

# Self-attention을 이용한 저피탐 레이더 파형 분류에 대한 연구

이시호, 김형윤, 무하마드 사지드 하룬\*, 남해운

한양대학교

{siho0201, hynkim, hnam}@hanyang.ac.kr, sajidiui222@gmail.com\*

## Low Probability of Intercept Radar Waveform Classification using Self-attention

Siho Lee, Hyeongyun Kim, Muhammad Sajid Haroon\*, Haewoon Nam

Hanyang Univ.

### 요약

본 논문에서는 self-attention이 결합된 convolutional neural network(CNN) 기반의 저피탐 레이더 변조 분류 모델을 제안한다. 전자전에서 다루어지는 저피탐 레이더는 신호 대 잡음비가 낮아 식별이 어렵다는 특징을 가지고 있어 보다 성능이 뛰어난 레이더 식별 알고리즘이 요구된다. 우리는 이미지 분류 성능을 높이기 위해 입력데이터의 자기 상관성을 뽑아내는 self-attention을 CNN에 결합하였다. 시뮬레이션에서는 12종의 저피탐 레이더 신호와 노이즈만 존재하는 신호를 Choi-Williams Distribution(CWD)알고리즘을 이용하여 시간 주파수 영역의 이미지로 변환시킨 후 모델의 입력 값으로 사용하였다. 제안하는 self-attention이 결합된 CNN 기반의 분류모델은 기존의 CNN만 사용한 분류모델보다 모든 신호 대 잡음비에서 더 높은 분류 성능을 보였다. 특히, 제안된 알고리즘은 기존의 분류모델보다 신호 대 잡음비가 가장 낮은 구간(-12 dB)에서 최대 5%의 분류 성능 향상을 보여주었다.

### I. 서론

전자전(electronic warfare, EW)은 전파되는 전자파의 군사적 응용을 통칭하는 개념으로 크게 전자공격(electronic attack, EA), 전자보호(electronic protection, EP), 전자지원(electronic support, ES)으로 나누어진다. 전자전 분야에서 중요한 부분 중 하나는 아군의 전자파는 적군에게 탐지되지 않게 하고 적군의 전자파를 파악하는 것이다[1]. 전자전에서 이러한 조건을 만족시키기 위하여 일반적인 펄스 레이더보다 낮은 송신 신호 출력을 가지는, 즉 신호 대 잡음비(signal to noise ratio, SNR)가 낮은 저피탐(low probability of intercept, LPI) 레이더를 사용한다. 저피탐 레이더에 linear frequency modulation(LFM), costas, barker 등 다양한 펄스 내 변조(Intra pulse Modulation) 방식이 사용되어 레이더 식별이 더 어려워지게 되었고, 이러한 이유로 레이더 신호의 변조 방식을 구별해내는 연구가 다양한 곳에서 진행되었다.

저피탐 레이더의 펄스 내 변조 방식을 구별하기 위한 대표적인 방법은 레이더 신호가 시간에 따른 주파수 변화가 있다는 점을 이용하여 레이더 신호를 시간 주파수 이미지(time frequency image, TFI)로 변환시킨 후 딥러닝 모델의 입력 값으로 사용하여 이미지 분류문제로 접근하는 것이다[2]. Convolutional neural network(CNN)는 이미지 분류에 사용되는 딥러닝 모델 중 하나로 컨볼루션 필터를 이용하여 이미지의 특징을 추출하고 추출된 특징으로 이미지를 분류한다. 레이더를 시간 주파수 이미지로 변환 시켰을 때, 신호의 변조 방식에 따라 서로 다른 형태의 이미지가 나타나게 되고, CNN은 이미지에 따른 서로 다른 특징 벡터를 추출하여 저피탐 레이더 변조 방식의 분류를 가능하게 한다.

