

单桩竖向极限承载力预测的 SVM 模型

范 量, 韩 阳, 王 威, 师旭超

(河南工业大学 土木建筑学院, 郑州 450052)

摘 要: 在综合分析了各种单桩竖向极限承载力分析方法的基础上,建立了基于支持向量机(SVM)的单桩竖向极限承载力预测模型。以实测数据为学习样本和测试样本,讨论了其可行性。研究表明,该方法能较好反映桩的实际受力过程,具有一定的工程应用价值。

关键词: 单桩; 竖向极限承载力; 支持向量机(SVM); 预测

中图分类号: TU 413.4 **文献标识码:** A

桩基础具有承载力高、沉降量小、调节不均匀沉降能力强的特性。如何科学合理地确定单桩的承载力是桩基设计中的一个关键技术问题。一般而言,静载荷试验是目前最直观、最可靠的方法,但存在荷载装置、试桩费用、施工进度及试桩的数量有限等缺陷。而其他经验公式普遍存在一定的局限性,适应性较差,各种理论也难以反映桩基复杂多变的机理。针对桩基性状及其影响因素的多样性、复杂性、非线性和非确定性,不确定性的研究方法能够充分考虑桩基性状的各种影响因素。对于不确定性的分析方法,人工神经网络应用最为广泛。但人工神经网络是基于启发式的,没有相当完备的理论基础,不能很好地控制训练后的网络推广,有时不能达到全局最优,且基于经验风险最小化准则,容易导致神经网络的过拟合问题。

支持向量机方法是根据结构风险最小化准则,提高了学习机的泛化(预测)能力,较好地解决了小样本、非线性、高维数和局部极小点等实际问题^[1],其基本思想是通过非线性变换将输入空间变换到一个高维空间,在这个新空间中求解一个有约束的凸二次规划问题,可以得到唯一的全局最优解。上述特点使得 SVM 方法成为一种优秀的学习算法,目前已经成功地推广到模式识别、函数拟合等领域。在岩土工程领域,SVM 方法也得到了一定的应用^[2]。由于桩基性状预测的复杂性,在单桩承载力与其影响因素之间存在着很强的非线性关系,而 SVM 方法可以很好地完成输入数据与输出数据之间的非线性映射,同时提高泛化能力。本文基于 SVM 方法建立了单桩竖向极限承载力预测模型,通过比较实测单桩竖向承载力数据、BP 网络模型的预测结果,用工程实例说明了 SVM 模型推算单桩承载力的有效性。

1 单桩竖向极限承载力预测的 SVM 模型原理

通过实测获得单桩竖向极限承载力数据的样本集 $\{(x_1, y_1), \dots, (x_i, y_i), \dots\}$, $x_i \in R^n$, $y_i \in R^1$, 其中 x_i 是影响单桩竖向极限承载力的各个因素, y_i 为单桩竖向极限承载力值。通过训练后,用一非线性回归函数 $f(\bullet)$ 描述 x_i 与 y_i 之间的非线性映射^[1],对于实测值以外的 x_i 通过 $f(\bullet)$ 找出对应的 y_i , 即所需预测单桩竖向极限承载力值。

考虑线性回归,设线性回归函数 $f(x)=wx+b$, 假设所有样本数据点集在精度 ε 下无误差地用 $f(x)$ 拟合,即

$$|y_i - wx_i - b| \leq \varepsilon \quad (i=1, \dots, l) \quad (1)$$

对于存在拟合误差的情况,引入松弛变量 $\xi_i \geq 0$, $\xi_i^* \geq 0$, 则线性函数回归问题变为:

$$\min \phi(w, b, \xi_i, \xi_i^*) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^l (\xi_i + \xi_i^*) \quad (2)$$

$$\left. \begin{aligned} y_i - wx_i - b &\leq \varepsilon + \xi_i \\ wx_i + b - y_i &\leq \varepsilon + \xi_i^* \\ \xi_i &\geq 0, \quad \xi_i^* \geq 0 \end{aligned} \right\} \quad (3)$$

收稿日期: 2006-09-19

基金项目: 河南省教育厅自然科学基金资助项目(200510463003)

