

文章编号: 1001-0920(2012)03-0329-06

针铁矿法沉铁过程铁离子浓度集成预测模型

熊富强, 桂卫华, 阳春华

(中南大学 信息科学与工程学院, 长沙 410083)

摘要: 针对某冶炼生产企业针铁矿法沉铁过程 Fe^{2+} 浓度和 Fe^{3+} 浓度难以实时检测的问题, 在奥拓昆普生产设备和工艺的基础上, 利用改进最小二乘支持向量机模型具有对小样本进行非线性预测、过程神经网络可充分表达历史数据序列中时间累积效应的特点, 提出一种基于信息熵方法的集成预测模型. 仿真实验表明, 集成预测模型具有良好的预测性能, 预测效果能满足针铁矿法沉铁过程对铁离子浓度值的误差要求.

关键词: 针铁矿法沉铁过程; Fe^{2+} 浓度和 Fe^{3+} 浓度; 改进最小二乘支持向量机; 过程神经网络; 集成预测模型
中图分类号: TP273 **文献标识码:** A

Integrated prediction model of iron concentration in goethite method to remove iron process

XIONG Fu-qiang, GUI Wei-hua, YANG Chun-hua

(School of Information Science and Engineering, Central South University, Changsha 410083, China. Correspondent: XIONG Fu-qiang, E-mail: xfqlqq@yahoo.com.cn)

Abstract: To deal with the problem of detecting the concentration of Fe^{2+} and Fe^{3+} in the goethite method to remove iron process of a smelting production enterprises, on the basis of Outokumpu production equipment and technology, by using improved least squares support vector machine to realize the nonlinear prediction for small sample and process neural networks to realize the time cumulative effect of historical data series, an integrated prediction model is proposed based on information entropy method. Simulation results show that, the integrated prediction model has good prediction performance which satisfies the error request of the iron concentration in goethite method to remove iron process.

Key words: goethite method to remove iron process; concentration of Fe^{2+} and Fe^{3+} ; improved least squares support vector machine; process neural networks; integrated prediction model

1 引言

锌作为一种重要的有色金属原材料, 在国民经济中有着广泛的应用, 湿法炼锌目前已成为锌冶炼的主导发展方向^[1]. 冶炼生产企业通常采用高铁硫化锌精矿直接常压富氧浸出的湿法冶炼方法, 由于铁在进行电沉积等后续工艺时存在较大危害, 除铁是湿法炼锌中最为普遍和重要的一道工序.

硫酸锌溶液的除铁方法主要有3种: 水解法沉铁、黄钾(钠)铁矾法沉铁和针铁矿法沉铁^[2]. 其中, 针铁矿法沉铁的铁渣含铁量较高, 夹带有价金属少, 结晶大, 容易过滤, 经适当预处理可作为炼铁富矿使用, 是除铁方法未来的发展方向. 然而, 针铁矿法除铁的工艺条件要求苛刻, 难以控制和掌握. 冶炼生产企业

在成套引入奥拓昆普生产设备和工艺基础上, 结合企业的生产实际, 进一步研究当矿源变化、浸出和沉铁操作条件调整导致的入口酸度和铁含量波动情况下的控制策略, 建立连续生产沉铁反应的过程模型, 优化调节各相关工艺参数, 提高沉铁效率, 保证针铁矿高品位的前提下减少氧化锌及氧气的添加量, 具有积极的意义.

冶炼生产企业针铁矿法沉铁过程采用4台沉铁反应器, 其中4#反应器出口的 Fe^{2+} 浓度和全铁离子浓度(包括 Fe^{2+} 浓度和 Fe^{3+} 浓度)是整个针铁矿法沉铁过程中的重要技术指标. 由于现场检测设备的实时性较差, 若能根据当前工况及过程参数建立精确的预测模型来预估出口的铁离子含量, 由预估值来指导

收稿日期: 2010-10-07; 修回日期: 2010-12-17.

基金项目: 国家自然科学基金项目(60874069); 国家863计划项目(2009AA04Z137); 湖南省自然科学基金项目(09JJ3122).

作者简介: 熊富强(1984—), 男, 博士生, 从事工业过程预测与优化控制的研究; 桂卫华(1950—), 男, 教授, 博士生导师, 从事复杂工业过程建模与优化、大系统理论与应用等研究.

当前时刻应鼓入的氧气量,则可以减少鼓入氧气的盲目性.

