

文章编号: 1000-7598-(2005) 12-1987-04

公路软基沉降预测的支持向量机模型

黄亚东, 张土乔, 俞亭超, 吴小刚

(浙江大学 土木工程学系, 杭州 310027)

摘 要: 提出了基于支持向量机 (SVM) 模型对公路软基沉降进行预测的一种新方法, 工程实例预测结果表明, 在同样的训练均方误差下, SVM 模型预测能力要优于 BP 神经网络模型, 同时该模型能够综合利用分级加载过程中的沉降观测数据作为训练样本集, 比仅依靠预压期内部分实测沉降数据的双曲线法更能反映地基土的变形趋势。因此, 将建立的 SVM 模型应用于公路软基沉降预测能够更准确地反映实际沉降过程。

关 键 词: 公路软基; 支持向量机(SVM); 沉降; 预测

中图分类号: U 416.1

文献标识码: A

Support vector machine model of settlement prediction of road soft foundation

HUANG Ya-dong, ZHANG Tu-qiao, YU Ting-chao, WU Xiao-gang

(Department of Civil Engineering, Zhejiang University, Hangzhou 310027, China)

Abstract: A new method based on support vector machine (SVM) model is proposed to predict settlement of road soft foundation. A case study shows that the prediction results accord well with the actual settlement measured data. The new method is also compared with BP artificial neural network model and traditional hyperbola method. The prediction results indicate that the SVM model has a better prediction ability than BP neural network model at the same training set mean-square error. Utilizing the settlement data under multi-stage loading, SVM model has a better reflection for foundation soil deformation trend compared with hyperbola method only using the data under pre-loading. Therefore, settlement prediction based on SVM model can reflect actual settlement process more correctly.

Key words: road soft foundation; support vector machine(SVM); settlement; prediction

1 引 言

公路软基沉降预测是目前高速发展的软土地区高速公路建设中亟待解决的一大技术难题^[1]。为了提高预测沉降结果的精度和可靠性, 国内外学者提出了不少沉降计算方法。通过分析地基现场初期实测沉降资料, 预测沉降发展规律, 并以此推算后期沉降量, 在实际工程中具有重要意义。目前基于部分初期实测沉降数据的沉降预测方法主要有 Asaoka 法^[2]、双曲线法^[3]、灰色理论方法^[4]等。随着人工智能研究领域的发展, 人工神经网络方法在软基沉降预测中得到了广泛应用^[1, 5]。这些方法在一定程度上提高了软基沉降预测的精度和可靠性, 但也存在着不足之处, 如双曲线法是一种经验方法, 根据初期实测沉降数据来预测时, 该法计算

沉降量往往偏大; 人工神经网络方法基于经验风险最小化 (ERM) 准则, 容易导致神经网络的过拟合问题。

统计学习理论 (statistical learning theory 即 SLT) 是由 Vapnik 等人在 20 世纪 70 年代末提出的一种有限样本下统计学习的理论。支持向量机 (support vector machine 即 SVM) 方法是 SLT 的一种成功实现。SVM 方法根据结构风险最小化 (SRM) 准则, 尽量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^[6], 其基本思想概括起来就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^[7]。在岩土工程领域, SVM 方法也得到了一定的应用^[8]。由于软基沉降预测的复杂性, 在沉降与沉降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。本文基于支持向量机方法建立了公路软基后期沉降预测模型, 通过比较实测沉降数据、BP 神经网络模型及双曲线法的预测结果, 用工程实例说明了 SVM 模型推算后期沉降更能反映实际沉降过程。

2 沉降预测的 SVM 模型原理^[9]

通过实测获得前期沉降数据的样本集 $\{(x_1, y_1), \dots, (x_l, y_l)\}$, $x_i \in R^n, y_i \in R^1$, 其中 x_i 是沉降影响因素, y_i 为沉降值。使之通过训练后, 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, 对于实测值以外的 x_i 通过 $f(\bullet)$ 找出对应的 y_i , 即后期沉降。

考虑线性回归, 设线性回归函数 $f(x) = wx + b$, 假定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:

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

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

式中 $C > 0$, 表示对超出误差 ε 的样本的惩罚程度。

目标函数是严格上凹的二次型, 约束函数是下凹的, 这是一个严格凸规划。按照最优化理论中凸二次规划的解法, 可以转化为下列对偶问题:

$$\begin{aligned} \text{Max } W(a, \alpha^*) \Big|_{w, b, \xi_i, \xi_i^*} = & \\ -\frac{1}{2} \sum_{i,j=1}^l (a_i - \alpha_i^*) (a_j - \alpha_j^*) (x_i x_j) - & \\ \sum_{i=1}^l (a_i + \alpha_i^*) \varepsilon + \sum_{i=1}^l (a_i - \alpha_i^*) y_i & \end{aligned} \quad (4)$$

$$\begin{aligned} \sum_{i=1}^l (a_i - \alpha_i^*) &= 0 \\ 0 \leq \alpha_i, \alpha_i^* \leq C, i=1, \dots, l & \end{aligned} \quad (5)$$

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在约束式 (5) 下求解下述非线性规划问题:

$$\begin{aligned} \text{Max } W(a, \alpha^*) \Big|_{w, b, \xi_i, \xi_i^*} = & \\ -\frac{1}{2} \sum_{i,j=1}^l (a_i - \alpha_i^*) (a_j - \alpha_j^*) [\varphi(x_i) \varphi(x_j)] - & \\ \sum_{i=1}^l (a_i + \alpha_i^*) \varepsilon + \sum_{i=1}^l (a_i - \alpha_i^*) y_i & \end{aligned} \quad (6)$$

令 $K(x_i, x_j) = \varphi(x_i) \varphi(x_j)$, 则式 (6) 为

$$\begin{aligned} \text{Max } W(a, \alpha^*) \Big|_{w, b, \xi_i, \xi_i^*} = & \\ -\frac{1}{2} \sum_{i,j=1}^l (a_i - \alpha_i^*) (a_j - \alpha_j^*) K(x_i, x_j) - & \\ \sum_{i=1}^l (a_i + \alpha_i^*) \varepsilon + \sum_{i=1}^l (a_i - \alpha_i^*) y_i & \end{aligned} \quad (7)$$

此时, 函数 $f(x)$ 可表示为

$$f(x) = \sum_{i=1}^l (\alpha_i - \alpha_i^*) K(x, x_i) + b \quad (8)$$

其中 $a_i - \alpha_i^* \neq 0$ 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。核函数的引入, 巧妙地解决了因 $\varphi(x)$ 未知而 w 无法显示表达的问题。

$K(x_i, x_j)$ 是对称正实数函数, 同时满足 Mercer 条件。目前研究最多的核函数主要有 3 类: (1) 多项式核函数 $K(x_i, x_j) = (x_i x_j + 1)^d$, $d=1, 2, \dots$; (2) 高斯基核函数 $K(x_i, x_j) = \exp(-\gamma \|x_i - x_j\|^2)$; (3) Sigmoid 核函数 $K(x_i, x_j) = \tanh[\beta(x_i x_j) + c]$ 。核函数的选取需要一定的先验知识。

应用现成的优化软件包, 上述的二次规划问题不难求解。有关文献提出了一些用于大规模样本点的 SVM 算法, Cortes 和 Vapnik 提出了 Chunking 算法^[10], Platt 提出了序贯最小优化算法 (Sequential minimal optimization, SMO)^[11]等。

3 工程实例分析

图 1 为某试验路段加载及实测地表沉降与时间变化关系曲线图, 该试验路段软土含水量较高, 渗透性低, 属于高压缩性土, 于 2001 年 10 月 2 日开始铺设第 1 层土工格栅及碎石垫层, 2001 年 10 月 3 日 ($t=0$ d) 进行第 1 次沉降观测, 2002 年 5 月下旬 ($t=263$ d) 堆载至设计标高。






