

# Autoencoder 기반 이상 탐지와 Few-Shot 학습을 이용한 기어 고장 진단 프레임워크

박지섭, 정재진

국립금오공과대학교

flamma0202@gmail.com, jeong@kumoh.ac.kr

## Gear Fault Diagnosis Framework Using Autoencoder-Based Anomaly Detection and Few-Shot Learning

Jiseop Park, Jae Jin Jeong

Kumoh National Institute of Technology

### 요약

산업 현장의 회전체 기계 고장 진단에서는 정상 데이터는 비교적 쉽게 확보되는 반면, 비정상 데이터는 수집이 제한적이라는 문제가 존재한다. 본 논문에서는 이러한 환경을 고려하여 정상 데이터만을 이용한 Autoencoder(AE) 이상 탐지와 소량의 비정상 샘플을 사용하는 Few-Shot 고장 분류를 결합한 2-Stage 기어 고장 진단 프레임워크를 제안한다. 제안 기법은 Stage-1에서 AE를 이용해 비정상 신호를 탐지하고, Stage-2에서 AE의 인코더 임베딩을 통해 Few-Shot 학습을 수행하여 고장 유형을 분류한다. 실험은 Aalto Gear Fault Dataset을 대상으로 수행되었으며, 최종 평가 결과 Stage-1에서 99.94%로 비정상을 검출하고 Stage-2를 통해 주요 기어 고장 유형을 99.93%의 정확도로 분류할 수 있음을 확인하였다.

### I. 서론

산업 현장에서의 회전체 기계 고장 진단은 설비 신뢰성과 유지보수 비용 측면에서 매우 중요한 문제이다 [1]. 최근 딥러닝 기반 상태 진단 기법이 활발히 연구되고 있으나, 실제 산업 환경에서는 정상(Healthy) 데이터는 비교적 쉽게 확보되는 반면 비정상(Faulty) 데이터는 매우 제한적으로 수집되는 문제가 존재한다 [2]. 특히 기어 시스템의 경우 고장 발생 빈도가 낮고 고장 유형별 데이터 수집이 어려워 지도 학습 기반의 다중 분류 모델을 직접 적용하는 데 한계가 있다.

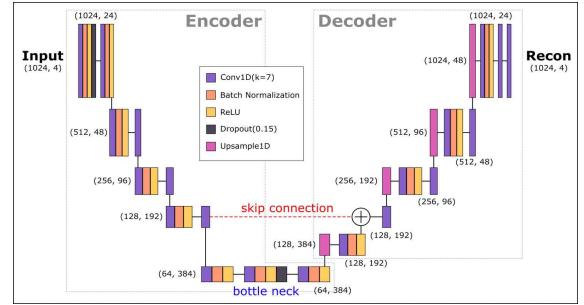
이에 따라 정상 데이터만을 활용하는 이상 탐지 접근법이 주목받고 있다. 이는 정상 상태의 분포를 학습한 뒤 입력 신호의 복원 오차 또는 잠재 표현의 이상성을 통해 비정상 상태를 검출하는 방식으로, Autoencoder(AE) 기반 방법이 대표적이다 [3]. 한편 고장 유형별 데이터가 극히 제한된 상황에서는 소량의 샘플만으로 분류를 수행하는 Few-Shot 학습이 효과적인 대안으로 제시되고 있다 [2].

본 논문은 이러한 관점에서 AE 기반 이상 탐지와 AE 인코더 임베딩을 활용하는 Few-Shot 분류를 결합한 2-Stage 프레임워크를 제안한다. 실험은 공개 기어 고장 데이터셋인 Aalto Gear Fault Dataset(AGFD)에서 수행되었으며, 제안한 프레임워크가 정상 데이터 기반 이상 탐지와 소량 샘플 기반 고장 분류를 효과적으로 수행할 수 있음을 보였다.

### II. 본론

#### 1. 데이터셋 및 전처리

AGFD는 실제 산업용 마린 스러스터를 축소한 시험 장비에서 측정된 기어 고장 데이터셋으로, Micropitting, Pitting, Tooth Flank Fracture (TFF), Wear의 현실적인 기어 고장 유형과 다양한 운전 조건을 포함한다 [4]. 본 논문에서는 AGFD 중 3012 Hz 샘플링, 750 RPM 조건에서 가속도 (acc1-acc4) 4채널을 사용하였다. 각 시계열을 길이 1024 윈도우로 분할하고 75% 오버랩을 적용했으며, 윈도우별 Z-score 정규화를 수행했다. 데이터셋 분할은 CSV 파일 단위로 진행하여 평가 누수를 방지했다.



[그림1] Last-skip 연결을 적용한 1D U-Net AE 구조.

