

DOI: 10.13382/j.jemi.B2003679

修正的潜在结构正交投影的过程监控*

王璇 王衍学

(北京建筑大学 北京 100044)

摘要:近年来,质量相关的故障诊断受到学界的广泛关注。目前存在多种基于后处理的故障诊断算法,但是,进一步的研究发现,当质量无关的故障幅度增强时,这些后处理算法会逐渐失去功能,除此之外,后处理算法在实践中会产生很大的计算量。为了进一步解决上述算法的弊端,采取一种预处理、建模、后处理的结构,并提出修正的潜在结构正交投影算法。对比之前的算法,该方法对质量相关的故障更具实用性,同时减少了模型所需潜在变量的数目,与之前算法相比,计算量更低,数值示例和田纳西-伊士曼过程用来验证该方法的有效性。

关键词:数据驱动;过程监控;数据预处理;质量相关故障检测

中图分类号: TP277 **文献标识码:** A **国家标准学科分类代码:** 460.40

Process monitoring based on modified orthogonal projections to latent structures

Wang Xuan Wang Yanxue

(Beijing University of Civil Engineering and Architecture, Beijing 100044, China)

Abstract: In recent years, quality-related fault diagnosis has attracted much attention from academic circles. Several fault diagnosis algorithms based on post-processing have been developed. However, further studies have found that these post-processing methods will gradually lose their function when the magnitude of quality-unrelated faults increases. In addition, post-processing algorithms will generate a lot of calculations in practice. In order to further solve the drawbacks of the above methods, this paper adopts a structure of preprocessing, modeling, and postprocessing. And proposed a modified orthogonal projection to latent structures (MOPLS). Compared with the previous algorithm, this method is more practical for quality-related faults. At the same time, the number of latent variables required by the model is reduced. Therefore, its computational complexity is lower than the previous algorithm. Numerical examples and Tennessee-Eastman (TE) process are used to verify the effectiveness of the method.

Keywords: data driven; process monitoring; data preprocessing; quality-related fault detection

0 引言

在工业生产过程中会发生各种故障,其中与产品质量相关的故障备受关注,因此质量相关的故障检测成为热门话题。数据驱动的故障诊断^[1-3]易于实施,对系统模型的需求较少,在过程监控领域引起了极大的关注。偏最小二乘(partial least squares, PLS)^[4]是典型的多元统计分析方法,同时 PLS 在不同的领域也得到了大量的应用^[5-7]。主成分分析(principal component analysis,

PCA)^[8]是过程监控中最常用到的另一种方法,但是经典 PCA 无法建立质量与过程变量间的联系,自然无法用于质量相关的故障检测。Li 等^[9]指出,标准 PLS 在过程变量空间执行倾斜分解,残差子空间可能包含输出相关的重要过程变量。因此,对于质量相关的故障检测,基于 PLS 的故障检测存在缺陷。为了克服标准 PLS 的缺点,Zhou 等^[10]首先提出一种基于 PLS 的后处理方法,即全潜结构投影(total projection to latent structures, T-PLS),通过进一步分解 PLS 的得分矩阵和负载矩阵,最终将过程空间分成 4 个子空间,与质量输出具有不同的相关性。

收稿日期:2020-11-19 Received Date: 2020-11-19

* 基金项目:国家自然科学基金(51875032)、北京建筑大学 2021 年度研究生创新项目资助

通过在4个子空间中设计适当的统计量,便可以实现对质量相关故障的分类。Yin等^[11]提出修正的偏最小二乘(modified partial least squares, M-PLS),该方法首先估计 X 与 Y 之间的回归系数矩阵,然后将 X 分别投影到系数矩阵的主空间和残差子空间,最终将过程空间 X 分解为两个正交的子空间。与T-PLS相比,M-PLS在过程空间上实现了正交分解,并且在大多数情况下比T-PLS更简单、更有效。通过对比两种方法的优势,Qin等^[12]提出并发的偏最小二乘(concurrent partial least squares, C-PLS),它比两者更有优势。进一步的研究发现,当故障幅度增大时,基于后处理方法无法降低故障的误报率。主要原因在于PLS模型中涉及一部分与输出无关的变量,后处理方法无法在后续处理中将其完全删除。为了解决这个问题,Wang等^[13]提出了总体主成分回归(total principal component regression, TPCR)故障检测方法,该方法成功将PCA应用于质量相关的故障检测。

TPCR^[14]实现质量相关的故障检测,但是针对质量相关的小幅值故障,故障检测率并不高。当故障幅度增大时,也会增加故障的误报率。为解决这个问题,本文提出预处理、建模、后处理结构,其中将潜在结构的正交投影(orthogonal projections to latent structures, O-PLS)^[15]作为预处理的工具,在建模前从输入空间中消除不必要的系统变化,从而构建过程变量与质量变量高度相关的PCA模型;在后处理阶段,通过TPCR方法将高度相关空间进一步划分为两个正交子空间。在两个独立子空间中设计统计指标,检测与质量相关或质量无关的故障。新方法减少了潜在变量的数量,降低了算法运算量。

