

DOI: 10.11883/bzycj-2025-0152

# 基于变分模态分解处理的冲击波压力 长短期记忆网络系统建模\*

罗瑶嘉, 张志杰

(中北大学仪器科学与动态测试教育部重点实验室, 山西 太原 030051)

**摘要:** 冲击波压力传感器采集系统兼具高低频动态特性, 而传统的基于传递函数的建模方法难以实现整体精准建模, 这一问题限制了系统补偿精度的提升。本文提出一种基于麻雀优化算法、变分模态分解和长短期记忆网络的动态特性融合建模方法, 旨在解决整体建模难题并提高系统动态特性建模精度。该方法通过优化算法搜索变分模态分解的模态数和惩罚因子, 自适应分解响应信号为多个模态分量并识别成分, 实现高频与低频分量的有效分离; 对低频分量进行动态特性补偿后, 将其作为压力信号和原响应信号构建模型输入输出数据集, 通过网络完成传感器系统动态特性建模。仿真与实爆试验结果表明, 相较于传统的反滤波补偿方法, 本方法补偿后信号与典型压力曲线的平均绝对百分比误差降低 75%, 振荡残余减小 38%, 满足作为输入压力信号的精度要求; 与单一神经网络建模相比, 该融合建模方法的误差降至 13%, 为解决传感器宽频带动态建模难题提供了一条有效途径。

**关键词:** 冲击波压力; 动态补偿; 变分模态分解; 长短期记忆

中图分类号: O384

国标学科代码: 13035

文献标志码: A

## Shock wave pressure modeling using long short-term memory network based on variational mode decomposition processing

LUO Yaojia, ZHANG Zhijie

(Key Laboratory of Instrumentation Science and Dynamic Measurement, Ministry of Education,  
North University of China, Taiyuan 030051, Shanxi, China)

**Abstract:** Shock wave pressure sensor acquisition systems exhibit both high- and low-frequency dynamic characteristics; however, traditional transfer-function-based modeling and compensation methods cannot achieve accurate full-band representation, thereby limiting further improvements in compensation accuracy and reconstructed signal fidelity under complex dynamic conditions. To overcome this limitation, a fusion modeling method integrating the sparrow search algorithm (SSA), variational mode decomposition (VMD), and a long short-term memory (LSTM) network was developed to enhance the dynamic characteristic modeling accuracy of shock wave pressure acquisition systems. In this method, SSA was employed to globally optimize the mode number and penalty factor of VMD using a comprehensive fitness function that combined sample entropy and the Pearson correlation coefficient, thereby improving the adaptability of the decomposition to nonstationary response signals contaminated by oscillations and noise. With the optimized parameters, VMD decomposed the sensor response signal into multiple intrinsic modal components; the frequency-domain characteristics of each component were then analyzed, and correlation coefficients together with jump durations were calculated and compared according to the spectral distribution characteristics of shock waves to identify the signal types contained in each mode. Based on this identification, high-frequency oscillatory modes and noise modes were discarded, enabling reconstruction of the effective shock wave signal.

\* 收稿日期: 2025-05-26; 修回日期: 2026-01-07

第一作者: 罗瑶嘉 (2001—), 女, 硕士研究生, 13554081002@163.com

通信作者: 张志杰 (1965—), 男, 博士, 教授, 博士生导师, zhangzhijie@nuc.edu.cn

A sinusoidal signal generator was used to obtain pressure acquisition waveforms in the range of 0.1–10 Hz; the amplitudes were converted into decibels to form the low-frequency magnitude-frequency characteristic curve, and a frequency-domain rational function fitting procedure was applied to establish the low-frequency transfer function. Using this transfer function, low-frequency dynamic compensation was performed on the reconstructed signal, and the compensated low-frequency signal was combined with the original sensor response to construct an input-output dataset that simultaneously preserved the compensated dynamic information and the original response characteristics. On the basis of this dataset, SSA was further used to optimize key LSTM hyperparameters, including the number of hidden units, the maximum number of training epochs, and the initial learning rate, and an LSTM network was trained to model the nonlinear, time-dependent, and memory-dependent behavior of the acquisition system, thereby achieving fusion modeling of high- and low-frequency dynamic characteristics within a unified framework. Simulation analyses and live explosion tests demonstrated that, compared with the traditional inverse-filtering compensation method, the proposed approach reduced the mean absolute percentage error (MAPE) between the compensated signal and the reference pressure curve by approximately 75% and decreased oscillation residuals by about 38%, satisfying the accuracy requirements for input pressure signals; compared with a single LSTM-based modeling approach, the VMD-LSTM fusion model reduced the overall modeling error to 13%, indicating improved accuracy and robustness. These results indicate that the SSA-optimized VMD decomposition, transfer-function-based low-frequency compensation, and SSA-tuned LSTM fusion modeling together provide an effective full-band modeling strategy, and that the proposed framework offers a robust solution for accurate dynamic characteristic modeling and compensation in shock wave pressure sensor acquisition systems.

**Keywords:** shock wave pressure; dynamic compensation; variational mode decomposition; long short-term memory

冲击波作为弹药爆炸及武器系统作用过程中产生的核心毁伤元,是引发人员致伤效应与工程结构失效的关键因素。随着科学技术的快速发展,军工领域不断突破技术瓶颈,而爆炸冲击波动力学研究作为毁伤评估体系的重要基础,其压力场时空分布特征的精准表征已成为现代武器效能量化研究的焦点问题。这一需求对冲击波压力测试系统提出了严苛的动态响应要求,需在瞬态过程中实现超压信号的高保真捕获。

在压力信号采集系统中,良好的动态特性是保证冲击波采集信号精度的关键。胡勇等<sup>[1]</sup>在冲击波检测综述中提到采集系统传感器要求除宽频带外,还应具有高频响、良好的检测线性度特性(能可靠记录冲击波压力的变化情况)、高信噪比、高灵敏度和良好的抗干扰特性。但通常系统受测量精度和制作工艺的影响,其动态性能往往无法满足动态测试要求<sup>[2]</sup>。在这种背景下,对现有压力采集信号进行去噪和补偿是改善系统性能的一条有效途径。

传统的动态补偿方法如频域修正法<sup>[3-5]</sup>、反卷积法<sup>[6]</sup>等,需要首先进行系统的精确实验标定与建模,这不仅对标定装置有较高的要求,而且受限于线性假设下的建模精度<sup>[7]</sup>。近年来,随着优化算法的迭代演进,基于智能寻参<sup>[8-9]</sup>的动态误差补偿机制已成为提升系统非线性失真抑制能力的重要技术路径。除此之外,神经网络在动态信号建模领域展现出显著潜力,其使复杂信号的重构与预测精度得到进一步提升。孙传猛等<sup>[10]</sup>通过卷积神经网络重构爆炸冲击波,信号曲线重构良好;于浩等<sup>[11]</sup>基于改进的重构技术对爆炸场超压、动压信号进行了威力重构,重构精度有了显著提高。Yao 等<sup>[12]</sup>使用经验模态分解与双向长短期记忆网络建立了逆传感网络,实现了对激波管压力阶跃信号的高精度重建;Lu 等<sup>[13]</sup>通过变分模态分解-粒子群优化与长短期记忆网络相结合的模型预测离心泵压力脉动信号,使均方误差降为 31.45 Pa<sup>2</sup>。以上研究均证明了神经网络在动态信号建模应用领域的潜力,同样表明对于不同频域叠加的信号采用模态分解处理后可以使神经网络预测精度较单个神经网络精度更高。

综上所述,基于融合启发式算法,近些年信号补偿与建模方法可以突破传统线性校正的模型阶次限制,实现算法的自适应参数寻优与多目标约束优化。但目前的研究多是基于实验室环境采集的动态响应特征进行建模,再将模型代入实测响应信号当中补偿处理,缺乏直接提取实测冲击波响应特征进行训练的方法。

为探究冲击波实测响应信号的动态特征, 提高冲击波压力场动态性能精度, 构建冲击波采集系统模型, 本文提出一种基于变分模态分解 (variational mode decomposition, VMD) 处理的冲击波压力长短期记忆 (long short-term memory, LSTM) 网络建模方法。该方法结合信号处理和深度学习的优势, 经验证适用于处理实爆环境下的非平稳时间序列。其中, 在动态特性补偿处理方面, 该方法所得处理信号较传统方法更接近典型冲击波曲线, 固有频率残余减小 38%; 系统建模方面, 该方法建模误差可降至 13%, 可显著提高冲击波压力采集系统动态特性模型的建模精度。

