

# 基于多输入卷积神经网络隔震支座沉降识别

赵丽洁<sup>1,2</sup>, 李纯<sup>1</sup>, 沈金生<sup>1</sup>, 王昊<sup>3</sup>

(1. 河北工程大学 土木工程学院, 河北 邯郸 056038; 2. 天津农学院 水利工程学院, 天津 300392;  
3. 天津城建大学 土木工程学院, 天津 300384)

**摘要:** 为了避免地基不均匀沉降导致隔震支座沉降以及对上部结构造成的隐性损伤, 针对隔震支座沉降识别方法进行研究, 提出一种基于多输入卷积神经网络 (multi-input convolutional neural network, MI-CNN) 的隔震支座振动信号识别模型。首先, 采集隔震支座水平方向加速度和位移信号, 采用归一化预处理和数据增强方法扩充样本; 然后, 将样本输入到所建立的网络模型中并进行训练; 最后, 利用完成训练的网络模型进行沉降识别。结果表明: 相较于传统单输入卷积神经网络 (Convolutional neural network, CNN) 模型, MI-CNN 模型易于训练, 可最大程度地发挥 CNN 对沉降信号特征的提取能力, 且具有更好的沉降位置识别准确率和更小的沉降程度识别误差, 以及针对不平衡数据集更稳定的识别效果。研究结果可为隔震支座沉降识别提供新思路。

**关键词:** 卷积神经网络; 隔震支座; 不平衡数据集; 沉降识别

中图分类号: TU375.4; TP183

文献标识码: A

## Seismic isolation bearing settlement recognition based on multi-input convolutional neural network

ZHAO Lijie<sup>1,2</sup>, LI Chun<sup>1</sup>, SHEN Jinsheng<sup>1</sup>, WANG Hao<sup>3</sup>

(1. School of Civil Engineering, Hebei University of Engineering, Handan 056038, China; 2. School of Water Conservancy Engineering, Tianjin Agricultural University, Tianjin 300392, China; 3. School of Civil Engineering, Tianjin Chengjian University, Tianjin 300384, China)

**Abstract:** In order to avoid the settlement of seismic isolation bearings caused by uneven foundation settlement and the hidden damage to the superstructure, a vibration signal identification model based on multi-input convolutional neural network (MI-CNN) is proposed to identify the settlement of seismic isolation bearings. First, the horizontal acceleration and displacement signals of seismic isolation bearings are collected, and the samples are expanded using normalised pre-processing and data enhancement methods. Then, the samples are fed into the established network model and trained. Finally, the settlement identification is performed using the trained network model. The results show that compared with the traditional single-input CNN model, the MI-CNN model is easier to train and can maximise the ability of CNN to extract features from the settlement signals, and it has a better accuracy in identifying the settlement location, a smaller error in identifying the settlement degree, and a more stable identification effect for the unbalanced data set. The results of this study can provide new ideas for the settlement identification of seismic isolation bearings.

**Key words:** convolutional neural network; isolation bearing; unbalanced dataset; settlement identification

## 0 引言

隔震建筑在多次地震灾害中表现卓越, 已有相对成熟的设计方法, 成为建设韧性城市中提高单体建筑结

收稿日期: 2023-08-22; 修回日期: 2023-12-29

基金项目: 国家自然科学基金项目 (52208193)

作者简介: 赵丽洁 (1988—), 女, 副教授, 博士, 主要从事结构健康监测与损伤识别研究。E-mail: ljzhaocz@126.com

通讯作者: 王昊 (1987—), 男, 讲师, 博士, 主要从事钢结构研究。E-mail: wanghao13689@163.com

构抗震韧性的主要手段。对隔震结构而言,地基不均匀沉降导致隔震支座发生沉降。隔震支座发生沉降时会对附近的梁、柱内力产生不同程度的影响,并对相邻区域支座变形和内力变化影响较大,严重时会导致隔震支座产生拉应力,进而使得隔震结构受拉破坏并丧失承载能力<sup>[1-3]</sup>。杜永峰等<sup>[4]</sup>利用 Perform-3D 软件分析基础隔震结构的隔震支座意外失效后,其余结构在地震动作用下的构件损伤指数和损伤路径变化。研究表明,角部隔震支座的失效会导致构件的损伤指数产生剧烈变化,使得支座失效位置上部位置的构件的破坏路径成为主要的损伤路径。韩博等<sup>[5]</sup>为研究隔震支座突然失效引起的竖向不平衡荷载耦合作用下隔震结构动力响应规律和支座失效后的荷载传递路径,进行了一个缩尺比例为 1:4 的 3 层平面不规则钢筋混凝土(reinforced concrete, RC)隔震框架结构振动台试验。结果表明,单个支座的瞬时失效直接影响整个隔震层的支座内力分布,同时失效位置处的结构竖向动力响应显著增加。综上所述,隔震支座发生沉降甚至失效对隔震层以及上部结构都会产生巨大危害,因此迫切需要对隔震支座发生沉降进行识别。

