

基于密集连接卷积神经网络的结构损伤识别

吁强¹,蔡晓丽¹,李翠²,朱学坤²,伍晓顺¹,朱驰¹

(1. 江西理工大学土木与测绘工程学院(南昌),江西南昌 330013; 2. 江西交通职业技术学院信息工程学院,江西南昌 330013)

摘要:提出一种经验模态分解(empirical mode decomposition, EMD)和密集连接卷积神经网络(densely connected convolutional network, DenseNet)相结合的结构损伤识别网络模型(E-DenseNet)。对采集的加速度信号进行EMD得到多个本征模态函数(intrinsic mode function, IMF)分量,接着剔除皮尔逊相关系数绝对值较小的弱相关IMF分量。根据输入数据的组织方式,设定3种E-DenseNet模型:E-DenseNet1利用强相关IMF分量重构信号建立一维单通道输入数据;E-DenseNet2将各强相关IMF分量分别视作一个通道来建立一维多通道输入数据;E-DenseNet3利用所有强相关IMF分量组成二维矩阵来建立二维单通道输入数据。某简支梁算例分析表明:E-DenseNet1计算速度快但识别精度低,E-DenseNet2计算速度快且识别精度高,E-DenseNet3识别精度高但计算速度慢;与一维多通道残差卷积神经网络(residual network, ResNet)及标准卷积神经网络(convolutional neural network, CNN)相比,E-DenseNet2的识别精度明显更优;E-DenseNet2因而具有兼顾计算效率和识别精度的优点。E-DenseNet2可视化分析表明了其识别过程,对于相同工况下的不同样本,输出层越深其输出特征越相似,直至全连接层给出极大相似输出特征。

关键词:损伤识别;神经网络;动力测试;灵敏度分析;经验模态分解

中图分类号:TU311.3; TU18

文献标识码:A

Structural damage detection by using densely connected convolutional neural network

YU Qiang¹, CAI Xiaoli¹, LI Cui², ZHU Xuekun², WU Xiaoshun¹, ZHU Chi¹

(1. School of Civil and Surveying and Mapping Engineering (Nanchang), Jiangxi University of Science and Technology, Nanchang 330013, China;

2. College of Information Engineering, Jiangxi V&T College of Communication, Nanchang 330013, China)

Abstract: A structure damage identification network model (E-DenseNet) that combines empirical mode decomposition (EMD) and densely connected convolutional network (DenseNet) is proposed. The collected acceleration signals undergo EMD to obtain multiple intrinsic mode function (IMF) components, and then the weakly correlated IMF components with small absolute values of Pearson correlation coefficients are removed. According to the organization of the input data, three types of E-DenseNet models are set. E-DenseNet1 reconstructs the signal using strongly correlated IMF components to establish one-dimensional single-channel input data. E-DenseNet2 treats each strongly correlated IMF component as a channel to establish one-dimensional multi-channel input data. E-DenseNet3 uses all strongly correlated IMF components to form a two-dimensional matrix to establish two-dimensional single-channel input data. The numerical analysis of a simply supported beam shows that: E-DenseNet1 runs quickly with poor damage detection accuracy. E-DenseNet2 is computationally efficient with high damage detection accuracy. E-DenseNet3 provides good damage detection results but is time-consuming. Compared with one-dimensional multi-channel residual convolutional neural network (ResNet) and standard convolutional

收稿日期:2023-03-25; 修回日期:2023-06-10

基金项目:国家自然科学基金项目(51868026);江西省自然科学基金项目(20202BAB204028);江西省研究生创新专项资金项目(YC2022-S695)

作者简介:吁强(1997—),男,硕士研究生,主要从事结构健康监测研究。E-mail:yuq202204@163.com

通讯作者:蔡晓丽(1985—),女,讲师,硕士,主要从事结构健康监测和BIM技术的研究。E-mail:cxlgyx@163.com

neural network (CNN), E-DenseNet2 performs much better in damage detection accuracy. It is thus concluded that E-DenseNet2 ensures both the computational efficiency and the damage detection accuracy. The visualization analysis of E-DenseNet2 exhibits its damage detection process that for different samples of the same damage scenario, a deeper layer outputs more similar features until the fully connected layer provides the most similar output features.

Key words: damage detection; neural network; dynamic test; sensitivity analysis; empirical mode decomposition

0 引言

工程结构在服役过程中不断累积的损伤对结构的安全性和耐久性构成严重威胁,甚至引发工程事故造成财产损失和人员伤亡。为避免工程事故的发生,有必要对在役结构进行结构健康监测^[1]。作为结构健康监测的核心内容,损伤识别一直备受研究人员关注。其中,基于结构动力特性的损伤识别方法成为研究热点^[2-3]。

近年来,随着深度学习^[4]的快速发展,卷积神经网络(convolutional neural network, CNN)凭借其强大的特征提取及特征映射能力,在智能诊断领域有着不俗的表现^[5-7]。其中,基于结构动力特性和 CNN 相结合的结构损伤识别方法也取得了很多成果^[8-11]。为了保证神经网络的学习能力,往往需要大幅增加网络深度。但是,网络深度的增加容易导致梯度消失和梯度爆炸^[12]。为了解决这个问题, HUANG 等^[13]在残差结构(ResNet)^[14]基础上开发了一种称为密集连接卷积网络(densely connected convolutional neural network, DenseNet)的新架构,并在 2017 年获得 CVPR 最佳论文。DenseNet 独特的连接方式使得特征可以重复利用,从而大幅提升网络的学习效率。这使得 DenseNet 在结构健康监测领域有着广泛的应用前景^[15]。为了降低计算成本,骆勇鹏等^[16]采用单通道一维 CNN 并直接利用原始数据来实现对简支梁和钢框架的损伤识别,获得了很好的识别效果。骆剑彬等^[17]考察了多通道一维 CNN 的损伤识别效果,结果表明多通道模型识别精度远好于单通道模型。为了提高输入数据的质量,叶壮等^[18]利用经验模态分解(empirical mode decomposition, EMD)对原始信号进行分解重构后输入多通道 CNN 实现了齿轮箱的故障诊断。可见,一维卷积和多通道可以大幅提高计算效率,EMD 则可以增强信号特征从而提高识别精度。

