doi:10.6041/j.issn.1000-1298.2020.S1.069

# 基于粒子群算法的混联机构神经网络自适应反演控制

庄肖波<sup>1</sup> 李耀明<sup>1</sup> 王 曜<sup>2</sup> 魏海峰<sup>2</sup> 陆彦如<sup>2</sup> (1. 江苏大学现代农业装备与技术教育部重点实验室,镇江 212013; 2. 江苏科技大学电子信息学院,镇江 212003)

摘要:针对含有不匹配干扰的混联机构轨迹跟踪控制问题,提出了一种极限学习机与自适应反演控制相结合的控制策略。在对干扰进行分析的基础上,分别采用两个极限学习机网络对系统中的匹配和不匹配干扰进行逼近和补偿。基于 Lyapunov 函数稳定性设计了混联机构的控制律与自适应律,实现混联机构的轨迹跟踪控制。由于控制器可调参数较多,采用粒子群算法进行控制器参数的寻优整定。仿真结果表明,所提出的控制方法具有良好的轨迹跟踪精度和鲁棒性。

关键词:混联机构;不匹配干扰;粒子群算法;反演法;极限学习机 中图分类号:TH238 文献标识码:A 文章编号:1000-1298(2020)S1-0576-08

# Neural Network Adaptive Backstepping Control of Hybrid Mechanism Based on PSO

ZHUANG Xiaobo<sup>1</sup> LI Yaoming<sup>1</sup> WANG Yao<sup>2</sup> WEI Haifeng<sup>2</sup> LU Yanru<sup>2</sup>

Key Laboratory of Modern Agricultural Equipment and Technology, Ministry of Education, Jiangsu University, Zhenjiang 212013, China
 School of Electronics and Information, Jiangsu University of Science and Technology, Zhenjiang 212003, China)

Abstract: Aiming at the trajectory tracking control problem of the hybrid mechanism with mismatched disturbance, a control strategy combining extreme learning machine and adaptive backstepping control was proposed. Considering the hybrid mechanism containing the characteristics of drive motor, adaptive control with backstepping method was used to design the control strategy in stages. Based on the disturbance analysis, the conveying mechanism modeling error, friction, load and external random disturbance, and motor voltage disturbance were taken as matched disturbance and mismatched disturbance were two lumped disturbance terms. Since the mismatched disturbance cannot be eliminated directly by the feedback controller, two ELM networks were used to perform on-line approximation respectively, and perform feedforward compensation in the designed backstepping controller. According to the stability theory of Lyapunov function, the control rate and adaptive rate of the hybrid mechanism were designed. The simulation results showed that the method effectively eliminated the influence of mismatch disturbance in the system and realized the trajectory tracking control of the hybrid mechanism. In addition, because the neural network adaptive inversion controller of the hybrid mechanism contained many adjustable parameters such as inversion stabilization coefficients and adaptive parameters, the particle swarm algorithm was used to optimize and set the controller parameters. The system error, output error, controller output and rise time were used as the objective function construction conditions, and the optimal parameters of the controller were obtained through 150 iterations of optimization. Neural network adaptive backstepping controller without PSO-optimize and the PD controller were simulated as a comparison. The simulation results showed that the neural network adaptive backstepping controller of the hybrid mechanism based on PSO optimization had excellent tracking accuracy and system robustness. Key words: hybrid mechanism; mismatched disturbance; PSO; backstepping control; ELM

收稿日期: 2020-08-01 修回日期: 2020-09-20

**基金项目:**国家自然科学基金项目(51977101)

作者简介: 庄肖波(1973-),男,博士生,主要从事工业自动化研究, E-mail: zxb@ just. edu. cn

通信作者:李耀明(1959—),男,教授,博士生导师,主要从事现代农业机械设计及理论研究,E-mail: ymli@ ujs. edu. en

#### 0 引言

随着汽车工业的高速发展,汽车制造的工艺要求也随之提高,但传统汽车电泳涂装输送机构多采 用串联机构形式,存在承载力差、多车型混线生产柔 性化水平不高等问题,混联机构将串、并联机构进行 有效结合,既保留了串联机构工作空间大、运动方式 灵活的优点,又能弥补其结构稳定性差、承载力小和 运动精度低等缺点<sup>[1]</sup>。

混联机构具有多变量、强非线性与耦合性的特点,尤其当白车身运行于电泳槽液中时,存在突变的未知干扰。研究者提出了多种控制方法来消除混联机构控制中的干扰,如变结构滑模控制<sup>[2]</sup>、基于干扰观测器的控制<sup>[3]</sup>、自适应控制<sup>[4]</sup>等,但是上述研究针对混联机构控制的动力学模型都没考虑驱动电机特性。在考虑驱动电机的混联机构轨迹跟踪控制中,由于输送机构的摩擦力、外部干扰等总干扰与控制输入不在同一通道,属于不匹配干扰。不匹配干扰无法直接利用反馈控制器消除,上述控制方法很 难有效抑制不匹配干扰。

反演法可以有效处理系统中的匹配与不匹配干扰,通常结合其他控制方法来保证系统的鲁棒性,如 自适应控制方法<sup>[5]</sup>和滑模控制方法<sup>[6]</sup>。然而,自适 应控制主要用来处理带有参数精确反馈形式和参数 严格反馈形式的系统<sup>[7]</sup>,滑模控制存在执行器饱和 与抖振问题<sup>[8]</sup>,限制了它们的应用范围。

神经网络因其强大的非线性逼近能力,常被用 于处理系统中的未知参数与不匹配干扰<sup>[9-11]</sup>,但是 BP 神经网络存在计算量大且容易陷入局部最优的 问题,而 RBF 网络隐层神经元基函数的中心矢量及 基宽度的选择也依赖经验和反复调试,选择不当反 而会影响控制效果。极限学习机(Extreme learning machine, ELM)作为一种快速学习算法,其网络结 构简单,且随机选择隐层节点参数,训练过程中仅需 调节网络输出权值,解决了网络参数调节问题,同时 具有很好的泛化性能。ELM 可结合多种智能控制 算法进行控制器的设计,成功应用于多种非线性控 制场景<sup>[12-14]</sup>。

反演法结合多种控制算法设计控制器可以有效 抑制系统中的匹配和不匹配干扰以及其他不确定量 的影响,但复合控制器中涉及大量可调参数,尤其是 反演镇定系数及自适应律系数对控制器性能及鲁棒 性具有决定性影响。随着智能算法的兴起,研究者利 用智能算法进行控制器参数的优化<sup>[15-16]</sup>。粒子群算 法(Partical swarm optimization, PSO)是一种高效的群 智能优化算法,其模拟了鸟类觅食与迁徙的特征,具 有简单高效的特点,被广泛应用于函数寻优<sup>[17]</sup>、神经 网络优化<sup>[18]</sup>、控制器参数优化<sup>[19]</sup>等领域。

