

基于神经网络的自适应状态观测器

覃祖旭 李渊涛 张洪钺

(北京航空航天大学自动控制系, 北京, 100083)

THE ADAPTIVE OBSERVER BASED ON NEURAL NETWORK

Qin Zuxu, Li Yuantao, Zhang Hongyue

(Department of Automatic Control, Beijing University of Aeronautics and Astronautics, Beijing, 100083)

摘要 利用 BP 神经网络动态系统对一类非线性时变系统的状态进行了估计。利用神经网络的“学习-遗忘”特性, 提出了非线性时变系统的自适应状态观测器, 对其结构及特性进行了讨论。仿真结果表明这种自适应状态观测器能跟踪系统参数及状态的变化。

关键词 状态估计, 神经网络, 非线性系统-时间相关

中图分类号 V249.121, TP273.2

Abstract The back-propagation neural network is applied to the state estimation of nonlinear time-varying system. An adaptive state estimator based on the neural network is proposed, and the structure and characteristics of the observer are discussed. The results of estimation show that the proposed nonlinear state observer can deal with a large unknown nonlinearity and track the real system state satisfactorily.

Key Words state estimation, neural nets, nonlinear systems-time dependence

由于 BP 神经网络对于非线性具有很强的适应能力, 出现了许多利用 BP 网络的动态系统方案, 但都没有涉及到非线性系统的状态估计。文献[1]针对非线性时不变系统提出了基于 BP 网的状态估计方案。在此基础上, 考虑到一类非线性时变系统参数的慢变特性, 提出了自适应状态观测器方案, 并进行了讨论及仿真。

1 BP 神经网络

BP 神经网络由输入层, 输出层和至少一个隐层构成。各层由若干非线性处理单元组成。神经元及 BP 结构示意图见图 1。图中 $h(\cdot)$ 为神经元激活函数, 选用双曲正切函数作为激活函数




图 1 神经元及 BP 网结构示意图

设第 j 个神经元输入及输出为 net_j 及 o_j , W_{ij} 表示第 i 与第 j 个神经元的联接权

1993 年 6 月 22 日收到, 1993 年 12 月 3 日收到修改稿

值。BP 有如下关系

$$h(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad \text{net}_j = \sum_i w_{ij} o_i \quad o_j = h(\text{net}_j) \quad (1)$$

Hech - Nielson^[2] 指出, 三层 BP 网如果其隐单元可以任意设定, 那么它能以任意精度逼近一个非线性函数, 即三层 BP 网有任意的学习能力。

2 自适应状态观测器

考虑如下非线性时变系统

$$\begin{cases} X_k = f(X_{k-1}, u_k, \beta(k)) \\ y_k = g(X_k) \end{cases} \quad (2)$$

其中, $u \in E^l$; $y \in R^m$; $X \in R^n$; $f(\cdot)$ 为已知的非线性函数; $g(\cdot)$ 为已知的非线性观测函数; $\beta(k)$ 表示系统随时间变化的参数, 它是一个随时间慢变的非线性函数。

为了从非线性时变系统的输入 u_k 及输出 y_k 估计系统的状态, 用图 2 结构的 BP 网络动态系统构成状态观测器, 系统的输出作为估计器的一个输入。动态方程如下

$$\begin{cases} Z_k = r(Z_{k-1}, u_k, y_k, \theta) \\ \hat{y}_k = g(Z_k) \end{cases} \quad (3)$$

其中 $Z_k \in R^n$ 为 BP 网络动态系统的状态, θ 为 BP 网权值和阈值向量。

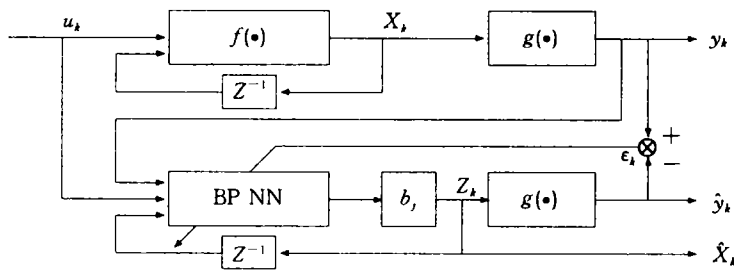


图 2 自适应状态观测器结构图

由于采用双曲正切函数, 故 BP 网络输出限制在 $[-1, +1]$ 之间, 因而在 BP 网络输出上乘以增益 b_j , 使其输出值域同真实系统相匹配。 b_j 理论上可取为 ∞ , 但实际系统的输出实际上是有限制的, 因此根据实际系统来确定。

为了正确估计系统状态, BP 网络的权、阈值通过极小化代价函数 E_k (式 (4)) 来进行调整, 式中 $\varepsilon_k = y_k - \hat{y}_k$

$$E_k = \frac{1}{2} \varepsilon_k^T \varepsilon_k + \frac{1}{2} \rho [Z_k - f(Z_{k-1}, u_k, \beta(k))]^T [Z_k - f(Z_{k-1}, u_k, \beta(k))] \quad (4)$$

对于非线性系统式(2), 若 $\beta(k)$ 为不变量, 即对于时不变系统, 有如下结论^[1]

