

DOI: 10.19650/j.cnki.cjsi.J2311194

基于分层分块堆叠状态相关降噪自编码器的 流程工业过程运行状态评价*

刘炎¹, 马喆¹, 褚菲², 王福利¹

(1. 东北大学信息科学与工程学院 沈阳 110819; 2. 中国矿业大学信息与控制工程学院 徐州 221116)

摘要:本文针对不同运行状态数据差异度小、数据易受强噪声干扰而且具有多工序的流程工业过程,提出了一种基于分层分块堆叠状态相关降噪自编码器(HMSPDAE)的过程运行状态评价方法。首先,根据工艺特性对全流程进行层次结构划分。然后,提出一种堆叠状态相关降噪自编码器模型,用于提取各个子工序及全流程过程数据中与运行状态密切相关的深层特征,进而建立基于HMSPDAE的全流程评价模型。所提方法可以有效降低模型复杂度、增强模型的可解释性。最后,以湿法冶金过程为背景进行仿真验证,结果表明HMSPDAE在两个不同实验中的评价准确率分别达到99.5%和99.38%,均优于其他方法,验证了所提方法的有效性和优越性。

关键词:过程运行状态评价; 分层分块; 流程工业; 状态相关; 堆叠自编码器

中图分类号: TP13 TH17 **文献标识码:** A **国家标准学科分类代码:** 510.80

Plant-wide process operating performance assessment based on hierarchical multi-block stacked performance-relevant denoising auto-encoder

Liu Yan¹, Ma Zhe¹, Chu Fei², Wang Fuli¹

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110819, China;

2. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou 221116, China)

Abstract: In this article, a hierarchical multi-block stacked performance-relevant denoising auto-encoder (HMSPDAE) is proposed to evaluate the process operating performance for plant-wide industrial processes with multiple sub-processes, low data difference among different operating performances, and strong noise interference. First, the whole process is divided into a hierarchical structure according to the process characteristics. Then, a method of stacked performance-relevant denoising auto-encoder is proposed to extract the performance-relevant deep features from the process data which are used to realize the operating performance assessment of each sub-process as well as the whole process. In further, a HMSPDAE-based whole-process evaluation model is formulated. The proposed method can effectively reduce the model complexity and enhance the interpretability of the model. Finally, simulation experiments are conducted in the wet metallurgical process. The results show that the assessment accuracy of HMSPDAE reaches 99.5% and 99.38% in two different experiments, which are both better than other methods.

Keywords: process operating performance assessment; hierarchical multiblock; plant-wide industrial process; performance-relevant; stacked auto-encoder

0 引言

为了获得优质产品和更好的经济效益,近年来面向工业生产过程的运行状态评价受到了越来越多的关注^[1-3]。过程运行状态评价是指在保证生产过程正常运

行的基础上,对实际生产运行状态进行更加精细的划分和识别,获得如优、良、中、差等评价结果,并据此调整与优化生产运行,保证生产过程能够运行在较好的状态。这有助于提升产品质量和企业的经济效益,具有重要的理论价值和现实意义。

收稿日期:2023-03-20 Received Date: 2023-03-20

* 基金项目:国家重点研发计划(2021YFF0602404)、国家自然科学基金(62073060,61973057,61973304)、高层次人才项目(DZXX-045)资助

近年来,针对工业过程运行状态评价问题,相关学者做了广泛的研究。考虑到实际工业数据中包含大量与运行状态无关的信息,Liu等^[4]提出基于优性相关变异信息的运行状态评价方法,从过程数据中提取与运行状态紧密相关的信息,消除无关信息的干扰,提高了评价结果的准确性。针对多模态工业过程,Lin等^[5]提出了基于稳定模态的中心马氏距离的评价方法;邹筱瑜等^[6]提出了一种基于贝叶斯推理和高斯混合模型的评价方法,有效避免了模态划分问题。为了进一步提高模型的可解释性,Zou等^[7]提出了一种将主成分分析和动态因果图相结合的评价方法。对于非高斯分布数据,Liu等^[8]提出了一种状态相关独立成分分析的过程运行状态评价方法。此外,Chu等^[9-10]提出了最小成本建模和改进的鲁棒全核潜变量投影算法,以解决过程变量间呈非线性相关的复杂工业过程运行状态评价问题。为分析过程数据中的动态特性,Zou等^[11]采用典型变量分析和慢特征分析相结合的方法,对工业过程进行细致的运行状态评价。为建立稳定可靠的评价模型,褚菲等^[12]在稀疏降噪自编码器模型中引入综合经济指标,迫使模型学习与综合经济指标相关的数据特征,提高了评价结果的准确性。然而,上述评价方法未考虑多个子工序间的共同作用对全流程运行状态的影响,并不适合流程工业过程的运行状态评价。

流程工业过程具有多变量、多工序、机理复杂等特点。由于不同子过程之间相互影响、相互制约,且过程变量间具有复杂的非线性相关关系,如不加区分地将全部过程变量直接用来建立一个复杂的全流程评价模型,不仅精度上难以保证,而且不考虑一系列的中间工艺不利于精准定位非优原因,导致模型可解释性变差。为了简化流程工业过程研究的复杂度,Westerhuis等^[13]提出了一种基于一定规则将一个长流程拆分为多个层次和子块的方法。其主要内容是将过程变量集合分割为若干个不相交的过程变量子集合,从而获得关于流程工业过程的局部和全局的信息。人们利用这种方法解决了变量选择^[14]、过程监测^[15]、优化^[16]等问题。Liu等^[17]和Zou等^[18]分别将这种方法应用于流程工业过程的运行状态评价中,在简化了问题求解规模的同时,获得了令人满意的评价结果。然而,从模型结构来看,上述评价方法均属于浅层特征提取和评价方法。当不同状态等级数据之间的差异度较小时,浅层模型只进行了一次特征提取,对变量间复杂非线性关系的表示能力有限且泛化能力较差,难以提取不同状态等级下更具区分度的深层本质特征,影响评价结果的准确性。

近年来,深度学习^[19-20]作为机器学习的一个重要分支受到了广泛关注。深度学习模型是一种利用多层神经网络来从数据中自动学习特征和规律的算法,通过多层的非线性映射来发现数据的内在结构和表达,无须具备

特征设计知识以及关于研究对象的先验知识。深度学习模型自动提取反映问题本质的深层特征,为不同状态等级的准确区分提供了重要的技术支持。目前,常见的深度学习算法主要包括堆叠自编码器(stacked auto-encoder, SAE)^[21]、卷积神经网络^[22]、长短期记忆网络^[23]等。其中,基于卓越的非线性处理能力和能够揭示高维数据中的低维结构的出色性能,SAE及其相关模型被广泛用于解决工业软测量^[24-25]、故障诊断^[26]、运行状态评价^[27-28]等问题。Yuan等^[25]将质量信息引入到传统SAE中有监督地指导特征提取,提出了基于堆叠有监督自编码器的质量预测方法。为了有效利用多源监测数据,蒋爱国等^[26]提出了一种多模态堆叠自编码器模型,融合了多传感器信息,实现了电机故障的有效识别。为了克服噪声数据的影响,Vincent等^[29]提出了堆叠降噪自编码器(stacked denoising auto-encoder, SDAE),提升了SAE从噪声干扰数据中提取本质特征的能力。在过程运行状态评价方面,为了提升了评价模型的鲁棒性,Bu等^[27]提出了一种堆叠稀疏降噪自编码器的方法。然而,该方法在特征提取时,由于未考虑所提特征与过程运行状态的相关性,在一定程度上影响了评价结果的准确性。

