



基于数据驱动高阶学习律的轮式移动机器人 轨迹跟踪控制

摘要

轮式机器人执行巡逻、播种和工业生产等任务是一个强非线性的间歇过程.针对重复运行的轮式机器人轨迹跟踪问题,本文提出了一种基于数据驱动的高阶迭代学习控制算法.首先,对轮式移动机器人的模型进行推导设计,并对推导得到的状态空间形式的离散时间模型利用基于状态转移的迭代动态线性化方法,将轮式机器人系统转化为线性输入输出数据模型;其次,设计高阶迭代优化目标函数得到控制律,并利用参数更新律估计线性输入输出数据模型中的未知参数.控制器的设计和分析只使用系统的输入输出数据,不包含任何显式的模型信息.通过采用高阶学习控制方法,在控制律中利用更多之前迭代的控制输入信息,提高了控制性能.最后,仿真结果验证了该方法在轮式机器人轨迹跟踪控制中的有效性.

关键词

数据驱动;高阶学习律;迭代学习;轮式机器人

中图分类号 TP273

文献标志码 A

收稿日期 2020-08-31

资助项目 国家自然科学基金(61873139);山东省泰山学者青年专家人才工程;山东省自然科学基金(ZR2019MF036)

作者简介

李佳伟,男,硕士生,研究方向为自适应控制、学习控制.ljiaawei0714@foxmail.com

林娜(通信作者),女,博士生,研究方向为复杂过程建模与控制、迭代学习控制、自适应控制等.linnaqingdao@163.com

0 引言

随着机器人技术的快速发展和社会的不断进步,轮式移动机器人(Wheeled Mobile Robot, WMR)凭借简单的机械结构、稳定的运行状态和强大的环境适应能力等独特的优势不仅被广泛应用于汽车生产和农产品种植等领域,在国家安全和空间探索等方面也发挥着重要作用^[1-3].由于轮式移动机器人在各领域的广泛应用,其运动控制的关键问题包括路径规划、路径跟踪和运动避障等引起了研究人员的广泛关注.其中,路径跟踪^[4-6]已成为当前研究的热点之一.

WMR本质上是一个强耦合、欠驱动、多变量非线性系统^[6-8],其轨迹跟踪控制器设计存在许多困难和问题,许多专家学者对此做了大量的研究工作.考虑到轮式移动机器人操作过程中未知的参数变化和外部干扰,文献[9]提出了一种基于改进非线性状态观测器的开关增益自适应滑模控制器;文献[10]提出了一种基于神经网络优化的鲁棒模型预测控制方法,提高了模型预测控制的计算效率.

值得注意的是,目前大部分的研究工作都是基于模型的控制方法以实现路径跟踪,控制性能取决于模型精度,因此很难满足实际工作要求.同时,数据驱动控制^[11-14](Data-Driven Control, DDC)在处理复杂动态过程的控制问题方面变得越来越流行,技术的进步使得获取和存储操作数据变得更加容易.DDC设计的原理是利用从实际系统中获得的测量数据来设计控制器,而不使用任何显式的辨识模型信息.

在实际工况中,WMR经常需要执行重复的任务^[15],如播种和喷洒作业的农用车辆和无人清扫车清扫公园环境路面、智能机器人执行搜索和巡逻任务等.在有限的时间内,它的工作环境和期望轨迹是重复不变的.对于重复运行的系统,迭代学习控制^[16-19](Iterative Learning Control, ILC)提供了一种新的控制器设计思想,它可以在固定的时间间隔内,通过利用之前迭代的误差信息来更新当前输入,实现控制性能改善.

目前,WMR的ILC设计也已经有一些报道.文献[20]通过引入自适应遗忘因子,提出了一种开环PD型ILC控制器,增强了ILC的鲁棒性和稳定性;文献[21]设计了一种新的迭代学习算法,突破了传统ILC中对参考轨迹和初始位置每次迭代必须相同的限制.然而,目前

¹ 青岛科技大学 自动化与电子工程学院,青岛,266061

大多数 ILC 控制方法的学习增益往往是固定不变的,而且控制过程中只使用前一次迭代的控制信息.

