

多变量系统的模糊神经网络控制模型及其应用

彭小奇 梅 炽 周子民 唐 英

(中南工业大学应用物理与热能工程系·长沙, 410083)

摘要: 本文综合模糊控制系统与人工神经网络的优点, 提出了一种多变量系统的模糊神经网络控制模型并给出了其建模方法, 该方法适合于多变量系统的建模及其模糊控制器的设计. 笔者以此方法建立了渣贫化电炉生产过程的模糊神经网络控制模型并开发出相应的决策支持系统, 该系统自 1992 年 6 月投入生产现场使用以来, 一直稳定可靠地正常运行, 取得了令人满意的效果和显著的经济和社会效益.

关键词: 多变量系统; 模糊神经网络; 贫化电炉

1 引言

非线性多变量系统的建模与控制一直是控制领域的研究难点之一, 至今尚未形成系统的、完整的理论. 由于模糊模型本质上是一种非线性模型, 适合于表达非线性系统的动态特性, 因此模糊控制已逐渐成为解决非线性多变量系统控制问题的有效手段之一, 模糊控制理论及应用的研究也成为控制界的研究热点之一.

人工神经网络的研究近年来取得了突破性进展, 为非线性多变量系统的控制提供了新的手段. 由于神经网络具有并行机制、学习记忆能力及自组织和自适应能力, 从而得到了控制界的广泛关注并取得了一些进展^[1].

由于在建立模糊控制模型和设计模糊控制器时, 需要对被控对象有较深入详细的了解, 采集大量输入输出数据进行适当处理, 以便得到较好的模糊控制规则, 而这一工作通常是较为繁琐和困难的. 当建模用的有效数据量少于结论参数量时, 将无法建立相应的模糊控制模型^[2]. 为克服这一缺点, 本文将神经网络理论与模糊控制理论相结合, 提出了一种多变量系统的模糊神经网络控制模型并给出了其建模方法, 利用神经网络具有的学习能力, 通过使用适当数量的具有充分激励信息的优选数据组作为学习样本对神经网络进行训练, 从而建立起系统的模糊神经网络控制模型.

2 多变量系统的模糊控制模型

设系统有 r 个输入 $x_i (i = 1, 2, \dots, r)$ 和 q 个输出 $y_j (j = 1, 2, \dots, q)$, 则 k 时刻任意输入量 $x_i(k)$ 的模糊控制模型推导如下.

对 x_i 的任何一条模糊控制规则 R^l , 按参考文献[3]有:

R^l : If $x_1(k-1)$ 是 A_1^l , $x_1(k-2)$ 是 A_1^l , $\dots$, $x_1(k-n)$ 是 A_1^l , $\dots$,
 $x_r(k-1)$ 是 A_r^l , $x_r(k-2)$ 是 A_r^l , $\dots$, $x_r(k-n)$ 是 A_r^l ,

$y_1(k-1)$ 是 B_1^{l1} , $y_1(k-2)$ 是 B_1^{l2} , ..., $y_1(k-m)$ 是 B_1^{lm} , ...,
 $y_q(k-1)$ 是 B_q^{l1} , $y_q(k-2)$ 是 B_q^{l2} , ..., $y_q(k-m)$ 是 B_q^{lm} .

Then
$$\begin{aligned} x_i^l(k) = & a_0^l + a_{i1}^l \cdot x_1(k-1) + a_{i2}^l \cdot x_1(k-2) + \cdots + a_{in}^l \cdot x_1(k-n) + \cdots \\ & + a_{r1}^l \cdot x_r(k-1) + a_{r2}^l \cdot x_r(k-2) + \cdots + a_{rn}^l \cdot x_r(k-n) \\ & + b_{i1}^l \cdot y_1(k-1) + b_{i2}^l \cdot y_1(k-2) + \cdots + b_{im}^l \cdot y_1(k-m) + \cdots \\ & + b_{q1}^l \cdot y_q(k-1) + b_{q2}^l \cdot y_q(k-2) + \cdots + b_{qm}^l \cdot y_q(k-m). \end{aligned} \tag{1}$$

