

文章编号:1000-582X(2007)02-0053-05

基于改进型 RBF 神经网络多变量系统的 PID 控制*

李绍铭,刘寅虎

(安徽工业大学 电气信息学院安徽省电力电子与电力传动重点实验室,马鞍山 243002)

摘要:针对工业控制中多输入多输出非线性时变系统,提出了基于改进型 RBF 神经网络的智能 PID 控制方法.采用最近邻聚类算法在线构造 RBF 神经网络辨识器并在线辨识被控对象,对 PID 控制器参数进行在线调整,实现了多变量非线性时变系统的解耦控制.仿真结果表明,控制器能根据系统运行状态获得对应于某种最优控制规律下的 PID 参数,解耦后的系统具有较好的动态和静态性能,与常规 RBF 神经网络 PID 控制方法相比,该方法具有控制精度高、响应速度快的优点,并且具备较强的自适应性和鲁棒性.

关键词:改进型 RBF 神经网络;非线性时变系统;PID 控制;最近邻聚类算法;解耦控制
中图分类号:TP183 **文献标识码:**A

对于工程实际中多输入多输出系统,系统内部的关联耦合以及对象参数的复杂性与不确定性,导致了常规 PID 控制系统控制效果不理想.近年来,神经网络技术以其强大的非线性映射能力、并行处理能力和自学习能力,在控制领域得到了广泛研究和应用.径向基(RBF—Radial Basis Function)神经网络是一种具有单隐层的 3 层前馈神经网络,它模拟了人脑中局部调整、相互覆盖接受域的神经网络,是一种局部逼近网络,能以任意精度逼近任意非线性函数.它和传统 PID 控制相结合形成的神经网络 PID 控制,大大改进了传统 PID 控制的性能.文献[1-3]采用 RBF 神经网络来辨识非线性系统,自适应整定 PID 参数以实现复杂系统的控制,结果显示比 BP 等其它前馈神经网络 PID 控制具有超调量小,较强的鲁棒性和适应性.但由于常规 RBF 神经网络的网络结构固定,适应性差,且如何确定隐层节点数和相应的数据中心,平衡好控制速度与精度两方面的要求,仍是 RBF 网络设计的一个难点.

针对常规 RBF 神经网络中所采用的学习算法的不足,笔者采用了一种快速有效的在线学习算法—最近邻聚类算法(nearest neighbor-clustering algorithm)^[4],通过该算法构造了一种动态自适应 RBF 神经网络模型,并以此网络模型为基础设计辨识器和 PID 控制器,对多变量非线性时变系统进行解耦控制,使系统控制具有较好的动态和静态性能.

神经网络模型,并以此网络模型为基础设计辨识器和 PID 控制器,对多变量非线性时变系统进行解耦控制,使系统控制具有较好的动态和静态性能.

1 改进型 RBF 神经网络的结构及学习算法

常规 RBF 神经网络须事先确定隐层节点的个数,隐层节点一旦确定,网络结构也就固定,网络的学习是通过改变隐层节点基函数的中心向量和隐层至输出层权值向量进行.笔者采用一种动态自适应 RBF 神经网络结构,该结构基于最近邻聚类学习算法,是一种在线自适应聚类学习算法,不须事先确定隐层节点个数,完成聚类所得到的 RBF 神经网络是最优的,并且此算法可在线学习.采用该算法构造网络结构具体过程如下^[5]:

设有 N 对输入-输出数据对 (x^k, v^k) , $k = 1, 2, \dots, N$, RBF 神经网络隐层非线性激励函数取高斯函数, RBF 网络隐单元输出为:

$$h_i(x^k) = \exp\left(-\frac{\|x^k - C_i\|^2}{b^2}\right), \quad (1)$$

式中: x^k 是输入矢量; y^k 是输出; $h_i(x^k)$ 是第 i 个隐单元的输出; C_i 是第 i 个隐单元高斯基函数的中心矢量, $i = 1, 2, \dots, n$, n 为隐单元数; b 是高斯基函数的半径.

