

选矿过程神经网络粒度软测量方法的研究*

张晓东¹ 王 伟² 王小刚³

(1 新松机器人自动化股份有限公司·沈阳,110015; 2.大连理工大学信息与控制研究中心·大连,116024;

3.东北大学自动化研究中心·沈阳,110006)

摘要: 结合选矿厂磨矿分级作业的实际工矿,提出了基于RBF网络的粒度软测量的设计方法.仿真和实际试验结果表明,该方法能够解决选矿生产中磨矿粒度因缺乏适当的检测设备而存在的难以进行在线检测的问题.

关键词: 选矿过程;神经网络;软测量

文献标识码: A

Research of the Particle Size Neural Network Soft Sensor for Concentration Process

ZHANG Xiaodong¹, WANG Wei² and WANG Xiaogang³

(1 Siasun Robot & Automation Co. Ltd. · Shenyang, 110015, P.R.China; 2 Dalian University of Technology · Dalian, 116024, P.R.China;

3. Research Center of Automation, Northeastern University · Shenyang, 110006, P.R.China)

Abstract: According to practical situation of concentration, a neural network soft sensor for grinding particle size is presented. Simulation and field test results show that this method can deal with the problem that grinding particle size can not be detected on line because of the absence of detection equipment.

Key words: concentration process; neural network; soft sensor

1 引言(Introduction)

磨矿作业的目的是将大颗粒矿石磨碎到一定粒度,使各种有用矿物与脉石分离,呈单体分离状态,以利于后续作业(浮选,浸出等)将有用矿物提取出来.磨矿粒度是选矿生产过程中磨矿作业的最重要的生产指标.但是在实际生产中,由于无法得到粒度的在线检测值,只能通过控制浓度来间接控制粒度.难以使磨矿粒度稳定在工艺指标的要求范围内.造成这种状况的原因主要是:1)目前的粒度分析仪检测周期长(通常为几分钟),其检测值只能对生产起监测指导作用,不能满足实时控制的要求.2)粒度分析仪价格昂贵,企业难以承受,只能通过人工采样,通过化验得到磨矿粒度的检测值.因此,应用软测量技术,实现粒度的在线检测具有重要的实际意义.

本文针对一个典型的磨矿分级作业流程,提出了一种基于RBF网络^[1]并考虑实际生产应用的磨矿粒度软测量方法.计算机仿真和现场试验结果表明了该方法能够解决磨矿粒度的在线检测与自动控制.

2 磨矿过程及其动态仿真(Grinding process and its dynamic simulation)

某金矿选厂磨矿作业是一个在我国选矿行业较为典型的磨矿分级过程,如图1所示.该流程由两段闭路磨矿组成.1[#]磨机与螺旋分级机组成一段磨矿,2[#]磨机与水力旋流器和给矿泵池构成二段磨矿.水力旋流器溢流矿浆粒度为整个磨矿作业的粒度指标,需要严格控制.

在选厂综合自动化系统投运以后,给矿量、水量、泵池液位、矿浆浓度、矿浆流量、压力等参数能够进行实时检测和有效控制.目前该磨矿作业的运行工况为:

1) 通过调节给矿量,能够克服扰动(矿石硬度、给矿粒度等)的影响,保持一段磨矿稳定、优化运行,使处理量保持最大.

2) 调节磨机进料端加水量以保持磨机的磨矿浓度恒定,提高磨矿效率.

3) 调节1[#]磨机出口加水量,控制螺旋分级机溢流浓度,能够根据矿石特性的改变进行两段磨矿负

* 基金项目:国家杰出青年科学基金(69825106)和高等学校骨干教师资助计划资助项目.

收稿日期:1999-08-10; 收修改稿日期:2000-10-16

荷的合理分配.

4) 调节给矿泵池补加水量, 控制旋流器给矿浓度.

5) 由于给矿泵池体积小, 通过设计合理的液位控制器, 调节渣浆泵速, 保持泵池液位相对稳定, 同时注意避免给矿体积流量的突变对旋流器分级过程产生的不良扰动.




图1 某金矿选矿厂磨矿作业流程图

Fig 1 Flow chart of grinding process at a gold mine concentration

建立一个如图1所示的磨矿作业动态特性的仿真系统. 该系统包括下面几个过程单元模型: 球磨机, 螺旋分级机, 给矿泵池, 水力旋流器. 球磨机可以用一个总体平衡动力学模型描述^[2], 泵池用一个完全的混合器模型表示, 水力旋流器模型采用 Lynch 和 Rao 方程^[3]表示, 螺旋分级机由于结构不同而表现出与水力旋流器不同的分级特性, 这里采用工业型螺旋分级机模型^[4].

