

人工神经网络预测非饱和土的特征参数

缪林昌 严明良

(河海大学岩土工程研究所 南京 210098) (南京机电学校 南京 210016)

殷宗泽

(河海大学岩土工程研究所 南京 210098)

摘 要 针对测定非饱和土的吸力既费时、费钱,又困难,而且往往是通过水分特征曲线间接求取,以致其精度不够理想这一问题,尝试采用人工神经网络进行预测研究,将部分已有的试验数据(含水量、吸力数据)作为输入模式进行训练,然后利用网络参数进行相应的参数预测。结果表明,神经网络预测技术十分有效,为工程应用提供了一种新的工具。

关键词 非饱和土;水分特征曲线;吸力;人工神经网络

中图分类号 P642;TP18

土的水分特征曲线是表示非饱和土体中水分的能量和数量之间的关系曲线,即土的吸力与含水量的关系曲线。在工程实践中人们常常遇到非饱和土,并且必然要研究非饱和土的强度与稳定性。非饱和土的强度和稳定性问题与基质势(吸力)密切相关。Fredlund 等^[1]曾经提出了非饱和土的抗剪切强度分式为

$$\tau_f = c' + (\sigma - u_a) \tan \varphi' + (u_a - u_w) \tan \varphi^b \tag{1}$$

他们用两个独立应力变量 $(\sigma - u_a)$ 和 $(u_a - u_w)$ 来表示非饱和土的强度,而 $(u_a - u_w)$ 正是土的吸力。吸力一般是通过仪器在室内和现场进行测定。由于非饱和土的性质比较复杂,对其吸力的测量往往是费时、费钱、困难的。为便于工程应用,不少学者致力于水分特征曲线函数的拟合研究,从而获得某一地区的水分特征曲线。这样只需测定不同深度土样的含水量,从而间接获得吸力参数。但是这样获取的吸力参数精度往往不太理想,主要原因是受制于水分特征曲线的拟合逼近的准确程度。影响其精度的因素有(a)试验数据的多少(b)测量仪器的精度(c)测量时的温度环境(d)人为因素等。因此,很难用一个数学函数包容这些影响因素。针对这些客观原因和缺陷,笔者尝试利用人工神经网络对有关不同深度土样的含水量和吸力数据进行训练,并预测其他深度含水量及相应的吸力,预测的结果和精度都达到了满意的效果,不仅充分显示了神经网络预测技术的巨大潜力,而且便于在实际工程中推广应用。

1 人工神经网络原理简介

人工神经网络只是对人脑功能的某种模仿、简化和抽象。网络一般由许多简单计算单元(即神经元)相互连接构成,而这些连接的强度(权值)是在使用中通过训练来自动调整,即所谓的“学习”。神经网络的一个重要特点是可以通过样本学习,无需人们事先给出特征和规律即可自己总结规律,完成模式识别与分类等任务,而学到的规律分布于网络的连接权值中。

1.1 人工神经元

网络中的神经元的类型(即输入输出关系)、网络构成形式(即各种神经元之间的连接方式)以及连接权重的学习规律是一个神经网络的三个要素。人工神经元将其接收到的信息(前一层的输出) $o_0, o_1, \dots, o_{n-1}$ 用 $w_1, w_2, \dots, w_{n-1}$ 连接强度以点积形式构成自己的输入 I^i ,再经 Sigmoid 函数(方程(3))转换,便得到这个单元的输出 O^i 。神经元的输入与输出关系为

$$I^i = \sum_j w_{ij} o_j \tag{2}$$

$$O^i = f(I^i) = 1/[1 + \exp(-I^i)] \tag{3}$$

1.2 反向传播学习算法

1986 年 Rumdhart 提出了反向传播学习算法,这个算法除考虑最后一层外,还考虑网络中其他层权值的改变,使得该算法适用于多层网络,成为目前广泛应用的学习算法之一。