本文以具有不匹配干扰的混联机构为研究对 象,提出基于 PSO 的神经网络自适应反演控制器。 采用反演法逐阶设计控制策略,对匹配与不匹配干 扰分别采用 ELM 网络进行 逼近并补偿,利用 Lyapunov 综合法设计混联机构的控制律与自适应 律,采用 PSO 对控制器参数进行整定优化,并对所 设计的控制策略进行仿真验证。

#### 1 系统建模

式

混联机构由行走机构和翻转升降机构组成,如 图1所示,车体固定在连接杆中部,实现车体在电泳 槽液中的前进、翻转、升降功能。因为行走机构结构 简单且做匀速前进,无需复杂控制,本文主要对升降 翻转机构进行分析。



图 1 混联机构样机 Fig. 1 Hybrid conveying mechanism

构建升降反转机构简图如图 2 所示,考虑驱动 电机特性的升降翻转机构关节空间动力学模型为

$$\begin{cases} \boldsymbol{M}(\boldsymbol{x})\ddot{\boldsymbol{x}} + \boldsymbol{C}(\boldsymbol{x},\dot{\boldsymbol{x}})\dot{\boldsymbol{x}} + \boldsymbol{G}(\boldsymbol{x}) + \boldsymbol{\Delta}_{1} = \boldsymbol{K}_{T}\boldsymbol{T}_{M}\boldsymbol{I}_{c} + \boldsymbol{w}_{1} \\ \boldsymbol{L}\dot{\boldsymbol{I}}_{c} + \boldsymbol{R}\boldsymbol{I}_{c} + \boldsymbol{K}_{E}\boldsymbol{T}_{M}\dot{\boldsymbol{x}} + \boldsymbol{\Delta}_{2} = \boldsymbol{u} + \boldsymbol{w}_{2} \end{cases}$$

中 
$$x,\dot{x},\ddot{x}$$
——机构位置、速度、加速度向量  
 $M(x)$ ——正定惯性矩阵  
 $C(x,\dot{x})$ ——离心力和哥氏力矩阵  
 $G(x)$ ——惯性矩阵  
 $K_{T}$ ——电机转矩常数矩阵  
 $I_{c}$ ——各关节电机的电枢电流矩阵  
 $L$ ——电机的电感常数矩阵  
 $R$ ——电机的电阻常数矩阵  
 $K_{E}$ ——电机的反电动势常数矩阵  
 $T_{M}$ ——电机到各关节传动比矩阵  
 $u$ ——电机控制电压矩阵  
 $\Delta_{1},\Delta_{2}$ ——建模不精确部分  
 $w_{1},w_{2}$ ——外部力干扰和电压随机干扰

建模不精确部分、外部力干扰和电压干扰同为不确 定量,将式(1)中同一通道中的不确定量整理可得 集总干扰项为

$$\boldsymbol{d}_1 = \boldsymbol{w}_1 - \boldsymbol{\Delta}_1 \tag{2}$$

(1)



图 2 升降反转机构简图

Fig. 2 Structure diagram of lifting and turning mechanism

$$\boldsymbol{d}_2 = \boldsymbol{w}_2 - \boldsymbol{\Delta}_2 \tag{3}$$

定义系统状态变量 $(x_1, x_2, x_3)^{\mathsf{T}} = (x, \dot{x}, \dot{i}_c)^{\mathsf{T}},$ 则 式(1)变换为

$$\begin{cases} \boldsymbol{x}_{1} = \boldsymbol{x}_{2} \\ \dot{\boldsymbol{x}}_{2} = \boldsymbol{M}^{-1} (\boldsymbol{K}_{T} \boldsymbol{T}_{M} \boldsymbol{x}_{3} - \boldsymbol{C} \boldsymbol{x}_{2} - \boldsymbol{G} + \boldsymbol{d}_{1}) \\ \dot{\boldsymbol{x}}_{3} = \boldsymbol{L}^{-1} (\boldsymbol{u} - \boldsymbol{R} \boldsymbol{x}_{3} - \boldsymbol{K}_{E} \boldsymbol{T}_{M} \boldsymbol{x}_{2} + \boldsymbol{d}_{2}) \\ \boldsymbol{y} = \boldsymbol{x}_{1} \end{cases}$$
(4)

式中干扰项 d<sub>1</sub>和 d<sub>2</sub> 无法对其精确建模,且 d<sub>1</sub>与控 制输入 u 不在同一通道,不能直接从控制输入通道 补偿,是不匹配干扰问题。

# 2 极限学习机

#### 2.1 ELM 概述

ELM 是 HUANG 等<sup>[20-21]</sup>提出的一种新型的神 经网络算法。ELM 相较于传统单隐层神经网络,网 络训练速度也获得极大提升,同时能避免易陷入局 部极小、过多迭代次数、训练耗时过长等基于梯度下 降的前馈神经网络导致的问题,ELM 无需大量参数 的调节整定,既能降低网络准备时间和难度,也能保 证模型精度和泛化性能。

由 N 个随机样本 $(x_i, t_i) \in \mathbf{R}^n \times \mathbf{R}^m$  构成的单隐 层神经网络可表示为

$$H\boldsymbol{\beta} = T \qquad (5)$$

$$\pm \boldsymbol{\mu} = \mathbf{I} \qquad (5)$$

$$\pm \boldsymbol{\mu} = \mathbf{I} \qquad (5)$$

$$\pm \mathbf{I} = \mathbf{I} \qquad (5)$$

$$\pm \mathbf{I} = \mathbf{I} \qquad (5)$$

$$= \begin{bmatrix} \mathbf{G}(a_1, x_1 + b_1) & \cdots & \mathbf{G}(a_{\tilde{N}} x_1 + b_{\tilde{N}}) \\ \vdots & \vdots & \vdots \\ \mathbf{G}(a_1, x_N + b_1) & \cdots & \mathbf{G}(a_{\tilde{N}} x_N + b_{\tilde{N}}) \end{bmatrix}_{N \times \tilde{N}} \qquad (6)$$

$$= \begin{bmatrix} \boldsymbol{\beta}_1^T \\ \vdots \\ \boldsymbol{\beta}_N^T \end{bmatrix}$$

$$= \begin{bmatrix} \mathbf{I}_1^T \\ \vdots \\ \mathbf{I}_N^T \end{bmatrix}$$

$$= \begin{bmatrix} \mathbf{I}_1^T \\ \vdots \\ \mathbf{I}_N^T \end{bmatrix}$$

式中 H----SLFN 的隐层输出矩阵

第*i*列参数为与输入值( $x_1, x_2, \dots, x_N$ )有关的第*i*个 隐层神经元的输出向量;第*j*行参数为与输入值 $x_j$ 有关的隐层神经元输出向量。

对于随机选取的  $a_i$  和  $b_i$ ,若隐层神经元与训练 集样本具有相同个数,则 SLFN 便能以误差为零的

精度逼近训练样本<sup>[17]</sup>,即  $\sum_{j=1}^{N} \| \mathbf{t}_{j} - \mathbf{y}_{j} \| = 0$ 。其中

