

DOI:10.19344/j. cnki. issn1671-5276.2024.01.023

基于 LMI 和扰动观测器的电动伺服系统 RBF 神经网络控制

李晓飞, 范元勋, 许鹿辉

(南京理工大学 机械工程学院, 江苏 南京 210094)

摘要: 为了提高电动伺服系统的加载力跟踪精度, 基于线性矩阵不等式(LMI)设计扰动观测器和控制器。针对系统中的非线性因素, 采用 RBF 神经网络逼近系统的数学模型; 在建立系统跟踪目标模型的基础上, 根据 LMI 设计扰动观测器对控制器进行多余力的补偿, 利用李雅普诺夫函数证明扰动观测器和控制器的收敛; 在 MATLAB/Simulink 中搭建仿真模型, 分析扰动观测器和 RBF 神经网络在不同工况下对系统相应量的精准估计, 且误差均满足所设定的性能指标, 同时与 PID 控制相比较, 证明所提控制策略的控制性能更优。

关键词: 电动伺服系统; 线性矩阵不等式; 扰动观测器; RBF 神经网络

中图分类号: TM351 **文献标志码:** A **文章编号:** 1671-5276(2024)01-0113-05

RBF Neural Network Control of Electric Servo System Based on LMI and Disturbance Observer

LI Xiaofei, FAN Yuanxun, XU Luhui

(School of Mechanical Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: In order to improve the loading force tracking accuracy of the electric servo system, a system of disturbance observer and controller is designed based on linear matrix inequality (LMI). Aimed at the nonlinear factors in the system, the RBF neural network is used to approximate the mathematical model of the system. Based on the establishment of the system tracking target model, the disturbance observer is designed according to LMI to compensate the excess force of the controller, and the Lyapunov function is applied to prove the convergence of disturbance observer and controller. A simulation model is constructed in MATLAB/Simulink, and the accurate estimation of the corresponding quantities of the system by the disturbance observer and RBF neural network is conducted under different working conditions, which shows that the errors all meet the set performance indicators, and the control performance of the proposed control strategy is better compared with PID control.

Keywords: electric serv system; linear matrix inequality; disturbance observer; RBF neural network

0 引言

电动伺服系统又称电动直线负载模拟系统(ELLS), 是对某型号航天用直线舵机进行硬件在环仿真的一种试验装置, 可实现在一定精度范围内对直线舵机的动态加载。但由于系统本身存在的不确定性和舵机位置输入所产生的多余力干扰, 使得 ELLS 在实际加载的过程中很难实现对输入信号的实时动态跟踪^[1]。因此, 实现对系统的精准控制, 提高加载过程中的准确度, 是 ELLS 的重点研究内容。

目前, 众多学者通过不同的控制理论对类似系统进行准确的跟踪控制, 主要有滑模控制、自抗扰控制、模型自适应控制及模糊和神经网络自适应等控制方式。针对控制系统中存在的非线性问题, LIU 等^[2]提出了一种基于神经网络近似的反

演滑模控制方法并利用神经网络逼近器来在线估计航天器的动力学不确定性, 有效地减少了滑模控制的抖振。聂守成等^[3]利用干扰观测器估计模型的不确定性并将其引入滑模切换函数中, 结合自适应算法完成对系统的位置跟踪。对于未知的负载转矩扰动, 董中华等^[4]针对采摘机械臂的不确定性设计一种 PSO-RBF 神经网络自适应控制器, 有效地实现轨迹的跟踪。

在具有反馈环节的控制系统设计过程中, 需经常考虑系统中存在的不确定性等约束条件, 在处理这些问题时, 其中一种思路就是将其转换为一个带有 LMI 约束的最优化问题^[5]。孙宜标等^[6]将通过扩张观测器与 LMI 滑模控制结合, 应用到直线伺服系统中, 提高了系统的鲁棒性。

