

基于声发射的机械密封状态识别

蒋恩超, 傅攀, 张思聪, 李扬

(西南交通大学 机械工程学院, 成都 610031)

摘要: 为适应声发射信号频率覆盖范围广且频率高的特点, 该文使用在 S 变换的基础优化而来的广义 S 变换, 通过对广义 S 变换的时频分辨率特性进行分析, 选取广义 S 变换的参数 $\lambda = 2\ 210$, $p = 0.151$, 使得其在 20~1 000 kHz 的频率范围内依然拥有 1~2 kHz 的频率分辨率; 随后在广义 S 变换分析的基础上对机械密封端面的声发射信号进行滤波和特征提取, 并使用 GA 优化的 TWSVM 对密封的磨损状况进行识别, 准确率达到 100%, 高于 GA-SVM 的识别率; 说明相比传统的 SVM 在 TWSVM 在模式识别上更具有优越性。

关键词: 声发射; 广义 S 变换; 模式识别; 孪生支持向量机

State Recognition of Mechanical Seal Based on AE

Jiang Enchao, Fu Pan, Zhang Sicong, Li Yang

(School of Mechanical Engineering, Southwest Jiaotong University, Chengdu 610031, China)

Abstract: AE signal is wide and high range in frequency. In this case this paper used generalized S transform to analysis AE signal in frequency domain and choose the parameter $\lambda = 2\ 210$, $p = 0.151$ made the generalized S transform has a frequency resolution ranged 1~2 kHz in the frequency ranged 20~1 000 kHz. and then this paper filter the AE signal and extract its characteristics based on the generalized S transform. and at last this paper diagnosis the condition of Mechanical seal by the method of GA-TWSVM and get a 100% accuracy rate which is high than the accuracy rate of GA-SVM. the result shows TWSVM is better than SVM in pattern recognition.

Abstract: AE; generalized S transform; pattern recognition; TWSVM

0 引言

声发射现象最早在 19 世纪 50 年代德国人凯赛尔在对钢、铜、铝等材料进行拉伸实验时被观察到^[1]。这是一种由于材料本身发生形变或者内部缺陷的动态过程中所产生的瞬时弹性波。当能量聚集到一定程度时, 材料就会发生塑性形变、开裂、断裂、脱落等缺陷, 当缺陷发生时应变能通过声发射信号传递出来, 其频率覆盖范围极高且高, 往往达到几十甚至几百千赫兹。研究表明^[2], 大多数金属非金属材料在发生形变或者破坏时都会伴随着声发射信号。

金刚石涂层机械密封端面的磨损过程中, 金刚石薄膜表面的晶粒在剪切力的作用下会产生一定量的断裂和磨屑。端面涂层的状态, 如涂层平整度, 涂层粗糙度, 裂纹数量、涂层脱落面积等都会因此发生变化, 这种变化会导致摩擦状态的改变^[3], 所发出的声发射信号也会有所不同。如果利用现代信号处理技术对声发射信号进行有效的分析, 过

滤采集到的声发射信号的噪声, 提取有效的声发射信号, 就可以长期实时的监测机械密封端面的磨损状态, 判断机械密封端面在运行过程中的磨损的严重程度, 对密封磨损所造成的危害进行提前预警。广义 S 变换是在美国地球物理学家 Stockwell R G 提出的 S 变换的基础上改进而来的^[4]。它继承了小波变换和短时傅里叶变换的优点, 同时具有更好的多分辨率特征, 其时频分辨率和频率的大小有关, 能够很好的适应声发射信号频率覆盖范围广的特点。

支持向量机是模式识别中常用的一种手段。2006 年, Mangasarian^[5]等人对近似支持向量机进行了改进, 提出了一种基于广义特征值的近似支持向量机 (简称 GEPSVM)。相比传统的支持向量机, GEPSVM 使用等式约束对凸优化问题进行求解, 使得计算求解的过程更加简单, 且算法的运行速度也更快。2007 年, Jayadeva 等^[6]在 GEPSVM 的基础上进一步提出了孪生支持向量机 (TWSVM) 将 GEPSVM 中的两个广义特征问题转化为两个规模更小的二次规划问题, 进一步加快了算法的训练速度, 使得其训练时间相比传统的支持向量机减少了 3/4。

