

神经网络建模的金浸出过程及其数值仿真研究

曹红¹, 李庆华²

(1. 浙江商业职业技术学院 财会金融学院, 浙江 杭州 310053;

2. 岭南师范学院 计算机与智能教育学院, 广东 湛江 524048)

摘要:为了精确模拟金浸出率的变化过程,研究设计了一个多级浸出模型,并基于前馈神经网络(Forward Neural Network, FNN)和径向基函数(Radial Basis Function, RBF)构建了反应速率预测模型。通过数值仿真与对比试验对模型的有效性进行了验证。结果表明:该模型对金浸出率的预测值与实际值误差保持在 2.1%~2.6%之间,适应性较强,精确度较高。

关键词:金;浸出;建模;FNN;RBF;多级浸出动态模型;数值仿真

中图分类号:TF803.21 **文献标识码:**A **文章编号:**1009-2617(2025)03-0424-08

DOI:10.13355/j.cnki.sfyj.2025.03.017

湿法冶金浸出过程建模^[1]在现代冶金工业中具有重要意义。浸出过程是湿法提取矿石中有价金属的关键工序,因涉及复杂的化学反应和动力学过程,所以受到多种因素的影响。这些因素相互作用构成了一个高度非线性的系统,使得传统的解析模型难以全面、准确地描述其动力学特性。当前建立数理模型,逐渐成为了破解这一难题的有效途径。如基于神经网络的非线性数据驱动模型^[2],可有效捕捉浸出过程中的复杂反应机制,进而不同工艺参数下对浸出效率进行较为精准的预测。这不仅有助于优化浸出工艺参数、提高金属浸出率,还能降低试验和生产成本,提高资源利用率。

目前已有许多将机器学习方法引入湿法冶金建模过程中的相关研究,但还存在计算精度不够高、智能化程度不高,以及模型过于简单无法适应更加复杂情况等问题^[3-5]。因此,研究设计了一个金浸出过程的单级浸出动态模型,并在此基础上构建了一个多级浸出模型,以此对金浸出过程中的浸出率的变化过程进行建模。随后构建了一个基于前馈神经网络(Forward Neural Network,

FNN)^[6-7]和径向基函数(Radial Basis Function, RBF)^[8-9]集成学习^[10]的金浸出过程反应速率预测模型,并通过数值仿真研究和试验研究验证了该模型的建模效果。

1 单级和多级浸出动态模型

1.1 单级浸出动态模型

单级浸出模型假设反应在一个单一反应器中进行,矿石颗粒与浸出液在均匀混合的条件下接触。金的浸出过程通常涉及金被氧化剂氧化并溶解在含有配位剂的溶液中。单级浸出过程中的反应速率可用以下动力学方程表示:

$$\frac{dc_A}{dt} = -kc_A。$$

式中: c_A —反应液中金浓度, mol/L; t —反应时间, s; k —反应速率常数, s^{-1} 。

该方程假设溶液中金浓度随时间呈指数衰减趋势,即金浓度变化由其初始浓度和反应速率常数共同决定。该方程的解析解为:

$$c_A(t) = c_{A0}e^{-kt}。$$

式中, c_{A0} —金初始浓度, mol/L。

收稿日期:2024-11-18

基金项目:浙江省教育厅支撑计划项目(Y202249939)。

第一作者简介:曹红(1979—),女,硕士,讲师,主要研究方向为人工智能应用及算法。

从解析解看出,金浓度随时间指数下降,可反映单级浸出过程中的动力学特征。

若考虑传质控制,扩散过程的影响可以用类似的方程描述,其中速率常数 k 包含扩散系数 D 和表面积。对于单级浸出过程,通常可以忽略反应器间的传质,因此模型相对简单。

1.2 多级浸出动态模型

多级浸出模型可用于描述湿法冶金等领域中多个反应器串联的情况以提高金属回收率。在这种配置中,每一级浸出器中,随固液接触和反应不断进行,溶液中金浓度在逐级传递中逐步降低。对于多级浸出过程,每一级反应器的金浓度变化可表示为:

$$\frac{dc_{A,i}}{dt} = -k_i c_{A,i} + F(c_{A,i-1} - c_{A,i})$$

式中: $c_{A,i}$ —第 i 级反应器中金浓度, mol/L; k_i —第 i 级反应器中的反应速率常数, s^{-1} , 能反映该级的反应速率; F —流速, L/s, 表示溶液在各级反应器之间的流动速率; $c_{A,i-1}$ —上一阶段反应器中金浓度, mol/L。

