文章编号：1006－544X（2007）04－0529－04

变形预测的一种新方法

潘国荣[1,2]，谷 川[1]

（1. 同济大学 测量与国土信息工程系，上海 200092；2. 现代工程测量国测绘局重点实验室，上海 200092）

摘 要：采用一种新的变形预测方法，即将GMDH神经网络预测方法运用到变形预测中进行短期以及长期预测，并且将预测得到的结果与采用BP神经网络预测得到的结果进行比较. 结果表明，GMDH神经网络是一种比较好的预测方法，在变形预测中具有一定的实用性.

关键词：GMDH算法；神经网络；变形预测；BP神经网络

中图分类号：P258 **文献标志码**：A

数据处理的群方法（group method of data handling，GMDH）是一种复杂非线性系统的启发式自组织建模方法，是一种以多项式为基础通过不断筛选组合来辨识非线性系统的模型，它对于高阶非线性系统的辨识有效[1]. 具有GMDH组织结构的神经网络称为GMDH神经网络（也称为多项式网络），是前馈神经网络中一种用于预测的实用神经网络，其特点是网络结构不固定，在训练过程中不断地改变.

相对于传统多层神经网络算法，GMDH算法具有如下特点：

1）建模过程自组织控制，不需任何初始假设；

2）最优复杂性及高精度预测；

3）能够自组织多层神经网络的每层最佳结构，即能够自动地保留有用的变量和删除多余的变量；

4）能够自动选择最佳的网络层数和每层的神经元数目[2－4].

正是由于GMDH算法的这些优点，决定其是一种实用性比较强的预测方法.

用常用的BP神经网络以及GMDH神经网络对一组变形监测数据分别进行短期以及长期预测，并对比预测结果.

1 GMDH神经网络的理论

GMDH算法的主要思想是由系统各输入单元交叉组合产生一系列的活动神经元，其中每一神经元都具有选择最优传递函数的功能. 再从已产生的一代神经元中选择若干与目标变量最为接近的神经元，被选出神经元强强结合再次产生新的神经元. 重复这样一个优势遗传、竞争生存和进化的过程，直至新产生的一代神经元都不比上一代更加优秀，于是最优模型被选出.

类似于其它神经网络，GMDH算法具有如下两个基本思想：①以分析黑箱的方法处理系统输入输出关系；②用网络间元素的互联关系描述网络的功能. GMDH神经网络的构建过程主要是一个不断产生活动神经元，由外部准则对神经元进行筛选，筛选得到的神经元强强结合再产生下一层神经元，直至具有最佳复杂性的模型被选出的这样一个过程[1].

考虑一非线性系统，$x_1, x_2, \cdots, x_n$ 为输入，y 为输出. 其关系为

$$y = f(x_1, x_2, \cdots, x_n). \tag{1}$$

函数 f 的离散Volterra级数展开式

$$y = a_0 + \sum_{i=1}^{n} a_i x_1 + \sum_{i=1}^{n}\sum_{j=1}^{n} a_{ij} x_i x_j + \sum_{i=1}^{n}\sum_{j=1}^{n}\sum_{k=1}^{n} a_{ijk} x_i x_j x_k + \cdots. \tag{2}$$

收稿日期：2007－01－18

作者简介：潘国荣（1960－），男，博士，教授，研究方向：精密工程测量与测量数据处理.

被广泛用来作为非线性模型的完全描述. 但是要完全确定 $a_0, a_i, a_{ij}, \cdots$ 等参数的值是不现实的,因为当 n 比较大时, 会产生巨大的维数灾. GMDH 方法是通过多层筛选的方法用局部简单的模型不断组合逼近式 (2), 以得到整体上比较复杂的模型.

基本的 GMDH 算法如图 1 所示, 其中 x_i 为初始输入变量,G 称为部分多项式,它是两个输入变量的完全二次多项式,$y_i^{(k)}$ 是由部分模型计算得到的输出,部分模型是通过拟合实测数据辨识得到的,$x_i^{(k)}$ 是中间变量,是从 $y_i^{(k)}$ 中按各层的检验准则筛选出来的,作为下一层的输入.

GMDH 网络的结构在训练过程中是不断的变化的,如图 2 所示为训练后的一个典型的网络结构.

