

딥러닝을 이용한 동일 주파수 대역에 공존하는 통신 및 레이더 신호 분리

정 석 현*, 남 해 운°

Separation of Coexisting Communication and Radar Signals within the Same Frequency Band Using Deep Learning

Suk-hyun Jung*, Hae-woon Nam°

요 약

통신 신호와 레이더 신호가 동일 주파수 대역에서 공존할 때 신호 중첩으로 인한 간섭이 불가피하게 발생하는데, 이로 인해 통신의 품질이 저하된다. 기존의 주파수 필터링 방식은 주파수가 완전히 겹치는 상황에서 성능이 제한적이므로, 이를 해결하기 위해 딥러닝 기반 접근법이 주목받고 있다. 본 논문에서는 중첩된 통신 및 레이더 신호를 분리하기 위해 딥러닝 모델인 U-Net과 Conv-TasNet을 사용하여 비트 오류율(Bit Error Rate, BER)을 통해 성능을 비교하였다. 실험 결과, 전반적으로 Conv-TasNet 방식이 U-Net 방식에 비해 BER이 낮게 나타났지만, 신호 대 간섭 비(Signal-to-Interference Ratio, SIR)가 낮은 환경에서는 U-Net의 BER이 더 낮게 나타났다.

Key Words : Deep learning, Communication signal, Radar signal, Interference, Frequency overlap, Signal separation, U-Net, Conv-TasNet

ABSTRACT

When communication signals and radar signals co-exist in the same frequency band, interference due to

signal overlap inevitably occurs, resulting in degraded communication quality. Traditional frequency filtering methods are limited in performance when the frequencies completely overlap, which has led to the growing attention towards deep learning-based approaches. In this paper, U-Net and Conv-TasNet, deep learning models, are used to separate the overlapped communication and radar signals, and their performance is compared in terms of Bit Error Rate (BER). The experimental results show that, overall, the Conv-TasNet approach yields a lower BER than the U-Net approach. However, in environments with low Signal-to-Interference Ratio (SIR), U-Net shows a lower BER than Conv-TasNet.

1. 서 론

무선 통신 기술의 발전으로 주파수 자원이 한정되면서, 동일 주파수 대역에서 통신 및 레이더 신호가 공존하는 상황이 증가하고 있다. 이러한 중첩 신호는 간섭을 일으켜 통신 품질과 신뢰성을 저하시킬 수 있다^[1]. 주파수 필터링과 같은 기존의 신호 처리 방법은 주파수 영역에서 완전히 겹치는 환경에서 성능이 크게 저하된다는 한계가 있다^[2].

이 문제를 해결하기 위해 딥러닝 모델이 대안으로 떠오르고 있으며, U-Net을 사용한 연구가 진행되고 있다^[3]. 그러나 U-Net은 시간-주파수 변환 후 생성되는 이미지를 이용하기 때문에 변환 과정에서 정보 손실이 발생할 수 있다. 반면 Conv-TasNet은 시간 영역에서 직접 작동하기 때문에 정보 손실을 최소화할 수 있으며, 이전에 음성 분리 분야에서 우수한 성능을 입증한 사례가 있다^[4].

본 논문에서는 U-Net과 Conv-TasNet을 적용하여 동일 주파수 대역에서 통신 신호와 레이더 신호가 중첩된 상황에서의 분리 성능을 비교 분석함으로써, 중첩 신호 환경에서도 통신 신호의 신뢰성과 전송 효율성을 극대화할 수 있는 가능성을 모색한다.

* 본 기술은 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터사업의 연구결과로 개발한 결과물입니다(IITP-2024-RS-2023-00258639).

• First Author : Hanyang University, Department of Applied Artificial Intelligence, jshyun0905@hanyang.ac.kr, 학생(석사), 정희원

° Corresponding Author : Hanyang University, Department of Electronic Engineering, hnam@hanyang.ac.kr, 정교수, 정희원

논문번호 : 202411-288-B-LU, Received November 17, 2024; Revised December 6, 2024; Accepted December 6, 2024

II. U-Net 기반 중첩 신호 분리

2.1 Short Time Fourier Transform

Short Time Fourier Transform (STFT)은 신호를 작은 시간 단위로 나누어 각 구간에 대해 푸리에 변환 (Fourier Transform)을 수행함으로써, 시간에 따른 주파수 변화를 분석할 수 있는 기법이다^[5]. 이를 통해 1차원의 In-phase and Quadrature-phase (I/Q) 신호 데이터를 2차원 시간-주파수 이미지로 변환할 수 있다. STFT의 수식은 다음과 같다.

$$STFT[m, k] = \sum_{n=0}^{N-1} x[n]w[n-m]e^{-j(2\pi kn/N)} \quad (1)$$

$x[n]$ 은 입력 신호, $w[n]$ 은 윈도우 함수이다.

