

# 基于深度学习算法的湿法冶金资源回收效率提升方法设计及研究

宋玉安, 赵 伟

(济源职业技术学院 材料工程学院, 河南 济源 459000)

**摘要:**为进一步提高湿法冶金资源回收率,解决资源回收流程控制的智能化、自动化控制程度不高的问题,提出了一种采用 Transformer 模型进行金属浸出率预测,再采用 Distributional Q-function 改进 DQN 模型进行湿法冶金金浸出率最大化的湿法冶金流程控制方法。结果表明:该系统控制方法能有效提升湿法冶金过程中金属浸出率的预测准确率;基于 Distributional Q-function 改进 DQN 模型能有效降低资源回收率最大化模型的迭代计算时间。该法能有效提高某工厂湿法冶金资源回收率。

**关键词:**Transformer 模型;最优化;Distributional Q-function;DQN 模型;资源回收

**中图分类号:**TF803.21 **文献标识码:**A **文章编号:**1009-2617(2025)01-0125-07

**DOI:**10.13355/j.cnki.sfyj.2025.01.017

湿法冶金作为一种重要的金属资源回收技术,资源回收率的提升一直是关注焦点,而浸出工序作为金属提取的关键步骤,直接决定金属浸出效果,因此对提升金属浸出率尤为重要。近些年,关于智能化优化浸出工艺以提高浸出率方面的研究已取得了一些进展<sup>[1-3]</sup>,但要获得更高的金属浸出率,仍需构建更加高效且智能的浸出控制体系。

为了进一步提升湿法冶金过程中金属浸出效果,以从某废渣中浸出金为例,提出了一个基于深度学习算法的湿法冶金资源回收流程控制方法,通过提高金浸出率的预测准确率<sup>[1-3]</sup>,从而提高湿法冶金资源回收效率<sup>[4-6]</sup>。首先使用基于 Transformer 的深度学习算法<sup>[7]</sup>进行金浸出率预测,在此基础上再建立金浸出率最大化模型,最后用基于 Distributional Q-function 改进 DQN 深度强化学习算法<sup>[8]</sup>对该模型进行求解。

## 1 基于 Transformer 模型的深度学习算法预测金浸出率

Transformer 模型是一种深度学习架构,主要用于处理序列到序列的任务,如机器翻译<sup>[9]</sup>、文本生成<sup>[10]</sup>等。其核心是自注意力机制<sup>[11]</sup>,该机

制能够在处理输入序列的同时,考虑到所有位置的信息,并按照不同部分的重要性赋予其不同的权重。多头注意力机制则可进一步扩展该能力,通过多个注意力头并行处理不同的信息子空间,增强模型对复杂语义的捕捉能力。位置编码的引入能解决 Transformer 缺乏序列位置信息的问题。

首先用基于 Transformer 模型的深度学习算法进行金浸出率预测。该模型的引入能有效提高金浸出率的预测准确率。计算过程如下:

### 1) 输入嵌入和位置编码

(1) 输入嵌入:每个金浸出率历史数据序列的数据单元被转换为词嵌入向量,并通过位置编码增加位置信息。计算公式如下:

$$f(x) = W_{Emb}(x) + P_{Eco}(x)。(1)$$

式中: $f(x)$ —最终输入向量; $W_{Emb}(x)$ —词嵌入向量; $P_{Eco}(x)$ —位置编码向量; $x$ —金浸出率历史数据向量。

(2) 位置编码:使用正弦和余弦函数为每个位置生成编码,并与词嵌入向量相加。计算公式如下:

$$PE(pos, 2i) = \sin\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right); (2)$$

$$PE(pos, 2i+1) = \cos\left(\frac{pos}{10000^{\frac{2i}{d_{model}}}}\right)。(3)$$

