

轴承振动信号 PF 分量的分数低阶特征提取^{*}

徐倩倩^{1,2}, 林茂海^{1,2}, 刘 凯³, 赵文全^{1,2}

(1. 齐鲁工业大学(山东省科学院)绿色印刷包装材料与技术重点实验室 济南, 250353)

(2. 齐鲁工业大学(山东省科学院)轻工科学与工程学院 济南, 250353)

(3. 西安理工大学机械与精密仪器工程学院 西安, 710048)

摘要 针对分数低阶 Alpha 稳定分布特性下轴承振动信号乘积函数(product functions, 简称 PF)的高阶统计特征提取性能退化问题,提出了轴承振动信号 PF 分量的分数低阶特征提取方法。通过信号平稳化 PF 分量的概率密度函数(probability density function,简称 PDF)曲线拖尾及特征指数 α 估计,验证轴承振动信号 PF 分量的分数低阶 Alpha 分布特性,并提出最优分数低阶统计量和共变低维流行映射矩构成轴承特征矩阵,以降低二阶及高阶统计量对信号分量特征描述误差,实现不同故障轴承特性的准确性表征。通过轴承特征散点图对比分析,结果表明,分数低阶次特征对轴承振动信号 PF 分量描述更为准确,不同状态轴承特征描述准确性和区分效果提升明显,具有一定的可行性及实际应用优势。

关键词 Alpha 稳定分布; 分数低阶次; 共变; 特征描述
中图分类号 TH17

引 言

设备关键零部件的准确性状态监测是实现设备智能诊断的关键因素。滚动轴承作为旋转机械中最常用也是最易损坏的支撑部件,是设备运行状态监测的主要对象。考虑到设备故障突发期间机械系统的驱动力、阻尼力及弹性力等动力学参数呈现非线性变化,导致其振动信号同时具有非高斯性及较强的非平稳特性,因此对设备轴承部件的实时状态特征提取,是目前实现其智能监测诊断的关键问题^[1-2]。自适应时频分解算法通过自适应的信号分解和降噪能力,兼顾了信号在时域和频域的局部化特征和全貌,有效实现振动信号的平稳化,是现有振动信号时频分析方法的研究热点^[3-5]。然而,当信号 PF 分量体现出一定分数低阶 Alpha 分布特性时,信号分量的方差发散,使得基于二阶、高阶统计的信号分量特征提取不够准确,导致常规算法下的状态描述性能显著退化,加大了机械设备智能监测难度^[6-7]。

近年来,Alpha 稳定分布及相应的基于分数低阶统计量的信号处理方法展现出比传统方法更为优

异的性能,在水声及雷达信号处理、语音信号处理、延时估计及生物医学等领域应用广泛^[8-11]。在针对轴承振动信号分布特征分析的研究中,Xiong 等^[12]通过信号 Alpha 分布参数与峭度值构造低速故障轴承的特征量,有效描述了不同载荷、不同故障尺寸下低速轴承状态。He 等^[13]基于轴承振动信号的 Levy 分布特征参数 α 和 β ,提出了新的分段非线性双稳态势函数,引起更为有效的随机共振现象。Li 等^[14]通过对称 Alpha 稳态分布描述信号固有模态分量,结合最小二乘支持向量机(support vector machine,简称 SVM)实现不同信号状态分类。申永军等^[15]将特征参数 α 和分散系数 γ 作为信号特征参数,验证了分数低阶 Alpha 分布更适宜描述轴承振动信号。

为兼顾轴承振动信号的非平稳特性和分数低阶 Alpha 分布特性,笔者提出基于分数低阶 Alpha 分布模型的信号 PF 分量特征提取改进算法,利用平稳化信号 PF 分量的最优分数低阶统计量和共变低维映射矩抑制 Alpha 稳态分布噪声干扰,实现故障轴承的状态特征有效描述,准确、直观地完成不同状态轴承分类识别,解决传统信号特征提取方法中方差假设不成立导致的设备状态描述不准确问题。

^{*} 国家自然科学基金资助项目(51275406);陕西省自然科学基金基础研究计划资助项目(2017JQ5012)
收稿日期:2018-12-10;修回日期:2019-07-13

