

# Fault Detection and Diagnosis of Rotating Machinery Based on Universal Feature Extraction and Selection

## 보편적 특징의 추출 및 선택에 기반한 회전체 기계의 고장 검출 및 진단

Min-Ki Kim<sup>1</sup>

김민기<sup>1</sup>

<sup>1</sup> Professor, Dept. of Computer Science, Engineering Research Institute, Gyeongsang National University, Korea, [mkkim@gnu.ac.kr](mailto:mkkim@gnu.ac.kr)

**Abstract:** Since most mechanical equipment includes rotating machines, rapid failure detection and diagnosis of rotating machinery is essential to manage mechanical equipment to operate normally. Traditional signal processing methods have the inconvenience of having to analyze the data characteristics of the domain and extract valid features manually every time the domain changes in order to diagnose a specific machine failure. In contrast, the methods using deep learning automatically extract valid features regardless of the domain, but they face the challenge of securing a large amount of data to train a deep neural network. In this study, we extract universal features widely used in traditional signal processing methods and apply the Relief-F algorithm to automatically select valid features. Finally input them into a shallow multi-layer perceptron (MLP) classifier, which can be trained with relatively little training data, to detect and diagnose machine failures regardless of the domain. As a result of applying the proposed method to the MaFaulDa dataset, it showed an accuracy of 99.95% for both fault detection and diagnosis when using a 256-dimensional feature vector. Even when the feature vector was reduced to 64 dimensions, the fault detection and diagnosis accuracy were 99.75% and 99.65%, respectively. These results show that the proposed method is effective in detecting and diagnosing failures in rotating machinery.

**Keywords:** Rotating Machinery, Fault Detection and Diagnosis, Relief-F Algorithm, Multi-Layer Perceptron (MLP)

**요약:** 기계 설비는 대부분 회전하는 기계를 포함하고 있으므로, 기계 설비가 정상적으로 동작하도록 관리하기 위해서는 회전체 기계에 대한 신속한 고장 검출 및 진단이 필수적이다. 전통적인 신호 처리 방식은 특정한 기계의 고장을 진단하기 위하여 도메인이 바뀔 때마다 해당 도메인의 데이터 특성을 분석하고 연구자가 수작업으로 유효한 특징을 추출해야 하는 번거로움이 있다. 이에 반하여 딥 러닝을 이용한 방식은 도메인에 무관하게 자동으로 유효한 특징을 추출하는데 비하여 심층신경망을 학습시키기 위하여 다량의 데이터를 확보해야 하는 과제를 안고 있다. 본 연구에서는 전통적인 신호 처리 방식에서 널리 사용되는 보편적인 특징들을 추출한 후 Relief-F 알고리즘을 적용하여 유효한 특징을 자동으로 선별하였다. 이렇게 추출된 특징을 상대적으로 적은 학습데이터로 학습시킬 수 있는 깊이가 얇은 다층퍼셉트론(MLP) 분류기에 입력하여

Received: August 09, 2023; 1<sup>st</sup> Review Result: September 11, 2023; Accepted: November 25, 2023

도메인에 무관하게 기계의 고장을 검출 및 진단할 수 있는 방법을 제안한다. 제안한 방법을 MaFaulDa 데이터세트에 적용하여 실험한 결과 256차원의 특징 벡터를 사용하였을 때 고장 검출과 진단 모두 99.95%의 정확도를 보였다. 특징 벡터를 64차원으로 줄인 경우에도 고장 검출과 진단 정확도는 각각 99.75%, 99.65%를 보였다. 이러한 결과는 제안한 방식이 회전체 기계의 고장 검출 및 진단에 효과적임을 보여준다.

**핵심어:** 회전체 기계, 고장 검출 및 진단, Relief-F 알고리즘, 다층퍼셉트론

## 1. 서론

정보통신기술과 IoT장비들의 보급이 확대되면서 공장 자동화에 대한 수요가 증대되고 있고, 근로 환경이나 안전상의 문제로 기존에 근로자가 수행하던 작업들을 로봇이 처리할 수 있도록 여러 영역에서 기계 설비의 도입이 늘어나고 있다. 기계의 사용 범위가 확대되고, 기능이 고도화됨에 따라 여러 장치들이 서로 유기적으로 연결되어 기계 설비들의 복잡도가 높아지고 있다. 이에 따라 한 개의 장치라도 고장이 발생하면 전체 시스템에 커다란 피해로 이어지게 된다. 기계 설비는 대부분 기어(gear), 샤프트(shaft), 베어링(bearing), 회전자(rotor) 등과 같은 회전하는 기기들을 포함하고 있는데, 이들은 운용 중에 발생하는 진동으로 인하여 시간이 경과함에 따라 축 정렬 불량, 베어링 불량, 질량 불균형 등과 같은 고장이 발생하게 된다. 따라서 회전체 기계에 대한 신속한 고장 검출 및 진단은 기계 설비가 정상적으로 동작하도록 관리하는데 필수적이다.

