

文章编号: 1001-0920(2012)11-1740-05

从机器人输出反馈自适应神经控制中学习

吴玉香, 杨梅, 王聪

(华南理工大学 自动化科学与工程学院, 广州 510641)

摘要: 针对系统参数完全未知且仅输出可测的机器人, 使用径向基函数(RBF)神经网络和高增益观测器设计了一种自适应神经控制算法. 该算法不仅实现了闭环系统所有信号的最终一致有界, 而且沿周期跟踪轨迹实现了对未知闭环系统动态的确定学习. 学过的知识可用来改进系统的控制性能, 也可应用于后续相同或相似的控制任务以节约时间和能量. 仿真研究表明了所设计的控制算法的正确性和有效性.

关键词: 确定学习; RBF神经网络; 自适应神经控制; 高增益观测器; 机器人

中图分类号: TP273

文献标志码: A

Learning from output feedback adaptive neural control of robot

WU Yu-xiang, YANG Mei, WANG Cong

(College of Automation and Engineering, South China University of Technology, Guangzhou 510641, China.

Correspondent: WU Yu-xiang, E-mail: xyuwu@scut.edu.cn)

Abstract: An adaptive neural control algorithm is proposed for completely unknown robot with only output measurement using RBF networks and high-gain observer. The designed adaptive neural controller not only guarantees ultimately bounded of all signals in the closed-loop system, but also achieves the deterministic learning of the unknown closed-loop system dynamics along periodic tracking orbit. The learned knowledge can be used to improve control performance, and can also be recalled and reused in the same or similar control task to save time and energy. Simulation results show the effectiveness of the proposed approach.

Key words: deterministic learning; RBF networks; adaptive neural control; high-gain observer; robot

1 引言

自适应神经网络控制已在机器人控制系统中得到广泛的研究, 并取得了满意的控制效果^[1-6]. 在已有自适应神经控制方案中, 神经网络被用来逼近机器人动态中的非线性函数, 同时人们利用Lyapunov稳定性理论来设计稳定、收敛和具有鲁棒性的闭环控制系统. 研究表明, 为了克服机器人模型不确定性及非结构不确定性等问题, 神经网络控制方法比传统的自适应控制和非自适应控制更具优势^[7]. 然而, 大多数基于神经网络的控制方法要求机器人关节速度的测量, 这不仅增加了机器人移动部分的重量和体积, 而且还会带来测量噪声, 影响机器人的控制性能和效率, 因此, 有必要设计仅使用位置测量的机器人控制器^[8]. 人们提出了几种使用观测器的自适应神经控制器^[9-11], 也取得了满意的控制效果. 但无论是具有关

节速度测量的自适应神经控制器, 还是仅有位置测量的自适应神经控制器, 都是基于神经网络的通用逼近性而展开的, 而对于神经网络的函数逼近能力(能否学习到系统未知动态)则很少研究. 由于不满足持续激励(PE)条件, 神经网络权值的收敛性不能得到保证, 以至于即使是重复执行相同的控制任务, 自适应神经控制器也不得不进行冗余而繁琐的重新训练, 浪费时间和能量.

本文基于确定学习理论^[12-13], 仅使用关节位置测量, 设计了一种新的机器人控制与学习策略, 不仅实现了闭环系统所有信号的最终一致有界, 而且实现了确定学习. 使用学过的知识可以改进系统的控制性能. 最后, 通过两连杆平面机器人的例子表明了所提出控制方法的正确性和有效性.

收稿日期: 2011-04-28; 修回日期: 2011-07-12.

基金项目: 国家自然科学基金项目(60743011, 61075082).

作者简介: 吴玉香(1968—), 女, 副教授, 从事确定学习、智能控制等研究; 杨梅(1988—), 女, 硕士生, 从事确定学习、智能控制的研究.

2 问题描述

对于一个 n 关节刚性臂机器人, 其动力学方程可表示为^[2]

$$M(q)\ddot{q} + V_m(q, \dot{q})\dot{q} + F(\dot{q}) + G(q) = \tau, \quad y = q. \quad (1)$$

其中: $q, \dot{q}, \ddot{q} \in R^n$ 代表关节的位置、速度和加速度; $M(q) \in R^{n \times n}$ 为对称正定的惯性矩阵; $V_m(q, \dot{q}) \in R^{n \times n}$ 为向心力和哥氏力矩阵; $F(\dot{q}) \in R^n$ 为摩擦力矢量; $G(q) \in R^n$ 为重力矢量; $\tau \in R^n$ 为关节驱动力矩矢量; $y \in R^n$ 为可测输出. 机器人系统(1)具有如下性质.

