选矿与原料预处理

基于 PSO 优化 T-S 模糊神经网络的磨矿粒度预测

黎芬芳，崔桂梅
（内蒙古科技大学 信息工程学院，内蒙古 包头 014010）

摘要：选矿厂二段磨矿粒度是影响精品矿位和回收率的关键因素。本文针对目前选矿厂无法对磨矿粒度进行实时检测的问题，结合二段磨矿过程，使用基于粒子群算法（PSO）优化 T-S 模糊神经网络的方法，建立二段磨矿粒度软测量模型；并采集选矿厂实际生产数据，进行模型对比试验。结果表明：PSO 优化 T-S 模糊神经网络的模型命中率为 94%，平均相对误差为 0.005 4，模型性能明显优于 T-S 模糊神经网络模型和 RBF 神经网络模型；优化模型能有效解决二段磨矿粒度与变量间的模糊性问题，且预测精度较高，满足选矿厂对二段磨矿粒度实时检测的要求。本文研究成果可为二段磨矿粒度软测量建模提供新策略。

关键词：球磨机；磨矿粒度；软测量模型；粒子群算法；T-S 模糊神经网络
中图分类号：TF3；TH113；TD453　　**文献标识码**：A　　**文章编号**：1000－8764（2022）04－0064－07
doi：10.13403/j.sjqt.2022.04.055

Grinding size prediction of optimization of T-S fuzzy neural network based on PSO

LI Fenfang，CUI Guimei
（*School of Information Engineering，Inner Mongolia University of Science and Technology，Baotou* 014010，*Inner Mongolia*，*China*）

Abstract：The two-stage grinding size in dressing work is a key factor affecting the iron concentrate grade and recovery rate. Aiming at the problem that the current dressing work cannot detect the grinding size in real time，combined with the two-stage grinding process，the method based on particle swarm optimization（PSO）is used to optimize the T-S fuzzy neural network，and a soft measurement model of two-stage grinding size is established；while the actual production data of the dressing work is collected，the model comparison tests is conducted. The results show that the model hit rate of the T-S fuzzy neural network optimized by PSO is 94%，the average relative error is 0.005 4，and the model performance is significantly better than the T-S fuzzy neural network model and the RBF neural network model；the optimization model can effectively solve the fuzzy problem between the particle size and variables of the two-stage grinding，and the prediction accuracy is high，which meets the requirements of the dressing work for the real-time detection of the size of the two-stage grinding. The research results can provide a new strategy for modeling the soft measurement of the size of the two-stage grinding.

Key words：ball mill；grinding size；soft measurement model；PSO；T-S fuzzy neural network

磨矿过程是选矿厂的重要工序，可为后续选别作业提供合格的磨矿粒度。磨矿粒度是检验磨矿产品的重要指标，影响后续选别作业的精矿品位和金属回收率，从而影响全厂的经济指标[1－2]。准确实时获取二段磨矿粒度值，是选矿厂进行磨矿过程优化控制、提高磨矿效率、保证磨矿产品质量的关键。在实际生产中，由于磨矿粒度检测仪造价高，后期维护费用昂贵，

收稿日期：2021－11－12；**修回日期**：2022－03－02
基金项目：国家自然科学基金资助项目（61763039）
作者简介：黎芬芳（1995—），女，硕士研究生，从事球磨机运行优化控制方面的研究。
通信作者：崔桂梅（1963—），女，教授，从事复杂过程建模及运行优化控制方面的研究。

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

现存的粒度检测仪器抗干扰能力差且精度低。目前大多数选矿厂仍然采用人工离线化验的方法对磨矿粒度进行检测[3]，此种检测方法的磨矿粒度具有大滞后性，在缺乏实时检测磨矿粒度的情况下实施闭环优化控制非常困难。软测量技术是使用一些可以测量的变量数据，用软件方法预测难以用传统仪表在线测量的参数和变量[4]。

