

基于自编码器无监督学习结构损伤量化检测研究^{*}

刘 琦 宁立远 戴华林 王家兴 东 尧
(天津城建大学计算机与信息工程学院 天津 300384)

摘 要: 结构健康检测指通过实时或周期性监测评估工程结构的健康状态,深度学习方法因能从原始数据中提取高层特征而备受关注。针对实际应用中损伤类别的多样性,缺乏对损伤状态进行定量分析,提出了部分跳跃卷积自编码器损伤判断量化方法。使用卷积自编码器处理结构响应,将高维数据降维至低维特征空间,通过重构误差设定损伤指标,以判断健康状态;基于低维特征构建损伤系数,实现结构损伤量化。利用国际结构控制协会与美国土木工程协会(IASC-ASCE) IASC-ASC I 和 IASC-ASCE II 数据集验证了算法在损伤判断和量化方面的有效性。实验结果表明,损伤指标对大部分损伤状态的判定准确率达到 100%,个别损伤状态下的准确率为 96%,对不同损伤状态的量化均符合预期。

关键词: 结构健康检测;卷积自编码器;损伤量化

中图分类号: TP212;TN911.72 **文献标识码:** A **国家标准学科分类代码:** 520.2060

Research on unsupervised structural damage quantification detection based on autoencoder

Liu Qi Ning Liyuan Dai Hualin Wang Jiaying Dong Yao
(School of Computer and Information Engineering, Tianjin Chengjian University, Tianjin 300384, China)

Abstract: Structural health monitoring refers to the evaluation of the health condition of engineering structures through real-time or periodic monitoring. Deep learning methods have gained attention due to their ability to extract high-level features from raw data. However, the diversity of damage types in practical applications and the lack of quantitative analysis for damage states remain challenging. In this paper, a partial skip-connected convolutional autoencoder-based approach for damage assessment and quantification is proposed. This method utilizes a convolutional autoencoder to process structural responses, reducing high-dimensional data to a low-dimensional feature space. A damage index is defined based on reconstruction error to assess health status, while a damage coefficient constructed from the low-dimensional features enables quantitative damage assessment. The effectiveness of the algorithm in damage detection and quantification is validated using the IASC-ASCE benchmark structures I and II datasets. Experimental results demonstrate that the damage index achieves 100% accuracy in identifying most damage states, with 96% accuracy in certain specific cases, and that the quantification aligns well with expected values across different damage states.

Keywords: structural health monitoring; convolutional autoencoder; damage quantification

0 引 言

异常检测是多个领域的重要问题,尤其在大型交通设施如公路、铁路和桥梁等结构健康监测中具有重要意义。随着结构老化和腐蚀风险增加,及时、准确地识别结构安全问题对公共安全至关重要^[1]。随着计算机技术的发展,机器学习特别是深度学习凭借其强大的学习能力,在结构

健康监测中展现了潜在应用价值。深度学习不仅能实现数据的高层次抽象,还能聚类相似特征的数据,使其在异常检测和损伤识别方面得到广泛关注^[2]。

目前,深度学习方法在结构损伤检测中得到了应用。卷积神经网络(convolutional neural network, CNN)在图像处理和二维数据分析中表现优异,被用于从原始信号中自动提取损伤敏感特征,于天河等^[3]改进了传统 U-Net 网

收稿日期:2024-09-18

^{*} 基金项目:天津市科技计划项目(23YDTPJC00350)资助

络,加入跳跃式多尺度融合模块和注意力门机制,并通过扩展 A* 算法计算裂缝的最短长度和最大宽度,有效提升了量化精度。Abdeljaber 等^[4]提出了利用 CNN 处理看台加速度信号的方法。李雪松等^[5]提出了混合噪声训练模式以增强 CNN 的抗噪性,但需要繁杂的预处理。骆勇鹏等^[6]研究通过 CNN 提高了桥梁损伤检测的效率,但未能充分利用时间序列信息。此外,韩宇等^[7]将 CNN 与长短期记忆网络(long short-term memory, LSTM) 结合,使模型能够捕捉时间维度的依赖关系。这些方法主要集中于有监督学习,需要大量标记数据来区分损伤与未损伤状态,但在实际应用中难以获取充足的损伤数据。

