

基于多源异构信息的浮选过程运行状态评价

刘炎, 卜齐杰, 赵红晨, 郭鑫
(东北大学信息科学与工程学院, 辽宁沈阳 110819)

摘要: 针对浮选过程中图像信息和过程数据信息共存且不同运行状态特征差异度小的问题,以深度学习技术为基础,提出了一种新的基于多源异构信息的浮选过程运行状态评价方法. 首先,建立一种残差网络(residual network, ResNet),旨在从不同等级的原始图像中提取更具区分度的深层特征. 其次,提出一种堆叠稀疏状态相关自编码器(stacked sparse performance-relevant autoencoders, SSPAE)模型,将状态等级标签引入到模型训练中,克服传统自编码器忽视状态相关特性的问题. 再次,建立基于注意力机制(attention mechanism, AM)的图像和数据特征融合模型,实现对多源异构信息的合理有效利用,并将融合后的特征输入SoftMax分类器建立运行状态评价模型. 最后,利用浮选过程数据进行仿真验证. 结果表明,基于本文提出的ResNet-SSPAE-AM模型的评价结果优于其他几种比较方法,说明所提方法在浮选过程运行状态评价中的优越性.

关键词: 运行状态评价;多源异构信息;深度学习;注意力机制;浮选过程

中图分类号: TP 13; TH 17 文献标志码: A 文章编号: 1005-3026(2024)09-1217-10

Operating Performance Assessment of Flotation Process Based on Multi-source Heterogeneous Information

LIU Yan, BU Qi-jie, ZHAO Hong-chen, GUO Xin

(School of Information Science & Engineering, Northeastern University, Shenyang 110819, China. Corresponding author: LIU Yan, E-mail: liuyan@ise.neu.edu.cn)

Abstract: In view of the coexistence of image information and process data information in flotation process and small differences among features of different operation state, a novel operating performance assessment method based on multi-source heterogeneous information and deep learning was proposed for flotation process. Firstly, a residual network (ResNet) is established to extract deep features with more discrimination from original images of different performance grades. Secondly, a stacked sparse performance-relevant autoencoders (SSPAE) model is proposed, which introduces the state level label into the model training to overcome the problem that the traditional autoencoder ignores the state-related characteristics. Furthermore, an image and data feature fusion model based on attention mechanism (AM) is established, and then the fused features are used as the inputs of the SoftMax classifier to train the operating performance assessment model, realizing the reasonable and effective utilization of the multi-source heterogeneous information. Finally, the flotation process data is used for simulation verification. The simulation results show that the proposed method is superior to other comparative methods, verifying its superiority in evaluating the operating performance of flotation processes.

Key words: operating performance assessment; multi-source heterogeneous information; deep learning; attention mechanism; flotation process

浮选作为选别矿物的主要方法,已广泛应用于冶金、煤炭、化工等行业. 目标矿物的品位和回收率是描述浮选目标矿物指标和选矿过程的重

要参数,目标矿物的品位是指目标矿物中主要有用成分的含量,回收率可以使用原矿品位、目标矿物品位和尾矿品位这3个指标进行计算. 为了

收稿日期: 2023-04-26

基金项目: 国家重点研发计划项目(2021YFF0602404); 国家自然科学基金资助项目(62073060).

作者简介: 刘炎(1984-),女,辽宁沈阳人,东北大学副教授,博士生导师.

保证目标矿物的品位和回收率、降低生产成本、提高综合经济效益,需要适时地对浮选过程进行操作优化,确保过程在较好状态下高效运行.过程运行状态评价是在过程运行正常的基础上,对实际生产运行状态的优劣作进一步的区分,为后续操作调整提供可靠依据,保证生产过程尽可能在较好的状态下运行.然而,由于操作滞后及外部环境干扰等原因,浮选过程运行状态时常偏离最初设置的理想水平,影响综合经济收益.因此,浮选过程运行状态评价具有重要的理论意义与应用价值.

浮选过程中,一方面利用工业相机实时采集浮选桶内的泡沫图像,另一方面还会利用泡沫图像分析仪同步搜集关于泡沫状态的过程数据信息.泡沫图像中包含了反映泡沫状态的全部静态特征,而泡沫的过程数据信息则提供了如泡沫大小、饱和度等浅层特征以及单一图像无法提供的动态特征,如泡沫稳定性和流速等.另外,存在矿浆液位、浮选桶内的充气量等过程变量影响目标矿物的回收率.因此,泡沫图像和过程数据信息均是评价浮选过程运行状态优劣的重要依据,它们之间相互补充,确保了泡沫信息的完备性.

随着数据采集技术的不断提升,学者们提出了很多数据驱动的过程运行状态评价方法.针对过程变量之间具有线性相关或近似线性相关的生产过程,Liu等^[1]提出了基于全潜结构投影模型的过程运行状态评价方法.针对非线性过程,Chu等^[2]提出全潜结构鲁棒核投影算法,消除了非线性数据中离群值对评价结果的影响.针对非高斯过程,Ye等^[3]采用高斯混合模型对多模态过程进行表征,建立了一种同时考虑过程运行安全性和最优性的在线评价方法.Zou等^[4]提出了基于改进动态因果关系图的过程运行状态评价方法.Yan等^[5]将案件推理法和贝叶斯网络相结合,实现了针对浮选过程精确的操作调整方法.Li等^[6]利用强化学习的方法,在不了解单元过程动力学和操作指标的情况下,成功获取粗浮选操作过程的最优解.然而,现有评价方法仍然面临两方面的挑战:一方面,传统评价方法由于只进行1次特征提取,无法挖掘各个状态等级数据中深层的本质特征,难以解决不同状态等级信息之间差异度较小情况下的过程运行状态评价问题;另一方面,传统评价方法不具备同时处理数据和图像等多源异构信息的能力.在图像信息的深层特

征提取上,卷积神经网络^[7](convolutional neural networks, CNN)具有局部连接和权值共享的特点,能够有效地表征图像信息中深层抽象的本质特征.目前,CNN在图像特征提取及识别^[8]、工业过程监测^[9]、故障诊断^[10-12]、软测量^[13]等方面应用广泛.残差网络(ResNet)^[14-15]是CNN的一种典型结构模型,其内部的残差模块使用了跳跃连接,解决了因增加深度带来的梯度消失问题,使得网络更容易训练,因此在诸多领域得到了广泛的应用.针对数据信息的深层特征提取,常用方法包括深度信念网络^[16]、堆叠自编码器^[17-19]、长短时记忆网络^[20]等.其中,堆叠自编码器因其强大的非线性处理能力和揭示高维数据低维结构的特点,被广泛应用于高维非线性数据的深层特征提取中.

