

# 전자전 환경에서 전이학습 기반 저피탐 레이더 변조 신호 분류 성능 분석

서 동 호\*, 박 지 연\*, 윤 우 진\*\*,  
 백 지 현\*\*, 이 원 진\*\*, 남 해 운<sup>o</sup>

## Analysis of LPI Radar Waveform Classification Based on Transfer Learning in Electronic Warfare Environment

Dongho Seo\*, Jiyeon Park\*, Woojin Yun\*\*,  
 JeeHyeon Baek\*\*, Wonjin Lee\*\*,  
 Haewoon Nam<sup>o</sup>

### 요 약

최근 저피탐 레이더 기술의 발전에 따라 LPI 레이더 위협 신호의 정확한 탐지 및 변조 방식 분류 기술이 중요한 기술로 대두되고 있다. 특히 레이더 변조 방식 분류에 관한 연구는 딥러닝 기반의 이미지 처리 분야에서도 연구가 활발히 진행되고 있다. 하지만 이러한 딥러닝 기반 기술은 실제 무기체계에 적용하는데 있어 양질의 학습 데이터 확보에 어려움이 존재한다. 본 논문에서는 전자전의 신호 수집환경을 고려하여, 전이 학습을 이용하여 낮은 SNR 환경에서도 레이더 신호 분류 성능을 향상시키는 방법을 제안한다. 제안한 전이 학습 기반의 분류 방법은 -12 dB 환경에서 90% 이상의 분류 성공률을 보임을 확인하였다.

**Key Words** : LPI Radar, Intra-pulse Modulation, CNN, Transfer Learning, Deep learning

### ABSTRACT

As the development of low detection radar technology, accurate detection and modulation classification technology for LPI threat signals is emerging as an important technology. In particular, research on the classification of radar modulation methods has been actively conducted recently by applying deep learning-based image processing technology. However, these deep learning-based approaches have difficulties in securing high-quality learning data when applied to weapon systems. In this paper, we propose a method to improve radar signal classification performance even in a low SNR environment using transfer learning considering the signal reception environment of electronic warfare. It was confirmed that the proposed transfer learning-based classification method showed a classification success rate of over 90% at -12 dB.

### 1. 서 론

최근 다양한 연구 분야에서 머신러닝 기술을 기반으로 한 다양한 연구가 진행되고 있으며, 특히 레이더 신호 처리 분야에서도 딥러닝 기반의 기술 응용 연구가 활발히 진행되고 있다<sup>1-3)</sup>. 하지만 딥러닝 기반 레이더 신호 처리 기술을 실제 무기체계에 적용하는데 있어 양질의 학습 데이터 확보 방안에 대한 이슈가 존재한다. 실제로 레이더 신호 수집은 쉽지 않을뿐더러 수집되는 데이터의 양과 신호 수집환경이 좋지 않아 대체로 낮은 신호 대 잡음비 (signal-to-noise power, SNR) 신호들이 수집된다.

전이 학습(transfer learning) 방식을 이용하면 이러한 학습 데이터 부족의 문제점을 보완할 수 있다. 전이 학습이란 사전학습 모델(pre-trained model)의 일부 혹은 전체 레이어를 원하는 대상 데이터를 이용하여 모델을 재학습 시키는 방식이며, 이미 학습이 완료

\* 이 논문은 2021년 정부(방위사업청)의 재원으로 국방기술진흥연구소의 지원을 받아 수행된 연구임(KRIT-CT-21-033)

\*\* 이 논문은 2021년 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(No.2020-0-01343, 인공지능융합연구센터지원 (한양대학교 ERICA))

• First Author : (ORCID:0000-0003-3192-1315) LIG Nex1, Electronic Warfare R&D center, dongho.seo@lignex1.com, 선임연구원, 정회원

<sup>o</sup> Corresponding Author : (ORCID:0000-0001-9847-7023) Hanyang University Dept. Elec. Eng., hnam@hanyang.ac.kr, 정교수, 정회원 (ORCID:0000-0001-7620-1499) Hanyang University Dept. Elec. Eng., bji0914@hanyang.ac.kr, 학생(석사과정), 학생회원

\*\* LIG Nex1, Electronic Warfare R&D center, woojin.yun@lignex1.com; jeehyeon.baek@lignex1.com; leewonjin@lignex1.com, 정회원  
 논문번호 : 202210-254-C-LU, Received October 24, 2022; Revised November 20, 2022; Accepted November 20, 2022

된 딥러닝 모델의 가중치를 이용하여 새로운 모델을 학습시키기 때문에 end-to-end 학습 방식에 비해 학습에 요구되는 시간이 적고, 추가적으로 적은 학습 데이터를 이용하여 모델의 성능을 향상시킬 수 있다<sup>4,6)</sup>.