本文在广义 S 变换分析的基础上对金刚石涂层机械密封端面的磨损过程中采集的声发射信号进行滤波和特征提取, 同时为了寻找孪生支持向量机的最优参数, 使用遗传算法优化的孪生支持向量机对密封的摩擦状态进行了识别, 达到了较好的识别效果。

收稿日期: 2018-01-08; **修回日期:** 2018-02-28。

基金项目: 中央高校基本科研业务费专项资金资助 (2682016CX033)。

作者简介: 蒋恩超 (1993-), 男, 浙江台州人, 硕士研究生, 主要从事智能化状态监测和故障诊断方向的研究。

傅攀 (1961-), 男, 河南人, 教授, 主要从事先进测控技术与系统方向的研究。

1 广义 S 变换原理

短时傅里叶变换是在傅里叶变换的基础上，在时域上对时间信号 $f(t) \in L^2(R)$ 进行加窗处理。用 $w(t)$ 表示窗函数，则短时傅里叶变换可以表示为：

$$W(f) = \int_{-\infty}^{+\infty} w(t) f(t) e^{-i2\pi ft} dt \quad (1)$$

如果令所加的窗为一个如式 (2) 所示的平移 τ 后的高斯窗：

$$w(t) = \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(t-\tau)^2}{2\sigma^2}} \quad (2)$$

则可以将式 (1) 改写为：

$$W(f, \tau) = \int_{-\infty}^{+\infty} \frac{1}{\sigma \sqrt{2\pi}} e^{-\frac{(t-\tau)^2}{2\sigma^2}} h(t) e^{-i2\pi ft} dt \quad (3)$$

如果令 $\sigma = \frac{1}{|f|}$ 即可到的到时间信号 $h(t)$ 的 S 变换。

因此一个时间信号 $h(t) \in L^2(R)$ ，其一维连续 S 波变换的定义为：

$$ST(\tau, f) = \int_{-\infty}^{+\infty} h(t) \frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)f}{|f|}} e^{-2\pi fjt} dt \quad (4)$$

其逆变换定义为：

$$h(t) = \int_{-\infty}^{+\infty} \left[\int_{-\infty}^{+\infty} ST(\tau, f) d\tau \right] e^{(2\pi fjt)} df \quad (5)$$

其中： $\frac{|f|}{\sqrt{2\pi}} e^{-\frac{(t-\tau)f}{|f|}}$ 为一个高斯窗函数， τ 为控制高斯窗

函数在时间轴上位置的位移参数， f 为频率。可以看出，S 变换不同于短时傅里叶变换之处在于 S 变换的窗函数的高度和宽度会随着频率的变化而发生变化，频率越高，窗函数的高度越高，宽度越小，这样就克服了短时傅里叶变换窗口高度和宽度固定的缺陷。

虽然 S 变换的分辨率会随着频率改变，具有较好的频率分辨率，但是当频率较高时，其频率分辨率依然较低。为了提高 S 变换在不同频率处的分辨率的适应能力使其能够根据信号的实际频率分布的特点和实际分析过程中的侧重点灵活的调节高斯窗函数随频率 f 变化的趋势。广义 S 变换在 S 变换中引入了两个参数 λ 和 p ，我们可以将其表达为：

$$GST(\tau, f) = \int_{-\infty}^{+\infty} \frac{\lambda |f|^p}{\sqrt{2\pi}} e^{-\frac{\lambda(t-\tau)^p}{|f|}} h(t) e^{-2\pi fjt} dt \quad (6)$$

2 GA-TWSVM

2.1 孪生支持向量机 (TWSVM)

不同于传统的支持向量机通过一个最大分类间隔器确定一个最佳分类平面来到对样本进行分类，孪生向量机是寻找两个非平行的超平面对样本进行分类。其目的就是在空间 R^n 中寻找两个非平行的超平面，使得所有同一类的样本离其中一个超平面的距离尽可能地近，同时离另外一个超平面尽可能地远^[7]。

假设在 R^n 空间中有如下训练样本：

$$T_{-1} = \{x_1, x_2, \dots, x_N\}$$

$$T_1 = \{x_1, x_2, \dots, x_M\} \quad (7)$$

其中： x 是一个 n 维的特征向量，样本集 T_{-1} 和 T_1 分别属于 -1 和 1 两个类别。可以分别用一个矩阵 $A(n \times N)$ 和 $B(n \times M)$ 来表示这两个样本集。