无监督学习过程不依赖数据标记,因而在数据稀缺的条件下表现出较大优势。李洪奎等^[8]提出了基于自编码器和生成对抗网络的 GANomaly 模型,通过重构差异来检测缺陷。郭小萍等^[9]利用邻域降噪正交自编码器提升了故障检测的鲁棒性。在动力响应分析中,刘玉驰等^[10]结合残差自编码器和数据融合技术以监测深海立管。Wang 等^[11]使用深度自编码器和一类支持向量机(one-class support vector machine, OC-SVM)对结构健康数据进行训练,检测偏离边界的数据作为潜在损伤。Pollastro 等^[12]结合变分自编码器(variational autoencoder, VAE)和 OC-SVM 进行异常检测,但 OC-SVM 依赖完整数据,实时性较差。Li 等^[13]收集桥梁的车辆垂直加速度信号,通过 DAE 重构车辆响应频率进行损伤检测,结合短时傅里叶变换提取频域特征,实现车辆通过桥梁时的即时损伤评估,但该方法仅能检测损伤状态变化,无法提供具体定位信息。Ma 等^[14]利用 VAE 提取桥梁位移响应中的损伤特征,实现了损伤定位,在此基础上,Wu 等^[15]改用自编码器,更注重特征向量之间的距离,然而,虽然实现了损伤的定位分析,建立在移动荷载的基础上,对数据集的采集环境要求高。尽管上述方法在损伤检测方面有所成效,但存在数据依赖性强、实时性差和损伤量化难的问题。

针对现有方法的不足,本文提出了结合数据主能量预处理的部分跳跃卷积自编码器损伤判断量化方法。该方法利用无监督学习,通过模型输入与输出之间的重构误差进行损伤判断,同时基于特征之间的距离分布量化损伤程度。本文的模型减少了对损伤数据的依赖,并通过损伤系数量化损伤程度实现损伤程度评估。IASC-ASCE 模拟数据和实测数据验证了该方法在损伤判断与定量分析上的有效性和准确性。

1 自编码器

自动编码器是一种无监督学习模型,其目的是提取输入数据的低维表示。训练目标是最小化输入数据与重建数据之间的差异,即使得输入数据经过编码器和解码器后的输出尽可能接近原始输入。

编码器部分接收输入数据(如图像、文本等),并将其逐层压缩成一个低维的隐变量。这种压缩通常通过一系

列的全连接层实现,每一层的神经元数量逐渐减少,从而提取输入数据的关键特征。

解码器部分则是一个对称的结构,它接收来自编码器的低维表示,并逐层将其还原回原始数据的形态。解码器同样通过一系列的全连接层实现,每一层的神经元数量逐渐增加,最终输出与输入数据相同维度的重建数据。

根据数据特性,自编码器可以被设计成不同的架构,以处理特定的数据或提取更具代表性的特征。

1.1 变分自编码器

变分自编码器是一种生成模型,主要应用于数据生成、数据分布建模以及无监督学习。它在自编码器的基础上结合了概率建模的思想,通过引入正则化约束使得编码器生成的隐空间具有良好的统计特性,从而更适合于数据生成任务。具体 VAE 模型如图 1 所示。




图 1 VAE 模型

Fig. 1 VAE model

1.2 卷积自编码器

卷积自编码器在编码器和解码器中使用了卷积层和反卷积层,而不是全连接层。卷积自编码器的训练目标同样也是最小化输入数据与重建数据之间的差异。卷积层能够捕捉数据的局部特征,训练好的自动编码器对正常信号具有较好的重建能力,而对异常信号重建误差较大,可以利用这一点进行异常检测,CAE 模型如图 2 所示。




图 2 CAE 模型

Fig. 2 CAE model

1.3 降噪自编码器(denoising autoencoder, DAE)

降噪自编码器通过在输入数据中人为加入噪声,然后要求模型去学习去噪,以获得接近原始无噪声数据的重建结果。它的主要目的是提升模型对输入数据的鲁棒性,使模

型能够有效地学习数据的潜在结构,并避免简单的记忆。
DAE模型如图3所示。




图3 DAE模型
Fig.3 DAE model

2 基于部分跳跃连接卷积自编码器 (partial skip-connected convolutional autoencoder, PSC-CAE) 的损伤判断量化方法

本文针对结构损伤量化问题开展研究,提出了基于PSC-CAE的损伤判断量化模型,首先通过数据特征提取对数据集进行划分,利用训练集和验证集进行模型训练,通过设定阈值组来确定损伤指标与损伤基准系数。最终借助损伤组的重构误差的损伤特征进行损伤判断,使用损伤误差提取特征的平均欧氏距离计算与损伤基准系数之间的分布距离得到损伤系数,进行损伤程度量化。损伤判断量化模型的流程如图4所示。

2.1 数据特征提取

本文数据特征提取采用主能量窗口分析法。主能量窗口分析通过提取主要能量成分,使其能够有效捕捉信号




图4 损伤判断与量化方法

Fig.4 Damage assessment and quantification method

中的主要特征。提取能量后的数据筛选除了不显著特征,使后续的特征提取与分析变得更加有效。在使用主能量窗口提取后,数据模型收敛更快,数据集的处理更集中。数据特征提取的具体步骤如图5所示。

