

基于实时机器学习算法的湿法冶金设备智能控制与故障检测模型设计研究

赵 铮

(平顶山职业技术学院 计算机科学与技术系,河南 平顶山 467000)

摘要:针对当前湿法冶金设备控制和智能检测模型较为简单、泛化能力较弱等问题,提出了一种基于深度学习的湿法冶金设备智能控制和故障检测算法模型,首先利用基于 SAC 深度强化学习算法对湿法冶金设备进行智能控制,再根据智能控制的近期历史数据,采用改进 ARIMA 算法对设备进行故障检测。为了进一步提升算法的实时性,引入 LoRA 微调网络对模型进行低参数微调和加速,LoRA 微调网络对模型进行低参数微调和加速。该模型对设备智能化控制精度达 93.24%,故障检测准确率达 91.34%,实际应用效果较好。

关键词:实时机器学习;SAC;ARIMA;LoRA

中图分类号:TF803.21 **文献标识码:**A **文章编号:**1009-2617(2025)02-0222-08

DOI:10.13355/j.cnki.sfyj.2025.02.011

在湿法冶金领域,设备的连续稳定运行是确保生产正常进行的重要条件。为了有效应对设备故障,减少停机时间、降低维护成本、延长设备使用寿命、提升生产效率,将实时机器学习算法应用于设备控制逐渐受到了关注。实时机器学习算法能够动态调整和优化设备控制参数^[1],通过构建智能故障检测模型,可以实现对设备状态的实时监测与精准预测,实现设备故障的早期预警与诊断,预防故障发生^[2]。随着技术的不断发展,实时机器学习算法在湿法冶金设备控制与故障检测领域的应用前景日益广阔。

目前,基于机器学习和深度学习的湿法冶金设备控制与故障检测方法的研究已有一些研究^[3-6],但仍存在模型较为简单、泛化能力弱、隐蔽设备故障预测不足、智能化程度较低等问题。为了探索更为先进、智能的湿法冶金设备控制与故障检测方法,研究提出了一个基于深度学习的实时湿法冶金设备智能控制和故障检测算法模型,首先利用基于 SAC 深度强化学习算法^[1]对湿法冶金设备进行智能控制,然后根据智能控制的近期历史数据,采用改进 ARIMA 算法^[2]进行故障

检测。为了进一步提升该算法模型的实时性,引入 LoRA 微调网络^[7]对模型进行低参数微调和加速。最后通过实证研究验证该算法模型的有效性。

1 基于 SAC 深度强化学习算法的湿法冶金设备智能控制

软演员评论家算法(Soft Actor-Critic,SAC)是一种基于最大化策略熵的强化学习算法,能够在探索与稳定性之间取得平衡,适用于连续控制问题。该算法通过同时更新策略网络和 Q 网络,以确保算法的稳定性和性能,并且强调通过最大化策略的熵来提升智能体的探索能力。SAC 的计算过程及其模型结构如下:

第 1 步:数据采集。采用温度传感器、压力传感器、流量传感器等多个类型的传感器从湿法冶金设备采集数据,输入 SAC 算法。

第 2 步:设置环境状态和动作。假设环境的状态空间为 $s \in \mathcal{S}$,动作空间为 $a \in \mathcal{A}$ 。SAC 的目标是通过策略 $\pi(a | s)$ 来最大化期望回报和熵的总和。其中, s 为环境的状态, a 为控制动作。

第 3 步:设置目标。最大化期望回报和策略

收稿日期:2024-10-14

作者简介:赵铮(1990—),女,硕士,讲师,主要研究方向为计算机应用。

熵。SAC 的目标是最大化总回报和策略的熵,以鼓励探索。目标函数为:

$$J(\pi) = \mathbb{E}_{\pi} \left[\sum_{t=0}^{\infty} \gamma^t (r(s_t, a_t) + \alpha \mathcal{H}(\pi(\cdot | s_t))) \right].$$

式中: $r(s_t, a_t)$ — 当前时刻的奖励; γ — 折扣因子; α — 熵权重系数, 调节探索与回报的权衡; $\mathcal{H}(\pi(\cdot | s_t)) = -\sum_a \pi(a | s_t) \lg \pi(a | s_t)$ — 策略的熵。

