

Wind Turbine Gearbox Fault Diagnosis Method Based on Wavelet Packet and SVM

Qiyuan Ou¹, Weixing Yao¹, Qiuzhan Zhou¹, Wenge Cheng², Yanru Wu²

¹College of Communication Engineering, Jilin University, Changchun

²Tianjin Maritime College, Tianjin

Email: ouqiyuan1234@126.com

Received: Nov. 21st, 2013; revised: Dec. 6th, 2013; accepted: Dec. 20th, 2013

Copyright © 2013 Qiyuan Ou et al. This is an open access article distributed under the Creative Commons Attribution License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited. In accordance of the Creative Commons Attribution License all Copyrights © 2013 are reserved for Hans and the owner of the intellectual property Qiyuan Ou et al. All Copyright © 2013 are guarded by law and by Hans as a guardian.

Abstract: In order to monitor gearbox real-timely, which is the core component of wind turbine, a method is put forward. This method is based on some vibration signals that are caused by different parts of gearbox at work and common faults of gearbox. Firstly, a gearbox working signal acquiring system is created. It uses high precision sensors to acquire signals when the wind turbine gearbox is working. Secondly, according to features of vibration signals of gearbox at work, using wavelet packet transform method can extract characteristics from working signals. Sending those data to Support Vector Machine (SVM), the system can implement intelligent fault diagnosis. At last, through experiments under laboratory condition, this method can reach more than 97.5% classification accuracy in the case of small sample.

Keywords: Wing Turbine; Gearbox; Wavelet Packet Transform; SVM; Fault Diagnosis

基于小波包和 SVM 的风机齿轮箱故障诊断方法

欧淇源¹, 姚为星¹, 周求湛¹, 程文阁², 吴艳茹²

¹吉林大学通信工程学院, 长春

²天津海运职业学院, 天津

Email: ouqiyuan1234@126.com

收稿日期: 2013 年 11 月 21 日; 修回日期: 2013 年 12 月 6 日; 录用日期: 2013 年 12 月 20 日

摘要: 为了对风力发电机组中故障高发的核心部件齿轮箱进行实时监控及故障分析, 提出了一种根据齿轮箱在工作时不同部位所产生的振动信号及齿轮箱常见故障事件的分析方法。首先设计了一套风机工作信号感知系统, 采用高精度传感器获取齿轮箱工作信号; 其次, 根据齿轮箱工作时的振动信号特性, 通过小波包变换方法对工作信号进行特征提取; 将这些特征值送到支持向量机(SVM)中进行训练和分类, 可以实现故障的智能诊断; 最后得出分析结果, 通过在实验室现有的齿轮箱实验台进行验证, 在小样本情况下能达到了 97.5% 以上的分类精度。

关键词: 风力发电机; 齿轮箱; 小波包; SVM; 故障诊断

1. 引言

风力发电机长期工作在野外, 其核心部件齿轮箱

容易发生故障, 对其故障诊断是最近该领域的研究热点之一。国外在风机的智能诊断维护技术比较先进,

较常见的理论方法有数据挖掘、模糊自组织神经网络等；我国相关故障检测理论及技术刚起步，需要更深入研究，特别在风机的智能监控领域^[1]。如金风科技公司搭建了 SACDA(Supervisory Control and Data Acquisition)系统，对风电场进行监控和信息的共享、交换、传输；北京东方振动和噪声技术研究所综合了 Hilbert 时频谱分析、连续小波分析等几种经典的振动信号处理手段，建立风机监控系统；目前我国的研究方法通常是针对风机部件振动信号，利用其时域或频域上的异常来实现故障判断。

