

周荣环,康帅,王自法,等.基于时频分析与深度学习的结构震后损伤评估[J].地震工程学报,2024,46(1):115-125.DOI:10.20000/j.1000-0844.20221021002
ZHOU Ronghuan,KANG Shuai,WANG Zifa,et al.Structural damage assessment after earthquakes using time-frequency analysis and deep learning [J]. China Earthquake Engineering Journal, 2024, 46 (1): 115-125. DOI: 10.20000/j.1000-0844.20221021002

基于时频分析与深度学习的结构震后损伤评估

周荣环¹, 康 帅¹, 王自法², 靳 满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: 为评估地震后钢筋混凝土(RC)框架结构的损伤状态,提高损伤评估的效率和精度,文章提出一种基于时频分析和一维卷积神经网络(1D-CNN)的地震损伤评估方法。首先利用增量动力时程分析对一个 6 层 RC 框架结构进行地震损伤模拟,并根据最大层间位移角对加速度信号进行损伤程度的标定,以此来获取数据样本,随后应用五种不同的时频分析方法对原始信号进行处理;然后建立基于 1D-CNN 的地震损伤评估模型,并利用贝叶斯优化算法寻找模型中的最优参数组合;最后评估所提出模型方法在噪声情况下的泛化能力。研究结果表明:五种时频分析方法中,小波散射变换方法的准确率最高,达 92.5%,且计算速度也最快,仅需 144 s;另外在噪声下该方法仍可以保持较高的损伤评估准确率,具有较好的鲁棒性和泛化能力。

关键词: 地震损伤评估; RC 框架结构; 时频分析; 一维卷积神经网络; 贝叶斯优化

中图分类号: TU375

文献标志码: A

文章编号: 1000-0844(2024)01-0115-11

DOI:10.20000/j.1000-0844.20221021002

Structural damage assessment after earthquakes using time-frequency analysis and deep learning

ZHOU Ronghuan¹, KANG Shuai¹, WANG Zifa², JIN Man¹

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

2. CEAKJ ADPRHexa Inc., Shaoguan 512000, Guangdong, China)

Abstract: To assess the damage state of reinforced concrete (RC) frame structures after earthquakes and improve the efficiency and accuracy of damage assessment, this study proposes an earthquake damage assessment method based on time-frequency analysis and one-dimensional convolutional neural network (1D-CNN). First, the earthquake damage to a six-story RC frame structure was simulated using incremental dynamic analysis. Based on the maximum story drift ratio, the degree of damage was calibrated to obtain data samples. Second, four different time-frequency analysis methods were applied to process the original signals. Third, an earthquake damage assessment model based on a 1D-CNN was established, and the optimal parameter com-

收稿日期: 2022-10-21

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(22A560009)

第一作者简介: 周荣环(1996—),男,硕士研究生,研究方向为结构损伤评估。E-mail:104753200702@henu.edu.cn。

通信作者: 康 帅(1983—),男,博士,副教授,研究方向为结构损伤评估。E-mail:kangshuai@henu.edu.cn。

bination in the model was determined using the Bayesian optimization algorithm. Finally, the generalization ability of the proposed model under noise was evaluated. The results show that among five time-frequency analysis methods, the wavelet-scattering transform method has the highest accuracy, reaching 92.5%, and the fastest calculation speed, taking only 144 s. In addition, the proposed method can maintain a high level of damage assessment accuracy under noise conditions, indicating good robustness and generalization ability.

Keywords: seismic damage assessment; RC frame structure; time-frequency analysis; one-dimensional convolutional neural network; Bayesian optimization

0 引言

地震会造成建筑物发生不同程度的损伤,从而引起大量的人员伤亡和巨大的经济损失。地震后协调有效的灾后应急反应可以减少人员伤亡和经济损失,并快速实现城市社会功能的恢复,但这都取决于对结构损伤状态及时且准确的评估,延迟或不准确的评估可能导致一些附加的损失。

随着计算机硬件性能的提升与人工智能技术的普及,神经网络为结构非线性地震响应评估问题带来了全新的可能^[1]。深度学习通过模拟人脑处理信息的机制,建立由大量神经元和连接组成的模型,从而不需要过多人为干预就能解决复杂的模式识别问题,近年来逐渐被应用于地震造成的结构损伤评估中,并取得了显著的效果^[2]。通常最有效的方法是采集结构在地震过程中的振动信号,并将采集的时域信号转换到频域或时频域内进行特征降维,去除冗余信息而保留有用的特征信息,最后将提取的特征信息输入神经网络分类器,进行损伤分类以评估损伤状态^[3-4]。韩小雷等^[5]以多个结构特征参数为变量,设计了2 592个 RC 框架结构进行增量动力分析,将震损指标划分为构件及结构两个层次,最后引入深度学习构建结构特征参数与震损指标间的非线性映射关系,建立了区域 RC 框架结构震损评估模型,该模型可反映楼层构件性能状态的分布规律,并能较好地预测结构宏观响应。Mangalathu 等^[6]利用 320 个水平地震动对建筑物和桥梁进行非线性时程分析,获取结构的加速度响应,然后使用连续小波变换将结构加速度信号转化为时频谱图,并输入到迁移学习模型中评估地震造成的损伤状态。Liao 等^[7]利用手机等移动设备采集振动信号,然后利用时频域特征和迁移学习建立损伤评估模型,并使用实际监测的结构地震响应数据验证了所提出模型的准确性和通用性。Torky 等^[8]通过快速傅里叶变换和离散小波变换两种时频分析方法对数据进行处