首先,将 N 个测点的数据进行归一化处理,取 N 个测点测得的数据组合为式(1)。

$$\bar{x} = (x_1, x_2, \dots, x_N) \quad (1)$$

其中,测点 x_i 响应时间长度为 l ,即获得数据组合的




图5 数据特征提取

Fig.5 Data feature extraction

$\bar{x}$ 大小为 $i \times l$ 。依次对响应测点 i 处的信息 x_i 进行归一化处理,其中 $\mu(x_i)$ 为测点 x_i 的均值, $\sigma(x_i)$ 为测点的标准差,如下所示:

$$\tilde{x} = \frac{x_i - \mu(x_i)}{\sigma(x_i)} \quad (2)$$

随后,使用滑动窗口对归一化好的数据集进行切分。窗口的大小的合理性直接影响能够捕获的特征类型,本文采用的滑动窗口大小为 $n \cdot f_s$, 其中 n 为测点个数, f_s 为采样频率, T 为周期时间, T 与基频 f_0 成反比,为了计算基频,使用快速傅里叶变换将训练样本转换成频域样本,计算基频时为方便后续计算,基频进行向上取整。其滑动的步长 N 计算过程如下所示:

$$N = f_s \cdot T \quad (3)$$

使用步长为 N , 大小为 $n \cdot f_s$ 滑动窗口将数据划分后如下所示:

$$\bar{x}_{n \cdot f_s}^i = \begin{bmatrix} x_{(i-1) \cdot N+1,1} & x_{(i-1) \cdot N+1,2} & \cdots & x_{(i-1) \cdot N+1,n} \\ x_{(i-1) \cdot N+2,1} & x_{(i-1) \cdot N+2,2} & \cdots & x_{(i-1) \cdot N+2,n} \\ \cdots & \cdots & \cdots & \cdots \\ x_{(i-1) \cdot N+f_s,1} & x_{(i-1) \cdot N+f_s,2} & \cdots & x_{(i-1) \cdot N+f_s,n} \end{bmatrix} \quad (4)$$




图 6 PSC-CAE 模型训练框架
Fig. 6 PSC-CAE model training framework

将阈值组与损伤数据分别放入到模型中进行重构误差计算。重构误差的计算过程如下所示:

$$L = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (7)$$

式中: L 为重构误差; n 为数据的组数; y_i 表示第 i 个样本的真实值; $\hat{y}_i$ 表示第 i 个样本的预测值。

阈值组数据划分如式(8)所示。假定输入样本测点个数为 s 个, $\bar{x}_{n \cdot f_s}^i$ 为第 i 个窗口样本数据,将这些数据组合为完整的数据集 $\bar{S}$ 。

$$\bar{S} = (\bar{x}_{n \cdot f_s}^1, \bar{x}_{n \cdot f_s}^2, \cdots, \bar{x}_{n \cdot f_s}^s) \quad (8)$$

将 $\bar{S}$ 输入模型中得到 s 个重构误差 L_s , 组合为 $\bar{S}$:

$$\bar{S} = (L_1, L_2, \cdots, L_s) \quad (9)$$

重构误差 $\bar{S}$ 的均值 μ 为:

式中: i 表示第 i 个窗口; n 表示第 n 个测点。

为了筛选出高能量的窗口,首先计算每个窗口的能量值。能量被定义为窗口数据的平方和,其中 E 表示能量, n 和 m 分别表示窗口中的行数与列数, E 的计算过程如下所示:

$$E = \sum_{i=1}^n \sum_{j=1}^m x_{i,j}^2 \quad (5)$$

将所有能量窗口计算能量值的第 t 百分位作为阈值,本文中 t 取 95,即保留 95% 的能量,计算式如下所示:

$$E_{\text{threshold}} = P_t(E) \quad (6)$$

2.2 部分跳跃连接卷积自编码器模型构建

本文搭建的 PSC-CAE 模型的训练结构如图 6 所示,主要流程包括数据输入、编码器和解码器 3 部分。首先,将预处理后的数据输入到编码器中;编码器通过多层卷积逐步提取输入数据的特征;接着,解码器将提取到的特征信息进行重构,以最小化重构误差为目标完成数据。

2.3 损伤判断

本文提出的损伤判断方法通过健康状态下数据的重构误差设置损伤指标,计算损伤状态下数据的损伤误差和损伤指标进行损伤判断,判断过程如图 7 所示。

$$\mu = \frac{1}{n} \sum_{i=1}^s L_i \quad (10)$$

重构误差 $\bar{S}$ 的标准差 σ 为:

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^s (L_i - \mu)^2} \quad (11)$$

