

采用 BP 神经网络优化的振动信号压缩感知方法

朱一凯^{1,2}, 陈安妮^{1,2}, 余哲帆^{1,2}, 万华平^{1,2}

(1. 东南大学混凝土及预应力混凝土结构教育部重点实验室, 江苏 南京 211189;

2. 浙江大学建筑工程学院, 浙江 杭州 310058)

摘要: 无线传感网络逐渐应用于结构健康监测, 但是因能耗问题难以实现长期、高频的数据采集工作。压缩感知技术可利用少量的采样点重构原始信号, 有望降低无线传感网络的能耗。实测振动信号因受到噪声干扰而导致稀疏性有限, 常用于压缩感知的 LASSO 算法难以精确求解稀疏系数, 进而影响振动信号重构效果。引入 BP 神经网络优化 LASSO 算法解得的稀疏系数, BP 神经网络经 ADAM 优化算法训练后, 可有效提升振动信号重构精度。用三层框架结构的模拟加速度数据和广州塔的监测加速度数据验证方法的有效性, 并探讨了正则化参数和优化迭代次数的影响。结果表明, 基于 BP 神经网络优化的压缩感知方法的信号重构效果在不同压缩率下均优于非优化的压缩感知方法。

关键词: 结构健康监测; 压缩感知; BP 神经网络; 稀疏系数; LASSO 算法

中图分类号: TU312⁺.3; TN957.52 **文献标志码:** A **文章编号:** 1004-4523(2023)05-1234-10

DOI: 10.16385/j.cnki.issn.1004-4523.2023.05.006

引言

结构健康监测已成为土木工程结构损伤演化行为研究的有效手段和服役安全保障的重要技术。结构健康监测是利用传感技术实时监测结构响应和环境变量, 运用信号处理方法提取反映结构健康状态的特征量, 进而对结构的服役状况进行评估^[1]。新兴的无线传感网络技术具有成本低廉、安装维护方便、布点规模大、干扰性小等优点, 逐渐被应用于大型土木结构的健康监测^[2]。无线健康监测系统受传感器电池寿命、节点存储空间和传输带宽限制, 难以进行长期、高频的数据采集工作。因此, 寻求一种高效率的采样方法对于无线健康监测系统非常必要, 有望解决无线传感网络的能耗问题, 提升无线健康监测系统的工作寿命。

压缩感知 (Compressive Sensing, CS)^[3] 是一种新型采样理论, 其利用信号的稀疏特性, 通过少量的采样数据恢复出原始信号。CS 广泛运用于图像处理、雷达成像及核磁共振等领域^[4-5]。在结构健康监测领域, CS 也逐渐得到研究人员的关注。Bao 等^[6-7] 使用 CS 对山东滨州黄河大桥的健康监测数据进行分析, 指出原始信号自身的稀疏性是成功实现 CS 的关键因素, 而结构监测信号自身稀疏性往往有限。

Yao 等^[8] 基于模拟退火算法和蚁群算法, 探究了基于 CS 的传感器布置方法, 仿真和实测数据验证了该布置方法有效性。李惠等^[9] 将随机解调器植入传感器, 用于产生随机采样矩阵, 节省了传感器内存空间。Wan 等^[10] 基于时移策略构造特殊稀疏字典, 适用于风速信号压缩与重构, 并利用杭州东站屋面实测风速信号验证了该方法有效性。

对于实测信号, 噪声污染不可避免, 噪声污染会导致原始信号的稀疏性降低, 而信号稀疏性又是影响 CS 效果的重要因素。针对信号噪声问题, Deanna 等^[11] 提出了 CoSaMP 算法, 采用回溯策略来降低噪声干扰影响, 但该方法效果对原始信号 (无噪声污染) 的稀疏性要求较高。Ji 等^[12] 和 Huang 等^[13] 提出了多任务贝叶斯压缩感知方法, 通过纳入噪声先验信息来降低噪声干扰, 该方法依赖于信号相关性且计算较为复杂。康杰等^[14] 基于 Polar 插值的改进正交匹配追踪恢复算法, 能够重构稀疏性较低的信号, 但该方法主要适用于频率泄漏引起的低稀疏性情况。

本文针对受噪声干扰且稀疏性较低的信号, 提出利用反向传播 (Back Propagation, BP) 神经网络对 LASSO 算法得到的稀疏系数进行优化, 用于改善 CS 效果。BP 神经网络将预期样本和输出样本的误差进行反向传播, 通过反复迭代训练, 得到优化的稀

收稿日期: 2021-12-16; **修订日期:** 2022-04-23

基金项目: 国家重点研发计划资助项目 (2021YFF0501001); 浙江省重点研发计划资助项目 (2021C03154); 国家自然科学基金资助项目 (51878235); 混凝土及预应力混凝土结构教育部重点实验室开放课题 (CPCSME2020-05)。

疏系数。本文提出了基于BP神经网络优化的CS方法,可有效提升信号重构的精度,通过仿真数据和实测数据验证了该方法的有效性。

1 压缩感知基本理论

原始信号 $x \in \mathbb{R}^N$ 经过观测矩阵 $\Phi \in \mathbb{R}^{M \times N}$ 压缩观测,可以得到观测信号 $y \in \mathbb{R}^M$,如下:

$$y = \Phi x \quad (1)$$

式中 M 和 N 的取值满足 $M < N$ 。原始信号在变换基 $\Psi \in \mathbb{R}^{N \times N}$ 下为稀疏,表示为:

$$w = \Psi^{-1} x \quad (2)$$

式中 w 为稀疏表示的系数向量。由式(2)可得:

$$x = \Psi w \quad (3)$$

将式(3)代入式(1),令传感矩阵 $A = \Phi \Psi$,有:

$$y = \Phi \Psi w = A w \quad (4)$$

根据方程(4),压缩感知问题可描述为:已知观测信号 y 和传感矩阵 A ,在 w 具有稀疏性的先验条件下,求解 w 。式(4)的求解可以转化为求解下式表示的 l_0 范数问题:

$$\min \|w\|_0 \quad \text{s.t.} \quad y = \Phi \Psi w = A w \quad (5)$$

式中 $\|\cdot\|_0$ 为 l_0 伪范数,表示向量中非零值的个数。

Candès 等^[15]指出传感矩阵 A 满足有限等距性条件(Restricted Isometry Property, RIP)时:

$$(1 - \delta_s) \|w\|_2 \leq \|A w\|_2 \leq (1 + \delta_s) \|w\|_2 \quad (6)$$

式(4)可以解得唯一的稀疏解;当观测矩阵 Φ 为伯努利随机矩阵时,传感矩阵 A 通常可以满足 RIP 条件。且式(5)可以转变为求解下式的 l_1 范数最小化问题:

$$\min \|w\|_1 \quad \text{s.t.} \quad y = \Phi \Psi w = A w \quad (7)$$

式中 $\|\cdot\|_1$ 为 l_1 范数,表示向量各个分量的绝对值之和。

式(7)可使用 LASSO 算法通过最小化方差来求解:

$$w = \arg \min \|y - A w\|_2^2 + \alpha \|w\|_1 \quad (8)$$

式中 α 为正则化参数,用来控制 w 的稀疏度,避免 LASSO 算法出现过拟合的情况。

式(8)是连续的凸函数,可以通过迭代求解,解得稀疏系数 w 的估计值 \hat{w} ,通过式(3)计算得到信号的估计值 \hat{x} 。

若 x 为一加速度信号,在离散余弦基(DCT)上的表示具有“能量集中”的特性,稀疏性较好,通常 DCT 选为变换基 $\Psi \in \mathbb{R}^{N \times N}$ 。

