

延时 2 回归神经网络及在超声马达控制中的应用

徐 旭^{1,2}, 梁艳春³, 时小虎³

(11 吉林大学数学学院, 吉林长春 130012; 21 南京航空航天大学振动工程研究所, 江苏南京 210016;

31 吉林大学计算机科学与技术学院, 国家教育部符号计算与知识工程重点实验室, 吉林长春 130012)

摘 要: 提出了一个结构简单的延时) 回归神经网络(Time2delay recurrent neural network, TDRNN) 模型. 通过在网络中同时引入延时结构和反馈结构来保证网络具有高的记忆/ 深度0和的记忆/ 分辨率0. 建立了 TDRNN 型的控制器对超声马达进行控制, 推导了 TDRNN 的动态递归反传算法. 在离散型 Lyapunov 稳定性的意义下, 导出了权值自适应学习速率的取值范围, 保证控制系统的快速收敛. 对超声马达速度控制的数值实验表明, 本文提出的延时) 回归神经网络在动态系统的辨识和控制方面具有很好的性能.

关键词: 延时; 回归神经网络; 超声马达; Lyapunov 稳定性

中图分类号: TP31 **文献标识码:** A **文章编号:** 03722112 (2004) 112191804

Time2Delay Recurrent Neural Network and Applications to Control of Ultrasonic Motors

XU Xu^{1,2}, LIANG Yan2chun³, SHI Xiao2hu³

(11 College of Mathematics Science, Jilin University, Changchun, Jilin 130012, China;

21 Institute of Vibration Engineering Research, Nanjing University of Aero. & Astro. Nanjing, Jiangsu 210016, China;

31 College of Computer Science and Technology, Jilin University, Key Laboratory of Symbol Computation and Knowledge Engineering of the Ministry of Education, Changchun, Jilin 130012, China)

Abstract: A time2delay recurrent neural network (TDRNN) model is proposed. TDRNN has a simple structure but far more / depth0 and / resolution ratio0 in memory by introducing the tim2delay and recurrent mechanism. A TDRNN controller is utilized for controlling ultrasonic motors. A dynamic recurrent back propagation algorithm is developed. To guarantee the fast convergence of the proposed neural network model, the optimal adaptive learning rates are derived in the sense of discret@type Lyapunov stability. Numer2 al experiments for controlling speeds of ultrasonic motors show that the TDRNN has good effectiveness in the identification and control for dynamic systems.

Key words: tim2delay; recurrent neural network; ultrasonic motor; Lyapunov stability

1 引言

超声马达(Ultrasonic Motor, USM)是一种新型驱动器, 具有许多优良的特性, 在军事、航空航天、医学等领域有着广泛的应用前景^[1]. 超声马达具有很强的非线性特性, 建立精确、实用的数学模型是很困难的. 因此传统的控制方法很难对超声马达实现有效的控制, 目前人们主要应用人工神经网络等智能方法对超声马达实施控制^[2,3].

人工神经网络(Artificial Neural Network, ANN)具有很强的学习能力、容错能力、并行计算能力和非线性映射的逼近能力等, 在模式识别、系统辨识与控制中获得了广泛的应用^[4]. 多层前向网络(FNN)是实际应用中广泛采用的一种网络结构, 它是静态网络, 为了控制动态系统则需要具有记忆性能的动

态网络.

/ 深度0和/ 分辨率0是衡量神经网络动态记忆特性的主要因素^[4]. 简单地说, 深度是指能存储以前多远的信息, 分辨率指对输入序列的各分量留住了多少信息. 延时单元记忆是低深度高分辨率的, 而大多数回归网络, 如对角回归神经网络(DRNN)^[5]和Elman网络等是高深度低分辨率的. 常见的神经网络结构在记忆性能上存在着不足^[4], 用于处理动态系统具有一定的缺陷. 因此, 建立记忆性能优良、快速收敛的高性能神经网络模型是应用的关键.

本文提出了一个结构简单、具有高深度、高分辨率的延时 2 回归神经网络结构(TDRNN)用于超声马达的控制. 对一种纵向振动超声马达的控制结果表明 TDRNN 具有良好的在线自适应能力.

