

文章编号: 1004-0609(1999)04-0868-05

基于 RBF 神经网络的转炉炼钢终点预报^①

柴天佑¹ 谢书明¹ 杜 斌² 任德祥²

(1. 东北大学 自动化研究中心, 沈阳 110006 2. 宝山钢铁公司 自动化研究所, 上海 201900)

摘 要: 转炉炼钢终点温度和成分是转炉炼钢的控制目标, 它与吹氧量、铁水加入量等多个变量之间存在着严重的非线性关系, 且无法在线连续测量。作者提出了基于 RBF 神经网络的转炉炼钢终点温度及碳含量预报模型, 并结合某钢铁企业一座 180 t 转炉的实际数据进行模型验证研究。结果表明, 该方法收敛速度快, 预报精度高。

关键词: 转炉; 炼钢; 预报; 神经网络

中图分类号: TF721

文献标识码: A

转炉炼钢是一个非常复杂的周期性降碳升温过程, 其间存在很多难以量化的因素, 建立准确的数学模型非常困难^[1], 同时由于在整个冶炼过程中难以连续不断地获得准确的温度与成分的测量信息, 难以实现对终点温度和碳含量的有效控制, 因而采用炼钢过程中的吹氧量、加入铁水量、副枪测得的钢水温度和碳含量等输入量来预报终点温度及碳含量。基于炉气分析并采用卡尔曼(Kalman)滤波^[2]及自适应最小二乘(ALS)算法^[3]的传统方法和基于吹炼终点钢中自由氧含量的 $[O]_F$ 法^[4]对转炉炼钢终点碳含量进行预报的方法精度比较低, 且不能预报终点温度。而基于副枪检测获得钢水光谱分析的 QV 法^[4]对转炉炼钢终点碳含量进行预报的精度虽然有了提高, 但同样不能预报终点温度。若采用线性 CARMA 模型及对参数的在线辨识自适应^[5]来预报终点钢水温度及碳含量, 则建模过于复杂, 不易推广。当炼钢工况变化大, 影响预报精度时, 采用对非线性系统具有很强逼近能力的神经网络—BP 网对转炉炼钢终点温度及碳含量预报^[1,6], 可提高其预报精度; 但是, BP 网收敛速度慢, 且容易

陷入局部极值点。本文采用收敛速度快、逼近能力强的 RBF 三层前馈网络^[7~9], 建立转炉炼钢终点温度及碳含量预报模型, 解决了上述问题。

1 炼钢过程动态模型

转炉炼钢就是将含有较多杂质(主要为碳和硅)的铁水, 通过吹入氧气使其发生反应, 达到去除杂质的目的, 从而获得要求的钢水成分和温度。由于氧与这些杂质的反应大多为放热反应, 因而在冶炼过程中会产生大量的富余热量。为了充分利用这部分热量, 提高转炉炼钢效率, 冶炼前需要加入一些废钢, 同时为了保证冶炼的顺利进行, 造出有利于脱除杂质的碱性渣, 中间还要分批加入一些副原料(如石灰、白云石、萤石、矿石等)。因此, 转炉炼钢终点温度 y_1 和碳含量 y_2 与装入的铁水量 x_1 , 废钢量 x_2 , 副枪测得的钢水温度 x_3 , 副枪测得的钢水碳含量 x_4 , 补吹氧气量 x_5 , 补吹石灰加入量 x_6 , 补吹混料加入量 x_7 , 补吹铁皮加入量 x_8 , 补吹矿石加入量 x_9 , 补吹白云石

① 国家自然科学基金资助及国家“九五”重点攻关课题
柴天佑(1947-), 男, 博士生导师

收稿日期: 1998-11-10; 修回日期: 1999-08-09

加入量 x_{10} 有关。由于整个冶炼过程既有化学反应又有物理变化, 因此转炉炼钢是一个具有多输入多输出、存在严重非线性的复杂系统, 可用下列非线性系统方程来表示

$$y = f(x_1, x_2, \dots, x_{10}) \quad (1)$$

式中 $y(t) = \begin{bmatrix} y_1(t) \\ y_2(t) \end{bmatrix}$, $f(\cdot)$ 为参数与结构未知的非线性函数。

