

基于静-动态特性协同感知的复杂工业过程运行状态评价

褚 菲^{1,2} 许 杨^{1,2} 尚 超³ 王福利⁴ 高福荣⁵ 马小平¹

摘 要 针对当前过程监测和运行状态评价方法等对工况信息感知不全面、漏报和误报现象严重等问题, 在深入研究工业现场数据静-动态特性协同感知方法的基础上, 提出关键性能指标 (Key performance indicators, KPI) 驱动的慢特征分析 (Slow feature analysis, SFA) 算法. 将关键性能指标信息融入到慢特征分析中, 协同感知复杂工业过程的静-动态特性变化, 并进一步通过计算潜变量之间的相似度及其一阶差分间的相似度实现对过程稳态和过渡的评价. 在此基础上, 建立基于静-动态特性协同感知的过程运行状态评价统一框架. 针对非优状态, 提出基于稀疏学习的非优因素识别方法, 实现对非优因素变量的准确识别. 最后, 通过重介质选煤过程实际生产数据和田纳西-伊斯曼 (Tennessee Eastman, TE) 过程数据验证了该方法的有效性.

关键词 复杂工业过程, 运行状态评价, 静-动态特性协同, 慢特征分析, 稀疏学习

引用格式 褚菲, 许杨, 尚超, 王福利, 高福荣, 马小平. 基于静-动态特性协同感知的复杂工业过程运行状态评价. 自动化学报, 2023, 49(8): 1621–1634

DOI 10.16383/j.aas.c201035

Evaluation of Complex Industrial Process Operating State Based on Static-dynamic Cooperative Perception

CHU Fei^{1,2} XU Yang^{1,2} SHANG Chao³ WANG Fu-Li⁴ GAO Fu-Rong⁵ MA Xiao-Ping¹

Abstract Current process monitoring and operation performance evaluation methods suffer from inadequate capturing of process information as well as severe missed and false alarms. By performing in-depth analysis of methods for concurrent monitoring static-dynamic characteristic of industrial data, this paper proposes a key performance indicators (KPI)-driven slow feature analysis (SFA) algorithm. It integrates KPI information into SFA model in order to concurrently capture static-dynamic characteristic changes of complex industrial processes. The similarity between latent variables and that between first-order differences are computed to evaluate the optimality of static and transitional operations. On this basis, a unified framework for process operation performance assessment is established based on an integrated perception of static-dynamic characteristics. A sparse learning-based non-optimal factor identification method is proposed to effectively highlight root-cause variables that cause unsatisfactory performance. The feasibility and effectiveness of the proposed method are validated based on data collected from a real-world dense medium coal preparation process and the Tennessee Eastman (TE) process.

Key words Complex industrial process, operation performance assessment, static-dynamic cooperative, slow feature analysis (SFA), sparse learning

Citation Chu Fei, Xu Yang, Shang Chao, Wang Fu-Li, Gao Fu-Rong, Ma Xiao-Ping. Evaluation of complex industrial process operating state based on static-dynamic cooperative perception. *Acta Automatica Sinica*, 2023, 49(8): 1621–1634

收稿日期 2020-12-14 录用日期 2021-06-06

Manuscript received December 14, 2020; accepted June 6, 2021
国家自然科学基金 (61973304, 62003187, 62073060, 61873049),
江苏省科技计划项目 (BK20191339), 江苏省六大人才高峰项目
(DZXX-045), 徐州市科技创新计划项目 (KC19055), 矿冶过程自动
控制技术国家重点实验室开放课题 (BGRIMM-KZSKL-2019-10)
资助

Supported by National Natural Science Foundation of China
(61973304, 62003187, 62073060, 61873049), Jiangsu Science and
Technology Plan Project (BK20191339), Six Talent Peak
Projects of Jiangsu Province (DZXX-045), Science and Techno-
logy Innovation Plan Project of Xuzhou (KC19055), and Open
Foundation of State Key Laboratory of Process Automation in
Mining and Metallurgy (BGRIMM-KZSKL-2019-10)

本文责任编辑 谢永芳

Recommended by Associate Editor XIE Yong-Fang

1. 中国矿业大学信息与控制工程学院 徐州 221116 2. 中国矿
业大学地下空间智能控制教育部工程研究中心 徐州 221116 3. 清
华大学自动化系 北京 100084 4. 东北大学信息科学与工程学院
沈阳 110819 5. 香港科技大学化工系 香港 999077

1. School of Information and Control Engineering, China Uni-
versity of Mining and Technology, Xuzhou 221116 2. Under-
ground Space Intelligent Control Engineering Research Center of
the Ministry of Education, China University of Mining and Tech-
nology, Xuzhou 221116 3. Department of Automation,
Tsinghua University, Beijing 100084 4. College of Information
Science and Engineering, Northeastern University, Shenyang
110819 5. Department of Chemical Engineering, Hong Kong
University of Science and Technology, Hong Kong 999077

为保障生产安全和产品质量,实现综合经济效益最大化,过程监控一直是工业领域关注的热点问题.目前,过程监控技术已成功应用于矿物加工、冶金、石化等重要工业制造过程,并取得了一定的经济效益^[1-2].然而,传统过程监测技术仅关注异常工况的发生,在未出现显著异常状况时,由于过程存在扰动和不确定性,导致非优乃至较差运行状态频发.特别在中国矿产加工、冶金等典型原材料加工工业中,尚存在原材料变化频繁、运行环境复杂恶劣、工况波动剧烈、设备运行状态不佳、产品质量和工艺参数无法实时全面检测,导致生产过程非优状态频发,运行控制效果难以满足实际生产要求^[3-5].

近年来兴起的过程运行状态评价方法对保障复杂工业过程安全高效运行、提高企业综合经济效益具有重要意义^[6-11],相关研究成果不断涌现.例如文献[6]提出一种面向多模式工业过程操作安全性和最优性评价的概率框架,利用高斯混合模型表征多种模式,构建安全性和最优性指标,并将其划分为不同的稳态等级进行评估.然而,对于非最佳的运行状态,该方法仅能进行定性分析,无法实现定量分析.文献[7]提出一种基于Fisher判别分析的过程运行状态在线评价方法,通过计算数据间相似度将未知状态样本划分至相似状态,有效减小数据间差异,提高运行状态识别准确率;然而,该方法未能提取与综合经济性能指标相关的信息,无法进一步识别非优因素.文献[8]基于构建的软测量模型,提出一种关键指标协调优化方法,实现了生产过程的优化运行.文献[9]提出一种基于综合经济指标相似度的在线运行状态评价方法,将全潜结构投影法应用于过程运行状态评价.通过进一步分解偏最小二乘法(Partial least squares, PLS)子空间和残差空间中的变化,有效提取与综合经济指标相关的信息,据此将数据分为不同的稳态等级,进而实现在线评价.文献[10]提出一种针对非高斯过程的运行最优性评估及非最优因素识别策略,利用生产过程过渡阶段信息实现在线评估,并结合各操作量贡献率识别非优因素^[11].文献[12]提出一种全潜鲁棒偏 M 估计的最优状态鲁棒评价方法,通过对样本数据进行加权,消除离群点影响,提高算法在低质量工业数据建模中的鲁棒性.

