

引用格式: 刘霞, 王露, 陈勇. 基于在线学习的离散时间人机协作系统预定性能柔顺控制 [J]. 电子科技大学学报, 2025, 54(1): 52-61.
LIU X, WANG L, CHEN Y. Discrete-time prescribed performance compliant control based on online-learning for human-robot collaboration system[J].
Journal of University of Electronic Science and Technology of China, 2025, 54(1): 52-61.

基于在线学习的离散时间人机协作系统 预定性能柔顺控制



刘霞^{1*}, 王露¹, 陈勇²

(1. 西华大学 电气与电子信息学院, 成都 610039; 2. 电子科技大学 自动化工程学院, 成都 611731)

摘要: 为了使人机协作系统中机器人能够准确地顺应人类行为, 提出了一种基于在线学习的离散时间预定性能柔顺控制方法。该方法在外环采用在线顺序极限学习机算法估计人类行为, 并将估计结果结合参考阻抗模型来重建参考轨迹。在内环建立了离散时间预定性能控制器用于跟踪重建后的参考轨迹, 并利用时间延迟估计来获得机器人复杂的未知动力学模型。分析了闭环系统的瞬态和稳态性能, 通过对比仿真验证了该方法的有效性。所提的离散时间控制方法可更好地满足数字计算机的工作原理, 在减少计算和内存负担的基础上, 使得机器人末端执行器的跟踪误差能够满足预设性能要求。此外, 该方法无需机器人精确的数学模型, 同时还能减轻人类操作机器人的力量负担, 保证人机协作的柔顺性。

关键词: 柔顺控制; 离散时间人机协作系统; 人类行为估计; 在线顺序极限学习机; 预定性能
中图分类号: TP273 **文献标志码:** A **DOI:** 10.12178/1001-0548.2023239

Discrete-time prescribed performance compliant control based on online-learning for human-robot collaboration system

LIU Xia^{1*}, WANG Lu¹, and CHEN Yong²

(1. School of Electrical Engineering & Electronic Information, Xihua University, Chengdu 610039, China;
2. School of Automation Engineering, University of Electronic Science and Technology of China, Chengdu 611731, China)

Abstract: To enable robot compliant to human behavior in human-robot collaboration system accurately, a discrete-time prescribed performance compliant control based on online-learning is proposed. This method employs online sequential extreme learning machine in the outer loop to estimate the human behavior. The estimation results are combined with a reference impedance model to reconstruct the reference trajectory. A discrete-time prescribed performance controller is established in the inner loop to track the reconstructed reference trajectory, and time delay estimation is employed to obtain the unknown dynamics of the robot. The transient and steady performances of the closed-loop system are analyzed. The effectiveness of the proposed controller is verified by comparative simulations. The proposed discrete-time control method can better satisfy the working principle of digital computers, and it can make the tracking error of the end-effector meet the prescribed performance with less computation and memory burden. In addition, the proposed method does not require the accurate mode of the robot, reduces the force burden of human operating the robot, and guarantees the compliance to the human behavior.

Key words: compliant control; discrete-time human-robot collaboration system; human behavior estimation; online sequential extreme learning machine; prescribed performance

机器人在执行实际任务中需要与人类操作者协作, 以便更灵活地执行任务, 如磨削抛光、分拣装配、手术复健和建筑施工等^[1-5]。在需要人类协作的情况下, 传统的位置控制方法仅让机器人固定地跟

踪预先设定的期望轨迹是不适用的, 而强制修改轨迹又可能会造成严重后果。因此, 机器人的柔顺性至关重要, 具有柔顺性的机器人能够主动顺应人类要求, 从而提高与人类协作时的安全性和灵活性。

收稿日期: 2023-09-18

基金项目: 国家自然科学基金面上项目 (61973257); 四川省自然科学基金面上项目 (2023NSFSC0510)

作者简介: 刘霞, 博士, 教授, 主要从事机器人控制、遥操作技术与工程应用方面的研究。

*通信作者 E-mail: xliuud@163.com

阻抗控制是实现协作机器人柔顺行为的一种有效方法^[6-7]。文献[8]针对2自由度串联机器臂, 提出了一种基于位置的分阶阻抗控制方案, 并对控制器参数进行了优化。文献[9]针对冗余机器臂提出了一种鲁棒集中式控制器, 并利用滑模来补偿未建模的系统动力学, 确保机器人在与环境交互作用中准确执行理想的阻抗。然而, 文献[8-9]的方法都依赖于机器人准确的动力学模型, 需要模型参数的先验知识。为了解决阻抗控制中机器人动力学模型不确定性的问题, 文献[10]提出了一种自适应神经网络指令滤波反演阻抗控制方法, 并使用自适应神经网络算法来估计机器人系统中的不确定动力学模型。文献[11]针对自主打磨机器人提出了一种新型的阻抗控制方法, 使用自适应神经网络在线补偿机器人不确定动力学。然而, 文献[10-11]中基于神经网络学习的方法需要花费较多的计算时间。

与上述方法相比, 时延估计 (time delay estimation, TDE) 作为一种简单且鲁棒性强的估计和补偿机器人不确定动力学的方法已被广泛运用于机器人系统中^[12-14]。在高维度的情况下, TDE 是不受动态系统输入-输出维度影响的方法之一。TDE 只需将系统的输出结果延迟一步, 就足以估计未知的动力系统^[15]。文献[16]针对上肢康复机器人提出了一种基于非线性 TDE 的模型参考自适应阻抗控制器, 使用稳定的参考阻抗模型来控制机器人末端执行器跟踪参考轨迹。文献[17]针对外骨骼机器人提出了基于人类逆动力学的新型二阶滑模控制器, 使用 TDE 来估计不确定动力学。文献[18]针对康复机器人提出了一种新的自适应阻抗, 并结合反演控制和 TDE 以执行被动辅助性康复运动。然而, 文献[16-18]都是通过阻抗控制使机器人根据人类施加的力进行轨迹调整, 属于被动地跟随人类。当人类想要改变运动轨迹时, 机器人就会起到负载的作用, 从而导致需要较大的人机交互力, 这不仅会给人类带来负担, 还可能对机器人系统造成不可逆的损害^[19]。

因此, 考虑机器人主动顺应人类行为是必要的。当人类操纵机器人末端执行器时, 机器人应该检测到人类行为并能根据人类行为更新末端执行器的参考位置, 从而使得机器人在人机协作中可以主动地顺应人类行为, 同时也能减轻人类引导机器人所需的时间和力量负担。文献[20]提出了一种基于反演的方法, 通过收集人类演示数据并将其用于迭代学习, 在执行特定任务时机器人主动调整行

为, 以提高任务执行精度。文献[21]提出了一种点对点运输物体过程中的人机协作方法, 但却并不能运用于实际中常见的空间运动。文献[22]将人类行为视为人机交互力的变化, 并通过设计力估计算法来获得人机交互力。文献[23]将人类行为定量描述为意向方向, 通过分析交互力与人类行为的关系并使用卡尔曼滤波器对其进行建模。然而, 人体的运动行为是时变的未知轨迹, 仅用文献[20-23]中的几种状态或运动方向来表示是不够的。

于是有学者提出将人手模型中的位置或速度轨迹考虑为人类行为。文献[24-25]采用基于径向基函数神经网络 (radial basis function neural network, RBFNN) 的方法来实现对人类行为的估计。然而, RBFNN 的参数选择是一项耗时且困难的工作, 同时存在过拟合和局部极小问题^[26]。文献[27]将力和速度通过模糊逻辑 (fuzzy logic, FL) 转换为定量值, 从而实现对人类行为的估计。然而, FL 同样存在计算复杂度高, 需要花费较多计算资源和时间的问题。为了避免这些问题, 文献[28]提出了一种单隐含层前馈网络 (single-hidden layer feedforward network, SLFN) ——极限学习机 (extreme learning machine, ELM)。在传统 SLFN 基础上, ELM 在训练过程中的输入权值和激活函数的偏置可以随机分配。因此相比于传统的 SLFN 和 RBFNN 等神经网络, ELM 具有计算更简单、效率更高、操作更方便等优点^[29]。文献[30]将 ELM 运用于对人类行为的估计, 并开发了基于模型参考的自适应阻抗控制算法。然而, 人类在合作过程中可能改变其行为, 因此, 如果直接使用 ELM 会导致人类行为发生改变时必须重新对基于大量样本数据进行学习训练。与其他有许多控制参数需要调整的顺序学习算法不同, 在线顺序极限学习机 (online sequential extreme learning machine, OS-ELM) 是 ELM 的在线版本, OS-ELM 只需要指定隐含层节点的数量, 就能够快速训练适应时变的人类行为, 而无需以前的样本数据^[31]。

