

基于 PLS-ELM 的滚动轴承性能衰退预测^{*}

王亚萍¹, 周 蓓², 白健弘², 田卫明², 葛江华¹

(1. 哈尔滨理工大学先进制造智能化技术教育部重点实验室 哈尔滨, 150080)

(2. 北京理工大学信息与电子学院 北京, 100081)

摘要 针对传统极限学习机预测滚动轴承故障时, 存在信号模式混叠、人为参数选取造成预测精度低下的问题, 提出了正态分布-经验小波变换结合偏最小二乘法的极限学习机(partial least squares-extreme learning machines, 简称 PLS-ELM)的故障预测方法。首先, 提出正态分布-经验小波变换信号降噪方法, 通过正态分布划分频率带界限, 在各频率带上构建带通滤波器进行降噪; 其次, 提出 PLS-ELM 的故障预测方法, 应用偏最小二乘法(partial least squares, 简称 PLS)中主成分数和加载权重分别改进极限学习机(extreme learning machines, 简称 ELM)隐含层节点数和网络权值, 激活函数选取 Softmax 以提高数据的拟合精度; 最后, 应用无量纲指标峭度来反映故障程度, 实现故障趋势预测。试验结果表明, 该方法能够准确划分频谱和克服模式混叠等问题, 并实现滚动轴承性能衰退趋势预测。

关键词 滚动轴承; 正态分布-经验小波变换; 偏最小二乘法的极限学习机; 性能衰退预测

中图分类号 TH165⁺.3; TN911.7

引言

随着大型旋转机械设备复杂化、精密化及系统化程度的提高, 对其生产的安全性、稳定性和可靠性要求越加严格。滚动轴承作为旋转机械里的核心零部件之一, 其健康与否会对一台旋转机械设备或者整个生产加工系统运转产生直接的影响。因此, 对滚动轴承进行状态检测与故障预测^[1]对降低设备使用风险、保障设备运行安全和避免灾难性事故发生具有重大意义。

在实际工况中由于环境里掺杂大量的噪声因素, 早期对信号进行时域频域的分析方法存在一定的不可靠性。例如, 经验模态分解(empirical mode decomposition, 简称 EMD)存在模态混叠^[2-3]等问题。小波变换^[4]由于海森堡不确定性原理和非适应性, 基函数一旦选定就无法更改。为此, Gilles 提出了经验小波变换(empirical wavelet transform, 简称 EWT)对信号进行处理的方法。EWT 能够对原始信号的傅里叶频谱进行自适应划分, 且能够在自适应划分的区间根据相应的带通滤波器构造出正交带通滤波器组, 以此对其提取出有用的调幅-调频分

量^[5]。邓飞跃等^[6]应用自适应频率窗 EWT 方法, 提取强背景噪声滚动轴承故障特征。Luo 等^[7]提出了自回归经验小波变换(the auto-regressive empirical wavelet transform, 简称 AR-EWT)方法, 在自回归功率谱中抑制非平稳因子, 正确分解添加有高斯白噪声和非静止分量的信号。EWT 信号降噪方法的核心是能够对信号的频谱进行自适应划分^[8], 划分结果直接影响后续信号分解的效果。祝文颖等^[9]采用单个分量估算的方法对频谱进行划分, 且提出了对敏感信号单个分量的选取方法, 但依旧存在 EWT 区间定位模糊的问题。正常滚动轴承振幅值的概率密度曲线表现为正态分布, 可应用区间估计进行频率带的划分。

通过降噪预处理后的数据可代入故障预测模型, 笔者应用的极限学习机中网络参数随机选取, 无需迭代寻优。Sun 等^[10]提出了集成的方法结合极限学习机减少随机参数的影响。Huang 等^[11]提出一种基于核函数的极限学习机, 以解决隐含层节点数不确定的问题。孙朝江等^[12]提出一种基于选择性更新的在线核极限学习机建模方法, 提高了在线软测量模型的学习速度和预测性能。Ban 等^[13]提出了平衡和优化学习的加权极限学习机, 改进的加

* 国家自然科学基金资助项目(51575143); 黑龙江省自然科学基金资助项目(E2018046)

收稿日期: 2019-04-02; 修回日期: 2019-07-02

权 ELM 在拟合非线性数据方面取得了较好的效果,但其计算复杂。偏最小二乘法^[14]是一种多个因变量对多自变量的线性回归建模方法,将线性回归分析、典型相关分析和主成分分析相结合,可以为预测领域提供更为丰富、深入的信息。

笔者首先提出正态分布-经验小波变换降噪方法,通过正态分布自适应地对信号频谱进行划分,克服模态混叠等问题;其次,应用 PLS-ELM 的故障预测模型进行性能衰退预测,有效划分滚动轴承全生命周期的故障阶段。

