

# 混沌时间序列的模糊神经网络预测<sup>\*</sup>

谭 文<sup>1)2)</sup> 王耀南<sup>2)</sup> 周少武<sup>1)</sup> 刘祖润<sup>1)</sup>

<sup>1)</sup> 湘潭工学院信息与电气工程系, 湘潭 411201)

<sup>2)</sup> 湖南大学电气与信息工程学院, 长沙 410082)

(2002 年 6 月 27 日收到, 2002 年 8 月 28 日收到修改稿)

设计一种新型混合模糊神经推理系统, 该系统仅从期望输入输出数据集即可达到获取知识、确定模糊初始规则基的目的. 再利用神经网络学习能力便不难修改规则库中的模糊规则以及隶属函数和网络权值等参数, 这样大大减少了规则匹配过程, 加快了推理速度, 从而极大地提高了系统的自适应能力. 用它对 Mackey-Glass 混沌时间序列进行预测试验, 结果表明利用该网络模型无论离线还是在线学习均能对 Mackey-Glass 混沌时间序列进行准确的预测, 证明了该系统的有效性.

关键词: 神经网络模型, 模糊逻辑, 混合推理系统, 混沌时间序列

PACC: 0545

## 1. 引言

在复杂非线性系统建模、辨识与控制研究中, 模糊逻辑系统和神经网络理论无疑是当今研究的热点. 模糊逻辑使人们易于将先验的系统知识结合到模糊规则中, 神经网络善于对网络参数进行自适应学习, 同时具有强大的并行处理能力和泛化能力. 因此, 将模糊逻辑的概念“抽象能力”和非线性处理能力与神经网络的自学习能力以及任意函数的逼近能力两者有机结合起来, 使系统既有模糊逻辑推理功能, 又赋予网络权值以明确的模糊逻辑意义. 迄今为止, 已开发出了许多具有学习能力的模糊系统模型, 如神经网络驱动的模糊推理系统, Mamdani 型模糊推理模型, Tsukamoto 型模糊推理模型以及 Takagi-Sugeno 型模糊推理模型<sup>[1-3]</sup>.

非线性混沌的研究是当今热门话题, 李智等运用自适应方法对几类混沌系统进行了有效的控制和识别<sup>[4,5]</sup>, 张家树等采用少参数二阶 Volterra 滤波器及自适应高阶非线性滤波等方法对混沌时间序列进行了预测研究<sup>[6-8]</sup>. 本文中提出了一种基于神经网络模型与模糊逻辑相结合的混合推理系统. 该系统

利用神经网络强大的学习能力及模糊逻辑的推理作用, 仅从期望输入输出样本数据对通过混合学习算法, 即可达到获取知识、确定模糊初始规则基的目的. 再利用神经网络学习能力便不难修改规则库中的模糊规则以及隶属函数和网络权值等参数, 这样大大减少了规则匹配过程, 加快了推理速度, 从而极大地提高了系统的自适应能力. 用它对 Mackey-Glass 混沌时间序列作预测试验, 结果表明了该系统的有效性.

## 2 系统模型结构

本文所提出的模糊神经模型为多层模糊神经网络. 下面以图 1 所示拓扑结构为例, 对网络各层关系进行描述. 设网络结构中的第  $L$  层的第  $b$  个节点的输入为  $I_b^{(L)}$ , 输出为  $O_b^{(L)}$ , 并用  $h, i, j, k, l$  分别表示第一层、第二层、第三层、第四层和第五层的神经元标号, 各层之间输入输出关系表示如下:

第一层 输入层. 该层每个神经元表示一个输入变量, 在这一层中的神经元直接将输入值送到下一层的神经元,

$$I_h^{(1)} = x_h, O_h^{(1)} = I_h^{(1)}, \quad (1)$$

式中  $h = 1, 2, \dots, m$  为  $m$  个输入量.

<sup>\*</sup> 国家自然科学基金(批准号 60075008)资助的课题.




