

DOI:10.19651/j.cnki.emt.2210152

基于RBF神经网络滑模控制的双尾鳍机器鱼*

霍建霖¹ 袁园² 张镭²

(1.河南省特种设备安全检测研究院 开封 475001; 2.河南大学物理与电子学院 开封 475001)

摘要: 为了开展水下探测,设计了一种双尾鳍水下机器鱼。由于其存在模型参数不确定性和复杂水波干扰,为了得到较好的控制效果,建立了带有参数不确定因子的动力学模型,并在此基础上设计了径向基函数(RBF)神经网络滑模控制器。利用Lyapunov函数证明了控制系统的稳定性。仿真结果表明,与传统的PID控制器相比,所设计的RBF神经网络滑模控制器对双尾鳍水下机器鱼模型参数变化不敏感,控制精度高,鲁棒性强。该方法为今后鳍驱动式水下机器人的设计及应用提供了参考。

关键词: 水下机器人;双尾鳍;滑模控制;神经网络

中图分类号: TP242 **文献标识码:** A **国家标准学科分类代码:** 510.8

Robotic fish with two caudal fins based on RBF neural network sliding mode control

Huo Jianlin¹ Yuan Yuan² Zhang Lei²

(1. Henan institute of special equipment safety inspection and testing, Kaifeng 475001, China;

2. School of Physics and Electronics, Henan University, Kaifeng 475001, China)

Abstract: In order to carry out underwater detection, an underwater robotic fish with two caudal fins is designed. Due to the uncertainties of model parameters and the disturbances of complex water waves, a dynamic model with uncertain parameter factors is established to obtain a better control effect. A radial basis function (RBF) neural network sliding mode controller is designed according to the dynamic model. The stability of the system is proved by using the Lyapunov function. The simulation results show that the designed controller is insensitive to the changes of the parameters of the dual-fin underwater robotic fish and has higher control accuracy and stronger robustness than the traditional PID controller. This method provides a reference for the design and application of fin-actuated underwater robot in the future.

Keywords: underwater robot; two caudal fins; sliding mode control; neural network

0 引言

鳍驱动式水下机器人有效率高、隐蔽性强、噪声低等优点,可用于水下生物观测、地质勘探等领域^[1]。但是由于复杂的水环境使鳍驱动式水下机器人的模型参数具有非线性和不确定性的问题,所以对其运动控制的研究一直是该领域的热点。Plamondon等^[2]采用自适应控制策略,利用机器人的桨叶产生定时控制力,实现机器人的轨迹跟踪。Remmas等^[3]采用模糊逻辑控制方法,结合视听信号控制鳍的摆动,实现鳍驱动式机器人对潜水员的跟踪。Salumae等^[4]采用基于优先级的方法控制鳍的运动,通过设计水下机器人运动自由度的优先级函数来实现机器人的位置跟

踪。然而,上述研究所用到的动力学模型参数都是在特定的实验或者仿真条件下得出的,在设计控制算法时没有考虑到模型参数的不确定性,这与具有非线性和时变性的水下环境不符。

径向基函数(radial basis function, RBF)神经网络滑模控制方法具有鲁棒性强,响应快速,不需要系统精确模型的优点^[5-6]。考虑到滑模运动与外界干扰无关的特性可以较好地处理水波的干扰问题,并且RBF神经网络可以识别任意不确定函数^[7-9]。本文对一种双尾鳍水下机器鱼设计了RBF神经网络滑模控制器,针对动力学模型中不确定项利用RBF神经网络在线逼近,以期实现期望对滑模控制器进行实时补偿,提升了整个控制系统的鲁棒性和控制精度。

收稿日期:2022-05-29

* 基金项目:河南省科技攻关质监专项(222102410008)资助

1 双尾鳍水下机器鱼

双尾鳍水下机器鱼结构如图1所示。舱体材料为聚丙烯。仓内含有锂电池、摄像头、单片机、通信模块、陀螺仪和加速度计、步进电机和两个伺服电机,尾鳍为弹性钢片。表1为双尾鳍机器鱼的设计参数。