1 正态分布-经验小波降噪

经验小波变换的实质是对信号的频谱进行划分,并相应的在每个区间构造带通滤波器,对信号进行降噪,为后续故障预测奠定基础。

1.1 正态分布确定区间个数

正态分布是熵最大、最混乱无序的分布,自然界大多数现象都服从正态分布。机械故障领域受大量独立、均匀效应影响的机械振动被视为正态分布。

设定随机样本 x_1, x_2, \dots, x_n 的真值为 x ,根据误差密度函数 $f(x)$ 可得

$$L(x) = f(x_1 - x)f(x_2 - x)\cdots f(x_n - x) \quad (1)$$

对 $L(x)$ 取对数并求导,设 $g(x) = \frac{f'(x)}{f(x)}$,可得

$$\sum_{i=1}^n g(x_i - \bar{x}) = 0 \quad (2)$$

拉普拉斯给出误差分布 $f(x)$ 满足 $g(x) = g(-x)$ 。取自然数 $m = n - 1$,令 $x_1 = x_2 = \dots = x_m = -x$, $x_n = mx$,则

$$mg(x) = g(mx) \quad (3)$$

为满足式(3),设 $g(x) = cx$,积分可得

$$f(x) = ke^{\frac{1}{2}Cx^2} \quad (4)$$

且 $\int_{-\infty}^{+\infty} f(x) dx = 1$,令 C 和 k 取相应值,则有

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2}{2\sigma^2}} \quad (5)$$

令数据集 $\mathbf{Y} = |\mathbf{X}|$,求出位置参数 μ 和形状参数 σ ,确定区间个数为

$$f(x)_{\max} = \frac{1}{2\sqrt{2\pi}\sigma} \quad (x = \mu) \quad (6)$$

1.2 构建区间内的带通滤波器

确定好频谱划分的区间边界后,模拟小波变换的信号处理方式,在每个划分的区间上构建带通滤

波器,根据 2π 的周期性只研究区间 $[0, 2\pi]$,可得到

$$|\hat{\varphi}_1(\omega)|^2 + |\hat{\varphi}_1(\omega - 2\pi)|^2 + \sum_{n=1}^M (|\hat{\psi}_n(\omega)|^2 + |\hat{\psi}_n(\omega - 2\pi)|^2) = 1 \quad (7)$$

其中: $\hat{\psi}_n$ 为经验小波函数; $\hat{\varphi}_n$ 为经验尺度函数。

在 T_n 不重叠的情况下也同样适用于 T_n ,即

$$\tau_n + \tau_{n+1} < \omega_{n+1} - \omega_n \Leftrightarrow \gamma\omega_n + \gamma\omega_{n+1} < \omega_{n+1} - \omega_n \Leftrightarrow \gamma < \frac{\omega_{n+1} - \omega_n}{\omega_{n+1} + \omega_n} \quad (8)$$

经验小波变换的细节系数为

$$\omega_f^\epsilon(n, t) = [f, \psi_n] = \int \overline{f(\tau) \psi_n(\tau - t)} dt = (\hat{f}(\omega) \overline{\hat{\psi}_n(\omega)}) \quad (9)$$

经验小波变换的近似系数为

$$\omega_f^\epsilon(0, t) = [f, \varphi_1] = \int f(\tau) \overline{\varphi_1(\tau - t)} dt = (\hat{f}(\omega) \overline{\hat{\varphi}_1(\omega)}) \quad (10)$$

由以上可得到经验模态函数为

$$\begin{cases} f_0(t) = \omega_f^\epsilon(0, t)^* \varphi_1(t) \\ f_k(t) = \omega_f^\epsilon(k, t)^* \psi(t) \end{cases} \quad (11)$$

1.3 调幅-调频分量筛选指标

基于有量纲的信号分析对轴承进行故障诊断,主要通过对信号时域分析进行诊断,主要包含均值、均方根值和方差 3 种参数。有量纲的指标能够有效反映不同程度的故障,通常用于中重度故障进行诊断或预测,对外部环境的变化比较敏感,且易受复合故障的影响。

无量纲指标是根据有量纲指标的比值转化而来,反映的是频率密度函数的形状。对于时间序列信号 $\mathbf{X} = \{x_i\}, i = 1, 2, \dots, n$,笔者应用的无量纲幅域参数为波形指标 S_f 、峰值指标 C_f 、脉冲指标 I_f 、裕度指标 CL_f 和峭度指标 K_r 。

2 基于 PLS-ELM 的故障预测

极限学习机是基于单隐层前馈神经网络的一种学习算法,由输入层、隐含层和输出层构成。对于连接输入层和隐含层的输入权值与隐含层的偏置值随机选取,输出的最小二乘解是依据连接隐含层和输出层的参数输出权值通过对平方损失函数最小化计算得到。

2.1 偏最小二乘法改进极限学习机

偏最小二乘回归方法是在主成分分析思想的基础上发展起来的,主要研究多因变量对多自变量的

回归建模。

设有 p 个自变量 $\{x_1, x_2, \dots, x_p\}$ 和 q 个因变量 $\{y_1, y_2, \dots, y_q\}$, 观察 n 个样本点进行标准化, 观察数据矩阵分别记为

$$\mathbf{X}_0 = \begin{bmatrix} x_{11} & \cdots & x_{1p} \\ x_{21} & \cdots & x_{2p} \\ \vdots & & \vdots \\ x_{n1} & \cdots & x_{np} \end{bmatrix} \quad (12a)$$

$$\mathbf{Y}_0 = \begin{bmatrix} y_{11} & \cdots & y_{1q} \\ y_{21} & \cdots & y_{2q} \\ \vdots & & \vdots \\ y_{n1} & \cdots & y_{nq} \end{bmatrix} \quad (12b)$$

算法流程如下。

1) 依据相关性最大的原则对变量组里的第 1 主成分进行提取, 提取的第 1 成分 $t_1 = w_{11}x_1 + \dots + w_{1p}x_p$, $\hat{\mathbf{u}}_1 = v_{11}y_1 + \dots + v_{1q}y_q$, 尽量提取存在变量组里的变异信息。计算第 1 对成分的得分向量, 定义为 $\hat{\mathbf{t}}_1$ 和 $\hat{\mathbf{u}}_1$, 则表达式为

$$\hat{\mathbf{t}}_1 = \mathbf{X}_0 \mathbf{w}_1 = \begin{pmatrix} t_{11} \\ t_{21} \\ \vdots \\ t_{n1} \end{pmatrix} \quad (13a)$$

$$\hat{\mathbf{u}}_1 = \mathbf{Y}_0 \mathbf{v}_1 = \begin{pmatrix} u_{11} \\ u_{21} \\ \vdots \\ u_{n1} \end{pmatrix} \quad (13b)$$