회전체 기계의 고장을 실시간으로 진단하기 위하여 센서로 획득한 시계열 진동 데이터를 이용하는 기계학습(machine learning) 방식이 많은 연구자들의 관심을 받고 있다[1-3]. 기계의 고장을 검출하는 문제는 고장 유무를 판단하는 두 클래스 분류(two-class classification), 고장을 진단하는 문제는 고장의 유형을 찾아내는 다중클래스 분류(multi-class classification)의 문제로 생각할 수 있다. 기계학습을 이용한 분류는 데이터의 전처리, 특징추출, 분류기 학습의 단계로 나누어 볼 수 있다. 전처리는 특징 추출의 효율성 및 효과성을 향상시키기 위해 특징 추출의 앞단에서 수행되는 제반 작업으로, 보통 신호에 포함된 노이즈(noise) 제거, 신호의 분할(segment), 정규화(scaling) 작업을 수행한다[4]. A. Alzghoul 외[5]는 클래스별 데이터의 불균형을 해소하기 위하여 전처리 과정에서 오버 샘플링을 수행하였으며, Kim 외[6]는 전처리를 통해 서로 다른 입력 패턴 공간을 공통의 공간으로 변환하여 고장 진단의 정확도를 향상시키는 방법을 제시하였다.

기계학습을 기반으로 기계의 고장을 검출 및 진단하는 연구들은 이에 적합한 특징을 추출하는데 많은 노력을 기울여 왔다. 고장 진단을 위해 L. Hong 외[7]은 DTW(dynamic time warping)를 이용하여 두 시계열 데이터의 잔차신호(residual signal)를 생성한 후 이에 대한 RMS(root mean square)와 상관 첨도(correlated kurtosis) 특징을 시간 영역(time-domain)에서 추출하였고, Ribeiro 외[8]는 회전체의 회전 주파수  $f_r$  을 추정하는 알고리즘[9]를 이용하여  $f_r$ ,  $2f_r$ ,  $3f_r$ 에 해당하는 주파수에서의 스펙트럼 값과 평균, 분산, RMS 등 12개의 통계적 특징을 포함한 19개 특징을 추출하였다. Pandya 외[10]는 웨이블릿 패킷 변환으로 진동 신호를 5단계의 분할을 통해 수평, 수직 양 방향으로 에너지와

첨도(kurtosis)를 추출한 후 상관관계를 기반으로 특징을 선택하여 다층퍼셉트론(MLP)를 통해 고장 유형을 분류하였다.

위에서 제시한 연구들은 도메인에 따라 연구자들이 해당 데이터의 특성을 분석하여 고장 진단에 적합한 특징들을 수작업으로 도출해내는 방식이다. 이에 비하여 컴퓨터비전과 언어처리 분야에서 두드러진 성능 향상을 보인 딥 러닝(deep learning) 기술을 적용한 고장 진단 방식은 적용 영역에 무관하게 유효한 특징을 자동으로 추출하고 분류까지 연속적으로 수행하는 장점이 있다[11]. Jing 외[12]는 시간 영역의 원천 신호(raw signal), 주파수 영역으로 변환한 신호, 그리고 이 둘을 결합한 신호 3종에 대하여 합성곱 신경망(CNN)으로 특징을 추출하고 고장을 진단한 결과 주파수 영역으로 변환한 신호를 이용한 방식이 가장 좋은 성능을 나타냈다. CNN을 구성하는 합성곱 층(convolution layer)의 개수가 늘어나면 파라미터의 개수가 늘어나 더 많은 학습 데이터가 요구되기 때문에 제한된 학습 데이터로 고장 진단의 정확도를 유지하면서 작은 모델을 만들기 위해 Yan 외[13]는 깊이우선 분리합성곱 연산과 공간적으로 분리가 가능한 합성곱 연산으로 경량 CNN(lightweight CNN)을 구성하였다. 기존 연구들이 1차원 시계열 데이터를 CNN의 입력으로 사용한 것과는 달리 Wang 외[14]는 1차원 신호를 2차원 신호로 변환하여 CNN에 입력하였고, 10개의 합성곱 층을 구성하면서 발생하는 기울기 소실(gradient vanishing) 문제를 해결하기 위하여 항등 사상(identity mapping)을 적용하였다.

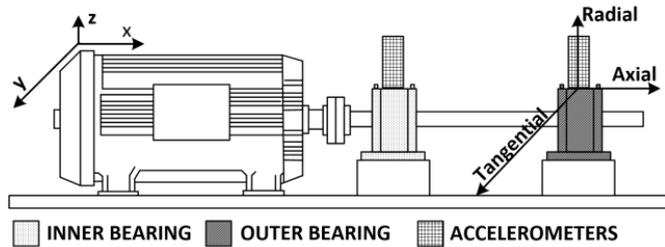
전통적인 신호 처리 방식은 특정한 기계의 고장을 진단하기 위하여 도메인이 바뀔 때마다 해당 도메인에서의 데이터 특성을 분석하고 연구자가 수작업으로 유효한 특징을 추출해야 하는 번거로움이 있다. 이에 반하여 딥 러닝을 이용한 방식은 도메인에 무관하게 자동으로 유효한 특징을 추출하는데 비하여 심층신경망을 학습시키기 위하여 다량의 데이터를 확보해야 하는 단점이 있다. 본 연구에서는 전통적인 신호 처리 방식에서 널리 사용되는 보편적인 특징들을 추출하되 이들 중 유효한 특징을 자동으로 선별하여 기계학습을 기반으로 도메인에 무관하게 고장을 진단할 수 있는 방안을 제시한다. 본 논문의 구성은 다음과 같다. 1장 서론에 이어, 2장에서는 회전체 기계의 고장 검출 및 진단을 위하여 본 연구에서 사용한 공개 데이터세트 MaFaulDa(Machinery Fault Database)[15]에 대하여 기술한다. 3장에서는 신호 처리 및 기계학습에 적용하기 위한 원천 데이터의 전처리 방법, 시간 영역, 스펙트럼 영역, 통계 영역에서 추출한 전통적인 신호 처리 분야에서 널리 사용되어 온 보편적 특징에 대한 간략한 소개, 그리고 이들 특징 집합에서 유효한 특징을 선택하는 방법에 대하여 설명한다. 그리고 다층퍼셉트론(MLP: multi-layer perceptron)으로 구성된 분류기에 대하여 기술한다. 4장에서는 제안된 방법을 구현하여 회전체 기계의 고장 검출 및 진단에 적용한 실험 결과와 분석 내용을 제시하고, 마지막으로 5장에서 결론 및 향후 과제에 대하여 기술한다.

