

文章编号: 1001-0920(2011)09-1417-04

## 电熔镁炉熔炼过程的智能设定值控制

吴志伟<sup>1</sup>, 柴天佑<sup>1</sup>, 付俊<sup>1</sup>, 闫占伟<sup>2</sup>

(1. 东北大学 流程工业综合自动化教育部重点实验室, 沈阳 110819; 2. 成都理工大学 工程技术学院, 四川 乐山 614000)

**摘要:** 电极电流值和极心圆直径是电熔镁砂生产过程中影响产品性能指标的两个重要参数, 在传统工艺中由人工设定. 由于生产过程中存在很多复杂特性, 人工给定的设定值很难保证其准确性. 针对这种情况, 提出了基于案例推理、迭代学习、PI控制、神经网络和规则推理的参数混合智能设定方法. 该方法成功应用于国内某电熔镁砂厂, 应用效果表明了所提出方法的有效性.

**关键词:** 电熔镁炉; 电极电流设定值; 极心圆直径设定值; 智能算法

**中图分类号:** TP273

**文献标识码:** A

## Intelligent setpoints control of smelting process of fused magnesium furnace

WU Zhi-wei<sup>1</sup>, CHAI Tian-you<sup>1</sup>, FU Jun<sup>1</sup>, YAN Zhan-wei<sup>2</sup>

(1. Key Laboratory of Integrated Automation for Process Industry of Ministry of Education, Northeastern University, Shenyang 110819, China; 2. The Engineering and Technical College, Chengdu University of Technology, Leshan 614000, China. Correspondent: WU Zhi-wei, E-mail: wuzhiwei\_2006@163.com)

**Abstract:** For the production of fused magnesia, electrodes currents and electrode circle diameter are two important parameters, which are high-related with the technical indices. As there are many complex characteristics in the production process, the setpoints of the two parameters provided by manual operations are often inappropriate, which often can degrade desired control accuracies. Therefore, the hybrid intelligent setting method is proposed by integrating the case-based reasoning(CBR), iterative learning control(ILC), PI control, neural network(NN) and rule based-reasoning(RBR). The applications to the melting magnesia factory in China show the effectiveness of the proposed method.

**Key words:** fused magnesium furnace; setpoints for electrodes currents; setpoints for electrode circle diameters; intelligent algorithm

### 1 引言

在实际工业过程的控制中, 控制系统的设计除了要满足被控量跟踪系统设定值外, 还要求产品的性能指标满足期望值要求. 以往的研究多假定可以获得理想的设定值, 进而研究如何提高闭环反馈控制的效果, 但忽略了偏离理想设定值时反馈控制不能使整个系统获得良好的运行效果这一问题<sup>[1]</sup>.

电熔镁砂是许多工业行业的重要原料和耐火材料, 主要熔炼设备为三相交流电熔镁炉. 熔炼过程主要是通过调整三相电极位置来控制电极电流进而保证熔炼过程稳定, 整个熔炼过程电能消耗极大. 在以节能降耗为目的的背景下, 熔炼过程运行控制的目标

是在保证产品产量的前提下, 尽量降低产品单吨能耗. 单吨能耗难以在线测量, 与电极电流值和极心圆直径关系密切, 它们之间的动态特性往往具有强耦合、非线性、难以用精确机理模型描述、随工况运行条件变化而变化的综合复杂特性. 现有生产方式下, 电极电流设定值和极心圆直径设定值还只能靠操作员凭经验人工给定, 当生产边界条件发生变化时操作员往往很难及时准确地调整上述两个设定值, 甚至给出错误的设定值, 导致产品的性能指标达不到要求, 造成能量的浪费.

自20世纪末开始, 部分学者针对电熔镁炉进行了研究. 文献[2-3]在理想条件下通过理论推导得出

收稿日期: 2010-06-28; 修回日期: 2010-12-17.

基金项目: 国家重点基础研究发展计划项目(2009CB320601); 国家自然科学基金项目(61020106003, 61004009).

作者简介: 吴志伟(1982—), 男, 博士生, 从事复杂工业过程的运行控制研究; 柴天佑(1947—), 男, 教授, 博士生导师, 中国工程院院士, 从事流程工业综合自动化理论、方法与技术等研究.

