

회전기계 결함신호 진단을 위한 신호처리 기술 개발

Signal Processing Technology for Rotating Machinery Fault Signal Diagnosis

최병근† · 안병현* · 김용휘* · 이종명* · 이정훈*

Byeong-Keun Choi† · Byung-Hyun Ahn* · Yong-Hwi Kim* · Jong-Myeong Lee*
· Jeong-Hoon Lee*

Key Words : Acoustic Emission(음향 방출), Signal processing(신호처리), Hilbert Transform(힐버트 변환), Fault classification(고장 분류), Feature selection(특징 선택)

ABSTRACT

Acoustic Emission technique is widely applied to develop the early fault detection system, and the problem about a signal processing method for AE signal is mainly focused on. In the signal processing method, envelope analysis is a useful method to evaluate the bearing problems and Wavelet transform is a powerful method to detect faults occurred on rotating machinery. However, exact method for AE signal is not developed yet. Therefore, in this paper two methods which are Hilbert transform and DET for feature extraction. In addition, we evaluate the classification performance with varying the parameter from 2 to 15 for feature selection DET, 0.01 to 1.0 for the RBF kernel function of SVR, and the proposed algorithm achieved 94% classification accuracy with the parameter of the RBF 0.08, 12 feature selection.

1. 서 론

정비 기술(Maintenance Technology)은 산업의 발전과 더불어 사후정비(Break-Down Maintenance)를 시작으로 하여 끊임없이 발전해왔다. 현재 가장 널리 Based Maintenance)로 상태 감시를 위한 데이터는 여러 가지 형태로 존재한다. 열(Heat), 압력(Pressure), 소음(Noise), 진동(Vibration) 등이 그 대표적인 예로 알려져 있다. 특히 진동 신호를 기반으로 한 상태감시 및 진단 기법은 기계설비의 주요 부분(베어링, 기어, 축계 등)의 결함 검출 및 원인 분석에 매우 유용하게 사용되고 있다. 하지만 정비 기

술은 앞으로 예지정비(Predictive Maintenance)⁽¹⁾를 목표로 연구가 진행되고 있으며, 세계 각 국에서 여러 가지 형태로 발전되고 있는 상황이다. 예지 정비는 설비의 여러 데이터를 종합하여 설비의 현 상태, 앞으로의 정비 계획, 잔류 수명 등을 예측하고, 사고의 사전 예방을 목표로 하기 때문에 기초 데이터는 매우 중요한 역할을 하게 된다. 그 기초 데이터 중에서 핵심이 되는 것은 결함의 조기 검출이다. 결함을 조기에 발견함으로써 설비의 현 상태뿐만 아니라, 잔류 수명, 사고 발생 시점 등을 예측할 수 있기 때문에 조기 결함 검출은 반드시 필요한 요소이다.⁽²⁾ 조기 결함 검출을 위한 선행 연구들은 기존의 진동 센서가 검지할 수 없는 신호를 대상으로 하기 때문에 진동 센서와 유사한 형태로 신호를 검출하지만 감도가 뛰어나고 고주파(초음파 이상)의 신호를 검지할 수 있는 음향방출(Acoustic Emission, AE) 센서로 조기 결함을 진단하는 연구들이 발표되었다⁽³⁻⁸⁾. 하지만 AE 센서에서 취득된 신호는 많은 잡음

† 교신저자: 최병근, 경상대학교 에너지기계공학과

E-mail : bgchoi@gnu.ac.kr

Tel : 055-772-0000, Fax : 055-772-9119

* 경상대학교 에너지기계공학과

(Background Noise)을 포함하고 있으며, 더불어 초음파 이상의 주파수 대역을 가지고 있기 때문에, 원신호를 이용하여 결합 분석을 위한 정보를 얻기가 쉽지 않다. 따라서 음향방출 센서가 적용된 결합 검출 연구에서는 많은 신호처리 기법들이 적용되었으며, 그 중 포락처리(Envelope Analysis)와 웨이블릿 변환(Wavelet Transform) 등이 유용한 것으로 나타나고 있다.

