

文章编号: 1004-0609(2003)05-1306-05

基于神经网络和灰色理论的密闭鼓风炉透气性预测模型^①

唐朝晖, 桂卫华, 吴敏, 陈晓方

(中南大学 信息科学与控制工程学院, 长沙 410083)

摘要: 以密闭鼓风炉熔炼过程为研究对象, 采用自适应组合集成技术将神经网络 NN 和灰色理论有机结合的方法建立了密闭鼓风炉透气性预测模型。仿真和工业应用结果表明: 所提出的模型能很好地实现密闭鼓风炉透气性的预测, 并能使铅锌产量得到显著的提高。

关键词: 密闭鼓风炉熔炼过程; 透气性; 预测模型; 神经网络; 灰色理论; 自适应模糊组合

中图分类号: TP 273

文献标识码: A

密闭鼓风炉(ISP)炼铅锌的熔炼过程是一个极其复杂的多元多相高温物理、化学反应过程, 具有明显的非线性、强耦合和大滞后特点, 其透气性的好坏直接影响到密闭鼓风炉的炉况和炉料的加料量, 因此, 有必要采用一种有效的方法建立模型实时预测密闭鼓风炉透气性, 准确预报密闭鼓风炉的透气性指数, 使密闭鼓风炉操作人员能及时、准确了解密闭鼓风炉的运行状态, 及时调整炉料加料制度和加料量, 使密闭鼓风炉处于最佳生产状态, 以减少因炉况波动而造成的损失, 从而提高密闭鼓风炉的生产量。

用于复杂工业生产过程的建模方法有很多, 其中人工神经网络 NN 作为一种智能化建模方法, 因具有任意逼近非线性的能力^[1, 2]和较高的精度, 应用日益广泛^[3~6], 已成功用于预测冶炼过程的成品质量^[7, 8]。但由于 NN 模型的建立基于已有历史数据, 仅能很好描述数据覆盖区域内的关系, 对未覆盖区域内的预测效果较差。与传统方法相比, 灰色系统可以对数据进行实时建模, 建模要求的样本点少, 也不要求样本有较好的分布规律, 而且计算量少, 有较强的适应性, 在实际工程应用方面非常有利, 但是由于过程异常复杂, 往往精度不高。可见, 单一建模方法都难以解决上述问题, 无法满足准确预报密闭鼓风炉透气性指数的要求。为此, 文中提出一种神经网络建模和灰色系统自适应模糊组合方法, 建立密闭鼓风炉透气性预测模型。仿真和工业应用结果表明, 所提出的模型能很好实现密闭鼓风炉透气性预测, 并能使铅锌产量得到显著的提高。

1 鼓风炉透气性指数的描述

为了研究密闭鼓风炉的透气性, 我们必须给出透气性好坏的判断标准。散料层的透气性用气体运动的厄根(Ergun)方程导出:

$$Q^2 / \Delta P = \left(\frac{A^2}{Hf} \right) \left(\frac{d_p \phi}{1 - \epsilon} \right)^3 \quad (1)$$

式中 A 为鼓风炉炉身平均横截面积, H 为料柱高度, ρ 为气体密度, f 为厄根方程的阻力系数, d_p , ϕ 为炉料平均颗粒度直径和平均形状系数, ϵ 为料层空隙度, Q 为气体通过散料层的阻损, 即通过散料层的气体体积流量。可见对密闭鼓风炉对象而言, 综合底部的风量和风压能够描述透气性的基本特征和变化。

通过现场的实际情况和理论分析, 得气体动力学方程:

$$K = Q^{1/7} / (p_B^{2/7} - p_T^{2/7}) \quad (2)$$

式中 K 为密闭鼓风炉的透气性, Q 为底部风风量, p_B 为底部风风压, p_T 为顶部风压。因为在韶关冶炼厂的密闭鼓风炉中顶部风压保持为较小的常数, 借鉴高炉对透气性指数的相关计算经验, 可以将公式简化为:

$$k = Q / p_B \quad (3)$$

根据实际的操作经验, 我们可以把底部风量对风压的比值为 0.65~0.7 时定为透气性不好, 0.7~0.8 时定为透气性正常, 0.8~0.85 时定为透气性好, 0.85~1.0 时定为优。