在该方程中,溶液从第 $i-1$ 级流入第 i 级反应器,且在该级中进行金的浸出反应。反应速率与浓度成正比,而流动项 $F(c_{A,i-1} - c_{A,i})$ 则反映了流动对浓度变化的影响。

通过耦合每一级的动力学方程,整个多级系统可用多组微分方程描述:

$$\begin{cases} \frac{dc_{A,1}}{dt} = -k_1 c_{A,1} + F(c_{in} - c_{A,1}) \\ \frac{dc_{A,2}}{dt} = -k_2 c_{A,2} + F(c_{A,1} - c_{A,2}) \\ \vdots \\ \frac{dc_{A,n}}{dt} = -k_n c_{A,n} + F(c_{A,n-1} - c_{A,n}) \end{cases}$$

式中: c_{in} —进入系统的溶液中金初始浓度, mol/L; n —反应器总级数。

多级浸出模型需要多组微分方程联立求解以每一级反应器中浓度随时间的变化情况。为了求解这些复杂的方程组,常用的数值方法,如欧拉法或其改进方法^[11],被广泛应用于实际计算中。通过多级动态模型,可以精确预测出金的浸出过程,

并优化流速和每一级的浸出时间,提高回收率。相比单级模型,多级模型考虑了传质和反应器间的传递,因此更适用于连续生产系统中的控制和优化。

2 基于 FNN 和 RBF 集成学习的反应速率模型建模

研究设计了一个基于前馈神经网络(Forward Neural Network, FNN)和径向基函数(Radial Basis Function, RBF)的集成学习的动力学反应速率模型,用于预测浸出过程中部分未知参数,最后再与多级浸出动态模型串联,从而实现浸出率的高效准确预测。

2.1 FNN 模型的原理

FNN 是一种典型的神经网络结构,可用于解决分类和回归等任务,通过层层传递输入数据进行计算,最终输出结果。FNN 的基本原理及分步算法如下:

1) 输入层。FNN 的输入层接收数据样本的特征向量,记为 $\mathbf{x} = [x_1, x_2, \dots, x_n]$, 其中 n 是特征数量。每个特征 x_i 表示样本的不同属性或数值。

2) 隐藏层计算。输入数据从输入层传递到隐藏层,隐藏层节点将输入的特征与权重相乘,并加上偏置项,再通过激活函数进行非线性转换。假设隐藏层中有 m 个节点,则第 j 个节点的输出为:

$$z_j = f\left(\sum_{i=1}^n w_{ji} x_i + b_j\right)$$

式中: z_j —隐藏层的第 j 个节点的输出; f —激活函数,常用的有 ReLU 等,用于引入非线性; w_{ji} —从输入层第 i 个节点到隐藏层的第 j 个节点的权重; x_i —输入层第 i 个特征; b_j —隐藏层的第 j 个节点的偏置项。

3) 输出层计算。隐藏层的输出传递到输出层,同样通过权重和偏置项进行线性组合后再通过激活函数。假设输出层有 k 个节点(通常与类别数相同),则输出层第 o 个节点的输出为:

$$y_o = g\left(\sum_{j=1}^m w'_{oj} z_j + b'_o\right)$$

式中: y_o —输出层第 o 个节点的输出; g —输出层

激活函数(如分类任务中常用 Softmax, 回归任务中可能用恒等函数); ω'_{oj} —从隐藏层的第 j 个节点到输出层第 o 个节点的权重; z_j —隐藏层的第 j 个节点的输出; b'_o —输出层第 o 个节点的偏置项。

2.2 RBF 模型原理

径向基函数模型是一种基于神经网络的模型, 主要用于分类、回归等任务。RBF 模型的核心在于使用径向基函数作为激活函数, 并依赖于输入数据的距离进行计算。RBF 模型的基本原理及算法步骤如下:

1) 输入层。输入层接收样本的特征向量, 记为 $\mathbf{x} = [x_1, x_2, \dots, x_n]$, 其中 n 表示特征的数量。每个输入特征 x_i 是样本的数值属性或描述变量。