收稿日期:2024-09-04

第一作者简介:宋玉安(1985—),男,硕士,讲师,主要研究方向为冶金技术。

式中:  $PE(pos, 2i)$ 、 $PE(pos, 2i+1)$ —位置编码向量的第  $2i, 2i+1$  个分量;  $pos$ —位置编号,  $d_{model}$ —位置向量的维度。

2) 自注意力机制

(1) 查询、键和值矩阵: 每个嵌入向量通过不同的线性层生成  $Q, K$  和  $V$  矩阵。计算公式如下:

$$Q = W_Q \cdot x, K = W_K \cdot x, V = W_V \cdot x. \quad (4)$$

式中:  $Q, K, V$ —查询、键和值矩阵;  $W_Q, W_K, W_V$ —对应的权重矩阵;  $x$ —输入向量。

(2) 点积计算和 SoftMax 归一化: 查询矩阵与键矩阵的转置进行点积运算, 得到注意力分数, 并通过 SoftMax 进行归一化。计算公式如下:

$$Attention(Q, K, V) = softmax\left(\frac{Q \cdot K^T}{\sqrt{d_k}}\right)V. \quad (5)$$

式中,  $d_k$ —键矩阵的维度。

3) 多头注意力

多头分解和拼接: 将查询、键和值矩阵分别分解成多个头部, 每个头部独立进行自注意力计算, 然后将所有头部的输出进行拼接。计算公式如下:

$$MultiHead(Q, K, V) = Concat(head_1, \dots, head_h)W_O. \quad (6)$$

式中:  $MultiHead(Q, K, V)$ —多头注意力的输出;  $Concat(\cdot)$ —拼接操作;  $head_1, \dots, head_h$ —各个头部的输出;  $W_O$ —输出权重矩阵。

4) 前馈网络

全连接层和激活函数: 在多头注意力层之后, 输出会通过一个全连接前馈网络, 该网络包含 2 个线性变换和 1 个  $ReLU$  激活函数。计算公式如下:

$$FFN(x) = max(0, xW_1 + b_1)W_2 + b_2. \quad (7)$$

式中:  $FFN(x)$ —前馈网络的输出;  $W_1, W_2$ —权重矩阵;  $b_1, b_2$ —偏置项,  $x$ —输入历史浸出率数据向量。

5) 解码器结构

(1) 解码器: 解码器也包含多个相同结构的解码器层, 但其结构比编码器复杂, 需要处理编码器的输出及之前解码层的输出。

(2) 编码器-解码器注意力: 解码器中的编码器-解码器注意力机制用于关注输入序列的相关部分。

6) 输出层

线性层和 softmax: 在最后 1 个解码器层之后, 输出向量通过 1 个线性层, 生成最终的结果。计算公式如下:

$$y = softmax(xW_{out}). \quad (8)$$

式中,  $y$ —输出结果;  $W_{out}$ —输出层的权重矩阵;  $x$ —输入历史浸出率数据向量。

Transformer 模型通过一系列设计的计算步骤实现了对输入序列深度和全面的处理。该架构不仅能高效处理湿法冶金浸出率的序列数据, 还能捕捉金浸出率数据序列的长距离依赖关系, 从而能较准确地预测金浸出率。Transformer 模型的原理如图 1 所示。

