

Scalogram과 Switchable 정규화 기반 합성곱 신경망을 활용한 베어링 결함 탐지

Scalogram and Switchable Normalization CNN(SN-CNN) Based Bearing Fault Detection

Myagmar Delgermaa*, 김윤수*, 석종원*★

Myagmar Delgermaa*, Yun-Su Kim*, Jong-Won Seok*★

Abstract

Bearing plays an important role in the operation of most machinery, Therefore, when a defect occurs in the bearing, a fatal defect throughout the machine is generated. In this reason, bearing defects should be detected early. In this paper, we describe a method using Convolutional Neural Networks (SN-CNNs) based on continuous wavelet transformations and Switchable normalization for bearing defect detection models. The accuracy of the model was measured using the Case Western Reserve University (CWRU) bearing dataset. In addition, batch normalization methods and spectrogram images are used to compare model performance. The proposed model achieved over 99% testing accuracy in CWRU dataset.

요약

베어링은 기계가 작동할때 중요한 역할을 한다. 때문에, 베어링에 결함이 발생하면 기계전체의 치명적인 결함을 발생시킨다. 그러므로 베어링 결함은 조기에 발견되어야한다. 본 논문에서는 연속 웨이블릿 변환과 Switchable 정규화를 기반으로 한 합성곱 신경망(SN-CNN)을 이용한 방법을 베어링 결함 감지 모델에 대해 설명한다. 모델의 정확도는 Case Western Reserve University (CWRU) 베어링 데이터 집합을 사용하여 측정되었다. 또한 배치 정규화(BN, Batch Normalization)[1] 방법과 스펙트로그램 이미지가 모델 성능의 비교를 위해 사용되었다.

Key words : Bearing fault detection, deep learning, CWRU dataset, switchable normalization, scalogram, convolutional neural network

* Dept. of Information and Communication Engineering,
Changwon National University

★ Corresponding author

E-mail : jwseok@changwon.ac.kr Tel : +82-55-213-3836

※ Acknowledgment

This research was supported by Basic Science Research Program through the National Research Foundation of Korea(NRF) funded by the Ministry of Education (2022R1I1A306349311)

Manuscript received Jun. 10, 2022; revised Jun. 20, 2020; accepted Jun. 28, 2022.

This is an Open-Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License(<http://creativecommons.org/licenses/by-nc/3.0>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

1. 서론

과학 기술의 빠른 발전과 함께 전자기기의 사용이 증가하고 있다. 전자기기는 제조업의 모든 부분에서 매일 사용되고 있다. 전자기기의 사용은 높은 습도나 과부하가 걸리면 기계의 결함으로 이어지고, 막대한 손실을 입게 된다. 베어링은 기계의 가장 중요한 구성요소이며, 베어링의 상태는 기계의 성능, 안정성, 효율성, 수명에 영향을 끼치게 된다[2][3]. 베어링은 크게 Ball, Inner-Race(IR), Outer-Race(OR), Cage 로 구성된다. 그림 1에서는 CWRU[4] 데이터 집합을 수집하기 위한 베어링 테스트 장비를 보여주고 있다. 전통적인 방식의 기계의 유지, 보수는 기계에 결함이 발생한 후, 이루어진다. 이

리한 방식의 유지, 보수는 예상치 못한 기계의 고장을 일으키고, 금전적인 손실을 일으키게 된다. 따라서 베어링의 상태를 모니터링 하여 회전하는 베어링의 결함을 감지하는 것은 공학 분야에서 필수적인 부분이다[5].




Fig. 1. Bearing elements and an experimental setup of the CWRU bearing test rig for ball bearing system.
그림 1. 볼 베어링 시스템용 CWRU 테스트 장비의 구성 요소 및 실험 환경 설정

베어링 상태를 모니터링 하여 결함을 감지하는 것은 실제 기계의 상태를 알 수 있으며, 베어링 결함을 감지하기 위한 진동 신호는 기계의 결함을 감지하기 위한 가장 유용한 정보 중 하나이다[6][7]. 진동 신호는 여러 형태의 결함을 감지할 수 있으며, 결함을 감지하기 위해 충분한 정보를 제공한다. 진동신호는 주로 비선형적이며, 비정상적이다. 그러므로 진동 신호의 특징을 추출하는 것이 중요하다[8].

시간영역, 주파수영역, 시간-주파수 영역에서의 신호 처리 방법인 고속 푸리에 변환(FFT, Fast Fourier Transform)[9], 웨이블릿 변환(WT, Wavelet Transform)[10] 등은 베어링 결함 감지를 위한 특징 추출을 위해 사용된다. 위와 같은 방법은 다른 종류의 특징을 추출하며, 다른 종류의 베어링 진동 신호는 다른 특징을 사용해야 한다. 특징은 주파수 특성이나, 결함 베어링 신호의 특성 등을 추출하며 결함 분류를 위해 중요한 특성을 선택하여 사용한다.

결함과 정상 상태의 데이터 분류를 위해서는 인공신경망[11], 서포트 벡터 머신(SVM, Support Vector Machine)[12], 주성분 분석(PCA, Principle Component Analysis)[13], K-최근접 이웃(KNN, K-Nearest Neighbor)[14] 등과 같은 머신러닝 알고리즘이 베어링 결함 검출을 위해 널리 사용되고 있다. 하지만, 머신러닝 알고리즘은 다양한 형태의 데이터를 다루기에 적합하지 않다는 한계를

가진다. 머신러닝 알고리즘의 특징 추출 단계는 고정적으로 이루어진다. 하지만 산업장비의 진동신호는 주로 고정적이지 않으며, 고정적인 형태의 특징 추출은 경험과 높은 수준의 사전지식이 필요하다. 게다가 머신러닝 알고리즘은 한개 혹은 두개의 레이어에서 학습이 이루어지므로 결함 신호의 정보를 충분히 학습하지 못하는 경향이 있으므로 결함 진단의 정확도에 한계가 있다. 그러므로 머신러닝 알고리즘의 정확도는 현대의 결함 진단 방법론으로서 적절하지 못하다[15].

