

베어링 진단을 위한 진동 신호 기반의 딥러닝 모델

*박수연 **김재광

성균관대학교

**linux@skku.edu

A Vibration Signal-based Deep Learning Model for Bearing Diagnosis

*Park, SuYeon **Kim, Jaekwang

Sungkyunkwan University

요약

최근 자동차, 철도차량 등 사용자가 있는 기계 시스템에서의 고장 발생 시 사용자의 안전과 관련된 사고로 이어질 수 있어 부품에 대한 모니터링 및 고장 여부 판단은 매우 중요하다. 이러한 부품 중에서 베어링은 회전체와 회전하지 않는 물체 사이에서 회전이 원활하게 이루어질 수 있도록 하는 부품인데, 베어링에 결함이 발생하게 될 경우, 기계 시스템이 정지하거나, 마찰 열에 의해 화재 등의 치명적인 위험이 발생한다. 본 논문에서는 Resnet과 오토인코더를 활용하여 진동 신호 기반의 베어링의 고장을 감지하고 분류할 수 있는 모델을 제안한다. 제안 방법은 raw data를 이미지로 변환하여 입력으로 사용하는데, 이러한 접근을 통해 수집된 데이터의 손실을 최소화하고 데이터가 가지는 정보를 최대한 분석에 활용할 수 있다. 제안 모델의 검증을 위하여 공개된 데이터셋으로 학습/검증 하였고, 제안 방법이 기존 방법과 비교하여 더 높은 F1 Score와 정확도를 보임을 확인하였다.

1. 서론

베어링의 진동 분석은 크게 고전적인 신호 처리 방식에 따른 분석 방법과 머신러닝 등의 방법을 이용한 분석 방법으로 나눌 수 있다. 여러 논문에서 진동 신호를 처리하는 방식과 진동 데이터를 활용하여 회전하는 베어링의 고장을 판단하는 분석 방식에 대해 소개하고 있다[1-4]. 고전적인 방식의 경우 가속도계로 측정된 진동 데이터를 먼저 low pass filter, high pass filter 등을 활용하여 노이즈를 제거한다. 진동 분석의 경우 frequency domain에서 더 많은 특징을 나타내므로 노이즈가 제거된 time domain의 데이터를 frequency domain으로 변환한다 [5,6]. Frequency domain에서 베어링의 결함 주파수 대의 진폭을 확인하고, 이를 바탕으로 고장 여부를 판단하게 된다[7,8]. 이러한 고전적인 진동 분석 방식의 경우 복잡한 전처리가 필요하고, 전처리를 담당하는 사람에 따라 다른 결과가 도출될 수 있다는 문제점이 있다[9-11]. 또한 시스템이 복잡해질수록 계산이 복잡하고 어려워진다.

머신러닝을 활용한 진동 분석 방법의 경우 고전적인 방법과 마찬가지로 측정된 진동 신호를 time domain에서 frequency domain 또는 time frequency domain으로 변환한다. 이 후 주파수 대역별로 max, min, average, kurtosis, skewness 등의 특징을 추출한다. 이렇게 추출된 특징을 일반적인 분류기 모델을 활용하여 학습 후 평가를 진행한다. 이렇게 머신러닝을 진동 분석에 활용할 경우 시스템이 복잡하더라도 복잡한 공식 대신 feature와 물리적 현상 사이의 관계 모델링이 수월하다는 장점이 있다. 또한 모델 학습에 의해 어느 정도 부족한 전처리를 보완 가능하다. 하지만 머신러닝 모델을 사용할 경우 현재까지 제안되는 대부분의 모델은 사용자가 임의로 정한 min, max, average, kurtosis, skewness 등 대푯값을 분류 모델의 입력으로 사용하고 있다. 진동 데이

터의 경우 일반적으로 kHz 단위의 높은 샘플링 비율로 측정이 되는데 이렇게 대푯값을 활용하여 분석을 할 경우 측정된 데이터의 손실이 발생한다. 또한 고장 분류 성능과 모델의 투명성을 trade off관계로 좋은 성능의 분류 모델이 존재하더라도 분류 결과에 대한 신뢰성 문제로 현업에서 사용하는 것에는 한계가 있다[12].

