

DOI: 10.19650/j.cnki.cjsi.J2108926

基于堆叠有监督降噪自编码的运行状态评价^{*}

刘 炎¹, 龚思哲², 王福利¹, 马 喆¹

(1. 东北大学信息科学与工程学院 沈阳 110819; 2. 哈尔滨工业大学航天学院 哈尔滨 150000)

摘 要:本文针对非线性噪声干扰的工业生产数据,提出一种基于堆叠有监督降噪自编码(SSDAE)的过程运行状态评价方法。首先,提出一种有监督降噪自编码模型,将状态等级标签引入到模型训练中,使得有监督 DAE 学习与过程运行状态密切相关的特征并具备较强的状态等级区分能力。其次,利用由多个有监督 DAE 模型堆叠而成的 SSDAE 提取过程数据中与运行状态密切相关的深层特征,并作为 SoftMax 分类器的输入建立过程运行状态评价模型。最后,将所提方法应用于湿法冶金过程运行状态评价,仿真结果表明,对数据按 30% 比例随机置零的方式进行损坏后,该方法的评价准确率高达 95%,明显优于其他几种比较方法,验证了所提方法在强噪声干扰条件下良好的性能和可行性。

关键词:工业过程;运行状态评价;降噪自编码;有监督学习;深度学习

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

Process operating performance assessment based on stacked supervised denoising auto-encoders

Liu Yan¹, Gong Sizhe², Wang Fuli¹, Ma Zhe¹

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

2. School of Astronautics, Harbin Institute of Technology, Harbin 150000, China)

Abstract: In view of the nonlinear industrial data disturbed by strong noise, a novel operating performance assessment method based on the stacked supervised denoising auto-encoders (SSDAE) is proposed for complex industrial process. Firstly, a supervised denoising auto-encoder (SDAE) model is formulated, in which the performance grade labels are introduced to train the model. In this way, the SDAE can learn the characteristics closely related to the process operating performance and has strong ability to distinguish performance grades. Secondly, the SSDAE model is established by the stacking multiple SDAE model layer by layer and used to extract deep features which are closely related to the operating performance from the process data. Then, the deep features are used as the inputs of the SoftMax classifier. And the operating performance assessment model is achieved. Finally, the proposed method is applied to the hydrometallurgical process. Simulation results show that the assessment accuracy of SSDAE is up to 95% after the data are damaged by randomly setting zero in the proportion of 30%, which is obviously superior to other compared methods. Hence, the good performance and feasibility of the proposed method are verified under the condition of strong noise interference.

Keywords: industrial process; operating performance assessment; denoising auto-encoder; supervised learning; deep learning

0 引 言

为了保证生产的安全、稳定以及更高的企业综合经济效益,工业过程运行状态评价逐渐受到学术界和工业界的关注^[1-4]。过程运行状态评价是在生产过程处于正

常状态的前提下,对实际生产运行状态做进一步的区分与识别,帮助现场操作及管理人员实时获知关于过程运行状态的优劣信息,并据此对生产过程进行调整与优化,保证生产过程在较好的状态下运行。因此,开展工业过程运行状态评价研究对于提高企业的综合经济效益有着重要的理论价值和实际意义。

收稿日期:2021-11-25 Received Date: 2021-11-25

^{*} 基金项目:国家重点研发计划(2021YFF0602404)、国家自然科学基金(62073060, 61973057, 61973304)和中央高校基本科研业务专项资金(N2104011)项目资助

近年来,针对工业过程运行状态评价方法的研究逐渐受到学者们的关注。Liu 等^[2]针对过程变量间具有线性相关关系的工业过程,提出了基于优性相关变异信息和全潜结构投影模型(total projection to latent structures, T-PLS)^[3]的评价方法。面向多模态过程, Ye 等^[1]提出了基于概率框架的运行状态评价方法; Liu 等^[5]提出了基于高斯过程回归的评价方法;邹筱瑜等^[6]研究了基于贝叶斯推理和高斯混合模型的评价方法。实际工业数据由于受到外部环境因素及噪声等干扰,通常呈非高斯分布,针对该问题文献[7]提出了一种基于状态相关独立成分分析的评价方法。另外,针对只有少量历史数据的新过程评价建模问题, Zou 等^[8]提出了基于跨域特征迁移学习的运行状态评价方法。然而,上述方法的潜在假设均是过程变量之间具有线性或近似线性的相关关系,针对非线性过程则难以获得满意的结果。

随着现代工业过程日趋复杂,过程数据常常具有非线性和噪声干扰等特点,传统的线性评价方法无法获得令人满意的评价结果。因此,储菲等^[9-10]分别基于神经网络和核技术提出了面向非线性工业过程的运行状态评价方法。另一个值得注意的是,正常工况下,由于不同状态等级所含信息之间的差异度要远远小于“正常”与“故障”之间的差异度。因此,过程运行状态评价本质上是致力于如何更有效地区分不同运行状态特征信息之间的微弱差异,以实现过程运行状态的精准区分与评价。但从模型结构来看,现有的状态评价方法由于只进行一次特征提取,仍属于浅层学习方法,在降噪程度和特征提取深度方面难以满足工业过程运行状态评价的需求。

近年来,越来越多的工作尝试使用深度学习方法来提取各类信息中的深层特征,常用的方法包括卷积神经网络^[11-12]、堆叠自编码器(stacked auto-encoders, SAE)^[13-14]、深度置信网络^[15-16]等。这些方法可以有效地从各类信息中自动提取反映问题本质的深层特征,为深层特征提取和不同状态等级的精准区分提供了重要的技术支持。其中,SAE 以其较强的非线性处理能力和揭示高维数据低维流形结构的良好性能,被广泛应用于高维非线性数据的深层特征提取中^[17-18]。Vincent 等^[19]在 2010 年提出了堆叠降噪自动编码器(stacked denoising auto-encoders, SDAE)的概念,通过将多个降噪自编码器(denoising auto-encoder, DAE)堆叠起来组成深度神经网络模型。SDAE 提升了 SAE 从噪声干扰数据中提取本质特征的能力,具有更强的鲁棒性^[20-21]。然而,自编码器(auto-encoder, AE)在特征提取时采用无监督的方式对原始数据进行重构,因此所提取特征中可能包含与任务无关的信息,影响网络性能与应用效果的进一步提升。因此,基于半监督和有监督学习的自编码器渐渐受到了

