



# 基于多 ANN 模型的复杂系统长时段预报

高峰 李人厚

(西安交通大学系统工程研究所 西安 710049)

**摘要** 提出一种多 ANN 结构的极值聚类训练算法,并将这种方法应用于复杂系统长时段预报.采用这种方法,可以提高长时段预报精度、增强模型的可靠性.以这种模型为基础可以进一步建立基于多 ANN 模型的复杂系统预测控制.

**关键词** 多 ANN 结构,多层前馈网络,非线性系统预报.

## 1 引言

多 ANN 结构,是由多个相对独立、相互连接、协同作用的子 ANN 或称 ANN 模块组成的系统.它是一种新型的神经网络系统,是在更高层次上对人脑结构的模拟.人脑正是由于这种层次化、模块化的组织形式才产生出复杂、高级的智能行为.

用多 ANN 结构的方法可以得到高度可靠的神经网络系统,这种思想曾被许多 ANN 研究者用来解决复杂问题<sup>[1-4]</sup>.为了解决复杂函数的逼近问题,本文作者也曾采用了多 ANN 方法<sup>[5]</sup>,极大地改善了 ANN 的逼近能力.

## 2 多 ANN 结构

多 ANN 结构如图1所示,内部通常包含两种类型的网络:一是实现某种映射关系的子网络,二是协调各子网络之间关系的门控网络.一般在一个多 ANN 结构中,有多个子网络,而仅有一个门控网络.各子网络具有相同的输入但生成各自独立的输出,而整体的输出是门控网络对各子网络输出值的加权和:

