

基于天牛须BP神经网络的船舶电动舵机自抗扰控制

孙宏林 李宁博 张均东

(大连海事大学 轮机工程学院 辽宁 大连 116026)

摘要 将自抗扰控制器(ADRC)引入到智能船舵机控制优化问题中,同时将神经网络嵌入到自抗扰控制,针对电动舵机快响应、非线性的特点提出一种神经网络自抗扰控制。将天牛须搜索(BAS)寻优能力强的特性与BP神经网络中的权值与阈值寻优过程相结合,建天牛须BP神经网络自抗扰控制器,弥补了BP神经网络训练时间较长、收敛速度较慢的问题。以船舶电动舵机系统作为被控对象在该控制器下的舵机系统的控制性能得到了提升,控制精度高无超调同时具有良好的鲁棒性,同时建立的BAS-BP神经网络自抗扰控制器对于实际应用具有指导意义。

关键词 天牛须搜索算法 BP神经网络 电动舵机 天牛须BP神经网络自抗扰控制

中图分类号 TP3 **文献标志码** A **DOI**:10.3969/j.issn.1000-386x.2024.03.013

THE ACTIVE-DISTURBANCE-REJECTION CONTROL OF MARINE ELECTRIC STEERING GEAR BASED ON LONGHORN WHISKER BP NEURAL NETWORK

Sun Honglin Li Ningbo Zhang Jundong

(School of Marine Engineering, Dalian Maritime University, Dalian 116026, Liaoning, China)

Abstract The active disturbance rejection controller (ADRC) was introduced into the intelligent ship steering gear control optimization problem, and the neural network was embedded in the ADRC. Aimed at the characteristics of fast response and nonlinear electric steering gear, a neural network active-disturbance rejection control was proposed. Combining the characteristics of BAS with the weight and threshold optimization process of BP neural network, an active disturbance rejection controller of BAS neural network was built to make up for the long training time and slow convergence speed of BP neural network. Taking Marine electric steering system as the controlled object, the control performance of the steering system under this controller was improved, the control precision was high, with no overshoot and has good robustness. The established BAS-BP neural network active disturbance rejection controller had guiding significance for practical application.

Keywords Longhorn beetle search BP neural network Electromechanical actuator (EMA) BAS-BP neural network ADRC

0 引言

现代智能无人船舶的舵机系统由电机驱动,经由减速机构带动舵叶偏转,完成船舶的航行姿态的稳定控制。理想化的船舶舵机模型为二阶系统模型,但在实际航行过程中会受到其载荷不定性变化同时和一系列的非线性动态因素影响,而传统的PID控制难以实

现船舶舵机角度的快速且较准确的优化控制^[1],同时为了保证与提高船舶舵机系统的控制能力和稳定性,此时针对船舶舵机系统的控制性能的非线性特性研究十分重要,并对此提出可靠的控制算法。

自抗扰控制算法针对非线性与快时变和耦合等一系列问题具有良好的控制能力,在自动控制领域具有广泛的应用前景^[2]。许多的研究学者针对传统非线性自抗扰控制多控制参数的问题进行改进与简化,提高

性能^[3]。但在实际操作应用过程中,自抗扰控制在控制规则优化与参数调整方面仍然存在较大的不足与难度。针对上述问题,提出改进的自抗扰控制算法与相对应自抗扰控制器设计方案,将微分跟踪器去除、非线性控制律状态空间线性化降低系统的参数复杂度,针对测量输出容易被噪声污染的问题,引入非线性 $fal(\cdot)$ 函数低通滤波系统构成新的自抗扰控制算法;在此基础上将天牛须搜索(BAS)寻优能力强的特性与 BP 神经网络中权值与阈值寻优过程相结合^[4-5],进一步提高神经网络函数逼近的准确度的能力,克服传统 BP 神经网络训练过程时间较长与收敛速度较慢的缺点^[6-7],建立 BAS-BP 神经网络的自抗扰控制策略,本质是将人工神经网络 ANN 嵌入到改进的自抗扰控制器中,利用神经网络能够任意逼近非线性函数的特性用辨识出的 ANN 去补偿掉对象的一部分,即近似地认为使原对象的变化范围变小,更进一步地提高改进自抗扰控制器的控制品质。