본 논문에서는 음향방출 신호를 주파수 영역으로 변환하여 각 베어링 결합 상태에서 나타나는 신호를 특징으로 추출하여 DET(Distance Evaluation Technique)를 통해 선정된 최적의 유형별 결합을 SVR(support vector regression)으로 진단한다. 제안한 알고리즘을 검증하기 위해 베어링의 기계적 결합 상태 6 가지의 음향방출 신호를 사용하였다. 각 신호는 초당 1,000,000Hz로 샘플링된 음향방출 신호를 61개씩 사용하였으며, 25개의 신호는 분류기 학습에 사용되었고, 나머지 36개를 실험에 사용하였다.

본 논문의 구성은 다음과 같다. 2장에서는 제안하는 알고리즘에 대하여 설명하고, 3장에서는 추출된 특징과 SVR 분류기를 이용하여 유형별 분류 성능에 대한 결과를 분석한다. 마지막으로 4장에서는 본 논문의 결론을 맺는다.

2. 알고리즘

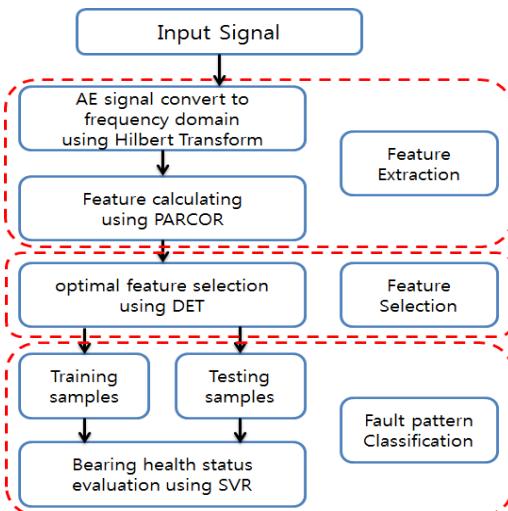


Figure 1. Proposed bearing fault diagnosis scheme using Acoustic Emission signal.

Fig. 1은 본 연구에서 제안하는 알고리즘의 흐름을 보여준다. 입력된 음방향출 신호는 웨이블릿 변환을 이용하여 주파수 영역으로 전환한 뒤 힐버트 변환에 의해 포락처리된다. 주파수 영역의 정보를 포락처리하면 신호 취득시 결합 신호와 주변에 생성되는 측대역파 외 추가되는 잡음을 최소화하는 효과가 있다. 잡음이 최소화된 신호에 PARCOR 기법을 활용하여 본 논문에서 사용한 6가지 유형의 베어링 고장 신호에 대한 각 유형별 특징을 추출하고, DET로 최적의 특징 개수를 선택한다. 선택된 특징을 SVR을 통하여 입력된 실험 특징과 학습된 특징을 비교하여 베어링의 상태를 진단한다.

2.1 힐버트 변환

힐버트 변환(Hilbert Transform, HT)⁽⁹⁾은 이론적으로 실수 데이터를 사용하여, 모든 주파수에 대해 진폭 1을 가지는 필터로 정의되며, 음의 주파수(negative frequency)와 양의 주파수(positive frequency)에 대해 90° ($\pi/2$) 만큼 위상 이동을하게 된다. 힐버트 변환의 결과는 식 (1)과 같이 실수부와 허수부의 합으로 표현된다.

$$z(t) = x(t) + jy(t) \quad (1)$$

힐버트 변환은 Fig. 2와 같이 포락처리를 위해 주로 사용되며, 포락처리는 원 신호에 대해 각 피크들을 요소로 하는 새로운 신호이다.

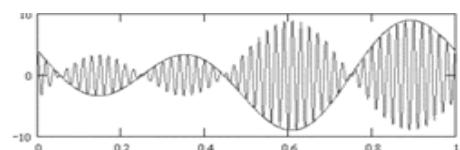


Figure 2. Enveloping by Hilbert transform.

