高技术通讯 2024 年 第 34 卷 第 11 期:1189-1199

doi:10.3772/j.issn.1002-0470.2024.11.006

基于 BLF 的变阻抗约束人机交互控制①

禹鑫燚② 史栓武 魏 岩 欧林林③

(浙江工业大学信息工程学院 杭州 310023)

摘 要 阻抗控制是一种广泛用于人机交互(HRI)的柔顺控制方法,它调节了机器人的跟踪精度和与环境接触的柔顺性。然而,传统的阻抗控制受限于阻抗参数恒定,很难适用于复杂的人机交互任务。为了解决人机交互中领导者与跟随者角色切换问题,本文提出了一种基于障碍李雅普诺夫函数(BLF)的变阻抗约束人机交互控制方法。首先,建立一种新的阻抗模型,将阻抗参数作为新的阻抗系统控制输入,同时将具有阻抗约束的变阻抗控制器设计问题转换成为一个可以求解的二次规划问题。其次,设计了一个基于 BLF 的自适应神经网络约束控制器来解决跟踪控制问题,同时该控制器保证了误差信号位于约束空间内,其中径向基神经网络用来补偿机器人动力学的不确定性同时保证了跟踪性能,闭环系统的稳定性通过李雅普诺夫稳定性定理进行了证明。最后,通过 2 个仿真案例验证了所提方法的有效性。

关键词 人机交互(HRI);变阻抗控制;模型预测控制;障碍李雅普诺夫函数(BLF);神经网络(NN)

近年来,随着社会的需要、智能控制和机器学习技术的发展,越来越多的机器人逐渐从结构化的工厂环境走进人们日常生活,如医疗、康复、装配等人机协作场景,交互控制技术的研究变得越来越重要。

阻抗控制作为一种可靠的控制方法被广泛运用于人机交互(human-robot interaction,HRI)控制,阻抗控制的目标是根据给定的质量-弹簧-阻尼系统,使得机器人的行为与环境适应[1]。常用的阻抗控制方法为阻抗参数固定的恒阻抗控制,它的阻抗参数一般根据应用场景及行业经验来进行整定,这种方法控制结构单一,一般用于简单的结构化任务。然而,在许多工作场景中,机器人往往需要在任务执行的过程中改变它们的阻抗,例如人机协作装配场景,机器人需要在装配任务中根据与人类的交互来调整刚度[2]。

变阻抗控制作为一种灵活高效的阻抗控制方法,能够自适应地调节机器人阻抗参数,处理一些更复杂的人机交互场景,因此,近年来许多学者对变阻抗控制算法进行了研究[3]。文献[4]设计了一个贝叶斯估计器来估计人类刚度以确定机器人的刚度。文献[5]采用最小二乘法学习人类的阻抗信息并调整机器人的阻抗。文献[6]设计了一种改进的高斯混合模型(Gaussian mixture model,GMM)与高斯混合回归(Gaussian mixture regression,GMR)算法,将人体阻抗控制率传递给机器人。以上变阻抗控制方法旨在将人类阻抗转化为机器人的阻抗,其中可能不存在任务相关的目标函数,对于某些任务,可能有明确的目标。例如康复训练场景,要求机器人具有较高的跟踪精度以保证引导病人正确完成康复训练任务。文献[7,8]构建了一个关于交互力与跟踪误差的代价函数,利用积分强化学习求解关于机器人阻抗模型最优参数的线性二次调节器问题(linear

① 国家自然科学基金(62203392)和浙江省自然科学基金(LY21F030018)资助项目。
② 男,1979 年生,博士,副教授;研究方向:机器人控制与规划;E-mail:yuxinyinet@163.com。
③ 通讯作者,E-mail:linlinou@zjut.com。
(收稿日期:2023-03-07)

quadratic regulator, LQR)。文献[9]提出了一种基于博弈论的人机交互框架,根据测量的交互力调节刚度系数实现人机协作。然而,以上的一些阻抗控制方法没有考虑机器人的状态约束,例如位置和速度约束。文献[10]提出了模型预测阻抗控制(model predictive impedance control, MPIC)方法,将阻抗控制器转换成一个模型预测控制器(model predictive controller, MPC),并允许对不同的系统参数施加约束,如状态或输入。但文献[10]并没有考虑对阻抗进行约束,即约束阻抗参数变化范围不合理的变阻抗控制率容易导致系统的不稳定。文献[11]初步解决了这个问题,将阻抗约束和状态约束问题转换成 2 个二次规划(quadratic programming, QP)问题,但这带来了较大的计算量,且最终得到的是一个基于模型的控制器。而基于障碍李雅普诺夫函数(barrier Lyapunov function, BLF)的约束控制方法可以直接将 BLF 嵌入到控制器的设计中[12],不需要求解优化问题便可以解决系统状态约束的问题,而且可以结合神经网络设计一个无模型的控制器。

文献[12]提出了 BLF 的概念,针对包含 BLF 的非线性系统控制器,当系统的状态接近设定的约束边界时,系统的控制量将趋近于无穷。文献[13-15]研究了机器人系统中的输入、输出约束控制问题。文献[16]提出了基于 BLF 的约束控制器来解决机器人系统中的关节位置约束问题。文献[17]提出了基于状态反馈和输出反馈的协作机器人阻抗控制器。文献[18]针对不确定机器人系统,研究了基于阻抗学习和正切 BLF 的自适应模糊神经网络约束控制。文献[19]结合积分 BLF,提出了基于导纳的物理人机交互约束控制器。然而,以上基于 BLF 的约束机器人阻抗控制方法不能解决变阻抗情况下状态约束问题,在复杂的交互场景中缺乏鲁棒性和灵活性。

此外,在机器人控制设计中,机械臂动力学的不确定性是不可忽略的,研究人员已经提出了许多控制策略来处理机器人的不确定性,例如自适应控制、模糊系统、神经网络和滑模控制[20-23]等。由于自适应神经网络(neural network, NN)具有结构简单和学习速度快等优点,其在机器人领域得到了广泛的应用。文献[24]结合神经网络,设计了扰动观测器来估计不确定扰动。文献[25]针对不确定机器人系统的轨迹跟踪问题,提出了一种基于径向基神经网络(radial basis function neural network, RBFNN)的非奇异终端滑模控制器用于估计机器人的未知动力学。本文利用 RBFNN 来补偿机器人动力学模型的不确定性以提高跟踪精度。

综上所述,本文提出了一种基于 BLF 的变阻抗约束人机交互控制方法,阻抗控制器的参数可以根据不同交互场景进行调节来满足交互需求。本文的主要贡献点为:(1)设计了一个基于 MPC 的变阻抗控制器,将变阻抗控制问题转换成一个 QP 优化问题,并添加约束条件将阻抗参数约束在一定范围内。相较于无阻抗约束的变阻抗控制方法,提出的方法可以防止不合适的变阻抗行为,保证系统的稳定性。(2)设计了基于 BLF 的自适应神经网络约束控制器跟踪变阻抗控制器的输出信号,保证闭环系统的所有信号是一致最终有界的。采用 RBFNN 补偿机器人动态模型中的不确定性,提高了机器人在内控制环中跟踪虚拟目标轨迹时的跟踪精度。

1 问题描述及控制背景

1.1 问题描述

考虑如图 1 所示的人机交互场景,机器人被要求在约束空间内完成人机交互任务。针对不同的交互任务,机器人往往需要采取不同的交互策略。例如人机康复训练[26],病人的肢体一般力量较弱,需

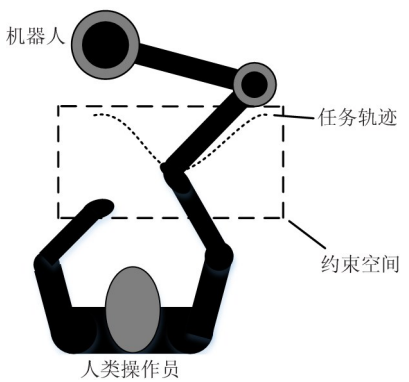

图 1 人机交互场景

要机器人作为领导者,人类作为跟随者配合机器人完成手臂康复训练任务,即机器人高阻抗的场景。而人机协作装配场景[27],当人类操作者需要处理工件装配的意外情况时,需要以人类作为领导者,机器人作为跟随者顺从人类意图协作完成工件重配任务[28-29],即机器人低阻抗的场景。面对不同的交互场景,本文旨在研究一种变阻抗控制方案,满足不同交互场景下的机器人变阻抗的需求。