图1 神经模糊推理系统结构示意图

第二层 模糊化层. 该层神经元用于实现规则的前件命题, 将上一层的清晰输入变量模糊化. 这一层的神经元与上一层的神经元连接权值均为 1, 每个神经元的隶属函数取为 Gaussian 型, 输入输出关系式为

$$I_i^{(2)} = O_h^{(1)}, \quad O_i^{(2)} = e^{-((I_i^{(2)} - c_i)^2 / \sigma_i^2)}, \quad (2)$$

式中  $c_i$  和  $\sigma_i$  分别表示隶属函数的中心和宽度, 为待调节的可变参数.

第三层 规则层. 该层的神经元与第二层神经元的连接强度全为 1, 规则神经元完成模糊逻辑“与”操作. 即

$$O_j^{(3)} = \min_{i \in I_j} (O_i^{(2)}), \quad (3)$$

式中  $I_j$  表示与第三层第  $j$  个神经元连接的第二层神经元的下标集,  $O_i^{(2)}$  为第二层第  $i$  个神经元的输出.

第四层 结论层. 该层每个神经元的隶属函数取为 Gaussian 型, 与第三层神经元的初始连接权值在  $[-1, +1]$  之间随机选取, 每条规则激活程度由权值平方决定. 该层函数表示如下:

$$O_k^{(4)} = \max_{j \in I_k} (O_j^{(3)} w_{kj}^2), \quad (4)$$

式中  $I_k$  表示与第四层第  $k$  个神经元连接的第三层所有神经元的下标集.

第五层 清晰化层. 本层神经元及与之相连的权值实现解模糊作用. 本处采用面积中心法进行解模糊, 最终输出信号可表示为

$$O_l^{(5)} = \frac{\sum_{k \in I_l} O_k^{(4)} \sigma_{lk} c_{lk}}{\sum_{k \in I_l} O_k^{(4)} \sigma_{lk}}, \quad (5)$$

式中  $I_l$  表示与第五层第  $l$  个神经元相连的第四层神经元的下标集,  $c_{lk}$  和  $\sigma_{lk}$  分别表示第四层第  $k$  个神经元的输出语言变量隶属函数的中心和宽度, 该神经元与第五层第  $l$  神经元相连, 这层神经元与第四层神经元的连接权值为单位向量. 因此整个网络需学

习的权值只有第四层神经元与第三层神经元之间的连接权值  $w_{kj}$ .

### 3. 混合学习算法

在模糊神经推理系统模型中, 学习过程分两个步骤, 即“结构学习阶段”找到合适的模型逻辑(FL)规则和“参数学习阶段”对隶属函数及网络参数进行微调. 系统的结构决定了模糊规则的条数及输入输出语言变量模糊子集个数, 而参数学习则决定了每条规则的具体表达及隶属函数形状.

#### 3.1 结构学习阶段

在模糊推理系统的设计过程中, 模糊规则的识别是极为重要的一个方面. 从有限的学习样本数据获取 FL 规则有两个步骤: 1) 输入输出空间的模糊分割; 2) 每个模糊子空间的 FL 规则的识别. 本文采用 Wang 和 Mendel<sup>[9]</sup>提出的模糊技术从输入-输出样本数据中获得一组模糊规则.

为简单起见, 选择具有两个输入一个输出的系统为例对该方法加以说明. 假定有一批期望输入输出数据对  $(x_1^1, x_2^1; y^1), (x_1^2, x_2^2; y^2), \dots$ , 其中  $x_1$  和  $x_2$  为输入,  $y$  为输出. 该方法包括下面三步:

第一步 将输入输出空间分割成若干模糊子空间, 确定每个输入输出变量模糊标记, 然后按隶属函数的中心等分输入输出数据空间的原则初选隶属函数参数(即中心和宽度). 图 2 表示  $x_1, x_2, y$  的定义域分为 5 个区间.