齿轮箱工作异常时，振动信号因为幅度及频率的变化会呈现明显的非平稳性，属于非平稳信号，可以通过小波包获取其故障信息。小波包变换利用一个低通滤波器 L 结合一个高通滤波器 H ，能够将振动信号分割为多个频率区间而且保存原信号的时域信息，能够很好地对时域和频域信息进行分析^[2,3]，所以利用其对齿轮箱振动信号分析，能够提取其时频信息。在故障诊断中，要实现计算机智能识别故障类型，这涉及到分类问题。经典的人工神经网络分类方法存在需求实际测量数据较多、计算时间长、无法保证全局最优的缺点，由于支持向量机能在有限样本情况下具有较好的分类推广能力，人为设置参数较少，计算速度较快，所以近年来它在故障领域成为活跃的研究方向^[4-6]。使用支持向量机对风机齿轮箱进行故障识别，能够解决样本数据收集较少、数据训练时间较长等问题。因此，利用小波包变换和支持向量机的风机齿轮箱故障诊断方法，能够对风力发电机齿轮箱进行有效地监控。

2. 小波包变换和支持向量机

2.1. 小波包变换方法

风力发电机在发电时，环境不断变化，使齿轮箱内部件的振动能量不断的变化，此时因为齿轮箱某部件工作异常、温度变化等因素，齿轮箱的振动信号会显示强烈的非平稳性。非平稳信号在时域及频域上有着明显的特征，需要有效的手段对其进行分析。小波包分析可以对信号的时域和频域信息同时进行分，能够有效地对非平稳信号进行特征提取^[7]。

利用小波包对信号进行分析，按照分析信号的需要来计算小波包分解的次数，利用小波包分解信号，

能够提取需要的频率区间上的特征^[8]。大部分的滤波方法，会使信号丢失部分特征，但是小波包滤波对信号进行分解及重组时能保留其原有信息^[9]。用小波包对信号分析的步骤如下^[10]：

步骤一：用 S 表示原始信号，选择合适的基函数，将信号进行 N 次的小波包分解。用 (i,j) 表示第 j 个节点，其中 $i = 1, 2, \dots, N$ ， $j = 1, 2, \dots, N$ ， X_{ij} 表示第 i 层得第 j 个区间的小波包分解幅值。

步骤二：将底层的小波幅值分别进行重组， S_{ij} 是 X_{ij} 的重组信号。初始信号 S 可表示为：

$$S = S_{i_0} + S_{i_1} + S_{i_2} + \dots + S_{i_{(2^N-2)}} + S_{i_{(2^N-1)}} \quad (1)$$

步骤三：计算出各个频率区间能量幅度。用 S_{ij} 对应区间的幅度为 E_{ij} ，得到：

$$E_{ij} = \int |S_{ij}(t)|^2 dt = \sum_{k=1}^n |x_{jk}|^2 \quad (2)$$

式中， $x_{jk}(j = 0, 1, 2, \dots, 2^N - 1, i = 1, 2, \dots, N)$ 表示 S_{ij} 的各个分量幅值。

步骤四：用每个频率区间的幅度组成一个一维数组 T ，有特征值序列：

$$T = [E_{i_0}, E_{i_1}, E_{i_2}, \dots, E_{i_{(2^N-1)}}] \quad (3)$$

要对这个结果进行归一化的处理。因此用下面的归一化公式：

$$E = \left(\sum_{j=0}^{2^N-1} |E_{ij}|^2 \right)^{1/2} \quad (4)$$

$$T' = T/E = [E_{i_0}/E, E_{i_1}/E, E_{i_2}/E, \dots, E_{i_{(2^N-1)}}/E] \quad (5)$$

公式(5)中， T' 就是归一化处理后的特征值数组。

2.2. 支持向量机(SVM)方法

SVM 是为了解决小样本问题学习和分类而提出来的，能够克服神经网络等方法所固有的过学习和欠学习问题^[11]，又有良好的非线性分类能力。它的基本思想是通过事先选择的非线性映射将输入向量映射到高维特征空间，在这个空间中利用结构风险最小化原则，同时引入间隔的概念，来构造最优决策函数，并巧妙地利用原空间的核函数取代高维特征空间的点积运算，避免了复杂计算^[12]。

