

基于高阶神经网络扩展卡尔曼滤波器逆算法的 非线性挠性结构的姿态控制

刘春梅 沈毅 胡恒章

(哈尔滨工业大学控制工程系·哈尔滨, 150001)

摘要: 本文针对非线性挠性结构的姿态控制, 提出了一种基于高阶神经网络及径向基函数网络(RBFN)相结合的网络模型, 用于非线性挠性结构的动态系统辨识, 以及基于卡尔曼滤波器(EKF)逆算法的控制策略. 针对神经网络辨识时的模型误差, 提出了一种简单有效的补偿方法, 给出了建模误差补偿与未补偿时的仿真结果. 仿真得出, 该方法具有收敛快, 算法简单, 并能有效消除建模误差等优点.

关键词: 高阶神经网络; 扩展卡尔曼滤波器逆算法; 非线性挠性结构; 建模误差补偿

Attitude Control of Nonlinear Flexible Structure Based on Inversion Algorithm of Extended Kalman Filter of High-Order Neural Networks

Liu Chunmei, Shen Yi and Hu Hengzhang

(Department of Control Engineering, Harbin Institute of Technology·Harbin, 150001, P.R. China)

Abstract: According to the attitude control of nonlinear flexible structure, a high-order RBF neural network is presented in this paper which combines high-order neural network and Radial basis function network (RBFN). The high-order RBFN is used for dynamical identification of nonlinear flexible structure and for the design of control scheme based on inverse algorithm of extended Kalman filter (EKF). The modeling error can be compensated by a simple but efficient method that avoids the occurrence of divergence in the inverse algorithm, and the comparison of results is presented between modeling error compensation and no modeling error compensation. According to the simulation, it is explicit that this method is of these characters such as fast convergence and simple algorithm.

Key words: high-order neural networks; extended kalman filter; nonlinear flexible structure; compensation of modeling error

1 引言(Introduction)

大型挠性结构(如卫星的太阳帆板)是复杂的非线性动态系统, 带有内在的未建模动态特性及结构不确定性, 以及三轴之间相耦合的非线性. 本文针对挠性结构非线性耦合, 以及多个挠性模态的特点, 采用高阶径向基函数网络, 用单层连接权值实现, 避免了一阶神经网络的多层连接权值, 以及权值计算的复杂性和多个偏微分的求解^[3]. 并采用了基于挠性结构前馈动力学特性的神经网络辨识模型的扩展卡尔曼滤波器逆算法^[4]. 该控制策略包含了两个部分. 第一部分由在线辨识的挠性结构的近似神经网络模型组成; 第二部分实现了基于神经网络模型的扩展卡尔曼滤波器逆算法, 计算控制量的输出. 同时, 针对神经网络的建模误差, 提出了一种简单有效的基于统计思想的在线补偿方法, 并给出了建模误差补偿前后的仿真结果.

2 用于辨识的神经网络模型(The neural network model for identification)

考虑一个如下的非线性动态系统

$$x(k+1) = f(x(k), u(k)). \quad (1)$$

其中 $x(k) \in \mathbb{R}^n$, $u(k) \in \mathbb{R}^m$ 分别为 k 时刻系统的状态向量和控制输入向量. $f(\cdot)$ 为未知的函数, 可用神经网络来逼近.

2.1 高阶 RBF 神经网络(High order RBF neural network)

本文结合高阶神经网络模型, RBF 神经网络模型, 提出了一种高阶 RBF 串并网络, 用于非线性挠性结构的动态系统辨识, 如图 1 所示.

定义网络的输入向量为:

$$v(k) = [u(k)^T, x(k)^T, u_1 u_2 \cdots u_{m-1} u_m, \\ u_1 x_1 \cdots u_m x_n, x_1 x_2 \cdots x_{n-1} x_n]^T. \quad (2)$$




