

文章编号: 1671-7848(2007)03-0284-03

一种神经网络 PID 自适应控制及其应用研究

许昌^{1,2}, 吕剑虹¹, 程明¹, 郑源²

(1. 东南大学 电气工程系, 江苏 南京 210096; 2. 河海大学 热能与动力工程系, 江苏 南京 210098)



摘 要: 为提高 PID 控制的自适应性能, 提出了一种神经网络 PID 自适应控制算法。最小资源分配网络(MRAN)是一种可以在线调整隐节点的 RBF 网络, 具有泛化能力强、计算精度高的优点。通过对 MRAN 的剪裁策略进行改进, 使改进的网络具有更加紧凑的结构; 把改进的 MRAN 和 PID 控制相结合, 提出了一种基于动态 RBF 网络的 PID 自适应控制策略, 并应用到对电站锅炉过热汽温的控制上。仿真结果表明, 所提出的控制算法与常规的控制算法相比具有更好的控制品质。

关键词: 最小资源分配网络; PID 自适应控制; 过热汽温

中图分类号: TP 27

文献标识码: A

Neural Network PID Adaptive Control and Its Application

XU Chang^{1,2}, LÜ Jian-hong¹, CHENG Ming¹, ZHENG Yuan²

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

2. Thermal and Power Engineering Department, Hohai University, Nanjing 210098, China)

Abstract: A neural network PID control algorithm is presented to improve the PID adaptive control performance. Minimal resource allocating network(MRAN) that is an RBF network of self-tuning hidden nodes online and has the excellences of strong generalization and high accuracy. The structure is improved by the reducing strategies of MRAN. The improved MRAN has more compact structure. Combining the improved MRAN with PID control, the PID self-adaptive control on dynamic RBF network is presented, and applied to control the superheated steam temperature of a power station boiler. Simulation results show that the presented algorithm has better performances than the conventional control algorithm.

Key words: minimal resource allocating network; PID adaptive control; super-heated steam temperature

1 引言

在工业过程控制中, PID 控制器以其具有直观、实现简单和鲁棒性强等优点而得到广泛应用。但是, 当被控对象含有不确定性和严重非线性时, 常规 PID 控制往往难以达到满意的控制效果。20 世纪 80 年代初繁荣起来的神经网络为控制界注入了新的活力, 给非线性控制带来了新的思路, 这使人们自然想到把神经网络技术与经典的 PID 方法相结合, 充分利用两者的优点组成性能更为优越的控制器。在这个方面已有一些研究成果, 如文献 [1, 2], 但这些研究都是针对固定网络隐节点, 这影响了网络泛化能力和预测精度, 从而难以提高控制的品质。本文通过把改进的 MRAN 算法与 PID 控制相结合, 提出一种基于动态 RBF 网络的 PID 自适应控制策略, 同时把提出控制策略应用到对电站锅炉过热蒸汽温度的控制仿真上, 结果表明提出的控制方法与常规的 PID 控制相比具有更好的控制品质。

2 MRAN 算法改进

一般的 RBF 网络, 隐节点数一旦确定后在学习过程中就不再变化。1991 年, 经 J. Platt 改进成网络隐节点数在学习过程中可按“距离准则”和“误差准则”增加的资源分配网络 RAN^[3]。1998 年, Y. Lu 改进了 RAN 隐节点数只增不减的弱点, 变为隐节点可按对输出“作用大小准则”剪裁的最小资源分配网络 MRAN^[4], 提高网络的泛化能力。MRAN 算法是一种样本序贯学习方法, 在样本输入过程中, 根据预测精度的需要, 按“距离准则”和“误差准则”增加隐节点, 同时按网络隐节点输出的“作用大小准则”对 RBF 网络的隐节点进行剪裁。笔者^[5]曾对该算法进行仿真分析, 发现用于控制剪裁隐节点的参数难于选取, 隐节点还有冗余的缺点, 对算法中的隐节点“剪裁策略”进行了改进, 加入了“合并策略”和“惩劣策略”。改进后的算法与 MRAN 算法相比, 具有更加紧凑的网络结构,

收稿日期: 2006-03-14; 收修定稿日期: 2006-04-07

基金项目: 国家教育部博士点基金资助项目(20050286041)

