

不确定性机器人的神经网络补偿控制*

徐建闽 周其节 梁天培

(华南理工大学自动化系·广州, 510641) (香港理工大学)

摘要: 本文研究具有不确定性的机器人的轨迹跟踪控制问题, 提出了一种由计算力矩控制器和神经网络补偿控制器构成的控制方案. 探讨了一种用神经网络估计机器人系统不确定性的途径, 给出了神经补偿控制器的设计方法, 并证明了闭环系统的收敛性. 仿真结构表明所提方案具有很好的鲁棒性和抗干扰能力.

关键词: 机器人; RBF 神经网络; 鲁棒补偿控制

1 引言

在过去的十年中, 关于机器人手臂的运动控制的研究已有许多有意义的工作. 对于模型已知的机器人系统, 应用计算力矩方法在理论上能够保证渐近的轨迹跟踪. 由于实际中的不确定性因素的存在, 研究具有不确定性的机器人系统的控制问题变得十分有意义. 相当多的工作研究了机器人的自适应控制方法^[1~6], 因为这种方法能够适应机器人模型中参数未知或时变的情况. 近年来, 将神经网络应用于机器人控制的研究引起了极大的关注^[7~9], 这是因为神经网络具有学习任意复杂的非线性和不确定性对象的能力. 这方面的研究大体可分两类: 一类是假定机器人动力学为完全未知的, 神经网络被训练来逼近系统的动力学或逆动力学, 以实现反馈控制或逆动力学控制方案. 另一类是假定机器人模型为部分已知的, 神经网络被用来学习模型中的未知信息, 如惯性矩阵、交叉耦合项等, 以减少在线计算上的负担. 在许多情况, 的确可以预先得到近似的机器人模型, 而基于模型的控制方案在实践中已被证明是有效的^[10~12]. 因此, 机器人模型的先验知识应该被适当利用, 而不是完全抛弃.

本文研究具有不确定性的机器人手臂的轨迹跟踪问题, 提出一种新的控制方案. 该方案利用一个基于标称模型的计算力矩控制器和一个可切入的神经网络鲁棒控制器对机器人进行控制, 以便使不确定性机器人系统获得较高的跟踪性能. 鲁棒控制器独立于原有的基于模型的计算力矩控制器, 因此, 它的切入不影响原来的控制系统的设计. 系统的工作原理如下: 在开始阶段, 系统由计算力矩控制器单独控制, 由于系统中存在不确定性因素, 机器人的跟踪误差不能收敛到零. 利用一个 RBF(Radial Basis Function)神经网络对系统的不确定性进行学习, 经过一段时间后, 设 RBF 网络已能较好地估计系统的不确定性函数. 在 $t=T$ 时刻 (T 应大于 RBF 网络的学习时间), 切入神经网络补偿控制器, 该控制器是根

* 国家自然科学基金、广东省自然科学基金资助课题.

本文于 1994 年 3 月 22 日收到. 1994 年 8 月 29 日收到修改稿.

据 Lyapunov 方法设计的, 其控制律由神经补偿信号和不连续的鲁棒控制信号构成. 理论与仿真均证明, 该方法对于具有未知或时变参数, 以及有外部干扰(如库仑摩擦) 的机器人系统是十分有效的, 而一般自适应控制器对于有常值干扰的机器人系统都难以做到无差的跟踪. 这是本方法的优越之处.

本文其余部分安排如下: 第二节介绍机器人手臂的模型及其性质, 给出一种新形式的计算力矩控制律, 由此导出了广义误差方程, 并讨论系统的不确定性对跟踪性能的影响. 第三节介绍 RBF 神经网络, 提出用 RBF 网络辨识机器人系统的不确定性的方法, 并给出一些基本引理. 第四节提出基于神经网络补偿的鲁棒控制器的设计方法, 证明了闭环系统的全局收敛性. 第五节给出计算力矩方法和新的控制方法的仿真结果. 最后概括本文的基本结论.