图1 双尾鳍水下机器鱼

表1 双尾鳍水下机器人的设计参数

参数	描述
舱体测量/m(长×宽×高)	0.14×0.125×0.059
尾鳍测量/m(长×宽×高)	0.1×0.045×0.0002
质量/kg	0.7
尾鳍质量/kg	0.006
惯性矩阵/(kg·m ²)	Diag(0.00078 0.001 0.001 5)
尾鳍最大摆动幅值/rad	π/12
尾鳍最大摆动频率/Hz	3
直行时尾鳍相位差/rad	π

该机器鱼的尾鳍具有多种工作模式。当两个尾鳍驱动频率相同但相位相差π时,双尾鳍水下机器鱼保持直线运动。当只有单个尾鳍摆动时,鱼体开始转向。

2 双尾鳍水下机器鱼建模

如图2所示,在分析双尾鳍水下机器鱼运动时分别定义 $O_I X_I Y_I Z_I$ 和 $O_b X_b Y_b Z_b$ 表示惯性坐标系和体坐标系。




图2 惯性坐标系和机体坐标系

利用Fossen矢量模型可以建立双尾鳍水下机器鱼的六自由度运动模型^[10]:

$$\begin{cases} M\ddot{\eta} + C(\dot{\eta})\dot{\eta} + D(\dot{\eta})\dot{\eta} + g(\eta) = \tau + d(t) \\ \dot{\eta} = J(\eta)v \end{cases} \quad (1)$$

式中: $v = [p \ q \ r \ u \ v \ \omega]^T$ 表示线速度和角速度, $\eta = [\theta \ \varphi \ \psi \ x \ y \ z]^T$ 表示惯性系下的姿态和位置, $J(\eta)$ 为雅各比矩阵, M 为包含鱼体刚体项和附加水质量项的惯性矩阵, $C(\dot{\eta})$ 为包含刚体项和附加水质量项的向心力和科氏力矩阵, $D(\dot{\eta})$ 为流体阻尼项,它包含线性阻尼和二次阻尼。由重力和浮力引起的恢复力和力矩矢量为 $g(\eta)$ 。 $\tau = [K \ M \ N \ X \ Y \ Z]^T$ 为施加到鱼体上的力矩和力。 $d(t)$ 为环境干扰。

考虑到一个周期内尾鳍受到垂直方向阻力的作用效果为0,鱼体在横向和垂直方向不受驱动力,因此鱼体的驱动力和力矩矩阵可以简化为:

$$\tau = [N \ X]^T \quad (2)$$

取鱼体的控制输入为:

$$\mu = [f_1^2 - f_2^2 \ f_1^2 + f_2^2]^T \quad (3)$$

式中: μ 为鱼体的驱动输入, $f_i (i = 1, 2)$ 为第*i*个尾鳍的驱动频率。

用于描述驱动输入 μ 与驱动力和力矩 τ 之间关系的矩阵 B 表示为^[11]:

$$B = \begin{bmatrix} \mathcal{H}_1 & 0 \\ 0 & \mathcal{H} \end{bmatrix} \quad (4)$$

\mathcal{H} 表示为:

$$\mathcal{H} = 8(1 - \cos(\theta_{\max}))C_d \rho r_c^2 \theta_{\max} A_f \quad (5)$$

式中: θ_{\max} 为尾鳍摆动最大幅值, C_d 为流体阻力系数, r_c 为尾鳍到伺服电机转轴的距离, A_f 为尾鳍的迎风面积。

式(5)满足:

$$\tau = B * \mu \quad (6)$$

考虑到在获取鱼体动力学模型水动力参数的过程中简化了一些条件,因此有必要在式(1)中加入不确定因子 ΔU 来接近水下真实情况,如式(7)所示。

$$M\ddot{\eta} + C(\dot{\eta})\dot{\eta} + D(\dot{\eta})\dot{\eta} + g(\eta) + \Delta U = \tau + d(t) \quad (7)$$

