

文章编号 1004-924X(2011)06-1406-08

# 自组织递归区间二型模糊神经网络在动态时变系统辨识中的应用

李迪, 陈向坚, 续志军\*, 杨帆, 牛文达

(中国科学院 长春光学精密机械及物理研究所, 吉林 长春 130033)

**摘要:**针对动态时变系统辨识过程中存在噪声干扰的问题, 本文将区间二型模糊集结合到递归神经网络中, 提出了自组织递归区间二型模糊神经网络以增强动态时变系统的抗噪能力。该自组织递归区间二型模糊神经网络由前件和后件两部分构成: 前件为区间二型模糊集模型, 用于将每个规则的激活强度反馈到自身构成内反馈回路, 其参数学习采用梯度下降算法; 后件为带有区间权值的 Takagi-Sugeno-Kang(TSK)模型, 其参数学习采用有序规则卡尔曼滤波算法, 且网络初始规则数为零。所有规则均通过结构学习和前后件参数同时在线学习来产生, 其网络结构学习采用的是在线区间二型模糊群集。为验证提出的神经网络的优越性, 将其应用到单输入单输出动态时变系统的辨识中。实验结果表明, 相对于前馈一型/二型模糊神经网络、递归一型模糊神经网络, 该神经网络的辨识能力强, 即使在存在白噪声的条件下, 也能减小测试及训练误差。

**关键词:**自组织递归区间; 二型模糊神经网络; 卡尔曼滤波; 梯度下降法; 噪声干扰; 动态时变系统辨识

**中图分类号:** TP391.4      **文献标识码:** A      **doi:** 10.3788/OPE.20111906.1406

## Type-II fuzzy neural networks with self-organizing recurrent intervals for dynamic time-varying system identification

LI Di, CHEN Xiang-jian, XU Zhi-jun\*, YANG Fan, NIU Wen-da

(Changchun Institute of Optics Fine Mechanics and Physics, Chinese Academy of Sciences, Changchun 130033, China)

\* Corresponding author, E-mail: xuzj538@ciomp.ac.cn

**Abstract:** To solve the noise interference issue for the dynamic time-varying system identification processing, a type-II Fuzzy Neural Network (FNN) with self-organizing recurrent intervals is proposed to enhance the system robustness against the noise. This type-II fuzzy neural network is composed of two parts. The antecedent part takes the type-II fuzzy-set model to form the feedback-loop internally by feeding the acting strength of each rule, and it uses an algorithm of gradient-descent method for parameter learning. The consequent part takes the Takagi-Sugeno-Kang (TSK) model and uses an rule-ordered Karman filtering method for parameter learning in no initial network rules. All rules are generated from the simultaneous on-line parameter learning from both parts above, in which the network structural learning takes the on-line interval type-II fuzzy-set. To verify its advantages in perform-

收稿日期: 2010-11-04; 修订日期: 2011-02-15.

基金项目: 国家自然科学基金资助项目 (No. 50905174)

ance, the proposed neural network is compared with the feed forward type-I/type-II FNNs and recurrent type-I FNN in applications of the single-in-single-out dynamic time-variant system identification. The experiment results indicate that the type-II fuzzy neural network (FNN) with self-organizing recurrent intervals has strong identification ability, and can reduce the errors of the training and test in the present of various white noises.

**Key words:** type-II fuzzy neural network; self-organizing recurrent interval; Kalman-filtering; gradient-descent algorithm; noise disturbance; dynamic time-varying system identification

## 1 引言

模糊神经网络不仅善于利用已有的经验知识,而且由于引入了神经网络的学习机制,增强了网络的自适应能力,从而使其同时具有推理能力强和自适应能力强的优点。另外,由于模糊神经网络同神经网络一样具有逼近任意连续非线性映射的特性,正越来越多地被用于对系统辨识的研究,但是,一般的模糊神经网络都是静态模糊神经网络,不适于动态系统的辨识问题。文献[1]提出了动态模糊神经网络,其模糊规则的后件采用带有内反馈的递归神经网络。基于 TSK 型递归模糊神经网络<sup>[2]</sup>,将其每条规则的有限长度反馈到神经网络中,作为神经网络的输入量。现已将动态模糊神经网络成功的应用到 UV-LIGA 工艺优化中、微细电火花加工放电状态逐级映射检测以及肺 CT 肿瘤靶区超分辨率重建等应用系统中<sup>[3-6]</sup>。

