



基于压缩感知和深度学习的结构损伤识别

赵雄鹰, 任宜春

(长沙理工大学 土木工程学院, 湖南 长沙 410114)

摘要: 针对目前结构健康监测采集数据时间长、海量数据占用内存高、运输成本高以及数据利用率低的问题, 文章提出了将压缩感知技术和深度学习网络相结合的结构损伤识别方法, 对有限元模拟得到的加速度响应信号用压缩感知技术进行处理, 得到了压缩信号和重构信号; 针对传统重构方法重构效果不佳的问题, 提出一种基于全变分正则化 (TV, Total Variation) 的交替方向乘子重构算法 (ADMM) 来改善重构性能, 建立了基于卷积神经网络 (CNN) 的简单损伤识别模型和基于此在这个模型上同时引入了数据增强技术和多头自注意力机制 (Multi-Head Attention) 的 MHA-CNN⁺ 模型。结果表明: 信号重构中, TV-ADMM 算法能以很高的精确率重构出原始信号; 在损伤识别任务中, 原始信号和重构信号在 CNN 模型上都能够以非常高的精确率完成损伤识别任务, 但对于压缩信号则表现不佳, 而压缩信号在 MHA-CNN⁺ 模型上则能以很高准确完成损伤识别任务。

关键词: 压缩感知; 深度学习; 损伤识别; 健康监测

中图分类号: TU 317; TU 391; TP183

文献标识码: A

文章编号: 1673-8993(2024)08-0007-08

doi: 10.13402/j.gcjs.2024.08.098

Structural damage identification based on compressed sensing and deep learning

ZHAO Xiongying, REN Yichun

(School of Civil Engineering, Changsha University of Science Technology, Changsha 410114, Hunan, China)

Abstract: Aiming to address the challenges of lengthy data collection, high memory consumption, elevated transportation costs, and low data utilization in current structural health monitoring, a novel approach for structural damage recognition is proposed by integrating compressive sensing and deep learning networks. Initially, acceleration response signals obtained from finite element simulations are processed using compressive sensing, yielding compressed and reconstructed signals. To address suboptimal reconstruction from conventional methods, an Alternating Direction Method of Multipliers (ADMM) with Total Variation (TV) regularization is introduced to enhance reconstruction performance. The TV-ADMM algorithm demonstrates highly accurate signal reconstruction. Subsequently, a convolutional neural network (CNN) based damage identification model is established, showing excellent accuracy for both original and reconstructed signals, but limited performance for compressed signals. To overcome this, data augmentation and Multi-Head Attention mechanisms are integrated into the model (MHA-CNN⁺), resulting in effective damage recognition using improved compressed signals.

Key words: compressed sensing; deep learning; damage identification; health monitoring

随着土建工程的使用时间增加, 各种结构部位都会出现不同程度的损伤。当这些损伤累积到一定程度, 结构可能会发生倒塌或断裂, 从而严

重威胁到人们的生命和财产安全。考虑到这一点, 对大型结构进行健康监测显得尤为重要。针对结构健康监测所产生的大量数据, 传统损伤识别方

收稿日期: 2024-02-09

作者简介: 赵雄鹰 (1999—), 男, 硕士研究生, 从事结构损伤识别方面的研究。

法在数据利用效率和识别精度上均存在不足。作为一种基于多层人工神经网络的方法,深度学习具有自动学习和提取数据中特征与模式的能力。在结构健康监测与损伤识别方面,深度学习网络可以充分挖掘这些数据,从而有效地捕获结构中的复杂非线性损伤特征。压缩感知是一种革命性的数据采集技术。与传统的奈奎斯特采样定理相对,后者要求采样频率至少为信号最高频率的两倍,实际应用中的采样率往往会超过此要求,导致数据存在较大冗余^[1]。相较之下,压缩感知能够以远低于传统方法的采样率进行数据采集,并在采集过程中实现数据压缩。