为充分利用浮选泡沫图像和过程数据信息,建立更具区分度的特征提取和表达方式,提高运行状态评价的准确性,本文以深度学习技术为基础,提出一种基于多源异构信息的浮选过程运行状态评价方法.首先,利用ResNet提取泡沫图像的深层特征,为从相似的泡沫图像中有效区分状态等级奠定基础.其次,提出一种基于堆叠稀疏状态相关自编码器(SSPAE)的数据深层特征提取方法,在剔除变量之间冗余信息的同时,实现对高维数据的有效压缩和降维,并且在状态等级标签的监督下,提取出与过程运行状态密切相关的特征,降低无关特征对评价模型的干扰.进一步地,提出一种基于注意力机制(AM)的图像和数据特征融合方法,即通过构建注意力网络,为不同状态等级下的两类特征自适应地分配权重并进行融合,再实现对多源异构信息的合理有效利用.最后,以融合后的特征作为输入,状态等级标签作为输出,建立浮选过程运行状态评价模型,实现浮选过程运行状态的在线评价.为便于描述,将本文所提出的评价模型简称为ResNet-SSPAE-AM模型.

本文的主要贡献包括:1)将状态等级标签引入稀疏自编码器(sparse autoencoder, SAE)中,提出稀疏状态相关自编码器(sparse performance-relevant autoencoder, SPAE)网络模型;2)将多个 SPAE 和状态相关自编码器(performance-relevant autoencoder, PAE)逐层堆叠,构建具有深层特征提取能力的 SSPAE 模型,为提取不同状态等级数据的深层特征奠定基础;3)建立注意力机制模型自适应地融合图像和数

据特征,提出基于 ResNet-SSPAE-AM 的浮选过程运行状态评价方法.

1 预备知识

1.1 残差网络

ResNet 通常由多个残差模块堆叠构成.在神经网络中,几个堆叠层可以拟合输入 x 得到目标映射 y ,而在残差模块中,堆叠层拟合得到残差 $F(x)=y-x$,并在直边连接的恒等映射下使得目标映射变为 $F(x)+x$.虽然最终的目标映射都是 y ,但学习的难易程度不同,且残差模块中的恒等映射保证了深层网络的训练误差不大于浅层网络的训练误差.

本文采用的残差模块为两层卷积堆叠残差模块,每个卷积层之后添加批标准化层和激活层.当 x 和 $F(x)$ 的维度相同时, x 通过恒等映射与 $F(x)$ 进行叠加,如图 1a 所示,输出为 $y=F(x)+x$;当它们的维度不同时,通过 1 个线性投影 W_p 统一 x 和 $F(x)$ 的维度,如图 1b 所示,此时残差模块的输出为 $y=F(x)+W_p x$.

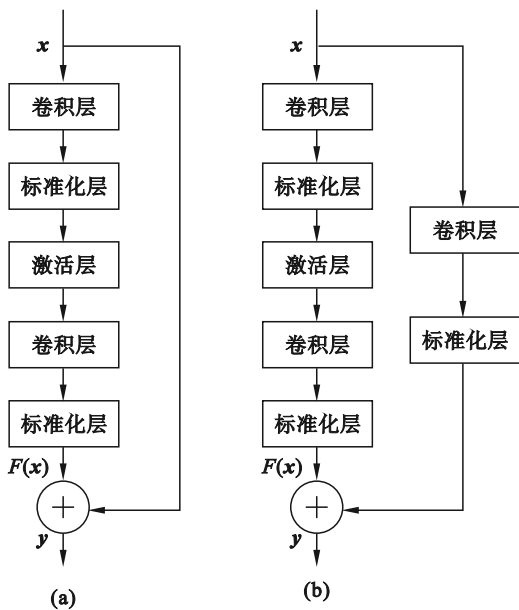


图 1 残差模块

Fig. 1 Residual module

(a)—恒等映射模块;(b)—投影映射模块.

1.2 堆叠稀疏自编码器

SAE 是利用稀疏编码的思想,在自编码器的基础上引入了稀疏惩罚项而提出的一种改进模型.由于 SAE 在稀疏约束条件下,部分神经元激活受到抑制,从而学习相对稀疏简明的数据特

征. SAE 的结构如图 2 所示,其中虚线箭头代表在训练过程中权值因受到被抑制的神经元影响而变得很小甚至为 0 的情况.




图 2 SAE 模型结构

Fig. 2 SAE model structure

SAE 的编码和解码过程分别如式 (1) 和式 (2) 所示:

$$h_s = f(W_s x + b_s), \quad (1)$$

$$\hat{x} = g(\hat{W}_s h_s + \hat{b}_s). \quad (2)$$

其中: $x \in \mathbf{R}^J$ 是 J 维输入数据; $h_s \in \mathbf{R}^M$ 是 M 维的隐含层特征; $\hat{x} \in \mathbf{R}^J$ 是 x 的重构; $W_s \in \mathbf{R}^{M \times J}$ 和 $b_s \in \mathbf{R}^M$ 分别是编码器的权重矩阵和偏差向量; $\hat{W}_s \in \mathbf{R}^{J \times M}$ 和 $\hat{b}_s \in \mathbf{R}^J$ 分别为解码器的权重矩阵和偏差向量; f 和 g 为激活函数,通常采用如 sigmoid 或 ReLU 等非线性函数.

对于训练数据 $X=[x_1, x_2, \dots, x_N] \in \mathbf{R}^{J \times N}$, SAE 的损失函数表达式如下:

$$J_{SAE} = J_{AE} + J_{KL} = \frac{1}{2N} \sum_{n=1}^N (x_n - \hat{x}_n)^2 + \beta \sum_{j=1}^M \left[\rho \lg \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \lg \frac{1 - \rho}{1 - \hat{\rho}_j} \right]. \quad (3)$$

其中: $J_{AE} = \sum_{n=1}^N (x_n - \hat{x}_n)^2 / 2N$ 表示输入数据与其重构值的均方误差; $J_{KL} = \sum_{j=1}^M \left[\rho \lg(\rho/\hat{\rho}_j) + (1 - \rho) \lg((1 - \rho)/(1 - \hat{\rho}_j)) \right]$ 是 KL 散度惩罚项,用于约束隐含层神经元; x_n 是训练数据集 X 中第 n 个样本, $n=1, 2, \dots, N$; $\hat{\rho}_j = \sum_{n=1}^N h_{s,n,j} / N$ 为隐含层第 j 个神经元的平均激活值, $h_{s,n,j}$ 是 x_n 的隐含层特征 $h_{s,n}$ 中的第 j 个元素; ρ 是稀疏参数; β 是惩罚项的系数. 利用反向传播 (back propagation, BP) 算法优化网络参数,从而获得输入数据更有意义的特征表达.