由于一些执行机构的动态过程对磨矿作业的影响, 因此有必要将其加入到仿真系统中. 给矿机构由一个二阶系统加纯滞后环节来描述, 渣浆泵由一个二阶系统描述, 加水阀的特性可以由一阶惯性环节表示, 用纯滞后环节描述矿浆在管线中的传输过程.

3 神经网络粒度软测量 (Neural network soft sensor of particle size)

3.1 辅助变量的选择 (Choice of associated variables)

水力旋流器是一种典型的离心式分级机, 当矿浆以一定压力进入旋流器后, 在其内部离心力的作用下, 细粒级进入溢流, 粗粒级进入底流形成循环负荷. 由于矿浆在旋流器内部的停留时间非常短, 因此旋流器粒度分级过程的理论模型可以描述为:

$$M_{200} = \frac{\sum_{i=1}^{d_{75}} m_i (1 - R_f - E_i (1 - R_f))}{\sum_{j=1}^N m_j (1 - R_f - E_j (1 - R_f))} \quad (1)$$

其中 M_{200} 为溢流矿浆中—200 目 (75 μm) 的百分含量, d_{75} 为 75 μm 粒径, N 为矿浆的最大粒径, m_i 为第 i 粒级的质量, 由给矿粒度分布决定, R_f 为给矿

浆中未经分级直接进入旋流器底流的质量分数. 它是由旋流器水量分布决定的, 即与旋流器结构参数和给矿矿浆的水含量有关. E_i 为旋流器的分级效率. 研究表明, 它是由旋流器的结构参数和操作参数共同决定的.

在式(1)中, 给矿粒度分布 m_i 无法得到实时检测值, 而 R_f 和 E_i 与旋流器的结构量和操作变量之间表现为难以准确描述的复杂的非线性关系. 因此, 上述的旋流器分级过程的理论模型难以应用. 为此, 利用神经网络直接建立旋流器溢流粒度分布与旋流器的操作变量和结构参数的模型:

$$M_{200} = f(X). \quad (2)$$

其中 f 为一个由神经网络实现的非线性函数, 输入变量 X 为: x_1 : 给矿流量, x_2 : 给矿浓度, x_3 : 给矿压力, x_4 : 给矿粒度分布, x_5 : 旋流器的结构参数 (入料口直径、溢流口直径、沉砂口直径等); M_{200} 为粒度软测量的主导变量.

在输入分量中, x_1, x_2, x_3 能够得到实时的检测值, 旋流器的结构参数 x_5 在其工作过程中是随磨损而缓慢变化的, 因此, 在建立软测量模型的过程中可以将其作为常数, 其影响可以通过模型矫正来补偿. 给矿粒度分布 x_4 不能在线检测, 而其又是软测量模型不可缺少的信息. 引起 x_4 变化的主要因素是一段磨矿溢流粒度的改变. 螺旋分级机通常是一段磨矿的粒度分级设备, 如图1所示. 由螺旋分级机的分级原理可知, 其溢流矿浆浓度与溢流粒度之间具有如图2所示的对应关系.




图2 溢流浓度与分级粒度的关系

Fig. 2 Relation of overflow density and classified size

由此可知, 溢流浓度的改变能够反映溢流粒度的变化, 而螺旋分级机的溢流浓度是在线可测的, 因此可以将一段磨矿溢流浓度作为旋流器给矿粒度分布 x_4 的替代变量.

根据上述分析, 并结合软测量辅助变量的选择原则^[5], 确定旋流器给矿流量, 给矿浓度和一段磨矿溢流浓度作为粒度软测量的辅助变量 (泵池液位通过底流泵速 (旋流器给矿流量) 保持稳定, 相应地给

矿压力能够保持不变,故不选择给矿压力作为粒度软测量的辅助变量)。

3.2 神经网络建模(Neural network model)

神经网络软测量是以神经网络模型为核心,通过输入变量(即辅助变量)到输出变量(即主导变量)的非线性映射来实现非线性对象的软测量。神经网络建模可以采用不同的网络拓扑结构,目前广泛采用的是多层前向网络。由于径向基函数(RBF)网络的非线性映射效果比其它函数网络优越、网络学习简单快速,故这里采用 RBF 网络建立粒度软测量模型,如图 3 所示。




图 3 RBF网络粒度软测量结构图

Fig 3 Structure of RBF soft sensor

3.2.1 样本的选择(Choice of samples)

由于神经网络泛化能力有限,会造成样本空间以外的预估计值出现较大偏差,使软测量模型失效。因此,建立神经网络软测量模型要以一个全面的样本空间为基础。通常,选矿生产中处理矿量通常在一个有限的范围内变化,因此粒度软测量的样本应当在处理量的正常变化范围内选取,同时注意样本的代表性和分布的均匀性。