^① 基金项目: 国家 863 高科技计划资助项目(2001AA411040)

收稿日期: 2002-07-29; 修订日期: 2002-11-12

作者简介: 唐朝晖(1965-)男, 副教授, 博士研究生。

通讯联系人: 唐朝晖, 0731-8879628; E-mail: zhtang@mail.csu.edu.cn

2 神经网络预测模型

人工神经网络 ANN 作为一种智能化建模方法, 可逼近任意非线性函数, 此方法已逐渐被应用于复杂冶炼过程的建模。

对于神经网络训练, 特征输入量的选择是一个非常关键的问题, 所选取的输入量关系到预测的精度。根据实际生产的情况得知: 炉料从开始加入到开始软化的时间大致是 0.5 h, 取 9 个历史时刻的数据基本上能够描述这个过程。因此, 在输入量的选取上, 我们将过去连续 9 个时刻的透气性作为神经网络的输入。其他的参数, 例如软化点和熔化点, 要 2 h 才有一个结果, 但是它会在 9 个历史数据里包含他们的影响。

建立 3 层结构的 BP 网络, 有输入层, 隐层和输出层, 分别为 9, 30 和 1 个神经元。在输入层, 9 个神经元是过去连续的 9 个时刻的透气性, 用 x_k 表示(k 为 1, 2, ..., 9), 而 1 个输出是当前的透气性。第 i 个神经元的输入和输出分别为:

$$x_i = \sum_{k=1}^9 (w_{i,k} x_k + b_i) \quad (4)$$

$$y_i = \tan \operatorname{sig}(x) \quad (5)$$

式中 $w_{i,k}$ 是由输入层 9 个神经元到隐层第 i 个神经元的信号权值, b_i 是隐层第 i 个神经元的阀值。如果其形式为

$$\tan \operatorname{sig}(x) = \frac{2}{1 + e^{-2x}} - 1 \quad (6)$$

则输入被映射到间隔(-1, 1), 在输出层, 神经元的输入和输出定义为:

$$x_0 = \sum_{i=1}^{30} w_{i,0} y_i + b_0 \quad (7)$$

$$K = x_0 \quad (8)$$

式中 $w_{i,0}$ 是由隐层第 i 个神经元到输出神经元的信号权值, b_0 是输入层神经元的基值, K 是透气性指数。式(4)~(8)可合写成

$$K = \sum_{i=1}^{30} w_{i,0} \tan \operatorname{sig} \sum_{k=1}^9 (w_{i,k} + b_i) + b_0 \quad (9)$$

式(9)表示在一定范围内 K 与 x_k 的关系, 在这里权值 $w_{i,k}$ 和 $w_{i,0}$, 以及基值 b_i 和 b_0 , 通过相应的 BP 网络进行学习来确定。

为了确定这些权值和基值, 从过程中抽取大量的统计数据, 用于 BP 网络的学习。在学习过程中, 网络输入为 x_k , 网络的输出为 K , 目标的输出透气性指数的实际值 K_A , 网络性能函数定义为

$$J = \frac{1}{N} \sum_j^N [K(j) - K_A(j)]^2 \quad (10)$$

式中 $K(j)$ 和 $K_A(j)$ 是网络输出和目标输出, N 是在学习中所用的目标输出个数。

在学习过程中, 通过不断调节网络的权值和基值, 使 J 达到最小。基本的反向传播学习算法^[9]被用于决定权值和基值, 它用 j 的梯度来调整权值和基值, 并最小化 J 权值和基值的调整朝负的梯度方向进行。设 $x_{wb}(k)$ 是当前的权值和基值, $g_{wb}(k)$ 是当前的梯度, $r_{wb}(k)$ 是当前的学习速率, 则学习算法可写成

