

基于SVDS-MSCNN的风电机组滚动轴承故障诊断*

史宗辉¹, 陈长征^{1,2}, 安文杰¹, 田森¹, 孙鲜明³

(1. 沈阳工业大学机械工程学院 沈阳, 110870)

(2. 辽宁省振动噪声控制工程技术研究中心 沈阳, 110870)

(3. 宁波坤博测控科技有限公司 宁波, 315200)

摘要 针对风电机组滚动轴承振动信号具有非平稳、非线性、强干扰的特点以及故障特征提取困难的问题,提出了一种基于奇异值分解(singular value decomposition, 简称SVD)、S变换与多尺度卷积神经网络(multiscale convolutional neural network, 简称MSCNN)的故障诊断方法。首先,将原始信号构造成Hankel矩阵,采用SVD对Hankel矩阵进行奇异值分解,再根据奇异值曲率谱选取有效奇异值进行信号重构;其次,对重构信号进行S变换生成特征图谱;最后,将其输入到MSCNN自适应提取特征进行故障识别。试验结果表明,利用SVDS-MSCNN方法进行风电机组滚动轴承故障诊断,其故障识别准确率达到97.5%,故障诊断效果优于其他深度学习算法。

关键词 滚动轴承;故障诊断;奇异值分解;S变换;卷积神经网络

中图分类号 TH133.33;TH17

引言

滚动轴承作为风电机组重要的零部件,其健康状况直接影响整个风电机组的正常运行^[1]。由于制造误差、装配不良及杂质入侵等因素,且风电机组长期在重负载、变转速条件下运行,承受较大的载荷,导致滚动轴承极易损坏^[2]。因此,对滚动轴承进行状态监测与诊断具有重要意义。

风电机组滚动轴承振动信号具有非平稳、非线性等特性,并存在其他设备激励源干扰与较强的背景噪声,因此早期微弱故障特征不易提取,需在分析信号前对信号做降噪处理。在分析信号时,单纯的时域或频域分析无法提供有价值的故障特征信息,需要对滚动轴承非平稳振动信号进行时频分析,常见的时频分析方法有连续小波变换(continuous wavelet transform, 简称CWT)和短时傅里叶变换(short time fourier transform, 简称STFT)^[3-4]。CWT由于受海森堡不确定性原理影响,难以选取合适的小波基函数。STFT由于窗函数与频率无关,无法同时获得频率和时间的高分辨率。S变换弥补了短时傅里叶窗函数固定不变的缺陷,克服了连续小波变换小波基选取困难的问题,是一种有效的时频分析方法。

卷积神经网络(convolutional neural network, 简称CNN)作为一种滚动轴承故障识别的方法,通过卷积、池化方式学习训练数据,能够更加全面地提取图像特征。近年来,国内外学者做了许多深入研究^[5-6]。Liu等^[7]提取齿轮振动信号特征,利用CNN进行模式识别,判断齿轮故障类型。Li等^[8]将多传感器信号输入到CNN模型中,结合改进的D-S证据理论对滚动轴承进行故障识别。虽然上述方法对各自的故障诊断具有较好的识别效果,但在使用CNN进行故障识别时,采用相同尺度的卷积核提取特征,无法同时提取全局和局部特征,导致有效信息丢失。

针对以上问题,笔者提出一种基于SVDS-MSCNN的风电机组滚动轴承故障诊断方法,利用原始数据构造Hankel矩阵,进行SVD,根据奇异值曲率谱选取有效奇异值进行信号重构,利用S变换对重构信号进行时频分析,生成特征图谱,输入到MSCNN中自适应提取特征,进行风电机组滚动轴承故障识别。

1 基本原理

1.1 SVD降噪理论

SVD降噪理论不需要预先知道信号周期,不依

* 国家自然科学基金资助项目(51675350, 51575361)

收稿日期:2022-04-15;修回日期:2022-06-08

赖于滤波器性能的优劣,没有相位滞后,是一种有效的信号降噪方法^[9-10]。由于采集的振动信号为一维数据,SVD处理的是二维矩阵,因此采用Hankel矩阵的方式将一维振动信号转化为二维矩阵形式,Hankel矩阵构造方式如下。