基于以上分析,本文针对重复运行的 WMR 系统提出了一种高阶迭代学习控制方法.首先,建立 WMR 联合直流电机的运动学方程,引入迭代动态线性化方法(Iterative Dynamic Linearization,IDL)^[22-23],将 WMR 系统表示为线性输入输出数据模型;其次,通过设计含有附加输入信息的目标函数,建立了高阶学习控制律,利用参数更新律对控制律中的未知参数估计;最后,仿真结果验证了所提方法的有效性.

本文的创新点在于:

1)与现有的 ILC 方法相比,控制器设计和分析过程只使用系统输入/输出(I/O)数据,不包含任何显式的模型信息;

2)通过采用高阶算法,在控制律中利用更多之前迭代的输入信息,提高了控制性能;

3)相比于传统的 ILC 方法,学习增益是自适应变化的而不是固定不变的,提高了控制算法的鲁棒性.

本文余下结构分布如下:第 1 节是基本问题描述,将 WMR 模型利用 IDL 转化为线性输入输出数据模型;第 2 节是控制器的设计;第 3 节利用仿真结果验证了所提方法的有效性;第 4 节总结全文.

1 问题描述

WMR 多采用双后轮驱动和双前轮支撑方式,前轮为用于平衡的无动力方向轮,驱动轮采用独立直流伺服电机(DC)驱动.在不考虑轮胎和地面横向滑动的情况下,WMR 可以简化为两轮车模型进行运动学分析,如图 1 所示.

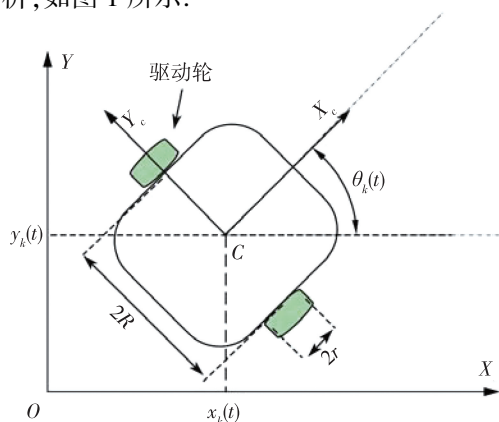


图 1 轮式机器人简图

Fig. 1 Schematic diagram of WMR

假设图 1 中 WMR 的两个驱动轮有相同的物理特性, r 为驱动轮的半径, $2R$ 为两轮之间的距离.两个轮子的中点为 C 点.设 WMR 的质心为 C 点,其位置坐标可设为 (x, y) . I 是 C 点的惯性力矩, m 是 WMR 的质量.

以点 C 为坐标原点,以 WMR 的前进方向为 X 轴,前进方向的垂直方向为 Y 轴,建立机体坐标系 CX_cY_c .机体坐标系与惯性坐标系之间的夹角为 θ ,即 WMR 的转向角.

记 $\mathbf{q}(t) = [x(t) \ y(t) \ \theta(t)]^T$ 表示 WMR 的广义坐标, $x(t)$ 和 $y(t)$ 分别表示 WMR 在平面坐标系中的横坐标和纵坐标, $\theta(t)$ 是 WMR 的转向角,点 C 表示 WMR 当前位置,当前线速度为 $v(t)$,角速度为 $\omega(t)$,则纯滚动、无滑移情况下,WMR 的非完整约束方程为

$$\dot{x} \sin \theta - \dot{y} \cos \theta = 0. \quad (1)$$

根据式(1)可得:

$$\mathbf{A}^T(\mathbf{q})\dot{\mathbf{q}} = [\sin \theta, -\cos \theta, 0] \begin{bmatrix} \dot{x} \\ \dot{y} \\ \dot{\theta} \end{bmatrix} = 0. \quad (2)$$

则 WMR 的运动学方程可以表示为

$$\begin{bmatrix} \dot{x}(t) \\ \dot{y}(t) \\ \dot{\theta}(t) \end{bmatrix} = \begin{bmatrix} \cos \theta(t) & 0 \\ \sin \theta(t) & 0 \\ 0 & 1 \end{bmatrix} \begin{bmatrix} v(t) \\ \omega(t) \end{bmatrix}. \quad (3)$$

