

베어링 고장 진단을 위한 CNN 기반 딥러닝의 계산 복잡도 감소 기법

박재현¹ · 김철홍^{2*}¹송실대학교 컴퓨터학과 박사과정^{2*}송실대학교 컴퓨터학부 교수

Computation Reduction Method for CNN-based Bearing Fault Diagnosis

Jae Hyun Park¹ · Cheol Hong Kim^{2*}¹Doctoral Course, Department of Computer Science and Engineering, Soongsil University, Seoul 06978, Korea^{2*}Professor, School of Computer Science and Engineering, Soongsil University, Seoul 06978, Korea

[요약]

산업 현장에서 사용되는 회전 기계의 상태를 진단하는 데 있어서 주요 부품인 베어링의 결함 발생 여부를 빠르고 정확하게 판단하는 것은 매우 중요하다. 베어링 고장 진단을 위해 최근에는 딥러닝 기법이 많이 활용되고 있는데, 딥러닝 기반 베어링 고장 진단 기법의 단점은 기존의 신호 분석 기법과 비교하여 상당히 복잡한 계산을 요구한다는 것이다. 본 논문에서는 베어링에서 획득한 음향 방출 신호를 활용하는 딥러닝을 통해 정확하게 고장을 진단하는 기존 기법의 계산 복잡도를 크게 감소시킬 수 있는 새로운 진단 기법을 제안한다. 실제 산업 현장에서 사용되는 회전 기계 설비는 고성능 GPU와 같은 높은 계산 처리량을 제공하는 장비를 활용하는데 제약이 있기 때문에 제한된 성능의 임베디드 보드에서도 빠르게 동작할 수 있는 고장 진단 기법이 요구되기 때문이다. 고장 진단을 위한 기존의 CNN 모델에서 레이어를 분리하여 베어링의 정상/비정상 상태만을 구분하는 초기 고장 진단 단계와 비정상 상태로 구분되는 경우에 한해 어떤 유형의 베어링 결함이 발생한 것인지를 판별하는 고장 원인 분류 단계로 구성함으로써 전체적인 고장 진단 정확도에는 거의 영향을 미치지 않는 수준에서 계산 복잡도를 약 55% 감소시킬 수 있다.

[Abstract]

Recently, deep learning methods have been adopted in bearing faults diagnosis to improve the accuracy; however, deep learning methods require much more computation complexity compared to previous signal processing methods. This paper proposes a method to reduce the computation complexity of the deep learning-based bearing faults diagnosis. The acoustic emission signals obtained from the working bearings are converted into spectrogram images, and CNN models are then applied to monitor the bearings' status. The mechanical facilities adopted in real industrial sites have difficulty using expensive processing devices, such as high-performance GPUs. Therefore, a bearing fault diagnosis method for embedded systems is necessary. The proposed method consists of two phases: an initial fault diagnosis phase that classifies normal/abnormal states and a fault-type classification phase determining the defect type for abnormal states. Our experiments using a Raspberry Pi board reveal that the proposed method decreases the time for bearing faults diagnosis by approximately 55% without compromising diagnostic accuracy.

색인어 : 베어링, CNN, 계산 복잡도, 딥러닝, 고장 진단**Keyword** : Bearing, CNN, Computation Complexity, Deep Learning, Fault Diagnosis<http://dx.doi.org/10.9728/dcs.2023.24.6.1373>

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.

Received 15 May 2023; Revised 26 May 2023

Accepted 30 May 2023

***Corresponding Author; Cheol Hong Kim**

Tel: +82-2-820-0674

E-mail: cheolhong@ssu.ac.kr

1. 서론

최근 들어 생산 현장에서 사용되는 기계 설비의 성능이 비약적으로 향상되었지만 동시에 기계 설비의 구조적 복잡도 또한 증가하였다. 산업 현장에서 사용되는 기계 설비들 중에서 고회전 대형 전기 모터와 같은 회전 기계는 생산 공정에서 큰 역할을 담당한다. 생산 현장에서 회전 기계에 고장이 발생하게 된다면 해당 고장을 수리하는데 발생하는 비용 뿐 아니라 수리를 진행하면서 생산 공정이 정지됨에 따라 부가적인 손실까지 발생하게 되므로 이를 방지하기 위해서는 작동하는 회전 기계의 상태를 실시간으로 감시하여 고장이 발생하는 초기에 해당 고장을 진단하는 기술이 꼭 필요하다. 회전 기계를 구성하는 부품 중 하나인 베어링은 회전 기계의 고장 원인 중 가장 큰 비중을 차지하므로, 베어링의 고장을 조기에 진단할 수 있다면 회전 기계의 고장으로 인해 발생하는 손실을 상당히 줄일 수 있을 것으로 기대된다[1].