反向传播算法由正向传播和反向传播两个过程组成。正向传播过程输入模式从输入层经隐含层处理,并传向输出层,每一层神经元的状态只影响下层神经元的状态。如果在输出层不能得到其期望输出,则转入反向传播,将该误差沿原来的连接通路返回,通过改变神经元的权值,使得误差最小。基于这一原理,笔者分别在 586 微机和工作站上开发编制了相应的计算软件,并进行计算训练预测。

2 神经网络预测非饱和土的吸力

由于非饱和土的力学参数的测定既困难,又费时费钱,常常借助水分特征曲线间接地求取吸力,因此其精度受制于水分特征曲线的数学函数与实测参数的逼近程度,并受观测土样的区域、深度的影响,从而导致水分特征曲线的拟合误差较大。针对这一不足,笔者选用神经网络进行训练并预测相应的吸力参数。神经网络最主要的特点是 (a)具有很强的鲁棒性和容错性 (b)具有很强的学习能力 (c)具有自适应非线性。

神经网络进行训练预测分为两个阶段,第一阶段是监督学习,第二阶段是无监督学习。监督学习是网络通过已知输入模式进行训练,即对输入层依次提供一个输入模式,先将这些值按正向传播规则向前传播,通过隐含层到达输出层,计算其输出值,这些输出值与对应输入模式的期望输出进行比较,然后将误差按原传播路径反传到网络中,再修正各个连接权值,使误差最小化。这样找到一组权值 w ,它对于所有参与训练的已知例子 α 计算的输出结果 O^α 与期望输出 O_{des}^α 之间的误差都能达到最小(或达到设计的精度要求)网络学习便告结束。本文中采用最小平方准则极小化进行,即

$$E(w) = \sum_{\alpha} \sum_i (O^{\alpha i} - O_{des}^{\alpha i})^2 \tag{4}$$

式中: α ——参与训练的模式数目; i ——输出层的神经元数目。

网络训练结束后,进行第二阶段的无监督学习,即利用监督学习阶段得到的权值,由网络对未知模式(未参与训练的模式)进行内插,得到所需的预测值。

为证明本文所述神经网络预测技术的有效性与实用性,对实际观测数据进行了训练和预测计算。所用的试验数据是引用程金茹等^[5]的,数据见表 1。表 1 中共有 14 组吸力与含水量数据,这些数据又分为四个层(2~9 m,9~18 m,18~21 m,21~28 m)。用某一组土样体积含水量作为输入层的输入数据,与体积含水量对应的基质势(吸力)作为期望输出。首先,用表 1 中 1.93 m,7.05 m,10.85 m,16.97 m,27.75 m 深度的五组含水量数据作为输入模式进行监督学习训练,网络参数为 16-15-16(即输入层、隐含层、输出层的神经元数目分别为 16,15,16),网络迭代 10 000 次,期望精度为 5%。然后,再用网络训练得到的权值对表 1 中的其他深度(3.8 m,5.75 m,8.94 m,12.84 m,14.8 m,18.6 m,20.66 m,23.3 m,25.4 m)的九组含水量数据进行无监督学习,得到相应