作者简介: 许昌(1973-), 男, 安徽全椒人, 讲师, 博士, 主要从事热工自动化和高效低污染燃烧等方面的教学与科研工作; 吕剑虹(1964-), 男, 江苏常熟人, 教授, 博士生导师。

而预测精度几乎不变，是一种有效的改进算法。本文提出的控制算法即基于改进的 MRAN 算法。

3 基于动态 RBF 网络的 PID 自适应控制

1) 基于动态 RBF 网络的 PID 自适应控制结构
本文提出的基于动态 RBF 网络的 PID 自适应控制结构如图 1 所示。




图 1 基于动态 RBF 网络的 PID 自适应控制结构

Fig.1 PID self-adaptive control structure on dynamic RBF network

图中，滤波器 F 选用一阶滤波器，取 $G_r(z^{-1}) = \frac{1 - \alpha_r}{1 - \alpha_r z^{-1}}$ ($0 < \alpha_r < 1$) 神经网络 NNI 用于动态辨识被控对象的非线性不确定过程；NNPID 为基于动态神经网络的 PID 控制器。

2) NNI 内模辨识器的设计 设被控对象可用 SISO 离散时间非线性系统表示：

$$y_m(t+1) = f(X(t)) = f(y_p(t), y_p(t-1), \dots, y_p(t-n+1), u(t), u(t-1), \dots, u(t-m+1)) \quad (1)$$

式中， $y_m(t+1)$ 为神经网络内模辨识器 (NNI) 的输出； y_p 为控制对象输出； u 为内模控制器输出； m, n 分别为延时阶数，均取 3。

内模辨识器采用本文所提出的改进 MRAN 算法，目标输出为 $y_p(t+1)$ 。

3) NNPID 控制器的设计 通常 PID 控制算法相对应的数字增量型算式为

$$u(t) = u(t-1) + k_p(\epsilon(t) - \epsilon(t-1)) + k_i T \epsilon(t) + k_D / T (\epsilon(t) - 2\epsilon(t-1) + \epsilon(t-2)) \quad (2)$$

由 PID 控制算法可看出，控制量 $u(t)$ 是 $u(t-1), \epsilon(t), \epsilon(t-1), \epsilon(t-2)$ 的函数，只要把 $u(t-1), \epsilon(t), \epsilon(t-1), \epsilon(t-2)$ 作为网络的输入， $u(t)$ 作为网络的输出，这时自适应地改变网络的参数也就等同于自适应地改变了 PID 的控制参数。本文采用以上的思想设计 NNPID 控制器，学习算法采用改进的 MRAN 算法，网络输入为 $X = [u(t-2), \epsilon(t-1), \epsilon(t-2), \epsilon(t-3)]^T$ ，网络输出为 $\hat{u}(t-1)$ ，而网络的目标输出 $u(t-1)$ 是通过内模辨识器采用误差反传算法得到。

NNPID 型控制器学习的目标是通过修正网络输入 $\hat{u}(t-1)$ ，从而使下面的性能指标函数最小：

$$J = 1/2 e^2(t) = 1/2 (y_r(t) - y_p(t))^2 \quad (3)$$

$y_p(t)$ 用 $y_m(t)$ 来代替，进行误差反传算法：

$$u_{k+1} = u_k - \eta \frac{\partial J}{\partial u_k} \quad (4)$$

$$u_{k+1} = u_k + \eta \epsilon(t) \frac{\partial y_m(t)}{\partial u_k} \quad (5)$$

$$\frac{\partial y_m(t)}{\partial u_k} = \sum_{j=1}^N \phi_j \alpha_j \frac{c_{j1} - u_k}{\sigma^2} \quad (6)$$

$$\phi_j = \exp(-\frac{\|x_i - \mu_j\|^2}{\sigma_j^2}) \quad (7)$$

式中， k 为学习次数， η 为学习系数。

通过对内模辨识器的误差反传迭代得出的 $u(t-1)$ 即为 NNPID 型控制器学习的目标值，NNPID 型控制器学习采用提出的改进 MRAN 算法。学习结束后 NNPID 作为控制器，接收新的系统误差和前一个采样周期的控制量作为网络的输入，输出即为新的控制量 $u(t)$ 。

