



基于批次图像化的卷积自编码故障监测方法

张海利, 王普, 高学金, 齐咏生, 高慧慧

引用本文:

张海利, 王普, 高学金, 等. 基于批次图像化的卷积自编码故障监测方法[J]. 控制与决策, 2021, 36(6): 1361–1367.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2019.1342>

您可能感兴趣的其他文章

Articles you may be interested in

基于广义主成分分析的重构故障子空间建模方法

Reconstructed fault subspace modelling method based on generalized principal component analysis

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

基于自适应混合核典型变量分析的工业过程质量相关故障检测

Quality-related fault detection for industrial processes based on adaptive mixed kernel canonical variable analysis

控制与决策. 2021, 36(4): 801–807 <https://doi.org/10.13195/j.kzyjc.2020.0690>

基于交叉熵的改进NPE间歇过程故障检测算法

Improved NPE batch process fault detection algorithm based on cross entropy

控制与决策. 2021, 36(2): 411–417 <https://doi.org/10.13195/j.kzyjc.2019.0725>

改进集成深层自编码器在轴承故障诊断中的应用

Application of improved ensemble deep auto-encoder in bearing fault diagnosis

控制与决策. 2021, 36(1): 135–142 <https://doi.org/10.13195/j.kzyjc.2019.0270>

基于互信息操作变量曲线参数化的间歇过程批内修正优化

Intra-batch correction optimization of batch process with manipulated variable trajectory parameterization based on mutual information

控制与决策. 2021, 36(1): 234–240 <https://doi.org/10.13195/j.kzyjc.2019.0825>

基于批次图像化的卷积自编码故障监测方法

张海利^{1,2,3,4}, 王 普^{1,2,3,4}, 高学金^{1,2,3,4†}, 齐咏生⁵, 高慧慧^{1,2,3,4}

(1. 北京工业大学 信息学部, 北京 100124; 2. 数字社区教育部工程研究中心, 北京 100124;
3. 城市轨道交通北京实验室, 北京 100124; 4. 计算智能与智能系统北京市重点实验室, 北京 100124;
5. 内蒙古工业大学 电力学院, 呼和浩特 010051)

摘 要: 针对间歇过程的非线性、多阶段性等特点及其三维数据形式, 提出基于批次图像化的卷积自编码故障监测方法. 首先, 将每个批次数据看作一个灰度图, 每个批次中数据变化可以看作图片的纹理变化, 利用卷积自编码器 (convolutional autoencoder, CAE) 直接对间歇过程三维数据进行特征提取, 避免三维数据展开成二维时导致的信息丢失, 无需分阶段充分考虑批次全局信息, 有效提取过程变量相关关系的动态变化; 同时, 利用卷积操作提取局部特征信息, 自编码网络可以解决非线性问题, 实现特征的无监督学习; 然后, 使用一类支持向量机 (one-class support vector method, OCSVM) 描述特征分布, 构造新的统计量, 确定控制限, 实现故障监测; 最后, 通过将该方法应用到 Pensim 仿真平台及重组人粒细胞集落刺激因子发酵的实际生产数据, 验证所提方法的准确性和有效性.

关键词: 间歇过程; 多阶段; 批次图像; 卷积自编码器; 一类支持向量机; 故障监测

中图分类号: TP273

文献标志码: A

DOI: 10.13195/j.kzyjc.2019.1342

开放科学(资源服务)标识码(OSID):



引用格式: 张海利, 王普, 高学金, 等. 基于批次图像化的卷积自编码故障监测方法 [J]. 控制与决策, 2021, 36(6): 1361-1367.