近年来,卷积神经网络在各个领域(如图像分类、目标识别等)发展迅速<sup>[6]</sup>,并成功应用于土木工程损伤识别领域<sup>[7]</sup>,其中主要包括识别节点损伤<sup>[8]</sup>、杆件损伤<sup>[9-12]</sup>、螺栓松动<sup>[13]</sup>和裂缝<sup>[14]</sup>等。随着卷积神经网络的深入,越来越多的学者将支座损伤作为研究对象,提出不同的识别方法。崔弥达<sup>[15]</sup>将卷积神经网络应用于桥梁橡胶支座病害识别,损伤类型为支座环向开裂、剪切变形,并利用 Python 编程语言开发桥梁支座病害自动识别软件。CHEN 等<sup>[16]</sup>将桥梁振动模态信息和支座损伤信息分别作为径向基函数神经网络的输入和输出,利用大量的数值模拟生成的数据完成支座损伤识别。ZENG 等<sup>[17]</sup>提出基于离散小波包变换和双向长短时记忆神经网络的支座轴压识别方法,准确识别出支座的轴压。值得注意的是,卷积神经网络在各种结构损伤识别领域发展迅速,但是用于隔震支座沉降识别的较少,所以本文对此开展研究。由于地基不均匀沉降会使得结构质量分布和抗侧刚度发生改变<sup>[18]</sup>,进而导致隔震支座振动信号(加速度和位移)产生变化,因此可以通过卷积神经网络学习振动信号特征来识别支座沉降。

文中通过对振动信号多输入的策略实现了多输入卷积神经网络(multi-convolutional neural network, MI-CNN),并将之应用于隔震支座沉降位置和程度识别,通过数值试验,验证了方法的有效性,并与传统单输入网络对比,证明所提方法在网络训练速度、识别性能和针对不均衡数据集上具有更优的性能。

## 1 多输入卷积神经网络模型

为了充分发挥卷积神经网络(convolutional neural network, CNN)模型对隔震支座信号特征的提取能力,本文提出了 MI-CNN 网络模型。模型由多输入层、卷积层、池化层、合并层、全连接层、分类层或回归层,以及为了增强模型泛化能力和加速网络训练的批量归一化层组成,如图 1 所示。其中输入 1 和输入 2 为加速度和位移样本,首先对其进行 3 组卷积和池化操作,其次在合并层将其沿着同一维度进行特征融合,然后到全连接将特征图展开输入到普通 BP 神经网络中进行计算,最后连接一个 Softmax 分类器或回归,实现对目标类别的分类和预测输出。MI-CNN 网络模型采用 Leaky-ReLU<sup>[19]</sup>函数作为激活函数,并使用最大池化,因为它的性能优于平均池化<sup>[20]</sup>,同时为了训练过程中更有效地优化损失函数,本文采用了一种更有效的优化方法,自适应矩估计(Adam),从而达到更有效的识别效果。Adam 是 AdaGrad(自适应梯度算法)和 Rmsprop(均方根传播算法)<sup>[21]</sup>的组合,它结合了 2 种算法的优点对每个参数保持自适应学习水平的能力。

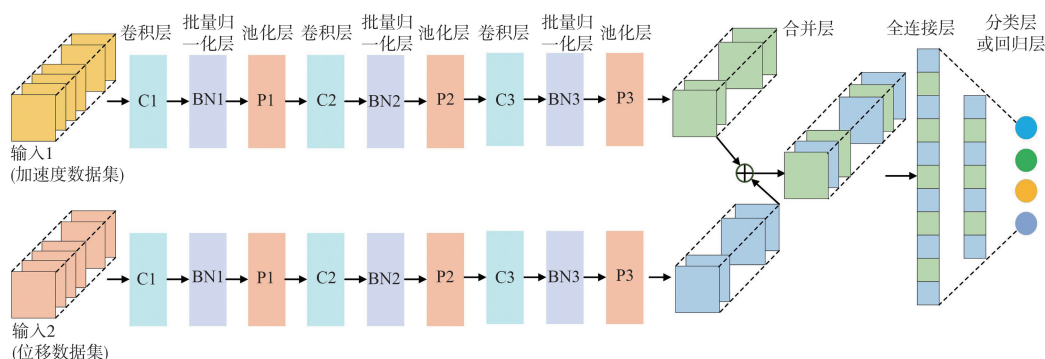


图 1 MI-CNN 模型

Fig. 1 MI-CNN model

## 2 试验验证

为了验证 MI-CNN 模型的有效性,首先利用数值模拟得到隔震支座沉降下加速度和位移信号,然后对数据进行归一化,接着采用滑动窗口增加样本,再将样本划分为训练集、验证集和测试集输入到模型中,同时为了与传统单输入网络对比,共设计了 CNN1、CNN2、MI-CNN3 这 3 种不同网络模型,并针对不均衡数据集进行验证。