表 1 不同吸力下土样体积含水量

Table 1 Volume water content data corresponding to various suctions %

深度 /m	吸力/kPa														
	1	2	5	9	12	15	20	30	40	60	80	100	200	300	500
1.93	44.5	43.7	43.2	40.4	37.8	34.9	29.7	23.8	17.2	15.0	13.1	11.9	10.4	10.2	10.0
3.80	47.1	46.3	45.9	44.3	42.8	41.6	39.8	36.0	33.0	29.2	27.2	26.5	20.6	19.0	15.6
5.75	44.6	43.6	43.3	41.8	40.3	38.4	35.8	28.7	23.5	18.5	15.6	17.3	10.7	9.8	8.1
7.05	52.0	51.5	51.3	49.9	48.2	47.0	44.2	35.2	28.3	22.0	15.5	13.5	10.4	9.7	8.4
8.94	46.2	46.1	46.3	45.5	44.1	42.5	39.7	33.9	29.9	26.1	24.4	24.3	19.8	16.6	16.1
10.85	43.1	43.0	43.5	41.6	39.7	38.7	35.4	31.4	27.8	24.1	21.9	20.6	17.6	16.5	15.9
12.84	39.8	39.6	39.7	38.5	36.5	33.6	29.5	27.1	24.7	22.9	21.6	18.2	16.9	15.7	14.5
14.80	42.7	42.6	42.7	42.1	41.2	40.3	38.8	35.8	33.0	29.3	26.9	26.6	23.7	20.7	19.2
16.97	33.6	33.9	34.1	33.6	33.3	32.6	31.2	28.3	25.5	22.2	20.6	19.1	15.1	14.1	13.0
18.60	25.5	25.4	25.4	25.2	24.8	24.6	24.3	24.0	23.6	23.2	22.8	22.4	21.4	20.7	19.6
20.66	34.1	34.1	33.9	33.8	33.3	32.9	32.2	30.6	29.6	27.6	26.3	25.2	21.3	20.5	18.2
23.30	42.7	43.0	43.3	43.8	43.3	42.9	42.1	38.3	33.2	27.1	24.4	22.8	19.2	18.8	16.8
25.40	35.4	35.5	35.1	35.7	35.5	35.1	34.4	33.2	31.7	29.0	26.6	26.4	20.8	20.0	16.6
27.75	40.0	40.0	39.7	39.5	39.2	39.1	38.8	37.4	36.5	34.9	33.3	31.4	23.4	18.6	16.5

的吸力预测值,见表2.

表2 吸力预测结果

Table 2 The suction data predicted																kPa
深度	实 际 吸 力/kPa															
/m	1	2	5	9	12	15	20	30	40	60	80	100	200	300	500	1000
3.80	1.0	2.0	5.1	9.2	12.6	15.3	20.4	31.0	41.3	61.1	80.8	102.1	201.5	300.0	497.6	940.8
5.75	0.8	1.8	4.7	8.4	10.5	14.3	19.1	27.4	36.8	57.9	77.7	95.4	196.5	298.7	503.3	942.7
8.94	1.0	2.1	5.2	9.3	12.6	15.5	20.6	31.3	41.4	61.1	81.3	102.3	201.6	302.0	499.3	939.8
12.84	0.9	2.0	5.1	9.0	12.1	15.2	20.3	30.1	40.5	60.2	81.1	101.3	200.0	300.8	500.0	941.0
14.80	1.0	2.2	5.4	9.8	13.8	16.0	21.3	33.5	44.1	62.8	82.8	105.7	204.4	303.0	496.3	938.7
18.60	1.2	2.4	5.7	10.3	15.7	16.6	22.1	36.1	47.4	64.6	84.7	110.3	207.8	303.0	492.7	938.6
20.66	1.1	2.3	5.5	10.1	14.8	16.2	21.6	34.8	45.7	63.8	83.4	107.9	206.3	302.5	493.8	939.0
23.30	1.0	2.2	5.4	9.8	13.6	15.9	21.2	33.2	43.6	62.6	82.4	104.7	204.0	304.0	497.5	938.3
25.40	1.1	2.3	5.4	10.0	14.6	16.1	21.4	34.6	45.5	63.7	82.9	107.3	206.3	302.1	493.7	940.3

为了便于在工程实践中推广应用,故保持网络参数不变,减少输入模式的个数进行比较预测.在这里,笔者只用表1中1.93 m,16.97 m,27.75 m深度的三组含水量数据进行监督训练,网络迭代3 417次,期望精度为3%.接着用其网络权值对表1中3.8 m,5.75 m,8.94 m,12.84 m,14.8 m,18.6 m,20.66 m,23.3 m,25.4 m深度处土样的含水量数据进行预测,结果见表3.接下来,又用表1中的1.93 m,16.97 m深度的两组含水量数据进行监督学习,网络迭代1 724次,期望精度为3%,同时得到一组权值,利用这组权值再对表1中3.8 m,5.75 m,8.94 m,12.84 m,14.8 m,18.6 m,23.3 m,25.4 m深度处土样的九组含水量数据进行预测,结果见表4.