2) 隐藏层(径向基核计算)。隐藏层节点使用径向基函数(如高斯函数)对输入数据进行变换, 每个节点计算输入与中心的距离并根据该距离得到响应。假设隐藏层有 m 个径向基节点, 第 j 个节点的输出为:

$$h_j = \phi \|\mathbf{x} - \mathbf{c}_j\| = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_j\|^2}{2\sigma_j^2}\right)$$

式中: h_j —隐藏层第 j 个节点的输出; ϕ —径向基函数, 通常选择高斯函数; $\|\mathbf{x} - \mathbf{c}_j\|$ —输入样本与中心 \mathbf{c}_j 的欧氏距离, 表示为 $\sqrt{\sum_{i=1}^n (x_i - c_{ji})^2}$; \mathbf{c}_j —第 j 个节点的中心向量(即 RBF 中心); σ_j —第 j 个节点的宽度参数(称为“扩展系数”), 控制径向基函数的覆盖范围。

3) 输出层(线性组合)。隐藏层输出的结果传递至输出层, 输出层将这些结果按权重进行线性组合以生成最终输出。假设输出层有一个输出节点, 则输出为:

$$y = \sum_{j=1}^m \omega_j h_j + b$$

式中: y —模型的输出(用于回归或分类预测); ω_j —连接第 j 个隐藏层节点和输出层的权重; h_j —隐藏层第 j 个节点的输出; b —输出层的偏置项。

2.3 模型的集成

FNN 和 RBF 的集成学习模型是将 2 种模型的特性相结合, 即利用 FNN 的层次结构及 RBF 的局部响应特性, 以提高模型的整体泛化能力和预测性能。基于 FNN 和 RBF 的集成学习模型的原理如下:

1) 集成输出层计算。在集成模型中, FNN 和 RBF 子模型分别生成输出 $\mathbf{y}_{\text{FNN}} = [y_{\text{FNN},1}, \dots, y_{\text{FNN},p}]$ 和 $\mathbf{y}_{\text{RBF}} = [y_{\text{RBF},1}, \dots, y_{\text{RBF},q}]$ 。集成模型将 2 个子模型的输出组合以生成最终预测结果。假设使用加权求和的方法来组合 FNN 和 RBF 子模型的输出, 最终集成模型的输出为:

$$y = \alpha \sum_{o=1}^p \beta_o y_{\text{FNN},o} + (1 - \alpha) \sum_{o=1}^q \gamma_o y_{\text{RBF},o}$$

式中: y —集成模型的最终输出; α —FNN 和 RBF 模型输出的组合权重系数, 控制两者的相对贡献, 范围为 $0 \leq \alpha \leq 1$; β_o —FNN 子模型第 o 个输出节点的权重; γ_o —RBF 子模型第 o 个输出节点的权重。

通过设置适当的 α 、 β_o 和 γ_o , 可以调节 FNN 和 RBF 子模型在集成输出中的相对重要性, 从而优化模型的表现。

2) 损失计算。为了衡量模型预测输出 y 与实际值 \hat{y} 的差异, 计算损失函数, 对于回归任务, 通常使用均方误差(MSE)来表示预测结果的误差:

$$L = \frac{1}{2} (y - \hat{y})^2$$

式中: L —损失值, 用于衡量预测值和真实标签之间的差距; \hat{y} —真实标签或目标值。

损失函数的目标是最小化 L , 从而尽可能缩小模型的预测值与真实值之间的差距。对于分类任务, 可使用交叉熵损失来定义损失函数。

3) 模型求解。为了优化模型参数, 使用进化算法计算优化损失函数, 具体步骤见第 3 节。

4) 输出结果。经过进化计算模型的多次训练迭代和参数优化, 集成模型收敛于一个相对较优的参数设置, 即 FNN 和 RBF 的各个参数被调整到一个优化状态。图 1 为基于 FNN 和 RBF 子模型的集成学习模型的基本结构。

