

DOI: 10.19650/j.cnki.cjsi.J1905313

一种基于 Lyapunov 约束的学习控制方法及应用*

马乐, 刘跃峰, 李志伟, 徐东甫, 张玉龙

(东北电力大学自动化工程学院 机器人研究所 吉林 132012)

摘要:针对非线性系统的稳定控制器直接设计问题,提出一种基于 Lyapunov 稳定性条件的学习控制器设计方法框架,将传统的控制器设计与稳定性证明分析问题转化为以控制器为求解项, Lyapunov 稳定条件为约束的最优化问题,提供了一种直接求解全局稳定的最优控制器的新途径。首先建立了以系统跟踪误差为目标函数与以 Lyapunov 稳定条件为约束的最优化问题,接着给出了一类基于神经网络实现的 PID 结合前馈控制器设计形式,最后分析并设计了学习控制器求解方法,采用相关深度学习技术以提升求解能力。二阶线性与非线性系统仿真测试与一级旋转倒立摆模拟实验表明所提方法具有快速收敛、低误差、控制输出平滑且低幅值等特点;在加入扰动、噪声、参数不确定性和不同的测试期望输出条件下的反步法对比测试结果表明所提方法对扰动与噪声具有强抑制能力,同时学习控制器具有高泛化能力。基于 V-Rep 的一级旋转倒立摆模拟与四旋翼单轴控制实物实验结果验证了所提方法对物理系统控制问题具有高控制精度与强抗扰能力。

关键词:直接控制器设计; Lyapunov 约束; 学习控制; 深度学习技术

中图分类号: TH861 TP273+.1 **文献标识码:** A **国家标准学科分类代码:** 510.80

A framework of learning controller with Lyapunov-based constraint and application

Ma Le, Liu Yuefeng, Li Zhiwei, Xu Dongfu, Zhang Yulong

(Robotics Technology Lab, School of Automation and Engineering, Northeast Electric Power University, Jilin 132012, China)

Abstract: In this paper, the direct way of designing a stable controller for nonlinear system is studied. A framework of learning controller with Lyapunov-based constraint is proposed, which transforms design and analysis of a controller to straightforward way by solving an optimization item with the Lyapunov constraint. A novel way of the global stability guaranteed controller is realized directly. Firstly, the optimization problem subject to Lyapunov-based constraints is formulated, in which the tracking error is the objective function to be minimized. Secondly, the controller combines with PID and feedforward is given in form of neural networks. Finally, the optimization solution of the controller method is analyzed and solved, in which some deep learning technologies are used to enhance the capability of solution. Test results of two simulations of 2 order linear and nonlinear systems demonstrate that the proposed method has high performance in speed of convergence, tracking error and smoothness and amplitude of control output. Results of comparison simulation with backstepping control to the nonlinear system with disturbance, noise, uncertainty of parameters and the difference of reference output demonstrate that the proposed method has high performance in terms of robustness and generalization. Results of simulated physical experiment of one-stage rotary inverted pendulum based on V-Rep and physical testing of single-axis controlling for quadrotor prove that the method proposed is capable of high precision control and strong disturbance rejection.

Keywords: direct controller design; Lyapunov constraint; learning control; deep learning technology

0 引言

一直以来控制器的系统稳定性分析在控制理论研究及应用中占有重要地位,稳定性是控制器实际工作的先决条件^[1]。

目前控制理论研究通常做法是首先设计针对特定模型系统的控制器,然后分析其稳定性^[2]。然而在控制器设计过程中,或因稍过于考虑稳定性分析而忽略了实际的控制性能^[3],同时普遍存在以下问题:1)稳定分析依赖系统与控制器参数,当实际与分析存在参数差异时不能保证分析仍成立,或需重调参数以确保系统稳定^[4];2)稳定性分析中通常忽略或简化噪声与扰动作用导致控制器动态性能有待提升^[5];3)在传统方法中完成控制器设计后,系统的控制性能随之固定,缺乏性能提升途径^[6]。因此是否能够瞄准控制问题本身直接设计具有性能提升能力与全局稳定性的控制器十分重要。

通常 Lyapunov 函数被用于控制器的稳定性分析,将其作为控制器设计条件是上述动机的积极思路^[7]。已有研究中一些方法蕴含了上述思想。首先 Backstepping 控制引入了“虚拟控制”针对严格反馈系统逐级建立 Lyapunov 函数并设计相应虚拟控制量实现最终控制器设计^[8]。然而该方法局限于系统模型形式^[9],并常伴随一定的稳态误差,同时当期望输出不确定时其导数难以精确获得,为此文献[10]研究引入了最优条件,力图改善控制性能,但该方法仅适用于凸优化问题,该条件往往难以保证。

另一种研究方法是寻找系统的控制 Lyapunov 函数(control lyapunov function, CLF)^[11]并利用 Sontag 公式直接构造稳定控制器^[12]。该方法同样存在一定的局限,首先方法仅适用于仿射系统^[13],其次寻找系统的 CLF 往往与稳定性分析同样困难^[14]。因此该方法虽提供了一个直接的控制器设计途径,但未从根本上简化控制器设计。

另外考虑到控制的根本问题之一是跟踪误差最小化,因此引入最优化指标也是实现上述动机的必要方法^[8,15]。模型预测控制(model predictive control, MPC)是一类基于求解最优化的控制方法,然而因传统 MPC 的预测范围有限,通过求解有限时段内最优化不能自动地确保闭环稳定性^[16]。为此文献[17]研究引入了 Lyapunov 稳定性条件。文献[18]在传统 MPC 优化环节加入了 CLF 约束项以实现稳定性约束,然而该方法需建立在某个已具备 Lyapunov 稳定控制器基础上,因此未能解决上述动机。

在前期工作基础上^[19],本文提出了一种以 Lyapunov 稳定性为约束条件的学习控制器设计框架,将跟踪误差范数与系统 Lyapunov 函数导数约束联立构成一组最优

化问题,并求解其最优学习控制器。本文设计了一个由神经网络实现的 PID、前馈控制器,采用深度学习技术提升优化问题的求解能力。本文通过引入 Lyapunov 稳定条件约束,提供了一种新的直接稳定控制器设计途径;采用控制输出限幅技术,使得到的控制器幅值限于给定界限内,规避了控制输出饱和问题;采用的深度学习技术提升了优化问题,同时学习过程为单点优化有利于本文方法的实际应用,经学习后的控制器具有良好的泛化和抗扰能力,并能脱离学习阶段独立运行。