作者简介: 范 量(1966-), 男, 河南郑州人, 高级工程师, 研究方向: 结构健康诊断等。

式中 $C>0$,表示对超出误差 ε 的样本的惩罚程度。

对于非线性函数回归问题,可以通过一非线性映射($x\rightarrow\varphi(x)$)把输入数据映射到一高维特征空间,然后在该高维特征空间进行线性回归,从而取得在原空间非线性回归的效果。根据上述思想,非线性函数回归问题可以转化为下列非线性规划问题:

$$\max W(a,a^*)|_{w,b,\xi,\xi_i^*}=-\frac{1}{2}\sum_{i,j=1}^l(a_i-a_i^*)(a_j-a_j^*)K(x_i,x_j)-\sum_{i=1}^l(a_i+a_i^*)\varepsilon+\sum_{i=1}^l(a_i-a_i^*)y_i \tag{4}$$

$$\sum_{i=1}^l(a_i-a_i^*)=0 \quad 0\leq a_i,a_i^*\leq C,i=1,\cdots,l \tag{5}$$

其中 $K(x_i,x_j)=\varphi(x_i)\varphi(x_j)$,此时函数 $f(x)$ 可表示为

$$f(x)=\sum_{i=1}^l(a_i-a_i^*)K(x,x_i)+b \tag{6}$$

式中 $a_i-a_i^*\neq 0$ 对应的 x_i 为支持向量;偏置量 b 可以通过 KTT 条件计算; $K(x_i,x_j)$ 称为核函数。

2 单桩竖向承载力预测的实例分析

2.1 单桩竖向极限承载力影响因素的确定

单桩竖向极限承载力受众多因素影响,在确定网络结构时必须考虑模型的简便易行。本文在分析单桩竖向极限承载力时,考虑的主要是桩的入土深度,桩的直径,静力触探试验得出的桩侧 p_s 加权平均值和桩端附近 p_s 值等 4 个影响因素^[3-4]。

2.2 学习样本和测试样本的选择

本文从文献[4]收集了上海地区 17 根预制桩的实测资料作为样本,随机选取前 12 个样本作为预测模型的学习样本(见表 1),取后 5 个样本实例用于测试建立的模型。

2.3 模型参数的选择

学习样本集确定后,模型的建立,主要是选择相应的 SVM 参数:核函数和 C 。本文 SVM 模型计算选用高斯基核函数: $K(x_i,x_j)=\exp(-\gamma\|x_i-x_j\|^2)$,参数选择如下: $C=10$, $\gamma=0.37$, $\varepsilon=0.001$ 。其中 ε 控制函数拟合误差的大小,从而控制支持向量的个数和推广能力,本文取 $\varepsilon=0.001$ 较为合适;参数 C,γ 的选择直接影响到预测精度,通过对大量的参数进行测试,最终选择了本文中的参数。图 1 是当 C 固定在 10 时,参数 γ 对测试集平均相对误差的影响曲线。图 2 是当 γ 固定在 0.37 时,参数 C 对测试集平均相对误差的影响曲线。图中平均相对误差(MAPE)为 $\frac{1}{n}\sum_{i=1}^n|(R_i-P_i)/R_i|$; R_i 为实测单桩承载力数据; P_i 为预测单桩承载力数据; n 为待预测的单桩承载力点数。

表 1 单桩竖向极限承载力预测模型的样本数据

Tab.1 The sample data of predicting vertical ultimate bearing capacity of single pile

序号	桩的入土深度/m	桩的直径/cm	桩侧 p_s 加权平均值/MPa	桩端 p_s 值/MPa	实测值/kN
1	37.3	45	0.983	2.25	1 400
2	33.8	45	0.968	2.29	1 860
3	33.8	45	0.938	2.02	1 280
4	29.8	45	0.973	2.48	1 890
5	28.9	45	0.821	2.30	1 250
6	28.9	45	0.767	1.20	1 000
7	31.8	45	1.850	10.37	3 100
8	31.8	45	1.640	10.82	3 100
9	20.2	25	0.753	1.24	600
10	21.2	25	0.703	1.04	500
11	30.6	40	1.473	6.00	1 950
12	30.6	40	1.327	6.00	1 755
1	35.3	45	0.915	2.12	1 320
2	32.3	45	0.946	2.42	1 800
3	37.3	45	0.978	2.21	1 400
4	31.8	45	1.770	10.58	3 100
5	20.4	25	0.765	1.24	650