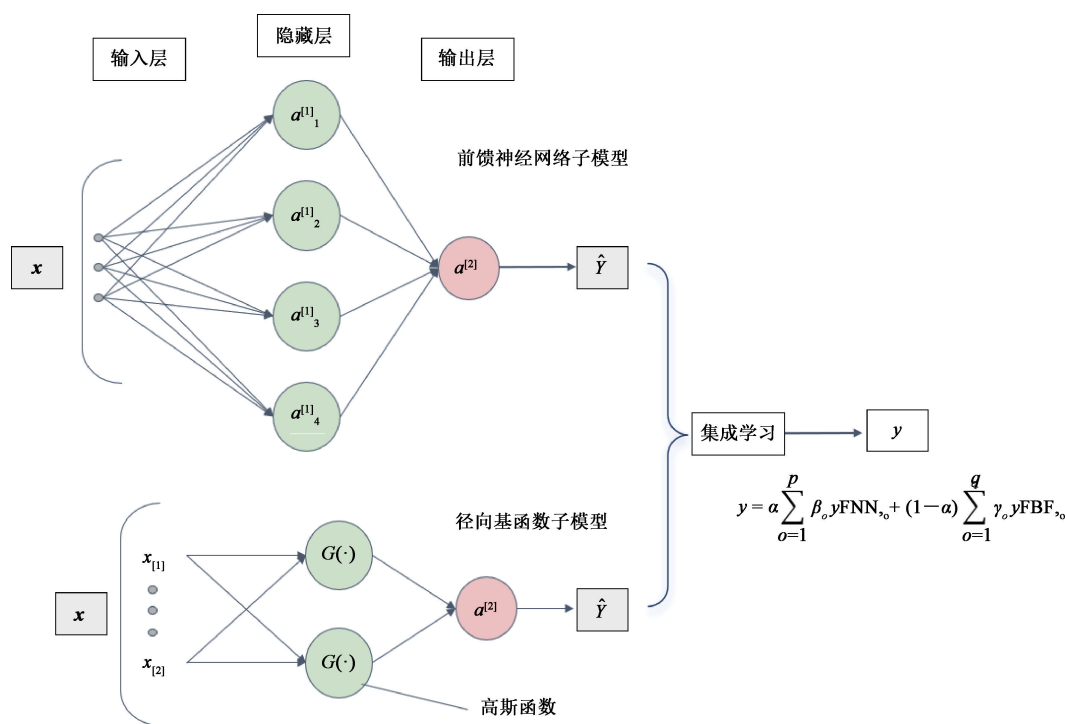


图 1 基于 FNN 和 RBF 集成学习模型的反应速率模型

Fig. 1 Reaction rate model based on FNN and RBF integrated learning model

3 基于进化计算方法的模型求解

针对 FNN 和 RBF 集成学习模型的求解,本研究采用进化计算的方法,通过使用改进的人工蜂群算法(Artificial Bee Colony, ABC)^[12]进行模型求解。人工蜂群算法的计算过程如下:

1)初始化阶段。首先随机生成一组解,即食物源位置,将其作为初始种群。每个解是一个在解空间内的随机向量。

初始化解 $x_{i,j}$ 的计算公式如下:

$$x_{i,j} = x_{\min,j} + \text{rand}(0,1) \cdot (x_{\max,j} - x_{\min,j})。$$

式中: $x_{i,j}$ —第 i 个食物源在第 j 维的初始位置; $x_{\min,j}$ 、 $x_{\max,j}$ —解空间第 j 维的下限、上限; $\text{rand}(0,1)$ —生成一个在 $[0,1]$ 区间内的随机数,用于产生均匀分布的随机位置。

2)工蜂阶段(探索新解)。每个工蜂在当前食物源位置 $x_{i,j}$ 的基础上,通过变异操作生成一个新解 $v_{i,j}$ 。计算公式如下:

$$v_{i,j} = x_{i,j} + \phi_{i,j} \cdot (x_{i,j} - x_{k,j})。$$

式中: $v_{i,j}$ —工蜂生成的新解在第 j 维的值; $x_{i,j}$ —当前解在第 j 维的位置; $x_{k,j}$ —随机选取的一个解在第 j 维的位置,且 $k \neq i$; $\phi_{i,j}$ —随机数,范围在 $[-1,1]$,用于控制变异幅度。通过该变异操作,工蜂能

