

# 一种振动信号降噪的堆叠降噪自编码器方法\*

赵志宏<sup>1,2</sup>, 李乐豪<sup>1</sup>, 杨绍普<sup>2</sup>, 赵敬娇<sup>1</sup>

(1. 石家庄铁道大学信息科学与技术学院 石家庄, 050043)

(2. 石家庄铁道大学省部共建交通工程结构力学行为与系统安全国家重点实验室 石家庄, 050043)

**摘要** 为了解决振动信号降噪问题, 提出一种基于堆叠降噪自编码器的方法。结合 PReLU 激活函数和批标准化对传统堆叠降噪自编码器进行改进, 增强了模型的特征提取和信号重构能力。堆叠降噪自编码器方法使用编码器提取含噪振动信号中的特征, 使用解码器进行信号重构, 从而实现振动信号降噪。在正弦信号、调幅信号和轴承故障仿真信号下进行降噪实验, 取得了优于传统降噪方法的降噪效果。利用实测的轴承振动信号进行实验, 在较强噪声情况下仍然可以对添加噪声的轴承振动信号进行有效降噪。实验结果表明, 提出的堆叠降噪自编码器方法可以应用于振动信号降噪。

**关键词** 自编码器; 降噪; 深度神经网络; 振动信号

**中图分类号** TN911.7; TH165+.3

## 引言

振动信号中蕴含着对机械部件故障诊断和寿命预测有用的健康状态信息, 但实测的振动信号中往往由于各种原因充斥着不同程度的噪声, 对故障的诊断造成困难。因此, 对振动信号进行降噪尤为重要。赵志宏等<sup>[1]</sup>将基于经验模态分解(empirical mode decomposition, 简称 EMD) 阈值降噪方法和 Savitzky-Golay 滤波降噪方法相结合, 同时对高频噪声和低频噪声进行降噪处理。贾亚超等<sup>[2]</sup>提出了一种基于灰度准则与集成经验模态分解(ensemble empirical mode decomposition, 简称 EEMD) 的降噪方法, 有效提高了信噪比, 降低了噪声对振动信号特征提取的干扰。向北平等<sup>[3]</sup>提出了一种基于样本熵的改进小波包阈值去噪算法, 能够获得较好的去噪效果, 有效地还原了信号的转动特征频率与故障特征频率。

传统降噪方法对于低噪声的信号具有一定的降噪效果, 但是对于强噪声信号的降噪效果不理想。Hinton 等<sup>[4]</sup>提出了具有非常强大学习能力的深度学习学习方法, 可以提取更加抽象的特征。Ranzato 等<sup>[5]</sup>提出的堆叠自编码器(stacked denoising auto-encoder, 简称 SDAE) 是一种经典的无监督深度学习模型, 得益于自编码器强大的特征提取能力, 被广泛应用于图像分类<sup>[6-7]</sup>、视频异常监测<sup>[8]</sup>、故障诊断以及图像降噪等领域。

在故障诊断领域, 文献[9-10]利用了堆叠降噪

自编码器中编码器的特征提取能力, 从振动信号中提取特征对故障进行分类。

在图像降噪领域, Xie 等<sup>[11]</sup>利用堆叠降噪自编码器对含有高斯白噪声的图像进行降噪, 并对叠加了文本的图像进行去除文字。Li<sup>[12]</sup>使用堆叠降噪自编码器在大型图像数据库 CIFAR-100 的灰度版本上进行训练, 获得了极好的降噪效果。马红强等<sup>[13]</sup>引入批标准化和残差学习改进堆叠降噪自编码器, 降低了网络的训练难度, 提高了图像的降噪性能。考虑到堆叠降噪自编码器在故障诊断和图像降噪中的成功应用, 笔者将堆叠降噪自编码器引入振动信号降噪, 提出一种利用带参数的修正线性单元(parametric rectified linear unit, 简称 PReLU) 激活函数和批标准化(batch normalization, 简称 BN) 改进的堆叠降噪自编码器振动信号降噪方法。本方法可以有效地降低振动信号的噪声, 将原始信号从含噪信号中还原出来, 降噪能力更强, 和原始信号相似程度更高。