따라서 본 논문에서는 베어링의 진동 데이터를 손실 없이 이미지로 바꾸어 이미지에서 데이터의 feature를 찾아내어 분류의 성능을 높이는 모델을 제안한다.

2. 관련 연구

진동 데이터를 분석할 때에 많이 사용하는 방법은 전처리 과정을 통해 주파수 도메인에서의 변환을 하고, 주파수 도메인에서 대푯값들을 찾아 입력으로 한 모델을 생성한다. 구체적으로는 시간 도메인에서 Fast Fourier Transform(FFT)을 통해 변환된 주파수 영역으로 변환 후 주파수 대역별로 average magnitude, kurtosis, skewness 등의 대푯값을 뽑는다. 이렇게 추출한 대푯값을 이 진동 데이터를 나타내는 특징으로 하여 분류를 위해 신경망의 입력으로 활용한다. 이처럼 분류가 완료된 후 Grad-CAM을 활용하여 어떤 주파수 대역이 분류에 영향을 많이 미쳤는지를 확인할 수 있으며 Decision Tree 등을 활용하여 앞서 정의한 입력 값 중 어떤 값이 분석 결과에 영향을 주는지 확인 하는 것이 가능하다[13-16]. 그러나 이러한 분석 방식은 고주파 대역이 모델에 많은 영향을 미친다는 점과 입력 중 어떤 대푯값(ex. 3000~4000Hz의 Skewness)이 선정되었는가에 대한 정보만을 제공한다는 한계점이 있다.

3. 제안 방법

본 논문에서는 진동신호를 이미지로 변환하는 세 가지 모델을 제안한다. 그 중 첫 번째 모델은 Resnet 18을 활용한 분류 모델이다. 먼저 12,000개의 진동 데이터로 구성된 이미지를 Resnet 18의 입력으로 한다. 모델의 구성은 아래 그림 1이 보이는 바와 같다.




그림 1. 진동데이터를 활용해 생성한 이미지를 입력으로 하는 분류 모델.

두 번째 모델은 오토인코더를 이용하여 이미지의 feature를 학습한 뒤 이를 Resnet 18에 입력으로 활용하는 분류 모델이다. 두 번째 모델은 먼저 오토인코더를 통해 low layer에서의 feature를 학습한다. 오토인코더의 학습 시 loss function은 MSE를 사용한다. 이후 encoding의 출력을 Resnet 18의 입력으로 하여 베어링의 상태를 분류한다. 두 번째 모델의 전체 구성은 그림 2가 보이는 바와 같다.



그림 2. 오토인코더의 학습 결과를 입력으로 하는 Resnet 18을 활용한 분류 모델.

세 번째 모델은 분류기인 Resnet 18에 1) 진동 데이터를 활용해 생성한 이미지와 2) 오토인코더에서 학습한 특징을 모두 입력으로 활용하는 분류 모델이다. 이 모델의 경우 1) 진동 데이터를 활용해 생성한 이미지를 직접 Resnet 18에 입력으로 활용하여 high layer의 특징 학습이 가능하며 2) 오토인코더에서 학습한 low layer의 특징을 함께 반영하여 분류가 가능하다는 장점이 있다. 세 번째 모델의 구성은 그림 3이 보이는 바와 같다.




그림 3. 진동 데이터를 활용해 생성한 이미지와 오토인코더의 학습 결과를 함께 입력으로 활용하는 Resnet18을 활용한 분류 모델.

4. 실험 및 결과

본 논문에서 사용된 베어링 데이터 세트는 case western reserve university에서 제공하며 여러 논문에서 사용되고 있다[17-22]. 이 데

이터는 샘플링 주파수가 12kHz인 모터의 드라이브 엔드에 장착된 가속 도계를 사용하여 수집하였다. 베어링의 손상 조건에 따라 1) normal, 2) inner ring fault, 3) outer ring fault, 4) ball fault로 라벨링 되어 있다. 기존 데이터에서는 베어링의 직경 및 모터의 부하에 따라 데이터를 나누고 있지만 본 연구에서는 해당 내용은 고려하지 않고 고장 관련 라벨과 진동 데이터만을 사용하여 분석을 진행한다.