类似于支持向量机，由于一般情况下样本的特征都是线性不可分的，对于这种情况首先要对分类样本使用核函数的方法，利用核函数建立样本和从低维空间到高维空间的映射关系，将样本映射到高维空间，并在高维空间寻找分类平面。

设所求的两个超平面的表达式为：

$$K(x^T, C^T)w_1 + b_1 = 0$$

$$K(x^T, C^T)w_2 + b_2 = 0 \quad (8)$$

其中： $C = [A^T, B^T]^T$ ，则该问题可以用数学公式表达为：

分类平面一：

$$\begin{aligned} \min_{w_1, b_1, \xi} & \frac{1}{2} \|K(A, C^T)w_1 + e_1 b_1\|^2 + c_1 e_2^T \xi \\ s. t. & -(K(B, C^T)w_1 + e_2 b_1) + \xi \geq e_2 \xi \geq 0 \end{aligned} \quad (9)$$

分类平面二：

$$\begin{aligned} \min_{w_2, b_2, \eta} & \frac{1}{2} \|K(B, C^T)w_2 + e_2 b_2\|^2 + c_2 e_1^T \eta \\ s. t. & -(K(A, C^T)w_2 + e_1 b_2) + \eta \geq e_2 \eta \geq 0 \end{aligned} \quad (10)$$

其中： e_1, e_2 为单位对角矩阵。

以式 (9) 为例，该问题可以通过拉格朗日方法求解，引入拉格朗日函数：

$$\begin{aligned} L(w_1, b_1, \alpha, \beta, \xi) &= \frac{1}{2} (K(A^T, C^T)w_1 + e_1 b_1)^T \\ & (K(A^T, C^T)w_1 + e_1 b_1) + c_1 e_2^T \xi - \\ & \alpha^T (- (K(B, C^T)w_1 + e_2 b_1) + \xi - e_2) - \beta^T \xi \end{aligned} \quad (11)$$

由 KKT 条件可以得到：

$$K(A^T, C^T)(K(A^T, C^T)w_1 + e_1 b_1) + K(B^T, C^T)\alpha = 0$$

$$e_1^T (K(A^T, C^T)w_1 + e_1 b_1) + e_2^T \alpha = 0$$

$$c_1 e_2 - \alpha - \beta = 0 \quad (12)$$

定义 $H = [K(A, C^T)e_1]$ ， $G = [K(B, C^T)e_2]$ ， $u = [w_1 \ b_1]^T$

综合上式则可以求得 $u = -(H^T H)^{-1} G^T \alpha$ ，同时可以得到该问题的对偶问题为：

$$\begin{aligned} \min_{\alpha} & \frac{1}{2} \alpha^T G (H^T H)^{-1} G^T \alpha - e_2^T \alpha \\ s. t. & 0 \leq \alpha \leq c_1 \end{aligned} \quad (13)$$

同理：

定义 $P = [K(A, C^T)e_1]$ ， $Q = [K(B, C^T)e_2]$ ， $v = [w_2 \ b_2]^T$

可以求得 $v = -(Q^T Q)^{-1} P^T \gamma$ ，同时也可以得到分类平面的对偶问题为

$$\begin{aligned} \min_{\gamma} & \frac{1}{2} \gamma^T G (H^T H)^{-1} G^T \gamma - e_1^T \gamma \\ s. t. & 0 \leq \gamma \leq c_1 \end{aligned} \quad (14)$$

在 u 和 v 得到确定后我们就可以由此求出 TWSVN 的两个分类平面的方程。

2.2 遗传算法优化

虽然孪生支持向量机简化了传统支持向量机的约束条件提高了计算速度, 但是不同于传统支持向量机只需要确定一个分类平面对样本进行分类, 孪生支持向量机需要确定两个分类平面。因此相比传统的支持向量机, 孪生支持向量机需要确定 3 个参数, 其中包括两个分类平面的惩罚因子 c_1, c_2 和核函数的参数 g , 如果采用简单的网格搜索算法, 则相对传统的支持向量机, 孪生支持向量机需要多一层网格进行搜索, 降低了搜索的速度。因此本文在孪生支持向量机的参数选择过程中选用了遗传算法来对孪生支持向量机参数进行寻优提出了遗传算法优化的孪生支持向量机 (GA_TWSVM)。其流程如下所示:

