

산업용 기계 이상 탐지를 위한 오토인코더 기반 모델 비교 연구

박지영, 김동현, 최정훈, 서동준*

경북대학교

{kelly1323, kdhnim96, cjh34544, *dongjunsuh}@knu.ac.kr

A Comparative Study of Autoencoder-based Models for Anomaly Detection in Industrial Machinery

Jiyoung Park, Donghyeon Kim, Jeonghoon Choi, Dongjun Suh*

Kyungpook National University.

요약

4차 산업혁명의 발전으로 AI 기술을 활용하여 생산 혁신을 위한 이상 탐지 연구가 활발히 진행되고 있다. 현재 이상 탐지는 주로 이미지 기반으로 연구되고 있으나 이미지를 통한 이상 탐지는 현장에서 많은 시간과 비용이 필요하다는 단점이 존재한다. 따라서 이러한 단점을 해결하기 위해 음향데이터 기반으로 이상 탐지를 진행하였다. 본 연구에서는 Log Mel-spectrogram 특징 추출 후 비지도 학습 기반의 모델들을 사용해 모델 간의 성능을 비교하여 적합한 모델을 판정하였다. 실험 결과 Toy Car, Toy Conveyor, Fan에서는 DAE, Pump는 AE가 Slider와 Valve는 CAE가 높은 AUC와 pAUC를 보여 줌을 확인하였다.

I. 서론

4차 산업혁명의 발전으로 AI 기술을 활용하여 생산 혁신을 위한 연구가 활발히 진행되고 있다. 특히, 제조 및 산업현장에서는 기계장비의 이상을 사전에 진단하고 예측하여 생산량과 수익을 증대시키기 위한 목적으로 머신러닝 및 딥러닝 기술을 적용한 연구가 진행되고 있다 [1].

현재 이상 탐지 기반 연구는 주로 이미지 데이터를 기반으로 사용되고 있다. 하지만 이미지 기반의 연구는 실제 산업현장에서 분석과 적용에 많은 시간과 비용이 필요하다는 단점이 존재한다. 또한, 결함이 기계 외부에 있을 경우 데이터 수집에 문제가 없지만, 기계 내부에 있을 경우 이미지 데이터 수집 시 시각적인 한계가 나타난다 [2]. 따라서, 상대적으로 데이터의 크기가 작고 시각적으로 보이지 않는 장소에 결함이 존재할 때, 데이터 수집이 쉬운 음향데이터를 활용함으로써 산업현장의 비용 절감, 중요 기계시설의 보안, 생산량 증대를 달성하고자 한다.

음향을 사용하여 이상을 탐지하는 ASD(Anomalous Sound Detection)는 의료, 보안, 산업현장에서 머신러닝 및 딥러닝 기술이 접목되어 사용되고 있으며 이미지 기반 데이터 주로 연구되는 이상 탐지의 대체로 주목받고 있다.

본 논문에서는 음향데이터를 활용하여 산업시설의 생산 혁신을 위해 Log Mel-spectrogram으로 특징 추출 후 비지도 학습 모델인 오토인코더와 오토인코더 기반의 DAE(Denoising AutoEncoder), CAE (Convolutional AutoEncoder)모델을 사용하여 Machine type 별 최적의 모델을 비교하고자 한다.

II. 본론

2.1 Dataset

본 논문에서는 기계 이상 탐지 연구를 수행하기 위해 Dcase에서 제공하는 MIMII(Malfunctioning Industrial Machine Investigation and Inspection) dataset을 사용하였다 [3]. 데이터 구성은 표 1과 같이 장난감

자동차(Toy-car), 장난감 컨베이어(Toy-conveyor), 밸브(Valve), 펌프(Pump), 팬(Fan), 슬라이드 레일(Slide rail) 6종류의 Machine Type으로 구성되어 있으며 각 Machine Type 별 3 - 4개의 ID를 가지고 있다. 각 Machine ID에는 정상, 이상으로 구분된다.

Table 1. MIMII Dataset Details

Machine Type	Machine ID	Normal condition	Anomalous condition
Toy Car	1	350	265
	2	350	265
	3	350	265
	4	350	265
Toy Conveyor	1	800	400
	2	800	400
	3	800	400
Fan	0	100	407
	2	100	407
	4	100	407
	6	100	407
Pump	0	100	143
	2	100	143
	4	100	143
	6	100	143
Slider	0	100	356
	2	100	356
	4	100	356
	6	100	356
Valve	0	100	119
	2	100	119
	4	100	119
	6	100	119

Table 2. Performance on MIMII Dataset

Machine Type	Machine ID	AE (%)		DAE (%)		CAE (%)	
		AUC	pAUC	AUC	pAUC	AUC	pAUC
Toy Car	1	82.45	69.73	83.00	72.55	75.81	61.16
	2	87.03	79.45	87.69	80.92	76.16	63.26
	3	64.63	56.52	63.87	56.49	57.20	51.81
	4	85.51	70.79	89.18	77.64	73.33	59.18
	Average	79.91	69.12	80.94	71.90	70.63	58.85
Toy Conveyor	1	77.12	64.99	83.40	70.21	78.42	63.15
	2	64.36	56.16	67.67	57.92	64.83	55.52
	3	76.99	62.75	82.66	64.53	79.62	62.43
	Average	72.82	61.30	77.91	64.22	74.29	60.37
Fan	0	54.47	49.51	55	49.39	49.55	49.48
	2	64.27	52.52	75.99	54.78	72.30	52.35
	4	53.43	52.34	63.74	52.48	58.87	51.52
	6	60.36	51.61	77.68	51.82	88.31	51.81
	Average	58.13	51.49	68.10	52.12	67.26	51.29
Pump	0	67.98	56.20	65.86	51.17	54.98	49.29
	2	61.25	58.46	61.42	58.89	54.99	52.82
	4	88.52	69.47	87.59	63.84	95.71	80.89
	6	74.03	57.94	76.62	59.77	73.56	51.13
	Average	72.94	60.52	72.87	58.42	69.81	58.53
Slider	0	91.17	66.15	97.69	89.26	98.35	91.82
	2	67.43	52.31	79.81	61.95	82.19	61.75
	4	64.91	55.02	94.73	73.03	97.08	84.65
	6	49.22	49.49	75.75	49.91	82.66	51.62
	Average	68.18	55.74	87.00	68.54	90.07	72.46
Valve	0	68.70	52.10	75.62	52.41	79.56	54.26
	2	67.13	51.84	77.19	52.06	85.74	57.50
	4	74.99	52.28	79.27	51.88	82.39	54.03
	6	54.68	48.50	61.45	48.46	63.31	48.94
	Average	66.37	51.18	73.38	51.20	77.75	53.68

