

# 저속 구름 베어링의 다중 결함 조기 검출

강현준, 정인규, 강명수, 김종면\*  
울산대학교 전기전자컴퓨터공학부

## Early Multiple Fault Identification of Low-Speed Rolling Element Bearings

Hyunjun Kang, In-Kyu Jeong, Myeongsu Kang, Jong-Myon Kim\*  
School of Electrical, Electronic, and Computer Engineering, University of Ulsan

### 요 약

본 논문에서는 저속으로 동작하는 구름 베어링의 다중 결함 조기 검출을 위해 결함 특징 추출, 효과적인 특징 선택, 선택된 특징을 이용한 결함 분류의 세 단계로 구성된 결함 진단 기법을 제안한다. 1 단계에서 이산 웨이블릿 변환을 이용하여 미세성분으로부터 통계적 결함 특징을 추출하고, DET(distance evaluation technique)를 이용하여 추출한 결함 특징 가운데 베어링 다중 결함 검출에 효과적인 특징을 선택한다. 마지막으로 선택된 특징을 k-NN(k-Nearest Neighbors) 분류기 입력으로 사용하여 결함을 진단한다. 본 논문에서는 제안한 결함 진단 기법의 성능을 분류 정확도 측면에서 평가한 결과 95.14%의 높은 분류 정확도를 보였다.

### 1. 서론

회전 기계는 산업현장에서 중요한 전략적 위치를 차지하며, 특히 회전 기계의 구성 요소인 베어링에 깨짐, 고착 및 어긋남 등의 결함 발생 시 축 정렬 불량(misalignment) 및 질량 불균형(unbalance)으로의 2차적 결함 발생의 원인이 되어 심각한 경제적 손실을 야기할 수 있다. 따라서 회전 기계의 안정적인 동작과 결함으로 인한 경제적 손실 및 인명 피해를 줄이기 위한 신뢰성 있는 베어링 조기 결함 진단 시스템 개발을 위한 연구가 최근까지도 활발히 진행되고 있다[1].

베어링 조기 결함을 위해 사용되는 신호로는 진동 신호(vibration signal)가 대표적이며 기계 설비의 주요 부분의 결함 검출 및 원인 분석에 매우 유용하게 사용되고 있다. 하지만 저속으로 동작하는 베어링의 경우 취득할 수 있는 진동 신호의 크기가 매우 작아 조기 결함 진단을 어렵게 한다. 이에 대한 대안으로 최근 음향 방출(acoustic emission) 신호를 이용한 저속 베어링 결함 진단 시스템 개발과 관련된 연구가 활발히 진행되고 있다[1]. 음향 신호를 이용한 베어링 결함 진단 시스템은 대부분 결함 특징 추출, 결함 진단을 위한 효과적인 특징 선택 및 분류의 세 단계로 구성된다[2]. 먼저 결함 특징 추출은 시간에 따라 주파수 성분의 변화가 발생하는 결함 신호의 비정상(non-stationary)적인 특징으로 인해 시간-주파수 영역 분석 방법과 함께 이루어진다. 따라서 본 논문에서는 대표적인 시간-주파수 분석 방법인 웨이블릿 변환(wavelet

transform)을 이용하여 신호를 분석하고 다중 베어링 결함에 대한 통계 값을 추출하여 특징 벡터를 구성한다. 이와 같이 추출한 특징들을 바탕으로 구성된 특징 벡터는 일반적으로 고차원이며 추출한 특징 모두를 분류기의 입력으로 사용할 경우 차원의 저주(curse of dimensionality)에 의해 분류 성능의 저하를 초래할 수 있다[3]. 이를 해결하기 위해 본 논문에서는 DET(distance evaluation technique)을 이용하여 특징의 민감도를 측정하고 이를 바탕으로 결함 진단에 효과적인 특징만을 일부 선택하여 분류기의 입력으로 사용한다[4]. 마지막으로 본 논문에서는 k-NN(k-Nearest Neighbors)[1] 분류기를 이용하여 다중 저속 구름 베어링 결함을 진단한다.