堆叠稀疏自编码器 (stacked sparse autoencoders, SSAE) 是由多个 SAE 逐层堆叠而成

的深度神经网络.在分别预训练完每个SAE后,将SAE的编码器参数作为SSAE的初始参数,利用BP算法对SSAE进行反向微调,优化整个网络的所有参数.

1.3 注意力机制

注意力机制的核心思想是权重分配,即为不同特征赋予不同的权重.在注意力的作用下,特征提取模型可以突出关键信息,弱化无关信息,从而作出更有效的决策.注意力值可通过式(4)计算:

$$\alpha = N(t^I, t^D). \quad (4)$$

其中: $t^I \in \mathbf{R}^{J_1}$ 和 $t^D \in \mathbf{R}^{J_2}$ 分别表示 2 种不同的特征, J_1, J_2 分别是 t^I, t^D 的维度; N 表示神经网络; $\alpha = [\alpha_1, \alpha_2, \dots, \alpha_j] \in \mathbf{R}^{\tilde{J}}, \tilde{J} = J_1 + J_2, \alpha_j$ 是第 j 维特征的注意力值, $j = 1, 2, \dots, \tilde{J}$.

对注意力值作归一化处理,得到注意力权重:

$$w = \frac{\exp(\alpha)}{\sum_{j=1}^{\tilde{J}} \exp(\alpha_j)} = [w_1, w_2, \dots, w_j]. \quad (5)$$

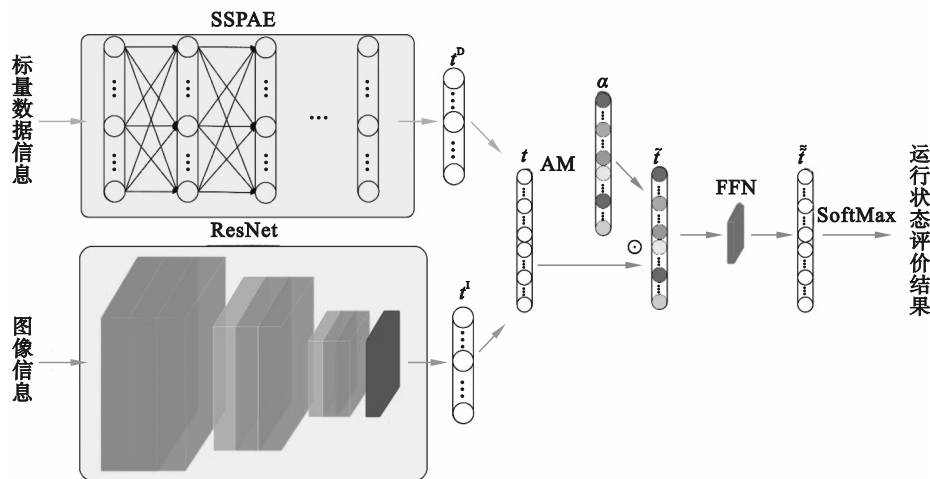


图3 基于 ResNet-SSPAE-AM 的评价模型的结构

Fig. 3 Structure of ResNet-SSPAE-AM assessment model

2.1 基于 ResNet 的图像特征提取

本文所建立的基于 ResNet 的图像特征提取模型由恒等映射模块和投影映射模块堆叠而成,网络结构如图 4 所示,其中 N_1 和 N_2 表示模块个数.每当图像特征维度减半时,通过投影映射统一 x 与 $F(x)$ 之间的维度.然后,连接平均池化层和全连接层对特征进行一维展开,并在最后一层连接 SoftMax 分类器.

假设共有 N 个图像训练样本,涵盖 C 个状态等级,将从第 n 个样本中提取的图像特征记为 $t_n^I \in \mathbf{R}^{J_1}$, J_1 为图像特征维度, $n = 1, 2, \dots, N$, 并采用独

其中, w_j 是第 j 维特征的注意力权重.

2 基于 ResNet-SSPAE-AM 的浮选过程运行状态评价

为充分利用多源异构信息,精准评价浮选过程的运行状态,本文提出一种基于 ResNet-SSPAE-AM 的浮选过程运行状态评价方法.首先,建立一种残差网络,实现对泡沫图像特征的深度挖掘.其次,提出 SSPAE 模型,确保从高维数据信息中提取出与过程运行状态密切相关的深层特征.进一步地,为综合利用图像和数据特征,提出基于注意力机制的数据和图像特征融合模型,即构建注意力网络,为不同状态等级下的两类特征自适应地分配权重并融合,提高特征表达的准确性和合理性.最后,以融合后的特征作为输入,状态等级标签作为输出,建立浮选过程运行状态评价模型,实现过程运行状态的在线评价.基于 ResNet-SSPAE-AM 的评价建模过程如图 3 所示.

热编码形式将其实际状态等级标签标记为 $y_n = [y_n^1, y_n^2, \dots, y_n^C]^T \in \mathbf{R}^C$. 将 ResNet 输出的状态等级标签记为 $\hat{y}_{R,n} = [\hat{y}_{R,n}^1, \hat{y}_{R,n}^2, \dots, \hat{y}_{R,n}^C]^T \in \mathbf{R}^C$, 可由式(6)计算:

$$\hat{y}_{R,n} = \begin{bmatrix} \hat{y}_{R,n}^1 \\ \hat{y}_{R,n}^2 \\ \vdots \\ \hat{y}_{R,n}^C \end{bmatrix} = \frac{1}{\sum_{c=1}^C \exp(\theta_{R,c}^T t_n^I)} \begin{bmatrix} \exp(\theta_{R,1}^T t_n^I) \\ \exp(\theta_{R,2}^T t_n^I) \\ \vdots \\ \exp(\theta_{R,C}^T t_n^I) \end{bmatrix}. \quad (6)$$

其中: $\theta_R = \{\theta_{R,1}, \theta_{R,2}, \dots, \theta_{R,C}\}$ 是 SoftMax 分类器的参数; $\hat{y}_{R,n}^c = \exp(\theta_{R,c}^T t_n^I) / \sum_{c=1}^C \exp(\theta_{R,c}^T t_n^I)$ 表示第 n 个样本属于第 c 个状态等级的后验概率.

