

基于神经网络的转炉炼钢终点控制

谢书明¹, 陶 钧², 柴天佑³

(1. 沈阳工业大学 电气工程学院, 辽宁 沈阳 110023; 2. 上海宝信软件股份公司, 上海 201900;

3. 东北大学 自动化研究中心, 辽宁 沈阳 110004)

摘要: 转炉炼钢是一种非常重要的炼钢方法, 终点控制是转炉炼钢后期的重要操作. 由于冶炼过程温度极高, 很难进行准确及时地测量, 无法形成通常意义下的反馈控制. 采用 RBF 神经网络预报转炉炼钢终点温度和碳含量, 在此基础上提出了基于神经网络的动态终点控制方法来确定在补吹阶段需要的吹氧量和加入的冷却剂量, 克服了传统控制方法中基于热平衡和氧平衡控制模型不准确的缺点, 提高了终点命中率.

关键词: 神经网络; 转炉炼钢; 终点控制

中图分类号: TF721 **文献标识码:** A

BOF steelmaking endpoint control based on neural network

XIE Shu-ming¹, TAO Jun², CHAI Tian-you³

(1. Electrical Engineering Institute, Shenyang University of Technology, Liaoning Shenyang 110023, China;

2. Stock Company of Baoxin Software of Shanghai, Shanghai 201900, China;

3. Research Center of Automation, Northeastern University, Liaoning Shenyang, 110006, China)

Abstract: BOF steelmaking is a kind of paramount steelmaking method. The endpoint control is an important operation in the later period of BOF steelmaking. Because the temperature is very high in the smelting, it is very difficult to take measurement accurately and timely. There is not method to form common feedback control. The BOF endpoint temperature and carbon content were predicted by means of RBF neural network. On the basis of this, the dynamic endpoint control method based on neural network was proposed so as to determine the blown oxygen and the added coolant during the reblowing. The shortcoming that the control model based on the heat balance and the oxygen balance was not accurate in the traditional method was overcome. The endpoint hitting ratio was raised.

Key words: neural network; BOF steelmaking; endpoint control

1 引言 (Introduction)

转炉炼钢终点控制是转炉吹炼后期的重要操作. 所谓吹炼终点是指钢水达到吹炼目标要求的时刻. 终点控制主要是指吹炼终点成分和温度的控制. 由于转炉炼钢工艺的进步, 对于在冶炼过程中难以脱除的硫、磷等杂质, 一般采用预先脱硫、磷或在转炉炼钢中提前脱除到终点要求的范围, 硅在吹炼初期基本已除去, 而对于具体钢种所要求的合金成份在转炉炼钢之后加以解决, 因此通常所说的终点控制指的是终点钢水温度和碳含量的控制. 终点控制不准确, 将会延长冶炼时间, 降低炉衬寿命, 增加金属消耗, 影响钢的质量. 目前国际上比较先进的控制方法是静态控制和以副枪检测信息为基础的动态控制相结合的方法^[1,2], 它们是以物料平衡和热平衡

为基础建立的微分方程或代数方程. 动态控制是在静态控制基础上, 在吹炼后期进行副枪检测, 根据检测信息对终点进行调整, 动态控制模型的精度直接关系到终点命中率的高低. 转炉炼钢在经过主吹之后, 钢水中的杂质大部分已经去除, 而且通过副枪检测获得了钢水的成份和温度, 为终点控制创造了有利条件. 目前动态终点控制应用比较普遍的是以氧平衡和热平衡为基础建立的机理模型或根据再现性原理给出的增量模型^[3,4]. 这些模型大多是在许多假设条件下得到的, 而且一般认为脱除的碳与吹入的氧具有确定的关系, 冷却剂带入的氧通过携氧系数来反映, 而冷却剂的冷却能力则通过冷却系数来反映, 有些还要由平衡常数对平衡方程式加以补偿, 由于各炉加入冷却材料在性能上 (如粒度、温度、成

份等)的不一致性,使得携氧系数和冷却系数发生一定的变化,而这些模型都无法很好地反映这一变化,而且吹氧与脱碳之间也不一定象模型所假定的那样具有比较简单的关系,限制了转炉炼钢终点命中率的进一步提高。