## 1 冲击波响应信号存在的特征问题

压电式压力传感器采集的爆炸冲击波动态信号通常分为正压和负压 2 个阶段。理想冲击波曲线函数基于爆炸或高速冲击过程中能量的快速释放和介质动态响应的物理规律, 经典的冲击响应函数如理想 Friedlander 方程<sup>[14]</sup> 的压力与时间关系为:

$$p(t) = p_0 + p_{\max} \left( 1 - \frac{t}{\Delta t_+} \right) e^{-bt/\Delta t_+} \quad (1)$$

式中:  $p_0$  为初始环境压力,  $p_{\max}$  为正负峰值超压,  $\Delta t_+$  为正压持续时间,  $b$  为正压衰减系数。

在冲击波采集过程中, 由于传感器系统自身动态特性的影响, 其输出信号会在峰值处出现振荡。这不仅会导致超压峰值估算不准, 也会使测得的正压作用时间和冲量偏小, 最终对冲击波威力的评估产生较大偏差。实际环境中的压力采集系统一般可以看作单输入单输出的线性系统, 但实际信号是通过系统采样所得到的离散信号, 且计算机处理数字信号, 因此使用 Z 变换将其描述为离散时间系统:

$$Y(z) = H(z)p(z) \quad (2)$$

式中:  $Y(z)$  为离散响应输出信号的 Z 变换,  $H(z)$  为系统离散传递函数,  $p(z)$  为离散压力输入信号的 Z 变换。

图 1 对比展示了实际冲击波的输入信号和响应输出信号。由于传感器及调理电路的物理结构因素, 在压力采集系统采集的冲击波响应信号中, 动态特性又分为低频和高频两部分: 低频动态特性主要集中于截止频率对信号的影响, 高频动态特性则主要集中于固有频率。因此, 传递函数  $H(z)$  又可以分为低频传递函数  $H_1(z)$  和高频传递函数  $H_h(z)$  两部分, 其关系具体为:

$$H(z) = H_1(z)H_h(z) \quad (3)$$

除此之外, 全频段噪声对响应信号的影响也是不可忽视的。

基于传递函数的建模与补偿方法, 首先需要在实验室环境下获得正弦信号、阶跃信号等激励源信号, 分别求得系统的低频和高频动态特性传递函数。尽管线性时不变假设简化了数学推导与计算, 但其与真实系统动态特性的误差偏离暴露明显。且其中高频传递函数通常阶数较高, 所需采集频率高, 对建模方法与激励信号精度的依赖尤其显著。低频段传递函数一般阶次较小, 仅建立低频段传递函数相较于建立全频段传递函数效率更高。

为规避全频段传递函数建立困难、激励信号难以获得的问题, 本文拟研究对冲击波压力信号进行 VMD 分解, 去除高频振荡后仅建立低频段传递函数补偿低频模态的可行性; 通过补偿后的压力信号结合响应信号建立输入输出数据集, 基于 LSTM 神经网络训练压力采集系统模型。

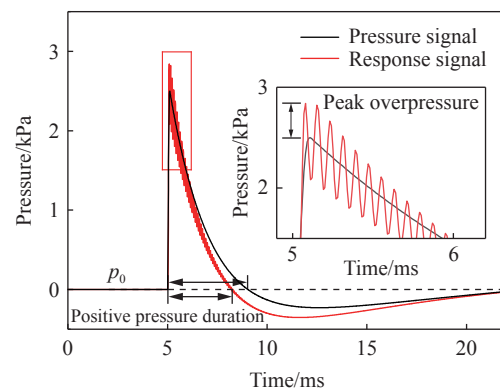


图 1 冲击波压力信号与响应曲线

Fig. 1 Shock wave pressure signal and response curve

## 2 VMD 分解处理与 LSTM 建模算法设计

本文设计的基于变分模态分解处理的冲击波压力长短期记忆网络系统建模算法,其核心思想是分而治之——首先通过 VMD 降低信号复杂度,再通过 LSTM 精细化建模,最终融合结果提升整体性能。该方法主要包括 3 个步骤:(1) 采用麻雀优化算法(sparrow search algorithm, SSA)对 VMD 与 LSTM 自适应参数寻优;(2) 基于 VMD 对冲击波响应信号进行模态分解,判断各模态分量(band limited intrinsic mode function, BLIMF)和残余(residual, Res)的成分,去除高频成分并对低频成分进行补偿,重构理想冲击波曲线;(3) 构建冲击信号的神经网络数据集,训练神经网络并评估模型性能。具体流程如图 2 所示。

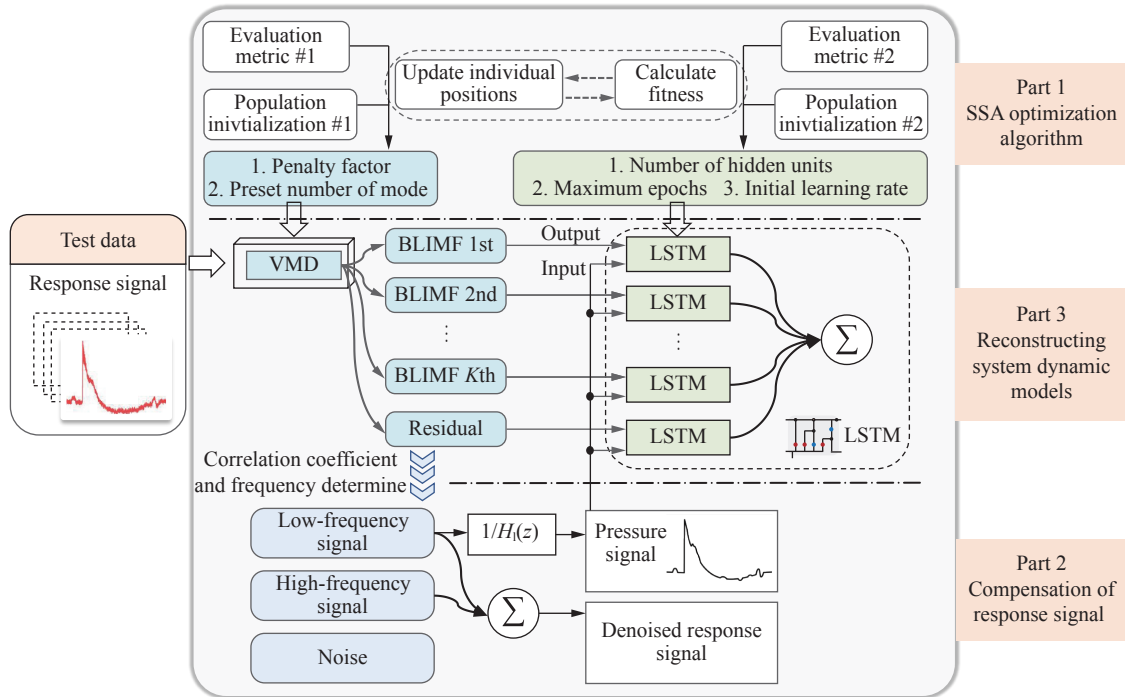


图 2 冲击波压力信号的变分模态分解与长短期记忆网络建模算法流程

Fig. 2 Flowchart of the modeling algorithm using VMD-LSTM for shock wave pressure signals

### 2.1 SSA-VMD 分解

理想冲击响应由低频趋势分量  $l(t)$  和 高频振荡分量  $h(t)$  组成,除此之外在实际采集场景中响应信号不可避免地存在一定程度的噪声分量  $g(t)$ ,因此可将响应信号  $y(t)$  视作:

$$y(t) = l(t) + h(t) + g(t) \tag{4}$$

通过 VMD 算法对冲击波压力信号  $y(t)$  进行分解,可得到  $K$  个模态分量和一个残余项,表示为:

$$y(t) = \sum_{i=1}^K F_i(t) + r(t) \tag{5}$$

式中:第  $i$  个模态分量记为  $F_i(t)$ ,其满足惩罚因子  $\alpha$  的约束条件;残余项  $r(t)$  通常为窄脉冲信号或接近于零的信号。

相比于传统的小波变换(wavelet transform, WT)、经验模态分解(empirical mode decomposition, EMD)等模态分解法,VMD 的优势在于数学模型和框架,通过变分框架约束模态带宽并最小化解调信号总方差,理论上可抑制常见的模态混叠问题,提升冲击波峰值超压辨识精度<sup>[15]</sup>。此外,结合 Hilbert 变换的窄带分解特性,其频域聚焦能力优势显著,能精准提取传感器动态响应中的特征频率分量。然而,VMD 分解结果依赖预设模态数  $K$  和惩罚因子  $\alpha$  的约束,无法与传统分解法一样根据信号特性自适应调节分解性能<sup>[16]</sup>。且参数  $K$  和  $\alpha$  的相互依赖关系使得传统的网格试错法效率低下,难以找到全局最优解。为了充分分离

