

基于改进主元分析 DDPCA 的滚动轴承过渡模态早期故障检测方法

石怀涛^{1,2}, 乔思康¹, 龙彦泽², 蔡圣福¹, 郭瑾¹

(1. 沈阳建筑大学机械工程学院, 辽宁 沈阳 110168; 2. 沈阳建筑大学高档石材数控加工装备与技术国家地方联合工程实验室, 辽宁 沈阳 110168)

摘要 目的 提出一种深度差分主元分析方法用于滚动轴承早期故障检测, 解决滚动轴承在运行过程中长期处于变转速等多模态工况, 故障特征难以提取和划分的问题。方法 结合差分算法和深度分解原理的分段 PCA 故障检测方法, 使用差分方法对原始数据进行处理, 通过 K-means 聚类方法将具有相似变量特征的过渡模态数据划分成为相同过渡子模态; 结合深度分解理论对每个过渡子模态建立故障检测模型, 并通过机械故障综合模拟实验台收集的数据验证模型准确性。结果 随着分解阶数的增加, 对过渡模态早期故障检测效果逐渐提升, 对滚动轴承过渡子模态的划分越来越清晰, 误报的情况也随着分解阶数的增加而逐渐减少; 滚动轴承持续减速状态下外圈故障一阶分解检测的漏检率为 17.2%, 二阶分解检测的漏检率为 8.6%, 三阶分解检测的漏检率为 6.6%。结论 笔者所提方法对过渡子模态进行多层分解, 可以准确提取过渡子模态中的故障特征并建立分段检测模型, 提高了过渡模态的滚动轴承早期故障检测的准确性。

关键词 多模态过程; 滚动轴承; 早期故障检测; 深度主元分析; 差分算法

中图分类号 TH165+.3

文献标志码 A

引用格式: 石怀涛, 乔思康, 龙彦泽, 等. 基于改进主元分析 DDPCA 的滚动轴承过渡模态早期故障检测方法[J]. 沈阳建筑大学学报(自然科学版), 2024, 40(2): 352-360. (SHI Huaitao, QIAO Sikang, LONG Yanze, et al. Incipient fault detection method of rolling bearing based on DDPCA[J]. Journal of Shenyang jianzhu university (natural science), 2024, 40(2): 352-360.)

Incipient Fault Detection Method of Rolling Bearing Based on DDPCA

SHI Huaitao^{1,2}, QIAO Sikang¹, LONG Yanze², CAI Shengfu¹, GUO Jin¹

(1. School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang, China, 110168; 2. National and Local Joint Engineering Laboratory of High-grade Stone Numerical Control Processing Equipment and Technology,

收稿日期: 2022-05-03

基金项目: 国家自然科学基金项目(5207052414, 51705341); 国家自然科学基金青年科学基金项目(5190051321)

作者简介: 石怀涛(1982—), 男, 教授, 博士, 主要从事电主轴故障诊断方法等方面研究。

Shenyang Jianzhu University, Shenyang, China, 110168)

Abstract: This paper proposed a deep difference principal component analysis (DDPCA) method for early fault detection of rolling bearings in extracting and dividing fault features of multimodal conditions. The parameters were adjusted according to the demand, which lead to the rolling bearing being in variable speed and multi-modal working conditions. In view of the dynamic process characteristics of rolling bearings in transition mode, the fault characteristics were difficult to extract and classify, the failure detection of rolling bearings in incipient stage cannot be carried out using the uniform detection model. This method uses differential method to process original data, classifies the transition mode data with similar variable characteristics into the same transition submodes by *K*-means clustering method, establishes fault detection model for each transition submode in combination with depth decomposition theory. The layer rate of the outer ring fault detection was 17.2%, 8.6% and 6.6%. The multi-layer decomposition of the transition submodes extracts the fault characteristics of the transition submodes accurately, the model is established to improve accuracy of the incipient failure detection of the rolling bearing in the transition mode.