原始振动信号为 $X=[x_1, x_2, \dots, x_n]$,在信号中随机选取一点 i 作为构造起点,构造方式为

$$A = \begin{bmatrix} x_{i+1} & x_{i+2} & \cdots & x_{i+n} \\ x_{i+2} & x_{i+3} & \cdots & x_{i+n+1} \\ \vdots & \vdots & \ddots & \vdots \\ x_{i+m} & x_{i+m+1} & \cdots & x_{i+n} \end{bmatrix} \quad (1)$$

其中: $i=1, 2, \dots, n-4096$; A 为 $m \times n$ 阶矩阵; N 为数据长度, $N=m+n-1$ 。

对于一个矩阵 $A_{m \times n}$,存在一个分解,可将矩阵 $A_{m \times n}$ 分解为两个正交矩阵 $U_{m \times m}$, $V_{n \times n}$ 与一个对角矩阵 $W_{m \times n}$ 的组合,即

$$A = UWV^T \quad (2)$$

其中: $U_{m \times m}=[u_1, u_2, \dots, u_m]$; $V_{n \times n}=[c_1, c_2, \dots, c_n]$;

$$W = \begin{bmatrix} \text{diag}(\gamma_1, \gamma_2, \dots, \gamma_r) & 0 \\ 0 & 0 \end{bmatrix}。$$

对角矩阵 W 前 r 阶对角线元素 $\gamma_i(i=1, 2, \dots, r)$ 为矩阵 $A_{m \times n}$ 的奇异值,奇异值在矩阵中按照降序排列,奇异值大小反映各元素的能量集中情况。较大的奇异值反映原始信号的有效信息,较小的奇异值反映信号的噪声成分。因此,降噪的关键在于如何确定奇异值的个数,奇异值选取过多,信号降噪效果差,奇异值过少则会丢失有效信息。

1.2 奇异值曲率谱

采用奇异值曲率谱的方式来选取奇异值的个数,进行信号重构^[11]。由奇异值曲线可知,有效信息和噪声成分存在明显的转折点,对于连续曲线 $y=x(t)$,曲率计算公式为

$$K = \frac{|y''|}{(1+y'^2)^{\frac{3}{2}}} \quad (3)$$

根据奇异值理论,奇异值按照从大到小的顺序构造奇异值序列 $B=\{\delta_1, \delta_2, \dots, \delta_n\}$,其中第 i 点的二阶导数为

$$y''_i = \delta_{i+1} - 2\delta_i + \delta_{i-1} \quad (i=2, 3, \dots, n-1) \quad (4)$$

一阶导数有向前和向后差分两种表示方法,向前差分、向后差分分别为

$$y'_i = \delta_{i+1} - \delta_i \quad (i=2, 3, \dots, n-1) \quad (5)$$

$$y'_i = \delta_i - \delta_{i-1} \quad (i=2, 3, \dots, n-1) \quad (6)$$

理想情况下,对于连续曲线,采用向前差分或向后差分得到的结果大致相同,而实际采集的振动信号受环境噪声及其他设备激励源的影响较大,向前差分或向后差分结果存在差异,需要通过对比分析选择向前差分或向后差分。

在奇异值序列 B 中每个数据点 i 都可以计算出一个曲率值 K_i ,所有曲率值构成的序列 $\{K_1, K_2, \dots, K_{n-1}\}$ 称之为奇异值曲率谱。奇异值曲率谱中曲率值大小反应奇异值的转折程度,奇异值曲率谱中至少存在一个转折点 K ,使该点曲率值最大, K 点是区分噪声信号与有效信号的分界线。因此,本研究将 K 处之后的点的奇异值置零,消除噪声干扰,保留有效信息。若曲率谱最大峰值的位置坐标 K 处奇异值曲线二阶导数 $y'' < 0$,则有效奇异值的个数为 K ;如果在 K 处奇异值曲线二阶导数 $y'' \geq 0$,则有效奇异值的个数为 $K-1$ 。

1.3 S变换理论

S变换^[12]是基于STFT与CWT改进的信号处理方法,采用可伸缩的高斯窗函数对信号进行时频分析,是一种高效的自适应时频分析方法^[13-14],非常适合处理非平稳、非线性信号,其编码方式在时间上具有唯一映射性,保证了其逆变换完全无损性。

对于连续信号 $x(t)$,其连续S变换定义为

$$S(\tau, f) = \int_{-\infty}^{\infty} x(t) \omega(\tau - t, f) e^{-i2\pi ft} dt \quad (7)$$