目前,国内外关于奥拓昆普生产工艺下铁离子浓度预测模型的相关文献比较少.由于针铁矿法沉铁过程中化学反应机理复杂,针对铁离子浓度的建模极其困难.随着生产企业基础自动化水平的大幅提升,针铁矿法沉铁过程中积累了一定的工业运行数据,这些数据中包含丰富的反映生产关键工艺参数的潜在信息,为针铁矿法沉铁过程铁离子浓度的预测建模提供了有利条件.

近年来,基于数据驱动的建模策略^[3-4]在复杂工业过程预测建模中取得了较好的应用效果.其中,支持向量机(SVM)建模方法采用结构风险最小化原则,兼顾训练样本的拟合性和复杂性,其预测模型具有良好的外推性能,已成为解决复杂工业过程预测建模问题的强有力工具^[5-6].但SVM预测建模过程的计算复杂度较大,于是Suykens等人^[7]提出了最小二乘支持向量机(LSSVM),该方法用训练误差的平方代替SVM中的松弛变量,将SVM的二次规划问题转化为求解线性方程组问题,从而具有更快的学习速度,在复杂工业过程预测建模中取得较好的应用效果^[8-10].

由于LSSVM模型的预测性能与核函数参数和正则化参数关系很大,常用的网格参数选择法计算量非常大,目前,主要采用遗传算法、粒子群算法等智能优化算法对上述参数进行选取,以缩短算法计算时间,降低对参数初值选取的依赖度.Storn等人^[11]共同提出了差分进化算法,该算法采用实数编码、基于差分的简单变异操作和一对一的竞争生存策略,降低了遗传操作的复杂性,具有强大的全局收敛能力和较好的鲁棒性.基本DE算法子代的生成采用“贪婪”的选择方式,虽然能使算法具有快速的收敛特性,但增加了算法陷入局部最优或早熟收敛的概率.为了克服这一缺陷,文献^[12]提出了一种基于密度聚类的小生境差分进化算法,利用多种群协同进化策略提高进化过程中种群的多样性,增强算法跳出局部最优的能力.

为了充分利用人工神经网络所具有的非线性映射和函数逼近功能,同时反映出实际过程控制量自身的时间相关性,何新贵等人^[13]提出了过程神经网络模型,它是由若干过程神经元和一般非时变神经元按一定拓扑结构组成的一种连续神经网络,其输入和权值是时变函数,聚合运算既有对空间的多输入聚合,也有对时间过程的累积,能充分反映历史数据序列中的时间累积效应.

本文在深入分析针铁矿法沉铁过程工艺机理的基础上,根据1#反应器入口的铁离子浓度及与除铁

有关的沉铁过程工况参数,利用基于小生境差分进化算法参数优化的改进LSSVM模型具有对小样本进行非线性预测、过程神经网络可充分表达历史数据序列中时间累积效应的特点,提出一种融合小生境差分进化算法-LSSVM和过程神经网络的集成预测模型,获得更加准确的沉铁过程4#反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度预测结果,以满足氧气添加量控制系统的要求.

2 针铁矿法沉铁过程工艺分析

设冶炼生产企业针铁矿法沉铁过程在整个常压富氧直接浸出工序中处于沉钢之后除铜氯之前,具体流程如图1所示.现有4台沉铁反应器,1台浓密机,3台压滤机,2台日常料仓,针铁矿法沉铁工艺流程如图2所示.