포락 처리된 신호로 원 신호에 나타나는 시간에 따른 진폭의 변화가 발생되는 주파수를 분별할 수 있다. 따라서 힐버트 변환 결과는 원신호에 비해 낮은 주파수로 변조된다.

힐버트 변환은 Fig. 3에서 나타내는 것과 같이 변조 신호의 존재 및 진폭 정도를 나타낼 수 있기 때문에 결합 신호주변에 생성되는 측대역파(Sidebands)의 평가를 주 목적으로 사용된다.

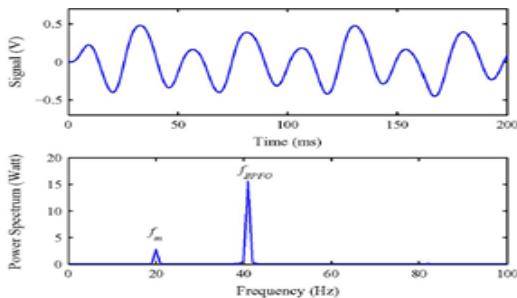


Figure 3. Example of the enveloping

2.2 특징 추출

Fig. 4는 고장 유형별 스펙트럼의 상관관계를 보여준다.

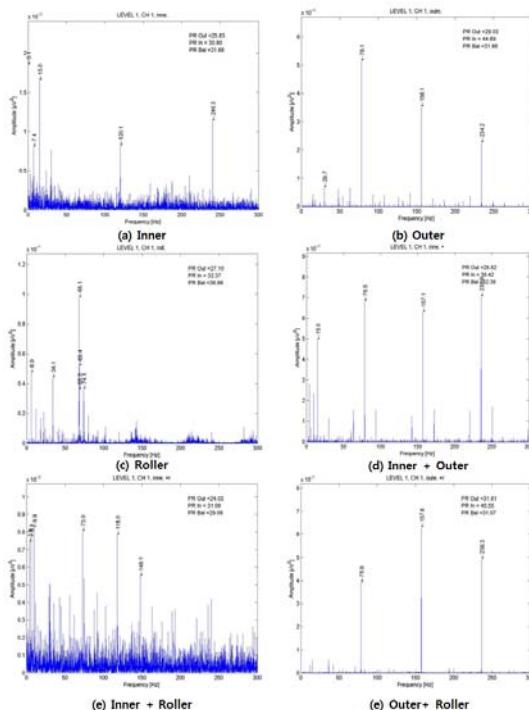


Figure 4. Each defected bearing spectra of fault signal (a) Inner (b) Outer (c) Roller (d) Inner+Outer (e) Inner+Roller (f) Outer+Roller

Fig. 4에서 나타내는 바와 같이 각 유형별 스펙트럼이 독립적으로 결합 유형 간 중복 없이 나타남을 알 수 있다. 따라서 본 논문에서는 스펙트럼 상에 나타나는 피크 신호를 특징 벡터로 추출하여 배어링

상태를 진단한다.

과거의 표본과 현재의 입력된 표본을 바탕으로 표본 간 상관관계를 모델링하는 방법에는 대표적으로 선형 예측 코딩(Linear Predictive Coding, LPC)이 있으나, LPC 계수는 출력 신호에 포함되는 잡음에 의해 값의 변화가 심한 단점을 가지고 있다. 따라서 본 논문에서는 신호 취득 시 생길 수 있는 잡음을 고려하여 이러한 현상에 LPC보다 강한 편 상관 계수(Partial Correlation Coefficients, PARCOR)를 특징 벡터로 사용한다.