根据式(6)和(7)的推导,可以将式(1)解耦为横摇和直行两个自由度的运动方程,如式(8)所示。

$$\ddot{\eta} = -M_2^{-1}((C_2(\dot{\eta}) + D_2(\dot{\eta}))\dot{\eta} + \Delta U_2) + M_2^{-1}B\mu + M_2^{-1}d(t) \quad (8)$$

式中:带有下标为2的矩阵是将双尾鳍水下机器鱼的六自由度运动模型解耦为二自由度运动模型后对应的矩阵。式(8)是在计算出模型参数近似值的基础上加入不确定因子得到的,它能更大程度地反映鱼体的真实运动情况。

3 双尾鳍水下机器鱼的RBF神经网络滑模控制

3.1 RBF神经网络滑模控制策略

根据双尾鳍水下机器鱼的动力学模型,模型的不确定项为:

$$\varepsilon = -M_2^{-1}((C_2(\dot{\eta}) + D_2(\dot{\eta}))\dot{\eta} + \Delta U_2) \quad (9)$$

RBF神经网络滑模控制基本控制策略如下:通过对系统的输出值 η 与期望值 η_d 做差可以得到运动模型的误差

e 。根据误差设计出滑模控制器的滑模面 s 。不确定项 ε 包含两个元素,这两个元素各通过一个 RBF 神经网络在线识别。将不确定项 ε 用 RBF 神经网络逼近得到的估计值 $\hat{\varepsilon}$ 代替,实现对滑模控制器的在线补偿。整个系统的控制结构如图 3 所示。




图 3 系统控制框图

3.2 RBF 神经网络滑模控制器的设计

根据式(9),可将双尾鳍水下机器鱼的动力学模型改写为,

$$\ddot{\eta} = \varepsilon + \zeta\mu + d(t) \quad (10)$$

式中: $\zeta = M_2^{-1}B$ 。

定义滑模控制系统的状态跟踪误差,

$$e = \eta - \eta_d \quad (11)$$

设计滑模控制器的滑模面,

$$s = \dot{e} + ce \quad (12)$$

式中: c 为常数矩阵且 $c > 0$ 。

对滑模面求导可得式(13),

$$\dot{s} = \dot{e} + c\dot{e} = -\ddot{\eta}_d + \varepsilon + \zeta\mu + d(t) + c\dot{e} \quad (13)$$

对于不确定矩阵 ε , 用 RBF 神经网络在线逼近。RBF 神经网络的算法为

$$\begin{cases} h_j = \exp\left(-\frac{\|x_r - b_j\|^2}{2\lambda_j^2}\right) \\ \varepsilon = W^* h_\varepsilon(x_r) + \sigma_\varepsilon \end{cases} \quad (14)$$

式中: x_r 为网络的输入, j 为网络隐含层的第 j 个节点, h_j 为第 j 个节点的高斯函数, W^* 为逼近不确定项 ε 的两个神经网络的理想权值矩阵, σ_ε 为逼近误差矩阵, 存在 $|\sigma_\varepsilon| \leq \sigma_{Me}$ 。 ε 为理想的神经网络的输出, $h_\varepsilon(x_r)$ 为网络输出的高斯函数矩阵。

取神经网络的输入为 $x_r = [\eta \quad \dot{\eta}]^T$, 用两个网络结构为 2-5-1 的 RBF 神经网络逼近不确定项 ε 中的元素, 那么两个网络的输出为:

$$\hat{\varepsilon} = \begin{bmatrix} \hat{W}_1^T h_{\varepsilon_1}(x_r) \\ \hat{W}_2^T h_{\varepsilon_2}(x_r) \end{bmatrix} \quad (15)$$

