

## 循环流化床锅炉燃烧过程建模研究

樊诚, 江青茵\*, 曹志凯, 周荣

(厦门大学化学化工学院化学工程与生物工程系, 福建, 厦门, 361005)

**摘要:** 针对具有多维非线性和纯滞后特性的循环流化床锅炉燃烧过程, 采用基于 PLS 学习算法和 OLS 学习算法的径向基函数 (RBF) 神经网络进行建模研究。首先通过循环流化床锅炉仿真平台产生用于建模实验的网络训练数据和泛化数据, 然后分别采用 OLS 算法和 PLS 算法进行网络训练和泛化研究, 最后讨论了影响建模结果的算法参数及其选取方法, 重点讨论了 PLS 算法的 4 个网络参数的影响和选取。与基于小波网络的建模实验比较, 对具有复杂特性的循环流化床锅炉燃烧过程, 采用 RBF 网络建模在保证建模精度的同时, 算法参数的选取也较为方便易行。

**关键词:** RBF 神经网络; 过程辨识; 循环流化床锅炉

**中图分类号:** TQ 015

**文献标识码:** A

**文章编号:** 1001-4160(2007)03-371-374

## Modeling of the combustion process of circulating fluidized bed boiler

Fan Cheng, Jiang Qingyin\*, Cao Zhikai and Zhou Rong

(Department of Chemical & Biochemical Engineering, College of Chemistry & Chemical Engineering, Xiamen University, Xiamen, 361005, Fujian, China)

**Abstract:** To get a online dynamic model of the combustion process of Circulating Fluidized Bed (CFB) Boiler which was difficult to be modeling because of its complex characteristics such as non-linear, time-delay, time-variation and multidimensional, the RBF network based on the PLS arithmetic and the OLS arithmetic was adopted. The data used as the network training samples and the data used in the generalization test of the network was produced by a CFB Boiler simulation system. The network training and generalization study was done by means of PLS arithmetic and OLS arithmetic individually. The arithmetic parameters, especially the parameters of PLS arithmetic were discussed to study their influence and selected methods. Contrasting to the online dynamic model of this process which was credited by the wavelet network, the model put forward in this paper keep the same precision and is more easily to select the parameters in the modeling.

**Key words:** RBF network, dynamic modeling, CFBB

Fan C, Jiang QY, Cao ZK and Zhou R. Modeling of the combustion process of circulating fluidized bed boiler. Computers and Applied Chemistry, 2007, 24(3):371-374.

### 1 引言

神经网络是用于复杂非线性系统辨识与模拟的有效工具<sup>[1,9]</sup>。常用的有 BP 网络、小波网络和径向基函数 (radial basis function, RBF) 网络。然而 BP 网络存在不足<sup>[2]</sup>, 主要是局部极小化问题和无法在线校正, RBF 网络和小波网络不存在这些缺点。RBF 神经网络在辨识方面已有实际应用, 文献[3]利用 RBF 网络成功地预测了羟胺反应器中氢离子浓度; 文献[4]将 RBF 网络用于常减压蒸馏装置的油品闪点和粘度的模型辨识; 文献[5]利用 RBF 网络对催化裂化过程转化率进行在线预估。以上应用证明 RBF 网络在工业过程建模方面的适用性。循环流化床 (circulating fluidized bed, CFB) 锅炉是目前燃煤设备的发展方向, 但其燃烧过程具有

强非线性、多变量耦合、大延迟等特性, 采用常规控制难以实现闭环控制。若采用模型预测控制, 由于循环流化床过程复杂, 机理建模困难, 同时对象特性多变, 因此需要寻求合适的、可在线修正的黑箱模型。文献[6]中提出一种用小波网络进行模型辨识的方法, 特点是可以实现网络模型的在线校正。RBF 网络同样具备在线校正网络的能力, 故本文采用 RBF 网络对 CFB 锅炉燃烧过程进行建模试验, 并与文献[6]的小波网络进行比较, 以期找到一种更合适的建模方法。

### 2 径向基函数网络简介

RBF 网络是 80 年代末提出的一种具有单隐层的三层前馈神经网络<sup>[5]</sup>, 是一种局部逼近网络。其隐层节点的激活函

收稿日期: 2006-02-21; 修回日期: 2006-10-08

基金资助: 福建省科技计划重点项目 (2005H044)

作者简介: 樊诚 (1981—), 男, 北京人, 硕士, 化学工程专业, 导师: 江青茵。

\* 通讯作者: 江青茵, 教授, 研究方向为流程先进控制及优化, E-mail: xdceds@xmu.edu.cn.

