

基于相关函数和卷积神经网络的结构损伤识别

康帅¹, 李治甫¹, 王自法^{1,2}, 董正方¹

(1. 河南大学 土木建筑学院, 河南 开封 475004; 2. 中国地震局工程力学研究所 地震工程与工程振动重点实验室, 黑龙江 哈尔滨 150080)

摘要: 为了改善基于振动信号的结构损伤识别效果, 提出一种基于相关函数和卷积神经网络相结合的结构损伤识别方法。以一铁路钢梁桥结构为例, 首先通过对结构的振动响应进行自相关运算来提高振动信号的信噪比, 再使用自相关样本作为卷积神经网络(convolutional neural network, CNN)的输入可以显著提高其识别精度, 且当振动信号中的噪声水平越高时, 自相关样本作为CNN输入的识别精度的提升效果越明显, 且自相关运算具有比快速傅里叶变换(fast Fourier transform, FFT)更强的抗噪性。使用互相关函数对结构上布置的多传感器的数据进行融合, 再将融合后的信号作为CNN的输入, 互相关在对2个传感器数据特征有效融合的前提下可以成倍地削减数据集的维度, 减少网络运算的参数量, 从而减少用时提高训练效率, 且互相关样本作为网络输入同样具有较高的识别精度和较强的抗噪性。

关键词: 损伤识别; 深度学习; CNN; 自相关; 互相关

中图分类号: TU311; TU18; TP183

文献标识码: A

Structural damage identification based on correlation function and CNN

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

(1. School of Civil Engineering and Architecture, Henan University, Kaifeng 475004, China; 2. Key Laboratory of Earthquake Engineering and Engineering Vibration, Institute of Engineering Mechanics, China Earthquake Administration, Harbin 150080, China)

Abstract: In order to improve the structural damage identification effect based on vibration signal, a structural damage identification method based on the combination of correlation function and convolutional neural network is proposed. Taking a railway steel girder bridge structure as an example, firstly, the signal-to-noise ratio of the vibration signal is improved by performing autocorrelation calculation on the vibration response of the structure, then the autocorrelation sample is used as the input of convolutional neural network, which can significantly improve the recognition accuracy. When the noise level in the vibration signal is higher, the improvement effect of the recognition accuracy of the autocorrelation sample as the convolutional neural network input is more obvious, and the autocorrelation operation has stronger noise immunity than that of the fast Fourier transform. The cross-correlation function is used to fuse the data of the multi-sensors arranged on the structure, then the fused signal is used as the input of the convolutional neural network. Under the premise of effective fusion of the data characteristics of the two sensors, the cross-correlation can double the dimension of the data set and reduce the number of parameters of the network operation, thereby reducing the time and improving the training efficiency, and the cross-correlation sample as the network input also has high recognition accuracy and strong noise immunity.

Key words: damage identification; deep learning; convolutional neural network; autocorrelation; mutual correlation

收稿日期: 2023-02-04; 修回日期: 2023-05-20

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)

作者简介: 康帅(1983—), 男, 副教授, 博士, 主要从事结构抗震研究。E-mail: kangshuai@henu.edu.cn

通讯作者: 李治甫(1996—), 男, 硕士研究生, 主要从事结构抗震研究。E-mail: LZFP@henu.edu.cn

0 引言

传统的基于振动的结构损伤识别的原理是结构物理特性(质量、刚度和阻尼)的改变会影响结构的模态参数,从而引起结构动力响应的改变^[1]。基于振动的损伤识别方法分为参数方法和非参数方法,参数方法通过对模态的变化进行分析来识别结构的损伤,非参数方法则直接从原始振动信号(加速度和位移)中获取结构的状态信息,从而识别结构的损伤。实际应用中模态参数易受损伤以外的因素影响,且频率和振型的测量过程中存在偏差^[2]。而非参数方法相比于参数方法无需人为过多参与计算,更为可靠。

随着计算机和人工智能的发展,深度学习^[3](deep learning, DL)算法在结构损伤识别的研究中取得了很好的成绩。深度学习网络模型通过充分学习结构的振动响应特征可以实现对结构损伤的识别。其中卷积神经网络的局部连接和权值共享等特点,使其具有较好的泛化能力和较高的计算效率,是当下结构损伤识别领域中应用最多的网络模型。多数研究中以加速度响应作为卷积神经网络^[4](convolutional neural network, CNN)的输入。ABDELJABER 等^[5]提出了一种自适应的 CNN 损伤识别方法,该方法能够从原始加速度信号中自动提取损伤特征,实现对振动的损伤实时检测和定位。SONY 等^[6]提出一种基于窗口一维卷积神经网络的全尺寸桥梁振动响应多类损伤识别方法,通过提取原始加速度时间序列的窗口样本来增强测量数据,以缓解训练数据集有限的问题。所提出的窗口 1D-CNN 方法的准确率达到 97%,并且在不同类型的损伤下表现良好。张健飞等^[7]利用结构振动响应的多尺度特征来提升卷积神经网络识别结构损伤的能力,给出 2 种多尺度 CNN 识别方法,具有更高的识别精度和抗噪性。骆勇鹏等^[8]将 1D-CNN 应用于结构损伤识别研究中,以原始加速度响应作为输入,构建的 CNN 能够准确地识别出结构的损伤位置和损伤程度,且具备一定的抗噪性能。