1 船舶电动舵机原理

1.1 现代智能船舶舵机原理

现代智能化船舶的舵机控制系统采用舵机控制器控制无刷直流电机转数;采用减速机构降速以及利用减速器带动舵轴转动,转角信息与转数信息在现代船舶控制中分别使用电位计与编码器进行监控测试传递构成完整的闭环控制回路^[8]。

从传统的伺服系统进行分类电动舵机属于位置控制,针对控制过程中跟踪的快速性能和较高的跟踪性能,船舶电动舵机控制系统是经典的位置环与速度环双闭环控制,其船舶舵机控制系统流程如图 1-图 2 所示。




图 1 电动舵机控制示意图




图 2 电动舵机结构

船舶电动舵机系统根据其工作原理在忽略电动舵机的电机电感时,可列船舶电动舵机系统的状态方程为:

$$\begin{cases} \dot{x}_1 = x_2 \\ x_2 = -\frac{K_m K_e}{J R_a} x_2 - \frac{T_L}{J} - \frac{T_m}{J} + \frac{K_s K_m}{J R_a} u \\ y = x_1 \end{cases} \quad (1)$$

船舶电动舵机系统中的相关系数分别如下所示:

电机转数为 n ;功率放大器系数为 K_s ;电感为 L ;反电势系数为 K_e 、力矩系数为 K_m ;电阻为 R_a ;摩擦力矩为 T_m ;总转动惯量为 J ;铰链力矩为 T_L ;控制输入为 u_a ;设船舶舵机实际控制过程转动角度为 x_1 ;角速度为 x_2 。同时在对船舶舵机控制系统的实际研究中发现摩擦力矩与铰链力矩变化与外部载荷的变化有关,跟随外部载荷不断随机变化,因此船舶电动舵机控制系统属于二阶非线性控制系统^[3]。

2 自抗扰控制器

2.1 基于天牛须 BP 神经网络的自抗扰控制器

自抗扰控制继承了经典 PID 控制特性是一种和实际密切相关的新型自动控制技术。它顺应了数字控制的潮流,发展和丰富了 PID 的内质。在 PID 控制原理的基础上,从实际现实控制,中广泛存在非线性特性作为切入点,开发了较为有针对性功能的算法:跟踪微分器(TD)、扩张状态观测器(ESO)和非线性 PID^[9-10]。

基于实际工程操作,设计 BAS-BP 神经网络自抗扰控制器:去除传统 ADRC 中的微分跟踪器 TD,采用线性误差反馈控制律代替非线性误差反馈控制和建立线性状态空间扩张状态观测器 LESO,降低了参数整定的复杂度与难度^[11];同时在此基础上引入 $fal(\cdot)$ 函数低通滤波系统,以此提高智能船舶舵机的静态控制性能;船舶电动舵机控制系统在实际控制过程中参数变化范围较大,当控制系统采用自抗扰控制时,对于控制参数变化起伏差值较大的系统将 ESO 的参数设定在一定的范围内后,其控制稳定性与动态性能表现不如控制参数变化范围幅度较小的系统^[12],为了降低船舶电动舵机控制参数变化幅度与带宽此时引入 BP 神经网络。

BP 神经网络采用误差反向传播学习算法,具有通过神经网络自身的学习实现高度复杂的非线性映射,从而实现从输入到输出的非线性映射^[13]。将 BAS-BP 神经网络嵌入到 ADRC 中,利用神经网络能够逼近非线性函数的特性去补偿控制对象的一部分变化以此降低扩张状态观测器的实际观测带宽占用,提高观测器估测精度,亦近似地使原系统参数变化范围变小,从而提高 ADRC 的控制能力,获得适应性更强的自抗扰

控制器^[14-15]。

假设船舶舵机控制系统模型为 h , 实际控制系统中由已知部分 h_0 和未知部分 h_1 两部分组成, 即 $h = h_0 + h_1$, 将已知部分 h_0 送入扩张状态观测器, 此时扩张状态 z_3 实时估计观测的是 h_1 由此降低了观测器的带宽负担, 进而提高了 ESO 的实时观测估计与补偿的能力。因而可建立天牛须 BP 神经网络自抗扰控制器, 如图 3 所示。

