

文章编号:1001-9081(2006)10-2446-04

## 一种基于 LS-SVM 的特征提取新方法及其在智能质量控制中的应用

吴德会<sup>1,2</sup>

(1. 九江学院 电子工程学院,江西 九江 332005;  
2. 合肥工业大学 仪器科学与光电工程学院,安徽 合肥 230009)  
(wdh\_hf\_mail@163.com)

**摘要:**提出一种基于最小二乘支持向量机(LS-SVM)的特征提取新方法,并将其成功应用到智能质量控制领域。首先,将线性特征提取公式表达成与 LS-SVM 回归算法中相同的形式;再遵循 SVM 方法将数据集由原输入空间映射到高维特征空间,进而使用该技巧通过线性形式实现非线性特征提取。然后,用常规控制图提取出一个含有 6 种模式、50 维特征的仿真数据集用于测试,通过 LS-SVM 特征提取后,原数据集的特征被降到了 3 维并保留了原 80% 的分类信息。最后,用 BP 分类器对特征提取后的样本进行识别,其结果优于新型 RSFM 网络直接对原始样本进行识别的效果。仿真实验结果表明了 LS-SVM 特征提取方法的可行性和有效性。

**关键词:**最小二乘支持向量机;回归算法;特征提取;控制图;模式识别

中图分类号: TP18 文献标识码:A

## Feature extraction method based on LS-SVM and its application to intelligent quality control

WU De-hui<sup>1,2</sup>

(1. Department of Electronic Engineering, Jiujiang University, Jiujiang Jiangxi 332005, China;  
2. School of Instrument Science and Opto-electronic Engineering, Hefei University of Technology, Hefei Anhui 230009, China)

**Abstract:** A new feature extraction method based on Least Squares Support Vector Machine (LS-SVM) was proposed and applied to intelligent quality control successfully. Firstly, the formulation of linear feature extraction was made in the same fashion as that in the LS-SVM linear regression algorithm. Secondly, the data was mapped from the original input space to a high dimensional one by following the usual SVM methodology so as that nonlinear feature extraction can be made from linear version of the formulation through applying the kernel trick. Thirdly, 50 dimensional simulated data sets, including six patterns, extracted by universal control chart, were used to test. As a result, characteristics of the original data sets declined to be 3 dimensional and 80% classification - messages remained. Finally, the BP-based abnormal pattern recognizer was applied to the characteristics extracted samples, and better results were obtained than that of directly recognizing original samples with RSFM methods. The simulation results indicate that this feature extraction method is not only feasible but also effective.

**Key words:** Least Squares Support Vector Machine( LS-SVM); regression algorithm; feature extraction; control chart; pattern recognition

## 0 引言

支持向量机<sup>[1,2]</sup> (Support Vector Machine, SVM) 通过结构风险最小化原理代替传统统计学的经验风险最小化原则,具有出色的学习泛化能力,它较好地解决了小样本、非线性、高维数、局部极小点等实际问题,已在模式识别<sup>[3]</sup>、序列预测<sup>[4]</sup>、函数回归<sup>[5]</sup>等领域得到了广泛的应用,相关的文献报道也较多。然而将 SVM 应用于特征提取领域的研究刚刚起步,国内报道还十分鲜见,尚有较多问题有待研究和探索。

本文在利用现有的最小二乘支持向量机<sup>[6,7]</sup> (Least Squares Support Vector Machine, LS-SVM) 回归算法的基础上提出了一种对样本数据特征进行提取的新方法,拓展了 SVM 的应用领域,并通过控制图异常模式进行特征提取的

效果验证该方法的可行性和有效性。

## 1 LS-SVM 函数回归算法

设某一待回归的输入、输出样本数据集为  $\{x_i, y_i\}$ , ( $i = 1, 2, \dots, N$ ),  $x_i \in R^n$  为  $n$  维系统输入向量,  $y_i \in R$  为系统输出。回归的目的就是经过数据学习确定一个函数解析式,使得在相同的输入情况下,解析式的输出能够在一定精度范围内与样本输出相同。