2.2 U-Net

U-Net은 이미지 세그멘테이션을 위해 개발된 인코더-디코더 구조의 딥러닝 모델이다^[6]. U-Net의 인코더 부분은 입력 이미지의 특징을 추출한다. 디코더는 이 추출된 특징을 바탕으로 원래 이미지의 크기로 복원한다. U-Net은 skip connection을 통해 인코더의 세부 정보를 디코더에 전달함으로써 위치 정보 손실을 최소화하기 때문에, 이미지 분할 및 복원에서 뛰어난 성능을 보여주고 있다. 본 논문에서 사용한 U-Net의 구성도는 그림 1과 같다.




그림 1. U-Net의 구성도
Fig. 1. Architecture of U-Net

2.3 U-Net 기반의 중첩 신호 분리 알고리즘

본 논문에서는 U-Net을 사용하여 STFT를 통해 변환된 통신 및 레이더 중첩 신호의 시간-주파수 이미지에서 두 신호를 분리하여 통신 신호를 복원하였고, 알고리즘은 그림 2와 같다. 먼저, 통신 및 레이더 중첩 신호의 I/Q 데이터를 In-phase 부분과 Quadrature-phase 부분으로 분리한 후, 각 부분을 STFT하여 각각의 시간-주파수 이미지를 생성한다. 이후 각 이미지를 개별적인




그림 2. U-Net 기반의 중첩 신호 분리 알고리즘
Fig. 2. Algorithm for separating overlapped signals based on the U-Net

U-Net 모델에 통과시켜 통신 신호의 In-phase 및 Quadrature-phase 부분의 시간-주파수 이미지를 각각 복원시킨다. 마지막으로, 각 복원된 이미지에 STFT의 역변환인 inverse Short Time Fourier Transform (iSTFT)을 적용하여 복원된 통신 신호의 I/Q 데이터를 얻는다.

III. Conv-TasNet 기반 중첩 신호 분리

3.1 Conv-TasNet

Conv-TasNet은 음성 신호 분리에서 뛰어난 성능을 보여준 모델로, 시간 영역에서 직접 신호를 분리함으로써 시간-주파수 변환 방식의 한계를 극복하기 위해 설계되었다^[7]. Conv-TasNet은 인코더, 분리기, 디코더의 세 가지 주요 구성 요소로 이루어져 있다.

인코더는 1차원 컨볼루션을 통해 입력된 혼합 신호를 고차원 특징으로 변환한다. 분리는 Temporal Convolutional Network (TCN)를 통해 신호의 긴 시간적 의존성을 학습하며, 각 소스 신호에 해당하는 마스크를 생성한다. 디코더는 분리기에서 생성된 마스크를 인




그림 3. Conv-TasNet의 구성도
Fig. 3. Architecture of Conv-TasNet

코더 출력에 적용함으로써 각 소스 신호를 시간 영역에서 복원한다. 본 논문에서 사용한 Conv-TasNet의 구성도는 그림 3과 같다.

3.2 Conv-TasNet 기반의 중첩 신호 분리 알고리즘

본 논문에서는 Conv-TasNet을 사용하여 통신 및 레이더 중첩 신호를 각각의 신호로 분리하여 통신 신호를 복원하였고, 알고리즘은 그림 4와 같다. 먼저, 통신 및 레이더 중첩 신호의 I/Q 데이터를 In-phase 부분과 Quadrature-phase 부분으로 분리한 후, 각 부분을 개별적인 Conv-TasNet 모델에 통과시켜 통신 신호와 레이더 신호로 분리한다. 이후, 각각 분리된 통신 신호의 In-phase 부분과 Quadrature-phase 부분을 합산함으로써 복원된 통신 신호의 I/Q 데이터를 얻는다.




그림 4. Conv-TasNet 기반의 중첩 신호 분리 알고리즘
Fig. 4. Algorithm for separating overlapped signals based on the Conv-TasNet

IV. 모의실험 및 결과

4.1 실험 환경

본 논문에서는 통신 신호와 레이더 신호가 동일한 주파수 대역에서 공존하고 있는 상황을 구현하여 실험하였다. 수신기의 중심 주파수는 통신 신호의 중심 주파수에 맞추어져 있으며, 샘플링 레이트는 1MHz이다.