式(3)可被简化为

$$\dot{\mathbf{q}} = \mathbf{S}(\mathbf{q})\mathbf{V}(t), \quad (4)$$

其中,

$$\mathbf{S}(\mathbf{q}) = \begin{bmatrix} \cos \theta(t) & 0 \\ \sin \theta(t) & 0 \\ 0 & 1 \end{bmatrix},$$

$$\mathbf{V}(t) = [v(t), \omega(t)]^T,$$

$$\dot{\mathbf{q}} = [\dot{x}(t), \dot{y}(t), \dot{\theta}(t)].$$

假设 WMR 在水平面上运动,不考虑表面摩擦,可以利用经典拉格朗日动力学方程得到 WMR 的动力学模型,如式(5)所示

$$\mathbf{M}(\mathbf{q})\ddot{\mathbf{q}} + \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}})\dot{\mathbf{q}} + \mathbf{G}(\mathbf{q}) = \mathbf{E}(\mathbf{q})\boldsymbol{\tau} + \mathbf{A}(\mathbf{q})\boldsymbol{\lambda}, \quad (5)$$

其中: $\ddot{\mathbf{q}} = [\ddot{x}, \ddot{y}, \ddot{\theta}]^T$ 表示广义加速度矢量; $\mathbf{M}(\mathbf{q}) \in \mathbf{R}^{3 \times 3}$ 是系统的惯性矢量矩阵; $\mathbf{G}(\mathbf{q}) \in \mathbf{R}^3$ 是系统的重力矢量; $\mathbf{C}(\mathbf{q}, \dot{\mathbf{q}})\dot{\mathbf{q}} \in \mathbf{R}^3$ 是与速度和位置有关的离心力和科里奥利力矩矩阵; $\mathbf{E}(\mathbf{q}) \in \mathbf{R}^{3 \times 2}$ 是与车轮间距和半径有关的输出转换矩阵; $\boldsymbol{\tau} = [\tau_r, \tau_l]^T$ 是驱动轮扭矩; $\mathbf{A}(\mathbf{q})\boldsymbol{\lambda} \in \mathbf{R}^3$ 是约束力矩; $\boldsymbol{\lambda}$ 是拉格朗日乘数.

由于 WMR 的轨迹局限于水平面,系统势能保持不变,系统动能可以表示为

$$K = \frac{1}{2}m(x^2 + y^2) + \frac{1}{2}I\theta^2, \quad (6)$$

其中, m 为 WMR 的质量, I 为惯性矢量.
则

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

$$\mathbf{C}(q, \dot{q}) = 0,$$

$$\mathbf{G}(q) = 0, \mathbf{E}(q) = \frac{1}{r} \begin{bmatrix} \cos \theta & \cos \theta \\ \sin \theta & \sin \theta \\ -R & R \end{bmatrix}.$$

式(5)可重写为

$$\mathbf{M}(q)\ddot{q} = \mathbf{E}(q)\tau - \mathbf{A}(q)\lambda. \quad (7)$$

对式(4)两边求导数可得:

$$\ddot{q} = \dot{\mathbf{S}}(q)\mathbf{V} + \mathbf{S}(q)\dot{\mathbf{V}}, \quad (8)$$

将式(8)代入式(7)可得:

$$\mathbf{S}^T \mathbf{M} \mathbf{S} \mathbf{V} + \mathbf{S}^T \mathbf{M} \dot{\mathbf{S}} \mathbf{V} = \mathbf{S}^T \mathbf{E} \tau - \mathbf{S}^T \mathbf{A} \lambda, \quad (9)$$

其中,

$$\mathbf{S}^T \mathbf{M} \mathbf{S} = \begin{bmatrix} m & 0 \\ 0 & I \end{bmatrix}, \quad \mathbf{S}^T \mathbf{M} \dot{\mathbf{S}} = \begin{bmatrix} m & 0 \\ 0 & I \end{bmatrix},$$

$$\mathbf{S}^T \mathbf{E} = \frac{1}{r} \begin{bmatrix} 1 & 1 \\ -R & R \end{bmatrix}, \quad \mathbf{S}^T \mathbf{A} = 0.$$

定义 $\bar{\mathbf{M}} = \mathbf{S}^T \mathbf{M} \mathbf{S}$ 和 $\bar{\mathbf{B}} = \mathbf{S}^T \mathbf{E}$, 则式(9)可简化为

$$\bar{\mathbf{M}} \dot{\mathbf{V}} = \bar{\mathbf{B}} \tau. \quad (10)$$

为了在式(5)中增加执行机构动力, 假设 WMR 的驱动轮由两个有机齿的电刷直流电机(DC)驱动, 电机的数学模型为

$$u = L \frac{di}{dt} + R_a i + K_b \omega_m, \quad (11)$$

其中, u 代表输入电压, R_a 表示电枢电阻, L 表示电枢电感, ω_m 表示为 DC 的角速度, K_b 表示反电势(Back Electromotive Force, EMF)常数.