表3 吸力预测结果

Table 3 The suction data predicted																kPa
深度	实 际 吸 力															
/m	1	2	5	9	12	15	20	30	40	60	80	100	200	300	500	1000
3.80	0.4	2.0	5.1	9.4	13.0	15.4	20.9	31.5	41.5	62.1	79.4	102.4	202.8	299.8	496.3	968.4
5.75	0.3	1.7	4.5	8.3	10.6	14.2	18.6	27.9	37.5	57.7	78.9	95.7	196.4	297.0	500.4	971.0
8.94	0.4	2.0	5.1	9.3	12.8	15.5	20.7	31.5	41.3	61.6	80.0	101.8	201.9	301.1	497.8	968.5
12.84	0.4	2.0	5.1	9.3	12.6	15.4	20.7	31.0	41.2	60.8	80.4	102.6	201.0	301.8	499.2	968.6
14.80	0.4	2.2	5.5	10.1	14.3	16.3	22.1	33.8	43.9	64.5	80.4	105.6	206.4	303.4	496.5	966.5
18.60	0.5	2.4	6.0	11.0	16.9	17.5	24.4	37.1	47.4	68.0	80.5	112.1	211.8	305.1	494.2	964.7
20.66	0.5	2.3	5.7	10.6	15.6	16.8	23.2	35.5	45.7	66.6	80.3	108.5	209.7	303.9	493.6	965.6
23.30	0.4	2.2	5.5	10.1	13.9	16.2	21.7	33.4	43.5	64.3	81.0	104.1	207.0	304.3	495.7	966.5
25.40	0.4	2.3	5.7	10.5	15.4	16.7	22.9	35.2	45.5	66.7	80.1	107.4	210.0	303.4	492.9	965.7

表4 吸力预测结果

Table 4 The suction data predicted																kPa
深度	实 际 吸 力															
/m	1	2	5	9	12	15	20	30	40	60	80	100	200	300	500	1000
3.80	0.2	1.5	4.4	9.7	4.5	15.5	21.1	31.2	41.1	62.1	78.0	101.6	201.4	298.0	496.0	974.6
5.75	0.2	1.4	4.2	9.2	4.0	15.0	19.3	29.4	39.0	58.9	80.0	97.5	198.8	299.3	499.1	975.2
8.94	0.2	1.5	4.4	9.6	4.4	15.5	20.7	31.2	40.8	61.3	78.8	100.4	199.8	298.7	496.8	974.9
12.84	0.2	1.6	4.5	9.9	4.5	15.7	21.2	31.3	41.3	61.2	79.8	103.1	200.7	302.0	499.1	974.1
14.80	0.2	1.6	4.5	10.0	4.7	15.9	21.7	32.3	42.0	63.4	77.8	102.3	201.6	298.3	494.9	974.5
18.60	0.2	1.7	4.6	10.3	5.2	16.1	23.5	33.7	43.4	65.6	75.4	106.9	202.9	296.0	496.0	974.7
20.66	0.2	1.6	4.5	10.1	4.9	16.0	22.4	33.0	42.7	64.7	76.4	104.0	202.7	296.7	493.7	974.6
23.30	0.2	1.6	4.5	10.0	4.5	15.8	21.2	31.9	41.8	63.3	78.7	100.6	202.4	299.5	494.5	974.4
25.40	0.2	1.6	4.4	10.1	4.8	15.8	22.0	32.6	42.3	64.8	76.2	102.3	202.8	295.7	492.6	974.8

比较表2、表3、表4,可以看出以表2的预测结果为佳.但从测量和计算等综合因素来考虑的话,表3的结果应当是首选.因为其测量工作和计算量都比较少,其不足之处是在1 kPa点预测误差大了些,这主要是由于该吸力值对应的含水量波动较大造成的.因此,在实际工程实践中,如研究非饱和土的边坡问题,需要验算其稳定性,必然要利用公式(1),但是我们不可能测定所有点的土样吸力值与含水量.如果利用本文介绍的神经网络预测技术,只需测量三组不同深度处土样的吸力与含水量的数据,并进行训练,便可预测其他不同深度处非饱和土样含水量所对应的全部吸力资料,进而验算非饱和土边坡的稳定性.在进行神经网络预测时必须要求网络参数一致.这样既减少了测量吸力的工作量,又保证计算的精度,并节约工程投资.