### 2.1 样本数据准备

采用 ETABS 和筑信达结构设计软件 CiSDesignCenter(简称 CiSDC)设计了 6 层基础隔震结构。结构总高度 19.8 m,各层层高 3.3 m,抗震设防烈度 8 度(0.2  $g$ ),属于乙类建筑设防类别,设计地震分组为二组,场地类别为三类。混凝土强度等级 C30,纵向受力钢筋 HRB400 级,箍筋 HPB335 级。柱截面尺寸为 650 mm $\times$ 650 mm,各层梁截面尺寸为 300 mm $\times$ 550 mm,各层板厚为 120 mm。纵向柱距为 4.5 m,横向柱距为 6、3、6 m。恒载:结构自重楼面均布荷载 5 kN/m<sup>2</sup>;活载:楼板均布荷载 2 kN/m<sup>2</sup>。隔震层的层高为 1.6 m,隔震支座高为 0.3 m,隔震层梁为 300 mm $\times$ 600 mm,板厚为 160 mm。基础隔震结构采用每根柱底布置一个隔震支座的形式,经计算确定隔震支座选用 LRB600 和 LNR600,其基本参数见表 1。基础隔震模型如图 2 所示,其中模型三视图、隔震支座布置见图 2(a)、(b)。

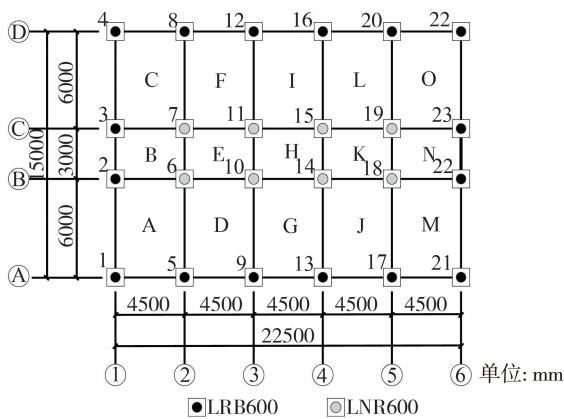
表 1 橡胶支座参数

Table 1 Parameters of rubber bearing

支座类型	LRB600	LNR600	支座类型	LRB600	LNR600
支座高度/mm	165	165	屈服力/kN	63	—
竖向刚度/(kN/mm)	2 200	1 900	屈服前刚度/(kN/mm)	13.11	—
等效刚度/(kN/mm)	1.58	0.98	屈服后刚度/(kN/mm)	1.01	—



(a) 模型三视图



(b) 隔震层平面图

图 2 基础隔震模型

Fig. 2 Model of base isolation

本文以地基不均匀沉降为前提,模拟隔震支座发生沉降。对不同区域隔震支座柱脚处,沿着重力方向施加相同位移荷载,通过调整位移荷载的大小,模拟隔震支座发生沉降。依据我国 GB 50007—2011《建筑地基基础设计规范》<sup>[22]</sup>的规定,将中低压缩土的框架结构相邻柱基础的 0.002 L 设定为结构的沉降限值,即沉降允许值为 6~12 mm 之间。以 10 mm 沉降量为初始值,并进行 5 mm 等量增加,假设区域 A 沉降 10 mm,则是将 1、2、5、6 号支座同时下沉 10 mm;假设区域 B 沉降 15 mm,则是将 2、3、6、7 号支座同时下沉 15 mm。以此类推,隔震支座沉降程度为 10、15、20、25、30、35 mm,具体见表 2。

沿着隔震结构底部水平方向,施加白噪声激励。根据表 2 所示的沉降工况,依次在发生沉降的位置,采集 6 种不同沉降程度下 24 个隔震支座加速度响应,采样频率为 100 Hz,时长为 30 s。利用 Hilber-Hughes-Taylor 数值积分法计算每个隔震支座的加速度响应,共生成 91(15 $\times$ 6+1)个 24 $\times$ 3000 的矩阵,位移样本采集同理。

