



# 数据驱动的多工况过程异常监测方法: 综述与展望

张景欣<sup>1</sup>, 周东华<sup>2,3\*</sup>, 陈茂银<sup>3</sup>, 吴德浩<sup>4</sup>

1. 东南大学自动化学院, 复杂工程系统测量与控制教育部重点实验室, 南京 210096

2. 山东科技大学电气与自动化工程学院, 青岛 266000

3. 清华大学自动化系, 北京 100018

4. 中南大学自动化学院, 长沙 410083

\* 通信作者. E-mail: zdh@mail.tsinghua.edu.cn

收稿日期: 2022–10–17; 修回日期: 2022–12–28; 接受日期: 2023–02–21; 网络出版日期: 2023–11–07

国家自然科学基金 (批准号: 62033008, 61873143, 62203472)、山东省泰山学者项目、山东省自然科学基金 (批准号: ZR2022ZD34) 和中央高校基本科研业务费专项资金资助项目

**摘要** 由于原材料、设定点、外界环境等因素变化, 工业过程通常具有多个运行工况. 多工况过程异常监测技术是保证工业系统安全运行的有效方式, 也是过程监测技术的研究热点与难点. 首先, 对多工况过程异常监测方法进行概述, 并将多工况过程的常见处理方式归纳为整体建模、自适应建模、混合建模和多模型建模方法; 其次, 分别回顾了多工况平稳过程和多工况非平稳过程的研究现状, 并分析了各类方法的优缺点; 最后, 结合实际工业系统特点, 指出该领域亟须解决的问题和未来发展方向.

**关键词** 数据驱动, 多工况过程, 异常监测, 平稳过程, 非平稳过程, 故障检测

## 1 引言

制造业是国民经济的主体, 是提升综合国力、保障国家安全、建设世界强国的关键. 与世界先进水平相比, 我国的制造业依然大而不强, 在自主创新能力、资源利用效率、产业结构水平、信息化程度等方面存在明显差距. 《中国制造 2025》指出, 加快制造业转型升级, 需要推进信息化和工业化深度融合, 推进制造过程智能化, 促进制造工业的状态信息实时监测. 工业系统内部结构复杂, 各组成部件联系紧密, 如果不能及时排除故障, 可能会造成巨大的经济损失甚至是人员伤亡. 异常监测技术可以及时识别过程异常和偏差, 指导操作员采取适当措施防止故障传播, 提高工业过程运行的安全性和可靠性. 随着工业生产智能化水平的不断提高、传感器技术和数据处理技术不断发展和进步, 工业系统积累了海量运行数据, 为数据驱动异常监测方法奠定坚实的基础.

经过三十多年的发展, 数据驱动异常监测技术逐渐受到重视<sup>[1,2]</sup>, 并取得了丰硕成果. 文献 [3] 总结了常用的主成分分析方法, 包括静态主成分分析、动态主成分分析、递归主成分分析和滑窗主成分

**引用格式:** 张景欣, 周东华, 陈茂银, 等. 数据驱动的多工况过程异常监测方法: 综述与展望. 中国科学: 信息科学, 2023, 53: 2087–2106, doi: 10.1360/SSI-2022-0404  
Zhang J X, Zhou D H, Chen M Y, et al. Data-driven anomaly monitoring methods for multimode processes: overview and perspectives (in Chinese). Sci Sin Inform, 2023, 53: 2087–2106, doi: 10.1360/SSI-2022-0404

表 1 评估多工况过程异常监测方法的标准案例和实际过程

Table 1 Benchmarks and real processes to evaluate anomaly detection approaches in multimode processes

	Name	Number of modes	Number of variables	Number of faults	Refs.
Benchmarks	Tennessee Eastman process	6	53	20	[13, 15~17]
	Continuous stirred tank reactor	2	9	6	[18~20]
	Fluidized catalytic cracking unit	2	335	10	[21]
	Distillation column	6	23	3	[22]
	Continuous stirred tank heater	5	3	2	[11, 23~26]
Practical processes	Industrial polyethylene process	3	15	3	[27, 28]
	Spheripol craft polypropylene	4	14	2	[29]
	Annealing furnace system	3	23	1	[30, 31]
	Wastewater treatment plants	3	11	2	[14, 32]
	Large-scale thermal power unit	3	14	3	[33~38]
	Finishing mill process	3	22	2	[9, 39, 40]
	Wind energy conversion system	2	10	2	[41]

分析,并在田纳西伊斯曼过程上进行详细比较,最后讨论了时间相关数据建模的挑战.文献[4]介绍了多元统计分析的基础知识,强调了设计分布式监测方案的必要性,并讨论了厂级监测的机遇和挑战.文献[5]从工业数据描述和挖掘的角度回顾了数据驱动异常监测方法的经典研究和最新进展,讨论了实际工业应用面临的挑战和可能的解决方案.文献[6]回顾了机器学习、数据挖掘技术在故障诊断的一般理论,以及在风力涡轮机和非线性伺服系统等系统装备的应用.文献[7]总结了基于模型、基于信号处理和基于人工智能的故障诊断方法,同时介绍了自动故障诊断系统设计和开发的典型步骤,包括系统知识表示、数据采集和信号处理、故障分类以及与维护相关的决策措施.由于原材料变化、设定点变动、外界环境、产品类型变动等,工业生产过程通常呈现多工况特性<sup>[8~11]</sup>,诸如连续搅拌釜式加热器<sup>[12]</sup>、田纳西伊斯曼过程<sup>[13]</sup>、污水处理过程<sup>[14]</sup>等.表1<sup>[9,11,13~41]</sup>总结了常用多工况过程的标准案例和实际工业过程信息,以及异常监测中的应用.但上述研究通常要求系统运行在单一工况下,不适合多工况过程的异常监测.

云计算和物联网的发展推动了机器学习在工业4.0方向的发展,促使机器学习成为解决多工况过程异常监测问题的重要技术.机器学习方法可分为无监督学习、半监督学习、监督学习和强化学习等.其中,基于无监督学习的多工况过程异常监测方法无需工况标签,利用聚类算法划分工况,或者建立单个异常监测模型<sup>[10,25,42,43]</sup>.基于监督学习的多工况过程异常监测方法在离线阶段训练需要工况标签信息,在线阶段需要辨识工况并进行异常监测<sup>[44,45]</sup>.若仅有少量的标签数据和大量无标签数据,需要借助半监督学习方法建立准确的异常监测模型<sup>[46]</sup>.强化学习通过学习策略以达成回报最大化或实现特定目标,已被应用于单一工况异常监测领域<sup>[47~49]</sup>,但尚未应用于多工况过程异常监测.文献[50]介绍了多工况机器学习,指出表示、融合、协同学习等是当前面临的挑战.文献[12]总结了20年来100多篇论文,将多工况连续过程异常监测方法划分为单模型方法和多模型方法,并分析了现有方法的优缺点和未来研究方向,但相关研究方法适用于每个工况均平稳的情形,不适用于每个工况非平稳的过程.文献[8]围绕多工况连续过程,介绍了离线和在线工况辨识方法,从多模型和混合模型角度回顾了多工况过程异常监测方法研究现状.由于深度学习在特征表示方面的优势,迁移学习、变分自编码器<sup>[51~58]</sup>等深度学习方法开始应用于多工况过程异常监测领域.例如,文献[57]提出了一种基于迁移学




图1 (网络版彩图) 传统多工况过程示意图

Figure 1 (Color online) Illustration of traditional multimode processes

习的多工况化学过程异常监测与诊断方法, 将知识从历史工况转移到异常监测的目标工况, 可解决某些工况中的异常数据稀少和无标签问题. 为了充分利用历史工况数据中的知识, 文献 [58] 提出了一种迁移字典学习方法来解决不同工况间的知识迁移问题, 从历史工况数据中学习初始字典, 随后通过平滑子空间插值的方式结合目标工况数据不足的特征来更新最终字典.

本文从多工况过程出发, 介绍多工况过程的一般处理方式, 包括整体建模、自适应建模、混合建模和多模型建模, 并分析其优缺点. 然后, 针对每个工况数据的平稳性, 回顾多工况平稳过程和多工况非平稳过程异常监测研究现状. 结合实际工业系统特点, 讨论目前存在的问题, 并进一步介绍多工况过程异常监测的未来发展方向.

## 2 多工况过程异常监测方法概述

### 2.1 基本定义

传统多工况过程要求每个工况在准稳态下运行, 不考虑工况间的过渡过程. 本文在定义多工况过程之前, 给出平稳工况的定义.

**定义1** 若数据在一定时间内变化率小, 即满足下列条件<sup>[12,59]</sup>:

$$\left| \frac{x(t) - x(t_0)}{t - t_0} \right| < T_x, \quad \forall t \in [t_0, t_0 + \Delta t], \quad (1)$$

则过程运行在平稳工况. 其中,  $x(t)$  是  $t$  时刻的变量,  $x(t_0)$  表示相应变量在初始  $t_0$  时刻的数值,  $T_x$  是与噪声方差和测量单元相关的阈值.

多工况过程是指由于外界环境变化、生产方案变动、原料特性变化等, 生产过程具有多个平稳工况<sup>[8]</sup>. 过程统计特性从一个工况过渡到另一个工况, 多工况特征可以看成是一种特殊的暂态或时变行为. 图1描述了传统多工况过程变量变化趋势, 每个工况内数据的均值、方差和协方差不随时间发生变化, 但不同工况的统计特性差异大.

由于负荷变动、外界环境、扰动等, 工业过程可被认定为随机过程. 为了更好地描述非平稳过程, 本文首先给出了弱平稳过程的概念.

**定义2** 一个随机过程  $\{X(t)\}$ , 对任意的正整数  $t$  和  $\tau$ , 满足下列条件<sup>[60]</sup>: (1) 期望  $\mathbb{E}[X(t)]$  为常数; (2) 方差  $\mathbb{E}[X^2(t)] < \infty$ ; (3) 协方差  $\mathbb{E}[X(t)X(t+\tau)]$  是关于  $\tau$  的函数, 则该过程为弱平稳过程.