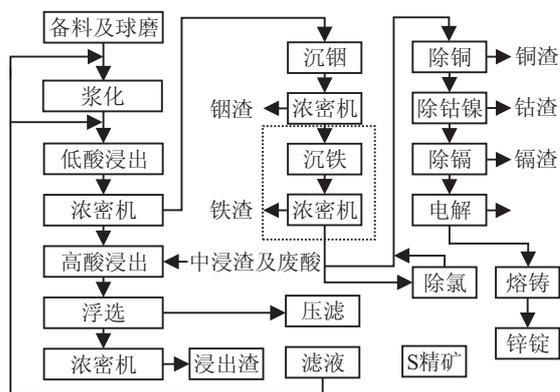


图1 常压富氧浸出工序流程

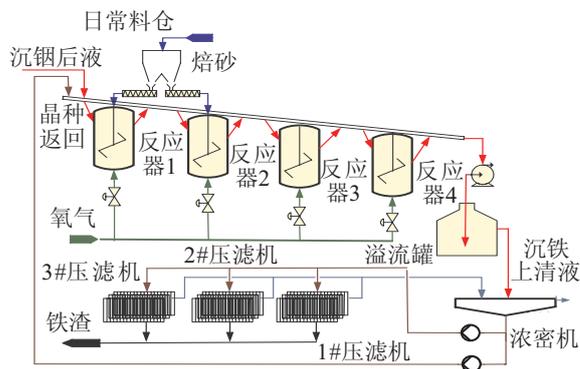


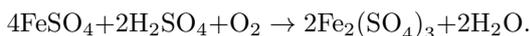
图2 针铁矿法沉铁工艺流程

4台沉铁反应器由高到低层呈阶梯排列,沉钢后液经溜槽首先进入1#沉铁反应器,1#反应器溢出后液通过流槽依次流经2#,3#,4#沉铁反应器.4#反应器浸出后液经溜槽自流到溢流槽,然后经泵压到浓密机固液分离,浓密机上清液即为沉铁上清液,送往锌II系统中性浸出.浓密机的底液部分作为晶种泵回1#沉铁反应器,部分送往1#~3#压滤机,经过压滤、洗涤后产出铁渣,其中1#~3#压滤机的上清液均送回浓密机,4#反应器溢出液即为针铁矿法除铁后液.生产过程中,沉钢后液流量加上返流流量的

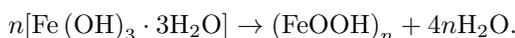
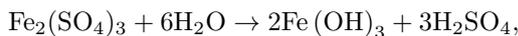
总流量大小约为 $300\text{ m}^3/\text{h}$, 每个反应器的有效容积约为 300 m^3 , 溢流罐容积约为 200 m^3 , 浓密机容积约为 1600 m^3 .

针铁矿法沉铁过程是通过加入中和剂调整 pH 值使沉钡后液中的铁以针铁矿形式沉淀在渣中, 同时鼓入氧气和氧化二价铁离子, 使溶液中 2 价铁离子小于 0.1 g/L , 总的铁离子小于 1.5 g/L . 沉铁过程的主要控制参数是 pH 值和氧化程度: pH 值通过添加挥发窑烟灰(氧化锌)来调控, 挥发窑烟灰主要添加在第 1 个沉铁反应器中, 第 2 个反应器中的挥发窑烟灰用于终点 pH 值微调, pH 值太低会降低沉淀效率, pH 值太高会使其他成分发生不必要的沉淀, 降低挥发窑烟灰的反应性, 这两个现象都会降低沉淀物中的铁含量, 奥拓昆普给出最后一个反应器中的 pH 值控制范围在 3~4 之间; 氧化程度通过在各反应器底部鼓入适量的氧气来实现, 必须鼓入足够量的氧气才能氧化掉几乎全部的亚铁, 但氧气量太大在经济上不划算, 需要减小氧气的浪费. 通过检测到的 4# 反应器出口溶液 pH 值和铁离子浓度, 对挥发窑烟灰(氧化锌)和氧气供应量进行调整.

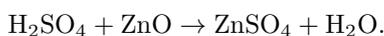
针铁矿法沉铁过程中主要的化学反应方程式如下: 氧化反应为



水解反应为



中和反应为



上述氧化反应、中和反应属于两相反应, 有较强的非线性, 同时, 3 个反应之间存在着强耦合关系.

根据对针铁矿法沉铁过程的实际调研, 考虑到工业现场 3# 反应器出口的 Fe^{2+} 浓度和 Fe^{3+} 浓度没有检测点, 确定影响 4# 反应器出口 Fe^{2+} 浓度的主要过程工况参数如下: 1# 反应器入口的 Fe^{2+} 浓度 x_1^{2+} , pH 值 x_2^{2+} , 总流量 x_3^{2+} , 各反应器的 pH 值 $x_4^{2+}, \dots, x_7^{2+}$ 和 O_2 流量 $x_8^{2+}, \dots, x_{11}^{2+}$, 1# 和 2# 反应器出口的 Fe^{2+} 浓度 x_{12}^{2+} 和 x_{13}^{2+} , 2# 反应器出口 Fe^{3+} 浓度 x_{14}^{2+} . 4# 反应器出口 Fe^{3+} 浓度的主要过程工况参数如下: 1# 反应器入口的 Fe^{3+} 浓度 x_1^{3+} , pH 值 x_2^{3+} , 总流量 x_3^{3+} , 各反应器的 pH 值 $x_4^{3+}, \dots, x_7^{3+}$ 和 O_2 流量 $x_8^{3+}, \dots, x_{11}^{3+}$, 1# 和 2# 反应器出口的 Fe^{3+} 浓度 x_{12}^{3+} 和 x_{13}^{3+} , 2# 反应器出口 Fe^{2+} 浓度 x_{14}^{3+} . 其中, 1# 反应器入口离子浓度每 8h 检测一次, 1# 反应器入口 pH 值可实时在线检测, 1# 反应器入口的总流量可在线检测, 1#, 2#, 3#, 4# 反应器的 pH 值和 O_2 流量可在线检测, 1#, 2#,