在当前解附近产生新的解,从而进行局部搜索。

3)适应度计算。计算每个新解 v_i 的适应度 $f(v_i)$,以评估解的质量。对于最小化问题,适应度通常可以表示为:

$$\text{fit}(v_i) = \frac{1}{1 + f(v_i)}。$$

式中: $\text{fit}(v_i)$ —新解 v_i 的适应度值; $f(v_i)$ —目标函数,表示解 v_i 的质量。对于不同的优化问题,目标函数形式会有所不同。适应度 $\text{fit}(v_i)$ 的定义根据本研究问题的特性进行调整,以保证算法收敛的效果。

4)选择跟随蜂阶段(概率选择)。跟随蜂根据适应度选择较好的食物源,选取概率由适应度决定,公式如下:

$$p_i = \frac{\text{fit}(x_i)}{\sum_{j=1}^N \text{fit}(x_j)}。$$

式中: p_i —第 i 个食物源被选中概率; $\text{fit}(x_i)$ —第 i 个食物源的适应度值; N —工蜂的总数。跟随蜂选择高适应度的解,更加集中在质量较高的区域进行搜索,以加快收敛速度。

5)生成新解(跟随蜂)。跟随蜂基于选中的食物源再次生成新解,与工蜂阶段相似,公式如下:

$$v_{i,j} = x_{i,j} + \phi_{i,j} \cdot (x_{i,j} - x_{k,j})。$$

式中的变量含义与工蜂阶段一致,这里主要是跟

随蜂对已知较优的解进行进一步搜索。

6) 侦查蜂阶段(替换停滞解)。若某个解未在一定次数内改进,则视其为停滞解,侦查蜂重新随机生成 1 个新的解,公式如下:

$$x_{i,j} = x_{\min,j} + \text{rand}(0,1) \cdot (x_{\max,j} - x_{\min,j})。$$

式中变量含义与初始化阶段一致,侦查蜂通过随

机化操作引入新的解以跳出局部最优。

7) 迭代终止条件。ABC 算法通常设置最大迭代次数或解的精度要求作为终止条件。若达到最大迭代次数或找到精度满足的解,则停止迭代。

用 ABC 算法进行模型求解的计算过程如图 2 所示。

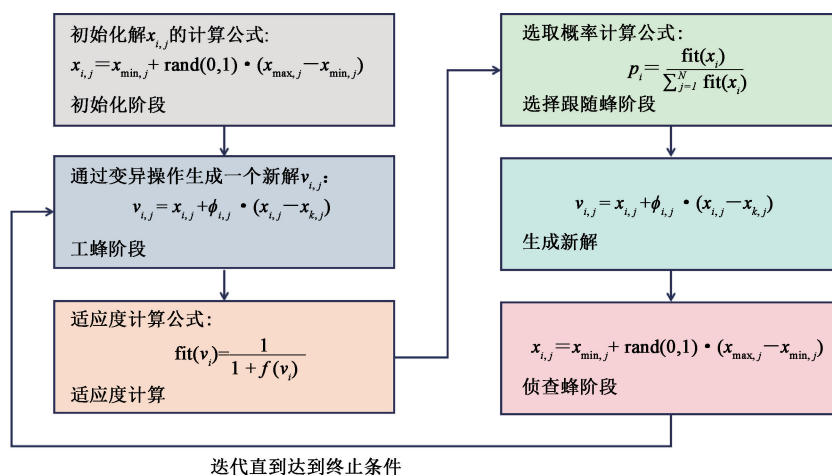


图 2 基于进化计算的模型求解过程

Fig. 2 Model solving process based on evolutionary computation

4 数值仿真

为了验证多级浸出动态模型的建模效果,进行了数值仿真试验,设置 3 个串联反应器,模拟每级反应器中金属浸出的传质和反应过程。

在多级浸出动态模型中,初始浓度会影响反应初期的溶质浓度梯度。因此,通过试验考察了金属初始浓度对浸出率的影响,结果见表 1。可以看出:相同浸出时间条件下,金初始浓度越高,相对应的浸出率也越高;初始浓度为 1.5 mol/L 时,浸出 50 min 的金浸出率达 94.0%,而此时初始浓度为 0.5 mol/L 时对应的金浸出率仅为 58.9%,说明较高的初始浓度能加速溶质的扩散和反应进程。

