

doi:10.6041/j.issn.1000-1298.2013.05.047

神经网络与计算力矩复合的机器人运动轨迹跟踪控制*

贺红林 何文丛 刘文光 封立耀
(南昌航空大学航空制造工程学院, 南昌 330063)

摘要: 为了实现机器人精密运动控制,在其关节系统引入计算力矩法(CTC)与神经网络复合的控制器,旨在通过CTC实现系统的初步控制并利用神经网络补偿机器人的不确定动力学特性所带来的运动误差。首先,建立了机器人的动力学模型并对其不确定性动力学量进行了描述;然后,为机器人构建了双闭环控制系统,并依据机器人标称模型规划出CTC控制律;进而,引入函数链神经网络(FLNN)对不确定性动力学量进行估值,并推导出FLNN的学习律;最后,对系统进行了仿真,结果显示,该复合控制器可将关节位置和速度跟踪误差控制在 ± 0.001 rad和 ± 0.001 rad/s之内,且其对机器人的参数变化及外部扰动具有较强的自适应性与鲁棒性。

关键词: 机器人 轨迹跟踪控制 函数链神经网络 计算力矩控制

中图分类号: TP242.2 **文献标识码:** A **文章编号:** 1000-1298(2013)05-0270-06

Tracking Control of Robot Using Hybrid Controller Based on Neural Network and Computed Torque

He Honglin He Wencong Liu Wenguang Feng Liyao
(School of Aeronautical Manufacturing Engineering, Nanchang Hangkong University, Nanchang 330063, China)

Abstract: In order to improve robot manipulator's tracking accuracy, a hybrid controller consisting of a functional link neural network sub-controller (FLNNC) and a computed torque sub-controller (CTC) was introduced into the manipulator, which made use of CTC to drive the manipulator reaching its desired position roughly while employed the FLNNC to compensate the tracking error caused by the dynamic uncertainty and disturbance of the robot. To accomplish this, firstly, a nominal dynamic model of the manipulator was established, and the dynamic uncertainty of the robot manipulator was modeled and formulized. And then, a control system with two close loops was built for the manipulator, and the computed-torque control law based on the nominal manipulator model was planned for the system. Moreover, a functional link neural network (FLNN) being capable of approximating the dynamic uncertainty term of the robot was designed in the system, and the weight learning algorithm for the FLNN was derived. Finally, simulations were made on that system so as to validate the hybrid controller. The results showed that both the position error and speed tracking error of the robot joints could be controlled within ± 0.001 rad and ± 0.001 rad/s, which meant that the proposed hybrid controller was able to make the robots tracking desired trajectory with high precision.

Key words: Robot Trajectory tracking Functional link neural network Computed torque control

引言

计算力矩法(CTC)是简单易行的机器人轨迹跟

踪控制方法^[1],它基于精确的机器人动力学模型,然而因机器人存在两类动力学不确定性,其精确的模型很难获得^[2~3]。为补偿两类不确定性所带来的

收稿日期: 2012-05-28 修回日期: 2012-07-20
* 国家自然科学基金资助项目(51265040)和江西省教育厅科学技术研究资助项目(GJJ12416)
作者简介: 贺红林,教授,博士,主要从事机器人控制技术以及复杂结构动力学与强度研究,E-mail: hehonglin1967@163.com

控制误差,自 20 世纪 80 年代以来,人们广泛地开展了机器人自适应和鲁棒控制研究,提出了许多控制算法^[4~5],但这些算法大多只具理论意义。近些年,人工神经网络(ANN)技术的发展受到越来越广泛的关注,将神经网络用于机器人控制成为机器人研究的重要方面^[6~9]。然而,现有的各种机器人神经网络控制或者要求机器人惯性阵精确已知且可逆,或需对关节进行加速度反馈,有的甚至还要求网络的连接权具有已知上界,从而影响其工程实用性。更主要是,大多采用了多层网络,造成其实时性差、不便实现。针对上述问题,本文提出由计算力矩结构和函数链网络(FLNN)复合的控制器。

1 机器人动力学模型

对于自由度为 n 的工业操作机器人,其臂杆系统的动力学方程具有一般形式^[1]

$$D(q)\ddot{q} + C(q, \dot{q})\dot{q} + G(q) + F_f(\dot{q}) + \tau_d = \tau \quad (1)$$

