

机械手的在线鲁棒自适应神经网络跟踪控制

胡 慧¹, 刘国荣²

(1. 湖南大学 电气与信息工程学院, 湖南 长沙 410082; 2. 湖南工程学院 电气与信息工程系, 湖南 湘潭 411104)

摘要: 考虑了一类具有外界干扰和不确定性的机械手臂轨迹跟踪鲁棒控制问题. 控制器由自适应RBF(radial basis function)神经网络控制器和PD控制器组成. 采用基于神经元灵敏度和获胜神经元概念的GP-RBF算法, 在线确定神经网络的初始结构和参数. 当误差满足一定要求时, 根据Lyapunov稳定性理论的自适应律进一步调整网络权值, 以保证机械手位置误差和速度跟踪误差渐近收敛于零. 所设计的控制器可保证闭环系统的稳定性和鲁棒性. 仿真结果证明了本文方法的有效性.

关键词: 机械手臂; 神经元灵敏度; 获胜神经元; GP-RBF算法; 轨迹跟踪

中图分类号: TP241 **文献标识码:** A

On-line adaptive robust neural network tracking control for robot manipulators

HU Hui¹, LIU Guo-rong²

(1. College of Electrical and Information Engineering, Hunan University, Changsha Hunan 410082, China;

2. Department of Electrical and Information Engineering, Hunan Institute of Engineering, Xiangtan Hunan 411104, China)

Abstract: The robust tracking control for a class of robot manipulators with disturbance and uncertainties is considered. The controller consists of an adaptive radial basis function(RBF) neural network controller and a PD controller. The initial structure and parameters of RBF neural network are determined on-line by the growing-and-pruning(GP-RBF) algorithm based on the sensitivity of neurons as well as the winner neuron concept. When the errors meet certain requirements, the adaptive law based on the Lyapunov stability further adjusts the weights of networks to ensure the asymptotic convergence of the tracking error to be zero. The controller guarantees the stability and robustness of the system. Simulation results demonstrate the efficacy of this method.

Key words: manipulator; sensitivity of neurons; winner neurons; GP-RBF algorithm; trajectory tracking

1 引言(Introduction)

机械手是一个高度非线性、强耦合、时变的控制对象, 其模型参数随它的位置、姿态和负载的变化而变化, 因而机械手轨迹跟踪是一个相当复杂和困难的控制问题. 近年来, 神经网络在机器人控制中得到广泛的应用, 用于补偿系统非线性和不确定性的影响, 以改善系统的控制性能. 在众多方案中, 神经网络通常用于在线或离线学习系统的非线性或不确定性^[1~3], 然而这些控制方案都要提前知道网络结构和初始参数, 这就需要大量的试验确定初始网络. 文[4]提出了一种广义自适应模糊神经控制器, 实现了模糊神经网络结构和初始参数的在线确定, 取得了很好的控制效果. 但是, 需要知道特定的教师信

号, 而且算法复杂, 限制条件较多.

本文提出了一种适合于一类具有外界干扰和不确定性的机械手臂轨迹跟踪鲁棒控制问题的控制器, 该控制器由自适应RBF神经网络控制器(A-RBFNNC)和PD控制器组成. 其中A-RBFNNC采用基于神经元灵敏度和获胜神经元概念的GP-RBF(growing and pruning RBF)算法, 在线确定神经网络的初始结构和参数, 该算法具有以下显著特点: 1) 在线和快速的学习能力, 能够自动地增加或删除神经元, 不需要先验知识就可以确定神经网络的结构和初始参数, 并根据神经元灵敏度和获胜神经元概念, 采用扩展卡尔曼滤波器算法(EKF)调节中心与当前神经网络输入向量间欧式距离最短的神经元的参

数^[5,6],大大提高了学习速度;2)跟踪误差快速收敛性和良好的鲁棒性,当误差满足一定要求时,按照基于Lyapunov稳定性理论的自适应律进行网络权值的进一步调整,并行的PD控制器起监督控制作用,增强了控制策略的完备性.

