

文章编号:1671-8860(2005)07-0588-04

文献标志码:A

# 大坝变形预报的模糊神经网络模型

王新洲<sup>1,2</sup> 邓兴升<sup>3</sup>

(1 武汉大学灾害监测与防治研究中心,武汉市珞喻路129号,430079)

(2 武汉大学测绘学院,武汉市珞喻路129号,430079)

(3 湖南省东江水电厂,资兴市,423403)

**摘要:**在介绍模糊推理神经网络FNN-LM训练算法及网络参数的确定方法的基础上,以东江大坝12个测点的水平位移预报为例,说明了模糊神经网络模型具有训练时间短、预报精度高的优势。

**关键词:**模糊神经网络;大坝变形;预报模型

**中图法分类号:**P207;P258

大坝变形预报通常采用统计模型或神经网络模型<sup>[1]</sup>。本文介绍了大坝变形预报的模糊神经网络模型,并以东江大坝变形预报为例,说明模糊神经网络模型在大坝变形预报中的优越性。

## 1 模糊推理神经网络结构

模糊推理神经网络以下列模糊规则为基础:

$R_1$ : If  $x_1$  is  $\mu_1^1$ , ...,  $x_i$  is  $\mu_i^1$ , ...,  $x_n$  is  $\mu_n^1$  then  $y$  is  $y_1$

...

$R_m$ : If  $x_1$  is  $\mu_1^m$ , ...,  $x_i$  is  $\mu_i^m$ , ...,  $x_n$  is  $\mu_n^m$  then  $y$  is  $y_m$

由此设计出如图1所示的多输入、多输出(MIMO)结构的模糊推理神经网络<sup>[2]</sup>。网络结构共分五层:第一层是输入层,各个节点直接与输入向量的各分量 $x_i$ 连接;第五层是输出层,每个节点代表一个输出量;第二层和第四层的每个节点均代表一个模糊值,每个节点的输出为对应模糊值的隶属度;第三层的每个节点代表一条模糊规则,该层的所有节点组成一个模糊规则库;第二层节点与第三层节点的连接定义了模糊规则的“条件”;第三层节点与第四层节点的连接定义了模糊规则的“结论”。对于每个规则节点,最多只能和每个输入、输出节点的一个模糊值相连接。

模糊推理神经网络的一个重要性质是具有万能逼近能力。

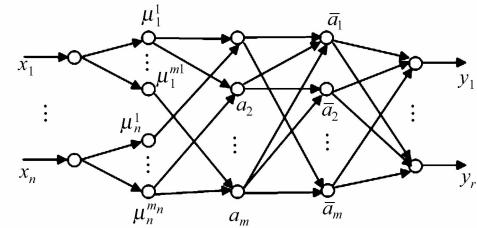


图1 基于 Mamdani 模型的 FNN 结构

Fig. 1 FNN Structure Based on Mamdani

## 2 FNN-LM 算法

### 2.1 FNN 的正向计算

结构如图1的FNN各层正向计算如下。

第一层起着将输入值  $x = [x_1, x_2, \dots, x_n]^T$  传送到下一层的作用。该层的节点数  $N_1 = n$ 。

第二层的作用是计算各输入分量属于各语言变量模糊集合的隶属度函数。隶属度函数可采用高斯函数(式(1))及PN函数(式(2))等来计算。通过调整  $a_{ij}$  和  $b_{ij}$ ,可以改变隶属度函数的位置和形状。该层的节点总数  $N_2 = \sum_{i=1}^n m_i$ ,  $m_i$  是  $x_i$  的模糊分割数。

$$f_{ij} = \exp\left[-\frac{1}{2}\left(\frac{u_i - a_{ij}}{b_{ij}}\right)^2\right] \quad (1)$$

收稿日期:2005-05-03。

项目来源:云南省省院省校合作计划资助项目(2003ZDBLA05A022);湖北省科技攻关计划重大资助项目(2001AA104A01);国家自然科学基金资助项目(40474003)。

$$f_{ij} = a_{ij} - \frac{2a_{ij}}{1 + \exp(b_{ij}u_i)} \in [-a_{ij}, +a_{ij}] \quad (2)$$

第三层用来匹配模糊规则前件, 根据应用领域的不同, 可采用 min、max、sum、prod 或 probor 等操作计算出每条规则的适用度。在变形预报 FNN 模型中, 采用 min 或 max 操作会抛弃大量的有用信息, 使大部分待调参数在迭代过程中得不到调整, 从而使算法效率低, 映射精度难以提高; prod 操作导致大部分第三层节点输出为 0, probor 方法导致算法复杂化且效率低, 均不宜采用。因此, 采用 sum 操作进行规则适用度的计算。此外, 该层的节点总数为  $N_3 = \prod_{i=1}^n m_i$ 。随着输入变量的增多, 模糊规则数呈指数增长, 众多的模糊规则严重影响网络收敛的速度, 网络庞大训练就困难, 这便是模糊规则组合爆炸问题。解决的方法有: 减少模糊分割数; 网络分解再组合; 删除无关规则<sup>[1]</sup>。