实际工业数据中,并非所有过程信息都与过程运行状态密切相关,那些与运行状态无关的信息不仅模糊了不同状态等级数据特征之间的差异度、无助于状态等级的精准区分,还会影响评价方法的灵敏性和准确性。此外,为了增强评价模型对噪声数据的抗干扰能力,需要一种具有鲁棒性的深层特征提取方法,以提高评价结果的准确性和可靠性。本文提出一种基于分层分块堆叠状态相关降噪自编码器(hierarchical multiblock stacked performance-relevant denoising auto-encoder, HMSPDAE)的流程工业过程运行状态评价方法。首先,针对流程工业过程的多工序、多变量、同一工序内变量耦合程度高、不同工序间变量耦合程度低的特点,对全流程进行层次结构分解,划分为工序层和全流程层,从而降低问题分析的难度,提高模型的可解释性。然后,分别建立基于堆叠状态相关降噪自编码器(stacked performance-relevant denoising auto-encoder, SPDAE)的各个子工序和全流程运行状态评价模型,实现基于HMSPDAE的全流程运行状态评价。本文的主要贡献包括:1)提出了一种状态相关降噪自编码器网络模型,在原始自编码器模型的基础上,在预训练过程中同时引入了状态等级标签和数据损坏环节;2)为了提取状态相关的深层特征,通过逐层堆叠多个状态相关的自编码器,构建了具备深层特征提取能力的SPDAE模型;3)提出了一种基于HMSPDAE的流程工业过程运行状态评价方法,为解决流程工业过程运行状态评价中非线性和噪声干扰的问题提供了一种新途径。

1 预备知识

1.1 降噪自编码器

自编码器(auto-encoder, AE)是包含一个隐含层的前馈无监督神经网络,通过编码器在隐含层提取输入数据的特征,再用该特征通过解码器重构原始的输入数据,并通过优化原始输入数据与重构数据之间的均方误差,优化网络参数,从而获得输入数据最优的特征表达。

降噪自编码器(denoising auto-encoder, DAE)是AE的一种衍生模型,其目的是提高AE对噪声数据的鲁棒性和泛化能力。相比于AE,DAE在特征提取之前增加了对原始输入数据的损坏环节,包括向原始输入数据中加入高斯噪声或随机置零等。将“损坏”的输入数据送入编码器,然后再通过解码器重构原始输入数据,从而建立更具鲁棒性的特征提取模型。DAE的网络结构如图1所示。

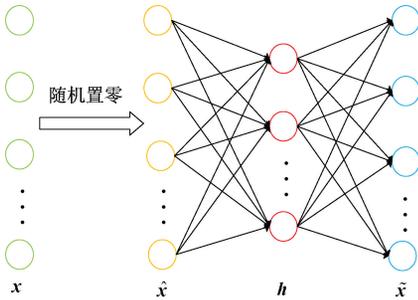


图1 DAE的示意图

Fig.1 Schematic diagram of DAE

DAE的编码过程为:

$$\mathbf{h} = f(\mathbf{W}\hat{\mathbf{x}} + \mathbf{b}) \quad (1)$$

其中, $f(\cdot)$ 为编码器激活函数, $\mathbf{W} \in R^{M_h \times M_x}$ 和 $\mathbf{b} \in R^{M_h}$ 分别为输入层到隐含层权重矩阵和偏置向量, M_x 是变量个数, M_h 表示隐含层的节点数, $\mathbf{x} \in R^{M_x}$ 和 $\hat{\mathbf{x}} \in R^{M_x}$ 分别表示原始输入数据和损坏后的输入数据, $\mathbf{h} \in R^{M_h}$ 为隐含层提取的特征向量。

DAE的解码过程为:

$$\hat{\mathbf{x}} = g(\tilde{\mathbf{W}}\mathbf{h} + \tilde{\mathbf{b}}) \quad (2)$$

其中, $g(\cdot)$ 为解码器激活函数, $\tilde{\mathbf{W}} \in R^{M_x \times M_h}$ 和 $\tilde{\mathbf{b}} \in R^{M_x}$ 分别为隐含层到输出层的权重矩阵和偏置向量, $\hat{\mathbf{x}} \in R^{M_x}$ 表示原始数据的重构向量。

对于包含 N 个样本的数据集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in R^{N \times M_x}$, 重构后的数据与原始输入数据之间的均方差可表

示为:

$$J_{DAE} = \frac{1}{2N} \sum_{n=1}^N \|\mathbf{x}_n - \hat{\mathbf{x}}_n\|^2 \quad (3)$$

其中, \mathbf{x}_n 和 $\hat{\mathbf{x}}_n$ 分别为 \mathbf{X} 中的第 n 个样本及其重构。

网络参数的优化需要利用反向传播(back propagation, BP)算法,通过不断迭代进行参数更新,减小重构误差,最终得到鲁棒的原始高维数据的低维特征表示。

1.2 堆叠降噪自编码器

SDAE是一种深度神经网络,它通过将多个DAE进行堆叠,实现了逐层的特征学习。它的训练过程包含无监督预训练(pretraining)和整体反向微调(fine-tuning)两个阶段。预训练时,SDAE将前一个DAE提取的隐含层特征作为下一个DAE的原始输入数据,参与下一个DAE的训练,逐层完成对每一个DAE的预训练。反向微调时,将预训练得到的每一个DAE的编码器参数保留下来,作为SDAE的初始化参数,再利用BP算法对整个网络进行反向微调,优化网络所有参数。

假设一个SDAE网络包含 K 个隐含层,将第 k 层被损坏后的输入记作 $\hat{\mathbf{H}}^{k-1} = [\hat{\mathbf{h}}_1^{k-1}, \hat{\mathbf{h}}_2^{k-1}, \dots, \hat{\mathbf{h}}_N^{k-1}]$, 其隐层特征记为 $\mathbf{H}^k = [\mathbf{h}_1^k, \mathbf{h}_2^k, \dots, \mathbf{h}_N^k]$, 输出为重构的 $k-1$ 层的隐层特征,记作 $\tilde{\mathbf{H}}^{k-1} = [\tilde{\mathbf{h}}_1^{k-1}, \tilde{\mathbf{h}}_2^{k-1}, \dots, \tilde{\mathbf{h}}_N^{k-1}]$ 。则第 k 个DAE预训练过程可表示为:

$$\mathbf{h}_n^k = f(\mathbf{W}^k \hat{\mathbf{h}}_n^{k-1} + \mathbf{b}^k) \quad (4)$$

$$\tilde{\mathbf{h}}_n^{k-1} = g(\tilde{\mathbf{W}}^k \mathbf{h}_n^k + \tilde{\mathbf{b}}^k) \quad (5)$$

其中, $n = 1, 2, \dots, N, k = 1, 2, \dots, K$, $\{\mathbf{W}^k, \mathbf{b}^k\}$ 和 $\{\tilde{\mathbf{W}}^k, \tilde{\mathbf{b}}^k\}$ 分别为第 k 个DAE的编码器和解码器参数。

按式(3)计算损失函数,利用BP算法进行参数更新,并据此方式完成全部DAE的预训练。

为了优化网络性能,在良好的初始参数下,进行反向微调,微调过程以有监督的方式进行。对于一个分类任务,通过在SDAE网络最后添加一个分类层,以SDAE提取的第 K 层特征 \mathbf{h}^K 作为输入预测原始数据的分类标签,基于交叉熵损失函数优化模型参数。

