

移动机器人的确定学习与控制

周勇¹, 王聪¹, 顾武军¹, 曾玮^{1,2}

(1. 华南理工大学自动化科学与工程学院, 广东广州 510640; 2. 龙岩学院物理与机电工程学院, 福建龙岩 364000)

摘要: 利用确定学习, 提出了移动机器人的学习控制策略. 在闭环控制过程中, 该控制器可以学习到未知控制系统的动态, 并将学到的动态作为经验知识以常值网络权值的形式储存. 在下次重复相同的控制任务时, 控制器可以调用以往所学到的动态知识用于控制并获得更好的控制性能. 该策略避免了耗时的神经网络重新训练过程, 使得移动机器人具有真正意义上的从经历中获取知识, 存储知识, 并将学到的知识再利用的智能控制能力.

关键词: 移动机器人; 确定学习; 径向基函数(RBF)神经网络; 学习控制

中图分类号: TP273 **文献标识码:** A

Deterministic learning and control of mobile robots

ZHOU Yong¹, WANG Cong¹, GU Wu-jun¹, ZENG Wei^{1,2}

(1. College of Automation Science and Technology, South China University of Technology, Guangzhou Guangdong 510640, China;
2. College of Physics and Mechanical and Electrical Engineering, Longyan University, Longyan Fujian 364000)

Abstract: By making use of the recent result of deterministic learning theory, we present a learning control scheme for mobile robots. In the process of closed-loop control, the unknown system dynamics is learned and memorized as experience knowledge in the format of constant neural weights. When repeating the same control tasks, the controller may invoke the previously learned knowledge in the new control process to achieve a better performance. With this scheme, the mobile robots can learn and memorize the knowledge of dynamics as experience for later use, exonerating from the repetitive training phase.

Key words: mobile robots; deterministic learning; radial basis function (RBF) neural-network; learning control

1 引言(Introduction)

移动机器人有着广泛的应用, 作为具有不确定性和非完整约束的多输入多输出系统, 对其跟踪控制问题的研究也吸引了很多人的关注, 人们利用各类控制方法对其进行了研究, 如反步法^[1-3]、滑模控制^[4-5]、智能控制^[6-8], 等. 作为智能控制的神经网络具有通用的逼近能力, 很多人对于参数未知并且存在动态不确定性的移动机器人控制问题进行了基于神经网络的研究, 如文献[6]中作者针对移动机器人的运动学和动力学特性, 以及存在的高度非线性、不确定性和外部干扰, 提出了一种基于神经网络的鲁棒控制方法, 该控制策略能够对系统中的未知不确定性和干扰进行补偿. 文献[8]中作者利用反步法提出了神经网络计算力矩控制器与运动学控制器结合的控制结构, 使得机器人能实现3种导航控制目标. 但是在这些方法中, 神经网络只是单纯地作为一个逼近工具而已, 每次即便重复相同的控制任务都要进行神经网络的重新训练, 对于系统未知动态的学习问题尚未研究.

从稳定的自适应控制过程中学习系统动态知识包含着神经网络估计权值是否收敛到理想值或者最优值的问题, 而这需要满足持续激励(PE)条件才能实现. 但通常情况下要满足PE条件是相当困难的事情. 确定学习文献[9]对这一问题提供了简单而有效的解决措施, 即通过合理设计的神经网络控制器, 在跟踪周期轨迹的过程中, 可以保证满足部分PE条件, 从而分析得到神经网络权值的部分收敛, 最终未知系统动态可以由一个常值神经网络来准确逼近^[10].

利用确定学习, 本文提出的控制策略可以在跟踪周期参考轨迹控制过程中使得神经网络学习到移动机器人未知的系统动态, 并以常值网络权值的形式存储, 在下次重复相同的任务时即可调用学习到的系统动态用于控制, 获得更好的控制性能, 同时避免了耗时的网络重新训练过程, 使得移动机器人具有根据经验学习系统动态知识, 并且将学到的知识再利用的能力.

2 模型(Model)

典型的移动机器人如图1所示, 它有3个自由度,

用下面的位姿向量描述: $q = [x \ y \ \theta]^T$, x_c, y_c 表示机器人中心点 P 在笛卡尔坐标系中的坐标, x, y 为移动机器人自身坐标系, θ 表示前进方向, 其值域为 $[-\pi, +\pi]$. 可由如下具有非完整约束的广义力学系统来描述^[8].