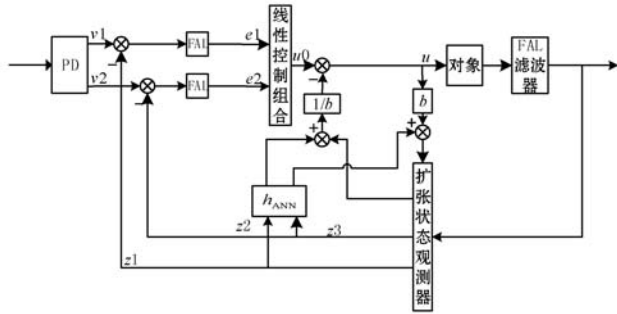


图 3 天牛须 BP 神经网络自抗扰控制器

2.2 建立天牛须 BP 神经网络自抗扰控制器

首先根据式(1)令 $y = x_1, x_2 = \dot{x}_1, x_3 = f = -\frac{T_L}{J} -$

$\frac{T_m}{J} + w$, 建立电动舵机控制系统的扩张状态观测器如式(4)所示:

$$\begin{cases} \dot{x}_1 = x_2 \\ \dot{x}_2 = x_3 + bu \\ \dot{x}_3 = f \\ y = x_1 \end{cases} \Rightarrow \begin{cases} e = z_1 - x_1 \\ \dot{z}_1 = z_2 - \beta_1(e) \\ \dot{z}_2 = z_3 - \beta_2(e) + bu \\ \dot{z}_3 = -\beta_3(e) \\ y = x_1 \end{cases} \quad (2)$$

式(2)左侧是状态空间方程, 右侧是三阶扩张状态观测器, 其中 β 为设定观测器的反馈矩阵。

采用现代控制理论中的极点配置的方式, 将状态观测器的极点配置在左半平面即 $-\omega_0$ 点, 此时 ESO 的带宽为 ω_0 , 公式如下:

$$s^3 + \beta_1 s^2 + \beta_2 s + \beta_3 = (s + \omega_0)^3 \quad (3)$$

$$\beta_1 = 3\omega_0, \beta_2 = 3\omega_0^2, \beta_3 = \omega_0^3$$

天牛须搜索 (Beetle Antennae Search, BAS) 算法也称之为甲壳虫算法, 是 2017 年基于甲壳虫觅食原理提出的生物启蒙算法, 对于多目标函数的智能优化优势明显, 其生物原理为: 当甲壳虫开始觅食时, 食物处于未知位置, 甲壳虫通过其两只触角对空气中的食物气味进行感知, 且根据食物距离两只触角的远近不同, 所感知的气味浓度也有所差异。当食物处于天牛左侧时, 左侧触角感知的气味浓度强于右侧触角感知的气

味浓度, 天牛根据两只触角所感知的浓度差, 向着浓度强的一侧随机前进, 通过一次次迭代, 最终找到食物的位置。同时 BAS 算法对于函数的具体形式以及梯度信息没有任何要求, 自动实现寻优过程, 且无须精确模型即可进行全局智能优化。同时天牛须搜索的个体值为一, 运算量少, 对比粒子群与差分进化算法等收敛速度更快, 并且精度远超 SPSA 与 ES 等在线优化算法, 更能在八位单片机上进行实际运行, 为下一步的实际工程应用奠定了基础^[16-17]。

本文的神经网络为三层, 以扩张状态观测器 ESO 的 z_1 与 z_2 为训练数据, z_3 为期望输出, 在神经网络模型中隐含层数选为 1, 输入层神经元个数为 2, 输出层神经元个数为 1, 隐含层神经元个数根据经验公式 $G = \sqrt{mn} + (1 \sim 10)$ 计算, $G = 5$ 建立结构为 2-5-1 的三层天牛须 BP 神经网络模型。

天牛须 BP 神经网络自抗扰算法的具体流程如下。

1) 建立天牛须摆向的随机向量, 同时进行归一化处理。

$$b = \frac{\text{rand}(k, 1)}{\|\text{rand}(k, 1)\|} \quad (4)$$

其中: $\text{rand}(\cdot)$ 定为随机函数; k 属于空间维度。则在 BP 神经网络中搜索空间维度为 $k = M \times N + N \times 1 + N + 1$ 。