Key words: multi-mode process; rolling bearing; incipient fault detection; deep PCA; difference algorithm

旋转机械作为工业生产中使用率最高的机械设备,在现代工业生产中应用广泛。旋转机械在运行过程中出现故障,可能会导致设备损坏或停运,进而耽误生产计划和进度。随着工业生产机械化和智能化程度逐步加深,连续化生产的情况日益增多,滚动轴承作为旋转机械中重要的传动零件,在实际生产中需要调整转速、负载等参数实现对不同产品的加工,导致滚动轴承时常处于变转速等多模态工况^[1]。当滚动轴承处于不同模态时,振动信号的特征变量会出现明显不同。在使用时间增加和长期处于多模态工况的共同作用下,滚动轴承早期故障会逐渐演化为严重故障。滚动轴承多模态的运行状态可以分为稳定模态和过渡模态。稳定模态作为滚动轴承主要的生产状态,决定了产品质量。而过渡模态不是主要的运行过程,但是从一个稳定模态到另一个稳定模态之间一定存在着过渡模态,这是一种普遍现象。过渡模态存在着不稳定性,容易受到外界因素的干扰,导致早期故障的出现或者使早期故障演变为严重故障,最终影响生产安全和产品质量,因此对过渡模态进行早期故障检测具有重要的研究意义。

近年来,越来越多的学者对于滚动轴承故障检测进行深入研究,提出了多种基于数据驱动的滚动轴承故障检测方法。文献[2-6]分别采用多种典型数据驱动方法对滚动轴承进行故障检测,均取得了良好效果。基于主元分析的故障检测方法,只需要正常运行状态的历史数据就可以完成故障检测模型的建立,适合对过渡模态滚动轴承进行早期故障检测。为了更准确和有效地对过渡模态进行建模和监控,需要考虑到过渡模态动态的数据特征。LU Ningyun 等^[7]利用与过渡模式相邻的两个子时段模型进行加权,来近似描述过渡模态的特性。Wang Yi 等^[8]提出了一种具有自学习能力的稀疏主成分分析算法,该算法考虑到当前 PCA 模型不能自我学习进行改进,引入突触智能来度量变量和正则化项来处理新数据,实现了监测模型随着当前模型和新数据实时更新,进而实现了对制粉系统运行状态过程检测。王文标等^[9]提出了一种交叉分段 PCA 故障诊断方法,该方法考虑到系统负荷变化时的多模态特性,选择单一参数值作为模态识别值,通过交叉重叠的分段方法建立多个模型进行监测,提高了多模态故障诊断的准确度。谭帅

等^[10]考虑到过渡模态变量相关关系的变化不能使用一个统一的 PCA 模型进行故障检测,提出将差分方法和 PCA 方法相结合,首先对过渡模态数据进行差分处理得到过渡模态数据的变量相对变化信息,然后利用 PCA 方法分段对差分变量的相关特性进行提取并进行故障检测,但是该方法没有考虑到滚动轴承过渡模态故障检测中早期故障信息微弱这一特点,容易造成漏报或误报。

当滚动轴承在运行过程中处于过渡模态时,转速等参数也是连续变化的,不能使用单一的模型进行故障检测,而且滚动轴承早期故障信号微弱,使用传统方法难以准确提取滚动轴承早期故障特征。针对以上问题,笔者提出一种结合差分算法和深度分解原理的分段 PCA 故障检测方法,先对滚动轴承信号采用差分矩阵的方法进行处理,然后通过处理后的数据进行细致的分解,再建立滚动轴承过渡模态早期故障检测模型,并通过实验数据对该模型进行验证;研究表明:该方法提高了过渡模态滚动轴承早期故障检测的准确性。

1 深度差分 PCA 建模方法

1.1 主元分析方法

主元分析方法(Principal Component Analysis, PCA)是一种被广泛应用的多元统计分析方法^[11]。随着科技的进步,工业生产流程朝着大数据化、复杂化的方向稳步发展,由于建模复杂性的缘故,导致滚动轴承的故障检测效率与准确率受到影响。就反映数据的信息而言,经常会出现若干变量,而此类变量就是导致故障检测受影响的主要因素。因为系统的复杂程度不断提高,变量间的信息重合、交叠现象加剧,愈发不易于故障检测。主元分析方法能够处理该问题,该方法会对原本数据中的特征信息予以保留,在降维的同时,降低计算难度和复杂性,因此在实际滚动轴承故障检测中得到广泛应

用^[12-18]。

采集正常工况下的数据 $X = (x_1 \ x_2 \ \cdots \ x_n) \in \mathbf{R}^{m \times n}$, $x_i \in \mathbf{R}^m$ 由 n 个传感器完成 m 次独立采样后获取。把得分矩阵 T 返回至观测矩阵的投影,即主元空间 $\tilde{X} \in \mathbf{R}^{m \times n}$ 。

$$\tilde{X} = TP^T. \quad (1)$$

记残差空间为 $E \in \mathbf{R}^{m \times n}$, 其原始矩阵 \bar{X} 根据主元分析划分为主元空间与残差空间,其公式如下:

$$\bar{X} = \tilde{X} + E = TP^T + E = XPP^T + E. \quad (2)$$

PCA 方法的故障检测考虑的包括比较 Hotelling- T^2 统计量及控制限、平方预测误差 SPE 统计量及控制限^[14]。通过计算得到主元空间,然后计算其统计量与控制限并进行比较,从而判断出采集数据时出现的故障。 T^2 统计量是对模型内部变化的一种度量,可以用来对多个主元同时进行检测;SPE 统计量是对模型外部变化的一种度量。