近年来，许多学者对磨矿粒度的软测量技术进行了广泛研究，软测量建模方法一般有机理建模和数据建模。实际中，磨矿工业过程复杂，难以构建机理模型，且纯机理模型在生产中应用较少；近年来，数据建模方法在磨矿粒度软测量中得到了大量应用。数据建模方法是借助大量历史生产数据，选取与粒度相关性较大的变量建立二段磨矿粒度软测量模型。张晓东等[5]采用 RBF 神经网络实现磨矿粒度在线检测；丁进良等[6]利用遗传算法和神经网络相结合的方法建立了软测量模型；张燕等[7]利用自适应自然梯度法对高斯过程超参数优化，达到了构造磨矿粒度软测量模型的目的；杨刚等[8]提出了一种基于混沌粒子群改进果蝇算法优化 BP 神经网络，通过优化 BP 神经网络中的权值和阈值来构建磨矿粒度软测量模型。上述模型对磨矿粒度在线检测具备一定的指导意义，但是其并未考虑磨矿生产过程中的返砂量不可测量，且螺旋分级机电流无法准确表示返砂量，使其存在模糊性的问题，二段磨矿粒度软测量模型预测精度仍有待提高。

本文基于该问题，采用基于粒子群算法(Particle Swarm Optimization，PSO)优化 T-S(Takagi Sugeno)模糊神经网络的方法建立球磨机二段磨矿粒度的软测量模型。该算法利用 PSO 算法来弥补 T-S 模糊神经网络后件网络连接权值上的随机性缺陷，利用优化后的 T-S 模糊神经网络对磨矿粒度建立软测量模型，以解决返砂量与螺旋分级机电流间模糊性表示的问题。

1　二段磨矿工艺流程及问题描述

1.1　二段磨矿工艺流程

磨矿过程是破碎的下一道工序，也是选矿前一道重要的工序。某选矿厂二段磨矿工艺流程如图 1 所示。经过处理的矿石经过给料机和一定量的水进入 1#球磨机进行粗磨，经研磨后的矿浆进入螺旋分级机进行筛选，不合格的粗颗粒矿石返砂进入 1#球磨机重新研磨，符合标准的矿浆进入二段回路泵池中。往泵池中补入一定量的水，利用浆泵将矿浆抽入到水力旋流器中。水力旋流器通过离心作用对矿浆进行筛选，合格矿浆从溢流口排出，形成磨矿产品提供给后续选别作业，不合格矿浆送入 2#球磨机内再次研磨。磨矿过程中，二段磨矿粒度是整个磨矿分级作业的关键工艺指标，关系到磨矿作业的质量，直接影响下级浮选作业。

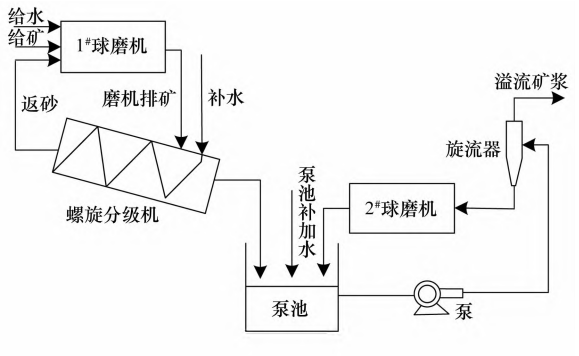


图 1　磨矿过程工艺流程

Fig. 1　Process flow of grinding process

在实际磨矿生产过程中，二段磨矿粒度是现场工作人员确定 1#球磨机给矿量和给水量的重要依据。然而磨矿工业生产工艺复杂，难以用粒度检测仪器在线实时监测二段磨矿产品粒度，工业现场二段磨矿产品粒度值一般由人工化验分析取得，该方法具有大滞后性，无法满足工业生产实时性的要求。

1.2　软测量问题描述

磨矿过程存在非线性、强耦合、时变性、不确定性等综合复杂特性[9]，使得其机理难以获得，多个变量无法直接检测。如：返砂量只能通过螺旋分级机电流以不确定的方式间接表示，且部分变量会受外界干扰因素的影响；磨矿粒度使采集到的变量间存在不准确性、模糊性[10]。磨矿运行优化过程控制对二段磨矿粒度软测量模型的实时性、准确性提出了严格要求。针对二级磨矿粒度与磨机入口给矿量、螺旋分