베어링에서 발생하는 진동 및 소음과 같은 동작 정보를 이용하여 고장을 진단하는 다양한 기법들이 개발되어 왔다[1], [2]. 기존의 베어링 고장 진단 기법들은 주로 진동 데이터를 사용하여 신호 처리 기법을 통해 고장을 진단하였다. 하지만 진동 데이터를 활용하는 진단 방법은 회전 기계의 회전 속도가 일정하거나 큰 변화가 없을 경우에만 높은 정확도를 보여주는 한계점을 가지고 있다. 가변적인 회전 속도를 가지거나 매우 저속으로 동작하는 환경의 경우에는 진동 신호와 비교하여 음향 방출 신호(Acoustic Emission Signals)를 활용하는 것이 더욱 효과적일 수 있다[3]. 음향 방출 신호는 물체에서 발생한 에너지가 탄성파의 형태로 전달되는 것으로 회전 기계에서 수집되는 음향 방출 신호에는 노이즈가 많이 존재하기 때문에 별도의 전처리 과정을 통해 노이즈를 제거해 줄 필요가 있다. 이를 위해 기존 연구에서는 회전 기계의 베어링에서 수집한 음향 방출 신호를 시간의 변화에 따라 주파수의 변화를 표현하는 스펙트로그램(Spectrogram) 이미지로 변환하였다[3]. 이러한 변환을 통해 노이즈를 제거함과 동시에 베어링 고장 진단에 용이하도록 특징을 추출하여 딥러닝을 적용하는 고장 진단 기법의 데이터로 사용하였다. 딥러닝 기법이 발전하면서 단순히 글자나 이미지 안의 물체를 판별하는 것을 넘어 효과적인 영상 데이터 분류를 가능하게 함으로써 다양한 산업 진단 분야에서 활용이 되고 있기 때문이다 [4], [5]. 기존 연구에서는, 스펙트로그램 이미지로 변환된 음향 방출 신호를 이미지 분류에 효과적인 CNN(Convolutional Neural Network)을 적용한 고장 진단 기법에 적용함으로써, 기존의 신호 처리에 기반한 고장 진단 기법에 비해 상당히 높은 진단 정확도를 제공할 수 있었다[3]. 또한, CNN 기반 딥러닝을 활용하는 베어링 고장 진단 기법의 실시간 진단 가능성을 판단하기 위해, 음향 방출 신호를 낮은 MAC(Multiply Accumulate) 복잡도를 가지는 CNN 모델에 적용하여 제한된 성능을 가지는 임베디드 보드에 학습된 상

태로 이식하여 고장을 진단하는데 소요되는 시간을 측정 한 후, 획득한 결과를 토대로 기존 기법으로는 실시간 고장 진단이 불가능하다고 판단하였다[6]. 본 논문에서는, 기존 연구에서 사용된 베어링 고장 진단 기법의 계산 복잡도를 감소시키기 위해, 사용되는 CNN 모델의 단계를 분리하여 입력 데이터의 정상/비정상 상태만을 구분하는 초기 고장 진단 단계와 초기 단계에서 고장으로 분류되는 데이터에 대해서만 어떤 종류의 베어링 결함인지를 판별하는 고장 원인 분류 단계의 2 단계로 구성함으로써, 고장 진단 정확도를 해치지 않는 정도에서 필터 수를 줄여 직접적인 연산량을 감소시키는 모델 경량화 기법을 제안하고자 한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구의 배경 및 관련 연구에 대해 기술하고, 3장에서는 제안하는 진단 계산 복잡도 감소 기법에 대해 설명한다. 4장에서는 고장 진단 정확도 및 복잡도 비교를 위한 실험 방법에 대해서 기술하고 실험 결과를 상세하게 논의한 후, 마지막으로 5장에서 결론을 기술한다.

II. 베어링 고장 진단 기법

2-1 베어링 특성

산업 현장의 회전기계에서 다방면으로 사용되는 볼 베어링의 고장을 유발하는 균열은 베어링을 구성하는 요소인 내륜(inner), 외륜(outer), 롤러(roller)에서 발생한다. 베어링에서 발생한 결함 유무를 판단하기 위한 고장 진단 기법은 베어링의 각 구성 요소에서 발생하는 결함 특성 주파수를 관찰함으로써 고장을 진단하게 된다. 결함 특성 주파수는 기계가 작동하면서 균열이 생긴 부분과 다른 부품이 접촉할 때 발생하게 되며 축의 회전 속도와 베어링의 구성 요소별 물리적 특성에 따라 다음의 식과 같이 표현할 수 있다[7].