1 问题描述

考虑控制系统如下:

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{F}(\mathbf{x}, \mathbf{u}) \\ \mathbf{y} = \mathbf{H}(\mathbf{x}) \end{cases} \quad (1)$$

构造 Lyapunov 函数 $V(\mathbf{x})$,若设计的控制器 $\mathbf{u}(\mathbf{x} | \boldsymbol{\theta}^u)$ 使 $\dot{V} < 0$,则 $\mathbf{u}(\mathbf{x} | \boldsymbol{\theta}^u)$ 对控制系统全局稳定。因此建立不等式约束最优化问题:

$$\begin{cases} \min \|\mathbf{y}^d - \mathbf{y}\| \\ \text{s.t. } \dot{V} < 0 \end{cases} \quad (2)$$

其中 $\min \|\mathbf{y}^d - \mathbf{y}\|$ 意在使控制系统输出的跟踪误差最小, $\dot{V} < 0$ 作为控制过程的全局稳定约束条件。若式(2)存在最优解 \mathbf{u}^* ,则 \mathbf{u}^* 为 Lyapunov 全局稳定条件下的最优控制器。

取跟踪误差内积为 Lyapunov 函数。

$$\mathbf{V}(\mathbf{x}) = (\mathbf{y}^d - \mathbf{y})^T (\mathbf{y}^d - \mathbf{y}) \quad (3)$$

离散化式(2),代入 $\dot{\mathbf{x}} = \mathbf{F}(\mathbf{x}, \mathbf{u})$ 得:

$$\begin{cases} \min \|\mathbf{y}_k^d - \mathbf{y}_k\| \\ \text{s.t. } \left(\frac{\partial \mathbf{V}}{\partial \mathbf{x}} \right)^T \mathbf{F}(\mathbf{x}_k, \mathbf{u}(\mathbf{x}_k | \boldsymbol{\theta}^u)) < 0 \\ \mathbf{y}_k = \mathbf{H}(\mathbf{x}_k + \mathbf{F}(\mathbf{x}_{k-1}, \mathbf{u}(\mathbf{x}_{k-1} | \boldsymbol{\theta}^u)) \Delta t) \end{cases} \quad (4)$$

式中: Δt 为采用时间间隔。

式(2)、(4)将控制器设计与 Lyapunov 稳定性证明问题转为以 Lyapunov 稳定性条件为约束的优化问题,进而给出了一种直接求解全局稳定控制器的新途径。

2 学习控制器设计

本文重点在于以 Lyapunov 稳定条件为约束的学习控制设计方法,基于该方法可设计不同结构控制器,本文仅对一类神经网络控制器加以分析。

本文设计的学习控制器如下:

$$\mathbf{u}_L = \mathbf{u}_p + \mathbf{u}_f \quad (5)$$

式中: \mathbf{u}_p 与 \mathbf{u}_f 分别为 PID 与前馈控制器。区别于传统方法,上述两种控制项均采用神经网络实现,记为 $\mathbf{u}_p(\mathbf{x}_p |$

θ^p 与 $u_f(x_f | \theta^f)$, θ^p 、 θ^f 为待学习的神经网络参数,因此控制器 u_L 的待学习参数为 $\theta^L: \langle \theta^p, \theta^f \rangle$ 。

采用3层前向网络构建学习控制器,其中隐层激活函数选为 Sigmoid 函数与线性整流函数(整流线性单元, ReLU):

$$\begin{cases} f_{\text{sigmoid}}(x) = \frac{1}{1 + e^{-x}} \\ f_{\text{ReLU}}(x) = \max(0, x) \end{cases} \quad (6)$$

u_p 的输入包括系统输出误差及其积分项与微分项,记为 $x_p = [x_e, x_s, x_d]^T$; u_f 的输入由系统期望输入序列构成,记为 $x_f = [y_k^d, y_{k-1}^d, \dots, y_{k-N_f+1}^d]^T$,其中 N_f 为输入维数。

考虑到实际系统中控制输入均应有界,因此利用 tanh 函数对设计的神经网络控制器做限幅处理:

$$\begin{cases} \tilde{u}_L = \Delta V \cdot f_{\text{tanh}}\left(\frac{u_L}{\Delta V}\right) + \frac{V_{\max} + V_{\min}}{2} \\ \Delta V = \frac{1}{2}(V_{\max} - V_{\min}) \end{cases} \quad (7)$$

式中: V_{\max} 、 V_{\min} 分别为系统控制输入上下限。该限幅方法优点在于相对 $\max(V_{\min}, \min(V_{\max}, x))$, 式(7) 确保了对控制输出的平滑限制,有利于后续基于梯度的优化求解。

3 学习控制器求解

在确定学习控制器结构后,下一个关键问题是如何利用控制系统信息优化控制器参数 θ^L 。式(3)为一类带不等式约束的最优化问题,需将其转化为无约束优化问题。虽然 Lagrange 乘子法是通常采用的优化方法,但对于不等式约束问题需满足 KKT (Karush-Kuhn-Tucher) 条件^[20],考虑式(3)不确保满足该条件,为此采用改进的惩罚函数法对式(3)非约束化。

建立惩罚函数 $\rho(x | \beta_\rho)$,其中 β_ρ 为函数参数,转化式(3)为无约束优化问题,目标函数为:

$$\begin{aligned} L(\theta^L | \cdot) &= \|y_k^d - y_k\| + \\ \lambda \cdot \rho\left(\left(\frac{\partial V}{\partial x}\right)^T F(x_k, u_L(x_k | \theta^L) | \beta_\rho)\right) \end{aligned} \quad (8)$$

式中: $\lambda > 0$, 为权衡系数。

惩罚函数 $\rho(x | \beta_\rho)$ 作用是当约束条件满足时函数不对优化问题产生影响,当不满足要求时产生一个惩罚项,迫使待优化参数趋向可行域。因此目标函数 L 最优解必同时满足跟踪误差极小与不等式约束两个条件。

为此将 $\rho(x | \beta_\rho)$ 设计为:

$$\begin{cases} \rho(x | [\beta_B, \alpha_\rho]) = (f_{\text{softplus}}(x + \beta_B))^{\alpha_\rho} \\ f_{\text{softplus}}(x) = \ln(1 + e^x) \end{cases} \quad (9)$$