3 吸力预测值分析

目前对非饱和土的特征参数的分析 ,通常的做法是进行吸力—含水量的回归分析 ,以求出水分特征函数的数学表达式.为此 ,我们进行相应的分析讨论.在表 1 中将深度 1.93 m ,16.97 m ,27.75 m 的三组含水量—吸力进行算术平均 ,得到一组(16 对)含水量—吸力数据 ,用这组数据进行拟合 ,拟合函数为

$$\theta = 52.69u_s^{-0.2032}$$

(5)

式中 : θ ——含水量 ; u_s ——吸力.现在用方程(5)求表 1 中 8.94 m 深度的含水量数据所对应的吸力值 ,并与神经网络预测的吸力值比较 ,见表 5.从表 5 比较的结果可以清楚地看到神经网络预测的吸力值的精度明显高于水分特征曲线计算的吸力精度 ,神经网络预测的吸力值与实测值相当接近 ,而水分特征曲线计算的吸力值与实测值相差较大.这也表明神经网络预测技术所具有的独特优点.

表 5 神经网络与水分特征曲线预测结果比较

Table 5 The suctions predicted by the neural net method compared with that by the soil-water characteristic curve method

测试方式	吸力/kPa															
实际	1	2	5	9	12	15	20	30	40	60	80	100	200	300	500	1000
神经网络预测	0.4	2.0	5.1	9.3	12.8	15.5	20.7	31.5	41.3	61.6	80.0	101.8	201.9	301.1	497.8	968.5
水分特征曲线预测	2.58	2.60	2.61	2.80	3.20	3.70	5.10	10.20	17.70	32.40	43.70	44.50	110.20	240.60	275.50	465.80

4 结 语

以上研究结果表明 ,神经网络利用已知部分不同深度土样含水量与吸力数据进行训练 ,可成功地预测其他不同深度土样含水量所对应的吸力 ,计算精度可靠 ,使用灵活 ,既减轻测量人员的大量测量工作 ,又节约工程项目的投资 ,并且便于在工程实践中推广应用.

参 考 文 献

1 Fredlund D G , Anqing Xing. Equation for the soil-water characteristic curve. Can Geotech J , 1994 , 31 :521 ~ 532

2 Rumdhart D E , McClelland J. Learning internal representation by back-propagation errors. Nature , 1986 , 332 :533 ~ 536

3 Holmstrom L. Using additive noise in back-propagation training. IEEE Trans Neural Network , 1992 , 3 (1) :34 ~ 39

4 焦李成.神经网络系统理论.西安 :西安电子科技大学出版社 ,1991.26 ~ 90

5 程金茹 ,郭择德 ,郭大波.非饱和土壤特征参数获取方法.水文地质工程地质 ,1996 (2) :9 ~ 13

Predicting Characteristic Parameter of Unsaturated Soil

with Artificial Neural Network

Miao Linchang

(Research Institute of Geotechnical Engineering , Hohai Univ. , Nanjing 210098)

Yan Mingliang

(Nanjing College of Mechanical & Electrical Engineering , Nanjing 210016)

Yin Zongze

(Research Institute of Geotechnical Engineering , Hohai Univ. , Nanjing 210098)

Abstract Because direct measurement of suction is costly time , consuming and difficult , generally , suction is indirectly found with soil-water characteristic curve , thus , the precision is not good enough. In order to solve the problem , the artificial neural network method and partial experimental data(water content and suction) are used as input patterns to train and predict corresponding parameters with network parameter. The results show that the method is very effective and is a powerful tool for engineering application.

Key words unsaturated soil ; soil-water characteristic curve ; suction ; artificial neural network