

输出不可量测非线性系统的神经模型参考自适应控制¹

曾 成 赵保军 何佩琨

(北京理工大学电子工程系 北京 100081)

摘 要 该文针对被控对象输出不可量测的非线性系统, 引入一个便于在线辨识的扩展神经网络模型, 提出一种基于前馈-反馈结构的神经网络模型参考自适应控制方法, 给出了具有全局收敛性的网络训练算法, 并分析了控制系统的稳定性。仿真结果表明该控制方法是有效的, 而且对网络初始权值的选取及被控对象特性参数的扰动都具有良好的鲁棒性。

关键词 神经网络控制, 模型参考自适应控制, 非线性系统, 有源噪声控制

中图分类号 TN-052, TP872

1 引 言

神经网络模型参考自适应控制是常用的非线性系统控制方法^[1-2], 其典型结构如图 1 所示。神经网络辨识器 (NNI) 辨识被控对象的模型, 作为误差反向传播通道 (图 1 中虚线所示), 把误差 e 反传至神经网络控制器 (NNC) 输出端, 以便于采用 BP 算法对 NNC 的权值进行自适应调整。受激励信号和神经网络模型泛化能力的限制, NNI 辨识的模型通常只能表征被控对象工作点附近的特性, 为跟踪工作点及被控对象特性的时变, 必须在控制过程中不断地对模型进行在线自适应修正。

在一些自适应对消系统中, 例如有源噪声、振动控制系统^[3-5], 被控对象和参考模型均未知, 且它们的输出 y 和 y_d 都无法量测, 能测量的只是被控对象输出与参考模型输出对消后的误差 e 。由于无法获得 y , 图 1 中被控对象模型的在线辨识将无法实现。对于这类系统, 目前一般都采用离线辨识的方法, 预先确定一个能表征所有工作点特性的尽可能准确的对象模型^[4,5]。

本文针对此类输出不可量测的非线性系统, 引入一个可以在线辨识的扩展的神经网络模型 (Extended Neural Network Model, ENNM), 给出了一种基于前馈-反馈控制结构的神经网络模型参考自适应控制方法。

2 控制系统结构

图 2 为控制系统的结构框图。 r 为参考输入, u 为控制输入, e 为参考模型输出与被控对象输出叠加后的误差。为解决被控对象和参考模型的输出不可量测问题, 把参考模型和被控对象结合起来, 视为一个以 u , r 为输入, e 为输出的扩展对象。为了便于进行误差 e 的反向传播, 采用非线性静态模型:

$$e_m(k) = f[u(k), \dots, u(k - M_u), r(k), \dots, r(k - M_r)] \quad (1)$$

作为该扩展对象的输入-输出模型, 并用具有线性输出层的单隐层前馈网络进行辨识, 可得到 ENNM 模型:

$$e_m(k) = f[u(k), \dots, u(k - M_u), r(k), \dots, r(k - M_r), \mathbf{H}(k)] = \sum_{j=1}^{N_M^H} h_j^{HO}(k) \sigma[z_j(k)] \quad (2)$$

¹ 2001-10-26 收到, 2002-05-13 改回




图1 神经网络模型参考自适应控制的典型结构




图2 输出不可量测系统的神经网络模型参考自适应控制

其中

$$z_j(k) = \sum_{m=0}^{M_u} h_{mj}^u(k)u(k-m) + \sum_{n=0}^{M_r} h_{nj}^r(k)r(k-n) \quad (3)$$

e_m 为模型输出, $\sigma(\cdot)$ 为隐层神经元激活函数, N_M^H 为隐层神经元的个数, $\mathbf{H}(k)$ 为 k 时刻 ENNM 网络的权值矩阵, $h_j^{HO}(k)$ 为 k 时刻第 j 个隐层神经元到输出神经元的连接权值, $h_{mj}^u(k)$, $h_{nj}^r(k)$ 分别为 k 时刻各输入神经元到隐层神经元 j 的连接权值。由于该 ENNM 模型是因果的, 且其各输入输出量都可以量测, 所以能够在线辨识。

NNC 采用线性输出层的动态递归单隐层网络, r 作为 NNC 的前馈输入, e 作为反馈输入, 使整个系统形成前馈-反馈复合控制结构。定义

$$\mathbf{X}(k) = [e(k-1), \dots, e(k-N_e), u(k-1), \dots, u(k-N_u), r(k), \dots, r(k-N_r)]^T \quad (4)$$