2) 将上述转化为数学中的条件极值问题

$$\langle \hat{\mathbf{t}}_1, \hat{\mathbf{u}}_1 \rangle = \langle \mathbf{X}_0 \mathbf{w}_1, \mathbf{Y}_0 \mathbf{v}_1 \rangle = \mathbf{w}_1^T \mathbf{X}_0^T \mathbf{Y}_0 \mathbf{v}_1 \Rightarrow \max \mathbf{w}_1^T \mathbf{w} = \|\mathbf{w}_1\|^2 = 1, \mathbf{v}_1^T \mathbf{v} = \|\mathbf{v}_1\|^2 = 1$$

3) 建立因变量和自变量对 t_1 的回归假定回归模型

$$\mathbf{X}_0 = \hat{\mathbf{t}}_1 \boldsymbol{\alpha}_1^\top + \mathbf{X}_1 \quad (14a)$$

$$\mathbf{Y}_0 = \hat{\mathbf{t}}_1 \boldsymbol{\beta}_1^\top + \mathbf{Y}_1 \quad (14b)$$

其中: $\boldsymbol{\alpha}_1$ 和 $\boldsymbol{\beta}_1$ 分别为多对一的回归模型中的参数向量; \mathbf{X}_1 和 \mathbf{Y}_1 为残差矩阵。

回归参数向量 $\boldsymbol{\alpha}_1$ 和 $\boldsymbol{\beta}_1$ 的最小二乘估计为

$$\boldsymbol{\alpha}_1 = \mathbf{X}_0^\top \hat{\mathbf{t}}_1 / \|\hat{\mathbf{t}}_1\|^2 \quad (15a)$$

$$\boldsymbol{\beta}_1 = \mathbf{Y}_0^\top \hat{\mathbf{t}}_1 / \|\hat{\mathbf{t}}_1\|^2 \quad (15b)$$

4) \mathbf{X}_1 和 \mathbf{Y}_1 代替 \mathbf{X}_0 和 \mathbf{Y}_0 : 若残差矩阵 \mathbf{Y}_1 的绝对值无限接近 0, 可以认为搭建的回归模型精度达标, 反之则用 \mathbf{X}_1 和 \mathbf{Y}_1 代替 \mathbf{X}_0 和 \mathbf{Y}_0 进行循环

$$\mathbf{w}_2 = (w_{21}, \dots, w_{2p})^\top \quad (16a)$$

$$\mathbf{v}_2 = (v_{21}, \dots, v_{2q})^\top \quad (16b)$$

同时, $\hat{\mathbf{t}}_2 = \mathbf{X}_1 \mathbf{w}_2$, $\hat{\mathbf{u}}_2 = \mathbf{Y}_1 \mathbf{v}_2$ 则为第 2 对成分得分向量。

$$\boldsymbol{\alpha}_2 = \mathbf{X}_1^\top \hat{\mathbf{t}}_2 / \|\hat{\mathbf{t}}_2\|^2 \quad (17a)$$

$$\boldsymbol{\beta}_2 = \mathbf{Y}_1^\top \hat{\mathbf{t}}_2 / \|\hat{\mathbf{t}}_2\|^2 \quad (17b)$$

分别为 \mathbf{X} , \mathbf{Y} 的第 2 对成分的负荷量, 则有

$$\mathbf{X}_0 = \hat{\mathbf{t}}_1 \boldsymbol{\alpha}_1^\top + \hat{\mathbf{t}}_2 \boldsymbol{\alpha}_2^\top + \mathbf{X}_2 \quad (18a)$$

$$\mathbf{Y}_0 = \hat{\mathbf{t}}_1 \boldsymbol{\beta}_1^\top + \hat{\mathbf{t}}_2 \boldsymbol{\beta}_2^\top + \mathbf{Y}_2 \quad (18b)$$

5) 使得 $n \times p$ 数据阵 \mathbf{X}_0 的秩 $r \leq \min(n-1, p)$, 则存在 r 个成分 t_1, t_2, \dots, t_r ,

$$\mathbf{X}_0 = \hat{\mathbf{t}}_1 \boldsymbol{\alpha}_1^\top + \dots + \hat{\mathbf{t}}_r \boldsymbol{\alpha}_r^\top + \mathbf{X}_r \quad (19a)$$

$$\mathbf{Y}_0 = \hat{\mathbf{t}}_1 \boldsymbol{\beta}_1^\top + \dots + \hat{\mathbf{t}}_r \boldsymbol{\beta}_r^\top + \mathbf{Y}_r \quad (19b)$$