由式(9)可看出当被约束项 < 0 时惩罚项趋近于 0,对优化不产生重要影响;当被约束项 > 0 时,惩罚项近似呈幂函数增长,进而迫使优化器将待优化参数拉近约束条件域。式(9)中 $\beta_B > 0$ 为边界裕量,使约束项稍远离临界值 0。

至此,采用基于梯度的优化算法(如 SGD、Adagrad、Adam 等)求解神经网络学习控制器参数。为保证在小误差状态下的迭代性能,本文选择跟踪误差为 Smooth L1 范数^[21]:

$$\|x\|_{\text{smoothL1}} = \begin{cases} \frac{1}{2}x^2, & |x| < 1 \\ |x| - \frac{1}{2}, & \text{其他} \end{cases} \quad (10)$$

注:式(10)仅在学习控制阶段求优过程使用,后续仿真结果均仍采用传统的跟踪误差指标评价。

4 仿真分析

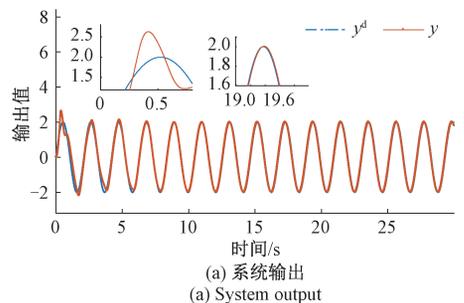
本文采用 Python 与 Pytorch 进行仿真,以测试不同系统模型的控制效果,从而验证提出方法有效性。

算例 1:二阶线性系统如下:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = -Ax_2 - Bx_1 + Cu \\ y = x_1 \end{cases} \quad (11)$$

其中 $A = 9, B = 6, C = 6$,期望轨迹设为 $y_i^d = 2\sin(3t)$,采样周期 $\Delta t = 0.01$ s。控制器相关参数设置为: $\lambda = 1, \beta_\rho = [0.1, 1]^T, V_{\max}, V_{\min}$ 分别为 ± 50 ,采用 Adagrad 算法进行迭代训练,学习律 $\eta = 0.36$ 。设初始状态 $[x_1, x_2] = [0, 0]$,仿真时长 30 s。

图 1 所示为本文方法对式(11)描述系统的仿真控制效果。从图 1(a)中看出系统输出在小于 2.5 s 时间内即达到稳定,并在小于 7.8 s 时间内跟踪误差降至低误差范围内,同时能在初始时段保持较低超调量。从图 1(b)看出整个控制过程中 u 始终保持在低幅值范围内,并且时序平滑。从图 1(c)看出跟踪误差范围在 10 s 内降至 0.05 以下。本文方法对算例 1 的学习控制具备超调小、收敛快速、跟踪精度高等特征。



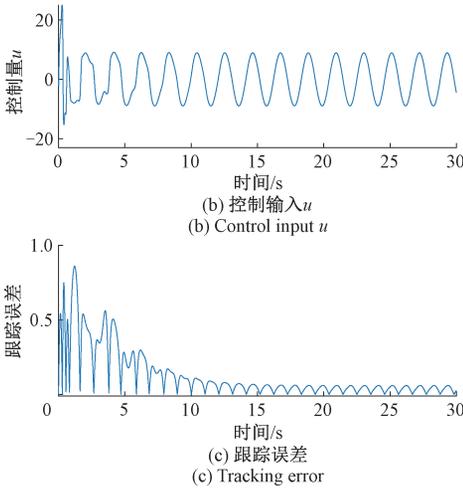


图1 算例1学习控制结果

Fig.1 Learning control performance of example 1

图2所示为控制器完成学习过程后的控制结果,从图2(a)看出控制器经过学习后在小于1s时间内即达到稳定,且动态性能较学习阶段明显提升,整个控制过程保持很低的误差(<0.01),图1(b)显示学习后控制输入依然保持低幅、平滑,图1(c)显示控制过程中跟踪误差低于0.01。经学习后控制器的效果相对完成学习过程的控制效果有明显提高,并保持了高跟踪精度。

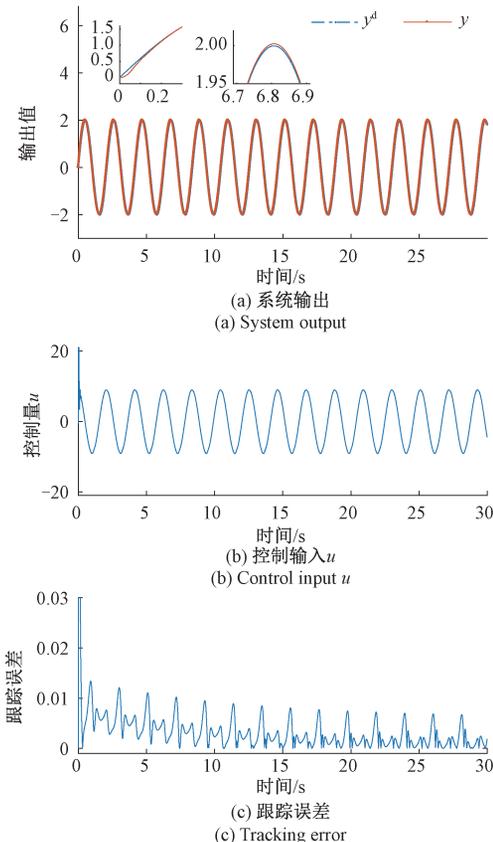


图2 学习完成后控制结果

Fig.2 Test performance of example 1 after learning

算例1仿真实验证明了本文方法对于一类二阶线性系统控制具有高精度控制性能。

算例2:二阶非线性系统如下:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = -A\cos(x_2) - B\sin(x_1) + Cu \end{cases} \quad (12)$$

算例2相关参数沿用算例1设置,图3所示为本文方法对式(12)描述系统的仿真控制效果。从图3(a)中看出系统输出在小于2.5s内即达到稳定,并在小于5s内跟踪误差降至低误差范围内。由于系统非线性,初始学习阶段的超调量大于算例1结果,但仍保持在较低范围内。从图3(b)看出控制输出保持在低幅值,但由于系统非线性在控制器学习过程中,输出较算例1有明显的震荡,分析原因为系统与 y^d 信号作用使控制信号频率增加,并受Lyapunov约束项的压迫导致学习过程中的震荡。图3(c)表明对于该类非线性系统在较短的学习控制时间内仍能使跟踪误差收敛至很低范围(<0.06s)。