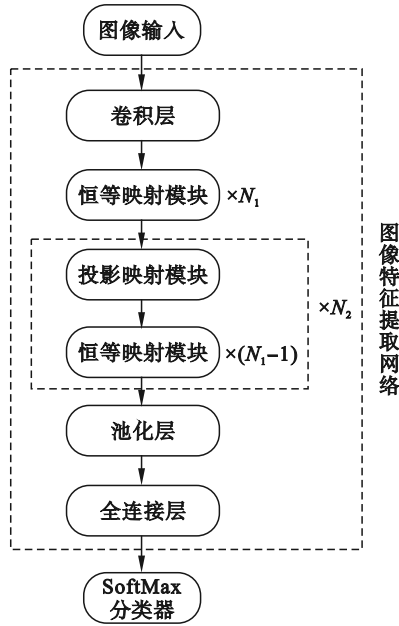


图 4 基于 ResNet 的图像特征提取模型

Fig. 4 Image feature extraction model based on ResNet

ResNet 的损失函数为

$$J_{\text{ResNet}} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_{\text{R},n} = - \sum_{n=1}^N \sum_{c=1}^C y_n^c \cdot \lg \hat{y}_{\text{R},n}^c \quad (7)$$

使用随机梯度下降来最小化损失函数 J_{ResNet} . 网络训练结束后, 将图像特征构成的集合记为 $T^1 = [t_1^1, t_2^1, \dots, t_N^1]^T \in \mathbf{R}^{N \times J_1}$.




图 5 SSPAE 的预训练过程

Fig. 5 The pretraining process of SSPAE

$$J_{\text{SPAE}}^{(1)} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_{\text{SP},n}^{(1)} + J_{\text{KL}} \quad (10)$$

第 1 个 SPAE 预训练完成后, 将隐含层特征 $\mathbf{h}_{\text{SP},n}^0, (n=1, 2, \dots, N)$ 作为第 2 个 SPAE 的输入. 假设按照上述方式已完成前 $l-1$ 个 SPAE 的预训练, 则第 l 个 SPAE 的输入 $\mathbf{h}_{\text{SP},n}^{l-1}$ 、隐含层特征 $\mathbf{h}_{\text{SP},n}^l$ 和输

2.2 基于 SSPAE 的数据特征提取

对于第 n 个数据样本 \mathbf{x}_n , 将 SPAE 网络输出的状态等级标签记为 $\hat{\mathbf{y}}_{\text{SP},n} = [\hat{y}_{\text{SP},n}^1, \hat{y}_{\text{SP},n}^2, \dots, \hat{y}_{\text{SP},n}^C]^T \in \mathbf{R}^C$. SPAE 的编码过程同式 (1), 解码过程如下:

$$\hat{\mathbf{y}}_{\text{SP},n} = g(\widehat{\mathbf{W}}_{\text{SP}} \mathbf{h}_{\text{SP},n} + \widehat{\mathbf{b}}_{\text{SP}}) = \mathbf{p}_{\theta_{\text{SP}}}(\mathbf{h}_{\text{SP},n}), n=1, 2, \dots, N. \quad (8)$$

其中, 激活函数 $g(\cdot)$ 选用 SoftMax 函数.

SSPAE 的损失函数如下:

$$J_{\text{SSPAE}} = J_{\text{PAE}} + J_{\text{KL}} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_{\text{SP},n} + J_{\text{KL}} \quad (9)$$

其中, $J_{\text{PAE}} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_{\text{SP},n}$ 是 PAE 网络输出的状态等级标签与实际状态等级标签之间的交叉熵, 若仅用此项作为损失函数来优化网络参数, 相当于不对隐含层特征作稀疏约束.

SSPAE 的训练过程包括预训练和微调两部分. 对于 1 个由 L_1 个 SPAE 和 L_2 个 PAE 堆叠而成的 SSPAE 网络, $L = L_1 + L_2$, 将第 l 个 SPAE 和第 l' 个 PAE 的网络参数、隐含层特征和输出的状态等级标签分别记为 $\{\mathbf{W}_{\text{SP}}^{(l)}, \mathbf{b}_{\text{SP}}^{(l)}; \widehat{\mathbf{W}}_{\text{SP}}^{(l)}, \widehat{\mathbf{b}}_{\text{SP}}^{(l)}\}$, $\{\mathbf{W}_{\text{P}}^{(l')}, \mathbf{b}_{\text{P}}^{(l')}; \widehat{\mathbf{W}}_{\text{P}}^{(l')}, \widehat{\mathbf{b}}_{\text{P}}^{(l')}\}$, $\mathbf{h}_{\text{SP},n}^l, \mathbf{h}_{\text{P},n}^{l'}$ 和 $\hat{\mathbf{y}}_{\text{SP},n}^l, \hat{\mathbf{y}}_{\text{P},n}^{l'}$, 其中 $l=1, 2, \dots, L_1, l'=1, 2, \dots, L_2, n=1, 2, \dots, N$. SSPAE 的预训练过程如图 5 所示. 首先, 利用原始数据样本训练第 1 个 SPAE, 其损失函数为

出 $\hat{\mathbf{y}}_{\text{SP},n}^l$ 之间的关系为

$$\mathbf{h}_{\text{SP},n}^l = f(\mathbf{W}_{\text{SP}}^l \mathbf{h}_{\text{SP},n}^{l-1} + \mathbf{b}_{\text{SP}}^l), l=1, 2, \dots, L_1, \quad (11)$$

$$\hat{\mathbf{y}}_{\text{SP},n}^l = g(\widehat{\mathbf{W}}_{\text{SP}}^l \mathbf{h}_{\text{SP},n}^l + \widehat{\mathbf{b}}_{\text{SP}}^l). \quad (12)$$

其中, $\mathbf{h}_{\text{SP},n}^0 = \mathbf{x}_n$.

