

改进多尺度幅值感知排列熵与随机森林结合的滚动轴承故障诊断

吴海滨, 陈寅生, 张庭豪, 汪颖

引用本文:

吴海滨, 陈寅生, 张庭豪, 等. 改进多尺度幅值感知排列熵与随机森林结合的滚动轴承故障诊断[J]. *光学精密工程*, 2020, 28(3): 621–631.

WU Hai-bin, CHEN Yin-sheng, ZHANG Ting-hao, et al. Rolling bearing fault diagnosis by improved multiscale amplitude-aware permutation entropy and random forest[J]. *Optics and Precision Engineering*, 2020, 28(3): 621–631.

在线阅读 View online: <https://doi.org/10.3788/OPE.20202803.0621>

您可能感兴趣的其他文章

Articles you may be interested in

基于信息融合的机器人薄壁轴承故障智能诊断

Intelligent fault diagnosis of thin wall bearing based on information fusion

光学精密工程. 2019, 27(7): 1577–1592 <https://doi.org/10.3788/OPE.20192707.1577>

混沌振子识别轴承早期故障的极半径不变矩判据

Polar radius moment invariants criterion for identifying bearing early failure by chaotic oscillator

光学精密工程. 2018, 26(2): 418–425 <https://doi.org/10.3788/OPE.20182602.0418>

多传感器集成氢气检测系统的知识推送故障诊断

Fault diagnosis based on knowledge pushing in multi-sensor integration hydrogen detection system

光学精密工程. 2015, 23(6): 1742–1748 <https://doi.org/10.3788/OPE.20152306.1742>

基于稀疏编码空间金字塔匹配和GA-SVM的列车故障自动识别

Automatic fault recognition algorithm for key parts of train based on sparse coding based spatial pyramid matching and GA-SVM

光学精密工程. 2018, 26(12): 3087–3098 <https://doi.org/10.3788/OPE.20182612.3087>

在轨飞轮故障诊断混合框架设计

Design of hybrid frame for on-orbit flywheel fault diagnosis

光学精密工程. 2018, 26(7): 1728–1740 <https://doi.org/10.3788/OPE.20182607.1728>

文章编号 1004-924X(2020)03-0621-11

改进多尺度幅值感知排列熵与 随机森林结合的滚动轴承故障诊断

吴海滨¹, 陈寅生^{1*}, 张庭豪², 汪颖¹

(1. 哈尔滨理工大学 测控技术与通信工程学院, 黑龙江 哈尔滨 150080;

2. 哈尔滨工业大学 电气工程及自动化学院, 黑龙江 哈尔滨 150080)

摘要: 针对滚动轴承故障识别准确率较低的问题, 本文提出了一种新型滚动轴承故障诊断方法。该方法能够在准确识别滚动轴承故障类型的基础上, 进一步分析故障的严重程度。首先, 通过固有时间尺度分解提取滚动轴承振动信号的最佳固有旋转分量, 突显故障信号的冲击特征; 然后, 利用改进多尺度幅值感知排列熵对信号幅值和频率变化敏感的特性, 计算不同时间尺度下的幅值感知排列熵作为故障特征向量, 改善了多尺度分析中的粗粒化过程, 提升了故障特征提取的稳定性; 最后, 利用故障特征集构建随机森林多分类器, 实现对滚动轴承不同故障类型的识别及严重程度分析, 具有较强的泛化能力。实验结果表明, 与现有滚动轴承故障诊断方法相比, 平均故障识别准确率达到 99.25%。该方法能够稳定而有效地提取滚动轴承的故障特征且具有较好的实时性。

关键词: 滚动轴承; 故障诊断; 固有时间尺度分解; 幅值感知排列熵; 随机森林

中图分类号: TH133.33; TP277 **文献标识码:** A **doi:** 10.3788/OPE.20202803.0621

Rolling bearing fault diagnosis by improved multiscale amplitude-aware permutation entropy and random forest

WU Hai-bin¹, CHEN Yin-sheng^{1*}, ZHANG Ting-hao², WANG Ying¹

(1. *School of Measurement-Control Technology and Communication Engineering, Harbin University of Science and Technology, Harbin 150080, China;*

2. School of Electrical Engineering and Automation, Harbin Institute of Technology, Harbin 150080, China)

** Corresponding author, E-mail: ChenYS@hrbust.edu.cn*

Abstract: Aiming at the problem of low fault identification accuracy of rolling bearing, a novel fault diagnosis method of rolling bearing was proposed. This method can identify fault types of rolling bearing accurately and analyze the fault severity. Firstly, the optimum proper rotation (PR) component of rolling bearing vibration signal was extracted by intrinsic time-scale decomposition (ITD) to highlight the impact characteristics of fault signal. Then, using the characteristic that improved multi-scale amplitude-aware permutation entropy (IMAAPE) was sensitive to signal amplitude and frequency changes, the AAPE values in different time scales were calculated as the fault

收稿日期: 2019-12-09; 修订日期: 2020-01-16.

基金项目: 航天科学技术基金资助项目 (No. JZJXX20190013); 国家自然科学基金资助项目 (No. 61671190, 61803128)

feature vector, which improved the coarse-grained process in multi-scale analysis and increased the stability of fault feature extraction. Finally, the random forest multi-classifier was constructed by using the fault feature set to realize the fault type identification and severity analysis of rolling bearing, which had a strong generalization ability. Experimental results show that compared with the existing fault diagnosis methods of rolling bearing, average fault identification accuracy is 99.25%. This method can extract the fault characteristics of rolling bearing stably and effectively with good real-time performance.