性质 1 惯性矩阵 $M(q)$ 是正定对称矩阵且有界, 即满足 $m_1 I \leq M(q) \leq m_2 I, \forall q \in R^n$. 其中: I 为适当维数的单位矩阵, $m_2 \geq m_1 > 0$.

性质 2 矩阵 $[\dot{M}(q) - 2V_m(q, \dot{q})]$ 是斜对称的.

令 $x_1 = q, x_2 = \dot{q}$, 系统(1)可表示为

$$\dot{x}_1 = x_2, \quad \dot{x}_2 = F_1 + G_1 \tau, \quad y = x_1. \quad (2)$$

其中: $F_1 = -M^{-1}(V_m \dot{q} + G + F)$, $G_1 = M^{-1}$, 并假定它们是完全未知的; x_2 是不可测的.

性质 3 根据性质2, $G_1(\cdot)$ 也是正定有界的, 即存在一些正常数 $\bar{g}_2 \geq \bar{g}_1 > 0$, 使得 $\bar{g}_2 I \geq G_1(\cdot) \geq \bar{g}_1 I$.

本文的控制目标是: 给定一有界的光滑周期参考轨迹 y_d , 使用局部 RBF 神经网络设计自适应神经控制器, 实现仅输出可测的未知机器人的控制与学习. 文中假定 \dot{y}_d, \ddot{y}_d 也为有界光滑周期轨迹.

3 自适应神经控制器设计

3.1 高增益观测器设计

由于 x_2 不可测, 使用高增益观测器估计 x_2 ^[14-15], 即

$$\varepsilon_\lambda \dot{\xi}_1 = \xi_2, \quad \varepsilon_\lambda \dot{\xi}_2 = -b_1 \xi_2 - \xi_1 + x_1. \quad (3)$$

其中: ε_λ 为小的正参数, 正常数 b_1 满足多项式 $s^2 + b_1 s + 1$ 为 Hurwitz, 存在正常数 h 和一个有限时间 t^* , 对于 $\forall t > t^*$, 有^[14]

$$\|\xi_2/\varepsilon_\lambda - \dot{y}\| \leq \varepsilon_\lambda h = O(\varepsilon_\lambda). \quad (4)$$

定义状态 $\hat{x} = [x_1, \hat{x}_2] = [x_1, \xi_2/\varepsilon_\lambda]^T$, 则有

$$\|\hat{x} - x\| \leq \varepsilon_\lambda h = O(\varepsilon_\lambda). \quad (5)$$

3.2 自适应神经控制器设计

定义矢量 Y_d, E 和滤波器跟踪误差分别为

$$Y_d = [y_d^T, \dot{y}_d^T]^T, \quad (6)$$

$$E = x - Y_d, \quad (7)$$

$$r = \dot{e} + \lambda e = [\lambda \quad 1] E. \quad (8)$$

其中: $x = [x_1^T, x_2^T]^T, E = [e^T, \dot{e}^T]^T, e = y - y_d$ 为输出跟踪误差, $\lambda > 0$ 为设计常数, 而

$$\hat{E} = \hat{x} - Y_d, \quad (9)$$

$$\hat{r} = [\lambda \quad 1] \hat{E}. \quad (10)$$

对式(8)求导, 得

$$\dot{r} = \dot{x}_2 - \ddot{y}_d + [\lambda \quad 1] E =$$

$$F_1(x) + G_1(x)u + \hat{v} + [\lambda \quad 1] \hat{E}. \quad (11)$$

其中: $\tilde{E} = E - \hat{E}, \hat{v} = -\ddot{y}_d + [\lambda \quad 1] \hat{E}, u = \tau$.

选择控制输入

$$u = -K_v \hat{r} - \hat{W}^T S(X). \quad (12)$$

其中: $K_v = \text{diag}(k_{vi}) > 0$ 为控制增益矩阵, $\hat{W}^T S(X)$ 被用来逼近未知函数

$$F_G(X) = G_1^{-1}(x)(F_1(x) + \hat{v} + [\lambda \quad 1] \hat{E}) = W^{*T} S(X) + \varepsilon(X). \quad (13)$$

这里: $F_G(X) = [F_{G1}(X), \dots, F_{Gn}(X)]^T$, 神经网络的输入为 $X = [x_1^T, \hat{x}_2^T]^T \in \Omega \subset R^{2n}$ (Ω 为紧集), W^* 为理想的神经网络权值, $\|\varepsilon(X)\| < \varepsilon^*$ ($\varepsilon^* > 0$) 为神经网络逼近误差.

选择权值更新律为

$$\dot{\hat{W}} = \Gamma S(X) \hat{r} - \sigma \Gamma \|\hat{r}\| \hat{W}. \quad (14)$$

其中: $\Gamma = \Gamma^T > 0$ 为设计矩阵, $\sigma > 0$ 为一个小正值.