针对风机一般处于恶劣环境下，样本采集成本较高，并且风机齿轮箱在工作时所产生的振动信号与其对应的故障状态有着非常复杂的非线性对应关系，所以现阶段选取支持向量机作为故障智能识别方法具有一定的优越性，并且由于支持向量机的人为设置参数较少，算法收敛速度较快^[11]，可以加快诊断系统的开发速度。

支持向量机解决最基础的问题是两类分类问题，根据训练集 $T = \{(x_1, y_1), \dots, (x_n, y_n)\}$ (其中 $x_i \in R^n$ 是输入， y_i 是输入数据对应的类别)，建立实值函数 $g(x)$ ，能让分类决策函数 $f(x) = \text{sgn}(g(x))$ 把测试数据正确分成两类。如果 $g(x)$ 是线性函数，即 $g(x) = w \cdot x + b$ ，(其中 w 为权向量， b 为阈值)，对于非线性函数，通过一个非线性映射，将输入数据映射到一个高维内积空间(Hilbert 空间)，并在 Hilbert 空间中进行线性分类。称 $w \cdot x + b = 0$ 为分划超平面方程。支持向量机要求找到的分划超平面不仅能将两类样本正确分开，还要使分类间隔最大，这样的分划超平面称为最优分划超平面。这样将两类分类问题转化为原始最优化问题^[13]：

$$\min_{w,b} \Phi(w) = \frac{1}{2} \|w\|^2 \quad (6)$$

$$y_i = (w \cdot x_i + b) \geq 1 \quad i = 1, 2, \dots, N, \quad (7)$$

根据对偶原理，可以将上述最优化问题转换为其对偶问题：

$$\min_{\alpha} \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n y_i y_j \alpha_i \alpha_j (x_i \cdot x_j) - \sum_{j=1}^n \alpha_j \quad (8)$$

$$\text{其中, } \sum_{i=1}^n y_i \alpha_i = 0 \quad \alpha_i \geq 0$$

求解对偶问题得到最优解：

$$\alpha^* = (\alpha_1^*, \dots, \alpha_n^*)^T \quad (9)$$

由对偶问题的解得到初始分类的最优解：

$$w^* = \sum_{i=1}^n y_i \alpha_i^* x_i \quad (10)$$

之后选择 α^* 中任意一个正向量 α_j^* 计算：

$$b^* = y_j = \sum_{i=1}^n y_i \alpha_i^* (x_i \cdot x_j) \quad (11)$$

综合上述各式可得到最优分类函数为：

$$f(x) = \text{sgn}[(w^* \cdot x) + b^*] \quad (12)$$

对偶问题的最优解 α^* 中每个 α_j^* 都和训练样本点一一对应，所以最后得出的最优分类函数只与对应 $\alpha_j^* \neq 0$ 的样本有关。根据 KKT 条件，大部分 α_j^* 为 0，为此将对应 $\alpha_j^* \neq 0$ 的样本输入称为支持向量^[14]。易知只有支持向量对最终的分划超平面起到作用。从中还能够看出 SVM 可以有效解决小样本识别问题。

3. 风机齿轮箱故障诊断实现

本文中硬件中使用试验的齿轮箱为风机组中典型的升速箱，诊断算法使用用 LabVIEW 和 MATLAB 混合编程来实现，图 1 是齿轮箱故障诊断实现框图。

3.1. 齿轮箱故障及信号采集

齿轮箱包括由箱体、齿轮、轴承、轴等部件，其中，在发生的故障中，齿轮占了 65%，轴承占了 25%，所以齿轮和轴承故障是重点研究的问题^[15]。齿轮主要发生的故障种类有断齿、齿面胶合、齿面磨损、齿面点蚀、齿形误差。轴承发生的故障一般有：磨损失效、疲劳失效、腐蚀失效、断裂失效、压痕失效、胶合失效等。