为了提高系统的跟踪精度, 本文在建立系统

基金项目: 航天一院 CALT 基金资助项目(CALT201512)

第一作者简介: 李晓飞(1997—), 男, 河南周口人, 硕士研究生, 研究方向为机电系统理论与技术, aasd0314@foxmail.com。

状态空间表达式和跟踪目标模型的基础上,基于LMI理论设计扰动观测器并将其应用到RBF神经网络控制器中,结合仿真验证该方法的有效性。

1 系统组成及其数学模型

1.1 结构组成

根据系统的功能划分,ELLS可分为加载系统、舵系统和测控系统3个组成部分,结构组成如图1所示。加载系统由PMSM、滚珠丝杠副及其之间的连接单元组成;舵系统由被测直线舵机组成;测控系统由上位机、工控机和数据采集单元组成。舵机被加载系统通过拉压力传感器与加载系统机械连接,以此完成对舵机的动态加载。由上位机编写PMSM和舵机运动控制程序,经TCP/IP传送至工控机,随后分别通过EtherCAT协议和RS422通信将控制指令传送至PMSM和舵机,与此同时,工控机对上位机传送过来的数据与采集卡接收的各传感器数据进行实时比较,形成闭环控制。




图1 ELLS结构组成示意图

1.2 数学模型

ELLS的数学模型主要从PMSM和中间传动环节的分析得到。采用 $d-q$ 坐标转换对PMSM进行建模。对其进行简化,令 d 轴 $i_d=0$,得到定子电压和电磁转矩方程,这里直接给出动态方程^[7],如式(1)所示。

$$\begin{cases} u_q = R_m i_q + L_m \dot{i}_q + K_e \omega_e \\ T_e = K_t i_q \\ T_e = T_L + B_m \omega_r + J_m \dot{\omega}_r \end{cases} \quad (1)$$

式中: L_m 、 u_q 和 i_q 分别为 q 轴的等效电感、定子电压和电流; R_m 为定子电阻值; ω_e 为转子电角速度; K_e 为反电动系数,且 $K_e = L_m i_d + \psi_f$,其中 ψ_f 为转子永磁体磁链; i_d 为 d 轴的等效定子电流; K_t 为转矩系数,且 $K_t = p_n \psi_f$,其中 p_n 为极对数; T_L 、 J_m 分别为折合到转轴上的负载转矩、等效转动惯量; B_m 为阻尼系数; ω_r 为机械角速度。

视转矩转速传感器为弹性元器件,结合滚珠

丝杠的运动转换关系,得到两者的数学模型如式(2)所示。

$$\begin{cases} T_L = K_A (\theta_r - \theta_l) \\ F = \frac{2\pi\eta}{P} T_L \end{cases} \quad (2)$$

式中: K_A 、 θ_r 、 θ_l 分别为转矩转速传感器的刚度系数和输入、输出角位移; η 和 P 分别为滚珠丝杠副的传动效率和导程。

综合式(1)和式(2),经拉普拉斯变换,得到图2所示的ELLS的模型。




图2 ELLS函数方块图

由图2的输出力 F 与输入电压 u_q 之间的传递函数,令状态变量为 $\mathbf{x} = [x_1 \ x_2 \ x_3]^T = [F \ \dot{F} \ \ddot{F}]^T$,可得到系统的状态空间表达式为

$$\begin{cases} \dot{\mathbf{x}} = \mathbf{A}\mathbf{x} + \mathbf{B}[\alpha(\mathbf{x}) + u + d] \\ y = \mathbf{c}^T \mathbf{x} \end{cases} \quad (3)$$