式中 T 表示转置, 则 k 时刻 NNC 的输出为

$$u(k) = g[\mathbf{X}(k), \mathbf{W}(k)] = \sum_{j=1}^{N_C^H} w_j^{HO}(k)\sigma[y_j(k)] \quad (5)$$

其中

$$y_j(k) = [\mathbf{W}_j^{IH}(k)]^T \mathbf{X}(k) = \sum_{i=1}^{N_C^I} w_{ij}^{IH}(k)x_i(k) \quad (6)$$

$$\begin{aligned} \mathbf{W}_j^{IH}(k) &= [w_{1j}^{IH}(k), w_{2j}^{IH}(k), \dots, w_{N_C^I j}^{IH}(k)]^T \\ &= [w_{1j}^e(k), \dots, w_{N_e j}^e(k), w_{1j}^u(k), \dots, w_{N_u j}^u(k), w_{0j}^r(k), \dots, w_{N_r j}^r(k)]^T \end{aligned} \quad (7)$$

N_C^H 为隐层神经元的个数, $N_C^I = N_e + N_u + N_r + 1$ 为输入层神经元的个数, $\mathbf{W}(k)$ 表示 k 时刻 NNC 网络的权值矩阵, $w_j^{HO}(k)$ 为 k 时刻第 j 个隐层神经元到输出神经元的连接权值, $\mathbf{W}_j^{IH}(k)$ 为 k 时刻输入层神经元到第 j 个隐层神经元的连接权值向量, $w_{1j}^e(k)$, $w_{mj}^u(k)$, $w_{nj}^r(k)$ 分别为 k 时刻各输入神经元到隐层神经元 j 的连接权值。

ENNM 和 NNC 中的各输入延迟线的长度 M_u, M_r, N_e, N_u, N_r 等视具体系统的阶次和纯延迟大小而定。

3 ENNM 和 NNC 的学习算法

ENNM 的目的是逼近扩展对象的输入-输出特性, 定义其目标函数为

$$J_m(k) = (1/2)[e_m(k) - e(k)]^2 \quad (8)$$

则 ENNM 的学习训练就是一般的非线性静态系统神经网络辨识问题。考虑实时性和收敛性要求, 采用计算量较小, 收敛快, 且能全局寻优的自适应快速 BP(Globally Convergent Adaptive Quick Back Propagation, GCAQBP) 算法来进行在线学习训练, 具体算法参见文献 [6]。

定义如 (1) 式所示的模型并采用如图 2 所示的控制结构之后, 就把一个参考输出的跟踪问题变成了一个最小输出控制问题。定义控制器 NNC 的目标函数为

$$J = (1/2)E[e^2(k)] \quad (9)$$

实时应用时还常采用如下的瞬时目标函数:

$$J(k) = (1/2)e^2(k) \quad (10)$$

利用梯度下降算法对 NNC 进行在线实时训练,

$$\mathbf{W}(k+1) = \mathbf{W}(k) - \Delta \mathbf{W}(k) = \mathbf{W}(k) - \eta(k) \nabla_w(k) \quad (11)$$

式中 $\nabla_w(k)$ 为 J 关于 NNC 权值 $\mathbf{W}(k)$ 的瞬时梯度:

$$\nabla_w(k) = \frac{\partial J}{\partial \mathbf{W}(k)} = \sum_{t=0}^L e(k+t) \frac{\partial e(k+t)}{\partial \mathbf{W}(k)} \quad (12)$$

其中 L 为被控对象脉冲响应的长度。因为 (12) 式需要未来时刻的误差, 无法实时应用, 所以 NNC 学习算法的关键在于如何把误差经 ENNM 进行反向传播, 求得上述 $\nabla_w(k)$ 的一个估计值 $\hat{\nabla}_w(k)$ 。由于 ENNM 输入层的延迟线的影响, 如果仅仅考虑 k 时刻的权值 $\mathbf{W}(k)$ 对误差 $e(k)$ 的作用, 取 $\hat{\nabla}_w(k) = \partial J(k) / \partial \mathbf{W}(k)$ 来近似估计 $\nabla_w(k)$ 是不准确的, 对于非最小相位对象或具有纯延时的对象, 这种近似可能导致算法发散 [2]。一个更准确的估计是 [4,5]

$$\hat{\nabla}_w(k) = \sum_{t=0}^{M_e} \frac{\partial J(k)}{\partial \mathbf{W}(k-t)} = \sum_{t=0}^{M_e} \frac{\partial J(k)}{\partial u(k-t)} \frac{\partial u(k-t)}{\partial \mathbf{W}(k-t)} \quad (13)$$

