

一种基于迭代学习的移动机器人轨迹跟踪控制方法^①

韩 龙, 刘国栋

(江南大学物联网工程学院, 江苏 无锡 214122)

摘 要: 机器人迭代学习在某些场合下有着重要的应用。传统的 P 型或 PD 迭代学习需要较长的迭代过程, 本文提出了一种具有快速收敛的迭代学习策略。在给出的轮式移动机器人运动学模型基础上进行了仿真, 结果证明了策略的有效性。

关键词: 机器人迭代学习; 快速收敛; 轮式移动机器人

A Kind of Mobile Robot Trajectory Tracking Control Methods Based on Iterative Learning

HAN Long, LIU Guo-Dong

(Jiangnan University Internet Of Things Engineering Institute, Jiangsu Wu Xi 214122)

Abstract: The Robot iterative learning in some places has an important application. Compared with the traditional types of P or PD iterative learning, this paper proposes a kind of iterative learning strategies which have a rapid convergence, and then we have a simulation based on the robot kinematics model given. The results show the effectiveness of the strategy.

Key words: Robot iterative learning; rapid convergence; wheeled mobile robots

1 引言

移动机器人具有时变、强耦合、非线性等特征, 使得实际上无法获得移动机器人的精确、完整的运动学模型。在某些特殊场合下, 移动机器人的规划轨迹是已知的, 如何控制机器人的运动来跟踪轨迹呢? 迭代学习 (Iterative Learning Control) 为解决这类问题提供了一种有效的途径。

迭代学习这个概念最早是由日本学者 S.Uchiyama 提出的, 然后 S.Arimoto^[1]、Z.Bien 等人进行了深入的研究, 目前这种方法主要应用有全局优化、模型参数辨识等^[2-4]。迭代学习就是根据前几次运行所产生的状态或输出误差, 按照一定的学习策略来修正上一次的输入, 经过多次迭代, 直到使误差在允许的范围之内^[5]。传统的迭代学习策略有 P 型、PD 型和 PID 等, 但是这些算法都是采用试探的方法来进行迭代且迭代次数比较长^[6]。文献[7-9]分别提出了新的迭代学习控制器的设计, 并利用过去的有效信息来解决期望轨迹

变化时的问题。本文提出了迭代学习策略, 通过模糊学习来改变初始迭代值, 从而具有较快的收敛速度, 仿真证明了其有效性。

2 轮式移动机器人系统描述




图 1 轮式移动机器人运动模型

① 收稿时间:2011-07-14;收到修改稿时间:2011-09-07

图 1 为轮式机器人运动模型，在同轴上有两个独立的驱动轮，驱动机器人在二维平面上运动^[10]。点 $p(k)$ 是左右驱动轮的中点，代表机器人的当前位置，在广义坐标系下 $p(k)$ 点定义为 $[x_p(k), y_p(k), \theta_p(k)]$ ，其中 $x_p(k)$ 和 $y_p(k)$ 为直角坐标系下 x 、 y 轴的坐标分量； $\theta_p(k)$ 为机器人的方向角， $p(k)$ 点的线速度和角速度分别为 $v_p(k)$ 、 $\omega_p(k)$ 。根据图 1， $p(k)$ 点的轮式移动机器人的离散运动学方程如式：

$$\begin{bmatrix} x_p(k+1) \\ y_p(k+1) \\ \theta_p(k+1) \end{bmatrix} = \begin{bmatrix} x_p(k) \\ y_p(k) \\ \theta_p(k) \end{bmatrix} + \Delta T * \begin{bmatrix} \cos \theta_p(k) & 0 \\ \sin \theta_p(k) & 0 \\ 0 & 1 \end{bmatrix} * \begin{bmatrix} v_p(k) \\ \omega_p(k) \end{bmatrix} \quad (1)$$

其中， ΔT 为采样时间，记 $\mathbf{q}(k) = [x_p(k), y_p(k), \theta_p(k)]^T$ 为状态向量， $\mathbf{u}_p(k) = [v_p(k), \omega_p(k)]^T$ 为速度向量，由(2)式确定：

$$\begin{cases} v_p(k) = v_r + v_{l/2} \\ \omega_p(k) = v_p(k)/r \end{cases} \quad (2)$$