除了上述讨论的柔顺控制和不确定动力学问题以外, 在实际应用中, 控制算法都是通过数字计算机系统以离散时间来进行采样和计算。但是使用连续时间的控制器在离散化后可能无法保持其固有特性, 导致控制性能下降^[32]。相比而言, 使用离散时间的控制器可以更好地满足数字计算机的工作原理和限制。因此, 本文提出了一种基于在线学习的离散时间人机协作系统预定性能柔顺控制方法。

所提控制方法在降低了计算复杂度的基础上,既能使得机器人末端执行器的跟踪满足预设指标,同时还能保证机器人对人类行为的柔顺性,提高了系统的瞬态和稳态性能。

1 机器人数学模型

首先考虑 n 自由度的非线性机器人动力学连续时间系统方程为^[33]:

$$\mathbf{M}(\mathbf{q}(t))\ddot{\mathbf{q}}(t) + \mathbf{C}(\mathbf{q}(t), \dot{\mathbf{q}}(t))\dot{\mathbf{q}}(t) + \mathbf{G}(\mathbf{q}(t)) = \boldsymbol{\tau}(t) + \mathbf{J}^T \mathbf{h}_b(t) \quad (1)$$

式中, $\mathbf{q}(t)$ 、 $\dot{\mathbf{q}}(t)$ 、 $\ddot{\mathbf{q}}(t) \in \mathbb{R}^{n \times 1}$ 分别为机器人关节连续时间的角位置、速度和加速度; $\mathbf{M}(\mathbf{q}(t)) \in \mathbb{R}^{n \times n}$ 为对称的正定惯性矩阵; $\mathbf{C}(\mathbf{q}(t), \dot{\mathbf{q}}(t)) \in \mathbb{R}^{n \times n}$ 为离心力和哥氏力项; $\mathbf{G}(\mathbf{q}(t)) \in \mathbb{R}^{n \times 1}$ 为重力项; $\boldsymbol{\tau}(t) \in \mathbb{R}^{n \times 1}$ 为机器人的控制力矩; \mathbf{J} 为雅克比矩阵; $\mathbf{h}_b(t) \in \mathbb{R}^{n \times 1}$ 为人机交互力。

将式 (1) 转化为笛卡尔坐标系下的连续时间动力学模型:

$$\mathbf{M}_x(\mathbf{x}(t))\ddot{\mathbf{x}}(t) + \mathbf{C}_x(\mathbf{x}(t), \dot{\mathbf{x}}(t))\dot{\mathbf{x}}(t) + \mathbf{G}_x(\mathbf{x}(t)) = \boldsymbol{\tau}_x(t) + \mathbf{h}_b(t) \quad (2)$$

式中, $\mathbf{x}(t)$ 、 $\dot{\mathbf{x}}(t)$ 、 $\ddot{\mathbf{x}}(t) \in \mathbb{R}^{n \times 1}$ 分别为机器人在笛卡尔坐标系下的位置、速度和加速度。

性质 1^[34]: 存在常数 $\ell_1, \ell_2 \in \mathbb{R}$ 使得惯性矩阵 $\mathbf{M}_x(\mathbf{x}(t))$ 的各特征值 $\lambda_i(\mathbf{M}_x(\mathbf{x}(t)))$ 满足:

$$\ell_1 \leq \lambda_i(\mathbf{M}_x(\mathbf{x}(t))) \leq \ell_2 \quad (3)$$

式中, $\lambda_i(\cdot)$ 表示矩阵 \cdot 的第 i 个特征值。

引入一个正定常数矩阵 $\bar{\mathbf{M}}_x$, 则式 (2) 可重写为:

$$\bar{\mathbf{M}}_x \ddot{\mathbf{x}}(t) + ((\mathbf{M}_x - \bar{\mathbf{M}}_x)\ddot{\mathbf{x}}(t) + \mathbf{C}_x(\mathbf{x}(t), \dot{\mathbf{x}}(t))\dot{\mathbf{x}}(t) + \mathbf{G}_x(\mathbf{x}(t)) - \mathbf{h}_b(t) = \boldsymbol{\tau}_x(t) \quad (4)$$

使用欧拉数值微分方法对式 (4) 的非线性机器人连续模型进行离散化:

$$\begin{cases} \partial \mathbf{x}(k) = \frac{\mathbf{x}(k+1) - \mathbf{x}(k)}{T_s} \\ \partial \partial \mathbf{x}(k) = \frac{\mathbf{x}(k+1) - 2\mathbf{x}(k) + \mathbf{x}(k-1)}{T_s^2} \end{cases} \quad (5)$$

式中, T_s 为样本区间; k 为采样点; $t = kT_s$ 。

设系统输出为 $\mathbf{y}(k) = \partial \mathbf{x}(k)$, 则对应的基于欧拉数值微分的系统模型可以写为:

$$\mathbf{y}(k+1) = \mathbf{y}(k) + T_s \bar{\mathbf{g}} \boldsymbol{\tau}_x(k) - T_s \bar{\mathbf{g}} ((\mathbf{M}_x - \bar{\mathbf{M}}_x) \partial \mathbf{y}(k)) + \mathbf{C}_x(\mathbf{y}(k-1), \mathbf{y}(k)) \mathbf{y}(k) + \mathbf{G}_x(\mathbf{y}(k-1)) - \mathbf{h}_b(k) + \mathbf{d}(k) \quad (6)$$

式中, $\bar{\mathbf{g}} = \bar{\mathbf{M}}_x^{-1}$; $\mathbf{d}(k)$ 为离散误差。

在人机协作任务中, 机器人末端执行器的参考轨迹由人类行为决定。在人类行为作用下, 末端执行器可根据参考阻抗模型得到新的参考轨迹。在笛卡尔坐标系下, 机器人末端执行器的参考阻抗模型一般定义为^[35]:

$$\mathbf{M}_d(\ddot{\mathbf{x}}_d(t) - \ddot{\mathbf{x}}_r(t)) + \mathbf{C}_d(\dot{\mathbf{x}}_d(t) - \dot{\mathbf{x}}_r(t)) + \mathbf{K}_d(\mathbf{x}_d(t) - \mathbf{x}_r(t)) = -\mathbf{h}_b(t) \quad (7)$$

式中, $\mathbf{x}_d(t)$ 为静止位置; $\mathbf{x}_r(t)$ 为参考轨迹; 对角矩阵 \mathbf{M}_d 、 \mathbf{C}_d 、 \mathbf{K}_d 分别为末端执行器所需阻抗的质量矩阵、阻尼矩阵和刚度矩阵, 均为正定矩阵。从式 (7) 中可以看出, 如果 $\mathbf{x}_d(t)$ 距离 $\mathbf{x}_r(t)$ 较远, 则人类需要施加较大的力移动末端执行器。相反, 如果机器人能够理解人类行为, 并相应地改变 $\mathbf{x}_d(t)$, 则人类移动末端执行器会更加轻松, 从而达到柔顺控制的目的。

在 $t = kT_s$ 时刻下所有变量具有固定值, 所以 $\boldsymbol{\tau}_x(k) = \boldsymbol{\tau}_x(t)$, $\mathbf{h}_b(k) = \mathbf{h}_b(t)$, $\mathbf{x}_d(k) = \mathbf{x}_d(t)$, $\mathbf{x}_r(k) = \mathbf{x}_r(t)$ 。