图1 移动机器人
Fig. 1 Mobile robot

动力学方程为

$$M(q)\ddot{q} + C(q, \dot{q})\dot{q} + F(\dot{q}) + G(q) + \tau_d = B(q)\tau - A^T(q)\lambda. \quad (1)$$

参数如下:

$$M(q) = \begin{bmatrix} m & 0 & 0 \\ 0 & m & 0 \\ 0 & 0 & I \end{bmatrix}, \quad C(q, \dot{q}) = \begin{bmatrix} 0 & 0 & 0 \\ 0 & 0 & 0 \\ 0 & 0 & 0 \end{bmatrix},$$

$$B(q) = \frac{1}{r} \begin{bmatrix} \cos \theta & \cos \theta \\ \sin \theta & \sin \theta \\ R & R \end{bmatrix}, \quad A^T(q) = \begin{bmatrix} -\sin \theta \\ \cos \theta \\ 0 \end{bmatrix},$$

$M(q) \in \mathbb{R}^{n \times n}$ 为对称正定惯性矩阵, $C(q, \dot{q}) \in \mathbb{R}^{n \times n}$ 为哥氏力矩阵, $G(q) \in \mathbb{R}^n$ 为重力矩阵, 对于平面移动机器人 $G(q) = 0$, $F(\dot{q}) \in \mathbb{R}^n$ 为摩擦力, $A(q) \in \mathbb{R}^{m \times n}$ 为约束矩阵, $\gamma \in \mathbb{R}^{m \times 1}$ 为约束力, τ_d 为有界的未知扰动, $B(q) \in n^{n \times r}$ 为输入变换矩阵, $\tau \in n^{n \times r}$ 为控制输入向量, m 为移动机器人的质量; I 为机器人的瞬时转动惯量; r 为轮子半径; $2R$ 为机器人两驱动轮之间的距离. 由于机器人只能在与驱动轮轴垂直方向上移动而引入的非完整约束可用如下方程表示: $\dot{y}\cos\theta - \dot{x}\sin\theta = 0$, 即

$$A(q)\dot{q} = 0. \quad (2)$$

通过引入适当向量可把式(1)(2)联系起来描述机器人的运动状态. 选取一系列满秩矩阵 $H(q)$ 作为 $A(q)$ 零空间的一组基, 即有: $A(q)H(q) = 0$, 则笛卡尔坐标系下的速度 \dot{q} 可由下式描述:

$$\dot{q} = H(q)V(t). \quad (3)$$

其中: $V = [\nu \ \omega]^T$ 表示线速度和角速度组成的向量.

根据 $A(q)$ 的表达式, 可得到

$$H(q) = \begin{bmatrix} \cos \theta & 0 \\ \sin \theta & 0 \\ 0 & 1 \end{bmatrix}. \quad (4)$$

对式(3)求导后代入式(1), 等式两边同乘以 H^T , 可以得到

$$H^T M H \dot{V} + H^T (M \dot{H} + C H) V + H^T F + H^T G + H^T \tau_d = H^T B \tau. \quad (5)$$

约束矩阵 $A(q)$ λ 可被消掉. 为了方便讨论, 对上式做一替换:

$$\bar{M}(q)\dot{V} + \bar{C}V + \bar{F} + \bar{G} + \bar{\tau}_d = \bar{\tau}, \quad (6)$$

其中:

$$\bar{M} = H^T M H = \begin{bmatrix} m & 0 \\ 0 & I \end{bmatrix},$$

$$\bar{C} = H^T (M \dot{H} + C H) = 0,$$

$$\bar{F} = H^T F, \bar{G} = H^T G,$$

$$\bar{\tau}_d = H^T \tau_d, \bar{\tau} = H^T B \tau.$$

3 确定学习和问题描述(Deterministic learning and problem formulation)

3.1 确定学习要素^[9](Elements of deterministic learning)

1) 径向基函数(RBF)网络.