1 分数低阶 Alpha 稳定分布

分数低阶 Alpha 稳定分布是一类非常重要的非高斯随机分布,其显著特征是远离均值或中值的样本数较多,从而造成其时间域波形上较多的尖峰脉冲,导致 PDF 曲线具有较厚的代数拖尾现象^[16]。若随机变量 X 存在特征参数 $0 < \alpha \leq 2$,分散系数 $\gamma \geq 0$,对称参数 β 和位置参数 a 使得其特征函数具有如下形式,则随机变量 X 服从稳定分布^[17]

$$\varphi(u) = \exp \{j a \mu - \gamma |u|^{\alpha} [1 + j \beta \operatorname{sgn}(u) \omega(u, \alpha)]\} \tag{1}$$

$$\begin{aligned} \text{其中: } \omega(u, \alpha) &= \begin{cases} \tan(\pi \alpha / 2) & (\alpha \neq 1) \\ (2 / \pi) \log |u| & (\alpha = 1) \end{cases}; \\ \operatorname{sgn}(u) &= \begin{cases} 1 & (u > 0) \\ 0 & (u = 0) \\ -1 & (u < 0) \end{cases} \end{aligned}$$

特征指数 α 决定了该分布脉冲特性的程度, α 值越小,脉冲特性越显著,概率密度函数 PDF 曲线拖尾越厚。不同 α 参数条件下 Alpha 分布如图 1 所示。当 $\alpha=2$ 时, $\varphi(u)=\exp \{j a \mu - \sigma^2 |u|^2\}$, 信号服从高斯分布;当 $0 < \alpha < 2$ 时为非高斯分布,定义为分数低阶 α 稳定分布,其中包含常见柯西分布 ($\alpha=1, \beta=0$)、皮尔森分布 ($\alpha=1 / 2, \beta=-1$)。




图 1 不同 α 参数下 Alpha 分布 PDF 曲线对比
Fig. 1 PDF curves comparison with different values of α

可见,分数低阶 Alpha 分布信号的概率密度函数 $f(x)$ 无法具有高斯分布 $f(x)$ 函数的收敛特性, $E|X|^2 = EX^2 = +\infty$, 导致信号方差 $\operatorname{Var}(X) = E(X^2) - (EX)^2$ 分散^[16-18]。对此,邱天爽等^[19]提出了 α 分布性质定理:任意服从 α 稳定分布的随机变量 $X, 0 < \alpha < 2$, 满足

$$\begin{cases} E[|X|^p] = +\infty & (p \geq \alpha) \\ E[|X|^p] < +\infty & (0 \leq p < \alpha) \end{cases} \tag{2}$$

当 $\alpha=2$ 时, $E[|X|^p] < +\infty \quad (p \geq 0)$ 。这就使得常规的基于二阶及高阶统计量的信号表征算法性能退化,降低设备状态描述准确性,加大了机械设备智能监测难度。

2 PF 分量时域分布特性分析

针对旋转机械振动信号噪声特性, Yu 等^[18]通过对比不同故障程度下的不同类型故障轴承信号分布假设,验证了轴承信号 Alpha 分布假设的正确性,明确 Alpha 分布干扰噪声的存在。笔者通过概率密度函数拖尾厚度和特征指数 α 值对比,进一步分析信号 PF 分量的时域分布特性,研究自适应局部均值分解算法 (local mean decomposition, 简称 LMD) 对分数低阶 Alpha 噪声抑制情况。

2.1 仿真振动信号

建立轴承(外圈固定)振动信号模型^[20]

$$S = \sin(2\pi f_b t) [1 + \chi \sin(2\pi f_r t)] + v_a \tag{3}$$

其中: f_b 为滚动体通过内圈的特征频率; f_r 为轴承旋转频率; χ 为调制比; v_a 为添加噪声,当特征指数 $\alpha=2$ 时 v_a 为高斯噪声。

取 $f_b=100 \text{ Hz}, f_r=25 \text{ Hz}, \chi=1$, 分别取 $\alpha_1=1.5, \alpha_2=2$, 构建 Alpha 分布、高斯噪声下轴承振动信号 S_1 和 S_2 。

由 LMD 对振动信号 S_1 和 S_2 进行自适应分解,获得信号 $PF_1(t)$ 分量及其概率密度函数 PDF 拖尾厚度对比如图 2 所示。由图 2 发现, S_1 信号 $PF_1(t)$ 分量较 S_2 信号分量具有非常显著的脉冲特性,且其概率密度曲线具有更厚的拖尾现象,证明在 Alpha 分布噪声干扰下, LMD 方法无法有效处理 Alpha 分布噪声,信号 $PF_1(t)$ 分量仍然表现出一定的 Alpha 分布特性。

