

# 노이즈 추가와 디노이징 처리에 따른 회전 기계설비의 결함 분류 모델 성능 변화

이세훈\*, 김성수\*\*, 조비건<sup>0</sup>

\*인하공업전문대학 컴퓨터시스템공학과,

\*\* (주)KC미래기술 기술연구소,

<sup>0</sup>(주)KC미래기술 기술연구소

e-mail: seihoon@inhac.ac.kr\*, sungsoo.kim@kcfuturetech.com\*\*, bigun.cho@kcfuturetech.com<sup>0</sup>

## Performance change of defect classification model of rotating machinery according to noise addition and denoising process

Se-Hoon Lee\*, Sung-Soo Kim\*\*, Bi-gun Cho<sup>0</sup>

\*Dept. of Computer Systems & Engineering, Inha Technical College,

\*\*KC Futuretech, Inc,

<sup>0</sup>KC Futuretech, Inc

### ● 요약 ●

본 연구는 환경 요인이 통제되어 있는 실험실 데이터에 산업 현장에서 발생하는 유사 잡음을 노이즈로 추가하였을 때, SNR비에 따른 노이즈별 STFT Log Spectrogram, Mel-Spectrogram, CWT Spectrogram 총 3가지의 이미지를 생성하고, 각 이미지를 입력으로 한 CNN 결함 분류 모델의 성능 결과를 확인하였다. 원본 데이터의 영향력이 큰 0db 이상의 SNR비로 합성할 경우 원본 데이터와 분류 결과상 큰 차이가 존재하지 않았으며, 노이즈 데이터의 영향이 큰 0db 이하의 SNR비로 합성할 경우, -20db의 STFT 이미지 기준 약 26%의 성능 저하가 발생하였다. 또한, Wiener Filtering을 통한 디노이징 처리 이후, 노이즈를 효과적으로 제거하여 분류 성능의 결과가 높아지는 점을 확인하였다.

**키워드:** 디노이징(denoising), 위너필터(Wiener Filter), CNN, 이미지 변환(image conversion)

## I. Introduction

본 연구에서는 비접촉식인 소음 센서를 활용하여 공조설비의 결함 분류를 진행하였다. 또한, 본 연구에서는 실험실과 산업 현장에서 취득되는 데이터가 환경 잡음 등 노이즈의 유무로 인하여 상이하다는 점을 반영하여 실험실에서 취득한 데이터에 실제 유사 설비가 가동 중인 산업 현장에서 취득한 노이즈를 다양한 SNR비로 추가하여 현장과 유사한 데이터를 생성하였다. 세 종류의 이미지 변환 기법을 사용하여 기법별 분류 결과와 디노이징 적용 후 정확도의 상승 폭을 확인하였다.

## II. Preliminaries

### 1. Related works

#### 1.1 소음/진동 상관관계 증명

Hisako Orimoto[1]는 전기 모터로 구동되는 회전 기계에 대한 소리와 진동 데이터의 음압과 RMS 값을 통하여 정상과 이상을 분류하였고, 회전 기계 설비의 진동과 소음 간에 상관관계가 있음을 입증하였다. S Chomphan[2] 등은 자동차의 진동과 소음 데이터를 이용한 FFT Spectrum의 Peak 분석을 통해 같은 주파수에 소음과 진동 모두 주요 Peak가 발생하는 것을 통해 소음과 진동의 주요 주파수에 대한 상관성을 입증하였다.

### 1.2 소음 데이터 결합 진단

Thanh Tran[3] 등은 Mel-Spectrogram을 이용하여 정상적인 드릴 비트와 피손된 드릴비트를 분류하는 결합 분류를 진행하여, Mel-Spectrogram이 결합 분류를 진행하는데 있어 적합하다는 것을 밝혔다. Hongmei Liu[4] 외 2인은 구름 베어링의 소음 데이터를 사용하여 오토인코더 모델을 통한 결합 분류를 진행하였다. 이를 통해 소음 데이터를 이용한 결합 진단이 진동 데이터를 활용한 결합 진단 결과와 비슷하거나 능가한다는 점을 밝혔다.

## III. The Proposed Scheme

### 3.1 제안 시스템 개요

본 연구에서 제안하는 시스템은 실제 산업 현장의 환경 소음을 실험실에서 취득한 정상 및 결합 음향 데이터에 합성하여 실제 산업 현장에서 취득한 데이터와 유사한 음향 데이터를 생성하고, 생성된 데이터에 Wiener 필터링을 적용하여 디노이징을 수행한다. 이후, STFT-Spectrogram으로 이미지로 변환하여 데이터 전처리하였으며, CNN 딥러닝 모델을 통해 결합 유형을 분류하였다. CNN 모델의 각 층 활성화 함수는 ReLU 함수를 사용하였고, 최종 분류를 위한 Fully connected layer에서는 Softmax 함수를 사용하여 각 클래스에 대한 확률값을 예측하도록 하였다.

