

저속회전베어링의 전동면 이상진단에 관한 연구

-웨이브렛과 패턴인식법의 적용-

김 태 구

인제대학교 산업안전보건학과

Abstract:

베어링은 산업현장에서 널리 쓰여지는 중요 부품이다. 따라서 이의 결함에 따른 손실을 예방하기 위해서는 이상을 진단하고 검지하는 기법이 요구된다. 따라서 본 연구에서는 저속회전하므로 노이즈가 많이 포함되어 정상상태의 신호검출이 어려운 저속회전베어링의 외륜이상을 웨이브렛의 Denoising 기법을 적용하여 정량적으로 진단하고 패턴인식법 중의 하나인 KDI(Kullback Discrimination Information)를 적용하여 이상상태의 진단/검지능력을 시험해 보았다. 웨이브렛의 Denoising 기법은 노이즈 캔셀링(Noise canceling)이 능력이 뛰어났고, KDI 기법은 저속회전베어링의 정상과 이상의 분류에 뛰어난 검지능력이 있음을 알 수 있었다.

1. 서론

회전베어링은 많은 생산설비에서 중요하게 사용되고 있는 기본적인 요소이다. 베어링의 전동체와 전동면은 로터의 하중을 받으며 회전하기 때문에 사용 중에 피로(Fatigue)에 의한 결함이 발생하기 쉽다. 결함이 발생하게 되면 발생 진동이 커지게 되고, 사용을 계속하게 되면 더 큰 이상이 발생하게 되어 시스템이 제 기능을 다하지 못하게 되는 고장이 된다. 또한 이상의 형태도 다양해지고 진단방법 또한 여러가지 이론에 의하여 진단 및 검출되고 있다. 본 연구는 작년 추계발표때의 실험결과를 바탕으로 저속으로 회전하는 베어링에 있어서 S/N 비(Sound to Noise ratio : 신호와 소음의 비)가 낮을 때에 웨이브렛 이론 중 Denoising 기법을 이용하여 베어링의 이상진단을 행하였고 그 정량적인 진단영역을 추가검토하였다. 또한 미소한 이상의 진단에 있어 유효한 패턴인식법의 이론 중 KDI(Kullback Discrimination Information)기법을 적용하여 진단의 신뢰성을 비교 평가하였다. 이에 따라 저속으로 회전하며 시스템의 정밀성이 요구되는 경우는, 진동 등의 S/N 비가 낮아 고장의 징후가 되는 파라미터(parameter)를 얻기 어려우므로 웨이브렛 변환기법과 패턴인식 기법을 적용하여 정량적으로 평가하는 방법을 시험해 보았다.

2. 이론

2.1 웨이브렛 이론(Wavelet Theory)

웨이브렛 변환은 FFT 와 같이 주파수 분포를 추출하는 변환이다. 시간방향에 유한의 길이로 존재하는 웨이브렛(파속)을, 시간방향으로 확대·축소 이동시키면서 해석대상의

파형과의 합성적분(Convolution)을 구하는 것이다. 마더 웨이브렛(Mother Wavelet)을 $\psi(x)$ 로 한 함수 $f(x)$ 의 웨이브렛 변환은 다음과 같이 정의되어진다.

$$(W_{\psi} f)(b, a) = \int_{-\infty}^{\infty} \frac{1}{\sqrt{|a|}} \overline{\varphi\left(\frac{x-b}{a}\right)} f(x) dx \quad (1)$$

a : Scaling parameter, b : Shift parameter, $\overline{}$: Complex number

웨이브렛 변환 $(W_{\psi})(b, a)$ 이나 이 변환치를 신호평면상의 점 $(b, 1/a)$ 에 나타내는 것은 신호의 성질을 아는 데 편리하지만, 식(1)의 처리를 연속적 시간계로 행할 때에는 비효율적이다. 또, 웨이브렛 변환에서는 불확정성 관계로부터 분해가능한 시간폭 X 주파수폭의 최소치가 결정된다. 따라서, 해석에서 최소의 대표적인 점 $(b, 1/a)$ 의 수치를 취하면 된다. 구체적으로는, 좌표 $(b, 1/a)$ 을 2개의 정수 j, k 에 의해 $(b, 1/a) = (2^{-j}k, 2^j)$ 로 놓고 이산화(Discrete)시키는 것이 합리적인 방법이다. 이 이산화한 웨이브렛변환 $(W_{\psi} f)(2^j k, 2^j)$ 을 $d_k^{(j)}$ 로 하여 다시 쓰면, 식(1)은

$$d_k^{(j)} = 2^j \int_{-\infty}^{\infty} \overline{\psi(2^j x - k)} f(x) dx \quad (2)$$

가 된다. 이산웨이브렛(Discrete wavelet) 변환을 행하기 위해서는 마더 웨이브렛 ψ 가 기저함수여야 한다는 조건이 추가된다. 본 연구에서는 ψ 에 다른 마더 웨이브렛을 비교해서 주파수 분해능력이 뛰어난 Coiflet Wavelet를 사용했다.