然而,由于实际生产装置存在明显动态变化和反馈调节作用,过程测量值具有显著时序相关性,呈现出典型的多维时间序列特点.单一的静态特性分析往往无法全面感知工况特性,导致模型泛化能力不足、误报与漏报问题严重^[13-15].为此,学者们提出了各类过程动态统计建模方法,例如动态PLS^[16]、多尺度主元分析^[17]、状态空间方程^[18]等.然而,这些

方法均无法清晰区分过程动态信息与稳态信息,因而对动态异常不敏感.慢特征分析(Slow feature analysis, SFA)算法是一种有效的能从多维时间序列数据中提取动态信息的无监督学习方法. SFA的潜变量具有缓慢变化的特点,有效从多维时序数据中抽取过程内在动态变化规律.文献[13]基于SFA对潜变量 s 的稳态分布 $P(s)$ 与 $\dot{s}$ 的动态分布 $P(\dot{s})$ 分别进行统计建模,利用稳态分布 $P(s)$ 描述过程变量的静态特性,利用 $P(\dot{s})$ 描述过程动态特性,赋予监控统计量不同物理含义,提供更全面的监控信息.此外, SFA与现代控制理论存在着深刻联系,因而,近年来在过程数据解析中得到了广泛应用^[19-20].文献[21]结合典型变量分析与慢特征分析,实现过程静态和动态特征的充分提取,进而实现过程运行状态的有效监控.文献[22]考虑闭环控制下过程动态特征提取,实现对不同操作状态的精细识别.文献[23]通过慢特征分析提取动态信息,提出了动静协同的随机森林法,实现过程故障精准分类.

在实际生产过程中,经验丰富的工程人员对过程运行状态的定性评价可归结为某种抽象的、蕴含深层次运行状态信息的关键性能指标(Key performance indicator, KPI),用来统一表征大型复杂工业过程中决策者最为关心的重要指标,这与温度、压力、流量、液位等传统参数共同构成了多源、多率过程数据.然而, KPI本质上描述了低水平技术/组件的性能与高水平生产质量、生产效率、能源和原材料消耗等之间的定量关系^[24-25],而这类信息通常难以在线实时获取,特别是运行状态评价信息需要有经验的操作人员进行事后分析得到.一个可行的思路是基于历史数据建立运行状态评价结果与快采过程变量之间的数学模型,实现KPI的实时预报,从而对过程运行状态进行在线评价.例如文献[26]通过引入性能指标对SFA的动态信息进行分解的方法,实现过程性能指标的有效监控.

为此,本文提出一种新的KPI驱动的SFA模型(KPI-driven SFA),通过对过程静-动态特性进行协同感知,实现了对运行状态评价信息的有效利用.在此基础上,建立了新的复杂工业过程运行状态评价框架. SFA本身是一种无监督学习算法,本文在SFA优化目标的基础上,进一步挖掘潜变量和KPI之间的相关关系,将运行状态评价信息有效融入到慢特征中,在协同感知过程静-动态特性信息的同时,显著提高慢特征与KPI之间的相关性.通过计算潜变量 t 及其一阶差分 $\dot{t}$ 之间的相似度,从稳态和动态的不同角度对过程运行状态进行精细描述,加深工程人员对过程运行状态的认知与理解.

在监测到非优状态后, 操作人员最为关心的问题在于如何有效识别导致运行状态非优的关键变量. 传统识别方法主要基于贡献图技术, 在变量维数高、采样噪声及干扰显著时, 存在识别准确率低等不足. 本文在运行状态评价方法基础上, 进一步提出一种基于组套索的非优因素识别方法, 消除无关变量影响, 实现对非优因素变量的准确识别, 为工程人员进行针对性调整与维护, 提供有益的指导信息.

本文主要贡献如下: 1) 采用 KPI-driven SFA 算法, 实现对过程静-动态特性的感知, 通过对过程内在本质特性的提取, 能有效减少过程噪声等过程不确定性影响, 相比于一般运行状态评价方法, 本文方法能有效减少误报和漏报问题; 2) 提出基于静-动态特性协同感知的运行状态评价统一框架, 在过程静-动态特性感知的基础上, 设计过程动态特性指标, 与静态指标协同分析, 对过程状态精确评价的同时实现对过程状态变化方向的识别; 3) 提出基于稀疏学习的非优因素识别方法, 从原始过程变量中获取具有组稀疏性的非优因素变量, 通过组套索对某个变量在过去一段时间内的总体贡献施加惩罚, 迫使无关变量的整体贡献率趋近于零, 从而实现对非优因素变量的准确识别和定位.

1 基于静-动态特性协同感知的运行状态评价方法框架

基于静-动态特性协同感知的运行状态评价方法由离线建模、在线评价和非优因素识别 3 个步骤组成.

针对传统方法无法全面感知工况信息的局限, 本文提出 KPI-driven SFA 离线建模算法, 对建模数据静-动态信息进行协同提取, 并根据与经济指标的相关度对特征空间进行分解, 分离出与经济指标直接相关的特征空间, 并计算隐变量样本的一阶差分, 建立运行状态离线评价模型. 在此基础上, 提出基于静-动态特性协同感知的在线评价方法, 有效应对了当前运行状态评价方法难以全面解析过程静-动态特性的问题. 通过制定有效评价规则, 依据静态评价指标大小, 实现过程运行状态的在线识别; 依据动态评价指标大小, 实现过程运行状态变化趋势在线识别, 完成对各个状态和过渡过程的综合评价. 针对非优因素识别容易将其他非关键变量错误识别出来的问题, 本文提出基于稀疏学习的非优因素识别, 通过组套索技术惩罚某个变量在过去一段时间的总体贡献, 迫使无关变量整体贡献率近似为零, 基于组贡献率 (Group-wise contribution, GWC)

大小, 有效识别非优因素变量.

1.1 基于 KPI-driven SFA 的运行状态离线评价模型

假设存在 m 个过程变量, X 为由 m 维输入向量组成的数据矩阵, Y 为过程 KPI 指标向量. 过程运行状态评价通常可分为不同等级. 不失一般性, 假设状态评价分为 {优, 良, 中} 3 个等级, 此时可利用标量数值 {1, 2, 3} 来分别表示不同状态评价结果, 以此构成 KPI 指标向量 Y .

