

## 基于广义 S 变换和并联神经网络的结构损伤识别研究

李行健, 吕建达, 赵凌云, 刁延松\*

(青岛理工大学 土木工程学院, 青岛 266525)

**摘要:**目前在利用 CNN 网络提取特征的结构损伤识别研究中, 仅仅利用 1D-CNN 和 2D-CNN 提取的特征进行损伤识别存在准确率低、识别效率不高等问题。提出了一种基于广义 S 变换和并联神经网络的结构损伤识别方法。为了丰富输入信号的特征维度, 利用广义 S 变换将滤波后的信号转化成时频图, 并同时将一维加速度响应信号和二维时频图分别输入 1D-CNN 和 2D-CNN 中进行时域和时频域特征提取, 并在汇聚层进行特征拼接, 然后通过 FC 层和 Softmax 层对损伤识别结果进行分类。利用 IASC-ASCE SHM Benchmark 结构第二阶段试验数据对所提出的并联网络模型进行验证, 结果表明, 所提出的网络模型与其他同类方法相比具有更高的识别精度和识别效率。

**关键词:**损伤识别; 广义 S 变换; 卷积神经网络; 时频分析; 特征融合

**中图分类号:**TU317; TU391 **文献标志码:**A **文章编号:**1673-4602(2024)01-0026-10

## Study on structural damage identification based on generalized S-transform and parallel neural network

LI Xingjian, LÜ Jianda, ZHAO Lingyun, DIAO Yansong\*

(School of Civil Engineering, Qingdao University of Technology, Qingdao 266525, China)

**Abstract:** Among the existing researches on structural damage identification that use CNN network to extract features, problems such as low accuracy and low recognition efficiency can be found when only 1D-CNN and 2D-CNN are used to extract features for damage identification. Therefore, this paper proposes a structural damage identification method based on generalized S-transform and parallel neural network. In order to enrich the feature dimensions of the input signal, the filtered signal is converted into a time-frequency diagram by using the generalized S-transform. At the same time, the one-dimensional acceleration response signal and the two-dimensional time-frequency diagram are input into 1D-CNN and 2D-CNN respectively for time-frequency and time-frequency feature extraction, and the characteristics are spliced in the convergence layer. Then, the damage identification results are classified through FC layer and Softmax layer. The proposed parallel network model is verified by the second-stage test data of IASC-ASCE SHM Benchmark structure. The results show that the proposed network model has higher identification accuracy and efficiency than

收稿日期: 2022-11-04

基金项目: 山东省自然科学基金资助项目(ZR2021ME239)

作者简介: 李行健(1997-), 男, 江苏无锡人。硕士, 研究方向为结构损伤识别。E-mail: 1448707274@qq.com。

\* 通信作者: 刁延松(1968-), 男, 山东烟台人。工学博士, 教授, 主要从事结构损伤识别及钢结构等方面的研究。  
E-mail: diaoys@163.com。

other similar methods.

**Key words:** damage identification; generalized S-transform; convolution neural network; time-frequency analysis; feature fusion

当土木工程结构发生损伤时,其物理参数(如质量、阻尼和刚度等)的改变会导致它的振动特性(如频率、振型和模态阻尼)随之改变,而传感器技术、计算机技术和信号分析技术的快速发展,使得人们能够通过分析传感器采集到的结构振动响应信号,捕捉其振动特性的变化,进而实现结构损伤的定位和程度量化<sup>[1]</sup>。

结构的响应信号分析是损伤识别和损伤分类的重要途径,也是影响结构损伤分类精度的重要因素。在提取结构振动信号特征方面一般使用时域分析、频域分析和时频域分析。目前常用的时频分析方法包括短时傅里叶变换(Short-time Fourier transform, STFT)、小波变换(Wavelet transform, WT)<sup>[2]</sup>和广义 S 变换(ST)<sup>[3]</sup>等。

近年来,人工智能发展迅速,基于传统机器学习的损伤识别方法在结构健康监测领域得到了广泛应用。目前常用的机器学习方法有 k 近邻分类算法(k-NN)<sup>[4]</sup>,随机森林算法(RF)<sup>[5]</sup>,支持向量机(SVM)<sup>[6]</sup>,反向传播神经网络(BP)<sup>[7]</sup>等。传统机器学习需要人工提取特征,对专业知识的依赖性大;网络结构简单,仅适用于数据量较少的情况。