## 1 堆叠降噪自编码器

### 1.1 传统自编码器

传统自编码器(auto-encoder, 简称 AE) 是一种目标为输出值与输入值相同的神经网络。其结构如图 1 所示, 由编码器和解码器两部分组成。

编码器提取特征的过程为

\* 国家自然科学基金资助项目(11972236, 11790282)

收稿日期: 2020-09-02; 修回日期: 2021-01-10




图1 传统自编码器的网络结构  
Fig.1 Architectures of the AE

$$h = f(x) = s(\mathbf{w}_1 x + b_1) \quad (1)$$

解码器重构的过程为

$$r = g(h) = s(\mathbf{w}_2 h + b_2) \quad (2)$$

其中  $r$  为  $x$  的重构。

传统自编码器的最理想状态是使  $r$  和  $x$  一致, 所以其损失函数的目标为最小化  $r$  和  $x$  的误差  $L(x, r)$ 。若传统自编码器采用  $r$  和  $x$  之间的均方误差, 其损失函数为

$$J(\mathbf{W}, b) = L(x, r) = \frac{1}{n} \sum \|x - r\|_2^2 \quad (3)$$

### 1.2 降噪自编码器

降噪自编码器 (denoising auto-encoder, 简称 DAE) 在自编码器的输入端添加某种噪声得  $\tilde{x}$ , 使得自编码器的目标为最小化  $L(x, g(f(\tilde{x})))$ 。降噪自编码器与传统自编码器相比, 其损失大于传统自编码器, 但是降噪自编码器能学到更多有关数据分布的有用信息, 从而实现降噪的鲁棒性。

降噪自编码器损失函数的计算图如图 2 所示。其中引入一个损坏过程  $C(\tilde{x}|x)$ , 这个条件分布代表给定数据样本  $x$  产生包含噪声的样本  $\tilde{x}$  的概率, 常见的加入噪声的方法是添加高斯噪声和置零, 笔者采取添加高斯噪声。降噪自编码器根据以下过程, 使用训练数据对  $(\tilde{x}, x)$  学习  $f$  和  $g$ : 首先, 从训练数据中抽取一个训练样本  $x$ ; 其次, 从  $C(\tilde{x}|x)$  获得一个含噪样本  $\tilde{x}$ ; 最后, 将  $(\tilde{x}, x)$  作为训练样本, 利用  $L(x, r)$  来更新自编码器  $f$  和  $g$  中的权值和偏置。




图2 降噪自编码器损失函数的计算图  
Fig.2 The computational graph of the cost function for a DAE

### 1.3 堆叠降噪自编码器

传统降噪自编码器由一层编码器和一层解码器组成。如果将一个训练好的降噪自编码器中的编码器的输出作为下一个自编码器的输入, 然后利用最小重构误差的原则进行训练, 以此将多个自编码器进行堆叠, 即逐层贪婪训练<sup>[14]</sup>, 直至所有的自编码器训练完成, 就可以得到具有多层的堆叠降噪自编码器, 其中每一层的训练都是无监督的。

堆叠自编码器相较于传统自编码器有着更深的网络结构, 具有更强的特征学习能力和泛化能力。图 3 为堆叠降噪自编码器的结构和逐层训练过程的示意图, 输入含噪的训练样本  $\tilde{x}$ , 经过多层对称结构的堆叠降噪自编码器映射为重构向量  $r$ , 其中的隐含层参数在自编码的训练后被固定。