$$x_{wb}(k+1) = w_{wb}(k) - r_{wb}(k) g_{wb}(k) \quad (11)$$

$$g_{wb}(k) = \frac{\partial J}{\partial x_{wb}}(k) \quad (12)$$

式中 k 是迭代的次数。神经网络的仿真结果如图 1 所示。

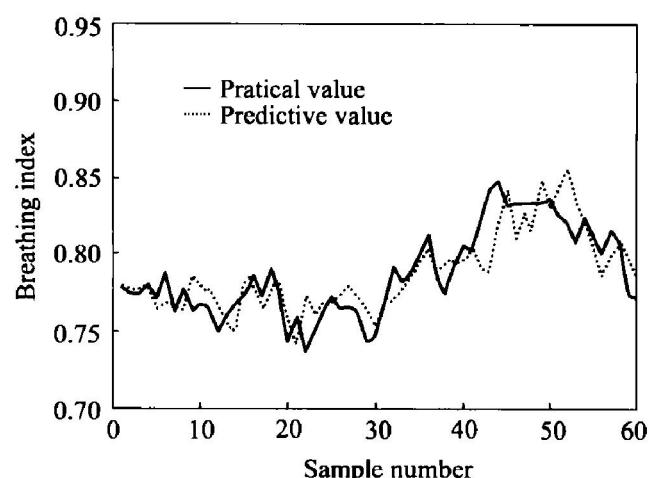


图 1 神经网络模型仿真结果
Fig. 1 Simulation result of neural network model

3 基于灰色理论的透气性预测模型

密闭鼓风炉的生产过程由于经常受到入炉物料物理化学特性的波动、操作条件、加料制度、料线的高低、炉顶的温度、渣形及渣温等不确定因素的干扰, 因而难以确知其输入输出间的复杂关系, 也就是说其系统属于灰色系统; 而且系统具有纯滞后现象, 一般很难建立其准确的数学模型。灰色预测控制是通过系统行为数据, 寻找系统发展的规律, 按照规律预测系统未来行为, 根据系统未来行为采取控制决策进行预控制。采用灰色系统建模的方法, 是通过对原始数据进行累加处理, 将原来离乱的数列变得比较有规律, 然后建立系统的模型。

GM(1, 1)模型的预测精度与原始数据列的分布有关, 自然也与建模维数有关, 老信息太多往往

会淹没新信息的特点,使预测对系统的波动反映迟缓,跟踪性变差,建模维数一般取为 5 为宜^[10]。根据生产过程的特点,将 n 选取为 5。

为了适应密闭鼓风炉熔炼过程的复杂性,建模过程中采用了等维新信息模型,也就是每次得到透气性指数的实际采样值之后,将最新的采样数据加入到建模所用的原始数据列中,同时去掉最前边一次采样数据,以保持数据列的维数不变。加入的数据是该熔炼时间内没有出现较大异常情况的数据,如结瘤、悬料等情况,以保证预测的精度。灰色理论模型的仿真结果如图 2 所示。