表 1 金初始浓度对金浸出率的影响
Table 1 Effect of initial gold concentration on leaching rate of gold %

浸出时间/min	0.5 mol/L	1.0 mol/L	1.5 mol/L
10	15.2	28.6	42.1
20	32.1	52.3	68.9
30	48.3	72.4	85.2
40	55.7	80.5	91.4
50	58.9	84.1	94.0

在多级浸出过程中,溶液流速会对反应物在系统中的循环速度产生影响,因为较高的流速能增加物料接触频率,使反应物更快速接触,从而提高浸出率。因此,通过试验考察了流速对金浸出率的影响,结果见表 2。可以看出:相同浸出时间条件下,溶液流速越快,金浸出率越高;流速为 0.7 L/min 时,浸出 30 min 的金浸出率即可达 79.4%,而此时流速为 0.3 L/min 对应的仅为 49.3%,进一步说明流速对反应物质接触效率的重要性。

表 2 流速对金浸出率的影响
Table 2 Effect of flow rate on leaching rate of gold %

浸出时间/min	0.3 L/min	0.5 L/min	0.7 L/min
10	18.3	25.6	35.1
20	34.2	52.1	63.7
30	49.3	70.2	79.4
40	55.1	77.9	86.8
50	57.9	81.6	88.9

反应速率常数 k 可表征反应本身的速率特性。因此,通过试验考察了反应速率常数 k 对金浸出率的影响,结果见表 3。可以看出:相同浸出时间条

件下,溶液流速越快,金浸出率越高; $k=0.2 \text{ min}^{-1}$ 时,浸出 50 min 的金浸出率为 92.0%,而此时 $k=0.05 \text{ min}^{-1}$ 对应的金浸出率仅为 51.5%,说明较高的反应速率常数对加快浸出有一定促进作用。

表 3 反应速率常数 k 对金浸出率的影响

浸出时间/min	0.05 min^{-1}	0.1 min^{-1}	0.2 min^{-1}
10	12.4	24.5	41.3
20	27.9	49.2	69.8
30	41.7	68.3	84.5
40	48.9	74.6	89.7
50	51.5	78.1	92.0

反应器体积会影响溶质在多级反应器中的滞留时间,滞留时间越长,溶质与溶剂之间的混合越充分,提高浸出率。因此,通过试验考察了反应器体积对金浸出率的影响。可以看出:相同浸出时间条件下,反应器体积越大,金浸出率越高;反应器体积为 15 L 时,浸出 50 min 的金浸出率达 92.1%,而此时体积为 5 L 对应的金浸出率仅为 54.9%,说明反应器体积越大,越有利于金浸出率。

表 4 反应器体积对金浸出率的影响

浸出时间/min	5 L	10 L	15 L
10	19.5	27.6	35.2
20	33.2	54.3	68.1
30	46.8	72.8	82.7
40	52.3	79.6	89.4
50	54.9	83.2	92.1

温度的变化对反应速率和浸出率有显著影响。因此,通过试验考察了温度对金浸出率的影响,结果见表 5。可以看出:温度为 45 °C 时,浸出 50 min 的金浸出率达 91.8%,而此时温

度为 25 °C 对应的浸出率仅为 54.7%,这说明温度会对加速浸出过程起到关键作用,因为较高温度可增加反应物分子的动能,加快浸出反应速率,因此在高温条件下可使金浸出率显著提高。

表 5 温度对金浸出率的影响

浸出时间/min	25 °C	35 °C	45 °C
10	16.3	25.4	38.6
20	29.8	48.9	67.5
30	44.1	67.6	83.1
40	51.9	75.3	89.2
50	54.7	79.4	91.8

5 验证试验

为了验证 FNN 和 RBF 集成学习模型对反应速率模型的建模效果,针对某公司金浸出工艺开展了验证试验。选择不同初始浓度、温度和流速作为试验条件,对金浸出率进行计算。通过一套在线监测系统数据进行采集,包括高精度传感器和数据采集器,每隔 5 min 自动采集反应器内溶质浓度、温度和浸出率等关键参数,试验的总时间设定为 50 min。随后分别基于采集的数据集,针对 FNN 和 RBF 集成学习模型进行了 3 个对比试验。