본 연구에서 제안하는 모델은 진동 데이터를 이미지로 변환하여 분석을 진행한다[23][24]. 진동 데이터를 그대로 입력으로 넣을 경우 시간과 관련된 특성을 반영할 수 없으며, 진동 데이터의 경우 일반적으로 x, y, z 세 개의 축으로 측정되는데 이러한 데이터들의 동시성 또한 설명이 불가능하다. 이를 이미지로 표현할 경우 x, y, z 축의 데이터를 RGB와 같이 3개의 채널을 활용하여 하나의 이미지로 생성이 가능하며, 이들의 동시성, 시간과 관련된 특징을 유지할 수 있는 장점이 있다. 아래 그림 4는 x, y, z축(3개의 채널)으로 이루어진 진동 데이터를 하나의 이미지로 표현하는 방식을 보인다. 이는 이미지에서 RGB 3개의 채널로 이루어진 데이터가 하나의 색을 가지는 이미지가 되는 방식과 같다.




그림 4. x, y, z 3채널로 구성된 데이터의 이미지 표현 방법.

원본 데이터의 경우 정상 데이터 4개, inner ring fault 16개, outer ring fault 28개, ball fault 16개로 구성되어 있으며 각각의 데이터의 길이 또한 다르다. 이 데이터를 1초 단위로 끊어 12,000개의 데이터를 100*120의 이미지로 생성하였다. 개념적으로 x, y, z축 세개의 채널로 이루어진 데이터를 이미지로 생성하여야 하나 본 논문에 활용된 데이터는 z축 한 축으로만 측정된 데이터로 gray scale의 데이터를 heatmap을 이용하여 이미지로 변환하였다. 아래의 그림8은 12,000개의 데이터로 생성한 이미지이다.




그림 5. 진동 데이터의 이미지 표현 예.

이렇게 이미지를 활용할 경우 시간과 관련된 특성을 데이터에 반영하여 분석하는 것이 가능하다. 고전적인 방식의 경우 Fast Fourier Transform(FFT) 과정을 거치며 시간 도메인의 특성을 잃게 되고, average magnitude, kurtosis, skewness 등의 계산된 대표 값들은 시간과 관련된 특성을 반영하지 못하는 입력으로 주어지게 된다.

하지만 이미지로 변환하여 분석을 진행할 경우 Fast Fourier Transform(FFT) 과정을 거치지 않기 때문에 시간 도메인에서의 특성을 잃어버리지 않으며, 앞의 그림 7과 같이 x, y, z축에서 수집된 신호의 경우 이미지의 한 픽셀로 합쳐 지기 때문에 동시에 일어나고 있는 진동 특성을 같은 시간으로 인식하여 분석이 가능하다는 장점이 있다. 또한 비슷한 시간대에 일어난 데이터들은 이미지에서 가까운 픽셀에 위치하기 때문에 특정 데이터 하나가 아닌 앞, 뒤 시간에 일어난 진동 특성을 함께 확인하여 특징을 추출할 수 있다는 장점이 있다.

표 1. 제안 방법들과 기존 방법과의 성능 비교표.

입력	Accuracy	F1 Score
제안방법 1	97.86	98.16
제안방법 2	92.14	91.65
제안방법 3	98.57	98.78
기존 방법 (FFT + 통계적 방법)	93.57	94.64

분석 결과 오토인코더의 출력과 진동 데이터 이미지를 입력으로 한 모델의 성능이 가장 뛰어난 것을 볼 수 있고, 오토인코더의 출력만을 입력으로 한 모델의 성능이 가장 낮은 것을 확인할 수 있다. 오토인코더의 경우 이미지의 low layer의 특징을 학습할 수 있다는 장점이 있지만, 데이터를 압축하며 손실이 발생하여 전체 데이터를 활용하여 분석한 모델보다 분류 성능이 낮게 나온 것으로 보인다. 하지만 오토인코더의 출력과 진동 데이터 이미지를 입력으로 할 경우 오토인코더를 통해 low layer의 특징을 학습한 후 진동 데이터의 이미지를 통해 high layer의 특징 또한 학습하여 가장 성능이 좋은 것을 확인할 수 있다.