최근 딥 러닝을 여러 분야에 적용하는 것은 중요한 연구가 되었다. 딥 러닝 알고리즘의 출현은 위에서 언급했던 머신러닝의 문제점을 해결했다. 딥 러닝은 머신러닝의 한 분야로서 원본 데이터의 특징을 전문적인 경험이나 정의 없이 자동적으로 학습하여 높은 정확도를 가진다[16]. 딥 러닝 모델은 여러 층의 신경망으로 구성되며 입력 신호로부터 특징을 학습하며, 추출한다. 딥 러닝 알고리즘은 많은 양의 데이터를 가질 때 눈에 띄게 향상된 성능을 보인다[8]. 딥 러닝은 지도 학습, 비지도 학습, 전이 학습 알고리즘 등이 사용된다. 딥 러닝 구조에는 오토 인코더, 변이형 오토 인코더[17][18], 적대적 신경망[19][20], 강화학습[21], 합성곱 신경망(CNN) 등이 높은 성능을 보여준다.

베어링 결함 검출에서는 합성곱 신경망이 사용될 수 있으며, 1차원 합성곱 신경망과 2차원 합성곱 신경망이 사용된다. 1차원 합성곱 신경망은 CWRU 데이터 집합에 대한 베어링 결함 진단에서 데이터 증강을 사용하여 97.1%의 정확도를 보여준다[22]. 2차원 합성곱 신경망에서는 2가지 데이터 증강 방법과 5가지 데이터 증강 기법을 이용하여 최대 99.91%의 정확도를 보여주었다. 2차원 합성곱 신경망은 1차원 베어링 진동 신호의 2차원 표현으로 변환하여 사용되었다. 2차원 신호는 같은 길이의 진동신호로 분할되어 사용되었으며, 변환된 2차원 신호를 2차원 합성곱 신경망에 입력 데이터로 사용하였다. 2차원 신호의 모든 픽셀 값은 진폭을 -1에서 1까지의 값으로 정규화한 값을 사용하였다. 또한, U-net 구조를 사용한 2차원 베어링 진동신호의 결함 감지 모델은 98.91%의 정확도를 보여주었으며[23], 계층적 적용형 깊은 합성곱 신경망(ADCNN)에서는 97.7%의 정확도를 보여주었다[24].

II. 본론

1. 시스템 개요

베어링 결함 감지 모델을 구현하기 위해 그림 2와 같

은 방법을 사용하였다. 우선, 베어링 진동 신호의 원본 데이터를 매트랩 파일로 저장한 후, 연속 웨이블릿 변환을 통해 스켈로그램 이미지로 변환한 후 switchable 정규화 방법을 기반으로 한 합성곱 신경망(SN-CNN) 모델에 입력한다. 마지막으로, 성능 비교를 위해 같은 합성곱 신경망 모델에 스펙트로그램을 입력신호로 넣어 성능을 측정하고, switchable 정규화 방법 대신 배치 정규화 방법을 사용한 모델의 성능을 측정하여 결과를 분석하였다. 성능 측정을 위해 AUC(The Area Under the Curve)와 ROC(Receiver Operating Characteristics)를 사용하였다. AUC와 ROC는 각각의 데이터 클래스에 대해 표로 성능을 시각화하여 나타냈다.

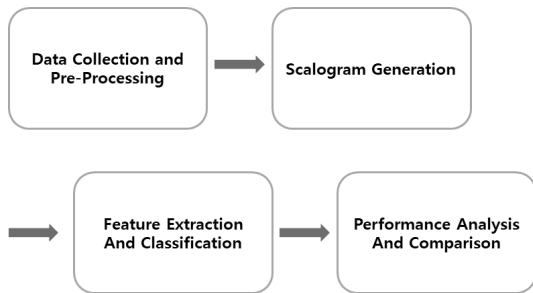


Fig. 2. Flowchart of Bearing Fault Detection Model.
그림 2. 베어링 결함 감지 모델 순서도

2. 연속 웨이블릿 변환

웨이블릿 변환은 비정상, 비선형 신호에 가장 적합하며 신호대 잡음비를 효과적으로 증가시킬 수 있다. 푸리에 변환이 기저 함수로 사인과 코사인 함수를 사용하는 것과 달리 웨이블릿 변환은 기저 함수 공간이 무한히 존재한다. 따라서, 웨이블릿 변환은 윈도우가 변하며 시간 특성, 주파수 특성이 높은 해상도를 가지므로 베어링 진동 신호를 더 정확하게 분석할 수 있다[25][26]. 웨이블릿 변환은 이산 웨이블릿 변환과 연속 웨이블릿 변환이 존재하며, 디테일한 시간-주파수 분석을 위해서는 연속 웨이블릿 변환이 사용된다.