结合深度学习的需求,压缩感知为其提供了极大便利。由于深度学习需要大量数据,采用压缩感知技术可以有效提高数据采集的效率,从而节省数据采集、储存和传输的时间和成本。此外,压缩感知还能显著地降低数据维度,这为加速深度学习网络的训练时间提供了可能。

基于深度学习的结构损伤识别研究是当前研究的热点。传统的机器学习方法通常需要手动提取特征,这一过程既耗时,又可能因缺乏专业知识而不够准确。深度学习算法在处理大量复杂数据方面具有显著优势,能够自动提取和学习数据的深层特征,从而提高损伤识别的准确性和效率。ABDELIABER 等^[2]首次尝试基于 CNN 的方法应用于振动的结构损伤检测,利用一维 CNN 从原始加速度数据中自动学习提取最优特征,实现了基于振动的损伤检测和损伤定位。DANG 等^[3]开发了一个实用的端到端框架,利用原始数据中嵌入的物理特征和精心设计的混合深度学习模型,通过涉及实验和合成数据集的 3 个案例研究,证明了所提出的方法实现了高度准确的损伤检测,与二

维 CNN 一样准确,而时间和内存复杂度更低。

本文采用压缩感知方法对有限元分析得到的加速度响应原始数据进行模拟采样。将原始数据、压缩数据和重构数据作为不同深度学习模型的输入,进行结构损伤的识别。经研究验证,利用压缩感知处理的数据不仅大大减轻了数据存储和传输的负担,而且其在损伤识别上的准确性和鲁棒性与直接使用原始数据相差无几。

1 数值算例

1.1 数据生成与预处理

传统的张弦梁结构因其冗余度较低,容易受到意外荷载的影响。若拉索的任一截面遭受损伤,结构可能会完全垮塌^[4,5]。针对这一问题,本研究采用了蒋友宝等^[6]提出的改进张弦梁结构模型进行数值模拟,以获取损伤数据。此改进结构不仅具有强大的抗连续倒塌能力,其结构配置也更为复杂。利用 ANSYS 软件建立了该改进结构的有限元模型。这一张弦梁模型的跨度为 5.25 m,包括上弦杆、下弦杆、上撑杆、下撑杆、边撑杆和下拉索。具体模型尺寸和细节如图 1 所示。

为了模拟结构在实际情境下的损伤情况,本研究通过降低弹性模量的方法来模拟损伤。根据不同的损伤位置和程度,共设计了 8 种损伤工况,详细情况如表 1 所示。在完成改进构型张弦梁的有限元模型构建后,选择在上弦杆的随机位置(除两端外)施加 5~200 N 的随机脉冲激励,以获取加速度响应信号。信号的采样频率设置为 100 Hz,每次采样持续 0.5 s。为了确保信号采集的准确性,在结构上布置了 8 个传感器,具体分布如图 2 所示。在每种损伤工况下,获得了 100 个损伤样本,总计 800 个样本,其中每个样本的大小为 500×8 。




图 1 改进构型张弦梁模型

所有这些样本组成了原始数据集 Data。

表 1 损伤工况设置

损伤工况号	损伤部位	损伤程度/%
1(无损工况)	—	—
2	SXG1	10
3	SXG1	50
4	SCG6	50
5	XCG2	50
6	XXG1	50
7	SXG1, SXG2	50
8	SXG1, SXG2, SXG3	50




图 2 传感器分布

为了模拟真实情况下环境噪声的干扰,在样本中分别加入了噪声水平为 5% 和 15% 的高斯白噪声。加入噪声后的数据集分别命名为 Data - n5 和 Data - n15。

1.2 基于 TV - ADMM 的压缩感知信号重构

为了实现信号的精准重构,要求信号变换到稀疏域中的稀疏表示越稀疏越好。常见的变换方法由小波变换、傅里叶变换、余弦变换。总结不同信号特征的稀疏表示方法如表 2 所示。文中的加速度响应样本的矩阵大小都为 500×8 , 其中一个传感器对应的时域图如图 3 所示。从图中可以看出该信号带有局部周期性, 表中的 DCT 最适宜该特征信号。