Fault detection of batch image-based convolutional autoencoder

ZHANG Hai-li^{1,2,3,4}, WANG Pu^{1,2,3,4}, GAO Xue-jin^{1,2,3,4†}, QI Yong-sheng⁵, GAO Hui-hui^{1,2,3,4}

(1. Faculty of Information Technology, Beijing University of Technology, Beijing 100124, China; 2. Engineering Research Center of Digital Community of Ministry of Education, Beijing 100124, China; 3. Beijing Laboratory for Urban Mass Transit, Beijing 100124, China; 4. Beijing Key Laboratory of Computational Intelligence and Intelligent System, Beijing 100124, China; 5. School of Electric Power, Inner Mongolia University of Technology, Hohhot 010051, China)

Abstract: Aiming at nonlinearity, multi phases and 3D data matrixes in batch processes, a fault detection method using a batch image-based convolutional autoencoder is proposed. Process data of each batch is considered as a grayscale image and is input to the convolutional autoencoder (CAE) directly for representation learning. Data variation in each batch can be regarded as the texture change of the image. Information loss caused by 3D data unfolding to 2D is avoided. Meanwhile, variable correlation is effectively extracted using global modeling with no need to phase division. Convolution operation extracts local conjunction features, and using an autoencoder is an efficient way for unsupervised learning. Then the one-class support vector method (OCSVM) is used to construct monitoring statistic and calculate control limit for fault detection. By applying the proposed method on the Pensim simulation and recombinant human granulocyte colony-stimulating factor (rhG-CSF) fermentation process, the effectiveness is demonstrated.

Keywords: batch process; multi-phase; batch image; convolutional autoencoder; one-class support vector machine; fault detection

0 引 言

间歇生产作为重要的工业生产模式因具有小批量、多品种、高附加值等优点被广泛用于制药、食品

加工、半导体制造等领域^[1-4]. 目前, 间歇生产过程正在向精细化、集约化发展, 对生产全流程进行有效监控至关重要, 既能保障间歇过程的生产安全, 又能提

收稿日期: 2019-09-24; 修回日期: 2019-12-31.

基金项目: 国家自然科学基金项目 (61803005, 61640312, 61763037); 北京市自然科学基金项目 (4192011, 4172007); 山东省重点研发计划项目 (2018CXGC0608); 北京市教育委员会项目 (PXM2019_014204_500034).

责任编委: 方华京.

†通讯作者. E-mail: gaosuejin@bjut.edu.cn.

高产品质量和生产效率,降低企业能耗和污染^[5].

间歇过程故障监测研究中最常用的是以主成分分析^[6-8]和偏最小二乘^[9]为核心的多元统计方法,通过对正常状态下的历史数据建模构造统计量实现故障监测^[10].针对间歇过程典型的三维数组形式,常先将三维数据沿变量^[11]或批次^[12]方向展开成二维矩阵,之后再行多元统计建模等.但是,对三维数据进行二维展开会损失部分信息^[13].针对间歇过程的多阶段性,通常是先将间歇过程分为不同的阶段,然后在各个阶段内分别建模进行故障监测^[14].如何合理分阶段是此类方法的一个难题.文献[15]将时间变量添加到核熵负载矩阵中,并利用模糊 C -均值对间歇过程进行阶段划分;文献[16]利用两步迭代序列阶段分割算法搜索并调整阶段分割点;文献[17]还研究了软阶段划分方法,有效减少过渡阶段“硬分类”导致的误警率.然而,分阶段建模是将各个阶段数据独立建模,没有考虑不同阶段之间数据的动态相关性,且阶段划分没有统一标准,建模步骤繁琐,更新困难.

以卷积神经网络(convolutional neural network, CNN)为代表的深度学习方法,在图像识别^[18]上取得了较大的成就,经过近几年的发展,逐渐扩展到过程建模^[19-20]、机械故障诊断^[21]及工业故障诊断^[22]上,但是在间歇过程的故障监测上应用还很少.卷积自动编码器(convolutional autoencoder, CAE)是文献[23]提出的一种无监督学习方法,将卷积神经网络中的卷积、池化等运算进行反向操作,对输入数据重构,并通过最小化输入数据与重构数据的均方差实现特征学习,在保留CNN的局部特征提取优势的同时,无需数据标签.该方法最初被应用于图像识别,近年来逐步扩展应用到图像视频^[24-25]、晶圆^[26]等的异常检测上,但是在间歇过程的故障监测上应用还很少.