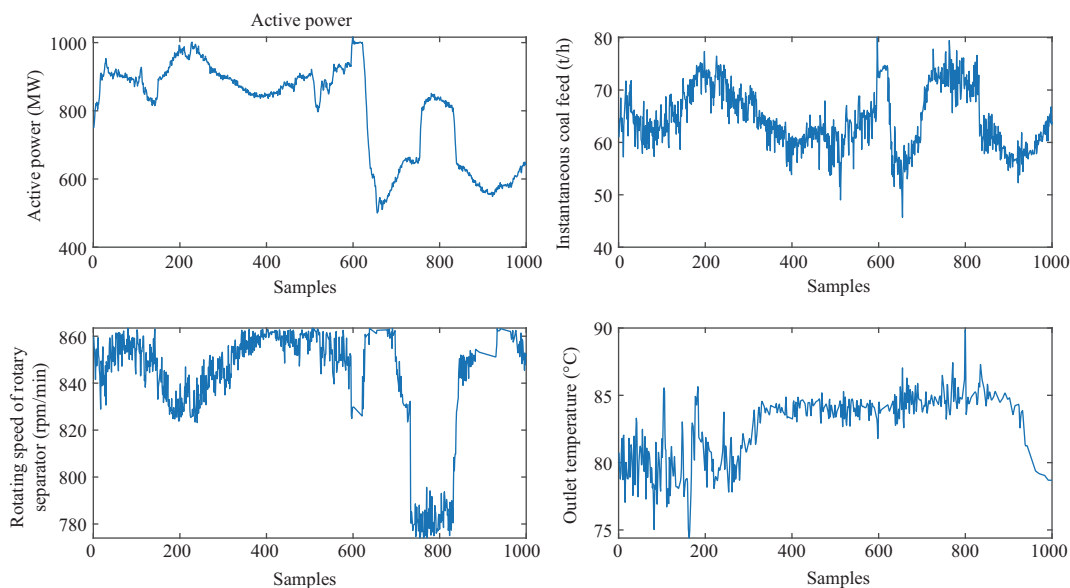


图 2 (网络版彩图) 多工况非平稳过程示意图

Figure 2 (Color online) Illustration of multimode nonstationary processes

若不满足上述条件, 则该过程为非平稳过程, 即数据的统计特性随时间发生变化的随机过程。

传统的多工况过程通常要求每个工况数据是平稳的, 如图 1 所示。但实际工业过程的多工况特性通常与非平稳特性、不确定性等耦合, 给异常监测带来诸多挑战。以大型火力发电机组为例, 原煤、负荷和环境因素影响机组的运行状态, 负荷随市场需求实时变化。如果按照传统的多工况过程定义式 (1) 划分火力发电机组的工况, 会造成工况数量庞大、每个工况的数据量少、相似工况重复出现等问题, 难以建立准确可靠的异常监测模型。结合研究对象的领域知识和系统原理, 考虑以原煤种类作为工况划分准则, 每个工况内的测量数据与负荷息息相关。若负荷是平稳变化, 则该过程为多工况平稳过程, 也是传统意义上的多工况过程。若负荷非平稳变化, 该过程为多工况非平稳过程, 如图 2 所示。出口温度设置与原煤息息相关, 实际出口温度在设定值附近波动, 可用于辅助判断工况。从图 2 可看出, 温度从  $80^{\circ}\text{C}$  转换到  $84^{\circ}\text{C}$ , 工况发生变化, 有功功率、瞬时给煤量、旋转分离器转速等呈现非平稳变化趋势。需要指出的是, 本文研究的多工况过程包括多工况平稳过程和多工况非平稳过程。

## 2.2 多工况过程的一般处理方式

结合文献 [8, 12] 及国内外学者的研究现状, 多工况过程异常监测思路可归纳为整体建模、自适应建模、混合建模和多模型建模 4 种类型。该种分类方法重点关注多工况的处理方式, 不考虑每个工况内数据的平稳性。

(1) 整体建模方法。整体建模方法借助转换函数  $G(\boldsymbol{x})$  移除数据的多工况特征<sup>[61, 62]</sup>, 将多峰分布数据转化为单峰分布数据, 随后利用传统的单一工况异常监测方法训练模型  $F(\boldsymbol{z})$ 。如图 3 所示, 在线应用阶段, 样本  $\boldsymbol{x}$  经  $G(\boldsymbol{x})$  转化为  $\boldsymbol{z}$ , 通过模型  $F(\boldsymbol{z})$  判断系统运行状态。近邻方法是常用的转换函数之一, 考虑数据的时间和空间信息的近邻方法有利于提高监测性能<sup>[62]</sup>。准确的转换函数是该类方法获取良好性能的关键, 但近邻方法的参数依赖于实际数据, 难以提供一个具有普适性的参数估计方法。另一种方式是利用转换函数将多工况数据投影到一个共同子空间和若干特定子空间<sup>[9, 11, 63]</sup>, 不需要过程运行状态的先验信息。其中, 共同子空间体现各工况数据的共有信息, 而特定子空间反映每个工




图3 整体建模方式

Figure 3 Overall modeling method




图4 自适应建模方式

Figure 4 Adaptive modeling method

况独有的特征. 该类方法要求建模前获取完备的训练数据, 存储历史工况的运行数据<sup>[11]</sup>. 若出现新颖工况, 采集该工况充分数据, 重新训练转换函数和异常监测模型. 在实际系统中, 新颖工况可能频繁出现, 导致该类方法的计算复杂度高; 难以确定准确的转换函数, 从而影响异常监测性能.

(2) 自适应建模方法. 传统的自适应建模方法在离线阶段根据少量数据训练初始模型, 在线应用阶段根据多工况条件和当前采集的正常数据实时调整监测模型  $F(\mathbf{x})$  参数, 以适应系统的缓慢变化, 如图4所示. 为了提高异常监测性能, 采用遗忘因子策略<sup>[64, 65]</sup>、贝叶斯策略<sup>[23, 43]</sup>和基于知识的规则<sup>[66, 67]</sup>等辅助更新模型参数. 遗忘因子策略不需要任何工况信息, 若判定系统运行正常, 根据新采集数据自动更新模型参数<sup>[64, 65]</sup>, 容易造成模型过拟合和高误报率. 贝叶斯策略指根据贝叶斯原理和若干个局部模型构建一个全局异常监测模型, 并依据新样本信息更新各局部模型参数<sup>[23]</sup>. 基于知识的规则方法利用过程知识、先验信息等移除干扰, 判断系统变化进而更新模型参数, 避免不必要的更新<sup>[66, 67]</sup>. 上述自适应建模方法不需要进行数据聚类, 适用于变化缓慢的多工况过程. 但数据预处理过程需要复杂的计算量, 难以辨识工况和选择模型参数, 无法准确跟踪多工况过程的快速变化.

另一种自适应建模方式是将多工况过程看成连续工况, 建立具有持续学习能力的多工况过程异常监测模型<sup>[33~37]</sup>. 它不需要完备的工况数据, 认定运行工况是依次出现的, 序列式地训练各个工况, 更加符合实际系统的特点. 该类方法的思想是将持续学习方法引入异常监测领域, 重点是解决传统方法应用于多工况过程时存在的遗忘灾难问题, 学习新颖工况特征时保留已学习工况的重要知识. 根据数据使用和知识巩固的方式, 持续学习可划分为正则化、数据重放和参数分离三类<sup>[68~70]</sup>. 基于正则化思想的多工况过程异常监测方法在损失函数中加入正则项, 减少工况敏感参数的变化, 以保留先前工况的重要信息, 克服单模型在连续工况下的遗忘灾难问题. 当工况发生变化, 采集新颖工况的少量数据更新模型参数, 同时保留已有工况的重要特征. 该类方法的关键是选择合适的异常监测方法、准确估计参数重要性和工况变换时刻. 优点是利用单个模型实现已学习工况和未来相似工况的异常监测, 不遗忘已学习的知识, 不需要完备的工况训练数据. 但此类方法要求工况具有一定的相似性, 不适合差异显著的多工况过程. 为了解决工况相似性的约束, 考虑采用数据重放方法解决单个模型在多工况的遗忘灾难问题, 即保存每个工况的代表性数据, 当新颖工况出现时, 从所有工况的原始测量数据中提取多工况特征, 实现多工况过程的异常监测, 同时能减少数据存储成本, 降低计算复杂度.

(3) 混合建模方法. 混合建模方法是在训练阶段建立若干局部异常监测模型  $F_1(\mathbf{x}), \dots, F_K(\mathbf{x})$ , 然后根据贝叶斯原理计算当前样本隶属各局部模型的后验概率, 通过贝叶斯融合得到全局监测结果  $J(\mathbf{x})$ <sup>[25, 42, 43, 71~73]</sup>. 如图5所示, 在线应用阶段, 计算当前样本  $\mathbf{x}$  在各个局部模型的监测结果, 随后经过线性加权获取监测结果  $J(\mathbf{x})$ . 其中, 局部模型数量  $K$  依据最小消息长度准则<sup>[43]</sup>、贝叶斯信息测度<sup>[74]</sup>、贝叶斯 Ying-Yang 学习准则<sup>[72, 75]</sup>、分数变量的核密度估计<sup>[76]</sup>和熵惩罚算子<sup>[77]</sup>等策略进行估计. 文献<sup>[71, 72]</sup>指出, 采用概率形式的混合模型能够有效处理工业数据中的噪声和不确定性. 混合






图 5 混合建模方式

Figure 5 Mixture modeling method

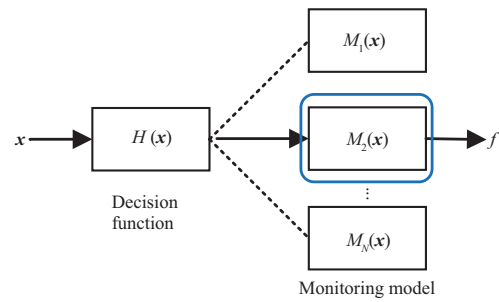


图 6 (网络版彩图) 多模型建模方式

Figure 6 (Color online) Multi-model modeling method

建模方法能灵活地为每个工况选择特定的监测模型, 同时考虑所有模型决策, 对过渡过程也有一定的监测能力. 但它需要完备的训练数据, 当新颖工况出现时, 需要采集并保存新颖工况正常数据, 重新训练模型参数. 实际工业过程会源源不断地出现新颖工况, 该类方法将会消耗巨大的数据存储成本和计算量.