Key words: rolling bearing; fault diagnosis; intrinsic time-scale decomposition; amplitude-aware permutation entropy; random forest

1 引言

滚动轴承是旋转机械中最常见的连接部件之一,但由于磨损、疲劳、腐蚀、过载等诸多因素的影响,滚动轴承在工作过程中极易发生故障^[1-6],进而影响机械设备的整体性能。因此,滚动轴承的故障诊断及严重程度分析对保证机械设备运行的可靠性及制定相应维修策略具有重要意义。

滚动轴承故障的位置及严重程度导致其振动信号的冲击特性存在明显差异。因此,基于振动信号的故障诊断技术成为当前滚动轴承异常状态监测的重要研究方向之一^[7]。滚动轴承故障诊断的本质是一个模式识别过程,主要包括特征提取和故障分类^[8-9]。但是,滚动轴承振动信号具有非线性和非平稳的特点,同时运行过程中容易受到多种外界因素的干扰,信噪比较低,导致轴承故障特征难以得到有效提取,影响故障诊断的识别准确率。

鉴于此,相关学者针对滚动轴承故障诊断展开了大量的研究工作。文献[7]利用集合经验模态分解(Ensemble Empirical Mode Decomposition, EEMD)实现对滚动轴承振动信号的自适应分解,并采用峭度值结合相关系数的方法确定包含主要轴承状态信息的本征模态函数,再利用其奇异值作为特征向量,通过超球多类支持向量机实现对滚动轴承的多故障分类。然而, EEMD 不能够完全解决 EMD 的模态混叠问题,峭度值结合相关系数的本征模态函数选择法会损失部分轴承故障信息,而超球多类支持向量机的核参数选取和优化过于复杂,增加了实际应用的困难。文献[10]利用局部均值分解(LMD)算法对滚动轴承振动信号进行预处理,再利用多尺度熵(MSE)提取故障特征

向量,最后构建 BP 神经网络分类器实现故障类型识别。但是,在时间序列的粗粒化过程中, MSE 的序列长度会随着尺度因子的增加而缩短。当尺度因子较大时,多尺度熵值具有不稳定性,进而影响特征提取的有效性。文献[11]利用多尺度排列熵提取滚动轴承振动信号中的故障特征,并采用 Laplacian Score 算法进行特征选择,随后通过支持向量机(SVM)实现故障类型识别。然而,基于排列熵的特征提取忽略了时间序列中元素幅值对熵值的影响,使得提取的故障特征具有较大的随机性,进而影响故障识别的准确率。

由于现有基于滚动轴承振动信号的故障诊断方法尚存在特征提取可分性不强、故障识别准确率较低及故障严重程度分析不充分等问题,本文提出了一种基于改进多尺度幅值感知排列熵(Improved Multiscale Amplitude-Aware Permutation Entropy, IMAAPE)与随机森林(Random Forest, RF)分类器的滚动轴承故障诊断方法。首先,采用固有时间尺度分解(Intrinsic Timescale Decomposition, ITD)对滚动轴承振动信号进行分解,选取最佳固有旋转分量,改善 EMD 分解结果的欠包络和过包络问题,并有效抑制了模态混叠和端点效应。然后,利用 IMAAPE 提取最佳固有旋转分量中蕴含的滚动轴承故障特征,改善了多尺度分析中的粗粒化过程,提升了故障特征提取的稳定性,同时在计算排列熵过程中引入相对规范化概率,增加对故障信号幅值和频率变化的敏感特性,有效提取故障类型与严重程度特征。最后,利用随机森林分类器泛化能力强、参数设置简便、训练速度快等优点,实现对滚动轴承不同故障类型的识别及严重程度分析。

2 固有时间尺度分解

ITD 适用于分析非平稳、非线性信号。ITD 能够将复杂时间序列分解为一系列固有旋转 (Proper Rotation, PR) 分量,准确地提取复杂时间序列信号的固有瞬时幅值、频率信息等相关形态特征^[12]。设 X_t 为待分析的复杂时间序列,定义 \mathcal{L} 为基线提取算子, \mathcal{L} 能够提取 X_t 中基线信号 $L_t = \mathcal{L} X_t$,并获取相应固有旋转分量 $H_t = (1 - \mathcal{L}) X_t$,信号 X_t 可以分解为:

$$X_t = \mathcal{L} X_t + (1 - \mathcal{L}) X_t = L_t + H_t. \quad (1)$$

ITD 算法的主要步骤如下:

Step1:假设 $\{\tau_k, k = 1, 2, \dots\}$ 表示信号 X_t 的局部极值,默认 $\tau_0 = 0$ 。

Step2:在区间 $[0, \tau_k]$ 中定义了 L_t 和 H_t ,且 X_t 在 $t \in [0, \tau_{k+2}]$ 的区间内有效。那么,在连续极值间隔 (τ_k, τ_{k+1}) 中提取的基线信号 L_t 表示为:

$$\mathcal{L} X_t = L_t = L_k + \left(\frac{L_{k+1} - L_k}{X_{k+1} - X_k} \right) (X_t - X_k), \quad t \in (\tau_k, \tau_{k+1}], \quad (2)$$

其中:

$$L_{k+1} = \alpha \left[X_k + \left(\frac{\tau_{k+1} - \tau_k}{\tau_{k+2} - \tau_k} \right) (X_{k+2} - X_k) \right] + (1 - \alpha) X_{k+1}, \quad (3)$$

其中: α 是线性缩放因子,用来调节提取固有旋转分量幅度, $\alpha \in [0, 1]$,通常取 $\alpha = 0.5$ 。

Step3:根据式(2)和式(3),固有旋转分量 H_t 可以表示为:

$$\mathcal{H} X_t \equiv (1 - \mathcal{L}) X_t = H_t = X_t - L_t, \quad (4)$$

其中 \mathcal{H} 为固有旋转提取算子。

Step4:将基线信号 L_t 作为下一次分解的输入信号,重复步骤 1~3,获取一系列 PR 分量。分解的终止条件为基线信号 L_t 变得单调或者小于某个预设值。