式中: $\alpha(\mathbf{x}) = -a_1 x_1 - a_2 x_2 - a_3 x_3$,其中 $a_3 = \frac{J_m R_m + B_m L_m}{J_m L_m b}$, $a_2 = \frac{K_A L_m + B_m R_m + K_e K_t}{J_m L_m b}$, $a_1 = \frac{K_A R_m}{J_m L_m b}$, $b =$

$$\frac{K_t K_A}{J_m L_m} \cdot \frac{2\pi\eta}{P}; \mathbf{A} = \begin{bmatrix} 0 & 1 & 0 \\ 0 & 0 & 1 \\ 0 & 0 & 0 \end{bmatrix}; \mathbf{B} = [0 \ 0 \ b]^T, \mathbf{c}^T =$$

$[1 \ 0 \ 0]$; u 为系统输入; d 为名义干扰。结合式(1)一式(3)可得

$$d = \frac{4\pi^2\eta}{P^2 d} K_A \left(\ddot{L} + \frac{J_m R_m + B_m L_m}{J_m L_m} \dot{L} + \frac{B_m R_m + K_e K_t}{J_m L_m} L \right) \quad (4)$$

式中: L 为舵机的扰动位移; $\dot{L}$ 为舵机的扰动速度; $\ddot{L}$ 为舵机的扰动加速度; $\ddot{L}$ 为舵机的扰动加加速度。

2 控制器和扰动观测器的设计及分析

2.1 目标模型确定

令式(3)所示系统的输入指令为 x_r ,与其一阶、二阶导数组成输入向量 $\mathbf{x}_r = [x_r \ \dot{x}_r \ \ddot{x}_r]^T$,定义系统跟踪误差向量为 $\mathbf{e} = [e \ \dot{e} \ \ddot{e}]^T = \mathbf{x} -$

x_r , 由于

$$\ddot{e} = b\alpha(x) + bu + bd - \ddot{x}_r \quad (5)$$

令 $b\tau = bu - \ddot{x}_r$, 则式(5)变为 $\ddot{e} = b[\alpha(x) + \tau + d]$, 可得误差状态空间表达式为

$$\dot{e} = A\mathbf{e} + B[\alpha(x) + \tau + d] \quad (6)$$

则其控制目标变为设计系统控制器, 使其输出满足 $u = \tau + \ddot{x}_r/b$ 时, 实现 $t \rightarrow \infty$ 时, $\mathbf{e} = 0$ 。

2.2 基于扰动观测器的RBF神经网络LMI自适应跟踪控制

在实际应用中, d 不仅仅包括舵机对系统的扰动, 还包括一些摩擦等非线性因素的影响, 这些非线性因素的干扰导致 d 无法准确获得, 而LMI作为一种数学工具, 已经被广泛地应用到现代控制理论中, 主要原因就是控制系统中很多问题都可以转换为LMI系统的可行性问题, 即LMI约束下的凸优化问题^[8]。

定义扰动观测器为

$$\begin{cases} \dot{z} = -K_d \{A\mathbf{e} + B[\alpha(x) + \tau + \hat{d}]\} \\ \dot{\hat{d}} = z + K_d \mathbf{e} \end{cases} \quad (7)$$

式中: K_d 为扰动观测器的增益向量; z 为扰动观测器的状态量; $\hat{d}$ 为观测到的扰动量。

取 $\tilde{d} = d - \hat{d}$, 结合式(6)和式(7), 得

$$\dot{\tilde{d}} = \dot{d} - (-K_d B \hat{d} + K_d B d) = \dot{d} - K_d B \tilde{d} \quad (8)$$

同样, 表达式 $\alpha(x)$ 往往包括非线性等因素的影响, 获取数学模型比较困难, 而RBF神经网络可以对任意未知的非线性函数进行逼近^[9], 因此这里使用RBF神经网络对 $\alpha(x)$ 进行估计, 取RBF神经网络算法为

$$\begin{cases} h_j = \exp\left(-\frac{\|\mathbf{x} - \mathbf{c}_{ij}\|^2}{2b_j^2}\right) \\ \alpha(\mathbf{x}) = \mathbf{W}^{*T} \mathbf{h}(\mathbf{x}) + \varepsilon \end{cases} \quad (9)$$

