

基于独立成分分析及其扩展模型的工业过程监测方法综述

孔祥玉^{1†}, 杨冶艳¹, 刘佑民², 罗家宇¹, 王晓兵¹

(1. 火箭军工程大学 导弹工程学院, 西安 710025; 2. 北京航天发射技术研究所, 北京 100072)

摘要: 独立成分分析 (independent component analysis, ICA) 是一种多变量统计分析方法, 常用于非高斯过程监测, 它能够有效利用信号的高阶统计信息 (三阶以上) 提取相互独立的独立成分, 在工业过程监测中得到了广泛的应用, 是当前国际过程监测领域的研究热点. 鉴于此, 介绍经典 ICA 模型、改进 ICA 模型及其在工业过程的过程监测技术. 首先, 对经典 ICA 模型进行介绍, 在此基础上对经典 ICA 模型进行分类并指出其优缺点; 其次, 针对经典 ICA 模型存在的缺陷, 从 ICA 自身存在的问题、噪声和离群值 3 方面梳理改进 ICA 模型的发展; 然后, 以工业过程为主要应用背景, 介绍 ICA 的过程监测技术如何从简单工业过程衍变至复杂工业过程, 以及面向工业过程运行数据的单一特性和混合特性, 综述 ICA 及其扩展模型在工业过程监测中的研究现状; 最后, 探讨该研究领域亟需解决的问题和未来的发展方向.

关键词: 独立成分分析; 工业过程; 过程监测; 单一特性; 混合特性

中图分类号: TP277

文献标志码: A

DOI: 10.13195/j.kzyjc.2020.1583

开放科学 (资源服务) 标识码 (OSID):



引用格式: 孔祥玉, 杨冶艳, 刘佑民, 等. 基于独立成分分析及其扩展模型的工业过程监测方法综述 [J]. 控制与决策, 2022, 37(4): 799-814.

Overview of industrial process monitoring methods based on independent component analysis and its extended model

KONG Xiang-yu^{1†}, YANG Zhi-yan¹, LIU You-min², LUO Jia-yu¹, WANG Xiao-bing¹

(1. School of Missile Engineering, Rocket Force University of Engineering, Xi'an 710025, China; 2. Beijing Institute of Space Launch Technology, Beijing 100072, China)

Abstract: The independent component analysis (ICA) is a multivariate statistical analysis method, which is often used for non-Gaussian process monitoring. It can effectively use the high-order statistical information (exceeding the third order) of the signal to extract independent components, which has been widely used in industrial process monitoring and is a research hotspot in the current international process monitoring field. As such, this paper introduces the classic ICA model, the improved ICA model and its process monitoring technology in industrial processes. Firstly, the classic ICA model is introduced, which is then classified and the advantages and disadvantages are pointed out. Secondly, in view of the shortcoming of the classic ICA model, the development of the improved ICA model is sorted out from three aspects, including ICA's own problems, noise and outliers. Then, the industrial process is applied as the main application background, and the ICA process monitoring technology is evolved from simple to complex industrial processes. Faced with the single and mixed characteristics of operating data in the industrial process, the current research status of the ICA and its extended models in industrial process monitoring are reviewed. Finally, the problems to be solved in this research field and the future development directions are discussed.

Keywords: independent component analysis; industrial process; process monitoring; single characteristic; mixed characteristics

0 引言

工业是第二产业的重要组成部分, 不仅影响着国民生活水平还体现了一个国家的综合实力. 随着生产技术和自动控制技术的不断发展, 为了保证工业

过程的安全稳定运行以及获取更高的经济效益, 现代工业过程在生产工艺、生产技术和生产流程等多方面都日趋自动化、复杂化^[1-2]. 采用合理可靠的过程监测技术, 保障工业过程等复杂系统的安全稳定运行

收稿日期: 2020-11-16; 录用日期: 2021-03-08.

基金项目: 国家自然科学基金项目 (61673387, 61833016); 陕西省自然科学基金项目 (2020JM-356).

责任编辑: 姜斌.

[†]通讯作者. E-mail: xiangyukong01@163.com.

逐渐成为国际过程监测领域的首要任务。

过程监测技术的目的是监测系统的运行状态,核心是故障检测技术,可以将其分为离线建模和在线监测两大步骤^[3]。过程监测技术因能实现对系统功能或设备运行状态的及时监测,成为实时监测系统以及过程安全控制系统的核心。过程监测流程如图1所示。

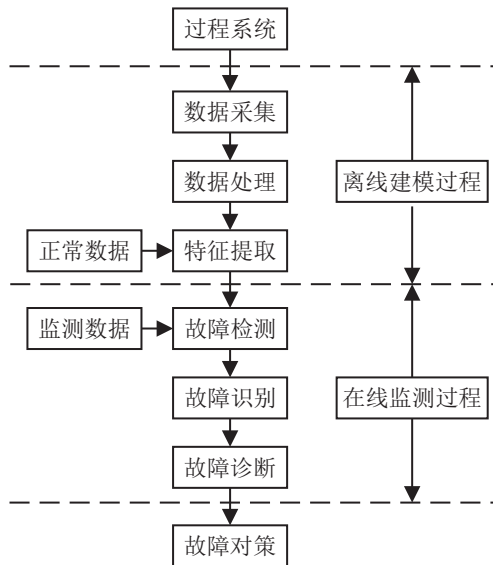


图1 过程监测流程

过程监测方法种类较多,其中基于解析模型的方法要求对过程的机理结构有深刻的认识,能够建立精

确的数学模型;基于知识的方法依赖于先验知识,不需要系统的数学模型;基于数据驱动的方法不需要系统的数学模型和先验知识,通过分析处理过程中的海量数据,挖掘数据内部包含的信息,以此获得工业过程的运行状态,实现过程监测。随着工业过程复杂度的日益增加和工业智能化水平的不断提升,先验知识和数学模型的获取越来越困难,采集、存储和处理海量过程数据成为可能。因此,基于数据驱动的过程监测方法已经逐渐成为热点问题^[4-5]。

多变量统计分析又称多元统计过程监测(multivariate statistical process monitoring, MSPM),它是基于数据驱动的过程监测方法中研究论文和应用案例数量最多的^[4]。主成分分析(principal component analysis, PCA)、偏最小二乘(partial least squares, PLS)、典型变量分析(canonical variable analysis, CVA)、独立成分分析(independent component analysis, ICA)^[6-9]、慢特征分析(slow feature analysis, SFA)^[10-12]和Fisher判别分析(fisher discriminant analysis, FDA)均是经典的基于数据驱动的MSPM方法^[13-15]。其中,PCA和PLS常在过程数据服从高斯分布的假设下进行过程监测,而实际的复杂工业过程由于动态扰动存在,很难满足高斯分布的大前提。因此,ICA作为PCA的延展方法得到进一步研究和发展。

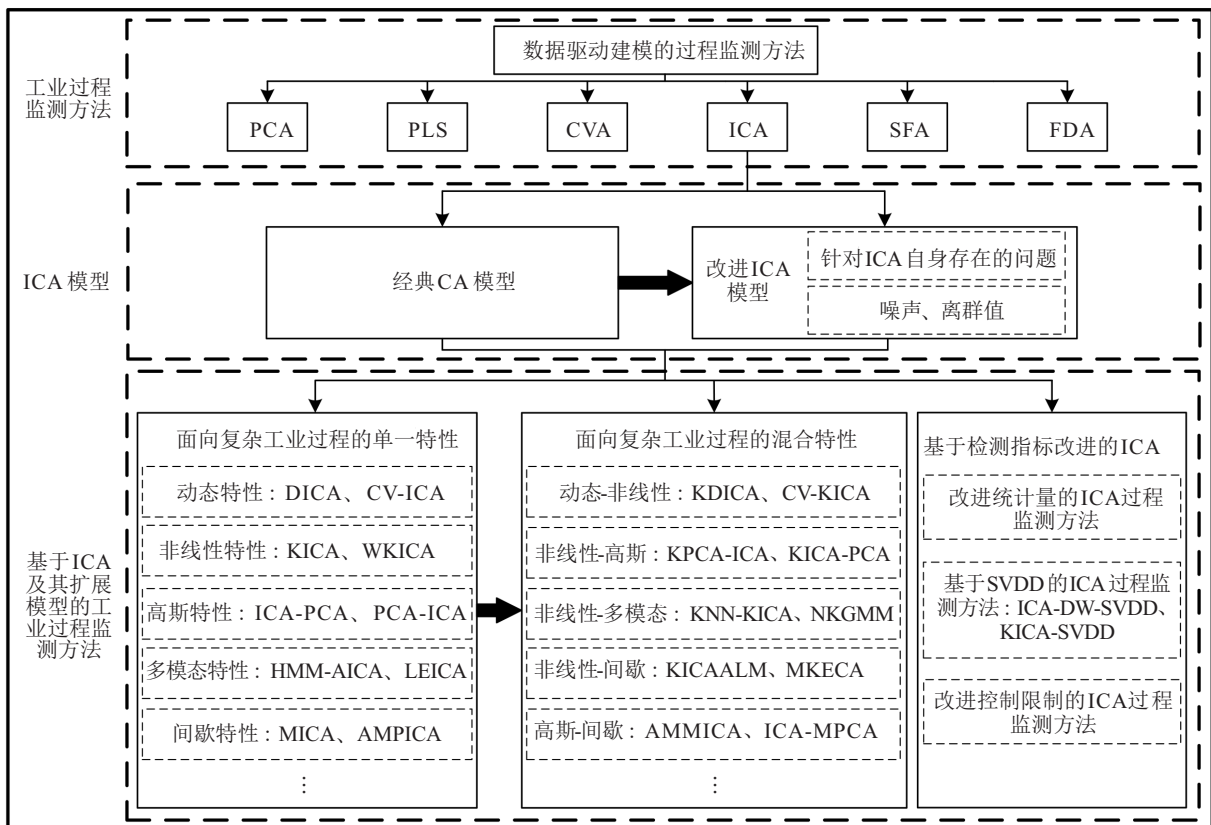


图2 过程监测下的ICA模型发展

从Lee等^[16]于2004年实现ICA在工业过程中的MSPM以后,人们提出了大量改进的ICA模型,其中包括:1)针对ICA自身存在的问题、噪声和离群值提出的改进ICA模型;2)考虑复杂系统单一特性、混合特性和基于检测指标改进的ICA模型.近20年,专家和学者在过程监测领域发表了大量综述性文献^[15,17-19],这些文献大部分涉及了ICA模型,但并未专门针对ICA及其扩展模型的工业过程监测方法进行综述.为此,本文给出如图2所示的过程监测下的ICA模型发展结构图.基于图2,将工业过程作为主要应用背景,以分类及改进方法为横轴,以ICA模型和基于ICA及其扩展模型的工业过程监测方法为纵轴对ICA模型进行综述.