理,然后使用混合卷积神经网络预测结构非线性地震响应。Lu 等^[9]提出了一种基于卷积神经网络(Convolutional Neural Network, CNN)的事后区域震害快速评估方法,将地震动的时频分布输入 CNN 评估结构震后损伤。针对单个建筑和清华大学校园建筑的区域案例使用该方法评估区域结构的损伤状态,结果表明该方法提供了较高精度的评估结果。

一维卷积神经网络(One-Dimensional Convolutional Neural Network, 1D-CNN)振动信号的特征进行学习,对时间序列的分析性能更强,能最大化地发挥深度学习自主学习信号特征的优势^[10]。Yuan 等^[11]比较了一维时间序列与二维图像编码这两种数据预处理方式,以探索最适合基于 CNN 的地震损伤评估的方法,得到的结论是图像编码方式相对于时间序列方式,对预测精度的提升并不明显,并且将一维时序列转为二维图像增加了大量的训练时间。正如 Kiranyaz 等^[10]所述,一维序列任务相比于二维图像任务,减少了图像编码的步骤,而且 1D-CNN 相比于 2D-CNN 需要相对浅的架构来管理分类任务,这使得 1D-CNN 的成本效益和计算效率更优越。震后损伤评估的本质是对加速度信号进行分类的任务,因此 1D-CNN 更适用于基于加速度信号的震后损伤评估。

可见,虽然时频分析结合 CNN 的方法在地震损伤评估领域中有一定的应用,但目前影响其广泛应用的最大障碍仍是如何建立精度与效率并存的地震损伤评估模型^[12]。时频分析方法可以提升损伤评估的准确率,1D-CNN 可以提升损伤评估的计算效率,故在众多时频分析方法中寻找最适合 1D-CNN 的方法至关重要。本文以一 6 层 RC 框架结构为研究对象,选取常用并适合 1D-CNN 的五种时频分析方法,并使用贝叶斯优化算法训练 1D-CNN 模型,对比其准确率和计算时间,确定最适合地震损伤评估的方法,还通过添加噪声验证该方法的抗噪性,从而提高

地震损伤评估的准确率和计算效率。

1 时频分析

1.1 时频分析方法

不同的时频变换方法从不同的角度对信号进行特征提取,使得其对信号的敏感程度也不一样,这会直接影响地震损伤模型的评估精度。因此选择五种常用的时频分析方法,并结合 1D-CNN 建立地震损伤评估模型。所采用的时频分析方法如下:

(1) 原信号时域

基于结构的加速度信号评估地震导致的结构损伤,是利用损伤结构的加速度信号本身就包含了损伤信息这一特性,将原时域加速度信号直接输入 1D-CNN 模型,提取原时域信号中的损伤特征,从而评估结构的损伤程度^[13]。

(2) 快速傅里叶变换

快速傅里叶变换是信号处理的重要方法之一,它将原信号从时域变换到频域,架起了时域和频域之间的桥梁。在现实工程中,信号若在时域内无法正常观察其现象以及变化规律,可以利用傅立叶变换转化到频率域中来观察。对于信号 $f(t) = L^2(R)$,其傅里叶变换定义为:

$$F(\omega) = \int_{-\infty}^{+\infty} f(t) e^{-i\omega t} dt \quad (1)$$

式中: $f(t)$ 是分析信号; $L^2(R)$ 是空间域; $F(\omega)$ 是信号 $f(t)$ 的傅立叶变换; t 是时间; $e^{-i\omega t}$ 是积分核,幅值为 1; ω 是频率。

(3) 短时傅里叶变换

短时傅里叶变换假设在某固定的窗函数 $g(t)$ 内信号是平稳信号,用傅里叶变换对其进行分析得到信号的频率成分,并沿时间轴移动窗函数 $g(t)$,得到信号的频率随时间的变化图。对于信号 $f(t) = L^2(R)$,其短时傅立叶变换定义为:

$$F(\omega, \pi) = \int_{-\infty}^{+\infty} g(t - \pi) s(t) e^{-i\omega t} dt \quad (2)$$

式中: $F(\omega, \pi)$ 是信号 $f(t)$ 的短时傅立叶变换; $g(t)$ 为窗函数,其他符号同上,采用 Hanning 窗函数。

短时傅里叶变换的结果是二维时频谱图,通过时频矩法可以从二维时频谱图中提取一维信息,用作 1D-CNN 的输入,用到的两个时频矩为瞬时频率和谱熵^[14]。瞬时频率是基于短时傅里叶变换计算的频谱图提取信号的瞬时频率,谱熵是基于功率谱估计信号的频谱的尖度或平坦度。将两个矩作为样本的两个特征向量输入 1D-CNN 模型。

