

文章编号: 1001-0920(2006)11-1312-04

基于主成分分析的动态神经网络预报方法及其应用

王玉涛¹, 严其艳¹, 杨 钢, 徐万仁²

(1. 东北大学 信息科学与工程学院, 沈阳 110004; 2 宝山钢铁股份有限公司 技术中心, 上海 200941)

摘要: 提出一种基于主成分分析法(PCA)和改进型多步Elman网络的实时预报方法。该方法能够在保留大量原始数据信息的前提下,消除样本数据间相关性,简化网络结构,通过动态递归算法实现复杂非线性系统实时预报。将该网络应用于宝钢某高炉铁水含硅量的预报,以 ± 0.05 作为预报误差,预报命中率达到88.17%。

关键词: 主成分分析法; 改进型多步Elman网络; 动态递归算法; 含硅量预报

中图分类号: TP183

文献标识码: A

Predictive Dynamic Neural Network Method Based on Principal Component Analysis and Its Application

WANG Yu-tao¹, YAN Qi-yan¹, YANG Gang¹, XU Wan-ren²

(1. College of Information Science and Engineering, Northeastern University, Shenyang 110004, China; 2 Baosteel Technology Center, Baoshan Iron and Steel Co., Ltd., Shanghai 200941, China. Correspondent: WANG Yu-tao, Email: wangyutao@mail.neu.edu.cn)

Abstract: A real-time prediction method based on principal component analysis (PCA) and improved multi-step Elman net is presented. With most original data information, this method eliminates the relativities among data and simplifies the net structure by processing the sample data with PCA. It can predict complex and nonlinear system with dynamic recurrent algorithm. The hit rate reached 88.17% to forecast the silicon content of a blast furnace on Bao Steel with errors ranging ± 0.05 .

Key words: PCA; Improved multi-step Elman net; Dynamic recurrent algorithm; Prediction of the silicon content

1 引言

神经网络是一种模仿生物大脑的信息处理方法,目前已在诸多领域得到广泛应用^[1,2]。它以其良好的非线性品质及灵活有效的学习方式,成为非线性系统建模和预报的研究热点问题。对于复杂非线性系统,由于其影响因素众多且存在强波动性和耦合性,造成训练样本间相关性大、样本选取困难及网络结构复杂。经研究证明,这些问题直接影响网络的训练速率及预报精度,是神经网络解决复杂非线性系统预报问题的难点^[3]。

本文提出一种具有动态递归特性的改进型多步Elman网络结构及其算法。历史数据的处理对于强

波动、大滞后非线性系统的预报性能尤为重要。本方法在标准Elman网络结构基础上,引入输出层反馈连接及连接增益可调的自反馈连接,使网络具有存贮和处理历史数据信息的能力,以提高网络的动态适应性,解决系统参数强波动性、大滞后问题;同时采用PCA对原始数据样本进行分析处理,产生新的维数降低、分量间相关性小的样本空间,作为改进型多步Elman网络的输入,以解决系统参数众多且存在强耦合性的问题。

将本文提出的方法应用于高炉铁水含硅量预报问题。预报时,综合考虑影响高炉铁水含硅量各工艺参数的不同时间滞后性,追溯影响当前时刻预报值

收稿日期: 2005-09-29; 修回日期: 2005-11-25

基金项目: 辽宁省自然科学基金项目(20042020)。

作者简介: 王玉涛(1970—),女,沈阳人,副教授,博士后,从事神经网络、软测量等研究;严其艳(1981—),女(土家族),湖南湘西人,硕士,从事神经网络、专家系统等研究。

的历史数据 同时, 针对相邻两次预报时间间隔较长的问题, 引入多步预报的方法 对宝钢某高炉数据样本进行铁水含硅量预报实验, 预报误差按 ± 0.05 计, 预报命中率达到 88.17%.

