

一种新的基于神经模糊推理网络的复杂系统 模糊辨识方法¹⁾

李佳宁^{1,2} 易建强¹ 赵冬斌¹ 西广成¹

¹⁾(中国科学院自动化研究所复杂系统与智能科学实验室 北京 100080)

²⁾(中国科学技术信息研究所信息资源中心 北京 100038)

(E-mail: li.jianing@gmail.com, jianqiang.yi@ia.ac.cn)

摘 要 针对基于输入输出数据的复杂系统的模糊辨识问题,提出了一种新的神经模糊推理网络及相应的学习算法.学习算法被应用于系统的结构辨识与参数辨识.在结构辨识阶段,介绍了一种新的直接从输入输出数据中抽取和优化模糊规则的学习算法;在参数辨识阶段,提出和推导了一种非监督学习和监督学习相结合的混合式学习算法,实现模糊隶属函数的初步调整和优化.仿真结果表明,本文的方法可以同时满足对辨识精度、收敛速度、可读性和规则数的要求.

关键词 模糊辨识, 神经模糊网络, 规则抽取, 非监督学习, 监督学习
中图分类号 TP18

A New Fuzzy Identification Approach for Complex Systems Based on Neural-Fuzzy Inference Network

LI Jia-Ning^{1,2} YI Jian-Qiang¹ ZHAO Dong-Bin¹ XI Guang-Cheng¹

¹⁾(Laboratory of Complex Systems and Intelligent Science, Institute of Automation,
Chinese Academy of Sciences, Beijing 100080)

²⁾(Information Resources Center, Institute of Scientific & Technical Information of China, Beijing 100038)

(E-mail: li.jianing@gmail.com, jianqiang.yi@ia.ac.cn)

Abstract This paper proposes a novel neural-fuzzy inference network and learning algorithm for fuzzy identification of complex systems based on input-output data. The learning algorithm is used for both structure identification and parameter identification of the fuzzy model. In the process of structure identification, a new approach is introduced for rule extraction from input-output data directly. By combining both unsupervised and supervised learning, a hybrid learning algorithm is presented for initial adjustment and optimization of membership functions. Simulations illustrate good performance of the proposed network and learning algorithm in terms of accuracy, readability, number of rules and practicability.

Key words Fuzzy identification, neural-fuzzy network, rule extraction, unsupervised learning, supervised learning

1) 国家自然科学基金项目 (60334020, 60440420130, 60475030, 60575047), 国家 973 项目 (2003CB517106), 科技部国际合作重点项目 (2004DFB02100), 中科院海外杰出学者基金 (2005-1-11) 资助

Supported by National Natural Science Foundation of P. R. China (60334020, 60440420130, 60475030, 60575047), National Basic Research Program of P. R. China (2003CB517106), Project of Ministry of Science and Technology of P. R. China (2004DFB02100), and the Outstanding Overseas Chinese Scholars Fund of Chinese Academy of Sciences (2005-1-11), P. R. China

收稿日期 2004-6-11 收修改稿日期 2006-4-26

Received June 11, 2004; in revised form April 26, 2006

1 引言

由于对系统设计的要求不断提高和增加以及系统本身的非线性、不确定性、延迟、时变等特征,传统的基于数学模型的系统辨识方法显现出诸多的局限性.同时,以语言知识模型为基础的模糊辨识方法在理论研究和实际应用中都得到了广泛的关注^[1,2].

与传统的系统辨识问题类似,模糊辨识也包括结构辨识和参数辨识.其中,结构辨识包含模糊空间分割和规则抽取,参数辨识指的是模糊隶属函数参数的选取和优化.如何利用信息得到模糊辨识模型主要有两种策略:一种是使用专家知识(先验知识),一种是基于输入输出数据.当不能得到足够和正确的专家信息,特别是面对复杂的未知模型时,基于输入输出数据的方法具有明显的优势.

由于神经网络在分布式处理、学习能力、鲁棒性和泛化能力方面具有明显的优势,而模糊系统的优势在于良好的可读性和可分析性.因此,将神经网络的思想与方法融合到模糊辨识模型的设计中,有望实现两者的优势互补,已有的研究和成果如文献[3~11].

