

结合多通道MTF和CNN的框架结构损伤识别方法*

梁 韬¹, 叶涛萍², 李守文², 方佳畅¹, 黄天立¹

(1. 中南大学土木工程学院 长沙, 410075) (2. 中建二局第一建筑工程有限公司 北京, 100023)

摘要 为提高复杂框架结构损伤识别的准确率,提出了一种基于多通道马尔可夫变迁场(multi-channel Markov transition field, 简称MCMTF)和卷积神经网络(convolutional neural network, 简称CNN)的框架结构损伤识别方法。首先,采用MCMTF理论将原始一维振动信号转换为二维图像,实现数据升维和多通道数据融合;其次,以MCMTF转换后的图像数据集作为输入训练CNN模型;最后,经调参优化自动提取损伤敏感特征,并实现损伤识别。将该方法应用于IASC-ASCE Benchmark框架结构数值模型及3层钢框架结构模型试验,对比研究了多通道MTF、单通道MTF和原始数据矩阵3种数据输入方式,CNN、长短时记忆(long short term memory, 简称LSTM)神经网络和深度神经网络(deep neural network, 简称DNN)3种网络模型,以及噪声对框架结构损伤识别准确率的影响。结果表明:MCMTF与CNN结合方法的损伤识别准确率最优且具有良好的鲁棒性,其对Benchmark框架数值模型模拟损伤的识别准确率可达94.4%,对3层钢框架试验模型实际损伤的识别准确率可达98.4%。

关键词 损伤识别;振动响应;卷积神经网络;多通道马尔可夫变迁场;数据升维;数据融合

中图分类号 TU312.3;TH825

引 言

基于振动的损伤识别是结构健康监测的关键技术之一,其主要目的是从监测系统采集的振动信号中提取结构损伤敏感指标,以监测结构运营状态^[1-2]。近年来,随着计算能力和智能算法的发展,机器学习尤其是深度学习方法在损伤识别领域得到广泛应用并取得了显著效果^[3-4]。

卷积神经网络作为深度神经网络之一,在图像分类及模式识别问题中均表现出优越性能。Abdeljaber等^[5-6]结合一维卷积神经网络(one dimensional CNN, 简称1D-CNN)模型从原始加速度信号中自动提取最优损伤敏感特征,验证了所提方法良好的损伤识别能力。Lin等^[7]设计了CNN模型关联动力响应与损伤信息,简支梁数值模拟结果表明,所提方法具有良好的损伤识别能力和抗噪性能。李雪松等^[8]通过IASC-ASCE Benchmark框架模型提取加速度数据矩阵,与经验模态分解特征向量、小波包变换特征向量进行对比分析,证明了CNN自动提取特征进行损伤识别分类的准确性和稳定性。李书进等^[9]采用混凝土框架算例,对比分析了1D-CNN和2D-CNN的损伤识别效果。

由于卷积神经网络具有强大的图像分类识别能

力,一些学者将结构振动信号转换为图像,进而充分发挥出CNN的性能。王慧等^[10]以各个振动响应测点为参考点构建内积矩阵,以此为结构特征参数输入2D-CNN模型,通过加筋壁板结构试验验证了所提方法的有效性。Li等^[11]提出了一种融合多通道信号的无阈值组合递归图和多标签CNN的结构损伤识别方法,其具有较高的识别精度、计算效率和鲁棒性。骆勇鹏等^[12]利用格拉姆角场理论将振动信号转换为二维图像,结合浅层2D-CNN模型,高效地识别了结构损伤。Dang等^[13]通过短时傅里叶变换将振动信号转换为时频谱图,通过三跨连续梁、3层框架结构和斜拉桥算例,验证了2D-CNN模型具有更高的损伤识别准确率。

一维时序信号和二维图像都可以输入到卷积神经网络,自动提取特征进而实现结构损伤识别,然而针对复杂框架结构,利用CNN的损伤识别方法在识别准确率上不够理想。为充分发挥CNN强大的图像处理功能优势,提高CNN针对复杂框架结构损伤识别的准确性,笔者通过改进神经网络模型的数据输入方式,即采用多通道马尔可夫变迁场理论将原始一维振动信号转换为二维图像,实现数据升维和多通道数据融合,并以MCMTF转换后的图像数据集作为输入训练CNN模型,提出了一种基于MC-

* 国家自然科学基金资助项目(52078486);中国建筑第二工程局有限公司青年课题资助项目(2022QN010001)