受上述研究启发,本文利用 EMD 和 DenseNet 搭建一种新的卷积神经网络模型 E-DenseNet,以便更加准确地提取结构损伤特征。首先,介绍 CNN、DenseNet、EMD 的基本原理。其次,解析 E-DenseNet 的模型架构。最后,以某简支梁为例展开数值分析,比较不同通道和数据维度 E-DenseNet 的性能表现,并对网络学习到的特征进行可视化分析以揭示结构损伤的识别原理。

1 基本原理

1.1 卷积神经网络

CNN^[19-20]是一种深度学习模型或类似于人工神经网络的多层感知器,常用来分析视觉图像。一个典型的 CNN 包括卷积层、池化层和全连接层,且通常为顺序连接。卷积层通过人为设置的卷积核对输入的特征图进行卷积计算,即

$$x_j^l = f\left(\sum_{i \in M_j} x_i^{l-1} \omega_{ij}^l + b_j^l\right) \quad (1)$$

式中: x_j^l 为第 l 层第 j 个元素(即该层输出); x_i^{l-1} 为第 $l-1$ 层的第 i 个元素(即该层输入); M_j 为第 $l-1$ 层的第 j 个卷积区域; ω_{ij}^l 为卷积核权值; b_j^l 为对应的偏置; f 为非线性激活函数。 f 通常采用 ReLU 激活函数,其表达式为

$$f(x) = \max(0, x) \quad (2)$$

池化层通常设置在卷积层后面并对卷积层的输出进行采样,以便对特征图进行降维。常用的池化操作有平均池化和最大值池化,分别对池化区域内的特征点取平均值和最大值。全连接层一般位于整个卷积神经网络的最后面,其主要作用就是将前层(卷积、池化等层)学习到的特征空间进行组合,最后映射到样本的标签空间。

1.2 DenseNet 架构

CNN 的网络层数一般较深。当 CNN 的层数变深时,容易出现网络退化(即梯度消失或梯度爆炸)问题。DenseNet^[13]是解决 CNN 网络退化问题的一种先进方案。DenseNet 通过建立前面所有层与后面层的密集连接来实现特征重用,具有较优的计算性能。密集连接块(Dense block)和过渡层(Transition layer)DenseNet 的 2 个重要模块,其简述如下。

1.2.1 密集连接块

密集连接块中每一层的输入均为前面所有层输出的拼接,其示意图如图 1 所示。密集连接的数学表达式为

$$x_l = H_l([x_0, x_1 \dots x_{l-1}]) \tag{3}$$

式中: $[x_0, x_1 \dots x_{l-1}]$ 为第 l 层之前所有特征图的拼接; x_l 为第 l 层的输出; H_l 为非线性组合函数,通常包含 BN-ReLU-Conv 等一系列非线性变换。假设初始输入的特征图通道数为 k_0 ,且每一层的卷积核数量均为 k ,则对于第 l 层,其输入的通道数为 $k_0 + (l-1)k$ 。可见,输入通道数与网络层数呈线性递增关系,因此, k 又被称为网络增长率。

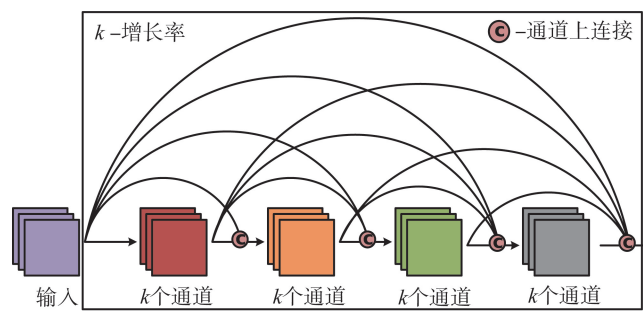


图 1 某 4 层密集连接块示意图 ($k=3$)

Fig. 1 Diagram of a four-layer densely connected block ($k=3$)

1.2.2 过渡层

包含密集连接块和过渡层的完整 DenseNet 示意图,如图 2 所示。在密集连接块中,每一层的特征图大小都相同,这样各层的连接操作才能顺利进行。为压缩整个训练模型的参数量,需要在密集连接块之间添加过渡层。一般在过渡层引入 1×1 卷积核来压缩特征图数量,并引入池化函数 MaxPooling 来进行采样。




图 2 DenseNet 示意图

Fig. 2 Diagram of DenseNet

1.3 经验模态分解(EMD)

EMD 是由 HUANG 等^[21]于 1998 年提出的一种自适应处理信号的算法。某时域信号经 EMD 处理后可以得到不同尺度的本征模态函数(IMF)分量以及一个残差分量,即

$$x(t) = \sum_{i=1}^n c_i + r_n(t) \tag{4}$$

式中: $x(t)$ 为原始时域信号; c_i 为第 i 个 IMF 分量; r_n 为残差分量; n 为 IMF 的个数。EMD 具体分解过程见文献[21]。

可以根据 IMF 分量与 $x(t)$ 之间的皮尔逊相关系数^[22] ρ 来判断它们之间的相关性。若 $|\rho| > 0.6$,则认为该阶 IMF 与 $x(t)$ 之间为强相关,反之为弱相关。通过 EMD,原始信号包含的损伤特征被主要分散到各阶强相关 IMF 分量。后文中,仅保留强相关 IMF 分量来重新组织网络模型的输入数据。将所有强相关 IMF 分量进行叠加可以得到重构信号。一般认为,该重构信号将极大保留原始特征信息,同时剔除噪声的干扰。

2 E-DenseNet 模型

将 EMD 和 DenseNet 相结合,搭建适用于结构损伤识别的 E-DenseNet 模型,其架构(或流程)如图 3 所

示。E-DenseNet 模型由 3 个密集连接块和过渡层连接构成,全局平均池化层置于最后一个密集连接块后面,最后为目标层。根据输入数据的组织方式,设定 3 种 E-DenseNet 模型:①E-DenseNet1 利用强相关 IMF 分量叠加后的重构信号建立一维单通道输入数据;②E-DenseNet2 将各阶强相关 IMF 分量视作一个通道来建立一维多通道输入数据;③E-DenseNet3 将各阶强相关 IMF 分量视作同一个二维矩阵的各行来建立二维单通道输入数据。