(4) 离散小波变换

通过小波变换可以表示时域和频域两个维度,所包含的有关损伤的信息更加丰富。离散小波变换是将小波变换中的尺度进行数量的精简,这降低了冗余也减少了计算量。离散小波变换将原始信号分解成高频段和低频部分,然后下一级再分解时,针对低频段进行,对高频段不再进行分解,分解过程如图 1 所示。




图 1 离散小波分解过程图

Fig.1 Diagram of discrete wavelet decomposition process

进行离散小波变换时需要确定两个重要参数:小波基函数和分解层数。对信号采用不同的小波基函数和分解层数分析时,会导致分析结果出现很大的差异性,因此选择合适的小波基函数和分解层数非常重要。文献[15-16]中表明对于波动性强的序列一般分解层数不超过 3 层。考虑到地震产生的加速度信号属于波动性较强的序列,也考虑了不同小波基函数的影响,最终选用 db15 和 sym6 小波作为小波基函数,而且都做 3 层分解,选择低频部分(cA3)作为输入。

(5) 小波散射变换

小波散射变换是对小波变换取模,因为小波系数的均值为 0,线性变化之后均值没变,所以通过非线性变化(取模)得到非 0 的小波系数,让其携带一定的信息。经过小波和模算子后会产生高频分量的损失,为了弥补这一缺陷,有必要以更高阶重新分解小波模系数,并执行模运算和卷积尺度平均。具有平移不变性的小波散射系数被逐层输出,小波模系数被转移到下一层进行计算。信号依次层层迭代,从而得到一系列的小波散射系数^[17]。小波散射变换就是原信号通过小波滤波器得到高频和低频信息,低频信息就是我们所需要的特征,而高频信息可以进一步提取特征,再重复进行小波变换和 nonlinear 变换,不断得到原信号的特征。小波和模算子使获得的散射系数具有平移不变性,解决了小波变换随时间变化的缺点,还具有局部变形稳定性和丰富的

特征信息的优点。小波散射分解过程如图 2 所示。




图 2 小波散射分解结构

Fig.2 Wavelet scattering decomposition structure

1.2 五种时频分析方法数据维数

对单个信号应用五种时频分析方法时,会使其数据维数发生变化,如表 1 所列。其中单个信号的原时域数据点长度为6 561;经过快速傅里叶变换能减少一半的信号长度,长度为3 281;经过短时傅里叶变换结合时频矩法后生成两个长度为 129 的矩;经离散小波变换后,低频部分的长度变为原长度的八分之一,长度为 821;小波散射变换将单信号变换成一个 7×258 的矩阵。

表 1 五种时频分析方法数据维数

Table 1 Data dimension of five time-frequency analysis methods

序号	时频分析方法	简写	单信号特征矩阵
1	原时域信号	TIME	[1,6 561]
2	快速傅里叶变换	FFT	[1,3 281]
3	短时傅里叶变换	STFT	[2,129]
4	离散小波变换	DWT	[1,821]
5	小波散射变换	WST	[7,258]

2 网络模型理论基础

2.1 一维卷积神经网络

CNN 最早被用于分类问题并展现出很好的适用性。对于信号分类问题,CNN 无需改变输入信号的维度,能最大程度保留信号原有特征,且其模型复杂度较低,可以大幅度提升训练速度。CNN 的基本结构包括有输入层、隐含层和输出层,其中隐含层主要有卷积层、批量归一化层、激活函数层、最大池化层、丢弃层以及全连接层。通常将卷积核的大小、卷积核的深度、卷积块的数量等称为网络架构,将学习率和 L2 正则化强度等称为超参数。卷积核的深度就是卷积核层重复的次数,卷积块包括 1 个卷积核的深度、1 个批归一化层、1 个激活函数层、1 个最大池化层。1D-CNN 基本模型如图 3 所示。




图 3 1D-CNN 基本模型

Fig.3 Basic model of 1D-CNN

数据从输入层传入,后经过不同数量的卷积层和池化层,卷积层对数据进行卷积运算,提取特征,池化层对特征进行向下采样,对数据进行降维。完成上述操作后,特征将会被扁平化为向量形式,然后再通过全连接层的运算,提取的分布式特征向量会经全连接层映射到样本标记空间,最终在输出层分类。上述整个过程是前向传播过程。反向传播通过构造输出值与真实值的损失函数作为目标函数,逐层求出目标函数对各神经元权值的偏导数,构成目标函数对权值向量的梯度并修改权值,网络模型的学习在权值修改过程中完成。网络模型训练的实质就是通过前向传播和反向传播的交替进行,对参数

不断地更新,使输出值与真实值的误差达到所期望值时训练结束,得到训练过程中最优参数或是训练完成之后的最终参数^[18]。

训练集主要用于调整可学习参数,验证集用于在训练过程中监控模型的性能,但不用于更新可学习参数。将训练模型在验证集上实现最小验证损失的模型检查点保存起来,以便使用最好的网络状态对未参与训练过程的测试集进行测试。