冲击波冲击响应信号中的低频趋势和高频振荡, 引入 SSA 智能优化算法自动化全局搜索  $K$  和  $\alpha$ 。

根据冲击响应特性, 提出一种基于样本熵  $S_i$  和皮尔逊相关系数  $\rho_{K,\alpha}$  的代数式作为算法的适应度函数。其中  $S_i$  评价第  $i$  个模态分量的复杂度,  $\rho_{K,\alpha}$  评价在当前  $K$ 、 $\alpha$  约束分解下的所有模态叠加所得的重构信号与原信号的一致性, 具体表示为:

$$r = 0.2\sigma_{F_i(t)} \quad (6)$$

$$S_i(2, r, t) = -\ln \frac{B_i^{(3)}(r)}{B_i^{(2)}(r)} \quad (7)$$

$$u_{K,\alpha}(t) = \sum_{i=1}^K F_i(t) \quad (8)$$

$$\rho_{K,\alpha} = \frac{\text{Cov}(u_{K,\alpha}(t), x(t))}{\sigma_{u_{K,\alpha}(t)}\sigma_{x(t)}} \quad (9)$$

$$E_{K,\alpha} = \min \left( \frac{\sum_{i=1}^K S_i(2, r, t)}{\rho_{K,\alpha}} \right) \quad (10)$$

式中:  $r$  为相似性判断阈值,  $\sigma_{F_i(t)}$  为第  $i$  个模态分量的标准差,  $B_i^{(2)}(r)$  和  $B_i^{(3)}(r)$  分别表示第  $i$  个模态的窗口长度为 2、3 的子序列,  $u_{K,\alpha}(t)$  为在某组  $K$ 、 $\alpha$  约束下的所有模态之和,  $E_{K,\alpha}$  为适应度函数。在算法的迭代过程中,  $S_i$  越大,  $\rho_{K,\alpha}$  越小, 表明该组  $K$ 、 $\alpha$  约束下的模态混叠情况严重, 反之则表明分解效果理想。因此, SSA 优化算法的适应度函数最小时  $E_{K,\alpha}$  对应的  $K$ 、 $\alpha$  值即为 VMD 的最优分解参数。

## 2.2 模态成分判断与低频处理

为了去除响应信号的高频振荡与噪声, 同时使冲击波重建信号尽可能保留有效频率, 进行模态分解后需要判断各模态所包含的信号类型。本文分别检验各模态  $F_i(t)$  与原信号  $y(t)$  之间的相关系数 (correlation coefficient, CC,  $R_{cc}$ ) 和频谱,  $R_{cc,i}$  定义如下:

$$R_{cc,i} = \frac{\sum_{n=1}^N (y(n) - \overline{y(n)})(c_i(n) - \overline{c_i(n)})}{\sqrt{\left( \sum_{n=1}^N (y(n) - \overline{y(n)})^2 \right) \left( \sum_{n=1}^N (c_i(n) - \overline{c_i(n)})^2 \right)}} \quad (11)$$

式中:  $R_{cc,i}$  为第  $i$  个模态与其原信号的相关系数,  $c_i(n)$  为第  $i$  个模态的离散时序,  $\overline{y(n)}$  和  $\overline{c_i(n)}$  分别为  $y(n)$  和  $c_i(n)$  的时序均值,  $N$  为时序长度。

在 SSA-VMD 分解充分的情况下, 根据冲击波频谱分布的特性, 冲击波峰值区域主要集中在低频部分<sup>[17]</sup>, 低频分量与原响应信号应具有 0.8 以上的强相关性; 噪声主要分布于高频段, 且高频分量与随机噪声的 CC 均较弱, 仅凭 CC 难以进行有效区分, 为此引入跳变时长作为判据。对于每个模态分量, 其包络线的指数衰减拟合曲线可以用  $A(t) = A_0 e^{-t/t_0}$  表示, 跳变时长  $t_0$  被量化为振幅衰减至初始阶跃的  $1/e$  时所需的时间。根据噪声幅值小、频段高的特点, 判定若模态的  $t_0 \leq 0.5$  ms 则为噪声分量, 予以剔除, 可得去除高频振荡后的信号  $y_1(t)$  为:

$$y_1(t) = y(t) - h(t) - g(t) \quad (12)$$

实际实验中通过正弦信号发生器测试传感器的低频段正弦信号采集率<sup>[17]</sup>, 因此基于已知建模的低频段离散传递函数  $H_1(z)$ , 根据离散传递函数式推导动态特性补偿处理后的压力信号  $\hat{p}(t)$ , 具体补偿为:

$$\hat{p}(t) = \mathcal{Z}^{-1}(Y_1(z)/H_1(z)) \quad (13)$$

式中:  $Y_1(z)$  为  $y_1(t)$  的 Z 变换形式。

### 2.3 SSA-LSTM 系统建模

在相同的压力采集系统下进行多次不同压力信号的实验, 基于上述冲击波响应信号的补偿步骤, 可以得到系统的多组输入输出数据, 建立神经网络建模的数据集。每组数据的输入信号  $p_{in}(t)$  和输出信号  $p_{out}(t)$  分别为:

$$p_{in}(t) = \hat{p}(t), \quad p_{out}(t) = y(t) \quad (14)$$

LSTM 在处理时序问题上性能优于传统循环神经网络 (recurrent neural network, RNN), 但模型的收敛速度、预测精度和泛化能力同样高度依赖参数的选择。传统的调参方法如网格搜索、随机搜索等效率较低且易陷入局部最优, 而启发式优化算法如粒子群优化算法也存在收敛速度慢的问题。本文采用 SSA 优化算法辅助 LSTM, 定义待优化的 LSTM 超参数集合为隐藏层数、最大训练次数和初始学习率 3 项; 训练集的适应度设置为均方误差 (mean squared error, MSE), 均方误差适应度具体定义为:

$$\varepsilon = \frac{1}{N} \sum_{n=1}^N (p_{out}(n) - \hat{p}_{out}(n))^2 \quad (15)$$

式中:  $p_{out}(n)$  为训练集的真实信号序列,  $\hat{p}_{out}(n)$  为训练集的预测信号序列。

LSTM 通过引入门控机制和细胞状态, 有效解决了 RNN 存在的梯度消失问题, 增强了长序列中的依赖关系, 并实现了对噪声的有效过滤, 成为处理时间序列数据的经典模型。LSTM 网络由若干单元组成, 而 LSTM 单元的核心是细胞状态和 3 种控制门, 分别是输入门、遗忘门和输出门, 门的特殊结构使其可以控制信息在单元之间的流动, 并对单元状态进行增减。算法流程如下:

$$i_t = \sigma(W_i(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_i) \quad (16)$$

$$f_t = \sigma(W_f(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_f) \quad (17)$$

$$\tilde{C}_t = \tanh(W_c(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_c) \quad (18)$$

$$C_t = f_t \odot C_{t-1} + i_t \odot \tilde{C}_t \quad (19)$$

$$o_t = \sigma(W_o(\mathbf{h}_{t-1}, \mathbf{x}_t) + \mathbf{b}_o) \quad (20)$$

$$\mathbf{h}_t = o_t \odot \tanh(C_t) \quad (21)$$

式 (16) 为输入门  $i_t$  的计算公式,  $i_t$  为  $t$  时刻的输入门输出,  $\mathbf{x}_t$  为在  $t$  时刻的时序输入,  $\mathbf{h}_{t-1}$  为  $t-1$  时刻的输出,  $(\mathbf{h}_{t-1}, \mathbf{x}_t)$  表示将  $\mathbf{h}_{t-1}$  和  $\mathbf{x}_t$  拼接成一个向量,  $W_i$  和  $\mathbf{b}_i$  分别为输入门的权重值和偏置向量,  $\sigma$  表示 sigmoid 函数。式 (17) 的遗忘门  $f_t$  同样由 sigmoid 层计算获得,  $W_f$  和  $\mathbf{b}_f$  分别为遗忘门的权重值和偏置向量。式 (18) 的候选细胞  $\tilde{C}_t$  由  $\tanh$  激活函数控制,  $W_c$  和  $\mathbf{b}_c$  分别为候选细胞的权重值和偏置向量。将  $\tilde{C}_t$  与输入门、遗忘门融合后可以获得  $t$  时刻更新后的细胞状态  $C_t$ , 其中  $\odot$  表示哈达玛积, 即对应元素相乘。式 (20) 为输出门  $o_t$  的计算公式,  $W_o$  和  $\mathbf{b}_o$  分别为输出门的权重项和偏置向量。 $o_t$  确定了下一个隐藏状态  $\mathbf{h}_t$ ,  $\mathbf{h}_t$  则提供先前输入的信息并用于此次预测。