考虑到实测的加速度信号往往含有噪声,式(3)中引入了噪声项 ϵ ,得到:

$$x = \Psi w + \epsilon \quad (9)$$

将噪声项 ϵ 在 DCT 上用系数向量 w_ϵ 表示,则式(9)转变为:

$$x = \Psi w + \Psi w_\epsilon = \Psi (w + w_\epsilon) \quad (10)$$

在信号传输过程中,传统方法传输完整原始信号 x ,未进行信号压缩。而 CS 传输方法是将原始信号 x 乘以观测矩阵 Φ 得到压缩信号 y ,然后将压缩信号进行传输,实现数据压缩传输效果;在接收传输数据后,再求解系数向量 $(w + w_\epsilon)$,并重构原始加速度信号 x 。但此时系数向量因受噪声干扰而稀疏性下降,利用 LASSO 算法得到的解为粗略稀疏系数。为了降低噪声的干扰影响和提升压缩感知效果,在粗略稀疏系数和精确稀疏系数之间建立一个映射,采用 BP 神经网络建立此映射。BP 神经网络具有极强的非线性映射能力,并适合处理大量复杂数据,具有得到接近精确稀疏系数的优化稀疏系数的潜力。

2 BP神经网络优化方法

2.1 BP神经网络原理

BP 神经网络如图 1 所示,通常由输入层、隐含层、输出层 3 个部分组成,每一层由若干神经元组成,层与层之间的神经元全数相连。神经元的输入是上一层神经元的输出,加权求和后加上阈值,代入激活函数,得到的输出传入下一层神经元。其对应的数学模型为:

$$a = f \left(\sum_{i=1}^n p_i w_i + b \right) \quad (11)$$

式中 p_i 为前一层中第 i 个神经元的输入; w_i 为对应的权值; n 为前一层神经元的个数; b 为该神经元的阈值; $f(\cdot)$ 表示激活函数。

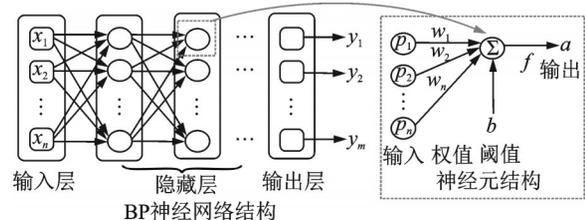


图1 BP神经网络及神经元结构

Fig. 1 BP neural network and neuron structure

构建神经网络是一个循环迭代过程,不断调整和更新神经元的权值和阈值,直到输出值和目标值之间的误差满足要求,达到满意的拟合效果^[16]。神经网络的输出值和目标值误差用均方误差定义,如下式所示:

$$\begin{cases} E_R(\theta) = \frac{1}{M \times N} \sum_{j=1}^K \|\xi_j' - \xi_j\|_2^2 \\ \theta = (\omega_1, \omega_2, \dots, \omega_n, b_1, b_2, \dots, b_m) \end{cases} \quad (12)$$

式中 $E_R(\theta)$ 为目标误差; ω_i 为第 i 个权值参数; b_i 为第 i 个阈值参数; K 为训练样本集中的样本个数; ξ_j 为第 j 个目标量; ξ_j' 为第 j 个输出量; N 为目标量的长度。

神经网络的优化问题转变成求 $E_R(\theta)$ 最小值的问题, 使用 ADAM 优化算法^[17] 求解。ADAM 通过计算梯度的一阶矩和二阶矩估计, 动态调整针对每个参数的学习率。其迭代式如下:

$$\begin{cases} \theta_i^{(k+1)} = \theta_i^{(k)} - g_i^{(k)} \\ g_i^{(k)} = \frac{\eta \hat{v}_i^{(k)}}{\sqrt{\hat{s}_i^{(k)} + \delta}} \end{cases} \quad (13)$$

式中 δ 为常数, 本文取 10^{-7} ; η 为初始学习率; $\theta_i^{(k)}$ 表示神经网络参数 θ 中第 i 个元素在第 k 次迭代中的取值; $g_i^{(k)}$ 表示第 k 次迭代时神经网络第 i 个参数应该沿梯度方向下降的距离; $v_i^{(k)}$ 和 $s_i^{(k)}$ 分别为第 i 个参数在第 k 次迭代时历史梯度平方的指数衰减平均和历史梯度的指数衰减平均; $\hat{v}_i^{(k)}$ 和 $\hat{s}_i^{(k)}$ 分别为 $v_i^{(k)}$ 和 $s_i^{(k)}$ 的修正偏差, 其计算公式如下:

$$\begin{cases} \hat{v}_i^{(k)} = \frac{v_i^{(k)}}{1 - \beta_1^k} \\ \hat{s}_i^{(k)} = \frac{s_i^{(k)}}{1 - \beta_2^k} \\ v_i^{(k+1)} = \beta_1 v_i^{(k)} + (1 - \beta_1) \frac{\partial E_R}{\partial \theta_i}(\theta^{(k)}) \\ s_i^{(k+1)} = \beta_2 s_i^{(k)} + (1 - \beta_2) \left[\frac{\partial E_R}{\partial \theta_i}(\theta^{(k)}) \right]^2 \end{cases} \quad (14)$$

式中 参数 $0 \leq \beta_1 < 1, 0 \leq \beta_2 < 1$, 分别取 0.9 和 0.999。

2.2 稀疏系数优化方法

本文方法结合了 LASSO 算法和 BP 神经网络, 前者用于寻找初始稀疏系数, 后者优化初始稀疏系数。LASSO 算法的目标是寻找稀疏系数中所有非零元素, 但由于噪声干扰, 能够较为准确地识别出稀疏系数中数值较大的非零元素。对于数值较小的非零元素, LASSO 算法求解精度较低, 但数值较小的非零元素和数值较大的元素具有一定的相关性。LASSO 算法求解出初始稀疏系数和精确稀疏系数, 其中较为精确的数值较大的非零元素与数值较小的元素具有一定的相关性。由于噪声的随机性较强, 难以高效精确描述数值大元素与数值小元素间的相关性, 为此根据初始稀疏系数来求解精确稀疏系数。