图1 高阶RBF神经网络串并联辨识模型

Fig. 1 Seriparallel identification model of high order RBF neural network

其中 $u(k)$ 为外部输入, $x(k)$ 是系统当前时刻的输出状态, $u_i u_j, u_i x_j, x_i x_j$ 是外部输入与系统当前输出状态之间的各种组合. 网络的第 i 个输出可表示为:

$$\hat{x}_i = g_i(v) = \sum_{j=1}^l \theta_{ij} \phi_j(\|v - c_j\|). \quad (3)$$

其中 $v \in \mathbb{R}^p$ 是网络的输入向量, $\|\cdot\|$ 表示欧几里得范数, $c_j \in \mathbb{R}^p, 1 \leq j \leq l$ 是 RBF 中心值, $\phi_j(\cdot)$ 是隐层第 j 个作用函数的输出, $\theta_{ij}, 1 \leq j \leq l, 1 \leq i \leq n$ 是输出层与隐层之间的连接权值, l 是隐层的神经元个数. 作用函数选为:

$$\phi_j(d) = d^2 \log d. \quad (4)$$

估计的状态输出可描述为:

$$\hat{x}(k+1) = g(v(k), c, \theta). \quad (5)$$

估计的误差 $e(k+1)$ 定义为:

$$e(k+1) = x(k+1) - \hat{x}(k+1) = f(x(k), u(k)) - g(v(k), c, \theta). \quad (6)$$

在本文中该网络的中心值选为输入空间中均匀分布的随机变量.

2.2 高阶 RBF 网络 EKF 学习算法 (EKF learning algorithm for high order RBF network)

EKF 方法用于神经网络权值估计时, 把未知的连接权值作为状态向量. 本文高阶 RBF 网络可以用如下的非线性系统方程描述:

$$\theta(k+1) = \theta(k), \quad (7)$$

$$d(k) = g(v(k), \theta(k), c) + w(k) = \hat{x}(k) + w(k). \quad (8)$$

其中 $d(k)$ 是期望的输出向量, $\hat{x}(k)$ 是网络输出层节点的输出向量, $w(k)$ 是假定方差为 $R(k)$ 的白噪声向量. 则 EKF 学习算法可表示为:

$$\begin{cases} \theta_i(k) = \theta_i(k-1) + K_i(k)[d(k) - \hat{x}(k)], \\ K_i(k) = P_i(k-1)H_i(k)^T[H_i(k)P_i(k-1) \cdot \\ H_i(k)^T + R(k)]^{-1}, \\ P_i(k) = P_i(k-1) - K_i(k)H_i(k)P_i(k-1). \end{cases}$$

对于 RBF 网络:

$$H_i(k) = \left(\frac{\partial \hat{x}(k)}{\partial \theta_i} \right)_{\theta_i = \theta_i(k-1)} = \phi^T(k). \quad (10)$$

其中 $p_i(k) \in \mathbb{R}^{l \times l}$, 初始值 $p_i(0)$ 可假定为 $\lambda I, \lambda \in \mathbb{R}; \theta_i$ 可假定为接近 0 的随机数.

3 高阶 RBF 神经网络 EKF 逆算法 (EKF inverse algorithm for high order RBF neural network)

用于辨识系统模型的神经网络逆映射可表示如下:

$$\hat{u}(k) = g^{-1}[x(k), x^d(k+1), c, \theta]. \quad (11)$$

其中 $x^d(k+1)$ 是系统的期望输出.

未知的控制输入向量 $u(k)$ 作为待估的状态向量. 高阶 RBFN 的输入向量 $v(k)$ 中, $x(k)$ 是已知的第 k 个时刻的系统输出, $u(k)$ 是在逆运算过程中待估的控制输入, 在神经网络的每一次迭代运算中, RBFN 的参数 c 和 θ 都保持不变, 直到迭代输出 $\hat{u}(k)$, 再在线辨识动态系统模型, 故神经网络逆运算与在线模型辨识是交替进行的. 因此, RBFN 网络输出可以表示为:

$$\hat{x}(k+1) = g[x(k), u(k), c, \theta] = h(u(k)). \quad (12)$$

如果假设其它的 $(m-1)$ 个控制输入是已知的, 那么, 控制输入 u_i 的更新就可以与其它的控制输入相解耦^[4]. 换言之, 上一步迭代获得的 $(m-1)$ 个控制输入估计, 可以作为第 i 个控制输入当前迭代的先验已知.

