

BP 神经网络在海洋平台桩基轴向承载力中的应用研究

陈磊

(中海油田服务股份有限公司, 天津 300450)

摘要:目前海洋石油导管架平台桩基础的轴向极限承载力常用的设计方法为 API RP2A(美国石油协会)和静力触探(CPT)的方法。在这两种方法的基础上,提出了用 BP 神经网络模型对桩的轴向极限承载力进行计算的思路,能够有效地预测桩的轴向极限承载力。根据 BP 神经网络算法具有较强的非线性映射能力和学习功能的特点,通过对影响单桩极限承载力因素的分析,依据静力触探资料建立了基于 BP 神经网络的单桩轴向极限承载力预测模型。通过利用 API RP2A 方法分析成果对该模型进行学习训练和预测检验,证明了预测模型性能良好、具有较高的精度和收敛速度快等特点,验证了神经网络方法的可行性,预测结果能够指导桩基础设计,缩短周期。因而具有较大的工程实用价值。

关键词:神经网络;静力触探;桩;极限承载力

中图分类号:P75

文献标志码:A

文章编号:1003-2029(2019)03-0085-07

海洋平台导管架桩基础是一种重要的基础形式,准确分析打入桩的承载力特性是一个非常重要的工程课题。承载力特性取决于地层土质特性,而土的力学性质又比较复杂,所受影响因素很多。常规方法是现场取样,再通过试验得到力学参数,采用相应的规范方法计算,其中每一个环节都要花费较多时间,周期长,影响后续桩基础的设计环节。而且不同的分析方法具有各自的适用性^[1]。因而准确、可靠地分析打入桩的承载力具有十分重要的意义。

孔压静力触探(piezcone penetration test, CPTu)作为一种理论与技术相对成熟的原位测试技术,已广泛应用于海洋地基勘察中,基本原理是将安装有阻力传感器的探头和孔隙水压力测试元件匀速地压入土中,实时地记录探头的阻力、侧摩擦力和孔隙水压力,反映地层的真实情况,具有快速、连续、经济、可靠等优势^[2]。早在 1982 年,Senne set 等、Campanella 等就提出通过静力触探有效锥尖阻力来估算地基土的不排水抗剪强度等参数,再通过理论

公式计算桩基承载力,还没有对静力触探参数建立 BP 网络模型计算桩基承载力进行研究。

对于陆地桩基础,可以利用静载试验测得地层承载力,国内有很多专家已将静载试验数据,建立了 BP 神经网络模型,进行预测承载力,均获得了满意的效果,精度也满足工程需求。海洋平台导管架桩基础与陆地桩基承载力机理类似,而利用 BP 神经网络预测海洋桩基承载力,目前对于这方面研究的相对较少,因此提出利用静力触探资料,对 BP 网络模型应用于海洋平台导管架平台桩基承载力的设计分析进行研究,并加以验证分析。

1 BP 网络原理

BP 神经网络(Error Back Propagation)又称为误差反传网络,是基于 BP 学习算法的多阶层前传神经网络,是人工神经网络的精华部分,实际应用中 80%~90%采用这种网络模型结构或其变形。BP 网

络从原理上能够模拟从输入到输出任意复杂的非线性映射,因此 BP 神经网络在桩基工程中有着较高的实用价值^[3]。它依靠调节各层间神经元(节点)的连接权值来“记忆”各学习样本。BP 网络的学习过程由向前计算过程和误差逆传播过程组成,通过对大量样本的学习自动建立输入和输出的高度非线性映射关系。它主要由输入层、隐含层和输出层组成,神经网络模型见图 1。在正向传播过程中,输入信息从输入层经隐单元层逐层处理,并传向输出层,每一层神经元的状态只影响下一层神经元的状态。如果在输出层不能得到预期的结果,则转入误差逆传播,将误差信号沿原来的连接通路返回,通过修正各层神经元的权值,使得误差信号最小^[4]。




图 1 BP 神经网络模型

Fig.1 BP neural network model

已经证明^[5]一个具有 N 个输入节点, $K=2N+1$ 个隐层节点和 M 个输出节点的 3 层 BP 网络可以实现任何从 n 维欧氏空间到 m 维欧氏空间的非线性映射,即: $R^n \rightarrow R^m$ 。

