

포락 신호 주파수 스펙트럼 기반 베어링 결함 자동 진단을 위한 1D-CNN 모델의 하이퍼파라미터 선정 방안에 대한 연구

임순현*, 이재웅*, 조영욱*, 한재민*, 이재욱*, 염기욱**, 손동구***, 김종면****

*울산대학교 전기전자컴퓨터공학과, **울산대학교 전기전자공학부, ***한국전자통신연구원, ****(주)예측진단기술

lsh0981@gmail.com, dlwodnd12345@gmail.com, zxm11hh7@mail.ulsan.ac.kr, dudrn1947@gmail.com, leeju970409@naver.com, duarldnr@gmail.com, sdk@etri.re.kr, jongmyon.kim@gmail.com

A study on hyperparameter selection method of 1D-CNN model for automatic diagnosis of bearing defects based on envelope signal frequency spectrum

Lim Soon-Hyun, Lee Jae-Ung, Jo Yeong-Uk, Han Jae-Min, Lee Jae-Wook, Yeom Gi-Uk, Shon Dong-Koo, Kim Jong-Myon

*Department of Electrical, Electronic and Computer Engineering, University of Ulsan
Department of Electrical and Electronic Engineering, University of Ulsan, *Electronics and Telecommunications Research Institute, ****Prognosis&Diagnostics Technologies

요약

본 논문은 회전기기 주요 결함 원인인 베어링 결함 진단에 있어 많은 연구가 진행되고 있는 1D-CNN 모델을 대상으로 하이퍼파라미터를 베어링 결함 주파수를 고려하여 선정하는 방안에 대해 논한다. 구체적으로, 1D-CNN에 입력되는 데이터는 베어링 구성요소 결함별 진동 신호를 포락 처리한 후 주파수 스펙트럼으로 변환한 값을 사용한다. 이후, 1D-CNN 모델의 하이퍼파라미터인 Stride, Size of convolution kernel를 결함 주파수를 고려하여 학습한 모델과 그렇지 않은 모델의 결과를 비교해보았다. 그 결과, 제안된 하이퍼파라미터 선정 방법을 통해 학습된 모델의 경우 학습에 활용된 파라미터가 획기적으로 감소할 뿐만 아니라 정확도 또한 우수했다. 이를 통해 1D-CNN 기반 베어링 결함 진단에 있어 결함 주파수를 고려하여 1D-CNN 하이퍼파라미터를 선정하는 것이 보다 효과적임을 알 수 있다.

I. 서론

산업현장에서 널리 사용되는 회전기기의 핵심 부품인 베어링은 설비결함 원인의 가장 큰 비중을 차지한다고 알려져있다.[1] 이에 인공지능 기반 베어링 결함 진단을 위해 다양한 연구가 진행되고 있으며, 대표적으로 1D-CNN 기반 베어링 결함 진단 연구가 활발히 이루어지고 있다[2-4]. 본 논문에서는 베어링 결함 자동 진단을 위해 정상 및 결함 베어링별 운전 시 발생하는 가속도 진동 신호를 포락처리 후 주파수 영역으로 변환한 데이터를 기반으로 1D-CNN 모델을 학습함에 있어 하이퍼파라미터를 베어링 결함 주파수를 고려하여 선정하는 방법에 대해 논하고자 한다.

II. 연구 배경

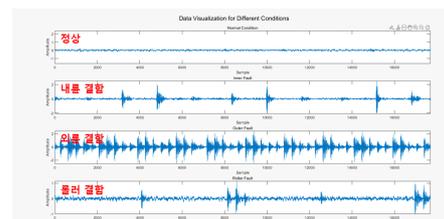
베어링 결함 발생 시 전동체가 그 결함을 통과할 때마다 충격에 따른 고유진동이 발생하며 진폭 변화의 주기를 찾기 위해 포락선(Envelope) 처리를 하고 주파수 스펙트럼을 분석한다[5]. 하지만 이는 전문가의 도메인 지식을 기반으로 분석해야하는 한계점이 존재하며, 이를 해결하기 위해 진동 신호의 스펙트럼을 입력으로 1D-CNN 기반 베어링 건전성 자동 진단 방법에 대한 연구가 진행되었다[6].