相关工艺参数的确定方法,但其仅为理论推导,且不能根据变化的熔炼工况在线调整这些工艺参数.文献[4]针对电极电流的控制问题提出了一种基于规则推理的控制方法,但没有涉及如何针对产品性能指标确定合理的电流设定值.

本文结合工业现场实际情况利用智能控制算法,分别提出了电极电流和极心圆直径的混合智能设定方法.本文提出的方法被成功应用于国内某电熔镁砂厂,可获得满足产品性能指标的设定值,应用效果表明了所提出方法的有效性.

## 2 基于智能算法的参数设定方法

### 2.1 电极电流值的设定

复杂工业过程的运行控制可分为两个部分:回路设定层和底层控制回路<sup>[5]</sup>.回路设定层根据控制目标确定底层控制回路的设定值;底层控制回路控制被控对象,使输出跟踪设定值.基于以上思想,本文提出了一种电熔镁炉电流智能控制策略,如图1所示.本文的重点在于回路设定层的设计.

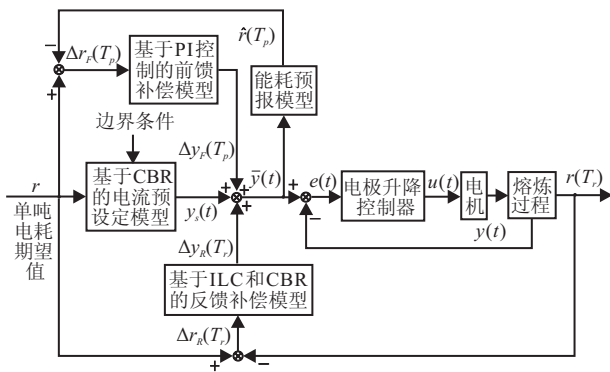


图1 电流智能控制系统结构图

控制系统包括由电流预设模型、能耗预报模型、前馈补充和反馈补偿模型组成的回路设定层和由电极升降控制器、电机构成的底层控制回路.

1) 基于案例推理的电流预设模型. 电流预设模型根据性能指标的期望值和边界条件产生控制回路的预设值  $y_s(t)$ . 本文将案例推理技术<sup>[6]</sup>与人工经验相结合得到由案例产生、案例检索、案例重用、案例修正和存储组成的电流预设模型.

①案例产生: 根据人工经验总结初始案例, 案例描述由性能指标  $r$  和边界条件  $B_i (i = 1, 2, \dots, 9)$  组成. 案例解为电流预设值  $y_s(t)$ . 案例构成如表1所示.

表1 电流预设模型的案例结构

案例描述	案例解
$r \ B_1 \ B_2 \ B_3 \ B_4 \ B_5 \ B_6 \ B_7 \ B_8 \ B_9$	$y_{sk}$
$C_1 \ C_2 \ C_3 \ C_4 \ C_5 \ C_6 \ C_7 \ C_8 \ C_9 \ C_{10}$	$y_s(t)$

②案例检索: 当前工况  $M$  的描述为  $C = c_j, j =$

$1, 2, \dots, 10. j = 1, 2, \dots, 6$  为数值型数据, 分别表示单吨能耗的期望值、熔炼炉数和设备参数;  $j = 7, 8, \dots, 10$  为枚举型数据, 分别表示各种原料系数和设备新旧程度. 案例  $M_k$  的描述为  $C = c_{j,k}, k = 1, 2, \dots, K, K$  为案例库中的案例数量.  $M$  和  $M_k$  的相似度由下式计算得到:

$$\text{SIM}(M, M_k) = \frac{\sum_{j=1}^J \lambda_j \text{sim}(c_j, c_{j,k})}{\sum_{j=1}^J \lambda_j}, \quad (1)$$

式中  $\lambda_j$  为案例权重.  $c_j$  和  $c_{j,k}$  的相似度  $\text{sim}(c_j, c_{j,k})$  由下式计算得到:

$$\text{sim}(c_j, c_{j,k}) = \begin{cases} \frac{1 - |c_j - c_{j,k}|}{\max(c_j, c_{j,k})}, & j = 1, 2, \dots, 6; \\ \frac{1 - |c_j - c_{j,k}|}{E}, & j = 7, 8, \dots, 10. \end{cases} \quad (2)$$

式中  $E$  为枚举型数据的类型数.