本文针对基于输入输出数据的复杂系统的模糊辨识问题,在充分考虑了神经网络的分布式处理和学习能力的基础上,构造了一种新的神经模糊推理网络和机制,并提出了相应的学习算法.本文的研究假定已经得到模糊空间的分割,在结构辨识阶段,提出了一种新的直接从输入输出数据中抽取和优化模糊规则的学习算法;在参数辨识阶段,提出和推导了一种混合式学习算法,实现参数的初步调整和优化.仿真结果表明,本文的方法可以同时满足对辨识精度、收敛速度、可读性和规则数的要求.

2 神经模糊推理网络

考虑到具有更一般意义的语言知识模型,本文选择 Mamdani 模型作为模糊模型的知识表示形式,表示为 R^i : if x_1 is A_1^i and if x_2 is $A_2^i, \dots$ and if x_m is A_m^i , then y^i is B^i , 其中, R^i 表示第 i 条模糊规则, x 和 y 是模糊规则的输入和输出, A 和 B 表示模糊输入输出隶属函数.




图 1 六层神经模糊推理网络

Fig. 1 Six-layered neural-fuzzy inference network

网络在经过学习和规则抽取后,它们将为 1 或 0.第四层的连接权值以及网络输入和输出模糊隶属函数的参数将通过下一节提出的算法得到学习和优化.

特别需要指出的是,我们所提出的六层神经模糊推理网络具有从下至上(实线箭头方向)和从上至下(虚线箭头方向)两种工作模式.网络在学习阶段,按照两种模式工作.经过

本节我们详细介绍所构造的六层神经模糊推理网络的结构层次和推理机制,下一节将给出网络的学习算法.基于输入输出数据的网络设计思想来源于文献[8].为了说明方便,假定网络有两个输入变量和单个输出变量,如图 1 所示.第一层和第六层的节点为网络的输入和输出节点,第二层和第四层的节点为模糊隶属函数的区间节点,完成隶属度的计算.第五层为归一化层.第三层的节点为规则节点,分别对应于每一条模糊规则的前件.在本文的讨论中,第二、三、五和六层的连接权值被设置为 1,分别完成传递和对应的功能.第四层的连接权值 W_{ij} 表示每一条模糊规则的前件和后件的映射关系,网络

学习后的网络将按照从下至上的模式工作. 下面, 我们分别给出按照两种工作模式, 网络每一层功能的具体实现. 假定在本文的讨论中, 所有模糊隶属函数选择高斯函数. 其中,

I_i^n 表示第 n 层第 i 个节点的输入

O_i^n 表示第 n 层第 i 个节点的输出

m_i^n, σ_i^n 表示第 n 层第 i 个节点的高斯隶属函数的均值和方差

W_{ij} 表示连接第 3 层第 i 个节点的输出和第 4 层第 j 个节点的输入的权值

从下至上模式 (输入训练数据作为第一层的输入):

第一层

$$O_i^1 = I_i^1, i = 1, 2 \quad (1)$$

第二层

$$I_i^2 = \begin{cases} O_1^1, & i = 1, 2, \dots, N_1 \\ O_2^1, & i = N_1 + 1, \dots, N_1 + N_2 \end{cases} \text{ and } O_i^2 = \exp[-(\frac{I_i^2 - m_i^2}{\sigma_i^2})^2], i = 1, 2, \dots, N_1 + N_2 \quad (2)$$

第三层

$$I_i^3 = \min(O_j^2, O_k^2), j = 1, 2, \dots, N_1, k = N_1 + 1, \dots, N_1 + N_2 \text{ and } O_i^3 = I_i^3, i = 1, 2, \dots, N_1 \times N_2 \quad (3)$$

说明: 使用相关最小推理机制计算模糊规则的激活强度.

第四层

$$I_j^4 = \sum_{i=1}^{N_1 \times N_2} W_{ij} O_i^3 \text{ and } O_j^4 = I_j^4, j = 1, 2, \dots, N_3 \quad (4)$$

第五层

$$I_j^5 = O_j^4 \text{ and } O_j^5 = I_j^5 / \sum_{j=1}^{N_3} I_j^5, j = 1, 2, \dots, N_3 \quad (5)$$

第六层

$$I_i^6 = O_i^5 \text{ and } O_1^6 = \sum_{i=1}^{N_3} m_i^5 \sigma_i^5 I_i^6 / \sum_{i=1}^{N_3} \sigma_i^5 I_i^6 \quad (6)$$

说明: 使用中心法去模糊化机制.

