

DOI: 10.19650/j.cnki.cjsi.J2311256

基于贝塔分布与滤波降噪算法的滚动轴承故障预警方法*

田 晶^{1,2}, 高晓岚^{1,2}, 陈仁桢^{1,2}, 张凤玲^{1,2}, 王 志^{1,2}

(1. 沈阳航空航天大学航空发动机学院 沈阳 110136; 2. 沈阳航空航天大学辽宁省航空推进系统先进测试技术重点实验室 沈阳 110136)

摘 要:针对机械系统中轴承故障信号具有非线性、非平稳且伴随较强背景噪声的特点,造成实现轴承故障早期预警困难的问题,提出了一种基于贝塔分布与滤波降噪算法结合的滚动轴承智能预警方法。首先,该方法采用基于贝塔分布的阈值确定方法计算出监测数据的预警阈值区间。然后,采用滑动平均滤波算法对采集的数据进行降噪处理以消除数据监测噪声,同时,对比分析了滑动平均滤波、H-P 滤波和形态滤波的降噪效果。最后,将计算出的预警阈值区间与滤波后的数据进行对比,根据监测数据是否超出阈值区间做出预警。本文采用 XJTU-SY 数据集和轴承实验数据验证算法准确性。结果表明,本文所提出方法能够准确地计算出平稳运行中的滚动轴承的预警阈值区间,并有效地对发生早期故障的轴承做出预警,其中最快的预警反应时间为 56.76 s,最慢的预警反应时间为 778.20 s。同时对比分析结果表明,在对原始数据进行滤波降噪处理时,滑动平均滤波降噪效果优于 H-P 滤波和形态学滤波。

关键词: 阈值确定;故障预警;滚动轴承;滑动平均滤波;贝塔分布

中图分类号: TH133 **文献标识码:** A **国家标准学科分类代码:** 460.40

Fault early warning method of rolling bearing based on beta distribution and filter algorithm

Tian Jing^{1,2}, Gao Xiaolan^{1,2}, Chen Renzhen^{1,2}, Zhang Fengling^{1,2}, Wang Zhi^{1,2}

(1. School of Aero-Engine, Shenyang Aerospace University, Shenyang 110136, China; 2. Key Laboratory of Advanced Measurement and Test Technique for Aviation Propulsion System, Shenyang Aerospace University, Shenyang 110136, China)

Abstract: The fault signals of rolling bearings in mechanical systems are usually nonlinear, non-stationary, and accompanied by strong background noise, which makes it difficult to realize early warning of bearing fault. An intelligent early-warning method for rolling bearings based on beta distribution and filter denoising algorithm is proposed in this article. First, the early warning threshold value interval of the monitoring data is calculated by the threshold determination method based on the beta distribution. Then, the average filtering algorithm is used to reduce the noise of the collected data to eliminate the data monitoring noise. Meanwhile, the noise reduction effects of moving average filtering, H-P filtering, and morphological filtering are compared and analyzed. Finally, the calculated warning threshold interval is compared with the filtered data, and the early warning is made according to whether the monitoring data exceed the threshold interval. The XJTU-SY dataset and bearing experimental data are used to evaluate the accuracy of the algorithm. The results show that the proposed method can accurately calculate the early warning threshold interval of rolling bearings in smooth operation and effectively warn the bearings of early failures. The fastest early warning response time is 56.76 s and the slowest early warning response time is 778.20 s. Furthermore, the comparative analysis results show that the effect of moving average filtering is better than those of H-P filtering and morphological filtering when filtering the original data.

Keywords: threshold determination; fault early warning; rolling bearing; moving average filtering; beta distribution

收稿日期: 2023-04-03 Received Date: 2023-04-03

* 基金项目: 国家自然科学基金(12172231)、辽宁省兴辽英才计划项目(XLYC2203042)、沈阳市中青年科技创新人才支持计划(RC220439)项目资助

0 引言

滚动轴承因为其在机械设备中的不可替代的作用在航空航天、加工中心、船舶以及各种旋转机械中被广泛使用,故被誉为“工业的关节”^[1]。其运行状态决定了机械设备是否能保持良好的工作状态。据统计,由于滚动轴承故障失效导致旋转机械故障停机的比例占旋转机械总故障停机比例的 45% ~ 55%^[2]。因此,开展及时发现滚动轴承故障并且做出相应智能预警的滚动轴承预警方法的研究,具有重要的现实意义。

针对滚动轴承故障信号非线性、非平稳,并且伴随着较强的背景噪声的特点,专家学者提出了小波变换,随机共振等多种轴承故障信号的处理方法^[3-4]。小波变换(wavelet transform, WT)具有良好的时频分析能力,小波基函数可以实现对非平稳信号特征的提取,但不能对随机噪声进行自适应处理^[5]。随机共振(stochastic resonance, SR)能够从强背景噪声中有效提取微弱信号,但受限于随机共振的绝热近似和线性响应理论,在应用时有着复杂的限制条件^[6]。趋势滤波是一种常见的时间序列平滑方法,典型的趋势滤波方法有 H-P 滑动滤波和 I1 趋势滤波,由 Hodrick 等^[7]提出的 H-P 滤波在经济学领域广泛应用, Kim 等^[8]在 2009 年提出的 I1 趋势滤波为 H-P 滤波的变体,但这类算法在使用时需要事先假定趋势模型,选用合适的正则项。滑动平均滤波算法相比于传统的趋势滤波算法更容易估算出全局和局部斜率,其高通滤波特性对时间序列起到平滑作用^[9-10]。预警阈值区间的确定是当前机械在线监测系统能否高效准确地实现滚动轴承故障早期预警的重要影响因素。国内外诸多学者对研究实现故障智能预警技术做出了许多突破, Zhang 等^[11]对一种基于多元状态估计和滑动窗相似性的辅助设备故障预警方法进行了研究; Vafaei 等^[12]研究了基于状态维修的模糊预警系统为潜在的生产线故障或其他危险情况提供早期预警; 杨锡运等^[13]对融合集合经验模态分解与宽度学习的齿轮箱故障预警方法做出了研究; 杨婷婷等^[14]研究了基于卷积神经网络-长短时记忆神经网络的磨煤机故障预警。现有的预警方法多采用智能模式识别算法对数据趋势进行预测进而实现预警,在实现工程应用的过程中对硬件性能要求较高,且计算效率相对较低。贝塔分布作为一组定义在 (0, 1) 区间的连续概率分布,在机器学习、区间估计、数理统计等方面有广泛的应用。刘兴杰等^[15]利用参数优化后的非标准贝塔分布对风电功率预测误差概率分布进行了拟合,并利用所得分布函数对风电功率预测的波动区间进行了估计; 胡堂清等^[16]提出了一种动态调整惯性权重的混合粒子群算法加入贝塔分布的动态调整,使得算法有良好的