T^2 统计量反映了每个主成分在变化趋势和幅值上偏离模型的程度,能够评估检测样本 $x(t)$ 距离主元空间原点的距离,等同于样本的一个平均值期望。其表达式为

$$T^2 = X^T P A^{-1} P^T X. \quad (3)$$

T^2 统计量近似服从 T^2 分布,其控制限 TUCL 的计算式如下:

$$TUCL = \frac{a(n^2 - 1)}{n(n - a)} F_{\alpha(a, n - a)}. \quad (4)$$

SPE 统计量作为数据的方差,反映输入数据对主元模型的偏离程度,可以由残差空间计算得到,其表达如下:

$$SPE = \| (I - PP^T) X \|^2. \quad (5)$$

SPE 的控制限 QUCL 由概率密度函数得到,其计算式如下:

$$QUCL = \theta_1 \left[\frac{h_0 C_\alpha \sqrt{2\theta_2}}{\theta_1} + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1} + 1 \right]^{\frac{1}{h_0}}. \quad (6)$$

$$\theta_j = \sum_{i=j+1}^T \lambda_i^j, \quad j = 1, 2, 3. \quad (7)$$

$$h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2}. \quad (8)$$

式中: C_α 为正态分布的 α 分位点。

1.2 深度分解原理

PCA 作为一种基本的故障检测方法,只需要正常状态下的数据来建立模型,但是 PCA 也因其其在提取主元的过程中会舍弃少量故障特征,导致 PCA 并不具备准确地检测出微弱的早期故障信息的能力,这也就导致 PCA 在早期故障检测的使用不具有普遍性。而基于深度分解理论的深度主元分析方法 (Deep Principal Component Analysis, Deep PCA) 刚好能够一定程度上弥补 PCA 在早期故障检测方面的不足。该方法对 PCA 故障检测方法进行优化。Deep PCA 方法就是基于经典的 PCA 方法,将主元空间和残差空间再进行分解,经过多次分解,原始数据可以保留更多的故障信息,这样就可以达到更加准确地检测出滚动轴承早期故障的目的,Deep PCA 方法分解过程如图 1 所示。




图 1 Deep PCA 方法分解过程

Fig. 1 The decomposition process of Deep PCA
具体步骤如下:

通过 PCA 方法获得训练集 X 的主元空间和残差空间。

$$X = X_{11} + X_{12}.$$
 (9)

X_{11} 是原始数据经过 PCA 方法分解得到的 X 的一阶主元空间, X_{12} 是原始数据 X 经过 PCA 方法分解得到的一阶残差空间。

X_{11} 和 X_{12} 可表示为

$$X_{11} = P_{11} P_{11}^T X.$$
 (10)

$$X_{12} = (I - P_{11} P_{11}^T) X.$$
 (11)

按照这个规律,可以得到原始数据 X 可以用 2^j 个子空间的和来表示,其中 j 表示分

解阶数,那么分解到 j 阶,得到子空间 $X_{j,k}$ 为

$$X_{j,k} = \begin{cases} P_{j,k} P_{j,k}^T X_{j-1,(k+1)/2}, & k \text{ 为奇数;} \\ (I - P_{j,k} P_{j,k}^T) X_{j-1,\frac{k}{2}}, & k \text{ 为偶数.} \end{cases}$$
 (12)

每个子数据集 $X_{j,k}$ 的 $T^2_{j,k}$ 统计量可以表示为

$$T^2_{j,k} = X^T P_{j+1,2k-1} \Lambda_{j,k}^{-1} P_{j+1,2k-1}^T X.$$
 (13)

式中: $\Lambda_{j,k}$ 为每个子数据集 $X_{j,k}$ 的主成分空间的特征值矩阵。

可以通过预设的显著性水平 α 结合 T^2 的概率密度函数计算得到 $T^2_{j,k}$ 的控制限 $TUCL$ 。

$$\int_0^{TUCL_{j,k}} f(T^2_{j,k}) dT^2_{j,k} = \alpha.$$
 (14)

SPE 统计量反映数据的偏离程度,可表示为

$$SPE_{j,k} = \| (I - P_{j+1,2k-1} P_{j+1,2k-1}^T) X \|^2.$$
 (15)