## 3 数值模拟与算法验证

### 3.1 SSA-VMD 分解处理性能验证

压力传感器系统可以描述为单输入单输出的线性时不变系统, 本文使用 MATLAB 仿真假定传感器真实动态数学模型为:

$$H(z) = H_l(z)H_h(z) = \frac{z - 0.9997}{z - 0.9994} \frac{0.1z^2 + 0.295z + 0.185}{z^2 - 1.4z + 0.98} \quad (22)$$

$H(z)$  由低频传递函数与高频传递函数共同构成。为了模拟实际环境中的冲击响应动态特性, 在仿真冲击波曲线中引入 BUMPS 噪声。且各信号均采用不同正负压冲量比的冲击响应信号, 用于增加数据集中的数据特征, 提高 LSTM 门控参数的自优化效率。

训练集和测试集的 4 种仿真冲击波压力信号与响应曲线如图 3 所示, 具体特征参数如表 1 所示。4 组有色噪声的信噪比分别为 20.3、21.2、20.1 和 20.5 dB。

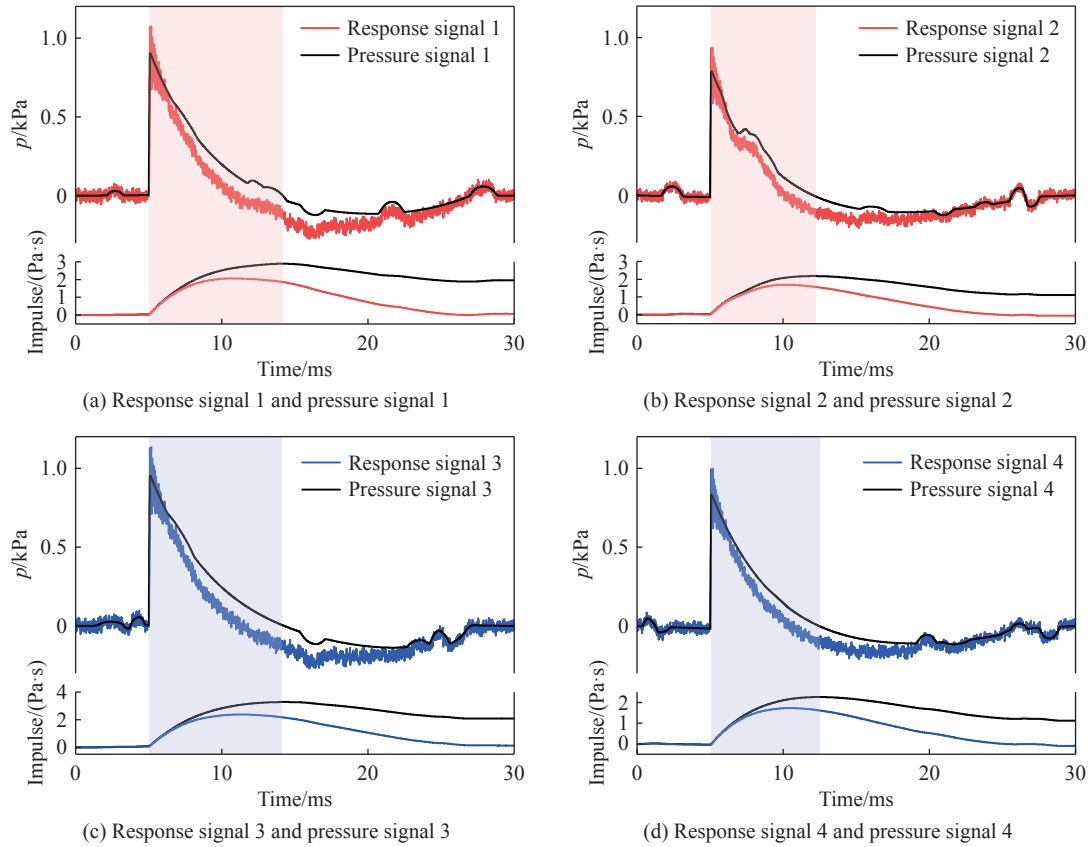


图 3 仿真冲击波压力信号与采集系统动态响应曲线

Fig. 3 Simulation of shock wave pressure signal and dynamic response curve of acquisition system

表 1 动态压力冲击信号及其响应特征参数

Table 1 Dynamic pressure impulse signal and its responses

组别	信号			响应		
	峰值超压/kPa	正压时间/ms	冲量/(Pa·s)	峰值超压/kPa	正压时间/ms	冲量/(Pa·s)
1	0.90	9.22	2.89	1.07	6.01	2.60
2	0.79	6.97	2.18	0.93	5.13	1.69
3	0.96	9.28	3.28	1.13	6.35	2.37
4	0.83	5.47	2.26	0.99	7.45	1.73

首先对训练集的响应信号 1、响应信号 2 分别进行模态分解。SSA-VMD 方法采用麻雀优化算法确定  $K$  与  $\alpha$  的最优解, 初始种群数量设置为 20, 最大迭代次数为 10 次,  $K$  界限设置为 2~6,  $\alpha$  参数界限设置为 100~3 500。由图 4 可知, 随着迭代次数的增加, 惩罚因子和预设模态数对各分解模态的约束程度增强, 优化算法适应度下降, 当迭代次数增至 10 次时各指标趋势趋于平稳。

结合频谱图(图 5)与时域分解图(图 6), 根据 2.2 节所述的成分判断定义, 计算模态的 CC 如表 2 所示。可以得知 VMD 分解所得 BLIMF1 为低频分量, BLIMF2 为高频分量, BLIMF3 为噪声分量。除此之外, res 包含噪声分量, 但根据跳变时长与图 5 判断, 其中同样包含低频有效跳变信号, 为了最大程度地保留峰值超压准确数值, 将 BLIMF1 与 res 的叠加量作为去除振荡后的信号。

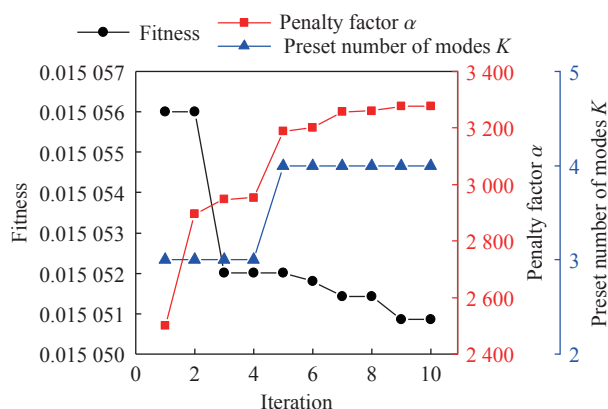


图 4 优化算法适应度随迭代过程的收敛趋势  
Fig. 4 Convergence trend of the optimizer's fitness across iteration steps

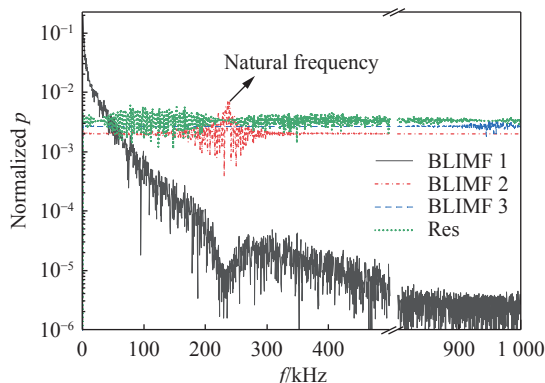


图 5 信号分解后各分量的幅频特性频谱  
Fig. 5 Amplitude-frequency characteristics spectra of the decomposed signal components

