

文章编号:1000-582X(2010)03-124-05

# RBF神经网络与模糊理论相结合的 磨矿分级智能控制方法

王云峰<sup>1,2</sup>, 李战明<sup>1</sup>, 袁占亭<sup>1</sup>, 万维汉<sup>3</sup>

(1. 兰州理工大学 电气工程与信息工程学院, 甘肃 兰州 730050;

2. 甘肃政法学院 计算机科学学院, 甘肃 兰州 730070;

3. 金川集团自动化工程有限公司, 甘肃 金昌 737104)

**摘要:**将RBF神经网络和模糊理论结合起来,提出了一种基于RBF神经网络和模糊理论实现智能控制的方法。该方法能够有效克服磨矿效率和旋流器入口压力等波动引起的扰动,使磨矿浓度和溢流粒度的波动减小,为浮选过程产品品位改善及产量提高创造了有利条件,在技术上实现了优化磨矿分级过程。该分析过程相对简单,网络学习训练时间少,学习精度高,估计值与分析值拟合非常好。仿真表明这类智能控制器可用于难以建立数学模型的控制系統。

**关键词:**RBF神经网络;模糊理论;磨矿;分级系统;智能控制;优化

中图分类号:TD923

文献标志码:A

## Intelligent control of the grinding and classification system based on fuzzy RBF neural network

WANG Yun-feng<sup>1,2</sup>, LI Zhan-ming<sup>1</sup>, YUAN Zhan-ting<sup>1</sup>, WAN Wei-han<sup>3</sup>

(1. College of Electrical and Information Engineering, Lanzhou University of Technology, Lanzhou 730050, Gansu, P. R. China; 2. College of Computer Science Institute, Gansu Political Science and Law Institute, Lanzhou 730070, Gansu, P. R. China; 3. Jinchuan Group Ltd. Automation Engineering Ltd, Jinchang 737104, Gansu, P. R. China)

**Abstract:** Based on RBF neural network and fuzzy theory, an intelligent control method, which can effectively overcome disturbance resulting from grinding efficiency and cyclone's inlet pressure, is proposed. This method that can make grinding concentration and overflow particle size well-proportioned will allow us to improve flotation grade and increase yield, and therefore realize the optimization of grinding and classification process. The present method is of simple analysis, less time of network learning and training. And high learning precision is high. The simulations show that our approach can also be applied to the control systems that are difficult to build accurate math model.

**Key words:** RBF neural network; fuzzy theory; grinding; classification system; intelligent control; optimization

磨矿分级过程在选矿领域是关键作业之一,产品粒度和浓度直接影响着后续浮选作业,一直是选

矿自动化的重点监控对象<sup>[1-2]</sup>。国外学者从传统控制策略、现代控制策略和智能控制策略,论述了磨矿

收稿日期:2009-11-18

基金项目:国家“十一五”科技支撑计划项目(2006BAJ01A06-3)

作者简介:王云峰(1968-),男,兰州理工大学博士研究生,甘肃政法学院副教授,主要从事模式识别、智能控制、信息安全等研究,(Tel)13919338948,(E-mail)wangyf\_05@163.com。

分级控制策略的研究现状和未来的发展趋势<sup>[3]</sup>。指出未来磨矿过程控制策略的发展趋势,将是智能控制策略或复合控制策略(将各种控制策略相互渗透,如模糊智能控制、自适应模糊控制、模糊预测控制),达到根据实际情况调整生产参数,使磨矿生产过程保持在最佳状态。张守元等<sup>[4-5]</sup>在总结分析PID控制和模糊控制特性的基础上,以分级机溢流浓度控制为例,提出了在动态过程中对PID参数进行模糊整定的规则。由于磨矿过程的复杂性、随机性,因此生产的自动控制是非常必要的。磨矿过程的自动控制受磨矿数学模型、检测仪表及人员素质条件所制约,最初采用定值控制,后来发展为自适应控制,近年来研究者们采用专家系统、模糊逻辑控制,磨矿过程等自动控制方法后不仅可以提高磨机处理量,而且可稳定生产,降低消耗,减轻工人劳动<sup>[6-7]</sup>。为了进一步提高选矿技术指标,笔者采用了RBF神经网络与模糊理论相结合的方式,在技术上实现了优化磨矿产品粒度组成,减少矿物过磨,避免中矿返回所引起的上游选别作业环境恶化,从而使整个选别过程得到优化,使金属回收率得到了提高,精矿质量得到了改善。