2 问题的提出

基于欧拉拉格朗日方程的 n 连杆机器人机械手的动力学模型可表示为

$$D(q)\ddot{q} + h(q, \dot{q}) = \tau + f. \quad (1)$$

其中, $q \in R^n$ 为关节的位移向量, $\tau \in R^n$ 为广义关节力矩向量, $D(q) \in R^{n \times n}$ 为机械手的惯性矩阵, $h(q, \dot{q})$ 是表征离心力、哥氏力和重力的非线性耦合项, $f \in R^n$ 是表征库仑摩擦力、负载变化和其它干扰的外部扰动项, 本文假设 f 为分段常值的外扰. 模型(1) 有如下一些性质:

性质 1 $D(q)$ 为正定对称阵, $D(q)$ 和 $D^{-1}(q)$ 一致有界.

性质 2 (1) 的左边可用一组适当选择的机械手的参数线性表示, 即

$$D(q)\ddot{q} + h(q, \dot{q}) = y(q, \dot{q}, \ddot{q})\theta. \quad (2)$$

其中 $\theta \in R^n$ 为机械手参数, $y(q, \dot{q}, \ddot{q}) \in R^{n \times m}$ 为回归矩阵, 它是机械手运动轨迹的函数阵.

我们先讨论单独采用计算力矩控制器的情况.

$$\tau = \tau_a = D_0(q)(\ddot{q}_d - (K_1 + K_2)\dot{e} - K_2K_1e) + h_0(q, \dot{q}). \quad (3)$$

其中 q_d 是期望的机械手运动轨迹, $e = q - q_d$ 是跟踪误差, $D_0 = D_0^T > 0$, h_0 分别为 D 和 h 在标称参数值 θ_0 下的估计, K_1 和 K_2 为正定的增益阵, 一般选为对角元素为正的对角阵以实现解耦. (3) 与一般的计算力矩公式有差别, 后面将看到, 采用数学技巧可导出降阶的广义误差方程.

(1) 的左边可写为

$$\begin{aligned} D\ddot{q} + h &= D\ddot{e} + h + D(\ddot{q}_d - K_1\dot{e}) + DK_1\dot{e} \\ &= D(\ddot{e} + K_1\dot{e}) + y_d\theta. \end{aligned} \quad (4)$$

上式中我们利用了 $D(\ddot{q}_d - K_1\dot{e}) + h = y_d\theta$, 其中 $y_d = y(q, \dot{q}, \ddot{q}_d - K_1\dot{e})$ (由性质 2).

(3) 可改写为

$$\begin{aligned} \tau &= D_0(\ddot{q}_d - K_1\dot{e}) + h_0 - D_0K_2(\dot{e} + K_1e) \\ &= y_d\theta_0 - D_0K_2(\dot{e} + K_1e). \end{aligned} \quad (5)$$

由(1), (4) 和(5) 有

$$D(\ddot{e} + K_1\dot{e}) + y_d\theta = y_d\theta_0 - D_0K_2(\dot{e} + K_1e) + f. \quad (6)$$

定义广义跟踪误差向量 $x := \dot{e} + K_1 e$ 和参数估计误差向量 $\bar{\theta} := \theta - \theta_0$. 我们得到广义误差方程:

$$\begin{aligned}\dot{x} &= -D^{-1}D_0K_2x - D^{-1}y_d\bar{\theta} + D^{-1}f \\ &= -K_2x + F(x).\end{aligned}\quad (7)$$

其中

$$F(x) = (I - D^{-1}D_0)K_2x - D^{-1}y_d\bar{\theta} + D^{-1}f. \quad (8)$$

$F(x)$ 表征了由不精确的参数估计和外扰引入的机器人系统的不确定性. 为了便于看出 $F(x)$ 对闭环系统的影响, 将(7) 改写为

$$\ddot{e} + (K_1 + K_2)\dot{e} + K_2K_1e = F(x). \quad (9)$$

可见, 如果 $F(x) = 0$, 只要适当选取 K_1 和 K_2 (如选为正定的对角阵), 即能保证 e 全局收敛于零. 但实际上由于不确定性因素的存在, $F(x) \neq 0$, 机械手的跟踪误差保持有界而不是趋于零(假定 $F(x)$ 是有界的).

换一个角度看, 如果我们能够获得不确定性函数 $F(x)$ 的一个良好的估计 $\hat{F}(x)$, 则可用此 $\hat{F}(x)$ 近似地补偿 $F(x)$ 的影响, 使机器人的跟踪精度改善. 由于人工神经网络具有很强的函数逼近能力, 因而可用来辨识非线性函数 $F(x)$.

