

CNN 기반 이상 진동 강조 필터뱅크를 활용한 회전체의 볼 베어링 결함 감지에 관한 연구

성규진, 이태목, 김재욱, 김동완*

동아대학교

dlrntka7592@gmail.com, dlxoahr999@gmail.com, z13zrn@gmail.com, *dongwankim@dau.ac.kr

A Study on CNN-Based Ball Bearings Fault Detection of a Rotating Shaft Using abnormal vibration emphasis Filter Bank

Gyujin Seong, Taemok Lee, Jaewook Kim, Dongwan Kim*

Dong-A Univ.

요약

볼 베어링의 특성상 장시간 운전으로 파손 가능성이 높은 회전 기계의 구성요소이다. 볼 베어링의 결함은 회전 기계의 오동작을 유발하는 주요 원인이며 회전 기계는 오동작할 때 이상 진동을 발생시키며 센서를 통해 진동 특징을 추출하는 것이 가능하다. 본 논문은 신호 처리 및 Convolutional Neural Network(CNN) 기반 볼 베어링 결함 분류를 진행한다. 신호 처리에서는 Mel-Frequency Cepstral Coefficient(MFCC)의 순서를 따른다. 그 과정에서 회전체 이상 진동 특징을 강조할 수 있는 Modified Scale이 적용된 Modified Filter Bank를 구현하고 스펙트로그램을 생성한다. 스펙트로그램을 이용하여 분류를 진행하기 위한 CNN 모델을 구현하고 학습 및 평가를 진행하였다 그 결과 테스트 데이터의 분류에서 95.21%의 정확도를 보였다. 이를 통해 Modified Filter Bank가 적용된 스펙트로그램 이미지는 이상 진동 특징을 증폭시켜 볼 베어링 결함 감지에 적용할 수 있다.

I. 서론

볼 베어링은 회전체의 중심축을 고정하기 위해 필수적인 부품이다. 볼 베어링은 일반적으로 내·외륜 사이에 구름 접촉된 상태로 장시간 운전하기 때문에 다른 부품들보다 파손될 가능성이 높다. 볼 베어링의 파손은 회전축을 비틀어 회전 기계 오동작의 주요 원인이 되며, 공정 중단, 인명 사고 등의 문제를 유발할 수 있다. 회전 기계는 운전 시 필수적으로 진동 신호를 방출하게 된다. 진동 신호는 기계의 상태를 나타내는 포괄적인 지표이므로 볼 베어링의 결함 감지 특징 추출에 효과적이다.[1] 특히 Mel-Frequency Cepstral Coefficient(MFCC)는 진동 신호에 대한 특징 벡터 추출에 좋은 성능을 보인다.[2] 최근 볼 베어링의 결함 진단에서는 기계학습 알고리즘을 적용하여 진동 신호 특징을 검출하는 연구가 진행되고 있다.[3] 본 논문에서는 볼 베어링의 결함을 감지하기 위해 MFCC 신호 처리 과정을 따르며, 회전체의 특징을 강조할 수 있는 Modified Scale을 제시한다. 생성된 스펙트로그램을 Convolutional Neural Network(CNN) 모델에 학습시킨다. 또한, 모델의 정확도를 검증한다.

표 1. 볼 베어링 구성요소들의 세부사항

Component	Value
내부 레이스 직경 [mm]	25.4
외부 레이스 직경 [mm]	50.8
공의 지름 [mm]	7.6
피치 지름 [mm]	38.1
볼 베어링의 공의 개수 [EA]	9

표 2. 볼 베어링 데이터 수집 조건

Conditions	Input shaft rate [Hz]	Fault size [mm]	Motor load [HP]
정상	48	X	0, 1, 2, 3
볼 결함		0.18, 0.36, 0.53	

II. 본론

본 논문에서 사용되는 데이터 세트는 Case Western Reserve University

에서 제공한 볼 베어링 결함 유무에 따른 진동 신호 데이터 세트이다.[4] 진동 신호는 초당 48,000번 테스트 장비에 부착된 가속도 센서를 통해 수집됐다. 표 1은 테스트 장비의 볼 베어링 구성의 세부 사항이며, 표 2는 데이터가 수집 조건이다. 본 논문에서 제안하는 신호 처리는 Google Colaboratory 환경에서 Python을 사용하였으며 CNN 모델 구현 및 검증 평가는 MATLAB을 사용하였다. 볼 베어링 진동 신호의 특징 추출을 위한 신호 처리는 Pre-Emphasis Filter 적용, Short-Time Fourier Transform(STFT), 전력 스펙트럼, Modified Filter Bank 적용, 스펙트로그램 생성의 순서로 진행된다. Pre-Emphasis Filter는 주파수 스펙트럼의 균형을 맞추고 높은 스케일링의 연산 문제를 방지하기 위해 사용되며 식 (1)에서 나타낸 α 는 필터 계수이다.

$$y(t) = x(t) - \alpha \cdot x(t-1) \quad (1)$$

STFT는 진동 신호의 각 시간 구간에서의 주파수의 특징을 얻어내기 위한 기법이며 Framing과 Tapering으로 나눌 수 있다. Framing은 진동 신호를 일정 시간 구간으로 Frame을 분할하여 각 시간 구간에서의 주파수 특성을 파악할 수 있도록 한다. Tapering은 분할된 각각의 Frame에 Window Filter를 적용하여 푸리에 변환 시 프레임들의 불연속으로 인한 주파수 신호의 분해능을 향상한다. 본 논문에서는 Sidelobe가 큰 Window Filter인 Hamming Filter를 적용하여 손실된 신호를 보상한다. 전력 스펙트럼은 볼 베어링에 결함이 있을 때 내·외부 요소들은 결함이 있는 부위와 충돌하며 충격으로 인해 발생하는 에너지를 검출하기 위해 사용되며 각 프레임의 평균적인 에너지를 의미하며 식 (2)에서 나타낸 N 은 나타낼 주파수 성분의 개수이며 512를 사용한다.

$$P = \frac{|FFT(x_i)|^2}{N} \quad (2)$$

그림 1에 도시한 Mel-Scale Filter Bank는 Mel-Scale에 따라 삼각형 필터의 조합으로 만들어지며 저주파수에서 더 높은 분해능을 가진다.