图2 输入输出隶属函数

第二步: 从学习样本数据对产生模糊规则. 首先, 确定不同区间已知数据对的隶属度; 其次, 给  $x_1^i, x_2^i, y^i$  在某一区间赋最大隶属度; 最后, 从一对期望输入输出数据对得到一条规则.

第三步 给每条规则分配一个隶属度. 当规则具有相同的前件(IF)部分, 而后件(THEN)部分不同时, 可取规则强度最大的那条起作用, 即每条规则

$R_i$  若  $x_1$  为  $A$  和  $x_2$  为  $B$  则  $y$  为  $C(w_i)$  其强度可表示为

$$w_i = \mu_a(x_1)\mu_b(x_2)\mu_c(y).$$

这一阶段学习结束,既可解决规则冲突问题,又能得到简化的规则基.

3.2 参数学习阶段

一旦确定了模糊规则基,则整个网络结构也就建立起来.接下来的工作是通过网络的学习优化调整隶属函数形状以及网络权值.这里采用梯度下降学习算法使目标误差函数

$$E = \frac{1}{2} \sum_{l=1}^q (\hat{O}_l - O_l^{(5)})^2 \tag{6}$$

最小.式中  $q$  表示第五层神经元数, $\hat{O}_l$  和  $O_l^{(5)}$  分别表示第五层神经元  $l$  的目标输出和实际输出.权值修正式

$$w_{kj}(t+1) = w_{kj}(t) - \eta \left( \frac{\partial E}{\partial w_{kj}} \right), \tag{7}$$

式中  $w_{kj}$  为对应第四层  $k$  神经元和第三层  $j$  神经元的权值, $\eta$  为学习率,则根据链式求导法则可将(7)式改写为

$$\begin{aligned} w_{kj}(t+1) &= w_{kj}(t) - \eta \frac{\partial E}{\partial O_k^{(4)}} \frac{\partial O_k^{(4)}}{\partial w_{kj}} \\ &= w_{kj}(t) - \eta \frac{\partial E}{\partial O_l^{(5)}} \times \frac{\partial O_l^{(5)}}{\partial O_k^{(4)}} \frac{\partial O_k^{(4)}}{\partial w_{kj}}. \end{aligned} \tag{8}$$

而高斯隶属函数中心( $c$ )和宽度( $\sigma$ )计算过程如下:

步骤1 由方程(1)–(5)将网络输入转换成输出,步骤2 误差反传.

第5层 从方程(6)得到

$$\frac{\partial E}{\partial O_l^{(5)}} = -(\hat{O}_l - O_l^{(5)}). \tag{9}$$

因此传播到前一层的误差为

$$\delta_l^{(5)} = -\frac{\partial E}{\partial O_l^{(5)}} = \hat{O}_l - O_l^{(5)}. \tag{10}$$

用方程(6)推导出可调宽度  $\sigma$  参数的自适应规则如下:

$$\frac{\partial E}{\partial \sigma_{lk}} = \frac{\partial E}{\partial O_l^{(5)}} \frac{\partial O_l^{(5)}}{\partial \sigma_{lk}}. \tag{11}$$

将方程(5)代入(11)式得到

$$\frac{\partial O_l^{(5)}}{\partial \sigma_{lk}}$$

$$\begin{aligned} &= \frac{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'}) O_k^{(4)} c_{lk} - (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'} c_{lk'}) O_k^{(4)}}{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2} \\ &= \frac{O_k^{(4)} (c_{lk} (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'}) - (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'} c_{lk'}))}{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2} \end{aligned} \tag{12}$$

式中  $k'$  为第四层一个神经元的标号,它与第五层的  $l$  神经元相连.

