

LS-SVM 在桥梁结构健康预测评估中的研究

于重重^{1,2}, 王竞燕¹, 谭 励¹, 涂序彦², 杨 扬²

(1 北京工商大学 计算机与信息工程学院, 北京 100048; 2 北京科技大学 信息工程学院, 北京 100083)

摘 要: 桥梁的结构变形包含的桥梁结构内涵信息丰富, 具有非线性、时序性和样本容量小的特点. 利用支持向量机, 以杭州湾大桥实测变形数据为研究对象, 提出了基于 LS-SVM 的桥梁结构变形预测模型, 通过实验证明了运用其对桥梁结构健康状况进行评估的可行性和有效性, 并且通过实验结果对比显示了最小二乘支持向量机在变形预测中的优势.

关键词: 桥梁结构健康监测; 变形; 最小二乘支持向量机

中图分类号: TP311

文献标识码: A

文章编号: 1000-7180(2011)06-0148-05

Study on LS-SVM in Evaluation of Bridge Structural Health Monitoring

YU Chong-chong^{1,2}, WANG Jin-yan², TAN Li¹, TU Xu-yan², YANG Yang²

(1 Dept. of Information Engineering, University of Science and Technology Beijing, Beijing 100083, China;

2 Dept. of Computer and Information Engineering, Beijing Technology and Business University, Beijing 100037, China)

Abstract: Structural distortion of bridge contains rich connotation information of bridge structures and possesses the features of nonlinear, sequential and small sample capacity. In this article, the calculated model of bridge structural distortion is given out by application of support vector machine and the practical monitoring data of Hangzhou Bay Bridge are taken as the study object. The feasibility and effectiveness of evaluation over bridge structural health state have been proved through test, and the superiority of least square support vector machine in distortion calculation has been shown on comparison of test results.

Key words: bridge structural health monitoring; distortion; least squares support vector machine

1 引言

长期使用会造成桥梁结构不同程度的自然积累损伤和突然损伤^[1], 以及由于养护不当等原因也会导致桥梁被人为损伤, 这使得桥梁结构健康监测的作用显得尤为重要. 桥梁结构健康监测^[2]主要是通过对桥梁结构状态的监控和评估, 从而在特殊气候和交通条件下或者桥梁运营状况发生异常的情况下, 发出警示信号, 准确和及时的对桥梁维护、维修和管理提供可靠和有利的依据.

1990 年代中期, 由 Vapnik 等提出的支持向量机(Support Vector Machine, SVM), 是建立在统计

学习理论^[3-5]和结构风险最小化原则之上发展起来的一种具有良好性能的学习方法, 其主要用于径向基函数、多项式或神经网络分类器进行学习和训练, 并且在解决非线性小样本以及高维模式识别问题上表现出特有的优势. 基于泛化能力强、维数不敏感、能获得全局最优解等特点, 使 SVM 方法得到了广泛的使用^[6-7]. 但是在求解过程中, 需要解决关于带约束的二次规划问题, 某些情况下会因为训练时间过长而使 SVM 的方法在效率方面受到一定的影响. 最小二乘支持向量机(Least Squares Support Vector Machine, LS-SVM)方法是在 SVM 的基础上发展起来的, 由 Suykens 等人提出^[8-9]. LS-SVM

收稿日期: 2010-10-20; 修回日期: 2011-02-10

基金项目: 北京市教委面上项目(KM200810011006); 北京市中青年骨干教师项目(200775)

在目标函数中采用了误差平方代替了 SVM 中的松弛变量,即把求解一个二次规划的问题转化为求解一组线性方程组,大大提高了求解的速率,改善了 SVM 的训练效率。

桥梁的变形数据集是一种具有非线性、时序特点的小样本数据集,并因为变形数据中包含的桥梁结构内涵信息丰富,监测实施简单,数据建模方法容易,所以对桥梁结构健康监测状态的评估和预测作用巨大。目前在变形数据预测方面存在的问题为:利用线性统计模型评估预测造成的误差较大,不能正确反映桥梁结构健康的状况。针对变形数据集的特点,提出基于统计学习理论的支持向量机模型适用于对非线性小样本数据集进行预测分析。本文利用最小支持向量机,以变形数据为研究对象,进行建模研究,证明了支持向量机可以作为对桥梁结构健康状况进行评估的一种有效的方法。

2 最小二乘支持向量机回归原理

LS-SVM 回归原理描述如下:

设样本集为

$$\{x_i, y_i\}, i = 1, 2, \dots, n, x_i \in R^n, y_i \in R$$

式中, x_i 作为第 i 个样本的输入, y 是相应的输出。根据 Suykens 提出的理论,通过非线性函数 $\varphi(x_i)$ 从输入空间 R^n 向高维特征空间 Z 映射。通过在高维空间中的线性函数:

$$f(x) = w \cdot \varphi(x) + b \quad (1)$$

进行样本拟合,其中 w 和 b 是待定参数根据 Suykens 提出的理论,通过非线性函数 $\varphi(x_i)$ 从输入空间 R^n 向高维特征空间 Z 映射。LS-SVM 化问题定义如下:

$$\min_{w, b, e} J(w, e) = \frac{1}{2} w^T w + \frac{1}{2} \gamma \sum_{i=1}^n e_i^2 \quad (2)$$

$$\text{s. t. } y_i = w \cdot \varphi(x_i) + b + e_i, \gamma > 0, i = 1, 2, \dots, n$$

目标函数的第一项表示模型的泛化能力,第二项表示模型的精确性, γ 是模型泛化和精度之间的一个可调参数,而 e_i 则是第 i 个数据的实际输出与预测值的差值。下面通过构建 Lagrange 函数,解决上述问题:

$$L(w, b, e; a) = J(w, b, e) - \sum_{i=1}^n a_i \{w \cdot \varphi(x_i) + b + e_i - y_i\} \quad (3)$$

式中, $a_i \in R$ 为 Lagrange 乘子。根据库恩-塔克条

件可得

$$\begin{cases} \frac{\partial L}{\partial w} = 0 \Rightarrow w = \sum_{i=1}^n a_i \varphi(x_i) \\ \frac{\partial L}{\partial b} = 0 \Rightarrow \sum_{i=1}^n a_i = 0 \\ \frac{\partial L}{\partial e_i} = 0 \Rightarrow a_i = \gamma e_i \\ \frac{\partial L}{\partial a_i} = 0 \Rightarrow w \cdot \varphi(x_i) + b + e_i - y_i \end{cases} \quad (4)$$

由式(4)中 $a_i = \gamma e_i$ 可知,如果 e_i 不为零,那么 Lagrange 乘子 a_i 也不为零。因此 LS-SVM 较于 SVM 来说,就是去了稀疏性。通过消去变量 w 和 e_i ,得到矩阵:

$$\begin{bmatrix} 0 & Z^T \\ Z & K + D \end{bmatrix} \begin{bmatrix} b \\ a \end{bmatrix} = \begin{bmatrix} 0 \\ y \end{bmatrix}$$

式中, $y = [y_1, y_2, \dots, y_n]^T$, $Z = [1, \dots, 1]^T$, $a = [a_1, a_2, \dots, a_n]^T$, $D = \text{diag}(\gamma^{-1}, \dots, \gamma^{-1})$, $K = \{K_{ij} = K(x_i, x_j), i, j = 1, 2, \dots, n\}$ 。

通过求解线性方程组式(4),可得最终的 LS-SVM 模型表达式:

$$f(x) = \sum_{i=1}^n a_i K(x, x_i) + b \quad (5)$$

3 基于 SVM 的桥梁结构变形预测模型

变形对于桥梁结构来说是一个重要的参数,对桥梁结构变形进行实时监测,能够及时获取桥梁结构变形信息,从而对大桥结构健康进行评估。基于桥梁结构的变形数据构造关联多属性样本集,经过数据预处理得到训练样本集和测试样本集,训练样本在参数进行优化后进行训练得到预测模型,将测试样本集输入模型得到预测的结构变形值,通过性能指标可以对模型做出综合评价。

3.1 样本属性选择

在桥梁监测的过程中,由上文对变形特点的介绍可知,变形值是主要的属性。在变形数据监测的过程中,通过对原始监测数据的观察和对变形特点的了解,可以确定三个与变形密切相关的辅助属性:月份、小时和温度,而变形值则作为主要属性。运用关联度分析法,以确定适合样本构造的最终的辅助属性集。通过计算得到主要属性变形和三个辅助属性之间的关联度如表1所示。

通过表中的相关系数 r 可知, r 的值越接近1,说明该辅助属性与主要属性变形之间的关系就越密切。上述三个辅助属性中,月份和温度的相关系数 r

较高,与变形的关系较为密切.虽然小时这个辅助属性的相关系数较低,但是对于变形数据来说,在数据监测的过程中是具有时序性的,且在每个小时的采集过程中针对某一个监测点的变形值来说,具有相对随机性,所以在决定最终辅助属性集合时,将小时也考虑在内.

表 1 主要属性与辅助属性的相关度

辅助属性	相关度系数(r)
月份	0.871 1
小时	0.166 5
温度	0.632 2

3.2 数据预处理

本文中的变形数据来自杭州湾跨海大桥北航道桥主跨等部位的结构变形.实际中,变形原始监测值并不能表征变形的物理意义,也不能直接作为研究数据,所获得的原始变形监测数据必须经过处理,得到相对变形值,才能够更好的研究变形问题.相对变形值,是指在同一时刻以参考点的变形值作为基准,其他监测点与参考点的变形值形成的差值.相对变形值在实际应用中具有更大的研究意义.以下基于杭州湾跨海大桥的实际情况,介绍相对变形值的具体内容.

