

# FDR 특징 선별 기법을 적용한 저널베어링 시스템의 상태진단

## Diagnostics for journal bearing system based on FDR feature selection

전병철\*. 정준하\*. 윤병동\*†. 김연환\*\*. 배용채\*\*

Byungchul Jeon, Joonha Jung, Byeng D. Youn, Yeon-Whan Kim and Yong-Chae Bae

### 1. 서 론

현대의 제조 산업과 발전 설비에 사용되는 대부분의 기계들은 고장이 발생할 수 있는 베어링과 회전체 구조물이 사용된다. 회전체 기계 시스템의 고유한 성능을 유지시키면서, 치명적 사고 예방을 통해 인명 및 경제적 손실을 피하기 위해서 고장 초기단계에서 효과적인 진단이 가능하도록 많은 다양한 방법들이 사용되고 있다. 특히, 진동 신호는 시스템의 거동상태를 가장 유용한 정보를 제공하는 인자 중의 하나로써 회전체 시스템의 상태 진단에 널리 사용되고 있다. 진단의 효율성을 높이고 정확도를 향상하기 위해서는 획득 데이터에서 진단에 가장 효과적인 특징을 추출하는 것이 매우 중요하다.

본 연구에서는 저널베어링 시스템에서 획득된 진동신호를 이용해 시간, 주파수 영역에서 통계적인 특징 파라미터를 추출하였으며, FDR(Fisher Discriminant Ratio) 특징 선별 기법과 Random 파라미터 조합의 성능평가를 적용하여 효과적인 이상 진단 알고리즘을 개발하였다.

### 2. 실험 구성 및 데이터 획득

저널베어링 시스템의 이상상태를 모사하기 위한 장치로 GE Bently Nevada사의 RK4 rotor kit을 사용하였으며, 시스템의 구성은 figure 1과 같다. 이상상태 조건으로 질량 불균형(unbalance), 마찰

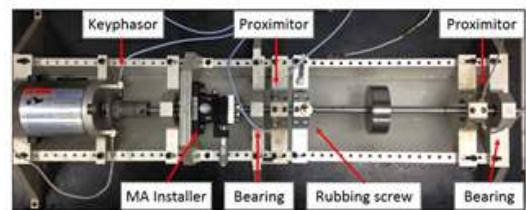


Figure 1. RK4 experimental setup

(rubbing), 오정렬(misalignment)을 대상으로 하였으며, 정상(normal) 상태의 데이터를 함께 획득하여 비교 대상으로 적용하였다. 질량 불균형은 소량의 질량을 디스크에 주입하였으며, 마찰은 rub screw를 이용하여 부분적인 마찰을 발생시켰고, 오정렬은 상하 위치 조절이 가능한 베어링을 추가하여 이상상태를 인가하였다.

실험의 신뢰성과 재연성을 확보하기 위해 모든 실험은 밸런싱을 통해 초기 진동치를 조절한 상태에서 진행하였다. 진동데이터는 proximitor probe를 이용해 DC 전압을 측정하고, 이를 변위 형태로 변환시켜 얻었다. Proximitor probe로 획득된 데이터는 NI DAQ 4432를 통해 4,000samples/s의 속도로 측정되었다. 실험은 3,600rpm의 steady-state 구간에서 training 조건과 testing 조건으로 나뉘어 각 상태별 3회씩 반복하여 진행되었다.

### 3. FDR 기반 특징추출 및 상태진단

#### 3.1 시간/주파수 영역 특징

RK4를 이용하여 획득된 진동 데이터의 정량화를 위해 시간 및 주파수 영역의 47개 특징 파라미터들이 사용되었다. 시간 영역에서는 Max, Mean, RMS, Skewness 등 통계적인 파라미터가 적용되었고, 주파수 영역에서는 FC, RMSF, RVF 등 스펙트럼의 에너지 집중도에 관련된 인자가 활용되었다.

\* 교신저자; 서울대학교 기계항공공학부

E-mail : bdyoun@snu.ac.kr

Tel : 02-880-1919

\*\* 서울대학교 기계항공공학부

\*\*\* 한국전력 전력연구원

### 3.2 FDR 기반 특징추출

두 가지 class의 데이터간 분별력의 척도인 FDR은 식 (1)과 같이 표기되며,  $\mu_i$ ,  $\mu_j$  및  $\sigma_i$ ,  $\sigma_j$ 는 각 class의 평균과 표준편차를 의미한다. 각 class 내의 분산이 작고 각 class간 평균의 차이가 클 경우가 FDR 값이 크고 분별력이 높은 경우이다.

