

热力系统局部非线性模型辨识

董均华, 徐向东

(清华大学 热能工程系, 北京 100084)

摘要: 在多模型控制中, 局部模型大多数是基于线性模型, 其数量和精度影响多模型控制的效果。提出一种基于 RBF 神经网络的非线性模型辨识算法, 采用 G. B. Sentoni 等人提出的非线性模型结构^[2~3], 利用径向基函数(Radial Basis Function, RBF)神经网络的逼近能力, 实现热力系统非线性模型辨识。在 RBF 神经网络的学习过程中, 根据性能函数调节学习率, 可以加快学习的收敛过程。最后进行了仿真验证, 基于 2 个局部非线性模型的多模型控制系统与基于 5 个局部线性模型的多模型控制系统相比, 减少了切换时的震荡, 控制精度有所提高。试验结果表明, 该辨识算法能减少固定模型数量, 从而减少模型搜索时间, 并且能够提高模型预测精度。

关键词: 热力系统; 局部模型; 非线性; RBF 神经网络

中图分类号: TK223.7 文献标识码: A

引言

由于热力系统自身存在的非线性和不稳定性等特性, 在不同工况区域内具有明显不同的动态性能。有鉴于此, 我们利用多模型方法解决复杂热力系统动态建模和控制问题。

现有的多模型控制中^[1], 局部模型大多数是基于线性模型。虽然用分段线性来逼近非线性具有一定精度, 但是对于锅炉这样的复杂控制对象, 模型数目过少则不足以描述系统的动态性能, 而过多的模型又会造成计算上的浪费。如果通过适当的辨识方法获得更逼近热力系统的非线性模型的话, 不仅可以提高模型精度, 而且可以减少模型个数, 减少计算时间, 消除模型切换时的震荡。

1 非线性模型描述

非线性模型描述有多种形式, 不同形式对应了不同算法的实现。采用 G. B. Sentoni 和 Lorenz T. Biegler 等人提出的非线性模型结构(见图 1)^[2~3], 该模型可以近似大多数离散时不变、MISO 系统。其表达式如下:

$$\begin{cases} x_{k+1} = Ax_k + B_u u_k + B_v v_k \\ y_k = g(x_k) = Cx_k + f_{NN}(x_k) \end{cases} \quad (1)$$

其中: u_k —操作变量; v_k —可测扰动; x_k —输入; y_k —输出。

模型结构由线性动态部分和静态非线性映射两部分组成。线性模型辨识采用目前比较成熟的 Subspace 辨识算法^[4]。该模型结构无需对结构参数(阶数和纯延时)进行复杂的假设和调整, 可以对含时变阶次和时延的系统更有效地逼近, 同时对采样时间间隔的选择具有很强的鲁棒性; 非线性模型辨识采用 RBF 神经网络辨识算法, 以线性模型输出误差为训练目标。

2 RBF 神经网络辨识

由于 RBF 神经网络具有结构简单、训练速度快的特点, 因此局部模型的非线性补偿部分辨识采用三层 RBF 神经网络^[5]。针对 MISO 系统的 RBF 网络的基本结构如图 1 所示。设系统具有 r 个输入, 网络使用了 m 个 RBF 神经元。

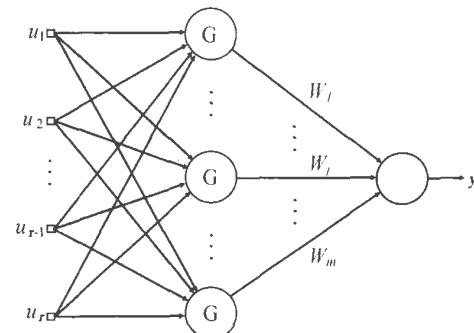


图 1 RBF 网络的基本结构

令 $u = [u_1, u_2, \dots, u_r]^T$ 分别为网络的输入向量, y 为网络的输出量,

$c_i = [c_{i1}, c_{i2}, \dots, c_{ir}]^T$ 为 RBF 基函数中心;

$\sigma_i = [\sigma_{i1}, \sigma_{i2}, \dots, \sigma_{ir}]^T$ 为 RBF 基函数宽度;
 $\{w_i(k) | i=1, 2, \dots, m\}$ 为 RBF 网络连接权值;
 φ_{ij} 为 RBF 网络的基函数形式。那么 RBF 网络

