

基于变结构径向基函数网络的船舶运动预测PID控制

尹建川, 东 昉, 李铁山, 胡江强

(大连海事大学 航海学院, 辽宁 大连 116026)

摘要: 针对船舶在海上运动的大时滞和动态时变等特点, 提出基于一种变结构径向基函数(RBF)神经网络的预测PID控制器. 通过建立反映系统动态变化的滑动数据窗口, 在线序贯学习窗口内的数据, 动态调整隐层节点与隐层至输出层的连接权值, 得到结构可自适应变化的RBF网络. 将该变结构RBF网络用于预测PID控制器中系统状态的在线多步预测, 通过得到的预测模型灵敏度信息在线调整PID控制器参数以控制系统的输出. 将该控制器用于船舶航向跟踪控制的仿真实验, 结果表明该控制器具有良好的适应性和鲁棒性.

关键词: 径向基函数神经网络; 变结构神经网络; 预测控制; 序贯学习

中图分类号: TP273 **文献标识码:** A

Ship motion predictive PID control based on variable structure radial basis function network

YIN Jian-chuan, DONG Fang, LI Tie-shan, HU Jiang-qiang

(College of Navigation, Dalian Maritime University, Dalian Liaoning 116026, China)

Abstract: To deal with the long time-delay and time-varying dynamics of the ship motion in sea, we present a predictive PID controller based on variable structure radial basis function (RBF) network. This network performs sequential learning through a sliding data window reflecting system dynamic changes, and adjusts online the hidden layer nodes and their weighting values in the connection to output layers. We thus obtain an adaptive variable structure RBF network. This variable structure RBF network is employed as a multi-step online predictor for a predictive PID controller. Parameters of the controller are online tuned based on the sensitivity information obtained from the variable RBF network predictor. The proposed predictive PID controller is applied to ship course tracking control. Simulation results demonstrate satisfactory adaptation and robustness of the controllers.

Key words: radial basis function neural networks; variable structure neural network; predictive control; sequential learning

1 引言(Instruction)

船舶在海上的运动呈现出强非线性、动态时变和有时滞等特性, 使用常规的PID控制器难以达到理想的控制效果. 而预测PID控制既有预测控制算法对时滞系统的良好控制效果^[1,2], 又有常规PID控制算法简单、易于实现的特点, 在工程实践中得到了成功的应用^[3]. 应用预测PID控制的关键是如何对系统状态进行精确和快速的辨识和预测. 神经网络的辨识和预测技术越来越多地被应用于滞后系统的控制^[4], 目前应用最多的是固定网络结构的静态网络. 静态网络在处理定常系统时有良好的表现, 而对时变动态系统进行辨识和预测时, 其固定的网络结构难以适应系统动态的变化, 不可避免地产生过拟合或欠拟合现象, 降低了网络的泛化能力, 所以需

要利用可变结构的神经网络进行时变系统的动态辨识与预测. 径向基函数(radial basis function, RBF)网络运算量小、拓扑结构简单且具有局部响应的特性, 可以方便地对其网络结构进行局部调整^[5]. 序贯学习算法即是根据RBF网络的上述特点而设计的变结构RBF网络构造算法. 目前常用的序贯学习算法有RAN^[6]、RANEKF^[7]和MRAN^[8]等. 以上算法的缺点是学习参数过多且所得网络隐节点较多, 不利于实际工程应用.

为了在线得到结构精简的变结构RBF神经网络, 本文提出一种新型的序贯算法——梯度正交模型选择(gradient orthogonal model selection, GOMS)算法. 该算法利用滑动数据窗口内实时更新的样本训练网络, 引入样本的梯度信息以反映系统动态随时间变

化的特性^[9], 利用较少的参数动态调整网络结构和连接权值. Mackey-Glass混沌序列在线预测实验验证了该序贯算法的有效性.

本文最后提出基于变结构RBF网络的预测PID控制器, 利用GOMS算法得到的变结构RBF网络对系统状态进行在线辨识和多步预测, 通过在线获得的网络灵敏度信息调整PID控制参数. 船舶航向跟踪控制仿真实验结果表明该控制器控制效果良好, 并具有较强的自适应性和鲁棒性.