2 自适应神经网络控制系统(Adaptive neural network control system)

描述 n 自由度机械手的动力学方程是一组高度非线性耦合微分方程,采用Lagrange-Euler方法,其动态方程可表达为

$$H(q)\ddot{q} + C(q, \dot{q}) + \phi(q) + d = u(t). \quad (1)$$

其中: $q, \dot{q} \in \mathbb{R}^n$ 是广义关节位置和速度矢量, $H(q) \in \mathbb{R}^{n \times n}$ 为惯性矩阵, $C(q, \dot{q})$ 包括离心力和哥氏力矩, $\phi(q) \in \mathbb{R}^{n \times n}$ 为重力项, $d \in \mathbb{R}^n$ 是未建模动态和外部干扰, $u(t) \in \mathbb{R}^n$ 是关节驱动力矩.

本文中的在线自适应神经网络控制系统如图1所示. 其中A-RBFNNC的输出 u_{NN} 与PD控制器输出 u_{PD} 并行共同产生控制力矩 u , 即

$$u = u_{NN} + u_{PD}. \quad (2)$$

控制目标是使机械手臂跟踪理想参考轨迹 q_d .




图1 在线自适应神经网络控制系统

Fig. 1 On-line adaptive NN control system

定义跟踪误差向量为

$$E = [q_d - q \quad \dot{q}_d - \dot{q}]^T = [e \quad \dot{e}]^T. \quad (3)$$

当机械手臂的精确模型已知时,控制力矩可设计为

$$u = H(q)\ddot{q}_d + F(q, \dot{q}) + d + H(q)KE. \quad (4)$$

其中: $F(q, \dot{q}) = C(q, \dot{q}) + \phi(q)$, $K = [K_2 \ K_1]$. 将式(4)代入式(1)中,经过几步直接运算后可得如下的误差方程:

$$\ddot{e} + K_1\dot{e} + K_2e = 0. \quad (5)$$

上式中适当地选择 K 时, $\lim_{t \rightarrow \infty} e(t) = 0$, 这是主要的控制任务. 但是由于机械手臂的工作环境及负载的变化,精确模型很难得到,模型中经常存在不确定性和外部干扰. 为解决该问题,利用A-RBFNNC来产

生最优力矩 u_{NN}^* , 则最优控制律如下:

$$u^* = u_{NN}^* + H(q)KE. \quad (6)$$

其中的神经网络采用在线增加和删除节点算法(GP-RBF)动态建立.

3 A-RBFNNC 结构及 GP-RBF 算法(A-RBFNNC architecture and GP-RBF algorithm)

3.1 网络结构(Network architecture)

RBF神经网络结构如图2所示.




图2 RBF神经网络结构

Fig. 2 RBF neural network architecture

其中: 输入向量 $x = (x_1, \dots, x_L)^T \in X \subseteq \mathbb{R}^L$, L 是输入向量的维数, 隐层包含 K 个神经元, 则神经网络的输出可表达为

$$y(x) = \sum_{i=1}^K w_i \phi_i(x) = W \phi(x). \quad (7)$$

其中: $W = [w_1, \dots, w_K]$, w_i 是第 i 个隐层神经元与所有输出神经元间的权值列向量, $\phi_i(x)$ 是第 i 个隐层神经元对应于输入向量 x 时的输出量, 表达式为

$$\phi_i(x) = \exp\left(-\frac{\|x - \mu_i\|^2}{\sigma_i^2}\right). \quad (8)$$

其中: $\mu_i = (\mu_{i,1}, \dots, \mu_{i,L})^T \in \mathbb{R}^L$ 和 σ_i 分别是对应于第 i 个隐层神经元的高斯函数的中心和宽度, $\|\cdot\|$ 表示向量的2-范数.

3.2 神经元灵敏度的计算(Calculation of neurons sensitivity)

假设经过顺序学习了 n 次后, RBF网络有 K 个隐层神经元, 当输入为 $x(i)$ ($i = 1, \dots, n$)时, 神经网络的输出

$$y_1(w_1, \mu_1, \sigma_1, \dots, w_K, \sigma_K, x_i) = \sum_{j=1}^K w_j \phi_j(x_i). \quad (9)$$

