

基于预测型间接迭代学习的 SCARA 机器人轨迹跟踪控制

严 浩, 白瑞林, 朱 朔

(江南大学 轻工过程先进控制教育部重点实验室, 江苏 无锡 214122)

摘 要: SCARA 机器人是一个强耦合、多输入多输出的非线性系统, 运行时较易受外界干扰的影响, 而且传统比例-积分-微分(PID)反馈控制器的轨迹跟踪精度较低。针对上述问题, 设计具有前馈作用的预测型迭代学习控制器(A-ILC)。利用运行批次在采样时刻 $t + \Delta$ 处的误差输出信息, 优化调整下次运行在采样时刻 t 处双闭环 PID 反馈控制器的角度。仿真结果表明, 与仅采用双闭环 PID 反馈控制器相比, 采用所设计的控制器能明显减小机器人末端的轨迹跟踪误差。

关键词: 机器人; 双闭环; 反馈控制器; 迭代学习; 轨迹跟踪

中文引用格式: 严 浩, 白瑞林, 朱 朔. 基于预测型间接迭代学习的 SCARA 机器人轨迹跟踪控制[J]. 计算机工程, 2017, 43(10): 296-301, 309.

英文引用格式: YAN Hao, BAI Ruilin, ZHU Shuo. Trajectory Tracking Control of SCARA Robot Based on Anticipatory-type Indirect Iterative Learning[J]. Computer Engineering, 2017, 43(10): 296-301, 309.

Trajectory Tracking Control of SCARA Robot Based on Anticipatory-type Indirect Iterative Learning

YAN Hao, BAI Ruilin, ZHU Shuo

(Key Laboratory of Advanced Process Control for Light Industry, Ministry of Education, Jiangnan University, Wuxi, Jiangsu 214122, China)

[Abstract] SCARA robot is a strong coupling, multi-input and multi-output nonlinear system, which is easy to be affected by outside interference when running, and the traditional Proportional-Integral-Derivative (PID) feedback controller leads to low trajectory tracking accuracy. To solve this problem, an Anticipatory-type Iterative Learning Controller (A-ILC) with feedforward function is designed, which utilizes the previous cycle output tracking error at moment $t + \Delta$ to adjust the angle reference of the double-loop PID feedback controller in next cycle at moment t . Simulation results show that compared with the double closed loop PID feedback controller, the designed controller can significantly reduce the trajectory tracking error at the end of the robot.

[Key words] robot; double closed loop; feedback controller; iterative learning; trajectory tracking

DOI: 10.3969/j.issn.1000-3428.2017.10.049

0 概述

SCARA (Selective Compliance Assembly Robot Arm) 机器人结构紧凑、运行速度快、控制精度高, 广泛应用于具有重复运动的工业生产过程。但 SCARA 机器人是一个时变、非线性和强耦合的复杂系统, 这使得传统比例-积分-微分 (Proportion-Integral-Derivative, PID) 控制、模糊控制、鲁棒控制等, 难以保证系统具有良好的轨迹跟踪精度^[1-4]。

对于重复性的轨迹跟踪运动, 迭代学习控制 (Iterative Learning Control, ILC) 是一种非常有效的控制策略, 通过运用上一次轨迹跟踪误差来优化调整下一次运行时的控制效果, 并且不依赖于系统数

学模型。文献[5]提出迭代学习控制后, 迭代学习控制在机器人的轨迹跟踪中得到了很好的发展。目前迭代学习控制基本都是直接型迭代学习^[6-8], 即迭代学习控制器的输出的力矩信号直接作用于机器人本体。文献[9]提出一种自适应迭代学习控制器, 能够自适应调节 PD 反馈控制器的增益, 迭代学习控制器用来修正控制力矩。文献[10]考虑机器人驱动器的动力学, 采用 PD 反馈控制和迭代学习前馈控制相结合的方式, 实现机器人轨迹跟踪精度逐次提高。文献[11]提出了一种新的带遗忘因子的迭代学习控制策略, 不仅加快了迭代学习算法的收敛速度, 而且不依赖学习控制的初始输入。文献[12]提出了一种基于低通滤波器的迭代