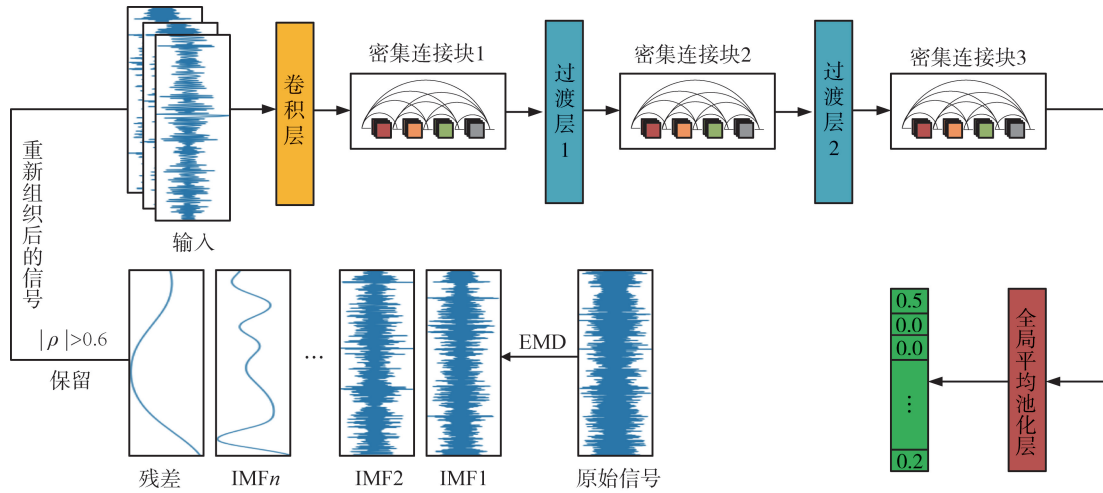


图3 E-DenseNet 模型架构示意图

Fig. 3 Illustration of the E-DenseNet model architecture

将结构的损伤位置与损伤程度映射到目标层的输出向量,并由携带激活函数 $\tan h$ 的全连接层来实现回归计算。 $\tan h$ 函数的计算公式为

$$\tanh(x) = (e^x - e^{-x}) / (e^x + e^{-x}) \quad (5)$$

式中: x 为 $\tan h$ 函数的输入; $\tanh(x)$ 为预测的损伤程度。

采用均方误差 (MSE) 作为损失函数,用来衡量预测的损伤向量与真实标签的差异程度。同时为避免过拟合,在损失函数中加入一个 L2 正则化项 λ 对权重参数进行惩罚。本文将 λ 设定为 0.0002,对应的损失函数表达式为

$$\text{loss}(\bar{y}, y) = \frac{1}{n} \sum_{i=1}^n (\bar{y}_i - y_i)^2 + \lambda \|w\|_2^2 \quad (6)$$

式中: $\text{loss}(\bar{y}, y)$ 为损失值; w 为权重矩阵; n 为训练样本数量。还采用线性相关系数 R 来衡量预测值与真实值之间的匹配程度, R 值介于 0~1 之间。总的来说, MSE 值越小、 R 值越大,则模型的性能越好。

3 数值验证

3.1 结构模型

某 1.6 m 跨简支工字梁为例展开数值分析,如图 4 所示。梁的弹性模量为 206 GPa、密度为 7850 kg/m³、泊松比为 0.3。该梁共包含 11 个节点和 10 个长度相等的单元。采用减小相应位置弹性模量的方式来模拟单元损伤。共建立包含无损工况在内的共 25 种损伤工况如表 1 所示。在 5 号节点施加白噪声激励,激励服从均值为 300 N、标准差为 30 N 的正态分布。激励时长为 400 s,采样频率为 50 Hz。利用 5 号节点测得的竖直方向加速度响应数据来展开模型训练和测试。




图4 某简支工字梁

Fig. 4 A simply supported I-beam

表 1 损伤工况设置
Table 1 Damage condition setting

工况号	损伤单元	损伤程度	工况号	损伤单元	损伤程度	工况号	损伤单元	损伤程度
1	—	—	10	5	0.045	19	9	0.285
2	1	0.075	11	5	0.300	20	10	0.120
3	1	0.21	12	6	0.150	21	10	0.195
4	2	0.135	13	6	0.165	22	3,6	0.150,0.165
5	2	0.27	14	7	0.060	23	5,7	0.30,0.06
6	3	0.015	15	7	0.255	24	1,3,5	0.075,0.180,0.300
7	3	0.18	16	8	0.090	25	3,6,9	0.180,0.150,0.285
8	4	0.105	17	8	0.225			
9	4	0.240	18	9	0.030			

3.2 样本准备及网络模型参数

一般而言,样本的数量越大则模型的评估效果越好,然而实际工程获得的数据往往是有限的。为获得更多的样本,采用滑窗重采样的方法对数据进行切片,如图 5 所示。滑窗长度为 2000,滑窗步长为 28。每种工况采集 500 组样本,共 12 500 组样本。将样本按 75%、15%、15% 划分为训练集、验证集和测试集。样本标签为结构损伤向量,如 [0.12,0,0.02,0,⋯,0] 表示 1 号单元损伤 12%、3 号单元损伤 2%。同时为模拟测量噪声的干扰,将对样本添加不同信噪比^[23] 的噪声。表 2 给出了 E-DenseNet 网络结构超参数设置情况。




图 5 滑窗重采样
Fig. 5 Slide window resampling schematic diagram

表 2 E-DenseNet 超参数设置

Table 2 Hyperparameter settings for E-DenseNet

结构层次	E-DenseNet1、E-DenseNet2		E-DenseNet3	
	超参数	输出尺寸	超参数	输出尺寸
1#卷积层	50×1Conv1D, strides=(20,1)	100×24	50×1Conv2D, strides=(20,1)	100×8×24
1#密集连接块	$\begin{bmatrix} 1 \times 1 \text{Conv1D} \\ 10 \times 1 \text{Conv1D} \end{bmatrix} \times 6$	100×96	$\begin{bmatrix} 1 \times 1 \text{Conv2D} \\ 10 \times 2 \text{Conv2D} \end{bmatrix} \times 6$	100×8×96
1#过渡层	1×1Conv1D	100×48	1×1Conv2D	100×8×48
	5×1Maxpooling, strides=(5,1)	20×48	5×1Maxpooling, strides=(5,2)	20×4×48
2#密集连接块	$\begin{bmatrix} 1 \times 1 \text{Conv1D} \\ 10 \times 1 \text{Conv1D} \end{bmatrix} \times 6$	20×120	$\begin{bmatrix} 1 \times 1 \text{Conv2D} \\ 10 \times 2 \text{Conv2D} \end{bmatrix} \times 6$	20×4×120
2#过渡层	1×1Conv1D	20×60	1×1Conv2D	20×4×60
	5×1Maxpooling, strides=(5,1)	4×60	5×1Maxpooling, strides=(5,2)	4×1×60
3#密集连接块	$\begin{bmatrix} 1 \times 1 \text{Conv1D} \\ 4 \times 1 \text{Conv1D} \end{bmatrix} \times 6$	4×132	$\begin{bmatrix} 1 \times 1 \text{Conv2D} \\ 4 \times 2 \text{Conv2D} \end{bmatrix} \times 6$	4×1×132
目标层	4×1Globalavepooling	1×132	4×1Globalavepooling	1×1×132
	10×1fullyconnected, tan h	10	10×1fullyconnected, tan h	10