$$y = \sum_{s=1}^n g_s \cdot y_s, \quad (1)$$

其中  $y_s$  表示第  $s$  个子网络的输出值.对于多 ANN 结构来说子网络的结构

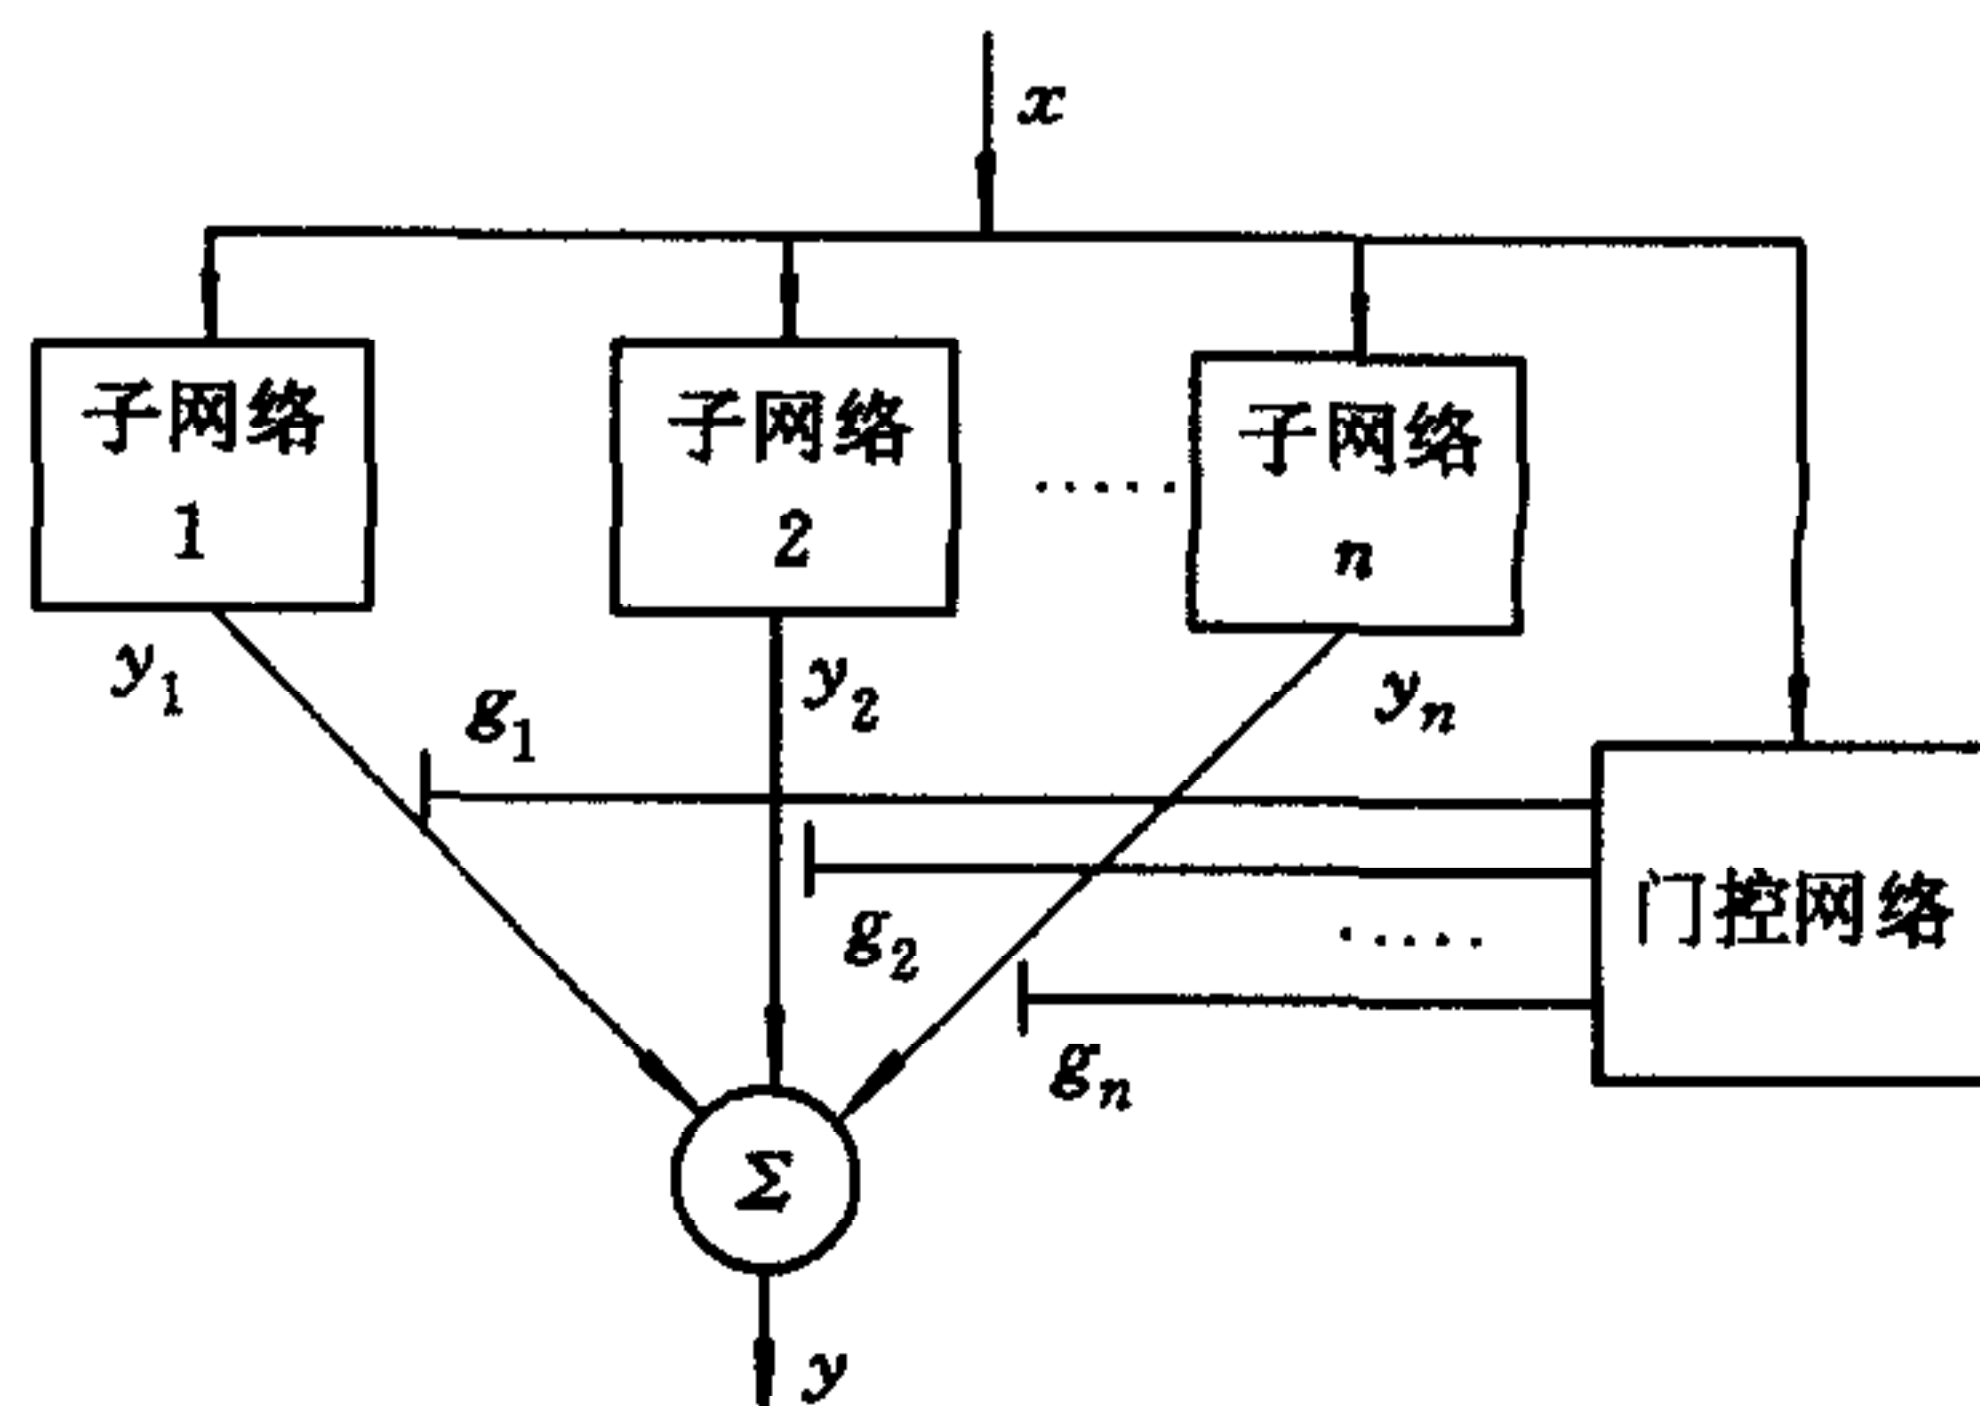


图1 多 ANN 结构示意图

形式可以是任意的, MFNN, RBF, FLN, CMAC 等都是可取的, 只要它们具有良好的对非线性映射的逼近特性. 这里为了使问题简化, 假设各子网络一律采用三层前馈网络的形式, 用式

$$y_s = W_s^2 \sigma(W_s^1 x + B_s^1) + B_s^2 \quad (2)$$

统一描述. 门控网络的输入与各子网络的输入相同, 对应于每一个子网络有一个输出量, (1)式中  $g_s$  表示其第  $s$  个输出. 门控网络的作用是分配各子网络在整体映射关系中的角色. 根据当前时刻的输入值, 按照某种原则产生输出, 即各子网络输出的加权值, 进而决定对各子网络的选择性. 门控网络的特性决定了整个多 ANN 结构的工作情况.

### 3 基于极值聚类的多 ANN 训练算法

#### 3.1 极值聚类算法

现有的多 ANN 结构聚类实现方法, 往往只是对输入空间进行聚类, 没有考虑样本的输出特征, 得到的划分仅仅体现了样本输入的分布关系, 不能体现出函数映射本身的简单性或复杂性.

