

진동 데이터 기반 설비고장예지를 위한 신호처리기법

A Signal Processing Technique for Predictive Fault Detection based on Vibration Data

송예원(Ye Won Song)*, 이홍성(Hong Seong Lee)**, 박훈석(Hoonseok Park)***,
김영진(Young Jin Kim)****, 정재윤(Jae-Yoon Jung)*****

초 록

항공기 엔진, 풍력발전기, 모터 등 회전기에서 발생하는 많은 문제들은 진동이나 소음과 같은 신호 데이터를 측정하여 이상감지를 할 수 있으며, 주파수 분석 등 여러 가지 신호처리가 데이터 전처리 단계에서 필요하다. 본 논문에서는 진동 데이터를 분석하여 설비 이상상태를 감지하는 기법을 소개한다. 정상상태 데이터를 기반으로 마할라노비스 거리를 측정하여 이상상태 유무를 모니터링 하는 방식을 사용한다. 특히 신호 데이터의 전처리 기법들을 도입하여 이상상태 감지의 성능을 개선할 수 있음을 보여준다. 전처리 단계에서 신호 데이터 수집 과정에서 발생한 누설오차(leakage)를 없애기 위해 해밍 윈도우(Hamming window)를 적용하고, 신호 데이터의 원신호인 포먼트(formant)를 분리하기 위하여 캡스트럼(cepstrum) 분석을 실시한다. IMS 베어링 진동 공개데이터를 대상으로 시간 구간별로 6가지 통계지표를 추출한 후 마할라노비스 거리 분류기를 적용하여 성능을 검증하였다. 제시된 신호처리 전처리 기법을 적용함으로써 성능이 획기적으로 향상되는 것을 실험에서 보여주었다.

ABSTRACT

Many problems in rotating machinery such as aircraft engines, wind turbines and motors are caused by bearing defects. The abnormalities of the bearing can be detected by analyzing signal data such as vibration or noise, proper pre-processing through a few signal processing techniques is required to analyze their frequencies. In this paper, we introduce the condition

이 논문은 정부의 재원으로 한국산업기술진흥원(KIAT)[스마트공장 운영설계 전문인력 양성사업, No. N0002429]과 한국산업기술평가관리원(KEIT)[스마트공장고도화기술개발사업, No. 10054508]의 지원을 받아 수행되었음.

* First Author, Service Business Department, SOOSAN INT(ywsong92@khu.ac.kr)

** Co-Author, Department of Industrial and Management Systems Engineering, Kyung Hee University (fraud9204@naver.com)

*** Co-Author, Department of Industrial and Management Systems Engineering, Kyung Hee University (hoonseok@khu.ac.kr)

**** Co-Author, Department of Industrial and Management Systems Engineering, Kyung Hee University (yjkim@khu.ac.kr)

***** Corresponding Author, Department of Industrial and Management Systems Engineering, Kyung Hee University(jyjung@khu.ac.kr)

Received: 2018-03-29, Review completed: 2018-05-02, Accepted: 2018-05-16

monitoring method for diagnosing the failure of the rotating machines by analyzing the vibration signal of the bearing. From the collected signal data, the normal states are trained, and then normal or abnormal state data are classified based on the trained normal state. For preprocessing, a Hamming window is applied to eliminate leakage generated in this process, and the cepstrum analysis is performed to obtain the original signal of the signal data, called the formant. From the vibration data of the IMS bearing dataset, we have extracted 6 statistic indicators using the cepstral coefficients and showed that the application of the Mahalanobis distance classifier can monitor the bearing status and detect the failure in advance.

키워드 : 베어링 고장 진단, 신호처리, 켈스트럼 분석, 해밍 윈도우, 마할라노비스 거리
Bearing Fault Diagnosis, Signal Processing, Cepstrum Analysis, Hamming Window, Mahalanobis Distance

1. 서 론

오늘날 제조업은 새로운 기술과 고도의 지능화된 시스템의 등장으로 인해 기계 시스템이 점점 발전해 나아가고 있는 한편 그에 따른 불확실성과 복잡성 역시 크게 증가하고 있는 추세이다[4]. 제조설비들은 다양한 장치들이 결합되면서 점점 복잡해지고 있으며, 설비가 노후화되면 고장에 취약해지고 유지보수가 어렵기 때문에, 생산성, 가용성, 안전성 향상을 위한 예지보전 기술의 필요성이 대두되고 있다[5].