S/N 비가 작은 신호의 해석에서는 웨이브렛 변환을 행하면 신호와 노이즈의 판별이 곤란하다. 이런 경우에 노이즈를 제거하고 신호에 포함된 정확한 정보만을 추출하는 것이 필요하다. 일반적으로 이런 처리를 Threshold 처리라고 하고 기준치 th 는 아래식과 같다.

$$th = \sigma \sqrt{2 \log N} \quad (3)$$

한편 Threshold 처리는 적용방법에 따라 소프트(Soft)와 하드(Hard)Threshold로 나누어 지는데, 각각의 웨이브렛의 변환계수 w_{ij} 와 Threshold 기준치를 th 라고 하면 소프트

Threshold는 다음식과 같이 계산되어진다.

$$\begin{aligned} w'_{ij} &= \text{sgn}(w_{ij}) (|w_{ij}| - th) \text{ if } |w_{ij}| \geq th \\ w'_{ij} &= 0 \text{ if } |w_{ij}| < th \end{aligned} \quad (4)$$

여기서 w_{ij} 는 웨이브렛 재구성 레벨 i 에서의 j 번째 웨이브렛 계수라고 한다.

2.2 패턴인식 및 Kullback Discrimination Information

패턴인식의 분야에서 사용되고 있는 최근접분류법(the Nearest Neighbor Classification Rule, 이하 NN Rule)은 다음과 같다. $x_m, m=1, \dots, M$ 을 표본시계열 (labelled time series), θ_0 를 그 시계열에 대응하는 라벨(label; 정상, 이상등) x_0, θ_0 를 새로 분류되는 테스트용 시계열과 그것의 라벨이라고 한다. 또, x_0 과 x_m 의 거리를 $d(x_0, x_m)$ 이라고 하면,

$$d(x_0, x_m) \leq d(x_0, x_n) \quad m=1, 2, \dots, M \quad (5)$$

$$\Rightarrow \theta_0 = \theta_m$$

즉, 새로 분류되는 테스트용 시계열은 그것의 최근접의 라벨이 주어진다.

칼박식별정보량(Kullback Discrimination Information, 이하 KDI)은 실제의 확률분포가 $f_0(x)$ 일 때, 그 분포를 $f_m(x)$ 로 가정했을 때의 부적합(dissimilarity)정도를 나타내는 척도로서, AR 모델을 fitting 시킨 거리의 계산식을 식(6)에 표시하면, 다음식과 같이 계산되어진다.

$$2d(x_0, x_m) = \log \left[\frac{\hat{\sigma}_m^2}{\hat{\sigma}_0^2} \right] + \frac{1}{n\hat{\sigma}_m^2} \sum_{t=1}^n [e_{0,m}(t)]^2 - 1 \quad (6)$$

여기서, 기호 $\hat{\sigma}_m^2, \hat{\sigma}_0^2$ 는 각각의 시계열 x_m, x_0 의 추정분산, $e_{0,m}(t)$ 는 표본시계열 x_m 에 Fitting 된 모델로부터 테스트용 시계열 x_0 을 Filtering 함으로 발생하는 잔차시계열이다.

3. 실험

실험장치를 그림 1 에 도식하였다. 정상과 외륜에 결함이 있는 볼베어링을 결함의 정도에 따라 대(크기 0.8 mm, 최대깊이 50 μ m), 중(크기 0.6 mm, 최대깊이 7.5 μ m), 소(크기 0.9 mm, 최대깊이 75 μ m)로 분류하여 저속회전에 의한 결함의 진단이 가능한지를 시험했다. 이상(소)의 경우가 결함의 크기가 크지만 진동수가 이상(중)보다 작으므로