* 收稿日期:2006-10-21

基金项目:安徽省教育厅自然科学基金项目(2006KJ032B)

作者简介:李绍铭(1965-),男,副教授,硕士生导师,研究方向为电力电子技术应用及自动控制,电话(Tel.):0555-2311735;

E-mail:lism@ahut.edu.cn.

1) 定义 $S(l)$ 用于存放属于各类的输出矢量之和, 定义一个计数器 $CT(l)$ 用于统计属于各类的样本个数, 其中 l 为类别数, 选择一个半径 b .

2) 从第一个数据对 (x^1, y^1) 开始, 在 x^1 上建立一个聚类中心, 令 $C_1 = x^1, S(1) = y^1, CT(1) = 1$. 这样建立的 RBF 网络只有一个隐单元, 其中心为 C_1 , 该隐单元到输出层的权矢量为 $w_1 = S(1)/CT(1)$.

3) 假设考虑第 k 个样本数据对 (x^k, y^k) 时, $k = 3, 4, \dots, N$, 设已存在 n 个聚类中心, 其中心点分别为 C_1, C_2, \dots, C_n , 网络中已有 n 个隐单元. 分别求出 x^k 到这 n 个聚类中心的距离 $\|x^k - C_i\|, i = 1, 2, \dots, n$, 设 $\|x^k - C_j\|$ 为这些距离中的最小距离, 即 C_j 为 x^k 的最近邻聚类, 则:

如果 $\|x^k - C_j\| > b$, 则将 x^k 作为一个新聚类中心, 并令 $C_{n+1} = x^k, S(n+1) = y^k, CT(n+1) = 1$. 且保持 $S(i), CT(i)$ 的值不变. 在上述建立的 RBF 网络中再添加第 $n+1$ 个隐单元, 该隐单元到输出层的权矢量为 $w_{n+1} = S(i)/CT(i)$.

如果 $\|x^k - C_j\| \leq b$, 则 $S(j) = S(j) + y^k, CT(j) = CT(j) + 1$. 隐单元到输出层的权矢量为 $w_i = S(i)/CT(i)$.

4) 根据上述规则建立的动态 RBF 神经网络如图 1 所示, 网络的输出为:

$$f_m(x^k) = \frac{\sum_{i=1}^n w_i \exp\left(-\frac{\|x^k - C_i\|^2}{b^2}\right)}{\sum_{i=1}^n \exp\left(-\frac{\|x^k - C_i\|^2}{b^2}\right)} \quad (2)$$




图1 改进型 RBF 神经网络的拓扑结构

由网络结构的构造过程可见: 1) 高斯基函数半径的大小决定了网络的复杂程度. b 越小, 所得到的聚类数目就越多, 从而导致越复杂的非线性回归过程, 计算量也越大. 但 b 是一个一维参数, 一般都可以通过实验和误差信息找到一个适当的值. 2) 由于每一个输入-输出数据对都可能产生一个新的聚类, 因此构造出的网络是一种动态网络, 实际上同时在进行参数和结构 2 个过程的自适应调整.

2 基于改进型 RBF 神经网络 PID 控制原理

多变量控制系统 (MIMO) 属于复杂过程控制系统, 由于系统有多个输入和输出, 内部结构比较复杂, 往往存在一定程度的耦合, 常需要对系统进行解耦. 笔者采用改进型 RBF 神经网络辨识器对多变量非线性时变系统进行辨识, 获得系统辨识模型, 用该模型的预测输出来取代系统的实际输出, 再在此基础上进行 PID 参数在线自整定, 实现了系统的解耦控制.

基于改进型 RBF 神经网络的 PID 控制器由 2 部分构成: PID 控制器和改进型 RBF 神经网络辨识器. PID 控制器直接对被控对象进行闭环控制, 3 个参数根据辨识器提供的信息由梯度下降法在线进行整定; 辨识器利用改进型 RBF 神经网络强大的非线性映射能力和快速、准确跟踪被控对象变化的优点, 获得 PID 参数在线自整定所需的 Jacobian 辨识信息 (即被控对象的输出对控制输入的灵敏度信息), 适应了系统运行状态的变化.