2.2 贝叶斯优化算法

CNN 模型的预设参数对泛化性能影响很大。贝叶斯优化算法通常通过给定的黑盒目标函数,不断添加新的样本点,更新目标函数的后验分布,直到

后验分布基本贴合真实的分布,从而最快地达到最优解,是一种非常适合分类和回归模型的自适应参数优化,属于全局优化算法^[19]。贝叶斯优化算法主要由代理模型和采集函数组成。由于目标函数难以得到,代理模型的作用是根据当前已有的数据来估计目标函数,使用高斯过程作为代理模型。采集函数利用估计的目标函数确定如何采样新的数据,然后根据新采集的数据更新代理模型。这一过程将被重复迭代,理想情况下会找到目标函数的全局最优解。使用贝叶斯优化算法对 1D-CNN 模型的参数进行优化,实现步骤如下:




图 4 贝叶斯优化算法迭代过程

Fig.4 Iterative process of Bayesian optimization algorithm

- (1) 确定最大迭代次数 N ,贝叶斯优化最大次数为 60 次,每次 300 个训练批次。
- (2) 利用采集函数获得评估点,即获取优化参数中的某个组合;
- (3) 利用评估点评估目标函数值,目标函数值选择验证集的误差率;
- (4) 整合数据后更新概率代理模型,使得代理模型更加贴合目标函数的分布;
- (5) 若当前迭代次数 n 小于最大迭代次数 N ,则返回步骤(2)继续迭代,否则选择最小误差率对应的最优评估点输出,获取网络模型的最优参数组合。

案例中贝叶斯优化算法优化的参数列于表 2,其中卷积核的大小在每个卷积层中都保持一致,且仅取奇数。贝叶斯优化算法迭代过程如图 4 所示,函数在第 56 计算步时,观测值和估计值已经达到最小值,此时计算结果最优,然后选取此时的贝叶斯优化参数作为 1D-CNN 模型的最终参数,并利用此时的模型去评估测试集,得到最终的模型评估准确率。

2.3 结果评价指标

为了更直观地评价模型的性能,了解模型的泛化能力,引入部分评估指标来衡量模型的性能。深度学习中常用评价指标有准确率、精确率、召回率和模型运行时间等^[20]:

表 2 贝叶斯优化参数

Table 2 Bayesian optimization parameters

名称	超参数		网络架构		
	学习率	L2 正则化强度	卷积核的大小	卷积核的深度	卷积块的数量
搜索空间	$[1 \times 10^{-4}, 1 \times 10^{-1}]$	$[1 \times 10^{-4}, 1 \times 10^{-1}]$	$[3, 11]$ (仅奇数)	$[1, 3]$	$[1, 5]$

(1) 准确率 A ,即正确检测的样本与总样本的比值,计算公式为:

$$A = \frac{TP + TN}{TP + FP + FN + TN}$$
 (3)

式中: TP 为正确识别到的正对象数; TN 为正确识别到的负对象数; FP 为错误识别到的正对象数; FN 为错误识别到的负对象数。

(2) 精确率 P ,即正确检测出的目标样本与检测到的所有目标样本的比值,计算公式为:

$$P = \frac{TP}{TP + FP}$$
 (4)

(3) 召回率 R ,即正确检测出的目标样本与实际的目标样本的比值,计算公式为:

$$R = \frac{TP}{TP + FN}$$
 (5)

(4) 模型训练时间,深度学习模型在训练时要

反复更新模型参数。若模型收敛过慢,训练时间长,就会使模型迭代次数变少,不能训练得到性能更佳的模型,模型的准确率也会受到干扰。因此,模型训练时间也是模型性能一个重要体现指标。

3 震后损伤评估方法概述

震后 RC 框架结构损伤评估主要步骤如下,流程如图 5 所示:

(1) 建立结构有限元模型,准确模拟各部分构件及边界条件。为提高网络模型的泛化能力,应尽可能增加样本数,因此使用更多的地震波对结构进行增量动力时程分析,获取更多的结构加速度响应数据。

(2) 根据结构最大层间位移角计算结构损伤状态,然后标定结构响应加速度数据与结构损伤状态标签之间的映射关系。将标记好损伤状态的样

本集按照不同地震事件分为训练集、验证集和测试集。




图 5 震后损伤评估流程图

Fig.5 Flow chart of post-earthquake damage assessment

(3) 构建 1D-CNN 模型。将数据和标签导入网络模型进行训练,使用贝叶斯优化算法不断更新网络模型参数,直至准确率达到最大值,并保存当前状态模型为最终的损伤评估模型。

(4) 使用构建好的最优损伤评估模型评估建筑结构在新发生地震后的损伤状态。

4 数据集建立

4.1 RC 框架结构设计

根据国家规范^[21-22]设计一 6 层 RC 框架结构。基本设计资料:结构平面尺寸为 21.6 m(长)×15 m(宽),首层层高 4.0 m,其余层高 3.6 m,结构总高度 22.2 m,如图 6 所示;抗震设防烈度为 8 度,地震分组为第二组,场地类别为Ⅱ类;楼面恒荷载为 3.5 kN/m²,楼面活荷载为 2.0 kN/m²;混凝土强度等级为 C40,钢筋等级为 HRB400;梁和柱截面尺寸为 300 mm(宽)×600 mm(高)和 600 mm×600 mm(边长)。




