

AnoGAN을 이용한 드론 로터 고장 진단

김은섭, 신수용*

금오공과대학교 IT융복합공학과

subway@kumoh.ac.kr, *wdragon@kumoh.ac.kr

Diagnosis of Drone Rotor Failure using AnoGAN

Eun Seop Kim, Soo Young Shin*

Dept. of IT Convergence Engineering

Kumoh National Institute of Technology

요 약

본 논문은 드론의 로터에서 발생하는 음향신호를 이용하여 드론의 고장 진단 방법을 제안한다. 일반적인 지도학습 방식의 딥러닝 분류 모델을 사용한다면 비정상 데이터의 수집하기 어렵고 학습에 사용되지 않은 또 다른 형태의 비정상 데이터가 입력으로 들어온다면 고장으로 분류하지 못하는 문제점이 있다. 이를 극복할 수 있는 방법으로 AnoGAN이라는 비지도 학습 기반의 방법을 통하여 Anomaly score를 산출하여 이를 통해 드론 로터의 고장을 진단할 수 있다. 이 같은 방법을 통해 스마트 팩토리에 필요한 인공지능 기반 예지 정비 등 관련 연구에 활용 가능하다.

I. 서 론

과거에 군사적 목적을 달성하기 위해서 많이 사용되던 드론은 근래에 민간 영역에서 다양한 분야에서 사용되고 있고 이에 따른 드론과 관련된 관련 사건 및 사고가 점차 증가하는 추세이다.[1] 이러한 저고도 무인 비행체와 관련된 사고들을 사전에 예방하기 위해서 여러 가지 센서들을 이용하여 식별할 수 있는 드론 방어 시스템을 연구, 개발하고 있다. 대표적으로 RGB 이미지, 열화상 이미지, 레이더, RF 스캔, 음향신호 기반 등의 방법이 있으며 음향신호 기반 드론 감지 방법은 저고도 근거리 환경에서 사용될 수 있으며, 카메라를 이용한 비전 기반 감지를 할 때, 학습되지 않은 드론의 이미지가 입력되었을 때 성능이 떨어지는 것을 보완할 수 있다.[2] 따라서 본 논문에서는 마이크를 이용한 음향신호 기반 드론 로터 고장 진단을 다룬다. 음향신호를 분류하기 위한 대표적인 방법으로는 MFCC(Mel-Frequency Cepstral Coefficient)를 이용한 지도학습 기반의 딥러닝이 많이 사용되고 있다. 그리고 통계적 특징 추출과 머신러닝을 이용한 방법이 있다. 하지만, 고장 데이터를 수집하여 라벨링 하는 것이 어렵고 데이터를 충분히 수집하여 학습시켰다 하더라도 라벨링 되지 않은 새로운 고장 유형의 음향신호가 입력된다면 정확도의 저하가 불가피하므로 비지도 학습 기반의 AnoGAN을 통한 드론 로터의 고장 진단을 제안한다.

II. 본론

본 논문에서는 음향 신호를 이용한 드론 로터의 고장 진단을 다룬다. 기존의 시각화 방법인 MFCC와 RP를 소개한 다음 AnoGAN을 이용한 방법을 제안한다.

II-1. 전처리

MFCC는 Mel-Frequency Cepstral Coefficient의 약자이며 음성신호에서 추출 가능한 특징이다. 소리의 고유한 특징을 나타내며 음성인식, 화자 인식, 음성합성 등의 소리 관련 문제들을 해결하는 데에 많이 사용되고 있다.[3] 하지만 사람의 청각기관의 특징을 이용한 mel-filter bank를 사용하기 때문에 드론의 소리를 분류하는데 적합하지 않을 수 있다. 따라서 반복되는 특징을 나타내는 데 용이한 recurrence plot을 통한 전처리 방법이 적합하다. 수식 1은 recurrence plot을 그리는 수식이며 두 궤적 간의 거리를 구한 것이다. $\theta(x)$ 는 단위 계단 함수이며 ϵ 은 임계값이며 임의로 조정할 수 있다. 수식 2는 궤적 간 거리와 ϵ 값을 비교하여 0과 1로 구성되는 간단한 RP를 그리는 수식이다. 그림 1은 recurrence plot의 예시이며 서로 다른 두 드론 Parrot 사의 Bebop과 Mambo의 음향 데이터를 이용하여 그린 것이다.