3.2.2 RBF 网络结构的确定(Structure of RBF)

RBF 神经元网络的结构即隐层节点数由基函数的中心数来确定,因此 RBF 网络基函数的中心值对其非线性映射能力具有重要作用。一般基函数中心采用聚类分析的方法确定,如 *K-Means* 方法、竞争学习方法等。而一种采用次胜者受罚的竞争学习方法(RPCL)^[6]能够克服常规聚类方法对于初始类数和位置的过于敏感,具有分配合适的数据中心数目的能力。其基本思想是不但获胜项修正以适应输入值,而其对次胜项采用惩罚的方法,使其远离输入值。

3.2.3 RBF 网络学习算法(Learning algorithm of RBF)

径向基函数 RBF 网络^[1]是一类前向网络,其拓扑结构如图 4 所示:




图 4 径向基函数RBF网络结构图

Fig 4 Structure of RBF

该网络完成如下非线性映射: $f_r(X) = W_0 +$

$\sum_{i=1}^{n_r} W_{0i} \phi(\|X - C_i\|)$, 其中, $X \in \mathbb{R}^n$ 是输入向量, $\phi(\cdot)$ 是一个 $\mathbb{R}^n \rightarrow \mathbb{R}$ 的函数, $\|\cdot\|$ 是欧氏范数, W_i 是权值, C_i 是 RBF 网络的数据中心, n_r 是中心数目。由于其输出节点是线性的,因此 RBF 网络学习算法可以采用收敛速度快的递推最小二乘学习算法。

4 仿真与试验结果(Simulation and test)

4.1 仿真结果(Simulation results)

利用磨矿过程动态仿真器(MPDS),在磨矿过程的稳态工作点上分别对给矿、矿石硬度、泵池补水施加有限带宽白噪声信号,得到 800 组输入输出数据,将其分成两组,分别作为训练数据和校验数据,取网络训练精度为 $\epsilon = 0.01$, 高斯形状参数为 $\alpha = 1$, 训练后得到的网络参数为:输入量 $n = 4$, 网络隐层结点 $n_r = 14$, 图 5 为训练后软测量模型对校验数据的估计结果。图中“——”为检验数据,“……”为软测量估计值。

4.2 试验结果(Test results)

在选厂磨矿作业稳定运行的状态下,对给矿、泵池给水施加连续阶跃信号,分别对旋流器给矿浓度、旋流器给矿流量、一段磨矿溢流浓度、溢流粒度 M_{200} 进行采样,采样周期为半分钟,连续采集 240 组数据,分为训练集和校验集,对网络进行训练和校验。图 6 为训练后的 RBF 网络软测量模型对校验数据的估计。图中,“ $\diamond$ ”为实际采样值,“——”为软测量模型的估计值。模型仿真和现场数据校验结果表明,本文提出的基于 RBF 网络的粒度软测量模型能够较好地跟踪旋流器给料的变化,得到溢流粒度的较为准确的预测值,具有较高的估计精度。




图5 网络模型对校验数据的估计

Fig. 5 NN model estimation to the verified data




图6 神经网络粒度软测量模型校验数据

Fig. 6 Verified data of NN size of soft sensor model

参考文献 (References)

- [1] Willis M J, Montague G A and Massimo C Di, et al. Artificial neural networks in process estimation and control [J]. Automatica, 1992, 28 (6): 1181 - 1187
- [2] Chen Bingchen. Mathematic Model of the Concentration [M]. Shenyang: Northeastern University Press, 1990 (in Chinese)
- [3] Rao T C. The characteristics of hydrocyclones and their application as control units in comminution circuits [D]. Australia: University of Queensland, 1996
- [4] Xie Hengxing. Research of mathematic model of industrial screw classifier [D]. Changsha: Central South University of Technology, 1988 (in Chinese)
- [5] Luo Rongfu and Shao Huohu. Research of associated variables choice in the reference control [A]. In Proc. of Control and Decision Conference of China [C], Shenyang, China, 1992 (in Chinese)
- [6] Xu Lei, Krzyzak A and Oja E. Rival penalized competitive learning for clustering analysis, RBF net, and curve detection [J]. IEEE Trans. on Neural Networks, 1993, 4(4): 636 - 649

本文作者简介

张晓东 1971年生, 2000年4月获东北大学博士学位, 主要研究方向为自适应控制, 过程控制等 Email: lotuszxd@263.net

王伟 1955年生, 大连理工大学教授, 博士生导师, 1990年至1992年在挪威科技大学从事博士后研究工作, 1998年至1999年为英国牛津大学访问学者, 主要研究方向为自适应控制, 预测控制, 过程控制等 Email: wangwei@dlut.edu.cn

王小刚 1960年生, 1991年获东北大学硕士学位, 现为东北大学自动化研究中心工程师, 主要研究方向为智能控制, 过程控制等