

边坡变形分析与预报的模糊人工神经网络方法*

邓跃进 王葆元 张正禄

(武汉测绘科技大学地学测量工程学院,武汉市珞喻路 129 号, 430079)

摘要 边坡变形受地质、水文、气候、突发因素(如暴雨、地震)、人工活动(如开挖或防护)等各种因素的影响,这些因素与变形之间一般不是确定的定量关系。本文介绍了不同影响因素与位移量的模糊关系及位移量的模糊近似推论,在此基础上应用模糊人工神经网络进行位移量预报,并以一个边坡监测资料为例说明了具体的应用方法。

关键词 模糊关系;模糊近似推论;模糊人工神经网络;变形预报

分类号 TP391; P642

对于一个变形问题,人们不仅关注以前发生的变形,更关注产生变形的原因和将来可能会发生的变形,因此变形分析与预报具有广泛的现实意义。变形分析与预报时一般要建立一定的数学模型,如回归分析模型、时间序列模型和卡尔曼滤波模型等。这些模型主要用来描述变量间确定的函数关系,但事实上在变形分析中各影响因素与变形量之间的关系并非是确定的。例如,我们很难肯定地说“100mm 的暴雨会引起 2mm 的变形”而宁愿使用一些较模糊的概念,比如说“100mm 左右的暴雨可能引起大约 2mm 的变形”。对于影响边坡变形的地质条件好坏或人工开挖程度等则更没有确切的定量关系,但这些模糊信息并不影响我们对问题的理解,反而更符合实际。

另一方面,在变形分析与预报时建立顾及各种因素非线性影响的数学模型比较困难,因此对监测数据的处理和分析具有很大的局限性。为此,我们尝试用人工神经网络进行变形监测数据处理。应用人工神经网络进行变形预报时以各种因素作为网络的输入神经元,以变形量作为网络的输出,各因素与变形之间的非线性动力学关系则由网络的结构描述,网络训练好以后即可用于预报和因素识别。

1 变量间的模糊关系和模糊近似推论

1.1 模糊关系

设自变量 f 和因变量 g 为实可测因素(即可

定量地测量的因素,如降雨量、位移量等),其论域分别为:

$$U = \{u_1, u_2, \dots, u_m\}$$

$$V = \{v_1, v_2, \dots, v_n\}$$

其中 U 称为自变量论域, V 称为因变量论域, u_s ($s = 1, 2, \dots, m; j = 1, 2, \dots, n$) 分别称为论域 U 和 V 的控制点,且设 $\Delta_1 = u_{i+1} - u_i > 0, \Delta_2 = v_{j+1} - v_j > 0$ 分别为论域 U 和 V 中控制点间的步距。

设 (u, v) 为一组原始数据资料对,用二维线性信息分配方法构造原始信息矩阵 $Q(m \times n)$,当 $u \leq u < u_{i+1}, v \leq v < v_{j+1}$ 时,

$$q_{s,t} = (1 - |u - u_s| / \Delta_1)(1 - |v - v_t| / \Delta_2) \quad (1)$$

其中, $s = i, i+1; t = j, j+1$

假设有 p 组原始数据资料对 (u, v) , 分别按(1)式计算它分配给 Q_j 的信息 q_{ij}^k , 则可得:

$$Q_j = \sum_{k=1}^p q_{ij}^k \quad i = 1, 2, \dots, m; j = 1, 2, \dots, n \quad (2)$$

式中,上标 k 表示原始数据资料组的编号。

对原始信息矩阵 $Q(m \times n)$ 的各列作正规化处理(即用该列最大值遍除该列各值),则可得自变量 f 和因变量 g 间的模糊关系矩阵 $R(m \times n)$:

$$R_{ij} = Q_{ij} / q_j \quad i = 1, 2, \dots, m; j = 1, 2, \dots, n \quad (3)$$

其中, $q_j = \max(Q_{ij})$, 且有 $0 \leq R_{ij} \leq 1$

1.2 模糊近似推论

模糊近似推论就是由自变量论域 U 上的模

糊子集通过模糊关系矩阵推出因变量论域 V 上的模糊子集。先考虑单因素情况, 设 f 和 g 之间有模糊关系矩阵 $R(m \times n)$, 则有一级模糊近似推论:

$$B^{(1)} = A^{(1)} \odot R \quad (4)$$

式中, $B^{(1)} (\times n)$, $A^{(1)} (\times m)$ 分别为论域 U 和论域 V 的模糊子集; “ \odot ” 表示运算规则或合成关系, 本文取简单的矩阵相乘运算。 $A^{(1)}$ 可用下述方法确定^[1]:

$$\begin{aligned} & \text{当 } u \leq u_1 \text{ 时 } A^{(1)} = [1, 0, 0, \dots, 0] \\ & \text{当 } u \geq u_m \text{ 时 } A^{(1)} = [0, 0, 0, \dots, 1] \\ & \text{当 } u_1 < u < u_m \text{ 时} \\ & A^{(1)} = [\max\{0, 1 - |u - u_j| \Delta_1\}] \\ & j = 1, 2, \dots, m \end{aligned} \quad (5)$$

其次考虑 r 个因素 $f_i (i = 1, 2, \dots, r)$ 的综合影响。设根据 (4) 式已求得各因素 f_i 的一级模糊近似推论结果 $B_j^{(1)}$, 则有二级模糊近似推论:

$$B^{(2)} = A^{(2)} \odot R^{(2)} \quad (6)$$

式中, $A^{(2)}$ 为各影响因素的权重, 可用求灰色关联度方法获得^[3]。 $R^{(2)}$ 是以各因素的 $B_j^{(1)}$ 为行元素的 $r \times m$ 阶二级模糊关系矩阵, 即

$$R^{(2)} = [B_1^{(1)} \quad B_2^{(1)} \quad \dots \quad B_r^{(1)}]^T \quad (7)$$

式中, r 为因素的个数

2 模糊人工神经网络

在人工神经网络模型中用得较多的是 BP (Back Propagation) 网络模型, 其一般结构如图 1 所示。网络由输入层神经元、隐含层神经元和输出层神经元组成。同一层神经元之间不互连, 不同层神经元间则全互连。传统的 BP 网络对确定型因果关系 (即一定的输入对应确定的输出) 具有很强的识别能力, 但不能处理矛盾样本。而现实中的模式识别常要求在复杂的环境下进行, 不可能把一切因素把握得十分准确。例如, 影响变形的因素除了降雨量、地下水、地质条件和人工开挖等重要因素外还有许多其它因素, 在同一时期地质条件和人工开挖程度都相近的两点的变形量可能存在显著差异, 而不同时期和不同点的变形量却可能相同。如果以各因素作为网络的输入神经元, 以变形量作为网络的输出, 这样就存在矛盾样本, 即输入相同而输出不同或输入不同而输出相同。为了处理矛盾样本, 文献 [1] 介绍了单个因素情况下基于信息扩散方法的模糊人工神经网络, 其实质是通过因素进行信息扩散从而将矛盾样本转化为非矛盾样本。本文则针对多个因素的情况构造基于

二级模糊近似推论的人工神经网络, 直接以各影响因素作为输入神经元, 而以位移量的二级模糊近似推论结果作为网络的输出。因为网络的输出是位移量的二级模糊近似推论结果而不是单个的位移量, 故存在矛盾样本的可能性就大大减少了。




图 1 BP 网络模型结构

Fig. 1 Back Propagation Neural Network Model

设网络的输入为 $X = (x_1, x_2, \dots, x_n)$, 输出为 $Y = (y_1, y_2, \dots, y_m)$, 理想输出为 $Y' = (y_1', y_2', \dots, y_m')$ 。网络的一般学习过程为:

(1) 将学习样本归化到 $[0, 1]$ 区间, 产生 $[0, 1]$ 区间的随机数作为神经元连接权的初值和阈值。

(2) 计算网络的输出 Y

a. 对于输入神经元, 其输出 o_j^I 与输入 x_j 相等, 即 $o_j^I = x_j, j = 1, 2, \dots, n$

b. 对于隐含神经元, 其输入 net^H 与输出 o_j^H 分别为:

$$\begin{aligned} net^H &= \sum_{i=1}^n W_{ji}^{HI} \alpha^I \\ o_j^H &= f(net^H - \theta_j^H), j = 1, 2, \dots, l \end{aligned} \quad (8)$$