其中: f 为频率; τ 为时窗函数中心点; t 为时间变量。

高斯窗函数 $\omega(\tau - t, f)$ 定义为

$$\omega(\tau - t, f) = \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} \quad (8)$$

因此,连续信号 $x(t)$ 的S变换定义式为

$$S(\tau, f) = \int_{-\infty}^{+\infty} x(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(\tau-t)^2 f^2}{2}} e^{-i2\pi ft} dt \quad (9)$$

将S变换离散化,构造时频特性复矩阵

$$\begin{cases} S\left[kT, \frac{n}{NT}\right] = \sum_{r=0}^{N-1} X\left(\frac{r+n}{NT}\right) e^{-\frac{2\pi^2 r^2}{n^2}} e^{i\frac{2\pi rn}{N}} & (n \neq 0) \\ S[kT, 0] = \frac{1}{N} \sum_{r=0}^{N-1} x\left(\frac{r}{NT}\right) & (n = 0) \end{cases} \quad (10)$$

$$x\left[\frac{n}{NT}\right] = \frac{1}{N} \sum_{k=0}^{N-1} x[kT] e^{-j\frac{2\pi kn}{N}} \quad (n=0, 1, \dots, N-1) \quad (11)$$

其中: N 为采样点数; T 为采样时间。

由式(7)~(11)可知,S变换克服了STFT窗口时宽不变的缺陷,能根据频率变化,自适应地调整窗函数宽度。在低频信号时段,窗函数变宽,频率分辨率高;在高频信号时段,窗函数变窄,时间分辨率高。因此,在时域、频域中都可获得较高的分辨率。

1.4 多尺度卷积神经网络

CNN作为一种高效的深度神经网络模型,具有较强的鲁棒性与泛化能力,被广泛用于图像处理、语音识别以及计算机视觉等领域^[15]。在进行卷积运算时,卷积核的大小影响特征提取能力与故障识别准确率。MSCNN作为一种改进的卷积神经网络算法,采用多尺度方式提取故障特征,利用多个不同尺度的卷积核,从特征图谱中提取局部及全局的故障特征并构建模型,进行风电机组轴承的故障诊断。MSCNN网络模型如图1所示。

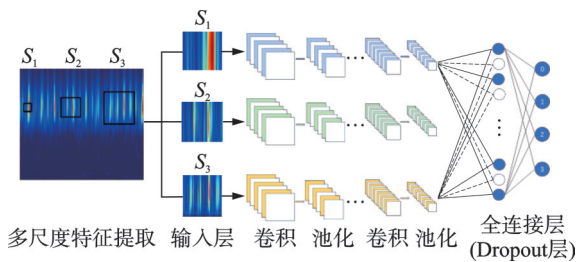


图1 MSCNN网络模型

Fig.1 MSCNN network model

由图1可知,以振动信号处理后得出的时频图作为原始图像输入, MSCNN由3组并行的具有3层卷积的池化结构组成,其中3组分支的卷积核大小分别为 $S_1(3 \times 3)$, $S_2(5 \times 5)$ 和 $S_3(7 \times 7)$,每组分支中卷积核的通道数分别为32,64和128。每一个卷积操作的步长为1,激活函数为ReLU,并在其后连接最大池化层,减少模型参数。样本经过3组并行的卷积池化结构之后输入到全连接层,进行信息融合,再经过Sofmax层输出诊断结果。此外,为防止过拟合,在全连接层中加入Dropout,并将其设置为0.5^[16]。基于SVDS-MSCNN的风电机组滚动轴承故障诊断步骤如下:

1) 利用原始数据,构造Hankel矩阵,利用SVD对Hankel矩阵进行分解,根据奇异值曲率谱选取有效奇异值进行信号重构,通过S变换对重构信号进行时频分析,获取振动信号的时频图,随机划分训练集和测试集;

2) 初始化网络结构,并利用训练集数据训练MSCNN模型;