为评估网络模型的训练效果,将按比例划分好的数据集(仅训练集参与训练)送入训练模型。共训练 500 个 epoch,选用 Adam 优化器,初始学习率设置为 0.001,并采用阶梯型衰减策略,衰减数为 0.95。整个模型的搭建和优化均在 TensorFlow 环境下进行。

3.3 评估结果

以工况 15(7 号单元 25.5%损伤)为例,考虑某个随机选取的验证集样本,DenseNet(采用原始信号作为输入数据)、E-DenseNet1~3 的损伤识别结果如图 6 所示。由图可知,无论是否考虑噪声影响,E-DenseNet2 和 E-DenseNet3 均可准确识别损伤位置,且定量识别结果非常接近真实值。其中,E-DenseNet2 在无噪、10 dB 和 5 dB 噪声情形下的损伤识别值分别为 25.683%、25.762%、24.934%,而 E-DenseNet3 则分别为

25.453%、25.923%、26.123%，而且未损杆件对损伤杆件的识别仅有轻微干扰。相比之下，即使不考虑噪声影响，DenseNet 和 E-DenseNet1 的损伤识别结果都比较差。这表明 E-DenseNet2 和 E-DenseNet3 比 DenseNet 和 E-DenseNet1 具有更好的损伤识别性能。

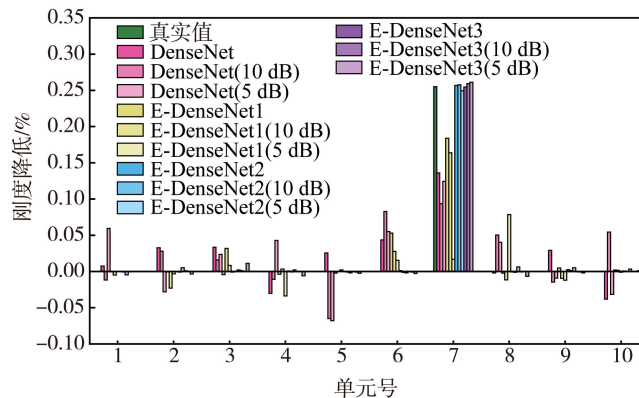


图6 DenseNet, E-DenseNet1, E-DenseNet2, E-DenseNet3 的损伤识别结果(工况 15)

Fig.6 Damage detection results of DenseNet and E-Densenet1, E-DenseNet2, E-DenseNet3(Case 15)

DenseNet、E-DenseNet1、E-DenseNet2、E-DenseNet3 在统计意义上的评估结果如表 3 所示。从 R 值和 MSE 值判断, 无论是否考虑噪声影响, E-DenseNet2 和 E-DenseNet3 的损伤识别效果都要远好于 DenseNet 和 E-DenseNet1。此外, E-DenseNet3 计算耗时远超 DenseNet、E-DenseNet1 和 E-DenseNet2。研究表明, 采用一维多通道的 E-DenseNet2 可以兼顾计算效率和识别精度。

表3 E-DenseNet, DenseNet 评估结果

Table 3 Evaluation results of E-DenseNet and DenseNet

模型类型	数据类型	R 值	MSE	单条样本用时/ms
DenseNet	无噪声	0.4944	2.00×10^{-3}	1.0
	SNR = 10 dB	0.4964	2.00×10^{-3}	
	SNR = 5 dB	0.4620	2.20×10^{-3}	
E-DenseNet1	无噪声	0.9451	1.48×10^{-4}	1.0
	SNR = 10 dB	0.9009	2.98×10^{-4}	
	SNR = 5 dB	0.8631	4.02×10^{-4}	
E-DenseNet2	无噪声	0.9986	5.32×10^{-6}	1.3
	SNR = 10 dB	0.9923	2.51×10^{-5}	
	SNR = 5 dB	0.9896	2.96×10^{-5}	
E-DenseNet3	无噪声	0.9989	8.84×10^{-6}	12
	SNR = 10 dB	0.9881	3.05×10^{-5}	
	SNR = 5 dB	0.9763	6.51×10^{-5}	

3.4 对比试验

均采用一维多通道输入数据的 E-DenseNet2、ResNet 和 CNN 这 3 种网络模型在训练集和验证集的 MSE 值变化趋势, 如图 7 所示。可以看出, 在训练集上 3 种模型的 MSE 曲线收敛速度相差不大, 但在验证集上 E-DenseNet2 的表现显然更好。可见, 虽然均为一维多通道训练模型, 但是 E-DenseNet2 比 ResNet、CNN 具有更好的泛化能力。

以工况 10(5 号单元微小损伤 4.5%) 为例, 考虑某个随机选取的验证集样本, DenseNet2、ResNet 和 CNN 这 3 种网络模型的损伤识别结果如图 8 所示。由图可知, 无论是否考虑噪声影响, E-DenseNet2 均可准确识别损伤位置, 定量识别结果也非常接近真实值, 且未损杆件对损伤杆件的识别几乎无干扰。相比之下, 即使不考虑噪声影响, ResNet 和 CNN 的损伤识别结果都很差, 存在较多干扰或误判的情况。研究表明 E-DenseNet2 比 ResNet 和 CNN 具有更好的损伤识别性能。

DenseNet、ResNet 和 CNN 在统计意义上的评估结果如表 4 所示。从 R 值和 MSE 值判断, 无论是否考虑噪声影响, E-DenseNet2 的损伤识别效果都要远好于 ResNet 和 CNN, 但计算耗时比 ResNet 略多而比 CNN 略少。