所有以上提到的递归模糊神经网络都是基于一型模糊理论。近年来,二型模糊逻辑系统越来越受到关注<sup>[7-9]</sup>,二型模糊逻辑是一型模糊逻辑的扩展,相对于一型模糊逻辑而言,其在处理不确定性等问题上更具有优越性,并成功地用于处理语言识别以及分类等问题<sup>[10-11]</sup>。本文提出自组织递归区间二型模糊神经网络,通过训练数据便可以自动进化网络结构并实现在线参数学习。自组织递归区间二型模糊神经网络有两个突出的特点:当前二型模糊神经网络都是基于前向神经网络来处理输入/输出映射问题,而在自组织递归区间二型模糊神经网络结构中,将每个规则的有限长度反馈到自身,形成由当前网络和滞后网络输入相结合形成后件的反馈环路;现有的二型模糊

神经网络只是学习参数,网络结构固定并且预先设定,而自组织递归区间二型模糊神经网络提出网络结构学习算法与参数学习算法,这两者同时在线学习,所有的规则也在线产生。文中通过系统辨识实例来验证自组织递归区间二型模糊神经网络的性能,同时与递归一型模糊神经网络,前馈模糊一型模糊神经网络,以及其它二型模糊神经网络进行了比较。

## 2 自组织递归区间二型模糊神经网络结构

假设待处理的动态系统是多输入多输出系统,该系统具有  $n_u$  个输入,  $n_o$  个输出,控制输入与输出向量分别用  $\mathbf{u}=(u_1, u_2, \dots, u_{n_u})$  和  $\mathbf{y}_p=(y_{p1}, y_{p2}, \dots, y_{p_{n_o}})$  表示,其中,  $n_u, n_o$  分别代表输入输出维数,多输入多输出 6 层自组织递归区间二型模糊神经网络结构如图 1 所示,每个递归模糊规则的后件是一个一阶 TSK 型,每层的数学含义介绍如下:




图 1 自组织递归区间二型模糊神经网络结构

Fig. 1 Structure of type-II fuzzy neural networks with self-organizing recurrent intervals

第一层(输入层):该层直接将当前状态  $x(t) = (u(t), y_p(t))$  作为输入,而前馈模糊神经网络则是将当前值与过去值同时作为该层的输入。该层每个输入节点的范围定位  $[-1, 1]$ , 并且无需调整权值。

第二层(隶属函数层):该层每个节点代表一个区间二型隶属函数,对于输入变量  $x_j$  的第  $i$  个区间二型模糊集用  $\tilde{A}_i^j$  表示。其中  $j = 1, 2, \dots, n_u + n_o$ , 使用的高斯主隶属函数有一个固定的标准偏差  $\sigma_j^i$  和一个不确定均值  $[m_{j1}^i, m_{j2}^i]$ 。

$$u_{\tilde{A}_i^j} = \exp\left\{\frac{-1}{2}\left(\frac{x_j - m_j^i}{\sigma_j^i}\right)^2\right\} \equiv N(m_j^i, \sigma_j^i, x_j), \quad (1)$$

其中  $m_j^i \in [m_{j1}^i, m_{j2}^i]$ , 对于隶属函数的不确定性足迹(FOU)用上隶属函数与下隶属函数来定界,对于上下隶属函数表示如下:

$$\bar{\mu}_j^i(x_j) = \begin{cases} N(m_{j1}^i, \sigma_j^i, x_j), & x_j < m_{j1}^i \\ 1, & m_{j1}^i \leq x_j \leq m_{j2}^i \\ N(m_{j2}^i, \sigma_j^i, x_j), & x_j > m_{j2}^i \end{cases}, \quad (2)$$

$$\underline{\mu}_j^i(x_j) = \begin{cases} N(m_{j2}^i, \sigma_j^i, x_j), & x_j \leq \frac{m_{j1}^i + m_{j2}^i}{2} \\ N(m_{j1}^i, \sigma_j^i, x_j), & x_j > \frac{m_{j1}^i + m_{j2}^i}{2} \end{cases}, \quad (3)$$