式中 $D(q)$ ——机器人的惯性矩阵
 $C(q, \dot{q})$ ——科氏/向心力矩阵
 $G(q)$ ——重力矩矢
 $F_f(\dot{q})$ ——关节摩擦力矩矢
 τ ——关节驱动力矩矢
 τ_d ——作用于关节的外部扰动

若令 $N(q, \dot{q}) \triangleq \dot{D} - 2C$,则不难证明 $N(q, \dot{q})$ 具有斜对称性,亦即对于任意给定的矢量 $\theta \in \mathbb{R}^n$,必有: $\theta^T N(q, \dot{q}) \theta = 0$ 。

由于机器人存在参数不确定性,因此,建模时通常只能得到其标称动力学模型,即

$$D_o(q)\ddot{q} + C_o(q, \dot{q})\dot{q} + G_o(q) + F_{of}(\dot{q}) = \tau_o \quad (2)$$

式中 $D_o(\cdot)$ ——依据机器人标称参数确定的惯性阵的标称量
 $C_o(\cdot)$ ——依据机器人标称参数确定的向心/科氏阵的标称量
 $G_o(\cdot)$ ——依据机器人标称参数确定的重力矩矢的标称量
 $F_{of}(\cdot)$ ——依据机器人标称参数确定的摩擦矩矢的标称量

若令 $N_o(q, \dot{q}) = \dot{D}_o(q) - 2C_o(q, \dot{q})$,则 N_o 也具斜对称性。当引入标称量后,式(1)可改写成

$$\underbrace{[D_o(q) + \Delta D(q)]}_{D(q)}\ddot{q} + \underbrace{[C_o(q, \dot{q}) + \Delta C(q, \dot{q})]}_{C(q, \dot{q})}\dot{q} + \underbrace{[G_o(q) + \Delta G(q)]}_{G(q)} + \underbrace{[F_{of}(\dot{q}) + \Delta F_f(\dot{q})]}_{F(\dot{q})} + \tau_d = \tau \quad (3)$$

式中, $\Delta D(\cdot)$ 、 $\Delta G(\cdot)$ 、 $\Delta C(\cdot)$ 和 $\Delta F_f(\cdot)$ 分别为相应动力学项的真值与其标称值的差值。若令

$$\Delta N(q, \dot{q}) \triangleq \Delta \dot{D} - 2\Delta C, \text{ 则 } x^T \Delta N(q, \dot{q}) x = 0。$$

2 FLNN 的函数矢逼近特性

本文的机器人控制器设计涉及到 FLNN 的应用。根据 ANN 理论,FLNN 的输入/输出关系可描述为

$$y = W^T \sigma(x) \quad (x \in \mathbb{R}^n, y \in \mathbb{R}^m) \quad (4)$$

式中 x, y ——网络的输入和输出
 W ——FLNN 的权值矩阵
 $\sigma(x)$ ——网络的激活函数矢

由于在 FLNN 中只有权阵 W 的值可调整,故它不像多层前馈网络那样具有广泛的非线性函数逼近能力,但其运行速度快、便于在线实现,特别是当 $\sigma(\cdot)$ 取定为基函数矢时,FLNN 也同样具有非凡的函数逼近能力。

根据 FLNN 理论,若 U 为定义于 $x \in \mathbb{R}^n$ 上的列紧子集,而 $C^m(U)$ 是定义于 U 上的函数集,只要 $\sigma(x)$ 为适当取定的基函数矢,那么对于任意给定的连续光滑函数 $f(x) \in C^m(U)$,总存在具有有限个隐含层神经元的 FLNN,该 FLNN 能以任意给定精度对 $f(x)$ 进行逼近,即

$$f(x) = W^T \sigma(x) + \varepsilon \quad (\|\varepsilon\| \leq \varepsilon_N) \quad (5)$$

式中 ε ——FLNN 的逼近误差
 ε_N ——给定的逼近精度

$\sigma(\cdot)$ 通常取径向基函数矢或 sigmoid 函数矢,当然也可像本文一样自行设计基函数。

3 控制系统设计

3.1 系统的构成

机器人控制器设计的实质,就是要规划出关节驱动力矩矢量 $\tau(t)$ 的适当形式,使机器人在关节空间内的实际运动轨迹 $q(t)$ 逼近其目标轨迹 $q_d(t)$,即 $q(t) \rightarrow q_d(t)$ 。为使系统免于加速度反馈,定义机器人广义轨迹跟踪误差,即

$$s(t) = \dot{e}(t) + \Lambda e(t) \quad (6)$$

其中 $e = q_d - q \quad \dot{e} = \dot{q}_d - \dot{q}$
式中 e ——机器人关节的位置偏差
 $\dot{e}$ ——关节角速度偏差