经过 ITD 分解后,时间序列 X_t 被分解为一系列 PR 分量和一个单调趋势分量。信号峰度能有效描述信号的脉冲特性。峰度值越高,信号所包含的脉冲特征越丰富。因此,定义峰度值最大的 PR 分量为最佳固有旋转分量,其计算过程如下^[13-14]:

$$K_i = \frac{1}{n} \sum_{k=1}^n PR_{ik}^4, \quad (5)$$

$$U_i = \frac{K_i}{\sum_{i=1}^m K_i}, \quad (6)$$

其中: K_i 表示第 i 个 PR 分量的峰度值, n 表示时间序列长度。 U_i 为第 i 个 PR 分量的归一化峰度值, m 是 PR 分量的个数。最佳固有旋转分量选取 U_i 为最大值时所对应的 PR 分量。

3 基于 IMAAPE 的特征提取

3.1 改进多尺度熵

仅从单一尺度对时间序列进行熵值分析,可能会损失原始信号的部分重要信息。因此,Costa 等于 2007 年提出了多尺度熵 (Multi-scale Entropy, MSE)^[15],实现对复杂信号在不同时间尺度下的特征信息提取,其定义如下:

假设一个长度为 N 的时间序列 $\{X_i\} = \{x_1, x_2, \dots, x_N\}$,利用尺度因子 $\tau = 1, 2, \dots, n$,对序列进行粗粒化,粗粒化过程如下:

$$y_j^\tau = \frac{1}{\tau} \sum_{i=(j-1)\tau+1}^{j\tau} x_i, 1 \leq j \leq \frac{N}{\tau}, \quad (7)$$

其中 y_j^τ 表示在尺度因子为 τ 时,经粗粒化后获得的新时间序列。

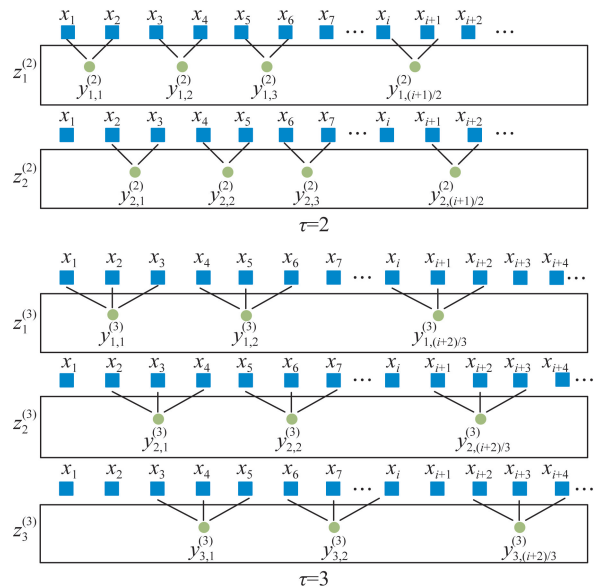


图 1 尺度因子 $\tau = 2$ 和 $\tau = 3$ 下改进多尺度熵的粗粒化过程

Fig. 1 Improved coarse-graining procedures for scale factor $\tau = 2$ and $\tau = 3$

随后,计算每个粗粒化的新时间序列的样本熵值,获得不同时间尺度下的 n 个多尺度熵值来描述原始时间序列的信号特征。然而,在粗粒化过程中,MSE 的时间序列的长度将缩短为 N/τ 。尺度因子 τ 越大,经粗粒化后的时间序列长度越短,这将影响后续对熵值的度量,降低特征提取效果。为了解决该问题,相关学者对 MSE 的粗粒化过程进行改进^[16],解决了 MSE 粗粒化后时间序列长度缩短的问题,改进多尺度熵的粗粒化过程如图 1 所示。改进后的粗粒化时间序列表示为:

$$\mathbf{z}_i^{(\tau)} = \{y_{i,1}^{(\tau)}, y_{i,2}^{(\tau)}, \dots\}, \quad (8)$$

$$\text{其中 } y_{i,j}^{(\tau)} = \frac{\sum_{f=0}^{\tau-1} x_{f+i+\tau(i-1)}}{\tau}.$$

3.2 幅值感知排列熵

Bandt 等于 2002 年提出排列熵 (Permutation Entropy, PE) 的概念^[17],目前 PE 广泛应用于对复杂时间序列信号的分析,以衡量一个非线性、非平稳性信号的复杂度。

假设给定的长度为 N 的时间序列 $\mathbf{x} = \{x_1, x_2, \dots, x_N\}$,对于每个时间点 t ,将信号 \mathbf{x} 嵌入到 d 维空间获得重构向量 $\mathbf{X}_t^{d,l} = \{x_t, x_{t+l}, \dots, x_{t+(d-1)l}, x_{t+(d-1)l}\}, t = 1, 2, \dots, N - (d-1)l$,其中, d 和 l 分别表示嵌入维数和时间延时。按每个向量 $\mathbf{X}_t^{d,l}$ 中元素的大小进行升序排列,即 $\{x_{t+(j_1-1)l}, x_{t+(j_2-1)l}, \dots, x_{t+(j_{d-1}-1)l}, x_{t+(j_d-1)l}\}$,其中 j_* 表示元素在重构向量 $\mathbf{X}_t^{d,l}$ 中的次序。因此,在嵌入维数为 d 时,共有 $d!$ 种排列顺序,第 i 种排列顺序记作 π_i 。

每个排列顺序 π_i 出现的概率表示为:

$$p(\pi_i^{d,l}) = \frac{p^{\text{update}}(\pi_i^{d,l})}{\sum_{i=1}^{N-d+1} \left(\frac{A}{d} \sum_{k=1}^d |x_{t+(k-1)l}| + \frac{1-A}{d-1} \sum_{k=2}^d |x_{t+(k-1)l} - x_{t+(k-2)l}| \right)}. \quad (12)$$

时间序列的 AAPE 可表示为:

$$\text{AAPE}(d, l, n) = - \sum_{\pi_k=1}^{\pi_k=d!} p(\pi_k) \ln p(\pi_k). \quad (13)$$