## 1 RBF模糊神经网络的控制系统设计

磨矿分级选别过程属于多耦合、参数时变的非线性控制模型,故采用传统的RBF神经网络与先进的模糊控制技术组合形成自适应模糊控制方案实现。

磨矿分级控制主要集中在磨机装载量和磨矿浓度的控制。因此笔者拟采用1个五输入一输出三层BP神经网络NN1实现对磨矿的分级过程进行在线辨识,寻找出磨机功率的最优值,作为下一步控制的设定值。然后再设计1个五输入二输出的三层BP神经网络NN2来预测磨机运行状态,以新给矿量、后补加水、返砂量(以分级机轴功率表示)、水量的累计变化量及磨机功率的实测值为NN2的输入,输出为磨机功率的最优值。

与磨机有功功率有关的主要参数是装载量和磨矿浓度。因此,笔者设计了2个模糊神经网络FN1和FN2。FN1的输入分别为功率指数的最优值与其实测值的偏差 $e$ 、偏差变化量 $e_c$ 及由NN2所判断出的磨机运行区域 $e_Q$ 。输出为新给矿量 $u_Q$ 。FN2的输入分别为功率指数的最优值与其实测值的偏差、偏差变化量及由NN2所判断出的磨机运行区域 $e_k$ ,输出为后补加水 $u_k$ 。模糊推理的结果是输出PID比例放大系数 $K_p$ 、积分时间 $T_i$ 和微分时间 $T_d$

的修正,实现了PID控制的自调整作用。模型辨识结构如图1所示。




图1 模型辨识结构图

### 1.1 模糊神经网络输入输出量的模糊化处理及控制规则的提取

首先分别在球磨机、渣浆池和水力旋流器的入口和出口分别设立必须的检测点。

1)球磨机。入口参数:原矿给矿量,磨矿前给水,加球量;出口参数:排矿量,排矿给水量(磨矿后给水)。

2)渣浆池。入口参数:排矿量,排矿给水量(磨矿后给水),液位;出口参数:泵速(流量),浓度。

3)旋流器。入口参数:压力(流量),浓度;出口参数:粒度,浓度。

接着根据磨矿工艺环节特点,确定系统误差的上下限,从而做出误差的论域;其次给出误差的模糊量级,分为7级:正大(PB),正中(PM),正小(PS),零(ZO),负小(NS),负中(NM),负大(NB)。它们都是论域U上的模糊集,最后建立这些模糊集的隶属函数。对误差、误差变化率和控制量分别处理,构造3组模糊集,分别表示相应的模糊量化等级。

利用这些模糊语言变量将模糊神经网络FN1和FN2的输入分量: $e$ 、 $e_c$ 、 $e_Q$ 、 $e_k$ 及输出控制量 $u_Q$ 、 $u_k$ 用模糊集合来表示,构成模糊集合如下。

$$E_c = \{NB, NM, NS, Z, PS, PM, PB\},$$

$$E_Q = \{NB, Z, PB\},$$

$$E_k = \{NB, Z, PB\},$$

$$U_Q = \{NB, NM, NS, NZ, PZ, PS, PM, PB\},$$

$$U_k = \{NB, NM, NS, NZ, PZ, PS, PM, PB\}.$$

控制规则是模糊控制器的核心,其形式为“IF... THEN...”。以阀门控制为例:

“如果流量略多(PS),如果流量变化正向略快(PS),则略关(NS)阀门”;

“如果流量略多(PS),如果流量变化正向过快(PM),则多关(NM)阀门”;