表 2 稀疏变换方法对比

稀疏变换方法(简称)	适用的信号特征
离散傅里叶变换(FFT)	平稳信号
脊波变换(Ridgelet)	直线边缘
小线变换(Beamlet)	奇异变换
曲波变换(Curvelet)	曲线结构、多方向线状变化等
轮廓波变换(Contourlet)	轮廓特征和方向性原理
剪切波变换(Shearlet)	光滑曲线、各向异性结构
非抽取小波变换(UWT)	各向同性边缘
离散余弦变换(DCT)	局部周期性

独立同分布的高斯随机观测矩阵和 DCT 是不相关的,是良好的观测矩阵,本文采样率取 30%、50% 和 80%,即每一列的观测数为 150、250 和 400,观测

后的矩阵大小为 150×8 、 250×8 和 400×8 。




图 3 加速度响应时序

1.2.1 基于总变分(TV)正则化的 ADMM 方法

总变分正则化是一种常用于图像处理和计算机视觉的技术,主要思想是对图像的梯度进行限制。在本方法中,引入总变分正则化能保持信号的局部平滑性,可以在捕获信号的粗略特性的同时,保留其细节部分。本文将引入总变分正则化的 ADMM 方法为 TV - ADMM。TV - ADMM 的目标是优化以下函数:

$$\min_x \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|x\|_1 + \lambda_w \|Dx\|_1 \quad (1)$$

式中: D 为差分矩阵; x 为重构信号; b 为原始信号; λ_1 和 λ_w 分别为 L1 范数和总变分的正则化参数。

为了引入 ADMM,在这里定义了两个辅助变量 z_1 和 z_2 ,然后将(1)式重写成下列式子:

$$\min_{x, z_1, z_2} \frac{1}{2} \|Ax - b\|_2^2 + \lambda \|z_1\|_1 + \lambda_w \|Dz_2\|_1 \quad (2)$$

$$\text{s. t. } x = z_1 \quad (3)$$

$$\text{s. t. } x = z_2 \quad (4)$$

采用增广拉格朗日方法来处理这个约束,得到一个增广拉格朗日函数如下。

$$L(x, z, u_1, u_2) = \frac{1}{2} \|Ax - b\|_2^2 + \lambda_1 \|z_1\|_1 + \lambda_w \|z_2\|_1 + u_1^T (x - z_1) + \frac{p}{2} \|x - z_1\|_2^2 + u_2^T (Dx - z_2) + \frac{p}{2} \|Dx - z_2\|_2^2 \quad (5)$$

其中: λ_1 和 λ_w 分别为 L1 范数和总变分的正则化参数, p 为 ADMM 的参数, b 为测量信号, A 为重构矩阵, x 为待重构信号, u_1 和 u_2 为拉格朗日乘数。 D 为差分矩阵,用来计算信号的差异或变化,从而得到信号的总变差。迭代过程如下:

(1) 更新 x : 固定了 z_1 、 z_2 、 u_1 和 u_2 , 然后根据它们来更新 x 。 x 是唯一的未知数。

(2) 更新 z_1 和 z_2 : 更新 z_1 时固定 x, z_2, u_1 和 u_2 , 使用软阈值函数对 $x + u_1$ 进行处理。这一步是对 L1 正则化项进行的优化。更新 z_2 时先通过 $D \times x$ 计算 Dx , 表示信号的差分, 然后固定 x, z_1, u_1 和 u_2 , 使用软阈值函数对 $Dx + u_2$ 进行处理。然后求解增广拉格朗日函数对 z 的最小化问题, 这一步是对 TV 正则化项进行的优化。通过软阈值操作可以有效地将一些系数设为 0, 从而实现特征选择以及使结果更稀疏。