### 2. 신호취득 환경 및 결함 유형

본 논문에서는 베어링 조기 결함 검출을 위해 정상 베어링과 세 가지 유형의 베어링 결함 신호를 취득 하였다. 결함 신호 취득을 위한 실험 환경은 그림 1과 같으며 15 Hz의 저속으로 전동기(0.5 kW, 220 V)를 동작시켜 실험을 수행하였다. 신호 취득을 위해 사용한 데이터 수집 보드 및 소프트웨어는 미국의 PAC(Physical Acoustics Corporation)사의 제품을 사용하였으며, 음향 방출 센서는 구동축의 베어링 하우징(housing) 부분에 부착하여 신호를 취득하였다. 그림 2는 구름 베어링의 구성 요소인 내륜(inner race), 외륜(outer race) 및 롤러(roller)에 발생한 결함으로, 각 결함은 최대 길이 6 mm, 깊이 0.6 mm의 크랙(crack)이며, 다중 베어링 결함 진단을 위해 각 결함 유

\* 교신 저자

형별 0.5초 간격으로 90개의 샘플을 취득하여 본 실험에 사용하였다.




그림 1. 정상 베어링 및 베어링 결함 신호 취득 환경



그림 2. 본 실험에서 사용한 베어링 결함

### 3. 저속 구름 베어링 조기 결함 진단 시스템

#### 3.1. 특징 추출

앞서 1장에서 언급하였듯이 음향 방출 신호는 비정상(non-stationary)적인 특징을 가지며 웨이블릿 변환(wavelet transform)은 이와 같은 신호를 해석함에 있어서 매우 유용하다. 웨이블릿 변환은 모 함수(mother function)를 이용하여 입력 신호를 다해상도(multi-resolution)를 갖는 주파수 대역으로 분해하여 근사 성분(혹은 저주파 성분, approximation)과 미세성분(혹은 고주파 성분, detail)으로 분해한다. 본 논문에서는 이산 웨이블릿 변환을 이용하여 입력 신호를 근사성분과 미세성분으로 분해하며 식 (1)과 같이 이산 웨이블릿 변환은 스케일링 함수(scaling function)  $\phi$ 와 웨이블릿 함수(wavelet function)  $\psi$ 로 구성된다.

$$\begin{aligned} \phi(k) &= \sqrt{2} \sum_n h(n) \phi(2k-n), \\ \psi(k) &= \sqrt{2} \sum_n g(n) \psi(2k-n), \end{aligned} \quad (1)$$

여기서  $h(n)$ 은 스케일링 필터(혹은 저주파 통과 필터)의 계수를,  $g(n)$ 은 웨이블릿 필터(혹은 고주파 통과 필터)의 계수를 각각 의미한다. 즉 입력 신호는 식 (1)의 저주파 통과 필터 및 고주파 통과 필터에 의해 두 개의 주파수 대역으로 분해된다. 이와 같은 과정을 통해 각 단계의 분해가 이루어지며  $j$ 번째 단계 후의 저주파 통과 필터 및 고주파 통과 필터를 지난 후의 신호  $c_j$ 와  $d_j$ 는 식 (2)와 같다.

$$\begin{aligned} c_j(k) &= \sum_n h(n-2k)x(n) \\ d_j(k) &= \sum_n g(n-2k)x(n), \end{aligned} \quad (2)$$

여기서  $x(n)$ 은 입력 신호이다. 식 (2)에서와 같이 저주파 대역 및 고주파 대역으로 분해된 후의 신호는 입력 신호의 길이의 1/2로 시간 해상도가 절반으로 감소되어 다운 샘플링(down sampling)이 가능하며 정보 손실 없이 다음 단계로 분해가 가능하다. 이와 같은 분해 과정을 부대역 부호화(subband coding)라하고 다음 단계로의 분해를 위해 위와 같은 과정이 계속 반복된다. 앞서 언급하였듯이 입력 신호는 모 함수에 의해 주파수 분할이 이루어지므로 모 함수의 선택이 중요하다. 본 논문에서는 입력 신호의 포락선 모양을 잘 반영하여 그 특성을 잘 나타내는 Daubechies 2(혹은 db2)을 이용하였으며 그림 3과 같다.




