

# 센싱 오류와 신호 지연을 고려한 Delay Decision 기반 베어링 결함 진단

조한결<sup>1,†</sup>, 유유빈<sup>2,†</sup>, DAI MIAO<sup>1</sup>, 반상우<sup>1\*</sup>

동국대학교 대학원 정보통신공학과<sup>1</sup>, 한국전자통신연구원<sup>2</sup>

johangyeol@dongguk.ac.kr, yooyubin@etri.re.kr, daimiao@dongguk.ac.kr, \*swban@dongguk.ac.kr

## Delay Decision Approach for Bearing Fault Diagnosis under Sensing Errors and Signal Delay

Hangyeol Jo<sup>1,†</sup>, Yoobin Yoo<sup>2,†</sup>, Miao Dai<sup>1</sup>, Sang-Woo Ban<sup>1\*</sup>

Department of Information & Communication Engineering, Graduate School, Dongguk University<sup>1</sup>, Electronics and Telecommunications Research Institute

### 요약

본 논문에서는 저 사양 IoT 환경에서 베어링 결함 진단이 가능한 결정지연(Delay Decision) 기반 경량화 딥러닝 모델을 제안한다. 제안모델은 진동 센서 신호의 스펙트로그램을 모델의 입력데이터로 하여 결함을 진단하는 과정에서, 일정 시간 동안에 연속된 진단 결과를 종합하여 결함진단을 하도록 하는 결정지연 기법 적용으로 일시적인 센싱 데이터 오류 또는 지연으로 인한 오 판단 문제를 해결하도록 하였다. Case Western Reserve University (CWRU) Bearing Dataset을 이용한 결함진단 성능 검증 실험에서 제안모델은 결정지연 기법을 적용하지 않은 단일 추론 모델에 비해 높은 진단 정확도를 보였다. 본 연구는 경량 딥러닝과 결정지연 기법의 결합으로 실제 회전 기계 시스템에서 신뢰성 있는 베어링 결함 진단 방법 제시를 통해 안정적인 결함 진단 시스템 구현 가능성을 보였다.

### I. 서론

회전 기계의 핵심 부품인 베어링은 전체 회전 기계 설비 결함의 약 40% 이상을 차지한다고 알려져 있다 [1][2]. 이에 따라 산업용 회전 설비, 풍력 발전기, 운송 장비 등 다양한 분야에서 베어링 상태 모니터링과 결함 진단을 위한 연구가 활발히 진행되고 있다 [3]. 그러나 기존 베어링 진단 기법은 고성능 장비와 대용량 데이터 전송 장치를 요구하기 때문에 저사양 IoT 환경에서는 적용이 제한적이다. 또한 실제 운용 환경에서는 센싱 오류와 진동 신호 지연이 빈번하게 발생하여, 기존 방법만으로 안정적으로 진단하기 어려운 한계가 있다.

본 논문에서는 이러한 한계를 극복하기 위해 경량 딥러닝 모델과 결정지연(Delay Decision) 기법을 결합한 베어링 결함 진단 방법을 제안한다. 이를 통해 저사양 IoT 환경에서도 효율적이고 안정적인 진단 성능을 달성할 수 있음을 보인다.

### II. 제안 모델

본 논문에서는 회전 기계의 결함을 효과적으로 진단하기 위해 경량화 딥러닝 모델과 결정지연 기법을 결합한 진단 기법을 제안한다. 제안모델의 전체 구조는 그림 1과 같이 경량 CNN 기반 분류 모듈과 결정지연 기반 진단 모듈로 구성된다.




그림 1. 제안 결정지연 기반 경량화 CNN 베어링 결함진단 모델

실험 데이터는 CWRU Bearing Dataset[4]을 사용하였다. 데이터셋은 진동 센서로부터 획득한 신호로 구성되어 있으며, 제안모델에서 진동 센서 신호는 STFT(Short-Time Fourier Transform)를 적용하여 시간-주파수 영역의 스펙트로그램으로 변환하여 모델의 입력데이터로 활용한다. 이때, 모델 경량화를 위하여 입력 스펙트로그램 크기는 65×5로 설정하였다. 경량화 CNN은 저사양 IoT 환경에서의 활용 가능성을 고려하여 convolution layer와 pooling layer를 최소화하면서도 결함 관련 특징을 효과적으로 추출할 수 있도록 설계하였다.