通过对 MFNN 的分析可以知道, MFNN 实现的映射是由各隐节点决定的一组饱和和上升曲面加权叠加. 划分子区域必须使各子区域中函数易于用这种曲面叠加形式来逼近, 这就是 MFNN 对函数简单性的要求. 从这一特点出发, 如果划分使得各区域中函数都是单极值的, 那么在各区域中用子网络逼近时, 隐节点的方向几乎都是指向极值点或与此相反, 隐节点之间的耦合现象非常少, 逼近比较容易.

为得到这种划分形式, 就要对样本集合进行极值聚类. 对此提出一种简捷而有效的搜索样本集局部极值点的方法, 可以对样本集中蕴涵的函数关系进行极值聚类.

设样本集合为  $\{(x_i, y_i), i=1, 2, \dots, P\}$ , 则极值聚类算法如下:

1) 设置初始值. 确定样本划分类数  $K$ , 选择  $K$  个初始聚类中心.

2) 按样本输入值的邻近关系, 确定样本集中各样本的归属关系. 对于第  $i$  个样本  $(x_i, y_i)$ , 如果  $\|x_i - c_k\| < \|x_i - c_j\|$ ,  $j=1, 2, \dots, K$ ,  $C_k$  和  $C_j$  为第  $k$  和第  $j$  个样本子集的聚类中心, 则  $(x_i, y_i) \in D_k$ ,  $D_k$  表示第  $k$  个样本聚类中心的子集.