4# 反应器出口的 Fe^{2+} 浓度和 Fe^{3+} 浓度每 2h 检测一次. 因此, 在建模过程中将数据样本的时间间隔设置为 2h, 对于 1# 反应器入口离子浓度采用插值方法进行处理, 对于能实时在线检测的数据取 2h 内的平均值, 从而获得 4# 反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度预测模型的输入变量集.

3 基于小生境差分进化算法参数优化的 LSSVM 预测模型

设 $S = (x_i, y_i) (i = 1, 2, \dots, n, x_i \in R^D, y_i \in R)$ 为一组给定训练样本集. 其中: x_i 为影响 4# 反应器出口 Fe^{2+} 浓度或 Fe^{3+} 浓度的工况参数, D 为工况参数的个数, y_i 为对应的 4# 反应器出口 Fe^{2+} 浓度或 Fe^{3+} 浓度. LSSVM 使用一个非线性映射 $\Phi(x) : R^D \rightarrow R^{D_h}$ 将训练集样本从原空间映射到 D_h 维特征空间 (Hilbert 空间), 构造高维空间线性回归函数为

$$y(x) = \langle w, \Phi(x) \rangle + b. \quad (1)$$

其中: w 为权值向量, b 为阈值.

针对非线性问题, 通过非线性变换将输入向量映射到高维特征空间, 并转化为类似的线性回归问题加以解决, 将回归估计问题定义为对一个损失函数进行风险最小化问题. LSSVM 利用结构风险最小化 (SRM) 原则构造如下具有等式约束条件的最小化目标函数:

$$\min J(w, e) = \frac{1}{2} w^T w + \frac{\gamma}{2} \sum_{i=1}^N e_i^2,$$

$$\text{s.t. } y = w^T \varphi(x_i) + b + e_i. \quad (2)$$

其中: γ 为正则化参数, $e_i (i = 1, 2, \dots, n)$ 为 n 个样本点训练误差. 为了方便求解上述优化问题, 通过拉格朗日乘子将约束优化问题转换为如下无约束问题:

$$L(w, b, e, a) =$$

$$J(w, e) - \sum_{i=1}^N \lambda_i (w^T \varphi(x_i) + b + e_i - y_i), \quad (3)$$

其中 $\lambda_i (i = 1, 2, \dots, n)$ 为拉格朗日乘子.

根据 KKT 最优化条件可得

$$\frac{\partial L}{\partial w} = \frac{\partial L}{\partial b} = \frac{\partial L}{\partial \lambda_k} = \frac{\partial L}{\partial e_k} = 0, \quad (4)$$

式 (4) 可以表示为

$$\begin{bmatrix} 0 & 1^T \\ 1 & W + \gamma^{-1}I \end{bmatrix} \begin{bmatrix} b \\ \lambda \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}. \quad (5)$$

其中: $y = [y_1, y_2, \dots, y_n]$, $1 = [1, 1, \dots, 1]^T$, $\lambda = [\lambda_1, \lambda_2, \dots, \lambda_n]$.

根据 Mercer 条件定义

$$W_{ij} = \langle \phi(X_i), \phi(X_j) \rangle = K(X_i, X_j), \quad (6)$$

式 (5) 可表示为

$$y(x) = \sum_{k=1}^n \lambda_k K(x_k, x) + b. \quad (7)$$

其中: λ_k 和 b 可由式 (5) 计算得到; $K(x_k, x)$ 为核函数, 选为 RBF 核函数

$$K(x_i, x) = \exp\left(-\frac{\|x_i - x\|^2}{2\sigma^2}\right). \quad (8)$$

正则化参数 γ 直接控制目标函数中的模型复杂度和训练误差的权重比例; 核参数 σ 控制核函数的作用半径, 是有界的局部函数. LSSVM 预测模型的性能在很大程度上取决于正则化参数 γ 和核参数 σ 是否能合理选取, 为了避免上述参数人工选取的主观性和盲目性, 本文利用基于密度聚类的小生境差分进化算法^[12]进行 LSSVM 模型参数的优化选取.

