无监督学习驱动的高端轴承故障智能诊断算法

陈彬强¹, 曾念寅^{1*}, 曹新城¹, 周生喜², 贺王鹏³, 田赛¹

1. 厦门大学航空航天学院, 厦门 361005;

2. 西北工业大学航空学院, 西安 710072;

3. 西安电子科技大学空间科学与技术学院, 西安 710071

* E-mail: zny@xmu.edu.cn

收稿日期: 2021-07-16; 接受日期: 2021-10-08; 网络版发表日期: 2021-11-18

国家自然科学基金(批准号: 62073271)、中央高校基本科研业务费项目(编号: 20720190009)、福建省科技计划对外合作项目(编号: 2019I0003)、中国工程院-英国皇家工程院中英校企项目(编号: UK-CIAPP-276)、国家重点研发计划项目(编号: 2020YFB1713500)和中国航空发动机集团2019年度产学研合作项目(编号: HFZL2019CXY02)资助

摘要 谱峭度是用于滚动轴承故障诊断的有效方法, 然而它对工程中常见的偶发性冲击特征具有高度的敏感性, 常导致特征提取结果失效. 为解决该问题, 针对多重偶发性冲击(sporadic impulses, SIs)干扰下的时间序列峭度计算提出了一种基于无监督学习的智能评估方法. 首先, 根据偶发性冲击在时域上能量高度集中的特性, 在时域将原始信号样本等间隔地划分为数据片段. 其次, 将各数据片段映射到统计参数特征空间(statistical parameter feature space, SPFS). 再次, 提出了迭代二均值聚类算法, 实现了聚类中心自定位及类簇数自适应整定, 利用含SIs片段与正常片段在SPFS显著的统计特性差异, 逐次识别并清除受SIs干扰的片段. 最后对未受SIs干扰的正常片段进行峭度信息融合, 得到智能峭度估计. 结合该智能峭度估计方法与多尺度分解方法提出了高端轴承故障诊断的新方法. 通过仿真算例及轴承故障诊断实际案例验证了该方法能够在多成分耦合、多重偶发性冲击干扰的不利影响下准确提取异常故障特征, 并在应用中能够兼顾智能化、高鲁棒性及高计算效率.

关键词 谱峭度, 无监督学习, 迭代二均值聚类, 滚动轴承, 故障诊断

1 引言

滚动轴承是机械中应用最广泛的部件, 其工作状态直接影响整台机器的性能^[1]. 在轴承故障发生的初期及时作出诊断, 为机器维修决策提供充足的时间, 对于避免或减少损失具有重要意义^[2]. 滚动轴承性能退化发生故障时, 连续平稳过程被破坏, 零件间发生周期性冲击. 然而, 在故障早期此冲击十分微弱, 被淹

没在复杂的噪声中, 呈现幅值和频率的调制特征^[3,4]. 因此, 滚动轴承微弱故障特征提取成为近年来研究的重点和难点.

共振解调技术具有确切的物理意义, 是目前被广泛应用的滚动轴承早期故障特征提取方法之一^[5,6], 关键难点在于确定合适的滤波器参数. Dwyer^[7]提出用峭度估计检测信号中的非高斯分量, Antoni^[8]进一步提出快速谱峭度方法(fast spectral kurtosis, FSK), 围绕峭度

引用格式: 陈彬强, 曾念寅, 曹新城, 等. 无监督学习驱动的高端轴承故障智能诊断算法. 中国科学: 技术科学, 2022, 52: 165–179

Chen B Q, Zeng N Y, Cao X C, et al. Unsupervised learning-driven intelligent fault diagnosis algorithm for high-end bearing (in Chinese). Sci Sin Tech, 2022, 52: 165–179, doi: 10.1360/SST-2021-0296

值最高谱线构建滤波器解调共振信号, 之后谱峭度方法(SK)逐渐应用于机械轴承、异步电机等故障诊断。马新娜等人^[9]使用设备典型故障特征的先验信息辅助FSK滤波带宽的优化。钟也磐等人^[10]采用局部均值算法在小波包分解的基础上细化特征频带, 构建加强型谱峭度图。田晶等人^[11]使用集成经验模态分解和Birge-Massart阈值方法去除监测信号中的噪声, 提升FSK的频带选择准确性。Wang等人^[12]提出小波包变换流形学习在时频空间降噪, 增强SK的共振频带检测性能。

各种降噪与频域细分算法提升了SK的共振解调性能, 但大都忽略了峭度度量自身的缺陷。四阶矩运算增强了远离期望的数据点对峭度度量的贡献度, 但也使该度量对信号中的强冲击干扰十分敏感。当监测信号存在SIs, SK将不能准确度量信号中周期性冲击成分的强度, 致使共振频带选择错误, 漏检设备故障。针对SIs的干扰, Chen等人^[13]结合时域的冲击性与频域的稀疏性, 提出一种空间谱集总峭度。代士超等人^[14]提出一种基于子频带谱峭度平均的快速谱峭度改进算法。Wang等人^[15]通过对多个信号样本的SK取平均值抑制SIs的干扰, 成功应用于风机轴承的故障诊断。但是, 面对工业现场显著强于正常信号的SIs, 甚至是短时持续的强噪声, 平均估计不足以消除SIs的干扰, 上述方法仍然难以正确判定共振频带。

随着工业信息化的不断提升, 数据驱动的故障诊断和预测性维护技术日益成为研究人员关注的焦点^[16,17]。机器学习模型通过端到端的自主学习从监测数据中自适应地提取特征, 构建与诊断对象匹配性更强的诊断模型。柏壮壮等人^[18]提出了一种基于遗传算法和支持向量机的自适应紧框架学习方法, 克服噪声对过完备字典的影响。王庆锋等人^[19]将无监督的K-means聚类算法应用于离心压缩机的智能故障诊断, 为自愈调控技术提供决策支撑。Mao等人^[20]使用自动编码器自适应地提取深度特征, 然后通过优化求解输出核正则目标函数建立诊断模型, 实现良好的泛化能力和鲁棒性。Singh等人^[21]提出一种利用分类和回归技术识别轴承磨损状态并预测剩余使用寿命的机器学习模型。Xue等人^[22]集和卡尔曼滤波器和支撑向量机预测设备的剩余使用寿命, Cao等人^[23]融合双树复小波框架和卷积网络间接监测刀具的磨损状态。Li等人^[24]使用粒子群优化算法改进极限学习机, 然后结合变分

模式分解算法从轴承故障早期的监测数据中提取微弱特征, 实现风机轴承故障的高精度诊断。数据驱动的人工智能算法不需要相关领域的专业知识, 然而获取充足的设备状态数据集却需要时间成本, 特别是故障状态监测数据难以获得, 这限制了全数据驱动故障诊断模型在工业应用中的推广速度。

