

DOI:10.19651/j.cnki.emt.2107172

# 基于改进的动态独立成分分析故障检测方法<sup>\*</sup>

张珂 蔡圣福 石怀涛 郭瑾 张啸尘

(沈阳建筑大学机械工程学院 沈阳 110168)

**摘要:** 针对滚动轴承早期故障特征微弱,且振动信号是一组随时间变化的序列,具有一定的时序相关性,导致滚动轴承早期故障检测难度增加的问题,提出了一种基于深度分解的动态独立成分分析(Deep DICA)故障检测方法。主要思想是首先增加观测数据矩阵,以便将动态过程考虑在内。然后,为了更好地挖掘出微弱的早期故障信息,提出了深度分解原理对早期故障进行特征提取。最后,建立故障检测模型进行在线故障检测,并通过轴承实验对所提出的方法进行了验证。实验结果表明,提出的基于 Deep DICA 的故障检测方法有很好的准确率和适用性。

**关键词:** 滚动轴承;早期故障;特征提取;故障检测;Deep DICA

**中图分类号:** TP277 **文献标识码:** A **国家标准学科分类代码:** 510.8060

## Fault detection method based on improved dynamic independent component analysis

Zhang Ke Cai Shengfu Shi Huaitao Guo Jin Zhang Xiaochen

(School of Mechanical Engineering, Shenyang Jianzhu University, Shenyang 110168, China)

**Abstract:** Aiming at the problem that the incipient fault characteristics of rolling bearing are weak, and the vibration signal is a group of time-varying sequence, which has a certain time-series correlation, leading to the difficulty of incipient fault detection of rolling bearing, a dynamic independent component analysis fault detection method based on deep decomposition principle (Deep DICA) is proposed. The main idea is to first increase the observation data matrix in order to take the dynamic process into account. Then, in order to better dig out the weak incipient fault information, the principle of deep decomposition is proposed to extract the features of incipient faults. Finally, a fault detection model is established for online fault detection and the proposed method is verified by bearing experiments. Experimental results show that the proposed fault detection method based on Deep DICA has good accuracy and applicability.

**Keywords:** rolling bearing; incipient fault; feature extraction; fault detection; Deep DICA

### 0 引言

滚动轴承作为普通机械设备的的重要组成部分,在长期重载、强冲击等复杂工况下,容易发生各种故障<sup>[1-3]</sup>。实际上,滚动轴承许多种类的严重故障是由小规模的早期故障逐渐演变而来的<sup>[4-5]</sup>,及时准确地检测早期故障有助于安排预防性维护,从而防止更严重的故障发生并确保系统保持最佳运行状态。

模型驱动和数据驱动方法是滚动轴承早期故障检测常用的两种方法<sup>[6]</sup>。模型驱动的方法涉及从系统数学模型的残差作为故障指示器<sup>[7]</sup>,然而为由复杂多变量组成的滚动轴承在实际工程中的运行数据建立精确的模型具有挑战性

和费时的,这使得模型驱动的方式不太常用。数据驱动的方式完全依赖历史过程数据的可用性,为连续运行过程识别数据集中的变量和底层模式之间的关系,引起越来越多的研究兴趣。多元统计数据分析是数据驱动方式一个重要分支,主成分分析(principal component analysis, PCA)和独立成分分析(independent component analysis, ICA)是先进的常用的基于多元统计分析的故障检测方法。ICA 相比 PCA 可以更好地处理非高斯数据,因此在工程实际中被广泛应用于运行过程的监控<sup>[8]</sup>。然而,传统的 ICA 算法仍然存在一些缺点,其假设一段时间内的观测值是独立的,然而在工程实际中由于过程动态特性的存在,这个假设是无效的。随后, Lee 等<sup>[9]</sup>提出了一种动态独立分量分析

收稿日期:2021-07-05

<sup>\*</sup> 基金项目:辽宁省自然科学基金项目(2019-ZD-0654)、辽宁省科学技术计划项目(2020JH1/10100012)、沈阳市重点创新研发计划项目(Y19-1-004)、沈阳市重点科技攻关项目(20-202-4-40)资助

(dynamic independent component analysis, DICA) 算法来处理动态非高斯多元过程。随着研究的不断深入, Villegas 等<sup>[10]</sup>运用 DICA 来检测和诊断污水处理厂的故障; Xu 等<sup>[11]</sup>将 DICA 与贝叶斯理论结合提出了动态贝叶斯独立成分分析 (dynamic Bayesian independent component analysis, DBICA), 并成功用于搅拌釜式反应器模拟系统的故障检测; Huang 等<sup>[12]</sup>将典型相关分析 (canonical correlation analysis, CCA) 和 DICA 结合并应用于斜拉桥的自振特性数据的检测。上述学者的研究都已取得非常好的进展, 然而他们的研究并没有考虑到对早期故障进行检测, 以滚动轴承为例, 其早期故障特征信号十分微弱, 特征提取很难实现, 故障检测效果不理想。因此需要采取一种合适的方法对早期的故障特征进行提取并进行故障检测。文献[13]提出深度分解原理并成功应用于高速电车的早期故障特征提取, 文献[14]将深度分解原理与主成分分析方法结合应用于滚动轴承早期故障检测, 上述对早期故障检测的研究都已取得预期的良好结果。

