

基于 IPSO-DSDAE 的选冶智能化验过程 异常检测方法

高云鹏^{1†}, 周泳彬¹, 张微¹, 赵建军^{2,3}, 赵海利^{2,3}

(1. 湖南大学 电气与信息工程学院, 湖南 长沙 410082;

2. 矿冶过程智能优化制造全国重点实验室, 北京 100160;

3. 矿冶过程自动控制技术北京市重点实验室, 北京 100160)

摘 要:智能化验结果直接关联选冶产品的纯度与品质, 及时识别选冶智能化验过程中的异常情况对于避免工艺参数调整失当和生产效率下降至关重要, 因此对该过程进行准确的异常检测具有重要意义. 本文提出了一种基于改进粒子群算法(improved particle swarm optimization, IPSO)优化的深度稀疏降噪自编码器(deep sparse denoising auto-encoder, DSDAE)的异常检测方法. 首先, 建立基于自编码器(auto-encoder, AE)的重构模型, 通过引入稀疏性约束、降噪机制和深层网络结构, 提高模型的鲁棒性与特征提取能力. 其次, 使用改进粒子群算法对模型参数进行优化. 最后, 开发选冶化验过程在线监测系统对本文提出的方法进行实际验证. 实验结果表明, 本文提出的方法的异常检测准确率达到 99.86%, 误报率及漏检率分别为 0.25% 与 0.28%, 相比现有方法提高了检测准确率、降低了误报率与漏检率, 可实现选冶智能化验过程异常数据的准确检测.

关键词:智能化验室; 深度稀疏降噪自编码器; 改进粒子群算法; 异常检测; 状态监测

中图分类号:TD926

文献标志码:A

Anomaly detection method for intelligent assay laboratory process in mineral processing and metallurgy based on IPSO-DSDAE

GAO Yunpeng^{1†}, ZHOU Yongbin¹, ZHANG Wei¹, ZHAO Jianjun^{2,3}, ZHAO Haili^{2,3}

(1. College of Electrical and Information Engineering, Hunan University, Changsha 410082, China;

2. State Key Laboratory of Intelligent Optimization and Manufacturing in Mining & Metallurgy, Beijing 100160, China;

3. Beijing Key Laboratory of Process Automation in Mining & Metallurgy, Beijing 100160, China)

Abstract: The results of intelligent assays are directly related to the purity and quality of mineral processing and metallurgical products. Timely identification of anomalies in the intelligent assay process is crucial for preventing improper adjustments to process parameters and avoiding declines in production efficiency. Therefore, accurate anomaly detection in this process is of great significance. This paper proposes an anomaly detection method based on deep sparse denoising auto-encoder (DSDAE) optimized by improved particle swarm optimization (IPSO)

* 收稿日期:2025-08-08

基金项目:国家重点研发计划资助项目(2021YFF0602402), National Key Research and Development Program of China(2021YFF0602402)

作者简介:高云鹏(1978—), 男, 辽宁营口人, 湖南大学教授, 博士

† 通信联系人, E-mail:gaoyunpeng@hnu.edu.cn

algorithm. First, a reconstruction model based on auto-encoder (AE) is established, in which sparsity constraints, a denoising mechanism, and a deep network structure are introduced to enhance the model's robustness and feature extraction capability. Then, the model parameters are optimized using the improved particle swarm optimization algorithm. Finally, an online monitoring system for the assay process is developed to validate the proposed method. Experimental results show that the proposed method achieves an anomaly detection accuracy of 99.86%, with a false alarm rate of 0.25% and a missed detection rate of 0.28%. Compared with existing methods, it significantly improves detection accuracy while reducing both false alarm rate and missed detection rate, enabling accurate anomaly detection in the intelligent assay process of mineral processing and metallurgy.

Key words: intelligent assay laboratory; deep sparse denoising auto-encoder; improved particle swarm optimization; anomaly detection; condition monitoring

随着选冶行业自动化建设与发展,智能化实验室成为控制选矿工艺质量的关键组件^[1].选冶智能化实验室通过整合机器设备与自动控制技术,实现对矿产样品物质成分、物理性质及工艺参数的自动化精确测定,其化验结果为选冶环节的工艺优化、设备调控与质量管控提供量化依据,为保障产品达标构筑核心防线^[2].然而,实际过程中由于样品污染、设备故障及人为操作不当等因素,异常情况时有发生,造成工艺参数调整失当、生产效率下降^[3].因此,选冶智能化验过程中的异常检测技术研究对维护智能化实验室的稳定运行具有重要价值与意义^[4].

当前异常检测主要可分为基于专家知识、基于解析模型和基于数据驱动三大类^[5-6],考虑到化验等实际工业过程相关参数的复杂性、耦合性和强非线性,不仅难以依靠领域专家的经验构建准确适用的规则^[7],而且要建立系统的准确解析模型也面临极大挑战^[8].相比之下,基于数据驱动的方法不依赖于机理知识和精确模型,可通过挖掘历史数据的有效信息,广泛应用于复杂过程数据的异常检测方面^[9].为此,刘强等^[10]提出利用主成分分析法(principal component analysis, PCA),通过对数据的主成分提取进行特征降维,结合测试统计量的变化实现异常判别. BANERJEE等^[11]构建基于偏最小二乘法(partial least squares, PLS)的异常检测方案,以最大化模型输入与输出间的协方差的方式区分质量相关空间,模型投影偏离程度较大即为异常数据. MANOHARAN等^[12]建立支持向量机(support vector machine, SVM),将异常检测问题转化为二分类问题,训练寻找最优超平面以区分正常样本与异常样

本. LIU等^[13]使用 K 最近邻算法(K -nearest neighbor, KNN),通过寻找新的输入实例在特征空间中距离最近的 K 个训练样本,确定输入实例的异常情况划分.然而,上述方法对数据分布的假设过于严苛,不符合假设或未知分布的数据将极大影响检测效果^[14].此外,相关异常检测方法高度依赖充足的有标签样本进行模型训练,缺少自动挖掘数据深层特征的能力.实际应用中异常样本通常数量稀少,且人工标注成本高,导致模型的检测准确度显著下降^[15].