第 4 步: Q 函数估计。Q 函数用于评估给定状态动作对的价值, SAC 使用 2 个 Q 网络 (Q_1 和 Q_2) 来减少策略更新中的过高估计误差。Q 的计算公式为:

$$Q(s_t, a_t) = r(s_t, a_t) + \gamma \mathbb{E}_{s_{t+1} \sim p} [\min(Q_1(s_{t+1}, a_{t+1}), Q_2(s_{t+1}, a_{t+1})) - \alpha \lg \pi(a_{t+1} | s_{t+1})].$$

式中: Q_1, Q_2 — 双 Q 网络, 用于避免过高估计; $p(s_{t+1} | s_t, a_t)$ — 状态转移概率。

第 5 步: 设置 Q 网络的损失函数。为了训练 Q 网络, SAC 将目标 Q 值与预测 Q 值的误差最小化, Q 网络的损失函数为:

$$J_Q = \mathbb{E}_{(s_t, a_t, r_t, s_{t+1}) \sim D} [(Q(s_t, a_t) - \hat{Q}(s_t, a_t))^2],$$

式中, $\hat{Q}(s_t, a_t)$ — 从目标网络计算得到的目标 Q 值。

第 6 步: 策略网络的优化。SAC 的策略网络直接生成动作 a , 并通过最大化熵正则化的目标函数进行更新。策略的目标是最大化预期 Q 值与熵的和, 策略网络的损失函数为:

$$J_{\pi} = \mathbb{E}_{s_t \sim D} [\alpha \lg \pi(a_t | s_t) - \min(Q_1(s_t, a_t), Q_2(s_t, a_t))].$$

式中: $\lg \pi(a_t | s_t)$ — 策略熵, α — 调节熵的权重参数。

第 7 步: 熵权重 α 的更新。熵权重 α 可以通过最小化策略的 KL 散度来自动调整。调整目标为:

$$J(\alpha) = \mathbb{E}_{a_t \sim \pi} [-\alpha \lg \pi(a_t | s_t) - \alpha \bar{\mathcal{H}}].$$

式中, $\bar{\mathcal{H}}$ — 目标熵, 用于控制策略探索的强度。

第 8 步: 动作的采样。策略网络输出的是高斯分布的均值和方差, 然后根据该分布对动作进行采样, 采样的过程为:

$$a_t = \mu(s_t) + \sigma(s_t) \cdot \epsilon, \epsilon \sim N(0, 1).$$

式中: $\mu(s_t)$ — 策略网络输出的动作均值, $\sigma(s_t)$ — 策略网络输出的动作标准差。

第 9 步: 重新参数化技巧。为了使策略网络的更新可微, SAC 使用了重新参数化技巧。将动

作表示为:

$$a_t = f(\epsilon_t; \theta) = \mu(s_t) + \sigma(s_t) \cdot \epsilon_t.$$

式中: $\epsilon_t \sim N(0, 1)$, 可以通过梯度下降对 $\mu(s_t)$ 和 $\sigma(s_t)$ 进行优化。

第 10 步: 引入状态值函数。为了提高训练稳定性, SAC 引入了状态值函数 $V(s_t)$, 它通过最小化以下损失函数来更新:

$$J_V = \mathbb{E}_{s_t \sim D} \left[\frac{1}{2} (V(s_t) - \mathbb{E}_{a_t \sim \pi} [Q(s_t, a_t) - \alpha \lg \pi(a_t | s_t)])^2 \right].$$

第 11 步: 目标网络更新。SAC 使用目标网络来稳定 Q 值更新, 目标网络参数 θ_{target} 通过软更新方式进行更新:

$$\theta_{target} \leftarrow \tau \theta + (1 - \tau) \theta_{target},$$

式中, $\tau \in [0, 1]$ 是软更新的系数, 为 0.005。

通过上述步骤, SAC 实现了策略和 Q 网络的交替更新, 在保证探索能力的同时, 稳定地进行湿法冶金设备的动作控制。SAC 模型的结构如图 1 所示。

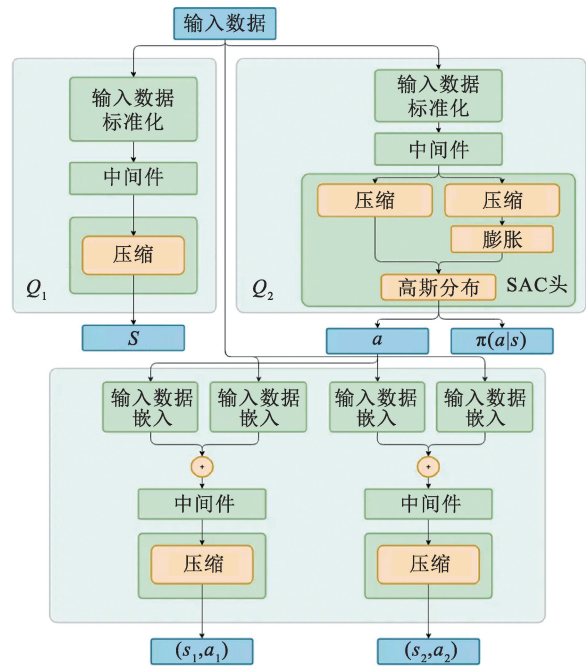


图 1 SAC 模型的结构

Fig. 1 Structure of SAC model

2 基于改进 ARIMA 算法的湿法冶金设备故障检测

本研究采用改进 ARIMA 算法对湿法冶金设

备进行故障检测,即通过对设备传感器历史数据的建模,预测未来的设备状态,并根据预测误差来判断设备是否发生故障。改进 ARIMA 算法的计算过程如下:

第 1 步:数据预处理。首先对传感器数据进行标准化处理,消除量纲差异。假设传感器数据序列为 $\mathbf{X} = \{x_1, x_2, \dots, x_n\}$, 则标准化后的数据为:

$$x'_i = \frac{x_i - \mu_x}{\sigma_x}$$

式中: μ_x —数据序列 X 的均值; σ_x —标准差; x'_i —标准化后的数据; x_i —标准化前的数据。

第 2 步:ARIMA 模型建模。ARIMA 模型通过 3 个参数 (p, d, q) 对时间序列进行建模。

p 代表自回归项的数量,即前 p 个滞后值的线性组合; d 代表差分阶数,用于将非平稳序列转化为平稳序列; q 代表移动平均项的数量,即前 q 个预测误差的线性组合。ARIMA 模型的表达式为:

$$(1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p)(1 - B)^d x'_i = \theta_0 + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q} + \epsilon_t$$

式中: B —滞后算子; $\phi_1, \phi_2, \dots, \phi_p$ —自回归系数; $\theta_1, \theta_2, \dots, \theta_q$ —移动平均系数, ϵ_t —随机误差项。

第 3 步:差分运算。若设备传感器数据呈现非平稳性,则需进行 d 阶差分。对数据序列 \mathbf{X} 进行 d 次差分的公式为:

$$x_i'^d = x'_i - x'_{i-d}$$

该步骤用于消除数据中的趋势性,得到平稳时间序列 $x_i'^d$ 。

第 4 步:自回归过程(AR)。通过自回归过程对历史数据进行建模。自回归项通过前 p 个滞后数据来预测当前值:

$$x_i'^d = \sum_{i=1 \sim p} \phi_p x'_{i-i} + \epsilon_t$$

式中: ϕ_p —自回归系数; x'_{i-i} —滞后数据。

第 5 步:移动平均过程(MA)。接下来,通过移动平均过程来校正自回归模型的误差。移动平均项通过前 q 个预测误差进行修正:

$$x_i'^d = \sum_{j=1 \sim q} \theta_j \epsilon_{t-j} + \epsilon_{t-j}$$

式中: θ_j —移动平均系数; ϵ_{t-j} —滞后误差项。

第 6 步:预测未来值。利用训练好的 ARIMA 模型对湿法冶金设备的未来状态进行预测。假设当前时刻为 t ,则未来 k 时刻的预测值为:

$$\hat{x}_{t+k} = \phi_1 x_t + \phi_2 x_{t-1} + \dots + \phi_p x_{t-p+1} + \sum_{j=1}^q \theta_j \epsilon_{t+j}$$

式中, \hat{x}_{t+k} —时刻 $t+k$ 的预测值。

第 7 步:故障检测。通过预测值与实际值的差异判断故障发生情况。预测误差 e_t 表示为:

$$e_t = x_t - \hat{x}_t$$

设定一个故障阈值 δ ,若 $|e_t| > \delta$,则判定设备可能存在故障。

第 8 步:改进的故障检测机制。为了提高故障检测的精度,本研究引入了基于自适应阈值的方法,根据历史预测误差的均值和标准差动态调整故障阈值 δ :

$$\delta = \mu_e + k \cdot \sigma_e$$

式中: μ_e —预测误差的均值; σ_e —预测误差的标准差; k —调节参数。

3 基于 LoRA 网络的低资源模型微调与加速

LoRA (Low-Rank Adaptation) 是一种轻量化微调技术,通过对预训练模型中的权重矩阵进行低秩分解,将参数更新限制在低秩子空间中,从而大幅减少训练和推理时的计算开销。对于一个预训练好的权重矩阵 $\mathbf{W}_0 \in \mathbb{R}^{d \times k}$,使用 LoRA 进行微调时,一般不直接更新完整的矩阵,而是通过 2 个低秩矩阵的乘积来代替 \mathbf{W}_0 的变化:

$$\mathbf{W} = \mathbf{W}_0 + \Delta\mathbf{W} = \mathbf{W}_0 + \mathbf{A}\mathbf{B}$$