연속, 이산 웨이블릿 변환은 이산화 방법의 지수 스케일의 파라미터가 다르다. 연속 웨이블릿 변환은 주로 지수함수의 밑을 2보다 작은 수로 사용한다. 반면에 이산 웨이블릿 변환은 항상 지수함수의 밑을 2로 사용한다. 그러므로 연속 웨이블릿 변환이 더 높은 해상도를 갖게 된다. 따라서 연속 웨이블릿 변환이 선호된다.

연속 웨이블릿 변환은 연속 타임 도메인 신호인 $x(t)$ 와 웨이블릿 함수의 상관관계로 만들어지며 웨이블릿 함수의 식은 식 (1)과 같다.

$$Cw(a,b) = \int_{-\infty}^{+\infty} x(t)\psi_{a,b}^* dt \tag{1}$$

$$= \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t)\psi^*\left(\frac{t-b}{a}\right) dt$$

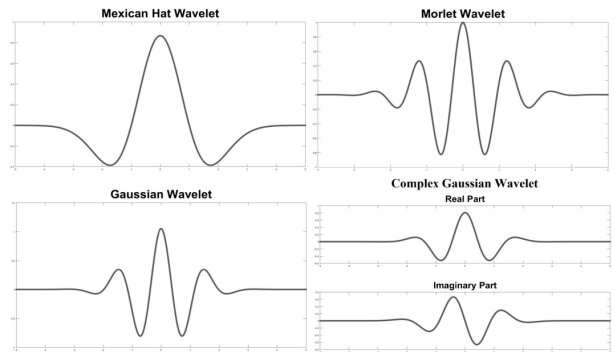


Fig. 3. Different types of continuous wavelets.
그림 3. 서로 다른 종류의 연속 웨이블릿 함수

Cw 는 웨이블릿 함수의 파라미터인 a, b 를 의미한다. ψ 는 연속 웨이블릿 함수의 종류를 의미한다. 연속 웨이블릿 변환은 파라미터 a 에 의해 스케일이 조정되며, b 에 의해 변환이 이루어진다. a 와 b 는 값이 연속적이므로 웨이블릿 변환 함수의 수는 무한하다.

가장 많이 사용되는 웨이블릿 함수는 그림 3과 같이 Mexican Hat, Morlet, Gaussian, Complex Gaussian wavelets등이 있다. Mexican Hat 웨이블릿은 간단하게 구성되며 빠르게 계산될 수 있는 알고리즘이다. 또한 라플라스 연산을 가우시안 함수에 적용하였으므로 가우시안 구조에 적합하다. 가우시안 웨이블릿은 Mexican Hat 웨이블릿과 유사하다. complex 웨이블릿은 양의 주파수에만 적용될 수 있다. Morlet 웨이블릿은 복소 지수가 가우시안 윈도우에 의해 곱해지며, 웨이블릿이 사람의 청각과 시각과 유사하며 시간-주파수 사이의 정보를 명확하게 이어준다.

연속 웨이블릿 변환은 스켈로그램이라는 시간-스케일의 스펙트럼을 만든다. 스켈로그램은 연속 웨이블릿 변환의 시간-주파수 함수의 절대 값을 가진다. 스펙트로그램은 입력신호를 윈도우 사이즈만큼 이동하여 시간-주파수 영역의 스펙트럼을 얻어낸다. 따라서, 실제 신호의 다른 스케일에서의 특징을 알아내기에는 스펙트로그램보다 스켈로그램이 더 뛰어나다.

연속 웨이블릿 변환에서 $2^{1/n}$ 와 같은 기저는 ‘voices per octave’라는 용어로서 사용되며 이 용어는 옥타브당 웨이블릿 필터의 개수를 표현하기 위해 사용된다[27]. 오디오 혹은 음악 신호에서 옥타브의 수는 주파수 분석

범위를 결정한다. 본 논문에서는 Morlet 웨이블릿을 사용하였다 Morlet 웨이블릿은 결함과 정상 베어링 진동 신호의 특성을 잘 나타내며 이전의 연구에서 좋은 성능을 보였으며 웨이블릿 함수의 연산량이 많지 않아 사용하게 되었다.

3. Switchable Normalization

정규화 방법은 딥 러닝 시스템의 필수적인 요소이며 일반화 성능을 개선하고 신경망의 최적화된 가중치를 찾아준다. 정규화 방법은 자연어처리, 컴퓨터 비전, 머신러닝 분야에서 연구되어 왔으며, 학습의 안정성을 높여주었다[20]. 정규화 방법은 크게 다음과 같은 세 가지 카테고리 나뉘어진다.

첫 번째로 가중치 정규화가 있다. 가중치 정규화는 해당 층의 가중치를 정규화 한다. 가중치 정규화는 식 7과 같이 최적화 한다. 두 번째는 신경망 층의 활성화 값을 정규화 하는 것이다. 배치 정규화(BN, Batch Normalization), Layer Normalization(LN)[28], Instance Normalization(IN)[29], Group Normalization(GN)[30] 등이 있다. 세 번째 방법은 위에서 설명한 방법을 결합시킨 Switchable Normalization(SN)이다[31].