 $y_i = (y_{1j}, y_{2j}, \dots, y_{mj})^{T} (j = 1, 2, \dots, \widetilde{N})$ 。研究表明,当 激活函数 *G* 无限可微时,可以随机确定隐层的权值 与阈值且无需再在训练过程中调整。

# 2.2 ELM 网络对未知项的估计

实际的控制工程中,基于前馈神经网络的良好 逼近特性,利用 ELM 网络对模型未知项进行估计。 设计 ELM 网络

$$\hat{\boldsymbol{d}}(\boldsymbol{z}) = \hat{\boldsymbol{\beta}}^{\mathrm{T}} \boldsymbol{h}(\boldsymbol{z}) \tag{8}$$

式中 z——网络的输入矩阵, $z \in \mathbf{R}^{k}$ 

 $\hat{d}(z)$ ——网络的输出矩阵, $\hat{d}(z) \in \mathbb{R}^n$ 

β-----ELM 网络的输出权值

**h**(z)——隐层节点的输出函数矩阵

在集合 $\Omega_z \in \mathbf{R}^*$ 上,该网络能以任意精度逼近d(z), 即有

$$\boldsymbol{d}(\boldsymbol{z}) = \boldsymbol{\beta}^* \boldsymbol{h}(\boldsymbol{z}) + \boldsymbol{\varepsilon}$$
(9)

式中 **β**<sup>\*</sup> — 网络的理想输出向量 **ε** — 逼近误差

假设对所有  $Z \in \Omega_{\epsilon}$ ,存在输出向量  $\beta^*$ ,满足  $|\varepsilon| \leq \varepsilon^*$ ,常数  $\varepsilon^* > 0$ ;同时理想输出权值向量定义为

 $\boldsymbol{\beta}^{*} \triangleq \arg\min_{\boldsymbol{\beta} \in \Omega_{d}} \{ \sup_{\boldsymbol{z} \in \Omega_{z}} |\boldsymbol{d}(\boldsymbol{z}) - \hat{\boldsymbol{\beta}}^{T} \boldsymbol{h}(\boldsymbol{z}) | \} \quad (10)$  $\mathbb{R} \| \hat{\boldsymbol{\beta}} \| \leq \boldsymbol{\beta}_{M}, \boldsymbol{\beta}_{M} \text{ bbt} \otimes \mathcal{B}, \text{ aff } \hat{\boldsymbol{d}}(\boldsymbol{z}) \neq \boldsymbol{\beta}, \text{ m} \hat{\boldsymbol{\beta}}$  $\boldsymbol{\beta}, \text{ bt} \boldsymbol{\beta}_{M} \neq \boldsymbol{\beta}_{M} \neq \boldsymbol{\beta}_{M}$ 

#### 3 控制器设计

针对带有不匹配干扰和模型不确定性的混联机 构轨迹跟踪问题,设计结合神经网络的自适应反演 控制器。采用反演法设计控制器,使用 ELM 网络来 逼近系统的干扰,并利用 Lyapunov 稳定性方法保证 系统稳定。

(1) 设  $y_a$  为期望位置指令, 且  $y_a$  具有三阶 导数。

 $\boldsymbol{\alpha}_{1} = -\lambda_{1}\boldsymbol{z}_{1} + \dot{\boldsymbol{y}}_{d}$ 

 $\lambda_{\perp} > 0$ 

定义误差为

$$\boldsymbol{z}_1 = \boldsymbol{y} - \boldsymbol{y}_d \tag{11}$$

(12)

取虚拟控制量

其中

定义误差

则

$$z_{2} = x_{2} - \alpha_{1}$$
(13)  
$$\dot{z}_{1} = \dot{x}_{1} - \dot{y}_{d} = x_{2} - \dot{y}_{d} = z_{2} + \alpha_{1} - \dot{y}_{d}$$
(14)

针对第1个子系统,设计 Lyapunov 函数为

$$\boldsymbol{V}_{1} = \frac{1}{2}\boldsymbol{z}_{1}^{\mathrm{T}}\boldsymbol{z}_{1} \qquad (15)$$

则 
$$\dot{V}_1 = z_1^T z_1 = z_1^T (\dot{x}_1 - \dot{y}_d) = z_1^T (x_2 - \dot{y}_d) =$$
  
 $z_1^T (z_2 + \alpha_1 - \dot{y}_d) = -\lambda_1 z_1^T z_1 + z_1^T z_2$  (16)

如果  $z_2 = 0$ , 则  $\dot{V}_1 < 0$ , 为此需要进行下一步 设计。

(2)集总干扰 *d*<sub>1</sub>包含混联机构摩擦力、建模误 差和外界随机干扰,为了消除干扰影响实现精确控 制,采用 ELM 估计 *d*<sub>1</sub>。

输入向量 
$$\mathbf{z} = (\mathbf{z}_1, \mathbf{z}_2)^{\mathrm{T}}$$
,则有  
 $\hat{\mathbf{d}}_1(\mathbf{z})_d = \hat{\boldsymbol{\beta}}_1^{\mathrm{T}} \boldsymbol{h}_1(\mathbf{z})$  (17)

式中  $\boldsymbol{\beta}_1$ —ELM 网络的输出权值  $\hat{\boldsymbol{d}}_1(\boldsymbol{z})_q$ 能以任意精度逼近  $\boldsymbol{d}_1(\boldsymbol{z})_q$ ,即有

$$\boldsymbol{d}_{1}(\boldsymbol{z})_{d} = \boldsymbol{\beta}_{1}^{*^{\mathrm{T}}} \boldsymbol{h}_{1}(\boldsymbol{z}) + \boldsymbol{\varepsilon}_{1}$$
(18)

式中  $\boldsymbol{\beta}_1^*$  ——ELM 网络的最优输出权值  $\boldsymbol{\varepsilon}_1$  —— 逼近误差

权值误差为 $\hat{\boldsymbol{\beta}}_1 = \boldsymbol{\beta}_1^* - \hat{\boldsymbol{\beta}}_1$ 。 式(18)求导得

$$\mathbf{M}^{-1}(\mathbf{K}_{T}\mathbf{T}_{M}\mathbf{x}_{3} - \mathbf{C}\mathbf{x}_{2} - \mathbf{G} + \mathbf{d}_{1}) + \lambda_{1}\dot{\mathbf{z}}_{1} - \ddot{\mathbf{z}}_{2} \quad (19)$$

$$\text{that } \mathbf{X} \stackrel{\text{that }}{\Rightarrow} 2 \wedge \mathbf{Z} \stackrel{\text{that }}{\Rightarrow} \stackrel{\text{that }}{\Rightarrow} \mathbf{H} \stackrel{\text{that }}{\Rightarrow} \mathbf{h}$$

 $\dot{z} = \dot{r} = \dot{a} =$ 

$$\boldsymbol{V}_{2} = \boldsymbol{V}_{1} + \frac{1}{2}\boldsymbol{z}_{2}^{\mathrm{T}}\boldsymbol{M}\boldsymbol{z}_{2} + \frac{1}{2\boldsymbol{\gamma}}\mathrm{tr}(\boldsymbol{\beta}_{1}^{\mathrm{T}}\boldsymbol{\beta}_{1}) \qquad (20)$$