Ball-Pass Frequency inner race (BPFI) :

$$BPFI = \frac{nf_r}{2} \left(1 + \frac{d}{D} \cos\phi \right) \tag{1}$$

Ball-Pass Frequency outer race (BPFO) :

$$BPFO = \frac{nf_r}{2} \left(1 - \frac{d}{D} \cos\phi \right) \tag{2}$$

Roller Spin Frequency (RSF) :

$$RSF = \frac{D}{2d} \left(1 - \left(\frac{d}{D} \cos\phi \right)^2 \right) \tag{3}$$

Fundamental Train(cage) Frequency (FTF) :

$$FTF = \frac{f_r}{2} \left(1 - \frac{d}{D} \cos \phi \right) \quad (4)$$

위 식에서 f_r 은 축의 회전 속도, n 은 베어링의 볼 개수, D 는 베어링 볼 사이의 직경, ϕ 는 하중의 각도를 각각 의미한다.

2-2 베어링 고장 진단 기법 관련 연구

1) 신호 처리 기반 고장 진단 기법

신호 처리에 기반한 베어링 고장 진단 기법은 베어링의 구성 요소에서 발생한 결함 특성 주파수의 단일 주파수 영역 스펙트럼 관찰 외에도 단일 시간 영역에서 고장의 특성을 나타내는 실효 값, 분산, 고저 차 등의 값을 이용하였다[8]. 이러한 방법은 회전 기계의 회전 속도가 일정하거나 큰 변화가 없을 경우에만 효과적이기 때문에 회전 속도가 가변적이거나 매우 저속인 환경에서는 적합하지 않았다. 이런 환경에서 결함 특성 주파수를 통해 베어링의 고장을 진단하기 위해서는 회전 주파수의 배수 함수로 나타나는 Order Tracking과 시간-주파수 영역 분석 방법이 주로 사용되었다. Order Tracking은 시간 세그먼트가 고정된 상태에서 수집한 비정상 상태의 데이터를 재샘플링하여 고정 각도 세그먼트의 신호로 변환하는 방식이다[9]. 이 방식은 결함 특성 주파수의 단일 영역 데이터를 통해 고장을 진단할 수 있지만 가변적인 속도에 대해서는 추가적인 설비와 작업을 필요로 하며 보간법을 적용하게 되면 정확도가 크게 떨어지는 단점이 있다. 시간-주파수 영역 분석 방식은 Order Tracking 방식의 단점을 해소하기 위해 사용하는 방식으로, 대표적인 예로 단시간 푸리에 변환(STFT; Short-Time Fourier Transform)[10], WT(Wavelet Transform)[11] 기법 등을 들 수 있다.

2) 딥러닝 기반 고장 진단 기법

딥러닝 기술이 발전하면서 여러 가지 형태의 데이터에서 복잡하게 존재하는 특징을 판별하고 추출하는 기술의 활용 분야가 크게 확장되었다. 이에 따라 산업 현장에서도 사용되는 장비들의 고장을 진단하는 딥러닝 기법들이 연구되었다. 이러한 연구에는 다양한 머신 러닝 기법들이 적용되었는데 새로 입력된 데이터를 분류하기 위해 기존의 데이터 중 가장 가까운 k 개의 데이터를 하나로 묶어 그룹으로 만들고 그룹 내 많은 비율을 차지하는 데이터가 속한 분류로 새로운 데이터를 편입시키는 k -NN(k -Nearest Neighbor) 알고리즘[12], 이진 트리 형태로 이루어졌으며 분기를 통해 데이터를 두 가지로 분류하는 과정을 반복하는 의사결정 트리[13], 의사결정 트리의 정확도를 개선하기 위해 다수의 트리를 생성하고 각각의 트리에서 예상되는 값을 조합하는 랜덤 포레스트 기법[14], 데이터를 구분 짓는 최적의 초평면을 구하고 이를 이

용해 특성을 판단하는 SVM(Support Vector Machine)[15] 등이 있다. 또한, CNN 모델은 이미지 데이터를 활용하여 특성을 판별하는데 매우 뛰어난 성능을 제공하기에 다양한 이미지를 활용하여 건물을 구분하는 기법과 같은 다양한 진단 분야에도 연구가 진행되어왔다[16]. 그러나 CNN 모델을 적용하는 기계 상태 진단 시스템은 많은 연산과 그에 따른 컴퓨팅 자원을 필요로 하기 때문에, 실제 산업 현장에서 사용되는 기계 설비에 이를 적용하기 위해서는 추가적인 계산 복잡도 감소 기법이 필수적으로 요구된다.

본 논문에서 활용한 베어링 고장 진단 기법은 크게 데이터 전처리, 데이터 학습 및 최적화, 베어링 고장 진단의 세 단계로 구분하며 전반적인 프로세스는 그림 1에 보이는 바와 같다. 데이터 전처리 단계에서는 회전 기계에 부착된 음향 방출 센서를 통해 수집한 음향 방출 신호를 단시간 푸리에 변환을 사용하여 시간-주파수 영역의 스펙트로그램 이미지로 변환시킨다. 데이터 학습 및 최적화 단계에서는 데이터 전처리 단계에서 획득한 스펙트로그램 이미지를 이용하여 CNN 모델을 학습시키고, 최적화 기법으로는 확률적 경사 하강법을 사용한다. 이외의 파라미터는 Learning Rate는 0.002, 모멘텀은 0.9, Weight Decay는 0.0005으로 설정한다.

