

Recurrence Plot과 딥러닝을 이용한 음향 기반 드론 고장 감지

김은섭*, 신수용^o

Audio-Based Drone Defect Detection Using Recurrence Plot and Deep Learning

Eun Seop Kim*, Soo Young Shin^o

요약

본 논문은 드론의 고장을 감지하여 사고로 인한 피해를 미리 방지하는 것을 목표로 Recurrence plot(RP)과 딥러닝을 이용한 음향신호 기반 드론의 고장 감지 기법을 제안한다. 드론 로터에서 발생하는 반복적인 패턴의 음향신호를 RP를 이용하여 이미지화하고 이를 이미지 인식 딥러닝 모델인 YOLOv5를 사용하여 드론의 고장을 감지한다. 4층 건물의 옥상에서 Bebop 2 드론으로 구성된 정상적인 드론과 비정상적인 드론에서 발생하는 음향신호를 이용하여 RP 데이터셋을 구성해 윈도우 PC에서 아나콘다 가상환경을 통해 YOLOv5 모델을 학습시켜 추론한다. 음성인식에 많이 사용되는 Mel-spectrogram과의 비교 평가를 통해 분류 정확도와 동작 소요시간을 측정하여 제안하는 방식의 성능 우수성을 입증한다. 제안하는 기법의 정확도는 97.5%로 매우 정확함을 확인하였으며 향후 연구 방향에 대하여 논의한다.

Key Words : Recurrence plot, Deep learning, Drone, Defect detection, YOLOv5

ABSTRACT

This paper proposes a drone defect detection scheme based on acoustic signals using Recurrence Plot (RP) and deep learning to detect drone defects and prevent damage caused by accidents in advance. The acoustic signals of a recurring pattern generated by the drone rotor are imaged using RP, and the drone defects are detected using the image recognition deep learning model YOLOv5. On the roof of a four-story building, RP datasets are constructed using the acoustic signals generated by the normal and abnormal drones composed of the Bebop 2 drone, and the YOLOv5 model is trained and inferred through the anaconda virtual environment on a Windows PC. Through comparative evaluation with mel-spectrogram, widely used for speech recognition, the classification accuracy and operation time are measured to prove the superiority of the performance of the proposed scheme. The accuracy of the proposed scheme is 97.5%, which is confirmed to be very accurate, and the future research direction is discussed.

* 이 논문은 2022년도 정부(교육과학기술부)의 재원으로 한국연구재단의 대학중점연구소 지원사업으로 수행된 연구임(2018R1A6A1A03024003)

• First Author : Kumoh National Institute of Technology, Dept. of IT Convergence Engineering, subway@kumoh.ac.kr, 학생회원

^o Corresponding Author : Kumoh National Institute of Technology, Dept. of IT Convergence Engineering, wdragon@kumoh.ac.kr, 중신회원

논문번호 : 202211-272-D-RU, Received November 3, 2022; Revised November 16, 2022; Accepted November 16, 2022

I. 서론

근래에 들어서 드론은 우리 일상생활에 더욱 가까워지고 있고 다양한 산업현장에도 적용되고 있다. 개인적인 촬영용 드론의 보급부터 사람을 이동시킬 수 있는 드론택시나 육로 이동이 어려운 상황에서 빠르게 물건을 운반할 수 있는 드론배송 등의 일상 영역뿐만 아니라 농약 살포, 생육 상태 확인 목적의 농업용 드론과 범죄감시나 도로나 건물 균열의 탐지가 가능한 순찰드론, 이러한 기능들을 실내에서 활용할 수 있도록 한 스마트팩토리 드론 등 적용되고 있는 사례가 많다.

이러한 드론의 긍정적인 사례에 반하여 부정적인 현상을 일으키기도 한다. 적대적인 의도를 갖고 테러 등의 공격 활동으로 피해를 일으키거나, 고장, 제어 및 조종의 실수나 미필적 고의 등에 의해 의도치 않은 사고를 유발하는 예도 잦아지고 있다. 따라서 이와 같은 피해를 예방하기 위하여 드론을 감지 또는 분류하거나 드론의 고장을 감지하여 피해를 예방하기 위한 연구가 필요하여 진행되고 있다^{1,2}.

드론은 프로펠러를 고속으로 회전시켜 빠르게 움직일 수 있는 특성을 띠고 있어서 카메라를 이용하여 이를 감지, 분류 등의 작업을 하려면 1초당 프레임 수의 부족, 시야각 등의 문제로 어려움을 겪을 수 있다.