2 堆叠状态相关降噪自编码器

2.1 状态相关DAE模型

虽然DAE具有从损坏数据中提取原始输入数据的特征的能力,但由于DAE以无监督的方式进行训练,并不专注于不同状态等级信息的特征表示,导致所提特征中容易包含与运行状态无关的干扰信息,对评价结果的准确性产生不利的影响。面对此问题,本文提出一种状态相关降噪自编码器(performance-relevant denoising auto-encoder, PDAE)。与DAE相同,PDAE也包含一层隐含

层,且在输入层之前增加对数据的“损坏”环节。区别在于,PD AE 在输出层重构原始输入数据的同时,还依据隐含层特征对数据所属状态等级进行分类,这样设计的网络模型能够在提取原始数据本质特征的同时兼顾运行状态相关的特征信息,更利于准确区分不同状态等级。PD AE 的结构如图 2 所示。

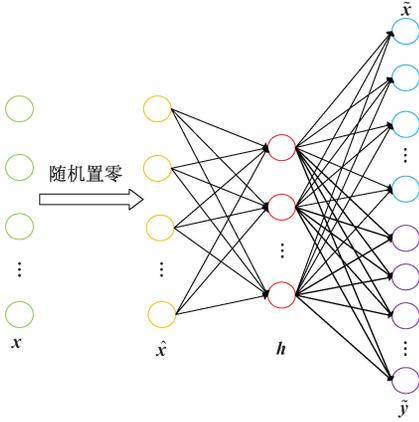


图 2 PD AE 的结构示意图

Fig. 2 Architecture diagram of PD AE

PD AE 的编码和解码过程如下:

$$\mathbf{h} = f(\mathbf{W}\hat{\mathbf{x}} + \mathbf{b}) \quad (6)$$

$$\tilde{\mathbf{x}} = g(\tilde{\mathbf{W}}_h \mathbf{h} + \tilde{\mathbf{b}}_h) \quad (7)$$

$$\tilde{\mathbf{y}} = \text{Softmax}(\tilde{\mathbf{W}}_y \mathbf{h} + \tilde{\mathbf{b}}_y) \quad (8)$$

其中, $\mathbf{W} \in R^{M_h \times M_x}$ 和 $\mathbf{b} \in R^{M_h}$ 分别为编码器权重矩阵和偏置向量, $\tilde{\mathbf{W}}_h \in R^{M_x \times M_h}$, $\tilde{\mathbf{b}}_h \in R^{M_x}$, $\tilde{\mathbf{W}}_y \in R^{n_{class} \times M_h}$, $\tilde{\mathbf{b}}_y \in R^{n_{class}}$ 分别为解码器重构原始输入和预测状态等级标签的参数, M_x, M_h, n_{class} 分别表示变量个数, 隐含层节点数以及状态等级个数, \mathbf{y} 是实际状态等级标签, 采用 one-hot 编码的形式, $\tilde{\mathbf{y}}$ 是模型输出的状态等级标签, $f(\cdot)$ 和 $g(\cdot)$ 为激活函数, 通常选用 sigmoid, Tanh 和 ReLU 等函数。SoftMax 函数的输出为样本属于每个状态等级的后验概率, 具体表示如下:

$$\text{Softmax}(\mathbf{x}) = \begin{bmatrix} p(y = 1 | \mathbf{x}; \boldsymbol{\theta}_s) \\ p(y = 2 | \mathbf{x}; \boldsymbol{\theta}_s) \\ \vdots \\ p(y = n_{class} | \mathbf{x}; \boldsymbol{\theta}_s) \end{bmatrix} =$$

$$\frac{1}{\sum_{n=1}^{n_{class}} e^{\boldsymbol{\theta}_n^T \mathbf{x}}} \begin{bmatrix} e^{\boldsymbol{\theta}_1^T \mathbf{x}} \\ e^{\boldsymbol{\theta}_2^T \mathbf{x}} \\ \vdots \\ e^{\boldsymbol{\theta}_{n_{class}}^T \mathbf{x}} \end{bmatrix} \quad (9)$$

其中, $\boldsymbol{\theta}_s = \{\boldsymbol{\theta}_1, \boldsymbol{\theta}_2, \dots, \boldsymbol{\theta}_{n_{class}}\}$ 是模型参数, $p(y = c | \mathbf{x}; \boldsymbol{\theta}_s)$, $c = 1, 2, \dots, n_{class}$, 为 \mathbf{x} 属于第 c 类的后验概率。

构造 PD AE 的损失函数如下:

$$J_{PD AE} = J_1 + J_2 = \frac{1}{2N} \sum_{n=1}^N \|\tilde{\mathbf{x}}_n - \mathbf{x}_n\|^2 - \frac{1}{N} \sum_{n=1}^N \mathbf{y}_n \log \tilde{\mathbf{y}}_n \quad (10)$$

其中, \mathbf{y}_n 为第 n 个样本的真实标签, $\tilde{\mathbf{y}}_n$ 为第 n 个样本的预测标签; $J_1 = \sum_{n=1}^N \|\tilde{\mathbf{x}}_n - \mathbf{x}_n\|^2 / 2N$ 是输入数据的重构损失, 用于衡量原始样本与重构样本之间的重构误差; $J_2 = -\sum_{n=1}^N \mathbf{y}_n \log \tilde{\mathbf{y}}_n / N$ 是评价结果的交叉熵分类损失。

2.2 SP DAE 模型

鉴于单个 PD AE 模型无法充分学习高维输入数据中的状态相关深层特征, 因此采用逐层堆叠的方法将多个 PD AE 模型组合成深层的 SP DAE 网络。通过逐层传递和提炼信息, 使网络具备更强大的能力, 更好地学习和表达状态相关的深层特征。SP DAE 的网络结构如图 3 所示。

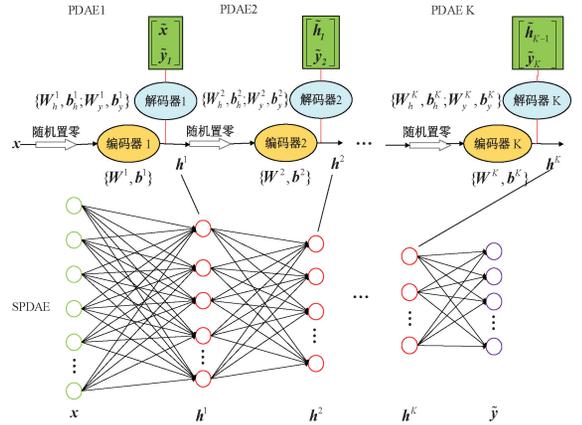


图 3 SP DAE 的网络训练示意图

Fig. 3 Training diagram of SP DAE

首先, 用输入数据 \mathbf{X} 和状态等级标签 \mathbf{Y} 对第一个 PD AE (PD AE 1) 进行预训练。获得第一层状态相关特征 $\mathbf{H}^1 = [h_1^1, h_2^1, \dots, h_N^1]$, 其中 h_n^1 表示从 x_n 中提取的状态相关特征。 $\tilde{\mathbf{X}} = [\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_N]$ 和 $\tilde{\mathbf{Y}}^1 = [\tilde{y}_1^1, \tilde{y}_2^1, \dots, \tilde{y}_N^1]$ 分别表示 PD AE 1 重构的原始数据和 PD AE 1 预测的等级标签。将 PD AE 1 的参数集记为 $\{\mathbf{W}^1, \mathbf{b}^1; \tilde{\mathbf{W}}_h^1, \tilde{\mathbf{b}}_h^1; \tilde{\mathbf{W}}_y^1, \tilde{\mathbf{b}}_y^1\}$, 其中 $\{\mathbf{W}^1, \mathbf{b}^1\}$ 表示编码器参数, $\{\tilde{\mathbf{W}}_h^1, \tilde{\mathbf{b}}_h^1\}$ 表示解码器中重构原始数据的参数, $\{\tilde{\mathbf{W}}_y^1, \tilde{\mathbf{b}}_y^1\}$ 表示解码器中预测状态等级标签的参数。然后, 利用第一层状态相关特征 \mathbf{H}^1 和状态等级标签 \mathbf{Y} 对 PD AE 2 进行预训练。

