

An Input Transformation with MFCCs and CNN Learning Based Robust Bearing Fault Diagnosis Method for Various Working Conditions

Yangjin Seo[†]

ABSTRACT

There have been many successful researches on a bearing fault diagnosis based on Deep Learning, but there is still a critical issue of the data distribution difference between training data and test data from their different working conditions causing performance degradation in applying those methods to the machines in the field. As a solution, a data adaptation method has been proposed and showed a good result, but each and every approach is strictly limited to a specific applying scenario or presupposition, which makes it still difficult to be used as a real-world application. Therefore, in this study, we have proposed a method that, using a data transformation with MFCCs and a simple CNN architecture, can perform a robust diagnosis on a target domain data without an additional learning or tuning on the model generated from a source domain data and conducted an experiment and analysis on the proposed method with the CWRU bearing dataset, which is one of the representative datasets for bearing fault diagnosis. The experimental results showed that our method achieved an equal performance to those of transfer learning based methods and a better performance by at least 15% compared to that of an input transformation based baseline method.

Keywords : Bearing Fault Diagnosis, Deep Learning, Distribution Difference, MFCCs, CNN

MFCCs를 이용한 입력 변환과 CNN 학습에 기반한 운영 환경 변화에 강건한 베어링 결함 진단 방법

서 양 진[†]

요 약

기계의 주요 부품인 베어링 결함 진단에 딥러닝을 활용하는 연구가 활발하게 진행되어 좋은 성능을 달성하였으나, 학습 데이터와 테스트 데이터의 운영 환경 차이로 인해 기계가 실제로 가동되는 환경에서는 성능 저하가 발생하는 문제가 있다. 학습 데이터와 테스트 데이터의 분포 차이 문제를 다루는 방법으로 데이터 적응이 제안되어 좋은 결과를 보여주고 있으나, 각 방법이 가정하고 있는 특정 적용 시나리오를 벗어나기 어렵다는 제약이 있다. 이에 본 연구는 MFCCs를 이용한 입력 데이터의 변환과 간단한 CNN 구조를 이용해 원시 도메인 데이터로부터 생성된 모델에 대해 추가적인 학습이나 조정 없이 타겟 도메인 데이터에 대한 테스트를 강건하게 수행하는 방법을 제안하였으며, 대표적인 베어링 결함 진단 데이터셋인 CWRU 베어링 데이터를 이용해 제안한 방법에 대한 실험 및 분석을 수행하였다. 실험 결과 전이 학습 기반의 방법들과 대등한 성능을 보였으며, 입력 변환 기반의 베이스라인 방법보다는 최소 15% 정도의 높은 성능을 달성하였다.

키워드 : 베어링 결함 진단, 딥러닝, 분포 차이, MFCCs, CNN

1. 서 론

기계에서 베어링 결함은 기계 자체에 손상을 주거나 기계 가동 중단에 따른 경제적 손실을 초래할 수 있으므로 이를 사전에 진단하고 그 결과에 따라 적절한 조치를 하는 것이 중요하다 [1-3]. 베어링의 결함 진단에는 센서를 이용해 수집된 진동 데이터를 일정한 기준과 방법에 따라 분석하는 기술이 사용되고 있는

데[4,5], 물리 모델 기반의 알고리즘[6-8]과 더불어 다양한 기계 학습 알고리즘을 적용하는 연구[9-11]가 진행되었고 근래에는 딥러닝 알고리즘을 적용하는 연구가 활발하게 진행되고 있다.

베어링의 결함 진단 기술로서 딥러닝 알고리즘이 주목받고 있는 것에는 특징 학습(Feature Learning)이라는 딥러닝의 특성이 큰 비중을 차지하고 있다[12,13]. 기존의 물리 모델 기반 알고리즘이나 기계학습 알고리즘의 경우 해당 분야의 전문 지식 없이 이를 적용하기가 어렵고, 특히 특징 추출(Feature Extraction)은 전문가에게조차도 많은 시간과 노력을 요구하는 일이다. 그에 비해 딥러닝은 데이터의 특징을 알고리즘 스스로 학습할 수 있기에 특정 분야에 대한 전문 지

[†] 정 회 원 : (주)이포존 연구소장

Manuscript Received : August 11, 2021

First Revision : October 8, 2021

Accepted : October 25, 2021

* Corresponding Author : Yangjin Seo(research.yj.seo@gmail.com)

식이 없거나 부족한 사람이라도 이를 이용한 문제 해결이 가능하다는 장점이 있다.

그런데 이와 같은 장점에도 불구하고 딥러닝을 이용하여 베어링 결함을 진단하는 것에는 몇 가지 현실적인 어려움이 존재하는데, 그중 하나가 운영 환경 변화에 따른 데이터 분포 차이 문제이다[14]. 동일 베어링에 동일 유형의 결함이 발생했다 하더라도 기계가 가동되는 환경 예를 들면 기계에 가해지는 부하에 따라 서로 다른 값의 진동 데이터가 발생하며 이러한 데이터로부터 특징을 스스로 학습하는 딥러닝 알고리즘은 각각을 다른 유형의 결함으로 판단하게 된다. 각 운영 환경에 따른 학습 데이터를 생성할 수 있다면 이러한 문제가 자연스럽게 해결되겠지만, 모든 운영 환경에 대해 모델이 일정 수준의 성능을 가질 수 있도록 충분한 데이터를 수집하는 것은 사실상 어려운 일이다.

이에 본 연구는 Mel Frequency Cepstral Coefficients(이하 MFCCs)를 이용한 데이터 변환과 이 데이터를 입력으로 하는 Convolutional Neural Network(이하 CNN)를 통해 운영 환경에 변화가 있더라도 베어링 결함을 강건하게 진단하는 방법을 제안한다. 딥러닝 적용 시 별도의 전처리 없이 원시 데이터(Raw Data)를 입력으로 한 학습과 테스트를 수행한 후 이를 기반으로 특정 사용 시나리오에서 좋은 성능을 달성한 사례들이 존재하지만[15-18], 데이터 전처리를 통해 원시 데이터의 특징 공간(Feature Space)이나 데이터 또는 특징 분포(Distribution)를 변경함으로써 더욱 나은 성능이나 더욱 일반화된 문제 해결 능력을 달성하는 것 또한 가능하다. 본 연구에서는 원시 진동 신호 입력 데이터를 소리 데이터의 처리에 많이 사용되는 MFCCs를 이용해 변환하면 간단한 CNN 학습만으로도 운영 환경 변화에 강건한 베어링 결함 진단이 가능함을 보인다.

본 논문의 구성은 다음과 같다. 먼저 2장에서는 베어링 결함 진단에 있어 운영 환경 변화 문제를 다룬 기존 연구를 살펴본다. 3장은 MFCCs와 CNN에 대한 간략한 소개와 함께 본 연구가 제안하는 운영 환경 변화에 강건한 결함 진단 방법을 설명한다. 이어지는 4장에서는 베어링 결함 진단 문제에서 사용되는 대표적인 데이터인 CWRU 베어링 데이터셋을 이용해 실험을 수행하고 이에 대한 평가 및 분석을 수행한다. 끝으로 5장에서는 본 연구의 결론과 향후 연구에 대해 정리한다.

2. 관련 연구

2.1 전이 학습 기반 연구

하나의 운영 환경에서 학습된 모델을 이용해 유사한 운영 환경에서 베어링 결함 진단을 수행하고자 한다면 이는 전이 학습(Transfer Learning) 또는 도메인 적응(Domain Adaptation) 문제로 다루어질 수 있다[19-21]. 도메인 적응은 여러 전이 학습 시나리오 중 특징 공간은 동일하지만 도메인 간의 데이터 분포가 다른 경우를 해결하려는 것이다. 예를 들어 어떤 모터에 부하 1이 가해진 환경에서 수집된 데이터를 입력으로 하여 결함 진단 모델이 생성되었다면, 도메인 적응을 적용해 부하 2가 가해진 동일 모터에 대해 결함 진단을 수행할 수 있는 것이다.