全局收敛能力; 侯代文等^[17]提出了一种双重粒子滤波方法,利用贝塔分布拟合系统参数的后验概率密度函数,在充分利用先验信息的前提下又避免了高斯分布拖尾部分采样,提高了采样效率。上述研究表明采用贝塔分布可以在保证效率的同时,准确地确定故障信号的预警阈值区间。

综上所述,本文将基于贝塔分布的阈值确定方法与滤波技术相结合构建智能故障预警算法,对机械设备平稳运行时滚动轴承发生故障与否进行预警。本文首先采用贝塔分布算法计算出动态阈值区间,然后对比几种滤波算法的降噪效果后,采用滑动平均滤波算法对原始趋势数据进行降噪处理,同时,与趋势滤波算法和形态滤波算法进行对比验证,最后将滤波降噪后的数据与动态阈值区间作比较,若超出阈值区间则说明滚动轴承发生故障,做出相应预警。本文采用西安交通大学的 XJTU-SY 轴承的实验数据验证该算法的准确性。

1 基于贝塔分布的动态阈值区间确定

对机械系统在线监测所选取的不同测点的监测参数趋势数据进行分参数检验可知,平稳状态下监测参数趋势数据不服从高斯分布,且同一机械系统的不同测点监测数据也来自不同总体^[18]。同样,对于机械系统中滚动轴承的监测参数趋势数据既不服从高斯分布也不来自同一总体,对于不同测点的趋势数据分布形式不同。因此,本文提出使用贝塔分布分别逼近正常运行采集到的各测点数据的概率密度分布,以得出轴承各个测点数据的贝塔概率密度函数,进而准确计算各个测点趋势数据的阈值区间。

1.1 贝塔分布

设随机变量的密度函数为:

$$f(x, \gamma, \eta, a, b) = \begin{cases} \frac{1}{(b-a)\beta(\gamma, \eta)} \left(\frac{x-a}{b-a}\right)^{\gamma-1} \left(1 - \frac{x-a}{b-a}\right)^{\eta-1}, & a \leq x \leq b \\ 0, & \text{其他} \end{cases} \quad (1)$$

其中:

$$\beta(\gamma, \eta) = \int_0^1 z^{\gamma-1} (1-z)^{\eta-1} dz, \gamma > 0, \eta > 0, \quad (2)$$

$$z = (x-a)/(b-a)$$

则称 x 服从贝塔分布,记为 $x \sim \beta(\gamma, \eta)$ 。 a, b 为 x 取值的上下边界值。形状参数 γ, η 的表达式为:

$$\gamma = \frac{(\mu_x - a)^2 (b - \mu_x) - \sigma_x^2 (\mu_x - a)}{\sigma_x^2 (b - a)} \quad (3)$$

$$\eta = \frac{(\mu_x - a) (b - \mu_x)^2 - \sigma_x^2 (b - \mu_x)}{\sigma_x^2 (b - a)}$$

式中: μ_x 为 x 的均值; σ_x 为 x 的标准差。

当 $a = 0, b = 1$ 时, 可得标准贝塔分布:

$$f(x, \gamma, \eta) = \frac{1}{\beta(\gamma, \eta)} x^{\gamma-1} (1-x)^{\eta-1}, \gamma > 0,$$

$$\eta > 0, 0 \leq x \leq 1 \quad (4)$$

贝塔分布密度函数为有界函数, 分布范围有限, 且贝塔分布函数简单, 只需选择适当的 γ, η 即可对多种不同形状的频率分布曲线进行拟合, 具有普适性及较好的准确性。

1.2 阈值区间确定方法

由于标准贝塔分布要求处理的趋势数据必须在 $0 \sim 1$ 之间, 而试验中采集到的振动数据不在此范围内, 因此必须将采集到的振动数据进行归一化处理。然后根据处理后的振动趋势数据计算贝塔分布的两个形状参数 γ 和 η , 最后计算出振动数据的自学习阈值区间。具体的智能学习算法如下:

1) 将监测时间内的振动数据 $X(i)$ 进行归一化处理:

$$X(i) = \frac{x - \min(x)}{\max(x) - \min(x)}, i = 1, 2, 3, \dots, N \quad (5)$$

式中: $\min(x)$ 为一组监测振动数据中的最小值; $\max(x)$ 为一组监测振动数据中的最大值。

2) 估计监测趋势数据的概率密度分布^[19]:

$$f(X_i; \gamma, \eta) = C_i / n B_i \quad i = 1, 2, \dots, N \quad (6)$$

将监测数据分为 N 个区间, X_i 是监测数据区间的中点值; γ, η 是贝塔分布的两个形状参数; C_i 是第 i 个区间中含有的数据点数; n 为监测数据个数; B_i 是区间的宽度。

