

基于 DnCNN 的侵入过载时频去噪方法

郑宏亮^{1,2}, 贾森清³, 郭宇朋^{1,2}, 薛颖杰¹, 韩晶^{1,2*}, 赵河明^{1,2}, 石志刚⁴

(1. 中北大学 机电工程学院, 太原 030051; 2. 山西省高端装备可靠性技术重点实验室, 太原 030051;
3. 西安机电信息技术研究所 机电动态控制重点实验室, 西安 710065;
4. 湖北三江航天红林探控有限公司, 湖北 孝感 432000)

摘要: **目的** 提高从侵入过载中准确估计刚体过载信号的能力。**方法** 提出一种基于前馈去噪卷积神经网络 (DnCNN) 的侵入过载时频去噪方法, 该方法首先应用短时傅里叶变换 (STFT) 提取侵入过载信号的时频图像, 使 DnCNN 能够充分利用时频图像信息, 估计出刚体过载时频图像。最后, 通过逆 STFT 将时频图像转换回时域, 得到估计的刚体过载信号。**结果** 在 5-Fold 交叉验证中, 所提方法在测试集上的平均绝对误差 (MAE) 为 0.968%, Pearson 相关系数 (r) 为 90.35%。与低通滤波、总体经验模态分解 (EEMD) 和小波变换方法相比, 所提方法的平均 MAE 分别降低了 1.82%、1.00%、0.75%, 平均相关系数 r 值分别提高了 47.81%、17.48%、22.93%。**结论** 所提方法可以从侵入过载中准确估计出刚体过载信号, 在去噪能力上优于低通滤波、EEMD 和小波变换方法, 且在去噪过程中, 无需调整参数, 能够自动完成去噪任务。

关键词: 硬目标侵入; 侵入过载; 前馈去噪卷积神经网络; 信号去噪; 时频分析; k -Fold 交叉验证

中图分类号: O385

文献标志码: A

文章编号: 1672-9242(2024)08-0017-08

DOI: 10.7643/issn.1672-9242.2024.08.003

Time-Frequency Denoising Method for Penetration Overload Signals Based on Denoising Convolutional Neural Network (DnCNN)

ZHENG Hongliang^{1,2}, JIA Senqing³, GUO Yupeng^{1,2}, XUE Yingjie¹, HAN Jing^{1,2*}, ZHAO Heming^{1,2}, SHI Zhigang⁴

(1. School of Mechanical and Electrical Engineering, North University of China, Taiyuan 030051, China; 2. Shanxi Key Laboratory of High-end Equipment Reliability Technology, Taiyuan 030051, China; 3. Science and Technology on Electromechanical Dynamic Control Laboratory, Xi'an Institute of Electromechanical Information Technology, Xi'an 710065, China;
4. Hubei Space Sanjiang Honglin Detection and Control Co., Ltd., Hubei Xiaogan 432000, China)

ABSTRACT: The work aims to enhance the ability to accurately estimate rigid body overload signals from the penetration overload signals. A time-frequency denoising method based on feedforward denoising convolutional neural network (DnCNN) was proposed. In this method, firstly the short-time Fourier transform (STFT) was applied to extract the time-frequency images of the penetration overload signal so that the DnCNN network could make full use of these images to effectively estimate the time-frequency images of the rigid-body overload. Finally, the time-frequency images were converted back to the time domain

收稿日期: 2024-04-25; 修订日期: 2024-05-27

Received: 2024-04-25; Revised: 2024-05-27

基金项目: 山西省高端装备可靠性技术重点实验室研究基金 (446110103)

Fund: Shanxi Key Laboratory of High-end Equipment Reliability Technology (446110103)

引文格式: 郑宏亮, 贾森清, 郭宇朋, 等. 基于 DnCNN 的侵入过载时频去噪方法[J]. 装备环境工程, 2024, 21(8): 17-24.

ZHENG Hongliang, JIA Senqing, GUO Yupeng, et al. Time-frequency Denoising Method for Penetration Overload Signals Based on Denoising Convolutional Neural Network (DnCNN)[J]. Equipment Environmental Engineering, 2024, 21(8): 17-24.

*通信作者 (Corresponding author)

by inverse STFT to obtain the estimated rigid body overload signal. In the 5-Fold Cross-Validation, the proposed method had a mean absolute error (MAE) of 0.968% and a Pearson correlation coefficient (r) of 90.35% on the test set. Compared with low-pass filtering, ensemble empirical modal decomposition (EEMD) and wavelet transform methods, the proposed method performed better in denoising ability. Specifically, the average MAE of the proposed method was reduced by 1.82%, 1.00%, and 0.75%, while the average correlation coefficient r -value was improved by 47.81%, 17.48%, and 22.93%, respectively. The proposed method can accurately estimate the rigid body overload signal from the penetration overload and outperform low-pass filtering, EEMD and wavelet transform methods in denoising capability. In the denoising process, there is no need to adjust parameters and the denoising task can be automatically completed.

