

http://dx.doi.org/10.17703/JCCT.2023.9.3.845

JCCT 2023-5-100

전이학습을 이용한 볼베어링의 진동진단

Transfer Learning-Based Vibration Fault Diagnosis for Ball Bearing

홍수빈*, 이영대**, 문찬우***

Subin Hong*, Youngdae Lee**, Chanwoo Moon***

요약 본 논문에서는 전이학습을 이용하여 볼베어링의 진동진단을 수행하는 방법을 제안한다. 고장을 진단하기 위해 진동신호를 시간-주파수로 분석할 수 있는 STFT를 CNN의 입력으로 이용하였다. CNN 기반의 딥러닝 인공신경망을 빠르게 학습하고 진단 성능을 높이기 위해 전이학습 기반의 딥러닝 학습 기법을 제안하였다. 전이학습은 VGG 기반의 영상 분류 모델을 이용하여 특징 추출기와 분류기를 선택적으로 학습하였고, 학습에 사용한 데이터 세트는 Case Western Reserve University 대학에서 제공하는 공개된 볼베어링 진동 데이터를 사용하였으며, 성능평가는 기존의 CNN 모델과 비교하는 방법으로 수행하였다. 실험 결과 전이학습이 볼베어링 진동 데이터에서 상태 진단에 유용하다는 것을 증명할 수 있을 뿐만 아니라 이를 통해 다른 산업에서도 전이학습을 사용하여 상태 진단을 개선할 수 있다.

주요어 : 베어링 고장 진단, 단시간 푸리에 변환, 합성곱 신경망, 전이학습, 딥러닝

Abstract In this paper, we propose a method for diagnosing ball bearing vibration using transfer learning. STFT, which can analyze vibration signals in time-frequency, was used as input to CNN to diagnose failures. In order to rapidly learn CNN-based deep artificial neural networks and improve diagnostic performance, we proposed a transfer learning-based deep learning learning technique. For transfer learning, the feature extractor and classifier were selectively learned using a VGG-based image classification model, the data set for learning was publicly available ball bearing vibration data provided by Case Western Reserve University, and performance was evaluated by comparing the proposed method with the existing CNN model. Experimental results not only prove that transfer learning is useful for condition diagnosis in ball bearing vibration data, but also allow other industries to use transfer learning to improve condition diagnosis.

Key words : Bearing failure diagnosis, short-time Fourier transform, Convolutional neural network, Transfer learning, Deep learning

1. 서론

볼베어링은 회전 장비에서 매우 중요한 역할을 수행

하며, 오랜 시간 동안 사용되다 보면 마모와 손상 등으로 인해 고장이 발생할 수 있다. 따라서 정기적인 검사와 유지보수가 필요하다. 이러한 검사 중 하나는 진동 진단 기술이다.

*정회원, (주)나인벨

**중신회원, (주)나인벨

***정회원, 국민대학교 전자공학부 교수(교신저자)

접수일: 2023년 4월 15일, 수정완료일: 2023년 5월 1일

게재확정일: 2023년 5월 10일

Received: April 15, 2023 / Revised: May 1, 2023

Accepted: May 5, 2023

***Corresponding Author: mcwnt@kookmin.ac.kr

School of Electrical Engineering, Kookmin Univ., Korea

진동진단 기술은 기계의 진동 신호를 측정하여 기계 내부의 결함을 감지하고 진단하는 기술이다. 이는 고장이 예방될 수 있도록 하며 비용과 시간을 절약할 수 있다. 하지만 볼베어링의 진동진단은 기존의 진동 신호 분석 방법으로는 정확한 진단이 어려운 경우가 많다. 이러한 문제를 해결하기 위해 전이학습(Transfer Learning) 기술을 이용한 볼베어링 진동진단 연구가 진행되고 있다.

전이학습은 기존에 학습된 모델의 지식을 새로운 문제 해결에 적용하는 기술로 적은 데이터로도 높은 성능을 보인다. 따라서 볼베어링 진동 신호 데이터를 학습시킨 전이학습 모델을 구축하여 정확한 진단을 가능하게 할 것이다[1].