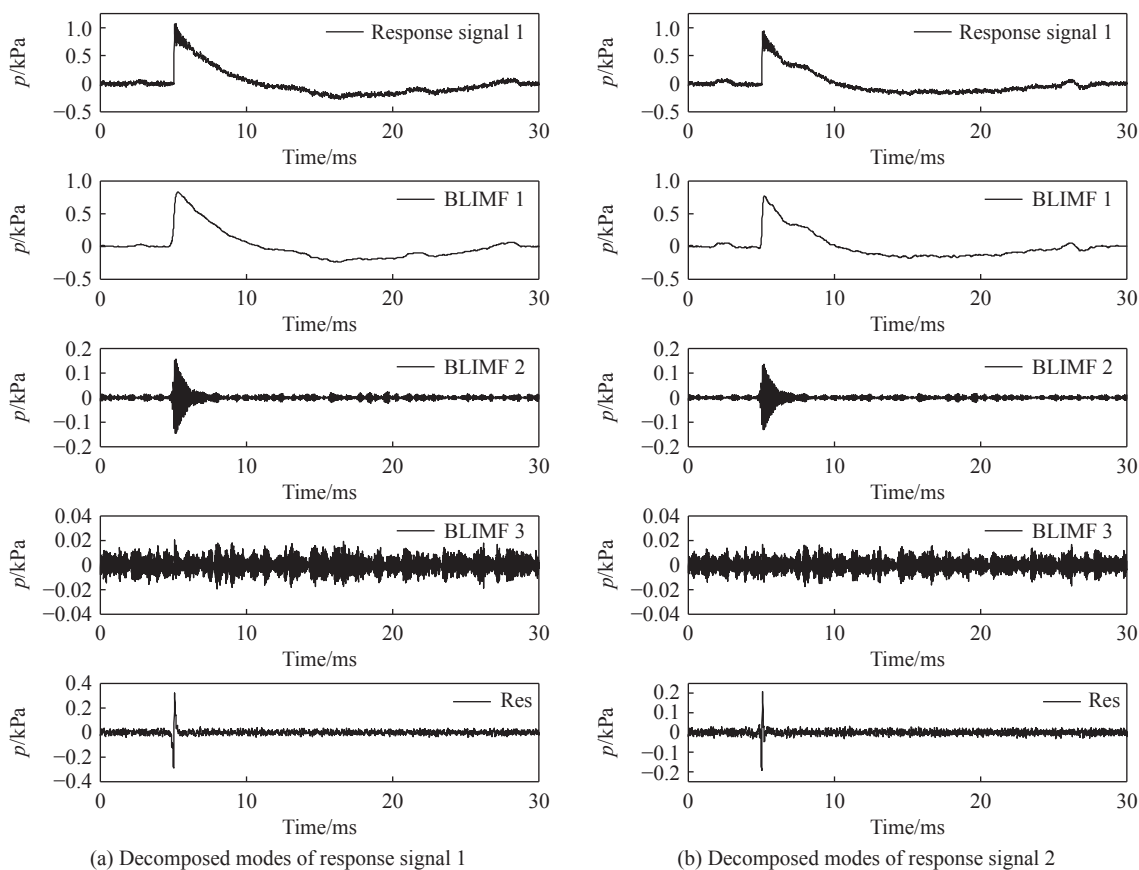


图 6 信号分解后各分量的时域特性  
Fig. 6 Time-domain characteristics of the decomposed signal components

实际环境中,使用正弦信号发生器可以测量出采集系统的低频段正弦信号幅值效率<sup>[18]</sup>,求得系统的低频段传递函数,因此在仿真中假定式中的低频段离散传递函数  $H_1(z)$  已知。根据上述分析,可得重构信号:

$$\hat{p}(t) = \mathcal{Z}^{-1} \left\{ \frac{\mathcal{Z}\{F_1(t) + r(t)\}}{H_1(z)} \right\} \quad (23)$$

补偿结果如图 7 所示。

表 2 信号分解后各分量的相关系数、跳变时长

Table 2 Correlation coefficients and jump durations for decomposed signal components

模态	信号1		信号2	
	CC	跳变时长/ms	CC	跳变时长/ms
BLIMF1	0.989	6.20	0.991	5.54
BLIMF2	0.098	3.89	0.098	3.55
BLIMF3	0.064	0.10	0.061	0.10
Res	0.223	1.44	0.192	0.32

采用平均绝对百分比误差 (mean absolute percentage error, MAPE) 量化评价图 7 去除振荡的处理效果。经计算, 响应信号 1 与原压力信号  $p(t)$  的 MAPE 由补偿前的 6.92% 减小至 1.55%, 信噪比由 20.3 dB 增大至 22.43 dB; 响应信号 2 的 MAPE 由补偿前的 4.58% 减小至 1.21%, 信噪比由 21.2 dB 增大至 22.53 dB, 证明算法的补偿与去噪效果良好, 重构信号可以满足作为神经网络输入压力信号的要求。以上述方法同样对验证集的响应信号 3 和响应信号 4 进行 SSA-VMD 处理, 得到神经网络的训练集和验证集所有输入输出时序。

### 3.2 系统建模性能验证

对比单 LSTM 神经网络与本文设计的 VMD-LSTM 组合神经网络算法的系统建模曲线精度, 并验证 SSA 优化 LSTM 神经网络超参数的合理性。

由于实测冲击波信号一般夹杂大量噪声, 模型易过度学习训练数据中的噪声和偶然特征导致过拟合, 网络引入 L2 正则化限制参数规模, 惩罚强度参数设置为 0.01。

单 LSTM 网络将补偿后所得的  $\hat{p}(t)$  作为数据集输入, 响应信号  $y(t)$  作为数据集输出, 训练所得的单个神经网络即为传感器系统模型; VMD-LSTM 网络将分解后的各模态作为数据集输入, 分别与响应信号  $y(t)$  建模, 最终将训练所得的各网络并联相加得到传感器整体系统模型, 响应信号 3、响应信号 4 作为验证集。如表 3 所示, 通过均方根误差 (root mean squared error, RMSE)、平均绝对误差 (mean absolute error, MAE) 和 MAPE 评价 2 种算法的性能。

表 3 模型的误差指标对比

Table 3 Comparison of error metrics for the models

算法	训练集			验证集		
	RMSE/Pa	MAE/Pa	MAPE/%	RMSE/Pa	MAE/Pa	MAPE/%
LSTM	55.545	38.828	7.4441	59.648	41.19	8.4934
SSA-VMD-SSA-LSTM	21.363	12.450	3.12	23.335	13.75	3.4385

图 8 展示了 VMD-LSTM 算法在验证集的冲击波响应建模曲线。从图 8 的区域标记放大图中可以得到, VMD-LSTM 建模曲线与单一 LSTM 建模曲线对比, 峰值超压的 MAPE 由 35% 降至 12%、正压持续时间的 MAPE 由 17% 降至 1%; 且 VMD-LSTM 建模曲线与原响应曲线的振荡周期趋势一致, 证明系统的固有频率特征建模良好。

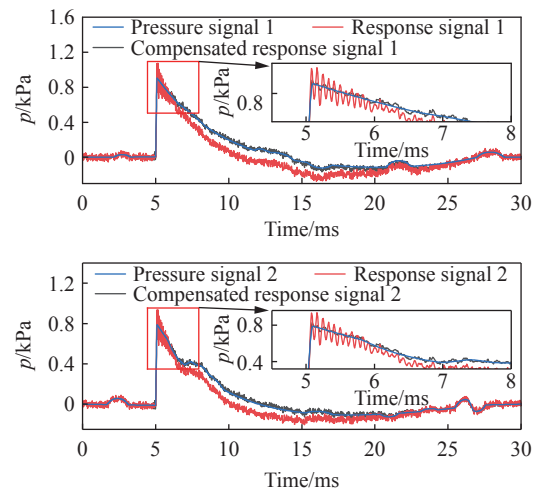


图 7 分解重构处理对冲击波响应信号补偿的效果

Fig. 7 Effect of decomposition-reconstruction processing on compensation of shock wave response signals

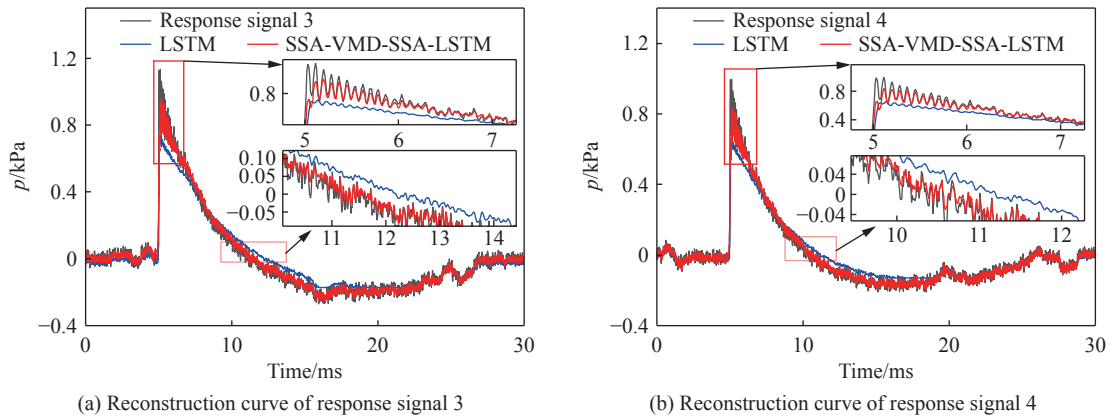


图 8 验证集冲击波压力信号的模型建模效果对比

Fig. 8 Comparison of model recovery performance for shock wave pressure signals on the validation set