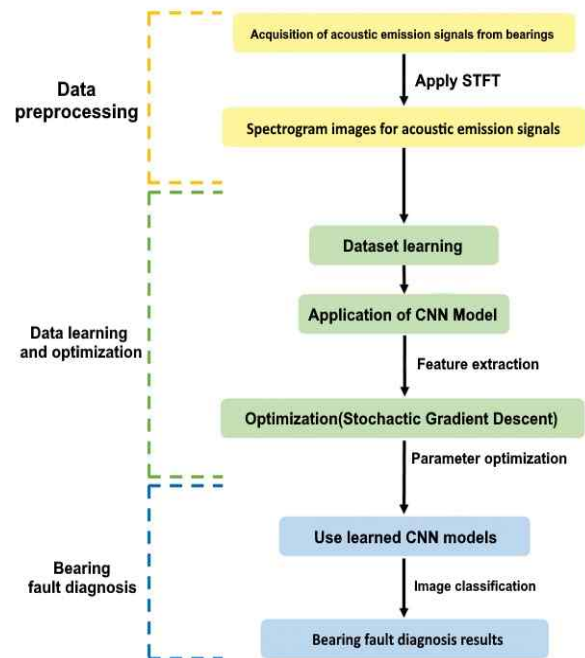


그림 1. 기존 베어링 고장 진단 프로세스
Fig. 1. Existing bearing fault diagnosis process

학습을 위한 CNN 모델은 비슷한 시기에 개발되었으며 높은 정확도를 제공하는 MobileNetV2, ShuffleNetV2, SqueezeNet1.1, ResNet34, VGG16을 사용하였다. 이러한 환경에서 CNN 모델별로 고장 진단을 진행한 후, 진단 정확도와 MAC 복잡도를 분석하였다[6]. 이후 분석한 결과를 토

대로 가장 낮은 복잡도를 보이는 모델을 선정하여 (ShuffleNetV2) 실제 산업 현장의 기계 설비에 부착 가능한 임베디드 보드의 예로 가정한 라즈베리 파이에 학습된 상태로 모델을 이식하여 실시간 고장 진단이 가능할 정도의 진단 속도를 제공할 수 있는지 확인하였다.

III. 베어링 고장 진단 계산 복잡도 감소 기법

본 논문에서는 회전 기계의 베어링에서 수집한 음향 방출 신호를 스펙트로그램 이미지로 변환한 뒤 CNN 모델을 적용한 고장 진단 기법을 제한된 성능의 임베디드 보드에서 실시간 고장 진단이 가능할 정도의 실행시간을 갖도록 경량화하는 방법을 제안한다. 그 방안으로 고장 진단 기법의 구조를 바꾼 구조적 경량화 기법과 정확도를 거의 저하시키지 않는 정도에서 사용하는 CNN 모델의 필터 수를 줄여 직접적인 연산량을 감소시키는 경량화 기법을 적용한다.

제안하는 구조적 경량화 기법은 그림 2에서 보이는 바와 같다. CNN 모델에서 한 개의 레이어를 분리하여 베어링의 정상 상태 여부만을 구분하는 역할을 담당하는 초기 고장 진단 단계를 구성하고, 이후 나머지 레이어를 포함하여 비정상 데이터로 분류된 경우에 대해 어디에서 발생한 결함으로 인한 베어링 고장인지 판별하는 고장 원인 분류 단계를 구성한다. 제안하는 기법에서, 초기 고장 진단 단계에서 사용되는 하나의 레이어는 매우 낮은 복잡도를 가지기 때문에 빠르게 정상/비정상 데이터를 구분할 수 있다는 장점을 제공할 수 있다. 이후 잔여 레이어를 포함한 CNN 모델의 전체 레이어를 사용하여 고장 원인을 분류하는데 이때 이전 단계에서 사용한 하나의 레이어는 이미 학습이 되었기 때문에 해당 레이어는 빠르게 지나가고 잔여 레이어의 학습이 이루어지게 된다. 이러한 방식을 적용하면 베어링 고장 진단에 요구되는 전체적인 연산량을 감소시킬 수 있다. 예를 들어, 일반적인 방식이 100개의 연산이 이루어지며 이를 10회 학습을 진행한다고 가정하면 총 연산 수는 1,000회가 되지만, 초기 고장 진단 단계에서 10개의 연산이 이루어지고, 고장 원인 분류 단계에서 90개의 연산이 수행된다고 가정하면 제안하는 기법에서는 총 연산 수가 910회(10 + 90*10) 되는 것이다.

