

# 基于支持向量机的机械设备状态趋势预测研究

李凌均, 张周锁, 何正嘉

(西安交通大学机械工程学院, 710049, 西安)

**摘要:** 提出了用支持向量机对机械设备状态趋势进行预测的新方法, 构造了相应的支持向量回归机, 并分别用仿真数据和实际数据对其性能进行了验证. 将该支持向量回归机应用于某机组振动信号的预测, 采用径向基核函数和合适的参数, 使该向量回归机对振动量峰峰值的单步预测误差小于 2%, 24 步预测误差小于 5%, 表明该算法对机械设备的运行状态趋势具有较好的预测能力.

**关键词:** 支持向量机; 回归; 趋势预测

**中图分类号:** TH17 **文献标识码:** A **文章编号:** 0253 - 987X(2004)03 - 0230 - 04

## Research on Condition Trend Prediction of Mechanical Equipment Based on Support Vector Machine

Li Lingjun, Zhang Zhousuo, He Zhengjia

(School of Mechanical Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

**Abstract:** A new method of condition trend prediction of mechanical equipment based on support vector machine was presented and the support vector regression machine was constructed. Both simulation data and actual data were used to validate the performance of this regression machine. The support vector regression machine was applied to the trend prediction of the vibration signal from machine sets. The single-step prediction error for peak-peak value of the vibration signal is less than 2% and the 24 steps prediction error is less than 5% with radial basis function (RBF) kernel function and proper parameters. These results show that the support vector regression machine has excellent performance of condition trend prediction for mechanical equipment.

**Key words:** support vector machine; regression; trend prediction

支持向量机 (Support Vector Machine, 简称 SVM) 是在 20 世纪 90 年代由 V. Vapnik 等人研究并迅速发展起来的一种基于统计学习理论 (Statistical Learning Theory, 简称 SLT) 的机器学习算法. 该算法通过寻求结构风险最小化来实现实际风险最小化, 从而达到在样本量较少的情况下, 亦能获得很好的学习效果. 另外, 因为支持向量机算法是一个二次优化问题, 所以能保证所得到的解就是全局最优解. 由于该算法具有完备的理论基础 (统计学习理论) 和出色的应用表现, 因此正在成为继神经网络之后, 在机器学习领域中新的研究热点.

SVM 的应用主要在模式识别、函数回归和概率密度估计方面. 在模式识别方面, 已被广泛应用于机械故障诊断、人脸识别和电子邮件分类等领域. 在函数回归方面, 也已成功地应用于金融预报<sup>[1]</sup>和电力负荷预报<sup>[2]</sup>等领域. 特别是 2001 年, 在由 EUNITE (European Network on Intelligent Technologies for Smart Adaptive System) 组织的一次电力负荷预测大赛中, Bo-Juen Chen 等人用支持向量机的方法预测, 因预测的准确性高而力挫群雄, 并最终一举夺魁<sup>[2]</sup>, 由此可见支持向量机的方法在预测方面所具有的优势. 本文研究支持向量机的回归 (Support

收稿日期: 2003 - 05 - 19. 作者简介: 李凌均 (1964 ~), 男, 博士生; 何正嘉 (联系人), 男, 教授, 博士生导师. 基金项目: 国家自然科学基金资助项目 (50175087); 国家“十五”科技攻关计划资助项目 (2001BA204B05).

Vector machine Regression,简称 SVR)在机械设备状态趋势预测和故障预示方面的应用,旨在为机械设备状态的预测提出一种新的方法.

### 1 支持向量机回归算法

本节简要介绍支持向量机的回归算法<sup>[3]</sup>.首先考虑线性回归问题,对于给定的训练样本  $(x_i, y_i)$ ,  $x \in R^d, y_i \in R, i = 1, \dots, n$ ,线性回归的目标就是求下列回归函数

$$f(x) = (w \cdot x_i) + b \tag{1}$$

式中:  $w \in R^n; b \in R; (w \cdot x_i)$ 为  $w$  与  $x$  的内积,并且满足结构风险最小化原理.

