

[文章编号] 1004-0609(2000)05-0732-04

基于神经网络和自适应残差补偿的 炼铜转炉吹炼终点预报模型^①

梅 焱, 胡志坤, 彭小奇, 姚俊峰, 胡 军

(中南工业大学 应用物理与热能工程系, 长沙 410083)

[摘 要] 讨论了权值初始化、变量的预处理、学习过程参数的自适应调节、网络拓扑结构等因素对学习和推广的影响, 提出了一种改进的 BP 神经网络学习算法, 在很大程度上改善了学习效率。采用改进的带有 8 个输入变量的 BP 神经网络算法和自适应残差补偿算法建立吹炼终点组合预报模型。利用某厂实际生产数据进行仿真运行的结果表明, 利用该组合预报模型得到的平均相对预测误差为 1.2%, 最大误差为 4%。

[关键词] 转炉; 铜钼吹炼; 神经网络; 终点预报

[中图分类号] TP 183; TF 811

[文献标识码] A

转炉吹炼的目的是通过铜钼和空气中的氧气进行剧烈的自热反应, 将 Cu_2S 氧化成金属铜。铜钼吹炼通常分为两个阶段: 造渣期和造铜期。造渣期的主要目的是除去铜钼中的铁元素, 生成主要含 Cu_2S 的白钼; 造铜期的主要目的是除去其中的硫元素, 生成含铜 98% 以上的粗铜, 且将贵金属元素富集。在铜钼吹炼过程中, 造铜期的终点判断直接影响粗铜的生产质量。欠吹会增加后续工序处理难度, 过吹使铜钼过多地氧化成 Cu_2O 。在实际生产中, 终点判断大多依据操作人员在恶劣条件下取样观察; 而利用 SO_2 分析仪分析吹炼产生的烟气成分以此判断吹炼终点也是实际中常用的方法, 但仪器价格昂贵且易损坏。曾有学者从反应机理出发^[1], 通过建立热力学模型来进行转炉过程仿真和终点预报, 取得一定效果。但由于许多热力学参数不能确定和生产现场操作参数变化的随机性, 所以其实际应用也存在很大的局限。

本文作者将改进的 BP 神经网络算法和自适应残差补偿算法相结合, 建立了炼铜转炉吹炼终点的组合预报模型, 通过判定铜钼中的含铜量来预报吹炼终点。运用实际生产数据进行仿真运行。结果表明实验建立的模型具有较高的预报命中率和较强的实时性。

1 改进的 BP 神经网络算法

1.1 学习算法

BP(Back Propagation)神经网络是人工神经网络中应用最广泛的一种网络模型, 结构简单且易于

编程处理, 具有较强的非线性处理能力。本文所建模型采用含输入层、隐含层和输出层的三层网络^[2]。

设有 Q 个样本, $x_i^q, t_i^q (q=1, 2, \dots, Q; i=1, 2, \dots, I)$ 为样本的输入、输出, $h_j^q (q=1, 2, \dots, Q; j=1, 2, \dots, J)$ 为隐含层的输出, 对样本采用进行批处理的方法进行网络训练^[3], 训练算法如图 1 所示。

1.2 学习算法改进策略

1.2.1 学习前预处理

避免刚训练开始就进入局部极小点的方法之一就是给权值和阈值(视为特殊权值)随机赋一小值, 如 $[0, 0.1]$ 之间。

由于自变量的单位不同, 为了避免夸大某些影响目标值的作用, 对变量进行自标准化^[4]:

$$x_i'^q = \frac{x_i^q - M_i}{S_i} \quad (1)$$

式中 $x_i'^q (q=1, 2, \dots, Q; i=1, 2, \dots, I)$ 是经过自标准化的第 q 个样本的第 i 个变量, x_i^q 是原始变量, M_i, S_i 分别是第 i 个变量的算术平均值和标准偏差。