把 $t_k = w_{k1}x_1 + \dots + w_{kp}x_p$ ($k=1, 2, \dots, r$) 代入 $\mathbf{Y} = t_1 \boldsymbol{\beta}_1 + \dots + t_r \boldsymbol{\beta}_r$, 得到 q 个因变量的偏最小二乘回归方程式为

$$y_j = a_{j1}x_1 + \dots + a_{jp}x_p \quad (j=1, 2, \dots, q) \quad (20)$$

2.2 基于PLS-ELM的故障预测

根据以上各个算法流程, 得到本研究整体流程如图 1 所示, 具体过程如下。

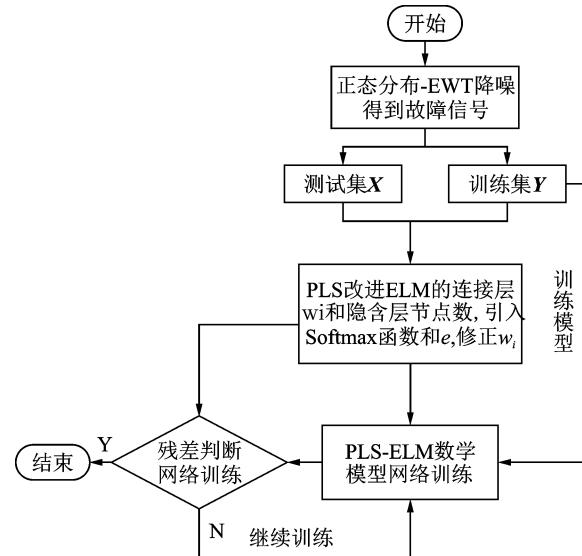


图 1 PLS-ELM 算法流程图

Fig. 1 PLS-ELM algorithm flow chart

1) 通过正态分布有效改进 EWT 频率带区间划分个数, 自适应划分 Fourier 频谱, 得到故障频率。

2) 降噪后的数据设 $\mathbf{X} = (x_1, \dots, x_p)$, $\mathbf{Y} = (y_1, \dots, y_m)$ 作为 ELM 的训练集和测试集, PLS 预处理数据得到主成分数和各自权重。

3) ELM 隐含层神经元个数即为主成分数, w_i 为输入层和隐含层之间的权值, β 为隐含层与输出层之间的初始权值。

4) 激活函数选取 Softmax, 将某一包含任何实数的 r 维向量 z 投影到 r 维实向量 $\sigma(z)$ 中, 每个元素在 $(0, 1)$ 之间且和为 1, 同时具有很强的非线性映

射能力

$$\sigma(z)_i = \frac{e^{z_i}}{\sum_1^r e^{z_i}} \quad (i=1,2,\dots,r) \quad (21)$$

输出层函数选取

$$\tilde{y} = \sum_{i=1}^r \beta_i t_i \quad (22)$$

5) 调整权值。计算网络误差为

$$e = \frac{1}{2}(y - \tilde{y})^2 \quad (23)$$

根据误差,求导并结合激活函数

$$\bar{\beta}_i = \beta_i + \eta t_i e' \quad (24)$$

6) 通过残差闭环反馈整个训练过程。

3 开源数据与试验数据验证

3.1 开源数据验证

为验证方法有效性,采用辛辛那提大学全寿命周期的试验数据。试验台上安装有 4 个双列滚动轴承,转速为 2 kr/min,采样频率为 20 kHz。试验时间为 2003-10-22T12:06:24 ~ 2003-11-25T23:59:56,历时 34 d,数据采集间隔为 10 min。试验结束后,轴承 3 内圈发生故障,根据数据得到如图 2 所示的振动信号时频域图。

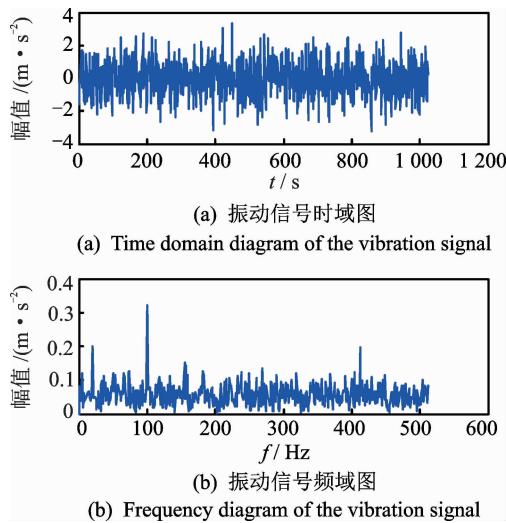


图 2 振动信号时频域图

Fig. 2 Time domain and frequency domain diagram of the vibration signal

传统的 EWT 频谱划分须计算出划分边界的具体数值。频谱的幅值极大值点如图 3 所示。

根据 $M_m + \alpha(M_1 - M_m) < M_i$ 计算得到 $i=5$, 所以取图 3 前 5 个极大值点。EWT 将这 5 个点所对应的横坐标中间值默认为边界点, 横坐标分别为

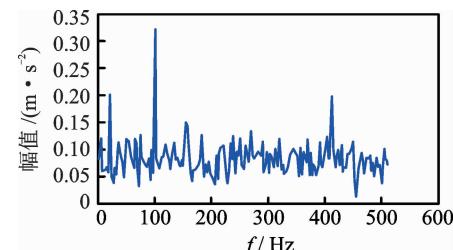


图 3 幅值极大值点

Fig. 3 Amplitude maximum point

[21, 101, 156, 158, 413], 边界值分别为 [11, 61, 128.5, 157, 285.5], 将频谱划分为 6 个区域。从图 4 可以看出,5 Hz 和 20 Hz 的频率并没有被划分开,噪声频率被划分到故障频率区域。

