像处理、人工智能^[14]。卷积神经网络模型的网络结构如图1所示,主要包括输入层、卷积层、池化层、全连接层和输出层。




图1 卷积神经网络示意

Fig.1 Convolutional neural network diagram

卷积层具有局部感知和参数共享的特点,可以有效降低网络模型的学习复杂度^[15],保证网络计算的稀疏性,大幅度提高计算效率。

卷积层运算如图2所示,输出公式如下所示:

$$y_{out} = f_i [b_{i,j} + \text{Conv}(y_{in}, \omega_{i,j})] \quad (1)$$




图2 一维卷积运算过程

Fig.2 One-dimensional convolution operation process

式中, y_{in}, y_{out} 为卷积层的输入和输出; $w_{i,j}$ 为第 i 层的第 j 个卷积核; $b_{i,j}$ 为第 i 层的第 j 个偏置项; f_i 为第 i 层的激活函数; Conv 为卷积运算函数。

池化层具有汇合信息和降维采样的作用,能有效减小参数量,常用的池化方式有最大池化、均值池化和范数池化^[17]等。图3为最大池化运算示意图,最大池化运算直接在感受野窗口内返回最大值。

全连接层可以整合卷积层或者池化层中具有类别区分性的局部信息^[16],卷积、池化层等将原始




图3 池化运算过程

Fig.3 Pooling operation process




图4 短钢梁桥测试布置

Fig.4 Test layout of the short steel bridge

表1 数据集
Table 1 Dataset

状态	激励次数	样本数
State0	2 073	31 095
State1	1 279	19 185
State2	1 414	21 210
State3	1 362	20 430
State4	1 286	19 290
State5	1 181	17 715
合计	8 595	128 925

表2 1D-CNN网络层设置

Table 2 Settings of the 1D-CNN Network Layer

网络层	参数
输入层	6 000×1
卷积层	5×1*8
池化层	2×1
卷积层	5×1*16
池化层	2×1
全连接层	300
全连接层	6
输出层	1

2.2 基于单传感器和多传感器的损伤识别

本文构建的一维卷积神经网络层设置见表2,

数据特征投射到隐层特征空间后,全连接层则将上层输出的分布式特征映射到样本标记空间。

2 基于1D-CNN的损伤识别研究

2.1 数据集介绍

数据集采用由日本北见工业大学理工学院的Y.Zhang等^[18]进行现场测试实验得到的数据,测量的结构为一座铁路钢梁桥,桥长 $l=6.45$ m,宽 $b=1.994$ m,高 $h=0.775$ m。在桥上5个不同位置处固定附加质量块来模拟实际工程中桥梁结构微小的质量或刚度改变,并在桥的主梁上翼缘表面安装15个加速度计来测量结构的振动信号。实验通过锤击桥梁施加冲击荷载,共有14个激励位置,具体情况如图4所示。每次激励时加速度计采集0.6 s的自由振动的加速度响应,采样频率为10 kHz,因此每次激励从每个加速度计采集到的样本长度为6 000。共构造了6种结构状态,状态0为结构未附加质量块,对应桥梁的无损伤状态,状态1~5分别为不同位置固定附加质量块,对应不同位置的损伤状态。每个结构状态下激励的次数见表1,共记录8 595次激励的数据,每次激励得到15个加速度计记录的样本,因此共得到128 925个样本。

第一、二层卷积核数量设置分别为8和16,并在其后设置一层神经元个数为300的全连接层。为加快网

络收敛,在卷积层后加入BN (Batch Normalization) 层,选用 ReLu 函数作为激活函数。Batchsize 设置为 300, Epochs 设置为 50, 初始学习率为 0.001。