研究学者的重视。针对分类问题,Chai 等^[22]提出了一种基于半监督学习的 AE 模型,通过在损失函数中增添分类标签和稀疏约束,提取类别规则所规定的特征,提高了算法的分类精度。在故障诊断中,Wang 等^[23]提出一种有监督的 SAE 模型,有效地提高了故障诊断的准确率。针对工业过程软测量问题,Yuan 等^[24]提出了堆叠质量驱动自编码器,将质量变量添加到输出层以指导网络对质量相关特征的学习,从而尽可能准确地预测输出。然而,上述半监督或有监督的 SAE 模型,在训练过程中因未考虑数据可能有损坏的情况,使得其处理强噪声干扰数据的能力较弱。

在工业过程运行状态评价中,并非所有过程信息都与过程运行状态密切相关;相反,某些信息的存在可能对于区分不同状态等级毫无用处甚至是干扰信息。另外,由于实际工业生产数据常常容易被噪声污染,运行状态评价中需要一种更具鲁棒性的特征提取方法,以增强评价模型对噪声数据的抗干扰能力。为了能够从过程数据中精确提取与过程运行状态密切相关的特征信息,实现精准区分不同状态等级的目标,本文针对变量间具有非线性相关关系且强噪声干扰的工业生产数据,提出一种基于堆叠有监督降噪自编码器(stacked supervised denoising auto-encoders, SSDAE)的过程运行状态评价方法。首先,通过优化实际状态等级标签与模型输出的状态等级标签之间的交叉熵损失,有监督地指导每个有监督 DAE 学习和提取与过程运行状态密切相关的特征信息。每个有监督 DAE 都以最大程度区分不同状态等级为目的,利用有监督学习的方式从输入数据中提取反映过程运行状态的本质特征,去除与过程运行状态无关的信息,最大程度的降低无关信息的干扰。与此同时,通过对原始输入数据进行损坏,有监督 DAE 可以完成对非线性数据更加鲁棒的特征表达,增强评价模型的鲁棒性。然后,将多个有监督 DAE 堆叠起来构成 SSDAE,前一个有监督 DAE 的隐含层特征作为后一个的输入信息,逐步地从过程数据中提取出与过程运行状态密切相关的深层特征。进一步地,将提取出的特征输入 SoftMax 分类器完成过程运行状态评价。最后,以黄金湿法冶金过程背景,验证了所提方法的有效性和优越性。

本文的主要贡献包括:1)将状态等级标签和数据损坏环节同时引入到原始 AE 模型训练中,提出了一种基于有监督学习的 DAE 网络模型;2)将多个有监督 DAE 逐层堆叠,构建了具有深层特征提取能力的 SSDAE 模型,为提取不同状态等级的深层特征奠定基础;3)提出了基于 SSDAE 过程运行状态评价方法,为解决非线性和噪声干扰的工业过程运行状态评价问题提供了一种新方法。

1 预备知识

1.1 自编码及降噪自编码

AE 首先通过编码过程提取输入数据特征,然后在解码过程中利用隐含层特征重构输入数据,并用损失函数值来描述重构数据与输入数据之间的差异大小,最后通过反向传播(back propagation, BP)算法优化网络参数,以此得到原始输入数据更优的特征表达。AE 的网络结构如图1所示,其中 $\mathbf{x} = [x_1, x_2, \dots, x_M]^T$ 是 M 维的输入数据, $\mathbf{h} = [h_1, h_2, \dots, h_p]^T$ 是 P 维的隐含层特征, $\tilde{\mathbf{x}} = [\tilde{x}_1, \tilde{x}_2, \dots, \tilde{x}_M]^T$ 为 AE 重构的输入数据。




图1 AE示意图

Fig.1 Schematic diagram of AE

编码过程为:

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

其中, $f(\cdot)$ 为激活函数,常选用 Sigmoid 或 Tanh 函数, $\mathbf{W} \in \mathbb{R}^{P \times M}$ 和 $\mathbf{b} \in \mathbb{R}^P$ 是连接输入层和隐含层的权重矩阵和偏置向量, $\theta = \{\mathbf{W}, \mathbf{b}\}$ 。

解码过程中利用隐含层特征 $\mathbf{h}$ 对输入数据进行重构,即:

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

其中, $g_{\tilde{\theta}}(\cdot)$ 为激活函数, $\tilde{\mathbf{W}} \in \mathbb{R}^{M \times P}$ 和 $\tilde{\mathbf{b}} \in \mathbb{R}^M$ 是连

接隐含层和输出层的权重矩阵和偏置向量, $\tilde{\theta} = \{\tilde{\mathbf{W}}, \tilde{\mathbf{b}}\}$ 。

假设训练数据集 $\mathbf{X} = [\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_N]^T \in \mathbb{R}^{N \times M}$ 中包含 N 个样本,其中第 n 个样本记为 $\mathbf{x}_n$,则重构数据与输入数据之间的误差可以用均方差来衡量,即:

$$L(\theta, \tilde{\theta}) = \sum_{n=1}^N (\mathbf{x}_n - \tilde{\mathbf{x}}_n)^2 / 2N \quad (3)$$

利用 BP 算法对网络参数进行更新优化,直到重构误差值足够小,便可得到较好的高维输入数据的低维特征表达。

类似地,DAE 同样包含编码和解码过程,但在编码之前,DAE 先对原始输入数据进行损坏。DAE 网络结构如图2所示,其中 $\hat{\mathbf{x}} = [\hat{x}_1, \hat{x}_2, \dots, \hat{x}_M]^T \in \mathbb{R}^M$ 是 $\mathbf{x}$ 损坏后的数据。DAE 以 $\hat{\mathbf{x}}$ 为基础进行编码操作,即:

$$\mathbf{h} = f_{\theta}(\hat{\mathbf{x}}) = f(\mathbf{W}\hat{\mathbf{x}} + \mathbf{b}) \quad (4)$$