其中， v_r 、 v_l 分别为轮式机器人右左轮的速度， r 为机器人的半径。则(2)式可以改写

$$\mathbf{q}(k+1) = \mathbf{q}(k) + \mathbf{B}(\mathbf{q}_p(k), k) \mathbf{u}_p(k) \quad (3)$$

其中，输入矩阵

$$\mathbf{B}(\mathbf{q}_p(k), k) = \Delta T * \begin{bmatrix} \cos \theta_p(k) & 0 \\ \sin \theta_p(k) & 0 \\ 0 & 1 \end{bmatrix}$$

2 轨迹跟踪问题描述

如图 1 中虚线为机器人的期望轨迹，因此期望轨迹上的 $p_d(k)$ 点的状态向量为 $p_d(k) = [x_d(k), y_d(k), \theta_d(k)]^T$ ，定义状态向量误差 $\Delta \mathbf{q}$ ，如式(4)：

$$\Delta \mathbf{q}(k) = \mathbf{q}_d(k) - \mathbf{q}(k) = \begin{bmatrix} x_d(k) - x_p(k) \\ y_d(k) - y_p(k) \\ \theta_d(k) - \theta_p(k) \end{bmatrix} \quad (4)$$

考虑到实际环境有噪音等的影响，因此移动机器人的离散运动学方程可描述为式(5)：

$$\begin{cases} \mathbf{q}(k+1) = \mathbf{q}(k) + \mathbf{B}(\mathbf{q}_p(k), k) \mathbf{u}_p(k) + \xi(k) \\ \mathbf{y}(k) = \mathbf{q}(k) + \eta(k) \end{cases} \quad (5)$$

其中， $\xi(k)$ 、 $\eta(k)$ 是状态噪声向量和输出策略噪声向量。当机器人进行迭代学习控制时，(5)式可以

改写为：

$$\begin{cases} \mathbf{q}_i(k+1) = \mathbf{q}_i(k) + \mathbf{B}_i(\mathbf{q}_p(k), k) \mathbf{u}_{i,p}(k) + \xi_i(k) \\ \mathbf{y}_i(k) = \mathbf{q}_i(k) + \eta_i(k) \end{cases} \quad (6)$$

其中， i 为迭代次数。这样轨迹跟踪问题就转换为 $p(k)$ 点去逼近 $p_d(k)$ 点运动的问题，即

$$\begin{aligned} \theta_p(k) &\rightarrow \theta_d(k), & y_p(k) &\rightarrow y_d(k), \\ x_p(k) &\rightarrow x_d(k). \end{aligned}$$

3 学习控制率设计

3.1 定义 1 向量范数

设向量 $C \in R^n$ ，则

$$\|C\| = \sqrt{C^T C} \quad (7)$$

定义为向量范数。

3.2 迭代学习律设计

本文设计的迭代学习控制律为：

$$\mathbf{u}_{i+1}(k) = \mathbf{p}_i \mathbf{u}_i(k) + \mathbf{L}_1(k) \mathbf{e}_i(k+1) + \mathbf{L}_2(k) \mathbf{e}_{i+1}(k) \quad (8)$$

其中 i 为迭代次数，误差信号为 $\mathbf{e}_i(k) = \mathbf{y}_d(k) - \mathbf{y}_i(k)$ ， \mathbf{L}_1 、 \mathbf{L}_2 为学习增益矩阵且有界，即 $\|\mathbf{L}_1\| \leq c_{L_1}$ ， $\|\mathbf{L}_2\| \leq c_{L_2}$ ，其中 c_{L_1} 、 c_{L_2} 为正常数； \mathbf{p}_i 表示本次迭代输入 \mathbf{u}_i 和上一次迭代输入 \mathbf{u}_{i-1} 的接近程度，且 $0 < \|\mathbf{p}_i\| \leq 1$ ，下面将做具体说明。在证明控制律收敛之前，先约定其满足几个假设条件：

