

베어링 복합결함 AE신호를 이용한 이미지화 고장분류

Image fault classification for AE complex fault signal

안병현* · 김용휘* · 이종명* · 하정민* · 최병근†
 Byung-Hyun Ahn* · Yong-Hwi Kim* · Jong-Myeong Lee*
 · Jeong-min Ha* · Byeong-Keun Choi†

1. 서 론

본 논문에서는 음향방출 신호를 주파수 영역으로 변환하여 각 베어링 결함 상태에서 나타나는 신호를 특징으로 추출하여 DET(Distance Evaluation Technique)를 통해 선정된 최적의 유형별 결함을 SVR(support vector regression)으로 진단한다. 제안한 알고리즘을 검증하기 위해 베어링의 기계적 결함 상태 6가지의 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

Fig. 1은 본 연구에서 제안하는 알고리즘의 흐름을 보여준다. 입력된 음향방출 신호는 웨이블릿 변환을 이용하여 주파수 영역으로 전환한 뒤 힐버트 변환에 의해 포락처리된다. 주파수 영역의 정보를 포락처리하면 신호 취득 시 결함 신호와 주변에 생성되는 측대역파 외 추가되는 잡음을 최소화하는 효

과가 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.

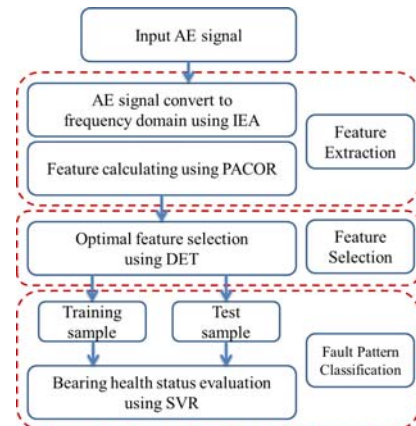


Figure 1. Algorithm of processing

2.1 특징 추출

Fig. 2에서 나타내는 바와 같이 각 유형별 스펙트럼이 독립적으로 결함 유형 간 중복 없이 나타남을 알 수 있다. 따라서 본 논문에서는 스펙트럼 상에 나타나는 피크 신호를 특징 벡터로 추출하여 베어링 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 상

† 교신저자; 최병근, 경상대학교 에너지기계공학과
 E-mail : bgchoi@gnu.ac.kr
 Tel : 055-772-9110, Fax : 055-772-9119
 * 경상대학교 에너지기계공학과

관 계수(Partial Correlation Coefficients, PARCOR)를 특징 벡터로 사용한다.

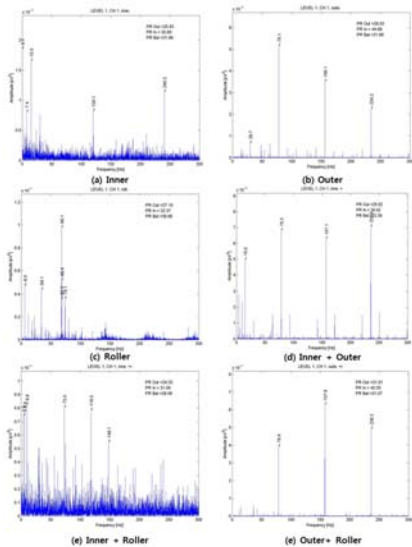


Figure 2. Each defected bearing spectra of fault signal

2.2 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.

Fig. 3은 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 3. Feature selection

2.3 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. 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 (1)로 나타낼 수 있다.

$$k(sv_i, sv_j) = \exp\left(-\frac{\|sv_i - sv_j\|^2}{2\sigma^2}\right) \quad (1)$$

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 결함 유형을 분류하는 최적의 σ 값을 선택한다.

3. 결과



Figure 4. Kind of the defected bearing

Fig. 4은 베어링 각 부분별 결함을 나타낸다. 최대 길이 6mm 깊이 0.6mm 로 내륜(Inner), 외륜(Outer), 롤러(Roller)에 각각 결함을 주었으며 단일 결함과 복합결함에 대한 분류 실험을 수행하였다.

3.1 실험결과

Fig. 5은 본 논문에서 제안한 알고리즘을 이용해 진동신호에 대한 최적의 분류 성능을 보여준다.




Figure 5. 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 바뀌가며 실험한 결과 잡음이 없는 상태의 음향 방출 신호에서 최적의 분류가 가능한 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 선정된 특징을 SVR입력으로 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 결함 시스템에 활용 할 수 있음을 보여준다.

후 기

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