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

级机电流、旋流器电流等过程变量存在非线性和模糊性的问题，在总结操作人员和专家经验知识的基础上，本文采用 T-S 模糊神经网络的方法建立二段磨矿粒度软测量模型。

神经网络不适合于表达具有模糊性的知识，因此在对神经网络进行训练时，不能很好地利用已有经验知识[11]。而 T-S 模糊神经网络由模糊系统和神经网络相结合形成，模糊系统以模糊逻辑为基础，通过模仿人类思维的模糊综合判断推理来处理常规方法难以解决的模糊信息处理问题[12]，可以处理工厂数据中不确定性和灵活的规则以及结合专家知识进行建模[13-14]，而且弥补了神经网络输出表达式的抽象问题；另一方面神经网络补偿了模糊系统较差的自适应能力和鲁棒性[15]。但实际应用中，T-S 模糊神经网络常常采用随机初始化网络参数的方式。网络参数的取值对模型性能有着很大的影响，采用粒子群算法对 T-S 模糊神经网络模型的后件网络参数配置[16]，能使 T-S 模糊神经网络具有较强的学习能力。

2 PSO 优化 T-S 模糊神经网络算法

2.1 模型输入

本文采用数据建模的方式建立二段磨矿粒度软测量模型。样本的结构属性、模型及其参数的选择是软测量模型有效准确的前提。由图 1 可得出，磨机入口给矿量 x_1，磨机入口给水量 x_2，螺旋分级机溢流浓度 x_3，水力旋流器给矿流量 x_4 和泵池补加水量 x_5 是影响二段磨矿粒度的主要因素；另外，原矿可磨性、矿石粒度大小、螺旋分级机返砂量等因素都对二级矿浆粒度具有直接影响，这些因素很难通过测量得到，其影响只能通过 1# 球磨机电流 x_6、螺旋分级机电流 x_7 以及旋流器电流 x_8 近似表示。综上所述，x_1、x_2、x_3、x_4、x_5、x_6、x_7、x_8 为二段磨矿粒度软测量模型的输入，可以表示为如下非线性函数：

$$M_{200}=f(x_1,x_2,x_3,x_4,x_5,x_6,x_7,x_8) \tag{1}$$

式中：M_{200}为二级溢流矿浆中 -0.074 mm 矿石的质量分数；f 为非线性函数。

2.2 PSO 优化 T-S 模糊神经网络

PSO 算法由 Eberhart 和 Kennedy 在 1995 年提出[17]。在求解最优化问题的过程中，群体中粒子与最优粒子以及粒子之间的信息交互，引导整个群体中粒子在保留自身多样性信息的同时，向群体最优粒子收敛，通过不断更新粒子位置逐渐找到最优解[18]。

在 D 维搜索空间中初始化粒子的位置和速度，所有的粒子都由一个适应值来判断目前粒子位置的优劣，其中粒子的具体含义是 T-S 模糊神网络后件的网络权值，以 T-S 模糊模型预测值与实际值之间的差值作为 PSO 算法中的适应值。粒子的方向和距离由速度决定，速度主要根据自身运行经验以及群体其他粒子运行经验进行动态调整，通过跟踪个体最优值 pbest 和全局最优值 gbest 更新粒子位置[19-20]。设在一个 D 维搜索空间中有 n 个粒子，它们的数学表达式如下。

$$V_{ji}^{k+1}=\omega V_{ji}^{k}+c_1r_1(P_{ji}^{k}-X_{ji}^{k})+c_2r_2(G_i^{k}-X_{ji}^{k}) \tag{2}$$

$$X_{ji}^{k+1}=X_{ji}^{k}+V_{ji}^{k+1} \tag{3}$$

式中：$V_j=(V_{j1},V_{j2},\cdots,V_{ji})^{\mathrm{T}}$ 代表在 D 维搜索空间中第 j 个粒子当前的速度，($j=1,2,\cdots,n$; $i=1,2,\cdots,D$)；$X_j=(X_{j1},X_{j2},\cdots,X_{ji})^{\mathrm{T}}$ 为种群中第 j 个粒子在 D 维空间的位置，即 T-S 模糊神经网络后件网络权值种群；$P_j=(P_{j1},P_{j2},\cdots,P_{ji})^{\mathrm{T}}$ 为第 j 个粒子的个体最优值(pbest)，即 T-S 模糊神经网络后件权值的最优解；$G=(G_1,G_2,\cdots,G_i)^{\mathrm{T}}$ 代表种群的群体最优值(gbest)；k 为当前迭代次数；ω 为惯性权重；c_1 和 c_2 是加速度常数；r_1 和 r_2 是分布于[0,1]区间的随机数。将粒子位置和速度限制在一定的区间 $[-X_{\max},X_{\max}]$、$[-V_{\max},V_{\max}]$，防止其盲目搜索。