음향 기반의 인식은 카메라의 시야각 문제에서 발생하는 단점을 극복할 수 있다. 또한, 전기나 진동의 신호를 이용하는 방법보다 많은 고장을 감지할 수 있고 무엇보다 쉽고 저렴하게 데이터를 얻을 수 있다³. 마이크 센서 하나로 모든 방향의 음향 데이터를 입력 받을 수 있으며 마이크 어레이를 사용하면 스위치 빔 포밍을 통해 특정 방향의 특정 소리를 집중적으로 입력받을 수도 있다. 특히, 상당수의 드론의 고장은 프로펠러, 로터 등의 고속 회전부에서 발생하게 되는데 일반적인 카메라로는 비행 중인 드론의 부품 상태를 점검하기 어려우며 음향 기반의 방법을 사용하여 그 신호를 분석함으로써 드론을 감지하고 고장 감지까지 가능하다. 예를 들면, 프로펠러의 일부가 손상된 드론을 영상을 통해 감지할 때는 프로펠러가 회전 중이므로 프레임을 감지하여 드론임을 알 수는 있지만 고장 여부에 대해서는 파악하기 어렵다.

Recurrence plot(RP)은 시계열 데이터를 이미지로 표현하기 위한 기법이다. 대표적인 시계열 데이터인 음성 데이터를 이미지 인식을 위한 딥러닝 모델에 사용하기 위하여 변환 과정을 거치게 된다. 시계열 데이터를 이미지화하기 위한 다양한 기법이 있지만, RP는

반복적인 특징을 나타내기에 적합한 기법이다⁴. 따라서 고속으로 회전하는 모터와 프로펠러를 갖는 드론의 음향신호는 반복적인 특징을 띄게 되므로 적용될 수 있다.

Mel-Spectrogram은 최근 MFCC(Mel Frequency Cepstral Coefficients)와 더불어 음성인식에 가장 많이 사용되는 기법의 하나다. MFCC는 사람의 달팽이관이 소리를 인식할 때 주파수가 낮은 대역의 변화는 쉽게 감지하지만 높은 대역의 변화는 감지하기 어렵다는 특성에 맞춰 특징 벡터화할 수 있도록 한 것이며 여러 단계 중 마지막에 DCT(Discrete Cosine Transform)를 적용하여 압축하여 표현하면 MFCC가 되고 DCT를 적용하지 않으면 Mel-Spectrogram이 된다⁵. 소리를 시각화하여 표현한다는 공통점을 갖기 때문에 본 논문에서는 RP의 비교군으로 mel-spectrogram을 사용하였다.

YOLOv5(You Only Look Once: Version 5)는 CNN(Convolutional Neural Network) 기반의 객체 인식 알고리즘으로 실시간 객체 인식이 가능한 빠른 속도와 높은 정확도를 특징으로 하는 모델이다. 본 논문에서는 제안하는 RP와 기존의 기법인 mel-spectrogram을 YOLOv5를 이용하여 모델을 학습시켜 드론의 고장을 감지하도록 하였고 성능을 비교하여 제안하는 기법의 우수성을 확인한다.

따라서 논문은 다음과 같은 구성으로 작성되었다. 2장은 본론으로서 전체 시스템과 음향신호를 이미지화하기 위해 사용된 RP와 mel-spectrogram에 대하여 설명하고 추론을 위한 CNN 모델인 YOLOv5에 대하여 다룬다. 3장에서는 실험 방법과 실험 환경에 대하여 설명한 후 실험 결과에 대해서 분석하였다. 그리고 4장에서는 본 논문의 결론과 향후 연구계획을 서술한다.

II. 본론

2.1 시스템 모델

본 논문의 전체 시스템 모델을 그림 1에 나타내었다. 크게 드론, 마이크, PC로 구성되며, 그림 1 시스템 모델의 3, 4번이 PC에서 구현된다.

시스템 모델의 첫 번째로, 드론을 호버링 시켜야 한다. 즉, GPS(Global Positioning System)를 기반으로 드론의 위치를 측위하여 드론 스스로 위치를 파악하여 정해진 위치를 일정하게 유지하도록 하고 드론 하부에 장착된 센서를 통해 높이도 일정하게 유지하여 제자리에 정지비행을 하도록 해야 한다. 그렇지 않다면, 드론의 위치는 바람 등의 외부요인에 의하여