2 梯度正交模型选择学习算法(Gradient orthogonal model selection algorithm)

2.1 滑动数据窗口(Sliding data window)

算法利用实时更新的滑动数据窗口(sliding data window, W_{SD})反映系统的实时动态. 该滑动窗口是一个固定宽度的先进先出样本数据序列. 每一步新的输入-输出数据进入数据窗口, 最早的一组数据则移出窗口. t 时刻的滑动数据窗口表示为

$$W_{SD} = [(x_{t-N+1}, y_{t-N+1}) \cdots (x_t, y_t)]. \quad (1)$$

其中: N 为滑动数据窗口的宽度, x 和 y 分别表示系统某时刻的输入和输出.

滑动窗口内的输入-输出数据用来反映系统的当前动态, 包括输入矩阵

$$X = [x_{t-N+1} \cdots x_t]$$

和对应的输出矩阵

$$Y = [y_{t-N+1} \cdots y_t].$$

为了有效地反映时变系统动态变化的趋势, 本算法利用原始数据的梯度信息训练网络^[9]. 将 t 时刻滑动窗口的输入及输出的一阶导数矩阵分别差分表示为:

$$X'_t = [x_{t-N+1} - x_{t-N} \cdots x_t - x_{t-1}], \quad (2)$$

$$Y'_t = [y_{t-N+1} - y_{t-N} \cdots y_t - y_{t-1}]^T. \quad (3)$$

利用上述一阶输入-输出梯度信息训练网络, 使网络输出 $\hat{Y}'_t = f(X'_t)$ 逼近 Y'_t , 得到一阶梯度输入-输出的神经网络映射 $f(\cdot)$. 为了使网络输出与原始数据一致, 该一阶梯度RBF网络最终输出表示为

$$\hat{Y}_t = F(X'_t) = \hat{Y}'_t + Y_{t-1} = f(X'_t) + Y_{t-1}. \quad (4)$$

利用同样的方法, 可以将一阶梯度RBF网络扩展为高阶梯度RBF网络. 如利用输入和输出的二阶信息进行网络训练并相应得到 $\hat{Y}''_t = f(X''_t)$ 后, 该二阶梯度RBF网络的最终输出表示为

$$\hat{Y}_t = F(X''_t) = f(X''_t) + 2Y_{t-1} - Y_{t-2}. \quad (5)$$

2.2 算法描述(Algorithm description)

结合序贯学习策略与正交最小二乘法^[10]中的子集选择方法, 本文提出基于滑动数据窗口的梯度正交模型选择(GOMS)学习算法. 算法学习滑动窗口内实时更新的数据, 每一步都对网络隐节点进行添加和修剪, 并调整网络权值.

算法开始时网络无隐节点. 每一步将最新样本输入的 ν 阶微分 $x^{(\nu)}$ 加入隐层作为新的隐节点, 与原有隐节点构成了候选隐节点集合 $\{c_1, \cdots, c_M\}$. ν 代表微分的阶数, M 为候选隐节点的数目.

计算各候选隐节点中心与滑动数据窗口输入 ν 阶微分的欧氏距离, 并由隐层径向基函数激活得到隐层响应矩阵 $\Phi \in \mathbb{R}^{N \times M}$.

本文采用常用的高斯函数作为径向基函数:

$$\phi_{j,k} = \exp\left(-\frac{\|x_j^{(\nu)} - c_k\|^2}{2\sigma^2}\right), \quad (6)$$

$$1 \leq j \leq N, 1 \leq k \leq M.$$

其中: c_k 表示第 k 个隐节点的中心, σ 表示宽度系数, $\|\cdot\|$ 表示欧氏距离.

由于在非正交空间内各隐节点对输出的贡献是相互影响的, 为了分别衡量单个隐节点对输出的贡献的大小, 利用Gram-Schmidt正交法则将各基向量 Φ 正交化: $\Phi = WA$. Φ 与各正交基向量所张成的空间 W 相同. $W = [w_1 \cdots w_M]$, 其正交列向量两两正交, 即

$$W^T W = \text{diag}\{w_1^T w_1, \cdots, w_M^T w_M\}.$$

计算每个隐节点中心向量对应的 w_k 的误差下降率(error reduction ratio, err)^[10]:

$$[\text{err}]_{ki} = \frac{(w_k^T y_i^{(\nu)})^2}{(w_k^T w_k)(y_i^{(\nu)T} y_i^{(\nu)})}. \quad (7)$$

根据向量空间理论, 在正交空间内 $\sum_{k=1}^M \cos^2 \theta_k = 1$, θ_k 为向量 w_k 与 y 的夹角. 但GOMS算法中隐层响应矩阵的维数为 $N \times M$, 而 N 与 M 通常不相等, 使 $\sum_{k=1}^M [\text{err}]_k \neq 1$, 所以无法仅根据各隐节点对应的err值判断其对输出的贡献. 本文将各隐节点对应的误差下降率进行标准化, 得到标准化误差下降率(normalized error reduction ratio, nerr)

$$[\text{nerr}]_k = \frac{[\text{err}]_k}{\sum_{k=1}^M [\text{err}]_k}. \quad (8)$$

由于 $\sum_{k=1}^M [\text{nerr}]_k = 1$, 使得可以利用nerr作为衡量指标对各隐节点的贡献进行直接衡量.