KEY WORDS: hard target penetration; penetration overload; denoising convolutional neural network; signal denoising; time-frequency analysis; k -Fold cross-validation

弹体侵彻靶体过程中的加速度（即侵彻过载）是攻坚武器及其防护研究的一个重要弹道环境参量。侵彻过载影响战斗部设计、炸药稳定性和智能引信的计层定深功能的实现^[1-3]。同时，防护工程中的遮弹层结构设计、材料优化等也需要依赖侵彻过载作为评估参量^[4]。侵彻过程中弹靶作用相当复杂，有多重振动信号作用在弹体上。因此，安装在引信内部的高 g 值加速度传感器测量的侵彻过载信号不仅包含弹体自身的刚体过载信号，还叠加了各种干扰噪声信号^[5-6]。弹体的刚体过载是弹在靶体内运动特性的表征，是侵彻弹体设计的重要参数，也是判断弹体是否侵入靶体以及侵入几层靶体的重要依据，因此常常需要单独提取进行研究。

在提取刚体过载信号时，常用的信号去噪方法包括低通滤波法^[7-9]、小波变换^[10-12]和经验模式分解（EMD）^[13]及其改进方法总体经验模式分解（EEMD）^[14-15]。低通滤波法基于刚体过载信号的低频特性^[16]，通过滤除高频无用噪声来提取刚体过载信号。其优点是简单实用，但缺点是无法滤除与刚体过载在频域上重叠的噪声。小波变换能够在时域和频域上捕捉信号的局部特征，从而更精确地提取刚体过载信号。若小波基函数或者阈值选取不当时，会导致提取结果不准确。经验模式分解（EMD）和总体经验模式分解（EEMD）方法无需预设基函数，但通常只能提供各个分量的形式，难以确定哪一个或哪几个分量对应于刚体过载信号，因此在实际使用中存在一定的局限性。

尽管上述方法均能估计出刚体过载信号，但还存在估计不准确的问题。卷积神经网络（CNN）是一种具有信号特征学习和非线性映射能力的深度学习基本架构，能够自适应地从数据中学习和提取规律，已被证明是信号处理的强大工具^[17-20]。在去噪方面，前馈去噪卷积神经网络（DnCNN）已在图像和信号领域取得成功^[21-23]。因此，本文考虑引入图像去噪领域的经典方法 DnCNN，从而提高准确估计刚体过载信号的能力。

本文针对当前去噪方法从侵彻过载中估计刚体过载时结果不准确的问题，提出了一种基于 DnCNN

的侵彻过载时频去噪方法。受 DnCNN 网络在图像去噪方面优异性能的启发，通过短时傅里叶变换（STFT）将一维侵彻过载信号转换为二维时频图像，使得 DnCNN 能够充分利用时频图像中的时频特征，最终准确估计出刚体过载信号，从而提高去噪的能力。此外，DnCNN 能够从数据中自适应学习和提取规律，在去噪过程中无需手动选择参数或进行人工干预^[24-25]，具有更强的自适应性。

1 DnCNN 去噪方法

1.1 DnCNN 侵彻过载去噪原理

侵彻过载信号是通过引信内的高 g 值加速度传感器测量得到的。在高速侵彻多层硬目标时，高 g 值加速度传感器测量的过载中不仅包含弹体自身的刚体过载信号，还叠加了多重振动信号，使得侵彻过载信号发生黏连。可将侵彻过载信号近似表示为弹体刚体过载信号和多重振动信号的叠加。

将一维侵彻过载信号转换为二维时频图像，一方面，可以同时表达信号的时间和频率信息特征，更直观地显示信号的时频特征；另一方面，有助于 DnCNN 学习二维时频图像的特征。在时频域中，侵彻过载信号可以描述为：

$$Y(t, f) = S(t, f) + N(t, f) \quad (1)$$

式中： $Y(t, f)$ 表示的是侵彻过载信号的时频图像； $S(t, f)$ 表示的是弹体刚体过载信号的时频图像； $N(t, f)$ 表示的是多重振动信号的时频图像，该多重振动信号由弹引系统结构振动响应和加速度传感器的振动信号等其他干扰噪声组成^[5-6]。去噪的过程为从侵彻过载信号中估计出弹体刚体过载信号。

DnCNN 是一种用于图像去噪的神经网络，它通过监督学习的方式，利用残差学习的思想训练 $R[Y(t, f)] \approx N(t, f)$ 映射函数来学习多重振动信号的时频图像，再利用 $S(t, f) = Y(t, f) - N(t, f)$ 估计出弹体刚体过载信号的时频图像。本文 DnCNN 的结构如图 1 所示，它具有输入层、中间层和输出层。