则

$$\dot{\boldsymbol{V}}_{1} + \frac{1}{2}\boldsymbol{z}_{2}^{\mathrm{T}}\boldsymbol{M}\,\dot{\boldsymbol{z}}_{2} + \frac{1}{2}\dot{\boldsymbol{z}}_{2}^{\mathrm{T}}\boldsymbol{M}\boldsymbol{z}_{2} + \frac{1}{2}\boldsymbol{z}_{2}^{\mathrm{T}}\dot{\boldsymbol{M}}\boldsymbol{z}_{2} + \frac{1}{\gamma_{1}}\mathrm{tr}(\boldsymbol{\widetilde{\beta}}^{\mathrm{T}}\,\boldsymbol{\widetilde{\beta}}) = -\lambda_{1}\boldsymbol{z}_{1}^{\mathrm{T}}\boldsymbol{z}_{1} + \boldsymbol{z}_{1}^{\mathrm{T}}\boldsymbol{z}_{2} + \boldsymbol{z}_{2}^{\mathrm{T}}(\boldsymbol{K}_{T}\boldsymbol{T}_{M}\boldsymbol{x}_{3} - \boldsymbol{C}\boldsymbol{x}_{2} - \boldsymbol{G} + \lambda_{1}\boldsymbol{M}\,\dot{\boldsymbol{z}}_{1} + \boldsymbol{C}\boldsymbol{z}_{2} - \boldsymbol{M}\,\dot{\boldsymbol{z}}_{d} + \boldsymbol{d}_{1}) + \frac{1}{\gamma_{1}}\mathrm{tr}(\boldsymbol{\widetilde{\beta}}_{1}^{\mathrm{T}}\,\boldsymbol{\widetilde{\beta}}_{1})$$
(21)

 $\dot{V}_2 =$ 

为了使整个系统稳定,必须设计控制律使 $V_2$ 负定,取 $K_T T_M x_3$ 为

 $\boldsymbol{K}_{T}\boldsymbol{T}_{M}\boldsymbol{x}_{3} = \boldsymbol{C}\boldsymbol{x}_{2} - \boldsymbol{C}\boldsymbol{z}_{2} + \boldsymbol{G} + \boldsymbol{M}\dot{\boldsymbol{\alpha}}_{1} - \boldsymbol{z}_{1} - \boldsymbol{\lambda}_{2}\boldsymbol{z}_{2} + \boldsymbol{z}_{3} - \hat{\boldsymbol{d}}_{1}$ (22)

其中, $\hat{d}_1$ 为集总干扰项 $d_1$ 估计,将式(22)代入式(21), 可得

$$\dot{\boldsymbol{V}}_{2} = -\boldsymbol{\zeta}_{1}^{\mathrm{T}}\boldsymbol{\Lambda}_{1}\boldsymbol{\zeta}_{1} + \boldsymbol{\zeta}_{1}^{\mathrm{T}}\boldsymbol{\varepsilon}_{1} + \boldsymbol{\zeta}_{1}^{\mathrm{T}}\,\boldsymbol{\beta}_{1}^{\mathrm{T}}\boldsymbol{h}_{1} + \frac{1}{\gamma_{1}}\mathrm{tr}(\boldsymbol{\beta}_{1}^{\mathrm{T}}\,\boldsymbol{\beta}_{1}) = -\boldsymbol{\zeta}_{1}^{\mathrm{T}}\boldsymbol{\Lambda}_{1}\boldsymbol{\zeta}_{1} + \boldsymbol{\zeta}_{1}^{\mathrm{T}}\boldsymbol{\varepsilon}_{1} + \frac{1}{\gamma_{1}}\mathrm{tr}(\boldsymbol{\beta}_{1}^{\mathrm{T}}\,\boldsymbol{\beta}_{1} + \gamma_{1}\,\boldsymbol{\beta}_{1}^{\mathrm{T}}\boldsymbol{h}_{1}\boldsymbol{\zeta}^{\mathrm{T}})$$

$$(\gamma_{1} > 0) \qquad (23)$$

$$\vdots \psi \qquad \boldsymbol{\zeta}_{1} = (\boldsymbol{z}_{1}, \boldsymbol{z}_{2})^{\mathrm{T}} \quad \boldsymbol{\Lambda}_{1} = (\boldsymbol{\lambda}_{1}, \boldsymbol{\lambda}_{2})^{\mathrm{T}}$$

设计神经网络权值自适应律为

$$\hat{\boldsymbol{\beta}}_{1} = \gamma_{1}\boldsymbol{h}_{1}\boldsymbol{\zeta}_{1}^{\mathrm{T}} - k\gamma_{1} \parallel \boldsymbol{\eta} \parallel \hat{\boldsymbol{\beta}}_{1} \quad (k > 0) \quad (24)$$

$$\ddagger \psi \qquad \boldsymbol{\eta} = (\boldsymbol{z}_{2}, \boldsymbol{z}_{3})^{\mathrm{T}}$$

将自适应律代入
$$V_2$$
,并由 $\hat{\boldsymbol{\beta}}_1 = \boldsymbol{\beta}_1^* - \boldsymbol{\beta}_1$ ,可得  
 $\dot{V}_2 \leq -\boldsymbol{\zeta}_1^T \boldsymbol{\Lambda}_1 \boldsymbol{\zeta}_1 + \boldsymbol{\zeta}_1^T \boldsymbol{\varepsilon}_1 + k \parallel \eta \parallel \operatorname{tr}(\boldsymbol{\widetilde{\beta}}_1^T (\boldsymbol{\beta}_1^* - \boldsymbol{\widetilde{\beta}}_1))$ 
(25)

(3) 同干扰 **d**<sub>1</sub> 类似, 为了消除电机电压干扰 **d**<sub>2</sub> 造成的误差, 采用一个 ELM 网络估计 **d**<sub>2</sub>。

输入向量 
$$z = (z_2, z_3)^T$$
,则有  
 $\hat{d}_2(z)_d = \hat{\beta}_2^T h_2(z)$  (26)  
式中  $\hat{\beta}_2$ ——ELM 网络的输出权值  
 $\hat{d}_3(z)_d$ 能以任意精度逼近  $d_3(z)_d$ ,即有

$$\boldsymbol{d}_{2}(\boldsymbol{z})_{d} = \boldsymbol{\beta}_{2}^{*^{\mathrm{T}}} \boldsymbol{h}_{2}(\boldsymbol{z}) + \boldsymbol{\varepsilon}_{2}$$
(27)

式中  $\boldsymbol{\beta}_2^*$ ——ELM 网络的最优输出权值  $\boldsymbol{\varepsilon}_2$ ——逼近误差