1 潜在结构正交投影

数据 X 中存在与 Y 无关的变量,这些变量影响了算法的性能。从 X 中消除这些变量可以显著减少PCA模型所需的潜在变量的数目,从而提高模型的可解释性和鲁棒性。同时,考虑到从 X 中删除的数据可能包含一些重要信息。O-PLS是一种常用的过滤工具,可以从 X 中去除与 Y 正交的变量,同时进一步分析去除部分的数据。本文采用O-PLS作为标准PCA的预处理方法,将过程变量空间分解为质量相关子空间和质量无关子空间。单个输出变量($l=1$)的O-PLS算法总结如下。

1) 输入数据 X 和输出数据 y 标准化,零均值,单位方差。

$$2) \mathbf{w}^T = \mathbf{y}^T X / (\mathbf{y}^T \mathbf{y})$$

$$3) \mathbf{w} = \mathbf{w} / \|\mathbf{w}\|$$

$$4) \mathbf{t} = X\mathbf{w} / (\mathbf{w}^T \mathbf{w})$$

$$5) \mathbf{c}^T = \mathbf{t}^T \mathbf{y} / (\mathbf{t}^T \mathbf{t})$$

$$6) \mathbf{u} = \mathbf{y}\mathbf{c} / (\mathbf{c}^T \mathbf{c})$$

$$7) \mathbf{p}^T = \mathbf{t}^T X / (\mathbf{t}^T \mathbf{t})$$

$$8) \mathbf{w}_\perp = \mathbf{p} - [\mathbf{w}^T \mathbf{p} / (\mathbf{w}^T \mathbf{w})] \mathbf{w}$$

$$9) \mathbf{w}_\perp = \mathbf{w}_\perp / \|\mathbf{w}_\perp\|$$

$$10) \mathbf{t}_\perp = X\mathbf{w}_\perp / (\mathbf{w}_\perp^T \mathbf{w}_\perp)$$

$$11) \mathbf{p}_\perp^T = \mathbf{t}_\perp^T X / (\mathbf{t}_\perp^T \mathbf{t}_\perp)$$

$$12) X_{\text{opls}} = X - \mathbf{t}_\perp \mathbf{p}_\perp^T$$

$$13) \mathbf{T}_\perp = [\mathbf{T}_\perp \quad \mathbf{t}_\perp] \quad \mathbf{P}_\perp = [\mathbf{P}_\perp \quad \mathbf{p}_\perp] \quad \mathbf{W}_\perp = [\mathbf{W}_\perp \quad \mathbf{w}_\perp]$$

14) 去除更多的正交成分,令 $X = X_{\text{opls}}$ 并重复步骤2)~13),直到达到满意的性能为止

$$15) X_\perp = \mathbf{T}_\perp \mathbf{P}_\perp^T$$

16) 使用 $\mathbf{W}_\perp$ 和 $\mathbf{P}_\perp$ 校正在线样本,对于观测样本 $\mathbf{x}_{\text{new}}^T$,使用步骤17)~20)计算正交成分

$$17) \mathbf{t}_{\perp_new_s}^T = \mathbf{x}_{\text{new}}^T \mathbf{w}_\perp / (\mathbf{w}_\perp^T \mathbf{w}_\perp)$$

$$18) \mathbf{t}_{\perp_new}^T = [\mathbf{t}_{\perp_new}^T \quad \mathbf{t}_{\perp_new_s}^T]$$

$$19) \mathbf{x}_{\text{new_opls}}^T = \mathbf{x}_{\text{new}}^T - \mathbf{t}_{\perp_new} \mathbf{p}_\perp^T$$

20) 令 $\mathbf{x}_{\text{new}}^T = \mathbf{x}_{\text{new_opls}}^T$ 并重复步骤17)~19),直到达到满意的性能

$$21) \mathbf{x}_{\perp_new}^T = \mathbf{t}_{\perp_new} \mathbf{p}_\perp^T$$

步骤2)~7)是针对单个输出 y 的标准非线性迭代偏最小二乘算法;步骤8)计算正交权重向量 $\mathbf{w}_\perp$;步骤9)~11)计算正交得分向量 $\mathbf{t}_\perp$ 和正交负载向量 $\mathbf{p}_\perp$;步骤12)从 X 中去除与质量不相关的部分。为了获得更多的正交成分,将数据矩阵 X 替换为 X_{opls} ,重复步骤2)~13)直到达到满意的效果。最后将所有的参数保存在矩阵 $\mathbf{W}_\perp$ 、 $\mathbf{T}_\perp$ 和 $\mathbf{P}_\perp$ 中。步骤15)中 $X_\perp$ 是 X 与 Y 正交部分。建立模型后,使用步骤17)~20)校正所有在线样本。步骤21)中 $\mathbf{x}_{\perp_new}^T$ 是在线样本 $\mathbf{x}_{\text{new}}^T$ 与 Y 正交的部分,假定样本参数 $N \gg m > l \geq 1$ 。