首先将 15 个加速度计的原始数据并行输入到 1D-CNN 中,每个传感器的每个样本作为 1D-CNN 网络每个通道的输入。训练集、验证集和测试集分别为 6 195、1 200、1 200。网络的输入层样本数据形式为 6 000×1×15,分别代表样本的长度、深度和通道个数,15 个传感器全部作为输入训练的网络识别结果为 99.08%,识别效果较为精确。再以单传感器数据分别训练神经网络并测试效果,比较单传感器数据输入和多传感器数据输入的识别效果。单传感器 CNN 的输入层样本数据形式为 6 000×1×1,训练集、验证集、测试集的划分同上。表 3 为单传感器数据单独作为输入的识别结果,15 个单传感器数据单独训练的网络平均测试精度为 97.97%,低于 15 个传感器全部作为输入的识别精度。

表 3 单传感器数据识别精度
Table 3 Recognition accuracy of single sensor data

传感器位置	识别精度/%
1	98.17
2	96.33
3	98.50
4	97.67
5	98.58
6	98.25
7	98.67
8	98.08
9	99.17
10	97.92
11	98.83
12	97.58
13	96.25
14	98.67
15	96.92

结果表明将 15 个传感器数据全部作为网络输入的识别精度较单传感器输入的高。传感器较为均匀的分布在桥梁上,融合 15 个传感器的振动信号能较完整地反映出振动信号中结构的状态信息,因此将全部传感器数据作为网络输入的识别效果一般较单传感器作为输入的好。但布置太多传感器所需成本较高,且通道个数太多会使参数量成倍增加,使训练效率降低。在实际工程应用中不仅要保

证损伤识别的高效率和高精度还要保证损伤识别的经济性,因此有必要对基于单传感器的识别精度的提升方法进行探讨,下文将基于单传感器的 CNN 网络进行研究。

3 小波包分解和 FFT 变换

3.1 时频变换方法

相关文献^[11]表明:频域信息更能直接反映出结构刚度的变化,依据频域数据训练的 CNN 收敛更快、更稳定。为对比将加速度样本的时域和频域特征作为输入的 CNN 在结构损伤识别中的效果,分别对加速度样本进行 DWPT(小波包变换, Multi-signal 1-D wavelet packet transform)和 FFT(快速傅里叶变换, Fast Fourier Transform)变换,将变换后的数据特征输入到 1D-CNN 中。在上文识别实验中 13 号加速度计数据的识别结果最差,下文的识别实验将基于 13 号加速度数据进行研究。

(1)小波包分解

小波变换具有多尺度的特点,可以由粗到细地逐步观察信号,但由于其对高频信号不进行分解,导致其频率分辨率随频率升高而降低^[19]。而小波包变换对信号高频部分也进行分解,是一种更精细的信号变换方式,变换后的信号特征具有更高的频率分辨率,图 5 所示为小波包三级分解的流程图。小波的选取原则有对称性、消失矩、正则性、相似性等,但本文将分解后系数输入到 CNN 网络来进行损伤的分类识别,因此通过 CNN 的识别效果来选取小波类型和确定分解层级,限于篇幅选取过程不进行展开说明。本文采用 sym16 小波对振动信号进行 $n = \text{floor}(\log_2 N)$ 级 DWPT 变换,得到的分解系数长度为 2^n 。




图 5 小波包分解树

Fig.5 Wavelet packet decomposition process

(2)快速傅里叶变换

快速傅里叶变换是离散傅里叶变换(Discrete Fourier Transform, DFT)的快速算法。FFT 将 N 点 DFT 分解成较小点数的 DFT,从而将时域信号快速转换为频域信号,能将信号中蕴含的时域和频