对优化目标函数求极值

$$Q(w) = \frac{1}{2}(w \cdot w) + CR_{emp}(f) \tag{2}$$

式中:  $C$  为惩罚因子,实现在经验风险和置信范围之间的折中;  $R_{emp}(f)$  为损失函数.常用的损失函数有二次函数、Huber 函数、Laplace 函数和  $\rho$ -不敏感函数,其中  $\rho$ -不敏感函数因具有较好的性质而得到广泛的应用,定义为

$$L(d, y) = \begin{cases} |d - y| - \frac{1}{2}|d - y|^2, & |d - y| \leq 1 \\ \frac{1}{2}, & \text{其他} \end{cases} \tag{3}$$

当引入  $\rho$ -不敏感损失函数时,式(2)可写为

$$Q(w) = \frac{1}{2}(w \cdot w) + C \sum_{i=1}^n \max(0, |y_i - f(x_i)| - 1) \tag{4}$$

显然,当  $|y_i - (w \cdot x_i) - b| \leq 1 (i = 1, 2, \dots, n)$ ,即所有样本点均落在由  $f(x) + 1$  和  $f(x) - 1$  组成的带状区域内(见图 1 中的 2 条细实线)时,式(4)可写为

$$\min \frac{1}{2}(w \cdot w) \tag{5}$$

约束条件

$$\begin{aligned} y_i + w \cdot x_i - b &\leq 1 \\ w \cdot x_i - y_i + b &\leq 1 \end{aligned}$$

考虑到上述条件不能充分满足,引入松弛因子




图 1 线性回归示意图

$\xi_i \geq 0$  和  $\xi_i^* \geq 0$ ,则式(5)的优化问题变为

$$\min \frac{1}{2}(w \cdot w) + C \sum_{i=1}^n (\xi_i + \xi_i^*) \tag{6}$$

约束条件

$$\begin{aligned} y_i - w \cdot x - b &\leq 1 + \xi_i \\ w \cdot x - y_i + b &\leq 1 + \xi_i^* \end{aligned}$$

上述问题可以通过求解最大化二次型<sup>[3]</sup>的参数  $\xi_i^*, \xi_i$  而得到解决

$$Q(\xi, \xi^*) = - \sum_{i=1}^n (\xi_i^* + \xi_i) + \sum_{i=1}^n y_i (\xi_i^* - \xi_i) - \frac{1}{2} \sum_{i=1, j=1}^n (\xi_i^* - \xi_i) (\xi_j^* - \xi_j) (x_i \cdot x_j) \tag{7}$$

其约束条件为

$$\left. \begin{aligned} \sum_{i=1}^n (\xi_i^* - \xi_i) &= 0 \\ 0 &\leq \xi_i^* \leq C \\ 0 &\leq \xi_i \leq C \end{aligned} \right\} i = 1, 2, \dots, n \tag{8}$$

式中:  $b$  可由式(6)的约束条件按等号求出.求解出上述各参数  $\xi_i, \xi_i^*, b$  后,就可得到对未来样本的预测函数

$$f(x, \xi, \xi^*) = \sum_{i=1}^n (\xi_i - \xi_i^*) (x_i \cdot x) + b \tag{9}$$

对于非线性问题,根据 V. Vapnik 提出的核函数理论<sup>[3]</sup>,可以用核函数  $K(x_i, x_j)$  来替代内积运算,实现由低维空间到高维空间的映射,从而使低维空间的非线性问题转化为高维空间的线性问题.引入核函数后,优化目标函数式(7)变为如下形式

$$Q(\xi, \xi^*) = - \sum_{i=1}^n (\xi_i^* + \xi_i) + \sum_{i=1}^n y_i (\xi_i^* - \xi_i) - \frac{1}{2} \sum_{i=1, j=1}^n (\xi_i^* - \xi_i) (\xi_j^* - \xi_j) K(x_i, x_j) \tag{10}$$

而相应的预测函数式(9)也变为

$$f(x, \xi, \xi^*) = \sum_{i=1}^n (\xi_i - \xi_i^*) K(x_i, x) + b \tag{11}$$

常用的核函数有多项式核函数、线性核函数、高斯核函数和径向基核函数.

