



Received: 2025/08/21
Revised: 2025/09/02
Accepted: 2025/09/23
Published: 2025/09/30

***Corresponding Author:**

Dooyoung Kim

Dept. of Artificial Intelligence, Republic of Korea Naval Academy
1, Jungwon-ro, Jinhae-gu, Changwon-si, Gyungsangnam-do, 51704, Republic of Korea
Tel: +82-2-907-5246
E-mail: dykim07@navy.ac.kr

회전익 항공기 기종 분류를 위한 실시간 음향 기반 경량 딥러닝 모델 비교연구

Comparative Study of Lightweight Deep Learning Models for Real-time Acoustic Classification of Rotary-wing Aircraft

허준석¹, 김두영^{2*}

¹해군사관학교 인공지능학과 사관생도

²해군 중령(진)/해군사관학교 인공지능학과 부교수

Junseok Heor¹, Dooyoung Kim^{2*}

¹Midshipman, Dept. of Artificial Intelligence, Republic of Korea Naval Academy

²CDR(Sel.), ROK Navy/Associate professor, Dept. of Artificial Intelligence, Republic of Korea Naval Academy

Abstract

본 연구는 회전익 항공기 음향 신호를 활용한 실시간 기종 분류를 위해 경량화된 딥러닝 구조를 제안한다. 입력 음향은 1초 단위로 분할 후 MFCC로 변환되어 시간-주파수 특징을 효과적으로 표현한다. CNN과 SqueezeNet을 기반으로 한 특징 추출기와 GRU 및 TCN 시계열 처리기를 조합한 다양한 구조를 비교한 결과, SqueezeNet-TCN 모델은 가장 적은 파라미터와 3 MB 미만의 모델 크기로 90 % 이상의 정확도를 달성하였다

This study proposes a lightweight deep learning framework for real-time classification of rotary-wing aircraft using acoustic signals. The audio input is segmented into 1-second frames and converted into MFCC to effectively capture time-frequency features. By comparing architectures combining CNN or SqueezeNet feature extractors with GRU and TCN temporal processors, the SqueezeNet-TCN model achieved over 90 % classification accuracy with a model size under 3 MB.

Keywords

MFCC(Mel-frequency Cepstral Coefficient), 합성곱 신경망(Convolution Neural Networks), 회전익 항공기(Rotary-wing Aircraft), 실시간분류(Real-time Classification), 경량 딥러닝(Lightweight Deep Learning)

1. 서론

회전익 항공기는 현대 작전 환경에서 정찰, 수송, 근접 항공지원 등 다양한 목적에 활용된다. 특히 기종에 따라 작전 반경, 탑재 용량, 운용 특성이 크게 상이하다. 예를 들어 Mi-8은 단일 메인로터와 테일로터를 사용하는 전통적인 구조로 최대 24명 내외의 병력 수송에 적합하다[1]. 반면 CH-47은 쌍로터 구조를 채택하여 더 높은 출력과 탑재 능력을 보유하고 있으며, 최대 50명 이상의 병력 수송이 가능하다[2]. 이러한 구조적 차이는 작전 반경, 임무 유형에 영향을 미친다. 따라서 기종 간 식별이 전술적 판단뿐 아니라 위협 인지와 선제적 대응에 핵심적인 정보로 작용한다.

또한 실전 환경에서 회전익 항공기 탐지는 단순 분류 성능뿐 아니라 실시간 대응 가능성을 염두해야 한다. 이를 위해 분류 정확도, 처리 속도, 탐지 거리 등 다양한 요소를 동시에 고려해야 한다[3]. 영상 및 레이더 기반 탐지는 정밀 분석에는 유리하지만, 기상, 지형, 장비 크기, 비용 등의 제약으로 휴대형 운용이 어렵다. 특히 레이더 기반 탐지 장비는 일반적으로 고출력 송수신 장치, 회전 안테나, 냉각 시스템 등으로 구성된다. 이는 높은 전력 소모와 큰 부피를 요구하므로 소형화에 한계가 있다[4].