根据重构误差求得均值 μ 与标准差 σ , 设定阈值 ϵ 为均值 μ 加 3 倍标准差 σ , 公式如下:

$$\epsilon = \mu + 3\sigma \quad (12)$$

将待检测数据放入已训练的模型,使用式(8)计算重构误差,并与阈值 ϵ 进行比较,如果重构误差大于基准阈值,则判定为损伤;反之,则判断为健康。当构建损伤状态并输入 P_a 组向量后,编码器从中产生了 P_a 个损伤误差,利用式(13)来计算损伤判定的准确率。

$$\text{准确率} = \frac{\text{损伤向量个数}}{P_a} \times 100\% \quad (13)$$




图7 损伤判断过程

Fig. 7 Damage assessment process

2.4 损伤系数

损伤量化方法通过计算损伤状态下与阈值组之间的损伤系数来进行损伤量化。当损伤程度越严重,损伤状态的潜在空间分布距离与健康状态下的分布距离偏差会变大,即损伤系数越大。具体损伤系数计算过程如图8所示。

损伤系数为损伤状态的损伤特征与阈值组的损伤基准系数之间的距离。

编码器部分将输入矩阵压缩为特征向量。假设将 n 个特征输入自编码器后,得到特征向量集 $\mathbf{M}$,其中 $\mathbf{m}_i$ 表示特征向量集中第 i 个分量,如下所示:

$$\mathbf{M} = \{\mathbf{m}_1, \mathbf{m}_2, \dots, \mathbf{m}_n\} \quad (14)$$

式(15)是计算向量之间的欧氏距离,其中 m_{ki} 与 m_{kj} 分别表示向量 $\mathbf{m}_i$ 与 $\mathbf{m}_j$ 的第 k 个元素。欧氏距离 d_{ij} 的定义排除了自身与自身的距离,即 D_{ij} ,如式(16)所示。通过欧氏距离构建平均欧氏距离 D ,其中如式(17)所示。

$$d_{ij} = \sqrt{\sum_{k=1}^n (m_{ki} - m_{kj})^2} \quad (15)$$

$$D_{ij} = \begin{cases} d_{ij}, & i \neq j \\ 0, & i = j \end{cases} \quad (16)$$

$$D = \frac{1}{n \times (n-1)} \sum_{i=1}^n \sum_{\substack{j=1 \\ i \neq j}}^n D_{ij} \quad (17)$$




图8 损伤系数计算

Fig. 8 Damage coefficient calculation

将健康状态的数据放入编码器,将样本特征向量的欧氏平均距离作为损伤基准系数 $\bar{d}$,如下所示:

$$\bar{d} = \frac{1}{N} \sum_{s=1}^N D_s \quad (18)$$

式中: N 为假设窗口样本数。

假设损伤状态下的窗口数为 P_b ,损伤状态下的窗口样本放入编码器部分,计算每个窗口状态下特征向量的欧氏距离成为损伤特征,损伤特征与损伤基准系数之间差值的绝对值的均值作为损伤系数 $\tilde{d}$, $\tilde{d}$ 的值越大,则证明损伤程度越大, $\tilde{d}$ 求解过程如下所示:

$$\tilde{d} = \frac{1}{P_b} \sum_{i=1}^{P_b} |D_i - \bar{d}| \quad (19)$$

3 有限元模拟实验

3.1 IASC-ASCE Benchmark 有限元仿真结构

为解决结构健康监测领域不同结构损伤识别方法直接对比的困难,国际结构控制协会与美国土木工程协会(international association for energy conservation and american society of civil engineers,IASC-ASCE)构建了用于结构健康监测的Benchmark有限元模型。有限元结构如图9所示。

该模型结构平面尺寸为 $2.5 \text{ m} \times 2.5 \text{ m}$,高度为 3.6 m 。构件采用热轧300 W级钢,公称屈服应力为 300 MPa (42.6 ksi)。Benchmark有限元仿真模型共4层,每层由9个柱单元(column)、12个梁单元(floor beam)、8个斜支撑(braces)单元构成。其中传感器共有16个,分别沿 x 轴有8个,沿 y 轴有8个,分布于4层结构




图9 Benchmark 钢结构框架

Fig. 9 Benchmark steel structure framework

框架,用于采集模型的振动信号,具体模型结构如图10所示。

本文采用的 IASC-ASCE Benchmark 有限元模型的结构损伤模式为7种,为工况1~7。工况8为无损伤状态,内容如表1所示。

其中,工况1~7的损伤状态对应的损伤工况结构如图11所示,使用虚线与圆圈突出结构损伤的部位。

3.2 损伤判定量化过程

以上述8种情况下为例,探究损伤情况下方法的损伤识别性能。数值模拟流程如下。

1)数据集生成,将健康状态下的响应按长度为1 000的窗口裁剪并重组,生成800组样本,并按4:1:3比例划分为训练集、验证集和阈值确定集(样本数分别为400、100和300)。对7种损伤状态下的响应数据进行相同处理,每种状态生成800组样本,每个样本为 $1 \times 1\,000 \times 16$ 的张量。