式中: $\mathbf{A} \in \mathbb{R}^{d \times r}$ —一个低秩矩阵,表示权重矩阵变化的基; $\mathbf{B} \in \mathbb{R}^{r \times k}$ —另一个低秩矩阵,表示权重变化的系数; $r \ll \min(d, k)$ —低秩近似的秩,通常设置为很小的值,以减少计算量。

在微调过程中,只需要训练 \mathbf{A} 和 \mathbf{B} ,而保持原始的 \mathbf{W}_0 不变。这可以大大减少训练过程中需要更新的参数数量,从而加速模型的训练和推理过程。微调时,更新的梯度仅作用于 \mathbf{A} 和 \mathbf{B} :

$$\frac{\partial \mathcal{L}}{\partial \mathbf{A}} = \frac{\partial \mathcal{L}}{\partial \Delta\mathbf{W}} \mathbf{B}^T, \frac{\partial \mathcal{L}}{\partial \mathbf{B}} = \mathbf{A}^T \frac{\partial \mathcal{L}}{\partial \Delta\mathbf{W}}$$

式中, \mathcal{L} —损失函数。

在故障检测模型中,假设已经基于改进 ARIMA 算法训练好了模型权重 \mathbf{W}_0 。通过 LoRA 进行微调时,引入 2 个低秩矩阵 \mathbf{A} 和 \mathbf{B} 来替换原始模型的权重变化部分,微调的参数更新仅作用于 \mathbf{A} 和 \mathbf{B} ,避免了对整个权重矩阵的更新。微调后的故障检测模型的权重为:

$$\mathbf{W} = \mathbf{W}_0 + \mathbf{A} \cdot \mathbf{B}$$

因此,最终的预测公式为:

$$\hat{x}_{t+k} = (\mathbf{W}_0 + \mathbf{A} \cdot \mathbf{B}) x_t。$$

式中: \hat{x}_{t+k} — 未来 k 时刻的预测值; x_t — t 时刻的输入数据。

由于低秩矩阵的维度 r 较小,模型在推理过程中计算的矩阵乘法复杂度降低为 $O(dr + rk)$, 而不是原始的 $O(dk)$ 。通过这种方式,模型的推理速度可大大提升,同时内存占用减少。使用 LoRA 微调模型时,参数数量的减少会加速效果显著提升。设定秩 r 较小,通常可以将参数量降低为原始模型的 1/10 或更少。本研究假设原始模型的参数量为 P ,微调后的参数量为

$$P_{\text{LoRA}} = d \times r + r \times k,$$

式中, $r \ll \min(d, k)$, 通过 LoRA 微调可以使得训练和推理效率显著提升。

在实际应用时,训练过程中的权重变化仅限于低秩矩阵 \mathbf{A} 和 \mathbf{B} , 而原始的权重矩阵 \mathbf{W}_0 保持不变。这使得模型可以在快速收敛的同时,保留模型的核心能力,尤其是在训练数据有限的情况下,这种微调方式能显著提升模型的泛化性能和推理速度。

在湿法冶金设备的故障检测中,实时性和低延迟是关键要求。通过 LoRA 的低秩微调,模型能够在保持较高准确率的同时,显著减少模型的计算开销,从而实现实时故障检测。图 2 为 LoRA 微调网络的原理。




图 2 LoRA 微调网络的原理
Fig. 2 Principles of LoRA fine-tuned networks

4 试验研究与实证研究

为了验证提出的算法模型的效果,本研究先

后进行了若干对比试验,并选择某工厂进行该算法模型效果的实证研究。

4.1 试验环境与试验设置

本研究提出的算法模型运行的软硬件环境如下:

CPU 为 Intel Xeon E5-2698 v4 @ 2.20GHz, 22 核, 44 线程, GPU 为 NVIDIA Tesla V100 32GB, 内存为 128GB DDR4 RAM, 存储为 2TB NVMe SSD, 网络为 1Gbps 高速网络连接, 传感器设备是温度传感器(精度 $\pm 0.1^\circ\text{C}$, 响应时间 $< 1\text{ s}$, 频率 100 Hz), 压力传感器(精度 $\pm 0.05\%$, 频率 100 Hz), 流量传感器(精度 $\pm 0.5\%$, 频率 50 Hz), 操作系统为 Ubuntu 20.04 LTS, 编程语言为 Python 3.8, PyTorch 2.0, TensorFlow 2.13, NumPy 1.23, Pandas 1.5, Scikit-learn 1.3, NVIDIA CUDA 11.7, NCCL 2.12, Horovod 0.26, 数据库为 PostgreSQL 13, InfluxDB 2.0。这种软硬件配置有效支持了本研究利用深度强化学习算法对湿法冶金设备的智能控制与故障检测,特别是满足了试验在处理高维数据和实时决策方面的要求。

试验在故障检测中使用的故障分类见表 1。

表 1 故障检测中使用的故障分类

Table 1 Fault classification used in fault detection

故障类型	故障特征	可能的原因
泵故障	流量骤减, 压力波动异常	泵磨损、堵塞或电机故障
温度传感器失效	温度读数波动剧烈、不在正常范围	传感器老化、连接线路故障
压力异常	压力超标或不足	管道堵塞、液体泄漏、阀门损坏
电积槽电流波动异常	电流异常波动、金属沉积速率降低	电源设备故障、电极板磨损、酸液浓度不足
酸液流量异常	酸液流量偏低或偏高, 影响浸出反应速率	管道堵塞或泄漏、阀门控制不当
设备振动过大	振动加剧、噪音增大	设备基础松动、部件磨损或故障
液位异常	液位过高或过低	液体供应异常、排放系统故障、阀门失效
传送带故障	传送带运行异常、速度不稳、材料传送中断	传送带松动或断裂、传动系统故障
搅拌机故障	搅拌速度降低或不均匀、搅拌扭矩波动	电机故障、搅拌叶片磨损、材料堵塞
电气系统故障	电气设备无法正常工作、设备无法启动	电气连接松动、设备损坏、电路过载

此外,试验环境为用硫酸从氧化铜矿中浸出铜的工艺过程。本研究使用的评价指标见表 2。

表 2 评价指标及说明

Table 2 Evaluation indicators and descriptions

序号	评价指标	说明
1	控制精度/%	评价设备在智能控制过程中对关键工艺参数的控制精度
2	浸出率/%	评价铜等金属的提取效率,反映智能控制系统对湿法冶金工艺的优化效果
3	能耗/W	评价设备在电积过程中单位金属产量的电能消耗,反映能效优化效果
4	准确率/%	用于评价故障检测模型的预测准确率,评价模型对设备故障的检测和预测能力
5	召回率/%	评价模型在故障检测中的灵敏度,反映预测模型对实际故障的捕捉能力
6	误报率/%	评价模型在故障预测中的误报情况,反映模型的检测结果可靠性
7	实时性/s	评价控制系统的响应速度和故障检测及时性,反映模型在实际生产环境中的快速反应能力,通常响应延迟应小于 200 ms。

本研究所用数据来源于某大型铜冶炼厂的湿法冶金设备传感器系统,主要包括 3 种关键参数:

1)温度:采集设备在浸出槽和电积槽中的温度,数据范围为 25~80 °C,采样频率为 100 Hz。

2)压力:监测设备内部的压力波动,数据范围为 0.5~1.5 MPa,采样频率为 50 Hz。

3)流量:记录酸液和金属溶液的流量,数据范围为 50~500 L/min,采样频率为 10 Hz。

在为期 10 天的生产周期中,共收集了约 0.5 TB 的传感器数据。这些数据经过预处理和清洗后用于模型的训练和验证。

4.2 对比试验与消融试验

为了验证本研究提出的算法模型对设备的智能控制和故障检测效果,对比了本算法模型与 4 个类似模型的应用效果评价指标,包括 2 个设备控制模型^[6-7]和 2 个故障检测模型^[4-5],结果见表 3。可以看出:本算法模型与其他模型相比,各项设备控制和故障检测评价指标均较优,说明本算法模型的应用效果较好。

表 3 不同的设备控制模型的应用效果评价指标对比结果

Table 3 Comparative results of evaluation indicators for application effectiveness of different equipment control models