제안하는 기법에서는 베어링 고장 진단 정확도를 거의 저하시키지 않는 정도에서 사용되는 CNN 모델의 필터 수를 줄여 연산량을 직접적으로 감소시키는 경량화 기법도 함께 적용한다[17],[18].

CNN 모델의 필터 수를 줄이는 만큼 연산량이 직접적으로 감소하게 되지만 이로 인하여 특징 맵 또한 줄어들기에 결과적으로 진단 정확도까지 점차 감소하게 된다. 하지만 CNN 모델에 따라 진단 정확도가 급격히 감소하는 지점이 다르게 존재하기 때문에, 여러 지점에 대해 테스트를 수행함으로써 기존 고장 진단 기법의 진단 정확도와 크게 차이 나지 않으면

서 연산량이 최소가 되는 지점을 찾아낼 수 있다. 이러한 방식의 필터 축소를 통해 네트워크 전체의 용량을 축소하는 방법은 이미 개발되어 레이어 구조가 규격화된 CNN 모델에 대해 세부적인 개선을 하는 것으로 준 구조적 경량화로도 볼 수 있다[18].

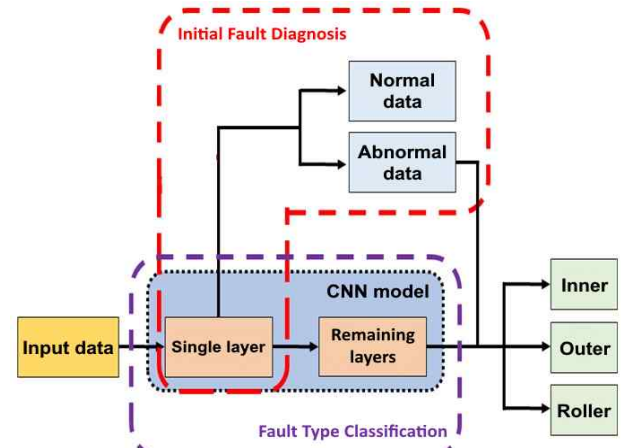


그림 2. 제안하는 베어링 고장 진단 프로세스
Fig. 2. Proposed bearing fault diagnosis process

IV. 실험 방법 및 결과

4-1 음향 방출 신호 수집 및 전처리

베어링을 구성하는 요소에서 균열이 발생하면 기계가 작동하면서 탄성파의 일종인 음향 방출 신호를 발생시키는데 이는 작동 초기에 발생하였거나 매우 작은 크기의 균열이 발생하여도 감지해낼 수 있다. 이러한 특징을 이용하여 그림 3에서 보이는 바와 같이 베어링의 내륜, 외륜, 롤러에 각각 3, 6, 12 mm의 균열을 생성한 뒤 250, 300, 350, 400, 450, 500 RPM(Revolutions Per Minute)의 속도로 각각 작동시켜 발생하는 음향 방출 신호를 수집하였다. 음향 방출 신호를 수집하는데 사용한 음향 방출 센서와 PCI(Peripheral Component Interconnect) 보드의 성능은 표 1과 같다.



그림 3. 베어링에 발생하는 균열 종류
Fig. 3. Types of cracks occurring in bearings

표 1. 음향 방출 신호 수집을 위한 실험 환경
Table 1. Experiment environments for acoustic emission signal collection

	Performance
Sound emission sensor	Resonant frequency : 650 kHz Operating frequency range : 100~900 kHz Peak sensitivity : -63 dB Directionality : ±1.5 dB
2-channel PCI board	Dynamic range : > 85 dB 18-bit 40 MHz A/D conversion Sensor testing : AST build




그림 4. 수집된 음향 방출 신호의 스펙트로그램 이미지 예시
Fig. 4. Example of a spectrogram image for acoustic emission signals

수집된 음향 방출 신호를 Matlab을 통해 단시간 푸리에 변환을 적용하여 시간-주파수 영역의 스펙트로그램 이미지로 변환하는데, Train Dataset으로는 250, 350, 450 RPM의 동작속도 데이터에 대해 결함 크기(3 mm, 6 mm, 12 mm)와 결함 위치(내륜, 외륜, 롤러) 각각의 클래스마다 96장씩, Validation 및 Test Dataset으로는 300, 400, 500 RPM의 동작속도 데이터에 대해 각 클래스마다 20장씩 변환하였다. 그림 4는 변환된 스펙트로그램 이미지의 예를 보인다.