2)模型的训练与阈值的确定将划分好的训练集与验证集输入到建立的CAE模型进行训练。当训练完成后,




图10 Benchmark 有限元模型

Fig. 10 Benchmark finite element model

表1 Benchmark 结构的损伤模式

Table 1 The damage modes of the Benchmark structure

损伤模式	损伤状态描述
工况1	第1层的支撑失去刚度
工况2	第1层和第3层的所有支撑失去刚度;
工况3	第1层的1根支撑失去刚度
工况4	第1层和第3层的1根支撑失去刚度
工况5	损伤模式与工况4相同,但西面的第1层楼的北楼板梁部分从西北柱上松开
工况6	第1层的1根支撑刚度减小2/3
工况7	第4层的1根支撑刚度减小1/10
工况8	无损伤

将阈值确定集的样本输入模型进行重构计算,提取特征。根据健康状态下数据的平均值加上3倍标准差设置损伤阈值。同时,根据特征矩阵之间的欧氏距离均值确定损伤基准系数。将训练集和验证集输入CAE模型进行训练。训练完成后,将阈值确定集样本输入模型进行重构,提取




图11 IASC-ASCE I 损伤工况结构

Fig. 11 IASC-ASCE I structural diagram of damage condition

特征。阈值组数据的重构误差的平均值加 3 倍标准差设为损伤指标,特征矩阵之间的欧氏距离均值确定损伤基准系数。

3)结构损伤判断与量化将 7 种工况下的数据集输入到已训练的模型中计算损伤误差,将损伤误差与损伤指标进行比较;当小于损伤指标时,判定为正常;若超过,则认定为存在损伤。同时,将损伤状态下的损伤特征与损伤基准系数进行计算得到损伤系数,从而确定损伤程度。

3.3 实验参数选择

为了确定 CAE 模型的最优参数配置,采用了网格搜索方法。本文优化了多个关键参数,包括卷积层数量(2~5 层)、学习率(0.000 1~0.01)、卷积核数量(32、48、64、80)、卷积核尺寸(3×3 和 5×5)、激活函数类型(SeLU 和 ReLU),以及池化层的步幅(2 或 3)。经过测试后,最终决定具体网络结构如表 2 所示。

表 2 IASC-ASCE I 实验的 CAE 结构		
Table 2 CAE structure of IASC-ASCE I experiment		
模型	层数	输出形状
编码器	输入层	(16,1 000)
	# 1 卷积层	(32,1 000)
	# 1 SeLU 层	(32,500)
	# 1 最大池化层	(48,500)
	# 2 卷积层	(48,500)
	# 2 SeLU 层	(48,500)
	# 2 最大池化层	(48,250)
	# 3 卷积层	(64,250)
	# 1 展平层	(16 000)
解码器	全连接层	(64,250)
	# 1 重构层	(64,250)
	# 1 反卷积层	(48,250)
	# 3 SeLU 层	(48,250)
	# 1 上采样层	(48,500)
	# 2 反卷积层	(32,500)
	# 4 SeLU 层	(32,500)
	# 2 上采样层	(32,1 000)
	# 3 反卷积层	(16,1 000)

3.4 实验结果分析

当实验采用最佳的网络结构后,网络训练损失曲线如图 12 所示,可以看到,模型的训练效果,在 200 轮 Epoch

后,模型的训练集与测试集接近稳定,表明模型的泛化能力良好,并未出现过拟合与欠拟合的现象。




图 12 IASC-ASCE I 训练损失曲线
Fig. 12 IASC-ASCE I training loss curve

在损伤判断的实验分析中,对工况 1~8 进行了评估,具体损伤准确率如表 3 所示。实验结果表明,在无损状态下,该方法取得了 100% 的准确率,充分表明对无损情况的识别能力。在损伤状态下,工况 1~6 同样达到了 100% 的准确率,部分跳跃卷积自编码器能够在重构过程中有效地保留和重建输入数据的关键信息。部分跳跃连接使模型能够在解码过程中利用浅层和深层特征的结合,从而提升了对损伤特征的敏感性。

然而,在工况 7 的损伤判断中,准确率略有下降,其中数据组 1、数据组 2、数据组 3 的准确率分别为 96%、95%、98%。这种现象的出现归因于工况 7 的损伤程度较轻,其重构数据与无损数据在特征上具有一定的相似性,导致判断过程中准确率有所降低。总体而言,该方法在不同损伤程度的情况下均表现出较高的准确率,证明了其在损伤判断方面的有效性和鲁棒性。

在损伤量化流程的实验分析中,计算各个损伤状态下的损伤系数。当损伤状态越严重,数据经过编码器得到的潜在空间结构距无损状态的潜在空间结构偏离越大,即损伤系数越大。结果如表 4 所示。计算各损伤状态下的损伤特征值,并将其与损伤基准系数进行计算,得出了相应的损伤系数如表 4 所示,结果表明,在不同激励状态下,损伤系数与损伤程度呈相关关系。在 7 种损伤工况中,工况 7 的损伤程度最低,即损伤系数最接近无损状态;工况 6 的损伤系数次之,表明工况 6 的损伤程度也较轻;工