3 使用 RBF 神经网络的函数估计

在神经网络控制系统的应用中, 有两类神经网络较为常用, 一类是含有 S 型激励函数的多层网络, 另一类是含有高斯激励函数的 RBF 网络. 本节给出 RBF 神经网络在非线性函数辨识中的一种应用方法.

近年来, 关于 RBF 网络的理论与应用的研究已取得一些结果^[13~15], 最近的文献报导了 RBF 网络用于非线性系统自适应控制的研究^[16]. RBF 网络可用数学公式表示为

$$\varphi_i = \exp\{-\|x - c_i\|^2/\sigma_i^2\}, \quad i = 1, 2, \dots, l, \quad (10)$$

$$y = W\varphi(x). \quad (11)$$

其中 $x \in R^m$ 为输入向量, $y \in R^a$ 为输出向量, $\varphi = [\varphi_1, \varphi_2, \dots, \varphi_l]^T$ 为隐层的输出向量; $W \in R^{a \times l}$ 为权矩阵, $c_i \in R^m$ 和 $\sigma_i > 0$ 分别是第 i 个隐元的中心向量和宽度. 容易看出, 每个 RBF 网络的隐元按照一个径向对称的函数(一般为高斯函数) 计算其输出, 输入离隐元的中心越近, 获得的输出也越大.

在 RBF 网络(10), (11) 中, 可调参数为网络的权阵以及每个隐元的中心与宽度. 然而, 为了数学上处理方便, 可以根据对象的一些信息, 将隐元的中心 c_i 与宽度 σ_i 固定, 或者对 c_i 和 σ_i 进行预训练, 得到粗略的值, 并在 RBF 网络的学习过程中将这些值保持不变. 这样处理有很大的好处. 因为网络的可调参数只剩下权阵 W , 而 W 与网络输出呈线性关系, 因而大大地简化了 RBF 网络的分析与学习过程.

下面我们讨论用 RBF 网络估计非线性函数 $F(x)$ 的具体方法. 在我们的问题中, RBF 网络的输入与输出向量分别为 x 和 $\hat{F}(x)$, 它们的维数相等, 即 $m = n$. 基于文献中发表的工作^[17,18] 和一些明显的结果, 我们先给出如下一些引理:

引理 1 由(7)描述的系统是 BIBO 稳定的, 并且广义跟踪误差 $x \in X$, 这里 X 为紧集.

引理 2 给定一个正的常数 ε_0 和一个连续函数 $F: X \rightarrow \mathbb{R}^n$, 存在一个权阵 $W = W^*$, 使得一个具有 l 个隐元的 RBF 网络的输出 $\hat{F}(x)$ 满足

$$\max_{x \in X} \|\hat{F}(x, W^*) - F(x)\| \leq \varepsilon. \quad (12)$$

其中 l 可能依赖于精度参数 ε_0 和函数 F .

引理 3 RBF 网络的输出 $\hat{F}(x, W)$ 关于其分量 (x, W) 是连续的.

于是, 我们可以将 (7) 表示为

$$\dot{x} = -K_2 x + \hat{F}(x, W^*) + \eta. \quad (13)$$

其中 $\eta = F(x) - \hat{F}(x, W^*)$, W^* 是对应于 $x \in X$ 的最优的权阵值, 即有

$$\|F(x) - \hat{F}(x, W^*)\| = \min \{ \sup_{x \in X} \|F(x) - \hat{F}(x, W)\| \}. \quad (14)$$

η 是有界的, 其界为 $\eta_0 = \sup_{x \in X} \|F(x) - \hat{F}(x, W^*)\|$.

根据 RBF 网络的性质, 网络输出 $\hat{F}(x, W^*)$ 可被表示成

$$\hat{F}(x, W^*) = W^* \varphi(x), \quad (15)$$

因此 (13) 可改写为

$$\dot{x} = -K_2 x + W^* \varphi(x) + \eta. \quad (16)$$

我们定义如下的辨识模型:

$$\dot{\hat{x}} = -K_2 \hat{x} + \hat{W} \varphi(x). \quad (17)$$

其中 $\hat{W}$ 为待估计的参数阵. 令 $\varepsilon = \hat{x} - x$, $\tilde{W} = \hat{W} - W^*$, 我们得到辨识误差模型为

$$\dot{\varepsilon} = -K_2 \varepsilon + \tilde{W} \varphi(x) - \eta. \quad (18)$$