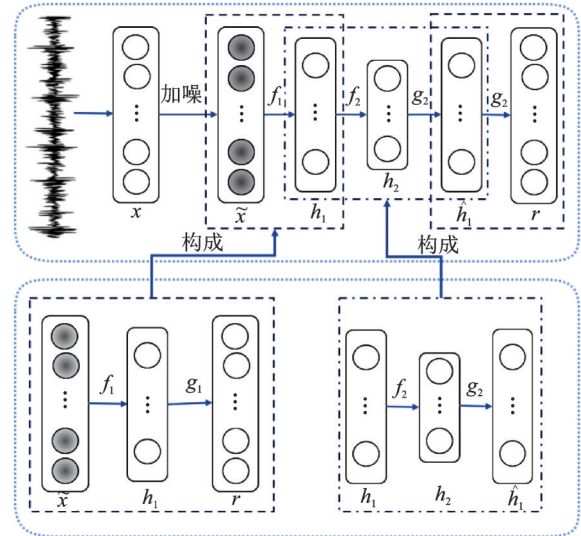


图3 堆叠降噪自编码器的网络结构和逐层训练示意图  
Fig.3 Architectures of the SDAE and schematic diagram of layer by layer training

## 2 堆叠降噪自编码器降噪方法

### 2.1 激活函数的选择

传统自编码器的激活函数常常采用 sigmoid 函数或修正线性单元 (rectified linear unit, 简称 ReLU) 函数, 其中 sigmoid 函数有容易出现梯度消失、消耗大量计算资源等问题<sup>[15]</sup>。ReLU 激活函数为

$$\text{ReLU}(x_i) = \begin{cases} x_i & (x_i > 0) \\ 0 & (x_i < 0) \end{cases} \quad (4)$$

ReLU 激活函数可以在神经元接收到负信号时, 使神经元处于抑制状态, 即置零; 当接收正信号时, 使神经元原样输出。因此, ReLU 可以提取到一个稀疏的特征<sup>[16]</sup>, 但是对于堆叠降噪自编码来说, 过

度稀疏的特征会对解码器生成样本造成负面影响,使得拟合程度不够。

PReLU<sup>[17]</sup>激活函数为

$$\text{PReLU}(x_i) = \begin{cases} x_i & (x_i > 0) \\ a_i x_i & (x_i < 0) \end{cases} \quad (5)$$

式(5)中  $a_i$  由动量方法更新

$$\Delta a_i = \mu \Delta a_i + \epsilon \partial \epsilon / \partial a_i \quad (6)$$

其中:  $\mu$  为动量;  $\epsilon$  为学习率;  $\epsilon$  为目标函数。

ReLU 和 PReLU 激活函数的区别如图 4 所示,可以看出 PReLU 激活函数允许负值输出,同时 PReLU 相较于 ReLU 仅仅增加了非常少量的参数,所以计算量的增加微乎其微,网络过拟合的风险不大,可以避免特征过度稀疏导致的拟合程度较差,并且不影响模型的泛化性能。




图 4 ReLU 和 PReLU 的区别

Fig.4 The difference between ReLU and PReLU

### 2.2 批标准化

为解决堆叠降噪自编码器训练过程中容易出现的梯度爆炸和梯度消失等问题,笔者采用了批标准化<sup>[18]</sup>方法。批标准化通过对输入进行白化预处理

$$\tilde{x} = (x - E(x)) / \sqrt{\text{Var}(x) + \epsilon} \quad (7)$$

其中:  $E(x)$  为其中一批输入  $x$  的平均值;  $\text{Var}(x)$  为该批次数据的方差;  $\epsilon$  为极小的正数,以避免分母为零。

