



신경망을 이용한 음향 측정 기반의 고장진단 시스템

남지인^a, 박희재^{a*}

A Neural Network based Fault Detection and Classification System Using Acoustic Measurement

Jiin Nam^a, Hee Jae Park^{a*}^a Department of Mechanical Design and Robot Engineering, Seoul National University of Science and Technology

ARTICLE INFO

Article history:

Received	13	April	2020
Revised	11	May	2020
Accepted	20	May	2020

Keywords:

Artificial intelligence
Machine learning
Neural network
Fault detection
Fast fourier transform

ABSTRACT

In this study, a fault detection and classification method using neural network-based acoustic measurement is proposed. In this method, a measured acoustic signal of the target equipment undergoes Fast Fourier transformation. The magnitude, for a range of frequencies, is accumulated and normalized to train predefined neural network model. To validate the proposed method, an experimental setup for cooling fan is established. The faults of the device are classified into five categories. A series of experiments for the experimental setup are conducted to validate the performance of the fault detection and classification of the proposed method. An accuracy of up to 98.6% is obtained for the test data. Thus, the experimental results show the effectiveness of the proposed fault detection algorithm.

1. 서론

본 논문에서는 고장 상황에 따라 작동음에서 활성화되는 주파수 대역의 패턴이 다르다는 점에 착안하여 장치의 상태별 작동음 데이터를 이용하여 훈련시킨 신경망으로 장치의 고장 여부 및 종류를 판단하는 고장진단 시스템을 제안한다.

냉각 팬, 펌프 등 365일 24시간 상시 동작하는 장치의 고장을 조기에 파악하는 것은 매우 중요하다. 장치의 고장을 파악하지 못하여 시스템이 중단되는 경우 막대한 시간적·물질적 손실이 발생하게 되며, 장치의 고장이 인명 피해를 초래하는 치명적인 사고로 이어질 수도 있기 때문이다. 이와 같은 장치들은 주기적으로 고장 여부를 검사할 필요가 있으나, 검사에도 상당한 비용과 인력이 수반된다. 따라서 컴프레서 압력이나 엔진 온도 등의 사전 징후를 활용한 고장진단 방식^[1], 가속도 센서 정보에 FFT를 적용, 주파수

로 변환해 진폭의 증가 추이를 파악하는 고장진단 방식^[2], 근접 센서에서 측정된 신호를 회전시켜 가상의 진동 신호를 획득, RNN 신경망을 이용하는 고장진단 방식^[3], 모터의 전류에서 파악한 특징 신호에 KNN 알고리즘을 적용하는 고장진단 방식^[4] 등 적은 비용으로도 고장을 파악할 수 있는 진단 기법에 관한 다양한 연구가 이루어지고 있다.

본 연구에서는 최근 각광받고 있는 AI 분야의 기술과 음향학 기법을 융합하여, 인력을 최소화하며 저렴한 비용으로도 상시 고장진단 및 분류가 가능한 시스템을 기본적인 완전 연결 신경망 (fully-connected neural network)만으로 구축하고자 한다.

모터나 베어링이 사용된 장치에 문제가 생긴 경우 이상이 있는 부품에 따라 독특한 소음이 발생하고, 이는 장치의 작동음에 반영된다. 따라서 장치의 작동음이나 진동을 분석하면 고장 발생 여부와 종류를 파악할 수 있다. 장치에서 수집한 음향이나 진동

* Corresponding author. Tel.: +82-2-970-6341

E-mail address: looki@seoultech.ac.kr (Hee Jae Park).

데이터에 FFT (Fast Fourier Transform)를 적용하여 주파수 영역으로 변환하면 고장 원인에 따라 다른 주파수 패턴을 얻을 수 있다. 이를 이용해 신경망을 학습시키면 각 고장 상황을 진단할 수 있게 된다.