在神经网络训练中, 过高或过低的超参数都会直接影响模型的收敛性和泛化能力。参考消融实验原理, 验证 SSA 优化算法所得的超参数合理性。首先采用 SSA 优化算法自适应调节 LSTM 的隐藏单元数目、最大训练次数和初始学习率, 其次将隐藏单元数目增大或减小 32, 其他参数与 SSA 最优参数相同。具体网络对比参数设置与误差变化见表 4, 表中首行为 SSA 的自适应超参数, 由 3 种误差变化的规律可知, SSA 优化算法的超参数设置是合理的。

表 4 优化算法对模型性能影响的消融实验分析

Table 4 Impact of optimization algorithms on model performance: an ablation analysis

隐藏单元数目/个	最大训练周期/轮	初始学习率	RMSE/Pa	MAE/Pa	MAPE/%
156	300	0.006 703 5	23	14	3.439
124	300	0.006 703 5	29	17	4.657
188	300	0.006 703 5	31	18	5.164

### 4 实测信号实验

本文在实际环境中开展验证性实验, 通过实测爆炸源试验得到 10 组压电式压力传感器响应信号。爆炸源基于 0.3~0.5 g TNT 当量, 为了在小当量下尽可能采集到冲击波的负压区特征, 测试距离固定为 10 cm。冲击波信号采集基于某型号国产压电式压力传感器, 与实验室自研压力采集设备组成采集系统<sup>[19]</sup>。压力传感器参考固有频率大于 150 kHz, 灵敏度为 5.91 mV/kPa, 量程为 0~1 MPa; 压力信号采集设备放大倍数设置为 0.5, 采样频率为 2 MHz, 因此采样频谱范围足以覆盖传感器固有频率。

为了验证 SSA-VMD 算法在同一个传感器采集系统的不同冲击波超压下, 对高频模态的特征提取具有一致性, 首先将十组响应信号作归一化处理, 分析高频幅频特性。图 9 为 10 组高频分解模态的归一化幅频特性, 颜色表示不同的幅值增益, 可以明显看出峰值频率集中于 184 kHz;

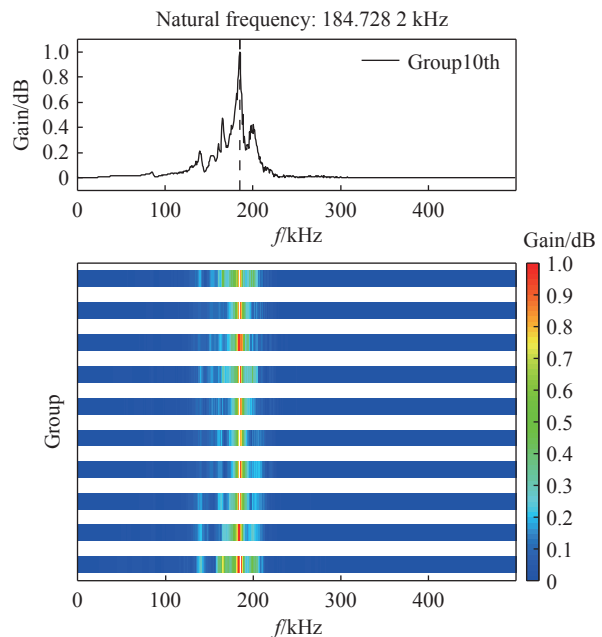


图 9 实测信号的高频分量幅频特性

Fig. 9 Amplitude-frequency characteristics of high-frequency signal components

半功率带宽频率范围约为 4.668 kHz, 整体半功率带宽波动不大于  $\pm 3\%$ 。因此, 可以证明 SSA-VMD 算法能够精准提取冲击波压力响应的高频特征模态。

为了增强网络的泛化能力, 需要提高训练数据的分布特征<sup>[20]</sup>。在 10 组中选取峰值超压最大的响应信号 1、峰值超压最小的响应信号 2 和随机选择的响应信号 3 作为后续 LSTM 神经网络建模算法数据集, 其中响应信号 1、响应信号 2 为训练集, 响应信号 3 为验证集。训练集时域分解如图 10 所示。

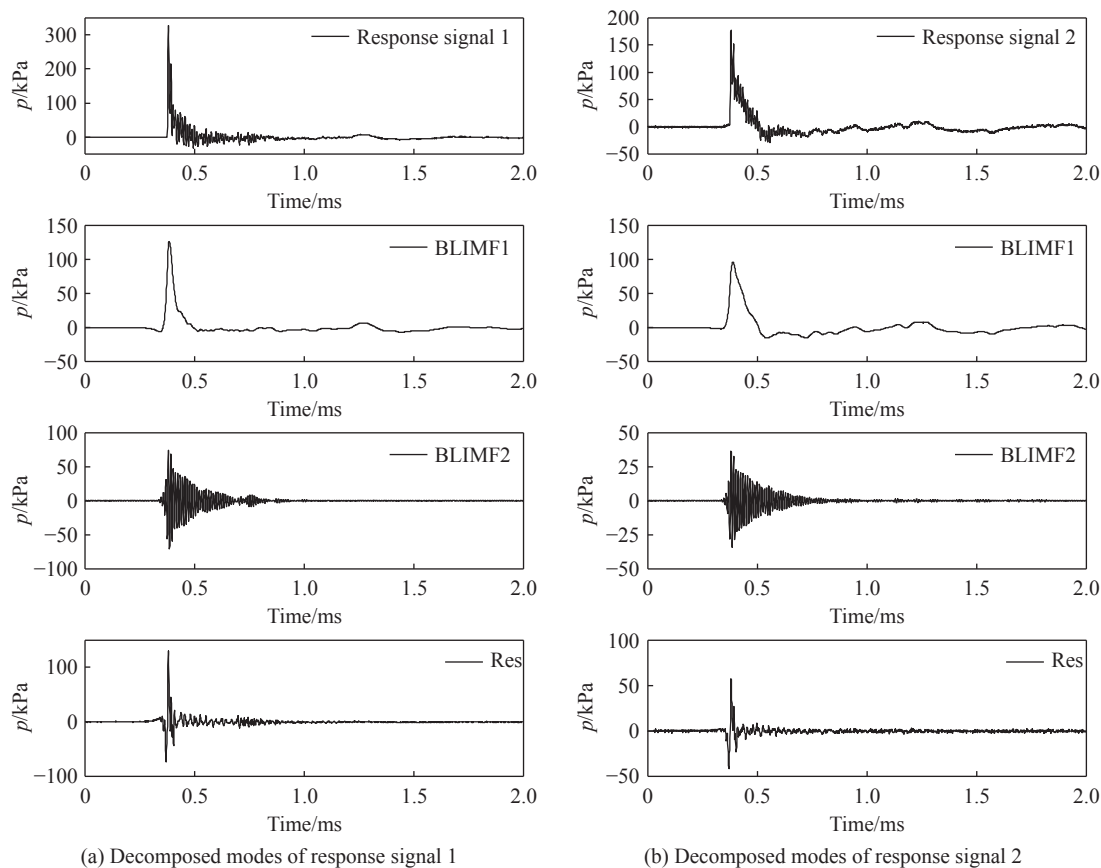


图 10 实测冲击波响应信号各分解模态的时域特性

Fig. 10 Time-domain characteristics of decomposed components of the shock wave response signal

根据 CC 与频谱判断法可知 BLIMF1 为低频分量, BLIMF2 为高频振荡分量。将 BLIMF1 与 Res 相加得到处理后压力信号  $y_1(t)$ 。