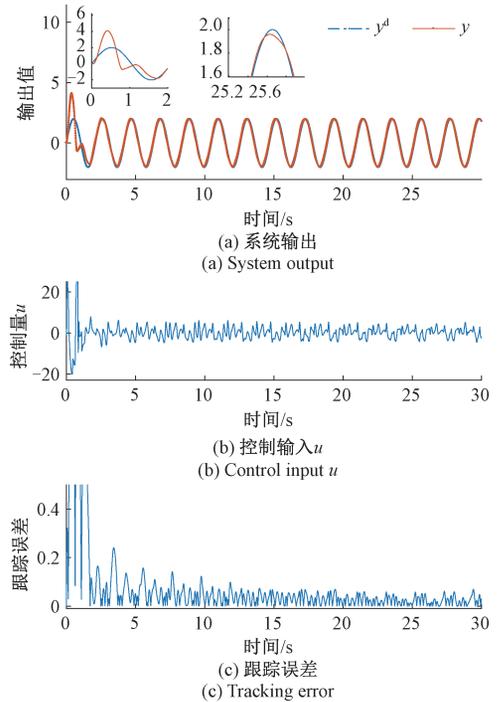


图3 算例2学习控制结果

Fig.3 Learning control performance of example 2

图4所示为控制器完成学习过程后的控制过程结果,从图4(a)看出学习后的跟随控制效果在初始阶段即优于学习控制过程,并且整体保持高跟踪精度,如图4(b)所示学习后的控制输出震荡明显小于学习过程,但由于非线性系统的频率叠加,控制输出震荡高于算例1结果;图4(c)表明虽然跟踪误差整体高于算例1但仍保持低误差水平。本文方法对于该类非线性系统具有良好的学习能力与控制性能。

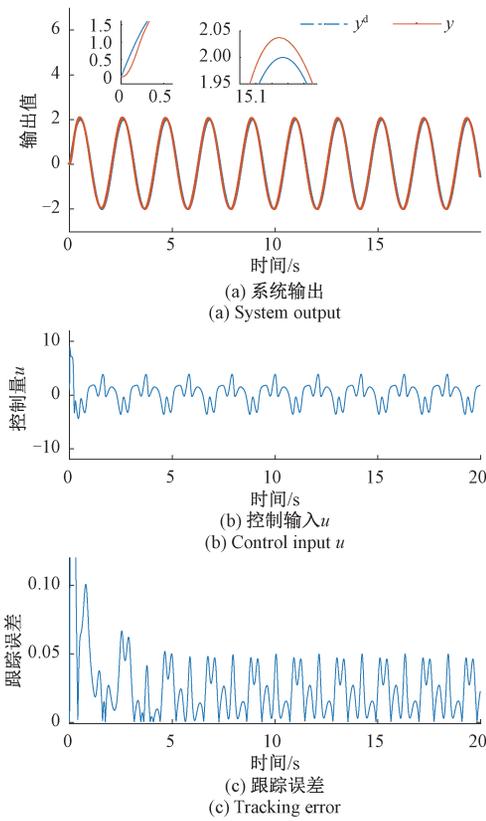


图4 学习完成后控制结果

Fig.4 Test performance of example 2 after learning

算例2 仿真实验证明了提出方法对于一类二阶非线性系统仍具有高控制性能。

算例3:在算例2基础上对模型加入随机扰动项 d_m 与噪声项 n_m 以测试本文方法的抗噪、抗能力,模型如下。

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = -A\cos x_2 - B\sin x_1 + Cu + d_m \\ y_h = x_1 + n_m \end{cases} \quad (13)$$

式中: d_m 与 n_m 分别为 ± 60 与 ± 0.2 的随机量。

测试阶段采用与学习阶段不同的模型参数与期望输出参数以测试本文方法对模型参数不确定问题的鲁棒性与学习算法的泛化能力。其中测试采用模型参数为 $A_{test} = 8$, $B_{test} = 6$, $C_{test} = 3$,期望输出设为 $y_t^{test,d} = 1.5\sin(6t)$ 。图5所示为测试过程中噪声与扰动信号时序。

为说明本文方法先进性,采用 Backstepping 控制作为基准方法按上述算例3条件仿真,与本文方法进行控制性能比较。图6所示为本文方法学习后的控制器与 Backstepping 控制方法在算例3条件下的控制效果。由于存在强扰动与噪声,并且期望输出频率高于学习阶段,控制输出幅值与频率整体高于算例2中图4结果,但跟踪误差幅值低于噪声幅值(如图4(c)所示)。如图6所示,在强噪声与扰动条件下,对于与学习阶段模型参数和

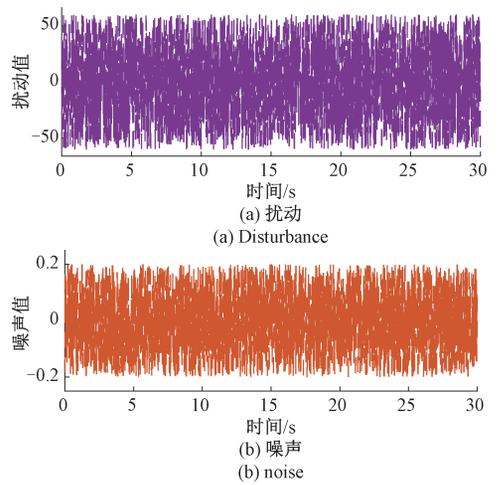


图5 算例3控制过程中的噪声与扰动

Fig.5 Disturbance and noise in example 3

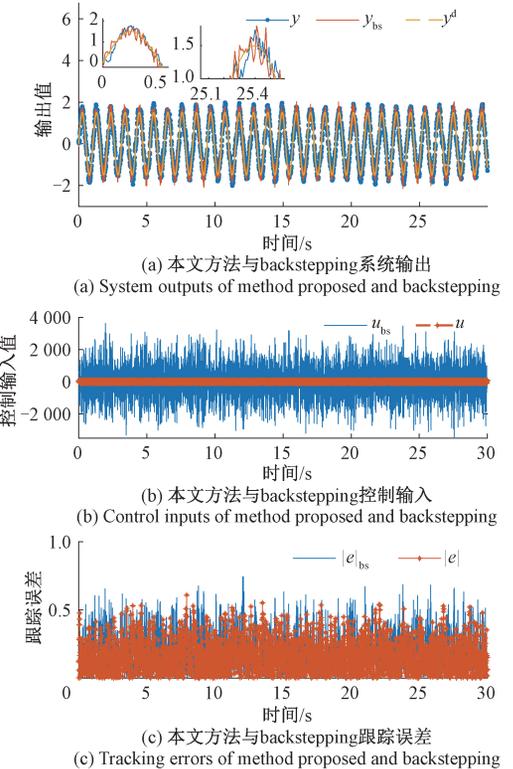


图6 算例3测试结果

Fig.6 Test performance of example 3 after learning

期望输出频率均不同的控制问题学习后的控制器表现出高精度控制性能与强抗扰能力。相比于 Backstepping 方法,本文方法与 Backstepping 方法的平均跟踪误差分别为 0.162 2 和 0.194 0,本文方法误差略低于后者,但控制输出 u 的平均幅值分别为 63.827 5 与 958.129 4,本文方法明显低于 Backstepping。算例3结果表明,对于该类非线性系统,本文方法具有良好的抗噪、抗能力、并对参数