Step1: 采用二进制编码, 对惩罚参数 c_1, c_2 和核函数参数 g 进行编码。

Step2: 适应度函数设置为 CV 意义下的训练预测的准确率, 并设置最低准确率要求为 50%。

Step3: 随机产生初始种群。设置当前迭代代数。

Step4: 输入训练样本, 计算种群个体的适应度, 即 CV 意义下 TWSVM 的准确率。如果当前迭代次数大于最高迭代次数, 则终止操作。

Step5: 判断个体的准确率是否达到适应度要求, 如果达到要求, 则对该个体进行解码。如果没达到要求, 则对种群进行选择, 交叉, 变异操作, 返回步骤 4。

Step6: 利用解码得到的最佳参数建立 TWSVM 模型。

Step7: 利用该模型进行预测分类^[8-9]。

3 实验分析

本实验利用了图 1 所示的试验台采集了金刚石涂层机械密封的干磨实验数据。



图 1 实验平台

由于声发射信号频率范围广, 往往达到几十甚至几百千赫兹。根据奈奎斯特采样定理, 采样频率至少达到信号频率的两倍以上才能准确还原原始信号^[10], 因此在采集声发射信号时往往要求较高的采样频率, 本实验的采样频率为 2 MHz, 共采集了 11 组密封的声发射数据, 在这 11 组数据中, 1 组为密封的全寿命数据; 4 组时长为 10 min 的正常密封在运行过程中的声发射信号; 6 组时长为 10 min 的磨损较为严重的密封的声发射信号。为了对密封的磨损状态进行识别, 首先需要对采集的声发射信号进行处理, 然

后提取声发射信号的特征, 最后利用特征矩阵对密封的摩擦状态进行识别。

3.1 基于广义 S 变换分析的声发射信号去噪

通过图 2 可以发现典型的声发射信号是由一个冲击引起的一系列逐渐衰减的波, 在时域上呈横置的三角形形状^[11]。图 3 为所采集的信号样本, 通过对比可以发现所采集的声发射信号在噪声的干扰下已经失去了典型的声发射信号特征, 这将直接影响声发射信号的特征提取效果。

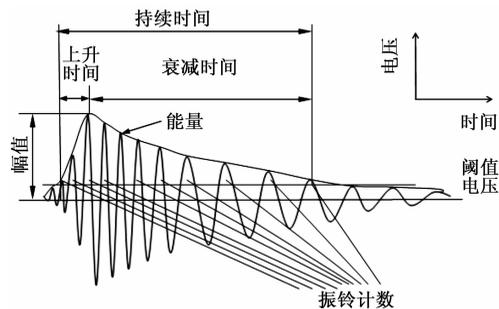


图 2 典型声发射信号

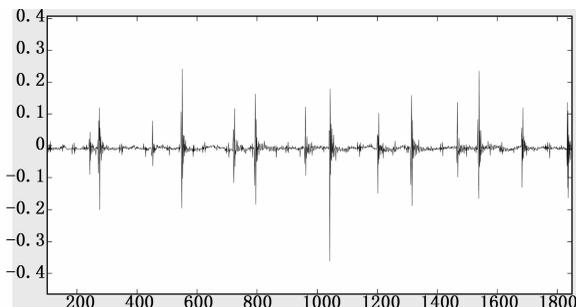


图 3 声发射信号样本

为了验证在机械密封运行过程中有效信号的主要频域分布范围。平均截取密封全寿命实验过程中的声发射数据使用广义 S 变换和 S 变换进行分析。为了选取合适的广义 S 变换的参数, 对广义 S 变换的频率分辨率进行分析。

由式 (6) 可以求得广义 S 窗函数的频窗中心 f^* 、频窗半径 B 分别为:

$$\omega^* = \frac{1}{E_f} \int_{-\infty}^{+\infty} f |X(f)|^2 df = f$$

$$B = \sqrt{\frac{1}{E} \int_{-\infty}^{+\infty} (f - f^*)^2 |X(f)|^2 df} = \frac{\lambda f^p}{2\sqrt{2}\pi}$$

为了达到较好的高频分辨率, 要求广义 S 变换在 1 000 kHz 处具有 2 kHz 的频率分辨率。在 20 kHz 处具有 1 kHz 的分辨率, 因此选取广义 S 变换的参数 $\lambda = 2\ 210$, $p = 0.151$ 。此时用广义 S 变换对声发射信号进行时频分析, 其分析结果如图 4 所示。