1.2 控制背景

1.2.1 机器人动力学

考虑一个 m 关节机器人动力学模型:

$$\boldsymbol{M}(q)\ddot{q}+\boldsymbol{C}(q,\dot{q})\dot{q}+\boldsymbol{G}(q)=\boldsymbol{\tau}_c-\boldsymbol{\tau}_h \tag{1}$$

其中,q、$\dot{q}$、$\ddot{q}\in R^m$ 分别代表关节位置、速度和加速度;$\boldsymbol{M}(q)\in R^{m\times m}$ 和 $\boldsymbol{C}(q,\dot{q})\in R^{m\times m}$ 分别代表惯性矩阵、哥氏力和离心力矩阵;$\boldsymbol{G}(q)\in R^m$ 为重力向量;$\boldsymbol{\tau}_c\in R^m$ 是控制力矩;$\boldsymbol{\tau}_h=\boldsymbol{J}^{\mathrm{T}}(q)f_h$ 为外力力矩,其中 $f_h\in R^n$ 表示任务空间中机器人末端受到的外力,$\boldsymbol{J}(q)\in R^{n\times m}$ 为雅克比矩阵。基于正运动学函数 $\boldsymbol{\Phi}(q)$,可以得到 $x=\boldsymbol{\Phi}(q)$,结合 $\dot{x}=\boldsymbol{J}(q)\dot{q}$,可将式(1)转换为任务空间中的机器人动力学模型:

$$\boldsymbol{M}_x(x)\ddot{x}+\boldsymbol{C}_x(x,\dot{x})\dot{x}+\boldsymbol{G}_x(x)=f_c-f_h \tag{2}$$

其中,x、$\dot{x}$ 和 $\ddot{x}\in R^n$ 分别代表机器人末端位置、速度和加速度,$\boldsymbol{M}_x(x)=\boldsymbol{J}^{+\mathrm{T}}(q)\boldsymbol{M}(q)\boldsymbol{J}^{+}(q)\in R^{n\times n}$,$\boldsymbol{C}_x(q,\dot{q})=\boldsymbol{J}^{+\mathrm{T}}(q)(\boldsymbol{C}(q,\dot{q})-\boldsymbol{M}(q)\boldsymbol{J}^{+}(q)\dot{\boldsymbol{J}}(q))\boldsymbol{J}^{+}(q)\in R^{m\times m}$,$\boldsymbol{G}_x(q)=\boldsymbol{J}^{+\mathrm{T}}\boldsymbol{G}(q)\in R^m$。

已知的式(2)具有以下特性[15]。

特性 1 惯性矩阵 $\boldsymbol{M}_x(x)$ 是对称正定矩阵。

特性 2 $\dot{\boldsymbol{M}}_x(x)-2\boldsymbol{C}_x(x,\dot{x})$ 是一个斜对称矩阵,即 $\xi^{\mathrm{T}}(\dot{\boldsymbol{M}}_x(x)-2\boldsymbol{C}_x(x,\dot{x}))\xi=0,\forall\xi\in R^n$。

引理 1[30] 若存在连续正定可微函数 $V(x)$ 满足以下条件:$\kappa_1(\|x\|)<V(x)<\kappa_2(\|x\|)$($K_1$ 与 κ_2 属于 K 类函数)且具有有界初始条件,若 $\dot{V}(x)\leqslant -pV(x)+C$,其中 C 和 ρ 为正常数,那么解 $x(t)$ 是一致最终有界的。

1.2.2 阻抗模型

任务空间中的阻抗模型可以表示为

$$\boldsymbol{M}\ddot{e}+\boldsymbol{D}\dot{e}+\boldsymbol{K}e=f_h \tag{3}$$

其中,$e=x-x_r$,$\boldsymbol{M}$、$\boldsymbol{D}$ 和 $\boldsymbol{K}$ 分别代表期望的惯性、阻尼和刚度矩阵。为了简化,阻抗模型式(3)可以解耦成以下一维模型:

$$m_i\ddot{e}_i+d_i\dot{e}_i+k_ie_i=f_{hi},\ i=1,2,\cdots,n \tag{4}$$

其中,$e_i=x_i-x_{ri}$;m_i、d_i 和 k_i 为正常数,分别代表第 i 维期望的惯性、阻尼和刚度值。当参考轨迹 x_r 给定,并且外力可测时,可以将式(5)作为机器人系统式(2)的输入以实现期望的阻抗行为式(3)。

$$\ddot{x}=\ddot{x}_r+\boldsymbol{M}^{-1}(f_h-\boldsymbol{D}(\dot{x}-\dot{x}_r)-\boldsymbol{K}(x-x_r)) \tag{5}$$

同理,在单维度情况下,式(5)可表示为

$$\ddot{x}_i=\ddot{x}_{ri}+\frac{f_{hi}-d\dot{e}_i-k_ie_i}{m_i} \tag{6}$$

为了实现良好的人机交互,需要将人的模型考虑在控制器的设计中,根据参考文献[7],人体的阻抗模型可以表示为

$$(\boldsymbol{D}_hs+\boldsymbol{K}_h)f_h=\boldsymbol{k}_ee \tag{7}$$

其中,$\boldsymbol{D}_h$、$\boldsymbol{K}_h$ 和 $\boldsymbol{k}_e$ 为未知的增益矩阵,这些参数因人而异,取决于具体的任务。式(7)可以写成如下时域形式:

$$\boldsymbol{D}_h\dot{f}_h+\boldsymbol{K}_hf_h=\boldsymbol{k}_ee \tag{8}$$

或等价于:

$$\dot{f}_h=-\boldsymbol{D}_h^{-1}\boldsymbol{K}_hf_h+\boldsymbol{D}_h^{-1}\boldsymbol{k}_ee \tag{9}$$

式(6)可以改写成以下状态空间形式:

$$\dot{\boldsymbol{\xi}}=\boldsymbol{A}\boldsymbol{\xi}+\boldsymbol{B}u' \tag{10}$$

其中,

$$\boldsymbol{\xi}=\begin{bmatrix}e\\ \dot{e}\\ f_h\end{bmatrix},\ \boldsymbol{A}=\begin{bmatrix}0 & 1 & 0\\ 0 & 0 & 0\\ \boldsymbol{D}_h^{-1}\boldsymbol{k}_e & 0 & -\boldsymbol{D}_h^{-1}\boldsymbol{K}_h\end{bmatrix},$$

$$\boldsymbol{B}=\begin{bmatrix}0\\ 1\\ 0\end{bmatrix},\ u'=\frac{1}{m}(f_h-d\dot{e}-ke) \tag{11}$$

这样阻抗控制就可以被看作一个状态反馈跟踪问题。

2 人机交互控制系统设计

2.1 控制系统概述

本文提出的控制系统由 2 部分组成,第 1 部分为基于 MPC 的变阻抗控制器,第 2 部分为基于 BLF

的自适应神经网络约束控制器。系统控制框图如图 2所示,首先 MPC 优化器根据交互力、参考轨迹与真实轨迹的偏差计算最优阻抗参数,得到考虑阻抗约束的期望阻抗模型,输出参考轨迹;然后自适应神经网络约束控制器跟踪期望轨迹得到合适的控制输入;最后输入机器人系统。