2 过程描述(Process description)

转炉炼钢一般分为三个阶段,即初期、中期和后期。终点控制主要是在后期完成的,是根据第一次副枪检测结果,通过吹入适量的氧气和加入一定量的冷却剂,使炉内的钢水温度和碳含量达到要求的目标范围。在转炉炼钢后期,钢水中的杂质大部分已经脱除,反应过程不象主吹阶段那样剧烈,逐渐趋于稳定,钢水中的碳含量和温度表现出比较确定的规律。钢水中碳含量 $C(t)$ 和温度 $T(t)$ 可由如下的状态方程来描述^[5]

$$\begin{cases} \dot{C}(t) = K_1 \frac{Q}{W_g} (e^{-K_2(C(t)-C_0)} - 1), \\ \dot{T}(t) = \alpha K_1 \frac{Q}{W_g} (1 - e^{-K_2(C(t)-C_0)}) - \beta, \\ C(t_f) = C_f, T(t_f) = T_f. \end{cases} \quad (1)$$

其中 K_1 为脱碳系数; Q 为氧流量; W_g 为钢水重量; C_0 为钢水碳含量 $C(t)$ 的吹炼极限状态; α 为脱碳升温系数; β 为由于热损失而造成的降温速率; t_f 为副枪检测时刻,即补吹的初始时刻; C_f 为副枪检测时钢水碳含量; T_f 为副枪检测时钢水温度; 参数 K_1 , K_2 , α , β 可以根据具体炉次进行估计。

对式(1)求解,并消去时间变量,则可得到系统的相轨迹方程

$$\begin{aligned} T(t) = & -\alpha C(t) + \frac{\beta W_g}{K_1 K_2 Q} \ln(1 - e^{-K_2(C(t)-C_0)}) + \\ & T_f + \alpha C_f - \frac{\beta W_g}{K_1 K_2 Q} \ln(1 - e^{-K_2(C_f-C_0)}). \end{aligned} \quad (2)$$

在转炉炼钢后期,钢水温度和碳含量按照上述相轨迹运行,只有在副枪检测时钢水温度和碳含量在相轨迹附近时,通过吹入适量的氧气才会命中目标。对于副枪检测时钢水温度和碳含量不在相轨迹附近时,无论吹入多少氧气都无法命中目标,必须采用一定的调整措施将其调整到相轨迹附近,通常是具体情况加入适量的冷却剂或碳粉。

3 终点控制(Endpoint control)

3.1 终点预报模型(Endpoint prediction model)

为了使转炉炼钢终点命中目标,在补吹阶段需

要吹入一定量的氧气和加入适量的冷却剂,同时为了使冶炼过程顺利进行,还要加入一些辅助原料,通常包括石灰、混料、矿石和白云石等。由于 RBF 神经网络从输入层到隐含层是径向基函数,从隐含层到输出层为线性关系,可以采用线性调整技术,因而收敛速度快,且不易陷入局部极值点。因此,以副枪检测信息为基础,建立转炉炼钢终点温度和碳含量预报的 RBF 神经网络。两个网络的结构完全相同,如图 1 所示,输入节点为 7 个,两个网络前 6 个节点相同,分别对应于补吹氧气量、补吹阶段加入铁皮量、石灰量、混料量、矿石量和白云石量,对于终点温度预报神经网络,第 7 个输入节点对应于第一次副枪检测到的钢水温度 T_f ; 而对于终点碳含量预报神经网络,第 7 个输入节点则对应于第一次副枪检测到的钢水碳含量 C_f , 隐含节点数 m 由训练结果确定,输出节点为 1 个,对应于终点钢水温度 T_e 或碳含量 C_e 。

