

DOI: 10.13382/j.jemi.B1902560

# 广义形态差值滤波与 AN 降维在故障诊断中的应用\*

肖洁 黎敬涛

(昆明理工大学 信息工程与自动化学院 昆明 650500)

**摘要:**由于轴承与设备其他内部构件之间存在强关联耦合关系,导致其振动信号与设备状态存在非线性关系;且信号单一特征难以全面描述设备状态,而多特征虽然包含较多状态信息,但高维特征所产生的信号冗余问题,易导致模型分类精度的下降。因此,提出一种基于广义形态差值滤波(GDIF)与自编码网络(AN)的滚动轴承故障诊断方法。该方法利用广义形态差值滤波对振动信号进行降噪处理,并通过极大似然估计(MLE)与AN从信号的高维特征中获取低维本质流形,缓解高维特征存在的维数灾难问题;最后,建立极限学习机(ELM)故障诊断模型,对轴承故障类型进行识别。轴承试验结果表明,该方法能够有效对信号进行降噪;通过AN对特征进行维数约简,能够使ELM模型分类精度达到98.04%。

**关键词:**广义形态差值滤波;AN;维数约简;极限学习机;故障诊断

**中图分类号:** TN0; TP181      **文献标识码:** A      **国家标准学科分类代码:** 460.1520

## Application of generalized morphological difference filtering and dimension reduction with AN in fault diagnosis

Xiao Jie Li Jingtao

(Faculty of Information Engineering and Automation, Kunming University of Science and Technology, Kunming 650500, China)

**Abstract:** The strong coupling between the bearing and other internal components of the equipment leads to nonlinear relationship between vibration signal and equipment state. Moreover, the single signal feature is difficult to describe the state of the equipment comprehensively, while multi-features contain more status information, the signal redundancy caused by high-dimensional features easily declines the classification accuracy of the model. Therefore, a rolling bearings fault diagnosis method based on generalized morphological difference filter (GDIF) and autoencoder network (AN) is proposed. This method uses the GDIF to reduce the noise of vibration signals, and obtains the low-dimensional intrinsic manifold from the high-dimensional features of the signal by the max likelihood estimate (MLE) and AN algorithm, which alleviates the dimension disasters of high-dimensional features. Finally, the extreme learning machine (ELM) fault diagnosis model is established to identify the bearing fault types. The experiments show that the method can effectively suppress the noise; and the classification accuracy of the ELM Model can reach 98.04% after dimension reduction of features by AN.

**Keywords:** generalized morphological difference filter; AN; dimension reduction; ELM; fault diagnosis

## 0 引言

随着《中国制造2025》的提出,工业设备逐步趋于智能化、复杂化。滚动轴承是工业设备中最常见、也最易损坏的部件之一,若其发生故障,可能导致主轴断裂、传动装置失灵等情况,进而导致生产的停滞,造成难以估计的损失;严重时,甚至会危及到工作人员的生命。因此,对

轴承运行状态进行分析、监测与故障诊断,就成为目前研究的热点之一<sup>[1-3]</sup>。

对于振动信号的预处理通常利用小波分解(wavelet decomposition, WD)、奇异值分解(singular value decomposition, SVD)、经验模态分解(empirical mode decomposition, EMD)等方法,上述信号分解方法虽然能够有效分解信号,但其参数的设定通常靠人工经验,在嵌入式系统中,以上方法的计算量也较大,易影响系统的实

收稿日期: 2019-09-04      Received Date: 2019-09-04

\* 基金项目: 国家自然科学基金(61663017)、云南省科技计划重点项目(2017FA027)资助

时性。自形态学引入信号处理后,因其具有计算量小,能针对性的消除正负冲击进行降噪,适合硬件实现等优点,而广泛应用于非线性信号处理中<sup>[4-5]</sup>。黄刚劲等<sup>[6]</sup>利用互补总体平均经验模态分解与广义形态差值滤波对轴承振动信号进行去噪处理,并利用 Teager 能量算子对信号进行分析;王龙胜等<sup>[7]</sup>提出了一种根据局部极值改变形态滤波的结构参数的滤波方法,对抑制噪声具有良好的效果;金涛等<sup>[8]</sup>利用粒子群算法对广义形态滤波进行优化,通过模型证明其抗噪效果较好;经哲等<sup>[9]</sup>利用自适应随机共振与广义形态差值滤波对液压泵信号进行降噪与特征提取,仿真实验验证了方法的有效性。因此,本文利用广义形态差值滤波对信号进行分解。

