

Deep Learning-Based Rotary Machine Speed Estimation System

딥러닝 기반의 회전기계 속도 추정 시스템

Yu-Jin Lee¹, Sung-Bock Lee², Sun-Il Kim³, Jang-Woo Kwon⁴

이유진¹, 이상복², 김선일³, 권장우⁴

¹ Senior Research Engineer, KC Future Technology Co., Ltd., Korea, yjlee@kcfuturetech.com

² Team Leader, Incheon Transit Corporation, Korea, leesbock@ictr.or.kr

³ General Manager, Incheon Transit Corporation, Korea, kimsunil@ictr.or.kr

⁴ Professor, Computer Engineering, Inha University, Korea, jwkwon@inha.ac.kr

Corresponding author: Jang-Woo Kwon

Abstract: Methods for estimating the rotational speed of equipment include a method using a rotation meter, a method using a vibration signal, and a method using a current signal. The rotation system is affected by the installation location and environment, and the method using the current signal presents difficulties in sensor installation and maintenance. The method using the existing vibration signal requires an expert to define the range of rotation speed, and it is difficult to apply it to industrial sites due to the large amount of computation. In this paper, we train a CNN model that classifies the rotational speed range using STFT images. After that, a rotational speed estimation system capable of detecting periodic signals using an autocorrelation function and operating in an edge device is proposed. The data used in the study was collected from air conditioning facilities, and the performance evaluation of the model and the estimated rotation speed of the digital tachometer and the system were compared and analyzed to evaluate the system performance. Through this study, it was confirmed that the proposed system estimates the rotational speed with high accuracy and can be applied to industrial sites. As a future study, it is necessary to improve the system function so that the rotational speed can be estimated without a specific speed range.

Keywords: Rotational Machinery, Rotational Speed Estimation, Short-time Fourier Transform, Convolutional Neural Network, Auto Correlation Function

요약: 설비의 회전속도를 추정하는 방법은 회전계를 사용하는 방법과 진동 신호를 이용하는 방법 및 전류 신호를 이용한 방법이 존재한다. 회전계는 설치 위치와 환경에 영향을 받으며 전류 신호를 이용하는 방법은 센서 설치 및 유지보수에 어려움이 존재한다. 기존의 진동 신호를 이용하는 방법은 회전속도의 범위를 전문가가 정의해야 하며 연산량이 많아 산업현장에 적용하기 어렵다. 본 논문에서는 STFT 이미지를 사용하여 회전속도의 범위를 분류하는 CNN 모델을 학습시킨다. 그 후 자기상관함수를 이용하여 주기적 신호를 검출하고 엣지 디바이스에서 동작이 가능한 회전속도 추정 시스템을 제안한다. 연구에 사용된 데이터는 공기조화설비에서 수집하였으며 시스템의 성능 평가를 위해 모델의 성능평가 및 디지털 타코미터와 시스템의 추정 회전속도를 비교 분석하였다. 본 연구를 통해 제안한 시스템이

Received: February 14, 2023; 1st Review Result: March 30, 2023; 2nd Review Result: April 27, 2023
Accepted: May 31, 2023

회전속도를 높은 정확도로 추정하며 산업현장에 적용 가능하다는 것을 확인하였다. 향후 연구로 특정한 속도 범위가 없어도 회전속도를 추정할 수 있도록 시스템 기능을 개선이 필요하다.

핵심어: 회전기계설비, 회전속도 추정, 단시간 푸리에 변환, 합성곱 신경망, 자기상관함수

1. 서론

산업현장에서는 회전기계설비의 결함 발생으로 인한 사고를 막기 위해 결함이 발생하기 전 설비의 상태를 주기적으로 점검하고 보수하는 설비보전 기술이 발전해왔다[1]. 최근에는 IoT(Internet of Things) 기술을 응용하여 다양한 센서를 사용한 기계설비의 상태 모니터링을 수행하는 기술이 산업현장에 사용되고 있으며 주요한 기술 중 하나로 진동 분석이 응용되고 있다[2]. 진동 분석은 설비에서 발생하는 진동 데이터를 주파수 스펙트럼으로 변환하고 결함주파수 차수분석(Order Analysis)을 수행하여 기계적 결함을 진단하는 기술이다. 결함주파수 차수분석은 분석 대상이 되는 설비의 진동 주파수 스펙트럼에서 결함주파수의 피크(peak) 존재여부와 진폭의 크기를 이용하여 수행한다[3].

차수분석을 위한 결함주파수는 기계적 사양과 해당 설비의 축 회전속도에 따라 정해진다. 기계적 사양은 회전설비가 설계될 때 정해지는 고정값이며 축 회전속도는 산업현장의 환경과 운영에 따라 변경된다. 기계설비의 진동 분석을 수행하기 위해서는 변경되는 회전속도 값을 측정하는 방법이 필요하다.

축 회전속도를 측정하는 방법으로는 설비의 회전축에 회전계를 설치하는 방법과 진동 신호를 이용하여 회전속도를 추정하는 방법이 존재한다. 회전계 설치 방법은 회전계의 회전축 주변에 회전계가 설치되어야 하므로 설치 위치와 공간에 제약이 많은 문제점이 있다. 진동 신호를 이용한 회전속도 추정 방법은 기존의 신호처리 방법과 통계적인 접근 방식 또는 딥러닝을 동시에 사용하여 구현된다. 이 방법은 회전속도가 존재할 수 있는 주파수 범위를 정의해야 한다. 또한 잘못된 범위를 정의할 경우, 회전속도의 추정 정확도가 떨어지거나 회전속도로 추정하지 못하는 문제가 발생하고 연산량이 많아 산업현장에 적용이 어렵다.

본 논문에서는 산업현장에서 사용할 수 있는 회전기계설비의 축 회전속도 추정 시스템을 제안한다. 제안하는 시스템은 산업현장에 설치하는 옛지 디바이스에서 설비에서 발생하는 진동 신호 STFT(Short Time Fourier Transform) 이미지를 이용한다. 수집된 진동 신호 데이터를 사전에 학습된 CNN(Convolutional Neural Network) 회전속도 분류모델로 회전속도 주파수 범위를 분류한다. 분류된 범위 내에서 자기상관함수(Auto correlation function, ACF)로 잡음(Noise) 제거 및 범위 내의 가장 지배적인 주파수 성분을 추정하여 회전속도 주파수를 구한다. 기존의 회전속도를 추정하는 방법 중에서 회전계 설치 방법은 설치 위치 확보가 어려운 문제점이 있다. 회전계 외의 다른 방법 중 진동 신호를 이용하는 방법은 전문가가 지정한 속도 범위가 필요하며 많은 연산량으로 인한 현장 적용의 어려움과 같은 문제점이 있다. 이를 개선하고 현장에 적용함으로써 환경 및 운영에 의한 가변적 회전속도를 가지는 설비의 진동 분석 문제점을 해결하는 방안으로 사용할 수 있다.