\hat{W}_1 和 \hat{W}_2 为分别为两个神经网络实际的权值, $h_{\varepsilon_1}(x_r)$ 和 $h_{\varepsilon_2}(x_r)$ 是两个神经网络的高斯函数的输出。 $\hat{\varepsilon}$ 为两个神经网络实际输出的函数。

根据式(14)的形式, 可以写成:

$$\begin{cases} \hat{W}^T = \begin{bmatrix} \hat{W}_1^T & 0 \\ 0 & \hat{W}_2^T \end{bmatrix} \\ h_\varepsilon(x_r) = \begin{bmatrix} h_{\varepsilon_1}(x_r) \\ h_{\varepsilon_2}(x_r) \end{bmatrix} \end{cases} \quad (16)$$

式(15)可以表示为:

$$\hat{\varepsilon} = \hat{W}^T h_\varepsilon(x_r) \quad (17)$$

采用神经网络最小参数学习法^[12-13], 令 $\Gamma = \|W^*\|^2$,

Γ 为正值, $\hat{\Gamma}$ 为 Γ 的估计, $\tilde{\Gamma} = \hat{\Gamma} - \Gamma$ 。

设计控制律为:

$$\mu = \zeta^{-1} \left[-\frac{1}{2} s \hat{\Gamma} h_\varepsilon^T h_\varepsilon + \ddot{\eta}_d - c\dot{e} - \delta \operatorname{sgn}(s) - ks \right] \quad (18)$$

式中: $\delta \geq 0, k \geq 0$ 。将式(18)代入(12)中:

$$\dot{s} = W^{*T} h_\varepsilon + \sigma_\varepsilon - \frac{1}{2} s \hat{\Gamma} h_\varepsilon^T h_\varepsilon - \delta \operatorname{sgn}(s) + d(t) - ks \quad (19)$$

定义闭环系统的李雅普诺夫函数^[14-15]为:

$$L = \frac{1}{2} s^T s + \frac{1}{2\gamma} \tilde{\Gamma}^T \tilde{\Gamma} \quad (20)$$

式中: $\gamma > 0$ 。

对式(20)求导可得:

$$\begin{aligned} \dot{L} &= s^T \dot{s} + \frac{1}{\gamma} \tilde{\Gamma} \dot{\tilde{\Gamma}} = s^T [W^{*T} h_\varepsilon + \sigma_\varepsilon - \frac{1}{2} s \hat{\Gamma} h_\varepsilon^T h_\varepsilon - \\ &\delta \operatorname{sgn}(s) + d(t) - ks] + \frac{1}{\gamma} \tilde{\Gamma} \dot{\tilde{\Gamma}} \leq \frac{1}{2} s^T s \hat{\Gamma} h_\varepsilon^T h_\varepsilon + \frac{1}{2} - \\ &\frac{1}{2} s^T s \hat{\Gamma} h_\varepsilon^T h_\varepsilon + s^T (\sigma_\varepsilon + d(t)) - \delta |s| + \frac{1}{\gamma} \tilde{\Gamma} \dot{\tilde{\Gamma}} - ks^T s = \\ &-\frac{1}{2} s^T s \tilde{\Gamma} h_\varepsilon^T h_\varepsilon + \frac{1}{2} + s^T (\sigma_\varepsilon + d(t)) - \delta |s| + \frac{1}{\gamma} \tilde{\Gamma} \dot{\tilde{\Gamma}} - ks^T s = \\ &\tilde{\Gamma} \left(-\frac{1}{2} s^T s h_\varepsilon^T h_\varepsilon + \frac{1}{\gamma} \dot{\tilde{\Gamma}} \right) + \frac{1}{2} + s^T (\sigma_\varepsilon + d(t)) - \delta |s| - \\ &ks^T s \leq \tilde{\Gamma} \left(-\frac{1}{2} s^T s h_\varepsilon^T h_\varepsilon + \frac{1}{\gamma} \dot{\tilde{\Gamma}} \right) + \frac{1}{2} - ks^T s \end{aligned} \quad (21)$$