2 离散时间预定性能柔顺控制器设计

如图 1 所示, 针对离散时间人机协作系统, 本文所提的离散时间预定性能柔顺控制采用内外双环的控制结构。外环采用 OS-ELM 对人类行为进行估计并通过参考阻抗模型来获得修正后的参考轨迹, 避免人类行为发生改变时, 需要重新基于大量样本数据进行学习训练。内环通过将预设性能函数规定的跟踪误差约束转化为等效的无约束形式, 根据转化误差设计最终的离散时间控制器, 并采用 TDE 技术估计系统动力学模型的不确定性。

2.1 人类行为估计

如果机器人能够理解人类行为, 将可以实现对人类的主动顺应, 提高交互效率, 减小人类负担, 避免机器人设备损坏。人手模型一般可以表示为弹簧-阻尼系统^[36]:

$$-\mathbf{C}_H \dot{\mathbf{x}}(t) + \mathbf{K}_H(\mathbf{x}_{Hd}(t) - \mathbf{x}(t)) = \mathbf{h}_b(t) \quad (8)$$

式中, 对角矩阵 \mathbf{C}_H 、 \mathbf{K}_H 为人体肢体的惯性矩阵和弹簧矩阵; \mathbf{x}_{Hd} 为人类操作机器人末端执行器的期望位置。同理, $\mathbf{x}_{Hd}(t) = \mathbf{x}_{Hd}(k)$ 。在本文中, 将人类操作机器人末端执行器的期望速度 $\partial \mathbf{x}_{Hd}(k)$ 考虑为人类行为。从人体肢体模型中可以看出, 人类行为 $\partial \mathbf{x}_{Hd}(k)$ 可以通过人机交互力 $\mathbf{h}_b(k)$ 、实际位置 $\mathbf{x}(k)$ 和实际速度 $\partial \mathbf{x}(k)$ 得到:

$$\partial \mathbf{x}_{Hd}(k) = f(\mathbf{h}_b(k), \mathbf{x}(k), \partial \mathbf{x}(k)) \quad (9)$$

式中, $f(\cdot)$ 是一个未知的非线性函数, 这使得估计 $\partial \hat{x}_{\text{Hd}}(k)$ 存在一定困难。因此, 利用具有较高学习速度的 ELM 处理复杂的非线性映射和模式分类。

ELM 作为一种特殊的 SLFN, 具有更简单、效率更高、操作更方便等显著优点。ELM 学习过程具体如下。

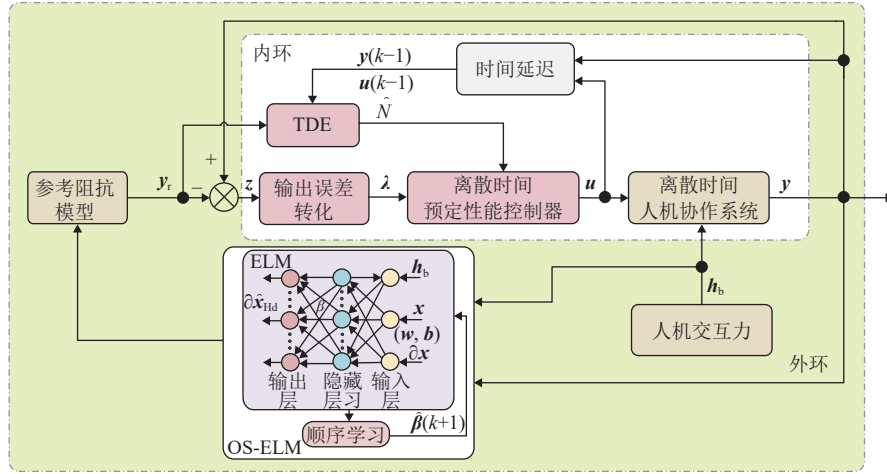


图1 基于在线学习的离散时间人机协作系统预定性能柔顺控制框图

任意选择 N 个样本的训练集 $(\mathbf{X}_u, \boldsymbol{\varpi}_u) \in \mathbb{R}^n \times \mathbb{R}^m$, $\mathbf{X}_u = [X_{u1}, X_{u2}, \dots, X_{un}]^T$ 为输入, $\boldsymbol{\varpi}_u = [\varpi_{u1}, \varpi_{u2}, \dots, \varpi_{um}]^T$ 为输出, 则具有 L 个隐含层节点的 SLFN 可以表示为:

$$\sum_{u=1}^L \beta_u \gamma(\mathbf{W}_u \mathbf{X}_j + b_u) = \varpi_u \quad u = 1, 2, \dots, N \quad (10)$$

式中, $\beta_u = [\beta_{u1}, \beta_{u2}, \dots, \beta_{um}]^T$ 为第 u 个隐含层的输出权重; $\gamma(\cdot)$ 为激活函数; $\mathbf{W}_u = [W_{u1}, W_{u2}, \dots, W_{un}]^T$ 为第 u 个隐含层的输入权重; b_u 为第 u 个隐含层的偏置。

式 (10) 可以简化写为:

$$\mathbf{H}\boldsymbol{\beta} = \boldsymbol{\omega} \quad (11)$$

式中, \mathbf{H} 为隐含层的输出矩阵; $\boldsymbol{\beta}$ 为权值矩阵; $\boldsymbol{\omega}$ 为期望输出矩阵; 分别表示为:

$$\mathbf{H} = \begin{bmatrix} \gamma(\mathbf{W}_1 \mathbf{X}_1 + b_1) \cdots \gamma(\mathbf{W}_L \mathbf{X}_1 + b_L) \\ \vdots \\ \gamma(\mathbf{W}_1 \mathbf{X}_n + b_1) \cdots \gamma(\mathbf{W}_L \mathbf{X}_n + b_L) \end{bmatrix}_{N \times L}$$

$$\boldsymbol{\beta} = [\beta_1^T, \beta_2^T, \dots, \beta_L^T]^T_{L \times m} \quad \boldsymbol{\omega} = [\varpi_1^T, \varpi_2^T, \dots, \varpi_N^T]^T_{N \times m} \quad (12)$$

在训练过程中, \mathbf{W} 、 b 、 $\boldsymbol{\beta}$ 的估计值 $\hat{\mathbf{W}}$ 、 \hat{b} 、 $\hat{\boldsymbol{\beta}}$ 需使得 ELM 的近似误差最小, 即:

$$\|\mathbf{H}(\hat{\mathbf{W}}, \hat{b}, \hat{\boldsymbol{\beta}}) - \boldsymbol{\omega}\| = \min_{\mathbf{W}, b, \boldsymbol{\beta}} \|\mathbf{H}(\mathbf{W}, X, b)\boldsymbol{\beta} - \boldsymbol{\omega}\| \quad (13)$$

通过式 (11) 得到 ELM 需要的输出权值 $\hat{\boldsymbol{\beta}}$ 为:

$$\hat{\boldsymbol{\beta}} = \mathbf{H}^\dagger \boldsymbol{\omega} \quad (14)$$

式中, \mathbf{H}^\dagger 为矩阵 \mathbf{H} 的穆尔-彭罗斯 (Moore-Penrose) 广义逆矩阵。

反向传播 (back propagation, BP) 作为一种基于梯度的学习算法, 经常被用于 SFLN 的训练, 但 BP 存在学习速度慢、局部极小、过度拟合等局限性。ELM 是一种随机分配输入权值和偏置的学习算法, 不需要去调整输入权值和偏置。

然而, 由于人类行为是时变的, 为了避免反复重新进行训练, 本文在传统 ELM 的基础上采用 OS-ELM 进行在线估计。OS-ELM 可以在不需要大量数据的情况下使用新的训练数据集快速训练。

OS-ELM 的学习过程具体如下。

1) 初始化

生成随机输入权重和偏置;

通过式 (12) 计算隐含层初始输出矩阵 $\mathbf{H}(0)$;