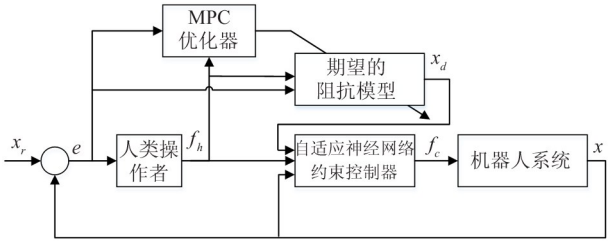

图 2　系统控制框图

2.2　基于 MPC 的变阻抗控制器设计

阻抗模型中的 $\boldsymbol{M}$、$\boldsymbol{D}$ 和 $\boldsymbol{K}$ 具有重要的物理意义,它们决定了惯性阻尼弹簧系统的特性。阻抗参数 $\boldsymbol{K}$ 和 $\boldsymbol{D}$ 越大,机器人的跟踪精度越高,柔顺性越差;相反,$\boldsymbol{K}$ 和 $\boldsymbol{D}$ 越小则跟踪精度越低,柔顺性越好。可以将高阻抗模型机器人作为领导者、人类作为跟随者的情况;反之,低阻抗模型看作人类为主导者、机器人为跟随者的情况。为了实现领导者与跟随者之间角色的转换,设计合适的变阻抗控制器是必要的。

为了在线调整阻抗模型的参数,许多变阻抗的方法被提出,例如基于博弈论的方法[9]、基于 LQR 的方法[7]。虽然这些方法都实现了阻抗自适应,但是没有考虑约束阻抗的变化区间,不合理的变阻抗行为可能导致系统不稳定。而 MPC 控制器可以用于求解一个带约束的有限范围最优控制问题,因此,本文采用基于 MPC 的变阻抗方法调节并约束阻抗参数。由于阻抗参数隐含在模型式(10)的控制输入中,无法在 MPC 优化问题中引入约束条件以限制阻抗变化的范围,因此定义 $\boldsymbol{u} = \left[\frac{-k}{m} \quad \frac{-d}{m} \quad \frac{1}{m}\right]^{\mathrm{T}}$,则 $\boldsymbol{u}' = \boldsymbol{\xi}^{\mathrm{T}}u$,将模型式(10)改写成以下形式:

$$\dot{\boldsymbol{\xi}} = \boldsymbol{A}\boldsymbol{\xi} + \boldsymbol{B}\boldsymbol{\xi}^{\mathrm{T}}\boldsymbol{u} \tag{12}$$

将模型式(12)进行离散化,可以得到:

$$\boldsymbol{\xi}_{t+1} = (\boldsymbol{A}T + \boldsymbol{I})\boldsymbol{\xi}_t + T\boldsymbol{B}\boldsymbol{\xi}_t^{\mathrm{T}}u_t \tag{13}$$

其中,T 为控制周期,$\boldsymbol{I}$ 为单位矩阵。设计输入 u_t 以解决以下单步 MPC 优化问题:

$$\min_{u_t}\boldsymbol{J}(u_t) = \boldsymbol{\xi}_{t+1}^{\mathrm{T}}\boldsymbol{Q}\boldsymbol{\xi}_{t+1} + \boldsymbol{u}_t^{\mathrm{T}}\boldsymbol{R}\boldsymbol{u}_t \tag{14}$$

$$\text{s.t.}\begin{cases} m_t = m_c \\ d_t = 2\sqrt{m_t}\dfrac{k_{\max}}{\sqrt{k_t}} \\ k_t \in [k_{\min}, k_{\max}] \end{cases} \tag{15}$$

其中,$\boldsymbol{Q}$ 和 $\boldsymbol{R}$ 分别为正定和半正定矩阵,m_c、$k_{\min}$ 和 $k_{\max}$ 为正常数,d_t、k_t 为时变的正数。式约束阻抗系统为一个定惯性变刚度、阻尼的二阶系统,刚度的变化范围为 $[k_{\min} \quad k_{\max}]$;另外,为了保证人机交互的安全,阻抗系统被设计为具有过阻尼特性,阻尼参数与刚度正相关。优化问题式(14)、(15)可以进一步写成以下二次规划形式:

$$\min_{u_t}\boldsymbol{J}(\boldsymbol{u}_t) = \frac{1}{2}\boldsymbol{u}_t^{\mathrm{T}}\boldsymbol{H}_t\boldsymbol{u}_t + f_t^{\mathrm{T}}\boldsymbol{u}_t + g_t \tag{16}$$

$$\text{s.t.}\begin{cases} \bar{\boldsymbol{A}}\boldsymbol{u}_t \leqslant \bar{b} \\ \bar{\boldsymbol{A}}_{eq}\boldsymbol{u}_t = \bar{b}_{eq} \end{cases} \tag{17}$$

其中 $\boldsymbol{H}_t = 2T^2\boldsymbol{\xi}_t\boldsymbol{B}^{\mathrm{T}}\boldsymbol{Q}\boldsymbol{B}\boldsymbol{\xi}_t^{\mathrm{T}} + 2\boldsymbol{R}$,$f_t = 2T\boldsymbol{\xi}_t\boldsymbol{Q}\boldsymbol{B}^{\mathrm{T}}\boldsymbol{\xi}_t$,$g_t = \boldsymbol{\xi}_t^{\mathrm{T}}(\boldsymbol{A}T + \boldsymbol{I})^{\mathrm{T}}\boldsymbol{Q}(\boldsymbol{A}T + \boldsymbol{I})\boldsymbol{\xi}_t$,$\bar{\boldsymbol{A}} = \begin{bmatrix} m_c & 0 & 0 \\ -m_c & 0 & 0 \end{bmatrix}$,$\bar{b} = [-k_{\min} \quad k_{\max}]^{\mathrm{T}}$,$\bar{\boldsymbol{A}}_{eq} = \begin{bmatrix} 0 & 0 & c_m \\ \dfrac{2k_{\max}\sqrt{m}}{k\sqrt{k}} & -1 & 0 \end{bmatrix}$,$\bar{b}_{eq} = [1 \quad 0]^{\mathrm{T}}$。显然,$\boldsymbol{H}_t$ 是一个正定矩阵,因此,优化问题式(16)和(17)是严格凸的二次规划问题。通过设定合适的权值矩阵 $\boldsymbol{Q}$、$\boldsymbol{R}$,可以求得满足约束式的最优输入,根据输入 $\boldsymbol{u}$ 的定义,可以解得最优阻抗参数 M^*、D^*、K^*,将其带入式(5),即可求出最优阻抗参数下的期望加速度信号。

2.3　基于 BLF 的约束控制器设计

本小节的目的是设计一个约束控制器使机器人跟踪期望的加速度信号(式(5)),并将机器人末端跟踪误差限制在一定范围内。根据式(2),令 $x_1 = x$,$x_2 = \dot{x}$,机器人动力学可以改写成:

$$\begin{aligned} \dot{x}_1 &= x_2 \\ \dot{x}_2 &= \boldsymbol{M}_x(x)^{-1}(f_c - f_h - \boldsymbol{G}_x(x) - \boldsymbol{C}_x(x,\dot{x})\dot{x}) \end{aligned} \tag{18}$$

跟踪误差被定义为

$$z_1 = x_1 - x_d \tag{19}$$

$$z_2 = x_2 - \alpha \tag{20}$$

其中 $z_1 = [z_{11},\cdots,z_{1n}]^{\mathrm{T}}$, $z_2 = [z_{21},\cdots,z_{2n}]^{\mathrm{T}}$,$\alpha$ 代表虚拟控制率。假设误差信号被要求满足约束 $|z_{1i}| < k_{ai}$(其中 $i = 1,2,\cdots,n$)。式(20)中的虚拟控制率可以被设计为

$$\alpha = \dot{x}_d - \boldsymbol{A} \tag{21}$$

$$\boldsymbol{A} = \begin{bmatrix} \dfrac{k_1 k_{a1}^2}{z_{11}\pi}\sin\left(\dfrac{\pi z_{11}^2}{2k_{a1}^2}\right)\cos\left(\dfrac{\pi z_{11}^2}{2k_{a1}^2}\right) \\ \cdots \\ \dfrac{k_n k_{an}^2}{z_{1n}\pi}\sin\left(\dfrac{\pi z_{1n}^2}{2k_{an}^2}\right)\cos\left(\dfrac{\pi z_{1n}^2}{2k_{an}^2}\right) \end{bmatrix} \tag{22}$$