设计逼近函数 ε 的神经网络的自适应率为:

$$\dot{\tilde{\Gamma}} = \frac{\gamma}{2} s^T s h_\varepsilon^T h_\varepsilon - \beta \gamma \tilde{\Gamma} \quad (22)$$

式中: $\beta > 0$ 。那么,

$$\begin{aligned} \dot{L} &\leq -\beta \tilde{\Gamma} \dot{\tilde{\Gamma}} + \frac{1}{2} - ks^T s \leq -\frac{\beta}{2} (\tilde{\Gamma}^2 - \Gamma^2) + \frac{1}{2} - \\ ks^T s &= -\frac{\beta}{2} \tilde{\Gamma}^2 - ks^T s + \left(\frac{\beta}{2} \Gamma^2 + \frac{1}{2} \right) \end{aligned} \quad (23)$$

令 $\beta = \frac{2k}{\gamma}$, 因此,

$$\begin{aligned} \dot{L} &\leq -\frac{k}{\gamma} \tilde{\Gamma}^2 - ks^T s + \left(\frac{\beta}{2} \Gamma^2 + \frac{1}{2} \right) = -2k \left(\frac{1}{2\gamma} \tilde{\Gamma}^2 + \right. \\ &\left. \frac{1}{2} s^T s \right) + \left(\frac{\beta}{2} \Gamma^2 + \frac{1}{2} \right) = -2kL + \frac{\beta}{2} \Gamma^2 + \frac{1}{2} \end{aligned} \quad (24)$$

解不等式(24)得:

$$L \leq \frac{\beta \Gamma^2 + 1}{4k} + (L(0) - \frac{\beta \Gamma^2 + 1}{4k})e^{-2kt} \quad (25)$$

即,

$$\lim_{t \rightarrow \infty} L = \frac{\beta \Gamma^2 + 1}{4k} = \frac{\frac{2k}{\gamma} \Gamma^2 + 1}{4k} = \frac{\Gamma^2}{2\gamma} + \frac{1}{4k} \quad (26)$$

由于 $\gamma > 0, k > 0$, 所以式(26)为正。将式(26)代入式(24)有,

$$\begin{aligned} \dot{L} &\leq -2kL + \frac{\beta}{2}\Gamma^2 + \frac{1}{2} = -2k\left(\frac{\Gamma^2}{2\gamma} + \frac{1}{4k}\right) + \frac{\beta}{2}\Gamma^2 + \\ &\frac{1}{2} = -\frac{k\Gamma^2}{\gamma} - \frac{1}{2} + \frac{k\Gamma^2}{\gamma} + \frac{1}{2} = 0 \end{aligned} \quad (27)$$

即式(27)满足 $\dot{L} \leq 0$ 。由于 $L \geq 0, \dot{L} \leq 0$, 闭环系统为渐近稳定。

通过上面的推导可知,基于双尾鳍水下机器鱼的动力学模型设计出了神经网络滑模控制器,利用RBF神经网络在线逼近动力学模型中的不确定项,实现控制律的实时补偿。RBF神经网络的自适应律由李雅普诺夫函数推导得出,保证了闭环系统的稳定性和神经网络的收敛性,为后面的仿真实验程序的编写打下基础。

4 仿真分析

4.1 参数设置

对于RBF神经网络滑模控制器,系统初始状态为 $\xi(0) = [0 \ 0 \ 0 \ 0]^T$,滑模控制切换函数的系数矩阵为 $c = [0.1 \ 0.01]^T$,切换函数增益 $\delta = [0.1 \ 0.05]^T$,根据神经网络所识别的对象,选择 η 和 $\dot{\eta}$ 作为输入。神经网络的结构为2-5-1,自适应律的参数选取为 $\gamma_1 = 0.01, \gamma_2 = 0.05$ 。对于每一个神经网络,其高斯函数的参数选取为


$$b_i = \begin{bmatrix} -0.5 & -0.25 & 0 & 0.25 & 0.5 \\ -0.5 & -0.25 & 0 & 0.25 & 0.5 \end{bmatrix}, \lambda_i = 5, (i = 1,$$