Λ ——适当取定的常值正定对称阵, $\Lambda \in \mathbb{R}^{n \times n}$
理论上讲,只要广义误差 s 有界,式(6)即表示一个稳定的系统,而 $e(t)$ 、 $\dot{e}(t)$ 也将有界。特别地,如果控制作用能使 $s(t) \rightarrow 0$,则 $e(t)$ 和 $\dot{e}(t)$ 必趋于 0。

为了实现机器人精密控制,在此构建图 1 所示具有位置和速度反馈的控制系统。该系统的控制器是由一个计算力矩子控制器和一个函数链神经网络子控制器(FLNNC)构成。两个子控制器的作用分

别是:通过 CTC 对机器人进行初步或粗略的运动控制;利用 FLNN 补偿机器人的不确定动力特性及其外部扰动以提高机器人的控制精度。




图 1 机器人神经网络控制系统

Fig. 1 Control diagram of robot manipulator

3.2 CTC 的控制律

根据图 1 的机器人系统结构,写出其关节控制力矩的输出形式

$$\tau = \tau_c + \tau_N \tag{7}$$

式中, τ_c 、 τ_N 分别表示 CTC 控制器和 FLNNC 的控制输出。在该复合控制器中,CTC 作为系统的主控制器。理论上,应根据机器人动力学项的结构及其真值来确定 CTC 子控制器的控制作用,但因真值很难准确获知,故本文依据动力学项的标称值计算 CTC 的控制输出,形如

$$\tau_c = D_o(K_p e + K_v \dot{e}) + C_o \dot{q}_d + G_o + F_{of} \tag{8}$$

式中, $K_p \in \mathbb{R}^{n \times n}$ 和 $K_v \in \mathbb{R}^{n \times n}$ 分别是适当取定的正定位置反馈阵和正定速度反馈阵。显然,式(8)中标称项是关于关节位置和速度的函数,可在线计算。将式(7)、式(8)进行比较,并考虑到位置误差和速度误差的定义,可得到

$$\begin{cases} D_o(\ddot{e} + K_v \dot{e} + K_p e) = - (F_\Delta(x) + \tau_d - \tau_N) \\ F_\Delta(x) = \Delta D \ddot{q} + \Delta C \dot{q} + \Delta G + \Delta F_f \end{cases} \tag{9}$$

要使式中的 $\ddot{e} + K_v \dot{e} + K_p e = 0$, 必须使

$$\tau_N = F_\Delta(x) + \tau_d \tag{10}$$

一旦有 $\ddot{e} + K_v \dot{e} + K_p e = 0$, 则适当取定矩阵 K_p 和 K_v 的值, 即使得 $e(t) |_{t \rightarrow \infty} \rightarrow 0$ 。

将式(6)、式(8)和式(10)进行综合考虑,可以得到机器人的误差动力学方程

$$\begin{cases} \Delta D \dot{s} = -\Delta C \dot{s} + F_\Delta(x_s) + \tau_d - \Delta \tau_N \\ F_\Delta(x_s) = \Delta D \eta_s + \Delta C \xi_s + \Delta F + \Delta G \end{cases} \tag{11}$$

其中 $x_s = [\eta_s^T \ \xi_s^T \ q^T \ \dot{q}^T]^T$ $\eta_s = \ddot{q}_d + \Lambda \dot{e}$