由于 4# 反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度预测模型的输入数据都为 14 维, 根据经验公式可知: $\sigma \in [0.1\sqrt{l}, \sqrt{l}]$, l 为输入数据的维数, 则 $\sigma \in [0.35, 4]$; 正则化参数 γ 设置在 $[l \times 10^{-1.2}, l \times 10^{1.5}]$, 则正则化参数 $\gamma \in [0.88, 440]$. 运用基于密度聚类的小生境差分进化算法对 LSSVM 参数优化选取的步骤如下:

Step 1: 在给定范围内对 LSSVM 模型的两个参数进行初始化, 构成一个由随机数组成的染色体, 进而形成初始种群.

Step 2: 将种群中的个体解码还原成 LSSVM 模型中的两个参数, 并用训练样本集对 LSSVM 模型进行训练学习, 以预测模型预估值和实际检测值的拟合误差作为优化目标, 使种群中的每个个体都有一个适应度值.

Step 3: 采用基于密度聚类的小生境差分进化算法进行目标函数寻优, 将较优的个体作为子代种群, 解码还原到 LSSVM 模型中充当两个参数, 并输入训练样本, 继续循环进行改进的差分进化算法的相关操作, 直到满足算法的停止条件.

Step 4: 从获得的种群中选择最优个体, 解码还原得到 LSSVM 模型中的两个参数, 建立相应的 LSSVM 模型, 进行 Fe^{2+} 浓度和 Fe^{3+} 浓度的预测建模.

4 过程神经网络预测模型

针对针铁矿法沉铁过程在时间上的继承性和连续性, 基于过程神经网络预测建模的基本思想, 分别建立如图 3 所示的具有 3 层结构的 4# 反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度时间序列预测模型, 拓扑结构为 1-5-1.

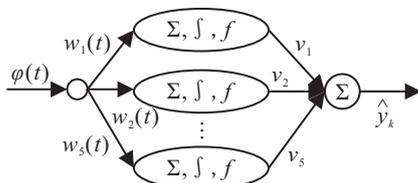


图 3 过程神经网络预测模型结构

设 4# 反应器出口 Fe^{2+} 浓度 (Fe^{3+} 浓度) 历史检测数据为 y_{k-1}, y_{k-2}, \dots , 将这些数据进行函数拟合, 产生时变函数 $\varphi(t)$, 并利用该函数对当前 k 时刻 Fe^{2+} 浓度 (Fe^{3+} 浓度) y_k 进行估计. 基于过程神经网络的 4# 反应器出口 Fe^{2+} 浓度 (Fe^{3+} 浓度) 时间序列预测模型对当前 k 时刻的预测值 \hat{y}_k 为

$$\hat{y}_k = \sum_{i=1}^5 v_i f\left(\int_0^T w_i(t) \varphi(t) dt - \theta_i\right) - \theta. \quad (9)$$

其中: $\varphi(t)$ 为过程神经元的输入函数, $[0, T]$ 为样本采样区间, $w_i(t)$ 为输入节点到隐层节点的连接权函数, v_i 为隐层节点到输出节点的连接权值, θ_i 和 θ 为过程神经元阈值, $f(\cdot)$ 为激励函数.

根据 Weierstrass 逼近定理空间上的推广并通过 Gram-Schmidt 正交化步骤, $\varphi(t)$ 和 $w_i(t)$ 可以展开为

$$\varphi(t) = \sum_{n=1}^N a_n b_n(t), \quad w_i(t) = \sum_{n=1}^N w_{in} b_n(t), \quad (10)$$

其中 $a_n, w_{in} \in R$ 为展开式系数, 则式 (9) 可转化为

$$\hat{y}_k = \sum_{i=1}^5 v_i f\left(\sum_{n=1}^N w_{in} a_n - \theta_i\right) - \theta. \quad (11)$$

对于给定的学习样本 $\{\varphi_n(t), y_n\}$, $n = 1, 2, \dots, M$, 设 y_n 为对应于样本 $\varphi_n(t)$ 的模型期望输出值, \hat{y}_n 为相应的模型实际输出, 则模型的误差函数为

$$E = \frac{1}{2} \sum_{t=1}^M (\hat{y}_n - y_n)^2 = \frac{1}{2} \sum_{t=1}^M \left(\sum_{i=1}^5 v_i f\left(\sum_{n=1}^N w_{in} a_{nt} - \theta_i\right) - \theta - y_n \right)^2. \quad (12)$$

采用具有自适应学习速率以及为训练参数的调整加动量项的方法^[14]进行网络的训练, 以降低网络对误差曲面局部细节的敏感性.

