

小波阈值神经网络在信号去噪及预测中的应用

岑翼刚¹, 尉宇², 孙德宝³

(1. 北京交通大学 信息科学研究所, 北京 100044; 2. 武汉科技大学 信息工程与科技学院, 湖北 武汉 430081;

3. 华中科技大学 控制科学与工程系, 湖北 武汉 430074)

摘要: 提出了一种小波阈值神经网络模型(wavelet threshold neural network, WTNN), 对合作式接收到的雷达信号进行去噪和预测. 这种网络模型把小波最优阈值去噪器加到神经网络中, 对带噪信号具有小波最优阈值去噪和预测的功能. 对小波系数作单层重构, 可简化训练算法, 使编程得到精简. 其次, 通过对训练算法进行分析, 得出了最优阈值及权值的调整公式. 最后通过对线性调频信号去噪及前向一步预测的实验结果可以看出, 当网络输入分别为带有高斯白噪声、高斯带限噪声、瑞利噪声的线性调频信号时WTNN得到的结果均优于利用Donoho阈值进行去噪后再预测的结果.

关键词: 最优阈值; 神经网络; 预测; 信号去噪

中图分类号: TP273 **文献标识码:** A

The application of wavelet threshold neural network in the de-noising and prediction

CEN Yi-gang¹, WEI Yu², SUN De-bao³

(1. Institute of Information Science, Beijing Jiaotong University, Beijing 100044, China;

2. School of Information Engineering & Technology, Wuhan University of Science & Technology, Wuhan Hubei 430081, China;

3. Department of Control Science & Engineering, Huazhong University of Science and Technology, Wuhan Hubei 430074, China)

Abstract: A wavelet threshold neural network (WTNN) model is proposed for denoising and prediction of cooperatively received radar signals. This WTNN incorporates a wavelet denoising layer with optimal wavelet thresholds into the neural network, for signal denoising and predicting. The training algorithm is simplified by the single-layer reconstruction of wavelet coefficients, leading to a compact programming. By analyzing the training algorithm, we derive the tuning formulas for searching optimal thresholds and network weights. The results of denoising and one-step ahead prediction for a linear frequency modulation signal with white Gauss noise, Gauss band-limited noise or Rayleigh noise show that the WTNN performs much better than the method of Donoho-threshold for denoising and prediction.

Key words: optimal threshold; neural network; prediction; signal de-noising

1 引言(Introduction)

现实世界中噪声不可避免, 信号去噪是目前的一个研究热点. 去噪先要进行系统建模, 这能极大提升去噪效果^[1]. Donoho提出了非线性小波阈值去噪^[2,3], 得到广泛应用^[4,5]. 目前, 小波阈值去噪多针对高斯白噪声, 对有色噪声, Donoho阈值不一定能得到较好去噪效果. 阈值去噪包括硬阈值与软阈值, 其中软阈值方法为

$$\tilde{d}_{j,k} = T(d_{j,k}, \tau_j), j=1, \dots, J, k=1, \dots, n_j, \quad (1)$$

此处, 阈值函数 T 为

$$T(d_{j,k}, \tau) = \begin{cases} d_{j,k} - \text{sgn}(d_{j,k})\tau_j, & |d_{j,k}| > \tau_j, \\ 0, & |d_{j,k}| \leq \tau_j, \end{cases} \quad (2)$$

τ_j 为第 j 层的阈值, $d_{j,k}$ 为第 j 层细节系数, $\tilde{d}_{j,k}$ 为阈值处理后第 j 层细节系数.

经典Donoho普适阈值为 $\tau_j = \hat{\sigma}_j \sqrt{2 \ln N}$, 但该阈值只是噪声的一个估计. 受背景噪声影响较大, 因此应寻找获得最优的阈值的方法. 本文提出一种新的神经网络: “小波阈值神经网络(WTNN)”, 该网络集成了小波阈值去噪, 使去噪与信号预测使用同一误差标准来提高预测精度, 可以在信号去噪、前向预测、带噪声的系统辨识中取得较好的效果.