图 1 荷载-沉降的时间序列曲线

Fig.1 The load-settlement time series curves

该试验路段有接近两年左右共 72 个沉降观测数据, 选取第 402 d 至 710 d 期间共 10 个时间间隔将近一年的沉降观测数据作为测试样本集, 剩余观测数据即加载开始至第 394 d 的数据作为训练样本集。一般, 影响路基沉降的主要因素有软土的工程性质、荷载性质、基础性质^[5], 由于地基土的性质和基础性质对于某一典型断面可以看作是固定的, 因此本文选取当前路堤填土荷载 p 和当前时刻 t 为输入变量, 输出为当前时刻 t 的沉降值。分别采用 SVM 模型和 BP 神经网络模型进行预测比较。为将 SVM 模型与传统的沉降预测方法进行比较, 选取实际工程中常用的双曲线法与其比较。

3.1 参数选择

SVM 模型计算选用高斯基核函数, 参数选择如下: $C=250$, $\gamma=1$, $\varepsilon=0.001$ 。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 2 是当 γ 固定在 1 时, 参数 C 对测试集平均相对误差的影响曲线, 图 3 是当 C 固定在 250 时, 参数 γ 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 $\frac{1}{n} \sum_i |(L_{R_i} - L_{P_i}) / L_{R_i}|$; L_{R_i} 为实测沉降数据; L_{P_i} 为预测沉降数据; n 为待预测的沉降点数。

图 2 C 对测试集 MAPE 的影响曲线Fig.2 Effect of C on MAPE of test set图 3 γ 对测试集 MAPE 的影响曲线Fig.3 Effect of γ on MAPE of test set

3.2 预测结果比较

基于同样的训练样本, 分别采用 SVM 模型、BP 神经网络模型对测试集进行了沉降预测。其中 BP 神经网络模型利用 MATLAB 神经网络工具箱建模, 输入层、隐层和输出层的神经元个数分别为 2, 3, 1, 训练使 BP 神经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。传统的沉降预测方法一般只利用加载完成后恒载阶段的沉降观测数据进行预测分析, 选取第 263 (加载结束) ~ 394 d 共 131 d 的沉降观测数据用双曲线法拟合测试集的沉降数据。计算结果见表 1。表中相对误差取 $(L_P - L_R) / L_R$, 绝对误差取 $L_P - L_R$ 。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 2 所示。

表 1 不同预测方法得到的相对误差和绝对误差

Table 1 Relative error and absolute error of different forecasting methods

时间 /d	实测值 /cm	SVM 模型		BP 神经网络模型		双曲线法	
		相对误差 /%	绝对误差 /cm	相对误差 /%	绝对误差 /cm	相对误差 /%	绝对误差 /cm
402	176.5	-2.92	-5.15	-1.93	-3.40	0.74	1.31
405	176.9	-2.54	-4.49	-1.66	-2.94	1.11	1.97
416	179.5	-1.82	-3.27	-1.41	-2.53	1.74	3.12
424	183.5	-2.48	-4.54	-2.45	-4.49	0.95	1.75
426	184.1	-2.43	-4.47	-2.50	-4.60	0.97	1.79
453	192.4	-2.07	-3.98	-3.62	-6.97	0.89	1.71
477	196.9	-0.60	-1.19	-3.65	-7.19	1.95	3.85
528	206.3	1.50	3.10	-4.83	-9.96	3.30	6.81
644	218.3	5.42	11.83	-6.71	-14.65	7.53	16.43
710	223.8	5.03	11.25	-8.25	-18.47	9.12	20.40

表 2 平均相对误差和最大绝对误差

Table 2 MAPE and maximal absolute error

参数	SVM 模型	BP 神经网络模型	双曲线法
平均相对误差 /%	2.68	3.70	2.83
最大绝对误差 /cm	11.83	-18.47	20.40

从表 1 和表 2 中可以看出:

(1) 在同样的训练集均方误差的情况下, BP 神经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,说明支持向量机模型泛化(预测)能力要明显优于 BP 神经网络模型。