使该层神经元的输出既不过分大也不过分小,均值为 0,标准差为  $1 + \epsilon$ 。白化预处理往往会削弱网络的性能,为了提升模型的表达能力,引入了“比例及平移”操作

$$y = \lambda \tilde{x} + \beta \equiv \text{BN}_{\lambda, \beta}(x) \quad (8)$$

其中:  $\lambda, \beta$  由迭代训练更新学习。

经过“比例及平移”操作,使得网络兼顾了较强的非线性表达能力,避免了陷入非线性区间两头使得网络收敛速度太慢。

### 2.3 堆叠降噪自编码器方法

堆叠降噪自编码器降噪方法流程如图 5 所示,步骤如下:①生成仿真信号或在较为理想的实验环境下采集到低噪声信号,利用这些信号生成含噪训练数据集和含噪测试数据集;②确定堆叠降噪自

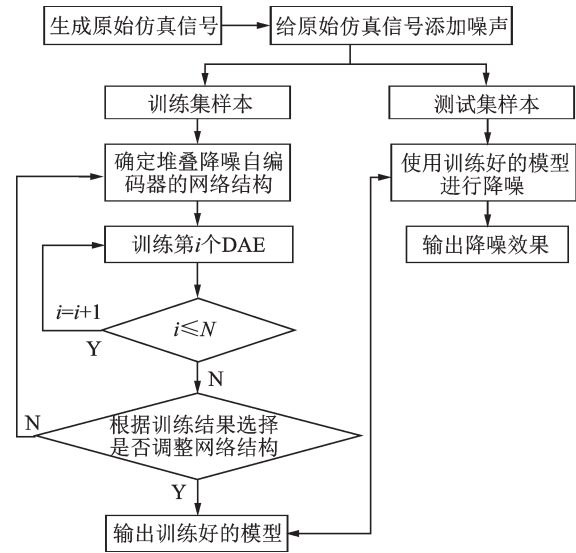


图 5 堆叠降噪自编码器方法流程

Fig.5 SDAE method flow

码器的网络结构,选择超参数,并利用训练数据集逐层训练;③根据训练数据集的降噪效果选择是否调整参数,如果效果不好则调整参数转至第 2 步,效果符合预期则进行第 4 步;④利用学习到的模型对测试数据集进行降噪,并输出结果。

为了测试本研究方法的性能,使用正弦信号、调制信号添加不同程度的高斯白噪声进行仿真降噪实验。采用降噪后的信噪比(signal noise ratio,简称 SNR)和均方根误差(root mean squared error,简称 RMSE)作为降噪性能的评价标准。

$$\text{SNR} = 10 \lg(P_s / P_n) \quad (9)$$

$$\text{RMSE} = \sqrt{\frac{1}{N} \sum_{i=1}^N (s_1 - s_0)^2} \quad (10)$$

其中:  $P_s$  为原始信号的有效功率;  $P_n$  为降噪后噪声的有效功率;  $s_1$  为原始信号;  $s_0$  为降噪后的信号;  $N$  为信号长度。

笔者采用的模型结构见图 6,采用 3 个自编码器

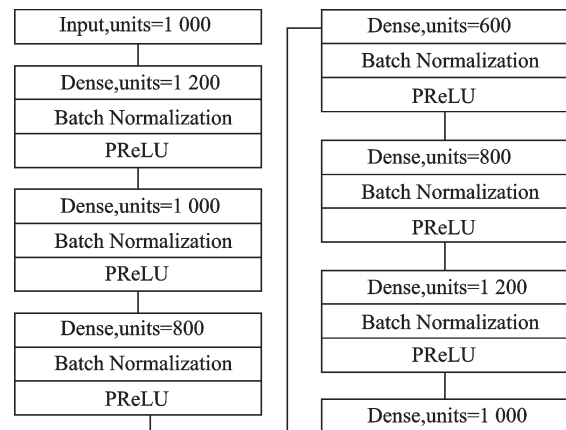


图 6 本研究方法所采用的模型

Fig.6 The model used in this method

进行堆叠,并在各个全连接层之间添加批标准化层用来加快网络训练避免过拟合,使用PReLU激活函数避免过度稀疏的特征对解码器造成负面影响。

### 3 仿真信号降噪实验

#### 3.1 正弦信号降噪实验

采用的仿真正弦信号为

$$x(t) = 2 \sin(10\pi t) \quad (11)$$

采样频率为1 kHz,采样时间为20 s,采用滑动窗口取样,步长为1,每个样本1 000个采样点,样本数目为10 000个。给这10 000个样本依次添加不同程度的高斯噪声,构造出信噪比为-20, -15, -10, -5, 0, 5, 10, 15和20 dB的9种含噪信号,将9种含噪信