由于神经网络可以逼近任意非线性函数, 因此可以用下列神经网络建模来预报 $y_1(t)$ 和 $y_2(t)$

2 基于 RBF 神经网络的终点预报方法

2.1 RBF 神经网络

RBF 网络是一个三层前向网络, 包括输入层、隐含层和输出层。为叙述方便, 设网络的输入节点数为 n , 隐含节点数为 m , 输出节点数为 1。

设 RBF 网络的输入为 $X = [x_1, x_2, \dots, x_n]^T$, 则网络的输出为

$$y = w_0 + \sum_{j=1}^m w_j \Phi(\|X - c_j\|) \quad (2)$$

式中 $w_0 \in \mathbf{R}$ 为偏置项; $w_j \in \mathbf{R} (j = 1, 2, \dots, m)$ 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; $c_j \in \mathbf{R}^n$ 为网络的中心。

径向基函数 Φ 有多种形式, 一般包括薄板样条函数、高斯函数、多二次函数、逆多二次函数等。本文选用如下的高斯函数

$$\Phi(v) = \exp(-v^2/\beta^2) \quad (3)$$

式中 β 为一个实常数, 决定高斯函数的形状。

2.2 预报模型

采用 RBF 神经网络逼近式(1), 可建立如图 1 所示的终点温度和终点碳含量的神经网络。网络为三层, 包括输入层、隐含层和输出层。输入节点 n 为 10 个, 分别对应于式(1)的 10 个输入变量, 隐含节点数 m 由训练结果确定, 输出节点为 2 个, 对应于终点温度 $\hat{y}_1$ 和碳

含量 $\hat{y}_2$ 。

$$\hat{y}_i = w_{i0} + \sum_{j=1}^m w_{ij} \Phi(\|X - c_j\|) \quad (4)$$




图 1 终点预报神经网络

Fig. 1 Neural network for endpoint prediction

2.3 网络中心与权值的确定

RBF 网络的输入层到隐含层为径向基函数, 而隐含层到输出层为线性关系, 因而网络中心对于网络实现非线性映射起着非常重要的作用, 必须合理地确定网络的中心。网络中心的确定有很多方法, 这里采用如下 k -均值聚类算法确定网络中心:

第(1)步 从输入样本 $X(k) (k = 1, 2, \dots, P)$, 其中 P 为输入样本总数) 中任意选择 m 组数据作为初始网络中心 $c_j^{(0)} (j = 1, 2, \dots, m)$;

第(2)步 将输入样本按最邻近规则分组, 即将每一输入样本 $X(k) (k = 1, 2, \dots, P)$ 与各个聚类中心 $c_j^{(l)} (j = 1, 2, \dots, m; l = 0, 1, 2, 3, \dots)$ 按下式求出它们之间的距离

$$d_{kj}^{(l)} = \|X(k) - c_j^{(l)}\| \quad (5)$$

式中 l 为确定聚类中心的次数, 由第(4)步的算式确定, 将输入样本 $X(k)$ 归为距离最小的那个聚类中心的一组;

第(3)步 按下式计算新的聚类中心

$$c_j^{(l+1)} = \frac{1}{M_j^{(l)}} \sum_{k_j=1}^{M_j^{(l)}} X_j(k_j) \quad (6)$$

式中 $M_j^{(l)}$ 为输入样本 $X(k)$ 中在第 l 次确定网络中心时属于第 j 个聚类的样本个数, 这里

的 $X_j(k_j)$ 为样本 $X(k)$ 中属于第 j 个聚类的样本;

第(4)步 计算 $\varepsilon = \|c_j^{(l)} - c_j^{(l-1)}\|$, 如果 ε 小于给定的数值, 则网络中心确定完毕, 否则转第(2)步。

按照上述步骤确定网络的中心, 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。网络中心确定之后, 就可以对网络的隐含层到输出层的权值 w_{ij} 进行调整。权值调整采用递推最小二乘法, 具体步骤为:

(1) 给定初始权值矢量 $W_i(0) \in \mathbf{R}^m$, 逆相关矩阵初始值 $P(0) \in \mathbf{R}^{m \times m}$, 误差能量初始值 $J(0) \in \mathbf{R}$, 一般选一个比较大的值, 误差能量迭代终止值 $\varepsilon \in \mathbf{R}$ 。

(2) 按下式计算 $P(k)$ ($k = 1, 2, \dots$) 的值

$$g(k) = \frac{P(k-1)Z(k)}{\lambda + Z^T(k)P(k-1)Z(k)} \quad (7)$$

$$P(k) = \frac{1}{\lambda} [P(k-1) - g(k)Z^T(k)P(k-1)] \quad (8)$$

式中 $Z(k) \in \mathbf{R}^m$ 为隐节点输出, $\lambda \in \mathbf{R}$ 为遗忘因子 ($0 < \lambda < 1$, 在学习过程中一般取 $0.9 < \lambda < 1$)。