3.3 改进多尺度幅值感知排列熵

IMAAPE 算法借鉴了改进多尺度熵算法中的粗粒化过程,突出不同时间尺度下的信号特征,再利用 AAPE 对信号幅值和频率变化敏感的特性,提取不同时间尺度下的信号特征。该方法的主要计算步骤如下:

Step1:假设待分析时间序列为 $\{x_1, x_2, \dots,$

$$p(\pi_i) = \frac{f(\pi_i)}{N-d+1}, \quad (9)$$

其中: $f(\pi_i)$ 表示统计排列顺序 π_i 出现次数的函数,每当 $\mathbf{X}_t^{d,l}$ 内部元素排列顺序为 π_i 时, $f(\pi_i)$ 便加 1。排列熵的定义如下:

$$\text{PE}(\mathbf{x}, d, l) = - \sum_{\pi_i=1}^{\pi_i=d!} p(\pi_i) \ln p(\pi_i). \quad (10)$$

然而,通过排列熵描述复杂时间序列还存在两个主要问题。第一,传统 PE 仅考虑了时间序列幅值的排列次序,而忽略了对应的时间序列中元素的幅值信息;第二,时间序列中幅值相等的元素对 PE 值的影响并没有清晰说明。鉴于此,文献[18]提出了幅值感知排列熵 (Amplitude-Aware Permutation Entropy, AAPE),以提升 PE 对时间序列的幅值和频率的敏感特性。不同于排列熵算法,AAPE 算法考虑了信号振幅的均值及振幅之间的偏差,引入了相对规范化概率替代 PE 中 $f(\pi_i)$ 的计数规则。

假设 $p(\pi_i^{d,l})$ 的初始值为 0,对于时间序列 $\mathbf{X}_t^{d,l}$, t 从 1 逐次增加至 $N-d+1$ 的过程中,每当出现排列顺序为 $\pi_i^{d,l}$ 时, $p(\pi_i^{d,l})$ 都要进行更新:

$$p^{\text{update}}(\pi_i^{d,l}) = p(\pi_i^{d,l}) + \left(\frac{A}{d} \sum_{k=1}^d |x_{t+(k-1)l}| + \frac{1-A}{d-1} \sum_{k=2}^d |x_{t+(k-1)l} - x_{t+(k-2)l}| \right), \quad (11)$$

其中: $A \in [0, 1]$ 为调整系数,调节信号振幅均值及振幅之间偏差的权重,一般取 0.5; $p^{\text{update}}(\pi_i^{d,l})$ 表示更新后的 $p(\pi_i^{d,l})$ 值。那么,对于整个时间序列中 $\pi_i^{d,l}$ 出现的概率为:

$x_N\}$,利用改进的粗粒化过程产生一组新的粗粒化时间序列 $\mathbf{z}_i^{(\tau)} = \{y_{i,1}^{(\tau)}, y_{i,2}^{(\tau)}, \dots\}$,其中, $y_{i,j}^{(\tau)} = \frac{\sum_{f=0}^{\tau-1} x_{f+i+\tau(i-1)}}{\tau}$, $\tau = 1, 2, \dots, n$ 。

Step2:对于每一个时间尺度因子 τ 和嵌入维数 d ,分别计算 $\mathbf{z}_i^{(\tau)} (i=1, 2, \dots, \tau)$ 中每个时间序列的 AAPE 值,并将其平均值定义为改进多尺度幅值感知排列熵:

$$\text{IMAAPE}(x, \tau, d) = \frac{1}{\tau} \sum_{i=1}^{\tau} \text{AAPE}(\mathbf{z}_i^{(\tau)}). \quad (14)$$

4 随机森林分类器

RF 由美国科学院院士 Breiman L. 于 2001 年提出,该算法适用于解决预测与分类问题^[19-20]。RF 集成了多个弱分类器,由众多决策树组成,其输出结果根据森林中每棵决策树的预测结果,利用投票原则确定。RF 的实现过程简单,具有较高的识别准确率,在故障诊断领域具有广泛应用^[21-22]。RF 的基本原理如下:

假设随机森林分类器由多个决策树 $\{h_j(\mathbf{x}, \Theta_k)\}$, $k=1, 2, \dots, n\}$ 组成, $\{\Theta_k, k=1, 2, \dots, n\}$ 表示相互独立且同分布的随机向量。随机森林分类器的训练样本集表示为 $\mathbf{D} = \{(\mathbf{x}_1, y_1), (\mathbf{x}_2, y_2), \dots, (\mathbf{x}_N, y_N)\}$, $\mathbf{x}_i = (x_{i,1}, \dots, x_{i,p})^T$ 表示第 i 个训练样本, \mathbf{x}_i 具有 p 个特征值, y_i 表示训练样本 \mathbf{x}_i 对应的标签。对训练样本集 \mathbf{D} 进行 n 次 Bootstrap 采样,获得 n 个 Bootstrap 子样本 $\mathbf{D}_j (j=1, 2, \dots, n)$ 。针对每个子样本 \mathbf{D}_j , 构建决策树模型 $h_j(\mathbf{x})$ (一般选用 CART 决策树), 最终获得由一组决策树 $\{h_1(\mathbf{x}), h_2(\mathbf{x}), \dots, h_k(\mathbf{x})\}$ 组成的决策树分类器。对于一个新的测试样本, 通过 n 个决策树投票, 得到最多票数的类别作为测试样本的最终类别, 分类决策如下:

$$f(\mathbf{x}) = \arg \max_y \sum_{j=1}^n I(h_j(\mathbf{x}) = y), \quad (15)$$

其中: $h_j(\mathbf{x})$ 代表第 j 棵决策树; $I(\cdot)$ 为示性函数, 即当集合内有此数时值为 1, 否则值为 0; y 表示类别标签 y_i 构成的目标变量。