令 $\delta(k-t) = \partial J(k) / \partial u(k-t)$, 并根据 (2), (3) 式把它进一步展开, 有

$$\delta(k-t) = e(k) \cdot \sum_{j=1}^{N_M^H} h_j^{HO}(k-t) \sigma'[z_j(k-t)] h_{ij}^u(k-t) \quad (14)$$

利用 (13), (14) 式并结合 GCAQBP 算法, 就可以对 NNC 进行在线训练了。其权值修正公式为

$$\Delta w_j^{HO}(k) = -\eta(k) \sum_{t=0}^{M_u} \delta(k-t) \sigma[y_j(k-t)], \quad j = 1, 2, \dots, N_C^H \quad (15)$$

$$\Delta w_{ij}^{IH}(k) = -\eta(k) \sum_{t=0}^{M_u} \delta_j^H(k-t) x_i(k-t), \quad i = 1, 2, \dots, N_C^I, \quad j = 1, 2, \dots, N_C^H \quad (16)$$

(15), (16) 式中

$$\delta_j^H(k-t) = \sigma'[y_j(k-t)]\delta(k-t)w_j^{HO}(k-t) \quad (17)$$

$$\eta(k) = \lambda(k)[J(k)]^\mu / \|\hat{\nabla}_w(k)\|^2 \quad (18)$$

$$\|\hat{\nabla}_w(k)\|^2 = \sum_{j=1}^{N_C^H} \sum_{t=0}^{M_u} \{\delta(k-t)\sigma[y_j(k-t)]\}^2 + \sum_{j=1}^{N_C^H} \sum_{i=1}^{N_C^I} \sum_{t=0}^{M_u} [\delta_j^H(k-t)x_i(k-t)]^2 \quad (19)$$

$$\lambda(k) = \lambda_0/[1+J(k)] \quad (20)$$

其中 λ_0 为初始学习率, $0 < \lambda_0 < 1$; $0 < \mu \leq 1$ 。

4 稳定性分析

如果被控对象和参考模型都是 BIBO 的, 那么对于有界的输入 r 和 u , 采用 GCAQBP 算法能够保证 ENNM 的辨识是全局收敛的^[6]。下面仅分析 NNC 的收敛性和整个系统的稳定性, 先给出以下几点假设:

假设 1 $\forall x \in R$, $\exists C > 0$, 使得 $|\sigma(x)| \leq C|x|$ 。

假设 2 如果 ENNM 已收敛, 则 $\forall k \in [0, \infty)$, 有 $[\nabla_w(k)]^T \hat{\nabla}_w(k) > 0$ 。

假设 3 选用的 NNC 网络具有任意精度的非线性函数逼近能力, 且 $\forall k \in [0, +\infty)$, $\exists C_w > 0$, 使得 $\|\mathbf{W}(k)\| < C_w$, 即 NNC 的权值有界。

关于 NNC 的收敛性以及系统的稳定性, 有以下定理:

定理 1 如果被控对象和参考模型是 BIBO 的, 那么采用由图 2 所示系统结构和由 (2)–(7) 式定义的 ENNM 和 NNC, 在满足假设 1–3 的条件下, 对于有界参考输入 $r(k)$, 利用 (14)–(20) 式所示的神经网络自适应控制律进行控制, 可以使系统渐近收敛, 即有 $\lim_{k \rightarrow \infty} J(k) = 0$ 。

证明 首先证明在 ENNM 收敛的条件下 NNC 的收敛性。

根据 (11) 式所示的梯度下降法以及 (15), (16) 式的权值修正算法, NNC 权值矩阵对时间 t 的导数可记为

$$\frac{d\mathbf{W}(k)}{dt} = -\eta(k)\hat{\nabla}_w(k) \quad (21)$$

考虑目标函数 J 随时间的变化率:

$$\begin{aligned} \frac{dJ}{dt} &= \left[\frac{\partial J}{\partial \mathbf{W}(k)} \right]^T \frac{d\mathbf{W}(k)}{dt} = -[\nabla_w(k)]^T \eta(k) \hat{\nabla}_w(k) \\ &= -\lambda(k)[J(k)]^\mu [\nabla_w(k)]^T \hat{\nabla}_w(k) / \|\hat{\nabla}_w(k)\|^2 \end{aligned} \quad (22)$$