3) 按下面的关系更新聚类中心: 搜索局部极大值时, 对第  $k$  个聚类, 如果有  $(x_i, y_i) \in D_k$ , 满足对  $\forall (x_j, y_j) \in D_k$ , 有  $y_j \leq y_i$ , 则选择  $(x_i, y_i)$  作为新的第  $k$  个聚类的聚类中心. 即取聚类域中具有最大的样本输出值的样本作为新的聚类中心. 同理, 搜索局部极小值时, 取聚类域中具有最小的样本输出值的样本作为新的聚类中心.

4) 检查聚类中心是否发生了变化: 是, 则返回 2.

5) 检查聚类中心是否临近, 即是否存在  $\|c_i - c_k\| < \epsilon$ , ( $\epsilon > 0$ ), 是则归并最相邻的两类, 然后返回 2; 否则算法结束.

以这一算法为基础, 可以这样完成对训练集的划分: 先求出样本集的局部极大值中心, 再求出局部极小值中心, 将所求出的中心合并为样本集极值中心集, 再按邻近原则(即算法第 2 步)重新划分样本区域.

极值聚类与其它多 ANN 结构中子网络功能划分和协作方法不同的是, 不仅利用了样本集的输入, 同时利用了样本集的输出, 进行的是针对函数关系的聚类. 通过划分降低

了函数的复杂性,所确定的子任务是子网络易于实现的,具有明确的几何意义,子网络的数目也是由问题的复杂性所决定的.

### 3.2 多 ANN 结构的极值聚类训练算法

由此可以得到基于极值聚类的多 ANN 训练算法:

1) 对整体样本集按极值聚类算法进行划分,选择初始分类数  $K = \text{样本总数}/50$ ,经分类及归并后可以得到  $K$  个极值聚类中心  $c_k, k=1, 2, \dots, K$ . 由邻近原则确定各子类的子样本集  $D_k$ ;

2) 初始化各子网络  $\text{ANN}_k$ , 在各训练子集  $D_k$  内,测试初始逼近误差  $E_k$ ;

3) 找出逼近误差最大的子网络  $\text{ANN}_k$ , 在相应的训练子集  $D_k$  内,按某种训练算法的训练  $T$  步(这里取  $T=50$ );

4) 检查是否所有  $E_k$  均小于规定误差限,是则训练结束,否则返回3.

在网络工作阶段,只需对当前输入值由邻近原则确定其所属类,激活该类对应的各子网络得到网络的输出值,并以此作为整体网络输出值.

因为, MFNN 对一个紧集上的任意连续函数具有任意逼近性,每个子网络可以任意逼近由子样本集所反映的函数关系,这样由这些子网络的共同作用就可以得到对整体样本集的任意逼近.

## 4 基于多 ANN 结构的复杂系统长时段预报

多 ANN 模型中,可以认为门控网络与各子网络是在不同精度上对系统的描述. 门控网络完成的是对系统输入的模式分类,是对系统的一种粗线条的、定性的描述. 各子网络是对各输入模式类的输出估计,是对系统的一种定量的描述. 因此,可将门控网络的训练与各子网络的训练分开,前者采用极值聚类算法离线进行. 这里提出的算法是在多 ANN 长时段预报模型中对各子网络的修正算法.

对一个实际对象,可以量测到一组实际的输入—输出数据  $\{u(t), y_p(t) | t=1, 2, \dots, T\}$ . 通过适当的实验设计,它可以在相当大的程度上反映出我们所关心的对象性态. 根据这组数据,可以离线建立对象的长时段预报模型.

这里以并联连接的 NARMA 模型作为长时段预报模型,以 ANN 模型描述如下:

$$\begin{cases} y_m(t) = \sum_{s=1}^S g_s(X(t)) \cdot y_s(X(t), \theta_s) \\ X(t) = [y_m(t-1)^T, \dots, y_m(t-K_y)^T, u(t-1)^T, \dots, u(t-K_u)^T]^T \\ \quad = [X_1(t)^T, \dots, X_{K_y}(t)^T, X_{K_y+1}(t)^T, \dots, X_{K_y+K_u}(t)^T]^T, \end{cases} \quad (3)$$

其中  $g_s$  表示门控网络的第  $s$  个输出量,  $y_s$  表示第  $s$  个子网络的输出值,网络形式如第2节所述.