图 2 为实验使用的齿轮箱试验台，采集的振动信号由三个振动传感器采集，分别安装在在输入齿轮的前后固定端及输出齿轮的前端。并使用 2 个速度传感




Figure 1. Wind turbine gearbox fault diagnosis flow chart
图 1. 风机齿轮箱故障诊断实现框图




Figure 2. Gearbox experiment table schematic
图 2. 齿轮箱实验台示意图

器计算输入齿轮和输出齿轮的转动速度，从而得出齿轮和轴承等的特征频率。

3.2. 基于小波包变换的信号特征提取

齿轮箱正常工作时，振动信号在各个频率区间的幅度大小变化很小，齿轮箱工作异常时，各个频率区间的幅度会增加或者减小。通过实验，齿轮箱各种异常状态下的各频率区间幅度大小不同，可以作为其特征进行工作状态区别。下图为两种工作情况下采集的振动信号，采样率为 10 kHz。

如图 3 所示，设备出现各类异常情况和正常工作时振动信号有显然不同的特征，两组不同工作情况下振动信号在时域和频域都有明显不同特征。这是因为齿轮箱发生输出齿轮断齿时，齿轮啮合振动运动会变得更强烈，采集振动信号在时域上会出现很强的振动冲击，导致时域信号幅度波动明显增加，同时冲击的频率为齿轮所在轴的转频，齿轮啮合频率会发生变化，导致频域能量产生变化。这些变化可经过相关算法处理作为特征成为齿轮箱工作状态的诊断依据。

小波包能够很好地分析信号的时域和频域信息，结合上述所知能够用来对风机齿轮箱振动信号进行处理。经过试验分析，发现了利用小波包对振动信号提取 8 个不同频率区间的幅值，在不同故障发生时频率区间幅值变化最明显。本文测试了正常工作和各种故障情况下的振动数据。如图 4 所示在输入齿轮前端振动传感器测试点提取到并经过归一化的 3 种工作情况下特征向量在频带上的分布图，可以发现不同故障发生的情况下其特征向量在各频率区间下的分布显然不同。

3.3. 基于支持向量机的故障分类实现

经过上面的分析，得出振动信号表现出来的特征值有其相应的故障种类。风力发电机的齿轮箱采集到的振动信号和故障种类有着非常复杂的非线性数学关系，而且户外样本数据采集成本和难度较高，考虑支持向量机拥有良好的非线性分类技术，并且能够解决小样本学习，所以可以利用它把振动信号和故障类型对应起来。