3) 将测试集输入到训练好的MSCNN网络模型中进行故障诊断,获取滚动轴承故障诊断结果。

风电机组滚动轴承故障诊断流程如图2所示。

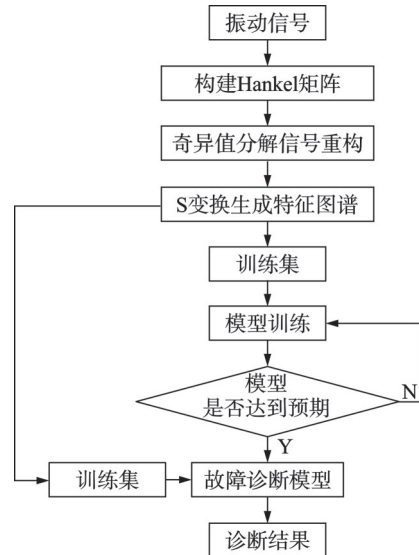



图2 风电机组滚动轴承故障诊断流程图

Fig.2 Fault diagnosis flow chart of fan rolling bearing

2 试验与结果分析

2.1 试验基本信息

风电机组发电机轴承振动数据来源于天津某风场,采用压电加速度传感器采集数据,测点为风电机组发电机前端盖径向,采样频率为16 384 Hz,采样时间为20 s。风电机组振动信号采集如图3所示。轴承数据样本由正常状态、滚动体故障、内圈故障、外圈故障4种状态组成,故障标签如表1所示。每种状态采用起点随机的方式截取4 096个数据点,生成2 500组样本,随机选取2 000组为训练集,剩余500组为测试集。其中,标签0,1,2,3分别代表正常状态、滚动体故障、内圈故障和外圈故障。



(a) 结构简图 (a) Structure diagram (b) 测点 (b) Measuring point

图3 风电机组振动信号采集

Fig.3 Wind turbine vibration signal acquisition

表 1 故障标签
Tab.1 Fault label

轴承状态	故障标签	故障缩写	训练集/组	测试集/组
正常	0	NF	2 000	500
滚动体故障	1	BF	2 000	500
内圈故障	2	IR	2 000	500
外圈故障	3	OR	2 000	500

2.2 试验分析

将每组数据构造 $2\ 048 \times 2\ 049$ 阶 Hankel 矩阵, 采用 SVD 对 Hankel 矩阵分解, 根据奇异值曲率谱选取有效奇异值进行信号重构。奇异值曲率谱如图 4 所示。




图 4 奇异值曲率谱

Fig.4 Singular value curvature spectrum

由图 4 可以看出, 当曲率 K 为 18 和 32 时, 曲率谱转折点较为明显, 且 $y'' \geq 0$ 。当 K 取 18 时, 利用前 17 个奇异值重构信号, 之后的奇异值置零, 在消除噪声的同时, 有效信息也被去除, 使重构信号与真实信号差异较大。因此, 选取 $K=32$ 时的奇异值重构信号。由于这时奇异值曲线二阶导数 $y'' \geq 0$, 因此有效奇异值个数为 31 个。利用有效奇异值重构信号, 信号对比如图 5 所示。




图 5 信号对比

Fig.5 Signal comparison

由于风电机组工作在有风力冲击与不确定载荷的环境中, 信号中的冲击特征被淹没在强背景噪声中, 无法直接通过时域波形判断其故障。图 5 中蓝色为原始信号, 红色为重构信号, 通过时域波形可明

显看出轴承存在周期性冲击特征。因此, 采用 SVD 的方法可有效去除振动信号中的干扰信号并保留有效特征, 为时频分析奠定了基础。

风场采集的滚动轴承振动信号具有非平稳、非线性等特性, S 变换作为一种有效处理非平稳、非线性信号的时频分析方法, 常被用于轴承振动信号的时频分析。因此, 针对轴承的 4 种状态, 采用 SVDS 处理信号时频图如图 6 所示。

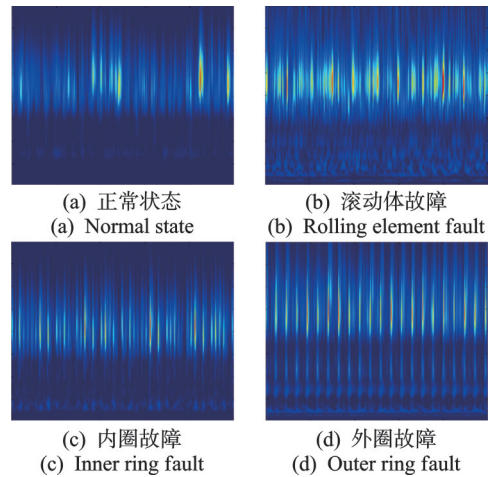




图 6 SVDS 处理信号时频图

Fig.6 SVDS processing signal time-frequency diagram

将时频图谱输入到 MSCNN 中, 以交叉熵损失函数作为 MSCNN 的损失函数, 在不同迭代次数下的模型故障识别曲线图如图 7 所示。



(a) 故障识别准确率
(a) Fault identification accuracy



(b) 故障识别损失值
(b) Fault identification loss value

图 7 模型故障识别曲线图

Fig.7 Model fault identification curve

由图7可以看出,在迭代到20次时,训练集和测试集的故障识别准确率分别达到97.5%和97.3%,损失值曲线降低至0.037。随着迭代次数的增加,故障识别准确率曲线和损失值曲线走势趋于稳定,模型达到收敛状态。