第三层(空间激活层):该层每个节点对应一个模糊规则,并作为空间规则节点,每个节点通过代数 product 操作对从第二层输出的节点进行 meet 运算来获取空间激活强度  $F^i$ , 它是一个区间一型模糊集,  $M$  为规则总数,计算公式如下所示:

$$F^i = [\underline{f}^i, \bar{f}^i], i = 1, \dots, M, \quad (4)$$

$$\bar{f}^i = \prod_{j=1}^{n_u+n_o} \bar{\mu}_j^i, \underline{f}^i = \prod_{j=1}^{n_u+n_o} \underline{\mu}_j^i, \quad (5)$$

第四层(临时激活层):该层的节点是用来形成内反馈回路的递归规则节点,递归规则节点的输出是临时激活强度,其不仅与当前的空间激活强度有关,还依赖于前一时刻临时激活强度。其计算公式如下:

$$\Psi_q^i(t) = \lambda_q^i F^i(t) + (1 - \lambda_q^i) \Psi_q^i(t-1) = \lambda_q^i [\bar{f}^i(t), \underline{f}^i(t)] + (1 - \lambda_q^i) [\bar{\Psi}_q^i(t-1), \underline{\Psi}_q^i(t-1)], \quad (6)$$

其中,  $i = 1, \dots, M; q = 1, \dots, n_o, \lambda_q^i$  是反馈权值。

第五层(后件层):该层节点称为后件节点,其

作为第四层输出及单元延迟算子的线性模型,第四层的每个节点都有一个后件节点。第  $i$  个后件节点连接第  $q$  个网络输出变量计算如下:

$$\tilde{y}'_q(t+1) = \sum_{j=0}^{n_u} \sum_{k=0}^{N_j} \tilde{a}_{jkq}^i u_j(t-k) + \sum_{j=0}^{n_o} \sum_{k=0}^{O_j} \tilde{a}_{(j+n_u)kq}^i y_{pj}(t-k), \quad (7)$$

其中,  $u_0(t) \triangleq 1, N_0 \triangleq 0, N_j, O_j$  分别代表控制输入  $u_j(t)$  及系统输出  $y_{pj}(t)$  的最大延迟数。 $\tilde{a}_{jkq}^i$  用下面的区间来代替:

$$\tilde{a}_{jkq}^i = [c_{jkq}^i - s_{jkq}^i, c_{jkq}^i + s_{jkq}^i], \quad (8)$$

其中,  $c_{jkq}^i, s_{jkq}^i$  分别代表区间的中心值和扩展值。 $\tilde{y}'_q(t+1)$  是一个区间一型模糊集,用  $[\tilde{y}'_{lq}, \tilde{y}'_{rq}]$  来代替,其中  $l, r$  分别代表左右极限,节点输出可改写为:

$$\tilde{y}'_{lq} = \sum_{j=0}^{n_u} \sum_{k=0}^{N_j} c_{jkq}^i u_j(t-k) + \sum_{j=0}^{n_o} \sum_{k=0}^{O_j} c_{(j+n_u)kq}^i y_{pj}(t-k) - \sum_{j=0}^{n_u} \sum_{k=0}^{N_j} s_{jkq}^i |u_j(t-k)| - \sum_{j=0}^{n_o} \sum_{k=0}^{O_j} s_{(j+n_u)kq}^i |y_{pj}(t-k)|, \quad (9)$$

$$\tilde{y}'_{rq} = \sum_{j=0}^{n_u} \sum_{k=0}^{N_j} c_{jkq}^i u_j(t-k) + \sum_{j=0}^{n_o} \sum_{k=0}^{O_j} c_{(j+n_u)kq}^i y_{pj}(t-k) - \sum_{j=0}^{n_u} \sum_{k=0}^{N_j} s_{jkq}^i |u_j(t-k)| - \sum_{j=0}^{n_o} \sum_{k=0}^{O_j} s_{(j+n_u)kq}^i |y_{pj}(t-k)|, \quad (10)$$