그림 1. Mel-Scale에 따른 Filter Bank

식 (3),(4) 및 그림 2는 회전 기계의 진동이 정상 진동 특징을 최소화하고 이상 진동의 특징을 강조한 Modified Scale이다. f 는 기존 주파수, r 는 Modified value, s 는 Scale Factor, a 는 Main Vibration, c 는 Resolution으로 표현할 수 있다. 식 (5),(6)는 Modified Scale의 역함수로 r 를 통해 f 를 구할 수 있다. Modified Scale은 파라미터의 변경을 통해 고속의 회전체에서도 적용할 수 있도록 구현되었다. 그림 3은 Modified Filter Bank에 적용하여 얻은 정상 및 이상 진동 신호의 스펙트로그램 데이터 세트다.

$$n = \frac{50}{49} \cdot s \cdot \left(\frac{1}{1 + \exp\left(\frac{1}{c}(a-f)\right) + \ln(49)} \right) \quad x \geq a \quad (3)$$

$$n = \frac{50}{49} \cdot s \cdot \left(\frac{1}{1 + \exp\left(\frac{1}{c}(a-f)\right) - \ln(49)} \right) \quad x \leq a \quad (4)$$

$$f = c \cdot \left(\ln\left(\frac{49n-48s}{98s-49n}\right) + \ln(49) \right) + a \quad x \geq s \quad (5)$$

$$f = c \cdot \left(\ln\left(\frac{49n}{50s-49n}\right) - \ln(49) \right) + a \quad x \leq s \quad (6)$$




그림 2. Modified Scale 그래프 형태




그림 3. 정상 진동 스펙트로그램(a)과 이상 진동 스펙트로그램(b)

CNN은 스펙트로그램 데이터 세트를 검증하는 수단으로 사용됐으며, 표 3에 아키텍처를 나타내었다. 정상 및 이상 진동 스펙트로그램 데이터를 사용하여 훈련과 검증을 진행했다. 훈련, 검증, 테스트 데이터는 각각 68%, 17%, 15%를 사용하였으며 평가 데이터 세트를 무작위로 사용하여 학습을 진행하였다. 이후 학습된 CNN 모델을 이용하여 분류를 진행하였다. 결함 분류 결과 검증 데이터에서 98.54% 테스트 데이터에서 95.21%의 정확도가 보이며 분류 결과에 따른 혼동행렬은 그림 4에 나타났다.

표 3. CNN 모델 아키텍처

Layer	Data size	Kernel size	Activation Function
Input data	227x227x3	X	X
Convolution	114x114x32	7x7x32	Cliped Rectified Linear Unit
Cross Channel Normalization (Window Channel Size = 5)			
Global Average Pooling (\cong Flatten)			
Fully Connected	32	X	Cliped Rectified Linear Unit
Drop out	0.5		
Fully Connected	2	X	X
Output data	6	x	Softmax

실제 클래스	Normal	761	8	실제 클래스	Normal	866	7
	Failure	41	214		Failure	10	280
예측 클래스				예측 클래스			
(a)				(b)			

그림 4. 검증 데이터 분류 혼동행렬(a)과 테스트 데이터 분류 혼동행렬(b)

III. 결론

본 논문에서는 볼 베어링의 진동 데이터 세트로 Modified Filter Bank를 적용하여 스펙트로그램을 만들었다. 또한, CNN 분류 모델이 볼 베어링의 결함을 잘 분류할 수 있는지를 검증하였다. 평가 결과 CNN 모델에서 Modified Filter Bank를 적용한 스펙트로그램 데이터는 95.21%의 정확도를 검출하였고 볼 베어링 결함 감지에 적용 가능성을 보였다.

ACKNOWLEDGMENT

이 논문은 2021년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(NRF-2021R1F1A1062443, 지능형 전파센싱 기반 블랙아이스탐지기술에 대한 연구)과 2023년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원(IITP)의 지원을 받아 수행된 연구임 (2022-0-00194, ICT R&D우수IP창출활용지원)

참 고 문 헌

- [1] Li, F., Meng, G., Ye, L., and Chen, P. "Wavelet transform-based higher-order statistics for fault diagnosis in rolling element bearings." *Journal of Vibration and Control*, pp. 1691-1709. 2008.
- [2] Hwang, C. H., Kang, M. S., and Kim, J. M. "A Study on Robust Feature Vector Extraction for Fault Detection and Classification of Induction Motor in Noise Circumstance." *Journal of the Korea Society of Computer and Information*, pp. 187-196. 2011.
- [3] Liu, R., Yang, B., Zio, E., and Chen, X. "Artificial intelligence for fault diagnosis of rotating machinery: A review." *Mechanical Systems and Signal Processing*, pp. 33-47. 2018.
- [4] CWRU, "48k Drive End Bearing Fault Data," Jan 2022 <https://engineering.case.edu/>