2. 회전 기계 속도 추정 관련 연구

기존의 회전계를 통해 설비의 회전속도를 추정하는 방법과 진동 신호를 이용한 회전속도 추정 방법에 대한 연구에 대해서 알아본다.

2.1 회전계를 이용한 회전속도 추정 방법

산업현장에서는 회전기계설비의 회전속도를 측정하기 위해서 엔코더(Encoder) 또는 타코미터(Tachometer)와 같은 회전계를 사용한다. 엔코더의 설치에 추가적인 유지보수와 설치 비용이 발생하기 때문에 대부분의 산업현장 설비는 발전소와 같이 정밀한 회전속도를 측정할 필요가 없어 엔코더가 설치되어 있지 않다.

그 외의 방법으로는 휴대용 디지털 타코미터로 측정하는 방법과 전동기에 인가되는 전원주파수를 이용하는 두 가지 방법이 있다. 디지털 타코미터는 센서부가 회전축에 근접하게 설치되어야 하므로 산업현장의 설비 방호장치로 인해 위치 및 공간을 확보하기 어려워 사용이 어렵다. 전동기의 극 수(P)와 설비에 인가되는 전원주파수(F_L)로 회전속도(RPM)를 추정하는 방법은 정의된 식 (1)에 의해 구할 수 있다[3].

$$RPM = \frac{120 \times F_L}{P} \quad (1)$$

식 (1)에 의해 산출된 회전속도는 전동기의 슬립율과 설비의 부하량이 고려되지 않은 회전속도이므로 설비 운행 속도와 오차가 발생할 수 있다.

2.2 센서 데이터를 이용한 회전속도 추정 방법

회전계를 설비에 설치하지 않고 기존의 설비 모니터링을 위해 설치한 센서만을 이용하여 설비에서 수집된 신호에 신호처리 및 통계적인 방법과 딥러닝을 적용한 회전속도를 추정하는 방법이 연구되었다[4-9].

2.2.1 위상 복조

위상 복조(Phase Demodulation) 방법은 회전속도가 임의의 신호에 의하여 위상 변조된 신호라고 가정하고, 진동 신호를 사용하여 속도를 추정한다[4]. 이 방법은 산업현장의 기계설비의 경우 복잡한 회전 구조로 되어 있고 이상적인 부하 상태를 가지고 있지 않기 때문에 노이즈로 인해 고조파 성분이 감소되어 사라질 수 있어 현장에 적용하기 어렵다.

2.2.2 다차 확률론적 접근

다차 확률론적 접근(Multi-order probabilistic approach, MOPA)은 속도 추정을 위해 신호에서 하나 이상의 고조파를 활용하는 기술이다[5]. MOPA 접근 방식은 진동 신호에서 회전속도가 존재할 수 있는 범위를 정해야만 정확도가 높은 결과를 받을 수 있다. 또한 모든 고조파의 정보를 사용하여 확률 밀도 함수의 예상값을 계산하므로 결과를 도출하기 위하여 많은 연산이 필요하기 때문에 산업현장에 적용하기에 어려움이 존재한다.

2.2.3 Cepstrum 기반 방식

Cepstrum 기반 방식은 Cepstrum을 이용하여 속도의 초기 추정치를 찾고 가변 차단

주파수(Cut-off frequencies)를 사용하여 맞물림 주파수 주변의 신호를 대역 통과 필터링한다. 다음으로, 분석 신호를 사용하여 속도를 추정한다[6]. 이 방법은 고조파 주변의 주파수 노이즈에 따라 성능이 크게 차이가 난다. 고조파 주변에 노이즈 레벨이 높을 경우, 정확한 회전 주기 추정이 어려워 회전주파수를 찾는 정확도가 떨어질 수 있다.

2.2.4 BLSTM을 이용한 방법

MMO-BLSTM 모델 구조는 BLSTM과 LSTM으로 구성된다. BLSTM은 순방향 및 역방향 시간의 진동 신호에서 속도 관련 정보를 학습한다. LSTM은 BLSTM에서 학습한 정보에서 순방향으로 예상 속도를 추출한다[7]. MMO-BLSTM 방법은 노이즈가 많은 신호에서 정확도가 떨어지기 때문에 산업현장의 복잡한 구조를 가진 기계설비의 회전속도 추정이 어렵다. 또한 BLSTM 모델의 특징인 양방향 모델 구조로 인해 데이터의 처리량이 많아 옛지 디바이스에 적용하기 어려움이 있다.

2.2.5 전류를 이용한 속도 추정 방법

전류 기반의 속도 추정 방법으로는 임펠러의 결함을 탐지하기 위하여 전류 데이터를 수집하고 주파수 분석 기반의 회전속도 추정 방법을 사용한다[8]. 터빈 발전기 시스템의 베어링 및 커플링 정렬불량을 탐지하기 위하여 주파수 분석 기반의 회전속도 추정 방법을 사용한다[9]. 전류 신호를 이용하여 속도를 추정하는 방법은 정확도가 높으나 센서의 설치 및 유지보수 시 전류 분야의 전문가가 필요하고 안전사고의 위험이 많아 현장 적용에 어려움이 있다.

3. 딥러닝 기반의 진동 신호 기반 회전기계 속도 추정 시스템

제안하는 시스템은 회전기계설비 중에서 공기조화설비를 대상으로 연구를 진행하였다. 공기조화설비는 운행 중에 사용자의 조작이나 외부요인이 존재하지 않는 경우 등속도를 유지한다. 기존의 현장에 적용하기 힘든 연구 방법[4-9]들의 문제점을 개선하고 산업현장에 적용하기 위해 최근의 산업 동향에 맞춰 옛지 디바이스에서 CNN을 이용한 회전속도를 추정할 수 있는 시스템을 제안한다.