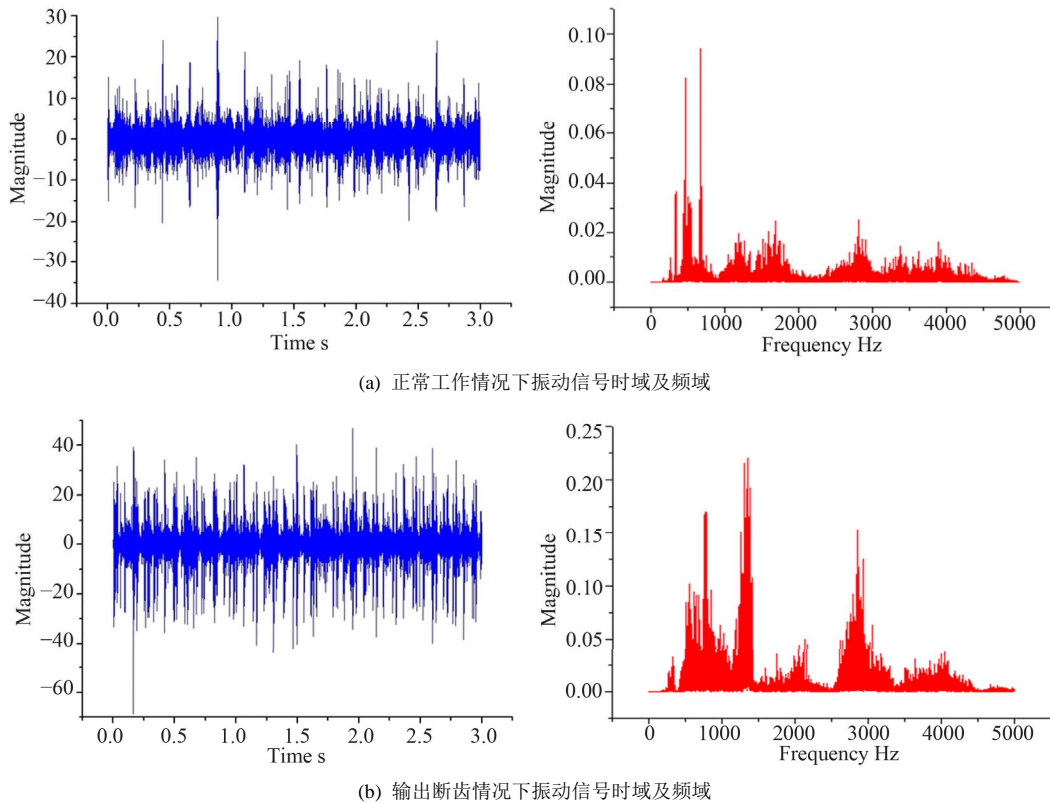


Figure 3. In both vases the vibration signal in time domain and frequency domain
图 3. 两种情况下振动信号时域和频域




Figure 4. Curve: system result of standard experiment
图 4. 标准试验系统结果曲线

当齿轮箱故障训练样本集采集完之后，在利用 SVM 寻找分类决策函数时，首先要选择 SVM 中的核函数。核函数用于将原输入空间需要用超曲面分划的分类问题转化成 Hilbert 空间中用超平面分划的问题，即核函数将非线性问题转化为线性问题，从而大大降低了问题的难度^[16]。核函数的选择有很大的灵活性，其中蕴含着特征选择，目前还没有针对特定的数据集选取核函数的方法^[12]。多项式核函数在分类时将分类决策函数分解成多个待分类向量的每个分量的多项式，每个多项式的运算结果综合起来就能够得出 SVM 最终的分类结果。因此，多项式核函数分类速度时令支持向量的个数不影响分类的运算量，因此加快了分类运算速度，同时保存了每个支持向量的特征。经小波包提取的特征个数不多，为了保持系统的识别率和提高识别速度，因此选取了多项式核函数：

$$K(x, x') = [(x \cdot x') + c]^d, \quad c = 100, d = 2 \quad (13)$$

基本的支持向量机仅能解决两类分类问题，而齿

轮箱故障诊断是多类分类问题，为实现利用 SVM 进行多类分类，可以采用一类对余类的 SVM 算法，即将多类识别问题转化为二类识别问题来解决。在样本训练时，先将训练样本值带入优化函数中，求出最优解以及非零值对应的支持向量，并根据支持向量求出权重向量 α^* 和阈值 b^* ，从而得到本分类器的分类决策函数^[11]。按照这样，分别求出所有故障对应的分类决策函数。

故障识别时，将输入特征送到每一个 SVM 计算器进行分类，然后逐步检查各个 SVM 计算器的结果。若一个计算器的结果为 1，则认为输入的故障为该类所对应的故障；若所有结果均不为 1，则拒绝识别该故障。由于识别存在一定的误差，可能同时有多个计算器的结果为 1，此时判断为第一个结果为 1 的故障。其大致分类算法流程图如图 5 所示。