(4) 多模型建模方法. 多模型方法在离线训练阶段利用聚类方法对数据进行划分, 认定每一类的数据来源于同一个工况, 为每个工况建立异常监测模型  $M_1(x), \dots, M_N(x)$ . 常见的聚类方法包括均值聚类、模糊  $c$  均值聚类、基于密度的聚类方法、基于滑窗的方法、隐马尔可夫模型等 [12, 78]. 如图 6 所示, 在线应用阶段, 该类方法通过决策函数  $H(x)$  判断当前样本所属工况, 确定异常监测模型进而识别运行状态 [79~81]. 需要指出的是,  $N$  为工况数量, 随着工业过程的发展不断增加. 常见的决策函数包括均方预测误差 [79]、概率函数 [81]、聚类方法 [82, 83] 等, 部分利用决策函数的多工况方法可同时监测平稳工况和过渡过程 [17, 84]. 该类方法能够辨识工况, 并为每个工况建立一个确定的异常监测模型, 但决策函数的准确性直接影响异常监测性能. 此外, 该类方法在训练前需要完备的训练数据, 数据存储成本和计算量大, 若存在大量相似工况, 可能出现工况辨识错误等问题.

表 2 总结了 4 种多工况过程异常监测一般处理方式的基本思想、优缺点和代表性文献. 整体建模和自适应建模属于单模型方法, 区别在于整体建模方法离线训练模型, 一旦出现新颖工况, 需要重新训练模型; 自适应方法根据新采集正常数据在线更新模型参数, 无须保存所有历史工况数据. 混合建模和多模型方法均需要提前确定局部模型数量, 存储所有工况历史数据, 一旦出现新颖工况, 需重新训练模型参数. 二者的区别在于混合模型方法将多个局部模型进行加权融合得到一个全局模型, 工况数量和局部模型数量  $K$  没有确定的关系; 多模型方法需要在线识别工况, 进而确定监测模型,  $N$  为工况数量.

### 3 多工况平稳过程异常监测研究现状

传统多工况过程是指多工况平稳过程, 即每个工况内数据平稳, 其异常监测问题已经得到了广大学者的关注, 并取得了丰硕的成果 [9, 15, 64, 72, 79, 80]. 借助表 2 的多工况处理方法, 依据将单一工况平稳过程异常监测方法拓展到多工况过程的研究思路, 梳理现有多工况平稳过程异常监测的研究现状. 单工况平稳过程的异常监测方法包括多元统计分析方法 [85]、信号处理 [86, 87] 和机器学习 [88, 89]. 其中, 最常见的方法包括主成分分析 (principal component analysis, PCA) [90, 91]、偏最小二乘 (partial least squares, PLS) [92, 93]、独立成分分析 (independent component analysis, ICA) [94]、线性判别分析 (linear

表 2 多工况过程的一般处理方式

Table 2 General monitoring methods for multimode processes

Approach	Technical core	Virtues	Drawbacks	Refs.
Overall modeling	A single model is built to describe the common features of multiple modes.	There is no need to cluster data.	It is intractable to acquire an accurate transformation function.	[9, 11, 61~63]
Adaptive modeling	The monitoring model is updated adaptively to adapt to the changing characteristics when the mode switches.	It enables to track the slow normal variations.	It is difficult to track the rapid changes accurately.	[33, 35~37, 64, 65]
Mixture modeling	A global model is built based on a weighted sum of local models, which can represent the multiple characteristics.	It is flexible to select a specific model for each mode and all model decisions are considered.	Mode is not identified and data from all potential modes are required before learning.	[25, 42, 71~73]
Multi-model modeling	Local monitoring models are built corresponding to each mode.	The mode is identified and a fixed model is established for each mode.	It is difficult to identify similar modes accurately and the monitoring performance depends on the decision function.	[17, 79~81, 84]

discriminant analysis, LDA)<sup>[95]</sup>、典型相关性分析 (canonical correlation analysis, CCA)、支持向量数据描述 (support vector data description, SVDD) 等, 上述方法的核心思想和优缺点详见表 3<sup>[96~100]</sup>.

### 3.1 基于整体建模的多工况平稳过程异常监测

基于整体建模的多工况平稳过程异常监测方法, 是将 2.2 小节介绍的整体建模方式与单工况平稳过程异常监测方法相结合, 实现多工况平稳过程的异常监测.

文献 [101] 借助加权  $k$  近邻标准化方式, 将多工况数据转化为近似的单工况或高斯分布数据, 随后建立基于 PCA 的异常监测模型. 文献 [61] 提出了一种基于局部密度比加权 SVDD 的多工况过程异常监测方法, 以解决训练样本中具有不同密度和离群值的多工况异常监测问题. 文献 [55] 采用三层堆叠式自动编码器从混合数据中提取特征, 消除混合数据的多工况特性, 并采用 Fisher 准则项分离正常和异常状态. 为了解决非线性多工况问题, 文献 [100] 通过计算预测输出和真实输出的差值消除多工况特性影响, 利用 SVDD 建立一维距离统计量在线监测系统运行状态. 文献 [11] 提出了一种基于结构字典学习的多工况过程异常监测方法, 不仅可以检测数据的故障, 还可以对正常工况进行分类和辨识, 从而采取适当的控制策略. 文献 [9] 分别在 PCA 和 PLS 基础上, 提取所有工况的共同特征以及每个工况独有的特征, 用于跟踪多工况过程的运行性能和产品质量. 文献 [63] 针对具有共同特征的多工况过程, 提出了一种新的基于共同特征和特有特征提取的异常监测方法, 构建共同基向量和特有基向量. 当新颖工况出现, 采集相应的正常数据, 使用迁移方法更新两个基向量, 并通过 Kullback-Leibler (KL) 距离衡量这两个特征中发生的变化. 考虑到多个工况之间的相似性和差异, 文献 [52] 提出了一种变向加权并行叠层自动编码器模型, 能够并行地提取工况公共和工况特有的深度特征, 用于非线性多工况过程异常监测. 文献 [102] 考虑不同工况间的过渡过程, 提出了一种工况间相对分析算法来研究工况间的关系. 根据每个工况与参考工况之间的相对变化以及对异常监测的影响, 将其分为三个不同的系统子空间和一个残差子空间, 包括增加部分、减少部分和不变部分. 然后分别对这些不同的变

表 3 典型的平稳过程异常监测方法

Table 3 Typical anomaly detection methods for single-mode stationary processes

Approach	Technical core	Virtues	Drawbacks	Refs.
PCA	Principal components that are linear independent are extracted by maximizing the covariance.	Simple calculation, few parameters, removing data noise and redundancy.	The variables are required to be linearly related, subject to Gaussian distribution, and independent of time.	[9, 33, 36, 65, 82]
PLS	Quality-related information is extracted and it tends to find faults in process input.	It can predict key performance indicators online and is applied to linear Gaussian processes.	It is sensitive to outliers and missing data. Besides, decomposition of process variable space is incomplete.	[9, 96]
ICA	Independent signal sources and higher-order statistical information are extracted from non-Gaussian signals.	It is applied to linear non-Gaussian processes.	The correlation of data in time series may be ignored and there may be a local minimum.	[82]
LDA	It is a supervised dimension reduction method, which aims to minimize the intra-class variance and maximize the inter-class difference.	Category prior information is used, and the classification information depends on the mean value.	It is not applicable to non-Gaussian distribution data, and may be overfitted.	[80, 97]
CCA	The correlation between two groups of indicators is reflected by the correlation between the comprehensive variables.	It can reflect the many-to-many relationship of two groups of variable indicators, and it is highly generalizable.	It is unable to represent the nonlinear and temporal relationship of data.	[71, 98, 99]
SVDD	It is a one-class classification issue and the target data set is hyperspherically described.	No data distribution is required, and it is robust to outliers.	The differences between different modes in data are ignored, and the monitoring model lacks interpretability.	[61, 100]

化进行建模, 并定义不同的监测统计信息进行在线监测, 以识别工况从属关系并监测异常状态。

上述基于整体建模的多工况平稳过程异常监测方法可归纳为 3 种类型: (1) 采用  $k$  近邻方法构建转换函数, 将多工况数据转化为单峰分布数据, 但难以确定合适近邻参数; (2) 采用 SVDD 等回归方法预测系统输出, 通过预测值和真实值间的残差消除多工况特性, 回归方法的预测性能将影响异常监测准确性; (3) 提取多个工况的共同特征和工况特有特征, 分别建立异常监测模型, 有利于判断异常的工况归属。当新颖工况出现, 上述三类方法通常需要重新训练模型, 计算复杂度高, 难以满足实际系统对算法的实时性需求。

### 3.2 基于自适应建模的多工况平稳过程异常监测

基于自适应建模的多工况平稳过程异常监测方法可归纳为两类: (1) 传统意义上的自适应方法, 即在线应用阶段, 根据当前采集的正常样本不断更新单一工况平稳过程异常监测模型参数, 诸如 PCA, PLS 等, 以适应多工况过程的变化; (2) 具有持续学习能力的多工况平稳过程异常监测方法, 在工况发生变化时, 根据采集的新颖工况少量数据更新模型参数, 特点在于提取新特征时巩固以前工况的重要知识。



传统自适应方法的研究起步较早,学者结合实际需求和现有方法的局限性不断提高异常监测方法性能.递归 PCA (recursive PCA, RPCA) 方法采用遗忘因子策略,依据当前采样数据不断更新 PCA 模型参数,从而实现多工况平稳过程的异常监测<sup>[65]</sup>.它不需要工况先验信息,但难以跟踪不同工况间的快速变化,容易将正常工况变化误判为异常.考虑到传统 RPCA 方法存在适应干扰、频繁更新模型、不能准确识别当前状态等问题,文献 [66] 借助过程知识和 if-then 规则提出了一种鲁棒 RPCA 方法,通过检测和辨识过程变化、移除干扰等反映工况变化,工况未发生变化时不进行模型更新,因此能减少不必要的模型更新,提升异常监测性能.文献 [15] 提出了多工况过程的综合监测框架,利用工况聚类、工况展开集成和自适应策略建立单个 PCA 模型,实现工况在线识别和模型自适应更新,以解决多工况过程的异常监测问题.为了监测新颖工况,文献 [51] 提出了一种局部自适应标准化和变分自动编码器双向长短期存储器的新型自适应深度学习方法,使用局部自适应标准化对局部移动窗口数据进行预处理,并训练变分自动编码器双向长短期存储器来检测局部移动窗口中的不稳定偏差.