2.2 Feature Extraction

각 Machine Type 별 특징 추출은 “.wav” 형식으로 제공된 음향 데이터를 이용해 Log Mel-spectrogram으로 진행하였다.

Mel-spectrogram은 사람의 비선형적인 음고 지각을 고려한 변형된 주파수의 멜 스케일 변환 기법이며, Log 변환은 고주파 밴드에서 저주파 밴드로 변환하는 기법이다. 두 방식을 결합한 Log Mel-spectrogram은 멜 영역의 스펙트럼에서 Log 변환을 적용함으로써 낮은 소리에 민감하고 큰 소리에 둔한 특징을 갖는다. 이를 통해 기계 소리 신호에 대한 전반적인 특징을 추출하였다. Log Mel-spectrogram을 통한 음향데이터의 특징 추출의 결과는 그림 1과 같다.

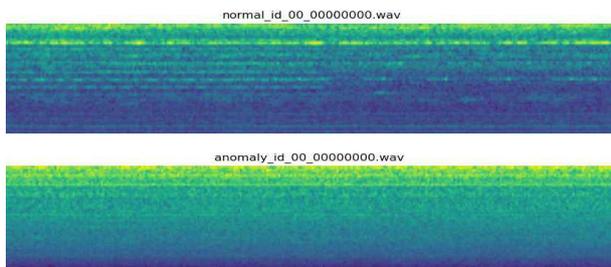


Figure 1. The example of Log Mel-spectrogram transformation

2.3 Experiments

사용 모델은 비지도 학습 기반 인공지능망 모델인 오토인코더와 이에 기반한 모델들을 사용하였다. DAE(Denoising AutoEncoder)는 기존 오토인코더 구조를 기반으로 하여 데이터 입력에 노이즈를 도입하여 이를 제거하는 방향으로 학습해 작은 변화에도 견고하고 간결한 표현을 학습할 수 있다. [4]. CAE(Convolutional AutoEncoder)는 컨볼루션 커널을 사용한 오토인코더로, 신호에 특화되어 있어 특징을 효과적으로 학습할 수 있다 [5]. 제안하는 두 모델은 데이터에 대해서 기본 오토인코더에 비해 효과적으로 고수준의 특징을 추출 가능하다. 이는 산업용 기계 데이터셋에서 의미 있는 정보를 학습하여 탐지해 낼 수 있음을 의미한다.

각 모델에 대한 성능평가는 이상 탐지에서 주로 사용되는 AUC(Area Under the ROC Curve), pAUC(Partial AUC)를 사용하여 각 ID 간의 평균을 계산하여 평가하였다. 표 2 는 특징 추출한 모델의 결과를 나타낸다. 분석 결과 Toy Car, Toy Conveyor, Fan에서는 DAE 모델, Pump는 AE 모델, Slider와 Valve는 CAE 모델에서 높은 성능을 확인하였다.

III. 결론

본 논문에서는 MIMII 데이터셋을 사용하여 각 Machine type에서 Log Mel-spectrogram을 사용해 특징을 추출한 후 비지도 학습 기반 모델들의 성능을 확인한 후 비교 분석하였다. 실험 결과 Toy Car, Toy Conveyor, Fan에서는 DAE가 높은 AUC와 pAUC를 보여 주었으며, Pump는 AE가 높은 성능을 보여 주었다. Slider와 Valve는 CAE가 높은 AUC와 pAUC를 보여 주었다.

향후 연구에서는 데이터셋 증강과 최신 특징 추출 기법 개발 및 비지도 학습 모델 개발을 통해 모든 Machine type에서 좋은 성능을 발휘하는 기법 개발 연구를 수행할 예정이다.

ACKNOWLEDGMENT

본 연구는 정부(과학기술정보통신부, 교육부)의 재원으로 한국연구재단의 지원을 받아 수행되었음 (과제번호: 2021R1A5A8033165, 2021R111A3049503)

참고 문헌

- [1] Lee, et al. Fault diagnosis of bearings using machine learning algorithm. Journal of Advanced Marine Engineering and Technology, 43(6), p. 455-462, 43.6.455, 2019
- [2] K. Miyazaki, et al. “sound processing and its applications”, IEEJ Transactions on Electrical and Electronic Engineering Volume 14, Issue 3 p. 340-351, Feb. 2023
- [3] H. Purohit, et al. “MIMII dataset: Sound dataset for malfunctioning industrial machine investigation and inspection,” arXiv preprint arXiv:1909.09347, 2019.
- [4] D. Bank, et al. “Autoencoders”, arXiv preprint, arXiv:2003.05991, Mar. 2020
- [5] S. Chen, et al. “One-dimensional convolutional auto-encoder-based feature learning for fault diagnosis of multivariate processes”, Journal of Process Control Volume 87, p. 54-67, Mar. 2020