深度学习具有能够自动提取特征、端到端的学习方式和复杂的网络结构的特点,擅长处理大数据集,在拟合能力和识别精度上优于传统机器学习。AZIMI 等<sup>[8]</sup>将时域信号转化为柱状图,输入 2D-CNN 进行系统状态评估。COFRE-MARTEL 等<sup>[9]</sup>将结构传递率函数灰度图输入 2D-CNN 识别结构损伤位置和程度。LIU 等<sup>[10-11]</sup>利用 STFT 将信号转换为二维时频图,并输入 2D-CNN,先后完成了有支撑钢框架结构和薄板的损伤识别。ABDELJABER 等<sup>[12]</sup>利用卡塔尔大学看台模拟器(QUGS)试验和钢梁、梁桥结构试验,验证了 1D-CNN 对基于振动的实时结构损伤检测和高定位的高准确率和灵敏度。KHODABANDEHLOU 等<sup>[13]</sup>将钢筋混凝土桥梁模型振动台试验中实测的振动响应数据,以矩阵的形式输入到 2D-CNN 中进行损伤识别研究,证明了 2D-CNN 可以利用结构的振动响应进行结构损伤识别。ZOU 等<sup>[14]</sup>提出了一种基于 CNN 的铝合金加筋板冲击损伤识别方法,用来准确识别冲击位置和损伤程度,加筋板仿真模拟验证了该方法具有较好的准确率和效率。TANG 等<sup>[15]</sup>将加速度数据的时域图和频域图叠加成的复合图输入到 2D-CNN 中进行数据异常检测及分类,并利用在役大跨度斜拉桥的实测加速度响应数据验证了该方法的有效性。

上述基于振动响应和深度学习模型的结构损伤识别研究取得了很大的进步,但仍存在损伤识别准确率不高、效率低的问题,主要因为深度学习模型单纯从时域振动响应信号或时频域振动响应信号提取的特征较少,容易丢失损伤数据的重要特征。因此,本文提出一种基于广义 S 变换和并联神经网络的结构损伤识别研究方法,先利用滤波器对信号进行滤波,而后通过广义 S 变换得到时频图,并将其按 8:1:1 的比例分为训练集、验证集、测试集输入到并联网进行训练与测试。其中并联网中 1D-CNN 的输入是滤波后的一维振动响应信号,2D-CNN 的输入是二维时频图,然后将两个网络输出的一维向量拼接起来,通过全连接层和 Softmax 层进行损伤结果分类。利用 IASC-ASCE SHM Benchmark 第二阶段结构试验数据,将该方法与其他网络模型的损伤识别方法的性能进行了比较,证明了所提方法的有效性。

## 1 基本原理

### 1.1 广义 S 变换

S 变换基本小波是 Morlet 小波<sup>[3]</sup>。S 变换结合了 STFT(短时傅里叶变换)和 WT(小波变换)的优势,能根据信号频率的变化自适应地选择时间窗的大小,而且 S 变换选择的高斯窗函数,省去了窗函数选择这一繁琐的步骤。信号  $x(t)$  的 S 变换定义为

$$(\tau, f) = \int_{-\infty}^{+\infty} x(t) g(t - \tau, f) \exp(-j2\pi ft) dt \quad (1)$$

$$X(\tau, f) = \int_{-\infty}^{+\infty} x(t) \frac{|f|}{\sqrt{2\pi}} \exp\left(-\frac{(t-\tau)^2 f^2}{2}\right) \exp(-j2\pi ft) dt \quad (2)$$

式中: 高斯函数  $g(t-\tau, f)$  由频率  $f$  和时移  $\tau$  控制。

定义  $\omega(t, f) = \frac{|f|}{\sqrt{2\pi}} \exp\left(-\frac{(\tau-t)^2 f^2}{2}\right) \exp(-j2\pi ft)$  为基本小波。广义 S 变换是对 S 变换进行了高斯窗的改造, 其定义为

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t) \frac{\lambda |f|^p}{\sqrt{2\pi}} \exp\left(-\frac{\lambda^2 f^{2p} (\tau-t)^2}{2}\right) \exp(-j2\pi ft) dt \quad (3)$$

式中:  $\lambda > 0; p > 0$ 。

当  $\lambda = 1, p = 1$  时, 即为标准 S 变换。

## 1.2 卷积神经网络

CNN 是一种带有卷积结构的深度学习模型。它所包含的模块有输入层、卷积层、池化层、全连接层和输出层。其结构如图 1 所示。其中卷积层和池化层是 CNN 的核心部分。在卷积层中, 滤波器(也叫卷积核)对输入信息在局部区域内作卷积运算来提取局部空间特征, 再将局部特征整合作为下一层的输入。计算公式为

$$\mathbf{a}^l = \sigma(\mathbf{W}^l * \mathbf{a}^{l-1} + \mathbf{b}^l) \quad (4)$$