从上至下模式 (输出训练数据作为第六层的输入): 其中, X_i^n 和 Y_i^n 的定义分别同前 I_i^n 和 O_i^n 的定义.

第六层

$$Y_1^6 = X_1^6 \quad (7)$$

第五层

$$X_i^5 = Y_1^6 \text{ and } Y_i^5 = \exp[-(\frac{X_i^5 - m_i^5}{\sigma_i^5})^2], i = 1, 2, \dots, N_3 \quad (8)$$

第四层

$$X_i^4 = Y_i^5, i = 1, 2, \dots, N_3 \quad (9)$$

与文献 [8] 的网络结构和推理机制相比, 当网络按照从下至上模式工作时, 本文方法的优势表现在: 1) 第四层的输出没有在 1 和输入之间取小值, 而是将输入直接传递到第五层, 避免了由于大于 1 的输入引起的不准确输出. 2) 由于引入了归一化层, 可以更准确地反映出在所有输出区间节点中, 每个输出区间节点被激活的强度.

3 三阶段学习算法

基于上述的神经模糊推理网络, 本文提出了一个三阶段的学习算法, 分别完成模糊隶属函数参数的初步调整, 模糊规则的抽取和模糊隶属函数参数的优化. 为了启动学习机制, 需要预先提供输入输出训练数据、网络的初始结构、模糊变量的初始分割和参数.

3.1 学习阶段一: 基于非监督学习的参数初步调整

在这一阶段, 网络按照两种模式工作. 输出训练数据从第六层向下传送至第五层, 输入训练数据从第一层向上传送至第二层. 输入输出模糊隶属函数的方差固定, 均值参考 Kohonen 自组织特征映射学习进行调整^[3]. 调整模糊隶属函数均值的目的是为了有效分配网络资源, 使得隶属函数更好地覆盖训练数据所提供的输入输出空间. 输入隶属函数均值的调整方法如下

$$\|x(t) - m_{closest}\| = \min_{1 \leq i \leq k} \{\|x(t) - m_i(t)\|\} \quad (10)$$

$$m_i(t+1) = m_i(t) + \alpha(t)[x(t) - m_i(t)] \text{ for } m_i = m_{closest} \quad (11)$$

$$m_i(t+1) = m_i(t) \text{ for } m_i \neq m_{closest} \quad (12)$$

其中, $x(t)$ 是输入训练数据, $\alpha(t)$ 是单调递减的学习因子, k 是输入变量模糊分割的个数. 输出隶属函数均值的调整采用完全类似的方法.

3.2 学习阶段二: 模糊规则的抽取

模糊隶属函数的参数经过第一阶段的初步调整后, 再将输入输出训练数据从网络的两端送入. 输入训练数据首先到达第二层的区间节点, 同时计算得到 O_i^2 , 通过第三层的连接权值和 O_i^2 , 可以得到第三层规则节点的激活强度 O_i^3 . 输出训练数据按照从上至下的传递模式可以到达第四层的区间节点, 同时计算得到 X_j^4 . 现在的任务是为每个规则节点找到正确的与输出区间节点的映射关系, 即 $N_1 \times N_2$ 条规则. 为了完成这个任务, 本文提出了一个新的学习算法, 称作最小相关 - 最大匹配算法 (Correlation-minimum and maximum-matching algorithm, CMMM). 具体如下:

Step 1. 所有训练数据依次送入网络, 计算第四层的连接权值 W_{ij} (初值为 0, $i = 1, 2, \dots, N_1 \times N_2$, $j = 1, 2, \dots, N_3$). 对于每一对输入输出训练数据, W_{ij} 按照下式更新

$$W_{ij \max} = W_{ij \max} + O_i^3 \times X_{j \max}^4 \quad (13)$$

其中, $j \max$ 表示被每一个输出训练数据激活的第四层的区间节点中, 激活强度最大的那个节点. 其它区间节点的连接权值不更新.