随着工业设备的复杂化,学者们开始利用多域特征构建模型,对设备状态进行监测<sup>[10]</sup>。钱伟等<sup>[11]</sup>利用峭度、均方根频率、小波包分频带能量值等多域特征,对飞机发电机的故障类型进行辨识;郑近德等<sup>[12]</sup>提取振动信号的广义复合多尺度排列熵,构建高维特征向量,并利用主成份分析(PCA)对高维特征进行降维,对滚动轴承进行故障诊断。江航等<sup>[13]</sup>利用各分量的能量值、多尺度峭度等特征,构建高维特征向量,实现对轮轨故障类型的识别。以上方法虽构建了包含更多设备状态信息的高维特征集,但该特征集存在信息的冗余性,易导致分类器性能的降低;虽然有采用的 PCA 对高维特征进行降维处理,但是 PCA 作为线性降维方法,难以对非线性问题产生良好的效果。而自编码网络(autoencoder network, AN)作为非线性流形学习方法,能够在非线性高维特征中寻找其低维流形,利用其低维本质特征能更准确的反映设备状态,降低信息间的冗余性,保证分类器分类性能<sup>[14]</sup>。

相较于支持向量机(support vector machine, SVM)与集成学习(ensemble learning, EL)等分类器,极限学习机(extreme learning machine, ELM)具有速度快,参数少的特点,更加适合嵌入式系统,能够保证监测的实时性。

综上所述,本文提出基于广义形态差值滤波与 AN 的滚动轴承故障诊断方法,该方法首先将振动信号进行广义形态差值滤波,去除噪声;然后,提取滤波后信号的时域、频域、排列熵等特征构建特征向量,并利用极大似然估计(maximum likelihood estimate, MLE)方法估计特征向量的本征维数;最后,通过 AN 对高维信号特征进行降维,利用得到的低维信号特征构建 ELM 故障诊断模型<sup>[15]</sup>,对设备状态进行分类。通过帕德博恩大学公开轴承数据集实验表明,GDIF 能够达到良好的去噪效果,提高了高维特征向量集的有效性;AN 能够有效寻取高维特征中的低维本质特征,减少高维特征所产生的信息冗余问题,该方法有效地提高分类模型的精度。

## 1 广义形态差值滤波

当机械设备发生故障时,会令振动信号产生不同频率的周期性脉冲信号,为了提高对故障脉冲信号特征提取的有效性,本文提出了利用广义形态差值滤波的方法来滤除噪声及谐波对振动信号的干扰。

### 1.1 广义形态学滤波

形态学滤波是一种经典的非线性滤波器,运用数学形态中腐蚀、膨胀等基本运算单元,进行开、闭组合运算,能够滤除噪声对信号的干扰。

给定两种不同尺寸的结构元素  $g_1, g_2$ , 定义广义形态开、闭运算及广义形态均值滤波器表达式如下:

$$GOC(n) = (f \cdot g_1 \circ g_2)(n) \quad (1)$$

$$GCO(n) = (f \circ g_1 \cdot g_2)(n) \quad (2)$$

$$F(n) = \{GOC(n) + GCO(n)\} / 2 \quad (3)$$

其中,“ $\cdot$ ”为闭运算;“ $\circ$ ”开运算。

### 1.2 广义形态差值滤波

广义形态学滤波用于处理轴承故障振动信号具有良好的降噪效果,但同时也会削弱轴承故障特征信号的能量,从而影响对故障冲击特征信息的提取精度。因此,根据传统广义形态开、闭运算的性质及特点,定义广义形态交替闭运算如式(4),广义形态交替开运算如式(5),构建广义形态差值滤波器如式(6)所示。

$$GFC(n) = (f \cdot g_1 \circ g_2 \circ g_1 \cdot g_2)(n) \quad (4)$$

$$GFO(n) = (f \circ g_1 \cdot g_2 \cdot g_1 \circ g_2)(n) \quad (5)$$

$$F(n) = GFC(n) - GFO(n) \quad (6)$$

结构元素形状以及尺寸的选取对滤波效果有着极大的影响。综合考虑计算复杂度以及轴承故障振动信号的特点,本文选取了长度分别为 1 和 6 的圆形结构元素。

## 2 高维特征的构建与维数约简

为提高数据可靠性,本文选取了 29 个多域特征以及排列熵来表征故障振动信号。本文提出了利用 AN 来实现维数约简的方法,能有效提高特征提取精度,在保留了原始高维数据结构的同时,又降低计算复杂度。