4-2 베어링 고장 진단 결과 분석

변환된 스펙트로그램 이미지들을 활용하여 CNN 모델 학습을 실시한 후, 결함 크기 및 결함 위치별 다양한 경우에 대한 진단을 실시하여 사용된 CNN 모델별로 진단 정확도 및 MAC 복잡도를 구하였다. 이때 사용된 진단 정확도의 지표는 Sensitivity로 아래의 식으로 계산된다. 이는 고장 진단 기법이 고장으로 판단한 데이터 중에 실제 고장이 발생한 데이터의 비율이 어느 정도 인지를 표현한다.

$$Sensitivity = \frac{N_{TruePositive}}{N_{TruePositive} + N_{FalseNegative}} * 100(\%) \quad (5)$$

각 CNN 모델별로 진단 정확도를 비교하는 그래프인 그림 5에서 보이는 바와 같이, 딥러닝을 활용하는 베어링 고장 진단 기법들은 95% 이상의 높은 진단 정확도를 제공함을 알 수 있다. 고장 진단 계산 복잡도를 비교하기 위해 사용한 MAC 복잡도는 CNN 모델을 구성하는 레이어 중에서 합성곱층에서 사용되는 연산인 단일 곱셈-누산(Fused Multiply-Add) 연산이 총 몇 번 수행되었는지를 측정한다. 즉 베어링 고장 진단 기법을 위해 수행된 연산 횟수를 계산하는 것으로, 계산 결과는 표 2에 보이는 바와 같다.

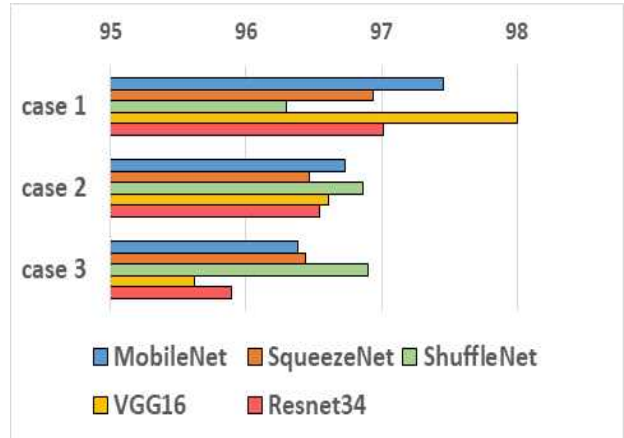


그림 5. CNN 모델별 고장 진단 정확도
Fig. 5. Fault diagnosis accuracy for applied CNN models

표 2. CNN 모델별 고장 진단 MAC 복잡도
Table 2. Fault diagnosis MAC complexity for CNN models

	Computation complexity (FLOPs)
VGG	15,493,134,850
ShuffleNet	42,675,170
ResNet	3,675,629,032
SqueezeNet	355,862,008
MobileNet	320,237,288

4-3 고장 진단 계산 복잡도 감소 기법 결과 분석

고장 진단에 사용된 다섯 가지 CNN 모델 모두 95% 이상의 높은 진단 정확도를 보여주지만, MAC 복잡도에서는 ShuffleNet이 크게 낮은 수치를 보인다는 것을 알 수 있다. 본 논문에서는, MAC 복잡도가 가장 낮은 ShuffleNet 모델을 학습시킨 후, 임베디드 보드에 이식하여 고장 진단에 소요되는 시간을 측정하였다. 임베디드 보드에서의 고장 진단 시간 측정을 위해서는, 1.2GHz 쿼드코어 CPU, 1GB RAM이 장착

된 라즈베리파이 보드에 학습된 상태의 경로 파일을 옮긴 후에 실제로 고장을 진단하는데 소요되는 시간을 30회 측정 후 평균값을 계산하였다. 실험 결과에 따르면, 고장 진단에 요구되는 시간은 24,270 ms로 실시간 고장 진단을 하기에는 다소 오랜 시간이 소요됨을 확인하였다.

본 논문에서는 제안하는 고장 진단 계산 복잡도 감소 기법을 ShuffleNet에 적용한 실험 결과는 그림 6에 보이는 바와 같다. 한 개의 레이어만을 이용하여 초기 고장 진단 단계를 구성하고 잔여 레이어를 사용하여 비정상 상태의 고장 원인을 분류하는 고장 원인 분류단계를 구성함과 동시에, ShuffleNet의 필터 수를 줄여 연산량을 직접적으로 감소시킨 결과이다. 그림 6에서 보이는 바와 같이 제안하는 계산 복잡도 감소 기법을 적용한 고장 진단 기법의 진단 정확도는 그림 5에 보이는 기존 기법의 진단 정확도와 비교하여 거의 차이를 보이지 않음을 확인할 수 있다.