## IV. Conclusions

### 4.1 진동 데이터 CNN 분류 모델 학습 결과

데이터셋은 정상 유형과 단일 결합 유형 7가지, 복합 결합 유형 9가지로 구성된다. 진동 데이터셋은 각 클래스별로 540장의 이미지를, 소음 데이터셋은 1,000장의 이미지를 사용하였다. 이때, 전체 이미지를 학습, 검증, 테스트 용도로 7:1:2 비율로 나누어 사용하였으며, 진동 데이터에 대한 실험에서 테스트셋에 대해 Mel-Spectrogram 1.0, STFT Log-Spectrogram은 0.9994, CWT는 0.9653의 정확도를 기록하여 전반적으로 높은 성능을 낸 것으로 나타났다.

### 4.2 소음 데이터 CNN 분류 모델 학습 결과

소음 데이터는 노이즈를 추가하지 않은 경우에 대한 실험과 노이즈를 추가한 경우 7가지에 대한 실험을 진행하였다. 진행 결과는 Table .1에 정리하였다.

Table 1. 소음 데이터의 CNN 분류 모델 학습 결과

Mel Spectrogram accuracy								
	noise x	20db noise	10db noise	5db noise	0db noise	-5db noise	-10db noise	-20db noise
Train	1.0	1.0	1.0	0.9937	1.0	1.0	1.0	0.9995
Validation	1.0	1.0	1.0	1.0	1.0	0.9994	1.0	0.9912
Test	1.0	1.0	0.9994	0.9994	0.9997	0.9994	0.9985	0.9891

  

STFT Log Spectrogram accuracy								
	noise x	20db noise	10db noise	5db noise	0db noise	-5db noise	-10db noise	-20db noise
Train	1.0	1.0	1.0	0.9878	1.0	0.9970	0.9999	0.9968
Validation	1.0	0.9994	0.9977	1.0	0.9988	0.9988	0.9971	0.7324
Test	0.9991	0.9974	0.9985	0.9988	0.9976	0.9968	0.9959	0.7179

  

CWT accuracy								
	noise x	20db noise	10db noise	5db noise	0db noise	-5db noise	-10db noise	-20db noise
Train	0.9971	0.9922	0.9980	0.9924	0.9771	0.9319	0.8224	0.1805
Validation	0.9729	0.9724	0.9647	0.9294	0.8347	0.8265	0.6659	0.0706
Test	0.9726	0.9744	0.9685	0.9247	0.8371	0.8159	0.6544	0.0574

Table 2. -20db Noise 합성 소음 데이터의 Wiener filter 적용 전/후 CNN 분류 모델 학습 결과

	Mel Spectrogram (-20db noise)			STFT Log Spectrogram (-20db noise)	
	Wiener filter 적용 전	Wiener filter 적용 후		Wiener filter 적용 전	Wiener filter 적용 후
Train	0.9995	0.9939	Train	0.9968	0.9952
Validation	0.9912	0.6341	Validation	0.7324	0.8741
Test	0.9891	0.6171	Test	0.7179	0.8642

  

	CWT (-20db noise)	
	Wiener filter 적용 전	Wiener filter 적용 후
Train	0.1805	0.1524
Validation	0.0706	0.08
Test	0.0574	0.0579

Table 2.은 노이즈의 비중이 가장 큰 -20db 노이즈가 추가된 소음 데이터에 Wiener Filter를 적용하기 전과 후의 모델 학습 결과를 비교한 것이다. 노이즈에 가장 견고한 것으로 나타났던 Mel-Spectrogram의 경우 테스트 정확도가 0.9891에서 0.6171로 오히려 감소한 것으로 나타났다. -20db에서 0.7179의 테스트 정확도를 기록하였던 STFT Log-Spectrogram은 Wiener Filter 적용 이후 0.8642로 성능이 향상되었다. 노이즈의 영향을 가장 많이 받는 것으로 확인된 CWT는 Wiener Filter 적용 시에도 기존 정확도와 크게 다르지 않은 성능을 기록하였다.

## REFERENCES

- [1] Orimoto, H. (2016). Statistical Fault Diagnosis Methods by Using Higher-Order Correlation Information between Sound and Vibration. *Intelligent Information Management*, 8(4), 87-97.
- [2] Chomphan, S., & Wongchai, B. (2020). Correlation Analysis Of Vibration And Sound Signals Of A Gasoline-Engine Car. *GEOMATE Journal*, 18(67), 195-201.
- [3] Tran, T., & Lundgren, J. (2020). Drill fault diagnosis based on the scalogram and mel spectrogram of sound signals using artificial intelligence. *IEEE Access*, 8, 203655-203666.
- [4] Liu, H., Li, L., & Ma, J. (2016). Rolling bearing fault diagnosis based on STFT-deep learning and sound signals. *Shock and Vibration*, 2016.