基金项目: 江苏省产学研前瞻性联合研究项目 (BY2015019-38); 江苏高校优势学科建设工程项目 (PAPD)。

作者简介: 严 浩 (1992—), 男, 硕士研究生, 主研方向为机器人控制技术; 白瑞林, 教授、博士生导师; 朱 朔, 硕士研究生。

收稿日期: 2016-08-01 **修回日期:** 2016-10-17 **E-mail:** jiangnan_yh@163.com

学习控制方法,消除了机器人轨迹跟踪过程中系统不确定性对跟踪性能的影响。

在工程实际中,机器人控制系统一般是多轴运动控制器加伺服驱动器的模式,这使得直接型迭代学习控制难以进行实际应用。为此,文献[13]提出一种基于 PD 型间接迭代学习的轨迹跟踪控制策略,通过 PD 型迭代学习控制器(PD-type Iterative Learning Control,PD-ILC)来优化调整双闭环 PID 反馈控制器的角度给定,但该方法迭代学习速度慢,需要重复运行多次,才能使得轨迹跟踪精度达到要求,并且该方法在迭代学习完成之后,迭代学习控制器没有利用本次运行的误差输出数据。为此,本文在双闭环 PID 反馈控制器的基础上,设计具有前馈功能的预测型迭代学习控制器(Anticipatory-type Iterative Learning Control,A-ILC)来取代 PD 型迭代学习控制器,在不改变现有机器人控制系统结构的前提下,提高 SCARA 机器人轨迹跟踪精度。

1 SCARA 机器人模型建立

1.1 SCARA 机器人平面定位模型

SCARA 机器人结构如图 1 所示。




图 1 SCARA 机器人机械结构

本文研究 SCARA 机器人轨迹跟踪控制,其末端在平面上的定位取决于轴 1 和轴 2 的关节角 θ_1 和 θ_2 的共同作用,所以 SCARA 机器人轨迹跟踪数学模型可以简化为图 2 所示。




图 2 SCARA 机器人轨迹跟踪简化模型

当已知机器人末端在平面中的位置 (x, y) 时,可以确定两关节的角度 θ_1 和 θ_2 ,即该模型的逆解为:

$$\begin{cases} \theta_1 = \arctan\left(\frac{y}{x}\right) - \arctan\left(\frac{l_2 \times \sin\theta_2}{l_1 + l_2 \times \cos\theta_2}\right) \\ \theta_2 = \pi - \arccos\left(\frac{-(x^2 + y^2) + l_1^2 + l_2^2}{2 \times l_1 \times l_2}\right) \end{cases} \quad (1)$$

当已知 θ_1 和 θ_2 时,可以确定机器人末端在平面中的位置 (x, y) ,即该模型的正运动学如下:

$$\begin{cases} x = l_1 \cos\theta_1 + l_2 \cos(\theta_1 + \theta_2) \\ y = l_1 \sin\theta_1 + l_2 \sin(\theta_1 + \theta_2) \end{cases} \quad (2)$$

在获取 SCARA 机器人数学模型后,在任务空间给定期望待跟踪轨迹,通过运动学逆解,获得对应关节期望角度。同时根据采集到的机器人实际关节角度,通过运动学正解,得到机器人末端实际的运行轨迹。

1.2 SCARA 机器人动力学模型

对于 n 关节的机器人系统,其动力学方程可以用二阶非线性微分方程来表示^[14],具体如式(3)所示。

$$D(\theta) \ddot{\theta} + C(\theta, \dot{\theta}) \dot{\theta} + G(\theta) = \tau \quad (3)$$

其中, $\theta \in \mathbb{R}^n$ 为关节角位置矢量; $\dot{\theta} \in \mathbb{R}^n$ 为关节角速度矢量; $\ddot{\theta} \in \mathbb{R}^n$ 为关节角加速度矢量; $D(\theta) \in \mathbb{R}^{n \times n}$ 为机器人的惯性矩阵; $C(\theta, \dot{\theta}) \in \mathbb{R}^n$ 表示离心力和哥氏力; $\tau \in \mathbb{R}^n$ 为各关节控制力矩。根据 SCARA 机器人结构,利用拉格朗日法对 SCARA 机器人进行动力学建模,得到式(3)中的各项参数为:

$$D(\theta) = \begin{bmatrix} D_{11} & D_{12} & 0 & D_{14} \\ D_{21} & D_{22} & 0 & D_{24} \\ 0 & 0 & D_{33} & 0 \\ D_{41} & D_{42} & 0 & D_{44} \end{bmatrix}$$