3.1 제안 시스템 개요

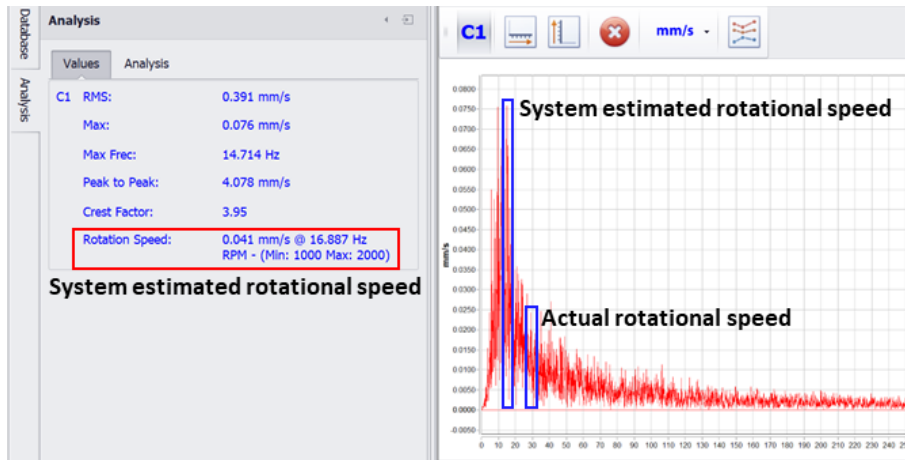


[그림 1] 시스템 장치 구성

[Fig. 1] System Device Configuration

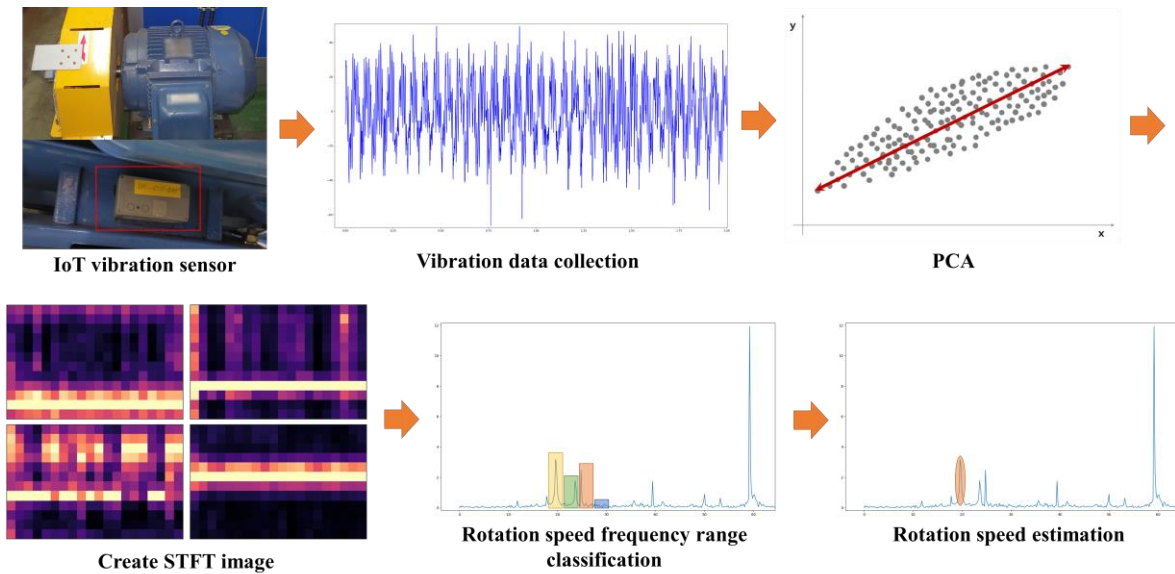
회전속도 추정 시스템의 장비 구성은 [그림 1]과 같다. 3축 가속도 진동 센서에서 수집된 진동 신호를 엷지 디바이스인 게이트웨이로 전송한다. 게이트웨이에서는 회전속도 추정 프로세스에 따라 회전속도를 추정하고 이를 서버로 전송한다.

게이트웨이는 Jetson Nano를 컴퓨터 보드로 사용하고 무선 통신을 지원하며 회전속도 추정 프로세스는 엷지 환경에서 연구를 진행하였다. 전문가는 기계설비의 상태 분석을 위하여 기계의 회전속도 정보를 알고 있어야 한다. 산업현장에는 [그림 2]와 같이 전문가가 회전속도 정보를 알고 있지 않아도 주파수 파형 분석을 원활하게 할 수 있도록 신호 파형에서 회전속도를 추정하는 기능을 제공하는 시스템이 있다. 그러나 해당 시스템은 주파수 파형에서 진폭이 가장 높은 주성분을 회전속도로 제공하는 것으로서 실용성이 높지 않고 결함 설비의 경우 정확도도 높지 않다.



[그림 2] 일반적인 회전 속도 추정을 위한 UI 시스템

[Fig. 2] UI for Estimating General Rotation Speed System



[그림 3] 회전 속도 추정 프로세스

[Fig. 3] Rotation Speed Estimation Process


제안하는 시스템은 회전속도 추정에 관련된 기존 연구의 문제점을 개선하고 주성분에 의한 분석의 오류를 개선하기 위해 기존의 전문가가 선정하던 회전속도의 범위를 CNN을 통해 분류한다. 이후에는 단위별 범위에서 주성분 신호가 있는 주파수 파형을 통해 신호처리 방법을 응용하여 회전주파수를 추정한다. 이를 통해 회전속도 추정을 자동화하여 설비 결함 진단 시스템으로 확장할 수 있다.

회전속도 추정 프로세스는 [그림 3]과 같다. 수집된 3축 진동 신호 데이터를 PCA를 사용하여 하나의 주성분 신호로 생성한다. 이 신호를 STFT 이미지로 변환한 후 사전에 학습이 완료된 CNN 모델을 이용하여 회전속도 주파수 범위를 분류한다. 이후 ACF를 이용하여 분류된 범위 내의 주파수 중에서 회전주파수를 추정한다.

3.2 회전속도 추정 프로세스

3.2.1 PCA 및 STFT 이미지 생성

시스템에 사용되는 진동 신호 데이터는 동일한 진동이 위상만 다르게 측정된 세 개의 축, 반경, 수직 방향의 세 개의 데이터므로 서로 비슷한 특성(Feature)을 가진다. 세 개의 데이터의 비슷한 특성을 하나의 특징 신호로 생성하기 위해 PCA를 사용하였다. PCA는 고차원의 데이터를 저차원 데이터로 변환하며 기존의 변수를 조합하여 새로운 변수를 만드는 변수 추출(Feature extraction) 기법이다[10]. PCA를 통해 만들어진 새로운 값은 각 축의 비슷한 특성인 회전속도의 특성을 하나의 새로운 주성분 신호로 생성하고 이 신호의 회전주파수 성분을 분석하기 위해 시간 및 주파수 특징을 동시에 확인할 수 있는 STFT 이미지로 변환한다. [그림 4]는 진동 신호를 이미지로 변환하는 과정을 나타낸다.