2 延时2回归神经网络(TDRNN)

提出的延时2回归神经网络结构如图1所示. 图中 d 表示一步延时, / t 0 是具有固定自反馈增益 K(0 F K< 1)的/ 联系0 单元,/ o 0 为双曲正切神经单元,/ p 0 为线性神经单元. 记 TDRNN 输入层节点的输出是 $I = \{I_i\}_{i=1}^N$, 联系单元的输出为 $z = \{z_i\}_{i=1}^N$, 隐层节点的输出为 $x = \{x_i\}_{i=1}^H$, 网络的输出为 $u = \{u_i\}_{i=1}^R$. $C_i R^N @N$ 为联系单元到隐层的连接权, $D_i R^H @R$ 为隐层到输出层的连接权, 这里 N 是输入层的节点数, H 为隐层节点数, R 为输出层节点数.

联系单元节点在 k 时刻的输出表示为

$$z_i(k) = b_i(k) + Kz_i(k-1), z_i(0), (i = 1, 2, \dots, N) \quad (1)$$

其中 $b_i(k) = I_i(k) + A_i(k-1) + \dots + A_i(k-M)$ 是联系单元节点的输入, $A+ K= 1, M$ 为延时的时间步数. 将 $z_i(k-1), z_i(k-2), \dots$ 按照式(1)展开可得到

$$z_i(k) = b_i(k) + Kb_i(k-1) + \dots + K^{k-1}b_i(1) = A(k) + B(k), (i = 1, 2, \dots, N) \quad (2)$$

其中, $A(k) = I_i(k) + I_i(k-1) + \dots + I_i(k-M), B(k) = \sum_{i=n}^{k-2} K^{k-1-M-i} b_i(k-1-1)$

考虑一个具有 N 个输入节点, H 个隐节点和 R 个输出节点的三层网络, 用 S^{TDR}, S^{DR}, S^{EL} 分别表示 TDRNN, DRNN 和 Emen 网络的权值总数 (包括 H 个域值), 则:

$$S^{TDR} = (N+R+1) @H, S^{DR} = (N @R+2) @H, S^{EL} = (N+R+1) @H+H^2 \quad (3)$$

可以看出, 虽然引入了一些联系单元和延迟单元, 但是 TDRNN 的权值没有增加, 并且比 DRNN 和 Emen 网络有更少的可调权值. 另外, 根据文献[5], 对角回归神经网络是指数型记忆的, 其强度随当前时间的距离指数衰减, 是高深度低分辨率的可以看出. 而从公式(2)中看出, 由于 B(k) 和 A(k) 的存在, 使得 TDRNN 的联系单元不仅记忆了输入值过去各个时刻的数值, 具有很高的记忆深度; 而且也精确地记忆了当前时刻之前的 M 个时刻的输入数值, 具有一定的记忆分辨率. 如果 M 很大, 则 TDRNN 具有很高的记忆深度和很强的记忆分辨率.




图1 延时2回归神经网络(TDRNN)结构

3 TDRNN 用于超声马达的速度控制

驱动电压的频率是超声马达速度控制的主要因素, 本文把驱动电压的频率作为唯一的控制变量, 控制的结构如图2

所示. 其中, USM 是超声马达, NNC 和 NNI 分别是 TDRNN 型结构的神经网络控制器和辨识器, y_d 是速度控制值, y 为超声马达的实际输出速度, $e_c(k) = y_d(k) - y(k)$ 是速度差. $y_1(k)$ 是辨识网络在 k 时刻的输出, $e_l(k) = y(k) - y_1(k)$ 辨识误差.

3.1 辨识器 NNI 的动态反传算法

图2中辨识网络 NNI 的结构和第2节的 TDRNN 网络(图1)具有相同的性质和输入输出关系, 这里取输入为 $u(k)$ 和 $y(k-1)$, 则 NNI 隐层节点的输出和网络的输出分别为

$$x_j(k) = f\left[\sum_{i=1}^N C_{ij}(k) z_i(k)\right] \quad (j = 1, 2, \dots, H) \quad (4)$$

$$y_1(k) = \sum_{j=1}^H (D_j(k) x_j(k)) \quad (5)$$

其中 $f(x)$ 是双曲正切函数. 定义误差函数 $E_l(k) = 1/2e_l^2(k)$, 令 $L_d(k)$ 可调权值 D 的学习率, $L_c(k)$ 可调权值 C 的学习率. 于是 NNI 的权值的改变量为

$$\Delta D_j = -L_d(k) \frac{\partial E_l(k)}{\partial D_j} = L_d(k) e_l(k) \frac{\partial y_1(k)}{\partial D_j} \quad (6)$$

$$\Delta C_{ij} = -L_c(k) \frac{\partial E_l(k)}{\partial C_{ij}} = L_c(k) e_l(k) D_j \frac{\partial x_j(k)}{\partial C_{ij}} \quad (7)$$

