

控制与决策

Control and Decision

基于公共特有子空间提取的工业设备多模式运行过程故障检测方法

何雨辰, 王云, 刘涛, 项剑, 娄睿冲, 王玉琦

引用本文:

何雨辰, 王云, 刘涛, 项剑, 娄睿冲, 王玉琦. 基于公共特有子空间提取的工业设备多模式运行过程故障检测方法[J]. 控制与决策, 2022, 37(6): 1469–1478.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2020.0947>

您可能感兴趣的其他文章

Articles you may be interested in

[基于多块信息提取的AUV资源勘查系统故障检测](#)

Fault detection of AUV resource exploration system based on multi-block information extraction

控制与决策. 2021, 36(4): 790–800 <https://doi.org/10.13195/j.kzyjc.2019.0732>

[基于广义主成分分析的重构故障子空间建模方法](#)

Reconstructed fault subspace modelling method based on generalized principal component analysis

控制与决策. 2021, 36(4): 808–814 <https://doi.org/10.13195/j.kzyjc.2019.0818>

[基于局部信息增量与MPLS的质量相关故障检测方法](#)

Quality-related fault detection method based on local information increment and MPLS

控制与决策. 2021, 36(7): 1647–1654 <https://doi.org/10.13195/j.kzyjc.2019.1402>

[基于双权重多邻域保持嵌入的间歇过程故障检测](#)

Fault detection of batch process based on double weight and multiple neighborhoods preserving embedding

控制与决策. 2021, 36(12): 3023–3030 <https://doi.org/10.13195/j.kzyjc.2020.0659>

[基于核典型相关性-熵成分分析的工业过程质量监测方法](#)

A quality monitoring method for industrial process based on kernel canonical correlation-entropy component analysis

控制与决策. 2021, 36(12): 2999–3006 <https://doi.org/10.13195/j.kzyjc.2020.0548>

基于公共特有子空间提取的工业设备多模式 运行过程故障检测方法

何雨辰¹, 王云^{2†}, 刘涛¹, 项剑³, 娄睿冲⁴, 王玉琦⁴

(1. 浙江大学机械工程学院, 杭州 310027; 2. 浙江同济科技职业学院机电工程系, 杭州 311123;
3. 浙江钱江设备有限公司, 浙江台州 317500; 4. 中国计量大学机电工程学院, 杭州 310018)

摘要: 工业设备运行状态直接影响到最终产品质量,有必要对设备运行过程开展监控,因此着重对工业设备运行数据中存在的不同阶次信息以及多模式等复杂数据特性展开讨论. 针对过程中存在的不同阶次信息问题,首先通过引入最大交互熵展开与偏最小二乘方法,将原始空间信息分解为高阶和低阶信息,并构建相应隐空间模型来提取高阶与低阶质量相关关系;其次,针对过程中存在的多模式运行问题,提出公共-特有信息提取算法,并结合高阶-低阶信息结构,将原始空间信息进一步分解,并构建相应隐空间模型;再次,设计在线监控算法,可有效判断过程中存在的模式切换或故障,提高了多模式过程监控算法效果;最后,相关算法在实际工业设备运行环境中进行了验证,结果表明,所提出的算法在设备多模式运行状态监测中的效果相比传统方法有较大优势.

关键词: 工业设备运行监控; 质量信息提取; 高阶低阶信息; 公共特有信息

中图分类号: TP242.2

文献标志码: A

DOI: 10.13195/j.kzyj.2020.0947

引用格式: 何雨辰,王云,刘涛,等. 基于公共特有子空间提取的工业设备多模式运行过程故障检测方法[J]. 控制与决策, 2022, 37(6): 1469-1478.

Multimode process monitoring for industrial equipments utilizing common-specific information extraction strategy

HE Yu-chen¹, WANG Yun^{2†}, LIU Tao¹, XIANG Jian³, LOU Rui-chong⁴, WANG Yu-qi⁴

(1. School of Mechanical Engineering, Zhejiang University, Hangzhou 310027, China; 2. Mechanical and Electrical Engineering Department, Zhejiang Tongji Vocational College of Science and Technology, Hangzhou 311123, China; 3. Zhejiang Qianjiang Robot, Taizhou 317500, China; 4. College of Mechanical & Engineering, China Jiliang University, Hangzhou 310018, China)

Abstract: Industrial equipments have been widely used in modern industry, which indicates that the final product quality highly relies on the operational status of industrial equipments. Therefore, it is of high importance to detect the quality-related faults in equipments where non-linearity and non-stationarity are considered as two crucial characteristics in operating data. In this paper, high order and low order information in process data are discussed in details where a two-step latent variables extraction method is implemented using maximum mutual information and partial least square (PLS). In order to handle multimode process monitoring issue, a common-specific information strategy is designed. Combined with the high order and low order information extraction, the original data are further separated into four subspaces: common high, common low, specific high and specific low order information, respectively. Secondly, an online monitoring algorithm is developed, which helps identify mode switch or fault and improves the performance of multi-mode process monitoring. Finally, monitoring performance is further demonstrated on a real mechanical arm where the result shows the superiority of the proposed method.

Keywords: industrial equipments monitoring; quality information extraction; high-low order information; common-specific information

收稿日期: 2020-07-11; 录用日期: 2021-04-06.

基金项目: 国家自然科学基金项目(61903352, 51775485); 中国博士后基金项目(2020M671721); 浙江省自然科学基金项目(LQ19F030007, LZ20E050002); 浙江省教育厅一般项目(Y202044960); 浙江同济科技职业学院科研项目(TRC1904).

责任编辑: 吴立刚.

†通讯作者. E-mail: wy@zjtongji.edu.cn.

0 引言

随着我国工业自动化水平的不断提高,工业设备在实际工业生产中得到了长足发展和广泛应用.工业设备是先进制造业的关键支撑装备,其生产方式不断向柔性、智能、精细转变,构建以智能制造为根本特征的新型制造体系迫在眉睫,近些年行业对工业设备的需求呈大幅增长趋势^[1].工业设备的稳定运行与否直接决定了产品生产过程安全与最终质量的可靠性;同时,工业设备中包含多元传感器,而单纯运用单一传感器无法对工业设备中部分故障进行合理的检测.因此,需要综合过程中的多元传感器对工业设备运行过程进行监测,保障生产过程和产品的稳定性.