2 基于 PCA 的数据处理方法

PCA 是一种将高维数据投影到一个包含原空间大部分信息的低维空间的多变量统计技术^[4]. 经 PCA 处理得到的各主成分实际上是输入参数矩阵中具有极大方差的列向量组合. 由于方差很小的主成分通常代表的是噪声信息, 将这些主成分舍弃并不会引起数据中有用信息的明显损失. 对高度耦合系统而言, 少数几个主成分就可包含原变量的大部分信息, 用保留的主成分代替原变量, 可达到减少变量个数, 简化计算的目的. 根据样本数据集的协方差矩阵的特征值确定各主成分的方差贡献率和累积方差贡献率时, 可由如下两公式计算:

$$\eta_i = \lambda_i / \left(\sum_{i=1}^m \lambda_i \right), \quad (1)$$

$$\eta_k = \left(\sum_{i=1}^k \lambda_i \right) / \left(\sum_{i=1}^m \lambda_i \right). \quad (2)$$

其中: η_i 为第 i 个主成分的方差贡献率, η_k 为前 k 项主成分的累积方差贡献率. 目前, 一般以前 k 项主成分的累积方差贡献率 85% 作为界限, 此时前 k 项的累积方差贡献率已反映了原变量的大部分信息. 因此, 可选择前 k 项主成分组成新的样本集作为改进型多步 Elman 网络的输入, 从而减少网络输入节点个数及消除输入变量间的相关性. 由此可见, 对于参数众多且具有强耦合性的复杂非线性系统预报问题, 可采用基于 PCA 的数据处理方法.

3 改进型多步 Elman 网络模型及学习算法

标准 Elman 网络是一种典型的反馈神经网络, 它是在前馈网络结构的基础上, 增加隐层输出反馈连接作为输入, 构成关联层, 使隐层输出的过去状态与网络输入一起作为隐层下一时刻的输入, 通过存储内部状态使其具备映射动态特性的功能, 进而提高网络适应时变特性的能力. 因此, 训练好的标准 Elman 网络具备非线性映射和动态特性, 从而得到网络的动态结构和系统的动力学模型^[5].

3.1 改进型多步 Elman 网络模型建立

标准 Elman 网络属于部分递归网络, 它对历史数据的记忆有限且不可控, 当系统非线性特性增强或隐层节点个数增加时, 逼近精度不能满足要求. 因此, 本文提出一种改进型多步 Elman 网络, 网络结构如图 1 所示. 该网络是对标准 Elman 进行改进得到的, 即在隐层反馈关联层增加一个增益为 α 的自反馈连接, 与隐层反馈连接一起构成关联层 1; 同时

增加关联层 2, 把预报的输出反馈作为输入, 并与增益为 γ 的自反馈连接一起构成关联层 2, 以存储和记忆网络的输出, 满足多步预报需要.




图 1 改进型多步 Elman 网络结构

设网络的关联层 1 及隐层的节点数目为 n , 外部输入的节点数目为 r , 关联层 2 及输出层的节点数目为 m , 关联层 1 输出记为 $x_{c,l}^1(k)$, $l = 1, 2, \dots, n$, 外部输入记为 $u_q(k)$, 外部输入的输出生记为 $x_q(k)$, 且 $x_q(k) = u_q(k)$, $q = 1, 2, \dots, r$. 关联层 2 的输出记为 $x_{c,p}^2(k)$, $p = 1, 2, \dots, m$, 隐层输出记为 $h_j(k)$, $j = 1, 2, \dots, n$, 网络输出记为 $y_i(k)$, $i = 1, 2, \dots, m$. 设 $W^1_{n \times n}, W^2_{n \times r}, W^3_{n \times m}, W^4_{m \times n}$ 分别是关联层 1 到隐层、输入层到隐层、关联层 2 到隐层及隐层到输出层的连接权矩阵, 则该网络数学模型可表示如下:

$$x_{c,l}^1(k) = h_l(k-1) + \alpha x_{c,l}^1(k-1), \quad (3)$$

$$x_{c,p}^2(k) = y_p(k-1) + \gamma x_{c,p}^2(k-1), \quad (4)$$

$$h_j(k) = f \left(\sum_{i=1}^n w_i^1 x_{c,i}^1(k) + \sum_{i=1}^r w_i^2 u_i(k) + \sum_{i=1}^m w_i^3 x_{c,i}^2(k) \right), \quad (5)$$

$$y_i(k) = \sum_{i=1}^n w_i^4 h_i(k). \quad (6)$$

式中: $i = 1, 2, \dots, m; j = 1, 2, \dots, n; l = 1, 2, \dots, n; p = 1, 2, \dots, m$. α, γ 为自反馈增益系数, $f(\bullet)$ 为隐层 sigmoid 函数.