(1) 由(6)式可知，在理想情况下，即 $\zeta_i(k) = 0$ 和 $\eta_i(k) = 0$ ，则：

$$\begin{cases} \mathbf{q}_d(k+1) = \mathbf{q}_d(k) + \mathbf{B}(\mathbf{q}_d(k), k) \mathbf{u}_d(k) \\ \mathbf{y}_d(k) = \mathbf{q}_d(k) \end{cases}$$

(2) 输入矩阵满足 Lipschitz 条件且有界 $\|\mathbf{B}(q_1, k) - \mathbf{B}(q_2, k)\| \leq c_B \|q_1 - q_2\|$ 和 $\|\mathbf{B}(q_i(k), k)\| \leq b_B$ ，其中 c_B 、 b_B 为常数。

(3) 控制输入 u_d 、干扰 $\zeta(k)$ 和噪声 $\eta(k)$ 有界，

则 $\max_{1 \leq k \leq n} \|\mathbf{u}_d(k)\| \leq c_{u_d}$ 、 $\max_{1 \leq i \leq \infty} \max_{1 \leq k \leq n} \eta_i(k) \leq c_\eta$ 和

$\max_{1 \leq i \leq \infty} \max_{1 \leq k \leq n} \zeta_i(k) \leq c_\zeta$ ，其中 c_ζ 、 c_{u_d} 和 c_η 为正常数。

(4) 每次迭代从 $q_d(0)$ 的邻域开始，即

$\|q_d(0) - q_i(0)\| \leq c_{q_0}$ ， c_{q_0} 为正常数。

证明：由式(4)可知：

$$\begin{aligned} \Delta q_i(k+1) &= q_d(k+1) - q_i(k+1) \\ &= q_d(k) + B(q_d(k), k)u_d(k) - \\ &\quad [q_i(k) + B(q_i(k), k)u_i(k) + \xi_i(k)] \\ &= \Delta q_i(k) + B(q_d(k), k)u_d(k) - \\ &\quad B(q_i(k), k)u_i(k) - \xi_i(k) \\ &= \Delta q_i(k) + B(q_d(k), k)u_d(k) - B(q_i(k), k) * \\ &\quad [u_i(k) - u_d(k) + u_d(k)] - \xi_i(k) \end{aligned}$$

整理后得到:

$$\begin{aligned} \Delta q_i(k+1) &= \Delta q_i(k) + [B(q_d(k), k)u_d(k) \\ &\quad - B(q_i(k), k)u_i(k)] * u_d(k) \\ &\quad + B(q_i(k), k) * \Delta u_i(k) - \xi_i(k) \end{aligned} \quad (9)$$

对(9)式两边同时取范数, 则

$$\begin{aligned} \|\Delta q_i(k+1)\| &= \|\Delta q_i(k)\| + \|B(q_d(k), k)u_d(k) \\ &\quad - B(q_i(k), k)u_i(k) * u_d(k) + B(q_i(k), k)\|\Delta u_i(k)\| \end{aligned}$$

假设条件化简后可以得到:

$$\|\Delta q_i(k+1)\| \leq \|C_B b_{q_0} + 1\| \|\Delta q_i(k)\| + b_B \|\Delta u_i(k) + c_\beta \quad (10)$$

令 $h_2 = (c_B c_{q_0} + 1)$, 则(10)式可以化简为:

$$\|\Delta q_i(k+1)\| \leq h_2 \|\Delta q_i(k)\| + b_B \|\Delta u_i(k)\| + c_\beta \quad (11)$$

由递推关系可以推出:

$$\|\Delta q_i(k+1)\| \leq \sum_{j=0}^{k-1} h_2^{k-1-j} [b_B \|\Delta u_i(j)\| + b_\xi] + h_2^k c_{q_0} \quad (12)$$

下面要考察 $\Delta u_i(k)$ 。

$$\begin{aligned} \Delta u_{i+1}(k) &= u_d(k) - u_{i+1}(k) \\ &= u_d(k) - p_i u_i(k) - L_1 \Delta q_i(k) - L_1 [B(q_d(k), k) \\ &\quad - B(q_i(k), k)] u_d(k) + L_1 B(q_i(k), k) \Delta u_i(k) \\ &\quad - L_2 \Delta q_{i+1}(k) + L_1 [\xi_i(k) + \eta_{i+1}(k)] + L_2 \eta_{i+1}(k) \end{aligned} \quad (13)$$