基于 CNN 的结构损伤识别多数以原始振动响应作为输入,使 CNN 充分学习结构的振动特性以达到识别出结构损伤的目的。研究发现输入到网络中的样本形式对网络的性能有较大的影响,通过对加速度样本进行响应处理可以实现更好的识别。COFRE-MARTEL 等^[9]使用结构的传递函数生成的图像作为 CNN 输入来提取结构特征,通过实验数据验证了该方法具有较好的识别效果。CHEN 等^[10]利用环境风振动数据,对某系拱桥索吊架的损伤进行了研究,使用桥面上电缆锚固点处加速度响应的傅里叶振幅谱(Fourier amplitude spectra, FAS)排列为矩阵用作 CNN 的输入。数值结果表明,利用 FAS 数据的 CNN 能够准确地检测损伤位置和损伤程度。DIAO 等^[11]对振动信号进行变分模态分解(variational mode decomposition, VMD),将分解的本征模态函数(intrinsic mode function, IMF)进行希尔伯特变换(Hilbert transform, HT),最后将频谱图作为 CNN 网络的输入,最后使用 2 个实验数据验证了该方法的有效性。MOSCOSO ALCANTARA 等^[12]使用建筑物的单个加速度计测量的加速度的小波谱作为输入,训练 CNN 模型来预测建筑物的损坏信息,所提出的方法具有较强的实用性。综上所述,通过对加速度响应进行相应有效的处理更有利于结构损伤识别效果的改善。

在信号处理研究领域中,由于自相关函数具有较好的周期性和抗噪性,信号可以通过自相关或互相关运算来提高振动信号的信噪比,削减噪声成分^[13]。本文提出基于自相关函数和 CNN 网络的识别方法,使用振动信号的自相关样本作为 CNN 的输入,来提升其识别精度,而且自相关样本具有比 FFT 变换后的频域样本更强的抗噪能力。同时通过对 2 个传感器数据进行互相关运算后可以减少网络输入数据的维度,提升网络训练效率,同样也具有较高的识别精度。

1 卷积神经网络

近年来, CNN 被广泛应用于图像处理^[14],具有独特的局部连接和权值共享特性。不需要输入和输出之间精确的数学表达式,可以有效地学习输入输出之间的非线性映射关系。CNN 主要包括输入层、池化层、全连接层、卷积层和输出层,卷积神经网络的示意图如图 1 所示。

卷积层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,防止网络计算中出现过拟合,有效地提高了计算效率。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,过滤冗余数据而保留重要特征,可以有效地提高计算效率,一定程度上可以防止过拟合。若将卷积层和池化层定义为一个基本单

元,则一般网络中会存在多个卷积池化单元。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],卷积层、池化层等将原始数据特征投射到隐层特征空间后,全连接层将上层输出的分布式特征映射到样本标记空间。




图1 卷积神经网络模型

Fig. 1 CNN model

本文所构建的一维卷积神经网络的结构设置如图2所示,包含2个卷积池化基本单元。为加快网络收敛,在卷积层后加入批量归一化(batch normalization, BN)层^[17],选用 ReLu(rectified linear unit) 函数作为激活函数。Batchsize 设置为 300, Epochs 设置为 50, 初始学习率设置为 0.000 1。




图2 一维卷积神经网络结构设置

Fig. 2 1D-CNN structure setting

2 自相关函数理论介绍

2.1 自相关函数和互相关函数表达式

振动信号的自相关函数为该信号 t 时刻值与 $t+\tau$ 时刻值之间的依赖关系,即变量 $x(t)$ 在 t 时刻和 $t+\tau$ 时刻量值的乘积在观察时刻内的期望值,信号 $x(t)$ 的自相关函数表达式为

$$R_x(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)x(t+\tau) dt \quad (1)$$