RBF网络具有线性参数化和局部学习的特点, 即

$$h(X) = W^{*T} S(X) + \varepsilon = W_\zeta^{*T} S_\zeta(X) + \varepsilon_\zeta. \quad (7)$$

其中: W^* 和 ε 分别为理想权值和逼近误差, S_ζ 为 S 的子向量, ζ 表示网络输入 X 的局部区域, 并且 $\|\varepsilon\|$, $\|\varepsilon_\zeta\|$, $\|\varepsilon_\zeta - \varepsilon\|$ 均为很小的值.

2) 部分持续激励(PE)条件.

反馈闭环控制系统中的PE条件通过如下几个步骤得到满足:

第1步 使用自适应神经网络控制使得系统状态跟踪给定周期参考轨迹 ϕ_d , 从而使得网络输入亦成周期信号 ϕ_ζ ;

第2步 根据跟踪收敛和局部RBF网络的特性, 确定学习证明了沿着周期轨迹 ϕ_ζ 的局部区域, 径向基函数向量 $S(X)$ 满足部分PE条件, 即 $S_\zeta(X)$ 满足PE条件.

3) 对控制系统动态的局部准确学习.

由于部分持续激励条件的满足, 可得到网络权重 W_ζ 收敛到理想值 W_ζ^* 的小领域内, 选择

$$\bar{W} = \text{mean}_{t \in [t_a, t_b]} \hat{W}(t), \quad (8)$$

其中: $[t_a, t_b]$ 表示收敛后的一个时间段. 从而, 沿着

周期轨迹 ϕ_c , 对系统动态的局部逼近可由下式获得:

$$\begin{aligned} h(X) &= W_c^{*T} S_c(X) + \varepsilon_c = \\ \hat{W}^T S(X) + \varepsilon_1 &= \bar{W}^T S(X) + \varepsilon_2. \end{aligned} \quad (9)$$

3.2 问题描述(Problem formulation)

对于给定参考轨迹 $q_r(t) = [x_r(t) \ y_r(t) \ \theta_r(t)]^T$ 及参考速度 $V_r = [\nu_r \ \omega_r]^T$, 对系统(6)设计控制器 $\bar{\tau}$ 使得

$$\lim_{t \rightarrow \infty} [q(t) - q_r(t)] = 0, \quad \lim_{t \rightarrow \infty} [V(t) - V_r(t)] = 0,$$

并且在控制过程中使得控制器能学到系统动态, 以网络常值的形式存储, 并且可以重新使用.

在分析对控制系统动态的学习之前先做如下一个假设:

假设 1 摩擦力项 $F(q)$ 为连续函数, 从而可用神经网络逼近: 在学习阶段干扰项 $\bar{\tau}_d$ 为比较小的值.

4 对控制系统动态确定学习(Deterministic learning of control system dynamics)

首先, 在移动机器人自身坐标系 (X_c, Y_c) 内定义位姿跟踪误差:

$$e = \begin{bmatrix} e_1 \\ e_2 \\ e_3 \end{bmatrix} = \begin{bmatrix} \cos \theta & \sin \theta & 0 \\ -\sin \theta & \cos \theta & 0 \\ 0 & 0 & 1 \end{bmatrix} \begin{bmatrix} x_r - x \\ y_r - y \\ \theta_r - \theta \end{bmatrix}. \quad (10)$$

对其求导有

$$\begin{cases} \dot{e}_1 = e_2 \omega - \nu + \nu_r \cos e_3, \\ \dot{e}_2 = -e_1 \omega + \nu_r \sin e_3, \\ \dot{e}_3 = \omega_r - \omega. \end{cases} \quad (11)$$

文献[3]给出了一个虚拟速度控制器:

$$V_c = \begin{bmatrix} \nu_r \cos e_3 + k_1 e_1 \\ \omega_r + k_2 \nu_r e_2 + k_3 \sin e_3 \end{bmatrix}, \quad (12)$$

其中: k_1, k_2, k_3 为控制参数, 使得系统(11)中的状态 e_1, e_2, e_3 渐近收敛. 利用反步设计法, 定义实际速度与虚拟速度控制器的误差:

$$Z = \begin{bmatrix} z_1 \\ z_2 \end{bmatrix} = V_c - V = \begin{bmatrix} \nu_c - \nu \\ \omega_c - \omega \end{bmatrix}. \quad (13)$$