2 带阈值去噪层的神经网络(Neural network with threshold de-noising layer)

WTNN是一种集去噪与预测为一体的神经网络, 其思想是在传统神经网络的隐含层之前设一阈值去

噪层,使用同一代价函数,通过梯度下降法来确定网络权值及最优阈值. 设 $o_k^q(m)$ 为第 q 层第 k 个神经元对应第 m 个输入输出对的输出. 则

$$o_k^Q(m) = f_k(\text{net}_k^Q(m)), \quad (3)$$

其中: Q 表示从隐含层开始,包含输出层(不包括输入层)的总层数; $\text{net}_k^Q(m)$ 为第 Q 层第 k 个神经元对应第 m 个输入输出对的输入:

$$\text{net}_k^Q(m) = \sum_{i=1}^{S_{Q-1}} \omega_{ih}^Q o_i^{Q-1}(m), \quad (4)$$

ω_{ih}^q 为第 q 层第 h 个神经元与第 $q-1$ 层第 i 个神经元之间的连接权值. 小波变换可表示成信号与分解或重构矩阵的乘积和,即

$$Wf_k(m) = \sum_{i=1}^{N_0} D_{k,i} p_i(m), k = 1, \dots, N_D, \quad (5)$$

式中 N_D 为分解矩阵行数. $Wf_k(m)$ 为各层高频系数与第 J 层逼近系数组成的向量,过阈处理后得

$$\tilde{W}f_k(m) = T(Wf_k(m), \tau_j), \quad (6)$$

去噪后的重构公式为

$$\tilde{p}_i(m) = \sum_{k=1}^{N_D} R_{i,k} \tilde{W}f_k(m), i = 1, \dots, N_0. \quad (7)$$

观察上述几个公式发现,式(5)(6)的形式分别与(4)(3)相似,而式(7)与(4)也很相似,因此可以把小波阈值去噪作为神经网络的一个隐含层,该层包含 N_D 个神经元,激励函数为阈值函数,如图1.




图1 集成了阈值去噪层的神经网络

Fig. 1 NN that integrates the threshold de-noising layer

图中 D 和 R 为小波分解和重构矩阵, 设对原带噪信号 $\{x_i\}_{i=1}^N$ 分解 J 层, 第 j 层系数个数为 c_j . 输入输出对为 $\{(p(m), y_m)\}_{m=1}^M$, M 为 $\{x_i\}_{i=1}^N$ 的分段数目, 每段长度为 N_0 , $p_i(m) = \{x_{i+m-1}\}_{i=1}^{N_0}$, $y_m = x_{m+N_0}$. $\{d_{j,k}(m)\}_{k=1}^{c_j}$ 与 $\{C_{J,k}(m)\}_{k=1}^{C_J}$ 为第 m 组输入输出对的第 j 层细节系数与第 J 层逼近系数. $\tilde{d}_{j,k}(m)$ 、 $\tilde{C}_{J,k}(m)$ 分别为 $d_{j,k}(m)$ 和 $C_{J,k}(m)$ 经过阈处理后的系数. $\{\tilde{p}_i(m)\}_{i=1}^{N_0}$ 为小波重构输出. 隐含层共有 L 个神经元, 对应权值为 w_{ih} . 整个网络输出为对应于第 m 组输入 $p(m)$ 的预测结果 $\tilde{y}_m$.

由上述看到, 该网络融去噪与预测为一体, 对于经典神经网络能够应用的场合均能应用, 并且在输入信号带有噪声时能得到较好的预测结果.