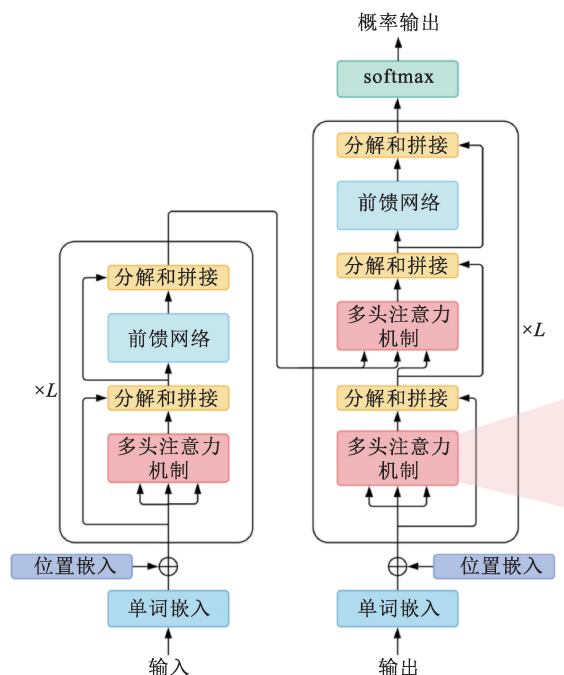


图 1 Transformer 模型的原理  
Fig. 1 Principle of Transformer model

2 金浸出率最大化模型的建立

金浸出率最大化模型基于几个关键因素, 包括原料的浸出效率、溶剂的选择、浸出温度、压力、时间等。本研究提出一个简化的数学模型, 旨在通过优化上述工艺参数实现浸出率最大化, 从而提高资源回收率。该模型说明如下:

1) 浸出率最大化

$$L_{max} = k \cdot c^n \cdot e^{\frac{-E_a}{RT}} \cdot t. \quad (9)$$

式中:  $L_{max}$ —浸出率最大化, 无量纲;  $k$ —反应速率常数;  $c$ —浸出剂浓度, mol/L;  $n$ —反应级数, 无量纲;  $E_a$ —表观活化能, J/mol;  $R$ —理想气体常数, J/(mol · K);  $T$ —热力学温度, K;  $t$ —反应时间, s。

2) 阿伦尼乌斯方程

$$k = A \cdot e^{\frac{-E_a}{RT}}, \quad (10)$$

式中,  $A$ —指前因子。

3) 反应级数方程

$$n = \frac{\partial \ln r}{\partial \ln c}, \quad (11)$$

式中,  $r$ —反应速率。

4) 温度与浸出率之间的关系

温度与浸出率之间的关系式可描述浸出率随温度变化的敏感度。二者中间的关系式如下:

$$\frac{\partial L}{\partial T} = k \cdot c^n \cdot e^{-\frac{E_a}{RT}} \cdot \left( \frac{E_a}{R} - T \right). \quad (12)$$

式中,  $L$ —浸出率, % , 是模型的目标函数。

通过调整优化上述方程中的变量(如浸出剂浓度、温度和时间), 从而实现金浸出率的最大化。模型原理如图 2 所示。

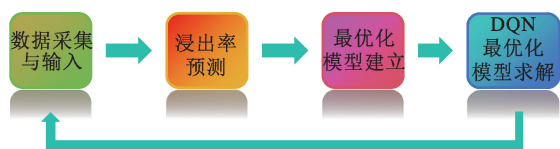


图 2 金浸出率最大化模型原理

Fig. 2 Principle of maximum gold leaching rate model

### 3 基于 Distributional Q-function 改进 DQN 模型的金浸出率最大化求解

作为一种深度强化学习模型, DQN 算法使用神经网络逼近  $Q$  函数, 输入为当前状态, 输出为每个可能动作的  $Q$  值。在训练过程中, DQN 利用时序差分误差更新网络参数, 以减小预测  $Q$  值与实际  $Q$  值之间的差距; 但由于最大化操作和目标值的不稳定性等因素, DQN 容易高估  $Q$  值, 导致学习效率和策略稳定性下降。

本研究采用的改进 Distributional Q-function 改进的 DQN 的核心思想<sup>[12]</sup>是建模  $Q$  值的概率分布, 而不仅仅是  $Q$  值的期望。改进的 DQN 算法能减轻原本 DQN 中由单一  $Q$  值估计带来的高估问题, 不仅关注回报的最大期望, 还考虑到了回报的不确定性和风险, 能更准确地捕捉到不同状态下采取行动所带来的回报分布情况, 从而提供更全面的信息供学习算法优化决策过程。通过考虑  $Q$  值的分布, 该算法的计算原理如下:

1) 该改进模型将  $Q$  值扩展为分布  $Z(s, a)$ 。在传统的 DQN 中,  $Q(s, a)$  表示在状态  $s$  下采取行动  $a$  的期望回报。而在 Distributional Q-func-

tion 改进的 DQN 中,  $Q$  值被扩展为一个分布  $Z(s, a)$ , 其可表征所有可能回报的概率分布。

2) 改进的目标值  $y_i$  的计算公式为

$$y_i = r + \gamma Z(s', a'). \quad (13)$$

式中:  $y_i$ —目标回报分布;  $r$ —即时奖励;  $Z(s', a')$ —下一状态-动作对的估计回报分布。与传统 DQN 不同, 这里的  $Z$  表示一个分布而不是单一值。

3) 该模型的损失函数定义为最小化预测回报分布。计算公式为

$$L(Z, y) = E[D_p(Z, y)]. \quad (14)$$

式中:  $L(Z, y)$ — $Z$  和目标回报分布  $y$  之间的距离;  $D_p$  可以是任何合适的距离度量, 本研究选择为 Wasserstein 距离。这种损失函数有助于更准确地调整模型预测的分布形状, 从而提高学习效率和策略的稳定性。

4) 此外, 在该改进的 DQN 架构中, 最优行动的选择不仅基于最大化总体价值  $V(s)$ , 还需考虑优势函数  $A(s, a)$ 。计算公式为

$$a^* = \arg \max_a V(s) + A(s, a) - \frac{1}{|A|} \sum_a A(s, a'). \quad (15)$$

式中: 优势函数  $A(s, a)$ —在状态  $s$  下采取特定行动  $a$  相比平均行为的优越性, 通过该函数, 模型能够学习在特定状态下哪些行动比平均行动更好, 从而细化决策过程并提高选择的行动效率;  $V(s)$ —在状态  $s$  下的总价值, 不考虑采取的具体行动, 该值被单独计算, 以提供对状态价值的直接评估, 从而增强网络的学习稳定性和性能。通过从优势函数中减去其平均值, 确保优势函数期望值为 0, 这有助于稳定学习过程中的价值估计。

5) 使用目标网络用来计算的目标  $Q$  值(实际上为一个分布)可以稳定训练过程, 减少过估计问题。计算公式为

$$Q_{\text{target}}(s, a) = r + \gamma Z_{\text{target}}(s', a'), \quad (16)$$

式中,  $Z_{\text{target}}$ —目标网络的分布估计。

6) 在训练过程中, 通过最小化预测分布和目标分布之间的均方误差  $\omega^*$  来优化网络参数。计算公式为

$$\omega^* = \arg \min_{\omega} \frac{1}{2N} \sum_{i=1}^N [Z_{\omega}(s_i, a_i) - (r_i + \gamma Z_{\omega}(s'_i, a'_i))]^2. \quad (17)$$

这种优化策略有助于模型更准确地学习每个状态-行动对下的回报分布,从而提高整体学习效果。Distributional Q-function 改进的 DQN 模型的原理如图 3 所示。