令 $a = [\tilde{W}_1, \tilde{W}_2, \dots, \tilde{W}_n]^T$, 其中 $\tilde{W}_i$ 为 $\tilde{W}$ 的第 i 行, 并令

$$\Phi(x) = \begin{bmatrix} \varphi(x)^T & 0 & \dots & 0 \\ 0 & \varphi(x)^T & \dots & 0 \\ \vdots & & \ddots & \vdots \\ 0 & \dots & 0 & \varphi(x)^T \end{bmatrix},$$

那么, (18) 可写成

$$\dot{\varepsilon} = -K_2 \varepsilon + \Phi(x) a - \eta. \quad (19)$$

利用 Lyapunov 方法很容易得到如下的参数修正律:

$$\dot{a} = -R^{-1} \Phi(x) P. \quad (20)$$

其中 R 和 P 是适当维的正定对称阵, 注意到 $\dot{a} = [\dot{W}_1, \dot{W}_2, \dots, \dot{W}_n]^T$, 于是 $\dot{W}$ 可容易地得到. 关于自适算法 (20), 我们有下面的结果:

引理 4 如果用于估计非线性函数 $F(x)$ 的 RBF 网络按 (20) 修正权阵元素, 则有下列性质:

1) 若 $\eta_0 = 0$, 则 $\varepsilon(t)$ 和 $\dot{a}(t) \rightarrow 0$.

2) 若 $\eta_0 \neq 0$, 那么 $\|\varepsilon(t)\| \leq 2\eta_0 \lambda_{\max}(P) / \lambda_{\min}(R)$. 其中 $\lambda_{\min}(\cdot)$ 分别为 $(\cdot)$ 的最大和最小特征值. (证略)

引理 5 若 $\varepsilon(t) \rightarrow 0$, 则 $\hat{F}(x) \rightarrow F(x)$. (证略)

4 新的机器人控制方案

由第二节我们知道,当机器人系统存在不确定因素时, $F(x) \neq 0$, 计算力矩控制器(3)不能使跟踪误差收敛到零,但跟踪误差 e 和广义误差 x 均保持有界. 在第三节我们给出了用 RBF 神经网络估计 $F(x)$ 的方法. 由引理 4 知, 辨识误差将收敛于零或落在一个球上, 因此, 可以认为非线性函数 $F(x)$ 被神经估计值 $\hat{F}(x)$ 很好地近似.

下面给出一种基于神经网络补偿的机器人鲁棒控制方案. 该方案将机器人的控制分为两个阶段. 第一阶段先由计算力矩控制器单独进行控制, 并让 RBF 神经网络按第三节的方法学习非线性函数 $F(x)$; 在第二阶段, 设 RBF 网络的输出 $\hat{F}(x)$ 已能满意地逼近 $F(x)$, 并入神经补偿控制器, 使其与计算力矩控制器共同起作用, 以改善不确定性机器人系统的跟踪性能. 这时, 控制力矩由两部分组成:

$$\tau = \tau_a + \tau_b. \quad (21)$$

其中 τ_a 是计算力矩控制器信号

$$\tau_a = D_0(q)(\ddot{q}_d - (K_1 + K_2)\dot{e} - K_2K_1e) + h_0(q, \dot{q}). \quad (22)$$

τ_b 是补偿控制器信号, 取下列形式:

$$\tau_b = -D_0[\hat{F}(x) + k(x)\text{sgn}(x)]. \quad (23)$$

其中 $k(x)$ 为待定函数. 将(21)~(23)代入(1)有

$$\dot{x} = -K_2x + F(x) - D^{-1}D_0[\hat{F}(x) + k(x)\text{sgn}(x)]. \quad (24)$$

由此可看出我们取补偿控制器为(23)的形式的动机是利用 $D^{-1}D_0\hat{F}(x)$ 去近似抵消 $F(x)$ 的影响, 增加不连续项 $k(x)\text{sgn}(x)$ 则是为在不完全补偿的情况下, 强迫 x 收敛到零.