将虚拟量代入式(11), 则有

$$\begin{cases} \dot{e}_1 = e_2 \omega - k_1 e_1 + z_1, \\ \dot{e}_2 = -e_1 \omega + \nu_r \sin e_3, \\ \dot{e}_3 = -k_2 \nu_r e_2 - k_3 \sin e_3 + z_2. \end{cases} \quad (14)$$

考虑以下候选Lyapunov函数:

$$V_1 = \frac{1}{2} e_1^2 + \frac{1}{2} e_2^2 + \frac{1}{k_2} (1 - \cos e_3), \quad (15)$$

求导可得到

$$\dot{V}_1 = -k_1 e_1^2 - k_3/k_2 \sin e_3^2 + z_1 e_1 +$$

$$1/k_2 z_2 \sin e_3, \quad (16)$$

其中的多出项 $z_1 e_1 + 1/k_2 z_2 \sin e_3$ 可在下一步设计中抵消. 接着进行反步控制的第2步设计, 由式(6)(13)得到

$$\bar{M} \dot{Z} = \bar{M} \dot{V}_c + \bar{F} + \bar{G} + \bar{\tau}_d - \bar{\tau}. \quad (17)$$

考虑候选Lyapunov函数:

$$V_2 = V_1 + 1/2 Z^T \bar{M} Z,$$

易求得理想的控制输入:

$$\begin{aligned} \bar{\tau}^* &= cZ + \begin{bmatrix} e_1 \\ \sin e_3/k_2 \end{bmatrix} + \bar{M} \dot{V}_c + \\ &\bar{C} + \bar{F} + \bar{G} + \bar{\tau}_d. \end{aligned} \quad (18)$$

由于控制系统动态

$$h(X) = \begin{bmatrix} h_1(X) \\ h_2(X) \end{bmatrix} = \bar{M} \dot{V}_c + \bar{C} + \bar{F} + \bar{G} \quad (19)$$

未知, 因此用一个神经网络来逼近, 即

$$h(X) = W^{*T} S(X) + \varepsilon. \quad (20)$$

对于给定的系统(6), 实际的控制输入如下:

$$\bar{\tau} = cZ + \begin{bmatrix} e_1 \\ \sin e_3/k_2 \end{bmatrix} + \hat{W}^T S(X) + \tau_n, \quad (21)$$

其中: \hat{W} 为 W^* 的估计值, 选取自适应率

$$\dot{\hat{W}} = \Gamma S(X) Z^T, \quad (22)$$

$\tau_n = [\tau_{n1} \ \tau_{n2}]^T$ 为滑模项, 为了防止高频振颤, 对滑模项引入如下边界层控制^[4]:

$$\tau_{ni}(z_i) = \begin{cases} \gamma \operatorname{sgn} z_i, & \text{如果 } z_i > \eta_i, \\ \gamma \frac{z_i}{\eta_i}, & \text{如果 } z_i \leq \eta_i. \end{cases} \quad (23)$$

其中: $i = 1, 2$. η_i 为边界层阈值, 通常为很小的正实数, 一般地, $\eta_i \ll \gamma$. 选取Lyapunov函数:

$$V_3 = V_2 + \frac{1}{2} \operatorname{tr}(\tilde{W}^T \Gamma^{-1} \tilde{W}),$$

其中 $\tilde{W} = \hat{W} - W^*$. 求导可得

$$\begin{aligned} \dot{V}_3 &= \\ &-k_1 e_1^2 - k_3/k_2 \sin e_3^2 - cZ^T Z + Z^T (\varepsilon + \\ &\bar{\tau}_d - \gamma \operatorname{sgn} Z) \leq -cZ^T Z \leq 0, \end{aligned} \quad (24)$$

其中 $\gamma > \|\varepsilon + \bar{\tau}_d\|$. 根据不变集定理易知 Z 渐近收敛到零, 由于边界层的存在, 则收敛到零的小领域内, 从而实际速度控制收敛到理想虚拟速度控制器的边界层内. 至此完成了控制器设计和稳定性分析.