观察该数学模型表达式并与标准 Elman 网络相比可知, 该模型表达式的式 (3) 中加入 $\alpha x_{c,l}^1(k-1)$ 项且增加了式 (4). 由式 (3) 可知, 关联层 1 在 k 时刻的输出为隐层 $k-1$ 时刻输出与关联层 1 的 $k-1$ 时刻输出的 α 倍之和, 因此式 (3) 可表示为

$$x_{c,l}^1(k) = h_l(k-1) + \alpha x_{c,l}^1(k-1) = f \left(\sum_{i=1}^n w_i^1 (k-1) x_{c,i}^1(k-1) + \sum_{i=1}^r w_i^2 (k-1) u_i(k-1) + \sum_{i=1}^m w_i^3 (k-1) x_{c,i}^2(k-1) \right) + \alpha x_{c,l}^1(k-1)$$

$$\sum_{i=1}^m w_i^3(k-1)x_{c,i}^2(k-1) + \alpha h_i(k-2) + \alpha^2 x_{c,i}^1(k-2). \quad (7)$$

由于 $x_{c,i}^1(k-1) = h_i(k-2) + \alpha x_{c,i}^1(k-2)$ 可继续展开, 所以 $x_{c,i}^1(k)$ 的值依赖于历史各个时刻的 $W^1(k-1), W^2(k-1), W^3(k-1), \dots, W^3(1)$. 同理对式(4)展开有同样的结论. 可见网络通过引入关联层, 达到了存储历史数据的功能. 同时, 可调整 α 和 γ 值来控制网络对历史数据的记忆能力, 加强模型的动态适应性.

3.2 改进型多步 Elman 网络学习算法

设 $y_i^d(k)$ 为实际值, $y_i(k)$ 为预报值, $\eta_1, \eta_2, \eta_3, \eta_4$ 为网络学习率, 则该网络连接权调整算法为

$$\Delta w_{j,l}^1 = \eta_1 \sum_{i=1}^m (y_i^d(k) - y_i(k)) \cdot w_{i,j}^4 \frac{\partial h_i(k)}{\partial w_{j,l}^1}, \quad (8)$$

$$\Delta w_{j,q}^2 = \eta_2 \sum_{i=1}^m (y_{d,i}(k) - y_i(k)) w_{i,j}^4 \cdot f_j \left(\sum_{i=1}^n w_i^1 x_{c,i}^1(k) + \sum_{i=1}^r w_i^2 u_i(k) + \sum_{i=1}^m w_i^3 x_{c,i}^2(k) \right) \cdot u_q(k), \quad (9)$$

$$\Delta w_{j,p}^3 = \eta_3 \cdot \sum_{i=1}^m (y_i^d(k) - y_i(k)) \cdot w_{i,j}^4 \frac{\partial h_i(k)}{\partial w_{j,p}^3}, \quad (10)$$

$$\Delta w_{i,j}^4 = \eta_4 \cdot (y_i^d(k) - y_i(k)) \cdot h_j(k), \quad (11)$$

$$\frac{\partial h_i(k)}{\partial w_{j,l}^1} = f_j \left(\sum_{i=1}^n w_i^1 x_{c,i}^1(k) + \alpha \frac{\partial h_i(k-1)}{\partial w_{j,l}^1} + \sum_{i=1}^r w_i^2 u_i(k) + \sum_{i=1}^m w_i^3 x_{c,i}^2(k) \right) \cdot h_i(k-1), \quad (12)$$

$$\frac{\partial h_i(k)}{\partial w_{j,p}^3} = f_j \left(\sum_{i=1}^n w_i^1 x_{c,i}^1(k) + \gamma \frac{\partial h_i(k-1)}{\partial w_{j,p}^3} + \sum_{i=1}^r w_i^2 u_i(k) + \sum_{i=1}^m w_i^3 x_{c,i}^2(k) \right) \cdot h_i(k-1), \quad (13)$$

$$\sum_{i=1}^r w_i^2 u_i(k) + \sum_{i=1}^m w_i^3 x_{c,i}^2(k) \cdot h_p(k-1). \quad (13)$$

式中: $i = 1, 2, \dots, m; j = 1, 2, \dots, n; l = 1, 2, \dots, n; q = 1, 2, \dots, r; p = 1, 2, \dots, m$. 由式(12)和式(13)可知, 梯度 $\partial h_j(k)/\partial w_{j,l}^1, \partial h_j(k)/\partial w_{j,p}^3$ 的计算是动态递归的, 由于初始的 $h_j(0)$ 为常数, 所以 $\partial h_j(0)/\partial w_{j,l}^1 = 0, \partial h_j(0)/\partial w_{j,p}^3 = 0$. 因此, 通过渐近递归计算可得到网络的权值修正.