考虑到滚动轴承在工程实际中的运行过程具有动态特性并且早期故障特征十分微弱, 本文提出了基于深度分解的动态独立成分分析 (deep dynamic independent component analysis, Deep DICA) 的滚动轴承早期故障检测方法, 该方法考虑到过程的动态特性, 通过引入时滞构建增广矩阵, 然后运用深度分解原理对增广矩阵进行特征提取, 最后建立在线检测模型进行故障检测, 该方法可以充分挖掘出微弱的早期故障特征, 实现早期故障检测的目标。

### 1 基于 Deep DICA 的早期故障检测方法

#### 1.1 DICA

工程实际中的运行过程很难保持静止状态, 必须考虑过程数据的序列相关性, 以实现有效的检测。在模型建立过程中使用时间滞后移动方法以消除数据序列的相关性, 并提高故障检测性能。假设观测矩阵  $\mathbf{X}$  为已经进行标准化处理过的包含  $m$  个观测变量, 并且每个观测变量有  $n$  个采样值, 观测矩阵可以表示为:  $\mathbf{X} = [\mathbf{x}(1), \mathbf{x}(2), \dots, \mathbf{x}(n)] \in \mathbf{R}^{m \times n}$ , 观测矩阵中每一行为一次采样。将前  $d$  个时刻采样数据进行扩展, 得到如下增广矩阵:

$$\mathbf{X}_s = \begin{bmatrix} \mathbf{x}(1) & \mathbf{x}(2) & \dots & \mathbf{x}(d+1) \\ \mathbf{x}(2) & \mathbf{x}(3) & \dots & \mathbf{x}(d+2) \\ \vdots & \vdots & \ddots & \vdots \\ \mathbf{x}(d+1) & \mathbf{x}(d+2) & \dots & \mathbf{x}(n) \end{bmatrix} \in \mathbf{R}^{m(d+1) \times (n-d)} \quad (1)$$

然后对增广矩阵  $\mathbf{X}_s$  建立 DICA 模型, 其模型如下:

$$\mathbf{X}_s = \mathbf{AS} + \mathbf{E} \quad (2)$$

式中:  $\mathbf{X}_s \in \mathbf{R}^{m(d+1) \times (n-d)}$  是经过扩展后的观测矩阵;  $\mathbf{S} = [s_1 s_2 \dots s_n]^T \in \mathbf{R}^{n \times (n-d)}$  是  $n$  个相互独立的源信号组成的矩阵;  $\mathbf{A} \in \mathbf{R}^{m(d+1) \times n}$  是混合矩阵;  $\mathbf{E} \in \mathbf{R}^{m(d+1) \times (n-d)}$  为残差矩阵;  $d$  为时间滞后常数。Ku 等<sup>[15]</sup>建议在通常情况下,  $d$  的

取值为 1 或 2。本文中取滞后常数为 2。DICA 要解决的问题是找到分离矩阵  $\mathbf{W}$  来重构源信号矩阵  $\hat{\mathbf{S}}$ , 其表达式如下所示:

$$\hat{\mathbf{S}} = \mathbf{WX}_s = \mathbf{WAS} \approx \mathbf{S} \quad (3)$$

DICA 可以弥补传统 ICA 方法在捕捉动态关系数据上的不足, 可以更真实地反映数据的动态特性。该方法不仅可以从互相关变量中提取独立成分, 还可以从自相关变量中提取独立成分, 在动态过程中表现出更强的监控性能。

#### 1.2 早期故障特征提取

考虑到运行过程的动态特性, 对振动传感器采集到的数据进行处理以增加观测数据矩阵, 接下来的工作便是运用深度分解原理对早期故障特征进行提取。深度分解原理依据于 PCA, PCA 是将原始数据空间分解成两个子空间, 其中主子空间可以用更少的潜在变量保留大部分方差信息, 运用深度分解原理即是采用 PCA 的特征分解的方式对构建的增广矩阵  $\mathbf{X}_s$  进行  $\lambda$  阶分解, 产生  $2^\lambda$  个子数据集  $\mathbf{X}_{s_{ik}}$ , 以这种方式挖掘早期微弱的故障特征。深度分解原理的分解结构如图 1 所示。




图 1 深度分解原理的分解结构

#### 1) 完整的深度分解过程

运用深度分解原理求得数据集  $\mathbf{X}_s$  的一阶分解结果为:

$$\mathbf{X}_s = \mathbf{X}_{s11} + \mathbf{X}_{s12} \quad (4)$$

这里  $\mathbf{X}_{s11}$  是构建的增广矩阵  $\mathbf{X}_s$  的一阶分解的主元空间,  $\mathbf{X}_{s12}$  是一阶分解的残差子空间。由 PCA 特征分解原理,  $\mathbf{X}_{s11}$  和  $\mathbf{X}_{s12}$  可由下式求得:

$$\mathbf{X}_{s11} = \mathbf{P}_{11} \mathbf{P}_{11}^T \mathbf{X}_s \quad (5)$$

$$\mathbf{X}_{s12} = (\mathbf{I} - \mathbf{P}_{11} \mathbf{P}_{11}^T) \mathbf{X}_s \quad (6)$$