1D-CNN은 1차원의 입력 데이터에 대한 패턴 인식에 강한 모델로써, 일반적으로 하이퍼파라미터인 Size of Kernel 및 Stride를 작게 선정하여 최대한 많은 특징을 추출 및 학습에 활용한다[7-9]. 하지만, 베어링 결함 발

생시 포락 주파수 스펙트럼상 결함 주파수와 그 배수 성분 주파수를 비롯하여 회전 주파수성분이 측대역파로 추출되는 것이 특징이기에 Size of Kernel 및 Stride를 작게할 경우 앞서 기술한 특징 인식에 다소 약점이 존재할 수 있다. 따라서, 본 논문에서는 베어링 결함 자동 진단을 위해 가속도 진동 포락 주파수 스펙트럼을 입력으로하여 1D-CNN 모델 학습시 Size of Kernel 및 Stride를 베어링 결함 주파수를 고려하여 적용한 결과를 분석해보았다.

III. 실험 데이터 및 1D-CNN 구조

모델에 학습시킬 데이터는 방진가공을 통해 외륜, 내륜, 롤러 각각 1mm 결함을 모사한 NJ204 롤러 베어링을 활용하여 베어링 결함모사 테스트베드에서 900RPM으로 25600S/s, 120초씩 취득하였다. [그림 1]은 취득한 정상 및 결함 베어링별 가속도 진동 시간파형이다.



[그림 1] 베어링 상태별 가속도 진동 시간파형

900RPM에서의 베어링 결함 주파수는 [표 1]과 같다.

[표 1] 900RPM 기준 NJ204 롤러 베어링 결함 주파수

구분	결함 주파수(Hz)
정상	-
외륜 결함	70
내륜 결함	94
롤러 결함	40

제한한 하이퍼파라미터를 적용한 1D-CNN 모델은 [표 2]와 같으며, 성능 및 연산량을 비교하기 위해 동일한 개수의 Convolution Layer를 가진 일반적인 모델을 [표 3]과 같이 설계하였다. 입력 데이터는 베어링 상태별 120초간 취득한 초단위 가속도 진동 데이터를 포락처리한 주파수 스펙트럼이다. 총 480세트중 320세트를 훈련, 80세트를 검증, 나머지 80세트를 테스트세트로 활용하였다. 주파수 스펙트럼상 주파수 간격은 1Hz이며, 첫 번째 Convolution Layer의 Size of Kernel을 베어링 결함주파수에서 가장 높은 주파수인 내륜결함보다는 크되 2배 성분보다는 작은 2^n 인 값인 128을 채택하였다. 이는 kernel이 각 결함별 결함 주파수 성분을 포함하고 GPU의 병렬처리 능력을 활용하기 위함이다. 그리고, 모든 Convolution Layer의 Stride를 Size of Kernel과 동일하게 선정하여 서로 다른 kernel 간의 중복성을 최소화하였다.

[표 2] 일반적인 1D-CNN 모델 구조

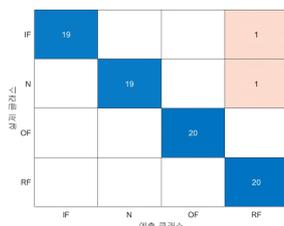
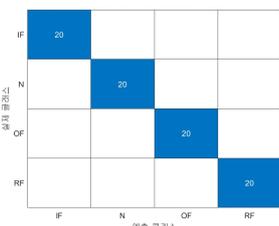
Layer	# of kernel	Size of kernel	Stride	Padding	Output shape	Weights, bias
Conv1	20	16	4	Same	3200*20	320, 20
Conv2	50	8	4	Same	800*50	8000, 50
FC	-	-	-	-	4	160000, 4

[표 3] 제안된 하이퍼파라미터를 적용한 1D-CNN 모델 구조

Layer	# of kernel	Size of kernel	Stride	Padding	Output shape	Weights, bias
Conv1	16	128	128	Same	100*16	2048, 16
Conv2	16	5	5	Same	20*16	1280, 16
FC	-	-	-	-	4	1280, 4

IV. 실험 결과

제안된 하이퍼파라미터를 활용한 모델의 분류 성능은 [그림 2]의 Confusion Matrix에서 볼 수 있듯이 100%이며, 일반적인 하이퍼파라미터 활용 모델의 분류성능은 [그림 3]의 Confusion Matrix와 같이 97.5%로 제안된 하이퍼파라미터 활용 모델의 성능이 더 우수함을 알 수 있다.