그림 3. 음향 방출 신호의 포락선과 db2 웨이블릿 모 함수

이와 더불어 베어링의 결함 특징을 잘 나타내는 주파수 대역 선택을 위해서는 적절한 웨이블릿 분해 단계를 거치는 것이 중요하다. 본 논문에서는 입력 신호에 대해 1단계와 2단계 웨이블릿 변환을 수행한 후 고주파 성분으로 간주되는 베어링 결함이 포함될 가능성이 높은 미세성분(detail)을 역변환 하고[5], 역변환 된 시간 영역 신호를 포락선 분석(envelope analysis)함으로써[6] 베어링의 결함 주파수 성분이 보다 잘 나타나는 대역을 특징 추출을 위해 사용한다. 그림 4는 1단계 및 2단계 웨이블릿 변환 결과를 바탕으로 한 포락선 분석의 결과이다. 그림 4에서 볼 수 있듯이 1단계 웨이블릿 변환 후 베어링의 결함 주파수 성분을 더욱 잘 표현하는 것을 확인 할 수 있으므로 본 논문에서는 1단계 웨이블릿 변환 후의 미세성분을 이용하여 12가지 통계적 파라미터(mean, crest factor, impulse factor, standard deviation, kurtosis, skewness, energy, peak, clearance factor, root mean square, latitude factor, absolute mean amplitude)[5]를 다중 베어링 결함 검출을 위한 결함 특징(fault feature)으로 사용한다.

#### 3.2 특징 선택

저속 구름 베어링 조기 결함 검출을 위해 앞서 추출한 12가지의 결함 특징 모두를 분류기(classifier)의 입력으로 사용할 경우 차원의 저주(curse of dimensionality)에 의하여 분류 성능은 낮아지고 수행 시간은 길어질 수 있다.

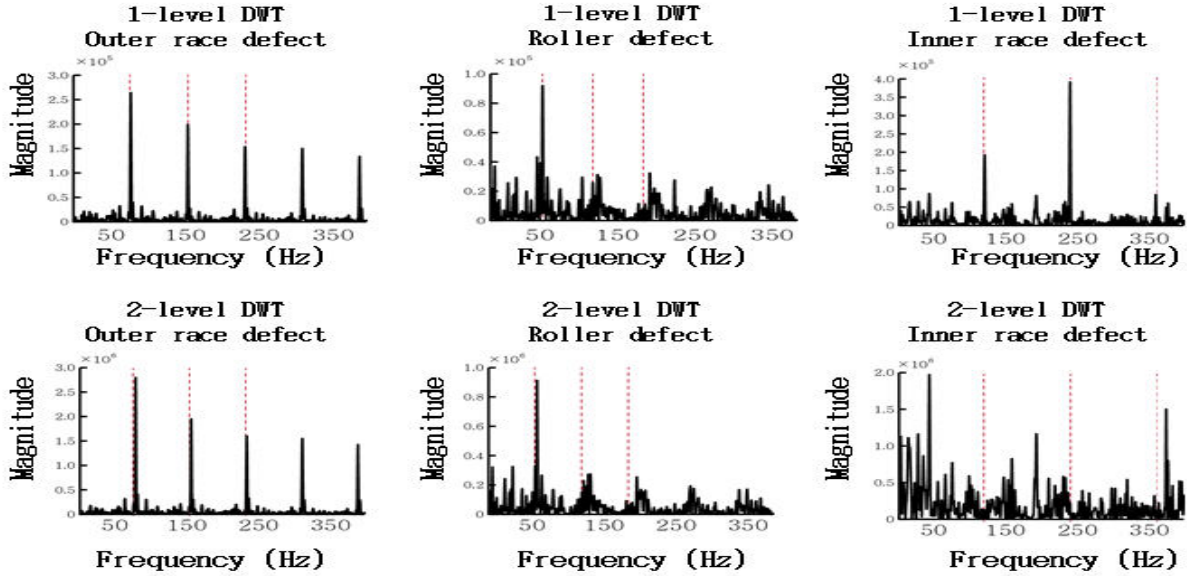


그림. 4. 1단계(위) 및 2단계(아래) 웨이블릿 변환 후 미세성분을 이용한 베어링 결함 별 포락선 분석 결과

이를 해결하기 위해 최근 결함 진단 연구에서는 추출한 특징을 대상으로 전체 클래스(class)에 대한 민감도(sensitivity)를 측정하여 민감도가 높은 특징들을 일부 선택하여 분류기의 입력으로 사용함으로써 분류 성능을 향상 시켜오고 있다. 따라서 본 논문에서는 특징의 민감도를 평가하기 위한 대표적인 방법인 DET(distance evaluation technique)를 이용하여 저속 구름 베어링 결함 진단에 효과적인 특징들만을 선택하며[4], 아래와 같은 네 단계를 통해 각 결함 특징의 민감도를 측정한다.