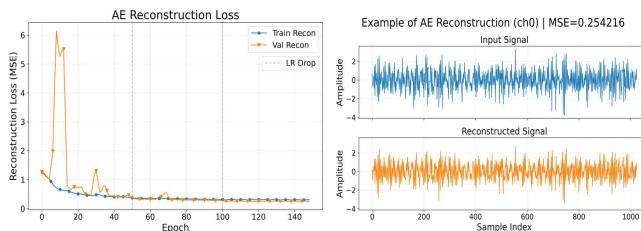
#### 2. Stage-1: Autoencoder 기반 이상 탐지

Stage-1에서는 정상 데이터만을 사용하여 학습된 1D U-Net 기반 AE를 이용해 이상 탐지를 수행하였다. 입력은 (1024, 4)의 다채널 시계열 신호이며, 인코더-디코더 구조를 통해 입력 신호를 복원한다. 본 논문에서는 U-Net 구조의 모든 skip connection을 사용하지 않고, 인코더 마지막 단계의 출력만을 디코더 입력에 연결하는 Last-skip 구조를 사용하였다. 이는 주요 고수준 특징을 효과적으로 전달하면서도 모델이 비정상 데이터를 과도하게 복원하는 문제를 완화하기 위한 설계이다. 본 논문에서 설계한 AE의 구조는 [그림1]에 나타내었다. 이상 점수는 입력 신호와 AE 복원 신호 간의 차이를 기반으로 정의하였다. 입력 윈도우  $x$ 와 이에 대한 복원 신호  $\hat{x}$ 에 대해 이상 점수  $s(x)$ 는 다음과 같이 평균 제곱 오차(MSE)로 계산된다.

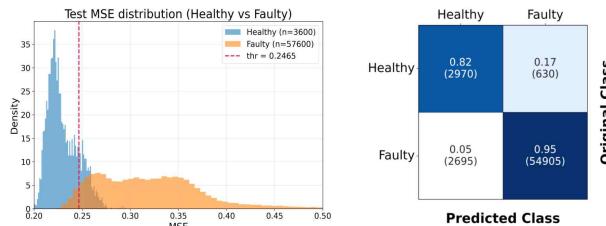
$$s(x) = \frac{1}{LC} \sum_{i=1}^L \sum_{j=1}^C (x_{i,j} - \hat{x}_{i,j})^2, \quad L = 1024, \quad C = 4 \quad (1)$$

AE는 Adam( $lr=1e-3$ ), batch size 256 조건에서 총 150 epoch 동안 학습을 진행했으며, 손실 함수는 복원 MSE를 사용하였다. 학습 중 50, 100 epoch에서 학습률을 10배씩 감소시켜 안정적인 손실 수렴을 유도했다. AE의 학습 손실 곡선과 입력 신호의 복원 예시는 [그림2]에 나타내었다.

이상 탐지를 위한 임계값은 Val set의 정상 데이터 분포를 기준으로 설정하였으며, Test set에서 Faulty Recall  $\geq 95\%$ 가 되도록 조정하였다.



[그림2] AE 학습 손실 곡선(좌)와 입력 신호 복원 예시(우).



[그림3] Test set에 대한 MSE 분포(좌)와 이상 탐지 혼동행렬(우).

Val set MSE 분포의 상위 84%지점( $\text{thr} \approx 0.2465$ )이 임계값으로 선정되었고, 이를 Test set에 적용한 결과 Faulty Recall 95.17%를 달성하였다. Healthy 데이터의 오탐률은 증가했으나, 고장 미검출 비율을 최소화하기 위해 Faulty Recall 우선 전략을 채택했다. [그림3]은 Test set에서 정상 데이터와 비정상 데이터의 MSE 분포와 설정된 임계값, 그리고 해당 임계값을 적용한 이상 탐지 결과를 나타낸다.

### 3. Stage-2: Few-Shot 고장 분류

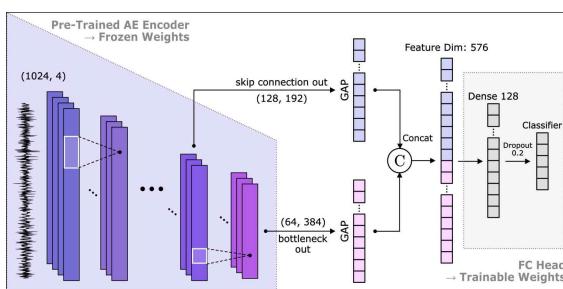
Stage-2에서는 Stage-1에서 비정상으로 판별된 신호만을 대상으로 고장 유형 분류를 수행한다. Stage-1에서 학습된 AE 인코더를 동결하여 특정 추출기로 사용하였으며, bottleneck과 Last-skip 특징을 전역 평균 풀링 후 연결하여 임베딩을 구성하였다. 이 임베딩을 입력으로 FC 기반 분류 Head를 학습하는 Few-Shot 분류기를 설계하였다. [그림4]은 Stage-2에 사용된 인코더 기반 특징 추출기와 분류기 구조를 나타낸다.