为了进一步研究MSCNN对SVDS特征提取时频图的故障分类能力,绘制测试集的滚动轴承故障分类混淆矩阵,如图8所示。




图8 滚动轴承故障分类混淆矩阵

Fig.8 Rolling bearing fault classification confusion matrix

图8中,横轴、纵轴分别代表MSCNN预测出的故障类型和实际故障类型,颜色较浅区域代表故障被误分类的数量。混淆矩阵中数字“21”代表有21个实际为滚动体故障的被分类为外圈故障。由混淆矩阵可知,SVDS-MSCNN的方法在识别轴承故障方面具有较高的准确率。

传统的滚动轴承故障诊断包括特征提取和故障识别两个过程。为验证基于SVDS-MSCNN滚动轴承故障诊断方法的优越性,设置如下2组对比试验:①特征提取方式不同,故障识别模型相同;②特征提取方式相同,故障识别模型不同。

对于第1组试验,常用的滚动轴承特征提取方式有人工提取特征(manual feature extraction,简称MFE),STFT和CWT等。MFE提取的特征包括均方根值、均值、绝对平均值、歪度、裕度、峭度、最大值、最小值、方差以及方根幅值等一维特征;STFT,CWT和SVDS提取的特征为二维特征。STFT和CWT处理信号时频图分别如图9,10所示。

本研究采用以上3种特征提取方式生成的时频图为输入,以MSCNN为故障识别模型,与SVDS-MSCNN进行对比。试验1故障识别准确率如图11所示。

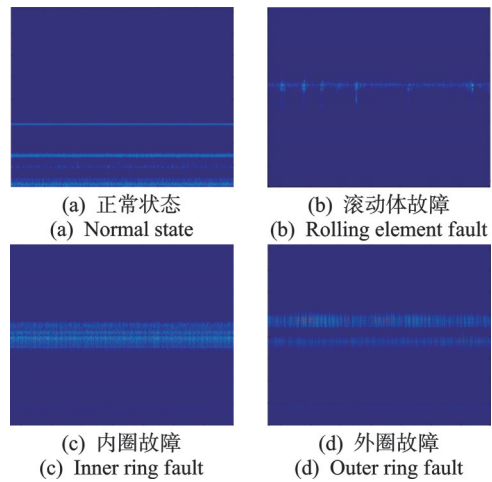


图9 STFT处理信号时频图

Fig.9 STFT processing signal time-frequency diagram

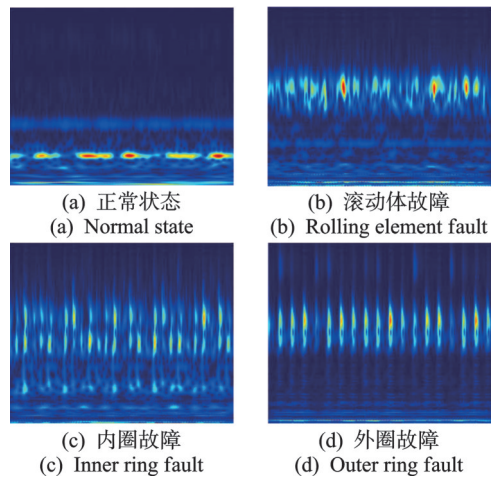


图10 CWT处理信号时频图

Fig.10 CWT processing signal time-frequency diagram




图11 试验1故障识别准确率

Fig.11 Test 1 fault recognition accuracy

由图11可知,采用MFE方式提取的是一维特征,其故障识别准确率为85.4%,低于其他3种以二维特征为输入的方法,这说明二维特征包含了更多的故障信息。SVDS弥补了STFT窗函数固定不变的缺陷,克服了CWT小波基选取困难等问题,其故障识别准确率达到97.3%,高于采用STFT与CWT提取二维特征的方法。