2.2 轴承实验台

以西储大学 SKF6205-2RS 型轴承故障数据库为例,研究实际轴承信号 $PF_1(t)$ 的分量分布特性^[21]。其中,加速度传感器安装于驱动端电机外壳,电机载荷为 1.5kW。SKF6205-2RS 型轴承数据包括 4 类: A 为正常状态; B 为滚动体故障(3 种故障尺寸分别为 0.178, 0.356 及 0.533mm); C 为内圈故障; D 为外圈故障。建立轴承数据库 $X = \{A, M(n)\}$, $M(n)$ 表示 n 损伤程度下的 M 类故障数据, $M \in \{B, C, D\}, n \in \{a, b, c\}$ 。数据测试条件为:转




图 2 模拟信号分量与 PDF 曲线拖尾对比

Fig. 2 Product functions and PDF curves comparison of analog signals with the same parameters except α




图 3 轴承 PF 分量与同参数高斯分布 PDF 曲线拖尾厚度对比

Fig. 3 PDF curves comparison of faulty bearings and Gaussian signals with the same parameters except α

频 $f_r=29.167\text{ Hz}$; 采样频率 $f_s=12\text{ kHz}$; 样本长度 $N=1\,024$; 样本数 $G=117$ 。

考察轴承信号 $\text{PF}_1(t)$ 分量的概率密度函数 PDF 曲线,并绘制其与同参数、不同特征指数 α 的高斯分布 PDF 曲线拖尾厚度对比图,如图 3 所示。分析图 3 可知:①正常轴承 PDF 曲线拖尾均略高于同参数高斯分布,表示设备运行振动混合信号符合 Alpha 稳定分布,在此基础上的轴承滚动体和内、外圈故障信号均体现了其 Alpha 分布特性;②滚动体故障轴承样本 $B(a)$ 、外圈故障样本 $D(b)$ 与同参数高斯分布 PDF 曲线趋势相似度较高,其他故障样本 PF 分量的 Alpha 稳态分布特征则较为明显。

进一步以 Koutrouvelis 回归法^[22] 估计故障信号 PF 分量特征指数 α 均值,见表 1。由表可见:故障轴承对应特征指数区分较为明显,滚动体故障 α 处于 1.61~1.99 范围,内圈故障处于 1.43~1.53 范围,外圈故障除 $D(b)$ 轴承出现突变,其余尺寸故

障处于 1.01~1.2 范围,基本符合故障轴承样本分量 PDF 曲线拖尾厚度变化规律。

表 1 SKF6205-2RS 轴承样本 $\text{PF}_1(t)$ 分量 α 均值
Tab. 1 Mean values of bearing samples (SKF6205-2RS)

样本	均值	样本	均值
A	1.897 1	C(b)	1.536 3
B(a)	1.997 0	C(c)	1.433 3
B(b)	1.618 7	D(a)	1.170 3
B(c)	1.967 9	D(b)	1.989 9
C(a)	1.522 1	D(c)	1.008 1

2.3 胶印机墨辊轴承

在胶印机 PZ650 的工作过程中,油墨经由传墨系统-印版滚筒-橡皮滚筒到达印刷纸张,完成高精度油墨转移。其中,着墨辊是油墨从墨路系统到达三大滚筒的关键部分,若着墨辊的支撑轴承出现故障,易导致油墨网点过大,出现糊版现象,直接影响

印品的印刷质量。针对着墨辊的支撑轴承振动状态进行监测,图 4 所示为不同状态下的 6001 型故障轴承。利用线切割加工轴承内圈、外圈故障,故障宽度分别为 0.1 和 0.3 mm。




图 4 内、外圈故障轴承实例

Fig. 4 Real bearings with inner race faulty and outer race fault

应用西门子 LMS Test Lab 振动测试分析系统分别检测不同状态轴承的振动信号。实验采用的加速度传感器型号为 PCB 333B30,灵敏度为 99.3mV/g,量程为±50g(峰值),传感器安装于固定轴承外圈。设定测试条件如下:着墨辊转频 $f_r=4\text{ Hz}$,采样频率 $f_s=6.4\text{ kHz}$,样本长度 $N=2\ 048$,样本数 $G=190$ 。

绘制 5 种测试样本的 PF 分量与同参数高斯分布 PDF 曲线拖尾厚度对比如图 5 所示,表 2 为估计样本特征指数 α 均值。图 5 与表 2 充分证明了墨辊轴承振动信号包含分数低阶 Alpha 分布噪声,其信号分量 $PF_1(t)$ 具有明显的 Alpha 分布特性。

