



基于 ANN 模型的非线性 自校正预测控制器¹⁾

王殿辉 柴天佑

(东北大学自动化研究中心 沈阳 110006)

摘要 采用局部建模和线性化方法,提出了一种基于人工神经网络(Artificial Neural Network——ANN)模型的非线性自校正预测控制算法.仿真实例表明,所提控制策略可有效地控制某些未知多变量非线性动态系统.

关键词 非线性多变量系统,自校正预测控制,人工神经网络,局部线性化.

1 基于 ANN 的预测模型

记 $NN^S(W)$ 为具有三层络结构的 BP 网络, S 表示隐层节点个数, W 表示网络的权重. 考虑如下 MIMO 非线性系统

$$y_j(k+1) = f_j[Y_1^k(n_{j1}), \dots, Y_p^k(n_{jp}), U_1^k(m_{j1}), \dots, U_q^k(m_{jq})], \quad j = 1, 2, \dots, p. \quad (1)$$

其中 $Y_l^k(n_{jl}) = [y_l(k), \dots, y_l(k-n_{jl})]$; $U_l^k(m_{jl}) = [u_l(k), \dots, u_l(k-m_{jl})]$; $u_l(k), y_l(k)$ 分别为系统在第 k 时刻的输入输出分量; f_j 是未知的非线性函数. 这里假设系统的阶次已知, 对象能控且是 BIBO 稳定的.

首先, 采用 p 个独立的 BP 网络进行离线辨识, 以建立被控系统的粗略模型.

记 $X_j(k) = [Y_1^k(n_{j1}), \dots, Y_p^k(n_{jp}), U_1^k(m_{j1}), \dots, U_q^k(m_{jq})]$. 于是, 选择适当幅值的随机输入激励被控系统, 可得到以下用于离线学习的导师信号

$$TS_N^0 = \{TS_{N_1}^0, TS_{N_2}^0, \dots, TS_{N_p}^0\}, \quad (2)$$

$$TS_{N_j}^0 = \{X_j(k) \rightarrow y_j(k+1) | u_i(k) \in \delta_i \text{Rand}(1), i = 1:q, k = 1:N\}, \quad (3)$$

其中 $\text{Rand}(1)$ 表示 $[-1, 1]$ 之间的均匀分布, δ_i 为幅值, N 为样本集合的长度.

应用串并联辨识模式对 TS_N^0 进行 L 次训练, 记学习后得到的 BP 网络模型为

$$\hat{f}_j(X_j) = NN_j^S[X_j, W_j(0, L); \eta_{j0}], \quad j = 1, 2, \dots, p, \quad (4)$$

其中 $W_j(0, L)$ 表示 BP 网络模型经 L 次学习后得到的权矩阵, η_{j0} 为离线学习率.

其次, 用闭环系统产生的输入输出数据 (IOD) 集合

1) 国家自然科学基金资助课题.

$$TS_{M_j}^k = \{X_j(k-i) \rightarrow y_j(k-i+1) | i = 1 : M\} (j = 1, 2, \dots, p) \quad (5)$$

对已经建立的 $NN_{j_j}^s$ 模型进行 R 次在线学习后得到精确的局部预测模型. 此时, 权的初始值为 $W_j(0, L)$. 因为 M 一般较小, 因此网络的学习速度很快, 通常 $R \leq 5$ 即可. 记在线学习后得到的局部 BP 网络模型为

$$\hat{f}_j(X_j) = NN_{j_j}^s[X_j, W_j(k, R); \eta_j], \quad j = 1, 2, \dots, p, \quad (6)$$

其中 $W_j(k, R)$ 表示对 $TS_{M_j}^k$ 经 R 次训练得到的权矩阵, η_j 为在线学习率. 根据 BP 网络的泛化能力, 在当前工作点附近可将得到的 $NN_{j_j}^s[W_j(k, R)]$ 模型作为系统的预测模型, 即有

$$y_{M_j}(k+1|k) = NN_{j_j}^s[X_j(k), W_j(k, R); \eta_j], \quad j = 1, 2, \dots, p, \quad (7)$$

其中 $y_{M_j}(k+1|k)$ 表示在第 k 时刻由 BP 网络预测模型计算得到的 $k+1$ 时刻的预测输出

为了书写方便, 以下简记 $NN_{j_j}^s[X_j, W_j(k, R); \eta_j]$ 为 $NN_{j_j}^s(X_j)$.