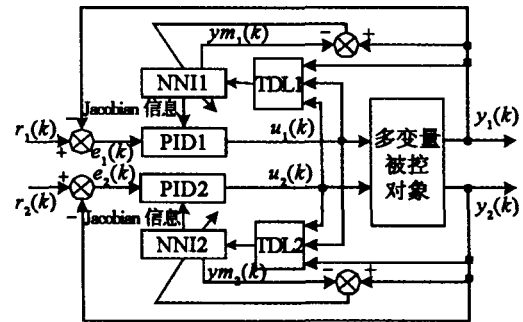


图2 改进型 RBF 神经网络 PID 控制系统结构

图 2 为改进型 RBF 神经网络 PID 控制系统结构图, 图中多变量被控对象为二变量耦合系统, 即 2 个输入输出通道, 且通道间存在耦合. 控制系统并联设有 2 个改进型 RBF 神经网络辨识器 NNI1 和 NNI2, 2 个 PID 控制器 PID1 和 PID2, 分别对 2 个输入输出通道进行控制, 以实现解耦. TDL1 和 TDL2 为延迟线, 对当前采样信号进行一定的延时; $r_1(k)$ 和 $r_2(k)$ 为系统参考输入, $y_1(k)$ 和 $y_2(k)$ 为系统实际输出, $y_{m1}(k)$ 和 $y_{m2}(k)$ 为辨识器输出.

设双输入双输出非线性离散系统模型为:

$$\left. \begin{aligned} y_1(k) &= f_1[y_1(k-1), \dots, y_1(k-n_1), u_1(k-1), \dots, \\ &\quad u_1(k-n_2), u_2(k-1), \dots, u_2(k-n_3)], \\ y_2(k) &= f_2[y_2(k-1), \dots, y_2(k-n_1), u_1(k-1), \dots, \\ &\quad u_1(k-n_2), u_2(k-1), \dots, u_2(k-n_3)]. \end{aligned} \right\} \quad (3)$$

式中: $u_1(k)$ ($u_2(k)$) 和 $y_1(k)$ ($y_2(k)$) 分别为 k 时刻系统的输入和输出; $f_1(\cdot)$ 和 $f_2(\cdot)$ 为非线性函数;

n_1, n_2 和 n_3 为采样延迟时间步数。

现采用 NNI1, NNI2 对系统进行辨识, 2 个通道的输入为:

$$\begin{cases} x_1^k = [u_1(k-1), \dots, u_1(k-n_2), u_2(k-1), \dots, \\ u_2(k-n_3), y_1(k-1), \dots, y_1(k-n_1)] , \\ x_2^k = [u_2(k-1), \dots, u_2(k-n_3), u_1(k-1), \dots, \\ u_1(k-n_2), y_2(k-1), \dots, y_2(k-n_1)] . \end{cases}$$

NNI1 和 NNI2 的辨识输出为:

$$\begin{cases} y_{m_1}(k) = f_{m_1}(x_1^k, C_1, C_2, \dots, C_{q_1}, w_1, w_2, \dots, w_{q_1}) , \\ y_{m_2}(k) = f_{m_2}(x_2^k, C_1, C_2, \dots, C_{q_2}, w_1, w_2, \dots, w_{q_2}) , \end{cases} \quad (4)$$

q_1, q_2 分别为 k 时刻 NNI1 和 NNI2 隐单元的个数。

根据改进型 RBF 神经网络辨识器对系统的在线辨识可获得 Jacobian 矩阵, 以 NNI1 为例, 其值为:

$$\begin{aligned} \frac{\partial y_1(k)}{\partial u_1(k)} &\approx \frac{\partial y_{m_1}(k)}{\partial u_1(k)} \approx \frac{\partial y_{m_1}(k)}{\partial x_1^k} \approx \\ &\frac{\partial f_{m_1}(x_1^k, C_1, \dots, C_{q_1}, w_1, \dots, w_{q_1})}{\partial x_1^k} = \\ &\frac{2(p_1 \cdot T_1 - p_2 \cdot T_2)}{p_1^2 \cdot b^2} , \end{aligned} \quad (5)$$