近些年,诸多学者针对工业机械臂运行过程监测展开了深入的研究^[2-3],按处理方式的不同大致可分为基于机理模型的方法和基于数据驱动的方法.基于机理模型的方法从机械臂物理结构方面对设备各系统组成及传感器之间的关系进行了详细的描述,通过分析机理模型参数在不同数据集下的变化,可判断系统当前状态中是否包含异常信息^[4].其中,文献[5]建立相应失效机理,并结合机电系统自身参数,对系统运行状况和剩余寿命进行了预测.文献[6]中建立了系统退化的动力学模型,并根据传感器中检测到的声音振动信号进行系统运行健康评估.为了刻画故障相关信息,近些年学者们研究并改进了基于观测器的故障诊断方法,其中主要包括自适应观测器、高增益观测器等^[7-8].例如,文献[9]对传统滑模观测器结构进行了优化,通过引入二阶滑模与神经网络,对过程中的故障进行诊断,保证了神经网络有限时间的收敛性.针对时变扰动,文献[10]运用自适应估计方法,并结合软测量技术开展早期故障的检测与诊断.文献[11]运用一种新型非线性控制策略,采用高增益状态观测器对状态向量和非线性动态进行估计,并在5自由度机械臂中得到了应用.

由于基于解析模型的故障检测方法对数学模型精度要求较高,相关模型特征参量的测量与计算偏差会直接导致模型失效,继而无法对实际机械臂系统进行完整描述,这也提高了相关技术开发成本和研发复杂度.随着近些年分布式集散系统(DCS)和互联网技术的高速发展,相关技术被应用于工业设备运行过程,并采集到了大量过程数据.如何充分运用工业设备现场运行数据,并提取其中数据特征用于工业设备运行过程监测成为了一个亟需解决的问题.近些年,数据驱动的工业设备运行状态故障诊断方法逐渐受到学者们的重视^[12-13].其中,多元统计分析方法在工

业过程故障诊断中得到了较好的应用,例如主元分析方法(principal component analysis, PCA)^[14-15]. Harrou等^[14]采用PCA生成过程数据的部分残差,结合 k 最近邻(k nearest neighbourhood, k NN)对相关残差进行信息识别,并绘制相关图谱对机械臂运行过程进行监测.为了解决工业设备实际运行过程存在的问题,加强机器学习在设备运行过程监测中的效果, Vallachira等^[15]以系统化假设为前提,对数据预处理过程展开了深入的研究,运用逻辑回归(logical regression, LR)和PCA方法对训练与测试数据进行分析,并输入分类器中,达到故障检测的目的.这些方法提取过程数据中的特征信息,并根据数据变化程度定义了相应正常工作区域.基于这一区域,将待检测数据与训练数据进行比较,进而在线判断这些待检测数据是否处于正常工作区域.如果在线数据相关特征量超过相关工作区域,意味着过程中有异常变化产生,以此对过程进行监控.为了充分考虑质量变量相关关系, Wold等^[16]提出了偏最小二乘(partial least squares, PLS)等方法,该方法建立新的优化函数以寻求不同空间隐变量之间的协方差最大化,并取得了较好的效果.考虑到上述方法中只运用二阶及以下统计量来描述过程数据特征,忽略了过程数据非高斯分布的情况;因此, Hyvärinen等^[17]提出了独立元分析(independent component analysis, ICA)方法,运用其中的独立元对过程中存在的非高斯分布信息进行提取.针对设备运行过程数据存在的不同数据特性,采用多元统计分析方法通过对传感器变量进行综合分析,对数据降维的同时提取相关数据特征信息,并设计相应统计量对过程关键信息进行监控,达到了较好的监测效果.

值得注意的是,在智能化工厂中,为满足客户不同的产品需求,通常情况下,单条生产线需要柔性化生产多个批次的产品.因此,同一条生产线上的工业设备需要进行不同模式的操作设定,以满足最终产品的生产要求^[10,18].为此,有必要根据工业设备运行状态选择合适模型对其相关数据特性进行描述. Park等^[19]针对设备运行过程数据存在自相关性等特点,运用隐马尔可夫模型(hidden Markov model, HMM),并根据运行过程的实时变化设计可变阈值对过程进行有效监测.在此基础上,结合高斯过程回归(Gaussian process regression, GPR), Park等^[20]对由于复杂环境影响所导致的工业设备多模式运行过程监测问题提出了改进方法.上述方法在一定程度上解决了由过程多工况所带来的模型失效问题,但

其得到的结果依然严重依赖过程相关数据特性服从高斯分布的前提假设,所建立的动态模型隐变量仍然服从高斯分布.由于复杂工业设备运行过程中各执行器和传感器变量之间存在较强的数学耦合,实际过程中数据大多不服从高斯分布,单纯运用基于线性、高斯变量构建的数学模型不能完全描述数据中复杂的数学关系.

如前所述,由于过程变量之间存在较强的耦合,以往数学模型中基于诸如方差、协方差所刻画模型特性只局限于二阶及以下统计量,未能完整地描述系统中高阶信息进行分析.交互熵方法作为一种衡量变量之间独立性的工具,相比协方差等二阶指标更能够描述过程变量之间深层次关系^[21-22].考虑到交互熵方法在提取高阶信息中的优势,He等^[23]提出了基于双层非高斯监控算法(double layer non-Gaussian monitoring, DLNGM),构建高阶信息特征空间对过程中质量相关数据进行提取,并用于大规模数据的分类和故障检测中.本文在前期研究基础上,采用一种基于最大交互熵展开方法的隐空间模型,该模型可对过程中二阶以上的高阶信息展开研究,有效解决了以往模型中未能完整提取过程高阶数据的问题.同时,由于过程存在多模式状态,不同模式的数据之间存在区别,考虑到物理结构中各变量之间关系在多模式切换过程下仍然保留有大量共性特征,需要针对不同模式下设备运行过程数据的公共与特有信息开展深入研究.公共信息通常被多个模式共享,且在整个设备运行过程中较为稳定.相反,包含各自模式特有信息的相关数据特征通常无法表征另外模式数据的特有信息.为完整提取多模式中的公共与特有信息,近年来有学者提出了基于子空间分解的解决思路^[24-25].Zhao等^[25]通过MsPCA方法对每个模式中变量之间的关系进行分析,进而对多模式过程中每个模式的特征进行单独提取,最后分析各模式特征之间的关系.然而,这一方法忽略了变量间关系对于公共与特有信息提取的影响,即单个模式中残差内的信息可能与另外模式的关联性更大,因此这一方法无法有效提取过程中的共同信息.为改善上述问题,Zhang等^[26-27]运用核偏最小二乘(kernel partial least squares, KPLS)方法对两个模式之间共同信息进行提取分析,并基于分析结果得到各个模式下相应的特有信息.该方法在考虑稳态工况的同时,兼顾了过渡过程,并建立相应子空间模型.然而,对于包含3个及以上模式的过程,该类方法中的共同特征子空间并未能有效提取各模式之间的共享信息.为此,Zhang

等^[26]在两模式基础上,基于PCA与PLS等方法,通过构建公共负载矩阵等特征参数,对多工况中过程的公共与特有信息进行提取.