收稿日期:2022-08-17;修回日期:2022-09-12

MTF和CNN的结构损伤识别方法。通过IASC-ASCE Benchmark多层框架结构模型数值模拟和3层框架结构试验,验证了所提方法的有效性。

1 马尔可夫变迁场

1.1 单通道马尔可夫变迁场

单通道马尔可夫变迁场(single-channel Markov transition field,简称SCMTF)是一种将时间序列编码成二维图像的方法^[14],表示离散时间序列的变迁概率,可以保留信号的时间依赖性和状态变迁信息,该方法提取的特征能够表示时间和频率上的动态变化。

对于采集的时间序列 $X = \{x_1, x_2, \dots, x_i, \dots, x_n\}$,先将其取值范围划分为 Q 个分位数箱,并将每个值 x_i 映射到相应的箱子 $q_j (j \in [1, Q])$,然后沿时间步长以第一马尔可夫链方式计算分位数箱之间的迁移概率,构造一个 $Q \times Q$ 加权邻接矩阵 W ,即

$$W = \begin{bmatrix} w_{11} & \dots & w_{1Q} \\ \vdots & & \vdots \\ w_{Q1} & \dots & w_{QQ} \end{bmatrix} \quad (1)$$

其中: $w_{ij} (i, j \in \{1, 2, \dots, Q\})$ 表示 q_j 中的元素被 q_i 中元素跟随的概率。

$$w_{ij} = P(x_i \in q_i | x_{i-1} \in q_j) \quad (2)$$

$\sum_j w_{ij} = 1$ 归一化后, W 即为马尔可夫矩阵。马尔可夫矩阵抛弃了时间序列 X 分布与时间步长依赖性之间的条件关系,去掉时间依赖性会导致大量信息丢失。为克服此缺点,马尔可夫变迁场将每个迁移概率沿时间顺序排列拓展马尔可夫矩阵,即

$$M = \begin{bmatrix} M_{11} & \dots & M_{1n} \\ M_{21} & \dots & M_{2n} \\ \vdots & & \vdots \\ M_{n1} & \dots & M_{nn} \end{bmatrix} = \begin{bmatrix} w_{ij} | x_1 \in q_i, x_1 \in q_j & \dots & w_{ij} | x_1 \in q_i, x_n \in q_j \\ w_{ij} | x_2 \in q_i, x_1 \in q_j & \dots & w_{ij} | x_2 \in q_i, x_n \in q_j \\ \vdots & & \vdots \\ w_{ij} | x_n \in q_i, x_1 \in q_j & \dots & w_{ij} | x_n \in q_i, x_n \in q_j \end{bmatrix} \quad (3)$$

其中:分位数箱 q_i 和 q_j 分别为时间步长 i 和 j 上的数据; M_{ij} 为 q_i 到 q_j 的迁移概率。

1.2 多通道马尔可夫变迁场

结构健康监测系统一般安装有多个传感器,仅采用SCMTF编码一个传感器上采集的时间序列信号进行分析,难以识别复杂框架结构的实际损伤情

况。因此,笔者提出多通道马尔可夫变迁场的信号编码方法,即在SCMTF保留时间依赖性的基础上,增加空间维度,关联并融合多个传感器测点时间序列信号之间的空间信息。

对于一组时间序列 $S = \{X_1, X_2, \dots, X_i, \dots, X_K\}$,其中: $X_i = \{x_1, x_2, \dots, x_i, \dots, x_n\} (i \in [1, K])$ 为第 i 个传感器上采集的时间序列经编码后形成第 i 个通道的二维图像; K 为通道数,即结构上安装的传感器数量; n 为时间步长。将一组时间序列 S 经空间维度数据融合后,转换成一张具有 K 个通道的二维图像,即 K 个图像在深度维度上进行叠加,其本质为一个三维数组。MCMTF编码示意图如图1所示。




图1 MCMTF编码示意图

Fig.1 Schematic of MCMTF coding

2 卷积神经网络

2.1 基本结构

卷积神经网络核心思想是通过一系列卷积、非线性激活函数映射和池化等操作对输入样本进行迭代学习和特征提取。CNN的基本结构由输入层、卷积层、池化层、全连接层及输出层构成。本研究采用的MCMTF-CNN结构示意图见图2。