综上所述, 融合物理模型方法与人工智能方法的优势, 本文提出一种无监督学习的智能谱峭度方法, 用以在恶劣环境中实现高端轴承的故障诊断。所提方法首先沿时间轴分割原始监测信号, 将SIs孤立到数据片段中。基于SIs会显著改变数据片段的峭度这一先验知识, 在SPFS对数据片段进行无监督聚类, 识别被SIs污染的数据片段(contaminated fragments, CFs)。针对SIs数量、时间与强度的不可预测性, 提出一种迭代二均值聚类算法, 逐步识别清除全部CFs, 解决聚类簇数难以设定的问题。然后基于正常片段(normal fragments, NFs)统计信号样本的峭度值, 结合双树复小波分解构建智能谱峭度(intelligent spectral kurtosis, ISK), 据此选择共振频带, 提取故障特征。

2 问题描述

2.1 谱峭度方法及其SIs敏感问题

设 $x(n)$ 为一个零均值非平稳随机过程, 则它可以分解为

$$x(n) = \int_{-1/2}^{+1/2} H(n, f) e^{j2\pi fn} dZ_x(f), \quad (1)$$

其中, $dZ_x(f)$ 是频谱增量, $H(n, f)$ 是 $x(n)$ 在频率 f 处的复包络, 可以通过带通滤波器组、小波包分解等计算方法得到。根据四阶中心矩的定义, 信号的谱峭度为

$$K_x(f) = \frac{\langle |H(n, f)|^4 \rangle}{\langle |H(n, f)|^2 \rangle^2} - 2, \quad (2)$$

其中, $\langle f(n) \rangle = \lim_{N \rightarrow \infty} N^{-1} \sum_N f(n)$ 表示函数 $f(n)$ 的时域平均值。谱峭度度量具备以下特征: 高斯过程的谱峭度为0; 平稳过程的谱峭度是与频率相关的常值函数; 加性噪声会降低非平稳过程的谱峭度值。谱峭度的上述性质与共振解调频带选择的目标相契合, 带通信号中的周期性冲击成分越强, 其谱峭度值越高。但

是在实际应用中却容易受到SIs的干扰. 当信号样本受到SIs的污染, 保留SIs的带通子信号(非高斯分量强度更高, 频率更低)的峭度会显著高于保留周期性瞬态冲击的带通子信号(非高斯分量强度更低, 频率更高). SK会选择含有SIs的频段而非含有周期性瞬态冲击的频段, 导致共振频带选择错误, 致使故障漏检. 因此, 消除SIs对于谱峭度方法至关重要.

2.2 k 均值聚类算法与类簇数难题

给定样本集 $D = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$, k 均值算法将样本划分为 k 个类簇 $C = \{C_1, C_2, \dots, C_k\}$, 优化目标为最小化全局误差 E .

$$E = \sum_{i=1}^k \sum_{\mathbf{x} \in C_i} \|\mathbf{x} - \mu_i\|_2^2, \quad (3)$$

其中, $\mu_i = \frac{1}{|C_i|} \sum_{\mathbf{x} \in C_i} \mathbf{x}$ 是类簇 C_i 的均值中心. 式(3)中的 2 范数可以替换为其他距离函数, 比如 1 范数和余弦距离, 但都是度量各样本围绕其类簇中心的紧密程度, E 越小则同类样本相似度越高. 遍历所有可能的类簇划分是一个 NP 难问题, 应用中常采取贪心策略. 初始化类簇数目和类簇中心后, 依据样本点距离各类簇中心的距离划分归属, 然后更新各类簇的均值中心, 重复迭代过程以近似地最小化全局误差 E . k 均值算法收敛速度快, 鲁棒性强, 可靠性高, 对于低维度数据尤其适用.

然而, 聚类簇数是难以预估的, 肘部法则是一种可行的优化方法, 但需要大量的重复均值聚类过程, 不满足工业现场对时效的要求.

3 无监督学习驱动的轴承故障智能诊断方法

无监督机器学习在工业监测数据挖掘与建模中的优越性已经在许多案例中得到验证^[25]. 本文提出一种融合无监督学习与谱峭度方法的轴承故障智能ISK诊断方法. 使用无监督的迭代二均值聚类算法在时域识别并清除CFs, 消除SIs对共振解调的干扰.

3.1 方法设计

所提出的ISK方法如图1所示, 包括7个步骤:

(1) 使用加速度传感器等技术采集信号样本;

图1 (网络版彩图) 无监督学习增强的智能故障诊断方法
Figure 1 (Color online) The flowchart of the proposed intelligent fault diagnosis method enhanced by unsupervised learning.

(2) 使用双树复小波包算法对原始信号样本进行多分辨分解, 获得带宽和中心频率不同的带通子信号;

(3) 将带通重构子信号在时域等分, 使SIs孤立到少数的CFs;

(4) 使用所提出的迭代二均值算法在峭度特征空间识别并清除CFs;

(5) 基于保留的NFs估计带通子信号的真实峭度, 消除SIs对ISK方法的干扰;

(6) 对所有带通子信号执行步骤3~5, 生成ISK智能谱峭度图;

(7) 根据ISK选择最优共振频带, 开展包络解调分析确认故障类型.

3.2 迭代二均值聚类算法

在实际应用中, CFs之间可能存在很大的强度差异, 类簇数难以设定. 为了无遗漏地识别CFs, 提出一种基于均值聚类的迭代二均值聚类算法, 每次二均值聚类清除少数的离群点, 通过迭代逼近在较低的计算开销下清除全部CFs. 设信号样本等分数目为 n , 数据片段的峭度特征值为 x_n , 则迭代二均值聚类算法流程如下.

算法1

输入: 初始样本集 $D = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$;

终止条件 λ .

过程:

repeat 1:

$$\mu_1 = \operatorname{argmin}_{\mathbf{x}_i \in D} \|\mathbf{x}_i\|_2^2; \quad \mu_2 = \operatorname{argmax}_{\mathbf{x}_i \in D} \|\mathbf{x}_i\|_2^2$$

repeat 2:

```

令  $C_1 = \emptyset; C_2 = \emptyset$ 
  for  $j = 1, 2, \dots, n$  do
    if  $\|\mathbf{x}_j - \boldsymbol{\mu}_1\|_2 < \|\mathbf{x}_j - \boldsymbol{\mu}_2\|_2$ 
       $C_1 = C_1 \cup \{\mathbf{x}_j\}$ 
    else
       $C_2 = C_2 \cup \{\mathbf{x}_j\}$ 
    end if
  end for
 $\boldsymbol{\mu}'_1 = \frac{1}{|C_1|} \sum_{\mathbf{x} \in C_1} \mathbf{x}$ 
 $\boldsymbol{\mu}'_2 = \frac{1}{|C_2|} \sum_{\mathbf{x} \in C_2} \mathbf{x}$ 
  if  $\boldsymbol{\mu}'_1 \neq \boldsymbol{\mu}_1 \parallel \boldsymbol{\mu}'_2 \neq \boldsymbol{\mu}_2$ 
     $\boldsymbol{\mu}_1 = \boldsymbol{\mu}'_1; \boldsymbol{\mu}_2 = \boldsymbol{\mu}'_2$ 
  end if
  until  $\boldsymbol{\mu}'_1 = \boldsymbol{\mu}_1 \& \& \boldsymbol{\mu}'_2 = \boldsymbol{\mu}_2$ 
  if  $\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1 > \boldsymbol{\mu}_1 * \lambda$ ;
     $n = |C_1|$ 
  end if
  until  $\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1 \leq \boldsymbol{\mu}_1 * \lambda$ 
  输出: NFs集合.