式中:  $l$  为层数;  $\mathbf{a}$  为输入矩阵;  $\mathbf{W}$  为卷积核权重;  $\mathbf{b}$  为偏差;  $\sigma$  为激活函数;  $*$  为卷积运算。




图 1 CNN 基本结构

池化层通常连接卷积层之后, 通过池化滤波器进行特征提取, 进一步压缩输入矩阵大小, 有助于提高模型的训练效率。常见的池化层有最大值池化和均值池化等。在图像分类中, 一般采用最大值池化。最大值池化公式为

$$y_{ijk} = \max(y_{i'j'k} : i \leq i' < i + p) \quad (5)$$

式中:  $p$  为池化窗口长度;  $y_{i'j'k}$  为池化之前区域值;  $y_{ijk}$  为池化后的值。

Dropout 层是用来防止网络模型过拟合, 其标准过程由式(6)给出。

$$y = f(\mathbf{W}x) \cdot \mathbf{m}, m_i \sim \text{Bernoulli}(p) \quad (6)$$

式中:  $f$  为激活函数;  $x$  为输入量;  $\mathbf{W}$  为权值矩阵;  $y$  为输出量。

全连接层连接在卷积层和池化层后, 其作用是处理由卷积层和池化层提取出的特征全部展开成一维向量并拼接在一起, 对输入信息进行分类。

$$\mathbf{z} = \mathbf{W}_z \mathbf{x} + \mathbf{b}_z \quad (7)$$

式中:  $\mathbf{x}$  为输入向量;  $\mathbf{z}$  为输出向量;  $\mathbf{W}_z$  和  $\mathbf{b}_z$  分别为权重和偏置项。

softmax 层一般连接在全连接层后, 其中 softmax 层的 softmax 函数对输入向量进行归一化, 其输出为元素总和等于 1 的  $n \times 1$  ( $n$  为分类数) 向量, 这些元素将在分类层中作为分类概率。计算公式为

$$y'_j = \text{softmax}(z_j) = \frac{e^{z_j}}{\sum_{i=1}^n e^{z_i}} \quad (8)$$

式中:  $y'_j$  为 softmax 输出的每个类别的概率。

分类层为最后的输出层,该层根据 softmax 输出的每个类别的概率进行最后分类并计算损失值,softmax 对应的损失函数为对数损失函数,计算公式为

$$L = \log \sum_{i=1}^n e^{z_i - z_j} \quad (9)$$

式中: $L$  为损失值(Loss)。

## 2 并联神经网络模型的结构损伤识别方法

本文所提出的基于并联神经网络模型的结构损伤识别流程如下:

1) 将采集到的结构加速度响应信号通过 FIR 滤波器得到滤除高频噪声的加速度响应信号,并将其分段。

2) 将分好段的振动信号通过广义 S 变换生成相对应时频图。

3) 将振动加速度响应信号和时频图构成样本集,并按 8 : 1 : 1 分为训练集、验证集和测试集。汇总所有样本集下的训练集、验证集和测试集,形成最终的数据集。

4) 将训练集输入到并联神经网络模型(模型结构见图 5)中进行模型结构与参数调优,同时输入验证集对模型进行初步评估,通过试算法确定模型最优参数组合结构。

5) 将测试集输入到训练好的网络模型中进行测试,对结构损伤状态进行识别和分类。

具体方法流程如图 2 所示。

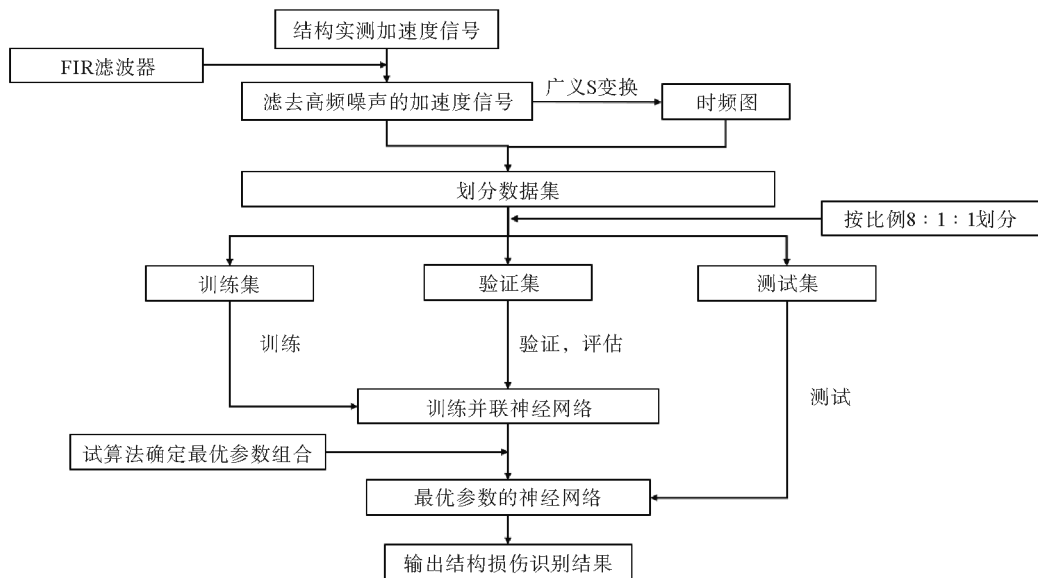


图 2 方法流程

### 2.1 数据集制作

在数据预处理阶段,考虑到噪声的影响,首先将实测的加速度响应信号通过 FIR 滤波器滤除高频噪声。而为了丰富统计信息各个层次的特征,利用 CNN 实现特征融合,即不仅将一维响应信号作为 1D-CNN 网络的输入提取其时域特征,又将二维时频图作为 2D-CNN 网络的输入提取其时频域特征。图 3 为结构加速度响应信号(工况 7 下 14 号测点的响应数据)。图 4 为其对应的时频图。




图3 结构加速度响应信号(工况7下14号测点的响应数据)

### 2.2 并联神经网络模型

并联神经网络是对1D-CNN模型和2D-CNN模型进行了并联,其模型结构如图5所示。该模型先将滤波后的加速度信号和与之对应产生的时频图分别放入1D-CNN网络和2D-CNN网络中进行特征提取,其中1D-CNN用来提取信号的时域特征,2D-CNN用来提取时频域特征,丰富两个不同维度的特征,充分发挥该网络模型特征融合的优势。然后进一步将提取的特征展开成一维向量,在汇聚层进行拼接,最后通过Dropout层、FC层和Softmax层,得到结构损伤状态的分类结果。




图4 时频

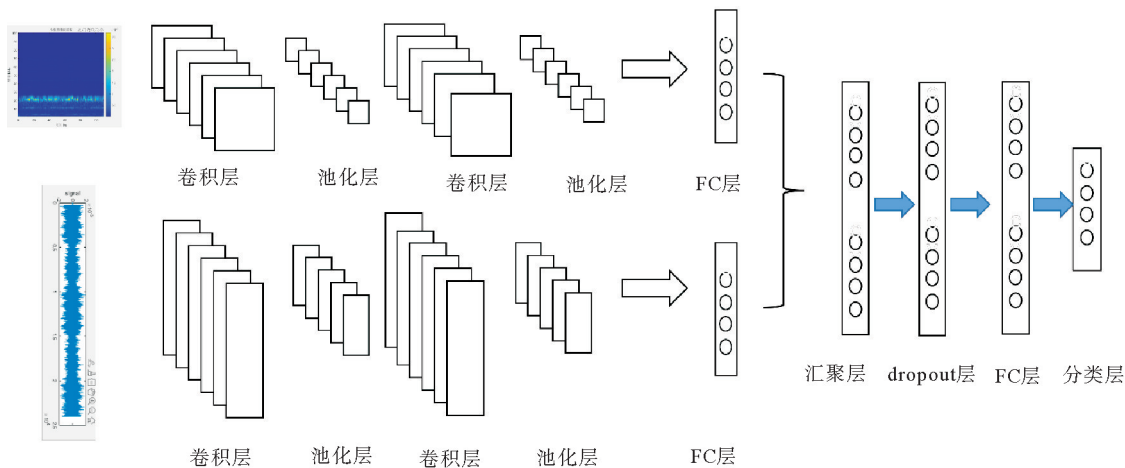


图5 并联神经网络模型结构

## 3 IASC-ASCE SHM Benchmark 第二阶段结构试验验证

### 3.1 IASC-ASCE SHM Benchmark 试验模型及工况设置

本文所选取的试验数据来自 IASC-ASCE SHM Benchmark 第二阶段结构试验实测数据。加拿大英属哥伦比亚大学(UBC)地震工程实验室所建立的 Benchmark 试验模型,其主体结构是一个4层2×2跨,