将图 4 和 5 进行对比, 广义 S 变换在整个高频频域内都具有较好的频率分辨率, 而 S 变换在高频部分的分辨率较低, 在稍高一点的频段就失去了分辨频率细节的能力, 因此并不适用于频率覆盖范围较广的声发射信号的分析中。从图 4 中可以得出 3 点结论: 1) 在机械密封的全寿命运行

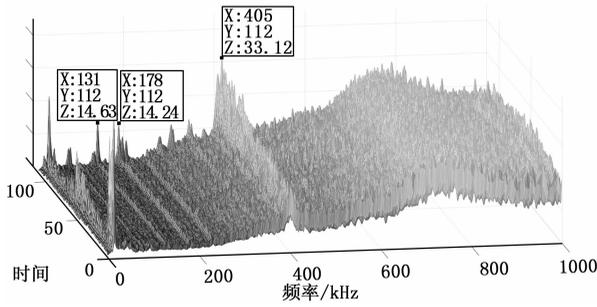


图 4 广义 S 变换结果

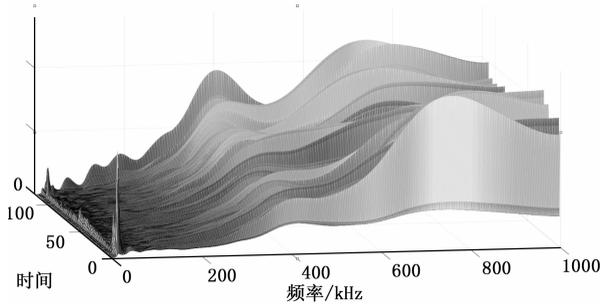


图 5 S 变换结果

过程中，声发射信号的主要能量集中在 200 kHz 以上的高频范围内，405 kHz 频点的幅值随着密封的运行稳步上升，和密封的整个全寿命的失效过程很好地吻合；2) 在低频范围内也有一部分能量较高的凸峰，但是由于这些突发具有随机性和突发性，因此可以认为低频范围内能量较高的凸峰部分为环境中的噪声；3) 在 100~200 kHz 的范围内，虽然该部分的信号能量分布较小，但是在 131 kHz 和 178 kHz 频率的幅值随着密封运行也稳步上升，尤其在密封失效的最后阶段，该两个频点的幅值上升较为明显。

综上所述，使用充零法^[12]对采集的 AE 信号进行去噪处理，具体操作为将频率范围 0~100 kHz 的广义 S 变换的幅值置零并进行广义 S 逆变换。图 6 为去噪前后声发射信号的波形的对比，从中可以发现滤波还原了的声发射信号的时域波形，使其更加接近声发射信号的实际特征。

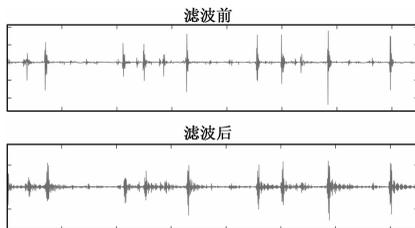


图 6 滤波前后的声发射信号

3.2 声发射信号的特征提取

在图 2 中我们可以看到，声发射信号具有其特有的波形特征。因此在一次声发射事件发生的时间长度内对声发射信号的时域特征进行统计来获得声发射信号的特征参数是一种原始但普遍有效的方法。一次声发射事件由多个振铃事件组成，其中幅值，振铃计数，上升时间，能量等参

数是较为常见且有效的特征参数，他们的定义在图 2 中已经给出。

声发射信号的某些特征参数的定义中，比如声发射信号的事件次数，振铃计数等的定义中均出现了阈值这个概念。阈值的设置是为了避免传感器本身的底噪对声发射信号特征参数的计算产生影响，声发射信号的事件次数，振铃计数等都受到受到阈值的影响，因此选取合适的阈值才能真实反映声发射信号的特征。

本文根据拉依达准则对阈值进行设置^[13]。假设传感器的底噪 $s(t)$ 为高斯白噪声，即 $s(t)$ 服从正态分布 $s(t) \sim N(\mu, \sigma^2)$ ，则根据拉依达准则 $s(t)$ 的幅值大小分布在 $[\mu - 3\sigma, \mu + 3\sigma]$ 的概率 p 为：

$$p(s(t) \in [\mu - 3\sigma, \mu + 3\sigma]) = 0.9974$$

可以认为 $s(t)$ 的幅值几乎全部集中在 $(\mu - 3\sigma, \mu + 3\sigma)$ 区间内，超出这个范围的可能性仅占不到 0.3%，因此对于幅值超过 $(\mu - 3\sigma, \mu + 3\sigma)$ 区间范围的信号都可以认为是密封端面所产生的声发射信号。