Step 2. 从 W_{ij} 中抽取和优化模糊规则. 和第三层的每个规则节点连接的 N_3 个连接权值分别与一给定的阈值比较. 如果所有的连接权值都小于给定的阈值, 那么这个规则节点和它的连接权值将被删除. 反之, N_3 个连接权值中最大的那个被置为 1, 即确定了这个规则节点和一个输出区间节点的映射关系, 同时, 其余的连接权值被置为 0.

经过第二阶段的学习后, 最多可以得到 $N_1 \times N_2$ 条模糊规则. 删除的规则节点被认为对任一输出区间节点仅有很小的作用或根本不起作用. 阈值的选取可以参照经验和精度要求.

与文献 [8] 的算法相比, 本文的算法把 $X_{j \max}^4$ 引入到权值的更新计算中, 因此可以更充分利用输入输出训练数据提供的信息, 提取出更准确的模糊规则, 并且在相同的阈值条件下, 获得的规则总数更少.

3.3 学习阶段三：基于监督学习的参数优化

当抽取出模糊规则，即确定了网络第三层与第四层的映射关系后，整个神经模糊推理网络的结构被完全确定下来。本阶段的学习任务是优化模糊隶属函数的参数，进一步提高模糊辨识的精度。在这一阶段，使用梯度下降法优化模糊隶属函数的均值和方差，使得下式的误差函数最小

$$E = \frac{1}{2}(y(k) - \hat{y}(k))^2 \quad (14)$$

其中， $y(k)$ 为期望输出， $\hat{y}(k)$ 为实际输出。对于每一对输入训练数据，网络按照从下至上的工作模式，计算得到网络的实际输出。根据实际输出与输出训练数据（期望输出）的差值，误差 E 按照链式规则，逐步计算得到每一层的误差梯度，进而修正模糊隶属函数的均值和方差。

下面，我们逐层推导给出梯度下降法的学习过程，其中， δ_i^n 表示第 n 层第 i 个节点的误差梯度， η 为单调递减的学习率。

第六层：参照 (14) 式，本层的误差梯度为

$$\delta_1^6 = -\frac{\partial E}{\partial O_1^6} = y(k) - \hat{y}(k) \quad (15)$$

第五层：结合 (6) 与 (15) 式输出隶属函数的均值按照下式更新

$$m_i^5(t+1) = m_i^5(t) + \eta \delta_1^6 \frac{\partial O_1^6}{\partial m_i^5} = m_i^5(t) + \eta \delta_1^6 \frac{\sigma_i^5 I_i^6}{\sum_{i=1}^{N_3} \sigma_i^5 I_i^6} \quad (16)$$

类似地，输出隶属函数的方差按照下式更新

$$\sigma_i^5(t+1) = \sigma_i^5(t) + \eta \delta_1^6 \frac{\partial O_1^6}{\partial \sigma_i^5} = \sigma_i^5(t) + \eta \delta_1^6 \frac{m_i^5 I_i^6 (\sum_{i=1}^{N_3} \sigma_i^5 I_i^6) - (\sum_{i=1}^{N_3} m_i^5 \sigma_i^5 I_i^6) I_i^6}{(\sum_{i=1}^{N_3} \sigma_i^5 I_i^6)^2} \quad (17)$$

结合 (6) 与 (15) 式，本层的误差梯度计算如下

$$\delta_i^5 = -\frac{\partial E}{\partial O_i^5} = -\frac{\partial E}{\partial O_1^6} \frac{\partial O_1^6}{\partial O_i^5} = \delta_1^6 \frac{m_i^5 \sigma_i^5 (\sum_{i=1}^{N_3} \sigma_i^5 O_i^5) - (\sum_{i=1}^{N_3} m_i^5 \sigma_i^5 O_i^5) \sigma_i^5}{(\sum_{i=1}^{N_3} \sigma_i^5 O_i^5)^2} \quad (18)$$