表 3 IASC-ASCE I 损伤准确率								
Table 3 IASC-ASCE I damage accuracy								
数据组	准确率/%							
	工况 1	工况 2	工况 3	工况 4	工况 5	工况 6	工况 7	工况 8
1	100	100	100	100	100	100	96	100
2	100	100	100	100	100	100	95	100
3	100	100	100	100	100	100	98	100

况 2 的损伤系数最高,表明损伤情况最严重;工况 1 的损伤系数仅次于工况 2,显示出较高的损伤程度;工况 4 和

工况 2 的损伤系数相对接近,表明这两种工况的损伤程度相似。

表 4 IASC-ASCE I 损伤系数
Table 4 IASC-ASCE I damage coefficient

数据组	损伤状态/损伤系数							
	工况 1	工况 2	工况 3	工况 4	工况 5	工况 6	工况 7	工况 8
1	2.200 356	3.853 869	1.197 771	1.201 269	1.219 755	0.593 836	0.217 34	0.120 1
2	2.616 38	4.336 55	0.831 234	0.916 08	0.940 471	0.385 822	0.193 86	0.136 302
3	2.300 356	3.224 873	1.242 429	1.317 34	1.416 54	0.775 345	0.232 41	0.113 18

进一步分析可知,损伤程度越高,损伤系数的值越大,从各工况的损伤系数对比中得到了验证。损失系数柱状图如图 13 所示,当损伤越严重,损伤系数有明显的上升。这表明,本文所提出的损伤系数能够有效反映结构损伤的严重程度,具有较高的可靠性和有效性。




图 13 IASC-ASCE I 损伤系数柱状图

4 物理模型实验验证

4.1 IASC-ASCE II 简介

IASC-ASCE Benchmark 结构研究包含(数值模拟与模型实验)两阶段的研究。在 IASC-ASCE Benchmark 基础上为了更高质量的实验数据,美国结构健康监测工作组对 Benchmark 进行了第 2 阶段的实验。为了进一步验证方法的实用性以及有效性,采用第 2 阶段的 IASC-ASCE Benchmark II 进行下一步实验研究。

加拿大英属哥伦比亚大学地震工程实验室所建立的 Benchmark 试验模型,平面尺寸为 2.5 m×2.5m,高度为 3.6 m。构件材料为热轧 300 W 级钢,300 MPa(42.6 ksi)。柱的截面为 B100×9,地梁的截面为 S75×11。在每个隔间中,支撑系统由两根直径为 12.7 mm(0.5 in)的螺纹钢杆组成,沿对角线平行放置。为了使质量分布合理实际,每个楼层的每个开间放置一块楼板,第 1 层、第 2 层和第 3 层各放置 4 块 1 000 kg 的楼板,第 4 层放置 4 块 750 kg 的楼板。每层都有两个质量块偏离中心放置,以增加结构平

移运动之间的耦合度。此外,使用两个槽钢将质量块固定到结构上,以将每个质量块用螺栓固定到钢架上。每个通道部分的质量约为 9.75 kg,两个通道的总质量为 19.5 kg,具体实验装置如图 14 所示。



图 14 IASC-ASCE Benchmark II 结构

Fig. 14 IASC-ASCE Benchmark II structure

在 IASC-ASCE Benchmark II 基准结构中布置了 15 个加速度传感器,采集由振动产生的加速度响应信号,实验中的损伤工况由拆除结构中的层间支撑或松动梁栓与梁栓之间的螺丝来进行模拟。其中,传感器放置在每层中间柱位置,具体传感器布置如图 15 所示。

按照之前的描述,实验使用了在 5~50 Hz 的随机振动台激励期间在结构上测量的加速度,加速度响应信号采样频率为 250 Hz,通过拆除结构中的支撑或松开梁柱连接处的螺栓来模拟损伤。Case1 为所有支架就位后,对标准的结构进行测试。Case7 考虑了无支撑框架,这种结构的频率低于完全支撑框架的频率。Case2~Case6 使用了在 Case1 的基础上进行扩充,Case8 和 Case9 在 Case7 的基础上进行扩充。具体损伤情况如表 5 所示。图 16 所示为损伤结构,其中红线表示支撑移除。

4.2 损伤识别

以上述 9 种实测情况为例,探究损伤情况下方法的损伤识别性能。

1)数据集生成考虑到采样频率为 250 Hz,在设计卷




图 15 传感器布置

Fig. 15 Sensor arrangement

表 5 IASC-ASCE II 结构损伤模式描述

Table 5 IASC-ASCE II structural damage mode description

Case	损伤情况
1	完全支撑配置
2	所有东侧支架都已拆除
3	移除东南角一个开间中所有楼层的支撑
4	移除东南角一个开间中 1 楼和 4 楼的支撑
5	在东南角的一个隔间中, 拆除第 1 层的支撑
6	移除东立面上所有楼层的支撑, 以及北立面上第 2 层的支撑
7	移除所有面上的所有支撑
8	配置 7 基础上添加东侧、北侧梁两端所有楼层的螺栓松动
9	配置 7 基础上添加东侧梁两端 1 层和 2 层松动的螺栓

