

样本空间基于多级高维特征表示的微小故障诊断

张彩霞^{1,3}, 王子涵², 文成林², 刘国文^{1,3}, 余 伟^{1,3}

(1. 佛山科学技术学院机电工程与自动化学院, 广东佛山 528000; 2. 杭州电子科技大学自动化学院, 浙江杭州 310018
3. 广东省智慧城市基础设施健康监测与评估工程技术研究中心, 广东佛山 528000)

摘 要: 传统主元分析(Principal Component Analysis, PCA)、相对主元分析等多元统计法基于阈值诊断故障, 由于是原空间等价表示, 并未增加任何信息量, 使得微小故障难以诊断; 且降维分成主元空间和残差空间, 微小信息得不到充分表示. 深度学习在模式识别方面有成功的应用, 深度学习多层次网络对细节进行线性组合表示, 但不具备可解释性, 仅有训练结果无理论依据, 机理分析困难. 本文提出一种将主元分析思想与深度学习思想结合的故障诊断方法, 在原 PCA 基础上先扩维再降维, 使得原始空间中不能表达的信息充分表达, 且具备可解释性. 理论和仿真实验分析表明, 本文方法能判断出传统 PCA 无法检测的微小故障, 提高了故障检测的检出率, 且具备可解释性.

关键词: 多级高维; 主元分析; 投影标架; 故障诊断

中图分类号: TP273 **文献标识码:** A **文章编号:** 0372-2112(2020)08-1647-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2020.08.026

Sample Space Based on Multi-level High Dimensional Feature Representation Micro-fault Diagnosis

ZHANG Cai-xia^{1,3}, WANG Zi-han², WEN Cheng-lin², LIU Guo-wen^{1,3}, YU Wei^{1,3}

(1. School of Mechatronic Engineering and Automation, Foshan University, Foshan, Guangdong 528000, China;
2. Automatic School, Hangzhou University, Hangzhou, Zhejiang 310018, China;
3. Guangdong Province Smart City Infrastructure Health Monitoring and Evaluation Engineering Technology Research Center, Foshan, Guangdong 528000, China)

Abstract: Traditional principal component analysis, relative principal component analysis and other multivariate statistical methods based on threshold to do the fault diagnosis. Since multivariate statistical method is an equivalent representation of the original space, it does not add any amount of information, making it difficult to diagnose minor faults. And the original space is reduced dimensionally into the principal component space and the residual space, so that the tiny information cannot be fully expressed. Deep learning has been successfully applied in pattern recognition. However, multilevel networks of deep learning represent linear combinations of details but do not have explanatory. Only with the result of training without theoretical basis, it is difficult to carry out mechanistic analysis. This paper presents a fault diagnosis method which combines PCA thought and deep learning thought. Based on the original PCA, this paper first expands and then reduces the dimension, making the inexplicit information in the original space fully expressed and interpreted. Theoretical and simulation experiments show that this method can judge the minor faults which cannot be detected by traditional PCA, improve the detection rate of fault detection and have interpretability.

Key words: multilevel high-dimensional; principal component analysis; projection frame; fault diagnosis

1 引言

复杂工业系统设备复杂化、系统集成化、规模大型化趋势日益突出, 使得故障信号具有隐蔽性特点, 及时

有效的检测出故障并采取措施, 能够提高生产效率、提升产品质量、减少经济损失和不必要的人身伤亡. 因此, 提高复杂工业系统安全性和可靠性的故障诊断技术越来越受到关注.

收稿日期: 2018-02-22; 修回日期: 2018-06-24; 责任编辑: 蓝红杰

基金项目: 国家自然科学基金(No. 61803087); 广东省基础与应用基础研究基金粤港澳应用教学中心项目(No. 2019KTSCX192); 佛山市核心技术攻关项目(No. 1920001001367); 佛山市科技创新项目(No. 2016AG10011)

现代工业系统中的微小故障通常相对于显著故障而言,具有隐蔽、随机、幅值低、故障特性不明显、易被噪声掩盖、易被较大正常变化淹没的特点^[1]. 通常认为,故障存在前提下,现有诊断方法诊断不出的故障可被视为微小故障. 相对于显著故障,微小故障虽特征不明显,但经过时间积累或设备系统间传播扩散,极易发展为危及系统安全的显著故障. 因此微小故障的及时诊断是保障系统安全并抑制故障恶化的关键因素之一.