3 网络训练算法(Network training algorithm)

首先讨论均方误差(MSE)最小意义下最优阈值去噪的方法. 设带噪信号为:

$$x_k = y_k + \xi_k, k = 1, \dots, n, \quad (8)$$

其中 $\xi_k \sim N(0, \sigma^2)$. 由图1知预测均方误差为

$$E = \frac{1}{2} \sum_{m=1}^M (y_m - \tilde{y}_m)^2. \quad (9)$$

梯度下降法中权值的选择没有限制, 但小波阈值 τ_j 的取值范围为 $[d_{j,\min}, d_{j,\max}]$, 其中 $d_{j,\min} = \min\{|d_{j,k}|\}$, $d_{j,\max} = \max\{|d_{j,k}|\}$. 因此应将无穷区间映射到 $[d_{j,\min}, d_{j,\max}]$, 如下:

$$\tau_j = d_{j,\max} / (1 + e^{-\tilde{\tau}_j}), \tilde{\tau}_j \in (-\infty, +\infty), \quad (10)$$

从而通过调整 $\tilde{\tau}_j$ 达到对 τ_j 的调整. $\tilde{\tau}_j$ 的调整量为

$$\Delta \tilde{\tau}_j = -\eta \frac{\partial E}{\partial \tilde{\tau}_j} = -\eta \frac{\partial E}{\partial \tau_j} \cdot \frac{\partial \tau_j}{\partial \tilde{\tau}_j}, \quad (11)$$

其中 η 为学习速率. 而由式(10)和图1有

$$\frac{\partial \tau_j}{\partial \tilde{\tau}_j} = -\tau_j (\tau_j / d_{j,\max} - 1), \quad (12)$$

$$\frac{\partial E}{\partial \tau_j} = \frac{\partial E}{\partial \tilde{p}_i(m)} \cdot \frac{\partial \tilde{p}_i(m)}{\partial \tau_j}, \quad (13)$$

由 $\tilde{y}_m = f[\sum_{i=1}^{N_0} w_{ij} \cdot \tilde{p}_i(m)]$, 并利用式(7)可得

$$\frac{\partial E}{\partial \tilde{p}_i(m)} = \sum_{i=1}^{N_0} \sum_{m=1}^M (\tilde{y}_m - y_m) w_{ih} f'[\sum_{i=1}^{N_0} w_{ih} \cdot \tilde{p}_i(m)], \quad (14)$$

$$\frac{\partial \tilde{p}_i(m)}{\partial \tau_j} = \frac{\partial \tilde{p}_i(m)}{\partial \tilde{d}_j} \cdot \frac{\partial \tilde{d}_j}{\partial \tau_j} = \sum_{k=1}^{c_j} R_{i,k} \frac{\partial T(d_{j,k}, \tau_j)}{\partial \tau_j}. \quad (15)$$

由式(2)知若系数的模比阈值小, 则 $\frac{\partial T(d_{j,k}, \tau_j)}{\partial \tau_j} = 0$, 这会使网络学习停止^[6]. 考虑下述改进阈值 $T(d, \tau) = d + \frac{1}{2}(\sqrt{(d - \tau)^2 + s} - \sqrt{(d + \tau)^2 + s})$, (16)

其中 s 为经验常数, $s = 0$ 时式(16)与式(2)相同. 则:

$$\frac{\partial T(d_{j,k}, \tau_j)}{\partial \tau_j} = -\frac{1}{2} \left(\frac{d_{j,k} - \tau_j}{\sqrt{(d_{j,k} - \tau_j)^2 + s}} + \frac{d_{j,k} + \tau_j}{\sqrt{(d_{j,k} + \tau_j)^2 + s}} \right). \quad (17)$$

综合(17)及式(11)~(15), 可得到 $\tilde{\tau}_j$ 的调整量 $\Delta \tilde{\tau}_j$:

$$\begin{aligned} \Delta \tilde{\tau}_j = & \frac{\eta}{2} \sum_{k=1}^{c_j} \sum_{i=1}^{N_0} \sum_{m=1}^M R_{i,k} \cdot (y_m - \tilde{y}_m) \cdot \\ & w_{ir} \cdot f' \cdot \tau_j \left(\frac{\tau_j}{d_{j,\max}} - 1 \right) \cdot \\ & \left(\frac{d_{j,k} - \tau_j}{\sqrt{(d_{j,k} - \tau_j)^2 + s}} + \frac{d_{j,k} + \tau_j}{\sqrt{(d_{j,k} + \tau_j)^2 + s}} \right). \end{aligned} \quad (18)$$