SFA 是一种无监督学习方法, 通过解决以下优化问题, 将 X 映射至低维空间, 得到若干个互不相关的慢特征:

$$\min_{g_j} \langle \dot{s}_j^2(t) \rangle_t \quad (1)$$

需要满足的约束如下:

$$\langle s_j^2(t) \rangle_t = 1 \quad (2)$$

$$\langle s_j(t) \rangle_t = 0 \quad (3)$$

$$\forall i \neq j, \langle s_i(t)s_j(t) \rangle_t = 0 \quad (4)$$

对于离散时间信号, $\dot{s}_j(t) = s_j(t) - s_j(t-1)$ 表示其差分, $\langle \cdot \rangle_t$ 表示对时间的期望. 约束 (2) 和约束 (3) 要求特征具有零均值和单位协方差, 而约束 (4) 确保特征之间不会包含重复信息. 若 $g_j(\cdot)$ 为线性映射 $g_j(x) := w_j^T x$ 且仅求取变化最缓慢的特征, 上述优化问题可近似地描述为如下问题:

$$\begin{aligned} \min_w \quad & w^T \Delta X^T \Delta X w \\ \text{s.t.} \quad & w^T w = 1 \end{aligned} \quad (5)$$

式中, ΔX 是由输入一阶差分 $\dot{x}(t)$ 构成的矩阵. 为解决潜变量与产品质量指标无关的局限性, 文献 [27] 提出一种与质量相关的监督学习方法. 在此基础上, 本文提出一种适用范围更广、由关键性能指标驱动的慢特征分析方法即 KPI-driven SFA, 抽取具有慢变化特点且与 KPI 紧密相关的潜变量. 其优化问题如下:

$$\begin{aligned} \max_w \quad & w^T X^T Y Y^T X w - \alpha w^T \Delta X^T \Delta X w \\ \text{s.t.} \quad & w^T w = 1 \end{aligned} \quad (6)$$

式中, 目标函数的第 1 项旨在最大化潜变量向量 $S = Xw$ 和 KPI 指标向量 Y 之间的协方差, 实现慢特征与 KPI 之间具有显著互相关性, 第 2 项是 SFA 的原始目标. $\alpha > 0$ 为正则化惩罚因子, 在两个目标间取得适当权衡, 使慢特征能同时描述过程变量 X 和 KPI 中的信息. α 的合理取值存在上界, 随着 α 取值不断增大, 目标函数中的二次项权值矩阵

$X^T Y Y^T X - \alpha \Delta X^T \Delta X$ 终将不再正定, 导致预测误差开始增加, 并且产生振荡^[27].

为方便优化问题求解, 本文在非线性迭代偏最小二乘算法^[28]基础上进行改进, 得到问题 (5) 的最优解, 其基本步骤见算法 1.

算法 1. KPI-driven SFA 算法

输入. 训练样本 X 、 ΔX 、 Y .

输出. 回归系数矩阵 R , 得分向量 t .

1) 随机选取 Y_a 的一列作为初始 u_a , ΔX_a 的一列作为初始 r_a ;

2) 计算投影方向 w_0 :

$$w_0 = \frac{1}{u_a' u_a} X_a' u_a - \frac{\alpha}{r_a' r_a} \Delta X_a' r_a$$

3) 得到标准化的向量 w_a :

$$w_a = \frac{w_0}{\sqrt{w_0' w_0}}$$

4) 将 X_a 投影到 w_a , 得到 X_a 的得分即慢特征; 将 ΔX_a 投影到 w_a , 得到 ΔX_a 的得分:

$$s_a = X_a w_a$$

$$r_a = \Delta X_a w_a$$

5) 剩余步骤与传统的非线性迭代偏最小二乘算法相同.

利用 KPI-driven SFA 得到的慢特征 $s(t)$ 涵盖了过程数据中的静-动态信息. 当 KPI 指标来自运行状态评价结果时, $s(t)$ 同时包含了过程运行状态评价信息, 在此基础上能够实现运行状态的准确评价. 基于各个不同状态等级下的过程数据, 计算其对应的慢特征 s , 并对其求一阶差分 $\dot{s}$ 用以描述过程动态特性变化, 进而实现过程静-动态特性协同感知.

1.2 基于静-动态特性协同感知的运行状态在线评价方法

在对过程运行状态进行在线评价时, 首先利用滑窗长度为 H 的在线数据, 计算其潜变量 s 与各个状态等级下潜变量 s 的中心距离:

$$d_k^c = \left\| \frac{1}{H} \sum_{h=k-H+1}^k s(h) - \frac{1}{N^c} \sum_{n=1}^{N^c} s_n^c \right\|^2 \quad (7)$$

以及潜变量一阶差分 $\dot{s}$ 之间的中心距离:

$$\dot{d}_k^c = \left\| \frac{1}{H} \left(\sum_{h=k-H+1}^k \dot{s}(h) + E \right) - \frac{1}{N} \sum_{n=1}^N \dot{s}_n^c \right\|^2 \quad (8)$$

式 (7)、式 (8) 中, s_n^c 表示在稳态运行状态 c 下采集得到的 N^c 个潜变量样本, $\dot{s}_n^c$ 表示其对应的一阶差分样本. d_k^c 表示当前过程运行状态与运行状态 c

之间的相似度, $\dot{d}_k^c$ 表示在不同运行状态之间进行过渡的趋势. E 为偏置量, 以体现趋势方向. 若当前变化趋势与向量 E 相反, 则 $\dot{d}_k^c$ 值较小. 图 1 为基于静-动态特性协同感知的复杂工业过程运行状态在线评价流程图.




图 1 基于静-动态特性协同感知的复杂工业过程运行状态在线评价流程图

Fig.1 Flow chart of online evaluation of the operating status of complex industrial processes based on static-dynamic cooperative perception

1.3 基于稀疏学习的非优因素识别

现有的非优因素识别方法以静态变量贡献分析为基础, 仅考虑了在当前采样时刻导致非优运行状态的过程变量. 然而, 由于复杂工业过程通常干扰大、噪声强、变量耦合严重, 传统的静态识别方法易受干扰和噪声的影响, 常常会将其他非关键变量识别为非优因素, 采集得到的工业数据质量普遍偏低, 误导工程人员的操作决策^[29-33]. 为此, 本文提出一种新的基于稀疏学习的非优因素变量识别方法. 非优的过程运行状态往往由少数变量引起, 因此非优变

量呈现出一定稀疏性, 其识别在某种意义上可视为稀疏学习问题, 其中最为常用的技术是套索正则化技术. 然而, 在线应用时, 常使用滑动窗方法增强信噪比、降低噪声扰动对评价结果的影响, 窗口中不仅包含当前时刻的采样数据, 还包括若干个历史采样点. 此时, 模型的不同输入变量形成了若干组, 每组对应滑窗内某个变量的所有样本. 因此, 非优变量呈现出典型的组稀疏性, 套索正则化方法无法得到具有组稀疏性的估计值. 为此, 本文采用文献 [34] 提出的基于组套索正则化的故障诊断方法, 通过组套索惩罚某个变量在滑窗内的总体贡献, 迫使无关变量的整体贡献率趋近于零, 从原始过程变量中恢复得到具有组稀疏性的非优因素变量. 首先, 将相似度 d_k^c 表示为二次型形式 $\text{Index}(x) = x^T M x$, 通过极小化 d_k^c 并利用组套索, 对某个变量在滑动窗内的总体贡献进行正则化惩罚, 根据组贡献识别导致过程状态发生变化的非优变量粗略位置, 之后观察变量贡献率确定非优变量.