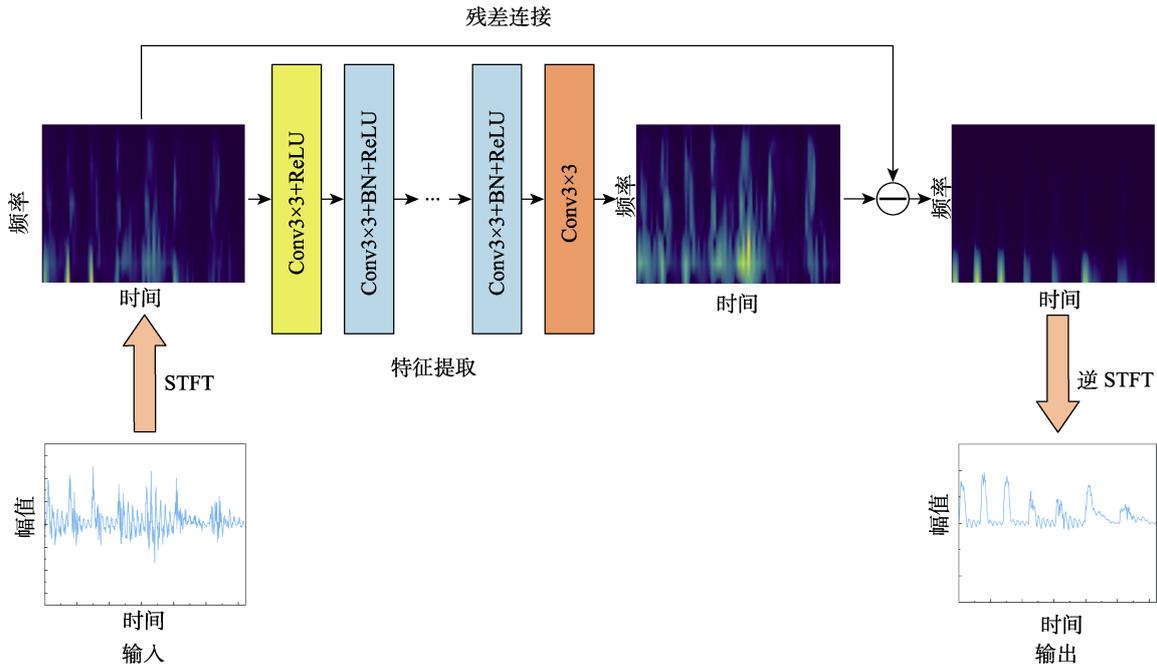


图 1 基于 DnCNN 的侵彻过载时频去噪总体流程
Fig.1 Time-frequency denoising process for penetration overload based on DnCNN

输入层包含 1 个 3×3 卷积层 (步长为 1), 具有 32 个特征图, 并采用线性整流激活函数 (ReLU)。输入层用于提取侵彻过载信号的时频图像 $Y(t, f)$ 的浅层特征。中间层包含 6 个 3×3 卷积层 (步长为 1), 具有 32 个特征图, 每个卷积层后依次进行批次归一化 (BN) 和 ReLU 激活函数。中间层用于提取浅层特征中的深层特征。输出层包含 1 个 3×3 卷积层 (步长为 1), 具有 2 个特征图。输出层负责对提取的深层特征进行重构, 最终输出多重振动信号的时频图像 $N(t, f)$ 。

DnCNN 的设计特点在于使用了 3×3 卷积核 (步长为 1), 这种卷积核在保持输入输出空间尺寸不变的同时, 提供了较好的感受野, 能够有效捕捉图像局部特征。通过在每个卷积层后添加 BN 层, 加速和稳定模型训练, 减少内部协变量偏移的影响, 提高了模型的泛化能力。ReLU 激活函数是一种神经网络中常用的激活函数, 它通过引入非线性, 使网络能够拟合更复杂的函数关系, 并减少梯度消失问题。此外, DnCNN 引入了残差学习策略, 不仅解决了网络深度增加导致性能下降的问题, 还提高了去噪性能。

1.2 DnCNN 去噪过程

使用训练过的 DnCNN 对侵彻过载信号进行去噪的流程如下。

步骤 1: 通过 STFT 将侵彻过载信号转换为二维时频图像。

步骤 2: 将转换后的侵彻过载信号的时频图像 $Y(t, f)$ 输入到 DnCNN 中, 得到估计的多重振动信号的时频图像 $\tilde{N}(t, f)$, 最后通过 $\tilde{S}(t, f) = Y(t, f) - \tilde{N}(t, f)$ 得

到估计的刚体过载时频图像 $\tilde{S}(t, f)$ 。

步骤 3: 对估计的刚体过载时频图像 $\tilde{S}(t, f)$ 进行逆 STFT, 得到估计的刚体过载信号。该去噪方法的总体流程如图 1 所示。

2 数据集的获取

本文通过仿真模型获取侵彻过载和刚体过载数据。此次仿真采用的弹体为截卵形弹体, 直径为 138 mm, 长径比为 4.88, CRH 为 2.68。由战斗部壳体、装药、引信、后盖等组成。引信经过简化, 由引信外壳、灌封材料、电路板和加速度计组成。加速度计等元器件安装固定于电路板感知侵彻过载信号。靶板的规格为 $3 \text{ m} \times 3 \text{ m} \times 0.3 \text{ m}$, 等效抗压强度 f_c 为 45 MPa。共布置 10 层靶板, 每个靶板间隔 1 m。弹引系统仿真模型如图 2 所示。

表 1 所示的 24 种工况条件包含了侵彻工况中较为常见和恶劣的情况。利用有限元仿真软件按表 1 所示的 24 种工况条件对弹引系统仿真模型进行数值仿

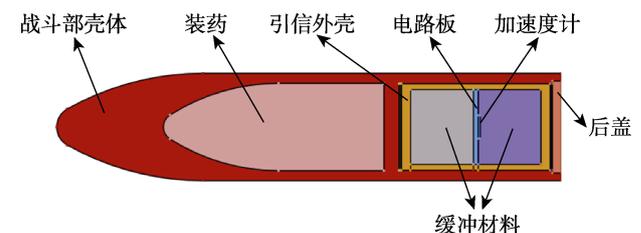


图 2 弹引系统仿真模型
Fig.2 Simulation model of warhead-fuze system

表 1 工况条件
Tab.1 Operating conditions

编号	侵彻着靶速度/(m·s ⁻¹)	侵彻着角/(°)	侵彻攻角/(°)
工况条件 1	800、900、1 000、1 100、1 200、1 300、1 400、1 500	0	0
工况条件 2	800、900、1 000、1 100、1 200、1 300、1 400、1 500	10	0
工况条件 3	800、900、1 000、1 100、1 200、1 300、1 400、1 500	10	2

