

# 페이딩 환경에 강인한 디지털 통신 변조 기법 자동 분류 딥러닝 모델

이동규, 한동석\*

대학원 전자전기공학부, 경북대학교

jasmindoe@knu.ac.kr, \*dshan@knu.ac.kr

## Channel Adaptive Deep Learning-based Automatic Modulation Classification Robust in Fading Environments

Dong Gyu Lee, Dong Seog Han\*

Graduate School of Electronic and Electrical Engineering, Kyungpook National University

### 요 약

본 논문에서는 다양한 채널 환경의 영향으로 발생하는 페이딩 환경에 강인한 딥러닝 기반 자동 변조 분류 기법을 제안한다. 기존 딥러닝 기반 자동 변조 분류 모델과 다르게 제안하는 모델은 다중 경로와 동기화 옵셋으로 인하여 채널 환경에 따른 분류 특성이 달라지거나 발생하는 성능 열화를 해결하고자 한다. 본 논문에서는 채널 분류를 위한 학습을 통해 획득한 채널 특성을 자동 변조 분류 학습에 전이시켜 혼합된 채널 환경에서 성능을 높였고 다양한 채널 환경에서 자동 변조 분류를 위해 재학습형 모델 구조로 향상된 성능을 보인다.

### I. 서론

기존의 통계적 AMC(Automatic modulation classification)[1] 접근 방식은 신호의 변조 방식 후보군과 수신 신호 간의 일치 가능성을 계산하는 기법과 HOC(high-order cumulant)와 HOS(high-order statistics) [2]와 같은 전처리된 특징을 추출하는 기법이 있다.

특징 추출 기법은 SVM(support vector machine)과 KNN(K-nearest neighbour)으로 전문적인 특징들을 추출하여 이들 간의 관계와 변조 방식에 따른 분포도를 기계적 학습방법으로 신호를 분별하였다 [3]. 최근에는 딥러닝 기반의 AMC 기법들이 제안되고 있는데 해당 기법들은 딥러닝 기법을 적용하여 수신 신호로부터 전처리된 특징을 추출하지 않고 시간 영역에서의 샘플된 신호를 입력으로 사용한다. 수신 신호의 시간 영역에서 IQ(in-phase and quadrature phase) 신호로부터 변조 분류 특징을 추출하기 위하여 일차원으로 변형된 CNN(convolutional neural network) 커널을 사용하여 높은 분류 정확성을 달성하였다 [5]. 그리고 시계열 신호에 대한 분류 정확성이 뛰어난 LSTM(long-short term memory)기반의 AMC 기법은 A/P(amplitude and phase) 신호를 사용하여 CNN 기반 시스템보다 계산량을 대폭 감소시켜 임베디드 시스템에서 구현이 가능해졌다 [6]. 그러나 이러한 기존 딥러닝 기반 AMC 시스템은 다중 경로 및 동기화 옵셋으로 발생하는 신호의 왜곡으로 인하여 분류 정확성이 떨어지는 문제점을 가진다.

본 논문에서는 채널 적응형 재학습 딥러닝 구조를 제안하여 혼합된 채널 환경에서 채널 특성으로 인한 변조 분류 성능 저하를 해결하고자 한다. 모의실험을 통해 제안하는 모델이 기존의 딥러닝 기반 AMC 시스템들보다 향상된 성능을 보였다.

### II. 제안하는 모델 및 모의실험 결과

송신 신호는 다중 경로 등으로 인한 페이딩 채널 환경을 통과할 경우 수

신기에서 왜곡이 발생한다. 그렇기 때문에 AMC 시스템은 채널 특성에 따른 수신 신호의 특성을 추출해야 한다. 우선적으로 수신 신호의 특성을 추출하기 전에 채널 상태를 인지하는 것이 필요하다. 본 논문에서 제안하는 모델은 2 단계로 구성된 모델을 제안한다.

