

# RBF神经网络在线学习方式及其在大坝位移监测中的应用\*

王德文<sup>1</sup>, 李智录<sup>2</sup>, 卢瑞章<sup>2</sup>

(1 陕西省河务水库管理站, 陕西 西安 710004; 2 西安理工大学 水利水电学院, 陕西 西安 710048)

[摘要] 针对目前RBF神经网络训练算法存在的问题, 提出了一种模拟人类学习方式的自动调整隐层节点数的在线训练方法, 对其理论依据进行了分析, 并用实例对其进行了验证。结果表明, 此种学习方法速度快、拟合精度高、新旧知识均可记忆, 克服了以往算法的不足, 具有很大的实用性。

[关键词] RBF神经网络; 在线训练; 大坝位移监测; 径向基函数

[中图分类号] TV 698 1<sup>+</sup> 1

[文献标识码] A

[文章编号] 1671-9387(2006)12-0226-05

近年来, 神经网络在各种系统中的应用越来越广泛, 但同时也凸现出一些缺陷, 如不能像人的神经那样实时学习新的东西。神经网络在实际应用中均采用离线训练(学习)方法, 即训练的过程被分为几个独立的阶段: 首先收集样本, 然后采用某种方法进行聚类, 最后循环校正网络权值。这种方法虽然可以满足某些简单应用的需要, 但仍存在很多问题, 如果系统是时变的, 则不可能事先收集到完整的样本; 即使系统不是时变的, 一般要收集完整的样本也是很困难的<sup>[1-3]</sup>。比如在大坝监测中, 由于大坝性态的复杂多变性以及监测时间的限制, 不可能得到比较完全的样本, 因此也就很难采用离线的训练方法, 可见研究一种能在线学习的神经网络训练方法有很大的现实意义。

与广泛应用的BP网络相比, RBF神经网络近年来也得到了非常深入的研究和关注。RBF神经网络不仅具有更好的函数拟合和泛化能力, 而且训练速度更快。同时其还具有一种非常诱人的特性——节点局部性, 即每个隐层节点单元分别代表一种不同的模式, 网络规模的扩大对其原有特性的影响较小<sup>[4-5]</sup>。这种允许添加新模式特性非常类似在线新知识的学习, 因此, 进一步研究RBF神经网络对实现其在线实时学习有很好的指导意义。因此, 本文在对RBF神经网络局部特性测试的基础上, 研究了其在线学习方法, 并在大坝位移的实时监测中进行了应用, 现将结果报道如下。

## 1 RBF神经网络局部特性的测试

为加深对RBF神经网络的了解, 特对其局部特性进行简单测试。本次测试采用黑河金盆水库大坝的位移监测数据, 全部数据进行统一训练, 网络最终建立了11个隐层节点, 其预报值与原测量值非常接近(图1)。然后依次去掉网络中1个节点再做输出计算, 结果见图2和图3(实际测试中共依次去掉6个节点)。由图2和图3可知, 每次去掉1个节点后只有部分数据受到影响, 也就是说只有此节点所代表的模式受到影响, 而不属于此模式的数据其结果基本不受影响。如此反向推理, 如果网络增加新模式, 也仅仅需要再增加1个相对应的节点即可, 这也是在线学习方法的理论基础。