号组合为含有90 000个样本的训练集,再按照制作训练集的方法制作同样数量的测试集。表1为本研究方法文献[2]中的EEMD方法、相关系数法对不同含噪正弦信号降噪后的SNR和RMSE进行对比,可以看出,本研究方法对于正弦信号的还原相较于传统方法有着明显优势。对于较低信噪比的仿真信号,本研究方法降噪后的信号比传统方法信噪比更高,时域波形更光滑;随着含噪信号的SNR增高,本研究方法也能继续保持更好的降噪效果。在强噪声的情况下,改进的EEMD方法降噪效果不是很理想,相关系数法在噪声低于-15 dB的情况下已经近乎于失效,而堆叠降噪自编码器方法仍然有效;在低噪声的情况下,堆叠降噪自编码器方法相较于EEMD方法和相关系数法可以获得更高的SNR和更低的RMSE。

表1 正弦信号仿真结果

Tab.1 Simulation results of sinusoidal signals


降噪前 SNR/dB	本研究方法		EEMD方法		相关系数法	
	降噪后 SNR/dB	RMSE	降噪后 SNR/dB	RMSE	降噪后 SNR/dB	RMSE
-20	5.994	0.621	-4.853	1.235	-19.086	6.357
-15	10.894	0.355	-0.644	0.761	-13.083	3.185
-10	21.157	0.106	3.955	0.448	-7.991	1.772
-5	22.955	0.086	7.515	0.297	6.157	0.348
0	25.642	0.065	10.313	0.215	10.497	0.211
5	31.097	0.035	15.679	0.116	15.598	0.117
10	34.694	0.023	18.819	0.081	17.975	0.089
15	37.459	0.017	19.635	0.104	22.159	0.055
20	39.007	0.014	26.642	0.033	26.439	0.034

本研究方法对含噪正弦信号降噪前后的时域波形如图7所示,从图中可以看出,本研究方法对于含噪正弦信号的降噪效果较好。其中对信噪比为-20 dB的含噪信号降噪后整体光滑,波形与正弦信号较为相似,虽然相位和振幅有差异,但是噪声含量显著下降;对噪声含量较少的含噪信号降噪后



(a) 对SNR=-20的含噪信号降噪效果

(a) Denoising effect on noisy signal with SNR=-20



(b) 对SNR=5的含噪信号降噪效果

(b) Denoising effect on noisy signal with SNR=5

图7 本研究方法对正弦信号的降噪效果

Fig.7 Denoising effect of this method on sin signals

整体光滑,波形还原程度好,相位和振幅差异较小。

#### 3.2 调幅信号降噪实验

采用的仿真调幅信号为

$$x(t) = 5(1 + \cos(80\pi t)) \cos(400\pi t) + 20(1 + \cos(80\pi t)) \cos(1600\pi t) + 15(1 + \cos(80\pi t)) \cos(1200\pi t) + 10(1 + \cos(80\pi t)) \cos(800\pi t) \quad (12)$$

采样频率为 12.8 kHz,采样时间为 4 s,采用滑动窗口取样,步长为 20,每个样本包含 1 000 个采样点,样本数目为 400。给这 400 个样本依次添加不同程度的噪声,构造出信噪比为 -20~20 dB 的 9 种含噪信号,将 9 种含噪信号组合为含有 3 600 个样本的训练集,再按照制作训练集的方法制作同样数量的测试集。表 2 为本研究方法对不同 SNR 含噪调幅信号降噪后得到的 SNR 和 RMSE,图 8 为本研究方法对含噪调幅信号降噪前后的时域波形。可以看出:本研究方法对于含噪调幅信号取得了较好的降噪效果,对 SNR 为 -20 dB 的含噪信号仍然具有较好的降噪能力,能明显提高信噪比,且降噪后获得的信号整体光滑;对较高信噪比的含噪信号降噪后整体光滑,波形还原程度好,相位和振幅差异较小。