基于组套索正则化的思想, 所有过程变量按照时间可以分为 m 个不同的组:

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_m \end{bmatrix} \quad (9)$$

式中, 每组向量 x_k 的维度等于滑动窗口长度 H . 非优变量识别问题转化为以下的无约束优化问题:

$$\min_f (x - f)^T M (x - f) + \lambda \sum_{k=1}^m \sqrt{H} \|f_k\|_2 \quad (10)$$

式中, 组套索惩罚项 $\sum_{k=1}^m \sqrt{H} \|f_k\|_2$ 迫使解在组层面具有稀疏性. 正则化因子 $\lambda > 0$ 用来平衡两个不同目标, 若 λ 过大, 则迫使所有变量的贡献都近似为零; 若 λ 太小, 使得 $f \rightarrow x$ 导致辨识结果失去意义. 因此, λ 的选择对非优变量识别结果具有显著影响. 一个可行的思路是, 基于一个有限的单调序列 $\{\lambda_1^* > \lambda_2^* > \dots > \lambda_J^*\}$ 选取 λ , 并且保证每个 λ^* 对应不同的组稀疏性; 若 f 估计得当, 则重构变量 $x^* = x - f$ 与最优状态具有较高的相似度 d_k^c , 因此 λ 的取值可按照如下准则确定 [34]:

$$\max_{j=1, \dots, J} \lambda_j^* \quad \text{s.t.} \quad \text{Index}(x^*) = (x - f)^T M (x - f) < \gamma_M \quad (11)$$

式中, γ_M 为在最优操作条件下二次型指标 $\text{Index}(x)$ 的控制限. 由于二次型指标 $\text{Index}(x^*)$ 服从自由度为 M 的卡方分布, 因此若 λ 取值合适, 统计量会落入控制限内, 这表明非优变量因素识别基本正确,

在对输入变量进行重构后, 数据分布接近最优操作工况.

通过求解式 (10) 中的正则化最小二乘问题 [35], 能够得到简明、清晰、复杂度低的识别结果, 同时增强结果的可解释性. 其中组贡献率定义如下:

$$\text{GWC}_k = \|f_k\| \quad (12)$$

式中, 无关变量的组贡献率往往为零, 因此可以通过观察各个组贡献率确定非优变量. 图 2 给出了基于稀疏学习的非优因素识别算法步骤.




图 2 基于稀疏学习的非优因素识别流程图

Fig. 2 Traceability flowchart of non-optimal factors based on sparse learning

综上, 基于静-动特性协同感知的复杂工业过程运行状态评价的具体步骤如下:

步骤 1. 假设历史数据 (x, y) , 并且已知其中数据 (x_c, y_c) 对应的状态等级 c ;

步骤 2. 对 X 和 Y 标准化后, 构建算法模型, 求解目标函数 (6):

$$S = RX \quad (13)$$

$$R = W(P^T W)^{-1} \quad (14)$$

步骤 3. 计算综合 KPI 指标 $R(i)$:

$$R(i) = \frac{s_i^T y}{\sqrt{\text{var}(s_i)} \sqrt{\text{var}(y)}} \quad (15)$$

步骤 4. 依据指标 $R(i)$ 对 R 中与质量无关的特征进行剔除, 得到 R_q ;

步骤 5. 计算各个状态的得分向量:

$$t_c = R_q x_c \quad (16)$$

步骤 6. 对各个状态得分向量进行时序增广, 计

算各个状态得分向量的一阶差分, 得到 $\dot{t}_c$;

步骤 7. 构造时刻 K 的滑动数据窗口, 构建时序增广矩阵后进行标准化;

步骤 8. 计算在线数据中的得分向量:

$$t_{on,q} = R_q x_{on} \quad (17)$$

步骤 9. 对在线数据得分向量进行时序增广, 计算在线数据得分向量的一阶差分, 得到 $\dot{t}_{on,q}$;

步骤 10. 根据式 (7) 计算的得分向量与各个状态等级的中心距离;

步骤 11. 根据式 (8) 计算的得分向量一阶差分与质量相关集合的状态等级一阶差分中心距离;

步骤 12. 根据距离 d_k^c , 定义在线数据相对于各个状态等级的评价指标:

$$\gamma_k^c = \begin{cases} \frac{1}{d_k^c}, & d_k^c \neq 0 \\ \frac{1}{\sum_{c=1}^C \frac{1}{d_k^c}}, & d_k^c = 0 \end{cases} \quad (18)$$

步骤 13. 根据距离 d_k^c , 定义在线数据相对于各个状态等级的评价指标:

$$\dot{\gamma}_k = \frac{\|E\|^2}{2d_k} \quad (19)$$

步骤 14. 根据评价指标对过程运行状态进行在线评价:

1) 当 $\gamma_k^c = \max_{1 \leq c \leq C} \{\gamma_k^c\} > \delta$ 时, 表明在线数据中的质量相关过程变异信息与状态等级中的变异信息一致, 可以判定过程的运行状态为 $\tilde{c}$;

2) 当 1) 不满足但条件 $\gamma_{k-w+1}^c < \dots < \gamma_k^c$ 成立, 表明过程运行状态正处于状态等级转换过程中, 即当前过程逐渐变化;

3) 当 $\dot{\gamma}_k = \max \{\dot{\gamma}_k\} = 1/2$ 时, 表明在线数据中与质量相关过程变异信息的变化速度未有明显变化, 可以判定过程状态未发生变化;

4) 当 $\dot{\gamma}_k = \max \{\dot{\gamma}_k\} < 1/2$ 时, 表明在线数据中与质量相关过程变异信息的变化速度发生变化, 可以判定过程处于过渡状态, 并且过程状态开始恶化;

5) 当 $\dot{\gamma}_k = \max \{\dot{\gamma}_k\} > 1/2$ 时, 表明在线数据中与质量相关过程变异信息的变化速度发生变化, 可以判定过程处于过渡状态, 并且过程状态开始优化.

步骤 15. 综合步骤 14 结果, 给出静-动态特性协同感知的运行状态评价结果:

1) 当满足步骤 14 中 1) 和 3) 时, 从静态信息得出状态等级为 $\tilde{c}$, 且动态信息表明过程状态未发生变化, 可以判定过程的运行状态为 $\tilde{c}$;

2) 当满足步骤 14 中 3) 但不满足 2) 时, 从静态信息得出状态等级未发生变化且 $\gamma_k^c = \max_{1 \leq c \leq C} \{\gamma_k^c\}$, 动态信息表明过程状态未发生变化, 可以判定过程的运行状态为 $\tilde{c}$;

3) 当满足步骤 14 中 2) 和 4) 时, 从静态信息得出状态发生变化, 且动态信息表明过程状态向较差方向发展, 可以判定过程的运行状态为由前一时刻状态向较差的过程状态发展;

4) 当满足步骤 14 中 2) 和 5) 时, 从静态信息得出状态发生变化且动态信息表明过程状态不断改善, 可以判定过程的运行状态为由前一时刻状态向较好的过程状态演化;

5) 如果步骤 14 中 1) ~ 5) 都不满足, 则维持上一时刻评价结果.

步骤 16. 针对评价结果为非优的过程, 进行非优因素识别, 按采样时间对过程数据分组 ($B_1, B_2, \dots, B_m$); 构建非优识别的无约束优化函数, 求解目标函数式 (10);

步骤 17. 依据式 (12), 计算各个组贡献率;

步骤 18. 根据计算的贡献率, 识别导致过程运行状态非优的原因变量.

2 重介质选煤过程案例分析

下面将本文提出的基于静-动态特性协同感知的复杂工业过程运行状态评价方法应用于重介质选煤过程, 基于来自实际现场的数据, 验证其有效性.

2.1 重介质选煤过程简介

重介质选煤过程是一个典型的运行在恶劣开放环境中的流程工业过程, 各种不确定性因素和干扰频发, 导致数据质量偏低. 选煤也称为洗煤, 主要目标是除去原煤中的杂质, 降低灰分含量, 为用户提供精煤和动力煤.