기존 방법으로는 가장 일반적으로 사용된 방법인 진동 데이터를 Fast Fourier Transform(FFT)을 하여 주파수 대역 별 대푯값을 추출

하여 분석을 진행하는 방법을 비교하였다. 이 경우 오토인코더의 결과값만으로 분류를 한 것 보다는 성능이 좋았지만 본 논문에서 제안하는 모델 1, 3 대비 accuracy 및 f1 score가 낮은 것을 확인할 수 있다. 고전적인 방식을 통해 분석을 진행할 경우 고장 관련 주파수를 확인하여 고장과 관련된 좋은 feature를 선별하여 분류 모델의 입력으로 활용하면 더욱 좋은 성능을 기대할 수 있으나 이 과정은 노동 집약적이며 분석하는 사람에 따라 다른 결과를 도출하게 될 가능성이 크다.

5. 결론

본 논문에서는 고장 분류를 위한 진동 신호 기반의 설명 가능한 딥러닝 모델을 제안하였다. 먼저 raw 진동 데이터를 이미지로 변환 후 오토인코더를 통해 low layer의 특징을 학습한다. 이후 분류기 모델에 오토인코더에서 학습한 인코더의 출력과 raw 데이터로 생성한 이미지를 입력으로 분류 모델을 학습시킨다. 본 논문에서 사용한 데이터는 베어링 진동 데이터 중 1축 데이터만을 활용하여 입력으로 사용하는 이미지를 생성하였다. 추후 3축 데이터를 모두 활용하여 이미지를 생성하고, 이를 바탕으로 진동 신호 기반의 설명 가능한 딥러닝 모델을 연구할 계획이다.

감사의 글

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 ICT명품 인재양성 사업의 연구결과로 수행되었음 (IITP-2022-0-01821)

참고문헌

- [1] E. García Plaza, P. J. Núñez López, and E. M. Beamud González, "Efficiency of vibration signal feature extraction for surface finish monitoring in CNC machining," *Journal of Manufacturing Processes*, vol. 44, pp. 145-157, August, 2019.
- [2] G. He, K. Ding, and H. Lin, "Fault feature extraction of rolling element bearings using sparse representation," *Journal of Sound and Vibration*, vol. 366, pp. 514-527, March, 2016.
- [3] Z. Ren, S. Zhou, C. E. M. Gong, B. Li, and B. Wen, "Crack fault diagnosis of rotor systems using wavelet transforms," *Computers & Electrical Engineering*, vol. 45, pp. 33-41, July, 2015.
- [4] B. Dolenc, P. Bošković, and Đ. Juričić, "Distributed bearing fault diagnosis based on vibration analysis," *Mechanical Systems and Signal Processing*, vol. 66-67, pp. 521-532, January, 2016.
- [5] Y. Liu, L. Guo, Q. Wang, G. An, M. Guo, and H. Lian, "Application to induction motor faults diagnosis of the amplitude recovery method combined with FFT," *Mechanical Systems and Signal Processing*, vol. 24, no. 8, pp. 2961-2971, November, 2010.
- [6] W. K. Lee, M. M. Ratnam, and Z. A. Ahmad, "Detection of chipping in ceramic cutting inserts from workpiece profile during turning using fast Fourier transform (FFT) and