如果第 k 个隐层神经元被删除, 则只有 $K-1$ 个隐层神经元的RBF神经网络的输出为

$$y_2(w_1, \mu_1, \sigma_1, \dots, w_{k-1}, \mu_{k-1}, \sigma_{k-1}, w_{k+1},$$

$$\mu_{k+1}, \sigma_{k+1}, \dots, w_K, \mu_K, \sigma_K, x_i) = \sum_{j=1}^{k-1} w_j \phi_j(x_j) + \sum_{j=k+1}^K w_j \phi_j(x_j). \quad (10)$$

这样, 对向量 x_i , 由于删除第 k 个隐层神经元而产生的误差为

$$\bar{E}(k, i) = \|y_1 - y_2\| = \|w_k\| \phi_k(x_i). \quad (11)$$

那么, 对 n 个输入向量, 由于删除第 k 个隐层神经元而产生的平均误差定义为第 k 个隐层神经元的灵敏度, 即

$$E_{\text{sig}}(k) = \frac{1}{n} \|(\bar{E}(k, 1), \dots, \bar{E}(k, n))\| = \frac{\|w_k\|}{n} \left(\sum_{i=1}^n \phi_k^2(x(i)) \right)^{1/2}. \quad (12)$$

3.3 GP-RBF网络学习算法(GP-RBF network learning algorithm)

根据以上定义的灵敏度概念, 结合以下神经网络隐层节点的增加和删除规则以实现最小网络结构, 提高网络训练速度.

第1步 计算两个误差量, 判断是否需要增加新的隐层节点.

$$\|x(i) - \mu_\rho(i)\| > \varepsilon_n, \quad \rho = \arg \min_j \|x(i) - \mu_j(i)\|, \quad (13)$$

$$\|\bar{e}(i)\| = \|y_d(i) - y(i)\| > \bar{e}_{\min}. \quad (14)$$

其中: $\mu_\rho(i)$ 是隐层获胜神经元的中心, 获胜神经元定义为中心与当前神经网络输入向量间欧式距离最短的神经元, $\varepsilon_n = \max\{\lambda^n \varepsilon_{\max}, \varepsilon_{\min}\}$ 输入空间的阈值, $\varepsilon_{\max}, \varepsilon_{\min}$ 分别为输入空间的最大和最小误差, $\lambda \in [0, 1]$ 之间的数; y, y_d 分别为实际和期望输出, $\bar{e}_{\min}$ 是输出空间的阈值. 当两个标准均满足时, 转入第2步加入一个新的隐层节点, 否则跳到第3步采用EKF算法更新网络参数.

第2步 增加隐层节点.

当第1步中所有条件都满足时, 加入一个新的隐层节点, 其参数由下式确定以减小误差:

$$w_{k+1} = \bar{e}_i, \mu_{k+1} = x(i), \sigma_{k+1} = \tau \|x(i) - \mu_\rho(i)\|. \quad (15)$$

其中 τ 是重叠因子通常取0.6~0.9, 此时神经网络具有较好的精确度和泛化能力.

第3步 采用EKF算法更新参数.

为了降低计算的复杂度和提高学习速度, 在进行参数更新时, 仅调整隐层中获胜神经元的参数, 即 $\alpha = [w_\rho^T \mu_\rho^T \sigma_\rho]^T$, 大大减小了需计算的矩阵的维数, 从而提高了网络训练速度.

α 采用EKF更新如下:

$$\alpha_i = \alpha_{i-1} + K_i \bar{e}_i. \quad (16)$$

其中: K_i 为卡尔曼增益矩阵, 对于图2所示网络结构, 则 K_i 的维数为 $(L + M + 1) \times M$ 维

$$K_i = Q_{i-1} S_i [R_i + S_i^T Q_{i-1} S_i]^{-1}. \quad (17)$$

其中: R_i 是可测噪声变量的方差, $S_i = \nabla_\alpha y(x_i)$ 是输出 $y(x_i)$ 关于参数向量 α 的梯度, S_i 的维数为 $(L + M + 1) \times M$ 维:

$$S_i = [\phi_\rho(x_i) I, \phi_\rho(x_i) \frac{2w_\rho^2}{\sigma_\rho^2} [x_i - \mu_\rho]^T, \phi_\rho(x_i) \frac{2w_\rho^2}{\sigma_\rho^3} \|x_i - \mu_\rho\|^2]^T. \quad (18)$$

Q_i 是误差协矩阵, 其大小为 $(L + M + 1) \times (L + M + 1)$,

$$Q_i = [I - K_i S_i^T] Q_{i-1} + \varsigma I. \quad (19)$$

ς 为一设定的标量. 参数更新后, 转至第4步执行节点删除过程.