일반적인 회전기기에서 발생하는 많은 문제들은 베어링이나 기어, 회전축 등에 의하여 발생하며, 이러한 결함들은 진동이나 소음과 같은 신호 데이터를 통하여 이상 징후를 감지할 수 있다[8]. 이를 위하여 다양한 센서로부터 들어오는 신호들을 수집하고 분석하여 설비의 실시간 상태를 확인함으로써 고장을 사전에 예방할 수 있고 설비들을 장기간 안정적으로 사용할 수 있다[2].

본 연구에서는 진동 신호 데이터를 분석하여 회전 기기의 상태를 모니터링 할 수 있는 방법

을 소개한다. 특히, 정상상태 데이터로부터 구축된 마할라노비스 공간(Mahalanobis space)을 기준으로 시스템의 상태를 평가함으로써 이상상태를 진단하는 마할라노비스 거리 분류기(Mahalanobis distance classifier)를 사용한다. 나아가 신호 데이터를 처리하는 기법들을 적용하여 마할라노비스 거리 분류기에 적용하여 이상상태 감지 성능이 획기적으로 향상되는 것을 보여준다.

본 논문의 제 2장에서는 설비고장예지에 대한 관련 연구를 기술한다. 제 3장에서는 마할라노비스 거리를 이용한 신호처리 기반의 설비고장예지 방법을 소개하고, 제 4장에서는 제시된 기법을 이용하여 베어링 데이터를 이용한 실험 성능 및 전처리 비교 분석 결과를 제시한 후, 제 5장에서 결론을 기술하였다.

2. 관련 연구

설비 이상에 관한 예지보전에 관련한 선행 연구를 살펴보면 인공신경망(artificial neural

networks), 선형판별분석(linear discriminant analysis), 주성분 분석(principal component analysis), 마할라노비스 거리 분류기(Mahalanobis distance classifier), 로지스틱 회귀 분석(logistic regression) 등 다양한 데이터마이닝 분석 기법을 이용한 이상 진단 기법이 제시되었고, 이들 중 마할라노비스 거리 분류기는 다른 분석 기법들에 비해 우수한 성능을 보여주고 있다[3].

기존 연구에서는 정상적으로 동작하는 회전 장치에 물리적인 힘을 가해 인위적으로 비정상 데이터를 생성하여 이상 진단을 구현하기도 하였다[8]. 그러나 이러한 인위적인 이상상태 데이터는 실제 환경의 다양한 이상상태를 정확하게 반영하기 힘들기 때문에 현실을 반영하는데 한계가 있다.

본 연구에서는 정상상태를 기준으로 마할라노비스 공간을 구축하여 거리를 측정하는 방식으로 진동 기반 설비 이상 진단을 수행하고자 하며, 이를 위하여 몇 가지 신호처리 기법들을 전처리에 적용하여 효과를 검증하였다. 특히 본 연구에서는 실제 고장이 발생된 베어링 진동 공개데이터를 시간에 따라 정상상태와 이상상태로 분류하고 데이터의 특성에 맞는 적절한 전처리 기법을 적용하고 마할라노비스 거리 분류기를 적용함으로써 예지보전의 정확도를 향상시켰다.