SVM 函数回归方法的基本思想是<sup>[1,2]</sup>:通过非线性变换  $\varphi(\cdot)$  将  $n$  维输入的样本从原空间映射到高维特征空间  $F$ ,并在该高维空间中构造最优线性回归函数:

$$f(x) = \omega^T \varphi(x) + b \quad (1)$$

SVM 在算法中用原空间的核函数代替高维特征空间的

点积运算,避免了复杂计算。

对于 LS-SVM,选择误差  $\xi_i$  的二范数损失函数作为风险最小化的估计问题<sup>[6]</sup>,因此可建立优化目标表示为:

$$\begin{aligned} \min \frac{1}{2} \omega^T \omega + \frac{1}{2} \gamma \sum_{i=1}^n \xi_i^2 \\ s.t. \quad y_i = \omega^T \varphi(x) + b + \xi_i, i = 1, 2, \dots, N \end{aligned} \quad (2)$$

在这里,正实数  $\gamma$  是调节量,它能够在训练误差和模型复杂度之间取一个折衷以便使所求的函数具有较好的泛化能力。LS-SVM 通过定义与标准 SVM 是不同的损失函数,将不等式约束改为等式约束。

所以其引入的 Lagrangian 函数为:

$$L(\omega, b, \xi, a) = \frac{1}{2} \omega^T \omega + \gamma \sum_{i=1}^n \xi_i^2 - \sum_{i=1}^N a_i [\omega^T \varphi(x_i) + b + \xi_i - y_i] \quad (3)$$

式中,  $a_i (i = 1, \dots, N)$  是 Lagrangian 乘子。

最优的  $a$  和  $b$  可以通过 KKT 条件<sup>[8]</sup> 获得:

$$\frac{\partial L}{\partial \omega} = 0, \frac{\partial L}{\partial b} = 0, \frac{\partial L}{\partial \xi} = 0, \frac{\partial L}{\partial a} = 0 \quad (4)$$

进一步可得:

$$\begin{cases} \omega = \sum_{i=1}^N a_i \varphi(x_i), \sum_{i=1}^N a_i = 0, a_i = \gamma \xi_i \\ \omega^T \varphi(x_i) + b + \xi_i - y_i = 0 \end{cases} \quad (5)$$

由上式消去  $\omega$  和  $\xi$ ,优化问题转化为求解如下方程:

$$\begin{vmatrix} 0 & \Theta^T \\ \Theta & \Omega + \gamma^{-1} I \end{vmatrix} \begin{vmatrix} b \\ a \end{vmatrix} = \begin{vmatrix} 0 \\ y \end{vmatrix} \quad (6)$$

其中  $y = [y_1, \dots, y_N]^T$ ,  $\Theta = [1, \dots, 1]^T$ ,  $a = [a_1, \dots, a_n]^T$ ,  $\Omega$  为一个方阵,其第  $i$  行第  $j$  列元素为  $\Omega_{ij} = \psi(x_i, x_j) = \varphi(x_i)^T \varphi(x_j)$ 。

LS-SVM 函数回归的结果为:

$$y(x) = \sum_{i=1}^N a_i \psi(x_i, x) + b \quad (7)$$

核函数  $\psi(\cdot)$  是满足 Mercer 条件<sup>[9]</sup> 的对称函数,其目的是从原始空间中抽取特征,将原始空间中的样本映射为高维特征空间中的一个向量,以解决原始空间中不能线性回归问题。核函数的形式包括: $\psi(x \cdot x_i) = x_i^T x$ (线性核); $\psi(x \cdot x_i) = (x_i^T x + 1)^k$ ( $k$  阶多项式核); $\psi(x \cdot x_i) = \exp(-\|x - x_i\|^2 / 2\sigma^2)$ (径向基核)等。

## 2 利用 LS-SVM 进行特征提取的实现

### 2.1 算法的基本思想

数据集特征提取通常是对数据集的样本重新进行维数组合(线性或非线性)时,将分布在原有特征中的分类信息集中到较少数量的特征中来,这样就能达到降低样本维数,而又尽可能多地保持原有分类信息的目的。一般认为相似的输入很有可能属于同一类,输入变量的方差越大,其所具有的聚类能力相对也越好<sup>[10]</sup>。