与传统自适应方法不同,具有持续学习能力的多工况过程异常监测方法可保留以前工况的重要信息,实现当前工况和已学习工况的异常监测.文献 [33] 首次提出了具有持续学习能力的 PCA 方法,采用弹性权重巩固方法衡量参数重要性,选择性地降低对工况敏感参数的变化,以期利用单个模型实现多个工况的同时监测.但该方法要求数据服从多元高斯分布,难以准确计算 Fisher 信息矩阵.为此,文献 [36] 采用突触智能方法估计参数重要性,通过参数对损失函数变化的灵敏性反映参数重要性.为了提高模型可解释性,进一步缓解 PCA 方法在多工况过程的遗忘灾难问题,利用稀疏 PCA 方法建立异常监测模型,借助单个模型实现连续平稳工况监测.

自适应方法不需要完备的工况数据,根据新采集数据不断更新模型参数,实时性强,数据存储成本低.传统自适应方法在提取新特征时,以前工况的重要信息被逐渐覆盖,当相似甚至相同工况再次出现时,算法重新适应系统变化,模型跟踪效率和准确性难以满足实际系统需求.具有持续学习能力的多工况过程异常监测方法,在学习新颖工况特征时保留以前工况的重要知识,有助于快速跟踪相似或相同工况的运行状态.但文献 [33,36] 假设工况具有一定的相似性,若出现差异性显著的工况,异常监测性能将急速下降.

### 3.3 基于混合建模的多工况平稳过程异常监测

基于混合模型的多工况平稳过程异常监测方法,离线阶段通常将数据划分为若干平稳的数据块,利用每个数据块建立平稳过程局部监测模型  $F_1(\mathbf{x}), \dots, F_K(\mathbf{x})$ ,并通过贝叶斯推断为每个局部模型赋予权重,最终获得全局监测结果.如图 5 所示,在线应用阶段,采集样本  $\mathbf{x}$ ,利用  $K$  个局部监测模型计算监测指标,最后借助贝叶斯融合方法计算全局监测结果  $J(\mathbf{x})$ .

文献 [42] 介绍了一种具有共同结构潜在基的混合概率主成分分析方法,可实现多工况平稳过程的异常监测与分离.文献 [72] 提出了一种改进的混合概率主成分分析方法,采用贝叶斯 Ying-Yang 方法确定局部模型数量,通过最大期望方法估计局部模型参数,并依据贝叶斯原理建立全局监测模型,可用于多工况过程异常监测.文献 [71] 利用变分贝叶斯高斯混合模型自动辨识工况,在每个工况内建立局部 CCA 模型,利用贝叶斯融合方法建立全局统计指标,优势是在概率意义上建立模型,具有鲁棒性,适用于多工况平稳系统.文献 [25] 建立有限高斯混合模型 (Gaussian mixture model, GMM),将数据分为若干类,每一聚类认定为一个工况.在缺乏先验信息的情况下,采用 Figueiredo-Jain 算法来自动优化聚类数量和统计参数.为每个工况建立局部模型和局部马氏距离统计量,并根据贝叶斯推断策略计算全局概率指标.同样地,文献 [103] 提出了一种新的基于局部成分的主成分分析方法来监测多工况过程的状态,使用有限 GMM 将过程数据划分为多个局部分量,不需要工况划分的过程先验知

识. 虽然 GMM 通常用于描述过程的多工况特性, 但传统的监测方案依赖于识别过程工况并对每个高斯分量应用单峰统计方法. 然而, 任何给定观测的过程工况通常是未知的, 它可能属于任何过程工况. 文献 [19] 提出了一种基于变分贝叶斯主成分分析和混合模型间 KL 散度的多工况过程异常监测方法, 用 KL 散度测量参考混合模型和监测混合模型之间关于每个过程工况的相异性, 利用贝叶斯推理将统计信息和控制限进行融合, 得到全局监测结果. 文献 [104] 提出了一种新的基于邻域的全局协调框架, 用于模型对齐和多工况过程异常监测, 通过将局部模型对齐到全局模型来涉及工况间的相关性.

基于混合建模方法需要完备的训练数据, 在线应用阶段无须辨识工况. 当新颖工况出现时, 需要采集该工况充分的数据, 重新训练模型参数, 计算量大, 数据存储成本高.

### 3.4 基于多模型建模的多工况平稳过程异常监测

基于多模型建模的多工况平稳过程异常监测方法, 离线阶段训练工况辨识模型, 并为每个平稳工况建立异常监测模型. 如图 6 所示, 在线阶段根据决策函数  $H(\boldsymbol{x})$  判断样本  $\boldsymbol{x}$  隶属的工况, 随后采用相应的异常监测模型判断系统运行状态.

文献 [17] 利用集成移动窗口策略和集成聚类方法辨识工况, 捕捉相应工况的过程模式, 进而建立邻接的多 ICA-PCA 模型. 文献 [13] 提出了一种 PCA 混合模型方法, 采用 GMM 方法辨识工况, 随后在每个工况内建立 PCA 局部异常监测模型. 文献 [105] 假设不同类别有共同的协方差, 采用鲁棒聚类方法, 保存物理变量之间的联系, 在每一类中借助 PCA 方法建立  $T^2$  和 SPE 统计量. 文献 [106] 提出了一种局部保持稀疏建模方法, 用稀疏线性组合表示非线性数据, 依据贝叶斯推断将测试样本分到特定工况, 适用于多工况非高斯过程. 文献 [83] 考虑每个工况的特点和不同工况的连接关系, 提出了一种多流形联合投影方法, 认为一个工况的数据点依赖于一个单独的流形, 利用样本点到流形的距离来判断当前工况, 计算样本到某工况各个样本点的距离和, 取最小距离所在的工况参数计算统计量. 文献 [84] 提出了一种基于局部核密度估计算法, 能在线识别工况, 跟踪工况变化. 文献 [80] 提出了一种基于概率 LDA 的多工况过程异常监测方法, 可实现故障分离并确定故障变量, 但需要工况标签. 为了提高故障监测灵敏度, 文献 [107] 提出了一种基于 KL 散度的多工况过程变量选择算法, 该算法能有效地选择有关故障的信息量最大的变量, 通过一步维特比算法在线识别工况, 并引入移动滑窗技术进一步提高监测性能. 文献 [54] 提出了一种基于分层模式识别策略和叠加去噪自动编码器的方案, 采用高斯混合模型将整个多工况过程划分为多个平稳工况, 随后提出了一种密度峰值聚类算法实现过渡工况识别, 最后利用堆叠去噪自编码器挖掘过程变量的深度非线性特征实现多工况平稳过程异常监测.

基于多模型建模方法需要完备的训练数据, 确定工况数量, 存储所有工况的运行数据. 文献 [11] 指出, 工业系统存在大量相似工况, 导致工况的错误辨识, 监测模型存在冗余. 因此, 多模型方法在实际工业应用中存在一定的局限性.

## 4 多工况非平稳过程异常监测研究现状

在实际工业系统中, 由于负荷变动、环境变化等, 单个工况的数据呈现非平稳特性 [25], 其异常监测研究取得了一定的进展 [76, 108~111]. 常见的单工况非平稳过程异常监测方法包括动态隐变量模型 (dynamic latent variable model, DLVM) [112]、慢特征分析 (slow feature analysis, SFA) [113]、协整分析 (cointegration analysis, CA) [114]、平稳子空间分析 (stationary subspace analysis, SSA) [110, 115] 等, 其核心思想和优缺点见表 4 [35, 37, 56, 81, 109, 111, 114, 116~119]. 结合表 2, 回顾多工况非平稳过程异常监测的研究现状.

表 4 典型的非平稳过程异常监测方法

Table 4 Typical anomaly detection methods for single-mode nonstationary processes

Approach	Technical core	Virtues	Drawbacks	Refs.
DLVM	Dynamic latent variables are extracted to explain the dynamic variations of data to the greatest extent.	The model furnishes excellent interpretability and is applied to nonstationary processes with slow changes.	The autocorrelation of process data is focused, but the cross-correlation between input and output is ignored.	[35,81]
SFA	Slow changing features are extracted from time series data.	It is applied to linear nonstationary processes with slow variations.	High-order dynamics may be ignored.	[56,111,116,117]
CA	It can deal with nonstationary data with long-term equilibrium relationship, and the linear combinations of the data are stationary.	It can mine the long-term dynamic equilibrium relationship of data, and then identify the dynamic changes and anomalies of the system.	Only the same order or even the first order single integer nonstationary data are considered.	[37,114,118,119]
SSA	The data are decomposed into a nonstationary subspace and a stationary subspace.	It can separate the nonstationary signals and stationary signals.	It cannot deal with nonstationary components yet.	[109]

#### 4.1 基于自适应建模的多工况非平稳过程异常监测

传统基于自适应建模的多工况非平稳过程异常监测方法,在线阶段每采集一个或一组正常数据,根据自适应方法思想逐步更新非平稳异常监测模型参数,以适应系统非平稳变化.文献[116]提出了一种递归 SFA (recursive SFA, RSFA) 方法,每采集一个正常样本更新模型参数,实时跟踪系统变化,能同时监测工作点变化和过程动态特性.随后,文献[117]提出了一种递归指数 SFA 方法,将原始数据映射到指数空间并建立自适应 SFA 模型,用于解决非线性问题.文献[109]提出了一种自适应指数 SSA 方法,能够估计平稳信号源.文献[118]提出了一种递归 CA (recursive CA, RCA) 方法,借助一定量的数据更新参数,能区别正常工况变化和真实异常.由于 RCA 方法仅考虑具有协整关系的非平稳数据,忽略其他平稳数据和无规律变化的非平稳数据,它对协整空间的正交子空间出现的异常并不敏感.由于运行工况的频繁变化,部分工况的样本不足以建立准确的模型,在线建模面临着重大挑战.为了解决这一问题,文献[56]提出了一种自适应 JIT-TL-SFA 建模方法,该方法将迁移学习 (transfer learning, TL) 和 SFA 融合到即时 (just-in-time, JIT) 学习中,设计了一种考虑时间相关性和空间相关性的时空相似性度量准则,以提高即时学习的性能.文献[43]提出了一种自适应滑窗 GMM 方法,利用专家知识建立规则库,避免盲目更新模型参数.

