

文章编号: 0451-0712(2001)03-0052-03

中图分类号: U445.48; U495

文献标识码: B

人工神经网络在隧洞支护中的应用

杨 述, 曹德成

(清华大学土木水利学院工程管理学系 北京市 100084)

摘 要: 首次将人工神经网络应用于隧洞开挖过程的支护时间预测中, 并通过自编程序证明了该法的可行性, 研究表明, 该法不仅可以综合考虑各种因素的影响, 而且可以十分有效地处理常规方法难以解决的问题。

关键词: 人工神经网络; 隧道支护; 应用

新奥法已经被广泛应用于隧洞施工中, 在开挖过程中, 支护时间的确定不仅关系到隧洞开挖的安全, 同时对工程经济性和总的开挖进度起着至关重要的作用。支护时间的确定, 往往受到多种因素的综合影响, 比如, 隧洞地质条件、地下水、环境温度、开挖方式、开挖进度、隧洞尺寸、截面形状、支护形式、支护材料等, 所以对于支护时间的确定, 传统方法很难准确预测, 人工神经网络则具有解决复杂的、不确定性的、非线性问题的能力, 因而在对基坑变形进行预测方面具有明显的优势。

1 BP 网络结构描述

BP 网络是由非线性变换单元组成的前馈型人工神经网络, 它的一个重要特点是由于其变换函数 $f(u)$ 是连续可微的, 因而可以严格利用梯度法进行推算, 它的权的学习解析式十分明确, 其学习算法称为反向传播算法 (Back-Propagation), 简称 BP 算法, 因而这种网络也称为 BP 网络。BP 网络每个神经元满足下列方程:

$$s_j = \sum \omega_{ij} X_i - \theta_j \quad (1)$$

$$u_j = g(s_j) \quad (2)$$

$$y_j = f(u_j) \quad (3)$$

式中: s_j 为神经元突触后电位的累加之值; θ_j 为阈值; u_j 为细胞 j 的状态, 在多数人工神经网络中, g 函数为一个线性函数, 或直接简化为 $\mu_j = s_j$; y_j 为表示神经元 j 的输出; $f(u_j)$ 为输入输出变换函数, 可取如下所示的非线性变换:

$$f(u_j) = \frac{1}{1 + e^{-u_j}} = \frac{1}{1 + e^{-(\sum \omega_{ij} X_i - \theta_j)}} \quad (4)$$

函数 $f(u_j)$ 的图形如图 1 所示, 它是一个连续可微的函数, 其一阶导数存在, 且满足输入与输出为非线性单调上升的关系。




图 1 函数 $f(u_j)$ 图形

图 2 所示是一个典型的多层 BP 网络的结构。设输入层有 n 个神经元, 输入矢量为 $x \in R^n$, $x = (x_1, x_2, \dots, x_n)^T$; 第二层有 n_1 个神经元, $x' \in R^{n_1}$, $x' = (x'_1, x'_2, \dots, x'_{n_1})^T$; 第三层有 n_2 个神经元; $x'' \in R^{n_2}$, $x'' = (x''_1, x''_2, \dots, x''_{n_2})^T$; 最后输出 m 个神经元, $y \in R_m$, $y = (y_1, y_2, \dots, y_m)^T$ 。如输入与第二层之间的连接权为 w_{ij} , 阈值为 θ_j ; 第二层与第三层之间的连接权为 w'_{jk} , 阈值为 θ'_k ; 第三层与最后层之间的连接权为 w''_{kl} , 阈值为 θ''_l , 则各层神经元的输出满足:

$$\begin{cases} y_l = f(u_l) = f(\sum_{k=1}^{n_2} \omega''_{kl} \times X''_k - \theta''_l) & \text{最后层输出} \\ X''_k = f(u'_k) = f(\sum_{j=1}^{n_1} \omega'_{jk} \times X'_j - \theta'_k) & \text{第三层输出} \\ X'_j = f(u_j) = f(\sum_{i=1}^n \omega_{ij} \times X_i - \theta_j) & \text{第二层输出} \end{cases} \quad (5)$$

式中: $l = 1, 2, \dots, m$; $k = 1, 2, \dots, n_2$; $j = 1, 2, \dots, n_1$; $i = 1, 2, \dots, n$ 。