假定采样间隔较小, 故可近似认为 $f_{c_j}(k) \approx f_{c_j}(k-1)$, 于是

$$\begin{aligned} \frac{\partial x_j(k)}{\partial C_{ij}} &= f_{c_j}(k) z_i(k) = f_{c_j}(k) [Kz_i(k-1) + b_i(k)] \\ &= f_{c_j}(k) b_i(k) + K \frac{f_{c_j}(k)}{f_{c_j}(k-1)} \frac{\partial x_j(k-1)}{\partial C_{ij}} \\ &\approx f_{c_j}(k) b_i(k) + K \frac{\partial x_j(k-1)}{\partial C_{ij}} \end{aligned} \quad (8)$$

根据误差反向传播算法, 辨识网络 NNI 的可调权值的学习算法如下

$$D_j(k) = D_j(k-1) + \Delta D_j(k), (j = 1, 2, \dots, H) \quad (9)$$

$$C_{ij}(k) = C_{ij}(k-1) + \Delta C_{ij}(k), (i = 1, 2, \dots, N; j = 1, 2, \dots, H) \quad (10)$$

3.2 NNI 的收敛性

定理1 设 NNI 的权值修正由式(9)和式(10)确定, 如果学习率 $L_c(k) > 0, L_d(k) > 0$, 并且满足

$$0 < L_d(k) + \frac{\partial y_1(k)}{\partial D} + L_c(k) + \frac{\partial y_1(k)}{\partial D} < 2 \quad (11)$$

则 NNI 的辨识过程收敛, 其中 $\partial + \partial$ 代表欧氏范数.

证明 定义 Lyapunov 能量函数为 $E_l(k) = 1/2e_l^2(k)$, 即:

$$\Delta E_l(k) = E_l(k+1) - E_l(k) = \frac{1}{2}e_l^2(k+1) - \frac{1}{2}e_l^2(k) \quad (12)$$

由于权值 D 和 C 最终决定了辨识误差, 所以学习过程的误差可以表示为

$$\begin{aligned} e_l(k+1) &= e_l(k) + \left[\frac{\partial e_l(k)}{\partial D}\right]^T \Delta D + \left[\frac{\partial e_l(k)}{\partial C}\right]^T \Delta C \\ &= e_l(k) - \left[\frac{\partial y_1(k)}{\partial D}\right]^T \Delta D - \left[\frac{\partial y_1(k)}{\partial C}\right]^T \Delta C \end{aligned} \quad (13)$$

定义: $G = L_d(k) + \frac{\partial y_1(k)}{\partial D} + L_c(k) + \frac{\partial y_1(k)}{\partial C}$, 则根据式(12)有

$$\Delta E_l(k) = \frac{1}{2}e_l^2(k)[(1-G)^2 - 1] = -\frac{1}{2}e_l^2(k)B(k) \quad (14)$$




图 2 超声马达控制结构图

其中: $B(k) = 1 - (1 - G)^2 = G(2 - G)$. 当 $0 < G < 2$ 时有 $B(k) > 0$. 由式(14), 有 $E_1(k) < 0$. 注意到 $E_1(k) > 0$, 根据离散型的 Lyapunov 稳定性方法, 当 $t \rightarrow \infty$ 时训练误差将达到最小. 定理 1 证毕. 为了保证辨识快速收敛, 尚须计算 $+9y_1(k)/9D +$ 和 $+9y_1(k)/9C +$.