Switchable normalization(SN)은 채널별, 층별, 미니 배치 별로 통계적 추정을 통해 IN, LN, BN 등을 결합하여 사용한다. SN은 정규화 방법의 중요도를 가중치로 학습하여 다양한 깊은 신경망에 적용시킬 수 있다. 하

나의 정규화 방법을 모든 층에 적용 시키는 것은 특정 작업에는 적합하지 않을 수 있다. 이미지 분류 혹은 물체 탐지 모델에서는 세 가지의 정규화 방법을 조합해서 사용하는 것이 선호되며 세 가지 정규화 방법의 최적의 조합을 찾기 위해서 SN이 사용된다. 이미지 분류에서 SN은 BN, IN, LN 세 가지 정규화 방법을 선택하여 사용하며 LSTM 구조에도 적용시킬 수 있다[31][32]. 그림 13은 SN을 시각화 한 그림이며 특징 맵을 $N \times C \times H \times W$ 형태로 나타내었다. N은 샘플 수, C는 채널 사이즈, H와 W는 특징의 공간축이다. BN은 NHW축을 사용하고 IN은 HW축, LN는 CHW 방향으로 정규화 한다. SN은 BN, LN, IN을 세 개의 정규화 방법의 중요도에 대한 가중치를 학습 중에 자동적으로 찾아서 알맞은 정규화 방법을 사용한다.




Fig. 4. The intuitive graphical representation of SN.
그림 4. SN 동작의 직관적 표현도

4. SN-CNN 모델

본 논문에서는 베어링 결함 분류를 위한 특징 추출을 위해서 합성곱 신경망(CNN)을 사용하였다. CNN은 효율

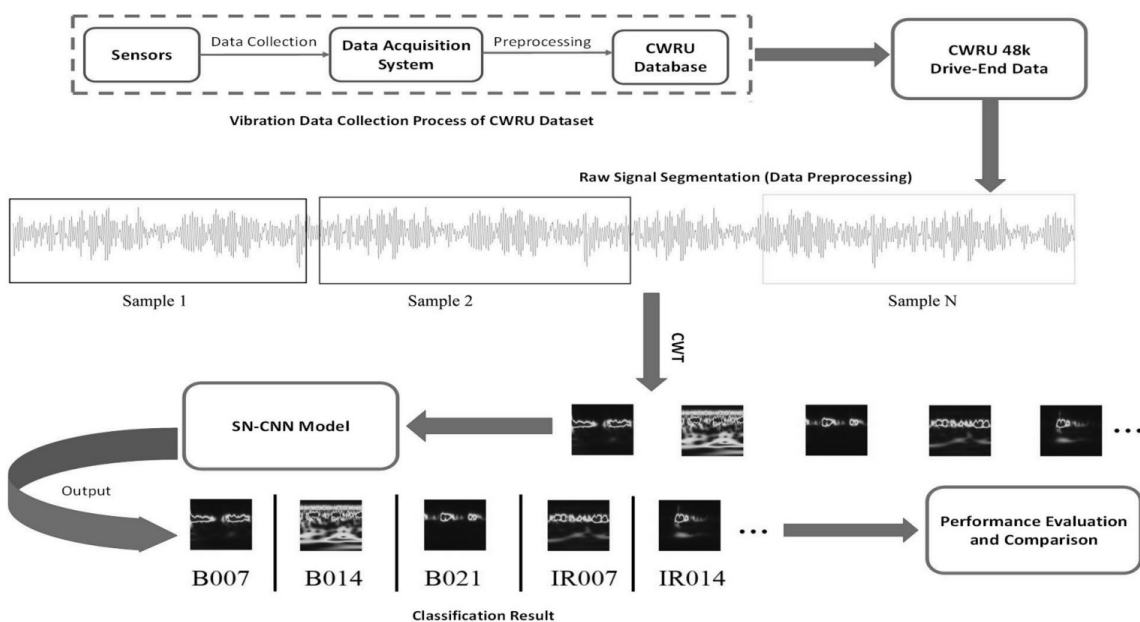


Fig. 5. Flow-Chart of the proposed SN-CNN model.
그림 5. 제안하는 SN-CNN 모델의 플로우 차트

적으로 픽셀 정보를 다운샘플링 하여 특징을 추출하고, 마지막에는 완전연결층(FC, Fully Connected Layer)을 통해 분류를 한다. 연속 웨이블릿 변환은 시간-주파수 영역에서의 특징 생성을 위해 이루어지며 Switchable Normalization을 통해 더 효율적이고 견고한 모델을 제안한다. SN-CNN은 Switchable Normalization과 CNN을 사용하여 분류를 한 모델이며 그림 5는 SN-CNN의 플로우 차트를 나타낸 그림이다. 플로우 차트의 설명은 다음 리스트와 같다.

- 진동데이터(48k DE data of load 1, 2, 3 hp)는 CWRU 데이터 집합을 결함 종류에 따라 10개의 클래스로 분류하였다. 또한, 각각의 클래스 데이터를 2048개의 데이터 포인트들로 이루어진 샘플로 나누었다.
- 나뉜진 진동 데이터는 연속 웨이블릿 변환을 통해 스칼로그램 이미지로 변환한다. 스칼로그램 이미지 사이즈는 $100 \times 100 \times 3$ 이다.
- 스칼로그램 이미지 데이터 집합은 훈련, 테스트, 검증 데이터 집합으로 나누어져야하며, 데이터 집합은 SN-CNN 모델의 특징 추출과 분류를 학습하기 위해 사용된다.
- 다음 단계는 배치정규화 기반 합성곱 신경망(BN-CNN)를 이용해 성능을 비교한다. 또한, 스칼로그램 이미지 대신 스펙트로 그램 이미지를 사용하여 SN-CNN 모델에 넣어 성능을 비교한다. 성능 평가는 AUC와 ROC커브를 이용해 이루어지며, 각각의 데이터 집합에 대한 confusion matrix를 통해 시각화 하였다.