[그림 4] 신호의 PCA 및 STFT 변환

[Fig. 4] PCA and STFT Conversion of Signals

STFT는 일반적으로 모든 주파수에 대한 주파수 분해능을 가지며 고조파 분석에 적합한 특징을 가진다[11]. 회전속도는 기본 회전주파수와 그 고조파 성분이 주파수로 나타나기 때문에 고조파 분석에 유리한 STFT를 이용하여 신호 분석을 수행하였다. 또한 STFT는 CNN을 사용하기 위한 이미지 신호 전처리 방법 중 연산량이 적어 엣지 디바이스에 적용하는데 이점이 있다[12].

3.2.2 회전속도 주파수 범위 분류 모델

CNN은 주로 시각적 이미지 처리를 위해 최적화된 인공신경망 구조이며 전체 이미지를 작은 단위로 나누고 각 부분을 분석한다. CNN은 합성곱 연산을 이용하는데 이는 신호처리와 같은 특징 추출을 위한 연구에 응용된다. 기계설비 모니터링 분야에서는 시간-주파수 파형을 이용한 CNN 모델이 기계 결함 진단을 위한 방법으로 많이 사용된다.

기계설비의 기어박스 결함 분류를 위하여 웨이블릿 변환 기반의 컨볼루션 신경망을 사용[13]하거나 회전자 결함 진단을 위한 CNN 기반 전이 학습에 관한 연구[14], 베어링 결함 진단을 위해 심층 합성곱 신경망과 S-변환을 이용[15] 또는 전동기의 고장진단을 위해서 CNN 기반의 데이터의 다중 입력 방식을 사용[16]하는 것과 같이 전동기에서 중요한 구성요소의 진동 신호를 통해 결함 및 열화 정도를 분류하기 위하여 많은 연구가 진행되고 있다. 따라서 본 논문에서는 회전속도와 같이 전동기에서 발생하는 주요 주파수 성분 분석에 사용되는 CNN 모델을 사용하여 회전속도 범위 분류 모델을 생성한다.

제안하는 시스템에서 사용하는 CNN 모델은 4개의 클래스로 회전속도를 분류한다. 학습데이터는 I사 공조실에 설치되어 있는 각각 사양이 다른 3개의 공기조화설비의 인버터에서 설정할 수 있는 전원주파수(F_L)와 4개의 클래스를 [표 1]과 같이 정의하였다.

[표 1] 회전 속도별 학습 데이터

[Table 1] Learning Data by Rotation Speed

| F_L (Hz) | RPM(rpm) | RPM label |
|------------|----------|------------------------------|
| 45.0 | 1350 | $1320 \leq \alpha < 1425$ |
| 46.7 | 1400 | |
| 50.0 | 1500 | $1425 \leq \alpha < 1575$ |
| 52.0 | 1560 | |
| 52.7 | 1580 | $1575 \leq \alpha < 1686$ |
| 55.0 | 1650 | |
| 56.7 | 1700 | $1686 \leq \alpha \leq 1800$ |
| 60.0 | 1800 | |



[그림 5] 실험실 테스트 장비

[Fig. 5] Laboratory Test Equipment

현장 인버터는 시스템에서 최소 45.0Hz, 최대 60.0Hz의 설정값으로 범위가 고정되어 있으며 5.0Hz의 간격으로 변경이 가능하다. 여기에 다양한 속도의 진동 데이터를 취득하기 위하여 [그림 5]와 같이 실험실의 테스트 설비에서 취득한 진동 데이터를 포함하여 데이터 셋을 구성하였다.

제안하는 CNN 구조는 4개의 컨볼루션 층과 풀링 층으로 구성되어 있으며 각 층의 활성화 함수로는 ReLU 함수를 사용하였다. 최종 분류를 위한 Dense Layer에서는 Softmax 함수를 사용하여 입력에 사용된 4개의 클래스에 대한 확률값을 도출하였다. 각 층의 연산이 완료될 때마다 dropout을 사용하여 과적합을 제어하였다. CNN 모델의 구조 및 세부 Layer와 하이퍼 파라미터의 값은 [표 2]와 같다.

[표 2] 회전속도 범위 분류 CNN 모델의 구조

[Table 2] Structure of Rotation Speed Range Classification CNN Model

| Layer (type) | Output Shape | Parameter |
|------------------------------|----------------------|-----------|
| conv2d (Conv2D) | (None, 220, 338, 32) | 896 |
| max_pooling2d (MaxPooling2D) | (None, 73, 112, 32) | 0 |
| dropout (Dropout) | (None, 73, 112, 32) | 0 |
| conv2d (Conv2D) | (None, 73, 112, 64) | 18,496 |
| max_pooling2d (MaxPooling2D) | (None, 24, 37, 64) | 0 |
| dropout (Dropout) | (None, 24, 37, 64) | 0 |
| conv2d (Conv2D) | (None, 24, 37, 64) | 36,928 |
| max_pooling2d (MaxPooling2D) | (None, 8, 12, 64) | 0 |
| dropout (Dropout) | (None, 8, 12, 64) | 0 |
| conv2d (Conv2D) | (None, 2, 4, 64) | 36,928 |
| max_pooling2d (MaxPooling2D) | (None, 2, 4, 64) | 0 |
| dropout (Dropout) | (None, 2, 4, 64) | 0 |
| flatten (Flatten) | (None, 521) | 0 |
| dense (Dense) | (None, 256) | 131,328 |
| dense (Dense) | (None, 4) | 1,028 |