表 2 隔震支座沉降工况

Table 2 Settlement condition of seismic isolation bearing

沉降工况	沉降区域	沉降程度/mm	沉降位置标签	沉降程度标签
未发生沉降	—	—	0	[0000000000000000]
沉降工况 1	A	10~35	1	[Z000000000000000]
沉降工况 2	B	10~35	2	[0Z00000000000000]
沉降工况 3	C	10~35	3	[00Z0000000000000]
沉降工况 4	D	10~35	4	[000Z000000000000]
沉降工况 5	E	10~35	5	[0000Z00000000000]
沉降工况 6	F	10~35	6	[00000Z0000000000]
沉降工况 7	G	10~35	7	[000000Z000000000]
沉降工况 8	H	10~35	8	[0000000Z00000000]
沉降工况 9	I	10~35	9	[00000000Z0000000]
沉降工况 10	J	10~35	10	[000000000Z000000]
沉降工况 11	K	10~35	11	[0000000000Z00000]
沉降工况 12	L	10~35	12	[00000000000Z0000]
沉降工况 13	M	10~35	13	[000000000000Z000]
沉降工况 14	N	10~35	14	[0000000000000Z00]
沉降工况 15	O	10~35	15	[00000000000000Z0]

注: 其中 Z 为沉降程度数值, 取值为 0.1、0.15、0.20、0.25、0.30、0.35。

为了便于卷积神经网络训练, 采用数据归一化将数据集缩放到  $[-1, 1]$  之间, 以便于不同特征或不同样本之间的比较, 也能消除量纲和数值大小的差异, 同时为了提升模型的泛化能力, 利用数据增强来扩充样本量。通过时间步长为 10 的滑动窗口, 使得每个沉降程度下产生 291 个样本, 如图 3 所示。其中沉降程度为 10、15、25、30、35 mm, 以及未发生沉降的样本用于模型训练, 沉降程度为 20 mm 用于模型测试, 其次将用于模型训练样本中, 每个沉降程度下 230 个样本组成训练集, 61 个样本组成验证集, 为了保证训练样本的均衡性, 把未发生沉降的样本扩充 (5 条不同的白噪声激励) 5 倍, 保持和其他训练样本一样的数目, 共得到训练集样本 18 400 个, 验证集样本数 4 880 个, 测试集样本数 4 365 个, 位移样本同理, 列出一组测试集的加速度和位移样本见图 4。




图 3 数据集增强方式

Fig. 3 Enhancement method for data set

0.1529	-0.1526	0.1496	-0.2571	0.4602	0.2983	•••
0.1530	-0.1530	0.1497	-0.2572	0.4596	0.2977	•••
0.1526	-0.1526	0.1491	-0.2574	0.4590	0.2970	•••
0.1527	-0.1527	0.1487	-0.2576	0.4581	0.2960	•••
•	•	•	•	•	•	•••
•	•	•	•	•	•	•••
0.1525	-0.1527	0.1491	-0.2574	0.4589	0.2969	•••
0.1522	-0.1528	0.1487	-0.2576	0.4580	0.2960	•••

(a) 加速度样本(24 × 100)

-0.2128	-0.2399	-0.2637	-0.2826	-0.2958	-0.3089	•••
-0.2048	-0.2323	-0.2563	-0.2755	-0.2891	-0.3024	•••
-0.2015	-0.2289	-0.2531	-0.2724	-0.2861	-0.2996	•••
-0.1951	-0.2228	-0.2471	-0.2667	-0.2807	-0.2944	•••
•	•	•	•	•	•	•••
•	•	•	•	•	•	•••
-0.2016	-0.2290	-0.2532	-0.2725	-0.2862	-0.2997	•••
-0.1952	-0.2229	-0.2472	-0.2668	-0.2807	-0.2945	•••

(b) 位移样本(24 × 100)

图 4 测试集部分样本

Fig. 4 Partial samples of test set

## 2.2 网络架构参数和评价指标确定

目前, CNN 网络架构及参数的确定很大程度取决于人工经验。根据前期调研结果, 基于 MI-CNN 模型采用 3 层结构, 其中输入 1 和输入 2 为数据增强后的加速度和位移样本, 通过 3 组卷积和池化操作, 将特征图在合并层沿着同一维度进行特征融合, 最后输入到全连接层, 经由分类层或回归层, 完成对目标类别的分类和预测。经过多次试验调试, 模型的最终参数如表 3 所示。