4 应用实例

本文将改进型多步 Elman 网络学习算法用于高炉铁水含硅量预报. 高炉冶炼是一个典型的复杂非线性过程, 包含着封闭、复杂的物理和化学变化, 而铁水含硅量是反映高炉炉热状态的重要指标, 因此, 高炉铁水含硅量的精确预报对高炉稳定运行、生产优质低耗具有重要意义^[6].

4.1 基于 PCA 的数据处理实验

在宝钢某高炉, 影响高炉铁水含硅量的主要工艺参数有风温、鼓风湿分、 η_{in} 、喷煤量、热负荷、风压、富氧量、 K 值、送风流量等. 它们之间具有一定的相关性, 且它们对铁水含硅量的影响都存在一定的时间滞后性. 本文采用该高炉在 2004-09-26 ~ 2006-10-11 现场连续采集的铁水含硅量及其相应的工艺参数数据作为数据样本.

各工艺参数的响应滞后时间各不相同(从几分钟到几小时不等), 因此本文在进行基于 PCA 的数据样本分析处理时, 根据各工艺参数的滞后时间, 追溯 n 分钟或 n 小时之前的历史数据. 采用 PCA 对上述工艺参数的数据样本进行分析处理, 求解样本数据集的协方差阵的特征值 λ 和特征向量 $v_i (i = 1, 2, \dots, 9)$, 结果如表 1 所示. 根据式(1)和式(2), 计算出各主成分的方差贡献率及累积方差贡献率如表 2 所示.

由表 2 可知, 以 85% 作为界限, 前 4 项的累积方差贡献率 89.89% > 85%, 反映原来工艺参数的大

表 1 协方差阵的特征值和特征向量

	0.022 2	- 0.275 1	- 0.383 7	- 0.480 3	- 0.074 7	- 0.514 1	0.248 8	0.432 1	- 0.165 4
	0.053 0	0.632 2	0.355 5	0.225 6	0.033 4	- 0.240 2	0.104 3	0.512 7	- 0.296 2
	- 0.113 2	- 0.379 1	- 0.301 1	0.586 9	- 0.073 1	0.156 5	- 0.354 7	0.423 3	- 0.271 4
	0.128 8	0.004 0	0.029 2	- 0.075 8	- 0.729 1	0.495 1	0.410 9	0.111 5	- 0.136 9
特征向量	- 0.221 3	0.252 6	- 0.370 1	- 0.246 9	0.511 8	0.543 1	0.176 3	0.084 9	0.306 6
	0.680 3	0.124 7	- 0.284 9	0.087 2	- 0.004 3	- 0.121 9	- 0.100 1	- 0.392 5	- 0.503 9
	- 0.051 5	0.127 6	0.146 8	- 0.528 5	- 0.234 6	0.129 4	- 0.752 6	0.106 5	- 0.175 2
	- 0.668 4	0.077 5	- 0.033 0	0.085 8	- 0.251 4	- 0.270 1	0.070 1	- 0.431 5	0.460 0
	0.078 4	- 0.528 4	0.627 8	- 0.114 2	0.275 8	0.094 2	0.142 0	- 0.004 1	- 0.449 8
特征值	0.052 6	0.128 2	0.242 9	0.252 2	0.315 0	1.366 9	1.574 0	2.458 1	3.410 3

表 2 各主成分的方差贡献率及累积方差贡献率

主成分	特征值	方差贡献率 /%	累计方差贡献率 /%
第 1 主成分	3.4103	34.80	34.80
第 2 主成分	2.4581	25.08	59.88
第 3 主成分	1.5740	16.06	75.94
第 4 主成分	1.3669	13.95	89.89
第 5 主成分	0.3150	3.21	93.10
第 6 主成分	0.2522	2.57	95.67
第 7 主成分	0.2429	2.48	98.15
第 8 主成分	0.1282	1.31	99.46
第 9 主成分	0.0526	0.54	100