- **Step 1** : 먼저  $i$ 번째 결함 특징을 대상으로  $j$ 번째 클래스 내 샘플들 간 평균 거리  $d_{i,j}$ 를 식 (3)과 같이 구하며, 이때  $d_{i,j}$ 는  $i$ 번째 특징의  $j$ 번째 클래스에 대한 클래스 내 군집정도(intra-class density)를 나타낸다.

$$d_{i,j} = \frac{1}{N \times (N-1)} \sum_{\substack{m,n=1 \\ m \neq n}}^N |f_{i,j}(m) - f_{i,j}(n)|, \quad (3)$$

여기서  $N$ 은  $j$ 번째 클래스의 총 샘플 개수를,  $f_{i,j}(m)$ 는  $j$ 번째 클래스  $m$ 번째 샘플에 대한  $i$  번째 특징 값을 각각 나타낸다. 다음으로 식 (4)와 같이  $i$  번째 특징에 대해 전체 클래스의 군집정도(entire-class density)  $d_{ai}$ 를 구하는데, 이때  $d_{ai}$  값이 작을수록 군집이 잘 되어 있음을 의미한다.

$$d_{ai} = \frac{1}{M} \sum_{j=1}^M d_{i,j} \quad (4)$$

여기서  $M$ 은 클래스의 총 개수 즉 베어링 결함 개수로 본 논문에서는 정상 베어링을 포함하여 총 세 가지 유형의 베어링 결함을 진단하므로  $M$ 의 값은 4이다.

- **Step 2** : 식 (5)는  $i$ 번째 특징에 대한 클래스 간 구별 정도(inter-class separability)를 나타낸다.

$$d'_{ai} = \frac{1}{M \times (M-1)} \sum_{\substack{m,n=1 \\ m \neq n}}^M |F_{ai,m} - F_{ai,n}|, \quad (5)$$

여기서  $F_{ai,j} = \frac{1}{N} \sum_{m=1}^N f_{i,j}(m)$ 이다.

- **Step 3** : DET는 식(4)와 식 (5)에서 구해진 값의 비  $\alpha_i$ 를 이용하여  $i$ 번째 특징을 대상으로 전체 클래스에 대한 민감도를 나타내는데 이는 식 (6)과 같다.

$$\alpha_i = d'_{ai} / d_{ai}. \quad (6)$$

즉  $\alpha_i$ 는  $d_{ai}$ 가 최소이고  $d'_{ai}$ 가 최대일 때 최대가 되며 이를 만족하는 결함 특징은 다중 베어링 조기 결함 검출을 위한 가장 좋은 특징으로 간주한다.

- **Step 4** : 일반적으로 DET를 이용하여 특징을 선택할 경우 임계값(threshold)을 두어 임계 값 보다 민감도가 높은 결함 특징을 분류기의 입력으로 사용함으로써 결함을 진단한다.

### 3.3 분류기

k-NN은 특징 공간에 있어 학습 샘플들에 가장 근접한 테스트 샘플을 분류하기 위한 패턴 인식방법으로, 학습 샘플들은 다차원의 특징 공간에 구성되며 클래스에 의해 여러 영역으로 분류된다. 이와 같은 다차원 공간상의 새로운 테스트 샘플은 학습 샘플들과 k번째 이내로 가장 근접한 클래스에 소속시키게 되며, 본 논문에서는 k를 2로 설정하였다.

<표 1> DET에 의해 선택된 결함 특징에 따른 분류 정확도

특징 선택	결함 별 분류 정확도								평균 정확도	
	내륜 결함		롤러 결함		외륜 결함		정상			
임계값	학습(%)	테스트(%)	학습(%)	테스트(%)	학습(%)	테스트(%)	학습(%)	테스트(%)	학습(%)	테스트(%)
1	100	11.11	100	85.00	100	98.88	100	53.33	100	62.08
0.5249	100	96.11	100	77.78	100	99.44	100	98.89	100	92.56
0.1266	100	97.22	100	85.00	100	99.44	100	98.89	100	95.14
0	100	93.88	100	80.00	100	98.33	100	93.33	100	91.39

4. 실험 결과

표 1은 DET를 이용하여 얻은 분류 정확도로 다음과 같다.

