

OFDM 시스템을 위한 합성곱 신경망 기반 자동 변조 인식

*송건호, *장민규, *윤동원[†]

*한양대학교 융합전자공학과

dwyoon@hanyang.ac.kr[†]

Convolutional Neural Network-Based Automatic Modulation Recognition for OFDM Systems

*Geonho Song, *Mingyu Jang, *Dongweon Yoon[†]

*Hanyang University

요약

자동 변조 인식(automatic modulation recognition, AMR)은 다양한 협력 및 비협력 통신에서 중요한 기술 중 하나이다. 현재 딥 러닝 기반의 AMR 이 많이 연구되고 있으며, 본 논문은 딥 러닝 알고리즘 중 합성곱 신경망(convolutional neural network, CNN)을 기반으로 한 직교 주파수 분할 다중화(orthogonal frequency division multiplexing, OFDM) 신호의 AMR 을 다룬다. AMR 을 위한 CNN 모델 및 다양한 신호 전처리 방법을 제시하고, 모의 실험을 통해 신호 전처리 방법에 따른 CNN 모델의 AMR 성능을 분석한다.

I. 서론

자동 변조 인식(automatic modulation recognition, AMR)은 수신 신호의 변조 방식을 아무 사전 정보 없이 추정하는 기술로, 현대 무선 통신에서는 인지 무선, 스펙트럼 감시 등의 다양한 협력 및 비협력 통신 상황에서 중요한 기술 중 하나이다[1]. 현재 딥 러닝을 기반으로 한 다양한 단일 및 다중 반송파 변조 방식 신호의 AMR 이 많이 연구되고 있다[2]–[4]. 본 논문은 딥 러닝 알고리즘 중 합성곱 신경망(convolutional neural network, CNN)을 기반으로 한 주파수 분할 다중화(orthogonal frequency division multiplexing, OFDM) 신호의 AMR 을 다룬다. 먼저 시스템 모델을 설명하고, AMR 을 위한 CNN 모델 및 다양한 신호 전처리 방법을 제시한 뒤, 모의실험을 통해 전처리 방법에 따른 CNN 모델의 AMR 성능을 분석한다.

II. 시스템 모델

OFDM 신호의 CNN 기반 AMR 의 시스템 모델은 그림 1 과 같다. 먼저 송신 OFDM 신호 $s(k)$ 가 채널을 통과하여 수신기에 도달하며, 이때 수신 OFDM 신호 $r(k)$ 는 다음과 같이 나타낼 수 있다.

$$r(k) = s(k) * h(k) + n(k) \quad (1)$$

여기서 $h(k)$, $n(k)$ 는 각각 채널 임펄스 응답과 가산성 백색 가우시안 잡음(additive white Gaussian noise, AWGN)을 나타낸다. 그 다음 수신기에서 $r(k)$ 를 전처리하여 CNN 모델에 입력하기 적합한 데이터로 변환한 뒤, 그것을 CNN 모델에 입력하여 변조 방식을 분류한다.



그림 1. OFDM 신호의 CNN 기반 AMR 의 시스템 모델

III. AMR 을 위한 CNN 모델 및 신호 전처리 방법

본 논문에서는 AMR 을 위해 그림 2 와 같은 CNN 모델을 제시한다. 여기서 $\text{Conv2d}(C, (H, W))$ 는 $H \times W$ 커널 C 개를 사용하는 합성곱층, $\text{Linear}(U)$ 는 유닛이 U 개인 완전연결층을 나타낸다. 또, BN, Dropout(p), PReLU, Softmax 는 각각 배치 정규화, 확률 p 의 드롭아웃, parametric rectified linear unit 활성화 함수, softmax 활성화 함수를 나타낸다.




그림 2. CNN 구조

본 논문에서는 in-phase and quadrature (I/Q) 구분 전처리, 진폭 및 위상(amplitude and phase, A/P) 전처리, 이산 푸리에 변환(discrete Fourier transform, DFT) 전처리, 혼합 표현의 총 4 가지 방법으로 $r(k)$ 를 전처리하여 CNN 모델에 입력하기 적합한 데이터로 변환한다. I/Q 구분 전처리는 $r(k)$ 를 실수부와 허수부로 분해하여 다음과 같은 2 차원 배열로 변환하는 것이다.

$$R_{I/Q}(k) = [\text{Re}\{r(k)\} \quad \text{Im}\{r(k)\}]^T \quad (2)$$

여기서 T 는 전치 연산자를, $\text{Re}\{\cdot\}$ 와 $\text{Im}\{\cdot\}$ 는 복소수의 실수부와 허수부를 나타낸다. A/P 전처리는 $r(k)$ 를 크기와 위상으로 분해하여 다음과 같은 2 차원 배열로 변환하는 것이다.