## 2. 데이터세트

회전체 기계에서 발생하는 진동 데이터를 이용하여 기계의 고장을 검출하고 진단하기 위해서는 회전체 기계의 고장 유형별로 진동 데이터를 수집해야 한다. 그러나 실제 기계의 운용 환경에서 고장이 나타날 때까지는 오랜 시간이 걸리기도 하고, 일정 기간내에 다양한 유형의 고장이 나타나는 것을 기대하기도 어렵다. 이러한 이유로 회전체 기계에서 발생하는 진동 데이터를 수집하기 위하여 기계 고장 시뮬레이터(MFS: Machine Fault Simulator)를 이용한다. [그림 1]은 본 연구에서 사용한 MaFaulDa 데이터세트

를 획득하는데 사용한 MFS의 구성을 간략히 제시한 것이다. 모터의 회전축에 연결된 회전체(rotor)는 두 개의 베어링 사이에 위치하고, 각 베어링 위쪽에 부착된 가속도 센서(accelerometer)를 통해 3방향(x, y, z)의 가속도를 계측한다. [그림 1]에는 제시되어 있지 않지만 타코미터(tachometer)와 마이크론을 통해 회전 속도와 소리를 측정한다. MFS로 질량 불균형, 정렬 불량, 베어링 결함을 인위적으로 발생시키고 변속 조건에서 신호를 계측하게 된다.

정상 및 5가지 유형의 고장 상태에서 발생하는 신호를 5초동안 50kHz로 기록하게 된다. [표 1]은 이렇게 수집된 MaFaulDa 데이터세트의 구성을 나타낸 것으로 총 1,951개 파일로 이루어져 있다. 특정 조건에서 계측된 신호는 csv 파일 형식으로 기록되는데, 각 파일은 8개 열, 250,000개 행으로 이루어져 있다. 1열은 타코미터에서 계측한 신호, 2~4열은 안쪽 베어링, 5~7열은 바깥쪽 베어링의 가속도 센서에서 계측한 3방향의 가속도 신호, 8열은 마이크론으로 계측한 소리 신호이다.



[그림 1] 회전체 기계의 진동 데이터 수집을 위한 장치의 구성[16]

[Fig. 1] Configuration of a Device for Collecting Vibration Data of a Rotating Device [16]

[표 1] MaFaulDa 데이터세트의 구성

[Table 1] Configuration of the MaFaulDa Dataset

State	Variation description (No. of measurements)	Sum of measurements
Normal	(49)	49
Imbalance	6g(49), 10g(48), 15g(48), 20g(49), 25g(47), 30g(47), 35g(45)	333
Horizontal misalignment	0.5mm(50), 1.0mm(49), 1.5mm(49), 2.0mm(49)	197
Vertical misalignment	0.51mm(51), 0.63mm(50), 1.27mm(50), 1.40mm(50), 1.78mm(50), 1.90mm(50)	301
Inner bearing faults	Ball fault: 0g(50/49), 6g(49/43), 20g(49/25), 35g(38/20)	558
Outer bearing faults	Cage fault: 0g(49/49), 6g(48/49), 20g(49/49), 35g(42/41) Outer race: 0g(49/49), 6g(49/49), 20g(49/49), 35g(37/41)	513

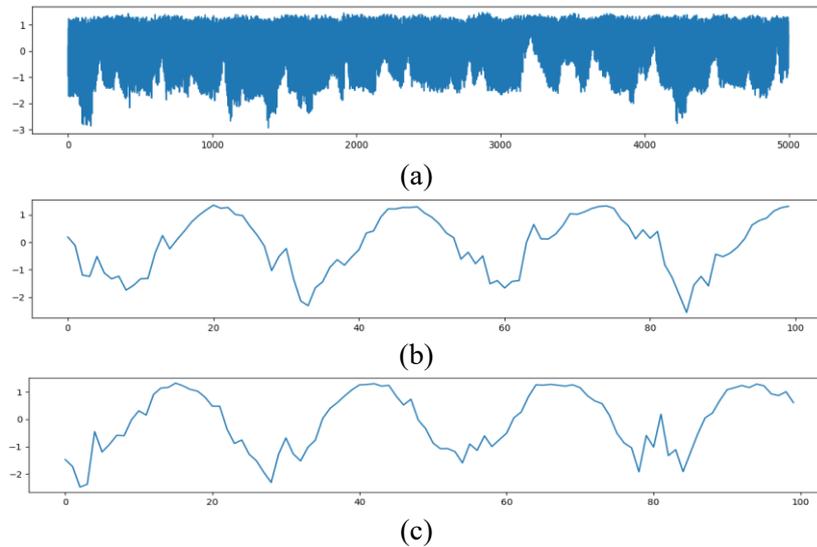
### 3. 고장 검출 및 진단

#### 3.1 전처리

수집된 파일들은 총 8개의 신호로 구성되어 있는데, 본 연구에서는 2개의 가속도 센서에서 계측한 6개 신호만을 사용하였다. 소리는 주변 환경에 따라 영향을 많이 받을 수 있고, 회전 속도와 무관하게 고장을 검출 및 진단하는 것이 필요하기 때문이다. 각 원천 신호(raw signal)는 250,000개의 시계열 값으로 구성되어 있는데, 대개는 계측된