이러한 한계를 극복하기 위해 본 연구는 수동형 센싱(sensing)이

이 가능하며, 비교적 저전력·저비용 구조로 실시간 적용이 가능한 음향 기반 기종 분류 접근을 제안한다. 음향 신호는 별도의 송신 없이 수집할 수 있어 장비 노출 없이 탐지가 가능하다. 실시간 적용을 위해 오디오를 1초 단위로 분할·순차 처리하며, 각 조각은 독립적으로 예측되면서도 이전 정보를 유지해 응답성과 정확도를 확보한다. 또한 스트리밍 환경에서 활용 가능한 다양한 신경망 구조를 비교·분석하여, 정확도·파라미터 수·추론 속도·경량성을 모두 고려한 최적 모델을 제시한다.

본 논문은 2.3장에서 관련 연구와 이론적 배경, 4장에서 모델 제안, 5장에서 성능 비교, 마지막으로 결론 및 향후 연구 방향을 제시하는 것으로 구성하였다.

2. 관련 연구

회전의 항공기 기종 식별 연구는 레이더 기반, 영상 기반, 음향 기반 접근으로 나뉜다[5-9]. 레이더 기반에서는 ISAR(inverse synthetic aperture radar)를 활용해 표적과 관측 플랫폼 간 상대 운동에서 발생하는 도플러 효과로 고해상도 2차원 영상을 생성하고 이를 바탕으로 회전의 항공기 및 드론을 분류하였다. 예를 들어 해상초계기 ISAR 센서를 이용해 획득한 함정 영상을 ResNet-50 기반 모델로 분류한 연구에서는 81종의 표적에 대해 99 % 이상의 정확도를 달성했다[5]. 또 다른 연구에서는 FMCW(frequency modulated continuous wave) 레이더로 회전의 운동이나 날갯짓 등 미세 움직임에 따른 주파수 변화를 분석하였다. 이는 드론·새·회전을 구분하였으며 ResNet-50 앙상블 모델로 다중 클래스 간에서도 높은 정확도를 보였다[6].

영상 기반 접근은 회전의 외형 이미지를 활용하여 기종 분류 또는 피아식별을 수행한다. 한 연구에서는 공격형(AH-64) 및 기동형(UH-60) 회전의 정지 이미지를 CNN 기반 모델로 학습시켜 98.9 % 정확도와 99.4 % 정밀도를 달성, 정지 영상에서도 높은 성능을 입증하였다[7]. 그러나 영상 기반 기법은 조명, 촬영 각도, 해상도 등 환경 조건에 민감하며, 실시간 감시에 적용하려면 처리 지연과 영상 품질 저하 문제가 따른다.

음향 기반 기종 식별 연구는 비교적 최근 활성화되었으며, UAV 탐지 및 분류에 MFCC(mel-frequency

cepstral coefficient), mel-spectrogram 등의 특징 추출과 CNN·RNN 모델을 결합하는 방식이 주류를 이룬다. 예를 들어 고정 마이크로 UAV 소리를 수집, 시간-주파수 영역으로 변환해 CNN 모델로 분류한 연구는 음향 데이터만으로 기체 식별이 가능함을 보였으며, 복잡한 장비 없이도 비교적 단순한 센서로 운용이 가능하다는 장점을 제시했다[8]. 또 다른 연구에서는 소형 마이크 어레이로 비행체 소음을 수집하고, FFT 기반 전처리 후 기계학습 분류기를 통해 UAV를 차량·사람 등 배경 소음과 구분하였다. 이 연구는 다양한 실외 환경 실험으로 UAV 고유의 회전 소음이 환경 소리와 명확히 구분됨을 확인하여, 음향 기반 탐지의 실용성과 확장성을 입증하였다[9].

그러나 기존 음향 기반 연구는 대부분 드론에 초점을 맞추고 있으며, 군용 회전의 항공기의 음향적 특성을 고려한 기종 분류 연구는 드물다. 회전의 항공기는 프로펠러·기체 구조에 따라 고유한 음향 패턴을 가지므로, 이를 효과적으로 인식·분류할 수 있는 시스템 개발이 필요하다. 본 연구는 MFCC 기반 특징 추출과 경량 딥러닝 모델을 결합하여 군용 회전의 항공기의 실시간 음향 분류 가능성을 검토하고, 실시간·모델 경량화 측면까지 고려한 실용적 기술 기반을 제시한다.