第 l 个 SPAE 的损失函数为

$$J_{\text{SSPAE}}^{(l)} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_{\text{SP},n}^{(l)} + J_{\text{KL}} \quad (13)$$

类似地,第 l' 个 PAE 的输入 $\mathbf{h}_{\text{P},n}^{(l')}$ 、隐含层特征 $\mathbf{h}_{\text{P},n}^{(l')}$ 和输出 $\hat{\mathbf{y}}_{\text{P},n}^{(l')}$ 之间的关系如下:

$$\mathbf{h}_{\text{P},n}^{(l')} = f(\mathbf{W}_{\text{P}}^{(l')} \mathbf{h}_{\text{P},n}^{(l'-1)} + \mathbf{b}_{\text{P}}^{(l')}), \quad (14)$$

$$\hat{\mathbf{y}}_{\text{P},n}^{(l')} = g(\tilde{\mathbf{W}}_{\text{P}}^{(l')} \mathbf{h}_{\text{P},n}^{(l')} + \tilde{\mathbf{b}}_{\text{P}}^{(l')}). \quad (15)$$

其中, $\mathbf{h}_{\text{P},n}^{(0)} = \mathbf{h}_{\text{SP},n}^{(l')}$.

第 l' 个 PAE 的损失函数为

$$J_{\text{PAE}}^{(l')} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_{\text{P},n}^{(l')}. \quad (16)$$

通过迭代执行 BP 算法,分别对每个 SPAE 和 PAE 进行反向微调,完成预训练.

将预训练得到的隐含层特征 $\mathbf{h}_{\text{SP},n}^{(0)}, \mathbf{h}_{\text{SP},n}^{(1)}, \dots, \mathbf{h}_{\text{SP},n}^{(L_1)}, \mathbf{h}_{\text{P},n}^{(0)}, \mathbf{h}_{\text{P},n}^{(1)}, \dots, \mathbf{h}_{\text{P},n}^{(L_2)}$ 逐层堆叠,以编码器参数 $\{\mathbf{W}_{\text{SP}}^{(0)}, \mathbf{b}_{\text{SP}}^{(0)}; \dots; \mathbf{W}_{\text{SP}}^{(L_1)}, \mathbf{b}_{\text{SP}}^{(L_1)}; \mathbf{W}_{\text{P}}^{(0)}, \mathbf{b}_{\text{P}}^{(0)}; \dots; \mathbf{W}_{\text{P}}^{(L_2)}, \mathbf{b}_{\text{P}}^{(L_2)}\}$ 作为 SSPAE 的初始参数,并在最后一个隐含层之后添加 SoftMax 分类器,构建 SSPAE 网络.连接最后一个隐含层和分类层的权重矩阵 $\mathbf{W}^{(L+1)}$ 和偏差向量 $\mathbf{b}^{(L+1)}$ 在微调之前随机初始化,之后利用 BP 算法对整个 SSPAE 网络进行反向微调,以更新网络的参数,从而建立浮选过程数据的深层特征提取模型.

SSPAE 网络训练完成后,将最后一个隐含层所提取的特征 $\mathbf{h}_{\text{P},1}^{(L_2)}, \mathbf{h}_{\text{P},2}^{(L_2)}, \dots, \mathbf{h}_{\text{P},N}^{(L_2)}$ 作为数据特征并记为 $\mathbf{T}^{\text{D}} = [\mathbf{t}_1^{\text{D}}, \mathbf{t}_2^{\text{D}}, \dots, \mathbf{t}_N^{\text{D}}]^{\text{T}}$,其中 $\mathbf{t}_n^{\text{D}} = \mathbf{h}_{\text{P},n}^{(L_2)} \in \mathbf{R}^{J_{\text{D}}}$, $n = 1, 2, \dots, N$.

2.3 基于特征融合的评价模型的建立

基于注意力机制的图像和数据特征融合是在描述不同状态等级特征时,自适应地为不同种类的特征赋予不同的权重,实现多源异构信息的有效融合,进而提高评价模型的准确性和可靠性.

首先,将图像特征和数据特征串行连接,即

$$\mathbf{t}_n = [(\mathbf{t}_n^{\text{I}})^{\text{T}}, (\mathbf{t}_n^{\text{D}})^{\text{T}}]^{\text{T}}, n = 1, 2, \dots, N. \quad (17)$$

通过建立 1 个两层的神经网络构建注意力模型, \tanh 作为激活函数,则注意力值计算方式如下:

$$\alpha_n = \mathbf{V} \tanh(\mathbf{U} \mathbf{t}_n). \quad (18)$$

其中, \mathbf{V} 和 \mathbf{U} 为待训练的权重.

然后,利用式(5)计算各个特征的注意力权重 \mathbf{w}_n ,并将融合后的特征表示为

$$\tilde{\mathbf{t}}_n = \mathbf{w}_n \odot \mathbf{t}_n. \quad (19)$$

其中, \odot 表示向量元素对应相乘.

将融合后的特征 $\tilde{\mathbf{t}}_n$ 作为前馈网络(feed forward network, FFN)的输入,其中 FFN 输出特征 $\tilde{\mathbf{t}}_n$ 如式(20)所示:

$$\tilde{\mathbf{t}}_n = \text{FFN}(\tilde{\mathbf{t}}_n) = \max(\tilde{\mathbf{t}}_n \tilde{\mathbf{W}}_1 + \tilde{\mathbf{b}}_1, 0) \tilde{\mathbf{W}}_2 + \tilde{\mathbf{b}}_2. \quad (20)$$

其中: $\tilde{\mathbf{W}}_1, \tilde{\mathbf{W}}_2$ 为权重矩阵; $\tilde{\mathbf{b}}_1, \tilde{\mathbf{b}}_2$ 为偏差向量.将 $\tilde{\mathbf{t}}_n$ 作为 SoftMax 分类器的输入,得到 ResNet-SSPAE-AM 网络输出的状态等级标签,记为 $\hat{\mathbf{y}}_n = [\hat{y}_n^1, \hat{y}_n^2, \dots, \hat{y}_n^C]^{\text{T}} \in \mathbf{R}^C$. ResNet-SSPAE-AM 的损失函数为

$$J_{\text{SSPAE}} = - \sum_{n=1}^N \mathbf{y}_n \cdot \lg \hat{\mathbf{y}}_n. \quad (21)$$

利用 BP 算法对 ResNet-SSPAE-AM 网络的参数进行更新优化.当整体反向微调完成后,得到了基于 ResNet-SSPAE-AM 的运行状态评价模型,完成离线建模.