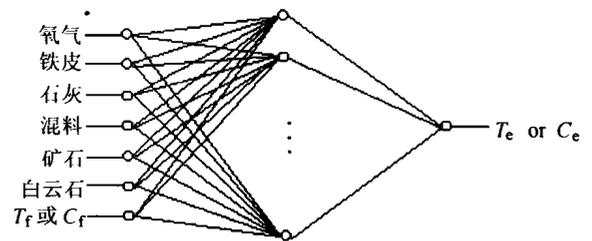


图 1 终点温度或碳含量神经网络

Fig. 1 Neural network of endpoint temperature and carbon content

从上面的分析可以得出,神经网络的输出即转炉炼钢终点温度 T_e 和终点碳含量 C_e 分别为

$$\begin{aligned} T_e = & w_{T0} + \sum_{j=1}^m w_{Tj} \Phi(\|X_T - c_{Tj}\|), \\ C_e = & w_{C0} + \sum_{j=1}^m w_{Cj} \Phi(\|X_C - c_{Cj}\|). \end{aligned} \quad (3)$$

其中 $w_{T0} \in \mathbb{R}$ 和 $w_{C0} \in \mathbb{R}$ 为偏置项; $w_{Tj} \in \mathbb{R}$ 和 $w_{Cj} \in \mathbb{R}$ ($j = 1, 2, \dots, m$) 为隐含层到输出层的权值; $\Phi(\cdot)$ 为径向基函数; $\|\cdot\|$ 为欧氏范数; $c_{Tj} \in \mathbb{R}^n$ 和 $c_{Cj} \in \mathbb{R}^n$ 为网络中心。

径向基函数 Φ 有多种形式,本文选用如下的高斯函数

$$\Phi(v) = \exp(-v^2/\beta^2). \quad (4)$$

其中 β 为一个实常数,决定高斯函数的形状。

由于 RBF 网络的输入层到隐含层不是靠权值连接,而是径向基函数,因此网络中心不仅直接关系到隐含层节点对输入变量的映射能力,而且对整个网络的性能起着非常重要的作用,必须合理地确定网络中心。本文采用 k -均值聚类算法^[6] 确定网络中

心,它可以使中心位于输入样本的重要区域内,从而使隐含层的输出更好地反映输入状况.网络中心确定后,就可以对网络进行训练,权值调整采用递推最小二乘法.

3.2 神经网络终点控制 (Neural network endpoint control)

在吹炼后期,大部分杂质都已除去,反应过程比较平稳,炉渣成分、钢水升温速度及降碳速度都呈现规律性的变化.考虑到补吹阶段加入的冷却剂也会带人一部分氧,因此补吹阶段所需的氧气量可以用下式表示^[4]

$$\Delta V_0 = V_{0e} - V_{0f} = \frac{\beta W_{st}}{10\alpha} \ln \left\{ \frac{\exp \left(\frac{C_f - C_0}{\beta} \right) - 1}{\exp \left(\frac{C_e - C_0}{\beta} \right) - 1} \right\} - \sum_i b_i r_i \quad (5)$$

其中 ΔV_0 为补吹氧气量 (Nm^3); C_e 为终点钢水碳含量 ($10^{-2}\%$); C_f 为主吹结束时副枪测得的钢水碳含量 ($10^{-2}\%$); V_{0e} 为吹炼终点吹氧量 (Nm^3); V_{0f} 为主吹阶段吹氧量 (Nm^3); b_i 为第 i 种冷却剂的携氧系数 (Nm^3/t); r_i 为副枪测定后加入的第 i 种冷却剂量 (t).

为了对终点温度进行调整,需要加入一定量的冷却剂,通常只加入一种冷却剂,冷却剂的加入量可以用下式计算^[4]

$$W_r = C_L \left(\gamma \frac{\beta}{10\alpha} \ln \left\{ \frac{\exp \left(\frac{C_f - C_0}{\beta} \right) - 1}{\exp \left(\frac{C_g - C_0}{\beta} \right) - 1} \right\} - (T_g - T_f) + \delta \right) / (H + \gamma \times B / W_{st}) \quad (6)$$

其中 W_r 为加入的冷却剂量 (t); C_L 为冷却剂计算系数; C_g 为目标终点碳含量 ($10^{-2}\%$); T_g 为目标终点钢水温度 ($^{\circ}\text{C}$); T_f 为主吹结束时副枪测得的钢水温度 ($^{\circ}\text{C}$); H 为冷却剂冷却能系数 ($^{\circ}\text{C}/\text{t}$); B 为冷却剂含氧系数 (Nm^3/t); δ 为常数; γ 为系数.