如图1所示,过程数据 X 经过O-PLS预处理后,分解为与 Y 不相关的正交数据 $X_\perp$ 和与 Y 高度相关的滤波数据 X_{opls} 两部分。然后使用TPCR算法对 X_{opls} 进一步正交分解为 X_y 和 X_o 。O-PLS是一种回归的方法,不能直接用于故障检测,因此,后续的后处理操作仍然是必需的。




图1 故障检测流程

Fig. 1 Overview of the proposed fault detection scheme

2 实验验证

2.1 总主成分回归

工业过程中,把过程数据和质量数据收集到输入矩阵 $\mathbf{X}$ 和输出矩阵 $\mathbf{Y}$, 其中输入矩阵 $\mathbf{X}$ 具有 m 个过程变量和 N 个样本,输出矩阵 $\mathbf{Y}$ 具有 l 个过程变量和 N 个样本。

$$\mathbf{X} = \begin{bmatrix} \mathbf{x}_1^T \\ \vdots \\ \mathbf{x}_N^T \end{bmatrix} \in \mathbf{R}^{N \times m}, \mathbf{Y} = \begin{bmatrix} \mathbf{y}_1^T \\ \vdots \\ \mathbf{y}_N^T \end{bmatrix} \in \mathbf{R}^{N \times l}$$

$$\mathbf{x}_i \in \mathbf{R}^m, \mathbf{y}_i \in \mathbf{R}^l, i = 1, \dots, N$$

假定过程是线性的,且所有测量值均服从正态分布,过程和测量噪声也遵循正态分布,并且 $N \gg m > l \geq 1$, 数据矩阵 $\mathbf{X}$ 执行 PCA。

1) 计算输入数据的协方差矩阵 $\mathbf{S} = \frac{\mathbf{x}^T \mathbf{x}}{n-1}$ 。

2) 对 $\mathbf{S}$ 执行奇异值分解,获得特征向量集 $\mathbf{P} = [p_1 \ p_2 \ \dots \ p_m]$ 和特征值集 $\mathbf{S} = [s_1 \ s_2 \ \dots \ s_m]$, p 和 s 是特征向量和特征值个数。

3) 在 $\mathbf{S}$ 中选择 A 个最大的特征值,并取出相应的特征向量 $\mathbf{P} = [p_1 \ p_2 \ \dots \ p_A]$ 。

4) $\mathbf{T} = \mathbf{X}\mathbf{P}$, 其中 $\mathbf{T}$ 是 $\mathbf{X}$ 的得分矩阵, $\mathbf{P}$ 是 $\mathbf{X}$ 的负载矩阵,将原始变量空间投影到不相关的潜在子空间。

$$\mathbf{T} = [\mathbf{t}_1 \ \mathbf{t}_2 \ \dots \ \mathbf{t}_A] \in \mathbf{R}^{n \times A}$$

$$\mathbf{X} = \hat{\mathbf{X}} + \mathbf{E} = \mathbf{T}\mathbf{P}^T + \mathbf{E} \quad (1)$$

其中 A 是潜在变量的数目, $\hat{\mathbf{X}}$ 为主元部分, $\mathbf{E}$ 为残差部分。

5) 在 $\mathbf{T}$ 和 $\mathbf{Y}$ 之间执行最小二乘回归,得到 $\mathbf{Q}^T$:

$$\mathbf{Q}^T = (\mathbf{T}^T \mathbf{T})^{-1} \mathbf{T}^T \mathbf{Y} \quad (2)$$

6) 进而得:

$$\hat{\mathbf{Y}} = \mathbf{T}\mathbf{Q}^T = \mathbf{X}\mathbf{P}\mathbf{Q}^T = \mathbf{X}\mathbf{B} \quad (3)$$

式中: $\hat{\mathbf{Y}}$ 是对 $\mathbf{Y}$ 的在线预测, $\mathbf{B} = \mathbf{P}\mathbf{Q}^T$ 是 $\mathbf{X}$ 、 $\mathbf{Y}$ 之间的系数矩阵。

7) 对 $\hat{\mathbf{Y}}$ 执行 PCA,得分矩阵 $\mathbf{T}_y$ 和 $\mathbf{Q}_y$ 为:

$$\mathbf{T}_y = \hat{\mathbf{Y}}\mathbf{Q}_y = \mathbf{T}\mathbf{Q}^T\mathbf{Q}_y \quad (4)$$