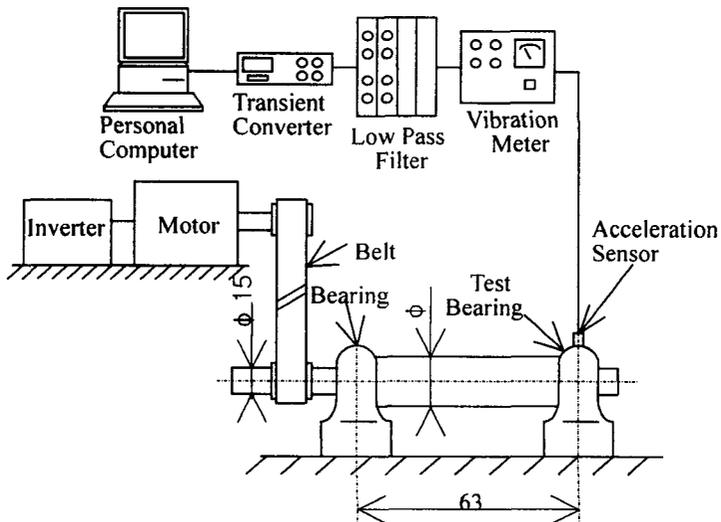


Fig.1 Schematic diagram of experimental apparatus

이상(소)로 하였다. 회전수는 5RPS 부터 1RPS 까지 1RPS 씩 감소시켜 실험하였고 데이터의 샘플링 간격은 0.1ms 이고 각 데이터의 개수는 8000 개씩 회전수당 5 개씩 수집하였다. 신호처리 이론에 의하여 데이터를 포락선 처리하고 Matlab 을 사용하여 마더-웨이브렛을 Coiflet 웨이브렛을 사용하여 변환처리하고 노이즈 제거처리 즉 본 연구에서는 Soft Threshold 를 실행하여 Denoising 하고 다시 웨이브렛 변환을 실행하였다. 동일 데이터를 KDI 이론에 의해 표준데이터를 부작위로 추출하고 각 테스트 데이터의 거리를 계산하였고 최근접분류법에 의해 상태를 분류하였다.

4. 결과 및 고찰

실험에서 얻은 데이터를 포락선 처리(Envelope processing)하기 전의 데이터를 그림 2 에 표시하였다. 회전속도에 따라 1 RPS 와 5 RPS 로 구분하여 표시하였다. 1RPS 의