统计法通过分析正常历史过程多个过程变量间相关性,建立正常样本估算的监测指标限,并基于该值实时分析在线样本的状态. 主元分析^[2-4]作为典型的多元统计法常用于故障诊断领域,使用 Hotelling T^2 统计量和平方预测误差 (Squared Prediction Error, SPE) 检测过程中是否发生异常. T^2 衡量样本向量在主元空间投影的变化, SPE 衡量在残差空间投影的变化. 针对过程运行特性或监控目标的不同,研究者对传统 PCA 法进行不同程度的拓展,取得了很多相关研究成果,文献[5]针对变量在系统中的不同重要性,提出相对主元方法,通过分析系统的先验信息确定各分量的重要程度,并赋以相应的权值,能更加准确识别故障;文献[6]针对文献[5]控制限只与保留的主元个数和置信度有关的问题,提出和动态数据窗口相结合的方法,减少故障误报;针对 PCA 模式复合效应在微小故障诊断上的局限性,文献[7]提出在指定元空间^[8]投影框架基础上的多级微小故障诊断;鉴于微小故障与正常状态间偏离较小,文献[8]结合概率分布度量,采用 Kullback-Leibler 测量化潜在分数与参照分数间的残差,提出适用于微小故障的 PCA 算法控制限;文献[9]在文献[8]基础上提出通过估计微小故障与噪声接近的量级来辨识微小故障. 文献[10]综述了基于数据驱动的微小故障诊断方法,并从增加新信息、挖掘未利用的隐含信息和采用新数学工具三个角度进行展望. 由于基于 PCA 的故障诊断是将原来空间等价表示,没有增加任何信息量,常造成很多微小故障难以诊断;同时,PCA 将空间降维分成主元空间和残差空间,描述数据主要趋势的变量组合,使得微小信息得不到充分表示^[11].

深度学习可通过多层次网络对细节进行线性组合表示,在模式识别方面有成功应用^[12-15]. 基于过程监测的深度学习,通过高阶网络表示潜在故障,用于故障信号诊断^[16],其中,SSAE (Stacked Sparse Auto-Encoder) 网络^[12,16,17]因具有较强的无监督学习能力,能监测细节和微小故障的变化而被广泛应用. 文献[18]提出深度学习隐层的相关性用 PCA 描述,得到不错检测效果. 但深度学习关注模式分类^[19],在数学原理上具有不可解释性,仅有训练结果,无理论依据,机理分析较困难.

基于以上分析,本文提出一种基于样本空间高维

特征表示的微小故障检测方法,既具备基于统计分析的可解释性,又能通过对细节的高阶表示提高微小故障的诊断能力. 首先,将正常数据样本集引入到 PCA 模型生成标准正交投影标架,将基于生成的标准正交排序基首尾相联,在两两相邻基向量之间线性连接线中间插入 i 个向量,从而形成高维特征表示空间的 i 级投影标架. 而后将正常数据样本集向该 i 级投影标架投影并进行 PCA 分析,并求取控制限. 当在线数据到来时,向 i 级投影标架投影,投影后的数据再计算控制限,并与正常数据的控制限进行比较实现故障检测.

2 样本空间的多级高维特征表示原理

PCA 模型通过投影法分析故障,主成分空间检测指标 T^2 和残差空间检测指标 SPE 是常用的 2 种检测指标,通过样本向正常(异常)区域投影后是否超过阈值进行故障诊断,未超出阈值则认为无故障. PCA 模型对正常样本进行零均值单位方差,得到标准化样本构成的矩阵 X ,由 X 的协方差矩阵 S 的特征向量 P ,构成样本空间数值投影空间的标准正交排序基集合,当有新样本数据时,通过投影后是否超过阈值判断是否存在故障.

图 1 给出了服从二元正态分布的样本在 PCA 前后的分布情况. 从几何观点来看,样本均值对应椭圆圆心,样本方差对应一个椭圆区域,样本协方差阵的特征向量决定了椭圆方向,其特征值决定了椭圆大小,协方差阵不同,椭圆大小和方向都不同. 椭圆边界代表了控制限,当样本落入椭圆范围内,则表明无故障发生,当样本落入椭圆外,则表明过程发生了异常.




图1 二维变量的样本分布图

图 1 表示二维变量下一般故障的检测情况,但还存在样本包含故障但因故障太小使得投影值小于检测阈值无法检测的情况,针对该情况,若在两相邻基向量 U_1, U_2 之间线性连接线中间插入一个新的投影空间基向量,则可以检测出该微小故障,分析如下(见图 2).

假设 U_1, U_2 为正常样本数据标准化后生成投影 K_{SPE} ,当在线获取一个新样本(假设附加故障 x),去均值后获得增量,故障 \vec{OC} 在 U_1, U_2 上的投影是分别是 \vec{OA} 与 \vec{OB} ,此时 $|OA| < K_{SPE}, |OB| < K_{SPE}$ (K_{SPE} 是残差空间检测阈值),故障无法被检测出.