以线性特征提取为例,即通过对输入的样本数据集  $\{X_i\}$  的特征重新线性组合,寻找单位列向量  $\omega$  使得线性组合数列  $\omega^T X_i$  具有最大的方差。

然而,LS-SVM 引入最小二乘线性系统到支持向量机中,因此其线性回归函数  $f(X) = \omega^T X + b$  的目标是追求回归误差  $\xi$  具有最小的方差。所以如何用 LS-SVM 的样本回归误差  $\xi$  来表达样本特征组合  $\omega^T X$ ,如何用 LS-SVM 现有回归算法实现样

本数列的最大方差是 LS-SVM 实现特征提取的两个关键问题。

设某一待进行特征提取的数据集为  $\{X'_i\}, (i = 1, 2, \dots, N)$ ,  $X'_i \in R^n$  为  $n$  维空间中的一个点。我们先对该数据集进行零均值化,即  $X_i = X'_i - \bar{X}'$  记作  $\{X_i\}$ ;再对数据集  $\{X_i\}$  进行拓展,将特征空间扩展成  $n+1$  维,形成新的数据集  $\{X_i, Y_i\}$ ,其中  $X_i \in R^n$  作为输入向量,  $Y_i \in R$  为输出,本文置  $Y_i = 0 (i = 1, 2, \dots, N)$ 。

设该数据集  $\{X_i, Y_i\}$  可由方程  $f(X) = \omega^T X + b (\omega \neq 0)$ , 进行回归,则样本点的回归误差:

$$\xi_i = f(X_i) - Y_i = f(X_i) = \omega^T X_i + b \quad (8)$$

又有:

$$\begin{aligned} \bar{\xi} &= \frac{1}{N} \sum_{i=1}^N \xi_i = \frac{1}{N} \sum_{i=1}^N (\omega^T X_i + b) \\ &= \frac{\omega^T}{N} \sum_{i=1}^N X_i + b = \omega^T \bar{X} + b = b \end{aligned} \quad (9)$$

其方差为:

$$\begin{aligned} D(\xi) &= \frac{1}{N} \sum_{i=1}^N (\xi_i - \bar{\xi})^2 = \frac{1}{N} \sum_{i=1}^N (\omega^T X_i)^2 \\ &= D(\omega^T X) \end{aligned} \quad (10)$$

由此,我们通过对数据集的特殊拓展可使回归误差  $\xi_i$  与线性特征组合  $\omega^T X_i$  具有相同的方差表达形式,将两者统一起来。

由于 LS-SVM 的回归目标( $\min D(\xi)$ ) 与特征提取的目标( $\max D(\omega^T X)$ ) 相矛盾,因此必须在现有 LS-SVM 回归算法基础上改进,实现新功能。

我们采用的方法是:定义新的调节量  $\chi = -\gamma$ ,并用  $\chi$  替代式(2) 中的原有调节量  $\gamma$ ,由于  $\chi$  为负实数,则 SVM 的优化目标自动转换为  $\max D(\xi)$ ,解决了第二个关键问题。

我们构造的新数据集  $\{X_i, Y_i\}$  具有特殊性,因此可对 LS-SVM 回归算法进一步简化。由  $Y_i = 0$ ,则式(6) 可简化为:

$$|\Omega + \chi^{-1} I| a = 0 \quad (11)$$

若  $a = 0$ ,则回归参数  $\omega = 0$ ,与特征提取的实际意义相违背,应求  $a$  的非零解。

定义正实数  $\lambda = -\chi^{-1}$ ,式(11) 可转换为以下对称矩阵特征值问题:

$$\Omega a = \lambda a \quad (12)$$

求解上式矩阵方程<sup>[11]</sup>, $\lambda_k$  为从大到小排列的  $N$  个特征值,  $a_k$  为  $\lambda_k$  对应的特征向量。