令 $E = [e_4 \ e_5]^T = \bar{M} Z$, 将控制器(21)代入式(17)得到

$$\dot{E} = -c\bar{M}^{-1} E - \begin{bmatrix} e_1 \\ \sin e_3/k_2 \end{bmatrix} - \tilde{W}^T S_c(X) -$$

$$\begin{aligned} & \tilde{W}_\zeta^T S_\zeta(X) + \varepsilon + \bar{\tau}_d - \gamma \operatorname{sgn} Z = \\ & -c\bar{M}^{-1}E - \begin{bmatrix} e_1 \\ \sin e_3/k_2 \end{bmatrix} - \tilde{W}_\zeta^T S_\zeta(X) + \\ & \varepsilon_\zeta + \bar{\tau}_d - \gamma \operatorname{sgn} Z. \end{aligned} \quad (25)$$

其中: $\tilde{W}^T S(X) = \tilde{W}_\zeta^T S_\zeta(X) + \tilde{W}_\zeta^T S_\zeta(X)$, $\varepsilon_\zeta = \varepsilon - \tilde{W}_\zeta^T S_\zeta(X)$, $S_\zeta(X)$ 是 $S(X)$ 的子向量, \tilde{W}_ζ 是相应的权值子向量, ζ 表示远离网络周期输入轨迹的区域. 根据RBF网络的局部特性可知, $\tilde{W}_\zeta^T S_\zeta(X)$ 为很小的值, 从而 ε_ζ 亦很小. 令 $W_\zeta = [W_{1\zeta} \ W_{2\zeta}]$, 将式(22)(25)写成如下带干扰项的线性时变系统:

$$\begin{bmatrix} \dot{e}_4 \\ \dot{e}_5 \\ \dot{\tilde{W}}_{1\zeta} \\ \dot{\tilde{W}}_{2\zeta} \end{bmatrix} = \begin{bmatrix} A & B^T \\ C & 0 \end{bmatrix} \begin{bmatrix} e_4 \\ e_5 \\ \tilde{W}_{1\zeta} \\ \tilde{W}_{2\zeta} \end{bmatrix} + d. \quad (26)$$

其中:

$$\begin{aligned} A &= \begin{bmatrix} -c/m & 0 \\ 0 & 1/I \end{bmatrix}, \quad B^T = \begin{bmatrix} S_\zeta^T(X) & 0 \\ 0 & S_\zeta^T(X) \end{bmatrix}, \\ C &= \begin{bmatrix} \Gamma S_\zeta(X)/m & 0 \\ 0 & \Gamma S_\zeta(X)/I \end{bmatrix}, \\ d &= \begin{bmatrix} -e_1 + \varepsilon_{\zeta 1} + \bar{\tau}_{d1} + \gamma \operatorname{sgn} z_1 \\ -\sin e_3/k_2 + \varepsilon_{\zeta 2} + \bar{\tau}_{d2} + \gamma \operatorname{sgn} z_2 \\ 0 \\ 0 \end{bmatrix}. \end{aligned}$$

根据文献[11]中定理1, 可知对于式(16)的标称部分, S_ζ 的持续激励条件可使网络权值指数收敛, 对于带干扰项 d 的情况, 根据假设1和文献[12]中的引理4.6可知当 d 为很小值时, 网络权值 W_ζ 收敛到理想值 W_ζ^* 的小邻域内, 从而根据确定学习, 系统动态可用如下常值网络表示:

$$\begin{aligned} h(X) &= W_\zeta^{*T} S_\zeta(X) + \varepsilon_\zeta = \\ & \hat{W}_\zeta^T S_\zeta(X) - \tilde{W}_\zeta^T S_\zeta(X) + \varepsilon_\zeta = \\ & \hat{W}_\zeta^T S_\zeta(X) + \hat{W}_\zeta^T S_\zeta(X) + \varepsilon_1 = \\ & \bar{W}_\zeta^T S_\zeta(X) + \bar{W}_\zeta^T S_\zeta(X) + \varepsilon_2 = \\ & \bar{W}^T S(X) + \varepsilon_2, \end{aligned} \quad (27)$$

其中 $\|\varepsilon_1 - \varepsilon_\zeta\|$, $\|\varepsilon_2 - \varepsilon_\zeta\|$ 均是很小的值. 在下次重复相同的控制任务时, 控制器即可根据以往的学习经验调用所学知识, 轻松实现控制, 并且由于少了重新学习的过程可以获得更好的控制性能. 学习控制所用控制器如下:

$$\bar{\tau} = cZ + \begin{bmatrix} e_1 \\ \sin e_3/k_2 \end{bmatrix} + \bar{W}^T S(X) + \tau_n. \quad (28)$$

稳定性证明类似于上文的分析, 为了简洁此处省略.