실제 회전 기계 운용 환경에서는 센싱 오류와 신호 지연이 빈번하게 발생하여 단일 추론 모델로 즉각적인 분류는 오 판단 가능성을 높인다. 이를 보완하기 위해 결정지연 기법을 제안하였다. 결정지연 기법은 일정 구간 동안의 연속된 예측 결과를 바탕으로 결함 진단을 결정하는 방식으로 제안모델에서는 일정 시간 구간 길이를 연속된 3프레임, 5프레임, 11프레임 간격을 적용하여 실험을 수행하였다. 즉 연속된 3회, 5회, 11회 개별진단 결과를 토대로 보팅 방식으로 결함을 진단하도록 하였다. 이러한 접근은 단일 진단 모델의 예측 불확실성을 완화하여 센싱 오류나 신호 지연 환경에서 신뢰성 있는 진단 성능을 보일 수 있다.

### III. 실험 결과

본 논문에서는 성능 검증 실험을 위해 CWRU Bearing Dataset의 12 kHz 샘플링 데이터를 사용하였다. 데이터에서 결함 종류는 Normal와 Inner race Fault, Outer race Fault, Ball Fault이고 결함의 크기는 0.007 inch~0.028inch이다. 결함 진단을 위한 진동 센서 위치는 회전 기계의 DE(Drive End), FE(Fan End), BA(Basement)로 구분된다. 모델 학습에는 훈련 데이터 300세트, 검증 데이터 100세트, 테스트 데이터 200세트가 활용되었다.

표 1은 단일 추론 방식으로 적용한 결과와 결정지연 기법을 적용한 결함

진단 정확도의 비교 결과를 보인다. 단일 추론기반의 성능은 DE 센서 98.02%, FE 센서 98.93%, BA 센서 96.36%를 보여 단일 추론기반 경량화 모델만으로도 우수한 진단 성능을 보이고 있지만, 센싱 오류와 신호 지연으로 인해 일시적 오분류가 발생할 가능성은 여전히 존재한다.

결정지연 기법에서 연속된 일정 시간 구간 길이를 5 프레임으로 적용한 경우, 모든 센서 위치에서 정확도가 향상되었으며, 특히 FE 센서에서는 100%의 정확도를 기록하였다. 또한, DE 센서와 BA 센서에서도 각각 99.90%, 99.65%로 개선되어, 단일 추론 대비 약 1~3%p의 성능 향상이 확인되었다.

표 1. 결정지연 적용 전후 센서별 베어링 결함 진단 정확도 비교

Sensor Location	Drive End	Fan End	Base A
단일추론 모델 진단 정확도	98.02%	98.93%	96.36%
결정지연 모델 진단 정확도	99.90%	100%	99.65%

이러한 결과는 결함지연 기법이 단일 프레임 기반 예측의 불안정성을 효과적으로 개선하여 모델의 신뢰성과 견고성을 향상시킬 수 있음을 입증한다. 특히 상대적으로 단일 추론 모델의 결함 진단 성능이 낮은 BA 센서에서도 성능이 크게 개선된 결과를 보이고 있다.

#### IV. 결론

본 논문에서는 저사양 IoT 환경에서 베어링 결함 진단에 적용 가능한 결정지연 기반 경량 딥러닝 모델을 제안하였다. 제안모델은 CWRU Bearing Dataset을 이용한 결함 진단 실험을 통해 모든 센서 위치에서 단일 추론 결함진단 대비 정확도가 향상되었다. 이는 결정지연 기법이 센싱 오류와 신호 지연 환경에서도 안정적인 진단을 가능하게 함을 보여준다. 향후 다양한 데이터셋과 실시간 적용 평가를 통해 제안 기법의 일반화 가능성 검증 연구를 수행할 계획이다.

#### ACKNOWLEDGMENT

This work was supported in part by the Korea Institute of Energy Technology Evaluation and Planning (KETEP) grant funded by the Korea government (MOTIE) under Grant No. 20214000000010, and in part by the Electronics and Telecommunications Research Institute (ETRI) grant funded by the Korean government [25ZK1100, Honam region regional industry-based ICT convergence technology advancement support project].

† These authors contributed equally to this work.

#### 참 고 문 헌

[1] Hakim, M., Omran, A. A. B., Ahmed, A. N., Al-Waily, M., & Abdellatif, A. (2023). A systematic review of rolling bearing fault diagnoses based on deep learning and transfer learning: Taxonomy, overview, application, open challenges, weaknesses and recommendations. *Ain Shams Engineering Journal*, 14(4),

101945.

[2] Dai, M., Jo, H., Kim, M., & Ban, S.-W. (2025). MSFF-Net: Multi-Sensor Frequency-Domain Feature Fusion Network with Lightweight 1D CNN for Bearing Fault Diagnosis. *Sensors*, 25(14), 4348.

[3] Yoo, Y., Jo, H., & Ban, S.-W. (2023). Lite and Efficient Deep Learning Model for Bearing Fault Diagnosis Using the CWRU Dataset. *Sensors*, 23(6), 3157.

[4] Case Western Reserve University Bearing Dataset. Available online: <https://engineering.case.edu/bearingdatacenter>