图2 MCMTF-CNN结构示意图

Fig.2 Schematic of the MCMTF-CNN architecture

2.1.1 卷积层

卷积层通常包含多个卷积核,卷积操作过程为输入与卷积核之间进行点积运算,卷积核在整个输入图像中以特定步长来回滑动,然后将结果送入激活函数,以局部区域连接和权值共享的方式得到输入图像的特征图,减少了参数量,降低了网络复杂度。卷积运算过程为

$$Z_j^l = f\left(\sum_{i \in M_j^l} \omega_{ij}^l * x_i^{l-1} + b_j^l\right) \quad (4)$$

其中: Z_j^l, x_i^{l-1} 分别为第 l 层第 j 通道、第 $l-1$ 层第 i 通道的特征值; ω_{ij}^l, b_j^l 分别为第 l 层权重和偏差; M_j^l 为输入特征图的集合; f 为激活函数。

本研究模型均采用线性整流 Relu 函数进行非线性变换,其形式为 $f(x) = \max(0, x)$ 。Relu 函数通过将部分权重归零以增加计算效率。

2.1.2 池化层

池化层比卷积层更大幅度地减少了连接个数,具有特征降维、特征不变性和降低过拟合的作用。本研究使用最大值池化和平均值池化 2 种池化函数。最大值池化选取图像区域的最大值作为该区域池化后的值,平均值池化则计算图像区域的平均值。

2.1.3 全连接层

全连接层中的每个神经元与其前 1 层的所有神经元进行全连接,整合卷积层或池化层中具有类别区分性的局部信息。神经元的激励函数采用 Relu 函数,最后 1 层全连接层的输出值采用 Softmax 逻辑回归函数进行多分类,其计算公式为

$$\text{softmax}(z_i) = \frac{\exp(z_i)}{\sum_{i=1}^n \exp(z_i)} \quad (5)$$

其中: z_i 为第 i 节点的输出值; n 为输出分类类别个数。

2.2 降低过拟合措施

过拟合指模型训练误差和测试误差之间的差距太大,模型复杂度过高,泛化能力差。为降低过拟合现象,本研究采用了 Dropout 和正则化 2 种方法。

2.2.1 Dropout

Dropout 按一定概率随机丢弃网络中的一些隐藏神经元,使处理后的网络模型减少对局部特征的依赖,增强泛化能力并加快学习速度。本研究在全连接层之间添加了 Dropout 层,丢弃参数比例为 50%。

2.2.2 正则化

损失函数用于评估模型预测值与真实值之间的差别,卷积神经网络的训练目标是使损失函数最小化。笔者采用交叉熵损失函数,其表达式为

$$\text{Loss} = -\sum_{i=1}^n [y_i \log p_i + (1 - y_i) \log (1 - p_i)] \quad (6)$$

其中: y_i 为真实值; p_i 为预测值; n 为分类类别个数。

正则化方法在损失函数上添加一个正则项。本研究使用 L2 正则化,通过惩罚权重平方和方式,降低权值大小和误差。L2 正则化表达式为

$$L(x, y) = \sum_{i=1}^n [y_i - h_o(x_i)]^2 + \lambda \sum_{i=1}^n \theta_i^2 \quad (7)$$

其中: y_i 为真实值; h_o 为预测函数; x_i 为第 i 个样本; λ 为正则化系数; θ_i 为第 i 个权重。

3 基于 MCMTF 和 CNN 的结构损伤识别流程

图 3 为基于 MCMTF 和 2D-CNN 的结构损伤识别方法流程图。首先,采集结构多测点加速度时间序列信号,使用滑动窗口方式,通过 MCMTF 方法对多测点信号进行图像转换,并按训练集:验证集:测试集=6:2:2 的比例划分多通道图像数据集;其次,分批次输入到构建的 2D-CNN 网络模型,调整参数进行优化,更新网络模型;最后,使用训练好的最优模型实现结构损伤识别。




图 3 基于 MCMTF 和 2D-CNN 的结构损伤识别流程图

Fig.3 Flowchart of the damage identification using MCMTF and 2D-CNN

4 数值模拟验证

4.1 IASC-ASCE Benchmark 框架模型

采用国际结构控制协会(IASC)和美国土木工程师协会(ASCE)提供的结构健康监测基准模型(IASC-ASCE Benchmark)^[15],如图 4 所示。该模型为一个 4 层 2 跨×2 跨的钢框架,跨长为 1.25 m,层高为 0.9 m。框架在各跨跨中布置加速度测点,4 层