2) 建立天牛左侧与右侧的两须空间坐标。

$$\begin{cases} \chi_m = \chi^n + \alpha \cdot \frac{\beta}{2} \\ \chi_{ln} = \chi^n - \alpha \cdot \frac{\beta}{2} \end{cases} \quad (5)$$

式中: χ_m 与 χ_{ln} 代表天牛右侧与左侧须在第 n 次迭代后的空间坐标; χ^n 表示第 n 次迭代后的质心坐标; α 为天牛两须之间的距离。

3) 由适应度函数来确定左右两须的气味强度同时更新天牛的位置。

$$\chi^{n+1} = \chi^n + \varepsilon^n \cdot b \cdot \text{sign}[f(\chi_r) - f(\chi_l)] \quad (6)$$

式中: ε^n 为第 n 次迭代后的步长因子。

4) 确定适应度函数。

$$\text{Fitness} = \frac{1}{N} \sum_{i=1}^N (\tau_{\text{sim}(i)} - \gamma_i)^2 \quad (7)$$

式中: $\tau_{\text{sim}(i)}$ 为第 i 个样本的模型输出值; N 为训练样本数; γ_i 是第 i 个样本的实际值。

5) 更新移动天牛的适应度, 设定步长因子。

$$\begin{cases} \alpha^n = \text{eta}_\alpha \times \alpha^{n-1} \\ v^n = \text{eta}_v \times \alpha^{n-1} \end{cases} \quad (8)$$

天牛在区域内的搜索能力受控于步长因子, 因此在初始步长选择过程中 eta 选取在 $[0, 1]$ 中靠近 1 的

一侧,避免在搜索过程中陷入局部最小的困境;式中 η_{α} 为天牛两须距离的衰减系数; η_{ν} 是两须步长的衰减系数,经过多次实验对比最后选定 $\eta_{\nu} = 0.95$ 。

6) 经判断符合达到结束迭代的条件,则输出为最优优化权值与阈值;不符合则重复上述过程达到符合条件。

7) 神经网络初始化训练与学习:将优化后的权值与阈值与从 $(-1, 1)$ 之间随机选取数字进行连接;输入训练数据与期望值,同时设定训练次数与误差精度。

8) 每层的输出:

$$\begin{cases} \omega_j(k) = f\left\{\sum_{i=1}^m [\varphi_{ij}\chi_i(k) - \theta_i]\right\} & j = 1, 2, \dots, \omega \\ \varpi_o(k) = f\left\{\sum_{j=1}^m [\varphi_{jo}\omega_j(k) - \lambda_o]\right\} & o = 1, 2, \dots, \omega \end{cases} \quad (9)$$

9) 误差:

$$e = \frac{1}{2} \sum_{k=1}^K [\varpi_o(k) - n_o(k)]^2 \quad (10)$$

$$\begin{cases} \delta_o(k) = \varpi_o(k) [1 - \varpi_o(k)] [\varpi_o(k) - n_o(k)] \\ \delta_j(k) = \varpi_o(k) [1 - \varpi_o(k)] \delta_o(k) \zeta_{jo} \end{cases} \quad (11)$$

式中: $\delta_o(k)$ 、 $\delta_j(k)$ 分别为输出层误差与隐层节点误差, e 为误差函数。

10) 修正权值:

$$\begin{cases} \zeta_{jo}^{N+1} = \zeta_{jo}^N + \eta \delta_o(k) \varpi_o(k) \\ \Delta \zeta_{jo}(k) = -\mu \frac{\partial e}{\partial \zeta_{jo}} = \eta \delta_o(k) \varpi_o(k) \end{cases} \quad (12)$$

$$\begin{cases} \varphi_{ij}^{N+1} = \varphi_{ij}^N + \eta \delta_j(k) \chi_i(k) \\ \Delta \varphi_{ij}(k) = -\mu \frac{\partial e}{\partial \varphi_{ij}} = \delta_j(k) \chi_i(k) \end{cases} \quad (13)$$