$$FDR = \frac{(\mu_i - \mu_j)^2}{\sigma_i^2 + \sigma_j^2} \quad (1)$$

본 실험의 4가지 class에 대해 2가지 class 조합을 나타내는 6개의 set(figure 2 참조)에 대해 47개 특징 파라미터의 FDR값이 계산되었다. 각 조합별로 얻어진 FDR 값은 각각의 특징 파라미터 고유의 분별력을 지니지만, 최적의 인자를 선택하고 특징 파라미터 수를 줄이기 위한 방법으로 식 (2)의 비용 함수가 적용되었다.

$$i_k = \operatorname{argmax} \left\{ a_1 C_j - \frac{a_2}{k-1} \sum_{r=1}^{k-1} |\rho_{i_r, j}| \right\}, \quad (2)$$

$j \neq i_r, r = 1, 2, \dots, k-1$

위의 식에서  $C_j$ 는 각 특성 파라미터의 FDR 값을 의미하고  $\rho$ 는 각 특징 파라미터간의 상관성지수를 의미하며,  $a_1$ ,  $a_2$ 는 모델 매개변수를 나타낸다.

식 (2)를 이용하여 각 set별 FDR의 분별력 우선순위를 매기고, 비용함수 크기를 기준으로 주요 영향 인자(figure 2의 주황색 부분 인자)를 식별할 수 있다. FDR은 2 class 분류 능력 평가에 기반하기 때문에 multi-class의 상호 연관성 확인을 위해 인자 간 랜덤 조합의 성능을 평가하였다. 5,000번의 랜덤 조합 테스트를 통해 분류 정확도가 80%이상인 인자들의 조합에 나타난 빈도를 기준으로 특성 파라미터의 최종 순위가 결정되었다.

Rank	Feature ranking via cost function value					
	Set 1	Set 2	Set 3	Set 4	Set 5	Set 6
1	8	14	8	14	5	17
2	5	34	33	11	8	34
3	35					23
4	2	23	2	23	2	14
5	33	17	35	17	35	37
6	36	38	37	43	37	11
7	43	43	44	38	36	38
8	34	37	36	44	43	43
9	24	32	34	37	34	32
10	37	33	27	40	10	39
11	11	39	20	28	20	20
45	30	26	25	26	14	25
46	20	30	13	25	25	15
47	19	25	19	15	30	42

Figure 2. Feature selection via cost value of FDR

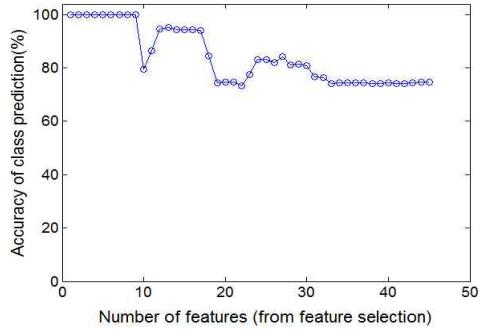


Figure 3. Classification accuracy by number of features

마지막으로 최종 순위가 결정된 인자를 이용하여 파라미터 수를 늘려가면서 testing data의 분류 정확도를 확인하였다.

### 3.3 결과 및 고찰

4 class에 대한 2 class의 조합은 figure 2와 같이 set1~6으로 나타낼 수 있으며, 식 (2)에 사용된 비용 함수를 이용하여 각 조합의 상위 50%에 해당하는 인자만을 선택하였다. 이 과정에서 특징 파라미터는 47개에서 16개로 줄어들게 되었으며, 이는 figure 2의 주황색 부분의 파라미터들을 대상으로 중복된 인자를 제외한 값이다. 16개 인자의 random 조합 성능평가를 통해 최종 인자의 분류능력 우선순위가 결정되었으며, 그 우선순위를 기준으로 특성인자를 늘리며 testing data 분류 정확도를 산출한 결과가 figure 3에 나타나 있다. 최적의 3~11개의 인자만을 사용하더라도 100% 분류 정확도를 얻을 수 있었다.

## 4. 결 론

저널베어링 회전체의 이상상태 분류를 위해 FDR 및 random 조합 성능평가를 적용하여 최적의 특징 파라미터 선정이 가능하였으며, 이를 통해 최소의 인자로 정확한 상태 분류가 가능함을 확인하였다. 추후에는 복잡 다양한 시스템에서 본 알고리즘의 적용 가능성성을 확인하고 성능을 개선해 나갈 계획이다.

## 후 기

본 논문은 2013년도 지식경제부 한국에너지기술평가원의 전력산업원천기술개발사업의 지원에 의하여 연구되었음 (2012101010001C).