R^l 表示第 l 条控制规则 ($l = 1, 2, \cdots, L; L$ 为控制规则总数); $A_i^{l1 \sim n}$, $B_j^{l1 \sim m}$ 是在输入、输出论域上适当定义的模糊子集; $x_i^l(k)$ 是由第 l 条规则确定的 k 时刻的第 i 个输入控制量; $a_0^l, a_{i1}^l \sim a_{in}^l$, $b_{j1}^l \sim b_{jm}^l$ 为待定的结论参数; n, m 分别为模型的输入、输出阶数.

令
$$\theta_e = [a_0^l \ a_{i1}^l \ a_{i2}^l \ \cdots \ a_{in}^l \ \cdots \ a_{r1}^l \ a_{r2}^l \ \cdots \ a_{rn}^l \ b_{i1}^l \ b_{i2}^l \ \cdots \ b_{im}^l \ \cdots \ b_{q1}^l \ b_{q2}^l \ \cdots \ b_{qm}^l]^T, \tag{2}$$

$$\varphi = [1 \ x_1(k-1) \ \cdots \ x_1(k-n) \ \cdots \ x_r(k-1) \ \cdots \ x_r(k-n) \ y_1(k-1) \ \cdots \ y_1(k-m) \ \cdots \ y_q(k-1) \ \cdots \ y_q(k-m)]^T. \tag{3}$$

则(1)式可改写为:

$$x_i^l(k) = \theta_e^T \cdot \varphi. \tag{4}$$

若模糊控制模型共有 L 条规则, 则对给定的一组输入输出数据 φ , 输入控制量 $x_i(k)$ 为

$$\begin{aligned} x_i(k) &= \frac{\sum_{l=1}^L \lambda_l \cdot x_i^l(k)}{\sum_{l=1}^L \lambda_l} \\ &= \frac{\sum_{l=1}^L \lambda_l \cdot \theta_e^T \cdot \varphi}{\sum_{l=1}^L \lambda_l}. \end{aligned} \tag{5}$$

加权系数 λ_l 为:

$$\begin{aligned} \lambda_l &= \prod_{i=1}^r \prod_{j=1}^n \mu_{A_i^{lj}}[x_i(k-j)] \\ &\quad \wedge \prod_{i=1}^q \prod_{j=1}^m \mu_{B_i^{lj}}[y_i(k-j)]. \end{aligned} \tag{6}$$

“ $\prod$ ”和“ $\wedge$ ”表示进行模糊逻辑与运算, 即取极小运算; $\mu_{A_i^{lj}}[x_i(k-j)]$ 表示 $x_i(k-j)$ 对模糊子集 A_i^{lj} 的隶属




图 1 多变量系统的模糊神经网络控制模型

函数值, $\mu_{B_i}^{ij}[y_i(k-j)]$ 的意义与之类似.

(5) 式即为输入量 x_i 的模糊控制模型.

3 模糊神经网络建模方法

若能确定(5)式中的 θ_i , 则模糊控制模型随之建立. 当建模用样本数多于模糊模型中待定结论参数量时, 可利用文献[2]给出的算法求取 θ_i , 但该算法不适用于建模样本数较少的情况. 为此, 根据(2), (3), (5), (6)式构造图1所示的模糊神经网络, 利用神经网络的学习能力来确定 θ_i . 图中的 $\sum$ 、 $\times$ 、 $\wedge$ 、 μ 、 $\div$ 分别表示相应神经元完成求和、求积、取极小、求隶属函数值及除法运算.