真计算。从计算结果中提取加速度计过载和战斗部壳体过载各 24 条数据,分别代表侵彻过载和刚体过载。为了评估模型在不同噪声程度下对侵彻过载的去噪能力,在侵彻过载上添加了不同信噪比(SNR=[0, 2, 4, 6, 8, 10])的高斯噪声,共得到 168 组数据,包括未添加噪声和已添加噪声的侵彻过载信号。每组数据中包括侵彻过载和刚体过载,其中侵彻过载作为训练样本,刚体过载作为训练标签。表 2 和图 3 显示了数据集中不同工况条件下的过载信号。工况 1~4 代表侵彻工况逐渐变差,侵彻弹体能够穿过的靶板层数越来越少,所得到的侵彻过载信号质量也随之变差,并且通过添加不同信噪比的高斯噪声,来模拟实际

侵彻过程中可能出现的信号扰动,信噪比越低表示信号扰动越大。

表 2 不同工况条件的过载信号信息
Tab.2 Overload signal information for different operating conditions

编号	侵彻着靶速度/(m·s ⁻¹)	侵彻着角/(°)	侵彻攻角/(°)	SNR
工况 1	800	0	0	无
工况 2	800	0	0	10
工况 3	1 200	10	0	6
工况 4	1 500	10	2	0

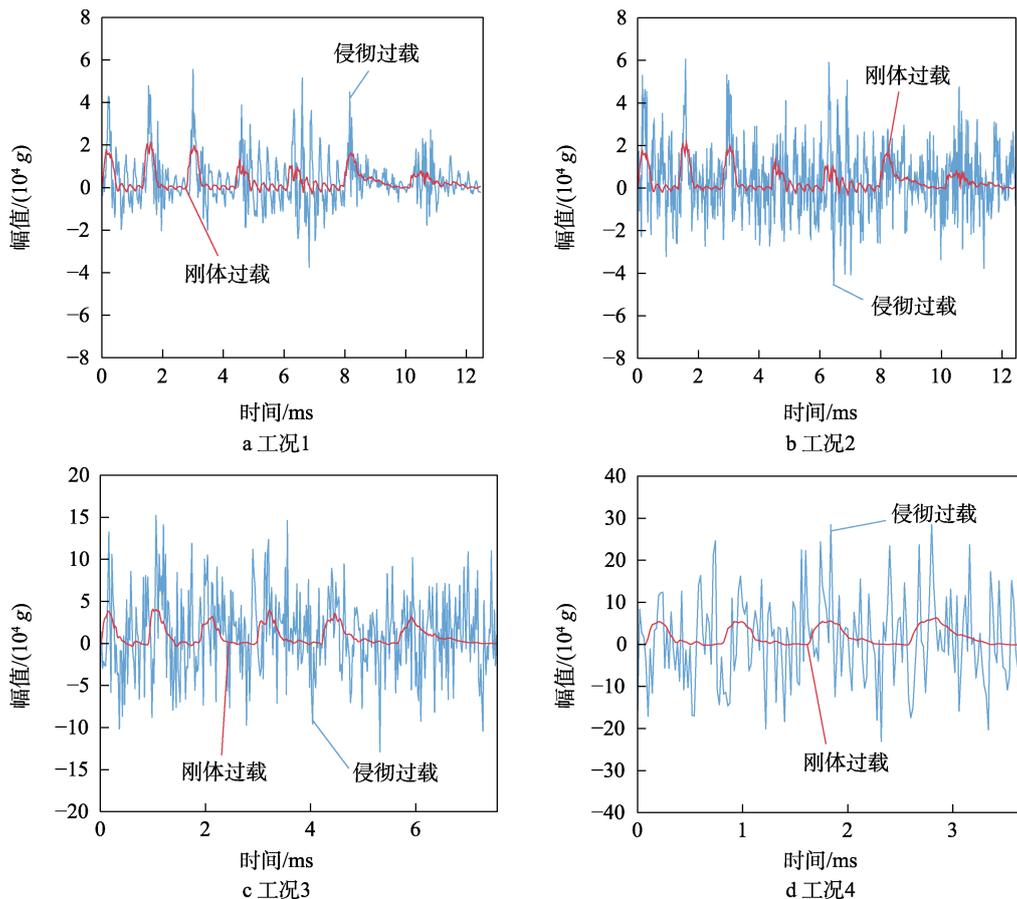


图 3 不同工况条件的过载信号曲线

Fig.3 Overload signal curves for different operating conditions: a) test 1; b) test 2; c) test 3; d) test 4

3 去噪方法性能验证

3.1 数据预处理

模型的输入和输出都为过载信号的时频图像,因

此需要对过载信号进行 STFT 变换,STFT 的计算方法如下:

$$STFT[t, f] = \sum_{n=0}^{N-1} x[n]h[n-t]e^{-j2\pi fn} \quad (2)$$

式中: $x[n]$ 是在时间 n 的输入信号; $h[n]$ 是时间 n 的窗函数; n 表示窗函数的宽度; t 表示时域和频域中的时间, 是时频图像的宽; f 表示频率的离散值, 是时频图像的高。因此, 时频图像 $STFT[t, f]$ 的维度大小为 $t \times f \times 2$, 其中实部和虚部作为 2 个独立的通道输入到 DnCNN, 使其能够同时学习信号的时间和频率信息。

