

OFDM 시스템에서 딥 러닝 기반 변조 식별

*신정완, *송건호, *장민규, *윤동원[†]

*한양대학교 융합전자공학과

[†]dwyoon@hanyang.ac.kr

Deep Learning-based Modulation Identification in OFDM Systems

*Jeongwan Shin, *Geonho Song, *Mingyu Jang, and *Dongweon Yoon

*Department of Electronic Engineering, Hanyang University

요약

자동 변조 분류는 무선 인지, 스펙트럼 감시 등의 비협력 통신 상황에서 가장 중요한 기술 중 하나이다. 본 논문에서는 직교 주파수 분할 다중화(OFDM, orthogonal frequency division multiplexing) 시스템에서 딥 러닝 기반으로 변조 방식을 자동으로 분류하고 식별 성능을 분석한다. OFDM 신호의 변조 분류를 위해 합성곱 신경망을 기반으로 변조 식별 신경망 구조를 설계하고 모의 실험을 통해 기존 논문 보다 향상된 변조 식별 정확도 성능을 가짐을 보인다.

I. 서론

직교 주파수 분할 다중화(OFDM, orthogonal frequency division multiplexing)는 높은 스펙트럼 효율과 페이딩, 간섭 등의 완화 효과 때문에 무선 통신 시스템에서 중요한 기술 중 하나로 알려져 있다. 또한 무선 통신 기술이 빠르게 발전함에 따라 다양한 분야에서 비협력 통신이 보편화 되고 있다. 비협력 통신 상황에서는 송신 신호에 대한 변조 방식을 수신부에서 알지 못한다. 따라서 수신 신호로부터 정보를 얻기 위해 수신부는 수신 신호만을 이용하여 송신부에서 사용한 변조 방식을 추정해야 한다. 이에 따라 비협력 통신 상황에서는 수신 신호만을 이용하여 변조 방식을 분류하는 자동 변조 분류(AMC, automatic modulation classification)기술이 필요하다.

전형적인 AMC 기술은 우도 기반 AMC 와 특징 값 기반 AMC 가 있다[1], [2]. 우도 기반 AMC 는 최적의 성능을 제공하지만 높은 복잡도로 인하여 활용에는 한계가 있으며 특징 값 기반 AMC 는 변조 분류를 위한 특징 값을 선정해야 한다는 문제점이 있다. 이를 극복하기 위해 최근에는 LSTM, ResNet 과 같은 다양한 딥 러닝 기법에 기반한 AMC 연구가 활발히 진행되고 있다[3]-[8].

본 논문에서는 OFDM 시스템에서 합성곱 신경망(CNN, convolutional neural network) 기반의 AMC 방법을 제안하고 분류 성능을 분석한다. 이를 위하여 수신 신호 샘플을 이용해 CNN 모델을 훈련하고 훈련된 모델을 이용하여 수신 OFDM 신호의 변조 방식을 분류한다. 모의 실험을 통해 제안한

방법의 성능을 분석하고 제안한 방법이 기존 방법보다 우수한 변조 식별 정확도를 가짐을 보인다.

II. CNN 기반 AMC

본 논문에서는 비협력 통신 상황에서 송신 OFDM 신호가 페이딩 채널을 통과하였다고 가정한다. 이 때 수신 신호는 다음과 같이 나타낼 수 있다.

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

여기서 $r(k)$, $x(k)$, $h(k)$, $n(k)$ 는 각각 수신 신호, 송신 신호, 페이딩 채널의 임펄스 응답, 가산성 백색 가우시 잡음을 나타낸다.

수신 신호의 IQ (in-phase and quadrature phase) 성분을 분리하면 다음과 같은 수신 신호 IQ 배열을 얻을 수 있다.

$$R(k) = \begin{bmatrix} \text{Re}\{r(k)\} \\ \text{Im}\{r(k)\} \end{bmatrix} \quad (2)$$

여기서 $\text{Re}\{\}$ 와 $\text{Im}\{\}$ 은 각각 실수부와 허수부를 나타낸다. 본 논문에서는 (2)와 같은 형태의 배열을 CNN 구조의 입력으로 사용한다.