在训练时,1到  $P$  步输出预报模型辨识的指标函数定义为

$$\begin{aligned} J(P) &= \frac{1}{2} \sum_{t=1}^P \sum_{s=1}^S g_s^2(X(t)) \cdot \|y_p(t) - y_s(X(t), \theta_s)\|^2 \\ &= \frac{1}{2} \sum_{t=1}^P \sum_{s=1}^S g_s^2(X(t)) \cdot \|\epsilon_s(t)\|^2, \end{aligned} \quad (4)$$

其中  $\varepsilon_s(t) = y_p(t) - y_s(X(t), \theta_s)$  是  $t$  时刻的第  $s$  个子网络的估计误差.  $J(P)$  反映了各子网络 1 到  $P$  步输出预报的总误差.  $J(P)$  的定义是假定每一个子网络要逼近的仍然是对象的整体特性, 只是在响应一个输入时对各子网络的信任度(由  $g_s$  决定)是不同的.

设已知模型输出初始值  $y_m(-K_y+1), y_m(-K_y+2), \dots, y_m(0)$ , 控制输入  $u(-K_u+1), \dots, u(0), u(1), \dots, u(P-1)$ , 和期望输出轨线  $y_p(1), y_p(2), \dots, y_p(P)$ . 长时段预报模型的离线训练问题可描述为: 在给定的模型结构(3)下, 确定模型参数  $\theta = (\theta_1^T, \theta_1^T, \dots, \theta_s^T)^T$ , 使式(4)的指标函数最小.

在给出训练算法前, 首先需求出目标函数对各子网络参数的导数

$$\frac{\partial J(P)}{\partial \theta} = \sum_{t=1}^P \sum_{s=1}^S \left( -g_s(X(t))^2 \cdot \left( \frac{\partial^+ y_s(X(t), \theta_s)}{\partial \theta^T} \right)^T \cdot \varepsilon_s(t) \right), \quad (5)$$

其中  $\frac{\partial^+}{\partial \theta}$  称为有序偏导(ordered derivatives)<sup>[6]</sup>, 表示对变量  $\theta$  考虑各种可能存在的复合函数关系之后求得的偏导数. (5)式中的有序偏导可由下面的式子计算得到:

$$\frac{\partial^+ y_s(X(t), \theta_s)}{\partial \theta^T} = \frac{\partial y_s(X(t), \theta_s)}{\partial \theta^T} + \sum_{i=1}^{K_y} \left( \frac{\partial y_s(X(t), \theta_s)}{\partial X_i(t)^T} \cdot \frac{\partial^+ y_m(t-i)}{\partial \theta^T} \right). \quad (6)$$

而网络整体输出对参数的灵敏度方程为

$$\frac{\partial^+ y_m(t)}{\partial \theta^T} = \sum_{s=1}^S \left( g_s(X(t)) \frac{\partial^+ y_s(X(t), \theta_s)}{\partial \theta^T} \right). \quad (7)$$

从这几个导数计算公式中可以看出, 当前时刻输出对模型参数的偏导数, 通过网络输入连接依赖于前  $K_y$  步的输出对参数的偏导数. 换言之当前时刻的误差会通过模型输入连接, 反向传播到网络工作的过去时刻中. 这就是沿时间的反向传播的思想. 其中式(6)反应了通过第  $s$  个子网络的反向传播.

需要指出的是, 在极值聚类多 ANN 模型内, 还存在一条通过门控网络的反馈通路. 但由于门控网络的输出值是通过求极值得到的, 每一时刻  $g_k$  中只有一个是 1, 其余全部是 0, 所以门控网络的输出对输入是不可导的. 在假设  $X(t)$  只有微小的变化时不影响  $g_k$  的取值的前提下, 可认为  $g_k$  对输入的导数为 0. 因此对极值聚类的多 ANN 模型只考虑误差通过各子网络的反向传播, 不考虑通过门控网络的反向传播.