显然 $\mathbf{Q}^T\mathbf{Q}_y$ 将 $\mathbf{T}$ 重新投影到 $\mathbf{T}_y$ 。

8) 从 $\mathbf{T}_y$ 重构 $\mathbf{X}_y$:

$$\mathbf{P}_y^T = (\mathbf{T}_y^T \mathbf{T}_y)^{-1} \mathbf{T}_y^T \hat{\mathbf{X}} \quad (5)$$

$$\mathbf{X}_y = \mathbf{T}_y \mathbf{P}_y^T = \mathbf{T}_y (\mathbf{T}_y^T \mathbf{T}_y)^{-1} \mathbf{T}_y^T \mathbf{T} \mathbf{P}^T \quad (6)$$

$$\mathbf{X}_o = \mathbf{X} - \mathbf{X}_y \quad (7)$$

其中, $\mathbf{X}_y$ 和 $\mathbf{X}_o$ 代表着与 $\mathbf{Y}$ 高度相关和不相关的子空间。

2.2 修正的潜在结构正交投影的过程监控

T^2 统计量用来监视这两个部分,在 $\mathbf{X}_o$ 上执行 PCA, 获取得分矩阵 $\mathbf{T}_o$ 和负载矩阵 $\mathbf{P}_o$, 同时去除特征值为 0 或极小值情况下的特征向量。每个在线样本 $\mathbf{x}_{\text{new}}$, 计算得分向量 $\mathbf{t}_{\text{new}}$, $\mathbf{t}_{\text{new}}^T = \mathbf{x}_{\text{new}}^T \mathbf{P}$, 再把 $\mathbf{t}_{\text{new}}$ 投影后得 $\mathbf{t}_{\text{ynew}}$:

$$\mathbf{t}_{\text{ynew}}^T = \mathbf{t}_{\text{new}}^T \mathbf{Q}^T \mathbf{Q}_y = \mathbf{x}_{\text{new}}^T \mathbf{P} \mathbf{Q}^T \mathbf{Q}_y \quad (8)$$

不相关部分的得分矩阵:

$$\mathbf{t}_{\text{onew}}^T = \mathbf{x}_{\text{new}}^T \mathbf{P}_o = (\mathbf{x}_{\text{new}}^T - \mathbf{t}_{\text{ynew}}^T \mathbf{P}_y^T) \mathbf{P}_o = (\mathbf{x}_{\text{new}}^T - \mathbf{x}_{\text{new}}^T \mathbf{P} \mathbf{Q}^T \mathbf{Q}_y \mathbf{P}_y^T) \mathbf{P}_o \quad (9)$$

子空间 $\mathbf{X}_y$ 的 T^2 统计量和域值计算:

$$\mathbf{T}_y^2 = \mathbf{t}_{\text{ynew}}^T \left(\frac{\mathbf{T}_y^2 \mathbf{T}_y}{n-1} \right)^{-1} \mathbf{t}_{\text{ynew}} \quad (10)$$

$$\mathbf{J}_{thy} = \frac{n+1}{n} F_\alpha(1, n-1) \quad (11)$$

子空间 $\mathbf{X}_o$ 的 T^2 统计量和域值计算:

$$\mathbf{T}_o^2 = \mathbf{t}_{\text{onew}}^T \left(\frac{\mathbf{T}_o^2 \mathbf{T}_o}{n-1} \right)^{-1} \mathbf{t}_{\text{onew}} \quad (12)$$

$$\mathbf{J}_{tho} = \frac{(A_o - 1)(n^2 - 1)}{n(n - A_o + 1)} F_\alpha(A_o - 1, n - A_o + 1) \quad (13)$$

其中 $F_\alpha(h_1, h_2)$ 是 F 分布; α 代表控制极限; h_1 和 h_2 代表自由度。

MOPLS 算法如下:

1) 将过程数据和质量数据收集到矩阵 $\mathbf{X}$ 和 $\mathbf{Y}$ 中,进行标准化;

2) 使用 O-PLS 算法,对数据矩阵 $\mathbf{X}$ 进行过滤,过滤后的数据矩阵为 $\mathbf{X}_{\text{opls}}$, 权重矩阵和负载矩阵为 $\mathbf{W}$ 和 $\mathbf{P}$;

3) 对数据矩阵 $\mathbf{X}_{\text{opls}}$ 执行 PCA,得分矩阵 $\mathbf{T}$;

4) 对 $\mathbf{T}$ 和 $\mathbf{Y}$ 执行最小二乘回归,负载矩阵 $\mathbf{Q}$;

5) $\hat{\mathbf{Y}} = \mathbf{T}\mathbf{Q}^T = \mathbf{X}\mathbf{P}\mathbf{Q}^T = \mathbf{X}\mathbf{B}$, 对 $\hat{\mathbf{Y}}$ 执行 PCA,获得 $\mathbf{T}_y$ 和 $\mathbf{Q}_y$;

6) 将 $\mathbf{X}$ 分解为 $\mathbf{X}_o$ 和 $\mathbf{X}_y$ 两个子空间;