根据公式(4)和(5)有 $\frac{9y_1(k)}{9D} = x_j(k)$, 按照欧氏范数的定义, 有 $+9y_1(k)/9D + = \sqrt{\sum_{j=1}^H (x_j)^2}$. 根据公式(7)和(8)可以得到 $\frac{9y_1(k)}{9C_j} = D_j(k) \sum_{i=1}^k K^{k-i} f_{c_i}(k-i) b_i(k-i)$, 所以 $+ \frac{9y_1(k)}{9C} + = \sqrt{\sum_{i=1}^N \sum_{j=1}^H \left(\frac{9y_1(k)}{9C_j} \right)^2}$
 $= \sqrt{\sum_{i=1}^N \sum_{j=1}^H \left(D_j(k) \sum_{l=1}^k K^{k-l} f_{c_l}(k-l) b_l(k-l) \right)^2}$ (15)

实际计算时, 可以根据 $9y_1(k)/9D +$ 和 $+9y_1(k)/9C +$ 的瞬态值, 自适应地选取权重 $L_d(k)$ 和 $L_c(k)$, 使其满足公式(11), 以使辨识网络高效率地运行.

3.1.3 控制器 NNC 的动态反传算法

系统的控制结构如图 2 所示. 神经网络控制器 NNC 具有和第 2 节的 TDRNN 网络(图 1)相同的性质. 为了简化网络结构这里选取的两个输入 $y(k-1)$ 和 $y_d(k)$ 分别表示实际的速度值和速度期望值. 记 NNC 的输入节点的输出为 $I_i^c(k) = \{I_i^c(k)\}_{i=1}^{N^c}$, 联系单元节点的输入为 $b_i^c(k) = \{b_i^c(k)\}_{i=1}^{N^c}$, 隐层节点的输出为 $x_i^c = \{x_i^c(k)\}_{i=1}^{H^c}$, 其中 N^c 为输入层节点数, H^c 为隐层节点数. 类似于公式(1)和(2), NNC 中联系单元的输入为, $b_i^c(k) = I_i^c(k) + A_i^c(k-1) + \dots + A_i^c(k-M)$.

由于超声马达的驱动频率只在其固有频率附近才能正常工作, 所以本文把 NNC 中输出层神经元的变换函数取为如下的形式: $g(x) = (1 - e^{-x}) / (1 + e^{-x}) + u^*$, 这里 u^* 是额定驱动频率

类似于 2.1 节中 NNI 的动态反传算法的推导, 可以得到控制网络 NNC 的可调权值的学习算法为

$$B_j(k) = B_j(k-1) + \beta B_j(k), (j = 1, 2, \dots, H^c) \quad (16)$$

$$A_{ij} = A_{ij}(k-1) + \beta A_{ij}(k), (i = 1, 2, \dots, N^c; j = 1, 2, \dots, H^c) \quad (17)$$

这里, $\beta B_j(k) U L_B(k) e_c(k) Y_{ij}(k) x_j^c(k)$, $\beta A_{ij}(k) U L_A(k) e_c(k) Y_{ij}(k) B_j(k) 9x_i^c(k)/9A_{ij}$, $9x_i^c(k)/9A_{ij} U f_{c_i}(k) b_i^c(k)$

$+ K 9x_j^c(k-1)/9A_{ij}$. $Y_{ij} U \sum_{j=1}^H D_j(k) f_{c_j}(k) C_{ij}(k)$ 是马达的输出对控制输入的敏感度, $L_B(k)$ 表示 NNC 的隐层到输出层权值 B 的学习率, $L_A(k)$ 表示联系单元到隐层权值 A 的学习率.

3.1.4 NNC 的收敛性

定理 2 设 NNC 中权值的修正由式(16)和(17)确定, 如果学习率 $L_B(k)$ 和 $L_A(k)$ 满足 $L_A(k) > 0$, $L_B(k) > 0$, 并且 $0 < L_B(k) + 9y(k)/9B +^2 + L_A(k) + 9y(k)/9A +^2 < 2$, 则 NNC 的控制过程收敛.

证明 定义 Lyapunov 能量函数为 $E(k) = 1/2e_c^2(k)$, 类似于定理 1 的证明, 可以证明定理 2. 类似于 $+9y_1(k)/9D +$ 和 $+9y_1(k)/9C +$ 的计算, 可以得到 $+9y(k)/9B +$ 和 $+9y(k)/9A +$ 的计算公式.

$$+ \frac{9y(k)}{9B} + = \sqrt{\sum_{N=1}^H \left[Y_{ij}(k) x_j^c(k) \right]^2}$$

$$+ \frac{9y(k)}{9A} + = \sqrt{\sum_{N=1}^N \sum_{j=1}^H \left[Y_{ij}(k) B_j(k) \sum_{l=1}^k K^{k-l} f_{c_l}(k-l) b_l(k-l) \right]^2}$$

根据上面的分析可以看到, 本文提出的权值学习算法的计算量和存储量与传统的 BP 算法相当; 收敛性的证明没有做任何假设, 理论上具有良好的完整性. 但是由于应用了一阶导数近似, 所以得到的解只具有一阶精度.