取权值误差为 $\hat{\boldsymbol{\beta}}_2 = \boldsymbol{\beta}_2^* - \hat{\boldsymbol{\beta}}_2$ 。 针对第3个子系统,设计 Lyapunov 函数为

$$\boldsymbol{V}_{3} = \boldsymbol{V}_{2} + \frac{1}{2}\boldsymbol{z}_{3}^{\mathrm{T}}\boldsymbol{z}_{3} + \frac{1}{2\gamma_{2}}\mathrm{tr}(\boldsymbol{\widetilde{\beta}}_{2}^{\mathrm{T}}\,\boldsymbol{\widetilde{\beta}}_{2}) \qquad (28)$$

则  $\dot{V}_3 = \dot{V}_2 + z_3^{\mathrm{T}} \dot{z}_3 + \frac{1}{\gamma_2} \mathrm{tr}(\widetilde{\boldsymbol{\beta}}_2^{\mathrm{T}} \widetilde{\boldsymbol{\beta}}_2) =$ 

$$-\lambda_1 z_1^{\mathrm{T}} z_1 - \lambda_2 z_2^{\mathrm{T}} z_2 + z_2^{\mathrm{T}} z_3 + z_3^{\mathrm{T}} (K_T T_M \dot{x}_3 - \dot{C} x_2 - C \dot{x}_2 - \dot{G} + 2\lambda_1 C \dot{z}_1 + \lambda_1 M \ddot{z}_1 - 2C \ddot{z}_d - M \ddot{z}_d + \dot{C} z_2 + C \dot{z}_2 + \dot{C} \dot{z}_2 + \dot{$$

$$\lambda_{2}\dot{\boldsymbol{z}}_{2} + \dot{\boldsymbol{z}}_{1} + \boldsymbol{d}_{2}) + \frac{1}{\gamma_{2}} \operatorname{tr}(\boldsymbol{\widetilde{\beta}}_{2}^{\mathrm{T}} \, \boldsymbol{\widetilde{\beta}}_{2}) \qquad (29)$$

为了使整个系统稳定,必须设计控制律使 $V_3$ 负定,取 $K_T T_M \dot{x}_3$ 为

$$\begin{cases} K_{T}T_{M} \dot{x}_{3} = T = K_{T}L^{-1}(u - Rx_{3} - K_{E}T_{M}x_{2} + \hat{d}_{2}) \\ T = C \dot{x}_{2} - 2\lambda_{1}C \dot{z}_{1} - \lambda_{1}M \ddot{z}_{1} + 2C \ddot{z}_{d} + M \ddot{z}_{d} - C \dot{z}_{2} - \\ \lambda_{2}\dot{z}_{2} - \dot{z}_{1} - z_{2} - \lambda_{3}z_{3} \end{cases}$$
(30)

其中 $\hat{d}_2$ 为未知项 $d_2$ 估计,将式(30)代人式(29),可得

$$\dot{\boldsymbol{V}}_{3} = \dot{\boldsymbol{V}}_{2} + \boldsymbol{z}_{3}^{\mathrm{T}}\boldsymbol{z}_{3} + \boldsymbol{z}_{3}^{\mathrm{T}}(\boldsymbol{\beta}_{2}^{*^{\mathrm{T}}}\boldsymbol{h}_{2} + \boldsymbol{\varepsilon}_{2}) + \frac{1}{\gamma_{2}}\mathrm{tr}(\boldsymbol{\widetilde{\beta}}_{2}^{\mathrm{T}}\boldsymbol{\widetilde{\beta}}_{2}) \leq -\boldsymbol{\zeta}_{2}^{\mathrm{T}}\boldsymbol{\Lambda}_{2}\boldsymbol{\zeta}_{2} + \boldsymbol{z}_{2}^{\mathrm{T}}\boldsymbol{\varepsilon}_{1} + \boldsymbol{z}_{3}^{\mathrm{T}}\boldsymbol{\varepsilon}_{2} + \boldsymbol{k} \parallel \boldsymbol{\eta} \parallel \mathrm{tr}(\boldsymbol{\widetilde{\beta}}_{1}^{\mathrm{T}}\boldsymbol{\widehat{\beta}}_{1}) + \frac{1}{\gamma_{2}}\mathrm{tr}(\boldsymbol{\widetilde{\beta}}_{2}^{\mathrm{T}}\boldsymbol{\widetilde{\beta}}_{2} + \boldsymbol{\gamma}_{2}\boldsymbol{\widetilde{\beta}}_{2}^{\mathrm{T}}\boldsymbol{h}_{2}\boldsymbol{\zeta}_{2}^{\mathrm{T}}) \quad (\boldsymbol{\gamma}_{2} > 0) \quad (31)$$

其中  $\boldsymbol{\zeta}_2 = (\boldsymbol{z}_1, \boldsymbol{z}_2, \boldsymbol{z}_3)^{\mathrm{T}}$   $\boldsymbol{\Lambda}_2 = (\boldsymbol{\lambda}_1, \boldsymbol{\lambda}_2, \boldsymbol{\lambda}_3)^{\mathrm{T}}$ 类似的,设计神经网络权值自适应律为

$$\dot{\boldsymbol{V}}_{3} \leqslant -\boldsymbol{\zeta}_{2}^{\mathrm{T}}\boldsymbol{\Lambda}_{2}\boldsymbol{\zeta}_{2} + \boldsymbol{z}_{2}^{\mathrm{T}}\boldsymbol{\varepsilon}_{1} + \boldsymbol{z}_{3}^{\mathrm{T}}\boldsymbol{\varepsilon}_{2} + \boldsymbol{k} \parallel \boldsymbol{\eta} \parallel \mathrm{tr}(\boldsymbol{\widetilde{\boldsymbol{\beta}}}_{1}^{\mathrm{T}}(\boldsymbol{\beta}_{1}^{*} - \boldsymbol{\widetilde{\boldsymbol{\beta}}}_{1})) + \boldsymbol{k} \parallel \boldsymbol{\eta} \parallel \mathrm{tr}(\boldsymbol{\widetilde{\boldsymbol{\beta}}}_{2}^{\mathrm{T}}(\boldsymbol{\beta}_{2}^{*} - \boldsymbol{\widetilde{\boldsymbol{\beta}}}_{2})) = -\boldsymbol{\zeta}_{2}^{\mathrm{T}}\boldsymbol{\Lambda}_{2}\boldsymbol{\zeta}_{2} + \boldsymbol{\eta}^{\mathrm{T}}\boldsymbol{E}^{\mathrm{T}} + \boldsymbol{k} \parallel \boldsymbol{\eta} \parallel \mathrm{tr}(\boldsymbol{\widetilde{\boldsymbol{\beta}}}^{\mathrm{T}}(\boldsymbol{B}^{*} - \boldsymbol{\widetilde{\boldsymbol{\beta}}}))$$