PSO 优化 T-S 模糊神经网络流程图如 2 所示。PSO 优化 T-S 模糊神经网络后件网络权值 $p_{ji}(k)$ 的步骤如下。

(1) 初始化：在 D 维搜索空间中随机产生粒子的位置与速度。

(2) 模型：建立 T-S 模型，根据输出误差

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

计算学习算法的后件权值，利用 T-S 模型训练误差作为粒子群的适应值。

(3) 更新：根据初始适应值确定个体极值 P_j 和全局最优解 P_g，然后更新粒子的速度和位置。

(4) 判断：判断粒子群的迭代次数是否达到最大值。如果为“是”，计算 T-S 模型的最佳参数；如果为“否”，回到第三步。

(5) 第二次判断：确定 T-S 模型的迭代是否已经达到最大值。如果为“是”，模型迭代结束；否则，回到第二步。

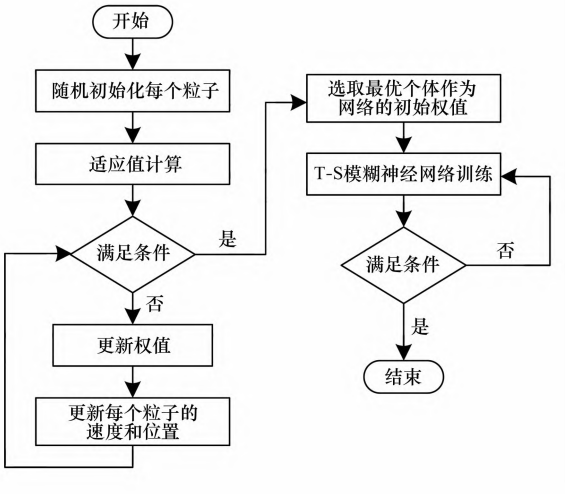


图 2　PSO 优化 T-S 模糊神经网络流程

Fig. 2　Flow of PSO optimizing T-S fuzzy neural network

设一个 MISO 系统输入向量 $x=[x_1,x_2,\cdots,x_D]^{\mathrm{T}}$，每个分量 x_i 均为模糊语言变量，并设 $A(x_i)=\{A_i^1,A_i^2,\cdots,A_i^m\}$ ($i=1,2,\cdots,D$; $j=1,2,\cdots,m$)。其中，A_i^j 是 x_i 的第 j 个语言变量值，它是定义在该论域 x_i 上的一个模糊集合，则 T-S模糊规则可用(4)式表示。

R_k: *if* x_1 *is* A_1^k *and* x_2 *is* A_2^k *and* $\cdots$ *and* x_D *is* A_D^k *then*

$$y_j=p_{j0}+p_{j1}x_1+\cdots+p_{ji}x_D \tag{4}$$

式中：R_k 为第 k 条规则，$k=1,2,\cdots,z$; $z\leqslant m^D$。

T-S 模糊神经网络的结构如图 3 所示[21-22]，该模型由前件网络和后件网络两部分组成，前件网络用于匹配模糊规则，后件网络用于产生模糊规则。

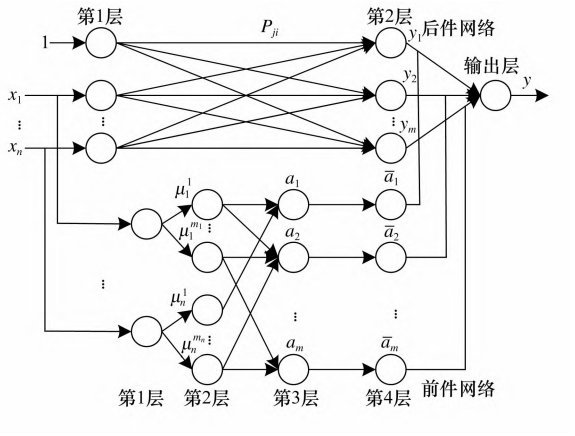


图 3　T-S 模糊神经网络结构

Fig. 3　The structure of the T-S fuzzy neural network

前件网络中：第 1 层为输入层，结点数为 $N_1=D$，D 为输入参数个数(8 个)；第 2 层为模糊化层，主要功能是对输入数据模糊化。其隶属度函数为高斯函数：

$$\mu_i^h(k)=\exp\left(-\frac{x_i(k)-c_{ij}(k)}{\delta_{ij}^2(k)}\right) \tag{5}$$