3) 最小二乘法求贝塔分布的形状参数

$$\delta_i = \{\ln \{C_i / n B_i f(x_i, \gamma, \eta)\}\} \quad (7)$$

$$\text{令 } Q = \sum_{i=1}^N W_i \delta_i^2, \text{ 求解方程 } \frac{\partial Q}{\partial \gamma} = 0, \frac{\partial Q}{\partial \eta} = 0 \text{ 得到形状参}$$

数 γ, η 的值。其中 W_i 为权因子, 根据实际情况或经验选取。

4) 计算出贝塔分布的双侧 α 分位数 λ_1, λ_2 :

$$p\{\hat{X} < \lambda_1\} = F(\lambda_1) = 0.5\alpha \quad (8)$$

$$p\{\hat{X} > \lambda_2\} = 1 - F(\lambda_2) = 0.5\alpha \quad (9)$$

双侧 α 分位数 λ_1 为 $\hat{X}$ 的 0.5α 分位数, λ_2 为 $\hat{X}$ 的 $1 - 0.5\alpha$ 分位数; α 定义为在数据采集集中尖峰噪声所引起的误差。在采集过程中由外因所致的尖峰噪声误差一般取 $\alpha = 5\%$ ^[20]。在实际应用中应根据采集系统性能和传感器特性设置 α 值。本文取 $\alpha = 0.05$ 。

5) 根据如下公式计算得到监测振动数据的故障动态预警阈值区间 $[D_1, D_2]$:

$$D_1 = \lambda_1 \times [\max(x) - \min(x)] + \min(x) \quad (10)$$

$$D_2 = \lambda_2 \times [\max(x) - \min(x)] + \min(x) \quad (11)$$

2 故障信号降噪方法

运行中的滚动轴承往往充斥着大量背景噪声, 要实现滚动轴承较为准确的故障预警必须对采集到的原始振动信号进行滤波降噪。

2.1 滑动平均滤波

滑动平均滤波是一种应用于时域信号上的信号平滑方法, 它算法简洁, 实时性好, 平滑性高。滑动平均是将某一时刻的数据与周围时刻的数据做加权, 能够很好地处理好一段时间内数据的关系, 减少随机误差的影响, 而且可以根据前后数据的重要程度调整权值。该算法首先把 N 个采集数据看成一个队列, 且队列长度固定为 N , 每进行一次新的采样, 把新的采样结果放进队尾, 去掉原来队首的一个数据。然后将队列中的 N 个数据进行算术平均运算, 得到的结果即为滤波结果。根据其算法原理可知, 滑动滤波法利用滚动更新队列中的数据, 使其始终保持有 N 个采样值。

$$y(t_n) = \frac{1}{N} \sum_{i=n}^{n+N-1} w_i x(t_i) \quad (12)$$

式中: $x(t_i)$ 为第 i 个采样值; $y(t_n)$ 为由 N 个采样值得到的第 n 个测量值; N 为滑动滤波器窗口长度; w_i 为加权系数, 满足以下条件:

$$w_0 > w_1 > \dots > w_{N-1} > 0 \quad (13)$$

$$w_0 + w_1 + \dots + w_{N-1} = 1 \quad (14)$$

加权系数可以根据实际情况而定, 也可以通过调参方式得到最佳权值, 本文中某一时刻前后的值为平等关系, 所以设权值相等, 即对多个连续的参数进行加权平均运算。 N 是滑动平均算法中唯一需要设定的参数, 窗口的大小直接影响滤波精度, 在选取最优模型时可以给定一系列的备选窗口大小, 采用标准差和总和的比值这两个误差指标进行评价, 最后选出最合适的参数。

2.2 H-P 滤波

假设时间序列 $y_t = \{y_1, y_2, \dots, y_n\}$ 是由趋势成分 $x_t = \{x_1, x_2, \dots, x_n\}$ 和波动成分 $z_t = \{z_1, z_2, \dots, z_n\}$ 组成, 则时间序列:

$$y_t = x_t + z_t (t = 1, 2, 3, \dots, T) \quad (15)$$

式中: T 为样本容量。

H-P 滤波就是从 y_t 中将 x_t 和 z_t 分离出来, 使得式(16)估计值最小:

$$\min \left\{ \sum_{i=1}^T (y_i - x_i)^2 + \lambda \sum_{i=1}^T [(x_{i+1} - x_i) - (x_i - x_{i-1})]^2 \right\} \quad (16)$$

式中: $\lambda (\lambda \geq 0)$ 为控制趋势序列平滑程度的惩罚因子, 称为平滑参数; 波动序列的平方和表示为 $\sum_{i=1}^T (y_i - x_i)^2$,

$\sum_{i=1}^T [(x_{i+1} - x_i) - (x_i - x_{i-1})]^2$ 为趋势序列的二阶差分序列的平方和。

通过矩阵运算,最终可以得到的唯一解:

$$c_i = (I + \lambda A)^{-1} y_i \quad (17)$$

式中:

$A =$

$$\begin{bmatrix} 1 & -2 & 1 & 0 & 0 & \cdots & 0 & 0 & 0 & 0 & 0 \\ -2 & 5 & -4 & 1 & 0 & \cdots & 0 & 0 & 0 & 0 & 0 \\ 1 & -4 & 6 & -4 & 1 & \cdots & 0 & 0 & 0 & 0 & 0 \\ & & & & \vdots & & & & & & \\ 0 & 0 & 0 & 0 & 0 & \cdots & 1 & -4 & 6 & -4 & 1 \\ 0 & 0 & 0 & 0 & 0 & \cdots & 0 & 1 & -4 & 5 & -2 \\ 0 & 0 & 0 & 0 & 0 & \cdots & 0 & 0 & 1 & -2 & 1 \end{bmatrix}$$

