

OFDM 시스템에서 오토인코더 기반 비정상 탐지 성능 분석

*최윤철, *마이클 치솜, *장민규, *윤동원[†]
*한양대학교 융합전자공학과

[†]dwyoon@hanyang.ac.kr

Performance Analysis of Autoencoder Based Anomaly Detection in OFDM Systems

*Yooncheol Choi, *Onyekwelu Michael Chisom, *Mingyu Jang, and *Dongweon Yoon[†]
*Department of Electronic Engineering, Hanyang University

요약

최근 비협력 통신 상황에서 딥러닝 기반의 자동 변조 분류(automatic modulation classification, AMC) 기술이 연구되고 있다. 이 때 딥러닝 기반의 AMC 는 훈련되지 않은 비정상 데이터에 취약하다는 단점이 있다. 본 논문에서는 오토인코더 기반의 직교 주파수 분할 다중화 신호의 비정상 탐지 기법을 제안하고 탐지 성능을 분석한다.

I. 서론

직교 주파수 분할 다중 방식(orthogonal frequency division multiplexing, OFDM)은 디지털 통신에서 기저대역 신호를 전송하기 위한 다중화 체계로 광범위하게 사용되어 왔으며 현재 LTE/NR 등의 이동통신 시스템에서 사용되고 있다[1]. 또한 다양한 분야에서 비협력 통신이 사용됨에 따라 OFDM 신호의 변조 방식을 추정하는 자동 변조 분류(automatic modulation classification, AMC) 기술도 발전하고 있다.

최근 딥러닝 기반의 OFDM 신호 AMC 연구가 활발히 진행되고 있는데[2], 딥러닝 기반의 AMC 는 훈련되지 않은 비정상 데이터에 취약한 단점이 존재한다[3]. 이를 극복하기 위해 OFDM 신호 AMC 에서 비정상 데이터를 탐지하기 위한 연구가 진행되었으며, 그 중 하나로 오토인코더 기반의 비정상 탐지 기법이 연구되었다[4]. 본 논문에서는 오토인코더 기반 OFDM 신호 비정상 탐지 기법을 제안하고 모의 실험을 통해 탐지 성능을 분석한다.

II. 오토인코더 기반 비정상 탐지 방법

비협력 통신 상황에서 OFDM 신호가 페이딩 채널을 통과하여 수신되었다고 가정하면 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 가우스 잡음을 나타낸다.

수신 신호를 N 크기로 구분하여 벡터를 구성한 후 I/Q (Inphase and Quadrature) 성분을 분리하여 결합하면 $1 \times 2N$ 크기의 배열을 얻을 수 있다. 본 논문에서는 이와 같은 형태의 배열을 오토인코더 훈련에 사용한다.

그림 1 에는 오토인코더의 구조를 나타내었다. 오토인코더는 입력 신호를 출력으로 복사하는 신경망인데 이 때 오토인코더는 인코더, 디코더, 그리고 병

목층으로 구성된다. 인코더는 입력 데이터를 저차원으로 압축한 다음 디코더는 압축된 신호를 다시 해제하여 입력 데이터와 같은 차원으로 복원한다. 이 때 오토인코더는 입력 신호와 출력 신호 간의 차이가 최소화되도록 학습을 진행한다.

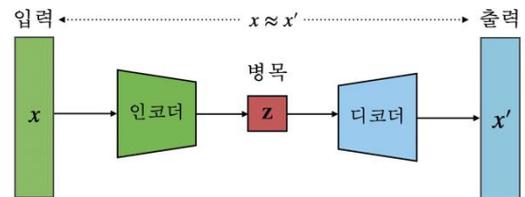


그림 1. 오토인코더 모델

본 논문에서 제안하는 오토인코더는 3 개의 완전 연결층으로 이루어진 인코더, 디코더와 1 개의 완전 연결층으로 이루어진 병목층으로 구성된다. 각 완전 연결층의 뉴런 수는 표 1 과 같다. 배치 크기는 500, Epoch 는 20, 학습률은 $3.33e-5$, 최적화 알고리즘은 Adam 을 사용하였다.

표 1. 오토인코더의 완전연결층 뉴런 수

	뉴런 수
인코더	1960
	480
	106
병목층	24
디코더	106
	480
	1960

오토인코더를 이용한 비정상 탐지 기법은 훈련된 입력과 훈련되지 않은 입력의 재구성 오류 분포 차이에 기반한다. 일반적으로 훈련된 입력의 재구성 오류가 훈련되지 않은 입력의 재구성 오류보다 더 작을 것으로 기대할 수 있다. 따라서 특정한 임계값을 설정하여 재구성 오류가 임계값 보다 작다면 정상 데이터로, 크다면 비정상 데이터로 분류할 수 있다.