为了在实测实验中验证 SSA-VMD 动态特性处理的性能, 将 SSA-VMD 与反滤波补偿法<sup>[2]</sup>进行对比。本文通过激波管实验获取阶跃响应曲线, 建模所得压力传感器高频段离散传递函数为:

$$H(z) = \frac{1.102z^3 - 1.035z^2 - 1.092z + 1.044}{z^4 - 0.9897z^3 - 0.9863z^2 + 0.9994z - 0.00403} \quad (24)$$

2 种补偿方法的时域曲线与幅频特性曲线如图 11 所示, 并给出低频趋势 BLIMF1。由于建模精度的影响, 在固有频率带宽范围内, 反滤波法较 SSA-VMD 处理法的残余幅值高于 38%; 除此之外, 与图 10(b)的低频频谱趋势相对比, 反滤波法的补偿结果产生了一个带阻失真范围, 该失真范围会导致有效峰值信号的减小。

实验使用正弦压力发生器测试压力采集系统的低频段传递函数。图 12(a) 正弦压力发生器采用双向双通道进出口同步调制技术, 能够产生不同频率的正弦压力波形, 失真度小于 2%。将压电式传感器固定于发生器气流口, 正弦信号激励压力设置为 500 kPa 不变, 令频率控制仪输入相同压力幅值下频率为 0.1~10 Hz 的正弦信号。部分正弦采集信号如图 12(b) 所示。

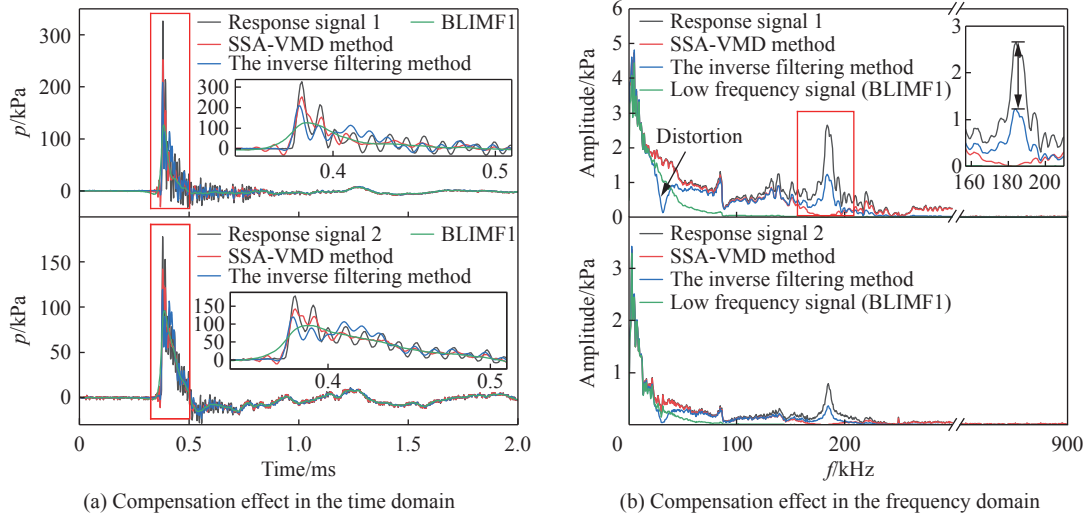



图 11 SSA-VMD 与反滤波的补偿结果实测对比

Fig. 11 Comparison of results between SSA-VMD and inverse filtering



(a) Sinusoidal pressure calibration platform



(b) Partial frequency sinusoidal signal response curves

图 12 基于正弦发生器的传感器低频动态响应信号变化规律

Fig. 12 Variation patterns in low-frequency response signals of the sensor tested with a sine generator

从 0.1~10 Hz 的正弦采集信号变化规律中可知, 在 3~10 Hz 范围内峰峰值基本稳定在 500 kPa。基于 500 kPa 的参考压力值, 将各正弦采集信号的峰峰值(kPa)转换为分贝值(dB)形式, 换算根据幅值类物理量的对数缩放规则, 具体为:

$$A = 20\lg(p_{v-v}/p_{ref}) \tag{25}$$

式中:  $A$  为信号峰值的相对大小, 单位为分贝;  $p_{v-v}$  为采集信号峰峰值,  $p_{ref}$  为参考压力值。根据换算后的各频率下幅值分贝, 可以得出传感器系统的 0.1~10 Hz 范围内幅频特性如图 13 所示。采用 MATLAB 的频域有理函数拟合可得低频段传递函数近似为:

$$H_1(t) = \frac{0.222 8s}{0.222 8s + 1} \tag{26}$$

对  $y_h(t)$  进行低频补偿处理。由图 14 所示的 3 组响应信号的处理前后变化曲线可知, 较未处理信号  $y_h(t)$  相比, 低频补偿处理使信号的振荡进一步减小至 37%,  $p(t)$  符合典型冲击波曲线趋势。




图 13 系统低频动态幅频特性曲线

Fig. 13 System low-frequency dynamic amplitude-frequency characteristic curve

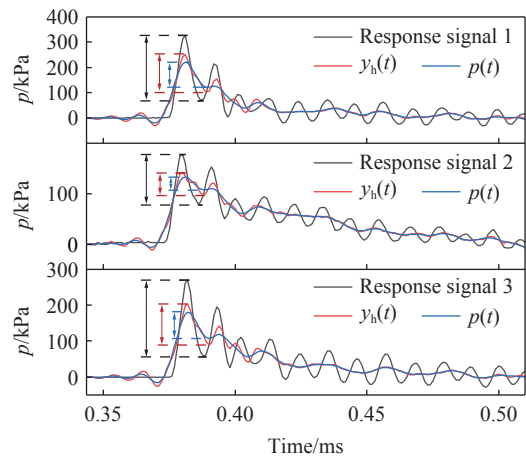


图 14 低频补偿的处理效果对比

Fig. 14 Comparative processing effectiveness of low-frequency compensation

最后, 对比单一 SSA-LSTM 网络训练结果, 将补偿所得  $p(t)$  作为数据集输入, 原始响应信号  $y(t)$  作为数据集输出。SSA 初始化种群数量为 10、最大迭代次数为 8, 优化隐藏单元数目、最大学习次数和初始学习率 3 个参数; 最终迭代所得网络参数设置为表 5 所示。

表 5 两种神经网络建模的误差性能指标

Table 5 A comparative evaluation of error metrics for the two neural network architectures

算法	隐藏单元数/个	初始学习率	RMSE/kPa	MAE/kPa	MAPE/%	峰值超压/kPa	振荡频率/kHz
SSA-LSTM	66	0.0409	8.667	3.088	30.08	179.77	85.03
SSA-VMD-SSA-LSTM	124	0.091909	3.406	1.015	13.17	207.73	183.82

图 15 展示了 2 种算法对验证集的重建曲线, 本文设计的 SSA-VMD-SSA-LSTM 的冲击波压力模态分解建模方法与原响应信号趋势高度一致, 振荡频率符合响应信号固有频率值。结合表 5 可知, 传感器系统建模误差 MAPE 减小至 13.17%, 所有误差指标较单一 LSTM 网络均减小 50% 以上。




图 15 实测验证集信号重建曲线

Fig. 15 Reconstruction curves for measured signals on the validation set

## 5 结论

本研究旨在补偿冲击波响应曲线, 并建立传感器系统动态特性模型。在理想冲击波曲线假设的基

基础上,分析了传感器动态特性在采集爆炸冲击波时存在的问题,设计了一种基于 SSA 优化的自适应 VMD 分解冲击波响应补偿方法,对比了不同适应度函数对分解模态的影响;设计了将 VMD 分解后的多模态通过 LSTM 串联训练重建传感器系统动态特性方法,并采用仿真与实测冲击波数据开展了相关验证性实验,得到了以下结论。

(1) 由于压电式压力传感器的低频截止频率和高频固有频率影响,响应信号的正压时间减小,峰值超压增大,冲击波曲线产生振荡,难以确定准确的冲击波压力趋势。

(2) SSA 优化算法可以根据信号自适应选择 VMD 分解模态数与带宽,通过 CC 和频谱判断分解后的各模态成分,可以将冲击波信号分解为低频分量、高频分量和噪声分量。采用此方法去除信号的高频振荡与噪声,较传统反滤波修正方法的残余振荡幅值减小 38%。

(3) 采用正弦信号发生器计算低频系统函数进行低频补偿,将补偿后信号与理想压力信号进行对比,验证了低频补偿使振荡幅值进一步减小,整体趋势符合理想冲击波压力曲线。

(4) 采用 VMD 结合 LSTM 神经网络对传感器系统进行建模,精度远高于单一 LSTM 系统建模;通过消融实验验证了 SSA 优化辅助 LSTM 参数设置,精度较经验设定参数的结果更好。最终实测的传感器系统建模误差 MAPE 减小至 13.17%。