3. 이론적 배경

3.1 MFCC

MFCC(mel-frequency cepstral coefficient)는 인간의 청각 특성을 반영해 음향 신호의 스펙트럼을 분석하는 대표적인 특징 추출 기법이다. Linear scale 보다 mel scale 기반 필터뱅크를 사용하면 저주파 영역의 인지력이 향상된다[10]. 본 연구에서는 입력 신호에 pre-emphasis를 적용하고, 프레임 분할·FFT·mel 필터뱅크 변환·DCT 과정을 거쳐 최종 MFCC 계수를 계산하였다[11].

본 연구에서 수집된 회전의 항공기 4종(CH-53[2], MI-8[1], UH-60[12], UH-1[13])의 MFCC 특성을 시각화한 결과를 Fig. 1에 나타냈다. 각 열은 시간 프레임, 각 행은 멜 주파수 계수를 나타내며, 색상은 해당 주파수 대역에서의 에너지 크기를 표현한다. 회전의 종류에 따라 에너지 분포와 주파수 대역별 패턴




Fig. 1. MFCC visualization of four rotary-wing aircraft types (CH-53, Mi-8, UH-60, UH-1)

에서 차이가 나타나는데, 이는 기체 고유의 엔진 및 로터 소음 특성에 기인한다. 예를 들어, CH-53은 저주파 영역에서의 강한 에너지 대역이 두드러지며[2], UH-1은 비교적 고주파 성분이 강조되는 양상을 보인다[13]. 이러한 시각적 차이는 MFCC가 기체 종류 분류에 유의미한 특징을 제공함을 시사한다.

3.2 CNN

CNN(convolutional neural networks)은 영상이나 음성과 같은 2차원 데이터의 공간적 패턴을 추출하는 데 효과적인 합성곱 기반 신경망 구조로, 시간-주파수 영역의 입력인 MFCC를 처리하는 데 유리하다[14]. 본 연구에서는 회전익 음향 신호의 지역적인 주파수 특징을 효과적으로 추출하기 위하여 CNN을 활용하였다. 해당 구조는 병렬 처리와 계산 효율성이 뛰어나 다양한 분류 문제에서 그 성능이 입증된 바 있다[15].

3.3 SqueezeNet

SqueezeNet은 파라미터 수를 최소화하면서도 성능 손실을 줄인 경량화된 CNN 구조로, fire module을 통해 연산량을 감소시킨다[16]. 또한 SE Block을 fire module 뒤에 접목하여 채널별 특징에 대한 중요도를 동적으로 조정하는 구조로 확장하였고, 이러한 설계는 파라미터 수의 증가 없이도 모델의 표현력을 향상시키는 데 기여한다[17].

3.4 GRU

GRU(gated recurrent unit)는 LSTM(long short-term memory)보다 단순한 구조를 가지면서도 유사한 시계열 처리 성능을 제공한다. 업데이트 게이트와

리셋 게이트를 사용하여 정보를 제어하며, 파라미터 수가 적어 계산 효율성이 높다[18]. 본 연구에서는 연산 자원이 제한적인 환경에서의 실시간성 확보를 고려하여 GRU를 실험에 포함시켰다.

3.5 TCN

TCN(temporal convolutional networks)은 시계열 데이터 처리에 특화된 1차원 합성곱 기반의 신경망 구조로, 전통적인 순환 신경망(recurrent neural networks, RNN)의 대안으로 제안되었다. TCN은 입력 시퀀스를 시간 순서대로 처리하면서도 순환 구조 없이 긴 시퀀스의 시간적 의존성을 효과적으로 학습할 수 있도록 설계되었다. 또한 각 합성곱 계층에서 dilation rate를 지수적으로 증가시키는 팽창 합성곱을 사용하여, 비교적 작은 커널 크기에도 넓은 시간 수용 범위를 확보한다. 이러한 구조는 장기 시계열의 의존성을 효율적으로 모델링할 수 있도록 한다[19].

4. 연구방법

본 연구에서는 실시간 회전익 항공기 음향 신호를 MFCC로 변환한 뒤, CNN·SqueezeNet 기반의 특징 추출기와 GRU·TCN 시계열 처리기를 조합한 네 가지 모델(CNN+GRU, CNN+TCN, SqueezeNet+GRU, SqueezeNet+TCN)의 성능을 비교하였다.