算法在每一步按照贡献大小由小到大顺序选择对输出贡献小的隐节点,并在所选择节点的nerr值之和大于设定的精度阈值 ρ 时,即在 $\sum_{k=k_1}^{k_{S+1}} [\text{nerr}]_k > \rho$ 时停止选择.得到对输出贡献较小的隐节点集合 $U_k = \{c_{k_1}, \dots, c_{k_S}\}$.如果某隐节点在连续 P 步都被选中,则将该节点从隐层中删除,即删除过去 P 步计算中得到集合 U 的交集

$$I = \{U_k \cap U_{k-1} \cap \dots \cap U_{k-P+1}\}. \quad (9)$$

在对网络隐节点进行添加和修剪调整后,通过线性最小二乘法更新隐层与输出层之间的连接权矩阵

$$\Theta = \Phi^+ Y^{(\nu)} = (\Phi^T \Phi)^{-1} \Phi^T Y^{(\nu)}. \quad (10)$$

由于GOMS算法通过滑动窗口进行滚动学习,所以只需学习滑动窗口内少量样本数据即可对RBF网络节点的数目和中心位置进行调整,隐层到输出层的连接权值也利用线性优化方法进行更新,提高了其学习速度.而且该算法只有3个调整参数且易于调整,方便了其在实际工程中的应用.

2.3 混沌时间序列在线预测实验(Experiment of chaotic time-series on-line prediction)

Mackey-Glass混沌时间序列预测是检验神经网络动态辨识能力与预测能力的标杆问题^[11],所以本节中将GOMS算法应用于该混沌序列的在线预测以检验该算法的辨识和预测性能.

Mackey-Glass时间序列可用时滞常微分方程表示如下:

$$\frac{ds(t)}{dt} = -bs(t) + a \frac{s(t-\tau)}{1 + s(t-\tau)^{10}}. \quad (11)$$

实验参数设置为: $a = 0.2, b = 0.1, \tau = 17$. 各时间序列值在间隔 $[t, t + \Delta t]$ 内利用梯形法则进行积分得到. 设 $\Delta t = 1$, 且 $0 \leq t \leq \tau$ 时 $s(t-\tau) = 0.3$.

在网络学习阶段, n 时刻的 ν 阶梯度训练样本的输入和输出分别设置为:

$$\begin{aligned} x_n^{(\nu)} &= [s_{n-\mu}^{(\nu)} \ s_{n-\mu-6}^{(\nu)} \ s_{n-\mu-12}^{(\nu)} \ s_{n-\mu-18}^{(\nu)}]^T, \\ y_n^{(\nu)} &= s_n^{(\nu)}. \end{aligned}$$

训练结束得到的神经网络的输出为 $z_n = F(x_n^{(\nu)})$, 训练误差为 $\epsilon_n = s_n - z_n$.

本实验是为了验证由GOMS算法得到的RBF神经网络的在线预测性能,所以在每一步学习以前的数据样本后,根据未学习样本的 ν 阶导数

$$x_{n+1}^{(\nu)} = [s_{n-\mu+1}^{(\nu)} \ s_{n-\mu-5}^{(\nu)} \ s_{n-\mu-11}^{(\nu)} \ s_{n-\mu-17}^{(\nu)}]^T \quad (12)$$