(3) 更新网络权值

$$W_i(k_1) = W_i(k_1-1) + g(k_1)[y_i(k_1) - Z^T(k_1)W_i(k_1-1)] \quad (9)$$

式中 $y_i(k_1) \in \mathbf{R}$ 为网络期望输出。

(4) 计算累积误差能量

$$J(k_1) = J(k_1-1) + \frac{1}{2} \sum_{i=1}^2 [y_i(k_1) - Z^T(k_1)W_i(k_1-1)]^2 \quad (10)$$

若 $|J(k_1) - J(k_1-1)| < \varepsilon$, 学习结束, 否则转第(2)步。

需要说明的是, 这里的 k_1 是学习的次数, y_1 和 y_2 对应于转炉炼钢终点温度和终点碳含量的实际值

2.4 数据预处理

在转炉炼钢中, 铁水加入量及补吹氧气量数值一般比较大, 而补吹时加入的冷却剂量比较小, 有时可能相差几个数量级, 大小相差如

此悬殊的数据作用于 RBF 网络的输入节点, 势必会湮没小数据对径向基函数的作用(即对隐节点的作用), 从而造成对隐层到输出层之间权值调整上的困难, 影响网络的收敛速度和精度。为克服这一缺点, 使每个输入的作用都能充分显示出来, 因此对原始数据进行标准化处理。

$$\text{令 } x'_i(k) = \frac{x_i(k) - \bar{x}_i}{\sigma_i} \quad (11)$$

式中

$$\bar{x}_i = \frac{1}{P} \sum_{k=1}^P x_i(k);$$

$$\sigma_i = \sqrt{\sum_{k=1}^P (x_i(k) - \bar{x}_i)^2};$$

$i = 1, 2, \dots, 10$, 对应于输入变量;

$k = 1, 2, \dots, P$, 对应于样本。

与此同时, 对样本中的终点温度和碳含量也进行同样的标准化处理, 因此, 网络训练是在输入数据和输出数据标准化后进行的。网络训练结束后, 按下式将训练后的输出结果还原, 得到实际的训练结果。

$$\hat{y} = \bar{y} + \sigma y' \quad (12)$$

式中 $\hat{y}$ 为训练后网络的实际输出值, $\bar{y}$ 为训练前对输出值(期望值)标准化时求得的平均值, σ 为训练前输出值的方差, y' 为用标准化数据训练网络后的输出值。

从前边的分析可知, 转炉炼钢终点预报包括以下步骤: (1) 首先对原始数据进行标准化处理; (2) 确定网络中心; (3) 网络加权值训练; (4) 终点温度及碳含量预报。另外, 在转炉炼钢中可能出现溢渣、喷溅以及其它各种异常情况, 造成样本中可能出现具有很大偏差的情况, 因而在神经网络训练前要将其剔除, 以保证网络准确反映炼钢过程。在对样本数据标准化处理后, 求出样本输入数据的中点和输出数据的中点, 并求出每个样本点距离中心点的距离。如果某个样本点距离中心点的距离相对于其它样本点距离中心点的距离(无论是输入数据还是输出数据)远很多, 则将该样本剔除, 不用于神经网络的训练。

3 对转炉炼钢终点温度和碳含量的预报

我们以某企业 180t 转炉连续 40 炉实际数据来建立预报模型(式(4)), 以此模型为基础预报 20 炉的终点温度和碳含量并与实际 20 炉的终点温度和碳含量进行比较。为了提高预报精度, 采用递推方法, 即不是在网络训练完后一成不变地对以后的 20 炉进行预报, 而只是对下一炉进行预报。预报后以新一炉的实际数据输入给模型, 同时去掉最前边一炉的数据, 以保持用于神经网络模型训练的仍为 40 炉的数据, 训练结束后再预报出下一炉的终点温度和碳含量, 依此类推, 完成 20 炉的预报。采用式(4)~(20)进行预报, 其中网络的隐含节点为 20 个, 遗忘因子 λ 为 0.99, 经过 $l=4$ 次确定的网络中心 $c_j^{(4)} (j=1, 2, \dots, 20)$ 分别为:

$$c_1^{(4)} = (0.8308, 0.2943, 0.3817, -0.1943, -0.1866, 2.0303, 1.6357, -0.7794, -0.8502, 0.9377)$$

$$c_2^{(4)} = (-1.1152, 0.7055, 0.7760, 0.1943, 0.1866, 2.7677, 1.7717, 0.6428, 0.1155, 1.2278)$$

$$c_3^{(4)} = (-1.4586, 0.9919, 1.0419, 0.1943, 0.1866, 2.7356, 1.4255, 0.4787, 0.6977, 0.9337)$$