式中: N 是迭代次数; η 是调整系数; μ 是学习效率。

11) 根据计算出的各个神经元误差,考察计算误差精度是否小于或者等于给定精度,决定是否结束算法计算,当结束神经网络训练得出的逼近函数 h_{ANN} 嵌入到自抗扰控制器当中;否则重复上述神经网络学习过程。

基于天牛须 BP 神经网络的自抗扰控制器扩张状态观测器前后变化为:

$$\begin{cases} e = z_1 - x_1 \\ \dot{z}_1 = z_2 - \beta_1(e) \\ \dot{z}_2 = z_3 - \beta_2(e) + bu \\ \dot{z}_3 = -\beta_3(e) \\ y = x_1 \end{cases} \Rightarrow \begin{cases} e = z_1 - x_1 \\ \dot{z}_1 = z_2 - 3\omega_0(x_1 - z_1) \\ \dot{z}_2 = z_3 + b_0u + h_{ANN} + 3\omega_0^3(x_1 - z_1) \\ \dot{z}_3 = \omega_0^3(x_1 - z_1) \\ y = x_1 \end{cases} \quad (14)$$

其控制输入式(15)。

$$u = -z_3 - \eta \frac{dfal(e, a, \delta)}{dz_1} z_2 - \eta fal[z_2 + h_{ANN} + \eta_{\alpha} fal(e, a, \delta)] \quad (15)$$

式中: η_{α} 为控制带宽, $\eta_{\alpha} = \delta^{1-a} \omega_c$ 。

2.3 $fal(\cdot)$ 函数低通滤波性能分析

针对舵机控制系统的稳态性能,以及控制输出过程中易受到噪声污染的问题,设计了 $fal(\cdot)$ 函数低通滤波系统。 $fal(\cdot)$ 函数的定义为:

$$fal(e, a, \delta) = \begin{cases} e \cdot \delta^{1-a} & |e| \leq \delta \\ |e|^a \cdot \text{sign}(e) & |e| > \delta \end{cases} \quad (16)$$

$fal(\cdot)$ 函数在 $0 < a < 1$ 时具有“小误差大增益,大增益小误差”的工程控制特性^[8]。 $fal(\cdot)$ 函数低通滤波系统的具体数学表现形式为:

$$\begin{cases} \dot{x} = k \cdot fal(e, a, \sigma) \\ e = y - y_0 \\ y_0 = x \end{cases} \quad (17)$$

因而此时建立完整的控制流程,如图4所示。

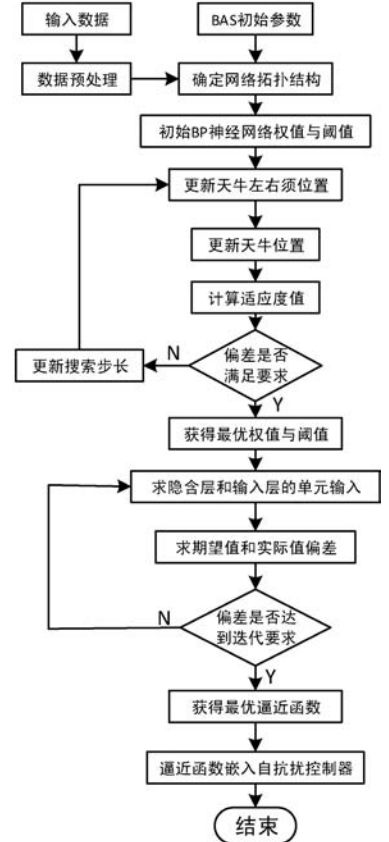


图4 天牛须 BP 神经网络的自抗扰控制流程

2.4 自抗扰控制器参数选择

改进的自抗扰控制器包括 ω_0 、 ω_c 、 b 、 a 、 k 、 δ 共6个参数。 ω_c 需要根据总体的需要设计,增加 ω_c 能够提高系统的响应时间同时降低超调量,但同时受到其噪声和不确定动态的限制作用,现代控制理论中 ω_0 和 ω_c 满足闭环主导极点的特性:存在 $\omega_0 = 3 \sim 5\omega_c$ 的关系;参