不确定性具有鲁棒性,同时学习算法具有良好的泛化能力。

综上,算例1~3仿真结果验证了本文方法在不同类型系统控制上的有效性,并显示了在噪声、扰动、参数不确定性及学习泛化性等方面的优越性能,并具有一定先进性。

5 物理系统模拟与实物实验

如图7所示,首先在虚拟实验软件 V-Rep 环境下建立一级旋转倒立摆实验平台,以测试本文方法在实际系统中性能。(注:V-Rep 是已被学界认可的虚拟实验软件^[22],该软件集成了高精度物理引擎,能最大程度的呈现实际实验结果^[23],因此采用该软件的模拟实验结果高参考价值。)

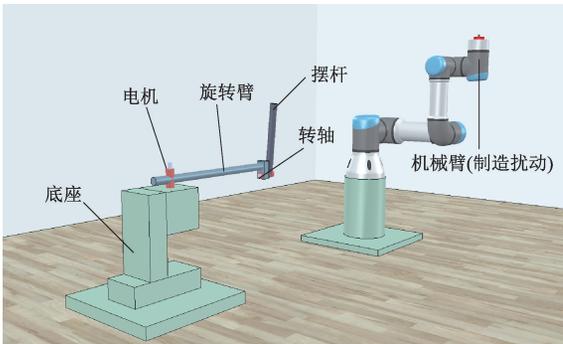


图7 V-Rep 模拟实验环境

Fig.7 Virtual experimental environment in V-Rep

一级旋转倒立摆实验平台相关参数如表1所示,实验对象的控制输出为平台电机转矩 τ_M ,被控量分别为摆杆角度 θ_{link} 与转台角度 $\theta_{platform}$ 。(注:在模拟实验环境中的动力学行为由 V-Rep 内部物理引擎计算,控制器设计中相关模型信息参考文献[24]获得。)本实验选择物理引擎为 Bullet2.83,仿真时间间隔为 10 ms,模型精度设为最高的“Very accurate”。实验采用 Python 远程 API 方式与 V-Rep 环境交互,采用同步模式以确保模拟实验的精确性。

首先对控制器学习阶段测试,以验证本文方法在实际系统下的学习与控制效果,设定初始条件为 $\theta_{link}^0 = 5^\circ$, $\theta_{platform}^0 = 0^\circ$ 期望角均为 0° (注:V-Rep 动力学引擎自带相关噪声模拟,因此本例中未添加噪声)。

图8所示为学习阶段控制结果,从中看出因初始误差和控制器学习初始阶段影响,被控量与控制量在 1 s 内均出现震荡,但在经 1.5 s 后被控量与控制输出均趋于稳定并在 1.5 s 后保持较小误差。该模拟实验 θ_{link} , $\theta_{platform}$ 的调节时间均为 1.2 s,稳态误差小于 0.5° ,超调分别

表1 一级旋转倒立摆参数

Table 1 Parameters of one-stage rotary inverted pendulum

符号	数值	单位	物理意义
m_0	57	kg	底座质量
m_1	0.062 83	kg	摆杆质量
m_2	0.150 7	kg	旋转臂质量
l_1	0.2	m	摆杆长度
l_2	0.4	m	旋转臂长度
I_1	0.002 439	$\text{kg}\cdot\text{m}^2$	旋转臂转动惯量 X
I_1	0.000 014	$\text{kg}\cdot\text{m}^2$	旋转臂转动惯量 Y
I_1	0.002 435	$\text{kg}\cdot\text{m}^2$	旋转臂转动惯量 Z
I_2	0.000 506	$\text{kg}\cdot\text{m}^2$	摆杆转动惯量 X
I_2	0.000 506	$\text{kg}\cdot\text{m}^2$	摆杆转动惯量 Y
I_2	0.000 008	$\text{kg}\cdot\text{m}^2$	摆杆转动惯量 Z

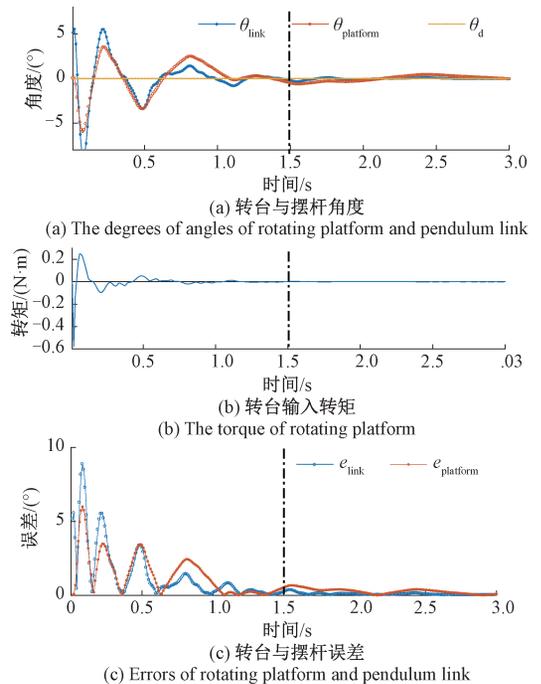


图8 一级旋转倒立摆控制器学习阶段测试结果

Fig.8 The results of controlling of one-stage rotary inverted pendulum using the controller under learning

为 9° 与 6° ,因此得出加入了 Lyapunov 稳定性约束的学习控制器能使模拟实验系统的被控量快速的收敛,进而验证了本文方法在实际物理系统有效性。图9所示为上述实验的视频图序,从中可看出在整个控制器参数学习过程中系统保持稳定,进一步证明了方法有效性。