针对上述存在的问题,基于无监督的自编码器(auto-encoder, AE)以其出色的非线性重构能力,在异常检测领域的应用逐渐增多. KARIM等^[16]和 ZHAO等^[17]利用AE识别与重构正常数据实例之间的共享模式进行异常检测. RAVI等^[18]通过将AE与SVM技术相结合,实现对异常视觉数据的检测. REUTER等^[19]提出使用深度前馈网络压缩提取数据特征,以提高AE的检测效果.然而,单层神经网络的基础结构导致AE特征提取能力有限,难以处理大规模数据集,且其对正常数据的重构效果会因噪声的干扰而显著下降.并且,AE的超参数与模型性能的映射关系复杂且难以凭经验确定,若超参数配置不当将放大模型在复杂场景下的不适应性.因此,对于不稳定性强、背景噪声大的选冶智能化验过程数据,基于AE的异常检测方法存在准确率低、漏检率高的问题.

为此,本文提出一种深度稀疏降噪自编码器(deep sparse denoising auto-encoder, DSDAE),针对AE数据重构效果受背景噪声影响大的问题,通过对输入数据加噪处理,使模型学习数据更具鲁棒性的

特征表示;同时在损失函数中引入稀疏性约束,利用多层网络结构,提高模型对高维数据的编码与特征提取能力.为增强模型的自适应性,设计改进粒子群优化(improved particle swarm optimization, IPSO)算法对DSDAE的超参数进行自适应寻优,解决传统优化算法易陷入局部最优的问题,最终提出基于IPSO-DSDAE的选冶智能化验过程异常检测方法,并基于选冶智能化验的运行过程实例验证本文提出方法的准确性和有效性.

1 选冶智能化验与异常模式

传统选冶化验操作由经验丰富的工人在专业化

验实验室中完成,化验结果易受工人疲劳、环境干扰等因素影响,稳定性欠佳.针对人工化验的不足,设计并开发选冶智能在线化验室,实现选冶化验操作的流水线化自动运行,降低因人为操作产生的数据误差,据此提高选冶化验效率和化验结果的准确度.

选冶智能在线化验室完整的工作过程如下:首先使用采样泵将被测样品抽取到样品管中,通过压缩空气机输送到样品接收站处并完成分拣;采用高精度注射泵将样品移位至自动制备装置中,根据元素含量的高低设定不同的稀释倍数,实现精确定容;最后将样品移动至高精度载流矿浆元素在线分析仪中,完成样本分析.选冶智能在线化验室工作原理如图1所示.




图1 选冶智能在线化验室工作原理图

Fig.1 Schematic diagram of the mineral processing intelligent assay laboratory

实际运行中设备故障、样品污染等因素可能导致选冶智能在线化验过程状态偏离正常工艺参数范围,若不能及时检测并处理异常,将严重影响化验结果与工艺决策的准确性.选冶智能在线化验过程异常数据的典型表现形式可分为恒偏差异常、卡死异常、突发异常和漂移异常4类,数据波形如图2所示.

1)恒偏差异常:蠕动泵的输出值持续偏离真实值,如消解溶液A进料体积因零点漂移导致测量值始终偏高1 mL,如图2(a)所示.

2)卡死异常:称重传感器因电气或机械故障停止动作,如待测样品质量在定容前某时刻固定为某一值,如图2(b)所示.

3)突发异常:蠕动泵的输出值受电磁干扰出现跳变,如消解溶液C进料体积增至正常范围之上,如图2(c)所示.

4)漂移异常:注射泵的零部件性能退化导致输出值缓慢偏移,如添加水体积随使用时间增长出现系统性漂移,如图2(d)所示.

2 基于IPSO-DSDAE的选冶智能化验过程异常检测

2.1 基于深度稀疏降噪自编码器的数据重构模型

选冶智能化验过程的异常判别通常依赖人工经验,由于设备故障、样品污染等异常工况在实际生




图2 选冶化验过程异常数据模式

Fig.2 Anomalous data patterns in mineral processing assay process

产中呈现低频且不可预知的特征,异常样本极为稀缺且标注成本高昂,严重制约了依赖大规模有标签数据的传统机器学习模型的有效应用.作为无监督学习模型的自编码器(AE)能自主挖掘数据深层特征关联,无需标签即可运行,这与选冶智能化验过程异常检测任务需求高度适配.

采集选冶智能化验过程状态数据作为AE的输入 $\{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m\}$,其中 $\mathbf{x}_i \in \mathbb{R}^n$, ($i=1, 2, \dots, m$), m 为输入特征数据个数, n 为输入特征数据维度, AE的编码器部分隐藏层的激活表达式为:

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

式中: f 为编码函数; $\mathbf{W}_e$ 为编码器神经网络的权重; $\mathbf{b}_e$ 为编码器神经网络的偏置; s_e 为激活函数.

解码器以编码器的输出结果 $\mathbf{h}$ 作为输入,该部分隐藏层得到激活表达式为:

$$\mathbf{y} = g(\mathbf{h}) = s_d(\mathbf{W}_d \mathbf{h} + \mathbf{b}_d) \quad (2)$$

式中: g 为解码函数; $\mathbf{W}_d$ 为解码器神经网络的权重; $\mathbf{b}_d$ 为解码器神经网络的偏置; s_d 为激活函数.