由 $u_d(k) = u_d(k) - p_i [u_i(k) - u_d(k) + u_d(k)] = (1 - p_i)u_d(k) + p_i \Delta u_i(k)$, 代入(13)式化简后得:

$$\begin{aligned} \Delta u_{i+1}(k) &= (p_i + L_1 B(q_i(k), k)) \Delta u_i(k) + (1 - p_i)u_d(k) \\ &\quad - L_1 \Delta q_i(k) - L_1 [B(q_d(k), k) \\ &\quad - B(q_i(k), k)] * u_d(k) - L_2 \Delta q_{i+1}(k) \\ &\quad + L_1 [\xi_i(k) + \eta_{i+1}(k)] + L_2 \eta_{i+1}(k) \end{aligned} \quad (14)$$

对式(14)两边同时取范数并参考假设条件, 化简后得:

$$\begin{aligned} \|\Delta u_{i+1}(k)\| &\leq \rho \|\Delta u_i(k)\| + b_{L_1} (1 + c_B c_{u_d}) \|\Delta q_i(k)\| + \\ &\quad c_{L_2} \|\Delta q_{i+1}(k)\| + (1 - p_i) c_{u_d} + c_{L_1} (c_\xi + c_\eta) + c_{L_2} c_\eta \end{aligned} \quad (15)$$

令 $h_1 = c_{L_1} (1 + c_B c_{u_d})$, $h_3 = (1 - p_i) c_{u_d} + c_{L_1} (c_\xi + c_\eta) + c_{L_2} c_\eta$, ρ 为谱半径, 则(15)可以化简为:

$$\begin{aligned} \|\Delta u_{i+1}(k)\| &\leq \rho \|\Delta u_i(k)\| + h_1 \|\Delta q_i(k)\| + \\ &\quad c_{L_2} \|\Delta q_{i+1}(k)\| + h_3 \end{aligned} \quad (16)$$

把(12)式代入(16)式得:

$$\begin{aligned} \|\Delta u_{i+1}(k)\| &\leq \rho \|\Delta u_i(k)\| + (h_1 + c_{L_2}) h_2^k c_{q_0} + h_3 + \\ &\quad h_1 \sum_{j=0}^{k-1} h_2^{k-1-j} * [b_B \|\Delta u_i(j)\| + c_\xi] + c_{L_2} \sum_{j=0}^{k-1} h_2^{k-1-j} \\ &\quad [b_B \|\Delta u_i(j)\| + c_\xi] \end{aligned} \quad (17)$$

对(17)两边同时乘以 $(\frac{1}{\partial})^k$, 取 ∂ 范数得, 并取 $\partial > \max\{1, h_2, c_{L_2}\}$, 则

$$\begin{aligned} \|\Delta u_{i+1}(k)\|_\partial &\leq \rho \|\Delta u_i(k)\|_\partial + (h_1 + h_2) h_2^k c_{q_0} + h_3 + \\ &\quad (b_B \|\Delta u_i\|_\partial + c_\xi) \frac{h_1}{\partial} \sum_{j=0}^{k-1} (\frac{h_2}{\partial})^{k-1-j} + (b_B \|\Delta u_{i+1}\|_\partial + c_\xi) \\ &\quad \frac{c_{L_2}}{\partial} \sum_{j=0}^{k-1} (\frac{h_2}{\partial})^{k-1-j} \end{aligned} \quad (18)$$

因为

$$\begin{aligned} \frac{h_1}{\partial} \sum_{j=0}^{k-1} (\frac{h_2}{\partial})^{k-1-j} &= \frac{1}{\partial} (\frac{h_2}{\partial})^{k-1} \sum_{j=0}^{k-1} (\frac{h_2}{\partial})^{-j} = \frac{1}{\partial} (\frac{h_2}{\partial})^{k-1} * \\ &\quad \frac{1 - (\frac{\partial}{h_2})^k}{1 - \frac{\partial}{h_2}} = \frac{1 - (h_2/\partial)^k}{\partial - h_2} \leq \frac{1 - (h_2/\partial)^n}{\partial - h_2} \end{aligned} \quad (19)$$