为了计算信号底噪的均值 μ 和方差 σ ，将传感器空置，采集一段此时传感器的数据来作为传感器的底噪。经过计算设置阈值为 0.0196，以此来计算声发射的波形特征。其中主要计算了单位时间内声发射信号的事件计数和振铃计数。

除此之外本实验还计算了峰态系数、偏态系数、峰值系数等 8 种常见的时域特征，并选取了广义 S 变换 131 kHz、178 kHz 和 405 kHz 共 3 个频率点处的幅值作为特征。

3.3 GA-TWSVM 模式识别

本实验共采集了 4 组正常密封在运行过程中的声发射信号和 6 组磨损较为严重的密封的声发射信号各 10min。为了增加样本的数量，每分钟截取两万个样本点，将每组十分钟的数据分为十组，共得到 100 组样本数据。其中正常磨损密封声发射数据 40 组，严重磨损密封声发射数据 60 组，取 26 组正常磨损密封声发射数据和 40 组严重磨损密封声发射数据作为训练样本。正常磨损样本标签为 1，严重磨损样本标签为 -1。

基于 matlabp 平台编程，设置 GA-TWSVM 参数的种群数量为 20，迭代代数数为 300，选取高斯核作为核函数。先用训练样本对 GA-TWSVM 模型进行训练，得到的最佳参数为 $c1 = 64.5442$ ， $c2 = 99.2485$ ， $g = 0.000133$ ，训练过程中的最佳适应度到达了 98.57%。然后用测试样本进行测试，测试的准确率也达到了 100%。其训练过程如图 7 所示。

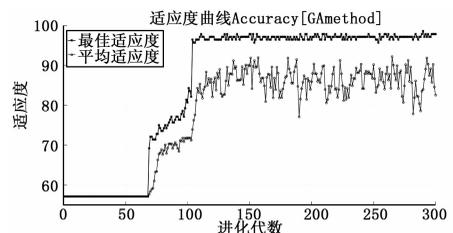


图 7 遗传算法优化过程

为了对比 GA-TWSVM 的诊断能力, 本实验同时设置 GA-SVM 进行对比。GA-TWSVM 和 GA-SVM 的诊断结果如表 1 所示。

表 1 GA-TWSVM 和 GA-SVM 诊断结果

项目	GA-TWSVM	GA-SVM
识别率/%	100	94.11
识别时间/s	0.016 7	0.017 8

4 结束语

本文主要研究广义 S 变换在声发射信号时频分析中的应用效果。通过对比发现, 通过调节 λ , p 两个参数, 可以调节其在各个频率范围内的频率分辨率, 因此适用于声发射信号这种信号频率覆盖范围极高且广的信号。目前针对声发射信号的研究较少, 后续可以在广义 S 变换的基础上对声发射信号的特征进行进一步研究。

本文验证了孪生支持向量机在模式识别中的识别效果, 通过对比可以发现孪生支持向量机相比传统的支持向量机具有更好的识别效果。虽然理论上孪生支持向量机的识别速度只需要支持向量机的 1/4, 但是在本实验中其识别速度并没有显著提高, 在之后的研究中需要将孪生支持向量机的程序进一步进行优化, 提高其识别速度。

参考文献:

[1] 张宝琪. 声发射的原理及应用 [J]. 化工炼油机械通讯, 1980 (6): 45-55.

[2] 李孟源. 声发射检测及信号处理 [M]. 北京: 科学出版社, 2010.

[3] 张东灿. 金刚石薄膜和类金刚石薄膜摩擦学性能试验及其应用 [J]. 计算机工程与设计, 2009, 30 (3): 679-682.

[3] Pan J, Han M. The evolutionary optimization of system of systems based on Agent model [A]. IEEE International Conference on System Science and Engineering [C]. IEEE, 2014: 231-235.

[4] Armbrust M, Fox A, Griffith R, et al. A view of cloud computing [J]. International Journal of Computers & Technology, 2010, 53 (4): 50-58.

