

DOI: 10.13382/j.jemi.2017.07.008

基于相对变换的 ICA 故障检测方法 *

石怀涛 周 乾 王雨桐 李颂华

(沈阳建筑大学 国家地方联合工程实验室 沈阳 110168)

摘要:针对传统独立主元分析方法(independent component analysis,ICA)在标准化处理后导致特征值大小近似相等,难以提取有代表性变量等问题,提出了一种基于相对变换的独立主元分析(relative transformation ICA,RTICA)故障检测方法。该方法引入欧氏距离相对变换理论,将原始空间数据变换得到相对空间,然后在相对空间进行独立主元分析,降低相对空间的数据维数,使提取的独立主元特征具有更大的适应性,建立故障检测模型,最终实现在线故障检测。该方法通过田纳西-伊斯曼过程仿真加以验证,并应用到电主轴裂纹故障的状态监测中,实验结果表明该方法能有效减少独立主元个数,简化故障检测模型的复杂度,增强状态检测性能。

关键词:电主轴;故障检测;相对变换;欧氏距离;独立主元分析

中图分类号: TP277; TN9 文献标识码: A 国家标准学科分类代码: 510.8010

Fault detection method based on relative-transformation ICA

Shi Huaitao Zhou Qian Wang Yutong Li Songhua

(National-Local Joint Engineering Laboratory, Shenyang Jianzhu University, Shenyang 110168, China)

Abstract: Aiming at the problems that the eigenvalues of independent component analysis (ICA) are approximately equal and the representative variables cannot be extracted effectively after dimensionless standardization processing, a fault detection method based on relative-transformation ICA (RTICA) is proposed. The method introduces the relative-transformation based on Euclidean distance. Firstly, the RTICA approach transfers the original data space into relative space by computing the Euclidean distance. Secondly, ICA approach is used to reduce the dimensions of the data in the relative space, extract the independent PCs possess greater adaptability, build the fault detection model and implement on-line fault detection. The proposed method has been applied to Tennessee Eastman (TE) and the fault simulation experiment in electric spindle system. The results show that the method can effectively reduce the number of independent principal components, simplify the complexity of fault detection model, and enhance the performance of state detection.

Keywords: electric spindle; fault detection; relative-transformation; Euclidean distance; ICA

1 引言

随着高速加工技术的不断进步和发展,尤其是在航空、航天、汽车、轮船等高端技术行业的广泛应用,以及机械、电子等产品的需求不断增加,使得数控机床技术越来越受到重视。数控机床是将高效率、高精度以及高柔性集为一体,不仅提高精度,而且提高生产效率,而高速电

主轴又是数控机床的核心部分,其不但要求较高的速度、精度,而且要求连续输出的高转矩能力和较大功率运行范围。因此,对电主轴系统的故障检测显得尤其重要。基础的数据驱动技术主元分析^[1-2](principal component analysis,PCA)方法已经在过程监测与故障诊断领域得到了越来越广泛的应用,目前广泛使用的多元统计方法除了PCA方法外,还有独立主元分析^[3-5](independent principal component analysis,ICA)、偏最小二乘法^[6]

(partial least squares, PLS)、规范变量分析法^[7] (canonical aariate analysis, CVA) 等。

经典 PCA 方法只能解决高斯和线性问题的缺陷局限了它在实际工况中的使用,PCA 只考虑了二阶相关性,提取的主元是不相关而非独立的。ICA 方法为解决非高斯、独立数据的问题提供一个新的研究方向。早在 20 世纪 80 年代,ICA 方法由 Herault 和 Jutten 等人第一次正式提出^[8],直到 20 世纪 90 年代中期公布了基于信息最大化原理的 ICA 新方法 INFORMAX 后^[9],ICA 研究才获得广泛关注。随着对 ICA 方法的关注,国内外对 ICA 方法的研究及应用有了新的进展,例如 Oja 提出基于固定点迭代的 FastICA 方法^[10];张曦等人^[11]应用 ICA 算法解决了汽轮发电机组的性能检测问题;韩敏等人^[12]提出基于神经网络与 ICA 方法结合应用等。ICA 方法利用高阶统计信息,可以更有效地分离出独立的非高斯数据信息,并且可以处理非线性数据。

ICA 方法虽然弥补了 PCA 方法的一些不足,但是仍然存在一些缺陷,为了提高独立主元方法的检测精度,提高运行速度,本文将相对变换方法^[13]引入到 ICA 方法之中,提出了基于相对变换的 ICA (relative transformation ICA, RTICA) 故障检测方法。文献[14]在 2009 年提出结合相对变换和主元分析方法用作故障诊断,有效提高故障检测精度。2011 年,易森等人^[15]提出基于相对变换的半监督分类算法,经相对变换后的半监督分类算法具有更好的处理稀疏和噪声数据的能力。本文提出的 RTICA 方法,引入基于欧氏距离的相对变换理论,通过计算采样数据之间的欧氏距离,将原始空间数据变换到相对空间作为新数据。然后,在相对空间进行 ICA 处理,降低相对空间的维数,提取含有主要信息的独立主元分量,从而建立故障检测模型,实现在线监测。在该方法中,相对变换本身是非线性放大变换,可有效区分近似相等数据,优化数据之间的可区分性,提高故障检测精度和检测率。