```

其中, $\|\cdot\|_2$ 表示均方根, $|\cdot|$ 表示数据集的样本数.

算法中 **repeat 2** 为常规的二均值聚类算法, 其迭代终止条件为 $\boldsymbol{\mu}'_1 = \boldsymbol{\mu}_1 \& \& \boldsymbol{\mu}'_2 = \boldsymbol{\mu}_2$, 即聚类中心不再移动. 因为初始聚类中心被设置为样本特征值的极大值与极小值, 所以每次 **repeat 2** 结束都能识别一部分特征值较大的CFs并清除.

repeat 1 是对保留的样本重复执行 **repeat 2**, 直到全部CFs都被清除. 因为CFs的峭度值显著高于NFs, 当CFs已经被全部清除, **repeat 2** 输出的两个类簇 C_1 和 C_2 的类间差异将显著降低. 所以, 可以为 $\boldsymbol{\mu}_1$ 和 $\boldsymbol{\mu}_2$ 的差值设置阈值作为 **repeat 1** 的终止条件. 因此, 本文设置超参数 λ , 以 $\boldsymbol{\mu}_2 - \boldsymbol{\mu}_1 \leq \boldsymbol{\mu}_1 * \lambda$ 为 **repeat 1** 的终止条件.

对于 n 个初始样本, 假设 **repeat 1** 需要迭代 m_1 次, **repeat 2** 需要迭代 m_2 次, 忽略每次 **repeat 2** 迭代结束清除被孤立样本导致的样本数目减少, 根据算法流程可

以估计其时间复杂度为 $O(3n * m_1 * m_2)$. 考虑到在本文的应用场景中, NFs的峭度指标非常相似, CFs数量很少且与NFs差异显著, **repeat 2** 可以快速收敛, 而 **repeat 1** 的迭代次数 m_1 不会超过CFs的数量, 所以可以估计所提迭代二均值算法在使用中的时间复杂度为 $O(n)$.

在双树复小波包分解出的子信号中很大一部分不包含CFs, 也就意味着 **repeat 2** 只需要执行一次, 对于这些子信号产生的附加计算更少. 另一方面, 为了使轴承故障引发的周期性瞬态冲击均匀地分布到时域数据片段中, 数据片段的长度应不小于单个轴承故障周期, 也就意味着在算法使用过程中 n 的数值很小, 进一步限制了所提ISK产生的额外计算时间消耗, 保证了算法的时效性.

3.3 双树复小波包分解

双树复小波变换采用双树滤波器, 提升了信号重构的完整性, 实现了近似平移不变性, 抑制了混叠. 以之为基础, 双树复小波包变换(the dual-tree complex wavelet packet transform, DTCWPD)进一步细化了高频频域分解, 实现了全频谱的多分辨率分解.

DTCWPD并行操作一对树形滤波器组, 以形成复数小波变换分离的实部和虚部, 对应于实树和虚树的小波 $\psi^{\text{Re}}(t)$ 和 $\psi^{\text{Im}}(t)$, 满足以下两个尺度关系:

$$\psi^*(t) = \sqrt{2} \sum_n h_1^*(n) \phi^*(2t - n), \quad (4)$$

$$\phi^*(t) = \sqrt{2} \sum_n h_0^*(n) \phi^*(2t - n), \quad (5)$$

此处 $*$ 表示实部或者虚部, $\{h_0^{\text{Re}}, h_1^{\text{Re}}\}$ 和 $\{h_0^{\text{Im}}, h_1^{\text{Im}}\}$ 分别表示实树和虚树的滤波器组, DTCWT确保该对小波满足以下公式给出的近似希尔伯特变换.

$$\psi^{\text{Im}}(t) \approx H\{\psi^{\text{Re}}(t)\}, \quad (6)$$

此处 $H\{\cdot\}$ 为希尔伯特算子, 因此复小波变换 $\psi(t) = \psi^{\text{Re}}(t) + j\psi^{\text{Im}}(t)$ 是准解析的.

Bayram等人^[26]提出了一种高效的DTCWPD实现方法, 其滤波器树由第一级滤波器组、双树滤波器组和通用滤波器组三种滤波器组成, 实现了实树和虚树的并行分解. 通用滤波器组应用于它自己的输出以及实树和虚树中双树滤波器的高通输出, 以实现准解析变换. 本文中使用的双树复小波基函数如图2所示.

图 2 (网络版彩图)双树复小波基函数的时频原子图。(a) 复尺度函数时域波形; (b) 复小波函数时域波形

Figure 2 (Color online) The time-frequency atom of DTCWPD. (a) The time-domain waveform of complex scaling function; (b) the time-domain waveform of the complex wavelet function.

4 滚动轴承故障数字仿真实验

4.1 含SIs污染轴承故障仿真信号构造

本节构造轴承故障模拟信号开展仿真实验, 验证所提出的迭代二均值聚类算法识别清除CFs的性能。根据轴承故障的机械原理, 理想的仿真信号 $s_0(t)$ 如等式(7)所定义, 由周期性瞬态成分 $x(t)$ 、谐波成分 $c(t)$ 和高斯白噪声 $n(t)$ 组成:

$$\begin{aligned} s_0(t) &= x(t) + c(t) + n(t), \\ x(t) &= \sum_k A^d e^{-\gamma(t-k/f^d)} \sin(2\pi f^s t) \varepsilon(t-k/f^d), \\ c(t) &= A_1^c \sin(2\pi f_1^c t) + A_2^c \sin(2\pi f_2^c t), \\ i(t) &= \sum_k A_k^i e^{-\gamma_k^i(t-\tau_k^i)} \sin(2\pi f_k^i t) \varepsilon(t-\tau_k^i), \end{aligned} \quad (7)$$