假设在忽略电枢电感的情况下, 由直流转矩与电流的关系和齿轮前后角速度与转矩的关系可得两驱动轮的扭矩为

$$\tau = \begin{bmatrix} \tau_r \\ \tau_l \end{bmatrix} = K_1 \begin{bmatrix} u_1 \\ u_r \end{bmatrix} - K_2 \begin{bmatrix} \omega_1 \\ \omega_r \end{bmatrix}, \quad (12)$$

其中: $K_1 = nK_r/R_a$, $K_2 = nK_b K_1$, n 为齿轮传动比, K_r 为直流的转矩常数; $\mathbf{u} = [u_1 \ u_r]^T$ 为输入电压, u_1 和 u_r 分别为驱动左右轮输入电压; ω_1 和 ω_r 分别为左右驱动轮的角速度; ω_l 和 ω_r 分别为左右驱动轮的角速度.

根据速度矢量 \mathbf{V} 与车轮角速度 ω_w ($\omega_w = \omega_m/n$) 的关系可知:

$$\begin{bmatrix} \omega_l \\ \omega_r \end{bmatrix} = \frac{1}{r} \begin{bmatrix} 1 & -R \\ 1 & R \end{bmatrix} \begin{bmatrix} v \\ \omega \end{bmatrix}. \quad (13)$$

将式(12)代入式(13)可得:

$$\begin{bmatrix} \tau_1 \\ \tau_r \end{bmatrix} = K_1 \begin{bmatrix} u_1 \\ u_r \end{bmatrix} - \frac{K_2}{r} \begin{bmatrix} 1 & -R \\ 1 & R \end{bmatrix} \begin{bmatrix} v \\ \omega \end{bmatrix}. \quad (14)$$

将式(14)代入式(10), 可得联合直流电机的动态模型表达式为

$$\begin{cases} \dot{\mathbf{V}} = -\frac{2K_2}{r^2} \begin{bmatrix} 1/m & 0 \\ 0 & R^2/I \end{bmatrix} \mathbf{V} + \frac{K_1}{r} \begin{bmatrix} 1/m & 1/m \\ -R/I & R/I \end{bmatrix} \mathbf{u}, \\ \mathbf{y} = \mathbf{C} \mathbf{V}, \end{cases} \quad (15)$$

其中, $\dot{\mathbf{V}} = [v \ \omega]^T$ 表示系统状态, $\mathbf{u} = [u_1 \ u_r]^T$ 表示系

统输入, \mathbf{y} 表示系统输出, $\mathbf{C} = \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}$.

式(15)通过离散化重新整理为

$$\begin{cases} \mathbf{V}(t+1) = \mathbf{A} \mathbf{V}(t) + \mathbf{B} \mathbf{u}(t), \\ \mathbf{y}(t+1) = \mathbf{C} \mathbf{V}(t+1), \end{cases} \quad (16)$$

其中,

$$\mathbf{A} = -\frac{2K_2 h}{r^2} \begin{bmatrix} (1+m)/m & 0 \\ 0 & (R^2+I)/I \end{bmatrix},$$

$$\mathbf{B} = \frac{K_1 h}{r} \begin{bmatrix} 1/m & 1/m \\ -R/I & R/I \end{bmatrix}, h \text{ 表示采样间隔.}$$

重复运行环境中的 WMR 运动模型可表示为

$$\begin{cases} \mathbf{V}_k(t+1) = \mathbf{A} \mathbf{V}_k(t) + \mathbf{B} \mathbf{u}_k(t), \\ \mathbf{y}_k(t+1) = \mathbf{C} \mathbf{V}_k(t+1), \end{cases} \quad (17)$$

其中, $t \in \{0, 1, \dots, N\}$ 表示重复的运行区间, N 是一个正整数, $k \in \{0, 1, \dots\}$ 表示迭代次数.

注 1 WMR 系统(17) 仅用来产生输入输出数据, 后续控制器设计及分析均不需要已知 \mathbf{A} , \mathbf{B} 和 \mathbf{C} 的信息. 也就是说, 在本文中 \mathbf{A} , \mathbf{B} 和 \mathbf{C} 是未知的.