(3) 更新 u_1 和 u_2 : 基于 x 和 z_1 的差异更新拉格朗日乘子 u_1 ; 基于 Dx 和 z_2 的差异更新拉格朗日乘子 u_2 , 确保在 TV-ADMM 中约束条件得到满足。最后迭代到最大次数的 x 即为重构的最终输出。

1.2.2 TV-ADMM 的重构效果


在 Python 平台上, 构建了压缩感知模型。在此模型中, 选择 DCT 作为稀疏基, 而高斯随机测量矩阵被选为观测矩阵。为了重构信号, 采用了 TV-ADMM 算法, 其中 L1 正则化参数设置为 0.05, TV 正则化参数为 1。模型的迭代次数定为 1 000 次, 而采样率有 3 个选项: 30%、50% 和 80%。值得注意的是, 这两个正则化参数是基于对模型的网格搜索得到的最优值。此外, 还构建

了一个采用 ADMM 的压缩感知模型, 经过网格搜索, 确定了最佳的 L1 正则化参数为 1.0。

图 4 展示了在 Data 数据集中随机选取的一个样本在不同采样率下使用 TV-ADMM 重构算法得到的第一个传感器的响应信号与原始信号的可视化对比。作为对比, 图 5 展示了使用 ADMM 重构算法对同一样本在不同采率的第一个传感器的响应信号与原始信号的对比

如图 4 所示, 采用 TV-ADMM 算法进行的信号重构与原始信号之间的差异在 80% 采样率和 50% 采样率的时候微乎其微。图 5 展示了使用 ADMM 算法进行信号重构时, 在不同采样率下存在较大的差异, 尤其是在低采样率下。尽管在高采样率下, 其重构效果尚可, 但在低采样率下, 效果明显不佳。通过这些可视化对比, 可以清楚地看到, 经过改进的 TV-ADMM 算法在信号重构方面的性能显著超越了传统的 ADMM 算法。


如图 4 所示, 采用 TV-ADMM 算法进行的信号重构与原始信号之间的差异在 80% 采样率和 50% 采样率的时候微乎其微。图 5 展示了使用 ADMM 算法进行信号重构时, 在不同采样率下存



采样率/%: (a) 30; (b) 50; (c) 80

1—原始信号; 2—使用 TV-ADMM 重构信号。

图 4 TV-ADMM 算法下不同采样率的重构对比



采样率/%: (a) 30; (b) 50; (c) 80

1—原始信号; 2—使用 ADMM 的重构信号。

图 5 ADMM 算法下不同采样率的重构对比

在较大的差异, 尤其是在低采样率下。尽管在高采样率下, 其重构效果尚可, 但在低采样率下, 效果明显不佳。通过可视化对比可以清楚看到, 经过改进的 TV - ADMM 算法在信号重构方面的性能显著超越了传统的 ADMM 算法。

表 3 和表 4 展示了在 Data 数据集中 10% 的样本采用 TV - ADMM 重构算法、ADMM 重构算法、正交匹配追踪算法 (OMP) 以及快速迭代收缩阈值算法 (FISTA) 时的重构误差和均方误差 (MSE)。表 5 和表 6 展示了在 Data - n15% 数据集中 10% 的样本采用 TV - ADMM 重构算法、ADMM 重构算法、正交匹配追踪算法 (OMP) 以及快速迭代收缩阈值算法 (FISTA) 时的重构误差和均方误差 (MSE) 通过表中的数据, 可以明显地观察到, 在各种采样率下, TV - ADMM 算法的重构性能显著地超过了其他算法。

表 3 Data 重构误差

重构算法	采样率/%		
	30	50	80
ADMM	35.480 0	22.587 2	11.010 3
FISTA	86.881 4	67.450 8	33.883 2
OMP	87.054 4	44.249 0	32.568 0
TV - ADMM	13.818 6	4.784 6	1.148 8