第六层(输出层):该层的每个节点对应一个输出变量,通过解模糊操作进行降阶处理来计算网络输出变量  $y'_q \in [y'_{lq}, y'_{rq}]$ , 输出量  $y'_{lq}, y'_{rq}$  可以通过 Karnik-Mendel 迭代过程<sup>[8]</sup> 来计算。后件参数按照升序排列,  $\tilde{y}_{lq} = (\tilde{y}_{lq}^1, \dots, \tilde{y}_{lq}^M), \tilde{y}_{rq} = (\tilde{y}_{rq}^1, \dots, \tilde{y}_{rq}^M)$  表示初始排列规则后件序列值,用  $\hat{y}_{lq} = (\hat{y}_{lq}^1, \dots, \hat{y}_{lq}^M), \hat{y}_{rq} = (\hat{y}_{rq}^1, \dots, \hat{y}_{rq}^M)$  表示重排之后的后件序列值,它们之间的关系表示如下:

$$\hat{y}_{lq} = Q_l \tilde{y}_{lq}, \hat{y}_{rq} = Q_r \tilde{y}_{rq}, \quad (11)$$

其中,  $Q_l, Q_r$  分别表示  $M \times M$  单位向量的置换矩阵,通过这些单位向量的置换重排输出变量序列。从而,初始规则激活强度序列  $\underline{\Psi} = (\underline{\psi}_q^1, \dots, \underline{\psi}_q^M)^T, \bar{\Psi} = (\bar{\psi}_q^1, \dots, \bar{\psi}_q^M)^T$  也做相应的重新排列,在计算输出量  $y'_{lq}$  时,新的规则序列  $\underline{\Psi}, \bar{\Psi}$  相应地变为  $Q_l \underline{\Psi}, Q_l \bar{\Psi}$ ; 在计算输出量  $y'_{rq}$  时,新的规则序列  $\underline{\Psi}, \bar{\Psi}$  相应地变为  $Q_r \underline{\Psi}, Q_r \bar{\Psi}$  具体计算公式显示如下:

$$y'_{lq} = \frac{\sum_{i=1}^L (Q_l \bar{\psi}) \hat{y}_{lq}^i + \sum_{i=1+1}^M (Q_l \underline{\psi}) \hat{y}_{lq}^i}{\sum_{i=1}^L (Q_l \bar{\psi})_i + \sum_{i=1}^L (Q_l \underline{\psi})_i}, \quad (12)$$

$$y'_{rq} = \frac{\sum_{i=1}^L (Q_r \bar{\psi}) \hat{y}_{rq}^i + \sum_{i=1+1}^M (Q_r \underline{\psi}) \hat{y}_{rq}^i}{\sum_{i=1}^L (Q_r \bar{\psi})_i + \sum_{i=1}^L (Q_r \underline{\psi})_i}, \quad (13)$$

方程式(12),(13)中  $y'_{lq}, y'_{rq}$  用最初的排列序列值,最后,通过计算  $y'_{lq}, y'_{rq}$  的平均值来获得网络输出变量  $y_q'$  的解模糊输出值:

$$y_q^i = \frac{y'_{lq} + y'_{rq}}{2}. \quad (14)$$

### 3 结构学习与前后件参数学习

自组织递归区间二型模糊神经网络通过结构与前后件参数同时学习来在线进化出所有二型模糊规则,针对结构学习算法和参数学习算法进行以下分析:

#### 3.1 结构学习

结构学习算法目的就是为了实现能够通过在线学习产生规则,从而修正网络结构。文献[12]中采用规则激活强度作为一型规则产生标准,将其方法扩展,作为自组织递归区间二型模糊神经网络的二型模糊规则产生标准。将空间激活强度(方程式(4))作为决定模糊规则产生与否的标准,由于空间激活强度是区间有界的,所以它的中心值为:

$$f_c^i = \frac{1}{2}(\underline{f}^i + \bar{f}^i). \quad (15)$$

空间激活强度中心值  $f_c^i$  作为规则产生标准。新数据  $x$  输入到网络当中,变化产生一个新的规则,每个新的二型模糊集的不确定均值表示如下:

$$[m_{j2}^{M(t)+1}, m_{j2}^{M(t)+1}] = [x_j - 0.1, x_j + 0.1], j=1, \dots, n_u + n_o. \quad (16)$$