另一种自适应方法是具有持续学习能力的多工况非平稳过程异常监测方法,目前正则化方法和数据重放方法已应用于解决单个非平稳异常监测模型在多工况过程的遗忘灾难问题.当工况发生变化时,正则化方法根据新颖工况少量正常数据更新非平稳异常监测模型参数;数据重放方法保留历史工况的少量典型数据或生成伪数据,当新颖工况出现时,利用所有工况的数据提取多工况特征,因此能借助单个模型实现对多个差异显著工况的异常监测.文献[34]考虑每个工况内数据的时序特点,设计了一种新的稀疏动态主成分分析 (sparse dynamic inner PCA, SDiPCA) 方法,适合多工况非平稳过程异常

监测. 针对传统突触智能方法重要性估计不准确和优化问题初始值固定等问题, 提出了改进的突触智能方法, 能够准确估计 SDiPCA 模型参数重要性. 但该方法要求工况之间具有一定的相似性, 不适用于差异性大的连续工况. 为此, 文献 [120] 采用数据重放的思想, 选择并保存历史工况的典型样本. 当新颖工况出现时, 采集一定量的数据, 并与保存的历史数据构成一个数据集, 建立非线性 SDiPCA 模型, 适用于长期非线性非平稳过程的异常监测任务. 文献 [35] 针对上述方法无法处理缺失数据和离群点等问题, 提出了一种具有持续学习能力的概率 SFA 方法, 对噪声和隐变量进行显式建模, 可区别部分的正常工况变化和真实异常. 考虑到上述 3 种方法无法自动识别工况, 文献 [37] 提出了一种自适应无监督的多工况非平稳过程异常监测方法, 结合先验信息、系统机理和数据构建统计量, 能够准确识别正常的工况变化和真实异常. 若系统正常运行, 根据新采集的样本实时更新协整分析和 PCA 模型参数, 适应系统的非平稳变化; 若系统工况发生正常变化, 采集少量数据离线训练模型, 同时借助弹性权重巩固方法解决 RPCA 在多工况过程的遗忘灾难问题.

区别于多工况平稳过程的自适应方法, 上述 RSFA, RCA 等方法提取系统的特征, 如慢特征、协整关系、信号源等, 通过适应特征变化实现多工况非平稳过程异常监测. 传统自适应方法能跟踪特征的缓慢变化, 但难以适应其快速变化. 具有持续学习能力的多工况非平稳异常监测方法, 需要判断工况切换时刻. 但在多工况非平稳过程中, 通常借助先验知识和专家经验识别正常工况变化<sup>[34, 35, 120]</sup>, 仅依赖运行数据难以区别正常工况变化和真实异常.

#### 4.2 基于混合模型的多工况非平稳过程异常监测

基于混合模型的多工况非平稳过程异常监测方法, 离线阶段通常建立多个局部非平稳过程异常监测模型, 借助贝叶斯原理对各局部模型赋予权值, 最终获得全局监测结果. 如图 5 所示, 在线应用阶段计算样本  $\boldsymbol{x}$  在异常监测模型  $F_1(\boldsymbol{x}), \dots, F_K(\boldsymbol{x})$  的结果, 通过线性加权得到全局结果  $J(\boldsymbol{x})$ , 进而判断系统的运行状态.

文献 [111] 通过 SFA 方法实现粗粒度的自动工况划分, 跟踪工况运行特性的变化, 同时采用 GMM 对每个条件工况进行细粒度分布评估, 设计基于贝叶斯推理的距离监测指标区分不同的运行场景. 文献 [108] 利用狄利克雷 (Dirichlet) 过程将数据分为若干类, 随后借助非平稳离散卷积核函数, 建立一个能够解释数据中的任何多工况信息的监测模型. 如果操作员确认新的健康运行工况, 则使用在新颖工况下收集的数据更新异常监测模型. 文献 [16] 提出了一种改进的动态邻域保持嵌入算法, 能够保持数据集的局部邻域结构, 对于单一工况的动力学行为, 考虑了序列相关性, 构建一个全局模型, 不需要先验过程知识. 文献 [10] 利用递归 GMM 方法和递归核 PCA 方法解决工业数据的多工况特性和非平稳特性, 在 GMM 框架下构建一个全局模型. 文献 [121] 考虑过程的非线性, 利用等价空间方法建立每个工况的监测模型, 根据贝叶斯融合得到全局结果. 文献 [119] 针对工况频繁变化的闭环系统, 提出了分布式稀疏协整分析方法, 能区别正常工况变化和真实异常.

基于混合模型的方法需要完备的训练数据, 但实际工业系统的历史数据难以涵盖所有运行工况. 此外, CA 和 SFA 等方法更加关注非平稳数据, 忽略了每个工况内平稳数据, 导致方法对平稳数据带来的异常不敏感.

#### 4.3 基于多模型的多工况非平稳过程异常监测

基于多模型的多工况非平稳过程异常监测方法, 离线阶段通常采用聚类方法、先验信息等划分工况, 随后在每个局部工况内建立非平稳过程监测模型. 如图 6 所示, 在线监测阶段, 通过贝叶斯原理、马尔可夫 (Markov) 模型等确定当前样本所属工况, 进而确定异常监测模型并获取异常监测结果.

文献 [81] 研究工况频繁更换的非平稳过程异常监测问题, 在概率框架下设计了切换自回归 DLVM 模型, 能够有效地提取非平稳过程中数据的自相关性和互相关性, 采用隐马尔可夫模型确定测试样本所属的特定工况. 此外, 文献 [114] 提出了一种基于 CA 和切换方案的高炉非平稳过程异常监测方法, 根据系统的运行状态确定工况是否发生了切换. 在每个工况下, 采用 CA 方法从原始非平稳测量变量中构建平稳特征, 并用 PCA 方法进行异常监测. 文献 [122] 提出了一种多子空间 SFA 方法, 采用邻域相减聚类算法进行工况划分, 在每个工况中建立高斯和非高斯子空间, 并利用 SFA 提取每个高斯子空间和非高斯子空间的静态和动态特征. 在线阶段利用局部异常概率确定在线数据的当前工况, 并根据所建立的异常监测模型得到监测结果. 文献 [26] 提出了一种基于条件独立贝叶斯学习和递推变元统计分析方法, 用于多工况过程中的传感器早期故障检测与隔离问题. 将正交变换应用于测量变量, 以提高不同工况数据下的条件独立程度, 并开发了一个带有窗口切换方案的多递推变元统计分析模型, 借助后验概率识别工况.

基于多模型的多工况非平稳过程异常监测方法为每个工况建立局部模型, 能自动辨识工况. 与基于混合模型的异常监测方法相似, 该类方法需要完备的工况训练数据. 在多工况非平稳过程中, 由于数据经常处于非平稳变化过程, 难以准确划分工况, 进而影响后续局部模型的建立.

## 5 挑战与展望

在过去 20 多年里, 学者们在多工况过程异常监测与故障诊断研究中取得了丰硕的成果, 部分方法在实际工业过程中得到广泛应用. 传统的异常监测方法通常考虑工况处理方式和每个工况内的数据特点, 借鉴机器学习方法建立模型. 多工况过程异常监测研究依然存在一些需要解决的问题, 其中包括以下几个方面:

(1) 闭环反馈下的过程监测. 目前, 大部分的多工况过程异常监测方法都是针对开环系统进行的, 没有考虑闭环反馈控制律下的数据特性变化<sup>[10]</sup>. 受闭环控制影响, 工业过程的运行特性和变量间的相关关系相较于开环系统均会发生变化, 现有的开环系统下异常监测方法无法真正解决实际问题, 需要重新设计符合实际工业特点的监测方法. 文献 [123] 指出, 反馈控制会抑制外部扰动的影响, 当异常扰动处于发展初期幅值较小时, 异常引起的变化会被控制器补偿, 从而影响故障特征的及时发现和提取. 此外, 闭环控制下, 子系统间复杂的耦合关系, 导致故障传播路径复杂、异常表现多变、变量相关性变化等. SFA 和 CA 方法是闭环系统下常用的异常监测方法<sup>[118, 119]</sup>, 通过数据动态特性和静态特性变化反映系统运行状态, 但依然不能解决微小异常和缓变异常监测问题. 由于工业系统普遍存在闭环控制, 闭环系统下多工况过程异常监测问题是一个值得研究的挑战性难题.

(2) 多工况非平稳过程的工况辨识. 在多工况过程异常监测方法中, 准确辨识工况是获得良好监测性能的关键. 在整体建模方法中, 子空间分解方法需要为每个工况建立独特的监测模型. 自适应方法借助工况切换信息, 能够更为准确地更新模型参数. 尤其是具有持续学习能力的多工况过程异常监测方法, 在工况发生变化时, 利用少量新颖工况数据更新模型参数. 多模型方法在训练和在线应用阶段均需要准确识别工况, 仅有混合模型方法无需准确的工况切换信息. 传统的监测方法通常假设工况信息已知, 或者采用聚类方法进行数据划分, 认定每一类数据来源于同一工况. 在多工况非平稳过程中, 变量在不同工况内均呈现非平稳变化趋势, 均值、方差等统计信息随运行过程发生变化, 常见的聚类方法难以区别当前工况的正常变化、工况的切换和真实异常. 现有文献中, SFA 方法能够区别部分的正常工况变化和真实异常, 但容易将阶跃异常和缓变异常误判为正常工况变化<sup>[34, 113]</sup>. CA 方法通过系统是否依然满足长期和短期均衡关系判断运行状态<sup>[118, 119]</sup>, 容易将正常的人工干扰误判为故障.