如果在两相邻基向量 U_1, U_2 之间线性连接线中间




图2 样本投影分析




图3 二级投影标架

插入一个新的投影空间基向量 U_{12} , \vec{OC} 在 U_{12} 上的投影 OD , 由于 $\vec{OC} \cdot U_1 < \vec{OC} \cdot U_{12}$, $\vec{OC} \cdot U_2 < \vec{OC} \cdot U_{12}$, 因此, 存在 \vec{OC} 在基 U_{12} 上的投影 $|OD| > K_{SPE}$ 的情形, 此时投影值超出了控制限, 则故障可被检测出来。

当样本空间是 n 维变量时, 基于 PCA 模型的故障检测指标如下:

$$\begin{cases} T^2(k) = t^T(k) \Lambda_A^{-1} t(k) = \sum_{i=1}^A \frac{t_i^2(k)}{\lambda_i} \\ Q(k) = \bar{x}^T(k) (I - P_A P_A^T) x^T(k) = \sum_{i=A+1}^n t_i^2(k) \end{cases} \quad (1)$$

类似于二元样本的椭圆分布情况, T^2 定义的正常控制域为一个超椭球, 也即样本的主要变化范围, Q 指标定义的正常控制域为一个超单位圆。任意切面椭圆边界代表了控制限, 当样本落入椭圆范围内, 则表明无故障发生, 当样本落入椭圆外, 则表明过程发生了异常。

样本空间是 n 维变量, 在两两相邻基向量之间线性连接线中间插入一个向量时, 微小故障仍然检测不出的情形下, 需要在新的三个方向上投影, 可以在三个点组成的面上找到最大投影方向, 需要面插值; 如果面插值后仍然检测不出故障, 则可 4 个点及已经组成的多面体内部一定有一个最大的投影方向, 进行插值。

如图 3 所示, 故障 OC ($\angle COB \approx 23^\circ$) 在 U_1, U_2 上的投影均没超过控制限, 无法检测出故障; 向相邻基向量 U_1, U_2 , 中间插入一个向量 U_{12} , ($\angle DOB \approx 45^\circ$)。此时, 故障 OC 分别向向量 U_{12}, U_2 , 投影, 因 $\angle DOC \approx \angle COB$, 投影向量基本相等, 故障在一级投影那里没有充分放大; 在向量 U_1, U_2, U_{12} , 间进行面插值, 需要再增加一个坐标轴 U_{212} , ($\angle EOB \approx 22.5^\circ$), 若此时投影 $|CE| < K_{SPE}$, 则故障可以被检测出。就是说, 有的故障在一级投影标架那里投影大, 可测出; 但另外一个故障在一级投影标架下投影虽然增加, 但是增加的不多, 未超出阈值, 因此检测不出, 需再增加一个坐标轴。依次类推, 当插入的坐标轴越来越多时, 每一维向量都可以找到最近的投影坐标轴, 得到最大的投影向量, 进而将故障进行最有效的表示, 有利于其检测出来。

3 基于多级高维特征的样本空间的投影标架生成

为了更好的描述多级高维特征的样本空间的投影标架生成过程, 给出下面几个定义。

等价投影空间: 采用主元分析的思想将样本空间生成一个与样本空间维数相同的投影空间的标准正交排序基集合, 称为等价投影空间 (U_1, U_2, \dots, U_n) ;

多级投影标架: 将基于样本集合生成的标准正交排序基首尾相联, 在两两相邻基向量之间线性连接线中间插入一个向量、二个向量, \dots, i 个向量, 形成高维特征表示空间的一级、二级、 \dots, i 级投影标架; 如在每个相邻的基向量之间线性连接线中间插入 1 个向量, 获得 1 级投影标架 $(U_1, \alpha_1 U_1 + \beta_1 U_2, U_2, \dots, U_{n-1}, \alpha_{n-1} U_{n-1} + \beta_{n-1} U_n, U_n)$ 进一步表示为 $(U_1, U_2, \dots, U_{2n-1})^{(1)}$

样本数据基于多级投影标架下高维特征表示的故障分析: 假设工业过程正常样本数据 X 通过主元分析法获得相互正交的特征向量组成等价投影空间 (U_1, U_2, \dots, U_n) , 正常数据集基于基础投影空间所得的 SPE 和 T^2 检测不会超过控制限。假设出现故障, $X + \Delta X$ 数据集为正常数据 X 上出现了故障 ΔX , ΔX 故障集的第 k 个分量 $\Delta X(k) = (\Delta x_1(k), 0, \dots, 0)^T$, 在 PCA 模型的标准正交排序基 (U_1, U_2, \dots, U_n) 的投影为 $\alpha_1 U_1 + \beta_1 U_2$, 如图 4。