由被控系统(2), 滤波器跟踪误差(8), 控制器(12)以及神经网络权值更新律(14)构成的闭环系统可表示为

$$\begin{cases} \dot{r} = G_1(x)[-K_v \hat{r} - \hat{W}^T S(X) + \varepsilon], \\ \dot{\hat{W}} = \dot{\hat{W}} = \Gamma S(X) \hat{r} - \sigma \Gamma \|\hat{r}\| \hat{W}, \end{cases} \quad (15)$$

其中 $\tilde{W} = \hat{W} - W^*$.

定理 1 考虑由被控系统(2), 滤波器跟踪误差(8), 控制器(12)以及神经网络权值更新律(14)构成的闭环系统(15), 对于一个足够大的紧集 Ω , 选取适当的初始条件, 令 $\hat{W}(0) = 0$, 则有:

1) 闭环系统所有信号保持最终一致有界;

2) 存在一个有限时间 T_1 , 使得在控制器参数选择适当的情况下, 对于所有的 $t \geq T_1$, 状态跟踪误差 $[e^T, \dot{e}^T]^T$ 收敛到零的一个小邻域内.

证明 1) 选择 Lyapunov 函数

$$V_w = \hat{W}^T \Gamma^{-1} \hat{W} / 2, \quad (16)$$

对 V_w 求导, 得

$$\begin{aligned} \dot{V}_w &= \hat{W}^T \Gamma^{-1} \dot{\hat{W}} = \hat{W}^T (S(X) \hat{r} - \sigma \|\hat{r}\| \hat{W}) \leq \\ &\|\hat{W}\| \|S(X)\| \|\hat{r}\| - \sigma \|\hat{r}\| \|\hat{W}\|^2 = \\ &-\|\hat{W}\| \|\hat{r}\| (\sigma \|\hat{W}\| - \|S(X)\|). \end{aligned} \quad (17)$$

由式(17)可知, 只有当 $\|\hat{W}\| > s^*/\sigma$ 时, 才有 $\dot{V}_w < 0$, s^* 为 $\|S(X)\|$ 的上界^[16]. 由此得知 \hat{W} 是最终一致有界的, 且界为 $\|\hat{W}\| \leq s^*/\sigma$. 由 $\tilde{W} = \hat{W} - W^*$ 知, \tilde{W} 也

是最终一致有界的,其界为

$$\|\tilde{W}\| \leq \|W^*\| + \|\hat{W}\| \leq \|W^*\| + \frac{s^*}{\sigma} =: \tilde{W}^*. \quad (18)$$

取 Lyapunov 函数 $V_r = \frac{1}{2g_2} r^T r$, 对 V_r 求导, 得

$$\begin{aligned} \dot{V}_r &\leq r^T(-K_v \hat{r} - \tilde{W}^T S(X) + \varepsilon) = \\ &r^T(-K_v r + K_v(r - \hat{r}) - \tilde{W}^T S(X) + \varepsilon) = \\ &-r^T K_v r + r^T(K_v[\lambda, 1]\tilde{x} - \tilde{W}^T S(X) + \varepsilon) \leq \\ &-\lambda_{\min}(K_v)\|r\|^2 + \|r\|(k_v c_\lambda \|\tilde{x}\| + \tilde{W}^* s^* + \varepsilon^*). \quad (19) \end{aligned}$$

其中: $c_\lambda = \|[\lambda, 1]\|$, $k_v = \|K_v\|$.

利用式(8)和(10)可得

$$\tilde{E} = E - \hat{E} = x - \hat{x} = \tilde{x}, \quad (20)$$

令 $c = \tilde{W}^* s^* + \varepsilon^*$, 则有

$$\dot{V}_r \leq -\lambda_{\min}(K_v)\|r\| \left(\|r\| - c_\lambda O(\varepsilon_\lambda) - \frac{c}{k_v} \right). \quad (21)$$

这表明 r 是最终一致有界的,且界为

$$\|r\| \leq O(\varepsilon_\lambda) + \frac{c}{K_v}. \quad (22)$$

显然,增加控制增益 K_v 和减小 ε_λ 均可使界尽量小.

适当选取 λ 可保证 $r = \dot{e} + \lambda e$ 是稳定的. 又因为 r, q_d, \dot{q}_d 是有界的, 所以 x_1, x_2 是有界的. 对于所有 X , $S(X)$ 是有界的, 可知 u 也是有界的. 因此, 闭环系统所有信号都是最终一致有界的.