式中, W_{ji}^{HI} 为隐含神经元 j 与输入神经元 i 的连接权; θ_j^H 为隐含神经元 j 的阈值; l 为隐含神经元个数; α^I 为输入神经元 i 的输出, 即 x_i ; f 为 sigmoid 函数, $f = 1 / (1 + \exp(-x))$

c. 对于输出神经元, 其输入 net^O 和输出 y_j 分别为:

$$\begin{aligned} net^O &= \sum_{i=1}^l W_{ji}^{OH} o_i^H \\ y_j &= f(net^O - \theta_j^O), j = 1, 2, \dots, m \end{aligned} \quad (9)$$

式中, W_{ji}^{OH} 为输出神经元 j 与隐含神经元 i 的连接权, θ_j^O 为输出神经元 j 的阈值。

(3) 计算均方差 $D = \|Y' - Y\|_2$, 如果 D 小于规定的值, 转 (5), 否则转 (4)

(4)按下式修改权值:

a. 对于输出神经元与隐含神经元的权 W_{ji}^{OH}

修改为:

$$\begin{aligned} W_{ji}^{OH} &= W_{ji}^{OH} + \Delta W_{ji}^{OH} \\ \Delta W_{ji}^{OH} &= \alpha \delta_j^o \alpha^H \\ \delta_j^o &= (y_j' - y_j) y_j (1 - y_j) \end{aligned} \quad (10)$$

式中, α 为学习速率

b. 对于隐含神经元与输入神经元的权 W_{ji}^{HI}

修改为:

$$\begin{aligned} W_{ji}^{HI} &= W_{ji}^{HI} + \Delta W_{ji}^{HI} \\ \Delta W_{ji}^{HI} &= \alpha \delta_j^H \alpha^I \\ \delta_j^H &= o_j^H (1 - o_j^H) \sum_{k=1}^m W_{kj}^{OH} \delta_k^o \end{aligned} \quad (11)$$

(5)进行下一个样本的训练,当所有样本训练

完成后,计算总能量 $E = \sum_{k=1}^p D_k$ (p 为样本个数),若 E 小于规定的值,则结束,否则根据上一周期的权值修改按下式调整权值并转 (2),再从第一个样本开始训练学习:

$$\begin{aligned} W_{ji}^{OH}(k+1) &= W_{ji}^{OH}(k) + \tau \Delta W_{ji}^{OH}(k) \\ W_{ji}^{HI}(k+1) &= W_{ji}^{HI}(k) + \tau \Delta W_{ji}^{HI}(k) \end{aligned} \quad (12)$$

式中, τ 为学习效率; $\Delta W_{ji}^{OH}(k)$ 、 $\Delta W_{ji}^{HI}(k)$ 为上一学习周期的权值修改

网络学习完成后即可按 (8)、(9) 式进行识别或预报

3 实例

表 1 是某高边坡上一监测点 1993 年的部分监测资料,现应用前述方法分析月降雨量 r 、月平均地下水位 d 与月位移量 s 的模糊关系,并应用模糊人工神经网络对月位移量进行预报

表 1 某点 1993 年度部分监测数据

Tab. 1 Some Monitoring Data of a Point in 1993

月份	r /mm	d /m	s /mm
1	106.6	95.46	11
2	123.5	97.77	6
3	150.3	98.42	9
4	136.2	98.03	10
5	170.8	95.57	9
6	143.7	97.84	9
7	250.8	99.51	13
8	52.6	104.54	11
9	24.7	95.67	2
10	13.8	95.03	1
11	16.9	96.86	2
12	26.4	96.36	1

3.1 各因素与位移量的模糊关系

下面以月降雨量因素 r 为例计算其与月位移量 s 的模糊关系矩阵 $R^{r,s}$ 。根据表 1 (论域的选取与样本数据有关),取月降雨量因素 r 的论域 $U = \{u_1^r, u_2^r, \dots, u_8^r\} = \{0, 40, 80, 120, 160, 200, 240, 280\}$,步距 $\Delta_1 = 40\text{mm}$,取月位移量的论域 $V = \{v_1, v_2, v_3, v_4, v_5\} = \{0, 4, 8, 12, 16\}$,步距 $\Delta_2 = 4\text{mm}$ 。表 1 中月降雨量与月位移量构成 12 组数据对,即 (106.6, 11), (123.5, 6), ..., (26.4, 1)。以第一组数据对 (106.6, 11) 为例,因 $80\text{mm} = u_3^r < u^r = 106.6\text{mm} < u_4^r = 120\text{mm}$,故 $i = 3$;又 $8\text{mm} = v_3 < v = 11\text{mm} < v_4 = 12\text{mm}$,故 $j = 3$,按 (1) 式计算有: $q_{3,3} = 0.0838$, $q_{4,3} = 0.1663$, $q_{3,4} = 0.2513$, $q_{4,4} = 0.4988$ 。同理对其它数据对分别计算,按 (2) 式将相同的元素相加得原始信息矩阵 $Q^{r,s}$ (8×5):