而由 (10) 式可知 $J(k) \geq 0$, 故由假设 2 有 $dJ/dt \leq 0$, 当且仅当 $J(k) = 0$ 时, 才有 $dJ/dt = 0$ 。也就是说, 在 ENNM 已收敛的条件下, 采用 (14)–(20) 式所示的神经网络自适应控制律修正 NNC 的权值, 总可以使系统渐近收敛于 $J(k) = 0$ 。

下面再证明在暂态调节阶段, NNC 输出有界。由于参考输入 $r(k)$ 和误差 $e(k)$ 有界, 不妨设 $\|\mathbf{X}\|$ 有界, 则根据假设 1 和假设 3, k 时刻控制输出的绝对值为

$$\begin{aligned}
|u(k)| &\leq \sum_{j=1}^{N_C^H} |w_j^{HO}(k)| \cdot |\sigma[y_j(k)]| \\
&\leq \sum_{j=1}^{N_C^H} |w_j^{HO}(k)| \cdot C \|[\mathbf{W}_j^{IH}(k)]^T \mathbf{X}(k)\| \\
&\leq \sum_{j=1}^{N_C^H} |w_j^{HO}(k)| \cdot C \|\mathbf{W}_j^{IH}(k)\| \cdot \|\mathbf{X}(k)\|
\end{aligned} \quad (23)$$

有界。

根据以上分析, NNC 在暂态调节阶段输入输出有界, 稳态渐近收敛, 所以整个系统是渐近稳定的, 稳态收敛于全局最优点 $J(k) = 0$ 。证毕

最后对以上定理的 3 个假设条件作以下说明: 假设 1 是很容易满足的, 常用的神经元激活函数如 Sigmoid 函数和线性函数, 都满足该假设。假设 2 只是系统稳定的充分条件, 一般说来, 个别时刻的梯度估计值不满足条件, 并不会影响系统的稳定性。假设 3 的权值有界条件很容易在算法中实现, 但受实际应用中网络结构复杂程度的限制, NNC 网络一般无法实现任意精度的逼近, 所以通常 $\lim_{k \rightarrow \infty} J(k) \neq 0$, 而总会有一定的稳态误差存在。

5 仿真实例及分析

考虑以下 3 种具有纯延时的典型非线性被控对象模型^[1]:

$$\text{对象1} \quad y_1(k) = \frac{y_1(k-1)y_1(k-2)[y_1(k-1)+0.25]}{1+y_1^2(k-1)+y_1^2(k-2)} + u(k-3) \quad (24)$$

$$\text{对象2} \quad y_2(k) = \frac{y_2(k-1)}{1+y_2^2(k-1)} + [u(k-2)+1]u(k-2)[u(k-2)-1] \quad (25)$$

$$\text{对象3} \quad y_3(k) = 0.6y_3(k-2) + \frac{u(k-1)}{1+u^2(k-2)} \quad (26)$$

参考模型均选为

$$y_m(k) = 0.6y_m(k-1) + 0.4r(k-3) \quad (27)$$

参考输入

$$r(k) = \sin(\pi k/80 + \pi/3) \quad (28)$$

激活函数

$$\sigma(x) = \frac{1 - e^{-x}}{1 + e^{-x}} \quad (29)$$

其它仿真条件为: $M_u = 7$, $M_r = 7$, $N_e = 3$, $N_u = 3$, $N_r = 3$, $N_M^H = 20$, $N_C^H = 15$; NNC 的初始学习率 $\lambda_0 = 0.4$, ENNM 的初始学习率为 0.8, NNC 和 ENNM 的初始权值在 $[-0.5, 0.5]$ 之间随机选取。

3 种被控对象的仿真控制结果 (前 400 个采样周期的控制误差) 分别如图 3(a), 3(b), 3(c) 中实线所示, 为便于考察控制效果, 图中同时给出了被控对象的输出 (虚线), 实际应用中它是不可量测的。从图 3 可见, 3 种情况下都有比较好的稳态控制效果, 被控对象 1, 3 的收敛速度较快, 具有多值逆映射的非线性对象 2 的收敛速度相对要慢一些, 稳态误差也较大。