5 仿真研究(Simulation study)

为了验证所提学习控制的有效性, 笔者进行了仿真研究, 参考轨迹和参考速度分别为

$$\begin{cases} x_r(t) = \cos t, \\ y_r(t) = 0.6 \sin t, \\ \theta_r(t) = \tan^{-1}(\dot{y}_r/\dot{x}_r), \end{cases} \quad \begin{cases} \nu_r(t) = \sqrt{\dot{x}_r^2 + \dot{y}_r^2}, \\ \omega_r(t) = \frac{\dot{y}_r \dot{x}_r - \dot{x}_r \dot{y}_r}{\dot{x}_r^2 + \dot{y}_r^2}. \end{cases}$$

所选参数如下:

$$\begin{aligned} m &= 10 \text{ kg}, \quad I = 5 \text{ kg} \cdot \text{m}^2, \quad R = 0.15 \text{ m}, \\ r &= 0.05 \text{ m}, \quad k_1 = 10, \quad k_2 = 5, \quad k_3 = 4, \quad c = 10. \end{aligned}$$

网络节点数 $N = 1680$, 网络权值初值 $W_1 = \text{zeros}(N, 1)$, $W_2 = \text{zeros}(N, 1)$, 机器人中心点初值 $x(0) = 1.2$, $y(0) = 0$, $\theta(0) = 0$, $\nu(0) = 0$, $\omega(0) = 0$. 网络输入 $X = [\dot{V}_c^T \ \nu \ \omega \ \theta]^T$, 中心点均匀分布在如下网格上: $[-0.6; 0.4; 0.6]$, $[-1.5; 0.75; 1.5]$, $[0.4; 0.4; 1.2]$, $[0.4; 0.5; 1.9]$, $[-1.8; 0.6; 1.8]$. 在学习阶段假设干扰为 $\bar{\tau}_d = 0.1 * [\sin t \ \cos t]$, $\gamma = 0.3$; 学到的知识再利用阶段 $\bar{\tau}_d = 1 * [\sin t \ \cos t]$, $\gamma = 1.5$. 重力矩阵 $G = 0$, 摩擦力项为

$$\bar{F} = \begin{cases} 0.06m(\nu^2 + 2\omega^2)|\theta|, \\ 0.06m(2\nu^2 + \omega^2)|\theta|. \end{cases} \quad (29)$$

仿真结果如图2-10所示, 图2闭环控制轨迹收敛到参考轨迹的小邻域里, 图3的学习控制速度跟踪轨迹几乎跟踪参考轨迹. 比较图2和图3, 在闭环控制速度跟踪误差方面, 利用学习控制的图3明显比图2收敛的更快, 在最开始的时候就能很好的跟踪参考轨迹. 神经网络权值收敛情况如图4所示. 从图中可以看出, 神经网络权值保持有界且部分权值收敛到最优值. 从图5和图6可以看出, 学习控制的位姿误差明显比闭环控制的时候要小, 并且在前期误差就能很快收敛到零. 图7和图8表明了系统的动力学学习效果, 图9表明系统的动力学学习误差收敛到一个小邻域内, 图10则可以看出使用学习控制能够很好的跟踪参考轨迹. 所以利用学到的动态知识重新用于控制可获得明显的性能改善.




图2 闭环控制速度跟踪误差

Fig. 2 Tracking error by using close-loop control




图 3 使用学习控制的跟踪误差

Fig. 3 Tracking error by using learning control




图 4 网络权值W1的部分收敛

Fig. 4 Partial converge of network weights of W_1




图 5 闭环控制的位姿误差

Fig. 5 Position error by using close-loop control




图 6 使用学习控制的位姿误差

Fig. 6 Position error by using learning control




图 7 动力学 $h_1(X)$ 学习效果

Fig. 7 Learning effect of dynamics of $h_1(X)$




图 8 动力学 $h_2(X)$ 学习效果

Fig. 8 Learning effect of dynamics of $h_2(X)$




图 9 系统动态学习误差

Fig. 9 Dynamic learning errors of the system




图 10 确定学习控制跟踪效果

Fig. 10 Tracking effect of deterministic learning control

6 结论(Conclusion)