$\mathbf{P}_{11}$  为主元空间对应的特征向量, 由此可计算出二阶分解结果:

$$\mathbf{X}_{s11} = \mathbf{X}_{s21} + \mathbf{X}_{s22} \quad (7)$$

$$\mathbf{X}_{s12} = \mathbf{X}_{s23} + \mathbf{X}_{s24} \quad (8)$$

则原始数据空间可以分解为:

$$\mathbf{X}_s = \mathbf{X}_{s11} + \mathbf{X}_{s12} = \mathbf{X}_{s21} + \mathbf{X}_{s22} + \mathbf{X}_{s23} + \mathbf{X}_{s24} \quad (9)$$

$$\mathbf{X}_{s21} = \mathbf{P}_{21} \mathbf{P}_{21}^T \mathbf{X}_{s11} \quad (10)$$

$$\mathbf{X}_{s22} = (\mathbf{I} - \mathbf{P}_{21} \mathbf{P}_{21}^T) \mathbf{X}_{s11} \quad (11)$$

$$\mathbf{X}_{s23} = \mathbf{P}_{23} \mathbf{P}_{23}^T \mathbf{X}_{s12} \quad (12)$$

$$\mathbf{X}_{s24} = (\mathbf{I} - \mathbf{P}_{23} \mathbf{P}_{23}^T) \mathbf{X}_{s12} \quad (13)$$

假设  $\mathbf{P}_{(\lambda-1)(2k-1)}$  是与  $\mathbf{X}_{s_{ik}}$  相关的主要负荷向量, 经过  $\lambda$  阶分解后  $\mathbf{X}_{s_{ik}}$  可以表述为:

$$\mathbf{X}_{s\lambda k} = \begin{cases} \mathbf{P}_{\lambda k} \mathbf{P}_{\lambda k}^T \mathbf{X}_{s\lambda-1(k+1)/2}, & k \text{ 为奇数} \\ (\mathbf{I} - \mathbf{P}_{\lambda k} \mathbf{P}_{\lambda k}^T) \mathbf{X}_{s\lambda-1k/2}, & k \text{ 为偶数} \end{cases} \quad (14)$$

运用深度分解概念对数据集进行不断地分解后,能够最大程度地提取早期微弱故障特征,达到预期的故障检测效果。

### 2) 理论分析

本节从理论分析角度说明 Deep DICA 的早期故障检测能力。深度分解同 PCA 特征提取原理一样,二者唯一区别是 PCA 对数据集仅进行一阶分解,深度分解则是采用 PCA 分解的方式对原始数据进行多阶分解,在分解的过程中,保存信息量的多少通常由协方差的大小来衡量。假设本文所提出的 Deep DICA 算法的每一层中对于同一个分量分解后产生的子空间向量之间是正交的。

采用 Deep DICA 进行故障检测时,增广矩阵  $\mathbf{X}_s$  的协方差可以表示为:

$$\mathbf{S} = \frac{1}{N-1} (\mathbf{X}_s)^T (\mathbf{X}_s) \quad (15)$$

根据式(4)增广矩阵  $\mathbf{X}_s$  的一阶分解协方差大小可以表示为:

$$\mathbf{S} = \frac{1}{N-1} (\mathbf{X}_{s11} + \mathbf{X}_{s12})^T (\mathbf{X}_{s11} + \mathbf{X}_{s12}) \quad (16)$$

经过  $\lambda$  阶分解后,协方差可以表示为:

$$\mathbf{S} = \frac{1}{N-1} \left( \sum_{k=1}^{2^\lambda} \mathbf{X}_{s\lambda k} \right)^T \left( \sum_{k=1}^{2^\lambda} \mathbf{X}_{s\lambda k} \right) \quad (17)$$

由于本文提出的 Deep DICA 方法每一层中对于同一个分量分解后产生的子空间向量之间是正交的,则存在:

$$\mathbf{X}_{s\lambda k}^T \mathbf{X}_{s\lambda(k+1)} = 0 \quad (18)$$

则式(17)简化式子得到:

$$\mathbf{S} = \sum_{k=1}^{2^\lambda} \frac{1}{N-1} \{ (\mathbf{X}_{s\lambda k})^T (\mathbf{X}_{s\lambda k}) \} \quad (19)$$

假设  $\mathbf{S}_{2k} = \frac{1}{N-1} \mathbf{X}_{s\lambda k}^T \mathbf{X}_{s\lambda k}$ , 那么协方差的大小可以由如下表达式表示:

$$\mathbf{S}_{11} + \mathbf{S}_{12} = \sum_{k=1}^3 \mathbf{S}_{2k} + \mathbf{S}_{24} = \sum_{k=1}^{2^\lambda-1} \mathbf{S}_{\lambda k} + \mathbf{S}_{2^{2^\lambda}} \quad (20)$$

因此由上述公式可以得到如下的大小比较关系:

$\sum_{k=1}^{2^\lambda-1} \mathbf{S}_{\lambda k} > \dots > \sum_{k=1}^3 \mathbf{S}_{2k} > \mathbf{S}_{11}$ 。由于协方差矩阵描述的是各个维度之间的所有关系信息,可以得到随着分解阶数的增加,Deep DICA 方法可以保留的方差信息会增多,可以保留更多的故障信息,达到早期故障检测的效果。为了考虑计算的复杂程度,基于式(4)~(13)将经过动态处理的增广矩阵仅进行三阶分解,生成三阶主子空间和残差空间。对于一阶分解的残差子空间为  $\mathbf{X}_{s12}$ , 二阶分解后的残差子空间为  $\mathbf{X}_{s24}$ , 三阶分解后的残差子空间为  $\mathbf{X}_{s38}$ 。通过如图 2 所示所描述的详细的几何关系可以看出,  $\mathbf{X}_{s12}$  的剩余量大于  $\mathbf{X}_{s24}$ , 同时  $\mathbf{X}_{s24}$  的剩余量大于  $\mathbf{X}_{s38}$ , 因此可以得出采用深度

分解原理分解后,残差空间越来越小,即主元空间包含的信息越来越多,可以挖掘到更多细微的故障信息,有利于对微弱的早期故障进行检测。

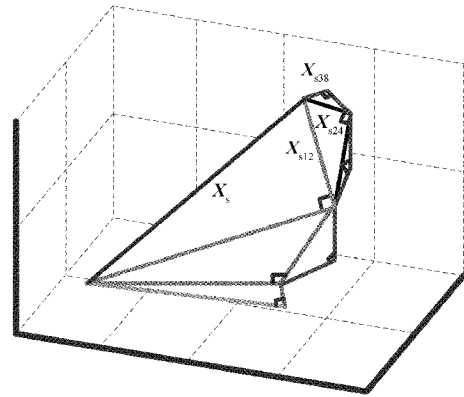


图 2 深度分解原理几何解释

### 1.3 基于 Deep DICA 的早期故障检测方法

本文提出的基于 Deep DICA 算法的故障检测模型主要包括如下 3 个部分:首先考虑到工程实际中的变量具有自相关和互相关的动态特征,引入滞后值来构建增广矩阵;然后运用深度分解原理对数据集进行早期故障特征提取;最后建立在线故障检测模型完成早期故障检测。故障检测流程具体如下。

离线阶段:

- 1) 收集正常工况下滚动轴承运行数据。
- 2) 确定时滞  $d$ , 根据式(1)构建增广矩阵  $\mathbf{X}_s$ 。
- 3) 运用深度分解原理选择合适分解阶数  $\lambda$ , 考虑到计算的复杂程度,本文仅进行到三阶分解,通过式(14)计算每一个子空间  $\mathbf{X}_{s\lambda k}$ 。
- 4) 计算每个  $\mathbf{X}_{s\lambda k}$  的主要独立成分个数,主要和剩余分离矩阵  $\mathbf{W}_d$  和  $\mathbf{W}_e$ 。

5) 控制限的确定。基于 Deep DICA 方法进行故障检测时,处理的数据不服从高斯分布,不能用一个特定的分布来直接计算控制限的值,通常用核密度估计方法确定控制限<sup>[16]</sup>,对给定训练集  $\mathbf{X} = [\mathbf{X}_1^T, \mathbf{X}_2^T, \dots, \mathbf{X}_n^T]$ , 其中  $\mathbf{X}_i \in \mathbf{R}^m$ 。核密度估计如下:  $\hat{f}(\mathbf{x}, \sigma) = \frac{1}{n\sigma^{i-1}} \sum_{i=1}^n \varphi(\sigma^{-1/2}(\mathbf{x} - \mathbf{x}_i))$ , 其中,  $\mathbf{x}$  为  $m$  维空间变量;  $\sigma$  为带宽参数;  $\varphi(x)$  为核函数。其中核函数选取高斯核函数  $\varphi(\mathbf{x}_i, \mathbf{x}_j) = \exp(-\|\mathbf{x}_i - \mathbf{x}_j\|^2 / 2\sigma^2)$ , 最后按照 99% 的置信区间确定控制限。这里首先计算正常工况下的统计量  $\mathbf{I}_{cik}^2$ 、 $\mathbf{I}_{ecik}^2$ 、 $\mathbf{SPE}_{cik}$ , 然后运用核密度估计其对应的控制限。

在线阶段:

- 6) 收集在线实时在线数据。
- 7) 确定时滞  $d$ , 根据式(1)构建增广矩阵  $\mathbf{X}_{st}$ 。
- 8) 计算统计量。假设训练数据已经过标准化处理,运用基于负熵最大化的 FastICA 进行特征提取,确定  $d$  个主