式中: $\mathbf{x}$ 为网络的输入; i 为网络的输入个数; j 为网络隐含层第 j 个节点; $\mathbf{h} = [h_1 \ h_2 \ \cdots \ h_n]^T$ 为高斯函数的输出; $\mathbf{W}^*$ 为网络的理想权值; ε 为网络的逼近误差, $|\varepsilon| \leq \varepsilon_N$ 。

RBF神经网络的输入取 $\mathbf{x} = [x_1 \ x_2 \ x_3]^T$, 则其输出为

$$\hat{\alpha}(\mathbf{x}) = \hat{\mathbf{W}}^T \mathbf{h}(\mathbf{x}) \quad (10)$$

因此

$$\tilde{\alpha}(\mathbf{x}) = \alpha(\mathbf{x}) - \hat{\alpha}(\mathbf{x}) = \tilde{\mathbf{W}}^T \mathbf{h}(\mathbf{x}) + \varepsilon \quad (11)$$

式中 $\tilde{\mathbf{W}} = \mathbf{W}^* - \hat{\mathbf{W}}$ 。

定义控制器设计为

$$\tau = \mathbf{K}\mathbf{e} - \hat{\alpha}(\mathbf{x}) - \hat{d} \quad (12)$$

式中: $\mathbf{K} = [k_1 \ k_2 \ k_3]$; $\hat{\alpha}(\mathbf{x})$ 为RBF神经网络的输出。

设计李雅普诺夫函数如下

$$V_c = \mathbf{e}^T \mathbf{P} \mathbf{e} + \frac{1}{\gamma} \tilde{\mathbf{W}}^T \tilde{\mathbf{W}} + \tilde{d}^2 \quad (13)$$

式中: $\mathbf{P} > 0$; $\mathbf{P} = \mathbf{P}^T$; $\gamma > 0$ 。

通过设计 $\mathbf{P}$, 可以调节 $\mathbf{e}$ 的收敛, 并且便于LMI的求解。对式(13)求导, 结合式(6)、式(8)、式(11)和式(12), 得

$$\begin{aligned} \dot{V}_c &= 2\mathbf{e}^T \mathbf{P} \dot{\mathbf{e}} - \frac{2}{\gamma} \tilde{\mathbf{W}}^T \dot{\tilde{\mathbf{W}}} + 2\tilde{d} \dot{\tilde{d}} = 2\mathbf{e}^T \mathbf{P} (A + B\mathbf{K}) \mathbf{e} + \\ &2\tilde{\mathbf{W}}^T \left[\mathbf{e}^T \mathbf{P} B \mathbf{h}(\mathbf{x}) - \frac{\dot{\tilde{\mathbf{W}}}}{\gamma} \right] + 2\mathbf{e}^T \mathbf{P} B (\varepsilon + \tilde{d}) - 2K_d B \tilde{d}^2 + \\ &2\tilde{d} \dot{\tilde{d}} \end{aligned} \quad (14)$$

令 $\dot{V}_{ci} = -2K_d B \tilde{d}^2 + 2\tilde{d} \dot{\tilde{d}}$, 则

$$\dot{V}_{ci} \leq -2K_d B \tilde{d}^2 + \sigma \tilde{d}^2 + \frac{1}{\sigma} \bar{D}^2 \quad (15)$$

式中: $|\dot{\tilde{d}}| \leq \bar{D}$, $\bar{D}$ 为正的常数; $\sigma > 0$ 。

设计RBF神经网络的自适应律为

$$\dot{\hat{\mathbf{W}}} = \gamma \mathbf{e}^T \mathbf{P} B \mathbf{h}(\mathbf{x}) \quad (16)$$