4 数值模拟结果

图 3 所表示的是一个典型的纵向振动超声马达^[6]. 马达的具体参数为: 驱动频率 271.8KHZ, 驱动电压 300V, 额定输出力矩 21.5N#cm, 额定输出能量 50W.




图 3 超声马达的结构图

图 4 表示应用本文的控制方法对超声马达控制前后的速度曲线比较图, 其中在 $t \in [9158, 9163]$ 秒时有 0.15N#cm 的外力矩作用在马达上, 期望的控制值是 11.5m/s. 可以看出控制后马达的实际输出很好地逼近期望值. 表明基于控制的 TDRNN 对于常数值期望速度具有很好的控制效果.




图 5 比较了用本文的 TDRNN 控制器和常规的 FNN 控制器^[3]得到的控制速度的波动情况. 这里期望速度是一正弦曲线, 速度的波动定义为 $F = (V_{max} - V_{min}) / V_{aver}$

@ 100%, 其中 V_{\max} , V_{\min} , V_{aver} 分别表示速度的最大值、最小值和平均值. 可见, 采用常规的 FNN 控制器方法所得到的速度波动较大, 达到 61.8%. 而用本文方法得到的速度的波动仅为 21.4%, 精度可以提高 3 倍左右.

为了具体地比较不同的神经网络控制器对超声马达控制的误差情况, 这里采用前馈网络(FNN)^[3]、对角递归神经网络(DRNN)^[5]和本文的延时2回归神经网络(TDRNN)控制器对超声马达进行了数值实验. 三种网络采用相同的输入、隐层和输出层的节点. 从图 6 中可以看出, 与其它两种网络相比, TDRNN 结构不仅稳定性好, 而且控制精度更高, 收敛速度更快.

5 结论

本文提出了一个结构简单的延时) 回归神经网络模型. TDRNN 网络中同时引入延时结构和反馈结构来保证网络具有较深的记忆深度和很高的记忆分辨率. 建立了一个 TDRNN 型的控制器, 对一种纵向振动超声马达速度控制进行了数值实验, 结果表明 TDRNN 对多种形式的参考速度都有很好的控




图 5 两种方法的速度响应比较图




图 6 不同神经网络结构的控制平均误差

制效果, 并且具有很强的在线自适应能力. 说明提出的 TDRNN 在对复杂非线性系统的实时应用具有广泛的前景.

参考文献:

- [1] Sashida T, Kenjo T. An Introduction to Ultrasonic Motors [M]. Oxford UK: Clarendon Press, 1993.
- [2] Xu X, Liang YC, Lee HP, et al. Identification and speed control of ultrasonic motors based on neural networks [J]. Journal of Micromechanics and Microengineering, 2003, 13(1): 104-114.
- [3] Senju T, Miyazato H, Yokoda S, Uezato K. Speed control of ultrasonic motors using neural network [J]. IEEE Transactions on Power Electronics, 1998, 13(3): 381-387.
- [4] 阎平烦, 张长水. 神经网络与模拟进化计算 [M]. 北京: 清华大学出版社, 2000.
- [5] Ku CC, Lee KY. Diagonal recurrent neural networks for dynamic systems control [J]. IEEE Transactions on Neural Networks, 1995, 6(1): 144-156.
- [6] 徐旭, 梁艳春, 时小虎. 纵向振动超声马达的力学模型 [J]. 声学学报, 2003, 28(3): 223-228.

作者简介:



徐旭男, 1972 年出生于吉林, 吉林省长春市人, 吉林大学数学学院讲师, 博士, 主要研究方向是神经网络应用、MEMS 系统宏建模和智能控制.

梁艳春男, 1953 年出生于吉林, 吉林省吉林市人, 吉林大学计算机科学与技术学院教授、博士生导师, 主要研究方向包括计算智能、MEMS 动力模型缩减、智能控制、生物信息学等. Email: ycliang@public.cc.jl.cn.