本文提出一种基于批次图像化的卷积自动编码故障监测方法.将每个批次数据看作二维灰度图,无需对间歇过程的三维数组进行二维转换,可避免信息丢失;每个批次中数据变化可以看作图片的纹理变化,整体建模充分考虑变量相关关系的动态变化,相比分阶段建模极大地减少了计算量;二维灰度图直接输入CAE中提取间歇过程的特征,模型建立无需故障数据及标签;利用OCSVM方法构造所提特征的监控统计量并确定其控制限,通过将当前采样时刻的监测统计量与控制限比较实现故障监测.

1 基本算法

1.1 卷积自动编码器

卷积自动编码器将卷积神经网络的卷积和池化操作与传统自编码器的无监督学习方式相结合,实现

图片等二维数据结构的深层特征提取^[27].在CAE中,若干个卷积层、池化层及全连接层构成编码单元,与之近似为逆运算的全连接层、反池化层及反卷积层构成解码单元.损失函数采用均方误差函数.通过最小化损失函数,即重构数据与输入数据的均方误差,实现特征的无监督学习.

1.1.1 编码单元

编码单元由卷积层、池化层、全连接层组成.

卷积层:对于输入 x ,卷积计算的公式如下:

$$h_k = \sigma(xW_k + b_k). \quad (1)$$

其中: h_k 为第 k 个卷积核计算得到的特征, W_k 和 b_k 分别为卷积核的权重和偏差, σ 为激活函数.

池化层:本文采用的是最大池化,即按一定的步长移动池化核并求最大值.每个池化后的特征在池化核中的位置都要记录下来,这样才能在解码单元进行逆运算.

全连接层:将二维特征图伸展成一维特征并降低到所需的维度.

1.1.2 解码单元

解码单元相当于编码单元的逆运算,由全连接层、反池化层、反卷积层组成.

全连接层:扩展数据维度并折叠为二维特征图.

反池化层:以二维特征图及图中每个数据点的位置索引为输入,按一定的步长及核大小恢复特征在池化运算前的特征图,其余位置补0.

反卷积层:也被称为转置卷积层,其运算与卷积运算类似,反卷积运算的权重是卷积层权重的转置,计算公式如下:

$$y = \sigma\left(\sum_{k \in H} (h_k \widetilde{W}_k + c)\right). \quad (2)$$

其中: c 为每个输入通道的偏差, h_k 为隐藏层的特征图, $\widetilde{W}_k$ 为卷积层中权重 W_k 的转置.

1.2 一类支持向量机

OCSVM的主要思想是寻找一个超平面将训练样本与原点分开,并尽可能地使间隔最大^[28].设训练数据集为 $\{x_i\}$, $x_i \in R_d$, $i = 1, 2, \dots, m$,如何找到满足上述条件的超平面是一个优化问题,由下式表示:

$$\begin{aligned} \min \quad & \frac{1}{2} \|\mathbf{w}\|^2 + \frac{1}{vm} \sum_{i=1}^m \xi_i + \mathbf{b}. \\ \text{s.t.} \quad & \mathbf{w} \cdot \varphi(x_i) + \mathbf{b} + \xi_i \geq 0; \\ & \xi_i \geq 0, i = 1, 2, \dots, m. \end{aligned} \quad (3)$$

其中: $\mathbf{w}$ 和 $\mathbf{b}$ 为超平面的参数, $\varphi(\cdot)$ 为核函数, ξ_i 为松弛变量, v 为误差限.松弛变量的作用是对错分样本点进行惩罚,误差限为允许出现的异常值比例的上

限. 求解该问题可得最优解 w^* 和 b^* , 则决策函数为

$$f(x) = \text{sgn}(w^* \cdot \varphi(x) + b^*). \quad (4)$$

2 基于批次图像化的卷积自动编码故障监测

针对间歇过程的多阶段性、非线性和三维数据形式, 本节介绍一种基于批次图像化的卷积自动编码故障监测方法. 该方法将批次数据进行图像化处理, 即一个批次的数据看作一张灰度图, 无需对批次数据进行二维展开及分阶段建模, 有效提取过程动态特征, 充分考虑数据批次间及批次内的相关性, 同时避免分阶段建模的繁琐步骤, 减少建模复杂度. 但是, 卷积自编码器提取的特征不满足高斯分布的条件, 无法像主成分分析(PCA)提取的主元特征一样构造 T^2 统计量, 因此引入OCSVM算法用于构造卷积自编码特征的统计量及其控制限. 通过将在线监控统计量与控制限比较实现故障监测.