第四层的节点数与第三层相同, 即  $N_4 = N_3$ , 它所实现的是归一化计算, 如式(3)所示:

$$\bar{a}_j = a_j / \sum_{j=1}^m a_j, j = 1, 2, \dots, m \quad (3)$$

第五层是输出层, 也叫解模糊化层, 它的作用是应用 sum-product 模糊推理和解模糊化方法实现清晰化计算输出。本文采用重心法, 如式(4)所示:

$$f = \sum_{j=1}^m w_j u_j \quad (4)$$

## 2.2 FNN-LM 学习算法

FNN 目前的学习算法有梯度下降算法、遗传算法、混合学习算法、TPH 算法、移动小论域法等。由于各个输入之间存在潜在相关性及每个输入序列前后存在潜在自相关性, 极可能使得基于各输入建立的 Hessian 矩阵为病态矩阵。因此, 将 LM 算法引入 FNN, 从而形成了 FNN-LM 学习算法。

FNN-LM 算法的搜索方向  $d_k$  由下式确定:

$$(\mathbf{J}(x_k)^T \mathbf{J}(x_k) + \lambda_k \mathbf{I}) d_k = -\mathbf{J}(x_k) e(x_k) \quad (5)$$

迭代公式为:

$$x_{k+1} = x_k - [\mathbf{J}(x_k)^T \mathbf{J}(x_k) + \lambda_k \mathbf{I}]^{-1} \cdot [\mathbf{J}(x_k)^T e(x_k)] \quad (6)$$

式中,  $e(x_k)$  为网络输出的误差向量;  $\mathbf{J}(x_k)$  是 Jacobian 矩阵;  $\mathbf{H} = \mathbf{J}(x_k)^T \mathbf{J}(x_k)$  为 Hessian 矩阵。当  $\mathbf{H}$  秩亏或病态时, 增大其主对角线元素, 其增大量  $\lambda_k (\lambda_k \geq 0)$  称为阻尼因子。 $\mathbf{H}$  矩阵对任何正数  $\lambda_k$  总具有对称正定的性质。 $\lambda_k = 0$  时,  $d_k$  的算法同高斯-牛顿法;  $\lambda_k \rightarrow \infty$  时,  $d_k \rightarrow 0$ , 转向目标函

数的负梯度方向, 变成最速下降法。这意味着足够大的  $\lambda_k$ , 条件  $e(x_k + d_k) < e(x_k)$  恒成立<sup>[3]</sup>。

引进步长因子  $\eta(k)$ , 则式(6)可写为:

$$x_{k+1} = x_k - \eta(k) [\mathbf{J}(x_k)^T \mathbf{J}(x_k) + \lambda_k \mathbf{I}]^{-1} [\mathbf{J}(x_k)^T e(x_k)] \quad (7)$$

式中,  $\lambda_k$  和  $\eta(k)$  的确定很重要, 直接影响网络学习的收敛速度、迭代振荡和预报精度。它们的迭代算法较多, 参见文献[1]。

## 3 网络参数的确定

### 3.1 输入输出的确定

建立大坝变形分析与预报模型主要有两个途径<sup>[4]</sup>: ①以环境量(如库水位、气温等)作为自变量, 将效应量(变形值)作为因变量, 建立起效应量和环境量之间的依赖关系; ②根据效应量自身变化规律, 而不涉及其他环境量, 建立起效应量序列前后之间的自依赖关系。

本文采用环境量模型, 由于环境量对大坝变形影响的滞后性, 温度因子取位移观测前  $e$  至  $f$  天的坝址气温日均值, 6 对  $e-f$  值为: 1-10、11-20、21-35、36-50、51-70、71-90; 水压分量取坝前水深  $h$  的  $j$  次幂,  $j$  取 1~3; 时效因子取  $\ln(t)$  和  $t$ , 其中  $t=(\text{观测日序}-\text{基准日序})/100$ <sup>[5]</sup>。

组织好数据后, 将样本数据分为三个部分<sup>[4]</sup>: 首先把某一日期后的样本数据作为预报样本, 数量约占总样本的 25%。然后再从剩余的样本中均匀抽取 25% 作为检测样本, 剩下 50% 作为训练样本。检测样本用于在训练过程中检测网络的学习效果, 得到样本检测误差, 判断网络收敛标准。训练样本用于网络训练, 以调整网络的隶属函数参数和权阈值。