选煤工艺流程中涉及多种仪表, 其大致工艺流程为: 原煤经过破碎和筛分, 粒度达到要求后, 与来自合格介质桶的重介质在混料桶内进行混合, 后经压力泵送入重介质旋流器分选, 最终选出灰分低的精煤和灰分高的尾煤; 重介质旋流器的底流和溢流经过脱介筛进行重介回收, 再经加水和磁铁粉调配密度后, 重新进入分选过程, 如图 3 所示^[36]. 其中, 煤泥含量是一个比较重要的变量. 评价煤的质量指标在煤炭行业中一般是灰分的量, 包括原煤和精煤.

悬浮液密度作为分选环节中的重点控制指标, 其主要作用是密度反馈, 确保密度可以符合稳定性的要求以及保障洗选产品的质量. 一般情况下, 对洗选后获得的精煤, 往往是通过快灰化验的方式来




图 3 重介质选煤工艺流程图

Fig.3 Process flow chart of heavy medium coal preparation

获得其灰分度, 而这一指标也是判断煤炭质量的关键. 但由于离线化验存在滞后性, 无法保证过程运行状态调控的及时性.

2.2 数据准备

通过重介质选煤工艺过程机理知识, 对影响选煤质量的影响因素进行分析. 由于重介质悬浮液密度、旋流器入口压力、合格介质桶液位、煤泥含量、磁性物浓度是重介质选煤过程中对选煤质量影响较大的工艺参数^[37], 所以最终确定这 5 个参数变量作为运行状态评价研究的过程变量. 性能指标的选择在算法实际应用中非常重要, 一般选择与过程运行最为密切且能反映过程运行状态的关键指标. 该指标并不是一个简单的运行参数或产品参数, 而是最能体现过程或产品核心价值的关键性能指标, 因而可视为某种 KPI. 在不同的应用场景中, 要根据过程工艺特点以及运行及操作模式等进行合理选择. 对于重介质选煤过程, 精煤灰分是表征重介质选煤过程的关键性能指标, 同时也是考核选煤厂煤炭产品质量的指标之一, 而精煤灰分一般是离线化验煤的灰分来进行的, 因此将煤的溢流口灰分值作为关键性能指标即输出变量.

本文用于工业案例应用研究的重介质选煤数据来自山东某选煤厂. 通过预处理, 选取 8000 组信息较完整的数据用于离线建模, 选择 1081 组数据用于在线评价.

选煤过程数据划分主要根据选煤过程的机理知识和过程数据的特征, 并结合实际生产过程经验进行. 本文按溢流灰分值, 将选煤过程划分为 3 个稳定状态, 分别用序号表示即 $c = 1, 2, 3$. 这 3 个状

态对应的运行状态评价等级分别为优、良、中, 如表 1 所示. 溢流灰分越大, 表示煤的质量越差, 其运行状态等级越差.

表 1 溢流灰分和对应的状态等级
Table 1 Overflow ash content and corresponding state level

灰分 (%)	状态等级 c
6.0 ~ 6.5	1 (优)
6.5 ~ 6.7	1 ~ 2 (优向良过渡)
6.7 ~ 7.2	2 (良)
7.2 ~ 7.5	2 ~ 3 (良向中过渡)
7.5 ~ 8.0	3 (中)

2.3 重介质选煤过程运行状态在线评价

需要注意的是, 复杂工业过程的运行状态通常不会发生突变, 因此在本文中不予考虑. 进行在线评价时, 从实际采集的样本数据中选取 1081 组数据, 包括 3 个稳定状态和 3 个过渡状态数据. 其中, 状态等级为优的数据 240 组, 状态等级为良的数据 481 组, 状态等级为中的数据 250 组; 另外, 优向良过渡数据 40 组, 良向中过渡数据 40 组, 中向良过渡数据 30 组. 由于实际工业过程运行环境复杂, 不确定性因素 (如扰动等) 繁多, 单个采样点识别的结果不够稳定. 因此在线评价时, 采用滑动窗口策略, 平稳算法稳定性与实时性之间关系. 其中滑窗长度 H 过小, 无法保证在线评价结果的稳定性; 滑窗长度 H 过大, 容易造成算法灵敏度降低、过渡状态识别不及时和评价结果滞后. 因此, 滑窗长度 H 需要在复杂过程的实际运行特性状态评价的准确性和及时性之间取得合理的折衷方案. 依据重介选煤流程工艺特性, 滑窗长度 H 取值往往在 3 ~ 5 之间. 本文参数设置如下: 评价指标阈值 $\varepsilon = 0.85$, 在线窗口数据的长度为 $H = 3$.

为更好体现提出的复杂工业过程运行状态评价方法的优越性, 本文给出基于 PLS 的复杂工业过程运行状态评价结果, 如图 4 所示. 图 4(a)、图 4(b)、图 4(c) 分别为在线数据与 3 个状态等级的评价指标值, 可以看出, 在样本点 1 ~ 240 之间, 状态等级优的评价指标略高于其他 2 个状态等级, 但无法稳定在预设阈值以上且评价结果波动幅度较大. 虽然能够观察到趋势, 但定量判断的错误率较高, 主要原因在于选煤过程噪声扰动多、数据质量低, 对传统方法准确性影响较大.

图 5 给出了基于静-动态特性协同感知的复杂工业过程运行状态在线评价结果. 图 5(a)、图 5(b)、




图 4 基于 PLS 的复杂工业过程运行状态评价

Fig.4 Evaluation of the operation status of complex industrial processes based on PLS

图 5(c) 分别表示在线数据与 3 个状态等级的评价指标值, 图 5(d) 为过程动态指标分析结果. 由图 5 可知, 在样本点 1~240 之间, 状态等级优的评价指标几乎都大于 0.85, 同时图 5(d) 过渡状态评价指标等于 0.5, 说明过程处于稳态. 因此由第 1.3 节判断准则可知, 此阶段过程处于优的运行状态. 在样本点 240~280 之间, 3 个状态等级的评价指标都小于 0.85, 图 5(b) 的评价指标值整体呈递增趋势, 图 5(a) 的评价指标值整体呈递减趋势; 图 5(d) 过渡状态评价指标小于 0.5, 说明运行状态在向较差状态发展且前一时刻是优状态. 结合评价准则, 可以判断该区间内过程处于由优向良过渡阶段. 与图 4 相比, 基于静-动态特性协同感知的复杂工业过程运行状态评价方法能够全面感知过程变化, 可以进一步判断运行状态是否平稳, 所以准确率得到了显著提高. 这是由于本文 KPI-driven SFA 方法能更好、更稳定地从低质量数据中提取过程内在变化的本质规律, 从而提高识别精度. 同理, 可以分析图 5 中状态等级为良和中的运行情况.

由于评价指标的阈值是根据经验选取的, 因此阈值的设定会影响最终的评价结果. 阈值越小, 越有利于稳定状态的识别, 但易将过渡状态误识别为与其相邻的稳态. 表 2 给出阈值分别为 0.85、0.80、0.70 时的状态识别情况. 本文中的误识别率表示在

线评价的结果和实际不一致的样本数与在线评价数据总数的比值. 由表 2 可以看出, 本文方法的误识别率适中, 且阈值越小, 误识别率越高.