2.3 특징 선정

DET(Distance Evaluation Technique, DET) 과정을 통해 두 가지 효과를 기대할 수 있다. 첫째는 원본 데이터에 비해 줄어든 크기의 데이터를 얻을 수 있다는 것이다. 데이터의 차원(Dimension)을 감소시킴으로써 원본 데이터를 그대로 사용할 때보다 더 빠른 시간에 연산을 마칠 수 있다. 둘째는 분류 성능 향상이다. 원본 데이터에는 분류기의 분류 기준 생성에 방해가 될 수 있는 관계없는(Irrelevant) 데이터, 잉여(Redundant) 데이터, 잡음(Noise) 데이터들이 섞여 있어 보다 보편적이고 정확한 분류기를 생성하기 어렵게 만든다. 특징 선택 과정을 통해 원본 데이터에서 이러한 부적절한 데이터들을 제거하고 분류기 생성에 밀접한 연관이 있는 데이터들만을 추출할 수 있다. 이로 인해 원본 데이터를 그대로 사용했을 때와 비교하여 더 정확한 분류기의 생성이 가능하게 된다. DET를 이용하여 특징을 선정하는 원리는 아래 내용과 같이 나타낼 수 있다⁽¹⁰⁾.

학습 데이터에서 C 개 유형의 특징 집합이 있다고 가정할 때 식 (5)와 같이 나타낼 수 있다.

$$\begin{aligned} q_{m,c,j}; m &= 1, 2 \dots M_c \\ c &= 1, 2 \dots C; j = 1, 2 \dots J \end{aligned} \quad (5)$$

$q_{m,c,j}$ 는 c 번째 유형이 갖는 j 번째 고유값의 m 번째 표본을 나타낸다. M_c 는 c 번째 유형의 표본수를 나타내며, J 는 각 표본은 개수를 나타낸다. 그러므로 C 개 클래스에서는 총 $M_c \times C \times J$ 개 표본을 얻을 수 있다. 식 (5)를 활용하여 다음 6단계에 따라 최적의 특징을 선정할 수 있다.

- 1단계 : 식 (6)에 따라 동일 조건 내에 있는 표본 간 평균 거리를 계산한다.

$$d_{c,j} = \frac{1}{M_c(M_c - 1)} \sum_{l,m=1}^{M_c} q_{m,c,j} - q_{l,c,j} \quad (6)$$

$l, m = 1, 2 \dots C; j = 1, 2 \dots J$

계산된 결과로 최종 C 유형의 평균 거리는 식(7)과 같이 나타낼 수 있다.

$$d_j^{(W)} = \frac{1}{C} \sum_{c=1}^C d_{c,j} \quad (7)$$

- 2단계 : $d_j^{(W)}$ 의 분산 계수는 식(8)에 따라 정의된다.

$$v_j^{(W)} = \frac{\max(d_{c,j})}{\min(d_{c,j})} \quad (8)$$

- 3단계 : 동일 유형 내 모든 표본의 평균 고유값은 식 (9)에 따라 계산된다.

$$u_{c,j} = \frac{1}{M_c} \sum_{m=1}^{M_c} q_{m,c,j} \quad (9)$$

계산된 결과를 식 (10)에 적용하여 다른 유형 표본 간 평균 거리를 구한다.

$$d_j^{(b)} = \frac{1}{C(C-1)} \sum_{c,e=1}^C |u_{e,j} - u_{c,j}|, \quad (10)$$

$c, e = 1, 2 \dots C, c \neq e.$

- 4단계 : $d_j^{(b)}$ 의 분산 계수는 식 (11)에 따라 정의된다.

$$v_j^{(b)} = \frac{\max(u_{e,j} - u_{c,j})}{\min(u_{e,j} - u_{c,j})}, \quad (11)$$

$c, e = 1, 2 \dots C, c \neq e.$

- 5단계 : 보정 계수는 식 (12)에 따라 계산된다.

$$\lambda_j = \frac{1}{\frac{v_j^{(W)}}{\max(v_j^{(W)})} + \frac{v_j^{(b)}}{\max(v_j^{(b)})}} \quad (12)$$

- 6단계 : 보정계수와 $d_j^{(b)}$, $d_j^{(W)}$ 로 α_j 를 계산한다.

$$\alpha_j = \lambda_j \frac{d_j^{(b)}}{d_j^{(W)}} \quad (13)$$

α_j 의 정규화는 식 (14)를 따른다.

$$\overline{\alpha_j} = \lambda_j \frac{\alpha_j}{\max(\alpha_j)} \quad (14)$$

정규화된 $\overline{\alpha_j}$ 를 이용하면 효과적으로 C 유형의 특징들을 나누어 선정할 수 있다. 본 논문에서는 특징 선정 개수에 변화를 주어 최적의 특징 선정 개수를 선택한다.