采用AE对已知的选冶智能化验过程状态样本

特征编码,使其逼近实际测量样本的特征来实现过程数据重构,将评价模型训练效果的损失函数定义为:

$$J_{AE}(\boldsymbol{\theta}) = \frac{1}{m} \sum_{i=1}^m L(\mathbf{x}_i, g(f(\mathbf{x}_i))) \quad (3)$$

式中: $\boldsymbol{\theta}$ 为模型网络参数矩阵 $\{\mathbf{W}, \mathbf{b}\}$; L 为均方误差函数.

由于选冶智能化验过程数据具有强背景噪声特性,为提高AE提取数据特征时的鲁棒性,对模型输入数据加入随机高斯白噪声,构成降噪自编码器(denoising auto-encoder, DAE),损失函数定义为:

$$J_{DAE}(\boldsymbol{\theta}) = \frac{1}{m} \sum_{i=1}^m L(\mathbf{x}_i, g(f(\mathbf{x}_i^*))) \quad (4)$$

式中: $\mathbf{x}_i^*$ 为经过噪声干扰后的污染输入.

DAE的基本结构如图3所示.

为降低模型处理高维选冶智能化验过程特征数据时的计算量、提高模型的特征提取能力,向损失函数中引入稀疏惩罚项约束,所得模型为稀疏降噪自编码器(sparse denoising auto-encoder, SDAE),其损失函数定义为:




图 3 降噪自编码器模型结构

Fig.3 Denoising auto-encoder architecture

$$J_{\text{SDAE}}(\theta) = J_{\text{DAE}}(\theta) + u \sum_{j=1}^S K_L(\rho || \hat{\rho}_j) \quad (5)$$

式中: S 为隐藏层神经元数量; u 为控制稀疏项强度的权重因子; $K_L(\rho || \hat{\rho}_j)$ 为惩罚因子的相对熵, 具体计算式见式(6)、式(7)。

$$K_L(\rho || \hat{\rho}_j) = \rho \log \frac{\rho}{\hat{\rho}_j} + (1 - \rho) \log \frac{1 - \rho}{1 - \hat{\rho}_j} \quad (6)$$

$$\hat{\rho}_j = \frac{1}{m} \sum_{i=1}^m [a_j x^i] \quad (7)$$

式中: $\hat{\rho}_j$ 代表编码器部分隐藏层各神经元的平均激活值; ρ 表示稀疏度; $a_j x^i$ 表示隐藏层节点 j 对样本 i 的响应输出。

为进一步捕捉选冶智能化验过程正常数据与异常数据间的深层特征差异, 将 SDAE 的网络隐藏层层数加深, 所得模型为 DSDAE, 其损失函数定义为:

$$J_{\text{DSDAE}}(\Theta) = \|x - z\|^2 + u \sum_{j=1}^S K_L(\rho || \hat{\rho}_j) \quad (8)$$

式中: Θ 为各个隐藏层对应的权重矩阵和偏置向量的集合; x 为输入特征数据; z 为 DSDAE 模型的输出结果。

DSDAE 通过逐层学习原始数据的特征, 相比于单层 AE 能够得到更深层次的特征表达, 且在特征提取过程中减少信息的丢失^[20]。深度网络的层数会影响模型的拟合效果, 模型复杂度也会影响其泛化能力。结合以往工程经验, 综合选冶过程对于模型可靠性和运算的复杂程度需求, 本文提出的 DSDAE 的编码器部分与解码器部分各包含 3 层隐藏层, 该结构可实现“原始信号—局部设备协同特征—全局异常判别特征”的分层抽象, 兼顾表征能力与训练稳定性, 同时避免了深层模型可能导致的过拟合和梯度消失问题, 在特征提取能力、优化稳定性与工业适配性间实现最优权衡, DSDAE 结构示意图如图 4 所示。

2.2 基于改进粒子群搜索的模型优化

DSDAE 的性能高度依赖于超参数的合理配置, 而选冶智能化验过程因其数据非线性强、时变特性明显且工况多变的特点, 对模型结构超参数提出更严苛的要求。若超参数配置不当, 模型将难以有效捕




图 4 深度稀疏降噪自编码器模型结构

Fig.4 Deep sparse denoising auto-encoder architecture

捉工艺过程中的复杂模式和细微变化, 导致对正常工况的学习不充分, 最终造成异常检测的误报率和漏检率显著升高。

作为解决全局优化问题的智能启发式算法, 粒子群优化算法 (particle swarm optimization, PSO) 能通过并行评估各组超参数对应的适应度值高效驱动搜索过程, 无须推导复杂的梯度信息, 这与选冶智能化验工业场景对算法鲁棒性和实用性的高要求高度契合, 因此本文引入改进 PSO 对 DSDAE 模型的网络结构超参数进行系统优化。

PSO 中每个粒子都具有两个属性: 表示当前候选解的位置和表示粒子在搜索空间中移动方向和距离的速度属性。其更新式为:

$$v_i(t+1) = \omega \cdot v_i(t) + c_1 \cdot r_1 \cdot (P_{\text{best}} - x_i(t)) + c_2 \cdot r_2 \cdot (G_{\text{best}} - x_i(t)) \quad (9)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (10)$$

式中: $v_i(t)$ 是粒子 i 在第 t 次迭代的速度; $x_i(t)$ 是粒子 i 在第 t 次迭代的位置; ω 为惯性权重, 用于调节全局和局部搜索能力; c_1 和 c_2 为加速度因子; r_1 和 r_2 为分布于 $[0, 1]$ 的随机数; P_{best} 为个体最优位置; G_{best} 为全局最优位置。