BP 网络的学习由 4 个过程组成:模式的顺传播、误差逆传播、记忆训练、学习收敛^[6]。响应函数采用 Sigmoid 型函数,即 $f(x)=1/(1+e^x)$,采用了按误差函数梯度下降的方向进行收敛。

设输入模式向量为 $A_k=(a_1, a_2, \dots, a_n)$,式中: k 为学习模式对数; n 为输入层单元个数。

中间层各单元的输入、输出分别如式(1)和式(2)所示:

$$S_j^k = \sum_{i=1}^n w_{ij}^k a_i^k - \theta_j \quad (1)$$

$$b_j^k = f(s_j^k) \quad (2)$$

式中: j 为中间层单元个数; w_{ij} 为输入层至中间层单元的连接权; θ_j 为中间层单元的阈值。

输出层各单元的输入、输出分别如式(3)和式(4)所示:

$$L_i^k = \sum_{j=1}^p v_{ji}^k b_j^k - \gamma_i \quad (3)$$

$$C_i^k = f(L_i^k) \quad (4)$$

式中: t 为输出层单元个数; v_{ji} 为中间层至输出层的连接权; γ_i 为输出层单元的阈值。

输出层各单元的一般化误差如式(5)所示:

$$d_i^k = (y_i^k - C_i^k) C_i^k (1 - C_i^k) \quad (5)$$

式中: y_i^k 项的物理意义表示网络希望输出与实际输出的绝对误差。

中间层各单元的一般化误差如式(6)所示:

$$e_j^k = \left[\sum_{i=1}^q d_i v_{ji}^k \right] b_j^k (1 - C_j^k) \quad (6)$$

用输出层各单元的一般化误差 d_i^k 调整连接权 v_{ji} 和阈值 γ_i , 分别如式(7)和式(8)所示:

$$v_{ji}(N+1) = v_{ji}(N) + \alpha d_i^k b_j^k \quad (7)$$

$$\gamma_i(N+1) = \gamma_i(N) - \alpha d_i^k \quad (8)$$

用中间层各单元的一般化误差 e_j^k 调整连接权 w_{ij} 和阈值 θ_j , 分别如式(9)和式(10)所示:

$$w_{ij}(N+1) = w_{ij}(N) + \beta e_j^k a_i^k \quad (9)$$

$$\theta_j(N+1) = \theta_j(N) - \beta d_j^k e_j^k \quad (10)$$

通过向前计算和误差逆传播过程,逐层修正各连接权,随着这种误差逆传播修正的不断进行,网络对输入模式响应的正确率也在不断上升,反复输入所有训练样本,重复训练,使输出误差满足预设精度,此时连接权则不再改变。网络经学习训练后,将待求的样本输入网络模型中,利用网络的非线性映射关系对样本进行预测。

2 极限承载力神经网络模型

2.1 承载力与静力触探关系

静力触探技术自 1971 年问世以来,迄今已有 80 年的历史。目前,许多国家都把静力触探列入国家规程或规范,并且对静力触探机理进行了深入的研究^[3]。桩在外力作用下,承载力包括桩端阻力和桩侧壁摩阻力。桩的实际极限端阻力与极限侧壁摩阻力同静力触探测出的锥尖阻力和侧壁摩阻力相比,虽然存在一定的差异,但由于它们受力相似,因此可以将静力触探试验看作一个小直径桩的现场载荷试验,模拟桩的受力状况,预测单桩承载力^[7]。而 BP 神经网络可以作为一个有效工具探求它们之间的内在关系。

2.2 模型的建立和实现

在建立 BP 神经网络时, 需要提取主要影响因素, 考虑海洋平台导管架桩基础的受力特性, 提取由静力触探试验得出的桩侧摩阻力 f_s 加权平均值和桩端附近 q_c 值, 以及海底泥面以下深度作为网络的基本输入矢量, 输入层的神经元数即是所提取的影响因素个数, 取 3 个因素为输入单元, 输出层由 1 个神经元组成, 取单桩极限承载力作为输出矢量, 选择 7 个节点为隐层单元数。