2 控制器设计

对于一步超前预测控制, 滚动优化性能指标函数简化成如下形式^[4]:

$$J(k) = \frac{1}{2} \left\{ \sum_{j=1}^p [y_{M_j}(k+1|k) - y_{d_j}(k+1)]^2 + \sum_{j=1}^q \lambda(j) \Delta u_j^2(k) \right\}, \quad (8)$$

其中 $\lambda(j) > 0$ 为加权因子, $\Delta u(k) = u(k) - u(k-1)$, $y_{d_j}(k)$ 为系统的期望输出.

记 $U(k) = [u_1(k), u_2(k), \dots, u_q(k)]^T$. 由极值的必要条件知它应满足方程

$$\sum_{j=1}^p [y_{M_j}(k+1|k) - y_{d_j}(k+1)] \frac{\partial y_{M_j}(k+1|k)}{\partial u_i(k)} + \lambda(i) \Delta u_i(k) = 0, \quad i = 1, 2, \dots, q. \quad (9)$$

对(9)式的求解只能采用一些数值方法. 然而, 以迭代的形式给出控制律含有参数的选取问题在实现和实时性要求上具有一定的局限性. 为此, 本文采用如下 ANN 预测模型的局部线性化方法

$$y_{M_j}(k+1|k) \approx NN_{j_j}^s(\tilde{X}_j) + \sum_{i=1}^q DNN_{j_j}^s(\tilde{X}_j) \Delta u_i(k), \quad j = 1, 2, \dots, p, \quad (10)$$

其中

$$\tilde{X}_j = [Y_1^k(n_{j1}), Y_2^k(n_{j2}), \dots, Y_p^k(n_{jp}), \tilde{U}_1^k(m_{j1}), \tilde{U}_2^k(m_{j2}), \dots, \tilde{U}_q^k(m_{jq})], \quad (11)$$

$$\tilde{U}_i^k(m_{ji}) = [u_i(k-1), u_i(k-1), u_i(k-2), \dots, u_i(k-m_{ji})], \quad (12)$$

$$DNN_{j_j}^s(\tilde{X}_j) = \left. \frac{\partial NN_{j_j}^s[X_j, W_j(k, R); \eta_j]}{\partial u_i(k)} \right|_{x_j = \tilde{X}_j}. \quad (13)$$

将(10)式代入方程组(9)中, 求解线性方程组, 得控制律为

$$U(k) = U(k-1) + A^{-1}(k)B(k), \quad (14)$$

这里 $A(k) = [a_{ij}] \in R^{q \times q}$, $B(k) = [b_1(k), b_2(k), \dots, b_q(k)]^T \in R^q$, 且有

$$a_{ij}(k) = \sum_{l=1}^p DNN_{l_j}^s(\tilde{X}_l) DNN_{l_j}^s(\tilde{X}_l) + \delta_{ij} \lambda(i), \quad (15)$$

$$b_i(K) = \sum_{l=1}^p [y_{di}(k+1) - NN_{i'}^s(\tilde{X}_l)] DNN_{i'}^s(\tilde{X}_l). \quad (16)$$

为了进一步改善控制器对模型失配和外界干扰的鲁棒性,有必要用实测的输出信息来校正未来输出的预测值,以构成闭环预测. 这里采用一种最简单的校正方法,即

$$y_{pj}(k+1|k) = y_{M_j}(k+1|k) + e_j(k), j = 1, 2, \dots, p, \quad (17)$$

其中 $e_j(k)$ 可由 k 时刻的实际输出与 ANN 预测模型在上一个工作点的预测值之差构成,亦即

$$e_j(k) = y_j(k) - NN_j^s[X_j(k-1), W_j(k, R); \eta_j]. \quad (18)$$

于是,只需修正(16)式中的 $NN_{i'}^s(\tilde{X}_l)$ 为 $NN_{i'}^s(\tilde{X}_l) + e_l(k)$, 即得到闭环预测下的控制律