제안하는 기법의 단계별(초기 고장 진단 단계, 고장 원인 분류 단계) 요구되는 MAC 복잡도는 표 4에 보이는 바와 같다. 고장 진단을 위해 요구되는 MAC 복잡도는 초기 고장 진단 단계에서 10,887,938 FLOPs(Floating point Operations Per Second), 고장 원인 분류 단계에서 19,296,563 FLOPs로 총 30,184,501 FLOPs의 복잡도를 보여준다. 이는 표 2에 보이는 기존 기법이 적용된 ShuffleNet 모델과 (42,675,170 FLOPs) 비교하여 복잡도가 약 30% 감소되었음을 알 수 있다. 또한, 제안 기법이 적용된 고장 진단 기법을 라즈베리파이 보드에 이식하여 수행한 결과 소요되는 시간은 11,147 ms로 기존 기법의 소요시간 (24,270 ms) 대비 약 55% 감소됨을 확인할 수 있다.

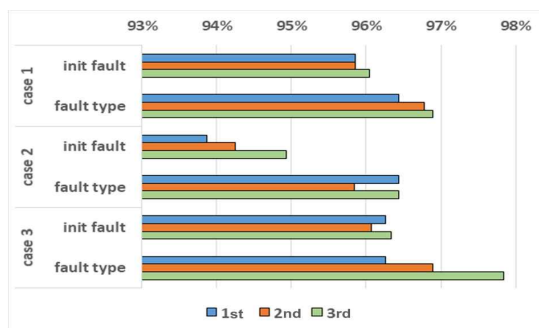


그림 6. 제안 기법을 적용한 고장 진단 정확도
 Fig. 6. Fault diagnosis accuracy for the proposed method

표 3. 제안 기법의 단계별 MAC 복잡도
 Table 3. Fault Diagnosis MAC Complexity for the proposed method

	Computation complexity (FLOPs)
Initial fault diagnosis phase	10,887,938
Fault type classification phase	19,296,563

V. 결 론

본 논문에서는 실제 산업 현장에서 빈번하게 사용되는 전기 모터의 주요 부품인 베어링 상태 진단을 위한 딥러닝 기반 베어링 고장 진단 기법의 계산 복잡도를 감소시키기 위한 기법을 새롭게 제안하였다. 베어링 고장 진단을 위해 적용되는 CNN 모델에서 한 개의 레이어를 별도로 분리하여 베어링의 정상/비정상 상태만을 구분하는 초기 고장 진단 단계를 구성하고, 비정상 상태로 판단된 데이터에 대해서는 잔여 레이어를 사용하여 어떤 종류의 베어링 결함이 발생한 것인지를 판별하는 고장 원인 분류 단계를 구성하는 구조적 경량화 기법을 적용하였다. 또한, 고장 진단 정확도를 거의 저하시키지 않는 수준에서 CNN 모델의 필터 수를 줄여 직접적인 연산량을 감소시키는 기법을 함께 적용하였다. 제안 기법을 적용한 결과, 기존의 베어링 고장 진단 기법과 비교하여 MAC 복잡도는 약 30% 감소시키고, 라즈베리파이에서 수행되는 고장 진단 시간은 약 55% 감소시키는 결과를 얻을 수 있었다.

감사의 글

본 연구는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2021R1A2C1009031)

참고문헌

- [1] S. Muhammad and J.-M. Kim, "Fault Diagnosis of Rotary Machine Bearings Under Inconsistent Working Conditions," *IEEE Transactions on Instrumentation and Measurement*, Vol. 69, No. 6, pp. 3334-3347, June 2020. <https://doi.org/10.1109/TIM.2019.2933342>
- [2] M. Kang, M. R. Islam, J. Kim, J.-M. Kim, and M. Pecht, "A Hybrid Feature Selection Scheme for Reducing Diagnostic Performance Deterioration Caused by Outlines in Data-driven Diagnostics," *IEEE Transactions on Industrial Electronics*, Vol. 63, No. 5, pp. 3299-3310, May 2016. <https://doi.org/10.1109/TIE.2016.2527623>
- [3] M. T. Pham, J.-M. Kim, and C. H. Kim, "Intelligent Fault Diagnosis Method Using Acoustic Emission Signals for Bearings Under Complex Working Conditions," *Applied Sciences*, Vol. 10, No. 20, pp. 1-14, October 2020. <https://doi.org/10.3390/app10207068>
- [4] H.-C. Park and S.-W. Lee, "CNN-Facilitated Color and Character Recognition in Practical Application," *The Journal of Korean Institute of Next Generation Computing*, Vol. 12, No. 6, pp. 104-115, December 2016.