域信息最大化地反映出来。在计算中N点的选取至关重要,过小导致分辨率较低,过大产生额外的计算量,且会导致频谱图畸变。本文将FFT的N点设置为原始数据的长度,保证了频率分辨率和频谱特性,且不需要改变CNN网络的输入层格式。FFT的表达式如下:

$$X(n) = \sum_{k=0}^{N-1} x_0(k) W_N^{nk} \quad (2)$$

$$n = 0, 1, \dots, N-1$$

式中, $W_N = e^{-j\frac{2\pi}{N}}$; n 为时域采样点的序列索引。

图6为本文所使用的原始加速度信号、DWPT变换、FFT变换后的数据特征。

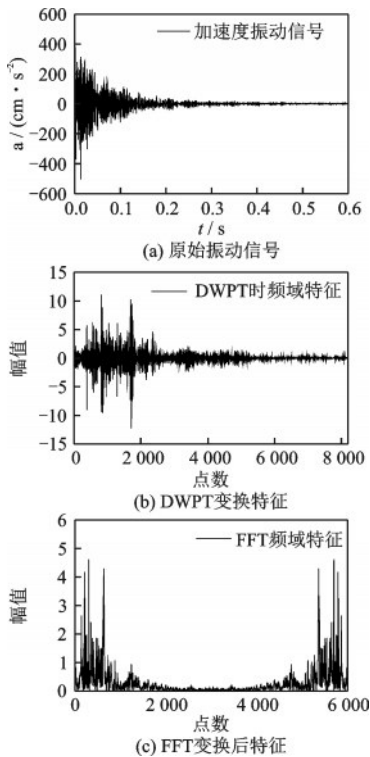


图6 信号特征

Fig.6 Signal characteristics

3.2 识别结果对比

三种形式的数据样本训练CNN时的精度迭代过程如图7所示,从图中可以看出,变换后的特征训练网络时收敛速度也得到了提升。且识别精度也有提升,其中小波包变换后特征作为输入的最终识别精度达到了99.67%,FFT变换后的特征为作为输入的最终识别精度为100%,均高于15个传感器数据全部作为输入的识别精度。

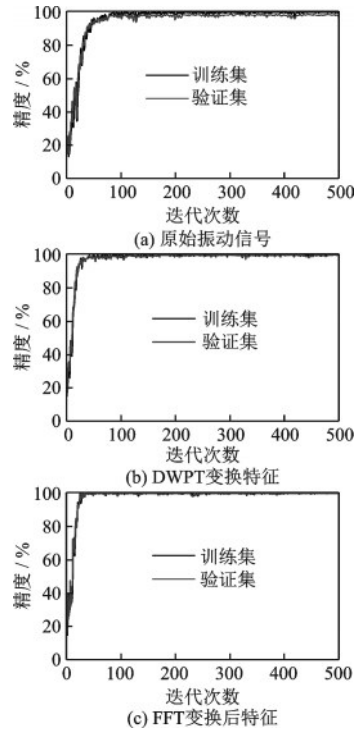


图7 训练精度

Fig.7 Training accuracy

3.3 含噪声信号样本的识别研究

前述实验所使用的数据集都是在相对稳定的情况下测得的,受外界干扰较小。但在实际应用中难免会受到外界影响,使测量的振动信号存在一定的噪声,因此有必要对含噪声样本的识别情况进行探讨。本文通过向信号中叠加不同强度的高斯白噪声来模拟实际工程应用中外界因素对加速度计的干扰,图8为添加不同强度噪声的样本特征,当信噪比为10 dB时,噪声对信号的影响较小,当信噪




图8 含噪声样本特征

Fig.8 Characteristic diagram of noisy samples

比为 1 dB 时噪声对信号特征的影响较为明显。

表 4 噪声样本识别精度

Table 4 Recognition accuracy of noise samples

信噪比/dB	原始样本/%	DWPT样本/%	FFT样本/%
无噪声	96.25	99.67	100.00
10	95.83	99.33	100.00
5	93.08	98.17	99.42
2	89.67	97.42	99.00
1	87.92	95.92	98.42