“如果流量略多(PS),如果流量变化负向过快(NM),则多开(PM)阀门”;

“如果流量太多(PB),如果流量变化正向略快

(PS),则多关(NM)阀门”。

控制规则的数量取决于矩阵的行列数目。相同规则合并后,部分无效规则可以剔除,每一条控制构造都是一条模糊条件语句,所有功能恰好是一组多重复合模糊蕴涵。

## 1.2 RBF 模糊神经网络的结构

RBF 模糊神经网络是由神经网络结构实现模糊控制的算法,其结构如图 2 所示。该网络由输入层、模糊化层、模糊推理层及输出层构成。




图 2 模糊神经网络结构图

输入层的各个节点直接与输入接,将输入量传到下一层。对该层的每个节点  $i$  输出表示为

$$u(i) = X = [x_1, x_2, \dots, x_n]。$$

模糊化层的每个节点代表一个语言变量值,用于计算属于各语言变量值模糊集合的各输入分量的隶属函数。若采用高斯型函数作为隶属函数, $c_{ij}$  和  $b_{ij}$  分别是第  $i$  个输入变量的第  $j$  个模糊集合的隶属函数的均值和标准差。

$$d(i, j) = \exp\left\{-\frac{(f_1(i) - c_{ij})^2}{(b_{ij})^2}\right\}$$

$$(i = 1, 2, \dots, n; j = 1, 2, \dots, m)。$$

由于磨机工作过程干扰太大,稳定性要求太高, $b_{ij}$  因取较大值,所以  $b_{ij}(E) = 1.6, b_{ij}(E_c) = 1.8, b_{ij}(E_Q) = 1.4, b_{ij}(E_k) = 1.4, b_{ij}(U_Q) = 1.6, b_{ij}(U_k) = 1.6$ 。

模糊推理层通过与模糊化层的连接来完成模糊规则的匹配,每个节点之间实现模糊运算,即通过各个节点的组合得到每个规则适用度。每个节点  $j$  的输出为该节点所有输入信号的乘积,即

$$d(j) = \min\{d(1, i_1), d(2, i_2), \dots, d(n, i_n)\},$$

$$i_1 \in \{1, 2, \dots, m_1\}, i_2 \in \{1, 2, \dots, m_2\}, \dots,$$

$$i_n \in \{1, 2, \dots, m_n\},$$

$$j = 1, 2, \dots, m, m = \prod_{i=1}^n m_i。$$

实现归一化处理

$$\overline{d(j)} = \frac{d(j)}{\sum_{i=1}^m d(i)} (j = 1, 2, \dots, m),$$

神经网络输出层的输出为各个规则的加权和,加权系数为各个模糊规则经归一化的适用度。

$$y(i) = \sum_{j=1}^m \omega(i, j) \overline{d(j)},$$

式中: $\omega(i, j)$  为输出层结点和第 3 层结点的连接权值。

## 1.3 模糊神经网络的学习算法

在各个输入分量的模糊分割数确定后,神经网络需要学习的参数主要是连接权值  $\omega(i, j)$  和隶属函数的  $c_{ij}$  和  $b_{ij}$ 。设误差代价函数为

$$E = \frac{1}{2} \sum_{i=1}^r (y_{di} - y_i)^2,$$

式中: $y_{di}$  和  $y_i$  分别表示期望输出和实际输出。则  $\omega(i, j)$ 、 $c_{ij}$  和  $b_{ij}$  的学习算法为

$$\partial \omega(k+1) = \partial \omega(k) - \beta \frac{\partial E}{\partial \omega(k)} =$$