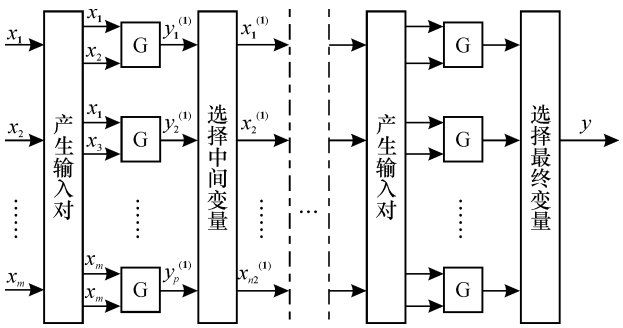


图 1 GMDH 算法

Fig. 1 Diagram of GMDH algorithm

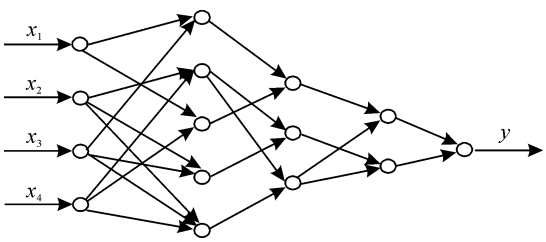


图 2 GMDH 网络结构

Fig. 2 Structure of GMDH network

该网络有 4 个输入和 1 个输出. GMDH 网络的输入层加工输入信号前向传递到中间层,中间层的每个神经元和前一层的 2 个神经元对应,因此,输出层的前一层(中间层)肯定只有 2 个神经元.

一般采用自适应线性元件作为 GMDH 网络中的神经元 (图 3), 该神经元的输入输出关系为

$$Z_{k,l} = w_5 Z_{k-1,i}^2 + w_4 Z_{k-1,i} Z_{k-1,j} + w_3 Z_{k-1,j}^2 + w_2 Z_{k-1,i} + w_1 Z_{k-1,j} + w_0. \quad (3)$$

其中,$Z_{k,l}$ 表示第 k 层的第 l 个处理单元,且 $Z_{0,l} = x_l$; w_i ($i = 1,2,3,4,5$) 为神经元的权值. 由式(3)可见,

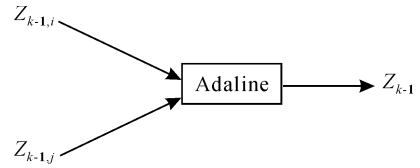


图 3 GMDH 网络中的神经元

Fig. 3 Nerve cell in GMDH network

GMDH 网络中的处理单元的输出是2 个输入量的二次多项式,因此网络的每一层将使得多项式的次数增大二阶,其结果是网络的输出可以表示成输入的高阶($2k$ 阶) 多项式,其中,k 是网络的层数(不含输入层).

2 GMDH 网络的训练及预测

2.1 GMDH 网络的训练

训练一个 GMDH 网络, 包括从输入层开始构造网络, 调整每一个神经元的权值和增加网络层数直到满足映射精度为止. 第 1 层的神经元数取决于输入信号的数量, 每一个输入信号需要一个神经元. 假设在时刻 k 神经元的权向量为

$$\boldsymbol{w}_k = [w_0, w_1, w_2, w_3, w_4, w_5]^{\mathrm{T}}, \quad (4)$$

输入向量为

$$\boldsymbol{x}_k = [1, , x_1, x_1^2, x_1 x_2, x_2, x_2^2], \quad (5)$$

由 Widrow-Hoff 学习规则可知

$$\boldsymbol{w}_{k+1}^{\mathrm{T}} = \boldsymbol{w}_k^{\mathrm{T}} + \alpha \frac{\boldsymbol{x}_k}{|\boldsymbol{x}_k|^2}(\boldsymbol{y}_{dk} - \boldsymbol{w}_k \boldsymbol{x}_k^{\mathrm{T}}). \quad (6)$$

式中:$\boldsymbol{y}_{dk}$ 为神经元在 k 时刻的目标输出向量;α 为学习效率,取值在[0.1,1) 之间. 按照上式可以调整神经元权值,降低神经元实际输出和目标输出之间的误差.