结合式(15), 则 $\dot{V}_c$ 存在

$$\begin{aligned} \dot{V}_c &\leq 2\mathbf{e}^T \mathbf{P} (A + B\mathbf{K}) \mathbf{e} + \delta \mathbf{e}^T \mathbf{P} B (\mathbf{e}^T \mathbf{P} B)^T + 2\mathbf{e}^T \mathbf{P} B \tilde{d} - \\ &2K_d B \tilde{d}^2 + \sigma \tilde{d}^2 + \frac{1}{\sigma} \bar{D}^2 + \frac{1}{\delta} \varepsilon_N^2 = \boldsymbol{\xi}^T \boldsymbol{\Phi} \boldsymbol{\xi} + \frac{1}{\sigma} \bar{D}^2 + \frac{1}{\delta} \varepsilon_N^2 \end{aligned} \quad (17)$$

式中: $\boldsymbol{\Phi} = \begin{bmatrix} \mathbf{P}(A + B\mathbf{K}) + * + \delta \mathbf{P} B B^T \mathbf{P} & \mathbf{P} B \\ B^T \mathbf{P} & -(K_d B + *) + \sigma \end{bmatrix}$;

$\boldsymbol{\xi} = [\mathbf{e}^T \ \tilde{d}]^T$, 其中, $A + * = A + A^T$; 符号 $*$ 代表矩阵的转置, 即 $\mathbf{P}(A + B\mathbf{K}) + * = \mathbf{P}(A + B\mathbf{K}) + (A + B\mathbf{K})^T \mathbf{P}$; $K_d B + * = K_d B + B^T K_d$ 。

为使不等式收敛, 令 $\boldsymbol{\Phi} + \alpha \mathbf{P}_0 < 0$, $\alpha > 0$, 即 $\boldsymbol{\Phi} < -\alpha \mathbf{P}_0$, 其中 $\mathbf{P}_0 = \text{diag}\{\mathbf{P}, \mathbf{I}\}$, 则存在

$$\begin{bmatrix} \mathbf{P}(A + B\mathbf{K}) + * + \delta \mathbf{P} B B^T \mathbf{P} + \alpha \mathbf{P} & \mathbf{P} B \\ B^T \mathbf{P} & -(K_d B + *) + \sigma + \alpha \end{bmatrix} < 0 \quad (18)$$

将式(18)左右同乘以 $\text{diag}\{\mathbf{P}^{-1}, \mathbf{I}\}$, 令 $\mathbf{Q}_1 = \mathbf{P}^{-1}$, $\mathbf{N} = \mathbf{K} \mathbf{Q}_1$, 可得第一个LMI为

$$\begin{bmatrix} A Q_1 + B N + * + \delta B B^T + \alpha Q_1 & B \\ B^T & -(K_d B + *) + \sigma + \alpha \end{bmatrix} < 0 \quad (19)$$

式中 $A Q_1 + B N + * = A Q_1 + B N + (A Q_1 + B N)^T$ 。

根据 $Q_1 = P^{-1}$, $P > 0$, 可得第二个 LMI 为

$$Q_1 > 0 \quad (20)$$

在第一个 LMI 中, 存在 $K_d B$ 项, 因为 $B = [0 \ 0 \ b]^T$, 则可确定 K_d 的前两个元素对扰动观测器不产生影响, 这里取 0, 结合 MATLAB 的 LMI 工具箱求解以上两个 LMI, 可得 $K_d = [0 \ 0 \ k]$, R 和 Q_1 , 其中 $k > 0$, 由 $N = K Q_1$, 进而求得 K 。

根据以上分析, 收敛性分析如下:

$$\begin{aligned} \dot{V}_e &\leq \xi^T \Phi \xi + \frac{1}{\sigma} \bar{D}^2 + \frac{1}{\delta} \varepsilon_N^2 = -\alpha e^T P e + \frac{1}{\sigma} \bar{D}^2 + \\ \frac{1}{\delta} \varepsilon_N^2 &\leq -\alpha \lambda_{\min}(P) \|e\|_2^2 + \frac{1}{\sigma} \bar{D}^2 + \frac{1}{\delta} \varepsilon_N^2 \end{aligned} \quad (21)$$