5 基于信息熵的集成预测模型

针对针铁矿法沉铁过程 4# 反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度的预测问题, 基于改进差分进化算法参数优化的 LSSVM 工艺参数预测模型充分考虑了操作参数波动带来的铁离子浓度波动, 不至于出现较大的偏差. 但由于影响 Fe^{2+} 浓度和 Fe^{3+} 浓度的因素较多, 仅根据主要过程工况参数进行预测具有一定的片面性, 会影响预测模型的精度. 过程神经网络模型从沉铁过程具有时间连续性的角度出发, 具有较高的预测精度, 但是在操作参数波动严重的情况下误差较大, 因此需要对这两个模型进行有效集成.

集成模型中的权重因子通常根据专家知识或操作人员生产经验来确定, 由于沉铁过程工况参数具有不确定性, 过程工况容易出现较大波动, 为了提高权重因子的可靠性, 本文采用信息熵方法^[15]来确定加权

因子的取值。

利用改进LSSVM预测模型和过程神经网络预测模型可以获得 k 时刻4#反应器出口 Fe^{2+} 浓度(Fe^{3+} 浓度)的预估值 \hat{y}_{1k} 和 \hat{y}_{2k} ,集成预测模型的预估值为 \hat{y}_k ,则第 i 个预测模型在 k 时刻的相对误差为

$$e_{ik} = \begin{cases} |(y_k - \hat{y}_{ik})/y_k|, & 0 \leq |(y_k - \hat{y}_{ik})/y_k| < 1; \\ 1, & |(y_k - \hat{y}_{ik})/y_k| \geq 1. \end{cases} \quad (13)$$

其中 y_k 为 k 时刻铁离子浓度实际检测值.利用熵值法确定加权系数的步骤如下:

Step 1: 计算第 i 个单一预测模型在 k 时刻的预测相对误差的比重

$$p_{ik} = e_{ik} / \sum_{t=1}^n e_{it}. \quad (14)$$

Step 2: 计算第 i 个单一预测模型预测相对误差的熵值

$$E_i = -\frac{1}{\ln n} \sum_{t=1}^n p_{it} \ln p_{it}. \quad (15)$$

Step 3: 计算第 i 个单一预测模型预测相对误差序列的变异程度系数

$$d_i = 1 - E_i. \quad (16)$$

Step 4: 计算各单一预测模型加权系数

$$w_i = \frac{1}{m-1} \left(1 - d_i / \sum_{i=1}^m d_i \right). \quad (17)$$

通过上述步骤可得到4#反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度集成模型的加权因子。

6 基于实际运行数据的验证分析

为了对集成预测模型性能进行验证,取实际生产过程中经异常数据处理和归一化处理的600组数据,其中前415组数据作为学习样本,后185组数据作为测试样本。

改进LSSVM预测模型中基于密度聚类的小生境差分进化算法参数设置如下:变异算子 $F = 1.2$, $F_{\text{base}} = 0.6$;交叉算子 $\text{CR} = 0.35$, $\text{CR}_{\text{min}} = 0.2$, $\text{CR}_{\text{max}} = 0.8$;邻域半径 $\varepsilon = 0.1$;密度阈值 $\text{MinPts} = 3$;种群大小设为50.经过优化算法优化后, Fe^{2+} 浓度预测模型最优参数值为 $\sigma_1 = 2.34$, $\gamma_1 = 27.84$; Fe^{3+} 浓度最优参数值为 $\sigma_2 = 1.83$, $\gamma_2 = 36.32$.对于过程神经网络预测模型,选取4#反应器出口 Fe^{2+} 浓度(Fe^{3+} 浓度)历史检测数据构成时间序列,对该时间序列中连续6个数据进行拟合,构成一个时变函数作为过程神经网络的输入函数,以第7个数据作为相应的理想输出.设置参数如下:输入函数用Legendre正交基函数展开,学习速率的初始值为0.015,动量系数为0.85,误差精度为0.005,最大迭代次数为1500次,