第 1 个试验在不同初始浓度下验证集成模型对反应速率随金始浓度的变化的建模准确性,通过分析模型对金浸出率的预测值与实际值的偏差进行评估。不同初始浓度条件下的浸出率预测值和实际值的对比见表 6。经计算得出,集成模型对浸出率的预测值与实际值的平均误差为 2.3%,表明该集成模型在处理浓度对反应速率的影响时表现良好,能有效捕捉反应物浓度变化对浸出率的动态影响,说明其在不同初始浓度下的建模效果较稳定。

表 6 不同初始浓度下金浸出率预测值和实际值的对比

浸出时间/min	0.5 mol/L		1.0 mol/L		1.5 mol/L	
	实际浸出率/%	预测浸出率/%	实际浸出率/%	预测浸出率/%	实际浸出率/%	预测浸出率/%
10	15.2	15.1	28.6	28.7	42.1	41.8
30	48.3	47.9	72.4	72.1	85.2	84.7
50	58.9	58.3	84.1	83.7	94.0	93.5

第2个试验在不同温度下验证集成模型对反应速率随反应温度的变化的建模效果,考察其在不同温度下的反应速率预测能力与实际试验数据的拟合程度。不同温度下的金浸出率预测值和实际值的对比见表7。经计算得出,集成模型对浸出率的预测值与实际值的平均误差为2.6%,说明模型能准确捕捉温度对反应速率的影响。

第3个试验通过改变流速探究集成模型对流速变化对金浸出率影响的敏感性,以验证模型在动态流动环境中对反应过程的适应性和精度。不同流速下的金浸出率预测值和实际值的对比见表8。经计算得出,集成模型对浸出率的预测值与实际值的平均误差为2.1%,表明模型能精确预测不同流速条件下的浸出动态过程。

表7 不同温度下的金浸出率预测值和实际值的对比

Table 7 Comparison of predicted and actual gold leaching rates at different temperatures

浸出时间/min	25 °C		35 °C		45 °C	
	实际浸出率/%	预测浸出率/%	实际浸出率/%	预测浸出率/%	实际浸出率/%	预测浸出率/%
10	16.3	16.5	25.4	25.7	38.6	38.2
30	44.1	43.9	67.6	67.3	83.1	82.7
50	54.7	54.2	79.4	79.0	91.8	91.2

表8 不同流速下的金浸出率预测值与实际值的对比

Table 8 Comparison of predicted and actual gold leaching rates at different flow rates

浸出时间/min	0.3 L/min		0.5 L/min		0.7 L/min	
	实际浸出率/%	预测浸出率/%	实际浸出率/%	预测浸出率/%	实际浸出率/%	预测浸出率/%
10	18.3	18.1	25.6	25.5	35.1	35.0
30	49.3	48.8	70.2	69.9	79.4	78.9
50	57.9	57.5	81.6	81.2	88.9	88.5

综上所述,FNN和RBF集成模型在不同试验条件下的预测误差均较低,证明其对多因素影响下反应速率动态建模的适应性较强,精度较高。

6 结论

通过构建多级浸出动态模型,以及FNN和RBF集成学习模型,成功实现了对金浸出动态过程的精准建模。在不同的金初始浓度、温度和流速条件下,该模型对金浸出率的预测值与实际值之间平均误差保持在2.1%~2.6%之间,预测误差较低,说明其对多因素影响下反应速率的适应性较强,精度也较高,实际应用效果较好,可用于实时监测和优化生产过程,以提升工艺效率与产品质量。