其中 A^d , f^d , f^s 分别为瞬态冲击的幅值、特征频率以及传递路径的共振频率, γ 为冲击响应衰减系数, $\varepsilon(\cdot)$ 为单位阶跃函数, A_1^c 和 f_1^c 分别为低频谐波成分的幅值和频率, $n(t)$ 为均值为0、标准差为 σ 的高斯白噪声。按照

表 1 轴承故障仿真信号的参数

Table 1 Parameters for bearing fault simulated signals

A^b	f^d	f^s	γ	A_1^c	A_2^c	f_1^c	f_2^c	σ
1	30 Hz	8 kHz	60π	0.7	0.9	150 Hz	460 Hz	2.5

表1设置各项参数, 以25.6 kHz为采样频率构造时长为5 s的离散数字仿真信号。统计 $s_0(t)$ 的峭度值为2.9, 信噪比约-6分贝。

然后, 根据等式(8)构造偶发性冲击成分 $i(t)$, 参数如表2所列。数据采集现场的SIs的来源和传递路径可能不同, 因而不同SIs设置了不同的共振频带 f_k^i 和衰减系数 γ_k^i 。统计 $i(t)$ 的峭度值为236.5。

最后, 将理想仿真信号 $s_0(t)$ 和偶发性冲击成分 $i(t)$ 合成受SIs污染的仿真信号 $s(t)=s_0(t)+i(t)$ 。图3(a)展示了所构造的 $s(t)$, 统计其峭度值为7.1。在自功率谱图3(b)中, 能够观察到谐波成分的谱峰和瞬态成分的频响通带, 但是无法确定故障的特征频率信息。

4.2 仿真信号的快速谱峭度分析实验

使用Antoni在文献[27]中推荐的快速谱峭度方法分析仿真信号 $s(t)$, 结果如图4所示。根据图4(a)选择最优滤波频带的中心频率为9000 Hz, 带宽为400 Hz, 这与设定的轴承故障瞬态冲击共振频率相差很大, 而与第2和第4个SIs的共振频率接近。重构频带[8800, 9200] Hz的子信号如图4(b)所示, 存在两个强烈的SIs, 与表2中的第2和第4个SIs在时间上一致。统计频带子信号的峭度值为156.6, 明显高于 $s(t)$ 的峭度值。这是因为滤波器消除了通带之外的噪声, 而保留了通带内的SIs。在子信号中, 相比于正常时段, SIs变得更加强烈, 导致峭度值升高。该带通子信号的希尔伯特包络解调谱如图4(c)所示, 包络谱的形式与单边指数衰减信号相同, 检测不到与轴承故障特征频率一致的谱峰序列。这证明, 当信号受到SIs污染时, 快速谱峭度方法会优选出最强SIs所在的频带, 不能准确诊断轴承故障。

4.3 智能故障诊断算法仿真实验

将信号片段等分, 数据片段长度设置为0.05 s, 是轴承故障瞬态冲击周期的1.5倍。5 s的仿真信号样本共被分割为100个数据片段, 计算每个数据片段的峭度

表 2 SIs 的构造参数

Table 2 Parameters of SIs

k	τ_k^i	A_k^i	f_k^i	γ_k^i
1	0.67	8.4	7430	35π
2	0.71	5.1	9030	50π
3	1.78	11.0	7410	45π
4	1.83	14.1	9050	40π
5	1.95	6.6	4980	38π
6	4.75	6.8	5020	40π
7	4.83	18.0	7390	45π

图 3 (网络版彩图) 受 SIs 污染的仿真信号样本. (a) 时域波形; (b) 自功率谱

Figure 3 (Color online) Simulated signal sample corrupted by SIs. (a) The time-domain waveform; (b) the self-power spectrum.

值, 并进行 0~1 标准化. 图 5 以直方图的形式展示了数据片段的标准化峭度. 分段间距为 0.02, 共划分为 50 个区间段, 后文的各直方图采用相同的设置. 在图 5 中, 大部分数据样本的峭度值较低, 表现出良好的聚集性. 少数几个受偶发性冲击污染数据样本的峭度值和有效值更高, 分布于特征空间的右侧.

根据仿真信号的设置参数, 直方图中右侧的 6 个数据片段都是 CFs, 应该被清除. 首先以 $\{0, 1\}$ 为初始聚类中心对数据片段进行二均值聚类, 测试二均值聚类算法能否清除 CFs. 图 6 展示了二均值聚类的结果, 两个类簇的分界点为 0.435. 可以看到左侧的三个 CFs 被错误地划分到 NFs 类簇中.

图 7 展示了三均值聚类的结果, 仍有一个峭度值较

图 4 (网络版彩图) 受 SIs 污染仿真信号的 FSK 分析结果. (a) 快速谱峭度图; (b) [8800, 9200] Hz 带通子信号时域波形; (c) [8800, 9200] Hz 带通子信号希尔伯特包络谱

Figure 4 (Color online) The FSK analysis results of simulated signal corrupted by SIs. (a) The fast spectral kurtosis map; (b) the time-domain waveform of the bandpass sub-signal of band [8800, 9200] Hz; (c) the Hilbert envelope spectrum of the bandpass sub-signal of band [8800, 9200] Hz.

低的 CFs 未能被检出. 需要注意的是, 这次实验的初始聚类中心为均匀分布的 $\{0, 0.5, 1\}$, 如果随机选择初始聚类中心, 识别错误率会更高.

图 6 和 7 证明, 如果不能准确地设置聚类簇数并初始化聚类中心, CFs 很可能被遗漏. 在工业现场, SIs 的数量、时间、强度都是不可预知的. 虽然肘部法则可以基于数据样本优化聚类簇数, 但是需要大量的重复实验, 与工业应用对时效的要求相冲突. 总结而言, 现有 K 均值聚类算法及配套优化方法无法满足工业现场智能故障诊断的需求.

使用本文中 3.2 节给出的迭代二均值聚类算法处理数据片段, λ 设置为 2, 识别结果如图 8 所示. 可见, 第一次二均值聚类将右侧的 CFs 清除, 第二次二均值聚类将中部的 3 个 CFs 清除. 第三次二均值聚类将 NFs 划

图 5 (网络版彩图)数据片段的归一化峭度值分布
Figure 5 (Color online) The distribution of normalized kurtosis values for data fragments.

图 6 (网络版彩图)二均值聚类结果
Figure 6 (Color online) The result of bi-mean clustering.

图 7 (网络版彩图)三均值聚类结果
Figure 7 (Color online) The result of three-mean clustering.

分为两个类簇, 达到算法设定的终止条件 $\mu_2 - \mu_1 \leq \mu_1 * \lambda$, 左右两个类簇被合并并输出. 该实验表明, 本文提出的迭代二均值聚类算法可以逐次地将特征异常的受污染片段从样本集中孤立出来, 最终仅保留正常的数据片段.