③案例重用: 当案例库中的案例与当前实际工况不完全匹配时, 需要对检索得到的案例解进行重用. 根据相似度  $\text{SIM}(M, M_k)$  和案例解  $y_{s,k}$ , 利用下式计算当前工况下的案例解:

$$y_s(t) = \frac{\sum_{k=1}^K \text{SIM}(M, M_k) \times y_{sk}}{\sum_{k=1}^K \text{SIM}(M, M_k)}. \quad (3)$$

④案例修正和存储: 将  $y_s(t)$  作为新的电流预设值与实际设定值进行比较, 若偏差小于 800 A, 则直接转入案例存储; 若大于 800 A, 则进行案例修正来改变模型的精度, 修正后的案例将保存到案例库中. 熔炼过程中, 案例库随工况知识的增加而不断完善, 从而实现对运行工况的自适应.

2) 能耗预报模型. 利用实际单吨能耗与单吨能耗期望值之差来调整设定值存在大滞后问题, 这就需要对单吨能耗进行预报. 本文通过分析电极电流与单吨能耗之间的关系, 建立能耗预报模型如下:

$$\hat{r}(T_p) = \frac{\sqrt{3}UI(t) \cos(\varphi T)}{\int_0^{3600T} \frac{3\alpha \left( \frac{I(t)^2}{G} - kG^{-\beta} L_e \right)}{1000 \times \sigma(3722.4\phi + 5677.2)} dt}. \quad (4)$$

式中:  $U$  表示电极相电压;  $\cos \varphi$  表示供电系统功率因数;  $\alpha$  表示电熔镁炉热效率;  $I(t)$  表示当前时刻的电极电流设定值;  $G$  表示电弧电导;  $\phi$  表示原料类型系数;  $\sigma$  表示原料质量系数;  $T$  表示熔炼总时间;  $L_e$  表示电弧长度;  $k, \beta$  为可调参数. 在电流设定值允许范围内, 预报模型能够根据当前时刻的设定值预报产品的单吨能耗.

3) 基于PI控制的前馈补偿模型. 固定的电流设定值不能适应整个熔炼过程, 当边界条件发生变化时需要对电流预设值进行校正. 本文使用PI控制方

法, 利用单吨能耗期望值和预报模型的输出值之间的偏差  $\Delta r_F(T_p) = r - \hat{r}(T_p)$  来产生电流预设值的前馈补偿值  $y_F(T_p)$ . 具体方法为:

当  $|\Delta r_F(T_p)| \geq 50$  时, 有

$$\Delta y_F(T_p) = \Delta y_F(T_p - 1) + [\Delta k_1(\Delta r_F(T_p) - \Delta r_F(T_p - 1)) + k_2 \Delta r_F(T_p)]; \quad (5)$$

当  $|\Delta r_F(T_p)| \leq 50$  时,  $\Delta y_F(T_p) = 0$ .

式(5)中  $k_1$  和  $k_2$  为可调整的参数.

4) 基于迭代学习和案例推理的反馈补偿模型. 能耗预报模型本身难免存在误差, 因此为提高控制精度, 本文设计了一个反馈补偿模型. 电熔镁炉熔炼过程具有典型的批过程特性, 这就需要设计不同批次熔炼过程之间的学习补偿机制. 迭代学习<sup>[8-11]</sup>控制方法适用于具有重复运行性质的被控对象, 可实现有限区间上的完全跟踪任务<sup>[7]</sup>. 本文选择如下所示的具有P型学习率的迭代学习算法:

$$\Delta y_R(T_r, L_f) = \Delta y_R(T_r, L_f - 1) + L(T_r) \Delta r_R(T_r, L_f - 1). \quad (6)$$

式中:  $\Delta y_R(T_r, L_f)$  表示经过  $L_f$  次迭代后的反馈补偿值;  $L(T_r)$  表示学习增益, 本文利用案例推理的方法计算得到, 其案例描述与表1相同.

5) 电极升降控制器. 电极升降控制器采用规则推理的控制策略. 规则库采用“原型分析”方法得到, 即从操作员的经验中提取规则“原型”, 整理成规则储存在规则库中. 规则库中的规则为产生式规则, 其形式为: If(前提)then(结论).