要的独立成分和  $e$  个残差独立成分,以及分别对应的分离矩阵  $W_d$  和  $W_e$ 。通过分离矩阵和白化矩阵  $Q$  的关系,求得  $B_d$  和  $B_e$ , 便于后面统计量的计算:

$$B_d = (W_d Q^{-1})^T \quad (21)$$

$$B_e = (W_e Q^{-1})^T \quad (22)$$

对于某一时刻  $k$  的采样数据  $x_{stnew}(k)$ , 通过分离矩阵  $W_d$  和  $W_e$  可以计算其对应的独立分量:

$$\hat{S}_{newd}(k) = W_d x_{stnew}(k) \quad (23)$$

$$\hat{S}_{newe}(k) = W_e x_{stnew}(k) \quad (24)$$

$I^2$  是主模型的统计量,是模型内部表征,定义如下:

$$I^2(k) = \hat{S}_{newd}^T(k) \hat{S}_{newd}(k) \quad (25)$$

$I_e^2$  是辅助模型的统计量,该模型会补偿误差,定义如下:

$$I_e^2(k) = \hat{S}_{newe}^T(k) \hat{S}_{newe}(k) \quad (26)$$

SPE 统计量代表系统外部过程变量变化的情况,在采样的  $k$  时刻:

$$SPE(k) = e(k)^T e(k) = (x_{stnew}(k) - \hat{x}_{stnew}(k)) \quad (27)$$

式中:  $\hat{x}_{stnew}(k) = SPE^{-1} B_d W_d x_{stnew}(k)$

9) 当统计量的值大于控制限的值则判断出现故障,否则没有故障产生。基于 Deep DICA 的故障检测流程如图 3 所示。

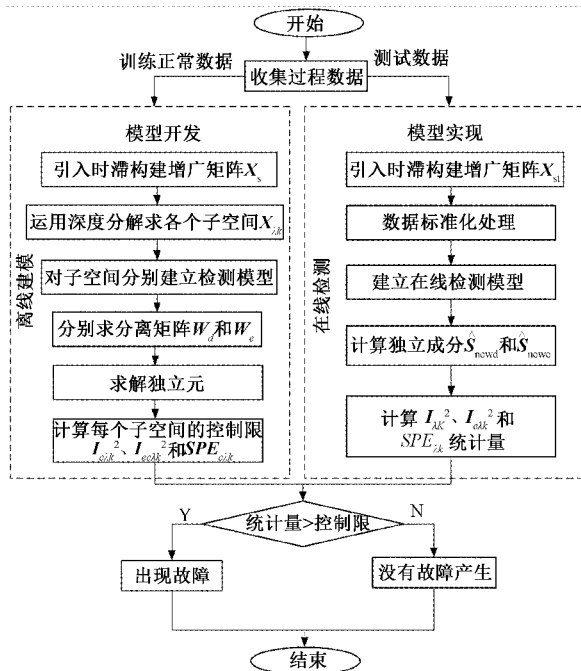


图 3 基于 Deep DICA 的故障检测流程

## 2 实验仿真与结果分析

本节采用旋转机械故障综合仿真实验装置在实验室模拟滚动轴承在工程实际中的运行状态,并用振动传感器采集信号,实验装置如图 4 所示。本次实验选择的滚动轴承

存在的凹陷故障直径非常小,仅为 0.5 mm,故障源存在于滚动轴承内圈中。滚动轴承在运转过程中振动冲击时产生的脉冲较小,产生故障特征信号比较微弱,因此这些故障为早期故障。使用该试验台采集 2 组数据,分别是滚动轴承正常运转时的数据和滚动轴承内圈故障数据,将采集的数据进行实验分析。




图 4 旋转机械故障综合模拟试验台

### 2.1 滚动轴承内圈故障仿真实验

当滚动轴承内圈存在故障缺陷时,滚动体经过该缺陷时会产生相应的脉冲力,本次的实验轴承故障直径很小,滚动体与内圈接触产生的冲击也很小,可以很好地进行滚动轴承的早期故障实验模拟。

图 5(a)和(b)分别描述的是 ICA 和 DICA 方法对滚动轴承内圈的故障检测结果,同时也分别是 Deep ICA 和 Deep DICA 方法进行一阶分解时的检测结果。实验结果显示,当采用传统 ICA 方法进行故障检测时,故障检测率很低,不到 30%。当采用 DICA 方法时,其检测效果相对 ICA 明显提升,其中  $I_{e01}^2$  统计量的检测率达到了 60.02%,但这两种方法均不适用于早期故障的检测。

图 6(a)~(b)描述的是采用 Deep ICA 方法进行二阶分解时的故障检测结果。其中图 6(a)是对二阶原始空间  $X_{11}$  的检测结果,  $SPE_{11}$  统计量的故障检测效果较好,检测率达到了 60.11%。图 6(b)是对二阶原始空间  $X_{12}$  的检测结果,  $SPE_{12}$  统计量的检测率达到了 56.56%,相比其他两个统计量检测效果好些。图 6(c)~(f)是对三阶原始空间的检测结果,其中三阶原始空间  $X_{24}$  的故障检测效果最好,  $SPE_{24}$  统计量受该故障的影响较大,故障检测率达到了 87.00%。可以看出,经过三阶后故障检测率明显提升更加适合对早期故障进行检测。