式中：$i=1,2,\cdots,D$; $j=1,2,\cdots,m$，m 为每个输入参数的模糊分割数：$c_{ij}(k)$ 和 $\delta_{ij}(k)$ 分别为 $\mu_i^j(k)$ 的中心和宽度。

第 3 层为模糊规则层，用于匹配模糊规则前件，计算出每条规则的适应度。节点函数：

$$\alpha_j(k)=\prod_{i=1}^{D}\mu_i^j(k) \tag{6}$$

结点数 $N_3=m$。第 4 层为归一化层，其公式如下。

$$\bar{\alpha}_j(k)=\frac{\alpha_j(k)}{\sum_{j=1}^{m}\alpha_j(k)} \tag{7}$$

后件网络中：第 1 层为输入层，第 0 个节点输入值 $x_0=1$，提供模糊规则后件中常数项。第 2 层共 m 个结点，计算每一条规则的后件，即

$$y_j(k)=\sum_{i=1}^{D}p_{ji}(k)\,x_i(k) \tag{8}$$

第 3 层为系统的输出，即

$$y(k)=\sum_{j=1}^{m}\bar{\alpha}_j(k)\,y_j(k) \tag{9}$$

2.3　模型性能指标

为了准确实现磨矿粒度实时在线检测，利

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

用平均相对误差[23]和模型命中率来对模型预测效果进行评价。磨矿粒度的检测误差范围为1%~2%，根据专家经验选取磨矿粒度 ±1% 的预测误差来计算模型预测精度，命中率计算如下。

$$J = \frac{1}{l}\sum_{i=1}^{l} H_i \times 100\% \tag{10}$$

$$H_i = \begin{cases} 1, \| \hat{y}_i^{(1)} - y_i^{(1)} \| < 1 \\ 0, \quad \text{其他} \end{cases} \tag{11}$$

式中：l 为预测样本长度；H_i 表示命中与否；$y_i^{(1)}$ 为实际值；$\hat{y}_i^{(1)}$ 是模型预测值。

平均相对误差 MRE 计算方法如下。

$$MRE = \frac{1}{n}\sum_{i=1}^{n} \frac{|\hat{y}(k) - y(k)|}{y(k)} \tag{12}$$

式中：n 为样本数；$y(k)$ 为实际值；$\hat{y}(k)$ 是模型预测值。

3 模型计算结果与分析

本文以某选矿厂现场采集的数据经过处理得到的 1 000 组数据建立二段磨矿粒度软测量模型，二段磨矿粒度时序分析如图 4 所示，其中 900 组数据做为模型的训练集，100 组做为模型的测试集。由于球磨机数据存在不同的量纲，本文采用了最大最小法对原数据进行归一化处理，将其映射到 [0,1]；同时，为了便于观察模型的输出，需要通过反归一化对归一化之后的数据进行还原。

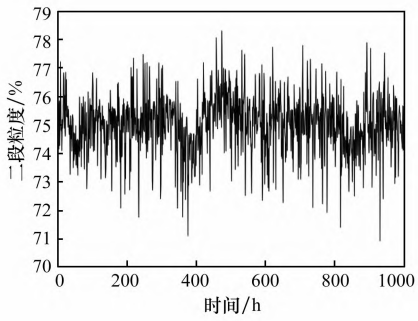
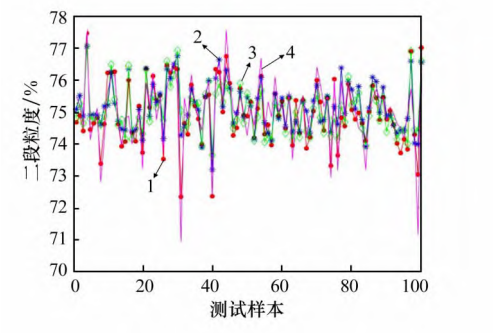