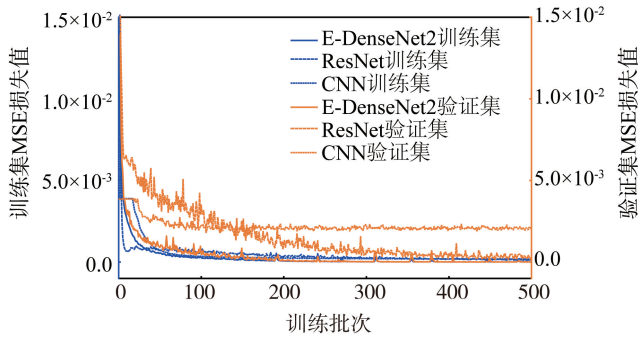


图 7 训练集和测试集的 MSE 变化趋势

Fig. 7 Changing trend of MSE in training set and test set

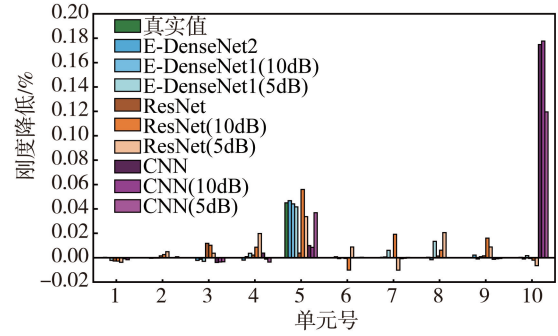


图 8 DenseNet2、ResNet 和 CNN 的损伤识别结果(工况 5)

Fig. 8 Damage detection results of DenseNet2, ResNet and CNN (Case 5)


表 4 3 种模型的评估结果

Table 4 Evaluation results of the three models


模型类型	数据类型	R 值	MSE	单条样本用时/ms
E-DenseNet2	无噪声	0.998 60	5.32×10^{-6}	1.3
	SNR = 10 dB	0.992 30	2.51×10^{-5}	
	SNR = 5 dB	0.989 60	2.96×10^{-5}	
ResNet	无噪声	0.914 20	3.31×10^{-4}	1.0
	SNR = 10 dB	0.892 70	3.46×10^{-4}	
	SNR = 5 dB	0.853 20	4.03×10^{-4}	
CNN	无噪声	0.444 80	2.20×10^{-3}	2.0
	SNR = 10 dB	0.045 74	2.10×10^{-3}	
	SNR = 5 dB	0.412 40	2.32×10^{-3}	

3.5 可视化分析


为了更好地理解训练模型各层输出特征的演变过程,以 E-DenseNet2 为例展开可视化分析。随机选取工况 2(1 号单元 7.5% 损伤)验证集 3 份样本(即一维输入数据多通道),分别记为信号一(无噪)、信号二(10 dB 噪声)和信号三(5 dB 噪声),如图 9 所示。将每个密集连接块的最后一个卷积层输出的特征图绘于图 10~图 12。观察特征图的浅层特征至深层特征的变化,可以发现不同信号之间的输出特征越来越相似,如图 12(a)、(b)、(c) 三者的第一张子图(1st)基本相同。这 3 个信号经全局平均池化后的结果如图 13 所示,全连接层的最终输出结果如图 14 所示。可以看出经过全局平均池化后,各个信号的输出特征已经非常相似,这使得全连接层的输出结果非常接近真实标签。



(a) 信号一




(b) 信号二



(c) 信号三

图9 随机选取的一维多通道输入数据 (IMFs)

Fig.9 Randomly selected 1D multi-channel input data (IMFs)