表 2 着墨辊轴承样本 $PF_1(t)$ 分量 α 均值

Tab. 2 Mean values of α from form roller bearings $PF_1(t)$					
样本	正常	内圈故障宽度/mm		外圈故障宽度/mm	
		0.1	0.3	0.1	0.3
均值	1.819 2	1.755 5	1.730 7	1.797 0	1.796 0

由此,笔者研究分析了模拟轴承振动信号、轴承实验台振动信号及胶印机墨辊轴承振动信号的平稳化 PF 分量的分布特性,由上述信号 $PF_1(t)$ 分量




图 5 测试样本 PF 分量与同参数高斯分布 PDF 曲线拖尾厚度对比

Fig. 5 PDF curves comparison of real faulty bearings and Gaussian signals with the same parameters

PDF 曲线与同参数高斯分布对比及特征指数 α 估计,充分验证了 LMD 方法对信号的冲击成分处理效果并不理想,信号 $PF_1(t)$ 分量仍然表现出明显的多冲击频谱特性,此时分数低阶 Alpha 分布模型更适合描述振动信号。因此,采用分数低阶特征描述信号 PF 分量比常规的二阶及高阶统计矩具有更好的适应性,避免常规假设误差。

3 轴承振动信号分数低阶特征描述

分数低阶 Alpha 稳定分布噪声干扰下,结合轴承振动信号的非平稳性,提出基于 Alpha 稳定分布的振动信号分数低阶特征提取方法。采用振动信号的局部均值分解实现振动信号的平稳化,获得具有分数低阶 Alpha 分布特性的时域信号 PF 分量,通过样本类间矩/类内矩比值寻找最优分数低阶阶次 p ,结合流行拉普拉斯特征映射算法 (Laplacian eigenmaps,简称 LE)实现高维共变矩的低维流行映射,最终由最优分数低阶统计和共变低维映射矩构建特征矩阵,实现信号分量状态的准确描述,达到多类别状态轴承的分类识别。算法流程如图 6 所示。

3.1 信号自适应分解

LMD 是一种自适应时频分析方法,可解决固定类型基函数可能会产生虚假的时频信息、多参数优化导致计算量大以及 Heisenberg 原理在时频域的限制性等问题,避免常用经验模式分解 (empirical mode decomposition,EMD)存在的过包络、欠包络缺陷等,在轴承故障信号处理中应用广泛^[23-27]。

对于任意检测信号 $x(t)$,LMD 最终通过三重




图 6 振动信号分数低阶特征描述

Fig. 6 The fractional lower order features extraction method

循环将 $x(t)$ 分解为一系列 $PF_i(t)$ 分量与余项 $u_i(t)$ 的和

$$x(t) = \sum PF_i(t) + u_i(t)$$

(4)

式(4)中, $PF_i(t)$ 分量为带噪信号 $x(t)$ 主要频率成分的时域表示,依据峭度最大原则常以最高频率分量 $PF_1(t)$ 作为故障轴承的主要特征体现^[28]。由此,LMD 算法将非平稳信号的特征提取问题转换为平稳分量的特征提取问题,实现了非平稳轴承振动信号的平稳化处理。

3.2 最优分数低阶统计

除了高斯分布、柯西分布和皮尔森以外, α 稳定分布无法获得概率密度函数解析式,此时统计矩是描述随机过程统计特性的重要手段。

根据 Alpha 稳定分布理论,当随机信号的特征指数为 α 时,只有阶数小于 α 阶的统计量是有界的,定义为分数低阶统计量(fractional lower order statistics,简称 FLOS),如式(5)所示

$$E[|X|^p] = \begin{cases} C(p, \alpha) \gamma^{p/\alpha} & (0 < p < \alpha) \\ \infty & (p \geq \alpha) \end{cases}$$

(5)

其中: $C(p, \alpha) = \frac{2^{p+1} \Gamma(\frac{p+1}{2}) \Gamma(-p/\alpha)}{\alpha \sqrt{\pi} \Gamma(-p/2)}$, $\Gamma(\cdot)$ 为伽