본 논문에서는 LPI 레이더의 펄스 내 변조 신호 분류를 위해 시간-주파수 분석(Time-Frequency Analysis, TFA)을 통해 9가지 LPI 펄스 내 변조 방식의 특징을 추출하고 이를 통해 시간-주파수 이미지(Time-Frequency Image, TFI)로 변환하여 ResNet 기반의 딥러닝 모델을 이용한 변조 신호 분류 방법을 제안한다. 또한 전자전의 미약한 수집 환경을 고려하여 전이 학습을 이용하여 낮은 SNR 환경에서도 레이더 신호 분류 성능을 향상시키는 방법을 제시한다.

## II. LPI 레이더 변조 방식 분류 알고리즘

본 논문에서 고려하는 LPI 레이더 펄스 내 변조 신호는 Rect, LFM, Costas code, Barker code, Frank code, P1, P2, P3 및 P4로 총 9가지로, AWGN 환경에서 생성하였다. 전자 지원(Electronic Support) 수신기에서 수집된 신호  $y[k]$ 는 AWGN 환경에서 레이더 신호  $x[k]$ 와 잡음  $n[k]$ 로 구성되며 아래와 같이 나타낼 수 있다.

$$y[k] = x[k] + n[k] = Ae^{j\theta[k]} + n[k], \quad (1)$$

where  $\theta[k] = 2\pi f[k]k + \phi[k]$ .

여기서  $f[k]$ 와  $\phi[k]$ 는 각각 순간 주파수(instantaneous frequency)와 위상 오프셋(phase offset)을 의미한다. 변조 방식에 따라서 주파수 변조의 경우  $f[k]$ 와  $\phi[k]$ 는 각각 상수와 변수가 되고, 위상 변조의 경우엔 반대가 된다. 본 논문에서는 TFA 알고리즘으로 CWD(Choi-Williams Distribution)<sup>7)</sup>를 이용하여 TFI로 변환 후 CNN의 입력으로 사용하였다. CWD를 이용하여 생성한 TFI는 CNN의 입력 크기에 맞추기 위해 bicubic 보간법<sup>8)</sup>을 이용하여  $224 \times 224$ 로 크기를 조정하고 해당 이미지를 gray scale로 변환하는 전처리 과정을 진행하였다.

## III. CNN 기반 전이 학습

기존의 레이더 신호 분류 연구에서는 TFI 특징을 효과적으로 학습시키기 위해 모델 학습에 상대적으로 높은 SNR(-6 dB 이상) 신호를 많이 사용하였다<sup>9,10)</sup>. 하지만 실제 전자전 환경 및 레이더 신호 수집 환경을

표 1. 학습 하이퍼 파라미터  
Table 1. The hyper-parameters for learning

Parameter	Value
Batch size	64
Number of epochs	15
Optimizer	Adam
Learning rate	0.001
Weight decay	1e-6
Patient for early stopping	5

고려한다면 높은 SNR 신호의 수집은 쉽지 않으며, 그 절제적인 데이터의 양도 적기 때문에 실 환경에서는 양질의 데이터를 이용한 신호 분류 모델 학습에 어려움이 존재한다. 전이 학습은 사전 학습된 모델의 신경망 가중치의 전이(transfer parameter)를 이용하여 모델을 학습시키는 방식이다. 전이 학습은 대상 데이터와 유사한 데이터로 사전 학습함으로써, 대상 데이터에 알맞은 가중치 초기화를 시킬 수 있고, 대상 데이터로 레이어를 세부 조정함으로써 성능을 올릴 수 있다<sup>11)</sup>. 본 논문에서는 전자전 환경의 데이터 수집에 대한 실질적 한계점을 고려하여, 전이 학습을 이용한 펄스 내 변조 신호 분류 모델의 성능 향상 방안을 제안한다. 표 1은 모델 학습에 사용한 하이퍼 파라미터를 나타낸다.