2.4 基于 ResNet-SSPAE-AM 的运行状态在线评价

基于 ResNet-SSPAE-AM 的运行状态在线评价步骤如下:

1) 将图像和数据输入 ResNet-SSPAE-AM 评价模型,得到图像特征 $\mathbf{t}_{\text{new}}^{\text{I}}$ 和数据特征 $\mathbf{t}_{\text{new}}^{\text{D}}$,进而按照式(22)~(27),对 $\mathbf{t}_{\text{new}}^{\text{I}}$ 和 $\mathbf{t}_{\text{new}}^{\text{D}}$ 串行合并后分别计算其注意力值 α_{new} 、注意力权重 \mathbf{w}_{new} 、融合特征 $\tilde{\mathbf{t}}_{\text{new}}$ 、前馈层输出特征 $\tilde{\mathbf{t}}_{\text{new}}$ 以及网络输出的状态等级标签 $\hat{\mathbf{y}}_{\text{new}}$.

$$\mathbf{t}_{\text{new}} = [(\mathbf{t}_{\text{new}}^{\text{I}})^{\text{T}}, (\mathbf{t}_{\text{new}}^{\text{D}})^{\text{T}}]^{\text{T}}, \quad (22)$$

$$\alpha_{\text{new}} = \mathbf{V} \tanh(\mathbf{U} \mathbf{t}_{\text{new}}), \quad (23)$$

$$\mathbf{w}_{\text{new}} = \frac{\exp(\alpha_{\text{new}})}{\sum_{j=1}^J \exp(\alpha_{\text{new},j})}, \quad (24)$$

$$\tilde{\mathbf{t}}_{\text{new}} = \mathbf{w}_{\text{new}} \odot \mathbf{t}_{\text{new}}, \quad (25)$$

$$\tilde{\mathbf{t}}_{\text{new}} = \text{FFN}(\tilde{\mathbf{t}}_{\text{new}}), \quad (26)$$

$$\hat{\mathbf{y}}_{\text{new}} = [\hat{y}_{\text{new}}^1, \hat{y}_{\text{new}}^2, \dots, \hat{y}_{\text{new}}^C]^{\text{T}}. \quad (27)$$

2) 当前所属状态等级为 $\hat{\mathbf{y}}_{\text{new}}$ 中最大元素的索引,即如果

$$c^* = \arg \max \{c | \hat{y}_{\text{new}}^c, c = 1, 2, \dots, C\}, \quad (28)$$

则当前过程运行于状态等级 c^* .

3 浮选过程中的仿真验证

3.1 浮选过程工艺简介

浮选过程通常包括粗选、精选和扫选 3 个子过程.原矿经过破碎机破碎、半自磨机研磨以及旋流器溢流得到满足粒度要求的矿石颗粒后,被依次连续地送入上述子过程,期间通过添加多种药剂改变矿物和浮选介质的物理和化学性质以实现矿物分离的目的.铜浮选过程流程图如图 6 所示,其中标号 1~9 为 9 台浮选机.




图 6 铜浮选流程示意图

Fig. 6 The schematic diagram of the copper flotation process

本文依托的浮选过程以粗选子过程为主导. 在保证浮选过程正常的情况下,即回收率大于0.7, 根据精矿品位划分状态等级.其中“优”的精铜矿品位区间为(25%,28%],“良”的精铜矿品位区间为(21%,25%],“中”的精铜矿品位区间为(19%,21%],“差”的精铜矿品位区间为(14%,19%].

首先,从历史生产数据库中,采集粗选过程“优”“良”“中”“差”4个状态等级下的共27 218张泡沫图像作为模型训练和在线测试的原始图像信息,每个等级样本数依次为7 013,7 630,6 804,

5 771.不同状态等级的原始泡沫图像信息如图7所示,该图与实际图像比例为1:25.图7a显示的泡沫流速偏高,小泡居多,对应铜精矿品位较低.图7b中,泡沫流速明显降低,泡沫尺寸逐渐增大,铜精矿泡沫开始富集,对应铜精矿品位逐渐升高的过程.图7c中,泡沫流速适中,大、中、小泡沫个数分布比例适中,铜精矿泡沫持续富集到一个相对稳定的状态,此时相应的铜精矿品位良好.图7d中,泡沫流速偏低,大泡明显增多,泡沫表面较亮,金属光泽明显,此时相应的铜精矿品位较高.




图 7 不同状态等级的原始泡沫图像

Fig. 7 Original froth images of different performance grades

(a)一差;(b)一中;(c)一良;(d)一优.

此外,同步收集关于泡沫状态的数据信息(如泡沫流动速度、泡沫面积、泡沫颜色等)以及反映浮选过程运行情况的其他数据信息(如浮选桶液位、充气量等)共29个变量,如表1所示.由于数据和图像的采用频率不一致,为了在时间上使两类信息相对应,以图像采样周期为标准,对2张图像采样间隔内的多个数据样本取平均值,作为与1个图像相对应的数据样本.对应后的样本中,随机选择60%的样本构成模型训练集,20%的样本用于模型校验,剩余20%的样本用于在线测试.

3.2 离线建模

本节中,除了建立本文提出的基于ResNet-SSPAE-AM的过程运行状态评价模型外,还建立其他3种不同的评价模型进行仿真对比实验,旨

在从不同方面验证本文所提方法的有效性.

1) 仅利用图像信息对浮选过程运行状态进行评价.此时,建立ResNet网络提取图像特征,并利用SoftMax分类器判断特征所属的状态等级,实现基于图像的运行状态评价.为方便描述,将其称为基于ResNet的评价模型.

2) 仅利用数据信息对浮选过程运行状态进行评价.此时,建立SSPAE网络提取数据特征,并利用SoftMax分类器判断特征所属的状态等级,实现基于数据的运行状态评价,将其称为基于SSPAE的评价模型.

3) 同时利用泡沫图像和数据信息,在特征融合时,不建立注意力网络,只对两类特征进行简单拼接,如式(17)所示.将该模型称为基于ResNet-SSPAE的评价模型.