$$\xi_s = \dot{q}_d + \Lambda e$$

式中,函数矢 $F_\Delta(x_s)$ 隐含了除 ΔCs 之外其它所有的参数不确定性因素的影响,称其为机器人的不确定性动力学函数矢。

3.3 FLNN 的控制律

为了降低系统轨迹跟踪误差,引入函数链神经

网络对 $F_\Delta(x_s)$ 进行估值,其实现形式为

$$\hat{F}_\Delta(x_s) = \hat{W}_s^T \sigma_\Delta(x_s) \tag{12}$$

式中 $\hat{W}_s$ ——网络的当前权值

$\sigma_\Delta(x_s)$ ——依据机器人动力学模型设计的基函数矢

根据图 1 的系统结构,FLNN 的控制输出形式为

$$\tau_N = \hat{W}_s^T \sigma_\Delta(x_s) + K_{N_s} s - \chi(t) \tag{13}$$

式中, K_{N_s} 是适当取定的正定增益阵,这里引入反馈量 $K_{N_s} s$ 的目的在于补偿式(11)中的动力学量 ΔCs ;引入鲁棒项 $\chi(t)$ 是为了适当补偿外部扰动。因 FLNN 存在函数逼近误差,且网络的当前权值 $\hat{W}_s$ 与理想值 W_s 也存在偏差,这必然导致 $\hat{F}_\Delta$ 与 $F_\Delta(x_s)$ 出现偏差,即

$$\tilde{F}_\Delta = F_\Delta(x_s) - \hat{F}_\Delta = \tilde{W}_s^T \sigma_\Delta(x_s) + \varepsilon_s \tag{14}$$

式中, $\tilde{W}_s = W_s - \hat{W}_s$, ε_s 是网络估值误差。将式(13)与式(14)代入式(11),可得

$$\begin{aligned} \Delta D \dot{s} = & -(\Delta Cs + K_{N_s} s) + \\ & \tilde{W}_s^T \sigma_\Delta(x_s) + \varepsilon + \tau_d + \chi(t) \end{aligned} \tag{15}$$

3.4 FLNN 的学习律

网络权值学习律设计既需保证系统的稳定性,又要使轨迹跟踪误差 $s(t)$ 足够小或趋于 0, 还需保证网络权值的有界性。针对这些要求并借助机器人参数自适应律的设计方法^[2], 规划出了 FLNN 的权值学习律,其具体描述如下:

假定拟采用式(12)给出的 FLNN 对 $F_\Delta(x_s)$ 进行估值或逼近,且网络理想权阵 W_s 及逼近误差 ε_s 有界, 即有 $\|W_s\| \leq W_B$ 、 $\|\varepsilon_s\| \leq \varepsilon_B$; 同时假定系统未建模扰动也有界, 即 $\|\tau_d\| \leq d_B$ 。若使 FLNNC 系统按式(13)的形式输出控制作用, 并取 FLNN 权值调整律为

$$\dot{\hat{W}}_s = \Theta(\sigma_\Delta(x_s) s^T - \vartheta \|s\| \hat{W}_s) \tag{16}$$

式中 Θ ——适当选取的正定阵

ϑ ——适当取定的正常数

则 s 和 $\hat{W}_s$ 必然一致有界, 并且若 K_{N_s} 中的元素取值足够大, 则 FLNNC 总能使 $s(t)$ 限制在足够小的范围内。

为证明式(16)给出的权值学习律可行性, 构建 Lyapunov 能量函数

$$L(t) = s^T \Delta D s / 2 + \text{tr}(\tilde{W}_s^T \Theta^{-1} \tilde{W}_s) / 2 \tag{17}$$

式中, 函数 $\text{tr}(\cdot)$ 表示对方阵进行求迹运算。

将式(17)两端同时对时间进行求导, 则有

$$\dot{L}(t) = s^T \Delta \dot{D} s / 2 + s^T \Delta D \dot{s} + \text{tr}(\dot{\tilde{W}}_s^T \Theta^{-1} \tilde{W}_s) \tag{18}$$

将式(16)和式(15)代入式(18), 得到

$$\dot{L}(t) = -s^T K_{N_s} \dot{s} + \vartheta \|s\| \operatorname{tr}(\widehat{W}_s^T (W_s - \widetilde{W}_s)) + s^T (\varepsilon_s + \tau_d) \quad (19)$$

考虑到式(19)中的方阵求迹运算满足

$$\operatorname{tr}(\widehat{W}_s^T (W_s - \widetilde{W}_s)) \leq \|\widetilde{W}_s\|_F \cdot \|W_s\|_F - \|\widetilde{W}_s\|_F^2 \quad (20)$$

再将式(20)回代到式(15)中,可得

$$\dot{L}(t) < -\|s\| [\vartheta (\|\widetilde{W}_s\|_F - W_B/2)^2 - \vartheta W_B^2/4 + K_{N_s, \min} \|s\| - (\varepsilon_B + d_B)] \quad (21)$$