2.3 样本和输入参数的选择

2.3.1 样本的选择 BP 神经网络的精度是建立在大量训练样本基础上的, 这里选取 6 个具有代表性新建平台静力触探孔数据, 每个静力触探孔 10 m

范围内均有取样孔, 根据取样孔得到地层力学参数, 按照 API 方法分析计算 84 in 桩径(海上常用)开口式钢管桩的极限承载力, 作为目标值。其中 5 个作为样本对网络进行训练, 之后, 再通过剩余 1 个检验样本来检验网络是否可行。部分训练样本如表 1 所示, 限于篇幅未将所有数据列出, 分别计算 1.1 m 处(第一层底界面)、1.1 m 处(第二层顶界面)、3.5 m 处(第二层底界面)、3.5 m 处(第三层顶界面)等深度点的承载力值。

试验数据由荷兰制造厂商 a.p.vandenberg 生产的(目前较为先进的静力触探设备)wison-APB 井下(downhole)静力触探系统测得。可同时测得锥尖阻力 q_c 、侧壁摩阻力 f_s 、孔隙水压力 u_2 3 个参数。

表 1 训练样本的输入与输出值
Tab.1 Input and output values of training samples

深度 /m	桩端阻力 q_c /MPa	侧摩阻力加 权平均值/ MPa	计算值 /MPa	拟合值 /MPa	相对 误差/%	深度 /m	桩端阻力 q_c /MPa	侧摩阻力加 权平均值 /MPa	计算值 /MPa	拟合值 /MPa	相对 误差/%
1.1	0.76	0.00	0.28	0.30	7.14	54.5	3.76	0.06	27.16	28.98	6.69
1.1	7.09	0.05	0.42	0.50	19.05	58.9	3.76	0.06	29.66	31.12	4.91
3.5	7.09	0.05	1.42	1.47	3.79	58.9	22.68	0.27	43.12	44.65	3.54
3.5	19.27	0.13	2.30	2.40	4.35	62.2	22.68	0.27	44.92	45.27	0.77
7	19.27	0.13	5.02	4.88	-2.79	62.2	3.96	0.05	31.62	34.79	10.01
7	12.28	0.12	3.22	3.62	12.37	68.4	3.96	0.05	36.61	39.44	7.73
10.5	12.28	0.12	5.15	5.40	4.81	68.4	38.73	0.25	67.07	64.98	-3.12
10.5	1.71	0.04	2.34	2.24	-4.22	78.9	38.73	0.25	73.81	71.01	-3.79
12	1.71	0.04	3.17	2.91	-8.11	78.9	5.87	0.14	43.67	44.72	2.40
12	8.68	0.70	5.85	5.76	-1.47	84.9	5.87	0.14	46.36	45.50	-1.85
14.2	8.68	0.70	7.18	6.65	-7.33	84.9	3.70	0.03	46.36	45.84	-1.11
14.2	1.53	0.02	3.50	4.06	16.03	94.8	3.70	0.03	54.99	53.52	-2.67
18.4	1.53	0.02	4.67	4.07	-12.87	94.8	19.14	0.18	67.97	66.86	-1.63
18.4	26.63	0.13	25.10	25.37	1.07	97.7	19.14	0.18	69.55	68.52	-1.48
20.5	26.63	0.13	28.83	26.80	-7.03	97.7	6.56	0.11	57.53	55.29	-3.90
20.5	2.86	0.04	6.69	7.71	15.20	100.4	6.56	0.11	58.75	56.46	-3.90
24	2.86	0.04	8.13	9.43	15.94	100.4	9.45	0.16	60.35	58.76	-2.64
24	17.17	0.20	19.89	18.64	-6.27	104	9.45	0.16	61.97	59.62	-3.79
27	17.17	0.20	23.48	20.54	-12.53	104	3.98	0.04	60.04	58.01	-3.37
27	42.47	0.28	39.80	41.98	5.48	106.5	3.98	0.04	62.55	60.01	-4.06
40.6	42.47	0.28	50.19	52.80	5.20	106.5	6.05	0.13	62.88	60.25	-4.19
40.6	2.72	0.03	18.77	19.31	2.89	108.8	6.05	0.13	63.91	62.07	-2.88
45.8	2.72	0.03	21.90	22.65	3.42	108.8	14.52	0.33	75.92	72.60	-4.37
45.8	5.12	0.03	29.37	28.78	-2.01	114.7	14.52	0.33	79.14	75.06	-5.16
48.8	5.12	0.03	30.72	29.82	-2.93	114.7	9.37	0.14	68.41	64.11	-6.28
48.8	16.14	0.33	37.51	36.45	-2.82	121.1	9.37	0.14	76.99	74.92	-2.69
54.5	16.14	0.33	40.62	40.58	-0.11						