1 经典ICA模型

人们为解决“鸡尾酒会”这类盲源分离(blind source separation, BBS)问题,提出能够利用信号高阶统计信息(三阶以上)的ICA模型^[20],自提出以来便引起了学术界和工程师的普遍关注,使其在如图3所示的信号处理、金融数据分析、故障检测及诊断、无线通信和图像处理等领域均有广泛的应用.

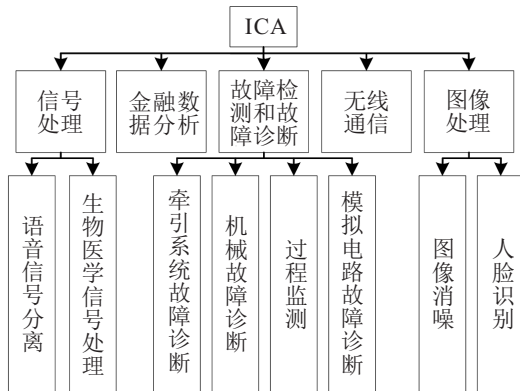


图3 ICA实际应用

ICA是近30年发展起来的,其原理如图4所示.ICA通过将观测到的数据矩阵分解成独立成分(independent components, ICs)的线性组合来寻求ICs, ICs代表统计独立并且它们是非高斯性的潜变量.ICA算法数学模型如下:

$$X = AS. \tag{1}$$

其中: $X \in \mathbf{R}^{m \times n}$ 为测量变量矩阵, $A \in \mathbf{R}^{m \times d}$ 为混合矩阵, $S \in \mathbf{R}^{d \times n}$ 为独立成分矩阵, d 为ICs数, m 为变量数, n 为样本数.




图4 ICA原理

在实际问题的求解中,除了测量变量矩阵 X ,剩余的独立成分矩阵 S 、混合矩阵 A 均是未知的.因此,需要将实际求解问题转化为根据测量矩阵 X 求解混矩阵 $W \in \mathbf{R}^{d \times m}$,最终得到输出 Y 的最优估计,即

$$\hat{S} = WX. \tag{2}$$

其中: $X \in \mathbf{R}^{m \times n}$ 为拥有 n 个样本的观测数据矩阵, $\hat{S} \in \mathbf{R}^{d \times n}$ 为重构的拥有 d 个ICs的独立成分矩阵.

ICA算法的实质是根据专家和学者提出的判别独立性最优的判据寻求解混矩阵 W ,从而使得重构矩阵 \hat{S} 中的 d 个ICs最大程度地相互独立^[8].1991年,Jutten等^[21]开始了BBS在国际上的研究;Comon^[6]阐述了ICA的基本概念并给出其严格的数学定义,使ICA成为盲信号分离的重要手段;1995年,Bell等^[22]不仅提出信息最大化准则,还运用ICA真正实现了BBS,加速了ICA的发展;Yang等^[23-24]提出了自然梯度搜索算法,不仅提升了梯度ICA的速度还使其成为ICA中广泛应用的搜索算法;1997年,Hyvärinen等^[25]提出了不同于文献[22-24]的定点迭代算法;1999年,Hyvärinen^[7]继续完善定点迭代算法,提出了固定点快速ICA(FastICA)算法;2002年,Li等^[26]利用ICA将高维的观测变量分解为几个ICs,降维后预测过程变量的变化趋势;同年,杨竹青等^[20]发表了国内第一篇ICA综述,较系统地阐述了经典ICA的原理和应用,其目的在于提高国内专家和学者对ICA理论及应用研究的兴趣.

将专家和学者于2003年以前提出的ICA划分为经典ICA,经典ICA又可以划分为基于随机梯度的自适应算法^[21,23,27]、最值化(最大化和最小化)相关准则函数^[6,22]和基于定点迭代的FastICA算法^[7-8]3种类型,其优缺点见表1.

表1 经典ICA方法的比较

	经典ICA	优点	缺点
最值化	基于随机梯度的自适应算法	保证收敛到一个相应的解	收敛速度慢且收敛性非常依靠学习速率参数的正确选择
	(最大化和最小化)相关准则函数	任何分布的ICs都适合	计算量大,计算效率低
	基于定点迭代的FastICA算法	任何类型的数据都适用,收敛速度快,计算效率高	在选择初始值的时候较敏感,可能导致算法不收敛

2 改进ICA模型

上述3种经典ICA模型各有优缺点,并且均采用理想数据构建模型.但在实际复杂系统中,过程数据可能会受噪声、离群值等影响.基于此,本节从ICA自身存在的问题、考虑噪声的ICA模型和去离群值的ICA模型3方面阐述改进ICA模型.

2.1 针对ICA自身存在的问题

2000年,Bingham等^[28]针对FastICA只对实值信号开发的缺陷,提出了复值源的第1个推广,并证明其能够保持实数源的立方全局收敛性^[29].2004年,Chevalier等^[30]通过比较研究证明了FastICA不能用于弱或高度相关空间的源,其收敛速度减慢,甚至在存在鞍点的情况下失败,特别是对于短块尺寸^[31].文献[32-35]针对文献[28]仅适用于二阶循环源的局限性,将算法的有效性扩展到非圆源,值得注意的是这些文献中的方法依赖于白化预处理,同时需要根据源分布选择函数以保证其稳定性.

以FastICA算法为代表的经典ICA模型存在如下缺陷:1)由于提取给定维数的全部ICs,计算量较大;2)无法按照代表特征或信号能量的方差确定ICs顺序和主导ICs个数;3)在白化空间中,正交矩阵的随机初始化致使经典ICA模型解不同.2006年,Lee等^[36]针对经典ICA模型的缺陷,提出了改进的ICA模型,该模型的基本思想是首先采用PCA提取主成分(principal components,PCs),然后在方差不变的前提下提取主导ICs.2009年,Huang等^[37]将分类回归树(classification and regression tree,CART)技术应用用于ICA,提出了ICA与CART相结合的过程扰动识别控制模型,最后引入常见的阶跃扰动和线性扰动进行实验,充分表明了该模型在提高扰动水平辨识精度方面的优势.2010年,Zhang等^[38]针对FastICA采用牛顿迭代法常常导致局部最小解的缺陷,提出了基于粒子群优化(particle swarm optimization,PSO)的改进ICA模型,该模型的基本思想是首先利用PSO-ICA从正常运行过程数据中提取主导ICs,然后根据原始信号恢复的作用确定ICs的阶数.同年,Zarzoso等^[39]提出基于峭度迭代最大化与代数最优步长对比的鲁棒独立成分分析(robust independent component analysis,RobustICA),该方法可以对实值信号和复值信号不加区分地分离,弥补了文献[34-37]需要白化预处理的不足以及具有强鲁棒性和高收敛性.2013年,Ge等^[40]提出性能驱动集成学习ICA(performance-driven ensemble learning ICA,PDELICA)模型,该模型不但采用集成

学习方法提高FastICA的稳定性而且结合参考异常数据集,采用性能驱动的方法实现了主导ICs的确定.2014年前后,集成学习方法在MSPM领域成为研究热点^[40-44],Tong等^[41]将集成学习方法与贝叶斯推理(Bayesian inference,BI)相结合,提出了基于集成学习和BI的改进ICA过程监测模型.Jiang等^[45]考虑到故障信息和ICs没有明确的映射关系,采用过程监测的特定标准排序ICs可能会丢失有用信息,为此提出加权ICA(weighted independent component analysis,WICA)模型.2017年,Tong等^[44]针对靠经验性选择ICA模型求解中的非二次函数问题,基于集成学习技术的优越性,综合采用不同非二次函数求解的改进ICA模型,提出了新的集成改进独立成分分析(ensemble modified independent component analysis,EMICA)模型.2018年,Li等^[46]也针对FastICA采用牛顿迭代法常常导致局部最小解的缺陷,提出基于生物地理学优化(biogeography-based optimization,BBO)的改进ICA模型BBO-ICA.特别指出:1)BBO-ICA模型可以获得理想的初始迭代点;2)Simon^[47]提出的BBO算法是一种新颖且有效的搜索极值或最值的优化方法,该算法相较PSO算法具有更强的搜索能力和搜索精度.

2.2 考虑噪声的ICA模型

文献[48-49]研究了噪声存在下ICA的最大似然估计.其中,Moulines等^[48]提出了一种EM算法估计噪声ICA模型;Hyvärinen^[49]利用极大似然估计方法研究含噪ICA问题,提出了基于联合似然最大化的高斯噪声ICA.在文献[48]中,噪声的协方差矩阵作为算法的一部分进行估计,EM算法的复杂度是ICs个数的指数函数.在文献[49]中,假设噪声的协方差矩阵已知,求解过程简单,计算要求低,但普适性较差.