(2) 按双曲线法得到的沉降与实测值相比都偏大,这与实际工程经验相符。比较 SVM 模型和双曲线法得到的预测结果,SVM 模型同样优于双曲线法,原因应该是 SVM 模型综合利用了分级加载过程的沉降观测数据作为训练样本集,而双曲线法仅仅利用了加载结束后恒载阶段(预压期)内部分沉降观测数据。这反映了软土地基的工程力学性质是随着加载逐渐改善的过程,所以 SVM 模型更能反映软土地基的变形趋势。

(3) 3 种预测方法在预测前期具有较高的预测精度,相对误差均在 5 % 以内,在第 644 d 和第 710 d 预测相对误差和绝对误差都有所增大,但结果还是能满足实际工程需要的。同时说明预测时间段的选取对预测精度有较大影响,如何选择最优的预测时间段有待于进一步研究。综合比较实测沉降值与 SVM 模型、BP 神经网络模型和双曲线法得出的预测结果,SVM 模型预测精度最高。因此将 SVM 模型应用于软基沉降预测中更能反映实际沉降过程。

4 结 语

本文把支持向量机方法应用于公路软基沉降预测中,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 神经网络模型。同时由于 SVM 模型能够综合考虑分级加载过程中的沉降观测数据,比仅仅靠预压期内部分实测数据的双曲线法预测结果更为合理。因此,将支持向量机模型应用于公路软基沉降预测是可行的和值得研究的。

参 考 文 献

- [1] 钟才根,丁文其,王茂和,等. 神经网络模型在高速公路软基沉降预测中的应用[J]. 中国公路学报, 2003, 16(2): 31—34.
ZHONG Cai-gen, DING Wen-qi, WANG Mao-he, et al. Application of artificial neural network to settlement prediction of highway soft foundation[J]. **China Journal of Highway and Transport**, 2003, 16(2): 31—34.
- [2] Asaoka A. Observational procedure of settlement prediction[J]. **Soils & Foundations**, 1978, 18(4): 87—101.
- [3] 钱玉林,丁毅. 路基沉降预测及其工程应用[J]. 扬州大学学报(自然科学版), 2001, 4(2): 75—78.
- [4] 雷学文,白世伟,孟庆山. 灰色预测在软土地基沉降分析中的应用[J]. 岩土力学, 2000, 21(2): 145—147.
LEI Xue-wen, BAI Shi-wei, MENG Qing-shan. The application of grey forecasting to analysing soft foundation settlements[J]. **Rock and Soil Mechanics**, 2000, 21(2): 145—147.
- [5] 杨涛,李国维,樊琨. 基于人工神经网络的公路软基沉降预测模型[J]. 上海理工大学学报, 2003, 25(2): 117—120.
YANG Tao, LI Guo-wei, FAN Kun. Prediction model of settlement of embankment on soft ground based on artificial neural network[J]. **Journal of University of Shanghai for Science and Technology**, 2003, 25(2): 117—120.
- [6] 张学工. 关于统计学习理论与支持向量机[J]. 自动化学报, 2000, 26(1): 32—40.
ZHANG Xue-gong. Introduction to statistical learning theory and support vector machines[J]. **Acta Automation Sinica**, 2000, 26(1): 32—40.
- [7] Smola A J, Scholkopf B. On a kernel-based method for pattern recognition, regression, approximation and operator inversion[J]. **Algorithmica**, 1998, 22: 211—231.
- [8] 赵洪波,冯夏庭,尹顺德. 基于支持向量机的岩体工程分级[J]. 岩土力学, 2002, 23(6): 698—701.
ZHAO Hong-bo, FENG Xia-ting, YIN Shun-de. Classification of engineering rock based on support vector machine[J]. **Rock and Soil Mechanics**, 2002, 23(6): 698—701.
- [9] Vapnik V N. The Nature of Statistical Learning Theory[M]. NY: Springer-Verlag, 1995.
- [10] Cortes C, Vapnik V. Support vector networks[J]. **Machine Learning**, 1995, 20: 273—297.
- [11] John C. Platt. Sequential Minimal Optimization: A Fast Algorithm for Training Support Vector Machines[R]. [s.l.]: Technical Report MSR-TR-98-14, 1998.