隐层过程神经元的激励函数选对数 S 函数,输出层神经元激励函数选择线性函数.通过基于信息熵的权值计算, Fe^{2+} 浓度(Fe^{3+} 浓度)最优加权系数分别为 $w_1 = 0.523$, $w_2 = 0.477$ ($w_1 = 0.518$, $w_2 = 0.482$),按照 $\hat{y}_k = w_1 \hat{y}_{1k} + w_2 \hat{y}_{2k}$ 可以获得当前 k 时刻4#反应器出口 Fe^{2+} 浓度(Fe^{3+} 浓度)集成模型输出值. Fe^{2+} 浓度和 Fe^{3+} 浓度集成预测模型的预测效果如图4和图5所示。

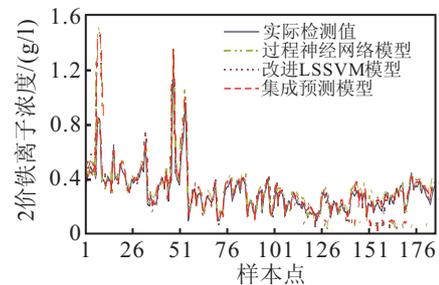


图4 Fe^{2+} 浓度的预测效果

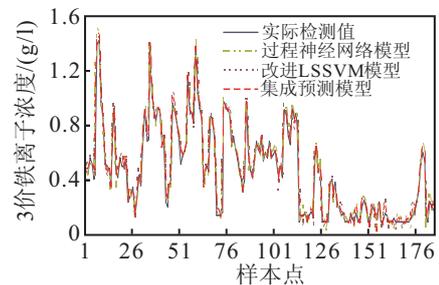


图5 Fe^{3+} 浓度的预测效果

为了对3个模型的预测效果和性能进行评价,采用如下MSE和MAPE指标:

$$\text{MSE} = \sqrt{\frac{1}{n} \sum_{k=1}^n \left(\frac{y_k - \hat{y}_{ik}}{y_k} \right)^2}, \quad (18)$$

$$\text{MAPE} = \frac{1}{n} \sum_{t=1}^n \left| \frac{y_k - \hat{y}_{ik}}{y_k} \right|. \quad (19)$$

其中: y_k 为 k 时刻 Fe^{2+} 浓度(Fe^{3+} 浓度)的实际检测值, \hat{y}_{ik} 为第 i 个模型在 k 时刻的 Fe^{2+} 浓度(Fe^{3+} 浓度)模型预测值. Fe^{2+} 浓度和 Fe^{3+} 浓度预测效果比较如表1和表2所示。

表1 Fe^{2+} 浓度预测效果对比

评价指标	改进LSSVM模型	过程神经网络模型	集成模型
MSE	0.1726	0.1625	0.1184
MAPE	0.1207	0.1269	0.0907

表2 Fe^{3+} 浓度预测效果对比

评价指标	改进LSSVM模型	过程神经网络模型	集成模型
MSE	0.2231	0.1994	0.1421
MAPE	0.1362	0.1262	0.0885

由图4,图5和集成预测模型的MSE和MAPE指标可知,得到的集成预测模型具有较高的预测精度。

与基于改进差分进化算法参数优化的LSSVM预测模型和过程神经网络预测模型相比, Fe^{2+} 浓度集成预测模型的MSE指标分别提高了0.0542%和0.0441%, MAPE指标分别提高了0.0300%和0.0362%; Fe^{3+} 浓度集成预测模型的MSE指标分别提高了0.0810%和0.0573%, MAPE指标分别提高了0.0477%和0.0377%, 均说明集成预测模型的预测精度和性能高于单一预测模型. 本文提出的集成预测模型的预测结果能够满足针铁矿法沉铁过程对铁离子浓度值的误差要求, 可以在生产现场进行实际应用.

7 结 论

本文针对某冶炼生产企业针铁矿法沉铁过程4#反应器出口 Fe^{2+} 浓度和 Fe^{3+} 浓度难以进行实时有效预测的问题, 根据与除铁有关的大量工况参数数据, 通过现场调研确定影响铁离子浓度的主要影响因素, 对相关生产过程数据进行预处理后, 分别建立了 Fe^{2+} 浓度和 Fe^{3+} 浓度的小生境差分进化算法-LSSVM预测模型和过程神经网络预测模型, 并通过信息熵方法对两个模型进行有效集成. 仿真分析表明, 集成预测模型具有良好的预测精度和鲁棒性, 能及时为生产操作提供参考, 其预测结果为指导氧量鼓入量的优化控制奠定了坚实的基础.