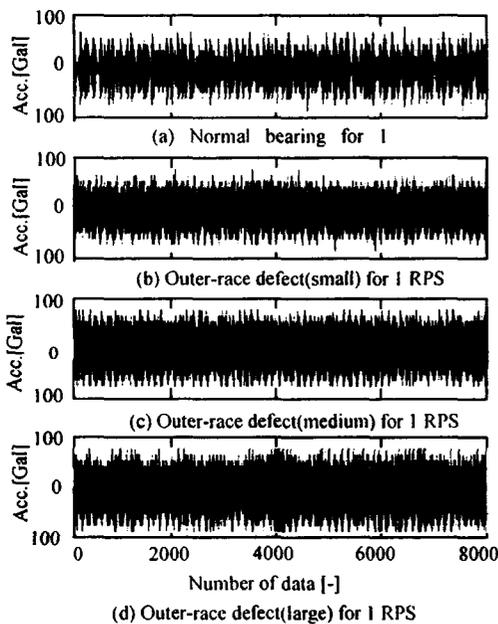


Fig.2 a Wave shapes of test bearings

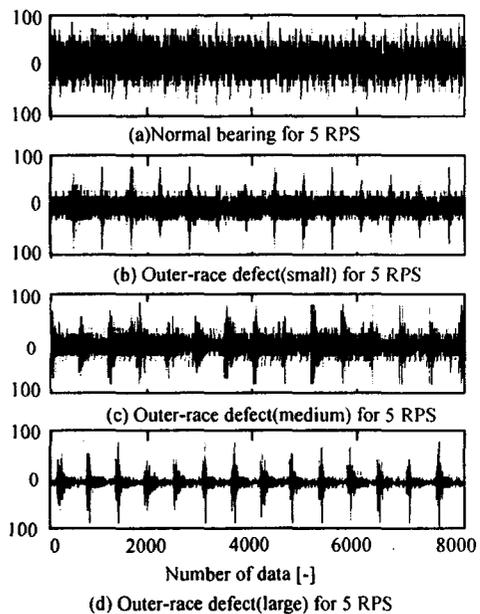


Fig.2 b Wave shapes of test bearings

경우는 정상상태와 이상상태와의 구분도 어렵지만 이상상태에서의 결함의 크기를 진단하기란 더 힘든 것을 알 수 있다. 외륜결함의 특성을 진단하기 위하여 일반적으로 신호처리기법에서 행하는 포락선 처리를 행한 후 웨이브렛해석을 행한 결과를 FFT 와 비교하여 감지능력을 그림 3 에 표시하였다. 작년 추계발표때의 정성적인 진단영역의 표시를 진단가능영역과 진단불가능영역으로 표시한 것이다. FFT 와 웨이브렛 변환기법을 비교하면 진단영역이 FFT 보다는 웨이브렛기법의 경우가 더 넓은 것을 알 수 있다. 즉, 웨이브렛 변환기법이 시간영역의 정보도 나타낼 수 있어 정보의 수도 많지만 Noise 저감능력에 있어서도 FFT 보다는 뛰어나다는 것을 본 실험에서도 알 수 있었다. 하지만 노이즈제거 성능이 뛰어난 웨이브렛변환을 이용한 기법에서도 그림 3 에서 보는 바와

같이 저속 3RPS 이하로 회전하며 손상의 정도가 작은 경우는 검지능력한계 이외에 있음을 알 수 있다. 즉, S/N 비가 현저히 낮은 경우의 검지능력을 향상시키는 방법에서도 한계가 있다는 것을 알 수 있다. 따라서 본 연구에서는 정상분포와 이상분포간의 거리차를 이용하여 정상상태와 이상상태를 분류할 수 있는 KDI 와 최근접분류법을 이용한 패턴인식법을 이용하여 변환기법으로 동일 데이터를 해석하여 그 결과를 표 1 에 표시하였다. 표 1 의 a 와 b 에서 보는 바와 같이 임의로 추출한 표준시계열 데이터를 가로에 표시하고 KDI 거리를 테스트 할 테스트 시계열 데이터를 세로로 표시하였고 각 상태의 이름에서 앞의 G 는 외륜의 이상, S 는 정상을 나타내고 가운데에 있는 E 는 결함의 크기로 대(大), F 는 중(中), H 는 소(小)를 의미한다. 총 20 개의 데이터 중 각 상태에서 1 개씩 표준데이터로 사용하고 나머지를 테스트 시계열 데이터로 사용하여 진단하였다. 결과로는 1RPS 에서 5RPS 를 전부 분류한 결과 총 80 개의 데이터 중 오분류(Miss classification)가 없이 100%상태분류가 가능했다. 즉 웨이브렛 변환기법에서는 분류가 불가능했던 3RPS 이하의 속도로 회전하는 가장 작은 결함(Small)의 분류까지도 가능함을 알 수 있었다. 따라서 노이즈가 많이 포함되어 있는 이상상태에서의 진단에서도 높은 검지능력을 얻었다.

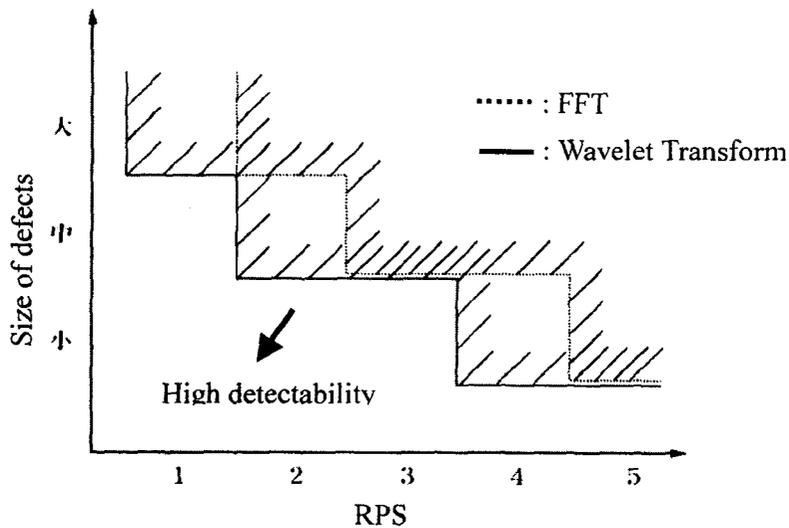


Fig.3 Comparing FFT with WT method

5. 결론

저속으로 회전하는 베어링의 이상을 웨이브렛의 Soft-threshold 의 기법인 Denoising 을 이용하여 진단하는 방법을 적용하고 이의 검지능력을 시험하고 KDI 기법과 비교한 결과 다음과 같은 결론을 얻을 수 있었다.

1) 웨이브렛의 Denoising 기법을 이용한 진단방법을 저속회전체의 진단에 적용해 봄으로

진단능력을 정량적으로 평가할 수 있었다.