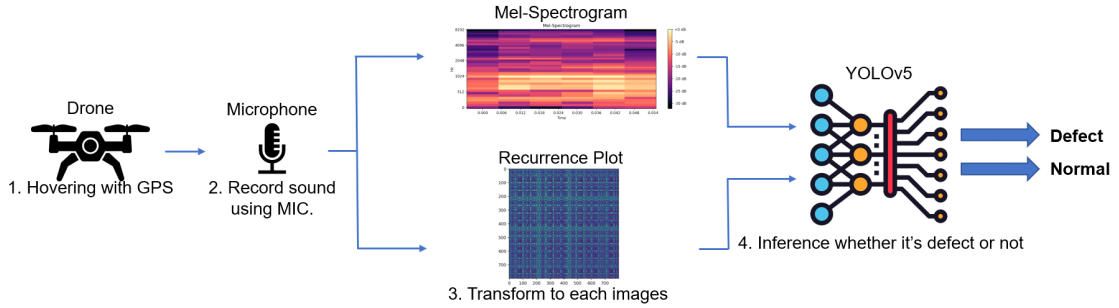


그림 1. 시스템 모델
Fig. 1. System model

불규칙한 움직임에 의해 발생하는 소리도 불규칙적으로 변하게 되고 드론과 마이크 사이의 거리도 변한다. 이는 고장 감지에 장애물이 될 수 있다. 두 번째로 마이크를 통해 드론의 소리를 녹음한다. 학습 데이터 수집과 드론 고장 추론을 위해서 정상적인 드론과 비정상적인 드론의 소리를 각각 녹음해야 한다. 세 번째로 드론의 음향 신호를 YOLOv5 모델에 사용하기 위하여 이미지 형태로 변환하는 단계가 필요하다. 본 논문에서 제안하는 기법으로는 RP와 비교군으로 사용하기 위해 기존에 음성인식 등에 많이 사용하던 mel-spectrogram을 사용한다. 마지막으로 YOLOv5를 이용한 학습과 추론을 통하여 드론이 고장인지 아닌지 판별하게 된다.

2.2 Mel-Spectrogram

Mel-spectrogram은 MFCC와 함께 최근 음성인식에 가장 많이 사용되는 기법이다. 그림 2는 MFCC를 구하는 과정을 나타낸 블록 다이어그램이며, 첫 번째와 마지막의 입력과 출력을 제외하면 pre-emphasis, sampling 및 windowing, FFT(Fast Fourier Transform), mel filter bank, DCT(Discrete Cosine

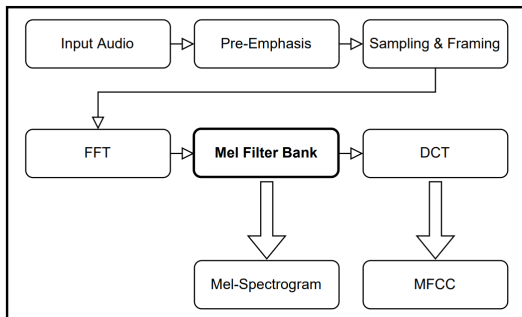


그림 2. MFCC를 구하기 위한 블록 다이어그램
Fig. 2. Block diagram for obtaining MFCC

Transform)의 다섯 단계를 거쳐서 얻게 된다. 일반적인 음성신호들은 고음 부분이 진폭이 작기 때문에 pre-emphasis를 통해 고주파 대역을 보상하여 전체 스펙트럼의 균형을 유지하도록 한다^[6]. 그다음 sampling과 windowing을 통해 20~40[msec] 정도의 길이로 나누어 FFT에 적합하도록 한다. FFT를 통해 주파수 스펙트럼을 구하고 mel filter bank를 거치게 되는데 이 부분이 알고리즘의 핵심적인 단계이다. 이 단계는 인간의 청각기관에서 음성을 인식하는 원리를 필터로 적용한 것으로 인간의 귀는 저음부에서는 주파수의 변화를 잘 감지하는 반면에 고주파수 대역에서는 주파수 변화를 잘 감지하지 못하는 특성을 이용한다^[7]. 이 같은 특징을 적용할 수 있는 멜 필터 뱅크를 그림 3에 나타내었다^[7]. 여기까지 거치면 mel-spectrogram을 구할 수 있고 DCT를 통해 압축하여 표현하면 MFCC를 구할 수 있다.