5 滚动轴承故障诊断方法流程

本文提出的故障诊断方法能够实现滚动轴承内环、外环及滚珠故障识别及故障严重程度分析, 该方法的故障识别及故障严重程度分析流程如图 2 所示。

本文提出的滚动轴承故障诊断方法改进了多尺度熵的粗粒化过程, 并利用幅值感知排列熵提取振动信号特征, 提升滚动轴承故障特征的可分性, 再通过随机森林分类器进行故障类型识别及故障严重程度分析。

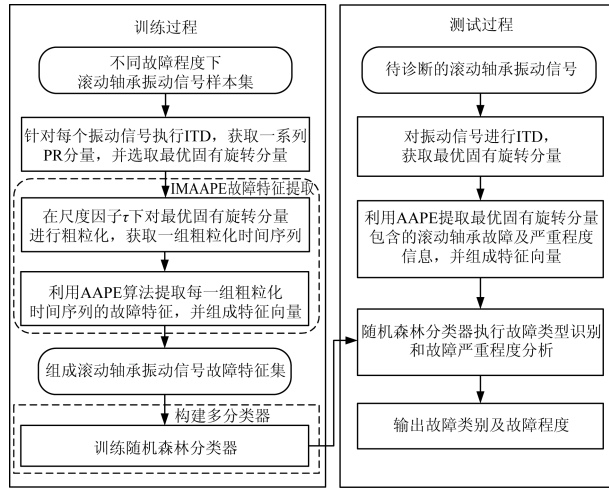


图 2 故障识别及故障严重程度分析流程

Fig. 2 Flow chart of fault identification and severity analysis

该方法通过 IMAAPE 对不同故障类型及故障严重程度(故障直径)的数据样本进行特征提取, 描述故障严重程度特征, 再利用 RF 良好的分类性能对故障类型及严重程度进行判断, 具体流程描述如下:

Step1: 获取不同故障程度下的滚动轴承振动信号, 并组成不同故障程度下的滚动轴承振动信号样本集;

Step2: 针对样本集中的每一个振动信号, 进行 ITD, 获取一系列 PR 分量, 并从中选取最优 PR 分量进行后续特征提取;

Step3: 利用 IMAAPE 提取最优 PR 分量不同时间尺度下包含的滚动轴承振动信号的幅值和频率特征, 组成不同故障程度下的故障特征向量;

Step4: 通过对滚动轴承振动信号样本集进行特征提取, 可以组成滚动轴承振动信号故障特征集, 并利用该特征集构建 RF 多分类器;

Step5: 对待测试的滚动轴承振动信号进行 ITD 分解, 选取最优 PR 分量提取故障特征向量, 将该特征向量输入到 RF 分类器中, 得到滚动轴承故障类型和故障严重程度。

6 实验与分析

6.1 实验数据

本文选用美国凯斯西储大学轴承数据中心^[23]提供的滚动轴承故障数据集对所提出的故

障诊断方法进行实验验证,滚动轴承实验平台如图 3 所示。实验以 SKF 轴承作为研究对象,数据集通过加速度传感器采集正常(NM)、内环故障(IR)、外环故障(OR)及滚珠故障(B)4 种状态下的轴承振动信号。加速度计安装在电机外壳的驱动端和风扇端的 12 点钟方向,采样频率为 12 kHz。对于三种故障类型,分别选取故障直径为 2.13,4.27 和 6.4 mm 三种不同的故障严重程度进行样本采集。2 237.1 W 负载下不同故障严重程度的滚动轴承振动信号的时域波形如图 4 所示,可见其振动信号的幅值和频率的变化与故障类型和故障严重程度的变化紧密相关。表 1 所示为本文中实验样本的轴承负载、故障类型及严重程度组成。实验样本一共包括 3 种不同的滚动轴承故障类型,每种故障类型分为 3 种不同的故障严重程度。将每种轴承数据不重叠地分割成多个

数据样本,每个样本中含有 $N=1\ 024$ 个采样点,组成每种故障严重程度下 50 个样本构成的实验数据集。实验中,采用每种故障严重程度下 10 个样本作为训练集,40 个样本作为测试集。