图 6 RC 框架结构的平面和立面图(单位:mm)

Fig.6 Plan and elevation of the RC frame structure (unit:mm)

4.2 有限元模型

使用 OpenSees 软件建立 RC 框架结构有限元分析模型,并对结构模型进行增量动力分析。梁和柱均采用纤维截面和非线性梁柱单元,将梁柱划分为若干个积分段,同时考虑各梁柱单元的 P-Delta 效应。混凝土本构采用 Concrete01,基于 Kent-Scott-Park 单轴混凝土本构模型,不考虑混凝土受拉的力学性能,计算效率高且易收敛。钢筋本构采用 Steel02,是单轴各向同性强化的 Giuffre-Menegotto-Pinto 本构模型,可以体现钢筋的包辛格效

应,具有较好的模拟效果和数值稳定性。采用质量矩阵与刚度矩阵线性组合的 Rayleigh 阻尼,基础按固结处理。

4.3 地震波选取

合理的地震动选择是正确进行地震反应分析并准确评估结构损伤的首要前提。目前主流的选波方法将震级、震中距、场地条件等信息作为第一评判指标^[23]。震级的大小通常能较大程度地影响地震动的频谱和持时特性,由于震级较小时其能量释放和波及的范围均较小,不会造成很大的破坏^[24],所

以在对建筑物进行地震分析时选择大于 4 级的地震动。近场地震动与远场地震动对结构的响应有所不同,这对结构的影响很大,通常通过震中距将地震波区分为近场和远场地震动来处理,但当前关于近场与远场地震动尚没有一个统一的定义,因此选取震中距范围在 0~400 km。场地条件对地震动记录影响较为显著,在地震动幅值和频谱特性的变化上均有体现,目前国际上常以 30 m 覆盖层厚度范围内

土层剪切波速作为场地类别划分的指标,王东超^[25]通过研究不同的地震动分类对易损性曲线的影响,按照 v_{S30} 将 PEER 地震动数据库中的地震动记录分为三大类: $v_{S30} \leq 260$ m/s, 260 m/s $\leq v_{S30} \leq 510$ m/s, 510 m/s $\leq v_{S30}$ 。因此按照第一评判指标,从 PEER 地震波数据库中挑选了 24 个地震事件共 216 条地震波,每类场地 72 条。选取地震事件参数列于表 3。

表 3 地震动记录信息

Table 3 Information of ground motion records						
数据集	编号	地震事件	地震时间	地震等级	数量	共计
训练集	1	ImperialValley-06	1979	6.53	12	180
	2	WhittierNarrows-01	1987	5.99	6	
	3	LomaPrieta	1989	6.93	12	
	4	CapeMendocino	1992	7.01	9	
	5	Northridge-01	1994	6.69	12	
	6	Kobe_Japan	1995	6.90	12	
	7	Chi-ChiTaiwan	1999	7.62	12	
	8	TottoriJapan	2000	6.61	12	
	9	Anza-02	2001	4.92	12	
	10	NiigataJapan	2004	6.63	12	
	11	Parkfield-02	2004	6.00	12	
	12	Chuetsu-oki_Japan	2007	6.80	12	
	13	Iwate	2008	6.90	12	
	14	L'Aquila_Italy	2009	6.30	9	
	15	ElMayor-Cucapah_Mexico	2010	7.20	12	
	16	Darfield_NewZealand	2010	7.00	12	
验证集	17	Coalinga-01	1983	6.36	6	18
	18	MorganHill	1984	6.19	3	
	19	Landers	1992	7.28	3	
	20	Kocaeli_Turkey	1999	7.51	6	
测试集	21	Yountville	2000	5.00	6	18
	22	BigBearCity	2003	4.92	3	
	23	SanSimeon_CA	2003	6.52	3	
	24	Christchurch_NewZealand	2011	6.20	6	

4.4 定义损伤状态

选取最大层间位移角为结构损伤性能指标,参考规范参考值^[26]及文献^[27]中的研究成果,将钢筋混凝土框架结构的损伤状态划分为三个性能状态,并给出各损伤状态的最大层间位移角参考值,如表 4 所列。

表 4 基于最大层间位移角的结构损伤分类
Table 4 Structural damage classification based on maximum story drift ratio

极限状态	轻微损伤	中等损伤	严重损伤
最大层间位移角	≤1/200	1/200~1/100	>1/100

4.5 建立地震损伤数据集

对 6 层 RC 框架结构进行增量动力时程分析时,选取峰值加速度(Peak Ground Acceleration, PGA)作为地震强度指标,最大层间位移角作为结