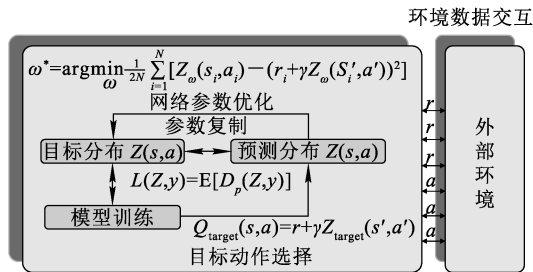


图 3 基于 Distributional Q-function 改进的 DQN 模型的原理

Fig. 3 Principles of improved DQN model based on Distributional Q-function

## 4 验证试验

### 4.1 试验环境及设计

为了验证本研究提出的方法对金浸出率的预测效果,设计了多个试验,试验的过程控制如图 4 所示,所用模型参数的设置见表 1。

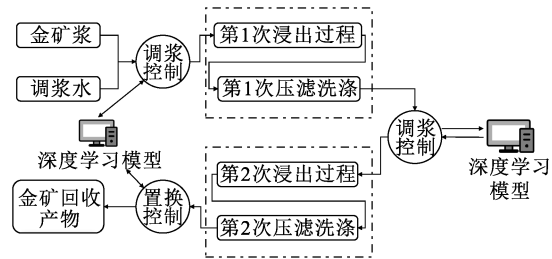


图 4 试验的过程控制示意

Fig. 4 Schematic diagram of test process control

表 1 模型参数的设置

Table 1 Setting of model parameters

模型	参数分类	参数名称	值
Transformer 模型	模型尺寸	隐层维度(d_model)	512 维
		Feed-forward 网络维度(d_ff)	2 048 维
		多头注意力头数(num_heads)	8 个
	训练参数	序列长度(max_seq_len)	512 个
		批处理大小(batch_size)	64 个/批
		学习率(learning_rate)	0.000 1
		权重衰减(weight_decay)	0.01
		学习率衰减策略(lr_decay)	线性衰减
		warmup 步骤数(warmup_steps)	4 000 步
		优化器	类型
正则化和其他	Dropout 率	0.1	
	标签平滑(label_smoothing)	0.1	
网络参数	输入维度	128 维	
	动作数量	18 个	
	隐藏层大小	256 个	
	输出层大小	动作数量	
DQN 模型	训练参数	学习率	0.003
		折扣因子(gamma)	0.99
		更新目标网络间隔(target_update_freq)	每 4 步更新 1 次
	优化器	探索策略	ε-greedy, 其中 ε 初始值 0.9, 每 10 000 步减小 0.001
		类型	RMSprop
记忆回放缓冲区	ε	0.01	
	容量	10 000 个样本	
	批大小(batch_size)	32 个/批	
正则化和其他	梯度裁剪	裁剪到[-1, 1]之间以防止梯度爆炸	
	批大小(batch_size)	32 个/批	

试验所用计算机配置情况为处理器(CPU)的型号为 Intel Xeon Gold 6230,核心数为 20 核,

线程数为 40 线程,基础频率为 2.1 GHz,最大睿频为 3.9 GHz;图形处理器(GPU)的型号为

NVIDIA Tesla V100, CUDA 核心数量为 5 120 个,内存容量为 16 GB HBM2,内存带宽为 900 GB/s,浮点性能为单精度 14TFLOPS;内存(RAM)为 128 GB DDR4;主硬盘为 1 TB PCIe NVMe SSD。软件环境包括操作系统为 Ubuntu Linux 20.04 LTS;编程语言与框架包括 Python 3.8,深度学习框架 PyTorch 1.9.0 和 TensorFlow 2.5.0,以及科学计算和数据处理库 NumPy 1.19.5, Pandas 1.2.5, Matplotlib 3.4.3。

### 4.2 金浸出率的预测准确性评价

为了评价 Transformer 模型对金浸出率的预测准确性,对比研究了 Transformer 和线性回归 2 种模型对金浸出率预测结果。对比试验采用的评价指标如下:

1) 平均绝对误差(MAE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (18)$$

式中:  $y_i$  — 真实值;  $\hat{y}_i$  — 预测值;  $n$  — 样本数量。该指标对浸出过程中的异常值不敏感,适用于评估预测值与真实值之间的实际偏差。

2) 均方误差(MSE):

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (19)$$

该指标对异常值很敏感,因此当存在极端值时, MSE 可能会变得很大。

3) 均方根误差(RMSE):

$$RMSE = \sqrt{MSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (20)$$

该指标可直观反映模型预测值与预测值之间的差异,适用于对误差大小有直观理解需求的场合。

为了提高模型预测结果评价的准确性,重复试验 10 次,取平均值。Transformer 和线性回归模型对金浸出率预测准确率的对比结果见表 2。

表 2 Transformer 和线性回归模型对金浸出率预测准确率的对比

Table 2 Comparison results of prediction accuracy of gold leaching rate by Transformer and linear regression model

