

循环流化床锅炉燃烧过程的小波建模研究

黄 啸¹, 江青茵^{1*}, 潘学红², 樊 诚¹, 曹志凯¹

(1. 厦门大学化学工程与生物工程系, 福建 厦门 361005)

2. 郑州新力电力有限公司, 河南 郑州 450000)

摘要: 针对高维非线性系统, 分析了基于多分辨分析的正交小波网络的建模能力, 并用于循环流化床锅炉燃烧过程的动态建模. 根据现场采集的实时数据进行网络训练和泛化实验, 理论分析和实验结果表明网络具有良好的辨识精度和泛化能力

关键词: 小波网络; 过程建模; 循环流化床锅炉

中图分类号: TK 220.22

文献标识码: A

文章编号: 0438-0479(2005)04-0525-05

循环流化床锅炉是目前燃煤设备的发展方向, 但它具有强非线性、多变量耦合、大延迟等特性, 其操作与控制远比一般锅炉更为复杂. 它的控制系统可分为汽水系统和燃烧系统两个相对独立的部分. 其中燃烧系统包括主蒸汽压力、炉床温度、炉膛负压等的控制, 主蒸汽压力和炉床温度的控制是难点. 原因之一是床内煤颗粒燃烧释放热量的特点和床层的热容量较大, 造成主蒸汽压力和床温对给煤量和送风量的响应的有较大滞后, 并呈现强非线性影响. 同时过程特性随燃煤品质的不同而变化; 原因二是给煤和送风量同时影响主蒸汽压力和床温, 使二者成为紧密的强耦合量. 对于燃烧系统的控制, 可以考虑采用模型预测控制, 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.

神经网络是用于非线性系统辨识与模拟的有效工具^[1]. 多层前向人工神经网络能够以任意精度逼近任何连续函数, 如基于 Sigmoid 函数的 BP 网络和基于径向基函数的 RBF 网络. 然而 BP 网络有以下不足^[2]:

1) 训练算法容易出现局部极小问题; 2) 算法收敛速度慢; 3) 网络隐层及节点数的选择, 尚需凭经验确定; 4) 需要离线学习, 无法进行在线辨识和校正. RBF 网络^[2-4]在非线形映射上采用径向基函数, 具有唯一最佳逼近的特性, 无局部最小问题, 但其网络隐层节点数目选定比较复杂, 尤其隐层节点的中心难求. 小波网络 (Wavelet Network, WN) 源于小波分解, 由 Q. Zhang 等^[5]于 1992 年提出, 是一种基函数网络. 因为小波基

函数良好的时频域局部特性, 弥补了传统 MLP 的缺陷, 小波网络具有学习收敛速度快以及模型结构紧凑等优点, 是近年来的研究热点^[6-11].




图 1 循环流化床锅炉各变量关系

Fig 1 Parameter relationship of CFBB

本文针对信号为低频的工业过程, 对一类小波网络^[8]进行了仿真研究和理论分析, 并采用现场采集的实时数据进行了网络训练和泛化试验.

1 小波网络

不失一般性, 可用如下的离散式表示多入单出动态过程:

$$y(t) = f[y(t-1), \dots, y(t-n_y), u(t-1-\tau), \dots, u(t-n_u-\tau)] \quad (1)$$

τ 为模型的滞后时间. $y \in R$, $u \in R^L$, 将 y , u 作为统一输入看待, 即令

$$x(t)^T = [y(t-1), \dots, y(t-n_y), u(t-1-\tau)^T, \dots, u(t-n_u-\tau)^T]^T$$

则有

$$y(t) = f(x(t)) \quad (2)$$

式中 $y \in R$, $x \in R^{n_y+L \times n_u}$, 而由小波逼近的基本原理可知, 对 $f(x) \in L^2(R)$, 可以统一用下式表示

收稿日期: 2004-04-01

基金项目: 厦门市科技计划项目 (3502Z20021090)

作者简介: 黄啸 (1979-), 男, 硕士.

* 通讯作者: xdcad@xmu.edu.cn




图 2 小波网络

Fig 2 Wavelet network

$$f(\mathbf{x}) = \sum_k c_k \phi_k(\mathbf{x}) \quad (3)$$

小波网络结构如图 2 所示, 与 BP 网不同, 中间节点 ϕ_k 为小波函数或尺度函数, k 为节点个数, $\mathbf{x}(t)$ 为输入向量. 已知学习数据集 $T_N = \{(\mathbf{x}_i, g(\mathbf{x}_i))\}_{i=1}^N$, $g(\mathbf{x}_i) \in L^2(R)$ 为待逼近的函数.