1998年,Cichoki等^[50]通过扩展已有的自适应算法,减少了测量噪声对解混矩阵 W 的影响.此外,还提出了一种既可以减少输出信号噪声又可以估计未知混合矩阵 A 和BBS的递归动态神经网络.1999年,Hyvärinen^[51]提出了一种基于高斯矩的对比函数,该函数即使在存在噪声的情况下也没有渐近偏差且对异常值具有鲁棒性.2003年,Cao等^[52]提出了可靠ICA方法,该方法将抑制噪声影响的鲁棒预白化技术与参数化的 t 分布密度模型相结合.2005年,Hyvärinen^[53]提出结合三性质的统一模型,并用极大似然估计实现了ICA的梯度上升算法.2006年,Liu等^[54]提出了两种用于有噪声情况的方法,能够严格地将噪声的影响从成本函数中剔除.2008年,Yang

等^[55]在文献[53]的基础上,假设ICs为时间信号,提出了采用高斯矩处理噪声ICA模型的算法。当噪声协方差矩阵已知时,将高斯矩算法引入噪声统一模型的估计;当噪声协方差未知时,提出一种新的高斯矩算法。2012年,Zhang等^[56]将基于QR分解的递推最小二乘自适应滤波方法与FastICA相结合,克服了经典ICA模型未考虑附加噪声的缺点。2014年,Cai等^[57]明确考虑噪声ICA模型中的测量噪声,提出了不需知道噪声协方差矩阵的NoisyICAn算法,该算法可以更方便地应用于实际工业过程。

2.3 去离群值的ICA模型

数据集被极值或离群值污染是信号处理中不可避免的问题,但离群值在不同检测方法中有不同的定义,下面给出如图5所示的离群值检测方法分类图。对于离群值敏感的算法,如基于高阶统计量的算法,必须使其具有鲁棒性^[58]。一般情况下,如果离群值对估计值的影响是有界的,则该估计值称为B-鲁棒的。ICA估计值的建立是困难的,更不用说创建具有B-鲁棒性的ICA估计值。2004年,Gadhok等^[58]采用简单明了的K均值(K-means)聚类算法寻找数据中的离群值,增强非B-鲁棒性的FastICA估计。

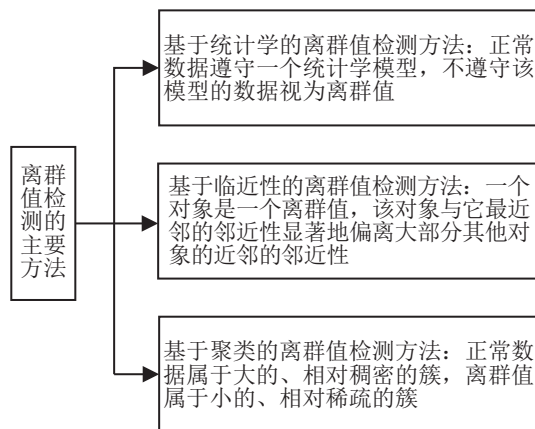


图5 离群值检测方法分类

2010年,Hsu等^[59]针对动态ICA(DICA)模型中的离线建模数据未考虑离群值的影响以及对离群值异常敏感的问题,提出一种剔除离群值的拒绝规则,提高了数据质量。2013年,Feng等^[60]考虑到经典ICA模型未考虑离群值的影响,以及最小二乘法、库克平方距离法、平方马氏距离法等传统的离群值研究方法不适合ICA的高维数据流,根据数据反映在影响函数上值的大小是否超过预设的阈值来检测离群值,提出了基于影响函数的离群值检测技术。

在离群值的不利影响下,FastICA算法可能无法可靠地提取非高斯特征^[61]。解决此类问题的常见方法是通过预处理过程数据去除离群值,然后

将FastICA算法应用于预处理过的数据^[59,62]。Wang等^[63]认为数据预处理可能破坏多元数据的相关结构或导致信息的丢失。2014年,Cai等^[64]提出了RobustICA算法,该算法有效地避免了通过数据预处理剔除离群值的弊端,但也存在离群值剔除过度或不足的问题。

3 基于ICA及其扩展模型的工业过程监测方法

2003年前后,ICA在工业过程故障检测及诊断方面的研究才逐步兴起,相关研究有文献[26,16,36,65-70]等。

在工业过程监测技术的发展中有各种各样的假设条件,例如经典ICA模型和改进ICA模型均在线性稳态非高斯特性等假设下进行过程监测。本文将过程数据满足线性稳态非高斯特性等假设的工业过程划分为简单工业过程,剩余的工业过程全部划分为复杂工业过程。在复杂工业过程中,系统通常具有动态特性且结构复杂,内部机理繁杂,过程数据在采集、传输过程中会被动态扰动、噪声、测量误差等影响。因此,采集到的过程数据常常具有混合特性。当前,MSPM技术下的ICA研究主要集中在处理具有混合特性的过程数据上。基于此,本节首先介绍基于ICA及其改进模型的简单工业过程监测方法,然后评述分析针对复杂工业过程单一特性和混合特性提出的故障检测及诊断方法,最后研究基于检测指标改进的ICA过程监测方法。

3.1 基于ICA及其改进模型的简单工业过程监测方法

2003年,Kano等^[65]将ICA引入简单流程工业的过程监测,第1次实现了基于ICA的单变量统计分析过程监测;同年, Lee等^[71]首次提出基于核密度估计(kernel density estimation, KDE)方法^[72]的ICA算法来监测数据非正态分布(非高斯)时的干扰,并将其运用于污水处理过程;同年,郭明等^[68]首次将ICA与支持向量机(support vector machines, SVM)相结合提出了基于ICA-SVM的故障诊断方法,该方法先采用ICA提取特征后结合SVM识别故障,相较工业过程中的人工神经网络故障诊断方法更易应用于当时的工业生产过程。2004年, Lee等^[16]将ICA用于故障检测及诊断,给出了较完整的过程监测策略。在文献[16]中,与PCA和PLS的故障检测指标 T^2 、平方预测误差(squared predicted error, SPE)相似,ICA采用3个指标 I^2 、 I_e^2 和SPE进行故障检测及诊断,但故障检测三指标的控制限均通过KDE方法获取。同年,Jiang等^[73]

采用ICA提取特征信息,结合FDA进行故障诊断。

2005年,何宁等^[70]在ICA的基础上提出字符串匹配故障诊断方法.该方法具有不需要训练数据和仅由过程数据驱动的优点,但其在分类彼此难以区分的故障时,故障诊断效果不好.2006年, Lee等^[36]针对文献[16]需提取所有的ICs、计算负荷高的缺点,提出了改进的ICA故障检测方法,该方法只需从高维多变量数据中提取主导ICs;同年,杨英华等^[74]运用ICA对水箱系统进行过程监测实验并取得了较好的监测效果。

2010年,Zhang等^[38]提出PSO-ICA方法并将其用于非高斯过程数据的故障检测;同年,Hsu等^[75]针对实际工业过程数据服从非高斯分布的情况,运用ICA提取隐藏信息,结合SVM进行故障检测,从而实现过程监测.2013年,Tian等^[76]为解决过程数据存在周期性扰动的问题,提出了AMRA-ICA过程监测方法,该方法引入平均多变量累积和消除数据中存在的周期性扰动,采用残差分析(residual analysis, RA)消除数据集中的干扰,然后运用ICA方法监测得到的正常残差.同年,Ge等^[40]提出结合集成学习方法和BI的ICA方法,解决了ICA中随机初始化导致的监测性能不稳定、ICs数量无法确定以及重要性无法判断的问题.该方法首先随机分组系统历史数据,构成不同的子数据集,然后建立子数据集ICA模型,最后集成子模型统计量以增强ICA提取系统特征的能力.实验结果表明,采用集成统计量进行故障诊断,提高了经典ICA的故障诊断性能。

2014年,Luo等^[77]提出了基于ICA的稀疏自动编码器过程监测方法,通过田纳西-伊斯曼(tennessee eastman, TE)过程验证了该方法检测故障的有效性,但效果差强人意;同年,严文武等^[78]提出了ICA与极限学习机(extreme learning machine, ELM)相结合的工业过程故障分类方法.2016年,Wang等^[79]为解决经典ICA模型未保留解混矩阵的全部特征信息而导致的信息缺失问题,提出利用混合信息的ICA模型MGB-ICA.2017年,Zhu等^[80]针对经典ICA缺乏对工业过程不确定性的概率描述问题,提出了一种新的用于非高斯过程监测的概率ICA(probabilistic independent component analysis, PICA)模型;同年,王普等^[81]提出了基于独立成分分析-最小二乘支持向量机(least square support vector machine, LSSVM)的冷水机组故障诊断方法.2018年,Kassouf等^[82]提出Random_ICA、KMO_ICA_Residuals和ICA_corr_y三种用于确定最佳ICs数量的方法,通过建立不同的指

标衡量不同数量的ICs对ICA模型性能的影响,从而寻找最佳数量ICs的提取方案,有效减少了ICA方法的计算复杂度.同年,Xie等^[83]提出了基于MM-ICA的故障检测和隔离方法,该方法先采用ICA提取ICs,后构造多个ICA模型定位故障。

3.2 面向复杂工业过程单一特性的ICA过程监测方法

3.2.1 动态ICA模型

由于波动、干扰和操作条件改变等因素的影响,实际的复杂工业过程通常是动态系统,从中采集的过程数据往往具有动态特性.当使用静态ICA模型进行过程监测时,难以有效地处理过程数据的动态特性.为此,人们提出了两种ICA动态扩展模型:1)数据矩阵扩充方法,即在输入中引入相关变量的历史数据,利用数据扩充方法将时间动态建模问题转化为空间静态建模问题,然后采用静态ICA模型建模;2)状态空间ICA(state-space independent component analysis, SSICA)模型,即利用监测动态过程的理想工具CVA处理动态特性,然后同样采用静态ICA模型建模。

2004年, Lee等^[16]采用数据矩阵扩充方法提出了DICA模型.2010年,Stefatos等^[84]提出了新的动态ICA过程监测方法和故障检测及诊断的创新机制.同年,Odiwei等^[85]发现,在提取ICs前ICA模型大多采用PCA降维及去相关,然而由于PCA的静态性质,这种模型不适用于监测动态过程.类似于动态PCA(dynamic principal component analysis, DPCA)的DICA能够处理动态特性,但效果并不理想,为此提出了SSICA动态扩展模型,该模型采用CVA降维并建立状态空间,然后从该状态空间分离出统计独立的ICs用于过程监测.2012年,Rashid等^[86]采用滑动窗口技术处理复杂工业过程的动态特性;同年,Yang等^[87]针对TE过程中难以检测的微小故障,如故障3,提出CVA与ICA相结合的CV-ICA方法,该方法结合两者的优点,首先利用CVA处理过程数据的动态特性,然后采用ICA计算ICs,实验结果验证了该方法的可行性和优越性.2015年,Huang等^[88]在DICA、DPCA和BI的基础上,提出一种新颖的过程监测方法DPCA-DICA-BI.该方法依然采用数据矩阵扩充方法处理过程的动态特性,通过Jarque-Bera检验测试将具有相同分布特性(高斯或非高斯)的过程变量置于一个块,然后用DPCA和DICA分别对高斯块数据和非高斯块数据进行处理,最后结合两个块的监测结果,使用BI做出综合决策.实验结果表明,在TE过程