由于不同工况条件的过载信号变化范围较大, 直接使用这些数据训练模型将显著影响训练的准确性和训练速度。因此, 有必要通过按比例缩放所有数据, 并将其映射在 $[-1, 1]$ 的范围内, 以防止模型过拟合。本文使用的归一化公式如式 (3) 所示。

$$x_k = \frac{x}{|x|_{\max}} \quad (3)$$

式中: x_k 表示归一化后过载信号的时频图像; x 表示归一化前过载信号的时频图像; $|x|_{\max}$ 表示归一化前过载信号的时频图像绝对值的最大值。

3.2 去噪性能评估指标

本文使用 2 个量化指标来评估去噪结果, 分别为平均绝对误差 (η_{MAE}) 和 Pearson 相关系数 (r)。MAE 用于衡量估计值和实际值之间的差异, 值越小表示估计值越准确。相关系数 r 用于衡量训练标签刚体过载和估计的刚体过载之间的波形相似性, r 越接近 1, 2 个信号的波形就越相似。量化指标的计算公式:

$$\eta_{MAE} = \frac{1}{n} \sum_n |S_i(t, f) - \tilde{S}_i(t, f)| \quad (4)$$

$$r(S, \tilde{S}) = \frac{\text{Cov}(S, \tilde{S})}{\sqrt{\text{Var}[S]\text{Var}[\tilde{S}]}} \quad (5)$$

式中: $S_i(t, f)$ 表示训练标签刚体过载的时频图像; $\tilde{S}_i(t, f)$ 表示估计的刚体过载的时频图像; S 表示训练标签刚体过载信号; \tilde{S} 表示估计的刚体过载信号; $\text{Cov}(S, \tilde{S})$ 表示 2 个信号的协方差; $\text{Var}[S]$ 表示训练标签刚体过载信号的方差; $\text{Var}[\tilde{S}]$ 表示估计的刚体过载信号的方差。

3.3 模型性能评估

为了准确评估模型在数据集上的泛化能力和去噪性能, 采用了 k -Fold 交叉验证法, k -Fold 交叉验证法的流程如图 4 所示。首先, 将整个样本数据集平均划分为 k 个子集, 每个子集轮流作为测试集, 而其余子集作为训练集。其次, 模型分别在 k 个划分的训练集中进行训练, 并将训练得到的模型在对应的 k 个测试集进行测试。最终取 k 次测试结果的平均值作为模型性能的最终评估。为了减少计算量, k 通常取为 5。

DnCNN 的训练和测试在 pytorch 框架下进行, 训练时使用 Adam 优化器, 学习率为 0.001, 迭代周期

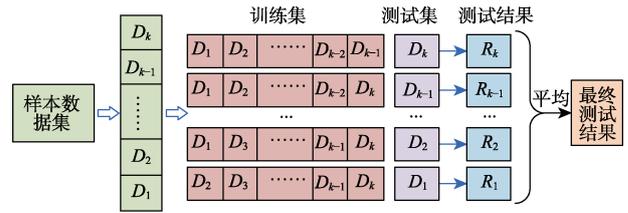


图 4 k -Fold 交叉验证法的流程
Fig.4 k -Fold cross-validation process

表 3 5-Fold 交叉验证结果
Tab.3 Results of 5-Fold cross-validation

评估指标	R_1	R_2	R_3	R_4	R_5	均值
$\eta_{MAE}/\%$	0.886	1.014	0.897	0.993	1.048	0.968
$r/\%$	90.59	89.13	91.26	88.77	89.85	90.35

数为 200, 批处理大小为 2。表 3 显示了 5-Fold 交叉验证的结果, 其中 DnCNN 的最终测试结果 MAE 均值为 0.968%, 相关系数 r 均值为 90.35%。结果显示, DnCNN 在数据集上表现出良好的去噪性能和泛化能力, 能够有效估计不同工况条件下侵彻过载信号中的刚体过载信号。

3.4 与其他方法的比较

为了进一步评估所提方法的去噪性能, 将其与 3 种去噪方法 (低通滤波、小波变换和 EEMD 方法) 进行了比较。对于低通滤波方法, 对图 3 过载进行频谱分析, 确定了截止频率为 2 000 Hz, 频谱分析结果如图 5 所示。在使用小波变换时, 计算了 3 种阈值类型以及软阈值和硬阈值函数。然后, 选择去噪效果最好的 Heursure 阈值和软阈值函数的组合进行演示。在使用 EEMD 方法时, 原始信号被分解为多个 IMF, 并选择了效果最好的多个 IMF 组合进行重构。选取 5-Fold 交叉验证中表现最佳的模型与其他方法进行对比。

应用不同去噪方法对图 3 侵彻过载的去噪性能评估指标结果见表 4。从工况 1~4 的去噪性能评估指标结果显示, 4 种方法的相关系数 r 呈现下降的趋势, MAE 呈现上升的趋势。该趋势表明, 侵彻过载信号质量越好, 4 种方法的去噪效果越好。结合图 5 分析, 该现象是由于侵彻过载信号质量越高, 信号中的多重振动信号含量就越低, 因此更容易准确估计出刚体过载信号。4 种方法对图 3 侵彻过载估计的刚体过载信号如图 6 所示。低通滤波在 4 种工况中估计的刚体过载信号的表现最差, 其原因在于低通滤波无法滤掉与刚体过载信号在频域上发生混叠的多重振动信号。EEMD 估计的刚体过载信号在相关系数 r 方面整体比小波变换好, 但在 MAE 方面整体比小波变换差, 说明 EEMD 从波形上能较为准确地描述刚体过载信号, 但估计的信号幅值会有所失真, 原因可能在于所选择的多个 IMF 组合分量对不同工况的侵彻过载信号

表4 不同去噪方法的去噪性能评估指标结果
Tab.4 Results of denoising performance evaluation metrics of different denoising methods