假设前 $k-1$ 个 PD AE 完成了预训练, 将第 $k-1$ 层状态相关特征为 $\mathbf{H}^{k-1} = [h_1^{k-1}, h_2^{k-1}, \dots, h_N^{k-1}]$ 用于 PD AE k 的预训练。PD AE k 的输入层、隐含层和输出层之间的关系如下:

$$h_n^k = f(\mathbf{W}^k \hat{h}_n^{k-1} + \mathbf{b}^k) \quad (11)$$

$$\hat{\mathbf{h}}_n^{k-1} = g(\tilde{\mathbf{W}}_h^k \mathbf{h}_n^k + \tilde{\mathbf{b}}_h^k) \quad (12)$$

$$\tilde{\mathbf{y}}_n^k = \text{Softmax}(\tilde{\mathbf{W}}_y^k \mathbf{h}_n^k + \tilde{\mathbf{b}}_y^k) \quad (13)$$

其中, $k = 1, 2, \dots, K$; $\hat{\mathbf{h}}_n^{k-1}$ 为损坏后的 \mathbf{h}_n^{k-1} 。值得注意的是 $\mathbf{h}_n^0 = \mathbf{x}_n$, 即为原始数据, 相应的 $\hat{\mathbf{h}}_n^0$ 即为原始数据损坏后的样本。 $\tilde{\mathbf{H}}^{k-1} = [\tilde{\mathbf{h}}_1^{k-1}, \tilde{\mathbf{h}}_2^{k-1}, \dots, \tilde{\mathbf{h}}_n^{k-1}]$ 表示对第 k 层输入数据的重构值, $\tilde{\mathbf{Y}}^k = [\tilde{\mathbf{y}}_1^k, \tilde{\mathbf{y}}_2^k, \dots, \tilde{\mathbf{y}}_n^k]$ 是 PDAE k 预测的状态等级标签。PDAE k 的参数集记为 $\{\mathbf{W}^k, \mathbf{b}^k; \tilde{\mathbf{W}}_h^k, \tilde{\mathbf{b}}_h^k; \tilde{\mathbf{W}}_y^k, \tilde{\mathbf{b}}_y^k\}$ 。

PDAE k 的损失函数如下:

$$J_{\text{PDAE}}^k = \frac{1}{2N} \sum_{n=1}^N \|\tilde{\mathbf{h}}_n^{k-1} - \mathbf{h}_n^{k-1}\|^2 - \frac{1}{N} \sum_{n=1}^N \mathbf{y}_n \log \tilde{\mathbf{y}}_n^k \quad (14)$$

当全部 PDAE 完成预训练后, 保留编码器参数 $\{\mathbf{W}^1, \mathbf{b}^1; \mathbf{W}^2, \mathbf{b}^2; \dots; \mathbf{W}^K, \mathbf{b}^K\}$ 作为 SPDAE 网络的初始参数。经过逐层堆层, 与运行状态相关的重要特征随着网络层数的增加被进一步地凝练和提取。在 SPDAE 网络的顶层添加一个 SoftMax 分类层, 并对整个模型进行反向微调。微调之前, 分类层的参数 \mathbf{W}^F 和 \mathbf{b}^F 随机初始化。随后利用 BP 算法优化 SPDAE 网络的参数。微调过程的损失函数为:

$$J_{\text{SPDAE}} = -\frac{1}{N} \sum_{n=1}^N \mathbf{y}_n \log \tilde{\mathbf{y}}_n \quad (15)$$

3 基于 HMSPPDAE 的流程工业过程运行状态评价

对于全流程工业过程, 同一子工序内, 过程变量之间的相互影响和相互依赖较为显著。而在不同子工序之间, 由于操作和条件的变化, 过程变量之间的相关关系相对较弱。如果对全流程进行评价建模时不加区分地处理, 会带来一些问题。首先, 由于工序众多, 直接对全流程进行建模不利于提取子工序内部的关键特征。其次, 全流程模型需要处理大量的输入变量和复杂的相互关系, 导致模型的训练和预测过程变得更加复杂, 而且难以清晰解释模型对于特定子工序或变量的影响和决策依据。因此, 本文提出一种基于 HMSPPDAE 的全流程过程运行状态评价方法。该方法根据全流程工艺设计和机理, 对其进行合理的层次结构划分, 分别建立子工序层和全流程层评价模型。基于 HMSPPDAE 的全流程过程运行状态评价具体可分为离线建模和在线评价 2 个步骤。

3.1 基于 HMSPPDAE 的离线建模

对流程工业过程进行层次结构分解, 划分为全流程层和工序层。工序层中, 根据生产环节或设备之间关联性强弱划分成不同子工序, 分别建立基于 SPDAE 的子工序评价模型, 提取不同子工序内与运行状态相关的深层特征, 实现对各子工序的运行状态评价。之后, 考虑各

子工序间的相互影响, 融合各子工序提取的特征, 建立基于 SPDAE 的全流程层评价模型。HMSPPDAE 建模流程如图 4 所示。

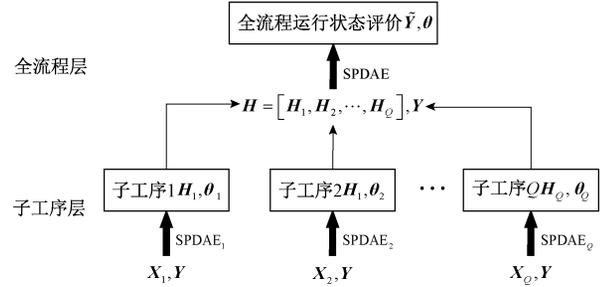


图4 HMSPPDAE 建模流程

Fig. 4 Modeling flow of HMSPPDAE

假设流程工业过程被划分为 Q 个子工序。首先, 建立子工序层的评价模型。将每个子工序的过程数据表示为 $\mathbf{X}_q = [\mathbf{x}_{1,q}, \mathbf{x}_{2,q}, \dots, \mathbf{x}_{N,q}] \in R^{N \times M_q}$, $q = 1, 2, \dots, Q$, 其中 $\sum_{q=1}^Q M_q = M_x$ 。将 \mathbf{X}_q 和实际状态等级标签 \mathbf{Y} 作为输入, 采用 SPDAE 对各个子工序分别建立评价模型, SPDAE 网络编码器参数 θ_q , $q = 1, 2, \dots, Q$ 即为子工序评价模型的参数。