将(9)和(12)式代入(11)式可变为

$$\begin{aligned} \frac{\partial E}{\partial \sigma_{lk}} &= \frac{\partial E}{\partial O_l^{(5)}} \frac{\partial O_l^{(5)}}{\partial \sigma_{lk}} \\ &= -(\hat{O}_l - O_l^{(5)}) \\ &\quad \times \frac{O_k^{(4)} (c_{lk} (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'}) - (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'} c_{lk'}))}{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2}. \end{aligned} \tag{13}$$

所以参数  $\sigma$  可按下式修正:

$$\begin{aligned} \sigma_{lk}(t+1) &= \sigma_{lk}(t) + \eta \delta_l^{(5)} \\ &\quad \times \frac{O_k^{(4)} (c_{lk} \sum_{k'} O_{k'}^{(4)} \sigma_{lk'}) - (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'} c_{lk'}))}{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2}. \end{aligned} \tag{14}$$

类似地,推导出可调中心  $c$  参数的自适应规则如下:

$$\begin{aligned} \frac{\partial E}{\partial c_{lk}} &= \frac{\partial E}{\partial O_l^{(5)}} \frac{\partial O_l^{(5)}}{\partial c_{lk}} \\ &= -(\hat{O}_l - O_l^{(5)}) \frac{\sigma_{lk} O_k^{(4)}}{\sum_k \sigma_{lk} O_k^{(4)}}. \end{aligned} \tag{15}$$

所以参数  $c$  可按下式修正:

$$c_{lk}(t+1) = c_{lk}(t) + \eta \delta_l^{(5)} \frac{\sigma_{lk} O_k^{(4)}}{\sum_k \sigma_{lk} O_k^{(4)}}. \tag{16}$$

第四层

该层所有神经元的误差是根据目标输出的解模糊及每个神经元的激活状况进行计算,只有误差信号需要计算和传播,因此有

$$\begin{aligned} \delta_k^{(4)} &= \frac{\partial E}{\partial O_k^{(4)}} \\ &= \frac{\partial E}{\partial O_l^{(5)}} \frac{\partial O_l^{(5)}}{\partial O_k^{(4)}}. \end{aligned} \tag{17}$$

由方程(5)得到

$$\frac{\partial O_l^{(5)}}{\partial O_k^{(4)}}$$

$$\sigma_{lk} (c_{lk} (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'}) - (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'} c_{lk'})) \\ = \frac{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2}{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2}. \quad (18)$$

因此利用方程(9)和(18),可以将方程(17)的误差信号变为

$$\delta_k^{(4)} = (\hat{O}_l - O_l^{(5)}) \\ \times \frac{\sigma_{lk} (c_{lk} (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'}) - (\sum_{k'} O_{k'}^{(4)} \sigma_{lk'} c_{lk'}))}{(\sum_{k'} O_{k'}^{(4)} \sigma_{lk'})^2}. \quad (19)$$

### 第三层

与第四层一样,该层没有参数需要调整,只有误差信号须计算然后反向传播,误差信号  $\delta_j^{(3)}$  按下式得出:

$$\delta_j^{(3)} = \frac{\partial E}{\partial O_j^{(3)}} \\ = \frac{\partial E}{\partial O_k^{(4)}} \frac{\partial O_k^{(4)}}{\partial O_j^{(3)}} \\ = S_{kj} \frac{\partial E}{\partial O_k^{(4)}} \\ = S_{kj} \delta_k^{(4)}, \quad (20)$$

式中当第三层第  $j$  个神经元的输出加权平方为第四层第  $k$  个节点输入的最大值时,  $S_{kj} = w_{kj}^2$ , 否则,

$$S_{kj} = 0.$$

### 第二层

利用方程(2)和(8)等号右边一部分,推导出可调中心  $c$  参数的自适应规则如下:

$$\frac{\partial E}{\partial c_i} = \frac{\partial E}{\partial O_i^{(2)}} \frac{\partial O_i^{(2)}}{\partial c_i} \\ = \frac{\partial E}{\partial O_i^{(2)}} O_i^{(2)} \frac{\chi(f_i^{(2)} - c_i)}{\sigma_i^2}. \quad (21)$$

