

라벨링 제약이 있는 산업 환경에서의 Active Learning 을 통한 소리 기반 기계 결함 진단

채지영, 이상훈*, 박경준*
대구경북과학기술원

cowldud3@dgist.ac.kr, 'leesh2913@dgist.ac.kr, *kjp@dgist.ac.kr

Machine Fault Diagnosis Based on Sound through Active Learning in Industrial Environments with Labeling Constraints

Jiyeong Chae, Sanghoon Lee', Kyung-Joon Park*
DGIST.

요 약

본 연구는 active learning 방법을 활용하여 라벨링 제약이 있는 산업 환경에서도 높은 성능을 보이는 소리 기반 기계 결함 진단 시스템을 제안한다. 제안하는 시스템은 산업 환경 상에서 데이터 라벨링을 최소화하여 비용 효율성을 향상시키면서도 결함 진단에 있어 유의미하게 높은 성능을 보인다. 산업 환경의 특성에 맞게 active learning의 파라미터를 최적화하는 추후 연구를 진행하여 추가적인 성능 향상을 기대할 수 있다.

I. 서 론

산업 현장에서의 기계 결함은 안전 및 생산성에 부정적인 영향을 끼치며, 특히 결함 초기에 발견되지 못할 경우 생산 중단으로 인한 경제적 손실이 일어날 뿐만 아니라 인명 피해까지 이어질 수 있다 [1]. 따라서 기계 결함을 탐지하는 것은 산업 현장에서 중요하게 여겨지는 요소 중 하나이다. 소리 기반의 기계 결함 진단 시스템은 산업 상의 기계 결함 문제를 해결할 수 있는 효율적인 방법으로 여겨지고 있다. 기계 작동 소리를 통해 해당 기계의 상태를 추측할 수 있으며, 이상 소음이 발생할 경우 오염, 누출, 회전 불균형, 레일 손상 등과 같은 문제를 탐지할 수 있다 [2]. 소리 기반의 기계 결함 진단은 인력을 통한 물리적 검사 방법에 비해 비용 효율적이며, 다양한 인공지능 기법을 활용하여 성능이 더욱 개선될 수 있다 [3]. 이러한 인공지능 기법의 성능을 최대화하기 위해서는 데이터에 대한 라벨링을 모두 진행한 뒤 모델을 학습하는 것이 효율적이지만, 실제 산업 환경에서는 물리적 제약 사항으로 인해 많은 양의 데이터에 대해 모든 라벨을 일일이 부여하는 것은 어려운 일이다 [4].

Active learning [5]은 이러한 기계 결함 진단 시스템에서 라벨링 제약을 해결하기 위해 사용되는 방식 중 하나이다. Active learning 은 전체 데이터의 작은 부분만 라벨링되어 있는 환경에서, 추가적으로 라벨링을 가장 필요로 하는 데이터 샘플들을 골라내어 라벨링을 진행하는 인공지능 학습 전략이다. Active learning 은 라벨링의 비용을 줄이면서 인공지능의 성능을 유지할 수 있어, 인공지능 기반 시스템의 운영 효율성을 향상시킬 수 있다.

본 논문에서는 라벨링 제약이 있는 산업 환경에서의 시스템 효율성을 개선하기 위해 active learning 을 통한 소리 기반 기계 결함 진단 시스템을 제안한다.

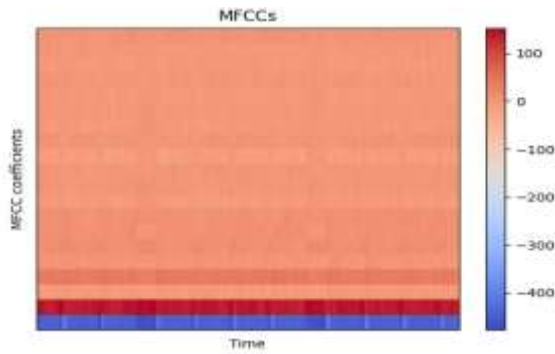
II. 본 론

Active learning 을 통한 소리 기반 기계 결함 진단 시스템의 프로세스는 다음과 같다.

1. 산업 현장의 기계 작동 소리 데이터를 수집한다.
2. 수집된 데이터에서 일부 (약 5% ~ 10%)의 무작위 샘플에 대해서 라벨링을 진행한다.
3. 라벨링이 완료된 초기 데이터셋을 통해 모델 훈련을 진행한다.
4. 훈련된 모델을 이용해, 라벨링이 없는 나머지 샘플에 대한 예측을 수행한다.
5. 예측의 불확실성이 높은 샘플들에 대해 추가적인 라벨링을 수행한다.
6. 추가적으로 라벨링된 데이터를 포함한 데이터셋으로 모델을 재훈련한다.

제안하는 시스템은 산업기계 오작동 조사 및 점검을 위한 소리 데이터 세트인 MIMII 데이터셋 [2]을 통해 평가된다. 우리는 MIMII 데이터셋 중 SNR 가 6dB 에 해당하는 Slider 기계의 작동 소리 샘플 712 개를 활용한다.

우리는 각 소리 데이터 샘플에 MFCC (Mel-Frequency Cepstral Coefficients) 신호처리를 진행하여 특징을 추출한다. MFCC 는 인간의 귀가 음성 신호를 인지하는 방식을 모방하여 주파수 성분을 추출하는 방식으로, Mel scale 을 사용하여 주파수 영역의 복잡한 구조를 단순한 계수로 표현한다 [6]. MFCC 의 결과는 그림 1 과 같이 나타난다.