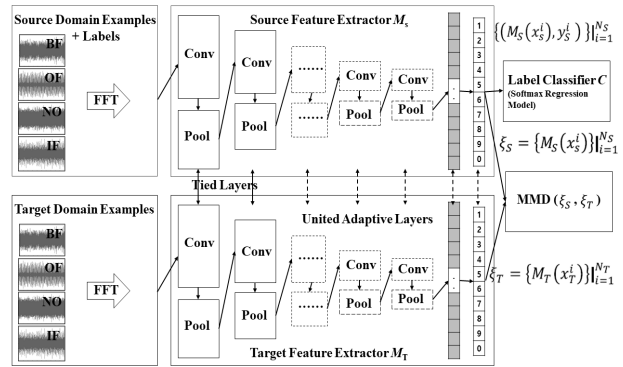


Fig. 1. Domain Adaptive Fine-tuning[21]

Zhang et al.은 학습 데이터와 테스트 데이터 사이의 분포 차이 문제를 해결하기 위해 DACNN(Domain Adaptive Convolutional Neural Networks)을 제안하였다[21]. DACNN은 원시 진동 신호에 고속 푸리에 변환(Fast Fourier Transform, 이하 FFT)을 적용한 샘플과 라벨(Label)을 입력 데이터로 하여 원시 도메인(Source Domain)에 대한 분류 모델을 생성한 후, 이를 목적 도메인(Target Domain) 모델의 초기 입력 파라미터로 사용하고 라벨이 없는 목적 도메인 입력 데이터와 함께 미세 조정(Fine-tuning)을 수행하여 원시 도메인과 목적 도메인 모두에 대해 좋은 분류 성능을 가지는 모델을 생성한다. Fig. 1은 DACNN의 핵심 동작을 보여주는데, 비용 함수에 두 데이터의 차이를 나타내는 대표적인 지표 중 하나인 MMD(Maximum Mean Discrepancy) 값을 기반으로 한 규제항(Regularizer)을 더해 데이터 분포 차이 문제를 해결한다. Li et al.은 MMD를 비용 함수에 더함에 있어 마지막 계층뿐만이 아닌 여러 계층에 걸쳐 적용하는 방법을 제안하였다[22].

Wang과 Liu는 목적 도메인 데이터에 라벨이 없는 경우를 비지도 적대적 도메인 적응을 통해 해결하는 방법을 제안하였는데, 도메인 간의 데이터 분포 차이를 최소화하는 데에는 바서스티안 거리(Wasserstein Distance)를, 클래스 단에서의 부정렬(Misalignment) 문제에는 삼중항 손실(Triplet Loss)을 사용하였다[23]. [22]와 [23]에서 저자들은 모두 1D CNN을 사용했으며, He et al. 또한 1D CNN을 사용하여 도메인 적응을 수행했는데, 높은 계산 복잡도를 가진 MMD 대신 CORAL 값을 이용해 원시 도메인과 목적 도메인 간의 데이터 분포 차이를 계산하고 이를 비용 함수에 반영하였다[24].

2.2 데이터 전처리 또는 변환 기반 연구

베어링 결함 진단에 있어 운영 환경 변화로 인해 진단 성능이 저하되는 문제를 전이 학습 기반 방법으로 해결하려는 시도가 성공적인 결과를 보이고 있음에도 불구하고 이를 현장에 적용할 때 여전히 어려움을 겪는 경우가 있는데, 그러한 경우 중 하나가 원시 도메인에서 생성된 모델을 목적 도메인에 바로 적용할 필요가 있을 때이다. 예를 들자면 모터에 부하 1이 가해진 환경에서 수집된 데이터만을 이용해 생성된 모델이 추가적인 학습이나 조정 없이 부하 2가 가해진 환경에서의 결함 진단에 바로 사용되기를 원하는 경우인데, 목적

도메인에서 수집된 데이터뿐만 아니라 추가적인 데이터 연산을 필수로 하는 전이 학습 기반의 방법으로는 이러한 요구를 충족시키는 것이 어렵다. 따라서 이러한 요구가 부당하고 비현실적인 것으로 생각될 수 있겠으나 베어링 결함 진단에 있어 부하나 속도 차이로 인해 운영 환경이 변하는 시나리오에 한해서는 전혀 불가능한 일은 아닌 것으로 판단된다.

Zhang, Peng, Li는 1D 진동 신호를 Equation (1)과 같이 복잡하지 않은 방법으로 2D 이미지로 변환한 후 $x(t)$ 는 t 시간에서의 진동 신호 측정값이며, 값을 n 개씩 묶어서 2D로 변환) 이를 입력으로 한 간단한 CNN을 이용해 99%가 넘는 정확도로 베어링 결함 진단이 가능함을 보였다[25]. 이는 운영 환경 변화에 관한 연구는 아니지만 입력 데이터를 변환하는 것만으로도 결함 진단에 있어 의미 있는 성능 개선이 가능함을 보여주는 것이다.

$$I = \begin{bmatrix} x(t) \cdots x(t+n-1) \\ \vdots \\ x(t+(m-1)n) \cdots x(t+mn-1) \end{bmatrix} \quad (1)$$

Hasan과 Kim은 1D 진동 신호에 이산 정규 직교 스톡웰 변환(Discrete Orthonormal Stockwell Transform)을 적용해 2D 이미지를 만든 후 이를 CNN의 입력으로 사용하여 부하(속도) 변화의 문제를 해결하고자 하였으며, CWRU 베어링 데이터셋을 사용한 실험을 통해 좋은 성능을 증명하였다[26]. 해당 결과는 원시 데이터를 특정 방식으로 변환해 주는 것만으로도 운영 환경 변화에 강건한 베어링 결함 진단이 가능함을 보여준다. 저자들은 또한 전이 학습을 추가로 적용하여 그 결과를 전이 학습을 적용하지 않은 경우와 비교 분석하였는데 전이 학습 추가 적용에 따른 정확도 개선은 크지 않았으나(여러 실험 시나리오에 대해 전이 학습을 적용한 경우가 평균적으로 1.04% 분류 정확도 개선) 학습 시간에 있어서 뚜렷한 단축 효과를 보였다.

Du et al.은 입력 데이터의 구조가 결함 진단 성능에 영향을 준다는 점을 설명한 후 1D 진동 신호를 STFT (Short-Time Fourier Transform) 2D 이미지로 변환하여 CNN 계열의 TDRN(Transfer Deep Residual Network)의 입력으로 사용하는 방법을 제안하였다(Fig. 2)[27]. TDRN의 경우 적은 양의 데이터를 가지고도 좋은 성능을 가진다는 점에서 다른 방식과 차별성을 보인다. 제안한 방법이 좋은 성능을 달성한 데에는 DRN 구조와 전이 학습의 적용이 핵심적인 요소이지만 STFT 2D 이미지의 사용 또한 중요한 요소가 된다.

[25-27]의 연구들은 진동 신호 데이터를 입력으로 하는 딥러닝 기반의 베어링 결함 진단에 있어 진동 신호 데이터 변환을 적용해 유사한 구조에서의 성능 개선 또는 동일한 성능을 보다 간편화된 구조로 달성할 수 있음을 보여주며, 특히 [26]은 진동 신호 데이터를 특정 방식으로 변환해 주면 운영 환경 변화에 강건한 베어링 진단도 가능함을 보여준다. 이에 본 연구는 소리 데이터의 처리에 많이 사용되는 MFCCs를 이용해 부하나 속도가 변하는 운영 환경에서 베어링 결함 진단을 강건하게 수행하는 방안을 제안한다.

