

경량화 CNN을 이용한 저피탐(LPI) 레이더 파형 식별

박세은, 남해운*

한양대학교

seeun0301@hanyang.ac.kr, hnam@hanyang.ac.kr*

LPI Radar Waveform Identification Using Lightweight CNN

Park Seeun, Haewoon Nam*

Hanyang Univ.

요약

본 논문은 4가지 LPI 레이더의 파형(LFM, Barker, Costas, Frank Code)을 식별하기 위해 STFT(Short-Time Fourier Transform) 기반의 시간-주파수 이미지(TFI, Time-Frequency Image)를 입력으로 사용하여 2계층(2-Layer)으로 구성된 경량화 CNN 모델을 통해 학습하였다. 실험 결과, SNR -5dB 이상에서는 100%의 식별 정확도를 보였지만, SNR -10dB에서는 위상 변조 파형(Barker, Frank Code)의 식별 정확도가 저하됨을 확인하였다.

I. 서론

현대 전장 환경에서의 레이더 기술은 적의 탐지 확률을 낮추는 방향으로 발전하고 있다. LPI(저피탐) 레이더는 낮은 피크 전력, 넓은 대역폭, 주파수 가변성 등을 적용하여 레이더 정보 수신기(RWR), 전자 지원(ES) 및 전자 정보(ELINT) 수신기에 의해 탐지되거나 식별되기 어렵게 만든다. 이에 대응하여 아군의 생존성을 확보하기 위해서는 복잡하게 변조된 LPI 신호를 조기에 탐지하고 식별하는 기술이 필수적이다. [1]

최근 딥러닝 기술의 발전으로 LPI 신호를 시간-주파수 이미지(TFI)로 변환하여 식별하는 연구가 활발히 진행되고 있다. 다수의 선행 연구는 고 해상도 이미지를 얻기 위해 CWD(Choi-Williams Distribution)를 주로 사용하였으나, 이는 높은 연산 복잡도로 인해 실시간 처리에 한계가 있다. [2]의 연구 결과에 따르면, CWD는 STFT(Short-Time Fourier Transform) 대비 약 88배 이상의 연산 시간이 소요되어 신속한 대응이 필요한 전술 환경에 부적합할 수 있다. 따라서 실시간성을 최우선으로 하는 시스템에서는 연산 효율이 뛰어난 STFT 기반의 전처리 방식이 요구된다.

또한, 딥러닝 기반의 레이더 신호처리 분야에서 경량화가 중요한 과제로 대두되고 있다. CNN이 LPI 파형 식별에 효과적임은 확인되었으나 [3], 대부분 고성능 GPU와 대규모 데이터셋에 의존한다. 그러나 실제 전장에서의 시스템은 주로 무인기(UAV)나 위성과 같이 전력, 메모리, 연산 자원이 제한된 플랫폼에 배치된다. 고성능 딥러닝 알고리즘의 복잡성은 이러한 임베디드 장치에서의 저전력 및 실시간 처리 요구사항을 충족하기 어렵게 만든다. [4]

이에 본 논문에서는 4가지 LPI 레이더 파형(LFM, Barker, Costas, Frank)을 효율적으로 식별하기 위해, STFT 기반의 시간-주파수 이미지(TFI)와 2계층의 경량화된 CNN 모델을 이용한 식별 기법을 제안한다.

II. 본론

1. 신호 모델 및 전처리

본 논문에서는 LPI 레이더 시스템에서 널리 사용되는 대표적인 펄스 내 변조(Intra-pulse Modulation) 방식 4가지를 선정하였다. 선정된 파형은 주파수 변조 방식인 LFM(Linear Frequency Modulation)과 Costas Code, 그리고 위상 변조 방식인 Barker Code와 Frank Code로 구성된다.

레이더 신호 생성을 위한 시뮬레이션 환경에서 샘플링 주파수는 10MHz, 펄스 폭은 20 μ s로 설정하였다. 각 파형의 세부 파라미터는 LFM의 경우 4MHz의 대역폭(Bandwidth)을 가지며, 이산 코드는 각각 Barker-13, Costas-10, 그리고 Frank-16 ($M=4$)의 길이를 갖도록 설계하였다. 생성된 신호는 윈도우 크기(Window Size)가 64인 STFT를 거쳐 64 \times 64 크기의 시간-주파수 이미지(TFI)로 변환하였다. [그림 1]은 전처리 과정을 거쳐 생성된 4가지 파형의 스펙트로그램 예시를 나타낸다. 또한, CNN의 학습 속도 향상과 계산 안정성을 위해 생성된 스펙트로그램의 픽셀 값을 [0, 1] 범위로 정규화(Normalization)하여 모델의 입력으로 사용하였다.