表 4 Data 均方误差

重构算法	采样率/%		
	30	50	80
ADMM	3.140 1	1.275 5	0.303 1
FISTA	3.273 7	2.084 8	0.582 0
OMP	1.845 6	0.593 0	0.426 4
TV - ADMM	0.477 4	0.057 2	0.003 3

表 5 Data - n15% 重构误差

重构算法	采样率/%		
	30	50	80
ADMM	56.610 3	40.063 9	21.265 2
FISTA	89.685 6	69.824 1	37.081 1
OMP	77.989 1	55.202 3	35.971 8
TV - ADMM	14.148 1	7.828 5	3.924 3

重构误差和均方误差是用来衡量重构效果的两个常用指标。 x 为原始信号, $\hat{x}$ 为重构信号, 重构误差和均方误差的计算定义分别为(6)式和(7)式:

$$\text{重构误差} = \|x - \hat{x}\|_2 \quad (6)$$

表 6 data - n15% 均方误差

重构算法	采样率/%		
	30	50	80
ADMM	1.289 6	0.640 8	0.179 6
FISTA	3.470 6	2.200 2	0.668 6
OMP	2.465 8	1.223 7	0.514 9
TV - ADMM	0.503 0	0.153 2	0.034 4

$$\text{均方误差} = \frac{1}{N} \sum_{i=1}^n (x_i - \hat{x}_i)^2 \quad (7)$$

1.3 基于深度学习的结构损伤识别

1.3.1 建立数据集

通过有限元分析模拟获得张弦梁结构在不同损伤工况下的加速度响应信号。这些信号经过压缩感知技术处理, 得到压缩信号和通过 TV - ADMM 算法重构的信号。为模拟真实情况, 还在信号中加入了不同水平的噪声。因此, 涉及的数据集有: 原始数据集 Data、噪声集 Data_n15、噪声集 Data_n5 以及前两者经过不同采样率压缩感知处理后得到的数据集, 每个数据集的维度为 $8 \times 1\,000 \times 500 \times 8$, 其中, 从左到右的维度分别代表工况类目、每种工况的样本数量、时间步数以及传感器数目。为了分类, 每种工况都被赋予一个从 0 - 7 的数字标签。此外, 所有数据按照 7:2:1 的比例被划分为训练集、验证集和测试集。

1.3.2 建立深度学习损伤识别分类模型

输入一个样本(加速度响应信号), 经过分类模型会返回一个可能性最高的标签, 这个标签如果与这个样本自带的标签一致, 则说明该样本识别正确, 不同数据集都会执行该任务, 但是目的不同。训练集是用来训练模型的数据集, 目的是使模型能够识别训练数据的特征, 并从中学习到通用的规律, 以便在未见过的数据上做出准确的预测。验证集用于调整模型的超参数, 例如学习率、正则化参数等, 目的是评估模型在未见过的数据上的表现, 避免过拟合。测试集是用来评估模型性能的数据集, 可以作为结构损伤识别的真实预测。训练、验证、测试准确率是指在各自数据集上计算得到的模型预测正确的样本比例, 也就是损伤识别分类正确的样本数占总样本数比例。值得注意的是, 在输入信号进入模型之前, 需要读取样本为二维 NumPy 数组, 然后再利用 “torch.from_numpy()” 函数转换

为张量形式的数,只有张量才能被模型处理。

用于训练的显卡为 GeForce RTX 3060,在 Python 平台利用 PyTorch 深度学习框架搭建本研究的二维卷积神经网络模型,包括两个卷积层、两个标准化层、两个池化层、一个正则化层和两个全连接层。此模型采用交叉熵损失函数。为增强性能和稳定性,模型引入了 Adam 优化器和学习率调度器。Adam 优化器依据梯度的一阶和二阶矩自适应调整学习率。学习率调度器使用步骤衰减策略,每 10 个周期乘以 0.95,以加速初期收敛并在后期维持稳定。模型参数设置为:批次大小 64,迭代 100 次,初始学习率 0.001。