缩尺比例为 1/3 的钢框架结构<sup>[16]</sup>,是国内外学者广泛认可的用来测试网络模型性能的试验结构模型(图 6)。

如图 6(b)所示,在 Benchmark 基准结构中布置了 15 个加速度传感器用来采集振动加速度响应信号,从底层开始,分别在每层的东面、西面和中间柱位置放置加速度传感器,东西面放置的传感器采集结构在南北方向的振动响应信号,中间柱位置放置的传感器用来采集结构在东西方向的振动响应信号。试验里的损伤工况通过拆除结构中的层间支撑或松动梁柱之间的螺栓来进行分类,工况介绍及数据划分见表 1。




图 6 IASC-ASCE SHM Benchmark 结构和传感器布置

### 3.2 样本集的构成与制作

由表 1 可知,结构的损伤位置均布置在结构的东面和西面,因此,分别选取中心柱附近 14 号传感器实测的加速度响应信号进行损伤识别研究。加速度响应信号的采样频率为 200 Hz,剔除掉激励启动前的记录数据,从每个响应信号上选取了 9~120 s 间的 22 000 个数据作为 1D-CNN 网络的输入,并用时频分析的方法生成时频图,其作为 2D-CNN 网络的输入。

FIR 滤波器的设计方法为等波纹最佳逼近法,根据模型结构的自振频率,设置通带频率为 23 Hz,阻带频率为 25 Hz,用来滤除响应信号中 24 Hz 以上的频率成分。

表 1 损伤工况及数据集划分

类别标签	损伤工况	训练集数量/个	验证集数量/个	测试集数量/个
1	保留全部支撑(无损伤)	320	40	40
2	拆除所有楼层东面全部支撑	320	40	40
3	拆除所有楼层东面南侧的跨间支撑	320	40	40
4	拆除第 1,4 层东面南侧的跨间支撑	320	40	40
5	拆除第 1 层东面南侧的跨间支撑	320	40	40
6	拆除所有楼层的东面支撑和第 2 层北面支撑	320	40	40
7	拆除所有楼层的所有支撑	320	40	40
8	工况 7+松开所有楼层东面北侧梁两端的螺栓	320	40	40
9	工况 7+松开第 1,2 层东面北侧梁两端的螺栓	320	40	40

将滤波后的加速度响应信号按每 2250 个数据为一组,相邻组段重叠数为 2200 进行分组。将每组大小为 2250 的响应信号通过连续小波变换生成时频图,作为 2D-CNN 网络模型的输入样本,每段大小为 2250×1 的向量为 1D-CNN 的输入样本。最终每种工况下生成 400 个样本。样本制作如图 7 所示。




图 7 样本制作

### 3.3 时频图分析

滤波后的加速度响应信号通过广义 S 变换生成时频图,其中采样频率  $F_s=200$ 。图 8(a)(b)分别为无损伤工况下和拆除所有楼层支撑工况下 14 号传感器上的数据生成的时频。由图 8(a)可以看出,无损伤工况下,响应信号的主频带集中在 20 Hz 左右。由图 8(b)可以看出,在拆除所有支撑的工况下,响应信号的主频带比较分散,主要分布在 10~20 Hz。结果表明,无损伤工况下和有损伤工况状态下的时频特征明显不同。