(24) 可写为

$$\dot{x} = -K_2x + D^{-1}D_0[\Delta(x) - k(x)\text{sgn}(x)]. \quad (25)$$

其中

$$\Delta(x) = D_0^{-1}DF(x) - \hat{F}(x). \quad (26)$$

显然, 存在两个正的常数 δ, δ_0 , 使下式成立

$$\|\Delta(x)\| = \|D_0^{-1}DF(x) - \hat{F}(x)\| \leq \delta_0 + \delta x. \quad (27)$$

现在我们给出如下结果:

定理 1 如果选择 K_2 使 $K_2^TD_0 + D_0K_2$ 为正定阵, 取 $k(x) = \delta_0 + \delta x$, 那么 $x \in L_2^a \cap L_\infty^a$, $\dot{x} \in L_\infty^a$, 且当 $t \rightarrow \infty$ 时, x 全局收敛于零.

证 取候选的 Lyapunov 函数为

$$V(x) = x^TD_0x, \quad (28)$$

则 V 可计算为

$$\begin{aligned} \dot{V}(x) &= x^T(K_2^TD_0 + D_0K_2)x \\ &\quad + 2x^TD_0D^{-1}D_0[\Delta(x) - k(x)\text{sgn}(x)]. \end{aligned} \quad (29)$$

由定理的条件, 我们知道 $\dot{V}(x)$ 是严格负定的, 类似于[6]的讨论, 我们得到 $x \in L_2^a \cap L_\infty^a$, $\dot{x} \in L_\infty^a$, x 全局收敛于零.

定理 2 如果定理 1 的条件满足, 且选 K_1 使得 $R^*[\lambda_i(-K_1)] < 0, \forall i$, 则当 $t \rightarrow \infty$,

e 和 $\dot{e}$ 全局收敛于零.

证 参见[6].

说明 1 如果(23)中不包含神经估计值 $\hat{F}(x)$, 即补偿控制器只用不连续项 $k(x)\text{sgn}(x)$, 虽然也能保证 x 收敛于零, 但 $k(x)$ 必须选择为

$$k(x) > \|D_0^{-1}DF(x)\| = \|D_0^{-1}D\| \|F(x)\|. \quad (30)$$

困难在于 $\|F(x)\|$ 是未知的, 因此需把 δ 和 δ_0 选得很大. 而使用 $\hat{F}(x)$ 能使 δ 和 δ_0 取得小些, 从而使跳跃力矩的幅度减小.

说明 2 切入补偿控制器后, 并不影响原有的计算力矩控制器的设计, 因为前面讲过, 为了实现标称机器人系统的解耦控制, 计算力矩控制器的增益阵 K_1 和 K_2 需选为正定的对角阵, 这恰好使得定理 1 和定理 2 关于 K_1 和 K_2 的要求自动满足.

说明 3 切入补偿器后, RBF 网络的权阵可以保持固定, 也可继续修正. 后者为神经自适应控制方式, 有较好的性能, 但增加计算负担.

5 仿真结果与讨论

本节以两旋转关节的刚性机械手为例对所提的方法进行仿真. 机械手模型(1)中的系数矩阵为^[5]:

$$D(q) = \begin{bmatrix} \theta_1 + \theta_3 + 2\theta_2 \cos q_2 & \theta_3 + \theta_2 \cos q_2 \\ \theta_3 + \theta_2 \cos q_2 & \theta_2 \end{bmatrix},$$

$$h(q, \dot{q}) = \begin{bmatrix} -\theta_3(2\dot{q}_1\dot{q}_2 + \dot{q}_2^2)\sin q_2 \\ \theta_3\dot{q}_1^2\sin q_2 \end{bmatrix}.$$

其中

$$\theta = \begin{bmatrix} \theta_1 \\ \theta_2 \\ \theta_3 \end{bmatrix} = \begin{bmatrix} I_1 + (m_1 l_1 + m_2)l_1^2 \\ m_2 l_1 l_2 / 2 \\ I_2 + m_2 l_2^2 / 4 \end{bmatrix},$$

$m_i l_i, I_i (i = 1, 2)$ 分别代表第 i 个连杆的质量、长度和转动惯量, 设机械手的实际参数为:

$$l_1 = l_2 = 0.5\text{m}, \quad m_1 = m_2 = 8\text{kg}, \quad I_1 = I_2 = 0.4\text{kgm}^2.$$

它们的标称值(先验估计值)取

$$l_{10} = l_{20} = 0.5\text{m}, \quad m_{10} = m_{20} = 4\text{kg}, \quad I_{10} = I_{20} = 0.2\text{kgm}^2.$$

易知, $\theta_0 = 0.5\theta$, 即有 50% 的参数估计误差.