PSO 存在早熟易收敛、搜索精度较低、后期迭代效率较低等缺点。因此, 本文提出使用改进的动态非线性惯性权重代替传统的线性惯性权重, 实现权重的递减与粒子的非线性搜索过程相协调, 提高迭代后期算法的收敛速度。改进后惯性权重的更新计算式为:

$$\omega(t) = \omega_{\text{start}} + (\omega_{\text{start}} - \omega_{\text{end}}) \times \left(\frac{2t}{T_{\text{max}}} - \frac{t^2}{T_{\text{max}}^2} \right) \quad (11)$$

式中: t 为当前迭代次数; ω_{start} 为初始惯性权重; ω_{end} 为迭代至最大次数时的惯性权重; T_{max} 为最大迭代次数。

粒子位置的搜索空间将随着迭代的进行而不断缩小,为使粒子能够跳出先前搜索到的最优值位置,向其更新计算式中引入自适应变异机制,扩大PSO的搜索范围.则有自适应变异的表达式为:

$$p = 0.5 \times \frac{t}{T_{\max}} + 0.5 \quad (12)$$

$$\mathbf{x}_{is}(t+1) = r_3(\mathbf{d}_{\max} - \mathbf{d}_{\min}) + \mathbf{d}_{\min} \quad (13)$$

式中: p 为自适应变异的概率; r_3 为分布于 $[0,1]$ 的随机数,当 $r_3 > p$ 时发生自适应变异; $\mathbf{x}_{is}$ 为随机变异粒子 s 的位置; $\mathbf{d}_{\max}$ 和 $\mathbf{d}_{\min}$ 分别表示粒子的最大和最小位置.

2.3 基于IPSO-DSDAE的异常检测

异常判定的阈值是影响选冶智能化验过程数据异常检测结果的重要因素,对于任意输入样本 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$,经IPSO-DSDAE编码-解码后得到的重构样本为: $\mathbf{Z} = [z_1, z_2, \dots, z_n]^T$,则单样本的重构残差向量 $\mathbf{R}$ 定义为:

$$\mathbf{R} = \mathbf{X} - \mathbf{Z} \quad (14)$$

设残差向量元素 r_i 反映第 i 个特征的重构偏差,

$r_i = x_i - z_i$.为消除特征量纲影响、综合衡量整体重构误差,引入均方根误差作为残差指标,其具体计算式为:

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n r_i^2} \quad (15)$$

设训练集包含 m 个正常样本,其均方根误差记为 $\{\text{RMSE}_1, \text{RMSE}_2, \dots, \text{RMSE}_m\}$,则正常样本的残差均值 μ 和标准差 σ 计算分别如下:

$$\mu = \frac{1}{m} \sum_{k=1}^m \text{RMSE}_k \quad (16)$$

$$\sigma = \sqrt{\frac{1}{m} \sum_{k=1}^m (\text{RMSE}_k - \mu)^2} \quad (17)$$

根据 3σ 原则,异常判定阈值设置为:

$$\text{Thres} = \mu + 3\sigma \quad (18)$$

式中: Thres 为异常判定阈值.当测试样本 $\text{RMSE} > \text{Thres}$ 时,判定为异常样本,反之判定为正常样本.

综上所述,本文提出的基于IPSO-DSDAE的选冶智能化验过程异常检测方法的流程示意图如图5所示.




图5 基于IPSO-DSDAE的选冶智能化验过程异常检测方法流程图

Fig.5 Flowchart of the IPSO-DSDAE-based anomaly detection method for the intelligent assay process in mineral processing and metallurgy

由图5可知,基于IPSO-DSDAE的选冶智能化验过程异常检测方法主要步骤如下:

1)选冶智能化验过程数据集构建.对选冶智能

在线化验室采集的多维状态数据进行预处理操作以消除量纲差异,完成选冶智能化验过程状态数据集的构建.

2)设置 IPSO 参数和适应度函数. 初始化粒子群算法的最大迭代次数、粒子的速度和位置, 建立适应度函数.

3)计算粒子个体适应度. 确定个体最优位置和全局最优位置. 根据式(9)和式(10)更新粒子的速度和位置, 将新粒子的适应度值与个体和全局最优位置进行比较并更新.

4)IPSO 算法优化 DSDAE 模型参数. 判断迭代次数是否达到上限或是否满足终止条件, 若不满足则开启下一次迭代, 根据式(11)完成惯性权重参数的非线性递减, 并且根据式(12)和式(13)引入位置自适应变异; 若满足则结束优化过程, 记录此时的全局最优位置, 赋予 DSDAE 模型参数.

5)选冶智能化验过程异常检测输出. 基于 IPSO-DSDAE 方法建立选冶智能化验过程异常检测模型, 使用模型重构选冶智能化验过程数据, 通过比较样本重构残差的 RMSE 与异常判定阈值实现对异常数据的判别.

3 实验与分析

3.1 数据分析和预处理

为验证本文提出的基于 IPSO-DSDAE 的选冶智能化验过程异常检测方法的准确性和有效性, 在福建紫金矿业的选冶智能在线化验室开展工业试验, 实际采集 2023 年 11 月 6 日至 2024 年 5 月 10 日的 3 700 组选冶智能化验过程数据作为样本, 以 IPSO-DSDAE 检测模型为基础, 确定烧瓶质量、待测样品质量、A/B/C 溶液进料体积、样品装料量等为输入变量, 其各自的重构值为输出变量, 异常检测模型的输入、输出变量见表 1, 现场采集的数据见表 2.