每个新的二型模糊集的中心值预先设定(本文中设置  $\sigma_j = 0.3$ ),它将决定模糊集宽度,新数据  $x(t)$  以后的每块输入表示:

$$I = \arg \max_{1 \leq i \leq M(t)} f_c^i(\mathbf{x}), \quad (17)$$

其中,  $M(t)$  表示  $t$  时刻已有的规则数,如果  $f_c^i \leq f_{th}$ , 则产生新的规则,  $f_{th} \in (0, 1)$  是预先设定的初值。新的规则产生之后,相应的新二型模糊集的

不确定均值和宽度计算如下:

$$[m_{j2}^{M(t)+1}, m_{j2}^{M(t)+1}] = [x_j(t) - 0.1, x_j(t) + 0.1], \quad (18)$$

$$\sigma_j^{M(t)+1} = \beta \left( \sum_{j=1}^{n_u+n_o} \left( x_j - \left( \frac{m_{j1}^i + m_{j2}^i}{2} \right) \right)^2 \right)^{0.5}, \quad (19)$$

在结构学习算法中,首先预设不确定范围,所有的隶属函数共享一个范围,通过下面的隶属函数参数学习算法,自动的调整隶属函数的不确定均值范围,使其各不相同。

#### 3.2 参数学习算法

参数学习与结构学习同时进行,对于每一个新输入数据,不论是否产生新的规则,自组织递归区间二型模糊神经网络中的所有参数都需要调整。为清晰阐述,这里只考虑第  $q$  个网络输出。参数学习的目的是为了减小误差:

$$E = \frac{1}{2} [y_q'(t+1) - y_d(t+1)]^2, \quad (20)$$

其中,  $y_q'(t+1), y_d(t+1)$  分别代表自组织递归区间二型模糊神经网络输出及希望输出值。

##### 3.2.1 前件参数调整算法

前件参数学习使用梯度下降算法,对前件参数进行学习修正:

$$\lambda_q^i(t+1) = \lambda_q^i(t) - \eta \frac{\partial E}{\partial \lambda_q^i(t)}, \quad (21)$$

其中,  $\eta$  是学习变量,本文中取值  $\eta = 0.03$ , 则:

$$\frac{\partial E}{\partial \lambda_q^i} = \frac{\partial E}{\partial y_q'} \left( \frac{\partial y_q'}{\partial y_{lq}'} \frac{\partial y_{lq}'}{\partial \lambda_q^i} + \frac{\partial y_q'}{\partial y_{rq}'} \frac{\partial y_{rq}'}{\partial \lambda_q^i} \right), \quad (22)$$

$w_j^i$  表示输入变量  $x_j$  在第  $i$  个区间二型模糊集  $\tilde{A}_j^i$  的参数,更新参数  $w_j^i$  的公式如下所示:

$$w_j^i(t+1) = w_j^i - \eta \frac{\partial E}{\partial w_j^i(t)}, \quad (23)$$

方程式(2)和(3)中的参数  $m_{j1}^i, m_{j2}^i, \sigma_j^i$  可用方程式(22)和(23)计算方法来更新。

##### 3.2.2 后件参数调整算法

在参数学习过程中,改变了后件值  $\tilde{y}_{lq}, \tilde{y}_{rq}$ , 相应的规则序列也随着改变。所以,在更新参数之前,有必要确定前件/后件参数的确切位置,在每一步学习时间内,模糊规则顺序变动,很难断定前件/后件参数的确切位置。针对这个问题,本文提出有序规则卡尔曼滤波算法,该算法确保在参数学习过程中保证原有规则顺序。将后件值映射为

按照方程式(11)规则顺序所形成的升序排列,根据这个映射,方程式(12)和(13)可以表示为  $\tilde{y}_{lq}$ ,  $\tilde{y}_{rq}$ , 这样保证当参数学习过程中后件值改变了但还是按照原来的顺序排列。基于原有的有序规则表达式,有序规则卡尔曼滤波算法描述如下,方程式(12)和(13)重写为:

$$\begin{cases} \tilde{y}'_{lq} = \Phi_{lq}^T \tilde{y}_{lq} \\ \Phi_{lq}^T = \frac{\bar{\psi}^T Q_l^T E_1^T E_1 Q_l + \psi^T Q_l^T E_2^T E_2 Q_l}{p_l^T Q_l \psi + g_l^T Q_l \psi} \in \mathbf{R}^{M \times 1}, \end{cases} \quad (24)$$

$$\begin{cases} \tilde{y}'_{rq} = \Phi_{rq}^T \tilde{y}_{rq} \\ \Phi_{rq}^T = \frac{\bar{\psi}^T Q_r^T E_3^T E_3 Q_r + \psi^T Q_r^T E_4^T E_4 Q_r}{p_r^T Q_r \psi + g_r^T Q_r \psi} \in \mathbf{R}^{M \times 1}, \end{cases} \quad (25)$$