2) 选取 Lyapunov 函数

$$V_r = \frac{1}{2g_2} r^T r, \quad (23)$$

对 V_r 求导, 可得

$$\begin{aligned} \dot{V}_r &= \frac{1}{g_2} r^T \dot{r} \leq r^T(-K_v \hat{r} - \tilde{W}^T S(X) + \varepsilon) = \\ &-r^T K_v \hat{r} + r^T \varepsilon - r^T \tilde{W}^T S(X) = \\ &-r^T K_v r + r^T K_v(r - \hat{r}) + r^T \varepsilon - r^T \tilde{W}^T S(X) = \\ &-r^T K_v r + r^T K_v[\lambda, 1]\tilde{x} + r^T \varepsilon - r^T \tilde{W}^T S(X). \quad (24) \end{aligned}$$

令 $K_v = K_{v1} + 3K_{v2}$, 其中 $K_{v1}, K_{v2} > 0$, 利用三角不等式 $2\alpha^T \beta \leq \eta \alpha^T \alpha + (1/\eta)\beta^T \beta (\eta > 0)$, 有

$$r^T \varepsilon \leq \frac{\varepsilon^{*2}}{4\lambda_{\min}(K_{v2})} + \lambda_{\min}(K_{v2})\|r\|^2, \quad (25)$$

$$-r^T \tilde{W}^T S(X) \leq \frac{\tilde{W}^{*2} s^{*2}}{4\lambda_{\min}(K_{v2})} + \lambda_{\min}(K_{v2})\|r\|^2, \quad (26)$$

$$r^T K_v[\lambda, 1]\tilde{x} \leq \lambda_{\min}(K_{v2})\|r\|^2 + \frac{\bar{c}_\lambda^2}{4\lambda_{\min}(K_{v2})}. \quad (27)$$

其中: $\bar{c}_\lambda = \|K_v\|c_\lambda \|\tilde{x}\| = O(\varepsilon_\lambda)$, s^* 为 $\|S(X)\|$ 的上界, \tilde{W}^* 为 $\|\tilde{W}\|$ 的上界(由式(18)定义), 则式(24)可表示为

$$\dot{V}_r \leq -r^T K_{v1} r + \frac{\tilde{W}^{*2} s^{*2} + \varepsilon^{*2} + \bar{c}_\lambda^2}{4\lambda_{\min}(K_{v2})}. \quad (28)$$

令 $\delta = \frac{\tilde{W}^{*2} s^{*2} + \varepsilon^{*2} + \bar{c}_\lambda^2}{4\lambda_{\min}(K_{v2})}$, 显然只要选择足够大的 K_v , δ 就能尽量小, 于是有

$$\dot{V}_r \leq -r^T K_{v1} r + \delta \leq -2\lambda_{\min}(K_{v1})g_2 V_r + \delta. \quad (29)$$

令 $c = \lambda_{\min}(K_{v1})g_2$, $p = \delta/2c > 0$, 则式(29)满足

$$0 \leq V_r(t) < p + (V_r(0) - p) \exp(-2ct), \quad (30)$$

即

$$r^T r < 2g_2 p + 2g_2 V_r(0) \exp(-2ct). \quad (31)$$

由上可知, 给定 $\beta > \sqrt{2g_2 p} = \sqrt{\delta/\lambda_{\min}(K_{v1})}$, 存在一个由 δ 和 $\lambda_{\min}(K_{v1})$ 决定的有限时间 T_1 , 使得对于所有的 $t \geq T_1$, r 满足

$$\|r\| < \beta, \quad (32)$$

其中 β 为一个小残差集的大小. 选取足够大的 K_v , 对于所有的 $t \geq T_1$, 滤波器跟踪误差 r 能够很小, 即状态跟踪误差 $[e^T, \dot{e}^T]^T$ 能收敛到零的一个小邻域内^[7], 从而表明 $X(t)|_{t \geq T_1}$ 收敛到 $Y_d(t)|_{t \geq T_1}$. \square

注 1 定理 1 表明, 经过时间 T_1 后, 系统轨迹 $x(t) = [x_1^T(t), \hat{x}_2^T(t)]^T$ 将变成与 $Y_d(t) = [q_d^T(t), \dot{q}_d^T(t)]^T$ 一样的周期轨迹. 由于 $X = [x_1^T, \hat{x}_2^T]^T$ 被选为 RBF 神经网络的输入, 根据文献[13]中的定理 2.7, $S(X)$ 将满足部分 PE 条件, 即沿着跟踪轨迹 $X(t)|_{t \geq T_1}$, $S_\xi(X)$ 满足 PE 条件.

注 2 高增益观测器(3)可能出现瞬态峰值现象, 可以采用文献[15]的输入饱和方法来克服峰值现象. 因此, 在一个很短的瞬态周期中, 当状态估计出现峰值时, 控制器饱和即可以阻止峰值传递到控制对象中.