그림 1 은 본 논문에서 사용하는 CNN 구조를 나타낸다. 제안하는 CNN 구조는 입력층, 2 개의 합성곱층, 3 개의 완전 연결층, 그리고 출력층으로 구성되어 있다. 입력층에서는 (2)와 같은 형태의 배열을 이용하여 $2 \times 1,920$ 크기의 행렬을 한 샘플로 입력한다. 첫 번째 합성곱층에는 128 개의 합성곱 커널이 있고 합성곱 커널 행렬의 크기는 1×320 이다. 두 번째 합성곱층은 크기가 2×8 인 합성곱 커널 64 개가 있다. 완전 연결층의 뉴런의 수는 각각 256, 128, 4 이다. 출력층에서는 변조 분류 결과가 출력된다. 마지막 완전 연결층에서는 확률 분포 값을

언기 위해 Softmax 함수를 활성화 함수로 사용하였으며 이를 제외한 나머지 완전 연결층과 합성곱 층에서는 활성화 함수로 PReLU 함수를 사용하였다. 또한 과적합을 방지하고 더 안정적인 학습을 위해 배치 정규화와 드롭아웃을 적용하였다.




그림 1. AMC 를 위한 CNN 구조




그림 2. 변조 식별 정확도

III. 모의 실험 및 성능 분석

제안한 AMC 방법의 변조 식별 정확도 성능을 분석하기 위하여 다음과 같은 모의 실험을 진행하였다. 모의 실험에서는 CNN 구현을 위해 Keras, Tensorflow 2.4 와 Python 3.7 을 백엔드로 사용하였으며, 신경망을 최적화하기 위해 모멘텀을 포함한 확률적 경사 하강법을 채택하였다. 100 번의 epoch 에 대해 CPU Intel Xeon E5-2690 v4 6 개와 NVIDIA Tesla V100 1 GPU 가 포함된 플랫폼을 사용하였고 약 40 분의 훈련시간이 소요된다. 데이터셋은 Matlab 으로 생성하였고, 디지털 선형 변조 중 4 가지의 변조 방식(BPSK, QPSK, 8PSK, 16QAM)이 고려되었다. OFDM 신호는 기존 논문 [7]과의 비교를 위해 부 반송파 16 개, 푸리에 변환 크기 256, cyclic prefix 길이 64 로 가정하였다. 채널은 라이시안 페이딩 채널, 도플러의 편이 주파수

500hz, Rician K-factor 20 을 가정하였다. 신호대 잡음비 (SNR)는 -5~30dB 사이에서 무작위로 생성하였다. 각 변조 방식마다 17,000 개의 데이터 샘플이 있고, 각각의 데이터는 14,000/3,000 으로 트레이닝 및 검증 샘플로 나뉜다.

모의 실험 결과에 따른 변조 분류 정확도는 그림 2 와 같다. 그림 2 에서 볼 수 있듯이 제안한 AMC 방법은 변조 식별 정확도 90%를 기준으로 기존 논문 [7] 대비 약 5dB 우수한 성능을 나타내는 것을 확인할 수 있다.

IV. 결론

본 논문에서는 OFDM 시스템에서 CNN 기반의 AMC 방법을 제안하고 분류 성능을 분석하였다. 모의 실험을 통해 제안한 AMC 방법이 기존 논문에 비해 우수한 변조 식별 성능을 나타내는 것을 확인하였다. 향후에는 다양한 채널 환경과 변조 방식을 고려하여 AMC 연구가 진행되어야 할 것이다.

참 고 문 헌

- [1] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "A Survey of automatic modulation classification techniques: classical approaches and new trends," *IET Commun.*, vol. 1, pp. 137-156, 2007.
- [2] H.-C. Wu, M. Saquib, and Z. Yun, "Novel automatic modulation classification using cumulant features for communications via multipath channels," *IEEE Trans. Wireless Commun.*, vol. 7, no. 8, pp. 3098-3105, Aug. 2008.
- [3] S. Kim and D. Yoon, "Automatic modulation classification in practical wireless channels," in *Proc. ICTC*, Jeju, Korea, 2016, pp. 915-917.
- [4] 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.
- [5] J. Lee, B. Kim, J. Kim, D. Yoon, and J. Choi, "Deep neural network-based blind modulation classification for fading channels," in *Proc. ICTC*, Jeju, Korea, 2017, pp. 552-555.
- [6] Y. Wang, J. Yang, and G. Gui, "Data-driven deep learning for automatic modulation recognition in cognitive radios," *IEEE Trans. Veh. Technol.*, vol. 68, no. 4, pp. 4074-4077, Apr. 2019.
- [7] 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.
- [8] J. Shi, S. Hong, C. Cai, Y. Wang, H. Huang, and G. Gui, "Deep learning-based automatic modulation recognition method in the presence of phase offset," *IEEE Access*, vol. 8, pp. 42841-42847, 2020.