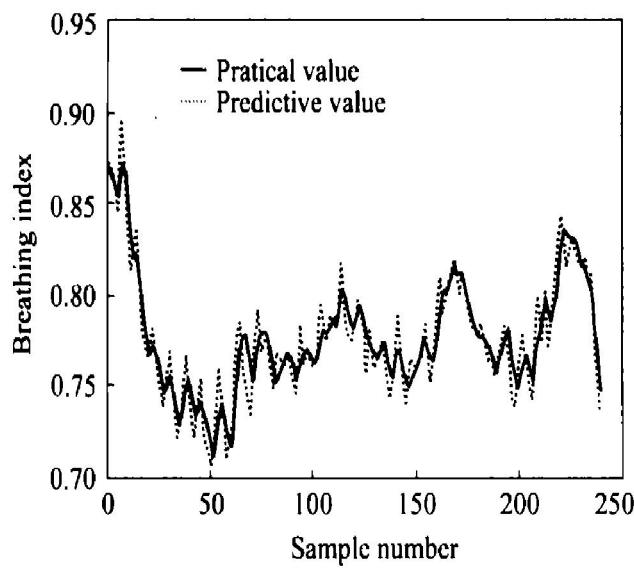


图 2 灰色理论模型仿真结果

Fig. 2 Simulation result of gray theory model

4 自适应模糊组合式模型

理论和实践表明,灰色 GM(1, 1) 预测法及神经网络法要明显优于传统的回归分析法。但是,人工神经 BP 网络算法存在收敛速度慢,训练耗时,因而不能跟上系统参数的变化,在实时性方面很难满足系统的要求。而灰色模型为线性模型,

因变量和自变量之间存在着非线性关系或者说这种关系还未知时,用其作预测分析时精度还不高,并且在系统数据波动较大时,也就是历史数据不是很平滑时,灰色理论模型的精度也不很高。为此采用两者的综合模型,既利用灰色模型弱化原始数据的随机性和累加生成数据的规律性,又利用神经网络的高度非线性,以期有更加良好的预测效果。综合模型的集成形式如图 3 所示。

灰色理论模型在系统比较平稳时预测的精度较高,在系统波动较大时预测的精度较低,而神经网络能够把原来相近的历史信息记录下来,拟合的效果较灰色理论好。为了进一步提高预测的精度和扩大模型的适用范围,利用组合预测理论,对灰色理论模型和神经网络模型进行组合优化。具体的方案如下:

设 $y(1), y(2), \dots, y(n)$ 为一实际问题的历史数据,利用这些数据对未来时期数据 $y(n+1)$ 进行预测,则设 $\hat{y}_1(i)$ 和 $\hat{y}_2(i)$ 为对于上述预测问题 $y(i)$ 所建立的灰色理论预测模型和神经网络预测模型。将 $i=1, 2, \dots, n$ 代入 $\hat{y}_1(i)$ 和 $\hat{y}_2(i)$ 得到的是两模型与历史数据 $y(i)$ 的拟合值;将 $i=n+1$ 代入 $\hat{y}_1(i)$ 和 $\hat{y}_2(i)$ 得到的是未来 $n+1$ 期预测值 $\hat{y}_1(n+1)$ 和 $\hat{y}_2(n+1)$ 。模型的互补组合预测模型为

$$\hat{y}(i) = k_1 \hat{y}_1(i) + (1 - k_1) \hat{y}_2(i) \quad 0 < k_1 < 1 \quad (13)$$

通过确定权参数值 K_1 ,寻求最优化的组合预测模型。

由统计理论中方差与协方差关系可知,对任意两个随机变量 X 和 Y 下列等式成立:

$$D(X+Y) = D(X) + D(Y) + 2V_c(X, Y) \quad (14)$$

为确定组合模型的权参数,令对应的偏差为

$$\begin{aligned} e_1(i) &= y(i) - \hat{y}_1(i), \quad i=1, 2, \dots, n, n+1 \\ e_2(i) &= y(i) - \hat{y}_2(i), \quad i=1, 2, \dots, n, n+1 \end{aligned}$$