表 2 调幅信号仿真结果

Tab.2 Simulation results of Am signals


降噪前 SNR/dB	降噪后 SNR/dB	RMSE	降噪前 SNR/dB	降噪后 SNR/dB	RMSE
-20	2.619	13.343	5	28.260	0.828
-15	9.113	4.204	10	30.217	0.829
-10	22.654	0.890	15	28.252	0.828
-5	28.473	0.811	20	28.251	0.828
0	28.321	0.823			

### 3.3 轴承仿真故障信号降噪实验

采用文献[19]中的轴承故障仿真信号为


$$x(t) = \exp(-800\text{mod}(t, 1/100)) \sin(6000\pi t) + \exp(-800\text{mod}(t, 1/80)) \sin(16000\pi t) \quad (13)$$

采样频率为 25 kHz,采样时间为 1 s,采用滑动窗口取样,步长为 20,每个样本包含 1 000 个采样点,样本数目为 400。给这 400 个样本依次添加不同程度的噪声,构造出信噪比为 -20~20 dB 的 9 种含噪信号,将 9 种含噪信号组合为含有 3 600 个样本的训练集,再按照制作训练集的方法制作同样数量的测试集。利用制作好的训练集进行训练,之后将训练好的自编码器对测试集进行降噪。表 3 为本研究方法对不同 SNR 的含噪调幅信号降噪后得到的 SNR 和 RMSE。图 9 为本研究方法对含噪调幅信号降噪前后的时域波形。可以看出:对信噪比为 -20 dB 的含噪信号降噪后与原始信号差异较大,整体波形还原程度不好;对于 SNR 为 -10 的含噪信号本研究方法的降噪效果较好,波形、相位和



(a) 对 SNR=-20 的含噪信号降噪效果

(a) Denoising effect on noisy signal with SNR=-20



(b) 对 SNR=-10 的含噪信号降噪效果

(b) Denoising effect on noisy signal with SNR=-10

图 8 本研究方法对调幅信号的降噪效果

Fig.8 Denoising effect of this method on Amplitude signals

表 3 轴承仿真故障信号仿真结果


Tab.3 Simulation results of bearing simulation fault signals

降噪前 SNR/dB	降噪后 SNR/dB	RMSE	降噪前 SNR/dB	降噪后 SNR/dB	RMSE
-20	1.071	0.200	5	22.672	0.016
-15	5.072	0.118	10	22.660	0.016
-10	14.736	0.035	15	22.729	0.016
-5	22.275	0.017	20	22.710	0.016
0	22.597	0.016			

振幅还原较为准确;对于更高信噪比的含噪信号的降噪效果,由表 3 中的 SNR 和 RMSE 可以看出,降噪效果同样较好。


## 4 实测轴承故障振动信号实验

采用凯斯西储大学(CWRU)滚动轴承数据集<sup>[20]</sup>,在深沟球轴承 SKF6205 的外圈滚道上通过电火花加工模拟滚动轴承故障信号,加工直径为 0.177 8 mm。数据集采用加速度传感器采集轴承安装座上的振动,采样频率为 12 kHz。实验中向上述信号中添加噪声,构造出为信噪比为 -10, -5, 0, 5, 10, 15, 20 dB 的 7 种