模型	设备控制评价指标			设备故障检测评价指标		
	控制精度/%	浸出率/%	能耗/W	准确率/%	召回率/%	误报率/%
设备控制模型 1 ^[4]	81.35	81.11	92			
设备控制模型 2 ^[5]	84.24	82.52	94			
设备故障检测模型 1 ^[6]				89.14	89.12	13.22
设备故障检测模型 2 ^[7]				90.12	88.82	17.39
本算法模型	93.24	93.52	81	91.34	90.11	10.13

为了验证本研究提出的算法模型中各组件产生的影响,进行了 3 个消融试验,分别替换 SAC、ARIMA 和 LoRA 模型组件。SAC 模型消融试验结果见表 4。可以看出,本算法模型使用的 SAC 智能设备控制模型与 BP 神经网络^[8]、DQN^[9]、DDQN^[10] 3 个模型相比,其对设备的控制精度更高,浸出率也较高,且能耗更低。

ARIMA 模块的消融试验结果见表 5。可以看出,相比 LSTM^[11]、HMM^[12]、Autoencoder^[13] 3 个模型,本算法模型使用的 SAC 智能设备控制模块对设备故障的预测准确率和召回率更高,故障误报率更低。

表 4 SAC 模块的消融试验结果

Table 4 Ablation test results of SAC module

模型	控制精度/%	浸出率/%	能耗/W
BP 神经网络	87.23	91.12	102
DQN	89.35	92.63	104
DDQN	91.42	91.26	92
SAC	93.24	93.52	81

LoRA 模块的消融试验结果见表 6。可以看出:采用了 LoRA 对本文模型进行微调之后,模型运行的延迟时间从 4.2 s 缩减至 1.2 s,缩减幅度较大,同时模型的训练时间也从 10.2 h 缩减至

5.7 h。较低的时延使得该算法模型智能设备控制和故障检测效果更佳。

表 5 ARIMA 模块的消融试验结果

Table 5 Ablation test results of ARIMA module

模型	准确率/%	召回率/%	误报率/%
LSTM	89.13	81.26	10.12
HMM	82.45	83.64	12.63
Autoencoder	87.24	86.22	15.31
ARIMA	91.34	90.11	10.13

表 6 LoRA 模块的消融试验结果

Table 6 Ablation test results of LoRA module

项目	推理延迟时间/s	模型训练时间/h
不使用 LoRA	4.2	10.2
使用 LoRA	1.2	5.7

为了验证本研究提出的算法模型对设备的智能控制效果,从算法模型的运行日志中采集了相关日志并进行统计分析,结果见表 7。可以看出,随本算法模型运行时间延长,模型对设备智能控制精度和故障检测准确率均升高,而推理延迟时间变短,说明其应用效果较好。

表 7 模型推理的设备控制关键评价指标变化情况

Table 7 Changes of key evaluation indicators of equipment control inferred by model

模型运行时间/h	SAC 模型的设备控制精度/%	ARIMA 模型的故障预测准确率/%	LoRA 模型的推理延迟时间/s
1	90.86	86.61	1.72
2	91.15	87.48	1.67
3	91.49	88.25	1.58
4	91.79	89.03	1.57
5	92.73	89.21	1.53
6	92.75	90.13	1.45
7	92.95	90.32	1.39
8	92.97	90.53	1.29
9	92.98	90.65	1.25
10	93.24	91.34	1.20

为了分析本研究提出的算法模型对设备故障的检测效果,从算法模型的日志中采集了各种类型故障检测评价指标,结果见表 8。可以看出:各种类型

的设备故障的检测准确率和召回率也均达 80%以上。经统计,故障检测误报率为 30%以下。说明本算法模型对各种类型设备故障具有较高的检测能力。

表 8 模型推理的各种类型设备故障检测评价指标情况

Table 8 Evaluation of indicators for various types of equipment fault detection by model

故障类型	准确率/%	召回率/%	误报率/%
泵故障	89.64	83.07	15.21
温度传感器失效	88.22	83.21	25.94
压力异常	83.34	88.34	13.77
电积槽的电流波动异常	85.52	84.85	23.07
酸液流量异常	82.51	85.38	19.54
设备振动过大	84.83	80.64	19.76
液位异常	86.73	87.95	12.43
传送带故障	85.23	85.46	11.81
搅拌机故障	80.02	86.82	24.28
电气系统故障	87.91	83.98	18.52