분류 클래스는 정상 오탐을 포함한 5개 클래스(Healthy, Micropitting, Pitting, TFF, Wear)로 구성하였으며, 5-Way 5-Shot 10-Query 설정의 에피소드 학습 방식을 적용하였다. 각 에피소드마다 샘플링된 Support set을 이용해 분류 Head를 소수의 업데이트 단계로 학습한 뒤, Query set에 대해 성능을 평가하였다. 학습은 총 500 에피소드 동안 수행하였으며 손실 함수로는 Sparse Categorical Cross-Entropy를 사용하였다.

검증 단계에서는 Val set을 대상으로 동일한 5-Shot 10-Query 설정의 200 에피소드 평가를 수행하였으며, 평균 분류 정확도는  $0.9978 \pm 0.0073$ 으로 나타나 제안한 Few-Shot 분류기의 안정적인 성능을 확인하였다.

### 4. 최종 평가

최종 평가는 Stage-1 이상 탐지 케이트를 통과한 Test set에 대해서만



[그림4] 사전 학습된 AE 인코더를 활용한 분류기 구조.

	Healthy	Micro-pitting	Pitting	TFF	Wear
Healthy	1.00 (621)	0.00 (0)	0.00 (0)	0.00 (0)	0.00 (0)
Micro-pitting	0.00 (0)	1.00 (3595)	0.00 (3)	0.00 (0)	0.00 (2)
Pitting	0.00 (0)	0.00 (3)	1.00 (2397)	0.00 (0)	0.00 (0)
TFF	0.00 (0)	0.00 (0)	0.00 (0)	1.00 (3598)	0.00 (2)
Wear	0.00 (0)	0.00 (0)	0.00 (0)	0.00 (0)	1.00 (3592)

[그림5] Stage-2 고장 유형 분류기를 이용한 최종 기어 고장 진단 결과.

Stage-2 분류기를 적용하여, 이상으로 판별된 샘플들에 대해 고장 유형 분류를 수행하는 방식으로 진행하였다. [그림5]은 Stage-1 이상 탐지 이후, Stage-2 분류기를 적용하여 얻은 최종 기어 고장 진단 결과를 나타낸다. Stage-1 이상 탐지 케이트를 통과한 샘플을 대상으로 Stage-2 분류기를 적용한 결과, 주요 기어 고장 유형을 99.93%의 정확도로 분류할 수 있었다. 또한 Stage-1에서 정상 샘플에 대한 오탐(False Positive)이 발생한 일부 경우에도, Stage-2 분류기를 통해 정상으로 재분류됨을 확인하였다.

### III. 결론

본 논문에서는 Aalto Gear Fault Dataset을 사용하여 정상 데이터만을 활용한 Autoencoder 이상 탐지(Stage-1)와 AE 인코더 임베딩을 적용한 Few-Shot 고장 분류(Stage-2)를 결합한 2-Stage 기어 고장 진단 프레임워크를 제안하였다. 실험 결과 Stage-1 이상 탐지 케이트를 통해 비정상 데이터에 대한 높은 검출 Recall을 달성하였으며, Stage-2 분류기를 통해 소량의 학습 샘플만으로도 주요 기어 고장 유형을 높은 정확도로 분류할 수 있음을 확인하였다. 이를 통해 비정상 데이터 수급이 제한적인 산업 환경에서도 신뢰도 높은 기어 고장 진단이 가능함을 보였다.

### ACKNOWLEDGMENT

본 결과물은 2025년도 경상북도 지역혁신중심 대학지원체계(RISE)-방위 Spin-on의 지원을 받아 수행된 결과입니다.(2025-rise-15-105)

### 참 고 문 현

- [1] Q. Zhang, N. Su, B. Qin, G. Sun, X. Jing, S. Hu, Y. Cai, and L. Zhou, "Fault diagnosis for rotating machinery based on dimensionless indices: Current status, development, technologies, and future directions," *Electronics*, vol. 13, no. 24, Art. no. 4931, 2024.
- [2] A. Hämäläinen, A. Karhinen, J. Miettinen, Z. Dahl, and R. Viitala, "Rapid deployment of deep learning-based condition monitoring for rotating machines," *IEEE Access*, vol. 13, pp. 192023 - 192044, 2025.
- [3] M. Sakurada and T. Yairi, "Anomaly detection using autoencoders with nonlinear dimensionality reduction," in \*Proc. 2nd Workshop on Machine Learning for Sensory Data Analysis (MLSDA)\*, 2014, pp. 4 - 11.
- [4] Z. Dahl, A. Hämäläinen, A. Karhinen, J. Miettinen, A. Böhme, S. Lillqvist, S. Haikonen, and R. Viitala, "Aalto gear fault datasets for deep-learning based diagnosis," *Data in Brief*, vol. 57, Art. no. 111171, 2024.