## IV. 모의실험 및 결과

본 논문에서는 ResNet18의 입력 레이어와 출력 레이어의 사이즈를 제외하고 동일한 구조의 네트워크로 분류기 모델을 디자인하였다. 모델 학습을 위해 학습 데이터셋은 펄스 내 변조 신호의 SNR을 -14 dB 부터 4 dB 까지 2 dB 단위로 증가시키며 SNR 당 500 개씩 펄스 신호를 생성하여 각각의 LPI 펄스 내 변조 신호는 총 5,000개의 데이터로 이루어져 있으며, 9개의 변조 신호에 대해 총 45,000개의 데이터를 학습에 사용하였다. 이때 사전 학습과 전이 학습을 위해 낮은 SNR 구간의 신호(-14 dB ~ -8 dB; D1)와 높은 SNR 구간의 신호(-6 dB ~ 4 dB; D2)를 구분하여 사용하였다. 사전학습에서는 전체 학습 데이터 셋을 8:2 비율로 나누어 학습과 검증용으로 사용했으며, 테스트를 위해 학습 데이터와 독립적으로 각 변조 신호별로 500 개씩 생성하여 사용하였다.

모의 실험은 D1과 D2 그룹을 이용하여 모델을 사전 학습 시킨 후, 서로 다른 데이터 그룹으로 전이 학습을 진행하였다. 예를 들어 D1 그룹의 데이터 셋을

표 2. 전이학습 방식에 따른 미세 조정.  
Table 2. Fine-tuning according to transfer learning method.

Methodology	
Type1	fine-tuning all layers
Type2	fine-tuning only FC layer

로 사전 학습을 시킨 경우엔 D2 그룹의 데이터 셋을 대상 데이터로 전이학습을 진행하는 방식이다. 표 2는 본 논문에서 사용한 두 가지 전이 학습 방식인 Type1과 Type2를 나타낸다. Type1은 사전 학습 모델의 모든 레이어에 대해 전이 학습을 진행하는 방식이고, Type2는 사전 학습된 모델의 마지막 완전결합층을 제외한 모든 레이어의 학습률을 0으로 조정함으로써, 마지막 완전결합층에 대해서만 가중치를 미세 조정하는 방식이다. 그림 1과 2는 각각 D1과 D2 그룹의 데이터로 사전 학습을 시킨 후 D2 그룹과 D1 그룹으로 전이 학습을 진행한 모델의 LPI 레이더 펄스 내 변조 신호 분류 성공률(percentage of correct classification, pcc)을 나타낸다. Total은 D1과 D2 그룹의 모든 데이터를 이용하여 end-to-end 방식으로 학습을 진행한 경우를 의미한다. 그림 1을 통해 알 수 있듯이 D1 그룹의 데이터로 학습을 진행할 경우, 모델이 -6 dB 이상의 신호에 대해 분류 성능이 향상되지 않는 것을 확인하였다. 해당 학습 모델을 D2를 이용하여 전이 학습을 진행할 경우 -6dB 이상의 신호에 대한 분류 성능이 증가하지만, 오히려 -6dB 이하의 신호에 대한 분류 성능이 떨어짐을 알 수 있다. 반면, 그림 2에서 알 수 있




그림 1. 높은 SNR 신호 데이터로 전이학습을 진행한 LPI 레이더 신호 분류 성능 비교  
Fig. 1. Comparison of LPI radar waveform classification performance via transfer learning with high SNR data.




그림 2. 낮은 SNR 신호 데이터로 전이학습을 진행한 LPI 레이더 신호 분류 성능 비교  
Fig. 2. Comparison of LPI radar waveform classification performance via transfer learning with low SNR data.

듯이 D2 그룹으로 사전 학습을 시킨 후 D1 그룹으로 Type1 방식의 전이 학습을 진행할 경우, SNR= -10 dB 기준에서 D2 그룹으로만 학습한 모델에 비해 분류 성능이 77%에서 95%로 크게 증가함을 확인할 수 있다. 더욱이 D1과 D2 그룹을 모두 사용해 end-to-end 방식으로 학습한 모델(Total)의 성능과 비교해도 -14 dB ~ -12 dB 환경에서 약 7% 이상의 분류 성능이 향상되었다.