参考文献(References)

- [1] 杨大锦, 朱华山, 陈加希. 湿法提锌工艺与技术[M]. 北京: 冶金工业出版社, 2006: 59-60.
(Yang D J, Zhu H S, Chen J X. Zinc hydrometallurgy process and technology[M]. Beijing: Metallurgy Industry Press, 2006: 59-60.)
- [2] 邓永贵. 硫酸锌浸出液针铁矿法除铁研究[D]. 长沙: 中南大学化学化工学院, 2008: 1-10.
(Deng Y G. Research on goethite process for the removal of ferric or ferrous ions from the leaching solution of zinc in hydrometallurgy[D]. Changsha: School of Chemistry and Chemical Engineering, Central South University, 2008: 1-10.)
- [3] Xu J X, Hou Z S. Notes on data-driven system approaches[J]. Acta Automatica Sinica, 2009, 35(6): 668-675.
- [4] 桂卫华, 阳春华, 李勇刚, 等. 基于数据驱动的铜闪速熔炼过程操作模型优化及应用[J]. 自动化学报, 2009, 35(6): 717-724.
(Gui W H, Yang C H, Li Y G, et al. Data-driven operational-pattern optimization for copper flash smelting process[J]. Acta Automatica Sinica, 2009, 35(6): 717-724.)
- [5] 张英, 苏宏业, 褚建. 一种基于支持向量机增量学习的软测量建模方法[J]. 化工自动化及仪表, 2005, 32(3):

22-24.

- (Zhang Y, Su H Y, Chu J. Soft sensor modeling based on support vector machines incremental learning[J]. Control and Instruments in Chemical Industry, 2005, 32(3): 22-24.)
- [6] 王春林, 周昊, 周樟华, 等. 基于支持向量机的大型电厂锅炉飞灰含碳量建模[J]. 中国电机工程学报, 2005, 25(20): 72-76.
(Wang C L, Zhou H, Zhou Z H, et al. Support vector machine modeling on the unburned carbon in fly ash[J]. Proceedings of the CSEE, 2005, 25(20): 72-76.)
- [7] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers[J]. Neural Processing Letters, 1999, 9(3): 293-300.
- [8] 周开军, 阳春华, 牟学民, 等. 基于泡沫特征与LSSVM的浮选回收率预测[J]. 仪器仪表学报. 2009, 30(6): 1295-1300.
(Zhou K J, Yang C H, Mou X M, et al. Flotation recovery prediction based on froth features and LSSVM[J]. Chinese J of Scientific Instrument, 2009, 30(6): 1295-1300.)
- [9] 张春晓, 张涛. 基于最小二乘支持向量机和粒子群算法的两相流含油率软测量方法[J]. 中国电机工程学报, 2010, 30(2): 86-91.
(Zhang C X, Zhang T. Soft measurement method for oil holdup of two phase flow based on least squares support vector machine and particle swarm optimization[J]. Proc of the CSEE, 2010, 30(2): 86-91.)
- [10] 张晓平, 赵珺, 王伟, 等. 基于最小二乘支持向量机的焦炉煤气柜位预测模型及应用[J]. 控制与决策, 2010, 25(8): 1178-1183.
(Zhang X P, Zhao J, Wang W, et al. COG holder level prediction model based on least square support vector machine and its application[J]. Control and Decision, 2010, 25(8): 1178-1183.)
- [11] Storn R, Price K. Differential evolution: A simple and efficient adaptive scheme for global optimization over continuous spaces[Z]. Berkeley: International Computer Science Institute, 1995(3): 5-15.
- [12] 张航, 王伟, 郑玲, 等. 一种基于密度聚类的小生境差分进化算法[J]. 计算机工程与应用, 2008, 44(23): 42-45.
(Zhang H, Wang W, Zheng L, et al. Density clustering based niching differential evolution[J]. Computer Engineering and Applications, 2008, 44(23): 42-45.)
- [13] 何新贵, 梁久祯. 过程神经网络的若干理论问题[J]. 中国工程科学, 2000, 2(12): 40-44.
(He X G, Liang J Z. Some theoretical issues on procedure neural networks[J]. Engineering Science, 2000, 2(12): 40-44.)

(下转第342页)