通过对 TE 过程的仿真实验验证了本文提出的 RTICA 方法可以有效减少独立主元个数,节省运算时间,提高故障检测精度;通过电主轴系统裂纹故障实验可得出 RTICA 方法真实有效,具有一定的实际研究价值。

2 基于 RTICA 的故障检测方法

2.1 相对变换

相对变换^[13]是根据认知的相对性规律提出的一种数据处理方法,它是将抽象的信号数据转化为容易理解的数据之间的距离,它将原始空间数据转换到相对空间,在相对空间中虽然仍采用原来的距离公式,但计算出的距离数据因为考虑了所有数据点的影响,使噪声数据和孤立点远离正常点,并起到一定的抑制噪声的能力。

以原始数据空间中的每个数据点作为基向量来构造新的相对空间,这样任意点 x 到所有点的距离就构成该点在新空间中的坐标,这个过程称为相对变换。

$$\Gamma: \mathbf{X} \rightarrow \mathbf{Y} \subset \mathbb{R}^{|X|} \quad (1)$$

$$\Gamma_x(x_i): (d_{i1}, d_{i2}, \dots, d_{i|X|}) = \mathbf{y}_i \in \mathbf{Y} \quad (2)$$

设 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{|X|}\}$; $|X|$ 为集合 X 的元素个数; d_{ij} 为相对变换中两个数据点之间的相对距离。

定义:给定训练集 \mathbf{X} ,它有 n 个观测值, m 个过程变量。 $\mathbf{X} = [\mathbf{x}_1^T, \mathbf{x}_2^T, \dots, \mathbf{x}_n^T], \mathbf{x}_i \in \mathbb{R}^m$ 。采样点 i 到采样点 j 之间的欧氏距离为:

$$d_e(\mathbf{x}_i, \mathbf{x}_j) = ((\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j))^{1/2} \quad (3)$$

欧氏距离的性质如下:

性质 1 当且仅当 $i = j$ 时, $d_e(\mathbf{x}_i, \mathbf{x}_j) = 0$;

性质 2 当 $i \neq j$ 时, $d_e(\mathbf{x}_i, \mathbf{x}_j) > 0$;

性质 3 $d_e(\mathbf{x}_i, \mathbf{x}_j) = d_e(\mathbf{x}_j, \mathbf{x}_i)$;

性质 4 $d_e(\mathbf{x}_i, \mathbf{x}_j) \leq d_e(\mathbf{x}_i, \mathbf{x}_k) + d_e(\mathbf{x}_j, \mathbf{x}_k)$ 。

定理 1 相对变换不是等距变换,而是一种放大变换。即 $\forall_{x_i, x_j \in X}, d(\mathbf{x}_i, \mathbf{x}_j) \leq d(\mathbf{x}'_i, \mathbf{x}'_j)$, 其中 X 为原始数据矩阵, \mathbf{x}'_i 为相对变换后的向量。

证明: $\mathbf{x}'_i = (d(\mathbf{x}_i, \mathbf{x}_1), d(\mathbf{x}_i, \mathbf{x}_2), \dots, d(\mathbf{x}_i, \mathbf{x}_n))$,

$$\text{其中 } d(\mathbf{x}_i, \mathbf{x}_1) = ((\mathbf{x}_i - \mathbf{x}_1)^T (\mathbf{x}_i - \mathbf{x}_1))^{1/2}, d(\mathbf{x}'_i, \mathbf{x}'_j)^2 =$$

$$\sum_{k=1}^n (d(\mathbf{x}_i, \mathbf{x}_k) - d(\mathbf{x}_i, \mathbf{x}_j))^2 =$$

$$\sum_{k=1}^n (((\mathbf{x}_i - \mathbf{x}_k)^T (\mathbf{x}_i - \mathbf{x}_k))^{1/2} - ((\mathbf{x}_j - \mathbf{x}_k)^T (\mathbf{x}_j - \mathbf{x}_k))^{1/2})^2 =$$

$$\sum_{k=1, k \neq j}^n (((\mathbf{x}_i - \mathbf{x}_k)^T (\mathbf{x}_i - \mathbf{x}_k))^{1/2} - ((\mathbf{x}_j - \mathbf{x}_k)^T (\mathbf{x}_j - \mathbf{x}_k))^{1/2})^2 +$$

$$(((\mathbf{x}_i - \mathbf{x}_k)^T (\mathbf{x}_i - \mathbf{x}_k))^{1/2} - ((\mathbf{x}_j - \mathbf{x}_k)^T (\mathbf{x}_j - \mathbf{x}_k))^{1/2})_{k=j}^2 =$$

$$\sum_{k=1, k \neq j}^n (((\mathbf{x}_i - \mathbf{x}_k)^T (\mathbf{x}_i - \mathbf{x}_k))^{1/2} - ((\mathbf{x}_j - \mathbf{x}_k)^T (\mathbf{x}_j - \mathbf{x}_k))^{1/2})^2 +$$

$$(\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j) \geq (\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j)$$

$$\text{又} \because d(\mathbf{x}_i, \mathbf{x}_j)^2 = (\mathbf{x}_i - \mathbf{x}_j)^T (\mathbf{x}_i - \mathbf{x}_j)$$

$$\therefore d(\mathbf{x}'_i, \mathbf{x}'_j)^2 \geq d(\mathbf{x}_i, \mathbf{x}_j)^2,$$