式中, W_B 表示 W 的上界, $K_{N_s, \min}$ 表示 K_{N_s} 中最小元素的值。由式(21)可知,一旦权值偏差阵出现以下情形

$$\|\widetilde{W}_s\|_F > B_W$$

其中 $B_W = W_B/2 + \sqrt{\vartheta W_B^2/4 + (\varepsilon_B + d_B)/\vartheta}$

或者一旦系统的轨迹跟踪误差越界,即

$$\|s\| > B_s$$

其中 $B_s = W_B^2/4 + (\varepsilon_B + d_B)/K_{N_s, \min}$

则 $\dot{L}$ 必变得小于 0, 亦即只要广义轨迹跟踪误差 s 脱离列紧集 $S_s = \{s | \|s(t)\| \leq B_s\}$ 或 $\widetilde{W}_s$ 脱离列紧集 $S_{\widetilde{W}} = \{\widetilde{W} | \|\widetilde{W}\|_F \leq B_W\}$, $\dot{L}$ 值就变为负值, 这将不仅使 $s(t)$ 的值控制在球域 S_s 内, 并且保证了 s 、 $\widetilde{W}_s$ 的终值一致有界性。 $\widetilde{W}_s$ 和 W_s 的终值一致有界必然导致 $\widehat{W}_s$ 的终值一致有界。式(21)还表明: B_s 的取值将随 $K_{N_s, \min}$ 的增大而减小。亦即在控制设计时只要保证 K_v 中最小元素足够大, 则总可使 s 控制在足够小的范围内。

3.5 网络拓扑的分解

在设计神经网络的几何拓扑时, 如果能将一个结构较复杂的网络的功能简化为通过若干较简单的子网来实现, 将大大提高网络执行速度。考虑到 $F_\Delta(x_s)$ 是由 $\Delta D\eta_s$ 、 $\Delta C\xi_s$ 、 ΔF 、 ΔG 等 4 项合成的, 故可先用 4 个子网分别逼近这 4 项, 再对子网的估值求和, 这样同样能获得 $F_\Delta(x_s)$ 的估值。各子网的逼近形式为

$$\begin{cases} \Delta D\eta_s(t) = \widehat{W}_D^T \sigma_{\Delta, D}(x_D) + \varepsilon_D \\ \Delta C\xi_s(t) = \widehat{W}_C^T \sigma_{\Delta, C}(x_C) + \varepsilon_C \\ \Delta F_f(\dot{q}) = \widehat{W}_F^T \sigma_{\Delta, F}(x_F) + \varepsilon_F \\ \Delta G(q) = \widehat{W}_G^T \sigma_{\Delta, G}(x_G) + \varepsilon_G \end{cases} \quad (22)$$

式中, $x_D \triangleq [\eta_s^T \quad q^T]^T$, $x_C \triangleq [\xi_s^T \quad q^T \quad \dot{q}^T]^T$, $x_D \triangleq q$, $x_F \triangleq [q^T \quad \dot{q}^T]^T$, ε_D 、 ε_C 、 ε_F 、 ε_G 为各子网的估值误差。

4 系统仿真

4.1 仿真对象

为了验证本文复合结构控制器的有效性和可行

性, 对图 2 所示的机器人臂杆系统进行了运动轨迹跟踪控制仿真, 该系统的动力学方程为

$$\begin{bmatrix} d_{11} & d_{12} \\ d_{21} & d_{22} \end{bmatrix} \begin{bmatrix} \ddot{q}_2 \\ \ddot{q}_1 \end{bmatrix} + \begin{bmatrix} c_{11} & c_{12} \\ c_{21} & c_{22} \end{bmatrix} \begin{bmatrix} \dot{q}_1 \\ \dot{q}_2 \end{bmatrix} + \begin{bmatrix} g_2 \\ g_1 \end{bmatrix} = \begin{bmatrix} \tau_1 \\ \tau_2 \end{bmatrix} - \begin{bmatrix} F_{f1} \\ F_{f2} \end{bmatrix} \quad (23)$$