而 BP 神经网络具有极强的非线性映射能力, 能够通过训练寻找初始稀疏系数和精确稀疏系数之间的非线性拟合关系, 对初始稀疏系数优化, 使其更加接近精确稀疏系数, 达到优化重构精度的效果。

首先, 利用 LASSO 算法能求解得到粗略稀疏系数 \hat{w} , 完成寻找稀疏系数的目标。再将用 LASSO 方法求得的粗略稀疏系数 \hat{w} 作为 BP 神经网络的输入, 利用 BP 神经网络得到优化稀疏系数 \hat{w}' , 使其更加接近式(2)中精确稀疏系数 w 。

为了避免神经网络泛化能力受稀疏系数幅值大小影响, 对稀疏系数进行线性归一化。对粗略稀疏系数及其对应稀疏系数归一化方法如下所示:

$$\begin{cases} \bar{w} = (\hat{w} - \hat{w}_{\min}) / (\hat{w}_{\max} - \hat{w}_{\min}) \\ \bar{w} = (w - \hat{w}_{\min}) / (\hat{w}_{\max} - \hat{w}_{\min}) \end{cases} \quad (15)$$

式中 \bar{w} , \bar{w} 分别为归一化后的粗略稀疏系数及其对应稀疏系数; \hat{w}_{\max} , \hat{w}_{\min} 分别为粗略稀疏系数的最大值和最小值。

需对神经网络进行训练, 预采集一段完整信号, 分为 K 段长度为 N 的信号。根据式(2)和(15)计算得到归一化后的精确稀疏系数样本集 \bar{w}_j , 为了消除稀疏系数幅值大小影响, 对其进行线性归一化后再作为神经网络的目标输出; 使用 LASSO 算法得到粗略稀疏系数样本集 $\bar{\hat{w}}_j$, 作为神经网络的输入, 得到神经网络的实际输出为归一化的优化稀疏系数 $\bar{\hat{w}}'$ 。利用 ADAM 优化算法得到模型参数, 建立 BP 神经网络。BP 神经网络训练完成后, 采用新的压缩数据用来测试, 对比粗略稀疏系数和优化稀疏系数的重构效果, 以检验该方法有效性。优化稀疏系数的计算流程如图 2 所示。

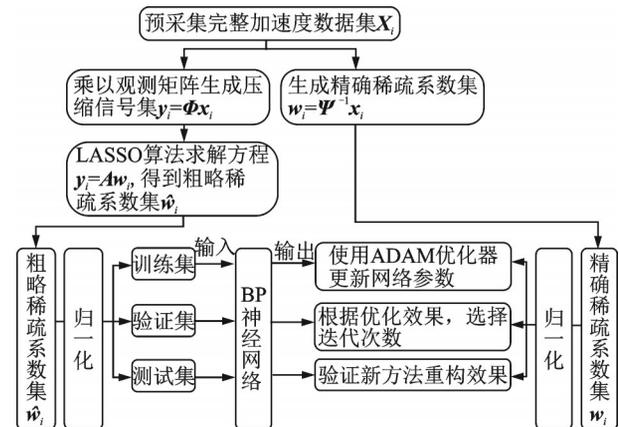


图 2 稀疏系数优化的计算流程

Fig. 2 Calculation process of sparse coefficient optimization

3 仿真数据验证

用三层框架结构(如图 3 所示)验证本文方法的

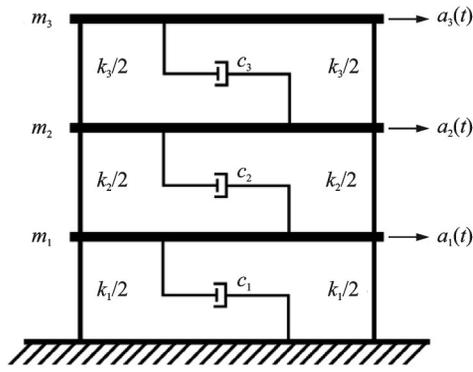


图 3 三层框架结构模型

Fig. 3 Structural model of three story frame

有效性。每层楼板的质量表示为 $m_i (i = 1, 2, 3)$, 每层楼的刚度系数为 k_i , 阻尼系数为 c_i 。每层楼板的质量、刚度系数、阻尼系数分别为 10 kg, 1000 kg/m 和 10 N·s/m。则该三层框架结构的质量矩阵 M 、刚度矩阵 K 和阻尼矩阵 C 分别为:

$$M = \begin{bmatrix} 10 & 0 & 0 \\ 0 & 10 & 0 \\ 0 & 0 & 10 \end{bmatrix}, K = \begin{bmatrix} 2 & -1 & 0 \\ -1 & 2 & -1 \\ 0 & -1 & 2 \end{bmatrix} \times 10^3,$$

$$C = \begin{bmatrix} 20 & -10 & 0 \\ -10 & 20 & -10 \\ 0 & -10 & 20 \end{bmatrix} \quad (16)$$

假设在每层楼板均装有加速度传感器,且传感器的采样频率设为 50 Hz,采样持续时间为 300 s。为了模拟结构振动响应,每层施加高斯噪声激励 $N(0, 0.01)$;同时考虑测试噪声影响,计算得到的振动响应加入高斯噪声 $N(0, 0.001)$ 。仿真模拟采用的电脑计算平台是:Windows10 操作系统/Intel Core i7-9750H CPU/16G RAM,及数值软件是:Python 3.9+numpy 1.21.1+scipy 1.7.1。得到的楼板加速度信号如图 4 所示。

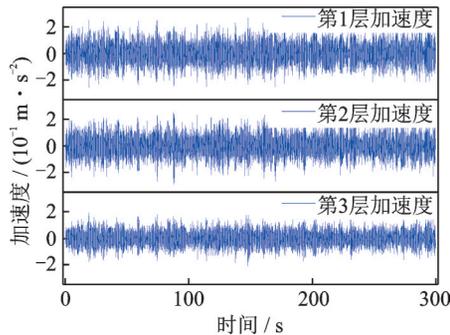


图 4 各层加速度信号采样值

Fig. 4 Sampling value of acceleration signal of each layer

定义采样率 $R = N/M$, 单次运算截取出长度 $N = 200$ 的一维时间序列进行运算,对 $R = 150\%, 175\%, 200\%$ 三种不同压缩率的情况进行讨论。在利用神经网络对粗略稀疏系数进行优化之

前,需选取合适的 LASSO 算法的正则化参数 α , 得到精度较好的稀疏系数,利于后续 BP 神经网络对稀疏系数进行优化。

$$\text{采用均方误差 } MSE = \frac{1}{K \times N} \sum_{j=1}^K \|\hat{x}_j - x_j\|$$

指标来评价重构信号的精度,其中 K 表示信号的段数。 α 依次取 $10^0, 10^{-1}, 10^{-2}, \dots, 10^{-10}$, 选用前 1000 个数据来进行压缩感知和重构,计算结果如图 5 所示。可知,当 $\alpha = 10^{-5}$ 时, LASSO 算法能够得到较高精度的粗略稀疏系数。