본 연구에서는 전이학습 기술을 이용하여 볼베어링의 진동진단을 수행하는 모델을 제안한다. 제안된 모델은 적은 데이터로도 높은 성능을 보이며 볼베어링의 결함을 정확하게 감지할 수 있다. 따라서 본 연구는 볼베어링의 안정적인 검사와 예방적인 유지보수를 위한 중요한 역할을 수행할 것이다.

II. 관련 연구

1. STFT(Short-Time Fourier Transform)

STFT는 시간 축에서 신호를 분석하는 데 사용되는 주파수 분석 방법의 하나다. STFT는 원 시계열 데이터를 작은 시간 윈도우로 분할하여 각 윈도우에서의 주파수 스펙트럼을 분석하는 방법이다. STFT는 주로 신호 처리 분야에서 많이 사용되며, 볼베어링 진동진단 분야에서도 널리 사용된다. 이는 STFT가 시간 영역과 주파수 영역에서 모두 정보를 제공하므로, 기계의 진동 신호를 분석할 때 유용하기 때문이다.

기존에는 STFT를 이용하면 볼베어링 진동 신호를 분석하였으나, 데이터 양이 적을 때는 STFT의 성능이 저하되는 문제가 있었다. 이를 해결하기 위해 전이학습을 이용하여 STFT의 성능을 개선하는 연구도 진행되고 있다. 따라서 STFT는 볼베어링 진동진단 분야에서 널리 사용되며, 전이학습을 이용하여 성능을 개선하는 연구도 많이 진행되고 있다. 이는 볼베어링 진동진단에 대한 정확한 분석을 위해 필수적인 기술이다 [2].

2. CNN(Convolutional neural network)

CNN은 딥러닝 알고리즘 중 하나로, 이미지나 음성과 같은 복잡한 패턴을 인식하는 데 매우 효과적이다 [3]. 이러한 특성을 활용하여, CNN을 이용한 볼베어링의 진동진단은 최근에 많은 연구가 이루어지고 있는 분야 중 하나이다 [4, 5]. CNN을 이용한 볼베어링의 진동진단은, 기존의 기계학습 알고리즘과 달리, 진동 데이터를 2차원 이미지 형태로 변환하여 진동 패턴을 학습하는 방식을 취한다. 이를 위해, 볼베어링의 진동 데이터를 푸리에 변환(Fourier Transform) 등의 신호처리 기술을 이용하여, 시간-주파수 영역에서의 진동 패턴을 추출한다. 이후, 이를 2차원 이미지로 변환하여 CNN 모델에 입력한다.

CNN 모델은 입력된 이미지에서 특징을 추출하여, 이를 이용하여 볼베어링의 상태를 판단한다. 이를 위해, CNN 모델은 학습 데이터를 이용하여 볼베어링의 정상 상태와 오작동 상태에 대한 특징을 학습한다. 이후, 새로운 진동 데이터가 입력되면, 이를 2차원 이미지로 변환하여 CNN 모델에 입력한다. 모델은 입력된 이미지에서 특징을 추출하여, 학습된 특징과 비교하여 볼베어링의 상태를 판단한다. CNN을 이용한 볼베어링의 진동진단은, 기존의 기계학습 알고리즘보다 더욱 정확하고 빠른 결과를 제공할 수 있다. 또한 CNN 모델은 학습된 특징을 시각화할 수 있기 때문에, 볼베어링의 오작동 원인 분석에도 활용할 수 있다. 따라서, 산업 현장에서의 실시간 볼베어링 진동진단에 매우 유용하게 활용될 수 있다.

3. 전이학습(Transfer Learning)

전이학습은 기존에 학습된 모델을 새로운 문제에 적용하는 기술이다 [6]. 이를 이용하여 볼베어링의 진동진단을 수행할 수 있다. 볼베어링의 진동진단은 회전하는 축과 베어링의 상태를 파악하는 기술이다. 이는 제조업, 에너지 산업 등 다양한 분야에서 중요한 역할을 한다. 전이학습을 이용하여 볼베어링의 진동진단을 수행하기 위해서는, 먼저 이미지나 신호 등의 데이터를 학습할 수 있는 분류기(classifier) 역할을 한다.