对于回归任务采用均方误差 (mean square error, MSE) 来评估模型预测性能, MSE 表示预测值和真实值

之间差异程度, MSE 越小, 说明模拟预测性能越好, 如式(1)所示:

$$\text{MSE}(y, y') = \frac{\sum_{i=1}^n (y_i - y'_i)^2}{n} \quad (1)$$

式中:  $y_i$  为真实值;  $y'_i$  为预测值;  $n$  为样本数。

表 3 MI-CNN 模型参数

Table 3 Parameters of MI-CNN model

参数名称	C1	P1	C2	P2	C3	P3
参数值	2×2	2×2	2×2	2×2	2×2	2×2
参数名称	迭代轮数	学习率	批大小	迭代次数	卷积核数目	—
参数值	200	0.001	64	57400	(10, 20, 30)	—

### 2.3 模拟结果分析

各模型在隔震支座沉降识别的训练集和验证集的训练曲线, 如图 5 所示。由图可知, 对于沉降位置识别的 3 个网络中, MI-CNN 训练过程更加稳定, 收敛速度相较于 CNN1 和 CNN2 更快, 其中 CNN2 训练过程抖动最剧烈; 对于沉降程度识别的 3 个网络, 损失曲线收敛迅速, 并都保持稳定状态。

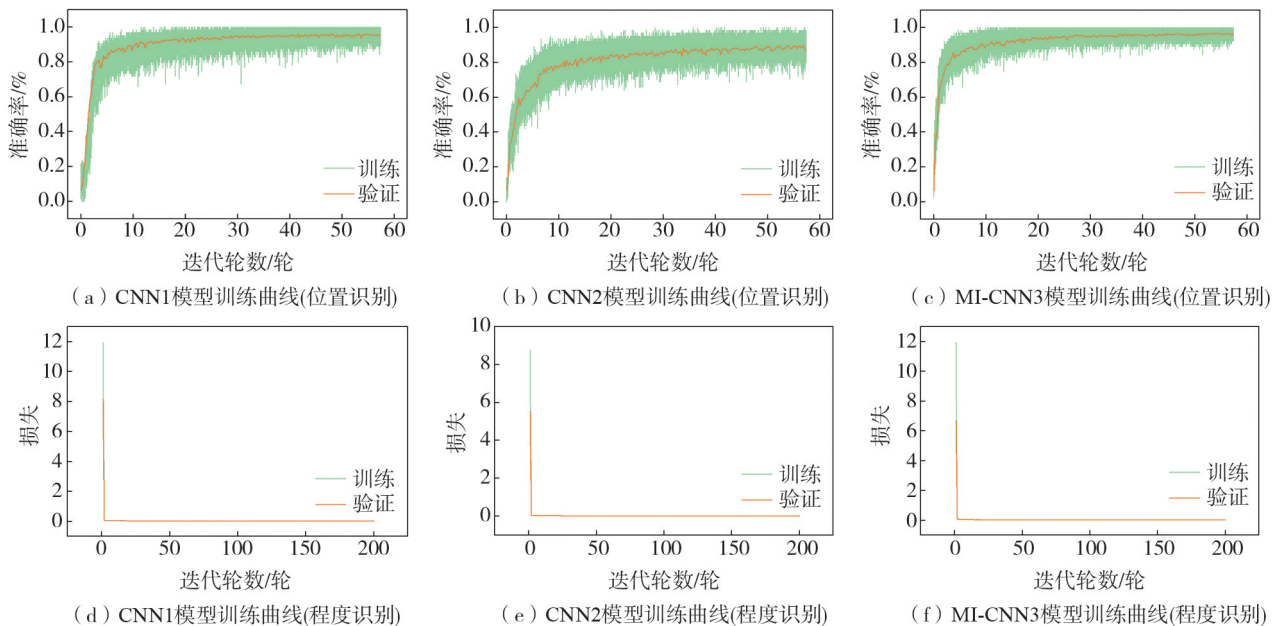


图 5 各模型在隔震支座沉降位置识别和沉降程度识别训练曲线

Fig. 5 Training curves for each model in identifying the settlement position and settlement degree of the isolation bearing

各模型在测试集上的识别结果如表 4 所示。结果表明, MI-CNN3 模型在经过训练后, 沉降位置识别准确率达到 98.92%, 而单输入模型 CNN1 和 CNN2 识别结果较差, 特别是 CNN2 识别准确率只有 90.19%。MI-CNN3 在沉降程度识别上对比 CNN1 和 CNN2 具有更小的预测误差。由此可见, 采用多输入策略的卷积神经网络是可行且有效的。

为了进一步显示不同模型的性能, 引入混淆矩阵对测试结果进行分析, 如图 6 所示。由图可知, 对于以加速度为输入的 CNN1 在识别真实类别为 2 时, 291 个样本有 260 个识别正确, 1 个被误判为 0 号类别, 3 个被误判为 8 号类别, 27 个被误判为 11 号类别, 在识别真实类别为 14 时, 291 个样本仅有 171 个识别正, 120 个全被误判错误, 其余部分识别结果较好; 对于以位移为输入的 CNN2 在识别真实类别为 2 时, 291 个样