模型	MAE/%	MSE/%	RMSE/%
线性回归	74.24	75.72	71.53
Transformer	91.63	89.62	91.37

由表 2 看出: Transformer 模型对浸出率的

预测准确性远高于线性回归模型,说明该模型对金浸出率的预测准确性较高。

### 4.3 金浸出率最大化模型求解过程分析

为了探索模型求解的全过程,绘制了本模型求解的全过程变化曲线,如图 5 所示。可以看出,基于 Distributional Q-function 改进的 DQN 模型能用较少的迭代次数,较快迭代到最优化的金浸出率结果。




图 5 模型的求解迭代过程

Fig. 5 Iterative process of solving model

### 4.4 实证研究

为了研究本模型对金浸出率预测效果,针对某金冶炼工艺进行实际验证研究。在氰化钠浓度 0.5%、pH=11、温度 20 °C、浸出时间 72 h、固液质量体积比 1:2 条件下,分别采用 LSTM 模型和本模型对金浸出率进行预测研究,并对比了经济指标,结果见表 3。可以看出:本模型对金浸出率的预测准确性远高于 LSTM 模型,说明先采用 Transformer 模型进行金浸出率预测、再采用 Distributional Q-function 改进 DQN 模型能实现湿法冶金浸出率最大化,该模型能对工艺条件进行实时监控与调整,通过优化浸出剂投加量,提高操作灵活性,缩短反应时间,减少异常波动,进一步降低生产成本,提高经济效益。

表 3 不同模型对金浸出率预测效果及经济指标评价结果

Table 3 Prediction effect of different models on gold leaching rate and evaluation results of economic indicators

模型	金浸出率/ %	预测准确率/ %	成本/ 万元	经济效益/ 万元
LSTM 模型	91.23	71.53	383	591
本模型	95.74	91.37	322	710

## 5 结论

针对某矿渣浸出金工艺,提出了一种基于深度学习算法的资源回收流程控制方法,该法先采用 Transformer 模型进行金浸出率预测,再采用 Distributional Q-function 改进 DQN 模型进行金浸出率最大化优化。Transformer 模型对金浸出率的预测准确性远高于线性回归模型,预测准确性较高;改进的 DQN 模型能有效降低了浸出率最大化模型的迭代计算时间。