图 7(a)~(b)描述的是采用 Deep DICA 方法在二阶分解过程中对原始空间  $X_{11}$  和  $X_{12}$  的故障检测结果,通过实验结果可以看出  $SPE_{12}$  统计量对该故障反应较为敏感,当存在故障时,该统计量受该故障影响最大,故障检测率达到了 77.51%,比进行一阶分解时的故障检测率有了一些提升,可以用作一些传统故障的检测,但仍不适合用于早期微弱故障的检测。

图 7(c)~(f)描述的是采用 Deep DICA 方法进行三阶






图5 基于传统方法的滚动轴承内圈故障检测

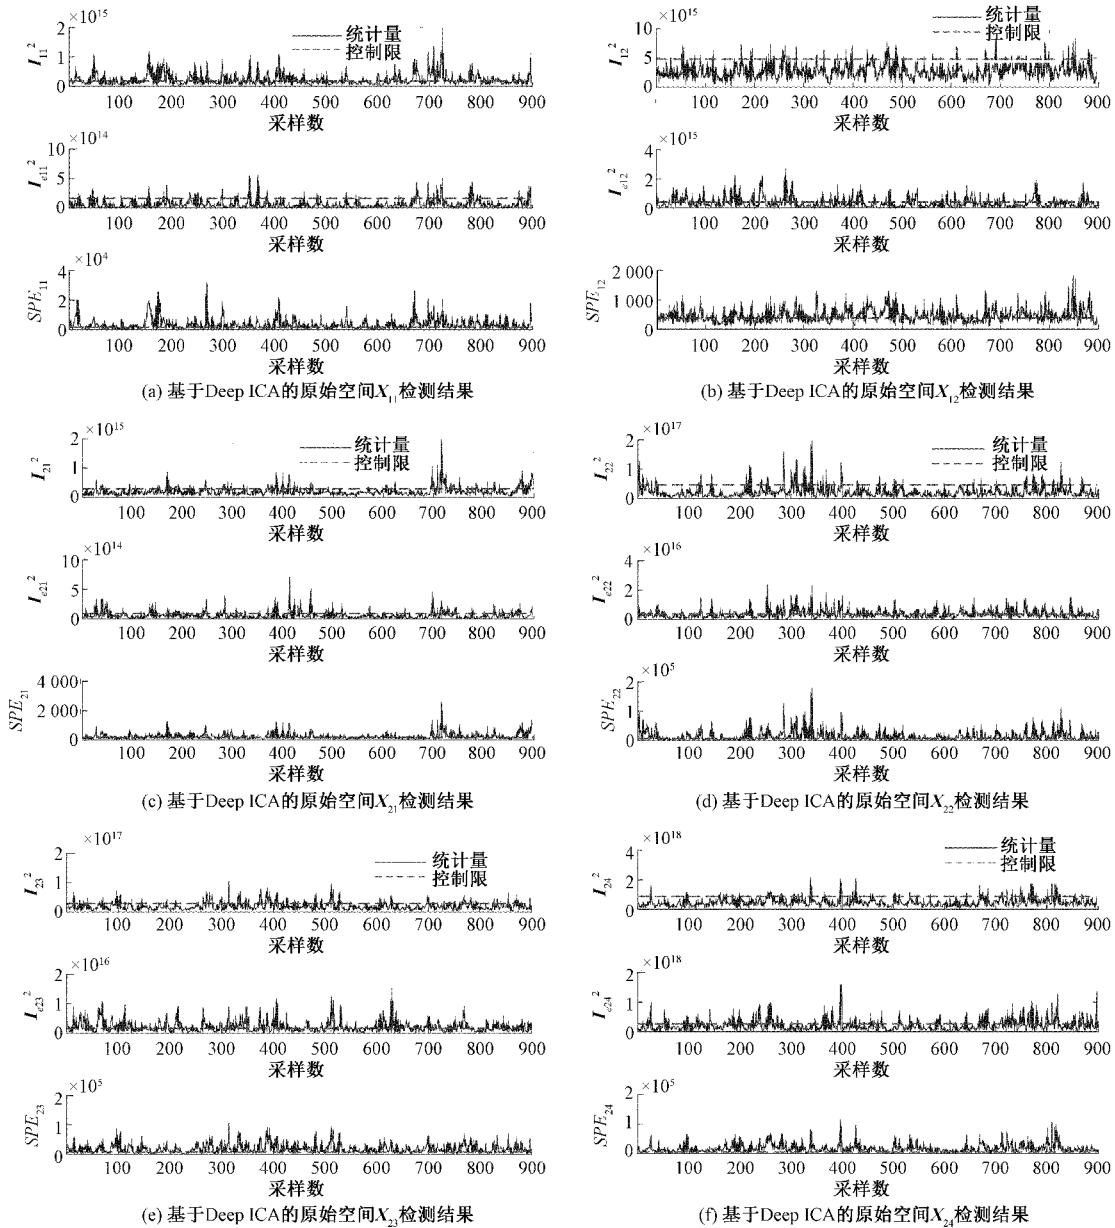