数是  $n$  维径向基函数  $\Phi_j^{(i)}(\mathbf{x}) = \Phi(\|\mathbf{x}^{(i)} - \mathbf{c}_j\|)$ ,  $j=1, \dots, n$ , 其中  $\mathbf{x}^{(i)}$  是第  $i$  个输入向量,  $\mathbf{c}_j$  是基函数的中心,  $\|\cdot\|$  是距离测度, 通常取为欧几里德距离。

RBF 网络的学习算法众多, 比较常用的是基于正交最小二乘(OLS)的学习算法和基于偏最小二乘(PLS)的学习算法。OLS 学习算法较为成熟, 是一种已经普遍应用的算法, 可参见文献[7]。PLS 算法是一种比较新的多元统计数据分析方法, 相关应用较少, 学习算法步骤如下[4]:

- (1) 将学习数据输入网络
  - (2) 设置学习宽度  $width$ 、主成分数  $f_n$ , 初始化聚类中心。
  - (3) 选中间节点数为训练样本总数  $P$ , 计算输入样本的隐层输出  $\Phi = [\Phi^{(1)} \Phi^{(2)} \dots \Phi^{(P)}]^T \in R^{P \times P}$ 。
  - (4) 根据学习数据提供的输出样本  $Y = [y^{(1)}, y^{(2)}, \dots, y^{(P)}]^T \in R^{P \times 1}$ , 求矩阵  $\Phi^T Y Y^T \Phi$  的最大特征值  $\lambda_1$ , 其对应的特征向量为  $\eta_1$
  - (5) 令  $t_1 = \Phi \eta_1 \in R^{P \times 1}$ ,  $P_1 = \Phi^T t_1 / \|t_1\|^2 \in R^{P \times 1}$ ,  $r_1 = Y - t_1 / \|t_1\|^2 \in R^{P \times 1}$ , 得到  $\Phi = t_1 P_1^T + \Phi_1$ ,  $Y = t_1 r_1 + Y_1$
  - (6) 对  $\Phi_1, Y_1$  重复 4, 5 两步  $f_n - 1$  次, 得到:  $\Phi = t_1 P_1^T + \dots + t_{f_n} P_{f_n}^T + \Phi_{f_n}$ ,  $Y = t_1 r_1 + \dots + t_{f_n} r_{f_n} + Y_{f_n}$
- $t_1, t_2, \dots, t_{f_n}$  即网络  $f_n$  个主成分,  $\Phi_{f_n}$  和  $Y_{f_n}$  为残差矩阵。 $Y = \Phi(\eta_1 r_1 + \dots + \eta_{f_n} r_{f_n}) + Y_{f_n}$ , 则网络输出为:  $Y = \Phi W + Y_{f_n}$ , 其中  $W = \eta_1 r_1 + \dots + \eta_{f_n} r_{f_n}$ ,  $W$  和  $Y_{f_n}$  就是网络的优化参数。经过学习的网络即可进行泛化, 泛化的步骤如下:

- (1) 设置泛化宽度  $width_t$ , 将泛化数据输入网络。
  - (2) 同上方法计算隐层输出  $\Phi = [\Phi^{(1)} \Phi^{(2)} \dots \Phi^{(Q)}]^T \in R^{Q \times Q}$ 。
  - (3) 将  $\Phi$  代入  $Y_m = \Phi W + Y_{f_n}$  即是网络输出。
- 为达到在线校正的目的加入递推最小二乘法校正步骤:
- (1) 设置校正遗忘因子  $c$ , 令  $P_1$  为  $\Phi^T \Phi$  的广义逆。
  - (2)  $K(k) = P(k-1) \Phi(k)^T [c + \Phi(k) P(k-1) \Phi(k)^T]^{-1}$ ,  $P(k) = [I - K(k) \Phi(k)] P(k-1) c^{-1}$ 。
  - (3)  $W(k) = W(k-1) + K(k) [Y(k) - Y_m(k)]$  即为校正后网络的优化权值。

### 3 建模实验

由于 OLS 算法已较为成熟, 而 PLS 算法是一种较新的学习算法, 故只对 PLS 算法进行建模试验验证。

为保持与工业过程系统特性相近, 选用如下动态系统(4 入 1 出):

$$y(t) = 0.5y(t-1) + u_1(t)(1 - 0.2y(t-1)^2) + u_1(t)^3 + u_2(t)(1 - 0.2y(t-2)^2) + u_2(t)^3$$

系统的输入为:

$$\mathbf{x}^T = [y(t-1) \quad y(t-2) \quad u_1(t) \quad u_2(t)], \text{ 其中}$$

$$u_1(t) = 0.3 \sin(2\pi t/25) + 0.1 \sin(\pi t/10), \quad u_2(t) = 0.3 \cos(2\pi t/25) + 0.1 \cos(\pi t/10), \quad y_1 = 0.5, \quad y_2 = 0.5$$

采用 500 个点作学习数据集, 200 个点作测试集。用基于 PLS 算法的 RBF 网络进行拟合, 得到的网络学习和泛化结果如图 1 图 2。图中实线为系统输出曲线, 虚线为网络输

出曲线。




Fig. 1 Learning curves.

图 1 学习曲线




Fig. 2 Generalization curves.

图 2 泛化曲线

以上结果表明, 基于 PLS 算法的 RBF 网络具有较好的建模精度和泛化能力。

## 4 循环流化床锅炉燃烧过程的建模实验

### 4.1 数据产生

该 CFB 锅炉的机理数学模型由文献[8]提出, 模型可简写为:

$$\mathbf{y}(k) = \mathbf{F}[\mathbf{y}(k-1), \mathbf{u}(k-1)] \quad (1)$$

其中  $\mathbf{y} = [y_1, y_2, y_3, y_4, y_5]^T$ ,  $\mathbf{u} = [u_1, u_2, u_3, u_4]^T$ ,  $\mathbf{F} = [f_1, f_2, f_3, f_4, f_5]$

$y_1, \dots, y_5$  为模型的输出量, 分别代表密相床料量(MCL)、密相温度(MT)、稀相床料量(XCL)、稀相温度(XT)、气包压力(P);  $u_1, \dots, u_4$  为模型的输入量, 分别代表给煤量、排渣量、一次风量、二次风量。

采用厦门大学海通 XD-APC 软件对该模型进行仿真求解, 产生试验数据。提取 500 组数据无量纲化后按 2:1 分成网络学习集和检测集。

### 4.2 建模试验

采用基于 PLS 算法的 RBF 网络, 对式(1)进行辨识。网络泛化无量纲化结果如图 3 所示, 其中实线为系统输出, 虚线为网络泛化。

由图中可见, 在忽略外界干扰的条件下, 基于 PLS 算法




Fig. 3 RBF generalization curves.  
图3 RBF网络泛化结果

的RBF网络可以得到满意的泛化效果。与之对比的基于OLS学习算法的RBF网络也得到类似的泛化效果(图略),两者的误差对比如表1所示。

由于以上模型建立时并未加入给煤量对炉床温度(包括稀相温度与密相温度)的滞后以及可能出现的随机干扰,为求模拟效果更接近工业状态,将模型修改为如下形式:

$$y(k) = F[y(k-1), u^*(k-1), u_1^*(k-4)] \quad (2)$$

其中,  $u^*(k) = u(k) + \xi(k)$ ,  $\xi(k)$ 为界限是  $u(k)$  稳态值  $\pm 5\%$  的高斯序列干扰;对于  $f_1, f_3, f_5, u_1^*(k-4) = 0$ 。