表 1 异常检测模型输入与输出变量			
Tab.1 Model inputs and outputs for anomaly detection			
输入变量	变量描述	变量单位	输出变量
X_1	烧瓶质量	g	Y_1
X_2	待测样品质量	g	Y_2
X_3	A 溶液进料体积	mL	Y_3
X_4	B 溶液进料体积	mL	Y_4
X_5	C 溶液进料体积	mL	Y_5
X_6	样品装料量	g	Y_6
X_7	1#泵加水体积	mL	Y_7
X_8	2#泵加水体积	mL	Y_8

表 2 现场部分采集数据								
Tab.2 Partial field-collected data								
序号	X_1/g	X_2/g	X_3/mL	X_4/mL	X_5/mL	X_6/g	X_7/mL	X_8/mL
1	115.584 3	0.159 7	12.074	4.180	5.183	124.049	91.707	1.049
2	115.466 9	0.145 0	12.012	4.121	5.089	123.380	92.154	1.166
3	111.594 2	0.163 4	11.979	3.964	5.024	121.239	90.139	1.593
4	115.077 4	0.146 2	12.129	4.080	5.164	123.914	91.326	1.216
.....								
3700	114.218 0	0.140 9	12.126	3.994	5.192	123.491	90.985	1.075

由表 1 和表 2 可知, 选冶智能在线化验室采集的数据可能存在运行数据单位不同、数值差异较大的情况, 为确保模型建立的准确性和稳定性, 使用 Min-Max 归一化函数, 对原始数据进行预处理, 使数据落入[0,1]区间, 其计算式为:

$$x_i = \frac{X_i - X_{\min}}{X_{\max} - X_{\min}}$$

(19)

式中: X_i 为该条数据的原始特征值; $X_{\max}$ 和 $X_{\min}$ 分别表示数据中的最大特征值和最小特征值; x_i 为归一化操作后新的特征值.

将采集的 3 700 组原始数据的 80% 作为训练集, 20% 作为测试集. 在测试集中引入采集的不同类型的异常工况数据, 形成 4 组不同异常样本测试集, 异常样本测试集的设置如表 3 所示.

表 3 异常样本测试集设置				
Tab.3 Anomalous sample test set configuration				
测试集 序号	异常变量	异常样本	正常样本	异常类型
1	X_3/mL	(391~740)	(0~390)	恒偏差
2	X_2/g	(171~210),	(0~170),	卡死
		(481~505)	(211~480), (506~740)	
3	X_5/mL	(271~530)	(0~270), (531~740)	突发
4	X_8/mL	(471~740)	(0~470)	漂移

3.2 评价指标

在选冶智能化验过程中, 异常检测模型的检测结果可分为以下各种情况:

1)真阳性(true positive, TP):过程出现异常情况, 模型准确地识别出异常并报警.

2)真阴性(true negative, TN):实际过程正常, 样品的检测结果符合预期, 检测模型能够正确地判断为正常状态.

3)假阳性(false positive, FP):实际过程正常, 但模型错误地将其判断为异常情况并报警;

4)假阴性(false negative, FN):过程出现异常情况,但模型未能识别出来,没有报警.

为评估异常检测模型的性能,本文选用准确率(accuracy, ACC)、误报率(false alarm rate, FAR)、漏检率(false negative rate, FNR)、 F_1 作为评价指标,通过比较多种方法的上述指标实现对提出算法的评价,指标的计算公式分别如下:

$$ACC = \frac{TP + TN}{TP + TN + FP + FN} \tag{20}$$

$$FAR = \frac{FP}{TN + FP} \tag{21}$$

$$FNR = \frac{FN}{TP + FN} \tag{22}$$

$$F_1 = \frac{2 \times P \times R}{P + R} \tag{23}$$

式中: P 为精确率; R 为召回率.

3.3 实验结果和分析

为验证本文提出的 IPSO-DSDAE 模型在选冶智能化化验过程的异常检测中具备鲁棒性,且能够有效提高准确率、降低误报率,本文从算法收敛过程、序列重构结果、抗噪性能分析以及与现有方法对比四个方面进行分析验证.实验使用 Windows 10 操作系统, CPU 为 Intel(R) Core(TM) i7-9750H, 显卡为 NVIDIA GeForce GTX1650, 内存为 16 GB.

3.3.1 算法收敛过程

利用 2.2 节所述的 PSO 和 IPSO 算法分别提取 DSDAE 网络结构超参数,算法的初始参数设置如表 4 所示.

表 4 PSO 和 IPSO 算法实验参数表
Tab.4 Experimental parameter table for PSO and IPSO algorithms

参数名称	PSO	IPSO
种群规模	10	10
最大迭代次数	100	100
惯性权重	$\omega = 0.5$	$\omega_k = 0.9 - 0.5 \tanh\left(\frac{t\pi}{4T_{\max}}\right)$
自适应变异概率	—	$p = 0.5 \times \frac{t}{T_{\max}} + 0.5$
位置变异	—	rand int (10, 200)
学习因子	$c_1 = c_2 = 0.5$	$c_1 = c_2 = 0.5$

IPSO 优化 DSDAE 网络参数迭代过程如图 6 中蓝色实线所示.

由图 6 可知,IPSO 迭代到 33 次时收敛至全局最优值.与 PSO 相比,IPSO 重构损失更低,说明 IPSO 能更好地平衡全局搜索和局部开发,具有更高的搜索精度和更好的优化性能.




图 6 PSO 和 IPSO 的适应度变化曲线

Fig.6 Fitness evolution curves of PSO and IPSO

采用 IPSO 算法优化 DSDAE 网络超参数,模型训练过程每次网络的激活函数为 Sigmoid,学习率为 0.01,批处理大小为 50,迭代次数为 200,后续实验训练参数与此保持一致,本文选择 Adam 作为模型的优化器.为评估本文所提出模型的训练效果,本文利用式(10)计算 DSDAE 模型每次迭代的损失值,并进行收敛性检验,如图 7 所示.