$$(33)$$

其中 
$$E = (\boldsymbol{\varepsilon}_1^{\mathrm{T}}, \boldsymbol{\varepsilon}_1^{\mathrm{T}}) > 0$$
  $\widetilde{\boldsymbol{\beta}} = \mathrm{diag} \{ \widetilde{\boldsymbol{\beta}}_1, \, \widetilde{\boldsymbol{\beta}}_2 \}$   
 $\boldsymbol{B}^* = \mathrm{diag} \{ \boldsymbol{\beta}_1^*, \, \boldsymbol{\beta}_2^* \}$   
根据 Schwarz 不等式,可得

$$\operatorname{tr}(\widehat{\boldsymbol{B}}^{\mathrm{T}}(\boldsymbol{B}^{*}-\widehat{\boldsymbol{B}})) \leq \|\widetilde{\boldsymbol{B}}\|_{F} \|\boldsymbol{B}^{*}\|_{F} - \|\widetilde{\boldsymbol{B}}\|_{F}^{2}$$

$$(34)$$

同时假定神经网络最大逼近误差及理想权值均 有界,即 ||  $E^{T}$  ||  $\leq b_{e}$ , ||  $B^{*}$  ||  $_{F} \leq B_{max}$ ,  $b_{e}$  与  $B_{max}$ 均为 正常数。由于  $\lambda_{min}$  ||  $\zeta_{2}$  ||  $^{2} \leq \zeta_{2}^{T} \Lambda_{2} \zeta_{2}$ ,  $\lambda_{min}$ 为  $\Lambda_{2}$  的最 小特征值, 可得

$$\begin{split} \dot{V}_{3} &\leq - \|\boldsymbol{\zeta}_{2} \| \lambda_{\min} \| \boldsymbol{\zeta}_{2} \| - \| \boldsymbol{\eta} \| [\lambda_{\min} \| \boldsymbol{\eta} \| + k \| \widetilde{\boldsymbol{B}} \|_{F} (B_{\max} - \| \widetilde{\boldsymbol{B}} \|_{F}) - b_{\varepsilon}] \end{split}$$
(35)  
为了使 $\dot{V}_{3} \leq 0$ ,需要满足

$$\lambda_{\min} \| \boldsymbol{\eta} \| + k \| \boldsymbol{\widetilde{B}} \|_{F} (B_{\max} - \| \boldsymbol{\widetilde{B}} \|_{F}) - b_{\varepsilon} > 0$$
(36)

若式(36)成立,则

$$\| \boldsymbol{\eta} \| > \left( b_{\varepsilon} + \frac{k}{4} B_{\max}^2 \right) / \lambda_{\min}$$
 (37)

或

$$\|\widetilde{\boldsymbol{B}}\|_{F} > \frac{1}{2}B_{\max} + \sqrt{\frac{B_{\max}^{2}}{4} + \frac{b_{\varepsilon}}{k}}$$
(38)

根据 ||  $\eta$  || 的收敛性可见,轨迹跟踪精度与神 经网络逼近误差上界  $b_{smax}$ 、以及参数  $k, \lambda_{min}$  有关。 通过适当调整 k 和  $\lambda_{min}$ ,可以提高轨迹跟踪精度。 但需要注意 k 的取值,如果 k 减小,则误差 ||  $\eta$  || 减 小,但 ||  $\tilde{B}$  ||  $_{F}$  增大,误差跟踪精度也将降低,所以 k需取值适当。

#### 4 粒子群优化

#### 4.1 粒子群算法

粒子群算法(PSO)在解空间初始化一群粒子, 其中每个粒子分别表示潜在最优解,粒子特征由位 置、速度以及适应度表示,适应度表示粒子品质。粒 子在解空间中,通过跟踪个体和群体极值确定最优 解方向即各粒子位置和速度,每更新一次位置则计 算一次适应度,再通过比较粒子个体和群体极值的 适应度更新个体和群体极值。

设在 *G* 维搜索空间中有 *m* 个粒子构成的种群  $U = (U_1, U_2, \dots, U_m)$ ,其中  $U_i = (u_{i1}, u_{i2}, \dots, u_{iG})$ 表 示第 *i* 个 *G* 维向量,即第 *i* 个粒子位置,即一个潜在 解。再由目标函数计算获得粒子在  $U_i$  位置的适应 度。第 *i* 个粒子速度  $V_i = (V_{i1}, V_{i2}, \dots, V_{iG})$ ,个体极 值为  $P_i = (P_{i1}, P_{i2}, \dots, P_{iG})$ ,群体极值为  $P_a = (P_{a1}, P_{a2}, \dots, P_{aG})$ ,则粒子速度和位置迭代公式为  $V_{id}^{k+1} = \omega V_{id}^{k+1} + c_1 r_1 (P_{id}^k - U_{id}^k) + c_2 r_2 (P_{ad}^k - U_{id}^k)$ 

(41)

$$U_{id}^{k+1} = U_{id}^{k} + V_{id}^{k+1} \tag{40}$$

式中 k——当前迭代次数  $c_1 \ c_2$ ——学习因子,是非负常数  $r_1 \ r_2$ ——加速因子,是(0,1)区间内的随机数  $\omega$ ——惯性权重  $k_m$ ——迭代的最大次数  $\omega_{-} \ \omega_{-}$ ——初始和终止的惯性权重

 $\omega = \omega_s - \frac{\omega_s - \omega_e}{k}k$ 

#### 4.2 基于 PSO 的控制器参数优化

设计的混联机构神经网络自适应反演控制器中 包含众多可调参数,其中包括反演镇定系数  $\Lambda = [\lambda_1 \ \lambda_2 \ \lambda_3]^T$ ,自适应参数 k,等待整定系数  $\Gamma = [\gamma_1 \ \gamma_2]^T$ ,这些参数常采用试凑法确定,需要耗费 大量时间精力,选择不当反而影响控制器的性能,因此,采用 PSO 对控制器参数进行寻优。

基于 PSO 的混联机构神经网络自适应反演控制器参数优化流程图如图 3 所示。



Fig. 3 Flow chart of particle swarm optimization

基于 PSO 优化神经网络自适应反演控制器参数的步骤如下:

(1)初始化粒子群粒子维数、规模、惯性权值、 加速度、迭代次数等。

(2)随机初始化粒子位置与速度。

(3)初始化粒子个体极值与群体极值。

(4)更新粒子的位置与速度。(5)根据目标函数

$$J = \left(\int_{0}^{\infty} (w_{1} | e(t) | + w_{2} \boldsymbol{u}^{\mathrm{T}}(t) \boldsymbol{u}(t) + w_{3} | e_{y}(t) | \right) \mathrm{d}t + w_{4}t_{u} \right)^{-1}$$

计算粒子的适应度,更新粒子的个体与群体极值,其 中 $w_1, w_2, w_3, w_4$ 为各项权重,e(t)为系统误差,  $e_y(t) = y(t) - y(t - 1)$ 为被控对象输出误差, u(t)为控制器的输出, $t_u$ 为上升时间。