- continuous wavelet transform (CWT)," Precision Engineering, vol. 47, pp. 406-423, January, 2017.
- [7] B. Dolenc, P. Bošković, and Đ. Juričić, "Distributed bearing fault diagnosis based on vibration analysis," Mechanical Systems and Signal Processing, vol. 66-67, pp. 521-532, January, 2016.
- [8] Y. Yang, W. Yang, and D. Jiang, "Simulation and experimental analysis of rolling element bearing fault in rotor-bearing-casing system," Engineering Failure Analysis, vol. 92, pp. 205-221, October, 2018.
- [9] D. Zhao, T. Wang, R. X. Gao, and F. Chu, "Signal optimization based generalized demodulation transform for rolling bearing nonstationary fault characteristic extraction," Mechanical Systems and Signal Processing, vol. 134, p. 106297, December, 2019.
- [10] J. Wang, Y.Y. Peng and W. Qiao, "Current-aided order tracking of vibration signals for bearing fault diagnosis of direct-drive wind turbines," IEEE Trans. Ind. Electron., vol. 63, pp. 6336-6346, October, 2016.
- [11] F. Jia, Y. G. Lei, J. Lin, X. Zhou and N. Lu, "Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data", Mech. Syst. Signal Process., vol. 72-73, pp. 303-315, May, 2016.
- [12] H.Y. Chen, and C.H. Lee, "Vibration signals analysis by explainable artificial intelligence (XAI) approach: Application on bearing faults diagnosis", IEEE Access, vol.8, p. 134246 - 134256, July, 2020.
- [13] E. Tjoa and C. Guan, "A survey on explainable artificial intelligence (xai): Towards medical xai," arXiv preprint arXiv:1907.07374, 2019.
- [14] M. Ribeiro, S. Singh, and C. Guestrin, "Why Should I Trust You?: Explaining the Predictions of Any Classifier," arXiv preprint, arXiv:1602.04938, 2016.
- [15] B. Zhou, A. Khosla, A. Lapedriza, A. Oliva, and A. Torralba, "Learning Deep Features for Discriminative Localization," IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2921-2929, December, 2015.
- [16] R. R. Selvaraju, M. Cogswell, A. Das, R. Vedantam, D. Parikh, and D. Batra, "Grad-CAM: Visual Explanations from Deep Networks via Gradient Based Localization", IEEE International Conference on Computer Vision (ICCV), pp. 618-626, December, 2016.
- [17] S. Wang, W. Huang, and Z. K. Zhu, "Transient modeling and parameter identification based on wavelet and correlation filtering for rotating machine fault diagnosis," Mechanical Systems and Signal Processing, vol. 25, no. 4, pp. 1299-1320, May, 2011.
- [18] B. Li, P.-l. Zhang, D.-s. Liu, S.-s. Mi, G.-q. Ren, and H. Tian, "Feature extraction for rolling element bearing fault diagnosis utilizing generalized S transform and two-dimensional non-negative matrix factorization," Journal of Sound and Vibration, vol. 330, no. 10, pp. 2388-2399, May, 2011.
- [19] X. Li, J. Ma, X. Wang, J. Wu, and Z. Li, "An improved local mean decomposition method based on improved composite interpolation envelope and its application in bearing fault feature extraction," ISA Transactions, July, 2019.
- [20] X. Li, Y. Yang, H. Pan, J. Cheng, and J. Cheng, "A novel deep stacking least squares support vector machine for rolling bearing fault diagnosis," Computers in Industry, vol. 110, pp. 36-47, September, 2019.
- [21] W. A. Smith and R. B. Randall, "Rolling element bearing diagnostics using the Case Western Reserve University data: A benchmark study," Mechanical Systems and Signal Processing, vol. 64-65, pp. 100-131, December, 2015.
- [22] P. Bashivan, I. Rish, M. Yeasin, and N. Codella, "Learning Representations from EEG with Deep Recurrent-Convolutional Neural Networks", International Conference on Learning Representations (ICLR), November, 2015.
- [23] M. Sundararajan, A. Taly, and Q. Yan, "Axiomatic attribution for deep networks", Proceedings of the 34th International Conference on Machine Learning, vol. 70, pp. 3319-3328, August, 2017.
- [24] J. Kim, J. H. Lee, "A novel recommendation approach based on chronological cohesive units in content consuming logs," Information Sciences, vol. 470, pp. 141-155, January, 2019.