为了更好地提取工业设备多模式状态下的公共与特有信息,本文提出一种新型公共与特有子空间结构对多模式过程相关数据特性进行分析.该方法的主要创新点和贡献总结如下:

1) 针对现有多模式方法中高阶信息提取不完全等问题,本文构建一种基于最大交互熵展开方法对过程中质量相关的高阶信息进行提取;

2) 针对现有多模式研究中公共特征空间信息提取不完善等问题,本文通过建立公共隐变量,将不同模式中的相似信息加以保留,并配合高阶信息与低阶信息提取方法,加强对多模式过程特征的提取;

3) 针对多模式过程监测中同时存在模式切换和故障检测的情况,本文提出一种工业设备多模式过程故障检测方法,运用公共与特有子空间中相关模型,将模式切换识别与故障检测进行有机统一,提高了多模式过程监测效率.

1 高阶信息提取方法

PLS方法隐空间的构建过程主要是基于协方差最大化思想设计目标函数,即在PLS中过程变量与质量变量对应隐变量之间的二阶关系达到了最大化.但是如前所述,过程中仍然包含大量高阶信息,这些高阶信息无法单纯运用二阶的方差或协方差进行表示,因此有必要重新设计目标函数对过程中相应高阶统计量进行描述.

在非高斯回归(NGR)方法中^[20],对于任意一组归一化后的变量,其相关隐变量可表示为

$$\begin{cases} t = xw, \\ u = yr, \end{cases} \quad (1)$$

其中 w 、 r 分别表示相关隐变量的权值向量.本文运用以下最大交互熵展开方法求取相关权值向量:

$$\begin{aligned} f(w, r) = & \\ & \alpha(H(v) - H(xw)) + \beta(H(xw) + H(yr) - \\ & H(xw, yr)) + \gamma(H(v) - H(yr)). \end{aligned} \quad (2)$$

其中: v 表示服从高斯分布的随机变量, $H(xw)$ 表示变量 xw 的熵, $H(xw, yr)$ 表示 xw 和 yr 的联合熵.上述优化函数中熵值运用Edgeworth展开可表示为如下形式^[28]:

$$H(p) = H(\phi_p) - \int p(v) \log \frac{p(v)}{\phi_p(v)} dv, \quad (3)$$

其中 ϕ_p 表示任意变量 p 的最优高斯估计.从上述方

程可以看出,熵方法在提取低阶信息的同时,也考虑了高阶信息,因此在优化函数中引入熵方法对隐变量高阶信息的提取有着较大帮助.基于式(1)和(2),可以提取过程中的高阶信息量,并配合之前已有的一系列低阶信息提取方法,对过程相关特征进行完整提取.在后续章节中,本文将根据这些信息对工业设备运行中不同模式的共同信息与特有信息进行分析,并建立相关统计量对过程进行监控.

2 工业设备多模式信息提取与故障检测方法

基于上一节的讨论,通过引入熵方法将运行过程中高阶信息量进行了提取,但是考虑到过程中除高阶信息外,仍然含有大量的低阶信息,因此有必要对过程进行二次提取,达到相关数据的完整描述.这里采用较为成熟的PLS方法对低阶信息中质量相关数据特征进行描述.

$$\begin{cases} X_L = T_L P_L^T + E_L, \\ Y_L = U_L Q_L^T + F_L. \end{cases} \quad (4)$$

其中: T_L 、 U_L 、 P_L 、 Q_L 、 E_L 和 F_L 分别代表低阶信息中主元矩阵、负载矩阵以及残差矩阵; X_L 和 Y_L 分别为高阶信息提取完成后剩余数据中的低阶信息量.

对于多模式过程,其共同信息可表示为共享隐空间信息.为此,基于多模式隐变量信息共享最大化思想,本文设计了如下目标函数:

$$\begin{aligned} f(t_c, u_c) = & \\ & \alpha(H(v) - H(t_c)) + \beta(H(t_c) + H(u_c) - \\ & H(t_c, u_c)) + \gamma(H(v) - H(u_c)). \end{aligned} \quad (5)$$

其中相关隐变量可表示如下:

$$\begin{cases} t_c = \sum_{i=1}^N \lambda(i) X_{(i)} w_c, \\ u_c = \sum_{i=1}^N \tau(i) Y_{(i)} r_c. \end{cases} \quad (6)$$

其中: $X_{(i)} \in R^{n \times m}$ 和 $Y_{(i)} \in R^{n \times l}$ 分别表示第*i*个模式的过程数据和质量数据; $\lambda(i)$ 和 $\tau(i)$ 分别表示第*i*个模式对于共同信息的贡献度; w_c 和 r_c 分别表示相应特征信息与原始空间信息之间对应的权重向量.考虑到这些信息仍然包含高阶与低阶信息,因此需要对共同信息中不同阶次的特征进行分类提取.本文运用前述高阶信息与低阶信息提取方法,对不同阶次信息内的共同信息与特有信息作进一步提取.

在式(6)中包含多个自变量,包括 $\lambda(i)$ 、 w_c 、 $\tau(i)$ 、

r_c 等参数,因此共同信息的提取涉及多参数优化问题.这里运用双循环迭代方法,即首先对相应负载矩阵进行随机初始化,将其视为已知量并求取参数 $\lambda(i)$ 、 $\tau(i)$,再将相关参数重新代入反求负载矩阵参数.具体步骤如下:

- 1) 归一化原始过程数据与质量数据;
- 2) 随机初始化高阶共同信息贡献度 $\lambda_H(i)$ 和 $\tau_H(i)$;
- 3) 将2)中的贡献度代入式(6)并结合式(2)求取高阶共同信息中的负载向量 w_{cH} 、 r_{cH} ;
- 4) 将3)中得到的负载向量代入式(6),此时待求自变量为高阶共同信息贡献度向量 λ_H 和 τ_H ;
- 5) 将4)得到的目标函数代入式(2),求解向量 λ_H 和 τ_H ;
- 6) 重复3)~5),直至模型所有参数收敛;
- 7) 根据式(1)求取第*i*个模式的得分

$$t_{cH(i)} = X_{(i)} w_{cH}, \quad u_{cH(i)} = Y_{(i)} r_{cH},$$

以及相应负载向量

$$p_{cH(i)} = \frac{X_{(i)}^T t_{cH(i)}}{\|t_{cH(i)}\|^2}, \quad q_{cH(i)} = \frac{Y_{(i)}^T u_{cH(i)}}{\|u_{cH(i)}\|^2},$$

同时计算剩余残差

$$X_{(i)} = X_{(i)} - X_{(i)} w_{cH} p_{cH(i)}^T,$$

$$Y_{(i)} = Y_{(i)} - Y_{(i)} r_{cH} q_{cH(i)}^T,$$

并将其代入2)继续提取数据中剩余高阶公共信息.