$$\begin{cases} D_{11} = \frac{1}{3}m_1 l_1^2 + m_2 \left(\frac{1}{3}l_2^2 + l_1^2 + l_1 l_2 c_2 \right) + (m_3 + m_4)(l_1^2 + l_2^2 + 2l_1 l_2 c_2) + \frac{1}{2}m_4 r^2 \\ D_{22} = \frac{1}{3}m_2 l_2^2 + m_3 l_2^2 + m_4 l_2^2 + \frac{1}{2}m_4 r^2 \\ D_{33} = m_3 + m_4, D_{44} = \frac{1}{2}m_4 r^2 \\ D_{12} = \frac{1}{3}m_2 l_2^2 + \frac{1}{2}m_2 l_1 l_2 c_2 + m_3 l_2^2 + m_3 l_1 l_2 + m_4 l_2^2 + m_4 l_1 l_2 c_2 + \frac{1}{2}m_4 r^2 \\ D_{13} = 0, D_{14} = -\frac{1}{2}m_4 r^2 \\ D_{21} = \frac{1}{3}m_2 l_2^2 + \frac{1}{2}m_2 l_1 l_2 c_2 + m_3 l_2^2 + m_3 l_1 l_2 + m_4 l_2^2 + m_4 l_1 l_2 c_2 + \frac{1}{2}m_4 r^2 \\ D_{23} = 0, D_{24} = -\frac{1}{2}m_4 r^2, D_{31} = D_{32} = D_{34} = 0 \\ D_{41} = -\frac{1}{2}m_4 r^2, D_{42} = -\frac{1}{2}m_4 r^2, D_{43} = 0 \end{cases}$$

$$C(\theta, \dot{\theta}) = \begin{bmatrix} 2D_{112}\dot{\theta}_2 & D_{122}\dot{\theta}_2 & 0 & 0 \\ D_{211}\dot{\theta}_1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{bmatrix}$$

$$\begin{cases} D_{112} = -\left(\frac{1}{2}m_2 + m_3 + m_4\right)l_1l_2s_2 \\ D_{122} = -\left(\frac{1}{2}m_2 + m_3 + m_4\right)l_1l_2s_2 \\ D_{211} = \left(\frac{1}{2}m_2 + m_3 + m_4\right)l_1l_2s_2 \end{cases}$$

$$G(\theta) = \begin{bmatrix} 0 \\ 0 \\ -(m_3 + m_4)g \\ 0 \end{bmatrix}$$

其中, m_i 代表各连杆的质量; l_i 代表各连杆长度; r 为旋转导轨的半径; c_i 和 s_i 分别是 $\cos(\theta_i)$ 和 $\sin(\theta_i)$ 的简写。

2 预测型间接迭代学习控制策略

间接迭代学习控制系统包含一个双闭环反馈控制器,其输出力矩直接作用于机器人本体;迭代学习控制器通过前一运行批次的轨迹跟踪误差优化调整下次运行时双闭环反馈控制器的关节角度给定,控制系统结构如图 3 所示。




图 3 间接迭代学习控制系统结构

2.1 双闭环 PID 反馈控制器设计

双闭环反馈控制器的输出力矩信号直接作用于 SCARA 机器人关节,其包含一个比例型(P)位置闭环和比例积分型(PI)速度闭环,控制器设计如式(4)所示。

$$\tau_i(t) = K_v \cdot [(r_i(t) - \theta_i(t)) \cdot K_p - \dot{\theta}_i(t)] + K_{vi} \cdot \sum_{t=0}^t [(r_i(t) - \theta_i(t)) \cdot K_p - \dot{\theta}_i(t)] \cdot \Delta_t \quad (4)$$

其中, i 表示第 i 个运行批次; t 表示运行采样时刻; Δ_t 为运行采样时间间隔; $r_i(t)$ 表示第 i 次运行时双闭环反馈控制器的实际关节角度给定值; $\theta_i(t)$ 表示第 i 次运行时编码器反馈的关节角度信号; $\dot{\theta}_i(t)$ 表示第 i 次运行时编码器反馈的关节角速度信号; $\tau_i(t)$ 表示第 i 次运行时作用于关节的力矩信号; K_p