2,3,4),网络的初始权重为0。由于传统的PID控制不需要被控对象明确的动力学模型,因此利用设计成差动形式的两个PID控制器与RBF神经网络滑模控制进行对比,控制航向的参数为 $P_1 = 50, I_1 = 10, D_1 = 1$,控制直行的参数为 $P_2 = 20, I_2 = 10, D_2 = 0.5$ 。在仿真实验过程中,只改变赋给鱼体的期望值,保持其他参数不变。


4.2 仿真结果分析

图4(a)展示了期望速度分别为0.15 m/s、0.2 m/s、0.25 m/s时鱼体跟踪响应曲线,图4(b)为响应误差曲线。其中,外界干扰为 $d(t) = 0.05 \times t \times (\text{step}(10) - \text{step}(11))$ N, $\text{step}(10)$ 表示在10 s处产生幅值为1的阶跃信号,模型的不确定项 $\Delta U = 0.01 \sin(10\pi t)$ 。根据图4(a),RBF神经网络滑模控制器使鱼体速度响应上升时间比PID控制器的上升时间快约1 s,调节时间快约3 s。并且PID控制器使鱼体速度响应的超调量是RBF神经网络滑模控制器的

5倍。说明RBF神经网络滑模控制器可以使双尾鳍水下机器鱼更快速的跟踪期望速度。根据图4(b),鱼体在前10 s只受不确定性 ΔU 的影响,RBF神经网络滑模控制器使鱼体的速度波动明显比PID控制器控制鱼体的速度波动平稳。在10 s时鱼体受到外来干扰,RBF神经网络滑模控制器使鱼体的速度跟踪误差在 ± 0.01 m/s 的范围内,PID控制器使鱼体的速度误差在 ± 0.03 m/s 的范围内,并且RBF神经网络滑模控制器使鱼体的速度波动时间比PID控制器短约2 s。说明在遇到外界干扰和模型参数变化时,RBF神经网络滑模控制器可快速的调节鱼体速度稳定在期望值。



(a) 速度跟踪曲线



(b) 速度跟踪误差曲线

图4 速度跟踪实验结果

图5(a)展示了期望角度为 $0.2 \sin(0.5\pi t + 0.5\pi)$ rad 时鱼体跟踪响应曲线,图5(b)为角度响应误差曲线。其中,外界干扰信号为 $d(t) = 0.002(\text{step}(20) - \text{step}(21))$ N·m,模型的不确定项 $\Delta U = 0.001 \sin(10\pi t)$ 。根据图5(a),RBF神经网络滑模控制器和PID控制器使鱼体航向角度响应上升时间都约为1 s。说明两个控制器使鱼体连续角度跟踪响应的动态性能相近。根据图5(b),由于鱼体运动模型的参数不断变化,RBF神经网络滑模控制器使鱼体的跟踪误差趋近于0 rad,PID控制器使鱼体的响应稳态误差为0.02 rad。在20 s时鱼体受外界干扰影响,RBF神经网络滑模控制器使鱼体角度响应误差为0.02 rad,鱼体重新稳定跟踪时间为2 s,PID控制器使系统响应误差为0.04 rad,重新稳定时间为20 s。说明所设计的控制器比PID控制器能更好的应对鱼体受到持续干扰和水动力参数突变的情况。