解码过程同式(2),然后按照式(3)所示计算重构数据 $\tilde{\mathbf{x}}$ 与原始输入数据 $\mathbf{x}$ 之间的重构误差,并利用 BP 算法优化网络参数。




图2 DAE示意图

Fig.2 Schematic diagram of DAE

1.2 堆叠降噪自编码

SDAE 是由多个 DAE 堆叠而成,其训练过程包含两部分:无监督预训练和整体的反向微调。预训练时,从前向后逐步地单独训练每一个 DAE,前一个 DAE 的隐含层特征作为下一个 DAE 的输入,训练下一个 DAE。以一个包含 L 个隐含层的 SDAE 为例,若将第 l 层的输入矩阵、隐含层特征矩阵和输出矩阵分别记为 $\mathbf{H}^{(l-1)} = [\mathbf{h}_1^{(l-1)}, \mathbf{h}_2^{(l-1)}, \dots, \mathbf{h}_N^{(l-1)}]$, $\mathbf{H}^{(l)} = [\mathbf{h}_1^{(l)}, \mathbf{h}_2^{(l)}, \dots, \mathbf{h}_N^{(l)}]$, $\tilde{\mathbf{H}}^{(l-1)} = [\tilde{\mathbf{h}}_1^{(l-1)}, \tilde{\mathbf{h}}_2^{(l-1)}, \dots, \tilde{\mathbf{h}}_N^{(l-1)}]$,第 l 层的编码和解码过程为:

$$\mathbf{h}_n^{(l)} = f_{\theta^{(l)}}(\hat{\mathbf{h}}_n^{(l-1)}) = f(\mathbf{W}^{(l)}\hat{\mathbf{h}}_n^{(l-1)} + \mathbf{b}^{(l)}) \quad (5)$$

$$\tilde{\mathbf{h}}_n^{(l-1)} = g_{\tilde{\theta}^{(l)}}(\mathbf{h}_n^{(l)}) = g(\tilde{\mathbf{W}}^{(l)}\mathbf{h}_n^{(l)} + \tilde{\mathbf{b}}^{(l)}) \quad (6)$$

其中, $l = 1, 2, \dots, L$, $\hat{\mathbf{H}}^{(l-1)}$ 是第 $l-1$ 层的被损坏后的输入数据, $\mathbf{W}^{(l)}$ 和 $\mathbf{b}^{(l)}$ 是连接第 l 个 DAE 的输入层和隐含层的权重矩阵和偏置向量, $\tilde{\mathbf{W}}^{(l)}$ 和 $\tilde{\mathbf{b}}^{(l)}$ 是连接第 l 个 DAE 的隐含层和输出层的权重矩阵和偏置向量, $\theta^{(l)} = \{\mathbf{W}^{(l)}, \mathbf{b}^{(l)}\}$, $\tilde{\theta}^{(l)} = \{\tilde{\mathbf{W}}^{(l)}, \tilde{\mathbf{b}}^{(l)}\}$ 。特别地, $\hat{\mathbf{H}}^{(0)} = \hat{\mathbf{X}} = [\hat{\mathbf{x}}_1, \hat{\mathbf{x}}_2, \dots, \hat{\mathbf{x}}_N]$, $\tilde{\mathbf{H}}^{(0)} = \tilde{\mathbf{X}} = [\tilde{\mathbf{x}}_1, \tilde{\mathbf{x}}_2, \dots, \tilde{\mathbf{x}}_N]$, $\hat{\mathbf{X}}$ 和 $\tilde{\mathbf{X}}$ 分别是原始数据 $\mathbf{X}$ 被损坏和重构后的结果。

然后,计算重构数据与输入数据之间的均方差为:

$$L(\theta^{(l)}, \tilde{\theta}^{(l)}) = \sum_{n=1}^N (\mathbf{h}_n^{(l-1)} - \tilde{\mathbf{h}}_n^{(l-1)})^2 / 2N \quad (7)$$

当所有 DAE 完成训练后,以每个 DAE 的参数 $\{\theta^{(1)}, \theta^{(2)}, \dots, \theta^{(L)}\}$ 作为 SDAE 的参数初始值,将它们堆叠起来构成 SDAE 网络。

整体反向微调的目的是使深层网络获得更好的学习效果。若 SDAE 执行的是分类任务,则可通过在 SDAE 网络最后添加一个分类层,应用 SDAE 提取的深层特征预测出原始数据的分类标签,并通过有监督的方式来对整个网络进行反向微调,优化整个网络的所有参数。

1.3 SoftMax 分类器

SoftMax 分类器是一种有监督的分类器,它采用 SoftMax 函数作为激活函数,输出是样本属于每个类别的概率。假设训练数据集中第 n 个样本的输出为 $y_n \in \{1, 2, \dots, K\}$, K 为类别总数,用 $p(y_n = k | \mathbf{x}_n)$ 表示 $\mathbf{x}_n$ 属于第 k 类的概率,则 SoftMax 分类器的输出 $\mathbf{h}_{\hat{\theta}}(\mathbf{x}_n)$ 为:

$$\mathbf{h}_{\hat{\theta}}(\mathbf{x}_n) = \begin{bmatrix} p(y_n = 1 | \mathbf{x}_n; \hat{\theta}) \\ p(y_n = 2 | \mathbf{x}_n; \hat{\theta}) \\ \vdots \\ p(y_n = K | \mathbf{x}_n; \hat{\theta}) \end{bmatrix} = \frac{1}{\sum_{k=1}^K e^{\hat{\theta}_k^T \mathbf{x}_n}} \begin{bmatrix} e^{\hat{\theta}_1^T \mathbf{x}_n} \\ e^{\hat{\theta}_2^T \mathbf{x}_n} \\ \vdots \\ e^{\hat{\theta}_K^T \mathbf{x}_n} \end{bmatrix} \quad (8)$$

其中, $\hat{\theta} = \{\hat{\theta}_1, \hat{\theta}_2, \dots, \hat{\theta}_K\}$ 是 SoftMax 分类器的模型参数。SoftMax 分类器最终的分类结果为拥有最大后验概率的类别标签。