$$\omega(k) + \beta (y_{di} - y_i) \overline{d(j)} x_i,$$

$$c_{ij}(k+1) = c_{ij}(k) - \beta \frac{\partial E}{\partial c_{ij}},$$

$$b_{ij}(k+1) = b_{ij}(k) - \beta \frac{\partial E}{\partial b_{ij}}。$$

## 1.4 智能控制系统结构

闭路磨矿分级过程由磨机、砂泵池和水力旋流器 3 部分组成。对于整个选矿过程,精矿质量和金属回收率的好坏很大程度上取决于磨矿产品的质量。如果磨矿产品的细度不够,矿物粒子间不能达到充分分解,会降低浮选指标。而如果过磨就会产生矿泥,不能对矿物进行充分回收。采用智能控制系统,在磨矿分级工业实时控制中,利用参数反馈在线修正规则的模糊控制器,第 1 段磨矿采用球磨机、自磨机或棒磨机进行粗磨,第 2 段采用球磨机或砾磨机与分级机组成闭路进行细磨。第 1 段磨机给矿量由磨机负荷控制系统自动调整,使磨机功率稳定在它的峰值附近工作。第 2 段磨机负荷控制系统,通过改变第 1 段排矿(即第 2 段给矿)的矿量和粒度,使第 2 段磨机功率稳定在它的峰值附近运行。第 1 段排矿变化会使本段磨机负荷改变,这个扰动由第 1 段磨机负荷控制系统进行校正。这样,使 2 段磨机功率均处在峰值附近工作。磨矿浓度根据磨机总给矿量与总给水量为定比值关系计算补充给水量进行前馈控制。第 2 段分级机溢流粒度或浓度,通过改变分级机给水量,实现定值控制。

采用 PLC 实现上述测控系统的主控机,完成原矿量、后水量、前水量、磨机功率、磨机音量、磨矿浓度、旋流器给矿浓度、泵池液位 8 个模拟量的检测,并对变频器以及 2 个电动调节阀等模拟量进行输出

控制。同时完成皮带电机工作、皮带电机停止、变频故障、电机故障等开关量信号的输入与输出。考虑多系统并行处理,采用国际先进的集散控制方案(DCS)。上位机采用工业控制机完成数据集中管理任务,PLC 作为下位机,完成独立系统的分散控制功能,数据传输通过高可靠的工业网络实现。管理层的工作站选用台湾最新工控机,配置了工业以太网卡、西门子通讯网卡,预装 WINCC5.5、STEP7 5.0 及各种通用软件和通讯软件,构建了如图 3 所示磨矿分级流程,由 5 个控制回路组成:1)根据第 1 段磨机负荷自动控制第一段磨机给矿回路,实现第 1 段磨机负荷定值控制,使磨机高效运行;控制回路包括负荷传感器  $S_1$  及其变送器  $S'_1 T_1 (S'_1 = 2S_1)$ 、控制器  $C_1$  和给矿执行机构  $A_1$  等。2)第 1 段磨机浓度前馈控制回路,目的是稳定磨矿浓度,它包括原矿计量秤  $W$  及其变送器  $WT$ 、控制器  $C_4$ 、执行机构  $A_4$  及其调节阀  $V_3$  等。3)第 2 段旋流器溢流浓度或粒度控制回路,实现磨矿品味粒度定值控制,它包括浓度计  $D$  及其变送器  $DT$ 、控制器  $C_2$ 、执行机构  $A_2$  及调节阀  $V_1$  等。4)根据第 2 段磨机负荷控制第 1 段两个分级机给水回路,以改变第一段返砂量,其溢流导致第 2 段返砂变化,使第 2 段磨机负荷稳定在要求的工作点上。控制回路有 2 个,分别包括负荷传感器  $S_2$  及其相应变送器  $S'_2 T_2 (S'_2 = \frac{1}{2} S_2)$ 、控制器  $C_3$ 、 $C'_3$  和给矿执行机构  $A_3$ 、 $A'_3$  及调节阀  $V_2$ 、 $V'_2$  等。