4) 基于动态 RBF 网络的 PID 自适应控制算法
基于动态 RBF 网络的 PID 自适应控制算法如下：

- ① 随机或按照常规的 PID 控制算法选择几组控制量作用于对象，所得到的几组控制量、系统误差、控制对象输出作为 PID 自适应控制算法迭代的基础。
- ② 对设定值作一阶滤波处理，得到 $y_r(t+1)$ 。
- ③ 采集内模辨识器网络的输入参数，运用改进 MRAN 算法，实时修正神经网络内模辨识器。
- ④ 应用式 (3)~ 式 (7)，对神经网络内模辨识器采用误差反传算法，得出 NNPID 控制器的目标输出 $u(t-1)$ 。
- ⑤ 采用改进 MRAN 算法，对 NNPID 控制器进行实时修正。
- ⑥ 采集 $X = [u(t-1), \epsilon(t), \epsilon(t-1), \epsilon(t-2)]^T$ 作为 NNPID 控制器的输入，网络的输出为控制量 $u(t)$ ，并作用于被控对象。
- ⑦ $t = t + 1$ ，返回步骤②，开始新一次的循环。

4 仿真实例

当某电厂机组负荷为 180 MW 时，经现场作阶跃飞升曲线得出从喷水减温阀到过热器出口汽温的动态特性为

$$\alpha(s) = \frac{-0.9 \exp(-12s)}{(1 + 26s)(1 + 32s)} \quad (8)$$

为检验本文提出的基于动态 RBF 网络的内模自适应控制效果，把被控模型融入图 1 的控制结构中。其中滤波器常数 $\alpha_r = 0.85$ ；内模型采用的改进 MRAN 算法参数选择： $E_{\max} = 3, E_{\min} = 1, M = 10, \epsilon = 0.95, R = 0.9, Q = 0.08, \delta_1 = 0.08, \gamma = 0.97, \delta_2 = 0.003, M_1 = 5, M_2 = 6, \delta = 0.005, E_1 = 0.002, E_2 = 0.0002, k = 2, p_0 = 1$ ；NNPID 控制器采用的改进 MRAN 算法参数 $k = 0.25$ ，其他参数与