其中:

$$\begin{aligned} p_1 &= \sum_{i=1}^{q_1} \exp\left(-\frac{\|x_1^k - C_i\|^2}{b^2}\right), \\ p_2 &= \sum_{i=1}^{q_1} w_i \exp\left(-\frac{\|x_1^k - C_i\|^2}{b^2}\right), \\ T_1 &= \sum_{i=1}^{q_1} w_i \cdot \exp\left(-\frac{\|x_1^k - C_i\|^2}{b^2}\right) \cdot C_{1,i}, \\ T_2 &= \sum_{i=1}^{q_1} \exp\left(-\frac{\|x_1^k - C_i\|^2}{b^2}\right) \cdot C_{1,i}, \end{aligned}$$

$C_{1,i}$ 为 $u_1(k-1)$, w_i 为每次在线更新的权值。

PID 控制器采用经典数字增量式, 仍以控制器 PID1 为例, 设系统输入指令信号为 $r_1(k)$, 则系统的控制误差为 $e_1(k) = r_1(k) - y_1(k)$. 控制算法为:

$$u_1(k) = u_1(k-1) + k_{p_1}[e_1(k) - e_1(k-1)] + k_{i_1}e_1(k) + k_{d_1}[e_1(k) - 2e_1(k-1) + e_1(k-2)]. \quad (6)$$

$$\text{令} \begin{cases} x_{c_1}(1) = e_1(k) - e_1(k-1), \\ x_{c_1}(2) = e_1(k), \\ x_{c_1}(3) = e_1(k) - 2e_1(k-1) + e_1(k-2). \end{cases}$$

控制器的输出为:

$$u_1(k) = u_1(k-1) + k_{p_1}x_{c_1}(1) + k_{i_1}x_{c_1}(2) + k_{d_1}x_{c_1}(3). \quad (7)$$

若将 $k_{p_1}, k_{i_1}, k_{d_1}$ 视为依赖于系统运行状态的可调系数, 则可将式(7)描述为:

$u_1(k) = g_1[u_1(k-1), k_{p_1}, k_{i_1}, k_{d_1}, x_{c_1}(1), x_{c_1}(2), x_{c_1}(3)]$, 式中 $g_1(\cdot)$ 是与 $k_{p_1}, k_{i_1}, k_{d_1}, u_1(k-1), y_1(k)$ 等有关非线性函数, 可以用改进型 RBF 神经网络通过训练和学习来找到这样一个最佳控制规律。

PID1 控制器参数整定的性能指标为:

$$J_{c_1} = \frac{1}{2}[r_1(k) - y_1(k)]^2 \approx \frac{1}{2}[r_1(k) - y_{m_1}(k)]^2$$

控制器的参数 $k_{p_1}, k_{i_1}, k_{d_1}$ 采用梯度下降法在线调整, 具体调整算法为:

$$k_{p_1}(k) = k_{p_1}(k-1) - \eta_{p_1} \frac{\partial J_{c_1}}{\partial y_1} \frac{\partial y_1}{\partial u_1} \frac{\partial u_1}{\partial k_{p_1}} = k_{p_1}(k-1) + \eta_{p_1} e(k) \frac{\partial y_1}{\partial u_1} x_{c_1}(1), \quad (8)$$

$$k_{i_1}(k) = k_{i_1}(k-1) - \eta_{i_1} \frac{\partial J_{c_1}}{\partial y_1} \frac{\partial y_1}{\partial u_1} \frac{\partial u_1}{\partial k_{i_1}} = k_{i_1}(k-1) + \eta_{i_1} e_1(k) \frac{\partial y_1}{\partial u_1} x_{c_1}(2), \quad (9)$$