通过向原始加速度信号中添加信噪比分别为 10、5、2、1 dB 的噪声,用不同噪声水平的信号分别训练并测试 1D-CNN 研究噪声对识别效果的影响,再将加入了不同噪声水平的样本进行 DWPT 和 FFT 变换再分别训练并测试 1D-CNN 来研究两种时频变换方法对识别精度的提升效果,并对两种变换方法的识别效果进行对比。表 4 为 5 种噪声强度影响下,3 种样本形式作为网络输入的识别精度,原始加速度样本作为输入时,随着噪声强度的增长识别精度下降较为明显。而 DWPT 和 FFT 变换后特征作为输入的识别精度相比于变换前均有不同程度的提升,当信噪比为 1 时,DWPT 变换的识别结果为 95.92%,FFT 变换的识别结果为 98.42%,相比于变换之前的 87.92%,分别提升了 8.00% 和 10.50%。图 9 为原始数据样本和两种时频变换后的样本在不同噪声工况下的识别情况,随着噪声强度的提高,识别精度呈现逐渐降低的趋势,但 DWPT 和 FFT 变换的识别精度下降趋势较为缓和。

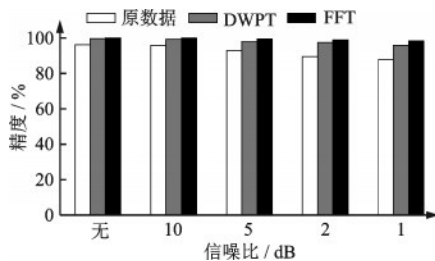


图 9 识别精度

Fig.9 Recognition accuracy

0	112	22	105	53	11	1
1	16	11	34	38	74	8
2	56	17	69	18	14	14
3	43	36	24	56	14	9
4	22	27	18	52	48	13
5	48	10	30	18	26	33
	0	1	2	3	4	5

(a) 原始振动信号

0	296	2		6		
1		180	1			
2	1	9	169	1	7	
3	2	1	4	169	5	
4			1	176	3	
5	3	19	4		12	
	0	1	2	3	4	5

(b) DWPT特征输入

0	296	2		6		
1		180	1			
2	1	9	169	1	7	
3	2	1	4	169	5	
4			1	176	3	
5	3	19	4		12	
	0	1	2	3	4	5

(c) FFT特征输入

图 11 识别混淆矩阵

Fig.11 Confusion matrix for identification

图 10 为两种时频变换方法相比于原始加速度样本对网络识别精度的提升效果,变换样本训练的网络识别精度随着噪声强度的增长提升幅度越来越大。从图 10 和图 11 可以更明显看出 DWPT 和 FFT 变换方法具有较强的抗噪性,且 FFT 变换特征作为输入的抗噪性更强。

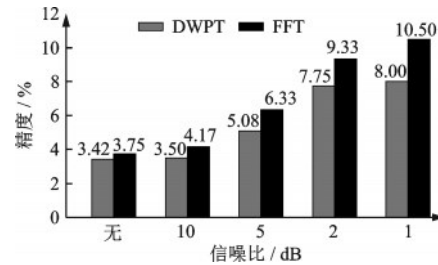


图 10 识别精度提升效果

Fig.10 Improvement effect of recognition accuracy

3.4 异源数据的识别

在以上分析中,训练集、验证集、测试集都是取自同一传感器,但将训练好的网络对未曾参与训练的传感器数据进行测试识别其效果却很差。图 11 (a)为使用 13 号加速度计数据训练的网络对 1 号加速度计数据识别的混淆矩阵,混淆程度较高,识别精度也只有 27.42%,这意味着训练好的网络只能对参与网络训练的传感器数据进行识别。若能实现训练好的网络对结构上任意位置的传感器数据的识别,当实际损伤评估应用中某些位置传感器损伤时,则可利用其它位置传感器数据作为补充,提升了评估系统的安全性。

同一结构上不同位置处的加速度响应虽然有较大差异,但结构各处的振动频率有较高的相似性,因此可以考虑将加速度响应变换为频域特征作为输入进行识别。通过 DWPT 和 FFT 变换后的频域特征作为输入的识别精度都有较大幅度的提升,其混淆矩阵见图 11(b)、(c),混淆程度得到了不同程度的降低,识别结果分别为 56.25% 和 93.08%。