第4步 删除隐层节点.

判断调整后的第 ρ 个隐层神经元是否需要删除, 如果

$$E_{\text{sig}}(\rho) < e_{\text{es}}, \quad (20)$$

则删除第 ρ 个隐层神经元, 其中 e_{es} 为一设定值. 方程(20)表明第 ρ 个隐层神经元的灵敏度低于设定值, 不够重要因此删除以精简网络.

4 控制系统收敛性和稳定性分析(Convergence and stability analysis of control system)

从方程(1)到(2)~(6), 可得跟踪误差方程为

$$\dot{E} = AE + B(u^* - u_{\text{NN}} - u_{\text{PD}}). \quad (21)$$

其中: $A = \begin{pmatrix} 0 & 1 \\ -K_2 & -K_1 \end{pmatrix}$, $B = \begin{pmatrix} 0 \\ H^{-1}(q) \end{pmatrix}$, 将式(6)和(7)代入式(21)中可得

$$\dot{E} = AE + B[u_{\text{NN}}^* - u_{\text{NN}} + H(q)KE - K_c E] = \Lambda E + B[W^* \phi^* - W \phi]. \quad (22)$$

其中: $\Lambda = -\begin{pmatrix} 0 & -1 \\ H^{-1}K_p & H^{-1}K_d \end{pmatrix}$, $K_c = [K_p, K_d]$ 是PD控制器增益, W^* 和 ϕ^* 为网络最优参数. 在网络学习过程中, 隐层节点数目不断发生变化, 可能 W^* 和 W 或 ϕ^* 和 ϕ 的维数不匹配. 为解决该问题, 假设在任一时刻所获得的 ϕ 均为最优值 ϕ^* , 即 ϕ^* 不

是唯一的, 那么 $\phi^* = \phi$, 则式(22)可写为

$$\dot{E} = \Lambda E + B[(W^* - W)\phi]. \quad (23)$$

式(23)表明只需进一步调整 W 使跟踪误差达到最小。 W 的自适应律如下:

$$\dot{w}_j^T = \begin{cases} \gamma \phi E^T P b_j, & \|w_j\| < \|w_j(0)\| \text{ 或} \\ & (\|w_j\| = \|w_j(0)\| \text{ 且} \\ & w_j \phi E^T P b_j \leq 0, \\ \gamma(I - \frac{w_j^T w_j}{\|w_j\|^2}) \phi E^T P b_j, & \|w_j\| = \|w_j(0)\| \\ & \text{且 } w_j \phi E^T P b_j > 0. \end{cases} \quad (24)$$

其中: γ 是自适应增益, $W = [w_1^T, \dots, w_M^T]^T$, $w_j = (w_{j1}, \dots, w_{jK})$ 是每一个输出节点所对应的权值行向量, $B = [b_1, \dots, b_M]$, $j = 1, \dots, M$, M 为神经网络输出节点数; P 是一个对称正定矩阵, 满足

$$P\Lambda + \Lambda^T P = -\Xi, \quad (25)$$

其中 Ξ 是给定的对称正定矩阵。

从文[4]可知, 权值 W 是有界的, 那么神经网络的输出也是有界的, 即自适应 GP-RBF 神经网络是收敛的。

定理 1 对于未知非线性系统(1), 采用控制规则(6)和自适应律(24), 那么, 相应的闭环系统是渐近稳定的。

证 根据式(23), 取 Lyapunov 函数为

$$V(t) = \frac{1}{2} E^T P E + \frac{1}{2\gamma} \text{tr}[(W^* - W)(W^* - W)^T].$$

$$H(q) = \begin{bmatrix} a_1 + 2a_3 \cos q_2 + 2a_4 \sin q_2 & a_2 + a_3 \cos q_2 + a_4 \sin q_2 \\ a_2 + a_3 \cos q_2 + a_4 \sin q_2 & a_2 \end{bmatrix},$$

$$F(q, \dot{q}) = \begin{bmatrix} -(a_3 \sin q_2 - a_4 \cos q_2) \dot{q}_1 \dot{q}_2 - (a_3 \sin q_2 - a_4 \cos q_2) (\dot{q}_1 + \dot{q}_2) \dot{q}_2 \\ (a_3 \sin q_2 - a_4 \cos q_2) \dot{q}_1^2 \end{bmatrix}.$$