4 从自适应神经控制中学习

4.1 一类 LTV 系统的稳定性分析

一类线性时变(LTV)系统的指数稳定与非线性系统的确定学习息息相关. 为了实现含有未知仿射项的非线性系统的确定学习, 文献[17]将与之相关的线性时变系统转化为如下形式:

$$\begin{bmatrix} \dot{e}_1 \\ \dot{e}_2 \\ \dot{\eta} \end{bmatrix} = \begin{bmatrix} A(t) & 0 \\ & S^T(t) \\ 0 & -\Gamma S(t)G(t) & 0 \end{bmatrix} \begin{bmatrix} e_1 \\ e_2 \\ \eta \end{bmatrix}. \quad (33)$$

其中: $e_1 \in R^{(n-a)}$, $e_2 \in R^a$, $\eta \in R^p$, $A(\cdot) : [0, \infty) \rightarrow R^{n \times n}$, $S(\cdot) : [0, \infty) \rightarrow R^{p \times a}$, $G(\cdot) : [0, \infty) \rightarrow R^{a \times a}$, $\Gamma = \Gamma^T > 0$. 定义 $e := [e_1^T, e_2^T]^T$, $B(t) := [0, S(t)] \in R^{p \times n}$, $H(t) := \text{block-diag}\{I, G(t)\} \in R^{n \times n}$, diag 表示块对角阵, $C(t) := \Gamma B(t)H(t)$.

假设 1^[18] 存在一个 $\phi_M > 0$ 使得对于所有 $t \geq 0$, 下式成立:

$$\max \left\{ \|B(t)\|, \left\| \frac{dB(t)}{dt} \right\| \right\} \leq \phi_M. \quad (34)$$

假设 2^[18] 存在对称矩阵 $P(t)$ 和 $Q(t)$ 使得 $-Q(t) = \dot{P}(t) + P(t)A(t) + A^T(t)P(t)$; 且 $\exists p_m, q_m, p_M$ 和 $q_M > 0$ 使得 $p_m \leq P(t) \leq p_M$, $q_m \leq Q(t) \leq q_M$.

引理 1^[17] 考虑系统(7), 在紧集 Ω 内假设 1 和假设 2 满足, 如果 $S(t)$ 满足 PE 条件, 则系统(33) 在紧集 Ω 内是一致指数稳定的.

证明过程见文献[17], 这里省略.

4.2 从自适应神经控制中学习

利用高斯 RBF 神经网络的局部属性, 经有限时间 T_1 后, 沿着跟踪轨迹 $X(t)|_{t \geq T_1}$, 系统(15) 可表示为

$$\begin{cases} \dot{r} = G_1(x)[-K_v \hat{r} - \tilde{W}_\xi^T S_\xi(X) + \varepsilon_\xi], \\ \dot{\tilde{W}}_\xi = \dot{\tilde{W}}_\xi = \Gamma_\xi S_\xi(X) \hat{r} - \sigma \Gamma_\xi \|\hat{r}\| \tilde{W}_\xi; \end{cases} \quad (35)$$

$$\dot{\tilde{W}}_{\bar{\xi}} = \dot{\tilde{W}}_{\bar{\xi}} = \Gamma_{\bar{\xi}} S_{\bar{\xi}}(X) \hat{r} - \sigma \Gamma_{\bar{\xi}} \|\hat{r}\| \tilde{W}_{\bar{\xi}}. \quad (36)$$

其中: $S_\xi(X)$ 为 $S(X)$ 的子矢量, \tilde{W}_ξ 为相应的权值矢量; 下标 ξ 代表靠近轨迹 $X(t)|_{t \geq T_1}$ 的区域, 下标 $\bar{\xi}$ 代表远离轨迹 $X(t)|_{t \geq T_1}$ 的区域; ε_ξ 为局部逼近误差, 且 $\|\varepsilon_\xi\|$ 的值很小.

定理 2 考虑由被控系统(2)、滤波器跟踪误差(8)、控制器(12)以及权值更新律(14)构成的闭环系统(35), 对于一个足够大的紧集 Ω , 选取适当的初始条件和控制参数, 令神经网络初始权值 $\hat{W}(0) = 0$, 则有如下结论:

沿着跟踪轨迹 $X(t)|_{t \geq T_1}$, 部分神经网络权值估计 \hat{W}_ξ 收敛到其最优权值 W_ξ^* 附近的一个小邻域内, 闭环系统的未知动态 $F_G(X)$ 可被 $\hat{W}^T S(X)$ 和 $\bar{W}^T S(X)$ 局部准确逼近, 其中 \bar{W} 定义为

$$\bar{W} = \text{mean}_{t \in [t_a, t_b]} (\hat{W}(t)), \quad (37)$$

这里 $[t_a, t_b] (t_b > t_a > T)$ 代表 \hat{W} 收敛后(瞬态过程后)的一个时间段.