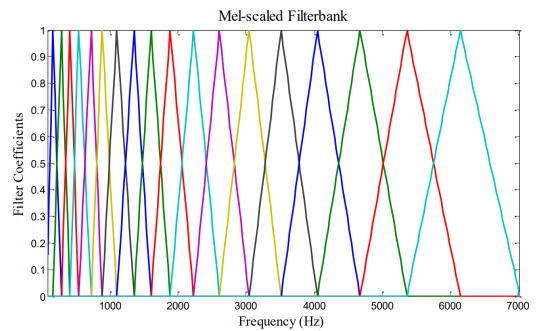


그림 3. 멜 필터 뱅크
Fig. 3. Mel filter bank

2.3 Recurrence Plot(RP)

앞서 언급한 mel-spectrogram과 MFCC의 경우에는 인간의 구강기관에서 발화된 음성을 청각기관에서 인식하는 특성을 모티브로 한 것이 핵심이므로 드론




그림 4. Recurrence plot(RP) 변환 예시
Fig. 4. Example of recurrence plot(RP) transformation

의 소리와 같은 기계적인 소리에는 다른 기법을 사용하는 것이 더욱 효과적일 수 있다. Recurrence plot은 그 이름에서 알 수 있듯이 시계열 데이터의 반복되는 특징을 나타내기 위해 적합한 기법이다.

그림 4는 시계열 데이터를 RP로 변환하기 위한 기법을 설명한 예시이다. 그림의 왼쪽은 시계열 데이터의 간단한 예시이며, 가운데는 왼쪽의 시계열 데이터를 이용하여 2차원의 위상 공간 궤적(2D phase space trajectory)을 그릴 것이고, 여기서 각 궤적 간의 거리를 행렬로 표현한 것이 오른쪽의 recurrence plot(distance matrix)이 된다^{8,9)}. 이를 식 (1)에서 다음과 같이 표현한다.

$$R_{i,j} = \theta(\epsilon - \| \vec{s}_i - \vec{s}_j \|) \quad (1)$$

여기서 θ 는 헤비사이드 함수, ϵ 은 임계거리 값을 의미한다. θ 와 ϵ 를 제외한 norm 부분만 사용하기도 하며 이를 unthresholded recurrence plot이라고 한다¹⁰⁾. 상술한 기법으로 궤적 간의 거리를 나타내어 반복되는 특징을 표현하므로 고속으로 회전하는 드론의 로터와 프로펠러에서 발생하는 음향신호를 표현하기에 매우 적합하다.

2.4 YOLOv5

YOLOv5(You Only Look Once: Version 5)는 YOLO의 다섯 번째 버전으로 빠른 속도와 정확도를 가진 객체 인식을 위한 CNN 모델이다. nano, small, midium, large, xlarge의 5가지의 종류를 갖고 있으며 각각 성능이 다르므로 사용할 기기의 연산능력에 따라서 선택할 수 있다.

모델의 상세한 구조를 그림 5에 나타내었다. CSP(Cross Stage Partial Network)는 YOLOv5에서

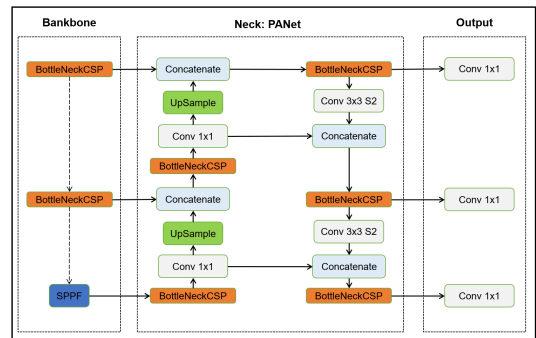


그림 5. YOLOv5 네트워크 구조
Fig. 5. YOLOv5 network architecture

핵심이 되는 모듈이며 입력받은 이미지에서 유용한 특징(feature)을 추출하는 역할을 한다. SPPF(Spatial Pyramid Pooling - Fast)는 다양한 크기의 이미지 입력에 대하여 다음 레이어에 대하여 고정된 벡터 크기가 입력되도록 하며 기존의 SPP와 동일한 기능을 하면서 단위 시간당 연산량은 증가하였다¹¹⁾.

또한, mosaic 데이터 증강 기법을 포함하고 있다. 네 장의 이미지를 무작위 크기로 잘라 하나의 이미지로 합친다. 이 과정에서 각각의 이미지의 크기가 작아지게 됨에 따라 감지할 객체의 크기도 작아지게 되어 작은 크기의 객체에 대하여 감지 성능이 높아지고 네 장의 이미지를 하나로 합치게 되므로 한 장의 이미지로 네 장을 학습시키는 효과도 있다. 따라서 학습이 더욱 원활하다.