其中在北航道桥部分,一共布置了 26 个变形监测点,利用连通管传感器来测量主跨变形情况.具体测点分布如图 1 所示.




图 1 北航道桥变形测点分布图

根据实际监测情况,位于桥墩处的监测点变形值变化相对较小,可作为最佳参考点(如图 1 中 9 号、20 号监测点);而位于跨中(如图 1 中 14 号、15 号监测点)、1/2 跨中(如图 1 中 11 号、12 号监测点)、1/4 跨中(如图 1 中 10 号、19 号监测点)处监测点的变形相对明显,可以作为重要参考点计算相对变形值以及作为构造样本时的主要属性.本文中选择位于跨中的监测点(如图 1 中 14 号),其某一时刻的变形值为 x_m ,而同一时刻位于桥墩处监测点(如图 1 中 9 号)的变形值为 x_0 ,则最终相对变形值 Δx 为

$$\Delta x = |x_m - x_0| \tag{6}$$

为了减小各辅助属性之间的量级差别,对各属性数据使用 $\hat{X}_i = \frac{X_i - \min(X_i)}{\max(X_i) - \min(X_i)}$ 将样本归一化到区间[0,1].将待预测的日期作为参考界限,选取参考日期前连续若干天的采集数据,经过数据预处理形成训练样本集,待预测日期的数据经过预处理后形成测试样本集.

3.3 SVM 参数优化

在样本集准备完毕后,预测模型需要确定核函数和各个参数的初始值.本文选用径向基核函数:

$$K(x, x_k) = \left\{ -\frac{\|x - x_k\|^2}{2\sigma^2} \right\} \tag{7}$$

式中, $\|x - x_k\| = \sqrt{\sum_{k=1}^n (x^k - x_i^k)^2}$, σ 为核宽度.对于 LS-SVM 预测模型中的正则参数 γ 和核参数 σ ,以及 ϵ -SVM 预测模型中的惩罚参数 C 和不敏感损失度 ϵ ,运用 10 次 10 倍交叉验证的网格搜索法进行参数寻优.

3.4 性能评价

为了综合评价基于 SVM 的结构变形预测模型,本文中采用最大相对误差(MRE)、最大绝对误差(MAE)和均方误差(MSE)3 个误差统计量以及模型的训练时间 T_{train} 和预测时间 T_{test} 作为评价性能指标.

$$\text{MRE} = \max\left(\frac{|y_i - \hat{y}_i|}{y_i}\right) \times 100\% \tag{8}$$

$$\text{MRE} = \max(|y_i - \hat{y}_i|) \tag{9}$$

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|^2 \tag{10}$$

式中, n 为测试样本容量, y_i 为真实值, $\hat{y}_i$ 为估计值.

4 仿真实验

4.1 模型验证

通过构建桥梁结构变形预测模型,验证该模型能否准确预测单个变形测点某天的变形数据,进一步验证其能否准确预测评估桥梁结构健康状况.本实验根据预测时间点在本月两种情况验证.

4.1.1 训练样本数据与测试样本数据在同月

选取图 1 中的 14 号测点,训练样本由 2008 年 10 月 1 日—10 日的 14 号测点的所有数据组成.测试样本为 08 年 10 月 11 日的 14 号监测点的原始监测数据.模型参数和性能指标如表 2 所示.

图 2 为原始值和预测值的分布趋势,可以看出预测值分布趋势基本符合原始值分布.图 3 为误差曲线图,从图中可以看到误差范围为[0.01,0.09],

在误差允许范围之内. 根据实验数据,计算出 MSE 的值为 0.0473,并体现出较优的时间性能.

表 2 同月份预测模型参数及性能指标

模型参数	方法名称	LS-SVR
	核函数	RBF
	正则化参数 γ	10
	RBF 核参数 σ	0.2
性能指标	训练时间/s	0.373 5
	预测时间/s	0.069 9
	MSE	0.002 2




图 2 同月份模型预测趋势图




图 3 同月份模型预测误差曲线

4.1.2 训练样本数据与测试样本数据不在同月
选取图 1 中的 14 号测点,训练样本由 2008 年 10 月 25—31 日的 14 号测点的所有数据组成. 测试样本为 2008 年 11 月 24 日的 14 号监测点的原始监测数据. 模型参数和性能指标如表 3 所示.