式中: τ 为滞后量; T 为动力响应时间。

自相关函数可以更好地反映出信号中的周期成分,因此对信号进行自相关运算可以有效消除信号中的随机噪声,突出振动信号的周期成分^[18]。

实际工程应用中,振动信号的形式总是用有限点数来表示的,即信号的采样点不可能无限多。则离散振动信号 $x(n)$ 的自相关函数则定义为

$$R_x(m) = \sum_{n=-\infty}^{\infty} x(n)x(n+m) \quad (2)$$

互相关函数与自相关函数原理相同,互相关函数描述2个信号在任意2个不同时刻之间的相关程度,在工程实践中又被称为匹配滤波^[19]。 $x(t)$ 、 $y(t)$ 的互相关函数为

$$R_{xy}(\tau) = \lim_{T \rightarrow \infty} \frac{1}{T} \int_0^T x(t)y(t+\tau) dt \quad (3)$$

2个离散的信号 $x(n)$ 和 $y(n)$ 的互相关函数的表达式为

$$R_{xy}(m) = \sum_{n=-\infty}^{\infty} x(n)y(n+m) \quad (4)$$

从式(1)~式(4)可知,自相关函数和互相关函数从原理上并无本质的区别,将互相关函数表达式中的另外一个函数替换成该函数就成了此函数的自相关函数表达式。

2.2 自相关函数性质

自相关函数特殊的性质使其被广泛应用于振动信号处理领域。一方面自相关函数具有实偶性,即 $R_x(-\tau) = R_x(\tau)$,另一方面周期信号的自相关函数同样具有周期性,且周期与原始信号周期相同^[20]。

由于自相关函数可以更加突出振动信号的周期性,抑制非周期性的噪声信号,因此可以对信号进行自相关算法来提高信号的信噪比。一组正弦信号的自相关示意图如图 3 所示,由图 3(a)和(b)可知,正弦信号的自相关函数继承了原始信号的频率特征。添加了信噪比为 10 dB 的高斯白噪声,如图 3(c)所示,其自相关函数图像如图 3(d)所示,从中可以明显观察到,原始信号和含噪声信号的自相关函数具有极为相似的特征。高斯白噪声不具有周期性,因此在自相关算法中得到了衰减,此为自相关函数去噪的原理。

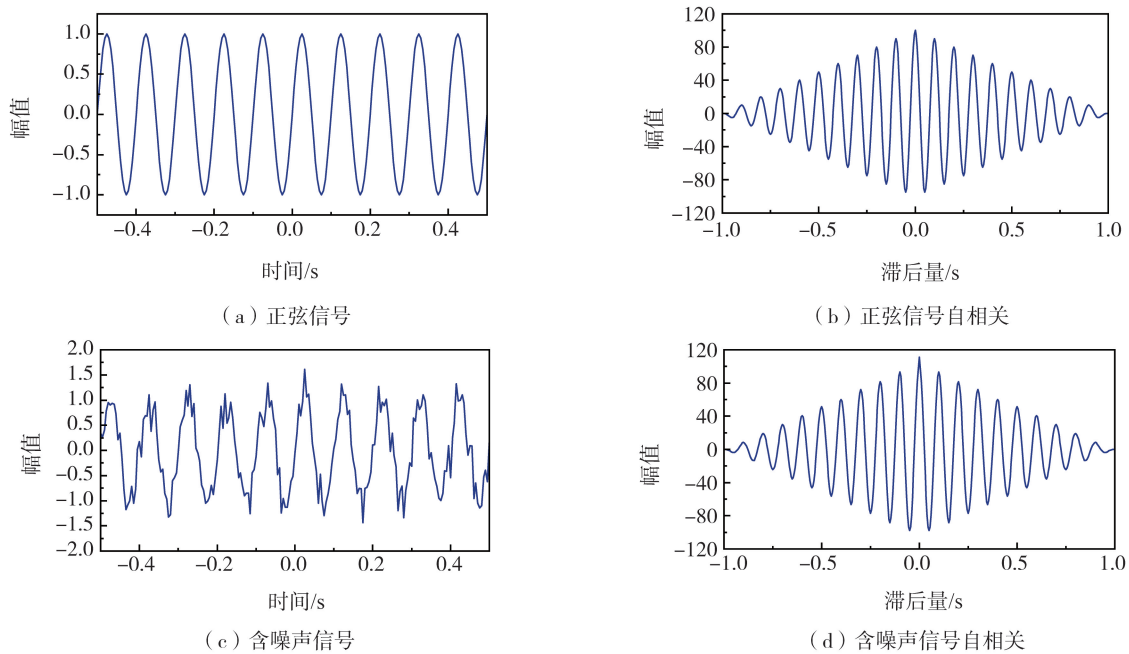


图 3 信号的自相关

Fig. 3 Autocorrelation of signal

3 基于自相关函数和 CNN 的损伤识别

3.1 数据集介绍

数据集采用由 ZHANG 等^[21]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,桥长为 6.45 m,宽为 1.994 m,高为 0.775 m。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,并在桥上 5 个不同位置处固定钢板和附加质量块模拟实际工程中桥梁结构微小的质量或刚度改变。实验通过锤击桥梁施加冲击荷载,共有 14 个激励位置,具体布置情况如图 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数据,采样频率为 10 kHz,因此每条振动信号的样本点数为 6000。