神经网络的学习算法推导如下:

将(5)式展开得:

$$\begin{aligned} x_i(k) &= \frac{1}{\sum_{l=1}^L \lambda_l} [\lambda_1 \theta_1^T \varphi + \lambda_2 \theta_2^T \varphi + \cdots + \lambda_L \theta_L^T \varphi] \\ &= \frac{1}{\sum_{l=1}^L \lambda_l} [\lambda_1 \lambda_2 \cdots \lambda_L] [\theta_1^T \theta_2^T \cdots \theta_L^T]^T \varphi. \end{aligned} \quad (7)$$

$$\text{令 } \Theta = [\theta_1^T \theta_2^T \cdots \theta_L^T]^T. \quad (8)$$

则 Θ 为

$$\Theta = \begin{bmatrix} a_0^1 & a_{11}^1 & \cdots & a_{1n}^1 & \cdots & a_{r1}^1 & \cdots & a_{rn}^1 & b_{11}^1 & \cdots & b_{1m}^1 & \cdots & b_{q1}^1 & \cdots & b_{qm}^1 \\ a_0^2 & a_{11}^2 & \cdots & a_{1n}^2 & \cdots & a_{r1}^2 & \cdots & a_{rn}^2 & b_{11}^2 & \cdots & b_{1m}^2 & \cdots & b_{q1}^2 & \cdots & b_{qm}^2 \\ \vdots & \vdots & \cdots & \vdots & \cdots & \vdots & \cdots & \vdots & \vdots & \cdots & \vdots & \cdots & \vdots & \cdots & \vdots \\ a_0^L & a_{11}^L & \cdots & a_{1n}^L & \cdots & a_{r1}^L & \cdots & a_{rn}^L & b_{11}^L & \cdots & b_{1m}^L & \cdots & b_{q1}^L & \cdots & b_{qm}^L \end{bmatrix}. \quad (9)$$

$$\text{令代价函数 } J \text{ 为 } J = \frac{1}{2} [\hat{x}_i(k) - x_i(k)]^2 \quad (10)$$

$\hat{x}_i(k)$ 为学习样本中的实际输入控制量, $x_i(k)$ 为神经网络输出的控制量, 学习目标是使 $x_i(k)$ 尽量逼近 $\hat{x}_i(k)$, 亦即使 $J \rightarrow \min$.

根据一阶梯度算法有:

$$\frac{\partial J}{\partial a_0^l} = \frac{\partial J}{\partial x_i(k)} \cdot \frac{\partial x_i(k)}{\partial a_0^l} = - [\hat{x}_i(k) - x_i(k)] \cdot \frac{\lambda_l}{\sum_{l=1}^L \lambda_l}, \quad (11)$$

$$\frac{\partial J}{\partial a_{i'v}^l} = \frac{\partial J}{\partial x_i(k)} \cdot \frac{\partial x_i(k)}{\partial a_{i'v}^l} = - [\hat{x}_i(k) - x_i(k)] \cdot \frac{\lambda_l}{\sum_{l=1}^L \lambda_l} \cdot x_i(k - i'), \quad (12)$$

$$\frac{\partial J}{\partial b_{jj'}^l} = \frac{\partial J}{\partial x_i(k)} \cdot \frac{\partial x_i(k)}{\partial b_{jj'}^l} = - [\hat{x}_i(k) - x_i(k)] \cdot \frac{\lambda_l}{\sum_{l=1}^L \lambda_l} \cdot y_j(k - j'). \quad (13)$$

其中, $i' = 1, 2, \cdots, n$; $j' = 1, 2, \cdots, m$.

$$\text{令 } \Delta x_i(k) = \hat{x}_i(k) - x_i(k), \quad (14)$$

$$\lambda = [\lambda_1 \lambda_2 \cdots \lambda_L]^T. \quad (15)$$

由(11), (12), (13)式可得:

$$\Theta = \Theta_0 + \Delta\Theta = \Theta_0 + \frac{\eta \cdot \Delta x_i(k)}{\sum_{i=1}^L \lambda_i} \cdot \lambda \cdot \varphi^T. \quad (16)$$

其中, η 为学习速率, Θ_0 为 Θ 的初值.

(16) 式即为网络权重学习算法, 同时可将其视作模糊控制模型中结论参数的辨识算法.

若从建模对象的实际输入输出数据中抽取与较好的系统性能指标相对应的数据组作为学习样本对神经网络进行训练, 则训练结束后所得模型为优化控制模型, 由神经网络产生的输入控制量为优化控制量.