$$CA^i = \frac{CLASSIFY_{correctly}^i}{F_{total}^i} \times 100(\%), \quad (7)$$

$$CA = \frac{1}{M} \sum_{i=1}^M CA^i, \quad (8)$$

여기서  $CA^i$ 는  $i$ 번째 클래스에 속하는 결함에 대한 분류 정확도,  $F_{total}^i$ 은  $i$ 번째 클래스에 속하는 결함의 수(본 논문에서  $F_{total}^i=60$ ),  $CLASSIFY_{correctly}^i$ 는  $i$ 번째 클래스에 속하는 결함이  $i$ 번째 클래스에 해당하는 결함이라고 판단된 결함의 총 수,  $M$ 은 총 결함 유형의 수(본 논문에서  $M=4$ )를 각각 의미한다. 그림 5에서와 같이 임계값이 1일 경우에는 피크(peak)를, 0.5249인 경우는 표준 편차(standard deviation), 피크(peak), RMS, 절대 평균 크기(absolute mean amplitude)를, 0.1266인 경우는 평균(mean)과 비대칭도(skewness)를 제외한 나머지를 각각 결함 특징으로 사용하였다.




그림 5. DET에 의한 결함 특징 별 민감도

표 1에서 DET에서 임계값을 0으로 한 경우는 추출한 12개의 결함 특징을 모두 이용한 것으로 평균 91.39%의 분류 정확도를 보였는데, 이는 DET를 이용하여 효율적인 특징을 선택하여 얻은 95.14%의 분류 정확도보다 낮으므로 효율적인 특징 선택이 성능 향상에 영향을 미치는 것을 확인할 수 있었다.

5. 결론

저속으로 동작하는 구름 베어링의 다중 결함 조기 검출을 위해 본 논문에서는 음향 방출 신호를 이용하여 결함 특징을 추출하였으며, DET를 이용 특징의 민감도를 평가함으로써 베어링 결함 진단에 효율적인 특징을 선택 k-NN의 입력으로 사용하여 결함을 분류하였다. 본 논문

에서는 제안한 결함 진단 기법의 성능을 분류 정확도 측면에서 평가하였고 모의실험 결과, DET에 의해 선택된 결함 특징을 이용할 경우 모든 특징을 사용할 경우보다 3.75%의 분류 정확도의 향상을 보였다.

감사의 글

이 논문은 2012년도 정부(교육부)의 재원으로 한국연구재단의 기초연구사업 지원을 받아 수행된 것이며 (NRF-2012R1A1A2043644), 또한 본 연구는 산업자원통상부의 광역경제권 선도산업 육성사업의 일환인 “동남광역경제권 선도산업 지원단”의 연구비 지원으로 수행되었음 (No. R0001220)

참고문헌

[1] D.H. Pandya, S.H. Upadhyay, S.P. Harsha, “Fault Diagnosis of Rolling Element Bearing with Intrinsic Mode Function of Acoustic Emission Data Using APF-KNN,” Expert Systems with Applications, Vol. 40, No. 10, pp. 4137-4145, 2013.

[2] B. Eftekharijad, M.R. Carrasco, B. Charnley, and D. Mba, “The Application of Spectral Kurtosis on Acoustic Emission and Vibration from Defective Bearing,” Mechanical Systems and Signal Processing, Vol. 25, pp. 266-284, 2011.

[3] C. Shen, D. Wang, F. Kong, P.W. Tse, “Fault Diagnosis of Rotating Machinery Based on the Statistical Parameters of Wavelet Packet Paving and a Genetic Support Vector Regressive Classifier,” Measurement, Vol. 46, No. 4, pp. 1551-1564, 2013.

[4] Y.G. Lei, Z.J. He, and Y.Y. Zi, “Application of an Intelligent Classification Method to Mechanical Fault Diagnosis,” Expert Systems with Applications, Vol. 36, No. 6, pp. 9941-9948, 2009.

[5] R. Yan, R.X. Gao, and X. Chen, “Wavelets for Fault Diagnosis of Rotary Machines: A Review with Applications,” Signal Processing, Vol. 96, pp. 1-15, 2014.

[6] D.S. Gu, J.G. Kim, T. Kelimu, S.C. Huh, and B.K. Choi, “Evaluation of the use of Envelope Analysis and DWT on AE Signals Generated from Degrading Shafts,” Materials Science and Engineering: B, Vol. 177, No. 19, pp. 1683-1690, 2012.