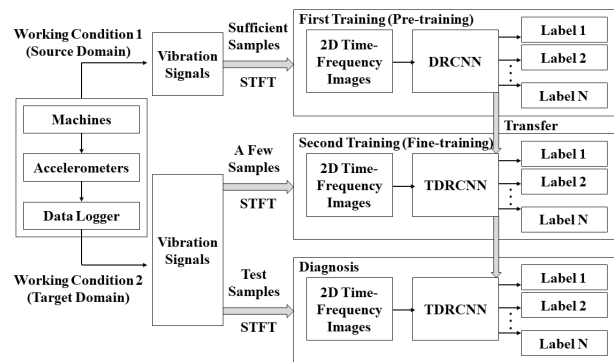


Fig. 2. Framework of [27]

MFCCs는 음성 인식을 포함한 다양한 소리 신호 처리 분야에 사용되어 왔는데, 근래에는 이를 진동 신호 처리에 활용하는 연구들 또한 수행되었다. Lee et al.은 중력 가속 장비의 결함 진단에 진동 신호를 STFT 또는 MFCCs를 기반으로 변환한 2D 스펙트로그램 이미지와 전이 학습이 적용된 VGG19 모델을 적용하여 결함 유형 별로 98~100%의 분류 정확도를 달성하였다[28]. 해당 연구에서 STFT를 적용한 경우와 MFCCs를 적용한 경우 간에 성능 차이는 없었다. Akpudo와 Hur는 플루이드 펌프의 고장 탐지에 MFCCs를 이용하였다[29]. Cheng et al.은 진동 신호에 대해 웨이블릿(Wavelet) 변환, 힐버트 황(Hilbert-Huang) 변환, MFCCs 변환의 3개 입력 데이터 변환과 CNN, LSTM, CNN-LSTM의 3개의 딥러닝 구조를 조합하여 신호 인식 성능을 비교하였으며, 실험 결과 MFCCs를 적용한 경우가 정확도와 속도 측면에서 가장 좋은 성능을 보였다[30]. [28-30]의 연구들은 운영 환경 변화에 관한 연구는 아니지만 MFCCs를 이용해 변환한 입력 데이터와 딥러닝 모델을 이용해 높은 정확도와 빠른 속도로 결함 진단을 수행할 수 있음을 보여준다. 본 연구는 MFCCs가 베어링 결함 진단에서 운영 환경 변화 문제에 대해 효과적인 도구로 사용될 수 있음을 제안한다.

3. 제안하는 베어링 결함 진단 방법

Fig. 3은 본 연구가 제안하는 베어링 결함 진단 방법의 전체 구성 및 동작을 간략하게 나타낸 것이다. 원시 도메인(왼쪽 위)에서 수집된 진동 신호 데이터를 MFCCs를 이용해 변환하고 이를 라벨과 함께 CNN의 입력으로 주면 학습이 진행되어 하나의 운영 환경에 대한 베어링 결함 진단 모델이 생성된다. 목적 도메인(왼쪽 아래)에서 수집된 진동 신호 데이터를 MFCCs를 이용해 변환한 후 앞서 생성된 모델을 추가적인 조정이나 학습 없이 바로 적용하여 베어링 결함 진단을 수행한다. Fig. 3에서 MFCCs 데이터가 가시화된 이미지 형태로 표시되었지만 실제로 CNN에 입력되는 값은 계산된 MFCCs 행렬이며, BF, IF, OF, NO는 각각 볼 결함, 내륜 결함, 외륜 결함, 정상을 의미한다.

전이 학습이 아닌 MFCCs 데이터 변환을 이용해 운영 환

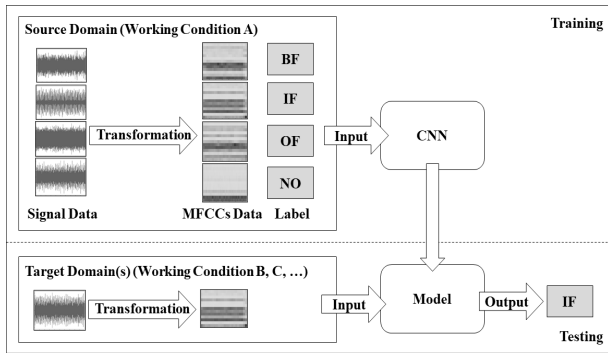


Fig. 3. Simplified Architecture of the Proposed Method




Fig. 4. MFCCs Processing

경 변화에 따른 베어링 결함 진단 성능 저하의 문제를 해결하고자 한 것은 본 연구가 최초이며, 1) 진동 신호 입력 데이터에 MFCCs를 이용한 데이터 변환을 적용하면 하나의 운영 환경에서 수집된 데이터를 통해 학습된 모델이 다른 운영 환경의 결함 진단에 바로 사용될 수 있음을 보이는 것과 2) MFCCs를 이용해 변환된 데이터에 대해서는 간단한 딥러닝 구조의 적용만으로도 빠르고 정확한 학습과 진단이 가능함을 보이는 것이 본 연구의 핵심이다.

3.1 MFCCs

MFC(Mel Frequency Cepstrum)는 사람의 소리 인지 메커니즘을 반영하여 소리의 특징을 표현하는 방식인데, 사람의 청각 기관이 고주파수보다 저주파수 대역에서 더 민감하다는 사실을 반영한 멜 스케일(Mel Scale)에 기반하여 신호의 특징을 추출한다. MFCCs는 MFC를 구성하는 계수(Coefficient)들로서 보통 4개에서 20개가 사용된다[31]. 진동 신호 데이터로부터 MFCCs를 계산하는 과정은 Fig. 4와 같으며 본 연구에서는 원시 진동 신호 데이터를 입력으로 받아 MFCCs를 계산해 주는 작업에 오픈소스 라이브러리 librosa[32]를 사용하였다. MFCCs 정의와 계산 방법에 대한 보다 자세한 내용은 [33]과 [34]에서 확인할 수 있다.

3.2 CNN 딥러닝 구조

최근 몇 년 동안 CNN 계열의 딥러닝 구조는 여러 분야에 광범위하게 이용되어 왔으며, 여러 기법(예를 들면 다양한 신호 전처리 기법) 또는 다른 딥러닝 구조(예를 들면 LSTM 구조)와 함께 베어링 결함 진단을 수행하는 강력한 도구로 사용되어 왔다[35,36].

Fig. 5는 CNN의 구조를 간략하게 표시한 것이다. 베어링 결함 진단에서 원시 데이터인 진동 신호는 1D 형태로 구성하는 것이 자연스럽고 이러한 형태의 입력에 맞게 CNN을 구성하는 것이 가능하나, 그림에서와 같이 데이터 변환을 이용해





Fig. 5. A Simplified Architecture of CNN



(a) Vibration Signal (b) MFCCs Spectrogram

Fig. 6. Input Examples

입력을 2D 형태로 구성하는 것 또한 가능하다. 입력에 대해 정해진 크기와 정해진 개수의 커널로 컨볼루션(Convolution) 연산과 최대 또는 평균 풀링(Pooling)을 수행하여 특징 학습이 수행되며, 여기서의 출력이 완전 연결 계층(Fully Connected Layer)을 거쳐 최종 출력으로 내보내 진다. CNN에 대한 보다 자세한 설명은 [37]과 [38]에서 확인할 수 있으며, [39]는 기계 결함 진단 분야에 CNN을 적용한 사례를 폭넓게 설명한다.

3.3 MFCCs와 CNN에 기반한 베어링 결함 진단 방법

본 연구는 베어링 결함을 진단하는 과정에 MFCCs로 변환된 2D 데이터를 입력으로 한 간단한 CNN 구조를 사용한다. 동일한 입력 데이터에 대해 나은 성능을 달성하는 딥러닝 구조를 찾는 것이 가능하겠으나 본 연구는 원시 진동 신호 데이터를 MFCCs를 이용해 변환하면 간단한 구조의 모델만 사용해도 운영 환경 변화에 강건한 베어링 결함 진단이 가능함을 확인함에 그 초점이 맞추어져 있다.