进行 μ 步预测,即预测 $z_{n+1} = F(x_{n+1}^{(\nu)})$ 的值,预测误差为

$$\epsilon_{n+1} = s_{n+1} - z_{n+1}. \quad (13)$$

设 $\mu = 50$,由式(11)积分产生5000组实验数据. RANEKF算法^[7]和MRAN^[8]算法是两种常用的序贯学习算法,所以利用这两种算法与GOMS算法进行对比实验. GOMS算法参数设置为: $N = 10, \rho = 0.0002, P = 3$. MRAN算法参数设置为^[11]: $\epsilon_{\max} = 0.7, \epsilon_{\min} = 0.07, \gamma = 0.999, e_{\min} = 0.095, e'_{\min} = 0.078, \kappa = 0.87, P_0 = R_n = 1.0, Q = 0.0002, \eta = 0.02, \delta = 0.01, M = 90$. RANEKF算法的参数设置为: $\epsilon_{\max} = 0.7, \epsilon_{\min} = 0.07, \gamma = 0.999, e_{\min} = 0.095, \kappa = 0.87, P_0 = R_n = 1.0, Q = 0.0002, \eta = 0.02$. 对比的性能指标为均方根误差(root-mean-square-error, RMSE)、平均绝对值误差(mean-absolute-error, MAE)、平均隐节点数目(average-hidden-units-number, AHUN)和运算时间. 该预测实验结果列于表1.

表1 Mackey-Glass时间序列预测实验结果对比
Table 1 Experiment results of M-G series prediction

算法	实验结果			
	RMSE	MAE	AHUN	运算时间/s
RANEKF	0.0676	0.0423	17.2024	123.127
MRAN	0.0700	0.0448	14.0426	51.214
GOMS($\nu=0$)	0.0100	0.0053	5.2434	8.1880
GOMS($\nu=1$)	3.9466e-5	3.2164e-6	7.9720	9.1250
GOMS($\nu=2$)	2.1151e-5	4.5246e-7	14.4030	11.4060
GOMS($\nu=3$)	0.1957	0.0341	15.6410	28.6470

表1显示GOMS算法具有较高的预测精度,尤其在一阶和二阶梯度情况下预测精度远高于另外两种算法.从运算时间看出GOMS算法具有更快的运算速度.在网络规模方面, GOMS算法构造的RBF网络在一阶和二阶梯度情况下的平均隐节点数目也少于其他两种算法.同时, GOMS算法只需要3个学习参数,远少于另外两种算法.以上比较均说明GOMS是一种有效的在线构造变结构RBF网络的学习算法.

3 基于变结构RBF网络的预测PID控制(Predictive PID control based on variable structure RBF network)

基于变结构RBF神经网络的预测PID控制方案可分为2部分:第1部分是预测器,利用GOMS算法在线构建的可变结构RBF神经网络进行直接多步预测,将预测值与期望值的偏差形成反馈.第2部分是基于变结构RBF网络的自适应PID控制器,通过神经网络预测模型得到的系统灵敏度信息进行指标函数的最小化计算,对PID参数进行在线调整后计算出控制器的输入,消除时滞对控制系统输出响应的影响.

该RBF网络预测PID控制方案如图1所示。




图 1 基于RBF神经网络的预测PID控制器

Fig. 1 Predictive PID controller based on RBF Network

图1中, CFM为指标函数最小化计算, PID为PID控制器, PLANT为被控机构, RBFN MSP为RBF网络多步预测器. $u(k)$, $y(k)$, $y_m(k)$ 分别为第 k 步的系统控制输入、被控对象输出和神经网络输出; $y_t(k+j)$, $y_m(k+j)$ 和 $e(k+j)$ 分别为第 $k+j$ 步系统期望输出、网络预测输出以及期望输出与预测输出之间的差值. Jacobian为预测模型的雅可比矩阵.

大滞后系统的离散模型可以表示为

$$\begin{aligned} y(k) &= f(y(k-1), \dots, y(k-n)), \\ u(k-d), \dots, u(k-d-m)), \end{aligned} \quad (14)$$

式中: $f(\cdot)$ 为非线性映射, m 和 n 分别为输入和输出的阶次, d 为系统时延.

对于大滞后系统, 由于当前施加的控制作用需要经过一段时间才能在输出中反映出来, 因此需要选择一个合适的当前控制作用, 使系统未来的输出结果满足期望要求. 可见, 克服大时滞的影响依赖于对系统输出的预测. 考虑到递推多步预测会引起误差累积, 本文采用直接多步预测的方法建立相关的模型进行学习和预测. 本文将GOMS算法得到的RBF网络用作单步及多步直接预测模型

$$\begin{aligned} y_m(k+j) &= f_m(y(k), \dots, y(k-n+1), \\ &u(k-d+1), \dots, u(k-d-m+1)), \end{aligned} \quad (15)$$

其中 $j(j=1, 2, \dots, L)$ 为预测步数, L 为控制时域长度. 上述预测过程的模型是通过GOMS算法在线构建的. 由于不存在误差的积累, 所以不需要对预测输出进行在线校正. 这种序贯学习方式反映系统动态的实时变化, 适合系统状态的短期预测.