显然闭环收敛结果为, 当 $t \rightarrow \infty$ 时

$$\|e\|_2^2 \rightarrow \frac{1}{\sigma \alpha \lambda_{\min}(P)} \bar{D}^2 + \frac{1}{\delta \alpha \lambda_{\min}(P)} \varepsilon_N^2 \quad (22)$$

增大 P 的特征值、 δ 或 σ 、 α 的值, 可以提高收敛效果。

3 仿真验证

针对以上分析, 在 MATLAB/Simulink 模块搭建式(7)所示的扰动观测器及式(12)所示的 RBF 神经网络控制器模型, 仿真原理如图 3 所示。




图3 控制仿真示意图

系统中各环节的参数如表 1 所示。取 $\alpha = 40$, $\delta = 10$, $\sigma = 0.001$, 经 MATLAB 的 YALMIP 工具箱求解 LMI 的两个不等式(19)、式(20), 得扰动观测器的参数 K_d 、控制器参数 K 及自适应律参数 P , 结果如式(23)所示。


$$\begin{cases} K_d = [0 \ 0 \ 5.242 \times 10^4] \\ K = [-554.07 \ -36.52 \ -0.68] \\ P = \begin{bmatrix} 1.07 \times 10^{-2} & 5.35 \times 10^{-4} & 6.69 \times 10^{-6} \\ 5.35 \times 10^{-4} & 3.10 \times 10^{-5} & 0 \\ 6.69 \times 10^{-6} & 0 & 0 \end{bmatrix} \end{cases} \quad (23)$$

表 1 系统各环节参数

参数	数值	参数	数值
L_m / H	0.011 4	$K_A / (\text{Nm/rad})$	6 100
R_m / Ω	2.1	η	0.95
$K_t / (\text{Nm/Arms})$	1.75	P / m	0.025
$K_e / (\text{V/(rad} \cdot \text{s}^{-1}))$	1.069 5	$J_m / (\text{kg} \cdot \text{m}^2)$	0.001 35
$B_m / (\text{Nm/(rad} \cdot \text{s}^{-1}))$	0.049 66		

神经网络的输入向量为 $x = [x_1 \ x_2 \ x_3]^T$, 结构采用 3-11-1 形式, 即输入数量为 3, 隐含层数量为 11, 输出数量为 1。为定量地分析所设计的扰动观测器估计精度, 取“双十指标”作为评价指标, 即幅值和相位偏差都在 10% 以内作为评价指标, 且将其与 PID 控制进行比较, 其中 PID 控制器参数已取到最优, 具体思路见文献[10]。

同时, 为了充分比较控制器在不同工况下的控制效果, 在运动频率相同的前提下, 取 PMSM 做 $x_r = 1\ 000 \sin(6\pi t)$ 、 $x_r = 1\ 000 \sin(10\pi t)$ 的正弦加载, 分别简称为 1 000 N-3 Hz 和 1 000 N-5 Hz, 直线舵机做 $L = 2 \sin(6\pi t)$ 和 $L = 2 \sin(10\pi t)$ 的正弦运动, 分别简称为 2 mm-3 Hz 和 2 mm-5 Hz, 给出加入两种观测器后的跟踪误差曲线, 如图 4 所示(本刊黑白印刷, 相关疑问咨询作者)。为表示系统的扰动估计效果, 图 5 给出在 2 mm-5 Hz 工况下扰动观测器的估计及其误差曲线, 图 6 给出在 1 000 N-5 Hz 工况下 RBF 神经网络对系统非线性项 $\alpha(x)$ 的估计及其误差曲线。




E1—PID, 1 000 N-3 Hz; E2—PID, 1 000 N-5 Hz;
E3—LMI, 1 000 N-3 Hz; E4—LMI, 1 000 N-5 Hz

图4 不同工况下的估计误差

由图 4 可知, 相对于 PID 控制, 无论是在低频 3 Hz 还是在高频 5 Hz 的工况下, 所使用的控制策略在系统稳定运行后都能实现对加载力的准确跟踪, 且误差接近 0, 满足指标, 即控制系统拥有很