因此, 融合数据、机理和先验信息是多工况非平稳过程工况辨识的解决方案.

(3) 实际工业应用存在的挑战. 考虑到实际工业系统的非线性、工况内数据的非平稳性、噪声、干扰等引起的不确定性、数据缺失等问题, 学者开展广泛研究并取得显著的理论成果<sup>[12, 35, 37, 42, 63]</sup>. 但理论研究应用到实际工业系统还有诸多挑战. 大规模复杂系统具有变量数量多、变量间耦合关系复杂、数据量庞大、信息密度低等特点, 如何从工业大数据中快速挖掘重要特征依然是过程监测面临的严峻挑战. 此外, 模型可解释性是阻碍实际应用的重要因素之一. 尽管现有方法能够提供良好的监测性能, 大部分情况下很难建立监测模型与实际系统的运行机理间的联系, 无法从系统原理角度解释模型的结构和参数, 导致运维人员难以理解和相信监测结果.

(4) 具有持续学习能力的多工况过程异常监测. 实际工业系统的多工况特性复杂, 包括工况数量多、工况切换频繁、新颖工况不断出现等, 导致部分工况的样本数据有限, 相似工况的辨识准确率低, 难以建立准确可靠的监测模型. 现有的整体建模、混合建模和多模型方法均需要完备的工况数据, 一旦出现新颖工况, 采集该工况充分数据, 利用所有工况的数据重新训练, 数据存储成本高, 计算量大, 影响算法的实时性. 传统自适应方法难以及时跟踪不同工况间的快速变化, 易将正常工况变化误判为异常. 具有持续学习能力的多工况过程异常监测方法假设来自多工况的数据是依次采集的, 通过不断更新模型参数实现连续工况监测<sup>[33~37]</sup>, 在提取当前工况特征时保留已学习的重要知识. 该类方法不需要完备的训练数据, 根据先验信息、系统机理和数据建立单个模型, 符合实际系统的特点和需求. 但现有基于正则化思想的持续学习方法要求不同工况具有一定的相似性, 适用于短期的异常监测任务. 一旦工况差异性大, 需要重新训练模型参数<sup>[68]</sup>. 采用数据重放思想的持续学习方法能够解决工况相似度的限制条件, 它需要保存每个历史工况的典型样本、确定工况切换时刻, 以及采集当前工况的充分数据等, 适用于长期连续工况的异常监测任务. 因此, 具有持续学习能力的多工况过程异常监测方法是具有潜力的发展方向, 无需完备的工况数据, 适应复杂多变的工况场景, 数据存储成本低, 算法实时性强. 同时, 理想的多工况过程异常监测方法具有如下特点: (i) 存储资源是常数, 随着工况源源不断地出现, 数据存储成本依然在一定范围内浮动; (ii) 不需要准确判定工况划分切换时刻, 适用于任何长度的数据流; (iii) 考虑到源源不断的工况数据, 选择性遗忘不重要信息, 为后续工况的重要特征保留一定的空间; (iv) 能够准确识别正常的工况变化和真实异常, 算法的计算成本低, 实时性强.

## 6 结语

本文围绕多工况过程, 总结了近 30 年来的异常监测与故障诊断算法发展现状. 将多工况过程异常监测方法划分为整体建模、自适应建模、混合建模和多模型方法, 并分析了各类方法的基本思想和优缺点. 针对每个工况内数据的平稳和非平稳特性, 将多工况过程细分为多工况平稳过程和多工况非平稳过程, 并结合多工况过程的一般处理方式回顾了其研究现状. 结合实际工业系统的特点, 分析了当前多工况过程异常监测方法面临的挑战及未来发展方向.

## 参考文献

- 1 Zhao C H, Yu W K, Gao F R. Data analytics and condition monitoring methods for nonstationary batch processes—current status and future. *Acta Autom Sin*, 2020, 46: 2072–2091 [赵春晖, 余万科, 高福荣. 非平稳间歇过程数据解析与状态监控——回顾与展望. *自动化学报*, 2020, 46: 2072–2091]
- 2 Fenton W G, McGinnity T M, Maguire L P. Fault diagnosis of electronic systems using intelligent techniques: a review. *IEEE Trans Syst Man Cybern C*, 2001, 31: 269–281



- 3 Rato T, Reis M, Schmitt E, et al. A systematic comparison of PCA-based statistical process monitoring methods for high-dimensional, time-dependent processes. *AIChE J*, 2016, 62: 1478–1493
- 4 Jiang Q C, Yan X F, Huang B. Review and perspectives of data-driven distributed monitoring for industrial plant-wide processes. *Ind Eng Chem Res*, 2019, 58: 12899–12912
- 5 Ji C, Sun W. A review on data-driven process monitoring methods: characterization and mining of industrial data. *Processes*, 2022, 10: 335
- 6 Precup R-E, Angelov P, Costa B S J, et al. An overview on fault diagnosis and nature-inspired optimal control of industrial process applications. *Comput Industry*, 2015, 74: 75–94
- 7 Abid A, Khan M T, Iqbal J. A review on fault detection and diagnosis techniques: basics and beyond. *Artif Intell Rev*, 2021, 54: 3639–3664
- 8 Wang F L, Chang Y Q, Wang S, et al. Multimode complex industrial process monitoring and fault diagnosis. Beijing: Science Press, 2016 [王福利, 常玉清, 王姝, 等. 多模态复杂工业过程监测及故障诊断. 北京: 科学出版社, 2016]
- 9 Zhang K, Peng K X, Dong J. A common and individual feature extraction-based multimode process monitoring method with application to the finishing mill process. *IEEE Trans Ind Inf*, 2018, 14: 4841–4850
- 10 Peng G Z, Huang K K, Wang H W. Dynamic multimode process monitoring using recursive GMM and KPCA in a hot rolling mill process. *Syst Sci Control Eng*, 2021, 9: 592–601
- 11 Huang K K, Wu Y M, Yang C H, et al. Structure dictionary learning-based multimode process monitoring and its application to aluminum electrolysis process. *IEEE Trans Automat Sci Eng*, 2020, 17: 1989–2003
- 12 Quiñones-Grueiro M, Llanes-Santiago O, da Silva Neto A J. Monitoring Multimode Continuous Processes: A Data-Driven Approach. Cham: Springer, 2021. 309
- 13 Xu X Z, Xie L, Wang S Q. Multimode process monitoring with PCA mixture model. *Comput Electrical Eng*, 2014, 40: 2101–2112
- 14 Wang B, Li Z C, Dai Z W, et al. Data-driven mode identification and unsupervised fault detection for nonlinear multimode processes. *IEEE Trans Ind Inf*, 2019, 16: 3651–3661
- 15 Tong C D, Palazoglu A, Yan X F. An adaptive multimode process monitoring strategy based on mode clustering and mode unfolding. *J Process Control*, 2013, 23: 1497–1507
- 16 Song B, Ma Y X, Shi H B. Multimode process monitoring using improved dynamic neighborhood preserving embedding. *Chemometrics Intell Lab Syst*, 2014, 135: 17–30
- 17 Zhu Z B, Song Z H, Palazoglu A. Process pattern construction and multi-mode monitoring. *J Process Control*, 2012, 22: 247–262
- 18 Song B, Yan H C, Shi H B, et al. Multisubspace elastic network for multimode quality-related process monitoring. *IEEE Trans Ind Inf*, 2019, 16: 5874–5883
- 19 Cao Y, Jan N M, Huang B, et al. Multimodal process monitoring based on variational Bayesian PCA and Kullback-Leibler divergence between mixture models. *Chemometrics Intell Lab Syst*, 2021, 210: 104230
- 20 Fang M, Kodamana H, Huang B. Real-time mode diagnosis for processes With multiple operating conditions using switching conditional random fields. *IEEE Trans Ind Electron*, 2019, 67: 5060–5070
- 21 Zhao S J, Zhang J, Xu Y M. Monitoring of processes with multiple operating modes through multiple principle component analysis models. *Ind Eng Chem Res*, 2004, 43: 7025–7035
- 22 Hwang D-H, Han C H. Real-time monitoring for a process with multiple operating modes. *Control Eng Pract*, 1999, 7: 891–902
- 23 Zhu J L, Ge Z Q, Song Z H. Recursive mixture factor analyzer for monitoring multimode time-variant industrial processes. *Ind Eng Chem Res*, 2016, 55: 4549–4561
- 24 Afzal M S, Tan W, Chen T W. Process monitoring for multimodal processes with mode-reachability constraints. *IEEE Trans Ind Electron*, 2017, 64: 4325–4335
- 25 Yu J, Qin S J. Multimode process monitoring with Bayesian inference-based finite Gaussian mixture models. *AIChE J*, 2008, 54: 1811–1829
- 26 Shang J, Zhou D H, Chen M Y, et al. Incipient sensor fault diagnosis in multimode processes using conditionally independent Bayesian learning based recursive transformed component statistical analysis. *J Process Control*, 2019, 77: 7–19
- 27 Liu J L. Fault detection and classification for a process with multiple production grades. *Ind Eng Chem Res*, 2008,