对于第2组试验,卷积神经网络常被应用于轴承的故障诊断,常见方法有VGG16和AlexNet等。因此,本研究利用振动信号经过SVDS处理后生成的时频图像,采用AlexNet与VGG16模型来进行故障识别,并与MSCNN诊断模型进行对比。试验2故障识别准确率如图12所示。




图12 试验2故障识别准确率

Fig.12 Test 2 fault recognition accuracy

由图12可知,采用MSCNN模型进行故障诊断的准确率最高,比AlexNet提高了8.1%,比VGG16提高了6.0%。MSCNN利用不同大小的卷积核在时频图中多尺度地提取故障特征,所提取的特征既包含时频图的全局特征,也包含其局部特征,因此提取的特征更全面,可更加有效地识别轴承故障类型。

针对以上对比试验,利用t-SNE算法对测试集数据进行可视化。对比试验聚类图如图13所示。

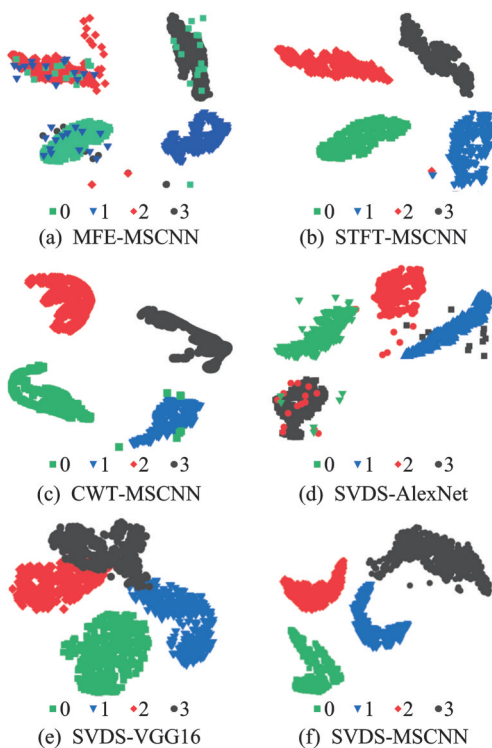


图13 对比试验聚类图

Fig.13 Cluster diagram of comparative test

由图13(a,b,c,f)可以看出,采用不同的特征提取方式、相同的网络模型,SVDS的特征提取方式聚类效果最好;由图13(d,e,f)可以看出,采用相同的特征提取方式、不同的网络模型,MSCNN训练效果最好。综上所述,本研究提出的SVDS-MSCNN方法比其他5种方法更适合滚动轴承的故障特征分类。

3 结论

1) 提出了SVDS-MSCNN的风电机组滚动轴承故障诊断模型。实际风电机组数据含有噪声因素干扰,采用SVDS进行降噪重构信号,进行特征提取生成时频图,通过设计的MSCNN神经网络对时频图特征进行信息提取。结果表明,本研究提出的SVDS-MSCNN方法对实际风电机组发电机滚动轴承故障识别准确率为97.3%。

2) 采用不同特征提取方法及不同网络模型进行对比分析,结果表明,在滚动轴承故障诊断中,SVDS特征提取方法优于MFE,STFT和CWT等方法。MSCNN对SVDS方式生成的特征图谱,通过设置不同尺度的卷积核来提取全局及局部的特征进行故障分类,其分类效果高于传统的神经网络模型。

参 考 文 献

- [1] 郑玉巧,魏剑峰,朱凯,等. 风力机主轴承故障监测方法[J]. 振动、测试与诊断, 2021, 41(2): 341-347.
ZHENG Yuqiao, WEI Jianfeng, ZHU Kai, et al. Monitoring method for main bearing faults of wind turbines [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(2): 341-347. (in Chinese)
- [2] 张旭辉,张超,樊红卫,等. 快速谱峭度结合阶次分析滚动轴承故障诊断[J]. 振动、测试与诊断, 2021, 41(6): 1090-1095.
ZHANG Xuhui, ZHANG Chao, FAN Hongwei, et al. Fast spectral kurtosis combined with order analysis for fault diagnosis of rolling bearings [J]. Journal of Vibration, Measurement & Diagnosis, 2021, 41(6): 1090-1095. (in Chinese)
- [3] 刘义亚,李可,陈鹏. 基于同步压缩小波变换的滚动轴承故障诊断[J]. 中国机械工程, 2018, 29(5): 585-590.
LIU Yiya, LI Ke, CHEN Peng. Fault diagnosis for rolling bearings based on synchrosqueezing wavelet transform [J]. China Mechanical Engineering, 2018,