进一步按 3.1 节方法步骤进行双树复小波包分解, 分解级数设置为 5, 子信号等分片段数设为 100. 使用所提出的迭代二均值聚类算法识别并清理各子信号中的

图 8 (网络版彩图)迭代二均值聚类结果. (a) 第一次; (b) 第二次; (c) 第三次
Figure 8 (Color online) The result of iterative bi-mean clustering. (a) First; (b) second; (c) third.

CFs, 生成ISK如图9(a)所示, 可见各子信号的ISK数值恢复正常. 实验在一台配置Intel Core i5处理器和8G内存的笔记本电脑上实施, 识别并清除CFs的过程的耗时约为2.3 s, 基本满足工业应用对时间节拍的要求.

表3列举了 $s(t)$ 中含SIs的带通子信号的峭度值和本文方法得出的ISK值, 作为参考也列举了 $s_0(t)$ 中各带通子信号的真实峭度值. 可见各带通子信号的ISK值与其真实峭度值的误差不超过2%, 证明所提出的迭代二均值聚类算法能够准确识别并清除信号中各个CFs, 可靠地估计信号样本的真实峭度.

由图9(a)得到最优共振频带为[8000, 8200] Hz, 覆盖了表1中设定的故障共振频率. 在最优带通子信号的时域波形中未见SIs的干扰. 子信号的希尔伯特包络解调谱故障特征频率为间隔的谱峰序列十分显著. 倍频谱峰逐次递减, 符合指数衰减特征, 表明重构子信号中周期性冲击成分单一, 未受到偶发性冲击的污染.

综上, 滚动轴承故障的数字仿真实验验证了本文提出的ISK方法可以克服多重SIs的干扰, 准确识别信

图9 (网络版彩图)受SIs污染仿真信号的ISK分析结果. (a) 智能谱峭度图; (b) [8000, 8400] Hz带通子信号时域波形; (c) [8000, 8400] Hz带通子信号希尔伯特包络谱

Figure 9 (Color online) The ISK analysis results of simulated signal corrupted by SIs. (a) The intelligent spectral kurtosis map; (b) the time-domain waveform of the bandpass sub-signal of band [8000, 8400] Hz; (c) the Hilbert envelope spectrum of the bandpass sub-signal of band [8000, 8400] Hz.

表3 含SIs的带通子信号的智能峭度估计

Table 3 Kurtosis estimation of sub-signal with SIs

频段 (kHz)	$s_0(t)$ 中子信号真实峭度	$s(t)$ 中子信号FSK值	$s(t)$ 中子信号ISK值
[4.8, 5.2]	3.03	78.26	2.99
[7.2, 7.6]	3.09	254.44	3.18
[8.8, 9.2]	3.00	269.70	2.88

号中的循环瞬态冲击及其频率位置.

5 电机轴承故障智能诊断实验

为了验证所提出的无监督学习增强的轴ISK方法的实用性, 使用凯斯西储大学(Case Western Reserve

University, CWRU)公开的滚动轴承故障数据开展验证实验.

5.1 实验设置与数据说明

凯斯西储大学滚动轴承实验数据是领域公认的可靠数据, 实验装置如图10所示, 包括电动机、电磁负载器、联轴器以及基座. 实验中, 滚动体故障被设置在电动机风扇端轴承中, 故障直径为0.5334 mm. 轴承型号为6203-2RS JEM SKF深沟球滚动体轴承, 滚珠8个. 电机转速约为1772 r/min, 根据滚动轴承故障物理模型可以估计各部件损伤对应的特征频率: 外圈, 90.17; 内圈, 146.09; 滚动体, 58.88; 保持架, 11.27.

实验中使用加速度传感器采集振动数据, 采样频率为12 kHz. 实验过程中受到未知来源SIs的干扰, 信号样本的时域波形和自功率谱如图11所示.

图10 (网络版彩图)凯斯西储滚动轴承故障实验装置

Figure 10 (Color online) The CWRU bearing test rig.

图11 (网络版彩图)凯斯西储轴承故障实验信号样本. (a) 时域波形; (b) 自功率谱

Figure 11 (Color online) A signal sample from CWRU defected bearing. (a) The time-domain waveform; (b) the self-power spectrum.

对故障信号样本进行FSK分析, 结果如图12所示. 根据图12(a)选择的最优滤波频带为[2250, 2500] Hz, 带通子信号的时域波形如图12(b)所示, 为SIs所处的频带, 观察不到周期性的冲击成分.

进一步计算最优滤波子信号的包络解调谱如图12(c), 包络谱中没有明显的等间隔谱峰. 这进一步验证了在SIs干扰下, FSK将会失效, 错误地选择滤波频带, 致使轴承故障漏检.

5.2 电机轴承故障的ISK智能诊断

以FSK分解第二层中的峭度最高频段[1500, 3000] Hz为例展示带通子信号的智能峭度计算过程. 将重构子信号等分为50个数据片段, 执行迭代二均值聚类, 过程如图13所示.

经过两次二均值聚类成功清除了全部CFs. 第1次清除了两个带有较强SIs CFs, 为图13(c)中深色的两个片段. 第2次清除了两个带有较弱SIs CFs, 为图13(c)中浅色的两个片段. 到第3次时满足迭代终止条件. 计算剩余NFs的ISK值为3.1.

进而使用3.1节给出的智能诊断方法对实验信号样本进行分析, 双树复小波包分解级数设置为5, 各重构子信号的等分段数设置为50. 使用迭代二均值聚类算法识别并清理各子信号中的CFs后计算ISK值, 生成智能谱峭度图如图14(a), 优选出的最优共振频带为[562.5, 750] Hz. 如图14(b)所示, 滤波后的子信号在时域波形中存在明显的周期性冲击.

图12 (网络版彩图) 凯斯西储故障信号样本的FSK分析结果. (a) 快速谱峭度图; (b) [2250, 2500] Hz带通子信号时域波形; (c) [2250, 2500] Hz带通子信号希尔伯特包络谱

Figure 12 (Color online) The FSK analysis results of CWRU fault samples. (a) The fast spectral kurtosis map; (b) the time-domain waveform of the bandpass sub-signal of band [2250, 2500] Hz; (c) the Hilbert envelope spectrum of the bandpass sub-signal of band [2250, 2500] Hz.

图13 (网络版彩图) [1500, 3000] Hz频段子信号的迭代二均值聚类结果. 第一次(a)和第二次(b)二均值聚类结果; (c) 被清理的异常片段; (d) 手动选择的片段的希尔伯特包络

Figure 13 (Color online) The iterative bi-mean clustering result of the signal fragments of frequency band [1500, 3000] Hz. The results of the first (a) and second (b) bi-mean clustering; (c) the anomalous fragments that were cleaned up; (d) the Hilbert envelope of the manually selected fragment.