初步表明变换后的频域特征训练的网络对异源数据的识别效果比时域好,且基于FFT变换后的频域特征识别效果最好。

4 基于卡塔尔大学看台模型的验证

4.1 实验介绍

图 12 为卡塔尔大学看台模型的现场装置,模型^[20]为 4.2 m×4.2 m 的钢框架,构造的 30 个损伤位置已在图上一一标注。通过对接头螺栓进行松动来模拟结构的损伤,如图 13 所示,并在每个关节处同时设置加速度计测量结构的振动响应,加速度计的采样率为 1 024 Hz。在每一种损伤工况下,对结构施加白噪声激励,共采集 256 s 的信号,每个信号长度为 262 144。选取 18 号节点的加速度计进行验证研究,把每个损伤工况下的加速度信号划分为以 1 秒为单位的 256 个样本,30 个损伤工况共计得到 7 680 个样本。对数据集进行随机打乱再进行划分,训练集、验证集和测试集的样本数量分别为 5 480、1 100、1 100。




图 12 看台模型试验布置
Fig.12 Test layout of the stand model




图 13 损伤构造方法
Fig.13 Damage construction method

4.2 损伤识别结果分析

从 DWPT 变换和 FFT 变换后特征作为输入的训练过程来看,频域特征训练网络时收敛速度更快,迭代过程更稳定。图 14~16 为三种形式的数据样本作为输入的识别精度图。




图 14 原始数据

Fig.14 Original data




图 15 小波包变换

Fig.15 Wavelet packet transform data




图 16 FFT 变换

Fig.16 Fast Fourier transform data

表 5 为识别结果,两种时频变换样本作为输入的识别精度相比于原始数据作为输入的识别精度有显著的提升,当信噪比为 1 dB 时,DWPT 和 FFT 变换作为输入的识别精度分别提高了 28.09% 和 29.00%。识别结果再次验证了 DWPT 和 FFT 变换能改善网络训练效率,能明显提高网络识别精度。

表 5 识别精度

Table 5 Recognition accuracy			
信噪比/dB	原始样本/%	DWPT 样本/%	FFT 样本/%
无噪声	98.27	100.00	100.00
10	94.09	99.91	100.00
5	84.00	99.73	99.91
2	75.00	99.55	99.64
1	70.36	98.45	99.36

4.3 异源数据的识别

选用 18 号加速度计数据训练网络,1 号加速度计数据测试。分别使用原始加速度数据、DWPT 和

FFT 变换特征作为输入,最终识别结果分别为 12.64%、63.45%、73.18%,识别混淆矩阵如图 17 所示。

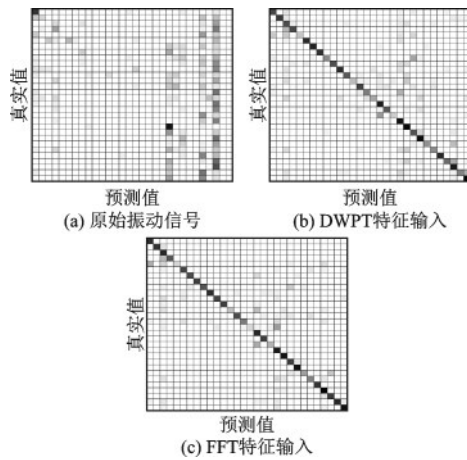


图 17 识别混淆矩阵

Fig.17 Confusion matrix of identification

为了提升对异源数据的识别效果,从 6、8、10、11、13、15、16、18、20 号传感器数据中分别抽取 2 000 个样本数据作为训练和验证集,训练集和验证集数据分别为 15 000 和 3 000,再从 7、9、12、14、17、19 号传感器数据中分别抽取 2 000 个样本依次测试训练好的网络。分别对数据集进行 DWPT 和 FFT 变换,使用变换之后的数据重复上述方案。表 6 为识别结果,DWPT 和 FFT 变换后特征训练的网络对异源数据的识别精度提升较为明显,识别结果较精确。再次验证了时频变换可以提升 CNN 对异源数据识别的效果,且 FFT 变换识别效果最好。