第四层：本层没有参数被修正。结合 (5) 与 (18) 式，本层的误差梯度计算如下

$$\delta_i^4 = -\frac{\partial E}{\partial O_i^4} = -\frac{\partial E}{\partial O_i^5} \frac{\partial O_i^5}{\partial O_i^4} = \delta_i^5 \frac{1}{\sum_{i=1}^{N_3} O_i^4} \quad (19)$$

第三层：本层没有参数被修正。结合 (4) 式，本层的误差梯度计算如下

$$\delta_i^3 = -\frac{\partial E}{\partial O_i^3} = \sum_{j=1}^{N_3} (-\frac{\partial E}{\partial O_j^4} \frac{\partial O_j^4}{\partial O_i^3}) = \sum_{j=1}^{N_3} (W_{ij} \delta_j^4), \quad i = 1, 2, \dots, N_1 \times N_2 \quad (20)$$

说明: 抽取模糊规则后, 和第三层的每个规则节点连接的 W_{ij} 中, 仅有一个为 1, 即一条模糊规则. 所以 (20) 式的计算结果为对应于 W_{ij} 等于 1 的 δ_j^4 .

第二层

$$\delta_i^2 = -\frac{\partial E}{\partial O_i^2} = \sum_{j=1}^{N_1 \times N_2} \left(-\frac{\partial E}{\partial O_j^3} \frac{\partial O_j^3}{\partial O_i^2} \right) = \sum_{j=1}^{N_1 \times N_2} (\delta_j^3 \frac{\partial O_j^3}{\partial O_i^2}), \quad i = 1, 2, \dots, N_1 + N_2 \quad (21)$$

结合 (4) 与 (5) 式, 得到

$$\frac{\partial O_j^3}{\partial O_i^2} = \begin{cases} 1, & \text{如果 } O_i^2 \text{ 是第 } j \text{ 个规则节点输入的最小值} \\ 0, & \text{其它} \end{cases} \quad (22)$$

接下来, 修正输入模糊隶属函数的参数. 结合 (2)、(21) 和 (22) 式, 输入模糊隶属函数的均值按照下式更新

$$m_i^2(t+1) = m_i^2(t) + \eta \delta_i^2 \frac{\partial O_i^2}{\partial m_i^2} = m_i^2(t) + \eta \delta_i^2 \exp\left[-\left(\frac{I_i^2 - m_i^2}{\sigma_i^2}\right)^2\right] \frac{2(I_i^2 - m_i^2)}{(\sigma_i^2)^2} \quad (23)$$

类似地, 输入模糊隶属函数的方差按照下式更新

$$\sigma_i^2(t+1) = \sigma_i^2(t) + \eta \delta_i^2 \frac{\partial O_i^2}{\partial \sigma_i^2} = \sigma_i^2(t) + \eta \delta_i^2 \exp\left[-\left(\frac{I_i^2 - m_i^2}{\sigma_i^2}\right)^2\right] \frac{2(I_i^2 - m_i^2)^2}{(\sigma_i^2)^3} \quad (24)$$

与传统的基于梯度下降法修正网络参数的方法相比, 本文方法的不同和优势在于: 1) 修正参数少. 待修正的参数仅为模糊隶属函数的参数, 因此算法运行速度快. 2) 收敛速度快. 我们的梯度下降学习是在参数经过初步调整后的基础上进行的, 因此可以克服由于网络初值设置不当引起的算法收敛速度慢和不易稳定的困难.

4 系统仿真

为了验证上述神经模糊推理网络的模型和学习算法应用于模糊辨识的有效性, 我们选择文献 [8] 中的二阶非线性离散系统作为仿真实例. 待辨识的系统模型如下:

$$y(k) = \frac{y(k-1)y(k-2)[y(k-1) + 2.5]}{1 + y^2(k-1) + y^2(k-2)} + u(k) \quad (25)$$

选择 $u(k)$, $y(k-1)$ 和 $y(k-2)$ 作为输入变量, $y(k)$ 作为输出变量. 每个输入变量被分割成 5 个模糊集, 输出变量包含 9 个模糊集, 因此可以确定网络每一层的节点数. 假定系统的初始状态为 0, 输入变量 $u(k) = 2 \sin(2\pi k/25)$, 分布在 $[-2, 2]$, 通过连续采样 50 个时刻的系统状态和输出, 分布在 $[-4, 6]$, 我们获得了 50 对输入输出训练数据. 假定输入输出模糊隶属函数的均值与方差的初值均匀覆盖输入输出空间, 按照下面的方法确定 (n 为模糊分割的个数):