通过上述步骤可以得到多模式过程中的高阶共同信息特征量,包括权值矩阵

$$W_{cH} = [w_{cH}^1 \quad w_{cH}^2 \quad \dots \quad w_{cH}^n],$$

$$R_{cH} = [r_{cH}^1 \quad r_{cH}^2 \quad \dots \quad r_{cH}^n],$$

以及负载矩阵

$$P_{cH(i)} = [p_{cH(i)}^1 \quad p_{cH(i)}^2 \quad \dots \quad p_{cH(i)}^n],$$

$$Q_{cH(i)} = [q_{cH(i)}^1 \quad q_{cH(i)}^2 \quad \dots \quad q_{cH(i)}^n].$$

这些信息由各个模型相应部分与其对应的贡献度结合得到,有较高的可解释性.由于上述步骤只针对过程中与高阶量相关的共同信息,在对各模式中特有信息进行提取之前,需要运用PLS方法对过程中低阶量相关的共同信息进行再次提取,完善共同信息对过程高阶量与低阶量的描述.多模式过程中低阶共同信息提取步骤如下所示:

- 1) 提取高阶共同信息后,分别求取第*i*个模式中的剩余残差

$$X_{(iLe)} = X_{(i)} - X_{(i)} W_{cH} P_{cH(i)}^T,$$

$$Y_{(iLc)} = Y_{(i)} - Y_{(i)}R_{cH}Q_{cH}^T;$$

2) 随机初始化低阶共同信息贡献度 $\lambda_L(i)$ 和 $\tau_L(i)$;

3) 将2)中的贡献度代入式(6)并结合PLS, 求取低阶共同信息中的负载向量 w_{cL} 和 r_{cL} ;

4) 将3)中得到的负载向量代入式(6), 此时待求自变量为低阶共同信息贡献度向量 λ_L 和 τ_L ;

5) 将4)得到的目标函数代入式(2), 求解 λ_L 和 τ_L ;

6) 重复3)~5), 直至模型所有参数收敛;

7) 根据式(1)求取第 i 个模式的得分

$$t_{cL(i)} = x_{(i)}w_{cL}$$

及相应负载向量

$$p_{cL(i)} = \frac{X_{(iLc)}^T t_{cL(i)}}{\|t_{cL(i)}\|^2}, \quad q_{cL(i)} = \frac{Y_{(iLc)}^T u_{cL(i)}}{\|u_{cL(i)}\|^2},$$

同时计算剩余残差

$$X_{(iLc)} = X_{(iLc)} - X_{(i)}w_{cL}p_{cL}^T;$$

$$Y_{(iLc)} = Y_{(iLc)} - Y_{(i)}r_{cL}q_{cL}^T;$$

并将其代入2)继续提取数据中剩余高阶公共信息。

基于上述步骤, 可以对多模式过程中不同阶次的共同信息进行提取。值得注意的是, 在这些共同信息提取完成后, 过程中每个模式仍然包含大量信息, 这些信息通常描述单个模式的特有数据特性, 而且模式之间信息并不共享, 因此仍然需要对这部分信息进行提取以便后期进行相应的故障诊断。剩余信息可以从提取共同信息的数据残差中获得, 第 i 个模式数据残差可表示为如下形式:

$$\begin{cases} X_{I(i)} = X_{(i)} - T_{cH(i)}P_{cH}^T - T_{cL(i)}P_{cL}^T, \\ Y_{I(i)} = Y_{(i)} - U_{cH(i)}Q_{cH}^T - U_{cL(i)}Q_{cL}^T. \end{cases} \quad (7)$$

其中 P_{cH} 、 P_{cL} 、 Q_{cH} 、 Q_{cL} 分别代表共同信息中高阶与低阶的负载矩阵, $T_{cH(i)}$ 、 $T_{cL(i)}$ 、 $U_{cH(i)}$ 、 $U_{cL(i)}$ 则分别代表第 i 个模式下公共信息对应的主元矩阵。由式(7)得到的数据残差只包含了每个模式下数据的特有信息, 需要对各部分数据进行单独建模, 考虑到 $X_{I(i)}$ 与 $Y_{I(i)}$ 仍然有不同阶次信息, 因此需要对这些特有信息进行分层次的建模。具体步骤如下所示:

1) 运用式(7)得到特有信息空间与公共信息空间, 并代入式(1)和(2)中, 求取相应模式内高阶信息对应的权值向量与负载向量 $w_{sH(i)}$ 、 $r_{sH(i)}$ 、 $p_{sH(i)}$ 、 $q_{sH(i)}$;

2) 计算剩余残差

$$X_{(iLs)} = X_{I(i)} - X_{I(i)}w_{sH(i)}p_{sH}^T;$$

$$Y_{(iLs)} = Y_{I(i)} - Y_{I(i)}r_{sH(i)}q_{sH}^T;$$

3) 针对 $X_{(iLs)}$ 、 $Y_{(iLs)}$, 运用PLS模型求取相应模式 i 对应的权值向量与负载向量 $w_{sL(i)}$ 、 $r_{sL(i)}$ 、 $p_{sL(i)}$ 、 $q_{sL(i)}$ 。

通过对特有信息的提取, 可以对各模式数据进行进一步分析, 并将其分解为不同阶次的信息。因此, 总结多模式过程信息提取方法, 工业设备运行过程的原始数据空间可分解为如下形式:

$$\begin{cases} X_{(i)} = T_{cH(i)}P_{cH}^T + T_{cL(i)}P_{cL}^T + T_{sH(i)}P_{sH}^T + \\ \quad T_{sL(i)}P_{sL}^T + E_{(i)}, \\ Y_{(i)} = U_{cH(i)}Q_{cH}^T + U_{cL(i)}Q_{cL}^T + U_{sH(i)}Q_{sH}^T + \\ \quad U_{sL(i)}Q_{sL}^T + F_{(i)}, \end{cases} \quad (8)$$

其中 $T_{sH(i)}$ 、 $T_{sL(i)}$ 、 $U_{sH(i)}$ 、 $U_{sL(i)}$ 分别代表第 i 个模式内特有信息相应空间的主元矩阵。通过式(8), 每个模式可以被分解为4个空间, 分别对应高阶与低阶的公共与特有信息, 如图1所示。