4. 实测数据处理及分析

实验 8 次测量了齿轮转速在 280 rpm 和 420 rpm




Figure 5. Curve: system result of standard experiment
图 5. 基于 SVM 分类算法的故障诊断结构

两种典型转速情况下的数据共 120 组，其中齿轮箱正常、输入端齿轮断齿、输出端轴承损伤、输出端齿轮断齿、输出端齿轮点蚀、输入端齿轮误差这六种工作情况各占 20 组，随机选择样本数据集中 66.7% 比例的数据作为样本数据，33.3% 的数据作为测试数据。首先，将 80 组数据送进训练集，每个样本数据带有 21 个输入(选取 3 个关键部位振动信号，每个振动信号用小波包分解为 8 个特征值，丢弃其中 1 个不明显的特征)，如表 1 上述六种工作情况的种类标记向量分别为 (1, 0, 0, 0, 0, 0)、(0, 1, 0, 0, 0, 0)、(0, 0, 1, 0, 0, 0)、(0, 0, 0, 0, 1, 0)、(0, 0, 0, 0, 0, 1)。然后将其余 40 组数据送进测试集进行试验，检验故障诊断系统是否能够正确给出如表 1 所示的期望输出向量。

之后，反复地将其它组次的 120 组数据随机抽取 80 组作为训练集，40 组作为测试集，进行试验，得出的观察结果如表 2 所示。

如表 2 所示，每次在用随机抽取 80 组小样本数据进行训练之后，再使用剩下的 40 组数据进行结果验证，如此进行了 8 次试验，仅在第 5 次试验时有 1 组数据分类发生了错误，未能正确地已被系统所识别，导致这一次的分类正确率为 97.5%，其它次数的数据均获得了正确的分类，分类正确率都达到了 100%。这说明网络的预测结果是准确的，也进一步说明了本文训练完的网络能够解决小样本分类问题，能够准确的将齿轮箱的故障类别进行识别，准确率达到了 97.5% 以上。

5. 结论

基于齿轮箱振动信号提出了一种基于小波包变换和支持向量机的风机齿轮箱故障诊断方法，首先介绍了齿轮箱典型故障种类和其产生的振动信号，然后使用小波包变换方法对振动信号进行分解，将得到的故障特征向量作为输入参数送入支持向量机中进行训练和故障诊断，最后在实验室环境下测试表明，本

Table 1. A set of real data and the desired output vector
表 1. 一组数据真实向量及期望输出

工作情况	类别标签	期望输出向量
齿轮箱正常	(1, 0, 0, 0, 0, 0)	(1, 0, 0, 0, 0, 0)
输入端齿轮断齿	(0, 1, 0, 0, 0, 0)	(0, 1, 0, 0, 0, 0)
输出端轴承损伤	(0, 0, 1, 0, 0, 0)	(0, 0, 1, 0, 0, 0)
输出端齿轮断齿	(0, 0, 0, 1, 0, 0)	(0, 0, 0, 1, 0, 0)
输出端齿轮点蚀	(0, 0, 0, 0, 1, 0)	(0, 0, 0, 0, 1, 0)
输出端齿轮误差	(0, 0, 0, 0, 0, 1)	(0, 0, 0, 0, 0, 1)

Table 2. Test results
表 2. 测试结果

测试编号	分类错误数	分类准确数	正确率
1	0	40	100%
2	0	40	100%
3	0	40	100%
4	0	40	100%
5	1	39	97.5%
6	0	40	100%
7	0	40	100%
8	0	40	100%

方法在样本数量较小的情况下，故障诊断准确率达到了 97.5% 以上，具有很高的故障识别精度以及较强的适应能力，可以有效的识别齿轮箱的各种常见故障。在户外恶劣环境中，振动信号更为复杂，如何对采集的信号进行滤波去噪，精确地提取到振动信号的特征，是未来进一步研究的内容。

参考文献 (References)