### 3.2 隶属度函数的确定

常用的隶属度函数有高斯函数、三角形函数、梯形函数等。由于输入值较大时(如库水位的三次方 2 744 000), 把隶属度函数的输出压缩到 [0, 1], 会产生较大变形, 尽管输入值变化剧烈, 但隶属度值变化却不敏感, 这样会导致网络映射能力降低, 为此可采用 PN 函数<sup>[1]</sup>。

虽然 FNN 具有自适应调整参数能力, 但隶属度函数参数宜在训练前确定, 应使图形看上去符合常规, 如图 2 所示。隶属度函数的参数只要初值选择合理, 一般网络训练对它的调整幅度不会太大, 这对加快网络收敛速度有利。

### 3.3 网络训练终止标准参数的确定

FNN 的学习能力很强, 可以高精度地逼近训

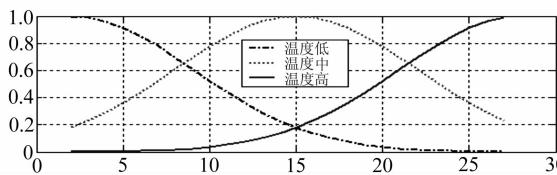


图 2 温度因子的隶属度函数

Fig. 2 Membership Function of Temperature Factor

练样本,但并不是训练误差越小,网络泛化能力就越强,应避免过度拟合。将样本分为三部分的目的在于网络训练过程中要对检测样本进行检测,若达到预定误差标准的要求,便可终止训练,这样可避免网络训练的盲目性。预定的误差标准可根据大坝安全监测的实际需要来确定。

由于预报样本在实践中是未知的,把包含预报样本均方根误差在内的综合均方根误差最小作为网络训练终止标准是不现实的。但训练样本和检测样本的均方根误差是可计算的,可用来作为网络训练终止的标准。为了避免给定的终止训练标准过于“苛刻”,应设置训练最大次数标准,使网络即使是在找不到“答案”的情况下也终止训练。

图 3 说明了训练次数盲目增加并不能无止境地降低均方根误差,训练 300 次时就已经实现了值为 0.51 的检测样本最小均方根误差。

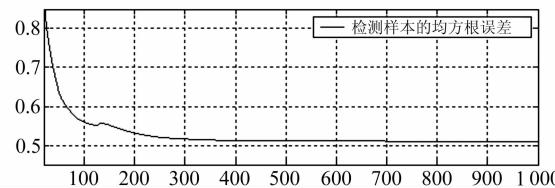


图 3 检测样本的均方根误差与训练次数的关系

Fig. 3 Relationship of Standard Deviation of Test Sample and Training Times

## 4 大坝变形预报实例

根据收集整理的东江大坝安全监测的位移、气温、库水位等资料,以 12 个坝体垂线观测点的径切向位移序列为预报对象,共有时间范围从 1999 年 1 月至 2003 年 12 月期间 245 个周期的样本数据,在此基础上分别建立了统计模型和 FNN 模型,其预报精度对比情况见表 1。

表 1 统计模型与 FNN 模型预报精度对比表

Tab. 1 Predict Precision Contrast for Statistic Model and FNN Model

测点名	统计模型		FNN 模型				
	MSE	MAE	MSE	MAE	N	$\lambda \times 10^{-5}$	$\eta$
L1H291R	1.101 7	0.676 8	0.771 7	0.557 2	50	4.5	0.20
L3H291R	1.272 5	0.919 0	1.074 5	0.720 1	50	4.5	0.20
L5H291R	2.517 0	2.062 0	1.826 0	1.147 3	50	4.5	0.20
L7H291R	1.537 3	1.000 0	1.204 3	0.894 3	50	4.5	0.30
L9H291R	0.721 7	0.503 9	0.575 3	0.456 9	50	4.5	0.22
L3H291L	0.425 5	0.331 4	0.308 1	0.257 0	50	4.5	0.20
L7H291L	0.294 1	0.233 7	0.275 9	0.197 5	16	4.5	0.20
L3H205R	0.585 0	0.493 8	0.476 7	0.362 8	28	4.5	0.10
L5H205R	1.355 7	1.249 5	1.275 4	1.026 1	50	4.5	0.20
L7H205R	0.481 4	0.384 0	0.448 2	0.304 8	15	4.5	0.15
L3H205L	0.588 2	0.478 6	0.511 1	0.409 1	9	4.5	0.20
L7H205L	0.385 4	0.324 5	0.381 4	0.278 3	19	4.5	0.15