常规的PID控制器的增量式为

$$\begin{aligned} u(k) &= u(k-1) + K_p(e(k) - e(k-1)) + K_i e(k) \\ &+ K_d(e(k) - 2e(k-1) + e(k-2)), \end{aligned} \quad (16)$$

其中: K_p 为比例系数, K_i 为积分比例系数, K_d 为微分比例系数, $e(k)$ 为反馈偏差.

为了使常规PID控制器参数能够根据系统动态的变化进行自适应调整, 采用神经网络在线整

定PID控制器的参数 K_p , K_i 和 K_d .

RBF网络的性能指标函数

$$J(k) = \frac{1}{2}(y_t(k+j) - y(k+j))^2. \quad (17)$$

其中 K_p , K_i 和 K_d 均采用梯度下降法进行调整. 以下以 K_p 为例说明控制参数的调整过程:

$$K_p(k) = K_p(k-1) + \eta \Delta K_p. \quad (18)$$

其中: η 为学习速率, ΔK_p 为 K_p 的梯度下降率.

$$\begin{aligned} \Delta K_p &= -\frac{\partial J}{\partial K_p(k-1)} = \\ &= -\frac{\partial J}{\partial y(k+j)} \frac{\partial y(k+j)}{\partial u(k-1)} \frac{\partial u(k-1)}{\partial K_p(k-1)} = \\ &= (y_t(k+j) - y(k+j)) \frac{\partial y(k+j)}{\partial u(k-1)} \cdot \\ &= (e(k-1) - e(k-2)). \end{aligned} \quad (19)$$

由于在 k 时刻 $y(k+j)$ 是未知的, 所以利用变结构RBF网络的预测输出 $y_m(k+j)$ 替代 $y(k+j)$ 以得到系统灵敏度信息

$$\frac{\partial y_m(k+j)}{\partial u(k-1)} \approx \frac{\partial y(k+j)}{\partial u(k-1)}. \quad (20)$$

采用上述GOMS算法得到的变结构RBF网络构造多步预测模型, 在线调整网络的输出 $y_m(k+j)$, 从而获得准确的灵敏度信息. 这样不必考虑系统本身精确的数学模型, 便可得到良好的控制效果, 同时也简化了控制器的设计.

4 船舶航向跟踪预测PID控制仿真 (Simulation of ship course tracking predictive PID control)

基于以上变结构RBF网络预测PID控制方案, 进行船舶航向跟踪控制仿真实验.

本仿真实验利用MATLAB编程, 船舶的航向和舵角数据均通过船舶运动数学模型在线生成. 船舶模型采用Abkowitz模型, 水动力参数采用“Mariner”型船舶的数据^[12]. 利用式(15)作为船舶航向在线预测模型, 输入为舵角, 输出为航向, 系统的输入和输出阶次分别取 $m=2$, $n=3$, 时滞 $d=2$, 控制时域长度 $L=2$, 控制的采样时间1 s, 仿真时间1600 s. 船舶的初始状态设置为: 初始航向 0° , 船速15 kn, 舵角限制 20° , 转舵速度限制 $2.5^\circ/\text{s}$. 设定目标航向 Ψ_r 在 $[0 \text{ s}, 400 \text{ s}]$ 内为 -10° , $[401 \text{ s}, 800 \text{ s}]$ 内为 10° , $[801 \text{ s}, 1200 \text{ s}]$ 内为 -20° , $[1201 \text{ s}, 1600 \text{ s}]$ 内为 20° . 利用GOMS在线构建变结构RBF神经网络的参数设置为: 滑动窗口宽度 $N=10$, 精度阈值 $\rho=0.05$,

连续计算步数 $P=3$, 梯度阶数 $\nu=1$.

设置风浪干扰以使仿真更接近船舶在海上运动的实际情况. 设风级为蒲氏4级, 海浪为3级, 风向在 $\pm 90^\circ$ 范围内以30 s为周期随机变化. 传统PID舵仍是目前应用最广泛的船舶自动舵, 所以利用常规PID控制方法在相同的条件下进行对比实验, 参数整定为: $K_p=8$, $K_i=0$, $K_d=80$. RBF网络预测PID控制器(实线)与传统PID控制器(点划线)的航向和舵角变化曲线分别如图2, 图3所示.