III. 실험

3.1 실험 환경 및 오디오 녹음

실험에 사용된 장비를 표 1에 나타내었다. Intel 코어 i7-4790 CPU 와 Nvidia GeForce GTX1060 GPU

를 탑재한 윈도우 PC에서 아나콘다 가상환경을 통해 구현하였다. 오디오 녹음은 삼성전자의 갤럭시 S10 스마트폰에 내장된 마이크를 이용하여 진행되었다. 녹음된 오디오는 웨이브(wav) 파일 형식이며 채널은 모노 타입이다. 평균 bitrate는 256Kbps이며 sampling rate는 44.1KHz으로 가청 주파수의 2배 이상으로 샘플링 되어 원신호로 복원할 수 있다. 따라서 실험에 적합하다. 표 2에 오디오의 상세 내용을 정리하였다.

그림 6에 데이터 수집 환경과 실험에 사용된 드론인 Bebop 2를 나타내었다. 4층 건물의 옥상에서 진행되었으며 고장 드론이 사용되므로 안전을 위하여 강한 바람이 불지 않는 날 진행하였고 GPS 기반 호버링을 통해 드론과 마이크의 거리는 2m 이상 4m 이하로 유지하였다. 그림 7은 실험에 사용된 고장 및 정상 드론의 프로펠러이다. 정상 경우 로터 축 중심으로부터 프로펠러 끝까지의 길이가 약 7.5cm이지만, 고장 프로펠러는 약 5.7cm로 약 24% 절제하여 4개의 프로펠러 중 하나를 고장 프로펠러로 사용하였다.

고장, 정상, 배경 소음을 각각 Defect, Normal, Unknown의 클래스로 나누어 3회에 나누어 녹음을 진행했고 노이즈가 심한 부분은 제거하고 각 데이터들은 50msec의 길이로 나누었다. 표 3에 나타난 것과 같이 데이터셋을 구성하였다. 데이터셋을 학습, 검증, 실험 60:20:20의 비율로 나누어 사용하였다.

표 1. 실험에 사용된 장비
Table 1. Used equipments for experiment

Equipment	Company	Model
Drone	Parrot	Bebop 2
PC (CPU)	Intel	i7-4790
PC (GPU)	Nvidia	GTX 1060
Microphone	Samsung	SM-G973N

표 2. 오디오 상세
Table 2. Audio Specification

File Format	Sampling rate	Bitrate	Channel
wav	44.1 KHz	256 Kbps	Mono

표 3. 수집한 데이터셋
Table 3. Collected dataset

Class	Audio length [sec]	The number of dataset
Defect	105.6	2,112
Normal	135.75	2,715
Unknown	99.9	1,998
Total	341.25	6,825



그림 6. 데이터 수집 환경 및 사용된 드론 (Bebop 2)
Fig. 6. Environment of data collection & used drone (bebop 2)



그림 7. 고장 및 정상 드론 구성
Fig. 7. Set up for defect and normal drone

3.2 이미지 변환 및 학습

드론의 오디오 신호를 녹음한 후, 각각 RP와 mel-spectrogram으로 변환하였다. 학습 모델로는 정확도와 속도를 고려하여 medium에 해당하는 YOLOv5m 모델을 이용하여 구현하여 실험을 진행하였고 각 기법의 성능을 비교하였다. 두 이미지 변환 기법 모두 Python 3.9.7, PyTorch 1.10.2 환경에서 batch size는 4, 이미지 크기는 640으로 하여 20 epochs만큼 학습하였다.

3.2.1 Mel-Spectrogram

Mel-spectrogram의 실험을 위하여 Python에서 음성 분석을 위해 사용되는 라이브러리인 librosa를 사용하여 구현하였다. Mel-spectrogram으로 변환하기

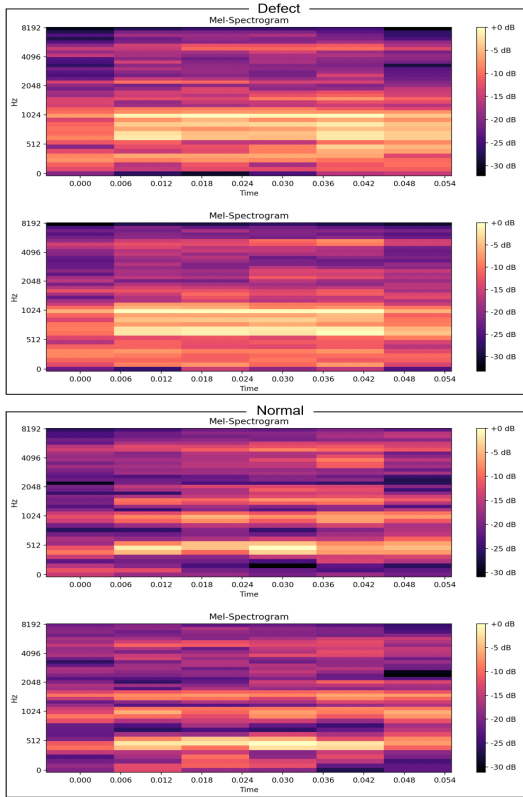


그림 8. 학습에 사용된 데이터셋의 예시 (Mel-Spectrogram)
Fig. 8. Examples of trained datasets (Mel-Spectrogram)