方法	%									
	工况1		工况2		工况3		工况4		均值	
	η_{MAE}	r								
DnCNN	0.63	97.61	0.81	95.32	0.61	95.82	0.55	95.82	0.65	96.14
低通滤波	2.28	61.06	3.01	48.30	2.56	47.88	2.03	36.08	2.47	48.33
EEMD	1.96	92.00	2.39	77.47	1.45	68.24	0.78	76.93	1.65	78.66
小波变换	1.29	90.00	1.89	74.84	1.59	61.28	0.83	66.73	1.40	73.21

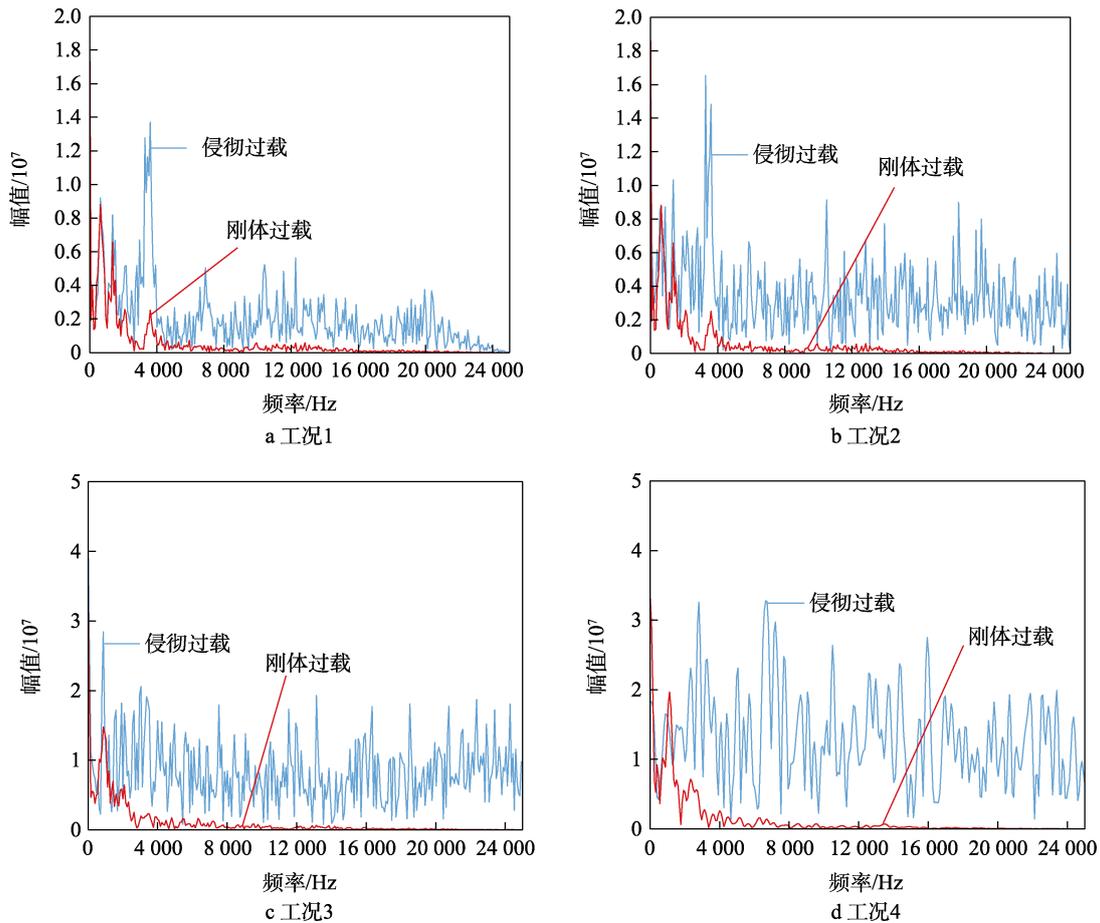
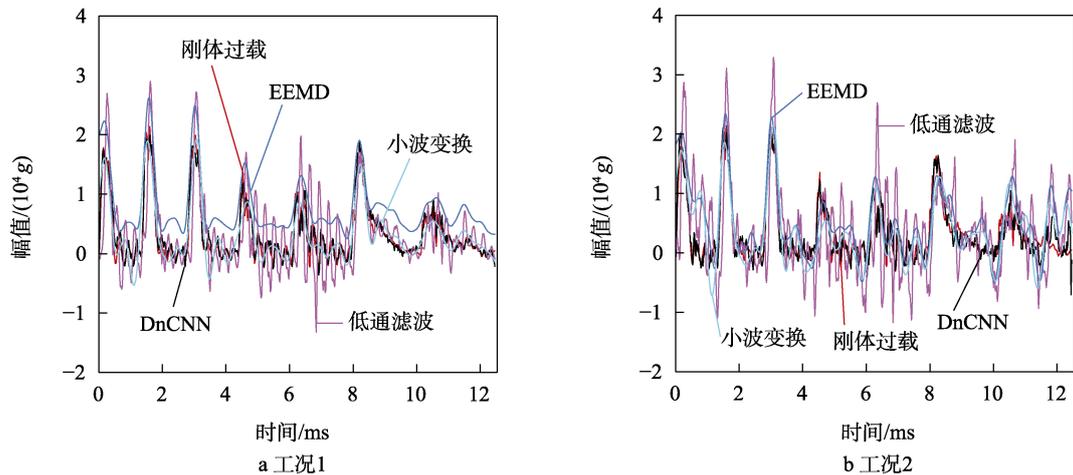