이후에는, 이전에 학습된 모델을 새로운 베어링의 진동데이터에 적용하여 진동진단을 수행한다. 이를 위해

서는, 새로운 베어링에서 측정된 진동 데이터를 전처리 (pre-processing)하여 모델이 입력받을 수 있는 형태로 변환한다. 이후에는 변환된 데이터를 모델에 입력하여 베어링의 상태를 분류한다. 전이학습을 이용하여 볼베어링의 진동진단을 수행하면, 새로운 베어링에 대해서도 높은 정확도로 상태를 판단할 수 있다. 또한, 이전에 학습된 모델을 재사용함으로써 데이터를 많이 필요로 하지 않아도 정확한 진동진단을 수행할 수 있다.

III. 제안한 고장 진단 방법

CNN 기반의 알고리즘은 데이터의 특성을 추출하며 학습하는 방식에 매우 효과적인 딥러닝 기법으로 알려져 있다. 신호의 전처리에 대한 Feature Extraction Module을 효과적으로 수행하기 위해, 사전 학습된 모델인 VGG-19 모델을 [7]을 사용하였다. 그림 1은 본 연구에서 제안하는 전체 시스템 구조를 보여준다.

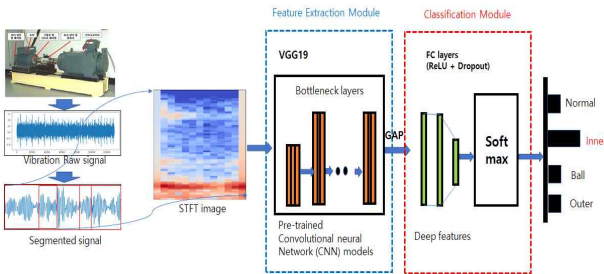


그림 1. 제안된 시스템 아키텍처
 Figure 1. Proposed System Architecture

우선, 획득한 진동 신호의 샘플링 주파수가 48 KHz이며, 진동 신호 데이터를 분할하기 위해서는 윈도우 길이를 784개로 정하고 스트라이드(stride)는 500으로 설정하였다. 윈도우 길이를 스트라이드(stride)만큼 이동하면서 진동 신호 데이터를 분할하였다. 고장 유형별로 분할했을 때 볼 고장은 486개, 내륜 고장과 정상은 487개, 외륜 고장은 488개로 총 1,948개로 데이터 세트가 생성된다.

딥러닝 기반 CNN을 이용해 특성 벡터를 추출하기 위해서는 생성된 데이터 세트가 1차원 신호이기 때문에 2차원 이미지를 구현하기 위해서는 STFT(Short Time Fourier Transform)를 기반으로 하는 스펙트로그램을 사용했다. 이 스펙트로그램은 시간-주파수 분석으로 비선형 신호의 특성을 추출하기 위해 적합하며, 노이즈가 있는 데이터를 분석에 유용한 도구이다.

CNN 입력을 위해서 스펙트로그램의 크기를 224x224로 조정하였다. 그 이후, 입력 스펙트로그램 영상에 대한 심층 특징들을 추출한다. 추출된 심층 특징들은 완전 연결 계층들로 구성된 분류 모듈의 입력 값으로 들어가기 위해 기존 VGG-19와는 다르게 GAP을 이용하여 각 채널당 하나의 특징 값으로 변환한다. 추출된 심층 특징의 형태가 높이 x 너비 x 깊이 일 때 GAP을 통해서 1 x 1 x 깊이 크기로 줄어든다. 이후 완전연결층 1개를 연결하고 마지막 완전연결층은 softmax를 이용해 현재 정상인지 내륜 고장인지 볼 고장인지 외륜 고장인지를 확률로 나타낸다.

IV. 실험 및 결과

1. 데이터 세트

본 논문에서 사용되는 데이터 세트는 Case Western Reserve University(CWRU)에서 제공한 볼베어링 결함 유무에 따른 진동 신호 데이터 세트이다 [8]. CWRU 베어링 데이터 세트를 선택한 이유는 다양한 베어링 고장 연구 분야의 연구원들이 표준으로 쉽게 접근할 수 있는 데이터 세트이기 때문이다 [9]. 이 데이터 세트는 정상, 내륜 고장, 외륜 고장, 볼 고장의 네 가지 클래스로 구성이 되며 총 1,948개로 이루어져 있다. 또한, 전체 데이터 세트 중 60%는 모델을 학습하기 위한 학습 데이터 세트로 사용되었고 20%는 학습된 모델의 성능을 평가하기 위해 검증 데이터 세트로 사용되었다. 마지막 20%는 학습된 모델의 성능을 한 번만 평가하기 위한 테스트 데이터 세트로 사용되었다. 표 1은 CWRU 데이터 세트에 대한 자세한 사항을 보여주며 그림 2는 CWRU 데이터 세트의 클래스별 스펙트로그램 영상 이미지를 보여준다.