4.3 实证研究

为了验证本研究提出的算法模型在实际生产环境中的应用效果,选择在某大型铜冶炼厂进行实证研究。该厂湿法炼铜设备主要包括浸出槽、电积槽、流量泵和传感器系统。通过将这些设备与本算法模型集成,对设备在生产过程中的运行状态进行实时控制,同时对故障进行预测和检测。

在 60 天的生产周期内共收集约 2 TB 的传感器数据。将这些数据进行初步处理,之后用于训练和验证智能控制与故障检测模型,实证验证结果见表 9。

表 9 实证研究结果

Table 9 Empirical research results

序号	项目	模型应用效果
1	铜浸出率	在有模型支持的情况下,铜平均回收率从 87.5% 提升至 92.3%,提高 4.8%
2	能耗优化	电积过程的能耗降低 7.2%,平均电能消耗从 350 kWh/t 铜降至 325 kWh/t 铜
3	故障预测与检测	模型成功提前预测了 3 个主要设备故障,平均提前时间为 2.3 h,减少了设备停机时间,避免了 15% 的潜在产能损失
4	误报率	故障预测模型误报率为 2.1%,大幅优于传统故障诊断方法

从表 9 看出,集成了本算法模型的智能控制系统能有效提高冶金设备的生产效率。这主要归因于该算法模型在实时优化、智能决策和精确故障预测 3 方面的综合能力。首先,基于深度强化学习的智能控制算法能够在生产过程中持续自适应学习,通过对历史数据的不断反馈和优化,实时调整工艺参数,确保生产条件始终处于最优状态,这种多变量动态控制机制避免了传统工艺中因参数设定固定而导致的效率损失,从而提高了铜浸出率和能耗效率;其次,SAC 算法的连续控制特性允许设备在面对复杂工况时快速响应,避免了手动干预的滞后性,该模型能够在不同生产阶段精准控制电积电流密度和槽压,优化能量消耗,并有效防止过载或无效功耗,使能耗减少;最后,模型集成的故障预测模块实时分析大量传感器数据,可以提前预测设备故障,该预测功能通过提取设备运行中的隐含特征,实现了对潜在问题的预判,大幅减少了停机和维护时间,保障了设备的稳定运行。

实证研究验证了本研究提出的基于实时机器学习算法的湿法冶金设备智能控制与故障检测模型在实际生产环境中的有效性。该模型不仅能提高生产效率,降低能耗,还可以显著减少设备故障带来的停机损失。

5 结论

通过引入基于 SAC 深度强化学习的智能控制算法,结合改进的 ARIMA 故障检测方法建立了一种湿法冶金设备的智能控制与故障检测的算法模型,并利用 LoRA 微调网络提升了该模算法模型的实时性能。对比试验和实证研究表明,该算法模型不仅能有效提升设备的生产效率与能耗优化,还能大幅减少设备故障造成的停机时间,可为湿法冶金设备控制智能化与可靠性提升提供一定技术参考,具有一定应用价值。

参考文献:

[1] 彭姿徐,王高才,农望.基于 SAC 的多服务移动边缘计算中任务卸载和资源配置算法[J].计算机应用研究,2023,40(5):1497-1503.
PENG Ziyu, WANG Gaocai, NONG Wang. SAC based algorithm for task offloading and resource provisioning in multiple-services mobile edge computing [J]. Application Research of Computers,2023,40(5):1497-1503.

[2] 冯剑,姚罕琦,黄啸虎,等. ARIMA 算法在工业控制器故障预测的应用[J].自动化仪表,2022,43(11):62-67.
FENG Jian, YAO Hanqi, HUANG Xiaohu, et al. Application of ARIMA algorithm to industrial controller fault prediction [J]. Process Automation Instrumentation, 2022, 43(11):62-67.

[3] 邓文艳.湿法冶金设备运行状态的多特征融合检测优化仿真[J].湿法冶金,2023,42(6):666-670.
DENG Wenyan. Optimization simulation of multi-feature fusion detection for the operating state of hydrometallurgical equipment [J]. Hydrometallurgy of China, 2023, 42(6): 666-670.

[4] 李伟.基于改进 PSO-SQP 算法优化控制金氰化浸出过程[J].湿法冶金,2023,42(3):317-321.
LI Wei. Optimization control of gold cyanide leaching process based on improved PSO-SQP algorithm [J]. Hydrometallurgy of China, 2023, 42(3):317-321.