III. 실험

1. 데이터 수집 및 전처리

해당 연구를 위해서 CWRU 베어링 데이터 집합이 사용되었다. CWRU 데이터 집합은 가장 많이 사용되는 베어링 진동 신호 데이터 집합 중 하나이며, Case Western Reserve University의 웹사이트에서 제공받을 수 있다. CWRU 베어링 데이터 집합은 대부분 기계의 결함 분석, 분류, 감지 등에 사용된다.

CWRU 베어링 데이터 집합의 수집은 그림 1과 같이 이루어진다. 그림에서는 볼 수 없지만 기계는 전기 유도 모터, dynamometer, 토크 변환기, 전기 제어 장치로 이루어져 있다. 진동 신호 수집 장치는 single-point drive-end(DE)와 fan-end(FE)로 이루어져 있으며 두 가지 신

호를 모두 수집하였다. 데이터 집합은 모두 161개로 그룹화 되었으며 크게 48k drive-end fault, 48k normal-baseline, 12k drive-end falut, 12k fan-end fault로 분류된다[33]. 또한 결함의 크기에 따라서도 분류되며, 결함의 크기는 7mils, 14mils, 21mils가 있다. 1 mil은 0.001인치를 의미한다. 또한, 진동 데이터는 0, 1, 2, 3의 horse-power로 녹음되었으며, 1720에서 1797까지의 rpm을 가진다. 결함의 종류는 Ball Crack, Inner-race Crack, Outer-race Crack 세 종류이고 비결함 베어링 진동 신호도 있다. 클래스는 결함 크기, 결함 종류, 결함 여부로 나누어 10개의 클래스를 만들었다. 예를 들어, 7mils Ball Crack, 14mils Outer-race Crack, 정상 클래스 등과 같이 분류된다. 데이터 집합은 총 A, B, C, D의 네가지 데이터 집합으로 나누었다. A 데이터 집합은 48k DE 1Hp load 데이터를, B 데이터 집합은 48k DE 2Hp load 데이터, C 데이터 집합은 48k DE 3Hp load 데이터, D 데이터 집합은 A, B, C 데이터 집합을 모두 모아 저장하였다. 다른 load의 데이터를 모두 합치는 것은 언뜻 보기에는 논리적이지 못한 일로 보일 수 있다. 하지만 load는 사실상 토크에 거의 영향을 주지 못하기 때문에 베어링 결함 진단에서는 의미가 없는 수치이다. load의 변화는 최대 로드인 3hp와 1hp를 비교 하면 shaft 속도가 4%정도 차이가 났다[34][35]. 이는 베어링 결함 진단에는 크게 영향을 끼치지 않는다. 데이터 전처리 단계에서는 진동 신호를 2048개의 데이터 포인트로 이루어진 N개의 데이터 샘플로 나눈다. 데이터 집합 A에서는 각 클래스마다 186개, B와 C에서는 236개가 있다. 딥 러닝을 사용 할 때 데이터 증강을 적용하여 데이터를 증강하면 딥 러닝 알고리즘에 적용 가능한 수의 데이터를 얻을 수 있다. 데이터 증강은 flipping을 통해 각 데이터 집합의 2배의 데이터 증강이 이루어졌다. 따라서 데이터 집합 A는 각 클래스 마다 372개의 데이터, B와 C는 472개의 데이터를 얻을 수 있었다.

Table 1. Class labels and the respective bearing fault conditions.

표 1. 베어링 결함 클래스 레이블

Class	Fault Type	Class	Fault Type
1	B007	6	IR021
2	B014	7	Normal
3	B021	8	OR007
4	IR007	9	OR014
5	IR014	10	OR021

표 1은 각 데이터 집합의 클래스를 나타낸 것이다. B, IR, OR은 각각 Ball Crack, Inner-race Crack, Outer-race Crack을 의미한다. 또한, 뒤에 붙은 숫자는 결함의 지름을 의미한다. 예를 들어, B007은 7 mils의 Ball Crack을 녹음한 베어링 진동 신호를 의미한다.

2. 스펙로그램 이미지 생성

2048개의 데이터 포인트로 나눈 N개의 데이터 샘플을 연속 웨이블릿 변환 함수중 하나인 Morlet wavelet을 사용하여 베어링 진동신호를 스펙로그램 이미지로 변환한다. voices per octave의 수는 12로 설정하였고, 스펙로그램 이미지 사이즈는 100×100×3으로 변환되며, 이 사이즈는 SN-CNN의 인풋 사이즈가 된다. 그림 15에서는 10개의 다른 클래스의 스펙로그램 이미지를 나열하였다.




Fig. 6. Scalogram images of ten different health conditions. 그림 6. 베어링 결함 종류에 따른 스펙로그램 이미지

3. 특징 추출과 분류

스펙로그램 이미지는 훈련, 테스트, 검증을 위해 0.7 : 0.2 : 0.1으로 나눈다. 클래스의 수는 10개이며 표 2에서 각각의 데이터 집합에 대한 샘플 수를 나타내었다.

Table 2. Length of train, test, and validation set used in the research.

표 2. 훈련, 테스트, 검증 데이터 집합의 크기

Dataset	Total Samples	Train Set	Test Set	Validation Set
48k DE Load1 (A)	3720	2700	720	300
48k DE Load2 (B)	4720	3410	940	370
48k DE Load3 (C)	4720	3410	940	370
D(A+B+C)	13160	9510	2600	1050

SN-CNN 모델에서는 8계층의 딥 러닝 신경망을 사용한다. 신경망의 구조는 5개의 특징 추출을 위한 층이 있다. 각각의 특징 추출 층은 합성 곱, ReLU 활성화 함수, swtichable normalization, max-polling 층으로 구성

Table 3. Model Specifications.