图 1 γ 对测试集 MAPE 的影响曲线

Fig.1 Effect of γ on MAPE of test set




图 2 C 对测试集 MAPE 的影响曲线

Fig.2 Effect of C on MAPE of test set

2.4 预测结果分析

基于同样的训练样本,数据归一化处理以后,分别采用 SVM 模型、BP 网络模型对测试集进行了沉降预测。其中 BP 网络模型的输入层、隐层和输出层的神经元个数分别为 4,9,1。经过不断的训练调试,确定学习速率增长比例因子为 1.05,学习速率下降比例因子为 0.7,动量常数为 0.9,学习速率为 0.01,期望误差为 0.001。训练了 4 434 次,使 BP 网络训练均方误差达到同样训练样本的 SVM 训练均方误差终止。计算结果见表 2。选取平均相对误差 MAPE 和最大绝对误差(取绝对值)作为衡量预测精度的指标,如表 3 所示。

从表 2 和表 3 中可以看出:
(1)在同样的训练集均方误差的情况下,BP 网络模型预测测试集样本的平均相对误差和最大绝对误差均大于由 SVM 模型得出的预测结果,说明 SVM 模型泛化(预测)能力要优于 BP 网络模型。

(2)2 种预测方法所得到的结果都具有较高的预测精度,对于预制桩承载力,其预测误差基本上都在 10%以内。由工程经验可知,对于岩土工程而言,这一误差是可以接受的,SVM 的预测值与实测值吻合较为理想,说明利用静力触探的资料,运用 SVM 模型预测预制桩的承载力是可行的。

3 结语

本文将 SVM 方法应用于单桩竖向极限承载力预测中,建立了 SVM 预测模型。工程实例计算结果表明,在同样的训练均方误差下,SVM 方法预测能力要优于 BP 网络模型,该模型适应于综合分析各种类型桩基础的承载性状,对桩基工程设计方法与计算理论的发展具有一定的指导意义和参考价值。

参考文献:

[1] 邓乃扬,田英杰.数据挖掘中的新方法——支持向量机[M].北京:科学出版社,2004.
 [2] 纪 华,郑璐石.支持向量机及其在岩土工程中的应用[J].宁夏工程技术,2005,4(2):160-164.
 [3] 魏 杰.静力触探确定桩承载力的理论方法[J].岩土工程学报,1994,16(3):103-111.
 [4] 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,2004,10(6):639-642.

A Model Based on SVM for Predicting Vertical Ultimate Bearing Capacity of Single Pile

FAN Liang, HAN Yang, WANG Wei, SHI Xu-chao

(School of Civil Engineering and Architecture, Henan University of Technology, Zhengzhou 450052, China)

Abstract: Different methods for predicting vertical ultimate bearing capacity of single pile are comprehensively analyzed. The method of support vector machines is proposed for evaluating slope stability and building predicting model. Based on a large set of samples, practical effectiveness of the theory of support vector machines for predicting vertical ultimate bearing capacity of single pile is discussed.

Key words: single pile; vertical ultimate bearing capacity; support vector machine(SVM); prediction

表 2 不同预测方法得到的相对误差和绝对误差

Tab.2 Relative error and absolute error of different forecasting methods

序号	预测值 /kN	SVM 模型		BP 网络模型	
		相对误差 /%	绝对误差 /kN	相对误差 /%	绝对误差 /kN
1	1 320.81	0.06	0.81	3.44	45.46
2	1 788.66	-0.63	-11.34	-6.96	-125.29
3	1 368.67	-2.24	-31.33	-1.80	-25.15
4	3 176.41	2.47	76.41	1.39	43.09
5	598.75	-7.88	-51.25	-2.67	-17.35

表 3 平均相对误差和最大绝对误差

Tab.3 MAPE and maximal absolute error

参数	SVM 模型	BP 网络模型
平均相对误差/%	2.66	3.25
最大绝对误差/kN	76.41	-125.29