2 堆叠有监督降噪自编码

2.1 有监督 DAE 模型

在过程运行状态评价中,并非所有输入变量都与过程运行状态相关。由于无监督的 DAE 试图重构原始输入数据,而非专注于不同过程运行状态的特征表示,使其难以学习和提取与过程运行状态相关密切的特征,提取的特征中可能包含与过程运行状态无关的干扰信息。当使用分层预训练构建 SDAE 网络时,无关的信息可能会向前传播到更深层。针对上述问题,本文提出了一种有监督的 DAE 模型用于过程运行状态评价问题,以状态等级标签数据为指导,提取出与过程运行状态密切相关的特征。

有监督 DAE 同样只包含一个隐含层,将输入数据损坏后训练网络参数。与 DAE 不同的是,有监督 DAE 是依据隐含层提取的特征对数据类别进行预测。有监督 DAE 的结构如图 3 所示。




图3 有监督 DAE 示意图

Fig. 3 Schematic diagram of the supervised DAE

采用独热编码形式对输入数据 $\mathbf{x}$ 的实际状态等级标签 $\mathbf{y} = [y_1, y_2, \dots, y_K]^T \in \mathbb{R}^K$ 进行标记,并将网络预测的状态等级标签记为 $\tilde{\mathbf{y}} = [\tilde{y}_1, \tilde{y}_2, \dots, \tilde{y}_K]^T \in \mathbb{R}^K$, 计算公式为:

$$\tilde{\mathbf{y}} = g(\tilde{\mathbf{W}}\mathbf{h} + \tilde{\mathbf{b}}) \quad (9)$$

其中,激活函数 $g(\cdot)$ 为 SoftMax 函数。

有监督 DAE 的主要目标是学习输入数据的有效特

征表达,使预测的状态等级与实际状态等级相同。通过有监督 DAE 的前向传播计算出所有输入数据的状态等级预测结果后,用交叉熵作为损失函数,对网络参数微调和优化。若将实际和预测的状态等级标签分别记为 $\mathbf{Y} = [\mathbf{y}_1, \mathbf{y}_2, \dots, \mathbf{y}_N]^T \in \mathbb{R}^{N \times K}$ 和 $\tilde{\mathbf{Y}} = [\tilde{\mathbf{y}}_1, \tilde{\mathbf{y}}_2, \dots, \tilde{\mathbf{y}}_N]^T \in \mathbb{R}^{N \times K}$, 则交叉熵损失函数计算如下:

$$L_{CE}(\mathbf{Y}, \tilde{\mathbf{Y}}) = -\frac{1}{N} \sum_{n=1}^N \mathbf{y}_n \log \tilde{\mathbf{y}}_n = -\frac{1}{N} \sum_{n=1}^N \sum_{k=1}^K y_{n,k} \log \tilde{y}_{n,k} \quad (10)$$

其中, $\mathbf{y}_n = [y_{n,1}, y_{n,2}, \dots, y_{n,K}]^T$ 和 $\tilde{\mathbf{y}}_n = [\tilde{y}_{n,1}, \tilde{y}_{n,2}, \dots, \tilde{y}_{n,K}]^T$ 分别是 $\mathbf{Y}$ 和 $\tilde{\mathbf{Y}}$ 中第 n 个样本。

可以看出,有监督的 DAE 专注于学习有利于区分不同状态等级的特征信息。这样,通过有监督 DAE 提取的特征可以大大减少与运行状态评价无关的特征,有效地避免误评价。

2.2 SSDAE 模型

由于单个有监督 DAE 尚不足以从含噪声的高维非线性数据中学习和提取与运行状态相关的深层特征,因此,类似于 SDAE,将多个有监督 DAE 逐层堆叠起来,构成深层 SSDAE 网络。SSDAE 网络的构建过程如图 4 中所示,可以概括如下:

1) 将原始数据 $\mathbf{X}$ 的损坏形式 $\hat{\mathbf{X}}$ 作为输入数据,并将对应的状态等级标签存储为独热编码形式 $\mathbf{Y}$ 。然后确定 SSDAE 网络结构,包括有监督 DAE 的个数及其隐含层神经元的个数。假设 SSDAE 网络中包含 L 个有监督 DAE 模型,则第 l 个有监督 DAE 的网络参数为 $\{\mathbf{W}^{(l)}, \mathbf{b}^{(l)}, \tilde{\mathbf{W}}^{(l)}, \tilde{\mathbf{b}}^{(l)}\}$, $l = 1, 2, \dots, L$, 隐含层特征 $\mathbf{H}^{(l)} = [\mathbf{h}_1^{(l)}, \mathbf{h}_2^{(l)}, \dots, \mathbf{h}_N^{(l)}]$, 输出矩阵 $\tilde{\mathbf{Y}}^{(l)} = [\tilde{\mathbf{y}}_1^{(l)}, \tilde{\mathbf{y}}_2^{(l)}, \dots, \tilde{\mathbf{y}}_N^{(l)}]$ 。

2) 利用输入数据 $\hat{\mathbf{X}}$ 和标签 $\mathbf{Y}$ 预训练第一个有监督 DAE。交叉熵损失函数为:

$$L_{CE}(\mathbf{Y}, \tilde{\mathbf{Y}}^{(1)}) = -\frac{1}{N} \sum_{n=1}^N \mathbf{y}_n^{(1)} \log \tilde{\mathbf{y}}_n^{(1)} = -\frac{1}{N} \sum_{n=1}^N [\mathbf{y}_n^{(1)} \log (g(\tilde{\mathbf{W}}^{(1)} f(\mathbf{W}^{(1)} \hat{\mathbf{x}}_n + \mathbf{b}^{(1)}) + \tilde{\mathbf{b}}^{(1)}))] \quad (11)$$

当第 1 个有监督 DAE 的预训练完成后,参数 $\{\mathbf{W}^{(1)}, \mathbf{b}^{(1)}\}$ 被保留下来用于构建深层 SSDAE 网络,同时将隐含层特征作为下一个有监督 DAE 的输入。