7) 计算 $\mathbf{X}_o$ 和 $\mathbf{X}_y$ 的 T^2 统计量和域值。

故障诊断逻辑为:

$$\begin{cases} \mathbf{T}_y^2 \geq \mathbf{J}_{thy}, \text{故障与质量相关} \\ \mathbf{T}_y^2 < \mathbf{J}_{thy} \&\& \mathbf{T}_o^2 \geq \mathbf{J}_{tho}, \text{故障与质量无关} \end{cases}$$

3 数值示例和案例研究

故障检测率(fault detection rates, FDRs)和故障误报率(fault alarm rates, FARs)常用于性能的评估。其中,有效报警是指检测出与输出 $\mathbf{Y}$ 相关的故障样本;错误的报警是检测出与输出 $\mathbf{Y}$ 不相关的故障样本。令 N_{nea} 和 N_{nfa} 分别表示有效报警的数量和错误报警的数量, N_{tfs} 代表故障样本的总数。FDR 和 FAR 可以定义^[16-17]:

$$FDR = \frac{N_{nea}}{N_{tfs}} \quad (14)$$

$$FAR = \frac{N_{nfa}}{N_{tfs}} \quad (15)$$

将 MOPLS 方法与 TPCR 和 T-PLS 方法做对比研究, 并通过数值示例和工业示例进行有效地测试。

3.1 数值示例

参考如下数值示例^[18]:

$$\begin{cases} \mathbf{x}_k = \mathbf{A}\mathbf{z}_k + \mathbf{e}_k \\ \mathbf{y}_k = \mathbf{c}\mathbf{x}_k + \mathbf{v}_k \end{cases} \quad (16)$$

其中:

$$\mathbf{z}_k \in R^3, \mathbf{z}_{k,i} \sim U([0, 1]), i = 1, 2, 3$$

$$\mathbf{A} = \begin{bmatrix} 1 & 3 & 4 & 4 & 0 \\ 3 & 0 & 1 & 4 & 1 \\ 1 & 1 & 3 & 0 & 0 \end{bmatrix}, \mathbf{e}_k \in R^5$$

$$\mathbf{e}_{k,j} \sim N(0, 0.05^2), j = 1, 2, \dots, 5$$

$$\mathbf{x}_k = [x_{k,1} \ x_{k,2} \ x_{k,3} \ x_{k,4} \ x_{k,5}]^T$$

$$\mathbf{v}_k \sim N(0, 0.01^2), \mathbf{c} = [2 \ 2 \ 1 \ 1 \ 0]$$

$U([0 \ 1])$ 为均匀分布, $\mathbf{x}_k$ 包含 5 个过程变量, $\mathbf{y}_k$ 包含一个质量变量, 将过程故障添加到样本。

$$\mathbf{x}_k = \mathbf{x}_k^* + \mathbf{\Xi}\mathbf{f} \quad (17)$$

式中: $\mathbf{x}_k^*$ 是式 (16) 生成的无故障值; $\mathbf{\Xi}$ 为故障方向; $\mathbf{f}$ 是故障幅度。

在正常条件下生成 400 个样本以建立回归模型, 另外生成 400 个样本进行检测, 其中前 200 个为无故障样本, 后 200 个为有故障样本。其中 MOPLS 和 TPCR 的潜在变量设置为 $A = 3, noc = 2$, T-PLS 的潜在变量 $A = 2, A_r = 1, A_o = 1$ 这由交叉验证确定。

1) 质量相关的故障

变量 $x_{k,1}$ 、 $x_{k,2}$ 、 $x_{k,3}$ 和 $x_{k,4}$ 负责预测 y_k , 因此, 质量相关的故障方向为 $\mathbf{\Xi} = [1 \ 1 \ 1 \ 1 \ 0]^T$ 。

设置故障幅度 $f = 6$, 输出 $\mathbf{y}$ 确实受到相关故障的影响, 如图 2 所示。




图2 质量相关故障时 $\mathbf{y}$ 的动态输出

Fig. 2 Dynamic output in the event of quality-related fault

在质量相关故障下, 测试当 $f = 6$ 时, MOPLS、TPCR、T-PLS 三种算法的故障检测结果。

故障检测结果如图 3~5 所示, 3 种方法有效检测出质量相关的故障。但是从图 3~5 可以观测到, TPCR、MOPLS 方法的检测率应该是最高的。




图3 质量相关故障 MOPLS 检测结果

Fig. 3 Detection result of quality-related fault by MOPLS




图4 质量相关故障 TPCR 检测结果

Fig. 4 Detection result of quality-related fault by TPCR




图5 质量相关故障 T-PLS 检测结果

Fig. 5 Detection result of quality-related fault by T-PLS

2) 质量无关的故障

变量 $x_{k,5}$ 对 y_k 没有贡献,如果 $x_{k,5}$ 发生故障,则不会影响输出。因此,质量无关的故障方向为:

$$\Xi=[0 \ 0 \ 0 \ 0 \ 1]^T$$
$$\hat{y}_k=c(x_k^*+\Xi f)=cx_k^*+c\Xi f=cx_k^* \tag{18}$$

