

文章编号: 1001-0920(2003)05-0637-04

基于 RBF 神经网络的单元机组负荷系统建模研究

刘志远^{1,2}, 吕剑虹¹, 陈来九¹

(1. 东南大学 动力工程系, 江苏 南京 210096; 2 南京工程学院 动力工程系, 江苏 南京 210013)

摘要: 采用径向基函数(RBF)神经网络进行多变量系统的建模研究。将正规化正交最小二乘(ROLS)算法扩展到多输入多输出系统, 建立多变量系统的 RBF 神经网络模型。对电厂单元机组负荷系统进行建模仿真研究的结果表明, 用该方法建立的多变量热工系统的非线性模型是有效的, 具有较高的辨识精度和较好的泛化能力。

关键词: 径向基函数; 神经网络; 正交最小二乘算法; 单元机组; 建模

中图分类号: N 945.12

文献标识码: A

Modelling of unit power plant load system based on RBF neural network

L IU Zh i-yuan^{1,2}, LU J ian-hong¹, CH EN L ai-jiu¹

(1. Department of Power Engineering, Southeast University, Nanjing 210096, China;

2 Department of Power Engineering, Nanjing Institute of Technology, Nanjing 210013, China)

Abstract: The modelling problem of multivariable system using radial basis function (RBF) neural networks is studied. The regularized orthogonal least square (ROLS) algorithm is extended to model multivariable nonlinear systems. The simulation results modeling the unit power plant load system show that establishing the nonlinear model of multivariable thermal system with this method is effective and has higher precision and better generalization properties.

Key words: Radial basis function; Neural network; Orthogonal least square algorithm; Unit power plant; Modelling

1 引言

热工过程具有非线性、慢时变、大迟延和不确定性, 难以建立精确的数学模型。基于对象近似线性模型设计的常规控制系统, 在过程工况发生变化时, 控制品质将会下降, 甚至影响控制系统的正常运行。因此, 建立性能良好的热工过程非线性模型是提高控制系统性能的基础。近年来, 神经网络已广泛应用于建立过程的非线性模型^[1], 但由于常用的多层神经网络计算量大、收敛速度慢、易陷入局部最小点, 影

响了它们的应用。径向基函数(RBF)神经网络具有可以逼近任意非线性映射的能力^[2], 而且网络结构简单, 其输出的连接权值与输出呈线性关系, 可采用保证全局最优的线性优化算法, 因而成为研究的热点, 并在信号处理、系统建模、过程控制和故障诊断等领域得到了成功的应用^[3]。

本文将文献[4]提出的正规化正交最小二乘法扩展到多输入多输出系统, 并用这种方法建立多变量系统的 RBF 神经网络模型。仿真研究表明, 采

收稿日期: 2002-07-03; 修回日期: 2002-09-29。

基金项目: 国家自然科学基金资助项目(50076008); 江苏省青年科技基金资助项目(BQ 2000002)。

作者简介: 刘志远(1967—), 男, 江苏兴化人, 副教授, 博士生, 从事热工过程控制的研究; 陈来九(1929—), 男, 上海人, 教授, 博士生导师, 从事热工过程自动控制等研究。

用该方法建立的多变量热工系统的非线性模型是有效的,而且模型辨识精度高,具有较好的泛化能力。

2 RBF神经网络及其学习算法

2.1 RBF神经网络的结构

RBF神经网络的结构如图1所示,它包括输入层、隐含层和输出层。设RBF神经网络的输入 x 为 p 维向量, $x = [x_1, x_2, \dots, x_p]^T \in R^p$,网络输出为 m 维向量, $\hat{f}(x) = [\hat{f}_1(x), \hat{f}_2(x), \dots, \hat{f}_m(x)]^T \in R^m$ 。




图1 RBF神经网络的结构

RBF神经网络第 i 个输出变量为

$$\hat{f}_i(x) = \sum_{j=1}^h w_{ji} \phi_j = \sum_{j=1}^h w_{ji} \Phi(x - c_j, \sigma_j) \quad (1)$$