1.3.3 损伤识别效果

图 6 展示了模型在原始数据集、5% 噪声水平数据集和 15% 噪声水平数据集上的训练曲线。从这些曲线中,可以明显观察到,无论噪声水平如何,CNN 模型的训练准确率都能迅速迭代至 100%。

如图 7 和图 8 所示,展示了在不同数据集上经过压缩感知处理后数据的训练情况。从图中可以明显观察到,在各种噪声水平下,重构数据的训练准确率都能迅速迭代至接近 100%,这间接证明了重构的高准确性。然而,对于压缩数据集,即使经过 100 次迭代,训练准确率仍然不尽人意。其中,不加噪声的数据集的效果稍好于加噪声的数据集。推测这种现象的原因可能是样本量不足和模型深度不


够。为了解决这一问题,对 CNN 模型进行了进一步的优化。为扩大样本量,考虑将每个传感器的时间序列单独作为一个输入,这意味着原来的 $1 \times 500 \times 8$ 的输入样本可以转换为 $8 \times 500 \times 1$,从而将总样本数量从 8 000 个增加到 64 000 个。

与原始信号相比,压缩信号去除了部分冗余信息,但同时也可能丢失了对分类有益的信息。因此,简化的 CNN 模型可能难以从压缩数据中提取有效特征。为了增强模型的表达能力,在第一个池化层后加入了多头注意力机制层。图 9 展示了在 50% 采样率的压缩原始数据上,不同 CNN 模型变种的表现:包括基础的 CNN 模型、数据增强的 CNN 模型(CNN⁺)、仅加入多头注意力机制的 CNN 模型(MHA - CNN)以及结合多头注意力机制和数据增强的 CNN 模型(MHA - CNN⁺)。结果显示,CNN 模型的训练准确率和验证准确率均不超过 60%。相较于 CNN,CNN⁺的训练准确率变动不大,但其验证准确率却显著提升,超过 70%。尽管数据样本量已经满足要求,但模型的深度不足,即它缺乏足够的能力来提取和识别关键特征。在 MHA - CNN 模型中,虽然训练准确率达到 80%,但其验证准确率不足 30%,这明确地展现了过拟合的问题,这可能是由于样本数量不足导致的。然而,当使用 MHA - CNN⁺模型时,训练和验证准确率均迅速收敛到 100%,这证明了将两种改进方法结合使用可以有效地克服单一方法的局限性。



1—原始数据; 2—5% 噪声水平; 3—15% 噪声水平。

图 6 简单 CNN 分类模型在不同噪声水平下的训练情况



采样率/%: 1—30; 2—50; 3—80。

图 7 原始信号在不同压缩感知采样率下的训练情况




图 8 15%噪声水平信号在不同压缩感知采样率下训练情况




图 9 原始信号在压缩感知 50% 采样率下压缩信号的训练情况

如图 10 所示, MHA - CNN⁺ 模型在 15% 噪声水平数据集上, 在不同采样率下的训练曲线均表现出色。不论采样率高低, 模型都能有效地收敛。尤其在采样率为 30% 的数据集上, 模型也能迅速实现 100% 的准确率。另外, 训练曲线与验证曲线几乎重合, 证明模型既没有过拟合, 也未出现欠拟合。

在模型训练完成后, 使用测试集评估模型识别分类的性能。表 7 详细展示了在 CNN 模型上各个测试集的表现, 其中括号内的数字表示在 MHA - CNN⁺ 模型上的准确率。从表 7 中可以看出, 无论是原始数据、带噪声的数据还是重构数据, 简单的 CNN