为位置环比例增益; K_v 和 K_{vi} 为速度环比例和积分增益。

2.2 预测型迭代学习控制器设计

预测型迭代学习算法利用之前运行批次在 $t + \Delta$ 采样时刻的角度输出误差,优化调整下一次运行时刻 t 处的角度给定,该方法不需要系统的微分信息,因此,不会带来测量噪声。另外由于充分利用系统之前运行批次输出误差的趋势信息,但又不要像 D 型迭代学习那样使用动态系统的高阶倒数。

令 $\theta_d(t)$ 表示关节待跟踪轨迹; $r_i(t)$ 表示第 i 次运行时双闭环反馈控制器的实际关节角度给定值; $r_{ILC-i}(t)$ 表示第 i 次运行时关节角度给定的调整量; $\theta_i(t)$ 为第 i 次运行完成后机器人关节输出的实际角度值,则具有前馈功能的预测型迭代学习控制器设计如下所示。

1) 第 i 次运行时,机器人轨迹跟踪误差如式(5)所示。

$$e_i(t) = \theta_d(t) - \theta_i(t) \quad (5)$$

2) 迭代学习控制器的输出如式(6)所示。

$$r_i(t) = \theta_d(t) + r_{ILC-i}(t) + Ke_i(t) \quad (6)$$

3) 关节角度给定的调整量如式(7)所示。

$$r_{ILC-i}(t) = r_{ILC-i-1}(t) + k_A e_{i-1}(t + \Delta) \quad (7)$$

第 1 次运行时,由于还没有前一批次运行的输出信息,因此角度给定调整量为 0,所以定义 $r_{ILC-0}(t) = 0$,使得 $r_{ILC-1}(t) = 0$ 。

则式(7)可表示为:

$$r_{ILC-i}(t) = k_A (\dot{e}_1(t + \Delta) + \dots + \dot{e}_{i-1}(t + \Delta)) \quad (8)$$

其中, k_A 为正的学习增益; K 为正比例增益; Δ 为超前采样时间。

从式(6)可以看出,由于引入 $r_{ILC-i}(t)$,使得迭代学习控制器充分利用了之前运行批次的输出误差信息;另外, $Ke_i(t)$ 表示每次运行过程中,轨迹跟踪的实时误差,即本次运行的误差信息能够通过前馈通道快速叠加到角度给定的调整量中。

2.3 算法流程

具有前馈功能的预测型间接迭代学习控制策略,进行轨迹跟踪的工作流程如下:

1) 轨迹给定。在任务空间给定待跟踪期望轨迹,通过运动学逆解,得到对应的关节期望角度位置输入 $\theta_d(t)$ 。

2) 初始化设置。初始化并存储第一次运行的角度指令调整量 $r_{ILC-1}(t) = 0, t \in [0, T], T$ 为运行周期。

3) 进行第 i 次(i 从 1 开始)迭代运行。双闭环反馈控制器的角度置指令实际给定为 $r_i(t) = \theta_d(t) + r_{ILC-i}(t) + Ke_i(t), t \in [0, T]$,同时采样并存储 $e_i(t)$ 。

4) 检验是否达到迭代停止条件。当没有达到停

止条件时,置 $i = i + 1$,同时根据 $e_i(t)$ 更新 $r_{\text{ILC},i+1}(t) = r_{\text{ILC},i}(t) + k_A e_i(t + \Delta)$,返回步骤 3) 进行第 $i + 1$ 次运行;否则迭代学习停止,保存 $r_{\text{ILC},i}(t)$ 。

迭代学习停止条件如式(9)所示。

$$E_{\max} = \max(E(t)) \leq \xi \quad (9)$$

$$E(t) = \sqrt{(\Delta p_x(t))^2 + (\Delta p_y(t))^2} \quad (10)$$

其中, $\Delta p_x(t)$, $\Delta p_y(t)$ 分别代表在采样时刻 t 处机器人末端在 x 轴、 y 轴上的实际位置与期望位置的偏差; E_{\max} 代表一个运行批次过程中,机器人末端在平面上的实际轨迹与期望轨迹偏差的最大值, ξ 为最大轨迹跟踪误差的阈值(单位 mm),算法流程如图 4 所示。