需指出, NNC 和 ENNM 的初始权值对系统的暂态过程有较大的影响, 图 3 只是分别在某个特定初始权值条件下的结果。虽然从多次仿真结果来看, 控制系统对初始权值是稳定的, 即对于随机选取的初始权值, 系统最终总能收敛, 但在某些初始权值条件下, 暂态控制输出的幅值相当大, 对于不允许大的暂态冲击的系统, 应该在算法中采取一些限幅措施。

为了进一步考察本文提出的控制系统对于被控对象特性参数扰动的鲁棒性, 在仿真过程中, 每间隔 300 个采样周期 (T), 按 $1 \rightarrow 2 \rightarrow 3 \rightarrow 1$ 的顺序依次切换 3 种被控对象模型, 其仿真结果如图 4 所示。图 4 中, 每次切换被控对象后都能在较短的时间内重新收敛, 表明控制系统对被控对象扰动具有良好的鲁棒稳定性。

此外, 由于系统引入了反馈控制, 对于输出侧的恒值扰动和周期扰动也有一定的抑制能力, 仿真研究也证明了这一点, 限于篇幅, 其结果不一一给出。




图 3 仿真结果 1




图 4 仿真结果 2

6 结 论

对于输出不可量测非线性系统,在采用神经网络模型参考自适应控制时,被控对象的模型难以在线修正。本文引入一个便于在线辨识的扩展对象模型,基于前馈-反馈控制结构,提出了一种适用于此类系统的神经网络模型参考自适应控制方法。采用一种比较准确的误差梯度估计方法,并利用具有全局收敛性的 GCAQBP 算法对扩展模型网络和控制网络进行在线自适应训练,改善了系统的收敛特性。仿真结果表明该控制方法是有效的,而且对网络初始权值的选取及被控对象特性参数的扰动具有良好的鲁棒性,对输出侧的恒值与周期扰动也有一定的抑制能力。这种方法在有源噪声、振动控制等自适应对消系统中,具有良好的应用前景。

参 考 文 献

- [1] 李新忠,简林柯,何 钺,非线性系统的模型参考神经网络控制,信息与控制, 1996, 25(6), 367-372.
- [2] G. Lightbody, G. W. Irwin, Direct neural model reference adaptive control, IEE Proc. Control Theory Appl., 1995, 142(1), 31-43.
- [3] S. J. Elliott, P. A. Nelson, Active noise control, IEEE Signal Processing Mag., 1993, 10(4), 12-35.
- [4] S. D. Snyder, N. Tanaka, Active control of vibration using a neural network, IEEE Trans. on Neural Networks, 1995, 6(4), 819-828.
- [5] M. Bouchard, B. Paillard, C. T. L. Dinh, Improved training of neural networks for the nonlinear active control of sound and vibration, IEEE Trans. on Neural Networks, 1999, 10(2), 391-401.
- [6] 何玉彬,李新忠,神经网络控制技术及其应用,北京,科学出版社, 2000, 39-48.

A NEURAL NETWORK MODEL REFERENCE ADAPTIVE CONTROL FOR THE NONLINEAR SYSTEM WITH UNAVAILABLE OUTPUTS

Zeng Cheng Zhao Baojun He Peikun

(Dept. of Electronic Engineering, Beijing Institute of Technology, Beijing 100081, China)

Abstract In this paper, by introducing an extended neural network model which can be easily identified on-line, a neural network model reference adaptive control method based on a feedforward-feedback structure is proposed for a class of nonlinear systems whose outputs are not measurable. A training algorithm with global convergence is offered, and the stability of the control system is analyzed. The simulation results show that this method is effective, and it has good robustness for both the selection of original network weights and the disturbance of plant parameters.

Key words Neural network control, Model reference adaptive control, Nonlinear system, Active noise control

曾 成: 男, 1971 年生, 博士生, 研究领域为数字信号处理、噪声有源控制、智能控制等。

赵保军: 男, 1960 年生, 博士, 副教授, 研究领域为图像处理、信号处理、神经网络与模糊控制等。

何佩琨: 男, 1940 年生, 博士生导师, 教授, 研究领域为信号处理等。