如图 6 所示,当 $\Xi=[0 \ 0 \ 0 \ 0 \ 1]^T$ 时,输出 y 不受故障影响。




图 6 质量无关故障时 y 的动态输出

Fig. 6 Dynamic output in the event of quality-unrelated fault

测试故障幅度 $f=6$, 在质量无关故障下,MOPLS、TPCR、T-PLS 三种方法的故障检测结果。图 7~9 所示为 3 种方法的故障检测结果,如图 7 所示,MOPLS 方法只在质量无关子空间 X_o 报警,在质量相关子空间 X_y 没有明显变化,说明 MOPLS 方法可以检测到与质量无关的故障。如图 8 所示,TPCR 算法可以检测到质量无关的故障。如图 9 所示,T-PLS 算法在 Q_o 发生误报,说明 T-PLS 无法适用质量相关的故障检测。




图 7 质量无关故障 MOPLS 检测结果

Fig. 7 Detection result of quality-unrelated fault by MOPLS

表 1 为不同故障幅度,与质量相关的故障检测率,由表 1 可见,T-PLS 算法针对小幅度故障和大幅度故障都展现出很好的检测性能。而 MOPLS 和 TPCR 算法在小




图 8 质量无关故障 TPCR 检测结果

Fig. 8 Detection result of quality-unrelated fault by TPCR




图 9 质量无关故障 T-PLS 检测结果

Fig. 9 Detection result of quality-unrelated fault by T-PLS

幅度故障时完全失效,但是 MOPLS 的检测性能整体优于 TPCR。

表 1 质量相关故障在质量相关子空间的 FDR

Table 1 FDR of quality-related faults in quality-related subspace

故障幅值	MOPLS	TPCR	T-PLS
0.1	1	0	5
0.6	3	0	99
2.0	30	27	100
4.0	94	92	100
6.0	100	100	100
10.0	100	100	100

表 2 为不同故障幅度,与质量无关故障的误报率,由表 2 可见,MOPLS 和 TPCR 在故障幅度 $f < 20$ 时,展现出很低的误报率,当故障幅度增大时,TPCR 算法出现轻微的误报率,并且有失效的风险。MOPLS 算法的误报率仍然近似 0%。而 T-PLS 算法的误报率为 100%,因此无法

确定故障是否真正的影响输出。

表 2 质量无关故障在质量相关子空间的 FAR

Table 2 FAR of quality-related faults in quality-unrelated subspace			
故障幅值	MOPLS	TPCR	T-PLS
0.1	0	0	13
0.6	0	0	100
4.0	0	0	100
10.0	0	0	100
20.0	0	1	100
50.0	0	16	100

综合考虑,基于 TPCR 提出的 MOPLS 算法,在故障幅度很大的情况下,展现出更好的性能,对质量无关的故障误报率基本为 0%。而 T-PLS 方法不适应于质量相关的故障检测,综合考虑 3 种方法,MOPLS 方法的检测性能最优。

在质量无关的故障诊断中,低的 FAR 并不意味着同样低的 FDR。对于质量无关的故障,质量相关的子空间中应该具有低的 FAR,但是质量无关的子空间中应该具有高的 FDR。表 3 为不同故障幅度,与质量无关故障的检测率,由表 3 可见,当故障幅度 $f \geq 0.6$ 时,MOPLS 和 TPCR 方法对质量无关故障的检测率都达到了 100%。但是当 $f < 0.6$ 时,MOPLS 的检测性能优于 TPCR。对于 $f < 6$ 小幅值故障,T-PLS 方法在质量无关子空间中的检测率低于 30%。

综合表 1~3,MOPLS 使用数据预处理,在故障幅度较大时,提高质量相关故障的检测能力,拥有比 TPCR 更稳定的性能。对于质量无关故障的检测率,其检测性能也优于其余两种方法。

表 3 质量无关故障在质量无关子空间的 FDR

Table 3 FDR of quality-unrelated faults in quality-unrelated subspace			
故障幅值	MOPLS	TPCR	T-PLS
0.1	24	6	0
0.2	80	60	0
0.6	100	100	1
4.0	100	100	16
6.0	100	100	30
10.0	100	100	82

3.2 工业示例

伊士曼公司开发的工业过程模拟器 TE 过程^[19],作为具有挑战性的基准,广泛用于评估过程控制和检测方法。整个过程一共生成 21 种故障,其中 15 种为已知,本文将使用其中 14 种已知故障,并选取最终产品成分 G 作

为质量变量。选取 22 个过程变量(XMEAS(1-22))和 11 个操作变量(XMV(1-11))作为输入数据 X 。所有的样本都应进行标准化,其中建模参数设置为 $A = 20, A_y = 1, A_r = 17$ 和 $noc = 2$,参考文献[20]。