(6)判断是否满足终止条件,如果满足即停止 迭代并输出最优值;否则跳转至步骤(4);终止条件 为达到最大迭代次数或适应度达到给定要求。

(7)结束寻优,输出优化参数值。

#### 5 仿真

为了验证所设计的控制器效果与基于 PSO 的参数优化方法的有效性,以翻转升降机构为控制对象,采用 Simulink 进行数值仿真,对比基于 PSO 优化的神经网络自适应反演控制器(PSO - EABC)与未优化参数的神经网络自适应反演控制器(PSO - EABC)与未优化参数的神经网络自适应反演控制器(EABC)、PD 控制器。同时在数值仿真试验时,考虑输送机构建模误差、摩擦力、负载和外界随机干扰以及电机电压干扰。

翻转升降机构连接杆中点的期望轨迹为

$$\begin{cases} 0.2455 & (0 \le t \le 4 \le) \\ 0.3455 - 0.1\cos(0.5p(t-4)/4) & (4 \le t \le 8 \le) \\ 0.3455 - 0.1\cos(0.5p(t-8)/4) & (8 \le t \le 12 \le) \\ 0.2455 & (12 \le t \le 16 \le) \\ (42) \end{cases}$$

$$\beta = \begin{cases} 0 & (0 \le t \le 2 \le) \\ \frac{\pi}{2} - \frac{\pi}{2} \cos(0.25\pi(t-2)) & (2 \le t \le 6 \le) \\ \pi & (6 \le t \le 10 \le) \\ \frac{3}{2}\pi - \frac{\pi}{2} \cos(0.25\pi(t-10)) & (10 \le t \le 14 \le) \\ 2\pi & (14 \le t \le 16 \le) \\ \end{cases}$$
(43)

各关节初始位置为 x = (0.42, -0.42, 0.42, -0.42, 0.1, 0.1) (44)

外部随机干扰设定为

$$d_{1i} = 50\sin\left(\frac{3}{2}\pi t + \frac{\pi}{3}\right) \quad (i = 1, 2, \dots, 6) \quad (45)$$
  
电机电压干扰设定为

 $d_{2i} = 2 \operatorname{sign}(\cos(6t))$  (*i* = 1,2,...,6) (46) 建模误差设定为

$$\boldsymbol{\Delta}_{1} = (0.2\boldsymbol{M}, 0.2\boldsymbol{C}, 0.2\boldsymbol{G})$$
(47)

$$\boldsymbol{\Delta}_{2} = (0. \, 2\boldsymbol{L}, 0. \, 2\boldsymbol{R}) \tag{48}$$

ELM 网络输入为  $z = (z_2, z_3)^T$ ,采用 Sigmoid 函数作为激活函数。通过反复调试,选取网络隐层神经元数 m = 12,网络输入层到隐层神经元权值 I 取 0~1 中随机数,网络输入阈值 b 取 200~300 中随机数,隐含层到输出层权值估计值初始化为 0.1。 PSO 优化算法参数设置,粒子群维数 20,粒子个数 50,粒子初始值为 0~1 中随机数,迭代次数为 150。 优化前后参数如表 1 所示,输送机构参数如表 2 所示,驱动电机参数如表 3 所示。

表1 神经网络自适应反演控制器参数

 
 Tab. 1
 Motor parameters of novel hybrid automobile electro-coating conveying mechanism

参数	优化前	优化后
反演系数 $\lambda_1$	450	532.32
反演系数 $\lambda_2$	1 000	1 042. 28
反演系数 λ <sub>3</sub>	1 200	1 244. 93
自适应参数 k	0.05	0.37
自适应参数 γ1	1 000	1 124.47
自适应参数 γ2	1 080	845.42
控制参数 $b_s$	0.120	0.103

#### 表 2 混联式汽车电泳涂装输送机的动力学参数

 
 Tab. 2
 Dynamic parameters of novel hybrid automobile electro-coating conveying mechanism

参数	数值	参数	数值
连杆长度 l <sub>1</sub> ~l <sub>4</sub> /m	0. 495	车身固定架斜支架长度 l <sub>8</sub> /m	0.6
连接杆长度 l <sub>7</sub> /m	0.720	车身固定斜支架质量 m <sub>71</sub> /kg	6
从动轮半径 r <sub>1</sub> /m	0.075	连接杆质量 <i>m<sub>15</sub></i> /kg	5
主动轮半径 $r_2/m$	0.025	车身质量 m/kg	23
连接杆半径 r <sub>15</sub> /m	0.0125	滑块质量 m <sub>s1</sub> 、m <sub>s2</sub> 、m <sub>s3</sub> 、m <sub>s4</sub> /kg	4
车体长度 a/m	0.58	连接杆质量 m/kg	7
车体高度 b/m	0.20	车体固定架夹角 θ/(°)	60
车体宽度 c/m	0.23	丝杠机械效率 $\eta$	0.9
从动轮质量 $m_b/kg$	3.2	丝杠导程 s/m	0.01
主动轮质量 $m_a/kg$	0.5	重力系数 g/(m·s <sup>-2</sup> )	9.8

表 3 混联式汽车电泳涂装输送机的电机参数

#### Tab. 3 Motor parameters of novel hybrid automobile

electro-coating conveying mechanism

参数	滑块电机	翻转电机
力矩常数 K <sub>T</sub> /(N・m・A)	0.562	0.959
电感 L/mH	2.870	3.506
电阻 R/Ω	1.638	0.655
反电动力矩常数 K <sub>E</sub>	0.0937	0.1600
电机传动比 $T_M$	$200\pi$	20

翻转升降机构的第一滑块与第三滑块对称,

第二滑块与第四滑块对称,第一主动轮与第二主 动轮对称,因此本文仅给出第一、第二滑块和第一 主动轮的仿真结果。图4、5为在给定轨迹下,包 含模型不确定性及存在外部干扰的情况,第一、第 二滑块和第一主动轮的轨迹跟踪曲线,从图中可 以看出,基于 PSO 的神经网络自适应反演控制在 存在较大干扰的情况下收敛更快,且跟踪效果优 于未优化的神经网络自适应反演控制方法和 PD 控制,验证了本文所考虑的系统中不匹配干扰的 必要性与本文设计控制方法的有效性,跟踪控制 效果与本文理论分析基本一致。



图 6、7 为第一、第二滑块和第一主动轮的轨迹 跟踪误差,从图中可以看出,采用 PD 控制无法实现 稳定跟踪,误差较大,采用 PSO 优化后的神经网络 自适应反演控制在外部干扰的影响下误差小于未经 参数优化的控制器,PSO 优化后的参数提高了控制 器性能,具有更强的鲁棒性与抗干扰性,与本文的理





### 6 结论

(1)考虑包含驱动电机特性的混联机构,采用 反演法分阶设计控制策略,同时将输送机构建模误 差、摩擦力、负载和外界随机干扰以及电机电压干 扰,作为匹配干扰与不匹配干扰两个集总干扰项,采 用 2 个 ELM 网络分别进行在线逼近,其中 ELM 网 络的输出基于 Lyapunov 函数设计权重自适应律在 线调整,并在控制器中前馈补偿。与传统混联机构 控制方法相比,有效消除了系统中存在的不匹配干 扰的影响,提升了混联机构跟踪控制性能。