表 4 各模型的沉降识别结果

Fig. 4 Settlement recognition results for each model

模型	沉降位置识别 (准确率)/%	沉降程度识别 (均方误差)
CNN1	96.54	$8.51 \times 10^{-4}$
CNN2	90.19	$1.01 \times 10^{-3}$
MI-CNN3	98.92	$6.46 \times 10^{-4}$

本有 92 个识别正确, 199 个被误判为 5 号类别, 在识别真实类别为 8 时, 291 个样本仅有 235 个识别正确, 56 个全被误判错误, 其余部分识别结果一般; 对于以加速度和位移为多输入的 MI-CNN3 在识别真实类别为 2 时, 291 个样本有 284 个识别正确, 5 个被误判为 8 号类别, 1 个被误判成 11 号类别, 1 个被误判为 14 号类别, 在识别真实类别为 14 时, 291 个样本有 255 个识别正确, 其余 36 个被误判错误, 剩余部分识别结果较好。由此可知, 单输入卷积神经网络在识别部分类别上出现了严重误判, 特别是 CNN1 中真实类别为 14 只, 有 172 个判别正确和 CNN2 中真实类别为 2 只, 有 92 个判别正确, 而多输入卷积神经网络除部分类别出现误判, 大部分都可以准确识别, 这说明 MI-CNN3 能够捕捉相近类别之间的差异, 且具有更优的沉降位置识别性能。