从权值调整公式可以看出, 网络期望输出值 $\boldsymbol{y}_{dk}$ 出现在每个输入神经元中, 并希望通过训练使各神经元都能达到这一期望输出. 对一个神经元来讲, 当训练数据集中每一个数据产生的均方差之和 S_E 达到最小时, 对这个神经元的训练就结束, 其权值予以固定. 当输入层的神经元被全部训练一遍后, 训练停止. 这时, 另一组数据 (通常称为选择数据) 被加到神经元上, 并计算相应的 S_E,对那些 S_E 小于阈值的神经元,即长入下一层,而其余神经元则舍弃,同时记录每一层神经元训练过程中产生的最小 S_E. 若当前曾在训练过程中产生的 S_E 小于前一层时(它表示网络精度得到提高),就产生一个新的神经元层,这一层中的神经元数取决于上一层中保留的神经元数,然后对新的神

经元层进行训练和选择，而保持一训练的神经元层不变，这一过程一直进行到 S_E 不再减小为止. 这时，取前一层神经元中误差最小的神经元作为网络输出. 当新神经元层只有一个神经元，且该层的 S_E 小于前一层时，这一神经元就作为输出神经元. 输出神经元确定以后，要对网络进行整理，所有与输出神经元无直接或间接联系的神经元都被舍弃，仅留下那些与输出有关的神经元.

2.2　基于 GMDH 网络的预测

训练一个用于预测的 GMDH 网络的步骤如下：

1）数据预处理. 包括数据规范化和除去数据中的静止直流成分. 习惯上，对于已有的输入输出样本，在进行神经网络的训练之前，首先进行归一化处理. 本文中对已有的输入输出数据作了式（7）所示的变换.

$$\begin{cases} u_i^* = \dfrac{u_i - u_{\min}}{u_{\max} - u_{\min}} \cdot 2 - 1, \\ y_i^* = \dfrac{y_i - y_{\min}}{y_{\max} - y_{\min}} \cdot 2 - 1. \end{cases} \tag{7}$$

式中：u_i、y_i 为第 i 组输入 - 输出实验数据对；$u_{\min}$、$u_{\max}$、$y_{\min}$、$y_{\max}$ 分别为 u_i、y_i 的最小值与最大值.

2）决定网络的输入信号数. 对于预测，需要用到 n 个过去输出值. 如果需要，n 的值可以通过计算相关系数确定.

3）将实验数据分成训练样本以及输出样本. 将样本数据分为学习集 A 和测试集 B. 大量的待选模型将在学习集 A 上产生，而测试集 B 中数据将用于对所产生模型的检验和筛选.

4）建立输入神经元层. 神经元数与输入信号数有关. 对每个输入信号，都有一个神经元与之对应，因此相应的神经元数为 C_i^2.

5）将神经元权值的初始值设为 0.

6）将训练数据组作用于输入层的每一个神经元. 在 k 时刻提取 $y_{k-1}(k = 1,2,\cdots)$ 作为输入信号，y_k 为期望输出，计算每一神经元的输出误差，并修正其权值和均方误差和，当均方差和大于上一循环计算值时，训练停止.

7）输入选择数据，计算每一神经元的输出均方差. 根据方差确定一个阈值，选择方差小于阈值的神经元作为小一层神经元.

8）当本层最小均方差大于前一层神经元的最小均方差或者本层仅有一个神经元时，停止训练过程. 如果训练是由于最小方差偏大引起的，则将前一层神经元作为输出层，并且重新整理网络；若训练是因本层只有一个神经元而停止的，且本次方差小于前一层时，则以本层神经元作为输出层并重新整理网络. 所谓重新整理网络，是指舍弃那些与输出神经元没有联系的神经元.

9）利用评价数据组检查训练好的网络性能. 评价数组可以是上述样本数据和测试数据的组合，也可以是一组全新的数据，采用全新数据可以在更广泛的基础上检查网络的性能. GMDH 神经网络的流程见图 4.

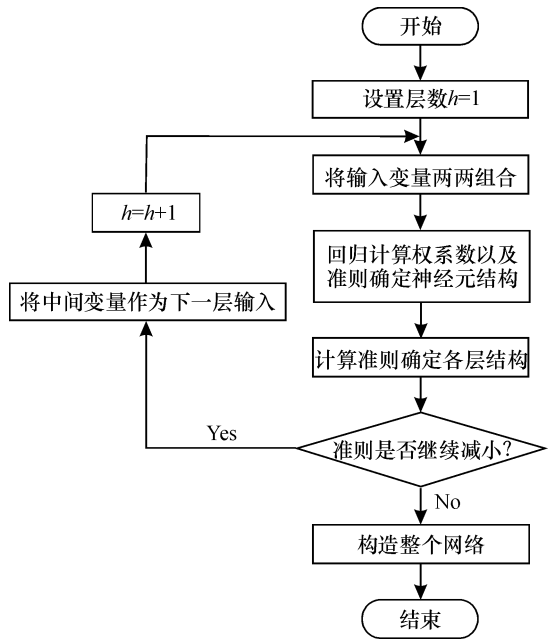


图 4　GMDH 神经网络流程图

Fig. 4　Flowing chart of GMDH neural network

3　GMDH 网络的实际应用

根据 GMDH 神经网络的原理与实现步骤，用 MATLAB 编写了 GMDH 神经网络的计算程序，并且使用变形监测数据对程序的实际效果进行检验，与人工神经网络中在数据处理以及预测方面应用最多的 BP 神经网络的预测结果进行比较，探讨了将其运用于变形数据预测的可行性.