过程辨识可分为两步: 确定节点个数及节点函数 ϕ_k ; 确定 ϕ_k 后, 可得到集合 $S_N = \{(\phi(\mathbf{x}_i), g(\mathbf{x}_i))\}_{i=1}^N$, 由 S_N 按误差 $e_N(f, g) = \frac{1}{N} \sum_{i=1}^N (f(\mathbf{x}_i) - g(\mathbf{x}_i))^2$ 最小的原则选定最优的 c_k . 因 c_k 和 ϕ_k 为线性关系, 容易通过线性优化方法如最小二乘或者迭代的梯度下降法^[8]得到解, 并可通过递推最小二乘实时在线地更新权值, 实现在线辨识. 故问题重点转化为如何寻求中间节点及基函数. 根据所采用的小波理论不同, 基函数的选择不同, 中间节点的确定方法也不相同, 以下着重讨论其中一种基于多分辨分析的正交小波网络.

由多分辨分析可知对任意一函数 $f(\mathbf{x}) \in L^2(R)$, 可进行如下分解:

$$f(\mathbf{x}) = \sum_n \langle f, \varphi_{m0n} \rangle \varphi_{m0n}(\mathbf{x}) + \sum_{m \neq m0n} \langle f, \Psi_{mn} \rangle \Psi_{mn}(\mathbf{x}) \quad (4)$$

当尺度 m 足够大时, 忽略右端第二项表示的小波细节分量, 网络输出可以任意精度逼近 f . 即存在足够大的整数 M , 在 $m > M$ 时, 有 $\|f(\mathbf{x}) - \sum_n \langle f, \varphi_{m0n} \rangle \varphi_{m0n}(\mathbf{x})\| < \varepsilon \forall \varepsilon > 0$ 其中 $\|\cdot\|$ 是 $L^2(R)$ 上的范数, 所以有

$$f(\mathbf{x}) \approx \sum_k \langle f, \varphi_{M,k} \rangle \varphi_{M,k}(\mathbf{x}) = \sum_k c_k \varphi_{M,k}(\mathbf{x}) \quad (5)$$

实际信号的分辨率都是有限的, 由前面的理论分析可知对任一函数 $f(\mathbf{x}) \in L^2(R)$ 都可按式 (5) 用单一尺度下尺度函数的线性组合逼近. 问题的关键在于节点函数的选择, 对于给定的 M , 要覆盖函数支撑 $[-1/2$

$1/2]^d$ 的最少节点个数为 $K = (2^M + p)^d$, 其中 d 为输入维数, $p \geq 1$ 为小正整数. M 越大, 逼近精度越高, 但网络泛化能力会随之下降. 与单维情况相比, 多维情况下存在两个问题: “维数灾难” 和学习数据不足. 如一维情况下对某函数的拟合选取 $[0, 1]$ 中 32 个中间节点, 对五维而言则需要 $32^5 = 2^{25}$, 超过三千万个节点, 而多元回归分析中的样本容量 (学习数据集) 数必须大于解释变量 (这里为节点函数) 数, 所以要求的线性无关的学习数据也将非常巨大. 虽然文献 [8] 中指出可以采用主元分析法 (PCAR) 或者投影寻踪法 (PPR) 实现数据的降维, 但直接应用到工业实际中显然存在困难.

实际工业过程有效信号频率较低, 在精度要求不太高的条件下有可能实现其动态系统的逼近^[10-11], 但节点的确定算法需要改进. 根据文献 [11], 式 (5) 可进一步表示为:

$$f(\mathbf{x}) = \sum_n \langle f, \varphi_{M,n} \rangle \varphi_{M,n}(\mathbf{x}) = \sum_n \langle f, \varphi_{M,n} \rangle 2^{M/2} \varphi(2^M \mathbf{x} - n) = \sum_n \theta_n \varphi[R_a(\mathbf{x} - b_n)] \quad (6)$$

θ_n 为系数, 可通过最小二乘法计算得到; R_a 是调整尺度空间的可变参数; b_n 是神经元的中心; R_a, b_n 可通过以下步骤确定:

- 1) 归一化, 确定输入变量的变化范围;
- 2) 选定隐层神经元数目及节点中心. 将输入空间用 n_i 等分 (n_i 从小的整数开始), 将神经元置于等距的网格之上, 则神经元的总数为 $N = \prod n_i$;
- 3) R_a 从一小的初始值开始, 通过最小二乘法用学习集的数据估计权值参数. 并用检测集测试结果; 增加 R_a 的值直到结果令人满意为止;
- 4) 增加 n_i 的值重复 2、3 的步骤, 获得对检测集而言误差最小的最佳网络;

2 建模实验

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)

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

系统的输入为低频信号

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

$$u_1(t) = 0.3\sin(2\pi t/25) + 0.1\sin(\pi t/10),$$

$$u_2(t) = 0.3\cos(2\pi t/25) + 0.1\cos(\pi t/10),$$

采用 500 个点作学习数据集, 200 个点作测试集. 由式 (6) 按前面步骤选取 R_a, b_n , 得到的网络学习和泛化实




图 3 学习曲线
Fig 3 Learning curves




图 4 泛化曲线
Fig 4 Generalization curves

验的曲线如图 3 4 所示。

根据以上动态系统辨识结果, 基于多分辨分析的网络拟合效果理想, 而且泛化能力很好, 可调参数少, 只是可变参数 R_a 需要凭借经验或先验知识选取。

事实上, 对于低通过程而言, 基于多分辨分析的小波网络有良好的拟合表现并非偶然现象。从频率角度分析, 由小波基条件 $\int_{-\infty}^{+\infty} \phi(x) dx$ 知其频谱上具备带通特性, 且带宽随着分辨率的减小而减小。对于流化床这类以低频信号为主的化工过程, 只采用小波基函数进行逼近, 随着分辨率减小带宽趋于零, 要严格描述, 则需要大量甚至无穷多级小波基函数, 而多分辨分析小波网络对低通过程的拟合有量体裁衣的优势: 尺度函数具有低通特性, 并采用部分小波基函数补充细节信息。当逼近精度要求不高时, 在合适的分辨率下, 只用有低通特性的尺度函数的线性组合来模拟这样的低通过程是合理且经济的, 同时, 尺度函数的低通特性也可有效地过滤实际工业信号中的高频干扰, 因此能保证网络有良好的泛化性能。

3 循环流化床锅炉燃烧过程建模

将基于多分辨分析的网络用于循环流化床锅炉料床平均温度的预测。对象一为 35 吨的小锅炉并根据装置的特点 (一次风不可调), 选定给煤和回料作为控制量, 并选用压差、一次风表征燃烧状况。则动态系统的输入为 5 个变量: 压差、给煤控制 (滞后 9 步)、回料控制、料床平均温度 (滞后 1 步)、一次风; 输出变量为料床平均温度。采用工业现场数据, 600 组作学习集, 200 组作为测试集。建模结果如图 5 6 所示, 其中 *output1* 为 5 个输入变量 R_a 均相等的情况下得到; 考虑到压差和一次风频率较其余 3 个输入变量高, 采用双 R_a 得到曲线 *output2* 可以看出曲线 *output2* 较 *output1* 略好。实验表明在此处 R_a 差别的影响并不十分明显。

对象二为 220 吨锅炉, 系统运行较平稳。由于装置回料不可调, 并根据现场数据曲线分析。

采用如下输入变量: 锅炉主控 (滞后 12 步)、锅炉主控 (滞后 18 步)、床温平均 (滞后 1 步)、料层差压平均、风煤比。输出为料床平均温度。取某动态过程的 500 组数据为学习集, 另一动态过程的 600 组数据作




图 6 数据集 1 泛化曲线
Fig 6 Generation curves of bed temperature for industrial process data 1




图 5 数据集 1 学习曲线
Fig 5 Learning curves of bed temperature for industrial process data 1




图 7 数据集 2 温度学习曲线

Fig 7 Learning curves of bed temperature for industrial process data 2




图 8 数据集 2 温度泛化曲线

Fig 8 Generation curves of bed temperature for industrial process data 2




图 9 数据集 2 压力学习曲线

Fig 9 Learning curves of steam pressure for industrial process data 2




图 10 数据集 2 压力泛化曲线

Fig 10 Generation curves of steam pressure for industrial process data 2

为测试集,结果如图 7、8 所示。

过热蒸汽压力的预估:选取锅炉主控(加滞后)、料层差压平均、风煤比、一级减温水量、过热蒸汽压力(滞后 1 步)为输入变量;输出变量为过热蒸汽压力。数据集同上,结果如图 9、10 所示。