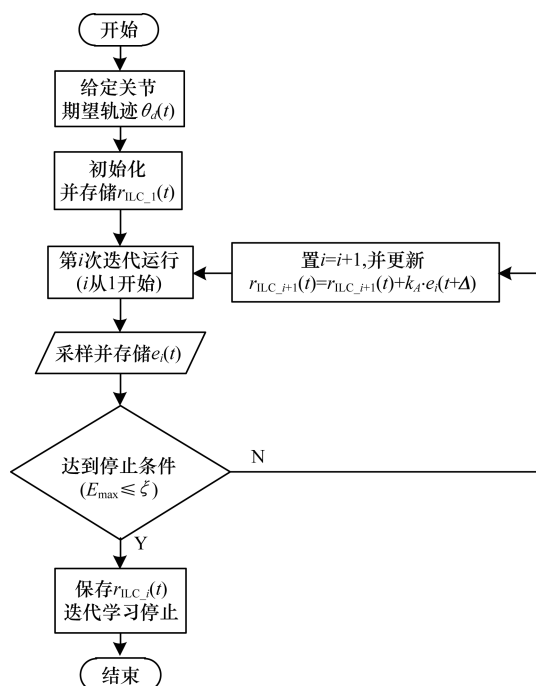


图 4 本文算法流程

3 实验结果分析

在 Matlab2012 环境下根据图 3 进行仿真实验,在 Simulink 的 S-function 函数中构建关节角度输入模块,并根据式(2)构建 SCARA 机器人动力学模型作为被控对象。其中,机器人本体参数如式(11)所示。在 Simulink 中实现仿真控制实验。

$$\begin{aligned} m_1 &= 15 \text{ kg}; m_2 = 12 \text{ kg}; m_3 = 3 \text{ kg}; m_4 = 3 \text{ kg} \\ l_1 &= 0.5 \text{ m}; l_2 = 0.4 \text{ m}; r = 0.2 \text{ m}; g = 9.8 \text{ m/s}^2 \end{aligned} \quad (11)$$

实验时 SCARA 机器人末端跟踪一个半径为 0.15 m 的圆轨迹,轨迹圆心 O 的坐标为 (0.25, 0.4), 轨迹起点 A 的坐标为 (0.4, 0.4), 逆时针运行, 轨迹运行时间为 4 s。机器人末端期望的圆形轨迹如图 2 中虚线圆所示, 并且根据式(1)逆解得到关节 1 和关节 2 的期望角度给定如图 5 所示。




图 5 两关节期望角度给定

很多国内外学者在研究机器人时,将摩擦不确定性、外界随机扰动、结构参数摄动等各种干扰视为高斯干扰^[15-16],所以,在实验时给机器人各个关节施加高斯力矩干扰。

3.1 双闭环 PID 反馈控制

现有机器人控制系统的控制策略大多采用双闭环反馈控制。实验时,双闭环 PID 反馈控制器参数为 $K_p = 150$, $K_v = 20$, $K_{vi} = 10$ 。根据 S-function 函数中的关节角度输入模块,将图 5 所示两关节期望角度作为双闭环 PID 反馈控制器的给定。同时对被控对象反馈输出的实际关节角度进行采样,根据式(2)正解得到 SCARA 机器人末端在平面内的实际轨迹。由给定圆轨迹和反馈得到的实际轨迹,计算出机器人末端轨迹跟踪误差如图 6 所示,机器人末端运行轨迹的终点定位误差、平均跟踪误差、最大跟踪误差如表 1 所示。




图 6 PID 反馈控制时末端轨迹跟踪误差

表 1 PID 反馈控制时任务空间跟踪误差 mm

误差类型	X 轴	Y 轴	轨迹平面
终点定位误差	0.001 9	0.157 1	0.157 2
平均跟踪误差	0.099 9	0.099 6	0.156 8
最大跟踪误差	0.159 2	0.159 4	0.162 8

3.2 基于预测型间接迭代学习的控制策略

在 Matlab2012 环境下,根据图 4 所示算法流程进行仿真实验,迭代学习停止条件为 $E_{\max} \leq 0.05 \text{ mm}$ 。

双闭环 PID 反馈控制器参数为 $K_p = 150, K_v = 20, K_{vi} = 10$ 。预测型迭代学习控制器参数为 $k_A = K = 0.3, \Delta = 8 \text{ ms}$ 。系统采样时间为 2 ms , 即提前了 4 个采样周期。同时采用文献[13]提出的无前馈 PD 型迭代学习控制进行实验, PD 型迭代学习控制器参数设置为 $k_p = 0.3, k_d = 0.25$, PID 双闭环反馈控制器参数为 $K_p = 150, K_v = 20, K_{vi} = 10$ 。迭代学习阶段和迭代学习完成之后共运行 20 个批次, 得到机器人末端的实际轨迹与期望轨迹偏差的最大值 E_{\max} , 其变化情况如图 7 所示。