结合 MFNN 的反向传播算法, 可得到如下的多 ANN 长时段预报模型离线辨识算法. 在第  $\theta-1$  次更新之后, 计算第  $\theta$  次权值更新

1. 初始化:  $\frac{\partial^+ y_m(0)}{\partial \theta^T} = \dots = \frac{\partial^+ y_m(-K_y+1)}{\partial \theta^T} = 0;$

2. 对  $t=1, 2, \dots, P$ , 计算

- a) 样本正向、反向传播. 由门控网络计算出  $t$  时刻各子网络的输出加权  $g_s(t)$ , 对被激活子网络由(6)式计算  $\frac{\partial^+ y_s(X(t), \theta_s)}{\partial \theta^T};$

- b) 计算累计梯度值;

- c)  $G(t) = G(t-1) + \sum_{s=1}^S \left( -g_s(X(t)) \cdot \left( \frac{\partial^+ y_s(X(t), \theta_s)}{\partial \theta^T} \right)^T \cdot \varepsilon_s(t) \right);$

- d) 由式(7)更新  $\frac{\partial^+ y_m(t)}{\partial \theta^T}.$

3. 采用某种方法更新各子网络权值阵. 可以选用 BP 型更新公式. 这里采用的是基


于变尺度法改进 BP 算法.

## 5 数值仿真


这里比较一下多 ANN 模型与单 ANN 模型的差别. 考虑动态系统

$$y(t+1) = \sin(\pi \cdot y(t)) \cdot \exp(-u(t)). \quad (8)$$

首先建立一步预报模型. 设精度要求为均方差  $MSE < 0.0001$ . 单 ANN 模型, 采用隐节点数可变的修正变尺度 BP 训练算法, 经过 2056 次迭代, 达到精度要求. 隐节点从 6 个开始增加到 19 个. 对多 ANN 模型, 采用极值聚类训练算法, 先对样本空间进行划分, 得到 6 个极值中心; 各子网络分别经过 568, 543, 675, 522, 520, 495 次训练达到精度要求, 隐节点数目分别为 8, 7, 6, 8, 8, 8 个. 由一步预报模型进行长时段预报, 分别从第 10 和 40 个采样时刻开始进行两次 30 步预报, 结果都不理想. 在一步预报模型的基础上, 再采用本文提出的方法进行长时段预报模型的辨识. 对单 ANN 模型, 经 50 次修正均方差为 0.4577, 之后不再下降. 对多 ANN 模型, 经 68 次迭代, 均方差为 0.0741. 多 ANN 模型的效果改善比较明显. 如图 2(a), (b) 所示, 图中实线表示对象输出曲线, 虚线表示模型预报输出曲线.



(a) 单网络的 30 步长时段预报模型学习结果



(b) 多网络的 30 步长时段预报模型学习结果

图 2 单网络与多网络模型预报结果对比

## 6 小结

本文提出了一种基于极值聚类的多 ANN 结构训练方法,并将多 ANN 结构应用于复杂系统长时段预报,提出了基于多 ANN 结构的长时段预报模型的离线批方式辨识算法.所提出的多 ANN 结构的极值聚类学习策略,可以大大提高预报精度,对于具有多极值特性的一类复杂系统预报问题是一种可行的方法.本文的方法可以作为进一步建立基于多 ANN 模型的复杂控制系统预测控制系统的基础.

### 参 考 文 献

- [1] Jacobs R A, Jordan M I *et al.* Adaptive Mixtures of local experts. *Neural Computation*, 1991, **3**:79—87.
- [2] Cho S B, Kim J H. combining multiple neural networks by fuzzy integral for recognition. *IEEE Trans SMC*, 1995, **25**(1).
- [3] Narendra K S, Levin A U. Regulation of nonlinear dynamical systems using multiple neural networks. , In: Proc. of ACC, 1990, 1609—1614.
- [4] Hrycej T. A Modular Architecture for Efficient Learning. Int'l Joint Conf. on Neural Networks, San Diego. 1990, **1**:557—562.
- [5] Li Renhou, Gao Feng. Complex function approximatino based on multi-ANN approach. *Chinese Journal of Systems Engineering and Electronics*, 1995, **6**(2):22—31.
- [6] Werbos P J. Backpropagation through time; what is does and how to do it? Proc. of IEEE. 1990, **78**:1550—1560.

## LONG-TERM PREDICTION FOR COMPLEX SYSTEM BASED ON MULTIPLE ANN MODELS

GAO FENG LI RENHOU

(Systems Engineering Institute, Xi'an Jiaotong University, Xi'an 710049)

**Abstract** An extremum clustering approach for multiple artificial neural networks is developed in this paper. Then it is used for long-term prediction of complex dynamic system. With this method the long-term prediction precision and model robustness can be improved. This approach can be used for complex system predictive control using multiple ANNs.

**Key words** Multiple ANNs, multi-layer feedforward neural networks, prediction of nonlinear systems.