为符合过程监控中超过控制限即发生故障的表述习惯, 本文将监控统计量设计为到超平面距离的相反数, 用 D 表示, 如下所示:

$$D = -(w^* \cdot \varphi(x) + b^*). \quad (5)$$

这样, 0 就是所设计统计量的控制限, 当 $D > 0$ 时, 故障发生, 否则是正常.

2.1 数据预处理

基于批次图像化的卷积自动编码故障监测算法中, 将一整个批次的数据当作二维灰度图处理会有两个问题: 一是计算机处理灰度图的数据范围与过程实际数据范围不同; 二是在批次生产未完成时如何实现在线监测. 针对这两个问题, 本文需要先对数据做预处理: 归一化和数据填充, 数据预处理流程如图1所示. 归一化是指在消除量纲的同时把数据变成 0~1 之间的小数. 数据填充是在线监测阶段, 批次生产未完成时, 后续未发生时刻的数据用训练的正常批次各个时刻平均值来填充.




图1 数据预处理

2.2 算法流程

基于卷积自动编码器的间歇过程故障监测分为离线建模和在线监测两个部分.

2.2.1 离线建模

step 1: 获取正常历史数据 $X(I \times K \times J)$, 进行预处理:

- 1) 将历史三维数据 $X(I \times K \times J)$ 沿变量方向展开成二维数据 $X(J \times IK)$;
- 2) 求每个变量的最大值及最小值;
- 3) 对每个变量进行归一化处理;
- 4) 将二维数组重新折叠成三维数组;
- 5) 所有训练批次求平均值, 得到正常批次数据各个时刻的平均值.

step 2: 设置 CAE 网络参数.

step 3: 将归一化后的三维数组输入网络进行训练.

step 4: 对 CAE 提取到的特征采用 OCSVM 建模, 求超平面的最优解, 得到统计量计算公式.

2.2.2 在线建模

step 1: 采集当前时刻 k 所有变量的数据 $x_{\text{new},k}(J \times 1)$, 并进行预处理:

- 1) 按离线求得的每个变量的最大最小值对 $x_{\text{new},k}(J \times 1)$ 进行归一化处理;
- 2) 将 k 时刻与 $1 \sim k-1$ 时刻归一化后的数据组合, 后续未发生的 $k+1 \sim K$ 时刻数据用正常批次对应时刻平均值填充.

step 2: 将填充完的一个批次数据输入到离线建模训练好的网络提取特征.

step 3: 将上一步中提取的特征代入式(5)中, 计算统计量 D , 若 $D > 0$, 则判定当前时刻出现故障, 否则为正常状态.

3 实验及结果分析

本节用 Pensim 青霉素发酵仿真平台数据和某生物制药公司 rhG-CSF 发酵的实际生产数据评估所提方法的有效性. 本文所有实验设备使用配置为 Intel i5-4590 CPU 和 12 GB RAM 的台式机, 软件为 pytorch 1.0. 经十折交叉验证确定所用 CAE 模型的结构参数如表1所示, 共包含 2 个卷积层、1 个池化层、2 个全连接层、1 个反池化层和两个反卷积层.

表1中: conv(1, 16, (11, 5), (2, 1), (5, 2)) 指卷积层输入通道数为1, 输出通道数为16, 卷积核大小为 11×5 , 步长为 2×1 , 填充大小为 5×2 ; maxpool(2, 2) 指池化层核大小为 2×2 , 步长为2; linear(10) 指输出特

表 1 CAE网络结构参数

序号	名称	参数
1	卷积层1	conv (1, 16, (11, 5), (2, 1), (5, 2))
2	卷积层2	conv (16, 32, (11, 5), (2, 1), (5, 2))
3	池化层	maxpool (2, 2)
4	全连接层	linear (10)
5	全连接层	linear (10)
6	反池化层	maxunpool (2, 2)
7	反卷积层2	convtranspose (32, 16, (11, 5), (2, 1), (5, 2))
8	反卷积层1	convtranspose (16, 1, (11, 5), (2, 1), (5, 2))