(a) 信号一

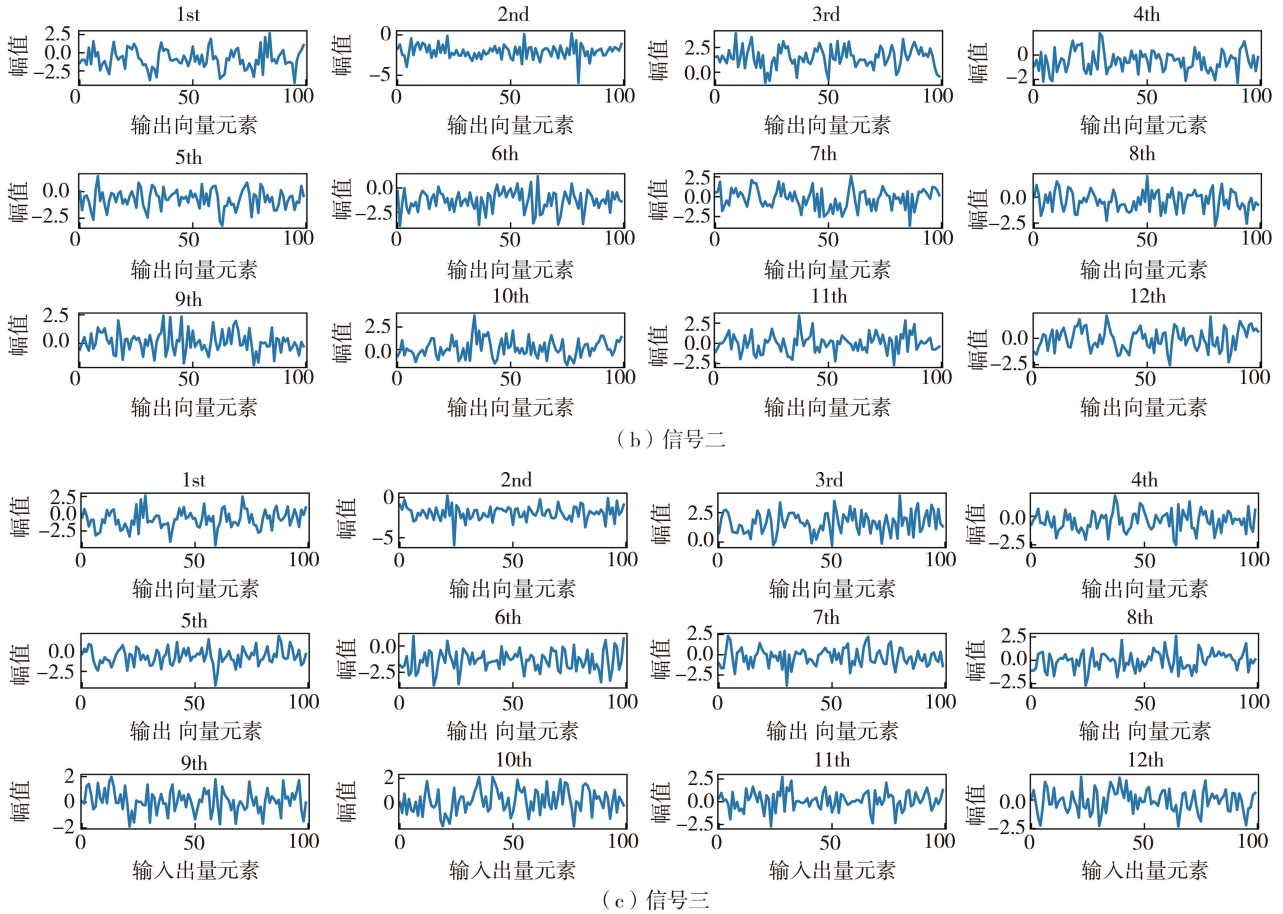
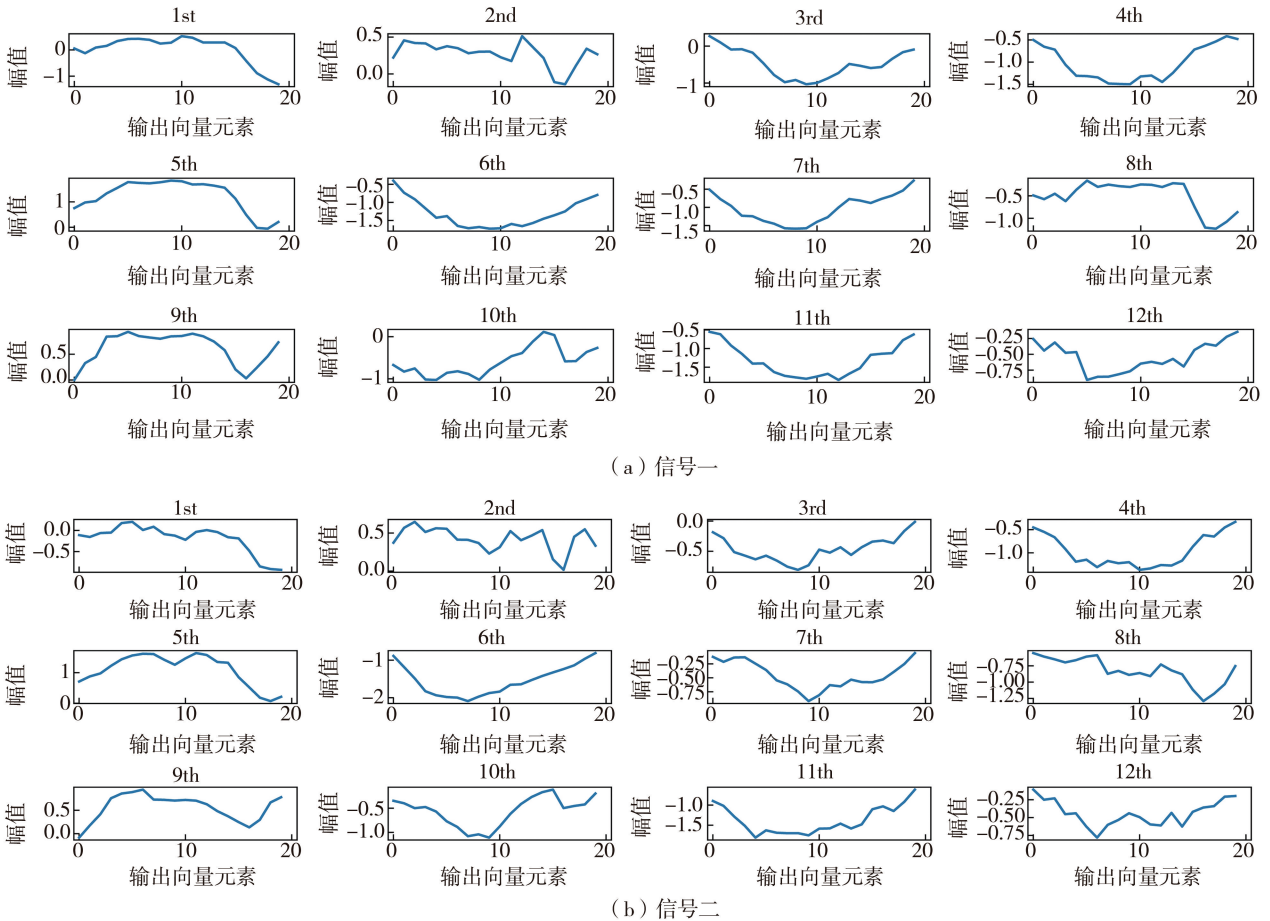
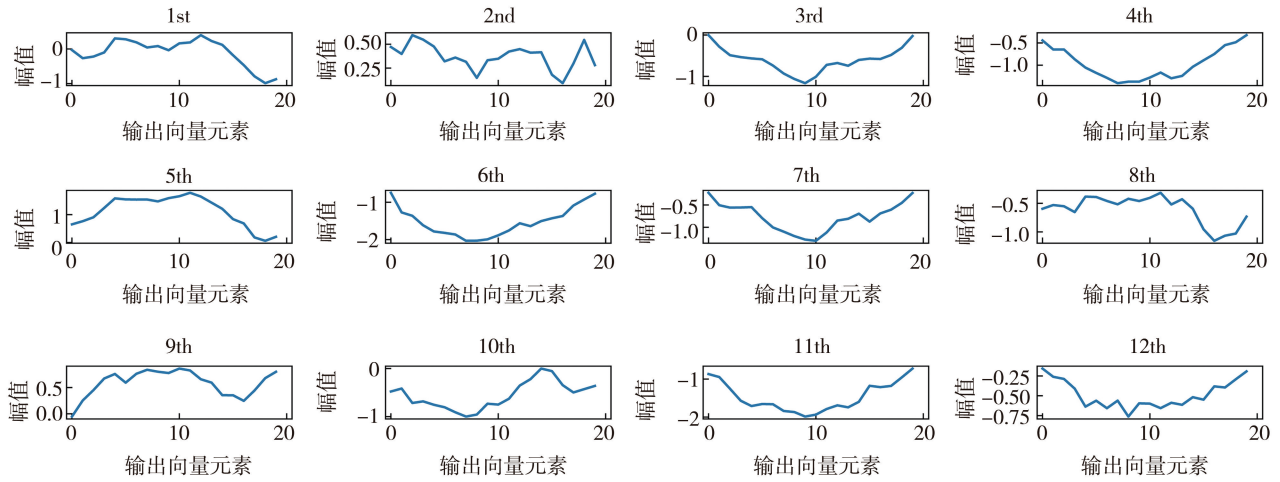