(a) 对SNR=-20的含噪信号降噪效果

(a) Denoising effect on noisy signal with SNR=-20



(b) 对SNR=-10的含噪信号降噪效果

(b) Denoising effect on noisy signal with SNR=-10

图9 本研究方法对轴承仿真故障信号的降噪效果

Fig.9 Denoising effect of this method on bearing simulation fault signals

含噪信号,其中信噪比由原始信号的平均功率和添加噪声的平均功率计算得到。采用滑动窗口取样,步长为20,每个样本包含1000个采样点,每种含噪信号采集到900个样本,共6300个样本。其中:4900个样本作为训练集,1400个样本作为测试集。


图10为本研究方法对含噪实测信号降噪前后的时域波形。可以看出,本研究方法对于信噪比大于-10dB的含噪信号可以显著减少噪声,提高信噪比,与原始信号相比时域波形相似程度很高。

## 5 结论

1) 本研究方法无需大量信号处理知识就可以自适应地对多种信号进行降噪。


2) 分别对正弦信号、调幅信号、轴承仿真故障振动信号以及实测轴承故障振动信号进行实验,都取得比较好的降噪效果,实验结果表明,本研究方法能够用于轴承振动信号降噪。

3) 对于低噪声的含噪信号,本研究方法相较于传统方法,可以取得更好的降噪效果;对于强噪声的含噪信号,传统方法降噪效果不理想,本研究方法仍然有效。




(a) 对SNR=-10的含噪信号降噪效果

(a) Denoising effect on noisy signal with SNR=-10



(b) 对SNR=-5的含噪信号降噪效果

(b) Denoising effect on noisy signal with SNR=-5



(c) 对SNR=0的含噪信号降噪效果

(c) Denoising effect on noisy signal with SNR=0

图10 本研究方法对外圈故障振动信号的降噪效果

Fig.10 Denoising effect of this method on out-race faults signal

4) 本研究方法的缺点为需要大量的样本进行训练,需要预先收集振动特征明显的振动信号。

## 参 考 文 献

- [1] 赵志宏,杨绍普,申永军. 一种改进的EMD降噪方法[J]. 振动与冲击,2009,28(12):35-37.  
ZHAO Zhihong, YANG Shaopu, SHEN Yongjun. An improved EMD based de-noising method [J]. Journal of Vibration and Shock, 2009, 28(12): 35-37. (in Chinese)
- [2] 贾亚超,李国龙,何坤,等. 基于灰色准则与EEMD的滚刀振动信号降噪方法[J]. 仪器仪表学报,2019,40(7):