图 4 短钢梁桥测试布置图

Fig. 4 Test layout of short steel bridge

此实验共构造了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~状态5分别为结构上不同位置处固定附加质量块,对应不同位置处的损伤状态。每个结构状态下激励的次数如表1所示,共记录8595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128925个样本。

表1 数据集
Table 1 Data set

样本组成	状态						合计
	状态0	状态1	状态2	状态3	状态4	状态5	
激励次数	2 073	1 279	1 414	1 362	1 286	1 181	8 595
样本数	31 095	19 185	21 210	20 430	19 290	17 715	128 925

3.2 方法介绍

卷积神经网络模型若要实现对结构状态的判断,就需将各个结构状态下对应的振动响应输入到神经网络中进行训练,使神经网络充分学习振动响应与结构状态之间的非线性映射关系。本文引入相关函数算法,结合自相关和互相关函数算法的特点,将振动响应进行相应处理再作为CNN输入。本文所提方法的逻辑流程图如图5所示。

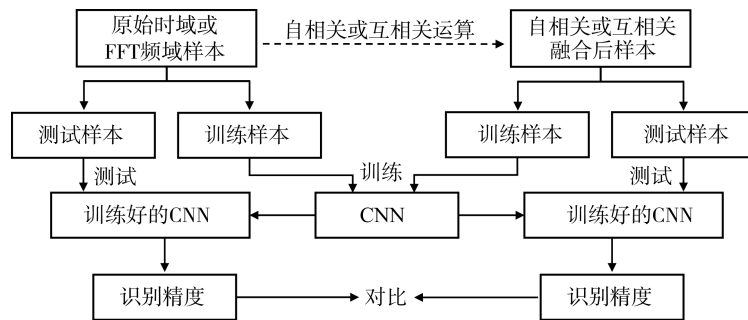


图5 逻辑流程图

Fig.5 Logical flow chart

3.3 损伤识别

从单个加速度计数据的8595个加速度响应样本中抽取6195和1200个分别作为训练集和验证集训练网络,再使用剩余的1200个样本测试训练好的网络。数据样本是长度为6000的一维序列,因此网络输入层形状为 $6000 \times 1 \times 1$ 。经自相关和互相关计算之后是长度为11999的对称序列,取前6000个数据点作为网络输入,网络输入层形状同样为 $6000 \times 1 \times 1$ 。加速度样本的原始特征和自相关特征分别如图6(a)和(b)所示。




图6 样本特征

Fig.6 Sample characteristics

其中每个样本对应一个表示为结构状态的标签,分别为0、1、2、3、4、5。训练网络时,将样本和标签一同输入网络中进行训练。测试网络时只需输入样本,网络模型会为每一个样本生成预测值。再将网络模型对每个测试样本的预测值与样本标签进行对比,由此得到测试集的识别精度。为了消除单个传感器数据单次

训练的偶然性,分别使用 15 个传感器数据进行训练。首先将单个加速度计的样本进行自相关运算,再使用自相关样本训练网络。基于原始样本和自相关样本的识别结果如表 2 所示。

表 2 识别结果

Table 2 Recognition results

样本形式	传感器编号							
	1	2	3	4	5	6	7	8
原始样本	98.17	96.33	98.50	97.67	98.58	98.25	98.67	98.08
自相关样本	99.42	99.75	99.83	99.67	99.75	99.75	99.67	99.75

样本形式	传感器编号							平均
	9	10	11	12	13	14	15	
原始样本	99.17	97.92	98.83	97.58	96.25	98.67	96.92	97.97
自相关样本	99.83	99.83	99.83	99.92	99.92	99.75	100.00	99.78

分别采用 15 个加速度计数据的原始样本训练的网络平均识别精度为 97.97%,对结构状态的评估效果较为精确,论证了基于 CNN 的结构损伤识别方法的可行性。而自相关样本具有比原始样本更高的识别精度,每个传感器数据的识别精度均高于原始样本,平均识别精度达到了 99.78%,初步说明自相关样本作为网络输入可以提升识别精度。

3.4 噪声样本的识别

由于自相关运算具有较强的抗噪性,对含噪声信号进行处理可以有效削减其中的噪声成分。为进一步探究噪声信号的自相关样本作为 CNN 输入时的识别效果,对结构的振动响应添加不同强度的噪声。将添加噪声的样本和它的自相关样本分别作为 CNN 的输入,训练并测试网络,对比 2 种样本的识别效果。选择 13 号传感器数据为本次实验的数据集。