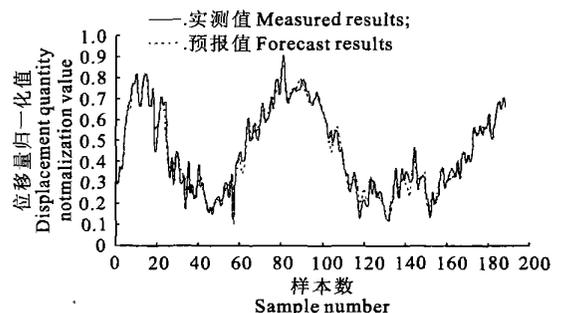


图1 RBF神经网络实测值与预报值的比较

Fig. 1 Comparison between measured and forecast results of RBF neural network

\* [收稿日期] 2006-08-25

[作者简介] 王德文(1961-), 男, 陕西澄城人, 高级工程师, 主要从事水库运行管理研究。E-mail: wdw1961@sina.com

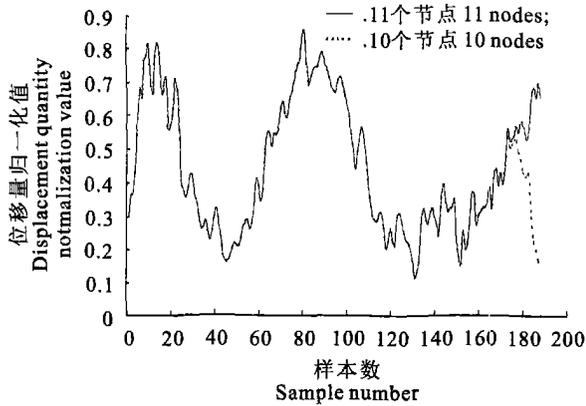


图2 RBF 神经网络 11 个节点与 10 个节点的预报结果比较

Fig. 2 Comparison between forecast results from 11 nodes and 10 nodes of RBF neural network

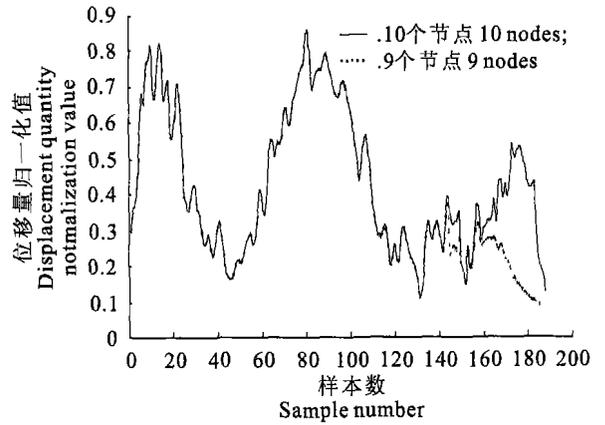


图3 RBF 神经网络 10 个节点和 9 个节点预报结果比较

Fig. 3 Comparison between forecast results from 10 nodes and 9 nodes of RBF neural network

## 2 RBF 网络的在线学习方法

类似人类的认知方式(学校学习阶段和工作学习阶段),神经网络的学习也应分为两个独立的过程,即离线训练和在线学习,同时在空闲时间进行必要的“复习”。因为离线训练是在线学习的基础,所以只有打好知识的基础才能有更好的学习效果。下面分别介绍离线训练和在线学习的方法,并全部在 Visual C++ 6.0 下通过验证。

### 2.1 离线训练

文献[6]提出了一种 RBF 网络的在线学习算法,即网络从一个节点开始进行学习,每当有 1 个新数据输入时便判断是否满足增加新节点的要求,如果达到要求就会按照规定增加 1 个新的节点,否则进行梯度下降迭代。测试结果表明,对样本数据只学习一次效果很不理想,循环训练多次效果较好,但也失去了在线学习的意义。因此,本文对其做部分修改后用做离线训练算法。该算法分为 2 个阶段<sup>[7-8]</sup>: 模式识别阶段和梯度下降训练阶段。在模式识别阶段顺序输入样本数据,网络分别判断每个输入矢量数据是否属于某个已有模式。如果不属于任何一个已有模式,则以当前输入数据作为新模式中心  $C$ , 使用 1 个较小的预设值作为宽度  $\delta$ , 若当前输入矢量数据属于某一模式  $K_i$  时,则用以下算法调整中心值  $C_{in}$ , 并增加此模式的匹配数据个数  $n = n + 1$ 。即有:

$$C_{in+1} = \frac{C_{in} \cdot n + X}{n + 1} \quad (1)$$

式中,  $C_{n+1}$ ,  $C_n$  分别为第  $i$  个中心  $n+1$  个和  $n$  个数据的值,  $X$  为新加入的数据。

模式识别阶段完成后进行梯度下降方式的训练,直到输出满足给定的目标精度值  $E$  ( $E$  为允许的误差值)。

下面是增加新模式的判断准则和训练阶段的梯度下降算法。

2.1.1 增加新模式节点的判定准则 给定第  $i$  个样本  $[\bar{X}_i, \bar{Y}_i]$ , 其中  $\bar{X}_i$  表示  $N$  维输入矢量,  $\bar{Y}_i$  表示  $M$  维输出矢量。如果同时满足以下条件则分配 1 个隐单元  $C_{P+1}$ :