图 7 机器人末端最大轨迹跟踪误差变化过程

由图 7 可以看出, 采用文献[13]所提方法, 迭代学习 13 次达到迭代学习停止条件; 采用预测型间接迭代学习控制策略, 迭代学习 5 次, 即可达到迭代学习停止条件。由此可见, 本文所提方法可以提高迭代学习收敛速度。

采用预测型间接迭代学习控制, 迭代学习完成后, 保存最后一次关节角度给定调整量 $r_{\text{ILC}_5}(t)$ 。当根据保存的最后一次关节角度给定调整量 $r_{\text{ILC}_5}(t)$ 运行时, 机器人末端最大轨迹跟踪误差保持在稳定阈值内。根据 $r_{\text{ILC}_5}(t)$ 第一次运行时, 任务空间轨迹终点定位误差、平均跟踪误差、最大跟踪误差如表 2 所示。

表 2 A-ILC 情况下任务空间跟踪误差 mm

误差类型	X 轴	Y 轴	轨迹平面
终点定位误差	0.000 4	0.032 7	0.032 7
平均跟踪误差	0.020 7	0.020 6	0.032 5
最大跟踪误差	0.033 4	0.033 3	0.034 5

3.3 PD-ILC 和有前馈 A-ILC 抗干扰能力

实际生产环境中往往存在电压波动、旁路电机启动停止等干扰, 使得机器人输入易受突变力矩的影响。分别采用 A 型间接迭代学习控制和 PD 型间接迭代学习控制, 在迭代学习完成之后第一次运行的 1.5 s 和 2.5 s 对关节 1 和关节 2 输入 $60 \text{ N} \cdot \text{m}$ 的力矩干扰, 得到两关节力矩输入分别如图 8 和图 9 所示。





图 8 A 型间接迭代学习控制时关节力矩输入





图 9 PD 型间接迭代学习控制时关节力矩输入

当机器人关节输入力矩受到干扰时, 快速克服干扰的能力成为评价机器人控制系统性能的重要指标。迭代学习完成之后, 当存在上述力矩干扰下, 分别采用 A 型间接迭代学习控制和 PD 型间接迭代学习控制策略, 得到机器人末端轨迹跟踪误差如图 10 所示。




图 10 输入力矩干扰情况下 A 型和 PD 型抗干扰能力

由此可以看出,采用具有前馈作用的预测型迭代学习控制器,在迭代学习完成之后,迭代学习控制器充分利用了本次运行的误差输出数据,提高了抗干扰能力。

4 实物实验与结果分析

实验在 4 自由度的 SCARA 机器人前两关节进行,如图 11 所示。工控机为运行 NI 实时系统的 PC 机,在 NI 实时系统上通过图形化编程语言 Labview 实时计算机器人末端的期望轨迹,并通过式(1)逆解为对应的关节期望角度。通过 PCI 插槽上的 NI 板卡与伺服驱动器进行总线通信,实时进行关节期望角度给定和实际角度信息等的反馈采集。




图 11 SCARA 机器人

目前国产工业机器人大部分仅采用伺服驱动器对各关节进行独立 PID 控制,即由工控机以总线或脉冲的形式进行关节期望角度给定,伺服驱动器进行位置环和速度环的反馈控制。在图 11 所示的工控机中,根据图 2 和式(1)进行关节期望角度的实时给定和反馈采集,关节角度指令刷新周期为 2 ms。根据采集反馈得到的关节角度信息,由式(2)正解得到机器人末端实际轨迹,则可以得到各个采样点处机器人末端轨迹跟踪误差如图 12 所示。




图 12 末端轨迹跟踪误差

采用具有前馈作用的预测型间接迭代学习控制策略时,仍采用伺服驱动器对各关节进行独立 PID 控制,但在 NI 实时系统上设计迭代学习控制器,根据式(6)对各关节的角度给定进行优化调整。迭代学习 7 次后轨迹跟踪误差基本不在发生变化,此时各个采样点处机器人末端轨迹跟踪误差如图 13 所示。从图 12 和图 13 可以看出,相比于传统机器人的控制策略,本文提出的方法能有效减小轨迹的跟踪误差。但实物实验的结果不如仿真实验结果理想,这是由于仿真实验时简化了一些不可测因素。