其中: $\Phi(\cdot)$ 为径向基函数,一般取为高斯函数 $\Phi(x) = \exp(-x^2/\sigma^2)$; $\|\cdot\|$ 为欧几里德范数; $c_j = [c_{1j}, c_{2j}, \dots, c_{pj}]^T \in R^p$ 为隐层第 j 个径向基函数的数据中心; σ_j 为径向基函数的宽度; w_{ji} 为第 j 个基函数输出与第 i 个输出节点的连接权值; h 为隐层节点的数目。

给定 N 对系统输入输出学习样本,RBF神经网络的学习问题,就是要找到一组数据中心 $c_j(j = 1, 2, \dots, h)$ 和相应的一组输出权值,使得网络在样本输入下的输出能以给定的精度逼近系统实际输出。

2.2 RBF神经网络的学习算法

在RBF神经网络中,隐层RBF中心的数量和位置直接影响着网络的逼近能力,而且要求RBF中心应能覆盖整个输入空间。但如果RBF中心的数量过多,将使网络的计算量显著增加,并将导致网络泛化能力下降。因此,建立RBF网络模型的关键在于选择合适的RBF中心。RBF中心的选择方法主要有聚类算法^[5]和正交最小二乘算法(OLS算法)^[6]。正交最小二乘算法可将RBF中心的选择和输出权值的学习结合起来,因此在实际中得到了较多的应用。但如果学习数据含有噪声或学习算法的停止阈值选

择不合适,将导致OLS算法出现过拟合,降低网络的泛化能力。文献[4]将正规化方法^[7]与OLS算法相结合,提出了正规化正交最小二乘算法(ROLS)。虽然它能有效提高RBF神经网络的泛化能力,但该方法仅对单输入单输出系统进行了研究。为建立多输入多输出系统的RBF神经网络模型,下面考虑多输入多输出情况下的ROLS算法。

定义

$$Y = [y_1 \ y_2 \ \dots \ y_m] \quad (2)$$

$$\hat{f} = [\hat{f}_1 \ \hat{f}_2 \ \dots \ \hat{f}_m] \quad (3)$$

$$W = [w_1 \ w_2 \ \dots \ w_m] \quad (4)$$

$$\Phi = [\Phi_1 \ \Phi_2 \ \dots \ \Phi_h] \quad (5)$$

$$E = [e_1 \ e_2 \ \dots \ e_m] \quad (6)$$

其中 $y_i = [y_i(1) \ y_i(2) \ \dots \ y_i(N)]^T, \hat{f}_i = [\hat{f}_i(1) \ \hat{f}_i(2) \ \dots \ \hat{f}_i(N)]^T, w_i = [w_{1i} \ w_{2i} \ \dots \ w_{hi}]^T, \Phi_i = [\Phi_i(1) \ \Phi_i(2) \ \dots \ \Phi_i(N)]^T, e_i = [e_i(1) \ e_i(2) \ \dots \ e_i(N)]^T$ 分别为系统输出向量、RBF网络模型输出向量、网络输出层连接权向量、网络隐层径向基函数向量和系统输出与RBF网络模型输出之间的误差向量。则多输入多输出系统可表示为如下线性回归方程

$$Y = \hat{f} + E = \Phi W + E \quad (7)$$

对回归矩阵 Φ 进行正交分解,有

$$Y = \Phi W + E = V U W + E \quad (8)$$

定义

$$U W = S \quad (9)$$

其中: $S = [s_1, s_2, \dots, s_m], s_i = [s_{1i}(1) \ s_{2i}(2) \ \dots \ s_{hi}(N)]^T$ 。则式(8)可写成

$$Y = V G + E \quad (10)$$

与单输出系统一样,考虑下列零阶正规化误差准则^[4]

$$\text{trace}(E^T E + S^T \text{diag}\{\lambda\} S) \quad (11)$$

经过化简(略),上式可表示为

$$\text{trace}(E^T E + S^T \text{diag}\{\lambda\} S) = \text{trace}(Y^T Y - S^T (V^T V + \text{diag}\{\lambda\}) S) \quad (12)$$