征层节点数为10. 每个卷积层及第1个反卷积层后的激活函数都使用tanh函数,而在第2个反卷积层后的激活函数使用sigmoid函数,这是为了将网络输出缩放到0~1范围内,以便与网络输入比较. 网络训练参数中学习率设为0.000 1, batch_size 设为10, epoch 设为10. 用于确定监控统计量及其控制限的OCSVM算法中误差限 $v = 0.005$,核函数选择高斯核,核参数根据文献[29]中所述的规则确定其上下限.

3.1 青霉素发酵仿真分析

本实验采用Pensim青霉素发酵仿真平台^[30],共采集10个过程变量:通风速率(L/h)、搅拌功率(W)、底物流加速率(L/h)、补料温度(K)、溶解氧浓度(mol/L)、排气二氧化碳浓度(mol/L)、pH值、反应温度(K)、反应热(Cal)、冷水流加速率(L/h),采样间隔为1 h,选取50个正常批次作为训练样本,4个故障批次作为测试样本,故障设置如表2所示.

表 2 故障设置

序号	故障变量	故障类型	时刻/h
1	通风速率	斜率为-0.002的斜坡故障	200
2	通风速率	幅值为-1的阶跃故障	200
3	搅拌功率	斜率为-0.003的斜坡故障	200
4	搅拌功率	幅值为-3的阶跃故障	200

将本文所提算法应用于Pensim平台仿真数据上,并与MPCA、多阶段MPCA、BDPCA (batch dynamic PCA)^[31]作对比,验证其故障监测的准确性及有效性. 其中,MPCA算法先将数据沿变量展开成二维,然后进行PCA降维,按85%的方差贡献率选取主元. 多阶段MPCA采用文献[15]的阶段划分结果,分为1~53 h, 54~78 h, 79~185 h, 186~205 h, 206~400 h五个阶段,每个阶段内利用MPCA单独建模并监测故

障. BDPCA方法中时滞参数为4,通过构造时滞增广矩阵实现SPE控制限的动态变化并完成故障监测.

表3为不同方法在故障批次1~4上的误报警率和漏报警率. 图2分别为CAE-OCSVM、BDPCA、多阶段MPCA和MPCA四种方法对故障批次3的监测结果.

从监测图2及表3中可以看出:CAE方法能够检出所有故障,且没有误报警,仅在故障批次3上有3%的漏报警;BDPCA的SPE统计量故障检测效果较好,在故障批次3上的漏报警率仅比CAE方法高2.5%,但是 T^2 统计量的检测结果较差;多阶段MPCA和MPCA方法虽然也能检出所有故障,但是误报警和漏报警率较高.




图 2 各算法对故障批次3的监测

表3 Pensim青霉素发酵过程的监测 %

序号	监测指标	CAE	BDPCA		多阶段MPCA		MPCA	
		D	T^2	SPE	T^2	SPE	T^2	SPE
1	误报警	0	14	0	1	0.5	14.5	12
	漏报警	0	0	0	0	0	0	0
2	误报警	0	14	0	1	1	13.5	12
	漏报警	0	2.5	0	1	1	0.5	1
3	误报警	0	0	0	0	0	9	7.5
	漏报警	3	28.5	5.5	26.5	4.5	22.5	9.5
4	误报警	0	10.7	0	0	0.5	8	4
	漏报警	0	0.5	0	0	0	0	0

MPCA方法没有考虑阶段变化,因此在阶段变化附近出现了误报警.多阶段MPCA和MPCA方法均在生产初期出现了误报警,这是因为青霉素发酵不同批次的起始条件会有一定差异,这两种方法对此都较敏感. BDPCA方法中SPE统计量的控制限是随时间动态变化的,而 T^2 统计量的控制限是不变的,因此在多阶段的发酵过程中,SPE的监测效果好而 T^2 的监测效果差,同时由于构造时滞增广矩阵,在生产最初的几个时刻无法进行故障监测. 而CAE方法将批次数据图像化处理,能够在提取局部特征的同时,从全局把握每个批次整体的变化特征,更具鲁棒性,同时OCSVM方法描述了正常批次特征的分布特点,避免了CAE特征无法构造 T^2 统计量的缺陷. 总体而言,相比MPCA和多阶段MPCA,本文方法监测效果更好.