4 结 论

可以看到对以上 3 组工业数据的预估,小波网络都显示了良好的泛化效果,预测曲线与实际曲线趋势基本一致,只是略有偏移。这里的学习集和检测集是分别在不同工况下采集的。而在设定模型的时候,又将影响较小的二次风、引风、排渣等信号忽略,这些偏移很有可能是忽略这些输入造成的。可考虑通过一定的方法^[12]将这类非随机干扰去除,并可通过递推最小二乘法在线校正节点权值以适应工况的改变,而这是 BP 网做不到的。理论分析和实际应用都表明,本文介绍的

小波网络应用于高维非线性动态系统的建模具有良好的辨识精度和泛化能力,可以用于实际工业装置的动态建模。

参考文献:

- [1] Narendra K S, Parthasarathy K. Identification and control of dynamical systems using neural networks[J]. IEEE Trans On Neural Networks, 1990, 1(1): 4-27.
- [2] 徐丽娜. 神经网络控制[M]. 北京: 电子工业出版社, 2003.
- [3] 王旭东, 邵惠鹤. RBF神经网络理论及其在控制中的应用[J]. 信息与控制, 1997, 26(4): 272-284.
- [4] 柴杰, 江青茵, 曹志凯. RBF神经网络的函数逼近能力及其算法[J]. 模式识别与人工智能, 2002, 15(3): 310-316.
- [5] Zhang Q, Benveniste A. Wavelet networks[J]. IEEE Trans On Neural Networks, 1992, 3(6): 889-898.
- [6] Pati Y C, Krishnaprasad P S. Analysis and synthesis of feed

- forward neural networks using discrete affine wavelet transformations [J]. IEEE Trans On Neural Networks 1993, 4 (1): 73–85
- [7] Zhang Q. Using wavelet network in nonparametric estimation [J]. IEEE Trans On Neural Networks 1997, 8 (2): 227–236
- [8] Zhang Jun, Walter G G, Miao Yubq et al Wavelet neural networks for function learning [J]. IEEE Trans On Signal Processing 1995, 43 (6): 889–898
- [9] 崔锦泰, 著. 小波分析导论 [M]. 程正兴, 译. 西安: 西安交通大学出版社, 1995
- [10] 黄德先, 金以慧. 基于小波神经网络的通用多变量非线性系统辨识算法和应用 [J]. 控制理论与应用, 2001, 18 (增刊): 63–68
- [11] Huang Dexian, Jin Yuhui, Zhang Jie et al Nonlinear chemical process modeling and application in epichlorohydrin production plant using wavelet networks [J]. Chinese J Chem. Eng, 2002, 10 (4): 435–433
- [12] Li Mingzhong, Wang Fuli, Gao Furong. Identification and control of nonlinear processes in the presence of unmeasured load disturbances [J]. Ind Eng Chem. Res, 2001, 40 (2): 275–282

Wavelet Modeling for Combustion Process of Circulating Fluidized Bed Boiler

HUANG Xiao¹, JIANG Qing-yin^{1*}, PAN Xue-hong²,
FAN Cheng¹, CAO Zhikai¹

(1. Department of Chemical & Biochemical Engineering Xiamen University,
Xiamen 361005, China; 2. Xinli Electric Power Co. Ltd., Zhengzhou 450000, China)

Abstract Circulating Fluidized Bed Boiler (CFBB) has a splendid future among all kinds of coal burning furnaces. At the same time, how to control the CFBB is regarded as a challenging problem because of its strong nonlinear coupling multivariable, time delay and time-varying characters. Neural network-based predictive control, which takes neural networks as predictive model, has strong robustness in nonlinear MIMO process control and is recommended to be adopted in the CFBB control. The wavelet network, a type of feed forward basis function network, is chosen to build the nonlinear predictive model due to its fast convergence, small size and especially the linear relationship between its node outputs and weight coefficients which could be expediently adjusted online and this is very important in the CFBB control. In this paper, the orthogonal wavelet network is proposed in the dynamic modeling of the combustion process of CFBB, not only for it can effectively avoid the problem of ‘curse of dimensionality’, but for it has more significant identifying accuracy and smaller network size when adopted in the low-frequency chemical processes. The industrial data collected from two kinds of industrial processes are used as trained samples and predicted samples. Both theory analysis and application results show that the learning accuracy and the generalization capability of this wavelet network are satisfying.

Key words wavelet network; dynamic modeling; CFBB