下一测试通过模拟环境中机械臂运动为旋转倒立摆系统施加扰动,以测试经学习后的控制器在实际扰动下的控制效果。如图10所示为实验视频图序启动机械臂

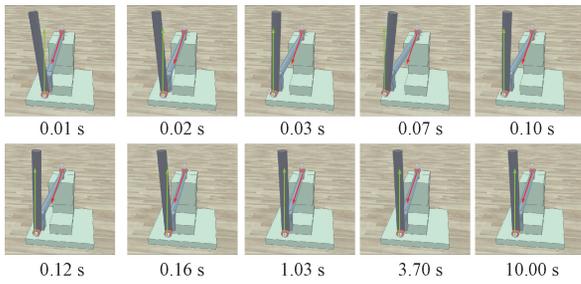


图9 控制器学习阶一级旋转倒立摆实验视频图序
Fig.9 The snapshots of controlling of one-stage rotary inverted pendulum using the controller under learning

并在 2.32 s 时刻对系统施加扰动, 2.43 s 扰动消失。图 11 所示为测试结果, 从图中可看出系统被施加扰动后, 两被控角度均在 2.32 s 时刻产生较大跳变, 虽然扰动作用在旋转臂上但转台主轴承承担了二个被控量控制, 因此 $\theta_{platform}$ 震荡幅值大于 θ_{link} , 同时控制力矩也随之震荡并且幅值高于上一测试结果; 此外系统在承受较大扰动条件下, 在 5 s 后系统被控量与控制力矩均趋于收敛, 并且两控制量误差均处于很小范围, 该模拟实验 $\theta_{link}, \theta_{platform}$ 的调节时间均为 2.52 s, 稳态误差小于 1° , 超调分别为 38° 与 30° , 控制指标均不如前一测试结果, 其原因在于本实验受到的冲击扰动远大于算例 1~3 测试, 但本实验结果证明在受到较大扰动后控制器仍可快速实现稳定。由图 11 可见, 整个实验过程中系统受到撞击扰动, 仍能够迅速调整并保持稳定, 证明了本文方法在实际系统控制的有效性 & 鲁棒性。上述实验结果与分析表明, 经学习后的学习控制器系统能够应用于实际物理系统并具有强抗扰能力。

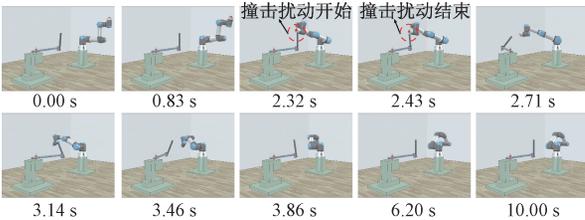


图 10 完成学习的控制器在撞击扰动条件下的实验视频图序
Fig.10 Snapshots of controlling of one-stage rotary inverted pendulum with physical disturbance using the controller after learning

最后利用 V-Rep 模拟实验环境与实际系统进行四旋翼无人机系统的单轴姿态控制实验, 如图 12 所示。首先在 V-Rep 环境中按旋转倒立摆方式训练学习控制器, 后将学习后控制器用于实际系统测试, 以验证本文方法在实际系统的有效性 & 实用性。模拟实验与实际单轴控制实验均采用串级控制, 外环采用 PID 控制、内环采用本文方法。

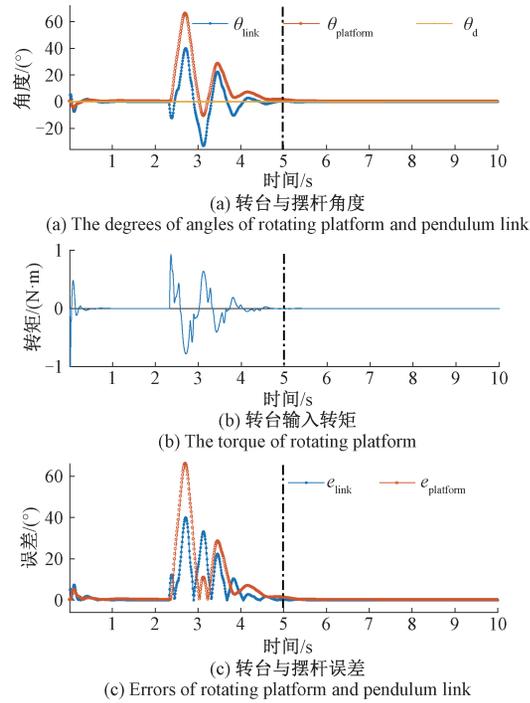


图 11 学习后控制器实际扰动下控制结果
Fig.11 The results of controlling of one-stage rotary inverted pendulum with physical disturbance using the controller after learning

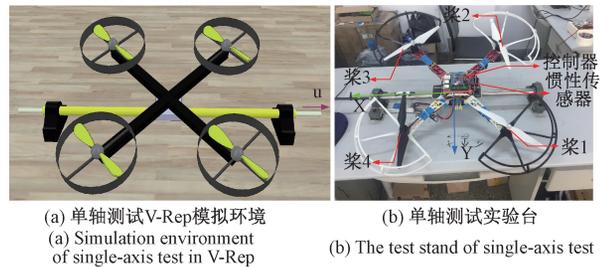


图 12 四旋翼单轴测试 V-Rep 与实物实验环境
Fig.12 Experimental environment for single-axis test of quadrotor in V-Rep and physical platform

实验针对四旋翼坐标系 x 轴转角(即 Roll 角)控制, 角度通过 IMU 模块反馈, 计算控制量 u 和对应的四个桨 PWM 信号(2 000~4 000), 不同 PWM 值对应不同转速, 转速平方近似正比于升力, 通过控制轴两侧升力差产生的转矩调节轴转角。实验中初始 Roll 角为 -23.4943° , 图 13 所示为经 V-Rep 环境训练后的学习控制器在实物实验平台测试视频图序, 如图 13 所示在四旋翼进入稳态后, 分别在约 15、30、45 s 左右施加 3 次冲击扰动(如图中圆圈所示)。