好的鲁棒性,而传统PID控制在实现高精度跟踪时,需要额外的前馈补偿环节,且需要根据不同工况实时调节PID中的3个参数。



D1— d 设定; D2— d 估计; DER— d 估计误差

图5 扰动观测器估计及其误差曲线

由图5可知,在设定的高频工况稳定运行后,扰动观测器的估计值接近舵机运动所造成的位置扰动,而其估计的幅值与设置值的误差在0.1%以内,满足指标,同时将其值引入到控制器中,提高控制器的控制效果。



A— $\alpha(x)$ 设定; AP— $\alpha(x)$ 估计; AE— $\alpha(x)$ 估计误差

图6 RBF网络对 $\alpha(x)$ 的估计及其误差

由图6可知,RBF神经网络对 $\alpha(x)$ 的幅值估计误差小于1%,相位误差小于 1° ,均满足“双十指标”,而且幅值误差主要由相位偏移所造成,RBF对非线性项的幅值具有很好的估计性能。

由以上分析可得,扰动观测器和RBF神经网络控制器在较高频率下都能得到很好的控制和估计效果,且跟踪误差在所设定的性能指标内,所提出的控制策略满足高频工况下动态加载准确跟踪。

4 结语

1)对于ELLS动态加载过程中存在的舵机位

置干扰和摩擦引起的多余力等问题,基于LMI理论设计系统的扰动观测器和控制器,并通过构造李雅普诺夫函数证明了所提出的控制策略的有效性。

2)通过搭建仿真模型,证明了所提出的扰动观测器和RBF神经网络控制器分别对系统的扰动量和非线性因素的准确估计,且两者的误差均满足“双十指标”,而且通过加入扰动项,证明了所提出的控制器拥有很强的鲁棒性。

参考文献:

- [1] 潘卫东,范元勋,雷建杰,等.摩擦对电动直线负载模拟器的影响及其抑制研究[J].兵工学报,2019,40(10):2050-2059.
- [2] LIU E J, YAN Y, YANG Y N. Neural network approximation-based backstepping sliding mode control for spacecraft with input saturation and dynamics uncertainty[J]. Acta Astronautica, 2022, 191: 1-10.
- [3] 聂守成,钱林方,陈志群,等.基于干扰观测器的弹丸协调器电液伺服系统自适应滑模控制[J].兵工学报,2020,41(9):1745-1751.
- [4] 董中华,陈鹏飞,李亚龙.采摘机械臂的PSO-RBF神经网络自适应控制[J].机械制造与自动化,2022,51(1):181-183,233.
- [5] 刘金琨,刘志杰.基于LMI的控制系统设计、分析及MATLAB仿真[M].北京:清华大学出版社,2020:1-5.
- [6] 孙宜标,仲原,刘春芳.基于LMI的直线伺服滑模位移跟踪控制[J].电工技术学报,2019,34(1):33-40.
- [7] 贾洪平,孙丹,贺益康.基于滑模变结构的永磁同步电机直接转矩控制[J].中国电机工程学报,2006,26(20):134-138.
- [8] MOLAVI A, FATHABADI F R. Robust model predictive anti-slip controller and speed profile tracking of an electric train based on LMI approach[J]. International Journal of Dynamics and Control, 2022, 10(6): 1943-1954.
- [9] 张通彤,姜湖海,岳巍,等.基于径向基函数神经网络的光电系统自适应控制[J].兵工学报,2022,43(3):556-564.
- [10] 潘卫东,范元勋,雷建杰,等.电动直线加载测试系统改进前馈补偿策略研究[J].振动、测试与诊断,2021,41(1):19-26,197.

收稿日期:2022-08-09