3) 对于后续的有监督 DAE,采取上述方式依次、逐步地对其进行预训练。假设第 $l-1$ 个有监督 DAE 已完成预训练,将 $\mathbf{H}^{(l-1)}$ 作为第 l 个有监督 DAE 的输入, $\hat{\mathbf{H}}^{(l-1)} = [\hat{\mathbf{h}}_1^{(l-1)}, \hat{\mathbf{h}}_2^{(l-1)}, \dots, \hat{\mathbf{h}}_N^{(l-1)}]$ 是其损坏后的数据,则第 l 个有监督 DAE 的输入 $\hat{\mathbf{H}}^{(l-1)}$ 、输出 $\tilde{\mathbf{Y}}^{(l)}$ 和隐含层特征 $\mathbf{H}^{(l)}$ 之间的关系是:

$$\mathbf{h}_n^{(l)} = f(\mathbf{W}_n^{(l)} \hat{\mathbf{h}}_n^{(l-1)} + \mathbf{b}^{(l)}), l = 1, 2, \dots, L \quad (12)$$

$$\tilde{\mathbf{y}}_n^{(l)} = g(\tilde{\mathbf{W}}^{(l)} \mathbf{h}_n^{(l)} + \tilde{\mathbf{b}}^{(l)}) \quad (13)$$

第 l 个有监督 DAE 的交叉熵损失函数为:

$$L_{CE}(\mathbf{Y}, \tilde{\mathbf{Y}}^{(l)}) = -\frac{1}{N} \sum_{n=1}^N \mathbf{y}_n^{(l)} \log \tilde{\mathbf{y}}_n^{(l)} = -\frac{1}{N} \sum_{n=1}^N [\mathbf{y}_n^{(l)} \log(g(\tilde{\mathbf{W}}^{(l)} f(\mathbf{W}^{(l)} \hat{\mathbf{h}}_n^{(l-1)} + \mathbf{b}^{(l)}) + \tilde{\mathbf{b}}^{(l)}))] \quad (14)$$

通过迭代执行 BP 算法对第 l 个有监督 DAE 进行反向微调,完成预训练。

4) 在全部有监督 DAE 都完成预训练后,以编码过程保留的参数 $\{\mathbf{W}^{(1)}, \mathbf{b}^{(1)}; \mathbf{W}^{(2)}, \mathbf{b}^{(2)}; \dots; \mathbf{W}^{(L)}, \mathbf{b}^{(L)}\}$ 作为

SSDAE 网络的初始化参数,并将它们逐层堆层,实现 SSDAE 的深层特征提取的功能。SSDAE 经过分层有监督学习后,与运行状态无关的信息将逐渐减少,而与运行状态相关的重要特征将随着网络层数的增加而进一步被凝练和提取。如图 4 中所示,为了进一步优化 SSDAE 网络对于不同状态等级特征的区分能力,在网络的顶层添加一个分类层进行微调,连接顶部隐藏层和分类输出层的权重矩阵 $\mathbf{W}^{(L+1)}$ 和偏差向量 $\mathbf{b}^{(L+1)}$ 可以在微调之前随机初始化。随后迭代地进行前向传播和反向传播,以更新整个网络的参数。通过整体反向微调,可以使整个 SSDAE 的参数更加优化,提取的深层鲁棒特征更具区分能力。




图4 SSDAE 网络训练示意图

Fig. 4 Training schematic diagram of SSDA

3 基于 SSDAE 的过程运行状态评价

由于 SSDAE 具有较强的特征提取能力、抗噪声干扰能力、较好的泛化性能,并能有监督地提取与过程运行状

态相关的深层特征,减少无关信息的干扰,所以针对强噪声干扰的非线性工业过程,本文提出了一种基于 SSDAE 的过程运行状态评价方法。该方法利用基于 SSDAE 的深度神经网络进行运行状态评价,可分为离线建模和在线评价两个步骤,离线建模包含历史数据采集与预处理、

SSDAE 有监督预训练、模型整体反向微调 3 个子步骤;在线评价包含在线数据采集与预处理、基于 SSDAE 的过程运行状态在线评价两个子步骤。

3.1 基于 SSDAE 的离线建模

1) 历史数据采集与预处理

首先,从复杂工业过程中采集不同运行状态下的生产数据,并对其进行数据预处理,处理后的数据与对应的状态等级标签构成离线建模数据。

2) SSDAE 有监督预训练

利用离线建模数据,对有监督 DAE 进行逐层地预训练,预训练完成后将每个有监督 DAE 的编码参数分层堆叠,构建 SSDAE 网络。

3) 模型整体反向微调

在 SSDAE 网络顶端加上 SoftMax 分类器。将 SSDAE 提取出的深层特征作为 SoftMax 分类器的输入,SoftMax 分类器按式(8)计算输入数据属于每个状态等级的概率,然后按照式(10)计算网络的交叉熵损失函数值,利用 BP 算法对整个网络的参数进行更新优化,迭代地执行这一过程直到损失函数值足够小或迭代次数达到设定值。

当整体反向微调完成后,便得到了基于 SSDAE 的运行状态评价模型,离线建模步骤完成。

3.2 基于 SSDAE 的在线评价

1) 在线数据采集与预处理

在线评价之前,按照离线建模数据的预处理方式,对实时的在线数据 $\mathbf{x}_{\text{new}}$ 进行预处理。为了表述简便,预处理后的在线数据仍记为 $\mathbf{x}_{\text{new}}$ 。

2) 基于 SSDAE 的过程运行状态在线评价

将经过预处理的在线数据 $\mathbf{x}_{\text{new}}$ 输入基于 SSDAE 的离线评价模型,得到:

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

$$\mathbf{h}_{\text{new}}^{(l)} = f(\mathbf{W}^{(l)}\mathbf{h}_{\text{new}}^{(l-1)} + \mathbf{b}^{(l)}), l = 2, \dots, L \quad (15)$$

$$\tilde{\mathbf{y}}_{\text{new}} = \mathbf{h}_{\theta}(\mathbf{h}_{\text{new}}^{(L)}) = [\tilde{y}_{\text{new},1}, \tilde{y}_{\text{new},2}, \dots, \tilde{y}_{\text{new},K}] \quad (16)$$

式中: $\mathbf{h}_{\text{new}}^{(l)}, l = 1, 2, \dots, L$ 是在线数据 $\mathbf{x}_{\text{new}}$ 的第 l 层隐含层特征, $\tilde{\mathbf{y}}_{\text{new}}$ 是 $\mathbf{x}_{\text{new}}$ 属于不同状态等级的概率。最终的在线评价结果为 $\tilde{\mathbf{y}}_{\text{new}}$ 中最大元素的索引,即:

$$k^* = \arg \max \{k | \tilde{y}_{\text{new},k}, k = 1, 2, \dots, K\} \quad (17)$$