在每一个采样时刻 k , RBFN 的第 t 步迭代输出向量与系统期望输出分别为 $\hat{x}(k, t)$ 和 $x^d(k+1)$. RBFN 可看作是第 i 个输入的非线性函数.

$$u_i(t+1) = u_i(t). \quad (13)$$

$$x^d = h[u_i(t)] + \xi(t) = \hat{x}(t) + \xi(t). \quad (14)$$

其中 $\xi(t)$ 假定为白噪声向量, 其方差为 $R(t) \in \mathbb{R}^{n \times n}$, 则 EKF 的逆算法为:

$$\hat{u}_i(t) = \hat{u}_i(t-1) + K_i(t)[x^d - \hat{x}(t)], \quad (15)$$

$$K_i(t) = P_i(t-1)H_i(t)^T[H_i(t)P_i(t-1) \cdot$$

$$H_i(t)^T + R(t)]^{-1}, \quad (16)$$

$$P_i(t) = P_i(t-1) - P_i(t-1)K_i(t)H_i(t). \quad (17)$$

其中 $K_i(t)$ 是 $(1 \times n)$ 的矩阵, 为卡尔曼增益矩阵, $H_i(t)$ 是 $(n \times 1)$ 的矩阵, $H_i(t)$ 定义如下:

$$H_i(t) = \left[\frac{\partial h}{\partial u_i} \right]_{u=a(t-1)}. \quad (18)$$

在本文高阶 RBF 神经网络作用函数下, $H_i(t)$ 的第 j 个元素可以表示为:

$$H_{ij} = \frac{\partial h_j}{\partial u_i} = \frac{\partial \hat{x}_j}{\partial u_i} = \sum_{k=1}^l \frac{\partial \hat{x}_j}{\partial \phi_k} \cdot \frac{\partial \phi_k}{\partial u_i} = \sum_{k=1}^l \theta_{jk} [1 + 2 \log d(k)] [(u_i - c_{k,i}) + \sum_{\substack{r=1 \\ r \neq i}}^{m+n} v_r (u_i v_r - c_{k,r})]. \quad (19)$$

其中 m 为控制输入的维数, n 为系统输出的维数, $d(k) = \|v - c(k)\|$. 方差矩阵 $R(t)$ 可以假定为对角矩阵 λI , $R(t)$ 可以用如下的递推算法在线估计:

$$\hat{\lambda}(t) = \hat{\lambda}(t-1) + v(t) \cdot \left[\frac{(x^d - \hat{x}(t))^T (x^d - \hat{x}(t))}{n} - \hat{\lambda}(t-1) \right]. \quad (20)$$

其中 $v(t) = 1/t$, n 为 RBF 神经网络输出的维数.

4 建模误差的补偿 (Compensation for modeling error)

定义建模误差如下:

$$e(t) = f(x(k), u(k)) - \hat{f}(x(k), \hat{u}(k)). \quad (21)$$

假设建模误差是一个噪声序列且与 $\xi(t)$ 无关, 其均值和方差如下:

$$E\langle e(k) \rangle = m(k), \\ E\langle (e(k_1) - m(k_1))(e(k_2) - m(k_2))^T \rangle = \delta(k_1 - k_2) S(k). \quad (22)$$

从实际仿真中可以看出, 一般 $m(k)$ 为非零向量, 为了使估计的 $\hat{u}_i(k)$ 更精确, 修改(14),

$$x^d = h[u_i(t)] + \xi(t) + e(k) = \hat{x}(t) + \xi(t) + e(k) = [\hat{x}(t) + m(k)] + \xi(t) + [e(k) - m(k)]. \quad (23)$$




图 2 滚转通道角度响应曲线
—为期望输出, ----为实际输出

Fig. 2 The angle response of roll channel
—desired output, - - actual output

$e(k) - m(k)$ 为均值为零的噪声序列, 其方差为 $S(k)$.

这样有

$$K_i(t) = P_i(t-1) H_i(t)^T [H_i(t) P_i(t-1) H_i(t)^T + R(t) + S(k)]^{-1}. \quad (24)$$

在本文中建模误差的统计特性首先通过离线建模估计, 在通过在线建模的过程修正.

5 仿真实例 (The simulation)

卫星太阳帆板挠性作用时, 姿态机动动力学方程可表示为:

$$\begin{cases} I\dot{w} + B_f^T \ddot{q} + V(w) H_m = T, \\ A_f \ddot{q} + D_f \dot{q} + E_f q + B_c \dot{w} = 0. \end{cases} \quad (25)$$

其中 I 是卫星转动惯量阵, $w = [w_x \ w_y \ w_z]^T$ 是角速度阵, $H_m = [h_x \ h_y \ h_z]^T$ 是卫星的角动量, $q = [q_n \ q_p \ q_T]^T$ 分别是太阳帆板挠性振动法向弯曲, 平面内弯曲和扭曲三种振型的一阶约束模态坐标, $T = [T_x \ T_y \ T_z]^T$ 是作用在卫星上的外力矩, 控制力矩和干扰力矩, A_f, D_f 和 E_f 分别是挠性振动的广义质量, 阻尼和刚度矩阵, B_c 是卫星姿态和帆板振动之间的耦合系数.