2.3 形态滤波

形态滤波主要由形态变换运算和结构元素两部分组成。其中形态变换运算包括腐蚀、膨胀、开运算和闭运算;结构元素有直线形、三角形和半圆形等。

设 $f(n)$ 为一维离散信号,设置其定义域为 $F = (0, 1, \dots, N-1)$, $g(m)$ 为结构元素,定义域为 $G = (0, 1, \dots, M-1)$, 且 $N \geq M, m \in 0, 1, \dots, M-1$, 则 $f(n)$ 关于 $g(m)$ 的腐蚀和膨胀分别定义为:

$$(f \ominus g)(n) = \min[f(n+m) - g(m)] \quad (18)$$

$$(f \oplus g)(n) = \max[f(n-m) + g(m)] \quad (19)$$

根据膨胀和腐蚀运算先后顺序, $f(n)$ 关于 $g(m)$ 的开、闭算子可分别定义为:

$$(f \circ g)(n) = (f \ominus g \oplus g)(n) \quad (20)$$

$$(f \cdot g)(n) = (f \oplus g \ominus g)(n) \quad (21)$$

研究表明,结构元素的形状和幅值对滤波结果影响较小^[21],本文使用扁平型结构元素。上文分析的腐蚀、膨胀、开、闭算子单一使用时会一并滤除信号中的高频噪声和故障冲击信息,本文使用组合形态学算子平均帽变换算法定义如下:

$$AVGH(f(n)) = 2f(n) - [(f \circ g)(n) + (f \cdot g)(n)] \quad (22)$$

3 基于贝塔分布与滤波算法的轴承预警方法

滚动轴承在出现故障时,采集故障轴承的振动信号时往往伴随着各种各样的背景噪声,使用单一的信号处理方法很难提取有效的故障信息。因此,本文提出了将基于贝塔分布的阈值区间确定方法与趋势滤波相结合的故障诊断方法对非平稳、非线性的滚动轴承故障信号进行诊断。该预警方法流程如图 1 所示。首先,采用基于贝塔分布的阈值确定方法计算出机器平稳运行状态下所采集的滚动轴承的趋势数据的故障阈值区间;其次,使用

滤波技术对采集的滚动轴承监测趋势数据进行降噪处理;最后,将去噪处理后的滚动轴承监测趋势数据与采用基于贝塔分布阈值确定方法计算出的故障阈值区间进行比较,若趋势数据超出滚动轴承的故障阈值区间,则说明滚动轴承将要发生故障,进而实现预警。算法流程如图 1 所示。




图 1 基于贝塔分布与滤波降噪算法的轴承预警方法

Fig. 1 A fault warning method of rolling bearing based on beta distribution and filter algorithm

4 诊断实例

4.1 滚动轴承故障模拟实验

本文采用西安交通大学的滚动轴承加速寿命试验数据验证所提出方法的有效性^[22]。该实验台整体结构如图 2 所示。该平台由交流电动机、电动机转速控制器、转轴、支撑轴承、液压加载系统和测试轴承等组成。该系统可对轴承施加径向载荷。径向力由液压加载系统产生,作用于测试轴承的轴承座上,转速是由交流电机的转速控制器进行设置调节的。两个 PCB 352C33 单向加速度传感器分别通过磁座固定在测试轴承的水平和竖直方

向。试验轴承为 LDK UER204 滚动轴承,其相关参数如表 1 所示。本文选取 3 种故障类型的轴承进行算法验证,轴承加速寿命试验工况信息如表 2 所示。每种工况选取两个不同故障位置的轴承,轴承数据详细信息如表 3 所示。试验中的采样频率为 25.6 kHz,每次采样时长为 1.28 s。




图 2 轴承加速寿命试验台

Fig. 2 Bearing accelerated life test bench

表 1 LDK UER204 轴承参数
Table 1 LDK UER204 bearing parameters

参数名称	数值	参数名称	数值
内圈直径/mm	29.30	滚珠直径/mm	7.92
外圈直径/mm	39.80	滚珠个数	8
轴承节径/mm	34.55	接触角/(°)	0
额定动载荷/N	12 820	额定静载荷/kN	6.65

表 2 轴承加速寿命试验工况
Table 2 Bearing accelerated life test conditions

工况编号	1	2	3
转速/(r·min ⁻¹)	2 100	2 250	2 400
径向力/kN	12	11	10

表 3 XJTU-SY 轴承数据信息
Table 3 XJTU-SY bearing data information

工况	数据集	样本总数	L_{10}	实际寿命	失效位置
1	Bearing1-1	123	5.600 h~9.677 h	2 h 3 min	外圈
	Bearing1-5	52		52 min	内圈、外圈
2	Bearing2-1	491	6.786 h~11.726 h	8 h 11 min	内圈
	Bearing2-5	339		5 h 39 min	外圈
3	Bearing3-3	371	8.468 h~14.632 h	6 h 11 min	内圈
	Bearing3-5	114		1 h 54 min	外圈