BP 神经网络常采用 Sigmoid 函数作为激励函数, 因而在训练时输出要将实际数据规范到 0 和 1 之间, 通常采用归一法来实现, 但教师样本中至少有 1 个 1 和 0, 这恰好是 S 函数的极值, 要有足够大的权值才能使网络输出与其匹配。因此可以采用如下方法将教师样本的值规范到 $[0.1, 0.9]$ 之间:

① [收稿日期] 1999-12-09; [修订日期] 2000-05-08

[作者简介] 梅 焱(1934-), 男, 教授, 博士生导师。




图 1 BP 神经网络学习算法流程图

Fig. 1 BP neural network exercise algorithm

$$t'_k = \frac{t_k^q - t_{k, \min}}{t_{k, \max} - t_{k, \min}} \times 0.8 + 0.1 \quad (2)$$

式中 t'_k ($q=1, 2, \dots, Q; k=1, 2, \dots, K$) 为教师样本中经过标准化的第 q 个样本的第 k 个输出; t_k^q 为教师样本中第 q 个样本的第 k 个输出; $t_{k, \max}^q, t_{k, \min}^q$ 分别教师样本中第 k 个输出的最大值和最小值。

1.2.2 模型参数自适应调节

为了防止学习震荡和加速收敛, BP 网络在修改权值时常加上一个动量项。学习速率 η 和动量因子 α 进行自适应调节, 是改进学习算法的有效手段之一^[5, 6]。 η 较大, 可以加快学习收敛速度, 但可能导致震荡。 α 能有效抑制震荡, 加速收敛速度, 但误差没有朝减小方向进行时, 动量项会减慢收敛速度。综合 η, α 对学习过程的影响, 令总误差的变化 ΔE 和学习速率的变化 $\Delta \eta$ 分别为

$$\Delta E_1 = E_1(n_0) - E_1(n_0 - 1) \quad (3)$$

$$\Delta \eta = \eta(n_0 + 1) - \eta(n_0) \quad (4)$$

式中 n_0 为迭代次数。采用如下自适应调节方案:

1) 当 $\Delta E_1 > 0$, 则 $\Delta \eta = k^* \eta$, $\alpha > 0$, 且 α 取一个较大的数, 当 $\eta(n_0 + 1)$ 大于一个给定的 η_1 时, 则

$$\eta(n_0 + 1) = \eta_1 \quad (5)$$

2) 当 $\Delta E_1 < 0$, 则 $\Delta \eta = -k \eta$, $\alpha = 0$, 当 η 小于一个给定的 η_2 时, 则

$$\eta(n_0 + 1) = \eta_2 \quad (6)$$

式中 k 为一小正数。

1.2.3 隐含层单元数的选取

隐含层通过输入层与隐含层之间连接权值的“自组织化”对输入模式进行特征抽取, 并将抽取的特征传递给输出层。一般, 单元数越大越好^[7], 但太大会导致网络冗余, 而且容易振荡。

本文采用“黄金点尝试法”确定隐含单元数, 即在训练次数中用 H (较大正数) 和 $\text{int}(0.618H)$ (int 为取整函数) 两个单元数分别训练。若得出的误差相差不大, 取小单元数, 否则取 H 为隐含层单元数。

1.2.4 网络的推广

网络真正的价值体现在网络强大的外推能力。导致网络推广能力差的原因有两种, 一种原因是因为网络没有记忆过当前模式, 导致外推能力差; 另一种原因是因为网络学习过程中出现了过拟合现象。解决第一种原因的办法只有多增加典型样本。隐含层单元数过多和网络学习中控制迭代的最小误差过小都会导致过拟合现象。经验表明^[8], 当隐含层单元数为输入的 4~5 倍时为佳, 最小误差不能太小, 这样, 就能有效地避免过拟合的危险。