图2 航向跟踪效果比较

Fig. 2 Comparison results of course tracking performance




图3 舵角变化情况比较

Fig. 3 Comparison results of rudder angle changes

通过图2和图3看出, 两种控制方法都能使船舶准确跟踪设定的航向. 但在RBF网络预测PID控制中, 由于对未来船舶航向进行预测且控制器根据预测结果进行了预先调整, 所以航向跟踪的超调较小, 同时舵角变化曲线较为平缓, 操舵幅度较小.

5 结论(Conclusion)

针对船舶运动大时滞和动态时变等特点, 通过滑动窗口学习在线得到变结构RBF网络作为状态预测器, 并以预测模型得到的灵敏度信息对PID控制参数进行在线调整, 构造出基于RBF网络的预测PID控制器. 船舶航向跟踪控制仿真实验验证了该控制方案具有较强的自适应性和鲁棒性, 是一种有效的船舶运动控制方案.

参考文献(References):

- [1] 席裕庚. 预测控制[M]. 北京:国防工业出版社, 1993. (XI Yugeng. *Predictive Control*[M]. Beijing: National Defense Industry Press, 1993.)
- [2] 穆朝絮, 张瑞民, 孙长银. 基于粒子群优化的非线性系统最小二乘支持向量机预测控制方法[J]. 控制理论与应用, 2010, 27(2): 164–168. (MU Chaoxu, ZHANG Ruimin, SUN Changyin. LS-SVM predictive control based on PSO for nonlinear systems[J]. *Control Theory & Applications*, 2010, 27(2): 164–168.)
- [3] MAN G N. Auto-tuned PID controller using a model predictive control method for the steam generator water level[J]. *IEEE Transactions on Nuclear Science*, 2001, 48(5): 1664–1671.
- [4] 戴文战, 娄海川, 杨爱萍. 非线性系统神经网络预测控制研究进展[J]. 控制理论与应用, 2009, 26(5): 521–530. (DAI Wenzhan, LOU Haichuan, YANG Aiping. Overview of neural network predictive control in nonlinear system[J]. *Control Theory & Applications*, 2009, 26(5): 521–530.)
- [5] 张冬青, 宁宣熙, 刘雪妮. 基于RBF神经网络的非线性时间序列在线预测[J]. 控制理论与应用, 2009, 26(2): 151–155. (ZHANG Dongqing, NING Xuexi, LIU Xueni. On-line prediction of nonlinear time series using RBF neural networks[J]. *Control Theory & Applications*, 2009, 26(2): 151–155.)
- [6] PLATT J. A resource allocating network for function interpolation[J]. *Neural Computation*, 1991, 3(2): 213–225.
- [7] KADIRKAMANATHAN V, NIRANJAN M. A function estimation approach to sequential learning with neural network[J]. *Neural Computation*, 1993, 5(6): 954–975.
- [8] VIGNESHWARAN S, SUNDARARAJAN N, SARATCHANDRAN P. Direction of arrival (DoA) estimation under array sensor failures using a minimal resource allocation neural network[J]. *IEEE Transactions on Antennas and Propagation*, 2007, 55(2): 334–343.
- [9] CHNG E S, CHEN S, MULGREW B. Gradient radial basis function networks for nonlinear and nonstationary time series prediction[J]. *IEEE Transactions on Neural Networks*, 1996, 7(1): 190–194.
- [10] CHEN S, COWAN C F N, GRANT P M. Orthogonal least squares learning algorithm for radial basis function networks[J]. *IEEE Transactions on Neural Networks*, 1991, 2(2): 302–309.
- [11] LU Y W, SUNDARARAJAN N, SARATCHANDRAN P. A sequential learning scheme for function approximation by using minimal radial basis function neural networks[J]. *Neural Computation*, 1997, 9(2): 461–478.
- [12] CHISLETT M S, STROM J T. *Planar motion mechanism tests and full-scale steering and maneuvering predictions for a mariner class vessel, report no. Hy-6, 1965*[R]. Denmark: Hydro and Aerodynamics Laboratory.

作者简介:

尹建川 (1974—), 男, 博士, 主要研究方向为控制理论与智能计算, E-mail: yinjianchuan@gmail.com;

东 昉 (1944—), 男, 教授, 博士生导师, 主要研究方向为控制理论与交通信息工程, E-mail: dfhxy@sohu.com;

李铁山 (1968—), 男, 副教授, 博士, 主要研究方向为控制理论与控制技术, E-mail: tieshanli@tom.com;

胡江强 (1970—), 男, 副教授, 博士, 主要研究方向为控制技术与智能计算, E-mail: hujiangqiang@126.com.