표 4. Mel-Spectrogram 매개변수
Table 4. Mel-Spectrogram parameter

Parameter	frame_length [sec]	frame_stride [sec]	n_mels
Value	0.025	0.010	40

위한 매개변수를 표 4에 나타내었다. 매개변수는 가장 일반적으로 선택하는 값으로 설정했다. frame_length, frame_stride를 각각 0.025, 0.010으로 하여 15msec마다 중첩하도록 하고 10msec 간격으로 출력하도록 하며, n_mels는 40으로 하여 주파수 대역을 40등분 표현했다. 이를 적용하여 학습에 사용된 mel-spectrogram의 일부를 그림 8에 나타내었다.

3.2.2 Recurrence Plot(RP)

Recurrence plot(RP)은 앞서 설명한 수식 (1)에서 임계거리 값과 헤비사이드 함수 부분을 제외한 궤적 간 거리의 norm 값만을 사용했다. 즉, 임의로 정할 수 있는 값에 따라서 표현되는 결과가 달라지는 것을 피하고자 unthresholded recurrence plot을 사용하였다.

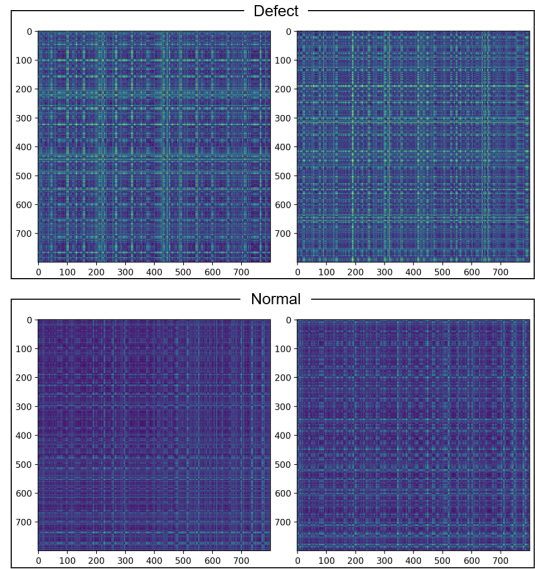


그림 9. 학습에 사용된 데이터셋의 예시 (Recurrence plot)
Fig. 9. Examples of trained datasets (Recurrence plot)

학습에 사용된 RP의 일부를 그림 9에 나타내었다.

3.3 실험 결과

3.3.1 학습 결과

두 변환 기법의 학습 결과를 그림 10에 나타내었다. 왼쪽은 mel-spectrogram, 오른쪽은 RP의 결과이며 각각의 가로축은 epochs이며, 세로축은 각각 classification loss와 precision을 나타낸다. 두 기법 모두 loss 그래프가 20 epochs에 가까워질수록 감소하며 안정되는 모습을 보였다. precision 그래프는 mel-spectrogram의 경우에는 다소 불안정한 형태를 보이지만 높은 값을 보이고 있고 RP의 경우엔 안정적으로 0.99에 가까운 값을 보이고 있다. 따라서 같은 학습량에서는 RP가 훨씬 우세함을 보여준다.

3.3.2 동작 소요시간

표현 기법별 실행 성능을 비교하기 위한 지표 중 하나로 동작 소요시간을 선정하였다. 동작 소요시간은 음향에서 이미지로의 변환 시간과 YOLOv5 추론 시간을 더한 시간을 의미한다. 측정은 python의 time 모듈을 이용하여 진행했다. 동일한 고장 드론 오디오 데이터를 사용하여 100개의 데이터셋에서 동작 소요시간을 계산한 후에 산술평균을 구하였다. Mel-spectrogram 100개의 동작 소요시간이 총 34.73초 소요되었고 RP 100개의 동작 소요시간이 24.93초 소요되었다. 이를 통해 계산한 1개당 동작 소요시간을 표 5에 구체적으로 정