### 2.1 时域特征

在时域中选择了均值、均方根值、方根幅值、绝对平均值、偏斜度、峭度、方差、最大值、最小值、峰峰值、峭度指标、峰值指标、偏斜指标、裕度指标、波形指标、脉冲指标等 16 个特征。令输入信号为  $X = \{x_1, \dots, x_N\}$ , 各特征的数学表达式如表 1 所示。

表 1 时域特征数学表达式

Table 1 Mathematical expression of time domain characteristics

时域特征	数学表达式	时域特征	数学表达式
均值	$\bar{X} = \frac{1}{N} \sum_{i=1}^N x_i$	峰峰值	$X_p = x_{\max} - x_{\min}$
均方根值	$X_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	波性指标	$S_f = \frac{X_{rms}}{ \bar{X} }$
方根幅值	$X_r = \left  \frac{1}{N} \sum_{i=1}^N \sqrt{ x_i } \right ^2$	峰值指标	$C_f = \frac{X_p}{X_{rms}}$
绝对平均值	$X_{Mad} = \frac{1}{N} \sum_{i=1}^N  x_i $	脉冲指标	$I = \frac{X_p}{X_r}$
偏斜度	$\alpha = \frac{1}{N} \sum_{i=1}^N x_i^3$	裕度指标	$L = \frac{X_p}{X_r}$
峭度	$\beta = \frac{1}{N} \sum_{i=1}^N x_i^4$	偏斜度指标	$C_w = \frac{\alpha}{X_{rms}^3}$
方差	$Var = \frac{1}{N-1} \sum_{i=1}^N (x_i - \bar{x})^2$	峭度指标	$K = \frac{\beta}{X_{rms}^4}$

2.2 频域特征

在频域中选择均值频率、标准差、频谱分散度指标(7个)、主频位置指标(2个)、均方根频率、频率中心等 13 个特征来表征主频带位置或者能量谱分散程度。 $f_i$ 、 $p_i$  分别为  $i$  时刻功率谱中所对应的频率值和幅值,13 个频域特征参数的表达式如表 2 所示。

表 2 频域特征数学表达式

Table 2 Mathematical expression of frequency domain characteristics

编号	频域特征参数	编号	频域特征参数
1	$f_1 = \frac{1}{K} \sum_{k=1}^K s(k)$	2	$f_2 = \frac{1}{K-1} \sum_{k=1}^K (s(k) - f_1)^2$
3	$f_3 = \frac{\sum_{k=1}^K (s(k) - f_1)^3}{K(\sqrt{f_2})^3}$	4	$f_4 = \frac{\sum_{k=1}^K (s(k) - f_1)^4}{K(f_2)^4}$
5	$f_5 = \frac{\sum_{k=1}^K s(k)f_k}{\sum_{k=1}^K s(k)}$	6	$f_6 = \sqrt{\frac{\sum_{k=1}^K s(k) \times (f_k - f_5)^2}{K}}$
7	$f_7 = \frac{\sqrt{\sum_{k=1}^K s(k)f_k^2}}{\sqrt{\sum_{k=1}^K s(k)}}$	8	$f_8 = \frac{\sqrt{\sum_{k=1}^K s(k)f_k^4}}{\sqrt{\sum_{k=1}^K s(k)f_k^2}}$
9	$f_9 = \frac{\sum_{k=1}^K s(k)f_k^2}{\sqrt{\sum_{k=1}^K s(k) \sum_{k=1}^K s(k)f_k^2}}$	10	$f_{10} = \frac{f_6}{f_5}$
11	$f_{11} = \frac{\sum_{k=1}^K (f_k - f_5)^3 s(k)}{K(f_6)^3}$	12	$f_{12} = \frac{\sum_{k=1}^K (f_k - f_5)^4 s(k)}{K(f_6)^4}$
13	$f_{13} = \frac{\sum_{k=1}^K (f_k - f_5)^{1/2} s(k)}{K(f_6)^{1/2}}$		

2.3 排列熵

排列熵(permutation entropy, PE)<sup>[16]</sup> 是一种检测时间序列复杂性的方法,在实际应用中可以表明含噪声情况,值越大表明该时间序列随机性越强,含噪越多,反之则表明越规则,并且受噪声干扰情况较好。该算法计算过程简洁,其复杂度仅取决于窗口大小。设一维离散时间序列  $X = \{x(i), i = 1 \cdots N\}$ , 算法描述如下。