표 1. CWRU 데이터 세트
 Table 1. CWRU Dataset

class	Train	Validation	Test	Total
Ball Fault	301	89	96	486
Inner Fault	313	86	88	487
Normal	326	68	113	487
Outer Fault	306	69	390	488
All	1,246	312	390	1,948




그림 2. CWRU 데이터 세트의 영상 예(STFT변환)
Figure 2. Example images from CWRU dataset(STFT transformation)

2. 시스템 환경

시스템 구현 환경으로는 Windows에서 클라우드 서비스인 Google Colaboratory과 Jupyter Notebook을 사용하였으며, 언어는 파이썬을 사용하였다. 라이브러리는 OpenCV와 TensorFlow를 사용하였다.

3. 실험 결과


이미지 분류 문제에서 전이학습이 효과적인 것으로 알려져 있기 때문에, 이를 볼베어링 진동진단 문제에 적용해 볼 수 있다. 기존의 CNN 모델과 전이학습을 이용한 볼베어링 진동진단 문제에 대한 실험을 진행하였다.

기존의 CNN 모델을 이용한 볼베어링 진동진단 문제에 대한 연구에서는, 전처리된 진동 데이터를 입력으로 사용하고 2D-CNN 모델을 사용하여 분류를 수행하였다. 이 모델은 3개의 컨볼루션 레이어와 2개의 풀랫 레이어로 구성하였다. 각각의 컨볼루션 레이어는 컨볼루션, 배치 정규화(Batch normalization), ReLU, 맥스 풀링, 배치 정규화(Batch normalization)로 구성되어 있다. 학습은 RMSprop 옵티마이저를 사용해서 학습시켰으며, 배치 사이즈는 32로 설정하였고, 총 10epoch까지 학습을 진행하였다.


전이학습을 이용한 볼베어링 진동진단 문제에 대한 연구에서는, ImageNet 데이터 세트에서 사전 학습된 VGG-19 모델을 사용하였다. VGG-19 모델은 16개의 컨볼루션 레이어와 3개의 완전 연결 레이어로 구성되어 있다. 이 모델을 그대로 사용하지 않고 특징 추출기의 가중치를 초기값으로만 사용하고 전체를 모두 미세조정(fine tuning)으로 학습하는 방법을 이용하였고, 손실함수는 크

로스 엔트로피(cross entropy), 최적화 기법은 Adam-optimizer를 적용하였다.

실험 결과는 다음과 같다. 그림 3은 각 epoch마다 학습과 검증 데이터에서 측정한 정확도와 손실을 나타낸다. 학습을 완료했을 때 두 방법 모두 학습 정확도와 검증 정확도가 증가하는 것을 알 수 있다. 또한 학습 손실과 검증 손실에 대해서도 감소하는 것을 알 수 있다. 하지만 기존 CNN에서는 훈련 데이터에서 과적합이 생겨서 성능이 떨어지지만 전이학습에서는 검증 데이터가 훈련 데이터보다 크다는 것은 과대적합을 완화시켜주고 성능도 우수함을 알 수 있다.



(a)



(b)

그림 3. 학습 데이터와 검증 데이터의 정확도와 손실 (a) 기존 CNN (b) 전이학습

Figure 3. Accuracy and loss of learning and verification data (a) Existing CNN (b) transfer learning

그림 4, 그림 5는 클래스별 성능 평가를 보여주기 위해 혼동 행렬이 사용된다. 기존 CNN 모델의 정확도는 97.4%이고, 사전 학습된 모델의 정확도는 99.6%로 나왔다. 이는 기존 CNN 모델과 전이학습 모델 모두 베어링 결함 감지에 매우 신뢰할 수 있음을 나타낸다.