此外, 从工厂实际采集的选煤数据中存在噪声干扰和离群点, 因此, 传统的运行状态评价方法其离线评价模型会因噪声干扰和离群点的影响而失去泛化能力, 从而导致在线评价结果准确性降低. 由图 5 可以看出, 本文方法能够得到较为准确的运行状态在线评价结果. 因此, 在干扰较小、数据质量较好情况下, 可以获得比较满意的运行状态评价结果.

2.4 重介选煤过程非优因素识别

利用基于静-动态特性协同感知的评价方法对重介质选煤过程进行评价. 当选煤过程运行在非优状态时, 则需要对导致过程非优因素变量进行识别. 本文分别对运行状态为良和中时, 进行非优原因识别.

图 6 是非优因素识别的结果, 其中横坐标 1~5 分别表示重介质悬浮液密度、介质桶液位、旋流器入口压力、磁性物浓度、煤泥含量 5 个过程变量. 其中, 图 6(a) 为基于变量贡献率的非优因素识别结果, 图 6(b) 为基于稀疏学习的非优因素识别结果. 由图 6(a) 可以看出, 在状态等级为良阶段, 介质桶




图 5 基于静-动态特性协同感知的复杂工业过程运行状态评价

Fig.5 Evaluation of the operating state of complex industrial processes based on the cooperative perception of static-dynamic characteristics

表 2 在线评价误识别率
Table 2 Misidentification rate of online evaluation

评价指标阈值	误识别样本数	误识别率 (%)
0.85	12	1.113
0.80	40	3.711
0.70	74	6.864

液位和磁性物浓度的贡献率近似,无法准确指出非优变量.这是由于非优因素变量与其他过程变量存在较强耦合性,导致轻微异常变量被错误地识别为主要贡献变量.由图 6(b) 的状态等级为良阶段可以看出,非优因素变量为介质桶液位,与实际生产经验相符.另外,以图 6(b) 状态等级为中阶段为例,通过分析 GWC 可以发现,介质桶液位的贡献率相对其他变量较高,因此导致过程处于非优的因素主

要是介质桶液位,而在图 6(a) 状态等级为中阶段,则无法清晰指明主要的非优因素.

综上所述,基于传统变量贡献率方法在过程未发生显著恶化时,由于运行状态等级为良和中都是正常状态,没有出现异常,因此没有出现显著的恶化,给出的识别结果往往不够明确,一般情况下,所有变量的贡献率都不为零,无法突出导致非优的变量.基于稀疏学习的方法将无关变量贡献识别为零,而且导致非优变量的贡献指示也更为突出和明确,这个结果与工艺分析具有一致性即由于介质桶液位未控制好导致的运行状态非优.介质桶液位过低和过高都会导致旋流器入口压力的波动,导致选煤效果不佳.

通过对重介质选煤过程进行运行状态评价以及对造成非优的原因进行追踪,可以实时监督生产过




图 6 非优因素识别结果
Fig.6 Identification results of non-optimal factors

程状况, 及时发现生产工况偏离最优状态的情况, 从而为选煤过程工艺流程的优化调整, 提高原煤分选质量, 最终为提高企业经济效益打下良好基础.

3 田纳西·伊斯曼过程案例分析

田纳西·伊斯曼 (Tennessee Eastman, TE) 过程是由 Downs 和 Vogel 以伊斯曼化学品公司的实际工艺流程为基础构造的仿真系统^[10]. 由于田纳西·伊斯曼仿真系统可以产生大量具有时变、强耦合和非线性数据, 所以被广泛用于各种复杂工业过程的控制和监控中. 该过程由反应器、冷凝器、压缩机、气凝塔和气/液分离器 5 个主要操作单元组成.

在 TE 过程中, 反应器温度较低, 影响化学反应速率, 过程反应不彻底、产物少、残余物多, 使工业过程的运营成本高, 因此可以通过改变反应器温度影响反应程度, 进而改变该过程的运行成本, 模拟过程运行的最优和非最优性能等级. 其中, 反应器温度与对应的状态等级关系如表 3 所示.

表 3 反应器温度与对应的状态等级
Table 3 Reactor temperature and corresponding status level

反应器温度 (°C)	状态等级	运行成本 (万元/h)
121.6	优	41.99 ~ 96.09
111.6	非优	

本文选取运行成本为综合经济指标, 从 41 个过程测量变量中选择 15 个与综合经济指标密切相关的变量进行建模, 见表 4. 本文从 1900 组样本中选取 1000 组样本作为训练数据, 其中优和非优状态等级数据各 500 组.

进行在线评价时, 选取 900 组数据, 包括 2 个稳定状态和 2 个过渡状态数据. 其中, 状态等级为优数据 270 组, 状态等级非优数据 500 组. 另外, 优

表 4 过程变量 (采样间隔时间 0.02 s)

Table 4 Process variables (sampling at intervals of 0.02 s)

变量编号	变量描述	单位
1	A 进料	km ³ /h
2	D 进料	kg/h
3	E 进料	kg/h
4	总进料	km ³ /h
5	再循环流量	km ³ /h
6	反应器进料速度	km ³ /h
7	反应器温度	°C
8	排放速度	km ³ /h
9	产品分离器温度	°C
10	产品分离器压力	kPa
11	分离器塔底低流量	m ³ /h
12	汽提塔压力	kPa
13	汽提塔温度	°C
14	反应器冷却水出口温度	°C
15	分离器冷却水出口温度	°C

到非优过渡数据 70 组, 非优到优过渡数据 60 组. 评价指标阈值 $\varepsilon = 0.8$, 在线窗口数据的长度设置为 $H = 3$.

3.1 TE 过程运行状态在线评价

为更好体现基于静-动态特性协同感知的复杂工业过程运行状态评价方法的优越性, 图 7 给出了基于 PLS 的 TE 过程运行状态评价结果. 其中, 图 7(a)、图 7(b) 分别表示状态等级优和非优的评价指标. 可以看出, 在样本点 1 ~ 240 之间, 非优等级的评价指标略高于状态等级为优; 在样本点 300 ~ 500 之间, 状态等级优无法稳定在预设阈值以上, 且评价结果波动幅度较大. 虽然能够看出基本趋势, 但错误率比较高. 主要原因是 PLS 算法无法有效提取过程的本质特征.




图7 基于PLS的TE过程运行状态评价
Fig.7 Evaluation of the operation status of TE process based on PLS

为此, 图8给出了基于静-动态特性协同感知的TE过程运行状态在线评价结果. 与基于PLS的TE过程运行状态相比, 基于静-动态特性协同感知的TE过程运行状态在线评价结果则更加准确, 在样本点300~500之间, 能够很直观地发现过程处于状态等级优, 指标稳定维持在预设阈值之上, 并且过程动态指标较为平稳地维持在0.5附近, 说明过程处于某一平稳状态. 在样本点200~270之间, 图8(a)和图8(b)指标都发生明显变化且过程动态指标大于0.5, 说明过程正在向好的状态发展. 需要注意的是, 在样本点600~800之间产生明显波动, 是由于TE过程工艺流程特性导致非优状态动态特性要大于优状态的动态特性. 然而, 由图8可以看出, 与平稳过程动态特性相比, 过渡状态的动态特性更加容易识别. 综上所述, 本文提出KPI-driven SFA方法能更稳定地提取过程内在变化的本质规律, 并有效识别过程变化方向, 丰富对过程




图8 基于静-动态特性协同感知的TE过程运行状态评价
Fig.8 Evaluation of the operating state of TE process based on the cooperative perception of static-dynamic characteristics

的认识. 同理, 可对图 8 中其他状态等级的运行状态进行分析.