玛函数。

p 值的选取直接影响 FLOS 的估计,对于轴承状态监测至关重要,故提出基于“最大类间距、最小类内距”的最优 p 值选取方法:首先,通过式(5)得到不同 p 值下每个样本的 FLOS 作为样本点特征值,记为 $E_p^{i,j}$,其中 $i \in \{1, 2, \dots, G\}$, $j \in \{1, 2, \dots, J\}$, G 为每种样本测试组数, J 为状态样本种类数;其次,以 K -means 聚类思想获得 J 种状态样本的最佳聚类中心点 $(x^1, x^2, \dots, x^J)$;最后,计算此时样本点特征 $E_p^{i,j}$ 与相应聚类中心 x^j 的距离,得到 J 类状态样本的类内矩和类间距,并由类间/类内比值得到 FLOS 最优阶次 p 值。

3.3 共变低维流行映射

由于 Alpha 分布信号没有有限的方差, Miller 提出了共变概念。对于联合对称稳态 α 分布(即 $S\alpha S$ 分布)的随机变量 X 和 Y ,满足 $1 < \alpha \leq 2$,设 Y 的分散系数为 γ_y ,则 X 和 Y 的共变为

$$[X, Y]_\alpha = \frac{E(XY^{<p-1>})}{E(|Y|^p)} \gamma_y \quad (1 \leq p < \alpha)$$

(6)

在一定的条件下其作用类似于高斯分布随机变量的协方差,可一定程度上强化信号的共性成分。针对高维共变矩阵,采用 LE 算法对其进行低维流行映射。LE 算法适用于设备工况特征的高维数据的非线性特征挖掘和降维,通过“子图间连接边的权值尽可能低、子图内连接边的权值尽可能高”的原则,结合图谱理论最终实现高维流形的最优嵌入。

若第 i 个节点 x_i 和第 j 个节点 x_j 之间有边连接,由热核法确定边的权值为

$$W_{ij} = \exp(-\|x_i - x_j\|^2 / \sigma^2)$$

(7)

构建拉普拉斯特征矩阵 $L = D - W$,假设构建的近对邻图是连通的,那么寻找低维嵌入的问题就归结为对广义特征向量问题的求解

$$Ly = \lambda Dy$$

(8)

其中: D 为对角权值矩阵;元素 $D_{ij} = \sum_j W_{ij}$ 。

L 经过特征分解后得到的最小 $d + 1$ 个特征值所对应的的特征向量 $p_1, p_2, \dots, p_{d+1}$ 即构成低维嵌入坐标 $T = [p_1, p_2, \dots, p_{d+1}]^T$,其中维数的优化目标数由故障类型数确定^[29-30]。

4 信号 PF 分量特征提取准确性对比

4.1 实验台轴承特征对比

以西储大学 SKF6205-2RS 型轴承故障数据,对比分析常规状态、时频多维特征与本研究所提出的分数低阶特征对不同故障尺寸下不同类型故障轴承的状态特征描述效果,故障样本分组见表 3。

表 3 故障轴承数据分组

Tab. 3 Grouped faulty samples

编号	故障分组	故障组描述
1	$X = \{M(n) M = B, C, D; n = a\}$	a 损伤尺度下 3 类故障
2	$X = \{M(n) M = B, C, D; n = b\}$	b 损伤尺度下 3 类故障
3	$X = \{M(n) M = B, C, D; n = c\}$	c 损伤尺度下 3 类故障
4	$X = \{M(n) M = B; n = a, b, c\}$	不同损伤尺度滚动体故障
5	$X = \{M(n) M = C; n = a, b, c\}$	不同损伤尺度内圈故障
6	$X = \{M(n) M = D; n = a, b, c\}$	不同损伤尺度外圈故障

根据多样本分量最小 α 值 $\min\alpha=0.876$ 确定 p 取值范围,取步进 $h=0.01$,计算不同 p 值下多组样本类内矩、类间距,如图 7(a)所示。当 $0.7 < p < \min\alpha$ 时,比值曲线整体呈上升趋势。进一步局部细化 p 值,步长 $h=0.001$,绘制类距比值曲线如图 7(b)所示,确定 FLOS 最佳阶次 $p=0.872$,此时类距比值最大。

针对每个故障轴承数据集的 G 组样本,根据式(6)分别计算 $PF_1(t)$ 分量的共变矩阵,获得高维共变矩 $\mathbf{C}_{G\times G}$,并作为 LE 算法的输入,构建拉普拉斯特征矩阵,对高维共变矩进行低维流形映射,实现每一类样本中故障成分强化。设低维映射空间维数为故障集样本种类数减去 1,获得每类样本的低维映射矩 $\mathbf{C}'_{G\times 2}$ 。