图 14 (网络版彩图)凯斯西储故障信号样本的ISK诊断结果. (a) 智能谱峭度图; (b) [562.5, 750] Hz带通子信号时域波形; (c) [562.5, 750] Hz带通子信号希尔伯特包络谱

Figure 14 (Color online) The ISK diagnosis result of CWRU experiment. (a) The intelligent spectral kurtosis map; (b) the time-domain waveform of the bandpass sub-signal of band [562.5, 750] Hz; (c) the Hilbert envelope spectrum of the bandpass sub-signal of band [562.5, 750] Hz.

进一步地分析子信号的希尔伯特包络解调谱, 如图14(c)所示, 存在显著的谱峰序列. 根据谱峰的频率可知其为滚动体故障特征频率的倍频及主轴转频的倍频. 细实曲线拟合了主轴转频的倍频谱峰, 这表明转轴存在偏心误差或联轴器存在同轴度误差. 图中星形点标记了滚动体故障特征频率的前三倍频, 从粗实线拟合曲线可知三个谱峰呈现出规律的指数衰减特征, 确切地表明了轴承的滚动体存在损伤.

观察图14(a)发现第4层第10个频段[3375, 3750] Hz的ISK值也很高. 图15具体分析该频段子信号的处理过程. 根据终止条件进行了两次迭代二均值聚类. 第一次聚类清除了1个含有很强SIs的CFs, 对应图15(c)中以深色标识的片段. 第二次聚类清除了7个峭度较低的CFs, 对应图15(c)中以浅色标识的片段. 由剩余NFs的时域波形可知该频带带通子信号的ISK数值

图 15 (网络版彩图) ISK次高频段的分析过程. 第一次(a)和第二次(b)二均值聚类结果; (c) 被清理的异常片段

Figure 15 (Color online) The analysis process of the frequency band with the second highest ISK metric. The results of the first (a) and second (b) bi-mean clustering; (c) the anomalous fragments that were cleaned up.

较高是因为其中存在周期性的冲击.

5.3 与其他谱峭度改进方法的对比

为进一步验证所提出的智能诊断方法的先进性, 开展与其他方法的对比实验. 参与对比的方法包括Wang等人^[15]提出的平均谱峭度方法(average spectral kurtosis, ASK)和二均值聚类增强谱峭度算法(binary-means enhanced spectral kurtosis, BMSK).

ASK的核心在于将原始信号样本分段后, 用各片段的谱峭度的平均值估计该信号样本的真实谱峭度. 其前提是信号样本中只有少数几个SIs, 且强度不能太高. 本实验中, 根据Wang等人的推荐, 信号样本等分长度为0.2 s, 细节步骤请参考文献^[15].

BMSK即使用二均值聚类算法将各频段重构子信号的片段分为两类, 然后使用其中较大类簇估计重构子信号的峭度值. 在本实验中, 使用数据片段峭度的最大值和最小值作为初始聚类中心.

5.3.1 ASK方法的局限性分析

图16展示了ASK的诊断结果. 对比图16(a)和12(a)可知, ASK的最高值明显低于FSK的最高值, 这表明平均估计可以在一定程度上抑制SIs对SK方法的干扰.

然而, 在ASK最优频段[3750, 4125] Hz的时域波形图16(b)仍存在多个SIs, 在子信号的希尔伯特包络谱中观察不到与故障频率相匹配的等间隔谱峰, 轴承故障诊断失败.

进一步分析, 在整个时域统计该频段子信号的峭度值为8.71, 而ASK得出的平均峭度值为7.37, 表明平均估计对SIs抑制效果有限. 以图16(b)子信号中2.1 s的最高冲击点为中心, 根据文献的建议将片段长度设置为0.2 s时, 片段峭度值为全时域峭度值的1.9倍. 这表

图16 (网络版彩图) 凯斯西储故障信号样本的ASK诊断结果. (a) 平均谱峭度图; (b) [3750, 4125] Hz带通子信号时域波形; (c) [3750, 4125] Hz带通子信号希尔伯特包络谱

Figure 16 (Color online) The ASK diagnosis result of CWRU experiment. (a) The averaging spectral kurtosis map; (b) the time-domain waveform of the bandpass sub-signal of band [3750, 4125] Hz; (c) the Hilbert envelope spectrum of the bandpass sub-signal of band [3750, 4125] Hz.

明, 虽然平均算法可以抑制离群点对整体的影响, 但是经过分段, SIs对CFs峭度值的影响可能加剧, CFs峭度值进一步升高, 两者相互抵消, 导致ASK方法对SIs的抑制效果受限.

5.3.2 BMSK方法的局限性分析

图17展示了BMSK方法的诊断结果. 最优频段为[2250, 2625] Hz, 对比图17(b)和11(a)可知, 相比于原始信号, 带通子信号中的SIs被有效地削弱, 其中第一个SIs的削弱幅度更大. 然而, 相比于NFs, CFs的幅值仍然高. 进一步分析带通子信号的希尔伯特包络谱, 未发现与故障频率相匹配的等间隔谱峰, 轴承故障诊断失败.

图17 (网络版彩图) 凯斯西储故障信号样本的BMSK诊断结果. (a) 二均值聚类增强谱峭度图; (b) [2250, 2625] Hz带通子信号时域波形; (c) [2250, 2625] Hz带通子信号希尔伯特包络谱

Figure 17 (Color online) The BMSK diagnosis result of CWRU experiment. (a) The spectral kurtosis map enhanced by bi-mean clustering; (b) the time-domain waveform of the bandpass sub-signal of band [2250, 2625] Hz; (c) the Hilbert envelope spectrum of the bandpass sub-signal of band [2250, 2625] Hz.

对比图17(a)和12(a), 可以发现BMSK的最大值相比于FSK的最高值下降了近70%, 表明二均值聚类的确可以剔除信号样本中受偶发冲击污染的片段. 然而, 对比图17(a)和14(a)可以发现, BMSK的最大值高达ISK最大值的4倍以上, 也显著高于ASK最大值, 表明该算法对于[2250, 2625] Hz频段失效. 具体地分析该频段的处理过程, 如图18所示. 在图18(a)中, 绝大部分NFs的峭度值聚集在0.1以下, 然而两个较小的异常数据点被错误地识别为NFs. 相应地, 在图18(b), 只有峭度值最高的深色片段被正确识别并清除, 其余两个幅值较小的冲击被遗漏. 分析可知, BMSK方法面对实际信号中复杂多变SIs可靠性很低.