[1] Ma, C.-L., Duan, B., et al. (2011) Design and Application of Wind Farm Fault Diagnosis System. *Power and Energy Engineering Conference (APPEEC)*. 2011 Asia-Pacific, Wuhan, 25-28 March 2011, 1-4.
[2] Zheng, X.-X., Xu, H.-S., et al. (2012) Fault Diagnosis of Wind

- Turbine Rolling Bearing Based on Wavelet and Hilbert Transforms. *Control Conference (CCC)*, 2012 31st Chinese, Heifei, 25-27 July 2012, 24-26.
- [3] Shen, C.-Q., Dong, W., et al. (2013) Fault Diagnosis of Rotating Machinery Based on the Statistical Parameters of Wavelet Packet Paving and a Generic Support Vector Regressive Classifier. *Measurement*. *Journal of the International Measurement Confederation*, **46**, 1551-1564.
- [4] Corinna, C. and Vladimir, V. (1995) Support-Vector Network. *Machine Learning*, **20**, 273-297.
- [5] Rafiee, J., Arvani, F., Harifi, S., et al. (2007) Intelligent Condition Monitoring of a Gearbox Using Artificial Neural Network. *Mechanical Systems and Signal Processing*, **21**, 1746-1754.
- [6] Lai, W.-X., Zhang, G.-C., et al. (2004) Classification of Gear Faults Using Cumulates and the Radial Basis Function Network. *Mechanical Systems and Signal Processing*, **18**, 381-389.
- [7] Sheng, X.-L., Wan, S.-T., et al. (2011) Gear Fault Diagnosis of Wind Turbine Generator System Based on Lifting Wavelet-Zooming Envelope Analysis. *Proceedings of the 2011 2nd International Conference on Mechanic Automation and Control Engineering*, Hohhot, 15-17 July 2011, 1332-1335.
- [8] Chen, J., Xue, T.-W. and Jing, J.-L. (2011) Gear Fault Diagnosis Based on Harmonic Wavelet Packet and Bp Neural Network. *Proceedings of the 2nd International Conference on Advanced Design and Manufacturing Engineering*, Taiyuan, 9-11 November 2011, 2683-2687.
- [9] Peng, H., Wen, Y.-X., et al. (2009) Crack Detection in Eggs with Multi-Level Wavelet Transform and Bp Neural Network. *Nongye Jixie Xuebao/Transactions of the Chinese Society of Agricultural Machinery*, **40**, 170-174.
- [10] Jiang, Y.-H., Tang, B.-P., et al. (2011) Feature Extraction Method of Wind Turbine Based on Adaptive Morlet Wavelet and SVD. *Renewable Energy*, **36**, 2146-2153.
- [11] Hu, Q., He, Z.-J., et al. (2007) Diagnosis of Rotating Machinery Based on Improved Wavelet Package Transform and SVM Ensemble. *Mechanical System and Signal Processing*, **21**, 688-705.
- [12] Yang, B.-S., Hwang, W.-W., et al. (2005) Cavitation Detection of Butterfly Valve Using Support Vector Machines. *Journal of Sound Vibration*, **287**, 25-43.
- [13] Yuan, S.-F. and Chu, F.-L. (2006) Support Vector Machines-Based Fault Diagnosis for Turbo-Pump Rotor. *Mechanical System and Signal Processing*, **20**, 939-952.
- [14] Zhang, Z.-S., Hu, Q., et al. (2005) Fuzzy Support Vector Machine and Its Application to Mechanical Condition Monitoring. Chongqing, 30 May-1 June 2005, 937-942.
- [15] Choi, K.H., Namburu, S.M., Azam, M.S., Luo, J., Pattipati, K.R. and Hine, A.P. (2005) Fault Diagnosis in HVAC Chillers. *IEEE Instrumentation & Measurement Magazine*, **8**, 24-32.
- [16] Ge, M., Du, R., et al. (2004) Fault Diagnosis Using Support Vector Machine with an Application in Sheet Metal Stamping Operations. *Mechanical System and Signal Processing*, **18**, 143-159.