4.2 阈值区间确定

以 XJTU-SY 轴承数据集 Bearing1-1 为例,对该轴承数据进行分析。由于 Bearing1-1 最终出现了外圈裂损,即载荷施加在水平方向,水平方向振动信号能包含更多故障信息,故选取水平振动信号进行分析。选取一段正常运行的监测数据,如图 3 所示。图 4(a)为趋势数据的概率密度分布。根据基于贝塔分布的动态阈值确定方法,用最小二乘法对选取轴承数据进行贝塔分布的拟合,拟合的贝塔分布概率密度曲线如图 4(b)所示。计算轴承 1-1 正常运行阶段的自学习智能阈值区间,取 $\alpha = 0.05$ 可得到拟合后的贝塔分布的两个形状参数分别是 $\gamma = 128.425\ 9, \eta = 106.918\ 8$, 趋势数据的阈值下限 $d1 = -4.104\ 1$, 阈值上限 $d2 = 4.185\ 3$, 自学习智能阈值区间 $[-4.104\ 1, 4.185\ 3]$ 。采用本文所提出的基于贝塔分布的智能阈值区间确定算法,对表 3 中各工况的阈值区间进行计算分析。各组轴承的贝塔分布形状参数与阈值区间如表 4 所示。




图 3 轴承 1-1 某段监测数据

Fig. 3 Monitoring data of a section of bearing 1-1

4.3 滤波算法分析

下面采用西安交通大学的滚动轴承加速寿命试验数据集集中的数据 Bearing 1-1 进行趋势滤波效果的对比。分别将数据用滑动平均滤波、H-P 滤波以及形态滤波进行信号的滤波处理,处理结果如图 5 所示,图 5(a)为




图 4 贝塔分布拟合效果

Fig. 4 The effect of beta distribution

表 4 XJTU-SY 轴承贝塔分布形状参数与阈值区间
Table 4 Beta distribution shape parameter and threshold interval of XJTU-SY bearing

轴承	γ	η	阈值区间
Bearing1-1	128.425 9	106.918 8	$[-4.104\ 1, 4.185\ 3]$
Bearing1-5	115.664 8	110.556 8	$[-5.448\ 9, 5.620\ 1]$
Bearing2-1	475.568 7	389.864 7	$[-1.720\ 9, 1.739\ 2]$
Bearing2-5	40.875 0	41.007 1	$[-7.988\ 8, 8.465\ 7]$
Bearing3-3	277.477 9	311.758 1	$[-2.392\ 3, 2.474\ 0]$
Bearing3-5	17.963 6	18.245 1	$[-8.329\ 0, 9.101\ 3]$

Bearing1-1 的原始振动信号,信号在 25.29×10^5 处产生了突变,即轴承开始发生故障。图 5(b)~(d) 分别为滑动平均滤波、H-P 滤波和形态滤波后的振动信号,其中的虚线为运用基于贝塔分布的阈值确定方法计算出的动态智能预警区间,若信号超出预警区间则发出预警。显然,由图 5(d) 可知,形态滤波无法较好地分离振动信号中的有效故障信息和振动噪声,滤波效果不尽人意。形态学滤波能够实现弱背景噪声干扰下的滚动轴承故障诊断,但无法有效提取强背景噪声下信号中的正负故障冲击特




图 5 轴承 1-1 滤波效果对比

Fig. 5 Comparison of filtering effect of bearing 1-1

征。相对于 H-P 滤波,滑动平均滤波对故障信号的保留更加完善,使用滑动平均滤波后的振动信号可以更准确地在轴承故障前进行预警。综上所述,本文选择滑动平均滤波与智能学习算法相结合实现滚动轴承的故障预警。

4.4 预警方法验证

首先,对 XJTU-SY 轴承数据集的工况 1 下两组轴承数据的振动信号进行分析。由于试验中载荷加载在水平方向,水平方向包含更多退化信息,故选取水平方向振动信号进行研究。由阈值确定方法计算出轴承 1-1 的自学习智能阈值区间,取 $\alpha = 0.05$ 可得 $\gamma = 128.425\ 9$ 、 $\eta = 106.918\ 8$,趋势数据的阈值下限 $d1 = -4.104\ 1$,阈值上限 $d2 = 4.185\ 3$,自学习智能阈值区间 $[-4.104\ 1, 4.185\ 3]$ 。轴承正常运行时的最大幅值为 A_h ,当幅值超过 $10 \times A_h$ 时认为轴承已经完全失效,同时停止实验。使用滑动平均滤波技术对趋势数据进行降噪处理,分析结果如图 6 所示,图 6(a) 为轴承 1-1 的原始振动信号,轴承 1-1 振动信号在 4×10^6 处完全失效。将滚动轴承 1-1 的实时滤波数据与计算出的智能阈值区间作对比,若数据超出智能阈值区间则说明滚动轴承已出现故障。信号在 2.529×10^6 处振动幅值大幅度增大,即轴承开始发生故障。图 6(c) 中滑动平均滤波后信号在 2.596×10^6 处超过计算出的智能阈值区间。将轴承信号大幅度增大到幅值超出预警阈值区间的这段时间定义为预警反应时间 t ,如式(23)所示。计算过程如式(24)所示,该方法的预警反应时间为 $122.68\ s$,即在轴承出现故障后的 $122.68\ s$ 做出了故障预警,该方法及时有效地对早期故障做出了预警。对于轴承 1-5,拟合后的贝塔分布两个形状参数分




图6 工况1轴承预警效果

Fig. 6 Bearing warning diagram for working condition 1

别是 $\gamma = 115.6648$ 、 $\eta = 110.5568$ ，自学习智能阈值区间 $[-5.4489, 5.6201]$ 。如图 6(b) 所示，轴承 1-5 振动信号在 17×10^5 处完全失效。信号在 12.8×10^5 处振动幅值大幅度增大，即轴承开始发生故障。图 6(d) 中滑动平均滤波后信号在 13.11×10^5 处超过计算出的智能阈值区间，即该方法在故障出现后的 56.76 s 做出了早期故障预警。

$$t = \frac{(x_D - x_{故障})}{F \cdot T} \quad (23)$$

式中： x_D 为幅值超过预警阈值区间对应的点数， $x_{故障}$ 为信号幅值大幅度增大对应的点数， F 为实验台采样频率， T 为采样时长。

$$t = \frac{(x_D - x_{故障})}{F \cdot T} = \frac{(2.596 - 2.529) \times 10^3}{25.6 \times 1.28} \times 60 \text{ s} = 122.68 \text{ s} \quad (24)$$