观察图18(b)中两个SIs的幅值接近, 在图18(a)中两个CFs的峭度值则相差超过一倍. 图18(c)放大展示了这一段信号, 可以发现, 相对于数据片段的时间尺度, 浅色冲击的衰减速度明显缓慢, 其中高幅值数据点的占比明显增加. 所以, 当图18(b)中的第一个SIs被划分到浅色片段中后, 它导致的峭度增幅显著下降, 而不能被二均值聚类检测到. 但是, 当浅色片段被错误地识别为NFs后, 第一个SIs在全部NFs中的占比又急剧下降, 导致[2250, 2625] Hz频段极高的二均值聚类增强谱峭度值. 这进一步说明, 在实际应用中, 监测信号遭受的未知来源冲击污染可能非常复杂, 简单的二均值聚类无法保证完全检测到全部CFs, 致使谱峭度方法失效.

三种算法识别的最优共振频带列举在表4中. 可见, 相比于BMSK方法, ASK方法的平均估计抑制了SIs的影响. 但是, 只有ISK方法识别出的最优共振频带未受SIs污染而准确地诊断出轴承故障, 验证了所提方法的优越性.

6 结论与讨论

为解决设备状态监测过程中不可避免的偶发性冲

图18 (网络版彩图)BMSK检测最优频段失效的原因. (a) 二均值聚类的结果; (b) 被清理的异常片段; (c) 遗漏的被污染片段

Figure 18 (Color online) The cause of the failure of BMSK algorithm. (a) The result of bi-mean clustering; (b) the anomalous fragments that were cleaned up; (c) the contaminated fragment that were missed.

击干扰, 本文提出一种无监督学习的ISK方法, 融合物理模型方法的可解释性和人工智能方法的自学习能力, 在恶劣的环境下实现高端轴承的故障诊断. 使用双树复小波包框架对监测信号进行多尺度分解, 在时域将带通子信号分段后, 使用所提的迭代二均值聚类算法逐次识别并清除受SIs污染的CFs. 统计NFs获得ISK智能谱峭度图, 可靠地识别包含周期性瞬态冲击成分

表4 不同算法提取的最优共振频带

Table 4 The resonance frequency band determined by various algorithms

方法	子信号峭度最大值	检测的最优共振频带 (Hz)	子信号中SIs幅值
ASK	5.2	[3750, 4125]	0.91
BMSK	18.3	[2250, 2625]	0.36
ISK	3.9	[562.5, 750]	无SIs

的共振频带, 识别故障类型. 电机轴承故障实验验证了 ISK 克服多重 SIs 诊断轴承早期故障的灵敏性与可靠性. 主要的研究结论如下.

(1) 谱峭度指标能够度量数据样本中非高斯分量的强度, 但无法由峭度指标估计非高斯分量的真实分布, 非高斯分量的概率与信号样本的峭度亦存在强烈的非线性. 当信号样本中受 SIs 污染, FSK 方法会检测仅含有 SIs 的频带, 致使故障漏检. 另一方面, 由于监测信号中白噪声的高斯属性和谐波成分以及轴承故障瞬态冲击的周期性, 未被 SIs 污染的 NFs 估计信号样本的真实峭度具有很高的可靠性.

(2) 消除信号样本中的 SIs 对 FSK 方法至关重要. 然而已有频域滤波方法难以在保留周期性瞬态冲击成分的前提下针对性地消除 SIs. 为此, 本文提出的无监督学习 ISK 在时域消除 SIs. 将信号样本等分为时域片段后, 含有 SIs 的 CFs 与正常的 NFs 在峭度特征空间存在显著的差异. 迭代二均值聚类算法采取逐次分离最远离群体的 NFs, 以样本集和的可分度为指标自适应停止 SIs 分离过程. 仿真实验表明, 迭代二均值聚类在几次迭代内清除全部 CFs, 避免了聚类簇数优化算法繁重的计算开销.

(3) 双树复小波包分解展现出良好的全频域细分和降噪能力, 与所提迭代二均值聚类算法相结合而生成智能谱峭度图. 电机轴承故障实验验证了所提智能谱峭度方法克服多重 SIs 诊断轴承早期故障的灵敏性与可靠性, 实验结果表明所提智能谱峭度方法明显优于已有的谱峭度改进方法.

然而, 由于设备的实际工况非常复杂, 偶发性冲击难以估计, 为提升所提方法应用于制造现场装备健康监测的泛化能力, 以下几个方面值得进一步的深入研究.

(1) 所提迭代二均值算法对所有的子信号都必须执行至少一次均值聚类, 产生不必要的计算. 后续需要研究 CFs 的快速检测算法, 降低 ISK 的计算量, 提升实时性.

(2) 所提时域分段方法对监测信号长度提出要求, 后续将研究信号重采样方法, 在 CFs 与 NFs 在特征空间可分离的前提下降低 ISK 算法对数据采集时长的要求.

(3) 所提 ISK 提供了一种敏捷可靠的轴承故障提取方法, 后续将开展应用机器学习/深度学习的故障模式智能分类与定位研究, 实现无人化的轴承健康状态智能维护.

参考文献

- 1 Rai A, Upadhyay S H. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribol Int*, 2016, 96: 289–306
- 2 Yuan Y, Ma G, Cheng C, et al. A general end-to-end diagnosis framework for manufacturing systems. *Natl Sci Rev*, 2020, 7: 418–429
- 3 Chen X F, Guo Y J, Xu C B, et al. Review of fault diagnosis and health monitoring for wind power equipment (in Chinese). *China Mech Eng*, 2020, 31: 175–189 [陈雪峰, 郭艳婕, 许才彬, 等. 风电装备故障诊断与健康监测研究综述. *中国机械工程*, 2020, 31: 175–189]
- 4 Yang R, Li H, Wang C, et al. Rolling element bearing weak feature extraction based on improved optimal frequency band determination. *Proc Inst Mech Eng Part C-J Eng Mech Eng Sci*, 2018, 238: 623–634
- 5 Xiong Q, Zhang X, Wang J, et al. Sparse representations for fault signatures via hybrid regularization in adaptive undecimated fractional spline wavelet transform domain. *Meas Sci Technol*, 2021, 32: 045107
- 6 Zhang X, Liu Z, Wang L, et al. Bearing fault diagnosis based on sparse representations using an improved OMP with adaptive Gabor sub-dictionaries. *ISA Trans*, 2020, 106: 355–366
- 7 Dwyer R. Detection of non-Gaussian signals by frequency domain Kurtosis estimation. In: *Processings of the International Conference on Acoustics, Speech and Signal*. IEEE, 1983. 607–610
- 8 Antoni J. The spectral kurtosis: A useful tool for characterising non-stationary signals. *Mech Syst Signal Process*, 2006, 20: 282–307
- 9 Ma X N, Yang S P. Typical fast kurtogram algorithm and its application (in Chinese). *J Vib Shock*, 2016, 35: 109–114 [马新娜, 杨绍普. 典型快速谱峭图算法的研究及应用. *振动与冲击*, 2016, 35: 109–114]
- 10 Zhong Y P, Chen W, Du W, et al. An enhanced spectral kurtosis method for aero-engine gear hub fault diagnosis (in Chinese). *J Propul Tech*, 2017, 38: 1140–1146 [钟也磐, 陈卫, 杜炜, 等. 基于加强谱峭度的航空发动机齿轮毂故障诊断. *推进技术*, 2017, 38: 1140–1146]
- 11 Tian J, Wang Y J, Liu L L, et al. Fault feature extraction of rolling bearing using Birge-Massart threshold denoising with EEMD and spectral