将 4 种不同噪声强度的样本单独划分为训练集、验证集、测试集,分别包含 6 195、1 200、1 200 个样本,4 种噪声样本单独训练并测试网络。再使用 4 种噪声信号的自相关样本训练并测试网络,训练过程中保持相同的网络参数,识别结果如表 3 所示。

表 3 噪声样本的识别精度

Table 3 Identification accuracy of noise samples

样本形式	识别精度/%			
	10 dB 噪声	5 dB 噪声	2 dB 噪声	1 dB 噪声
原始噪声样本	97.17	93.67	90.25	86.75
自相关样本	99.75	99.67	99.33	99.25

噪声信号的自相关样本作为 CNN 输入时的识别精度较原始噪声样本有较大幅度的提升,信噪比从

10 dB 降至 1 dB 时,识别精度仅仅下降了 0.50%,而原始噪声样本作为输入的识别精度下降了 10.42%。信噪比为 1 dB 时,自相关样本作为输入的识别精度依然能达到 99.25%,识别效果较为精确。

3.5 自相关样本和 FFT 样本识别效果对比

前述结果表明振动信号的自相关样本训练的 CNN 具有较好的识别效果,而快速傅里叶变换(FFT)后的频域样本也具有较强的抗噪性^[22]。为了对 2 种形式的样本分别作为 CNN 网络输入时的识别精度进行比较,将含噪信号的自相关样本和 FFT 频域样本单独训练 CNN 网络并测试,识别结果如表 4 所示。

表 4 FFT 样本和自相关样本识别精度对比

Table 4 Comparison of recognition accuracy between FFT and autocorrelation samples

样本形式	识别精度/%				
	无噪声	10 dB 噪声	5 dB 噪声	2 dB 噪声	1 dB 噪声
FFT 变换样本	100.00	100.00	99.42	99.00	98.42
自相关样本	99.92	99.75	99.67	99.33	99.25

没有添加噪声和信噪比为 10 dB 的信号其 FFT 频域样本的识别精度均能达到 100%,略高于自相关样本。结果表明 FFT 样本和自相关样本作为网络输入都可以显著提升 CNN 模型的识别精度,但随着噪声强度的增长,自相关样本的识别精度下降较 FFT 频域样本的慢,识别精度开始高于 FFT 频域样本。

为了消除单个传感器数据以及单次实验的偶然性,对多个传感器测得的数据进行重复实验。选取传感器位置编号为 2、4、6、10、12、14 的 6 个传感器的数据做重复识别实验,分别对原始数据和添加了不同强度噪

声的数据进行 FFT 变换和自相关变换,使用变换后样本训练并测试 CNN 网络。每个传感器数据的具体识别结果如表 5 所示,当使用原始振动信号或信号中噪声能量很低时,FFT 样本的识别精度往往略高于自相关样本或与之相当。而当信噪比小于或等于 5 dB 时,自相关样本的识别精度均高于 FFT 样本的识别精度,且当噪声强度越大,两者的差距也愈大。

表 5 FFT 样本和自相关样本识别精度

Table 5 FFT sample and autocorrelation sample recognition accuracy

传感器编号	样本形式	识别精度/%				
		无噪声	10 dB 噪声	5 dB 噪声	2 dB 噪声	1 dB 噪声
2	自相关	99.92	99.92	99.58	99.33	98.67
	FFT	100.00	100.00	99.42	97.08	96.25
4	自相关	99.92	99.92	99.58	99.08	98.33
	FFT	100.00	99.67	99.33	98.08	96.83
6	自相关	99.83	99.75	99.50	99.50	99.17
	FFT	100.00	99.92	99.75	99.33	98.83
10	自相关	99.92	99.83	99.58	99.42	98.92
	FFT	100.00	99.75	99.42	99.08	97.33
12	自相关	100.00	99.83	99.83	99.08	98.75
	FFT	100.00	99.75	99.58	98.25	97.83
14	自相关	99.83	99.83	99.75	99.58	99.25
	FFT	100.00	100.00	99.75	99.00	98.58

6 个传感器数据的 2 种形式的样本随着噪声强度的增长其平均识别精度的下降趋势图如图 7 所示,当振动信号中不添加噪声或噪声能量占比很小时,FFT 变换后的识别效果较自相关样本好。但随着噪声强度增长到一定程度时,自相关样本的识别精度会高于 FFT 变换样本,自相关样本的下降趋势整体较 FFT 样本缓和。相对来说 FFT 变换更适合处理信噪比较高的数据,而自相关样本更适合处理噪声强度较高的数据。这也说明自相关样本作为输入时受噪声的影响较小,具有较强的抗噪能力。