从而得到 τ_j 的调整公式

$$\tau_j = d_{j,\max} / (1 + e^{-(\tilde{\tau}_j + \Delta \tilde{\tau}_j)}), \quad (19)$$

由(18)知阈值调整涉及重构矩阵 $R_{i,k}$, 这增加了仿真复杂度, 因此将带噪信号的各层分解系数单层重构后再搜索最优阈值. 小波重构公式为

$$C_{j,k} = 2^{-1/2} (\sum_k C_{j+1,k} h_{n-2k} + \sum_k d_{j+1,k} g_{n-2k}). \quad (20)$$

令 $\{d_{i,k} = 0 | i < j\}$ 及 $C_{j,k} = 0$, 即将除第 j 层细节系数外的系数均置为 0, 重构后得第 j 层细节系数的单层重构信号 d_j^r , 类似可得单层重构逼近系数 C_j^r . 单层重构信号反映了第 j 层小波系数对重构信号的独立贡献, 对其过阈处理后得到重构去噪信号:

$$\tilde{x} = \sum_{j=1}^J d_j^r + C_j^r. \quad (21)$$

此时阈值 τ_j 是针对单层重构信号而言的, 仿照上述最优阈值选择方法, 只需将式(15)修改为

$$\frac{\partial \tilde{x}}{\partial \tau_j} = \sum_{k=1}^{c_j} \frac{\partial T(d_{j,k}, \tau_j)}{\partial \tau_j}, \quad (22)$$

因此得到新的阈值调整公式为

$$\begin{aligned} \Delta \tilde{\tau}_j = & \frac{\eta}{2} \sum_{k=1}^{c_j} \sum_{i=1}^{N_0} \sum_{m=1}^M (y_m - \tilde{y}_m) \cdot w_{ir} \cdot f' \cdot \\ & \tau_j \left(\frac{\tau_j}{d_{j,\max}} - 1 \right) \cdot \left(\frac{d_{j,k} - \tau_j}{\sqrt{(d_{j,k} - \tau_j)^2 + s}} + \right. \\ & \left. \frac{d_{j,k} + \tau_j}{\sqrt{(d_{j,k} + \tau_j)^2 + s}} \right). \end{aligned} \quad (23)$$

此处自然想到一个问题: 对未单层重构的系数使用阈值和单层重构后再使用阈值, 这两种方法的去噪效果是否一样? 对此有:

定理 1 设细节系数先过阈再重构及先单层重构再过阈处理得到的信号分别为 $\{\hat{x}_k^o\}$ 与 $\{\hat{x}_k^{sr}\}$, 对应的第 j 层细节系数阈值分别为 τ_j 与 τ_j' , 纯净信号为 $\{y_k\}$. 令 $E_I = \frac{1}{2} \sum_k (\hat{x}_k^o - y_k)^2$; $E_{II} = \frac{1}{2} \sum_k (\hat{x}_k^{sr} - y_k)^2$. 那么若存在 τ_j 使 E_I 达到极小, 则也使 E_{II} 达到极小.

证 先考虑单层分解重构. 设对应 E_I 和 E_{II} 的阈值分别为 $\tau_1 = \sigma_1 \sqrt{2 \ln N}$ 和 $\tau_1' = \tilde{\sigma}_1 \sqrt{2 \ln N}$, σ_1 和 $\tilde{\sigma}_1$ 分别为小波系数单层重构前后的噪声标准差, 噪声 $\{\xi_i\} \sim N(0, \sigma^2)$, 其一层小波分解高频系数为 $\{\xi_{d,1m}\}$. 设 $\xi_{d,1n}^{sr} = 2^{-\frac{1}{2}} \sum_k \xi_{d,1k} g_{n-2k}$ 为 $\{\xi_{d,1m}\}$ 的单层重构系数, 则 $\tilde{\sigma}_1^2 = 2^{-1} \sum_k g_{n-2k}^2 \sigma_1^2$, 从而有 $\tau_1' = G \tau_1$, 其中 $G = \sqrt{2^{-1} \sum_k g_{n-2k}^2} = \text{const.}$ 另外:

$$d_n^{sr} = 2^{-\frac{1}{2}} \sum_k d_{1,k} g_{n-2k}, \quad (24)$$

$$C_n^{sr} = 2^{-\frac{1}{2}} \sum_k C_{1,k} h_{n-2k}, \quad (25)$$

则有

$$E_{II} = \frac{1}{2} \sum_n [(C_n^{sr} - y_n) + T(d_n^{sr}, \tau_1')^2], \quad (26)$$

$$E_I = \frac{1}{2} \sum_n [(C_n^{sr} - y_n) + 2^{-\frac{1}{2}} \sum_k T(d_{1,k}, \tau_1) g_{n-2k}]^2, \quad (27)$$

因此只需考虑(27)中第2项 $2^{-\frac{1}{2}} \sum_k T(d_{1,k}, \tau_1) g_{n-2k}$,

将式(16)带入, 并令 $P = 2^{-\frac{1}{2}} \sum_k g_{n-2k}$, 经整理得

$$d_n^{sr} + \frac{1}{2} \{ \sqrt{(d_n^{sr} - \tau_1'')^2 + s'} - \sqrt{(d_n^{sr} + \tau_1'')^2 + s'} \}, \quad (28)$$

其中 $\tau_1'' = P \tau_1 = \frac{P}{G} \tau_1'$, $s' = P^2 s$.

而式(26)中 $T(d_n^{sr}, \tau_1')$ 为

$$d_n^{sr} + \frac{1}{2} [\sqrt{(d_n^{sr} - \tau_1')^2 + s} - \sqrt{(d_n^{sr} + \tau_1')^2 + s}]. \quad (29)$$

式(28)与(29)的形式一样, 只差一个常系数 $\frac{P}{G}$. 因此若存在 τ_1 使得式(28)达到极小, 则式(29)也可以达到极小, 即 E_I 和 E_{II} 达到极小. 所以, 先过阈处理

再重构和先单层重构再过阈处理这两种方法对于最优阈值的选择是无影响的. 同理对多层分解, 上述结论也成立. 证毕.

根据定理1将图1改为图2. 图2在搜索算法中避免了重构矩阵 R , 减少了计算量, 方便编程实现.




图2 改进的集成了阈值去噪单元的神经网络

Fig. 2 Advanced NN that integrates the threshold de-noising layer

4 仿真试验结果(Simulation results)

将WTNN用于信号去噪及一步前向预测. 首先将带噪信号输入网络进行小波分解得 $\{d_{1,i}(m), \dots, d_{J,i}(m), C_{J,i}(m)\}$ 及单层重构系数 $\{d_{1,i}^{sr}(m), \dots, d_{J,i}^{sr}(m), C_{J,i}^{sr}(m)\}$, 利用上述训练算法搜索各层系数的最优阈值, 对细节单层重构信号过阈处理得 $\{\tilde{d}_{1,i}^{sr}(m), \dots, \tilde{d}_{J,i}^{sr}(m), \tilde{C}_{J,i}^{sr}(m)\}$, 将过阈处理后的各层系数分别进行一步前向预测, 预测结果求和即得最终的预测结果 $\tilde{y}(m)$. 文献[7, 8]已说明了这种基于小波分解与重构(WDR)的方法可以提高预测精度.

线调频(LFM)信号是雷达中广泛使用的信号. 由于传输信道、接收机及外界干扰, 使接收信号含有噪声, 影响雷达通信. 此处讨论合作式的雷达通信, 因而可得到纯净信号用于网络训练.