- 29(5): 585-590. (in Chinese)
- [4] 刘湘楠, 赵学智, 上官文斌. 强背景噪声振动信号中滚动轴承故障冲击特征提取[J]. 振动工程学报, 2021, 34(1): 202-210.
LIU Xiangnan, ZHAO Xuezhi, SHANGGUAN Wenbin. The impact features extraction of rolling bearing under strong background noise [J]. Journal of Vibration Engineering, 2021, 34(1): 202-210. (in Chinese)
- [5] ZHAO D Z, WANG T Y, GAO R X, et al. Signal optimization based generalized demodulation transform for rolling bearing nonstationary fault characteristic extraction[J]. Mechanical Systems and Signal Processing, 2019, 134: 106297.
- [6] 雷亚国, 许学方, 蔡潇, 等. 面向机械装备健康监测的数据质量保障方法研究[J]. 机械工程学报, 2021, 57(4): 1-9.
LEI Yaguo, XU Xuefang, CAI Xiao, et al. Research on data quality assurance for health condition monitoring of machinery [J]. Journal of Mechanical Engineering, 2021, 57(4): 1-9. (in Chinese)
- [7] LIU C, CHENG G, CHEN X H, et al. Planetary gears feature extraction and fault diagnosis method based on VMD and CNN[J]. Sensors, 2018, 18(5): 1523.
- [8] LI S B, LIU G K, TANG X H, et al. An ensemble deep convolutional neural network model with improved D-S evidence fusion for bearing fault diagnosis [J]. Sensors, 2017, 17(8): 1729.
- [9] 陈永辉, 熊兰, 范禹邑, 等. 基于互感器电压信号的光伏电弧故障检测方法[J]. 太阳能学报, 2021, 42(10): 68-75.
CHEN Yonghui, XIONG Lan, FAN Yuyi, et al. Photovoltaic arc fault detection method based on transformer voltage signal [J]. Acta Energetica Solaris Sinica, 2021, 42(10): 68-75. (in Chinese)
- [10] GUO M J, LI W G, YANG Q J, et al. Amplitude filtering characteristics of singular value decomposition and its application to fault diagnosis of rotating machinery[J]. Measurement, 2020, 154: 107444.
- [11] 赵学智, 叶邦彦, 陈统坚. 基于奇异值曲率谱的有效奇异值选择[J]. 华南理工大学学报(自然科学版), 2010, 38(6): 11-18, 23.
ZHAO Xuezhi, YE Bangyan, CHEN Tongjian. Selection of effective singular values based on curvature spectrum of singular values[J]. Journal of South China University of Technology (Natural Science Edition), 2010, 38(6): 11-18, 23. (in Chinese)
- [12] YAN B K, WANG B, ZHOU F X, et al. Sparse feature extraction for fault diagnosis of rotating machinery based on sparse decomposition combined multiresolution generalized S transform [J]. Journal of Low Frequency Noise Vibration and Active Control, 2019, 38(2): 441-456.
- [13] LIN R Y, LIU Z W, JIN Y L. Instantaneous frequency estimation for wheelset bearings weak fault signals using second-order synchrosqueezing S-transform with optimally weighted sliding window[J]. ISA Transactions, 2021, 115: 218-233.
- [14] PINNEGAR C R, MANSINHA L. Time-local spectral analysis for non-stationary time series: the S-transform for noisy signals [J]. Fluctuation and Noise Letters, 2012, 3(3): L357-L364.
- [15] JING L Y, WANG T Y, ZHAO M, et al. An adaptive multi-sensor data fusion method based on deep convolutional neural networks for fault diagnosis of planetary gearbox[J]. Sensors, 2017, 17(2): 414.
- [16] WANG H Q, LI S, SONG L Y, et al. A novel convolutional neural network based fault recognition method via image fusion of multi-vibration-signals [J]. Computers in Industry, 2019, 105: 182-190.



第一作者简介:史宗辉,男,1997年12月生,硕士生。主要研究方向为风力发电机状态检测及故障诊断。

E-mail:792211309@qq.com

通信作者简介:陈长征,男,1964年9月生,博士、教授、博士生导师。主要研究方向为设备状态监测与故障诊断。

E-mail:czchen@sut.edu.cn