图 5 角度跟踪实验结果

5 结 论

本文针对鳍驱动式水下机器人受水波干扰和存在模型参数不确定性导致控制性能变差的问题设计了一种 RBF 神经网络滑模控制器。仿真实验结果表明,所设计的 RBF 神经网络滑模控制器优于传统的 PID 控制器,在面对外界干扰和动力学模型参数变化的情况下,能有效控制双尾鳍水下机器人跟踪速度和航向角度,响应速度快,鲁棒性高,可使系统响应符合期望性能,为水下机器人运动控制研究提供了参考。

参考文献

- [1] KRUUSMAA M, GKLIWA R, TUHTAN J, et al. Salmon behavioural response to robots in an aquaculture sea cage[J]. Royal Society Open Science, 2020, 7(3), DOI:10.1098/rsos.191220.
- [2] PLAMONDON N, NAHON M. Adaptive controller for a biomimetic underwater vehicle[J]. Journal of Unmanned Vehicle Systems, 2013, 1(1):1-13.
- [3] REMMAS W, CHEMORI A, KRUUSMAA M. Diver tracking in open waters: A low cost approach based on visual and acoustic sensor fusion[J]. Journal of Field Robotics, 2020, 38(3): 494-508.
- [4] SALUMAE T, CHEMORI A, KRUUSMAA M. Motion control architecture of a 4-fin U-CAT AUV using DOF prioritization [C]. 2016 IEEE/RSJ International Conference on Intelligent Robots and

Systems, Daejeon Convention Center, Daejeon, Korea (South), 2016: 1321-1327.

- [5] LAKHEKAR G, WAGHMARE L, JADHAV P, et al. Robust diving motion control of an autonomous underwater vehicle using adaptive neuro-fuzzy sliding mode technique[J]. IEEE Access, 2020, 8, DOI:10.1109/ACCESS.2020.3001631.
- [6] 王亚锋,安坤,孟江. 基于 RBF 神经网络的迟滞非线性模型预测控制[J]. 电子测量技术, 2021, 379(23):42-47.
- [7] WANG J, LIU Y, CAO G, et al. Design of RBF Adaptive Sliding Mode Controller for A Supercavitating Vehicle[J]. IEEE Access, 2021, 9, DOI:10.1109/ACCESS.2021.3063192.
- [8] SUN Y, XU J, QIANG H, et al. Adaptive sliding mode control of maglev system based on RBF neural network minimum parameter learning method [J]. Measurement, 2019, 141: 217-226.
- [9] 李宏玉,丁善峰,余超,等. 基于滑模变结构的永磁同步电机控制研究[J]. 国外电子测量技术, 2019, 38(9): 112-116.
- [10] FOSSEN T I. Marine control systems-guidance, navigation, and control of ships, rigs and underwater vehicles[M]. Norway: Marine Cybernetics, 2002:340-350.
- [11] REMMAS W, CHEMORI A, KRUUSMAA M. Inverse-model intelligent control of fin-actuated underwater robots based on drag force propulsion[J]. Ocean Engineering, 2021, 239(1):1-11.
- [12] 刘金琨, RBF 神经网络自适应控制及 MATLAB 仿真[M]. 北京:清华大学出版社, 2018: 112-113.
- [13] WU X, ZHAO H, HUANG B, et al. Minimum-learning-parameter-based anti-unwinding attitude tracking control for spacecraft with unknown inertia parameters [J]. Acta Astronautica, 2021, 179: 498-508.
- [14] 马乐,刘跃峰,李志伟,等. 一种基于 Lyapunov 约束的学习控制方法及应用[J]. 仪器仪表学报, 2019, 40(9): 189-198.
- [15] 葛媛媛,张宏基. 基于自适应模糊滑模控制的机器人轨迹跟踪算法[J]. 电子测量与仪器学报, 2017, 31(5): 746-755.

作者简介

霍建霖,高级工程师,主要研究方向为自动检测技术和特种设备检测技术。

袁园(通信作者),硕士研究生,主要研究方向为水下机器人。

E-mail:104754190986@henu.edu.cn

张镭,教授,主要研究方向为测控技术。