

ConvLSTM 모델 기반의 짧은 지연시간을 갖는 베어링 결함 진단

김지호, 신지훈, *김태환
한국항공대학교 항공전자정보공학부
e-mail : *taehwan.kim@kau.ac.kr*

Low-Latency Bearing Fault Diagnosis
Based on Convolutional Long Short-Term Memory

Ji-Ho Kim, Ji-Hoon Shin, *Tae-Hwan Kim
School of Electronics and Information Engineering
Korea Aerospace University

Abstract

This study presents a novel approach based on convolutional long short-term Memory (ConvLSTM) model to reduce the latency involved in bearing fault diagnosis. Time-series sensor data are segmented into short vectors that are fed sequentially into the model to find spatio-temporal features efficiently. The ConvLSTM model is devised to a many-to-many structure by which the failure can be diagnosed as soon as several consecutive prediction results correspond to the failure condition. The experiments based on the proposed approach show that the latency reduction is as high as 99.3% compared to the 2D-CNN approach.

I. 서론

베어링은 기계의 내부에서 회전하는 샤프트를 지지하여 물체의 회전을 보조하는 기계의 기본 요소이다. 베어링 결함의 지속은 전체 기계 고장으로

이어질 수 있으며, 이는 전체 기계 고장 원인의 30-40%를 차지한다 [1]. 베어링 결함이 치명적인 손상을 일으키기 전에 초기 단계에서 진단할 수 있다면 예측 불가능한 가동 중지 시간과 경제적 손실을 피할 수 있기 때문에 짧은 시간 내에 결함을 진단할 수 있어야 한다.

베어링은 기계 내부에 다양한 요소로 둘러싸여 있기 때문에 기계에 부착된 센서의 진동 데이터를 통해 고장을 진단한다. 머신 러닝 기반의 결함 진단은 이미지 데이터에서 공간적 특징을 추출하는 2차원 컨볼루션 신경망 (2D-CNN) [2-4], 전처리 과정 없이 1차원 원시 데이터를 처리하는 1차원 컨볼루션 신경망 (1D-CNN) [5-7], 시간적 특징을 고려한 재귀신경망 (RNN) [8]을 기반으로 연구가 진행되고 있다. 또한 이전 연구들은 결함 진단의 정확도에 초점이 맞춰져 있으며, 결과 도출까지 걸리는 지연 시간은 대부분 고려되지 않았다.

본 논문에서는 Convolutional Long Short-Term Memory (ConvLSTM) 기반의 짧은 지연을 갖는 베어링 결함 진단 방법을 제안한다. 한 번에 긴 벡터를 얻기 위해 생기는 입력의 대기 시간을 줄이기 위해 짧은 원시 벡터로 결함을 진단하며 이전 입력을 기반으로 결함을 진단하기 위해 다대다 구조의 ConvLSTM 모델이 사용된다. 또한 각 입력의 결과를

최종 결함 진단의 예측 값으로 보고 결함을 특정 횟수 이상 연속적으로 예측한다면 결함을 더 빨리 진단할 수 있다. 해당 방법은 Case Western Reserve University (CWRU) 베어링 데이터를 기반으로 실험되었으며 1D-CNN 기반의 접근 방식에 비해 50.89%, 2D-CNN 기반의 접근 방식에 비해 99.3%의 지연 시간을 감소시켰다.

II. 기존의 결함 진단 방법

2.1 결함 진단 프레임워크

일반적인 결함 진단의 프레임워크는 크게 1) 데이터 취득, 2) 데이터 처리 두 단계로 나뉜다. 2)단계의 데이터 처리는 전처리 과정과 추론 과정을 포함한다. 이 때 데이터 취득과 데이터 처리 단계는 각각이 그림 1과 같이 병렬적으로 수행될 수 있다.

데이터 취득 단계는 적절한 크기의 입력이 얻어질 때까지 순차적으로 들어오는 진동 데이터를 취득하고 저장한다. 따라서 데이터 취득 시간은 데이터의 크기에 의해 결정되며, 데이터 크기는 가장 좋은 성능을 내는 값으로 실험을 통해 결정된다. 더 긴 취득 시간동안 데이터를 취득하면 짧은 취득 시간동안 얻은 데이터보다 더 많은 정보를 담고 있기 때문에 성능이 좋아질 것이라고 기대할 수 있지만 긴 데이터를 얻기 위해 기다려야하는 지연 시간도 증가하는 단점이 있다.