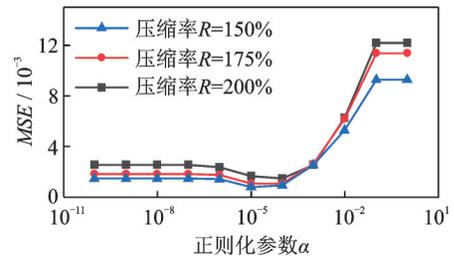


图 5 不同压缩率情况下的均方误差与正则化参数的关系 (框架结构模型)

Fig. 5 Relationship between MSE and regularization parameters under different compression rates (frame structure model)

前 10199 个采样点通过步长为 1、长度为 200 的滑动窗构成 10000 个 $N = 200$ 的信号样本,生成 10000 个精确稀疏系数样本和粗略稀疏系数样本。将得到的精确稀疏系数样本和粗略稀疏系数样本划分为 10 组,每组有 1000 个粗略稀疏系数样本及其对应的精确稀疏系数样本。前 9 组数据用作训练集对神经网络进行训练,第 10 组数据作为验证集,判断出合适的迭代次数。根据式(12)定义本文方法的目标误差 $E_R = \frac{1}{K \times N} \sum_{j=1}^K \|\bar{w}_j' - \bar{w}_j\|_2^2$,用于评价训练后的神经网络拟合精度。神经网络设置 1 层隐藏层,输入、输出信号长度均为 200,避免神经网络内部传递信息出现丢失或者冗余,将其神经元数量设置为 200;初始学习率 η 设置为 10^{-4} 。图 6 展示了 150%,

$$E_R = \frac{1}{K \times N} \sum_{j=1}^K \|\bar{w}_j' - \bar{w}_j\|_2^2$$

神经网络拟合精度。神经网络设置 1 层隐藏层,输入、输出信号长度均为 200,避免神经网络内部传递信息出现丢失或者冗余,将其神经元数量设置为 200;初始学习率 η 设置为 10^{-4} 。图 6 展示了 150%,

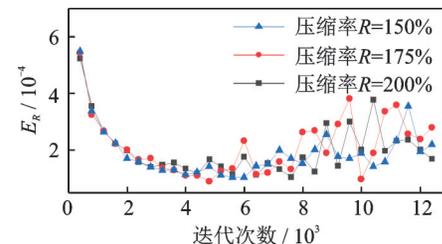


图 6 不同压缩率情况下的目标误差与迭代次数的关系 (框架结构模型)

Fig. 6 Relationship between target error and iteration times under different compression rates (frame structure model)

175%, 200% 三种压缩率下在不同迭代次数下的目标误差 E_R 。

由图6可知,当迭代次数为4400时,目标误差 E_R 达到较小值,随着迭代次数继续增加,目标误差 E_R 逐渐增大,因此迭代次数为4400时的BP神经网络的效果最佳。选择长度为5000时的加速度信号作为测试集,将其分为25段,每段 $N=200$ 。对于测试集,利用上述方法得到粗略稀疏系数和优化稀疏系数,基于两种稀疏系数来重构信号,并计算各自的均方误差 MSE ,对比结果如图7所示。从图7中可以看出,本文方法得到的重构信号与原始信号的误差相对更小。

为更加直观展示重构效果,将重构出的时域信号和频域信号及其误差展示在图8和9中。从图8

和9中可以看出,对于第1层楼板的加速度信号,优化稀疏系数重构出的信号与原始信号之间的偏差在时域和频域都更小。

为了更全面展示本文重构方法的性能,将第1层优化重构信号与贝叶斯算法和CoSaMP算法重构信号进行对比。采用误差指标 MSE 衡量重构误差,并引入频率重心指标 $CF = \sum f_i y_i / \sum y_i$ 和均方频率 $MSF = \sum f_i^2 y_i / \sum y_i$, 表征重构信号的频率特征,其中, f_i 表示频谱中第 i 个频率; y_i 表示第 i 个频率对应的幅值。不同算法的指标对比结果如表1所示。相较于其他重构算法,使用BP神经网络优化的重构信号误差明显更小,并且重构信号的频率特征更加接近原始信号。

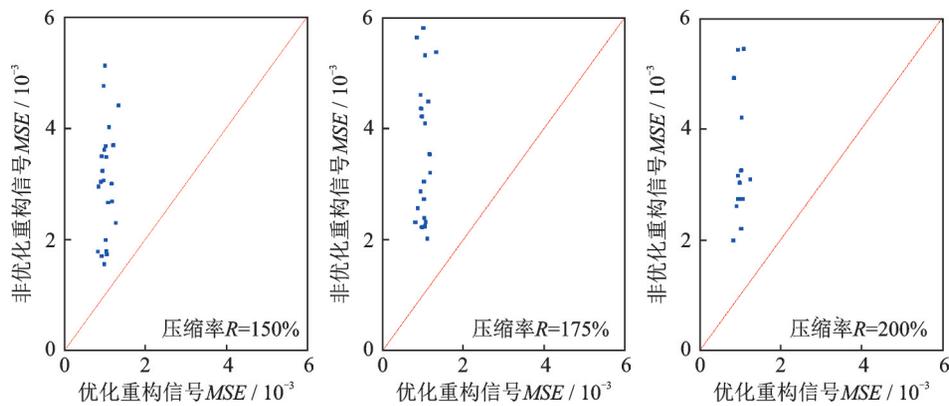


图7 重构信号优化前后的误差对比(框架结构模型)

Fig. 7 Error comparison before and after optimization of reconstructed signal (frame structure model)