为了更好地理解CAE中卷积运算的意义及其所提取特征与其他方法的异同,本文分别采用二维灰度图和PCA降维后的三维散点图对故障批次3进行可视化展示. 如图3(a)所示为CAE中原始数据和两个卷积层特征的灰度图,数据大小原本均为 400×10 ,为了能够更清晰地观察特征图,对长宽比例进行缩放,其中每一列表示一个变量,从上到下表示采样时间递增. 所有图片的约1/5处类似褶皱部分即对应青霉素发酵过程的阶段变化. 故障变量(搅拌速率)为第2个变量,在原始数据灰度图可以看到第2列数据下半部分纹理变化规则与其他时刻明显不同,每经过一次卷积变换,故障特征都扩展到其临近的特征向量上,在卷积层二维灰度图中,第1~6列图片纹理都与其他时刻明显不同,这是因为卷积运算在提取局部特征上的优势,能够对局部的故障信息进行有效揭示. 图3(b)为CAE、BDPCA、多阶段MPCA和MPCA四种方法提取特征经PCA降维后的三维散点图. CAE和BDPCA都能有效区分故障和正常特征,

但多阶段MPCA和MPCA方法提取的故障特征与正常特征都有重叠.




图3 可视化分析

3.2 重组人粒细胞集落刺激因子发酵实验分析

重组人粒细胞集落刺激因子 (recombinant human granulocyte colony-stimulating factor, rhG-CSF)的发酵是一个典型的多阶段间歇生产过程. 发酵周期大约18.5 h. 该实验共采集8个过程变量: pH、溶解氧浓度(%)、罐压(Bar)、温度($^{\circ}\text{C}$)、搅拌转速(rpm)、补葡萄糖量(ml)、补培养基量(ml)、通气量(L/min). 采样间隔为30 min,共采集25批次正常数据,并对其进行等长处理,得到训练数据 $X(25 \times 8 \times 37)$,另选一个故障批次数据进行测试,该故障批次是补葡萄糖量在6.5 h,

即第13个采样点处发生的斜坡故障,故障持续至批次结束.

图4和表4分别为CAE-OCSVM、BDPCA、多阶段MPCA和MPCA四种方法应用在rhG-CSF发酵实际生产中的故障监测图和监测结果.其中:多阶段MPCA按文献[15]的方法划分为3个阶段:0~5.5h, 6~14.5h, 15~18.5h. CAE方法在8h处检测出故障,且不存在误报警;BDPCA方法故障检测延迟较长,且最初几个时刻无法进行故障监测,这是因为在生产最初无法构造时滞增广矩阵;多阶段MPCA方法 T^2 统计量在8h处检测出故障,无误报警;MPCA方法在8h处能检测出故障,但是存在误报警. CAE方法将青霉素发酵批次数据作灰度图处理,无需分阶段建模,有效提取批次过程变量间的相关关系,OCSVM更好地描述特征分布,构造的统计量监测效果更好.




图4 各算法对rhG-CSF生产中故障批次的监测

表4 rhG-CSF 发酵过程的监测							%
监测指标	CAE	BDPCA		多阶段MPCA		MPCA	
	D	T^2	SPE	T^2	SPE	T^2	SPE
误报警	0	0	37.5	0	0	8.33	8.33
漏报警	12	16	32	24	12	24	12

4 结 论

针对间歇过程的非线性、多阶段性和三维数据形式,本文提出了一种基于批次图像化的卷积自编码故障监测算法,通过将每个批次过程数据作为一个二维灰度图,直接输入卷积自编码器中进行无监督学习,避免数据展开导致信息丢失,无需划分阶段减少建模工作量,深层地提取了过程变量的变化特征.然后利用OCSVM对所提取特征设计统计量并确定控制限实现了故障监测.在青霉素发酵仿真数据及rhG-CSF生产现场实验数据上分别进行了验证,与MPCA、多阶段MPCA和BDPCA方法的结果比较,有效降低了故障误报警率和漏报警率,具有较强的应用价值.