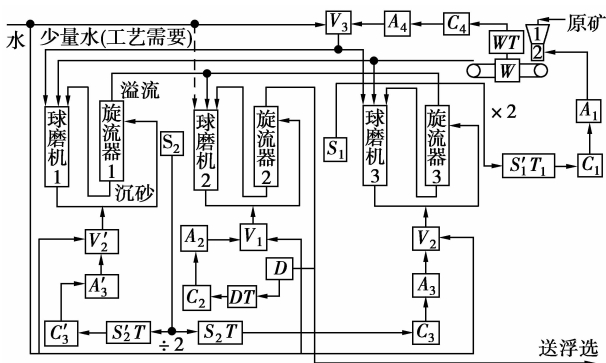


图 3 2 段磨矿分级流程框图

## 2 仿真研究

一般的工业控制对象都是一阶或者二阶系统。仿真是针对式(4)所示的二阶对象而进行的:

$$G(s) = \frac{K_p}{(T_1 s + 1)(T_2 s + 1)} e^{-T_d s}, \quad (4)$$

式中:  $T_1 = 180 \text{ s}$ ;  $T_2 = 120 \text{ s}$ ;  $K_p = 8$ ;  $T_d = 150 \text{ s}$ 。

在仿真过程中,模糊 RBF 神经网络的输入信号为 2 个,即控制系统的误差信号及 RBF 网络的辨识信号,针对每个输入取 5 个模糊集进行模糊化,即  $n=2, N=5$ ,模糊 RBF 神经网络结构取 2-5-5-3 的形式,网络学习参数取  $\beta=0.20, d=0.02$ ,网络的初始权值及隶属函数参数初值通过试验得到。RBF 辨识网络的结构取为 3-6-1。

通过与目前最广泛使用的 PID 控制相比较,选定相同的给矿量设定值、扰动信号,分别对系统加以 2 种控制。可以看出运用 RBF 神经网络与模糊理论相结合技术后,控制效果得到了明显的改善。与一般的 PID 控制相比响应特性对比如表 1 所示。为了验证其鲁棒性,在第 300 个采样时间时控制器输出加 0.1 的干扰,系统的抗干扰指标如表 2 所示,由表 1、2 数据可知,笔者设计的模糊神经网络控制的过渡时间明显减少,稳态偏差和超调量较传统 PID 方法有明显的改善,通过加干扰可以看出其鲁棒性很强。

表 1 模糊神经网络控制与 PID 控制性能指标数据表

性能指标	上升时间 $t_r/s$	调整时间 $t_s/s$	峰值时间 $t_p/s$	最大超调量 $m_p$	静态误差
PID 控制响应	0.5	1.6	0.8	0.15	0
模糊控制响应	0.2	1.5	0.3	0.12	0

表 2 模糊神经网络控制与 PID 控制抗干扰性能指标数据表

性能指标	调整时间 $t_s/s$	峰值时间 $t_p/s$	最大超调量 $m_p$	静态误差
PID 控制响应	1.1	0.4	0.04	0
模糊控制响应	0.4	0.1	0.02	0

通过对磨矿浓度和溢流粒度质量指标的跟踪对比,从图 4、5 可以看出运用 RBF 神经网络与模糊理论相结合技术后,控制效果得到了明显的改善。




图 4 旋流器溢流粒度控制效果跟踪对比




图5 磨矿浓度控制效果跟踪对比

### 3 结 语

对于选矿过程磨矿分级系统,采用RBF神经网络与模糊理论相结合技术后,能够有效地克服磨矿效率和旋流器入口压力等波动引起的扰动,通过RBF神经网络的训练,得到了矿石在进入浮选前达到的一个最佳的颗粒尺寸,减少过磨或欠磨给浮选过程的产品质量带来的影响,在基于RBF神经网络与模糊理论的智能控制系统下,水力旋流器的溢流粒度分布得到了改善,提高了矿石产品的回收率,降低了能耗,增加了磨矿处理量,并且使磨矿浓度和溢流粒度的波动减小。与原有的常规控制相比,该控制系统的控制质量明显提高,大大改善了磨矿分级的分级效果,为浮选过程产品品位改善及产量提高创造了有利条件。