针对 WMR 系统(17), 本文中给出如下假设:

假设 1 WMR 系统(17) 满足相同的初始状态条件, 即 $\mathbf{V}_k(0) = \mathbf{c}$, $\forall k$, 其中 \mathbf{c} 为常数向量.

定理 1 对于非线性系统(17) 在满足假设 1 的条件下, 必然存在一个伪雅可比矩阵(Pseudo Jacobian matrix, PJM) $\Phi_k(t)$ 使下式成立:

$$\Delta \mathbf{y}_k(t+1) = \Phi_k(t) \Delta \mathbf{U}_k(t), \quad (18)$$

其中, $\mathbf{U}_k(t) = [u_k^T(0), u_k^T(1), \dots, u_k^T(t)]^T$, Δ 是一个迭代差分算子, 即:

$$\Delta \mathbf{y}_k(t+1) = \mathbf{y}_k(t+1) - \mathbf{y}_{k-1}(t+1),$$

$$\Delta \mathbf{U}_k(t) = \mathbf{U}_k(t) - \mathbf{U}_{k-1}(t).$$

证明 根据系统(17), 可得:

$$\mathbf{V}_k(t+1) = \mathbf{A}^{t+1} \mathbf{V}_k(0) + \sum_{i=0}^t \mathbf{A}^{t-i} \mathbf{B} \mathbf{u}_k(i). \quad (19)$$

进一步,系统输出变为

$$\mathbf{y}_k(t+1) = \mathbf{CA}^{t+1}\mathbf{V}_k(0) + \mathbf{C} \sum_{i=0}^t \mathbf{A}^{t-i} \mathbf{B} \mathbf{u}_k(i). \quad (20)$$

相邻两次迭代的输出作差,并利用假设 1, 可得:

$$\mathbf{y}_k(t+1) - \mathbf{y}_{k-1}(t+1) = \mathbf{C} \sum_{i=0}^t \mathbf{A}^{t-i} \mathbf{B} \Delta \mathbf{u}_k(i) = \mathbf{\Phi}_k(t) \Delta \mathbf{U}_k(t), \quad (21)$$

其中,

$$\begin{aligned} \mathbf{U}_k(t) &= [\mathbf{u}_k^T(0), \mathbf{u}_k^T(1), \dots, \mathbf{u}_k^T(t)]^T, \\ \mathbf{\Phi}_k(t) &= [\boldsymbol{\varphi}_k(0), \boldsymbol{\varphi}_k(1), \dots, \boldsymbol{\varphi}_k(t)], \\ \boldsymbol{\varphi}_k(i) &= \mathbf{CA}^i \mathbf{B}, i \in \{0, \dots, t\}. \end{aligned}$$

定理 1 得证.

本文的控制目标是找到一个最优的控制输入使得跟踪误差 $\mathbf{e}_k(t+1) = \mathbf{y}_d(t+1) - \mathbf{y}_k(t+1)$ 随迭代次数 k 趋于无穷时收敛于零.

2 控制器设计

考虑如下目标函数:

$$\begin{aligned} J(\mathbf{U}_k(t), \boldsymbol{\alpha}_k) &= \|\mathbf{e}_k(t+1)\|^2 + \\ &\lambda \left\| \mathbf{U}_k(t) - \sum_{i=1}^l \alpha_{k,i} \mathbf{U}_{k-i}(t) \right\|^2, \quad (22) \end{aligned}$$

其中, $\boldsymbol{\alpha}_k = (\alpha_{k,1}, \alpha_{k,2}, \dots, \alpha_{k,l})^T$, $\sum_{i=1}^l \alpha_{k,i} = 1, l \geq 1$ 是一个正整数, λ 是权重因子.

利用最优条件 $\frac{1}{2} \frac{\partial J(\mathbf{U}_k(t), \boldsymbol{\alpha}_k)}{\partial \mathbf{U}_k(t)} = 0$ 可得:

$$\begin{aligned} \mathbf{U}_k(t) &= \mathbf{U}_{k-1}(t) + \frac{\mathbf{\Phi}_k^T(t)}{\lambda + \|\mathbf{\Phi}_k(t)\|^2} \mathbf{e}_{k-1}(t+1) + \\ &\frac{\lambda}{\lambda + \|\mathbf{\Phi}_k(t)\|^2} \sum_{i=2}^l \alpha_{k,i} \mathbf{U}_{k-i}(t). \quad (23) \end{aligned}$$