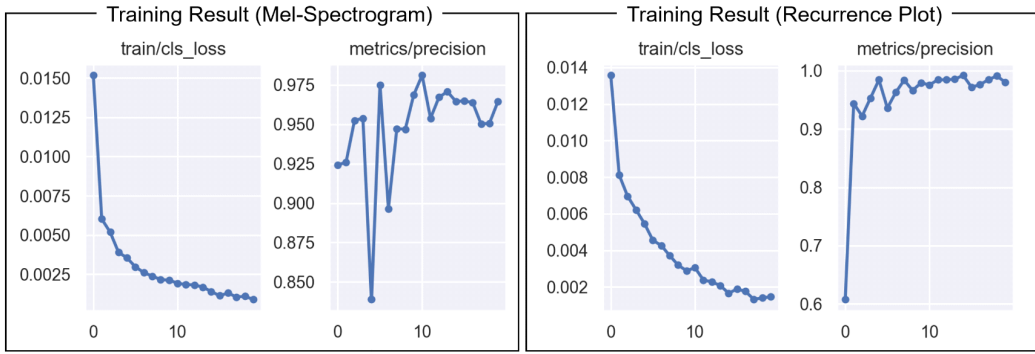


그림 10. 학습 결과
Fig. 10. Training result

표 5. 동작 소요시간
Table 5. Operation time

Imaging method	Transformation [msec]	Inference [msec]	Operation [msec]
Mel-Spectrogram	328.5	18.8	347.3
Recurrence Plot	225.4	23.9	249.3

리하였다. 이미지 크기의 차이로 인해 추론 시간은 RP가 길지만 동작 소요시간은 훨씬 앞서기 때문에 제안하는 기법이 우수하다.

3.3.3 분류 정확도

성능 비교를 위한 다른 지표로 분류 정확도를 선정했다. 동일한 실험 데이터셋 950개를 추론하여 분류 정확도 실험을 진행하였다. 그림 11, 12는 mel-spectrogram과 RP의 분류 예측 결과를 보여준다. Mel-spectrogram의 경우 클래스의 이름을 RP와 구분하기 위하여 편의상 MFCC를 붙였다. mel-spectrogram은

File Name	Prediction
DefectMFCC1300.png: 256x640	1 DefectMFCC, Done.
DefectMFCC1301.png: 256x640	1 DefectMFCC, Done.
DefectMFCC1302.png: 256x640	1 DefectMFCC, Done.
...	...
DefectMFCC1697.png: 256x640	1 DefectMFCC, Done.
DefectMFCC1698.png: 256x640	1 DefectMFCC, Done.
DefectMFCC1699.png: 256x640	1 DefectMFCC, Done.
...	...
NormalMFCC1650.png: 256x640	1 NormalMFCC, Done.
NormalMFCC1651.png: 256x640	1 NormalMFCC, Done.
NormalMFCC1652.png: 256x640	1 NormalMFCC, Done.
...	...
NormalMFCC2197.png: 256x640	1 NormalMFCC, Done.
NormalMFCC2198.png: 256x640	1 NormalMFCC, Done.
NormalMFCC2199.png: 256x640	1 NormalMFCC, Done.

그림 11. Mel-Spectrogram 추론 결과
Fig. 11. Inference result of mel-spectrogram

File Name	Prediction
Defect1300.png: 480x640	1 Defect, Done.
Defect1301.png: 480x640	1 Defect, Done.
Defect1302.png: 480x640	1 Defect, Done.
...	...
Defect1697.png: 480x640	1 Defect, Done.
Defect1698.png: 480x640	1 Defect, Done.
Defect1699.png: 480x640	1 Defect, Done.
...	...
Normal1650.png: 480x640	1 Normal, Done.
Normal1651.png: 480x640	1 Normal, Done.
Normal1652.png: 480x640	1 Normal, Done.
...	...
Normal12197.png: 480x640	1 Normal, Done.
Normal12198.png: 480x640	1 Normal, Done.
Normal12199.png: 480x640	1 Normal, Done.

그림 12. Recurrence plot 추론 결과
Fig. 12. Inference result of recurrence plot

표 6. 분류 정확도 비교
Table 6. Comparison of classification accuracy

Imaging method	Accuracy
Mel-Spectrogram	96.6%
Recurrence Plot	97.5%

918개의 데이터셋에서 정확하게 분류되었고 32개의 데이터셋에서 오분류 되었다. RP는 926개의 데이터셋에서 정확하게 분류되었고 24개의 데이터셋에서 오분류 되었다. 분류 정확도를 표 6에 나타내었다. 모두 양호한 결과를 보였고 제안하는 기법인 RP가 더 높은 결과를 보여 우수함을 증명하였다.

IV. 결론

본 논문에서는 드론에 의한 피해를 사전에 방지하기 위한 RP와 YOLOv5를 이용한 음향신호 기반 드론 고장 감지 시스템을 구현하여 성능을 비교하였고 결과를 분석하였다. Mel-spectrogram과의 비교 평가

결과에서 제안하는 기법인 RP가 97.5%의 정확도와 249.3msec의 동작 소요시간으로 더 우수한 성능으로 드론 고장을 감지할 수 있음을 보였다.