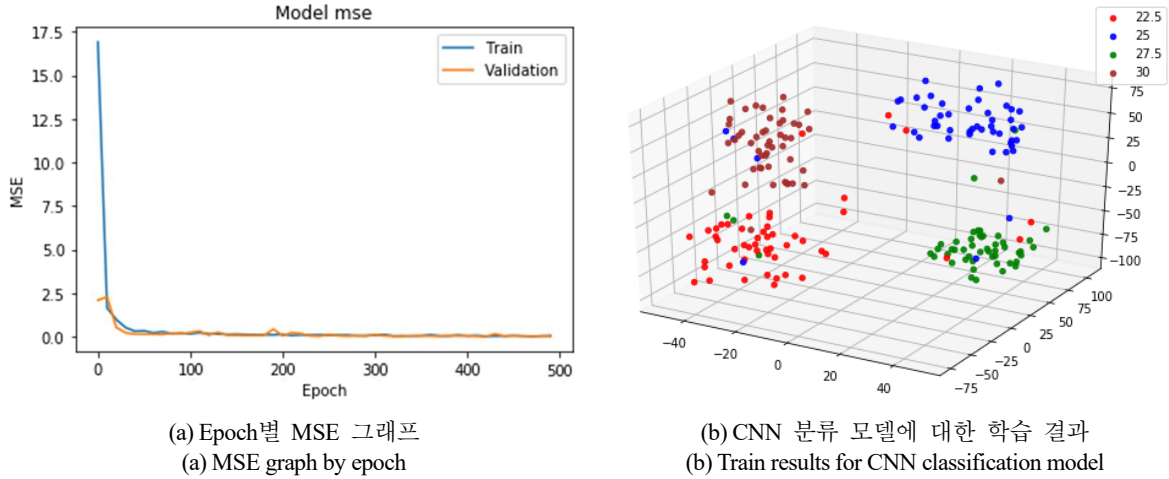
입력 데이터는 (220, 338, 32)의 픽셀 크기를 가지는 STFT 이미지를 사용하였고 학습할 때 사용한 초기 파라미터는 Batch size = 6, Epoch 횟수는 100회, Optimizer = Adam, loss = ‘sparse categorical cross entropy’를 사용하였다.

각 회전속도(RPM) 별로 진동 데이터를 5초간 1회씩 2,160회를 수집하였다. 회전속도별 데이터의 부족으로 인해 딥러닝 모델을 생성할 때 데이터 셋의 특징을 반영하지 못하거나 과소적합 및 과대적합을 방지하기 위하여 데이터 증강(Data Augmentation)을 수행하였다[17]. 데이터 증강 방법으로 Raw 데이터에 가우시안 노이즈(Gaussian noise)를 더하여 1차 증강을 수행하였다. 2차 증강은 STFT 이미지로 변환한 데이터에 Cycle GAN(Generative Adversarial Networks)을 사용하여 수행하였다. 이를 통하여 실제 측정된 데이터와 유사한 데이터를 생성함으로써 데이터의 다양성을 확보하였다[18].

데이터 증강을 통해 진동 데이터는 86,400개로 각 회전속도 라벨당 21,600개의 데이터 셋을 생성하였다. 학습 데이터 셋으로는 전체 데이터 중 69,120개의 데이터를 사용하였다. 검증 데이터 셋으로 전체 데이터 중 17,280개의 데이터를 사용하였다.

[그림 6]의 (a)는 모델의 학습을 수행한 결과를 나타내며 Epoch 별 MSE 값은 Epoch가

약 80회 이후로 0.1 이하를 유지하면서 값의 변화가 거의 없음을 확인하였다. [그림 6]의 (b)는 CNN 분류 모델의 Train 결과를 나타내며 데이터 셋이 4개의 회전속도 라벨별로 모여있는 것을 확인할 수 있다.



[그림 6] 모델 학습 및 결과

[Fig. 6] Model Learning and Results

[표 3]은 CNN 분류 모델의 Test 결과를 나타낸다. 각 회전속도 별로 precision, recall, f1-score가 약 90% 이상인 것을 확인하였으며 CNN 분류 모델 학습 결과의 Accuracy가 93%인 것을 확인하였다.

[표 3] CNN 분류 모델 테스트 결과

[Table 3] CNN Classification Model Test Results

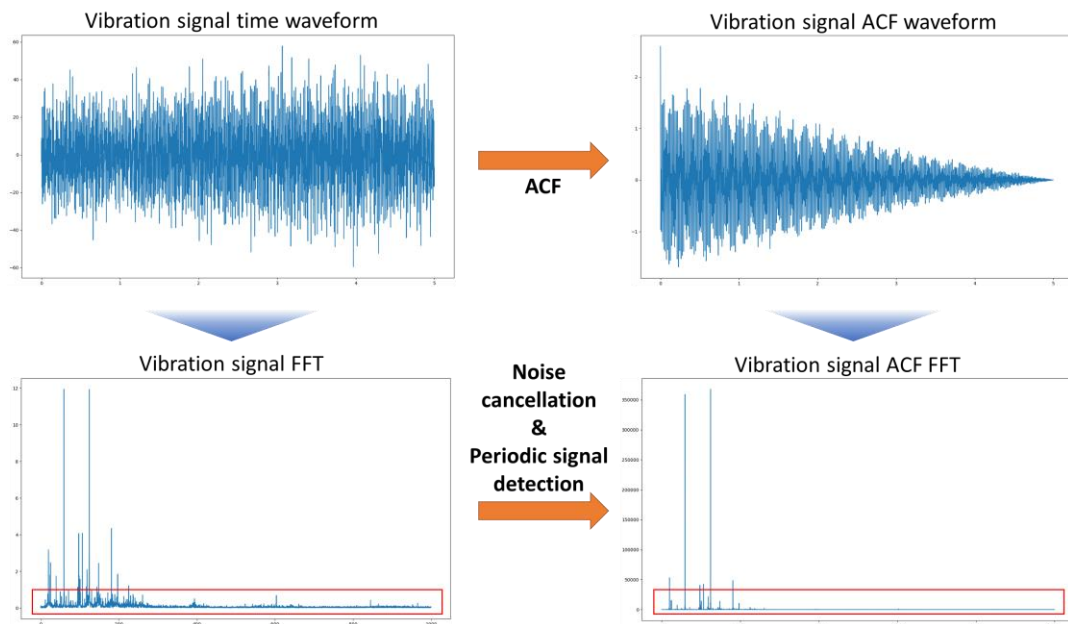
| Label | Precision | Recall | F1-score |
|------------------------------|-----------|--------|----------|
| $1320 \leq \alpha < 1425$ | 0.91 | 0.93 | 0.92 |
| $1425 \leq \alpha < 1575$ | 0.96 | 0.92 | 0.94 |
| $1575 \leq \alpha < 1686$ | 0.94 | 0.95 | 0.94 |
| $1686 \leq \alpha \leq 1800$ | 0.93 | 0.92 | 0.92 |

3.2.3 회전속도 추정 방법

CNN 모델을 통하여 분류된 회전속도 범위 내에서 정확한 회전속도를 추정을 수행한다. 진동 신호의 주파수 성분들에는 회전기계의 회전 주기에 따른 주파수 신호와 잡음(Noise)이 혼재되어 있기 때문에 회전 주기에 따른 주파수 신호만 추출할 필요가 있다.