본 논문에서는 신경망을 이용하여 장치의 고장을 진단할 수 있는 시스템을 설계하고, 고장진단 가능성을 검증하기 위한 일련의 실험들을 진행하였다. 실험을 통해 여러 종류의 고장이 있는 장치의 작동음을 수집하고, 신경망을 구성해 수집한 데이터로 훈련시킨다. 최종적으로 훈련된 신경망의 성능을 평가하여 설계한 시스템의 고장진단 가능성을 검증하였다.

2. 고장진단 시스템

2.1 고장진단 방식 제안

모터를 사용하는 장치가 정상적으로 작동할 때는 지배적인 주파수와 그 고조파로 구성된 작동음이 발생한다. 반면, 장치에 이상이 있는 경우에는 지배적인 작동 주파수뿐만 아니라 다른 대역의 주파수 성분들이 추가된다. 이러한 음향 데이터를 주파수 영역에서 분석하기 위해 진동 센서나 마이크 등을 이용해 장치의 작동음을 수집한다. 수집한 음향 데이터에 단시간 푸리에 변환(short-time Fourier Transform, STFT)을 적용해 작동음을 주파수 대역별로 분리한다. STFT를 적용할 경우 일정 시간 간격으로 주파수 데이터를 축적하여 Fig. 1과 같은 스펙트로그램(spectrogram)으로 나타낼 수 있다. 이 그림은 매 순간의 스펙트럼을 시간 순으로 나타낸 것이다. Fig. 1(a), (b)의 스펙트로그램은 고장 유무에 따라 주파수 패턴이 달라지는 예를 보여주고 있다. 정상 구동 상태인 (a)는 약 150 Hz 부근에서 정상 구동음이 관측되는 반면에 고장 상태인 (b)는 약 60 Hz 이하의 여러 저주파 성분들이 추가적으로 관측된다. 이를 분석하면 장치의 정상 구동 및 고장 상태를 판별할 수 있게 된다. 이와 같은 주파수의 크기(magnitude) 패턴은 장치에 이상이 발생한 부위에 따라서도 다른 양상으로 나타나기 때문에 주파수 데이터를 이용하여 고장 여부뿐만 아니라 고장의 종류 역시 파악할 수 있다.

Fig. 2에 제안된 고장진단 시스템의 간략한 구조도가 표시되어 있다. 냉각팬이나 펌프, 터빈 등의 장치가 고장진단 대상이 되고, 대상의 작동음을 수집하기 위해서 진동 센서나 마이크 등의 음향 센서를 설치한다. 마이크로프로세서에서는 STFT 연산을 수행하여 주파수 대역별로 연산된 값을 PC로 전송한다. PC에서는 Python을 이용하여 데이터를 변환하고, 이 데이터를 토대로 tensorflow 기반의 keras를 이용하여 설계된 신경망 모델을 훈련시킨다. 최종적으로 훈련 결과를 평가하여 신경망 모델을 완성한다.