Fig. 2는 입력 단계부터 최종 분류에 이르는 전체 처리 흐름을 나타낸다. 먼저, 원본 음향 신호는 1초 단위로 분할되어 MFCC 특징 벡터로 변환된다. 이 특징은 특징 추출기로 전달되며, CNN 기반 구조는 Conv2D, MaxPooling, BatchNormalization 층을 통해 지역적 주파수 패턴을 추출한다. SqueezeNet 기반 구조는 fire module을 사용해 1×1 및 3×3 합성곱을 결합하여 파라미터 수를 줄이고, SE block을 통

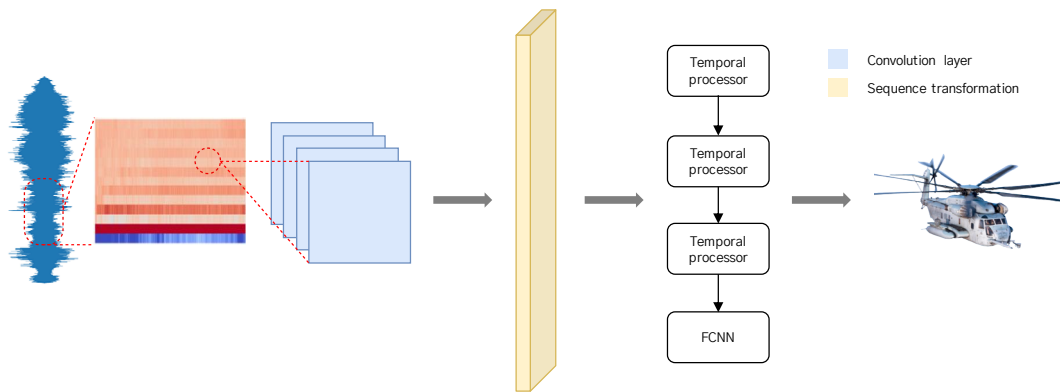


Fig. 2. Proposed acoustic-based rotary-wing aircraft classification mode

해 채널별 중요도를 동적으로 조정함으로써 경량화 및 표현력 향상을 동시에 달성한다. 이후 시계열 처리기로 GRU 또는 팽창 합성곱(dilated convolution) 기반 TCN을 적용한다. GRU는 게이트 구조를 통해 이전 상태 정보를 효율적으로 유지하며, TCN은 dilation rate[1,2,4,8]을 적용해 순환 구조 없이도 장기 시퀀스 의존성을 학습한다.

Fig. 3에는 각 조합의 세부 계층 구조와 파라미터 구성이 제시되어 있다. 모든 모델은 실시간 처리 환경에서 연산 효율성과 높은 분류 정확도를 동시에 확보하는 것을 목표로 설계되었다[20].

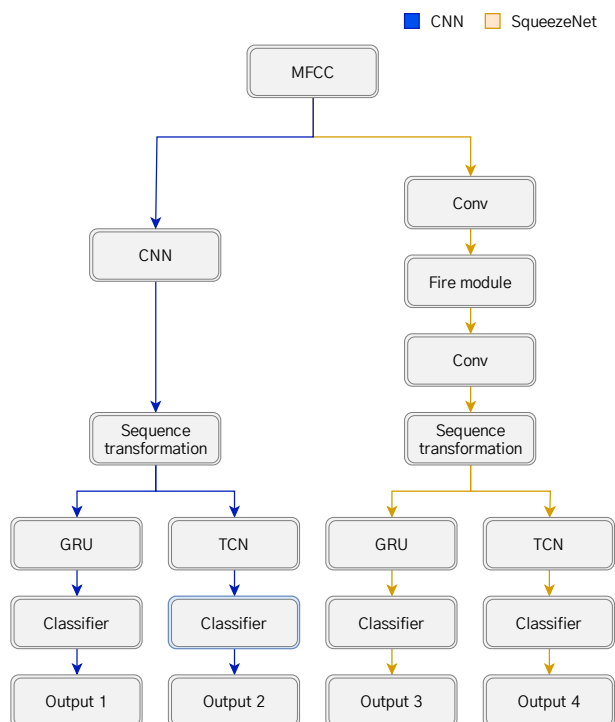


Fig. 3. Architectural overview of the four proposed helicopter classification models