数 b 是扩张状态观测器与补偿控制输入的共用参数,根据系统的结构与特点决定参数; k 为 $fal(\cdot)$ 函数低通滤波器的比例因子,其 k 值越大跟踪速度越快,但跟其滤波效果成反比; $a(0 < a < 1)$ 为滤波参数之一; δ 决定滤波函数的幅值大小,值越大延时越小。

3 实验与结果分析

利用 MATLAB 2020a 建立现代智能化船舶电动舵机控制模型,在仿真建模中伺服电机的参数根据某实际无刷直流电机设定参数为:额定功率 120 W;额定转矩 $5.76\text{mN} \cdot \text{m}$;额定电压 24 V;额定电流 5.58 A;转子惯量 $85\text{g} \cdot \text{cm}^2$;转矩常数 $22.1\text{mN} \cdot \text{m/A}$;速度 $445\text{r}/(\text{min} \cdot \text{V})$;额定转速 $8560\text{r}/\text{min}$,同时与相关的机械参数完成对于智能船舶舵机的控制模型建立。考虑自抗扰控制器的自身特点与控制目标的特性,设定相对应的控制参数分别如下: $\omega_0 = 4206.2, \omega_c = 862.4, a = 0.29, b = 12, k = 4712.1, \delta = 0.72$ 。当系统运行稳定后,采集扩张状态观测器中的 z_1, z_2 与 z_3 的值 500 个,送入神经网络用于训练函数逼近。期望误差最小值为 0.01,利用 BAS-BP 神经网络算法迭代训练 500 次。将经天牛须 BP 神经网络模型训练得到的逼近函数 h_{ANN} 与 ADRC 相结合进行控制补偿,此时研究发现系统的 $b = 7.8$ 变化幅度最为明显,说明 BAS-BP 神经网络的嵌入降低了控制系统实际所需带宽。在参数不变的前提下重新进行控制仿真进行更直观的对比。采用 MATLAB 建立仿真和训练分别如图 5 - 图 7 所示。




图 5 天牛须 BP 神经网络自抗扰控制仿真图




图 6 BAS-BP 神经网络训练过程表示




图 7 优化 BP 神经网络适应度对比

为了更直观地体现改进前后 ADRC 的控制特性,在控制中加入方波与随机数的扰动量,与传统的 PID 控制进行对比,从图 8 - 图 11 的对比中可看出:自抗扰控制器在控制上无超调,在跟踪阶跃信号方面表现出了良好的跟踪特性,表现得更迅速与直观,同时在加入 BAS-BP 神经网络逼近的非线性函数后,提高了自抗扰控制器的响应速度控制精度与稳态性能效果。




图 8 PID 控制曲线




图 9 扰动曲线




图 10 自抗扰控制曲线




图 11 天牛须 BP 神经网络自抗扰控制曲线

4 结 语

针对传统自抗扰控制器参数多,提出的新型自抗扰控制器减少了控制参数,能够不依赖被控模型,且具有良好的鲁棒性。将天牛须算法与 BP 神经网络相结合克服了训练时间长、收敛速度慢的缺点且提高了逼近函数的准确度。天牛须 BP 神经网络嵌入扩张状态观测器(ESO)中,利用 BP 神经网络拟合部分扰动,降低 ESO 观测器的计算复杂度,提高观测精度。对于电动舵机控制仿真结果显示将神经网络嵌入自抗扰控制新型自抗扰控制器降低了超调量,适应于船舶电动舵机中实际控制状况复杂多变,提高了船舶电动舵机的控制精度,天牛须 BP 神经网络自抗扰控制算法对于下一步实际应用具有指导意义。