통신 신호의 변조 방식은 Binary Phase Shift Keying (BPSK), Quadrature Phase Shift Keying (QPSK), 16-Quadrature Amplitude Modulation (16-QAM)을 사용하였고, 통신 신호의 대역폭은 250kHz로 설정하였다. 통신 신호의 신호 대 잡음 비(Signal-to-Noise Ratio, SNR)는 10dB로 설정하였으며, 레이더 신호를 간섭으로 고려할 때 통신 신호의 신호 대 간섭 비(Signal-to-Interference Ratio, SIR)의 범위는 -30dB에서 20dB까지로 설정하였다.

레이더 신호의 변조 방식은 Linear Frequency

Modulation (LFM), Frequency Shift Keying (FSK)을 사용하였고, 레이더 신호의 최대 주파수는 통신 신호의 중심 주파수보다 250kHz 높고 최소 주파수는 250kHz 낮다. LFM 신호는 300~1000μs의 주기로 주파수가 선형적으로 증가하고 감소하는 패턴을 반복한다. FSK 신호는 100~500μs의 주기로 주파수 도약(Frequency Hopping)이 발생한다.

U-Net 및 Conv-TasNet 모델을 학습시키기 위해 각 SIR별로 192개의 타임 슬롯 데이터를 사용하였고, 모델의 검증을 위해 각 SIR별로 48개의 타임 슬롯 데이터를 사용하였으며, 각 타임 슬롯 데이터는 1,000개의 I/Q 샘플로 구성되어 있다. 비트 오류율(Bit Error Rate, BER) 그래프의 신뢰도를 높이기 위해 대량의 테스트 데이터를 활용하였으며, 테스트 데이터는 각 SIR에 대하여 통신 신호의 변조 방식별로 1,000,000개의 비트로 구성되어 있다.

U-Net 모델의 입력 데이터는 STFT 이미지 픽셀의 실수 값과 허수 값을 각 채널로 분할하여 저장한 이미지 형태로 $2 \times 128 \times 128$ 의 크기를 가진다. Conv-TasNet 모델의 입력 데이터는 1×1000 의 크기를 가지는 시간축 신호 데이터이다. U-Net 및 Conv-TasNet 모델의 학습을 위해 사용된 하드웨어는 Intel® Xeon(R) Silver 4214R CPU, NVIDIA GeForce RTX 3090 GPU, 125.5 GiB RAM이다. U-Net 및 Conv-TasNet 모델 모두 학습횟수(epoch)는 200, 학습률(learning rate)은 0.0005, 배치 사이즈(batch size)는 64로 설정하였다.

4.2 실험 결과

본 논문에서는 사전에 미리 학습한 U-Net 및 Conv-TasNet 모델을 이용하여 통신 및 레이더 중첩 신호 테스트 데이터에서 통신 신호를 분리하여 복원한 후, 복원된 통신 신호를 복조하여 SIR 및 통신 신호의 변조 방식별로 BER을 계산함으로써 각 모델의 분리 성능을 평가하였다. 그림 5, 그림 6은 각각 In-phase, Quadrature-phase 부분을 학습한 U-Net 모델의 Epoch별 Loss를 나타낸 그래프이고 그림 7, 그림 8은 각각 In-phase, Quadrature-phase 부분을 학습한 Conv-TasNet 모델의 Epoch별 Loss를 나타낸 그래프이다. 그림 9, 그림 10, 그림 11은 통신 신호의 변조 방식이 각각 BPSK, QPSK, 16-QAM일 때의 각 SIR별 BER 성능을 U-Net, Conv-TasNet 모델별로 나타낸 그래프이다. 전반적으로 Conv-TasNet 방식의 BER이 U-Net 방식에 비해 낮게 나타났지만, SIR이 낮은 경우 U-Net 방식의 BER이 더 낮게 나타났다.