표 3. 모델 상세 정보표

Category	Values
# of Params	258.664
Size of Model	3,135 (KB)
Calculation Speed	7.7 (ms, per 1 batch, 32 images)

된다. 합성 곱 블록은 필터 사이즈 3×3, stride 사이즈 1으로 설정하였고, max-pooling 층의 사이즈는 2×2, stride 사이즈 1으로 설정하였다. 또한 가중치 초기화 방법으로 he_normal[36] 커널 초기화 방법을 사용했다. 5개의 합성 곱 층에서 필터 개수는 각각 다르며, 첫 번째 층부터 64, 32, 64, 32, 64개의 합성 곱 층을 사용하였다. 합성 곱 층이 끝나고 두개의 완전연결층을 가지고 256, 128의 사이즈를 사용하였다. 또한 드롭아웃 방법을 적용하여 훈련 데이터에 대한 과 적합을 방지였다. 드롭아웃은 각각의 완전연결층에 사용되었으며, 0.2의 비율을 사용하였다. 마지막으로 10개의 클래스를 분류하기 위한 마지막 층에서는 SoftMax 활성화 함수를 사용하였다. 러닝 레이트는 0.001로 설정 하였고, Adam[37] 옵티마이저를 사용하였다.

SN-CNN 모델의 구조는 그림 16에서 나타내었다. 표 3에서는 SN-CNN 모델의 각 층과 각 층에서의 파라미터 수를 정리하였다.

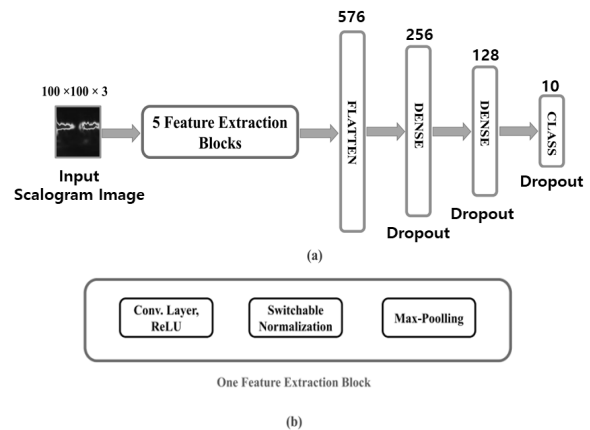


Fig. 7. Network architecture of SN-CNN model.

그림 7. SN-CNN 모델 구조

4. 성능 분석

그림 8은 배치사이즈 32로 학습한 후 훈련, 테스트, 검증 데이터의 정확도를 표로 나타내었다. 평가는 스펙트로그램과 스펙로그램 이미지를 SN-CNN 모델에 넣어 진행하였고 데이터 집합 A, B, C, D를 사용하였다. ‘SCG’는 스펙로그램, ‘SPG’는 스펙트로그램을 의미한다.

Input	Dataset	Training Accuracy	Testing Accuracy	Validation Accuracy
Scalogram	A	100%	99.86%	100%
Spectrogram	A	99.46%	97.79%	97.32%
Scalogram	B	100%	99.78%	99.19%
Spectrogram	B	100%	97.73%	97.30%
Scalogram	C	100%	99.89%	100%
Spectrogram	C	99.41%	98.04%	38.92%
Scalogram	D	100%	99.88%	99.71%
Spectrogram	D	99.97%	97.12%	96.12%

Fig. 8. SN-CNN model accuracy for scalogram and spectrogram images.

그림 8. 스켈로그램과 스펙트로그램의 성능비교표

DS/BS	Accuracy(SN-CNN)			Accuracy(BN-CNN)		
	Train	Test	Valid.	Train	Test	Valid.
A/16	100%	99.58%	100%	99.96%	98.21%	94.33%
B/16	100%	99.78%	100%	99.65%	97.60%	98.68%
C/16	100%	100%	100%	99.68%	97.90%	98.42%
D/16	100%	99.92%	100%	99.83%	98.18%	98.11%
A/32	100%	99.72%	100%	99.96%	98.22%	94.67%
B/32	99.73%	99.79%	99.73%	99.68%	97.91%	98.38%
C/32	100%	99.75%	100%	99.39%	97.81%	98.42%
D/32	100%	99.73%	99.52%	99.74%	97.89%	97.26%
A/64	100%	99.44%	99.33%	99.93%	98.63%	94.67%
B/64	100%	99.57%	100%	99.65%	98.01%	98.68%
C/64	100%	99.68%	99.46%	99.65%	98.22%	98.42%
D/64	100%	99.84%	99.52%	99.84%	98.14%	97.29%

Fig. 9. The efficiency of SN-CNN and BN-CNN model using scalogram as input.

그림 9. 스켈로그램 이미지를 입력으로 사용했을 때 SN-CNN과 BN-CNN 성능비교표

같은 구조의 베어링 결함 감지 모델에 배치 정규화 방법 대신 switchable normalization을 사용하여 두 개의 모델을 비교하였다. 또한 비교를 위해 배치 사이즈를 16, 32, 64를 사용하여 A, B, C, D 각각의 데이터 집합에 적용하여 실험을 진행하였다. 해당 결과는 그림 9에 정리되어 있다.