$SPE_{j,k}$ 控制限计算方法可以参照 $TUCL_{j,k}$, 控制限 $QUCL_{j,k}$, 即:

$$\int_0^{QUCL_{j,k}} f(SPE_{j,k}) dSPE_{j,k} = \alpha.$$
 (16)

1.3 差分算法

稳定模态作为运行过程中较为稳定的模态,其数据的变量相关性在一定时间内呈现出高度相似的状态。过渡模态作为存在于稳定模态转换之间的模态,其数据的特性是随着转变过程变化而实时改变的,不能够直接通过主元分析提取其特征。过渡模态在过程中的动态特性会呈现出一定的相对稳定的规律,当忽略随机干扰的情况下,相同的过渡模态会具有相同的规律,这种规律可以通过 PCA 方法建立模型,再对相同过渡模态的进行在线监测,从而判定对当前过渡模态运转状态进行故障检测。笔者提出一种针对过渡模态滚动轴承早期故障检测的深度差分主元分析 (Deep Difference Principal Component Analysis, DDPKA) 方法。

不同的稳定模态具有这不同的特征,过

渡模态存在于两个稳定模态之间,但从稳定模态 X 向稳定模态 Y 转变和从稳定模态 Y 向稳定模态 X 转变中所经历的过渡模态是两种完全不同的模态,需要分别对两种过渡模态建模,图2所示为稳定模态 X 向稳定模态 Y 的过渡子模态情况。




图2 稳定模态 X 向稳定模态 Y 转变的过渡子模态

Fig. 2 The transition submodes from X to Y

在忽略一定随机干扰的前提下,从固定的初始稳定模态到固定的结束稳定模态中间经历的过渡模态,其数据动态特性具有相似性,当使用电机、轴承和检测器的参数设定相同时,可以设定滚动轴承从静止开始加速到相同的速度,通过检测器收集 I 次滚动轴承振动数据和振动数据,那么就可以认为收集到的 I 组数据都具有相同的动态特性。收集到过渡模态数据矩阵为 $X(I \times J \times K)$,其中 I 表示过程收集次数, J 表示收集变量数, K 表示收集的采样数。

将收集到的过渡模态数据矩阵 $X(I \times J \times K)$ 以平行于数据收集次数 I 和变量个数 J 方向进行展开,可以得到 K 个二维矩阵,每个矩阵表示为 $X_k(I \times J)$ 。

将矩阵 X_k 沿着 K 方向以步长为 h 做差分,可表示为

$$X_k^* = X_k - X_{k-h}. \tag{17}$$

对每个矩阵 X_k 计算得到差分矩阵 $X^*(I \times J \times (K-h))$,如图3所示。

差分矩阵 $X^*(I \times J \times (K-h))$ 沿平行于 I 和 J 平面方向进行展开,可以得到 $(K-h)$ 个二维差分子矩阵 $X_k^*(I \times J)$,表示 $(K-h)$ 个变量之间变量的变化趋势。变化趋势相似




图3 差分过程示意图

Fig. 3 The schematic diagram of difference process
的差分子矩阵 $X_k^*(I \times J)$,可以使用 K -means 聚类算法将变化趋势相似的差分子矩阵归为一类,这样可以使同一种数据拥有更多建模数据,模型也就更加具有准确性。

聚类需要用到 PCA 方法的计算各差分子矩阵 X_k^* 的主成分向量 P_k^* ,如式(18)所示:

$$X_k^* = T_k^* P_k^*. \tag{18}$$

聚类得到 A 种过渡子模态,第 a 类过渡子模态的过渡模态差分矩阵可以表示为 $X_{(a)}^*(I \times J \times n_a)$, n_a 表示将其沿着变量个数 J 方向展开,得到二维矩阵 $\tilde{X}_{(a)}^*(n_a I \times J)$,将过渡批次在时间方向上进行融合,每一列数据代表在第 a 个过渡子模态下每个批次在每个时刻上变量的变动情况。图4为 $X_{(a)}^*(I \times J \times n_a)$ 展开为 $\tilde{X}_{(a)}^*(n_a I \times J)$ 的示意图。