III. 모의 실험 및 성능 분석

제한한 비정상 탐지 방식의 성능을 분석하기 위하여 모의 실험을 진행한다. 훈련 데이터 셋으로는 디지털 선형 변조 방식 중 4 가지(BPSK, QPSK, 8PSK, 16QAM)를 고려하며 OFDM 신호의 푸리에 변환 크기는 256, cyclic prefix 길이는 64, 부반송파 개수는 16 을 사용한다. 채널은 라이시안 페이딩 채널을 가정하고 도플러 편이 주파수는 500Hz, Rician K-factor 는 20 을 가정한다. 신호 대 잡음비(signal-to-noise ratio, SNR) 범위는 0~19dB 로 설정한다. 훈련 데이터를 구성하기 위해 SNR 범위에서 1dB 간격으로 1000 개의 샘플을 생성하며 각 샘플을 행으로 쌓아 총 80000×3840 크기의 행렬을 생성한다. 한편, 비정상 데이터는 평균이 0 이고 표준 편차가 0.0719 인 가우스 분포로부터 생성한다.

활성화 함수에 따른 비정상 탐지 성능을 분석하기 위하여 본 논문에서는 SELU, RELU, LeakyRELU, ELU, GELU, SOFTPLUS 의 6 가지 활성화 함수를 고려한다. 또한 전처리 기법으로는 Standard Scaler 와 MinMax Scaler 를 사용한다. SELU 함수를 사용하기 위해서는 Standard Scaler 가 필수이기 때문에 이를 사용하며 나머지 활성화 함수에서는 MinMax Scaler 를 사용한다.

모의 실험의 성능 지표로는 수신기 동작 특성 곡선 아래 면적(area under receiver operating characteristic curve, AUROC)를 사용하는데 AUROC 가 1 에 가까울수록 제한한 모델의 성능이 좋음을 나타낸다. 본 논문에서는 모의 실험 결과에 따른 비정상 탐지 성능을 재구성 오류 분포와 AUROC 로 나타내었다.

먼저, 그림 2 에는 활성화 함수에 따른 재구성 오류 분포를 나타내었다. 이 때 파란색 분포는 정상 데이터의 분포이며 빨간색 분포는 비정상 데이터의 분포를 나타낸다. 그림 2 를 통해 활성화 함수에 따라 재구성 오류 분포가 차이가 나는 것을 확인할 수 있다. 특히, LeakyRELU 를 사용할 경우 정상 데이터의 분포와 비정상 데이터의 분포가 잘 분리되어 AUROC 가 1 에 가까울 것으로 예상되고 RELU 와 SELU 를 사용할 경우 두 분포가 겹쳐 있어 AUROC 성능이 1 과 멀어질 것이라고 예상할 수 있다.

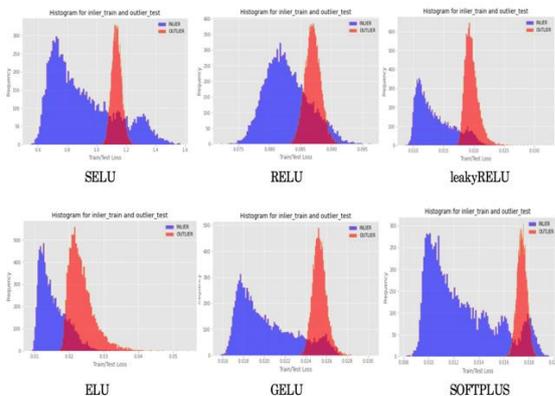


그림 2. 활성화 함수에 따른 재구성 오류 분포

한편, 표 2 에는 활성화 함수에 따른 AUROC 를 나타내었다. 표 2 를 통해 LeakyRELU 의 AUROC 가 가장 크고 SELU 의 AUROC 가 가장 작은 것을 확인할 수 있다. 따라서 모의 실험 결과를 통해 활성화 함수로 LeakyRELU 를 사용하는 것이 OFDM 신호 AMC 에서 비정상 데이터를 탐지하는데 가장 좋을 것이라고 판단할 수 있다.

표 2. 활성화 함수에 따른 AUROC

활성화 함수	AUROC
SELU	0.8063
RELU	0.8718
LeakyRELU	0.9599
ELU	0.9482
GELU	0.9465
SOFTPLUS	0.9365

IV. 결론

본 논문에서는 오토인코더 기반 OFDM 신호의 비정상 탐지 기법을 제안하고 탐지 성능을 분석하였다. 모의 실험을 통해 LeakyRELU 를 사용하였을 때 제안한 비정상 탐지 기법의 성능이 가장 좋은 것을 확인하였다. 향후에는 보다 다양한 비정상 데이터와 변조 방식을 고려하여 비정상 탐지 연구가 진행되어야 할 것이다.

Acknowledgement

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

참고문헌

- [1] M. Ergen, *Mobile Broadband: Including WiMAX and LTE*, New York, NY, USA: Springer, 2009.
- [2] G. Song, M. Jang, and D. Yoon, "CNN-based automatic modulation classification in OFDM systems," in *Proc. IEEE Int. Conf. Comput. Inf. Telecommun. Syst.*, Jul. 2022, pp. 101-104.
- [3] S. Bulusu, B. Kailkhura, B. Li, P. K. Varshney, and D. Song, "Anomalous example detection in deep learning: a survey," *IEEE Access*, vol. 8, pp. 132330-132347, Jul. 2020.
- [4] 최윤철, 장민규, 안성배, 윤동원, "오토인코더 기반 OFDM 신호의 이상치 탐지," 한국산업융합학회 춘계 학술대회 논문집, 2022 년 7 월.