图 3 凯斯西储大学滚动轴承实验平台

Fig. 3 Rolling bearing experimental platform of Case Western Reserve University

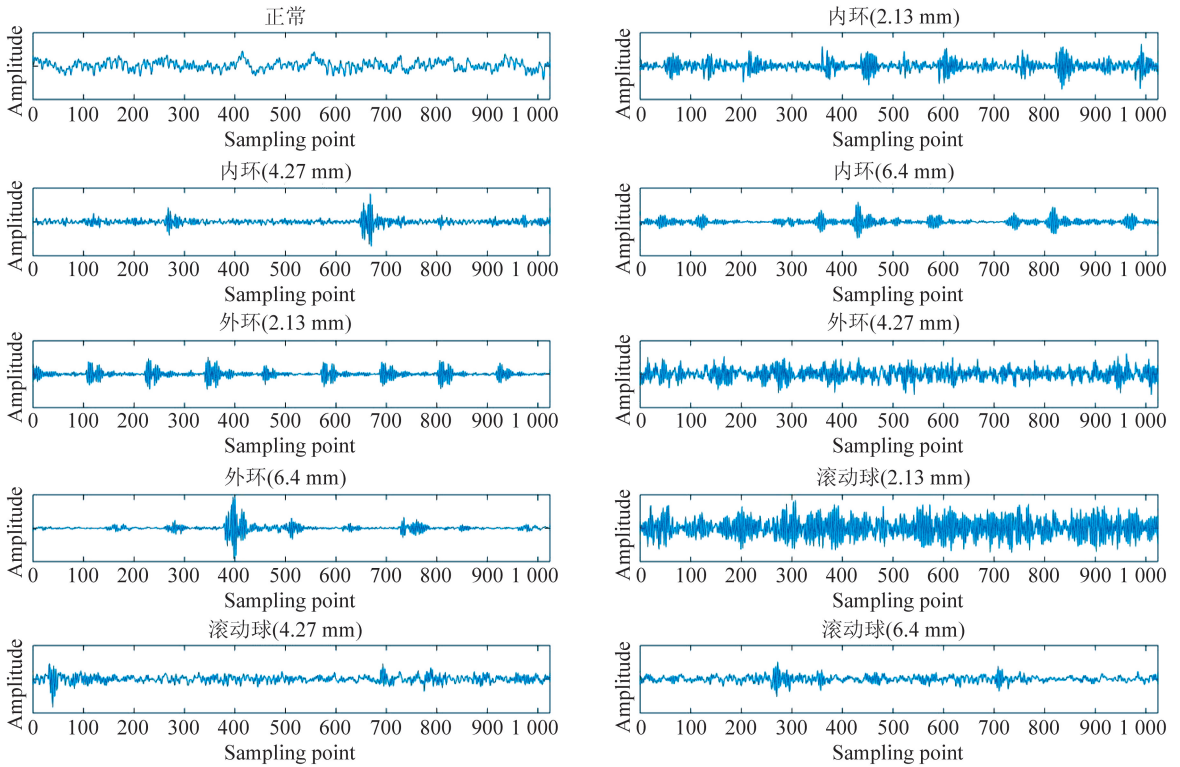


图 4 负载 2 237.1 W 下不同故障严重程度的滚动轴承振动信号

Fig. 4 Vibration signals of rolling bearing with different fault severity under 2 237.1 W

表 1 实验样本的故障类型及严重程度组成

Tab.1 Composition of fault types and severity in experimental samples

故障类型	类别 标签	故障 直径/mm	负载/W			
			0	720	1 440	2 237.1
正常	NM	—	✓	✓	✓	✓
内环故障	IR07	2.13	✓	✓	✓	✓
	IR14	4.27	✓	✓	✓	✓
	IR21	6.4	✓	✓	✓	✓
外环故障	OR07	2.13	✓	✓	✓	✓
	OR14	4.27	✓	✓	✓	✓
	OR21	6.4	✓	✓	✓	✓
滚珠故障	B07	2.13	✓	✓	✓	✓
	B14	4.27	✓	✓	✓	✓
	B21	6.4	✓	✓	✓	✓

6.2 滚动轴承故障特征提取实验

在执行滚动轴承故障特征提取前,需采用 ITD 对振动信号进行预处理,进一步突显信号固有瞬时幅值、频率等形态特征。图 5 所示为故障直径为 2.13 mm 下滚珠故障的振动信号 ITD 分解实验结果。ITD 将故障振动信号分解为 5 个 PR 分量和 1 个单调趋势分量。由分解结果可见,最优 PR 分量包含描述滚珠故障振动信号中的主要幅值和频率特征。

滚动轴承振动信号经 ITD 分解后,采用 IMAAPE 进行特征提取。对最优 PR 分量进行 IMAAPE 特征提取,设置嵌入维数 $d=4$,时间延迟 $l=1$,时间尺度 $\tau=20$,调整系数 $A=0.5$ 。对测试集的振动信号样本进行 IMAAPE 特征提取,得到 20 维的滚动轴承振动信号故障特征向量。图 6 所示为 0 负载下不同故障直径的 IMAAPE 特征聚类图,从特征向量的前 3 个维度可以看出,本文提出的特征提取方法能够较好地描述,特征向量具有较强的聚类性。图 7 所示为 0 负载下不同故障严重程度 IMAAPE 特征聚类

图,选取特征向量中前 2 个维度可以看出,本文提出的特征提取方法对不同故障严重程度的特征提取结果也具有较好的聚类性。




图 5 故障直径 2.13 mm 下滚珠故障的 ITD 分解结果
Fig. 5 ITD decomposition results of ball fault under fault diameter of 2.13 mm

为了说明 IMAAPE 滚动轴承振动信号特征提取方法的性能,本文将 IMAAPE 与现有滚动轴承故障特征提取方法的效果进行对比。实验采用 0 负载下内环故障、外环故障和滚珠故障各 40 个样本进行分析,实验结果如表 2 所示。不同故障类型情况下,特征向量的类间距离平均值越大,表示特征提取方法提取的不同故障类型的特征差异性越大;不同故障类型情况下特征向量的类内距离平均值越小,表示特征提取方法提取的相同故障类型的特征差异性越小。由表 2 可见,IMAAPE 的平均类间距离大于改进多尺度排列熵^[11] (IMPE) 和精细复合多尺度排列熵^[25] (RCMPE),但小于改进多尺度样本熵^[26] (IMSE)、改进多尺度模糊熵^[11] (IMFE) 和精细复合多尺度样本熵^[25] (RCMSE),而 IMAAPE 的平均类内距离在所有特征提取方法中最小。该实验结果说明 IMAAPE 提取的滚动轴承故障特征具有较好的聚类性质。此外,由表 2 可知,在计算相同的采样点数的样本时,IMAAPE 的平均耗时为所有特征提取方法中最小的,具有较好的实时性。表 3 为故障程度识别准确率的比较。




图 6 负载 0 下不同故障直径的 IMAAPE 特征聚类图

Fig. 6 IMAAPE feature clustering diagram of different fault diameters under zero load

表 2 滚动轴承故障特征提取算法的性能比较

Tab. 2 Performance comparison of rolling bearing fault feature extraction algorithms

特征提取方法	平均类间距离	平均类内距离	平均耗时/s
IMAAPE	1.24	0.20	0.39
IMPE	0.95	0.23	0.57
RCMPE	0.96	0.30	1.11
IMSE	2.22	0.94	0.42
IMFE	3.72	0.33	17.30
RCMSE	4.02	0.38	0.40

述的特征提取方法与 RF 分类器相结合,设置 CART 决策树数量为 50,对滚动轴承 10 种不同健康状态下的每种类别 40 个测试样本进行分析,实验结果如表 4 所示。由实验结果可知,与当前不同滚动轴承故障特征提取方法相比较,本文提出的 IMAAPE 故障特征提取方法具有更好的故障严重程度描述能力,提取的特征向量具有更高的可分性。