可以计算出第 a 个过渡子模态对应的 $T_{(a)11}^2$ 统计量和 $TUCL_{(a)11}$ 控制限:

$$T_{(a)11}^2 = \tilde{X}_{(a)}^{*T} P_{(a)21} A_{(a)11}^{-1} P_{(a)21}^T \tilde{X}_{(a)}^*. \tag{19}$$

$$\int_0^{TUCL_{(a)11}} f(T_{(a)11}^2) dT_{(a)11}^2 = \alpha. \tag{20}$$

其中, $A_{(a)11}$ 为第 a 个过渡子模态 $\tilde{X}_{(a)}^*$ 的特征矩阵。




图4 过渡子模态展开示意图

Fig. 4 The expansion schematic diagram of transition submode

同时,计算出第 a 个过渡子模态对应的 $SPE_{(a)11}$ 统计量和 $QUCL_{(a)11}$ 控制限:

$$SPE_{(a)11} = \| (I - P_{(a)21} P_{(a)21}^T) \tilde{X}_{(a)}^* \|^2. \quad (21)$$

$$\int_0^{QUCL_{(a)11}} f(SPE_{(a)11}) dSPE_{(a)11} = \alpha. \quad (22)$$

当推广到第 j 阶,假设第 j 阶共有 m 个过渡子模态,那么此时第 m 个过渡子模态 $\tilde{X}_{(m)j,k}^*$ 表示为

$$\tilde{X}_{(m)j,k}^* = \begin{cases} P_{(m)j,k} P_{(m)j,k}^T \tilde{X}_{(m)j-1,(k+1)/2}^*, & k \text{ 为奇数;} \\ (I - P_{(m)j,k} P_{(m)j,k}^T) \tilde{X}_{(m)j-1,k/2}^*, & k \text{ 为偶数.} \end{cases} \quad (23)$$

j 阶第 m 个过渡子模态 $\tilde{X}_{(m)j,k}^*$ 的 T^2 统计量可以表示为

$$T_{(m)j,k}^2 = \tilde{X}_{(m)j,k}^{*T} P_{j+1,2k-1} A_{(m)j,k}^{-1} P_{j+1,2k-1}^T \tilde{X}_{(m)j,k}^*. \quad (24)$$

式中: $A_{(m)j,k}$ 为每个子数据集 $\tilde{X}_{(m)j,k}^*$ 的主成分空间的特征值矩阵。

对于 $T_{(m)j,k}^2$ 的控制限 $TUCL_{(m)j,k}$,可以通过预设的显著性水平 α 和 $T_{j,k}^2$ 的概率密度函数计算得到,控制限 $TUCL_{(m)j,k}$ 可表示为

$$\int_0^{TUCL_{(m)j,k}} f(T_{(m)j,k}^2) dT_{(m)j,k}^2 = \alpha. \quad (25)$$

j 阶第 m 个过渡子模态 $\tilde{X}_{(m)j,k}^*$ 的 SPE 统计量可表示为

$$SPE_{(m)j,k} = \| (I - P_{(m)j+1,2k-1} P_{(m)j+1,2k-1}^T) \tilde{X}_{(m)j,k}^* \|^2. \quad (26)$$

与 $T_{(m)j,k}^2$ 的控制限的计算方法相似, $SPE_{(m)j,k}$ 的控制限 $QUCL_{(m)j,k}$ 可表示为

$$\int_0^{QUCL_{(m)j,k}} f(SPE_{(m)j,k}) dSPE_{(m)j,k} = \alpha. \quad (27)$$

计算 j 阶 M 种过渡子模态的 T^2 统计量和 SPE 统计量,可以得到 $T_{(M)j,k}^2$ 和 $SPE_{(M)j,k}$ 过渡模态的分段函数。

2 滚动轴承运行故障检测

基于 DDPCA 过渡模态滚动轴承早期故障检测方法验证过程,需要使用健康滚动轴承振动数据进行离线建模,再用带有故障的滚动轴承振动数据进行测试模型的准确性。数据集是笔者使用机械故障综合模拟实验台采集,数据采集过程中通过加速度传感器对三种健康状况不同的滚动轴承采集到的振动信号,通过转速传感器记录实验过程中转速的变化情况。该数据集使用的滚动轴承包含两种状态:①健康滚动轴承;②外圈存在故障的滚动轴承。运行转速设定:①增大转速;②减小转速。具体过渡模态滚动轴承振动数据收集实验的实验设定如表 1 所示。

表1 过渡模态滚动轴承故障数据实验设计

Table 1 Experimental design of fault data for rolling bearing in transition mode

轴承状态	速度设定 1	速度设定 2
健康	加速	减速
外圈故障	加速	减速

该实验使用的故障滚动轴承均为轻微故障,因此实验数据适用于滚动轴承早期故障检测,能更准确地反映滚动轴承运行过程中过渡模态的早期故障,所以选用该数据集来对笔者所提方法进行验证。