从式(5) 可得线性特征组合向量:

$$\omega_k^T = \sum_{i=1}^N a_{ki} X_i^T \quad (13)$$

则最佳的分类特征为:

$$z_i(X) = \omega_1^T X = \sum_{i=1}^N a_{1i} X_i^T X \quad (14)$$

式中,  $a_1$  对应于最大特征值  $\lambda_1$  的特征向量。因此,若依次用  $\lambda_k (k = 1, 2, \dots, m)$  对应的特征向量  $a_k$  生成新的特征,则可将原特征从  $n$  维降低到  $m (m < n)$  维,实现特征的线性优化。

对于非线性特征提取,可遵循 SVM 方法,将数据集  $\{X_i\}$  从原始特征空间映射到高维特征空间  $\{\varphi(X_i)\}$ ,并在高维空间中寻找使得组合数列  $\omega^T \varphi(X_i)$  具有最大的方差列向量  $\omega$ 。

实际计算时使用该技巧,用原空间的核函数代替高维特征空间的点积运算,非线性特征提取的最佳分类特征表达为:

$$z_i(X) = \omega_1^T \varphi(X) = \sum_{i=1}^N a_{ii} \psi(X_i, X) \quad (15)$$

## 2.2 LS-SVM 实现特征提取具体步骤

根据 LS-SVM 实现特征提取的原理, 对数据集  $\{X'_i\}$ , ( $i = 1, 2, \dots, N$ ),  $X'_i \in R^n$  进行特征提取的具体步骤如下:

步骤 1: 数据集零均值化。

对该数据集  $\{X'_i\}$  中每个列向量(样本)  $X'_i$  作变换:  $X_i = X'_i - \bar{X}'$ , 其中,  $\bar{X}'$  为  $X'$  的均值向量, 新数据集记作  $\{X_i\}$ 。若将  $X'_i \in R^n$  看作  $n$  维空间中的一个点, 零均值化的目的就是将数据集的中心与坐标原点重合。

步骤 2: 数据集特征拓展。

将零均值的数据集  $\{X_i\}$  拓展为  $\{X_i, Y_i\}$ , 新增加的 1 维特征  $Y_i = 0$  作为输出, 使原特征空间由  $n$  维扩展成  $n + 1$  维。

步骤 3: 用简化后的 LS-SVM 算法对数据集  $\{X_i, Y_i\}$  进行回归。

先构造协方差矩阵  $\Omega$ , 其第  $i$  行第  $j$  列元素为  $\Omega_{ij} = \psi(x_i, x_j)/(N \times n) = \varphi(x_i)^T \varphi(x_j)/(N \times n)$ ; 解式(12)的特征值问题, 从大到小求取特征值  $\lambda_k$  ( $k = 1, 2, \dots, N$ ) 及其对应的特征向量  $a_k$ 。

步骤 4: 对数据集进行特征重组, 实现特征提取。

对于线性特征提取, 可用式(13)直接求取特征组合向量  $\omega$  对数据集特征进行线性重组。非线性特征提取, 由于特征从原空间映射到高维空间, 不能直接求取相应的特征组合向量  $\omega$ , 可由式(15)的核运算实现特征提取。

## 3 LS-SVM 提取控制图特征的应用及效果

控制图技术是统计过程质量控制最常采用的手段, 通常情况下将控制图分成 6 种基本的模式<sup>[12]</sup>, 即正常型、上升趋势型、下降趋势型、向上阶跃型、向下阶跃型和周期型。控制图识别就是从控制图中连续提取 20 个~50 个工序数据作为一个样本, 再用神经网络对该样本所具有趋势进行识别, 从而判断加工过程是否正常, 揭示加工过程潜在质量问题<sup>[13]</sup>。

由于输入样本维数较高(20~50), 同时各维数据自身就含有高斯噪声, 因此识别速度和识别率均不高。若能对工序数据进行预处理, 提取分类特征, 则不仅可有效地降低其维数, 提高识别速度, 同时还能突出其特征信息, 降低错误率。所以本文通过工序数据特征提取的仿真实验来检验所提出的特征提取方法的有效性。