그림 4. 기존 CNN의 혼동행렬
 Figure 4. Confusion Matrix for Existing CNN




그림 5. 전이학습의 혼동행렬
 Figure 5. Confusion Matrix for transfer learning

표 2는 기존의 CNN과 전이학습의 분류 정확도를 비교한 것으로 전이학습의 우수성을 확인할 수 있었다. 기존에는 딥러닝 모델인 CNN(Convolutional Neural Network)을 이용한 방법이 많이 사용되었다. 그러나 이 경우 모델을 학습하는 데에 많은 데이터와 시간이 필요했기 때문에 문제가 있었다. 따라서 최근에는 전이학습을 이용한 방법이 제안되어 많은 관심을 받고 있다. 전이학습을 이용하면 기존 모델에서 학습된 특성들을 새로운 문제에 재사용함으로써 학습 시간을 단축하고 정확도를 높일 수 있다.

표 2. 분류 정확도
 Table 2. Classification accuracy

	Accuracy
기존 CNN	0.974
전이학습	0.996

V. 결 론

본 논문에서는 전이학습을 이용하여 볼베어링의 진동진단을 수행하는 방법을 제안하였다. 고장을 진단하기 위해 진동신호를 시간-주파수로 분석할 수 있는 STFT를 CNN의 입력으로 이용하였다. 전이학습은 VGG 기반의 영상 분류 모델을 이용하여 특징 추출기와 분류기를 선택적으로 학습하였고, 실험은 기존의 CNN 모델과 비교하였다. 실험 결과 전이학습을 사용한 모델이 기존의 모델보다 더 높은 진단 정확도를 보여주었다. 따라서 전이학습이 볼베어링 진동데이터에서 상태 진단에 유용하다는 것을 증명할 수 있을 뿐만 아니라 이를 통해 다른 산업에서도 전이학습을 사용하여 상태 진단을 개선할 수 있을 것이다.

References

- [1] J. P. Yun, M. S. Kim, G. K. W. Shin, "Fault Diagnosis and Analysis Based on Transfer Learning and Vibration Signals", *Journal of Korean Embedded Engineering Society*, vol.14, no.6, pp. 287-294 (8 pages), 2019. <https://doi.org/10.14372/IEMEK.2019.14.6.287>
- [2] Naver blog, STFT, <https://m.blog.naver.com/vmv-tech/220936084562>
- [3] Wikipedia, Convolutional Neural Network, https://ko.wikipedia.org/wiki/%ED%95%A9%EC%84%B1%EA%B3%B1_%EC%8B%A0%EA%B2%BD%EB%A7%9D
- [4] Y. J. Kim, H. J. Jeon, Y. K. Kim, "A Comparison Study of Ball Bearing Fault Diagnosis and Classification Analysis Using XAI Grad-CAM", *The Transactions of the Korean Institute of Electrical Engineers*, Vol. 71, No. 9, p.1315-1325, 2022. DOI <https://doi.org/10.5370/KIEE.2022.71.9.1315>
- [5] G. J. Seong, T. M. Lee, J. W. Kim, D. W. Kim, "A Study on CNN-Based Ball Bearings Fault Detection of a Rotating Shaft Using abnormal vibration emphasis Filter Bank", *Proceedings of the conference of the Korean Society for Communications and Communications*, pp. 414 - 415 (2pages), 2023.
- [6] Naver blog, Transfer Learning, <https://blog.naver.com/PostView.naver?blogId=beyondlegend&logNo=222521774448&parentCategoryNo=&categoryNo=93&viewDate=&isShowPopularPosts=true&from=search>
- [7] Karen Simonyan, Andrew Zisserman, "Very Deep

- Convolutional Networks for Large-Scale Image Recognition”, arXiv preprint arXiv:1409.1556, 2015.
- [8] CWRU, “48k Drive End Bearing Fault Data,” Jan 2022, <https://engineering.case.edu/>
- [9] D. T. Hoang, H. J. Kang, “Rolling element bearing fault diagnosis using convolutional neural network and vibration image”, *Cogn. Syst. Res.*, Vol. 53, pp. 42 - 50, 2019. DOI <https://doi.org/10.1016/j.cogsys.2018.03.002>