图 13 A 型间接迭代学习控制时末端轨迹跟踪误差

5 结束语

基于双闭环 PID 反馈控制器和具有前馈功能的预测性迭代学习控制器,本文提出一种 SCARA 机器人轨迹跟踪控制方法。仿真结果表明,仅采用双闭环 PID 反馈控制时,机器人末端最大轨迹跟踪误差达到 0.162 8 mm;采用具有前馈作用的 A-ILC 时,离线迭代学习 5 次,机器人末端最大轨迹跟踪误差减小到 0.034 5 mm;使用 PD-ILC 时,需要迭代学习 13 次才能达到迭代学习停止条件;并且采用具有前馈作用的 A-ILC 能够更加快速有效地消除外界干扰的影响。由于 SCARA 机器人自由度较少,后期需要在自由度更高的 6 轴工业机器人上验证该算法的有效性。

参考文献

- [1] 陈启军,王月娟,陈辉堂. 基于 PD 控制的机器人轨迹跟踪性能研究与比较[J]. 控制与决策,2003,18(1): 53-57.
- [2] AMER A F, SALLAM E A, ELAWADY W M. Fuzzy Pre-compensated Fuzzy Self-tuning Fuzzy PID Controller of 3 DOF Planar Robot Manipulators[C]// Proceedings of International Conference on Advanced Intelligent Mechatronics. Washington D. C., USA: IEEE Press, 2010: 599-604.
- [3] 郭其龙,张连东. SCARA 型机器人鲁棒控制及仿真的研究[D]. 大连:大连交通大学,2008.
- [4] 王田苗,陶 永. 我国工业机器人技术现状与产业化发展战略[J]. 机械工程学报,2014,50(9): 1-13.

(下转第 309 页)

参考文献

- [1] JIANG Xiaolong, SHEN Shan, CADWELL C R, et al. Principles of Connectivity Among Morphologically Defined Cell Types in Adult Neocortex [J]. *Science*, 2015, 350(6264): 1108.
- [2] ASCOLI G A, DONOHUE D E, HALAVI M. NeuroMorpho. Org: A Central Resource for Neuronal Morphologies [J]. *The Journal of Neuroscience*, 2007, 27(35): 9247-9251.
- [3] 蔺想红,张玉平,李志强,等. 三维神经元几何形态生成算法研究进展[J]. *计算机工程*, 2015, 41(2): 161-166.
- [4] van ELBURG R A J. Stochastic Continuous Time Neurite Branching Models with Tree and Segment Dependent Rates [J]. *Journal of Theoretical Biology*, 2011, 276(1): 159-173.
- [5] LÓPEZ-CRUZ P L, BIELZA C, LARRAÑAGA P, et al. Models and Simulation of 3D Neuronal Dendritic Trees Using Bayesian Networks [J]. *Neuroinformatics*, 2011, 9(4): 347-369.
- [6] ZUBLER F, HAURI A, PFISTER S, et al. Simulating Cortical Development as a Self Constructing Process: A Novel Multi-scale Approach Combining Molecular and Physical Aspects [J]. *PLoS Computational Biology*, 2013, 9(8).
- [7] CATIG G C, FIGUEROA S, MOOREM J. Experimental and Computational Models of Neurite Extension at a Choice Point in Response to Controlled Diffusive Gradients [J]. *Journal of Neural Engineering*, 2015, 12(4).
- [8] DONG Xintong, SHEN Kang, BÜLOW H E. Intrinsic and Extrinsic Mechanisms of Dendritic Morphogenesis [J]. *Annual Review of Physiology*, 2015, 77: 271-300.
- [9] KROTTJE J K, van OUYEN A. A Mathematical Framework for Modeling Axon Guidance [J]. *Bulletin of Mathematical Biology*, 2007, 69(1): 3-31.
- [10] ROCCASALVO I M, MICERA S, SERGI P N. A Hybrid Computational Model to Predict Chemotactic Guidance of Growth Cones [J]. *Scientific Reports*, 2015, 5: 11340.
- [11] LUCZAK A. Measuring Neuronal Branching Patterns Using Model-based Approach [J]. *Frontiers in Computational Neuroscience*, 2010, 4(4): 135.
- [12] KOENE R A, TIJMS B, van HEES P, et al. NETMORPH: A Framework for the Stochastic Generation of Large Scale Neuronal Networks with Realistic Neuron Morphologies [J]. *Neuroinformatics*, 2009, 7(3): 195-210.
- [13] ZUBLER F, DOUGLAS R. A Framework for Modeling the Growth and Development of Neurons and Networks [J]. *Frontiers in Computational Neuroscience*, 2009, 3(8): 681-696.
- [14] ASCOLI G A, KRICHMAR J L. L-neuron: A Modeling Tool for the Efficient Generation and Parsimonious Description of Dendritic Morphology [J]. *Neurocomputing*, 2000, 32: 1003-1011.
- [15] 封宁. 基于神经生物学的神经元真实感仿真 [D]. 杭州: 浙江大学, 2005.
- [16] MOHANTY B B, JENA G. Implication of Fractal L-system Modeling Towards Neural Growth [J]. *International Journal of Advance Computing Techniques and Applications*, 2015, 2(2): 84-88.
- [17] 蔺想红,张田文,张贵仓. 进化大规模脉冲神经网络的发育方法 [J]. *计算机学报*, 2012, 35(12): 2633-2644.
- [18] PAREKH R, ASCOLI G A. Quantitative Investigations of Axonal and Dendritic Arbors Development, Structure, Function, and Pathology [J]. *Neuroscientist*, 2015, 21(3): 241-254.
- [19] MYATT D R, HADLINGTON T, ASCOLI G A, et al. Neuromantic—From Semi-manual to Semi-automatic Reconstruction of Neuron Morphology [J]. *Frontiers in Neuroinformatics*, 2012, 6: 4-17.
- [20] PAREKH R, ASCOLI G A. Neuronal Morphology Goes Digital: A Research Hub for Cellular and System Neuroscience [J]. *Neuron*, 2013, 77(6): 1017-1038.
- [21] ASCOLI G A, SCORCIONI R. *Neuron and Network Modeling* [M]. Berlin, Germany: Springer, 2006.