1) 对每个  $x(i)$  用相空间重构延迟坐标法进行重构,得到如下重构向量:

$$X_i = \{x(i), x(i+1), \dots, x(i+(m-1) \cdot l)\} \quad (7)$$

其中,  $l$  为延迟时间。组成如下  $m$  维重构矩阵:

$$X = [X_1 \cdots X_{n-m+l}]^T \quad (8)$$

2) 对每一个  $X_i$  进行升序排列,即:

$$X_i = \{x(i+j_1-1) \cdot l \leq x(i+j_2-1) \cdot l \leq \dots \leq x(i+j_m-1) \cdot l\} \quad (9)$$

此时排列方式  $\{j_1, j_2, \dots, j_m\}$ , 为  $m!$  种排列中的一种。

3) 用频率估计概率得到每一种排列方式出现的概率为  $p_1, p_2, \dots, p_k, k \leq m!$ , 则根据香农熵原理得该时间序列  $X$  的排列熵为:

$$H = (- \sum_{i=1}^k p_i \cdot \lg p_i) \lg(m!) \quad (10)$$

2.4 极大似然值估计

过大的本征维数不能有效地消除噪声,而过小的本征维数则有可能失去信号中的有效信息。本文采用 MLE 来估计合适的高维特征空间本征维数  $d$ 。具体步骤如下。

1) 给定样本数据集为  $X = \{X_i, i = 1 \cdots N\}$ , 设  $S_x(r)$  为半径为  $r$  的小球面。假设  $X_i$  随机落在小球面上的概率服从增量稳定的齐次泊松分布,则增量  $N(t, x)$ , 表示以  $x$  为中心,  $t$  为半径的圆所包含的样本数量,其定义式为:

$$N(t, x) = \sum I \{x \in S_x(t)\} \quad (11)$$

用泊松分布近似其值得:

$$\lambda(t) = f(x) V(m) dt^{d-1} \quad (12)$$

式中:  $V(m)$  为  $m$  维空间单位球的体积;密度采样函数  $f(x) \approx c, c$  为常数。

2) 令  $\theta = \lg f(x)$ , 则  $N(t)$  的似然函数为:

$$L(d, \theta) = \int \lg \lambda(t) dN(t) - \int_0^r \lambda(t) dt \quad (13)$$

3) 令  $\frac{\partial L(d, \theta)}{\partial d} = 0, \frac{\partial L(d, \theta)}{\partial \theta} = 0$ , 求的局部最优维数

$m$  为:

$$\hat{m}_r(x) = \left[ \frac{1}{N(r, x)} \sum_{j=1}^{N(r, x)} \lg \frac{r}{T_j(x)} \right]^{-1} \quad (14)$$

4) 用  $k$  近邻数代替球面半径  $r$ , 则可求得每个样本点基于 ELM 的局部本征维数:

$$\tilde{d}_k(x_i) = \left[ \frac{1}{k-1} \sum_{j=1}^{k-1} \lg \frac{T_k(x_i)}{T_j(x_i)} \right]^{-1} \quad (15)$$

式中:  $T_j(x_i)$  表示  $x_i$  到他第  $j$  个邻近点的欧氏距离。

5) 取所有局部极大似然本征维数的平均值得高维特征空间本征维数  $\tilde{d}_k$ :

$$\tilde{d}_k = \frac{1}{N} \sum_{i=1}^N \tilde{d}_k(x_i) \quad (16)$$

## 2.5 自编码网络

AN 是一种无监督的学习方法,该算法通过编码、解码来学习重构一个可以有效表达原始输入信号的特征。假设输入高维特征集为  $X = \{x_i, i = 1 \cdots N\}$ , 其中  $x_i \in R^p$ ; 输出的高维特征数据集为  $Y = \{y_i, i = 1 \cdots N\}$ , 其中  $y_i \in R^d, d \ll p$ ; 目标函数为  $f(x)_{\text{target}} = \min \|X - Y\|$ 。为了最大程度上实现输出信号对输入信号的复现, AN 通过反向传播算法自动训练调整权值  $w_i$ , 捕捉输入  $X$  最重要的特征,从而达到降维的效果。