计算初始输出权重 $\hat{\boldsymbol{\beta}}(0)$ 如下:

$$\mathbf{P}(0) = (\mathbf{H}(0)^T \mathbf{H}(0))^{-1} \quad (15)$$

$$\hat{\boldsymbol{\beta}}(0) = \mathbf{P}(0) \mathbf{H}(0)^T \boldsymbol{\varpi}(0) \quad (16)$$

通过 $\partial \hat{x}_{\text{Hd}}(0) = \mathbf{H}(0) \hat{\boldsymbol{\beta}}(0)$ 求得 $\partial \hat{x}_{\text{Hd}}(0)$ 。

2) 顺序学习

接收新的样本 $\mathbf{X}(k+1)$, $\boldsymbol{\varpi}(k+1)$;

通过式 (12) 计算隐含层初始输出矩阵 $\mathbf{H}(k+1)$;

计算更新输出权重 $\hat{\boldsymbol{\beta}}(k+1)$;

$$\mathbf{P}(k+1) = \mathbf{P}(k) - \mathbf{P}(k+1) \mathbf{H}(k+1)^T \times (\mathbf{H}(k+1) \mathbf{P}(k) \mathbf{H}(k+1)^T + \mathbf{I})^{-1} \mathbf{H}(k+1) \mathbf{P}(k) \quad (17)$$

$$\hat{\boldsymbol{\beta}}(k+1) = \hat{\boldsymbol{\beta}}(k) + P(k+1)\mathbf{H}(k+1)^T \times (\boldsymbol{\varpi}(k+1) - \mathbf{H}(k+1)\hat{\boldsymbol{\beta}}(k)) \quad (18)$$

通过 $\partial \hat{\mathbf{x}}_{\text{Hd}}(k+1) = \mathbf{H}(k+1)\hat{\boldsymbol{\beta}}(k+1)$ 求得 $\partial \hat{\mathbf{x}}_{\text{Hd}}(k+1)$ ；进入下一次学习。

如式 (14) 所示，ELM 是采用解析解的方式一次性完成所有权重的计算。而如式 (18) 所示，OS-ELM 采用的是顺序学习的方式，只需根据新的样本进行权重递推更新，当前一次迭代的中间结果和新的数据被学习后就不再使用。因此，OS-ELM 在实现在线估计人类行为的同时，能显著降低学习计算复杂度和内存使用量。

2.2 离散时间预定性能控制器设计

为了保证离散时间闭环系统的瞬态和稳态性能，本节设计了一个离散时间预定性能控制器使得末端执行器能够跟踪重建后的参考轨迹。所提控制器可确保跟踪误差能约束到预定性能要求区域内，收敛速度等指标符合预定性能要求。

在 2.1 节中得到了估计的人类行为 $\partial \hat{\mathbf{x}}_{\text{Hd}}$ ，将 $\partial \mathbf{x}_d = \partial \hat{\mathbf{x}}_{\text{Hd}}$ 代入参考阻抗模型式 (7) 获得机器人末端执行器新的参考轨迹 $\mathbf{y}_d(k) = \partial \mathbf{x}_r(k)$ ，则跟踪误差可表示为：

$$\mathbf{z}(k+1) = \mathbf{y}_d(k+1) - \mathbf{y}(k+1) \quad (19)$$

选取跟踪误差预定性能函数为：

$$\boldsymbol{\vartheta}(k+1) = (1-\alpha)\boldsymbol{\vartheta}(k) + \alpha\boldsymbol{\vartheta}_\infty \quad (20)$$

式中， $0 < \alpha < 1$ 为决定性能函数收敛速率的常数；

$\boldsymbol{\vartheta}_\infty = \lim_{k \rightarrow \infty} \boldsymbol{\vartheta}(k)$ 满足 $0 < \boldsymbol{\vartheta}_\infty < \boldsymbol{\vartheta}(0)$ 。

从而跟踪误差预定性能形成了一个约束区域：

$$-\boldsymbol{\vartheta}(k) < \mathbf{z}(k) < \boldsymbol{\vartheta}(k) \quad (21)$$

为了解决该约束控制问题，需要选择一个严格递增函数 $\Theta(\lambda(k))$ 将跟踪误差 $\mathbf{z}(k)$ 转换为无约束的等效形式：

$$\mathbf{z}(k) = \boldsymbol{\vartheta}(k)\Theta(\lambda(k)) \quad (22)$$

式中， $\lambda(k)$ 为转换误差，选取为：

$$\lambda(k) = \Theta^{-1}\left(\frac{\mathbf{z}(k)}{\boldsymbol{\vartheta}(k)}\right) = \frac{1}{2} \ln\left(\frac{\boldsymbol{\vartheta}(k) + \mathbf{z}(k)}{\boldsymbol{\vartheta}(k) - \mathbf{z}(k)}\right) \quad (23)$$

利用转换误差 $\lambda(k)$ 构建滑动变量如下：

$$\mathbf{s}(k+1) = \lambda(k+1) + r\lambda(k) \quad (24)$$

式中， $0 < r < 1$ 为常数。

将式 (23) 代入式 (24)，可得：

$$\mathbf{s}(k+1) = \frac{1}{2} \ln\left(\frac{\boldsymbol{\vartheta}(k+1) + \mathbf{z}(k+1)}{\boldsymbol{\vartheta}(k+1) - \mathbf{z}(k+1)}\right) + r\lambda(k) \quad (25)$$

则等效控制律 $\boldsymbol{\tau}_{\text{eq}}(k)$ 可由 $\mathbf{s}(k+1) = 0$ 得到，此时：

$$\frac{\boldsymbol{\vartheta}(k+1) + \mathbf{z}(k+1)}{\boldsymbol{\vartheta}(k+1) - \mathbf{z}(k+1)} = e^{-2r\lambda(k)} \quad (26)$$

式中， e 为自然底数。

将式 (6) 和式 (19) 代入式 (25)，得：

$$\begin{aligned} \mathbf{z}(k+1) = & -\frac{1 - e^{-2r\lambda(k)}}{1 + e^{-2r\lambda(k)}} \boldsymbol{\vartheta}(k+1) = \\ & \mathbf{y}_d(k+1) - \mathbf{y}(k) - T_s \bar{\mathbf{g}} \boldsymbol{\tau}_x(k) + T_s \bar{\mathbf{g}} (((\mathbf{M}_x - \bar{\mathbf{M}}_x) \partial \mathbf{y}(k)) + \\ & \mathbf{C}_x(\mathbf{y}(k-1), \mathbf{y}(k)) \mathbf{y}(k) + \mathbf{G}_x(\mathbf{y}(k-1)) - \mathbf{h}_b(k) + \mathbf{d}(k)) \end{aligned} \quad (27)$$

对式 (27) 进行移项，可得等效控制律 $\boldsymbol{\tau}_{\text{eq}}(k)$ ：

$$\begin{aligned} \boldsymbol{\tau}_{\text{eq}}(k) = & \frac{1}{T_s \bar{\mathbf{g}}} \left(\mathbf{y}_d(k+1) - \mathbf{y}(k) + \frac{1 - e^{-2r\lambda(k)}}{1 + e^{-2r\lambda(k)}} \right) + \\ & (((\mathbf{M}_x - \bar{\mathbf{M}}_x) \partial \mathbf{y}(k)) + \mathbf{C}_x(\mathbf{y}(k-1), \mathbf{y}(k)) \mathbf{y}(k) + \\ & \mathbf{G}_x(\mathbf{y}(k-1)) - \mathbf{h}_b(k) + \mathbf{d}(k)) \end{aligned} \quad (28)$$

由于参数变化、未知动态引起末端执行器系统动力学的不确定性，式 (28) 中使用到的系统动力学模型参数在实际中是时变、非线性的，因此很难获得。本文采用简单鲁棒的 TDE 技术来估计机器人末端执行器的未知动力学。

首先，将机器人末端执行器的未知动力学（包括离散误差）集总考虑为：

$$\begin{aligned} \mathbf{N}_x(k) = & (((\mathbf{M}_x - \bar{\mathbf{M}}_x) \partial \mathbf{y}(k)) + \mathbf{C}_x(\mathbf{y}(k-1), \mathbf{y}(k)) \mathbf{y}(k) + \\ & \mathbf{G}_x(\mathbf{y}(k-1)) - \mathbf{h}_b(k) + \mathbf{d}(k)) \end{aligned} \quad (29)$$