然后, 建立全流程层评价模型。将各个子工序提取的状态相关特征融合为 $\mathbf{H} = [\mathbf{H}_1, \mathbf{H}_2, \dots, \mathbf{H}_Q] \in R^{N \times M_h}$, $M_h = \sum_{q=1}^Q M_{h,q}$, 其中 $M_{h,q}$ 为第 q 个子工序 SPDAE 模型最后一个隐含层的节点数。将融合后的特征 \mathbf{H} 以及实际状态等级标签 \mathbf{Y} 作为输入, 利用 SPDAE 建立全流程层评价模型。

3.2 基于 HMSPPDAE 的在线评价

对于在线数据 \mathbf{x}_{new} , 将对应于第 q 个子工序的数据 $\mathbf{x}_{new,q}$, $q = 1, 2, \dots, Q$, 输入到第 q 个子工序的 SPDAE 评价模型中, 得到:

$$\mathbf{h}_{new,q}^1 = f(\mathbf{W}_q^1 \mathbf{x}_{new,q} + \mathbf{b}_q^1) \quad (16)$$

$$\mathbf{h}_{new,q}^2 = f(\mathbf{W}_q^2 \mathbf{h}_{new,q}^1 + \mathbf{b}_q^2) \quad (17)$$

⋮

$$\mathbf{h}_{new,q}^{K_q} = f(\mathbf{W}_q^{K_q} \mathbf{h}_{new,q}^{K_q-1} + \mathbf{b}_q^{K_q}) \quad (18)$$

$$\tilde{\mathbf{y}}_{new,q} = \text{Softmax}(\mathbf{W}_q^F \mathbf{h}_{new,q}^{K_q} + \mathbf{b}_q^F) \quad (19)$$

其中, $\theta_q = \{\mathbf{W}_q^1, \mathbf{b}_q^1; \mathbf{W}_q^2, \mathbf{b}_q^2; \dots; \mathbf{W}_q^{K_q}, \mathbf{b}_q^{K_q}; \mathbf{W}_q^F, \mathbf{b}_q^F\}$ 是第 q 个子工序评价模型参数集, K_q 表示第 q 个子工序评价模型的隐含层数。

第 q 个子工序的评价结果为 $\tilde{\mathbf{y}}_{new,q}$ 中最大元素的索引, 即:

$$\text{Result}_{new,q} = \text{argmax} \{c | \tilde{y}_{new,q,c}, c = 1, 2, \dots, n_{class}\} \quad (20)$$

其中, $\tilde{y}_{new,q,c}$ 是 $\tilde{y}_{new,q}$ 中第 c 个元素。

进一步地,将各个子工序提取的最后一个隐含层特

征合并为 $\mathbf{h}_{new} = [\mathbf{h}_{new,1}^{K_1}, \mathbf{h}_{new,2}^{K_2}, \dots, \mathbf{h}_{new,Q}^{K_Q}]$, 并将 \mathbf{h}_{new} 输入到全流程层 SPDAE 评价模型中, 得到:

$$\mathbf{h}_{new}^1 = f(\mathbf{W}^1 \mathbf{h}_{new} + \mathbf{b}^1) \quad (21)$$

$$\mathbf{h}_{new}^2 = f(\mathbf{W}^2 \mathbf{h}_{new}^1 + \mathbf{b}^2) \quad (22)$$

⋮

$$\mathbf{h}_{new}^{K'} = f(\mathbf{W}^{K'} \mathbf{h}_{new}^{K'-1} + \mathbf{b}^{K'}) \quad (23)$$

$$\tilde{y}_{new} = \text{Softmax}(\mathbf{W}^{F'} \mathbf{h}_{new}^{K'} + \mathbf{b}^{F'}) \quad (24)$$

$$\text{Result}_{new} = \text{argmax} \{c | \tilde{y}_{new,c}, c = 1, 2, \dots, n_{class}\} \quad (25)$$

其中, $\theta = \{\mathbf{W}^1, \mathbf{b}^1; \mathbf{W}^2, \mathbf{b}^2; \dots; \mathbf{W}^{K'}, \mathbf{b}^{K'}; \mathbf{W}^{F'}, \mathbf{b}^{F'}\}$ 是全流程层评价模型参数集, K' 为全流程层评价模型的隐含层数。

若全流程层评价为优, 则认为当前过程运行状态是令人满意的; 若全流程层评价结果为非优, 则需进一步查看各个子工序的运行状态, 并根据子工序评价结果判断导致全流程运行状态非优的具体子工序。

4 湿法冶金过程中的仿真验证

4.1 工艺过程简介

湿法冶金是一个复杂的化工过程, 伴随固、液混合, 受到许多因素的影响。该过程的反应机理极其复杂, 反应涉及力学、物理学、化学等过程, 并伴有随机因素。金湿法冶金全流程主要包括一浸一洗子工序、二浸二洗子工序和锌粉置换子工序。生产过程中, 首先对富集后的金精矿进行调浆处理。然后, 将矿浆依次注入一浸一洗子工序的 4 个浸出槽中, 同时加入氰化钠和氧气。精矿中的金在每个浸出槽里与氰化钠发生浸出反应, 氧提供氧化还原电位来促进反应, 实现精矿中的金和杂质的分离。之后, 将矿浆送入压滤机中, 溢流含金氰络离子的溶液流入锌粉置换子工序, 产出的滤饼经调浆处理后送往二浸二洗子工序。二浸二洗子工序的工艺机理与一浸一洗子工序相同, 其目的是进一步分离精矿中剩余的金与杂质, 两浸两洗的工艺设置保证了黄金的浸出率。在锌粉置换子工序中, 含金氰络离子的溶液与锌粉发生置换反应, 并经过板框压滤机的固液分离, 形成金泥, 从而实现金精矿的分离和富集。本文用于运行状态评价的过程变量列于表 1。

4.2 离线建模

从历史生产数据库中采集用于模型训练和在线测试的样本共计 2 564 个, 其中训练集包含 2 164 个样本, 涵盖“差”、“一般”、“良”、“次优”、“优”5 个状态等级, 相对应的状态等级标签为 1、2、3、4、5。离线建立网络模型时, 进一步将训练集按照 4:1 的比例进行划分, 前者用

表 1 过程变量

Table 1 Process variables

序号	工序	过程变量	单位
1		矿浆浓度	w. t. %
2		第一浸出槽氰化钠流量	mL·min ⁻¹
3		第二浸出槽氰化钠流量	mL·min ⁻¹
4		第四浸出槽氰化钠流量	mL·min ⁻¹
5		第一浸出槽空气流量	m ³ ·h ⁻¹
6		第二浸出槽空气流量	m ³ ·h ⁻¹
7		第三浸出槽空气流量	m ³ ·h ⁻¹
8	一浸一洗	第四浸出槽空气流量	m ³ ·h ⁻¹
9		第一浸出槽溶解氧浓度	mg·L ⁻¹
10		第一浸出槽氰根离子浓度	mg·L ⁻¹
11		第四浸出槽氰根离子浓度	mg·L ⁻¹
12		浸出槽一上方氧化氢气体浓度	mg·L ⁻¹
13		立式压滤机给料压力	MPa
14		立式压滤机挤压压力	MPa
15		立式压滤机液压压力	MPa
16		矿浆浓度	w. t. %
17		第一浸出槽氰化钠流量	mL·min ⁻¹
18		第二浸出槽氰化钠流量	mL·min ⁻¹
19		第四浸出槽氰化钠流量	mL·min ⁻¹
20		第一浸出槽空气流量	m ³ ·h ⁻¹
21		第二浸出槽空气流量	m ³ ·h ⁻¹
22		第三浸出槽空气流量	m ³ ·h ⁻¹
23	二浸二洗	第四浸出槽空气流量	m ³ ·h ⁻¹
24		第一浸出槽溶解氧浓度	mg·L ⁻¹
25		第一浸出槽氰根离子浓度	mg·L ⁻¹
26		第四浸出槽氰根离子浓度	mg·L ⁻¹
27		浸出槽一上方氧化氢气体浓度	mg·L ⁻¹
28		立式压滤机给料压力	MPa
29		立式压滤机挤压压力	MPa
30		立式压滤机液压压力	MPa
31		脱氧塔压力	KPa
32		贵液金氰络合物浓度	mg·L ⁻¹
33	锌粉置换	贫液金氰络合物浓度	mg·L ⁻¹
34		锌粉添加量	Kg·h ⁻¹
35		板框压滤机液压压力	MPa