5. 실험 및 결과

5.1 실험설정

본 실험은 TensorFlow를 기반으로 수행되었으며, 입력 데이터는 44,100 Hz로 샘플링된 회전익 항공기의 음향 신호를 MFCC로 변환한 후 일정한 시간 단위로 분할하여 사용하였다. 모든 모델은 손실 함수로 Sparse Categorical Crossentropy[21]를, 최적화 도구로 Adam[22]을 사용하였으며, 모델 구조에 따라 학습률은 0.0004에서 0.0005 사이로 조정되었다. 학습은 15 epoch까지 진행되었고, 배치 크기는 64로 설정하였다. 더불어 과적합을 방지하기 위해 조기멈춤(EarlyStopping)을 적용하였다. 데이터는 훈련과 검증 세트를 8:2 비율로 분할하였으며, 최종 평가는 분류 정확도와 손실값을 기준으로 수행되었다.

5.2 데이터셋

본 연구는 군용 회전익 항공기의 실제 음원 데이터를 기반으로 실험을 수행하였다. 각 기체는 엔진·로터 구조·회전수에 따른 고유 음향 패턴을 가지며, 이는 MFCC 변환을 통해 시계열 주파수 패턴으로 추출된다. 데이터 분량은 Table 1에 제시하였다. 원본 신호는 44,100 Hz로 샘플링하고, 실시간 분류를 위해 1초 단위로 분할하여 MFCC 특징 벡터를 생성하였다. 또한 해안 파도, 빗소리, 바람 등 환경 잡음을 포함한 다양한 음향 시나리오를 학습 데이터에 반영해 잡음 환경에서도 성능을 유지하도록 구성하였다. 모든 음원은 라벨링 후 특징 추출을 거쳐, 전체의 80%는 학습, 20%는 검증에 사용하였다.

Table 1. Architectural overview of the four proposed helicopter classification models

Rotary wing	Segments	Signal length (in time)
CH-53	4,857	2h 41m
MI-8	3,177	1h 54m
UH-60	4,693	2h 36m
UH-1	2,857	1h 35m

5.3 성능 비교

본 연구는 MFCC 기반 입력 특성을 다양한 딥러닝 모델로 처리하여 성능을 비교하였다. Fig. 4는 모델의 학습·검증 정확도 변화를, Table 2는 모델의 사이즈와 파라미터 수를 나타낸다. CNN-GRU는 약 80% 정확도를 보였으며, CNN-TCN, SqueezeNet-GRU, SqueezeNet-TCN은 85% - 90%로 더 높은 성능을 기록했다. TCN은 GRU보다 긴 시간의 패턴 학습에 유리했고, SqueezeNet 기반 모델은 CNN 대비 크기와 파라미터 수를 크게 줄이면서도 유사하거나 더 높은 정확도를 달성했다. 이는 fire module과 SE Block이 핵심 음향 특징을 효과적으로 추출하고 불필요한 정보를 배제했기 때문으로 해석된다.




Fig. 4. Training and test accuracy curves for four different model architectures

Table 2. Comparison of model size and parameter count across architectures

Model	Model size (MB)	Parameters
CNN+GRU	4.42	1,138,126
CNN+TCN	3.34	835,534
SQZ+GRU	3.08	743,054
SQZ+TCN	3.71	593,418

Fig. 5는 모델 간 예측 불일치율(divergence rate)을 보여준다. CNN-GRU는 다른 모든 모델과 약 18%로 가장 높은 불일치를 보였으며, 이는 해당 모델이 다른 구조들과 비교해 상이한 특징 표현이나 예측 기준을 학습했음을 보여준다. 반면 SqueezeNet-TCN과 SqueezeNet-GRU 간의 불일치율은 9%로 가장 낮아, 구조적 유사성과 입력 특성에 대한 유사한 처리 방식을 시사한다. 이러한 분석은 각 모델이 상호 보완적 또는 다른 민감도를 기반으로 학습했음을 보여준다.