TDE 技术是利用系统上一采样时刻输入输出来估计当前时刻系统的所有非线性项 $\mathbf{N}_x(k)$ ，得到其估计值 $\hat{\mathbf{N}}_x(k)$ ：

$$\begin{aligned} \mathbf{N}_x(k) \approx \hat{\mathbf{N}}_x(k) \triangleq \mathbf{N}_x(k-1) = \\ \frac{1}{T_s \bar{\mathbf{g}}} (\mathbf{y}(k-1) - \mathbf{y}(k)) + \boldsymbol{\tau}_x(k-1) \end{aligned} \quad (30)$$

在连续系统中，TDE 需要依赖于加速度反馈。虽然可以通过测量位置、速度计算其微分来获得所需要的加速度，但微分本质上是将噪声放大，因此可能无法从有噪声的测量中获得良好的加速度反馈。低质量的加速度反馈会导致其性能有所下降^[37]。而从式 (30) 中可以看出，在离散系统中采用 TDE 只需要速度、力矩就能得到 $\hat{\mathbf{N}}_x$ ，不需要额外的加速度反馈。

TDE 误差表示为：

$$\boldsymbol{\varepsilon}(k) = \mathbf{N}_x(k) - \hat{\mathbf{N}}_x(k) \quad (31)$$

引理 1^[38] 令 $\mathbf{g}(x) = \mathbf{M}_x^{-1}$ ，在选择 $\bar{\mathbf{g}}$ 时若满足

以下条件:

$$\|I - \mathbf{g}(x)\bar{\mathbf{g}}^{-1}\| < 1 \quad (32)$$

则 TDE 误差 $\boldsymbol{\varepsilon}(k)$ 是有界的, 即 $\|\boldsymbol{\varepsilon}\| \leq \Lambda$, Λ 是一个未知的正常数。其中 I 表示相应维度的单位矩阵。

通过性质 1 可知 $\frac{1}{\ell_1} \leq \lambda_i(\mathbf{g}(x)) \leq \frac{1}{\ell_2}$, 虽然 $\mathbf{g}(x)$ 不确定, 但可以选择较大的 $\bar{\mathbf{g}}$ 来实现上述条件。

将式 (31) 代入式 (28), 可得到等效控制器:

$$\boldsymbol{\tau}_{\text{eq}}(k) = \frac{1}{T_s \bar{\mathbf{g}}} \left(\mathbf{y}_d(k+1) - \mathbf{y}(k) + \frac{1 - e^{-2r\lambda(k)}}{1 + e^{-2r\lambda(k)}} \right) + \hat{\mathbf{N}}_x(k) + \boldsymbol{\varepsilon}(k) \quad (33)$$

式中, TDE 误差 $\boldsymbol{\varepsilon}(k)$ 未知, 等效控制器 $\boldsymbol{\tau}_{\text{eq}}(k)$ 只有在 $\boldsymbol{\varepsilon}(k) = 0$ 时才能保证系统沿着滑模面运动。于是需要引入一个用于提高控制器鲁棒性的非线性切换项 $\boldsymbol{\tau}_s(k)$:

$$\boldsymbol{\tau}_s(k) = \mathbf{K}_s \text{sign}(\mathbf{s}(k)) \quad (34)$$

式中, \mathbf{K}_s 为增益项, 其取值范围将在闭环系统性能分析中给出。从而得到最终的离散时间预定性能柔顺控制器:

$$\boldsymbol{\tau}_x(k) = \frac{1}{T_s \bar{\mathbf{g}}} \left(\mathbf{y}_d(k+1) - \mathbf{y}(k) + \frac{1 - e^{-2r\lambda(k)}}{1 + e^{-2r\lambda(k)}} \right) + \hat{\mathbf{N}}_x(k) + \mathbf{K}_s \text{sign}(\mathbf{s}(k)) \quad (35)$$

可以看出式 (35) 中不包含机器人系统模型参数, 且采用的都是转化误差 $\lambda(k)$ 。不需要计算系统的未知动力学, 只需要系统的输出反馈, 从而在极大减少计算量的基础上, 保证跟踪误差约束到由预定性能函数式 (20) 预先确定的任意小的区域式 (21) 内。且收敛速度等系统瞬态指标符合预定的要求, 即被控对象同时符合瞬态和稳态性能要求, 进而提升系统的控制性能。

3 闭环系统性能分析

定理 1 考虑对笛卡尔坐标系下的机器人末端执行器系统式 (2) 进行离散化得到的离散系统模型式 (6), 利用 TDE 式 (30) 估计机器人的集总未知动力学, 并采用离散时间预定性能控制器式 (35), 则能保证滑动变量式 (24) 在预定性能函数式 (20) 下可以稳定在边界内。其中增益 \mathbf{K}_s 的选择满足以下条件:

$$\begin{cases} \Lambda < \mathbf{K}_s < \frac{\boldsymbol{\vartheta}_\infty}{(1 + e^{-2r\lambda(k)})/e^{-2r\lambda(k)}} & \mathbf{s}(k) > 0 \\ \Lambda < \mathbf{K}_s < \frac{\boldsymbol{\vartheta}_\infty}{1 + e^{-2r\lambda(k)(k)}} & \mathbf{s}(k) < 0 \end{cases} \quad (36)$$

证明:

对式 (26) 进行移项并结合式 (23), 得:

$$r\lambda(k) = \frac{1}{2} \ln \left(\frac{1}{e^{-2r\lambda(k)}} \right) \quad (37)$$

将式 (37) 代入式 (25), 则有:

$$\begin{aligned} \mathbf{s}(k+1) &= \frac{1}{2} \ln \left(\frac{\mathbf{g}(k+1) + \mathbf{z}(k+1)}{\mathbf{g}(k+1) - \mathbf{z}(k+1)} \right) + \frac{1}{2} \ln \left(\frac{1}{e^{-2r\lambda(k)}} \right) = \\ &= \frac{1}{2} \ln \left(\frac{(1 + e^{-2r\lambda(k)})\boldsymbol{\vartheta}(k+1) - (1 - e^{-2r\lambda(k)})\boldsymbol{\vartheta}(k+1)}{(1 + e^{-2r\lambda(k)})\boldsymbol{\vartheta}(k+1) + (1 - e^{-2r\lambda(k)})\boldsymbol{\vartheta}(k+1)} \right) = \\ &= \frac{-\left(1 + e^{-2r\lambda(k)}\right)T_s \bar{\mathbf{g}}(\mathbf{K}_s \text{sign}(\mathbf{s}(k)) - \boldsymbol{\varepsilon}(k)) \frac{1}{e^{-2r\lambda(k)}}}{\left(1 + e^{-2r\lambda(k)}\right)T_s \bar{\mathbf{g}}(\mathbf{K}_s \text{sign}(\mathbf{s}(k)) - \boldsymbol{\varepsilon}(k)) \frac{1}{e^{-2r\lambda(k)}}} \\ &= \frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1) - \left(1 + e^{-2r\lambda(k)}\right)T_s \bar{\mathbf{g}}(\mathbf{K}_s \text{sign}(\mathbf{s}(k)) - \boldsymbol{\varepsilon}(k))}{2\boldsymbol{\vartheta}(k+1) + \left(1 + e^{-2r\lambda(k)}\right)T_s \bar{\mathbf{g}}(\mathbf{K}_s \text{sign}(\mathbf{s}(k)) - \boldsymbol{\varepsilon}(k))} \right) \end{aligned} \quad (38)$$