图2 终点预报结果

Fig. 2 Endpoint predictive results

需要说明的是, 这里的网络中心是对应于 一组样本的, 如前边所说的那样, 当加入新一 炉数据而同时去掉最前边一炉数据时, 网络中 心同时也会发生变化, 训练时能量函数误差限 ε 为 0.01, 训练次数为 65~100 次, 因样本不 同而不同, 预报结果如图 2 所示。当预报误差 要求 $|\Delta t| < 15^\circ\text{C}$, $|\Delta w_c| < 5$ 时, 温度命中率为 85%, 碳命中率为 80%, 碳温同时命中率为 75%。由此可见, 预报精度比较高。采用一般 的 PC586 微机进行网络训练并求出终点温度 及碳含量时间一般为 6~7 min, 有时会稍微长 一些, 但不超过 10 min。在实际转炉炼钢过程 中, 从测得终点成分和温度到下一炉副枪检测 时间至少有 20 min(包括装铁水和废钢及主吹 时间等), 在这段时间完全可以完成网络的训 练与终点温度及碳含量的预报, 根据预报结果 可以对补吹氧气量及冷却剂加入量进行调整, 从而提高终点命中率。

4 结论

转炉炼钢过程的动态特性存在着严重的未 知非线性, 传统的数学模型很难准确描述这一 过程。基于 RBF 神经网络建立转炉炼钢终点 预报模型, 具有较高的预报精度。和较快的收 敛特性, 可以实时应用于转炉炼钢过程的终点 控制。

REFERENCES

- 1 Yun S Y and Chang K S. I&SM, 1996, 8: 37~ 42.
- 2 Zhang Runyu(张润宇), Xiao Bing(肖兵) and Zhang Wendi(张文弟). ACTA Automatica Sinica(自动化学报), 1993, 19(3): 381~ 383.
- 3 Li Yanping(李彦平) and Pan Dehui(潘德惠). Control and Decision(控制与决策), 1988, 3(2): 7~ 10.
- 4 Saito Tadashi, Ebato Koichi, Tsubone Iwao *et al.* Tetsu-to-hagane, 1990, 11: 1972~ 1977.
- 5 Wang Shunhuang(王顺晃), Du Dachuan(杜大川), Liu Hongcai(刘宏才) *et al.* Journal of University of Science and Technology Beijing(北京科技大学学报), 1992, 14(5): 563~ 568.
- 6 Ding Rong(丁容) and Liu Liu(刘浏). Iron and Steel(钢铁), 1997, 32(1): 22~ 26.
- 7 Yingwei L, Sundarajan N and Saratchandran P. In: IEE Proc Control Theory Appl, 1997, 144(2): 202 ~ 208.
- 8 Hepworth S J and Dexter D L. Mathematics and Computers in Simulation, 1996, 41: 39~ 51.
- 9 Chen Xiaohong(陈小红), Gao Feng(高峰), Qian Jixin(钱积新) *et al.* Control Theory and Applications(控制理论与应用), 1998, 15(2): 226~ 231.

Endpoint prediction of basic oxygen furnace steelmaking based on RBF neural network

Chai Tianyou¹, Xie Shuming¹, Du Bin², Ren Dexiang²

1. *Research Center of Automation, Northeastern University,
Shenyang 110006, P. R. China*

2. *Automatic Institute, Baoshan Iron and Steel Company,
Shanghai 201900, P. R. China*

Abstract: The endpoint temperature and carbon content of basic oxygen furnace (BOF) are the control objects of the BOF steelmaking process. There exists serious non-linearity among them and blowing oxygen etc, and the online continue measurement can not be made. The predictive model of endpoint temperature and carbon content of the BOF steelmaking based on RBF neural network was put forward, and the research of verifying the model was made by comparing the predictive value with the practical data of an 180t converter in a factory. The results show that the method has fast convergence speed and accurate prediction.

Key words: BOF; steelmaking; prediction; neural network

(编辑 何学锋)