本文采用自编码网络对轴承故障特征数据集进行降维处理,步骤如下。

- 1) 设置各项参数,如学习率、去噪参数、隐藏层个数、前向算法迭代次数等;
- 2) 初始化偏置向量以及权值矩阵;
- 3) 运行前向算法,并计算输出层单个神经元的代价函数;
- 4) 运行反向传播算法,利用梯度下降法更新权值矩阵。

## 3 ELM 模型的构建

ELM 是一种前向神经网络,其结构由输入层、一个隐藏层和输出层组成。相比于 BP、SVM 算法,ELM 具有易于使用、计算速度快、泛化能力强等优点<sup>[15]</sup>。

假定训练集为  $S = \{(X_i, t_i) | X_i \in R^n, t_i \in R^m, i = 1, \dots, N\}$ , 激活函数为  $g(x)$ , 隐藏层节点数为  $\tilde{N}$ , 输入层与隐藏层间的权值矩阵为  $W = (w_{ij})_{N \times \tilde{N}}$ , 隐藏层阈值为  $b = (b_1, b_2, \dots, b_{\tilde{N}})$ , 则 ELM 模型可表示为:

$$\sum_{i=1}^{\tilde{N}} g(w_i \cdot x_i + b_i) \beta_i = t_j, j = 1, 2, \dots, N \quad (17)$$

用矩阵的方式可转换为:

$$H\beta = T \quad (18)$$

具体算法步骤如下。

- 1) 随机产生输入层与隐含层的连接权值  $w_{ij}$  与隐藏层神经元阈值  $b_i$ ;
- 2) 根据  $H\beta = T$ , 计算隐藏层输出矩阵  $H$ ;
- 3) 通过求解方程组得  $\beta = H^+ T$ , 计算输出层权值  $\beta$ , 其中  $H^+$  为  $H$  的伪逆矩阵。

## 4 基于 GDIF-AN 的故障诊断方法

轴承振动信号是一种典型的非线性信号,由于工况的复杂,所采集的振动信号含有不同程度的噪声;且随着工况复杂度的提高、设备组件数量的增多,导致具有随机性、传播性等特征的故障频发,若采用单一特征对设备进行诊断,由于包含的信息较少,导致误诊、漏诊概率较高,而采用多特征,又面临信息间的冗余问题<sup>[16-18]</sup>。因此,本文将广义形态差值滤波与 AN 相结合,该方法首先利用广义形态差值滤波对信号进行降噪处理;然后,提取降噪后信号的多域特征,构建高维特征集;最后,利用 AN 对高维特征进行约简,并利用低维特征构建 ELM 故障诊断模型,对设备运行状态进行分析与诊断,具体诊断流程如下。

- 1) 通过广义形态差值滤波对信号进行滤波降噪;
- 2) 提取去噪后信号的时域、频域、排列熵等特征,构建高维特征集;
- 3) 利用极大似然值估计法估计特征的本征维数;
- 4) 利用 AN 提取高维特征中的低维流形;
- 5) 将低维特征用于建立 ELM 故障诊断模型,对设备状态进行分析与诊断。

## 5 实例分析

### 5.1 实验平台

数据来自德国 Paderborn 大学轴承数据集<sup>[19]</sup>, 实验平台如图 1 所示,装置从左到右分别为测试电机,测量轴、轴承组件、飞轮、电动机负载,采样频率 64 000 Hz。由于实验平台为真实损伤,仅有正常、内圈、外圈故障等 3 种状态。实验轴承各项参数如表 3 所示,经过计算可得外圈故障基频为 104.56 Hz, 内圈故障基频为 157.94 Hz, 滚动体故障基频为 137.48 Hz。




图 1 实验平台

Fig.1 Experimental platform

表 3 实验轴承基础参数

Table 3 Specific information about test bearing

轴承参数	值
轴承型号	6203-2RS JEM SKF
滚动体直径 $d/\text{mm}$	7.94
节圆直径 $D/\text{mm}$	39.04
滚动体数 $z$	9
接触角/ $^\circ$	0

### 5.2 分析验证

选取正常状态、内圈故障状态、外圈故障状态各 100 个样本,共计 300 个样本。每个样本选取 10 240 个采样数据点作为原始振动信号进行分析。外圈故障信号时域波形如图 2 所示,可以发现原始信号中波形较为复杂且噪声较多。首先,对该振动信号进行广义形态差值滤波,滤除噪声信号。滤波前的包络谱图如图 3 所示,滤波后的包络谱图如图 4 所示。由图 3、4 可以看出,广义形态差值滤波能够有效滤除振动信号中的噪声成分,峰值更加集中在外圈故障基频 104.56 Hz,二倍频 209.12 Hz,三倍频 313.68 Hz 附近。