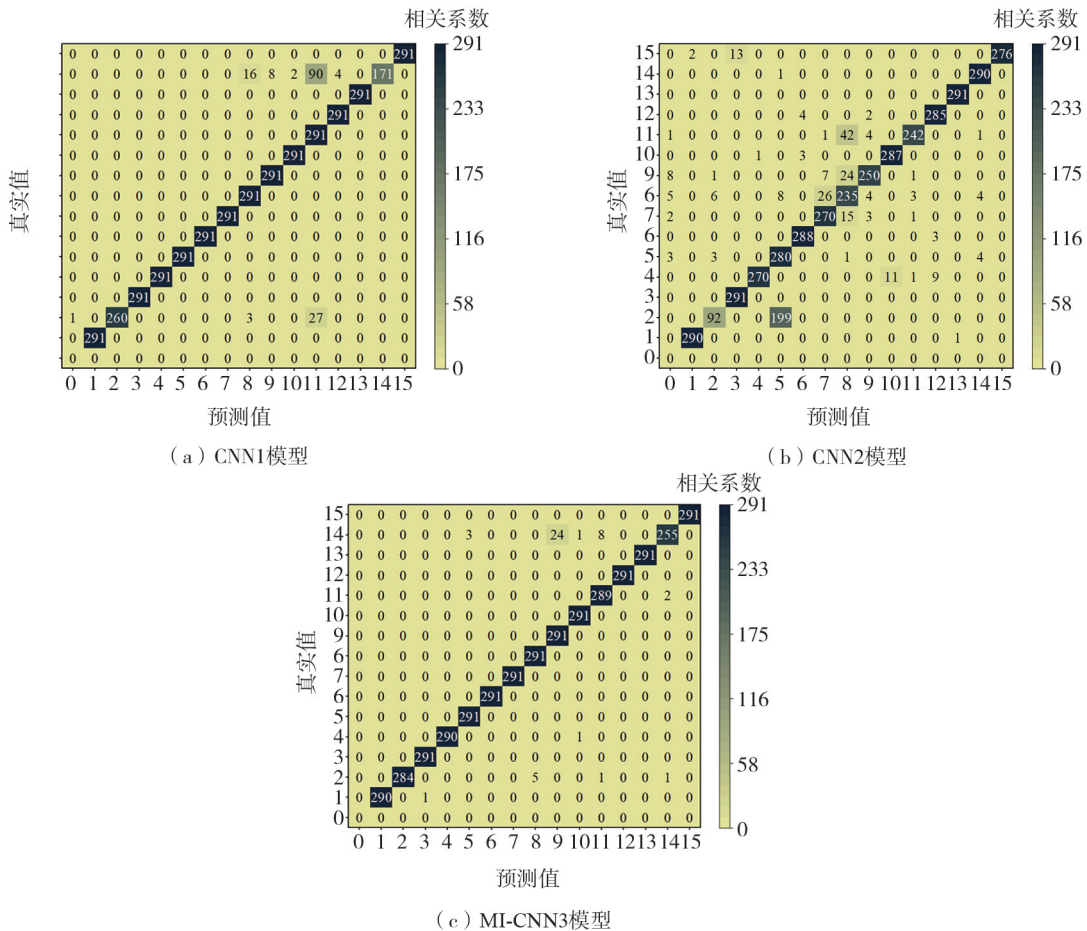




图 6 各模型沉降位置识别混淆矩阵

Fig. 6 Confusion matrices for settlement position recognition for each model

对于各模型沉降程度识别, 随机挑选一组沉降工况预测样本展示, 如图 7 所示。由图可知, MI-CNN 沉降程度预测值与实际值更加接近, 而单信号输入网络沉降程度预测容易受到周围工况的干扰, 特别是 CNN2 中 5 号沉降程度预测值接近 0.05, 而 MI-CNN 能够消除周围工况对预测结果的影响, 最大程度的减少误判的风险。





(c) MI-CNN3模型

图7 各模型沉降程度识别结果

Fig. 7 Settlement degree recognition results for each model

## 2.4 不平衡数据集验证

考虑到实际工程中,振动响应数据采集过程中往往会出现不平衡性,即某些沉降工况样本较少,然而这会使得神经网络倾向于学习大类别的特征,而忽略了小样本,且识别样本较少的类别存在较高的错分代价。在训练样本中,将各沉降程度下沉降工况 1、3 样本量减少至 200、150、100、50,其余沉降工况训练样本保持不变,构造不平衡数据集,来重新训练 CNN1、CNN2、MI-CNN3,并在测试集上进行沉降位置识别,如表 5 所示。具体不平衡工况如下:

- A: 训练样本中各个沉降程度下沉降工况 1、3 样本量各减少至 200(训练集 160,验证集 40)。
- B: 训练样本中各个沉降程度下沉降工况 1、3 样本量各减少至 150(训练集 120,验证集 30)。
- C: 训练样本中各个沉降程度下沉降工况 1、3 样本量各减少至 100(训练集 80,验证集 20)。
- D: 训练样本中各个沉降程度下沉降工况 1、3、样本量各减少至 50(训练集 40,验证集 10)。

表5 各模型在不平衡工况下的沉降位置识别结果

Fig. 5 Settlement position recognition results for each model under unbalanced conditions

不平衡工况	网络模型			不平衡工况	网络模型			%
	CNN1	CNN2	MI-CNN3		CNN1	CNN2	MI-CNN3	
A	96.01	88.81	98.65	C	93.61	87.68	97.57	
B	95.04	88.45	98.01	D	92.74	86.04	97.16	

由表 5 可知,随着不平衡工况中部分沉降工况样本数量减少,各模型沉降位置识别结果也随之降低,但也都维持 85%以上的识别准确率。其中 CNN1 和 CNN2 在不平衡工况下沉降位置识别准确率下降相对较快,而 MI-CNN3 识别结果较好,即使在样本不平衡的工况 D 中依旧保持着 97.16%识别准确率,证明了所提模型在针对不平衡数据集上依旧保持着,较稳定的沉降位置识别效果。

## 3 结论

本文提出了一种多输入卷积神经网络隔震支座沉降识别模型,将加速度和位移信号输入到模型中,通过多层卷积池化,使网络同时学到了隔震支座沉降信号的时间和空间特征,实现对隔震支座沉降识别。通过模拟结果得出如下结论:

- 1) 与传统的单输入 CNN 相比,MI-CNN3 沉降位置识别训练过程更加平稳,收敛速度更快。
- 2) 对于沉降位置识别,MI-CNN3 具有更好的辨识能力,测试集中识别准确率达到 98.92%,对于沉降程度识别,其相比 CNN1 和 CNN2 具有更小的预测误差,且预测值和实际值更加接近。
- 3) 在不平衡样本中,随着部分沉降工况中样本数量的减少,各模型的沉降位置识别准确率逐渐降低。即使在样本最不平衡的工况 D 中,MI-CNN3 识别准确率依旧达到了 97.16%,而 CNN1 和 CNN2 却只有 92.74%和 86.04%。

目前 MI-CNN3 模型只是在数值模型中进行了验证,属于有监督学习,后续将进一步开展实验室模型的验证,并引入迁移学习,以及无监督学习将所提方法应用到实际工程结构中。