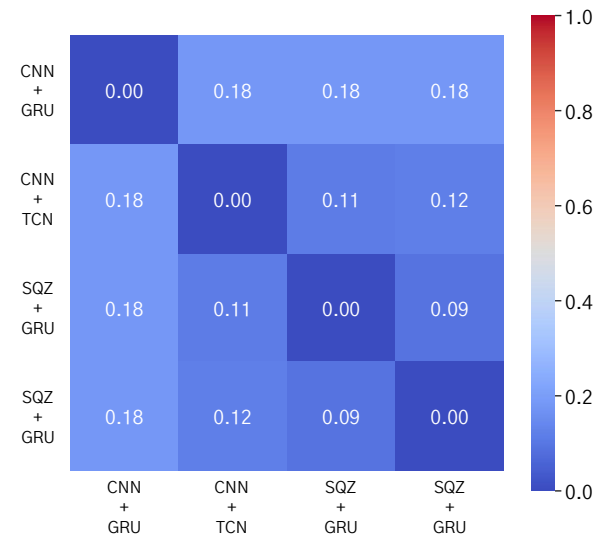


Fig. 5. Divergence rate heatmap showing prediction inconsistency between different model pairs

6. 결론

본 연구는 회전익 항공기의 실시간 분류를 위하여 경량 딥러닝 구조를 설계하고, CNN, TCN, GRU, SqueezeNet을 조합한 모델들의 성능과 효율성을 비교하였다. MFCC 기반의 시간-주파수 음향 정보를 입력으로 사용한 결과, SqueezeNet-TCN은 약 59만 개의 파라미터와 3 MB 이하 크기로 90% 이상의 정확도를 달성했다. CNN-TCN의 경우 더 많은 파라미터를 사용하지만 가장 높은 정확도를 기록했다. 따라서 SqueezeNet-TCN은 경량성과 성능 간 균형을 맞춘 대안, CNN-TCN은 성능 극대화를 위한 대안으로 제시된다.

또한 본 연구는 스트리밍 환경을 고려하여 오디오 데이터를 1초 단위로 분할 처리하는 방식을 적용하였다. 각 세그먼트별로 독립적인 예측을 수행하면서도 TCN과 같은 시계열 처리기를 통해 연속된 구간의

시간적 연관성을 학습함으로써, 실시간 순차 분류를 가능하게 하였다. 실험에는 저주파 기반의 강한 소음 환경도 포함되었는데, 이 조건에서도 모델은 비교적 안정적인 성능을 유지하여 소음이 많은 상황에서도 수동 음향 탐지 방식이 효과적일 수 있음을 보여준다.

아울러 제안된 모델은 자원 제약이 심한 환경에서도 활용할 수 있을 만큼 경량성과 효율성을 갖추고 있다. 작은 모델 크기와 낮은 연산량으로 운용이 가능하다는 특성은 배터리 기반 또는 무전원 감시 센서, 휴대용 표적 식별 장비, TICN 기반 전술 네트워크와 연계된 실시간 경보 체계 등에서의 적용 가능성을 보여준다[23]. 다만 이러한 가능성을 실제로 입증하려면 제안된 모델을 실제 장비에 탑재하고 현장 환경에서 그 성능과 에너지 효율을 검증하는 후속 연구가 필요하다. 결론적으로, 본 연구의 결과는 소형 무기체계, 개인 전투체계, 전방 감시 장비 등 다양한 분야에서 본 모델을 활용할 수 있는 잠재력을 제시하지만, 이를 현실화하기 위해서는 추가적인 실험과 면밀한 검토가 요구된다.