图 2 外圈故障信号时域波形

Fig.2 Time-domain waveform of outer race fault signal




图 3 滤波前的包络谱图

Fig.3 Spectral envelope before filtering




图 4 滤波后的包络谱图

Fig.4 Spectral envelope after filtering

对滤除噪声后的 300 个样本,提取其 16 个时域特征参数、13 个频域特征参数以及 1 个排列熵共 30 个特征构建 300×30 的高维特征集。

将正常状态、内圈、外圈两种故障状态的特征利用 MLE 估计其本征维数,其结果为 3 维。设置自编码器学习率为 1,隐藏层数为 3,去噪参数为 0.1,迭代次数为 30,训练自编码器,对 30 维特征进行维数约简,得到 300×3 的特征集,其降维前后前三维特征可视化结果如图 5 所示。对比两图可以发现在降维后的特征空间中能够有效的对故障数据集进行分类。

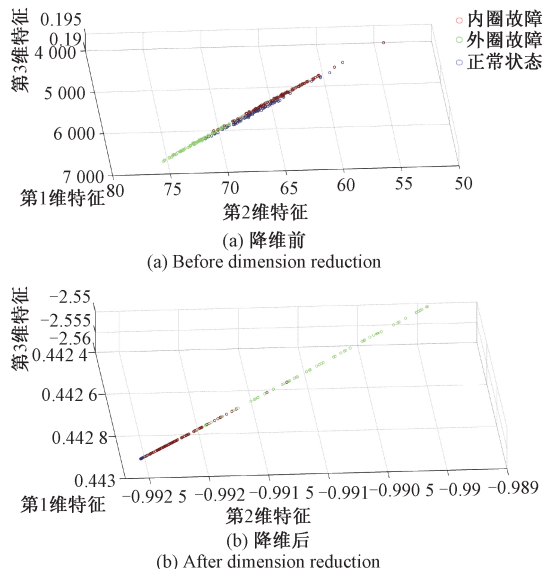


图 5 降维前后前三维特征可视化结果

Fig.5 Visualization results of pre-three-dimensional features before and after dimension reduction

将降维后的 3 维特征数据集作为样本的特征向量,建立 ELM 故障诊断模型,对轴承故障状态进行辨识。将每种故障状态的样本集随机划分为 66 个训练集与 34 个测试集,共计 198 个训练集样本、102 个测试集样本。设置隐藏层神经元个数为 40,激励函数为 Sigmoid 函数,其测试集分类结果如图 6 所示。图 7 所示为仅进行广义形态学滤波处理的 ELM 模型识别结果,图 8 所示为仅进行 AN 降维的 ELM 诊断模型的识别结果。对比可知,针对同一个样本数据集,基于 GDIF-AN 的 ELM 故障诊断模型识别精度最高,为 98.04%。表 4 为 ELM 模型与 AN-ELM 模型更新时间,AN-ELM 利用较小的时间损耗,大大提升了模型的识别精度。