采用 Monte Carlo 模拟法<sup>[14]</sup>来获取工序仿真数据, 即:

$$y(t) = u + x(t) + d(t), t = 1, 2, \dots, T \quad (16)$$

式中:  $y(t)$  为工序质量参数值;  $u$  为受控条件下的质量参数均值;  $x(t) \sim N(0, \sigma)$  为质量参数的随机高斯分布偏差,  $\sigma$  为分布的标准方差;  $d(t)$  为异常干扰值。为了讨论方便, 不失一般性, 取  $u = 0, \sigma = 1, T = 50$ , 即每个样本含 50 维特征。

对于正常模式  $d(t) = 0$ ;

对于趋势型模式  $d(t) = \pm d \cdot t$ , 其中:  $+$ 、 $-$  分别代表上升和下降趋势, 参数  $d$  为倾斜度, 本文取  $d = 0.2$ 。

对于阶跃型模式  $d(t) = \pm v \cdot s$ , 其中  $v$  表示阶跃位置, 在阶跃前取值为 0, 阶跃后为 1;  $s$  为阶跃幅度, 本文设定  $v = 25$ ,  $s = 2$  或 3。

对于周期型模式:  $d(t) = a \cdot \sin(2\pi t/T)$ , 式中  $T$  为变化周期,  $a$  为幅度。本文取  $T = 50, a = 2$  或 3。

相应的控制图模式如图 1 所示, 其中纵坐标为质量特征值, 横坐标为样本特征序号。

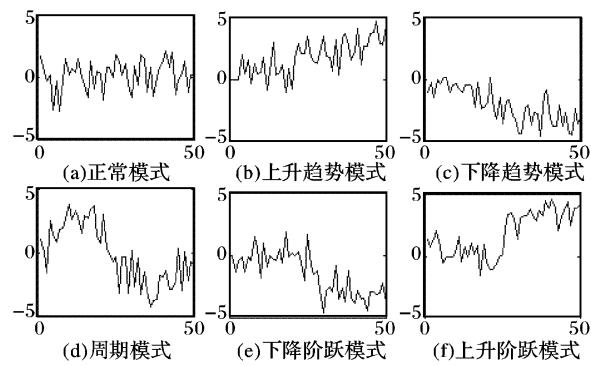


图 1 质量控制图常见模式

从每种基本模式中随机生成 10 个样本, 构成数据集  $S_1$ , 按本文的 LS-SVM 特征提取步骤, 对该数据集处理求取特征组合向量  $\omega_k$ , 其中, 核函数  $\psi(x \cdot x_i)$  取  $x_i^T x$ (线性核)。

求解式(12)的矩阵方程, 得其特征值  $\lambda_1 = 3.0655, \lambda_2 = 0.5863, \lambda_3 = 0.0786, \lambda_4 = 0.0451, \dots$  及其对应的特征向量  $a_k$ , 并由式(13)计算特征组合向量  $\omega_k$  ( $k = 1, 2, \dots, N$ )。由此可见, 经过向量  $\omega_k$  特征重组后, 原特征空间(50 维)上的大多数分类信息集中到了前两维特征上。

再生成 150 个测试样本(每种模式生成 25 个)进行特征提取实验, 验证效果。图 2 是原样本特征分布和基于 LS-SVM 方法重组后的特征分布效果对比图。因为原始过程样本特征共有 50 维, 限于版面原因不可能将所有特征向量的投影图画出, 本文均匀抽取第 1 维、第 25 维和第 50 维特征进行投影(如图 2(a)所示), 其余各维投影相似。