表 1 浮选过程变量
Table 1 Variables of the flotation process

序号	名称	单位	序号	名称	单位
1	粗选 X 轴速度	cm/s	16	浮选机检测点 1 液位	cm
2	粗选 Y 轴速度	cm/s	17	浮选机检测点 2 液位	cm
3	粗选大泡数	个	18	浮选机检测点 3 液位	cm
4	粗选中泡数	个	19	浮选机检测点 4 液位	cm
5	粗选小泡数	个	20	浮选机检测点 5 液位	cm
6	粗选大泡面积	像素	21	浮选机 1 充气量测量值	m ³ /min
7	粗选中泡面积	像素	22	浮选机 2 充气量测量值	m ³ /min
8	粗选小泡面积	像素	23	浮选机 3 充气量测量值	m ³ /min
9	粗选大泡稳定性	%	24	浮选机 4 充气量测量值	m ³ /min
10	粗选中泡稳定性	%	25	浮选机 5 充气量测量值	m ³ /min
11	粗选小泡稳定性	%	26	浮选机 6 充气量测量值	m ³ /min
12	粗选泡沫稳定性	%	27	浮选机 7 充气量测量值	m ³ /min
13	粗选图像色调	°	28	浮选机 8 充气量测量值	m ³ /min
14	粗选图像饱和度	%	29	浮选机 9 充气量测量值	m ³ /min
15	粗选图像亮度	%			

在建立基于 ResNet 的图像特征提取模型时,通过实验对比分析,最终确定 ResNet 的结构($N_1=3, N_2=2$)如表 2 所示.以第一个卷积层为例,输入图像的尺寸为 64 像素×64 像素,3 个通道,卷积层采用 32 个 3×3 的卷积核,滑动步长设为 2.最小批次数量设置为 256,共训练 800 轮次.前 500 轮次的训练过程中将学习率设置为 10^{-4} ,后 300 轮次的学习率设置为 10^{-5} .最终模型的验证集精度可达到 96.5%.

在建立基于 SSPAE 的数据特征提取模型时,需要考虑 SPAE 和 PAE 隐含层数对整个网络性能的影响.图 8a 和 8b 分别展示了在训练集上当 $L_2=8$ 和 $L_1=2$ 时,SSPAE 的准确率随着 SPAE 和 PAE 隐含层数增加的变化情况.最终确定的 SSPAE 模型的结构为 [29, 300, 300, 29, 26, 23, 20, 17, 14, 11, 4],其中 29 是输入层节点数,300 是 2 个 SPAE 的稀疏层的节点数,29, 26, 23, 20, 17,

14, 11 分别是不同的 PAE 的隐含层的节点数,4 为输出层节点数.设置学习率为 1×10^{-4} ,最小批次数量为 256, $\beta=1, \rho=0.05$,共训练 100 轮次.

表 2 残差网络结构
Table 2 Structure of ResNet

名称	输出维度	参数
卷积层	32×32	3×3, 32, 步长=2
恒等映射模块	32×32	3×3, 32, 步长=1
恒等映射模块	32×32	3×3, 32, 步长=1
恒等映射模块	32×32	3×3, 32, 步长=1
投影映射模块	16×16	3×3, 64, 步长=1
恒等映射模块	16×16	3×3, 64, 步长=1
恒等映射模块	16×16	3×3, 64, 步长=1
投影映射模块	8×8	3×3, 128, 步长=1
恒等映射模块	8×8	3×3, 128, 步长=1
恒等映射模块	8×8	3×3, 128, 步长=1
平均池化层	128	—
全连接层	11	—




图 8 准确率随隐含层数的变化

Fig. 8 Change of accuracy rate with numbers of hidden layers

(a)—准确率随 SPAE 隐含层数的变化; (b)—准确率随 PAE 隐含层数的变化.

将 ResNet 提取的图像特征和 SSPAE 提取的数据特征分别通过简单拼接和注意力机制进行

特征融合,建立基于 ResNet-SSPAE 和 ResNet-SSPAE-AM 的评价模型. ResNet-SSPAE 和

ResNet-SSPAE-AM 的训练过程中,学习率设为 1×10^{-4} ,训练轮次为 200,最小批次数为 256.

3.3 离线建模在线评价

在线评价中,测试集共包含 5 447 个样本,其中,第 1~1 061 个样本属于状态等级“差”,第 1 062~2 384 个样本属于状态等级“中”,第 2 385~3 959 个样本属于状态等级“良”,第 3 960~5 447 个样本属于状态等级“优”.图 9 为基于 ResNet, SSPAE, ResNet-SSPAE 和 ResNet-SSPAE-AM 的在线评价结果.基于 ResNet, SSPAE, ResNet-SSPAE 的评价方法的准确率分别为 97.41%, 96.62% 和 96.97%,而基于 ResNet-SSPAE-AM 的评价方法的准确率最高,可达到 97.78%.

此外,表 3 中还比较了不同评价方法在线评

价结果的精准率、召回率和 $F1$ 值.从表 3 可以看出,基于 ResNet-SSPAE-AM 的评价方法在大部分状态等级下都能够获得最高的精准率、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其他 3 种方法.在线评价过程中,为了进一步说明图像信息和数据信息在描述不同状态等级中所起的作用,图 10 展示了基于 ResNet-SSPAE-AM 的在线评价中图像和数据特征在不同状态等级下的注意力权重.由图 10 可知,图像和数据特征在不同状态等级中的作用确实不同,单纯利用某一类特征或将两类特征简单拼接融合,都无法精确地描述状态等级本质特征,这也进一步说明了本文所提出的基于 ResNet-SSPAE-AM 的评价方法优于其他几种比较方法的原因.

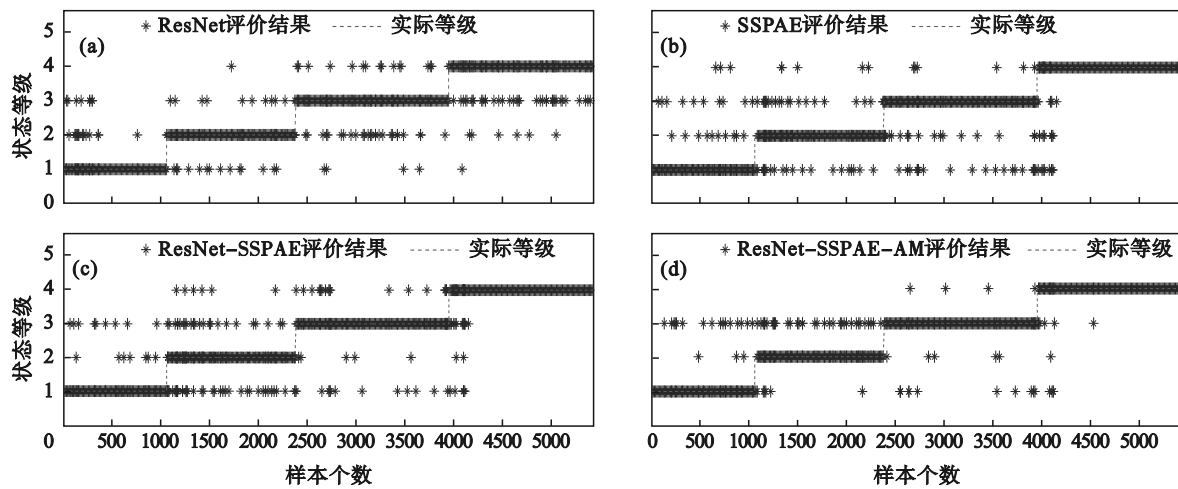


图 9 不同方法的在线评价结果

Fig. 9 Online assessment results based on different methods

(a)—基于 ResNet 的在线评价; (b)—基于 SSPAE 的在线评价; (c) —基于 ResNet-SSPAE 的在线评价;
(d) —基于 ResNet-SSPAE-AM 的在线评价.