定理: 系统式(2)为时不变系统, 如果通过调整 BP 网的权值及阈值, 使神经网络的式(3)充分逼近真实系统, 即 E_k 达到极小值零, 则有 $Z_k = X_k$ 。

对于时变系统来说, 由于系统参数是时变的, 没有上述结论。但考虑到系统参数的

慢变特性, 仍可以在一个个小的时间片段上近似地估计时变系统的状态。

BP 网采用误差反向传播的算法来修正权值及阈值。修正量表示为

$$\Delta\theta = -\eta_k \text{grad}E_k \quad (5)$$

其中, η_k 为学习因子, $\text{grad}E_k$ 为 E_k 的梯度。将 θ 分开表示为权值 w_{ij} 及阈值 γ_j 则有

$$\Delta w_{ij} = -\eta_k \frac{\partial E_k}{\partial w_{ij}}, \quad \Delta \gamma_j = -\eta_k \frac{\partial E_k}{\partial \gamma_j}$$

其中: $\frac{\partial E_k}{\partial w_{ij}(k)} = \left[(\hat{y}_k - y_k)^T \frac{\partial g}{\partial Z_k^T} + [Z_k - f(u_k, Z_{k-1}, \beta(k))]^T \rho \right] \delta_j o_i(k)$

$$\frac{\partial E_k}{\partial \gamma_j(k)} = \left[(\hat{y}_k - y_k)^T \frac{\partial g}{\partial Z_k^T} + [Z_k - f(u_k, Z_{k-1}, \beta(k))]^T \rho \right] \delta_j$$

$$\delta_j = \frac{\partial Z_k}{\partial \text{net}_j(k)} = \frac{dh(\text{net}_j(k))}{d\text{net}_j(k)} \sum_m = \frac{\partial Z_k}{\partial \text{net}_j(k)} w_{mj}$$

给修正加上冲量项, 可使学习在“平坦”处步伐加大, 式中 α_k 为冲量项因子。

$$\Delta w_{ij}(k) = -\eta_k \frac{\partial E_k}{\partial w_{ij}(k)} + \alpha_k \Delta w_{ij}(k-1), \quad \Delta \gamma_j(k) = -\eta_k \frac{\partial E_k}{\partial \gamma_j(k)} + \alpha_k \Delta \gamma_j(k-1)$$

3 自适应估计算法

如图 3 所示将 (t_0, t_N) 时间历程分为 N 有重叠的时间窗口, 用 WIN_i 表示。 WIN_0 表示 $t < t_0$ 段, WIN_1 表示第一个窗口, N_1 表示用 WIN_1 内数据训练的网络。其他以此类推。另外用 WIN_{i+1} 表示 WIN_i 与 WIN_{i+1} 的重叠部分, 这里 WIN_i 的长度可以不同。




图 3 时间窗口示意图

利用 BP 网络的“学习-遗忘”特性, 在各个时间窗口上不断学习, 跟踪非线性时变系统的参数变化并进行状态估计。自适应估计过程如下:

(a) 预学习段 WIN_0 : 利用系统的任意数据作为样本训练, 获得网络 N_0 。

(b) WIN_1 期间等待新数据, 并利用 N_0 及真实系统输出 y_k 来估计系统状态。

(c) 在 $\text{WIN}_2 - \text{WIN}_{12}$ 期间, 利用 WIN_1 内数据训练新网络 N_1 , 同时利用 N_0 及 y_k 估计系统状态, 并接受一部分新数据。

(d) 重复(b)及(c)过程, 用 WIN_i 内数据训练网络 N_i , 并估计系统状态, 等待新数据。


整个估计过程是不间断的, 但学习过程是间断的, 估计总是采用最新获得的神经网络, 从而可获得系统整个时间期间的状态估值。

4 仿真


仿真系统

$$\begin{cases} X_{k+1} = (1 + \beta(k))\sin X_k - 0.1X_{k-1} + u_k \\ y_k = 0.01X_k^3 + X_{k-1} \end{cases} \quad \beta(k) = \sin(0.035k)$$

BP 网络输入层、隐层、输出层神经元数目分别为 4、20、1。学习因子取为 0.2，冲量项因子取为 0.05，阈值选为 0。系统的输入采用白噪声。神经网络的预学习采用任意时间段的数据作为样本来进行。仿真采用等宽窗口，窗口宽度为 50 个时间间隔，每 10 步作一次数据更新及自适应学习。仿真结果见图 4 (a) 及图 4 (b)。可以看出，由于预学习是粗糙的，在开始段的估计也很不准确，但随着新数据的获得及训练，在后面的时间窗口内逐渐跟踪上真实系统的状态及参数变化。



(a) 系统状态 (实线) 及估计器估计的状态 (虚线)



(b) 系统输出 (实线) 及估计器的输出 (虚线)

图 4 仿真结果

参 考 文 献

- 1 Li Y T, *et al.* The nonlinear observer based on neural network. The first Chinese world congress on intelligent control and intelligent automation, Beijing; 1993
- 2 Nielsen R H. Theory of the back-propagation neural network. Proc IEEE 1989 Int Conf Neural Networks,
- 3 Chen F C. Back-propagation neural network for nonlinear self-tuning adaptive control. IEEE Control Systems Magazine, April 1990