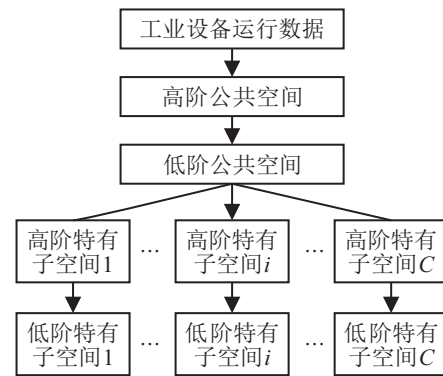


图1 子空间分解流程

不同模式共享公共负载矩阵等公共子空间特征信息, 这部分信息表明了在同一系统中不同模式之间仍然包含部分共同点。在提取完公共子空间后, 式(8)提取各个模式中特有的信息, 并构建不同层次的子空间, 不同模式特有信息中的差异性得到了保留。因此, 本文提出的多层次结构能够满足工业设备多模式运行过程监测需求。

3 工业设备多模式运行过程识别与故障检测

在对多模式运行过程中不同信息进行提取后, 需要依据提取的信息构建统计量对过程进行监测。考虑到多模式过程中不同模式的切换会对故障检测造成干扰, 因此采用识别与故障检测一体式的方法开展相关研究, 即在线识别与故障检测同步进行。假设待检测的在线样本可表示为 (x_{test}, y_{test}) , 其不同空间的隐变量可分别表示为如下形式:

$$\begin{cases} t_{cH,\text{test}} = x_{\text{test}} W_{cH}, \\ t_{cL,\text{test}} = x_{\text{test}} (I_{cH} - W_{cH} P_{cH}^T) W_{cL}, \\ t_{sH,\text{test}} = \\ x_{\text{test}} (I_{cH} - W_{cH} P_{cH}^T) (I_{cL} - W_{cL} P_{cL}^T) W_{sH}, \\ t_{sL,\text{test}} = \\ x_{\text{test}} (I_{cH} - W_{cH} P_{cH}^T) (I_{cL} - W_{cL} P_{cL}^T) \times \\ (I_{sH} - W_{sH} P_{sH}^T) W_{sL}, \end{cases} \quad (9)$$

其中 I_{cH} 、 I_{cL} 、 I_{sH} 分别代表相应维度的单位矩阵. 值得注意的是, 上述高阶隐变量通常不服从高斯分布, 因此需要构建新统计量对过程进行监测. 为此, 本文引入核密度估计方法(KDE)定义高阶统计量, 相关统计量可表示为如下形式:

$$\begin{cases} I_{cH}^2 = t_{cH,\text{test}} \left(\frac{T_{cH(i)}^T T_{cH(i)}}{n-1} \right)^{-1} t_{cH,\text{test}}^T, \\ I_{sH}^2 = t_{sH,\text{test}} \left(\frac{T_{sH(i)}^T T_{sH(i)}}{n-1} \right)^{-1} t_{sH,\text{test}}^T. \end{cases} \quad (10)$$

其中 I_{cH}^2 和 I_{sH}^2 分别代表公共与特有信息的高阶统计量, 同时相关统计限运用 KDE 可表示如下:

$$\begin{cases} f_{cH}(x) = \frac{1}{n\lambda_{cH}} \sum_{i=1}^n K \left(\frac{I_{cH}^2 - I_i^2}{\lambda_{cH}} \right), \\ f_{sH}(x) = \frac{1}{n\lambda_{sH}} \sum_{i=1}^n K \left(\frac{I_{sH}^2 - I_i^2}{\lambda_{sH}} \right). \end{cases} \quad (11)$$

其中: K 是核函数, λ 为平滑参数或带宽, $I_i^2 (i = 1, 2, \dots, n)$ 为第 i 个在线样本的相关统计量. 在式(10)和(11)中, 分别给出了高阶信息统计量与相应统计限. 而在低阶信息的监控中, 相关信息通常满足高斯分布, 可以运用 Hotelling's T^2 来定义如下统计量与统计限:

$$\begin{cases} T_{cL}^2 = t_{cL,\text{test}} \left(\frac{T_{cL(i)}^T T_{cL(i)}}{n-1} \right)^{-1} t_{cL,\text{test}}^T, \\ T_{sL}^2 = t_{sL,\text{test}} \left(\frac{T_{sL(i)}^T T_{sL(i)}}{n-1} \right)^{-1} t_{sL,\text{test}}^T; \end{cases} \quad (12)$$

$$\begin{cases} T_{\alpha,cL}^2 = \frac{k_{cL}(n^2-1)}{n(n-k_{cL})} F_{\alpha}(k_{cL}, n-k_{cL}), \\ T_{\alpha,sL}^2 = \frac{k_{sL}(n^2-1)}{n(n-k_{sL})} F_{\alpha}(k_{sL}, n-k_{sL}). \end{cases} \quad (13)$$

本文基于上述统计量与统计限, 对多模式过程同时进行在线模式识别与故障检测, 相关算法流程如图2所示.

算法步骤具体如下:

1) 分别计算在线测试样本在第 i 个模式下的统计量 $I_{cH(i)}^2$ 、 $I_{sH(i)}^2$ 、 $T_{cL(i)}^2$ 、 $T_{sL(i)}^2$ 以及相关模式的统计限 $f_{cH(i)}$ 、 $f_{sH(i)}$ 、 $T_{\alpha,cL(i)}^2$ 、 $T_{\alpha,sL(i)}^2$;

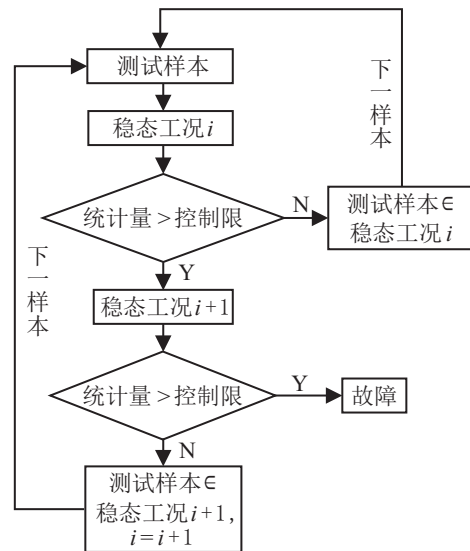


图2 工业设备在线识别与故障检测方法流程

2) 当且仅当 $I_{cH(i)}^2 < f_{cH(i)}$ 、 $I_{sH(i)}^2 < f_{sH(i)}$ 、 $T_{cL(i)}^2 < T_{\alpha,cL(i)}^2$ 、 $T_{sL(i)}^2 < T_{\alpha,sL(i)}^2$ 都满足时, 工业设备运行过程状态无切换且无故障;