取 $\partial > \max\{1, h_1, h_2, c_{L_1}, h_2 + b_B c_{L_2}\}$, 把(19)式代入(18)式, 化简后得:

$$\begin{aligned} (1 - b_B c_{L_2} \frac{1 - (h_2/\partial)^n}{\partial - h_2}) \|\Delta u_{i+1}(k)\|_\partial &\leq (\rho + h_1 b_B \frac{1 - (h_2/\partial)^n}{\partial - h_2}) \\ &\quad \|\Delta u_i(k)\|_\partial + (h_1 + c_{L_2}) h_2^k c_{q_0} \frac{c_\xi (h_1 + b_{L_2}) [1 - (h_2/\partial)^n]}{\partial - h_2} \end{aligned} \quad (20)$$

由(20)式可以得到:

$$\|\Delta u_{i+1}(k)\|_\partial \leq h_4 \|\Delta u_i(k)\|_\partial + h_5 \quad (21)$$

其中

$$h_4 = \frac{\rho + h_1 b_B \frac{1 - (h_2/\partial)^n}{\partial - h_2}}{1 - b_B c_{L_2} \frac{1 - (h_2/\partial)^n}{\partial - h_2}}$$

$$h_5 = \frac{(h_1 + c_{L_2})h_2^k c_{q0} + \frac{c_\xi(h_1 + b_{L_2})[1 - (h_2/\partial)^n]}{\partial - h_2}}{1 - b_B c_{L_2} \frac{1 - (h_2/\partial)^n}{\partial - h_2}}$$

由(21)递推公式可以得到:

$$\begin{aligned} \|\Delta u_{i+1}(k)\|_\rho &\leq h_4^i \|\Delta u_i(k)\|_\rho + h_5 \sum_{j=0}^{i-1} h_4^j \\ &= h_4^i \|\Delta u_i(k)\|_\rho + \frac{h_5(1 - h_4^i)}{1 - h_4} \end{aligned} \quad (22)$$

取 ∂ 使得 $h_4 \approx \rho < 1$, 则

$$\lim_{i \rightarrow \infty} \|\Delta u_i(k)\|_\rho = \frac{h_5}{1 - h_4} \quad (23)$$

因此输入误差收敛。同理其他误差也都收敛, 证毕。

3.3 关于 \mathbf{p}_i 的说明

\mathbf{p}_i 是表示本次迭代输入 \mathbf{u}_i 和上一次迭代输入 \mathbf{u}_{i-1} 的接近程度。以前的 P 或 PD 型学习律算法需要较长时间的迭代(大约需要迭代 500 次), 本文引入这个变量主要是为了通过修正 \mathbf{p}_i 来使得算法快速收敛, 其算法主要是通过模糊推理来获得。假设第 i 次迭代和 $i-1$ 次迭代的出入误差用 Δd_i 表示, 对 $\Delta d_i \in [d_1, d_2]$ 进行模糊化, 其中 d_1, d_2 是其论域范围, 其语言变量为 {负大, 负中, 负小, 零, 正小, 正中, 正大}, 记为 {NB, NM, NS, Z, PS, PB}, 然后通过离线实验来得到 \mathbf{p}_i 的隶属度。根据定义 1 可知, (4)式的向量范数为:

$$\|\Delta \mathbf{q}(k)\| = \left\{ [x_d(k) - x_p(k)]^2 + [y_d(k) - y_p(k)]^2 + [\theta_d(k) - \theta_p(k)]^2 \right\}^{1/2} \quad (24)$$

由于轨迹跟踪控制是通过不断进行迭代学习来逼近期望轨迹的, 而迭代次数并不好确定, 目前关于这方面的相关研究都是采用试探的方法。如果能根据某种指标来确定迭代次数, 那么无疑会减少许多计算量, 降低运算复杂度。本文根据实验和以往的专家累计经验, 以状态向量误差 $\Delta \mathbf{q}$ 的范数为指标即(24)式, 当达到其阈值 $b_{\Delta q}$ ($b_{\Delta q}$ 是常数, 由实验和经验得到), 就可以认为 $p_d(k)$ 已经逼近了, 其流程图如图 2 所示:

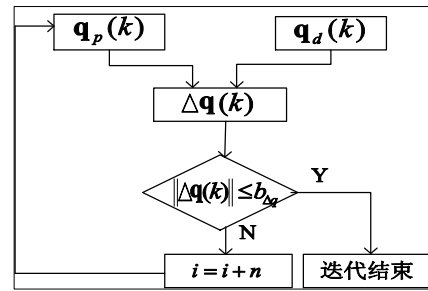


图 2 迭代学习流程图


其中 n 为每次迭代次数的增量, 是一个常数。

4 实验和仿真

通过上文的策略设计, 下面用实验来验证。对机器人离散系统(6)进行仿真, 假设每次迭代被控对象初始值与期望值相同, 即 $x_{i,p}(0) = x_d(0)$, $y_{i,p}(0) = y_d(0)$, $\theta_{i,p}(0) = \theta_d(0)$, 采用(8)式的学习规律。期望位置为 $x_d(t) = \cos \pi t$, $y_d(t) = \sin \pi t$, $\theta_d(t) = \pi t + \pi/2$, 可以看出其期望轨迹是一个圆;

取 $L_1 = L_2 = \begin{bmatrix} \cos \theta(k) & \sin \theta(k) & 0 \\ 0 & 0 & 1 \end{bmatrix}$, 采样时间

$\Delta T = 10\text{ms}$, 初始迭代次数为 50; 每次迭代时间为 2000 次^[11]。图 3 为不同迭代次数下的仿真图, 可以看出大约迭代 150 次时获得较满意的结果, 而传统的迭代次数在 180 次左右才能得到较满意的结果, 且误差收敛时间也减小了^[12]。图 4 为状态误差随迭代次数变化收敛的仿真图, 可以看出随仿真次数增加其误差不断减小, 大概迭代 150 次时获得较为满意结果。



(a) $i=50$ 迭代次数



(b) $i=100$ 迭代次数(c) $i=150$ 迭代次数

图 3 不同迭代次数轨迹跟踪图




图 4 轨迹跟踪状态误差收敛图

5 结语

本文提出了基于迭代的轨迹跟踪的学习控制率,从仿真可以看出,取得了较好的效果。结合实际

参加的全国机器人大赛,并把本文策略应用到江南大学 AF 机器人中去,并在 2008 年和 2010 年取得了优异的成绩。

参考文献

- 1 Suguru Arimoto. Mathematical Theory of Learning with Applications to Robot Control. Proc. of 4th Yale Workshop on Applications of Adaptive Systems. New haven, 1985: 379–388.
- 2 Owens DH, Iterative learning control-an optimization paradigm. Annual Reviews in Control, 2005, 37: 1099–1121.
- 3 Taybi A, Model reference adaptive iterative learning control system. International Journal of Adaptive Control and Signal Processing, 2006, 20(9): 475–489.
- 4 Madady A. A model reference adaptive iterative learning control system. The 32th Annual Conference of IEEE Industrial Electronics Society, Paris, 2006: 627–632.
- 5 许顺孝, 杨富文. 迭代学习控制的研究与进展. 厦门大学学报, 2001, 40(1): 46–49.
- 6 徐进学, 吴海, 等. 基于内模的机器人迭代学习控制. 机器人, 1998, 20(6): 401–403.
- 7 李玉忍, 张林, 等. 迭代学习在 PID 中的应用. 2008, 28(6): 5–8.
- 8 姚仲舒, 王宏飞, 等. 一种机器人轨迹跟踪的迭代学习控制方法. 兵工学报, 2004, 25(3): 330–334.
- 9 回立川, 林辉. 一种新型的迭代学习控制器的设计研究. 计算机仿真, 2009, 26(3): 333–335.
- 10 蔡自兴, 贺汉根, 等. 未知环境中移动机器人导航控制理论与方法. 科学出版社, 2009: 429–432.
- 11 刘金琨. 机器人控制系统的设计与 MATLAB 仿真[M]. 清华大学出版社, 2008: 323–333.
- 12 阎世梁, 张华, 等. 极坐标下基于迭代的移动机器人轨迹跟踪控制. 计算机应用, 2010, 30(8): 2017–2020.