部分信息,因此可选择第 1 主成分到第 4 主成分组成新的样本集作为改进型多步 Elman 网络的输入

4.2 基于改进型多步 Elman 网络的预报实验

由于相邻两次出铁的时间间隔平均为 2 h,在此期间有的工艺参数已产生较大变化(如风压),为提高预报精度,本实验采用多步预报的方法。每步的含硅量数据通过对每炉的铁水含硅量进行插值得到。根据实验分析,选取 20 min 作为一步,因此每炉的数据大致可分为 6 步,即多步预报的步数为 6,网络输出层节点个数为 6。

网络的输入采用经 PCA 处理后的前 4 项主成分,则输入节点数为 4。通过实验,隐层节点个数设为 10 可较好地进行训练和预报。关联层 1 节点个数等于隐层节点个数,即为 10;关联层 2 节点个数等于输出层节点个数,即为 6。由此可见,网络节点数目较少,网络结构比较简单。

实验时,学习率 η , η_1 , η_2 , η_3 均设为 0.1,经 PCA 进行数据处理后网络结构得到简化,迭代耗费时间大大缩短。采用较小的学习率对训练速率影响较小,并有利于提高训练好的网络预报精度。自反馈增益 α 设为 0.7, γ 设为 0.5,网络初始权值取 $[-0.5, 0.5]$ 之间的随机数。取 2004-09-26 的 0:00 ~ 2004-09-30 的 4:00 的连续 50 炉数据作为训练样本,采用上述网络模型进行训练,训练迭代 250 次(时间为 2.1 s)可使全局误差小于设定的误差(误差平方和 0.01)。此时,训练计算的误差平方和为 0.0055。其迭代次数比标准 Elman 网络在相同条件下解决该问题至少要迭代训练 5 000 次(时间为 3 min 左右)以上明显减少。

图 2 给出了 2004-10-01 的 0:00 ~ 2004-10-11 的 0:00 的连续 120 炉高炉铁水含硅量预报结果。以绝对误差不大于 0.05 统计,预报命中率达到 88.17%。可见基于 PCA 和改进型多步 Elman 网络进行预报的预报值和实际值有良好的对应关系。




图 2 改进型多步 Elman 网络预报结果

5 结 语

本文针对复杂非线性系统的动态预报问题,提出改进型多步 Elman 网络预报方法进行实时预报。该网络在标准 Elman 网络基础上,对隐层反馈连接关联层增加增益可调的自反馈,同时增加网络输出反馈连接与增益可调的自反馈关联层,提高网络的动态适应性,满足多步预报需要。

本文考虑复杂非线性系统参数之间的相关性和强耦合性,采用 PCA 对原始数据进行分析处理,在保留原始数据中所包含的大部分信息的前提下压缩数据维数,保证网络预报模型的简洁与高效。

该网络采用动态递归算法进行预报,通过网络训练,具有适应结构非线性和不确定性的能力,能够直接、生动地反映系统的动态特性,弥补了目前常用静态神经网络预报方法及标准 Elman 网络预报复杂非线性系统中存在的不足。

将该网络模型应用于宝钢某高炉铁水含硅量的预报,实验结果证明本方法网络结构简化,训练迭代次数比标准 Elman 网络显著减少,训练速率加快,预报精度较高。由此可见,该网络可较好地预报复杂非线性系统,是一种具有发展前途的实时预报方法。

参考文献(References)

- [1] Zhang G P, Qi M. Neural Network Forecasting for Seasonal and Trend Time Series [J]. *European J of Operational Research*, 2005, 160(2): 501-504.
- [2] Chen J. A Predictive System for Blast Furnaces by Integrating a Neural Network with Qualitative Analysis [J]. *Engineering Applications of Artificial Intelligence*, 2001, 14(5): 77-85.
- [3] Pham D T, Liu X. Training of Elman Networks and Dynamic System Modelling [J]. *Int J of System Science*, 1996, 27(2): 221-226.
- [4] 何晓群. *现代统计分析方法与应用* [M]. 北京: 中国人民大学出版社, 1998: 51-68.
- [5] Shinichi K, Masakazu N. Recurrent Neural Network with Short-term Memory and Fast Structure Learning Method [J]. *Systems and Computers in Japan*, 2003, 34(6): 69-79.