由 $\mathbf{C}_{G\times 2}$ 与最优分数低阶统计 E_p 构成轴承样本三维特征矩 $\mathbf{CE}_{G\times 3}$,以 $\mathbf{CE}_{G\times 3}$ 三维特征为坐标,绘制其样本三维分布散点图,并与文献[27]中样本分量 23 维特征经过 LE 映射所得三维散点图对比分析,如图 8 所示。可见,针对多状态故障轴承,常规算法下的时频域多维特征提取在每个故障集中都存在不同程度的样本点重合,而本研究方法在所提取特征量个数远小于对比文献前提下有:①基于本方法的故障集 2 的三维空间散点较为混乱,可视化效果较差,但从其单一变量对比图 9 可见,3 种样本区分较好;②轴承故障集 1,3~6 的聚类边界更为明确,减少了各个故障集的空间重合样本点,基本实现了 3 类






图 7 类间/类内比值随 p 值变化曲线
Fig. 7 The variation curve between distance ratio and p values

样本的完全分离。这证明笔者提出的分数低阶特征提取对不同状态轴承振动特性描述更为准确,可在一定程度上提高轴承状态识别的准确性。



(a) 基于常规二阶及高阶统计量的轴承故障样本散点图
(a) 3D scattered plots of fault bearings based on conventional second or higher order statistics



(b) 基于分数低阶统计量的轴承故障样本散点图

(b) 3D scattered plots of fault bearings based on fractional lower order statistics

图 8 故障轴承特征三维散点图对比

Fig. 8 3D scattered plots comparisons




图 9 故障集 2 的最优 FLOS 对比曲线


Fig. 9 The variation curve of fault set 2

4.2 墨辊轴承特征对比

对胶印机的 5 种着墨辊轴承测试样本进行分


组,见表 4。由图 6、式(4)~式(8)计算信号分量最优分数低阶统计与共变流行映射,构成着墨辊轴承信号分数低阶特征矩阵。其中,最小 α 值 $\min \alpha = 1.454$,最优 FLOS 值对应最佳阶次 $p = 1.453$ 。对比分析了故障集的特征矩阵三维散点图,如图 10 所示。

可见,在实际的工程应用设备中,复杂设备运行环境干扰使得传统基于二阶、高阶统计量的状态特征提取方法效果退化更为明显,基本无法区分不同状态墨辊轴承,而笔者提出的分数低阶特征统计算法则可一定程度上抑制信号冲击成分对状态描述准确性的干扰,较好地实现不同状态墨辊轴承的振动特性描述。



(a) 基于常规二阶及高阶统计量的轴承故障样本散点图

(a) 3D scattered plots of fault bearings based on conventional second or higher order statistics



(b) 基于分数低阶统计量的轴承故障样本散点图
(b) 3D scattered plots of fault bearings based on fractional lower order statistics

图 10 着墨辊轴承故障集散点图

Fig. 10 3D scattered plots comparisons of inking roller bearings

表 4 6001 轴承测试样本分组
Tab. 4 Grouped faulty samples (6001)

编号	故障分组描述
1	正常状态、0.1 及 0.3 mm 尺寸下内圈故障
2	正常状态、0.1 及 0.3 mm 尺寸下外圈故障
3	正常状态、0.1 mm 尺寸下内圈、外圈故障
4	正常状态、0.3 mm 尺寸下内圈、外圈故障

5 结 论

1) 传统的自适应时频分析方法所得信号 PF 分量仍然表现出较强的脉冲特性,而最优分数低阶统计量 FLOS 能够描述信号的分数阶次统计特征,共变映射矩则可在分数阶次上更加有效地强化信号共性成分,故将二者作为轴承振动信号状态描述统计量是可行的。

2) 实际工程应用中,基于分数低阶次的信号特征统计量可避免方差有限假设所造成的误差,不同状态轴承特征的描述性能及区分提升尤其明显。

3) 笔者提出的方法可有效提取多种机械故障特征,提高设备状态监测准确性,具有较好的实际应用优势,为实现设备整机智能诊断提供理论依据。

参 考 文 献

[1] 唐友福,刘树林,刘颖慧,等. 基于非线性复杂测度的往复压缩机故障诊断[J]. 机械工程学报, 2012, 48(3): 102-107.
TANG Youfu, LIU Shulin, LIU Yinghui, et al. Fault diagnosis based on nonlinear complexity measure for reciprocating compressor [J]. Journal of Mechanical Engineering, 2012, 48(3):102-107. (in Chinese)