将WTNN与利用Donoho阈值先去噪预处理再预测(称为P+MLP)的结果相比较, 两者区别在于前者在去噪和预测使用同一评价函数, 而后者则使用了两个评价函数. 处理对象均为带噪LFM信号. 小波分解4层. 新阈值函数(16)中 $s = 0.01$. 各层阈值初始化在 $[0.05d_{j,\max}^{sr}, 0.15d_{j,\max}^{sr}]$ 内. 信号共有512个点, 归一化频率范围为 $[0, 1]$, 调频范围为 $[0.02, 0.15]$, 调频斜率0.13, 信号幅度 $A = 1$. 噪声为 $N(0, 0.5)$ 的白噪声, 信噪比 $10\log_{10}\frac{A^2}{\sigma^2} = 3.0103$ dB. 用512个点中的前60%即307个点来训

练网络, 测试时使用全部的512个点. 下面3个仿真实例分别对高斯白噪声、高斯带限(色)噪声及瑞利噪声下的信号去噪和预测. 在图3~5中, (b)图均为不同噪声类型下带噪信号的频谱; (c)和(e)分别为WTNN的去噪和预测结果; (d)和(f)分别为P+MLP去噪和预测的结果; (g)和(h)分别为WTNN和P+MLP预测结果的局部放大图. (e)~(h)中的虚线和实线各表示纯净信号和预测结果. 3种噪声下信噪比均为 $\text{SNR}=3.0103$ dB, 预测结果的MSE按式(9)计算见表1.

表1 WTNN与P+MLP对不同噪声类型信号的预测均方差

Table 1 Prediction mean square errors of WTNN and P+MLP in different types of noise and SNR

信噪比	网络结构	高斯白噪声	高斯带限噪声	瑞利噪声
0 dB	WTNN	59.2017	76.9474	66.3006
	P+MLP	68.9479	85.4128	71.0294
-3.0103 dB	WTNN	81.8329	94.2691	94.6303
	P+MLP	87.7118	96.7387	98.6289

例1 高斯白噪声下LFM信号去噪及预测, 如图3.






图3 高斯白噪声下的方针结果

Fig. 3 Simulation results of the Gauss white noise

例2 带高斯色噪声的LFM信号去噪及预测. 将例1中高斯白噪声改为高斯色噪声(高斯带限噪声), 色噪声可以由白噪声通过一个一阶线性滤波器得到, 此处滤波器传函为 $\frac{\sqrt{1-a^2}}{(1-az^{-1})}$, 参数 $a = 0.9$. 结果如图4.






图4 高斯色噪声(高斯带限噪声)下的仿真结果
Fig. 4 Simulation results under the Gauss color noise
(Gauss band limit noise)

例3 瑞利噪声下LFM信号去噪及预测. 若 X_I 和 X_Q 服从标准正态分布且统计独立, 则随机变量 $X = |X_I + jX_Q|$ 服从瑞利分布. 结果如图5.




图5 瑞利噪声下的仿真结果

Fig. 5 Simulation results under the Rayleigh noise

从上述3例看出, WTNN无论在去噪还是预测均优于P+MLP方法, 对不同类型噪声有较好的适应性. 降低信噪比, 在0和-3 dB下预测结果的MSE见表1.

5 结论(Conclusion)

本文提出了一种WTNN网络. 其优势在于: 将去噪及预测相结合, 利用改进的连续可导阈值函数使得搜索最优阈值成为可能; 将阈值去噪集成于神经网络中, 使得去噪与神经网络训练使用同一误差标准, 避免了去噪和预测双重评价函数对预测精度的影响; 通过小波系数单层重构, 分别对各层系数进行预测, 使得预测结果更加准确并易于编程实现. 不同噪声类型下的仿真结果证明了本文方法的有效性和优越性.

参考文献(References):