仿真参数:

$$\begin{aligned} a_1 &= I_1 + m_1 l_{c1}^2 + I_e + m_e l_{ce}^2 + m_e l_1^2, \\ a_2 &= I_e + m_e l_{ce}^2, \quad a_3 = m_e l_1 l_{ce} \cos 30^\circ, \\ a_4 &= m_e l_1 l_{ce} \sin 30^\circ, \quad m_1 = 1 \text{ kg}, \quad m_2 = 2 \text{ kg}, \\ l_1 &= 1 \text{ m}, \quad l_{c1} = 0.5 \text{ m}, \quad l_{ce} = 0.6 \text{ m}, \\ I_1 &= 0.12 \text{ kgm}^2, \quad I_e = 0.25 \text{ kgm}^2. \end{aligned}$$

期望跟踪信号 $q_d = [0.41 \sin \pi(t-0.5), \cos \pi t]^T$. 初始条件为 $q_1 = q_2 = 0 \text{ rad}$, $\dot{q}_1 = \dot{q}_2 = 0 \text{ rad/s}$,

对上式求导, 并将式(23)和(25)代入式中, 得

$$\begin{aligned} \dot{V}(t) &= \frac{1}{2} \dot{E}^T P E + \frac{1}{2} E^T P \dot{E} - \frac{1}{\gamma} \text{tr}[(W^* - W) \dot{W}^T] = \\ &= \frac{1}{2} E^T (P\Lambda + \Lambda^T P) E + E^T P B (W^* - W) \phi - \\ &= \frac{1}{2} E^T \Xi E + E^T P B (\dot{W} - W) \phi - \\ &= \frac{1}{\gamma} \text{tr}[(W^* - W) \dot{W}^T]. \end{aligned} \quad (26)$$

当满足式(24)中的第1种情况时, 式(27)变为

$$\begin{aligned} \dot{V}(t) &= -\frac{1}{2} E^T \Xi E + E^T P B (\dot{W} - W) \phi - \\ &= \text{tr}[(W^* - W) \phi E^T P B] = \\ &= -\frac{1}{2} E^T \Xi E + E^T P B (\dot{W} - W) \phi - \\ &= E^T P B (W^* - W) \phi = \\ &= -\frac{1}{2} E^T \Xi E \leq 0. \end{aligned}$$

同理, 当满足式(24)中的第2种情况时,

$$\dot{V}(t) \leq -\frac{1}{2} E^T \Xi E \leq 0. \quad (27)$$

式(26)(28)和(29)表明, $V(t) \geq 0$ 且 $\dot{V}(t) \leq 0$. 所以, 相应的闭环系统是渐近稳定的。

5 仿真研究(Simulation study)

考虑二自由度机械手臂的跟踪控制问题, 系统方程为

$$H(q) \ddot{q} + F(q, \dot{q}) + d = u.$$

其中:

$\ddot{q}_1 = \ddot{q}_2 = 0 \text{ rad/s}^2$. 系统中总是存在不确定性和干扰, 随意引入干扰信号 $d = [0.5 \sin(2\pi t), \sin(2\pi t)]^T$, 采样周期为 0.01 s , 最大迭代次数 $N = 600$, 重叠因子 $\lambda = 0.9$, $\varepsilon_{\max} = 0.99$, $\varepsilon_{\min} = 0.5$, $es = 0.003$, $e_{\min} = 0.1$, 自适应增益 $\gamma = 15$, 传统 PD 控制器增益

$$\begin{aligned} k_p &= \text{diag}\{25, 25\}, \quad k_d = \text{diag}\{7, 7\}, \\ P &= \begin{bmatrix} \text{diag}\{10, 32\} & 2.5H(q) \\ 2.5H(q) & 0.7H(q) \end{bmatrix}. \end{aligned}$$

采用MATLAB进行仿真实验, 实验结果如图3所示.