图 4 IASC-ASCE Benchmark 模型(单位:m)

Fig.4 IASC-ASCE Benchmark model (unit:m)

共有16个测点(8个 x 方向,8个 y 方向)。

笔者考虑质量对称分布,假设楼板完全刚性,采用该模型的12自由度有限元模型^[8],即只考虑平面内 x,y 方向及扭转自由度。有限元模型中梁、柱采用 Euler-Bernoulli 梁单元,支撑为无抗弯刚度的轴向杆件,采用杆单元。通过去除支撑或减小不同单元的刚度模拟结构损伤,定义了5种损伤模式, IASC-ASCE Benchmark 损伤模式如表1所示。

表1 IASC-ASCE Benchmark 损伤模式

序号	损伤模式
0	无损伤
1	第1层所有斜支撑不提供刚度
2	第1层及第3层所有斜支撑不提供刚度
3	第1层的1根斜支撑不提供刚度
4	第1层及第3层各有1根斜支撑不提供刚度
5	第1层的1根斜支撑折减1/3刚度

4.2 数据集的构造

采用作用于每层 y 方向的风荷载激励,分别采集无损伤和5种损伤模式下结构各层加速度响应,采样频率为1 kHz,采样时间为40 s,且在响应中添加了5%的高斯白噪声。分别采用原始数据矩阵(original data matrix,简称 ODM)、SCMTF 和 MC-MTF 等3种方式处理加速度响应,构造数据集。

1) ODM 方式:采集图4所示框架16个测点的加速度数据作为原始数据,构成 $4\,000 \times 16$ 格式的矩阵,采用图5所示的滑动窗口及图6所示的3种方式构造数据集。相邻窗口在滑动时重叠,由此构造的数据集既保证了损伤特征的完整性,也增加了模型训练的样本数量。




图5 Schematic of sliding window

2) SCMTF 方式:仅采集框架第2层 y 方向 \ddot{y}_{2b} 测点的加速度数据,划分为 256×1 格式的时间序列,采用图6所示方式构造数据集,通过SCMTF将加速度响应数据转换为 $256 \times 256 \times 1$ 规格的MTF图像。图7所示为无损伤和5种损伤模式下,框架第

2层 y 方向 \ddot{y}_{2b} 测点的加速度响应经SCMTF转换后的图像。

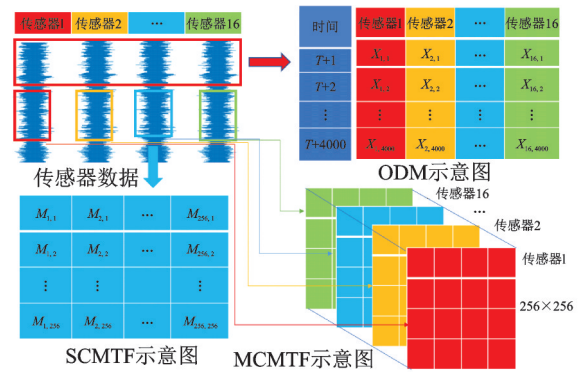


图6 3种数据集构造示意图

Fig.6 Schematic diagram of three kinds of dataset

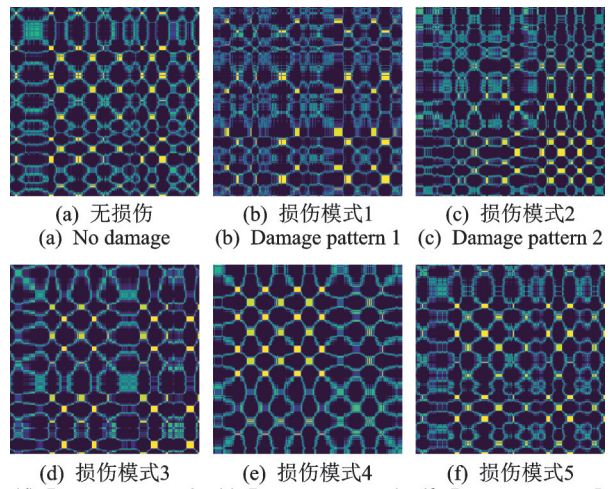


图7 无损伤和5种损伤模式下 \ddot{y}_{2b} 测点加速度响应的MTF图像

Fig.7 MTF images of accelerations on measurement \ddot{y}_{2b} under no damage and five damage patterns