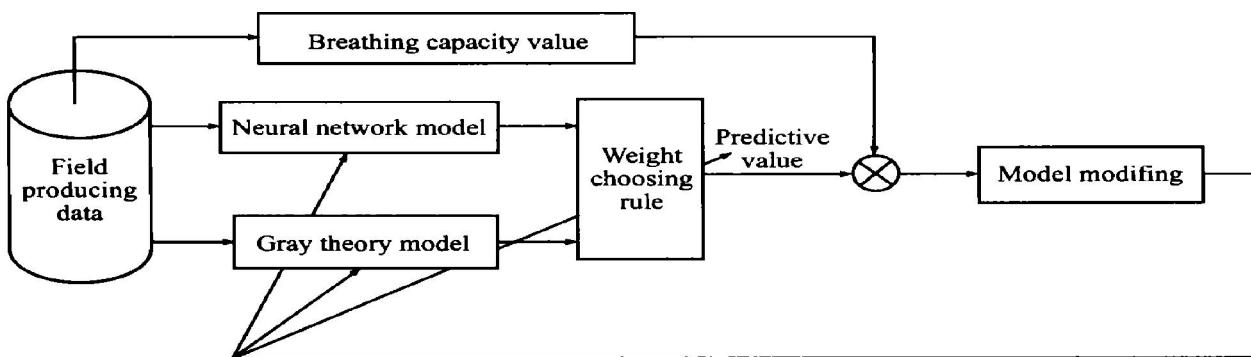


图 3 灰色理论和神经网络模型的集成形式

Fig. 3 Integration form of neural network model and grey theory model

$e(i) = y(i) - \hat{y}(i), i = 1, 2, \dots, n, n+1$
可得

$$e(i) = y(i) - \hat{y}(i) = k_2 e_1(i) + (1 - k_1) e(i) \quad (15)$$

再令

$$e_1(i) = y(i) - \hat{y}_1(i), i = 1, 2, \dots, n$$

$$e_2(i) = y(i) - \hat{y}_2(i), i = 1, 2, \dots, n$$

$$e(i) = y(i) - \hat{y}(i), i = 1, 2, \dots, n$$

由于 e_1, e_2, e 均为随机变量, 故

$$D(e) = k_1^2 D(e_1) + (1 - k_1)^2 D(e_2) + 2k_1(1 - k_1) \cdot V_c(e_1, e_2) \quad (16)$$

为求方差 $D(e)$ 之最小值, 由极值原理知方差 $D(e)$ 最小值必产生在驻点, 故由 $\frac{dD(e)}{dk_1} = 0$ 可得

$$k_1^1 = \frac{D(e_1) - V_c(e_1, e_2)}{D(e_1) + D(e_2) - 2V_c(e_1, e_2)} \quad (17)$$

取 $k_1 = k_1^1$ 时, 组合预测模型与实际值的拟合偏差的方差最小。

由于当随机变量 X 和 Y 相互独立时, 其协方差为零, 而两模型 $\hat{y}_1(i)$ 和 $\hat{y}_2(i)$ 是独立建立的, 由误差分析理论可认为偏差 e_1 与 e_2 相互独立, 可忽略其协方差 $V_c(e_1, e_2)$, 从而有

$$k_1^1 = \frac{D(e_1)}{D(e_1) + D(e)_2}$$

故两模型的组合优化模型为

$$\hat{y}(i) = \frac{D(e_2)\hat{y}_1(i) + D(e_1)\hat{y}_2(i)}{D(e_1) + D(e_2)} \quad (18)$$

将前述灰色理论和神经网络所建的模型结果综合在一起, 选取了其中相同的一段数据(264组), 通过上述的方法求得作用系数为0.4312, 建立综合模型为

$$\hat{y}(i) = 0.4312^* \hat{y}_1(i) + 568.8\hat{y}_2(i) \quad (19)$$

仿真的结果如图4所示。神经网络模型的预测误差

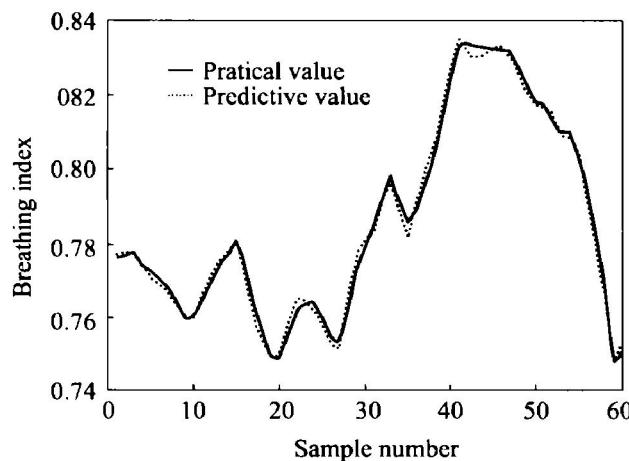


图4 综合模型仿真结果

Fig. 4 Integrated model simulation result

绝对值为0.016, 相对值为2.01%。灰色模型仿真的预测误差绝对值为0.0138, 相对值为1.78%。集成模型预测误差绝对值为0.002, 相对值为0.25%。