图 14 所示为实物实验测试结果(注:单轴实验 X 轴两侧旋翼 PWM 值保持一致, 即 $PWM1 = PWM4, PWM2 =$

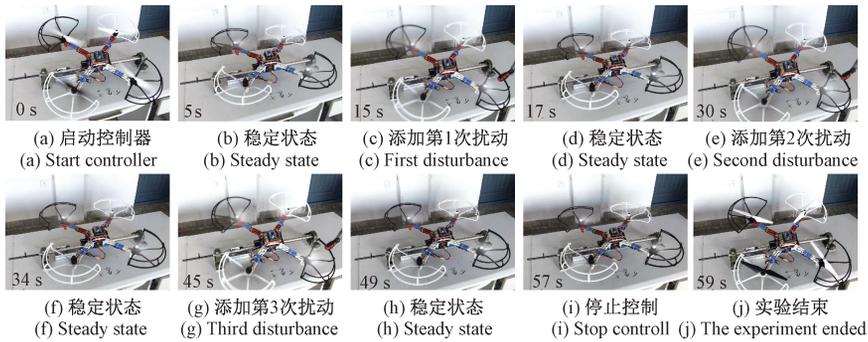


图 13 学习后控制器在实际四旋翼实验视频附

Fig.13 Snapshots of single-axis controlling using the trained controller in V-Rep

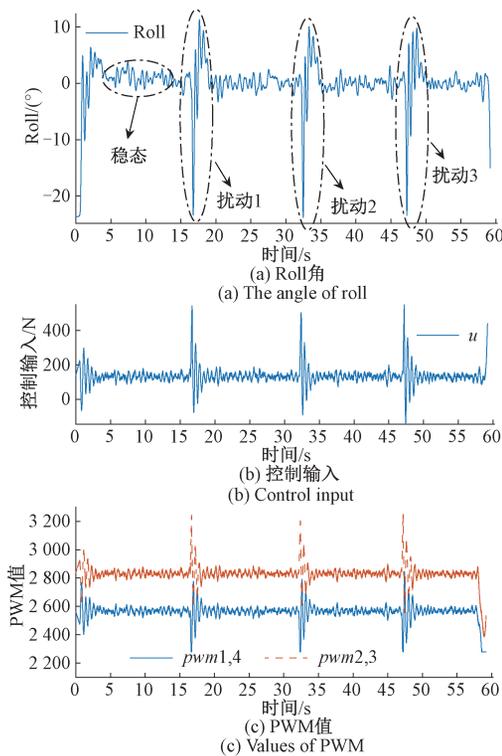


图 14 学习后控制器四旋翼单轴实验结果

Fig.14 Experimental results for single-axis controlling using controller trained

PWM3), 图 14 中曲线噪声由 IMU 传感器噪声与转桨转动谐波叠加所致, 从 Roll 曲线图看出系统在 5 s 内进入稳态过程, 当受到扰动后仍可在 5 s 内保持稳定。从控制 u 与 PWM 曲线看出, 除在初始调节与扰动抑制过程外均保持低幅值。稳态时 u 值不为 0 原因在于: 1) 转角控制中无人机机体与转轴间产生摩擦力/矩, 该力/矩在稳态中与 u 产生的部分力矩抵消并保持系统稳态; 2) 机体 X 轴两侧质量不等, 质量差产生的力矩抵消部分 u 产生的力矩。

本实验中, Roll 角控制的调节时间小于 5 s, 稳态误差在 $\pm 3^\circ$ 内, 初始超调量小于 6.5° , 扰动最大调节时间小

于 5 s, 稳态误差在 $\pm 3^\circ$ 内, 最大超调量小于 12° 。虽然控制性能指标良好, 但分析制约性能因素有以下几点: 1) 实物实验中摩擦特性与 V-Rep 不同; 2) V-Rep 中模型参数与实际系统存在差异; 3) 实际实验中噪声强且成份复杂, 以上 3 点是制约本文方法在实际系统控制中性能的主要因素。综上得出, 经 V-Rep 模拟学习后的控制器在实际四旋翼系统单轴控制中仍保持稳定且具有良好的控制性能, 验证了本文在实际系统中的有效性与实用性。

旋转摆模拟实验与单轴控制实物实验结果得出, 本文方法在实际物理系统控制问题中能够有效实现控制器参数学习, 且学习后的控制器可应用于实际系统中, 并对实际扰动具有较强的抑制能力, 两实验基本验证了本文方法对于实际系统的有效性与实用性。

6 结 论

通过上述理论分析、仿真与模拟实验测试得出以下结论: 1) 本文提出的基于 Lyapunov 稳定性条件约束的学习控制器设计方法, 对于二阶线性、非线性系统具有良好的控制器学习能力, 能够直接设计控制品质良好并具有全局稳定性的神经网络控制器; 2) 采用的控制输出限幅技术能够保证控制器输出在限定范围内, 进而规避了输出饱和问题, 同时满足实际控制需要; 3) 采用的深度学习优化技术与惩罚函数正则方法展现了良好的优化性能, 提升了控制器求解能力; 4) 本文方法具有对实际物理扰动的抑制能力。上述结论表明了本文方法的有效性、实用性与先进性。

本文研究内容为前期的基础工作, 如下问题值得分析与后续研究: 1) 本文采用了基于 PID 参数与前馈作为输入的控制形式, 因此学习阶段可看成对该种控制器的参数寻优, 同时控制器形式也是决定性能的关键因素, 后续研究将分析其他结构控制器; 2) 仿真测试中用到了系统模型结构与反馈状态信息, 后续研究将利用辨识技术对方法进行无模型化与输出反馈扩展; 3) 后续研究将