2.3.2 输入参数的归一化 由于所选用的 CPT 各参数具有不同的量纲,因此为了减少量纲的差异对变量的影响,同时减小误差,需要首先对数据进行标准化,转化为无量纲的形式,将数据归一化为[0,1]中的值。经过分析后的典型训练样本具有代表性高的特征,可使该 BP 神经网络得到充分地训练,从而使误差降至预设的范围。归一化的方式可以根据具体数据特点进行灵活处理,原则是对所有样本的同一数据元素进行相同的处理。常见的归一化方法表达式如式(11)所示:

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (11)$$

式中: x' 为归一化后的数据; $x_{\min}$ 为原始数据; $x_{\max}$ 是 x 的最大值; $x_{\min}$ 是 x 的最小值。

文中对桩长、侧摩阻力加权平均值、端承载力以及网络输出值承载力目标值均采用上述方式归一化,由于网络中数据经过归一化处理,所以网络输出值并不是直接的最后结果,要经过后处理即根据输出结果的归一化相反方式计算得到,即^[8]:

$$x = x' \times (x_{\max} - x_{\min}) + x_{\min}$$

2.4 模型的学习训练和检验

网络模型采用 trainingd 训练函数,初始学习速率 $lr=0.05$;最大学习次数 epoch=20 000,期望误差最小值设定值 goal=8.6e-3。从图 2 看出,学习次数为 14 189 次时,达到期望误差最小值,此时网络已经训练完毕。

训练后的网络具备计算轴向受荷桩承载力的能力,需验证训练效果如何,将 5 个孔的静力触探参数作为输入,对神经网络进行验证,将网络的输出值(拟合值)与按照 API 规范计算结果对比分析,相对误差=(拟合值-计算值)/计算值*100,检验结果如表 1,数据未完全列出。经分析,BP 神经网络拟合值与计算值的轴向极限承载力相对误差平均值为 1.39%,最大为 30.8%,最小为-23.2%,样本序号对应的相对误差散点图如图 3 所示,可以看出绝大部分数据集中在 $\pm 10\%$ 范围内。

图 4 显示拟合值与计算值的相关曲线(相关系数达 0.922 3 以上)几乎是过原点,截距仅 0.014,拟合曲线系数为 0.96,接近于 1,说明数据吻合得较好;从图 5~图 9 可看出,拟合值与计算值(目标值)离散点分布非常相近,且趋势完全一致。综合分析认为训练的 BP 神经网络模型的拟合精度高,具备