图5 不同工况条件的过载信号频谱分析结果

Fig.5 Spectral analysis results of overload signals under different operating conditions: a) test 1; b) test 2; c) test 3; d) test 4



a 工况1

b 工况2

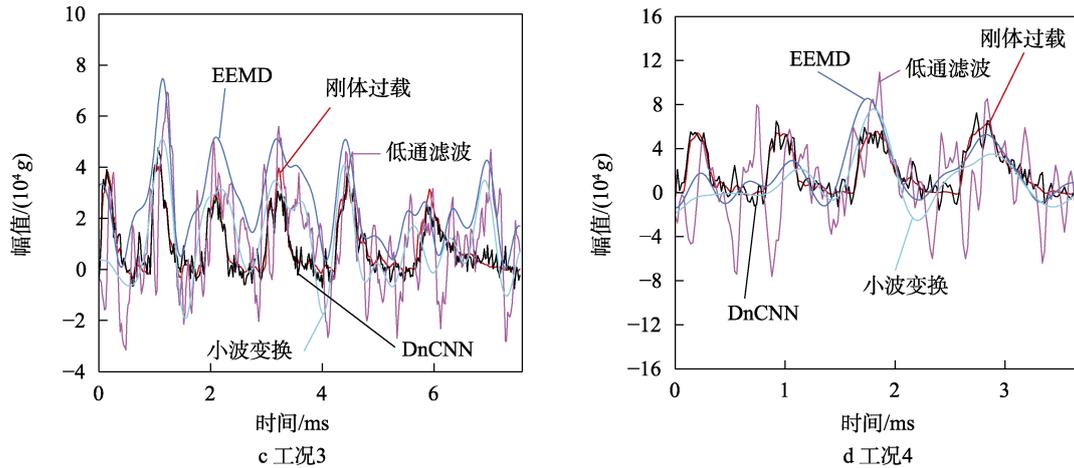


图 6 不同去噪方法的去噪效果

Fig.6 Denoising effect of different denoising methods: a) test 1; b) test 2; c) test 3; d) test 4

的适应性不足。小波变换虽然能够较为准确地估计出刚体过载信号的幅值,但在波形上还存在少量的振荡,原因可能在于所选择的阈值方法无法完全滤除无效信号。与低通滤波、EEMD 和小波变换方法相比, DnCNN 估计的刚体过载信号在 MAE 和相关系数 r 方面是最佳的,平均 MAE 分别降低了 1.82%、1.00%、0.75%, 而平均相关系数 r 分别提高了 47.81%、17.48%、22.93%。这表明 DnCNN 具有更高的去噪水平和更小的波形失真,其主要原因在于 DnCNN 能够有效地学习侵彻过载时频图像与刚体过载时频图像之间的映射关系,从而准确估计出刚体过载信号。

4 结语

本文提出一种基于 DnCNN 的侵彻过载时频去噪方法,并在叠加了不同 SNR 的高斯噪声仿真数据集上进行了验证。结果表明,所提方法在数据集上表现出良好的泛化性能,同时在去噪结果上优于低通滤波、EEMD 和小波变换方法,能够准确估计刚体过载信号,为侵彻过载信号的分析处理提供了一种新的解决方案。未来的工作将继续研究所提出的方法对侵彻过载信号的域适应能力,以将其应用范围扩大到多种工况条件的侵彻过载信号。

参考文献:

- [1] 陈小伟, 金建明. 动能深侵彻弹的力学设计(II): 弹靶的相关力学分析与实例[J]. 爆炸与冲击, 2006, 26(1): 71-78.
CHEN X W, JIN J M. Mechanics of Structural Design of EPW(II): Analyses on the Design of EPW Projectiles, concrete Targets and Examples[J]. Explosion and Shock Waves, 2006, 26(1): 71-78.
- [2] 王佳乐, 杨富锋, 王燕, 等. 2 种方式装药弹丸侵彻混凝

- 土的安全性仿真[J]. 兵工自动化, 2021, 40(10): 34-40.
WANG J L, YANG F F, WANG Y, et al. Safety Simulation of 2 Kinds of Charge Projectile Penetrating Concrete[J]. Ordnance Industry Automation, 2021, 40(10): 34-40.
- [3] 游金川, 李东杰, 欧阳科, 等. 侵彻引信炸点精确控制技术[J]. 中国惯性技术学报, 2016, 24(1): 114-118.
YOU J C, LI D J, OUYANG K, et al. Precise Detonating-Control Technique for Hard-Target Penetration Fuze[J]. Journal of Chinese Inertial Technology, 2016, 24(1): 114-118.
- [4] 黄家蓉, 刘瑞朝, 何翔, 等. 侵彻过载测试信号的数据处理方法[J]. 爆炸与冲击, 2009, 29(5): 555-560.
HUANG J R, LIU R C, HE X, et al. A New Data Processing Technique for Measured Penetration Overloads[J]. Explosion and Shock Waves, 2009, 29(5): 555-560.
- [5] 程祥利, 刘波, 赵慧, 等. 侵彻战斗部-引信系统动力学建模与仿真[J]. 兵工学报, 2020, 41(4): 625-633
CHENG X L, LIU B, ZHAO H, et al. Dynamic Modeling and Simulation for Penetration Warhead-Fuze System[J]. Acta Armamentarii, 2020, 41(4): 625-633.
- [6] 刘伟钊, 李蓉, 牛兰杰, 等. 硬目标侵彻起爆控制技术研究现状及展望[J]. 兵工学报, 2023, 44(6): 1602-1619.
LIU W Z, LI R, NIU L J, et al. Research Status and Prospect of Hard-Target Penetration Initiation Control Technology[J]. Acta Armamentarii, 2023, 44(6): 1602-1619.
- [7] 赵海峰, 张亚, 李世中, 等. 侵彻弹体频率特性分析及过载信号处理[J]. 中国机械工程, 2015, 26(22): 3034-3039.
ZHAO H F, ZHANG Y, LI S Z, et al. Frequency Characteristics Analyses of Penetrating Missile and Penetration Overload Signal Processing[J]. China Mechanical Engineering, 2015, 26(22): 3034-3039.
- [8] 徐鹏, 祖静, 范锦彪. 高速动能弹侵彻硬目标加速度测试技术研究[J]. 振动与冲击, 2007, 26(11): 118-122.
XU P, ZU J, FAN J B. Study on Acceleration Test Technique of High Velocity Kinetic Energy Projectile Pene-