表 5 为轴承振动信号常见的时域参数。在相同工况下，内圈受损的轴承 2-1 的峰值因子、峭度因子以及脉冲因子等时域参数比外圈受损的轴承 2-5 高出多倍，即轴承 2-1 具有更为显著的冲击特性。同理选取水平振动信号进行分析。与工况 1 两组轴承处理步骤相同，取 $\alpha = 0.05$ 可得到拟合后的 $\gamma = 475.5687$ 、 $\eta = 389.8647$ ，趋势数据的阈值下限 $d1 = -1.7209$ ，阈值上限 $d2 = 1.7392$ ，自学习智能阈值区间 $[-1.7209, 1.7392]$ 。使用滑动平均滤波技术滤波后如图 7 所示，图 7(a) 为轴承 2-1 的原始振动信号，图 7(c) 为滤波后轴承 2-1 振动信号与自学习阈值区间。依据式 (23) 计算得预警反应时间为 128.17 s。对于轴承 2-5，其有效值约为轴承 2-1 的 4 倍，即其振动信号中包含有更多的能量。根据阈值确定方法计算滚动轴承正常运行阶段的自学习智能阈值区

间，可得到拟合后的贝塔分布的两个形状参数分别是 $\gamma = 40.8750$ 、 $\eta = 41.0071$ ，趋势数据的阈值下限 $d1 = -7.9888$ ，阈值上限 $d2 = 8.4657$ ，自学习智能阈值区间 $[-7.9888, 8.4657]$ 。使用滑动平均滤波技术对趋势数据进行滤波处理。如图 7 所示，图 7(d) 为轴承 2-5 的滤波后的信号，将滚动轴承 2-5 的实时滤波数据与计算出的智能阈值区间作对比判断滚动轴承是否出现故障。该方法在故障反应时间 695.80 s 后做出了早期故障预警。图 7 表明该预警方法既可以对具有较强冲击特性的内圈故障的轴承做出预警，也可以对大能量有表面裂纹的外圈故障轴承做出较为准确的预警。

表 5 XJTU-SY 轴承数据时域参数

Table 5 Time domain parameters of XJTU-SY bearing data

轴承	有效值	峰值因子	峭度因子	脉冲因子
B1-1	2.119 5	16.795 7	14.959 4	28.620 0
B1-5	2.829 8	15.367 0	15.663 4	26.517 9
B2-1	1.074 8	32.479 6	56.285 7	64.326 6
B2-5	4.221 3	9.147 7	8.090 6	14.702 1
B3-3	1.242 3	25.770 4	36.903 6	49.735 3
B3-5	4.503 0	6.191 5	3.597 7	8.081 3




图7 工况2轴承预警效果

Fig. 7 Bearing warning diagram for working condition 2

最后分析工况 3 下两组轴承水平方向趋势数据。如图 8 中(a)、(c)所示，振动幅值大幅增加后不久轴承失效，即轴承 3-3 为突然失效型轴承。轴承 3-3 原始振动信号约在 11.15×10^6 处幅值突变，将轴承 3-3 的原始振动信号使用滑动平均滤波进行降噪处理，降噪后信号在 11.24×10^6 处超出智能阈值区间，该方法在故障反应时

间 164.79 s 后做出了早期故障预警。对于轴承 3-5,如图 8 所示,轴承在寿命前期幅值就发生了大幅度变化,随后幅值缓慢增大直至失效,轴承 3-5 为缓慢退化型轴承。图 8(b)中原始振动信号约在 3.277×10^5 处大幅度增加,图 8(d)中实时滤波数据也于 7.527×10^5 处超出阈值区间,即该方法的故障反应时间为 778.20 s。综上所述,该基于贝塔分布与滑动平均滤波的预警方法可以准确地对突然失效型轴承和缓慢退化型轴承做出故障预警。




图 8 工况 3 轴承预警效果

Fig. 8 Bearing warning diagram for working condition 3

综合分析以上 6 组滚动轴承全寿命周期数据可得,基于贝塔分布的阈值确定与滑动平均滤波相结合的方法能够比较准确、全面地实现对不同损坏部位、不同失效类型的滚动轴承的故障预警。当使用滑动平均滤波后的振动趋势数据超出计算出的智能预警阈值区间时,意味着滚动轴承的故障损坏即将发生。

4.5 实际轴承寿命实验

本文采用实际轴承加速寿命试验数据进一步验证所提出方法的预警效果。该轴承全寿命实验台整体结构如图 9 所示。该实验台采用电机、动态扭矩传感器、滚动轴承寿命测试系统、液压加载装置作为实验负载形成完整的故障模拟系统,通过调节加载油站压力来改变实验负载大小。该系统可对轴承施加径向载荷。径向力由液压加载系统产生,作用于测试轴承的轴承座上,转速是由交流电机的转速控制器进行设置调节的。3 个 PCB 352C33 单向加速度传感器分别固定在测试轴承的水平、竖直和轴向方向上。试验轴承为 NSK 6007 滚动轴承。本文选取两组轴承实验数据进行算法验证,轴承加速寿命试验工况信息如表 6 所示,其中,两组轴承均发生外圈内侧点蚀以及存在外圈划痕,如图 10、11 所示。试验中的采样频率为 12.8 kHz。