Fig. 5은 DET를 이용하여 내륜 고장에 대한 특징 개수를 선택한 예를 보여준다. 민감도가 0.3958 이상의 값들을 선정하여 분류기 학습에 사용하였으며, 특징 민감도는 1에 가까울수록 입력된 신호 고유의 특성을 나타낸다.

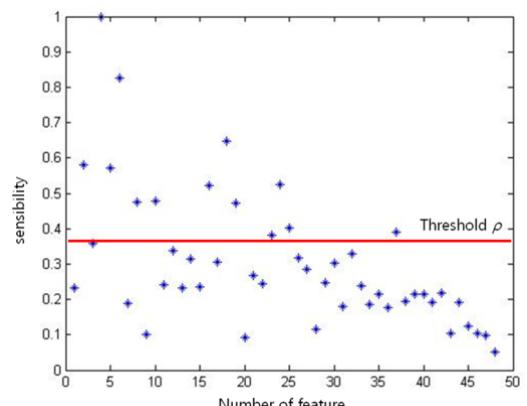


Figure 5. Feature selection

2.4 회귀분석

SVR(Support Vector Regression)은 서포터 벡터

기계(Support Vector Machine, SVM)가 가지는 회귀특성(Regression)을 특화시킨 알고리즘으로 SVM이 가지는 이진 분류기의 기능적 한계를 극복하고 주어진 다양한 데이터를 효과적으로 분류하는 분류기이다⁽¹¹⁾. SVR의 원리는 식 (13)과 같은 학습 데이터가 있다 가정한다.

$$(x_1, y_1), \dots (x_n, y_n) \subset \chi \times R \quad (15)$$

식 (13)에서 n 은 학습 데이터 개수이고, x 는 입력 벡터, y 는 출력벡터, χ 는 입력공간($\chi = R^d$)을 나타낸다. SVR은 모든 학습 데이터에 대해서 실제 목표값이 y 로부터 작은 편차와 가중치 벡터 ω 를 가지는 람수 $f(x)$ 를 찾는 것이다. 식 (14)는 이와 같은 조건을 만족하는 선형함수 $f(x)$ 를 나타낸다.

$$f(x) = \langle \omega, x \rangle + b \text{ with } \omega \in \chi, b \in R \quad (16)$$

여기서 b 는 바이어스이며, $\langle \omega, x \rangle$ 는 입력공간에 대한 내적이다. 대부분의 경우 주어진 자료는 선형적으로 분류되지 않는 경우가 많은데, 이런 경우 커널 함수(kernel function)를 이용하여 주어진 데이터를 고차원의 공간으로 사상시켜 분류한다. 대표적으로 polynomial function, Gaussian radial basis function 등이 있으며, 본 논문에서는 일반적으로 좋은 분류 성능을 보이는 RBF(Gaussian radial basis function)를 이용하였다. 본 논문에서 활용하는 RBF 커널 함수는 식 (15)로 나타낼 수 있다⁽¹²⁾.

$$k(sv_i, sv_j) = \exp\left(\frac{\|sv_i - sv_j\|^2}{2\sigma^2}\right) \quad (17)$$

커널 함수 $k(sv_i, sv_j)$ 에서 sv_i, sv_j 는 입력 특징 벡터이며, σ 는 효과적인 기본 커널 함수의 폭을 결정하기 위해 사용자가 설정하는 매개 변수이다. σ 값에 따라 분류 성능에 영향을 미치므로 본 논문에서는 결합 유형을 분류하는 최적의 σ 값을 선택한다.