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] 雷江龙, 余娟, 向明旭, 等. 基于深度神经网络的数据驱动潮流计算异常误差改进策略[J]. 电力系统自动化, 2022, 46(1): 76-84.
LEI Jianglong, YU Juan, XIANG Mingxu, et al. Improvement strategy for abnormal error of data-driven power flow calculation based on deep neural network[J]. Automation of Electric Power Systems, 2022, 46(1): 76-84.
[3] 高军, 刘亚东. 基于定性定量混合建模的金湿法冶金过程优化研究[J]. 长春师范大学学报, 2022, 41(10): 65-73.
GAO Jun, LIU Yadong. Research on process optimization based on qualitative and quantitative hybrid modeling for the gold hydrometallurgy[J]. Journal of Changchun Normal University, 2022, 41(10): 65-73.
[4] 马治卿, 高东坡, 马磊. 湿法冶金硫化镍加压浸出过程的建模方法[J]. 有色冶金设计与研究, 2022, 43(4): 14-18.
MA Zhiqing, GAO Dongpo, MA Lei. Modeling method of nickel sulfide pressure leaching in hydrometallurgical process[J]. Nonferrous Metals Engineering & Research, 2022, 43(4): 14-18.
[5] 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.
- [6] 朱文刚, 盛春岩, 范苏丹, 等. 基于前馈神经网络的多模式集成降水预报研究[J]. 干旱气象, 2024, 42(1): 117-128.
ZHU Wengang, SHENG Chunyan, FAN Sudan, et al. Research on multi-model integrated precipitation forecast based on feed forward neural network[J]. Journal of Arid Meteorology, 2024, 42(1): 117-128.
- [7] 张利成, 鲍煦, 李静, 等. 湍流扩散环境中基于前馈神经网络的信源定位算法[J]. 东南大学学报(自然科学版), 2023, 53(2): 370-376.
ZHANG Licheng, BAO Xu, LI Jing, et al. Source localization algorithm based on feed-forward neural network in turbulent diffusion environment[J]. Journal of Southeast University: Natural Science Edition, 2023, 53(2): 370-376.
- [8] 王昭昶, 张涛, 杨滨, 等. 基于径向基函数神经网络的脑损伤电阻抗成像仿真研究[J]. 中国医学装备, 2023, 20(3): 1-5.
WANG Zhaoxi, ZHANG Tao, YANG Bin, et al. Simulation study of electrical impedance imaging of brain injury based on RBF neural network [J]. China Medical Equipment, 2023, 20(3): 1-5.
- [9] 刘泓杉, 刘慧博. 基于径向基函数神经网络的永磁同步电机转速自适应控制策略[J]. 电子器件, 2023, 46(6): 1552-1560.
LIU Hongsan, LIU Huibo. Speed adaptive control strategy of permanent magnet synchronous motor based on RBF neural network [J]. Chinese Journal of Electron Devices, 2023, 46(6): 1552-1560.
- [10] 姚锐, 李俊, 惠萌, 等. 基于集成学习的自适应提升分类模型的局部放电识别研究[J]. 电网技术, 2022(6): 2410-2419.
YAO Rui, LI Jun, HUI Meng, et al. Pattern recognition for partial discharge using adaptive boost classification model based on ensemble method [J]. Power System Technology, 2022(6): 2410-2419.
- [11] 冯志友, 张燕, 杨廷力, 等. 基于牛顿欧拉法的 2UPS-2RPS 并联机构逆动力学分析[J]. 农业机械学报, 2009(4): 193-197.
FENG Zhiyou, ZHANG Yan, YANG Tingli, et al. Inverse dynamics of a 2UPS-2RPS parallel mechanism by newton-euler formulation [J]. Transactions of the Chinese Society for Agricultural Machinery, 2009(4): 193-197.
- [12] 周新宇, 尹子悦, 高卫峰, 等. 一种基于强化学习的自适应多邻域人工蜂群算法[J]. 计算机学报, 2024, 47(7): 1521-1546.
ZHOU Xinyu, YIN Ziyue, GAO Weifeng, et al. Adaptive multi-neighborhood artificial bee colony algorithm based on reinforcement learning [J]. Chinese Journal of Computers, 2024, 47(7): 1521-1546.

Neural Network Modelling of Gold Leaching Process and Its Numerical Simulation

CAO Hong¹, LI Qinghua²

(1. School of Accounting and Finance, Zhejiang Business College, Hangzhou 310053, China;

2. School of Computer Science and Intelligence Education, Lingnan Normal University, Zhanjiang 524048, China)

Abstract: In order to accurately simulate the variation process of gold leaching rate, a multistage leaching model was designed, and the reaction rate prediction model based on the Forward Neural Network (FNN) and Radial Basis Function (RBF) was constructed. The validity of the model was verified by numerical simulation and comparative test. The results show that the error between the predicted value and the actual value of the gold leaching rate is between 2.1% and 2.6%, which is effective and accurate.

Key words: gold; leaching; modeling; FNN; RBF; multi-stage leaching dynamic model; numerical simulation