表 4 ELM 与 AN-ELM 模型更新时间比较

Table 4 Time comparison of updating between ELM and AN-ELM model

	ELM	AN-ELM
时间/s	1.051 204	1.138 679




图6 GDIF-AN-ELM 模型识别结果

Fig.6 Recognition result of GDIF-AN-ELM model

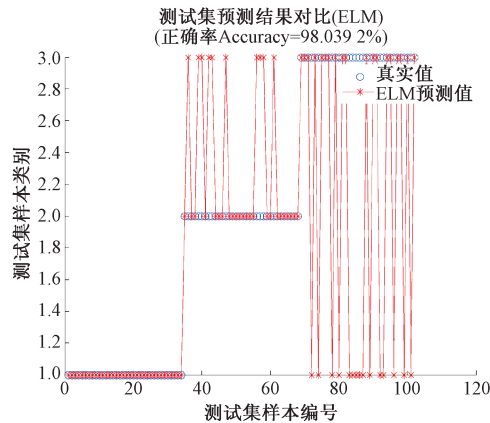


图7 GDIF-ELM 模型识别结果

Fig.7 Recognition result of GDIF-ELM

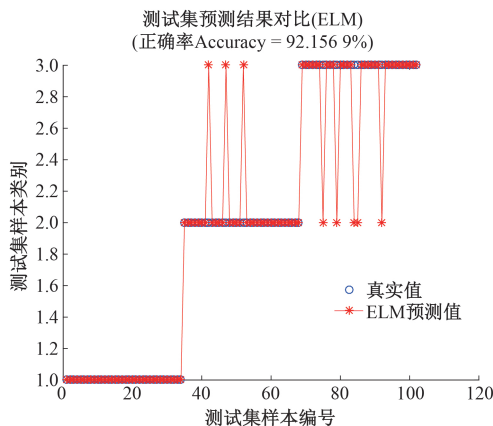


图8 AN-ELM 模型识别结果

Fig.8 Recognition result of AN-ELM model

实验结果表明, GDIF 能够有效滤除噪声影响, 提取有效特征向量, AN 能够对高维特征进行有效约简, 提取高维特征中的低维本质流形, 提高模型的分辨率。综上

所述, 本文提出的基于广义形态差值滤波与 AN 的故障诊断方法能够对轴承状态进行有效监测。

## 6 结 论

通过对滤波前后的信号进行包络谱分析可知, 广义形态差值滤波能够有效滤除振动信号中的噪声成分。AN 能够有效对高维特征进行维数约简, 提取其低维本质流形, 防止高维特征间产生的信号冗余问题, 提高模型的辨识精度。本文采用了振动信号数据对设备进行分析, 而在实际工程中, 通常包含电信号、振动信号等多传感器信息, 如何利用包含更多设备状态信息的多传感器信号, 对设备进行混合建模, 是今后的研究方向与重点。

## 参考文献

- [ 1 ] MIAO Y H, ZHANG M, LIN J. Periodicity-impulsiveness spectrum based on singular value negentropy and its application for identification of optimal frequency band [ J ]. IEEE Transactions on Industrial Electronics, 2019, 66(4) : 3127-3138.
- [ 2 ] ZHAO Z, SHUMING W, BAIJIE Q, et al. Enhanced sparse period-group lasso for bearing fault diagnosis [ J ]. IEEE Transactions on Industrial Electronics, 2019, 66(3) : 2143-2153.
- [ 3 ] PANDARAKONE S E, MIZUNO Y, NAKAMURA H. Evaluating the progression and orientation of scratches on outer-raceway bearing using a pattern recognition method [ J ]. IEEE Transactions on Industrial Electronics, 2019, 66(2) : 1307-1314.
- [ 4 ] LV J, YU J. Average combination difference morphological filters for fault feature extraction of bearing [ J ]. Mechanical Systems and Signal Processing, 2018(100) : 827-845.
- [ 5 ] SHEN C, TSE P W, ZHU Z, et al. Rolling element bearing fault diagnosis based on EEMD and improved morphological filtering method [ J ]. Journal of Vibration and Shock, 2013, 32(2) : 39-43, 66.
- [ 6 ] 黄刚劲, 范玉刚, 黄国勇. CEEMD 与广义形态差值滤波结合的故障诊断方法研究 [ J ]. 华中师范大学学报 (自然科学版), 2017, 51(3) : 304-308, 316.  
HUANG G J, FAN Y G, HUANG G Y. Research on fault diagnosis method combining CEEMD with generalized morphology difference filter [ J ]. Journal of Central China Normal University ( Natural Sciences ), 2017, 51(3) : 304-308, 316.
- [ 7 ] 王龙胜, 吕勇, 肖涵. 广义形态差值滤波器的构造及其在轴承故障中的应用 [ J ]. 机械设计与制造, 2015(6) : 25-29.  
WANG L SH, LV Y, XIAO H. Structure and application