证毕。

由于相对变换不是等距变换,而是具有放大作用的变换,这更有利于观测出故障数据。

另一方面,必须保证原始数据矩阵经过欧式距离相对变换前后能量守恒,否则不能保证相对变换后的数据矩阵和变换前的数据矩阵性质一致。因此,我们需要对此结论进行证明,在信号分析中能量守恒常用范数不变来体现。

定理 2 原始数据矩阵经过欧式距离相对变换前后能量守恒,即 $\|\mathbf{X}\|_2^2 = M \|\mathbf{X}^R\|_2^2$ 。

证明:给定数据集 $\mathbf{X} = \{\mathbf{x}_i, i = 1, 2, \dots, n\}$, $\mathbf{x}_i \in \mathbb{R}^m$ 为第 i 个采样,该数据集的重心(采样数据的均值矩阵)为 $\bar{\mathbf{X}} = (\bar{\mathbf{x}}_1, \bar{\mathbf{x}}_2, \dots, \bar{\mathbf{x}}_n)$ 。

令 $d_e^2(\mathbf{x}_i, \mathbf{x}_j) = d_e^2(\mathbf{x}_i, \bar{\mathbf{X}}) + d_e^2(\mathbf{x}_j, \bar{\mathbf{X}}) + 2d_e(\mathbf{x}_i, \bar{\mathbf{X}})d_e(\mathbf{x}_j, \bar{\mathbf{X}})$, 其中 $d_e(\mathbf{x}_i, \mathbf{x}_j)$ 表示向量 \mathbf{x}_i 和 \mathbf{x}_j 之间的欧式距离。

$$\begin{aligned} d_e(\mathbf{x}_i, \bar{\mathbf{X}})d_e(\mathbf{x}_j, \bar{\mathbf{X}}) &= \\ \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n (\mathbf{x}_i - \bar{\mathbf{X}})(\mathbf{x}_j - \bar{\mathbf{X}})^T &= \\ \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{X}}) \sum_{j=1}^n (\mathbf{x}_j - \bar{\mathbf{X}})^T &= \\ \frac{1}{n} \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{X}})(n\bar{\mathbf{X}} - n\bar{\mathbf{X}})^T &= 0 \\ \|X^R\|_2^2 &= \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n d_e^2(\mathbf{x}_i, \mathbf{x}_j) = \\ \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n d_e^2(\mathbf{x}_i, \bar{\mathbf{X}}) + \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n d_e^2(\mathbf{x}_j, \bar{\mathbf{X}}) &= \\ \frac{1}{n} \sum_{i=1}^n d_e^2(\mathbf{x}_i, \bar{\mathbf{X}}) + \frac{1}{n} \sum_{j=1}^n d_e^2(\mathbf{x}_j, \bar{\mathbf{X}}) &= \\ \sum_{i=1}^n \sigma_i^2 + \sum_{j=1}^n \sigma_j^2 &= 2 \sum_{i=1}^n \sigma_i^2 = 2 \sum_{i=1}^n \text{var}(\mathbf{x}_i) \end{aligned}$$

$$\text{此外, } \sum_{i=1}^n \text{var}(\mathbf{x}_i) =$$

$$\begin{aligned} \sum_{i=1}^n E\{\mathbf{x}_i^2\} &= E\{\text{tr}(\mathbf{XX}^T)\} = E\{\text{tr}(\mathbf{XX}^T)\} = \\ E\{\text{tr}(\mathbf{X}^T \mathbf{X})\} &= E\{\text{tr}(\mathbf{X}^T \mathbf{P} \mathbf{P}^T \mathbf{X})\} = E\{\text{tr}(\mathbf{T} \mathbf{T}^T)\} = \\ \sum_{j=1}^n E\{\mathbf{T}_j^2\} &= \|\mathbf{T}\|_2^2 \end{aligned}$$

其中 \mathbf{T} 为主元分析中主元得分^[16], 根据文献[16]可知, PCA 变换前后能量守恒,

$$\text{可得 } \|\mathbf{T}\|_2^2 = \|\mathbf{X}\|_2^2,$$

$$\text{因此 } \|X^R\| = 2\|X^R\|_2 = M\|X^R\|_2,$$

此时 $M = 2$ 。

$$\text{所以 } \|X^R\| = M\|X\|_2,$$

证毕。

相对变换中采用的距离有多种, 例如欧式距离^[17]、Chebychev 距离^[18]、Manhattan 距离^[19]、Minkowsky 距离^[20]、Mahalanobis 距离^[21]等。他们的公式分别为:

$$d_e(\mathbf{x}, \mathbf{y}) = \sqrt{\sum_{i=1}^n (\mathbf{x}_i - \mathbf{y}_i)^2} \quad (4)$$

$$d_e(\mathbf{x}, \mathbf{y}) = \max_{i=1}^n |\mathbf{x}_i - \mathbf{y}_i| \quad (5)$$

$$d_{man}(\mathbf{x}, \mathbf{y}) = \sum_{i=1}^n |\mathbf{x}_i - \mathbf{y}_i| \quad (6)$$

$$d_{min}(\mathbf{x}, \mathbf{y}) = \sqrt[p]{\sum_{i=1}^n |\mathbf{x}_i - \mathbf{y}_i|^p} \quad (7)$$

$$d_{mah}(\mathbf{x}, \mathbf{y}) = |\Delta C|^{(1/n)} (\mathbf{x} - \mathbf{y})^T C^{-1} (\mathbf{x} - \mathbf{y}) \quad (8)$$

每种度量距离方法都有不同的特点, 根据文贵华^[22]在面向机器学习的相对变换文中的研究可知, 欧式距离在原始空间的区分能力是最好的。在正常的操作当中, 随着样本数的增加距离度量能力是相对减弱的, 而欧式

距离是减弱最不明显的一个。因此本文采用欧式距离作为相对变换的量度, 更有效的提高了故障检测效率。

2.2 ICA

在实际工况中,许多情况下先验知识是很难获取的,对于不要求先验知识的问题被称为盲源信号分离问题(BSS)^[23], ICA 的发展和盲源信号分离是紧密相连的, ICA 便是一种处理 BSS 问题的有效方法。

ICA 是多通道信号的处理方法, 它将采集到的多通道观测数据分离成相互独立的信源, 并在保留主要原始数据的基础上实现降维。ICA 的原理结构如图 1 所示。

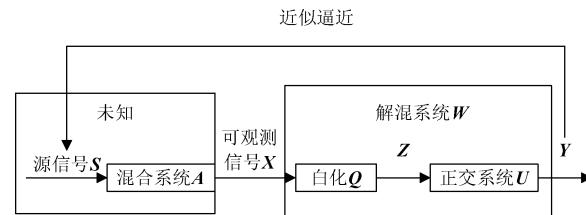


图 1 ICA 原理结构

Fig. 1 ICA principle structure

图 1 中, S 为原始信号源, X 为可观测信号, A 为混合矩阵。

ICA 的任务是在 S 与 A 未知的情况下, 求解矩阵 W , 使得到的 Y 最优逼近信号源 S 。在 ICA 处理之前, 首先要消除数据的二阶相关性, 用到的方法是白化处理, 又称球化处理, 公式如下:

$$\mathbf{V} = \mathbf{A}^{-1/2} \mathbf{U}^T \quad (9)$$

$$\mathbf{Q} = \mathbf{VX} \quad (10)$$

式中: $\mathbf{A} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_n)$, $\lambda_i (i = 1, \dots, n)$ 为协方差矩阵 $E\{\mathbf{XX}^T\}$ 的前 n 个特征值(特征值按大小顺序从大到小排列), \mathbf{U} 为特征值对应的特征向量矩阵。

ICA 算法的主要步骤如下所示:

- 1) 对观测数据 X 进行标准化, 使它均值为 0;
- 2) 对数据进行白化处理;
- 3) 选择一初始随机权向量 $w(0)$, 令 $k = 1$;
- 4) 令 $w(k) = E\{vg(w(k-1)^T \mathbf{x})\} - E\{g(w(k-1)^T \mathbf{x})\}w(k-1)$, 向量 v 是均值为 0, 方差为 1 的高斯分布变量, 函数 g 为非二次函数 G 的一阶导数, 算子 E 表示数学期望, 可以通过采样值去估计;
- 5) 归一化处理, 即 $w(k) = w(k) / \|w(k)\|$;
- 6) 若 $1 - |w(k)^T w(k-1)| \geq \varepsilon$, 令 $k = k + 1$, 转回步骤 4), 否则输出向量 $w(k)$ 。

通过上述步骤可以得到一个独立分量, 经过不断重复获取 p 个列向量 w_1, w_2, \dots, w_p , 即分离矩阵 W , 通过式(11)得到近似矩阵 Y 。

$$Y = XW \quad (11)$$

在此数据基础上进行故障检测, 有较好的故障检测

效果和实用性。解决了先验知识难以获取的问题,以及非高斯性、非线性、独立性的相关问题。

2.3 基于RTICA的故障检测方法

基于欧氏距离相对变换的ICA方法是通过求取采样点之间的欧式距离,将原始数据空间转换到相对空间,然后在相对空间中进行ICA建模。欧式距离虽然是相对变换中效果最好的距离公式,但是依然存在一些缺点,例如它将不同样本的属性同等看待,没有考虑变量的数量级等问题,所以在相对变换之前需要标准化处理。经过相对变换后的数据降低了相似性,增加了数据之间的可分性,它不是等距变换,而是具有放大作用的变换。因此RTICA方法能保留更多的数据信息,使得故障检测效果更加明显,检测效率更高。