Fig. 6(a)와 같은 원시 입력 데이터는 Fig. 6(b)와 같은 MFCCs로 변환되는데, Fig. 6(b)는 이해를 돕기 위해 MFCCs를 시각화한 스펙트로그램으로 제안하는 방법에서 CNN의 실제 입력으로는 해당 이미지가 아닌 MFCCs 행렬이 사용된다. 시간 도메인(Time-domain) 진동 신호 데이터를 1초 단위씩 묶어 이에 대해 MFCCs 변환을 적용하였으며, 학습 데이터 샘플에는 오버래핑(Overlapping)을 이용한 데이터 확장(Data Augmentation)을 적용하였다. Fig. 7은 적용한 CNN 구조의 입력 계층부터 출력 계층까지를 간략하게 도시화한 것이며, Table 1은 적용한 CNN 구조를 상세히 기술하고 있는데, 각 최대풀링(MaxPooling) 계층 뒤에는 배치 정규화(Batch Normalization)를 적용하였으며, 완전 연결 계층과 출력 계층 사이에는 0.3의 확률로 드롭아웃(Dropout)을 적용하였다. 이렇게 구성된 CNN을 이하 논문에서는 편의상 mfCNN이라 지칭한다. 모델의 구현 및 실험에는 구글 Colab환경에서




Fig. 7. Applied CNN Architecture

Table 1. The Details of the Applied CNN Architecture

Layer	Parameters
Input	13×24 MFCCs matrix
Conv1	(3×3)×32 kernels, stride=1, padding=valid
MaxPooling1	(3×3), stride=2, padding=same
Conv2	(3×3)×32 kernels, stride=1, padding=valid
MaxPooling2	(3×3), stride=2, padding=same
Conv3	(2×2)×32 kernels, stride=1, padding=valid
MaxPooling3	(2×2), stride=2, padding=same
Fully Connected	64 units
Output	10 classes

TensorFlow/Keras 프레임워크를 사용하였으며, MFCCs의 생성이나 가시화에는 librosa 라이브러리를 이용하였다.

4. 실험 및 분석

4.1 데이터셋

mfCNN이 운영 환경 변화에 강건하게 동작하는지 검증하기 위해 CWRU 베어링 데이터셋[40,41]을 이용하였다. CWRU 데이터셋은 Fig. 8과 같이 구성된 환경에서 드라이브 단(Drive-end)과 팬 단(Fan-end)에 진동 센서를 부착하여 수집한 데이터인데, 센서 부착은 3시, 6시, 12시 방향 세 위치가 적용되었다. 센서 부착 위치에 따른 데이터는 외륜 결함 베어링이 장착된 경우에 대해서만 구분하여 수집하였다. 해당 데이터는 볼(Ball), 내륜(Inner Raceway), 외륜(Outer Raceway)에 인위적으로 만든 0.007, 0.014, 0.021인치 크기의 결함이 있는 베어링을 장착하고 데이터를 수집한 것이며, 정상 베어링 데이터는 48k, 결함이 있는 베어링 데이터는 12k, 48k의 샘플링 레이트로 수집되었다. 또한 모터에 0, 1, 2, 3HP의 부하(Load)를 주어 모터 속도가 각각 1797, 1772, 1750, 1730rpm으로 동작하는 환경에서 데이터가 수집되었다. 본 연구의 실험에는 12k 샘플링 레이트로 수집된 드라이브 단 데이터를 이용하였으며, 모터 부하는 1, 2, 3HP가 적용된 경우를, 외륜 결함 베어링은 센서가 6시 방향에 부착된 경우를 이용하였다.




Fig. 8. Experimental Setup for CWRU Dataset[40]

Table 2. The Details of Fault Classes

Label	0	1	2	3	4	5	6	7	8	9
Type	Normal	BF			IF			OF		
Size	N/A	0.007	0.014	0.021	0.007	0.014	0.021	0.007	0.014	0.021

4.2 실험

실험을 통해 다음과 같은 2개의 핵심 사항을 확인하였다. 첫째, 1D 진동 신호 데이터에 MFCCs를 이용한 데이터 변환을 적용하면 이를 입력으로 하는 CNN 모델이 운영 환경 변화에 강건한 베어링 결함 진단을 수행하게 되는가이다. 둘째, MFCCs를 입력으로 한 베어링 결함 진단 모델은 간단한 구조 만으로도 충분한 성능을 달성할 수 있는가이다. 첫째에 대해서는 실험 1과 실험 2를 통해, 둘째에 관해서는 실험 3을 통해 달성 여부를 확인하였다. 실험 1은 MFCCs 입력 변환이 적용된 CNN 모델이 학습과 테스트 시의 운영 환경이 서로 다른 경우에 어떤 수준의 성능을 달성하는지를 확인하기 위한 것이며, 실험 2는 운영 환경 변화에 따른 베어링 결함 진단에 있어 MFCCs 입력 변환을 적용한 경우와 다른 입력 변환 방법을 적용한 경우의 성능을 비교하기 위한 것이다. 실험 3은 입력으로 MFCCs가 사용될 때 CNN 모델 구조가 성능에 미치는 영향을 확인하기 위한 것이다.

1) 결함 분류 정의

먼저 실험에 사용한 결함 분류의 정의는 Table 2와 같다. Table 2에서 BF는 볼 결함을, IF는 내륜 결함을, OF는 외륜 결함 중 6시 방향에 센서가 부착된 경우를 의미한다. 정상 베어링 데이터는 레이블 0으로, 볼 결함 중 결함 크기가 0.007인 것은 레이블 1로 정의하였으며, 나머지 결함 종류 레이블 정의는 표의 내용과 같다. 실험에 사용된 운영 환경 도메인은 모터에 가해진 부하에 따르며, 부하 1HP(속도 1772rpm), 부하 2HP(속도 1750rpm), 부하 3HP(속도 1730rpm)가 적용된 경우를 각각 도메인 A, B, C로 정의하였다.

Table 3은 같은 결함 상태를 가지는 베어링이 운영 환경 A, B, C에서 발생시키는 진동 신호 데이터의 통계적 특성이 다. Table 2의 총 10개의 결함 분류(라벨)의 각 결함 상태별로 세 개의 운영 환경(도메인)에서 수집한 데이터를 실험에 사용하므로 총 30개의 조합이 존재하는데, Table 3은 그중

Table 3. Statistics of Vibration Signal Data for a Bearing with a Same Fault Type in Different Working Conditions

Label	Domain	Min	Max	Avg	SD
0	A	-0.3079	0.2641	0.0125	0.0651
	B	-0.3079	0.2641	0.0125	0.0651
	C	-0.3065	0.2837	0.0124	0.0647
1	A	-0.6596	0.6397	0.0039	0.139
	B	-0.5667	0.6046	0.0046	0.1471
	C	-0.7206	0.6715	0.0042	0.1536
5	A	-2.0015	2.0301	0.0036	0.1653
	B	-1.8805	1.8542	0.0037	0.163
	C	-2.0176	2.1269	0.003	0.1807

일부인 베어링이 정상인 경우(라벨 0), 베어링 볼에 0.007인치 크기의 결함이 있는 경우(라벨 1), 베어링 내륜에 0.014인치 크기의 결함이 있는 경우(라벨 5)의 값들이며, Min, Max, Avg, SD는 각각 최솟값, 최댓값, 평균값, 표준편차이다. 각 경우의 통계적 특성을 비교해 보면 베어링이 정상일 때 발생하는 진동 신호는 모든 운영 환경에서 유사한 값이 발생하지만, 베어링에 결함이 있는 경우에는 운영 환경에 따라 차이가 있는 값을 가진다. 이러한 차이는 하나의 운영 환경(도메인)에서 수집된 데이터로 학습된 모델을 다른 운영 환경의 결함 진단(테스트)에 사용하기 어렵게 만드는 요인이 된다.