[그림 1] 하나의 데이터 샘플에서 추출한 MFCC

MFCC 처리된 데이터셋에 지도학습 방법인 Convolutional neural network (CNN), 비지도학습 방법인 K-means clustering, 그리고 제안하는 active learning 기반의 반 지도학습 방식의 성능을 확인한다. 제안하는 방식은 전체 데이터셋 샘플 712 개의 70%에 해당하는 훈련 데이터셋 중 10%를 초기 데이터셋으로 가정하고, 추가적으로 가장 불확실성이 높은 20 개의 데이터를 라벨링하여 CNN 모델의 학습을 진행한다. 각 진단 모델은 인공지능 모델의 성능을 평가하는데 주로 사용되는, 정밀도와 재현율의 조화평균인 F1 점수를 사용해서 평가된다. 평가 결과는 <표 1>과 같다.

모든 샘플에 대해 라벨링이 되어있는 학습 데이터셋을 활용하는 CNN 방법이 가장 높은 F1 점수를 보이고, 라벨링된 데이터 없이 군집화를 하는 K-means 방법은 약 0.2 의 매우 낮은 성능을 보인다. 제안하는 active learning 기반의 CNN 의 경우, 지도 학습 방식인 CNN 에 비해 약 15% 감소된 F1 점수를 보인다.

Model	F1 score
CNN	0.97087
K-means	0.22857
Active Learning based CNN * 새롭게 라벨링된 샘플 수 20 개	0.82222

<표 1> 인공지능 기법에 따른 F1 성능

하지만, 제안하는 active learning 기반의 CNN 방식은 학습에 이용되는 새롭게 라벨링된 데이터의 수가 조금씩 증가할수록 모델의 성능이 급격히 향상된다. <표 2>는 새롭게 라벨링된 샘플의 수에 따른 F1 점수를 나타낸다.

예측이 가장 불확실한 샘플들 중 상위 20 개의 샘플에 대해 라벨링을 진행 한 뒤 학습한 CNN 모델의 경우 0.82 의 F1 점수를 보인다. 하지만 50 개의 샘플로 학습을 더 진행한 모델의 경우, 0.96 의 F1 점수로, 성능이 크게 향상됨을 확인할 수 있다. 이를 통해, active learning 기반의 CNN 방법이 지도학습의 CNN 방법에 비해서는 상대적으로 낮은 성능을 보이지만, 최소한의 데이터 샘플을 라벨링하면서 비슷한 성능을 보일 수 있음을 알 수 있다.

새롭게 라벨링 된 샘플 수	F1 score
20 개	0.82222
30 개	0.91836
50 개	0.96047

<표 2> 새롭게 라벨링된 샘플 수에 따른 F1 성능

III. 결론

본 연구를 통해 소리 기반 기계 결함 진단에 있어 active learning 의 잠재적 가치와 효용성을 확인할 수 있다. CNN 방법 및 K-means 방법과 비교했을 때, active learning 기반의 CNN 방법은 상대적으로 적은 데이터 라벨링 비용으로도 높은 성능을 달성할 수 있다. 이러한 결과는 active learning 전략이 라벨링에 필요한 비용과 자원을 크게 절약하면서도, 고성능의 예측을 수행할 수 있는 기법임을 입증한다. 이는 특히 시간적, 물리적 제약이 있는 산업 환경에서의 기계 결함 진단에 있어 효율적인 접근 방법이 될 수 있다. 또한, 산업 상의 데이터에 관한 모델의 성능을 지속적으로 모니터링하여 정보가 가장 풍부한 데이터 샘플을 선별함으로써 모델의 정확도와 신뢰성을 대폭 향상시킬 수 있다.

본 연구는 active learning 을 통해 라벨링 제약이 있는 산업환경에서도 소리 기반의 기계 결함 진단을 효율적으로 수행할 수 있음을 나타냄과 동시에, 산업 환경의 특성에 맞게 active learning 의 하이퍼파라미터를 최적화함으로써 성능이 개선될 여지가 있음을 시사한다.

참고 문헌

- [1] Hou, Liqun, and Neil W. Bergmann. "Novel industrial wireless sensor networks for machine condition monitoring and fault diagnosis." IEEE transactions on instrumentation and measurement 61.10 (2012): 2787-2798.
- [2] Purohit, Harsh, et al. "MIMI Dataset: Sound dataset for malfunctioning industrial machine investigation and inspection." arXiv preprint arXiv:1909.09347 (2019).
- [3] De Donato, Lorenzo, et al. "A survey on audio-video based defect detection through deep learning in railway maintenance." IEEE Access (2022).
- [4] Santos, Araken, and Anne Canuto. "Applying semi-supervised learning in hierarchical multi-label classification." Expert systems with applications 41.14 (2014): 6075-6085.
- [5] Dimitrakakis, Christos, and Christian Savu-Krohn. "Cost-minimising strategies for data labelling: optimal stopping and active learning." International Symposium on Foundations of Information and Knowledge Systems. Berlin, Heidelberg: Springer Berlin Heidelberg, 2008.
- [6] Tiwari, Vibha. "MFCC and its applications in speaker recognition." International journal on emerging technologies 1.1 (2010): 19-22.