基函数输出可以写成:

$$\Phi_i[u(k), c_i, \sigma_i] = \prod_{j=1}^r \varphi_{ij}(u_j, c_{ij}, \sigma_{ij}) \quad (2)$$

则 RBF 网络可写成:

$$y(k) = \sum_{i=1}^m w_i(k) \Phi_i[u(k), c_i, \sigma_i] \quad (3)$$

取性能函数为:

$$J = (y(k) - y^*(k))^2 \quad (4)$$

其中: $y^*(k)$ 为 k 时刻的目标输出。由最速梯度法可得到神经网络参数的递推式:

$$\begin{aligned} \Delta w_i(k) &= -\alpha \frac{\partial J}{\partial w_i(k)} \\ \Delta c_{ij}(k) &= -\alpha \frac{\partial J}{\partial c_{ij}(k)} \\ \Delta \sigma_{ij}(k) &= -\alpha \frac{\partial J}{\partial \sigma_{ij}(k)} \end{aligned} \quad (5)$$

其中: α 为学习速率, 该算法是前馈神经网络的经典训练算法, 使参数的调整沿着性能函数下降的梯度方向进行优化, 所以, 通过一定时间的学习之后, 会使得神经网络的估计值和期望值越来越接近。但是由于学习速率 α 为常数, 当学习率 α 过大时, 容易造成学习过程的振荡; 如果学习率 α 取得过小, 又容易造成学习过程缓慢。因此本文采用性能函数修正各个可调参数的学习率:

$$\begin{aligned} \alpha_w &= \frac{\alpha_0 J_j^s}{(1+J_j)(\sum_{i=1}^m (\frac{\partial J_i}{\partial w_{ij}}))} \\ \alpha_c &= \frac{\alpha_0 J_j^s}{(1+J_j)(\sum_{i=1}^m \sum_{j=1}^r (\frac{\partial J_i}{\partial c_{ij}}))} \\ \alpha_\sigma &= \frac{\alpha_0 J_j^s}{(1+J_j)(\sum_{i=1}^m \sum_{j=1}^r (\frac{\partial J_i}{\partial \sigma_{ij}}))} \end{aligned} \quad (6)$$

其中: α_0 —初始的学习率, $s \in (0, 1)$ 。易知性能函数将按照如下的规律递减:

$$\begin{aligned} \frac{dJ_j}{dt} &= \sum_{i=1}^m \left(\frac{\partial J_i}{\partial w_{ij}} \frac{\partial w_{ij}}{\partial t} \right) + \sum_{i=1}^m \sum_{j=1}^r \left(\frac{\partial J_i}{\partial c_{ij}} \frac{\partial c_{ij}}{\partial t} \right) + \sum_{i=1}^m \sum_{j=1}^r \times \\ \left(\frac{\partial J_i}{\partial \sigma_{ij}} \frac{\partial \sigma_{ij}}{\partial t} \right) &= -\sum_{i=1}^m \left(\frac{\partial J_i}{\partial w_{ij}} \alpha_w \frac{\partial w_{ij}}{\partial t} \right) - \sum_{i=1}^m \sum_{j=1}^r \left(\frac{\partial J_i}{\partial c_{ij}} \alpha_c \frac{\partial c_{ij}}{\partial t} \right) - \\ \sum_{i=1}^m \sum_{j=1}^r \left(\frac{\partial J_i}{\partial \sigma_{ij}} \alpha_\sigma \frac{\partial \sigma_{ij}}{\partial t} \right) &= -\frac{3\alpha_0 J_j^s}{1+J_j} \end{aligned} \quad (7)$$

由式(6)可知, 只要选择适当的 α_0 并满足 $s \in (0, 1)$, 便可以做到学习率随性能函数变化。根据误差大小来调整学习率, 可以保证 RBF 网络在有限的

时间内收敛。

3 仿真实验验证

利用 220 t/h 煤粉炉仿真平台, 选取减温水流量、给水流量、给粉机转速、主蒸汽流量以及高过入口烟气温度作为输入变量, 减温水流量和给水流量作为操作变量, 其余 3 个作为可测扰动, 主汽温为被控量。模型辨识算法步骤如下:

(1) 利用辨识信号进行试验。调整锅炉负荷 (80% ~ 100%), 采集 1137 个数据序列并保存数据, 采样周期为 20 s。随机选取 937 个序列作为训练样本, 其余的 200 个作为校验数据。

(2) 确定 Laguerre 滤波器极点, 预选模型阶数, 构造状态转移方程系数矩阵^[4]。经过反复对比测试最终选定 5 个输入通道 Laguerre 滤波器组极点为 [0.82, 0.79, 0.75, 0.76, 0.85]。

(3) 将试验数据输入值代入初始模型得到状态向量矩阵: $\{X(t) | t=1, \dots, k\}$ 。以状态向量为输入, 试验数据输出值为目标, 利用偏最小二乘回归方法(PLS)估计模型输出方程系数 C , 得到线性 MISO 系统的状态空间描述。对单个输入输出通道的线性系统(A, B_i, C), 进行模型降阶处理; 之后重构 MISO 系统, 重新计算状态向量样本 $\{X(t) | t=1, \dots, k\}$ 。最后得到局部模型的线性部分如下:

$$\begin{aligned} A &= \begin{bmatrix} 1.019 & 0.036 & -0.271 & 0.008 & 0.049 \\ -0.114 & 0.826 & 0.183 & 0.021 & -0.031 \\ 0.088 & 0.069 & 0.157 & 0.163 & -0.122 \\ -0.425 & 0.450 & 0.086 & 0.069 & -0.115 \\ 1.038 & -0.895 & 0.218 & 0.294 & 0.581 \end{bmatrix} \\ B_u &= \begin{bmatrix} 0.587 & -0.219 \\ -0.947 & 0.157 \\ 3.901 & -0.513 \\ -0.636 & 0.824 \\ -0.880 & -1.702 \end{bmatrix} \\ B_v &= \begin{bmatrix} -0.241 & 0.305 & -0.280 \\ 0.184 & -0.814 & 0.368 \\ -0.148 & 2.160 & 0.107 \\ 2.865 & 4.312 & 0.904 \\ -1.788 & -5.367 & 2.584 \end{bmatrix} \\ C &= \begin{bmatrix} 0.427 \\ 0.563 \\ -0.025 \\ -0.007 \\ 0.022 \end{bmatrix}^T \end{aligned}$$

$$U(t) = \begin{bmatrix} u_{\text{FA}}(t-1) \\ u_{\text{FW}}(t-1) \end{bmatrix}, V(t) = \begin{bmatrix} u_{\text{FF}}(t-1) \\ u_{\text{FM}}(t) \\ u_{\text{FG}}(t) \end{bmatrix}$$

式中下标 FA、FW、FF、FM 和 FG 分别表示减温水流量、给水流量、给粉量、主蒸汽流量以及高过入口烟气温度。

(4) 构造 RBF 神经网络, 以状态样本为输入, 以线性模型输出误差为目标, 训练网络, 最终获得非线性映射 f_{NN} 。非线性映射部分通过反复训练和交叉验证, 最终确定为 $5 \times 7 \times 1$ 的单隐层结构。训练后, 用校验数据对网络进行检验, 结果如表 1 所示。

表 1 RBF 网络输出误差表

均方根误差(MSE)	训练数据	校验数据
线性部分输出误差	0.294	0.306
RBF 网络输出误差	0.043 3	0.050 7

(5) 针对局部子模型, 进行了相应的模型验证工作, 得到了在减温水流量 -10% 扰动下的主汽温响应曲线, 如图 2 所示。可见, 局部模型具有良好的响应性能。