转炉炼钢终点控制的目标是终点温度和碳含量,而动态控制模型则是根据副枪检测到的钢水状况和吹炼终点要达到的目标确定控制量,即吹氧量和加入冷却剂量,因此,在某种意义上讲,动态终点控制模型就是转炉炼钢终点过程的逆模型.在上一节,建立了转炉炼钢动态终点预报的神经网络模型,在这一节建立转炉炼钢过程的动态控制模型,从而实现整个过程为 1 的传递.输入为要求的终点温度和碳含量,而输出为实际的终点温度和碳含量. RBF 神经网络具有结构简单、训练时间短的特点,但它的映射能力不如 BP 网,比较适应于向终点预报这样

关系比较简单的正向过程.从式(5)和(6)可以知道,补吹氧气量和加入的冷却剂量与很多因素有关,而且具有很强的非线性,而 BP 网具有很强的非线性映射能力,因此,在本文中采用 BP 网建立控制模型.建立神经网络逆系统的方法有直接逆系统建模、正-逆系统建模等方法.本文采用正模型-逆系统学习方法^[7],即首先要建立一个对象的正模型,利用逆神经网络的期望输入与受控系统正模型输出之差来调整逆神经网络的权值,因而它是使系统正模型输出与期望输出之差最小而不是使逆神经网络输出与系统输入之差最小.采用神经网络控制的转炉炼钢动态终点控制系统如图 2 所示.神经网络控制模型为两个:一个是补吹阶段所需吹氧量神经网络,另一个则是补吹阶段加入冷却剂神经网络,网络结构为三层 BP 网.主要是因为,从动态终点控制模型(5)和(6)可知,在补吹阶段所需吹氧量与副枪检测时钢水中的碳含量、目标碳含量以及补吹阶段加入的冷却剂有关.在实际炼钢中,为了操作方便,通常只加入一种冷却剂,而其它辅助原料加入量很少,忽略其对氧气量的影响,因此,补吹氧气量神经网络控制器输入节点为 3 个,分别对应上述三个变量,网络输出对应于补吹氧气量 ΔV_0 ,其结构如图 3(a) 所示;而补吹阶段加入的冷却剂量则与副枪检测时的钢水温度和碳含量以及目标钢水温度和碳含量有关,因此加入冷却剂神经网络控制器输入节点为 4 个,其结构如图 3(b) 所示,网络输出对应于加入的冷却剂量 W_r ,隐含层节点数通过训练决定.

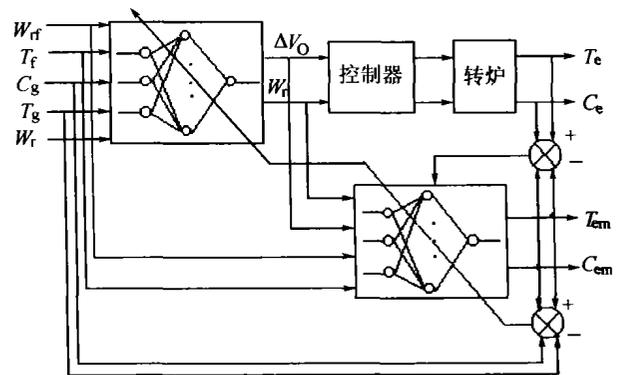


图 2 神经网络转炉炼钢动态终点控制系统

Fig. 2 Neural network based BOF dynamic endpoint control system

在图 2 中,神经网络正模型为 3.1 节介绍的预报模型,在这里它是利用实际样本数据训练好的神经网络,在神经网络控制器训练过程中起到传递作用.由于补吹氧气量神经网络和加入冷却剂神经网络都为 BP 网,而且结构基本相同,为了简单起见,

这里只以补吹氧气量神经网络为例加以论述. 设目标钢水温度和碳含量分别为 T_g 和 C_g , 神经网络控制模型的输出分别为补吹氧气量 ΔV_0 和加入冷却剂量 W_r , 神经网络预报模型输出为钢水终点碳含量 C_{em} 和终点温度 T_{em} , 定义如下的广义能量函数

$$J_C = \frac{1}{2} \sum_{p=1}^P (C_g(p) - C_{em}(p))^2, \quad (7)$$

$$J_T = \frac{1}{2} \sum_{p=1}^P (T_g(p) - T_{em}(p))^2.$$

其中 P 为训练样本数.