2 组合预报模型

2.1 神经网络预报模型

由于吹炼的开始和结束是以送风的开始和结束作为标志, 所以把造铜期吹炼所需氧量作为预报目标, 以熔体中的含铜量作为判定终点的标准。影响吹炼所需氧量的因素很多, 主要为动力学因素和热力学因素。因此, 考虑两方面的主要因素, 将影响因素适当分类, 选择铜钼中的 Cu, S 和 Fe 元素的质量、铜钼和熔剂中所含 SiO_2 的总量、冷料总量、几种对目标值影响大的冷料量以及冷料加入的次数作为模型的输入变量, 共 8 个, 记为 $X = \{x_i, i=1, 2, \dots, 8\}$; 选择铜钼吹炼所需氧量为输出变量, 记为 Y 。用本文所述的方法, 经仿真试验, 对隐含层取 40 个单元。采用新息等维模型, 选取最新的 70 炉数据作为训练样本集, 其后 30 炉作为测试集, 然后再将新的实际数据补充进来, 去掉最早 1 炉数据, 对神经网络进行训练, 使模型具有自学习和自适应性。

2.2 自适应残差补偿算法^[9]

由于神经网络模型只考虑了影响吹炼所需氧量的主要因素,而且只考虑了静态因素。但是,目标值还跟那段时间的炉况、入炉铜钼的质量(主要指铜钼带渣率)、操作人员的操作习惯等因素有关,所以必须考虑网络模型学习后残差的补偿。实验采用多元线性回归建立残差与各影响因素之间关系的模型,将 Q 个样本作为样本集,以此对训练好的网络给出的预测值进行补偿,设

$$y(q) = y_m(q) + \Delta y(q) \quad (7)$$

式中 $y(q)(q = 1, 2, \dots, Q)$ 为吹炼实际用氧量, $y_m(q)(q = 1, 2, \dots, Q)$ 为训练好的神经网络给出的预测值, $\Delta y(q)(q = 1, 2, \dots, Q)$ 为吹炼实际用氧量与神经网络给出的预测值残差, $x_i(q)(q = 1, 2, \dots, Q)$ 为神经网络的输入变量,从而建立线性回归补偿模型:

$$\Delta Y = XA \quad (8)$$

式中

$$\Delta Y = [\Delta y(1), \Delta y(2), \dots, \Delta y(Q)]^T \quad (9)$$

$$X_0 = [1, 1, \dots, 1]^T, X_i = [x_i(1), x_i(2), \dots, x_i(Q)]^T (i = 1, 2, \dots, I) \quad (10)$$

$$X = [X_0, X_1, X_2, \dots, X_P]^T \quad (11)$$

$$A = [a_0, a_1, a_2, \dots, a_I]^T \quad (12)$$

A 为回归系数,应用最小二乘法求得 A ,即

$$A = (X^T X)^{-1} X^T \Delta Y \quad (13)$$

残差补偿可以采用新息模型,即利用前 Q 次的输入变量和预测残差来预测第 $Q + 1$ 次的残差 $\Delta y(Q + 1)$,然后依如下公式得到氧量测量值:

$$\tilde{y}(Q + 1) = y_m(Q + 1) + \Delta y(Q + 1) \quad (14)$$

这样得到实际的 $P + 1$ 次残差信息后,将其和第 $P + 1$ 次的神经网络输入变量加入样本集,去掉第一个样本的信息,始终保持 P 个样本,实验采用 70。

2.3 吹炼终点预测算法

吹炼终点预测算法如图 2 所示。

3 仿真实验

以某厂 100 炉数据为样本进行仿真。根据现场要求,设相对误差 ε 满足:

$$\varepsilon = |Y_o - Y_p| / |Y_p| \quad (15)$$

式中 Y_o 和 Y_p 表示网络的输出值和实际值;设拟合允许平均相对误差 $\varepsilon < 1.5\%$,也即为现场的 1.5 min 左右(现场误差允许最大误差为 8~10 min)。结果如图 3。

表 1 列出了本组合预报模型的有关指标。因




图 2 吹炼终点预测算法

Fig. 2 Predicting algorithm of converting endpoint




图 3 造铜期吹炼终点预报值与实际值

Fig. 3 Matte cycle prediction value and practice value of copper-matte converting endpoint