3) 当上述任一统计量超过相应统计限时, 计算在线测试样本在第 $i+1$ 个模式下的统计量 $I_{cH(i+1)}^2$ 、 $I_{sH(i+1)}^2$ 、 $T_{cL(i+1)}^2$ 、 $T_{sL(i+1)}^2$ 以及相应统计限 $f_{cH(i+1)}$ 、 $f_{sH(i+1)}$ 、 $T_{\alpha,cL(i+1)}^2$ 、 $T_{\alpha,sL(i+1)}^2$, 比较统计量与统计限之间的关系, 如果 $I_{cH(i+1)}^2 < f_{cH(i+1)}$ 、 $I_{sH(i+1)}^2 < f_{sH(i+1)}$ 、 $T_{cL(i+1)}^2 < T_{\alpha,cL(i+1)}^2$ 、 $T_{sL(i+1)}^2 < T_{\alpha,sL(i+1)}^2$ 都满足时, 则表示工业设备运行状态发生切换;

4) 如不满足3)的条件, 则表明过程存在故障;

5) 检测下一个在线测试样本并重复1)~5)。

根据上述步骤, 可同时实现工业设备运行状态在线识别与故障检测的目标. 首先, 需要通过式(10)和(12)计算过程中高阶信息与低阶信息的相关统计量, 并结合式(11)和(13)所建立的统计限, 对过程当前状态进行故障检测, 如1)和2)所示. 如果当前时刻在模式 i 中未能检测故障, 则表示在线样本状态与模式 i 一致且过程中无故障. 如果样本在当前训练模型下被检测出故障, 则存在两种可能, 即过程中含有故障或者过程在线模式存在切换, 需要进一步对过程进行监测, 如3)所示. 针对上述情况, 可采用下一模式(第 $i+1$ 模式)对过程当前时刻进行检测. 如果满足3)中的条件, 则认为过程故障检测超限是由于过程模式切换造成的, 过程并无故障发生. 值得注意的是, 工业设备实际运行过程存在部分扰动, 这会使得过程当前状态发生微小波动, 对过程识别与故障检测产生干扰. 因此, 本文在过程状态切换的判别中加入缓冲区, 即连续多点检测均满足4)中的条件, 才判定过程状态发生切换, 这一缓冲经过实际验证可有效改善过程

表1 多轴工业机器人具体参数

关节	质量/kg	重心坐标/mm			惯性力矩表(每根轴的末端作为坐标系)/(kg·mm ²)					
		X	Y	Z	1xx	1yy	1zz	1xy	1xz	1yz
J ₁	100	-99.2	-153.9	-77.8	5.425 × 10 ⁶	3.23 × 10 ⁶	6.06 × 10 ⁶	-2.35 × 10 ⁶	-6.8 × 10 ⁵	-1.01 × 10 ⁶
J ₂	14	-254.6	23.5	43.2	7.21 × 10 ⁴	1.62 × 10 ⁵	1.63 × 10 ⁶	8.1 × 10 ³	1.31 × 10 ⁵	-1.398 × 10 ⁴
J ₃	27.8	-101.5	-20.5	-118.2	7.067 × 10 ⁵	1.1 × 10 ⁶	7.4 × 10 ⁵	-7.19 × 10 ³	-4.79 × 10 ⁵	-1.18 × 10 ⁴
J ₄	10.7	0.988	296.1	28	1.21 × 10 ⁶	6.65 × 10 ⁴	1.19 × 10 ⁶	2.64 × 10 ³	-2.75 × 10 ²	1.25 × 10 ⁵
J ₅	45	-30	20.7	-77.8	4.96 × 10 ⁴	5.43 × 10 ⁴	1.84 × 10 ⁴	2.03 × 10 ²	-9.52 × 10 ³	1.02 × 10 ⁴

扰动所带来的过程状态误判. 如果过程当前时刻状态经连续两个模式检测, 均发生超限现象, 则认为过程存在故障, 需要对过程进行及时报警.

本文提出的工业设备在线识别与故障检测方法通过比较当前时刻统计量与相应模式统计限, 可有效改善工业设备多模式运行过程在线识别误判情况, 同时可提高过程故障检测效率, 保证设备运行过程的稳定与安全.

4 算法验证

本文算法在如图3所示的工业机器人环境中作了进一步验证, 具体参数如表1所示. 选取并采集各关节水平夹角、位置、速度、转矩等信号. 由于生产线中产品质量通常与机械臂的末端点位置的精确程度有直接关系, 本文以机械臂的末端点位姿作为模型中的关键质量变量, 其余传感器采集的数据作为过程变量. 具体各传感器设置如表2所示.



图3 工业机械臂实验环境

本文为了模拟机器人多工况运行过程, 将机械臂末端点运行轨迹设置为直线、三角形、四边形, 并在3种运行过程中分别采集了1000个样本点组成了包含3000个样本点的训练数据集. 此外, 为了模拟机械臂故障干扰信号, 本文在每个工况第501个采样点处引入故障干扰, 干扰源为放置在同一台机械臂末端点的2kg负载, 并进行了相同操作下3个工况的故障数据采集, 用以验证算法在建模与故障检测方面的效果.

首先, 本文运用新型子空间分解方法对工业机器人多工况运行过程进行建模, 将空间分解为4个子空

间, 并在每个子空间内建立统计限对多工况过程进行在线识别与故障检测, 具体故障检测结果如表3所示.

表2 机械臂各传感器描述

变量	变量描述
过程变量1	1关节水平夹角
过程变量2	2关节水平夹角
过程变量3	3关节水平夹角
过程变量4	4关节水平夹角
过程变量5	5关节水平夹角
过程变量7	1关节实际位置值
过程变量8	2关节实际位置值
过程变量9	3关节实际位置值
过程变量10	4关节实际位置值
过程变量11	5关节实际位置值
过程变量13	1关节实际速度值
过程变量14	2关节实际速度值
过程变量15	3关节实际速度值
过程变量16	4关节实际速度值
过程变量17	5关节实际速度值
过程变量19	1关节电机电流有效值
过程变量20	2关节电机电流有效值
过程变量21	3关节电机电流有效值
过程变量22	4关节电机电流有效值
过程变量23	5关节电机电流有效值
过程变量25	1关节转矩有效值
过程变量26	2关节转矩有效值
过程变量27	3关节转矩有效值
过程变量28	4关节转矩有效值
过程变量29	5关节转矩有效值
质量变量1	末端点x轴方向加速度
质量变量2	末端点y轴方向加速度
质量变量3	末端点z轴方向加速度
质量变量4	末端点x轴方向角速度
质量变量5	末端点y轴方向角速度
质量变量6	末端点z轴方向角速度
质量变量7	末端点x轴方向角度
质量变量8	末端点y轴方向角度
质量变量9	末端点z轴方向角度