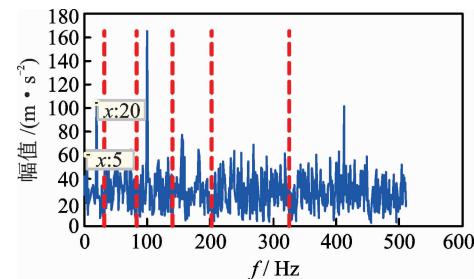


图 4 EWT 自适应频谱划分

Fig. 4 EWT adaptive spectrum division

采用正态分布对频谱的划分如图 5 所示,正态分布-EWT 的频谱划分结果和 EWT 的划分结果有所不同,在 5 Hz 和 20 Hz,20 Hz 和 100 Hz 之间存在划分边界,说明此方法可以实现准确划分。

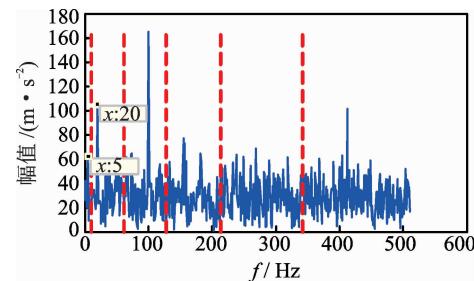


图 5 正态分布-EWT 频谱划分

Fig. 5 Normal distribution-EWT spectrum division

辛辛那提滚动轴承试验发生的是内圈故障,其故障频率计算公式为

$$f_i = \frac{1}{2} Z f_0 \left(1 + \frac{d}{D} \cos \alpha \right) \quad (25)$$

其中: Z 为滚动体个数; f_0 为主轴转频; d,D 分别为滚动体直径和节圆直径; α 为接触角。

采用小波变换、互补集合经验模态分解 (complementary ensemble empirical mode decompositi-

tion,简称CEEMD)和正态分布-EWT对信号分解并进行对比,分解结果如图6所示。

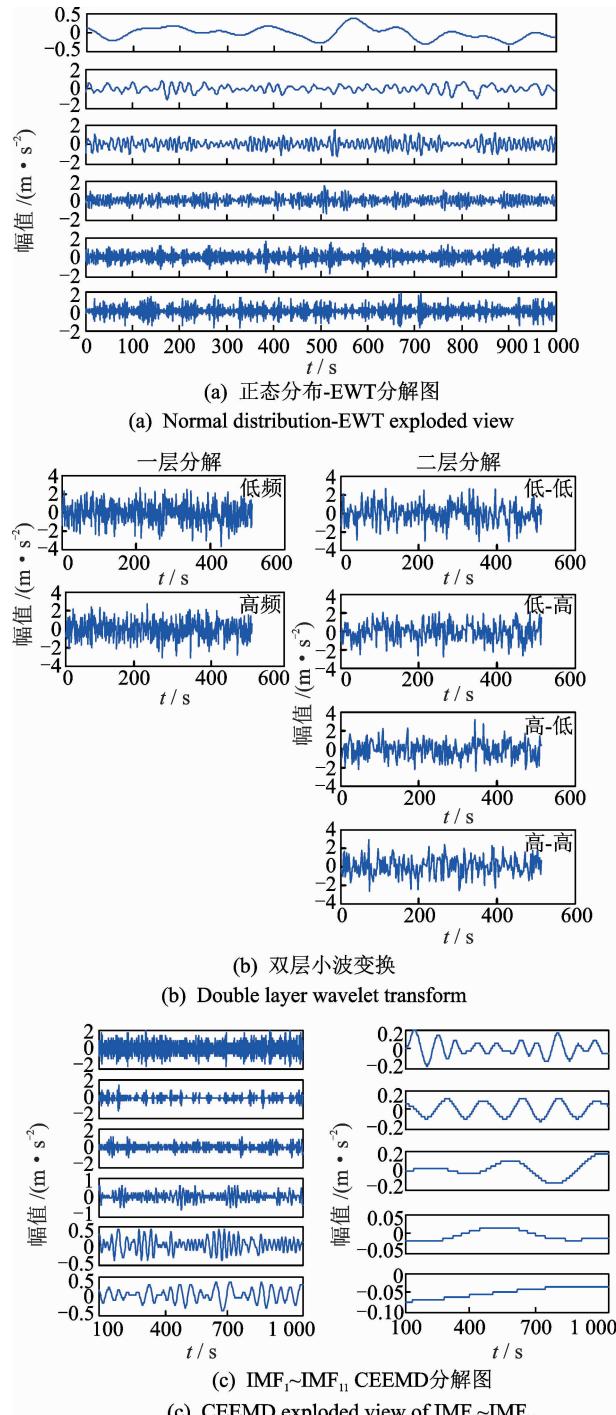


图6 正态分布-EWT、双层小波变换和CEEMD对比

Fig. 6 Comparison of Normal distribution-EWT, double layer wavelet transform and CEEMD

通过降噪分解对比,正态分布-EWT分解后的信号相对于EWT,CEEMD分解得到的分量更少,且接近于真实噪声。每个调幅-调频分量中仅含有1个主频成分,能够更好地区分故障频率与噪声频率。对比正态分布-EWT和CEEMD的图中可以看

出,CEEMD发生了模态混叠现象,正态分布-EWT的不同分量之间不存在模态混叠现象。

通过时间变化对每个指标的表现进行计算,如图7所示,脉冲指标26 d之前轴承工作平稳,从第26 d开始,波峰指标和峭度指标的幅值都有明显上升,说明这两个指标对轴承早期发生的故障较为敏感,并且在失效前始终存在相对明显的波动情况。