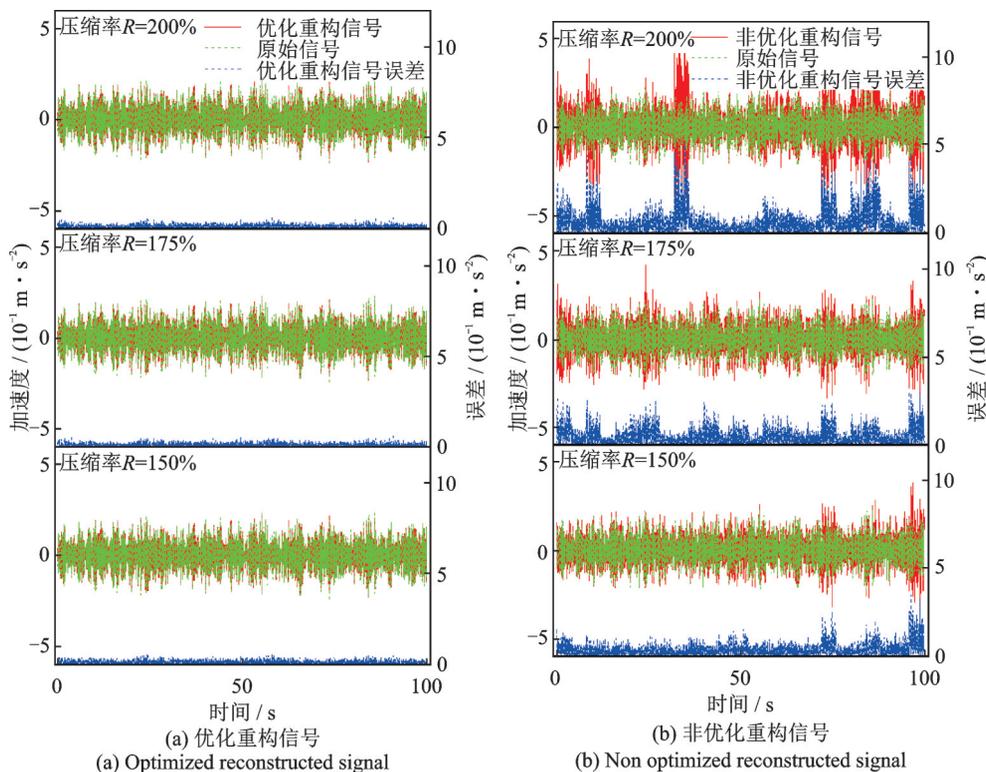


图8 重构加速度信号在时域内对比结果(第1层传感器)

Fig. 8 Comparison results of reconstructed acceleration signal in time domain (layer 1 sensor)

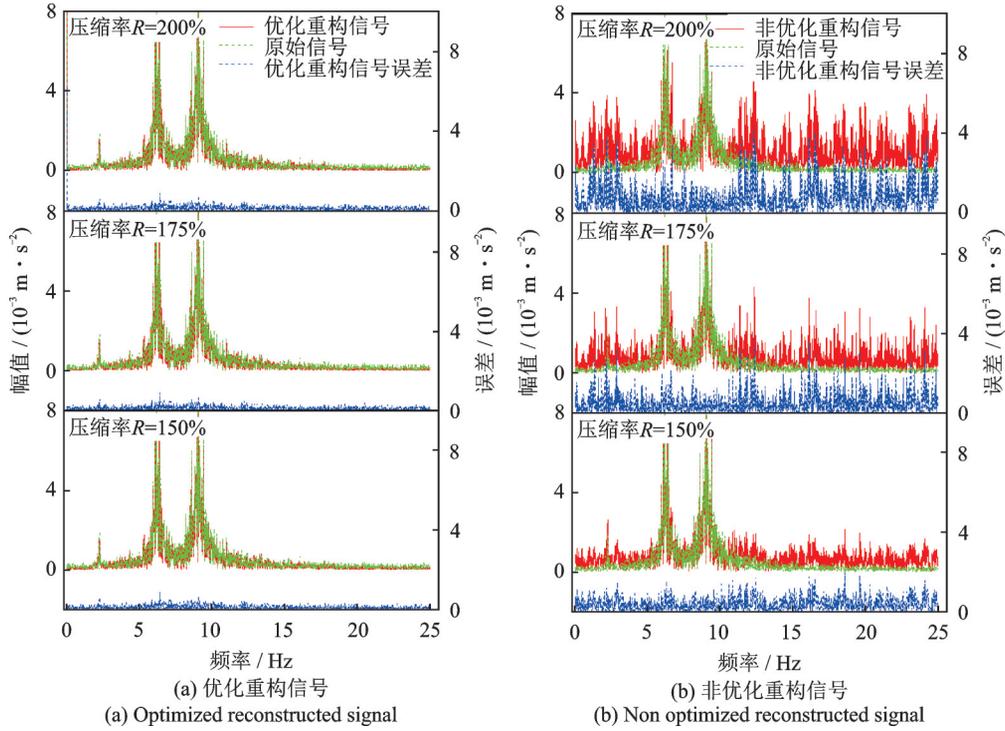


图 9 重构加速度信号在频域内对比结果(第 1 层传感器)

Fig. 9 Comparison results of reconstructed acceleration signal in frequency domain(layer 1 sensor)

表 1 不同算法重构信号的误差和频率特征对比(第 1 层传感器)

Tab. 1 Comparison of error and frequency characteristics of reconstructed signals with different algorithms (layer 1 sensor)

信号类型	压缩率 R=150%			压缩率 R=175%			压缩率 R=200%		
	MSE/ 10 ⁻⁴	CF/ Hz	MSF/ Hz ²	MSE/ 10 ⁻⁴	CF/ Hz	MSF/ Hz ²	MSE/ 10 ⁻⁴	CF/ Hz	MSF/ Hz ²
原始信号	0	9.4	111.3	0	9.4	111.3	0	9.4	111.3
优化重构信号	2.89	9.0 (-0.4%)	97.5 (-12.4%)	2.91	8.9 (-0.4%)	96.2 (-13.5%)	2.87	9.0 (-0.4%)	98.7 (-11.3%)
贝叶斯算法重构信号	6.77	10.5 (0.9%)	145.9 (31.1%)	7.95	10.6 (1.1%)	152.2 (36.8%)	9.32	10.9 (1.3%)	160.7 (44.4%)
CoSaMP算法重构信号	10.8	11.5 (1.9%)	178.7 (60.6%)	11.7	11.6 (1.9%)	179.9 (61.7%)	12.4	11.6 (1.9%)	180.3 (62.1%)

注:括号中的数值表示频率特征指标与原始信号的相对误差。

为了更全面展示方法的可行性,对所有楼板的加速度数据进行分析。在三种不同压缩率的情况下,优化前后的加速度信号重构误差对比结果如图 10 所示。使用 BP 神经网络优化后,加速度信号的重构误差降低明显,表明本文方法用于仿真加速度信号重构精度高。

4 实测数据验证

用广州塔的实测加速度信号进一步验证本文方法的有效性。广州塔位于中国广东省广州市海珠区,总高度 600 m,其中天线桅杆高 146 m,塔身主体高 454 m。广州塔的塔身主体布置了 20 个加速度传

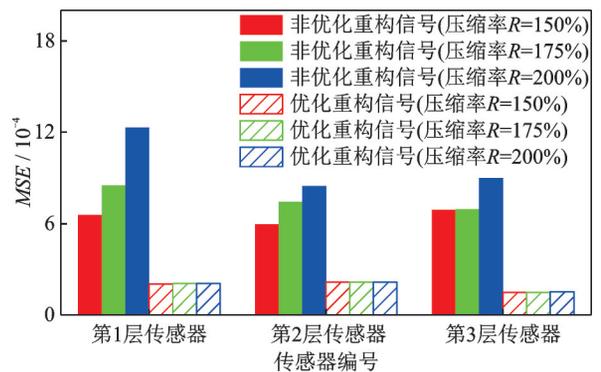


图 10 不同测点优化前后重构信号的误差对比(第 1~3 层传感器)

Fig. 10 Error comparison of reconstructed signals before and after optimization of different measuring points (sensors of layer 1~3)