其中 $\lambda > 0$ 为正规化系数。对式(12)化简,得

$$\frac{\text{trace}(E^T E + S^T \text{diag}\{\lambda\} S)}{\text{trace}(Y^T Y)} = 1 - \frac{\text{trace}(S^T (V^T V + \text{diag}\{\lambda\}) S)}{\text{trace}(Y^T Y)} = 1 - \sum_{j=1}^m \frac{\sum_{i=1}^h s_{ji}^2 (v_j^T v_j + \lambda)}{\text{trace}(Y^T Y)} \quad (13)$$

定义由 v_k 引起的正规化误差衰减率为

$$[\text{rerr}]_k = \frac{\sum_{i=1}^m s_{ki}^2 (v_k^T v_k + \lambda)}{\text{trace}(Y^T Y)} \quad (14)$$

与单输入单输出系统相似, 可根据上述正规化误差衰减率来选择对输出能量贡献最大的回归矩阵的列 Φ_j , 当满足

$$1 - \sum_{k=1}^h [\text{rerr}]_k < \xi \quad (15)$$

时, 选择过程结束。其中 $0 < \xi < 1$ 为指定的容许误差。

正规化系数 λ 可按下列方法递推选择^[4]

$$\lambda = \frac{Y \text{ trace}(E^T E)}{N - Y \text{ trace}(Y^T Y)} \quad (16)$$

其中

$$Y = \sum_{i=1}^h \frac{v_i^T v_i}{v_i^T v_i + \lambda} \quad (17)$$

经过一定次数的迭代, 便可找到一个合适的 λ 。

3 仿真研究

单元机组负荷系统是一个典型的多变量系统。本文以某电厂 125MW 中间再热燃煤机组负荷系统为对象模型, 其动态特性^[8] 为

$$\begin{bmatrix} N_E \\ P_T \end{bmatrix} = \begin{bmatrix} \frac{68.81s}{(1+12s)(1+82s)} & \frac{1}{(1+83s)^2} \\ -2.194 \left(\frac{0.064}{1+3s} + \frac{0.936}{1+124s} \right) & \frac{2.194}{(1+80s)^2} \end{bmatrix} \begin{bmatrix} u_T \\ u_B \end{bmatrix} \quad (18)$$

其中: N_E 和 P_T 分别为发电机实发功率和主蒸汽压力; u_T 和 u_B 分别为汽机调门指令和锅炉燃料率指令。

取输入 u_T 和 u_B 为互不相关的伪随机信号, 变化幅度为设计值的 $\pm 3\%$, 对上述对象进行仿真。取采样周期为 15 s, 共记录 200 对数据。将记录数据作为样本数据, 采用上述算法, 建立该负荷系统的 RBF 神经网络模型。RBF 神经网络模型的输入向量^[8] 选为 $[u_T(k-1), u_T(k-2), u_B(k-1), u_B(k-2), N_E(k-1), N_E(k-2), P_T(k-1), P_T(k-2)]^T$, 模型的输出变量为 $[N_E(k), P_T(k)]^T$, RBF 宽度取为 4, 容许误差 $\xi = 0.024$, 正规化系数 λ 经多次迭代后收敛于 $\lambda = 0.00069898$, 所得 RBF 网络模型有 18 个数据中心。

为判断所建立的 RBF 神经网络模型的可靠性, 采用自相关函数检验法^[9] 对所建立的 RBF 神经网络模型进行检验, 即通过检验 RBF 神经网络模型输出与过程输出残差序列 $\{e_i(t)\}$ 是否(或近似) 为白噪声序列。两个输出 $N_E(t)$ 和 $P_T(t)$ 的残差均值分别为 8.5705×10^{-4} 和 -4.4351×10^{-4} 。图 2 为所建立的 RBF 神经网络模型的有效性检验。由图 2 可见, 当 $l = 1 \sim 20$ ^[9] 时, 两个输出残差序列的自相关系数 $\rho(l)$ 基本都落在 95% 置信区间内。因此, 可认为输出残差序列为白噪声序列, 所得模型是可靠的。