(1)  $\bar{E}_i > \epsilon$ , 式中  $\bar{E}_i$  为网络输出误差矢量;

$\cdot$  为某种范数运算(下同);  $\epsilon$  为误差阈值,  $\epsilon > 0$ 。

(2)  $\text{Min} \|\bar{X}_i - C_r\| > \eta(t)$ , 式中  $\eta(t) = \{\alpha \eta_{\max}, \eta_{\min}\}$ , 是距离阈值,  $0 < \alpha < 1$ ;  $1 - r - P$ ,  $P$  为当前 RBF 网络的隐单元个数;  $C_r$  为第  $r$  个隐单元的中心矢量。

2.1.2 梯度下降法计算方法<sup>[9-11]</sup> 设  $y_i$  为网络的

第  $i$  个输出, 则有:  $\hat{y}_i = \sum_{j=1}^P \omega_j h_j$ , 式中  $\omega_j$  为第  $j$  个隐单元到第  $i$  个输出的连接权值;  $h_j$  为第  $j$  个隐单元的输

出,  $h_j = \exp(-\frac{\|X - C_j\|^2}{\delta_j^2})$ , 其中  $C_j$  和  $\delta_j$  分别为第  $j$  个隐单元的中心矢量和宽度,  $\|X - C_j\|^2 = \sum_{k=1}^N (x_k^{(i)} - c_k^{(j)})^2$ 。选取神经网络训练的目标函数:

$$J = \frac{1}{2} \sum_{i=1}^M (y_i - \hat{y}_i)^2 = \frac{1}{2} \sum_{i=1}^M [y_i - \sum_{j=1}^P \omega_j \exp(-\frac{\|X - C_j\|^2}{\delta_j^2})]^2 \quad (2)$$

由于要对网络各隐单元的中心和宽度采用梯度

下降法进行调整,所以要求得目标函数 $J$ 对隐单元中心矢量的各个分量和宽度的偏导数:

对中心:

$$\frac{\partial J}{\partial c_i^{(q)}} = \frac{1}{2} \frac{\partial}{\partial c_i^{(q)}} \sum_{i=1}^M (y_i - \hat{y}_i)^2 = - \frac{2(x^{(q)} - x_i^{(q)})h_i}{\delta_i^2} \sum_{i=1}^M (y_i - \hat{y}_i)\omega_i \quad (3)$$

对宽度:

$$\frac{\partial J}{\partial \delta_i} = \frac{1}{2} \frac{\partial}{\partial \delta_i} \sum_{i=1}^M (y_i - \hat{y}_i)^2 = - \frac{2 \sum_{i=1}^M (x - c_i)^2 h_i}{\delta_i^3} \sum_{i=1}^M (y_i - \hat{y}_i)\omega_i \quad (4)$$

则可以得到对中心矢量的各个分量和各个隐单元宽度的梯度下降调整算法为:

$$c_i^{(q)}(k) = c_i^{(q)}(k-1) - \gamma \frac{\partial J}{\partial c_i^{(q)}(k-1)} \quad (5)$$

$$\delta_i(k) = \delta_i(k-1) - \gamma \frac{\partial J}{\partial \delta_i(k-1)} \quad (6)$$

### 2.1 自组织在线学习

在线学习过程也采用自动增加新模式和梯度下降法修正误差,但使用的训练样本与离线训练不同,其不再采用全部的真实样本,而是用自动构造的数量较少又具有典型代表性的训练集<sup>[12]</sup>。为了保证调整后的网络对原有的记忆模式和新增加的模式具有同样的识别效果,需要精心构造训练样本集。