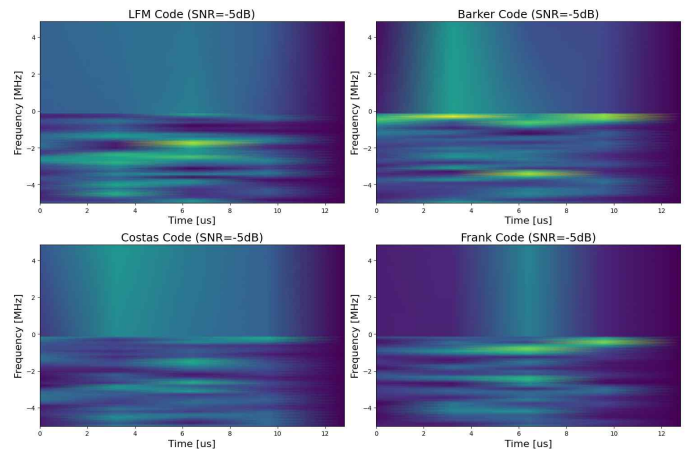


그림 1. 4가지 LPI 파형의 STFT 스펙트로그램 예시

2. 제안하는 경량화 CNN 모델

본 논문에서 제안하는 모델은 [표 1]과 같이 2개의 합성곱 블록(Convolutional Block)과 완전연결 계층(Fully Connected Layer)으로 구성된 경량화 구조이다. 입력 데이터로는 전처리된 64×64 크기의 TFI를 사용하였다. 각 블록은 3×3 커널과 최대 풀링(Max Pooling)을 통해 신호의 지역적 특징(Local Features) 추출 및 차원 축소를 수행하고, 이를 통해 효율적인 연산과 잡음이 심한 환경에서도 정확하게 파형을 구분할 수 있게 하였다. 추출된 2차원 특징 맵들은 1차원 벡터 형태로 평탄화(Flatten)되며, 이 벡터가 완전연결 계층을 통과하면서 최종적으로 4가지 파형 클래스로 식별된다.

모델 최적화를 위해 Adam 옵티마이저(Optimizer)를 사용하였으며, 학습률(Learning Rate)은 0.001로 설정하였다. 손실 함수(Loss Function)는 교차 엔트로피(Cross-Entropy)를 적용하였고, 총 10 에포크(Epochs) 동안 학습을 진행하였다.

표 1. 제안 CNN의 세부 구조

Layer	Output Shape	Kernel / Stride	Parameters
Input	$64 \times 64 \times 1$	—	0
Conv_1	$64 \times 64 \times 16$	$3 \times 3 / 1$	160
Pool_1	$32 \times 32 \times 16$	$2 \times 2 / 2$	0
Conv_2	$32 \times 32 \times 32$	$3 \times 3 / 1$	4,640
Pool_2	$16 \times 16 \times 32$	$2 \times 2 / 2$	0
Flatten	8192	—	0
FC (Output)	4	—	9,220
Total			14,020

3. 시뮬레이션 분석 및 결과

제안 모델의 성능을 검증하기 위해 생성된 2,000개의 데이터셋을 8:2 비율로 무작위(Random)로 나누어 학습 및 테스트 데이터로 사용하였다. 학습 과정에서 모델이 다양한 잡음 환경에 적응할 수 있도록 -5dB 에서 $+5\text{dB}$ 사이의 SNR 조건에서 AWGN 잡음을 추가하여 설정하였다. 테스트는 학습 조건과 동일한 시나리오 1(SNR $-5 \sim 5\text{dB}$)과 모델의 한계 성능을 검증하기 위한 시나리오 2(SNR -10dB)로 나누어 진행하였다.