其中 $k_i(i = 1,\cdots,n)$ 是正的常数。将 z_2 对时间求导,结合式(18)和(20)可得:

$$\dot{z}_2 = \boldsymbol{M}_x(x)^{-1}(f_c - f_h - \boldsymbol{G}_x(x) - \boldsymbol{C}_x(x,\dot{x})\dot{x}) - \dot{\alpha} \tag{23}$$

然后,构建一个正切型李雅普诺夫函数如式(24)所示。

$$V_1 = \sum_{i=1}^{n}\frac{k_{ai}^2}{\pi}\tan\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) \tag{24}$$

将 V_1 对时间求导,可得:

$$\dot{V}_1 = \sum_{i=0}^{n} z_{1i}\dot{z}_{1i}\sec^2\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) \tag{25}$$

进一步,基于式(24)构建候选李雅普诺夫函数 V_2 为

$$V_2 = V_1 + \frac{1}{2}z_2^{\mathrm{T}}\boldsymbol{M}_x z_2 \tag{26}$$

对 V_2 求导可得:

$$\begin{aligned}\dot{V}_2 &= \dot{V}_1 + z_2^{\mathrm{T}}\boldsymbol{M}_x(x)\dot{z}_2 + \frac{1}{2}z_2^{\mathrm{T}}\dot{\boldsymbol{M}}_x(x)z_2 \\ &= \sum_{i=0}^{n} z_{1i}\dot{z}_{1i}\sec^2\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) + z_2^{\mathrm{T}}(f_c - f_h - \boldsymbol{G}_x(x) \\ &\quad - \boldsymbol{M}_x(x)\dot{\alpha} - \boldsymbol{C}_x(x,\dot{x})\alpha)\end{aligned} \tag{27}$$

因此,基于动力学模型的约束控制器被设计为

$$f_c = \boldsymbol{M}_x(x)\dot{\alpha} + \boldsymbol{C}_x(x,\dot{x})\alpha + \boldsymbol{G}_x + f_h - \boldsymbol{K}_2 z_2 - \begin{bmatrix} z_{11}\sec^2\left(\dfrac{\pi z_{11}^2}{2k_{a1}^2}\right) \\ \cdots \\ z_{1n}\sec^2\left(\dfrac{\pi z_{1n}^2}{2k_{an}^2}\right) \end{bmatrix} \tag{28}$$

其中 $\boldsymbol{K}_2 \in R^{n\times n}$ 为正常数矩阵。将式(28)代入式(27),可以得到 $\dot{V}_2$ 满足以下条件:

$$\dot{V}_2 = -\sum_{i=0}^{n}\frac{k_i k_{ai}^2}{\pi}\tan\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) - z_2^{\mathrm{T}}\boldsymbol{K}_2 z_2 < \rho_1 V_1 \tag{29}$$

$$\rho_1 = \min\left(2k_1,2k_2,\cdots,2k_n,\frac{2\lambda_{\min}(\boldsymbol{K}_2)}{\lambda_{\max}(\boldsymbol{D}_x)}\right) \tag{30}$$

其中,$\lambda_{\max}(\cdot)$ 和 $\lambda_{\min}(\cdot)$ 分别代表矩阵 $\cdot$ 的最大和最小特征值。为了确保闭环系统的稳定,控制参数应该满足 $k_i > 0(i = 1,2,\cdots,n)$,$\boldsymbol{K}_2 > 0$。

由于在实际机器人系统中,获得精确的 $\boldsymbol{M}_x(x)$,$\boldsymbol{C}_x(x,\dot{x})$ 和 $\boldsymbol{G}_x$ 是很困难的,控制率式(28)往往不能直接用于机器人控制,而神经网络在拟合模型不确定方面具有良好的性能,因此,设计如下神经网络自适应律:

$$\dot{\hat{\boldsymbol{W}}}_i = -\boldsymbol{\Gamma}_i[S_i(Z_i)z_{2i} + \sigma_i\hat{\boldsymbol{W}}_i],\ i = 1,2,\cdots,n \tag{31}$$

其中,$\boldsymbol{\Gamma}_i$ 代表正定增益矩阵,$\hat{\boldsymbol{W}}_i$ 代表估计的神经网络权值,σ_i 是一个正的常数,$\boldsymbol{Z}_i = [x_{1i},x_{2i},\alpha_i,\dot{\alpha}_i]$ 为神经网络的输入,$\hat{W}^{\mathrm{T}}S(\boldsymbol{Z})$ 被用于估计 $W^{*\mathrm{T}}S(\boldsymbol{Z})$。

$$W^{*\mathrm{T}}S(Z) = \boldsymbol{M}_x(x)\dot{\alpha} + \boldsymbol{C}_x(x,\dot{x})\alpha + \boldsymbol{G}_x - \varepsilon(Z) \tag{32}$$

其中,W_i^* 代表理想的神经网络权值,$\varepsilon(\boldsymbol{Z})$ 为有界神经网络误差。进一步,设计基于径向基神经网络的约束控制器为

$$f_c = f_h + \hat{\boldsymbol{W}}^{\mathrm{T}}S(\boldsymbol{Z}) - \boldsymbol{K}_3 z_2 - \begin{bmatrix} z_{11}\sec^2\left(\dfrac{\pi z_{11}^2}{2k_{a1}^2}\right) \\ \cdots \\ z_{1n}\sec^2\left(\dfrac{\pi z_{1n}^2}{2k_{an}^2}\right) \end{bmatrix} \tag{33}$$

下面将对控制器式(33)为输入构成的闭环系统进行稳定性分析,考虑一个新的李雅普诺夫候选函数为

$$V_3 = V_2 + \frac{1}{2}\sum_{i=1}^{n}\tilde{\boldsymbol{W}}_i^{\mathrm{T}}\boldsymbol{\Gamma}_i^{-1}\tilde{\boldsymbol{W}}_i \tag{34}$$

其中 $\tilde{\boldsymbol{W}}_i = \boldsymbol{W}_i^* - \hat{\boldsymbol{W}}_i$ 代表神经网络权值估计误差。

将 V_3 对时间求导可得:

$$\dot{V}_3 = \sum_{i=0}^{n} z_{1i}\dot{z}_{1i}\sec^2\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) + \sum_{i=1}^{n} \tilde{\boldsymbol{W}}_i^{\mathrm{T}}\boldsymbol{\Gamma}_i^{-1}\dot{\tilde{\boldsymbol{W}}}_i + \boldsymbol{z}_2^{\mathrm{T}}(f_c - f_h - \boldsymbol{G}_x(x) - \boldsymbol{M}_x(x)\dot{\alpha} - \boldsymbol{C}_x(x,\dot{x})\alpha) \tag{35}$$

将式(31)和式(32)代入式(35)可得:

$$\dot{V}_3 = -\sum_{i=0}^{n} \frac{k_i k_{ai}^2}{\pi}\tan\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) - \boldsymbol{z}_2^{\mathrm{T}}\boldsymbol{K}_3\boldsymbol{z}_2 + \boldsymbol{z}_2^{\mathrm{T}}(\hat{\boldsymbol{W}}^{\mathrm{T}}S(\boldsymbol{Z}) - \boldsymbol{W}^{*\mathrm{T}}S(\boldsymbol{Z}) - \varepsilon) - \sum_{i=1}^{n} \tilde{\boldsymbol{W}}_i^{\mathrm{T}}(S_i(\boldsymbol{Z})z_{2i} + \sigma_i\hat{\boldsymbol{W}}_i) \tag{36}$$

因为,

$$-\boldsymbol{z}_2^{\mathrm{T}}\varepsilon \leqslant \frac{1}{2}\boldsymbol{z}_2^{\mathrm{T}}\boldsymbol{z}_2 + \frac{1}{2}\|\bar{\varepsilon}\|^2$$

$$-\sigma_i\tilde{\boldsymbol{W}}_i^{\mathrm{T}}\hat{\boldsymbol{W}}_i \leqslant \frac{\sigma_i}{2}(\|\boldsymbol{W}_i^*\|^2 - \|\tilde{\boldsymbol{W}}_i\|^2)$$