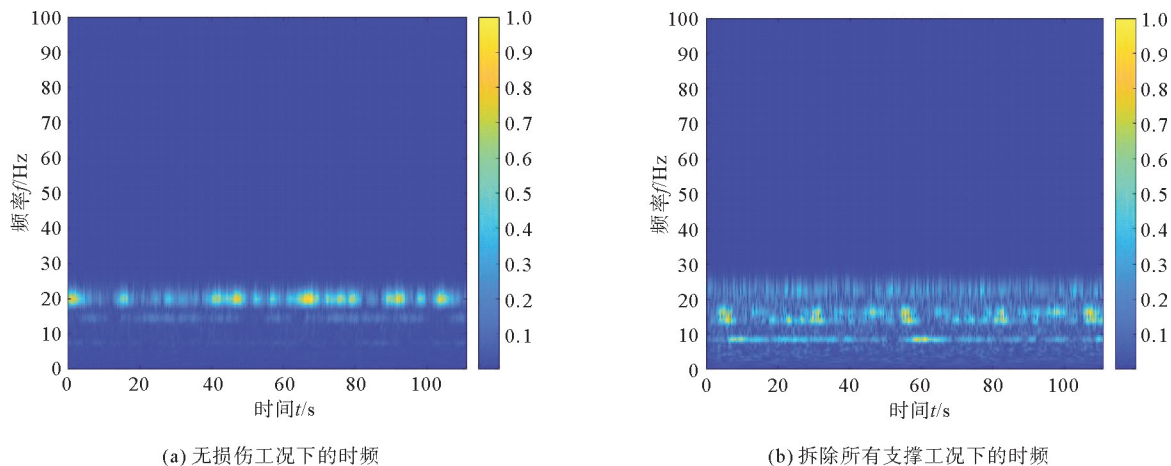


图 8 无损伤工况下和拆除所有支撑工况下的时频

### 3.4 试验环境和网络模型参数

硬件环境:CPU 为 Intel i9-7980XE(2.6 GHz),内存为 64 GB,固态硬盘为 464 GB, GPU 为 RTX 2080(2×8 G)。

软件环境:MATLAB 2020a。

本文以损伤识别结果的准确率和训练时长为指标,通过试算法确定最优并行神经网络模型结构与参数组合,并行神经网络中 1D-CNN 的模型层次和参数见表 2。并行神经网络中 2D-CNN 的模型层次和参数见表 3。并行神经网络的最优参数组合见表 4。

表 2 1D-CNN 模型参数

层类型	卷积核尺寸	卷积核数量	特征图尺寸
输入层	—	—	1×2200
卷积层 1	7×1	6	1×732
池化层 1	2×1	6	1×366
卷积层 2	7×1	16	1×360
池化层 2	2×1	16	1×180
FC 层	1×1	2280	2280

表 3 2D-CNN 模型参数

层类型	卷积核尺寸	卷积核数量	特征图尺寸
输入层	—	—	64×64
卷积层 1	5×5	6	60×60
池化层 1	2×2	6	30×30
卷积层 2	5×5	16	26×26
池化层 2	2×2	16	13×13
FC 层	1×1	2704	2704

### 3.5 试验结果

将 Benchmark 结构中 14 号传感器采集到的振动加速度响应信号生成数据样本集,并输入到并联网络模型中,进行结构损伤识别,以损伤识别分类结果的准确度和训练时长为指标,以 1D-CNN 和 2D-CNN 网络模型为对比模型,通过比较来验证本文所提出并联神经网络的有效性。其中,图 9—14 分别为三种网络模型下的训练进程及其混淆矩阵。表 5、表 6 分别为在各网络模型中进行损伤识别分类的平均准确率和平均训练时长,其中训练时长是各模型收敛完成所用的时间。