的故障检测及诊断中,该方法具有更好的监测性能。

3.2.2 非线性ICA模型

在钢铁、化工和生物等复杂工业过程中,过程变量间存在明显的非线性,而线性ICA模型及动态ICA模型在实际的过程监测中往往难以得到满意的监测效果。为了有效地解决这类问题,专家和学者提出了大量非线性ICA模型。其中,基于核的方法因具有不涉及非线性优化、本质上只需要线性代数运算及建模前不必指定ICs个数等优点成为非线性过程监测中的主流方法。2005年, Yang等^[89]结合核PCA(kernel principal component analysis, KPCA)和ICA提出了核ICA(kernel independent component analysis, KICA)模型,使用非线性映射式“核技巧”将低维非线性过程数据映射到高维空间,然后采用线性方法降维并提取特征,最后成功地应用到人脸识别领域。在KICA的基础上,衍生出大量改进KICA故障检测及诊断模型。2007年, Zhang等^[90]在KICA的基础上提出了非线性过程监测新模型,真正实现了非线性ICA模型的过程监测。

Lee等^[91]在ICA的过程监测方面做了诸多努力,有力地推动了ICA在这一领域的应用与发展并取得了丰硕的成果,针对非正态分布过程变量之间存在的非线性关系,通过引入核函数,结合核中心化、核白化和改进的ICA模型,提出了KICA过程监测方法。同年,赵忠盖等^[92]进一步验证了KICA模型在非线性的过程监测的有效性。Zhang等^[93]通过引入相似性分析和均值聚类方法降低了KICA模型中的计算误差及计算复杂度。2009年, Zhang^[94]结合KPCA和KICA的优势,将KICA和KPCA都用于故障检测,然后采用SVM对故障进行分类。2012年,蔡连芳等^[95]针对KICA过程监测方法忽略数据投影前后局部近邻结构保持问题,结合KICA与局部保持投影(locality preserving projections, LPP)提出了改进的KICA故障检测方法。2014年, Zhao等^[96]针对KICA收敛速度较慢的问题,提出了基于峭度的鲁棒KICA故障检测方法。同年,赵小强等^[97]提出了KPCA与KICA相结合的双核方法。Zhang等^[98]在KICA进行故障检测的基础上,采用LSSVM进行故障诊断,建立了复杂工业过程的过程监测模型。2016年, Xiao等^[99]采用ICA从KPCA的变换空间中提取特征,然后使用多个二分类SVM实现对非线性过程的故障诊断。同年,韩敏等^[100]考虑到ICs对系统故障贡献程度的不同,提出了加权KICA(weighted kernel independent component analysis, WKICA)故障检测模型。

2017年, Du等^[101]提出故障相关的KICA (fault-related kernel independent component analysis, FKICA)过程监测方法,该方法将过程数据的数据空间分解为4个子空间,有利于充分利用历史故障数据。同年, Cai等^[102]提出了新的基于高斯混合模型(Gaussian mixture model, GMM)的WKICA过程监测方法,该方法首先采用GMM估计KICA提取的ICs的概率(重要性),然后基于估计的概率区分体现主要过程变化的主导ICs并为其分配较大的权重,最后进行在线故障检测及诊断。此外,他根据敏感性分析的思想开发了非线性贡献图方法,当检测到故障后识别故障变量。2018年,为解决KICA求解ICs时对非二次函数和初始点要求较高、精度不理想的问题, Feng等^[103]提出了基于Hibert-Schmidt独立性准则的KICA故障检测方法,该方法利用直接二项式展开定理得到控制极限,不仅降低了计算复杂度和实现难度,而且提高了控制精度。2019年, Wang等^[104]提出了监督KICA(supervised kernel independent component analysis, SKICA)故障检测方法,该方法在ICA中引入线性判别分析,不仅能够有效提取非线性特征,而且扩大了不同类别样本间的距离,有利于识别及分类等任务。同年, Zhang等^[105]为提高复杂工业过程中故障检测的准确性、减少计算时间,提出了结合特征向量选择(feature vector selection, FVS)的KICA故障检测方法,该方法通过采用高斯径向基核函数和多项式核函数的联合核函数提高KICA模型的学习及泛化能力,采用FVS算法降低计算复杂度。Liu等^[106]提出了基于混沌粒子群优化(chaotic particle swarm optimization, CPSO)的改进KICA故障检测模型CPSO-KICA,该模型解决了KICA模型中核参数的选取具有偶然性的问题。

3.2.3 高斯ICA模型

PCA和PLS在过程数据服从高斯分布的假设下进行过程监测,ICA在运行数据绝对不服从正态分布的假设下进行故障检测及诊断。在实际的工业过程中,过程变量复杂且高斯特性和非高斯特性混合,任何单一的MSPM技术都不足以提取隐藏信息。基于此,人们提出了许多用于故障检测及诊断的高斯ICA模型。根据目前的研究成果,高斯ICA模型主要分为以下两类:ICA-PCA模型和PCA-ICA模型。

2004年, Kano等^[107]提出了ICA与PCA相结合的组合统计过程控制方法。2007年, Ge等^[108]考虑到工业过程等复杂系统的过程数据可能同时具有非高斯特性和高斯特性,提出了ICA-PCA两步

信息提取的过程监测模型. 2008年, Liu等^[109]先用PCA提取特征, 后采用ICA从PCA的PCs中提取非高斯特征. 2009年, Ge等^[110]提出了ICA与因子分析(factor analysis, FA)相结合的过程监测方法ICA-FA, 该方法首先采用ICA提取非高斯特征, 然后采用概率方法将剩余的高斯部分分解为潜在的影响因素和未建模的不确定性. 2016年, Jiang等^[111]提出了结合贝叶斯的PCA-ICA故障诊断方法. 2019年, Zhang等^[112]提出了混合ICA(hybrid independent component analysis, H-ICA)过程监测方法, 该方法通过分析二阶非零延迟协方差矩阵捕获时间结构信息, 通过分析统计量(二阶和高阶)全面调查及分析过程信息. 同年, Xu等^[113]将ICA-PCA与相关向量机(relevant vector machine, RVM)集成, 提出了用于提取高斯和非高斯信息的ICA-PCA-RVM多变量过程监测新方法, 该方法使用RVM分类器自动计算控制限, 既减少了操作人员的精力又提升了故障检测的精度.

3.2.4 多模态ICA模型

在复杂工业过程中, 外界环境、产品类型、方案、组分和原料等改变皆会致使工业过程具有不同潜在过程特性的多种模态, 因此, 多模态工业过程的过程监测研究面临挑战. 为了有效解决多模态工业过程的过程监测难题, 人们提出了两种ICA多模态扩展方法: 1) 为了解决不同区域局部空间的内在联系, 可以采用按照子功能时段或区域划分的方法; 2) 针对部分工业过程受空间等因素制约、具有多时段特性的情况, 可采用外部分析法或按照不同子时段分别建立监测模型.

1997年, Gallagher等^[114]指出大多数工业过程都是时变的, 因此监测这类过程需要不断地更新监测模型以适应这种动态性变化. 2004年, Kano等^[115]提出了基于外部分析的多模态故障检测及诊断方法. 2012年, Rashid等^[116]指出对于具有多个操作条件和固有系统不确定性的复杂化工过程, 常规MSPM技术不适用, 因为它们无法表征转换模式和过程的不确定性, 为此提出了基于隐式马尔科夫模型(hidden Markov model, HMM)的自适应ICA方法HMM-AICA. 2013年, Zhang等^[117]将非高斯数据的原始空间划分成公共和特定两部分, 基于改进的KICA获得全局的多模态基向量和子基向量, 然后分别分析各模式下的公共及特定部分, 实现对各种模态进行分析的目的. 2014年, Jiang等^[118]提出了联合概率密度和双重加权独立成分分析(double-weighted independent component analysis, DWICA)的多模态

非高斯过程监测方案, 旨在将DWICA扩展到多模态版本. 2017年, Zhong等^[119]提出了局部熵ICA(local entropy independent component analysis, LEICA)过程监测方法, 该方法通过局部概率密度估计消除多模态特征的影响.

3.2.5 间歇ICA模型

现代复杂工业过程主要划分为连续、离散和间歇3大类, 其中间歇工业过程具有更加复杂的运行机理^[4, 120-121]. 此外, 间歇工业过程成批次生产采集到的三维过程数据不同于连续工业过程的二维数据, 难以直接建立模型. 基于此, 间歇工业过程的过程监测问题更为复杂, 为此, 专家和学者提出了多种用于故障检测及诊断的间歇ICA模型.

间歇工业过程的过程数据可以表示为 $X(I \times J \times K)$. 其中: I 为生产批次个数, J 为测量变量, K 为时间序列. 可以通过3种方式将三维矩阵 $X(I \times J \times K)$ 展开, 然后运用ICA进行故障检测及诊断, 但只有两种展开方式是合理的: 1) 按照批次展开, 构建一个维度为 $I \times JK$ 的矩阵; 2) 按照测量变量展开, 构建一个维度为 $IK \times J$ 的矩阵.

2004年, Yoo等^[122-123]仿照多向PCA(multiway principal component analysis, MPCA)的建模思路提出了多向ICA(multiway independent component analysis, MICA)模型, 该模型首先将三维过程数据 $X(I \times J \times K)$ 展开成二维数据, 然后采用ICA进行过程监测. 2008年, Zhao等^[124]在MICA的基础上提出了基于MICA的自适应过程监测模型AMPICA, 该模型适用于长时间批处理. 2013年, Yu等^[125]提出了新颖的MICA混合模型及基于互信息的故障检测与诊断方法, 该方法不仅能够检测出不同阶段的异常事件, 还能以较高的准确度诊断故障变量; 同年, Guo等^[126]提出了改进的MICA在线批处理过程监测方法, 该方法为了优化主导ICs的数量, 引入可以评估具有不同ICs的重构观测值的系统偏差新概念, 为了轻松地确定控制范围, 利用Box-Cox转换将监测的统计数据转换为高斯分布数据.

3.3 面向复杂工业过程混合特性的ICA过程监测方法

随着工业过程的不断复杂化, 实际的工业过程往往是多种特性混合的复杂系统. 为得到较满意的过程监测效果, 专家和学者已取得了如下进展:

1) 对于动态特性和非线性特性混合的复杂工业过程, Fan等^[127]提出了核动态ICA(kernel dynamic independent component analysis, KDICA)过程监测方

法. Sun等^[128]结合CVA和KICA,提出了CV-KICA故障检测方法.

2) 对于动态特性和高斯特性混合的复杂工业过程, Tian等^[129]结合PCA、CVA和ICA这3种MSPM技术,提出了故障诊断的多层贡献传播分析.

3) 对于动态特性和多模态特性混合的复杂工业过程, Xu等^[130]提出了动态贝叶斯ICA(dynamic Bayesian independent component analysis, DBICA)故障检测方法,该方法首先采用数据矩阵扩充方法处理过程数据的动态特性,然后将BI与ICA相结合建立概率混合模型.