图4 ΔY 在基础坐标系投影

则该 $\alpha_1 U_1 + \beta_1 U_2$ 基于基础坐标系上的分量非常小, 以至于无法检测出来。在原基础坐标系上增加投影。 $\alpha_1 U_1 + \beta_1 U_2$ 作为新的投影标架, 则故障 ΔY 在该方向上投影最大, 从而超过控制限。

$$U_{12} = \alpha U_1 + \beta U_2 = \alpha U_1 + (1 - \alpha) U_2$$

基于 $\max[U_1^T \begin{bmatrix} \alpha \\ \beta \end{bmatrix}]$, 一定能找到一个值 α , 使 $U_{12} = \alpha U_1 + \beta U_2 = \alpha U_1 + (1 - \alpha) U_2$ 值最大。

即, 在原基础坐标系上无法检测出故障时, 在 U_1, U_2 间线性插值, 一级投影标架下能够获得最大投影进而检测出故障;

同理分析, 若 1 级投影标架下无法检测出故障, 则在 U_1, U_2, U_3 平面内进行面插值可以检测出, 即

$$\max[U^T \begin{bmatrix} \alpha \\ \beta \\ \gamma \end{bmatrix}] \text{ 一定能找到一个值 } \alpha, \text{ 使得 } U^{(2)} = \alpha U_1 + \beta U_2 + \gamma U_3 \text{ 值最大。}$$

若面插值仍检测不出故障, 则有 $U_1, U_2, U_3, U_4, \dots$, 组成的多面体内一定可以找到一点, 使得在该方向上投影最大, 即进行多面体插值, 可以检测出故障。

坐标系 $(U_1, U_2, U_3, \dots, U_n)$, 投影坐标为 $(Y_1, Y_2, Y_3, \dots, Y_n)$, 出现故障后的投影坐标为 $(Y_1^{(1)}, Y_2^{(1)}, Y_3^{(1)}, \dots, Y_n^{(1)})$, 则

$$(Y_1^{(1)}, Y_2^{(1)}, Y_3^{(1)}, \dots, Y_n^{(1)}) - (Y_1, Y_2, Y_3, \dots, Y_n) = (\Delta Y_1, \Delta Y_2, \Delta Y_3, \dots, \Delta Y_n)$$

若 $\Delta Y_i \neq 0$ (其它分量全部为 0), 则该分量在 Y_i 基向量上投影最大;

若 $\Delta Y_i \neq 0, \Delta Y_j \neq 0$, (其它分量全为 0), 在 $\sqrt{\Delta Y_i^2 + \Delta Y_j^2}$ 方向投影最大, 在两两相邻基向量 Y_i, Y_j 之间线性连接线中间插入 $\sqrt{\Delta Y_i^2 + \Delta Y_j^2}$ 一个向量, 在该方向故障投影值最大;

若 $\Delta Y_i \neq 0, \Delta Y_j \neq 0, \Delta Y_k \neq 0$, (其它分量全部为 0), 在相邻基向量 Y_i, Y_j, Y_k 组成的面向量间插入一个向量, 在该方向故障投影值最大;

若 $\Delta Y_i \neq 0, \Delta Y_j \neq 0, \Delta Y_k \neq 0, \Delta Y_l \neq 0$, 4 个分量不为零时, 在相邻基向量 Y_i, Y_j, Y_k, Y_l 组成多面体间插入一个向量, 在该方向故障投影值最大。

4 基于多级高维特征的样本空间的故障诊断

针对利用传统 PCA 算法用于故障检测时, 由于特征提取不明显, 对征兆微小而被淹没在噪声中的故障或较大正常过程变化淹没的故障会显得不适用; 同时, 针对基于深度学习的故障诊断无法进行机理分析的问题, 本文在原来 PCA 基础上先扩维, 将在原始空间中不能表达的信息通过扩维时进行充分表达, 可在原投影的基础上增加一个投影, 二个投影, \dots , 依次类推. 从而形成高维特征表示空间的 i 级投影标架, 并基于该多级投影标架进行微小故障检测研究。

4.1 一级投影标架生成

4.1.1 投影空间的标准正交排序基生成

主元分析^[13,14]是一种常用的多元统计分析方法. 采用主元分析的思想生成样本空间维数相同的投影空间的标准正交排序基集合, 主要过程如下:

首先, 获得工业现场 m 个传感器进行的 n 次独立采样所构成的正常历史测量数据矩阵 X_0 , 其中, 矩阵 X_0 每一行代表一次样本, 每一列代表一个传感器 n 次测量的数据。