其中 $d_{11} = m_1 l_{c1}^2 + m_3 l_{c3}^2 + m_4 l_{c1}^2 + I_1 + I_3 \triangleq \phi_{x1}$

$$d_{12} = (m_3 l_2 l_{c3} - m_4 l_1 l_{c4}) \cos(q_2 - q_1) =$$

$$d_{21} \triangleq \phi_{x2} \cos(q_2 - q_1)$$

$$d_{22} = m_2 l_{c2}^2 + m_3 l_2^2 + m_4 l_{c4}^2 + I_2 + I_4 \triangleq \phi_{x3}$$

$$c_{11} = c_{22} = 0 \quad c_{12} = -\phi_{x2} \dot{q}_2 \sin(q_2 - q_1)$$

$$c_{21} = -\phi_{x2} \dot{q}_1 \sin(q_2 - q_1)$$

$$g_1 = (m_1 l_{c1} + m_3 l_{c3} + m_4 l_1) g \cos q_1 \triangleq \phi_{x4} \cos q_1$$

$$g_2 = (m_1 l_{c2} + m_3 l_2 - m_4 l_{c4}) g \cos q_2 \triangleq \phi_{x5} \cos q_2$$

进行控制仿真时, 分别设定机器人的相关动力学参数的真值和标称值

$$\phi_x = [\phi_{x1} \quad \phi_{x2} \quad \phi_{x3} \quad \phi_{x4} \quad \phi_{x5}]^T = [9 \quad 0.5 \quad 6 \quad 23 \quad 3]^T$$

$$\phi_{x0} = [6 \quad 0.2 \quad 4 \quad 13 \quad 4]^T$$

并且设定系统的目标轨迹和关节扰动力矩为

$$q_d(t) = [\pi \sin(\pi t)/2 \quad \pi \cos(\pi t)/2]^T$$

$$\tau_d = [6.5 \sin(2.3 \pi t) \quad 3.2 \cos(3.7 \pi t)]^T$$




图 2 两自由度机器人臂杆系统

Fig. 2 2-DOF robot manipulator system

4.2 基函数矢设计

根据式(23)和式(22)规划出控制对象相关动力学项的 FLNN 估值的网络结构, 如图 3 所示。图中的 $\otimes$ 表示乘法器, 各个子网的基函数矢分别取定为

$$\sigma_{\Delta, D}(x_s) = [1 \quad \cos(q_2 - q_1) \quad \cos(q_2 - q_1) \quad 1]^T$$

$$\sigma_{\Delta, C}(x_s) = [\cos q_1 \quad \cos q_2]^T$$

$$\sigma_{\Delta, F}(x_s) = [\dot{q}_1 \quad \operatorname{sgn}(\dot{q}_1) \quad \dot{q}_2 \quad \operatorname{sgn}(\dot{q}_2)]^T$$

$$\sigma_{\Delta, G}(x_s) = \begin{bmatrix} \dot{q}_1 \sin(q_2 - q_1) \\ \dot{q}_2 \sin(q_2 - q_1) \\ \dot{q}_2 \sin(q_2 - q_1) \end{bmatrix}$$

4.3 仿真结果

利用 Matlab 对系统控制性能进行仿真, 有关控




图 3 面向仿真对象的 FLNN 子网

Fig. 3 FLNNC for simulated robot

制参数设定为： $\vartheta = 1.2$, $\Lambda = \text{diag}(10, 10)$, $K_p = \text{diag}(40, 40)$; $K_v = \text{diag}(30, 30)$, $\Theta = \text{diag}(50, 50)$ 。

图 4 给出了机器人系统存在参数不确定性与外部扰动,利用复合控制器进行控制时的结果。由图可见系统的位置和速度跟踪误差分别为 $\pm 0.001 \text{ rad}$