图 5 是基于 DDPCA 方法对持续减速状态滚动轴承外圈故障一阶分解检测结果,分别描述的是 T_{01}^2 统计量和 SPE_{01} 统计量的仿真结果。从图中可以得出, T_{01}^2 的检测结果和对过渡子模态的划分效果不明显; SPE_{01} 的漏检率较低,但是对过渡子模态的划分效果不明显。




图5 减速状态滚动轴承外圈故障的一阶分解检测结果

Fig. 5 The first layer results of DDPCA for outer ring fault at deceleration state

图6是基于DDPCA方法对持续减速状态滚动轴承外圈故障二阶分解检测结果。通过与一阶分解结果对比可以看出,相较于一阶分解,二阶分解的故障检测效果都有了一

定的提升。其中 T_{12}^2 对过渡子模态进行划分,同时检测率比一阶更高, SPE_{11} 对过渡子模态划分效果相较于一阶分解的检测效果有一定提升。

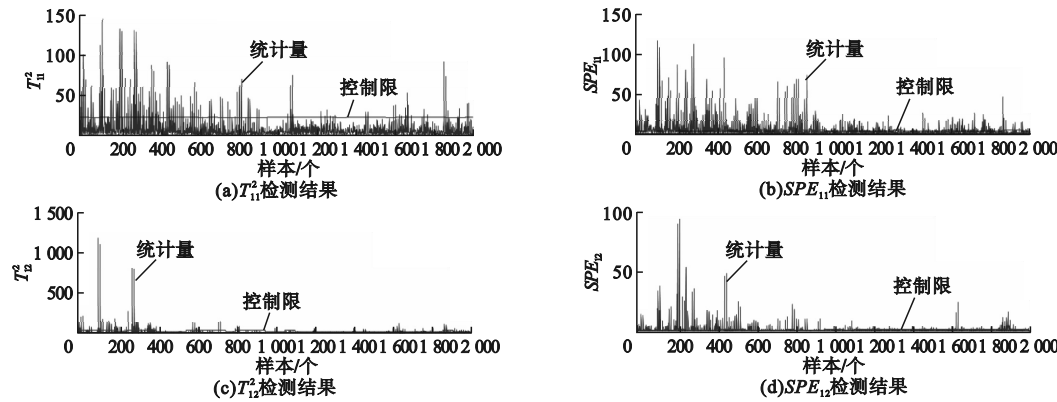
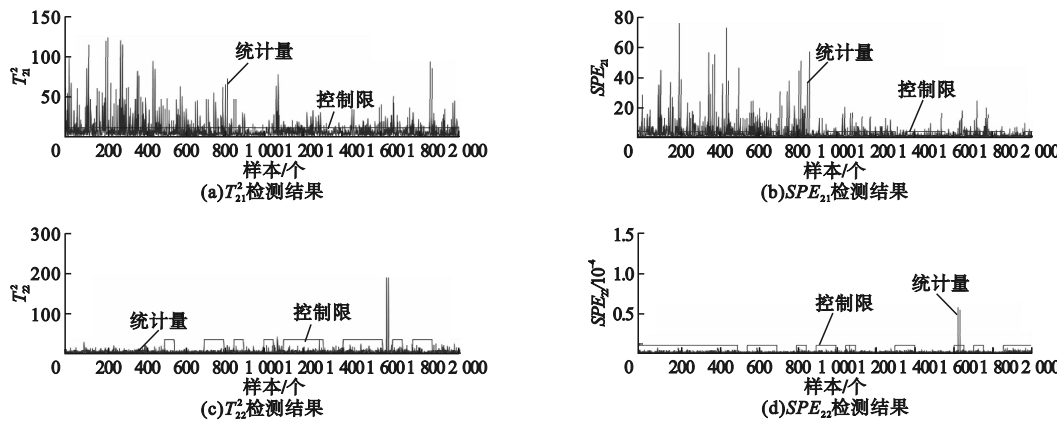


图6 减速状态滚动轴承外圈故障的二阶分解检测结果

Fig. 6 The second layer results of DDPCA for outer ring fault at deceleration state

图7是DDPCA方法对于处于持续减速状态下的滚动轴承外圈故障的三阶分解检测结果。由图可以看出,相较于二阶分解的检测效果,三阶分解对于过渡子模态的划分有着显著的提升,其中 T_{23}^2 故障检测结果尤其明