证明 令 $\theta = G_1^{-1}(x)r$, $\eta = \tilde{W}_\xi$, 式(35) 可转化为

$$\begin{cases} \dot{\theta} = [-K_v G_1(x) + \dot{G}_1^{-1}(x)G_1(x)]\theta - \eta^T S_\xi(X) + \varepsilon_\xi(X) + K_v(r - \hat{r}), \\ \dot{\eta} = \Gamma_\xi S_\xi(X)G_1(x)\theta - \sigma \Gamma_\xi \|\hat{r}\| \tilde{W}_\xi. \end{cases} \quad (38)$$

将式(38) 写成矩阵形式

$$\begin{bmatrix} \dot{\theta} \\ \dot{\eta} \end{bmatrix} = \begin{bmatrix} A(t) & B(t) \\ -C(t) & 0 \end{bmatrix} \begin{bmatrix} \theta \\ \eta \end{bmatrix} + \begin{bmatrix} \varepsilon_\xi + K_v(r - \hat{r}) \\ -\sigma \Gamma_\xi \|\hat{r}\| \tilde{W}_\xi \end{bmatrix}. \quad (39)$$

因 $\|K_v(r - \hat{r})\| \leq \lambda_{\max}(K_v)c_\lambda O(\varepsilon_\lambda) = O(\varepsilon_\lambda)$, 故 $\|\varepsilon_\xi + K_v(r - \hat{r})\|$ 和 $\|\sigma \Gamma_\xi \|\hat{r}\| \tilde{W}_\xi\|$ 很小, 系统(39) 可看成是一类扰动系统^[7]. 其中

$$A(t) = [-K_v G_1 + \dot{G}_1^{-1} G_1], \quad (40)$$

$$B(t) = [-S_\xi^T(X)], \quad (41)$$

$$C(t) = [-\Gamma_\xi S_\xi(X)G_1]. \quad (42)$$

选取 $P(t) = [G_1]$, 则有

$$\dot{P} + PA + A^T P = [-2G_1(K_v - \dot{G}_1^{-1})G_1 + \dot{G}_1]. \quad (43)$$

假设 1 很容易满足. 据性质 3 和 $\dot{G}_1(\cdot), \dot{G}_1^{-1}(\cdot)$ 的有界性, 可选择 K_v 使得 $2G_1(K_v - \dot{G}_1^{-1})G_1 - \dot{G}_1$ 为严格正定的, 故 $\dot{P} + A^T P + PA$ 的负定性得到保证, 可见假设 2 也能够满足.

经过时间 T_1 后, 神经网络的输入 $X(t)$ 跟踪上周期轨迹. 根据文献[13]中的定理 2.7, $S(X)$ 将满足部分 PE 条件, 即沿着跟踪轨迹 $X(t)|_{t \geq T_1}$, $S_\xi(X)$ 满足 PE 条件. 由引理 1 可知, 系统(39) 的正常系统一致指数稳定. 对于扰动系统(39), 使用文献[19]中的引理 4.6, 参数误差 $\eta = \tilde{W}_\xi$ 在有限时间 $T (T > T_1)$ 内指数收敛到零附近的一个小邻域内. 邻域的大小由神经网络的逼近能力和状态跟踪误差决定.

\tilde{W}_ξ 收敛到 W_ξ^* 附近的小邻域内是指, 沿着跟踪轨迹 $X(t)|_{t \geq T}$, 未知闭环系统动态 $F_G(X)$ 能够用递归子矢量 $S_\xi(X)$ 表示, 且误差很小, 即

$$F_G(X) = \hat{W}_\xi^T S_\xi(X) + \varepsilon_\xi, \quad (44)$$

其中 $\|\varepsilon_\xi\| - \varepsilon^*$ 很小. 根据 $\bar{W} = \text{mean}_{t \in [t_a, t_b]} (\hat{W}(t))$ 选取 \bar{W} , 由 RBF 神经网络的局部属性, 式(44) 可表示为

$$F_G(X) = \bar{W}_\xi^T S_\xi(X) + \bar{\varepsilon}_\xi. \quad (45)$$

其中: $\bar{W}_\xi^T = [\bar{w}_{j_1}, \dots, \bar{w}_{j_\xi}]^T$ 为 \bar{W} 的子矢量, $\bar{\varepsilon}_\xi$ 为闭环系统动态由 $\bar{W}_\xi^T S_\xi(X)$ 逼近时的误差, 在瞬态过程结束后, $\|\bar{\varepsilon}_\xi\| - \|\varepsilon_\xi\|$ 很小.