由方程(3)得到

$$\frac{\partial E}{\partial O_i^{(2)}} = \frac{\partial E}{\partial O_j^{(3)}} \frac{\partial O_j^{(3)}}{\partial O_i^{(2)}}. \quad (22)$$

由方程(20)得到

$$\frac{\partial E}{\partial O_j^{(3)}} = \delta_j^{(3)}. \quad (23)$$

于是从方程(3)和(20)得出

$$r = \text{Arg} \min_{i \in I_i} (O_i^{(2)}), \quad (24)$$

于是

$$\frac{\partial E}{\partial O_i^{(2)}} = \begin{cases} \sum_j \delta_j^{(3)} & \text{若 } i = r; \\ 0 & \text{其他.} \end{cases} \quad (25)$$

输入变量隶属函数的中心可按式修正:

$$c_i(t+1) = c_i(t) + \eta \frac{\partial E}{\partial O_i^{(2)}} O_i^{(2)} \\ \times \frac{\chi(f_i^{(2)} - c_i)}{\sigma_i^2}. \quad (26)$$

类似地,用方程(2)和(8)可推导出  $\sigma_i$  的自适应规则

$$\frac{\partial E}{\partial \sigma_i} = \frac{\partial E}{\partial O_i^{(2)}} \frac{\partial O_i^{(2)}}{\partial \sigma_i} \\ = \frac{\partial E}{\partial O_i^{(2)}} O_i^{(2)} \frac{\chi(f_i^{(2)} - c_i)}{\sigma_i^3}. \quad (27)$$

因此,输入变量隶属函数的参数  $\sigma_i^{(2)}$  可按式修正:

$$\sigma_i(t+1) = \sigma_i(t) + \eta \frac{\partial E}{\partial O_i^{(2)}} O_i^{(2)} \\ \times \frac{\chi(f_i^{(2)} - c_i)}{\sigma_i^3}. \quad (28)$$

步骤3 确定学习是否成功.设均方误差(MSE)为

$$\text{MSE} = \frac{1}{N} \sum_{i=1}^N (O_i - \hat{O}_i)^2, \quad (29)$$

式中  $N$  为训练样本个数,  $\hat{O}_i, O_i$  分别为第  $i$  个目标输出和实际输出,当 MSE 小于某个预先给定的误差值时,学习成功结束,否则,转步骤1.

## 4. 混沌动力系统的预测

实践研究表明,将模糊集合理论与神经网络技术结合起来的新型预测方法在复杂系统建模中具有独特的优越性,并在天气预报、地质科学、信号处理、工业过程控制等领域得到了成功而广泛地应用.自1977年 Mackey 和 Glass<sup>[10]</sup>首次发现时滞系统中的混沌现象以来,时滞混沌系统便引起了人们的广泛关注.但由于时滞系统具有无穷维状态空间,使得时滞系统的研究变得十分困难,本文将 Mackey-Glass 混沌时间序列预测作为仿真实例,以证明所提出系统的有效性,系统学习、辨识原理框图如图3所示.混沌时间序列可由时滞微分方程得到

$$\frac{dx(t)}{dt} = \frac{\alpha x(t-\tau)}{1+x^\gamma(t-\tau)} - \beta x(t), \quad (30)$$

令  $\alpha = 0.2, \beta = 0.1, \gamma = 10, \tau$  为惟一可调的参数, Mackey-Glass 方程称为时滞参数  $\tau$  的函数,其行为特性文献<sup>[11]</sup>已做过深入研究.当  $\tau > 17$  时方程(30)产生混沌(见图4),并具有分形维数近似为2.1的奇异吸引子.图5为  $\tau = 17$  时系统(30)式相图.