积神经网络时,由于卷积层的层数为奇数会导致计算上的不便,因此将窗口设置为 $1 \times 256 \times 12$ 。通过计算提取数据集中健康状态 Case1 的响应数据集,使用 256×12 的时间窗口对健康状态 1~200 s 响应进行随机裁剪,按照 3:1:1 划分训练集,验证集,阈值确定集。样本为 $1 \times 256 \times 15$ 的张量。

2)模型的训练与阈值的确定将划分好的训练集与验证集输入到建立的模型进行训练,直至损失值降到最低。当训练完成后,将阈值确定集样本输入到模型中进行计算,根据健康状态下的平均值加上 3 倍的标准差设置损伤指标。根据特征矩阵自身欧氏距离的均值确定损伤基准系数。

3)结构损伤判断与量化将 Case2~Case9 八种工况下数据集输入到训练好的模型中进行重构计算。然后,




图 16 IASC-ASCE II 损伤结构

Fig. 16 IASC-ASCE II damage structure diagram

将损伤特征与步骤 2)中确定的损伤指标进行比较,当值低于设定的损伤指标时,判定为损伤;如果超过损伤指标,则认定存在损伤。由于数据量有限,不对无损状态下的数据进行探讨。同时将损伤状态下的损伤特征与损伤基准系数进行对比计算,得到损伤系数,继而确定损伤程度。

4.3 实验参数选择

经过网格搜索法寻找最优参数,本文设置如表 6 所示的参数。

4.4 实验结果分析

当实验采用最佳的网络结构后,网络训练损失曲线如图 17 所示,在经过 500 轮训练之后,训练集与验证集趋势趋于稳定,证明模型训练没有过拟合与欠拟合发生。

将 Case2~Case9 进行损伤判断,由于 Case2~Case9 的损伤程度均大于无损状态,重构误差与无损数据的偏离较大,损伤准确率均为 100%,Case2~Case9 的准确率如表 7 所示。

表 8 所示为 Case2~Case9 的损伤系数,根据损伤严重程度导致潜在空间分布距离偏差,Case7~Case9 在移除所有面上的所有支撑后,损伤系数显著增加,损伤程度远高于 Case2~Case6,表明这些工况下的损伤状态更加严重,符合预期。Case6 与 Case2 的损伤程度相对较大,损伤

表 6 IASC-ASCE II 实验的 CAE 结构
Table 6 CAE structure of IASC-ASCE II experiment

模型	层数	输出形状
编码器	输入层	(15,256)
	# 1 卷积层	(30,256)
	# 1 SeLU 层	(30,256)
	# 1 最大池化层	(30,128)
	# 2 卷积层	(45,128)
	# 2 SeLU 层	(45,128)
	# 2 最大池化层	(45,64)
	# 3 卷积层	(60,64)
	# 1 展平层	(3 840)
解码器	全连接层	(4096)
	# 1 重构层	(60,64)
	# 1 反卷积层	(45,64)
	# 3 SeLU 层	(45,64)
	# 1 上采样层	(45,128)
	# 2 反卷积层	(30,128)
	# 4 SeLU 层	(30,128)
	# 2 上采样层	(30,256)
	# 3 反卷积层	(15,256)




图 17 IASC-ASCE II 训练损失曲线
Fig. 17 IASC-ASCE II training loss curve

系数位于较高水平;而 Case3、Case4 和 Case5 的损伤系数较小,表明其损伤程度较轻。

损伤系数柱状图如图 18 所示,当损伤程度越高,损伤系数的值越大,由图 18 可以看出,在损伤情况越严重的工况下,损伤系数明显上升。实验结果表明,损伤系数可以有效的证明结构损伤的严重程度,具有较高的可靠性与有效性。

表 7 损伤状态 Case2~Case9 的准确率
Table 7 Accuracy of damage status Cases 2~Cases 9

损伤模式	Case2	Case 3	Case 4	Case 5	Case 6	Case 7	Case 8	Case 9
准确率/%	100	100	100	100	100	100	100	100

表 8 损伤状态 Case2~Case9 的损伤系数
Table 8 Damage coefficient of damage states Case2~Case9

损伤模式	Case 2	Case 3	Case 4	Case 5	Case 6	Case 7	Case 8	Case 9
损伤系数	1.356 8	0.741 43	0.677 44	0.618 03	1.774 71	4.087 04	4.761 7	4.511 3