收稿日期: 2001-01-08




图2 多层B-P网络(四层)

BP网络的学习算法与BP网络的基本思想是利用LMS算法(即 δ 学习律),通过梯度搜索技术,使网络的希望输出和实际输出的均方差最小。在学习时,首先需要提供足够样本的教师,然后根据误差修改权的初始值,直到满足要求为止。如果要输入的学习样本数为 P 个, x^1, x^2, \dots, x^P ,已知与其对应的教师为 t^1, t^2, \dots, t^P ,LMS算法是用实际的输出 y^1, y^2, \dots, y^P 与教师 t^1, t^2, \dots, t^P 之间的误差来修改其连接权和阈值,使 y^{P_l} 与要求的 t^{P_l} 尽可能接近。为方便起见,在图2的网络中,把阈值写入连接权中,令:

$\theta_l = w_{0l}, \theta'_k = w_{0k}, \theta_j = w_{0j}; x_0 = x'_0 = x''_0 = -1$ 。则方程(5)改为:

$$\begin{cases} y_l = f(u_l) = f(\sum_{k=1}^{n_2} w_{lk} \times X'_k) \\ X'_k = f(u'_k) = f(\sum_{j=1}^{n_2} w'_{jk} \times X_j) \\ X_j = f(u_j) = f(\sum_{i=1}^n w_{ij} \times X_i) \end{cases} \quad (6)$$

如果第 P_l 个样本输入到图2所示的网络中,得到输出 $y_l, l=1, 2, \dots, m$ 。则误差为:

$$E_{P_l} = \frac{1}{2} \sum_{l=1}^m (t^{P_l} - y^{P_l})^2 \quad (7)$$

对于 P 个学习样本其总误差为:

$$E_g = \sum_{P=1}^P E_{P_l} = \frac{1}{2} \sum_{P=1}^P \sum_{l=1}^m (t^{P_l} - y^{P_l})^2 \quad (8)$$

采用梯度下降法,对每个 w_{sq} 的修正值为:

$$\Delta w_{sq} = - \sum_{P_l=1}^P \eta \frac{\partial E}{\partial w_{sq}} \quad (9)$$

式中: η 为步长。则由此可推出多层BP网络各层之间权修正的基本表达式如下:

$$w_{lk}(n_0+1) = w_{lk}(n_0) + \eta \sum_{P_l=1}^P \delta_{P_l}^l X_k^{P_l} \quad (10)$$

$$w'_{jk}(n_0+1) = w'_{jk}(n_0) + \eta \sum_{P_l=1}^P \delta_{P_l}^k X_j^{P_l} \quad (11)$$

$$w_{ij}(n_0+1) = w_{ij}(n_0) + \eta \sum_{P_l=1}^P \delta_{P_l}^j X_i^{P_l} \quad (12)$$

当权的修正是在所有样本输入后通过计算其总的误差而进行的,则这种修正被称为批处理。批处理修正可以保证其 E 总向减小的方向变化,在样本数多的时候,它比分别处理时的收敛速度快。由以上分析可以看出,整个BP网络的学习过程分为两个阶段:第一个阶段是从网络的底部向上进行计算,如果网络的结构权已设定,输入已知学习样本,可按公式(6)计算每一层的神经元输出;第二个阶段是对权值和阈值的修改,这是从最高层向下进行计算和修改。从已知最高层的误差修改与最高层相联的权,然后按公式(10)、(11)、(12)修改各层的权;两个过程反复交替,直到达到收敛为止。具体计算步骤如下:

(1)对图2所示网络各层的权和阈值赋初值,可取一个随机数加到各层上,使 $w_{sq}(0) = \text{Random}(\cdot)$, sq 为 ij, jk, kl ;

(2)在已知 P 个学习样本中,依次将样本输入到图2所示的网络中。先取一个样本 $P_1=1$,将其输入 $x_i^{P_1}$ 和期望输出(教师) $t_i^{P_1}$ 输入到网络中;

(3)按公式(6)分别计算各层的输出 x_j, x'_k, y_l ;

(4)计算网络输出误差:第 P_1 个样本的输出误差按公式(7)进行计算;

(5)待所有样本均输入网络后,按公式(8)进行网络总误差计算。如果 $E_{\text{总}} < \epsilon$,则学习停止,其中 ϵ 为大于0的一个给定小数;否则转到步骤(6);