其中,  $p_l$  为  $L$  维单位列向量;  $g_l$  为  $M-L$  维单位列向量;  $p_r$  为  $R$  维单位列向量;  $g_r$  为  $M-R$  维单位列向量。  $E_1$  为  $L$  维误差列向量;  $E_2$  为  $M-L$  维误差列向量;  $E_3$  为  $R$  维误差列向量;  $E_4$  为  $M-R$  维误差列向量。因此,方程式(24)中的输出量  $y_q'$  重写为:

$$y_q' = \frac{1}{2}(y'_{lq} + y'_{rq}) = \frac{1}{2}(\Phi_{lq}^T \tilde{y}_{lq} + \Phi_{rq}^T \tilde{y}_{rq}) = \frac{1}{2}[\Phi_{lq}^T \Phi_{rq}^T] \begin{bmatrix} \tilde{y}_{lq} \\ \tilde{y}_{rq} \end{bmatrix}, \quad (26)$$

### 4 仿 真

采用自组织递归区间二型模糊神经网络对单输入单输出时变动态系统进行辨识,带有时间延迟的动态系统数学模型描述如下:

$$y_{p1}(t+1) = 0.72y_{p1}(t) + 0.025y_{p1}(t-1) + u_1(t-1) + 0.01u_1^2(t-2) + 0.2u_1(t-3), \quad (27)$$

设定动态系统的系统输入量为:

$$u_1(t) = \begin{cases} \sin(\frac{\pi t}{50}), & t < 400 \\ 1.0, & 400 \leq t \leq 550 \\ -1.0, & 550 \leq t \leq 700 \end{cases} \quad (28)$$

假定系统未知,为了辨识其动态系统的动力学模型,采用图 2 所示的辨识结构。对于上面的单输入单输出系统 ( $n_u = 1, n_o = 1$ ),当前变量  $u_1(t), y_{p1}(t)$  作为自组织递归区间二型模糊神经

网络输入层的输入量,系统的输出量依赖与前三个时刻输入量及前一时刻输出量,因此自组织递归区间二型模糊神经网络中单元延迟算子数目  $N_1 = 3, O_1 = 1$ ,在训练过程中,取系统输出  $y_{p1}(t+1)$  作为希望输出值  $y_d(t+1)$ ,总的在线训练时间为 9 000 s,网络结构学习初始值  $f_h$  决定了产生模糊集的数目,当  $f_h = 0.05$  时,将会产生两个模糊规则。

图 3 显示对于控制量为方程式(28)时,动态系统的输出量与使用自组织递归区间二型模糊神经网络辨识模型的输出量,图 4 显示了自组织递归区间二型模糊神经网络辨识模型的输出值与系统输出值之间的误差,表 1 显示了网络结构学习产生的规则数,训练参数个数,均方根误差的训练及测试结果。




图 2 动态系统辨识模型结构图  
Fig. 2 Architecture of dynamical system identification model




图 3 系统输出与基于 T2FNN SORI 模型辨识的输出比较  
Fig. 3 Actual outputs of system and T2FNN SORI identification model




图 4 基于 T2FNNSORI 辨识模型与系统输出误差比较  
Fig. 4 Errors of outputs between the T2FNNSORI i-  
dentification model and actual system

表 1 4 种神经网络模型与 SISO 系统辨识性能的比较

Tab.1 Performance of models for SISO system identification

	规则数量	参数量	训练误差	测试误差
FT1FNN	7	46	0.013	0.039
FT2FNN	4	45	0.024	0.043
RT1FNN	5	60	0.005 4	0.005 8
T2FNNSORI	2	40	0.003 3	0.006