由于 $\mathbf{\Phi}_k(t)$ 是未知的,所以式(23)可重写为

$$\begin{aligned} \mathbf{U}_k(t) &= \mathbf{U}_{k-1}(t) + \frac{\hat{\mathbf{\Phi}}_k^T(t)}{\lambda + \|\hat{\mathbf{\Phi}}_k(t)\|^2} \mathbf{e}_{k-1}(t+1) + \\ &\frac{\lambda}{\lambda + \|\hat{\mathbf{\Phi}}_k(t)\|^2} \sum_{i=2}^l \alpha_{k,i} \mathbf{U}_{k-i}(t), \quad (24) \end{aligned}$$

其中, $\hat{\mathbf{\Phi}}_k(t)$ 是 $\mathbf{\Phi}_k(t)$ 的估计值,在线更新律由以下估计准则函数得到:

$$\begin{aligned} J(\hat{\mathbf{\Phi}}_k(t)) &= \|\Delta \mathbf{y}_{k-1}(t+1) - \hat{\mathbf{\Phi}}_k(t) \Delta \mathbf{U}_{k-1}(t)\|^2 + \\ &\mu \|\hat{\mathbf{\Phi}}_k(t) - \hat{\mathbf{\Phi}}_{k-1}(t)\|^2, \quad (25) \end{aligned}$$

其中, μ 是一个权重因子.

利用最优条件令 $\frac{1}{2} \frac{\partial J(\hat{\mathbf{\Phi}}_k(t))}{\partial \hat{\mathbf{\Phi}}_k(t)} = 0$, 可得估计

律为

$$\begin{aligned} \hat{\mathbf{\Phi}}_k(t) &= \hat{\mathbf{\Phi}}_{k-1}(t) + \\ &\frac{\eta (\Delta \mathbf{y}_{k-1}(t+1) - \hat{\mathbf{\Phi}}_{k-1}(t) \Delta \mathbf{U}_{k-1}(t)) \Delta \mathbf{U}_{k-1}^T(t)}{\mu + \|\Delta \mathbf{U}_{k-1}(t)\|^2}, \quad (26) \end{aligned}$$

其中, $0 < \eta < 2$ 表示步长因子, $\hat{\mathbf{\Phi}}_k(0)$ 是给定且有界的.

为了增强估计算法(26)对 $\hat{\mathbf{\Phi}}_k(t)$ 的跟踪能力,设计了如下重置算法:

$$\begin{aligned} \|\hat{\mathbf{\Phi}}_k(t)\| &= \|\hat{\mathbf{\Phi}}_0(t)\|, \\ \text{如果 } \|\hat{\mathbf{\Phi}}_k(t)\| &\leq \varepsilon \text{ 或 } \|\Delta \mathbf{U}_{k-1}(t)\| \leq \varepsilon, \quad (27) \end{aligned}$$

其中, ε 是一个充分小的正的常数.

进一步,为了提高控制算法的对外部扰动的鲁棒性,设计控制律为

$$\begin{aligned} \mathbf{U}_k(t) &= P_k(t) \frac{\|\hat{\mathbf{\Phi}}_k(t)\|^2}{\lambda + \|\hat{\mathbf{\Phi}}_k(t)\|^2} \mathbf{U}_{k-1}(t) + \\ &\frac{\hat{\mathbf{\Phi}}_k^T(t)}{\lambda + \|\hat{\mathbf{\Phi}}_k(t)\|^2} \mathbf{e}_{k-1}(t+1) + \\ &\frac{\lambda}{\lambda + \|\hat{\mathbf{\Phi}}_k(t)\|^2} \sum_{i=2}^l \alpha_{k,i} \mathbf{U}_{k-i}(t), \quad (28) \end{aligned}$$

其中, $P_k(t) = \frac{\|\hat{\mathbf{\Phi}}_k(t)\|^2}{\lambda + \|\hat{\mathbf{\Phi}}_k(t)\|^2}$ 表示自适应变化的控制增益.

综上所述,所设计的基于数据驱动的高阶学习方案由式(26)、(27)和(28)组成.

从上述控制方案中可以看出,所提的高阶学习方案与 MWR 的数学模型、机理和阶数均无关.控制方案中只有 PJM 需要在线调整,与以往数据驱动的自适应 ILC 方法相比,本文所提方法利用了更多之前迭代的输入信息,提高了控制性能.