- 187-194.
- JIA Yachao, LI Guolong, HE Kun, et al. Denoising method for vibration signal of hob based on grey criterion and EEMD [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 187-194. (in Chinese)
- [3] 向北平,周建,倪磊,等. 基于样本熵的改进小波包阈值去噪算法[J]. 振动、测试与诊断, 2019, 39(2): 410-415.
- XIANG Beiping, ZHOU Jian, NI Lei, et al. Research on improved wavelet packet threshold denosing algorithm based on sample entropy [J]. Journal of Vibration, Measurement & Diagnosis, 2019, 39(2): 410-415. (in Chinese)
- [4] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks [J]. Science, 2006, 313(5786): 504-507.
- [5] RANZATO M, BOUREAU Y L, LECUN Y. Sparse feature learning for deep belief networks [J]. Advances in Neural Information Processing Systems, 2007, 20: 1185-1192.
- [6] KEMKER R, KANAN C. Self-taught feature learning for hyperspectral image classification [J]. IEEE Transactions on Geoscience & Remote Sensing, 2017, 55(5): 2693-2705.
- [7] LI E Z, DU P J, SAMAT A, et al. Mid-level feature representation via sparse autoencoder for remotely sensed scene classification [J]. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 2017, 10(3):1068-1081.
- [8] RIBEIRO M, LAZZARETTI A E, LOPES H S. A study of deep convolutional auto-encoders for anomaly detection in videos [J]. Pattern Recognition Letters, 2018, 105:13-22.
- [9] JIA F, LEI Y, LIN J, et al. Deep neural network: a promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data [J]. Mechanical System and Signal Processing, 2006(72/73):303-315.
- [10] 侯文擎,叶鸣,李巍华. 基于改进堆叠降噪自编码的滚动轴承故障分类[J]. 机械工程学报, 2018, 54(7): 87-96.
- HOU Wenqing, YE Ming, LI Weihua. Rolling element bearing fault classification using improved stacked de-noising auto-encoders [J]. Journal of Mechanical Engineering, 2018, 54(7): 87-96. (in Chinese)
- [11] XIE J Y, XU L L, CHEN E H. Image denoising and inpainting with deep neural networks [J]. Advances in Neural Information Processing Systems, 2012, 1: 341-349.
- [12] LI H M. Deep learning for image denoising [J]. International Journal of Signal Processing, Image Processing & P, 2014, 7: 171-180.
- [13] 马红强,马时平,许悦雷,等. 基于改进栈式稀疏去噪自编码器的自适应图像去噪[J]. 光学学报, 2018, 38(10):120-127.
- MA Hongqiang, MA Shiping, XU Yuele, et al. Adaptive image denoising auto-encoder [J]. Acta Optica Sinica, 2018, 38(10):120-127. (in Chinese)
- [14] BENGIO Y, LAMBLIN P, POPOVICI D, et al. Greedy layer-wise training of deep networks [C] // Advances in Neural Information Processing Systems. Cambridge:MIT Press, 2007:153-176.
- [15] NGUYEN V, 蔡觉平,魏琳育,等. Sigmoid函数的低复杂度概率分段线性拟合法[J]. 西安电子科技大学学报, 2020, 47(3):58-64.
- NGUYEN V, CAI Jueping, WEI Linyu, et al. Low complexity probability-based piecewise linear approximation [J]. Journal of Xidian University, 2020, 47(3): 58-64. (in Chinese)
- [16] 郑宗生,刘兆荣,黄冬梅,等. 基于改进激活函数的用于台风等级分类的深度学习模型[J]. 计算机科学, 2018, 45(12):177-181.
- ZHENG Zongsheng, LIU Zhaorong, HUANG Dongmei, et al. Deep learning model for typhoon grade classification based on improved activation function [J]. Computer Science, 2018, 45(12): 177-181. (in Chinese)
- [17] HE K M, ZHANG X Y, REN S Q, et al. Delving deep into rectifiers: surpassing human-level performance on ImageNet classification [C] //ICCV: 2015 IEEE International Conference on Computer Vision. Los Alamitos, CA: IEEE Computer Society, 2015: 1026-1034.
- [18] IOFFE S, SZEGEDY C. Batch normalization: accelerating deep network training by reducing internal covariate shift [C]//Proceedings of the 32nd International Conference on Machine Learning. Atlanta, GA: JMLR, 2015: 448-456.
- [19] 王宏超,陈进,霍柏琦,等. 强抗噪时频分析方法及其在滚动轴承故障诊断中的应用[J]. 机械工程学报, 2015, 51(1):90-96.
- WANG Hongchao, CHEN Jin, HUO Baiqi, et al. Noise-resistant time-frequency analysis method and its application in fault diagnosis of rolling bearing [J]. Journal of Mechanical Engineering, 2015, 51(1): 90-96. (in Chinese)
- [20] SMITH W A, RANDALL R B. Rolling element bearing diagnostics using the Case Western Reserve University data: a benchmark study [J]. Mechanical Systems and Signal Processing, 2015 (64/65): 100-131.



**第一作者简介:**赵志宏,男,1972年8月生,博士、教授。主要研究方向为机械故障诊断、机械动力学、深度学习和非线性动力学。曾发表《多小波系数特征提取方法在故障诊断中的应用》(《振动、测试与诊断》2015年第35卷第2期)等论文。  
E-mail:hb\_zhaozhong@126.com