4) 对于非线性特性和高斯特性混合的复杂工业过程, Peng等^[131]直接利用ICA处理动态PLS中动态分量的非高斯特性,提出了采用多阶段动态非高斯模型的批量过程质量监测方案.

5) 对于非线性特性和高斯特性混合的复杂工业过程, Xiao等先提出KPCA-ICA故障检测方法^[132],后将KPCA-ICA故障检测方法和多个SVM结合进行故障诊断^[99]. 2014年, Fan等^[133]提出了滤波KICA-PCA(filtering kernel independent component analysis-principal component analysis, FKICA-PCA)过程监测方法,该方法最大的创新点是计算了ICs的方差,可以比较高斯和非高斯特征.

6) 对于非线性特性和多模态特性混合的复杂工业过程, Yu^[134]提出了非线性核高斯混合模型(nonlinear kernel Gaussian mixture model, NKGMM)的推理监测方法. Na等^[135]提出了KNN-KICA故障检测新方法.

7) 对于非线性特性和间歇特性混合的复杂工业过程, 王丽等^[136]提出了基于KICA的局部建模(kernel independent component analysis and local modeling, KICAALM)监测方法,该方法既不需要估计未来测量值,又解决了KICA不能直接处理间歇过程高维历史建模数据的难题. 常鹏等^[137]提出了基于MKECA的故障检测及诊断新方法,该方法解决了KPCA白化后的过程数据忽略数据簇结构信息的问题.

8) 对于高斯特性和间歇特性混合的复杂工业过程, 王培良等^[138]提出了基于迭代多模型ICA(adaptive multi-model independent component analysis, AMMICA)的故障在线监测方法. 肖应旺等^[139]提出了ICA-MPCA过程监测方法.

9) 对于非线性特性、高斯特性和间歇特性混合的复杂工业过程, Zhao等^[140]提出了改进的非线性间

歇监测方法,该方法通过捕获潜在非线性特性的变化,将整个批处理持续时间分为不同的阶段,然后针对各个子阶段采用KICA-PCA的两步建模策略探索非线性和高斯等特征.

3.4 基于检测指标改进的ICA过程监测方法

ICA是一种常用的非高斯过程监测方法,ICA及其扩展模型的故障检测指标通常采用KDE方法获取静态控制限,KDE方法为基于ICA及其扩展模型的过程监测方法求取控制限提供了可能,但当数据分布不均匀(过于分散或集中)时,该方法获取的监测阈值可能不合理,导致过程监测效果不稳定. 由于ICA的故障检测指标影响过程监测效果,专家和学者提出了不少基于检测指标改进的ICA过程监测方法,主要将其分为3类: 1) 改进统计量的ICA过程监测方法; 2) 基于支持向量数据描述(support vector data description, SVDD)的ICA过程监测方法; 3) 改进控制限的ICA过程监测方法.

2010年, Hsu等^[59]考虑到提取的ICs通常呈偏态分布,采用椭圆型监测统计量 I^2 、 I_c^2 和SPE可能无法恰当地捕捉ICs的特征,采用调整后的外向度这种矩形监测统计量来监测非高斯过程. 2011年, Lee等^[62]提出了局部离群因子(local outlier factor, LOF)与ICA相结合的过程监测方法,该方法摆脱了椭圆及矩形监测统计量的使用局限性,不考虑数据的实际分布情况,直接计算监测统计量. 2013年, 樊继聪等^[141]直接加权经典ICA的过程监测三指标(I^2 、 I_c^2 和SPE),提出了两种联合的ICA故障检测指标. 2015年, Cai等^[102]提出了基于GMM-WKICA的过程监测方法,该方法使用GMM向不同的ICs赋予不同的权重并采用基于权重的监测统计量.

2016年, Chen等^[142]针对ICA在故障检测中不能识别影响故障诊断能力的重要组成部分问题,提出了将ICA、杜宾沃森(Durbin watson, DW)与SVDD相结合的故障检测方法ICA-DW-SVDD. 2017年, 杨泽宇等^[143]提出了KICA-SVDD的故障检测方法,该方法采用KICA提取数据特征,采用SVDD检测故障.

2018年, 王培良等^[144]提出了基于HMM的自适应检测限设计方法,该方法将时间相关数据块的特征信息变化作为故障检测的依据,运用时间窗方法确定ICs. 首先采用ICs组成的监测矩阵训练HMM模型,然后采用HMM模型对监测矩阵进行相关性评估并设计评估值的自适应因子和检测控制限,最后进行在线故障检测.

4 研究展望

本文以工业过程监测技术为主要应用背景,专门对ICA及其扩展模型进行了较为全面的综述.虽然专家和学者针对工业过程监测问题提出了大量的故障检测及诊断模型,但仍不完善,还需要进一步研究和讨论:

1) 过程监测建模数据可靠性的问题. 基于数据驱动的过程监测方法只依赖于过程数据,过程数据的可靠性决定了ICA及其扩展模型的可靠性. 因此,在多变量耦合、多扰动、大滞后等情况下,有必要对过程监测建模数据存在噪声、离群值和缺失值等问题进行深入研究.

2) 数据驱动的分布式过程监测研究. 复杂工业过程由成百上千个控制回路构成,信息、能量及物料之间的传递和反馈控制使得设备自身或外部扰动等导致的故障可能会引起链式反应,滋生更多、更大的故障. 因此,彼此独立的过程监测系统已经不能满足实际的故障检测及诊断需求,分布式过程监测方法是未来复杂工业过程故障检测及诊断的可行研究方向.

3) 基于融合的过程监测方法. 基于数据驱动的MSPM技术在工业过程等复杂系统的过程监测中具有很强的通用性,但过程知识和内部机理的缺失可能会导致过程监测信息的不准确. 在当前条件下,增强与专家的交互作用或建立融入经验知识(过程知识和内部机理)的运行数据建模方法,以提高过程监测性能和产品质量,保证生命和财产的安全.

4) 故障预测的研究. 基于数据驱动的复杂工业过程故障检测及诊断方面的研究已取得不少的进展,相比之下,复杂工业过程故障预测方面的研究较少,深度学习的出现为其发展提供了可能. 在生物、化工等复杂工业过程中,毒性物质、微生物和氨氮等物质的浓度难以使用传统传感器直接测量,需使用软测量技术. 因此,在数据驱动的复杂工业过程监测方法基础上,结合软测量技术和深度学习进行故障预测是值得期待的研究方向.

5 结论

近20年来,ICA已由经典ICA模型发展到改进ICA模型,是MSPM的重要方法之一. 通过将ICA及其扩展模型应用在工业过程,解决了非高斯工业过程的过程监测问题. 随着工业过程复杂性的日益增加,ICA过程监测方法也随之从工业过程的动态、非线性、高斯、多模态、间歇等单一特性发展到多特性混合的复杂工业过程. ICA及其扩展模型不局限于工业过程的故障检测及诊断,在信号处理、金融数据分

析、机械故障检测及诊断、无线通信和图像处理等领域都有广泛的应用. 因此,ICA及其扩展模型具有巨大的研究价值.

参考文献(References)

- [1] 周东华, 魏慕恒, 司小胜. 工业过程异常检测、寿命预测与维修决策的研究进展[J]. 自动化学报, 2013, 39(6): 711-722.
(Zhou D H, Wei M H, Si X S. A survey on anomaly detection, life prediction and maintenance decision for industrial processes[J]. Acta Automatica Sinica, 2013, 39(6): 711-722.)
- [2] 赵春晖, 王福利. 工业过程运行状态智能监控: 数据驱动方法[M]. 北京: 化学工业出版社, 2019: 1-35.
(Zhao C H, Wang F L. Intelligent monitoring of industrial process operating status: Data-driven method[M]. Beijing: Chemical Industry Press, 2019: 1-35.)
- [3] 姚志湘. 过程系统状态空间统计模型和化工过程监测[D]. 广州: 华南理工大学, 2003.
(Yao Z X. Statistics modeling of the state space and monitoring of chemical process systems[D]. Guangzhou: South China University of Technology, 2003.)
- [4] 彭开香, 马亮, 张凯. 复杂工业过程质量相关的故障检测与诊断技术综述[J]. 自动化学报, 2017, 43(3): 349-365.
(Peng K X, Ma L, Zhang K. Review of quality-related fault detection and diagnosis techniques for complex industrial processes[J]. Acta Automatica Sinica, 2017, 43(3): 349-365.)
- [5] 孔祥玉, 曹泽豪, 安秋生, 等. 偏最小二乘线性模型及其非线性动态扩展模型综述[J]. 控制与决策, 2018, 33(9): 1537-1548.
(Kong X Y, Cao Z H, An Q S, et al. Review of partial least squares linear models and their nonlinear dynamic expansion models[J]. Control and Decision, 2018, 33(9): 1537-1548.)
- [6] Comon P. Independent component analysis, a new concept[J]. Signal Processing, 1994, 36(3): 287-314.
- [7] Hyvärinen A. Fast and robust fixed-point algorithms for independent component analysis[J]. IEEE Transactions on Neural Networks, 1999, 10(3): 626-634.
- [8] Hyvärinen A, Oja E. Independent component analysis: Algorithms and applications[J]. Neural Networks, 2000, 13(4/5): 411-430.
- [9] 常鹏, 乔俊飞, 张祥宇, 等. 基于四阶累积分析的工业大肠杆菌制备过程故障诊断[J]. 控制理论与应用, 2020, 37(3): 667-675.
(Chang P, Qiao J F, Zhang X Y, et al. Fourth order cumulant analysis based fault diagnosis of the preparation process of industrial escherichia coli[J]. Control Theory and Applications, 2020, 37(3): 667-675.)
- [10] Shang C, Yang F, Gao X Q, et al. Concurrent monitoring