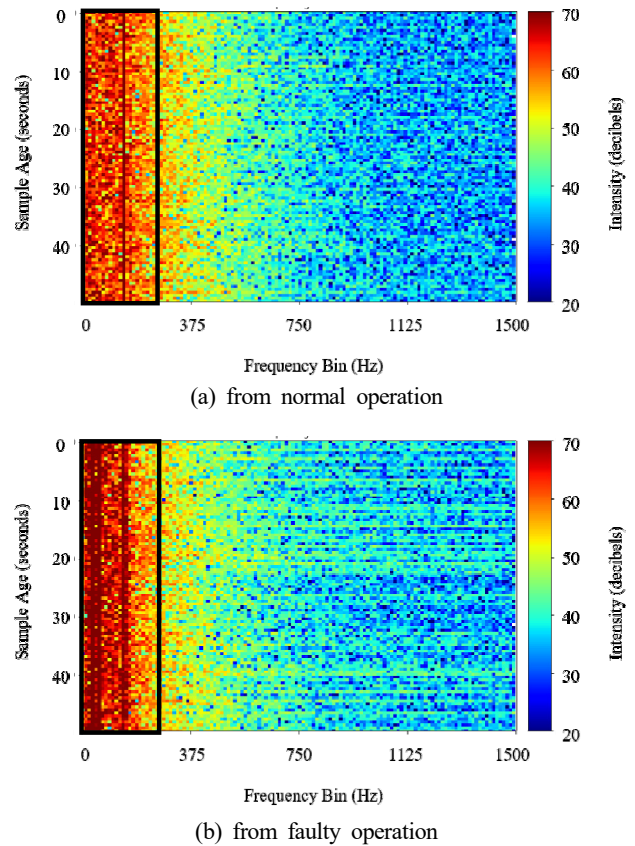


Fig. 1 Spectrogram of operation sound




Fig. 2 Configurations of the proposed of fault detection system

2.2 신경망을 이용한 고장진단 방법

이 절에서는 음향 신호 측정 기반의 신경망을 이용한 고장진단 시스템을 구축하기 위한 절차로서 고장의 정의, 작동음 수집, 신경망 구축, 신경망 조정에 대하여 설명한다. Fig. 3은 고장진단 과정의 흐름을 나타낸 그림이다.

2.2.1 고장 정의

작동음의 주파수 데이터를 입력받아 대상 장치의 동작 상태를 예측하는 신경망 모델을 구성하고자 한다. 그러기 위해서는 먼저 대상 장치의 다양한 고장 상황을 정의해야 한다. 발생 가능한 고장은 단선, 파손 등 불시에 일어날 수 있는 고장과 먼지 유입이나 베어링의 마모, 축 손상 등의 노후화로 인한 고장이 있을 것이며

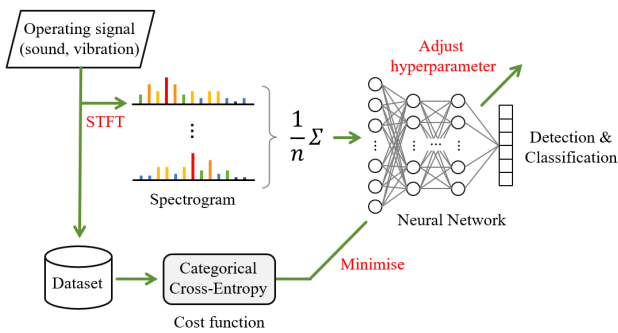


Fig. 3 Flow diagram of fault detection system

이는 대상 장치의 종류와 포함된 부품에 따라 달라지게 된다.

2.2.2 작동음 수집

정의한 고장에 해당하는 장치를 준비하여 각 상황의 작동음을 수집해야 한다. 정상과 고장을 모두 포함한 작동음은 신경망 모델의 학습과 평가, 최종 성능 테스트에 사용되기 때문에 작동음을 수집하는 것은 매우 중요하다.

음향 센서를 이용해 작동음을 수집할 때는 주위 환경음과 돌발적 소음 등을 고려해야 한다. 외부 환경음이란 장치 주변 환경에서 지속적인 소음이 발생하는 것으로, 장치 작동음 분석에 방해 요인으로 작용한다. 외부 환경음의 영향을 제거하기 위해 음향 센서를 2개 사용한다. 장치의 작동음을 수집하는 작동음 센서와 외부 환경음을 수집하는 환경음 센서로 나누어 측정된 음향 데이터에 각각 STFT를 적용, 두 센서에서 측정된 주파수 크기 값의 차를 입력 데이터로 사용한다. 또한 장치에 고장이 일어난 경우에 발생하는 소음은 오랜 시간 지속된다. 따라서 짧은 시간 동안 지속되는 소음은 장치 외부에서 발생한 소음일 가능성이 높다. 5초 미만으로 지속되는 소음을 단발성 소음으로 간주하고, 작동음을 분석하는 단위 시간은 10초로 설정한다. 단발성 소음의 영향을 제거하기 위해 단위 시간 동안 수집한 작동음의 주파수 대역별 크기의 평균을 구한다. 위의 두 과정을 차례로 거친 데이터가 신경망의 입력으로 사용된다.