### V. 결론

본 논문에서는 딥러닝을 이용한 9가지 LPI 레이더 변조 신호 분류 알고리즘을 소개하였다. 특히, 전자전 환경에서 딥러닝 모델의 학습을 위한 양질의 학습 데이터를 확보하기 어려운 점을 고려하여 딥러닝 기반 변조 분류 모델의 성능을 향상시키기 위해 전이 학습을 이용하는 방법을 제시하였다. 또한 제안한 방법을 시뮬레이션을 통해 검증한 결과, 제안한 전이 학습 기반의 분류 방법은 -12dB에서 90% 이상의 분류 성공률을 보임을 확인하였다. 제안한 분류 방법은 향후 전자전 신호 수집환경에서 사용 가능한 신호 분류 알고리즘 개발에 유용하게 활용될 것으로 기대된다.

### References

[1] M. Kim and S. Kong, "Automatic intrapulse modulated LPI radar waveform identifi-

- cation,” *J. KIMST*, vol. 21, no. 2, pp. 133-140, Apr. 2018.  
(<https://doi.org/10.9766/KIMST.2018.21.2.133>)
- [2] J. Wang, P. Liu, M. She, S. Nahavandi, and A. Kouzani, “Bag-of-words representation for biomedical time series classification,” *Biomed. Signal Process. Contr.*, vol. 8, no. 6, pp. 634-644, Nov. 2013.  
(<https://doi.org/10.1016/j.bspc.2013.06.004>)
- [3] T. Huynh-The, V. -S. Doan, C. -H. Hua, Q. -V. Pham, T. -V. Nguyen, and D. -S. Kim, “Accurate LPI radar waveform recognition with CWD-TFA for deep convolutional network,” in *IEEE Wireless Commun. Lett.*, vol. 10, no. 8, pp. 1638-1642, Aug. 2021.  
(<https://doi.org/10.1109/LWC.2021.3075880>)
- [4] H. Lee, J. Kim, J. Yu, Y. Jeong, and S. Kim, “Multi-class classification using transfer learning based convolutional neural network,” *JKIIS*, vol. 28, no. 6, pp. 531-537, Dec. 2018.  
(<https://doi.org/10.5391/JKIIS.2018.28.6.531>)
- [5] J. Park, Y. Kim, D. Seo, J. Ahn, and H. Nam, “Deep learning-based modulation signal detection scheme via transfer learning for cognitive radio network,” *J. KICS*, vol. 45, no. 10, pp. 91-102, Sep. 2020.  
(<https://doi.org/10.7840/kics.2020.45.10.1708>)
- [6] S. Chung and M. Chung, “Pedestrian classification using CNN’s deep features and transfer learning,” *JICS*, vol. 20, no. 4, pp. 91-102, Aug. 2019.  
(<https://doi.org/10.7472/jksii.2019.20.4.91>)
- [7] H. Choi and W. J. Williams, “Improved time-frequency representation of multi-component signals using exponential kernels,” in *IEEE Trans. Acoustics, Speech, and Sign. Process.*, vol. 37, no. 6, pp. 862-871, Jun. 1989.  
(<https://doi.org/10.1109/ASSP.1989.28057>)
- [8] R. Keys, “Cubic convolution interpolation for digital image processing,” in *IEEE Trans. on Acoustics, Speech, and Sign. Process.*, vol. 29, no. 6, pp. 1153-1160, Dec. 1981.  
(<https://doi.org/10.1109/TASSP.1981.1163711>)
- [9] S. -H. Kong, M. Kim, L. M. Hoang, and E. Kim, “Automatic LPI radar waveform recognition using CNN,” in *IEEE Access*, vol. 6, pp. 4207-4219, Jan. 2018.  
(<https://doi.org/10.1109/ACCESS.2017.2788942>)
- [10] Z. Qu, M. Xiaojie, and Z. Deng, “Radar signal intra-pulse modulation recognition based on convolutional neural network,” *IEEE Access*, vol. 6, pp. 43874-43884, Aug. 2018.  
(<https://doi.org/10.1109/ACCESS.2018.2864347>)
- [11] K. Weimann and Tim O. F. Conrad, “Transfer learning for ECG classification,” *Scientific reports*, vol. 11, no. 1, pp. 1-12, Mar. 2021.  
(<https://doi.org/10.1038/s41598-021-84374-8>)