构损伤指标。对上文所选取的地震波,根据 PGA 进行调幅处理,将调幅后的地震波输入结构进行动力时程分析,从而得到结构最大层间位移角,并以此计算与之相对应的结构损伤指标。将所有地震波时程曲线按照等步长法进行调幅处理,将每条地震波时程曲线的 PGA 以 0.02g 为起点,0.02g 为步长进行调幅,直至结构倒塌为止。地震波加载方向为 X 向。

$$a'(t) = a(t) \times PGA / A_{\max} \tag{6}$$

式中: $a'(t)$ 为调整后加速度时程曲线; $a(t)$ 为原始地震波加速度曲线; $A_{\max}$ 为原始地震波加速度曲线峰值。

由于地震动数据是从具有不同采样率和不同持续时间的不同台站采集的,因此有必要对地震动

记录进行下采样和截断,以满足网络模型的输入需要。具体是将单条地震动数据下采样到 200 Hz,并截断为6 561个数据点,共持时 32.805 s 的时间序列,以确保所有地震动序列的数据大小相同。如果采集到的地震动数据没有足够的数据量,用等量的零填充,并且对所有选中的地震动进行基线漂移修正。

训练集、验证集和测试集中的地震波是来自 PEER 数据库中不同的地震事件。这种设置确保了用于训练模型、验证模型和用于测试模型的地震波完全不同,保证了所提出的方法模型可以合理正确地评估地震对建筑物造成的损伤。最终共有 216 条不同的地震波分别作用于结构,由于每条地震波能调幅的最大次数不尽相同,因此表 5 列出了训练集、验证集和测试集的最终数据量。

表 5 各数据集地震波数量

名称	训练集	验证集	测试集
条数/条	180	18	18
调幅/次	13 793	524	1 118

5 计算结果对比

5.1 评估结果对比

在相同的计算机硬件配置下,使用相同的数据集对五种时频分析方法的网络模型进行训练和测试。使用的计算机硬件 CPU 为 i5-12400F,GPU 为 NVIDIA GeForce GTX3060,内存为 16 GB;使用 MATLAB 平台构建和训练 1D-CNN 模型;使用模拟数据中的测试集评估经过贝叶斯优化的 1D-CNN 的泛化能力。五种时频分析方法和 1D-CNN 模型的损伤评估结果如表 6 所列,混淆矩阵如图 7 所示。

表 6 五种时频分析方法的准确率

名称	TIME	FFT	DWT		WST	STFT
			db15	sym6	default	
准确率/%	86.6	86.7	90.8	90.4	92.5	58.4




图 7 五种时频分析方法的混淆矩阵

Fig.7 Confusion matrix of five time-frequency analysis methods

由表 6 知,原时域信号、快速傅里叶变换、小波变换、小波散射的准确率均在 80% 以上,这表明时频分析结合 1D-CNN 的地震损伤评估方法能够评估震后框架结构损伤。图 7 展示了五种时频分析方法的混淆矩阵,其中列是 1D-CNN 模型的预测类,行是非线性时程分析获得的真实类,最后一列表示召回率,最后一行表示精确率,右下角单元格表示准确率。在测试集上,较高的召回率、精确率和准确率

表明该模型具有更好的泛化能力。可以看出,小波散射方法的准确率在五种时频分析中是最高的,达 92.5%,这表明该模型方法对地震损伤评估具有很好的泛化能力。由于快速傅里叶变换结合时频矩法的正确率很低,因此后续分析不再考虑该方法。

5.2 网络结构对训练结果的影响

深度学习网络模型在训练中的普遍问题是训练时间太长,通常需要较长的时间才能使模型达到较

高的准确率。因此本部分通过对比多种时频分析方法的方式,选择训练时间最短且准确率高的方法,来提高地震损伤评估模型方法的准确率,缩短训练时间。为了评估深度学习网络模型的计算效率,对比了包含四种时频分析的五个网络模型所消耗的计算时间和计算资源。计算资源是衡量网络模型能否在有限的硬件设备下运行,以及其计算时间是否可控的重要指标,主要由参数量和计算量这两个参数决定。参数量是模型所有带参数层的权重参数总量,带参数层有:卷积层、批归一化层、全连接层;激活函数层和最大池化层中都没有参数,它们仅提供了一种非线性的变换。参数量与输入的数据无关,主要与模型的结构有关系,决定了网络模型的内存或显存大小。计算量是指输入单个样本模型完成一次前向传播过程所发生的浮点运算数,主要与输入的数据和模型的结构有关系,可以用来衡量算法或模型的复杂度,是模型计算时间的一个参考量。一般来说,参数量越低的网络,计算量越小,保存模型所需的内存则越小,同一硬件处理相同数据所需的计算量则越小,相同时间内就能处理更多的数据,速度也就越快。

表 7 展示了五种网络模型的网络架构、参数量、计算量和计算时间。由表 7 可知,相同硬件配置情况下小波散射时频分析方法结合 1D-CNN 的计算时间是最短的,仅有 144 s。这是因为:(1)由表 4 可知,小波散射时频分析方法相比于其他时频分析方法有更小的数据维数;(2)由表 7 可知,小波散射网络模型相比于其他网络模型有更少的计算量和参数量,占用的计算资源也更少。正如文献[28]中所述,模型的数据量、维数、可接受时间和存储复杂性对于算法的高效性都非常重要,不仅如此,GPU 比 CPU 更昂贵且计算内存空间也更小,因此在有限的计算硬件下,选择计算效率最高、计算准确率最高的分析方法和网络模型对震后损伤评估至关重要。在基于