表 3 不同评价方法的精准率、召回率和 $F1$ 分值

Table 3 Precision, recall and $F1$ -score of different assessment methods

%

指标	方法	状态等级				加权平均
		差	中	良	优	
精准率	ResNet	97.93	96.56	96.41	98.90	97.42
	SSPAE	92.68	96.75	97.12	98.98	96.67
	ResNet-SSPAE	93.55	98.88	96.68	98.32	97.05
	ResNet-SSPAE-AM	96.13	99.29	95.93	99.73	97.82
召回率	ResNet	97.93	97.73	97.14	97.04	97.41
	SSPAE	97.83	94.48	96.51	97.78	96.62
	ResNet-SSPAE	98.49	93.65	97.71	98.05	96.97
	ResNet-SSPAE-AM	98.21	95.31	98.67	98.72	97.78
$F1$ -score	ResNet	97.93	97.14	96.77	97.96	97.41
	SSPAE	95.19	95.60	96.82	98.38	96.63
	ResNet-SSPAE	95.96	96.19	97.19	98.18	96.98
	ResNet-SSPAE-AM	97.16	97.26	97.28	99.22	97.78

注:粗体数字表示不同方法在该指标下的最大值.




图 10 图像和数据的注意力权重

Fig. 10 Attention weight of image and data

(a)—图像; (b)—数据.

4 结 论

本文针对浮选过程多源异构信息共存且不同等级原始信息差异度小的情况,提出了一种基于 ResNet-SSPAE-AM 的浮选过程运行状态评价方法.该方法以深度学习技术为基础,分别建立了基于 ResNet 和 SSPAE 的图像和数据特征提取模型,并利用注意力机制为两类特征自主地分配权重并融合,从而建立基于融合特征的运行状态评价方法.浮选过程中的实验结果表明,相比于仅利用单一种类信息的 ResNet 和 SSPAE 模型,以及将两类特征简单拼接的 ResNet-SSPAE 模型,本文提出的基于 ResNet-SSPAE-AM 的运行状态评价方法具有更高的准确率和可靠度,说明通过合理地利用多源异构信息,运行状态评价模型的性能得到了有效的提升.

参考文献:

- [1] 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.
- [2] Chu F, Dai W, Shen J, et al. 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.
- [3] Ye L B, Liu Y M, Fei Z S, 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.
- [4] Zou X Y, Chang Y Q, Wang F L, et al. Process operating performance optimality assessment with coexistence of quantitative and qualitative information [J]. *The Canadian Journal of Chemical Engineering*, 2018, 96(1): 179-188.
- [5] Yan H, Wang F L, Yan G G, et al. Hybrid approach integrating case-based reasoning and Bayesian network for operational adjustment in industrial flotation process [J]. *Journal of Process Control*, 2021, 103: 34-47.
- [6] Li J N, Chai T Y, Lewis F L, et al. Off-policy Q-learning: set-point design for optimizing dual-rate rougher flotation operational processes [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(5): 4092-4102.
- [7] Krizhevsky A, Sutskever I, Hinton G E. ImageNet classification with deep convolutional neural networks [J]. *Communications of the ACM*, 2017, 60(6): 84-90.
- [8] Zarie M, Jahedsaravani A, Massinaei M. Flotation froth image classification using convolutional neural networks [J]. *Minerals Engineering*, 2020, 155: 106443.
- [9] Zhang Y J, Soon H G, Ye D S, et al. Powder-bed fusion process monitoring by machine vision with hybrid convolutional neural networks [J]. *IEEE Transactions on Industrial Informatics*, 2020, 16(9): 5769-5779.
- [10] Wen L, Li X Y, Gao L, et al. A new convolutional neural network-based data-driven fault diagnosis method [J]. *IEEE Transactions on Industrial Electronics*, 2018, 65(7): 5990-5998.
- [11] Huang T, Zhang Q, Tang X A, et al. A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems [J]. *Artificial Intelligence Review*, 2022, 55(2): 1289-1315.
- [12] Cen J, Yang Z H, Liu X, et al. A review of data-driven machinery fault diagnosis using machine learning algorithms [J]. *Journal of Vibration Engineering & Technologies*, 2022, 10(7): 2481-2507.
- [13] Yuan X F, Qi S B, Shardt Y A W, et al. Soft sensor model for dynamic processes based on multichannel convolutional neural network [J]. *Chemometrics and Intelligent Laboratory Systems*, 2020, 203: 104050.
- [14] He K M, Zhang X Y, Ren S Q, et al. Deep residual learning for image recognition [C]//2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). Las Vegas, 2016: 770-778.
- [15] Xue Z X, Yu X C, Liu B, et al. HResNetAM hierarchical residual network with attention mechanism for hyperspectral image classification [J]. *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, 2021, 14: 3566-3580.
- [16] Jiao J Y, Zhao M, Lin J, et al. Residual joint adaptation adversarial network for intelligent transfer fault diagnosis [J]. *Mechanical Systems and Signal Processing*, 2020, 145: 106962.
- [17] Yuan X F, Qi S B, Wang Y L. Stacked enhanced auto-encoder for data-driven soft sensing of quality variable [J]. *IEEE Transactions on Instrumentation and Measurement*, 2020, 69(10): 7953-7961.
- [18] Yu Y, Li J T, Li J C, et al. Automated damage diagnosis of concrete jack arch beam using optimized deep stacked autoencoders and multi-sensor fusion [J]. *Developments in the Built Environment*, 2023, 14: 100128.
- [19] Deng Z W, Wang Z Y, Tang Z H, et al. A deep transfer learning method based on stacked autoencoder for cross-domain fault diagnosis [J]. *Applied Mathematics and Computation*, 2021, 408: 126318.
- [20] Yuan X F, Li L, Wang Y L, et al. Deep learning for quality prediction of nonlinear dynamic processes with variable attention-based long short-term memory network [J]. *The Canadian Journal of Chemical Engineering*, 2020, 98(6): 1377-1389.