感器(如图11所示),采样频率为50 Hz。关于广州结构健康监测系统的更详细介绍,请参考文献[18]和网站:<http://www.zn903.com/ceyxia/benchmark/index.htm>。

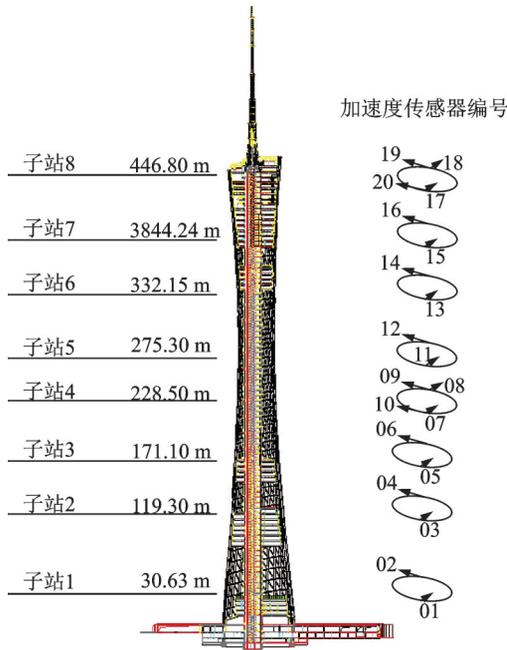


图11 广州塔加速度传感器测点布置

Fig. 11 Measuring point layout of acceleration sensor of Canton tower

用广州塔底部编号01传感器的加速度信号进行深入分析,同样考虑 $R = 150\%$, 175% , 200% 三种压缩率情况。根据上节提到的方法构建训练集、验证集和测试集。图12展示了正则化参数 α 和均方误差 MSE 的关系,由12图可知,当 α 取 10^{-5} 时,粗略稀疏系数重构出的信号与原始信号误差最小。图13展示了不同压缩率下和不同迭代次数与目标

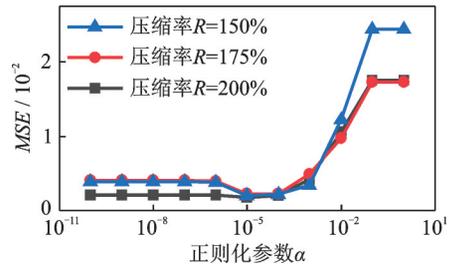


图12 不同压缩率情况下的均方误差与正则化参数的关系(广州塔)

Fig. 12 Relationship between MSE and regularization parameters under different compression rates (Canton tower)

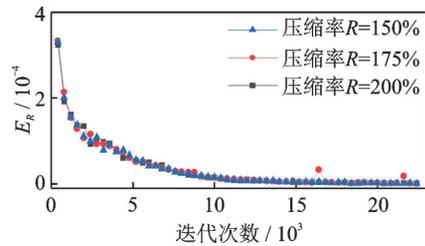


图13 不同压缩率情况下的目标误差与迭代次数的关系(广州塔)

Fig. 13 Relationship between target error and iteration times under different compression rates (Canton tower)

误差 E_r 的关系。由图13可知,当迭代次数取20000时,目标误差 E_r 达到较小值且不再明显减小,因此迭代次数为20000时的BP神经网络达到训练效果。

同样地,选择长度为5000的测试集,参照上一节的方法求得粗略稀疏系数和优化稀疏系数信号。基于两种稀疏系数重构出加速度信号,计算得到各自的均方误差 MSE ,结果如图14所示。图14表明,优化后得到的重构信号的误差更小。

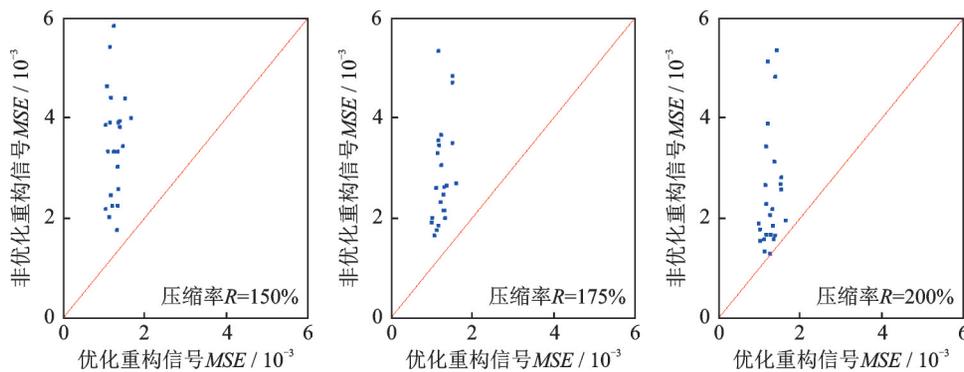


图14 重构信号优化前后的误差对比(广州塔)

Fig. 14 Error comparison before and after optimization of reconstructed signal(Canton tower)

为更直观展示重构效果,重构加速度信号在时域和频域的对比结果如图15和16所示。由图15和16可得,优化后的重构加速度信号与原始加速度信号之间的偏差在时域和频域均更小。

为了更全面展示本文重构方法的性能,不同算法重构信号的指标对比结果如表2所示。在三种不同压缩率的情况下,相较于其他重构算法,使用BP神经网络优化的重构信号误差明显更小,并且重构

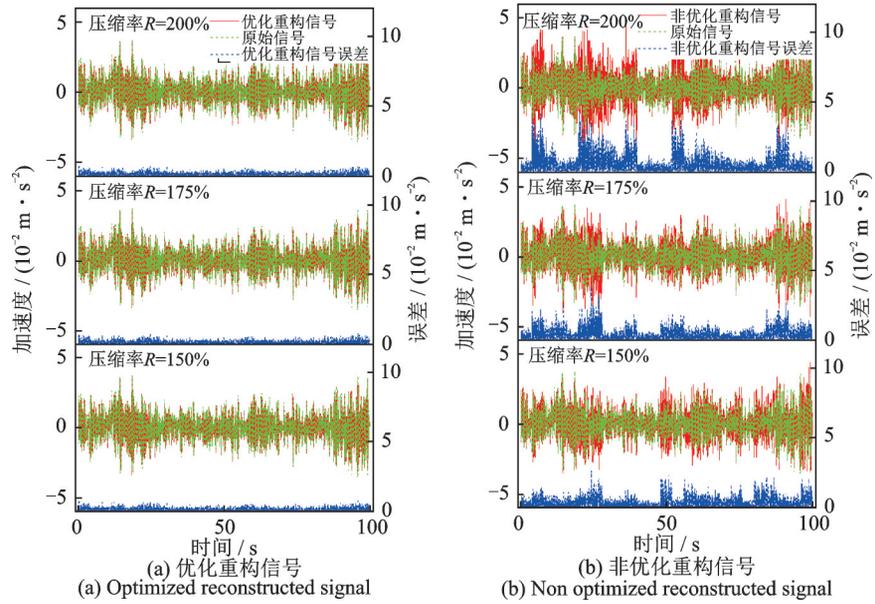


图 15 重构加速度信号在时域内对比结果(传感器编号 01)