2.2.3 신경망 구성

데이터를 신경망에 투입하기 전에 입력 데이터의 각 원소값이 0과 1 사이의 범위가 되도록 하는 정규화 과정을 거쳐야 한다. 데이터 전처리가 완료되면 이들을 훈련/검증/테스트 데이터셋으로 분리한다. 신경망을 훈련시킬 때는 검증 데이터셋이나 테스트 데이터셋에 포함된 데이터를 사용하지 않도록 한다^[5].

입력으로 사용할 데이터는 1차원 벡터이므로, 완전 연결 레이어를 사용해 일반적인 신경망을 구성할 수 있다. 입력 레이어의 노드 수는 입력 벡터의 크기와 동일하게 결정하고, 신경망의 깊이나 은

닉 레이어의 노드 수 등의 하이퍼(hyper) 파라미터는 정의한 고장의 종류나 복잡도 그리고 훈련에 사용할 데이터 셋의 크기에 따라 조절한다. 구성할 신경망의 목적은 입력된 데이터가 정상/정지/고장의 최소 3가지 상황 중 어떤 범주에 해당하는지 판별하는 것이며, 고장을 다양하게 정의했다면 더 많은 범주가 존재할 것이다. 이와 같은 다중 분류 문제를 해결하기 위해서는 출력 노드의 활성화 함수로 softmax, 비용 함수로 categorical crossentropy를 사용한다^[6]. 활성화 함수 softmax를 사용하면 입력한 데이터가 각 범주에 해당할 확률을 나타내는 1×n 벡터 형태의 출력을 얻을 수 있다. 이 때 출력 레이어의 노드 수는 정의한 고장의 가짓수(범주의 수)인 n이 되어야 하며, 분류 결과를 나타내는 레이블(범주)이 숫자로 이루어져 있어야 한다^[7]. 정수 레이블을 사용할 수도 있으나, 각각의 범주를 벡터 형태로 나타내는 원-핫-인코딩 방식을 사용하는 것이 좋다.

2.2.4 신경망의 조정

모델 구성을 완료하고 나면 학습과 평가를 반복하면서 과소적합 및 과대적합을 방지하기 위해 신경망 모델을 세부조정 한다. 이 과정에서 은닉 레이어의 수, 노드 수, epoch 및 batch 등의 하이퍼 파라미터를 조절하여 모델의 성능을 높일 수 있고, 과대적합을 방지하기 위하여 드롭아웃^[8]이나 가중치 규제 등의 기법을 사용할 수도 있다.

3. 고장진단 가능성 검증

3.1 실험장치 구성

본 논문에서는 제안된 고장진단 시스템의 성능과 효용성을 검증하고자 냉각 팬을 대상으로 구체적 연구를 진행하였다. 설계한 고장진단 시스템이 실제로 장치의 고장을 진단할 수 있는지 검증하기 위하여 Fig. 4와 같이 실험장치를 구성하였다. 진단 대상 장치는 최대 RPM 1400, 작동음 28 dBA 미만이며 볼 베어링이 장착된 12 mm 냉각 팬으로, 작동음을 수집하기 위하여 마이크 센서를 사용하였다. 진동 센서를 사용할 수도 있으나 실험에 사용한 냉각

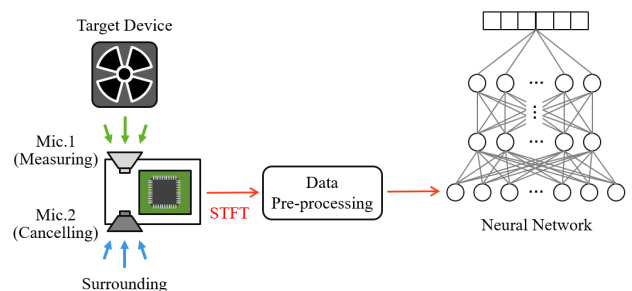


Fig. 4 Configuration of experiment system

팬은 사이즈가 작고 진동보다는 공기 유동음이 지배적이기 때문에 마이크 센서를 채택하였다.

실험장치 주변 환경 소음의 영향을 제거하기 위해 측정용 마이크와 소거용 마이크를 설치하였다. 실험장치에 이 두 마이크를 설치할 때 다음의 두 조건을 고려하였다.