为了消除因量纲不同引起的主元分析误差的影响, 在主元分析前需进行相应的标准化处理 (零均值单位方差). 第 j 个时刻采集到的数据样本, 将数据样本中第 k 个传感器测量变量 $\hat{x}_k(j)$ 减去示第 k 个变量的样本均值 $E(\hat{x}_k)$, 而后除以该变量的样本方差, 即可得到该变量该时刻的零均值单位方差, 具体计算如下:

$$x_k(j) = \frac{\hat{x}_k(j) - E(\hat{x}_k)}{\text{var}^{1/2}(\hat{x}_k)}, \quad k = 1, 2, \dots, m; j = 1, 2, \dots, n \quad (2)$$

将采集到的数据样本 $x_k(j)$ 全部进行标准化处理后, 可以得到由标准化样本构成的矩阵 \bar{X}_0 ,

$$\bar{X}_0 = \begin{pmatrix} x_{01}(1) & x_{02}(1) & \dots & x_{0m}(1) \\ \vdots & \vdots & \ddots & \vdots \\ x_{01}(n) & x_{02}(n) & \dots & x_{0m}(n) \end{pmatrix}$$

X_0 矩阵的协方差矩阵 S_0 为:

$$S_0 = \text{cov}(\bar{X}_0) \approx \frac{1}{m-1} \bar{X}_0^T \bar{X}_0 = U_0^T \Lambda U_0 \quad (3)$$

求出协方差矩阵 S_0 的特征值 λ_0 和特征向量 U_0 , 并将特征值按照从大到小 $\lambda_{01} \geq \lambda_{02} \geq \dots \geq \lambda_{0m} \geq 0$ 的顺序排列, 同时将与特征值对应的特征向量也按照顺序进行排列. 则 $U_0 = (U_{01}, U_{02}, U_{03}, \dots, U_{0m})$ 构成了样本等价投影空间的标准正交排序基集合 U_0 。

4.1.2 一级投影标架

基于样本集合生成的标准正交排序基 $(U_{01}, U_{02}, U_{03}, \dots, U_{0m})$ 首尾相联, 根据本文第 3 部分基于多级高维特征的样本空间的投影标架生成的方法, 在两两相邻基向量之间的线性连接线中间插入一个向量, 得到 $\bar{U}_1 = (U_{01}, \alpha_{01} U_{01} + \beta_{01} U_{02}, U_{02}, \dots, U_{0(n-1)}, \alpha_{0(n-1)} U_{0(n-1)} + \beta_{0(n-1)} U_{0n}, U_{0n})$, 原始数据 X_0 向插入坐标系后的向量 \bar{U}_1 投影, 得到投影矩阵 X_1 , 用 X_1 代替 X_0 , 按照 3.1.1 中公式(2) 标准化样本构成的矩阵 \bar{X}_1 , 则 X_1 矩阵的协方差矩阵 S_1 为:

$$S_1 = \text{cov}(\bar{X}_1) \approx \frac{1}{2n-2} \bar{X}_1^T \bar{X}_1 = U_1^T \Lambda U_1$$

重新求取 X_1 矩阵的协方差矩阵 S_1 特征值 λ_1 和特征向量 U_1 , 并将特征值按照从大到小 $\lambda_{11} \geq \lambda_{12} \geq \dots \geq \lambda_{1m} \geq 0$ 的顺序排列, 同时将与特征值对应的特征向量

也按照顺序进行排列. 则 $U_1 = (U_{11}, U_{12}, U_{13}, \dots, U_{1(2n-1)})$ 构成了样本等价投影空间的标准正交排序基集合 U_1 .

4.1.3 多级投影标架

二级投影标架的生成如 4.1.2, 在两两相邻基向量之间线性连接线中间插入二个向量, $\tilde{U}_2 = (U_1, \alpha_1 U_1 + \beta_1 U_2, \alpha_2 U_1 + \beta_2 U_2, U_2, \dots, U_{n-1}, \alpha_{n-1} U_{n-1} + \beta_{n-1} U_n, \alpha_{2(n-1)} U_{n-1} + \beta_{2(n-1)} U_n, U_n)$ 原始数据 X_0 向插入坐标系后的向量 \tilde{U}_2 投影, 得到投影矩阵 X_2 , 用 X_2 代替 X_0 , 按照 4.1.1 中式(2) 标准化样本构成的矩阵 \bar{X}_2 , 则 X_2 矩阵的协方差矩阵 S_2 为:

$$S_2 = \text{cov}(\bar{X}_2) \approx \frac{1}{3n-3} \bar{X}_2^T \bar{X}_2 = U_2^T \Lambda U_2$$

则 $U_2 = (U_{21}, U_{22}, U_{23}, \dots, U_{2(3n-2)})$ 构成了样本等价投影空间的标准正交排序基集合 U_2 .