图 2 RBF 神经网络模型的有效性检验 (虚线为 95% 置信区间)

为了验证所建立的 RBF 神经网络模型的泛化能力, 取输入 u_T 和 u_B 为互不相关且各自与网络训练时的输入互不相关的伪随机信号, 变化幅度为设计值的 $\pm 3\%$ 。对上述对象进行仿真, 取采样周期为 15 s, 共记录了 200 对数据。将记录的数据作为测试数据, 输入到上述 RBF 神经网络模型, 模型输出数据与测试数据的比较如图 3 所示。由图 3 可以看出,



(a) 输出 $N_E(t)$ 曲线




(b) 输出 $P_T(t)$ 曲线


图 3 RBF 神经网络模型输出与测试输出数据的比较

RBF 模型输出能较好地跟踪测试数据, 所建立的 RBF 神经网络模型具有较好的泛化能力。

在上述验证过程中, 分别取输入 u_T 和 u_B 为伪随机信号而令 $u_B = 0, u_T = 0$, 分别对对象进行仿真, 并采用上述 RBF 神经网络模型进行测试。在这两种情况下, 所建立的 RBF 模型输出都能较好地跟踪系统的输出。图 4 是当 $u_T = 0$ 时, 对象模型输出与 RBF 神经网络模型输出的比较。



(a) 输出 $N_E(t)$ 曲线



(b) 输出 $P_T(t)$ 曲线

图 4 $u_T(t) = 0$ 时, 对象模型输出与 RBF 神经网络模型输出的比较

4 结 论

本文将单输入单输出正规化正交最小二乘算法扩展到多输入多输出系统, 并用于建立多变量系统的 RBF 神经网络模型。通过对单元机组负荷系统的

仿真研究表明, 将这种方法用于多变量系统的非线性建模不仅是有效的, 而且模型辨识精度高, 并具有较好的泛化能力。

参考文献 (References):

[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] Park J, Sandberg IW. Universal approximation using radial-basis-function networks [J]. *Neural Computation*, 1991, 3(2): 246-257.

[3] Barry Gomm J, Ding Li Yu. Selecting radial basis function network centers with recursive orthogonal least squares training [J]. *IEEE Trans on Neural Networks*, 2000, 11(2): 306-314.

[4] Chen S, Chng E S, Alkadhimi K. Regularized orthogonal least squares algorithm for constructing radial basis function networks [J]. *Int J Control*, 1996, 64(5), 829-837.

[5] Moody J E, Darken C. Fast learning in networks of locally tuned processing units [J]. *Neural Computation*, 1989, 1(2): 281-294.

[6] Chen S, Billings SA. Neural networks for nonlinear dynamic system modelling and identification [J]. *Int J Control*, 1992, 56(2): 319-346.

[7] M J L Orr. Regularised centre recruitment in radial basis function networks [R]. Edinburgh, Scotland: University of Edinburgh, 1993.

[8] 吕剑虹. 预测控制在热工过程控制中的应用研究 [D]. 南京: 东南大学, 1990.

[9] 方崇智, 萧德云. 过程辨识 [M]. 北京: 清华大学出版社, 1988.

下 期 要 目

满意度原理研究与应用的现状与展望.....	黄洪钟, 等
供应链渠道协调中的 Stackelberg 主从对策	常良峰, 等
两传感器两扫描周期的数据关联.....	徐 毓, 金以慧
基于模糊性能指标的广义预测控制器参数调整.....	李少远, 等
多变量非线性系统的间接模糊输出反馈自适应控制.....	佟绍成, 朱延枫
基于 HSC 的非线性 PD 控制器	陈 众, 等
双混沌机制优化方法及其应用.....	修春波, 等
模糊 Delta 算子系统的鲁棒稳定性分析与控制	向峥嵘, 等
虚拟企业环境下的复杂产品并行开发框架模型研究.....	陈 希, 王宁生