3 仿真实验

为了充分说明所提出方法的有效性,本部分给出了仿真实验.

WMR 控制系统的参数给出如下:

$$m = 36 \text{ kg}, I = 15.625 \text{ kg} \cdot \text{m}^2, 2R = 1.5 \text{ m}, r = 0.15 \text{ m}, K_1 = 7.2, K_2 = 2.592.$$

系统重复运行 80 次.在仿真中,期望路径设置为

$$\mathbf{V}_d(t) = \begin{bmatrix} v_d(t) \\ w_d(t) \end{bmatrix} = \begin{bmatrix} 0.5 \sin(t\pi/10) \\ 0.7 \sin(t\pi/2) + 0.6\pi \end{bmatrix},$$

$$t \in \{0, 1, \dots, 10\}.$$

为了模拟实际中的外部扰动,在仿真中考虑如

下输出扰动 $d_k(t) = [d_{k,1}(t) \ d_{k,2}(t)] = 0.03 \text{ rand}[1 \ 1]$, 如图 2 和图 3 所示.




图 2 随机噪声 $d_{k,1}(t)$

Fig. 2 Random noise $d_{k,1}(t)$




图 3 随机噪声 $d_{k,2}(t)$

Fig. 3 Random noise $d_{k,2}(t)$

应用本文所提出的基于数据驱动的高阶学习算法(26)–(28), 控制器参数设置为 $\eta = 1, \mu = 1, \rho = 0.2, \lambda = 0.01, l = 3, a_1 = 0.1, a_2 = 0.1, a_3 = 0.8$, 采样时间设置为 $h = 0.1$. 图 4 和图 5 分别表示不同迭代次数下的线速度和角速度的跟踪性能. 图 6 和图 7 分别表示线速度和角速度的跟踪误差随着迭代的变化情况. 从图 4–7 可以看出所提的基于数据驱动的高阶算法对 WVR 系统可以达到很好的跟踪控制效果.




图 4 线速度跟踪性能

Fig. 4 Performance of linear velocity tracking




图 5 角速度跟踪性能

Fig. 5 Performance of angular velocity tracking




图 6 线速度跟踪误差

Fig. 6 Tracking error of linear velocity




图 7 角速度跟踪误差

Fig. 7 Tracking error of angular velocity

4 结论

针对轮式机器人执行巡逻任务的重复特性, 提出了一种数据驱动的高阶迭代学习控制算法. 通过引入基于状态转移的迭代动态线性化技术, 将轮式移动机器人系统转化为线性输入输出数据模型形式, 在此基础上, 利用包含更多之前迭代输入信息的指标函数, 设计高阶学习律, 并对数据模型中的参数

设计更新算法,从而实现轨迹跟踪的目的,提高了控制性能.