内模型相同；采用误差反传算法校正神经网络内模型辨识器时，学习系数 η 为 0.15。与常规 PID 控制进行比较，系统响应如图 2 所示。

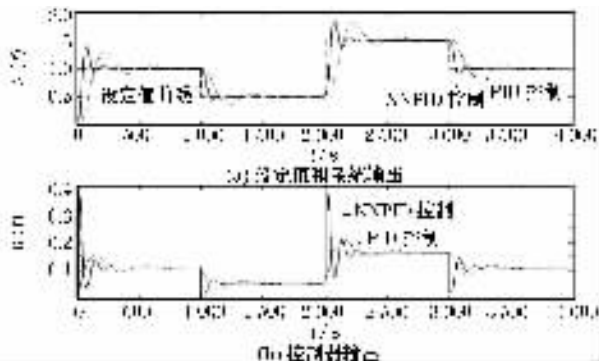


图 2 设定值变化时系统和控制器输出响应曲线

Fig.2 System and controller output response curves on setpoint step

由图可以看出，NNPID 控制的过渡时间相对较短，而短暂的超调量与常规的 PID 控制相当，控制器输出相对平稳。

1) 对象增益变化 改变原对象模型的比例增益，由 0.9 变为 0.96，控制效果如图 3 所示。

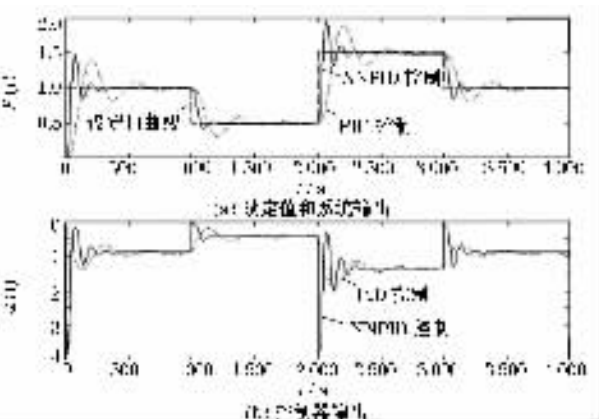


图 3 设定值变化时系统和控制器输出响应曲线

Fig.3 System and controller output response curves on setpoint step

与图 2 比较，可以看出常规 PID 控制结构在设定值变化后稳定时间相对较长，超调量变化相对也较大，鲁棒性不及 NNPID 控制。

2) 对象惯性时间常数变化 当对象惯性时间常

数变化，分别变为 30 和 40 时，延迟时间变为 15，控制效果如图 4 所示。

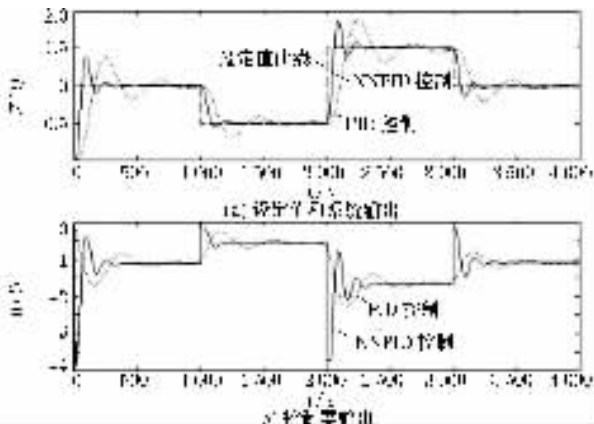


图 4 设定值变化时系统和控制器输出响应曲线

Fig.4 System and controller output response curves on setpoint step

与图 2 比较，可以看出常规的 PID 控制结构在设定值变化后超调量变化相对较大、稳定时间相对较长，鲁棒性明显不及 NNPID 控制结构。

5 结 语

把改进的最小资源分配网络和传统的 PID 方法相结合，提出基于动态 RBF 网络的 PID 自适应控制算法，并把提出算法用到对电站锅炉过热蒸汽温度的控制上。仿真结果表明，提出的控制算法同时具有批 PID 控制和神经网络控制的优点，响应速度快，没有静态偏差；具有更好的自适应性和鲁棒性。

参考文献(References):

- [1] Takao K J, Yamamoto T R. A design of model driven cascade PID controllers using a neural network[J]. IEEE Trans On Neural Networks, 2003, 14(3): 1547-1552.
- [2] 韩京清. 非线性 PID 控制器[J]. 自动化学报, 1994, 20(6): 487-490. (Han Jingqing. Nonlinearity PID controller[J]. Automation Journal, 1994, 20(6): 487-490.)
- [3] Platt J. A resource allocating network for function interpolation[J]. Neural Computation, 1991, 3(2): 213-225.
- [4] Lu Y, Sundararajan N, Saratchandran P. Performance evaluation of a sequential minimal radial basis function (RBF) learning algorithm[J]. IEEE Trans on Neural Networks, 1998, 9(2): 308-318.
- [5] 许昌. 锅炉典型非线性过程的神经网络建模及控制研究[D]. 南京: 东南大学, 2005. (Xu Chang. Neural network modeling and control study on boilers typical nonlinearity process[D]. Nanjing: Southeast University, 2005.)

(上接第 251 页)

参考文献(References):

- [1] Zdzislaw P. Rough sets theoretical aspects of reasoning about data[M]. London: Kluwer Academic Publishers, 1991.
- [2] Zdzislaw P. Rough set theory and its applications to data analysis[J]. Cybernetics and Systems, 1998, 29(7): 661-688.
- [3] Zdzislaw P, Roman S. Rough set approach to multi-attribute decision analysis[J]. European Journal of Operational Research, 1994, 78(3): 443-459.
- [4] Salvatore G, Benedetto M, Roman S. Rough approximation of a preference relation by dominance relations[J]. European Journal of Opera-

- tional Research, 1999, 123(1): 63-83.
- [5] Salvatore G, Benedetto M, Roman S. Rough sets theory for multi-criteria decision analysis[J]. European Journal of Operational Research, 2001, 131(1): 1-47.
- [6] Salvatore G, Benedetto M, Roman S, et al. An algorithm for induction of decision rules consistent with the dominance principle[A]. Rough sets and current trends in computing[C]. Banff, Canada: RSCTC 2000 Second International Conference, 2000.
- [7] Salvatore G, Benedetto M, Roman S. Rough approximation by dominance relation[J]. International Journal of Intelligent Systems, 2002, 17(2): 153-171.
- [8] Pindur R, Susmaga R. Fast rule extraction with binary-coded relations[J]. Intelligent Data Analysis, 2003, 7(1): 27-42.