- of operating condition deviations and process dynamics anomalies with slow feature analysis[J]. *AIChE Journal*, 2015, 61(11): 3666-3682.
- [11] Qin Y, Zhao C H. Comprehensive process decomposition for closed-loop process monitoring with quality-relevant slow feature analysis[J]. *Journal of Process Control*, 2019, 77: 141-154.
- [12] Zhang H Y, Tian X M, Deng X G, et al. Batch process fault detection and identification based on discriminant global preserving kernel slow feature analysis[J]. *ISA Transactions*, 2018, 79: 108-126.
- [13] 黄克, 赵炯, 周奇才, 等. 基于多变量统计过程监控的盾构机故障诊断[J]. *中国工程机械学报*, 2012, 10(2): 222-227.
(Huang K, Zhao J, Zhou Q C, et al. Fault diagnosis on shield machines based on multivariable statistical process monitoring[J]. *Chinese Journal of Construction Machinery*, 2012, 10(2): 222-227.)
- [14] 周东华, 李钢, 李元. 数据驱动的工业过程故障诊断技术: 基于主元分析与偏最小二乘的方法[M]. 北京: 科学出版社, 2011: 1-20.
(Zhou D H, Li G, Li Y. Data-driven industrial process fault diagnosis technology: A method based on principal component analysis and partial least squares[M]. Beijing: Science Press, 2011: 1-20.)
- [15] 纪洪泉, 何潇, 周东华. 基于多元统计分析的故障检测方法[J]. *上海交通大学学报*, 2015, 49(6): 842-848.
(Ji H Q, He X, Zhou D H. Fault detection techniques based on multivariate statistical analysis[J]. *Journal of Shanghai JiaoTong University*, 2015, 49(6): 842-848.)
- [16] Lee J M, Yoo C, Lee I B. Statistical monitoring of dynamic processes based on dynamic independent component analysis[J]. *Chemical Engineering Science*, 2004, 59(14): 2995-3006.
- [17] 刘强, 柴天佑, 秦泗钊, 等. 基于数据和知识的工业过程监视及故障诊断综述[J]. *控制与决策*, 2010, 25(6): 801-807.
(Liu Q, Chai T Y, Qin S J, et al. Progress of data-driven and knowledge-driven process monitoring and fault diagnosis for industry process[J]. *Control and Decision*, 2010, 25(6): 801-807.)
- [18] Dai X W, Gao Z W. From model, signal to knowledge: A data-driven perspective of fault detection and diagnosis[J]. *IEEE Transactions on Industrial Informatics*, 2013, 9(4): 2226-2238.
- [19] Gao Z W, Cecati C, Ding S X. A survey of fault diagnosis and fault-tolerant techniques — Part I: Fault diagnosis with model-based and signal-based approaches[J]. *IEEE Transactions on Industrial Electronics*, 2015, 62(6): 3757-3767.
- [20] 杨竹青, 李勇, 胡德文. 独立成分分析方法综述[J]. *自动化学报*, 2002, 28(5): 762-772.
(Yang Z Q, Li Y, Hu D W. Independent component analysis: A survey[J]. *Journal of Automatics*, 2002, 28(5): 762-772.)
- [21] Jutten C, Herault J. Blind separation of sources, Part 1: An adaptive algorithm based on neuromimetic architecture[J]. *Signal Processing*, 1991, 24(1): 1-10.
- [22] Bell A J, Sejnowski T J. An information-maximization approach to blind separation and blind deconvolution[J]. *Neural Computation*, 1995, 7(6): 1129-1159.
- [23] Yang H H, Amari S T. Adaptive online learning algorithms for blind separation: Maximum entropy and minimum mutual information[J]. *Neural Computation*, 1997, 9(7): 1457-1482.
- [24] Yang H H, Amari S I, Cichocki A. Information-theoretic approach to blind separation of sources in non-linear mixture[J]. *Signal Processing*, 1998, 64(3): 291-300.
- [25] Hyvärinen A, Oja E. A fast fixed-point algorithm for independent component analysis[J]. *Neural Computation*, 1997, 9(7): 1483-1492.
- [26] Li R F, Wang X Z. Dimension reduction of process dynamic trends using independent component analysis[J]. *Computers & Chemical Engineering*, 2002, 26(3): 467-473.
- [27] Friedman J H. Exploratory projection pursuit[J]. *Journal of the American Statistical Association*, 1987, 82(397): 249-266.
- [28] Bingham E, Hyvärinen A. A fast fixed-point algorithm for independent component analysis of complex valued signals[J]. *International Journal of Neural Systems*, 2000, 10(1): 1-8.
- [29] Ristaniemi T, Joutsensalo J. Advanced ICA-based receivers for block fading DS-CDMA channels[J]. *Signal Processing*, 2002, 82(3): 417-431.
- [30] Chevalier P, Albera L, Comon P, et al. Comparative performance analysis of eight blind source separation methods on radiocommunications signals[C]. 2004 IEEE International Joint Conference on Neural Networks. Budapest: IEEE, 2004: 273-278.
- [31] Tichavsky P, Koldovsky Z, Oja E. Performance analysis of the FastICA algorithm and crame/spl acute/r-rao bounds for linear independent component analysis[J]. *IEEE Transactions on Signal Processing*, 2006, 54(4): 1189-1203.
- [32] Douglas S C. Fixed-point algorithms for the blind separation of arbitrary complex-valued non-Gaussian signal mixtures[J]. *EURASIP Journal on Advances in Signal Processing*, 2007, 2007(1): 1-15.
- [33] Novey M, Adali T. On extending the complex FastICA algorithm to noncircular sources[J]. *IEEE Transactions on Signal Processing*, 2008, 56(5): 2148-2154.
- [34] Novey M, Adali T. Complex ICA by negentropy maximization[J]. *IEEE Transactions on Neural Networks*,

- 2008, 19(4): 596-609.
- [35] Li H L, Adali T. A class of complex ICA algorithms based on the kurtosis cost function[J]. *IEEE Transactions on Neural Networks*, 2008, 19(3): 408-420.
- [36] Lee J M, Qin S J, Lee I B. Fault detection and diagnosis based on modified independent component analysis[J]. *AIChE Journal*, 2006, 52(10): 3501-3514.
- [37] Huang S P, Chiu C C. Process monitoring with ICA-based signal extraction technique and CART approach[J]. *Quality and Reliability Engineering International*, 2009, 25(5): 631-643.
- [38] Zhang Y W, Zhang Y. Fault detection of non-Gaussian processes based on modified independent component analysis[J]. *Chemical Engineering Science*, 2010, 65(16): 4630-4639.
- [39] Zarzoso V, Comon P. Robust independent component analysis by iterative maximization of the kurtosis contrast with algebraic optimal step size[J]. *IEEE Transactions on Neural Networks*, 2010, 21(2): 248-261.
- [40] Ge Z Q, Song Z H. Performance-driven ensemble learning ICA model for improved non-Gaussian process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2013, 123: 1-8.
- [41] Tong C D, Palazoglu A, Yan X F. Improved ICA for process monitoring based on ensemble learning and Bayesian inference[J]. *Chemometrics and Intelligent Laboratory Systems*, 2014, 135: 141-149.
- [42] Li N, Yang Y P. Ensemble kernel principal component analysis for improved nonlinear process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2015, 54(1): 318-329.
- [43] Jiang Q C, Wang B, Yan X F. Multiblock independent component analysis integrated with Hellinger distance and Bayesian inference for non-Gaussian plant-wide process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2015, 54(9): 2497-2508.
- [44] Tong C D, Lan T, Shi X H. Ensemble modified independent component analysis for enhanced non-Gaussian process monitoring[J]. *Control Engineering Practice*, 2017(58): 34-41.
- [45] Jiang Q C, Yan X F. Non-Gaussian chemical process monitoring with adaptively weighted independent component analysis and its applications[J]. *Journal of Process Control*, 2013, 23(9): 1320-1331.
- [46] Li X S, Wei D, Lei C, et al. Statistical process monitoring with biogeography-based optimization independent component analysis[J]. *Mathematical Problems in Engineering*, 2018, 2018: 1-14.
- [47] Simon D. Biogeography-based optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2008, 12(6): 702-713.
- [48] Moulines E, Cardoso J F, Gassiat E. Maximum likelihood for blind separation and deconvolution of noisy signals using mixture models[C]. *IEEE International Conference on Acoustics, Speech, and Signal Processing*. Munich: IEEE, 1997: 3617-3620.
- [49] Hyvärinen A. Independent component analysis in the presence of Gaussian noise by maximizing joint likelihood[J]. *Neurocomputing*, 1998, 22(1/2/3): 49-67.
- [50] Cichocki A, Douglas S C, Amari S. Robust techniques for independent component analysis (ICA) with noisy data[J]. *Neurocomputing*, 1998, 22(1/2/3): 113-129.
- [51] Hyvärinen A. Gaussian moments for noisy independent component analysis[J]. *IEEE Signal Processing Letters*, 1999, 6(6): 145-147.
- [52] Cao J T, Murata N, Amari S, et al. A robust approach to independent component analysis of signals with high-level noise measurements[J]. *IEEE Transactions on Neural Networks*, 2003, 14(3): 631-645.
- [53] Hyvärinen A. A unifying model for blind separation of independent sources[J]. *Signal Processing*, 2005, 85(7): 1419-1427.
- [54] Liu W, Mandic D P, Cichocki A. Blind second-order source extraction of instantaneous noisy mixtures[J]. *IEEE Transactions on Circuits and Systems II: Express Briefs*, 2006, 53(9): 931-935.
- [55] Yang Y M, Guo C H. Gaussian moments for noisy unifying model[J]. *Neurocomputing*, 2008, 71(16/17/18): 3656-3659.
- [56] Zhang M L, Wang S Z, Jia X Y. RLS adaptive noise cancellation via QR decomposition for noisy ICA[J]. *Advanced Materials Research*, 2011(403-408): 1291-1296.
- [57] Cai L F, Tian X M, Chen S. A process monitoring method based on noisy independent component analysis[J]. *Neurocomputing*, 2014(127): 231-246.
- [58] Gadhok N, Kinsner W. A study of outliers for robust independent component analysis[C]. *Canadian Conference on Electrical and Computer Engineering*. Niagara Falls: IEEE, 2004: 1421-1425.
- [59] Hsu C C, Chen M C, Chen L S. A novel process monitoring approach with dynamic independent component analysis[J]. *Control Engineering Practice*, 2010, 18(3): 242-253.
- [60] Feng P X, Li L P, Zhang H B, et al. Outliers detection in ICA[C]. *2013 International Conference on Communications, Circuits and Systems (ICCCAS)*. Chengdu: IEEE, 2013: 328-330.
- [61] Ollila E. The deflation-based FastICA estimator: Statistical analysis revisited[J]. *IEEE Transactions on Signal Processing*, 2010, 58(3): 1527-1541.
- [62] Lee J, Kang B, Kang S H. Integrating independent component analysis and local outlier factor for plant-wide process monitoring[J]. *Journal of Process Control*, 2011,