图 7 平均识别精度对比

Fig. 7 Comparison of average recognition accuracy

4 基于互相关函数和 CNN 的损伤识别

4.1 基于互相关的数据融合

振动响应测试时一般会在结构上设置多个传感器,多个传感器能较充分地表达整个结构的振动特性,更好地对结构的损伤状态进行分析。基于 CNN 的损伤识别使用多个传感器数据并行输入的识别效果同样较单个传感器数据作为输入的好,且多传感器数据并行输入可以较好地克服噪声对识别效果的影响,具有较强的抗噪能力。但选取较多传感器数据作为网络的输入会成倍地增加网络运算的参数量进而影响网络运算的时间。而互相关能将 2 个传感器数据进行融合,可以成倍地减少网络并行运算的通道维度,从而减少网络运算的参数量,缩短网络运算的时间。

为了测试基于互相关函数的损伤识别效果,设置 2 种方案进行对比,第一种是使用双通道 CNN 网络,将 2 个传感器数据并行输入到网络中训练;第二种就是将 2 个传感器同时测量的数据进行互相关融合再输入到单通道 CNN 网络中。为对比 2 种方法的识别效果,选用 1、3、5、7、9、11、13、15 号传感器数据,使用 2 种方法训练并测试网络,对其识别结果进行对比分析。

将 1 号传感器数据分别与 3、5、7、9、11、13、15 号传感器数据进行组合,对比 7 种组合方式的识别结果。7 种组合方式使用 2 种方法得到的识别结果如图 8(a) 所示,互相关融合方式的识别精度均高于双通道,但 7 种组合方式之间的识别精度相差较小,不能从中得出组合方式与识别效果之间的关系。




图 8 识别结果对比

Fig. 8 Comparison of identification results

将 1 个传感器数据与另外 7 个传感器数据进行互相关运算可以得到 7 个数据集,而若将 8 个传感器数据集进行两两互相关就可以得到 4 个互相关样本,数据集维度减至一半。8 个传感器数据中将对称的传感器数据组合得到的识别结果如图 8(b) 所示,2 个数据集互相关融合后的识别精度相比于 2 个数据集并行输入双通道 CNN 均有提升。且因互相关融合后的数据集只需占用 1 个网络通道,所需的训练用时较短。互相关融合的数据集训练用时平均只有 169.75 s,低于双通道 CNN 的 299.25 s。初步说明互相关算法不仅可以 将 2 个数据集维度减半,有效地降低训练过程中的运算量,提高训练效率,而且能够实现较高的识别精度。

4.2 噪声工况的识别效果

基于互相关的数据融合不仅能够减少数据集的维度,还能实现较为精准的识别效果。为了进一步论证互相关融合数据在基于 CNN 的损伤识别中的优势,本节考虑了噪声的影响。以编号为奇数的传感器为研究对象,将融合后的 1&15、3&13、5&11、7&9 这 4 个融合数据集输入到 4 个通道 CNN 模型,并将未融合的 1、3、5、7、9、11、13、15 这 8 个传感器数据集输入 8 个通道 CNN 模型。分别向数据样本中添加 1、2、5、10 dB 的噪声,来进一步探究互相关融合方法的抗噪能力,识别结果如表 6 所示。

表 6 互相关 4 个通道和 8 个通道识别精度对比

Table 6 Comparison of cross-correlation four-channel and eight-channel recognition accuracy

通道数量	对比指标	识别精度				
		无噪声	10 dB 噪声	5 dB 噪声	2 dB 噪声	1 dB 噪声
4 个通道	精度/%	100.00	99.92	99.92	99.58	99.42
	用时/s	289	298	292	288	291
8 个通道	精度/%	98.75	98.67	97.50	97.33	96.33
	用时/s	472	476	472	477	474

随着噪声强度的增强,识别精度逐渐下降,如图 9 所示。而互相关 4 个通道输入 的识别精度下降较为缓慢,当信噪比为 1 dB 时,互相关 4 个通道输入 的识别精度依然能达到 99.42%。互相关融合后的 4 个数据集所占用的网络通道较未融合前少了 4 个,因此运算时间得到大幅度缩减。每个工况下的训练用时如图 10 所示,互相关 4 个通道的平均用时为 291.6 s,而未融合的 8 个通道网络平均用时为 474.2 s。




图 9 精度对比

Fig. 9 Accuracy comparison




图 10 用时对比

Fig. 10 Time comparison

5 卡塔尔看台模型数据集的验证

5.1 试验介绍

为了验证所提方法在不同应用场景中的适用性,使用卡塔尔看台模型的数据集进行论证。卡塔尔大学看台模型的现场装置图如图 11 所示,模型^[5]为 4.2 m×4.2 m 的钢框架。试验通过对接头螺栓进行松动来模拟结构的损伤,构造的 30 个损伤位置已在图 11(a)上标注。对结构施加白噪声激励,并在每个关节处同时放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都采集 256 s 的信号,每个信号数据为样本点数 262 144。把每个损伤工况下的加速度信号划分为以 1 s 为单位的 256 个样本,30 个损伤工况共计得到 7 680 个样本,每个振动信号的样本点数为 1 024。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 个。