显。将一阶分解结果与三阶分解结果进行对比可以得出结论,基于DDPCA滚动轴承早期故障诊断方法对于过渡模态滚动轴承外圈故障早期故障检测有着显著的效果。



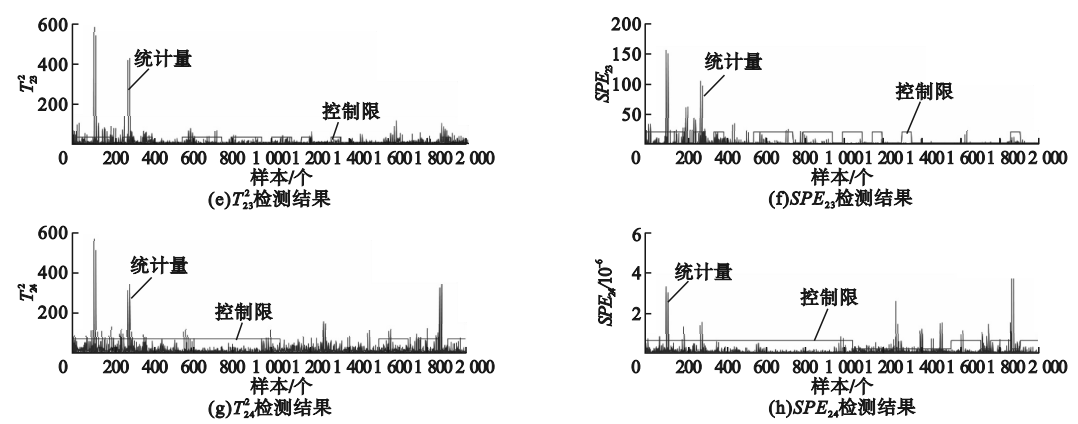


图7 减速状态滚动轴承外圈故障的三阶分解检测结果

Fig. 7 The third layer results of DDPCA for outer ring fault at deceleration state

基于 DDPCA 滚动轴承过渡模态早期故障检测方法对滚动轴承在持续减速状态下外圈故障检测的漏检率分别为 17.2%、8.6% 和 6.6%。以漏检率来看,在对减速过程滚动轴承早期进行故障检测过程中,在一阶分解时,基本没有表现出对过渡子模态的划分,且漏检率较高。而进入到二阶分解时,可以看出检测率和对过渡子模态的划分效果都有一定提升。从三阶分解结果可以看出,三阶分解的 T^2 对过渡子模态划分的效果都有了明显提升,同时检测率也有提升。所以,随着 DDPCA 方法的分解阶数的增加,对过渡子模态的划分越来越清晰,误报的情况也随着分解阶数的增加而逐渐减少。基于 DDPCA 的过渡模态早期故障检测方法可以清晰地描述过渡模态的动态特性,可以对过渡模态滚动轴承早期故障进行准确的检测。

3 结 论

(1) 针对滚动轴承过渡模态早期故障检测过程中,出现的故障特征具有动态性和滚动轴承早期故障功能特征微弱难以提取问题,笔者提出了一种基于深度差分主元分析方法,该方法使用差分的方法对原始数据进行处理,将具有相似变量特征的过渡模态数据划分成为相同过渡子模态,结合深度分解理论准确提取过渡子模态中的故障特征,对

每个过渡子模态建立故障检测模型。

(2) 随着分解阶数的增加,对过渡模态早期故障检测效果逐渐提升,对滚动轴承过渡子模态的划分越来越清晰,误报的情况也随着分解阶数的增加而逐渐减少;滚动轴承持续减速状态下外圈故障一阶分解检测的漏检率为 17.2%,二阶分解检测的漏检率 8.6%,三阶分解检测的漏检率 6.6%。

(3) 笔者所提方法对过渡子模态进行多层分解,可以准确提取过渡子模态中的故障特征并建立分段检测模型,提高了过渡模态的滚动轴承早期故障检测的准确性。

参考文献

[1] 张锐戈,肖荣辉,高忠坚. 变工况下滚动轴承双谱分析及智能故障诊断[J]. 噪声与振动控制, 2021, 41(6): 97–104.
(ZHANG Ruige, XIAO Ronghui, GAO Zhongjian. Bi-spectrum analysis and intelligent fault diagnosis for rolling element bearings under variable operation conditions [J]. Noise and vibration control, 2021, 41(6): 97–104.)

[2] LUO Maolin, GUO Yu, WU Xing, et al. An analytical model for estimating spalled zone size of rolling element bearing based on dual-impulse time separation [J]. Journal of sound and vibration, 2019, 453: 87–102.