模型修改后产生数据,取300组为学习数据,200组为检测数据。对式(2)仍采用PLS算法进行建模实验,网络泛化结果如图4所示,其中实线为系统输出,虚线为网络泛化输出。




Fig. 4 RBF generalization curves.  
图4 网络泛化结果

从图中可看到,密相温度和稀相温度的泛化曲线在某些区间有抖动现象,这可能是由于加入高斯干扰造成的。试验证明,通过一阶滤波处理后,抖动现象得到了改善,滤波按下式进行:

$$y_{im}^*(k) = \alpha y_{im}(k) + (1 - \alpha) y_{im}(k-1), 0 < \alpha < 1, \text{其中} \alpha \text{为滤波参数。}$$

总的来说基于PLS算法的RBF神经网络的泛化效果还是比较令人满意的。基于OLS的RBF网络在此种情况下泛化效果(图略)较差,两种算法的误差对比见表1。

表1 PLS与OLS泛化误差表

Table 1 Generalization error of PLS and OLS.

泛化误差		MCL	MT	XCL	XT	P
模拟1	PLS	0.0356	0.0462	0.0317	0.0248	0.0427
	OLS	0.0322	0.0308	0.0340	0.0161	0.0495
模拟2	PLS	0.0131	0.0150	0.0186	0.0382	0.0145
	OLS	0.0236	0.2277	0.1722	0.3256	0.1552

### 4.3 网络参数选取的讨论

网络参数对结果有重要的影响。基于PLS算法的RBF网络有4个可调参数,分别是学习主成分数  $f_n$ 、学习宽度  $width$ 、泛化宽度  $widtht$  和遗忘因子  $c$ 。学习主成分数  $f_n$  指的是网络学习过程的迭代学习次数;学习宽度  $width$  和泛化宽度  $widtht$  分别指的是网络在学习和泛化过程中中间结点Gaussian函数的宽度参数  $\sigma_j$ ;遗忘因子  $c$  为  $< 1$  的正数,一般取值不宜过小,在  $0.9 \sim 1.0$  之间,否则在干扰较强时容易导致估计值剧烈波动,甚至发散。为研究各参数对于网络泛化效果的影响,不妨以密相温度  $y_1$  为例,分别在其他参数不变的前提下,改变某一参数值,并观察其变化与网络泛化均方根误差的关系。如图5所示:




Fig. 5 Discussion of how to select parameters.  
图5 网络参数选取讨论

从图5中我们看到,泛化均方根误差  $eerr$  对于  $f_n$  的值总体来说比较敏感,但是在  $f_n = 4 \sim 8$  时误差变化并不大,同时此段区域内误差值也比较小,也就是说在工作点附近误差值对于  $f_n$  值并不是很敏感,由于  $f_n$  值代表迭代学习次数,只能取为正整数,所以该值比较好确定,而且在工作点附近鲁棒性比较好;在  $width > 3 \times 10^{-4}$  时误差比较稳定,即在该区域内只要该参数的数量级不变,误差对于  $width$  不是很敏感,可以将工作点选择在该区域内以期网络可以得到比较强的鲁棒性;误差对于  $widtht$  不敏感,在  $widtht$  在很大区域内变化,误差变化很小;当  $c < 0.90$  时,如前所述,误差明显增大,甚至在个别点出现了不收敛的情况,而当  $0.91 < c < 1.0$  时,网络误差还是比较稳定,  $c$  值选取在该区域之间对网络鲁棒性和泛化能力都有好处。对于除密相温度  $y_1$  外,  $y_2, \dots, y_5$  的试验也都得到了类似的结果,就不在重复叙述。