3. 이상감지 시스템

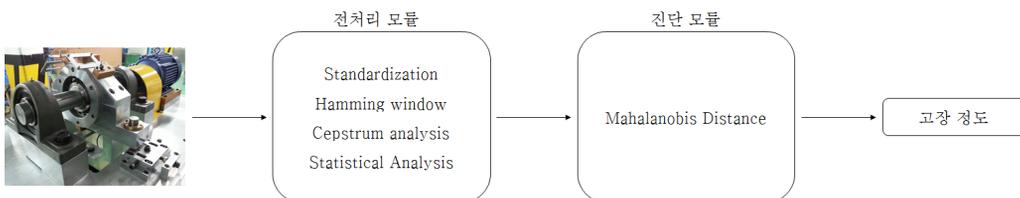
3.1 데이터 수집

베어링 장비에 부착된 센서를 통해 베어링의 진동, 소음 신호를 측정하고 수집한다. 수집된 신호 데이터는 전처리 모듈에서 신호처리 기술을 적용하여 진단에 용이한 형태로 변환된다. 전처리 모듈은 <Figure 1>과 같이 표준화(standardization), 해밍 윈도우(Hamming window), 캡스트럼 분석(cepstrum analysis), 통계지표(statistical indicators) 추출의 단계로 진행된다. 진단 모듈에서는 전처리된 신호 패턴을 분석하여 현재 상태를 파악하고 고장유무를 판정하는 진단 및 모니터링 작업을 수행한다. 본 논문에서는 마할라노비스 거리 분류기를 이용하며, 해당 설비가 정상적인 상태에서 얼마나 멀어지고 있는지를 마할라노비스 거리로 측정하여 각 상태의 고장유무를 판단한다.

3.2 신호 데이터 전처리

3.2.1 데이터 표준화

길이가 N 인 신호 데이터의 i 번째 관찰값 x_i 에서 관찰값들의 평균인 \bar{x} 를 빼고 이를 표준편차 σ 로 나누어 신호 데이터의 신호 데이터의 i 번째 관찰값을 z_i 로 표준화 시킬 수 있다.



<Figure 1> Overall Framework for Condition Monitoring System

$$z_i = \frac{x_i - \bar{x}}{s}, i = 1 \dots N \quad (1)$$

3.2.2 해밍 윈도우 및 켈스트럼 분석

연속된 데이터를 임의로 구간화하는 과정에서 발생하는 불연속적인 양, 즉 누설오차(leakage)를 제거하기 위해 해밍 윈도우를 적용할 수 있다. 즉, 추출된 신호 데이터의 길이가 정확히 신호주기의 정수배인 경우에는 정확한 주파수 도메인, 즉, 스펙트럼을 얻을 수 있지만, 그렇지 않을 경우 양 끝단의 불연속으로 인한 오차가 발생한다. 이를 제거하기 위해 중심에서 양끝으로 갈수록 신호 데이터가 0에 가까운 값으로 변환하는 윈도우 함수를 적용하면, FFT 결과에서 더 정확한 스펙트럼을 얻을 수 있다[10]. 본 연구에서는 이러한 데이터 누설효과를 최소화하기 위하여 해밍 윈도우를 적용하며, 적용된 식은 (2)와 같다. N은 윈도우의 길이를 나타낸다.

$$w_i = 0.54 - 0.46 \cos \frac{2\pi i}{N} \quad (2)$$

켈스트럼 분석은 고속 푸리에 변환(fast Fourier transformation: FFT)을 적용하여 주파수 영역(frequency domain)으로 표시된 신호의 로그 스케일을 푸리에 역변환(Inverse FFT)하는 방법이다. 시간축 상에서 일반적인 충격 신호에 대한 응답은 입력 신호와 전달함수가 합성(convolution)되어 복잡한 형태의 신호로 나타나는데, 이때 켈스트럼 분석을 적용하면 입력 신호의 파형과 응답을 구현하는 전달함수를 분리할 수 있다. 켈스트럼을 적용함으로써 로그 함수가 두 개의 곱으로 형성된 함수를 합으로 분리하여 나타냄으로써 주파수 영역으로 변환된 신호의 크기와 위상을 분리할 수 있다.

3.2.3 통계적 지표 추출

시계열 데이터의 특성을 효과적으로 반영하기 위하여 알려진 6가지 통계 기반의 상태지표(condition indicators)를 이용하였고, 각 지표의 측정 방법은 <Table 1>에 나타내었다.