表 7 五种网络模型的计算资源和时间

Table 7 Computing resources and time of five network models

名称	TIME	FFT	DWT		WST
			db15	sym6	
卷积核的大小	9	7	11	11	9
卷积层的深度	1	2	2	2	1
卷积块的数量	5	2	4	4	1
参数量/MB	0.17	0.17	0.21	0.21	0.09
计算量/kFLOPS	127.11	137.77	221.42	221.42	65.61
时间/s	1 200	619	408	412	144

评估准确率、计算时间和资源占用的前提下,在这五种时频分析方法与网络模型中,建议使用小波散射结合 1D-CNN 模型进行震后损伤快速评估。

5.3 鲁棒性验证

由于实际环境中采集到的信号一般都带有一定的外界干扰,尤其在地震作用下,采集到的加速度信号中会不可避免地包含一定的噪声,通常通过添加高斯白噪声来模拟这种噪声的影响。

工程中一般使用信噪比(SNR)评价信号内噪声含量的强弱,信噪比公式如下:

$$SNR(dB) = 10\lg\left(\frac{P_{\text{signal}}}{P_{\text{noise}}}\right) \tag{7}$$

式中: P_{signal} 表示原始信号的功率; P_{noise} 表示噪声信号的功率。

为了评估地震损伤评估模型的抗噪性,图 8 展示了未加高斯白噪声前的原始信号和加入白噪声后的信号。从图中可以看出,加入白噪声后,原始信号被高斯白噪声信号严重污染了,这将影响原始信号的信号特性,影响时频分析对信号的处理以及网络模型对信号特征的提取,因此可能会影响损伤评估的准确率。




图 8 原始信号与加噪信号

Fig.8 Raw signal and noisy signal

表 8 为在噪声作用下不同时频分析方法与网络模型的评估结果。当 SNR 等于 1 dB 时,五种模型的准确率均有下降,但是小波散射变换方法识别准确率仍在 90% 以上。结果表明,基于小波散射变换的时频分析和 1D-CNN 的地震损伤识别模型有很好的抗噪性和鲁棒性。

表 8 噪声作用下的准确率

名称	TIME	FFT	DWT		WST
			db15	sym6	
准确率/%	85.4	85.7	89.0	89.6	90.5

6 结论

针对地震作用下结构损伤评估精度不高和评估效率低的问题,研究了基于时频分析和 1D-CNN 模型的地震损伤评估方法,并通过数值模拟验证了所提方法的有效性和鲁棒性。结论主要包括:

(1) 对比分析了五种时频分析方法及其对应的网络模型,共有四种时频分析方法能达到 80% 以上的准确率,其中基于小波散射时频分析方法结合 1D-CNN 的评估精度最高,可达 92.5%。这实现了无需人工干预损伤特征量的提取,自动评估地震损伤。

(2) 从时频分析之后的数据维数和网络模型的计算资源这两个角度分析了深度学习的计算效率。其中基于小波散射时频分析方法结合 1D-CNN 的数据维数与其占用的计算资源都是最小的,最终计算时间也最短,仅需 144 s。这实现了在有限的硬件资源下快速评估地震损伤。

(3) 对原始信号添加噪声后,小波散射时频分析方法结合 1D-CNN 仍表现出最高的准确率。这验证了该方法在不同工作环境条件下都有较强的泛化能力和较好的鲁棒性。

参考文献(References)

[1] 许泽坤,陈隽.非线性结构地震响应的神经网络算法[J].工程力学,2021,38(9):133-145.
XU Zekun, CHEN Jun. Neural network algorithm for nonlinear structural seismic response[J]. Engineering Mechanics, 2021, 38(9):133-145.

[2] 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.

[3] KONG X A, CAI C S, HU J X. The state-of-the-art on framework of vibration-based structural damage identification for decision making[J]. Applied Sciences, 2017, 7(5): 497.

[4] HOU R R, XIA Y. Review on the new development of vibration-based damage identification for civil engineering structures: 2010-2019[J]. Journal of Sound and Vibration, 2021, 491:115741.

[5] 韩小雷,吴梓楠,杨明灿,等.基于深度学习的区域 RC 框架结构震损评估方法研究[J].建筑结构学报,2020,41(增刊 2):27-

35.
HAN Xiaolei, WU Zinan, YANG Mingcan, et al. Research on seismic damage assessment method of regional RC frame structure based on deep learning[J]. Journal of Building Structures, 2020, 41(Suppl02): 27-35.

[6] MANGALATHU S, JEON J S. Ground motion-dependent rapid damage assessment of structures based on wavelet transform and image analysis techniques[J]. Journal of Structural Engineering, 2020, 146(11): 04020230.

[7] LIAO W J, CHEN X Y, LU X Z, et al. Deep transfer learning and time-frequency characteristics-based identification method for structural seismic response[J]. Frontiers in Built Environment, 2021, 7: 627058.

[8] TORKY A A, OHNO S. Deep learning techniques for predicting nonlinear multi-component seismic responses of structural buildings[J]. Computers & Structures, 2021, 252: 106570.