将自进化递归区间二型模糊神经网络 (T2FNNSORI)与 TSK 前馈一型/二型模糊神经网络(FT1FNN/FT2FNN)、递归一型模糊神经网络(RT1FNN)对上面的单输入单输出系统的辨识性能进行比较:其中,前馈一型模糊神经网络是一个自组织神经模糊推理网络,网络结构和参数都通过在线学习;前馈二型模糊神经网络是一个区间二型模糊神经网络,网络参数学习采用梯度下降法,网络结构是预先设定的固定网络结构;将以上两个模糊神经网络在相同网络结构条件下进行比较得到:前馈二型模糊神经网络的总参数量与前馈一型模糊神经网络的数量接近相同,前者由于使用外参数及规则后件,所以前者的规则参数比后者多,导致后者的规则数比前者的规则多;递归一型模糊神经网络的规则数、网络训练总参数、均方根误差的训练及测试都列在表 1 中。最终结果表明:自组织递归区间二型模糊神经网络相对于其它前馈和递归网络来说,能减小训练和

测试误差。

当系统输出中存在噪声时,将自组织递归区间二型模糊神经网络与 TSK 前馈一型/二型模糊神经网络、递归一型模糊神经网络的系统辨识性能再次加以对比,表 2 显示了各种模糊神经网络在不同噪声条件下的测试误差,这里的噪声是人

表 2 系统存在白噪声条件下,4 种神经网络模型与 SISO 系统辨识性能的比较

Tab.2 Performance of four models for SISO system identification with different noise levels

	FT1FNN	FT2FNN	RT1FNN	T2FNNSORI
STD=0.1	0.042 ±0.003	0.043 ±0.003	0.039 ±0.002	0.035 ±0.001
STD=0.5	0.291 ±0.008	0.257 ±0.007	0.223 ±0.005	0.197 ±0.005
STD=0.7	0.457 ±0.009	0.402 ±0.008	0.367 ±0.007	0.348 ±0.007

为加入的 3 个水平高斯白噪声,STD=0.1,0.5,0.7,从表 2 中可见:自组织递归区间二型模糊神经网络较其它模糊神经网络的测试误差都小。


## 5 结 论

本文提出了自组织递归区间二型模糊神经网络,该神经网络不用预先设定网络结构,可以通过网络结构算法在线学习来进化神经网络结构;其前件参数采用梯度下降算法来学习,后件参数采用有序规则卡尔曼滤波算法在线学习,从而提高了学习精度。仿真结果表明:不论系统中是否存在噪声,自组织递归区间二型模糊神经网络相对于前馈一型/二型模糊神经网络、递归一型模糊神经网络具有更好的辨识能力。本文的下一步的工作任务是分析自组织递归区间二型模糊神经网络的收敛性能,同时考虑将其应用到具有噪声及不确定性因素的微型飞行器系统的参数辨识中。