基于RTICA故障检测方法的具体步骤如下。

1) 标准化处理

给定训练集 $X_{m \times n}$ (m 为采样数, n 为变量数), 通过式(12)进行标准化, 得到 Z_{ij} 。

$$Z_{ij} = \frac{1}{n-1}(X_{ij} - \bar{X}_j)/\sigma_j \quad (12)$$

式中: \bar{X}_j 为矩阵均值, σ_j 为每一列的标准差。

2) 相对变换

将标准化后的训练数据, 经欧式距离公式(式(4))变换到相对空间, 数据由原来的 $m \times n$ 矩阵变换为 $n \times n$ 矩阵。

3) ICA建模

(1) 对数据进行白化处理, 去除变量间耦合, 得到白化矩阵 Q 这一步在ICA中已逐渐被PCA取代;

(2) 通过独立主元分析, 得到 d 个主要独立主元成分, e 个残差独立主元成分, 以及相应的分离矩阵 W_d, W_e ;

(3) 通过下列公式实现建模:

$$\hat{s}_{newd}(k) = W_d x_{new}(k) \quad (13)$$

$$\hat{s}_{newe}(k) = W_e x_{new}(k) \quad (14)$$

其中 $x_{new}(k)$ 为某一时刻新采集的数据。

4) 求解统计量及控制限

ICA方法有3个统计量, 分别为 I^2, I_e^2, SPE , 计算公式分别如下:

$$I^2(k) = \hat{s}_{newd}^T(k) \hat{s}_{newd}(k) \quad (15)$$

$$I_e^2(k) = \hat{s}_{newe}^T(k) \hat{s}_{newe}(k) \quad (16)$$

$$SPE(k) = e(k)^T e(k) = (x_{new}(k) - \hat{x}_{new}(k))^T \times (x_{new}(k) - \hat{x}_{new}(k)) \quad (17)$$

由于经过相对变换和ICA分离出的独立成分不服从高斯分布, 所以很难用某一个近似分布来确定3个统计量的控制限。因此, 引入核密度估计方法^[24]来实现求取控制限。核密度估计公式定义为:

$$\hat{f}(\mathbf{x}) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{\mathbf{x} - \mathbf{x}_i}{h}\right) \quad (18)$$

其中 $K(\cdot)$ 通常选取高斯核函数 $K(\mathbf{x}) = (2\pi)^{-p/2} \exp(-\mathbf{x}^T \mathbf{x}/2)$, 通过核密度估计可以得到 I^2, I_e^2, SPE 概率密度函数, 根据 99% 的置信区间确定临界值, 即控制限 $I_{limit}^2, I_{e limit}^2, SPE_{limit}$ 。

5) 对新观测数据故障检测

首先对新采集的数据标准化和白化预处理, 然后将预处理后的数据相对变换到相对空间, 在相对空间进行ICA处理, 求取新的统计量 $I_{new}^2, I_{e new}^2, SPE_{new}$, 并和步骤4)中获得的控制限比较, 超过控制限的视作故障数据, 低于控制限的视为正常数据, 以此来判断是否有故障发生。

故障检测流图如图2所示。

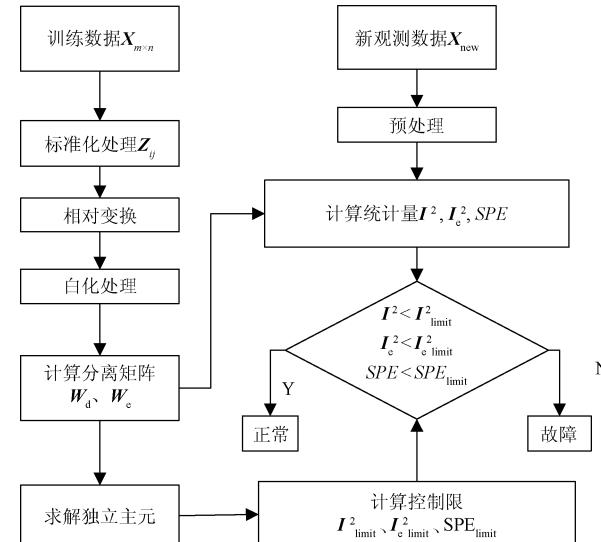


图2 RTICA故障检测流程

Fig. 2 Flow chart of RTICA fault detection

2.4 离线建模计算复杂度分析

由于欧式距离是将不同样本的属于同等看待, 而且没有考虑变量的数量级差别, 因此, 在相对变换之前需要进行标准化处理。基于RTICA方法在离线建模时, 将输入矩阵 $X_{m \times n}$ (m 为采样数, n 为变量数) 经过标准化处理后进行欧式距离相对变换, 变换到相对空间的矩阵为 $m \times m$ 维, 相比于原始空间数据规模是变大了, 因此, RTICA的处理时间比ICA是相对增加的。但是, 由于ICA故障检测模型和RTICA故障检测模型都是在离线状态下建立的, 所以离线建模的计算复杂度和建模时间不会影响在线监测的实时性。