$$Q^{r,s} = \begin{bmatrix} 1.2264 & 0.7289 & 0 & 0 & 0 \\ 1.2739 & 0.7714 & 0.1713 & 0.5138 & 0 \\ 0 & 0 & 0.1626 & 0.4876 & 0 \\ 0 & 0 & 1.4076 & 1.4151 & 0 \\ 0 & 0 & 1.8062 & 0.7662 & 0 \\ 0 & 0 & 0.2025 & 0.0675 & 0 \\ 0 & 0 & 0 & 0.5475 & 0.1825 \\ 0 & 0 & 0 & 0.2025 & 0.0675 \end{bmatrix} \begin{matrix} u_1^r \\ u_2^r \\ u_3^r \\ u_4^r \\ u_5^r \\ u_6^r \\ u_7^r \\ u_8^r \end{matrix}$$

按 (3) 式对 $Q^{r,s}$ 作正规化处理得模糊关系矩阵 $R^{r,s}$ (8×5)。取月平均地下水位因素 d 的论域

为 $U^d = \{u_1^d, u_2^d, \dots, u_5^d\} = \{95, 98, 101, 104, 107\}$,步距为 3m ,同理可得其与月位移量的模糊

关系矩阵 $R^{d,s} (5 \times 5)$

$$R^{r,s} = \begin{bmatrix} v_1 & v_2 & v_3 & v_4 & v_5 \\ 0.9627 & 0.9449 & 0 & 0 & 0 \\ 1 & 1 & 0.0948 & 0.3631 & 0 \\ 0 & 0 & 0.0900 & 0.3446 & 0 \\ 0 & 0 & 0.7793 & 1 & 0 \\ 0 & 0 & 1 & 0.5414 & 0 \\ 0 & 0 & 0.1121 & 0.0477 & 0 \\ 0 & 0 & 0 & 0.3869 & 1 \\ 0 & 0 & 0 & 0.1431 & 0.3699 \end{bmatrix} \begin{matrix} u_1^r \\ u_2^r \\ u_3^r \\ u_4^r \\ u_5^r \\ u_6^r \\ u_7^r \\ u_8^r \end{matrix}$$

$$R^{d,s} = \begin{bmatrix} v_1 & v_2 & v_3 & v_4 & v_5 \\ 1 & 0.9560 & 0.3601 & 0.5742 & 0 \\ 0.4444 & 1 & 1 & 1 & 0.9873 \\ 0 & 0 & 0.0441 & 0.2818 & 1 \\ 0 & 0 & 0.0822 & 0.4151 & 0 \\ 0 & 0 & 0.0181 & 0.0911 & 0 \end{bmatrix} \begin{matrix} u_1^d \\ u_2^d \\ u_3^d \\ u_4^d \\ u_5^d \end{matrix}$$

地质条件和人工开挖因素也是影响变形的重要因素,但它们不是实可测因素,不能按上述方法建立其与变形量的模糊关系。可根据专家评判或打分方法给出大概隶属度,并构造模糊关系矩阵。设地质条件因素 g 和人工开挖因素 h 的论域分别为 $U^g = \{u_1^g, u_2^g, \dots, u_s^g\} = \{\text{极好, 较好, 一般, 较差, 极差}\}$, $U^h = \{u_1^h, u_2^h, u_3^h, u_4^h\} = \{\text{大开挖, 小开挖, 未开挖, 加固}\}$, 它们与位移量的模糊关系矩阵 $R^{g,s} (5 \times 5)$, $R^{h,s} (4 \times 5)$ 分别构造如下:

$$R^{g,s} = \begin{bmatrix} v_1 & v_2 & v_3 & v_4 & v_5 \\ 1.0 & 0.7 & 0.1 & 0 & 0 \\ 0.8 & 1.0 & 0.3 & 0 & 0 \\ 0.2 & 0.8 & 1.0 & 0.4 & 0.1 \\ 0 & 0.4 & 0.8 & 1.0 & 0.2 \\ 0 & 0 & 0.6 & 0.9 & 1.0 \end{bmatrix} \begin{matrix} u_1^g \\ u_2^g \\ u_3^g \\ u_4^g \\ u_5^g \end{matrix}$$

$$R^{h,s} = \begin{bmatrix} v_1 & v_2 & v_3 & v_4 & v_5 \\ 0 & 0.3 & 0.8 & 1.0 & 0.8 \\ 0 & 0.2 & 1.0 & 0.7 & 0.1 \\ 0.8 & 1.0 & 0.5 & 0.1 & 0 \\ 1.0 & 0.6 & 0.1 & 0 & 0 \end{bmatrix} \begin{matrix} u_1^h \\ u_2^h \\ u_3^h \\ u_4^h \end{matrix}$$

模糊关系矩阵 $R^{g,s}$ 中的元素可理解为在不同的地质条件下产生不同的变形的可能性,例如 $R_{11}^{g,s} = 1.0$ 可理解为在地质条件为 $u_1^g = \text{极好}$ 时,位移量为 $v_1 = 0\text{mm}$ 的可能性为 1.0。对 $R^{h,s}$ 可作同样的理解,但对定量计算得到的 $R^{r,s}$ 和 $R^{d,s}$ 不能作这样简单的理解。

3.2 位移量的模糊近似推论

仍以降雨量因素为例,对第一组数据对 (106.6, 11), 按 (5) 式得 $A^{(1)} = [0, 0, 0.335,$

$0.665, 0, 0, 0, 0]$, 由 (4) 式得 $B_r^{(1)} = [0, 0, 0.5383, 0.7804, 0]$, $B_r^{(1)}$ 可理解为在月降雨量为 106.6mm 的条件下月位移量分别为 0, 4, 8, 12, 16mm 的可能性分别为 0, 0, 0.5383, 0.7804, 0, 即月位移量在 8~12mm 之间的可能性最大。同理对表 1 中月平均地下水位因素 d 的第一列数据对 (95.46, 11) 有 $B_d^{(1)} = [0.9148, 0.9627, 0.4582, 0.6395, 0.1514]$ 。又从资料中获知该点处的地质条件为较差, 1993 年度也未进行开挖, 故可取 $A_g^{(1)} = [0, 0, 0, 1, 0]$, $A_h^{(1)} = [0, 0, 1, 0]$, 则得 $B_g^{(1)} = [0, 0.4, 0.8, 1.0, 0.2]$, $B_h^{(1)} = [0.8, 1.0, 0.5, 0.1, 0]$ 。因此有二级模糊关系矩阵 $R^{(2)}$:

$$R^{(2)} = \begin{matrix} & B_r^{(1)} & B_d^{(1)} & B_g^{(1)} & B_h^{(1)} \\ \begin{matrix} v_1 \\ v_2 \\ v_3 \\ v_4 \\ v_5 \end{matrix} & \begin{bmatrix} 0 & 0.9148 & 0 & 0.8 \\ 0 & 0.9627 & 0.4 & 1.0 \\ 0.5383 & 0.4582 & 0.8 & 0.5 \\ 0.7804 & 0.6395 & 1.0 & 0.1 \\ 0 & 0.1514 & 0.2 & 0 \end{bmatrix} \end{matrix}^T$$

在进行二级模糊近似推论时, $A^{(2)}$ 可根据其它监测数据按求灰色关联度方法获得。本文限于篇幅, 有关灰色关联度的计算将另文给出, 此处则直接引用计算结果, 即 $A^{(2)} = [0.327, 0.164, 0.529, 0.315]$, 则由 (6) 式可得 $B^{(2)} = [0.402, 0.684, 0.832, 0.922, 0.131]$, 即在月降雨量为 106.6mm, 月平均地下水位为 95.46m, 地质条件较差和未开挖的情况下引起的位移量可能接近 12mm, 这与实际变形观测为 11mm 的结果是相符的。同理可对其它数据进行二级模糊近似推论。为了验证上述模糊关系及模糊近似推论的正确