2) 웨이블릿 변환기법으로 검지하지 못하는 이상을 KDI 기법을 적용함으로써 높은 검지능

Table 1. (a) Results of KDI for 1 RPS

		Sample time series			
		GEA1	GFA1	GHA1	SBA1
Test Time Series	GEA1	0.0001	0.2484	0.1674	0.6708
	GEA2	0.0186	0.2395	0.2018	0.6069
	GEA3	0.0134	0.2024	0.1680	0.5799
	GEA4	0.0261	0.1115	0.1171	0.4428
	GEA5	0.0125	0.2454	0.1919	0.5915
	GFA1	0.1223	0.0001	0.1221	0.2334
	GFA2	0.1470	0.0125	0.1340	0.2709
	GFA3	0.1306	0.0051	0.1329	0.2144
	GFA4	0.1264	0.0120	0.1292	0.2577
	GFA5	0.1323	0.0040	0.1280	0.2375
	GHA1	0.1070	0.3209	0.0001	0.5009
	GHA2	0.0912	0.2557	0.0063	0.3868
	GHA3	0.0923	0.2386	0.0075	0.3988
	GHA4	0.0875	0.2531	0.0062	0.4347
	GHA5	0.0991	0.2709	0.0076	0.4206
SBA1	0.2265	0.1948	0.1595	0.0001	
SBA2	0.2435	0.2279	0.1696	0.0027	
SBA3	0.2181	0.1917	0.1516	0.0015	
SBA4	0.2170	0.1923	0.1516	0.0037	
SBA5	0.2352	0.1992	0.1675	0.0029	

Table 1. (b) Results of KDI for 5 RPS

		Sample time series			
		GEE1	GFE1	GHE1	SBE1
Test Time Series	GEE1	0.0001	0.2099	0.0718	0.1664
	GEE2	0.0019	0.1999	0.0688	0.1587
	GEE3	0.0142	0.1671	0.0720	0.1343
	GEE4	0.0089	0.1852	0.0610	0.1461
	GEE5	0.0141	0.1609	0.0639	0.1185
	GFE1	0.5189	0.0001	0.4744	0.0956
	GFE2	0.5074	0.0019	0.4619	0.1081
	GFE3	0.4906	0.0044	0.4548	0.1066
	GFE4	0.4462	0.0073	0.4074	0.1009
	GFE5	0.5622	0.0069	0.5376	0.1210
	GHE1	0.1912	0.1916	0.0001	0.1195
	GHE2	0.1754	0.1581	0.0121	0.0947
	GHE3	0.1828	0.1826	0.0079	0.1147
	GHE4	0.1930	0.2022	0.0099	0.1275
	GHE5	0.1871	0.1578	0.0140	0.0941
SBE1	0.5571	0.1052	0.2496	0.0001	
SBE2	0.5408	0.0922	0.2270	0.0097	
SBE3	0.5797	0.1101	0.2747	0.0071	
SBE4	0.5366	0.1062	0.2560	0.0019	
SBE5	0.5383	0.1061	0.2419	0.0045	

력(Detectability)을 얻을 수 있었고, 이런 시스템에 적용이 가능함을 알 수 있었다.

참고문헌

- 1) L. Pasti, B. Walczak: Optimization of signal de-noising in discrete wavelet transform, *Chemometrics and Intelligent Laboratory Systems*, Vol 48, pp. 21~34 1999.
- 2) D.E. Newland, An introduction to random vibrations, spectral & wavelet analysis(3rd. ed.), Longman Scientific & Technical, pp.114-124, 1993.
- 3) Tae-gu Kim and Hisahi Shimizu, A study on Diagnosis of Gear Damages using Wavelet Transform, *Journal of Japan Society for Safety Engineering*, Vol.36, No.5, pp.289-295, 1997.
- 4) Bjørn K. Alsberg, Andrew M. Woodward and Douglas B. Kell: An introduction to wavelet transforms for chemometricians: A time-frequency approach, *Chemometrics and Intelligent Laboratory Systems*, Volume 37, Issue 2, June 1997, Pages 215-239
- 5) W. Gersch, Time Series Modeling Methods, *Mechanical Signature Analysis Theory and Application*, Academic Press, UK, pp. 288-318, 1986.
- 6) David L. Donoho: De-noising by Soft-Thresholding, *IEEE TRANSACTIONS ON INFORMATION THEORY*, VOL. 41, NO.3, 1995
- 7) Chung-Seog Oh: Application of wavelet transform in fatigue history editing, *International Journal of Fatigue*, Vol.23, pp. 241 ~ 250, 2001