- 1) 소거용 마이크는 측정용 마이크에 수집되는 불필요한 환경 소음을 제거하기 위한 것으로, 측정용 마이크에 들어오는 환경음을 소거용 마이크에서 대부분 측정 가능해야 한다.
- 2) 소거용 마이크에 작동음이 수집되는 경우 작동음 정보가 손실되므로, 이를 최소화하기 위하여 소거용 마이크는 측정용 마이크와 일정 거리를 두고 설치되어야 한다.

두 조건이 상반되기 때문에 작동음 마이크를 설치할 때는 여러 번의 테스트를 거쳐서 환경음 소거가 가능하면서도 작동음 측정 손실이 적은 위치를 찾아야 한다. 작동음 마이크는 장치를 향하도록 고정하고 환경음 마이크의 위치와 각도를 달리하며 작동음 손실과 환경음 소거 정도를 확인하였다.

Fig. 5는 실험장치를 환경 소음을 소거하지 않은 경우와 소거용 마이크의 설치 위치를 다르게 한 경우로 나누어 동일한 환경 소음에 노출시킨 상황을 스펙트로그램으로 나타낸 것이다. (a)와 비교했을 때 (b)~(d) 모두 환경 소음 제거 면에서는 성공적인 결과를 보인다. 그러나 작동음 손실 면에서는 (d)가 나머지 모델에 비해 손실이 적은 것을 확인할 수 있다. 따라서 환경음 마이크를 (d)와 같이 설치하여 실험장치의 고장 상황별 작동음을 수집하도록 하였다.

실험 장치인 냉각 팬의 작동 시 발생 가능한 고장을 조사하고 정상상을 포함하여 6개의 상태를 정의하였는데, (0) 정상 동작, (1) 모터 정지, (2) 블레이드 손상, (3) 먼지 등의 이물질 유입, (4) 베어링 윤활제 부족, (5) 회전축 이상이다. 5가지의 고장 중 모터가 정지한 상황은 음향이 발생하지 않지만 전기적 문제 등에 의하여 발생할 수 있는 치명적 고장이므로 분류에 포함하였다. 정의된 6가지 상황에 대한 샘플 장치를 준비하여 측정과 FFT 변환으로 작동음 데이터를 수집하였다. 장시간 사용하여 자연적으로 고장이 발생한 샘플 장치를 수집하는 것이 거의 불가능하였기 때문에 연구 목적으로 인위적으로 고장을 만들고 작동시켜서 음향을 측정하였다. FFT 변환의 주파수의 범위는 대상 시스템에 따라 달라질 수 있으나 본 연구에서는 정상 구동음의 주파수의 10배 정도인 1.5 kHz로 잡았다.

이와 같은 실험을 통해 단위 시간 동안의 평균값 및 정규화의 전처리를 거친 총 9753세트의 데이터를 획득하였다. 일반적으로 학습 데이터 셋과 검증 데이터 셋의 비율을 7:3 정도로 유지하는 것이 좋다는 연구들에 따라 데이터셋을 해당 비율로 유지하였다^[5]. 테스트를 위해 각 케이스 별로 데이터를 180세트씩 분리한 뒤 남은 데이터의 70%를 학습 데이터로, 30%를 검증 데이터로 사용하