(6)反向逐层计算网络各层节点误差。对已知样本的教师可得:

$$\delta_{P_1}^l = (t_i^{P_1} - y_i^{P_1}) y_i^{P_1} (1 - y_i^{P_1})$$

$$\delta_{P_1}^k = \sum_{l=1}^{n_1} \delta_{P_1}^l w_{lk} X_k^{P_1} (1 - X_k^{P_1})$$

$$\delta_{P_1}^j = \sum_{k=1}^{n_2} \delta_{P_1}^k w'_{jk} X_j^{P_1} (1 - X_j^{P_1})$$

(7)按公式(10)、(11)、(12)修改各层的权和阈值,回到步骤(2)继续进行计算,直到满足要求为止。

2 工程背景

天生桥一级水电站引水隧洞开挖洞径为11.6 m,通过的地层为三迭系中统边阳组T2b互层状厚层、中厚层泥岩和砂岩,其中泥岩约占2/3,湿抗压强度为15~20 MPa,且具有失水崩解的特性。岩层走向与隧洞轴线走向近于平行,倾角为45°~50°,倾向山里,岩体质地软弱,层间错动带和节理(共5组,其中一组为反倾向节理,与层面组合于洞顶易形成“屋脊形”塌方)极为发育,且沿线有3条较大的断

层(F19、F20、F26)。岩石坚固系数 $f=2\sim4$, 围岩以 IV 类为主, 少量为 III 类和 V 类围岩。引水隧洞穿越的 10 号冲沟除地质构造复杂外, 上覆岩层薄, 厚度仅 18~28 m, 其中强风化带宽 8~10 m。弱风化带以下(含弱风化带)岩层仅为隧洞开挖洞径的 1~1.5 倍, 隧洞稳定性差。其特殊的地质条件对施工的影响和威胁较大, 而喷锚支护好坏是隧洞施工成败的关键。设计方面明确要求引水隧洞的开挖采用“新奥法”施工。

隧洞开挖支护时间预测的神经网络模型采用三层结构如图 3 所示, 输入层包括 5 个单元, 分别为开挖半径 x_1 (不规则截面取折算后的值)、地下水压力 x_2 、岩石弹模 x_3 、岩石风化程度 x_4 、上部覆盖层厚度 x_5 。隐层包含 11 个单元, 输出层仅有一个单元 y , 即开挖到支护的最佳时间。在具体应用时, 各输入量不能直接输入到网络中, 须先将各输入量进行规范化处理, 将它们变化为 0~1 之间的值, 然后再输入网络中进行计算。同样, 经过网络计算得到的结果, 也必须经还原后, 才成为所要预测的支护最佳时间。

本例中, x_1, x_2, x_3 分别以 m、MPa、m 为基数进行规范化处理, 而 x_4, x_5 则直接折算进行规范化处理。输出层单元以“h”为单位。




图 3 人工神经网络应用模型

本文根据天生桥一级水电站引水隧洞的开挖监测数据, 选取了 30 个样本进行验证(所有样本均经作者进行了适当的转化)。其中以 25 个样本进行学习, 5 个样本作为测试。学习样本如表 1 所示, 其中