$$R_{A/P}(k) = [|r(k)| \quad \text{Arg}\{r(k)\}]^T \quad (3)$$

여기서 $\text{Arg}\{\cdot\}$ 는 복소수의 주편각을 나타낸다. DFT 전처리는 $r(k)$ 의 DFT 를 실수부와 허수부로 분해하여 다음과 같은 2 차원 배열로 변환하는 것이다.

$$R_{DFT}(k) = [\text{Re}\{R(k)\} \quad \text{Im}\{R(k)\}]^T \quad (4)$$

여기서 $R(k)$ 는 $r(k)$ 의 DFT 를 나타낸다. 혼합 표현은 (2), (3), (4)중 서로 다른 2 개 이상을 결합하여 3 차원 이상의 배열로 변환하는 것이다.

IV. 모의실험 및 성능 분석

제시한 CNN 모델의 신호 전처리 방법에 따른 AMR 성능을 분석하기 위하여 다음과 같은 모의실험을 진행하였다. 모의실험에서는 OFDM 신호 생성을 위해 MATLAB 을 사용하였고 CNN 구현을 위해 PyTorch 라이브러리를 사용하였다. 변조 방식으로는 BPSK, QPSK, 8PSK, 16QAM, 64QAM 를 가정하였으며 송신 OFDM 신호는 부반송파 개수 16, 고속 푸리에 변환 길이 256, cyclic prefix 길이 64 를 고려하였다. 송신 채널로는 Rician K-factor 20, 도플러 편이 주파수 500Hz 인 라이시안 페이딩 채널을 가정하였다. 각 전처리 방법에 따라 수신 신호 대 잡음 비(signal-to-noise ratio, SNR) 범위가 [0, 2, ..., 20] dB 이고 SNR 마다 변조 방식 당 샘플 개수가 각각 1,000 과 200 인, 즉 총 샘플 개수가 각각 105,000 과 21,000 인 훈련 세트와 검증 세트로 CNN 모델을 훈련 및 검증하였으며, 훈련된 CNN 모델을 [-10, -5, ..., 30] dB 의 SNR 범위에서 테스트하였다. 이때 SNR 마다 변조 방식 당 샘플 개수가 3,000, 즉 총 샘플 수가 15,000 인 테스트 세트를 사용하였다.

그림 3 은 I/Q, A/P, DFT, I/Q+DFT, I/Q+ A/P+ DFT 의 5 가지 전처리 방법에 대한 CNN 모델의 AMR 성능을 테스트 정확도로 나타낸 것이다. 그림 3 으로부터 분류 정확도 90%를 기준으로 I/Q 와 I/Q+DFT 전처리의 성능이 가장 좋은 것을 확인할 수 있다.




그림 3. 전처리 방법에 따른 AMR 성능

V. 결론

본 논문에서는 CNN 기반 OFDM 신호의 AMR 을 위한 CNN 모델을 제시하고 다양한 신호 전처리 방법에 따른 CNN 모델의 AMR 성능을 분석하였다. 모의실험을 통해 I/Q 와 I/Q+DFT 전처리가 가장 높은 성능을 나타내는 것을 확인하였다. 향후에는 더 다양한 채널 환경, 변조 방식, 신호 전처리 방법을 고려하여 AMR 연구가 진행되어야 할 것이다.

ACKNOWLEDGMENT

이 논문은 2021 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임(2019-0-00964, 스펙트럼 쉐어링을 통한 기존 무선국 보호 및 주파수 공유기술 개발)

참 고 문 헌

- [1] S. Peng and Y.-D. Yao, "A survey of modulation classification using deep learning: signal representation and data preprocessing," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 33, no. 12, pp. 7020-7038, Dec. 2022.
- [2] J. Lee, J. Kim, B. Kim, D. Yoon, and J. Choi, "Robust automatic modulation classification technique for fading channels via deep neural network," *Entropy*, vol. 19, no. 9, pp. 454, Aug. 2017.
- [3] S. Peng, H. Jiang, H. Wang, H. Alwageed, Y. Zhou, M. M. Sebdani, and Y.-D. Yao, "Modulation classification based on signal constellation diagrams and deep learning," *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 30, no. 3, pp. 718-727, Mar. 2019.
- [4] S. Hong, Y. Zhang, Y. Wang, H. Gu, G. Gui, and H. Sari, "Deep learning-based signal modulation identification in OFDM systems," *IEEE Access*, vol. 7, pp. 114631-114638, 2019.