### 2.2 极心圆直径的设定

与电流设定值类似, 人工经验结合理论分析<sup>[3]</sup>得到的极心圆直径设定值在边界条件变化时同样不能满足生产要求. 因此, 本文提出了一种具有补偿机制的极心圆直径智能确定方法, 如图2所示.

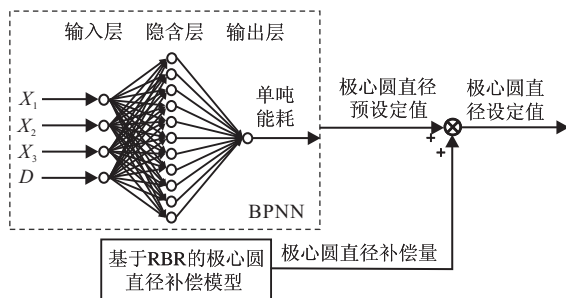


图2 极心圆直径智能确定方法结构图

该方法首先利用过程数据建立一个基于神经网络的极心圆直径预设模型, 该模型可得到使单吨能耗最小的极心圆直径预设值; 然后通过规则推理对极心圆直径预设值进行补偿, 以消除边界条件变化带来的影响. 虽然依据现有的生产工艺, 极心圆直径

的调整还需要人工参与, 但是本文提出的方法可以帮助操作员确定合适的极心圆直径和调整时机.

1) 基于神经网络的极心圆直径预设模型. 本文使用BP神经网络来建立极心圆直径预设模型, 输入包括不同品位产品所占的百分比( $X_1, X_2, X_3$ )和极心圆直径( $D$ ), 输出为产品单吨能耗, 隐含层节点数为11. 利用该模型, 设置相应的产品品位系数和不同的极心圆直径可以得到不同的产品单吨能耗, 单吨能耗最小值所对应的极心圆直径即为极心圆直径预设值. 图3所示为产品品位分别在98.5%以上含量为17.65%, 98%含量为32.45%和97%~98%含量为45.23%时极心圆直径与单吨能耗预测值的关系. 可以看到, 单吨能耗最低值为2620 kWh/t, 此时对应的极心圆直径为710 mm.




图3 神经网络预测下的不同极心圆直径和单吨能耗

2) 基于规则推理的极心圆直径补偿模型. 当熔炼过程的边界条件发生较大变化时, 神经网络预设模型无法体现边界条件变化对极心圆直径的影响, 需要进行修正. 因此本文通过对生产工艺的研究和对人工经验的总结, 设计了一个基于规则推理的极心圆直径补偿模型. 规则库如表2所示, 其中L.OL为原料中杂质含量,  $B_9$ 为炉壳新旧程度,  $\Delta = 1$ 表示边界条件发生变化,  $\xi$ 为极心圆直径补偿量.

表2 极心圆直径补偿模型规则库

规则	前 提	结 论
1	$\Delta = 1$ and $7\% \leq L.OL \leq 9\%$ and $B_9 = 1$	$\xi = 10$ mm
2	$\Delta = 1$ and $9\% \leq L.OL \leq 12\%$ and $B_9 = 1$	$\xi = -10$ mm
⋮	⋮	⋮
9	$\Delta = 1$ and $7\% \leq L.OL \leq 9\%$ and $B_9 = 3$	$\xi = 35$ mm
10	$\Delta = 1$ and $L.OL \leq 4\%$ and $B_9 = 3$	$\xi = 40$ mm

### 3 工业应用

国内某电熔镁砂厂拥有电熔镁炉18台, 每年生产各种品位的电熔镁砂约10万t. 改造前该厂电极电流和极心圆直径的设定值完全凭借经验人工给定. 根据该厂的实际情况, 结合前面所述方法, 将本文提出的智能设定方法应用到该厂的实际生产中. 图4所示为某熔炼过程在2:00~5:00时间段内的电极电流和极心圆直径的变化情况. 3:05和4:28时, 边界条件两次

发生变化, 电流设定值和极心圆直径设定值也相应地进行了自动调节. 表3记录了熔炼过程在不同时刻的运行工况数据.