3.2 TE 过程非优因素识别

利用基于静-动态特性协同感知的评价方法对重介质选煤过程进行评价, 当 TE 过程运行在非优状态时, 则需要对导致过程非优因素变量进行识别. 本文在运行状态为非优等级时, 进行非优原因识别.

图 9 为非优原因识别结果, 其中横坐标 1~15 分别表示表 4 中的 15 个变量. 图 9(a) 是基于变量贡献率的非优因素识别结果, 图 9(b) 是基于稀疏学习的非优因素识别结果. 由图 9(a) 可以看出, 导致状态非优的主要变量是反应器温度, 但有许多其余变量具有较大贡献率, 误导实际现场操作人员. 其中, 产品分离器温度、汽提塔压力、汽提塔温度的贡献率近似. 这是由于非优因素变量与其他过程变量存在较强耦合性, 导致轻微异常变量错误地识别为主要贡献变量, 造成基于变量贡献率的非优因素识别无法准确指出影响过程状态的变量. 由图 9(b) 可以看出, 非优因素变量为反应器温度. 为了对反应器温度调整进行适应, 后续的生产子流程 (气液分离器和汽提塔) 将进行一些调整, 这些调整反映在分离器温度、汽提塔温度和反应器冷却水出口温度上. 上述这些变量的改变都直接或间接地影响生产过程的运营成本, 因此基于稀疏学习的非优因素识别结果与实际情况一致.




图 9 TE 过程非优因素识别结果

Fig. 9 Identification results of non-optimal factors in the TE process

4 结束语

针对复杂工业过程中由于过程感知不全面导致漏报、误报现象严重的问题, 本文提出一种基于静-动态特性协同感知的运行状态评价方法, 并将其应用于重介质选煤过程. 通过本文提出的 KPI-driven SFA 算法, 实现工业过程静-动态特性协同感知以及运行状态信息的深度提取. 利用特征信息的相似度以及一阶差分信息的相似度, 完成对过程稳态和过渡的评价; 在此基础上, 给出基于静-动态特性协同感知的运行状态评价的统一框架, 实现过程运行状态实时评价与演化趋势实时监测, 有效减少误报、漏报问题. 当运行状态非优时, 本文提出一种基于稀疏学习的非优因素识别方法, 基于低质量过程数据实现非优因素变量准确识别, 降低无关变量影响, 提高识别结果的可解释性. 最后, 基于重介质选煤过程实际生产数据, 全面分析和验证了本文方法的有效性和实用性. 今后将对无监督或半监督机制等数据学习方法展开进一步研究工作.

References

- Gui Wei-Hua, Zeng Zhao-Hui, Chen Xiao-Fang, Xie Yong-Fang, Sun Yu-Bo. Knowledge-driven process industry smart manufacturing. *Science China: Information Sciences*, 2020, **50**(9): 1345–1360
(桂卫华, 曾朝晖, 陈晓方, 谢永芳, 孙玉波. 知识驱动的流程工业智能制造. *中国科学: 信息科学*, 2020, **50**(9): 1345–1360)
- Yang Chun-Hua, Han Jie, Zhou Xiao-Jun, Zhang Run-Dong, Gui Wei-Hua. Discussion on uncertain optimization method of nonferrous metallurgy process. *Control and Decision*, 2018, **33**(5): 856–865
(阳春华, 韩洁, 周晓君, 张润东, 桂卫华. 有色冶金过程不确定优化方法探讨. *控制与决策*, 2018, **33**(5): 856–865)
- Qian Feng, Gui Wei-Hua. Boosting optimization and upgrade for manufacturing industry by artificial intelligence. *Science Foundation in China*, 2018, **32**(3): 257–261
(钱锋, 桂卫华. 人工智能助力制造业优化升级. *中国科学基金*, 2018, **32**(3): 257–261)
- Chai Tian-You. Development directions of industrial artificial intelligence. *Acta Automatica Sinica*, 2020, **46**(10): 2005–2012
(柴天佑. 工业人工智能发展方向. *自动化学报*, 2020, **46**(10): 2005–2012)
- Chai Tian-You. Artificial intelligence research challenges in intelligent manufacturing processes. *Science Foundation in China*, 2018, **32**(3): 251–256
(柴天佑. 制造流程智能化对人工智能的挑战. *中国科学基金*, 2018, **32**(3): 251–256)
- Liu Y, Wang F, Chang Y. Operating optimality assessment based on optimality related variations and non-optimal cause identification for industrial processes. *Journal of Process Control*, 2016, **39**: 11–20
- Liu Yan, Chang Yu-Qing, Wang Fu-Li. Online assessment of process operating performance based on Fisher discriminant analysis. *Control and Decision*, 2014, **29**(9): 1655–1660
(刘炎, 常玉清, 王福利. 基于 Fisher 判别分析的过程运行状态在线评价. *控制与决策*, 2014, **29**(9): 1655–1660)
- Xie S W, Xie Y F, Huang T W, Gui W H, Yang C H. Coordinated optimization for the descent gradient of technical index in the iron removal process. *IEEE Transactions on Cybernetics*, 2018, **48**(12): 3313–3322
- Liu Y, Chang Y, Wang F. Online process operating perform-