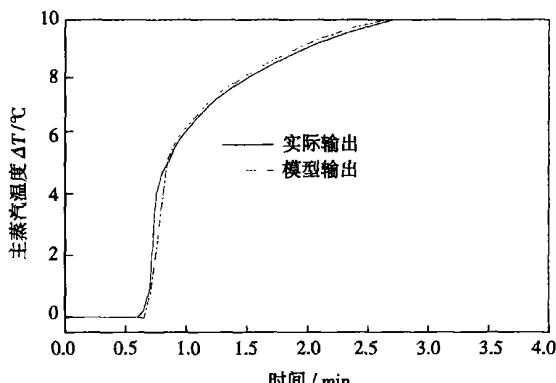


图 2 局部模型减温水流量扰动(-10%)响应验证曲线

(6) 控制性能测试。采用 K. S. Narendra 等人提出的基于模型切换的多模型间接自适应控制^[6~7]。固定模型集含两个工况区域的局部模型($60\% \sim 80\%$ 和 $80\% \sim 100\%$), 改变压力设定值: $t=10$ min 时, 从 100% 负荷降至 85% 、 $t=30$ min 时再降至 75% , 观察其控制效果, 并与常规 PID 控制和基于局部线性模型的多模型控制(固定模型集为 $60\%、70\%、80\%、90\%$ 和 100% 5 个工况下的局部模型)对比, 主蒸汽压力和主蒸汽温度试验曲线如图 3 和图 4 所示。由性能曲线可以看出, 基于局部非线

性模型的多模型控制(NMMAC)方法与常规控制策略相比, 缩短了过渡过程时间, 能够更好地跟踪负荷变化; 与基于线性模型的多模型控制(LMMAC)相比, 减少了模型的数量, 模型切换时的震荡减弱, 控制性能得到了改善。

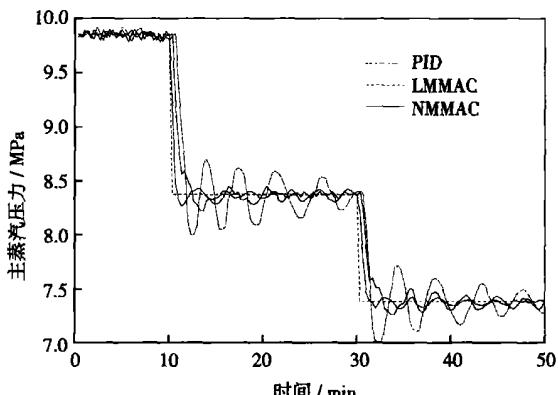


图 3 变负荷主汽压动态响应对比曲线

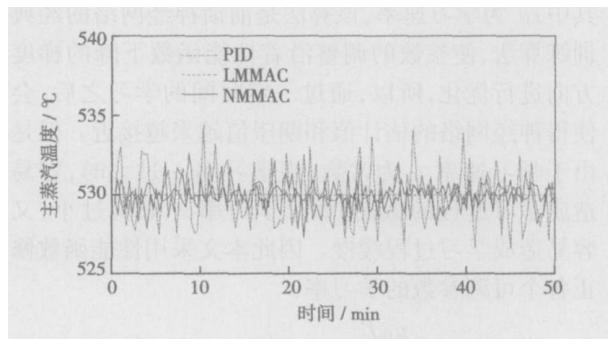


图 4 主汽温控制性能对比曲线

4 总 结

采用非线性状态空间模型结构, 这种模型结构有利于算法程序实现和节省运行开支。对于非线性映射部分辨识, 利用 RBF 神经网络的逼近能力, 同时对 RBF 学习速率进行了改进, 根据性能函数调节学习率, 可以加快学习的收敛过程, 较好地解决了局部模型的构建问题, 得到了精度较高、规模较小的网络模型。最后进行了仿真验证, 基于 2 个局部非线性模型设计多模型控制系统, 并与基于 5 个局部线性模型的多模型控制系统进行对比, 前者虽然模型数量更少, 减少了模型切换时的震荡, 控制精度也有所提高。试验结果表明, 该算法在建立实际热力对象模型时能够提高模型精度, 同时可以减少局部模型的数量, 具有良好的跟踪性能。

(下转第 95 页)

模型精度有所降低,但隐节点数大大减小,网络结构得到简化,同时运算时间也减少。因此,在对模型精度要求不是很高的热工过程中,适当降低精度要求可以提高神经网络的实时建模能力。

表3 对网络性能的影响

e_{\min}	隐节点数	均方根误差(RMSE)	运算时间/s
0.01	28	0.0374	27.6
0.02	24	0.0586	24.9
0.05	20	0.0613	16.5
0.1	13	0.0769	10.3
0.2	12	0.0644	8.2
0.5	11	0.0684	7.1

2.3.2 e'_{\min} 对网络性能的影响

由表4可见, e'_{\min} 也对网络性能有较大影响。适当减小 e'_{\min} 可以降低模型误差,但却会带来隐节点的增加及运算时间的延长。同时, e'_{\min} 过小会使网络训练过程中隐节点的增删过于频繁,不适用于实际热工过程的应用。