其中,$\|\varepsilon\| \leqslant \|\bar{\varepsilon}\|$,$\bar{\varepsilon}$ 是误差上界。进一步可得:

$$\dot{V}_3 \leqslant -\sum_{i=0}^{n} \frac{k_i k_{ai}^2}{\pi}\tan\left(\frac{\pi z_{1i}^2}{2k_{ai}^2}\right) - \boldsymbol{z}_2^{\mathrm{T}}(\boldsymbol{K}_3 - \frac{1}{2}\boldsymbol{I})\boldsymbol{z}_2 - \sum_{i=1}^{n} \frac{\sigma_i}{2}\|\tilde{\boldsymbol{W}}_i\|^2 + \sum_{i=1}^{n} \frac{\sigma_i}{2}\|\tilde{\boldsymbol{W}}_i^*\|^2 + \frac{1}{2}\|\bar{\varepsilon}\|^2 \leqslant -\rho V_3 + C \tag{37}$$

其中,

$$\rho = \min\left(\min_{i=1,2,\cdots,n}(k_i), \frac{2(\lambda_{\min}(\boldsymbol{K}_3 - \frac{1}{2}\boldsymbol{I}))}{\lambda_{\max}(\boldsymbol{M}_x(x))}, \min_{i=1,2,\cdots,n}\left(\frac{\sigma_i}{\lambda_{\max}(\boldsymbol{\Gamma}_i^{-1})}\right)\right)$$

$$C = \sum_{i=1}^{n} \frac{\sigma_i}{2}\|\boldsymbol{W}_i^*\|^2 + \frac{1}{2}\|\bar{\varepsilon}\|^2 \tag{38}$$

为了确保闭环系统的稳定性,控制参数需满足 $k_i > 0$ $(i = 1,2,\cdots,n)$,$\boldsymbol{K}_3 > 0$。因此,根据引理 1,可得定理 1。

定理 1 对于式(18)描述的具有输出约束的系统,若初始状态有界,则控制器式(33)可以保证所有误差信号都是半全局一致最终有界的,z_1、z_2 和 $\tilde{\boldsymbol{W}}$ 将分别收敛到集合 Ω_{z_1}、Ω_{z_2} 和 $\Omega_{\tilde{W}}$ 内,其中:

$$\Omega_{z_1} = \{\boldsymbol{z}_1 \in R^n \mid \|z_{1i}\| \leqslant \sqrt{\boldsymbol{H}}, i = 1,2,\cdots,n\}$$

$$\Omega_{z_2} = \left\{\boldsymbol{z}_2 \in R^n \mid \|z_{2i}\| \leqslant \sqrt{\frac{\boldsymbol{H}}{\lambda_{\min}(\boldsymbol{M}_x(x))}}\right\}$$

$$\Omega_{\tilde{W}} = \left\{\tilde{\boldsymbol{W}} \in R^{l\times n} \mid \|\tilde{\boldsymbol{W}}_i\| \leqslant \sqrt{\frac{\boldsymbol{H}}{\lambda_{\min}(\boldsymbol{\Gamma}^{-1})}}\right\} \tag{39}$$

其中 $\boldsymbol{H} = 2(V_3(0) + \boldsymbol{C}/\rho)$。

证明 在不等式(37)两边同乘 $e^{\rho t}$,可得:

$$e^{\rho t}\dot{V}_3 \leqslant -\rho V_3 e^{\rho t} + \boldsymbol{C}e^{\rho t} \tag{40}$$

$$\frac{\mathrm{d}}{\mathrm{d}t}(V_3 e^{\rho t}) \leqslant \boldsymbol{C}_3 e^{\rho t} \tag{41}$$

对不等式(41)积分,可得:

$$V_3 \leqslant (V_3(0) - \frac{\boldsymbol{C}}{\rho})e^{-\rho t} + \frac{\boldsymbol{C}}{\rho} \leqslant V_3(0) + \frac{\boldsymbol{C}}{\rho} \tag{42}$$

进一步可得:

$$\frac{1}{2}\boldsymbol{z}_1^{\mathrm{T}}\boldsymbol{z}_1 \leqslant V_3(0) + \frac{\boldsymbol{C}}{\rho}$$

$$\frac{1}{2}\boldsymbol{z}_2^{\mathrm{T}}M_x(x)\boldsymbol{z}_2 \leqslant V_3(0) + \frac{\boldsymbol{C}}{\rho} \tag{43}$$

$$\frac{1}{2}\tilde{\boldsymbol{W}}^{\mathrm{T}}\boldsymbol{\Gamma}^{-1}\tilde{\boldsymbol{W}} \leqslant V_3(0) + \frac{\boldsymbol{C}}{\rho}$$

因此可以得出 $\boldsymbol{z}_1$ 收敛与紧集 Ω_{z_1},同理可以得 $\boldsymbol{z}_2$,$\tilde{\boldsymbol{W}}$ 收敛于紧集 Ω_{z_2}、$\Omega_{\tilde{W}}$。

本文提出的基于 BLF 的变阻抗人机交互控制方法总结为算法 1。

算法 1 基于 BLF 的变阻抗人机交互控制方法

输入: 参考轨迹 x_r,交互力 f_h,仿真步数 N

输出: 机器人控制力矩 f_c

1. **for** $t = 1,\cdots,N$ **do**
2. 观测系统式(13)的状态 ξ_t
3. 求解 MPC 优化问题式(16)、(17),计算阻抗 k_t,d_t
4. 根据求得的阻抗参数和式(5)计算期望的加速度信号
5. 根据式(33)计算控制力矩
6. 根据式(31)计算神经网络更新率
7. 计算下个时刻神经网络权值 $\hat{\boldsymbol{W}}_{t+1} = \hat{\boldsymbol{W}}_t + \dot{\hat{\boldsymbol{W}}}_t T$
8. **end for**

3 仿真实验

本节通过 CoppeliaSim (4.1.0, Windows) 和 Mtalab (R2020a) 联合仿真验证本文所提方法的有效性。利用 CoppeliaSim 仿真平台构造了图 3 所示的二连杆臂,Matlab 通过 CoppeliaSim 官方提供的应用程序接口与 CoppeliaSim 中的二连杆机械臂进行通信。

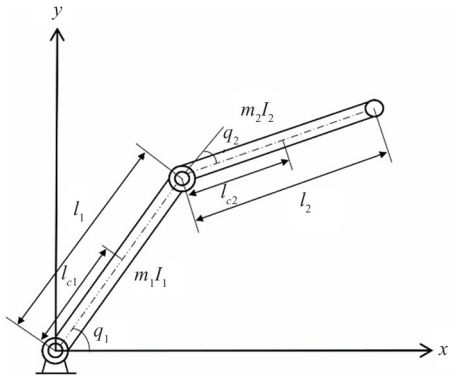

图 3　二连杆机械臂

图 3 中,m_i 和 l_i 分别代表连杆 i 的质量和长度,l_{c_i} 代表关节 i 到连杆 i 质心的距离,I_i 表示连杆 i 的惯性,其中 $i = 1,2$。图 3 中的二连杆臂动力学可以表示为

$$\boldsymbol{M}(q) = \begin{bmatrix} p_1 + 2p_2\cos(q_2) & p_3 + p_2\cos(q_2) \\ p_3 + p_2\cos(q_2) & p_3 \end{bmatrix}$$

$$\boldsymbol{C}(q,\dot{q}) = \begin{bmatrix} -p_2\sin(q_2)\dot{q}_2 & -p_2\sin(q_2))(\dot{q}_1 + \dot{q}_2) \\ p_2\dot{q}_1 & 0 \end{bmatrix}$$

$$\boldsymbol{G}(q) = \begin{bmatrix} (m_1 + m_2)l_1\cos(q_2) + m_2l_2\cos(q_1 + q_2) \\ m_2l_2\cos(q_1 + q_2) \end{bmatrix}$$