图 7 DSDAE 模型训练损失

Fig.7 Training loss of the DSDAE model

由图 7 可知,DSDAE 在前 15 次迭代中损失下降趋势明显,随后逐渐收敛,该结果表明本文构建的模型可更好地学习训练数据中的模式和规律.

3.3.2 序列重构结果

采用正常工况下化验过程数据集作为训练集,对构建的 IPSO-DSDAE 模型进行训练,使模型具备重构正常化验过程数据的能力;使用测试集对模型进行验证,每组测试数据的异常数据重构结果和重构误差热力图分别如图 8 和图 9 所示.

由图 8 可知,在选冶智能化化验过程数据正常样本对应的采样点范围内,IPSO-DSDAE 模型的输出




图 8 选冶智能化验过程序列重构效果图

Fig.8 Sequence reconstruction results of the intelligent assay process in mineral processing and metallurgy




图 9 选冶智能化验过程序列重构误差热力图

Fig.9 Heatmap of reconstruction errors in the sequence of the intelligent assay process for mineral processing and metallurgy

重构结果与输入特征数据高度重合,平均重构残差值较小,表明模型能准确学习并重构正常选冶智能化验过程数据的特征模式,对正常数据的拟合效果优异;在异常样本对应的采样点区间内,模型输出的重构值与真实值出现明显偏离,平均重构残差值显著增大,且异常检测结果能准确标记出这些异常区间,说明模型对异常数据的重构能力显著下降,可通过重构值与真实值的偏差有效识别选冶智能化验过程异常.

由图9可知,在选冶智能化验过程数据正常样本对应的采样点范围内,热力图颜色较浅,表明重构误差较小;在异常样本对应的采样点区间内,异常特征变量对应的热力图颜色较深,表明该变量的重构误差较大.热力图清晰地量化了各变量对总残差的贡献比例,实现了异常变量的快速定位,为异常溯源和故障定位提供了精准指引.

3.3.3 抗噪性能分析

为了突出所提基于IPSO-DSDAE的异常检测模型在强背景噪声下具有更好的抗噪性能,本文构建了4种同样基于DSDAE模型的对比模型,分别为PSO-DSDAE、GJO-DSDAE^[21]、SSA-DSDAE^[22]、RSO-DSDAE^[23],其中所有模型的网络深度为6层,其余参数均与原文献保持一致.

在实测数据中加入高斯白噪声以模拟噪声干扰,共生成信噪比分别为18、16、14、12、10、8 dB的6组含噪信号,再把强噪声干扰数据输入上述不同模型进行异常检测对比,最终结果取10次实验结果的平均值,具体如图10所示.

由图10可知,在不同信噪比的背景噪声下,本文提出的IPSO-DSDAE异常检测模型准确率始终高




图10 不同方法在不同背景噪声下检测准确率平均值
Fig.10 Average detection accuracy of different methods under various background noise levels

于 PSO-DSDAE、SSA-DSDAE、RSO-DSDAE 和 GJO-DSDAE. 在信噪比14~18 dB 范围内, PSO-DSDAE 模型准确率保持在98% 以上;在信噪比为12、10、8 dB 的背景噪声下本文模型准确率分别达到94.02%、86.2%、85.1%, 而其余模型的准确率均低于85%, 证明所提模型有更好的抗噪性能. 随着噪声不断增强, 5种模型异常检测准确率都呈下降趋势, 但相比其余4种模型, 本文提出的IPSO-DSDAE 模型下降趋势明显更缓慢, 总体波动更小, 说明所提模型能从噪声数据中学习更稳定和深层次的特征信息, 从而增强网络的鲁棒性和泛化能力, 在背景噪声下稳定性更好.

3.3.4 与现有方法对比

为更客观地评估提出本文模型的异常检测能力, 使用5个复杂工业过程中常用的无监督异常检测模型作为对比模型, 包括局部离群因子算法(local outlier factor, LOF)、支持向量机(SVM)、主成分分析法(principal component analysis, PCA)、生成对抗网络(generative adversarial network, GAN)、变分自编码器(variational autoencoder, VAE). 在相同的实验配置下对选矿化验过程数据集进行测试, 以测试集1为例, 比较本文所提出的IPSO-DSDAE 模型的性能, 其实验结果如表5所示.

表5 不同模型的异常检测结果对比
Tab.5 Comparison of anomaly detection results from different models

检测模型	准确率	误报率	漏检率	F_1 值
LOF	0.574 8	0.007 6	0.891 1	0.194 8
SVM	0.530 3	0.086 9	0.896 8	0.171 8
PCA	0.607 3	0.207 2	0.598 9	0.491 2
GAN	0.852 7	0.102 6	0.197 1	0.837 6
VAE	0.867 6	0.148 7	0.114 3	0.863 5
IPSO-DSDAE	0.998 6	0.002 5	0.002 8	0.998 5

由表5可知, 本文提出的IPSO-DSDAE 模型在整体性能方面优于其他对比模型, 取得了99.85% 的最高 F_1 值, 显著高于 VAE (86.35%) 和 GAN (83.76%);在准确率指标上, 相较于 VAE 和 GAN 分别提升了13.1和14.59个百分点;且本文提出的IPSO-DSDAE 模型漏检率仅为0.28%, 在保持高准确率的同时实现了低漏检率.