显然, 图 1 所示网络可依据训练结果全部用硬件构成, 直接以其作系统的模糊控制器, 使之与被控对象构成模糊神经网络控制系统.

需要指出, 为降低网络的复杂性, 提高学习速度, 构造图 1 所示网络前, 应参考现场实际操作控制经验对建模对象进行分析并利用结构辨识方法初步确定 n 和 m , 再用相关分析法剔除作用较弱的输入和输出变量, 最后根据分析结果确定图 1 所示网络的结构.

4 实际应用

4.1 现场概况

某冶炼厂熔炼车间有两台额定功率均为 5000kVA 的渣贫化电炉, 用于贫化由吹炼转炉产出的转炉渣, 从中提取钴、镍等贵金属. 若忽略生产过程中基本不变及变化缓慢的因素, 则可将其视作图 2 所示的多变量系统. 转炉渣中的镍、钴为电炉提取冶金的对象; 硫化剂通常为镍焙砂或其他硫化矿物, 用于破坏转炉渣中的磁铁矿物并生成钴钨; 焦粉用作还原剂破坏磁铁矿物并还原有价金属; 石英石用作熔剂起造渣和调控渣型的作用. 入炉物料通电熔炼后产出钴钨和贫化电炉渣, 钴钨送下一道工序处理, 含少量镍、钴的贫化渣被废弃.




图 2 渣贫化电炉

贫化电炉生产过程分化料期和贫化期两个阶段. 因化料期熔化物料需耗大量电能, 故在此期间应加大电极电流以提高电能输入量; 贫化期因物料已熔化, 需电量较少, 故应降低电极电流以节约电能. 化料期和贫化期电极电流的大小及其持续时间的长短对生产性能指标有较大影响.

衡量贫化电炉生产状况的指标主要有“贫化电炉渣含钴”、“贫化电炉渣含镍”及“吨转炉渣耗电量”三项, 这三项指标值越低, 贵金属资源利用率越高, 单位产品能耗越低, 经济效益越显著. 降低这三项指标值的主要途径是先根据入炉转炉渣量及其成分确定硫化剂、石英石和焦粉的最佳入炉量, 再根据入炉物料量确定化料期、贫化期的电极电流及其持续时间, 最后根据上述结果确定钴钨及贫化渣的放出量.

例如, 入炉石英石量过少, 则电炉耗电量降低, 但造渣用石英石量不足, 渣型不良, 钨渣分离条件恶化, 贵金属随渣损失量增大; 随着入炉石英石量的增加, 电炉耗电量增大, 钨

渣分离条件好转,贵金属随渣损失量减少;若入炉石英石量过大,则电炉耗电量显著增加,渣型不良,贵金属损失量增大.其他各量对生产指标也存在类似影响,因此有必要对有关各量进行优化决策和控制.

冶金过程的决策和控制通常基于冶金过程的物料平衡和热平衡计算,其前提是计算前必须知道有关信息的输入输出量及其成分和物相组成、炉体结构和有关热工参数等.但生产现场检测仪表不全,检测数据的误差和滞后性较大,难以对有关数据进行实时准确测量,因此难以应用物料平衡与热平衡算法实现过程的实时决策与控制.另外,平衡算法本质上是一种静态算法,难以适应动态的生产过程^[4],因此实际生产决策和控制主要依靠生产人员的经验.当生产操作控制人员技术水平较高、生产经验较丰富时,相应的生产指标也较好.笔者便是选取与较好生产指标相应的实际生产数据作为学习样本来建立渣贫化电炉生产过程的模糊神经网络控制模型.

4.2 渣贫化电炉模糊神经网络控制模型

因笔者以“贫化电炉渣含钴”、“贫化电炉渣含镍”、“吨转炉渣耗电量”为优化目标从实际生产数据中获取的建模样本数较少,故选用模糊神经网络控制模型对系统建模.以入炉石英石量为例,其建模过程如下.