3) MCMTF 方式:采集框架16个测点的加速度数据,每个测点数据划分为 256×1 格式的时间序列,采用图6所示方式构造数据集,将16个测点的加速度响应数据转换为 $256 \times 256 \times 16$ 规格的多通道MTF图像。多通道MTF图像与图7所示MTF图像类似。

将3种方式构造的数据集(无损伤和5种损伤模式各400个样本,共2400个样本)均按照6:2:2的比例划分为训练集、验证集和测试集。

4.3 数据输入方式对损伤识别结果的影响

模型训练硬件配置如下:服务器运行内存为96G,处理器为Intel Xeon W-3245@3.2GHz,显卡GPU为NVIDIA Quadro P2200。软件采用Python语言,在Spyder开发环境下基于Tensorflow2.4.0框

架搭建 CNN 模型。分别采用 4.2 节的 3 类数据集,构造模型按照从简单到复杂的规则,将卷积层层数、卷积核个数以及全连接层的神经元个数从少到多进行训练测试,经反复调整优化获取网络最优超参数组合,得到 3 类最优 CNN 模型,即 ODM-CNN 模型、SCMTF-CNN 模型和 MCMTF-CNN 模型,其结构如表 2 所示。其中:ODM-CNN 模型采用 4 个卷积层、2 个池化层,初始学习率为 0.000 4;SCMTF-CNN 模型采用 5 个卷积层、2 个最大池化层,初始学习率为 0.000 8;MCMTF-CNN 模型采用 4 个卷积层、1 个最大池化层和 1 个平均池化层,初始学习率为 0.001。3 种模型训练均采用 Adam 优化函数,设置批样本尺寸为 32 个,循环次数为 200 次。

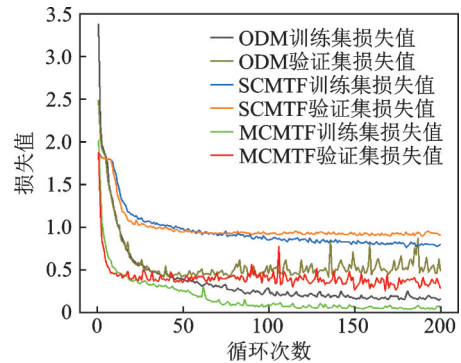
表 2 3 类 CNN 模型结构

Tab.2 Structures of three types of CNN model

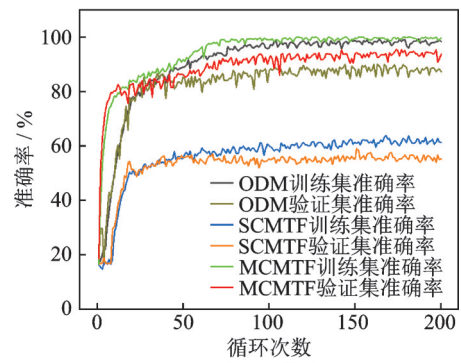
层数	类型	ODM-CNN 模型	SCMTF-CNN 模型	MCMTF-CNN 模型
0	Input	(4 000,16,1)	(256,256,1)	(256,256,16)
1	Conv2D	16,(3,3)	8,(3,3)	16,(3,3)
2	Conv2D	8,(3,3)	8,(3,3)	—
3	Pooling	(2,2)	(3,3)	(2,2)
4	Conv2D	8,(3,3)	8,(3,3)	8,(3,3)
5	Conv2D	8,(3,3)	8,(3,3)	8,(3,3)
6	Conv2D	—	8,(3,3)	8,(3,3)
7	Pooling	(2,2)	(2,2)	(2,2)
8	Flatten	—	—	—
9	Dense	4 000	200	400
10	Dropout	0.5	0.5	0.5
11	Dense	140	30	100
12	Dropout	0.5	0.5	0.5
13	Softmax	6	6	6

图 8 为 CNN 模型训练过程中损失值和准确率变化曲线。当训练集和验证集的损失值趋于不变时,表明该模型已达到收敛。可以看出:当模型收敛时,MCMTF-CNN 模型性能最好,在训练集上的准确率已近似达到 100%,在验证集上的准确率约为 95%;ODM-CNN 模型性能次之,训练集准确率约为 98%,验证集准确率约为 88%;SCMTF-CNN 模型性能最差,训练集和验证集的准确率分别约为 60% 和 55%。