[2] 雷亚国,贾峰,孔德同,等. 大数据下机械智能故障诊断的机遇与挑战[J]. 机械工程学报, 2018, 54(5): 94-104.
LEI Yaguo, JIA Feng, KONG Detong, et al. Opportunities and challenges of machinery intelligent fault diagnosis in big data era [J]. Journal of Mechanical Engineering, 2018, 54(5):94-104. (in Chinese)

[3] HUANG N E, SHEN Z, LONG S R, et al. The empirical mode decomposition and the Hilbert spectrum for nonlinear and non-stationary time series analysis [J]. Proceedings Mathematical Physical & Engineering Sciences, 1998, 454(1971):903-995.

[4] ZHANG X G, SONG Z Y, LI D D, et al. Fault diagnosis for reducer via improved LMD and SVM-RFE-MRMR[J]. Shock and Vibration, 2018,2018:1-13.

[5] LÜ Y, ZHANG H Z, YI C C. Trivariate empirical mode decomposition via convex optimization for rolling bearing condition identification [J]. Sensors, 2018, 18(7):2325.

[6] SHAO M, NIKIAS C L. Signal-processing with fractional lower order moments - stable processes and their applications [J]. Proceedings of the IEEE, 1993, 81(7):986-1010.

[7] CHAN R Q, WANG J, LIN R Q, et al. Spectrum sensing based on nonparametric autocorrelation in wireless communication systems under alpha stable noise[J]. Mobile Information Systems, 2016,2016:1-6.

[8] 查代奉,高玉宝,熊美英,等. 非高斯噪声下基于 MD 准则与 Givens 旋转的 EP 信号提取方法[J]. 生物医学工程学杂志, 2010, 27(3): 495-499.
ZHA Daifeng, GAO Yubao, XIONG Meiyong, et al. Estimation of evoked potentials based on MD criterion and Givens matrix in non-Gaussian noise environments [J]. Journal of Biomedical Engineering, 2010, 27(3): 495-499. (in Chinese)

[9] 胡学龙,王志坚. 基于分数低阶矩的图像阈值检测和颗粒度分析算法[J]. 中国图象图形学报, 2008, 13(10): 1821-1824.
HU Xuelong, WANG Zhijian. Image threshold detection and granularity analysis algorithm based on FLOM [J]. Journal of Image and Graphics, 2008, 13(10):1821-1824. (in Chinese)

[10] 郑作虎,王首勇. 复杂海杂波背景下分数低阶匹配滤波检测方法[J]. 电子学报, 2016, 44(2): 319-326.
ZHENG Zuohu, WANG Shouyong. Radar target detection method of fractional lower order matched filter