图 9 轴承加速寿命试验台

Fig. 9 Bearing accelerated life test bench

表 6 轴承加速寿命试验工况

Table 6 Bearing accelerated life test conditions

工况编号	1	2
转速/($\text{r}\cdot\text{min}^{-1}$)	7 000	6 000
径向力/kN	10	11



图 10 轴承点蚀

Fig. 10 Bearing pitting




图 11 轴承外圈划痕

Fig. 11 Bearing outer ring scratch

由于试验中载荷加载在竖直方向,竖直方向包含更多退化信息,故选取竖直方向振动信号进行研究。由阈值确定方法计算出工况 1 下轴承 1 的自学习智能阈值区间,取 $\alpha = 0.05$ 可得 $\gamma = 77.472\ 6$ 、 $\eta = 161.289\ 5$,趋势数据的阈值下限 $d1 = -6.164\ 6$,阈值上限 $d2 = 6.665\ 0$,自

学习智能阈值区间 $[-6.164\ 6, 6.665\ 0]$ 。使用滑动平均滤波技术对趋势数据进行降噪处理,分析结果如图12所示,图12(a)为轴承1的原始振动信号,将滚动轴承1的实时滤波数据与计算出的智能阈值区间作对比,若数据超出智能阈值区间则说明滚动轴承已出现故障。如图12(a)所示,轴承1振动信号在 12×10^8 处完全失效。信号在 9.2×10^8 处振动幅值大幅度增大,即轴承开始发生故障。图12(c)中滑动平均滤波后信号在 10×10^8 处超过计算出的智能阈值区间,即该方法在轴承出现早期故障时准确地做出了故障预警。对于工况2的轴承2,拟合后的贝塔分布两个形状参数分别是 $\gamma = 111.677\ 4$ 、 $\eta = 107.904\ 3$,自学习智能阈值区间 $[-5.096\ 2, 5.080\ 2]$ 。由图12(d)可知,经过滑动平均滤波后的信号与基于贝塔分布的阈值确定方法计算出的阈值对比可以实现滚动轴承的故障预警。




图12 实际轴承寿命实验轴承预警效果

Fig. 12 Bearing warning diagram for bearing life test

5 结 论

针对现有算法难以实现机械系统中轴承故障的早期预警问题,本文提出了基于贝塔分布与滤波降噪算法的滚动轴承智能预警方法。并采用XJTU-SY轴承实验数据验证算法准确性。得到如下结论:

1) 本文提出的基于贝塔分布与滑动平均滤波技术的滚动轴承的智能预警方法预警效果良好,能简单高效的对滚动轴承故障进行预警。

2) 本文对比了滑动平均滤波、H-P滤波以及形态滤波等几种常见的滤波降噪方法对滚动轴承监测振动数据

的滤波效果,研究表明,相对于另外两种滤波方法,滑动平均滤波对滚动轴承振动数据的滤波效果更好,能够有效抑制噪声。

3) 采用贝塔分布拟合监测振动数据的概率密度分布,进而基于贝塔分布确定的阈值区间可以准确的预示轴承故障数据的突变。

参考文献

- [1] 鄢小安, 贾民平. 基于参数自适应特征模态分解的滚动轴承故障诊断方法[J]. 仪器仪表学报, 2022, 43(10): 252-259.
- YAN X AN, JIA M P. A rolling bearing fault diagnosis method based on parameter-adaptive feature mode decomposition [J]. Chinese Journal of Scientific Instrument, 2022, 43(10): 252-259.
- [2] 赵小强, 张青青. 改进 Alexnet 的滚动轴承变工况故障诊断方法[J]. 振动、测试与诊断, 2020, 40(3): 472-480.
- ZHAO X Q, ZHANG Q Q. Improved Alexnet based fault diagnosis method for rolling bearing under variable conditions [J]. Journal of Vibration, Measurement & Diagnosis, 2020, 40(3): 472-480.
- [3] QIN Y, MAO Y F, TANG B P, et al. M-band flexible wavelet transform and its application to the fault diagnosis of planetary gear transmission systems [J]. Mechanical Systems and Signal Processing, 2019, 134(C): 106298.
- [4] 崔玲丽, 王鑫, 王华庆, 等. 基于改进开关卡尔曼滤波的轴承故障特征提取方法[J]. 机械工程学报, 2019, 55(7): 44-51.
- CUI L L, WANG X, WANG Q H, et al. Feature extraction of bearing fault based on improved switching Kalman filter [J]. Journal of Mechanical Engineering, 2019, 55(7): 44-51.
- [5] 杜占涛, 纪爱敏, 陈曦晖, 等. 基于 ISVD 多级降噪和 SVM 的轴承故障诊断研究[J]. 机电工程, 2022, 39(5): 567-577.
- DU ZH T, JI AI M, CHEN X H, et al. Bearing fault diagnosis based on ISVD multistage noise reduction and SVM [J]. Journal of Mechanical & Electrical Engineering, 2022, 39(5): 567-577.
- [6] 张刚, 谭春林, 贺利芳. 二维非对称双稳随机共振系统及其在故障诊断中的应用[J]. 仪器仪表学报,