참고문헌

- [1] Mi-8 Helicopter, Global Aviation, <https://globalflyaviation.com/mi-8-helicopter>
- [2] CH-53 Technical Data, Rotorcraft.info, <https://rotorcraft.info/fe/acft/1217>
- [3] Reo Olson, Daniel H. Cress, "Passive Acoustic Range Estimation of Helicopters," Technical Report EL-92-13, U.S. Army Corps of Engineers, 1992.
- [4] Cooling High-Power Radar Systems: A Thermal Technology Guide, Military Embedded Systems, <https://militaryembedded.com/radar-ew/thermal-management/cooling-high-power-radar-systems-a-thermal-technology-guide> (검색일: 2022. 2. 11.)
- [5] 김기태, 임요준, "ISAR 영상 기반 해상표적 식별을 위한 인공지능 연구," 산업시스템학회지, Vol. 45, No. 2, pp. 12-19, 2022.
- [6] 박준형, 박준성, "저불확실성 마이크로 도플러 영상과 초경량 합성곱 신경망을 이용한 소형 드론 분류," IEEE Transactions on Image Processing, DOI: 10.1109/TIP.2024.3388895
- [7] 김태완, 문호석, 김종환, "합성곱 신경망 기반의 헬기 기종 분류 모형 연구," 제어로봇시스템학회 논문지, Vol. 26, No. 6, pp. 479-486, 2020.
- [8] Zhong, Jilong, Fan, Aigen, Fan, Kuangang, Pan, Wenjie, and Zeng, Lu, "Research on the UAV Sound Recognition Method Based on Frequency Band Feature Extraction," Drones, Vol. 7, No. 6, 2023.
- [9] Wijinker, Dirk, van Dijk, Tom, Snellen, Mirjam, de Croon, Guido, and De Wagter, Christophe, "Hear-and-avoid for Unmanned Air Vehicles Using Convolutional Neural Networks," International Journal of Micro Air Vehicles, Vol. 13, pp. 1-15, 2021.
- [10] Bai, Shaojie, Kolter, J. Zico, and Koltun, Vladlen, "An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling," arXiv preprint, arXiv:1603.03947, 2016.
- [11] Davis, S. B. and Mermelstein, P., "Comparison of Parametric Representations for Monosyllabic Word Recognition in Continuously Spoken Sentences," IEEE Transactions on Acoustics, Speech, and Signal Processing, Vol. 28, No. 4, pp. 357-366, 1980.
- [12] Mi-8 Helicopter - Technical Overview, Rotorcraft.info, <https://rotorcraft.info/fe/acft/1224>
- [13] UH-1 Iroquois - Technical Overview, Rotorcraft.info, <https://rotorcraft.info/fe/acft/842>
- [14] 이상현, 이성일, "딥러닝 기반 무인항공기 탐지를 위한 음향 데이터셋 구축에 관한 연구," 디지털콘텐츠학회 논문지, Vol. 25, No. 2, pp. 327-334, 2024.
- [15] Ko, Nuri, Park, Jung-Ju, and Kim, Young-Hwan, "Helicopter Sound Recognition Using Mel-frequency Cepstral Coefficients and Hidden Markov Models," IEEE Transactions on Consumer Electronics, Vol. 59, No. 1, pp. 197-202, 2013.
- [16] Iandola, Forrest N., Han, Song, Moskewicz, Matthew W., Ashraf, Khalid, Dally, William J., and Keutzer, Kurt, "SqueezeNet: AlexNet-level Accuracy with 50x Fewer Parameters and <0.5MB Model Size," arXiv preprint, arXiv:1602.07360, 2016.
- [17] Gandhimathi Alias Usha, S., Maheswari, P. Uma, Priya, M. Jeya, Jeevalakshmi, V. et al., "Lightweight Deep Learning Model for Wireless Capsule Endoscopy Image Classification Using SqueezeNet," Proceedings of the 2025 International Conference on Visual Analytics and Data Visualization (ICVADV), 2025.
- [18] 김현종, 길명선, 문양세, "DGA 도메인 탐지를 위한 LSTM과 GRU 모델 비교," 2021 한국컴퓨터종합학술대회 논문집, 한국정보과학회, pp. 122-124, 2021. 6.
- [19] Bai, Shaojie, Kolter, J. Zico, and Koltun, Vladlen, "An Empirical Evaluation of Generic Convolutional and Recurrent Networks for Sequence Modeling," arXiv preprint, arXiv:1803.01271, 2018.
- [20] Donahue, Jeff, Hendricks, Lisa Anne, Guadarrama, Sergio, Rohrbach, Marcus, Venugopalan, Subhashini, Saenko, Kate, and Darrell, Trevor, "Long-term Recurrent Convolutional Networks for Visual Recognition and Description," Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), pp. 2625-2634, 2015.
- [21] TensorFlow, "tf.keras.losses.SparseCategoricalCrossentropy," https://www.tensorflow.org/api_docs/python/tf/keras/losses/SparseCategoricalCrossentropy

[22] Kingma, Diederik P., and Ba, Jimmy, "Adam: A Method for Stochastic Optimization," Proceedings of the 3rd International Conference on Learning Representations (ICLR), 2015.

[23] 전술통신체계 - C4I/통신, 한화시스템,
<https://www.hanwhasystems.com/kr/business/defense/c5i/communication01.do>