图 4 CTC 与 FLNNC 复合控制轨迹跟踪结果

Fig. 4 Trajectory tracking based on hybrid controller

(a) 位置跟踪误差 (b) 角速度误差

(c) 控制力矩 (d) 权阵 W_c 中部分元素变化

和 $\pm 0.001 \text{ rad/s}$ 。图 4c 给出了关节的控制作用,可见 CTC 的输出比 FLNNC 输出的要大,但二者的差距不明显,造成此情况的主要原因是在仿真时刻意地让动力学参数的标称值远离其真值,从而造成 FLNNC 需产生较大的控制作用来补偿建模偏差所带来的控制误差。图 5 给出了单独采用 CTC 对机器人进行控制时的结果。图 5a 给出了基于精确模型的机器人 CTC 控制结果,此时系统的跟踪误差很小,这进一步说明了基于精确模型的 CTC 能实现机器人精密控制;图 5c 和图 5d 是依据标称模型设计 CTC 的控制结果,此时的系统控制精度较低,说明 CTC 不适于存在参数不确定性和外部扰动机器人控制应用中。图 6 是仅采用 FLNNC 时的控制结果。对比图 6 和图 4 可发现,单独采用 FLNNC 时系统的控制精度要明显低于采用复合控制器时的精度;而将图 6 与图 5 进行对比,还可看出当机器人存在参数不确定性和扰动时,采用 FLNNC 的控制效果要优于采用 CTC 时的控制效果。




图 5 计算力矩法控制的轨迹跟踪结果

Fig. 5 Trajectory tracking based on CTC

(a) 位置跟踪误差(基于精确模型) (b) 位置跟踪误差(基于标称模型) (c) 速度跟踪误差(基于标称模型) (d) 控制输出(基于标称模型)

5 结束语

针对机器人动力学模型的高度非线性、强耦合特征以及其存在的参数与非参数不确定性,为了实现机器人的精密轨迹跟踪控制,本文引入函数链神经网络对机器人的非确定性动力学量进行逼近,并构建出基于神经网络与计算力矩法复合的双闭环机




图6 神经网络控制的轨迹跟踪结果

Fig.6 Trajectory tracking results based on FLNNC

(a) 位置跟踪误差 (b) 角速度误差 (c) 控制力矩

器人控制系统。依据机器人的标称动力学模型设计
出其计算力矩子控制器的结构及其控制律;根据机
器人的动力学项的结构规划出了其函数链神经网络
逼近器的结构,并规划出神经网络的学习律。为了
验证所推出复合控制器的可行性与有效性,对该复
合控制器的性能进行了仿真。结果显示:这种复合
控制作用可将机器人系统的位置与速度跟踪误差分
别控制在 $\pm 0.001\text{ rad}$ 和 $\pm 0.001\text{ rad/s}$ 之内,并且该
控制器对机器人的外部扰动以及机器人结构参数的
变化具有较强的鲁棒性和自适应性。神经网络和计
算力矩法复合的控制器既能实现机器人精密控制又
便于实现,是一种具有发展前景的机器人控制技术。

参 考 文 献

1 谢明江. 不确定性机器人鲁棒跟踪控制方法研究[D]. 上海:上海交通大学,2000.
Xie Mingjiang. On the robust tracking control of robot manipulators with uncertainties[D]. Shanghai: Shanghai Jiaotong University, 2000. (in Chinese)

2 Somawang A, Siam C. Reducing steady-state errors of a direct drive robot using neurofuzzy control [C]. 2nd Asian Symposium on Industrial Automation and Robotics, Bangkok, Thailand, 2001;302 ~ 305.

3 Shuzhi S G. Adaptive control of robots having both dynamical parameter uncertainties and unknown input scalings [J]. Mechatronics,1996,6(5):557 ~ 567.

4 王洪斌. 不确定性机器人轨迹跟踪鲁棒控制方法研究[D]. 秦皇岛:燕山大学,2006.
Wang Hongbin. Research on robust control of robot manipulators tracking under uncertainties [D]. Qinhuangdao: Yanshan University, 2006. (in Chinese)

5 Barambone O. Robust neural control for robotic manipulators [J]. Automatica, 2002,38(3):235 ~ 242.

6 Patino H D, Ricardo Carelli. Neural networks for advanced control of robot manipulators [J]. IEEE Transactions on Neural Networks, 2002,13(2):343 ~ 354.

7 Vesna Rankovic, Ilija Nikolic. Control of industrial robot using neural network compensator [J]. Theoretical and Applied Mechanics, 2005,32(2): 147 ~ 163.

8 Patiño D. Neural network-based model reference adaptive control system [J]. IEEE Transactions on Systems, Man and Cybernetics, Part B: Cybernetics, 2000, 30(1): 198 ~ 204.

9 Jiang Zhaohui, Taiki Ishita. A neural network controller for trajectory control of industrial robot manipulators [J]. Journal of Computers, 2008, 3(8):1 ~ 7.