图 4 二段磨矿粒度时序图

Fig. 4 Time series diagram of secondary grinding grain size

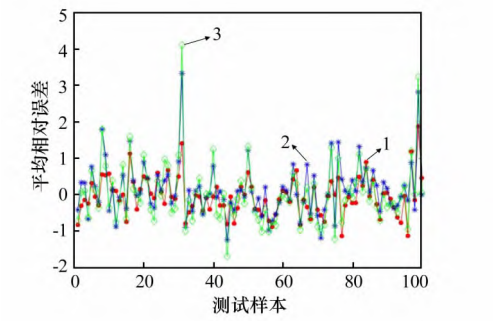
采用 PSO 优化 T-S 模糊神经网络、T-S 模糊神经网络、RBF 神经网络三种方法，分别对经处理后某选矿厂实际生产数据进行训练，各模型隐含层节点均为 12，3 种模型的预测结果如图 5 所示。由图 5 可知，PSO 优化 T-S 模糊神经网络跟踪实际磨矿粒度值效果明显优于其他两种方法。各模型误差如图 6 所示。由图 6 可知，PSO 优化 T-S 模糊神经网络误差曲线的波动明显小于其他两种模型。



1—PSO-T-S；2—T-S；3—RBF；4—真实值。

图 5 磨矿粒度预测仿真分析

Fig. 5 Simulation diagram of grinding particle size prediction



1—PSO-T-S；2—T-S；3—RBF。

图 6 3 种模型误差曲线

Fig. 6 Error curves of three models

模型性能指标如表 1 所示。由表 1 可知：3 种预测模型的平均相对误差都比较小，预测精度都比较好。由于螺旋分级机返砂量、原矿石可磨性等因素无法直接测量且难以准确表示，系统变量间具有不确定性和模糊性，RBF 神经网络无法很好处理具有模糊性的系统，而 T-S 模糊神经网络结合了神经网络和模糊逻辑系统两者的优点且具有较强的模糊推理能力，因此 T-S 模型比 RBF 模型准确性更高，但是 T-S 模糊神经网络在权值的选择上具有随机性，采用 PSO 算法对权值进行优化以弥补 T-S 参数随机性问题，使模型拥有更高的准确性。PSO 优化

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net

T-S 模糊神经网络的命中率达到 94%，平均相对误差为 0.54%。可见，PSO 优化 T-S 模糊神经网络的预测效果优于其他两种神经网络模型，能很好地跟踪实际磨矿粒度值的变化；因此 PSO 优化 T-S 模糊神经网络具有较好的预测结果。

表 1　各模型性能指标

Table 1　Performance indicators of each model

模型名称	模型命中率/%	平均相对误差
PSO 优化 T-S 模糊神经网络	94	0.005 4
T-S 模糊神经网络	89	0.006 7
RBF	84	0.007 9

4　结　论

本文以二段磨矿粒度为研究对象，针对磨矿过程中各变量的模糊性，采用 T-S 模糊神经网络建立磨矿粒度软测量模型，同时使用 PSO 算法优化 T-S 模糊神经网络的后件网络权值；利用实际生产数据进行仿真实验，T-S 模糊神经网络的模型命中率为 89%，平均相对误差为 0.006 7，模型性能优于 RBF 神经网络模型。经过 PSO 优化后的 T-S 模糊神经网络模型命中率为 94%，模型命中率在 3 种模型中最高，平均相对误差最小为 0.005 4。通过与 T-S 模糊神经网络、RBF 的预测结果对比，得出 PSO 优化 T-S模糊神经网络建立的二段磨矿粒度预测模型具有更高的准确性。本文研究结果可为选矿厂运行优化和节能提供强有力的理论支撑。

参考文献:

[1] WEI D, CRAIG I K. Grinding mill circuits: A survey of control and economic concerns [J]. International Journal of Mineral Processing, 2009, 90(1-4): 56-66.

[2] 代伟，柴天佑. 数据驱动的复杂磨矿过程运行优化控制方法[J]. 自动化学报，2014，40(9): 2005-2014.
DAI Wei, CHAI Tianyou. Data-driven optimal operational control of complex grinding processes [J]. Acta Automatica Sinica, 2014, 40(9): 2005-2014.