表3 两类过程监测方法故障检出率和误检率对比

指标	本文算法	PLS	DLNGM	ChI-PLS
故障检出率/%	91.2	17.0	54.67	72.47
故障误检率/%	5.03	4.77	4.47	0.73

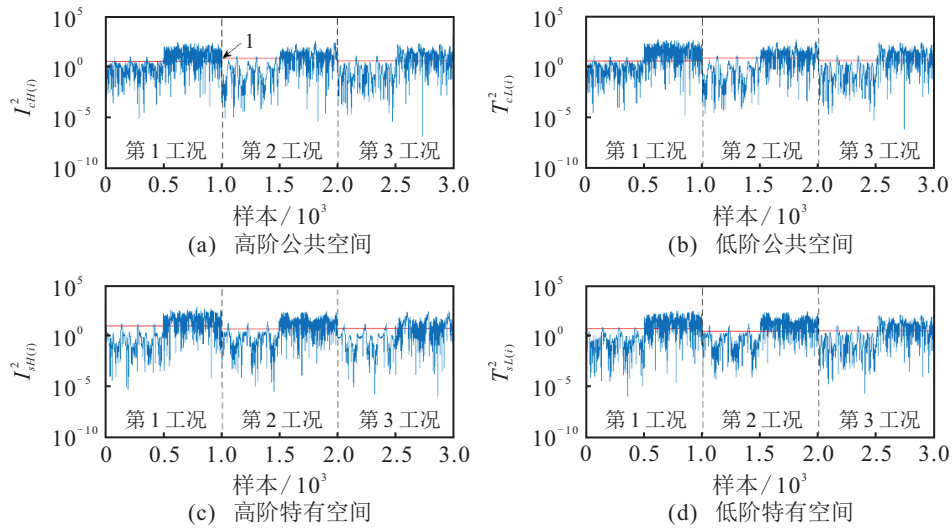


图4 基于子空间分解方法的工业机器人运行过程监测结果

由图4中标注1处的模型跳变可以看出,本文所提出的工业机器人运行过程监测算法可有效对不同运行模式进行识别并切换相应模型以适应工况变化,降低了设备运行过程监测的误报率.

与此同时,在各模式中,本文算法针对过程中存在的不同类型数据特性,将过程分解为多个子空间,各子空间内均能检测到各工况后半段产生的故障,达到了较好的监测效果,在保持较低故障误检率的同时,提高了故障的检出率.为对比工业机器人运行过程监测效果,本文还引入PLS方法、非高斯监控(DLNGM)以及CnI-PLS方法对同一机器人运行过程进行监测,用于分析高阶信息以及公共特有空间的引入对过程监控带来的影响.相关方法的故障检测结果如图5~图7所示.

首先,运用PLS方法对过程进行故障检测,如图5所示,由于PLS方法只能提取过程中的低阶信息量,在特有空间中仍然包含大量的高阶公共特征未被提




图5 基于PLS的工业机器人运行过程监测结果




图6 基于CnI-PLS的工业机器人运行过程监测结果




图7 基于DLNGM的工业机器人运行过程监测结果

取,因此建模效果不理想,未能对不同模态中发生的故障进行有效识别预警,即便故障误检率较低,仍然存在较高的故障漏报率.同时,由于工业机器人模式

的在线识别依赖于故障检测结果,因此在前两个模式切换过程中,基于PLS的工业机器人模式在线识别方法也未能及时有效调整相应模型参数以适应不同模式切换带来的监测模型变化.为了改善过程中公共特有信息提取不充分对故障检测所带来的影响,本文引入CnI-PLS方法对相同工况进行故障检测,检测效果如图6所示.由于CnI-PLS方法重点对过程中公共信息和特有信息进行了提取,并对各子空间分别进行故障检测,取得了较好的效果,相比于PLS方法故障检出率和误检率都得到了较大的改善.然而值得注意的是,CnI-PLS方法本质上仍然是一种低阶特征提取方法,并未能充分考虑过程中的高阶信息.为此,引入DLNGM方法对相同工况进行故障检测对比试验,其检测结果如图7所示.相比于PLS等低阶方法,DLNGM在建模过程中考虑了高阶信息,并对高阶和低阶信息进行了分类提取,因此故障检出率和误检率都有一定的提升.然而,DLNGM方法并没有充分考虑多工况过程中不同工况之间的联系和区别,因此存在一定的故障漏检和误检情况.为了克服上述方法在多工况机器人运行过程中遇到的困境,本文算法对相同工况进行了故障检测试验,检测效果如图4所示.从图中可以发现,本文算法有效结合了高阶信息与公共特有结构各自的优势,并将其有机结合用于多工况过程的故障检测中,取得了较好的效果,且工况在线识别效果由于模型精度的提升得到了较好的保障,进一步改善了过程中故障检测和误检情况.

5 结论

本文针对工业机器人运行过程数据中高低阶次信息以及多模式等复杂数据特性,提出了一套完整的工业机器人运行过程监测方法,以保证工业机器人的平稳有序运行.首先,提出了一种最大交互熵展开方法,并结合PLS方法,对过程中高阶与低阶信息开展相关研究;其次,针对过程多模式运行特点,引入了公共-特有子空间分解结构,并结合高阶与低阶信息,在不同子空间中提取过程相关特性;然后,基于子空间分解方法,设计工业机器人运行状态在线识别与故障检测方法,对设备运行状态进行有效监测;最后,本文提出的算法在实际工业机器人平台上进行了验证,表明本文提出的方法相对于传统方法在故障检出率上有一定的优势.