同理, 按照一级、二级投影标架的生成方法, 基于样本集合生成的标准正交排序基首尾相联, 在两两相邻基向量之间线性连接线中间插入三个向量、四个向量、 \dots i 个向量, 从而形成高维特征表示空间的一级、二级、 \dots i 级投影标架 $U_i = (U_{i1}, U_{i2}, \dots, U_{i[(i+1) * n - i]})$; 进一步基于相邻多个基向量形成一个多面体, 在多面体内部进行不同密度的插值, 从而形成相应的投影标架.

4.2 离线训练

(1) 数据预处理: 将获得的正常历史数据矩阵的各列进行零均值和单位方差标准化处理;

(2) 获取特征向量矩阵 U : 利用相似变换将过程变量的协方差矩阵转换为具有对角形式的特征矩阵 U ;

(3) 特征向量矩阵扩维 U_i : 将特征向量矩阵 U 相邻的两个列量之间增加 i 个向量, 组成新的特征向量矩阵 U_i ;

(4) 将最初的原始数据向新的特征向量矩阵 U^k 的列向量为坐标进行投影, 得到新的一组投影后的数据 X_i ;

(5) 数据再次处理: 获得投影后数据矩阵 X_i , 对该矩阵的各列进行零均值和单位方差进行标准化处理;

(6) 利用相似变换将过程变量的协方差矩阵转换为具有对角形式的特征矩阵 U_i 和特征值 λ_i ;

(7) 以参考数据集为基准, 分别计算相应多级投影标架下主元空间和残差空间的检测指标.

4.3 在线监测阶段

(1) 数据预处理: 将测试数据集向新的特征向量矩阵 U_i 投影, 得到新投影空间下的坐标 X_i ;

(2) 将新投影坐标按零均值和零方差进行处理;

(3) 计算处理后的测试数据 $T^2(i)$ 及 $SPE(i)$ 指标值, 通过与正常控制限的比较, 可发现是否发生异常.

5 仿真及分析

为验证方法的有效性, 考虑噪声符合或者正常变

化下小故障的组合, 构建以下系统变量^[20]:

其中, $\text{randn}(N, 1)$ 是用 Matlab 产生的 N 行 1

$$\begin{cases} x_1(k) = 10 + 0.2 \times \text{randn}(N, 1) \\ x_2(k) = 20 + 0.05x_1(k) + 0.8 \times \text{randn}(N, 1) \\ x_3(k) = 10 + 5 \times x_2(k) - 2 \times x_1(k) + 0.2 \times \text{randn}(N, 1) \\ x_4(k) = 20 + 0.3 \times \text{randn}(N, 1) \\ x_5(k) = 10 - 1.3 \times x_1(k) + 0.2 \times x_2(k) + 0.8 \times x_3(k) \end{cases}$$

列的随机数, 选取 500 个正常数据建立 PCA 模型; 由正常数据模型分别计算 T^2 统计限和 SPE 统计限, 再采集 500 个样本作为测试数据, 对测试数据的变量的 401 - 500 时刻引入一定幅值的恒偏差故障, 下面分别讨论单变量恒偏差故障和多故障复合微小故障.

(1) x_1 在 401 - 500 时刻加入 0.1 的偏差故障

首先, 由原始数据集计算出 T^2 统计限和 SPE 统计限, 在 SPE 统计限不变情况下, 检测结果如下, 见表 1.

表 1 恒偏差故障故障检测结果

故障	PCA		FramePCA(First-class)	
	T^2	SPE	T^2	SPE
误报样本	3	4	3	311
误报率	0.0075	0.01	0.0075	0.7775
漏报样本	98	86	90	0
漏报率	0.98	0.86	0.9	0

传统 PCA 故障检测方法和一级标架 PCA 故障检测方法的 SPE 统计量可以分别从图 5 和图 6 中看到, 当故障样本是恒偏差故障的时候, 但这种故障是微小的偏差, 原始的投影空间不足以显示足够多的故障信息, 从而导致在原始投影空间中故障分量在残差方向上的 SPE 统计量没有超过统计限, 造成了故障样本的大量漏报现象. 在将原始数据投影到一级标架空间后, 得到的新的主元空间和残差空间, 那么故障样本中存在的潜在故障变量在一级标架空间的投影方向上会大于 SPE 统计限, 从而提高了故障检测准确度. 在故障检测中, SPE 指标主要衡量正常过程变量之间的相关性被改变的程度, 当主元空间将大部分的变化建模之后, 残差将变得更加平稳和具有随机性, 从而 SPE 相比 T^2 检测是更有效的故障检测指标, 从表 1 中可以看到, 对于多个变量耦合的复合故障, 由于故障信息在一级标架的残差空间中的投影提高了故障样本中故障分量的显示能力, 从而有效的降低了故障漏报现象.