- 2021, 42(1): 228-236.
- ZHANG G, TAN CH L, HE L F. Two-dimensional asymmetric bi-stable stochastic resonance system and its application in fault diagnosis [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 228-236.
- [7] HODRICK J R, PRESCOTT C E, POSTWAR U S. Business cycles: An empirical investigation [J]. Journal of Money, Credit and Banking, 1997, 29(1): 1-29.
- [8] KIM S J, KOH K, BOYD S, et al. L1 trend filtering [J]. SIAM Review, 2009, 51(2): 339-360.
- [9] FATTAH S A, ZHU W P, AHMAD M O. Identification of autoregressive moving average systems based on noise compensation in the correlation domain [J]. IET Signal Processing, 2011, 5(3): 292-305.
- [10] JOSE A R, EDUARDO R, JUAN C E. Detrending fluctuation analysis based on moving average filtering [J]. Physica A: Statistical Mechanics and its Applications, 2005, 354: 199-219.
- [11] ZHANG W, LIU J Z, GAO M M, et al. A fault early warning method for auxiliary equipment based on multivariate state estimation technique and sliding window similarity [J]. Computers in Industry, 2019, 107: 67-80.
- [12] VAFAEI N, RIBEIRO R A, CAMARINHA M, et al. Fuzzy early warning systems for condition based maintenance [J]. Computers & Industrial Engineering, 2019, 128: 736-746.
- [13] 杨锡运, 邓子琦, 康宁. 融合集合经验模态分解与宽度学习的齿轮箱故障预警方法 [J]. 计算机集成制造系统, 2022, 28(6): 1835-1843.
- YANG X Y, DENG Z Q, KANG N. Gearbox fault warning method based on integrated empirical mode decomposition and width learning [J]. Computer Integrated Manufacturing Systems, 2022, 28(6): 1835-1843.
- [14] 杨婷婷, 高乾, 李浩千, 等. 基于卷积神经网络-长短期记忆神经网络的磨煤机故障预警 [J]. 热力发电, 2022, 51(10): 122-129.
- YANG T T, GAO Q, LI H Q, et al. Coal mill fault early warning technology based on CNN-LSTM net-work [J]. Thermal Power Generation, 2022, 51(10): 122-129.
- [15] 刘兴杰, 谢春雨. 基于贝塔分布的风电功率波动区间估计 [J]. 电力自动化设备, 2014, 34(12): 26-30, 5.
- LIU X J, XIE CH Y. Wind power fluctuation interval estimation based on beta distribution [J]. Electric Power Automation Equipment, 2014, 34(12): 26-30, 5.
- [16] 胡堂清, 张旭秀, 曹晓月. 一种动态调整惯性权重的混合粒子群算法 [J]. 电光与控制, 2020, 27(6): 16-21.
- HU T Q, ZHANG X X, CAO X Y. A hybrid particle swarm optimization with dynamic adjustment of inertial weight [J]. Electronics Optics & Control, 2020, 27(6): 16-21.
- [17] 侯代文, 殷福亮. 非线性系统中状态和参数联合估计的双重粒子滤波方法 [J]. 电子与信息学报, 2014, 33(24): 9-14.
- HOU D W, YIN F L. A dual particle filter for state and parameter estimation in nonlinear system [J]. Journal of Electronics & Information Technology, 2014, 33(24): 9-14.
- [18] 张明, 冯坤, 江志农. 基于动态自学习阈值和趋势滤波的机械故障智能预警方法 [J]. 振动与冲击, 2014, 33(24): 9-14.
- ZHANG M, FENG K, JIANG ZH N. A mechanical fault early warning methodology based on dynamic self-learning threshold and trend filtering techniques [J]. Journal of Vibration and Shock, 2014, 33(24): 9-14.
- [19] 曹天捷, 周则恭. 最小二乘法在估计概率分布参数中的应用 [J]. 机械强度, 1997, 19(4): 33-36.
- CAO T J, ZHOU Z G. Application of the least square method in the estimation of the parameters of the probability distribution [J]. Journal of Mechanical Strength, 1997, 19(4): 33-36.
- [20] CHEN Z, IVANOV P, HU K. Effect of nonstationarities on detrended fluctuation analysis [J]. Physical Review E, 2002, 65(4): 041107.
- [21] 王圣博, 陈丙炎, 程尧, 等. 基于尺度优化形态学滤波的滚动轴承故障诊断 [J]. 轴承, 2022, 513(8): 64-70, 78.
- WANG SH B, CHEN B Y, CHENG Y, et al. Fault

diagnosis for rolling bearings based on scale optimization morphological filtering [J]. Bearing, 2022, 513 (8): 64-70, 78.

[22] WANG B, LEI Y G, LI N P, et al. A hybrid prognostics approach for estimating remaining useful life of rolling element bearings[J]. IEEE Transactions on Reliability, 2018; 1-12.

作者简介



田晶,2012 年于沈阳航空航天大学获得硕士学位,2019 年于西北工业大学获得博士学位,现为沈阳航空航天大学教授,主要研究方向为航空发动机振动、强度及可靠性,航空发动机状态监测与故障诊断。

E-mail: tianjing@188.com

Tian Jing received his M.Sc. degree from Shenyang Aerospace University in 2012, and received his Ph. D. degree from Northwestern Polytechnical University in 2019. He is currently a professor at Shenyang Aerospace University. His main research interests include aeroengine vibration, strength and reliability, aeroengine condition monitoring and fault diagnosis.



高晓岚,2020 年在兰州理工大学获得学士学位。现为沈阳航空航天大学硕士研究生,主要研究方向为轴承故障预警、轴承寿命预测。

E-mail: 657750051@qq.com

Gao Xiaolan received her B.Sc. degree from Lanzhou University of Technology in 2020. She is currently a master student at Shenyang Aerospace University. Her main research interests are bearing fault warning and bearing life prediction.



张凤玲(通信作者),2000 年在天津大学获得学士学位,2020 年在北京航空航天大学获得博士学位。现为沈阳航空航天大学副教授,主要研究方向为航空发动机振动控制、高温动态应变计疲劳寿命研究、航空发动机故障诊断。

E-mail: fling707@163.com

Zhang Fengling (Corresponding author) received her B. Sc. degree from Tianjin University in 2000, and received her Ph. D. degree from Beihang University in 2020. Her main research interests include aeroengine vibration control, vibration fault diagnosis and aero-engine fault diagnosis.