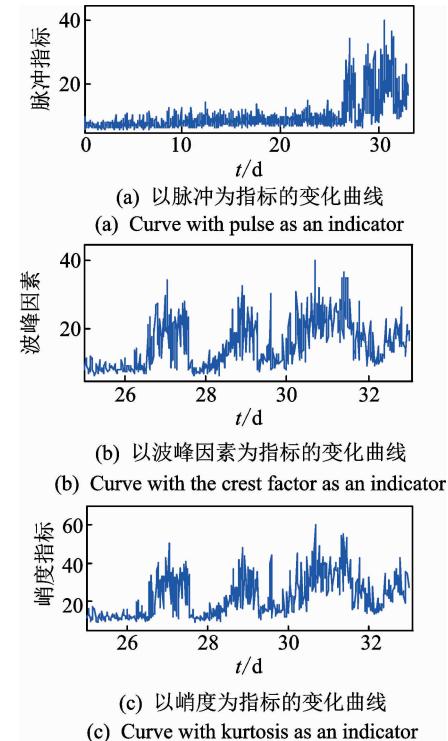


图7 不同指标的变化曲线

Fig. 7 Curve of variation of different indicators

以AM-FM₃为例,得到降噪时频谱图如图8所示。

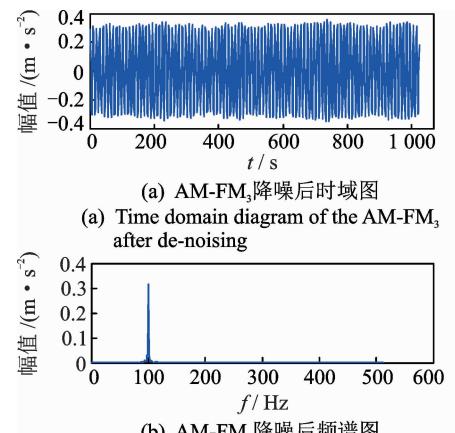


图8 AM-FM₃降噪时频谱图

Fig. 8 Time domain and frequency domain diagram of the AM-FM₃ after de-noising

根据式(25)可以看出,该方法能准确得出试验数据的故障频率。将正态分布-EWT 的降噪数据应用到故障预测模型,笔者将传统的极限学习机、支持向量机(support vector machine,简称 SVM)和偏最小二乘法的极限学习机预测精度及各参数进行对比,分别得到如图 9 所示的预测效果。表 1 为预测模型各指标对比。

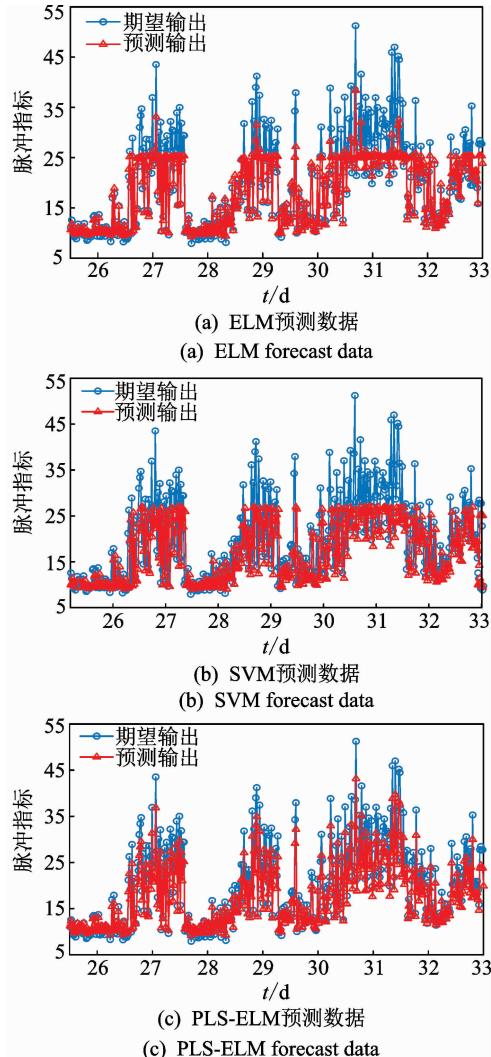


图 9 各种数学模型预测数据对比

Fig. 9 Various mathematical models predict data comparison

表 1 预测模型各指标对比

Tab. 1 Predictive model comparison of indicators

数学模型	均方误差	相关度
ELM	15.583 2	0.581 2
SVM	19.607 0	0.601 0
PLS-ELM	14.148 7	0.619 7

由表 1 可知:①偏最小二乘法的极限学习机的线性相关程度为 0.619 7,相较于前两者较高;②均方误差能很好地体现预测数据与原始数据的差异性,基于 PLS-ELM 的均方误差为 14.148 7,低于前两者。

3.2 试验数据验证

采用如图 10 所示的试验台来验证笔者提出的信号降噪与故障预测方法的有效性。滚动轴承振动测试台主要由 SGM7J-04AFC6S 伺服电机、YMC122A100 加速度传感器、POD-0.6 kg 磁粉制动器、GFC-40X66 梅花联轴器和底座等连接件与紧固件组。该试验用 CoCo-80 动态信号分析仪采集信号数据,7204C/P5 单列角接触球轴承,具体参数如表 2 所示。根据滚动轴承常见故障位置与故障类型,试验主要模拟外圈裂痕故障。