(2)针对本文所设计的混联机构神经网络自适 应反演控制器中包含的反演镇定系数、自适应参数 等可调参数,采用 PSO 进行寻优整定,选择系统误 差、输出误差、控制器输出和上升时间作为目标函数 构造条件,通过 150 次迭代优化获得控制器最优参 数。仿真结果表明,基于 PSO 优化的混联机构神经 网络自适应反演控制器,跟踪精度与系统鲁棒性得 到进一步提升。



- YUAN Wei, GAO Guoqin. Disturbance observer-based adaptive integral sliding mode control for the hybrid automobile electrocoating conveying mechanism [J]. International Journal of Advanced Robotic Systems, 2019, 16(3):1-12.
- [2] BAEK J, JIN Maolin, SOOHEE H. A new adaptive sliding-mode control scheme for application to robot manipulators [J]. IEEE Transactions on Industrial Electronics, 2016, 63(6): 3628 - 3637.
- [3] 于欣波, 贺威, 薛程谦, 等. 基于扰动观测器的机器人自适应神经网络跟踪控制研究[J]. 自动化学报, 2019, 45(7): 1307-1324.

YU Xinbo, HE Wei, XUE Chengqian, et al. Disturbance observer-based adaptive neural network tracking control for robots [J]. Acta Automatica Sinica, 2019, 45(7): 1307 - 1324. (in Chinese)

- [4] WANG Hanlei. Adaptive control of robot manipulators with uncertain kinematics and dynamics [J]. IEEE Transactions on Automatic Control, 2017, 62(2): 948-954.
- [5] 薛晔,于海生,吴贺荣.柔性关节机器人的模糊反步自适应位置控制[J].青岛大学学报(工程技术版),2019,34(2): 56-62.

XUE Ye, YU Haisheng, WU Herong. Fuzzy backstepping adaptive position control of flexible joint robot [J]. Journal of Qingdao University(Engineering & Technology Edition), 2019, 34(2): 56-62. (in Chinese)

- [6] ZHENG Xuemei, LI Peng, LI Haoyu, et al. Adaptive backstepping-based NTSM control for unmatched uncertain nonlinear systems [J]. Journal of Systems Engineering and Electronics, 2015, 26(3): 557 - 564.
- [7] LIU Yanjun, SHAO Chengtong. Barrier lyapunov functions-based adaptive control for a class of nonlinear pure-feedback systems with full state constraints[J]. Automatica, 2016, 64(1):70-75.
- [8] NA M, HIROSH I, YOICH I. Design of an adaptive sliding mode controller for robust yaw stabilisation of in-wheel-motor-driven electric vehicles [J]. International Journal of Vehicle Design, 2015, 67(1):98 - 113.
- [9] AREFI, MOHAMMAD M, JAHED R, et al. Adaptive neural stabilizing controller for a class of mismatched uncertain nonlinear systems by state and output feedback[J]. IEEE Transactions on Cybernetics, 2015, 45(8): 1587 - 1596.
- [10] 刘晓飞,姚建涛,赵永生.基于模型的冗余驱动并联机构神经网络同步协调控制[J/OL].农业机械学报,2018, 49(2):367-375.

LIU Xiaofei, YAO Jiantao, ZHAO Yongsheng. Model-based synchronous control of redundantly actuated parallel manipulator with neural network [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018, 49(2): 367 - 375. http: // www.j-csam.org/jcsam/ch/ reader/view\_abstract.aspx? flag = 1&file\_no = 20180248&journal\_id = jcsam. DOI: 10.6041/ j.issn.1000-1298.2018.02.048. (in Chinese)

- [11] WEI He, CHEN Yuhao, YIN Zhao. Adaptive neural network control of an uncertain robot with full-state constraints [J]. IEEE Transactions on Cybernetics, 2015, 46(3): 620 - 629.
- [12] PETKOVIC D, DANESH A, DADKHAH M, et al. Adaptive control algorithm of flexible robotic gripper by extreme learning machine [J]. Robotics and Computer-Integrated Manufacturing, 2016, 37(1): 170-178.
- [13] ZHOU Zhiyu, WANG Chao, ZHU Zefei, et al. Sliding mode control based on a hybrid grey-wolf-optimized extreme learning machine for robot manipulators[J]. Optik, 2019, 185: 364 - 380.
- [14] SI Wu, WANG Youyi, CHENG Shijie. Extreme learning machine based wind speed estimation and sensorless control for wind turbine power generation system[J]. Neurocomputing, 2013, 102: 163 175.
- [15] 刘文帅,姚小敏,李超群,等.基于响应面和遗传算法的尾座式无人机结构参数优化[J/OL].农业机械学报,2019, 50(5):88-95.

LIU Wenshuai, YAO Xiaomin, LI Chaoqun, et al. Optimization of configuration parameters of tail-sitter UAV based on response surface and genetic algorithm [J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2019,50(5): 88-95. http://www.j-csam.org/jcsam/ch/reader/view\_abstract.aspx? flag = 1&file\_no = 20190510&journal\_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2019.05.010. (in Chinese)

- [16] BOUNAR N, LABDAI S, BOULKROUNE A. PSO GSA based fuzzy sliding mode controller for DFIG-based wind turbine [J]. ISA Transactions, 2019, 85: 177 - 188.
- [17] 贾会群,魏仲慧,何昕,等.基于改进粒子群算法的路径规划[J/OL].农业机械学报,2018,49(12):371-377.
   JIA Huiqun, WEI Zhonghui, HE Xin, et al. Path planning based on improved particle swarm optimization algorithm[J/OL]. Transactions of the Chinese Society for Agricultural Machinery, 2018,49(12):371-377. http://www.j-csam.org/jcsam/ch/reader/view\_abstract.aspx? flag = 1&file\_no = 20181244&journal\_id = jcsam. DOI: 10.6041/j.issn.1000-1298.2018.12.
   044. (in Chinese)
- [18] HAMDI H, REGAYA C, ZAAFOURI A. Real-time study of a photovoltaic system with boost converter using the PSO RBF neural network algorithms in a MyRio controller[J]. Solar Energy, 2019, 183: 1 16.
- [19] 邓涛,卢任之,李亚南,等.运用改进 PSO 算法的驾驶员自适应方向与速度综合控制优化研究[J].重庆理工大学学报(自然科学),2015,29(8):12-17.
   DENG Tao, LU Renzhi, LI Ya'nan, et al. Optimization for driver model of integrated control of direction and speed based on improved PSO algorithm[J]. Journal of Chongqing University of Technology(Natural Science), 2015, 29(8):12-17. (in Chinese)
- [20] HUANG Guangbin, CHEN Lei, CHEE K. Universal approximation using incremental constructive feedforward networks with random hidden nodes[J]. IEEE Trans. on Neural Networks, 2006, 17(4): 879-892.
- [21] HUANG Guangbin, WANG Dianhui, LAN Yuan. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2):107-122.