- kurtosis (in Chinese). *J Aerospace Power*, 2019, 34: 1399–1408 [田晶, 王英杰, 刘丽丽, 等. 基于Birge-Massart阈值降噪与EEMD及谱峭度的滚动轴承故障特征提取. *航空动力学报*, 2019, 34: 1399–1408]
- 12 Wang Y, Tse P W, Tang B, et al. Kurtogram manifold learning and its application to rolling bearing weak signal detection. *Measurement*, 2018, 127: 533–545
- 13 Chen B Q, Zhang Z S, Zi Y Y, et al. Detecting of transient vibration signatures using an improved fast spatial-spectral ensemble kurtosis kurtogram and its applications to mechanical signature analysis of short duration data from rotating machinery. *Mech Syst Signal Processing*, 2013, 40: 1–37
- 14 Dai S C, Guo Y, Wu X, et al. Improvement on fast kurtogram algorithm based on sub-frequency-band spectral kurtosis average (in Chinese). *J Vib Shock*, 2015, 34: 98–102, 108 [代士超, 郭瑜, 伍星, 等. 基于子频带谱峭度平均的快速谱峭度图算法改进. *振动与冲击*, 2015, 34: 98–102, 108]
- 15 Wang L, Liu Z, Cao H, et al. Subband averaging kurtogram with dual-tree complex wavelet packet transform for rotating machinery fault diagnosis. *Mech Syst Signal Process*, 2020, 142: 106755
- 16 Yuan Y, Zhang Y, Ding H. Research on key technology of industrial artificial intelligence and its application in predictive maintenance (in Chinese). *Acta Automat Sin*, 2020, 46: 2013–2030 [袁烨, 张永, 丁汉. 工业人工智能的关键技术及其在预测性维护中的应用现状. *自动化学报*, 2020, 46: 2013–2030]
- 17 Lei Y, Yang B, Jiang X, et al. Applications of machine learning to machine fault diagnosis: A review and roadmap. *Mech Syst Signal Processing*, 2020, 138: 106587
- 18 Bai Z Z, Lu Y X, Gao Q W, et al. Bearing fault diagnosis based on adaptive tight frame learning (in Chinese). *J Vib Shock*, 2021, 40: 296–303 [柏壮壮, 卢一相, 高清维, 等. 基于自适应紧框架学习的轴承故障诊断. *振动与冲击*, 2021, 40: 296–303]
- 19 Wang Q F, Liu J H, Wei B K, et al. Research on data-driven clustering analysis fault identification method (in Chinese). *J Mech Eng*, 2020, 56: 7–14 [王庆锋, 刘家赫, 卫炳坤, 等. 数据驱动的聚类分析故障识别方法研究. *机械工程学报*, 2020, 56: 7–14]
- 20 Mao W, Feng W, Liang X. A novel deep output kernel learning method for bearing fault structural diagnosis. *Mech Syst Signal Process*, 2018, 117: 293–318
- 21 Singh S, Agarwal T, Kumar G, et al. Predicting the remaining useful life of ball bearing under dynamic loading using supervised learning. In: *Proceedings of the International Conference on Industrial Engineering and Engineering Management*. Macao, 2019
- 22 Xue Z, Zhang Y, Cheng C, et al. Remaining useful life prediction of lithium-ion batteries with adaptive unscented kalman filter and optimized support vector regression. *Neurocomputing*, 2020, 376: 95–102
- 23 Cao X C, Chen B Q, Yao B, et al. Combining translation-invariant wavelet frames and convolutional neural network for intelligent tool wear state identification. *Comput Industry*, 2019, 106: 71–84
- 24 Li K, Su L, Wu J, et al. A rolling bearing fault diagnosis method based on variational mode decomposition and an improved kernel extreme learning machine. *Appl Sci*, 2017, 7: 1004
- 25 Yuan Y, Tang X, Zhou W, et al. Data driven discovery of cyber physical systems. *Nat Commun*, 2019, 10: 4894
- 26 Bayram I, Selesnick I W. On the dual-tree complex wavelet packet and M-band transforms. *IEEE Trans Signal Process*, 2008, 56: 2298–2310
- 27 Antoni J. Fast computation of the kurtogram for the detection of transient faults. *Mech Syst Signal Process*, 2007, 21: 108–124

Unsupervised learning-driven intelligent fault diagnosis algorithm for high-end bearing

CHEN BinQiang¹, ZENG NianYin¹, CAO XinCheng¹, ZHOU ShengXi², HE WangPeng³ & TIAN Sai¹

¹ School of Aerospace Engineering, Xiamen University, Xiamen 361005, China;

² School of Aeronautics, Northwestern Polytechnical University, Xi'an 710072, China;

³ School of Aerospace Science and Technology, Xidian University, Xi'an 710071, China

Spectral kurtosis is an effective method for rolling bearing fault diagnosis. However, it is highly sensitive to common accidental impact features in engineering, which frequently leads to feature extraction failure. To solve this problem, a robust evaluation method based on unsupervised learning is proposed to calculate the kurtosis of time series under the interference of multiple sporadic impulses (MSIs). First, dynamic signal samples are divided into equal intervals according to the characteristics of high energy concentration in the time domain. Second, each block is mapped to statistical parameter feature space (SPFS). Third, based on the significant statistical difference between MSI and other components in SPFS, an isolated 2-means clustering algorithm is proposed that realizes the self-location of clustering center and self-adaptive adjustment of clustering number and identifies and suppresses blocks receiving interference in the signal step by step. Finally, kurtosis information fusion is performed for the remaining samples, excluding MSI interference. A new method for high-end bearing fault diagnosis is proposed, which is combined with the robust kurtosis evaluation method and the multi-scale decomposition method. Through simulations and actual bearing fault diagnosis, it is verified that the method can accurately extract abnormal fault features under the adverse effects of multicomponent coupling and multiple accidental impact interference and can consider intelligence, high robustness, and high computational efficiency in applications.

spectral kurtosis, unsupervised learning, iterative mean clustering, rolling bearing, fault diagnosis

doi: [10.1360/SST-2021-0296](https://doi.org/10.1360/SST-2021-0296)