그림 1은 제안한 딥러닝 기반 AMC 구조의 전체 개념도를 나타낸다. 첫 번째 단계에서는 채널 상태를 파악하기 위해 통과한 채널 상태를 분류하는 과정으로 각 CNN 레이어의 학습이 진행된다. 해당 과정에서 총 2개의 잔차 연결을 통해 다양한 환경을 학습하는 도중 발생하는 망각을 최소화하고 학습 성능을 높인다. 입력으로는 채널을 통과한 수신 신호가 되고 학습이 완료되면 해당 뉴런들은 채널 변화에 따른 분포도를 추출한다.

2단계에서는 다양한 채널 환경에 대한 자동 변조 분류를 학습하게 된다. 학습을 진행하기 전에 1단계에서 학습이 완료된 뉴런들을 고정시킨다. 이후 해당 뉴런들은 자동 변조 분류를 위한 CNN 레이어들과 평행 결합이 된다.

2단계의 CNN 구조는 1단계의 레이어와 유사한 구조를 가지지만 추가적으로 이전 학습과 현재 학습을 융합하는 레이어가 추가된다. 이를 통해 채널 환경에 따라 다양하게 존재하는 변조들을 학습하며 발생하는 망각을 최소화하여 성능을 향상시킨다.

최종적으로 채널 특성을 추출하는 1단계 레이어들의 뉴런 결과가 2단계 레이어들의 뉴런에 전이되어 채널 환경에 따른 자동 변조 분류의 향상된 성능을 보인다.

모의실험은 서로 다른 길이를 가지는 OFDM 신호와 각 부반송파에 사용된 변조 방식으로 QPSK, 16-QAM, 32-QAM, 64-QAM을 사용한 수신된 신호의 분류 성능을 분석한다. 유효 심볼의 길이가 다른 OFDM 신호를 생성하기 위하여 동일한 대역폭에서 주파수 영역에서의 부반송파의 수를 변화하였다. 채널 환경은 AWGN(additive white Gaussian noise) 채널과 3개의 다중 경로로 이루어진 Rayleigh 채널로 3탭으로 구성 FIR(finite impulse response) 필터를 모델링하여 채널 환경을 구성하였다.

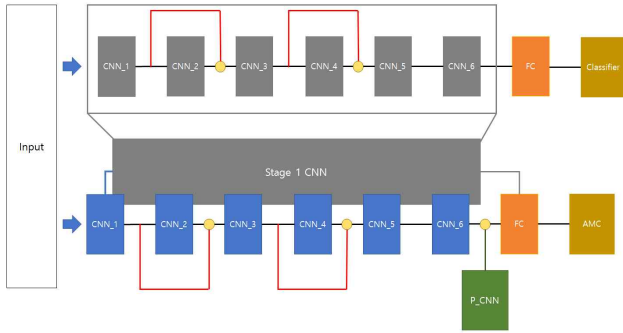


그림. 1. 제안하는 딥러닝 기반 디지털 통신 변조 자동 분류 모델

SNR(signal-to-noise ratio) 범위는  $-30\text{dB}$ 에서  $30\text{dB}$ 으로 설정하여 제안하는 모델의 성능을 분석하였다. 딥러닝 구조를 학습하고 테스트에 사용된 데이터 크기는 약 50,000 프레임으로 구성하였고, 학습방법은 SGDM(stochastic gradient descent with momentum)을 통해, 초기 학습률은 0.01으로 설정하여 10번째 학습 에포크마다 이전 학습률의 10분의 1만큼 줄이면서 학습을 진행하였다.

그림 2는 SNR에 따른 기존 딥러닝 방식의 AMC 시스템과 제안하는 모델을 기반한 AMC 시스템의 분류 성능을 나타낸다. 각 딥러닝 구조는 학습 과정에서 AWGN 채널과 Rayleigh 채널을 통해 성능을 비교하였다. 기존 IQ-FWB-CNN과 제안하는 모델의 IQ-FWB-CNN의 입력 샘플의 수는 4096으로 동일하고 FFT 처리기는 4개를 사용하였다.