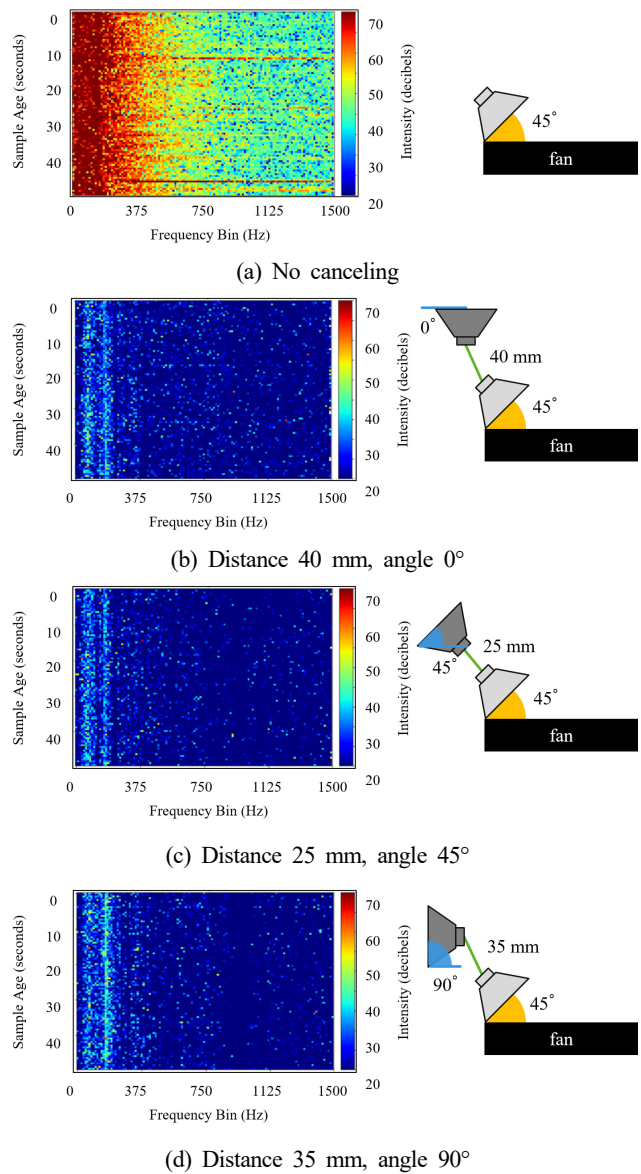


Fig. 5 Spectrograms for various postures of canceling mic

였다.

3.2 모델 구성 및 성능 평가

입력으로 사용할 데이터는 1.5 kHz 이하 범위에서 측정된 주파수 대역별 크기(magnitude)로 이루어진 벡터이다. 이 벡터는 1.5 kHz까지의 주파수를 256등분한 1×256 크기이며, 각 성분은 약 5.8 Hz 범위의 FFT 크기 정보를 가지고 있다. 실험에 사용된 마이크 성능의 한계로 인해 각 벡터의 첫 번째 원소인 0~5.8 Hz 영역의 측정 정확도가 낮다. 따라서 해당 항목을 삭제하여 1×255 크기의 벡터를 신경망의 입력으로 사용하였다. 입력 레이어의 노드 수는 입력되는 벡터의 크기에 맞추어 255로 설정하였다. 은닉 레이어는 3층을 사용하고 각 노드 수는 128개로 설정하였다. 대상 장치