参考文献(References)

[1] 池荣虎, 侯忠生, 黄彪. 间歇过程最优迭代学习控制的发展: 从基于模型到数据驱动[J]. 自动化学报, 2017, 43(6): 917-932.
(Chi R H, Hou Z S, Huang B. Optimal iterative learning control of batch processes: From model-based to data-driven[J]. Acta Automatica Sinica, 2017, 43(6): 917-932.)

[2] 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.)

[3] Ge Z Q. Review on data-driven modeling and monitoring for plant-wide industrial processes[J]. Chemometrics and Intelligent Laboratory Systems, 2017, 171: 16-25.

[4] Ding S X. Data-driven design of monitoring and diagnosis systems for dynamic processes: A review of subspace technique based schemes and some recent results[J]. Journal of Process Control, 2014, 24(2): 431-449.

[5] 柴天佑. 工业过程控制系统研究现状与发展方向[J]. 中国科学: 信息科学, 2016, 46(8): 1003-1015.
(Chai T Y. Industrial process control systems: Research status and development direction[J]. Scientia Sinica (Information), 2016, 46(8): 1003-1015.)

[6] Yang C M, Hou J. Fed-batch fermentation penicillin process fault diagnosis and detection based on support vector machine[J]. Neurocomputing, 2016, 190: 117-123.

[7] Wang J, Hu Y, Shi H B. Fault detection for batch processes based on gaussian mixture model[J]. Acta Automatica Sinica, 2015, 41(5): 899-905.

[8] Xiong W L, Guo X G. A process on-line monitoring method based on multi-mode identificatio[J]. Control and Decision, 2018, 33(3): 403-412.