图4 电极电流值和极心圆直径的变化

表3 熔炼过程在各时间点的运行工况

2:00	$\Delta = 0, L.O.L = 6.7\%, B_1 = 18, B_2 = 250, B_3 = 1300,$ $B_4 = 3.3, B_5 = 8, B_6 = 2, B_7 = 2, B_8 = 1, B_9 = 1$
3:05	$\Delta = 1, L.O.L = 11.5\%, B_1 = 18, B_2 = 250, B_3 = 1300,$ $B_4 = 3.3, B_5 = 8, B_6 = 1, B_7 = 3, B_8 = 1, B_9 = 1$
4:28	$\Delta = 1, L.O.L = 3.6\%, B_1 = 18, B_2 = 250, B_3 = 1300,$ $B_4 = 3.3, B_5 = 8, B_6 = 2, B_7 = 1, B_8 = 1, B_9 = 3$

实际应用结果显示, 应用本文所提出方法, 控制系统能够根据生产的实际情况自动调节设定值, 保证了产品产量, 并可降低3%左右的单吨能耗, 这说明本文提出的方法正确有效. 该方法于2008年投入使用至今, 取得了良好的经济效益.

## 4 结论

针对以往电熔镁炉熔炼过程中某些重要参数均由人工凭借经验设定的实际情况, 本文提出了基于智能算法的参数智能设定方法, 并将所提出的设定方法成功应用于国内某电熔镁砂厂, 保证了产品产量, 降低了产品的单吨能耗, 实现了节能降耗的目的, 取得了较好的经济效益和社会效益.

## 参考文献(References)

[1] Garduno-Ramirez R, Lee K Y. Supervisory multiobjective optimization of a class of unit processes: Power unit case

study[C]. Proc of the American Control Conf. Arlington: IEEE Press, 2001: 1497-1502.

- [2] 郭茂先. 工业电炉[M]. 北京: 冶金工业出版社, 2002: 111-118.  
(Guo M X. Industry furnace[M]. Beijing: Metallurgical Industry Press, 2002: 111-118.)
- [3] 顾根华, 秦勤, 薛丰. 电熔镁砂炉主要工艺参数的研究[J]. 节能, 1996, 2: 16-19.  
(Gu G H, Qin Q, Xue F. The research for the major technological parameters of electric smelting furnace[J]. Energy Conservation, 1996, 2: 16-19.)
- [4] 吴志伟, 吴永建, 柴天佑, 等. 一种基于规则推理的电熔镁炉智能控制系统[J]. 东北大学学报: 自然科学版, 2009, 30(11): 1526-1529.  
(Wu Z W, Wu Y J, Chai T Y, et al. Intelligent control system of fused magnesia production via rule-based reasoning[J]. J of Northeastern University: Natural Science, 2009, 30(11): 1526-1529.)
- [5] 柴天佑, 丁进良, 王宏, 等. 复杂工业过程运行的混合智能优化控制方法[J]. 自动化学报, 2008, 34(5): 505-515.  
(Chai T Y, Ding J L, Wang H, et al. Hybrid intelligent optimal control method for operation of complex industrial processes[J]. Acta Automatica Sinica, 2008, 34(5): 505-515.)
- [6] Soumitra D, Wierenga B, Dalebout A. Case-based reasoning systems: From automation to decision-aiding and stimulation[J]. IEEE Trans on Knowledge and Data Engineering, 1997, 9(6): 911-922.
- [7] Srinivasan B, Bonvin D. Controllability and stability of repetitive batch processes[J]. J of Process Control, 2007, 17(3): 285-295.
- [8] Saab S S. On the P-type learning control[J]. IEEE Trans on Automatic Control, 1994, 39(11): 2298-2302.
- [9] Xiong Zhi Hua, Zhang Jie. A batch-to-batch iterative optimal control strategy based on recurrent neural network models[J]. J of Process Control, 2005, 15(1): 11-21.
- [10] Krothapally M, Palanki S. A neural network strategy for batch process optimization[J]. Computers and Chemical Engineering, 1997, 21(1): 463-468.
- [11] Lee J H, Lee K S, Kim W C. Model-based iterative learning control with a quadratic criterion for time-varying linear systems[J]. Automatica, 2000, 36(5): 641-657.