3 仿真实验和结果分析

3.1 基于RTICA方法的TE过程故障仿真

在验证故障检测方法的过程中, 往往不能确定用作

样本的数据是否合适有效,因此采用 TE 过程数据包作为验证数据。TE 过程是伊斯曼化学公司创建的,其目的是为评价过程控制和监控方法的有效性的工业过程,TE 数据包已在过程监控领域得到了广泛应用。TE 过程包括 12 个控制变量和 41 个测量变量,以及 21 个预设定的故障工况(16 个已知故障,5 个未知)。

以 TE 数据故障一为例分析 RTICA 的故障检测效果,并与 ICA 方法检测结果相比较。TE 数据包含训练集和测试集两个部分,训练集包含 480 组数据,测试集包含 960 组数据,每组观测值都有 52 个过程变量。训练数据是正常工况下采集的数据,可用来训练建模,测试数据是在正常工况下运行,后续引入故障的数据。图 3 和 4 所示分别是 ICA 和 RTICA 对故障一的检测结果。

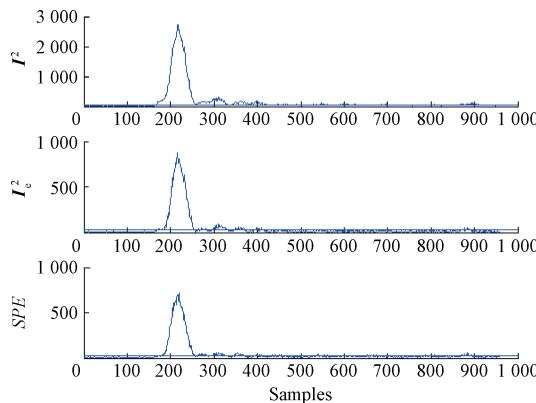


图 3 基于 ICA 方法的故障检测

Fig. 3 Fault detection based on ICA method

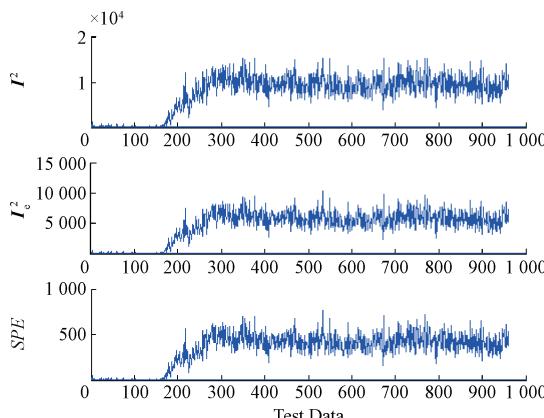


图 4 基于 RTICA 方法的故障检测

Fig. 4 Fault detection based on RTICA method

图 4 中水平横线为统计量阈值,超过阈值的为故障数据。故障是在第 161 点引入的,RTICA 方法准确的检测出第 161 点的故障,以及后续的故障数据,而 ICA 算法是在第 163 点检测到故障,并在第 400 点以后基本检测不到,这说明 ICA 算法还是存在一些缺陷,RTICA 方法恰

好能解决这个问题,弥补了 ICA 的不足。

由表 1 可见,与 ICA 方法相比,基于 RTICA 的故障检测效果好很多,3 个统计量的检测率高达 98% 以上,运行时间与 ICA 运算时间相差无几。基于相对变换后的故障数据和正常数据之间的相对距离变大,促使独立主元分析更好地检测出故障数据,并且拥有模型简单、容易理解、检测精度高等优点。

表 1 基于 ICA 和 RTICA 方法的故障检测效果比较

Table 1 Fault detection results based on ICA and RTICA methods

方法	统计量	检测率/%	在线检测时间/s
基于 ICA 故障检测方法	I^2	49.88	0.299 1
	I_e^2	44.52	
	SPE	47.63	
基于 RTICA 故障检测方法	I^2	99.68	0.266 8
	I_e^2	98.17	
	SPE	98.78	

3.2 基于 RTICA 方法在电主轴系统故障应用研究

电主轴系统属于高精密设备,及时检测故障并加以维修对生产高精度产品有非常重要的意义。本次实验以电主轴裂纹故障作为研究对象,应用 AIC9900 设备故障综合模拟诊断分析系统软件采集分析数据。在正常工况下采集 1000 组正常数据用于离线训练,建立模型,在线采集 400 组数据进行检测,并在第 51 个采样点加入故障。

基于 ICA 和基于 RTICA 的故障检测结果如图 5、6 所示。

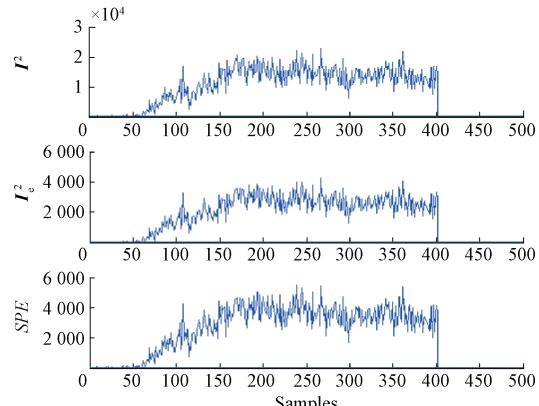


图 5 基于 ICA 方法对电主轴裂纹故障检测

Fig. 5 Fault detection based on ICA for electric spindle crack

通过 3 个统计量的效果图比较(表 2)可见,ICA 方法在第 55~60 采样点上能够检测出故障,以及第 60 采样点之后的故障数据都能检测出来,故障检测率达到 97.63%。经过相对变换后的 ICA 方法不仅节约时间,而且和统计量对故障数据的敏感度高达 100%,因此 RTICA 故障检测方法检测效率更高,效果更好。