在对熔炼过程进行机理分析的基础上,通过对实际生产数据进行相关性分析得:

$$\begin{aligned} x_3(k) = F[x_1(k), x_1(k-1), x_2(k), x_2(k-1), x_3(k-1), \\ x_5(k-1), y_1(k-1), y_2(k-1)]. \end{aligned} \quad (17)$$

即 $x_3(k)$ 与入炉焦粉量无关.

根据(17)式建立(1)式所示的模糊控制规则,此后即可利用前述方法建立入炉石英石量的模糊神经网络控制模型.

建模过程中遇到的主要问题是学习算法的收敛速度和判定学习结果是否为全局最优.为加快学习速度,对学习速率 η 进行模糊调节,当学习误差较大时,选用较大的 η 以加快收敛速度;当学习误差较小时,减少 η 以提高网络的逼近精度.采用这种方法后,网络的学习速度显著加快.因无法判断学习结果是否全局最优,故直接采用实践检验,将所得网络模型对生产过程进行实时仿真,若仿真结果良好,则认为所得模型为优化模型.

4.3 应用效果

笔者利用本文所述方法建立了前述渣贫化电炉的模糊神经网络控制模型并以此为基础开发出渣贫化电炉生产过程决策支持系统.该系统自1992年6月投入生产现场使用至今,运行状态良好并于1993年4月通过专家鉴定.因本系统从实际生产过程出发,通过优化配料量及化料期电极电流及其持续时间来减少电能损失,优化渣型及贫化期电极电流和持续时间来改善钨渣分离条件以降低钴、镍随渣损失,故取得了良好效果.1992年下半年与1991年同期生产指标的比较结果如下:

1) 吨转炉渣耗电量平均降低182kWh,比原指标降低39.6%.1992年两台贫化电炉共处理转炉渣 6.0×10^4 吨,故:

$$\text{年节电量} = 182 \times 6.0 \times 10^4 = 1.092 \times 10^7 \text{ kWh.}$$

2) 渣含钴平均降低 0.022%, 比原指标降低 23.7%。因 1992 年实际产出贫化渣 8.32×10^4 吨, 后续工序钴的回收率为 44.5%, 氧化钴市价为 30 万元/吨, 氧化钴中钴的重量百分含量为 78.5%, 后续工序加工费及其他成本为 17 万元/吨氧化钴, 故:

$$\text{年创效益} = 0.022\% \times 8.32 \times 10^4 \times 44.5\% \div 78.5\% \times (30 - 17) = 135 \text{ 万元.}$$

3) 渣含镍平均降低 0.043%, 比原指标降低 61.4%。因后续工序镍回收率为 94%, 电镍市价为 5 万元/吨, 后续工序加工费及其他成本为 2.8 万元/吨镍, 故

$$\text{年创效益} = 0.043\% \times 8.32 \times 10^4 \times 94\% \times (5 - 2.8) = 74 \text{ 万元.}$$

5 结 论

1° 本文结合模糊控制与人工神经网络的优点提出的多变量系统模糊神经网络控制模型及其建模方法适用于线性和非线性多变量系统的模糊建模, 故在工业过程的决策与控制中有较大的实用价值。

2° 用本文方法建立的渣贫化电炉模糊神经网络控制模型经实践证明能产生优化的生产控制决策, 有效地指导生产操作, 改进生产性能指标, 显著降低单位产品能耗和镍、钴的随渣损失量, 提高贵金属资源利用率, 从而获得显著的经济和社会效益。

参 考 文 献

- [1] Bavarian, B.. Special Section on Neural Networks for System and Control. IEEE Contr Syst, 1988, 8(2): 3-31; 1989, 9(3): 25-29; 1990, 10(3): 3-87
- [2] 彭小奇, 梅炽等. 多变量模糊控制模型辨识方法及其在矿热电炉决策支持系统中的应用. 控制理论与应用, 1994, 10(5): 582-587
- [3] Tomohiro Takagi & Michio Sugeno. Fuzzy Identification of Systems and Its Application to Modelling and Control. IEEE Trans. Syst Man & Cybern, 1985, 15(2): 116-132
- [4] 彭小奇, 梅炽等. 炼镍矿热电炉配料控制的动态模糊优化算法. 中国有色金属学报, 1994, 4(1): 96-100