图6 基于 Deep ICA 的滚动轴承内圈故障检测结果

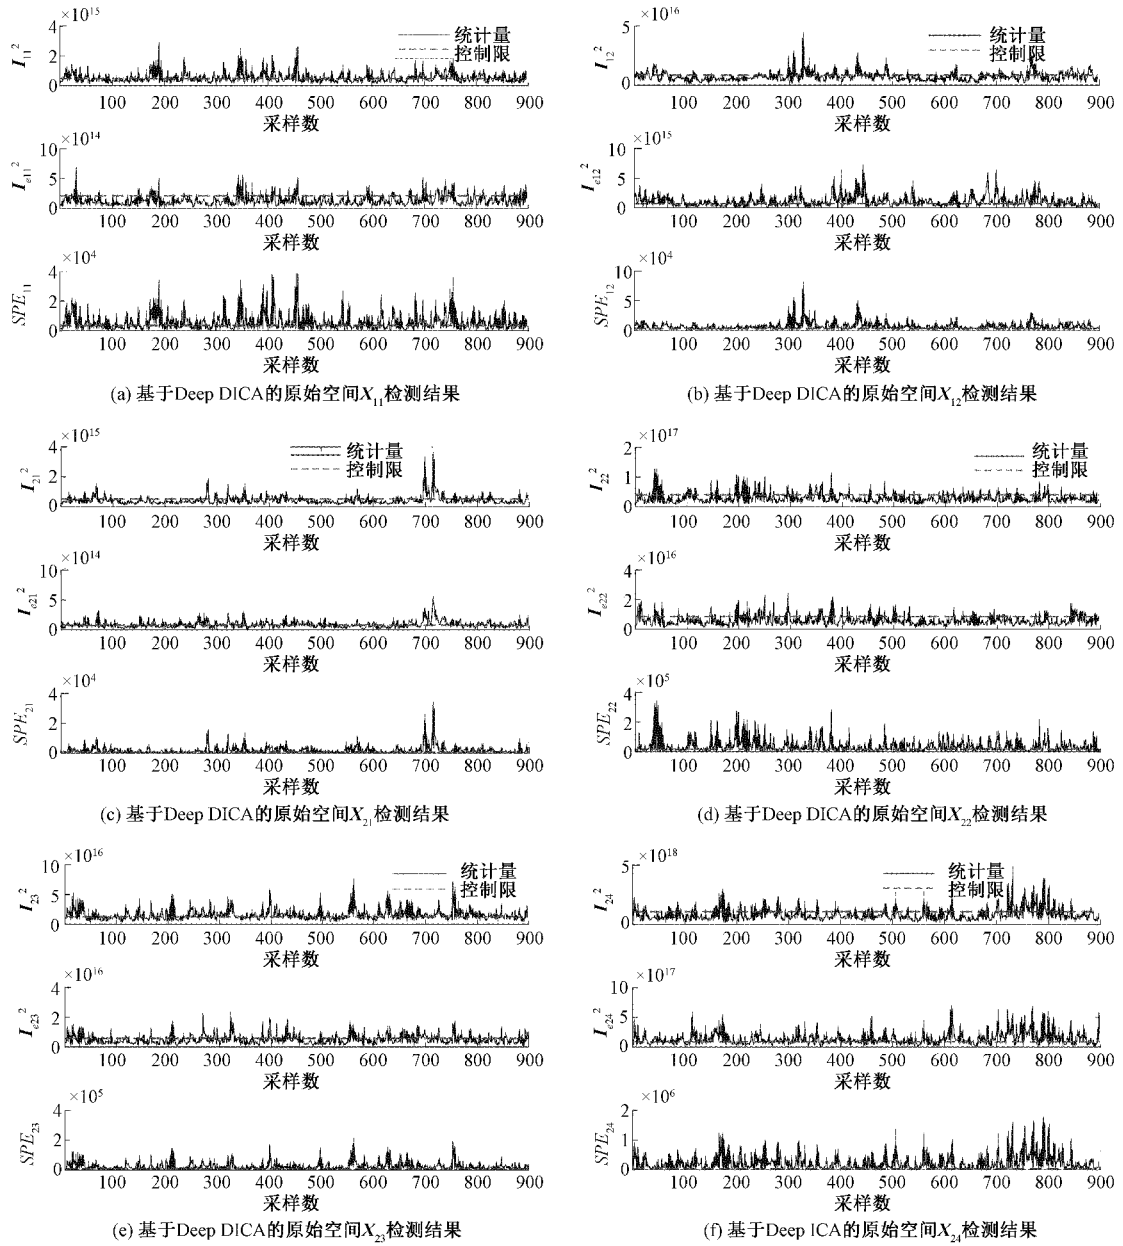


图 7 基于 Deep DICA 的滚动轴承内圈故障检测结果

分解时的故障检测结果,通过对比各个原始空间的故障检测率,可以得到  $SPE_{24}$  统计量对该故障最为敏感,其故障检测率达到了 89.76%,使用原始数据集进行实验分析时,当采用深度分解原理进行三阶分解故障特征提取后,可以看出故障检测率明显提升,对于一些早期故障特征不明显的故障可以检测出来,这也说明采用深度分解原理进行早期微弱故障特征提取的合理性及本文提出的 Deep DICA 方法进行早期故障检测的有效性。