IV. 결론

4차 산업 혁명으로 인해 딥 러닝 알고리즘은 여러 연구 분야에 적용되고 있다. 기계 결함 진단을 위해 딥 러닝 알고리즘이 사용되며, 높은 성능을 보여주고 있다. 따라서 본 논문에서는 딥 러닝 알고리즘을 통해 기계 결함 진단을 하였다. 또한, 데이터로 CWRU 베어링 데이터 집합을 이용하여 연속 웨이블릿 변환을 이용한 전처리 과정을 거쳤으며 SN-CNN(Switchable normalization-based convolutional neural network) 모델을 사용하여 정상 클래스 1개와 결함 종류에 따른 9개의 클래스로 분류하였다. 모델의 성능 비교를 위해 연속 웨이블릿 변환을 사용한 성능과 스펙트로그램을 사용한 성능을 비교하고, SN-CNN과 BN-CNN의 성능을 비교하였다. 성능은 연속 웨이블릿 변환과 SN-CNN을 사용할 때 가장 높은 정확도를 보여주었으며 테스트 정확도는 데이터 집합 'A', 'B', 'C', 'D'에서 99.44%에서 100%까지의 정확도를 보였다.

References

- [1] Ioffe, Sergey, and Christian Szegedy. "Batch normalization: Accelerating deep network training by reducing internal covariate shift," ICML, 2015.
- [2] 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. DOI: 10.1109/ACCESS.2020.2990528
- [3] D. Neupane and J. Seok, "'Deep learning-based bearing fault detection using 2-D illustration of time sequence," in *Proc. Int. Conf. Inf. Commun. Technol. Converg. (ICTC)*, pp.562-566, 2020. DOI: 10.1109/ICTC49870.2020.9289232
- [4] Case Western Reserve University Bearing Data Center. Accessed: 22, 2019. [Online]. Available: <https://csegroups.case.edu/bearingdatacenter/home>
- [5] C. Sun, Z. Zhang, Z. He, Z. Shen, and B. Chen, "Manifold learning-based subspace distance for machinery damage assessment," *Mech. Syst. Signal Process.*, vol.70-71, pp.637-649, 2016. DOI: 10.1016/j.ymsp.2015.09.032

- [6] A. Boudiaf, A. Moussaoui, A. Dahane, and I. Atoui, "A comparative study of various methods of bearing faults diagnosis using the case western reserve university data," *J. Failure Anal. Prevention*, vol.16, no.2, pp.271-284, 2016. DOI: 10.1007/s11668-016-0080-7
- [7] M. S. Safizadeh and S. K. Latifi, "Using multi-sensor data fusion for vibration fault diagnosis of rolling element bearings by accelerometer and load cell," *Inf. Fusion*, vol.18, no.1, pp.1-8, 2014. DOI: 10.1016/j.inffus.2013.10.002
- [8] L. Yuan, D. Lian, X. Kang, Y. Chen, and K. Zhai, "Rolling bearing fault diagnosis based on convolutional neural network and support vector machine," *IEEE Access*, vol.8, pp.137395-137406, 2020. DOI: 10.1109/ACCESS.2020.3012053
- [9] V. K. Rai and A. R. Mohanty, "Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert-Huang transform," *Mech. Syst. Signal Process.*, vol.21, no.6, pp.2607-2615, 2007. DOI: 10.1016/j.ymsp.2006.12.004
- [10] Z. Peng, F. Chu, and Y. He, "Vibration signal analysis and feature extraction based on reassigned wavelet scalogram," *J. Sound Vib.*, vol.253, no.5, pp.1087-1100, 2002. DOI: 10.1006/jsvi.2001.4085
- [11] M.-Y. Chow, P. M. Mangum, and S. O. Yee, "A neural network approach to real-time condition monitoring of induction motors," *IEEE Trans. Ind. Electron.*, vol.38, no.6, pp.448-453, 1991. DOI: 10.1109/41.107100
- [12] Y. S. Wang, Q. H. Ma, Q. Zhu, X. T. Liu, and L. H. Zhao, "An intelligent approach for engine fault diagnosis based on Hilbert-Huang transform and support vector machine," *Appl. Acoust.*, vol.75, no.1, pp.1-9, 2014. DOI: 10.1016/j.apacoust.2013.07.001
- [13] A. Malhi and R. X. Gao, "PCA-based feature selection scheme for machine defect classification," *IEEE Trans. Instrum. Meas.*, vol.53, no.6, pp.1517-1525, 2004. DOI: 10.1109/TIM.2004.834070
- [14] D. H. Pandya, S. H. Upadhyay, and S. P. Harsha, "Fault diagnosis of rolling element bearing with intrinsic mode function of acoustic emission data using APF-KNN," *Expert Syst. Appl.*, vol.40, no.10, pp.4137-4145, 2013. DOI: 10.1016/j.eswa.2013.01.033s
- [15] Z. Chen, J. Cen, and J. Xiong, "Rolling bearing fault diagnosis using timefrequency analysis and deep transfer convolutional neural network," *IEEE Access*, vol.8, pp.150248-150261, 2020.
- [16] D. Neupane and J. Seok, "A review on deep learning-based approaches for automatic sonar target recognition," *Electronics*, vol.9, no.11, pp.1972, 2020. DOI: 10.3390/electronics9111972
- [17] J. Sun, C. Yan, and J. Wen, "Intelligent bearing fault diagnosis method combining compressed data acquisition and deep learning," *IEEE Trans. Instrum. Meas.*, vol.67, no.1, pp.185-195, 2018. DOI: 10.1109/TIM.2017.2759418
- [18] C. Li, W. Zhang, G. Peng, and S. Liu, "Bearing fault diagnosis using fully-connected winner-take-all autoencoder," *IEEE Access*, vol.6, pp.6103-6115, 2018. DOI: 10.1109/ACCESS.2017.2717492
- [19] W. Jiang, C. Cheng, B. Zhou, G. Ma, and Y. Yuan, "A novel GANbased fault diagnosis approach for imbalanced industrial time series," 2019, arXiv:1904.00575. Accessed: 7, 2020. [Online]. Available: <http://arxiv.org/abs/1904.00575>
- [20] D. Zhao, F. Liu, and H. Meng, "Bearing fault diagnosis based on the switchable normalization SSGAN with 1-D representation of vibration signals as input," *Sensors*, vol.19, no.19, pp.2000, 2019.
- [21] R. Wang, H. Jiang, X. Li, and S. Liu, "A reinforcement neural architecture search method for rolling bearing fault diagnosis," *Measurement*, vol.154, Art. no.107417, 2019.
- [22] L. Eren, "Bearing fault detection by one-dimensional convolutional neural networks," *Math. Problems Eng.*, vol.2017, pp.1-9, 2017. DOI: 10.1155/2017/8617315
- [23] D. K. Soother, I. H. Kalwar, T. Hussain, B. S. Chowdhry, S. M. Ujjan, and T. D. Memon, "A novel method based on UNET for bearing fault diagnosis," *Comput., Mater. Continua*, vol.69, no.1, pp.393-408, 2021.