因原有的记忆模式和新增加的记忆模式均以径向基函数中心向量和宽度的形式存储在隐层节点中,故训练样本集可以由节点中心加高斯噪声得到(假设当前有 $K$ 个隐层节点,相应应有 $K$ 个中心),即:

$$X_j^L = C_j + \delta_j \cdot N(0, 1) \quad (L = 1, 2, \dots, r; j = 1, 2, \dots, K) \quad (7)$$

式中, $X_j^L$ 为由节点 $j$ 中心构造的第 $L$ 个训练样本; $C_j$ 和 $\delta_j$ 分别为第 $j$ 个节点的中心向量和宽度。

每个节点的中心经过 $r$ 次高斯噪声叠加后形成 $r$ 个代表同一模式的训练样本,则一共有 $K \times r$ 个训练样本。

对于待学习的新矢量数据 $X_{new}$ 采用以下方法处理:首先判断 $X_{new}$ 是否属于新的模式,如果不是,则只需把 $X_{new}$ 加入构造的 $K \times r$ 个训练样本中,得到一个有 $(K \times r + 1)$ 个样本的训练集;如果是新模式,则增加1个隐层节点模式(与离线模式识别阶段增加方式相同),并按照同其他模式一样的方法计算,最终得到有 $(K + 1) \times r$ 个样本的训练集。

训练集构造完成后就可以按照离线训练的方法做梯度下降训练。由于构造的样本数量远小于实际的样本数量,而且基本的中心和宽度都已经确定,调整很快就可以达到稳定,从而完成训练。因此,采用构造样本进行训练的速度远小于采用全部数据的速度,从而满足了在线学习快速和记忆完整的要求。

### 2.2 阶段复习

构造的训练集虽然总体上代表全部的典型模式,但并不能排除存在其他误差的可能,因为训练集毕竟是采用随机函数生成的。而且,由于每次学习1个新的样本时都重新构造新的训练集,所以也不能排除会有累积偏差的可能性。因此,当在线学习进行一段较长的时间后,需要对已学知识进行系统的“复习”,即用真实数据样本进行一次类似离线训练的过程,让它纠正一些学习偏差,从而使网络具有更好的精度和拓展性。实际测试结果表明,这个复习过程非常快,基本上只需要提交1遍数据就可以达到很高的拟合精度,所以此过程是非常有效和必需的。