[그림 7]은 Raw FFT 파형과 ACF를 이용하여 잡음 제거 및 주기 신호 특징을 추출하였을 때의 파형을 나타낸다. ACF는 어떠한 성분이 신호에서 지속적으로 유지되는지 파악할 수 있기 때문에 진동 신호에 ACF를 적용하고 진폭이 높은 주파수 성분을 추출함으로써 잡음을 제거하고 회전속도 및 회전 주기에 따른 주파수 신호만을 추출할 수 있다[19]. CNN 모델로 분류된 회전속도 범위와 ACF로 추출된 주파수 성분을

이용하여 회전속도 범위 내에 지배적인 주파수 성분이 존재하는지 확인하고 최종적인 회전속도 추정을 수행한다.



[그림 7] 잡음 제거 및 주기적인 신호 감지

[Fig. 7] Noise Cancellation and Periodic Signal Detection

4. 실험 및 성능평가

4.1 실험 환경 및 데이터

실험 환경은 [그림 8]과 같이 인버터의 전원주파수(F_L) 값 설정이 자유로운 산업현장의 공기조화설비의 전동기를 선정하여 진동 데이터를 수집한다.



[그림 8] 시스템 실험을 위한 시설 환경

[Fig. 8] Facility Environment for System Experiments

실험 데이터는 [표 4]와 같이 14가지의 회전속도를 정의하고 데이터를 수집하였다.

[표 4] 실험 데이터 정의

[Table 4] Define Experimental Data

| # | $F_L(\text{Hz})$ | $RPM(\text{rpm})$ | # | $F_L(\text{Hz})$ | $RPM(\text{rpm})$ |
|---|------------------|-------------------|----|------------------|-------------------|
| 1 | 44.0 | 1320 | 8 | 52.5 | 1575 |
| 2 | 45.0 | 1350 | 9 | 53.7 | 1611 |
| 3 | 46.2 | 1386 | 10 | 55.0 | 1650 |
| 4 | 47.5 | 1425 | 11 | 56.2 | 1686 |
| 5 | 48.7 | 1461 | 12 | 57.5 | 1725 |
| 6 | 50.0 | 1500 | 13 | 58.7 | 1761 |
| 7 | 51.2 | 1536 | 14 | 60.0 | 1800 |

4.2 시스템 성능평가 결과

시스템 성능평가를 위한 분류에 사용된 데이터의 라벨은 [표 4]에 정의된 14가지의 회전속도이며 데이터의 총 개수는 3,696개를 사용하였다. 회전속도 범위 라벨은 Case 1이 1,320rpm 이상 1,425rpm 미만, Case 2가 1,425rpm 이상 1,575rpm 미만, Case 3이 1,575rpm 이상 1,686rpm 미만, Case 4가 1,686rpm 이상 1,800rpm 이하로 정의하였다. 또한 각 Case의 회전속도 사잇값은 Case 1의 경우 [표 4]의 #1부터 #3까지, Case 2의 경우 [표 4]의 #4부터 #7까지, Case 3의 경우 [표 4]의 #8부터 #10까지, Case 4의 경우 [표 4]의 #11부터 #14까지로 정의하였다. 라벨에 의해서 Case 1과 Case 4의 데이터 개수는 792개, Case 2와 Case 3의 데이터 개수는 1,056개로 각각 전체 데이터의 21.43%, 28.57%를 차지한다.

[표 5]는 CNN 모델에서의 회전속도 범위의 분류 결과를 나타낸다. 분류 결과를 살펴보면 Case 2과 Case 4는 90% 이상의 f1-score를 보여주고 Case 1과 Case 3은 82%와 78%로 Case 2와 Case 4에 비해 분류 성능이 좋지 않으나 전체 Accuracy는 88%의 성능을 보이므로 기준에 4가지의 회전속도로 학습시킨 CNN 모델이 그 회전속도의 사잇값도 정해진 회전속도 범위로 분류가 가능한 것을 확인하였다.

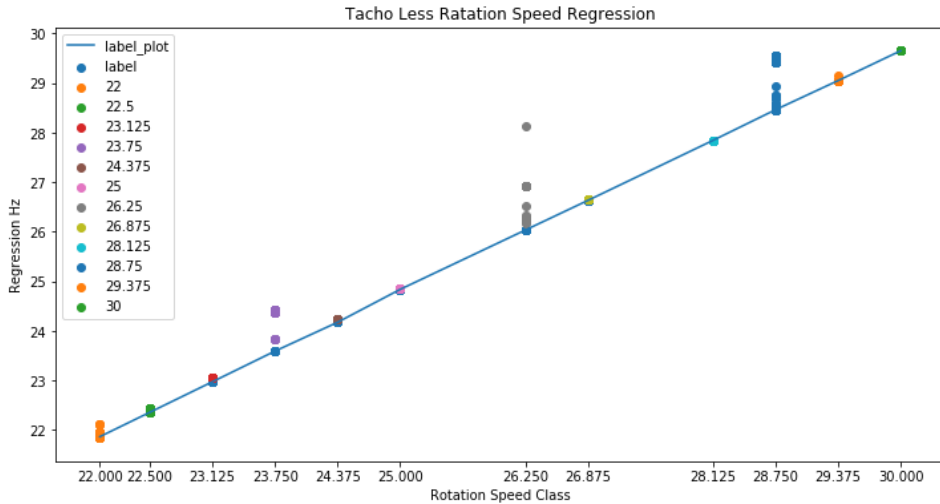
[표 5] CNN 모델의 분류 결과

[Table 5] Classification Results of CNN Models

| Case | Label | Precision | Recall | F1-score |
|------|------------------------------|-----------|--------|----------|
| 1 | $1320 \leq \alpha < 1425$ | 0.74 | 0.93 | 0.82 |
| 2 | $1425 \leq \alpha < 1575$ | 0.99 | 0.85 | 0.91 |
| 3 | $1575 \leq \alpha < 1686$ | 0.81 | 0.75 | 0.78 |
| 4 | $1686 \leq \alpha \leq 1800$ | 0.98 | 1.00 | 0.99 |

[그림 9]는 CNN 분류 결과를 ACF를 이용하여 회전속도를 추정한 결과의 성능 평가 결과를 R2 Score 그래프로 나타낸다. x축은 추정할 회전속도의 라벨을 나타내며 y축은 회전속도 추정 시스템이 추정한 결과를 나타낸다.