将测试集的 480 个样本输入到已训练好的 3 类 CNN 模型,对比分析各模型的损伤识别效果,如表 3 所示。可以看出:MCMTF-CNN 模型在测试集上的分类准确率最高,达到 94.4%,损失值最低,为 0.259 9,模型的拟合效果最好;ODM-CNN 模型在测试集上性能次之,测试准确率为 88.5%;SCMTF-



(a) Loss values



(b) Accuracies

图 8 CNN 模型训练过程中损失值和准确率变化曲线

Fig.8 Evolutional curves of loss values and accuracies during the training process

表 3 3 类 CNN 模型损伤识别效果比较

Tab.3 Comparison of damage identification results among three types of CNN model

比较项目	ODM-CNN	SCMTF-CNN	MCMTF-CNN
测试准确率/%	88.5	60.6	94.4
测试损失值	0.479 6	0.903 5	0.259 9
收敛迭代次数	125	150	125
模型训练时间/s	452	158	775
单条样本测试时间/ms	0.44	0.25	1.69

CNN 模型测试准确率仅为 60.6%。原因如下:MCMTF-CNN 方法能将多个加速度传感器之间的拓扑相关性融入模型训练,且对数据进行了升维及融合处理,使得数据中隐含的信息能更充分地被 CNN 模型学习,自动提取的特征对损伤更为敏感,因此 MCMTF-CNN 模型的损伤识别效果最优;ODM-CNN 方法将原始振动信号构造成矩阵形式融入模型训练,考虑了多测点信息,因此 ODM-CNN 也具有较好的损伤识别效果;SCMTF-CNN 方法仅使用单个测点信息进行模型训练,由此训练得到的模型性能较差,无法实现损伤识别。本研究针对 SCMTF 方法选取了不同的单个加速度测点位置的数

据进行训练,模型测试结果均较差。

在训练和测试时间上,MCMTF-CNN模型训练时长为775 s,单条样本测试时间为1.69 ms,速率不及ODM-CNN和SCMTF-CNN。这是由于MCMTF-CNN模型结构更复杂,训练参数更多,牺牲了训练及测试时间以提高识别准确率。

图9为3类CNN模型的损伤识别准确率。可以看出:MCMTF-CNN模型在各损伤模式下的识别准确率均较优;SCMTF-CNN模型均较差;ODM-CNN模型对损伤模式0,1,2和5的识别准确率较好,而对损伤模式3和4的识别准确率较差,误判较多。这是由于这2种损伤模式的区分仅在于框架第3层1根斜支撑是否提供刚度,这一差别对加速度数据的影响较小,模型难以自动提取出针对这2种损伤模式的强敏感性特征,进而降低了识别效果。

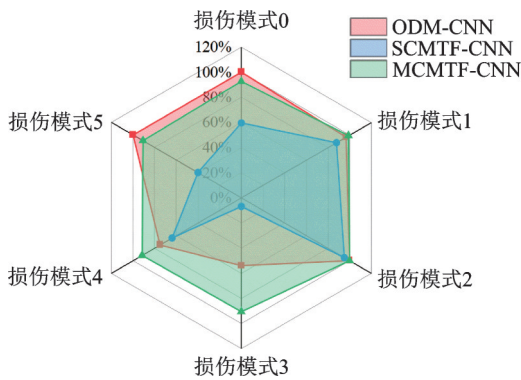


图9 3类CNN模型的损伤识别准确率

Fig.9 Identification accuracies of three types of CNN model




图10 不同神经网络模型的损伤识别混淆矩阵

Fig.10 Confusion matrix of damage identification of different NN models

4.5 噪声对损伤识别结果的影响

为研究MCMTF-CNN模型损伤识别时的抗噪性能,笔者分别无损伤和5种损伤模式下的加速度响应数据中添加噪声水平为1%,3%,5%和7%的高斯白噪声,通过MCMTF转换后生成图像数据

4.4 神经网络模型对损伤识别结果的影响

为比较不同神经网络模型的损伤识别效果,验证MCMTF与2D-CNN模型结合方法识别损伤的高准确率,笔者采用相同的加速度数据作为模型输入,分别训练了LSTM和DNN神经网络模型,得到的模型结构如表4所示。其中:LSTM模型结构主要由LSTM层和全连接层(Dense)组成;DNN模型结构主要由全连接层组成,括号内数字表示隐藏单元个数。