表4 e'_{\min} 对网络性能的影响

e'_{\min}	隐节点数	均方根误差(RMSE)	运算时间/s
0.2	58	0.031	187.8
0.3	48	0.041	144.8
0.5	25	0.044	23.2
0.6	16	0.055	11.2
0.7	6	0.083	3.4
0.8	4	0.110	2.2

其它一些初始参数,如及 ϵ_{\max} , ϵ_{\min} 也对网络的结构和性能有一定影响。在实际建模过程中,要针对不同的模型选择合适的初始参数,以使网络综合性能达到最优。

3 结语

介绍了基于 RBF 网络的资源分配网络(RAN),

(上接第 90 页)

参考文献:

- [1] DI PALMA F, MAGNI L. A multi-model structure for model predictive control[J]. Annual Reviews in Control, 2004, 28(1): 47—52.
- [2] SENTONI GUILLERMO B, BIEGLER LORENZ T. State-space nonlinear process modeling: identification and universality[J]. AIChE Journal, 1998, 44(10): 2229—2239.
- [3] SENTONI G B, BEIGLER L T. Model reduction for nonlinear DABN et models // Proceedings of the American Control Conference[C]. San Diego, CA, 1999: 2052—2056.
- [4] WANG LI WEI, WANG XIAO, FENG JU FU. Intrapersonal subspace analysis with application to adaptive Bayesian face recognition[J]. Pattern Recognition, 2005, 38(4): 617—621.
- [5] 刘志远, 吕剑虹, 陈来九. 新型 RBF 神经网络及在热工过程建模中的应用[J]. 中国电机工程学报, 2002, 22(9): 118—122.
- [6] NARENDRA K S, GEORGE K. Adaptive control of simple nonlinear systems using multiple models // Proceedings of the IEEE American Control Conference[C]. American: IEEE, 2002: 1779—1784.
- [7] 翟军勇, 费树岷. 基于在线学习的多模型自适应控制[J]. 中国电机工程学报, 2005, 25(9): 80—83.

指出了其在建模过程中存在的不足,如无法删除对网络不产生贡献的隐节点。通过采用能够加快收敛速度的 EKF 算法及能够删除冗余隐节点的剪枝策略,使得网络结构更加紧凑。同时加入滑动窗口 RMS 准则,提高了网络的泛化能力,并最终建立了改进的最小资源分配网络(MRAN)。进而将改进的 MRAN 应用到两种热工过程的在线建模,从计算结果看,MRAN 网络具有结构紧凑、模型精度高、泛化能力强及收敛速度快的特点,非常适合于热工过程的在线建模。最后分析了网络初始参数 e_{\min} 及 e'_{\min} 对网络性能的影响,表明了在建模过程中,正确选取初参数对优化网络性能的重要性。

参考文献:

- [1] IRWIN G, BROWN M, HOGG B, et al. Neural network modeling of a 200 MW boiler system[J]. IEE Proc-Control Theory Application, 1995, 142(6): 529—536.
- [2] NOURA H, THEILLIOL D, AUBRUN C. Control law reconfiguration for nonlinear systems based on multilayer neural network and fuzzy model: application to a thermal plant // Proceedings of the IEEE International Conference on Systems Man and Cybernetics[C]. France: IEEE, 1994: 453—458.
- [3] 魏海坤. 神经网络结构设计的理论与方法[M]. 北京: 国防工业出版社, 2005.
- [4] 杨戈, 吕剑虹, 刘志远. 基于 RBF 神经网络的热工过程在线自适应建模算法研究[J]. 中国电机工程学报, 2004, 24(1): 191—195.
- [5] CHENG Y H, LIN C S. A learning algorithm for radial basis function networks: with the capability of adding and pruning neurons[J]. IEEE Int Conf on Neural Networks, 1994, 1: 797—801.
- [6] SUNDA RARJAN N, SARATCHANDRAN P, LU Y W. Radial basis function neural networks with sequential learning, MRAN and its applications[M]. Singapore: World Scientific, 1999.
- [7] 倪维斗, 徐基豫. 自动调节原理与透平机械自动调节[M]. 北京: 机械工业出版社, 1999.
- [8] WIGREN T. Recursive identification based on nonlinear state space models applied to drum-boiler dynamics with nonlinear output equations // 2005 American Control Conference June 8—10[C]. Portland, OR: 2005.