表 1 预报模型仿真试验指标

Table 1 Simulation test indicatrix of prediction model

Specimens	Specimen number	Average relative error/ %	Maximal relative error/ %	Minimum relative error/ %	Exercise times
Exercise specimens	70	1.48	6.86(No. 4)	0.02(No. 10)	4 290
Verification specimens	30	1.20	3.97(No. 83)	0.11(No. 91)	

此,本组合预报模型具有较高的预报精度和实用性。而且,采用自适应残差补偿后,平均相对误差和最大相对误差都分别比拟合的平均相对误差和最大相对误差小,故对改善预报模型具有重要的意义。而且,随着实用中的不断学习和适应,其预报精度定能进一步提高。

4 结论

1) 将传统的预测方法和神经网络结合起来预报铜硫吹炼终点, 避免了复杂的机理模型, 具有预报快、精度高的特点; BP 神经网络改进的学习算法, 能对网络进行快速、有效的训练。

2) 利用线性回归模型对学习残差进行自适应补偿。

[REFERENCES]

- [1] Goto S. Equilibrium calculations between matte, slag and gaseous phases in copper smelting [A]. Copper Metallurgy—Practice and Theory [C]. London: Inst Min Met, 1974. 23– 34.
- [2] CHAI Tian-you(柴天佑) and XIE Shu-ming(谢书明). 基于 RBF 神经网络的转炉炼钢终点预报 [J]. The Chinese Journal of Nonferrous Metals(中国有色金属学报), 1999, 9(4): 868– 872.
- [3] HUANG De-shuang(黄德双). 神经网络模式识别系统理论 [M]. Beijing: Electronic Industry Press, 1996. 122.
- [4] LIU Hong-li(刘洪霖) and BAO Hong(包 宏). 化工冶金过程人工智能优化 [M]. Beijing: Metallurgical Industry Press, 1999. 15.
- [5] XU Xiao-li(徐小力) and YIN Jian(殷 健). 旋转机械趋势预测方法的研究 [J]. Journal of Beijing Institute of Machinery(北京机械工业学院学报), 1999(1): 23– 27.
- [6] LIU Zhen-yu(刘振宇), WANG Zhao-dong(王昭东), WANG Guo-dong(王国栋), et al. 利用神经网络预测热轧 C-Mn 钢力学性能 [J]. Journal of Iron and Steel Research(钢铁研究学报), 1995, 31(1): 54– 57.
- [7] ZHANG Li-min(张利民). 神经网络模型及应用 [M]. Shanghai: Fudan University Press, 1994. 34– 36.
- [8] YIN Shen-ming(尹申明), LU Jian-dong(陆建东), LEI Ming(雷 鸣), et al. 自适应神经网络学习方法研究 [J]. Computer Research And Development(计算机研究与发展), 1994, 31(6): 24– 29.
- [9] XIE Shu-ming(谢书明), GAO Xian-wen(高宪文), and CHAI Tian-you(柴天佑). 基于灰色模型的转炉炼钢终点预报研究 [J]. Journal of Iron and Steel Research(钢铁研究学报), 1999, 11(4): 9– 11.

Converting furnace endpoint prediction model based on neural network and adaptive error compensation

MEI Chi, HU Zhi-kun, PENG Xiao-qi, YAO Jun-feng, HU Jun

(Department of Applied Physics and Heat Engineering,

Central South University of Technology, Changsha 410083, P. R. China)

[Abstract] The effect of mass initialization, variables pretreatment, adaptive adjustment of parameters and structure of network on exercise and generalization was discussed in detail. An improved BP neural network exercise algorithm which was developed to greatly improve its efficiency was proposed, and a grouping prediction model based on the neural network algorithm with 8 input variables and error compensation of linear regression were developed. For simulating test, the average error of the model is 1.2%, and the maximal error of the model is 4%.

[Key words] converting furnace; neural network; endpoint prediction; linear regression

(编辑 龙怀中)