相比于 LOF、SVM、PCA, 本文提出的模型通过多层神经网络的逐层特征抽象, 自动学习从原始传

传感器信号到深层故障特征的非线性映射,而非仅依赖浅层特征映射,因此其捕捉复杂非线性关联的能力更强;相比于GAN,本文提出的模型无需大量正常样本支撑模型训练,且降噪机制的引入,提高了模型的鲁棒性和工业场景适配性;相比于VAE,本文提出模型通过稀疏性约束强制网络学习最具判别性的特征表示,在处理难以用简单概率分布描述的工业异常数据非结构化特征时,得到正常与异常样本的类间距离区分更为明显。

通过上述实验及其对比分析结果可知,本文提出的基于IPSO-DSDAE的选冶智能化验过程异常检测方法准确度和泛化能力相较于现有的其他模型得到了增强,可更好地实现选冶智能化验过程的异常检测和实际工程应用。

4 在线监测系统与实测结果

为实时掌握选冶智能化验过程关键参数动态、定位异常源并追溯历史数据,实现过程数据采集、处理、检测、预警的全流程闭环,本文设计开发了一套完整的选冶智能化验过程在线监测系统,其结构框图如图11所示。该系统通过部署于智能化验各环节设备上的高精度传感器网络实时采集过程数据,并将数据安全上传至云端样本库,实现数据的实时监测与结构化存储,系统后端采用Python语言的PYQT模块建立与数据库的稳定连接。





图11 选冶化验过程在线监测系统结构框图

Fig.11 System architecture of the online monitoring platform for the assay process

基于本文提出的IPSO-DSDAE模型开发了选冶智能化验过程异常检测功能模块,可实现对化验过程的异常精准检测、故障变量分离以及历史日志追溯等核心功能,将异常检测功能模块部署到选冶智能化验过程在线检测系统,系统管理界面如图12所示。该界面直观呈现了提出的异常检测模型在实际工业场景中的应用效果:界面实时展示了化验过程关键变量的观测值、模型重构值及当前重构残差,通过残差与阈值的对比实现异常状态实时判定。残差贡献分布图清晰地量化各变量对总残差的贡献比例,为故障定位提供精准指引。系统可自动记录异常发生时间、变量类型及残差变化趋势,支持日志导出与历史数据回溯。该界面实现了“数据采集—模型计算—异常判定—故障溯源”的全流程可视化,使操作人员能够快速掌握化验过程的运行状态,有效提升了异常处置的及时性与准确性。



说明: 本系统采用优化自编码器方法实现智能化验过程异常检测

图12 选冶化验过程在线检测系统界面

Fig.12 Interface of the online assay monitoring system

基于本系统,对福建紫金矿业的选冶智能在线化验室4组包含异常工况的化验流程进行异常检测,得到实际检测结果如表6所示。

由表6可知,本文开发的选冶化验过程在线监测系统在4组不同化验批次异常检测任务中的准确率均高于99%,且保持着低误报率和漏检率,表明本系统能有效实现选冶智能化化验过程的异常检测。

表6 系统实际异常检测结果
Tab.6 Actual anomaly detection results of the system

化验批次	准确率	误报率	漏检率	F_1 值
1	0.998 6	0.002 5	0.002 8	0.998 5
2	0.994 6	0.004 5	0.015 1	0.969 7
3	0.996 0	0.003 8	0.004 2	0.996 9
4	0.993 2	0.002 1	0.014 8	0.990 7

5 结论

本文针对选冶智能化化验过程中状态参数不稳定性强、异常样本稀缺且背景噪声干扰大导致的异常检测精度不足等问题,提出了一种基于改进粒子群算法优化深度稀疏降噪自编码器(IPSO-DSDAE)的异常检测方法。实验结果表明:本文构建的深度稀疏降噪自编码器(DSDAE)模型通过引入降噪机制,解决了模型在高噪声环境下鲁棒性低的问题;通过添加稀疏惩罚项,降低了计算复杂度并增强了特征提取能力;通过使用深层网络结构,实现了对高维选矿化验数据的有效特征抽象;同时本文设计的改进粒子群算法(IPSO)对模型超参数进行优化,通过引入动态非线性惯性权重调整与位置自适应变异策略,有效解决了传统算法易陷入局部最优的问题,提升了全局搜索能力和收敛精度。本文所提方法在选矿化验过程异常检测中取得了99.86%的高准确率,误报率与漏检率分别低至0.25%和0.28%,且在不同信噪比噪声干扰下表现出优异的抗噪能力和稳定性;相比现有方法,本方法在检测精度、抗干扰能力及稳定性方面均有显著提升,能更精准地识别各类异常。综上所述,本文提出方法可为选冶智能在线化验过程的安全稳定运行提供可靠的技术保障,具有重要的工程应用价值。

参考文献

[1] WU Y F, SUN Y R, YU X B, et al. Intelligent experiment robotic systems design for material preparation and detection[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2025, 55(2):1241-1251.

[2] 赵军生, 沈卫卫, 汪鹤鸣, 等. 哥伦比亚某含铜金矿石选冶过程优化生产实践[J]. 中国矿业, 2024, 33(5):232-238. ZHAO J S, SHEN W W, WANG H M, et al. Production practice of optimized beneficiation and smelting process for a copper-bearing gold ore in Colombia[J]. China Mining Magazine, 2024, 33(5):232-238. (in Chinese)

[3] 权土生. 矿山选矿化验过程中误差分析与质量控制策略研究[J]. 世界有色金属, 2024(12): 193-195. QUAN T S. Research on error analysis and quality control strategies in the mineral processing and analysis process of mines [J]. World Nonferrous Metals, 2024(12): 193-195. (in Chinese)

[4] ZHANG W, GAO Y P, ZHOU Y B, et al. A denoising shrinkage stacked autoencoder method for fault detection in industrial beneficiation ILAB process with uncertainty [J]. Measurement, 2025, 256:117910.