2) 실험 1: MFCCs 입력 변환 기반 결함 진단 성능 확인

학습과 테스트 시의 기계 운영 환경이 서로 다른 경우에, MFCCs 입력 변환을 적용한 베어링 결함 진단이 어떤 수준의 성능을 달성하는지 확인하기 위한 실험 시나리오는 다음과 같다. 먼저 하나의 도메인 예를 들면 도메인 A의 데이터를 이용해 mfCNN을 학습시킨다. 1초간의 데이터에 대해 MFCCs를 생성하므로 12,000개의 데이터 값을 이용해 하나의 13×24 MFCCs 행렬을 생성한다. 데이터 확장(Data Augmentation)을 적용하여 각 분류별로 150개, 총 1,500개의 학습 데이터 샘플을 생성하는데, 그중 20%는 검증(Validation)에 활용된다. 이렇게 생성된 모델을 가지고 별도의 처리 없이 도메인 B의 데이터와 도메인 C의 데이터에 대해 테스트를 수행한다. 테스트 데이터는 데이터 확장 없이 도메인별로 각 분류별 50개씩 총 500개의 샘플을 구성한다. 정리하자면 원시 도메인 A의 데이터를 이용해 mfCNN을 학습시킨 후 구해진 모델을 이용해 목적 도메인 B와 C의 데이터에 대해 베어링 결함 진단을 수행한다. B나 C가 원시 도메인으로 사용된 경우도 같은 과정을 수행한다.

모델 최적화에는 Adam 알고리즘을 0.0001의 학습률로 적용하였으며, 손실함수로는 희소 범주형 교차 엔트로피(Sparse Categorical Cross Entropy), 성능 평가에는 정확도(Accuracy)를 이용하였다. 미니 배치 크기 32, 에폭은 30을 적용하고 각 테스트 경우 별로 100회 실험을 수행하여 얻은 결과는 Table 4의 마지막 행과 같다. 실험 결과에서 확인할 수 있는 바와 같이 mfCNN은 모든 운영 환경 변화 시나리오에서 성공적으로 동작하였는데, 도메인 C의 데이터를 이용해 학습된 모델로 도

Table 4. Accuracy Comparison with Related Works

Method	A→B	A→C	B→A	B→C	C→A	C→B
WDCNN [15]	99.20	91.00	95.10	91.50	78.10	85.10
WDCNN(AdaBN) [15]	99.40	93.40	97.50	97.20	88.30	99.90
DACNN _s [21]	99.86	98.40	97.89	89.46	89.65	99.14
DACNN [21]	100.00	99.69	100.00	99.90	97.98	100.00
mfCNN	100.00	99.77	99.59	100.00	96.65	100.00

메인 A에서 베어링 결함 진단을 수행한 경우(C→A)를 제외하고는 100%에 가까운 정확도를 보였으며 가장 낮은 성능을 보인 C→A의 경우도 96.65%의 정확도를 달성하였다.

Table 4에는 비교를 위해 기존 연구의 성능을 함께 표시하였는데, 경우별로 가장 높은 정확도를 달성한 값을 굵은 글자로 표시하였다. 성능 비교는 기존 연구 중 입력 변환에 기반을 두지 않으면서 데이터셋과 실험 시나리오상 mfCNN과의 직접적인 성능 비교가 가능한 [15]와 [21]을 대상으로 하였으며, 입력 변환 방법에 따른 진단 성능 비교는 실험 2에서 진행하였다. 실제로 [21]은 진동 신호 데이터에 FFT를 적용하지만, FFT는 신호 처리에 있어 가장 많이 사용되는 기본적인 입력 변환 방식이기에 [21]이 입력 변환에 중점을 둔 방법은 아닌 것으로 판단하였다. WDCNN[15]은 1D 원시 진동 신호를 입력으로 받는 넓은 첫 계층 (64×1) 사용을 특징으로 하는 CNN 구조로서 도메인 적응 방법인 AdaBN를 적용하면 평균 95.95%의 비교적 높은 정확도로 운영 환경에 강건한 베어링 결함 진단을 수행한다. DACNN[21]은 원시 도메인에서 생성된 모델(DACNNs)을 MMD 기반으로 미세 조정 수행 후 목적 도메인에 적용하여 평균 99.6%의 높은 정확도를 달성하였다. 본 연구가 제안한 mfCNN은 전이 학습 기반의 방법들과 달리 원시 도메인에서 생성된 모델을 추가적인 처리 없이 목적 도메인에 바로 적용하며, 평균 99.34%의 정확도로 DACNN과 대등한 성능을 달성하였다.

3) 실험 2: 다른 입력 변환 방법과의 진단 성능 비교

학습과 테스트 시의 기계 운영 환경이 서로 다른 경우에, 사용한 입력 데이터 변환 방식에 따른 베어링 결함 진단의 성능 비교를 위해 성능 비교 베이스라인(Baseline)으로 [25]를 선택하고 기존 연구 및 본 연구의 실험 결과에서 가장 도전적인 시나리오로 판명된 C를 원시 도메인으로 하는 경우(C→A, C→B)의 베어링 결함 진단 정확도를 구하였다. 베이스라인 방법에서는 1D 원시 입력 데이터값을 그대로 사용하되 이를 적절한 간격으로 묶어서 2차원 행렬로 구성하여 CNN의 입력으로 사용한다. 샘플을 생성할 때 mfCNN과 동일한 방식으로 데이터 확장을 적용하였다. 베이스라인의 입력으로 어떤 크기의 2차원 행렬을 사용할지를 결정해야 하는데 21×21과 45×45 두 개의 2차원 행렬을 이용하여 실험을 수행하였다. 21×21은 441개의 데이터값을 묶은 것으로 이 개수는 1730rpm에서 1772rpm으로 동작하는 모터에 대해 12k의 샘플링 레이트로 데이터를 수집하는 경우 약 400개의 데이터면 1회전에서 발생한 데이터를 포함할 것이라는 분석에 따른 것

Table 5. Classification accuracy of baseline

21×21		45×45		21×21, 1,500 Samples	
C→A	C→B	C→A	C→B	C→A	C→B
79.39%	85.64%	72.43%	81.59%	10.00%	10.00%

이다. 45×45는 2,025개의 데이터값을 묶은 것으로 MFCCs를 생성하는 윈도우/프레임 크기 2,048과 유사한 값을 적용한 것이다. MFCCs는 12,000개의 데이터를 묶어 하나의 샘플(13×24 행렬)을 생성하여 각 분류별 150개씩, 총 1,500개의 입력 샘플을 구성하였지만, 베이스라인의 경우 각 분류별 1,200개씩 총 12,000개의 입력 샘플을 구성하였으며 테스트 샘플은 각 분류별 50개씩 총 500개로 mfCNN과 동일하다.

Table 5는 베이스라인의 성능 실험 결과로 1열과 2열은 21×21, 3열과 4열은 45×45 입력을 적용한 것이며, 5열과 6열은 21×21 입력으로 각 분류별 150개, 총 1,500개의 샘플을 학습에 사용한 것으로 mfCNN의 실험 시와 같은 학습 샘플 개수를 적용한 것이다. 1열, 2열과 3열, 4열의 결과를 비교해 보면 진동 신호 데이터를 어떤 간격으로 묶어 샘플을 구성하는지가 결함 진단 성능에 영향을 준다는 것을 알 수 있다. Table 5의 결과를 Table 4 마지막 행의 5열, 6열과 비교해 보면 Table 4 마지막 행의 5열(C→A)이 96.65%, 6열(C→B)이 100%의 정확도를 달성한 mfCNN이 Table 5의 1열(21×21의 C→A)이 79.39%, 2열(21×21의 C→B)이 85.64%로 각각 최고의 성능을 보인 베이스라인보다 최소 15% 정도의 높은 성능을 달성하였다. 21×21 입력에 총 1,500개의 샘플을 학습에 적용한 경우(Table 5에서 5열과 6열) C→A, C→B 모두 10%의 정확도를 보였는데, 분류 레이블 종류가 10개인 것을 고려하면 결함 진단이 사실상 전혀 이루어지지 않고 있다. 이는 원시 데이터 그대로를 입력으로 한 경우 적은 수의 샘플로는 모델이 제대로 동작하지 않을 수 있음을 보여준다. 표에 표시하지 않았지만 총 6,000개의 샘플로 학습을 수행하면 12,000개를 이용한 경우와 비슷한 수준의 성능을 달성함도 확인하였다.