其中

$$V(w) = \begin{bmatrix} 0 & -w_z & w_y \\ w_z & 0 & -w_x \\ -w_y & w_x & 0 \end{bmatrix}. \quad (26)$$

仿真时用的参数如下:

$$I = \begin{bmatrix} I_x & I_{xy} & I_{xz} \\ I_{xy} & I_y & I_{yz} \\ I_{xz} & I_{yz} & I_z \end{bmatrix} = \begin{bmatrix} 3000 & 35 & 0 \\ 35 & 1500 & 0 \\ 0 & 0 & 2500 \end{bmatrix}.$$

$$A_f = \text{diag}(15.51, 19.92, 9.78),$$

$$D_f = \text{diag}(0.01, 0.01, 0.01),$$

$$E_f = \text{diag}(65.83, 708.94, 342.10),$$

$$B_c = \text{diag}(145.00, 11.20, 84.00).$$




图 3 滚转通道角速度响应曲线
—为期望输出, ----为实际输出

Fig. 3 The angle velocity response of roll channel
—desired output, - - actual output

取状态向量为

$$x = [\theta_x \ \theta_y \ \theta_z \ q_N \ q_P \ q_T \ \dot{\theta}_x \ \dot{\theta}_y \ \dot{\theta}_z \ \dot{q}_N \ \dot{q}_P \ \dot{q}_T].$$

从仿真曲线可以看出(如图 2,图 3),各通道实际的输出与系统期望的输出很接近,实现了姿态的




图 4 俯仰通道角度误差响应曲线

— ① 没有建模误差补偿

--- ② 建模误差补偿后

Fig. 4 The angle error response of pitch channel

— ① without compensation of modeling error

--- ② with compensation of modeling error

6 结论(Conclusion)

本文采用了高阶 RBF 神经网络用于未知的动态系统建模,并结合 EKF 逆算法,同时提出了一种建模误差的简单有效的补偿方法,获得了对非线性挠性结构的有效控制.该方法收敛速度快,算法简单.

参考文献(References)

- 1 Chen S, Cowan C F N and Grant P M. Orthogonal least squares learning algorithm for radial basis function networks. IEEE Trans. Neural Networks, 1991, 2(2): 301 - 309
- 2 Youji L and Sakai H. A real-time learning algorithm for a multilayered neural networks based on the extended kalman filter. IEEE Trans. on Signal Processing, 1992, 40(4): 959 - 966
- 3 Lax midhar B and Santanu C. On adaptive trajectory tracking of a robot

有效控制.

建模误差未补偿与补偿后,俯仰通道的角度响应与角速度响应误差曲线如图 4,图 5,可以看出随着时间的增长,建模误差将影响到系统的控制精度.




图 5 俯仰通道角速度误差响应曲线

— ① 没有建模误差补偿

--- ② 建模误差补偿后

Fig. 5 The angle velocity error response of pitch channel

— ① without compensation of modeling error

--- ② with compensation of modeling error

manipulator using inversion of its neural network emulator. IEEE Trans. On Neural Networks, 1996, 7(6): 1401 - 1414

- 4 Chun-Tang C and Ching-Cheng T. A fuzzy neural based extended Kalman filter. International Journal of Systems Science, 1996, 27(3): 333 - 339

本文作者简介

刘春梅 1973 年生. 哈尔滨工业大学控制工程系博士研究生. 主要研究神经网络与变结构控制. E-mail: rock@ac411.hit.edu.cn

沈毅 1965 年生. 1995 年于哈尔滨工业大学控制工程系获博士学位, 哈尔滨工业大学控制工程系教授, 国家 863 专题专家. 主要研究领域为检测技术与自动化装置, 导航制导与控制, 故障诊断与容错技术. E-mail: sy@ac411.hit.edu.cn

胡恒章 1932 年生. 1955 年毕业于哈尔滨工业大学电机系, 现为该校控制工程系教授, 博士生导师. 主要研究领域为: 随机控制, 智能控制, 导航制导与控制, 惯性设备测试.