### 2.3 算法流程

离线训练流程见图4,在线学习流程见图5。

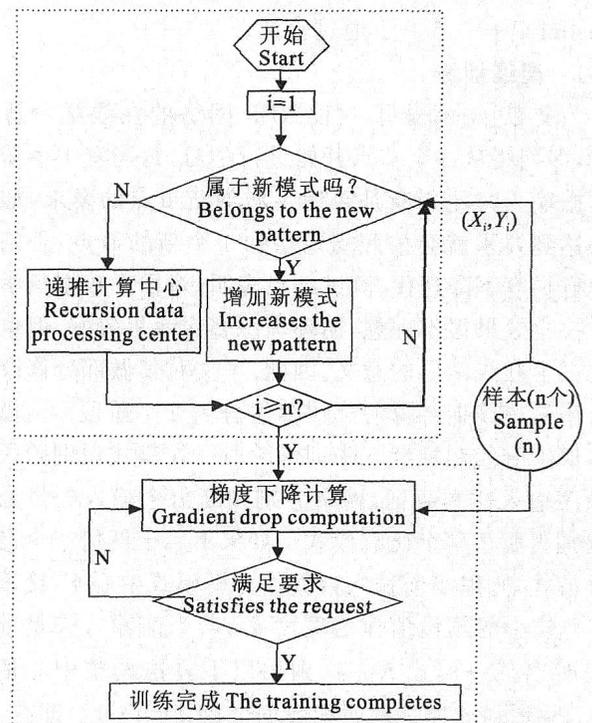


图4 RBF神经网络离线训练流程图

Fig 4 Algorithm flow figure of offline training of RBF neural network

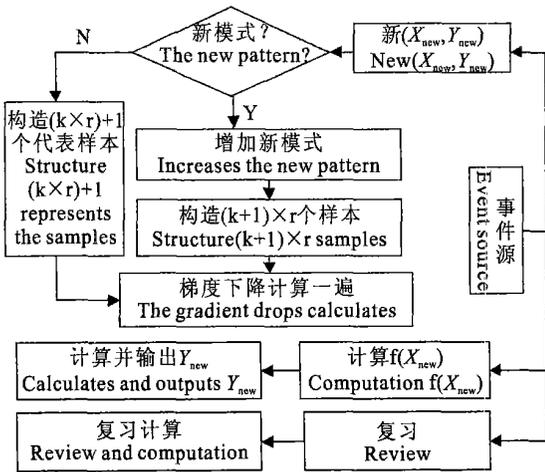


图5 RBF神经网络在线学习流程图

Fig 5 A algorithm flow figure of online studying of RBF neural network

### 3 实例测试

选取金盆水库大坝R11测点的188个位移数据样本进行模拟。为了证明本算法的有效性,将数据分为两组,前100个用于离线训练(结果见图6),后88个用于在线学习(结果见图7)。由于位移量的影响因子比较多,在该组样本中选择7个影响因子,因此RBF神经网络的输入层有7个神经元节点。由于输出为位移量,因此输出层为1个神经元节点。由图6可以看出,已学习过的样本数据拟合的很好,而未学习过的则相差很大,这和局部特性测试中去掉2个节点后的结果非常相似,说明未学习的样本中至少存在2个不同的新模式。由图7可知,由在线学习所得到的提前一步预测系列与实测系列总体上比较相似。

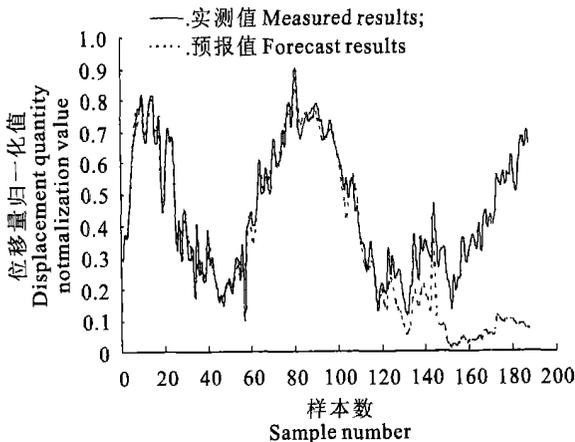


图6 RBF神经网络离线训练结果

Fig 6 Response to all samples on offline training results of RBF neural network

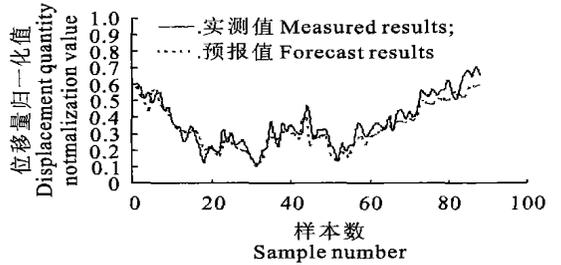


图7 RBF神经网络在线学习结果

Fig 7 Online learning forecast results of RBF neural network

图8是在线学习结束并复习1遍后的网络训练结果对全体数据的响应状态。由图8可见,其拟合度可以与离线训练的结果相媲美,充分说明了此在线学习方法的可行性和有效性。本算法虽然还不能完全脱离历史数据而独立在线学习,但是可以从新模式增加和时间花费的矛盾中较好地解脱出来,从而实现既能学习新知识,又能使花费的时间最少,最终达到很好的训练结果。可见,本文提出的RBF神经网络在线学习算法有很好的实用价值。