现将本文提出的非线性自校正预测控制算法归纳如下:

步骤 1. 选取适当的 ANN 结构,通常隐节点个数选取在 3—10 之间;

步骤 2. 离线辨识,用适当幅值的随机输入激励未知对象,以产生导师信号集 TS_N^0 , 并使用批量学习方法对 TS_N^0 进行 L 次训练;

步骤 3. ANN 模型的在线学习,用 BP 学习算法对当前记忆的闭环 IOD 集合 $TS_{M_j}^k (j = 1, 2, \dots, p)$ 进行 R 次训练,通常 $R \leq 5$;

步骤 4. 反馈校正,用 \tilde{X}_j 代入预测模型,分别计算 $NN_j^s(\tilde{X}_j)$ 和 $DNN_j^s(\tilde{X}_j)$, 并用(18)式校正预测模型的输出 $y_{M_j}(k+1|k)$;

步骤 5. 计算控制律 $U(k)$, 并将其作用于被控系统;

步骤 6. 记录最新得到的闭环 IOD 集合 $TS_{M_j}^k$, 重复步骤 3—5, 直到完成整个控制过程.

3 仿真例子

被控对象为双输入输出的非线性系统

$$\begin{cases} y_1(k+1) = \frac{y_1(k)}{1 + y_1^2(k) + y_2^2(k-1)} + u_1(k-1)u_2(k-1) + u_1(k)u_2(k), \\ y_2(k+1) = \frac{y_1(k-1)y_2(k)}{1 + y_2^2(k)} + u_1(k-1)u_1(k) + u_2(k-1)u_2(k), \end{cases} \quad (19)$$

初值条件为零,跟随信号为 $y_{di} = i (i = 1, 2)$. 选用的 BP 网络模型均为 $NN^5(W)$ 结构,在线学习率和加权系数分别取为 $\lambda_1 = 3.45, \lambda_2 = 2.35, \eta_1 = \eta_2 = 0.15, M = 1, R = 3$. 为了考察控制算法对系统参数和结构变化的适应能力,仿真中在 $k = 50$ 时对第一个子系统加入 25% 的负载;在 $k = 100$ 时对第二个子系统加入 25% 的负载;在 $k = 150$ 时刻以后改用仿真模型

$$\begin{cases} y_1(k+1) = \frac{1.5y_1(k) + 0.75}{1 + y_1^2(k) + y_2^2(k-1)} + u_1(k-1)u_2^3(k-1) + u_1^3(k)u_2(k), \\ y_2(k+1) = \frac{[y_1(k-1) - 1]y_2(k)}{1 + y_2^2(k)} + u_1^3(k-1)u_1(k) + u_2(k-1)u_2^3(k). \end{cases} \quad (20)$$

系统的跟踪响应及控制输入曲线如图 1 所示.

应该指出, 加权因子作为控制器参数将对系统的动态响应产生很大的影响. 至于如何得到合适的加权系数, 以使闭环系统具有期望的动态响应, 目前还没有有效的方法. 这方面的工作有待于作进一步的研究.