表 4 网络模型参数

网络优化器	adam
学习率	0.001
L2 正则化	0.000 01
批大小	50
迭代次数/次	1 800




图 9 并联神经网络的训练进程

—●— 准确率; —▲— 验证准确率;  
—○— 损失; —■— 验证损失

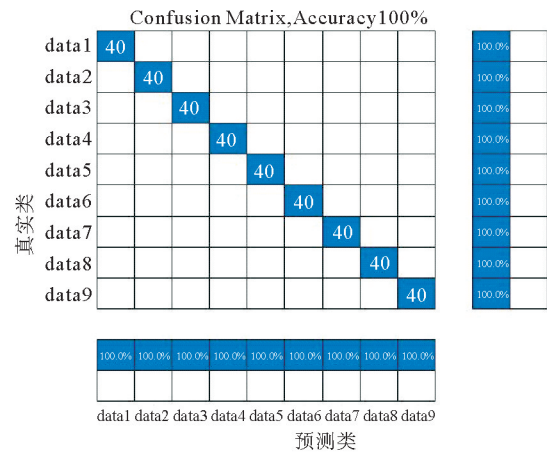


图 10 并联神经网络的混淆矩阵




图 11 2D-CNN 的训练进程

—●— 准确率; —▲— 验证准确率;  
—○— 损失; —■— 验证损失

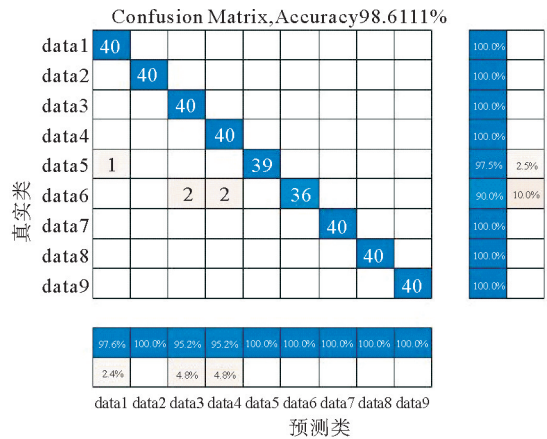


图 12 2D-CNN 的混淆矩阵

从表 5 可以看出,1D-CNN 网络模型的准确率最低,2D-CNN 网络模型准确率为 98.61%,而并联神经网络模型的准确率稳定在 100%。从表 6 可以看出,在训练时长上,并联神经网络训练时长远少于其他两种网络模型,基本维持在 38 s 左右。而从图 9,11,13 可以看出,本文所提出的并联神经网络模型的收敛趋势稳定,收敛速度最快。主要原因在于并联神经网络模型结合了 1D-CNN 和 2D-CNN 的优势,不仅丰富了响应信号不同维度的特征,还同时提取了响应信号时域和频域的特征,这更加有利于网络捕捉信号的特征关系,提高了模型损伤识别准确率和模型训练效率。因此,并联神经网络模型在损伤识别上具有更好的综合识别效果,与期望相符合。




图 13 1D-CNN 的训练进程  
 - - - 准确率; — 验证准确率;  
 ····· 损失; - · - 验证损失

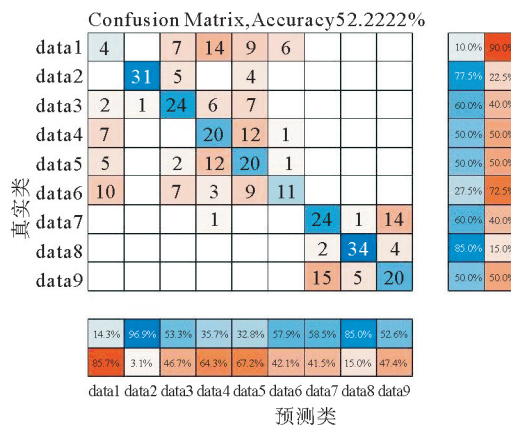


图 14 1D-CNN 的混淆矩阵

表 5 三种网络模型的平均训练准确率 %

网络模型	准确率
1D-CNN	52.22
2D-CNN	98.61
并联神经网络	100.00

表 6 三种网络模型的平均训练时长 s

网络模型	训练时长
1D-CNN	45
2D-CNN	104
并联神经网络	38

### 4 结论

本文提出一种基于广义 S 变换和并联网络的结构损伤识别方法,将一维加速度响应信号、二维时频图和 CNN 结合起来,通过 1D-CNN 和 2D-CNN 提取出不同维度的特征,且能同时捕捉到响应信号中时频域的特征,从而极大地提高了结构损伤识别的准确率和效率。IASC-ASCE SHM Benchmark 第二阶段结构试验数据进一步证明了基于广义 S 变换和并联神经网络结构损伤识别方法的可行性。和其他网络模型相比,本文所提出的方法有更高的准确率和效率,为结构损伤识别分类提供了新的物理理想模型。

### 参考文献 (References):

[1] AVCI O, ABDELJABER O, KIRANYAZ S, et al. A review of vibration-based damage detection in civil structures: From traditional methods to machine learning and deep learning applications[J]. Mechanical Systems and Signal Processing, 2021, 147: 107077.

[2] MORLET J, ARENS G, FOURGEAU E, et al. Wave propagation and sampling theory, Part II: Sampling theory and complex waves[J]. Geophysics, 1982, 47(2): 222-236.

[3] STOCKWELL R G, MANSINHA L, LOWE R P. Localization of the complex spectrum: The S transform[J]. IEEE Trans on Signal Processing, 1996, 17: 998-1001.

[4] VITOLA J, POZO F, TIBADUIZA D A, et al. A sensor data fusion system based on k-nearest neighbor pattern classification for structural health monitoring applications[J]. Sensors, 2017, 17(2): 417.

[5] ZHOU Q, ZHOU H, ZHOU Q, et al. Structure damage detection based on random forest recursive feature elimination[J]. Mechanical Systems and Signal Processing, 2014, 46(1): 82-90.

[6] 孙艳丽, 杨娜, 张正涛, 等. 基于核主元分析和支持向量机的结构损伤识别研究[J]. 应用基础与工程科学学报, 2018, 26(4): 888-900.

SUN Yanli, YANG Na, ZHANG Zhengtao, et al. Structural damage identification study based on kernel component analysis and support vector machine[J]. Journal of Applied Basic and Engineering Science, 2018, 26(4): 888-900.

[7] 孙宗光, 高赞明, 倪一清. 基于神经网络的损伤构件及损伤程度识别[J]. 工程力学, 2006(2): 18-22.