[9] Rendall R, Chiang L H, Reis M S. Data-driven methods

- for batch data analysis — A critical overview and mapping on the complexity scale[J]. *Computers & Chemical Engineering*, 2019, 124: 1-13.
- [10] Qin S J. Survey on data-driven industrial process monitoring and diagnosis[J]. *Annual Reviews in Control*, 2012, 36(2): 220-234.
- [11] Qin Y, Zhao C H, Wang X Z, et al. Subspace decomposition and critical phase selection based cumulative quality analysis for multiphase batch processes[J]. *Chemical Engineering Science*, 2017, 166: 130-143.
- [12] Peres F A P, Peres T N, Fogliatto F S, et al. Fault detection in batch processes through variable selection integrated to multiway principal component analysis[J]. *Journal of Process Control*, 2019, 80: 223-234.
- [13] Jiao J, Yu H, Wang G. A quality-related fault detection approach based on dynamic least squares for process monitoring[J]. *IEEE Transactions on Industrial Electronics*, 2016, 63(4): 2625-2632.
- [14] 赵春晖, 王福利, 姚远, 等. 基于时段的间歇过程统计建模、在线监测及质量预报[J]. *自动化学报*, 2010, 36(3): 366-374.
(Zhao C H, Wang F L, Yao Y, et al. Phase-based statistical modeling, online monitoring and quality prediction for batch processes[J]. *Acta Automatica Sinica*, 2010, 36(3): 366-374.)
- [15] Gao X J, Yang Y X, Wang P, et al. Fault monitoring of fermentation process based on extended kernel entropy load matrix[J]. *Control Theory & Applications*, 2018, 35(6): 813-821.
- [16] Qin Y, Zhao C H, Gao F R. An iterative two-step sequential phase partition (ITSP) method for batch process modeling and online monitoring[J]. *AIChE Journal*, 2016, 62(7): 2358-2373.
- [17] Zhao C H, Wang F L, Lu N Y, et al. Stage-based soft-transition multiple PCA modeling and on-line monitoring strategy for batch processes[J]. *Journal of Process Control*, 2007, 17(9): 728-741.
- [18] Gu J X, Wang Z H, Kuen J, et al. Recent advances in convolutional neural networks[J]. *Pattern Recognition*, 2017, 77: 354-377.
- [19] Liu Y, Fan Y, Chen J H. Flame images for oxygen content prediction of combustion systems using DBN[J]. *Energy & Fuels*, 2017, 31(8): 8776-8783.
- [20] Liu Y, Yang C, Gao Z L, et al. Ensemble deep kernel learning with application to quality prediction in industrial polymerization processes[J]. *Chemometrics and Intelligent Laboratory Systems*, 2018, 174: 15-21.
- [21] Hoang D T, Kang H J. A survey on deep learning based bearing fault diagnosis[J]. *Neurocomputing*, 2018, 335: 327-335.
- [22] Xuan Q, Chen Z Z, Liu Y, et al. Multiview generative adversarial network and its application in pearl classification[J]. *IEEE Transactions on Industrial Electronics*, 2019, 66(10): 8244-8252.
- [23] Masci J, Meier U, Ciresan D, et al. Stacked convolutional auto-encoders for hierarchical feature extraction[C]. *The 21st International Conference on Artificial Neural Networks*. Berlin: Springer-Verlag, 2011: 52-59.
- [24] Lin X C, Tang Y, Tianfield H, et al. A novel approach to reconstruction based saliency detection via convolutional neural network stacked with auto-encoder[J]. *Neurocomputing*, 2019, 349: 145-155.
- [25] Ribeiro M, Lazzaretti A E, Lopes H S. A study of deep convolutional auto-encoders for anomaly detection in videos[J]. *Pattern Recognition Letters*, 2018, 105: 13-22.
- [26] Yu J B, Zheng X Y, Liu J T. Stacked convolutional sparse denoising auto-encoder for identification of defect patterns in semiconductor wafer map[J]. *Computers in Industry*, 2019, 109: 121-133.
- [27] Mao T, Zhang Y, Ruan Y F, et al. Feature learning and process monitoring of injection molding using convolution-deconvolution auto encoders[J]. *Computers and Chemical Engineering*, 2018, 118: 77-90.
- [28] Mahadevan S, Shah S L. Fault detection and diagnosis in process data using one-class support vector machines[J]. *Journal of Process Control*, 2009, 19(10): 1627-1639.
- [29] Xiao Y C, Wang H G, Zhang L, et al. Two methods of selecting Gaussian kernel parameters for one-class SVM and their application to fault detection[J]. *Knowledge-Based Systems*, 2014, 59: 75-84.
- [30] Gülnur B, Cenk Ü, Cinar A. A modular simulation package for fed-batch fermentation: Penicillin production[J]. *Computers & Chemical Engineering*, 2002, 26(11): 1553-1565.
- [31] Vanlaer J, Gins G, Van Impe J F M. Comparison of MPCAV, ARPCA, and BDPCA fault detection performance in a fed-batch penicillin fermentation process[C]. *Proceedings of the 7th IFAC Symposium on Fault Detection, Supervision and Safety of Technical Processes*. Barcelona: Elsevier, 2009.

作者简介

张海利(1992—), 女, 博士生, 从事工业过程故障监测及诊断的研究, E-mail: zhanghaili999@163.com;

王普(1962—), 男, 研究员, 博士生导师, 从事集散系统、现场总线系统、组态软件、EMS、楼宇自动化系统、社区信息化和智能化等研究, E-mail: wangpu@bjut.edu.cn;

高学金(1973—), 男, 教授, 博士, 从事发酵过程建模、监控与故障诊断, 生物传感器研制, 地铁车站通风空调系统节能与故障诊断, 列车自动驾驶仿真等研究, E-mail: gaouxuejin@bjut.edu.cn;

齐咏生(1975—), 男, 教授, 博士, 从事工业过程的故障监测与诊断、风力发电系统故障监测与诊断、移动机器人的智能控制等研究, E-mail: qyslyt@163.com;

高慧慧(1991—), 女, 讲师, 博士, 从事机器学习、深度学习及其在智能制造、智慧交通领域的应用等研究, E-mail: gaohh@bjut.edu.cn.

(责任编辑: 闫 妍)