参考文献

References

- [1] Chan R P M, Stol K A, Halkyard C R. Review of modelling and control of two-wheeled robots [J]. *Annual Reviews in Control*, 2013, 37(1) : 89-103
- [2] Do K D. Output-feedback formation tracking control of unicycle-type mobile robots with limited sensing ranges [J]. *Robotics and Autonomous Systems*, 2009, 57(1) : 34-47
- [3] Pan J, Zhang L J, Manocha D. Collision-free and smooth trajectory computation in cluttered environments [J]. *The International Journal of Robotics Research*, 2012, 31(10) : 1155-1175
- [4] Kim Y, Kim B K. Time-optimal trajectory planning based on dynamics for differential-wheeled mobile robots with a geometric corridor [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(7) : 5502-5512
- [5] Gunnarsson S, Norrlöf M. On the disturbance properties of high order iterative learning control algorithms [J]. *Automatica*, 2006, 42(11) : 2031-2034
- [6] Wu W, Chen J, Mao L. Two-wheeled mobile robot tracking based on iterative learning control [J]. *Materials Science and Information Technology*, 2012, 433 : 5866-5870
- [7] Ye J. Tracking control of a non-holonomic wheeled mobile robot using improved compound cosine function neural networks [J]. *International Journal of Control*, 2015, 88(2) : 364-373
- [8] Gao Y, Chong K T. Min-max model predictive controller for trajectory tracking of a wheeled mobile robot with slipping effects [J]. *IEICE Transactions on Fundamentals of Electronics, Communications and Computer Sciences*, 2011, E94-A(2) : 680-687
- [9] Cui M Y, Liu W, Liu H Z, et al. Extended state observer-based adaptive sliding mode control of differential-driving mobile robot with uncertainties [J]. *Nonlinear Dynamics*, 2016, 83(1/2) : 667-683
- [10] Xiao H Z, Li Z J, Yang C G, et al. Robust stabilization of a wheeled mobile robot using model predictive control based on neurodynamics optimization [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(1) : 505-516
- [11] Dekker L G, Marshall J A, Larsson J. Experiments in feedback linearized iterative learning-based path following for center-articulated industrial vehicles [J]. *Journal of Field Robotics*, 2019, 36(5) : 955-972
- [12] Bu X H, Hou Z S, Chi R H. Model free adaptive iterative learning control for farm vehicle path tracking [J]. *IFAC Proceedings Volumes*, 2013, 46(20) : 153-158
- [13] Tan L N. Distributed optimal integrated tracking control for separate kinematic and dynamic uncertain non-holonomic mobile mechanical multi-agent systems [J]. *IET Control Theory & Applications*, 2017, 11(18) : 3249-3260
- [14] Yu C, Chen X. Trajectory tracking of wheeled mobile robot by adopting iterative learning control with predictive, current, and past learning items [J]. *Robotica*, 2015, 33(7) : 1393-1414
- [15] Maupong T M, Rapisarda P. Data-driven control: a behavioral approach [J]. *Systems & Control Letters*, 2017, 101 : 37-43
- [16] Tanaskovic M, Fagiano L, Novara C, et al. Data-driven control of nonlinear systems: an on-line direct approach [J]. *Automatica*, 2017, 75 : 1-10
- [17] Hou Z S, Chi R H, Gao H J. An overview of dynamic-linearization-based data-driven control and applications [J]. *IEEE Transactions on Industrial Electronics*, 2017, 64(5) : 4076-4090
- [18] Wang D, Liu D R, Zhang Q C, et al. Data-based adaptive critic designs for nonlinear robust optimal control with uncertain dynamics [J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2016, 46(11) : 1544-1555
- [19] Chi R H, Hou Z S, Jin S T, et al. Data-driven terminal iterative learning control with high-order learning law for a class of non-linear discrete-time multiple-input—multiple output systems [J]. *IET Control Theory & Applications*, 2015, 9(7) : 1075-1082
- [20] Jin X. Fault-tolerant iterative learning control for mobile robots non-repetitive trajectory tracking with output constraints [J]. *Automatica*, 2018, 94 : 63-71
- [21] 池荣虎, 侯忠生, 于镭, 等. 高阶无模型自适应迭代学习控制 [J]. *控制与决策*, 2008, 23(7) : 795-798
CHI Ronghu, HOU Zhongsheng, YU Lei, et al. Higher-order model-free adaptive iterative learning control [J]. *Control and Decision*, 2008, 23(7) : 795-798
- [22] Chi R H, Liu Y, Hou Z S, et al. High-order data-driven optimal TILC approach for fed-batch processes [J]. *The Canadian Journal of Chemical Engineering*, 2015, 93(8) : 1455-1461
- [23] Chi R H, Huang B, Hou Z S, et al. Data-driven high-order terminal iterative learning control with a faster convergence speed [J]. *International Journal of Robust and Nonlinear Control*, 2018, 28(1) : 103-119

Data-driven high-order learning control for path tracking of wheeled mobile robots

LI Jiawei¹ LIN Na¹ CHI Ronghu¹

¹ School of Automation & Electronics Engineering, Qingdao University of Science & Technology, Qingdao 266061

Abstract The task of patrolling, seed sowing and industrial production of wheeled robots is a strongly nonlinear intermittent process. In this paper, a data-driven high-order iterative learning control algorithm is proposed for the path tracking of wheeled mobile robots in repeated running scenes. First, the model of wheeled mobile robot is derived and designed, and the discrete-time model in state space is transformed into linear input/output data model by using iterative dynamic linearization method based on state transition. Second, a high-order iterative optimization objective function is designed to obtain the control law, and the parameter update law is used to estimate the unknown parameters in the linear data model. By using high order learning control method, more control input information of previous iteration is used in the control law to improve the control performance. Finally, the simulation results verify the effectiveness of this method in the trajectory tracking control of wheeled robot.

Key words data-driven; high-order learning law; iterative learning; wheeled mobile robot (WMR)