[5] XING Y Q, WANG B W, GONG Z C, et al. Data-driven fault diagnosis for PEM fuel cell system using sensor pre-selection method and artificial neural network model[J]. IEEE Transactions on Energy Conversion, 2022, 37(3):1589-1599.

[6] ZHOU Y, WANG K, ZHANG Y L, et al. A review of statistical process monitoring methods for non-linear and non-Gaussian industrial processes [J]. The Canadian Journal of Chemical Engineering, 2025, 103(7): 3092-3119.

[7] 仇晶, 陈荣融, 朱浩瑾, 等. 基于溯源图的网络攻击调查研究综述[J]. 电子学报, 2024, 52(7):2529-2556. QIU J, CHEN R R, ZHU H J, et al. A survey of network attack investigation based on provenance graph [J]. acta electronica Sinica, 2024, 52(7): 2529-2556. (in Chinese)

[8] ZHANG Z J, LI S Y, YANG Y R. Explorative policy optimization for industrial-scale operation of complex process control systems [J]. Journal of Process Control, 2025, 152:103471.

[9] LOMOV I, LYUBIMOV M, MAKAROV I, et al. Fault detection in Tennessee Eastman process with temporal deep learning models [J]. Journal of Industrial Information Integration, 2021, 23: 100216.

[10] 刘强, 孔德志, 郎自强. 基于多级动态主元分析的电熔镁炉异常工况诊断[J]. 自动化学报, 2021, 47(11): 2570-2577. LIU Q, KONG D Z, LANG Z Q. Multi-level dynamic principal component analysis for abnormality diagnosis of fused magnesia furnaces [J]. Acta Automatica Sinica, 2021, 47(11): 2570-2577. (in Chinese)

[11] BANERJEE A, ROY K. Machine-learning-based similarity meets traditional QSAR: “q-RASAR” for the enhancement of the external predictivity and detection of prediction confidence outliers in an hERG toxicity dataset [J]. Chemometrics and

- Intelligent Laboratory Systems, 2023, 237:104829.
- [12] MANOHARAN A, BEGAM K M, APAROW V R, et al. Artificial neural networks, gradient boosting and support vector machines for electric vehicle battery state estimation; a review[J]. Journal of Energy Storage, 2022, 55:105384.
- [13] LIU S Z, MA S, CHEN H Q, et al. Combining KNN with autoencoder for outlier detection[J]. Journal of Computer Science and Technology, 2024, 39(5):1153-1166.
- [14] 于骞翔, 李擎, 李琳琳, 等. 面向大规模工业生产过程的数据驱动故障诊断方法综述[J]. 工程科学学报, 2025, 47(4): 780-793.
- YU Q X, LI Q, LI L L, et al. A survey of data-driven fault-diagnosis methods for large-scale industrial production processes [J]. Chinese Journal of Engineering, 2025, 47(4): 780-793. (in Chinese)
- [15] 王嘉玺. 化工过程异常检测方法研究及应用[D]. 北京:北京化工大学, 2022.
- WANG J X. Research and application of anomaly detection method in chemical process [D]. Beijing: Beijing University of Chemical Technology, 2022. (in Chinese)
- [16] KARIM A M, KAYA H, GÜZEL M S, et al. A novel framework using deep auto-encoders based linear model for data classification [J]. Sensors, 2020, 20(21):6378.
- [17] ZHAO J C, DENG F, LI Y L, et al. Attract-repel encoder: learning anomaly representation away from landmarks [J]. IEEE Transactions on Neural Networks and Learning Systems, 2022, 33(6): 2466-2479.
- [18] RAVI A, KARRAY F. Autoencoder regularization using support vector data description for anomaly detection [C]//2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC). October 17-20, 2021. Melbourne, Australia. IEEE, 2021:1842-1848.
- [19] REUTER L, JUNG O, MAGIN J. Neural network based anomaly detection for SCADA systems [C]//2020 23rd Conference on Innovation in Clouds, Internet and Networks and Workshops (ICIN). February 24-27, 2020. Paris, France. IEEE, 2020: 194-201.
- [20] 王印松, 赵佳玉. 基于深度自编码器的城市固废焚烧过程燃烧状态识别[J]. 控制工程, 2024, 31(10):1729-1737.
- WANG Y S, ZHAO J Y. Combustion state recognition of municipal solid waste incineration process based on deep autoencoder [J]. Control Engineering of China, 2024, 31(10): 1729-1737. (in Chinese)
- [21] 张毛焕, 张伟杰, 徐树山. 基于改进金豺狼算法优化堆叠降噪自编码器的离心泵故障诊断方法[J]. 计量学报, 2025, 46(5): 730-737.
- ZHANG M H, ZHANG W J, XU S S. Centrifugal pump diagnosis using stacked denoising auto encoders optimized by improved golden jackal optimization [J]. Acta Metrologica Sinica, 2025, 46(5):730-737. (in Chinese)
- [22] 马良玉, 孙佳明. 基于SDAE预测模型和改进SSA的NO_x排放优化[J]. 中国电机工程学报, 2022, 42(14): 5194-5201.
- MA L Y, SUN J M. NO_x emission optimization based on SDAE prediction model and improved SSA [J]. Proceedings of the CSEE, 2022, 42(14):5194-5201. (in Chinese)
- [23] 张彬桥, 舒勇, 江雨. 基于改进变分模态分解和优化堆叠降噪自编码器的轴承故障诊断[J]. 计算机集成制造系统, 2024, 30(4): 1408-1421.
- ZHANG B Q, SHU Y, JIANG Y. Bearing fault diagnosis based on improved variational mode decomposition and optimized stacked denoising autoencoder [J]. Computer Integrated Manufacturing Systems, 2024, 30(4):1408-1421.