## 参考文献:

- [1] 郭计敏. 金氰化浸出过程非线性预测控制方法及仿真算法分析研究[J]. 湿法冶金, 2023, 42(6): 659-665.  
GUO Jimin. Nonlinear predictive control method and simulation algorithm analysis of gold cyanide leaching process [J]. Hydrometallurgy of China, 2023, 42(6): 659-665.
- [2] 程前, 关世泽, 李瑞霖, 等. 废旧锂电池中钴锂浸出率影响因素的全因子实验[J]. 厦门理工学院学报, 2022, 30(3): 81-89.  
CHENG Qian, GUAN Shize, LI Ruilin, et al. Full factorial experimental study on influencing factors of  $\text{Li}^+$  and  $\text{Co}^{2+}$  leaching efficiency from spent lithium ion batteries [J]. Journal of Xiamen University of Technology, 2022, 30(3): 81-89.
- [3] 莫文水. 金氰化浸出过程混合建模及仿真算法分析研究[J]. 湿法冶金, 2023, 42(4): 429-435.  
MO Wenshui. Hybrid modeling and simulation algorithm of gold cyanide leaching process [J]. Hydrometallurgy of China, 2023, 42(4): 429-435.
- [4] 顾群. 湿法冶金下游流程的分层优化及全流程优化仿真算法分析研究[J]. 湿法冶金, 2023, 42(2): 205-214.  
GU Qun. Hierarchical optimization and whole process optimization simulation algorithm of hydrometallurgy downstream process [J]. Hydrometallurgy of China, 2023, 42(2): 205-214.
- [5] 刘炎, 马喆, 褚菲, 等. 基于分层分块堆叠状态相关降噪自编码器的流程工业过程运行状态评价[J]. 仪器仪表学报, 2023, 44(8): 228-238.  
LIU Yan, MA Zhe, CHU Fei, et al. Plant-wide process operating performance assessment based on hierarchical multi-block stacked performance-relevant denoising auto-encoder [J]. Chinese Journal of Scientific Instrument, 2023, 44(8): 228-238.
- [6] 杨欣伟, 赵雪娇. 某湿法冶金流程运行状态的在线评价方法优化及仿真分析[J]. 湿法冶金, 2023, 42(4): 422-428.  
YANG Xinwei, ZHAO Xuejiao. Operation state evaluation and simulation algorithm analysis of gold hydrometallurgy process based on rough set [J]. Hydrometallurgy of China, 2023, 42(4): 422-428.
- [7] MOSHE Z, DVIR A. Transformer-based time-to-event prediction for chronic kidney disease deterioration [J]. Journal of the American Medical Informatics Association, 2024. DOI: 10.1093/jamia/ocae025.
- [8] 林时敬, 徐安军, 刘成, 等. 基于深度强化学习的炼钢车间天车调度方法[J]. 中国冶金, 2021, 31(3): 37-43.  
LIN Shijing, XU Anjun, LIU Cheng, et al. Crane scheduling method in steelmaking workshop based on deep reinforcement learning [J]. China Metallurgy, 2021, 31(3): 37-43.
- [9] 宫响. 基于 Transformer 模型的神经机器翻译改进方法研究[J]. 自动化与仪器仪表, 2023(8): 257-261.  
GONG Yun. Research on improved neural machine translation method based on transformer model [J]. Automation & Instrumentation, 2023(8): 257-261.
- [10] 卢益清, 严实莲, 杜朋. 基于 Transformer 和 VAE 的汽车新闻文本生成研究[J]. 北京信息科技大学学报(自然科学版), 2023, 38(2): 82-87.  
LU Yiqing, YAN Shilian, DU Peng. Automotive news text generation based on Transformer and VAE [J]. Journal of Beijing Information Science and Technology University (Natural Science Edition), 2023, 38(2): 82-87.
- [11] 商敬安, 韩磊, 吴彬, 等. 基于自注意力机制的多尺度电力机房二次设备巡检算法[J]. 计算机应用, 2022, 42(增刊1): 366-370.  
SHANG Jingan, HAN Lei, WU Bin, et al. Self-attention mechanism-based inspection algorithm for secondary equipments in multi-scale power room [J]. Journal of Computer Applications, 2022, 42(Sup. 1): 366-370.
- [12] PANDA D K, TURNER O, DAS S, et al. Prioritized experience replay based deep distributional reinforcement learning for battery operation in microgrids [J]. Journal of Cleaner Production, 2024, 434. DOI: 10.1016/j.jclepro.2023.139947.

## Design and Research of Hydrometallurgical Resource Recovery Efficiency Improvement Method Based on Deep Learning Algorithm

SONG Yu'an, ZHAO Wei

(School of Materials and Engineering, Jiyuan Vocational and Technical College, Jiyuan 459000, China)

**Abstract:** In order to further improve the recovery rate of hydrometallurgical resources and solve the problem that the intelligent and automatic control degree of resource recovery process control is not high, a hydrometallurgical process control method is proposed, which uses Transformer model to predict metal leaching rate and then uses Distributional Q-function to improve DQN model to maximize gold leaching rate. The results show that the system control method can effectively improve the prediction accuracy of metal leaching rate in hydrometallurgy process. Improving the DQN model based on Distributional Q-function can effectively reduce the iterative calculation time of the model with maximum resource recovery rate. The method can effectively improve the recovery rate of hydrometallurgical resources in a certain plant.

**Key words:** Transformer model; optimization; Distributional Q-function; DQN model; resource recovery