模糊隶属函数的均值

$$m_i = \min + \frac{\max - \min}{n+1} i \quad (26)$$

模糊隶属函数的方差

$$\sigma_i = \frac{2(\max - \min)}{3(n+1)} \quad (27)$$

在学习阶段一, 根据输入输出训练数据, 初步调整 24 个模糊隶属函数的均值. 学习率为单调递减的函数 $e^{(-0.6-\frac{k}{100})}$. 在学习阶段二, 根据我们提出的最小相关 - 最大匹配算法计算第四层的连接权值. 当阈值选择 0.02 时, 提取出与训练数据相匹配的 28 条模糊规则. 我们使用如下的均方误差函数 (Mean square error, MSE) 作为性能评估函数

$$MSE = \frac{1}{N} \sum_{k=1}^N (y(k) - \hat{y}(k))^2 \quad (28)$$

其中, $y(k)$ 为期望输出, $\hat{y}(k)$ 为模糊辨识器的输出, N 为采样点的个数. 经过前两个阶段的学习, 模糊辨识器的均方误差为 0.0896. 仿真曲线如图 2 所示.

为了比较, 在相同的条件下, 按照文献 [8] 的网络结构和模糊规则抽取方法进行仿真, 提取得到 29 条模糊规则, 均方误差为 0.1462, 仿真曲线如图 3. 可以看出, 应用本文的方法, 在使得模糊规则数目更小的同时, 也可以获得较小的均方误差, 模糊辨识器的跟踪速度快.




图 2 期望输出与经过前两个阶段学习后的辨识器输出

Fig. 2 Expected output and identifier output after the first and the second learning steps




图 3 期望输出与文献 [8] 的辨识器输出

Fig. 3 Expected output and identifier output of Reference [8]

当初步调整了模糊隶属函数的参数和提取模糊规则后, 我们就可以应用学习阶段三来优化模糊隶属函数的参数. 选择输出模糊隶属函数参数的学习率为 $e^{(\log 0.1-k/500)}$, 输入模糊隶属函数参数的学习率为 $e^{(\log 0.001-k/500)}$. 50 对训练数据依次送入网络, 共循环 10 次, 学习次数为 500 次. 图 4 为每当所有训练数据循环一次后, 计算的均方误差的变化曲线. 经过 10 次循环后, 期望输出与实际输出的均方误差为 0.0452, 仿真曲线如图 5. 经过参数优化后的输入输出模糊隶属函数如图 6 所示.




图 4 均方误差曲线

Fig. 4 Mean square error






图 5 期望输出与三个学习阶段结束后的辨识器输出

Fig. 5 Expected output and identifier output after the all three learning steps



(a) 输入 $u(k)$ 的模糊隶属函数
(Fuzzy membership function of Input $u(k)$)



(b) 输入 $y(k-1)$ 的模糊隶属函数
(Fuzzy membership function of Input $y(k-1)$)




图 6 经过参数优化后的输入输出模糊隶属函数

Fig. 6 The optimized input and output fuzzy membership functions

5 结语

本文提出和构造了一种新的神经模糊推理网络和学习算法,用来解决基于输入输出数据的复杂系统的模糊辨识问题.我们的方法充分利用了神经网络的分布式处理和学习能力,综合考虑了对辨识精度、收敛速度、可读性和规则数的要求.

在结构辨识阶段,我们提出了一种新的直接从训练数据中抽取和优化模糊规则的学习算法,该算法充分利用了训练数据提供的信息,使得提取出的模糊规则数目更少、更准确和更容易理解.参数辨识分为初步调整和优化两个阶段,基于我们的神经模糊推理网络,提出和推导了自组织特征映射和梯度下降法相结合的混合式学习算法.该算法主要具有如下两方面的优势:1) 经过初步调整后的参数使得网络在梯度下降学习阶段具有较快的收敛速度和良好的稳定性.2) 由于在梯度下降学习阶段,整个网络的待修正参数仅为模糊隶属函数的参数,因此算法实现简单,执行速度快.