전처리 과정은 원시 데이터를 모델의 입력에 맞게 가공해주는 과정을 뜻한다. 예를 들어, 2D-CNN의 경우 2차원 데이터로 입력을 받아야하기 때문에 1차원 데이터가 입력일 경우, 이를 2차원으로 가공해 주어야한다. 2D-CNN의 경우 전 처리 과정에 걸리는 시간이 추론 과정에 걸리는 시간과 비슷하게 소요될 수 있다 [9].

마지막 과정은 모델의 추론 과정으로, 데이터의 특징을 추출하고 Fully-connected layer (FCL)을 통해 최종 결함 진단 결과를 내는 단계이다.

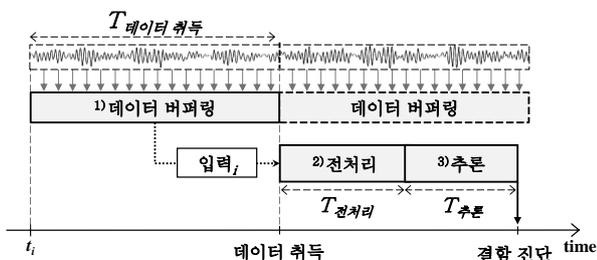


그림 1. 기존 결함 진단 방법의 전반적인 처리 흐름

2.2 뉴럴 네트워크 기반의 결함 진단

딥러닝 모델 중 CNN은 공간적인 특징의 추출에 뛰어나지만 시간적인 특징을 추출하지 못하는 구조적인 단점을 가지고 있다. 따라서 더 긴 취득 시간동안 데이터를 취득하여 사용할 때 더 좋은 성능을 보이며 이로 인해 입력 대기 시간이 증가한다. 또한 입력 데이터를 취득하고 나서도 2차원으로 입력을 가공 하는 데에 걸리는 시간 때문에 입력을 짧은 지연 시간 내에 처리하지 못한다.

CNN과 달리 RNN은 데이터의 시간적인 특징을 추출할 수 있기 때문에 순차 데이터를 효과적으로 처리한다. 결함 진단 데이터는 시간에 따라 순차적으로 계속 들어오기 때문에 시간적인 특징이 중요하며 이를 처리하기 위해서는 CNN보다 RNN이 더 적합하다. 또한 RNN은 행렬-벡터 곱 연산으로 이루어져 있으며, CNN은 행렬-행렬 곱 연산으로 이루어져 있기 때문에 일반적으로 CNN에 비해 연산 복잡도가 낮다. 하지만 RNN 그 자체로는 공간적 특징을 추출하기 어렵기 때문에, 일반적으로 다른 모델과 함께 쓰인다 [10].

III. 제안하는 결함 진단 방법

그림 2는 제안하는 ConvLSTM 기반의 결함 진단 방법을 보여주고 있다. 입력의 크기는 X, State 크기는 h로 표현하였으며 입력의 크기인 X는 결함 진단의 모든 지연 시간에 영향을 미치기 때문에 지연시간을 줄이기 위한 핵심 파라미터인 것을 확인할 수 있다. W는 워밍업 파라미터이며, P는 인내 파라미터, N은 입력의 총 개수이다. I는 모델의 추론 과정, D_n은 각각 각 입력에 대한 결함 예측 결과가 도출되는 시점이다.

ConvLSTM 모델은 RNN의 각 게이트 곱셈 연산을 컨볼루션 연산으로 대체하여 시공간적인 특징을 모두 얻을 수 있는 능력을 갖기 때문에 전처리 과정이 필요하지 않으며 입력 데이터가 들어오면 바로 모델의 입력으로 들어갈 수 있다. 또한 입력의 크기를 줄여도 시간적인 특징을 활용하여 이전의 정보를 통해 결함을 진단할 수 있다.