其中,$p_1 = (m_1 + m_2)l_1^2 + m_2l_2^2$,$p_2 = m_2l_1l_2$,$p_3 = m_2l_2^2$,$g = 9.8\ \mathrm{m \cdot s^{-2}}$。二连杆臂的正运动学和雅克比矩阵分别为

$$\boldsymbol{\Phi}(q) = \begin{bmatrix} x \\ y \end{bmatrix} = \begin{bmatrix} l_1\cos q_1 + l_2\cos(q_1 + q_2) \\ l_1\sin q_1 + l_2\sin(q_1 + q_2) \end{bmatrix},$$

$$\boldsymbol{J}(q) = \begin{bmatrix} -l_1\sin q_1 + l_2\sin(q_1 + q_2) & -l_2\sin(q_1 + q_2) \\ l_1\cos q_1 + l_2\cos(q_1 + q_2) & l_2\cos(q_1 + q_2) \end{bmatrix}$$

在 CoppeliaSim 仿真环境中,二连杆机械臂模型参数被设定为 $m_1 = m_2 = 0.5\ \mathrm{kg}$,$l_1 = l_2 = 0.30\ \mathrm{m}$,$l_{c1} = l_{c2} = 0.15\ \mathrm{m}$,$I_1 = I_2 = 1\ \mathrm{kg \cdot m^2}$。仿真环境中的外力是通过计算平面上不动点和动点的距离得到的,通过拖动点,可以产生大小和方向不同的外力作用于机械臂末端。

为了验证所提控制器在不同交互场景下的性能,本节中设计了 2 组仿真案例。

案例 1 是人类作为跟随者,机器人作为领导者。任务轨迹为一条圆形参考轨迹,设为

$$\begin{cases} x_r = 0.42\sin(2\pi t/15 - 1.3) \\ y_r = 0.42\sin(2\pi t/15 + 0.26) \end{cases}$$

其中 $t \in [0,15]$。当人类施加外力使得机器人偏离参考轨迹时,机器人将人类外力作为干扰,刚度增大,阻止机器人末端偏离参考轨迹。

案例 2 参考轨迹与案例 1 一致,但要求人类施加外力时机器人刚度减小以顺从人类。仿真平台的控制频率被设为 100 Hz,机器人末端的初始位置设为 $(x_0, y_0) = (0.409\,8, 0.109\,8)$。变阻抗控制器参数设为 $m_c = 1$,$k_{\min} = 60$,$k_{\max} = 120$,$\boldsymbol{Q} = diag\{1.0, 0.1, 0.1\}$,$\boldsymbol{R} = diag\{10^{-9}, 10^{-9}, 10^{-9}\}$,约束控制器参数设为 $\boldsymbol{K}_3 = diag\{5,5\}$,$\boldsymbol{k}_a = [0.05, 0.05]^{\mathrm{T}}$,神经网络节点中心在区间 $[-1,1]$ 内均匀选择,节点个数设置为 128,神经网络的初始权值设为 0,$\boldsymbol{\Gamma}_i = 10\boldsymbol{I}_{128}$,$\sigma_i = 0.002$。

图 4 为案例 1 的仿真结果。如图 4(a)所示,当 $t = 5$ s 和 $t = 9$ s 左右时,在机械臂末端分别施加了 X 方向和 Y 方向的交互力,此时机械臂偏离参考轨迹 x_r,进而跟踪期望轨迹 x_d。图 4(c)、(e)所示分别为机器人 X、Y 方向和任务空间的跟踪轨迹。从图 4(b)可以看出机器人为了抵抗外力的干扰,X 方向和 Y 方向刚度随着外力的增加而增加,在 $t = 8$ s 及 $t = 11$ s 左右,X 方向和 Y 方向的外力分别减小到 0,此时机器人刚度减小,并且重新恢复跟踪参考轨迹 x_d。跟踪误差轨迹如图 4(d)所示,其中虚线和点划线分别代表误差的约束上界和下界,显然,跟踪误差 z_1 始终在预定义的约束中,并且收敛到一个接近 0 的值,这表明控制器式良好的跟踪性能。

案例 2 要求人类作为主导者,机器人作为跟随者顺从人类意图。引入以下函数改变刚度上下界为

$$\begin{cases} \bar{k}(t) = k_{\min} + (k_{\max} - k_{\min})\,\mathrm{e}^{-|f_h|/(2\sigma^2)} \\ \underline{k}(t) = \bar{k}(t) - \tilde{k} \end{cases}$$

其中,$\bar{k}(t)$、$\underline{k}(t)$ 分别代表刚度上界和下界,$\tilde{k}$ 为设定的刚度上下界差值。设定 $k_{\min} = 60$,$k_{\max} = 120$,$\tilde{k} = 20$,$\sigma = 0.86$,$\boldsymbol{Q} = diag\{0.10, 0.01, 0.01\}$,$\boldsymbol{R} = diag\{10^{-9}, 10^{-9}, 10^{-9}\}$。图 5 为案例 2 的仿真结果,与案例 1 类似,当 $t = 5$ s 和 $t = 9$ s 时分别在机器人末端 X 方向和 Y 方向施加外力。图 5(a)是外力的变化轨迹图;图5(b)为刚度变化轨迹图,当交互力