3. 실험 및 결과

3.1 실험 환경

Table 1은 음향방출 신호를 취득하기 위해 사용된 PAC(physical acoustics corporation)사의 변환기, 증폭기, 데이터 수집 보드 및 소프트웨어의 상세 정보를 보여준다.

Table 1. Properties of AE system

2channel AE system on PCI-Board	18bit A/D conversion 5M samples/s rate
AE Sensor (Wideband Type)	Peak sensitivity : -62dB Operating freq. range : 100~1000kHz Resonant freq. : 650kHz Directionality : +/- 1.5dB
Preamplifier Gain	Wide dynamic range <90dB 20/40/60dB selectable gain

Fig. 6는 실험 진행에 활용된 베어링 음향방출 신호 취득 장치와 절차이다. 음향방출 센서는 구동축 피구동축의 베어링 케이싱 부분에 부착하여 실험을 수행하였으며, 회전속도 15Hz에 맞춰 실험을 수행하였다.

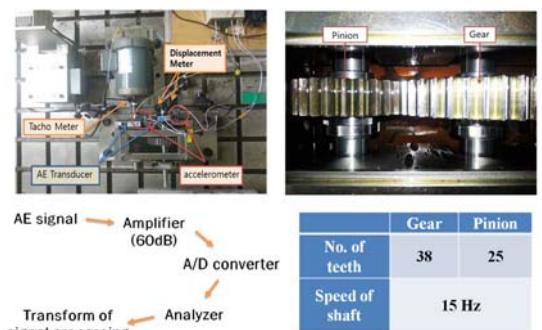


Figure 6. Acoustic Emission signal acquisition procedure.



Figure 7. Kind of the defected bearing

Fig. 7은 베어링 각 부분별 결함을 나타낸다. 최대 길이 6mm 깊이 0.6mm로 내륜(Inner), 외륜(Outer), 롤러(Roller)에 각각 결함을 주었으며 단일 결함과 복합결합에 대한 분류 실험을 수행하였다.

Table 2. Fault classification performance

	Inner	Outer	Roller	Inner + Outer	Inner + Roller	Outer + Roller	Performance (%)
Inner	33	2	0	1	0	0	91.66
Outer	0	36	0	0	0	0	100
Roller	0	4	32	0	0	0	88.89
Inner + Outer	0	0	0	36	0	0	100
Inner + Roller	0	0	0	3	33	0	91.67
Outer + Roller	0	0	0	0	1	35	97.23

3.2 실험결과

Fig. 8과 Table 2는 본 논문에서 제안한 알고리즘을 이용해 진동신호에 대한 최적의 분류 성능을 보여준다.

한 매개변수 수치는 0.08, 특징 개수 선택은 12개가 요구된다.

4. 결 론

본 논문에서는 베어링의 고장 분류를 위한 알고리즘을 소개하였다. 주파수 영역에서 신호를 전처리(Preprocessing)한 후 최적의 RBF 커널함수 매개변수와 특징 벡터 선택에 대해 연구하였다.

최적의 선택 개수로 고장 유형별 설정된 특징을 SVR 입력으로 사용하여 베어링 고장을 분류하였다. 최적의 특징 벡터 추출을 위해 특징의 수를 2에서 15로, 매개변수를 0.01에서 1.0으로 바꾸어 가며 실험한 결과 94%이상의 높은 분류 성능을 보였음을 확인할 수 있었다. 이러한 결과는 음향방출 신호를 활용하여 추출된 특징으로 신뢰성 있는 조기 결합시스템에 활용 할 수 있음을 보여준다.