<Table 1> Statistical Indicators

Statistics	Formula	Description
Root Mean Square	$x_{rms} = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}$	A square root of mean square on time series value
Peak-to-Peak	$x_{ptp} = x_{\max} - x_{\min}$	The change between highest value and lowest value on time series
Crest factor	$x_{crest} = \frac{x_{ptp}}{x_{rms}} = \frac{x_{\max} - x_{\min}}{\sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2}}$	The peak-to-peak of the time series value divided by the RMS value
Skewness	$x_{skew} = \frac{\frac{1}{n} \sum_{i=1}^n x_i^3}{\sigma^3}$	Measure of the asymmetry of the measured value
Kurtosis	$x_{kurt} = \frac{\frac{1}{n} \sum_{i=1}^n x_i^4}{\sigma^4}$	Measure about how much data is concentrated at the center on time series
Standard Deviation	$x_{sd} = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2}$	Measure that is used to quantify the amount of variation

3.3 마할라노비스 거리 기반의 이상감지 기법

본 연구에서는 구간별 신호 데이터로부터 추출된 통계적 지표로 구성된 벡터에 대하여 마할라노비스 거리를 측정하여, 해당 구간의 이상상태 여부를 판정하게 된다.

마할라노비스 거리(Mahalanobis distance)는 군집 분석에서 자주 쓰이는 거리 척도로, 다변량 데이터에서 변수 간의 상관관계가 존재할 때 공분산 행렬을 활용한 데이터 표준화를 거쳐서 거리를 측정한다. 나아가 마할라노비스 거리 분류기는 훈련 데이터로부터 마할라노비스 공간을 미리 구성한 후, 임의의 데이터에 대하여 그 공간과의 거리를 측정하여 거리에 따라 훈련 데이터와 동일 클래스 여부를 판정하는 기법이다[3].

3.3.1 정상상태 마할라노비스 공간 구성

본 연구에서는 이상상태 감지를 위하여 먼저 정상상태 훈련 데이터를 이용하여 마할라노비스 공간을 구성한다. 정상상태 데이터의 개수를 n 이고 통계적 지표의 개수가 k 라고 할 때, i 번째 데이터의 j 번째 통계적 지표값 x_{ij} 은 식 (3)과 같이 그 통계적 지표들의 평균인 \bar{x}_j 를 빼고 그 표준편차 s_j 로 나누어 표준화할 수 있다.

$$z_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}, i = 1 \dots n, j = 1 \dots k \quad (3)$$

그리고 통계적 지표 간의 공분산행렬(covariance matrix) C 를 활용하여, i 번째 데이터의 마할라노비스 거리 D_i 를 식 (4)와 같이 계산할 수 있다.

$$D_i^2 = \frac{1}{k} Z_i^T C^{-1} Z_i, i = 1 \dots n \quad (4)$$

여기서 k 는 통계적 지표의 개수를 의미하고, $Z_i = (z_{ij})$ 는 i 번째 데이터의 표준화 벡터, Z_i^T 는 Z_i 의 전치행렬, C^{-1} 은 공분산행렬의 역행렬을 나타낸다.

일반적으로 정상상태의 마할라노비스 공간이 적절히 구축되었다면, 정상상태 데이터들의 마할라노비스 거리는 보통 0~2범위 안에 분포하며 평균은 1에 근사하게 되어서 이를 마할라노비스 단위 공간(Mahalanobis unit space)이라고도 부른다[3].

3.3.2 마할라노비스 거리 계산

테스트 데이터의 마할라노비스 거리는 다음과 같이 측정할 수 있다. 테스트 데이터 y_{ij} 에서 정상상태의 지표 평균 \bar{x}_j 를 빼고 표준편차 s_j 를 통해 표준화시킨다.

$$w_{ij} = \frac{y_{ij} - \bar{x}_j}{s_j}, i = 1 \dots m \quad (5)$$

다음으로 정상상태의 공분산행렬을 이용하여 마할라노비스 거리를 아래의 식을 통해 계산한다.

$$D_i^2 = \frac{1}{k} W_i^T C^{-1} W_i, i = 1 \dots m \quad (6)$$

만약 정상상태로부터 구한 마할라노비스 공간이 유효하다면 이상상태의 마할라노비스 거리는 정상상태의 마할라노비스 거리보다 매우 크게 나타난다. 일반적으로 2 이상이면 정상상태에서 벗어난다고 판정한다[3].