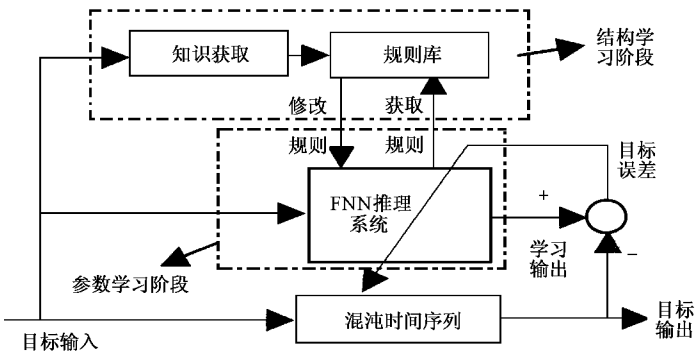


图3 模糊神经网络学习辨识原理框图




图4  $\tau=17$  时 Mackey-Glass 混沌时间序列




图5  $\tau=17$  时系统相图

4.1. 仿真实验

目的是根据  $t$  时刻以前的一组数据  $x(\cdot)$  ,去精确预测  $x(t+\Delta t)$  ,其中  $\Delta t$  为预测时间步幅。预测方法是令  $\Delta t$  为时滞参数 ,取  $D$  个点 ,即  $(x(t-(D-1)\Delta t), \dots, x(t-\Delta t), x(t))$  去预测将来时刻  $x(t+\Delta t)$  .若  $m$  为整数 ,实验任务是利用模糊神经模型构造函数

$$y(t+\Delta t)=f(x(t),x(t-\Delta t),x(t-2\Delta t),\dots,x(t-m\Delta t)), \tag{31}$$

式中  $f(\cdot)$  为  $m+1$  维空间上映射 , $y(t+\Delta t)$  为输出层一个神经元的输出 , $x$  取  $x(t),x(t-\Delta t),\dots,x(t-m\Delta t)$  为输入量 , $x(t+\Delta t)$  记为  $y(t+\Delta t)$  .根据文献 [12] 知 ,当  $\tau=17$  时  $\Delta t=6$  .选取 1000 对学习样本数据 ,即

$[x(t-18),x(t-12),x(t-6),x(t);x(t+6)](t=19,20,\dots,1018)$  .式中前 4 个数据为输入 ,最后一个为输出 ,记为  $x(t+\Delta t)$  .前 500 对(从  $x(1)$  到  $x(500)$ )当作训练数据 ,其余 500 对(从  $x(501)$  到  $x(1000)$ )用作测试数据以验证辨识模型的有效性 .输入输出变量的隶属函数模糊标记初选为 5 个 :VS (很小) ,S (小) ,M (中) ,L (大) 和 VL (很大) .

4.2. 在线自适应学习的仿真结果

对图 4 的混沌时间序列进行自适应方法的仿真研究 ,先用 500 个训练数据建立模糊规则基以形成整个网络结构 .然后对网络进行训练微调隶属函数的参数 ,使系统性能指标达到期望值 ,最后当出现新的样本数据对时 ,对现有的规则库进行在线修正 ,并用修正的网络模型去预测未来值 ,即对图 4 的混沌序列进行在线学习时 ,对从前 500 个数据集建立的网络进行训练调整各种参数 ,并以此模型预测下一个数据  $x(501)$  ,再用  $x(501)$  的估计值去修改模糊规则基 ,修正后的网络又去预测下一个数据  $x(502)$  ,这种自适应方法一直到第 1000 个数据  $x(1000)$  为止 .仿真结果如图 6 所示 ,比较其中的 (b) 与 (d) 图 ,不难发现 ,采用自适应预测方法 ,其效果明显大有改进 .