由此可以看出, 综合模型的预测准确度要好于灰色理论模型和神经网络模型。

5 结论

依据所掌握的密闭鼓风炉历史数据和先验知识, 建立了基本可行的基于灰色理论的密闭鼓风炉透气性指数预测模型, 同时提出一种基于神经网络密闭鼓风炉透气性测指数预测模型。综合灰色理论和神经网络各自的特点, 提出了自适应模糊组合式模型, 采用并联形式将两者有机结合, 并通过专家推理进行集成协调与更新修正, 实现密闭鼓风炉的透气性可靠、准确的预测。仿真和工业应用结果表明, 提出的模型能很好实现密闭鼓风炉透气性预测, 使铅锌产量有了显著的提高。

REFERENCES

- [1] Funahashi K I. On the approximate realization of continuous mappings by neural networks[J]. Neural Networks, 1989(2): 183-192.
- [2] CHEN S, Billings S A. Neural networks for nonlinear dynamic system modeling and identification[J]. Int J Control, 1992, 56(2): 319-346.
- [3] WU Min, Nakano M, SHE Jin-hua. A model-based expert control strategy using neural networks for the coal blending process in an iron and steel plant[J]. Expert Systems with Applications, 1999(16): 271-281.
- [4] WANG Ya-lin, GUI Wei-hua, CHEN Xiao-fang, et al. Neural network modeling for composition prediction of Pb-Zn sinter in imperial smelting process[A]. Proceedings of the Annual Chinese Automation Conference in the UK[C]. Derby, England, 1999. 21-24.
- [5] 王旭东, 邵惠鹤. 基于神经网络的通用软测量技术[J]. 自动化学报, 1998, 24(5): 702-706.
- WANG Xu-dong, HAO Hu-huo. General soft-measuring technology based on neural network[J]. Acta Automatica Sinica, 1998, 24(5): 702-706.
- [6] 罗荣福, 邵惠鹤. 分布式网络局部学习方法及其在推断控制中的应用[J]. 自动化学报, 1994, 20(6): 739-742.
- LUO Rong-fu, SHAO Hu-huo. Distributing network local learning method and its application in inference control

- [J]. Acta Automatic Sinica, 1994, 20(6): 739 - 742.
- [7] Pedrycz W. Conditional fuzzy clustering in the design of radial basis function neural networks[J]. IEEE Trans on Neural Networks, 1998, 9(4): 601 - 612.
- [8] Chen C L, Chen W C, Cheng F Y. Hybrid learning algorithm for Gaussian potential function network[J]. IEE Proceedings-D, 1993, 140(6): 442 - 448.
- [9] Hagan M T, Demuth H B, Beale M H. Neural Network Design[M]. Boston: PWS Press, 1996.
- [10] 毕效辉, 姚琼荟. 灰色预测在过程控制中的应用[J]. 西南工学院学报, 1997(3): 35 - 38.
- BI Xiaohui, YAO Qionghui. Predictive application of grey theory in process control[J]. Journal of Southwest Institute of Technology, 1997(3): 35 - 38.

Predicative model based on neural network and gray theory for imperial blast furnace breathing capacity

TANG Zhao-hui, GUI Wei-hua, WU Min, CHEN Xiao-fang

(College of Information Science & Engineering,

Central South University, Changsha 410083, China)

Abstract: Based on gray theory and neural network, the breathing capacity predication model of an imperial blast furnace was constructed by self-adaptive integration technology according to the melting process in an imperial blast furnace. Simulation and industry application results show that the predictive model can realize accurate predication of the breathing capacity for imperial blast furnace, which leads to a notable increase of plumbum and zinc output.

Key words: imperial blast furnace melting process; breathing capacity; predictive model; neural networks; gray theory; self-adaptive fuzzy combination

(编辑 晏绍明)