表 6 识别精度

Table 6 Recognition accuracy

传感器 编号	原始 样本/%	DWPT 变换 样本/%	FFT 变换样 本/%
7	71.85	99.90	100.00
9	78.90	99.90	100.00
12	64.90	99.95	100.00
14	60.90	99.90	99.95
17	72.05	99.85	100.00
19	75.25	100.00	100.00

5 结 论

为解决基于单传感器数据作为 CNN 输入识别

精度不高的问题,提出对加速度样本进行 DWPT 变换和 FFT 变换再训练 CNN 的识别方法,依据一铁路钢梁桥的振动试验数据进行了对比分析,最后用卡塔尔看台模型数据对上述结果进行了验证。主要得出以下结论;

(1)将单传感器测得的加速度数据进行 DWPT 和 FFT 变换,使用变换特征训练并测试 CNN 网络,两种变换方法训练的网络识别精度均高于多传感器数据作为输入训练的网络,且收敛速度更快。

(2)基于两种时频变换的 CNN 识别方法对含噪声样本的识别精度提升更为明显,随着噪声强度的增加识别精度的提升幅度越来越大,且 FFT 变换特征作为输入的识别精度最高。

(3)原始加速度样本训练好的网络难以识别未曾参与网络训练的传感器数据,识别效果较差,而 DWPT 变换和 FFT 变换特征训练的 CNN 能显著改善这一问题,FFT 变换特征作为输入的网络对异源数据的识别效果最好。

(4)通过增加训练集传感器数量以及对传感器位置合理的布置,并使用 DWPT 和 FFT 变换后特征训练网络能实现对异源数据精准的识别效果。

参考文献:

- [1] 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):1-11,17. Zhu H P, Yu J, Zhang J B. A summary review and advantages of vibration-based damage identification methods in structural health monitoring[J]. Engineering Mechanics, 2011,28(2): 1-11,17. (in Chinese)
- [2] 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 Q W. A review of vibration-based structural damage identification methods[J]. Journal of Vibration and Shock, 2007,26(10): 86-91,100,190. (in Chinese)
- [3] 鲍跃全,李惠.人工智能时代的土木工程[J].土木工程学报,2019,52(5):1-11. Bao Y Q, Li H. Artificial intelligence for civil engineering[J]. China Civil Engineering Journal, 2019,52(5): 1-11. (in Chinese)
- [4] Le C Y, Bottou L, Bengio Y, et al. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [5] Abdeljaber O, Avci O, Kiranyaz S, et al. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks[J]. Jour-