4. 실험

본 논문에서는 University of Cincinnati에서 제공하는 IMS(Intelligent Maintenance System) 베어링 결함 데이터를 대상으로 상태 모니터링 및 고장 사전감지를 위한 실험을 수행하였다. 이 데이터를 통하여 제시된 기법의 성능 평가를 위하여 세 가지 실험 계획을 수립하였다. 첫 번째 실험은 데이터를 전처리 과정을 거치지 않고 고장 유무를 진단하였고, 두 번째 실험에서는 단순히 표준화 과정만을 수행한 이후 상태를 진단하였다. 마지막 실험은 논문에서 제시한 상태 모니터링 기법에 따라서 표준화, 해밍 윈도우, 캡스트럼 분석을 모두 수행한 데이터로 장비상태를 진단하고 이를 비교하였다.

4.1 데이터 및 실험 설계

본 연구에서 사용된 데이터는 베어링 테스트 조정장치의 센서를 통해 베어링 진동 관측값이 10분 간격으로 기록되어 있다. 해당 장치의 축의 회전속도는 2,000PRM, 반지름 방향으로 6,000lbs의 하중이 가해졌으며, 1초 동안 20,480개(20 kHz)의 진동값이 10분 간격으로 기록되었다. 진단 시스템의 구축을 위해 4개의 베어링 중 정상 및 이상상태 식별이 가능한 첫 번째 베어링의 실험 데이터를 사용하였다.

본 연구에서는 수집된 데이터를 시간 순서로 총 40개 구간의 데이터셋으로 나누고, 진동신호의 이상상태가 발견되기 시작하는 시점을 기준으로 24개의 훈련용 정상상태 데이터셋(T1~T24)과 4개의 테스트용 정상상태 데이터셋(N1~N4), 그리고 12개의 테스트용 이상상태 데이터셋(A1~A12)으로 구분하여 실험에 사용하였다.

4.2 실험 결과

4.2.1 실험 1-표준화하지 않은 실험

산업장비로부터 수집된 시계열 진동 신호 데이터를 표준화 등의 전처리 없이 정상상태의 훈련 데이터로 마할라노비스 공간을 구성하고, 테스트 데이터들의 진단 성능을 확인하였다. 마할라노비스 공간을 기준으로 정상상태 훈련 데이터의 마할라노비스 거리, 테스트 데이터의 마할라노비스 거리를 측정된 결과는 <Table 2>, <Table 3>와 같다.

일반적으로 마할라노비스 거리값은 0~2사이이면 마할라노비스 공간과 유사한 통계적 공간에 존재한다고 판단한다. <Table 2>를 보면 정상상태인 훈련 데이터(T1~T24) 중 T1, T24가 마할라노비스 거리가 2를 약간 초과하는 결과를 보였으며, 이는 정상상태의 마할라노비스 공간에 대한 신뢰도가 낮다고 볼 수 있다.

<Table 2> Mahalanobis Distance of Training Data without Preprocessing

Training data(24 normal data)											
T1	2.1989	T5	0.3302	T9	0.9074	T13	1.3262	T17	0.1973	T21	0.7737
T2	0.2460	T6	0.3485	T10	0.7468	T14	0.7181	T18	0.1973	T22	1.0057
T3	0.1266	T7	1.0261	T11	0.9253	T15	0.3458	T19	0.1561	T23	1.9129
T4	0.2590	T8	1.4739	T12	0.3202	T16	0.9966	T20	0.1822	T24	2.4461