$$k_{d_1}(k) = k_{d_1}(k-1) - \eta_{d_1} \frac{\partial J_{c_1}}{\partial y_1} \frac{\partial y_1}{\partial u_1} \frac{\partial u_1}{\partial k_{d_1}} = k_{d_1}(k-1) + \eta_{d_1} \frac{\partial J_{c_1}}{\partial y_1} \frac{\partial y_1}{\partial u_1} \frac{\partial u_1}{\partial k_{d_1}} x_{c_1}(3), \quad (10)$$

式(8)-(10)中, $\eta_{p_1}, \eta_{i_1}, \eta_{d_1}$ 为学习速率, 其值取 (0,1) 间的数. $\frac{\partial y_1}{\partial u_1}$ 为未知被控对象的信息, 由于辨识器输出能很好地逼近实际输出, 因此可以把辨识输出 $y_{m_1}(k)$ 近似看作 $y_1(k)$.

由于改进型 RBF 神经网络的结构是随输入-输出数据对动态变化的, 网络的构造和学习同时进行, 因此获得被控对象的 Jacobian 信息较常规 RBF 网络辨识器更加准确, 且能很好地适应参考信号的变化; PID 控制器根据从 RBF 神经网络辨识器获得的梯度调整所需的 Jacobian 信息在线对参数 k_p, k_i, k_d 进行整定, 从而适应了系统运行状态的实时变化, 使系统获得对应于某种最优控制律下的 PID 参数^[6]; 同时, 由于并联的 RBF 神经网络辨识器输入包含了其它通道中的控制器的输出信息, 这样辨识器的辨识信息同时包含了其它通道对其的耦合影响, 进而实现了解耦。

3 系统仿真实例

设有二变量耦合非线性时变被控对象:

$$\begin{cases} y_1(k) = \frac{a(k) \cdot y_1(k-1)}{1 + y_1(k-1)^2} + u_1(k-1) + 0.2u_2(k-2), \\ y_2(k) = \frac{a(k) \cdot y_2(k-1)}{1 + y_2(k-1)^2} + 0.8u_2(k-1) + 0.7u_1(k-2), \end{cases} \quad (11)$$

式(11)中,系 $a(k)$ 数是慢时变的, $a(k) = 1.2(1 - 0.8e^{-0.01k})$.

改进型 RBF 神经网络辨识器的输入为:

$$\begin{cases} x_1^k = [u_1(k-1), u_1(k-2), u_2(k-1), u_2(k-2), y_1(k-1)], \\ x_2^k = [u_2(k-1), u_2(k-2), u_1(k-1), u_1(k-2), y_2(k-1)]. \end{cases}$$

系统参考输入信号为:

$$\begin{cases} r_1(k) = 1.0 \operatorname{sign}(\sin(2\pi kt)) , \\ r_2(k) = -1.0 \operatorname{sign}(\sin(2\pi kt)) . \end{cases}$$

采样周期取 0.001 s;基函数半径 b 取 0.72;控制器 3 个参数取值范围取 $[-10, 10]$, 初始值取 $k_p = 0.03, k_i = 0.02, k_d = 0.03$;控制器参数的学习速率取 $\eta_p = \eta_i = \eta_d = 0.01$. 经过 2 500 个采样周期后的 Matlab 仿真结果如图 3、图 4、图 5 所示,图 6 给出了采用一般 RBF 神经网络实现 PID 控制的仿真结果.