图3为跟踪误差清晰地表明了在有较大外扰的情况下, 系统能够跟踪期望的轨迹, 并且跟踪误差收敛快, 稳定性好具有较好的鲁棒性.




图3 跟踪误差曲线

Fig. 3 Tracking errors

图4表明了应用GP-RBF算法隐层节点自动产生和删除的过程, 最终隐层节点数为8个.




图4 隐层节点个数图

Fig. 4 Node numbers of hidden layer

为了说明本文方法的优越性, 在相同的环境下, 使用另一种可进行在线学习的最近邻聚类学习算法^[8]对网络进行初始学习.

图4中隐层节点变化曲线表明为了达到相应的精度, 最近邻聚类算法所需隐层节点个数为32个, 与GP-RBF相比网络结构复杂得多, 就训练时间而言, 本文方法训练时间为2.1517 s, 而最近邻聚类学习算法训练时间为3.011 s, 训练时间大大减少. 比较图3和图5可知, 本文方法具有更强的跟踪能力.




图5 跟踪误差曲线图

Fig. 5 Tracking errors

6 结论(Conclusion)

本文提出了基于GP-RBF算法的机械手臂轨迹跟踪神经网络自适应控制方法, 给出了具体的控制算法和系统稳定性、收敛性的证明. 对本文方法进行了大量的仿真实验, 实验结果表明系统具有跟踪误差快速收敛性, 闭环系统的全局稳定性及良好的鲁棒性, 为了说明本文方法的优越性, 采用另一种可进行在线学习的最近邻聚类学习算法对网络进行初始学习, 比较仿真结果表明, 本文方法具有更加简洁的网络结构, 更快的学习速度及更强的跟踪能力.

参考文献(References):

- [1] ARSLAN H, KUZUCU A. A robot control application with neural networks[J]. *IEEE International Conference on Industrial Electronics*, 1997, 3(10): 1238 – 1241.
- [2] YANG X, MENG M. A neural networks approach to real-time motion planning and control of robot manipulator[J]. *IEEE International Conference on System, Man and Cybernetics*, 1999, 4(5): 674 – 679.
- [3] FENG G. A new stable tracking control scheme for robotic manipulators[J]. *IEEE Transactions on Systems, Man and Cybernetics*, 1997, 27(5): 510 – 516.
- [4] GAO Y, JOO M. Online adaptive fuzzy neural identification and control of a class of MIMO nonlinear systems[J]. *IEEE Transactions on Fuzzy Systems*, 2003, 11(4): 462 – 476.
- [5] HUANG G B, SARATCHANDRAN P, NARASIMHAN S. A generalized growing and pruning RBF(GGP-RBF) neural network for function approximation[J]. *IEEE Transactions on Neural Networks*, 2005, 16(1): 57 – 67.
- [6] LI Y, SUNDARARAJAN N, SARATCHANDRAN P. Analysis of minimal radial basis function network algorithm for real-time identification of nonlinear dynamic systems[J]. *IEEE Proceedings: Control Theory and Applications*, 2000, 147(4): 476 – 484.
- [7] 李江, 杨慧中. 一种基于扩展Kalman滤波器的神经网络学习算法[J]. *东南大学学报(增刊)*, 2004, 34: 230 – 234.
(LI Jiang, YANG Huizhong. Learning algorithm for neural networks based on extended Kalman filter[J]. *Journal of Southeast University(Natural Science Edition)*, 2004, 34(Suppl): 230 – 234.)
- [8] 朱明星, 张德龙. RBF网络基函数中心选取算法的研究[J]. *安徽大学学报*, 2000, 24(1): 72 – 78.
(ZHU Mingxing, ZHANG Delong. Study on the algorithms of selecting the radial basis function center[J]. *Journal of Anhui University Natural Science Edition*, 2000, 24(1): 72 – 78.)

作者简介:

胡 慧 (1979—), 女, 博士研究生, 从事非线性系统控制和神经网络控制等的研究, E-mail: onlymyhui@126.com;

刘国荣 (1957—), 男, 博士, 教授, 博士生导师, 从事智能控制和不确定非线性系统控制等研究, E-mail: lgr@hnie.edu.cn.