当 $\mathbf{s}(k) > 0$ 时, 将 $\text{sign}(\mathbf{s}(k)) = 1$ 代入式 (38), 可得:

$$\begin{aligned} \mathbf{s}(k+1) &= \\ &= \frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1) - \left(1 + e^{-2r\lambda(k)}\right)T_s \bar{\mathbf{g}}(\mathbf{K}_s - \boldsymbol{\varepsilon}(k))}{2\boldsymbol{\vartheta}(k+1) + \left(1 + e^{-2r\lambda(k)}\right)T_s \bar{\mathbf{g}}(\mathbf{K}_s - \boldsymbol{\varepsilon}(k))} \right) \end{aligned} \quad (39)$$

将式 (36) 代入式 (39), 得:

$$\begin{aligned} 2\boldsymbol{\vartheta}(k+1) - \boldsymbol{\vartheta}_\infty + T_s \bar{\mathbf{g}} \left(\frac{1 + e^{-2r\lambda(k)}}{e^{-2r\lambda(k)}} \right) \Lambda &< \\ 2\boldsymbol{\vartheta}(k+1) - \left(\frac{1 + e^{-2r\lambda(k)}}{e^{-2r\lambda(k)}} \right) T_s \bar{\mathbf{g}}(\mathbf{K}_s - \boldsymbol{\varepsilon}(k)) &< \\ 2\boldsymbol{\vartheta}(k+1) & \end{aligned} \quad (40)$$

$$2\boldsymbol{\vartheta}(k+1) < 2\boldsymbol{\vartheta}(k+1) + (1 + e^{-2r\lambda(k)})T_s \bar{\mathbf{g}}(\mathbf{K}_s - \boldsymbol{\varepsilon}(k)) < 2\boldsymbol{\vartheta}(k+1) + T_s \bar{\mathbf{g}}e^{-2r\lambda(k)}\boldsymbol{\vartheta}_\infty - (1 + e^{-2r\lambda(k)})\Lambda \quad (41)$$

$$\frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1) - \boldsymbol{\vartheta}_\infty - T_s \bar{\mathbf{g}} \left(\frac{1 + e^{-2r\lambda(k)}}{e^{-2r\lambda(k)}} \right) \Lambda}{2\boldsymbol{\vartheta}(k+1) + T_s \bar{\mathbf{g}}e^{-2r\lambda(k)}\boldsymbol{\vartheta}_\infty - (1 + e^{-2r\lambda(k)})\Lambda} \right) <$$

$$\mathbf{s}(k+1) < \frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1)}{2\boldsymbol{\vartheta}(k+1)} \right) = 0 \quad (42)$$

当 $\mathbf{s}(k) < 0$ 时, 同理可得:

$$0 < \mathbf{s}(k+1) <$$

$$\frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1) + \boldsymbol{\vartheta}_\infty / e^{-2r\lambda(k)} + T_s \bar{\mathbf{g}} \left(\frac{1 + e^{-2r\lambda(k)}}{e^{-2r\lambda(k)}} \right) \Lambda}{2\boldsymbol{\vartheta}(k+1) - \boldsymbol{\vartheta}_\infty - T_s \bar{\mathbf{g}}(1 + e^{-2r\lambda(k)})\Lambda} \right) \quad (43)$$

结合式 (42) 和式 (43), 得:

$$\begin{aligned} \frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1) - \boldsymbol{\vartheta}_\infty - T_s \bar{\mathbf{g}} \left(\frac{1 + e^{-2r\lambda(k)}}{e^{-2r\lambda(k)}} \right) \Lambda}{2\boldsymbol{\vartheta}(k+1) + T_s \bar{\mathbf{g}}e^{-2r\lambda(k)}\boldsymbol{\vartheta}_\infty - (1 + e^{-2r\lambda(k)})\Lambda} \right) &< \\ \mathbf{s}(k+1) &< \\ \frac{1}{2} \ln \left(\frac{2\boldsymbol{\vartheta}(k+1) + \boldsymbol{\vartheta}_\infty / e^{-2r\lambda(k)} + T_s \bar{\mathbf{g}} \left(\frac{1 + e^{-2r\lambda(k)}}{e^{-2r\lambda(k)}} \right) \Lambda}{2\boldsymbol{\vartheta}(k+1) - \boldsymbol{\vartheta}_\infty - T_s \bar{\mathbf{g}}(1 + e^{-2r\lambda(k)})\Lambda} \right) & \end{aligned} \quad (44)$$

从式 (44) 可以得到, 滑动变量 $s(k+1)$ 在预定性能函数式 (20) 下是有界的。由此定理 1 得证。

4 仿真验证

为了验证本文方法的有效性和优越性, 采用如图 2 所示的人机协作系统进行仿真验证, 并将本文方法与文献 [22]、文献 [30] 方法和传统简单阻抗方法进行了对比。




图 2 人机协作系统示意图

机器人的模型如下^[39]:

$$\begin{aligned} \mathbf{M}(\mathbf{q}) &= \begin{bmatrix} m_1 + m_2 + 2m_3 \cos q_2 & m_2 + m_3 \cos q_2 \\ m_2 + m_3 \cos q_2 & m_2 \end{bmatrix} \\ \mathbf{C}(\mathbf{q}, \dot{\mathbf{q}}) &= \begin{bmatrix} -m_2 \dot{q}_2 \sin q_2 & -m_3 (\dot{q}_1 + \dot{q}_2) \sin q_2 \\ m_3 \dot{q}_1 \sin q_2 & 0 \end{bmatrix} \\ \mathbf{G}(\mathbf{q}) &= \begin{bmatrix} m_4 g \cos q_1 + m_5 g \cos (q_1 + q_2) \\ m_5 g \cos (q_1 + q_2) \end{bmatrix} \\ \mathbf{J}(\mathbf{q}) &= \begin{bmatrix} -\sin q_1 - \sin (q_1 + q_2) & -\sin (q_1 + q_2) \\ \cos q_1 + \cos (q_1 + q_2) & \cos (q_1 + q_2) \end{bmatrix} \end{aligned} \quad (45)$$

模型中的参数 m_i 由 $\mathbf{M} = \mathbf{P} + p_l \mathbf{L}$ 给出:

$$\begin{aligned} \mathbf{M} &= [m_1 \ m_2 \ m_3 \ m_4 \ m_5]^T \\ \mathbf{P} &= [p_1 \ p_2 \ p_3 \ p_4 \ p_5]^T \\ \mathbf{L} &= [l_1^2 \ l_2^2 \ l_1 l_2 \ l_1 \ l_2]^T \end{aligned} \quad (46)$$

式中, q_1 、 q_2 分别为机器人关节 1 和关节 2 的角度位置; \dot{q}_1 、 \dot{q}_2 分别为关节 1 和关节 2 的角速度; $p_l = 0.5$ 为负载, $l_1 = l_2 = 1$ 为关节 1 和关节 2 的长度; $g = 9.8$ 为重力加速度; $\mathbf{P} = [1.66 \ 0.42 \ 0.63 \ 3.75 \ 1.25]^T$ 为机器人的参数向量。

采样时间 $T_s = 0.001$ s, 参考阻抗模型的参数设为 $\mathbf{M}_d = [0.2 \ 0; 0 \ 0.2]$, $\mathbf{C}_d = [3 \ 0; 0 \ 3]$, $\mathbf{K}_d = [2 \ 0; 0 \ 2]$, 人类行为设为 $\delta \mathbf{x}_{\text{Hd}}(k) = \begin{bmatrix} 0.4 \cos(2kT_s) \\ \frac{0.8}{1 + (2kT_s)^2} \end{bmatrix}$, $\mathbf{y}(0) = [0; 0]$, $\boldsymbol{\tau}_x(0) = [0; 0]$ 。

参数设置为: $\bar{\mathbf{M}}_x = [0.2 \ 0; 0 \ 0.1]$, $\boldsymbol{\alpha} = [0.8 \ 0; 0 \ 0.9]$, $\mathbf{r} = [0.8 \ 0; 0 \ 0.9]$, $\mathbf{K}_s = [0.001 \ 0; 0 \ 0.001]$, $\boldsymbol{\vartheta}_\infty = [0.005; 0.005]$ 。误差转换函数初始值设为 $\boldsymbol{\vartheta}(0) = [0.5; 0.5]$, 隐含层节点 $L = 60$ 。