图 3 基于改进型 RBF 神经网络 PID 控制的方波输出响应




图 4 改进型 RBF 神经网络辨识器的辨识结果




图 5 被控对象 Jacobian 信息 dy 的辨识结果




图 6 基于常规 RBF 神经网络 PID 控制的方波输出响应

由仿真结果可以看出:1)在最初 200 个采样周期,由于改进型 RBF 神经网络刚刚建立,隐单元数少,辨识器的辨识效果不太理想,辨识信息不够准确,PID 参数的调整还不能很好地适应输入信号的变化,解耦控制不太理想;2)经过 200 个采样周期的学习后,动态 RBF 神经网络辨识器就能精确辨识系统输出,系统响应快,解耦控制效果较好;3)随着学习的增加,辨识精度进一步提高,辨识信息较准确地反映了系统的运行状态,解耦控制相当理想.

4 结 论

神经网络 PID 控制中神经网络结构的选择在获得系统期望的动态响应和跟踪效果方面起着非常重要的作用,一般要求所选用的神经网络的学习算法具有快速有效的在线学习功能,以满足实时控制、适应对象和环境变化的需要.笔者设计出一种基于最近邻聚类算法的动态 RBF 神经网络 PID 控制器,它克服了常规 RBF 神经网络 PID 控制器中学习算法的缺点,计算量小、跟踪时间短、网络收敛精度高,PID 参数很好地适应了环境的变化,解耦控制效果较好.仿真结果说明了该方法的有效性.

参考文献:

- [1] 薛昊洋,刘红军. 基于 BP 神经网络的多变量 PID 解耦控制[J]. 仪器仪表标准化与计量,2005,(6):7-9.
- [2] 李晓静,吴庆宪. 一类神经网络整定 PID 参数的非线性系统解耦方法[J]. 河南科技大学学报,2005,26(1):48-51.
- [3] 刘金琨. 先进 PID 控制及其 MATLAB 仿真[M]. 北京:电子工业出版社,2003:104-111.
- [4] 王立新. 自适应模糊系统与控制—设计与稳定性分析[M]. 北京:国防工业出版社,1995:39-41,39-52.
- [5] 朱明星,张德龙. RBF 网络基函数中心选取算法的研究[J]. 安徽大学学报,2000,24(1):72-78.
- [6] 陶永华,尹怡欣,葛芦生. 新型 PID 控制及其应用[M]. 北京:机械工业出版社,1998:158-170.

PID Control for Multivariable System Based on Ameliorative RBF Neural Networks

LI Shao-ming, LIU Ying-hu

(School of Electrical Engineering & information, Anhui University of Technology, Maanshan 243002, China)

Abstract: Aiming at systems which are of characteristics of multi-input and multi-output, nonlinearity and time-variation in the industrial control fields, this paper presents a intelligent PID control method based on ameliorative RBF neural networks, which constructs RBF neural networks identifier on-line and identifies a controlled object on-line by means of adopting the nearest neighbor-clustering algorithm, and adjusts parameters of PID controller on-line and realizes decoupling control of multivariable, nonlinear and time-variation system. The simulation result indicates that the controller can get parameters which are optimal under some control law, it makes the decoupled system, compared to the PID control method based on the conventional RBF neural networks, has perfect dynamic and static performances, possesses the advantages of high precision, quick response speed and is of great adaptability and robustness.

Key words: ameliorative RBF neural networks; nonlinear and time-variation system; PID control; nearest neighbor-clustering algorithm; decoupling control

(编辑 侯 湘)

(上接第52页)

Application of a FDTD/MOMTD Hybrid Method to the Scattering Problem of the Ground Penetrating Radar

ZHOU Chao, YI Ji-hui

(Key Laboratory of High Voltage Engineering and Electrical New Technology Under the State Ministry of Education, Chongqing University, Chongqing 400030, China)

Abstract: In order to analyze and research the scattering problem of the ground penetrating radar under the ground, a hybrid method combining FDTD and MOMTD is constructed to solve the problem. The curve of current on central feeding point of pick-up antenna is obtained by simulating when different distance between the ideal conductor and the ground is considered. correctness of the result gained by employing the hybrid method is proved through qualitative and quantitative analysis.

Key words: finite difference time domain; method of moments in the time domain, hybrid method

(编辑 姚 飞)