그림 5. In-phase 부분으로 학습된 U-Net 모델의 Epoch별 Loss
Fig. 5. Epoch-wise loss of the U-Net model trained on the In-phase component




그림 6. Quadrature-phase 부분으로 학습된 U-Net 모델의 Epoch별 Loss
Fig. 6. Epoch-wise loss of the U-Net model trained on the Quadrature-phase component




그림 7. In-phase 부분으로 학습된 Conv-TasNet 모델의 Epoch별 Loss
Fig. 7. Epoch-wise loss of the Conv-TasNet model trained on the In-phase component




그림 8. Quadrature-phase 부분으로 학습된 Conv-TasNet 모델의 Epoch별 Loss
Fig. 8. Epoch-wise loss of the Conv-TasNet model trained on the Quadrature-phase component




그림 9. 복원된 BPSK 신호의 SIR별 BER
Fig. 9. BER versus SIR of restored BPSK signals




그림 10. 복원된 QPSK 신호의 SIR별 BER
Fig. 10. BER versus SIR of restored QPSK signals




그림 11. 복원된 16-QAM 신호의 SIR별 BER
Fig. 11. BER versus SIR of restored 16-QAM signals

V. 결 론

본 논문에서는 동일 주파수 대역에서 통신 신호와 레이더 신호가 중첩된 환경에서 U-Net과 Conv-TasNet의 신호 분리 성능을 비교하였다. 실험 결과, Conv-TasNet 방식은 U-Net 방식에 비해 전반적으로 낮은 BER을 보이며, 중첩 신호 분리 성능 면에서 더 우수한 결과가 나타났다. 이는 Conv-TasNet이 시간-주파수 변환을 거치지 않고 시간 영역에서 직접 신호를 분리하여, STFT 기반의 U-Net에서 발생할 수 있는 정보 손실을 최소화했기 때문으로 판단된다. 반면, 낮은 SIR에서는 U-Net 방식의 BER이 낮게 나타났다. 이는 SIR이 낮을 때 시간 영역에서는 통신 신호의 형태를 파악하기 어려워 모델의 학습에 제약이 생기지만, 시간-주파수 영역에서는 SIR이 낮은 환경에서도 통신 신호의 형태가 비교적 명확히 나타나 학습이 용이해지기 때

문이다.

향후 연구에서는 다양한 중첩 신호 환경과 더 복잡한 간섭 조건에서 두 모델의 성능을 심층적으로 분석할 예정이다. 이를 통해 각 모델의 장점을 결합하여 다양한 SIR 조건에서도 우수한 성능을 발휘할 수 있는 새로운 알고리즘을 설계하는 것을 목표로 한다. 또한, 실시간 구현 가능성을 고려해 모델을 경량화하는 방향으로 연구를 확장할 계획이다.

masking for speech separation,” *IEEE/ACM Trans. Audio, Speech, and Language Process.*, vol. 27, no. 8, pp. 1256-1266, May. 2019. (<https://doi.org/10.1109/TASLP.2019.2915167>)

References

- [1] S. Haykin, “Cognitive radio: brain-empowered wireless communications,” *IEEE J. Sel. Areas in Commun.*, vol. 23, no. 2, pp. 201-220, Feb. 2005. (<https://doi.org/10.1109/JSAC.2004.839380>)
- [2] H. L. Van Trees, *Optimum Array Processing*, John Wiley & Sons, 2002. (<https://doi.org/10.1002/0471221104>)
- [3] S.-H. Lee, S.-H. Jung, J.-Y. Jung, and H.-W. Nam, “Deep learning-based separation technique for radar-communications overlapping signals,” *J. KICS*, vol. 49, no. 5, pp. 711-717, May. 2024. (<https://doi.org/10.7840/kics.2024.49.5.711>)
- [4] C. Wang, M. Jia, Y. Zhang, and L. Li, “Multi-speaker speech separation under reverberation conditions using Conv-Tasnet,” *J. Advances in Inf. Technol.*, vol. 14, no. 4, pp. 694-700, July. 2023. (<https://doi.org/10.12720/jait.14.4.694-700>)
- [5] J. B. Allen and L. R. Rabiner, “A unified approach to short-time Fourier analysis and synthesis,” in *Proc. IEEE*, vol. 65, no. 11, pp. 1558-1564, Nov. 1977. (<https://doi.org/10.1109/PROC.1977.10770>)
- [6] O. Ronneberger, P. Fischer, and T. Brox, “U-net: Convolutional networks for biomedical image segmentation,” in *MICCAI 2015: 18th Int. Conf., Munich, Germany, Oct. 2015, Proc., Part III 18*, pp. 234-241, Springer Int. Publishing, 2015. (https://doi.org/10.1007/978-3-319-24574-4_28)
- [7] Y. Luo and N. Mesgarani, “Conv-tasnet: Surpassing ideal time-frequency magnitude