选取质量相关的 9 个故障 IDV(1,2,5,6,7,8,10,12,13)和质量无关的 5 个故障 IDV(3,4,9,11,15),参考文献[16]。

由表 4 可见,针对与质量无关的 5 种故障,MOPLS,TPCR 和 T-PLS 各有优势,大多数情况下,都展现出低于 10%的误报率,在 IVD(11)中,T-PLS 的误报率达到 27.97%,而 MOPLS,TPCR 基本上略高于 10%。综上所述,对于 TE 过程,MOPLS、TPCR 和 T-PLS 三种方法对于质量无关的故障均表现出较低的误报率。

表 4 TE 过程与质量无关的误报率 FAR

Table 4 FAR of quality-unrelated faults of the TE process			
故障编号	MOPLS	TPCR	T-PLS
IDV(3)	7.37	7.37	6.99
IDV(4)	3.62	3.62	6.24
IDV(9)	9.86	9.86	8.74
IDV(11)	10.49	10.36	27.97
IDV(15)	6.62	6.62	4.24

由表 5 可见,TE 过程对于质量相关故障的检测,MOPLS,TPCR 和 T-PLS 展现出相似的能力。在 IVD(1)、IVD(2)、IVD(5)、IVD(12)四类故障中,MOPLS 和 TPCR 的检测性能基本相似,优于 T-PLS 方法;IVD(6)、IVD(7)、IVD(8)、IVD(10)、IVD(13)五类故障中,MOPLS 和 TPCR 的检测性能基本相似,并且低于 T-PLS 方法。在 IVD(5)中 MOPLS 和 TPCR 方法的检测性能远远高于 T-PLS,而在 IVD(7)、IVD(10)、IVD(13)中 MOPLS 和 TPCR 方法的检测性能也会低于 T-PLS。

表 5 TE 过程与质量相关的误报率 FDR

Table 5 FDR of quality-related faults of the TE process			
故障编号	MOPLS	TPCR	T-PLS
IDV(1)	84.14	84.39	81.40
IDV(2)	94.88	94.88	93.51
IDV(5)	99.63	99.63	29.71
IDV(6)	99.13	99.13	99.88
IDV(7)	40.07	40.20	71.41
IDV(8)	82.27	82.27	87.27
IDV(10)	59.80	59.68	79.53
IDV(12)	88.01	88.26	87.14
IDV(13)	77.53	77.78	94.01

4 结 论

本文提出了一种预处理、建模、后处理的结构,首先使用 O-PLS 进行预处理,将数据矩阵 $\mathbf{X}$ 中与 $\mathbf{Y}$ 无关的成分率先除去,预处理后的数据矩阵与 $\mathbf{Y}$ 有更强的相关性。最后使用 TPCR 算法将输入空间进一步分解为两个正交的子空间为完全负责预测输出和与输出无关。分别在两个子空间中设计了两个统计指标,检测与质量相关和与质量无关的故障。数值示例中,MOPLS 方法比 TPCR、T-PLS 有更好的故障检测能力,对于小幅度故障有更高的检测率,对于大幅度故障有着更强的鲁棒性。工业示例中,3 种方法各有优势,其中 MOPLS 的检测性能与 TPCR 基本相似,T-PLS 模型所需的潜在变量数目与 PLS 相同,即 $A = 20$,而 MOPLS 模型的潜在变量数目为 $noc = 2$,MOPLS 的计算量比 T-PLS 低。

本文提出的 MOPLS 方法不仅提高大幅度故障和小幅度故障的检测性能,还降低了计算量。结合其清晰的诊断逻辑,MOPLS 更适用于实际的过程监控,但是仿真实验发现,当微小故障发生时,MOPLS 的检测率并不是太高,远未达到工业应用的要求,如何大幅度提高对于微小故障的检测能力,这是未来主要的研究方向之一。