增加仿真模型类型并将方法应用于其他实际系统,同时对方法适用范围做理论分析。

参考文献

- [1] MATTILA J, KOIVUMÄKI J, CALDWELL D G, et al. A survey on control of hydraulic robotic manipulators with projection to future trends[J]. IEEE/ASME Transactions on Mechatronics, 2017, 22(2): 669-680.
- [2] FIACCHINI M, JUNGERS M, GIRARD A. Stabilization and control Lyapunov functions for language constrained discrete-time switched linear systems [J]. Automatica, 2018, 93: 64-74.
- [3] YU ZH X, LI SH G, YU ZH SH, et al. Adaptive neural output feedback control for nonstrict-feedback stochastic nonlinear systems with unknown backlash-Like hysteresis and unknown control directions[J]. IEEE Transaction on Neural Networks and Learning Systems, 2018, 29(4): 1147-1160.
- [4] LE-TIEN L, ALBU-SCHÄFFER. A. Robust adaptive tracking control based on state feedback controller with integrator terms for elastic joint robots with uncertain parameters [J]. IEEE Transactions on Control Systems Technology, 2018, 26(6): 2259-2267.
- [5] WANG D, HE H B, LIU D R. Adaptive critic nonlinear robust control: a survey [J]. IEEE Transactions on Cybernetics, 2017, 47(10): 3429-3451.
- [6] YANG Y N, YAN Y. Backstepping sliding mode control for uncertain strictfeedback nonlinear systems using neural-network-based adaptive gain scheduling [J]. Journal of Systems Engineering and Electronics, 2018, 29(3): 580-586.
- [7] HOMER T, MHASKAR P. Constrained control lyapunov function-based control of nonlinear systems[J]. Systems & Control Letters, 2017, 110: 55-61.
- [8] WEN G X, GE S ZH S, TU F W. Optimized backstepping for tracking control of strict-feedback systems[J]. IEEE Transactions on Neural Networks and Learning Systems, 2018, 29(8): 1-13.
- [9] 兰永红, 黄奇奔 颜渐德. 基于干扰观测器的永磁同步电机反推控制[J]. 电子测量与仪器学报, 2017, 31(9): 1524-1531.
- LAN Y H, HUANG Q H, YAN J D. Disturbance observer-based backstepping control for PMSM [J]. Journal of Electronic Measurement and Instrumentation, 2017, 31(9): 1524-1531.
- [10] ASCENCIO P, ASTOLFI A, PARISINI T. Backstepping PDE design: A convex optimization approach[J]. IEEE Transactions on Automatic Control, 2017, 63(7): 1943-1958.
- [11] FURGON R, CHEN Y J, TANAKA M, et al. An SOS-based control lyapunov function design for polynomial fuzzy control of nonlinear systems[J]. IEEE Transactions On Fuzzy Systems, 2017, 25(4): 775-787.
- [12] SONTAG E D. A ‘universal’ construction of Artstein’s theorem on nonlinear stabilization [J]. Systems and Control Letters, 1989, 13(2): 117-123.
- [13] GUERRO-CASTELLANOS J F, RIFAÍ H, ARNEZ-PANIAGUA V, et al. Robust active disturbance rejection control via control lyapunov functions: Application to actuated-ankle-foot-orthosis [J]. Control Engineering Practice, 2018, 80(18): 49-60.
- [14] 陈奕梅, 韩正之. 基于控制 Lyapunov 函数的鲁棒自适应控制器设计[J]. 系统工程与电子技术, 2006, 28(3): 435-438.
- CHEN Y M, HAN ZH ZH. Design of robust adaptive controller based on the control Lyapunov function [J]. Systems Engineering and Electronics, 2006, 28(3): 435-438.
- [15] 惠宇, 池荣虎. 基于迭代扩张状态观测器的数据驱动最优迭代学习控制 [J]. 控制理论与应用, 2018, 35(11): 1672-1679.
- HUI Y, CHI R H. Iterative extended state observer based data driven optimal iterative learning control [J]. Control Theory & Applications, 2018, 35(11): 1672-1679
- [16] MAYNE D Q. Model predictive control: recent developments and future promise [J]. Automatica, 2014, 50(12): 2967-2986.
- [17] SHEN CH, SHI Y, BUCKHAM B. Trajectory tracking control of an autonomous underwater vehicle using lyapunov-based model predictive control [J]. IEEE Transactions on Industrial Electronics, 2018, 65(7): 5796-5805.
- [18] DE LA PENA D M, CHRISTOFIDES P D. Lyapunov-based model predictive control of nonlinear systems subject to data losses [J]. IEEE Transactions on Automatic Control, 2008, 53(9): 2076-2089.
- [19] 马乐, 王东, 李元昕, 等. 全向旋翼机械臂设计建模及动态补偿 PID 控制 [J]. 仪器仪表学报, 2018, 39(3): 89-99.
- MA L, WANG D, LI Y X, et al. Design, modeling and dynamic compensation control of a fully-actuated aerialmanipulation System [J]. Chinese Journal of Scientific Instrument, 2018, 39(3): 89-99.
- [20] CLEMPNER J B. Necessary and sufficient Karush-Kuhn-Tucker conditions for multiobjective markov chains optimality [J]. Automatica, 2017, 42(71): 135-142.

- [21] LIU W, ANGUELOV D, ERHAN D, et al. SSD: Single shot multiBox detector [C]. European Conference on Computer Vision, 2016: 21-37.
- [22] CHEN J, JIA B X, ZHANG K X. Trifocal Tensor-based adaptive visual trajectory tracking control of mobile robots[J]. IEEE Transactions On Cybernetics, 2017, 47(11): 3784-3798.
- [23] 国易,毛建旭,王耀南,等. 多移动机器人运动目标环绕与避障控制[J]. 仪器仪表学报, 2018, 2(39): 11-20.
GUO Y, MAO J X, WANG Y N, et al. Circumnavigation of a moving target and obstacle avoidance with multiple mobile robots [J]. Chinese Journal of Scientific Instrument, 2018, 2(39): 11-20.
- [24] DWIVEDI P, PANDEY S, JUNGHARE A S. Stabilization of unstable equilibrium point of rotary inverted pendulum using fractional controller[J]. Journal of the Franklin Institute, 2017, 354(17): 7732-7766.

作者简介



马乐,2006年于辽宁工业大学获得学士学位,2009年于东北电力大学获得硕士学位,2014年于沈阳工业大学获得博士学位,现为东北电力大学副教授,主要研究方向为旋翼机械臂系统与控制、机器人控制、机器人视觉。

E-mail: male_robot_nedu@sina.com

Ma Le received his B. Sc. degree from Liaoning University of Technology in 2006, M. Sc. degree from Northeast Electric Power University in 2009, and Ph. D. degree from Shenyang University of Technology in 2014. He is currently an associate professor at Northeast Electric Power University. His main research interests include aerial manipulation control, robot control and computer vision.



李志伟(通信作者),分别在2008年和2012年于东北林业大学取得硕士、博士学位。2016年至今,任职于东北电力大学自动化工程学院,主要研究方向为非线性系统建模、控制及数值模拟。

E-mail: zhiwei.li@neepu.edu.cn

Li Zhiwei (Corresponding author) received his M. Sc. and Ph. D. degrees in control theory and control engineering both from Northeast Forestry University in 2008 and 2012, respectively. He has been a faculty with the School of Automation Engineering at Northeast Electric Power University since 2016. His research interests include establishment and control of nonlinear dynamic system & numerical simulation research and its applications.