编辑 顾逸斐

(上接第301页)

- [5] ARIMOTO S, KAWAMURA S, MIYAZAKI F. Bettering Operation of Robots by Learning [J]. *Journal of Robotic Systems*, 1984, 1(2): 123-140.
- [6] CHIEN C J, TAYEBI A. Further Results on Adaptive Iterative Learning Control of Robot Manipulators [J]. *Automatica*, 2008, 44(3): 830-837.
- [7] 郝晓弘,李翠明. 一种机器人轨迹跟踪控制的迭代学习方法 [J]. *科学技术与工程*, 2008, 8(7): 1813-1817.
- [8] 王跃灵,沈书坤,王洪斌. 2-DOF 并联机构动力学建模与迭代学习控制 [J]. *计算机工程*, 2009, 35(17): 163-166.
- [9] OUYANG P R, ZHANG W J, GUPTA M M. An Adaptive Switching Learning Control Method for Trajectory Tracking of Robot Manipulators [J]. *Mechatronics*, 2006, 16(1): 51-61.
- [10] GOPINATH S, KAR I N. Iterative Learning Control Scheme for Manipulators Including Actuator Dynamics [J]. *Mechanism & Machine Theory*, 2004, 39(12): 1367-1384.
- [11] 田森平,谢胜利. 一种新的带有遗忘因子的迭代学习控制算法 [C]//第二十二届中国控制会议. 宜昌: 中国自动化学会, 2003: 331-334.
- [12] 王跃灵,沈书坤,王洪斌. 基于低通滤波器的不确定机器人迭代学习控制 [J]. *控制工程*, 2010, 17(1): 106-109.
- [13] 刘松国. 六自由度串联机器人运动优化与轨迹跟踪控制研究 [D]. 杭州: 浙江大学, 2009.
- [14] 蔡自兴. *机器人学* [M]. 北京: 清华大学出版社, 2005.
- [15] MENG D, JIA Y, DU J, et al. Learning Control for Time-delay Systems with Iteration-varying Uncertainty: A Smith Predictor-based Approach [J]. *IET Control Theory & Applications*, 2010, 4(12): 2707-2718.
- [16] YANG Z, CHAN C W. Conditional Iterative Learning Control for Non-linear Systems with Non-parametric Uncertainties Under Alignment Condition [J]. *IET Control Theory & Applications*, 2009, 3(11): 1521-1527.

编辑 刘冰