마지막 FCL의 결과만 결함 진단 결과로 사용하는 대신, ConvLSTM을 거친 모든 FCL의 출력을 최종 진단의 예측 값으로 전부 사용한다. 즉, ConvLSTM 모델은 다대다 구조로 사용하며 결함으로 판단 가능한 연속적인 예측 값이 나오면 진단을 더 빨리 할 수 있도록 하여 지연 시간을 감소시킨다. 이 때 워밍업 파라미터(W)는 모델이 실제로 결함을 진단하기 전에 충분한 데이터를 저장하는 데 필요한 최소 타임

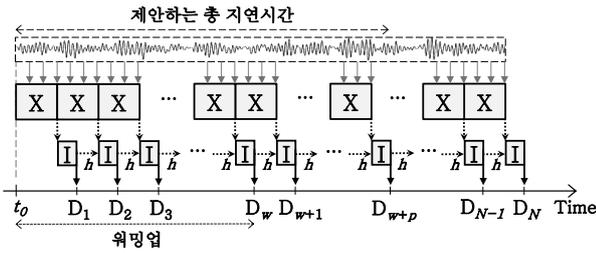


그림 2. 제안하는 결합 진단의 처리 흐름

스탬프 수이다. 인내 파라미터(P)는 위밍업 파라미터의 타임 스탬프 이후 동일한 결과의 연속 예측 수이며 W, P 모두 실험적으로 결정된다. 최소 지연 시간은 W 타임 스탬프 직후 P개의 연속 결과가 예측될 때 발생하고 최대 지연 시간은 P개의 연속 결과 예측이 마지막 타임 스탬프까지 발생하지 않아 모든 타임 스탬프를 계산해야할 때 발생한다.

IV. 결과 및 분석

제안하는 지연시간 감소를 위한 결합 진단 방법은 1.2GHz로 동작하는 ARM Cortex-A53 프로세서에 구현되었다. 그림 3은 실험 환경의 방법을 보이고 있다. 모델로는 16 state size 2 레이어의 ConvLSTM 모델을 사용했으며, 위밍업 파라미터와 인내 파라미터는 각각 8과 4로 설정하였다.

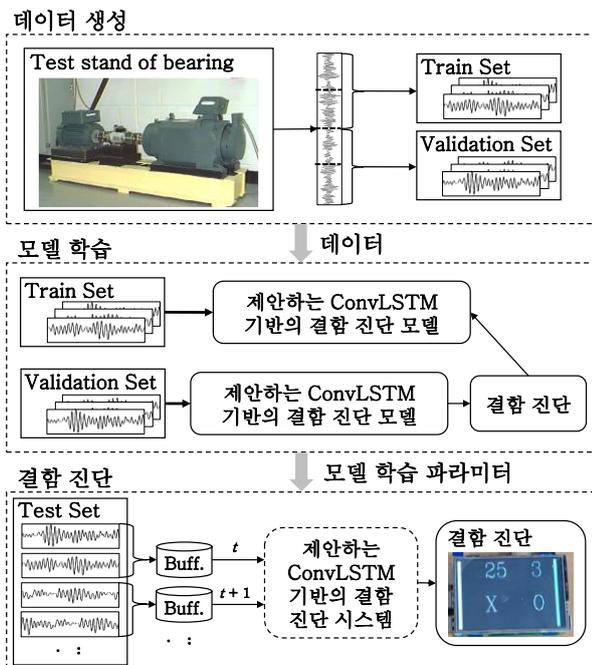


그림 3. 실험 환경 및 순서

제안하는 방법을 평가하기 위해서 Case Western Reserve University Bearing Data Center에서 제공하는 베어링 데이터를 사용하였으며 다른 뉴럴 네트워크 모델 기반의 방법과 제안하는 방법을 비교하기 위하여 파라미터의 수를 대략적으로 동일하게 맞추어 비교를 진행하였다. 그림 4는 다른 방법과 제안하는 방법의 정확도와 지연 시간을 비교한 표이다. 제안하는 방법을 CWRU 데이터셋으로 실험하였을 때 0.033ms의 지연 시간을 가졌으며 98.47%의 정확도를 보였다. 제안하는 방법을 1D-CNN과 비교하였을 때 50.89%의 지연 시간의 감소를 달성하였으며 정확도는 1.77% 증가하였고 2D-CNN과 비교하였을 때는 99.3%의 지연 시간을 감소시키며 정확도는 0.08% 증가하였다.