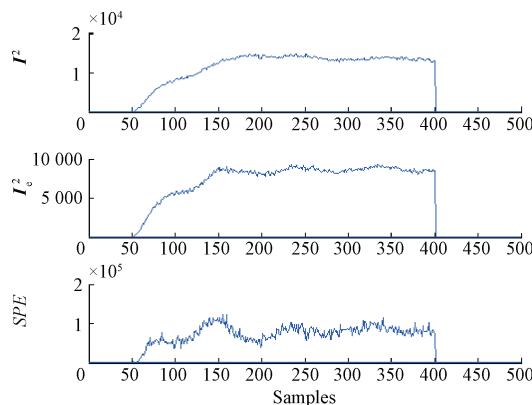


图6 基于RTICA方法对电主轴裂纹故障检测
Fig.6 Fault detection diagram based on RTICA
for electric spindle crack

表2 基于ICA和RTICA方法对电主轴裂纹
故障检测效果比较

Table 2 Fault detection results based on ICA and RTICA
methods for electric spindle crack

方法	统计量	检测率/%	在线检测时间/s
基于 ICA 故障检 测方法	I^2	96.68	5.299 1
	I_e^2	97.52	
	SPE	97.63	
基于 RTICA 故障 检测方法	I^2	100	4.766 8
	I_e^2	100	
	SPE	99.38	

4 结论

在实际工业过程中,故障检测方法所依赖的先验信息往往难以获取,且原始信号分量相互独立,基于这种问题,ICA 提供了一个有效可行的解决途径。但是,传统的ICA方法在标准化处理后出现特征值大小近似相等,难以提取有代表性变量等问题。为了解决这些问题,本文提出了一种基于RTICA故障检测方法。该方法通过引入欧氏距离相对变换理论,将原始空间数据变换得到相对空间,然后在相对空间进行独立主元分析,建立故障检测模型,最终实现在线故障检测。经过相对变换后的数据不仅降低了数据维数,简化运算,而且使提取的独立主元特征具有更大的适应性。该方法通过田纳西-伊斯曼过程仿真加以验证,并应用到电主轴裂纹故障的状态监测中,实验结果表明该方法能有效减少独立主元个数,简化故障检测模型的复杂度,增强状态检测性能,具有一定研究价值。

参考文献

- [1] ABDI H, WILLIAMS L J. Principal component analysis[J]. Wiley Interdisciplinary Reviews Computational Statistics, 2010, 2(4):433-459.
- [2] SHLENS J. A tutorial on principal component analysis[J]. Computer Science, 2014, 51(3):219-226.
- [3] ERHARDT E B, RACHAKONDA S, BEDRICK E J, et al. Comparison of multi-subject ICA methods for analysis of fMRI data [J]. Human Brain Mapping, 2011, 32(12):2075-2095..
- [4] 肖宾杰. 基于独立成分分析的指静脉识别研究[J]. 电子测量与仪器学报, 2012, 26(10):841-845.
XIAO B L. Study of finger vein identification based on independent component analysis[J]. Journal of Electronic Measurement and Instrument, 2012, 26(10):841-845.
- [5] ARORA S, GE R, MOITRA A, et al. Provable ICA with unknown gaussian noise, and implications for Gaussian mixtures and autoencoders [J]. Algorithmica, 2015, 72(1):215-236.
- [6] HULLAND J. Use of partial least squares (PLS) in strategic management research: a review of four recent studies [J]. Strategic Management Journal, 2015, 20(2):195-204.
- [7] PERDOMO-ORTIZ A, FLUEGEMANN J, NARASIMHAN S, et al. A quantum annealing approach for fault detection and diagnosis of graph-based systems[J]. The European Physical Journal Special Topics, 2015, 224(1):131-148.
- [8] CHIROMA H, ABDULKAREEM S, HERAWAN T. Evolutionary neural network model for west texas intermediate crude oil price prediction [J]. Applied Energy, 2015, 142(3):266-273.
- [9] JUN B, KIM T, KIM D. A compact local binary pattern using maximization of mutual information for face analysis[J]. Pattern Recognition, 2011, 44(3):532-543.
- [10] VOSS J, RADEMACHER L, BELKIN M. Fast algorithms for Gaussian noise invariant independent component analysis[C]. Advances in Neural Information Processing Systems, 2013:2544-2552.
- [11] 张曦, 朱亚清, 阎威武, 等. 基于独立主元分析的汽轮机性能监测与评估[J]. 控制工程, 2012, 19(1):30-32.
ZHANG X, ZHU Y Q, YAN W W, et al. Performance monitoring and assessment of generator based on independent component analysis [J]. Control Engineering, 2012, 19(1):30-32.