参考文献(References)

- [1] 王晓兵. 工业机器人故障诊断技术的发展趋势[J]. 科技与创新, 2018(11): 88-89.
(Wang X B. The development trend of industrial robot fault diagnosis technology [J]. Science and Technology & Innovation, 2018(11): 88-89.)
- [2] 李卓然. 基于贝叶斯网络分类算法的采摘机器人故障诊断研究[J]. 农机化研究, 2020, 42(5): 211-215.
(Li Z R. Fault diagnosis of picking robot based on Bayesian network classification algorithms[J]. Journal of Agricultural Mechanization Research, 2020, 42(5): 211-215.)
- [3] 张会彬. 基于模型的六自由度机械臂故障诊断研究[D]. 沈阳: 沈阳理工大学, 2019.
(Zhang H B. Research on fault diagnosis of 6-DOF manipulator based on model[D]. Shenyang: Shenyang Ligong University, 2019.)
- [4] 刘河星. 基于自组织临界理论的工业机器人故障预测方法研究[D]. 天津: 天津职业技术师范大学, 2019.
(Liu H X. Research on fault prognosis method of industrial robot based on self-organized criticality theory[D]. Tianjin: Tianjin University of Technology and Education, 2019.)
- [5] Pecht M, Jaai R. A prognostics and health management roadmap for information and electronics-rich systems[J]. Microelectronics Reliability, 2010, 50(3): 317-323.
- [6] Gašperin M, Juričić D, Boskoski P, et al. Model-based prognostics of gear health using stochastic dynamical models[J]. Mechanical Systems and Signal Processing, 2011, 25(2): 537-548.
- [7] 吴巍. 多机械臂协作系统的故障诊断与容错控制[D]. 郑州: 郑州大学, 2019.
(Wu W. Fault diagnosis and fault tolerant control for manipulators cooperation system[D]. Zhengzhou: Zhengzhou University, 2019.)
- [8] Caccavale F, Marino A, Muscio G, et al. Discrete-time framework for fault diagnosis in robotic manipulators[J]. IEEE Transactions on Control Systems Technology, 2013, 21(5): 1858-1873.
- [9] Van M, Kang H J, Suh Y S, et al. A robust fault diagnosis and accommodation scheme for robot manipulators[J]. International Journal of Control, Automation and Systems, 2013, 11(2): 377-388.
- [10] Rezazadeh A S, Koofigar H R, Hosseinnia S. Adaptive fault detection and isolation for a class of robot manipulators with time-varying perturbation[J]. Journal of Mechanical Science and Technology, 2015, 29(11): 4901-4911.
- [11] Mushage B O, Chedjou J C, Kyamakya K. Fuzzy neural network and observer-based fault-tolerant adaptive nonlinear control of uncertain 5-DOF upper-limb exoskeleton robot for passive rehabilitation[J]. Nonlinear Dynamics, 2017, 87(3): 2021-2037.
- [12] 王随平, 张彤, 宁小玲. 基于集成神经网络的深海机器

- 人故障诊断研究[J]. 计算机测量与控制, 2010, 18(4): 773-775.
(Wang S P, Zhang T, Ning X L. Fault diagnosis of deep-seabed mining robot based on integrated neural network[J]. Computer Measurement & Control, 2010, 18(4): 773-775.)
- [13] 张彤. 遗传神经网络在深海机器人故障诊断中的应用研究[D]. 长沙: 中南大学, 2010.
(Zhang T. Application of genetic algorithm and neural network in deep-seabed robot fault diagnosing[D]. Changsha: Central South University, 2010.)
- [14] Harrou F, Khaldi B, Sun Y, et al. An efficient statistical strategy to monitor a robot swarm[J]. IEEE Sensors Journal, 2020, 20(4): 2214-2223.
- [15] Vallachira S, Orkisz M, Norrlöf M, et al. Data-driven gearbox failure detection in industrial robots[J]. IEEE Transactions on Industrial Informatics, 2020, 16(1): 193-201.
- [16] Wold S, Sjöström M, Eriksson L. PLS-regression: a basic tool of chemometrics[J]. Chemometrics and Intelligent Laboratory Systems, 2001, 58(2): 109-130.
- [17] Hyvärinen A, Oja E. Independent component analysis: Algorithms and applications[J]. Neural Networks, 2000, 13(4/5): 411-430.
- [18] Yang H Y, Yin S. Actuator and sensor fault estimation for time-delay Markov jump systems with application to wheeled mobile manipulators[J]. IEEE Transactions on Industrial Informatics, 2020, 16(5): 3222-3232.
- [19] Park D, Erickson Z, Bhattacharjee T, et al. Multimodal execution monitoring for anomaly detection during robot manipulation[C]. 2016 IEEE International Conference on Robotics and Automation (ICRA). Sweden, 2016: 407-414.
- [20] Park D, Kim H, Kemp C C. Multimodal anomaly detection for assistive robots[J]. Autonomous Robots, 2019, 43(3): 611-629.
- [21] Kraskov A, Stögbauer H, Grassberger P. Estimating mutual information[J]. Physical Review E, Statistical, Nonlinear, and Soft Matter Physics, 2004, 69(6): 066138.
- [22] Zeng J, Xie L, Kruger U, et al. A non-Gaussian regression algorithm based on mutual information maximization[J]. Chemometrics and Intelligent Laboratory Systems, 2012, 111(1): 1-19.
- [23] He Y C, Zeng J S. Double layer distributed process monitoring based on hierarchical multi-block decomposition[J]. IEEE Access, 2019, 7: 17337-17346.
- [24] Zhao C H, Gao F R. Between-phase-based statistical analysis and modeling for transition monitoring in multiphase batch processes[J]. AIChE Journal, 2012, 58(9): 2682-2696.
- [25] Zhao C H, Gao F R, Niu D P, et al. A two-step basis vector extraction strategy for multiset variable correlation analysis[J]. Chemometrics and Intelligent Laboratory Systems, 2011, 107(1): 147-154.
- [26] Zhang Y W, Li S. Modeling and monitoring between-mode transition of multimodes processes[J]. IEEE Transactions on Industrial Informatics, 2013, 9(4): 2248-2255.
- [27] Zhang Y W, Wang C, Lu R Q. Modeling and monitoring of multimode process based on subspace separation[J]. Chemical Engineering Research and Design, 2013, 91(5): 831-842.
- [28] Van Hulle M M. Edgeworth approximation of multivariate differential entropy[J]. Neural Computation, 2005, 17(9): 1903-1910.

作者简介

何雨辰(1988—), 男, 副教授, 博士, 从事大数据分析处理/神经网络、流程工业数据处理与故障诊断等研究, E-mail: yche@cjlu.edu.cn;

王云(1987—), 女, 工程师, 硕士, 从事大数据分析处理、基于数据分析的工业先进机械臂运行过程监测的研究, E-mail: wy@zjtongji.edu.cn;

刘涛(1979—), 男, 教授, 博士, 从事人体动力学分析和生物力学信息反馈的穿戴式传感器系统、运动康复机器人等研究, E-mail: liutao@zju.edu.cn;

项剑(1986—), 男, 工程师, 硕士, 从事工业机械臂软硬件的研究, E-mail: xiangjian@qj-robot.com;

娄睿冲(1997—), 男, 硕士生, 从事工业过程故障分类算法、集成结构的研究, E-mail: P20010854033@cjlu.edu.cn;

王玉琦(1999—), 男, 硕士生, 从事工业过程故障检测、故障诊断算法的研究, E-mail: 1800103234@cjlu.edu.cn.

(责任编辑: 孙艺红)