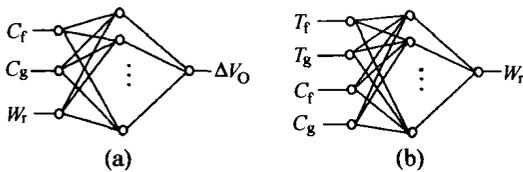


图3 神经网络

Fig. 3 Neural network

设网络输入层为 N 个节点, 隐含层为 M 个节点, 输出层为 1 个节点, 从输入层到隐含层的权值为 $W_{ij}^{(o)}$ ($i = 1, 2, 3, j = 1, 2, \dots, M$), 隐含层到输出层的权值为 $W_j^{(o)}$, 网络的输入变量为 U_i , 隐含层的输出为 V_j , 使式(7)达到极小, 可按网络的负梯度修改权值, 则有

$$W_j^{(o)}(k+1) = W_j^{(o)}(k) - \eta \frac{\partial J_C}{\partial W_j^{(o)}} =$$

$$W_j^{(o)}(k) + \eta \sum_{p=1}^P (C_g(p) - C_{em}(p)) \frac{\partial C_{em}(p)}{\partial W_j^{(o)}}, \quad (8)$$

$$W_{ij}^{(o)}(k+1) = W_{ij}^{(o)}(k) - \eta \frac{\partial J_C}{\partial W_{ij}^{(o)}} =$$

$$W_{ij}^{(o)}(k) + \sum_{p=1}^P (C_g(p) - C_{em}(p)) \frac{\partial C_{em}(p)}{\partial W_{ij}^{(o)}}. \quad (9)$$

其中

$$\frac{\partial C_{em}}{\partial W_j^{(o)}} = \frac{\partial C_{em}}{\partial \Delta V_0} \frac{\partial \Delta V_0}{\partial W_j^{(o)}},$$

$$\frac{\partial C_{em}}{\partial W_{ij}^{(o)}} = \frac{\partial C_{em}}{\partial \Delta V_0} \frac{\partial \Delta V_0}{\partial W_{ij}^{(o)}}.$$

在预报模型中采用的是 RBF 神经网络, 且基函数为高斯函数, 则

$$\frac{\partial C_{em}}{\partial \Delta V_0} = \frac{\partial}{\partial \Delta V_0} \left[\sum_{i=1}^{n_q} W_i^{(c)} \exp \left(-(X - X_{0i})^2 / (2\sigma^2) \right) \right] =$$

$$- \sum_{i=1}^{n_q} W_i^{(c)} \exp \left(-(X - X_{0i})^2 / (2\sigma^2) \right) (\Delta V_0 - \Delta V_{0i}') / \sigma^2. \quad (10)$$

式中 n_q 为预报模型隐含层节点数; $W_i^{(c)}$ 为预报模型

网络权值; X 为预报模型输入变量; X_{0i} 为预报模型的网络中心; $\Delta V_{0i}'$ 为补吹氧气量的网络中心.

在神经网络控制模型中, 激活函数选如下双曲正切函数

$$V_j = \tanh \left(\sum_{i=1}^N W_{ij}^{(o)} U_i \right), \quad (11)$$

$$\Delta V_0 = \tanh \left(\sum_{j=1}^M W_j^{(o)} V_j \right),$$

因此

$$\frac{\partial \Delta V_0}{\partial W_j^{(o)}} = (1 - \tanh^2 \left(\sum_{i=1}^M W_j^{(o)} V_j \right)) V_j, \quad (12)$$

$$\frac{\partial \Delta V_0}{\partial W_{ij}^{(o)}} = W_j^{(o)} (1 - \tanh^2 \left(\sum_{j=1}^M W_j^{(o)} V_j \right)) (1 - \tanh^2 \left(\sum_{i=1}^N W_{ij}^{(o)} U_i \right)) U_i. \quad (13)$$

将式(10), (12)和(13)分别代入式(8)和(9)就可得到神经网络逆模型隐含层到输出层和输入层到隐含层权值调整量.