### 2 时间序列预测方法和误差评价

假设系统的输出采样时间间隔是  $\Delta t$ ,得到的输出时间序列为

$$t(0), t(\Delta t), \dots, t(i\Delta t), \dots, t((n-1)\Delta t) \tag{12}$$

该输出序列也是对未来值进行预测时的输入序列.由  $n$  时刻的前  $m$  个值预测第  $n$  个值的问题可表示

为寻找如下的对应关系  $f$  的问题

$$t_n = f(t_{n-1}, t_{n-2}, \dots, t_{n-m}) \quad (13)$$

式中  $t_i$  是  $t(i)$  的缩写形式,  $i = 1, 2, \dots$  在训练回归模型时, 组成如下的训练样本对: 输入  $(t_1, t_2, \dots, t_m)$  对应某时刻的输出为  $(t_{m+1}), (t_2, t_3, \dots, t_{m+1}), (t_{m+2}), \dots$  并依此类推, 由  $l$  个训练样本就可构建  $l - m$  个训练样本对.

当模型训练完成后, 对未来值第 1 步预测的形式为

$$t_{n+1}^* = f(t_n, t_{n-1}, \dots, t_{n-m+1}) \quad (14)$$

第 2 步预测为

$$t_{n+2}^* = f(t_{n+1}^*, t_n, t_{n-1}, \dots, t_{n-m+2}) \quad (15)$$

后续各步预测依此类推, 并由此形成多步预测.  $t_i$  为第  $i$  点的真实值,  $t_i^*$  为第  $i$  点的预测值,  $i = 1, 2, \dots$  在某些情况下, 例如对缓变信号, 其预测点间的时间间隔较长, 当进行第 2 步预测时, 第 1 步的真实值就已经知道了, 在式 (15) 中就可以用真实值  $t_{n+1}$  替代预测值  $t_{n+1}^*$ , 这就成了单步预测.

对于评价预测的精度问题, 文中采用的误差计算公式为<sup>[2]</sup>

$$M_{APE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{t_i - t_i^*}{t_i} \right| \quad (16)$$

### 3 仿真数据验证分析

本小节用 sinc 函数的仿真数据验证上述的 SVR 算法. sinc 函数在很多文献中被广泛应用于函数的回归验证<sup>[4]</sup>, 其定义为

$$f(t) = \text{sinc}(t + a) + b \quad (17)$$

不失一般性, 取  $a = -4, b = 0.5$ , 对该函数在区间  $t \in [0, 8]$  上均匀地取 81 个数据点, 其中前 61 个点作为学习样本, 后 20 个点作为测试样本. 这是一个典型的时间序列预报问题, 可按照第 2 节的数据组织方法组织训练样本数据和输出测试数据.

图 2a 显示了用 SVR 对上述仿真数据的回归结果, 图 2b 显示的是对 20 个测试样本点的单步预测结果. 该例回归算法所用的参数为  $\gamma = 0.01, C = 100$ , 核函数为二阶高斯核函数, 回归步长  $m = 5$ . 从图中可以看出, 预测值曲线和真实值之间是很接近的, 表明这种预测方法具有较好的预测精度.


表 1 和表 2 比较了几种在参数不同情况下的回归误差和预测误差.