确定学习运用自适应控制和非线性动力学系统的概念与方法, 研究未知动态环境下的知识获取(建

模)、表达和再利用(识别、控制)等问题. 本文利用确定学习的成果, 设计的控制器在稳定的动态控制过程中可准确学习到移动机器人的未知系统动态并可以存储再利用, 而且使用学习控制避免了网络的重新训练过程, 通过仿真图比较可以知道确定学习控制获得了更好的控制性能.

参考文献(References):

- [1] FIERRO R, LEWIS F L. Control of a nonholonomic mobile Robot: backstepping kinematics into dynamics[J]. *Journal of Robotic Systems*, 1997, 14(3): 149 – 163.
- [2] JIANG Z P, NIJMEIJER H. Tracking control of mobile robots: a case study in backstepping[J]. *Automatica*, 1997, 33(7): 1393 – 1399.
- [3] 祝晓才, 董国华, 蔡自兴, 等. 不确定曲面上非完整移动机器人的鲁棒镇定[J]. 动力学与控制学报, 2006, 4(4): 299 – 307. (ZHU Xiaocai, DONG Guohua, CAI Zixing, et al. Robust stabilization of nonholonomic mobile robots moving on uncertain[J]. *Journal of Dynamics and Control*, 2006, 4(4): 299 – 307.)
- [4] YANG J M, KIM J H. Sliding mode control for trajectory of nonholonomic wheeled mobile robots[J]. *IEEE Transactions on Robotics and Automation*, 1999, 15(3): 578 – 587.
- [5] YILDIRIM S. Adaptive robust neural controller for robots[J]. *Robotics and Autonomous Systems*, 2004, 46(3): 175 – 184.
- [6] 彭金柱, 王耀南, 余洪山. 基于神经网络的非完整移动机器人鲁棒跟踪控制[J]. 中国机械工程, 2008, 19(7): 823 – 827. (PENG Jinzhu, WANG Yaonan, YU Hongshan. Neural network-based robust tracking control for nonholonomic mobile robot[J]. *China Mechanical Engineering*, 2008, 19(7): 823 – 827.)
- [7] 晁红敏, 胡跃明, 吴忻生. 高阶滑模控制在非完整移动机器人鲁棒输出跟踪中的应用[J]. 控制理论与应用, 2002, 19(2): 253 – 257. (CHAO Hongmin, HU Yueming, WU Xinsheng. Applications of high-Order sliding mode control to robust output tracking of non-holonomic mobile robots[J]. *Control Theory & Applications*, 2002, 19(2): 253 – 257.)
- [8] FIERRO R, LEWIS F L. Control of a nonholonomic mobile robot using neural networks[J]. *IEEE Transactions on Neural Networks*, 1998, 9(4): 589 – 600.
- [9] WANG C, HILL D J. Learning from neural control[J]. *IEEE Transactions on Neural Networks*, 2006, 17(1): 130 – 145.
- [10] SANNER R M, SLOTINE J E. Gaussian networks for direct adaptive control[J]. *IEEE Transactions on Neural Networks*, 1992, 3(6): 837 – 863.
- [11] LORIA A, PANTELEY E. Uniform exponential stability of linear time-varying systems: revisited[J]. *Systems & Control Letters*, 2002, 47(1): 13 – 24.
- [12] KHALIL H K. *Nonlinear Systems*[M]. 3rd ed. Upper Sanddle River, NJ: Prentice-Hall, 2002.

作者简介:

周勇 (1986—), 男, 硕士研究生, 主要研究方向为机器人的智能学习控制, E-mail: zhou_yong1986@126.com;

王聪 (1968—), 男, 教授, 博士生导师, 主要研究方向为确定性学习、基于模式的控制等, E-mail: wangcong@scut.edu.cn;

顾武军 (1982—), 男, 硕士研究生, 主要研究方向为机器人的智能学习控制, E-mail: gwj7211@163.com;

曾玮 (1979—), 男, 博士研究生, 主要研究方向为确定性学习、动态模式识别等, E-mail: zw0597@126.com.