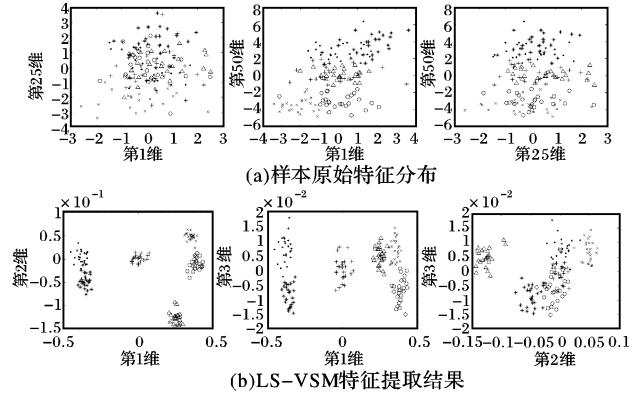


图 2 基于 LS-SVM 方法特征提取过程样本前后效果对比

若用前两个组合向量  $\omega_1, \omega_2$  对原特征进行重组, 构成 2 维子特征空间  $\hat{S}$ , 可保证 78.5% 的识别信息不丢失, 6 类测试样本在该子空间的投影如图 2(b) 左图所示。明显, 在该子图中所有测试样本可清晰地分为 4 个大类, 即受控类、周期类、上升类和下降类, 而向上阶跃与上升趋势、向下阶跃与下降趋势样本之间有少量重叠。因而我们又引入第 3 个组合特征  $\omega_3^T X$ , 使识别信息增加到 80.2%。第 1 ~ 第 3 维及第 2 ~ 第 3 维的特征向量投影分别如图 2(b) 中图及右图所示, 在第 2 ~ 第 3 维投影图中向上阶跃与上升趋势、向下阶跃与下降趋势样本之间无发生重叠现象。

显而易见, 通过本文提出的 LS-SVM 特征提取方法不但降低了样本维数(从 50 维到 3 维), 而且突出了分类特征。混杂在一起的原始特征在新的特征空间中分布有明显的改善, 5 种异常模式样本的特征在新特征空间中远离正常模式聚类中心, 且彼此相对分散无重叠。

为验证本文的 LS-SVM 特征提取方法对后续识别的作用

用,我们再利用 BP 神经网络对特征提取前后的样本进行训练和识别<sup>[15]</sup>,并将其与新型神经网络 RSFM 进行控制图异常模式识别的结果<sup>[16]</sup>进行对比,其结果如表 1 所示。

所用 BP 网络输入层节点数对应样本的特征维数(特征提取前为 50 维,提取后为 3 维),中间层节点数取 6,输出层节点数取 6,对应于控制图的 6 种基本模式,分别用输出 1 和 -1 表示是否为该类型的样本。学习因子  $a = 0.2$ ,学习允差  $e = 0$ 。

为便于进行识别速度和效果的对比,本文采用与文献[16]中 RSFM 方法的相同条件对 BP 网络进行实验,训练样本均取  $2560 \times 6$  组,测试样本取  $10000 \times 6$  组,训练迭代次数  $t$  同样取 1000。从表 1 中可见,在相同的条件下,直接用 BP 网络进行异常模式识别除训练时间较短外,错误率、误识率和漏识率等其他效果均不如 RSFM 网络。

再将 BP 网络方法的训练样本数降为  $40 \times 6$  组后进行实验。由于减少了训练样本,训练过程的耗时明显减少(测试过程耗时不变),但其测试错误率高达 12.5%。

在同样的条件下,加入 LS-SVM 特征提取环节后再进行实验。通过两次实验结果对比,不难发现:1)由于 LS-SVM 特征提取方法最后通过矩阵乘法实现特征重组(式 14 所示),因此其耗时的增加量甚微(60 000 个测试样本提取时间仅为 0.1s),几乎可忽略。2)由于降低了特征维数(从 50 维到 3 维),减小了 BP 网络结构的复杂度,因此在相同样本数量下训练、测试时间可降低 50% 以上。3)LS-SVM 特征提取方法突出了样本特征,减小了其他各维的干扰,明显降低 BP 方法识别的错误率(从 12.5% 降低到 1.4%),特别是误识率和漏识率仅为 0.1%,甚至优于新型 RSFM 网络直接进行异常模式识别的效果。

表 1 几种控制图异常模式识别方法的结果对比(时间单位:s)

方法	训练过程				测试过程				结果					
	训练样本	特征提取	训练耗时	总耗时	测试样本	特征提取	识别耗时	总耗时	错误数	错误率	误识数	误识率	漏识数	漏识率
BP 网络识别	15 360	/	902	902	60 000	/	3.67	3.67	5 118	8.5%	356	3.6%	722	1.5%
	240	/	26.2	26.2	60 000	/	3.72	3.72	7 472	12.5%	585	5.9%	1053	2.1%
RSFM 网络识别	15 360	/	2 580	2 580	60 000	/	11	11	1 784	3.0%	130	1.3%	552	1.1%
LS-SVM 特征提取 + BP 网络识别	240	0.0	11.2	11.2	60 000	0.101	2.28	2.38	837	1.4%	8	0.1%	44	0.1%