- [5] N. Khan, I. U. Haq, F. U. M. Ullah, M. Y. Lee, and S. W. Baik, "Efficient Sport Videos Classification via Convolutional Neural Network," *The Journal of Korean Institute of Next Generation Computing*, Vol. 16, No. 6, pp. 7-16, December 2020.
- [6] J. H. Park and C. H. Kim, "Analysis of Accuracy and Computation Complexity of Bearing Fault Diagnosis Methods Using CNN-Based Deep Learning," *The Journal of Korean Institute of Next Generation Computing*, Vol. 18, No. 1, pp. 7-18, February 2022.
<http://doi.org/10.23019/kingpc.18.1.202202.001>
- [7] R. B. Randall and J. Antoni, "Rolling Element Bearing Diagnostics—A Tutorial," *Mechanical Systems and Signal Processing*, Vol. 25, No. 2, pp. 485-520, February 2011.
<https://doi.org/10.1016/j.ymssp.2010.07.017>
- [8] M. Bhadane and K. I. Ramachandran, "Bearing Fault Identification and Classification with Convolutional Neural Network," in *Proceedings of the 2017 International Conference on Circuit, Power and Computing Technologies*, Kollam, India, pp. 1-5, April 2017.
<https://doi.org/10.1109/ICCPCT.2017.8074401>
- [9] M. Bai, J. Huang, M. Hong, and F. Su, "Fault Diagnosis of Rotating Machinery Using an Intelligent Order Tracking System," *Journal of Sound and Vibration*, Vol. 280, No. 3-5, pp. 699-718, February 2005.
<https://doi.org/10.1016/j.jsv.2003.12.036>
- [10] H. Liu, L. Li, and J. Ma, "Rolling Bearing Fault Diagnosis Based on STFT-Deep Learning and Sound Signals," *Shock and Vibration*, Vol. 2016, pp. 1-12, September 2016.
<https://doi.org/10.1155/2016/6127479>
- [11] Q. Sun and Y. Tang, "Singularity Analysis Using Continuous Wavelet Transform for Bearing Fault Diagnosis," *Mechanical Systems and Signal Processing*, Vol. 16, No. 6, pp. 1025-1041, November 2002.
<https://doi.org/10.1006/mssp.2002.1474>
- [12] E. Choi and N. Park, "Application and Development of Machine Learning Training Program Based on Understanding K-NN Algorithm," *Journal of The Korean Association of Information Education*, Vol. 25, No. 1, pp. 175-184, February 2021.
<http://dx.doi.org/10.14352/jkaie.2021.25.1.175>
- [13] Y.-B. Jo, W.-S. Na, S.-J. Eom, and Y.-J. Jeong, "Traffic Sign Recognition Using SVM and Decision Tree for Poor Driving Environment," *Journal of IKEEE*, Vol. 18, No. 4, pp. 485-494, December 2014.
<http://dx.doi.org/10.7471/ikeee.2014.18.4.485>
- [14] J. H. Lee and J. G. Baek, "RTC(Real-Time Contrast) Control Chart Using Random Forest Based Multi-Class Classifier," *Journal of the Korean Institute of Industrial Engineers*, Vol. 44, No. 4 pp. 306-315, August 2018.
<https://doi.org/10.7232/JKIEE.2018.44.4.306>
- [15] L.-L. Jiang, H.-K. Yin, X.-J. Li, and S.-W. Tang, "Fault Diagnosis of Rotating Machinery Based on Multisensor Information Fusion Using SVM and Time-Domain Features," *Shock and Vibration*, Vol. 2014, 418178, April 2014.
<https://doi.org/10.1155/2014/418178>
- [16] H.-C. Lee, I.-H. Park, T.-H. Im, and D.-T. Moon, "CNN-Based Building Recognition Method Robust to Image Noises," *Journal of the Korea Institute of Information and Communication Engineering*, Vol. 24, No. 3, pp. 341-348, March 2020.
<http://doi.org/10.6109/jkiice.2020.24.3.341>
- [17] H.-W. Lee, "Optimization of the Number of Filter in CNN Noise Attenuator," *The Journal of the Korea Institute of Electronic Communication Sciences*, Vol. 16, No. 4, pp. 625-632, August 2021.
<http://dx.doi.org/10.13067/JKIECS.2021.16.4.625>
- [18] K. Seo, "Evolutionary Computation Based CNN Filter Reduction," *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 67, No. 12, pp. 1665-1670, December 2018.
<http://doi.org/10.5370/KIEE.2018.67.12.1665>



박재현 (Jea Hyun Park)

2018년 : 전북대학교 IT정보공학과 (공학사)
2022년 : 숭실대학교 대학원 컴퓨터학과 (공학석사)

2022년~현재 : 숭실대학교 컴퓨터학과 박사과정
※ 관심분야 : 딥러닝, 임베디드시스템



김철홍 (Cheol Hong Kim)

1998년 : 서울대학교 컴퓨터공학과 (공학사)
2000년 : 서울대학교 대학원 컴퓨터공학부 (공학석사)
2006년 : 서울대학교 대학원 전기컴퓨터공학부 (공학박사-컴퓨터시스템)

2005년~2007년: 삼성전자 책임연구원
2007년~2020년: 전남대학교 컴퓨터정보통신공학과 교수
2020년~현재 : 숭실대학교 컴퓨터학부 교수
※ 관심분야 : 컴퓨터시스템, 임베디드시스템, 고장진단시스템