신호의 일부를 샘플링하여 특징 추출에 사용한다. 데이터의 크기가 크면 처리 시간이 길어질 뿐만 아니라 많은 저장 공간이 필요하기 때문에 원천 신호를 축소하여 이용하게 되는데, 이때 원천 신호에 포함된 정보를 손상시키지 않게 샘플링하는 것이 중요하다. 원천 신호에 대한 샘플링 방법이 고장 진단의 정확도에 어떤 영향을 미치는지에 대한 실험 결과[16]에 따르면 원천 데이터를 균등하게 다운 샘플링하는 방식이 시간을 축소하여 원천 데이터의 일부를 그대로 사용하는 샘플링 방식보다 우수한 고장 진단 결과를 보였다. 따라서 본 연구에서는 원천 데이터를 다운 샘플링하는 전략을 택하였다.

5가지 고장 유형별 데이터는 최소 197개에서 최대 558개로 구성되어 있으나 정상 데이터는 49개로 데이터 개수가 불균형하게 분포되어 있다. 기계학습 방식에서 데이터의 불균형은 분류기를 효과적으로 학습시키는데 어려움을 발생시키기 때문에 이러한 데이터의 불균형을 해소하는 방안이 필요하다. 기계가 실제로 운용되는 환경에서는 오히려 고장 상태의 신호를 획득하는 것이 어렵고, 정상 상태에서 신호를 획득하는 것은 용이하다. 이러한 점을 고려할 때 정상 상태에 해당하는 데이터를 확장하여 데이터 불균형의 문제를 해결하는 것이 현실적 여건에 부합되는 방식이다. 본 연구에서는 샘플링 간격을 유지하면서 다운 샘플링의 시작 위치를 변경하여 정상 상태 신호의 개수를 확장하였다. [그림 2]는 1개의 원천 신호로부터 2개의 서로 다른 신호를 생성한 예를 보여주고 있다. (a)는 정상 상태에서 계측한 50kHz의 원천 신호 중 첫 5,000개 값을 도시한 것이고, (b)와 (c)는 샘플링 시작 위치를 달리하여 1kHz로 다운 샘플링한 신호를 제시한 것이다.



[그림 2] 원천 신호와 샘플링 시작점이 다른 두개의 다운 샘플링 신호

[Fig. 2] Raw Signal and its Two Down-sampled Signals with Different Start Position

### 3.2 특징 추출 및 선택

딥 러닝 방식에서는 별도의 특징 추출 과정 없이 전처리된 신호를 심층 신경망의 입력으로 사용하여 특징을 자동으로 추출하고 전연결층을 거쳐 분류를 수행한다. 이 방식은 도메인에 무관하게 자동으로 특징을 추출할 수 있는 장점이 있으나, 심층 신경망을 학습시키기 위해 다량의 학습 데이터를 확보해야 하는 문제를 안고 있다. 정상

상태의 신호는 다량의 데이터를 확보하는데 어려움이 없지만, 실제 환경에서 고장 유형별로 다량의 데이터를 확보하는 것은 현실적으로 매우 어려운 과제이다.

본 연구에서는 다층퍼셉트론(MLP)으로 구성된 신경망을 이용함으로써 상대적으로 적은 데이터를 이용하여 신경망을 효과적으로 학습시킬 수 있다. 이 방식은 먼저 전처리된 신호로부터 유효한 특징을 추출한 후 이것을 MLP에 입력한다. 이 방식을 도메인에 무관하게 적용하기 위해서는 기존에 수작업으로 진행된 특징 추출 과정을 자동화해야 한다. 이 문제를 해결하기 위하여 본 연구에서는 전통적인 신호 처리 방식에서 광범위하게 사용되어온 여러 특징들을 추출하고, 이들 중에서 해당 도메인에 적합한 특징들을 자동으로 선별하여 특징의 차원을 줄이는 방식을 제안한다. 즉 기존 연구들이 특정 도메인에 적합하다고 판단되는 특징을 찾아 최적의 특징집합을 구성하는 방식이라면, 본 연구는 신호 처리에 사용되는 보편적인 특징집합을 구성한 후 특정 도메인에서 유효성이 떨어지는 특징들을 제거하여 최적의 특징집합을 구성하는 방식으로 볼 수 있다. 보편적인 특징집합을 구성하기 위하여 시계열 데이터의 신호 처리에서 널리 사용되는 특징을 제공하는 파이썬 기반의 오픈소스라이브러리 TSFEL[17]를 이용하였다.