- ance assessment and non-optimal cause identification for industrial processes. *Journal of Process Control*, 2014, **24**(10): 1548–1555
- 10 Liu Y, Wang F, Chang Y, Ma R. Operating optimality assessment and non-optimal cause identification for non-Gaussian multi-mode processes with transitions. *Chemical Engineering Science*, 2015, **137**: 106–118
 - 11 Peng K, Zhang K, Li G, Zhou D. Contribution rate plot for non-linear quality-related fault diagnosis with application to the hot strip mill process. *Control Engineering Practice*, 2013, **21**(4): 360–369
 - 12 Chu Fei, Zhao Xu, Dai Wei, Ma Xiao-Ping, Wang Fu-Li. Data-driven robust evaluation method for optimal operating status and its application. *Acta Automatica Sinica*, 2020, **46**(3): 439–450
(褚菲, 赵旭, 代伟, 马小平, 王福利. 数据驱动的最优运行状态鲁棒评价方法及应用. 自动化学报, 2020, **46**(3): 439–450)
 - 13 Shang C, Huang B, Yang F, Huang D. Slow feature analysis for monitoring and diagnosis of control performance. *Journal of Process Control*, 2016, **39**: 21–34
 - 14 Zhao C H, Sun H. Dynamic distributed monitoring strategy for large-scale non-stationary processes subject to frequent varying conditions under closed-loop control. *IEEE Transactions on Industrial Electronics*, 2019, **66**(6): 4749–4758
 - 15 Qin Y, Zhao C. Comprehensive process decomposition for closed-loop process monitoring with quality-relevant slow feature analysis. *Journal of Process Control*, 2019, **77**: 141–154
 - 16 Kaspar M H, Ray W H. Dynamic PLS modelling for process control. *Chemical Engineering Science*, 1993, **48**(20): 3447–3461
 - 17 Misra M, Yue H H, Qin S J, Ling C. Multi-variate process monitoring and fault diagnosis by multi-scale PCA. *Computers & Chemical Engineering*, 2002, **26**(9): 1281–1293
 - 18 Zhao S Y, Huang B, Liu F. Linear optimal unbiased filter for time-variant systems without apriori information on initial conditions. *IEEE Transactions on Automatic Control*, 2017, **62**: 882–887
 - 19 Wiskott L, Sejnowski T J. Slow feature analysis: Unsupervised learning of in-variances. *Neural Computing and Applications*, 2002, **14**: 715–770
 - 20 Shang C, Yang F, Huang B, Huang D. Recursive slow feature analysis for adaptive monitoring of industrial processes. *IEEE Transactions on Industrial Electronics*, 2018, **65**(11): 8895–8905
 - 21 Zou X, Zhao C. Concurrent assessment of process operating performance with joint static and dynamic analysis. *IEEE Transactions on Industrial Informatics*, 2019, **16**(4): 2776–2786
 - 22 Zhang S, Zhao C, Huang B. Simultaneous static and dynamic analysis for fine-scale identification of process operation statuses. *IEEE Transactions on Industrial Informatics*, 2019, **15**(9): 5320–5329
 - 23 Chai Z, Zhao C. Enhanced random forest with concurrent analysis of static and dynamic nodes for industrial fault classification. *IEEE Transactions on Industrial Informatics*, 2020, **16**(1): 54–66
 - 24 Ma L, Dong J, Peng K. A novel key performance indicator oriented hierarchical monitoring and propagation path identification framework for complex industrial processes. *ISA Transactions*, 2020, **96**: 1–13
 - 25 Ding S X, Yin S, Peng K, Hao H, Shen B. A novel scheme for key performance indicator prediction and diagnosis with application to an industrial hot strip mill. *IEEE Transactions on Industrial Informatics*, 2012, **9**(4): 2239–2247
 - 26 Zheng J, Zhao C. Online monitoring of performance variations and process dynamic anomalies with performance-relevant full decomposition of slow feature analysis. *Journal of Process Control*, 2019, **80**(8): 89–102
 - 27 Chiplunkar R, Huang B. Output relevant slow feature extraction using partial least squares. *Chemometrics and Intelligent Laboratory Systems*, 2019, **191**: 148–157
 - 28 De Jong S. SIMPLS: An alternative approach to partial least squares regression. *Chemometrics and Intelligent Laboratory Systems*, 1993, **18**(3): 251–263
 - 29 Gao X, Yang F, Huang D. Model quality assessment and model mismatch detection: A temporal smoothness regularization approach. *IFAC-Papers OnLine*, 2018, **51**(18): 903–908
 - 30 Li G, Alcalá C F, Qin S J, Zhou D. Generalized reconstruction-based contributions for output-relevant fault diagnosis with application to the Tennessee Eastman process. *IEEE Transactions on Control Systems Technology*, 2010, **19**(5): 1114–1127
 - 31 Liu Y, Zeng J, Xie L, Luo S, Su H. Structured joint sparse principal component analysis for fault detection and isolation. *IEEE Transactions on Industrial Informatics*, 2019, **15**: 2721–2731
 - 32 Yuan M, Lin Y. Model selection and estimation in regression with grouped variables. *Journal of the Royal Statistical Society: Series B (Statistical Methodology)*, 2006, **68**(1): 49–67
 - 33 Yu W K, Zhao C H. Sparse exponential discriminant analysis and its application to fault diagnosis. *IEEE Transactions on Industrial Electronics*, 2018, **65**(7): 5931–5940
 - 34 Shang C, Ji H, Huang X, Yang F, Huang D. Generalized grouped contributions for hierarchical fault diagnosis with group lasso. *Control Engineering Practice*, 2019, **93**: Article No. 104193
 - 35 Yan Z B, Yuan Y. Variable selection method for fault isolation using least absolute shrinkage and selection operator (LASSO). *Chemometrics and Intelligent Laboratory Systems*, 2015, **146**: 136–146
 - 36 Bai J, Xing Y, Chen Y. Application of three products heavy medium coal preparation process in Tangshan Chun'ao coal preparation plant. *Clean Coal Technology*, 2013, **19**(3): 26–29
 - 37 Chu F, Wu Q, Dai W, Ma X, Wang F. Latent variable techniques based operating performance assessment for the dense medium coal preparation process. In: Proceedings of the 35th Chinese Control Conference. Chengdu, China: IEEE, 2016. 9821–9826



褚菲 中国矿业大学信息与控制工程学院教授。2014 年获得东北大学博士学位。主要研究方向为复杂工业过程的建模、控制与优化, 统计过程监测及运行状态评价。

E-mail: chufeizhufei@sina.com

(CHU Fei Professor at the School of Information and Control Engineering, China University of Mining and Technology. He received his Ph.D. degree from Northeastern University in 2014. His research interest covers modeling, control and optimization of complex industrial process, and statistical process monitoring and operating performance assessment.)



许杨 中国矿业大学信息与控制工程学院硕士研究生。2019 年获得中国矿业大学学士学位。主要研究方向为复杂工业过程运行优化及运行状态评价。E-mail: xuyang_668@sina.com

(XU Yang Master student at the School of Information and Control Engineering, China University of Mining and Technology. He received his bachelor degree from China Uni-

versity of Mining and Technology in 2019. His research interest covers optimization of complex industrial process and operating performance assessment.)



尚 超 清华大学自动化系副教授. 2016 年获得清华大学博士学位. 主要研究方向为大数据解析及工业应用, 过程监控与故障诊断和工业过程建模. 本文通信作者.

E-mail: c-shang@tsinghua.edu.cn

(**SHANG Chao** Associate professor in the Department of Automation, Tsinghua University. He received his Ph.D. degree from Tsinghua University in 2016. His research interest covers big data analysis and industrial applications, process monitoring and fault diagnosis, and industrial process modeling. Corresponding author of this paper.)




王福利 东北大学信息科学与工程学院教授. 1988 年获得东北大学博士学位. 主要研究方向为复杂工业系统的建模、控制与优化, 过程监测和故障诊断.

E-mail: wangfuli@ise.neu.edu.cn

(**WANG Fu-Li** Professor at the College of Information Science and Engineering, Northeastern University. He received his Ph.D. degree from Northeastern University in 1988. His research interest

covers modeling, control and optimization of complex industrial process, process monitoring and fault diagnosis.)



高福荣 香港科技大学化工系教授. 主要研究方向为过程建模、控制和监测. E-mail: kefgao@ust.hk

(**GAO Fu-Rong** Professor in the Department of Chemical Engineering, Hong Kong University of Science and Technology. His research

interest covers process modeling, control and monitoring.)



马小平 中国矿业大学信息与控制工程学院教授. 2001 年获中国矿业大学博士学位. 主要研究方向为过程控制, 网络化控制系统及故障检测.

E-mail: xpma@cumt.edu.cn

(**MA Xiao-Ping** Professor at the School of Information and Control Engineering, China University of Mining and Technology. He received his Ph.D. degree from China University of Mining and Technology in 2001. His research interest covers process control, networked control system and fault detection.)