[그림 2]는 시나리오 1에서의 학습과 테스트의 정확도(Accuracy) 곡선을 나타낸다. 제안 모델은 4 에포크 이후 안정적으로 수렴하는 모습을 보이며, 학습 및 테스트 데이터 모두 100%에 도달하였다. [그림 3(a)]의 파형을 식별하는 혼동행렬(Confusion Matrix)에서는 LPI 레이더의 4가지 파형 모두에서 오분류가 발생하지 않음을 볼 수 있다.




그림 2. 학습-테스트 정확도 곡선 (SNR $-5 \sim 5\text{dB}$)

낮은 SNR 환경(SNR -10dB)인 시나리오 2의 결과([그림 3(b)])를 살펴보면, LFM 파형의 경우 높은 식별률을 보여주나 위상 변조인 Barker와 Frank Code에서는 식별률이 현저히 저하됨을 알 수 있다. 특히 Frank Code의 식별률 저하가 두드러지는데, Frank Code가 위상이 미세하게 변하는 다중 위상(Polyphase) 구조를 가져, BPSK 기반인 Barker Code보다

잡음에 의한 위상 왜곡에 더 민감하기 때문이다. 이는 신호 전처리 과정인 STFT에서 크기(Magnitude) 정보만을 시각화함에 따른 위상(Phase) 정보의 손실을 원인으로 볼 수 있다. 잡음이 높아지는 낮은 SNR 환경에서는 잡음이 위상 변화 패턴을 마스킹(Masking)하기 때문에 식별 정확도가 감소한 것으로 분석된다. 선행 연구 [2]에 따르면, 고해상도 시간-주파수 분포인 CWD는 STFT 대비 높은 해상도를 제공하여 신호의 미세 패턴을 명확히 분리할 수 있다. 따라서 CWD를 적용한다면 낮은 SNR 환경에서의 위상 변조 신호 식별률을 개선할 수 있을 것으로 예상된다. 다만, 본 연구는 임베디드 환경에서의 실시간성을 최우선 목표로 하였기 때문에, 연산 효율이 뛰어난 STFT 기반의 경량화 모델을 제안하였다.




그림 3. LPI 파형 식별 혼동행렬 (a) 시나리오 1 (b) 시나리오 2

III. 결론

본 논문에서는 LPI 레이더 파형을 실시간으로 식별하기 위한 경량화된 딥러닝 모델을 제안하였다. 연산 복잡도가 높은 기존의 CWD 대신 연산 효율이 뛰어난 STFT를 전처리 과정에 적용하였으며, 2개의 계층만으로 구성된 경량 CNN 모델을 설계하여 하드웨어 부담을 최소화하였다. 제안 모델은 SNR -5dB 이상에서는 4가지 주요 파형(LFM, Barker, Costas, Frank)에 대해 100%의 식별 정확도를 달성하였으나, SNR -10dB 에서는 위상 변조 파형(Barker, Frank)의 식별률이 저하되는 한계를 확인하였다. 이는 STFT 기반 전처리 과정에서 위상 정보가 소실되고, 강한 잡음이 파형의 패턴을 마스킹하기 때문으로 분석된다. 향후에는 낮은 SNR 환경에서의 식별 성능을 개선하기 위해, STFT의 연산 효율을 유지하면서도 위상 정보를 효과적으로 활용할 수 있는 추가적인 연구를 진행할 계획이다.

ACKNOWLEDGMENT

본 연구는 2025년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No.2022R1A2C1011862)

참 고 문 헌

- [1] P. E. Pace, "Detecting and Classifying Low Probability of Intercept Radar", Artech House, 2009.
- [2] 이무현, 박성재, 김용철, 조성환, "딥러닝 기반 실시간 LPI 레이다 신호 분류를 위한 효율적인 시간-주파수 표현 기법 연구," 한국산학기술학회논문지, 제26권 제8호, pp. 285-294, 2025.
- [3] S.-H. Kong, M. Kim, L.H. Hoang, and E. Kim "Automatic LPI Radar Waveform Recognition Using CNN," IEEE Access, vol. 6, pp. 4207-4219, 2018.
- [4] Xiangang Gao, Bin Wu, Peng Li and Zehuan Jing, "1D-CNN-Transformer for Radar Emitter Identification and Implemented on FPGA," Remote Sensing, vol. 16, no. 16, p. 2962, 2024.