DOI: 10.32604/cmc.2021.014941

[24] X. Guo, L. Chen, and C. Shen, "Hierarchical adaptive deep convolution neural network and its application to bearing fault diagnosis," *Meas. J. Int. Meas. Confederation*, vol.93, pp.490-502, 2016. DOI: 10.1016/j.measurement.2016.07.054

[25] P. M. Bentley and J. T. E. McDonnell, "Wavelet transforms: An introduction," *Electron. Commun. Eng. J.*, vol.6, no.4, pp.175-186, 1994.

DOI: 10.1049/ecej_19940401

[26] L. Saribulut, A. Teke, M. B. Latran, and M. Tümay, "Fundamentals and literature review of wavelet transform in power quality issues," *J. Electr. Electron. Eng. Res.*, vol.5, no.1, pp.1-8, 2013. DOI: 10.5897/JEEER2013.0435

[27] D. Komorowski and S. Pietraszek, "The use of continuous wavelet transform based on the fast Fourier transform in the analysis of multi-channel electrogastrography recordings," *J. Med. Syst.*, vol.40, no.1, pp.1-15, 2016.

DOI: 10.1007/s10916-015-0358-4

[28] Ba, Jimmy Lei, Jamie Ryan Kiros, and Geoffrey E. Hinton. "Layer normalization," *NeurIPS workshop*, 2016.

[29] V. Dumoulin, J. Shlens, and M. Kudlur. "A learned representation for artistic style," *ICLR*, 2017.

[30] Wu, Yuxin, and Kaiming He. "Group normalization," *ECCV*, 2018.

[31] P. Luo, R. Zhang, J. Ren, Z. Peng, and J. Li, "Switchable normalization for learning-to-normalize deep representation," *IEEE Trans. Pattern Anal.* vol.43, no.2, pp.712-728, 2021.

DOI: 10.48550/arXiv.1806.10779

[32] P. Luo, J. Ren, Z. Peng, R. Zhang, and J. Li, "Differentiable learning-to-normalize via switchable normalization," in *Proc. 7th Int. Conf. Learn. Represent. (ICLR)*, pp.1-19, 2019.

[33] W. A. Smith and R. B. Randall, "Rolling element bearing diagnostics using the case western reserve university data: A benchmark study," *Mech. Syst. Signal Process.*, vols.64-65, pp.100-131, 2015.

DOI: 10.1016/j.ymsp.2015.04.021

[34] W. Huang, J. Cheng, and Y. Yang, "Rolling bearing fault diagnosis and performance degradation assessment under variable operation conditions based on nuisance attribute projection," *Mech. Syst. Signal Process.*, vol.114, pp.165-188, 2019.

DOI: 10.1016/j.ymsp.2018.05.015

[35] X. Li, W. Zhang, and Q. Ding, "A robust intelligent fault diagnosis method for rolling element bearings based on deep distance metric learning," *Neurocomputing*, vol.310, pp.77-95, 2018.

DOI: 10.1016/j.neucom.2018.05.021

[36] He, Kaiming, et al. "Delving deep into rectifiers: Surpassing human-level performance on imagenet classification," *ICCV*, 2015.

[37] Kingma, Diederik P., and Jimmy Ba. "Adam: A Method for Stochastic Optimization," *ICLR*, 2015.

BIOGRAPHY

Myagmar Delgermaa (Member)



2015 : BS degree in Dept. of Information & Computer Science, National University of Mongolia.
2021~ : MS degree in Dept. of Information & Communication Engineering, Changwon National University.

Yun-Su Kim (Member)



2020 : BS degree in Dept. of Information & Communication Engineering, Changwon National University.
2022 : MS degree in Dept. of Information & Communication Engineering, Changwon National University.

2022~ : Ph.D degree in Dept. of Information & Communication Engineering, Changwon National University.

Jong-Won Seok (Member)

1995 : MS degree in Electronics Engineering, Kyungpook National University

1999 : Ph.D degree in Electronics Engineering, Kyungpook National University

2004~ : Professor, Changwon National University.