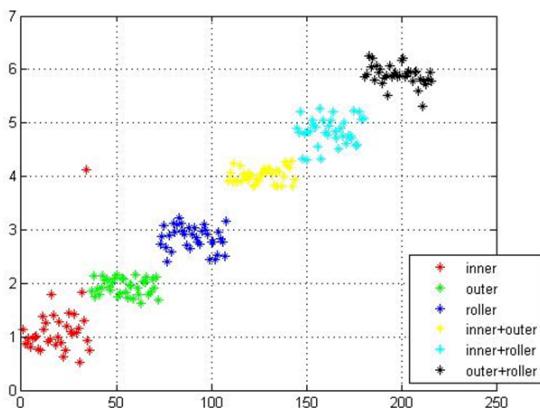


Figure 8. Fault classification performance

학습된 각 유형별 25개 표본을 제외한 36개의 데이터로 실험한 결과 평균 94.9%의 높은 분류 정확도를 보였다. 실험은 전술한 최적의 RBF 커널함수의 매개변수와 DET 특징 개수 선택을 위해 커널함수의 매개변수는 0.01에서 1.0까지, 특징 개수는 2개부터 15개까지 바꿔가며 실험한 결과 잡음이 없는 상태의 음향 방출 신호에서 최적의 분류가 가능

후 기

본 연구는 국립과학재단(NRF) 일반연구자지원사업(과제번호:2012-0216) 및 산학협력 선도대학 육성사업(기술개발과제)의 지원으로 수행 되었으며, 관계자 여러분께 감사드립니다.

참 고 문 헌

- (1) R. K. Mobley, 2002, An Introduction to Predictive Maintenance (2nd Edition), Elsevier Science(USA).
- (2) G. P. Sullivan, R. Pugh, A. P. Melendez and W. D. Hunt, 2010, Operations & Maintenance - Best Practices : A guide to Achieving Operational Efficiency (Rel. 3.0), U.S. Department of Energy.
- (3) B. Robert and J. Antoni, 2011, Rolling element bearing diagnostics, Mechanical System and Signal Processing, vol. 25, no. 2, pp. 485-520.
- (4) N. Baydar and A. Ball, 2003, Detection of gear failures via vibration and acoustic signals using wavelet transform, Mechanical System and Signal Processing, vol. 17, no. 4, pp. 787-804.
- (5) H. E. Jeong, D. S. Gu, H. J. Kim, Tan. Andy, Y. H. Kim and B. K. Choi, 2007, The application of AE transducer for the bearing condition monitoring of low-speed machine, KSNVE07S-09-03.
- (6) H. J. Kim and D. S. Gu and H. E. Jeong and Andy Tan and Eric Kim and B. K. Choi, 2007, The comparison of AE and Acceleration transducer for the early detection on the low-speed bearing, KSNVE07S-09-04.
- (7) T. H. Loutas, G. Sotiriades, I. Kalaitzoglou and V. Kostopoulis, 2009, Condition monitoring of a single-stage gearbox with artificially induced gear cracks utilizing on-line vibration and acoustic emission measurements, Applied Acoustics, vol. 70, pp. 1148-1159.
- (8) M. Entezami, S. Hillmansen and C. Roberts, 2010, Wind Turbine Condition Monitoring System, University of Birmingham.
- (9) D. Wang, Q. Miao and R. Kang, 2009, Robust health evaluation of gearbox subject to tooth failure with wavelet decomposition”, Journal of Sound and Vibration, vol. 324, pp. 1141-1157.
- (10) Yaguo Lei, Zhengjia He, Yanyang Zi, Qiao Hu, 2007, Fault diagnosis of rotating machinery based on multiple ANFIS combination with GAs, Mechanical Systems and Signal Processing 21, pp. 2280-2294.
- (11) A.J. Smola, B. Scholkopf, 2004, A tutorial on support vector regression, Statistics and Computing 14, pp. 199-222.
- (12) M. Deriche, 2005, Bearing Fault Diagnosis Using Wavelet Analysis, Computers, Communications, & Signal Processing with Special Track on Biomedical Engineering, CCSP 2005. 1st International Conference on, pp. 197-201.