### II. 딥러닝 학습 모델

본 논문에서는 CNN에 self-attention구조를 결합시켜 레이더 변조 방식의 분류성능을 높이는 연구를 진행하였다. Self-attention은 자연어처리 모델 중 sequence to sequence(seq2seq) 모델에 처음 등장했으며 입력 문장의 단어들 사이의 상관성을 나타내는 벡터를 추출하는 역할을 한다. 입력 데이터의 자기 상관성을 뽑아내는 특징을 가지고 있는 self-attention




그림 1. 저피탐 레이더 신호의 시간 주파수 이미지 예시 (a) LFM 0dB (b) LFM -4dB (c) LFM -8dB (d) LFM -12dB (e) Costas 0dB (f) Costas -4dB (g) Costas -8dB (h) Costas -12dB

은 CNN과 결합하여 이미지 분류 문제에 적용시킬 수 있다[3]. 컨볼루션 필터를 통과한 이미지는 지역적인 특징을 가지는 벡터 값을 가지게 되는데 이 특징 벡터를 self-attention 레이어의 입력 값으로 사용하여 특징 벡터들 사이의 연관성을 추출하게 하면 이미지의 지역적인 정보뿐 아니라 전역적인 정보도 나타내는 특징 벡터를 얻을 수 있다.

Attention 메커니즘은 입력 데이터에 대하여 query, key, value라고 지칭되는 동일한 차원을 가지는 3개의 벡터행렬을 만든 후 이 3개의 벡터행렬간의 관계성을 추출하게 된다[4]. Self-attention은 attention을 응용한 것으로 동일한 데이터에 대하여 query, key, value 값이 만들어져 입력 데이터 스스로에 대한 관계성을 추출하게 되고 이는 데이터를 나타내는 새로운 특징으로 사용된다. 컨볼루션 필터를 통과한 이미지의 특징 벡터행렬을  $X$ 라고 하면  $X$ 와 동일한 크기의 크기를 가지는 학습이 가능한 벡터행렬을  $X$ 와 각 벡터 요소별로 곱하여 query(Q), key(K), value(V) 값을 만들어낸다.

$$\begin{aligned} Q &= X \times W_Q \\ K &= X \times W_K \\ V &= X \times W_V \end{aligned} \quad (1)$$

표 1 딥러닝 모델 구조

CNN	CNN + Self-attention
Convolution layer (1, 32, 3, 1, RRelu)	Convolution layer (1, 32, 3, 1, RRelu)
Max pooling layer (2,2)	Self-attention layer(32,32)
Convolution layer (32, 64, 3, 1, RRelu)	Self-attention layer(32,32)
Max pooling layer (2,2)	Self-attention layer(32,32)
Convolution layer (64, 128, 3, 1, RRelu)	Max pooling layer (2,2)
Flatten layer	Convolution layer (32, 64, 3, 1, RRelu)
Dense layer(1024, RRelu)	Max pooling layer (2,2)
Dense layer(128, RRelu)	Convolution layer (64, 128, 3, 1, RRelu)
Dense layer(13)	Flatten layer
	Dense layer(1024, RRelu)
	Dense layer(128, RRelu)
	Dense layer(13)

식(1)의  $W_Q$ ,  $W_K$ ,  $W_V$ 는 각각 query, key, value에 대한 가중치 벡터이다. 이 3개의 벡터행렬 사이의 연관성을 구하는 방식 중 가장 대표적인 것으로 닷-프로덕트 어텐션(dot-product attention)이 있다. 이 방식을 적용한 self-attention 출력 값은 다음과 같다.

$$Attention(Q, K, V) = softmax(\frac{QK^T}{\sqrt{d_k}}) V \quad (2)$$

여기서  $d_k$ 는 key 벡터의 차원을 의미한다.

본 연구에서 LFM, costas, barker, frank, T1~T4, P1~P4 변조 방식이 적용된 레이더 신호와 noise만 존재하는 신호가 학습에 사용되었고 Choi-Williams distribution(CWD) 알고리즘을 사용하여 I/Q 데이터를 시간 주파수 이미지로 변환시켰다. 그림 1은 해당 이미지 예시를 보여준다. 사용한 데이터의 샘플 길이는 1,024이고 0dB부터 -12dB(2dB 간격)까지의 신호 대 잡음비를 가진다. 신호 대 잡음비별 각 신호의 학습데이터는 800개가 사용되었고 테스트데이터는 200개가 사용되었다. 학습데이터로는 모든 신호 대 잡음비의 데이터가 사용되었으며 테스트 단계에서는 신호 대 잡음비별 데이터를 사용하였다.