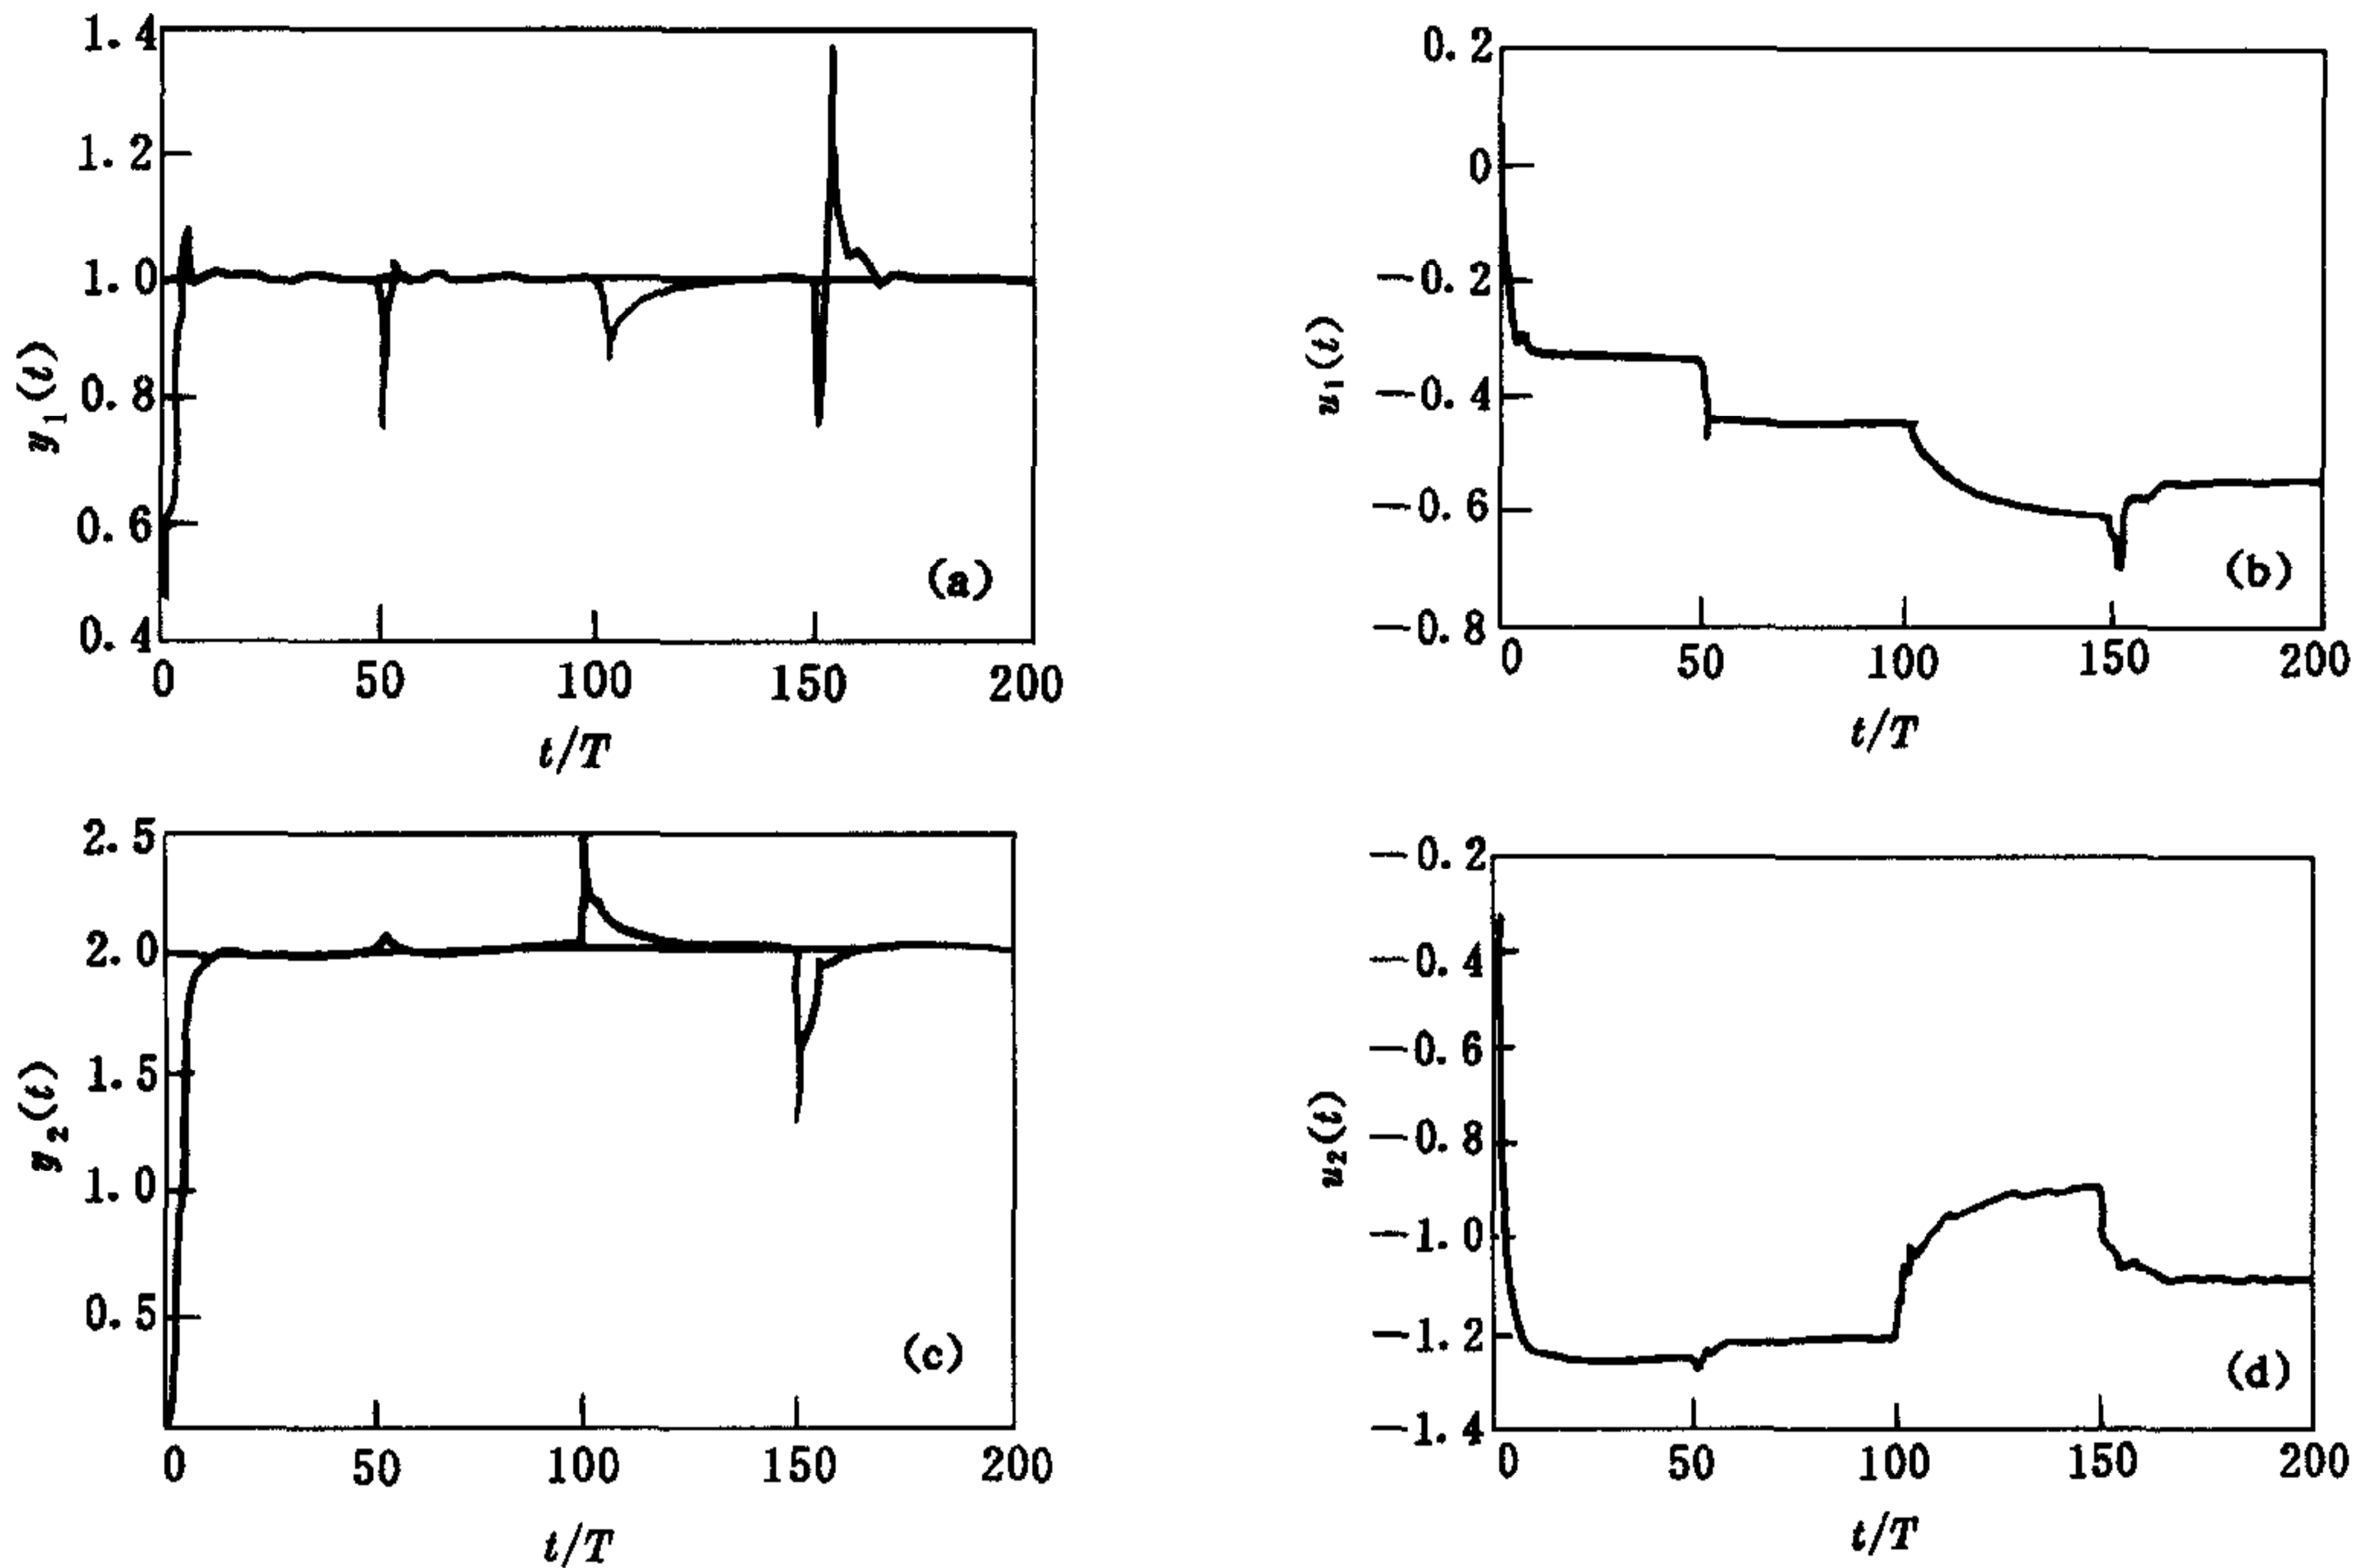


图 1 非线性系统的跟踪响应及控制输入曲线

参 考 文 献

- [1] Narendra K S, Parthasarathy K. Identification and control of dynamical systems using neural networks. *IEEE Trans. on Neural Networks*, 1990, 1(1):1-27.
- [2] Jean S D, Naveen B, Thomas J M. Neural net based model predictive control. *Int. J. of Control*, 1991, 54(6): 1453-1468.
- [3] Willis M J et al. Artificial neural networks in process estimation and control. *Automatica*, 1992, 28(6):1181-1187.
- [4] Clark D W, Mohtadi C, Tuffs P S. Generalized predictive control, Part I :the basic algorithm; Part II : extension and interpretations. *Automatica*, 1987, 23(2):137-160.

ARTIFICIAL NEURAL NETWORKS BASED NONLINEAR SELF-TUNING PREDICTIVE CONTROLLER

WANG DIANHUI CHAI TIANYOU

(Research Center for Automation of Northeastern University, Shenyang 110006)

Abstract Using neural networks as nonlinear predictors, this paper proposes a self-tuning predictive controller for multivariable nonlinear systems. The main idea of the presented control strategy is to use the linearization technique in feedforward neural net identifier models. Simulation examples including a time-varying plant and a nonlinear plant are shown to demonstrate the effectiveness of the control algorithm.

Key words Multivariable nonlinear systems, self-tuning predictive control, artificial neural networks, local linearization.