## 参考文献:

- [1] MASTORCOSTAS P A, THEOCHARIS J B. A recurrent fuzzy-neural model for dynamic system identification[J]. *IEEE Trans. Syst., Man and Cyber. Part B: Cybernetics.*, 2002, 32(2):176-190.
- [2] JUANG C F. A TSK-type recurrent fuzzy network for dynamic systems processing by neural network and genetic algorithm [J]. *IEEE Trans. Fuzzy Systems*, 2002, 10(2):155-170.
- [3] 郑晓虎, 朱荻. 模糊神经网络在 UV-LIGA 工艺优化中的应用[J]. *光学 精密工程*, 2006, 14(1):139-144. ZHENG X H, ZHU D. Application of fuzzy neural network to optimizing UV-LIGA process[J]. *Opt. Precision Eng.*, 2006, 14(1):139-144. (in Chinese)
- [4] 张玲瑄, 贾振元. 微细电火花加工放电状态逐级映射检测[J]. *光学 精密工程*, 2010, 18(3):663-669. ZHANG L X, JIA ZH Y. Successive mapping detection of micro EDM discharge state [J]. *Opt. Precision Eng.*, 2010, 18(3):663-669. (in Chinese)
- [5] 李勇, 王珂, 张立保, 等. 多断层融合的肺 CT 肿瘤靶区超分辨率重建[J]. *光学 精密工程*, 2010, 18(5):1213-1218. LI Y, WANG K, ZHANG L B, et al.. Super-resolution reconstruction of pulmonary nodules based on CT multi-section fusion[J]. *Opt. Precision Eng.*, 2010, 18(5):1213-1218. (in Chinese)
- [6] 张友旺. 基于动态递归模糊神经网络的自适应电液位置跟踪系统[J]. *控制理论与应用*, 2005, 22(4):551-555. ZHANG Y W. Adaptive electro\_hydraulic position tracking system based on dynamic recurrent fuzzy neural network [J]. *Control Theory and Applications*, 2005, 22(4):551-555. (in Chinese)
- [7] KARNIK N N, MENDEL J M, LIANG Q. Type-2 fuzzy logic systems[J]. *IEEE Trans. Fuzzy Systems*, 1999, 7(6):643-658.
- [8] MENDEL J M. Type-2 fuzzy sets made simple[J]. *IEEE Trans. Fuzzy Systems*, 2002, 10(2):117-127.
- [9] JOHN R, COUPLAND S. Type-2 fuzzy logic: A historical view[J]. *IEEE Comput. Intell. Mag.*, 2007, 2(1):57-62.
- [10] ZENG J, LIU Z Q. Type-2 fuzzy hidden Markov models and their application to speech recognition [J]. *IEEE Trans. Fuzzy Syst.*, 2006, 14(3):454-467.
- [11] JUANG C F, CHIU S H, CHANG S W. A Self-organizing TS-type fuzzy network with support vector learning and its application to classification problems[J]. *IEEE Trans, Fuzzy Syst*, 2007, 15(5):998-1008.
- [12] JUANG CH F. A self-Evolving Internal Type-2 Fuzzy Neural Network With Online Structure and Parameter learning[J]. *IEEE Trans, Fuzzy Syst*, 2008, 16(6):1411-1424.

## 作者简介:



李 迪(1983—),男,吉林白山人,博士研究生,2004年、2006年于东北电力大学分别获得学士、硕士学位,主要从事嵌入式系统、微型飞行器的图像传输与自动控制方面的研究。E-mail: li-di19821111@163.com



陈向坚(1983—),女,吉林人,博士研究生,2004年、2006年于东北电力大学分别获得学士、硕士学位,主要从事微型飞行器自动控制、智能控制方面的研究。E-mail: cxj831209@163.com



杨帆(1984—),男,吉林长春人,工学硕士,研究实习员,主要从事结构有限元分析与光机结构设计方面的研究。E-mail: yangfan-84@163.com



牛文达(1983—),男,吉林长春人,工学硕士,研究实习员,主要从事光机结构的设计与研究。E-mail: thornnightingale@163.com

通讯作者:



续志军(1953—),男,吉林长春人,研究员,博士生导师,主要从事电子技术、自动控制方面的研究。Email: xuzj538@ciomp.ac.cn

## ● 下期预告

# 大孔径长条反射镜支撑结构设计

辛宏伟<sup>1</sup>,关英俊<sup>2</sup>,李景林<sup>1</sup>,杨利伟<sup>1</sup>,董得义<sup>1</sup>,张学军<sup>1</sup>

(1.中国科学院 长春光学精密机械与物理研究所,吉林 长春 130033;

2.长春工业大学 机电工程学院,吉林 长春 130012)

为了使大孔径长条形空间反射镜支撑结构同时满足高刚度、高强度和良好的热尺寸稳定性要求,建立了反射镜支撑系统的模态解析数学模型,并对该模型所描述的反射镜沿各轴向的平动和转动模态特性进行了研究。利用模态解析解所得3个支撑点确保质量分布相对均匀时,系统的动—静态刚度达到最大的结论,结合有限元分析技术确定了反射镜的支撑位置。此外,在支撑结构中设置了柔性环节,改善反射镜在各工况下所受的应力环境以确保其光学性能。通过优化柔性铰链的最薄处厚度和圆弧半径两个参数来调节反射镜的面形精度,使面形精度满足设计指标要求。分析及试验结果表明:柔性铰链最薄处厚4 mm,圆弧半径为2 mm时,反射镜在检测方向重力和4℃均匀温升工况下的面形精度RMS值均优于12.3 nm。组件实际一阶固有频率为146 Hz,与有限元分析误差小于5%,柔性支撑结构动态应力响应远小于材料的屈服极限,完全满足反射镜结构系统的设计指标要求。