设外部干扰为库仑摩擦: $f = -0.2\text{sgn}(\dot{q})$. 机械手期望运行轨迹为

$$qd_1 = 0.5\cos t \text{ rad}, \quad qd_2 = 0.5\sin t \text{ rad}.$$

仿真时, 初始的机械手位置误差和初始速度均设计零.

采用计算力矩控制方法的仿真结果如图 1 所示, 由图 1(a) 和 (d) 可见, 由于建模误差和外部干扰的影响, 机械手的跟踪误差和广义误差都比较大, 然而, 整个闭环系统是稳定的. 由图 1(d) 还可看出, 当 $t > 2.5$ 秒, 广义误差 x 进入一个两维的闭集, 其中心在原点, 各边长为 0.8, 因此, 可以利用这一信息, 在选择 RBF 神经网络的隐元的高斯函数时把注意力集中在这个团集上. 在仿真中, 我们按该集上的网格来选取 RBF 的隐元的中心, 网格的

间距(或步长)为 0.1,故共有 $17 \times 17 = 289$ 个隐元. 为计算方便,隐元的宽度均取为 1. 初始权阵设置为零. 其余矩阵或参数取为: $P = I, R = I, K_1 = 5I, K_2 = 2I, \delta = 15, \delta_0 = 0.1$. 新的控制方法的仿真结果如图 2 所示,神经补偿器的切入时刻为 $t = 5$ 秒. 由图 2(a) 和 (b) 可见,补偿器切入后,机械手的位置误差与速度误差很快收敛于零. 图 2(d) 为 $\varepsilon = \hat{x} - x$ 的运行曲线,由 ε 在两个阶段都能收敛于零得知 $\hat{F}(x)$ 能够很好地逼近 $F(x)$.




图 1 计算力矩控制仿真结果




图 2 神经网络补偿控制仿真结果

神经补偿控制器由两部分组成. 说明 1 指出,对于外扰的机器人系统,单用不连续项

$k(x)\text{sgn}(x)$ 虽能使误差收敛于零,但控制力矩的跳跃幅度较大,抖动严重.反过来,若单用神经估计器信号 $\hat{F}(x)$ 去补偿不确定性,则只能使误差降低,而不能使误差收敛于零,因为这种补偿是不完全的.因此,神经估计信号与不连续控制信号的组合是相辅相成的.

我们还对神经网络的结构参数与学习公式作了仿真研究.发现两点:1) 增加 RBF 网络隐元的数量可以使估计精度明显地提高;2) 若在学习公式(20)中增加阻尼项,即采用如下修正算法:

$$\dot{a} = -\beta a - R^{-1}\Phi^T(x)Pe. \quad (31)$$

其中 β 为阻尼系数,则可使 RBF 网络的学习过程中的振摆情况得到改善.

本文提出一种新的机器人神经网络补偿控制方案,探讨了一种用神经网络估计机器人系统不确定性的途径,给出了神经补偿控制器的设计方法并证明了闭环系统的收敛性.所提的方案对于含有未知参数和外部干扰的机器人系统是十分有效的,比传统的自适应控制方法有更好的抗干扰能力.