4) 실험 3: CNN 모델 구조가 성능에 미치는 영향 확인

Table 6은 실험 1과 2에 사용된 CNN 모델 구조의 명세이다. mfCNN이 총 파라미터 수 18,890개의 간단하고 가벼운 CNN 구조를 이용함에도 불구하고 평균 99.34%의 정확도로 운영 환경 변화에 강건한 베어링 결함 진단 결과를 보일 수 있었던 것은 MFCCs 입력 변환의 사용에 따른 것이라 판단된다. 이와 관련하여 실험 3에서는 추가적인 실험을 통해 MFCCs 입력 사용 시 더 간단한 딥러닝 모델로도 충분한 성능을 달성할 수 있는지와 더 복잡한 모델 이용 시 성능 개선이 있는지를 확인하였다. 이를 위해서는 먼저 딥러닝 모델의 복잡도를 평가할 수 있는 지표가 있어야 하는데, 본 실험에서는 몇 가지 사용 가능한 딥러닝 모델 복잡도 지표 중 가장 간단하면서도 효과적인 지표인 파라미터 수를 기준으로 하였다 [42,43].

본 실험에서는 운영 환경 변화 시나리오 중 가장 어려운

Table 6. The details of the mfCNN architecture

Layer	Output Shape	Param #
Conv2D	(None, 22, 11, 32)	320
MaxPooling2D	(None, 11, 6, 32)	0
Bath Normalization	(None, 11, 6, 32)	128
Conv2D	(None, 9, 4, 32)	9248
MaxPooling2D	(None, 5, 2, 32)	0
Bath Normalization	(None, 5, 2, 32)	128
Conv2D	(None, 4, 1, 32)	4128
MaxPooling2D	(None, 2, 1, 32)	0
Bath Normalization	(None, 2, 1, 32)	128
Flatten	(None, 64)	0
Dense	(None, 64)	4160
Dropout	(None, 64)	0
Dense	(None, 10)	650

Table 7. Accuracy comparison between different architectures

mfCNN (18,890)	mfCNN 2 (15,146)	mfCNN 3 (36,138)
96.65%	95.86%	96.80%

경우로 판명된 C→A에 대해 실험 1과 같은 방식으로 실험을 수행하되, 다른 파라미터 수를 가지는 CNN 구조를 적용하여 실험 1에서 얻은 결과와 비교하였다. CNN은 컨볼루션 계층의 커널 크기, 필터 개수, 스트라이드 값, 패딩 값, 풀링 크기, 컨볼루션 계층의 개수, 풀링 계층의 개수 등에 의해 다양한 구조를 가질 수 있으나, mfCNN의 경우 입력이 13×24이므로 네트워크 깊이의 변동 폭이 제한적이며, 그에 따라 파라미터 변동 폭도 크지 않다. 본 실험에서는 비교를 위해 15,146개의 파라미터를 가지는 mfCNN 2와 36,138개의 파라미터를 가지는 mfCNN 3를 구성하여 C→A에 대한 결함 진단을 수행하였으며 그 결과는 Table 7과 같다. 결과에서 확인할 수 있는 바와 같이 사용한 CNN 구조에 따라 성능에 차이가 있지만, 그 차이가 크지 않다. 결론적으로 MFCCs를 입력으로 한 베어링 결함 진단은 간단한 CNN 구조만으로도 충분한 성능을 달성할 수 있음을 확인하였다.

4.3 분석

실험 2를 통해 입력 데이터를 적절하게 구성해 주는 것만으로도 베어링 결함 진단 성능이 큰 폭으로 개선되는 것을 확인하였으나, 원시 진동 데이터값을 그대로 사용하는 방식으로는 운영 환경 변화에 대한 대응에 한계가 있음 또한 확인하였다. mfCNN은 원시 진동 데이터를 MFCCs를 통한 데이터 변환과 이를 입력으로 한 간단한 CNN 구조를 기반으로 운영 환경 변화에 강건한 베어링 결함 진단을 수행할 수 있음을 실험 1과 실험 3에서 확인하였다.

Fig. 9는 모터 회전 속도가 1730rpm(부하 3HP)인 환경에서 수집된 데이터 중 정상 베어링인 경우 (Fig. 9(a)), 베어링 볼에 0.007인치 크기의 결함이 있는 경우 (Fig. 9(b)), 내륜에 0.007인치 크기의 결함이 있는 경우 (Fig. 9(c)), 외륜에

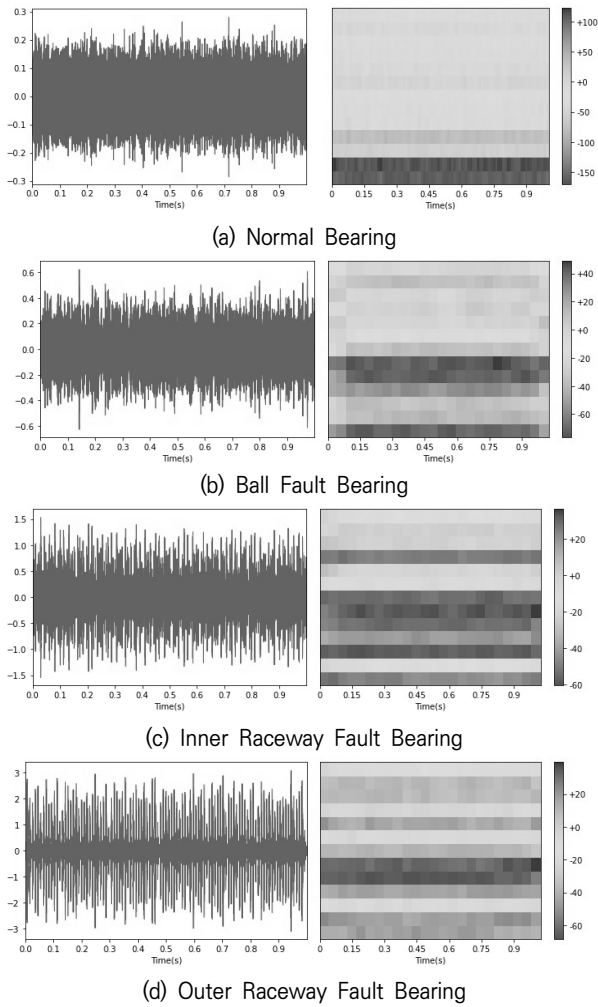


Fig. 9. Vibration Signal and Its MFCCs for 1730rpm

0.007인치 크기의 결함이 있는 경우 (Fig. 9(d)) 각각의 시간도메인 진동 신호(왼쪽)와 MFCCs 스펙트로그램(오른쪽)을 표시한 것이다. Fig. 10은 모터 회전 속도가 1750rpm(부하 2HP)인 환경에서 수집된 데이터이다. Fig. 9와 Fig. 10을 보면 하나의 운영 환경에서 베어링의 결함 상태/종류에 따라 뚜렷하게 구분되는 원시 진동 신호가 발생함을 확인할 수 있으나 (예를 들면 Fig. 9(a) 왼쪽과 Fig. 9(d) 왼쪽의 이미지는 확연히 다른 모양이다), 서로 다른 운영 환경에서 같은 결함을 가지는 베어링이 어느 정도 유사한 또는 구분되는 데이터를 발생시키는지 사람이 숫자나 가시화된 데이터를 보고 판단(예를 들면 Fig. 9(d) 왼쪽과 Fig. 10(d) 왼쪽의 이미지를 비교하여 판단)하는 것은 사실상 불가능하다. 뿐만 아니라 수집된 원시 데이터값을 기반으로 학습된 모델 또한 다른 운영 환경에서 발생한 베어링의 같은 결함 유형을 효과적으로 진단하지 못했다.