模型均能有效完成损伤分类任务。然而, 对于压缩数据, 简单的 CNN 模型的表现并不理想。但当采用改进后的 MHA - CNN⁺ 模型时, 其分类任务的表现则显著提升。结果表明, 无论是在原始数据集还是经过噪声处理和压缩感知处理的数据集上, 模型都能以非常高的准确率完成损伤识别任务。

为了进一步验证 MHA - CNN⁺ 的优越性, 选取 CNN 中有代表性的残差神经网络 (ResNet) 作为对比, 同样用采样率为 50% 的压缩信号作为输入数据, 分别选取 ResNet50 和 ResNet152 作为训练模型, 图 11 可以看出网络深度远大于 MHA - CNN⁺ 的




图 10 15%噪声水平下不同压缩感知采样率的压缩信号在 MHA - CNN⁺ 上的训练情况

表 7 不同信号集在 CNN 和 MHA - CNN ⁺ 上的测试准确率								%
数据集	未采样	采样率/%						
		30		50		80		
		压缩数据	重构数据	压缩数据	重构数据	压缩数据	重构数据	
Data	100. 0	60. 5 (96. 0)	97. 5	55. 2 (98. 3)	100. 0	41. 4 (99. 1)	100. 0	
Data - n15	100. 0	38. 4 (96. 4)	96. 3	42. 1 (95. 9)	99. 2	48. 1 (99. 8)	99. 9	




图 11 50%采样率的压缩信号在不同 CNN 模型上的训练情况

ResNet50 和 ResNet152 在迭代收敛方面有优势,但仍存在过拟合现象。同时模型网络的深度也增加了模型训练的时间,在本文的硬件条件下,ResNet50 和 ResNet152 迭代 100 轮用时分别为 9201s 和 3 015 s,而 MHA - CNN⁺ 仅用时 903 s。

2 结 论

(1) 采用压缩感知理论,在远低于奈奎斯特采样定理要求的采样率下模拟采集了张弦梁结构模型的加速度响应信号。基于采集得到的压缩信号,精确地重构出原始信号。然后,使用基于 CNN 的损伤识别分类模型对压缩信号进行损伤识别,实验结果表明该方法效果显著。

(2) 文章提出了一种新颖的 TV - ADMM 重构优化算法,其性能在重构效果上显著超越了 ADMM、FISTA、OMP 等传统方法。

(3) 对于原始信号、加入噪声的信号及重构信号,构建的简单 CNN 模型已经能够出色地完成损伤识别分类任务。而针对压缩信号,本文进一步提出了 MHA - CNN⁺ 模型。该模型集成了数据增强技术和多头注意力机制,实验证明它能有效地处理压缩信号的损伤分类任务。

无论是本文提出的 TV - ADMM 重构优化算法还是 MHA - CNN⁺ 损伤识别分类模型,它们都展

现出对噪声的良好鲁棒性。但研究也存在着不足,只对一个张弦梁结构进行了研究,对于其他结构效果如何还有待进一步研究。

参考文献:

- [1] 胡邦邦,任宜春. 基于压缩信号处理的框架结构损伤识别[J]. 工程建设,2023,55(4):8-12.
- [2] ABDELIABER O,AVCI O,KIRABYAZ 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.
- [3] DANG H V,TRAN - NGOC H,NGUREN T V,et al. Data - driven structural health monitoring using feature fusion and hybrid deep learning [J]. IEEE Transactions on Automation Science and Engineering,2020,18(4):2087-2103.
- [4] 蒋友宝,陈奕琳,张梦华,等. 下弦与撑杆改进构型张弦梁结构抗连续倒塌动力试验研究[J]. 建筑结构学报,2023,44(4):178-187.
- [5] 朱奕锋. 张弦结构的抗连续倒塌研究[D]. 南京:东南大学,2013.
- [6] 蒋友宝,周浩,康维,等. 基于抗连续倒塌性能的张弦梁结构撑杆构型与数值验证[J]. 建筑结构学报,2021,42(增刊1):186-194.