我们可以看到, 在 SPE 检测限不变的情况下, 由于一级标架空间使得投影方向增加, 从而让原本无法显示的故障样本在一级标架空间的投影方向的统计量超出统计限, 达到提高故障检测检出率.

(2) x_1, x_2, x_3 在 401 - 500 时刻分别加入 0.01、




图5 原始PCA模型




图7 原始PCA结果




图6 一级标架空间PCA模型

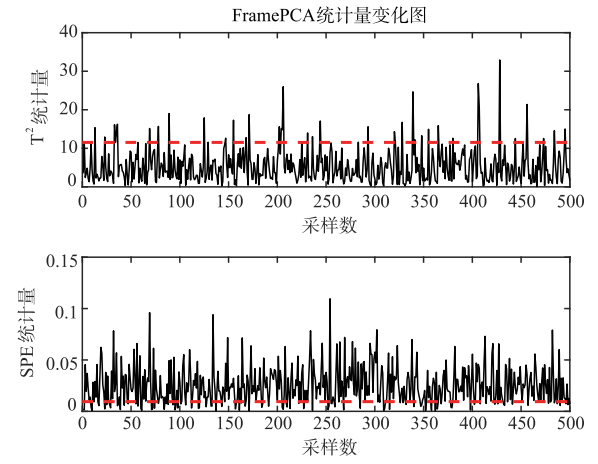


图8 一级标架空间PCA结果

0.03、0.05 的偏差故障对于微小复合故障而言,由于故障是由多个微小偏差复合,所以在原始的检测限下,故障样本在原始空间以及一级标架空间下并不一定能在残差空间投影方向上显示出故障分量使其超出 SPE 统计限,在这种情况下,我们采用多级标架空间,在对微小复合故障作故障检测,传统 PCA 方法故障检测结果如图 7 所示,一级标架 PCA 方法故障检测结果如图 8 所示,二级标架 PCA 方法故障如图 9 所示。

表 2 微小复合故障检测结果

故障模式 5	PCA		FramePCA (First-class)		FramePCA (Second-class)	
	T^2	SPE	T^2	SPE	T^2	SPE
误报样本数	3	4	33	311	33	311
误报率	0.008	0.01	0.083	0.77	0.083	0.77
漏报样本数	98	99	92	19	92	0
漏报率	0.98	0.99	0.92	0.19	0.92	0

在传统 PCA 的故障检测方法中我们可以看到故障




图9 二级标架空间PCA结果

样本在残差空间中的 SPE 统计量并不能超过统计限,并且在一级标架空间的投影中,微小故障样本的故障分量在残差投影方向上的投影依然无法超出统计限,那么在一级投影标架空间扩维形成二级投影标架空间,在新的投影标架空间下,随着故障变量分量在残差

空间中投影显现出来,从而提高了故障检测的准确度。在表 2 中我们可以看到,微小故障样本的故障分量在一级标架空间的残差空间中投影并不能超出统计限,导致不能提升故障检测的准确性,那么在二级标架空间的残差空间中,微小故障分量在新的投影方向上可以显示出故障并且超过统计限,从而提高了故障检测准确性。当然,多级标架空间方法同时存在不足之处,当投影方向增加,使微小故障样本的投影显示的同时,系统的正常样本在增加的投影方向上的投影也会增大,这样会导致在多级标架的统计量也会超过统计限,就会造成系统正常状态的误报,所以综合故障检测指标是进一步研究的重点。

6 结论

多级标架理论是针对数据预处理,将原空间不能展示的微小故障信息展示出来。深度学习根据多层次网络对细节进行线性组合表示,但进行机理分析比较困难,针对以上问题,提出一种增加维度冗余表示系统特征的基础上再进行降维,用于故障诊断的方法。通过在原来 PCA 基础上增加 n 个向量形成 n 级投影标架。扩维的方法,将原始空间中不能表达的信息进行充分表达,使得特征不明显的微小故障能够在 n 级投影标架下进行放大。实验证明,原始投影空间中无法检测出的微小故障,能够在新的多级高维特征表示的投影标架下检测出来,提高了故障检测的检出率。