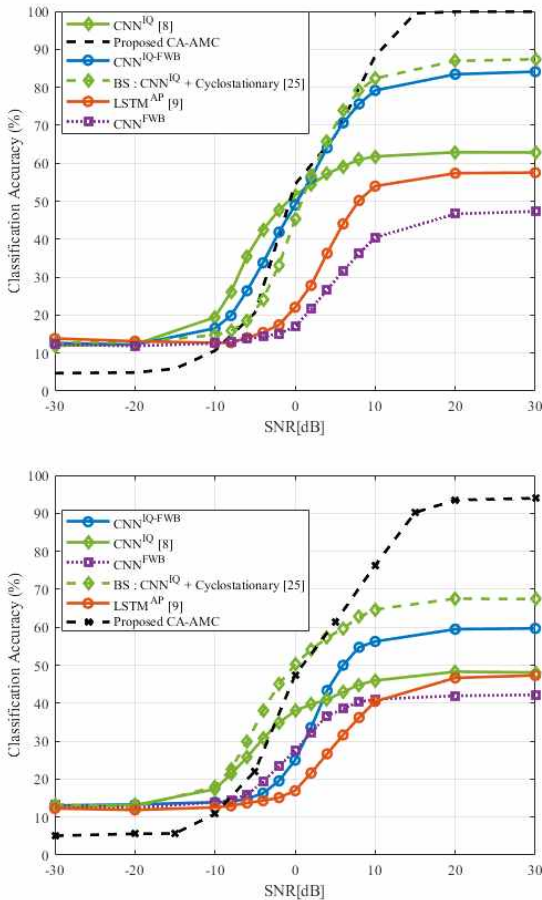


그림. 2. AWGN 채널 환경과 Rayleigh 채널환경에서 SNR에 따른 기존 DL 기법과 제안한 딥러닝 모델 기반 AMC 분류 성능

#### IV. 결론

본 논문에서는 기존 딥러닝 기반의 AMC 시스템이 가지는 한계점을 극복하기 위해 2단계 구조의 학습과 잔차 연결 및 재학습 구조를 사용한 모델을 제안하였다. 제안 모델을 통해 채널 환경에 따른 자동 변조 모의실험을 통해 기존 딥러닝 기반의 AMC 시스템보다 향상된 성능 향상을 보였다.

#### ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터지원사업의 연구결과로 수행되었음 (IITP-2022-2020-0-01808)

#### 참고 문헌

- [1] C. D. Alwis, A. Kalla, Q.-V. Pham, P. Kumar, K. Dev, W.-J. Hwang, and M. Liyanage, "Survey on 6G frontiers: Trends, applications, requirements, technologies and future research," *IEEE Open J. Commun. Soc.*, vol. 2, pp. 836 - 886, 2021.
- [2] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "Blind modulation classification: A concept whose time has come," in *Proc. IEEE Sarnoff Symp.*, 2005, pp. 223 - 228.
- [3] W. Gardner, "Signal interception: a unifying theoretical framework for feature detection," *IEEE Trans. Commun.*, vol. 36, no. 8, pp. 897 - 906, 1988.
- [4] B. Kroon, S. Bergin, I. O. Kennedy, and G. O'Mahony Zamora, "Ste adystate RF fingerprinting for identity verification: One class classifier versus customized ensemble," in *Proc. Artif Intell. Cogn. Sci.*, 2010, pp. 198 - 206.
- [5] T. J. O'Shea, J. Corgan, and T. C. Clancy, "Convolutional radio modulation recognition networks," in *Proc. Int. Conf. Eng. Appl. Neural Netw.*, pp. 213 - 226, 2016.
- [6] S. Rajendran, W. Meert, D. Giustiniano, V. Lenders, and S. Pollin, "Deep learning models for wireless signal classification with distributed low-cost spectrum sensors," *IEEE Trans. on Cogn. Commun. Netw.*, vol. 4, no. 3, pp. 433 - 445, 2018.
- [7] He, Kaiming, Xiangyu Zhang, Shaoqing Ren, and Jian Sun. "Deep residual learning for image recognition." In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pp. 770-778. 2016.