TSFEL에서 제공하는 특징들은 시간 영역, 통계 영역, 스펙트럼 영역으로 구분되어 있다. 본 연구에서는 시간 영역에서  $t_i$  시점에 가속도 센서로 측정한 값  $s_i$ 를 이용하여 자기상관(autocorrelation), 무게중심, 엔트로피, 피크 간 거리 등 총 17개 특징을 추출한다. 통계 영역에서는 측정 값  $s_i$ 에 대한 평균, 표준편차, 최대값, 최소값, 첨도, 왜도, 히스토그램 분포 등 통계적 특성을 나타내는 15개 특징, 스펙트럼 영역에서는 측정된 신호를 푸리에 변환(FFT)과 웨이블릿 변환을 거쳐 주파수와 크기(magnitude) 값으로 변환한 후 기반주파수, 최대주파수, 첨도, 왜도, 엔트로피, FFT계수의 평균, 웨이블릿 분산, 표준편차 등 26개의 특징을 추출한다. 각 특징은 대부분 스칼라이지만, 히스토그램의 분포, 웨이블릿 평균 등은 벡터이다. 히스토그램 분포는 빈(bin) 개수만큼의 차원을 갖게 되며, 웨이블릿 분산은 윈도우 폭만큼의 차원을 갖는다. 벡터 형태의 특징을 모두 스칼라 형태로 바꾸면 시간 영역에서 17개, 통계 영역에서 30개의 특징 값이 추출되며, 스펙트럼 영역은 다운 샘플링 빈도에 따라 특징의 개수에 차이가 나타난다. 1kHz로 다운 샘플링하는 경우 119개의 특징 값이 산출되어, 3개 영역에서 추출한 특징을 합하면 166개가 된다. MaFaulDa 데이터세트는 타코미터, 2개의 가속도 센서, 마이크로폰에서 측정한 8개 신호로 구성되어 있는데, 본 연구에서는 가속도 센서에서 측정한 두 쌍의 3축 가속도 신호를 이용하므로, 1kHz로 다운 샘플링하는 경우 특징벡터는  $996(=2 \times 3 \times 166)$ 차원이 된다.

특징벡터를 구성하는 특징들 중에서 회전체 기계의 고장 검출 및 진단에 도움이 되지 않거나 유사한 정보를 나타내는 특징들을 제거하면 특징벡터의 차원을 줄일 수 있다. 특징벡터의 차원을 줄이면 기억 공간을 절약할 수 있을 뿐만 아니라 신경망의 뉴런 개수가 줄어들어 상대적으로 적은 데이터로 효과적인 학습이 가능하다.

특징벡터를 구성하는 각 특징들의 중요도를 가중치로 표현하여 내림차순으로 정렬하면 식 (1)과 같이  $n$ 차원의 특징벡터  $V$ 를 나타낼 수 있다.

$$V = \{F_1, F_2, \dots, F_m, F_{m+1}, \dots, F_n\} \quad (1)$$

여기서  $F_1$ 은 회전체 기계의 고장 유무나 고장 유형을 식별하는데 가장 중요한 특징이고,  $F_n$ 은 가장 중요도가 떨어지는 특징이므로, 앞쪽에 나타나는 중요도가 높은  $m$ 개의 특징을

추려내면 축소된  $m$  차원의 특징벡터를 구할 수 있다. 본 연구에서는 유효한 특징들을 선택하기 위하여 Relief-F 알고리즘[18]을 이용하였다. 여기서 히트(hit)란 특징벡터  $V_i$  와 동일한 클래스에 속하는 특징벡터를 의미하고, 미스(miss)란 특징벡터  $V_i$ 의 클래스와 다른 클래스에 속하는 특징벡터를 의미한다. 임의의 특징벡터  $V_i$ 가 속하는 클래스내에서 가장 가까운  $k$ 개의 특징벡터  $H$ 와 다른 클래스에 속하는 가장 가까운  $k$ 개의 특징벡터  $M$ 에 대하여, 어떤 특징이 같은 클래스에 속하면 차이가 작게 나타날수록 좋은 특징이 되고 다른 클래스에 속하면 차이가 크게 나타날수록 좋은 특징이 된다. 이러한 원리는 아래 제시된 Relief-F 알고리즘의 맨 아래 제시된 가중치 계산식에 의하여 각 특징의 가중치를 갱신한다. 이러한 과정을 거쳐 가중치가 크게 나타날수록 좋은 특징이 된다.

**Relief-F Algorithm**

-입력: 학습 데이터셋(특징벡터 + 정상 or 고장 유형 레이블)

-출력: 특징벡터를 구성하는 각 특징의 중요도(weight)

$W[A] = 0.0$  # 가중치 초기화

For  $i := 1$  to  $d$  do #  $d$ : 학습 데이터의 개수

임의의 선택한 특징벡터  $V_i$ 에 대하여,

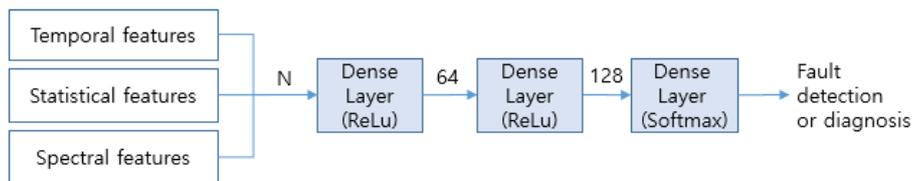
가장 가까운  $k$ 개의 히트  $H$ 와 가장 가까운  $k$ 개의 미스  $M$ 을 구한다

For  $A := 1$  to  $f$  do #  $f$ : 특징 집합

$$W[A] = W[A] - \sum_{j=1}^k \frac{diff(A, V_i, H_j)}{m \cdot k} + \sum_{c \neq class(V_i)} \left[ P(C) \sum_{j=1}^k \frac{diff(A, V_i, M_j(C))}{m \cdot k} \right]$$