对比结果如图 3~图 8 所示。由于本文是将人

手模型中的期望速度考虑为人类行为, 而文献 [22] 方法和传统阻抗方法并没有考虑对人类期望速度的估计, 因此图 3 和图 4 先对本文方法与文献 [30] 方法进行了比较。图 3 为人类行为估计结果, 可以看出本文采用 OS-ELM 和文献 [30] 采用 ELM 来估计人类行为都可以得到较准确的结果。但是, 从图 4 控制方法的训练时间可以看出本文方法由于采用 OS-ELM 不需要使用大量数据集, 因此训练时间更短, 而文献 [30] 中使用传统 ELM 方法依赖于大量数据集, 因此训练时间更长。





图 3 人类行为估计




图 4 控制方法的训练、测试时间

图 5 和图 6 为机器人末端执行器跟踪误差图, 可以看出在 4 种控制方法下, 机器人末端执行器虽然都能实现对重建后参考轨迹的跟踪, 且跟踪误差都稳定在 0 附近。但是, 相比于其他 3 种方法, 本文方法由于采用了预定性能控制, 其跟踪误差在预定时间内就能快速收敛, 且跟踪误差始终位于预定性能边界内, 因此可以满足预定性能要求。从图 6 跟踪误差局部放大图中可以更加清晰地看出, 所提方法的跟踪误差收敛最快, 且始终都满足预定性能要求。而文献 [22] 方法、文献 [30] 方法和传统简单阻抗方法由于没有考虑预定性能, 跟踪误差收敛较慢, 且跟踪误差超出了预定性能边界。

图 7 为本文方法、文献 [22] 方法、文献 [30]

方法和传统简单阻抗方法的控制力矩。本文方法在初始跟踪误差较大的情况下, 控制力矩迅速调整使得跟踪误差快速收敛, 从而在预定时间内快速到达稳定状态。此外还可以看到在 4 种方法中本文方法的控制力矩最为平滑, 表明所提方法有效地提升了系统的瞬态和稳态性能。

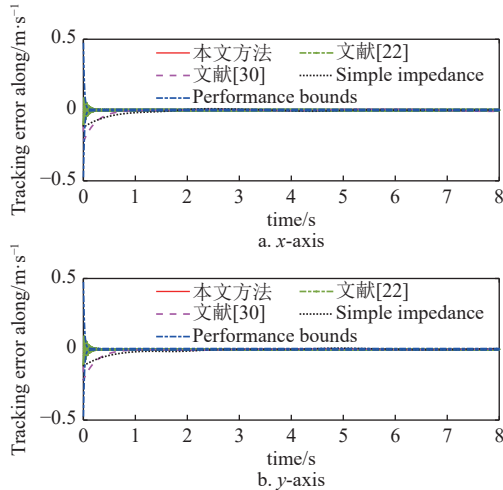


图 5 机器人末端执行器跟踪误差

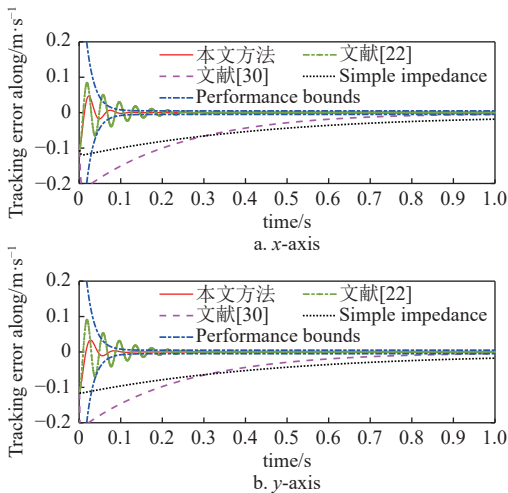


图 6 机器人末端执行器跟踪误差局部放大

图 8 为 4 种方法的实际的人机交互力, 由于文献 [22] 是直接将人机交互力考虑为人类行为, 而传统阻抗并没有考虑人类行为对交互力的影响, 因此本文所提方法和文献 [30] 方法所需人机交互力要小于文献 [22] 方法和传统阻抗方法。此外, 由于本文方法还考虑了预定性能, 使得机器人末端执行器能够快速收敛到期望阻抗, 因此所需的人机交互力小于文献 [30] 方法的人机交互力, 是 4 种方法中人机交互力最小的, 这表明本文方法有效地减轻了人类引导机器人所需要的力量负担, 保证了人

机协作的柔顺性。

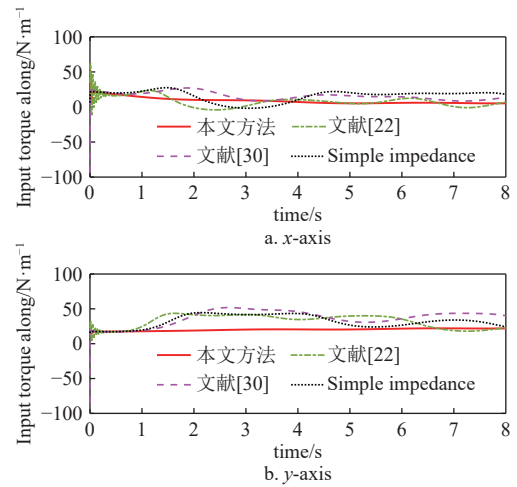


图 7 控制力矩

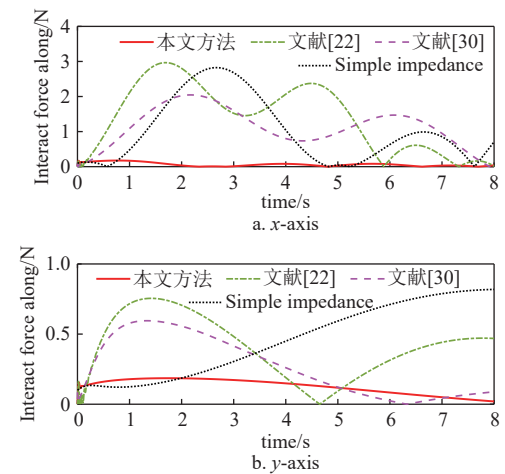


图 8 人机交互力

综上, 得益于人类行为估计和预定性能控制, 采用本文所提方法时机器人末端执行器可以主动快速地顺应人类行为, 从而使得人类的操作负担减小, 且表现出较高的柔顺性和良好的跟踪性能。

5 结束语

本文针对离散时间人机协作系统, 提出了一种基于在线学习的预定性能柔顺控制方法。本方法采用了内外双环控制结构, 在外环利用 OS-ELM 估计人类行为, 并结合参考阻抗模型来重建机器人末端执行器参考轨迹。在内环建立了离散时间预定性能控制, 并利用 TDE 来估计机器人复杂的系统动力学。本方法在减小计算复杂度和内存占用的基础上, 能够有效估计人类行为从而使得人机协作更加柔顺, 且保证系统满足预定性能。然而在实际中, 人机协作系统可能同时还会与环境交互, 如何保证