(渠源 编辑)

variable speed regulation, flow guide regulation

HHT 与 RBF 神经网络在离心泵故障振动信号处理中的应用= **The Application of HHT and RBF Neural Networks for Processing Fault-vibration Signals from Centrifugal Pumps**[刊, 汉] / ZHOU Yun-long, HONG Jun, ZHAO Peng (College of Energy Source and Mechanical Engineering under the Northeast University of Electric Power, Jilin, China, Post Code: 132012)// Journal of Engineering for Thermal Energy &Power. — 2007, 22 (1). — 84 ~ 87

According to the specific features of fault-vibration signals of a centrifugal pump, presented is a new method for fault diagnosis of vibration signals of a centrifugal pump by employing a combination of Hilbert-Huang transformation (HHT) and a radial basis function (RBF) neural network. First, the time series data from the vibration signals of a centrifugal pump is subject to an empirical mode decomposition (EMD) followed by a Hilbert-Huang Transformation to obtain the energy of various intrinsic mode functions (IMF). Moreover, with "energy ratio" serving as an element, the eigenvector obtained from vibration signals of the centrifugal pump by utilizing the energy ratio can depict very well fault information for different vibrations. By using a RBF neural network, the mapping extending between the eigenvector and fault modes can be established to realize a fault diagnosis, thus achieving a high diagnostic rate for such conditions as normal state, mass imbalance, rotor misalignment and foundation loosening fault of a centrifugal pump. The experimental research results show that the method under discussion can effectively diagnose the vibration signals of a centrifugal pump. **Key words:** centrifugal pump, Hilbert-Huang transformation, RBF (radial basis function) neural network, fault diagnosis

热力系统局部非线性模型辨识= **Discrimination of the Local Nonlinear Model of a Thermodynamic System**[刊, 汉] / DONG Jun-hua, XU Xiang-dong (Department of Thermal Energy Engineering, Tsinghua University, Beijing, China, Post Code: 100084)// Journal of Engineering for Thermal Energy &Power. — 2007, 22 (1). — 88 ~ 90, 95

In a multi-model control (MMC) version, a majority of local models are based on a linear model and their number and accuracy may influence the effectiveness of the multi-model control. An algorithm for the discrimination of nonlinear models is proposed based on a radial basis function (RBF) neural network. By adopting a nonlinear model structure proposed by G. B. Sotomayor and others and utilizing the approximation ability of a radial basis function (RBF) neural network, realized was the discrimination of nonlinear models in a thermodynamic system. During the process of learning the RBF neural network, one can accelerate the converging process of learning by regulating the learning speed according to a performance function. Finally, a simulation verification was conducted. A multi-model control system based on two local linear models instead of five local nonlinear models can diminish the oscillation during a switching-over with the control accuracy being somewhat enhanced. The experimental results indicate that the discrimination algorithm under discussion can reduce the number of fixed models, thereby shortening model searching time and raising model prediction accuracy. **Key words:** thermodynamic system, local model, non-linearity, RBF neural network

基于最小资源分配网络的热工对象辨识= **Discrimination of a Thermodynamic Object Based on a Minimum Resource Allocation Network**[刊, 汉] / YANG Shi-zhong, LU Jian-hong (College of Energy Source and Environment under the Southeast University, Nanjing, China, Post Code: 210096)// Journal of Engineering for Thermal Energy & Power. — 2007, 22 (1). — 91 ~ 95

The establishment of a comprehensive nonlinear model for a thermodynamic process serves as a basis for the overall optimization of a thermodynamic control system. However, it is difficult for a static neural network to establish a model for nonlinear dynamic processes. A resource allocation network (RAN) lends itself to dynamically adjust the network parameters while an extension Kalman filter (EKF) algorithm can accelerate the converging speed. By organically combining the above-mentioned methods and adding on this basis pruning tactics and a sliding-window root-mean-square criterion, an improved minimum resource allocation network (MRAN) can be formed. The improved MRAN has been applied to the nonlinear dynamic modeling of a typical thermodynamic process. The simulation results show that the MRAN features a compact network structure and high modeling accuracy, thus making it suitable for on-line applications. Finally, analyzed