4 实验研究 (Test research)

以某厂 180 吨转炉的 60 炉实际测量数据进行实验研究. 取前 35 炉数据用于神经网络预报模型和控制模型的训练, 对其余 25 炉进行计算. 网络训练中, 预报模型的隐含层节点数为 12, 学习率 $\eta = 0.9975$, 误差准则 $\epsilon = 0.001$; 神经网络控制模型的隐含节点数为 6, 学习率 $\eta = 0.01$, 误差准则 $\epsilon = 0.001$. 仿真过程与实际转炉炼钢过程相对应, 首先用前 35 炉的数据训练预报模型和控制模型, 利用该控制模型计算出第 36 炉需要补吹的氧气量和加入的冷却剂量, 并以此计算量利用预报模型计算出能够达到的终点温度和碳含量, 然后将第 36 炉的实际数据加到用于建模的数据中, 同时去掉最前边一炉的数据, 以保持建模数据量不变, 重复上述过程直到完成所有 25 炉的计算. 计算出其余 25 炉需要补吹的氧气量和加入冷却剂量分别如图 4 和 5, 相应的终点温度和碳含量如图 6 和 7 所示, 图中“ \circ ”代表实际值, “ \times ”代表通过模型计算的值. 终点碳含量 ($\times 10^{-2}\%$) 计算值与实际值之间的均方误差 $\sigma_c = 2.7333$, 终点温度 ($^{\circ}\text{C}$) 计算值与实际值之间的均方误差 $\sigma_T = 9.6873$, 由此可以看出, 该方法具有较高的精度. 另外, 在转炉炼钢从装料到出钢的时间大约为 50 分钟, 而该仿真在 P-III 计算机上大约需要 30 分钟的时间, 况且, 网络的训练可以每几炉 (例如 3 炉) 进行一次, 在此期间保持模型不变, 因此, 完全可以应用到实际的炼钢过程中.