- 47: 8250–8262
- 28 Zhou L, Chen J H, Hou B P, et al. Multi-grade principal component analysis for fault detection with multiple production grades. *Chemometrics Intell Lab Syst*, 2018, 175: 20–29
- 29 Ge Z Q, Song Z H. Multimode process monitoring based on Bayesian method. *J Chemom*, 2009, 23: 636–650
- 30 Wang F L, Tan S, Peng J, et al. Process monitoring based on mode identification for multi-mode process with transitions. *Chemometrics Intel Lab Syst*, 2012, 110: 144–155
- 31 Tan S, Wang F L, Peng J, et al. Multimode process monitoring based on mode identification. *Ind Eng Chem Res*, 2012, 51: 374–388
- 32 Wang Y, Zheng Y, Wang Z, et al. Time-weighted kernel-sparse-representation-based real-time nonlinear multimode process monitoring. *IEEE Trans Ind Inf*, 2022, 18: 2411–2421
- 33 Zhang J X, Zhou D H, Chen M Y. Monitoring multimode processes: a modified PCA algorithm with continual learning ability. *J Process Control*, 2021, 103: 76–86
- 34 Zhang J X, Zhou D H, Chen M Y, et al. Continual learning for multimode dynamic process monitoring with applications to an ultra-supercritical thermal power plant. *IEEE Trans Automat Sci Eng*, 2023, 20: 137–150
- 35 Zhang J X, Zhou D H, Chen M Y, et al. Continual learning-based probabilistic slow feature analysis for multimode dynamic process monitoring. *IEEE Trans Automat Sci Eng*, 2022. doi: 10.1109/TASE.2022.3219125
- 36 Zhang J X, Zhou D H, Chen M Y. Self-learning sparse PCA for multimode process monitoring. *IEEE Trans Ind Inf*, 2023, 19: 29–39
- 37 Zhang J X, Zhou D H, Chen M Y. Adaptive cointegration analysis and modified RPCA with continual learning ability for monitoring multimode nonstationary processes. *IEEE Trans Cybern*, 2023, 53: 4841–4854
- 38 Wang M, Zhou D H, Chen M Y. Adjustable multimode monitoring with hybrid variables and its application in a thermal power plant. *IEEE Trans Ind Inf*, 2023, 19: 1425–1435
- 39 Dong J, Zhang C, Peng K X. A new multimode process monitoring method based on a hierarchical Dirichlet process-hidden semi-Markov model with application to the hot steel strip mill process. *Control Eng Pract*, 2021, 110: 104767
- 40 Tang P, Peng K X, Dong J, et al. Monitoring of nonlinear processes with multiple operating modes through a novel Gaussian mixture variational autoencoder model. *IEEE Access*, 2020, 8: 114487–114500
- 41 Haghani A, Krueger M, Jeansch T, et al. Data-driven multimode fault detection for wind energy conversion systems. *IFAC-Papers OnLine*, 2015, 48: 633–638
- 42 Kodamana H, Raveendran R, Huang B. Mixtures of probabilistic PCA with common structure latent bases for process monitoring. *IEEE Trans Control Syst Technol*, 2019, 27: 838–846
- 43 Xie X, Shi H B. Dynamic multimode process modeling and monitoring using adaptive Gaussian mixture models. *Ind Eng Chem Res*, 2012, 51: 5497–5505
- 44 Huang K K, Wei K, Zhou L F, et al. Multimode process monitoring and mode identification based on multiple dictionary learning. *IEEE Trans Instrum Meas*, 2021, 70: 1–12
- 45 Wang F. Linear chain conditional random field for operating mode identification and multimode process monitoring. *ACS Omega*, 2022, 7: 29483–29494
- 46 Huang K K, Tao S J, Liu Y S, et al. Label propagation dictionary learning based process monitoring method for industrial process with between-mode similarity. *Sci China Inf Sci*, 2022, 65: 110203
- 47 Wang H, Xu J W, Yan R Q. Multi-Scale attention based deep reinforcement learning for intelligent fault diagnosis of planetary gearbox. *J Mech Eng*, 2022, 58: 133–142 [王辉, 徐佳文, 严如强. 基于多尺度注意力深度强化学习网络的行星齿轮箱智能诊断方法. *机械工程学报*, 2022, 58: 133–142]
- 48 Wang H, Xu J, Sun C, et al. Intelligent fault diagnosis for planetary gearbox using time-frequency representation and deep reinforcement learning. *IEEE ASME Trans Mechatron*, 2022, 27: 985–998
- 49 周君. 基于深度强化学习的旋转机械故障诊断方法研究. 硕士学位论文. 重庆: 重庆交通大学, 2020
- 50 Baltrusaitis T, Ahuja C, Morency L-P. Multimodal machine learning: a survey and taxonomy. *IEEE Trans Pattern Anal Mach Intell*, 2019, 41: 423–443
- 51 Wu H, Zhao J S. Self-adaptive deep learning for multimode process monitoring. *Comput Chem Eng*, 2020, 141: 107024
- 52 Wang K, Guo Z Y, Wang Y L, et al. Common and specific deep feature representation for multimode process monitoring using a novel variable-wise weighted parallel network. *Eng Appl Artif Intell*, 2021, 104: 104381

- 53 Yu F, Liu J C, Liu D M. Multimode process monitoring based on modified density Peak clustering and parallel variational autoencoder. *Mathematics*, 2022, 10: 2526
- 54 Gao H, Wei C, Huang W, et al. Multimode process monitoring based on hierarchical mode identification and stacked denoising autoencoder. *Chem Eng Sci*, 2022, 253: 117556
- 55 Lu W P, Yan X F. Deep model based on mode elimination and fisher criterion combined with self-organizing map for visual multimodal chemical process monitoring. *Inf Sci*, 2021, 562: 13–27
- 56 Guo J J, Du W L, Nascu I. Adaptive modeling of fixed-bed reactors with multicycle and multimode characteristics based on transfer learning and just-in-time learning. *Ind Eng Chem Res*, 2020, 59: 6629–6637
- 57 Wu H, Zhao J S. Fault detection and diagnosis based on transfer learning for multimode chemical processes. *Comput Chem Eng*, 2020, 135: 106731
- 58 Huang K K, Wen H F, Zhou C, et al. Transfer dictionary learning method for cross-domain multimode process monitoring and fault isolation. *IEEE Trans Instrum Meas*, 2020, 69: 8713–8724
- 59 Srinivasan R, Viswanathan P, Vedam H, et al. A framework for managing transitions in chemical plants. *Comput Chem Eng*, 2005, 29: 305–322
- 60 Viitasaari L, Ilmonen P. On modeling a class of weakly stationary Processes. *Front Appl Math Stat*, 2020, 5: 68
- 61 Li H, Wang H G, Fan W F. Multimode process fault detection based on local density ratio-weighted support vector data description. *Ind Eng Chem Res*, 2017, 56: 2475–2491
- 62 Song B, Shi H B. Temporal-spatial global locality projections for multimode process monitoring. *IEEE Access*, 2018, 6: 9740–9749
- 63 Zhang K, Peng K X, Zhao S S, et al. A novel common and specific features extraction-based process monitoring approach with application to a hot rolling mill process. *Control Eng Pract*, 2020, 104: 104628
- 64 Wang X, Kruger U, Irwin G W. Process monitoring approach using fast moving window PCA. *Ind Eng Chem Res*, 2005, 44: 5691–5702
- 65 Elshenawy L M, Yin S, Naik A S, et al. Efficient recursive principal component analysis algorithms for process monitoring. *Ind Eng Chem Res*, 2010, 49: 252–259
- 66 Jin H D, Lee Y-H, Lee G, et al. Robust recursive principal component analysis modeling for adaptive monitoring. *Ind Eng Chem Res*, 2006, 45: 696–703
- 67 Lee Y-H, Jin H D, Han C H. On-Line process state classification for adaptive monitoring. *Ind Eng Chem Res*, 2006, 45: 3095–3107
- 68 Hadsell R, Rao D, Rusu A A, et al. Embracing change: continual learning in deep neural networks. *Trends Cogn Sci*, 2020, 24: 1028–1040
- 69 Parisi G I, Kemker R, Part J L, et al. Continual lifelong learning with neural networks: a review. *Neural Networks*, 2019, 113: 54–71
- 70 Delange M, Aljundi R, Masana M, et al. A continual learning survey: defying forgetting in classification tasks. *IEEE Trans Pattern Anal Mach Intell*, 2022, 44: 3366–3385
- 71 Jiang Q C, Yan X F. Multimode process monitoring using variational Bayesian inference and canonical correlation analysis. *IEEE Trans Automat Sci Eng*, 2019, 16: 1814–1824
- 72 Zhang J X, Chen H, Chen S C, et al. An improved mixture of probabilistic PCA for nonlinear data-Driven process monitoring. *IEEE Trans Cybern*, 2019, 49: 198–210
- 73 Wen Q J, Ge Z Q, Song Z H. Multimode dynamic process monitoring based on mixture canonical variate analysis model. *Ind Eng Chem Res*, 2015, 54: 1605–1614
- 74 Thissen U, Swierenga H, de Weijer A P, et al. Multivariate statistical process control using mixture modelling. *J Chemometrics*, 2005, 19: 23–31
- 75 Choi S W, Martin E B, Morris A J, et al. Fault detection based on a maximum-likelihood principal component analysis (PCA) mixture. *Ind Eng Chem Res*, 2005, 44: 2316–2327
- 76 Liu J L, Chen D-S. Nonstationary fault detection and diagnosis for multimode processes. *AIChE J*, 2010, 56: 207–219
- 77 Ma L, Dong J, Peng K X. Root cause diagnosis of quality-related faults in industrial multimode processes using robust Gaussian mixture model and transfer entropy. *Neurocomputing*, 2018, 285: 60–73
- 78 Xu R, Wunsch D. Survey of clustering algorithms. *IEEE Trans Neural Netw*, 2005, 16: 645–678
- 79 Zhao S J, Zhang J, Xu Y M. Performance monitoring of processes with multiple operating modes through multiple