SUN Zongguang, GAO Zanming, NI Yiqing. Identification of damaged members and damage extent in bridge deck by neural network[J]. Engineering Mechanics, 2006(2): 18-22.

[8] AZIMI Mohsen, PEKCAN Gokhan. Structural health monitoring using extremely compressed data through deep learning[J]. Computer-Aided Civil and Infrastructure Engineering, 2020, 35: 597-614.

- [9] COFRE-MARTEL Sergio, KOBRICH Philip, DROGUETT Enrique Lopez, et al. Deep convolutional neural network-based structural damage localization and quantification using transmissibility data[J]. Shock and Vibration, 2019, 27: 9859281.
- [10] LIU Heng, ZHANG Yunfeng. Deep learning-based brace damage detection for concentrically braced frame structures under seismic[J]. Advances in Structural Engineering, 2019, 22(16): 3473-3486.
- [11] LIU Heng, ZHANG Yunfeng. Deep learning based crack damage detection technique for thin plate structures using guided lamb wave signals[J]. Smart Materials and Structures, 2020, 29 (1): 015032.
- [12] ABDELJABER O, AVCI O, KIRANYAZ S, et al. Real-time vibration-based structural damage detection using one-dimensional convolutional neural networks[J]. Journal of Sound & Vibration, 2017, 388: 154-170.
- [13] KHODABANDEHLOU H, PEKCAN G, FADALI M S. Vibration-based structural condition assessment using convolution neural networks[J]. Structural Control & Health Monitoring, 2019, 26(2): e2308. 1-e2308. 12.
- [14] ZOU B, 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, 99: 1-12.
- [15] TANG Z, CHEN Z, BAO Y, et al. Convolutional neural network-based data anomaly detection method using multiple information for structural health monitoring[J]. Structural Control & Health Monitoring, 2019, 26(1): e2296. 1-e2296. 22.
- [16] DYKE S J, BERNAL D, BECK J, et al. Experimental phase II of the structural health monitoring benchmark problem[C]//Proceedings of the 16th ASCE Engineering Mechanics Conference. 2003.

(责任编辑 姜锡方;英文校审 程文华)

---

### (上接第 18 页)

- [12] 王海东,刘举. 考虑 SSI 和填充墙刚度效应的 RC 框架结构抗震性能研究[J]. 湖南大学学报(自然科学版),2019,46(3):41-49.  
WANG Haidong,LIU Ju. Study on seismic performance of RC frame structure considering SSI and infill wall stiffness effects[J]. Journal of Hunan University (Natural Science Edition),2019,46(3):41-49.
- [13] 叶列平,陆新征,赵世春,等. 框架结构抗地震倒塌能力的研究:汶川地震极震区几个框架结构震害案例分析[J]. 建筑结构学报,2009,30(6):67-76.  
YE Lieping,LU Xinzhen,ZHAO Shichun,et al. Research on the seismic collapse resistance of frame structures; Case study of several frame structures in the extreme seismic zone of Wenchuan earthquake[J]. Journal of Building Structures,2009,30(6):67-76.
- [14] 杨伟松. 学校多层 RC 框架结构地震倒塌机理研究[D]. 哈尔滨:中国地震局工程力学研究所,2015.  
YANG Weisong. Study on earthquake collapse mechanism of multi-story RC frame structure in school[D]. Harbin;Institute of Engineering Mechanics, China Earthquake Administration,2015.
- [15] 王波,郭迅,宣越,等. 设置半高连续填充墙的 RC 框架结构地震倒塌振动台试验[J]. 应用基础与工程科学学报,2021,29(3):656-668.  
WANG Bo,GUO Xun,XUAN Yue,et al. Shaking table test of RC frame structure with half-height continuous infill wall set up for earthquake collapse[J]. Journal of Applied Basic and Engineering Sciences,2021,29(3):656-668.
- [16] 王广庆. 砌块填充墙的精细化模拟与等效斜撑建模[D]. 哈尔滨:哈尔滨工业大学,2016.  
WANG Guangqing. Refined simulation of block infill walls with equivalent diagonal bracing modeling[D]. Harbin;Harbin Institute of Technology,2016.
- [17] ACI. TMS 402-13, Building code requirements for masonry structures[S]. Farmington Hills:American Concrete Institute,2013.
- [18] ATC-63,Quantification of building seismic performance factors[S]. Washington D C:Applied Technology Council, 2009.
- [19] VAMVATSIKOS D,CORNELL C. Incremental dynamic analysis[J]. Earthquake Engineering and Structural Dynamics, 2002, 31(3):491-514.

(责任编辑 姜锡方;英文校审 程文华)