性,我们对该边坡 15个具有代表性的监测点, 1993年度共 180组数据进行计算,推得的结果与实际监测值基本相符。具体数据和计算结果将在其它文献中给出,在此不一一罗列

3.3 位移量模糊预报的神经网络方法

以月降雨量、月平均地下水位、地质条件和人工开挖 4个因素用作 BP网络的输入神经元,以位移量的二级模糊近似推论结果作为网络的输出,即 4个输入神经元和 5个输出神经元。取隐含

神经元个数为 6,利用该边坡 15个具有代表性的监测点, 1993年度共 180组数据,按上述方法处理后作为训练样本。训练前按 (13)式将样本归化到 $[0, 1]$ 区间:

$$x_i^p = (x_i^p - x_{\min}^p) / (x_{\max}^p - x_{\min}^p) \quad (13)$$

式中, $x_{\max}^p = \max \{x_i^p\}$; $x_{\min}^p = \min \{x_i^p\}$; N 为样本个数,此处 $N= 180$,上标 p 表示因素, $p= 1, 2, 3, 4$

表 2 1994年部分位移量观测值 (/mm)和模糊预报结果 (预报值最可能区间)

Tab. 2 Predictions of some Displacements (most Probable Regions) in 1994 by the Presented Approach

点号	月份	1	2	3	4	5	6	7	8	9	10
1	观测值	4	- 4	3	4	11	12	10	6	- 1	0
	预报值区间	[2, 4]	[- 4, - 2]	[2, 4]	[2, 4]	[8, 10]	[12, 14]	[8, 10]	[6, 8]	[0, 2]	[- 2, 0]
2	观测值	2	- 1	- 1	2	8	9	7	2	3	1
	预报值区间	[0, 2]	[- 2, 0]	[0, 2]	[0, 2]	[6, 8]	[8, 10]	[6, 8]	[2, 4]	[2, 4]	[0, 2]
3	观测值	2	0	- 3	4	4	2	0	3	- 1	0
	预报值区间	[0, 2]	[- 2, 0]	[- 2, 0]	[2, 4]	[4, 6]	[2, 4]	[0, 2]	[2, 4]	[- 2, 0]	[- 2, 0]
4	观测值	2	- 1	0	- 1	5	10	11	4	7	2
	预报值区间	[0, 2]	[- 2, 0]	[- 2, 2]	[- 2, 0]	[2, 4]	[6, 8]	[8, 10]	[4, 6]	[6, 8]	[2, 4]
5	观测值	0	- 1	1	2	6	9	4	2	- 3	0
	预报值区间	[0, 2]	[- 2, 0]	[0, 2]	[0, 2]	[4, 6]	[8, 10]	[4, 6]	[2, 4]	[- 2, 0]	[- 2, 0]
6	观测值	6	2	0	3	10	10	9	4	- 1	2
	预报值区间	[4, 6]	[2, 4]	[0, 2]	[2, 4]	[8, 10]	[8, 10]	[8, 10]	[4, 6]	[- 2, 0]	[0, 2]
7	观测值	0	- 3	2	4	- 2	8	5	3	- 1	2
	预报值区间	[0, 2]	[- 2, 0]	[0, 2]	[2, 4]	[- 2, 0]	[4, 6]	[4, 6]	[2, 4]	[- 2, 0]	[0, 2]
8	观测值	0	- 3	3	3	5	8	2	3	2	1
	预报值区间	[- 2, 0]	[- 4, - 2]	[2, 4]	[2, 4]	[4, 6]	[4, 6]	[2, 4]	[2, 4]	[2, 4]	[0, 2]
9	观测值	2	- 3	1	1	- 1	2	0	6	2	- 1
	预报值区间	[0, 2]	[- 2, 0]	[- 2, 0]	[0, 2]	[- 2, 0]	[0, 2]	[0, 2]	[4, 6]	[2, 4]	[0, 2]
10	观测值	3	0	- 1	1	3	10	12	8	4	3
	预报值区间	[2, 4]	[0, 2]	[- 2, 0]	[0, 2]	[0, 2]	[8, 10]	[10, 12]	[6, 8]	[4, 6]	[2, 4]
11	观测值	3	- 2	0	1	3	1	3	6	2	- 4
	预报值区间	[2, 4]	[- 2, 0]	[0, 2]	[0, 2]	[0, 2]	[0, 2]	[0, 2]	[2, 4]	[6, 8]	[2, 4]
12	观测值	6	- 1	1	2	6	9	4	3	1	- 2
	预报值区间	[2, 4]	[- 2, 0]	[0, 2]	[0, 2]	[4, 6]	[8, 10]	[2, 4]	[2, 4]	[0, 2]	[- 2, 0]
13	观测值	2	- 1	0	3	3	5	7	1	- 2	0
	预报值区间	[0, 2]	[- 2, 0]	[0, 2]	[2, 4]	[2, 4]	[2, 4]	[4, 6]	[2, 4]	[- 2, 0]	[- 2, 0]
14	观测值	0	0	2	4	9	8	13	6	- 3	4
	预报值区间	[- 2, 0]	[0, 2]	[0, 2]	[2, 4]	[8, 10]	[8, 10]	[10, 12]	[6, 8]	[- 4, - 2]	[2, 4]
15	观测值	3	- 3	1	3	11	5	1	- 2	5	- 1
	预报值区间	[0, 2]	[- 2, 0]	[0, 2]	[2, 4]	[8, 10]	[4, 6]	[0, 2]	[- 2, 0]	[4, 6]	[- 2, 0]