#### 参考文献:

- [1] MENDEZ D A, GALVEZ E D, CISTERNAS L A. Cisternas Modeling of grinding and classification circuits as applied to the design of flotation processes[J]. Computers & Chemical Engineering, 2009,33(1):97-111.
- [2] 黄开国,陈万雄,彭先淦,等.一种低品位镍矿石的浮选工艺[J].中国有色金属学报,1999,9(3):601-605.  
HUANG KAI-GUO, CHEN WAN-XIONG, PENG XIAN-GAN, et al. A flotation technique for low-grade nickel ore [J]. The Chinese Journal of Nonferrous Metals, 1999,9(3):601-605.
- [3] GONZALEZ G D, MIRANDA D, CASALI A, et al. Detection and identification of ore grindability in a semiautogenous grinding circuit model using wavelet transform variances of measured variables [J]. International Journal of Mineral Processing, 2008, 89(1):53-59.
- [4] CHOI T J, SUBRAHMANYA N, LI H, et al. Generalized practical models of cylindrical plunge grinding processes [J]. International Journal of Machine Tools and Manufacture, 2008,48(1):61-72.
- [5] 王会清,张守元.预测模糊控制在磨矿分级过程的应用研究[J].矿冶工程,2002,22(3):60-62.  
WANG HUI-QING, ZHANG SHOU-YUAN. Application of predictive fuzzy control in grinding and classification [J]. Mining and Metallurgical Engineering, 2002,22(3):60-62.
- [6] 汪若尘,陈龙,江浩斌,等.半主动悬架模糊动态建模与神经网络控制[J].江苏大学学报:自然科学版,2009,30(1):23-26.  
WANG RUO-CEHN, CHEN LONG, JIANG HAO-BIN, et al. Fuzzy dynamic model and neural network control of semi-active suspension[J]. Journal of Jiangsu University: Natural Science Edition, 2009, 30 (1): 23-26.
- [7] ZHANG R X, HUANG G B, SUNDARAJAN N, et al. Improved GAP-RBF network for classification problems [J]. Neurocomputing, 2007, 70 (16): 3011-3018.
- [8] AGUIRRE L A, ALVES G B, CORREA M A. Steady-state performance constraints for dynamical models based on RBF networks [J]. Engineering Applications of Artificial Intelligence, 2007, 20 (7): 924-935.
- [9] 冯冬青,马书磊,陈铁军,等.一类时变非线性系统的参数反馈模糊控制器分析与设计[J].信息与控制,2002,31(4):310-314.  
FENG DONG-QING, MA SHU-LEI, CHEN TIE-JUN, et al. Analysis and design of fuzzy controller with parameter feedback for a kind of nonlinear time varying system [J]. Information and Control, 2002, 31(4): 310-314.
- [10] BEHOUNRK L. On the difference between traditional and deductive fuzzy logic[J]. Fuzzy Sets and Systems, 2008,159(10):1153-1164.
- [11] CIRIC M, IGNJATOVIC J, BOGDANOVIC S. Fuzzy equivalence relations and their equivalence classes[J]. Fuzzy Sets and Systems, 2007,158(12):1295-1313.
- [12] 刘建书,邹建华,万百五,等.基于神经网络质量模型的磨矿过程智能控制[J].有色金属,2004,56(1):310-314.  
LIU JIAN-SHU, ZOU JIAN-HUA, WAN BAI-WU, et al. Intelligent control of grinding process based on neural network quality model[J]. Nonferrous Metals, 2004,56(1): 310-314.
- [13] KENNEDY J, EBERHART R. Particle swarm optimization [M]. Perth, Australia: [s. n.], 1995: 1942-1948.
- [14] ZHANG J, MORRIS A. Fuzzy neural networks for nonlinear systems modeling [J]. Control Theory and Application, 1995, 142(6): 551-561.
- [15] HASEGAWA T, HORIKAWA S I, FURUHASHI T, et al. On design of adaptive fuzzy controller using fuzzy neural networks and a description of its dynamical behavior [J]. Fussy Sets and Systems, 1995, 71(1): 3-23.

(编辑 王维朗)