**3.3 분류기 구성**

회전체 기계의 고장 진단을 위해 선택된 특징들을 이용하여 신경망을 학습시키고 새로운 데이터에 대하여 분류를 통해 고장을 진단하게 된다. 본 연구에서는 보편적 특징을 추출한 후 도메인에 적합한 특징을 선택하여 신경망에 입력시키는 방식을 사용하므로 [그림 3]에 제시된 바와 같이 입력층, 두 개의 은닉층, 출력층으로 이루어진 다층퍼셉트론 (MLP) 만으로 분류기를 구성하였다. 입력층의 노드는 Relief-F 알고리즘으로 선택한  $m$  개이고, 첫 번째 은닉층은 64개의 노드, 두 번째 은닉층은 128개의 노드로 구성하였으며 활성화 함수는 ReLu를 사용하였다. 그리고 MLP 학습과정에서 과적합이 나타나는 것을 방지하기 위하여 은닉층의 출력에 연결된 가중치에 드롭 아웃을 적용하였다. 실험을 통해 드롭 아웃 비율은 0.25로 설정하였다. 특징 추출과 분류의 기능을 모두 갖춘 깊은 신경망에 비하여 분류만을 수행하는 MLP는 상대적으로 적은 양의 데이터로도 신경망을 효과적으로 학습시킬 수 있는 장점이 있다.



[그림 3] MLP 분류기의 구성

[Fig. 3] Configuration of the MLP Classifier

### 4. 실험 결과 및 분석

신호 처리에서 널리 사용되는 도메인에 무관한 보편적 특징들 중에서 대상 도메인에 적합한 특징들을 선택하고, 선별된 특징을 신경망을 통해 분류하기 위해서는 학습 과정이 필수적이다. MaFaulDa 데이터세트는 정상 데이터가 49개, 비정상 데이터가 1,902개이고, 비정상 데이터를 고장 유형별로 살펴보면 질량 불균형이 333개, 수평 정렬불량이 197개, 수직 정렬불량이 301개, 내측 베어링 이상이 558개, 외측 베어링 이상이 513개이다.

본 연구에서는 전체 데이터 중 80%를 학습데이터, 나머지 20%를 테스트 데이터로 분리하였다. 정상 데이터는 비정상 데이터에 비하여 데이터 규모가 작으므로 전처리 단계에서 설명한 바와 같이 샘플링 간격을 유지하면서 다운 샘플링의 시작 위치를 변경하여 정상 상태의 학습데이터를 390개로 확장하였고, 5가지 고장 유형에 해당하는 데이터는 확장하지 않았다. 각 특징이 나타내는 값의 범위가 서로 다르기 때문에 학습데이터에 나타난 정보를 이용하여 전체 데이터를 정규화(*scaling*) 하였다.

전처리 단계에서 다운 샘플링을 통해 신호의 길이를 축소하였는데, 신호의 길이가 기계의 고장 검출 및 진단 정확도에 미치는 영향을 파악하기 위하여 다운 샘플링 빈도를 달리하여 실험을 진행하였다. 학습 데이터와 테스트 데이터의 편향성에 의한 성능의 차이를 최소화하기 위하여 5겹 교차 검증을 수행하였다. [표 2]는 추출된 모든 특징을 MLP의 입력으로 사용하여 5겹 교차 검증을 통해 얻어진 분류 정확도의 평균을 제시한 것이다. 50kHz인 원천 신호를 1kHz로 다운 샘플링한 신호를 사용하였을 때 99.90%의 고장 검출 정확도를 얻었고, 5가지 유형의 고장 진단에 대하여 99.04%의 정확도를 얻었다. 다운 샘플링의 빈도를 줄이게 되면 신호의 길이가 축소되는 장점이 있지만 고장 검출 및 진단의 정확도가 낮아지는 결과를 보였으며 성능 저하는 크게 나타나지 않았다.

[표 2] 다운 샘플링 빈도에 따른 분류 정확도

[Table 2] Classification Accuracy with Different Down-sampling Frequency

Sampling frequency	Fault detection	Fault diagnosis
1kHz	99.90 %	99.04 %
0.5kHz	99.85 %	98.49 %
0.25kHz	99.75 %	97.83 %

추출된 모든 특징들을 결합한 고차원 특징벡터에는 서로 중복되거나 회전체 기계의 고장 유형을 분류하는데 그다지 중요하지 않은 특징들도 포함되어 있다. 전체 특징들 중에서 중요한 특징들을 선별하여 MLP 입력으로 사용할 경우 분류 정확도에 어떤 영향을 미치는지 확인하였다. Relief-F 알고리즘에서 학습데이터의 개수  $d$ 와 특징 집합  $f$ 는 정해져 있고, 가까운 히트와 미스를 구할 때 필요한  $k$  값을 설정해야 한다. [표 3]은 1kHz로 다운 샘플링한 신호에 대하여  $k$  값을 달리하여 128개 특징을 선별하였을 때 MLP 분류기의 성능을 측정된 실험 결과이다.  $k$  값 30일 때 고장 검출 정확도가 99.95%로 가장 좋았고,  $k$  값이 10일 때 고장 진단 정확도가 99.95%로 가장 높게 나타났다.  $k$  값의 커지면 특징선택을 위한 처리 시간이 빠르게 증가하는데 비하여 고장 검출 및 진단의 정확도의 변화는 미미한 수준이었다.