表 1 实例验证人工神经网络学习样本输入样本

输入样本编号	神经元输入值					样本教师值 t	网络输出值 y
	x_1	x_2	x_3	x_4	x_5		
01	0.713	0.525	0.285	0.054	0.128	0.024	0.018
02	0.713	0.525	0.285	0.054	0.132	0.027	0.022
03	0.713	0.525	0.285	0.054	0.103	0.029	0.035
04	0.713	0.525	0.285	0.054	0.106	0.031	0.027
05	0.713	0.525	0.285	0.054	0.0116	0.024	0.03
06	0.713	0.525	0.285	0.048	0.0118	0.027	0.031
07	0.713	0.53	0.285	0.048	0.0112	0.018	0.14
08	0.713	0.53	0.285	0.048	0.0133	0.022	0.028
09	0.713	0.53	0.285	0.048	0.0143	0.031	0.031
10	0.713	0.53	0.285	0.048	0.0152	0.023	0.027
11	0.713	0.53	0.285	0.033	0.0155	0.022	0.023
12	0.713	0.53	0.285	0.033	0.0148	0.023	0.019
13	0.824	0.53	0.285	0.033	0.0146	0.027	0.029
14	0.824	0.53	0.285	0.033	0.0177	0.041	0.033
15	0.824	0.522	0.285	0.033	0.0176	0.035	0.042
16	0.824	0.522	0.293	0.033	0.0173	0.033	0.041
17	0.824	0.522	0.293	0.039	0.018	0.029	0.035
18	0.612	0.522	0.293	0.039	0.0187	0.026	0.031
19	0.612	0.522	0.293	0.039	0.019	0.042	0.034
20	0.612	0.522	0.293	0.039	0.0186	0.028	0.033
21	0.612	0.522	0.293	0.039	0.0182	0.027	0.021
22	0.612	0.525	0.293	0.039	0.0181	0.022	0.019
23	0.612	0.525	0.293	0.039	0.0166	0.024	0.022
24	0.612	0.525	0.293	0.039	0.0163	0.026	0.024
25	0.612	0.525	0.293	0.039	0.0157	0.027	0.025

文章编号: 0451-0712(2001)03-0055-04

中图分类号: TU37, TU317

文献标识码: B

检测混凝土内部缺陷与厚度的冲击反射法及测试系统

罗骥先, 傅翔, 宋人心, 朱大铮, 王五平

(南京水利科学研究院 南京市 210024)

摘 要: 冲击反射法是一种新型的混凝土结构无损检测技术。它可以用专门的冲击器在结构物的一面轻微弹击, 利用应力波的往复反射探测结构物内部的缺陷和厚度。作者研究了这项技术并推出一整套测试系统。本文叙述该项技术的原理、测试系统及工程实际应用情况。

关键词: 冲击反射; 缺陷; 厚度; 混凝土; 测试系统

0 引言

目前常用的探测混凝土结构内部缺陷(空洞、剥离层、疏松层、裂缝等)的无损检测方法是超声法。但该法是穿透测试, 需要两个相对测试面, 而且必须

测试多个测点, 通过相对比较才能作出判断。对于单面结构, 如道路、底板、隧洞衬砌、喷射混凝土等则难以运用。另外, 这些结构往往还需要测量厚度。

针对这些问题, 国际上从 20 世纪 80 年代中期

收稿日期: 2000-12-26

学习误差取 0.0001, 步长取 0.01, 学习次数共计 1790204 次。测试结果见表 2。由表 2 可以看出, 预

测值与实测值的最大误差为 5.65%, 完全可以满足工程需要。

表 2 网络预测值与实测值之间的比较

编号	神经元输入值					网络输出值	网络预测支护	工程实际支护	误差百分比
	x_1	x_2	x_3	x_4	x_5	y	时间 t'	时间 t	
01	0.612	0.525	0.293	0.039	0.0162	0.024	26.24	26.43	4.02%
02	0.612	0.525	0.293	0.039	0.0175	0.024	26.24	26.81	5.65%
03	0.612	0.525	0.293	0.039	0.0177	0.025	28.31	28.19	3.01%
04	0.612	0.525	0.293	0.039	0.0180	0.026	30.78	30.70	2.44%
05	0.612	0.525	0.293	0.039	0.0184	0.028	35.12	35.09	5.31%

3 其它工程

本方法和程序应用于中缅公路 5 号洞和山西万家寨水利枢纽工程引水洞的工程数据验证, 程序收敛, 误差完全可以满足工程需要。

4 结论

作者通过自编程序, 利用 MATLAB 人工神经网络工具箱, 验证了在隧洞开挖支护时间预测中应用人工神经网络的可行性。这种尝试的成功, 不仅拓宽了人工神经网络的应用范围, 也为解决工程中复

杂的、模糊的、不确定性问题找到了一条出路。

参考文献:

- [1] 张立明. 人工神经网络的模型及其应用[M]. 上海: 复旦大学出版社, 1994.
- [2] 闻新. MATLAB 神经网络应用设计[M]. 北京: 科学出版社, 2000.
- [3] 袁曾任. 人工神经网络及其应用[M]. 北京: 清华大学出版社, 1999.
- [4] 龚晓南. 深基坑工程设计施工手册[S]. 北京: 中国建筑工业出版社.