Fig. 9와 Fig. 10에서 같은 결함 상태/종류를 가지는 베어링에 대해 다른 운영 환경에서 수집한 데이터를 가지고 생성한 MFCCs를 비교해 보면 사람이 둘 사이의 유사성을 판단하기가 여전히 쉽지 않다. 그러나 본 연구에서 제안한 mfCNN

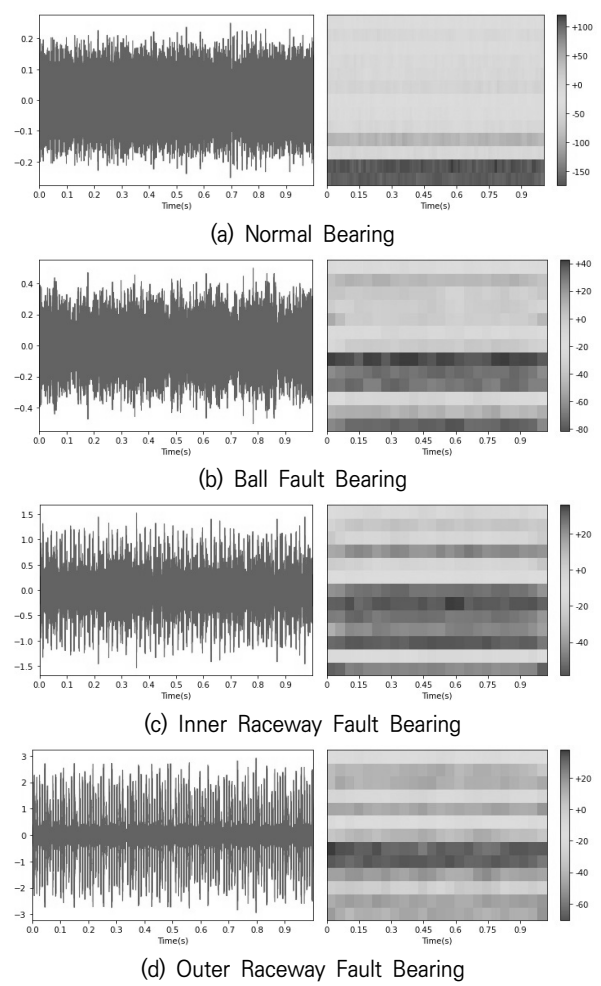


Fig. 10. Vibration Signal and Its MFCCs for 1750rpm

은 하나의 운영 환경에서 수집된 원시 진동 데이터를 일정 시간 간격으로 묶어 MFCCs 변환을 적용하고 이를 입력으로 학습된 CNN 베어링 결함 진단 모델로 다른 운영 환경에서도 같은 상태/종류의 결함을 효과적으로 찾아낸다. 원시 데이터로부터 MFCCs를 생성하는 것은 빠른 처리가 가능하고[44], 그 결과 얻어진 데이터의 차원이 크지 않으며 (본 연구에서는 12,000개의 데이터를 보다 분명하고 견고한 식별 특성을 가지는 312개의 데이터값으로 변환), 적은 수의 샘플(본 연구에서는 학습에 1,500개의 샘플 적용)과 복잡하지 않은 딥러닝 구조로도 높은 성능을 달성하게 한다는 점에서 mfCNN은 활용 가능성이 크다고 판단된다.

5. 결 론

기계의 주요 부품인 베어링의 결함을 딥러닝을 이용해 진단하는 연구는 성공적인 결과를 달성해 왔으나, 운영 환경 변화로 인해 학습 데이터와 테스트 데이터 간의 분포 차이가 있으면 진단 성능이 크게 저하되는 문제가 있다. 이러한 문제를 전이 학습 방식으로 해결하려는 연구들이 수행되어 이 또한

좋은 결과를 달성하였으나, 원시 도메인에서 생성된 모델을 목적 도메인에 바로 적용할 수 없다는 한계를 해결하지는 못한다. 이에 본 연구는 운영 환경이 변하는 시나리오에서 베어링 결함 진단을 강건하게 수행하는 방식으로서 MFCCs에 기반한 데이터 변환과 이를 입력으로 한 간단한 CNN 구조를 이용해 원시 도메인에서 생성된 모델을 추가 처리 없이 여러 목적 도메인에 바로 적용하는 방법을 제안하였다.

베어링 결함 진단 분야의 대표적인 데이터인 CWRU 데이터셋을 이용해 제안한 방법의 성능을 확인한 결과 모터 속도 (부하)에 변화가 있는 환경에서 수집된 복수 도메인의 데이터에 대해 강건한 베어링 결함 진단 성능을 보였으며, 기존 연구에서 제안한 방법 및 베이스라인 방법과의 성능 비교를 통해 MFCCs를 이용한 입력 데이터 변환을 통해 낮은 비용, 높은 성능으로 운영 환경 변화에 강건한 베어링 결함 탐지가 가능하다는 것을 확인하였다.

본 연구는 실험에 CWRU 데이터를 이용하여 동일한 베어링을 여러 운영 환경에서 동작시키며 결함 진단 성능을 확인하였다. 향후에는 같은 결함 유형을 가지는 다른 베어링에 대해서도 강건한 결함 진단이 가능한 방법을 연구할 예정이다. 예를 들면 볼 결함이 발생한 A사 베어링의 진동 데이터를 이용해 생성된 모델이 같은 볼 결함이 발생한 B사 베어링의 결함을 진단하는 방법을 찾고자 한다. 또한 A→C와 C→A의 경우처럼 두 개의 도메인에서 발생한 동일한 쌍의 데이터를 가지고 하나의 도메인에서 학습된 모델을 다른 도메인의 테스트에 적용했을 때 A→C는 99.77%, C→A는 96.65%로 정확도에 차이를 보이는 이유에 관해서도 추가적인 연구를 수행할 예정이다.

References

- [1] H. Qiu, J. Lee, J. Lin, and G. Yu, "Robust performance degradation assessment methods for enhanced rolling element bearing prognostics," *Advanced Engineering Informatics*, Vol.17, No.3-4, pp.127-140, 2003.
- [2] S. Nandi, H. A.Toliat, and X. Li, "Condition monitoring and fault diagnosis of electrical motors—A review," *IEEE Transactions on Energy Conversion*, Vol.20, No.4, pp.719-729, 2005.
- [3] F. Camci, K. Medjaher, N. Zerhouni, and P. Nectoux, "Feature evaluation for effective bearing prognostics," *Quality and Reliability Engineering International*, Vol.29, No.4, pp.477-486, 2013.
- [4] M. Lebold, K. McClintic, R. Campbell, C. Byington, and K. Maynard, "Review of vibration analysis methods for gearbox diagnostics and prognostics," in *Proceedings of the 54th Meeting of the Society for Machinery Failure Prevention Technology*, Virginia Beach, pp.623-634, 2000.
- [5] P. Wang and G. Vachtsevanos, "Fault prognostics using dynamic wavelet neural networks," *AI EDAM*, Vol.15, No.4, pp.349-365, 2001.
- [6] R. Yan, R. X. Gao, and X. Chen, "Wavelets for fault diagnosis of rotary machines: A review with applications," *Signal Processing*, Vol.96, pp.1-15, 2014.
- [7] D. An, N. H. Kim, and J. H. Choi, "Practical options for selecting data-driven or physics-based prognostics algorithms with reviews," *Reliability Engineering & System Safety*, Vol.133, pp.223-236, 2015.
- [8] A. Cubillo, S. Perinpanayagam, and M. Esperon-Miguez, "A review of physics-based models in prognostics: Application to gears and bearings of rotating machinery," *Advances in Mechanical Engineering*, Vol.8, No.8, pp.1-21, 2016.
- [9] J. Lee, F. Wu, W. Zhao, M. Ghaffari, L. Liao, and D. Siegel, "Prognostics and health management design for rotary machinery systems—Reviews, methodology and applications," *Mechanical Systems and Signal Processing*, Vol.42, No.1-2, pp.314-334, 2014.
- [10] K. L. Tsui, N. Chen, Q. Zhou, Y. Hai, and W. Wang, "Prognostics and health management: A review on data driven approaches," *Mathematical Problems in Engineering*, 2015.
- [11] D. Wang, K. L. Tsui, and Q. Miao, "Prognostics and health management: A review of vibration based bearing and gear health indicators," *IEEE Access*, Vol.6, pp.665-676, 2017.
- [12] Y. Lei, F. Jia, J. Lin, S. Xing, and S. X. Ding, "An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data," *IEEE Transactions on Industrial Electronics*, Vol.63, No.5, pp.3137-3147, 2016.
- [13] L. Jing, M. Zhao, P. Li, and X. Xu, "A convolutional neural network based feature learning and fault diagnosis method for the condition monitoring of gearbox," *Measurement*, Vol.111, pp.1-10, 2017.
- [14] A. Zhang, S. Li, Y. Cui, W. Yang, R. Dong, and J. Hu, "Limited data rolling bearing fault diagnosis with few-shot learning," *IEEE Access*, Vol.7, pp.110895-110904, 2019.
- [15] W. Zhang, G. Peng, C. Li, Y. Chen, and Z. Zhang, "A new deep learning model for fault diagnosis with good anti-noise and domain adaptation ability on raw vibration signals," *Sensors*, Vol.17, No.2, p.425-445, 2017.
- [16] L. I. Xueyi, L. I. Jialin, Q. U. Yongzhi, and H. E. David, "Semi-supervised gear fault diagnosis using raw vibration signal based on deep learning," *Chinese Journal of Aeronautics*, Vol.33, No.2, pp.418-426, 2020.
- [17] H. Li, Q. Zhang, X. Qin, and S. Yuantao, "Raw vibration signal pattern recognition with automatic hyper-parameter-optimized convolutional neural network for bearing fault diagnosis," *Proceedings of the Institution of Mechanical Engineers, Part C: Journal of Mechanical Engineering Science*, Vol.234, No.1, pp.343-360, 2020.
- [18] G. Jin, T. Zhu, M. W. Akram, Y. Jin, and C. Zhu, "An adaptive anti-noise neural network for bearing fault diagnosis under noise and varying load conditions," *IEEE Access*, Vol.8, pp.74793-74807, 2020.