Fig. 15 Comparison results of reconstructed acceleration signal in time domain (sensor No. 01)

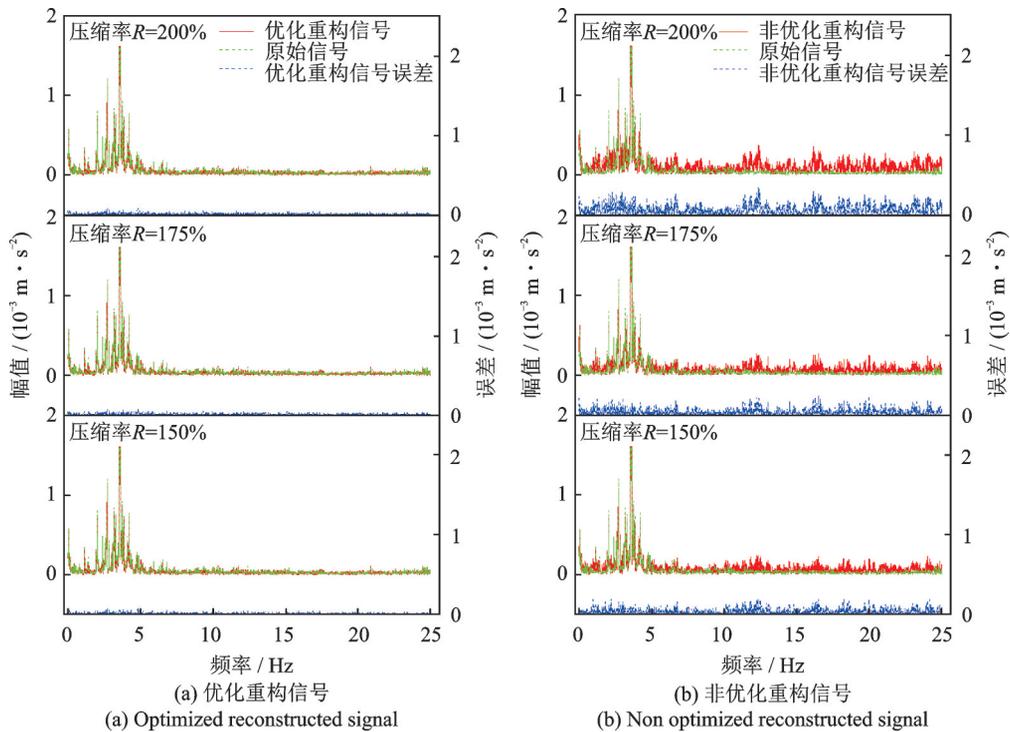


图 16 重构加速度信号在频域内对比结果(传感器编号 01)

Fig. 16 Comparison result of reconstructed acceleration signal in frequency domain (sensor No. 01)

表 2 不同算法重构信号的误差和频率特征对比(传感器编号 01)

Tab. 2 Comparison of error and frequency characteristics of reconstructed signals with different algorithms (sensor No. 01)

信号类型	压缩率 R=150%			压缩率 R=175%			压缩率 R=200%		
	MSE/10 ⁻⁴	CF/Hz	MSF/Hz ²	MSE/10 ⁻⁴	CF/Hz	MSF/Hz ²	MSE/10 ⁻⁴	CF/Hz	MSF/Hz ²
原始信号	0	7.7	104.5	0	7.7	104.5	0	7.7	104.5
优化重构信号	3.59	7.6 (-0.1%)	103.1 (-1.3%)	3.59	7.6 (-0.1%)	103.1 (-1.3%)	3.60	7.6 (-0.1%)	103.2 (-1.3%)
贝叶斯算法重构信号	7.60	9.2 (1.4%)	137.2 (31.4%)	9.29	9.6 (1.8%)	146.0 (39.8%)	10.3	9.6 (1.8%)	145.8 (39.5%)
CoSaMP算法重构信号	13.9	11.0 (3.2%)	176.6 (69.1%)	14.9	11.1 (3.3%)	179.0 (71.4%)	16.9	11.3 (3.4%)	183.3 (75.5%)

注:括号中的数值表示频率特征指标与原始信号的相对误差。

信号的频率特征更加接近原始信号。

为了更全面展示方法的可行性,用所有传感器的加速度数据进行分析,这里只展示重构信号误差的对比结果。在三种不同压缩率的情况下,优化前

后的加速度信号重构误差对比结果如图17所示。使用BP神经网络优化后,加速度信号的重构误差降低明显,表明本文方法用于加速度信号重构精度高。

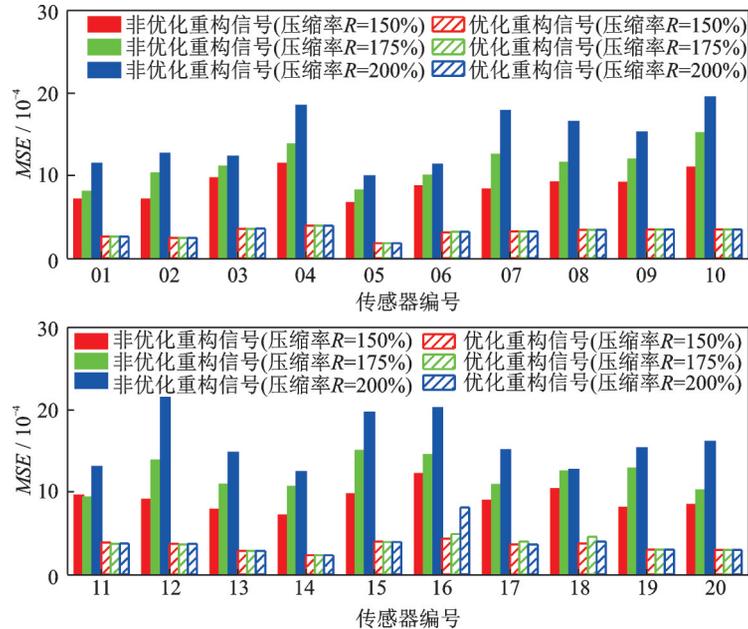


图17 不同测点优化前后重构信号的误差对比(传感器编号01~20)

Fig. 17 Error comparison of reconstructed signals before and after optimization of different measuring points (Sensor No. 01 ~ 20)

5 结论

噪声会导致振动信号的稀疏性下降,进而影响LASSO算法用于信号重构的效果。本文提出了基于BP神经网络优化的压缩感知方法,利用BP神经网络对LASSO算法得到的稀疏系数进行优化,提升振动信号的重构精度。用三层框架结构和广州塔验证本文方法的有效性,得到的结论如下:(1)LASSO算法的正则化参数和BP神经网络的迭代次数是本文方法的两个关键参数,选择合适的正则化参数可以获得较高精度的稀疏系数,选取合适的迭代次数可提升BP神经网络的优化效果。(2)相比非优化的重构信号,基于BP神经网络优化的重构信号与原始信号之间的偏差在时域和频域均更小,表明引入的BP神经网络优化策略可有效提升压缩感知方法的性能。

参考文献:

[1] 李宏男, 高东伟, 伊廷华. 土木工程结构健康监测系统的研究状况与进展[J]. 力学进展, 2008, 38(2): 151-166.
Li Hongnan, Gao Dongwei, Yi Tinghua. Advances in structural health monitoring systems in civil engineering [J]. Advance in Mechanics, 2008, 38(2): 151-166.