[5] 薛海莉,李晓敏.基于改进动态因果图的湿法冶金浸出过程故障诊断方法研究[J].湿法冶金,2024,43(2):201-205.
XUE Haili, LI Xiaomin. Fault diagnosis method for hydrometallurgical leaching process based on improved dynamic causal diagram [J]. Hydrometallurgy of China, 2024, 43(2): 201-205.

[6] 李乐,舒越超,吴健鹏,等.基于 PSO-BP 神经网络湿式摩擦元件损伤预测模型[J].北京理工大学学报,2022,42(12):1246-1255.
LI Le, SHU Yuechao, WU Jianpeng, et al. A damage prediction model of wet friction elements based on PSO-BP neural network [J]. Transactions of Beijing institute of Technology, 2022, 42(12):1246-1255.

[7] 谢思静,文鼎柱.基于联邦分割学习与低秩适应的 RoBERTa 预训练模型微调方法[J].数据采集与处理,2024,39(3):577-587.
XIE Sijing, WEN Dingzhu. Fine-tuning method for pre-trained model RoBERTa based on Federated split learning and Low-rank adaptation [J]. Journal of Data Acquisition and Processing, 2024, 39(3):577-587.

[8] 何龙,张冉阳,赵刚要,等.基于 BP 神经网络的 GH5188 高温合金本构模型[J].特种铸造及有色合金,2021,41(2):223-226.
HE Long, ZHANG Ranyang, ZHAO Gangyou, et al. Constitutive model of GH5188 superalloy based on BP neural network [J]. Special Casting & Nonferrous Alloys, 2021, 41(2):223-226.

[9] 郁洲,毕敬,苑海涛.基于改进 DQN 算法的复杂海战场路径规划方法[J].智能科学与技术学报,2022,4(3):418-425.
YU Zhou, BI Jing, YUAN Haitao. A path planning method for complex naval battle field based on an improved DQN algorithm [J]. Chinese Journal of Intelligent Science and Technology, 2022, 4(3):418-425.

- [10] 李国梁,李峭,徐亚军,等.基于 DDQN 的片上网络混合关键性消息调度方法[J].北京航空航天大学学报,2021,48(7):1233-1241.
LI Guoliang, LI Qiao, XU Yajun, et al. A DDQN-based mixed-criticality messages scheduling method for network-on-chip[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 48(7): 1233-1241.
- [11] 郭佳丽,邢双云,栾昊,等.基于改进的 LSTM 算法的时间序列流量预测[J].南京信息工程大学学报(自然科学版),2021,13(5):571-575.
GUO Jiali, XING Shuangyun, LUAN Hao, et al. Prediction of time series traffic based on improved LSTM algorithm[J]. Journal of Nanjing University of Information Science & Technology (Natural Science Edition), 2021, 13(5): 571-575.
- [12] 袁利伟,龙皓楠,李斌,等.基于 HMM 算法的矿山水灾害链复杂演化网络模型构建及应用[J].化工矿物与加工,2023,52(8):47-55.
YUAN Liwei, LONG Haonan, LI Bin, et al. Construction and application of complex evolutionary network model of mine water disaster chain based on HMM algorithm[J]. Industrial Minerals & Processing, 2023, 52(8): 47-55.
- [13] 郭一阳,于炯,杜旭升,等.基于自编码器与集成学习的离群点检测算法[J].计算机应用,2022,42(7):2078-2087.
GUO Yiyang, YU Jiong, DU Xusheng, et al. Outlier detection algorithm based on autoencoder and ensemble learning [J]. Journal of Computer Applications, 2022, 42(7): 2078-2087.

Intelligent Control and Fault Detection Method for Hydrometallurgical Equipment Based on Real-time Machine Learning Algorithms

ZHAO Zheng

(Department of Computer Science and Applications, Pingdingshan Vocational and Technical College, Pingdingshan 467000, China)

Abstract: Aiming at the problems such as relatively simple control and intelligent detection model of hydrometallurgical equipment and weak generalization ability, an algorithm model for intelligent control and fault detection of hydrometallurgical equipment based on deep learning was proposed. Firstly, SAC deep reinforcement learning algorithm was used to perform intelligent control of hydrometallurgical equipment. The improved ARIMA algorithm is used to detect the fault of the equipment. In order to further improve the real-time performance of the algorithm, LoRA fine-tuning network is introduced to fine-tune and accelerate the model with low parameters, and LoRA fine-tuning network to fine-tune and accelerate the model with low parameters. The accuracy of the model is 93.24% and the accuracy of fault detection is 91.34%. The practical application effect is good.

Key words: real-time machine learning; SAC; ARIMA; LoRA