4 基于 SSDAE 的湿法冶金过程运行状态评价

4.1 湿法冶金工艺简介

湿法冶金过程的主要工序包括氰化浸出、压滤洗涤、锌粉置换等。由于黄金的经济价值极高,不理想的过程运行状态严重影响企业经济效益,使得在线评价湿法冶

金生产过程运行状态具有重要实际意义。本文以某黄金湿法冶金过程为背景,验证所提方法的有效性和优越性。

湿法冶金过程中,浮选后的矿浆首先被送往氰化浸出工序,期间向浸出槽内添加氰化钠并充入空气,经过化学反应后,使矿石原料中的金以金氰络合物的形式存在于矿浆中。矿浆中的氰根离子浓度和溶解氧浓度是影响该工序运行状态的两个重要因素。实际生产过程中,通过电脑加药机调节氰化钠流量进而控制氰根离子的浓度。当氰化钠发生水解反应时,不仅能够释放出有毒的氰化氢气体,危害人身安全,还会加剧氰化钠的消耗,因此要将矿浆的 pH 值控制在 11 左右以确保生产安全。矿浆中的溶解氧浓度则是通过控制风机的空气流量来调节的。另外,由于矿浆浓度间接反映了矿浆中的黄金含量,因此其直接影响氰化钠的添加量。浸出后的矿浆被送往压滤洗涤工序,该工序的主要任务是利用压滤机的挤压将含金贵液从矿浆中分离出来,即通过给滤腔施加一定的压力,使过滤过程加速,提高固液分离率,而压滤机的给料压力、挤压压力和液压压力是影响固液分离率的重要因素。

此后,贵液被送往锌粉置换工序。由于贵液中不可避免地混有杂质,为了减少锌粉消耗量、提高反应效率,进行置换反应前需要对贵液进行除杂与脱氧处理,而脱氧塔压力是决定脱氧效果的重要因素。通过向脱氧后的贵液中添加适量锌粉,可将金置换出来。最后,通过板框压滤机的挤压将贫液排出,金留在滤饼中。贵液中的金氰络合物浓度反映了贵液中的黄金含量,是衡量锌粉添加量是否合适的重要依据。锌粉添加量则是置换工序中最为关键的影响因素,若锌粉添加量不足,则会导致大量金氰络合物未被充分置换,残留在贫液当中,造成资源浪费;而过量添加会造成锌粉原料的浪费,提高生产成本。贫液中的金氰络合物浓度则进一步反映了置换反应的充分程度和整个生产过程的运行状态。板框压滤机液压力则影响固液分离率。最终,达到一定重量的滤饼被送往精炼工序,实现金的回收。实际过程中,为减少浪费、提高产量,将生产工艺设计成两次氰化浸出和两次压滤洗涤。通过对黄金湿法冶金过程的生产工艺和机理的深入分析,选取 35 个过程变量用于过程运行状态评价,如表 1 所示。

4.2 离线建模

长期的生产运行积累了大量的实际生产数据,它们构成的历史生产数据库,为分析生产过程运行状态提供了重要的数据支撑。从历史生产数据库中选取 2 165 个样本,根据综合经济效益由低到高,将其分为 5 个状态等级,分别是“差”、“一般”、“良好”、“次优”和“优”。利用随机分组的方式将数据分为训练集和测试集,其中训练集包含 1 732 个样本,测试集包含 433 个样本,对训

表 1 湿法冶金过程运行状态评价的变量

Table 1 Process variables of operating performance assessment for hydrometallurgical process

工序名称	变量名称	单位
第一次氰化浸出	矿浆浓度	%
	浸出槽 1 氰化钠流量	mL/min
	浸出槽 2 氰化钠流量	mL/min
	浸出槽 4 氰化钠流量	mL/min
	浸出槽 1 空气流量	m ³ /h
	浸出槽 2 空气流量	m ³ /h
	浸出槽 3 空气流量	m ³ /h
	浸出槽 4 空气流量	m ³ /h
	浸出槽 1 溶解氧浓度	mg/L
	浸出槽 1 氰根离子浓度	mg/L
	浸出槽 4 氰根离子浓度	mg/L
	氰化氢气体浓度	mg/L
第二次氰化浸出	矿浆浓度	%
	浸出槽 1 氰化钠流量	mL/min
	浸出槽 2 氰化钠流量	mL/min
	浸出槽 4 氰化钠流量	mL/min
	浸出槽 1 空气流量	m ³ /h
	浸出槽 2 空气流量	m ³ /h
	浸出槽 3 空气流量	m ³ /h
	浸出槽 4 空气流量	m ³ /h
	浸出槽 1 溶解氧浓度	mg/L
	浸出槽 1 氰根离子浓度	mg/L
	浸出槽 4 氰根离子浓度	mg/L
	氰化氢气体浓度	mg/L
第一次压滤洗涤	立式压滤机给料压力	MPa
	立式压滤机挤压压力	MPa
	立式压滤机液压压力	MPa
第二次压滤洗涤	立式压滤机给料压力	MPa
	立式压滤机挤压压力	MPa
	立式压滤机液压压力	MPa
锌粉置换	脱氧塔压力	kPa
	贵液金氰络合物浓度	mg/L
	贫液金氰络合物浓度	mg/L
	锌粉添加量	kg/h
	板框压滤机液压压力	MPa

所采用的仿真实验环境如下:软件平台:PyCharm 2020.1.3;深度学习框架:Tensorflow1.14;硬件平台:CPU: Intel i5-7200U 2.50 GHz、RAM:8.0 GB、操作系统:Windows 10。

由于深度神经网络的拓扑结构和网络参数对于网络的性能影响很大,经过反复调试,最终设置 3 个隐含层,其他网络参数的设置如表 2 中所示。

表 2 SSDAE 网络参数设定

Table 2 SSDAE parameter setting

参数名	参数值
输入层节点数	35
第一个隐含层节点数	25
第二个隐含层节点数	15
第三个隐含层节点数	5
损坏比例/%	30
学习率	0.009
批大小	32
预训练轮数	30
微调轮数	50