[5] Tan Z, Zhou W, Sun J, et al. An improvement of static subtree partitioning in metadata server cluster [J]. International Journal of Distributed Sensor Networks, 2012: 1129-1132.

[6] 陈 锋. 基于网络结构的推荐算法研究 [D]. 西安: 西安电子科技大学, 2015.

[7] 郭艳红. 推荐系统的协同过滤算法与应用研究 [D]. 大连: 大连理工大学, 2008.

[8] 李 聪, 梁昌勇, 马 丽. 基于领域最近邻的协同过滤推荐算法 [J]. 计算机研究与发展, 2008, 45 (9): 1532-1538.

[9] 许富龙, 刘 明, 龚海刚, 等. 延迟容忍传感器网络基于相对距离的数据传输 [J]. 软件学报, 2010, 21 (3): 490-504.

[10] 刘 鑫, 陈 伟. 基于 AJAX 和 Server Push 的 Web 树组件设

研究 [D]. 上海: 上海交通大学, 2010.

[4] Stockwell R G, Mansinhs L, Lower R P. Localization of the complex spectrum: the S transform [J]. IEEE Transactions on Signal Processing, 1996, 44 (4): 998-1001.

[5] Mangasarian O L, Wild E W. Multisurface proximal support vector machine classification via generalized eigenvalues [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2006, 28 (1): 69-74.

[6] Jayadeva, Khemchandnt R, Suresh C. Twin support vector machines for pattern classification [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2007, 29 (5): 905-910.

[7] 黄华娟. 孪生支持向量机关键问题的研究 [D]. 徐州: 中国矿业大学, 2014.

[8] 蒋恩超, 傅 攀, 张思聪. 小波包和 GA-SVM 在轴承故障诊断中的应用 [J]. 计算机测量与控制, 2017, 25 (10): 7-10.

[9] 杨 杰, 郑 宇, 刘 董, 等. 基于遗传算法的 SVM 带权特征和模型参数优化 [J]. 计算机仿, 2008, 25 (9): 113-118.

[10] 郝建民. 采样定理与奈奎斯特准则的研究 [J]. 遥测遥控, 1998 (2): 12-20.

[11] 廖传军, 王道连, 王洪锐, 满满. 机械密封碰摩声发射信号的特征提取方法研究 [J]. 机械设计与制造, 2014 (7): 208-211.

[12] 刘永春, 童敏明, 陈 琳, 等. 基于广义 S 变换的声发射信号去噪研究 [J]. 计算机应用研究, 2011, 28 (12): 4535-4536, 4540.

[13] 朱 海, 高胜峰, 蔡 鹏, 丁文强. 基于拉依达准则的自适应小波阈值选取方法 [J]. 海洋技术学报, 2016, 35 (4): 50-54.

[11] 胡 宁, 朱培栋, 邹 鹏. 域间路由由协同监测中的信息共享机制 [J]. 软件学报, 2011, 22 (3): 481-494.

[12] 陈 阳, 怀进鹏, 胡春明. 基于内存混合复制方式的虚拟机在线迁移机制 [J]. 计算机学报, 2011, 34 (12): 2278-2291.

[13] 叶可江, 吴朝晖, 姜晓红, 等. 虚拟化云计算平台的能耗管理 [J]. 计算机学报, 2012, 35 (6): 1262-1285.

[14] 黎玲利, 王宏志, 高 宏, 等. XML 数据流上 Top-K 关键字查询处理 [J]. 软件学报, 2012, 23 (6): 1561-1577.

[15] 冯朝胜, 秦志光, 袁 丁. 云数据安全存储技术 [J]. 计算机学报, 2015, 38 (1): 150-163.

[16] 丁 滢, 王怀民, 史佩昌, 等. 可信云服务 [J]. 计算机学报, 2015, 38 (1): 133-149.

[17] 蒋乾悦, 张亚英. 基于模糊综合决策的服务器推送方法 [J]. 计算机科学, 2014, 41 (5): 86-90.

[18] 部 帅, 张宏科, 徐怀松. Sink 轨迹固定传感器网络的高效数据采集机制 [J]. 软件学报, 2010, 21 (1): 147-162.

[19] 谷 峪, 于 戈, 李晓静, 等. 基于动态概率路径事件模型的 RFID 数据填补算法 [J]. 软件学报, 2010, 21 (3): 438-451.