从表 1 中可以看出, 不同的  $\gamma$  值对回归精度和预测精度的影响都很大, 较小的  $\gamma$  可以得到较高的


预测精度, 但同时也带来了较大的计算工作量. 在实际应用中, 可根据需要, 在保证一定预测精度的前提下选择合适的  $\gamma$ , 以减少计算工作量. 不同的核函数对回归和预测精度有一定的影响, 但影响程度不是很大. 径向基核函数和高斯核函数具有较好的总体性能, 在下面的工程数据应用验证中, 也将进一步看到这一点.

### 4 工程应用

对某炼油厂重油催化裂化装置的运行情况进行



(a) 回归结果



(b) 预测结果

图 2 对仿真数据的回归和预测结果

表 1 对仿真数据的回归误差

	回归误差/ %			
	径向基	高斯	多项式	线性
0.00	0.002	0.027	0.055	0.057
0.01	1.176	1.125	1.221	1.079
0.02	1.931	1.635	1.601	2.152

表 2 对仿真数据的预测误差

	预测误差/ %			
	径向基	高斯	多项式	线性
0.00	0.601	0.883	1.116	1.154
0.01	2.085	1.983	2.013	2.159
0.02	2.081	2.105	2.440	2.864

监测,连续记录机组的振动信号,从这些振动信号中,每隔1h提取一个振动的峰峰值A,组成一个单变量时间序列.在这个序列里,连续选取96个点作为回归训练样本,数据的组织和计算采用第2节所述的方法.图3给出了回归曲线图,此处所用的核函数为径向基核函数,  $\sigma = 0.01, C = 100, m = 5$ .从图3中可以看出,回归曲线和原始数据点是非常靠近的,说明回归效果很好.

图4a显示的是分别采用4种不同的核函数对给定样本进行回归后,再对训练样本后面24个时刻的单步预测结果.图4b是采用同样的方法所做出的






图3 某机组振动峰峰值的回归结果



(a) 单步预测



(b) 24步预测

图4 某机组振动峰峰值的预测结果

多步(24步)预测结果.4条曲线分别表示径向基核函数、高斯核函数、多项式核函数和线性核函数的预测结果,其他参数均相同,即  $\sigma = 0.01, C = 100, m = 5$ .从图4中可以看出,4种核函数对于单步预测都有较好的预测能力,而对于多步预测情况就大不相同了,径向基核函数具有较好的多步预测能力,而线性 and 多项式核函数预测的曲线和真实值相差较大,具有较大的误差,如表3所示.比较表3和图4b的结果可以看出,表3所列的多项式和线性核函数的预测误差虽然只有5.512%和6.873%,似乎其误差不是太大,但图4中的这2条预测曲线却和真实值相差甚远,已经明显看出不具有预测能力.当出现这种误差和预测曲线表示结果不太一样的情况时,这2种核函数就不具备预测的能力,表现出一种均值预测,即预测值等于训练样本的均值,而这种情况在其他的预测方法中也存在.总之,预测值不会偏离真值太多,计算出的误差也就不会太大,但已经完全无法预测出数据的变化规律来了.

表4给出了回归步长取不同值时的预测误差.从表中可以看出,不同的回归步长对预测误差有着一定的影响.可以看出,较大的  $m$  并不能带来较好的预测精度,但却增加了计算量和计算时间.在本例中,取  $m = 5$  时可以得到较好的预测精度.

表3 不同核函数对某机组振动数据的预报误差 %

核函数	径向基	高斯	多项式	线性
单步预测误差	1.769	1.850	2.172	1.976
多步预测误差	2.556	4.286	5.512	6.873

表4 不同  $m$  对回归精度的影响

$m$	24	15	10	5	4	3
预报误差/ %	1.781	1.748	1.752	1.573	1.816	2.046

训练样本的多少对于预测精度也是有影响的.为此,本文做了实验对比,结果发现,若样本数量太多,其中的偶发因素也多,特别是对于机组振动这类数据,可能的工况变化等因素会使预测精度降低.若样本数量太少,又不足以反映数据的变化规律,也得不到好的预测结果.对于周期或准周期信号,一般选取3~5个周期的信号作为训练样本比较合适.