表 3 滚动轴承故障特征提取算法准确率比较

Tab. 3 Accuracy comparison of rolling bearing fault feature extraction algorithms

特征提取方法	故障程度识别准确率/%
IMAAPE	99.25
IMPE	96.00
RCMPE	97.50
IMSE	84.25
IMFE	96.25
RCMSE	92.25




图 7 0 负载下不同故障严重程度的 IMAAPE 特征聚类图

Fig. 7 Clustering diagram of IMAAPE features with different fault severity under zero load

6.3 滚动轴承故障类型识别实验

为了验证 IMAAPE 与 RF 相结合的轴承故障诊断方法的性能,对滚动轴承 10 种不同健康状态下的每种类别 40 个测试样本进行实验验证,结果如表 5 所示。可见,提出的滚动轴承故障诊断方法能够有效地识别正常、内环故障、外环故障、滚珠故障,并且能够较为有效地分析故障严重程度,误报率较低,平均识别准确率高达 99.25%。

为了进一步说明本文提出的 IMAAPE 故障特征提取方法的可分性,本文分别利用表 2 中描

表4 不同滚动轴承故障诊断方法识别率比较

Tab. 4 Comparison of identification rates of different fault diagnosis methods for rolling bearings

对比方法	故障类型	是否考虑故障 严重程度	故障类别数	平均识别率/%	
				对比方法	本文方法
文献[2]	正常、内环、外环	是	5	97.81	100
文献[7]	正常、内环、外环、滚珠	否	4	100	100
文献[8]	正常、内环、外环、滚珠	否	4	100	100
文献[24]	正常、内环、外环、滚珠	是	7	100	100
文献[26]	正常、内环、外环、滚珠	否	4	97.78	100
文献[27]	正常、内环、外环、滚珠	是	10	99.10	99.25

表5 滚动轴承故障诊断方法的识别率

Tab. 5 Identification rates of proposed rolling bearing fault diagnosis methods

类别标签	NM	IR07	IR14	IR21	OR07	OR14	OR21	B07	B14	B21	识别率/%
NM	40	—	—	—	—	—	—	—	—	—	100
IR07	—	40	—	—	—	—	—	—	—	—	100
IR14	—	—	39	—	—	—	—	—	—	—	97.5
IR21	—	—	—	40	—	—	—	—	—	—	100
OR07	—	—	—	—	40	—	—	—	—	—	100
OR14	—	1	—	—	—	39	—	—	—	—	97.5
OR21	—	1	—	—	—	—	39	—	—	—	97.5
B07	—	—	—	—	—	—	—	40	—	—	100
B14	—	—	—	—	—	—	—	—	40	—	100
B21	—	—	—	—	—	—	—	—	—	40	100

为了进一步说明本文提出方法在滚动轴承故障诊断中的性能,将本文提出的滚动轴承故障诊断方法与现有方法进行比较,实验结果如表5所示。可见,本文提出的方法能够实现滚动轴承故障类型识别,并能够进一步分析轴承故障的严重程度。在不考虑故障严重程度的情况下,能够准确识别故障类型,故障识别准确率达到100%;在考虑故障严重程度的情况下,提出的故障诊断方法具有故障严重程度分析能力,且具有相对较高的平均故障识别率,达到99.25%。

7 结论

ITD能够稳定地将滚动轴承故障信号分解为一组PR分量,其中最优PR分量能够突显滚

动轴承故障信号的冲击特征,适用于滚动轴承振动信号的时-频分析。IMAAPE改善了多尺度分析中的粗粒化过程,并利用幅值感知排列熵对信号幅值和频率变化敏感的特性,计算不同时间尺度下的AAPE值并组成特征向量,具有较强的故障描述能力且实时性较好。基于IMAAPE与RF的滚动轴承故障诊断方法能够在准确识别故障类型的基础上,进一步对故障严重程度进行分析,在考虑故障严重程度的情况下,平均故障识别准确率达到99.25%。

本文方法目前仅适用于滚动轴承固定负载下的故障类型识别及故障严重程度分析。为了进一步提升该滚动轴承故障诊断方法的泛化能力,后续的研究重点为变负载情况下滚动轴承的故障类型与故障严重程度分析。

参考文献:

- [1] LI Y B, WANG X Z, LIU Z B, *et al.*. The entropy algorithm and its variants in the fault diagnosis of rotating machinery: a review [J]. *IEEE Access*, 2018, 6: 66723-66741.
- [2] YANG Y T, ZHENG H L, LI Y B, *et al.*. A fault diagnosis scheme for rotating machinery using hierarchical symbolic analysis and convolutional neural network [J]. *ISA Transactions*, 2019, 91: 235-252.
- [3] WANG X Z, SI S B, WEI Y, *et al.*. The optimized multi-scale permutation entropy and its application in compound fault diagnosis of rotating machinery [J]. *Entropy*, 2019, 21(2): 170.
- [4] HAN M H, PAN J L. A fault diagnosis method combined with LMD, sample entropy and energy ratio for roller bearings [J]. *Measurement*, 2015, 76: 7-19.
- [5] 徐彦伟, 刘明明, 刘洋, 等. 基于信息融合的机器人薄壁轴承故障智能诊断 [J]. *光学精密工程*, 2019, 27(7): 1577-1592.
XU Y W, LIU M M, LIU Y, *et al.*. Intelligent fault diagnosis of thin wall bearing based on information fusion [J]. *Opt. Precision Eng.*, 2019, 27(7): 1577-1592.
- [6] 胡鹏浩, 胡毅, 党学明. 精密角接触球轴承综合参数测量仪 [J]. *光学精密工程*, 2014, 22(11): 3038-3043.
HU P H, HU Y, DANG X M. Multi-parameter measuring instrument for precise angular contact rolling bearing [J]. *Opt. Precision Eng.*, 2014, 22(11): 3038-3043. (in Chinese)
- [7] 康守强, 王玉静, 姜义成, 等. 基于超球球心间距多类支持向量机的滚动轴承故障分类 [J]. *中国电机工程学报*, 2014, 34(14): 2319-2325.
KANG SH Q, WANG Y J, JIANG Y CH, *et al.*. Fault classification of rolling bearing based on hypersphere spherical center distance multiclass support vector machine [J]. *Proceedings of the CSEE*, 2014, 34(14): 2319-2325. (in Chinese)
- [8] 李永波. 滚动轴承故障特征提取与早期诊断方法研究[D]. 哈尔滨: 哈尔滨工业大学, 2017.
LI Y B. *Investigation of Fault Feature Extraction and Early Fault Diagnosis for Rolling Bearings* [D]. Harbin: Harbin Institute of Technology, 2017. (in Chinese)
- [9] 刘长良, 武英杰, 甄成刚. 基于变分模态分解和模糊 C 均值聚类的滚动轴承故障诊断 [J]. *中国电机工程学报*, 2015, 35(13): 3358-3365.
LIU C L, WU Y J, ZHEN C G. Rolling bearing fault diagnosis based on variational mode decomposition and fuzzy C means clustering [J]. *Proceedings of the CSEE*, 2015, 35(13): 3358-3365. (in Chinese)
- [10] LIU H H, HAN M H. A fault diagnosis method based on local mean decomposition and multi-scale entropy for roller bearings [J]. *Mechanism and Machine Theory*, 2014, 75: 67-78.
- [11] ZHENG J D, CHENG J S, YANG Y. Multiscale permutation entropy based rolling bearing fault diagnosis [J]. *Shock and Vibration*, 2014: 154291.
- [12] FREI M G, OSORIO I. Intrinsic time-scale decomposition: time-frequency-energy analysis and real-time filtering of non-stationary signals [J]. *Proceedings of the Royal Society A: Mathematical, Physical and Engineering Sciences*, 2007, 463(2078): 321-342.
- [13] LI C, LIANG M. Continuous-scale mathematical morphology-based optimal scale band demodulation of impulsive feature for bearing defect diagnosis [J]. *Journal of Sound and Vibration*, 2012, 331(26): 5864-5879.
- [14] LI Y B, XU M Q, WANG R X, *et al.*. A fault diagnosis scheme for rolling bearing based on local mean decomposition and improved multiscale fuzzy entropy [J]. *Journal of Sound and Vibration*, 2016, 360: 277-299.
- [15] COSTA M, GOLDBERGER A L, PENG C K. Multiscale Entropy Analysis of Complex Physiologic Time Series [J]. *Physical Review Letters*, 2002, 89(6): 068102.
- [16] AZAMI H, ESCUDERO J. Improved multiscale permutation entropy for biomedical signal analysis: Interpretation and application to electroencephalogram recordings [J]. *Biomedical Signal Processing and Control*, 2016, 23(1): 28-41.
- [17] BANDT C, POMPE B. Permutation entropy: a natural complexity measure for time series [J]. *Physical Review Letters*, 2002, 88(17): 174102.
- [18] AZAMI H, ESCUDERO J. Amplitude-aware permutation entropy: Illustration in spike detection and signal segmentation [J]. *Computer Methods and Programs in Biomedicine*, 2016, 128: 40-51.
- [19] BREIMAN L. Random Forests [J]. *Machine Learning*, 2001, 45(1): 5-32.
- [20] CUTLER A, CUTLER D R, STEVENS J R.

- Random Forests [J]. *Machine Learning*, 2004, 45(1): 157-176.
- [21] VAKHARIA V, GUPTA V K, KANKAR P K. Efficient fault diagnosis of ball bearing using ReliefF and Random Forest classifier [J]. *Journal of the Brazilian Society of Mechanical Sciences and Engineering*, 2017, 38(8): 2969-2982.
- [22] PATEL R K, GIRI V K. Feature selection and classification of mechanical fault of an induction motor using random forest classifier [J]. *Perspectives on Science*, 2016, 8: 334-337.
- [23] *Bearing Data Center* [EB/OL]. Cleveland, Tex: Case Western Reserve University, 2000-01-31 [2019-02-21]. <http://csegroups.case.edu/bearingdatacenter/home>.
- [24] JINDE Z, DEYU T, HAIYANG P, *et al.*. A refined composite multivariate multiscale fuzzy entropy and laplacian score-based fault diagnosis method for rolling bearings [J]. *Entropy*, 2017, 19(11): 585.
- [25] HUMEAUHEURTIERR A, WU C, WU S. Refined composite multiscale permutation entropy to overcome multiscale permutation entropy length dependence [J]. *IEEE Signal Processing Letters*, 2015, 22(12): 2364-2367.
- [26] JU B, ZHANG H J, LIU Y B, *et al.*. A feature extraction method using improved multi-scale entropy for rolling bearing fault diagnosis [J]. *Entropy*, 2018, 20(4): 212.
- [27] YAN X, JIA M. Intelligent fault diagnosis of rotating machinery using improved multiscale dispersion entropy and mRMR feature selection [J]. *Knowledge-Based Systems*, 2019, 163: 450-471.

作者简介:



吴海滨(1977—),男,上海人,博士,教授,2002年于哈尔滨工业大学获得硕士学位,2008年于哈尔滨理工大学获得博士学位,主要从事机器视觉、医学虚拟现实、故障诊断的研究。E-mail: woo@hrbust.edu.cn

通讯作者:



陈寅生(1986—),男,黑龙江哈尔滨人,博士,讲师,2011年、2017年于哈尔滨工业大学分别获得硕士、博士学位,主要从事自确认传感器技术、滚动轴承故障诊断等的研究。E-mail: ChenYS@hrbust.edu.cn