参 考 文 献

- [1] Ortega, R., Spong, M. W.. Adaptive Motion Control of Rigid Robots: A Tutorial. *Automatica*, 1989, 25(6):877—888
- [2] Slotine, J. J. E. and Li, W.. Composite Adaptive Control of Robot Manipulators. *Automatica*, 1989, 25(4):509—519
- [3] Spong, M. W., Ortega, R. On Adaptive Inverse Dynamics Control of Rigid Robots. *IEEE TR-AC*, 1990, 5(1):92—95
- [4] Slotine, J. J. E. and Li, W.. Adaptive Manipulator Control: A Case Study. *IEEE TR-AC*, 1988, 33(11):995—1003
- [5] Xu, J. M., Zhou, Q. J. and Leung, T. P.. Implicit Adaptive Inverse Dynamics Control of Robot Manipulators. *Proc. of IEEE Conf. on Robotics and Automation*, Atlanta, USA, May, 1993, 2:334—339
- [6] Zhou, Q. J., Xu, J. M. and Leung, T. P.. Globally Stable Adaptive Controller of Robot Manipulators. *Proc. of IEEE Conf. on Computers, Communication and Automation*, Beijing, Oct., 1993, 4:90—93
- [7] Miller, T. W., et al.. Real Time Dynamic Control of an Industrial Manipulator Using a Neural Network Based Learning Controller. *IEEE Trans. Robotics and Automation*, 1989, RA-5:641—657
- [8] Kung, S. Y. and Hwang, J. N.. Neural Network Architectures for Robotic Applications. *IEEE Trans Robotics and Automation*, RA-5:1989,641—657
- [9] Kuperstein, M. and Wang, J.. Neural Controller for Adaptive Movements with Unforeseen Payload. *IEEE Trans Network*, 1:1990, 137—142
- [10] Khosla, P. K. and Kanade, T.. Experimental Evaluation of Nonlinear Feedback and Feedforward Control Schemes for Manipulators. *Int. J. Robotics Research*, 1988, 7:18—28
- [11] Khosla, P. K. and Kanade, T.. Real-Time Implementation and Evaluation of Computed-Torque Scheme. *IEEE Trans Robotics and Automation*, 1989, RA-5: 245—253
- [12] Leahy, M. B., et. al.. Robust Model-Based Control: An Experimental Case Study. *Proc. IEEE Conf. Robotics and Automation*, 1990, 1982—1987
- [13] Broomhead, D. S. and Lowe, D.. Multivariable Functional Interpolation and Adaptive Networks. *Complex Systems*, 1988, 2:321—355

- [14] Moody, J. and Darken, C. J.. Fast Learning in Networks of Locally-Tuned Processing Units. *Neural Computation*, 1989, 1:281—294
- [15] Renals, S. and Rohwer, R.. Phoneme Classification Experiments Using Radial Basis Functions. *Proc. Int. Joint. Conf. on Neural Networks*, 1989, 1:461—467
- [16] Sanner, R. M. and Slotine, J. J. E.. Gaussian Networks for Direct Adaptive Control. *Proc. American Control Conf.*, 1991, 2153—2159
- [17] Hertman, E. J. et. al.. Layered Neural Networks with Gaussian Hidden Units as Universal Approximations. *Neural Computation*, 1990, 2:210—215
- [18] Park, J. and Sandberg, I. W.. Universal Approximation Using Radial-Basis-Function Networks. *Neural Computation*, 1991, 3:246—257

Neural Compensating Control of Uncertain Robots

XU Jianmin and ZHOU Qijie

(Department of Automation, South China University of Technology • Guangzhou, 510641, PRC)

T. P. Leung

(Hong Kong Polytechnic University • Hong Kong)

Abstract: A new trajectory tracking control scheme of robot manipulators is developed in this paper. The proposed scheme consists of a well known computed torque controller, which is based on the known nominal robot dynamics model, and a compensating controller, which is realized incorporating an radial basis function (RBF) neural network estimator and a discontinuous control signal. The compensating controller works like an add-on device. The proposed control scheme is effective to the robot systems with unknown parameters and disturbance such as Coulomb friction. The simulation results have demonstrated the feasibility of the proposed scheme.

Key words: robot manipulator; RBF neural network; robust compensating control

本文作者简介

徐建闽 1960年生,副教授.1982年于江西工学院电机系获学士学位,1986年和1994年在华南理工大学分别获硕士和博士学位,现任华南理工大学交通学院副院长、交通工程系系主任.研究兴趣为非线性控制,鲁棒控制,自适应控制,神经网络控制,机器人及其控制,交通监控及CIMS.

周其节 1930年生,1951年毕业于中山大学,1955年哈尔滨工业大学研究生毕业,现为华南理工大学自动化系教授,博士生导师.主要研究领域为非线性系统理论,线性系统理论,自适应控制系统,变结构控制系统及机器人与控制.近年来发表了有关论文70余篇.

梁天培 1946年生.1967年毕业于香港大学机械工程系,而后获得香港大学硕士、伦敦大学哲学博士和清华大学工学博士学位,现任香港理工大学副校长兼理学院院长及机械工程系讲座教授.香港工程师学会会长,研究兴趣为自动控制、CAD专家系统、机器人及其控制.