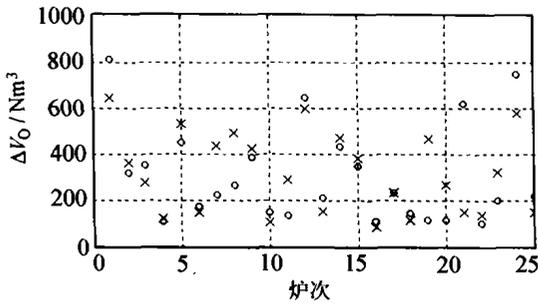


图 4 补吹氧气量
Fig. 4 Reblown oxygen

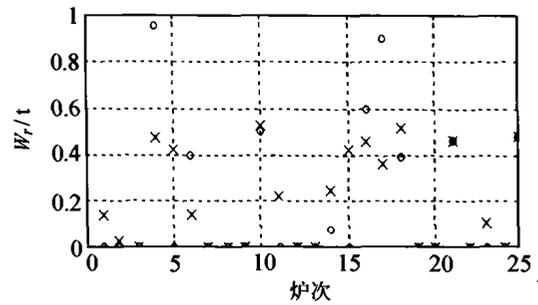


图 5 加入冷却剂
Fig. 5 Added coolant

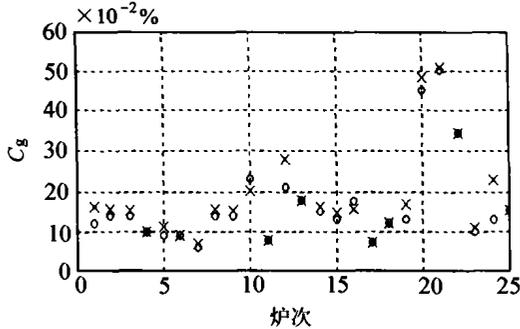


图 6 终点控制碳含量
Fig. 6 Endpoint control carbon content

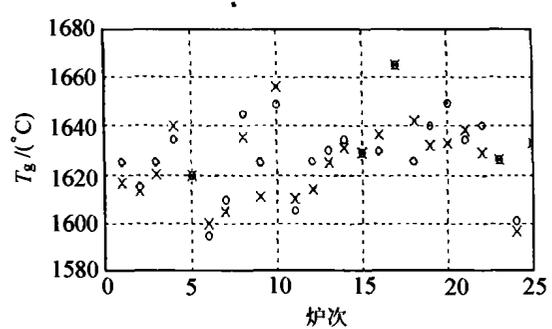


图 7 终点控制温度
Fig. 7 Endpoint control temperature

5 结论 (Conclusion)

转炉炼钢冶炼环境恶劣,钢水温度极高,很难准确地对其进行连续测量,而且影响终点的因素很多,因此,给转炉炼钢终点控制带来很大困难.基于神经网络的转炉炼钢终点控制通过预报模型的传递作用,使得对神经网络控制模型的训练不是使控制模型的输出与实际补吹氧气量和加入冷却剂之差为最小,而是使预报模型的输出与实际终点温度和碳含量之差最小,提高了控制模型的精度,克服了传统方法只根据边界条件确定补吹氧气量和加入冷却剂量的缺点.

参考文献 (References):

[1] GALLOWAY S M, GREEN M J, BALAJEE S R, et al. Improvement in furnace performance at Inland steel company's No.2 BOF shop through models utilization and standardization of operating practices [A]. 1991 *Steelmaking Conf Proc* [C]. Pittsburgh: American Iron and Steel Society, 1991: 389 - 396.

[2] ANDERSON D, BARNES C M, WHITTAKER H J. Fully dynamic process control of the BOS in British Steel [A]. 1991 *Steelmaking Conf Proc* [C]. Pittsburgh: American Iron and Steel Society, 1991: 379 - 387.

[3] KEN I, MASAO F, MASAKAZU M, et al. New endpoint control system with auto-parameter-tuning in BOF [A]. 1995 *Steelmaking Conf Proc* [C]. Nashville: American Iron and Steel Society, 1995:

715 - 719.

[4] 戴云阁,李文秀,龙腾春,主编.现代转炉炼钢[M].沈阳:东北大学出版社,1998,10:148 - 150.
(DAI Yunge, LI Wenxiu, LONG Tengchun. *Modern BOF Steel-making* [M]. Shenyang: Northeastern University Press, 1998, 10: 148 - 150.)

[5] 李彦平,潘德惠.转炉吹炼后期动态终点控制[J].东北工学院学报,1991, 12 (4): 376 - 381.
(LI Yanping, PAN Dehui. Dynamic end-point control for late stage of BOF blowing process [J]. *J of Northeast University of Technology*, 1991, 12(4): 376 - 381.)

[6] 王永骥,涂健,编著.神经网络控制[M].北京:机械工业出版社,1998, 2: 78 - 80.
(WANG Yongji, TU Jian, ed. *Neural Network Control* [M]. Beijing: Mechanical Industry Press, 1998, 2: 78 - 80.)

[7] HUNT K J, SBARBARO D. Neural networks for nonlinear internal model control [J]. *IEE Proc-D: Control Theory and Application*, 1991, 138 (5): 431 - 438.

作者简介:

谢书明 (1962 -),男,博士,副教授,现为韩国浦项工科大学博士后研究员.研究领域为复杂工业过程的建模与控制,智能控制及其应用.E-mail: xiesm_wy@hotmail.com;

陶钧 (1972 -),男,博士.研究领域为复杂工业过程的建模与控制,智能控制及其应用.E-mail: shtaojun@etang.com;

柴天佑 (1947 -),男,教授,博士生导师,国务院学科评议组成员.研究领域为自适应控制,智能控制和工业过程综合自动化理论及应用.E-mail: tychai@mail.neu.edu.cn.