V. 결론

본 논문에서는 베어링 결합 진단에 걸리는 지연 시간을 ConvLSTM 모델을 통해 감소시키는 방법을 제안한다. 입력의 크기를 작게 받아도 시공간적 특징을 추출할 수 있도록 ConvLSTM 모델을 사용하였으며, 위밍업 파라미터와 인내 파라미터를 실험적으로 설정하여 연속적인 결합의 예측이 설정한 결합 진단에 필요한 예측 횟수만큼 발생할 경우 모든 입력을 처리하지 않고도 더 빨리 결합을 진단할 수 있다. 제안하는 방법은 CWRU 데이터셋을 사용하여 실험되었으며 1D-CNN과 비교하였을 때 50.89%, 2D-CNN과 비교하였을 때 99.3%의 지연시간 감소를 달성했다.

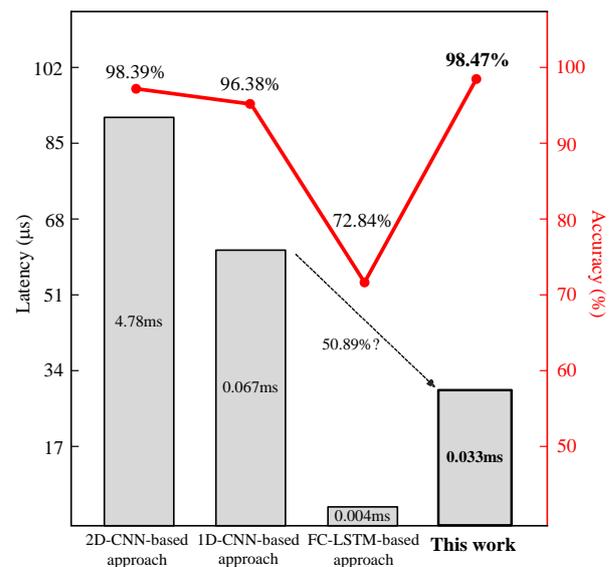


그림 4. CWRU 데이터셋의 정확도와 지연시간 비교

참고문헌

- [1] C. Heising, et al., "IEEE recommended practice for the design of reliable industrial and commercial power systems," IEEE Std 493-2007 (Revision of IEEE Std 493-1997) - Redline, pp.1-426, 25 June 2007.
- [2] Z. Li, T. Zheng, W. Yang, H. Fu, and W. Wu, "A robust fault diagnosis method for rolling bearings based on deep convolutional neural network," in Proc. Prognostics and System Health Management Conference, Qingdao, China, 2019, pp. 1-6.
- [3] P. Liang, C. Deng, J. Wu, Z. Yang, and J. Zhu, "Intelligent fault diagnosis of rolling element bearing based on convolutional neural network and frequency spectrograms," in Proc. IEEE International Conference on Prognostics and Health Management, San Francisco, CA, USA, 2019, pp. 1-5.
- [4] L. Wen, X. Li, L. Gao, and Y. Zhang, "A new convolutional neural network-based data-driven fault diagnosis method," IEEE Trans. Ind. Electron., vol. 65, no. 7, pp. 5990-5998, July 2018.
- [5] H. Kong, Q. Yang, Z. Zhang, Y. Nai, D. An, and Y. Liu, "Onedimensional convolutional neural networks based on exponential linear units for bearing fault diagnosis," in Proc. Chinese Automation Congress, Xi'an, China, 2018, pp. 1052-1057.
- [6] Y. Li, L. Zou, L. Jiang, and X. Zhou, "Fault diagnosis of rotating machinery based on combination of deep belief network and one-dimensional convolutional neural network," IEEE Access, vol. 7, pp.165710-165723, 2019.
- [7] C. Li, L. Yu, A. Zhang, Q. He, W. Yang, and Z. Duan, "A novel bearing fault diagnosis of raw signals based on 1d residual convolution neural network," in Proc. International Conference on High Performance Big Data and Intelligent Systems, Shenzhen, China, 2020, pp. 1-6.
- [8] X. Li, H. Jiang, Y. Hu, and X. Xiong, "Intelligent fault diagnosis of rotating machinery based on deep recurrent neural network," in Proc. International Conference on Sensing, Diagnostics, Prognostics, and Control, Xi'an, China, 2018, pp. 67-72.
- [9] 신지훈, 김철기, 김태환, "사운드 이벤트 감지를 통한 기계 상태 모니터링", 전자공학회논문지, 제55권, 제11호, 2018, pp. 84-90.
- [9] M. Qiao, S. Yan, X. Tang, and C. Xu, "Deep convolutional and LSTM recurrent neural networks for rolling bearing fault diagnosis under strong noises and variable loads," IEEE Access, vol. 8, pp. 66257-66269, 2020.