- trating into Hard Target[J]. *Journal of Vibration and Shock*, 2007, 26(11): 118-122.
- [9] 王成华, 陈佩银, 徐孝诚. 侵彻过载实测数据的滤波及弹体侵彻刚体过载的确定[J]. *爆炸与冲击*, 2007, 27(5): 416-419.
WANG C H, CHEN P Y, XU X C. Filtering of Penetration Deceleration Data and Determining of Penetration Deceleration on the Rigid-Body[J]. *Explosion and Shock Waves*, 2007, 27(5): 416-419.
- [10] YAN R Q, GAO R X, CHEN X F. Wavelets for Fault Diagnosis of Rotary Machines: A Review with Applications[J]. *Signal Processing*, 2014, 96: 1-15.
- [11] 王杰, 李蓉, 黄惠东. 基于小波系数的粘连信号穿层特征提取方法[J]. *探测与控制学报*, 2016, 38(1): 13-17.
WANG J, LI R, HUANG H D. Layer Penetrating Adhesion Signal Characteristic Extracting Based on Wavelet Coefficients[J]. *Journal of Detection & Control*, 2016, 38(1): 13-17.
- [12] 李飞胤. 多次短间隔冲击-振动耦合力学试验理论与方法研究[D]. 南京: 南京理工大学, 2021.
LI F Y. Study on Theory and Method of Coupling Mechanical Test of Multiple Short-Interval Impact-Vibration[D]. Nanjing: Nanjing University of Science and Technology, 2021.
- [13] LEI Y G, LIN J, HE Z J, et al. A Review on Empirical Mode Decomposition in Fault Diagnosis of Rotating Machinery[J]. *Mechanical Systems and Signal Processing*, 2013, 35(1/2): 108-126.
- [14] PAN L, LIU K, JIANG J F, et al. A De-Noising Algorithm Based on EEMD in Raman-Based Distributed Temperature Sensor[J]. *IEEE Sensors Journal*, 2017, 17(1): 134-138.
- [15] WARREN T L, FORRESTAL M J, RANGLES P W. Evaluation of Large Amplitude Deceleration Data from Projectile Penetration into Concrete Targets[J]. *Experimental Mechanics*, 2014, 54(2): 241-253.
- [16] ZHANG D B, LI J, WEI X K, et al. Research on Dynamic Test of Hyper-Velocity Impact Penetration Acceleration Signal[J]. *IEEE Access*, 2020, 8: 194879-194893.
- [17] GUO Y, DAVY A, FACCILOLO G, et al. Fast, Nonlocal and Neural: A Lightweight High Quality Solution to Image Denoising[J]. *IEEE Signal Processing Letters*, 2021, 28: 1515-1519.
- [18] ZHU W Q, MOUSAVI S M, BEROZA G C. Seismic Signal Denoising and Decomposition Using Deep Neural Networks[J]. *IEEE Transactions on Geoscience and Remote Sensing*, 2019, 57(11): 9476-9488.
- [19] WEN J J, YAO H P, WU B, et al. A Deep Learning Approach to Recover High-g Shock Signals from the Faulty Accelerometer[J]. *IEEE Sensors Journal*, 2020, 20(4): 1761-1769.
- [20] ZHANG Q, XIAO J Y, TIAN C W, et al. A Robust Deformed Convolutional Neural Network (CNN) for Image Denoising[J]. *CAAI Transactions on Intelligence Technology*, 2023, 8(2): 331-342.
- [21] ZHANG K, ZUO W M, CHEN Y J, et al. Beyond a Gaussian Denoiser: Residual Learning of Deep CNN for Image Denoising[J]. *IEEE Transactions on Image Processing*, 2017, 26(7): 3142-3155.
- [22] GÜNEN M A, BEŞDOK E. Effect of Denoising Methods for Hyperspectral Images Classification: DNCNN, NGM, CSF, BM3D and Wiener[J]. *Mersin Photogrammetry Journal*, 2023, 5(1): 1-9.
- [23] ZENG T Y, LI J Y, HU M S, et al. Toward Higher Performance for Channel Estimation with Complex DnCNN[J]. *IEEE Communications Letters*, 2020, 24(1): 198-201.
- [24] JIANG G Q, HE H B, YAN J, et al. Multiscale Convolutional Neural Networks for Fault Diagnosis of Wind Turbine Gearbox[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(4): 3196-3207.
- [25] LI S C, LIU K, JIANG J F, et al. An Ameliorated Denoising Scheme Based on Deep Learning for Φ -OTDR System with 41-Km Detection Range[J]. *IEEE Sensors Journal*, 2022, 22(20): 19666-19674.