[표 3] Relief-F 알고리즘의 k값에 따른 분류 정확도

[Table 3] Classification Accuracy with Different k at Relief-F Algorithm

k	Fault detection	Fault diagnosis
5	99.90%	99.90%
10	99.85%	<b>99.95%</b>
30	<b>99.95%</b>	99.90%
50	99.90%	99.80%

[표 2]와 [표 3]에 제시된 실험 결과를 토대로 다운 샘플링 빈도는 1kHz로 설정하였고, Relief-F 알고리즘의 k=10으로 설정한 후 최적의 특징집합을 찾기 위하여 선택할 특징의 개수 N을 달리하여 분류 정확도를 측정하였다. MLP의 입력으로 사용할 특징벡터의 차원을 두배 씩 늘려가면서 실험한 결과 [표 4]에 제시된 바와 같이 특징벡터의 차원이 커질수록 고장 검출 및 진단 정확도는 향상되는 것으로 나타났다. 특징벡터를 128차원으로 구성하였을 때 고장 진단 정확도는 99.95%를 보였으며, 특징벡터의 차원을 32로 크게 줄인 경우에도 고장 검출 99.70%, 고장 진단 98.14%의 만족할 만한 정확도를 얻을 수 있었다.

[표 4] 특징벡터의 차원에 따른 분류 정확도

[Table 4] Classification Accuracy with Different Dimension of Feature Vector

N	Fault detection	Fault diagnosis
32	99.70%	98.14%
64	99.75%	99.65%
128	99.85%	<b>99.95%</b>
256	<b>99.95%</b>	<b>99.95%</b>

회전체 기계의 고장 검출 및 진단에 대한 제안된 방법의 성능을 기존 연구들과 비교하기 위해서 동일한 데이터셋을 이용한 연구들을 살펴보았다. [표 5]는 MaFaulDa 데이터셋을 사용하여 고장 진단의 정확도를 측정한 연구 결과들을 정리한 것이다. Alzghoul 외[5]와 Ribeiro 외[8]의 연구는 연구자가 수작업으로 각각 31개와 19개 특징을 추출하여 사용하였고, Wang 외[14]는 합성곱 신경망(CNN)을 이용하여 자동으로 추출된 특징을 사용하였다. 일반적으로 학습 데이터의 비율이 높을수록 신경망이 다양한 사례에 대한 학습을 함으로써 분류 성능이 높게 나타난다. 제안된 방법으로 32차원의 특징벡터를 구성하였을 때 98.14%의 정확도를 보여 31차원의 특징벡터를 사용한 [5]보다 정확도가 높게 나타났으며, 128개의 특징을 선택하였을 때 99.95%의 정확도를 보여 CNN에 기반한 [15]보다 우수한 성능을 나타냈다. 이러한 결과들을 종합해 보면 제안된 특징 추출 및 선택 방식이 회전체 기계의 고장 검출 및 진단에 매우 효과적임을 확인할 수 있다.

[표 5] 관련 연구들과의 성능 비교

[Table 5] Performance Comparison with related Studies

Method	Features (N)	Ratio of train data & test data	Fault diagnosis Accuracy
Alzghoul 외[5]	handcrafted features (31)	90: 10	97.10%
Ribeiro 외[8]	handcrafted features (19)	90: 10	96.43%
Wang 외[14]	CNN-generated features	80: 20	99.30%
Proposed method	Feature selection (32)	80: 20	98.14%
	Feature selection (128)	80: 20	99.95%

### 5. 결론

기계학습을 기반으로 진동 신호를 분석하여 회전체 기계의 고장을 검출하거나 진단하는 연구들이 활발히 이루어져 왔다. 기계학습 방식은 원천적으로 학습에 필요한 다량의 데이터를 확보해야 하는 문제를 안고 있다. 그러나 현실적으로 고장 유형별로 다량의 데이터를 확보하는 것은 쉽지 않은 일이다. 본 연구에서는 이러한 문제를 해결하기 위하여 상대적으로 적은 학습데이터로 분류기를 학습시킬 수 있는 깊이가 얕은 다층퍼셉트론(MLP)을 구성하였다. 그리고 신호 처리 분야에서 널리 사용해온 보편적 특징들을 추출한 후 Relief-F 알고리즘을 적용하여 특징벡터의 차원을 축소하여 MLP의 입력으로 사용함으로써 소량의 학습 데이터를 이용하여 회전체 기계의 고장을 효과적으로 검출 및 진단할 수 있는 방법을 제안하였다. 제안된 방식을 구현하여 MaFaulDa 데이터셋으로 실험한 결과 고장 검출과 진단 모두 99.95%의 정확도를 보여 제안한 방법이 회전체 기계의 고장 검출 및 진단에 효과적임을 확인할 수 있었다. MaFaulDa 데이터셋은 기계 고장 시뮬레이터를 이용하여 신호를 생성한 것으로 노이즈가 적고, 고장 유형도 인위적으로 생성된 것이다. 따라서 제안된 방식의 유효성을 보다 객관적으로 확인하기 위해서는 다양한 데이터셋을 사용한 추가적인 연구가 필요하다.