由高斯 RBF 神经网络的局部属性, 沿着跟踪轨迹 $X(t)|_{t \geq T}$, S_ξ 和 $\bar{W}_\xi^T S_\xi(X)$ 都非常小, 这意味着沿着跟踪轨迹 $X(t)|_{t \geq T}$, 整个 RBF 神经网络 $\bar{W}^T S(X)$ 能够逼近未知闭环系统动态 $F_G(X)$, 即

$$F_G(X) = \bar{W}_\xi^T S_\xi(X) + \bar{W}_\xi^T S_\xi(X) + \varepsilon_1 = \bar{W}^T S(X) + \varepsilon_2, \quad (46)$$

其中 $\|\varepsilon_2\| - \|\bar{\varepsilon}_\xi\|$ 很小. 可知沿跟踪轨迹 $X(t)|_{t \geq T}$, $\bar{W}^T S(X)$ 能够逼近未知闭环系统动态 $F_G(X)$. \square

注 3 对于机器人, $M(q)$ 的元素仅为常数和 q 的三角函数的线性组合, 因此, $\dot{M}(q)$ 的元素仅为 \dot{q} 与 q 的三角函数的组合, 而 $[q, \dot{q}] \in \Omega$, 故 $\dot{M}(q)$ 是有界的. 根据 $\dot{M}(q)\dot{M}^{-1}(q) = I$, $\dot{M}^{-1}(q)$ 也是有界的, 故 $\dot{G}_1(\cdot)$ 和 $\dot{G}_1^{-1}(\cdot)$ 均是有界的.

5 仿真研究

两连杆平面机器人, 其动态方程可表示为^[2]

$$M(q)\ddot{q} + V_m(q, \dot{q})\dot{q} + F(\dot{q}) + G(q) = \tau, \quad (47)$$

$$M(q) = \begin{bmatrix} l_2^2 m_2 + l_1^2 (m_1 + m_2) + 2l_1 l_2 m_2 \cos(q_2) & \rightarrow \\ & l_2^2 m_2 + l_1 l_2 m_2 \cos(q_2) \\ \leftarrow & l_2^2 m_2 + l_1 l_2 m_2 \cos(q_2) \\ & l_2^2 m_2 \end{bmatrix},$$

$$V_m(q, \dot{q})\dot{q} = \begin{bmatrix} -2l_1l_2m_2 \sin(q_2)(\dot{q}_1\dot{q}_2 + 0.5\dot{q}_2^2) \\ l_1l_2m_2 \sin(q_2)\dot{q}_1^2 \end{bmatrix},$$

$$G(q) = \begin{bmatrix} l_1(m_1 + m_2)g \cos(q_1) + l_2m_2g \cos(q_1 + q_2) \\ l_2m_2g \cos(q_1 + q_2) \end{bmatrix}.$$

其中: q_1 和 q_2 为关节 1 和关节 2 的角度; m_1 和 m_2 为连杆 1 和连杆 2 的质量; l_1 和 l_2 为连杆 1 和连杆 2 的长度; g 为重力加速度. 在仿真中摩擦力可表示为^[20]

$$F(q) = [12\dot{q}_1 + 0.5\text{sgn}(\dot{q}_1) \quad 12\dot{q}_2 + 0.5\text{sgn}(\dot{q}_2)]^T. \quad (48)$$

参考轨迹设为 $q_d(t) = [0.8 \sin t, 0.8 \cos t]^T$. 两连杆平面机器人的系统参数为^[2]: $l_1 = l_2 = 1.0 \text{ m}$, $m_1 = 0.8 \text{ kg}$, $m_2 = 2.3 \text{ kg}$, $g = 9.8 \text{ m/s}^2$.

高增益观测器的参数选为: $b_1 = 4$, $\varepsilon_\lambda = 0.001$. 控制器参数选为: 神经网络节点数 $N = 5 \times 5 \times 5 \times 5 = 625$, 均匀分布在 $[-1.5 \ 1.5] \times [-1.5 \ 1.5] \times [-1.5 \ 1.5] \times [-1.5 \ 1.5]$ 范围内, 宽度 $\eta = 0.7$, $\Gamma = \text{diag}(10)$, $K_v = \text{diag}(50)$, $\lambda = 20$, $\sigma = 0.0001$, 初始权值 $\hat{W}(0) = 0$. 初始状态 $X(0) = [0, 0.65; 0, 0]$. 仿真结果如图 1~图 4 所示.