- 21(7): 1011-1021.
- [63] Wang D, Romagnoli J A. Robust multi-scale principal components analysis with applications to process monitoring[J]. *Journal of Process Control*, 2005, 15(8): 869-882.
- [64] Cai L F, Tian X M. A new fault detection method for non-Gaussian process based on robust independent component analysis[J]. *Process Safety and Environmental Protection*, 2014, 92(6): 645-658.
- [65] Kano M, Tanaka S, Hasebe S, et al. Monitoring independent components for fault detection[J]. *AIChE Journal*, 2003, 49(4): 969-976.
- [66] 陈国金, 梁军, 钱积新. 独立元分析方法(ICA)及其在化工过程监控和故障诊断中的应用[J]. *化工学报*, 2003, 54(10): 1474-1477.
(Chen G J, Liang J, Qian J X. Independent component analysis and its application to chemical process monitoring and fault diagnosis[J]. *CIESC Journal*, 2003, 54(10): 1474-1477.)
- [67] 陈国金, 梁军, 刘育明, 等. 基于多元统计投影方法的过程监控技术研究[J]. *浙江大学学报: 工学版*, 2004, 38(12): 28-32.
(Chen G J, Liang J, Liu Y M, et al. Process monitoring based on multivariate statistical projection analysis[J]. *Journal of Zhejiang University: Engineering Science Edition*, 2004, 38(12): 28-32.)
- [68] 郭明, 谢磊, 何宁, 等. 一种基于ICA-SVM的故障诊断方法[J]. *中南工业大学学报: 自然科学版*, 2003, 34(4): 447-450.
(Guo M, Xie L, He N, et al. The method of independent component analysis and support vector machine based fault diagnosis[J]. *Journal of Central South University of Technology: Natural Science Edition*, 2003, 34(4): 447-450.)
- [69] He N, Zhang J M, Wang S Q. Combination of independent component analysis and multi-way principal component analysis for batch process monitoring[C]. 2004 IEEE International Conference on Systems, Man and Cybernetics. The Hague: IEEE, 2004: 530-535.
- [70] 何宁, 谢磊, 郭明, 等. 基于独立成分的动态多变量过程的故障检测与诊断方法[J]. *化工学报*, 2005, 56(4): 652-658.
(He N, Xie L, Guo M, et al. Fault detection and diagnosis in continuous dynamic multivariable processes using independent component analysis[J]. *CIESC Journal*, 2005, 56(4): 652-658.)
- [71] Lee J M, Yoo C K, Lee I B, et al. New monitoring technique with an ICA algorithm in the wastewater treatment process[J]. *Water Science and Technology*, 2003, 47(12): 49-56.
- [72] Martin E B, Morris A J. Non-parametric confidence bounds for process performance monitoring charts[J]. *Journal of Process Control*, 1996, 6(6): 349-358.
- [73] Jiang L Y, Wang S Q. Fault diagnosis based on independent component analysis and fisher discriminant analysis[C]. Proceedings of 2004 International Conference on Machine Learning and Cybernetics. Shanghai: IEEE, 2004: 3638-3643.
- [74] 杨英华, 吴英华, 陈晓波, 等. 基于独立源分析的过程监测方法[J]. *控制与决策*, 2006, 21(10): 1190-1192.
(Yang Y H, Wu Y H, Chen X B, et al. Process monitoring based on independent component analysis method[J]. *Control and Decision*, 2006, 21(10): 1190-1192.)
- [75] Hsu C C, Chen M C, Chen L S. Integrating independent component analysis and support vector machine for multivariate process monitoring[J]. *Computers & Industrial Engineering*, 2010, 59(1): 145-156.
- [76] Tian Y, Du W L, Qian F. Fault detection and diagnosis for non-Gaussian processes with periodic disturbance based on AMRA-ICA[J]. *Industrial & Engineering Chemistry Research*, 2013, 52(34): 12082-12107.
- [77] Luo L, Su H Y, Ban L. Independent component analysis-based sparse autoencoder in the application of fault diagnosis[C]. Proceeding of the 11th World Congress on Intelligent Control and Automation. Shenyang: IEEE, 2014: 1378-1382.
- [78] 严文武, 潘丰. 基于ICA-ELM的工业过程故障分类[J]. *计算机工程*, 2015, 41(10): 290-294.
(Yan W W, Pan F. Industry process fault classification based on ICA-ELM[J]. *Computer Engineering*, 2015, 41(10): 290-294.)
- [79] Wang B, Yan X F, Jiang Q C. Independent component analysis model utilizing de-mixing information for improved non-Gaussian process monitoring[J]. *Computers and Industrial Engineering*, 2016, 94: 188-200.
- [80] Zhu J L, Ge Z Q, Song Z H. Non-Gaussian industrial process monitoring with probabilistic independent component analysis[J]. *IEEE Transactions on Automation Science and Engineering*, 2017, 14(2): 1309-1319.
- [81] 王普, 辛娇娇, 高学金, 等. 基于独立元分析-最小二乘支持向量机的冷水机组故障诊断方法[J]. *北京工业大学学报*, 2017, 43(11): 1641-1647.
(Wang P, Xin J J, Gao X J, et al. Fault diagnosis of Chiller based on independent component analysis and least squares support vector machine[J]. *Journal of Beijing University of Technology*, 2017, 43(11): 1641-1647.)
- [82] Kassouf A, Bouveresse D J, Rutledge D N. Determination of the optimal number of components in independent components analysis[J]. *Talanta*, 2018, 179: 538-545.
- [83] Xie X L, Jiang B, Liu J W, et al. Fault detection and isolation based on MM-ICA with application to high-speed railway[C]. 2018 Chinese Automation Congress. Xi'an: IEEE, 2018: 111-115.

- [84] Stefatos G, Hamza A B. Dynamic independent component analysis approach for fault detection and diagnosis[J]. *Expert Systems with Applications*, 2010, 37(12): 8606-8617.
- [85] Odiowei P P, Cao Y. State-space independent component analysis for nonlinear dynamic process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2010, 103(1): 59-65.
- [86] Rashid M M, Yu J. A new dissimilarity method integrating multidimensional mutual information and independent component analysis for non-Gaussian dynamic process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2012, 115: 44-58.
- [87] Yang Y H, Chen Y L, Chen X B, et al. Multivariate industrial process monitoring based on the integration method of canonical variate analysis and independent component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 2012, 116: 94-101.
- [88] Huang J, Yan X F. Dynamic process fault detection and diagnosis based on dynamic principal component analysis, dynamic independent component analysis and Bayesian inference[J]. *Chemometrics and Intelligent Laboratory Systems*, 2015, 148: 115-127.
- [89] Yang J, Gao X M, Zhang D, et al. Kernel ICA: An alternative formulation and its application to face recognition[J]. *Pattern Recognition*, 2005, 38(10): 1784-1787.
- [90] Zhang Y W, Qin S J. Fault detection of nonlinear processes using multiway kernel independent component analysis[J]. *Industrial & Engineering Chemistry Research*, 2007, 46(23): 7780-7787.
- [91] Lee J M, Qin S J, Lee I B. Fault detection of non-linear processes using kernel independent component analysis[J]. *Canadian Journal of Chemical Engineering*, 2007, 85(4): 526-536.
- [92] 赵忠盖, 刘飞. 一种基于核独立元分析的非线性过程监控方法[J]. *系统仿真学报*, 2008, 20(20): 5585-5588. (Zhao Z G, Liu F. Nonlinear process monitoring method based on kernel independent component analysis[J]. *Journal of System Simulation*, 2008, 20(20): 5585-5588.)
- [93] Zhang Y W, Qin S J. Improved nonlinear fault detection technique and statistical analysis[J]. *AIChE Journal*, 2008, 54(12): 3207-3220.
- [94] Zhang Y W. Enhanced statistical analysis of nonlinear processes using KPCA, KICA and SVM[J]. *Chemical Engineering Science*, 2009, 64(5): 801-811.
- [95] 蔡连芳, 田学民, 张妮. 一种基于改进KICA的非高斯过程故障检测方法[J]. *化工学报*, 2012, 63(9): 2864-2868. (Cai L F, Tian X M, Zhang N. Non-Gaussian process fault detection method based on improved KICA[J]. *CIESC Journal*, 2012, 63(9): 2864-2868.)
- [96] Zhao J, Feng Y, Shen Z Y, et al. Research on robust kernel independent component analysis based on Kurtosis in fault detection[C]. *Proceedings of the 33rd Chinese Control Conference*. Nanjing: IEEE, 2014: 3047-3052.
- [97] 赵小强, 钱君秀. 基于双核独立元分析的化工过程故障诊断算法研究[J]. *上海交通大学学报*, 2014, 48(7): 1004-1008. (Zhao X Q, Qian J X. A fault diagnosis algorithm for chemical process based on dual-kernel independent component analysis[J]. *Journal of Shanghai Jiao Tong University*, 2014, 48(7): 1004-1008.)
- [98] Zhang X Y, Wang X D, Fan Y G, et al. Fault diagnosis of industrial process based on KICA and LSSVM[C]. *Chinese Control and Decision Conference*. Changsha: IEEE, 2014: 3802-3807.
- [99] Xiao Y W, Zhang X H. Novel nonlinear process monitoring and fault diagnosis method based on KPCA-ICA and MSVMs[J]. *Journal of Control, Automation and Electrical Systems*, 2016, 27(3): 289-299.
- [100] 韩敏, 张占奎. 基于加权核独立成分分析的故障检测方法[J]. *控制与决策*, 2016, 31(2): 242-248. (Han M, Zhang Z K. Fault detection method based on weighted kernel independent component analysis[J]. *Control and Decision*, 2016, 31(2): 242-248.)
- [101] Du W Y, Fan Y P, Zhang Y W, et al. Fault diagnosis of non-Gaussian process based on FKICA[J]. *Journal of the Franklin Institute-Engineering and Applied Mathematics*, 2017, 354(6): 2573-2590.
- [102] Cai L F, Tian X M, Chen S. Monitoring nonlinear and non-Gaussian processes using Gaussian mixture model-based weighted kernel independent component analysis[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(1): 122-135.
- [103] Feng L, Di T R, Zhang Y W. HSIC-based kernel independent component analysis for fault monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 178: 47-55.
- [104] Wang G P, Yang J X. SKICA: A feature extraction algorithm based on supervised ICA with kernel for anomaly detection[J]. *Journal of Intelligent & Fuzzy Systems*, 2019, 36(1): 761-773.
- [105] Zhang L, Zhong X Y, Chai Y, et al. A fault detection method for non-Gaussian industrial processes via joint KICA and FVS[C]. *Proceedings of 2018 Chinese Intelligent Systems Conference*. Singapore: Springer, 2019: 191-203.
- [106] Liu M G, Li X S, Lou C Y, et al. A fault detection method based on CPSO-improved KICA[J]. *Entropy*, 2019, 21(7): 668.
- [107] Kano M, Tanaka S, Hasebe S, et al. Combined multivariate statistical process control[J]. *IFAC*