[3] CHENG Junsheng, PENG Yanfeng, YU Yang. Adaptive sparsest narrow-band decomposition method and its applications to rolling element bearing fault diagnosis [J]. Mechanical systems & signal processing, 2017, 85:

- 947-962.
- [4] ZHU Jun, CHEN Nan, PENG Weiwen. Estimation of bearing remaining useful life based on multiscale convolutional neural network [J]. IEEE transactions on industrial electronics, 2019, 66(4): 3208-3216.
- [5] 席剑辉, 崔健驰, 蒋丽英. 基于 JADE-ICA 的滚动轴承多故障信号盲源分离[J]. 振动与冲击, 2017, 36(5): 231-237.
(XI Jianhui, CUI Jianchi, JIANG Liying. JADE-ICA-based blind source separation of multi-fault signals of rolling bearings [J]. Journal of vibration and shock, 2017, 36(5): 231-237.)
- [6] 谭帅, 侍洪波, 王福利, 等. 多模态过程过渡初期与末期的监测方法[J]. 上海应用技术学院学报(自然科学版), 2016, 16(1): 26-30.
(TAN Shuai, SHI Hongbo, WANG Fuli, et al. Monitoring method for beginning and ending of transitional mode in multi-mode process [J]. Journal of Shanghai institute of technology (natural science), 2016, 16(1): 26-30.)
- [7] LU Ningyun, GAO Furong, WANG Fuli. Sub-PCA modelling and on-line monitoring strategy for batch processes [J]. AIChE journal, 2004, 50(1): 255-259.
- [8] WANG Yi, XU Guanghua, LIANG Lin, et al. Detection of weak transient signals based on wavelet packet transform and manifold learning for rolling element bearing fault diagnosis [J]. Mechanical systems & signal processing, 2015, 54/55: 259-276.
- [9] 王文标, 田志远, 汪思源, 等. 交叉分段 PCA 在锅炉故障诊断中的应用[J]. 信息与控制, 2020, 49(4): 507-512.
(WANG Wenbiao, TIAN Zhiyuan, WANG Siyuan, et al. Optimal operation method based on cross and piecewise PCA for industrial boilers [J]. Information and control, 2020, 49(4): 507-512.)
- [10] 谭帅, 王福利, 常玉清, 等. 基于差分分段 PCA 的多模态过程故障监测[J]. 自动化学报, 2010, 36(11): 1626-1636.
(TAN Shuai, WANG Fuli, CHANG Yuqing, et al. Fault detection of multi-mode process using segmented PCA based on differential transform [J]. Acta automatica sinica, 2010, 36(11): 1626-1636.)
- [11] HUANG Darong, KE Lanyan, MI Bo, et al. A new incipient fault diagnosis method combining improved RLS and LMD algorithm for rolling bearings with strong background noise [J]. IEEE access, 2018, 6: 26001-26010.
- [12] 游达章, 陈林波, 张业鹏, 等. 基于 PCA-CNN 的滚动轴承故障诊断方法研究[J]. 机床与液压, 2021, 49(19): 172-177.
(YOU Dazhang, CHEN Linbo, ZHANG Yepeng, et al. Study on fault diagnosis methods of rolling bearing based on principal component analysis and convolutional neural network [J]. Machine tool & hydraulics, 2021, 49(19): 172-177.)
- [13] ZHAO Chunhui, WANG Fuli, LU Ningyu, et al. Stage-based soft-transition multiple PCA modeling and on-line monitoring strategy for batch processes [J]. Journal of process control, 2007, 17(9): 728-741.
- [14] CHEN Hongtian, JIANG Bin, LU Ningyu, et al. Deep PCA based real-time incipient fault detection and diagnosis methodology for electrical drive in high-speed trains [J]. IEEE transactions on vehicular technology, 2018, 67(6): 4819-4830.
- [15] HUANG Huan, NATALIE B, LIANG Ming. A method for tachometer-free and resampling-free bearing fault diagnostics under time-varying speed conditions - science direct [J]. Measurement, 2019, 134: 101-117.
- [16] XU Weixiao, JING Luyang, TAN Jiwen, et al. A multimodel decision fusion method based on DCNN-IDST for fault diagnosis of rolling bearing [J]. Shock and vibration, 2020, 2020(1): 1-12.
- [17] WANG Yujing, JIANG Yicheng, KANG Shouqiang, et al. Diagnosis method of fault location and performance degradation degree of rolling bearing based on optimal ensemble EMD [J]. Chinese journal of scientific instrument, 2013, 34(8): 1834-1840.
- [18] AKA C, MHA B, MFHA D, et al. Hidden Markov model based principal component analysis for intelligent fault diagnosis of wind energy converter systems [J]. Renewable energy, 2020, 150: 598-606.

(责任编辑:刘春光 英文审校:范丽婷)