表4 LSTM和DNN神经网络模型结构

层数	LSTM	DNN
1	LSTM(32)	Flatten
2	LSTM(32)	Dense(100)
3	Dense(256)	Dense(100)
4	Dense(128)	Dense(100)
5	Dense(6)	Dense(6)

不同神经网络模型的损伤识别混淆矩阵如图10所示。每种损伤模式的数量通过颜色强度可视化,副对角线为模型正确识别损伤模式的数量。

由图10可以看出,CNN,LSTM和DNN模型的识别准确率分别为94.4%,84.4%和81.3%,说明基于CNN强大的图像处理功能,通过与MCMTF方法结合,能准确地识别复杂结构的损伤。类似地,CNN,LSTM和DNN等模型识别损伤时,误判主要发生在损伤模式3和4,这与4.3节结论基本一致。

集,输入到基于5%噪声水平数据训练好的模型(命名为5%_CNN)进行测试,4种噪声水平下5%_CNN模型的测试准确率分别为79.0%,87.1%,94.4%和88.8%。

鉴于5%_CNN模型性能在其他噪声水平下的测试效果不佳,笔者基于1%,3%和7%噪声水平下

的加速度响应数据,进行训练调参优化得到 3 个模型,加上 5%_CNN 模型,共 4 个优化模型。噪声水平对 MCMTF-CNN 损伤识别准确率的影响见图 11,准确率分别为 97.9%,95.4%,94.4% 和 92.1%。


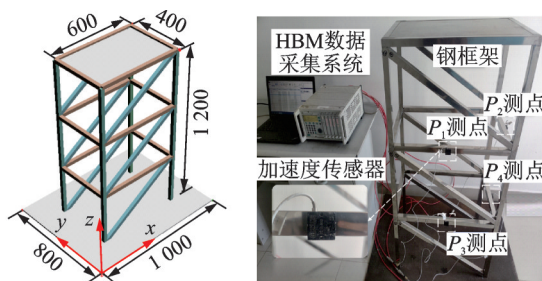


图 11 噪声水平对 MCMTF-CNN 损伤识别准确率的影响
Fig.11 Effects of noise levels on damage identification accuracies of MCMTF-CNN

由图 11 可以看出,针对其他 3 种不同噪声水平数据进行测试,优化模型的损伤识别准确率均比未优化的 5%_CNN 模型高,而优化模型的识别准确率随噪声水平的增加而降低,但仍维持了较高的识别准确率。

5 3 层钢框架试验验证

试验模型为一个 3 层钢框架结构,采用不锈钢材料,各层层高均为 400 mm,长为 600 mm,宽为 400 mm,结构立柱、横梁及斜撑均采用 25 mm×25 mm 矩形截面钢管,顶部采用 600 mm×400 mm×2 mm 不锈钢板,底部采用 1000 mm×800 mm×8 mm 钢板,每侧超出框架 200 mm。3 层钢框架试验结构如图 12 所示。



(a) 结构尺寸图(单位: mm) (b) 试验布置图
(a) Structural dimension drawing (unit:mm) (b) Test layout

图 12 3 层钢框架试验结构

Fig.12 Three-layer steel frame test structure

框架从上至下共有 $P_1 \sim P_4$ 4 个加速度传感器测点,分别布置在第 2 层与第 1 层 x, y 方向横梁跨中处。在钢框架顶部连续施加 x 向脉冲锤击激励,使钢框架产生振动,采用 HBM MGCplus 动态数据采集系统采集框架结构振动加速度信号,采样频率为

200 Hz,采样时间为 100 s。

试验模型中斜支撑设计为可拆卸模式,与立柱通过螺栓连接。通过拆除不同层斜支撑模拟结构损伤,定义了 3 层钢框架损伤模式如表 5 所示。

表 5 3 层钢框架损伤模式

Tab.5 Damage patterns of the three-layer steel frame

序号	损伤模式
0	无损伤
1	去掉第 3 层所有斜支撑
2	去掉第 2 层所有斜支撑
3	去掉第 1 层所有斜支撑
4	去掉第 3 层及第 2 层所有斜支撑
5	去掉第 3 层及第 1 层所有斜支撑
6	去掉第 1 层及第 2 层所有斜支撑
7	去掉所有斜支撑