### 5 结论

本文研究了支持向量机回归方法在机械设备状  
(下转第238页)

大变形量,实际变形量与模拟计算的变形量  $s$  的比较见表 5.可以看出,有限元模拟计算与实验得出的变形量基本相符.假设快速成型机的精度允差为 0.1 mm,对于 XI - 01 树脂,支撑的间距设计为 10 mm 时,制作可以满足成型精度的要求.

### 3 结 论

从本文的研究中,可知在光固化快速成型时,零件水平下表面支撑设计的一般规则如下.

(1) 零件水平下表面边界凸角点为变形最大处,设计的支撑应具有足够的强度,以避免在制作过程中被拉裂.

(2) 由于零件水平下表面边界比其内部区域的变形大,因此支撑应沿该表面的边界设计成轮廓形式.

(3) 由于零件水平下表面长线方向的两端变形比较大,因此长线两端设计的支撑应具有足够的强度.

(4) 在零件水平下表面边界内部区域内,可以设计成十字交叉支撑,支撑的间距与树脂材料有关,应以满足成型精度要求为设计依据,并通过有限元分析与实验来获取支撑间距的设计规则.

#### 参考文献:

- [1] 洪 军. 面向 STL 模型特征的支撑生成技术研究 [D]. 西安:西安交通大学机械工程学院,2000.
- [2] Jacobs P F. Rapid prototyping and manufacturing: fundamentals of stereolithography [M]. New York: McGraw-Hill Inc, 1992.
- [3] 武殿梁,丁玉成,洪 军. 光固化快速成型过程中零件变形的数值模拟[J]. 西安交通大学学报, 2001, 35 (3):307 ~ 311.
- [4] 洪 军,武殿梁,李涤尘. 光固化快速成型中零件制作方向多目标优化问题研究[J]. 西安交通大学学报, 2001, 35(5):506 ~ 510.

(编辑 管咏梅)

(上接第 233 页)

态预测中的应用.分别用仿真数据和工程实际数据对该方法进行了实验验证,并对影响预测精度的各参数进行了详细的分析,得出的结论如下.

(1) 选择合适的核函数及其参数,该方法的单步预测误差可达到 2%,多步预测误差可达到 5%.在本文中,对机组振动的峰峰值进行预测,选用二阶径向基核函数可以得到比较好的预测效果.这说明该方法在机械设备状态预测中可以满足实际需要,具有很好的应用前景.

(2) 对于  $\sigma$  - 不敏感损失函数,其  $\sigma$  的值对预测精度有较大的影响,在实际应用中,可根据实际问题对预测精度和计算效率的要求来选择合适的  $\sigma$  值,从而实现预测精度与计算效率的较好统一.

(3) 对训练样本数量的选取,也要有一个合适的范围.本文研究的对象是变化比较剧烈的振动信号,又是准周期信号,因此对于这种情况,一般选用 3 ~ 5 个周期的信号作为训练样本比较合适.

(4) 对  $m$  一般不宜取得过大,因为  $m$  过大并不

能提高回归精度,而只会增加计算量,因此  $m$  取 3 ~ 5 即可得到较好的预测精度.

#### 参考文献:

- [1] Cao Lijuan, Francis E H T. Financial forecasting using support vector machines [J]. Neural Computing and Application, 2001(10):184 ~ 192.
- [2] Chen B J, Chang M W, Lin C J. Load forecasting using support vector machines: a study on EUNITE competition 2001 [R]. Taiwan: Department of Computer Science and Information Engineering, Taiwan University, 2002. 1 ~ 11.
- [3] Vapnik V N. 统计学习理论的本质[M]. 张学工,译.北京:清华大学出版社,2000.
- [4] Chuang C C, Su S F. Robust support vector regression networks for function approximation with outliers [J]. IEEE Transaction on Neural Networks, 2002, 6 (13): 1 322 ~ 1 330.

(编辑 管咏梅)