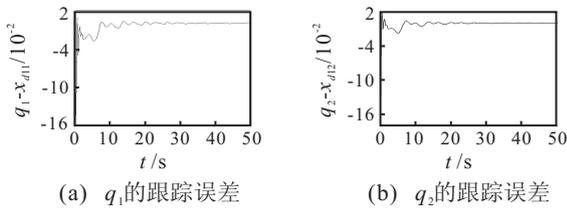


图 1 使用 $\hat{W}^T S(X)$ 时的状态跟踪误差

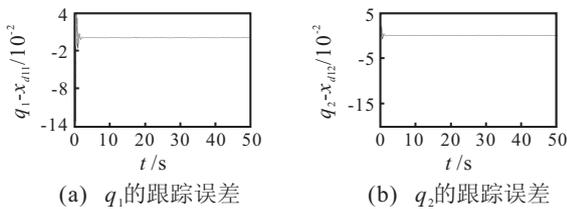


图 2 使用 $\bar{W}^T S(X)$ 时的状态跟踪误差

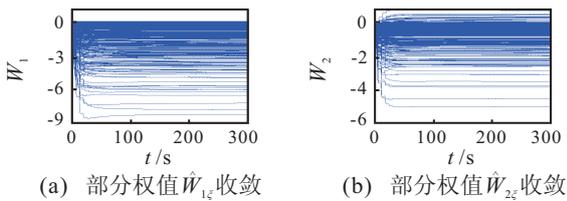


图 3 部分权值 \hat{W}_ξ 收敛

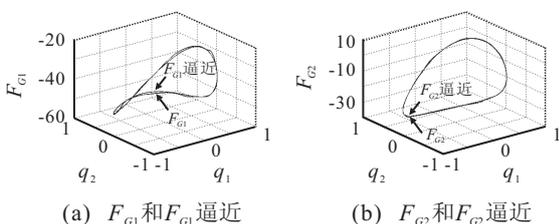


图 4 函数和使用 $\bar{W}^T S(X)$ 的函数逼近

从仿真结果可以看出, 本文提出的控制算法不仅成功地驱动仿真系统的状态收敛到参考状态附近很小的邻域内, 而且在跟踪控制过程中实现了未知闭环系统动态的准确逼近, 即确定学习. 使用学过的知识(以常值神经网络权值储存)改进了系统的控制性能.

6 结 论

本文针对系统参数完全未知的机器人, 基于确定学习理论设计了输出反馈自适应神经控制器. 该控制器在对周期轨迹进行稳定的跟踪控制中, 实现了部分神经网络权值的收敛和未知闭环系统动态的局部准确逼近, 即确定学习. 学过的知识以时不变且空间分布的方式表达, 以常值神经网络权值的方式存储, 可用来改进系统的控制性能, 也可应用于后续相同或相似的控制任务中, 节省了时间和能量.

参考文献(References)

- [1] Miyamoto H, Kawato M, Setoyama T, et al. Feedback error learning neural networks for trajectory control of a robotic manipulator[J]. Neural Network, 1988, 1(3): 251-265.
- [2] Frank L Lewis, Kai Liu, Aydin Yesildirek. Neural net robot controller with guaranteed tracking performance[J]. IEEE Trans on Neural Network, 1995, 6(3): 703-715.
- [3] Tsuji T, Tanaka Y. On-line learning of robot arm impedance using neural networks[J]. Robotics and Autonomous Systems, 2005, 52(4): 257-271.
- [4] Xu Dong, Zhao Dongbin, Yi Jianqiang, et al. Trajectory tracking control of omnidirectional wheeled mobile manipulators: Robust neural network-based sliding mode approach[J]. IEEE Trans on Systems, Man, and Cybernetics: B, 2009, 39(3): 788-799.
- [5] 牛玉刚, 杨成梧, 陈雪如. 基于神经网络的不确定机器人自适应滑模控制[J]. 控制与决策, 2001, 16(1): 79-82. (Niu Y G, Yang C W, Chen X R. Adaptive sliding mode control for robot manipulators based on neural network[J]. Control and Decision, 2001, 16(1): 79-82.)
- [6] 俞建成, 李强, 张艾群, 等. 水下机器人的神经网络自适应控制[J]. 控制理论与应用, 2008, 25(1): 9-13. (Yu J C, Li Q, Zhang A Q, et al. Neural network adaptive control for underwater vehicles[J]. Control Theory & Applications, 2008, 25(1): 9-13.)
- [7] Slotine J J, Li W. Applied nonlinear control[M]. Englewood Cliffs: Prentice Hall, 1991: 311-326.
- [8] Nicosia S, Tomei P. Robot control by using only joint position measurements[J]. IEEE Trans on Automatic Control, 1990, 35(9): 1058-1061.