基于OLS算法的RBF网络有两个可调参数,学习精度和Gaussian函数的宽度。本试验对于两个参数都不敏感,在很大范围内变化网络的泛化误差变化很小。

综上所述,对于本试验来说,基于 PLS 算法的 RBF 网络具有比较好的泛化能力和鲁棒性,4 个可调参数都比较好选定,而且对于网络的泛化结果影响不大,这就预示了该网络具有比较强的鲁棒性。基于 OLS 算法的 RBF 网络在加入随机干扰时的网络泛化精度方面不及 PLS 算法,但网络训练参数较容易确定。

#### 4.4 工业数据建模实验及与小波网络的比较

文献[6]给出了基于多分辨分析的正交小波网络的 CFB 锅炉燃烧过程的神经网络建模研究,建模试验得到了比较满意的结果。基于多分辨分析的正交小波网络可选参数有三个,分别是调整尺度空间可变参数  $R_a$ 、神经元中心  $b_n$  和中间节点数  $n$ 。 $n$  和  $b_n$  可以提前指定, $R_a$  需根据提前指定的  $n$  和  $b_n$  选取,选取时需要凭借经验或先验知识,虽然有两个可调参数可以提前指定,但是参数  $R_a$  的调整并无明显的规律可寻,较难确定,并且这些参数对网络辨识结果影响较大。小波网络与 RBF 网络对同一组工业数据进行学习泛化,学习数据与泛化数据采用同一系统两种工况下产生的数据,RBF 网络的泛化结果略好于小波网络,泛化结果如图 6 所示:




Fig. 6 RBF generalization curves.

图 6 RBF 网络泛化结果

由以上分析可看出,基于 OLS 和 PLS 算法的 RBF 网络与基于多分辨分析的正交小波网络具有类似的建模精度和泛化能力,但在网络参数的选取上,基于多分辨分析的正交小波网络更多地依赖经验和先验知识,较难确定。故在参数选取方面 RBF 网络更方便一些。

## 5 结论

具有复杂特性的 CFB 锅炉燃烧过程的辨识建模是 CFB 锅炉预测控制研究的基础,本文分别采用基于 PLS 算法和 OLS 算法的 RBF 网络作为辨识建模的工具,经过不同数据组合的建模实验比较,基于 PLS 算法表现了较好的泛化效果和鲁棒性,且网络的训练参数和泛化参数的选取较波网络更为容易。因此可选择基于 PLS 算法 RBF 网络作为 CFB 锅炉燃烧过程的建模工具,工业数据的建模实验验证了这一结果。

## References

- 1 Narendra KS and Parthasarathy K. Identification and control of dynamic systems using neural networks. *IEEE Trans, On Neural Networks*, 1990, 1(1):4-27.
- 2 Xu Lina. *Neural Network Control*. Beijing: Electronic Industrial Press, 2003.
- 3 Cai Ning, Li Sheng and Zhao Yingkai. Predictive control of nonlinear system based on RBF neural network. *Automation in Petro-Chemical Industry*, 2002, 5:31-33.
- 4 Wang Wenxin, Pan Li deng, Li Rong, Xu Yongxin and Wen Guanghui. Development of RBF neural network with double model structure and its application to atmospheric and vacuum distillation units. *Journal of Beijing University of Chemical Technology*, 2004, 31(4):91-94.
- 5 Chai Jie, Jiang Qingyin and Cao Zhikai. Function approximation capability and algorithms of RBF neural network. *Pattern Recognition and Artificial Intelligence*, 2002, 15(3):310-316.
- 6 Huang Xiao, Jiang Qingyin, Pan Xuehong, Fan Cheng and Cao Zhikai. Wavelet modeling for combustion process of circulating fluidized bed boiler. *Journal of Xiamen University (Natural Science)*, 2005, 7:525-529.
- 7 Chai Jie. Research on application of AI for optimal control system in FCCU. Xiamen University, 2002, 05:30-32.
- 8 She Wenwu. Simplified model and simulation of CFB boiler. Xiamen University, 2005, 06:90-102.
- 9 Wu Jianfeng, He Xiaorong and Chen Bingzhen. Modeling nonlinear dynamic chemical process base on artificial neural networks. *Computers and Applied Chemistry*, 2001, 18(2):105-110.