图 10 滚动轴承振动测试台

Fig. 10 Rolling bearing vibration test rig

表 2 轴承具体参数

Tab. 2 Specific parameters

内圈 / mm	外圈 / mm	厚度 / mm	动负荷 / kN	静负荷 / kN
20	47	14	14	7.84

转速 $n=1\text{kr}/\text{min}$,采样频率 $f=400\text{Hz}$ 。依据滚动轴承外圈故障频率的计算公式

$$f_0 = \frac{1}{2} Z f_0 \left(1 - \frac{d}{D} \cos\alpha\right) \quad (26)$$

得到外圈的故障频率约为 52.98 Hz。

数据经傅里叶变换后,裂痕故障信号频域图如图 11 所示。可以看出,裂痕故障对信号的影响比较大,信号的转动频率幅值较低。从频谱图能够清晰看到在 50~60 Hz 的区间存在一个波峰,其与理论计算频率极其接近。

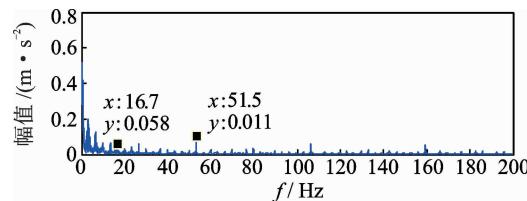


图 11 裂痕故障信号频域图

Fig. 11 Crack signal frequency domain diagram

采用正态分布-EWT 进行分解,得到 EWT 自适应频谱划分如图 12 所示。可以看出,故障频率位于第 3 个调幅-调频分量中,对其进行降噪后的频谱

图如图13所示。

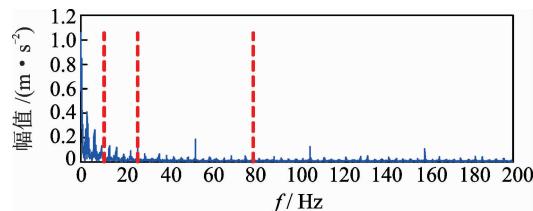
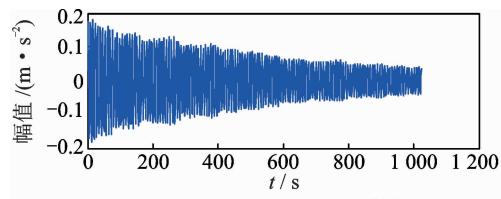


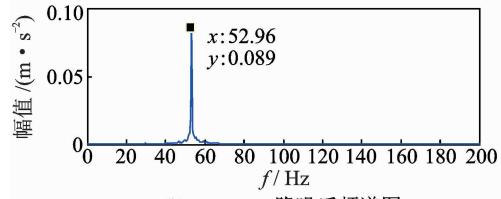
图12 EWT自适应频谱划分

Fig. 12 EWT adaptive spectrum division



(a) AM-FM₃降噪后时域图

(a) Time domain diagram of the AM-FM₃ after de-noising



(b) AM-FM₃降噪后频谱图

(b) Frequency domain diagram of the AM-FM₃ after de-noising

图13 降噪后AM-FM₃频谱图

Fig. 13 AM-FM₃ frequency spectrum after de-noising

通过对不同预测输入值进行试验对比,将未处理的数据和经过正态分布-EWT降噪的数据作为PLS-ELM的输入。峭度^[15]代表振动信号分布特性,可以用于提取设备的故障特征信息,峭度指标作为无量纲特征具有较好的稳定性。不同输入数据形式的结果如图14,15所示。可以看出,图14未经处理的数据进行预测会造成不同故障阶段的振动信号的混叠,而图15经过降噪处理后的数据可以准确实现轴承衰退阶段的划分。