### 2.2 结果分析与比较

表 1 所示为采用 Deep ICA 和 Deep DICA 方法进行多阶分解时的故障检测性能比较,当进行一阶分解时实际上是运用传统的 ICA 和 DICA 方法来进行故障检测,检测结果

显示传统的 ICA 的故障检测率很低,不到 30%,DICA 的检测率相对 ICA 提高了一些,但它们对于早期的微弱故障信号的检测效果均不理想。随着分解阶数的增加,Deep ICA 和 Deep DICA 的二阶分解比一阶分解的故障检测率进一步提升,当进行三阶分解时,故障检测率接近 90%,与此同时,由于 Deep DICA 考虑到过程动态的特性而比 Deep ICA 有着更好的故障检测效果,更加适合早期故障的检测。

表 1 滚动轴承内圈故障检测性能比较 %

检测方法	一阶分解	二阶分解	三阶分解
	检测率	检测率	检测率
Deep ICA	29.33	60.11	87.00
Deep DICA	60.02	77.51	89.76

### 3 结 论

针对在工程实际中采集到的滚动轴承数据为具有动态特性的非高斯数据,并且滚动轴承存在早期故障特征信号微弱的特点,本文提出 Deep DICA 的故障检测方法。该方法考虑到了实际运行过程的动态特性,采用深度分解原理对构建的增广矩阵进行多阶分解,以这种方式来深度挖掘早期故障特征,然后建立在线检测模型来完成早期故障的检测。最后通过滚动轴承实验验证了所提方法的有效性。

#### 参考文献

- [1] 马超,王少红,徐小力,等.基于CSBP的滚动轴承故障智能诊断方法[J].电子测量与仪器学报,2019,33(12):58-63.
- [2] SHI H T, BAI X T, ZHANG K, et al. Influence of uneven loading condition on the sound radiation of starved lubricated full ceramic ball bearings [J]. Journal of Sound and Vibration, 2019, 461:114910.
- [3] 张昕昕,敬伟,王鹏,等.基于小波神经网络的高速自动机故障预测方法研究[J].国外电子测量技术,2020,39(8):11-16.
- [4] 王小飞,王元鑫,曲建岭,等.面向大样本飞参数据的航空发动机性能监控方法[J].仪器仪表学报,2020,41(7):175-184.
- [5] 吴君凤.基于孪生支持向量机的民用航空发动机故障诊断[J].电子测量技术,2020,43(22):132-136.
- [6] KAMAKRISHNA KINI K, MADAKYARU M. Anomaly detection using multi-scale dynamic principal component analysis for Tennessee Eastman Process[C]. 2019 Fifth Indian Control Conference (ICC), 2019: 219-224.
- [7] RAMAKRISHNA KINI K, MADAKYARU M. Monitoring multivariate process using improved independent component analysis-generalized likelihood ratio strategy[J]. IFAC-Papers Online, 2020, 53(1): 392-397.
- [8] FAN J C, WANG Y Q. Fault detection and diagnosis of non-linear non-Gaussian dynamic processes using kernel dynamic independent component analysis[J]. Information Sciences, 2014, 259:369-379.
- [9] LEE J M, YOO C K, LEE I B. Statistical monitoring

of dynamic processes based on dynamic independent component analysis [J]. Chemical Engineering Science, 2004, 59(14):2995-3006.

- [10] VILLEAGAS T, FUENTE M J, SAINA-PALMERO G I. Fault diagnosis in a wastewater treatment plant using dynamic independent component analysis [J]. 18th Mediterranean Conference on Control and Automation, 2010: 874-879.
- [11] XU Y, DENG X G. Fault detection of multimode non-Gaussian dynamic process using dynamic Bayesian independent component analysis[J]. Neurocomputing, 2016, 200:70-79.
- [12] HUANG H B, YI T H, LI H N. Anomaly identification of structural health monitoring data using dynamic independent component analysis[J]. Journal of Computing in Civil Engineering, 2020, 34(5): 04020025.
- [13] CHEN H T, JIANG B, LU N Y, 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.
- [14] SHI H T, GUO J, BAI X T, et al. Research on a nonlinear dynamic incipient fault detection method for rolling bearings [J]. Applied Sciences, 2020, 10(7):2443.
- [15] KU W F, STORER R H, GEORGAKIS C. Disturbance detection and isolation by dynamic principal component analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1995, 30(1):179-196.
- [16] 杨泽宇,王培良.基于核独立成分分析和支持向量数据描述的非线性系统故障检测方法[J].信息与控制,2017,46(2):153-158.

#### 作者简介

张珂,工学博士,教授,主要从事智能电主轴的研究等方面的教学与科研工作。

E-mail:zhangke@sjzu.edu.cn

蔡圣福,在读硕士研究生,主要研究方向为电主轴系统的故障检测与诊断。

E-mail:cai201924@163.com

石怀涛(通信作者),工学博士,教授,主要研究方向为智能电主轴系统开发优化与控制 and 工业系统故障检测与诊断。

E-mail:sht@sjzu.edu.cn