- in complex sea clutter background [J]. *Acta Electronica Sinica*, 2016, 44(2):319-326. (in Chinese)
- [11] 李丽,邱天爽,贺明妍. 基于分数低阶类相关熵的双基地 MIMO 雷达目标参数联合估计新算法[J]. *通信学报*, 2016, 37(12):42-49.
LI Li, QIU Tianshuang, HE Mingyan. Novel method based on fractional lower-order correntropy-analogous statistics for parameter jointly estimation in bistatic MIMO radar [J]. *Journal on Communications*, 2016, 37(12):42-49. (in Chinese)
- [12] XIONG Q, Xu Y H, PENG Y Q, et al. Low-speed rolling bearing fault diagnosis based on EMD denoising and parameter estimate with alpha stable distribution [J]. *Journal of Mechanical Science and Technology*, 2017, 31(4): 1587-1601.
- [13] HE L F, ZHOU X C, ZHANG T Q. Stochastic resonance characteristic analysis of new potential function under levy noise and bearing fault detection[J]. *Chinese Journal of Physics*, 2018, 56(2): 538-560.
- [14] LI Y J, ZHANG W H, XIONG Q, et al. A novel fault diagnosis model for bearing of railway vehicles using vibration signals based on symmetric alpha-stable distribution feature extraction[J]. *Shock and Vibration*, 2016, 2016:1-13.
- [15] 申永军,段春宇,王杜娟,等. 基于 α 稳定分布和支持向量机的轴承模式分类[J]. *振动、测试与诊断*, 2015, 35(6):1068-1074.
SHEN Yongjun, DUAN Chunyu, WANG Dujuan, et al. Pattern classification for rolling bearing based on α -stable distribution and support vector machine [J]. *Journal of Vibration, Measurement & Diagnosis*, 2015, 35(6):1068-1074. (in Chinese)
- [16] NOLAN J P. Stable distributions: models for heavy-tailed data[EB/OL]. [2018-03-01]. Progress Chapter Online at Academic2. american. edu/~jpnolan.
- [17] MA X Y, NIKIAS C L. Joint estimation of time delay and frequency delay in impulsive noise using fractional lower order statistics[J]. *IEEE Transactions Signal Process*, 1996, 44(11):2669-2687.
- [18] YU G, LI C N, ZHANG J F, et al. A new statistical modeling and detection method for rolling element bearing faults based on alpha-stable distribution[J]. *Mechanical Systems and Signal Processing*, 2013, 41(1/2): 155-175.
- [19] 邱天爽,郭莹. 信号处理与数据分析[M]. 北京:清华大学出版社, 2015:372.
- [20] 李志农,吕亚平,韩捷. 基于时频分析的机械设备非平稳信号盲分离[J]. *机械强度*, 2008, 30(3):354-358.
LI ZhiNong, LÜ Yaping, HAN Jie. Bland separation of non-stationary signals in the mechanical equipment based on time-frequency analysis[J]. *Journal of Mechanical Strength*, 2008, 30(3):354-358. (in Chinese)
- [21] The Case Western Reserve University Bearing Data Center. [2018-05-11]. <http://csegroups.case.edu/Bearingdatacenter/pages/welcome-case-western-reserve-university-bearing-data-center-website>.
- [22] KOUTROVELIS I A. Regression type estimation of the parameters of stable laws [J]. *Journal of the Acoustical Society of America*, 1980, 75(4):918-928.
- [23] XIANG L, YAN X A. A self-adaptive time-frequency analysis method based on local mean decomposition and its application in defect diagnosis[J]. *Journal of Vibration and Control*, 2016, 22(4):1049-1061.
- [24] YANG Y, CHENG J S, ZHENG K. An ensemble local means decomposition method and its application to local rub-impact fault diagnosis of the rotor systems [J]. *Measurement*, 2012, 45(3):561-570.
- [25] 黄传金,孟雅俊,雷文平,等. 复局部均值分解全矢包络技术及其在转子故障特征提取中的应用[J]. *机械工程学报*, 2016, 52(7):69-78.
HUANG Chuanjin, MENG Yajun, LEI Wenping, et al. Full vector envelope technique based on complex local mean decomposition and its application in fault feature extraction for rotor system[J]. *Journal of Mechanical Engineering*, 2016, 52(7): 69-78. (in Chinese)
- [26] WANG J G, LI J, WAN X D. Fault feature extraction method of rolling bearings based on singular value decomposition and local mean decomposition [J]. *Journal of Mechanical Engineering*, 2015, 51(3):104-110.
- [27] 徐倩倩,刘凯,侯和平,等. 基于局部均值分解与拉普拉斯特征映射的滚动轴承故障诊断方法[J]. *中国机械工程*, 2016, 27(22):3075-3081.
XU Qianqian, LIU Kai, HOU Heping, et al. Diagnosis method of fault bearings based on LMD and LE [J]. *China Mechanical Engineering*, 2016, 27(22): 3075-3081. (in Chinese)
- [28] 李宏坤,赵长生,周帅,等. 基于小波包-坐标变换的滚动轴承故障特征增强方法[J]. *机械工程学报*, 2011, 47(19):74-80.
LI Hongkun, ZHAO Changsheng, ZHOU Shuai, et al. Fault feature enhancement method for rolling bearing based on wavelet packet-coordinate transformation [J]. *Journal of Mechanical Engineering*, 2011, 47(19):74-80. (in Chinese)
- [29] HE Q B. Vibration signal classification by wavelet packet energy flow manifold learning [J]. *Journal of Sound and Vibration*, 2013, 332(7):1881-1894.
- [30] HE Q B. Time-frequency manifold for nonlinear feature extraction in machinery fault diagnosis[J]. *Mechanical Systems and Signal Processing*, 2013, 35(1/2):200-218.



第一作者简介:徐倩倩,女,1989年2月生,博士生、讲师。主要研究方向为印刷包装设备状态监测与诊断、振动信号处理以及3D打印材料。曾发表《基于局部均值分解与拉普拉斯特征映射的滚动轴承故障诊断方法》(《中国机械工程》2016年第27卷第22期)等论文。
E-mail:18700197780@163.com