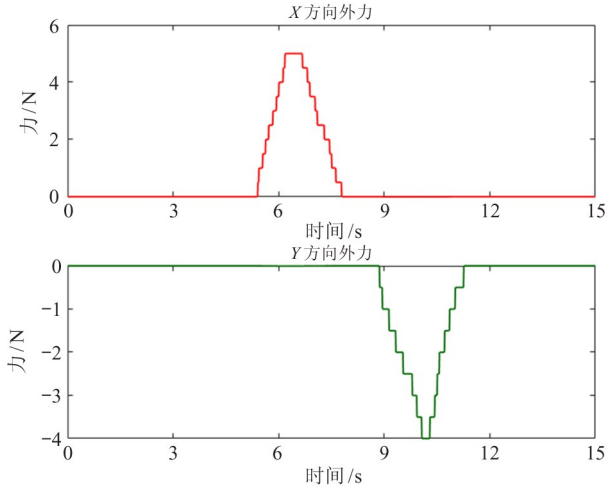

（a）X 方向和 Y 方向施加的外力

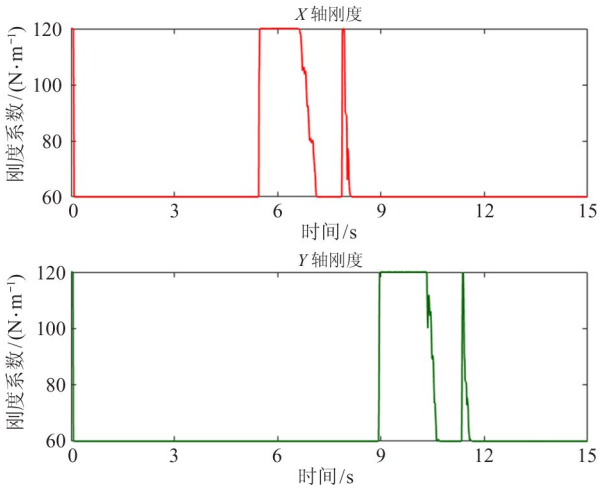

（b）刚度变化轨迹

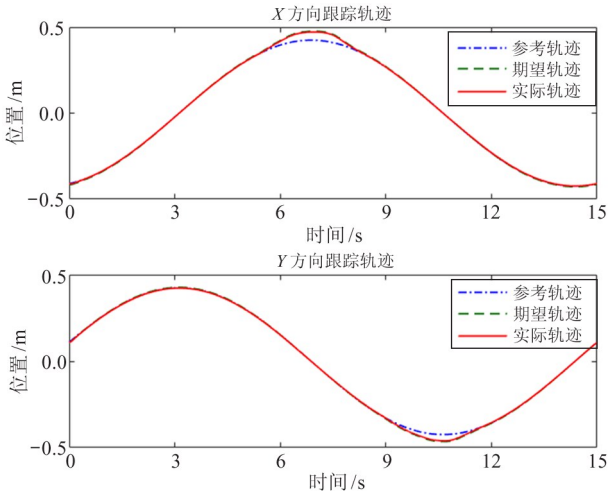

（c）X 方向和 Y 方向跟踪轨迹

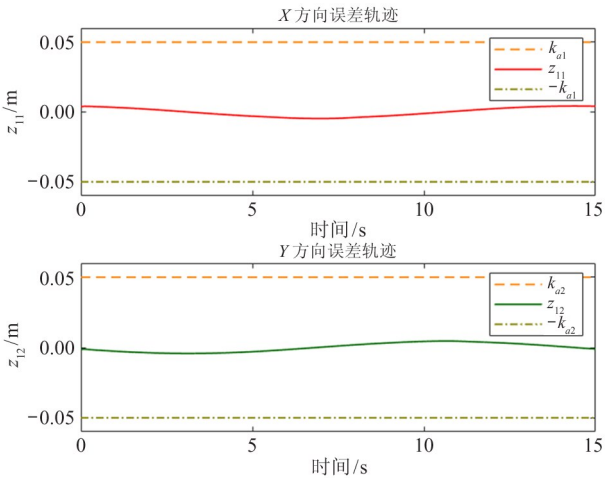

（d）跟踪误差轨迹

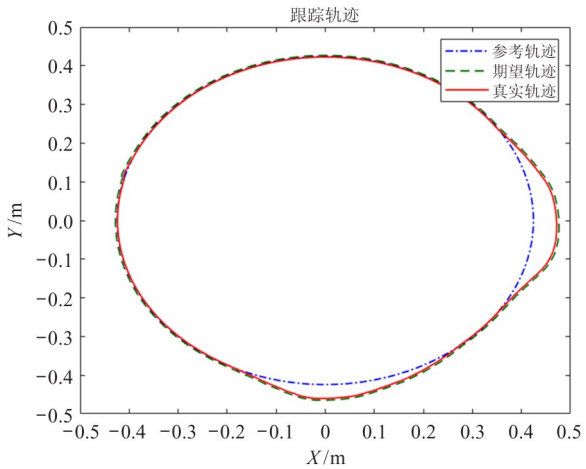

（e）任务空间跟踪轨迹

图 4　案例 1 仿真结果

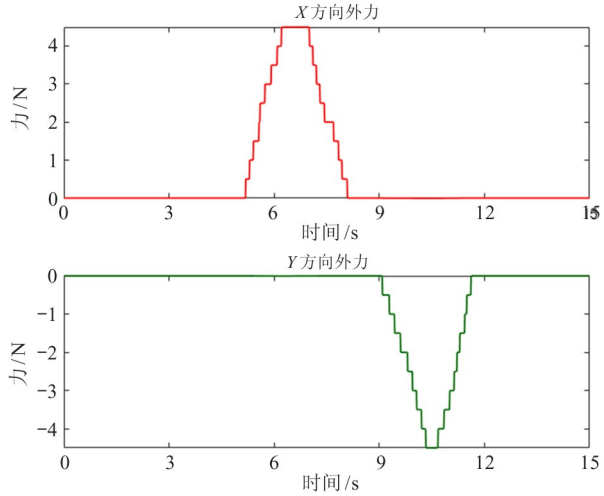

(a) X 方向和 Y 方向施加的外力

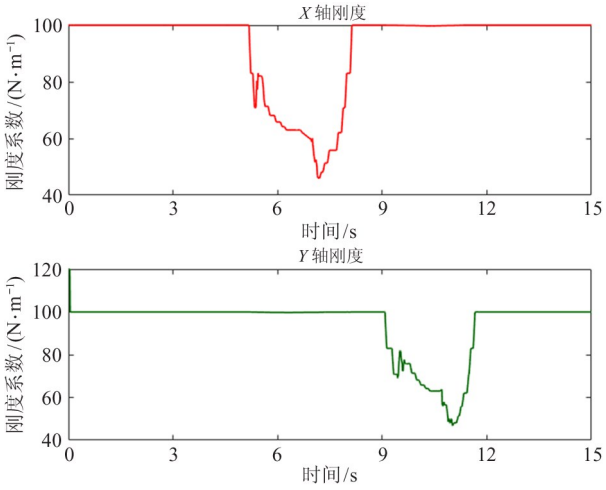

(b) 刚度变化轨迹

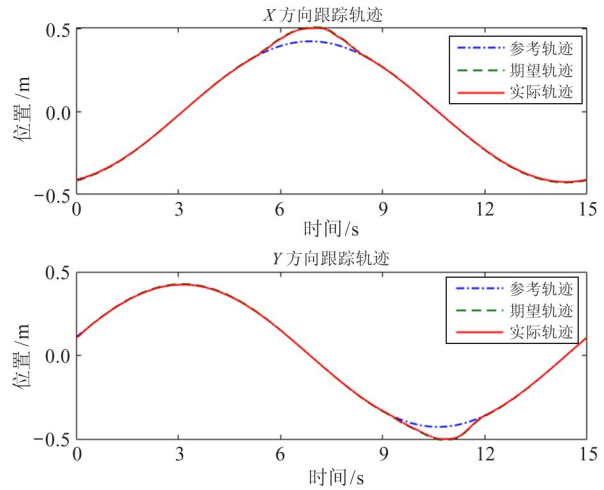

(c) X 方向和 Y 方向跟踪轨迹

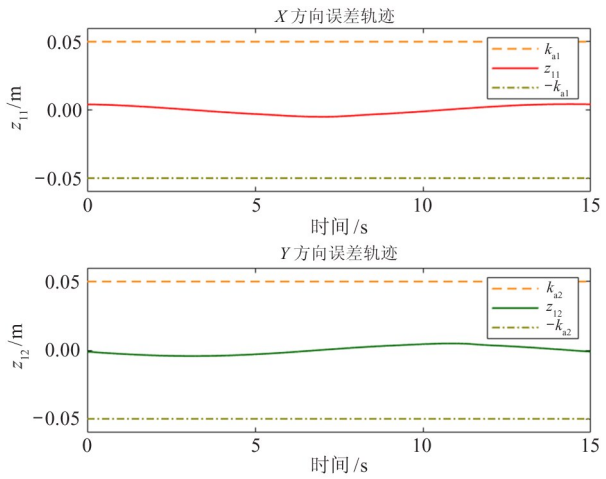

(d) 跟踪误差轨迹

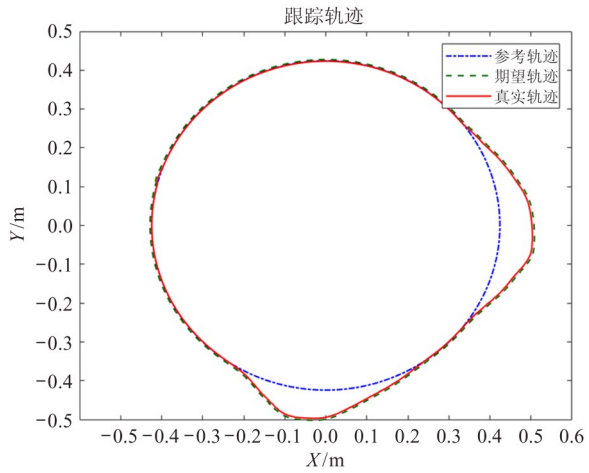

(e) 任务空间跟踪轨迹

图 5　案例 2 仿真结果

增加时,刚度减小,同时机器人的交互柔顺性增加。当交互力减小并逐渐减小到 0 时,刚度增大并逐渐恢复到初始刚度值;图 5(c)、(e)为机器人末端跟踪轨迹和 X 方向及 Y 方向跟踪轨迹,相较于案例 1 高

阻抗情况下的跟踪结果,低阻抗参数下的机器人真实轨迹与参考轨迹的偏差更大,这表明机器人实现了顺从人类意图的目标;跟踪误差轨迹如图 5(d)所示,显然,跟踪误差 z_1 始终在预定义的约束中,并且收敛到一个接近 0 的值,验证了所提控制器的良好跟踪性能。

4 结 论

本文提出了一种基于 BLF 的变阻抗约束控制方法,能够针对不同交互场景实现机器人变阻抗行为,解决了人机交互中领导者与跟随者角色切换问题。构建了一种新的阻抗模型,将阻抗参数作为新的阻抗系统的输入。设计了一种基于 MPC 的变阻抗约束控制器,通过求解一个 QP 约束优化问题求解最优阻抗参数,同时保证阻抗参数约束在一定范围内。此外,为了处理跟踪控制问题,提出了一种基于 BLF 的自适应神经网络约束控制方法,保证跟踪误差位于给定的约束域内,同时,自适应神经网络补偿了机器人动力学模型的不确性,提高了跟踪精度。最后,通过 2 个仿真案例验证了所提方法在不同交互场景下的良好性能。

参考文献

[1] FERRAGUTI F, TALIGNANI LANDI C, SABATTINI L, et al. A variable admittance control strategy for stable physical human-robot interaction[J]. The International Journal of Robotics Research, 2019,38(6):747-765.