[2] 欧进萍. 重大工程结构智能传感网络与健康监测系统的研究与应用[J]. 中国科学基金, 2005(1):8-12.
Ou Jinping. Research and practice of smart sensor networks and health monitoring systems for civil infrastructures in China's mainland [J]. Bulletin of National Science Foundation of China, 2005(1):8-12.

[3] David L D. Compressed sensing [J]. IEEE Transactions on Information Theory, 2006, 52(4): 1289-1306.

[4] 潘榕, 刘昱, 侯正信, 等. 基于局部DCT系数的图像压缩感知编码与重构[J]. 自动化学报, 2011, 37(6): 674-681.
PAN Rong, LIU Yu, HOU Zhengxin, et al. Image coding and reconstruction via compressed sensing based on partial DCT coefficients [J]. Acta Automatica Sinica, 2011, 37(6): 674-681.

[5] 余慧敏, 方广有. 压缩感知理论在探地雷达三维成像中的应用[J]. 电子与信息学报, 2010, 32(1): 12-16.
Yu Huimin, Fang Guangyou. Research on compressive sensing based 3D imaging method applied to ground penetrating radar [J]. Journal of Electronics and Information Technology, 2010, 32(1): 12-16.

[6] Bao Y Q, Beck J L, Li H. Compressive sampling for accelerometer signals in structural health monitoring [J]. Structural Health Monitoring, 2011, 10(3): 235-246.

[7] Bao Y Q, Yu Y, Li H, et al. Compressive sensing-based lost data recovery of fast-moving wireless sensing for structural health monitoring [J]. Structural Control and Health Monitoring, 2015, 22(3): 433-448.

- [8] Yao R G, Shamim N P, Parvathinathan V. Compressive sensing based structural damage detection and localization using theoretical and metaheuristic statistics[J]. *Structural Control and Health Monitoring*, 2017, 24(4): e1881.
- [9] 李惠, 鲍跃全, 李顺龙, 等. 结构健康监测数据科学与工程[J]. *工程力学*, 2015, 32(8): 1-7.
Li Hui, Bao Yuequan, Li Shunlong, et al. Data science and engineering for structural health monitoring[J]. *Engineering Mechanics*, 2015, 32(8): 1-7.
- [10] Wan H P, Dong G S, Luo Y. Compressive sensing of wind speed data of large-scale spatial structures with dedicated dictionary using time-shift strategy[J]. *Mechanical Systems and Signal Processing*, 2021, 157: 107685.
- [11] Deanna N, Joel A T. CoSaMP: iterative signal recovery from incomplete and inaccurate samples[J]. *Applied and Computational Harmonic Analysis*, 2008, 26(3): 301-321.
- [12] Ji S H, Xue Y, Lawrence C. Bayesian compressive sensing [J]. *IEEE Transactions on Signal Processing*, 2008, 56(6): 2346-2356.
- [13] Huang Y, James L B, Li H. Multitask sparse Bayesian learning with applications in structural health monitoring [J]. *Computer-Aided Civil and Infrastructure Engineering*, 2019, 34(9): 732-754.
- [14] 康杰, 段忠东. 基于Polar插值改进的结构振动信号压缩采样正交匹配追踪恢复算法[J]. *振动工程学报*, 2020, 33(3): 450-458.
KANG Jie, DUAN Zhongdong. An improved OMP algorithm with Polar interpolation for structural vibration signals recovery by compressed measurements[J]. *Journal of Vibration Engineering*, 2020, 33(3): 450-458.
- [15] Candes E J, Tao T. Decoding by linear programming [J]. *IEEE Transactions on Information Theory*, 2005, 51(12): 4203-4215.
- [16] 杨杰, 李爱群, 缪长青. 面向结构健康监测的神经网络性能分析与设计[J]. *工程力学*, 2008, 25(7): 74-78.
Yang Jie, Li Aiqun, Miao Changqing. Analysis and design of SHM-oriented neural networks[J]. *Engineering Mechanics*, 2008, 25(7): 74-78.
- [17] Kingma D P, Ba J. Adam: a method for stochastic optimization[C]. *Proceedings of the 3rd International Conference on Learning Representations (ICLR)*, 2015.
- [18] Ni Y Q, Xia Y, Liao W Y, et al. Technology Innovation in developing the structural health monitoring system for Guangzhou new TV tower[J]. *Structural Control and Health Monitoring*, 2009, 16(1): 73-98.

An approach for compressive sensing of vibration signal using BP neural network optimization

ZHU Yi-kai^{1,2}, CHEN An-ni^{1,2}, YU Zhe-fan^{1,2}, WAN Hua-ping^{1,2}

(1.Key Laboratory of Concrete and Pre-stressed Concrete Structures of Ministry of Education, Southeast University, Nanjing 211189, China; 2.College of Civil Engineering and Architecture, Zhejiang University, Hangzhou 310058, China)

Abstract: Wireless sensor networks (WSNs) are gradually applied to structural health monitoring. Due to the involved energy consumption issue, it is difficult for WSNs to achieve long-term and high-frequency data acquisition. Compressive sensing (CS) is able to use a small number of sampling points to reconstruct the original signal, which is expected to reduce the energy consumption of the WSNs. The sparsity of the measured vibration signal is limited due to the noise contamination. This causes the failure of the LASSO, a widely-used CS algorithm, in seeking the accurate sparse coefficient, which hinders the reconstruction performance of CS of the vibration signal. This paper proposes a method to optimize the sparse coefficient to effectively improve the accuracy of reconstructed vibration signal by using BP neural network. The simulated acceleration data of a three-floor frame and the monitored acceleration data of Canton Tower are both used to verify the effectiveness of the proposed CS method. The effects of regularization parameters and the number of optimization iterations are explored in detail. The result shows that the proposed optimized CS method performs better than the non-optimized one under different compressed ratios.

Key words: structural health monitoring; compressive sensing; BP neural network; sparse coefficient; LASSO algorithm

作者简介: 朱一凯(2001—),男,博士研究生。E-mail: 3190101978@zju.edu.cn。

通讯作者: 万华平(1986—),男,博士,研究员,博士生导师。E-mail: hpwan@zju.edu.cn。