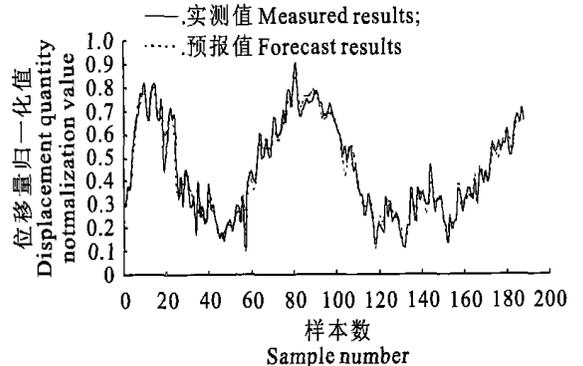


图8 RBF神经网络最终训练效果

Fig 8 Final training results of RBF neural network

### 4 小结

本研究首先对RBF神经网络的局部特性做了实例测试,并在分析得到的理论基础上提出了一种与人类学习过程相类似的学习算法。此算法主要包括模式识别、离线训练、在线学习和阶段复习4个部分,其中模式识别和在线学习过程会根据新数据的记忆情况自动增加隐层节点(新模式),该过程是实现在线学习的关键。阶段复习是维持网络记忆不会偏移的保障。本研究还对在线学习中的训练样本进行了优化,加快了学习速度,并用实例证明了该算法的正确性及可靠性,对具有时变特性的非实时系统

具有较高的实用价值。

目前,RBF神经网络的学习算法多采用离线训练,而本研究提出的算法使RBF神经网络具有在线

学习的功能,从而使RBF神经网络在许多需要实时在线预报的领域有了更广阔的应用前景。

### [参考文献]

- [1] 徐丽娜 神经网络控制[M]. 哈尔滨: 哈尔滨工业大学出版社, 1998
- [2] 史忠科 神经网络控制理论[M]. 西安: 西北工业大学出版社, 1997.
- [3] 赵林明, 胡浩云, 魏德华, 等. 多层前向人工神经网络[M]. 郑州: 黄河水利出版社, 1999.
- [4] 张学工 模式识别[M]. 北京: 清华大学出版社, 2000
- [5] 黄德双 神经网络模式识别系统理论[M]. 北京: 电子工业出版社, 1996
- [6] 王学雷, 邵惠鹤, 李亚芬. 一种径向基函数神经网络在线训练算法及其在非线形控制中的应用[J]. 信息与控制, 2001, 30(3): 249-253
- [7] 王旭东, 邵惠鹤 RBF神经网络及其在非线形系统建模中的应用[J]. 控制理论与应用, 1997, 14(1): 59-66
- [8] 宫赤坤, 华泽钊 RBF网络在线辨识算法与应用研究[J]. 甘肃工业大学学报, 2002, 28(3): 64-67.
- [9] 葛守西 现代洪水预报技术[M]. 北京: 中国水利水电出版社, 1999: 75-76
- [10] 范文兵, 陶振麟, 张素贞. 基于递推正交最小二乘的RBF网络结构优化[J]. 华东理工大学学报, 2001, 6(27): 503-506
- [11] 阚平凡 人工神经网络与模拟进化计算[M]. 北京: 清华大学出版社, 2000
- [12] 宋爱国 一种可在线学习的变结构径向基函数网络及其在被动声纳目标识别中的应用[J]. 电子学报, 1999, 27(10): 67-69

## Online study method of RBF neural network and its application in the dam displacement monitoring

WANG De-wen<sup>1</sup>, LI Zhi-lu<sup>2</sup>, LU Rui-zhang<sup>2</sup>

(1 *Water Conservancy Administration Reservoir Management Station, Xi'an, Shaanxi 710048, China;*

2 *College of Water Resource and Hydroelectricity Engineering, Xi'an University of Technology, Xi'an, Shaanxi 710048, China*)

**Abstract:** Aiming at the present problem in RBF neural network, an on-line training algorithm is presented, which can simulate the study of human and modify the nodes automatically. The theory on which this algorithm is based has been discussed. Results show that the algorithm can study fast and memorize both new and old knowledge with high simulating precision. So the algorithm can overcome the shortcomings of other existing algorithms and has great practicability.

**Key words:** RBF neural network; on-line training; dam displacement monitoring; radial basis function