[2] ROZO L, CALINON S, CALDWELL D, et al. Learning collaborative impedance-based robot behaviors[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Washington, USA: AAAI Press, 2013:1422-1428.

[3] SHARIFI M, ZAKERIMANESH A, MEHR J K, et al. Impedance variation and learning strategies in human-robot interaction[J]. IEEE Transactions on Cybernetics, 2021,52(7):6462-6475.

[4] YU X, HE W, LI Y, et al. Bayesian estimation of human impedance and motion intention for human-robot collaboration[J]. IEEE Transactions on Cybernetics, 2019, 51(4):1822-1834.

[5] YU X, LI Y, ZHANG S, et al. Estimation of human impedance and motion intention for constrained human-robot interaction[J]. Neurocomputing, 2020,390:268-279.

[6] KRONANDER K, BILLARD A. Learning compliant manipulation through kinesthetic and tactile human-robot interaction[J]. IEEE Transactions on Haptics, 2013,7(3):367-380.

[7] MODARES H, RANATUNGA I, LEWIS F L, et al. Optimized assistive human-robot interaction using reinforcement learning[J]. IEEE Transactions on Cybernetics, 2015,46(3):655-667.

[8] LI Z, LIU J, HUANG Z, et al. Adaptive impedance control of human-robot cooperation using reinforcement learning[J]. IEEE Transactions on Industrial Electronics, 2017,64(10):8013-8022.

[9] LI Y, TEE K P, YAN R, et al. A framework of human-robot coordination based on game theory and policy iteration[J]. IEEE Transactions on Robotics, 2016,32(6):1408-1418.

[10] BEDNARCZYK M, OMRAN H, BAYLE B. Model predictive impedance control[C]//2020 IEEE International Conference on Robotics and Automation. Paris, France: IEEE, 2020:4702-4708.

[11] JIN Z, QIN D, LIU A, et al. Constrained variable impedance control using quadratic programming[C]//2022 International Conference on Robotics and Automation. Xi'an, China: IEEE, 2022:8319-8324.

[12] TEE K P, GE S S, TAY E H. Barrier Lyapunov functions for the control of output-constrained nonlinear systems[J]. Automatica, 2009,45(4):918-927.

[13] HE W, MENG T, HE X, et al. Unified iterative learning control for flexible structures with input constraints[J]. Automatica, 2018,96:326-336.

[14] LI Z, CHEN Z, FU J, et al. Direct adaptive controller for uncertain MIMO dynamic systems with time-varying delay and dead-zone inputs[J]. Automatica, 2016,63:287-291.

[15] HE W, GE S S, LI Y, et al. Neural network control of a rehabilitation robot by state and output feedback[J]. Journal of Intelligent and Robotic Systems, 2015,80(1):15-31.

[16] HE W, CHEN Y, YIN Z. Adaptive neural network control of an uncertain robot with full-state constraints[J]. IEEE Transactions on Cybernetics, 2015,46(3):620-629.

[17] DONG Y, HE W, KONG L, et al. Impedance control for coordinated robots by state and output feedback[J]. IEEE Transactions on Systems, Man, and Cybernetics: Systems, 2019,51(8):5056-5066.

[18] HE W, DONG Y. Adaptive fuzzy neural network control for a constrained robot using impedance learning[J]. IEEE Transactions on Neural Networks and Learning Systems, 2017,29(4):1174-1186.

[19] HE W, XUE C, YU X, et al. Admittance-based controller design for physical human-robot interaction in the constrained task space[J]. IEEE Transactions on Automa-

tion Science and Engineering, 2020,17(4):1937-1949.
[20] DUONG T, ATANASOV N. Adaptive control of SE(3) Hamiltonian dynamics with learned disturbance features [EB/OL]. (2021-09-21) [2023-02-09]. https://arxiv.org/pdf/2109.09974v1.
[21] WEN G, LI B, NIU B. Optimized backstepping control using reinforcement learning of observer-critic-actor architecture based on fuzzy system for a class of nonlinear strict-feedback systems[J]. IEEE Transactions on Fuzzy Systems, 2022,30(10):4322-4335.
[22] NGUYEN H T, CHEAH C C. Analytic deep neural network-based robot control[J]. IEEE/ASME Transactions on Mechatronics, 2022,27(4):2176-2184.
[23] HOU S, WANG C, CHU Y, et al. Neural-observer-based terminal sliding mode control: design and application [J]. IEEE Transactions on Fuzzy Systems, 2022, 30(11):4800-4814.
[24] CHEN M. Disturbance attenuation tracking control for wheeled mobile robots with skidding and slipping[J]. IEEE Transactions on Industrial Electronics, 2016, 64(4):3359-3368.
[25] SUN Y, GAO Y, ZHAO Y, et al. Neural network-based tracking control of uncertain robotic systems: predefined-time nonsingular terminal sliding-mode approach[J]. IEEE Transactions on Industrial Electronics, 2022, 69(10):10510-10520.
[26] PEHLIVAN A U, LOSEY D P, O'MALLEY M K. Minimal assist-as-needed controller for upper limb robotic rehabilitation[J]. IEEE Transactions on Robotics, 2015, 32(1):113-124.
[27] LUO J, SOLOWJOW E, WEN C, et al. Reinforcement learning on variable impedance controller for high-precision robotic assembly[C]//2019 International Conference on Robotics and Automation. Montreal, Canada: IEEE, 2019:3080-3087.
[28] SUZUKI S, FURUTA K. Adaptive impedance control to enhance human skill on a haptic interface system[J]. Journal of Control Science and Engineering, 2012, 2012: 1-10.
[29] CREMER S, DAS S K, WIJAYASINGHE I B, et al. Model-free online neuroadaptive controller with intent estimation for physical human-robot interaction[J]. IEEE Transactions on Robotics, 2019,36(1):240-253.
[30] GE S S, WANG C. Adaptive neural control of uncertain MIMO nonlinear systems[J]. IEEE Transactions on Neural Networks, 2004,15(3):674-692.

Variable impedance control based on barrier Lyapunov function for constrained human-robot interaction

YU Xinyi, SHI Shuanwu, WEI Yan, OU Linlin
(College of Information Engineering, Zhejiang University of Technology, Hangzhou 310023)

Abstract

Impedance control is a compliant control method widely used in human-robot interaction (HRI). It regulates the tracking accuracy of the robot and the contact compliance with the environment. However, fixed impedance parameters limit the applicability of impedance control in complex HRI tasks. In order to realize the role switching between leader and follower in HRI, a variable impedance control approach is proposed based on barrier Lyapunov function (BLF) for constrained HRI. Firstly, A novel impedance model is established and the impedance parameters are designed as the control input of the new impedance system. The design problem of variable impedance controller with impedance constraints is transformed into a quadratic programming problem. Secondly, BLF-based adaptive neural network constrained controller is designed to solve the tracking control problem. At the same time, the controller ensures that the error signal within the constrained domain. The radial basis neural networks (NNs) are adopted to handle uncertainty of the robot dynamics and guarantee tracking performance. The stability of the closed-loop system is proved by the Lyapunov stability theorem. Finally, the effectiveness of the proposed method is verified by two simulation cases.

Key words: human-robot interaction(HRI), variable impedance control, model predictive control, barrier Lyapunov function(BLF), neural network (NN)