〈Table 3〉 Mahalanobis Distance of Test Data without Preprocessing

Test data(4 normal data and 12 abnormal data)							
N1	2.4858	A1	383.1564	A5	82.7521	A9	301.7465
N2	4.6849	A2	346.8526	A6	247.7782	A10	62.3294
N3	9.2762	A3	231.4498	A7	223.9317	A11	251.2914
N4	17.3637	A4	23.5781	A8	226.8779	A12	15025.3466

〈Table 4〉 Mahalanobis Distance of Training Data with Standardization

Training data(24 normal data)											
T1	1.8333	T5	0.6769	T9	0.7873	T13	0.2865	T17	2.0412	T21	0.9078
T2	0.5258	T6	0.2696	T10	0.4174	T14	0.4456	T18	0.3162	T22	1.5891
T3	0.2811	T7	0.4399	T11	0.4820	T15	0.9006	T19	0.2280	T23	1.0175
T4	1.4807	T8	1.2384	T12	1.1298	T16	0.6400	T20	0.8400	T24	0.3921

〈Table 5〉 Mahalanobis Distance of Test Data with Standardization

Test data(4 normal data and 12 abnormal data)							
N1	4.7114	A1	630.6310	A5	94.7669	A9	322.4844
N2	1.4352	A2	280.3135	A6	197.8018	A10	70.6552
N3	2.1584	A3	197.6309	A7	5.4556	A11	152.0583
N4	18.9765	A4	13.3083	A8	228.4830	A12	112.2298

〈Table 3〉에서 이상상태의 테스트 데이터 12개(A1~A12)는 모두 2 이상의 마할라노비스 거리로 측정되어 이상상태라고 분류가 되었으나, 4개의 정상상태 테스트 데이터(N1~N4)도 모두 마할라노비스 거리가 2를 초과하여 정상적으로 분류되지 못했다.

4.2.2 실험 2-표준화만 적용한 실험

데이터 표준화만의 전처리 과정을 거친 훈련 데이터 및 테스트 데이터로 실험한 결과는 〈Table 4〉, 〈Table 5〉와 같다.

표준화 작업만을 거친 정상상태 훈련 데이터(T1~T24)의 경우, 마할라노비스 거리가 역시 0~2사이로 나와야 하지만, 〈Table 4〉에서 T17의 경우 마할라노비스 거리가 2를 초과하

는 결과를 보여서, 마할라노비스 공간에 대한 신뢰도가 떨어진다.

그리고 〈Table 5〉에서 이상상태 테스트 데이터(A1~A12)의 마할라노비스 거리는 대부분 2 이상으로 측정되었으나 A7구간의 거리가 2 미만으로 측정되었다. 또한, 정상상태 테스트 데이터(N1~N4)는 4구간 중 3구간의 거리가 2 이상으로 정확하게 진단하지 못하였다.

4.2.3 실험 3-제시된 방법

제 3장에서 설명한 바와 같이 진동 신호 데이터의 전처리 단계에서 표준화, 해밍 윈도우, 캡스트럼 분석을 모두 거친 이용한 실험 결과를 〈Table 6〉, 〈Table 7〉에 제시하였다.

<Table 6> Mahalanobis Distance of Training Data with Standardization, Hamming Window, and Cepstrum

Training data(24 normal data)											
T1	0.0229	T5	0.1234	T9	0.0833	T13	0.3436	T17	0.2843	T21	1.2630
T2	0.0485	T6	1.7086	T10	0.1892	T14	0.0159	T18	0.2853	T22	0.7461
T3	0.2888	T7	0.1709	T11	0.0690	T15	0.0375	T19	0.1899	T23	0.3304
T4	0.1427	T8	0.2540	T12	0.0379	T16	0.0320	T20	0.2199	T24	0.7793

<Table 7> Mahalanobis Distance of Test Data with Standardization, Hamming Window, and Cepstrum

Test data(4 normal data and 12 abnormal data)							
N1	1.5489	A1	26.9808	A5	15.2015	A9	473.5843
N2	0.7587	A2	141.9984	A6	31.5595	A10	464.3511
N3	0.8766	A3	80.6922	A7	142.6638	A11	448.4148
N4	0.8384	A4	25.4212	A8	119.4029	A12	691.3534