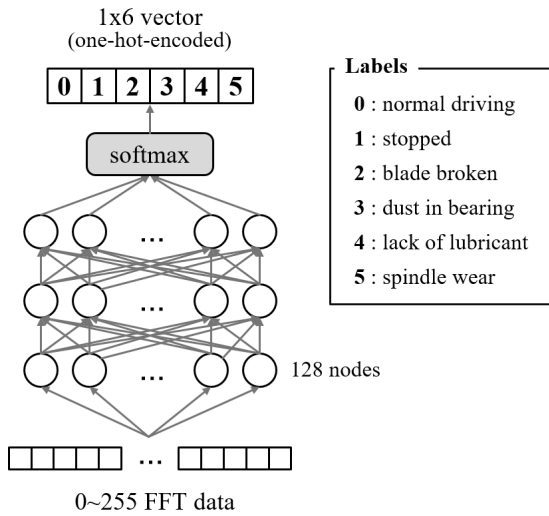


Fig. 6 Neural Network architecture

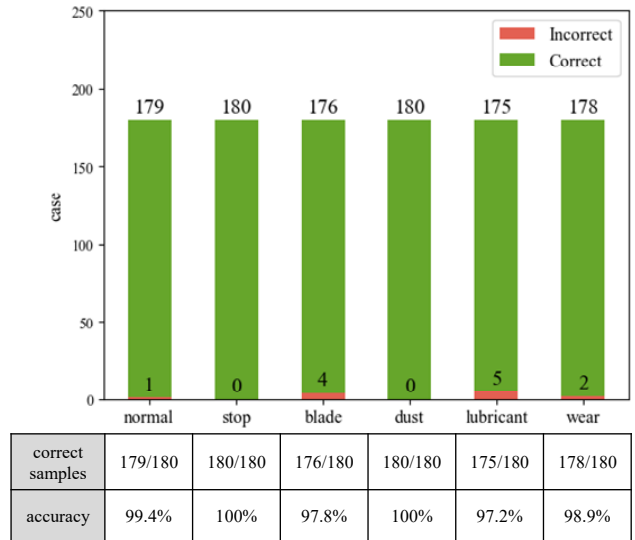


Fig. 8 Accuracy of test dataset for various faults

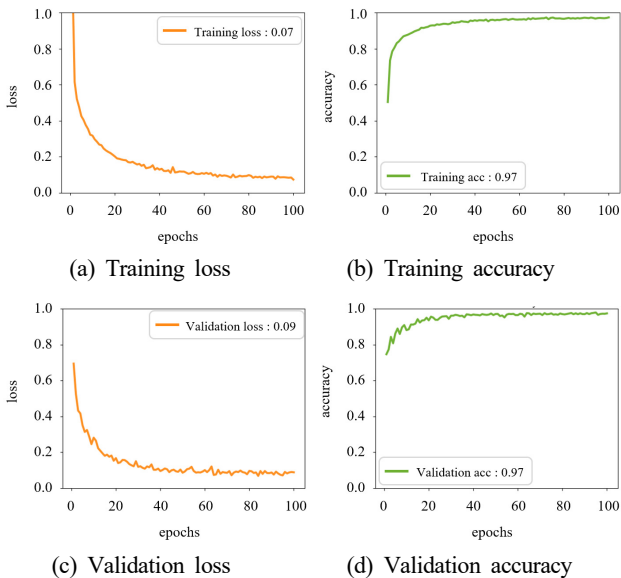


Fig. 7 Loss and accuracy of neural network used in the proposed method

의 상태는 앞서 정의한 대로 정상 구동을 포함해 6가지 범주로 구별할 수 있기 때문에 출력 노드의 활성화 함수로는 softmax를 사용하고 노드 수는 범주의 수와 같은 6개로 설정하였다. 이후 학습과 평가를 반복하며 epoch 및 batch size 등의 하이퍼 파라미터를 조정, 모델의 최종 구조를 결정하고 과대 적합을 방지하기 위해 각 레이어에 드롭 아웃 0.3을 적용하였다. Fig. 6에 실험 장치의 신경망 모델 구조를 표시하였다.

구성된 모델을 6198세트의 훈련 데이터에서 epoch 100, batch size 50으로 훈련시킨 뒤, 2655세트의 검증 데이터로 검증하였다. 모델 훈련 및 평가 결과 훈련 손실 및 정확도는 각각 7%, 97%이며 검증 손실 및 정확도는 9%, 97%를 기록하였다. Fig. 7은 훈련과

검증에 대한 신경망의 손실 및 정확도 그래프이다.

최종적으로 각 상황별 데이터 180세트로 이루어진 테스트 데이터 1080세트를 통해 신경망의 훈련 성과를 확인하였다. 테스트 데이터셋에 대한 정확도는 약 98.6%이며, 범주별 진단 결과는 Fig. 8과 같다.

4. 결론

본 논문에서는 고장 상황에 따라 작동음에서 활성화되는 주파수 대역의 패턴이 다르다는 점에 착안하여, 장치의 상태별 작동음 데이터로 훈련시킨 신경망을 통해 장치의 고장 여부 및 종류를 판단하는 고장진단 시스템을 제안하였다. 장치에서 수집한 작동음에 STFT를 적용하여 얻은 주파수 대역별 크기를 입력으로 받아들이는 시스템의 상태를 판단할 수 있는 신경망을 설계하고 작동음 데이터를 통해 망을 훈련시켜 장치의 고장진단에 활용하는 방법이다.