- of generalized morphology difference filter in the bearing failure[J]. Machinery Design & Manufacture, 2015(6): 25-29.
- [ 8 ] 金涛, 刘对. 基于改进形态滤波与 TLS-ESPRIT 算法的电力系统低频振荡模态辨识[J]. 中国测试, 2017, 43(1): 89-95.
- JIN T, LIU D. Identification of low frequency oscillation in power system based on improved generalized morphological method and TLS-ESPRIT algorithm [ J ]. China Measurement & Testing, 2017, 43(1): 89-95.
- [ 9 ] 经哲, 郭利. 自适应随机共振形态学在液压泵振动信号特征提取中的应用 [ J ]. 仪表技术与传感器, 2015(8): 92-95, 99.
- JING ZH, GUO L. Application of adaptive stochastic resonance morphology in hydraulic pump vibration signal feature extraction[J]. Instrument Technique and Sensor, 2015(8): 92-95, 99.
- [ 10 ] AKHAND R, UPADHYAY S H. An integrated approach to bearing prognostics based on EEMD-multi feature extraction, Gaussian mixture models and Jensen-Renyi divergence [ J ]. Applied Soft Computing, 2018, 71: 36-50.
- [ 11 ] 钱伟, 王海斌, 杨江, 等. 飞机发电机故障诊断的多特征参数组合分析 [ J ]. 测控技术, 2017, 36(7): 47-51, 58.
- QIAN W, WANG H B, YANG J, et al. Combination analysis on multi-characteristic parameters of aircraft generator fault diagnosis [ J ]. Measurement & Control Technology, 2017, 36(7): 47-51, 58.
- [ 12 ] 郑近德, 刘涛, 孟瑞, 等. 基于广义复合多尺度排列熵与 PCA 的滚动轴承故障诊断方法 [ J ]. 振动与冲击, 2018, 37(20): 61-66.
- ZHENG J D, LIU T, MENG R, et al. Generalized composite multiscale permutation entropy and PCA based fault diagnosis of rolling bearings [ J ]. Journal of Vibration and Shock, 2018, 37(20): 61-66.
- [ 13 ] 江航, 尚春阳, 高瑞鹏. 基于 EMD 和神经网络的轮轨故障噪声诊断识别方法研究 [ J ]. 振动与冲击, 2014, 33(17): 34-38.
- JIANG H, SHANG C Y, GAO R P. Wheel/rail fault noise diagnosis method based on EMD and neural network [ J ]. Journal of Vibration and Shock, 2014, 33(17): 34-38.
- [ 14 ] YU X J, YIN J J, YU X, et al. Infrared spectra modeling of insoluble dietary fiber content in moso bamboo shoot based on auto-encoder network manifold learning [ J ]. Spectroscopy and Spectral Analysis, 2013, 33(6): 1512-1516.
- [ 15 ] WANG Z Q, XIN J C, YANG H X, et al. Distributed and weighted extreme learning machine for imbalanced big data learning [ J ]. Tsinghua Science and Technology, 2017, 22(2): 160-173.
- [ 16 ] 肖顺根, 马善红, 宋萌萌, 等. 基于 EEMD 和 PCA 滚动轴承性能退化指标的提取方法 [ J ]. 江南大学学报 (自然科学版), 2015, 14(5): 572-579.
- XIAO SH G, MA SH H, SONG M M, et al. Performance degradation indicator extraction method of rolling bearings based on the EEMD and PCA [ J ]. Journal of Jiangnan University ( Natural Science Edition ), 2015, 14(5): 572-579.
- [ 17 ] 马婧华, 汤宝平, 宋涛. 基于自适应本征维数估计流形学习的相空间重构降噪方法 [ J ], 振动与冲击, 2015, 34(11): 29-34.
- MA J H, TANG B P, SONG T. Phase space reconstruction method for vibration signal's noise reduction based on adaptive intrinsic dimension estimation manifold learning [ J ]. Journal of Vibration and Shock, 2015, 34(11): 29-34.
- [ 18 ] 崔锡龙, 王红军, 邢济收, 等. 广义形态滤波和 VMD 分解的滚动轴承故障诊断 [ J ]. 电子测量与仪器学报, 2018, 32(4): 51-57.
- CUI X L, WANG H J, XING J SH, et al. Rolling bearing fault diagnosis of generalized morphological filtering and VMD decomposition [ J ]. Journal of Electronic Measurement and Instrumentation, 2018, 32(4): 51-57.
- [ 19 ] LESSMEIER C, KIMOTH O J K, ZIMMER D, et al. Condition monitoring of bearing damage in electromechanical drive systems by using motor current signals of electric motors: A benchmark data set for data-driven classification [ C ]. Proceedings of the European Conference of the Prognostics and Health Management Society, 2016: 5-8.

## 作者简介



肖洁, 2017 年于东华大学获得学士学位, 现为昆明理工大学硕士研究生, 主要研究方向为设备状态监测与故障诊断。

E-mail: 785228291@qq.com

**Xiao Jie** received her B.Sc. degree from Donghua University in 2017. She is currently a M.Sc. candidate at Kunming University of Science and Technology. Her main research interests include equipment condition monitoring and fault diagnosis.