[9] LU X Z, XU Y J, TIAN Y A, et al. A deep learning approach to rapid regional post-event seismic damage assessment using time-frequency distributions of ground motions[J]. Earthquake Engineering & Structural Dynamics, 2021, 50(6): 1612-1627.

[10] KIRANYAZ S, AVCI O, ABDELJABER O, et al. 1D convolutional neural networks and applications: a survey[J]. Mechanical Systems and Signal Processing, 2021, 151: 107398.

[11] YUAN X Z, TANKSLEY D, LI L J, et al. Faster post-earthquake damage assessment based on 1D convolutional neural networks[J]. Applied Sciences, 2021, 11(21): 9844.

[12] ZHANG C W, MOUSAVI A A, MASRI S F, et al. Vibration feature extraction using signal processing techniques for structural health monitoring: a review[J]. Mechanical Systems and Signal Processing, 2022, 177: 109175.

[13] NGUYEN H D, LAFAVE J M, LEE Y J, et al. Rapid seismic damage-state assessment of steel moment frames using machine learning[J]. Engineering Structures, 2022, 252: 113737.

[14] KŁOSOWSKI G, RYMARCZYK T, WÓJCIK D, et al. The use of time-frequency moments as inputs of LSTM network for ECG signal classification[J]. Electronics, 2020, 9(9): 1452.

[15] 李辰玉.基于小波变换的结构损伤识别研究[D].大连:大连理工大学,2020.
LI Chenyu. Research on structural damage identification based on wavelet transform[D]. Dalian: Dalian University of Technology, 2020.

[16] 张娜.基于小波分析的网格结构信号预处理和去噪研究[D].南昌:南昌大学,2019.
ZHANG Na. Research on signal preprocessing and denoising of grid structure based on wavelet analysis[D]. Nanchang: Nanchang University, 2019.

[17] 樊鑫,程建远,王云宏,等.基于小波散射分解变换的煤矿微震信号智能识别[J].煤炭学报,2022,47(7):2722-2731.
FAN Xin, CHENG Jianyuan, WANG Yunhong, et al. Intelligent recognition of coal mine microseismic signal based on wavelet scattering decomposition transform[J]. Journal of China Coal Society, 2022, 47(7): 2722-2731.

[18]曹永杰.基于平行卷积神经网络的结构损伤识别[D].广州:广州大学,2022.
CAO Yongjie.Structural damage identification based on parallel convolutional neural network[D].Guangzhou:Guangzhou University,2022.

[19]崔佳旭,杨博.贝叶斯优化方法和应用综述[J].软件学报,2018,29(10):3068-3090.
CUI Jiaxu,YANG Bo.Survey on Bayesian optimization methodology and applications[J].Journal of Software,2018,29(10):3068-3090.

[20]杨铎,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.

[21]中华人民共和国住房和城乡建设部,国家质量监督检验检疫总局.建筑抗震设计规范:GB 50011—2010[S].北京:中国建筑工业出版社,2010.
Ministry of Housing and Urban-Rural Development of the People's Republic of China,General Administration of Quality Supervision,Inspection and Quarantine of the People's Republic of China.Code for seismic design of buildings:GB 50011—2010[S].Beijing:China Architecture & Building Press,2010.

[22]中华人民共和国住房和城乡建设部.混凝土结构设计规范:GB 50010—2010[S].北京:中国建筑工业出版社,2011.
Ministry of Housing and Urban-Rural Development of the People's Republic of China.Code for design of concrete structures:GB 50010—2010[S].Beijing:China Architecture & Building Press,2011.

[23]张锐,李宏男,王东升,等.结构时程分析中强震记录选取研究综述[J].工程力学,2019,36(2):1-16.
ZHANG Rui,LI Hongnan,WANG Dongsheng,et al.Selection and scaling of real accelerograms as input to time-history analysis of structures:a state-of-the-art review[J].Engineering Mechanics,2019,36(2):1-16.

[24]乔云龙.框架结构地震反应的不确定性分析[D].哈尔滨:中国地震局工程力学研究所,2020.
QIAO Yunlong.Uncertainty analysis of seismic response of frame structures[D].Harbin:Institute of Engineering Mechanics,China Earthquake Administration,2020.

[25]王东超.结构地震易损性分析中地震动记录选取方法研究[D].哈尔滨:哈尔滨工业大学,2016.
WANG Dongchao.Study on selection method of ground motion records in structural seismic vulnerability analysis[D].Harbin:Harbin Institute of Technology,2016.

[26]American Society of Civil Engineers.Prestandard and commentary for the seismic rehabilitation of builings[S].Washington D C:Federal Emergency Management Agency,2000.

[27]邓夕胜,赖馨粤,袁凯,等.罕遇地震下高层 RC 框架结构双地震动强度参数易损性分析[J].世界地震工程,2022,38(3):19-29.
DENG Xisheng,LAI Xinyue,YUAN Kai,et al.Vulnerability analysis of multiple ground motion intensity measure rectors for high-rise RC frame structure under rare earthquake[J].World Earthquake Engineering,2022,38(3):19-29.

[28]XU R,WUNSCHII D.Survey of clustering algorithms[J].IEEE Transactions on Neural Networks,2005,16(3):645-678.

(本文编辑:贾源源)