参 考 文 献

- [1] 吕寅新. 一种船舶电动舵机伺服驱动控制系统设计与研究[D]. 大连:大连海事大学,2020.
- [2] 高华鑫. 基于变结构自抗扰的车用 PMSM 模型预测控制[J]. 计算机应用与软件,2018,35(6):83-87,137.
- [3] 史运涛,刘伟川,雷振伍,等. 基于混杂优化方法的 ADRC 参数整定方法研究[J]. 控制工程,2013,20(4):748-752.
- [4] 王甜甜,刘强. 基于 BAS-BP 模型的风暴潮灾害损失预测[J]. 海洋环境科学,2018,37(3):457-463.
- [5] 刘晓峰,苗鸿宾,温静媛. 基于 BAS-BP 神经网络的钻削力预测[J]. 组合机床与自动化加工技术,2019(8):49-52.
- [6] 张荣,韩京清. BP 神经网络在自抗扰控制器中的应用[C]//中国控制会议,1998:4.
- [7] 付文强,赵东标,赵世超. 基于 BP 神经网络优化自抗扰 PMSM 高精度速度控制[J]. 微特电机,2020,48(12):50-54.
- [8] 刘磊,赵国平,岳彩锐,等. 无人艇电动舵机电磁振动仿真与分析[J]. 中国造船,2020,61(S1):150-155.
- [9] 刘瑞娟. 基于等价输入干扰补偿的几类典型系统扰动抑制设计[D]. 长沙:中南大学,2014.
- [10] 韩京清. 利用非线性特性改进 PID 控制律[J]. 信息与控制,1995,24(6):356-364.
- [11] 易星,吴昊. 基于双种群混沌鲸鱼算法的自抗扰控制器参数整定[J]. 计算机应用与软件,2019,36(4):281-285,294.
- [12] 韩京清. 非线性状态误差反馈控制律——NLSEF[J]. 控制与决策,1995,10(3):221-225,231.
- [13] 王宏志,王婷婷,胡黄水,等. 基于 Q 学习优化 BP 神经网络

的 BLDCM 转速 PID 控制[J]. 吉林大学学报(工学版),2021,51(6):2280-2286.

- [14] 彩凯,赵世海. 基于 BP 神经网络自抗扰控制的放卷张力控制系统[J]. 山东纺织科技,2018,59(5):29-34.
- [15] 齐晓慧,李杰,韩帅涛. 基于 BP 神经网络的自适应自抗扰控制及仿真[J]. 兵工学报,2013,34(6):776-782.
- [16] 葛峰,韩建立,高松. 基于 BAS-BP 神经网络的多应力加速寿命试验预测方法[J]. 兵工自动化,2020,39(6):5-9,41.
- [17] 王宇轲. 基于 BA-BP 算法的汽车配件需求预测系统研究与实现[D]. 成都:西南交通大学,2017.

(上接第 8 页)

- [25] Matsumoto T, Goto M, Ishii R, et al. Where should robots talk?: Spatial arrangement study from a participant workload perspective [C]//13th IEEE International Conference on Human-Robot Interaction,2018:270-278.
- [26] Ali M, Orden K, Parkhurst K, et al. Aging and engaging: A social conversational skills training program for older adults[C]//23rd International Conference on Intelligent User Interfaces,2018:55-66.
- [27] Briggs P, Scheutz M, Tickle-Degnen L. Are robots ready for administering health status surveys? first results from an HRI study with subjects with Parkinson's disease[C]//10th Annual International Conference on Human-Robot Interaction,2015:327-334.
- [28] Wulf L, Garschall M, Himmelsbach J. et al. Hands free-care free: Elderly people taking advantage of speech-only interaction[C]//8th Nordic Conference on Human-Computer Interaction: Fun, Fast, Foundational,2014:203-206.
- [29] Khosla R, Chu M T. Embodying care in Matilda: An affective communication robot for emotional wellbeing of older people in Australian residential care facilities [J]. ACM Transactions on Management Information Systems,2013,4(4):1-33.
- [30] Khosla R, Chu M T, Kachouie R, et al. Embodying care in Matilda: An affective communication robot for the elderly in Australia[C]//2nd ACM SIGHIT Health Informatics Symposium,2012:295-304.
- [31] Sabelli A M, Kanda T, Hagita N. A conversational robot in an elderly care center: An ethnographic study[C]//6th International Conference on Human-Robot Interaction,2011:37-44.
- [32] Heerink M, Kröse B, Wielinga B, et al. Measuring the influence of social abilities on acceptance of an interface robot and a screen agent by elderly users[C]//Conference on People and Computers XXIII Celebrating People and Technology,2009:1-5.