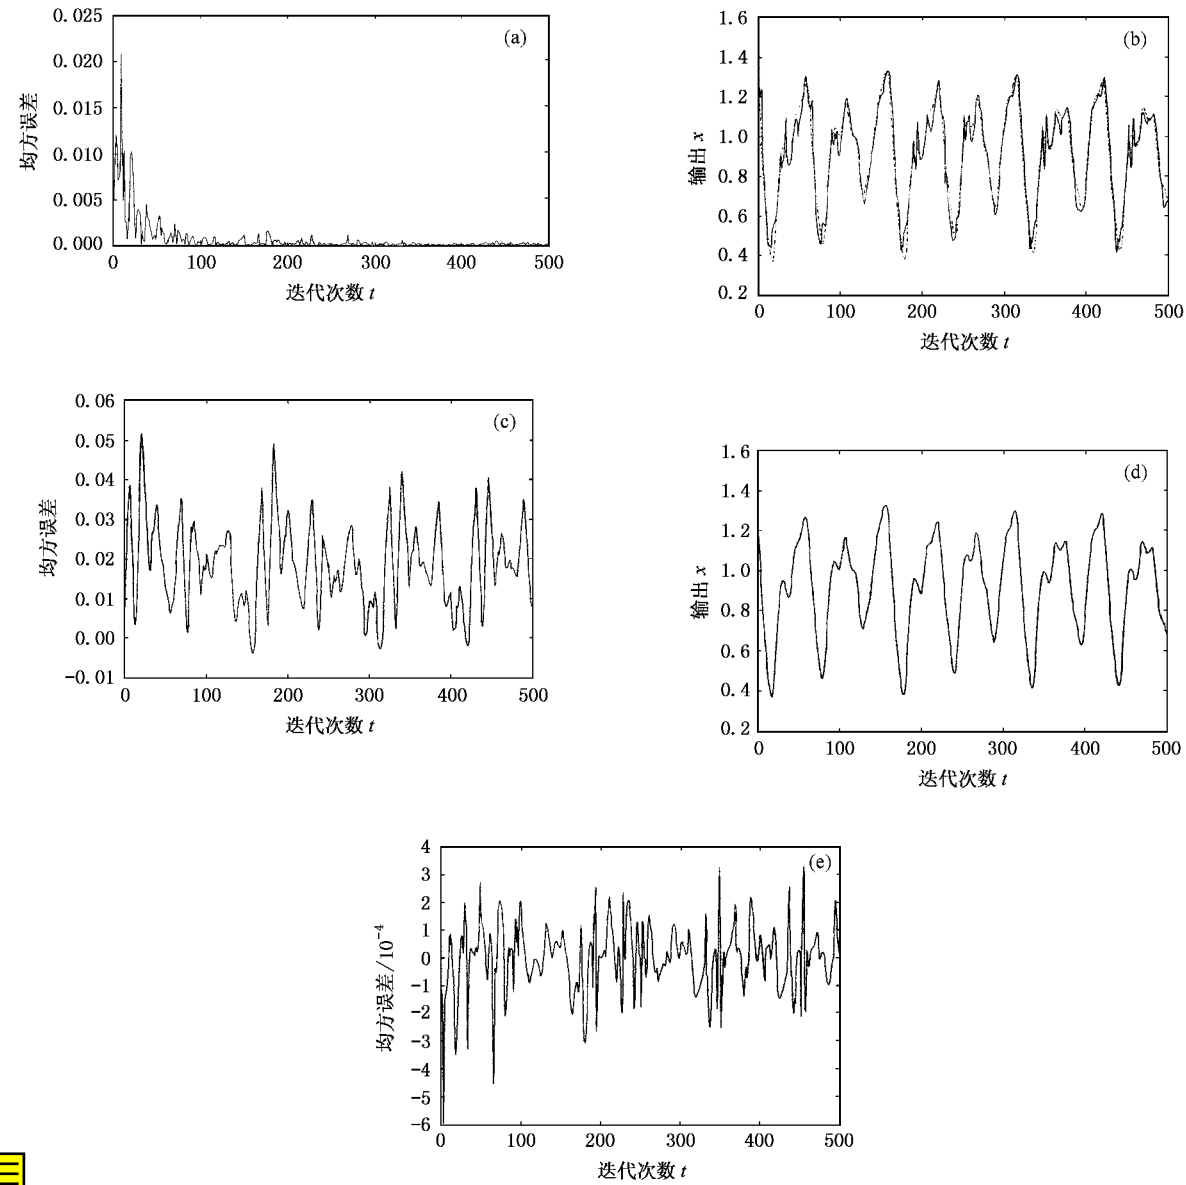


图 6 系统预测 Mackey-Glass 混沌时间序列仿真曲线 (a)为训练测试模型 MSE 曲线 (b)为目标(实线)与预测(虚线)时间序列 (c)为离线预测误差曲线 (d)为在线预测(虚线)时间序列及目标(实线)时间序列 (e)为在线预测误差曲线