注:样本被识别为其他类型,称为错误;正常型样本被识别为异常,称为误识;异常型的样本被识别为正常,称为漏识;

## 4 结语

本文在利用现有的 LS-SVM 回归算法的基础上进行改进,成功地实现了对样本数据特征的提取,拓展了 SVM 的应用领域。就其在质量控制图异常模式识别的应用来看,该方法成功地将样本的特征从 50 维降到了 3 维,保留了 80% 的分类信息;同时还使原本交错在一起的 6 种基本模式样本在新的特征空间中彼此相对分散无重叠。最后,通过识别结果的对比,经 LS-SVM 特征提取后可有效提高识别速度和识别率,即使使用普通的 BP 神经网络其识别速度和识别率也明显优于新型 RSFM 网络对未经过特征提取样本的识别效果。实验结果表明了该 LS-SVM 特征提取方法的可行性和有效性。

## 参考文献:

- [1] CORTES C, VAPNIK VN. Support-vector networks[J]. Machine Learning, 1995, 20(3): 273–297.
- [2] VAPNIK VN. An overview of statistical learning theory[J]. IEEE Trans on Neural Networks, 1999, 10(5): 988–999.
- [3] BURGES JCC. A Tutorial on Support Vector Machine for Pattern Recognition[J]. Data Mining and Knowledge Discovery, 1998, 2(2): 121–167.
- [4] MUKHERJEE S, OSUNA E, GIROSI F. Nonlinear Prediction of Chaotic Time Series Using a Support Vector Machine[A]. Proc of IEEE NNNSP97[C]. 1997. 24–26.
- [5] GAO JB, GUN SR, HARRIS CJ. Mean field method for the support vector machine regression[J]. Neuro computing, 2003, 50: 391–405.
- [6] SUYKENS JAK, LUKAS L, VANDEWALLE J. Sparse approximation using least squares support vector machine [A]. IEEE Int Symposium on Circuits and Systems[C]. Geneva, 2000. II: 757–760.
- [7] 叶美盈, 汪晓东, 张浩然. 基于在线最小二乘支持向量机回归的混沌时间序列预测[J]. 物理学报, 2005, 54(6): 2568–2573.
- [8] LECUN YA, JACKEL LD, BOTTOU L, et al. Learning algorithms for classification: A comparison on hand written digit recognition [A]. Neural Networks: The Statistical Mechanics Perspective[C]. Singapore, 1995. 261–276.
- [9] VAPNIK VN. The nature of statistical learning theory[M]. New-York: Springer-Verlag, 1999.
- [10] WOLD S, ESBENSEN K, GELASI P. Principle Components Analysis[J]. Chemometrics and Intelligent Laboratory Systems, 1987, 12(2): 37–46.
- [11] SLEIJEPENG LG, VANDER HA. A Jacobi-Davidson iteration method for linear eigen value problem[J]. SIAM J Matrix Anal Appl, 1996, 17: 401–425.
- [12] GRANT EL, LEAVENWORTH RS. Statistical quality control[M]. New York: McGraw-Hill Book Company, 1998.
- [13] PERRY MB, SPOERRE JK, VELASCO T. Control chart pattern recognition using back propagation artificial neural networks[J]. International Journal of Production Research, 2001, 39(15): 3399–3418.
- [14] HWARNG HB, HUBELE NF. Back-propagation pattern recognizers for X-bar control charts[J]. Computers & Industrial Engineering, 1993, 24: 219–235.
- [15] GUH RS, HSIEH YC. A neural network based model for abnormal pattern recognition of control charts[J]. Computer & Industrial Engineering, 1999, 36(1): 97–108.
- [16] 乐清洪, 朱名铨, 王润孝. 一种新型的神经网络及其在智能质量诊断分析中的应用[J]. 机械科学与技术, 2005, 24(1): 30–34.