参考文献

- [1] 杜望,王衍学. 基于协整和向量误差修正的轴承剩余寿命预测[J]. 电子测量与仪器学报, 2020, 34(9): 32-39.
DU W, WANG Y X. RUL prediction method for rolling bearing based on cointegration system and vector error correction[J]. Journal of Electronic Measurement and Instrumentation, 2020, 34(9): 32-39.
- [2] 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.
MA CH, WANG SH H, XU X L, et al. Intelligent diagnosis method of rolling bearing faults based on CSBP [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(12): 58-63.
- [3] 宋浏阳,李石,王芃鑫,等. 基于动态统计滤波与深度学习的智能故障诊断方法[J]. 仪器仪表学报, 2019, 40(7): 39-46.
SONG L Y, LI SH, WANG P X, et al. Intelligent fault diagnosis method based on dynamic statistical filtering and deep learning [J]. Chinese Journal of Scientific Instrument, 2019, 40(7): 39-46.
- [4] 李元,吴昊侯,张成,等. 基于改进偏最小二乘法的多模态过程故障检测方法[J]. 计算机应用, 2018, 38(12): 3601-3606.
LI Y, WU H Y, et al. Multi-modal process fault detection method based on improved partial least squares[J]. Journal of Computer Applications, 2018, 38(12): 3601-3606.
- [5] GAO T, LUO H, YIN S. A recursive modified partial least square aided data-driven predictive control with application to continuous stirred tank heater[J]. Journal of Process Control, 2020, 89: 108-118.
- [6] CHEN J F, YANG Z Q. Data-driven subspace-based adaptive fault detection for solar power generation systems[J]. IET Control Theory and Applications, 2013, 7(11): 1498-1508.
- [7] 李鹏辉,陈建林,申忠利,等. 基于偏最小二乘法的气动执行机构故障诊断研究[J]. 电力系统保护与控制, 2018, 46(11): 1674-3415.
LI P H, CHEN J L, SHEN ZH L, et al. Research on fault diagnosis of pneumatic actuator based on partial least square method [J]. Power System Protection and Control, 2018, 46(11): 1674-3415.
- [8] 周卫庆,司风琪,徐治皋. 基于 KPCA 残差方向梯度的故障检测方法及应用[J]. 仪器仪表学报, 2017, 38(10): 2518-2524.
ZHOU W Q, SI F Q, XU ZH H. Fault detection method and application based on KPCA residual direction gradient[J]. Chinese Journal of Scientific Instrument, 2017, 38(10): 2518-2524.
- [9] LI G, QIN S J, ZHOU D H. Geometric properties of partial least squares for process monitoring [J]. Automatica, 2010, 46(1): 204-210.
- [10] ZHOU D H, LI G, QIN S J. Total projection to latent structures for process monitoring[J]. AIChE Journal, 2010, 56: 168-178.
- [11] YIN S, DING S X, ZHANG P. Study on modifications of PLS approach for process monitoring [J]. IFAC Proceedings Volumes, 2011, 44(1): 12389-12394.
- [12] QIN S J, ZHENG Y Y. Concurrent projection to latent structures for output-relevant and input-relevant fault monitoring[J]. Decision and Control, 2012, 16(9): 222-229.
- [13] WANG G, LUO H, PENG K. Quality-related fault detection using linear and nonlinear principal component regression[J]. Journal of the Franklin Institute, 2016, 353(10): 2159-2177.
- [14] WANG G, LUO H, PENG K X. Quality-related detection using linear and nonlinear principal component regression[J]. Journal of the Franklin Institute, 2016, 353(10): 2159-2177.
- [15] BIAGIONI D J, ASTLING D P, MACGREGOR P, et al. Orthogonal projection to latent structures solution

- properties for chemometrics and systems biology data[J]. Journal of Chemometrics, 2011, 25(9): 514-525.
- [16] JIA Q, ZHANG Y. Quality-related fault detection approach based on dynamic kernel partial least squares [J]. Chemical and Intelligent Laboratory, 2016, 62 (3): 242-252.
- [17] ZHANG K, HAO H, CHEN Z, et al. A comparison and evaluation of key performance indicator-based multivariate statistics process monitoring approaches [J]. Journal of Process Control, 2015, 33(6): 112-126.
- [18] LI G, QIN S J, ZHOU D H. Output relevant fault reconstruction and fault subspace extraction in total projection to latent structures models [J]. 2010, 49: 9175-9183.
- [19] 吕鹏飞, 闫云聚, 荔越. 基于马氏距离的改进核 Fisher 化工故障诊断研究 [J]. 自动化学报, 2020, 46(11): 2379-2391.
- LU P F, YAN Y J, LI Y. Research on improved nuclear fisher chemical fault diagnosis based on mahalanobis distance[J]. Acta Automatica Sinica, 2020, 46(11): 2379-2391.
- [20] YIN S, WANG G, GAO H J. Data-driven process monitoring based on modified orthogonal projections to latent structures[J]. Control Systems Technology, 2015, 24(4): 1480-1487.

作者简介



王璇, 2018 年于山东农业大学获得学士学位, 现为北京建筑大学硕士研究生, 主要研究方向为基于数据的故障诊断。

E-mail: 15621532197@163.com

Wang Xuan received his B. Sc. degree from Shandong Agricultural University in 2018. He is currently a M. Sc. candidate at Beijing University of Civil Engineering and Architecture. His main research interest includes data-based fault diagnosis.



王衍学, 2009 年于西安交通大学获得博士学位, 2010~2011 年加拿大渥太华大学博士后, 现为北京建筑大学教授、博士生导师, 主要研究方向为装备故障诊断与智能维护、剩余寿命与健康管理及信号处理与特征提取等。

E-mail: wyx1999140@126.com

Wang Yanxue received his Ph. D. from Xi'an Jiaotong University in 2009 and postdoctoral fellow at the University of Ottawa in Canada from 2010 to 2011. Now he is a professor and Ph. D. supervisor of Beijing University of architecture. His main research interests include equipment fault diagnosis and intelligent maintenance, RUL prognosis and health management, signal processing and feature extraction etc.