人、机器人、环境这三者安全且准确地交互控制将作为下一步的研究工作。

参考文献

- [1] ZHU Y H, WU Q C, CHEN B, et al. Physical human-robot interaction control of variable stiffness exoskeleton with sEMG-based torque estimation[J]. *IEEE Transactions on Industrial Informatics*, 2023, 19(10): 10601-10612.
- [2] 薛智慧, 刘金国. 空间机械臂操控技术研究综述[J]. *机器人*, 2022, 44(1): 107-128.
XUE Z H, LIU J G. Review of space manipulator control technologies[J]. *Robot*, 2022, 44(1): 107-128.
- [3] 王艺霖, 邱静, 黄瑞, 等. 人机协同智能系统及其临床应用[J]. *电子科技大学学报*, 2020, 49(4): 481-489.
WANG Y L, QIU J, HUANG R, et al. Human-robot collaborative intelligent system and its clinical applications[J]. *Journal of University of Electronic Science and Technology of China*, 2020, 49(4): 481-489.
- [4] KIM S, PEAVY M, HUANG P C, et al. Development of BIM-integrated construction robot task planning and simulation system[J]. *Automation in Construction*, 2021, 127: 103720.
- [5] LENG Y, SHI X Y, HIROATSU F, et al. Automated construction for human-robot interaction in wooden buildings: Integrated robotic construction and digital design of iSMART wooden Arches[J]. *Journal of Field Robotics*, 2023, 40(4): 810-827.
- [6] LEICA P, ROBERTI F, MONLLOR M, et al. Control of bidirectional physical human-robot interaction based on the human intention[J]. *Intelligent Service Robotics*, 2017, 10(1): 31-40.
- [7] HOGAN N. Impedance control: An approach to manipulation: Part I—Theory[J]. *Journal of Dynamic Systems, Measurement, and Control*, 1985, 107(1): 1-7.
- [8] KIZIR S, ELŞAVI A. Position-based fractional-order impedance control of a 2 DOF serial manipulator[J]. *Robotica*, 2021, 39(9): 1560-1574.
- [9] NICOLIS D, ALLEVI F, ROCCO P. Operational space model predictive sliding mode control for redundant manipulators[J]. *IEEE Transactions on Robotics*, 2020, 36(4): 1348-1355.
- [10] LIN G R, SHAN B Q, MA Y M, et al. Adaptive neural network command filtered backstepping impedance control for uncertain robotic manipulators with disturbance observer[J]. *Transactions of the Institute of Measurement and Control*, 2022, 44(4): 799-808.
- [11] HUO Y X, LI P, CHEN D C, et al. Model-free adaptive impedance control for autonomous robotic sanding[J]. *IEEE Transactions on Automation Science and Engineering*, 2022, 19(4): 3601-3611.
- [12] ZHANG X, LIU J G, TONG Y C, et al. Attitude decoupling control of semifloating space robots using time-delay estimation and supertwisting control[J]. *IEEE Transactions on Aerospace and Electronic Systems*, 2021, 57(6): 4280-4295.
- [13] JIN M L, LEE J, SEO K H, et al. Self-tuning control for articulated robots using the plestan's method[J]. *International Journal of Precision Engineering and Manufacturing*, 2021, 22(4): 557-566.
- [14] BRAHMI B, DRISCOLL M, LARAKI M H, et al. Adaptive high-order sliding mode control based on quasi-time delay estimation for uncertain robot manipulator[J]. *Control Theory and Technology*, 2020, 18(3): 279-292.
- [15] YUCEF-TOUMI K, ITO O. A time delay controller for systems with unknown dynamics[C]//Proceedings of the 1988 American Control Conference. New York: IEEE, 1988: 904-911.
- [16] OMRANI J, MOGHADDAM M M. Nonlinear time delay estimation based model reference adaptive impedance control for an upper-limb human-robot interaction[J]. *Proceedings of the Institution of Mechanical Engineers Part H, Journal of Engineering in Medicine*, 2022, 236(3): 385-398.
- [17] BRAHMI B, DRISCOLL M, EL BOJAIRAMI I K, et al. Novel adaptive impedance control for exoskeleton robot for rehabilitation using a nonlinear time-delay disturbance observer[J]. *ISA Transactions*, 2021, 108: 381-392.
- [18] BRAHMI B, SAAD M, BRAHMI A, et al. Compliant control for wearable exoskeleton robot based on human inverse kinematics[J]. *International Journal of Advanced Robotic Systems*, 2018, 15(6): 1-18.
- [19] HUO Y X, LI X, ZHANG X, et al. Adaptive intention-driven variable impedance control for wearable robots with compliant actuators[J]. *IEEE Transactions on Control Systems Technology*, 2023, 31(3): 1308-1323.
- [20] WARRIER R B, DEVASIA S. Iterative learning from novice human demonstrations for output tracking[J]. *IEEE Transactions on Human-Machine Systems*, 2016, 46(4): 510-521.
- [21] CORTEVILLE B, AERTBELIEN E, BRUYNINCKX H, et al. Human-inspired robot assistant for fast point-to-point movements[C]//Proceedings of the IEEE International Conference on Robotics and Automation. New York: IEEE, 2007: 3639-3644.
- [22] MA Z Q, LIU Z X, HUANG P F. Discrete-time practical robotic control for human-robot interaction with state constraint and sensorless force estimation[J]. *ISA Transactions*, 2022, 129: 659-674.
- [23] WAKITA K, HUANG J, DI P, et al. Human-walking-intention-based motion control of an omnidirectional-type cane robot[J]. *ASME Transactions on Mechatronics*, 2013, 18(1): 285-296.
- [24] YAN H, HAN M, YANG R X, et al. Research on intention recognition method based on radial basis function neural network[J]. *Information Technology and Control*, 2019, 48(4): 637-647.
- [25] DONG B, WANG Y X, CHEN J C, et al. Decentralized robust interaction control of modular robot manipulators via harmonic drive compliance model-based human motion intention identification[J]. *Complex & Intelligent Systems*, 2023, 9(2): 1247-1263.
- [26] HUANG G, HUANG G B, SONG S J, et al. Trends in

- extreme learning machines: A review[J]. *Neural Networks*, 2015, 61: 32-48.
- [27] HAMAD Y M, AYDIN Y, BASDOGAN C. Adaptive human force scaling via admittance control for physical human-robot interaction[J]. *IEEE Transactions on Haptics*, 2021, 14(4): 750-761.
- [28] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: Theory and applications[J]. *Neurocomputing*, 2006, 70(1/2/3): 489-501.
- [29] HU Y H, WANG H, CAO Z W, et al. Extreme-learning-machine-based FNTSM control strategy for electronic throttle[J]. *Neural Computing and Applications*, 2020, 32(18): 14507-14518.
- [30] KHAN A M, YUN D W, ZUHAIB K M, et al. Estimation of Desired Motion Intention and compliance control for upper limb assist exoskeleton[J]. *International Journal of Control, Automation and Systems*, 2017, 15(2): 802-814.
- [31] LIANG N Y, HUANG G B, SARATCHANDRAN P, et al. A fast and accurate online sequential learning algorithm for feedforward networks[J]. *IEEE Transactions on Neural Networks*, 2006, 17(6): 1411-1423.
- [32] KANG S Z, WU H T, YANG X L, et al. Discrete-time predictive sliding mode control for a constrained parallel micropositioning piezostage[J]. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 2022, 52(5): 3025-3036.
- [33] YU X B, HE W, LI Y N, et al. Bayesian estimation of human impedance and motion intention for human-robot collaboration[J]. *IEEE Transactions on Cybernetics*, 2021, 51(4): 1822-1834.
- [34] ROY S, BALDI S, LI P, et al. Artificial-delay adaptive control for underactuated Euler-Lagrange robotics[J]. *ASME Transactions on Mechatronics*, 2021, 26(6): 3064-3075.
- [35] BRAHMI B, EL BOJAIRAMI I, LARAKI M H, et al. Impedance learning control for physical human-robot cooperative interaction[J]. *Mathematics and Computers in Simulation*, 2021, 190: 1224-1242.
- [36] LI Y N, GE S S. Human-robot collaboration based on motion intention estimation[J]. *ASME Transactions on Mechatronics*, 2014, 19(3): 1007-1014.
- [37] WANG H, SU Y X. Differentiator-based time delay control for uncertain robot manipulators[J]. *Asian Journal of Control*, 2023, 25(1): 485-496.
- [38] WANG Y C, LEIBOLD M, LEE J, et al. Incremental model predictive control exploiting time-delay estimation for a robot manipulator[J]. *IEEE Transactions on Control Systems Technology*, 2022, 30(6): 2285-2300.
- [39] 刘金琨. 机器人控制系统的设计与 MATLAB 仿真: 基本设计方法[M]. 2 版. 北京: 清华大学出版社, 2022.
- LIU J K. Robot control system design and MATLAB simulation[M]. 2nd ed. Beijing: Tsinghua University Press, 2022.

编辑 税红