[그림 2] 제안된 하이퍼파라미터 활용 모델의 Confusion Matrix

[그림 3] 일반적인 하이퍼파라미터 활용 모델의 Confusion Matrix

뿐만 아니라, 일반적인 하이퍼파라미터 활용 모델의 학습에 사용된 파라미터 개수인 168,394개 대비 제안된 하이퍼파라미터 활용 모델의 학습에 사용된 파라미터 개수는 4,644개이다. 이는 제안된 하이퍼파라미터 활용 모델의 학습의 경우 일반적인 하이퍼파라미터 활용 모델대비 약 2.7%의 파라미터만을 사용했음에도 우수한 성능을 확보할 수 있음을 보여준다.

V. 결론

베어링 결함 자동 진단을 위해 주파수 스펙트럼을 입력으로 1D-CNN 모델을 설계할 시, Size of Kernel 및 Stride를 결합주파수를 고려하여 선정할 경우 보다 적은 파라미터를 활용하여 더 높은 분류성능을 확인할 수 있었다. 이는 베어링 결함에 의한 신호가 특정 주파수의 배수로 나타나며, 해당 주파수들의 측대역 성분이 검출되는 특징에 의한 것으로 판단된다. 본 연구를 바탕으로 추후 산업계에서 설비 자동 진단 방법으로써 1D-CNN을 적용할 경우, 결합 주파수를 고려하여 하이퍼파라미터를 선정한다면 연산량을 줄이면서도 더욱 높은 성능을 확보하여 경쟁력을 확보할 수 있을 것으로 기대된다.

ACKNOWLEDGMENT

본 논문은 울산시-ETRI 2차 공동협력사업의 일환으로 수행되었음. [24AB1600, 제조 혁신을 위한 주력산업 지능화 기술 개발 및 산업현장에서의 사람-이동체-공간 자율협업지능 기술 개발] 또한 이 연구는 2023년도 산업통상자원부 및 한국산업기술기술평가원(KEIT) 연구비 지원에 의한 연구임 ('20023566').

참고 문헌

- [1] J Chuya-Sumba, "Deep-Learning Method Based on 1D Convolutional Neural Network for Intelligent Fault Diagnosis of Rotating Machines", Applied Sciences, 12(4), 2022
- [2] IH Ozcan, "Enhanced bearing fault detection using multichannel, multilevel 1D CNN classifier", Springer, 104, pp435-447, 2022
- [3] H Wang, "Rolling Bearing Fault Diagnosis Using Multi-Sensor Data Fusion Based on 1D-CNN Model", Entropy, 24(5), 2022
- [4] L Eren, "Bearing Fault Detection by One-Dimensional Convolutional Neural Networks", Mathematical Problems in Engineering, 2017
- [5] 일본진동기술연구원 공저(김태호, 임강민, 최연선, 한승우, 최병근 공역), "ISO 규격에 따른 기계설비의 상태감시와 진단 (진동, 영역Ⅲ)", (사)한국소음진동공학회 한국설비진단자격인증원, p.132,(2013.04)
- [6] 김예진, "베어링 고장진단을 위한 진동 신호 스펙트럼 기반 1D CNN 모델 연구", 대한기계학회논문집A권, pp.615-616, 2022
- [7] 변은석, "1D CNN을 이용한 이미지 기반의 진동 신호 측정 및 보정", 대한기계학회논문집A권, 46(8), pp765-772, 2022
- [8] Hakim. M, "Bearing Fault Diagnosis Using Lightweight and Robust One-Dimensional Convolution Neural Network in the Frequency Domain", Sensors, 22(15), 5793, 2022
- [9] I Mitiche, "1D-CNN based real-time fault detection system for power asset diagnostics", IET Gener.Trasm.Distrib. 14(24), 5766-5773, 2020