<Table 8> Comparison of Error Rates Among Three Preprocessing Experiments

Preprocessing	Training error rate (normal states(24))	Test error rate	
		normal states(4)	abnormal states(12)
none	8.3%(2/24)	100%(4/4)	0%(0/12)
standardization	4.2%(1/24)	75%(3/4)	0%(0/12)
standardization+Hamming window+cepstrum	0%(0/24)	0%(0/4)	0%(0/12)

<Table 6>에서 24개 정상상태 훈련 데이터(T1~T24)의 마할라노비스 거리를 측정할 결과, 마할라노비스 거리가 모두 0~2사이로 적절히 분포하였음을 확인할 수 있다.

<Table 7>에서 12개 이상상태 테스트 데이터(A1~A12)의 마할라노비스 거리가 2 이상으로 잘 분류가 되었고, 또한 4개 정상상태 테스트 데이터(N1~N4)의 거리도 모두 0~2 사이로 정확히 분류되었음을 확인할 수 있었다.

4.3 실험 결과 비교

본 연구에서는 정상상태의 데이터셋으로부터

통계적 지표들을 추출하여 마할라노비스 공간을 구축한 후, 정상상태와 이상상태를 분류하는 단일 클래스 분류 기법을 사용한다. 특히, 이를 위한 전처리 단계를 세 가지로 구분하여 실험을 수행하였다. 구축된 마할라노비스 공간과의 거리가 2 이상인 경우에 이상상태로 분류하며, 세 가지 전처리 실험에서의 오차율을 <Table 8>과 같았다. 전처리를 하지 않은 실험과 표준화만을 수행한 실험에서는 학습용 정상상태의 마할라노비스 거리가 2 이상으로 나타난 구간이 각각 2개, 1개씩 있어서 마할라노비스 공간이 제대로 구축되지 않았을 뿐만 아니라, 훈련용 정상상태의 오차율이 각각 100%와

75%로 성능이 매우 저조하였다.

반면에 표준화와 해밍 윈도우, 캡스트럼을 모두 적용한 실험에서는 학습용 정상상태의 마할라노비스 공간이 제대로 구성이 되어 오차율이 0%였으며, 훈련용 정상상태 및 이상상태 데이터 모두 마할라노비스 거리 2를 기준으로 완벽하게 분류가 되어, 오차율이 모두 0%로 측정됨을 확인할 수 있었다. 이는 해밍 윈도우를 통한 데이터의 누설오차 방지, 캡스트럼 분석을 통한 노이즈 제거 및 원신호 분리가 효과적으로 수행되어 베어링 결함 감지의 성능을 높일 수 있음을 보여주었다.

5. 결론 및 추후 연구

IMS 베어링 데이터셋을 활용하여 이상감지 실험을 수행하면서 세 가지 전처리 실험을 비교 분석함으로써, 본 연구에서 제안하는 이상감지 방법의 성능이 우수함을 확인하였다. 특히, 제안된 이상 진단 방법은 실험 장치에 물리적인 힘을 가해 인위적으로 비정상 데이터를 생성하지 않고도 정상상태 데이터만을 이용하여 이상상태를 감지할 수 있다는 측면에서 의미가 있다.

본 연구의 결과는 베어링 데이터뿐만 아니라 산업 현장에서 다양한 진동 기반 설비 이상감지에 확대 적용할 수 있을 것으로 예상된다. 나아가 측정된 변수들 중에서 불필요한 변수를 제거한 후 마할라노비스 거리를 계산하는 방법인 마할라노비스 다구찌 시스템을 적용하여 보다 안정적인 진단 시스템을 구축할 수 있을 것으로 예상된다.