于模型训练, 后者用于模型校验, 以确定合适的网络超参数。训练过程中, 首先对数据进行标准化预处理, 预处理后的数据具有零均值和单位方差。然后, 采用随机置零

的方式对数据进行损坏,损坏比例设为 20%。最后,根据生产工艺,将训练数据划分为 3 个子数据集,分别对应一浸一洗子工序、二浸二洗子工序、锌粉置换子工序,用于建立基于 SPDAE 的子工序及全流程层评价模型。

仿真实验环境为,软件平台:PyCharm 2021.1.1, Python3.8;硬件平台:CPU: Intel i5-11300H (3.10 GHz);RAM:16.0 GB;操作系统:Windows 10。

由于深度神经网络的拓扑结构和超参数对于网络的性能有很大的影响,根据模型在验证集上的测试结果,确定了各子工序及全流程层评价模型的超参数如表 2 所示。

表 2 HMSPPDAE 的超参数

Table 2 Hyperparameters of HMSPPDAE

子工序或全流程层	参数名称	参数值
一浸一洗 二浸二洗	输入层节点数	15
	第一个隐含层节点数	12
	第二个隐含层节点数	9
	第三个隐含层节点数	5
	输出层节点数	5
	预训练学习率	0.03
	微调学习率	0.015
锌粉置换	输入层节点数	5
	隐含层节点数	4
	输出层节点数	5
	学习率	0.015
全流程层	输入层节点数	14
	第一个隐含层节点数	11
	第二个隐含层节点数	8
	第三个隐含层节点数	5
	输出层节点数	5
	预训练学习率	0.045
	微调学习率	0.01
共用参数	Batch Size	16
	预训练 Epoch	100
	微调 Epoch	150

图 5 展示了预训练后,微调过程中的交叉熵损失和验证集评价准确率的变化。从 3 个子工序和全流程层的训练过程来看,网络在第 60 轮就已经接近收敛。其中,锌粉置换子工序训练效果相对略差,这是由于锌粉置换子工序的过程变量中与运行状态相关的变量相对较少,导致该子工序评价模型训练起来相对困难。

图 6 为微调后各个子工序以及全流程层所提取的特征的 t-SNE 可视化结果。可以看出,HMSPPDAE 提取出的深层特征可以较好区分不同的状态等级,展现了其强大的特征提取能力。

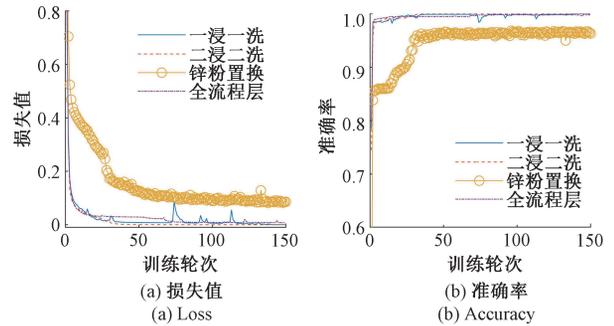


图 5 微调过程

Fig. 5 Fine tuning process

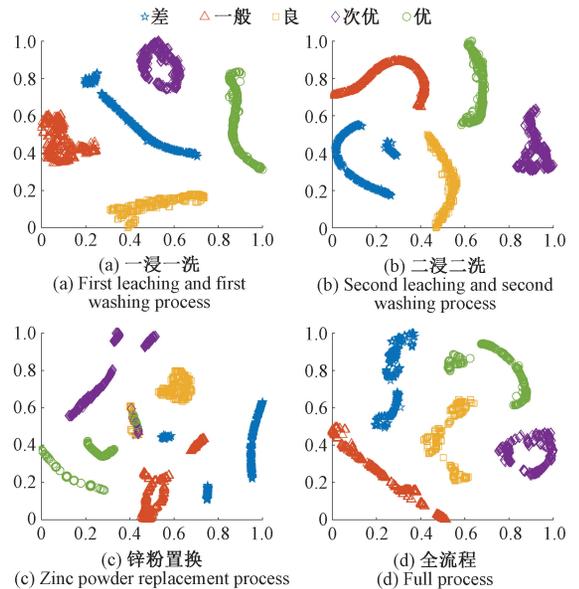


图 6 深层特征的 t-SNE 可视化

Fig. 6 t-SNE visualization of deep features

4.3 在线评价

为了说明本文所提 HMSPPDAE 网络的有效性和优越性,另外选取分层分块 SDAE (hierarchical multiblock SDAE, HMSDAE)、分层分块 SAE (hierarchical multiblock SAE, HMSAE) 以及针对全流程只建立一个评价模型的 SPDAE 网络进行对比实验。HMSDAE 和 HMSAE 中各个子工序和全流程层评价模型的网络结构与 HMSPPDAE 相同,SPDAE 的输入层、3 个隐含层和输出层节点分别为 35、25、15、10 和 5,其余超参数与 HMSPPDAE 全流程层评价模型超参数相同。

测试集的 400 个样本中涵盖两种不同情况下的测试数据,分别由 200 个样本构成。实验一中,前 80 个采样时刻的过程运行状态均为优,但从第 81 个采样时刻开始,由于一浸一洗子工序中氰化钠流量减小,使得矿浆中氰根离子浓度降低,导致浸出率偏低,过程运行状态由优转向一般。图 7 为上述评价方法针对实验一的在线评价结果,从图 7 中可以看到,大部分方法可以在第 81 个时刻左右识别出过程运行状态由优转变为一般,进一步地分析子工序的评价结果,发现一浸一洗子工序的运行状态同样在第 81 个采样时刻左右由优转变为一般,而其他子工序运行状态保持为优,说明全流程的非优运行状态是由一浸一洗子工序导致的,在线评价结果与实际情况相符。表 3 所示为不同方法在各个子工序及全流程层的评价准确率。从表 3 中可以看出,HMSPDAE 模型无论在全流程层还是各个子工序的评价中,其准确率均高于其他方法,平均值可达到 99.5%。

实验 2 中,全流程在前 80 个采样时刻运行状态也为优,但从第 81 个时刻开始,由于二浸二洗子工序的空气流量降低,使得矿浆中溶解氧浓度不足,影响二浸二洗子

表 3 实验 1 的评价结果比较

Table 3 Assessment results comparisons on experiment 1

工序	HMSPDAE	HMSDAE	HMSAE	SPDAE
一浸一洗	99.50	98.00	99.00	-
二浸二洗	99.00	99.00	96.00	-
锌粉置换	99.50	98.50	97.00	-
全流程层	100.00	100.00	99.00	99.00
平均值	99.50	98.88	97.75	-