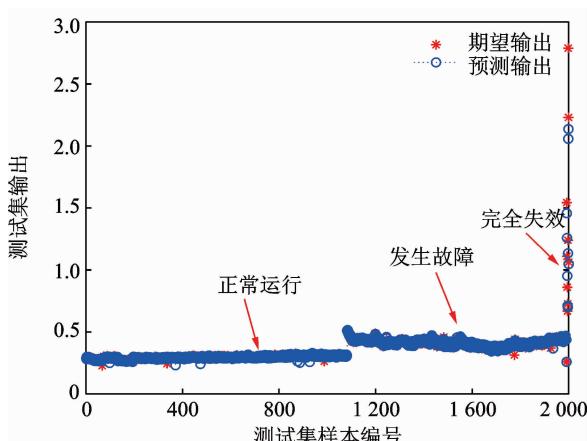


图14 原始数据的趋势预测

Fig. 14 Trend prediction of raw data

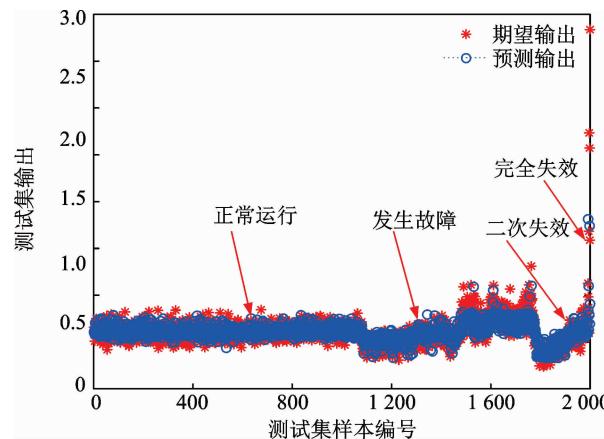


图15 降噪后的峭度指标趋势预测

Fig. 15 Prediction of kurtosis index trend after noise reduction

4 结论

1) 正态分布-EWT相对于传统信号分解方法,能够自适应的将信号频谱划分成区间,克服了模式混叠,每个分解得到的调幅-调频分量都只对应一个频率,分解准确性高。

2) 通过评价指标对各调幅-调频分量进行筛选,可以得到相关性最高的一组,降噪效果明显。

3) PLS-ELM相较SVM等故障预测方法的预测精度高,均方根误差更小,通过无量纲峭度指标可以看出,该方法能够实现滚动轴承衰退趋势的预测。

4) 通过仿真和试验数据验证,本研究方法能够有效地对振动信号进行降噪,得到具体的故障频率,实现故障位置的识别和故障趋势的预测。

参 考 文 献

- [1] 彭宇,刘大同. 数据驱动故障预测和健康管理综述[J]. 仪器仪表学报, 2014, 35(3):481-495.
PENG Yu, LIU Datong. Data-driven prognostics and health management: a review of recent advances[J]. Chinese Journal of Scientific Instrument, 2014, 35(3):481-495. (in Chinese)
- [2] DAUBECHIES I, LU J, WU H T. Synchrosqueezed wavelet transforms: an empirical mode decomposition-like tool [J]. Applied & Computational Harmonic Analysis, 2011, 30(2):243-261.
- [3] 王亚萍,许迪,葛江华,等. 基于SPWVD时频图纹理特征的滚动轴承故障诊断[J]. 振动、测试与诊断, 2017, 37(1): 115-119.
WANG Yaping, XU Di, GE Jianghua, et al. Rolling bearing faults diagnostics based on SPWVD time-fre-

- quency distribution image texture feature[J]. Journal of Vibration, Measurement & Diagnosis, 2017, 37(1):115-119. (in Chinese)
- [4] 程军圣,于德介,邓乾旺,等.时间-小波能量谱在滚动轴承故障诊断中的应用[J].振动与冲击,2004(2):33-36,127.
CHENG Junsheng, YU Dejie, DENG Qianwang, et al. Application of time-wavelet power spectrum to fault diagnosis of rolling bearings[J]. Journal of Vibration and Shock, 2004(2):33-36, 127. (in Chinese)
- [5] GILLES J. Empirical wavelet transform[J]. IEEE Transactions on Signal Processing, 2013, 61(61):3999-4010.
- [6] 邓飞跃,强亚文,杨绍普,等.一种自适应频率窗经验小波变换的滚动轴承故障诊断方法[J].西安交通大学学报,2018,52(8):22-29.
DENG Feiyue, QIANG Yawen, YANG Shaopu, et al. A fault diagnosis method of rolling element bearings with adaptive frequency window empirical wavelet transform[J]. Journal of Xi'an Jiaotong University, 2018, 52(8):22-29. (in Chinese)
- [7] LUO Z J, LIU T, YAN S Z, et al. Revised empirical wavelet transform based on auto-regressive power spectrum and its application to the mode decomposition of deployable structure[J]. Journal of Sound and Vibration, 2018, 431(29):70-87.
- [8] 陈志新,刘鑫,卢成林,等.基于经验小波变换的复杂强噪声背景下弱故障检测方法[J].农业工程学报,2016,32(20):202-208.
CHEN Zhixin, LIU Xin, LU Chenglin, et al. Weak fault detection method based on empirical wavelet transform in complex strong noise background[J]. Chinese Society of Agricultural Engineering, 2016, 32(20):202-208. (in Chinese)
- [9] 祝文颖,冯志鹏.基于改进经验小波变换的行星齿轮箱故障诊断[J].仪器仪表学报,2016,37(10):2193-2201.
ZHU Wenying, FENG Zhipeng. Fault diagnosis of planetary gearbox based on improved experience wavelet transform[J]. Chinese Journal of Scientific Instrument, 2016, 37(10):2193-2201. (in Chinese)
- [10] SUN Z L, CHOI T M, AU K F, et al. Sales forecasting using extreme learning machine with applications in fashion retailing[J]. Decision Support Systems, 2008, 46(1):411-419.
- [11] HUANG G B, DING X, ZHOU H. Optimization method based extreme learning machine for classification[J]. Neurocomputing, 2010, 74(1/3):155-163.
- [12] 孙朝江,汤健,魏忠军,等.基于选择性更新的在线核极限学习机建模[J].控制工程,2013,4:659-662.
SUN Chaojiang, TANG Jian, WEI Zhongjun, et al. On-line kernel extreme learning machine modelling based on selective update[J]. Control Engineering of China, 2013, 4: 659-662. (in Chinese)
- [13] BAN X, LIU R, SHEN Q, et al. Weighted extreme learning machine for balance and optimization learning [C] // International Conference on Cloud Computing and Intelligence Systems. [S. l.]: IEEE, 2016:1-11.
- [14] ZHOU J, GAO W, ZHANG S, et al. Quality-relevant fault monitoring based on locally linear embedding enhanced partial least squares statistical models[C] // 2017 IEEE 6th Data Driven Control and Learning Systems Conference (DDCLS). [S. l.]: IEEE, 2017.
- [15] 胡爱军,赵军,孙尚飞,等.基于谱峭度和最大相关峭度解卷积的滚动轴承复合故障特征分离方法[J].振动与冲击,2019,38(4):158-165.
HU Aijun, ZHAO Jun, SUN Shangfei, et al. Feature separation method of rolling bearing composite fault based on deconvolution of spectral kurtosis and maximum correlation kurtosis[J]. Journal of Vibration and Shock, 2019, 38(4):158-165. (in Chinese)



第一作者简介:王亚萍,女,1972年4月生,教授。主要研究方向为数字化设计与仿真分析、可靠性设计、故障诊断与寿命预测。曾发表《基于 SPWVD 时频图纹理特征的滚动轴承故障诊断》(《振动、测试与诊断》2017年第37卷第1期)等论文。

E-mail:wypbl@163.com