- [19] I. Goodfellow, Y. Bengio, and A. Courville, "Deep learning," Cambridge: MIT press, 2016.
- [20] R. Zhang, H. Tao, L. Wu, and Y. Guan, "Transfer learning with neural networks for bearing fault diagnosis in changing working conditions," *IEEE Access*, Vol.5, pp.14347-14357, 2017.
- [21] B. Zhang, W. Li, X. L. Li, and S. K. Ng, "Intelligent fault diagnosis under varying working conditions based on domain adaptive convolutional neural networks," *IEEE Access*, Vol.6, pp.66367-66384, 2018.
- [22] X. Li, W. Zhang, Q. Ding, and J. Q. Sun, "Multi-layer domain adaptation method for rolling bearing fault diagnosis," *Signal Processing*, Vol.157, pp.180-197, 2019.
- [23] X. Wang and F. Liu, "Triplet loss guided adversarial domain adaptation for bearing fault diagnosis," *Sensors*, Vol.20, No.1, pp.320-338, 2020.
- [24] J. He, X. Li, Y. Chen, D. Chen, J. Guo, and Y. Zhou, "Deep transfer learning method based on 1D-CNN for bearing fault diagnosis," *Shock and Vibration*, 2021.
- [25] W. Zhang, G. Peng, and C. Li, "Bearings fault diagnosis based on convolutional neural networks with 2-D representation of vibration signals as input," in *Proceedings of the 3rd International Conference on Mechatronics and Mechanical Engineering*, Shanghai, pp.13001-13005, 2016.
- [26] M. J. Hasan and J. M. Kim, "Bearing fault diagnosis under variable rotational speeds using stockwell transform-based vibration imaging and transfer learning," *Applied Sciences*, Vol.8, No.12, p.2357-2071, 2018.
- [27] Y. Du, A. Wang, S. Wang, B. He, and G. Meng, "Fault diagnosis under variable working conditions based on STFT and transfer deep residual network," *Shock and Vibration*, 2020.
- [28] S. Lee, et al., "A study on deep learning application of vibration data and visualization of defects for predictive maintenance of gravity acceleration equipment," *Applied Sciences*, Vol.11, No.4, pp.1564-1578, 2021.
- [29] U. E. Akpudo and J. W. Hur, "A cost-efficient MFCC-based fault detection and isolation technology for electromagnetic pumps," *Electronics*, Vol.10, No.4, pp.439-458, 2021.
- [30] Z. G. Cheng, W. J. Liao, X. Y. Chen, and X. Z. Lu, "A vibration recognition method based on deep learning and signal processing," *Engineering Mechanics*, Vol.38, No.4, pp.230-246, 2021.
- [31] A. Lerch, "An introduction to audio content analysis: Applications in signal processing and music informatics," Wiley-IEEE Press, 2012.
- [32] Librosa [Internet], <https://github.com/librosa/librosa>
- [33] F. Zheng, G. Zhang, and Z. Song, "Comparison of different implementations of MFCC," *Journal of Computer Science and Technology*, Vol.16, No.6, pp.582-589, 2001.
- [34] S. Gupta, J. Jaafar, W. W. Ahmad, and A. Bansal, "Feature extraction using MFCC," *Signal & Image Processing: An International Journal*, Vol.4, No.4, pp.101-108, 2013.
- [35] S. Tang, S. Yuan, and Y. Zhu, "Data preprocessing techniques in convolutional neural network based on fault diagnosis towards rotating machinery," *IEEE Access*, Vol.8, pp.149487-149496, 2020.
- [36] S. Zhang, S. Zhang, B. Wang, and T. G. Habetler, "Deep learning algorithms for bearing fault diagnostics: A comprehensive review," *IEEE Access*, Vol.8, pp.29857-29881, 2020.
- [37] K. O'Shea and R. Nash, "An introduction to convolutional neural networks," *arXiv preprint arXiv:1511.08458*, 2015.
- [38] S. Albawi, T. A. Mohammed, and S. Al-Zawi, "Understanding of a convolutional neural network," In *International Conference on Engineering and Technology*, Antalya, 2017, pp.1-6.
- [39] J. Jiao, M. Zhao, J. Lin, and K. Liang, "A comprehensive review on convolutional neural network in machine fault diagnosis," *Neurocomputing*, Vol.417, pp.36-63, 2020.
- [40] Case Western Reserve University (CWRU) Bearing Data Center [Internet], <https://csegroups.case.edu/bearingdatacenter/home>.
- [41] D. Neupane and J. Seok, "Bearing fault detection and diagnosis using case western reserve university dataset with deep learning approaches: A review," *IEEE Access*, Vol.8, pp.93155-93178, 2020.
- [42] X. Ding, X. Zhang, N. Ma, J. Han, G. Ding, and J. Sun, "Repvgg: Making vgg-style convnets great again," In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, pp.13733-13742, 2021.
- [43] L. Alzubaidi, et al., "Review of deep learning: Concepts, CNN architectures, challenges, applications, future directions," *Journal of Big Data*, Vol.8, No.1, pp.1-74, 2021.
- [44] S. A. Alim and N. K. A. Rashid, "Some commonly used speech feature extraction algorithms," in *From Natural to Artificial Intelligence*, IntechOpen., ch.1, pp.2-119, 2018.



서 양 진

<https://orcid.org/0000-0001-5748-8412>

e-mail : research.yj.seo@gmail.com

1998년 중앙대학교 컴퓨터공학과(학사)

2000년 중앙대학교 컴퓨터공학과(석사)

2010년 중앙대학교 컴퓨터공학과(박사)

2004년 ~ 2010년 (주)소프트캡프 차장

2010년 ~ 2012년 (주)시큐아이 차장

2017년 ~ 2020년 (주)코튼캔디 CTO

2020년 ~ 현 재 (주)이포즌 연구소장

관심분야: 딥 러닝, 디지털 트윈, 디지털 전환, 보안