- [12] 韩敏, 姜力文, 赵耀. 基于 PSO-ICA 和 RBF 神经网络的转炉炼钢终点预报模型[J]. 信息与控制, 2010, 39(1):82-87.
- HAN M, JING L W, ZHAO Y. Endpoint prediction model of basic oxygen furnace steelmaking based on PSO-ICA and RBF neural network [J]. Information and Control, 2010, 39(1):82-87.
- [13] 石怀涛, 刘建昌, 张羽, 等. 基于相对变换 PLS 的故障检测方法[J]. 仪器仪表学报, 2012, 33(4):816-822.
- SHI H T, LIU J CH, ZHANG Y, et al. Fault detection method based on relative-transformation partial least squares [J]. Chinese Journal of Scientific Instrument, 2012, 33(4):816-822.
- [14] 石怀涛, 刘建昌, 张颖伟, 等. 基于相对变换的主元分析故障诊断[J]. 华中科技大学学报:自然科学版, 2009(S1):70-73.
- SHI H T, LIU J CH, ZHANG Y W, et al. Fault diagnosis in industry process based on relative transformation principal component analysis [J]. Journal of Huazhong University of Science and Technology: Natural Science Edition, 2009(S1):70-73.
- [15] 易森, 刘小兰. 基于相对变换的半监督分类算法[J]. 计算机应用, 2011, 31(10):2793-2795.
- YI M, LIU X L. Semi-supervised classification algorithm based on relative transformation [J]. Journal of Computer Applications, 2011, 31(10):2793-2795.
- [16] YU H, GUO J, LI J, et al. Zero drift and solid earth tide extracted from relative gravimetric data with principal component analysis [J]. Geodesy and Geodynamics, 2015, 6(2):143-150.
- [17] DRAISMA J, HOROBET E, OTTAVIANI G, et al. The Euclidean Distance degree of an algebraic variety [J]. Foundations of Computational Mathematics, 2016, 16(1):99-149.
- [18] VE T, LIN T T, TSAI S C, et al. Permutation arrays under the Chebyshev distance[J]. IEEE Transactions on Information Theory, 2010, 56(6):2611-2617.
- [19] KOCIUMAKA T, PACHOCKI J W, RADOSZEWSKI J, et al. On the string consensus problem and the manhattan sequence consensus problem [C]. International Symposium on String Processing & Information Retrieval, 2014:244-255.
- [20] HU L Y, HUANG M W, KE S W, et al. The distance function effect on k-nearest neighbor classification for medical datasets[J]. Springer Plus, 2016, 5(1):1304.
- [21] 郑宏亮, 王建英. 一种基于 Mahalanobis 距离的增量聚类算法[J]. 计算机应用与软件, 2011, 28(12):38-40.
- ZHENG H L, WANG J Y. An incremental clustering algorithm based on Mahalanobis distance [J]. Computer Applications and Software, 2011, 28(12):38-40.
- [22] SUN Y X, WEN G H. Cognitive gravitation model-based relative transformation for classification [J]. Soft Computing, 2016, doi:10.1007/s00500-016-2131-0.
- [23] 赵伟, 陈伟杰, 黄秀节. 改进的 FastICA 在盲图像分离中的应用[J]. 国外电子测量技术, 2010, 29(5):70-72.
- ZHAO W, CHEN W J, HUANG X J. Application of blind image separation based on improved FastICA algorithm [J]. Foreign Electronic Measurement Technology, 2010, 29(5):70-72.
- [24] 张保强, 陈国平, 郭勤涛. 结构动力学模型确认问题的核密度估计方法[J]. 机械工程学报, 2011, 47(17):29-36.
- ZHANG B Q, CHEN G Q, GUO L T. Structural dynamic model validation problem solution using kernel density estimation method [J]. Journal of Mechanical Engineering, 2011, 47(17):29-36.

作者简介



石怀涛, 1982 年出生, 分别在 2005 年和 2012 年于东北大学取得学士学位和博士学位, 沈阳建筑大学副教授, 机械工程学院副院长, 主要研究方向为智能电主轴系统开发优化与控制和工业系统故障检测与诊断。
E-mail: sht@sjzu.edu.cn

Shi Huaitao was born in 1982, received B. Sc. and Ph. D. from Northeastern University in 2005, 2012, respectively. Now he is an associate professor of Shenyang Jianzhu University. His main research interest includes development of intelligent spindle system optimization and control, and industrial system fault detection and diagnosis.



周乾, 1990 年出生, 2013 年于山东理工大学取得学士学位, 现为沈阳建筑大学研究生, 主要研究方向为电主轴故障诊断。
E-mail: yongqianzhou@126.com

Zhou Qian was born in 1990, received B. Sc. from Shandong University of Technology in 2013. Now he is a M. Sc. candidate in Shenyang Jianzhu University. His main research interest is fault diagnosis of electric spindle.