## 参考文献:

- [1] 胡勇, 马天, 王俊龙, 等. 针对个体防护的冲击波检测评估技术 [J]. *爆炸与冲击*, 2025, 45(4): 041101. DOI: 10.11883/bzycj-2024-0118.  
HU Y, MA T, WANG J L, et al. Shock wave detection and evaluation techniques for individual protection [J]. *Explosion and Shock Waves*, 2025, 45(4): 041101. DOI: 10.11883/bzycj-2024-0118.
- [2] 张志杰. 动态测试与校准技术 [M]. 北京: 机械工业出版社, 2021: 8-9.  
ZHANG Z J. Dynamic measurement and calibration technology [M]. Beijing: China Machine Press, 2021: 8-9.
- [3] 韦志慧. 基于 MATLAB 传感器动态误差频域修正方法 [J]. *机械*, 2012, 39(S1): 17-20. DOI: 10.3969/j.issn.1006-0316.2012.S1.005.  
WEI Z H. A correcting method of frequency domain for sensor's dynamic error based on MATLAB [J]. *Machinery*, 2012, 39(S1): 17-20. DOI: 10.3969/j.issn.1006-0316.2012.S1.005.
- [4] 徐浩, 杜红棉, 范锦彪, 等. 冲击波测试系统低频特性与补偿方法研究 [J]. *爆炸与冲击*, 2019, 39(10): 104102. DOI: 10.11883/bzycj-2019-0233.  
XU H, DU H M, FAN J B, et al. Research on low frequency characteristics and compensation method of a shock wave test system [J]. *Explosion and Shock Waves*, 2019, 39(10): 104102. DOI: 10.11883/bzycj-2019-0233.
- [5] 张龙, 廖旭东, 张宝国, 等. 有限空间爆炸瞬态温度的动态补偿方法研究 [J]. *传感技术学报*, 2020, 33(6): 861-866. DOI: 10.3969/j.issn.1004-1699.2020.06.012.  
ZHANG L, LIAO X D, ZHANG B G, et al. Research on dynamic compensation method for explosion transient temperature in finite space [J]. *Chinese Journal of Sensors and Actuators*, 2020, 33(6): 861-866. DOI: 10.3969/j.issn.1004-1699.2020.06.012.
- [6] 杨文杰, 张志杰, 赵晨阳, 等. 基于零极点配置理论的压力传感器动态特性补偿 [J]. *科学技术与工程*, 2016, 16(2): 78-82, 99. DOI: 10.3969/j.issn.1671-1815.2016.02.015.  
YANG W J, ZHANG Z J, ZHAO C Y, et al. The dynamic characteristics compensation of the pressure sensor based on the theory of configuring zero-poles [J]. *Science Technology and Engineering*, 2016, 16(2): 78-82, 99. DOI: 10.3969/j.issn.1671-1815.2016.02.015.
- [7] 王志超, 张志杰, 赵晨阳. 压力传感器的模型不确定度研究 [J]. *测试技术学报*, 2020, 34(1): 54-60. DOI: 10.3969/j.issn.1671-7449.2020.01.009.  
WANG Z C, ZHANG Z J, ZHAO C Y. Research on model uncertainty of pressure sensor [J]. *Journal of Test and Measurement Technology*, 2020, 34(1): 54-60. DOI: 10.3969/j.issn.1671-7449.2020.01.009.
- [8] 郑德智, 吴钧明, 樊尚春. 基于改进烟花算法的传感器动态特性补偿方法研究 [J]. *计测技术*, 2020, 40(5): 25-30. DOI: 10.11823/j.issn.1674-5795.2020.05.05.  
ZHENG D Z, WU J M, FAN S C. Research on dynamic compensation of sensors based on improved fireworks algorithm [J].

- Metrology and Measurement Technology*, 2020, 40(5): 25–30. DOI: 10.11823/j.issn.1674-5795.2020.05.05.
- [9] 赵博, 李鹤. 结合 EMD 和 LSF 的振动信号降噪方法的研究 [J]. *振动、测试与诊断*, 2022, 42(3): 606–610, 624. DOI: 10.16450/j.cnki.issn.1004-6801.2022.03.028.
- ZHAO B, LI H. Noise reduction method of vibration signal combining EMD and LSF [J]. *Journal of Vibration, Measurement and Diagnosis*, 2022, 42(3): 606–610, 624. DOI: 10.16450/j.cnki.issn.1004-6801.2022.03.028.
- [10] 孙传猛, 裴东兴, 陈嘉欣, 等. 基于深度学习的爆炸冲击波信号重构模型 [J]. *计测技术*, 2022, 42(2): 57–67. DOI: 10.11823/j.issn.1674-5795.2022.02.07.
- SUN C M, PEI D X, CHEN J X, et al. Research on reconstruction model of explosion shock wave signal based on deep learning [J]. *Metrology and Measurement Technology*, 2022, 42(2): 57–67. DOI: 10.11823/j.issn.1674-5795.2022.02.07.
- [11] 于浩, 刘彦, 孙亚如, 等. 爆炸冲击波场参数数字重构技术研究 [J]. *北京理工大学学报*, 2025, 45(3): 219–228. DOI: 10.15918/j.tbit1001-0645.2024.078.
- YU H, LIU Y, SUN Y R, et al. Research on digital reconstruction of explosion shock wave field parameters [J]. *Transactions of Beijing Institute of Technology*, 2025, 45(3): 219–228. DOI: 10.15918/j.tbit1001-0645.2024.078.
- [12] YAO Z J, LI Y S, SHI B, et al. An improved reconstruction method of the reflected dynamic pressure in shock tube system based on inverse sensing model identification [J]. *Aerospace Science and Technology*, 2024, 145: 108903. DOI: 10.1016/j.ast.2024.108903.
- [13] LU J X, ZHOU Y Z, GE Y L, et al. Research into prediction method for pressure pulsations in a centrifugal pump based on variational mode decomposition-particle swarm optimization and hybrid deep learning models [J]. *Sensors*, 2024, 24(13): 4196. DOI: 10.3390/s24134196.
- [14] FRIEDLANDER F G. The diffraction of sound pulses: I. diffraction by a semi-infinite plane [J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 1946, 186(1006): 322–344. DOI: 10.1098/rspa.1946.0046.
- [15] DRAGOMIRETSKIY K, ZOSSO D. Variational mode decomposition [J]. *IEEE Transactions on Signal Processing*, 2014, 62(3): 531–544. DOI: 10.1109/TSP.2013.2288675.
- [16] ZHANG X, MIAO Q, ZHANG H, et al. A parameter-adaptive VMD method based on grasshopper optimization algorithm to analyze vibration signals from rotating machinery [J]. *Mechanical Systems and Signal Processing*, 2018, 108: 58–72. DOI: 10.1016/j.ymsp.2017.11.029.
- [17] 李向荣, 马翊闻, 李帅, 等. 爆炸冲击波峰值区域频率分布特性研究 [J]. *北京理工大学学报*, 2019, 39(2): 125–130. DOI: 10.15918/j.tbit1001-0645.2019.02.003.
- LI X R, MA Y W, LI S, et al. Research on frequency distribution of peak area of blast shock wave [J]. *Transactions of Beijing Institute of Technology*, 2019, 39(2): 125–130. DOI: 10.15918/j.tbit1001-0645.2019.02.003.
- [18] ZHAI Y P, ZHANG Z J, ZHANG H. Analysis and compensation of low frequency characteristics of sensors for vibration testing [J]. *Journal of Measurement Science and Instrumentation*, 2019, 10(2): 176–181. DOI: 10.3969/j.issn.1674-8042.2019.02.010.
- [19] 赖富文, 王文廉, 张志杰. 大当量战斗部爆炸冲击波测试系统设计及应用 [J]. *弹箭与制导学报*, 2009, 29(3): 133–135, 138. DOI: 10.3969/j.issn.1673-9728.2009.03.039.
- LAI F W, WANG W L, ZHANG Z J. Design and application of test system for blast wave [J]. *Journal of Projectiles, Rockets, Missiles and Guidance*, 2009, 29(3): 133–135, 138. DOI: 10.3969/j.issn.1673-9728.2009.03.039.
- [20] HASTIE T, TIBSHIRANI R, FRIEDMAN J. The elements of statistical learning: data mining, inference, and prediction [M]. 2nd ed. New York: Springer, 2009. DOI: 10.1007/978-0-387-84858-7.

(责任编辑 张凌云)