笔者等尝试用对某超高建筑的一个沉降监测点的 55 期观测数据为应用实例，说明其应用过程. 其中的 1 ~ 45 期数据作为学习样本，采用本文的 GMDH 神经网络算法对其第 46 ~ 50 期变形数据进行短期预测以及对 51 ~ 55 期变形数据进行长

期预测，并且将预测结果同采用 BP 神经网络进行比较. 预测都采用只有一个输出的方式，然后将输出加入到样本中进行下一个预测. 两种方法的预测结果见表 1.

图 5 所示的折线图表明了两种预测方法所得到的预测结果之间的区别.

表 1 预测结果比较

Table 1 Comparision of prediction results mm

期数	实测变形量	BP 神经网络		GMDH 神经网络	
		预测值	绝对误差	预测值	绝对误差
46	21.00	21.26	+0.26	20.68	−0.32
47	21.98	22.50	+0.52	21.52	−0.46
48	24.02	24.64	+0.62	24.16	+0.14
49	24.49	25.46	+0.97	24.89	+0.40
50	27.05	25.93	−1.12	26.62	−0.43
51	27.46	27.02	−0.44	27.80	+0.34
52	29.82	27.37	−2.55	30.26	+0.44
53	30.30	28.41	−1.89	31.24	+0.94
54	32.49	29.28	−3.21	31.82	−0.67
55	33.27	29.75	−3.52	32.28	−0.99

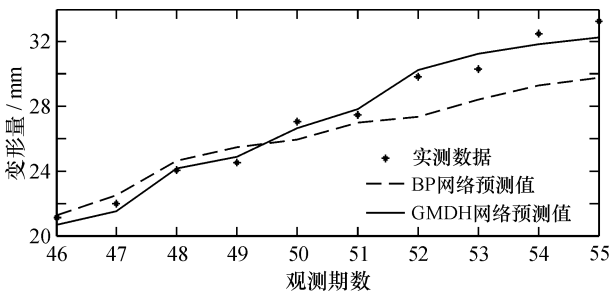


图 5 预测结果比较

Fig. 5 Comparison of different prediction methods

通过图表结果比较可以发现：GMDH 神经网络在短期预测精度方面稍优于 BP 神经网络；对于长期预测结果，BP 神经网络的预测结果开始整体偏离了实测数据，GMDH 神经网络虽也在精度上比短期预测有所下降，但依然优于 BP 神经网络的预测结果.

4 结 论

将 GMDH 神经网络应用到变形监测数据预测的实践之中，并且与 BP 神经网络预测得到的结果进行比较. 结果表明，GMDH 神经网络能够取得比较好的预测结果，相比应用最多的 BP 神经网络具有一定的优势. 由此，本文提出的对于变形监测数据的处理与预测的 GMDH 神经网络方法具有很好的实用以及参考价值.

参考文献：

[1] Ivakhnenko A G. Heuristic self-organization on problems of engineering cybernetics [J]. Automatic, 1970, 6 (3): 207 – 219.

[2] 刘光中，颜科琦，康银劳. 基于自组织理论的 GMDH 神经网络算法及应用 [J]. 数学的实践与认识，2001 (4): 464 – 467.

[3] 赵小梅，宋执环，李平. 改进的 GMDH 型神经网络及其在混沌预测中的应用 [J]. 电路与系统学报，2002 (1): 13 – 17.

[4] 飞思科技研发中心. 神经网络理论与 MATLAB 实现 [M]. 北京：电子工业出版社，2005.

New Method for Deformation Prediction

PAN Guo-rong[1,2], GU Chuan[1]

(1. *Department of Surveying and Geo-informatics*, *Tongji University*, *Shanghai* 200092, *China*;
2. *Key Laboratory of Modern Engineering Surveying*, *Shanghai* 200092, *China*)

Abstract: A new method for deformation prediction (GMDH NN) is put forward including short-term and long-term prediction in deformation prediction. The prediction is compared with BP NN. The result indicates that GMDH NN is a comparatively good prediction method, and has a wide application in deformation prediction.

Key words: GMDH algorithm; neural network; deformation prediction; BP neural netwook