(下转第 1320 页)

的解,而且求解速度快 同时还尝试采用随机选取初始解的方法,分别采用遗传算法(GA)和禁忌搜索算法(TS)对实例进行20次计算,计算费用分别为1 944.91和1 907.80,平均计算时间均大于1 s,可见,无论是解的质量还是收敛速度都比本文的方法差,说明采用扫描法求初始解是有效的

表4 禁忌搜索算法和遗传算法计算结果比较

	分 组	配送 点	平均计算 时间/s	费 用	基 地
GA	11, 12, 13, 14, 16, 17	11			
	22, 24, 26, 27, 28, 30	27			
	18, 20, 21, 23, 25, 29	20	0.43	1 890.9	B ₁
	3, 5, 6, 8, 15, 19	3			
	1, 4, 2, 7, 9, 10	4			
TS	11, 12, 13, 14, 16, 17	11			
	24, 26, 27, 28, 29, 30	27			
	18, 20, 22, 21, 23, 25	20	0.25	1 880.33	B ₁
	1, 3, 5, 6, 8, 15, 19	3			
	4, 2, 7, 9, 10	4			

7 结 语

本文针对铁路行包运输的特点,给出了优化行包基地及配送点选址规划的数学模型,将改进的扫描法和禁忌搜索算法结合起来求解,能够得到良好的计算结果,而且搜索空间小,求解速度快 因为扫描法来源于求解路径问题,所以本文的计算方法为配送路径研究奠定了良好的基础,对铁路行包公司规划行包基地和配送点的选址布局有着一定的意义 此外,铁路行包运输客户的需求是动态的,而本文是基于客户需求是静态的情况,因此,研究动态需求条件下的选址模型和算法,以及配送车辆的调度是下一步需要解决的问题

参考文献(References)

- [1] Cornujis G, Fisher M L, Nemheuser G L. Location of Bank Accounts to Optimize Float: An Analytic Study of Exact and Approximate Algorithms [J]. *Management Science*, 1977, 23(8): 45-56
- [2] Owen S H, Daskin M S. Strategic Facility Location: A

Review [J]. *European J of Operational Research*, 1998, 111: 423-447.

- [3] Klose A, Drexl A. Facility Location Models for Distribution System Design [J]. *European J of Operational Research*, 2005, 162: 4-29.
- [4] Aikens C H. Facility Location Models for Distribution Planning [J]. *European J of Operational Research*, 1985, 22(2): 1-19.
- [5] Revelle C S, Eiselt H A. Location Analysis: A Synthesis and Survey [J]. *European J of Operational Research*, 2005, 162: 423-447.
- [6] Gillett B, Miller L. A Heuristic Algorithm for the Vehicle Dispatch Problem [J]. *Operations Research*, 1974, 22: 340-349.
- [7] 夏洁, 高金源, 余舟毅. 基于禁忌搜索的启发式任务路径规划算法[J]. *控制与决策*, 2002, 17(增): 773-776 (Xia J, Gao J Y, Yu Z Y. Heuristics Decision Algorithm for Mission Path Planning Based on Tabu Search [J]. *Control and Decision*, 2002, 17(S): 773-776)
- [8] 刑文训, 谢金星. *现代优化计算方法*[M]. 北京: 清华大学出版社, 1999: 11-28 (Xing W X, Xie J X. *Computing Method of Modern Optimization* [M]. Beijing: Publishing House of Tsinghua University, 1999: 11-28)
- [9] Zhong Y, Cole M H. A Vehicle Routing Problem with Backhauls and Time Windows: A Guided Local Search Solution [J]. *Transportation Research Part E*, 2005, 41: 131-144.
- [10] 符卓. 带装载能力约束的开放式车辆路径问题及禁忌搜索算法研究[J]. *系统工程理论与实践*, 2004, 3: 124-127. (Fu Z. The Capacitated Open Vehicle Routing Problem and Its Tabu Search Algorithm [J]. *System Engineering Theory and Practice*, 2004, 3: 124-127.)
- [11] Rolland E, Schilling D A, Current J. An Efficient Tabu Search Procedure for the p-Median Problem [J]. *European J of Operational Research*, 1996, 96: 329-342.

(上接第1315页)

- [6] 王玉涛, 周建常, 王师. 神经网络与时差方法结合预报铁水含硅量[J]. *钢铁*, 1999, 34(11): 7-11 (Wang Y T, Zhou J C, Wang S. Application of Neural

Network Model and Temporal Difference Method to Predict the Silicon Content of the Hot Metal [J]. *Iron and Steel*, 1999, 34(11): 7-11)