References

- [1] Alejandro, D., Mejia, T., Medjaher, K., Zerhouni, N., and Tripot, G., "A Data-Driven Failure Prognostics Method Based on Mixture of Gaussians Hidden Markov Models," *IEEE Transactions on Reliability*, Vol. 61, No. 2, pp. 491-501, 2012.
- [2] Jeon, B. C., Jung, J. H., Youn, B. D., Kim, Y. W., and Bae, Y. C., "Evaluation of Datum Unit for Diagnostics of Journal-Bearing Systems," *Transactions of the Korean Society of Mechanical Engineers*, Vol. 39, No. 8, pp. 801-806, 2015.
- [3] Lee, S. H. and Lim, G., "Performance Comparison of Mahalanobis-Taguchi System and Logistic Regression-A Case Study," *Journal of the Korean Institute of Industrial Engineers*, Vol. 39, No. 5, pp. 393-402, 2013.
- [4] Lee, S. H. and Yoon, B. D., "Industry 4.0 and direction of prognostics and health management (PHM)," Vol. 25, No. 2-4, pp. 351-357, 2015.
- [5] Lim, H. J., Kim, S. D., Jung, S. H., Hong, S. W., Oh, G. H., and Park, J. H., "Analysis of Vibration Signal for Failure Diagnosis of Rotating Devices," *Proceedings of Korean Society of Precision Engineering Spring Conference*, pp. 301-307, 1995.
- [6] Paik, Y. S., Mok, Y. J., Lee, S. J., and Lee, Y. B., "Data Processing of Vibration Records and Its Application," *Journal of the Korean Society of Civil Engineers*, Vol.

- 16, Vol. 2-4, No. III-4, pp. 351-358, 1995.
- [7] Park, C. S. and Youn, D. J., "A Noise Reduction Signal Processing for Online Monitoring: Minimum Variance Cepstrum," *Journal of the Korean Society for Non-destructive Testing*, Vol. 31, No. 6, pp. 671-676, 2011.
- [8] Park, S. G., Park, W. S., Jung, J. E., Lee, Y. Y., and Oh, J. E., "A Fault Diagnosis on the Rotating Machinery Using Mahalanobis Distance," *Transactions of the Korean Society of Mechanical Engineers*, Vol. 32, No. 7, pp. 556-560, 2008.
- [9] Yang, J. H. and Kwon, O. K., "Model-based Fault Diagnosis Applied to Vibration Data," *Journal of Institute of Control, Robotics and Systems*, Vol. 18, No. 12, pp. 1090-1095, 2012.

저 자 소개



송예원
2014년
2015년
2017년~현재
관심분야

(E-mail: ywsong92@khu.ac.kr)
경희대학교 산업경영공학과 (학사)
경희대학교 산업경영공학과 (석사)
수산아이엔티 서비스사업팀
지능형시스템설계, 진단시스템, 데이터마이닝, 빅데이터분석



이홍성
2012년~현재
관심분야

(E-mail: fraud9204@naver.com)
경희대학교 산업경영공학과 학부생
데이터 마이닝, 빅데이터분석, 인공지능



박훈석
2014년
2018년
2018년~현재
관심분야

(E-mail: hoonseok@khu.ac.kr)
경희대학교 산업경영공학과 (학사)
경희대학교 산업경영공학과 (석사)
경희대학교 산업경영공학과 박사과정
기계학습, 빅데이터분석, 스마트팩토리



김영진
1982년
1984년
1991년
1997년~2017년
관심분야

(E-mail: yjkim@khu.ac.kr)
서울대학교 기계설계공학과 (학사)
서울대학교 기계설계공학과 (석사)
University of California, Berkeley 기계공학 (박사)
경희대학교 산업경영공학과 교수
지능형시스템설계, 진단시스템, CAD/CAM



정재윤
1999년
2001년
2005년
2005년~2006년
2006년~2007년
2007년~현재
관심분야

(E-mail: jyjung@khu.ac.kr)
서울대학교 산업공학과 (학사)
서울대학교 산업공학과 (석사)
서울대학교 산업공학과 (박사)
네덜란드 아인트호벤공대 초빙연구원
유비쿼터스컴퓨팅 원천기술개발지원센터
경희대학교 산업경영공학과 부교수
스마트 팩토리, 빅데이터분석, 프로세스 마이닝