使用训练集数据对基于 SSDAE 的评价模型进行训练,图 5 是 SSDAE 在经过预训练后,微调过程中交叉熵损失函数值和模型在训练集上的评价准确率。从图 5(a)中可以看出随着微调次数的增加 SSDAE 的损失函数值迅速下降,由最初的 14.13 迅速减小并最终收敛至 0.038。从图 5(b)可以看出,训练集上的第一轮的平均评价准确率很高,为 61.17%,之后平均评价准确率迅速上升,仅仅经过 2 轮后,训练准确率便上升至 99% 以上,并最终收敛至 100%。从训练结果来看,SSDAE 具有较快的收敛速度与较高的初始评价精度。这是因为 SSDAE 的在预训练过程中已经能够很好地提取过程运行状态相关的信息,学习到更好地初始化参数。




图 5 基于 SSDAE 的评价模型训练

Fig. 5 SSDAE-based assessment model

练集和测试集数据均进行标准化处理,并采用按 30% 比例随机置零的方式对数据进行损坏。

4.3 在线评价与对比分析

利用测试集数据对训练好的 SSDAE 模型性能进行测试。测试集中共有 433 个样本,其中“差”、“一般”、“良好”、“次优”、“优”5 种状态等级的样本个数分别为 93、68、98、98、76。另外,为了验证所提方法的优越性,分别建立基于 T-PLS、SAE 和 SDAE 的运行状态评价模型作为对比,并利用上述测试数据对黄金湿法冶金过程进行运行状态评价。为公平起见,基于 SAE 和 SDAE 的离线评价模型的网络结构和参数设置与 SSDAE 的相同。

图 6~9 分别为基于 T-PLS、SAE、SDAE 和 SSDAE 的过程运行状态在线评价结果,其评价准确率分别为 80%、90%、93% 和 95%。其中子图(f)纵轴 1、2、3、4、5 分别代表“差”、“一般”、“良好”、“次优”、“最优”5 个状态等级。从图 6 和 7 可以看出,面对损坏数据,基于 T-PLS 和 SAE 的评价结果波动较大且出现许多误评价,影响模型的整体评价效果。进一步地,从图 8 和 9 可知,即使面对数据损坏严重的情况,基于 SSDAE 的评价方法仍然可以获得较高的评价精度。另外,由于 SDAE 同样具有较强的抗噪性能与特征提取能力,它获得了比 T-PLS 和 SAE 更好的评价结果,但仍然逊色于基于 SSDAE 的评价结果。究其原因,可以归结为:通过同时引入状态等级标签和数据损坏环节,有监督的 DAE 更加专注于从原始非线性强噪声干扰数据中学习有利于区分不同状态等级的特征信息,在很大程度上排除无关信息的干扰,为 SSDAE 提供了更好的初始化参数,使得所提取的深层特征更有利于不同状态等级的区分与识别,有效地避免误评价。




图 6 基于 T-PLS 的评价结果

Fig. 6 Assessment results based on T-PLS




图 7 基于 SAE 的评价结果

Fig. 7 Assessment results based on SAE




图 8 基于 SDAE 的评价结果

Fig. 8 Assessment results based on SDAE






图 8 基于 SDAE 的评价结果价
Fig.8 Assessment results based on SDAE




图 9 基于 SSDAE 的评价结果
Fig.9 Assessment results based on SSDAE

为了从多角度验证本文所提方法的优越性,还引入了精准率、召回率、F1 值这些评价指标对模型在线评价结果进行进一步的比较与分析,计算公式如下:

精准率=
$$\frac{TP}{TP+FP}$$
(18)

召回率=
$$\frac{TP}{TP+FN}$$
(19)

F1=
$$\frac{2\times\text{精准率}\times\text{召回率}}{\text{精准率}+\text{召回率}}$$
(20)

其中,TP、TN、FP、FN 的含义参如表 3 所示。

表 3 TP、TN、FP、FN 含义
Table 3 Meanings of TP, TN, FP, and FN

实际运行状态	评价结果	
	正例	反例
正例	TP(真正例)	FN(假反例)
反例	FP(假正例)	TN(真反例)

表 4~6 分别列出了各模型运行状态在线评价结果的精准率、召回率和 F1 值。从表 4~6 可以看出本文所提出的基于 SSDAE 的过程运行状态评价方法对大部分状态等级都拥有最高的评价精准率、召回率和 F1 值。同时,精准率、召回率、F1 值的加权平均值均高于另外 3 种方法。仿真结果进一步验证了本文所提方法的有效性 with 优越性,表明本文所提方法可以有效、准确地对强噪声干扰的非线性过程运行状态进行评价。

表 4 运行状态在线评价结果的精准率

Table 4 Precision of online assessment results

方法	精准率					加权平均
	差	一般	良	次优	优	
T-PLS	0.89	0.81	0.74	0.95	0.76	0.83
SAE	0.96	0.97	0.97	1.00	0.81	0.91
SDAE	1.00	0.99	0.99	1.00	0.84	0.93
SSDAE	1.00	0.97	0.97	1.00	0.89	0.95

表 5 运行状态在线评价结果的召回率

Table 5 Recall of online assessment results

方法	召回率					加权平均
	差	一般	良	次优	优	
T-PLS	0.65	0.72	0.95	0.76	0.79	0.77
SAE	0.76	0.93	0.96	0.83	0.99	0.89
SDAE	0.77	0.99	1.00	0.85	1.00	0.91
SSDAE	0.84	0.97	1.00	0.91	0.99	0.94

表 6 运行状态在线评价结果的 F1 值

Table 6 Recall of online assessment results

方法	F1 值					加权平均
	差	一般	良	次优	优	
T-PLS	0.74	0.66	0.84	0.85	0.71	0.77
SAE	0.85	0.81	0.96	0.91	0.89	0.89
SDAE	0.87	0.86	0.99	0.92	0.91	0.91
SSDAE	0.91	0.89	0.98	0.95	0.94	0.94