앞으로는 본 시스템을 임베디드 보드 등 소형 SBC (single board computer) 및 Onboard AI를 이용하여 구현하여 장소의 제약을 받지 않도록 하거나 드론 자체적으로 고장의 유형을 감지할 수 있는 연구와 구체적으로 드론이 어떤 유형의 고장 인지를 감지하기 위한 연구를 이어갈 예정이다.

References

- [1] S. Park, H. T. Kim, S. Lee, H. Joo, and H. Kim, "Survey on anti-drone systems: Components, designs, and challenges," *IEEE Access*, vol. 9, pp. 42635-42659, Mar. 2021. (<https://doi.org/10.1109/ACCESS.2021.3065926>)
- [2] S. Al-Emadi, A. Al-Ali, A. Mohammad, and A. Al-Ali, "Audio based drone detection and identification using deep learning," *2019 15th IWCMC*, pp. 459-464, Tangier, Morocco, Jun. 2019. (<https://doi.org/10.1109/IWCMC.2019.8766732>)
- [3] A. Altinors, F. Yol, and O. Yaman, "A sound based method for fault detection with statistical feature extraction in UAV motors," *Applied Acoustics*, vol. 183, 108325, Dec. 2021. (<https://doi.org/10.1016/j.apacoust.2021.108325>)
- [4] E. S. Kim and S. Y. Shin, "Performance comparison for drone classification by color expression of recurrence plot," in *Proc. Symp. KICS*, pp. 396-397, Jeju Island, Korea, Jun. 2022.
- [5] K. Shin, S. Yoo, and H. Oh, "Detection and classification for low-altitude micro drone with MFCC and CNN," *J. KIIICE*, vol. 24, no. 3, pp. 364-370, Mar. 2020. (<https://doi.org/10.6109/JKIIICE.2020.24.3.364>)
- [6] K. Chakraborty, A. Talele, and S. Upadhyay, "Voice recognition using MFCC algorithm," *IJIRAE*, vol. 1, no. 10, pp. 2349-2163, Nov. 2014.
- [7] Y. M. Ali, M. P. Paulraj, S. Yaacob, R. Yusuf, and S. A. bakar, "Analysis of accent-sensitive words in multi-resolution mel-frequency cepstral coefficients for classification of accents in Malaysian English," *Int. J. Automotive and Mechanical Eng.*, vol. 7, pp. 1053-1073, Jun. 2013. (<https://doi.org/10.15282/ijame.7.2012.21.0086>)
- [8] N. Hatami, Y. Gavet, and J. Debayle, "Classification of time-series images using deep convolutional neural networks," *Tenth ICMV 2017*, pp. 242-249, Vienna, Austria, Apr. 2018.
- [9] D. Seo, J. Ahn, and H. Nam, "Analysis performance of burst signal detection using recurrence plot algorithm," *J. KICS*, vol. 44, no. 11, pp. 2074-2077, Nov. 2019. (<https://doi.org/10.7840/kics.2019.44.11.2074>)
- [10] J. Nam and J. Kang, "Chaos signal classification and verification using CNN," *Trans. Korean Soc. Noise and Vibration Eng.*, vol. 31, no. 1, pp. 82-90, Feb. 2021. (<https://doi.org/10.7840/10.5050/KSNVE.2021.31.1.082>)
- [11] Q. Song, L. Shaobo, B. Qiang, J. Yang, X. Zhang, Z. Li, and Z. Duan, "Object detection method for grasping robot based on improved YOLOv5," *Micromachines*, vol. 12, no. 11, pp. 1-18, Oct. 2021. (<https://doi.org/10.3390/mi12111273>)

김 은 섭 (Eun Seop Kim)



2021년 2월 : 금오공과대학교 전
자공학부 졸업

2021년 3월~현재 : 금오공과대
학교 IT융복합공학과 석사과
정

<관심분야> 딥러닝, 음향인식,
영상처리

[ORCID:0000-0001-9928-6421]

신 수 용 (Soo Young Shin)



1999년 2월 : 서울대학교 전기공
학부 졸업

2001년 2월 : 서울대학교 전기공
학부 석사

2006년 2월 : 서울대학교 전기공
학부 박사

2010년~현재 : 금오공과대학교
전자공학부 교수

<관심분야> 차세대 무선통신 기술, 드론 응용, 블록체
인, 머신러닝, 딥러닝, 혼합현실

[ORCID:0000-0002-2526-2395]