[3] 王新华，桂卫华，王雅琳，等. 混合核函数支持向量机的磨矿粒度预测模型[J]. 计算机工程与应用，2010，46(12): 207-209.
WANG Xinhua, GUI Weihua, WANG Yalin, et al. Prediction modeling for particle size of grinding circuit of mixturekernels SVM [J]. Computer Engineering and Applications, 2010, 46(12): 207-209.

[4] PING Z, CHAI T, HONG W. Intelligent optimal-setting control for grinding circuits of mineral processing process [J]. IEEE Transactions on Automation Science & Engineering, 2009, 6(4): 730-743.

[5] 张晓东，王伟，王小刚. 选矿过程神经网络粒度软测量方法的研究[J]. 控制理论与应用，2002(1): 85-88.
ZHANG Xiaodong, WANG Wei, WANG Xiaogang. Research of the particle size neural network soft sensor for concentration process [J]. Control Theory and Cations, 2002(1): 85-88.

[6] 丁进良，岳恒，齐玉涛，等. 基于遗传算法的磨矿粒度神经网络软测量[J]. 仪器仪表学报，2006，27(9): 981-984.
DING Jinling, YUE Heng, QI Yutao, et al. NN soft-sensor for particle size of grinding circuit based GA [J]. Chinese Journal of Scientific Instrument, 2006, 27(9): 981-984.

[7] 张燕，张佳，周颖，等. 基于自适应自然梯度法的高斯过程磨矿粒度软测量建模[J]. 北京工业大学学报，2016，42(8): 1153-1159.
ZHANG Yan, ZHANG Jia, ZHOU Ying, et al. Modeling of grinding particle size soft sensor based on the adaptive natural gradient method in the gauss process [J]. Journal of Beijing University of Technology, 2016, 42(8): 1153-1159.

[8] 杨刚，王建民. 基于 MFOA 优化 BP 神经网络的磨矿粒度软测量[J]. 矿业研究与开发，2018，38(2): 101-105.
YANG Gang, WANG Jianmin. Soft sensing of grinding size by optimized BP neural network based on MFOA [J]. Mining Research and Development, 2018, 38(2): 101-105.

[9] 赵珺，崔庆磊，刘颖，等. 基于多目标分层遗传模糊建模的磨矿过程溢流粒度软测量[J]. 控制与决策，2015，30(12): 2187-2192.
ZHAO Jun, CUI Qinglei, LIU Ying, et al. Multi-objective hierarchical genetic fuzzy modeling for soft-sensor of overflow particle size in grinding process [J]. Control and Decision, 2015, 30(12): 2187-2192.

[10] 张燕，代亚菲，陈玲玲，等. 基于改进的 FOA-LSSVM 磨矿粒度软测量模型[J]. 矿业研究与开发，2015(11): 97-103.
ZHANG Yan, DAI Yafeil, CHEN Lingling, et al. Soft-measuring Model for Grinding Size Based on the Improved FOA-LSSVM Model [J]. Mining Research and Development, 2015(11): 97-103.

[11] 孙增圻，徐红兵. 基于 T-S 模型的模糊神经网络[J]. 清华大学学报(自然科学版)，1997(3): 77-81.

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved.　http://www.cnki.net

SUN Zengqi, XU Hongbin. Fuzzy-neural network based on T-S model [J]. Journal of Tsinghua University, 1997(3): 77 – 81.

[12] 桂卫华,阳春华. 复杂有色冶金生产过程智能建模、控制与优化[M]. 北京:科学出版社,2010.
GUI Weihua, YANG Chunhua. Intelligent modeling, control and optimization of complex non-ferrous metallurgical production process [M]. Beijing: Science Press, 2010.

[13] ZHANG R, TAO J, GAO F. A New Approach of Takagi-Sugeno fuzzy modeling using an improved genetic algorithm optimization for oxygen content in a coke furnace [J]. Industrial & Engineering Chemistry Research, 2016, 55(22): 6465 – 6474.

[14] LIN Y Y, CHANG J Y, LIN C T. Identification and prediction of dynamic systems using an interactively recurrent self-evolving fuzzy neural network [J]. IEEE Transactions on Neural Networks & Learning Systems, 2013, 24(2): 310 – 321.

[15] HUANG X, HE L, ZHAO H, et al. Information gain-based modular fuzzy neural network to forecast rainstorm [J]. Water Science & Technology Water Supply, 2020, 21(6): 114 – 127.