计算轴向受荷桩承载力的能力,可以用来预测评价海洋桩基承载力。




图 2 BP 网络收敛曲线

Fig.2 BP network convergence curve




图 3 训练相对误差散点图

Fig.3 Train relative error scatter plot




图 4 计算值和拟合值相关曲线

Fig.4 Calculated and fitted value correlation curve




图 5 1 孔计算值和拟合值散点图

Fig.5 Bore 1 calculated and fitted value scatter plot




图 6 2 孔计算值和拟合值散点图

Fig.6 Bore 2 calculated and fitted value scatter plot




图 7 3 孔计算值和拟合值散点图

Fig.7 Bore 3 calculated and fitted value scatter plot




图 8 4 孔计算值和拟合值散点图

Fig.8 Bore 4 calculated and fitted value scatter plot




图 9 5 孔计算值和拟合值散点图

Fig.9 Bore 5 calculated and fitted value scatter plot

2.5 BP 神经网络预测应用及误差分析

利用已经建立的 BP 网络模型，将 6 孔静力触探试验参数作为预测样本，海底泥面以下深度，桩侧阻力 f_s 加权平均值和桩端附近 q_c 值作为网络的

输入矢量，数据见表 2，进行预测单桩极限承载力。并与 API 方法的计算值进行对比，相对误差=(预测值-计算值)/计算值 *100。

表 2 预测样本的输入与输出值
Tab.2 Input and output values of prediction samples

深度 /m	桩端阻力 q_c /MPa	侧摩阻力 加权平均 值/MPa	计算值 /MPa	预测值 /MPa	相对 误差/%	深度 /m	桩端阻力 q_c /MPa	侧摩阻力 加权平均 值 /MPa	计算值 /MPa	预测值 /MPa	相对 误差/%
2.5	2.21	0.01	0.64	0.57	-10.18	46.2	8.13	0.07	32.96	29.92	-9.21
2.5	0.44	0.03	0.68	0.60	-11.76	46.2	2.42	0.02	18.53	20.00	7.92
5	0.44	0.03	1.10	1.00	-9.09	56	2.42	0.02	25.74	25.62	-0.45
5	1.95	0.05	1.46	1.30	-10.96	59	2.40	0.01	26.90	28.25	5.00
6	1.95	0.05	1.78	1.80	1.12	59	12.62	0.09	41.32	45.00	8.91
6	1.27	0.01	2.26	2.00	-11.50	64	12.62	0.09	44.05	50.00	13.51
9	1.27	0.01	2.88	3.00	4.17	64	3.09	0.03	30.43	31.21	2.56
9	4.45	0.04	4.20	4.80	14.22	88	3.09	0.03	52.63	47.12	-10.47
13.8	4.45	0.04	6.87	6.85	-0.32	100	3.70	0.04	66.14	56.19	-15.04
13.8	15.69	0.04	10.21	13.00	27.33	112	4.75	0.06	81.26	65.91	-18.89
18.6	15.69	0.04	14.63	16.00	9.36	112	17.37	0.18	109.47	96.07	-12.24
18.6	1.79	0.01	5.26	5.54	5.35	118.5	17.37	0.18	113.64	99.97	-12.03
40	1.79	0.01	14.83	15.62	5.30	118.5	6.14	0.06	84.95	73.98	-12.91
40	8.13	0.07	29.58	26.17	-11.52	140.2	6.14	0.06	115.12	88.30	-23.30




图 10 6 孔计算值和预测值散点图

Fig.10 Bore 6 calculated and prediction value scatter plot




图 12 预测相对误差散点图

Fig.12 Prediction relative error scatter plot




图 11 6 孔计算值和预测值相关曲线

Fig.11 Correlation curve of Bore 6 calculated and prediction value

从图 10 可看出，拟合值与计算值(目标值)离散点分布非常相近，且趋势完全一致。图 11 显示预测值与计算值的相关曲线 (相关系数达 0.980 7 以上)，截距为 2.6，拟合曲线系数为 0.83，比较接近 1，说明数据吻合得较好。

图 12 是按照样本序号对应的相对误差散点图，可以看出该孔 BP 神经网络预测值与计算值的相对误差绝大部分数据集中在±10%范围内，平均值为-2.68%，最大为 27.3%(仅 1 个样本)，最小为-23.3%(表 2)。对岩土工程中桩基础承载力的训

训练误差和预测误差,最大误差小于25%,平均误差小于15%一般是可以接受的^[9]。因此,此次的预测精度算是较高的。

预测数据在64 m以后,计算值相对是偏小的,并没有高估地层承载力,对于工程而言,是保守的,有利于选择持力层进行桩基础设计。

3 结论

(1) 通过本文分析,BP网络在海洋桩基承载力中的应用是可行的,预测数据与规范计算值比较吻合。在工程地质钻孔取样资料缺失,或者由于试验数据周期长导致暂时缺失土工试验数据,无法利用

API规范计算承载力时,可以利用静力触探资料,根据训练的BP网络模型,进行预测桩基承载力,作为桩基设计的参考,缩短海洋工程周期。

(2) 根据检验值和预测值,可以看出,在0~64 m范围内BP网络预测值略大于计算值,在大于64 m深度以后,BP网络预测值小于计算值,预测值是比较保守的,有利于桩基础设计,不至于造成承载力不够导致桩基失稳,具有较大的工程实用价值。

(3) 学习训练数据量相对有限,如果有大量的静力触探数据和对应的取样孔精度较高的实验值,对网络进行学习训练,或者同时采用概率神经网络^[10]以及GA-BP神经网络^[8],效果会更好,精度更高。

参考文献:

- [1] 苏世定,杨仲轩,郭望波.黏土中打入桩竖向承载力计算方法效果评价[J].岩土力学,2015,36(S2):389-393.
SU Shi-ding, YANG Zhong-xuan, GUO Wang-bo. Assessment of design methods for axial bearing capacity of driven piles in clay [J]. Rock and Soil Mechanics, 2015, 36(S2): 389-393.
- [2] 刘松玉,吴燕开.论我国静力触探技术(CPT)现状与发展[J].岩土工程学报,2004(04):553-556.
LIU Yu-song, WU Yan-kai. On the state-of-art and development of CPT in China [J]. Chinese Journal of Geotechnical Engineering, 2004(04): 553-556.
- [3] 诸伟琦,陈文才.单桩极限承载力的神经网络预测[J].上海大学学报(自然科学版),2004(06):639-642.
ZHU Wei-qi, CHEN Wen-cai. Predicting bearing capacity of single pile using neural network [J]. Journal of Shanghai University: Natural Science, 2004(06): 639-642.
- [4] 张国栋,彭刚,王钊,等. BP神经网络在单桩承载力预测中的应用[J].三峡大学学报(自然科学版),2003(01):6-8.
ZHANG Guodong, PENG Gang, WANG Zhao, et al. Application of back propagation neural network to predicting bearing capacity of single pile[J]. Journal of China Three Gorges University: Natural Sciences, 2003(01): 6-8.
- [5] 焦李成.神经网络系统理论[M].西安:西安电子科技大学出版社,1990.
JIAO Li-cheng. Neural network system theory[M]. Xi'an: Xi'an Electronic Technology University Press, 1990.
- [6] 郝小员,刘汉龙,高玉峰.人工神经网络在水泥喷粉桩承载力设计计算中的应用[J].河海大学学报(自然科学版),2002(04):32-36.
HAO Xiao-yuan, LIU Han-long, GAO Yu-feng. Application of artificial neural network to design of bearing capacity of cement mixing piles[J]. Journal of Hohai University: Natural Sciences, 2002(04): 32-36.
- [7] 曹茂森,周翠玲,戴景军. BP神经网络在静力触探确定单桩承载力中的应用[J].山东农业大学学报(自然科学版),2002(03): 338-342.
CAO Mao-sen, ZHOU Cui-ling, DAI Jing-jun. The application of BP neural net in the design determination of the bearing capacity of single pile using the result of static contact survey[J]. Journal of Shandong Agricultural University: Natural Science, 2002(03): 338-342.
- [8] 张明远,钟珞.基于GA-BP神经网络的单桩承载力预测[J].武汉理工大学学报,2008(03):86-89.
ZHANG Ming-yuan, ZHONG Luo. Bearing capacity prediction of single pile based on genetic algorithm and BP neural network [J]. Journal of Wuhan University of Technology, 2008(03): 86-89.
- [9] 涂帆,常方强. BP神经网络预测水泥搅拌桩单桩承载力[J].华侨大学学报:自然科学版,2007,28(1):68-70.
TU Fan, CHANG Fang-qiang. The method of BP neural network predicting the bearing capacity of single cement mixing Pile [J]. Journal of Huaqiao University: Natural Science, 2007, 28(1): 68-70.
- [10] 刘刚,徐华荣.基于概率神经网络对单桩竖向承载力预测方法的研究[J].城市勘测,2016(03):161-164.
LIU Gang, XU Huarong. Research on vertical bearing capacity of single pile based on probabilistic neural network [J]. Urban Geotechnical Investigation & Surveying, 2016(03): 161-164.

Application Research of BP Neural Network in Offshore Platform Pile Foundation Axial Bearing Capacity

CHEN Lei

China Oilfield Services Ltd, Tianjin 300450, China

Abstract: At present, the design methods of pile axial ultimate bearing capacity for offshore oil jacket platform commonly used include API RP2A (American Petroleum Institute) and Cone Penetration Test (CPT). Based on these two methods, the idea of using BP neural network model to calculate the pile axial ultimate bearing capacity is proposed, which could effectively predict the pile axial ultimate bearing capacity. According to the characteristics of BP neural network algorithm with strong nonlinear mapping ability and learning function, through the analysis of factors affecting the single pile ultimate bearing capacity, the prediction model of axial ultimate bearing capacity based on BP neural network is established based on the CPT data. By using the analysis results of API RP2A method to study, train and test the prediction of the model, it is proved that the prediction model has good performance, high accuracy and fast convergence speed, and the feasibility of the neural network method is verified. The prediction results can guide the pile foundation design and shorten the engineering period. Therefore, it has great practical value in engineering practice.

Key words: neural network; cone penetration test; pile; ultimate bearing capacity