图 11 看台模型试验布置

Fig. 11 Test layout of spectators stand model

5.2 损伤识别

因数据集不同,本章节所使用的卷积神经网络模型与前文也不同。使用的网络模型是通过贝叶斯进行优化过的较优设置,网络结构设置如图 12 所示。Batchsize 设置为 500, Epochs 设置为 100, 初始学习率设置为 0.000 1。




图 12 优化后的神经网络结构设置

Fig. 12 Optimized neural network structure settings

选用 16 号加速度计数据进行 FFT 变换和自相关运算,使用 3 号和 28 号加速度计数据进行互相关运算。分别对原始样本、FFT 样本和自相关样本作为网络输入的识别精度进行对比,将互相关融合后样本训练的网络和未融合数据训练的双通道网络的识别精度进行对比,识别结果如表 7 所示。

表 7 不同噪声强度下的识别精度

Table 7 Recognition accuracy under different noise intensities

通道数量	样本形式	识别精度/%			
		10 dB 噪声	5 dB 噪声	2 dB 噪声	1 dB 噪声
1 个通道	原始数据	95.27	86.91	76.55	72.55
	FFT 样本	100.00	99.82	99.64	99.55
	自相关样本	100.00	99.91	99.73	99.73
2 个通道	原始数据	99.73	98.27	92.82	88.55
	互相关样本	100.00	100.00	99.82	99.73

将 16 号加速度计数据集进行 FFT 变换和自相关运算再作为网络输入,对识别精度的提升效果更为明显。当信噪比为 1 dB 时,自相关样本训练好的网络识别精度依旧能达到 99.73%,略高于 FFT 样本的 99.55%。相比于变换前精度分别提升了 27.18%和 27.00%。3 号加速度计和 28 号加速度计数据并行输入网络的识别精度较单传感器输入时略高,但将 2 个数据集进行互相关融合后再输入单通道 CNN 的识别效果更好,且训练网络的用时有所减少。

本章节所使用的数据集和卷积神经网络完全不同于上文,但都得出了同样的结论。自相关运算可以显著提升 CNN 模型的识别精度,且具有较好的噪声鲁棒性。将多个传感器数据进行互相关融合,在有效削减数据集维度的前提下可以显著提升网络的识别精度,同样具有较强的抗噪性。

6 结论

本文使用 CNN 模型并结合相关函数算法的特点针对一桥梁结构进行损伤识别研究,分析了自相关函数算法的抗噪性原理,并将振动信号的自相关样本作为 CNN 的输入,主要分析了自相关样本作为网络输入的识别精度和抗噪性能。并利用互相关算法的特点,将其应用于传感器的数据融合,将融合后的数据作为 CNN 的输入,对比了不同通道和噪声水平下的识别效果。最后,使用不同的结构试验数据和不同的卷积神经网络模型论证了所提方法在不同应用场景中的适用性。主要得出以下结论:

1) 基于自相关样本训练的 CNN 模型具有更好地识别效果。通过对输入到网络的振动响应数据进行自相关运算,可以显著提升网络的识别精度,且具有较强的抗噪能力,当添加噪声的强度达到 1 dB 时,其自相关样本训练的 CNN 模型依旧能达到精准的识别效果。

2) 作为 CNN 模型的输入,自相关样本具有比 FFT 变换样本更强的抗噪性。当信号样本中不含噪声或噪声能量很低时,基于振动信号的 FFT 样本训练的 CNN 模型比自相关样本的识别精度略高,但随着噪声强度的增长,自相关样本的识别精度会高于 FFT 变换后样本。

3) 互相关运算可以融合不同传感器之间的数据,基于融合之后的数据集训练的 CNN 模型的识别精度较双通道 CNN 模型的高,且训练用时较双通道网络的短。

4) 通过互相关进行数据集融合可以将数据集维度减少一半,再结合多通道 CNN 模型,可以实现较精准的识别效果,且具有较强的抗噪性。

参考文献:

- [1] 李慧民,董美美,熊雄,等. 基于振动的结构损伤识别研究综述[J]. 建筑结构, 2021, 51(4): 45-50, 38.
LI Huimin, DONG Meimei, XIONG Xiong, et al. State-of-the-art review of vibration-based damage identification framework for structures[J]. Building Structure, 2021, 51(4): 45-50, 38. (in Chinese)
- [2] 滕志强. 基于卷积神经网络与振动信号的结构损伤识别[D]. 广州: 广东工业大学, 2021.
TENG Zhiqiang. Structural damage detection based on convolutional neural network and vibration signals[D]. Guangzhou: Guangdong University of Technology, 2021. (in Chinese)
- [3] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [4] LECUN 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 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.
- [6] SONY S, GAMAGE S, SADHU A, et al. Multiclass damage identification in a full-scale bridge using optimally tuned one-dimensional convolutional neural network[J]. Journal of Computing in Civil Engineering, 2022, 36(2): 04021035.
- [7] 张健飞,蔡东成. 基于多尺度卷积神经网络的结构损伤识别研究[J]. 地震工程与工程振动, 2022, 42(1): 132-142.
ZHANG Jianfei, CAI Dongcheng. Research on structural damage identification based on multi-scale convolutional neural networks[J]. Earthquake Engineering and Engineering Dynamics, 2022, 42(1): 132-142. (in Chinese)
- [8] 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 Yongpeng, WANG Linkun, LIAO Feiyu, 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)
- [9] COFRE-MARTEL S, KOBRICH P, LOPEZ DROGUETT E, et al. Deep convolutional neural network-based structural damage localization and quantification using transmissibility data[J]. Shock and Vibration, 2019, 2019: 9859281.

- [10] CHEN Q Y, YUN C B, DUAN Y F. Cable damage identification of tied-arch bridge using convolutional neural network[M]//WANG C M, DAO V, KITIPORNCHAI S, et al. Lecture Notes in Civil Engineering. Singapore: Springer Singapore, 2020: 77-84.
- [11] DIAO Y S, LV J D, WANG Q X, et al. Structural damage identification based on variational mode decomposition-Hilbert transform and CNN[J]. Journal of Civil Structural Health Monitoring, 2023, 13(6/7): 1415-1429.
- [12] MOSCOSO ALCANTARA E A, BONG M D, SAITO T. Structural response prediction for damage identification using wavelet spectra in convolutional neural network[J]. Sensors, 2021, 21(20): 6795.
- [13] 黄良敏, 丁志华, 洪威, 等. 相关多普勒光学层析成像[J]. 物理学报, 2012, 61(2): 231-237.
HUANG Liangmin, DING Zhihua, HONG Wei, et al. Correlated Doppler optical coherence tomography[J]. Acta Physica Sinica, 2012, 61(2): 231-237. (in Chinese)
- [14] 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 Shuo, XU Qingfeng, WANG Zhuolin. Research progress on structural damage detection based on convolutional neural networks[J]. Journal of Architecture and Civil Engineering, 2022, 39(4): 38-57. (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 Changqing, GAO Zhiyong, QIN Jing, 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] LI T, MENG Z J, NI B B, et al. Robust geometric ℓ_p -norm feature pooling for image classification and action recognition[J]. Image and Vision Computing, 2016, 55: 64-76.
- [17] GARBIN C, ZHU X Q, MARQUES O. Dropout vs. batch normalization: An empirical study of their impact to deep learning[J]. Multimedia Tools and Applications, 2020, 79(19/20): 12777-12815.
- [18] 方能炜, 刘兰徽, 邢镔, 等. 自相关结合灰色关联度的轴承早期故障诊断方法[J]. 机械科学与技术, 2023, 42(12): 1972-1976.
FANG Nengwei, LIU Lanhui, XING Bin, et al. Early fault diagnosis of bearing coupling autocorrelation and grey relational degree[J]. Mechanical Science and Technology for Aerospace Engineering, 2023, 42(12): 1972-1976. (in Chinese)
- [19] 朱艳晶. 基于正交序列的超声波多址定位技术研究[D]. 长春: 吉林大学, 2022.
ZHU Yanjing. Research on Multiple-access ultrasonic positioning using orthogonal sequence[D]. Changchun: Jilin University, 2022. (in Chinese)
- [20] 罗向龙. 基于图傅里叶变换和深度学习的短时交通流预测方法研究[D]. 西安: 长安大学, 2021.
LUO Xianglong. Research on methods of short-term traffic flow prediction based on graph fourier transform and deep learning[D]. Xi'an: Changan University, 2021. (in Chinese)
- [21] ZHANG Y Q, 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.
- [22] 李斌, 孙强, 何佳伟, 等. 基于谐波注入的柔性直流系统接地极线路故障测距方法[J]. 电网技术, 2020, 44(12): 4773-4782.
LI Bin, SUN Qiang, HE Jiawei, et al. Fault location for grounding electrode line of MMC DC system based on harmonic injection[J]. Power System Technology, 2020, 44(12): 4773-4782. (in Chinese)