- nal of Sound & Vibration, 2017, 388: 154-170.
- [6] Han Q H, Pan Y Z, Yang D B, et al. CNN-based bolt loosening identification framework for prefabricated large-span spatial structures [J]. Journal of Civil Structural Health Monitoring, 2022, 12: 517-536.
- [7] Teng S, Chen G. Vibration signal-based structural damage detection through deep learning and digital image correlation [C]// IOP Conference Series: Earth and Environmental Science. China: IOP Publishing Ltd, 2021, 719(2): 022047.
- [8] 罗雨舟, 向天宇, 郝柳青. 卷积神经网络在结构损伤检测中的应用 [J]. 土木工程与管理学报, 2020, 37(3): 155-161, 173.
Luo Y Z, Xiang T Y, Hao L Q. Application of convolutional neural networks in structural damage detection [J]. Journal of Civil Engineering and Management, 2020, 37(3): 155-161, 173. (in Chinese)
- [9] 骆勇鹏, 王林堃, 廖飞宇, 等. 基于一维卷积神经网络的结构损伤识别 [J]. 地震工程与工程振动, 2021, 41(4): 145-156.
Luo Y P, Wang L K, Liao F Y, et al. Vibration-based structural damage identification by 1-dimensional convolutional neural network [J]. Earthquake Engineering and Engineering Dynamics, 2021, 41(4): 145-156. (in Chinese)
- [10] 骆剑彬, 刘越生, 姜绍飞, 等. 基于卷积神经网络和迁移学习的结构损伤识别 [J]. 福州大学学报(自然科学版), 2022, 50(4): 546-552.
Luo J B, Liu Y S, Jiang S F, et al. Structural damage detection based on convolutional neural networks and transfer learning [J]. Journal of Fuzhou University (Natural Science Edition), 2022, 50(4): 546-552. (in Chinese)
- [11] 李书进, 赵源, 孔凡, 等. 卷积神经网络在结构损伤诊断中的应用 [J]. 建筑科学与工程学报, 2020, 37(6): 29-37.
Li S J, Zhao Y, Kong F, et al. Application of convolutional neural networks in structural damage diagnosis [J]. Journal of Building Science and Engineering, 2020, 37(6): 29-37. (in Chinese)
- [12] Zou B J, Li W, Yang N, et al. Impact-induced damage recognition of aluminium alloy stiffened plate structure based on convolutional neural network [J]. IEEE Sensors Journal, 2021, 21(18): 20283-20295.
- [13] 杨铄, 许清风, 王卓琳. 基于卷积神经网络的结构损伤识别研究进展 [J]. 建筑科学与工程学报, 2022, 39(4): 38-57.
Yang S, Xu Q F, Wang Z L. Research progress on structural damage detection based on convolutional neural networks [J]. Journal of Architecture and Engineering, 2022, 39(4): 38-57. (in Chinese)
- [14] 李书进, 熊书琪, 范沛然, 等. 考虑残差学习的深层卷积神经网络在结构损伤识别中的应用研究 [J/OL]. 工业建筑: 1-12 [2022-08-18].
Li S J, Xiong S Q, Fan P R, et al. Application study on deep convolutional neural network considering residual learning in structural damage identification [J/OL]. Industrial Construction: 1-12 [2022-08-18]. (in Chinese)
- [15] 季长清, 高志勇, 秦静, 等. 基于卷积神经网络的图像分类算法综述 [J]. 计算机应用, 2022, 42(4): 1044-1049.
Ji C Q, Gao Z Y, Qin J, et al. Review of image classification algorithms based on convolutional neural network [J]. Journal of Computer Applications, 2022, 42(4): 1044-1049. (in Chinese)
- [16] Meng Z J, Ni B B, Li T, et al. Robust geometric ℓ_p -norm feature pooling for image classification and action recognition [J]. Image & Vision Computing, 2016, 55: 64-76.
- [17] 周飞燕, 金林鹏, 董军. 卷积神经网络研究综述 [J]. 计算机学报, 2017, 40(6): 1229-1251.
Zhou F Y, Jin L P, Dong J. Review of the researches on convolutional neural networks [J]. Chinese Journal of Computer, 2017, 40(6): 1229-1251. (in Chinese)
- [18] Zhang Y, Miyamori Y, Mikami S, et al. Vibration-based structural state identification by a 1-dimensional convolutional neural network [J]. Computer-Aided Civil and Infrastructure Engineering, 2019, 34(9): 822-839.
- [19] 范春昞, 吴守鹏, 刘晓文, 等. 基于小波包变换与随机森林的滚动轴承故障特征分析方法 [J]. 机械设计与制造, 2020, 57(10): 59-63, 70.
Fan C Y, Wu S P, Liu X W, et al. Fault feature analysis method of rolling bearing based on wavelet packet transform and random forest [J]. Machinery Design & Manufacture, 2020, 57(10): 59-63, 70. (in Chinese)
- [20] Abdeljaber O, Avci O, Kiranyaz M S, et al. 1-D CNNs for structural damage detection: Verification on a structural health monitoring benchmark data [J]. Neurocomputing, 2018, 275: 1308-1317.

(本文编辑: 周小潭)