- PLS models. *J Process Control*, 2006, 16: 763–772
- 80 Liu Y, Zeng J S, Bao J, et al. A unified probabilistic monitoring framework for multimode processes based on probabilistic linear discriminant analysis. *IEEE Trans Ind Inf*, 2020, 16: 6291–6300
- 81 Zhou L, Zheng J Q, Ge Z Q, et al. Multimode process monitoring based on switching autoregressive dynamic Latent variable model. *IEEE Trans Ind Electron*, 2018, 65: 8184–8194
- 82 Ha D, Ahmed U, Pyun H, et al. Multi-mode operation of principal component analysis with  $k$ -nearest neighbor algorithm to monitor compressors for liquefied natural gas mixed refrigerant processes. *Comput Chem Eng*, 2017, 106: 96–105
- 83 Xu X, Ding J L, Liu Q, et al. A novel multimanifold joint projections model for multimode process monitoring. *IEEE Trans Ind Inf*, 2021, 17: 5961–5970
- 84 Quiñones-Grueiro M, Prieto-Moreno A, Llanes-Santiago O. Modeling and monitoring for transitions based on local kernel density estimation and process pattern construction. *Ind Eng Chem Res*, 2016, 55: 692–702
- 85 Yin S, Ding S X, Xie X C, et al. A review on basic data-driven approaches for industrial process monitoring. *IEEE Trans Ind Electron*, 2014, 61: 6418–6428
- 86 Sapena-Bano A, Pineda-Sanchez M, Puche-Panadero R, et al. Fault diagnosis of rotating electrical machines in transient regime using a single stator current's FFT. *IEEE Trans Instrum Meas*, 2015, 64: 3137–3146
- 87 Nasir V, Cool J, Sassani F. Intelligent machining monitoring using sound signal processed with the wavelet method and a self-Organizing neural network. *IEEE Robot Autom Lett*, 2019, 4: 3449–3456
- 88 Yang L X, Zhang Z J. A conditional convolutional autoencoder-based method for monitoring wind turbine blade breakages. *IEEE Trans Ind Inf*, 2021, 17: 6390–6398
- 89 Jiang Q C, Yan S F, Cheng H, et al. Local-global modeling and distributed computing framework for nonlinear plant-wide process monitoring with industrial big data. *IEEE Trans Neural Netw Learn Syst*, 2021, 32: 3355–3365
- 90 Kano M, Hasebe S, Hashimoto I, et al. A new multivariate statistical process monitoring method using principal component analysis. *Comput Chem Eng*, 2001, 25: 1103–1113
- 91 Cho J-H, Lee J-M, Choi S W, et al. Fault identification for process monitoring using kernel principal component analysis. *Chem Eng Sci*, 2005, 60: 279–288
- 92 Li G, Qin S J, Zhou D H. Geometric properties of partial least squares for process monitoring. *Automatica*, 2010, 46: 204–210
- 93 Si Y B, Wang Y Q, Zhou D H. Key-performance-indicator-related process monitoring based on improved kernel partial least Squares. *IEEE Trans Ind Electron*, 2021, 68: 2626–2636
- 94 Zhu J L, Ge Z Q, Song Z H. Non-Gaussian industrial process monitoring with probabilistic independent component analysis. *IEEE Trans Automat Sci Eng*, 2017, 14: 1309–1319
- 95 Bazdar A, Kazemzadeh R B, Niaki S T A. Fault diagnosis within multistage machining processes using linear discriminant analysis: a case study in automotive industry. *Qual Technol Quantitative Manage*, 2017, 14: 129–141
- 96 Zheng Y, Qin S J, Chai T Y. Fault detection of multimode processes using concurrent projection to latent structures. *IFAC-PapersOnLine*, 2016, 49: 705–710
- 97 Liu Y, Zeng J S, Xie L, et al. Multimode process monitoring based on modified probabilistic linear discriminant analysis. In: *Proceedings of the 8th Data Driven Control and Learning Systems Conference (DDCLS)*, 2019. 604–609
- 98 Chen Z W, Liu C, Ding S X, et al. A just-in-time-learning-aided canonical correlation analysis method for multimode process monitoring and fault detection. *IEEE Trans Ind Electron*, 2020, 68: 5259–5270
- 99 Ha U, Kim C, Lee Y, et al. A multimodal stress monitoring system with canonical correlation analysis, In: *Proceedings of the 37th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2015. 1263–1266
- 100 Du W L, Tian Y, Qian F. Monitoring for onlinear multiple modes process based on LL-SVDD-MRDA. *IEEE Trans Automat Sci Eng*, 2014, 11: 1133–1148
- 101 Wang G Z, Liu J C, Zhang Y W, et al. A novel multi-mode data processing method and its application in industrial process monitoring. *J Chemometrics*, 2015, 29: 126–138
- 102 Zhao C H, Wang W, Qin Y, et al. Comprehensive subspace decomposition with analysis of between-mode relative changes for multimode process monitoring. *Ind Eng Chem Res*, 2015, 54: 3154–3166

- 103 Li Y, Yang D S. Local component based principal component analysis model for multimode process monitoring. *Chin J Chem Eng*, 2021, 34: 116–124
- 104 Ma Y X, Song B, Shi H B, et al. Neighborhood based global coordination for multimode process monitoring. *Chemometrics Intell Lab Syst*, 2014, 139: 84–96
- 105 Maestri M, Farall A, Groisman P, et al. A robust clustering method for detection of abnormal situations in a process with multiple steady-state operation modes. *Comput Chem Eng*, 2010, 34: 223–231
- 106 Peng X, Tang Y, Du W L, et al. Multimode process monitoring and fault detection: a sparse modeling and dictionary learning method. *IEEE Trans Ind Electron*, 2017, 64: 4866–4875
- 107 Wu D H, Zhou D H, Zhang J X, et al. Multimode process monitoring based on fault dependent variable selection and moving window-negative log likelihood probability. *Comput Chem Eng*, 2020, 136: 106787
- 108 Tan R M, Cong T, Ottewill J R, et al. An on-line framework for monitoring nonlinear processes with multiple operating modes. *J Process Control*, 2020, 89: 119–130
- 109 Chen J H, Zhao C H. Exponential stationary subspace analysis for stationary feature analytics and adaptive nonstationary process monitoring. *IEEE Trans Ind Inf*, 2021, 17: 8345–8356
- 110 Wu D H, Sheng L, Zhou D H, et al. Dynamic stationary subspace analysis for monitoring nonstationary dynamic processes. *Ind Eng Chem Res*, 2020, 59: 20787–20797
- 111 Zhao C H, Chen J H, Jing H. Condition-driven data analytics and monitoring for wide-range nonstationary and transient continuous processes. *IEEE Trans Automat Sci Eng*, 2021, 18: 1563–1574
- 112 Qin S J, Dong Y N, Zhu Q Q, et al. Bridging systems theory and data science: a unifying review of dynamic latent variable analytics and process monitoring. *Annu Rev Control*, 2020, 50: 29–48
- 113 Shang C, Yang F, Gao X Q, et al. Concurrent monitoring of operating condition deviations and process dynamics anomalies with slow feature analysis. *AIChE J*, 2015, 61: 3666–3682
- 114 Jia C, An C, Su W. Nonstationary process monitoring based on cointegration analysis with a switching scheme. In: *Proceedings of 2020 Chinese Automation Congress (CAC)*, 2020. 6984–6988
- 115 Wu D H, Zhou D H, Chen M Y. Probabilistic stationary subspace analysis for monitoring nonstationary industrial processes with uncertainty. *IEEE Trans Ind Inf*, 2022, 18: 3114–3125
- 116 Shang C, Yang F, Huang B, et al. Recursive slow feature analysis for adaptive monitoring of industrial processes. *IEEE Trans Ind Electron*, 2018, 65: 8895–8905
- 117 Yu W K, Zhao C H. Recursive exponential slow feature analysis for fine-scale adaptive processes monitoring with comprehensive operation status identification. *IEEE Trans Ind Inf*, 2019, 15: 3311–3323
- 118 Yu W K, Zhao C H, Huang B. Recursive cointegration analytics for adaptive monitoring of nonstationary industrial processes with both static and dynamic variations. *J Process Control*, 2020, 92: 319–332
- 119 Zhao C H, Sun H. Dynamic distributed monitoring strategy for large-scale nonstationary processes subject to frequently varying conditions under closed-loop control. *IEEE Trans Ind Electron*, 2019, 66: 4749–4758
- 120 Zhang J X, Chen M Y, Hong X. Monitoring multimode nonlinear dynamic processes: an efficient sparse dynamic approach with continual learning ability. *IEEE Trans Ind Inf*, 2023, 19: 8029–8038
- 121 Haghani A, Jeansch T, Ding S X. Quality-related fault detection in industrial multimode dynamic processes. *IEEE Trans Ind Electron*, 2014, 61: 6446–6453
- 122 Xu H, Yu H Q. Anomaly detection method for multimode complex industrial process based on multiple subspaces slow feature analysis. *IEEE Access*, 2021, 9: 119722–119734
- 123 Zhou D H, Liu Y, He X, et al. Review on fault diagnosis techniques for closed-loop systems. *Acta Autom Sin*, 2013, 39: 1933–1943

## Data-driven anomaly monitoring methods for multimode processes: overview and perspectives

Jingxin ZHANG<sup>1</sup>, Donghua ZHOU<sup>2,3\*</sup>, Maoyin CHEN<sup>3</sup> & Dehao WU<sup>4</sup>

1. *College of Automation, Key Laboratory of Measurement and Control of Complex Systems of Engineering, Ministry of Education, Southeast University, Nanjing 210096, China;*

2. *College of Electrical Engineering and Automation, Shandong University of Science and Technology, Qingdao 266000, China;*

3. *Department of Automation, Tsinghua University, Beijing 100018, China;*

4. *College of Automation, Central South University, Changsha 410083, China*

\* Corresponding author. E-mail: zdh@mail.tsinghua.edu.cn

**Abstract** Industrial processes usually need to function under multiple conditions because of changes in raw materials, setting points, and the external environment. Anomaly monitoring methods for multimode processes effectively ensure the safe operation of industrial systems, and they are a research hotspot of current process monitoring technology. Herein, anomaly monitoring methods for multimode processes are summarized, including overall modeling, adaptive modeling, hybrid modeling, and multi-model modeling methods. Research progress of multimode stationary processes and multimode nonstationary processes is then reviewed, and the advantages and disadvantages of these methods are analyzed. Finally, considering the characteristics of the practical industrial systems, the open problems in this field and the future development direction are summarized.

**Keywords** data-driven, multimode processes, anomaly monitoring, stationary processes, nonstationary processes, fault detection