CNN 모델에서 성공적으로 회전속도 범위가 분류된 데이터는 전체 데이터의 98.45%이다. 회전속도 범위 내의 지배적인 속도가 2개 이상 존재하여 속도를 추정하지 못한 데이터는 전체 데이터의 1.55%를 차지한다. 따라서 회전속도를 추정하는 시스템의 R2 score는 94%인 것을 확인하였다.






[그림 9] 회전속도 추정 시스템의 성능 평가 결과

[Fig. 9] Performance Evaluation Results of Rotation Speed Estimation System

또한 실제 산업현장에서 사용되는 디지털 타코미터와 비교하여 시스템의 정확도를 확인하였다. [표 6]은 타코미터 측정값과 시스템에서 추정한 회전속도의 비교 오차를 나타낸다. [표 6]의 비교 오차는 전동기 회전축의 초당 회전수가 약 0.1회 이하의 오차를 가진다는 의미이며, 시스템이 회전계와 비교하였을 때 정확한 회전속도 추정을 수행하는 것을 확인하였다.

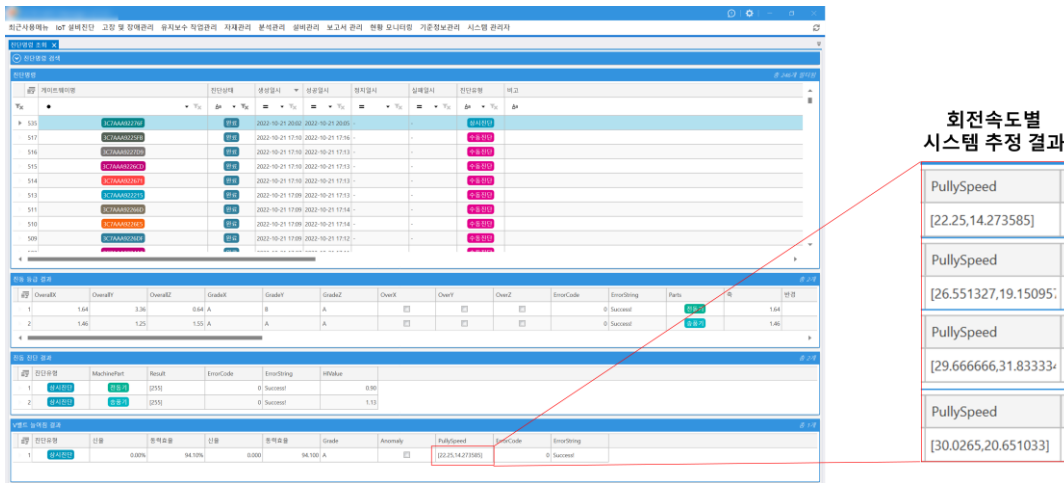
[표 6] 타코미터와 시스템 추정 회전 속도의 비교

[Table 6] Comparison of Tachometer and System Estimated Rotational Speed

| Tachometer | System estimated rotation speed | Comparative error |
|---|--|---------------------|
|  | PullySpeed [22.25,14.273585] 1335rpm | 6.4rpm (0.106Hz) |
|  | PullySpeed [26.551327,19.15095] 1593rpm | 4.9rpm (0.082Hz) |
|  | PullySpeed [29.666666,31.833333] 1779rpm | 0.2rpm (0.003Hz) |

이 결과를 바탕으로 개발된 시스템은 I사의 산업현장에서 운영되는 237대의 공기조화설비에 적용하였으며 결과를 개발한 시스템의 UI에서 확인하였다. 확인한 결과,

적용 대상 공기조화설비의 회전속도 추정 결과는 237대 중 215대인 90.72%의 공기조화설비 회전속도를 정확하게 추정한 것을 확인할 수 있었다. [그림 10]은 본 논문에서 개발된 시스템의 회전속도 추정 UI이다.



[그림 10] 시스템의 회전속도 추정 UI

[Fig. 10] System Rotational Speed Estimation UI

5. 결론

본 논문에서는 회전기계설비의 회전속도 추정 시스템의 설계와 실험을 통하여 시스템의 정확도를 검증하였으며, 이를 실제 산업현장에 적용하고 설비에서 수집된 진동 데이터만을 이용하여 해당 회전기계의 속도를 추정하는 시스템을 구현하였다. 기존의 통계적 방식과 딥러닝을 이용한 회전속도 추정 방법은 노이즈가 섞인 진동 신호와 복잡한 구조를 가지는 회전기계의 진동 신호에서 회전속도를 추정하지 못하는 문제점을 가지고 있다. CNN 모델을 사용하여 회전속도의 범위를 분류함으로써 신호를 단순화하고 ACF를 사용하여 복잡한 신호를 주기적 특징만 추출하고 신호의 노이즈를 제거하여 회전속도를 추정하는 두 단계로 구성된 시스템을 설계함으로써 기존의 회전속도 추정 방법의 문제점을 해결하였다.

4차산업으로 인해 설비의 상태 모니터링이 대두되는 산업현장에서 현장별 환경에 영향을 받지 않고 회전속도를 추정 가능하다는 것을 본 연구로 증명하였고 더 나아가 회전속도를 응용한 설비의 진동 분석을 통한 결함 진단 분야에 도움이 될 것으로 생각한다.

연구의 한계점으로 본 논문에서 제안한 시스템은 제한된 회전속도의 범위 내에서 CNN 분류 모델과 신호처리 알고리즘을 사용하여 회전속도를 추정함으로써 회전속도 범위 외의 언급되지 않은 값을 추정할 수 없다는 문제점을 가지고 있다. 기계설비는 본 연구에서 제안한 시스템의 추정 가능한 속도 범위 외의 더 다양한 회전속도로 운영된다. 따라서 특정한 속도 범위가 없어도 회전속도를 추정할 수 있도록 시스템 기능을 개선해야 한다. 또한 공기조화설비 외의 다양한 설비에서 수집한 데이터를 사용하여 회전속도 추정 시스템을 구성하지 못하여 다른 환경에 적용할 경우 모델의 재학습 및 검증이 필요하다. 다양한 설비 및 환경에서 적용이 가능하도록 다양한 데이터를

수집하고 다양한 환경에 적용할 수 있도록 기능을 개선해야 한다.