[16] ZHANG S, JIANG H, YIN Y, et al. The prediction of the gas utilization ratio based on TS fuzzy neural network and particle swarm optimization [J]. Sensors, 2018, 18(2): 625.

[17] SGI W, LIU D, CHENG X, et al. Particle swarm optimization-based deep neural network for digital modulation recognition [J]. IEEE Access, 2019, 7(99): 104591 – 104600.

[18] 宋君,任廷志,王奎越,等. 基于CF-PSO-SVM的冷连轧非稳态工作辊弯辊模型优化[J]. 钢铁,2021,56(11):78 – 86.
SONG Jun, REN Ting, WANG Kui, et al. Optimization of work roll bending model in unsteady process of tandem cold rolling based on CF-PSO-SVM [J]. Iron and Steel, 2021, 56(11): 78 – 86.

[19] 尹学,李绍铭,闫成忍. 基于GA-PSO-BP神经网络的烧结终点预测模型[J]. 烧结球团,2020,45(6):35 – 39.
YIN Xue, LI Shaoming, YAN Chengren. Prediction model of BTP based on GA-PSO-BP neural network [J]. Sintering and Pelletizing, 2020, 45(6): 35 – 39.

[20] 徐雪玉,刘琼. 基于改进SVM的淘洗机选矿质量在线预测研究[J]. 烧结球团,2021,46(2):89 – 94.
XU Xueyu, LIU Qiong. Research on online prediction of washing machine beneficiation quality based on improved SVM [J]. Sintering and Pelletizing, 2021, 46(2): 89 – 94.

[21] 崔桂梅,李静,张勇,等. 基于T-S模糊神经网络模型的高炉铁水温度预测建模[J]. 钢铁,2013,48(11):11 – 15.
CUI Guimei, LI Jing, ZHANG Yong, et al. Prediction modeling study for blast furnace hot metal temperature based on T-S fuzzy neural network model [J]. Iron and Steel, 2013, 48(11): 11 – 15.

[22] AHN C K. Delay-dependent state estimation for T-S fuzzydelayed Hopfield neural networks [J]. Nonlinear Dynamics, 2010, 61(3): 483 – 489.

[23] RJH A, ABK B. Another look at measures of forecast accuracy-science direct [J]. International Journal of Forecasting, 2006, 22(4): 679 – 688.

(上接第57页)

[11] 张淑会,王宝勇,兰臣臣,等. 球团矿化学成分控制现状及展望[J]. 钢铁,2020,55(8):19 – 26.
ZHANG Shuhui, WANG Baoyong, LAN Chenchen, et al. Prospects and present status of pellets chemical composition control [J]. Iron and Steel, 2020, 55(8): 19 – 26.

[12] DWARAPUDI S, GHOSH T K, SHANKAR A, et al. Effect of pellet basicity and MgO content on the quality and microstructure of hematite pellets [J]. International Journal of Mineral Processing, 2011, 99: 43 – 53.

[13] 范建军,郭宇峰,臧龙,等. 碱度对细粒级铁矿粉球团性能的影响[J]. 钢铁研究学报,2019,31(5):440 – 445.
FAN Jianjun, GUO Yufeng, ZANG Long, et al. Effect of basicity on properties of pellets produced by ultra fine-sized iron concentrate [J]. Journal of Iron and Steel Research, 2019, 31(5): 440 – 445.

[14] ILJANA M, KEMPPAINEN A, PAANANEN T, et al. Effect of adding limestone on the metallurgical properties of iron ore pellets [J]. International Journal of Mineral Processing, 2015, 141: 34 – 43.

[15] 张元波,陈茜钧,苏子键,等. 碱度对高硅镁质球团矿质量影响的研究[J]. 烧结球团,2020,45(5):39 – 43.
ZHANG Yuanbo, CHEN Xijun, SU Zijian, et al. Research on effect of basicity on properties of high-silica magnesium pellets [J]. Sintering and Pelletizing, 2020, 45(5): 39 – 43.

[16] LU Jianguang, LAN Chenchen, LÜ Qing, et al. Effects of SiO_2 on the preparation and metallurgical properties of acid oxidized pellets [J]. International Journal of Minerals, Metallurgy and Materials, 2021, 28(4): 629 – 636.

(C)1994-2022 China Academic Journal Electronic Publishing House. All rights reserved. http://www.cnki.net