5 结 论

本文针对具有噪声干扰的复杂非线性工业过程,提出了基于 SSDAE 的过程运行状态在线评价方法。不同于传统的无监督 DAE 模型,有监督 DAE 通过将状态等级标签和数据损坏环节同时引入到模型训练中,以最小化状态等级标签的交叉熵为网络优化目标,迫使有监督 DAE 学习与过程运行状态密切相关的特征。进一步地,将多个有监督 DAE 逐层堆叠构建 SSDAE 网络,从而利用有监督学习的方式从输入数据中提取反映过程运行状态本质的深层特征,去除与过程运行状态无关的信息,最大程度的降低无关信息的干扰。最后,以黄金湿法冶金过程为背景,通过与其他几种评价方法的对比分析,验证了本文所提方法的有效性。

参考文献

[1] YE L B, LIU Y M, FEI ZH SH, 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] LIU Y, CHANG Y Q, WANG F L. Online process operating performance assessment and nonoptimal cause identification for industrial processes [J]. Journal of Process Control, 2014, 24(10):1548-1555.

[3] 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.

[4] 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.

[5] LIU Y, WANG F L, CHANG Y Q, et al. Operating optimality assessment and nonoptimal cause identification for non-Gaussian multimode processes with transitions[J]. Chemical Engineering Science, 2015, 137:106-118.

[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] LIU Y, WANG F L, CHANG Y Q, et al. Performance-relevant kernel independent component analysis based operating performance assessment for nonlinear and non-Gaussian industrial processes[J]. Chemical Engineering Science, 2019, 209:115167.

[8] ZOU X Y, WANG F L, CHANG Y Q. Assessment of operating performance using cross-domain feature transfer learning[J]. Control Engineering Practice, 2019, 89: 143-153.

[9] 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, <https://doi.org/10.16383/j.aas.c200475>.

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, <https://doi.org/10.16383/j.aas.c200475>.
- [10] 褚菲, 赵旭, 代伟, 等. 数据驱动的最优运行状态鲁棒评价方法及应用[J]. 自动化学报, 2020, 46(3): 439-450.
- CHU F, ZHAO X, DAI W, et al. Data-driven robust evaluation method and application for the optimal operating status [J]. Acta Automatica Sinica, 2020, 46(3): 439-450.
- [11] CHUA O, ROSKA T. The CNN paradigm [J]. IEEE Transactions on Circuits & Systems I Fundamental Theory & Applications, 1993, 40(3): 147-156.
- [12] 蓝金辉, 王迪, 申小盼. 卷积神经网络在视觉图像检测的研究进展[J]. 仪器仪表学报, 2020, 41(4): 167-182.
- LAN J H, WANG D, SHEN X P. Research progress on visual image detection based on convolutional neural network [J]. Chinese Journal of Scientific Instrument, 2020, 41(4): 167-182.
- [13] YU J, HONG C, RUI Y, et al. Multi-task autoencoder model for recovering human poses [J]. IEEE Transactions on Industrial Electronics, 2018, 65: 5060-5068.
- [14] SHI C, LUO B, HE S, et al. Tool wear prediction via multidimensional stacked sparse autoencoders with feature fusion [J]. IEEE Transactions on Industrial Informatics, 2020, 16(8): 5150-5159.
- [15] WANG Y, PAN Z, YUAN X F, et al. A novel deep learning based fault diagnosis approach for chemical process with extended deep belief network [J]. ISA Transactions, 2020, 96: 457-467.
- [16] 冯兆熙, 邱度金, 孔令驹, 等. 基于深度置信网络的轴承剩余使用寿命预测[J]. 电子测量与仪器学报, 2021, 35(10): 124-129.
- FENG ZH X, QIU D J, KONG L J, et al. Remaining useful life prediction of bearing based on deep belief network [J]. Journal of Electronic Measurement and Instrumentation, 2021, 35(10): 124-129.
- [17] YAN W, TANG D, LIN Y. A data-driven soft sensor modeling method based on deep learning and its application [J]. IEEE Transactions on Industrial Electronics, 2017, 64(5): 4237-4245.
- [18] BU K Q, LIU Y, WANG F L. Operating performance assessment based on multi-source heterogeneous information with deep learning for smelting process of electro-fused magnesium furnace [J]. ISA Transactions, 2021, <https://doi.org/10.1016/j.isatra.2021.10.024>.
- [19] 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: 3371-3408.
- [20] YU W K, ZHAO C H. Robust monitoring and fault Isolation of nonlinear Industrial processes using denoising autoencoder and elastic net [J]. IEEE Transactions on Control Systems Technology, 2019, 28(3): 1-9.
- [21] 普运伟, 郭江, 刘涛涛, 等. 基于模糊函数等高线与栈式降噪自编码器的雷达辐射源信号识别[J]. 仪器仪表学报, 2021, 42(1): 207-216.
- PU Y W, GUO J, LIU T T, et al. Radar emitter signal recognition based on ambiguity function contour lines and stacked denoising auto-encoders [J]. Chinese Journal of Scientific Instrument, 2021, 42(1): 207-216.
- [22] CHAI Z, SONG W, WANG H, et al. A semi-supervised auto-encoder using label and sparse regularizations for classification [J]. Applied Soft Computing, 2019, 77: 205-217.
- [23] WANG Y, YANG H, YUAN X, et al. Deep learning for fault-relevant feature extraction and fault classification with stacked supervised auto-encoder [J]. Journal of Process Control, 2020, 92: 79-89.
- [24] YUAN X F, ZHOU J, HUANG B, et al. Hierarchical quality-relevant feature representation for soft sensor modeling: A novel deep learning strategy [J]. IEEE Transactions on Industrial Informatics, 2020, 16(6): 3721-3730.


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, 硕士研究生导师, 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 master advisor at Northeastern University. Her main research interests include process operating performance assessment, process monitoring, etc.



龚思哲, 2021年于东北大学获得学士学位, 现为哈尔滨工业大学硕士研究生, 主要研究方向为深度学习、图像处理与缺陷检测等。

E-mail: gongsizhe0908@163.com

Gong Sizhe received his B. Sc. degree from Northeastern University in 2021. He is currently a master student at Harbin Institute of Technology. His main research interests include deep learning, image processing, and defect detection, etc.