References

- [1] S. K. Nithin, K. Hemanth, V. Shamanth, R. S. Mahale, P. C. Sharath, A. Patil, Importance of condition monitoring in mechanical domain, *Materials Today: Proceedings*, (2022), Vol.54, No.2, pp.234-239.
DOI: <http://dx.doi.org/10.1016/j.matpr.2021.08.299>
- [2] A. Khadersab, S. Shivakumar, Vibration analysis techniques for rotating machinery and its effect on bearing faults, *Procedia Manufacturing*, (2018), Vol.20, pp.247-252.
DOI: <http://dx.doi.org/10.1016/j.promfg.2018.02.036>
- [3] B. S. Yang, *Condition Monitoring & Diagnostics*, GS intervision, Inc, (2019)
Available from: <http://www.yes24.com/Product/Goods/77127654>
- [4] J. Urbanek, T. Barszcz, N. Sawalhi, R. B. Randall, Comparison of amplitude-based and phase-based method for speed tracking in application to wind turbines, *Metrology and measurement systems*, (2011), Vol.18, No.2, pp.295-303.
DOI: <http://dx.doi.org/10.2478/v10178-011-0011-z>
- [5] Q. Leclere, H. Andre, J. Antoni, A multi-order probabilistic approach for Instantaneous Angular Speed tracking debriefing of the CMMNO14 ' diagnosis contest, *Mechanical Systems and Signal Processing*, (2016), Vol.81, pp.375-386.
DOI: <http://dx.doi.org/10.1016/j.ymsp.2016.02.053>
- [6] J. Antoni, J. Griffaton, H. Andre, L. D. Avendano-Valencia, F. Bonnardot, O. Cardona-Morales, G. Castellanos-Dominguez, A. P. Daga, Q. Leclere, C. M. Vicuna, D. Q. Acuna, A. P. Ompusunggu, E. F. Sierra-Alonso, Feedback on the Surveillance 8 challenge: Vibration-based diagnosis of a Safran aircraft engine, *Mechanical Systems and Signal Processing*, (2017), Vol.97, pp.112-144.
DOI: <http://dx.doi.org/10.1016/j.ymsp.2017.01.037>
- [7] M. Rao, Q. Li, D. Wei, M. J. Zuo, A deep bi-directional long short-term memory model for automatic rotating speed extraction from raw vibration signals, *Measurement*, (2020), Vol.158, pp.107719.
DOI: <http://dx.doi.org/10.1016/j.measurement.2020.107719>
- [8] P. K. Pradhan, S. K. Roy, A. R. Mohanty, Detection of broken impeller in submersible pump by estimation of rotational frequency from motor current signal, *Journal of Vibration Engineering & Technologies*, (2020), Vol.8, pp.613-620.
DOI: <http://dx.doi.org/10.1007/s42417-019-00165-6>
- [9] M. Lal, Modeling and estimation of speed dependent bearing and coupling misalignment faults in a turbine generator system, *Mechanical Systems and Signal Processing*, (2021), Vol.151, pp.107365.
DOI: <http://dx.doi.org/10.1016/j.ymsp.2020.107365>
- [10] S. Al Zu'bi, N. Islam, M. Abbod, 3d multiresolution analysis for reduced features segmentation of medical volumes using pca, *2010 IEEE Asia Pacific Conference on Circuits and Systems*, IEEE, (2010)
DOI: <http://dx.doi.org/10.1109/APCCAS.2010.5774847>
- [11] R. Ingale, Harmonic analysis using FFT and STFT, *International Journal of Signal Processing, Image Processing and Pattern Recognition*, (2014), Vol.7, No.4, pp.345-362.
DOI: <http://dx.doi.org/10.14257/ijsp.2014.7.4.33>
- [12] M. M. Farag, A Self-Contained STFT CNN for ECG Classification and Arrhythmia Detection at the Edge, *IEEE Access*, (2022), Vol.10, pp.94469-94486.
DOI: <http://dx.doi.org/10.1109/ACCESS.2022.3204703>
- [13] Y. Liao, X. Zeng, W. Li, Wavelet transform based convolutional neural network for gearbox fault classification, In *2017 Prognostics and System Health Management Conference (PHM-Harbin)*, IEEE, (2017)
DOI: <http://dx.doi.org/10.1109/PHM.2017.8079274>

- [14] H. Jung, S. Choi, B. Lee, Rotor Fault Diagnosis Method Using CNN-Based Transfer Learning with 2D Sound Spectrogram Analysis, *Electronics*, (2023), Vol.12, No.3, pp.480.
DOI: <https://doi.org/10.3390/electronics12030480>
- [15] G. Li, C. Deng, J. Wu, X. Xu, X. Shao, Y. Wang, Sensor data-driven bearing fault diagnosis based on deep convolutional neural networks and S-transform, *Sensors*, (2019), Vol.19, No.12, pp.2750.
DOI: <https://doi.org/10.3390/s19122750>
- [16] A. Choudhary, R. K. Mishra, S. Fatima, B. K. Panigrahi, Multi-input CNN based vibro-acoustic fusion for accurate fault diagnosis of induction motor, *Engineering Applications of Artificial Intelligence*, (2023), Vol.120, pp.105872.
DOI: <https://doi.org/10.1016/j.engappai.2023.105872>
- [17] A. Mikołajczyk, M. Grochowski, Data augmentation for improving deep learning in image classification problem, 2018 International Interdisciplinary PhD Workshop (IIPHDW), IEEE, (2018)
DOI: <http://dx.doi.org/10.1109/IIPHDW.2018.8388338>
- [18] M. Hammami, D. Friboulet, R. Kechichian, Cycle GAN-based data augmentation for multi-organ detection in CT images via Yolo. 2020 IEEE International Conference on Image Processing (ICIP), IEEE, (2020)
DOI: <http://dx.doi.org/10.1109/ICIP40778.2020.9191127>
- [19] K. Ishizuka, T. Nakatani, M. Fujimoto, N. Miyazaki, Noise robust voice activity detection based on periodic to aperiodic component ratio, *Speech Communication*, (2010), Vol.52, No.1, pp.41-60.
DOI: <http://dx.doi.org/10.1016/j.specom.2009.08.003>