제안된 방법의 진단 성능과 효율성을 검증하기 위해 냉각 팬에 대한 실험장치를 구성하고 일련의 실험을 진행하였다. 냉각 팬에서 발생 가능한 고장의 종류를 정의하고 주변 환경으로부터의 간섭을 소거하기 위한 소거용 마이크를 채용하였다. 환경음의 영향을 소거한 작동음을 주파수-크기 데이터로 변환해 신경망을 훈련하였다. 신경망 훈련 결과 훈련 손실 7%, 훈련 정확도 97%와 검증 손실 9%, 검증 정확도 97%를 기록했으며 1080세트의 테스트 데이터를 대상으로 테스트한 정확도는 98.6%로, 제안한 신경망이 여러 경우의 고장을 매우 정확하게 진단할 수 있음을 확인하였다.

본 연구에서는 장치에 발생한 단일 고장을 파악하는 방법을

제안하였다. 제안된 진단 방법은 6가지 상황에 대한 각각의 발생 가능성을 출력하기 때문에 2가지 이상의 고장 요인이 동시에 발생하는 경우에도 어떤 문턱값을 정하여 그 이상이 되는 상황을 검출하게 한다면 복합적 고장을 진단할 수 있을 것이라 판단된다.

향후에는 제안된 진단 방법을 다양한 장치에 적용이 가능하도록 하는 일반화 연구가 필요하고 음향 데이터뿐만 아니라 영상 등 다른 측정 방식을 융합하는 방법에 대한 연구를 계속할 것이다.

후 기

이 연구는 서울과학기술대학교 교내연구비의 지원으로 수행되었습니다.

References

- [1] Baek, S. J., Kim, D. Y., 2016, Fault Symptom Extraction of Automotive Engines by the Event Occurrence Analysis Over Time interval, Proceedings of The Korean Institute of Industrial Engineers Fall Conference, 1324-1328.
- [2] Jang, J. H., Ha, C. K., Chu, B. S., Park, J. Y., 2016, Development of Fault Diagnosis Technology Based on Spectrum Analysis of Acceleration Signal for Paper Cup Forming Machine, Journal of the Korean Society of Manufacturing Process Engineers, 15:6 1-8. <https://doi.org/10.14775/ksmp.2016.15.6.001>.
- [3] Ko, J. U., Jung, J. H., Kim, M. Y., Kong, H. B., Youn, B. D., 2018, Noise Robust Fault Diagnosis Technique to Simultaneously Learn Classification and Denoising, Proceedings of The Korean Society of Mechanical Engineers Conference, 165-167.
- [4] Ham, S. J., Han, S. Y., Kim, S. G., Park, H. J., Park, K. J., Choi, J. H., 2019, Fault Diagnosis Study of Train Door Using Motor Current Signal, Journal of Applied Reliability, 19:4 353-361.
- [5] Chollet, F., 2017, Deep Learning with Python, Manning Publications, New York.
- [6] Vasilev, I., 2019, Advanced Deep Learning With Python: Design and Implement Advanced Next-generation AI Solutions Using TensorFlow and PyTorch, Packt Publishing Ltd, Birmingham.
- [7] Potdar, K., Pardawala, T. S., Pai, C. D., 2017, A Comparative Study of Categorical Variable Encoding Techniques for Neural Network Classifiers, International Journal of Computer Applications, 175:4 7-9, <https://doi.org/10.5120/ijca2017915495>.
- [8] Rahmani, M., Atia, G. K., 2018, Data Dropout in Arbitrary Basis for Deep Network Regularization, Proceedings of 52nd Asilomar Conference on Signals, Systems, and Computers, 66-70.



Jiin Nam

Student in the Department of Mechanical Design and Robot Engineering, Seoul National University of Science and Technology. Her research interest is Machine Learning.
E-mail: jiin@seoultech.ac.kr



Hee Jae Park

Professor in the Department of Mechanical Design and Robot Engineering, Seoul National University of Science and Technology. His research interest is Mechatronics and Machine Learning.
E-mail: looki@seoultech.ac.kr