图 18 损伤系数图
Fig. 18 Damage coefficient diagram

5 结 论

本文提出了一种基于自编码器的全新结构损伤检测量化方法,利用卷积自编码器结合健康状态下的加速度数据,实现了对结构损伤的有效检测。数值模拟与实验验证表明,该方法能够在不同损伤情况下识别损伤的存在,且损伤程度越严重,损伤系数越大,进一步证明了该方法在损伤程度量化方面的有效性。该方法通过健康状态损伤指标来判断损伤,简化了损伤识别过程,具有简便易行的特点。同时,自编码器对数据进行压缩,通过损伤状态与健康状态下欧氏平均距离的差异来量化损伤程度,为结构状态的评估与监测提供了可靠依据,有助于判断结构的损伤程度。该方法展示了良好的性能,无需复杂算法,自编码器结构易于实现,为损伤量化提供了一种新途径。

参 考 文 献

- [1] TALAEI KHOEI T, OULD SLIMANE H, KAABOUCH N. Deep learning: Systematic review, models, challenges, and research directions [J]. Neural Computing and Applications, 2023, 35(31): 23103-23124.
- [2] JIA J, LI Y. Deep learning for structural health monitoring: Data, algorithms, applications, challenges, and trends [J]. Sensors, 2023, 23(21): 8824.
- [3] 于天河, 徐博超, 侯善冲, 等. 基于图像的道路裂缝分割及量化方法研究 [J]. 仪器仪表学报, 2024, 45(9): 77-91.
YU T H, XU B C H, HOU S H C H, et al. Research on image-based road crack segmentation and quantification method [J]. Chinese Journal of Scientific Instrument, 2024, 45(9): 77-91.
- [4] 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.
- [5] 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 X S, MA H W, LIN Y Z H. Structural damage identification based on convolutional neural networks [J]. Journal of Vibration and Shock, 2019, 38(1): 159-167.
- [6] 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 Y P, WANG L K, LIAO F Y, et al. Structural damage identification based on one-dimensional convolutional neural networks [J]. Earthquake Engineering and Engineering Vibration, 2021, 41(4): 145-156.
- [7] 韩宇, 李剑, 马慧宇, 等. 基于 CNN-LSTM 的桥梁结构损伤诊断方法 [J]. 国外电子测量技术, 2021, 40(7): 1-6.
HAN Y, LI J, MA H Y, et al. Bridge structural damage diagnosis method based on CNN-LSTM[J]. Foreign Electronic Measurement Technology, 2021, 40(7): 1-6.
- [8] 李洪奎, 陈浩, 刘韵婷, 等. 基于改进自编码器结构的轮胎缺陷检测 [J]. 电子测量与仪器学报, 2024, 38(10): 170-179.
LI H K, CHEN H, LIU Y T, et al. Tire defect detection based on improved autoencoder structure [J]. Journal of Electronic Measurement and Instrumentation, 2024, 38(10): 170-179.
- [9] 郭小萍, 张志朋, 李元. 基于邻域降噪正交自编码器的工业过程故障检测[J]. 电子测量技术, 2022, 45(21): 142-147.
GUO X P, ZHANG Z H P, LI Y. Fault detection in industrial processes based on neighborhood denoising orthogonal autoencoder [J]. Electronic Measurement Technology, 2022, 45(21): 142-147.
- [10] 刘玉驰, 蒋玉峰, 王树青, 等. 基于数据融合及残差卷积自编码器的结构损伤识别方法[J]. 振动与冲击, 2023, 42(4): 194-203.
LIU Y C H, JIANG Y F, WANG S H Q, et al. Structural damage identification method based on data fusion and residual convolutional autoencoder[J]. Journal of Vibration and Shock, 2023, 42(4): 194-203.
- [11] WANG Z, CHA Y J. Unsupervised deep learning approach using a deep auto-encoder with a one-class support vector machine to detect damage[J]. Structural Health Monitoring, 2021, 20(1): 406-425.
- [12] POLLASTRO A, TESTA G, BILOTTA A, et al. Semi-supervised detection of structural damage using variational autoencoder and a one-class support vector machine[J]. IEEE Access, 2023, 11: 67098-67112.
- [13] LI Z, LIN W, ZHANG Y. Real-time drive-by bridge damage detection using deep auto-encoder [J]. Structures, 2023, 47: 1167-1181.
- [14] MA X, LIN Y, NIE Z, et al. Structural damage identification based on unsupervised feature-extraction via variational auto-encoder [J]. Measurement, 2020, 160: 107811.
- [15] WU J, NIE Z. Damage detection of beam bridge under a moving load using auto-encoder [J]. Journal of Building Technology, 2021, 3(1): 13-25.

作 者 简 介

刘琦, 讲师, 主要研究方向为结构损伤识别。

E-mail: liuqicj@126.com

宁立远, 硕士研究生, 主要研究方向为结构损伤识别。

E-mail: Nliyuan@163.com

戴华林(通信作者), 教授, 主要研究方向为虚拟现实技术、数字图像处理、机器学习。

E-mail: dai_hualin@163.com