- Proceedings Volumes, 2004, 37(1): 281-286.
- [108] Ge Z Q, Song Z H. Process monitoring based on independent component analysis-principal component analysis (ICA-PCA) and similarity factors[J]. *Industrial & Engineering Chemistry Research*, 2007, 46(7): 2054-2063.
- [109] Liu X Q, Xie L, Kruger U, et al. Statistical-based monitoring of multivariate non-Gaussian systems[J]. *AIChE Journal*, 2008, 54(9): 2379-2391.
- [110] Ge Z Q, Xie L, Song Z H. A novel statistical-based monitoring approach for complex multivariate processes[J]. *Industrial and Engineering Chemistry Research*, 2009, 48(10): 4892-4898.
- [111] Jiang Q C, Yan X F, Li J. PCA-ICA integrated with Bayesian method for non-Gaussian fault diagnosis[J]. *Industrial & Engineering Chemistry Research*, 2016, 55(17): 4979-4986.
- [112] Zhang S M, Zhao C H. Hybrid independent component analysis (H-ICA) with simultaneous analysis of high-order and second-order statistics for industrial process monitoring[J]. *Chemometrics and Intelligent Laboratory Systems*, 2019, 185: 47-58.
- [113] Xu Y, Shen S Q, He Y L, et al. A novel hybrid method integrating ICA-PCA with relevant vector machine for multivariate process monitoring[J]. *IEEE Transactions on Control Systems Technology*, 2019, 27(4): 1780-1787.
- [114] Gallagher N B, Wise B M, Butler S W, et al. Development and benchmarking of multivariate statistical process control tools for a semiconductor etch process: Improving robustness through model updating[J]. *IFAC Proceedings Volumes*, 1997, 30(9): 79-84.
- [115] Kano M, Hasebe S, Hashimoto I, et al. Evolution of multivariate statistical process control: Application of independent component analysis and external analysis[J]. *Computers & Chemical Engineering*, 2004, 28(6/7): 1157-1166.
- [116] Rashid M M, Yu J. Hidden Markov model based adaptive independent component analysis approach for complex chemical process monitoring and fault detection[J]. *Industrial & Engineering Chemistry Research*, 2012, 51(15): 5506-5514.
- [117] Zhang Y W, An J Y, Zhang H L. Monitoring of time-varying processes using kernel independent component analysis[J]. *Chemical Engineering Science*, 2013, 88: 23-32.
- [118] Jiang Q C, Yan X F. Joint probability density and double-weighted independent component analysis for multimode non-Gaussian process monitoring[J]. *Industrial & Engineering Chemistry Research*, 2014, 53(52): 20168-20176.
- [119] Zhong N, Deng X G. Multimode non-Gaussian process monitoring based on local entropy independent component analysis[J]. *The Canadian Journal of Chemical Engineering*, 2017, 95(2): 319-330.
- [120] 张杨. 基于粒子群优化的工业过程独立成分分析方法研究与应用[D]. 沈阳: 东北大学信息科学与工程学院, 2010.
(Zhang Y. Study on application of independent component analysis methods based on PSO in industrial process[D]. Shenyang: School of Information Science and Engineering, Northeastern University, 2010.)
- [121] 刘强, 卓洁, 郎自强, 等. 数据驱动的工业过程运行监控与自优化研究展望[J]. *自动化学报*, 2018, 44(11): 1944-1956.
(Liu Q, Zhuo J, Lang Z Q, et al. Perspectives on data-driven operation monitoring and self-optimization of industrial processes[J]. *Acta Automatica Sinica*, 2018, 44(11): 1944-1956.)
- [122] Yoo C K, Lee D S, Vanrolleghem P A. Application of multiway ICA for on-line process monitoring of a sequencing batch reactor[J]. *Water Research*, 2004, 38(7): 1715-1732.
- [123] Yoo C K, Lee J M, Vanrolleghem P A, et al. On-line monitoring of batch processes using multiway independent component analysis[J]. *Chemometrics and Intelligent Laboratory Systems*, 2004, 71(2): 151-163.
- [124] Zhao C H, Wang F L, Mao Z Z, et al. Adaptive monitoring based on independent component analysis for multiphase batch processes with limited modeling data[J]. *Industrial & Engineering Chemistry Research*, 2008, 47(9): 3104-3113.
- [125] Yu J, Chen J Y, Rashid M M. Multiway independent component analysis mixture model and mutual information based fault detection and diagnosis approach of multiphase batch processes[J]. *AIChE Journal*, 2013, 59(8): 2761-2779.
- [126] Guo H, Li H G. On-line batch process monitoring with improved multi-way independent component analysis[J]. *Chinese Journal of Chemical Engineering*, 2013, 21(3): 263-270.
- [127] 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.
- [128] Sun D D, Gong X F, Chen Y L. Integrating canonical variate analysis and kernel independent component analysis for Tennessee Eastman process monitoring[J]. *Journal of Chemical Engineering of Japan*, 2020, 53(3): 126-133.
- [129] Tian R M, Cao Y. Multi-layer contribution propagation analysis for fault diagnosis[J]. *International Journal of Automation and Computing*, 2019, 16(1): 40-51.
- [130] 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.
- [131] Peng K X, Li Q Q, Zhang K, et al. Quality-related process monitoring for dynamic non-Gaussian batch process with multi-phase using a new data-driven method[J]. *Neurocomputing*, 2016, 214: 317-328.
- [132] Xiao Y W, Zhang C Z. Novel nonlinear process monitoring based on KPCA-ICA[J]. *Advanced Materials Research*, 2012, 588/589: 1054-1057.
- [133] Fan J C, Qin S J, Wang Y Q. Online monitoring of nonlinear multivariate industrial processes using filtering KICA-PCA[J]. *Control Engineering Practice*, 2014, 22: 205-216.
- [134] Yu J. A nonlinear kernel Gaussian mixture model based inferential monitoring approach for fault detection and diagnosis of chemical processes[J]. *Chemical Engineering Science*, 2012, 68(1): 506-519.
- [135] Na Z, Xiao G D. Nonlinear multimode process fault detection based on KNN-KICA[C]. *The 27th Chinese Control and Decision Conference. Qigndao: IEEE*, 2015: 2770-2775.
- [136] 王丽, 侍洪波. 基于核独立元分析的间歇过程在线监控[J]. *化工学报*, 2010, 61(5): 1183-1189.
(Wang L, Shi H B. Online batch process monitoring based on kernel ICA[J]. *CIESC Journal*, 2010, 61(5): 1183-1189.)
- [137] 常鹏, 乔俊飞, 王普, 等. 基于MKECA的非高斯性和非线性共存的间歇过程监测[J]. *化工学报*, 2018, 69(3): 1200-1206.
(Chang P, Qiao J F, Wang P, et al. Monitoring non-Gaussian and non-linear batch process based on multi-way kernel entropy component analysis[J]. *CIESC Journal*, 2018, 69(3): 1200-1206.)
- [138] 王培良, 葛志强, 宋执环. 基于迭代多模型ICA-SVDD的间歇过程故障在线监测[J]. *仪器仪表学报*, 2009, 30(7): 1347-1352.
(Wang P L, Ge Z Q, Song Z H. Online fault monitoring for batch processes based on adaptive multi-model ICA-SVDD[J]. *Chinese Journal of Scientific Instrument*, 2009, 30(7): 1347-1352.)
- [139] 肖应旺, 徐保国. 基于ICA-MPCA的间歇过程监测方法[J]. *仪器仪表学报*, 2009, 30(5): 990-996.
(Xiao Y W, Xu B G. Monitoring method for batch process based on ICA-MPCA[J]. *Chinese Journal of Scientific Instrument*, 2009, 30(5): 990-996.)
- [140] Zhao C H, Gao F R, Wang F L. Nonlinear batch process monitoring using phase-based kernel independent component analysis — Principal component analysis (KICA-PCA)[J]. *Industrial & Engineering Chemistry Research*, 2009, 48(20): 9163-9174.
- [141] 樊继聪, 王友清, 秦泗钊. 联合指标独立成分分析在多变量过程故障诊断中的应用[J]. *自动化学报*, 2013, 39(5): 494-501.
(Fan J C, Wang Y Q, Qin S Z. Combined indices for ICA and their applications to multivariate process fault diagnosis[J]. *Acta Automatica Sinica*, 2013, 39(5): 494-501.)
- [142] Chen M C, Hsu C C, Malhotra B, et al. An efficient ICA-DW-SVDD fault detection and diagnosis method for non-Gaussian processes[J]. *International Journal of Production Research*, 2016, 54(17): 5208-5218.
- [143] 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.
(Yang Z Y, Wang P L. Fault detection method for non-linear systems based on kernel independent component analysis and support vector data description[J]. *Information and Control*, 2017, 46(2): 153-158.)
- [144] 王培良, 叶晓丰, 杨泽宇. 独立成分相关分析的自适应故障监测方法[J]. *控制理论与应用*, 2018, 35(9): 1331-1338.
(Wang P L, Ye X F, Yang Z Y. Adaptive fault detection method based on correlation analysis of independent component[J]. *Control Theory & Applications*, 2018, 35(9): 1331-1338.)

作者简介

孔祥玉(1967—), 男, 教授, 博士生导师, 从事系统特征提取、非线性系统建模及其应用、自适应信号处理等研究, E-mail: xiangyukong01@163.com;

杨治艳(1997—), 女, 硕士生, 从事系统特征提取、多元统计过程监控的研究, E-mail: 1151212817@qq.com;

刘佑民(1985—), 男, 高级工程师, 博士, 从事智能化与健康管理等研究, E-mail: snakelym1985@163.com;

罗家宇(1994—), 男, 博士生, 从事系统特征提取、基于数据驱动的复杂系统故障检测及诊断的研究, E-mail: 540629964@qq.com;

王晓兵(1996—), 男, 硕士生, 从事复杂系统的故障检测及诊断、非线性系统建模及其应用的研究, E-mail: ctwangxiaobing@163.com.

(责任编辑: 郑晓蕾)