A Fuzzy Neural Networks Control Model of Multivariable Systems and Its Application

PENG Xiaoqi, MEI Chi, ZHOU Jiemin and TANG Ying

(Department of Applied Physics and Thermal Engineering, Central South University of Technology · Changsha, 410083, PRC)

Abstract: This paper presents a fuzzy neural networks control model of multivariable systems as well as modelling method. This method is suited for modelling multivariable systems and designing fuzzy neural networks controller. A fuzzy control model of electric furnace for cleaning slag has been built with this method. A decision support system based on the model has been designed and put into operation since June 1992 and satisfactory results have been obtained.

Key words: multivariable systems; fuzzy neural networks; electric furnace for cleaning slag

本文作者简介

彭小奇 1962 年生, 硕士, 副教授. 1983 年毕业于重庆大学自动化系, 后分配到西南自动化研究所工作. 1986 年入哈尔滨工业大学控制工程系攻读硕士学位, 1988 年毕业后到中南工业大学任教. 曾获部级科技进步二等奖. 当前主要研究领域为有色冶金生产过程建模与优化控制和生产过程智能决策支持系统, 感兴趣的领域为模糊神经网络与智能控制.

梅 焜 1934 年生, 博士生导师. 1956 年毕业于中南矿冶学院冶金系, 现任中南工业大学副校长, 多次获得国家和省部级科技成果奖. 当前主要研究领域为冶金热工设备数学模拟与全息仿真、冶金炉窑优化控制.

周子民 1948 年生, 博士, 教授. 1981 年毕业于中南矿冶学院冶金系, 1985 获硕士学位, 1990 年获有色冶金学博士学位. 当前主要研究领域为工业电炉电、热场数学仿真与建模, 有色冶金生产过程优化控制.

唐 英 1962 年生, 硕士, 讲师. 1983 年毕业于华东师范大学物理系, 后分配到川北教育学院任教, 1985 年入华东师范大学物理系攻读硕士学位, 1988 年毕业后任教于中南工业大学. 当前主要研究领域为冶金过程自动检测技术.

Newly Approved Events

Title	Date	Place	Deadline	Further Information
IMEKO/IFAC Congress	June	Tampere	*	Prof. O. Aumala, TTKK/MIT
New Measurements-	2-6	Finland		POB 692, SF33101 Tampere
Challenges and Visions	1997			Finland FAX+358/3131/3162171
IFAC Symposium (3rd)	June	Annecy	1 Sept.	Prof. L. Foulloy, LAMII/
Intelligent Components	9-11	France	1996	CESALP, BP 806
& Instruments f. Control	1997			F-74016 Annecy, France FAX+33/50666020 e-mail: foulloy@univ-savoie. fr
Applications-SICICA'97				
IFAC Symposium	June	Budapest	30 Sept.	Ms. Cs. Banyasz, Computer &
Robust Control Design	25-27	Hungary	1996	Automation Res. Inst., POB 63
	1997			H-1518 Budapest, Hungary FAX+361/1667503 e-mail: h10kev@huella. bitnet
IFAC(CIGRE)Symp.	August	Beijing	31 May	Chinese Association of Autom.
Control of Power Plants	18-21	China, P. R.	1996	POB 2728, Beijing 100080
and Power Systems	1997			China, P. R. FAX+861/2545229
IFAC Symposium	August	Hull	30 Sept.	Prof. R. Patton, Dept. of El. Eng
Fault Detection, Super-	25-28	UK	1996	Hull Univ., Hull HU6 7RX, UK
vision & Safety for	1997			FAX+44/482/466664 e-mail;
Technical Processes				
SAFEPROCESS '97				r. j. patton@e-eng. hull. ac. uk