### References

[1] Y. Lei, B. Yang, X. Jiang, F. Jia, N. Li, A. K. Nandi, Applications of machine learning to machine fault diagnosis: A review and roadmap, *Mechanical Systems and Signal Processing*, (2020), Vol.138, No.106587. DOI: <https://doi.org/10.1016/j.ymssp.201.106587>

[2] J. P. Kumar, P. S. Chauhan, P. P. Pandit, Time domain vibration analysis techniques for condition monitoring of rolling element bearing: A review, *Materials Today: Proceedings*, (2022), Vol.62, pp.6336-6340. DOI: <https://doi.org/10.1016/j.matpr.2022.02.550>

[3] S. Kumar, M. Lokesha, K. Kumar, K. R. Srinivas, Vibration based fault diagnosis techniques for rotating mechanical components: Review paper, *Proceedings of the Materials Science and Engineering*, IOP Publishing Ltd, (2018) DOI: <https://doi.org/10.1088/1757-899X/376/1/012109>

[4] N. K. Verma, A. K. Agrawal, R. K. Sevakula, D. Prakash, A. Salour, Improved signal processing techniques for machine fault diagnosis, *Proceedings of the IEEE 8th International Conference on Industrial and Information Systems*, (2013) DOI: <https://doi.org/10.1109/ICIIInfS.2013.6732018>

- [5] A. Alzghoul, A. Jarndal, I. Alsyouf, A. A. Bingamil, M. A. Ali, S. Slbaiti, On the usefulness of pre-processing methods in rotating machines faults classification using artificial neural network, *Journal of Applied and Computational Mechanics*, (2021), Vol.7, No.1, pp.254-261.  
DOI: <https://doi.org/10.22055/JACM.2020.35354.2639>
- [6] T. Kim, J. Chai, Pre-processing method to improve cross-domain fault diagnosis for bearing, *Sensors*, (2021), Vol.21, No.15, 4970.  
DOI: <https://doi.org/10.3390/s21154970>
- [7] L. Hong, J. S. Dhupia, A time-domain fault detection method based on an electrical machine stator current measurement for planetary gear-sets, *Proceedings of the International Conference on Advanced Intelligent Mechatronics*, IEEE, (2013)  
DOI: <https://doi.org/10.1109/AIM.2013.6584330>
- [8] F. M. L. Ribeiro, M. A. Marins, S. L. Netto, E. A. B. Silva, Rotating machinery fault diagnosis using similarity-based models, *Proceedings of the 35th Smpoio Brasileiro de Telecomunicacoes e Processamento de Sinais*, (2017)  
DOI: <https://doi.org/10.14209/sbrt.2017.133>
- [9] A. A. de Lima, T. M. Prego, S. L. Netto, E. A. B. da Silva, R. H. R. Gutierrez, U. A. Monteiro, A. C. R. Troyman, F. J. d. C. Silveira, L. Vaz, On fault classification in rotating machines using Fourier domain features and neural networks, *Proceedings of the 4th Latin American Symposium on Circuits and Systems*, IEEE, (2013)  
Available from: <https://ieeexplore.ieee.org/document/6518984>
- [10] D. H. Pandya, S. H. Upadhyay, S. P. Harsha, Fault diagnosis of bearing with supervised machine learning techniques, *Proceedings of the International Conference on Innovations in Design and Manufacturing*, Research Gate, (2012)  
Available from: <https://www.researchgate.net/publication/327365937>
- [11] S. Qiu, X. Cui, X. Ping, N. Shan, Z. Li, X. Bao, X. Xu, Deep learning techniques in intelligent fault diagnosis and prognosis for industrial systems: A review, *Sensors*, (2023), Vol.23, No.3, 1305.  
DOI: <https://doi.org/10.3390/s23031305>
- [12] L. Jing, M. Zhao, R. Li, X. Xu, A convolutional neural network-based feature learning and fault diagnosis method for the condition monitoring of gearbox, *Measurement*, (2017), Vol.111, pp.1-10.  
DOI: <http://doi.org/10.1016/j.measurement.2017.07.017>
- [13] J. Yan, T. Liu, X. Ye, Q. Jing, Y. Dai, Rotating machinery fault diagnosis based on a novel lightweight convolutional neural network, *PLOS ONE*, (2021), Vol.16, No.8, e0256287.  
DOI: <https://doi.org/10.1371/journal.pone.0256287>
- [14] Y. Wang, Z. Zhao, G. Cao, A convolutional neural network method based on Adam optimizer with power-exponential learning rate for bearing fault diagnosis, *Journal of Vibroengineering*, (2022), Vol.24, No.4, pp.666-678.  
DOI: <https://doi.org/10.21595/jve.2022.22271>
- [15] D. Pestana-Viana, R. Zambrano-Lopez, A. A. de Lima, T. de M. Prego, S. L. Netto, E. A. B. da Silva, The influence of feature vector on the classification of mechanical faults using neural networks, *Proceedings of the 7th Latin American Symposium on Circuits and Systems*, IEEE, (2016)  
DOI: <https://doi.org/10.1109/LASCAS.2016.7451023>
- [16] A. Sokolovsky, D. Hare, J. Mehnen, Cost-effective vibration analysis through data-backed pipeline optimization, *Sensors*, (2021), Vol.21, No.19, 6678.  
DOI: <https://doi.org/10.3390/s21196678>
- [17] M. Barandas, D. Folgado, L. Fernandes, S. Santos, M. Abreu, P. Bota, H. Liu, T. Schultz, H. Gamboa, TSFEL: Time series feature extraction library, *SoftwareX*, (2020), Vol.11, No.100456.  
DOI: <https://doi.org/10.1016/j.softx.2020.100456>
- [18] I. Kononenko, Estimaing attributes: Analysis and extensions of RELIEF, *Proceedings of the European Conference on Machine Learning*, Springer-Verlag, (1994)  
Available from: <https://sci2s.ugr.es/keel/pdf/algorithm/congreso/FS-Relief-F.pdf>