表 3 跨月份预测模型参数及性能指标

模型参数	方法名称	LS-SVR
	核函数	RBF
	正则化参数 γ	10
	RBF 核参数 σ	0.2
性能指标	训练时间/s	0.397 7
	预测时间/s	0.084 7
	MSE	0.007 1

图 4 为原始值和预测值的分布趋势,可以看出预测值分布趋势基本符合原始值分布,但不如图 2 拟合效果好. 图 5 为误差曲线图,从图中可以看到误




图 4 跨月份模型预测趋势图




图 5 跨月份模型预测误差曲线

差范围为[0.02,0.16],大于图 3 中的误差范围,但仍然在较为理想的误差限内. 在时间消耗上仍然体现出较优的性能.

综合上述实验结果,对于某一个变形监测点,只要无论训练数据和预测数据是否在时间上连续,跨度在一定范围内,该模型是可以较为准确预测一个月时间段内的某一天变形值,从而可以针对单个变形测点对桥梁结构健康状况进行预测评估.

4.2 LS-SVR 与传统 SVR 性能比较实验

实验选取 4.1 节中同月份的数据,模型的初始参数如表 4 所示.

表 4 两种方法参数信息表

方法名称	核函数	参数初始值
C-SVR	RBF	惩罚因子 $C=100$
		不敏感损失度 $\epsilon=0.1$
		核函数参数 $\sigma=0.2$
LS-SVR	RBF	正则参数 $\gamma=10$ 核函数参数 $\sigma=0.2$

经过参数寻优,LS-SVM 与 C-SVM 预测实验结果比较和误差曲线比较如图 6 和图 7 所示,具体性能指标参数如表 5 所示.




图 6 LS-SVM 与 C-SVM 预测实验比较图




图 7 LS-SVM 与 C-SVM 误差曲线比较图

表 5 不同 SVM 模型预测效果的对比

评价指标	C-SVR	LS-SVR
MRE/%	0.789 9	0.657 5
MAE	0.108 0	0.089 9
MSE	0.014 1	0.002 2
T_{train}	2.109 3	0.373 5
T_{test}	0.003 2	0.001 3

从表 5 中可以看出,C-SVM 预测实验产生的误差相对 LS-SVM 预测结果比较明显,针对实际的变形数据,LS-SVM 预测实验的 RMSE 值为0.047 3,而 C-SVM 实验的 RMSE 值0.108 9,在预测实验的准确率方面,使用 LS-SVM 预测的误差率较小;在训练时间方面,LS-SVM 需要0.373 5 s,而 C-SVM 则需要2.109 3 s,在预测实验的时间效率方面,LS-SVM 也占有绝对的优势.因此,对于预测短时间段的变形值,利用 LS-SVM 能够得到更为理想的结果,并且能够较准确地基于单变形测点对桥梁结构健康状况进行预测评估.

5 结束语

对于桥梁结构健康监测与评估,是近些来的热点研究问题.以杭州湾跨海大桥实际采集的变形数据作为研究对象,通过实验仿真,证明了运用 SVM

建立的结构变形预测模型,对桥梁结构健康状况进行监测和评估的可行性和有效性.并且在实验中,对 C-SVM 与 LS-SVM 在预测性能方面进行了比较,在实际数据为研究对象的背景下,LS-SVM 显示出了更好的性能.

参考文献:

[1] 秦权. 桥梁结构的健康监测[J]. 中国公路学报, 2000, 13(2): 37—42.

[2] 张启伟. 大型桥梁健康监测概念与监测系统设计[J]. 同济大学学报, 2001, 29(1): 65—69.

[3] Vapnik V N. The nature of statistical learning theory [M]. New York: Springer Verlag, 1995.

[4] Burges C J C. A tutorial on support vector machines for pattern recognition[J]. Knowledge Discovery and Data Mining, 1998, 2(2): 121—167.

[5] Vapnik V N. An overview of statistical learning theory [J]. Ieee Transactions on Neural Networks, 1 999, 10 (5): 988—999.

[6] 崔永超,王永华. 基于支持向量机的软测量建模方法的应用[J]. 南京工业大学学报, 2007, 5: 99—102.

[7] 谭超. 基于支持向量机的软测量技术及其应用[J]. 传感器技术, 2005, 24(8): 77—79.

[8] Suykens J A K, Vandewalle J. Least squares support vector machine classifiers [J]. Neural Processing Letters, 1999(9): 293—300.

[9] Suykens J A K. Nonlinear modeling and support vector machines[C]// IEEE Instrumentation and Measurement Technology Conference. Budapest, Hungary: Institute of Electrical and Electronics Engineers Inc. 2001: 287—295.

作者简介:

于重重 女, (1971—), 博士研究生, 副教授, CCF 会员. 研究方向为智能信息处理、计算机网络与监控系统.