工序的浸出率,导致过程运行状态由优转向次优,对应的在线评价结果如图 8 所示。与在实验 1 中的表现类似,实验 2 中 4 种评价方法也能在第 81 个时刻左右识别出全流程层和子工序运行状态的转变。表 4 为不同方法在各个子工序及全流程层的评价准确率。从中可以看出,HMSPDAE 模型无论在全流程层还是各个子工序的评价中,均表现出最优的性能。

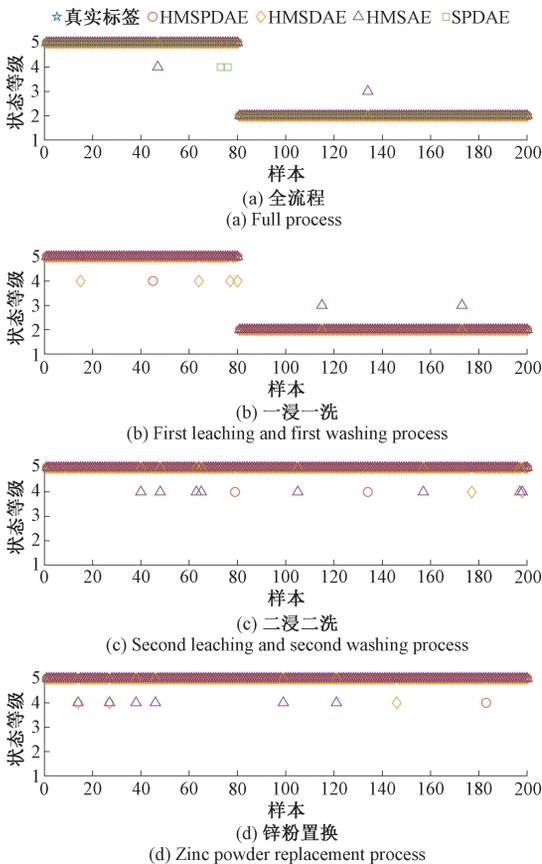


图 7 实验 1 在线评价结果

Fig. 7 Online assessment results of experiment 1

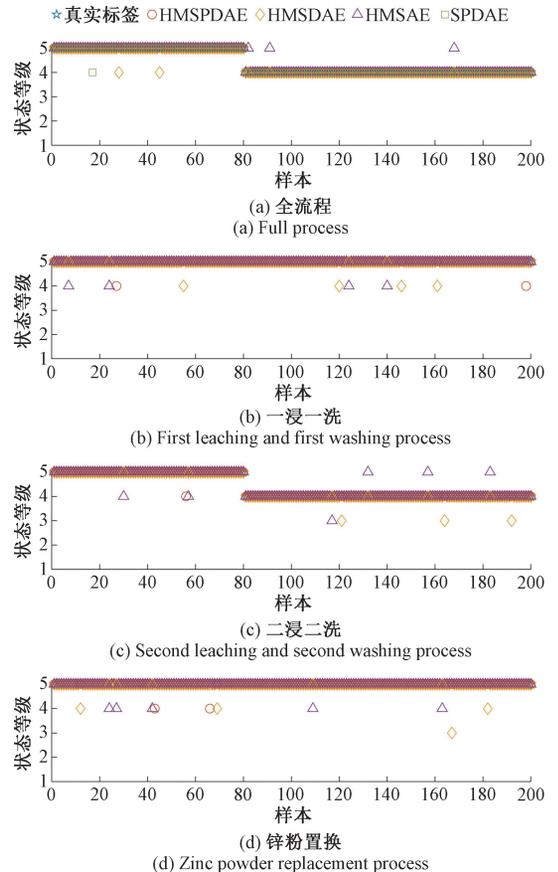


图 8 实验 2 在线评价结果

Fig. 8 Online assessment results of experiment 2

表4 实验2的评价结果比较

Table 4 Assessment results comparisons on experiment 2

工序	%			
	HMSPDAE	HMSDAE	HMSAE	SPDAE
一浸一洗	99.00	98.00	98.00	-
二浸二洗	99.50	98.50	97.00	-
锌粉置换	99.00	98.00	97.50	-
全流程层	100.00	99.00	98.50	99.50
平均值	99.38	98.38	97.75	-

从实验1和2的比较结果来看,由于HMS PDAE采用了分层分块的建模方式,建模过程中需先对各个子工序中的特征进行压缩和提炼,融合后再建立全流程层评价模型,使得所建立的评价模型比单纯基于SPDAE的全流程评价模型能够更加精准的表征和描述不同状态等级的本质特征,从而获取更加准确的评价结果,且可以精准定位导致运行状态非优的子工序,提高了评价结果的可解释性。另外,与HMSDAE相比,由于HMS PDAE着眼于状态相关特征的提取,进一步提炼了有助于区分不同运行状态的关键特征,使得其获得更准确的评价结果。与HMSAE相比,HMS PDAE不仅进行了状态相关特征的提取而且在训练过程中还引入了损坏环节,进一步提升了模型对噪声数据的抗干扰能力。将测试数据按20%随机置零后,全流程层的平均评价准确率在两个实验下分别达到了99.5%和99.38%,优于其他方法。

5 结 论

本文针对流程工业过程提出了一种分层分块的堆叠状态相关降噪自编码器,以提取过程数据的深层特征并建立流程工业过程运行状态评价模型。实施过程中,采取分层分块的思想,首先对流程工业过程进行层次结构的划分,分为多个子工序,并利用SPDAE分别建立各个子工序的评价模型。然后,再将子工序提取的特征进行融合,利用SPDAE建立全流程层评价模型。最后,以金湿冶金过程为背景,分别与HMSDAE、HMSAE和单纯利用SPDAE建立的全流程评价模型相比较,HMS PDAE在不同实验下均能获得最高的平均评价准确率,验证了所提方法的有效性和优越性。

参考文献

[1] YE L, LIU Y, FEI Z, et al. Online probabilistic assessment of operating performance based on safety and optimality indices for multimode industrial processes[J]. Industrial & Engineering Chemistry Research, 2009, 48(24): 10912-10923.

[2] 李茜,苏天赐,胡意茹,等.融合在线监测数据的海底电缆综合健康状态评估[J].电子测量与仪器学报,2021,35(9):89-98.
LI Q, SU T C, HU Y R, et al. Comprehensive health status assessment of submarine cables with online monitoring data[J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(9): 89-98.

[3] LI C, LIU X, ZHANG W, et al. Assessment method and indexes of operating states classification for distribution system with distributed generations[J]. IEEE Transactions on Smart Grid, 2016, 7(1): 481-490.

[4] LIU Y, WANG F L, CHANG Y Q. Operating optimality assessment based on optimality related variations and nonoptimal cause identification for industrial processes[J]. Journal of Process Control, 2016, 39: 11-20.

[5] LIN Y, CHEN M, ZHOU D. Online probabilistic operational safety assessment of multi-mode engineering systems using Bayesian methods[J]. Reliability Engineering and System Safety, 2013, 119: 150-157.

[6] 邹筱瑜,常玉清,王福利,等.基于GMM和贝叶斯推理的多模态过程运行状态评价[J].控制理论与应用,2016,33(2):164-171.
ZOU X Y, CHANG Y Q, WANG F L, et al. Operation performance assessment for multimode processes based on GMM and Bayesian inference[J]. Control Theory & Applications, 2016, 33(2): 164-171.