根据上述 BP 网络的学习算法,得到网络训练后输入层到隐含层的连接权阵 W^{HI} (表 6)及隐含层到输出层的连接权阵 W^{OH} (表 5)分别如下:

		隐含层					
		1	2	3	4	5	6
输入层	1	0.646	0.342	0.342	0.645	0.312	0.672
	2	0.545	0.378	0.975	0.345	0.632	0.385
	3	0.742	0.975	0.697	0.675	0.851	0.354
	4	0.597	0.371	0.249	0.159	0.874	0.325

		输出层				
		1	2	3	4	5
隐含层	1	0.645	0.698	0.164	0.642	0.455
	2	0.878	0.318	0.975	0.642	0.641
	3	0.487	0.641	0.646	0.954	0.159
	4	0.348	0.546	0.434	0.484	0.871
	5	0.564	0.648	0.962	0.445	0.422
	6	0.975	0.643	0.154	0.313	0.444

应用训练好的网络对该边坡 1994 年的监测数据进行模糊预报,取得了较好的预报效果(在表 2 中列出了部分预报结果)。与传统的回归模型或时间序列模型相比,神经网络方法不要求监测数据具有很强的规律性,且可用训练后的网络对所

有监测点预报,因此具有一定的实用性

4 结 论

影响变形的因素具有模糊不确定性。初步试验表明,根据观测资料,利用神经网络模型建立变形与多种不同因素间的复杂关系并进行变形预报是可行的。模糊关系和模糊近似推论的建立依赖于样本的容量及各因素论域和权重的确定。如何充分利用样本信息,从有限的样本中最佳地建立各因素与变形间的模糊关系及在应用人工神经网络进行预报时如何利用新的资料自适应性地更新网络等问题有待进一步深入研究。

参 考 文 献

- 1 黄崇福,王家鼎.模糊信息优化处理技术及其应用.北京:北京航空航天大学出版社,1995.
- 2 胡守仁,余少波,戴葵.神经网络导论.长沙:国防科技大学出版社,1993.
- 3 邓聚龙.灰色系统理论教程.武汉:华中理工大学出版社,1991.

Application of Fuzzy Artificial Neural Network to the Deformation Analysis and Predication of Side Slope

Deng Yuejin Wang Baoyuan Zhang Zhenglu

(School of Geo-science and Surveying Engineering, W TU SM, 129 Luoyu Road, Wuhan, China, 430079)

Abstract The deformation of a side slope depends on several factors, such as geological condition, rainfall and underground water. However, the relationships between these factors and deformation can not be surely regarded as determinate and quantitative. In this paper the fuzzy relationships between different factors and displacement as well as the fuzzy approximate inference of displacement are analyzed, then based on this the application of fuzzy artificial neural network to deformation predication is introduced and demonstrated by a practical example of a side slope deformation monitoring.

Key words fuzzy relationship; fuzzy approximate inference; fuzzy artificial neural network; deformation predication