注:MSE 为均方根误差;MAE 为平均绝对误差;N 为训练次数; $\lambda$  为阻尼因子; $\eta$  为步长因子。

由表 1 可知,在预报精度上,FNN 预报模型的 MSE 和 MAE 都比统计模型的相应误差要小;在迭代次数上,均未超过 50 次,表明训练速度很快。

位移预报值与观测值对比情况和预报误差以 L7H205L 测点(如图 4、图 5)为例说明之,其余测点相同。图 4 显示,L7H205L 测点位移预报值与观测值在 60 个观测周期中基本吻合;图 5 显示,93% 的预报误差在  $\pm 0.5$  mm 范围内,表明该 FNN 变形预报模型具有较高的预报精度。

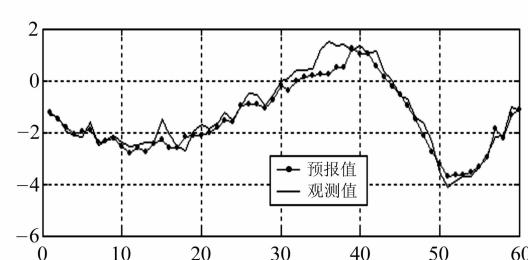


图 4 L7H205L 测点位移预报值与观测值对比

Fig. 4 Comparison Between Obsevations and Predict Values on Point L7H205L

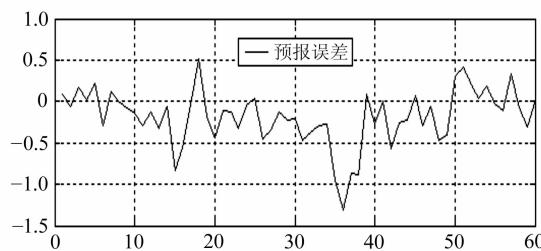


图 5 L7H205L 测点位移预报误差

Fig. 5 Predict Error of Point L7H205L

## 5 结语

1) 人工神经网络模拟了人脑的硬件,模糊系统模拟了人脑的软件(思维),由两者结合产生的FNN,同时具有神经网络的低层次的学习、计算能力和模糊系统的高层次的推理、决策能力,成为了信息处理和知识挖掘的新工具。

2) 东江大坝的变形预报实例充分说明了本文采用的FNN变形预报模型具有训练时间短、预报精度高的特点,相对于其他变形预报模型具

有一定的优势。可在大坝监测实践中进行变形预报、异常报警,这对大坝安全运行和管理具有重要意义。

## 参 考 文 献

- 1 邓兴升. 大坝变形分析及预报的模糊神经网络方法研究:[学位论文]. 武汉:武汉大学,2004
- 2 Norgaard M. Neural Network Based System Identification Toolbox. Department of Automation, Technical University of Denmark, Denmark, 1997
- 3 黄全义. 大坝变形预报神经网络专家系统方法研究:[博士论文]. 武汉:武汉大学,2001
- 4 王铁生,华锡生. 模糊神经网络在大坝变形预报中的应用. 工程勘察,2002(5): 56~58
- 5 吴中如. 水工建筑物安全监控理论及其应用. 北京:高等教育出版社,2003
- 6 王振雷. 模糊神经网络理论及其在复杂系统中的应用研究:[博士论文]. 辽宁:东北大学,2002

**第一作者简介:**王新洲,教授,博士生导师。主要从事空间数据处理理论与应用方面的研究。

E-mail: xzhwang@sgg.whu.edu.cn

## Fuzzy Neural Network Modeling for Dam Deformation Prediction

WANG Xinzhou<sup>1,2</sup> DENG Xingsheng<sup>3</sup>

(1) Research Center for Disaster Monitoring and Prevention, Wuhan University, 129 Luoyu Road, Wuhan 430079, China)

(2) School of Geodesy and Geomatics, Wuhan University, 129 Luoyu Road, Wuhan 430079, China)

(3) Dongjiang Hydroelectric Power Plant, Hunan Province, Zixing 423403, China)

**Abstract:** On the basis of the analysis of characteristics of Fuzzy logic and neural network, the possibility and inevitability of the combination between them are introduced. It gives the FNN-LM algorithm and the method to determine the network parameter. Relative to other models, the superiority of FNN deformation prediction model is showed by the historical displacement prediction models of twelve points of Dongjiang dam for their short training time and high prediction precision.

**Key words:** fuzzy neural network; dam deformation; prediction modeling

**About the first author:** WANG Xinzhou, professor, Ph.D supervisor. He is concentrated on the research and education on the theory and application of spatial data processing.

E-mail: xzhwang@sgg.whu.edu.cn