参考文献

- [1] Ren L, Xu Z Y, Yan X Q. Single-sensor incipient fault detection[J]. IEEE Sensors Journal, 2011, 11(9): 2102 - 210.
- [2] Yan R, Gao R X, Chen X. Wavelets for fault diagnosis of rotary machines: a review with applications[J]. Signal Processing, 2014, 96(5): 1 - 15.
- [3] Wong P K, Yang Z, Chi M V, et al. Real-time fault diagnosis for gas turbine generator systems using extreme learning machine[J]. Neurocomputing, 2014, 128(5): 249 - 257.
- [4] 周东华, 李钢, 李元. 数据驱动的工业过程故障诊断技术[M]. 科学出版社, 2011: 23 - 27, 58 - 59.
- [5] 文成林, 胡静, 王天真, 陈志国. 相对主元分析及其在数据压缩和故障诊断中的应用研究[J]. 自动化学报, 2008(09): 1128 - 1139.
WEN Cheng-Lin, HU Jing, Wang TIAN-Zhen, CHEN Zhi-Guo. Relative PCA with applications of data compression and fault diagnosis[J]. Acta Automatica Sinica, 2008, 34(9): 1128 - 1139. (in Chinese)
- [6] 王天真, 刘远, 汤天浩, 陈炎. 基于相对主元分析的动态数据窗口故障检测方法[J]. 电工技术学报, 2013, 28(1): 142 - 148.
WANG Tian-zhen, LIU Yu-an, TANG Tian-ha, CHEN Yan. Dynamic data window fault detection method based on relative principal component analysis[J]. Transactions of China Electrotechnical Society, 2013, 28(1): 142 - 148. (in Chinese)
- [7] 周福娜, 文成林, 陈志国, 冷元宝. 基于指定元分析的多级相对微小故障诊断方法[J]. 电子学报, 2010, 38(8): 1874 - 1879.
WANG Tian-zhen, LIU Yuan, TANG Tian-hao, CHEN Yan. Dynamic data window fault detection method based on relative principal component analysis[J]. Acta Electronica Sinica, 2010, 38(8): 1874 - 1879. (in Chinese)
- [8] Harmouche J, Delpha C, Diallo D. Incipient fault detection and diagnosis based on Kullback-Leibler divergence using principal component analysis: Part I[J]. Signal Processing, 2014, 94: 278 - 28.
- [9] Harmouche J, Delpha C, Diallo D. Incipient fault detection and diagnosis based on Kullback-Leibler divergence using principal component analysis: Part II[J]. Signal Processing, 2015, 109: 334 - 344
- [10] 文成林, 吕菲亚, 包哲静, 等. 基于数据驱动的微小故障诊断方法综述[J]. 自动化学报, 2016, 42(9): 1285 - 1299.
WEN Cheng-Lin, LV Fei-Ya, BAO Zhe-Jing, LIU Mei-Qin. A review of data driven-based incipient fault diagnosis[J]. Acta Automatica Sinica, 2016, 42(9): 1285 - 1299. (in Chinese)
- [11] Wise B M, Gallagher N B. The process chemometrics approach to process monitoring and fault detection[J]. Journal of Process Control, 1996, 6(6): 329 - 348.
- [12] Lv F, Wen C, Bao Z, et al. Fault diagnosis based on deep learning[A]. American Control Conference (ACC) [C]. Boston, MA, USA, IEEE, 2016. 6851 - 6856.
- [13] Tamilselvan P, Wang P. Failure diagnosis using deep belief learning based health state classification[J]. Reliability Engineering & System Safety, 2013, 115: 124 - 135.
- [14] Chang C H. Deep and shallow architecture of multilayer neural networks[J]. IEEE Transactions on Neural Networks and Learning Systems, 2015, 26(10): 2477 - 2486.
- [15] Lu S, Liu H, Li C. Manifold Regularized stacked autoencoder for feature learning[A]. The 2015 IEEE International Conference on Systems, Man, and Cybernetics [C]. IEEE, 2015. 2950 - 2955.
- [16] Lv F, Wen C, Liu M, Bao Z. Weighted time series fault diagnosis based on a stacked sparse autoencoder[J]. Journal of Chemometrics, 2017, 31(4): e2912.
- [17] R Raina, A Battle, H Lee, et al. Self-taught learning: transfer learning from unlabeled data[A]. The 24th Int Conf on Machine Learning [C]. New York: ACM Press, 200. 759 - 766.

- [18] Baldi P, Hornik K. Neural networks and principal component analysis: Learning from examples without local minima[J]. *Neural Networks*, 1989, 2(1): 53 – 58.
- [19] Japkowicz N, Hanson S J, Gluck M A. Nonlinear autoassociation is not equivalent to PCA[J]. *Neural Computation*, 2000, 12(3): 531 – 545.
- [20] 胡静. 基于多元统计分析的故障诊断与质量监测研究[D]. 浙江大学, 2015.

作者简介



张彩霞 女, 1976 年生于河南平顶山, 博士, 教授, 研究方向为多源信息融合与智能控制系统.

E-mail: zh_caixia@163.com