应该指出的是,本文的研究没有涉及到输入输出模糊空间的分割问题,但是,我们认为这并不影响研究的意义,原因在于本文的工作是相对独立的,采用不同的方法对输入输出模糊空间进行分割后,可以简单方便的与本文的网络结构和学习算法相融合,进而解决复杂系统的模糊辨识问题.对于另一种使用较多的 T-S 模糊模型,本文的网络结构和学习算法也具有借鉴意义,考虑到 T-S 模糊模型的建模精度更高,有望取得更好的辨识效果.此外,本文的思想和方法对于复杂系统的模糊建模与控制问题也具有相当的启示意义.

在实际中,复杂系统的辨识绝不是一个简单的问题,涉及到结构辨识和参数辨识的诸多环节,辨识效果取决于多种因素的共同作用.从某种意义上,系统辨识应该被认为是一个需要使用者积极参与的、交互式的反复实验的过程.

References

- 1 Wang H W, Ma G F. Nonlinear systems modeling via fuzzy logic rules. *Control Theory and Applications*, 2000, **17**(3): 419~422
- 2 Emami M R, Turksen B, Goldenberg A A. Development of a systematic methodology of fuzzy logic modeling. *IEEE Transactions on Fuzzy Systems*, 1998, **6**(3): 346~361
- 3 Lin C T, Lee C S G. Neural-network-based fuzzy logic control and decision system. *IEEE Transactions on Computers*, 1991, **40**(12): 1320~1336
- 4 Lin C T, Lee C S G. Real-time supervised structure/parameter learning for fuzzy neural network. In: *Proceeding of IEEE International Conference on Fuzzy Systems*. San Diego, CA, USA: IEEE Press, 1992. 1283~1290
- 5 Jang J S R. ANFIS: Adaptive-network-based fuzzy inference systems. *IEEE Transactions on Systems, Man, and Cybernetics*, 1993, **23**(3): 665~685
- 6 Kim S H, Kim Y H, Sim K B, Jeon H T. On developing an adaptive neural-fuzzy control system. In: *Proceedings of IEEE/RSJ International Conference on Intelligent Robots and Systems*. Yokohama, Japan: IEEE Press, 1993. 950~957

- 7 Juang C F, Lin C T. An on-line self-constructing neural fuzzy inference network and its applications. *IEEE Transactions on Fuzzy Systems*, 1998, **6**(1): 12~32
- 8 Farag W A, Quintana V H, Torres G L. A genetic-based neuro-fuzzy approach for modeling and control of dynamical systems. *IEEE Transactions on Neural Networks*, 1998, **9**(5): 756~767
- 9 Wang J S, Lee C S G. Structure and learning in self-adaptive neural fuzzy inference systems. *International Journal of Fuzzy Systems*, 2000, **2**(1): 12~22
- 10 Chakraborty D, Pal N R. Integrated feature analysis and fuzzy rule-based system identification in a neural-fuzzy paradigm. *IEEE Transactions on Systems, Man, and Cybernetics-Part B*, 2001, **31**(3): 391~422
- 11 Babuska R. Neural-fuzzy methods for modeling and identification. Recent Advances in Intelligent Paradigms and Applications. Abraham A, Jain L C, Kacprzyk J eds., Heidelberg, Germany: Physica-Verlag, 2003. 161~186

李佳宁 助理研究员, 博士. 主要研究方向为智能控制、信息组织与检索.

(**LI Jia-Ning** Assistant professor, Ph.D.. Her research interests include intelligent control, information organization and retrieval.)

易建强 研究员, 博士生导师. 主要研究方向为智能控制、机器人.

(**YI Jian-Qiang** Ph.D., professor. His research interests include intelligent control and robotics.)

赵冬斌 副研究员, 硕士生导师. 主要研究方向为智能控制、机器人.

(**ZHAO Dong-Bin** Ph.D., associate professor. His research interests include intelligent control and robotics.)

西广成 研究员, 博士生导师. 主要研究方向为复杂系统理论与应用.

(**XI Guang-Cheng** Professor. His research interests include theory and applications of complex system.)