## 参考文献:

- [1] 莫艳丽. 隔震体系的损伤破坏与控制[D]. 广州: 广州大学, 2012.  
MO Yanli. Control methods for damage and failure of seismic isolation system[D]. Guangzhou: Guangzhou University, 2012. (in Chinese)
- [2] 杜永峰, 谢丽, 包超. 湿陷性黄土地基不均匀沉降对基础隔震结构的影响分析[J]. 建筑科学, 2016, 32(7): 34-40.  
DU Yongfeng, XIE Li, BAO Chao. Influence analysis of collapsible loess foundation uneven settlement on the base isolation structure[J]. Building Science, 2016, 32(7): 34-40. (in Chinese)
- [3] 闫东琦. 考虑支座转角影响的地基不均匀沉降基础隔震结构地震响应分析[D]. 银川: 宁夏大学, 2022.  
YAN Dongqi. Seismic response analysis of base isolation structure considering the influence of bearing rotation caused by uneven settlement of foundation[D]. Yinchuan: Ningxia University, 2022. (in Chinese)
- [4] 杜永峰, 杨晨晓, 黄小宇. 支座失效下基础隔震结构的损伤路径识别[J]. 兰州理工大学学报, 2019, 45(1): 112-119.  
DU Yongfeng, YANG Chenxiao, HUANG Xiaoning. Damage path identification of base seismo isolated structures in case of isolating bearing failure[J]. Journal of Lanzhou University of Technology 2019, 45(1): 112-119. (in Chinese)
- [5] 韩博, 杜永峰, 时晨, 等. 考虑支座失效的基础隔震结构振动台试验研究[J]. 湖南大学学报(自然科学版), 2023, 50(7): 84-96.  
HAN Bo, DU Yongfeng, SHI Chen, et al. Shaking table test study of a base-isolated structure under an isolation bearing failure[J]. Journal of Hunan University(Natural Science Edition), 2023, 50(7): 84-96. (in Chinese)
- [6] 黄心汉, 苏豪, 彭刚, 等. 基于卷积神经网络的目标识别及姿态检测[J]. 华中科技大学学报(自然科学版), 2017, 45(10): 7-11.  
HUANG Xinhan, SU Hao, PENG Gang, et al. Object identification and pose detection based on convolutional neural network[J]. Journal of Huazhong University of Science and Technology(Natural Science Edition), 2017, 45(10): 7-11. (in Chinese)
- [7] 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)
- [8] 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 networks in structural damage identification[J]. Journal of Architecture and Civil Engineering, 2020, 37(6): 29-37. (in Chinese)
- [9] 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): 167-175.  
LI Xuesong, MA Hongwei, LIN Yizhou. Structural damage identification based on convolution neural network[J]. Journal of Vibration and Shock, 2019, 38(1) 167-175. (in Chinese)
- [10] 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)
- [11] TENG S, CHEN G F, Gong P P, et al. Structural damage detection using convolutional neural networks combining strain energy and dynamic response[J]. Meccanica, 2019, 55: 945-959.
- [12] 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: 1-22.
- [13] 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(3): 154-170.
- [14] CHA Y, CHOI W, BÜYÜKÖZTÜRK O. Deep learning-based crack damage detection using convolutional neural networks[J]. Computer-Aided Civil and Infrastructure Engineering. 2017, 32, 361-378.
- [15] 崔弥达. 基于图像处理的桥梁支座病害自动识别关键技术研究[D]. 南京: 东南大学, 2018.  
CUI Mida. Research on key techniques of automatic defect identification for bridge bearings based on image processing[D]. Nanjing: Southeast University, 2018. (in Chinese)
- [16] CHEN Z, FANG H, KE X, et al. A new method to identify bridge bearing damage based on radial basis function neural network[J]. Earthquakes and Structures, 2016, 11(5): 841-859.
- [17] ZENG Y, PAN P, HE Z Z, et al. An innovative method for axial pressure evaluation in smart rubber bearing based on bidirectional long-short term memory neural network[J]. Measurement, 2021: 109653.
- [18] 徐芳泽. 基不均匀沉降框架结构抗震性能研究[D]. 银川: 宁夏大学, 2022.  
XU Fangze. Research on the seismic performance of frame structures with uneven settlement of foundation[D]. Yinchuan: Ningxia University, 2022. (in Chinese)
- [19] TÓTH L. Phone recognition with hierarchical convolutional deep maxout networks[J]. EURASIP journal on audio, speech, and music processing, 2015, 2015(1): 1-13.
- [20] SCHERER D, M A, BEHNKE S. Evaluation of pooling operations in convolutional architectures for object recognition[C]// In Proceedings of the International Conference on Artificial Neural Networks, Thessaloniki; Springer Verlag, 2010(9): 15-18.
- [21] KINGMA D P, BA J L. Adam: A method for stochastic optimization [C]// 3rd International Conference on Learning Representations, La Jolla: ICLR, 2015: 1-15.
- [22] GB 50007—2011 建筑地基基础设计规范[S]. 北京: 中国建筑工业出版社, 2011  
GB 50007—2011 Code for design of building foundation[S]. Beijing: China Architecture & Building Press, 2011. (in Chinese)