[7] ZOU X, WANG F L, CHANG Y Q. Process operation performance optimality assessment and cause identification based on PCA-DCD[J]. In Proceeding of the 28th Chinese Control Congress, 2016: 43-48.

[8] LIU Y, NEI H, WANG F L. Operating performance assessment based on performance-relevant independent component analysis for non-Gaussian batch processes[J]. In Proceedings of the 39th Chinese Control Conference, 2020: 27-29.

[9] CHU F, DAI B, MA X. A minimum-cost modeling method for nonlinear industrial process based on multimodel migration and bayesian model averaging method[J]. IEEE Transactions on Automation Science and Engineering, 2019(99): 1-10.

[10] CHU F, DAI W, SHEN J. Online complex nonlinear industrial process operating optimality assessment using

- modified robust total kernel partial M-regression [J]. Chinese Journal of Chemical Engineering, 2018, 26(4): 775-785.
- [11] ZOU X, ZHAO C. Concurrent assessment of process operating performance with joint static and dynamic analysis [J]. IEEE Transactions on Industrial Informatics, 2020(16): 2776-2786.
- [12] 褚菲, 傅逸灵, 赵旭, 等. 基于 ISDAE 模型的复杂工业过程运行状态评价方法及应用[J]. 自动化学报, 2021, 47(4): 849-863.
- CHU F, FU Y L, ZHAO X, et al. Operating performance assessment method and application for complex industrial process based on ISDAE model[J]. Acta Automatica Sinica, 2021, 47(4): 849-863.
- [13] WESTERHUIS J A, KOURTI T, MACGREGOR J F. Analysis of multiblock and hierarchical PCA and PLS models[J]. Journal of Chemometrics, 1998, 12: 301-321.
- [14] WOLD S, KETTANEH N, TJESSEM K. Hierarchical multiblock PLS and PC models for easier model interpretation and as an alternative to variable selection[J]. Journal of Chemometrics, 1996, 10(5-6): 463-482.
- [15] QIN S J, VALLE S, PIOVOSO M J. On unifying multiblock analysis with application to decentralized process monitoring[J]. Journal of Chemometrics, 2010, 15(9): 715-742.
- [16] HE D K, YUAN Q Y, WANG F L, et al. Plant-wide hierarchical optimization based on a minimum consumption model [J]. Canadian Journal of Chemical Engineering, 2016, 94(6): 1158-1166.
- [17] LIU Y, WANG F L, GAO F R, et al. Hierarchical multiblock T-PLS based operating performance assessment for plant-wide processes [J]. Industrial & Engineering Chemistry Research, 2018, 57(43): 14617-14627.
- [18] ZOU X Y, WANG F L, CHANG Y Q, et al. Two-level multiblock operating performance optimality assessment for plant-wide processes [J]. The Canadian Journal of Chemical Engineering, 2018, 96: 2395-2407.
- [19] XU Y, LIU Z, WU X, et al. Deep joint demosaicing and high dynamic range imaging within a single shot [J]. IEEE Transactions on Circuits and Systems for Video Technology, 2022, 32(7): 4255-4270.
- [20] GENG Z, CHEN Z, MENG Q, et al. Novel transformer based on gated convolutional neural network for dynamic soft sensor modeling of industrial processes [J]. IEEE Transactions on Industrial Informatics, 2021, 18(3): 1521-1529.
- [21] 刘炎, 龚思哲, 王福利, 等. 基于堆叠有监督降噪自编码器的运行状态评价[J]. 仪器仪表学报, 2022, 43(4): 271-281.
- LIU Y, GONG S ZH, WANG F L, et al. Process operating performance assessment based on stacked supervised denoising auto-encoders[J]. Chinese Journal of Scientific Instrument, 2022, 43(4): 271-281.
- [22] LI W, LUO Z, XIAO Z, et al. A GCN-based method for extracting power lines and pylons from airborne LiDAR data[J]. IEEE Transactions on Geoscience and Remote Sensing, 2022, 60: 1-14.
- [23] JIN R B, CHEN Z H, WU K Y, et al. Bi-LSTM-based two-stream network for machine remaining useful life prediction[J]. IEEE Transactions on Instrumentation and Measurement, 2022, 71: 1-10.
- [24] LIU C, WANG K, WANG Y, et al. Deep nonlinear dynamic feature extraction for quality prediction based on spatiotemporal neighborhood preserving SAE[J]. IEEE Transactions on Instrumentation and Measurement, 2021(70): 1-10.
- [25] YUAN X, GU Y, WANG Y, et al. A deep supervised learning framework for data driven soft sensor modeling of industrial processes [J]. IEEE Transactions on Neural and Learning Systems, 2020(31): 4737-4746.
- [26] 蒋爱国, 符培伦, 谷明, 等. 基于多模态堆叠自编码器的感应电机故障诊断[J]. 电子测量与仪器学报, 2018, 32(8): 17-23.
- JIANG AI G, FU P L, GU M, et al. Induction motor fault diagnosis based on multimodal stacked auto-encoder[J]. Journal of Electronic Measurement and Instrumentation, 2018, 32(8): 17-23.
- [27] BU K Q, WANG F L, LIU Y. Operating performance assessment based on stacked sparse denoising auto-encoder for gold hydrometallurgy processes [J]. In Proceedings of the 39th Chinese Control Conference, 2020: 2904-2909.
- [28] BU K Q, LIU Y, WANG F L. Operating performance

assessment based on multi-source heterogeneous information with deep learning for smelting process of electrofused magnesium furnace[J]. ISA Transactions, 2022, 128: 357-371.

- [29] VINCENT P, LAROCHELLE H, LAJOIE I, et al. Stacked denoising autoencoders: Learning useful representations in a deep network with a local denoising criterion[J]. Journal of Machine Learning Research, 2010, 11(12): 3371-3408.

作者简介



刘炎 (通信作者), 2016 年于东北大学获得博士学位, 现为东北大学副教授, 博士研究生导师, 主要研究方向为复杂工业过程运行状态评价、过程监测等。

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

Liu Yan (Corresponding author) received her Ph. D. degree from Northeastern University in 2016. She is currently an associate professor and a Ph. D. advisor at Northeastern University. Her main research interests include process operating performance assessment, process monitoring, etc.



马喆, 2021 年于东北大学获得学士学位, 现为东北大学硕士研究生, 主要研究方向为复杂工业过程运行状态评价、深度学习等。

E-mail: 2170751@stu.neu.edu.cn

Ma Zhe received his B.Sc. degree from Northeastern University in 2021. He is currently a master student at Northeastern University. His main research interests include process operating performance assessment, deep learning, etc.



褚菲, 2014 年于东北大学获得博士学位, 现为中国矿业大学教授, 博士研究生导师。主要研究方向包括复杂工业过程建模、控制与优化、机器学习及运行状态评价等。

E-mail: chufeizhufei@sina.com

Chu Fei received his Ph. D. degree from Northeastern University in 2014. He is currently a professor and a Ph. D. advisor at China University of Mining and Technology. His main research interests include modeling, control and optimization of complex industrial process, statistical process monitoring and operating performance assessment, etc.



王福利, 1988 年于东北大学获得博士学位, 现为东北大学教授, 博士研究生导师。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等。

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

Wang Fuli received his Ph. D. degree from Northeastern University in 1988. He is currently a professor and a Ph. D. advisor at Northeastern University. His research interests include modeling, control and optimization of complex industrial process, process monitoring and fault diagnosis, etc.