5. 结 论

将神经网络(NN)理论与 FL 系统结合起来提出两阶段混合自适应学习方法,克服了基于先验知识

确定模糊规则及网络结构的困难,用 NN 实现模糊推理,加快了学习过程,提高了网络精度;而且得出的算法既可离线辨识复杂神经模糊模型,也可在线修正和调整模糊规则,为复杂非线性系统的辨识和混沌时间序列预测、控制提供了一条实际有效途径.

[ 1 ] Lin C T and Lee C S G 1991 *IEEE Trans. Comput.* **40** 1320

[ 2 ] Uehara K and Fujise M 1991 *IEEE Trans. Fuzzy Systems* **1** 205

[ 3 ] Kim J and Kasabov N 1999 *Neural Networks* **12** 1301

[ 4 ] Li Z H *et al* 2001 *Chin. Phys.* **10** 494

[ 5 ] Chen S H *et al* 2002 *Chin. Phys.* **11** 233

[ 6 ] Zhang J S *et al* 2000 *Acta Phys. Sin.* **49** 403 [ in Chinese ] 张家树等 2000 物理学报 **49** 403 ]

[ 7 ] Zhang J S *et al* 2000 *Acta Phys. Sin.* **49** 24 ( in Chinese ) 张家树等 2000 物理学报 **49** 24 ]

[ 8 ] Zhang J S *et al* 2001 *Acta Phys. Sin.* **50** 1248 ( in Chinese ) 张家树等 2001 物理学报 **50** 1248 ]

[ 9 ] Wang L X and Mendel J M 1992 *IEEE Trans. System, Man and Cybernetics* **22** 1414

[ 10 ] Mackey M C and Glass L 1977 *Science* **197** 287

[ 11 ] Farmer J D 1982 *Physica D* **3** 366

[ 12 ] Takens F 1981 Detecting Strange Attractor in turbulence , in Rand L and Young *Lecture Notes in Mathematics*( Berlin :Springer-Verlag ) p366

# Prediction of the chaotic time series using neuro-fuzzy networks \*

Tan Wen<sup>1 2)</sup> Wang Yao-Nan<sup>2)</sup> Zhou Shao-Wu<sup>1)</sup> Liu Zu-Run<sup>1)</sup>

<sup>1)</sup> Department of Information and Electrical Engineering , Xiangtan Polytechnic University ,Xiangtan 411201 ,China )

<sup>2)</sup> College of Electrical and Information Engineering ,Hunan University ,Changsha 410082 ,China )

( Received 27 June 2002 ; revised manuscript received 28 August 2002 )

Abstract

A novel hybrid neural fuzzy inference system is presented. Only based on the desired input-output data pairs , are the knowledge acquisition and initial fuzzy rule sets available. Then ,employing neural networks learning techniques , the fuzzy logic rules ,input-output fuzzy membership functions and weights in networks can be easily tuned. So the rule matching is reduced ,in-ferencing is accelerated , adaptability of the system is greatly improved. To illustrate the performance of the proposed neuro-fuzzy hybrid model , simulations on the chaotic Mackey-Glass time series prediction are performed. Combining either off-line or on-line learning with the proposed hybrid model , we can show that the chaotic Mackey-Glass time series are accurately predicted , and demonstrate the effectiveness of the model.

**Keywords :** neural network , fuzzy logic , hybrid inference system , chaotic time series

**PACC :** 0545

\* Project supported by the National Natural Science Foundation of China ( Grant No.60075008 ).