使用 MCMTF 方法及滑动窗口方式构造数据集,单个样本尺寸为 $256 \times 256 \times 4$,无损伤和 7 种损伤模式下各取 400 个样本,共 3 200 个样本,按照 6:2:2 的比例划分为训练集、验证集和测试集。将训练集、验证集作为输入进行调参优化,得到 MCMTF-CNN 模型。采用 3 层卷积,第 1 层有 16 个 3×3 的卷积核,另外 2 层有 8 个 3×3 卷积核,步长为 2,2 个 2×2 的最大池化层,初始学习率为 0.000 5。模型训练采用 Adam 优化函数,设置批样本尺寸为 32 个,循环 100 次后模型快速收敛。

将测试集输入到 MCMTF-CNN 模型中,损伤识别混淆矩阵如图 13 所示。可以看出,MCMTF-CNN 模型对各损伤工况均有较好的识别效果,整体测试准确率为 98.4%。




图 13 MCMTF-CNN 损伤识别混淆矩阵

Fig.13 Confusion matrix of damage identification of MCMTF-CNN

6 结 论

1) 相比 ODM 和 SCMTF, MCMTF 构造的数据集能融合多测点数据之间的拓扑相关信息,训练得到的 CNN 模型损伤识别准确率最优。5% 噪声

水平下针对 IASC-ASCE Benchmark 模型训练的最优 CNN 模型,其损伤识别准确率为 94.4%, MC-MTF-CNN 模型对实验室钢框架结构的识别准确率为 98.4%。

2) 对比采用相同的加速度数据作为模型输入训练得到的 LSTM 和 DNN 模型, CNN 模型的损伤识别准确率最优。

3) 针对不同噪声水平数据,基于单一噪声水平数据训练得到的 MCMTF-CNN 模型,其损伤识别准确率有所降低。构造 MCMTF-CNN 模型时需充分考虑噪声水平的影响,针对不同噪声水平数据进行训练优化。

参 考 文 献

- [1] 孙利民,尚志强,夏焯. 大数据背景下的桥梁结构健康监测研究现状与展望[J]. 中国公路学报, 2019, 32(11):1-20.
SUN Limin, SHANG Zhiqiang, XIA Ye. Research status and prospect of bridge structure health monitoring under the background of big data [J]. China Journal of Highway and Transport, 2019, 32(11): 1-20. (in Chinese)
- [2] 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.
- [3] SONY S, DUNPHY K, SADHU A, et al. A systematic review of convolutional neural network-based structural condition assessment techniques [J]. Engineering Structures, 2021, 226: 111347.
- [4] 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.
- [5] 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 and Vibration, 2017, 388: 154-170.
- [6] 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.
- [7] LIN Y Z, NIE Z H, MA H W. Structural damage detection with automatic feature extraction through deep learning [J]. Computer-Aided Civil and Infrastructure Engineering, 2017, 32(12): 1025-1046.
- [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] 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)
- [10] 王慧,郭晨林,王乐,等. 基于内积矩阵及深度学习的结构健康监测研究[J]. 工程力学, 2022, 39(2): 14-22,75.
WANG Hui, GUO Chenlin, WANG Le, et al. Structural health monitoring based on inner product matrix and deep learning [J]. Engineering Mechanics, 2022, 39(2): 14-22,75. (in Chinese)
- [11] LI D, LIANG Z L, REN W X, et al. Structural damage identification under nonstationary excitations through recurrence plot and multi-label convolutional neural network[J]. Measurement, 2021, 186: 110101.
- [12] 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.
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. (in Chinese)
- [13] DANG H V, RAZA M, NGUYEN T V, et al. Deep learning-based detection of structural damage using time-series data [J]. Structure and Infrastructure Engineering, 2021, 17(11): 1474-1493.
- [14] WANG Z G, OATES T. Encoding time series as images for visual inspection and classification using tiled convolutional neural networks [C] //Workshops at the Twenty-Ninth AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2015: 40-46.
- [15] JOHNSON E A, LAM H F, KATAFYGIOTIS L S, et al. Phase I IASC-ASCE structural health monitoring benchmark problem using simulated data[J]. Journal of Engineering Mechanics, 2004, 130(1): 3-15.



第一作者简介:梁韬,男,1999年6月生,硕士生。主要研究方向为结构健康监测及损伤识别。

E-mail:liangtao@csu.edu.cn

通信作者简介:黄天立,男,1977年2月生,博士、教授。主要研究方向为结构健康监测、评估与维护管理。

E-mail:htianli@csu.edu.cn