그림 1 Recurrence Plot of Bebop(Left) and Mambo(Right)[3]

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

$$R(i,j) = \begin{cases} 1 & \text{if } \|\vec{x}(i) - \vec{x}(j)\| \leq \epsilon \\ 0 & \text{otherwise,} \end{cases} \quad (2)$$




그림 2 DCGAN Architecture for Calculating Anomaly Score[4]

II-2. AnoGAN을 이용한 고장 진단

AnoGAN(Anomaly detection with Generative Adversarial Network)은 일반적으로 생각하는 딥러닝 분류 모델의 데이터 어노테이션 작업의 어려움을 극복할 수 있고 비정상 데이터를 수집하는 것이 어려운 경우에 용이한 방법이다.[4] 또한, 지도학습의 딥러닝 방법을 사용할 경우에는 모든 종류의 고장 양상에 대한 데이터를 수집할 수 없으므로 또 다른 유형의 고장이 발생한다면 분류에 실패할 수 있다. 제안된 방법은 비지도 학습 방법과 DCGAN을 동시에 사용하여 비정상 데이터 없이 정상 데이터만을 사용한 학습으로 이상을 분류하는 방식이다. 실제로 현장에서 학습용 데이터를 수집하기 위하여 드론을 인위적으로 고장 내는 등의 행위는 비경제적이며 비정상 드론을 사용하는 비행 실험은 매우 위험하다. 그림 3은 Bebop 2 드론이며 정상상태의 로터와 고장 난 로터의 예시이다. 고장의 여러 가지 유형 중 충돌 등의 상황에 의해서 프로펠러가 깨진 상황을 보여 준다.

DCGAN(Deep Convolutional Generative Adversarial Network)은 GAN을 이미지 인식에 적합하도록 구현한 것으로 생성 모델(Generator)과 판별 모델(Discriminator)의 두 가지 모델로 구성되며 두 모델이 서로 경쟁하면서 실제와 가까운 데이터를 자동으로 만드는 방식이다.[5] 생성 모델은 판별 모델을 속이도록 학습하고 판별 모델은 생성 모델에서 만들어진 데이터를 실제 데이터인지 아닌지 판별할 수 있도록 서로 대립하며 학습이 이뤄진다. 따라서 두 가지 모델이 균형을 이루도록 학습해야 좋은 결과를 얻을 수 있다.

AnoGAN은 DCGAN에서 이상 점수(anomaly score)를 계산하여 정상 데이터인지 비정상 데이터인지 구분한다. 정상 데이터의 학습에서 데이터들의 분포를 학습하고 정상 범위를 벗어날수록 높은 이상 점수가 나타나 고장예지를 가능하도록 한다. 여기서 정상 데이터 분포는 드론의 종류나 실험 환경에 따라서 달라질 수 있으므로 적절한 임계값을 정해야 한다.

III. 결론

본 논문에서는 비지도 학습 방법인 AnoGAN을 이용하여 드론의 로터 고장을 진단할 수 있는 방법을 제안하였다. 제안된 방법은 비지도 학습 기반의 방법이기 때문에 지도학습 기반의 방법과는 달리 별도의 라벨링 등



그림 3 Example of Normal Rotor and failure Rotor

의 번거로운 절차가 필요하지 않고 본 논문과 같이 정상 데이터를 수집하는 것이 어렵거나 새로운 고장 양상이 나타나기 쉬운 경우에 기존의 방법들에 비해서 고장을 효과적으로 진단할 수 있다.

그러나 AnoGAN은 DCGAN을 통해 구현하므로 데이터의 형태에 따라서 생성 모델과 판별 모델을 균형 있게 설계하여 구현하지 않으면 제대로 된 학습이 이뤄지지 않으며 이상 점수를 계산할 때 적절한 임계값을 정해야 정확하게 드론 로터의 고장을 진단할 수 있다. 그리고 입력되는 외부 잡음이 클수록 정확도가 떨어질 수 있어 비음향 기반 방법들에 비해 약점이 있다.

따라서 향후에는 잡음에 강인한 고장 감지에 대해서 연구할 필요가 있다.

ACKNOWLEDGMENT

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

“본 연구는 과학기술정보통신부 및 정보통신기획평가원의 지역지능화혁신인재양성(Grand ICT연구센터) 사업의 연구결과로 수행되었음”(IITP-2022-2020-0-01612)

참 고 문 헌

- [1] J. McCoy, A. Rawal, D. B. Rawat and B. M. Sadler, “Ensemble Deep Learning for Sustainable Multimodal UAV Classification,” in *IEEE Transactions on Intelligent Transportation Systems*, doi: 10.1109/TITS.2022.3170643.
- [2] S. Park, H. T. Kim, S. Lee, H. Joo and H. Kim, “Survey on Anti-Drone Systems: Components, Designs, and Challenges,” in *IEEE Access*, vol. 9, pp. 42635–42659, 2021.
- [3] 김은섭, 신수용. “Recurrence Plot을 이용한 드론 비행음 감지 및 분류” in *한국통신학회 학술대회논문집*, vol. 77, pp. 617–618., 2022.
- [4] Schlegl, T., Seeböck, P., Waldstein, S. M., Schmidt-Erfurth, U., & Langs, G. “Unsupervised anomaly detection with generative adversarial networks to guide marker discovery” in *International conference on information processing in medical imaging*, pp. 146–157. 2017. Springer, Cham.
- [5] Radford, Alec, Luke Metz, and Soumith Chintala. “Unsupervised representation learning with deep convolutional generative adversarial networks.” *arXiv preprint arXiv:1511.06434* (2015).