- [1] BISHOP C M. Training with noise is equivalent to Tikhonov regularization[J]. *Neural Comput*, 1995, 7(1): 108 – 116.
- [2] DONOHO D L. De-noising by soft-thresholding[J]. *IEEE Transactions on Information Theory*, 1995, 41(3): 613 – 627.
- [3] DONOHO D L, JOHNSTONE I M. Threshold selection for wavelet shrinkage of noisy data[C] // *Proceedings of the 16th Annual Conference of the IEEE Engineering in Medicine and Biology Society*, Maryland, USA: [s.n.], 1994: 24 – 25.
- [4] 岑翼刚, 孙德宝. 信号Lipschitz奇异性的计算与分析[J]. *计算机工程与应用*, 2004, 40(18): 35 – 38.
(CEN Yigang, SUN Debao. The calculation and analysis of signal's Lipschitz singularities[J]. *Computer Engineering and Applications*, 2004, 40(18): 35 – 38.)
- [5] 岑翼刚, 孙德宝. 利用小波对信号进行去噪及参数估计[J]. *现代雷达*, 2003, 25(3): 31 – 35.
(CEN Yigang, SUN Debao. Application of wavelet analysis for signal parameters estimation and denoising[J]. *Modern Radar*, 2003, 25(3): 31 – 35.)
- [6] ZHANG X P. Thresholding neural network for adaptive noise reduction[J]. *IEEE Transactions on Neural Networks*, 2001, 12(3): 567 – 583.
- [7] 贺国光, 马寿峰, 李宇. 基于小波分解与重构的时间序列预测法[J]. *自动化学报*, 2002, 28(6): 1011 – 1014.
(HE Guoguang, MA Shoufeng, LI Yu. A study on forecasting for time series based on Wavelet analysis[J]. *Acta Automatica Sinica*, 2002, 28(6): 1011 – 1014.)
- [8] 高飞, 张晓辉. 基于小波分解的色噪声预测[J]. *北京理工大学学报*, 2003, 23(3): 354 – 359.
(GAO Fei, ZHANG Xiaohui. Colored noise prediction based on wavelet decomposition[J]. *Transactions of Beijing Institute of Technology*, 2003, 23(3): 354 – 359.)

作者简介:

岑翼刚 (1978—), 男, 博士, 讲师, 2006年毕业于华中科技大学控制科学与工程系, 目前在北京交通大学信息科学研究所工作, 从事信号处理、小波分析等方面的研究, E-mail: cenyigang@163.com;

尉宇 (1970—), 男, 武汉科技大学副教授, 博士, 从事信号处理、脉内分析等方面的研究, E-mail: waveleter@163.com;

孙德宝 (1941—), 男, 华中科技大学控制科学与工程系教授, 博士生导师, 从事人工智能、信号处理等方面的研究。

下 期 要 目

时变复杂动力学网络的同步控制	王 磊, 戴华平, 孙优贤
基于自适应带宽的快速动态高斯核均值漂移算法	周芳芳, 樊晓平, 叶 榛
检验门限协整模型中的线性协整	杨 政, 田 铮, 原子霞
时滞离散系统正弦扰动的最优抑制	唐功友, 王笑寒, 王海红
具反应扩散混合时滞Cohen-Grossberg神经网络的指数耗散性	楼旭阳, 崔宝同
一类非线性大滞后系统的改进无模型自适应控制	金尚泰, 侯忠生
基于神经网络与多模型的非线性自适应广义预测解耦控制	石宇静, 柴天佑
含输入和状态时滞的T-S模糊系统的鲁棒控制	李 丽, 刘晓东, 杨晓光
基于矩阵式变换器的异步电机直接转矩控制策略	杨 苹, 胡 斌, 陈 武, 钟国基
非线性系统的自组织多模型自适应逆控制	高大远, 沈 辉, 胡德文
双输入单输出潜遗传变论域模糊控制算法及其收敛性	龙祖强, 梁昔明, 游开明, 陈列尊
铅锌烧结过程质量产量的智能集成优化控制	徐辰华, 吴 敏
三峡工程两坝联合通航调度的混合模拟退火算法	张晓盼, 齐 欢, 袁晓辉
一类切换线性奇异系统的 H_∞ 控制	付主木, 费树岷
舰载红外警戒系统的单站多目标数据关联与滤波算法	李 晨, 韩崇昭, 徐林海, 朱洪艳
基于一种FGA-ANFIS技术的DMFC温度建模和控制	戚志东, 朱新坚
一类时滞不确定随机系统的鲁棒控制的新方法	罗毅平, 邓飞其, 高京广
自校正解耦信息融合Wiener状态估值器	邓自立, 李春波