图 10 第一个密集连接块最后一层卷积层特征输出

Fig. 10 The last convolutional layer features output of the first densely connected block






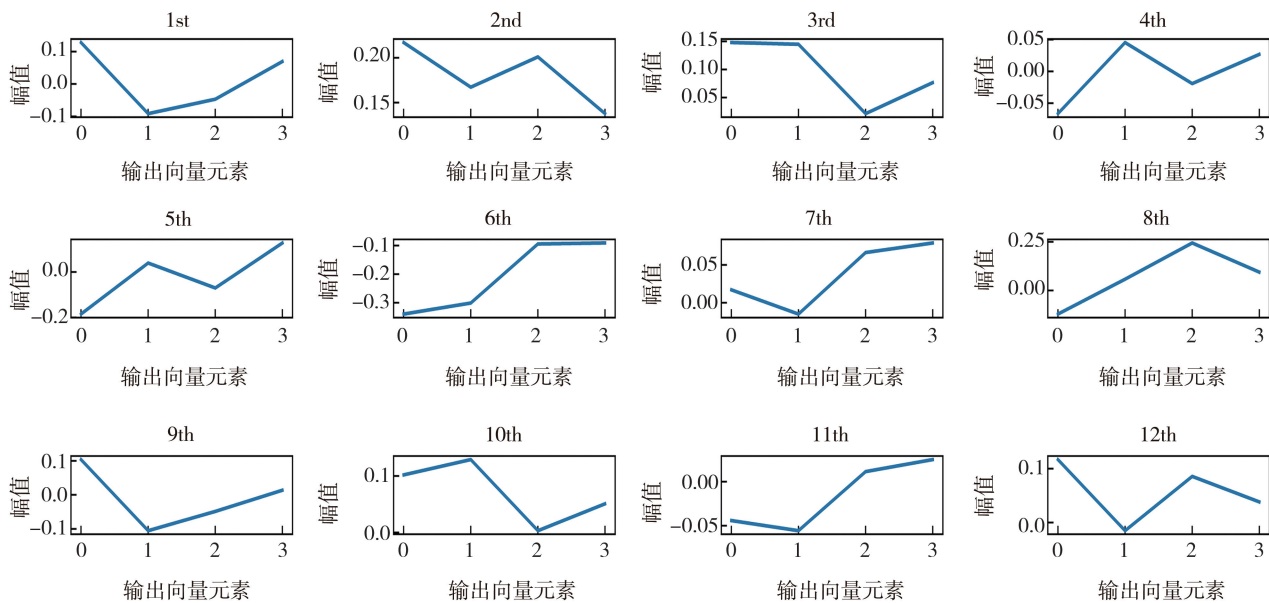
(c) 信号三

图 11 第二个密集连接块最后一层卷积层特征输出

Fig. 11 The last convolutional layer features output of the second densely connected block



(a) 信号一



(b) 信号二

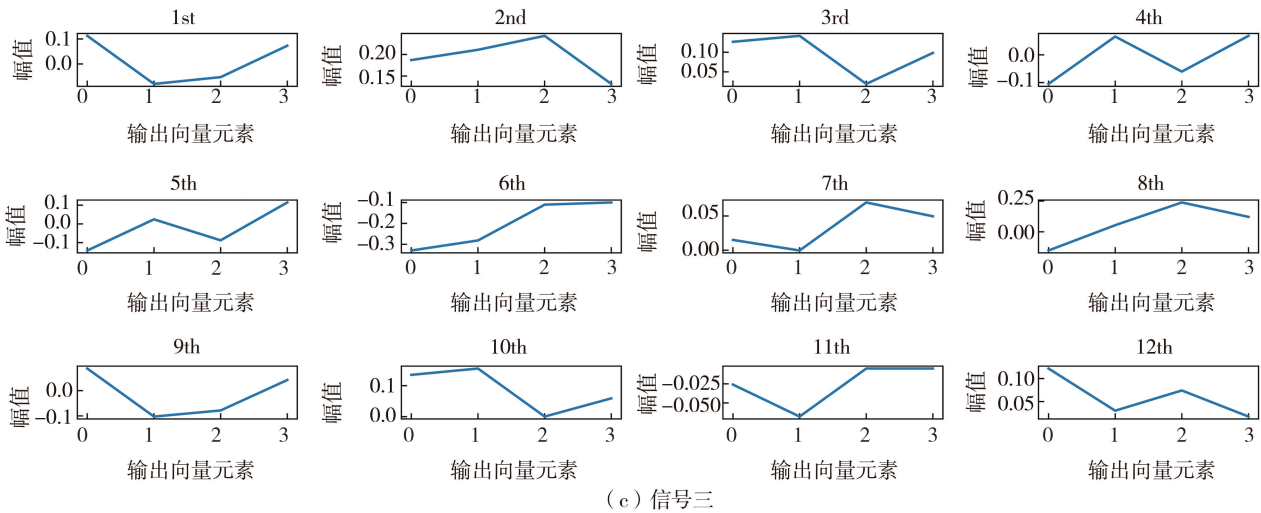


图 12 第三个密集连接块最后一层卷积层特征输出

Fig. 12 The last convolutional layer features output of the third densely connected block




图 13 全局平均池化输出

Fig. 13 Global average pooling output




图 14 全连接层输出

Fig. 14 Fully connected layer output

4 结论

本文提出一种 EMD 和 DenseNet 相结合的结构损伤识别网络模型 (E-DenseNet), 结论如下:

- 1) 直接利用未经 EMD 处理的原始信号作为输入数据的 DenseNet 识别精度较差, 而采用经 EMD 处理后数据的 E-DenseNet1~3 识别效果均比 DenseNet 好, 研究表明 EMD 有利于提高识别精度。
- 2) E-DenseNet2 的识别精度远超 ResNet 和 CNN (均采用一维多通道输入数据), 研究表明采用密集连接方式有利于提升识别精度。
- 3) E-DenseNet2 与 E-DenseNet3 的识别精度相当, 但前者计算耗时仅为后者的约 1/10, 研究表明 E-DenseNet2 可以兼顾计算效率和识别精度。

参考文献:

[1] 李宏男, 李东升. 土木工程结构安全性评估、健康监测及诊断述评[J]. 地震工程与工程振动, 2002, 22(3): 82-90.
LI Hongnan, LI Dongsheng. Safety assessment, health monitoring and damage diagnosis for structures in civil engineering [J]. Earthquake Engineering and Engineering Dynamics, 2002, 22(3): 82-90. (in Chinese)

[2] 张家滨, 唐催, 王磊, 等. 基于频率变化率的结构刚度非均匀退化识别[J]. 振动. 测试与诊断, 2018, 38(3): 486-493.
ZHANG Jiabin, TANG Cui, WANG Lei, et al. Identification of non-uniform stiffness degradation in structure based on the change rate of frequency[J]. Journal of Vibration, Measurement & Diagnosis, 2018, 38(3): 486-493. (in Chinese)

[3] 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 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, 17. (in Chinese)

[4] LECUN Y, BENGIO Y, HINTON G. Deep learning[J]. Nature, 2015, 521: 436-444.

- [5] FLAH M, RAGAB M, LAZHARI M, et al. Localization and classification of structural damage using deep learning single-channel signal-based measurement[J]. *Automation in Construction*, 2022, 139: 104271.
- [6] 张伟. 基于卷积神经网络的轴承故障诊断算法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
ZHANG Wei. Study on bearing fault diagnosis algorithm based on convolutional neural network[D]. Harbin: Harbin Institute of Technology, 2017. (in Chinese)
- [7] 李泽东, 李志农, 陶俊勇, 等. 基于特征融合的注意力增强卷积神经网络的航空发动机滚动轴承故障诊断方法[J]. *兵工学报*, 2022, 43(12): 3228-3239.
LI Zedong, LI Zhinong, TAO Junyong, et al. Fault diagnosis for aero-engine rolling bearings based on an attention augmented convolutional neural network with feature fusion[J]. *Acta Armamentarii*, 2022, 43(12): 3228-3239. (in Chinese)
- [8] 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 convolution neural network[J]. *Journal of Vibration and Shock*, 2019, 38(1): 159-167. (in Chinese)
- [9] 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 Yuzhou, XIANG Tianyu, HAO Liuqing. Application of convolutional neural network in structural damage diagnosis[J]. *Journal of Civil Engineering and Management*, 2020, 37(3): 155-161, 173. (in Chinese)
- [10] 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 Shujin, ZHAO Yuan, KONG Fan, et al. Application of convolutional neural network in structural damage identification[J]. *Journal of Architecture and Civil Engineering*, 2020, 37(6): 29-37. (in Chinese)
- [11] 骆勇鹏, 王林堃, 郭旭, 等. 利用单传感器数据基于 GAF-CNN 的结构损伤识别[J]. *振动.测试与诊断*, 2022, 42(1): 169-176, 202, 203.
LUO Yongpeng, WANG Linkun, GUO Xu, et al. Structural damage identification using single sensor data based on GAF-CNN[J]. *Journal of Vibration, Measurement & Diagnosis*, 2022, 42(1): 169-176, 202, 203. (in Chinese)
- [12] BENGIO Y, SIMARD P, FRASCONI P. Learning long-term dependencies with gradient descent is difficult[J]. *IEEE Transactions on Neural Networks*, 1994, 5(2): 157-166.
- [13] HUANG G, LIU Z, VAN DER MAATEN L, et al. Densely connected convolutional networks[C]//2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Honolulu, HI, USA. Piscataway, NJ, USA: IEEE, 2017: 2261-2269.
- [14] HE K M, ZHANG X Y, REN S Q, et al. Deep residual learning for image recognition[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, NV, USA. Piscataway, NJ, USA: IEEE, 2016: 770-778.
- [15] WANG R H, LI J, Chencho, et al. Densely connected convolutional networks for vibration based structural damage identification[J]. *Engineering Structures*, 2021, 245: 112871.
- [16] 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)
- [17] 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 Jianbin, LIU Yuesheng, JIANG Shaofei, 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)
- [18] 叶壮, 余建波. 基于多通道一维卷积神经网络特征学习的齿轮箱故障诊断方法[J]. *振动与冲击*, 2020, 39(20): 55-66.
YE Zhuang, YU Jianbo. Gearbox fault diagnosis based on feature learning of multi-channel one-dimensional convolutional neural network[J]. *Journal of Vibration and Shock*, 2020, 39(20): 55-66. (in Chinese)
- [19] 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)
- [20] 戴伦, 张文达, 田石柱. 桥梁线弹性地震反应的卷积神经网络估计[J]. *地震工程与工程振动*, 2021, 41(4): 188-195.
DAI Lun, ZHANG Wenda, TIAN Shizhu. Convolutional neural network estimation of bridge linear elastic seismic response[J]. *Earthquake Engineering and Engineering Dynamics*, 2021, 41(4): 188-195. (in Chinese)
- [21] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis[J]. *Proceedings of the Royal Society of London Series A: Mathematical, Physical and Engineering Sciences*, 1998, 454(1971): 903-995.
- [22] 陶洋, 祝小钧, 杨柳. 基于皮尔逊相关系数和信息熵的多传感器数据融合[J]. *小型微型计算机系统*, 2023, 44(5): 1075-1080.
TAO Yang, ZHU Xiaojun, YANG Liu. Multi-sensor data fusion based on pearson coefficient and information entropy[J]. *Journal of Chinese Computer Systems*, 2023, 44(5): 1075-1080. (in Chinese)
- [23] 伍晓顺, 程润辉. 阶跃激励下网架结构的动力响应扩展及其误差分析[J]. *振动与冲击*, 2022, 41(17): 213-220, 261.
WU Xiaoshun, CHENG Runhui. Dynamic response expansion and its error analysis of space truss structures under step excitation[J]. *Journal of Vibration and Shock*, 2022, 41(17): 213-220, 261. (in Chinese)