본 연구에서 사용한 CNN과 CNN에 self-attention을 추가한 모델을 표 1에서 정리하였다. Convolution layer의 입력 파라미터는 순서대로 입력 채널 사이즈, 출력 채널 사이즈, 커널 사이즈, stride, 활성화 함수이고 self-attention layer는 입력 데이터의 크기와 채널 개수가 동일한 convolution layer로 구현하여 attention연산, 층 정규화, residual 연산을 포함시켰다. 손실 함수는 categorical cross entropy를 사용하였고 옵티마이저는 AdamW를 사용하였다. 학습의 에포크는 100으로 설정하고 학습률은 0.001을 초기 값으로 설정하였고 에포크당 이전 학습률에 0.99를 곱한 값으로 조정 되게 하였다.

### III. 시뮬레이션 결과

그림 2는 신호 대 잡음비별 분류 성능 비교 그래프이다. 모든 신호 대 잡음비에서 self-attention을 결합시킨 구조가 더 높은 분류성능을 나타내었다. 가장 높은 신호 대 잡음비인 0dB에서 4.31%의 차이가 발생했고 가장 낮은 신호 대 잡음비인 -12dB에서는 5.07%로 가장 큰 차이가 발생하였다. 추가적으로 confusion matrix를 사용하여 개별 신호에 따른 분류 성능을 확인하였다. 그림 3은 confusion matrix중 신호 대 잡음비가 -10dB에 해당하는 결과이다. 대부분의 신호 분류 성능이 향상되었고 분류 성능이 가장 낮았던 T1 신호의 경우 62%에서 83%로 크게 향상되었음을 확인할 수 있다.




그림 2. 신호 대 잡음비별 분류 성능 비교 그래프

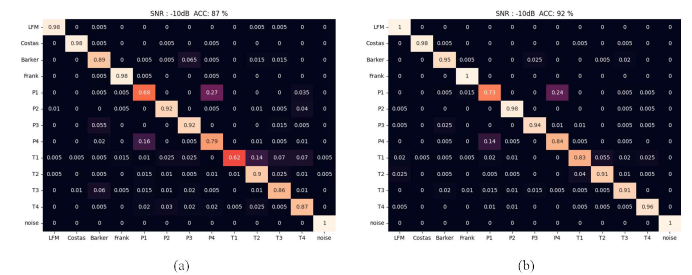


그림 3. 모델에 따른 confusion matrix 예시 (a) CNN (b) CNN + Self-attention

### IV. 결론

본 논문에서는 기존의 CNN에 self-attention 구조를 추가하였을 때 저 피탐 레이더 변조 식별 문제를 해결하는 것에 있어 학습 성능에 어떤 영향을 미치는지 확인하였다. 실험 결과 self-attention을 추가한 구조가 기존의 CNN에 비해 모든 신호 대 잡음비에서 더 우수한 성능을 보였다. Self-attention layer의 추가로 인한 이미지의 전역적인 특징이 학습에 반영되어 분류 성능의 향상을 일으키는 것으로 판단된다. 본 연구 결과를 토대로 생각해보았을 때 self-attention이 전역적인 특징정보를 나타낸다는 점을 이용하여 CNN뿐만이 아닌 다른 딥러닝 모델에도 self-attention을 적용 시켜 학습 성능을 향상시킬 수 있을 것으로 기대된다.

### ACKNOWLEDGMENT

이 논문은 2023년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No. 2019-0-00964, 스펙트럼 쉐런지를 통한 기존 무선국 보호 및 주파수공유 기술개발)

### 참고 문헌

- [1] 박태용, 김완주, “저피탐 (LPI) 레이더 탐제 플랫폼의 피탐 확률 감소에 관한 연구,” Journal of the Korea Institute of Information and Communication Engineering, vol. 18, no. 5, pp. 1243-1248, 2014.
- [2] 김민준, 공승현, “펄스 내 변조 저피탐 레이더 신호 자동 식별,” 한국군사과학기술학회지, vol. 21, no. 2, pp. 133-140, 2018.
- [3] Yuan, Shibo, Peng Li, and Bin Wu, “Towards Single-Component and Dual-Component Radar Emitter Signal Intra-Pulse Modulation Classification Based on Convolutional Neural Network and Transformer,” Remote Sensing, vol. 14, no. 15, 3690, 2022.
- [4] Vaswani, Ashish, et al, “Attention is all you need,” Advances in neural information processing systems, 30, 2017.