

# 위상 오프셋을 고려한 딥러닝 기반 변조 분류 성능 분석

송건호\*, 김재윤\*\*, 김동영\*\*\*, 윤동원\*\*\*\*

## Performance Analysis of Deep Learning-based Modulation Classification under Phase Offset

Geonho Song\*, Jaeyun Kim\*\*, Dongyeong Kim\*\*\*, and Dongweon Yoon\*\*\*\*

본 연구는 (주)LIG넥스원 비협력 통신 신호 분석 기반 기술 연구 과제에 지원을 받아 수행되었음.

### 요약

자동 변조 분류(AMC, Automatic Modulation Classification)는 현대 무선 통신의 다양한 협력 및 비협력 상황에서 전송 효율과 신뢰도를 극대화하는 데 핵심적인 역할을 하며, 이와 관련하여 딥러닝(Deep learning) 기반의 다양한 연구 결과들이 보고되고 있다. 그러나, 기존 연구들은 주로 동일한 환경의 훈련 및 테스트 데이터를 이용한 분류 성능 개선에 초점을 두고 있으며, 특정 조건에서만 학습된 모델은 수신 신호의 왜곡으로 인한 변화에 민감하여 실제 환경에서 적용이 제한될 수 있다. 본 논문에서는 위상 오프셋(Phase offset)이 존재하는 환경에서 딥러닝 기반 AMC의 분류 성능과 실제 적용 가능성을 분석한다. 위상 오프셋 조건과 변조 방식별 신호 패턴의 구조적 특성을 고려한 광범위한 컴퓨터 모의실험을 통해, 다양한 위상 오프셋을 고려하여 학습한 딥러닝 모델이 실제 환경에서 효용성을 가질 수 있음을 보인다.

### Abstract

Automatic Modulation Classification (AMC) plays a crucial role in enhancing transmission efficiency and reliability in various cooperative and non-cooperative contexts, and numerous Deep Learning (DL)-based approaches have been reported. However, existing studies mainly focus on improving classification performance using training and test data from the same environments, and models trained only under specific conditions can be sensitive to distortions in received signals and may have limited applicability in real-world environments. This paper analyzes the classification performance and practical applicability of DL-based AMC in the presence of phase offset. Through extensive computer simulations that consider phase offset conditions and structural characteristics of modulation-specific signal patterns, we show that a DL model trained with diverse phase offsets can be effective in practical environments.

### Keywords

automatic modulation classification, non-cooperative context, phase offset, deep learning

\* 한양대학교 융합전자공학과 석박사통합과정(공동1저자) · Received: Dec. 19, 2025, Revised: Jan. 08, 2026, Accepted: Jan. 11, 2026

- ORCID: <https://orcid.org/0009-0004-3259-0532>

\*\* 한양대학교 융합전자공학과 박사과정,  
LIG넥스원 연구위원(공동1저자)

- ORCID: <https://orcid.org/0000-0002-4692-8467>

\*\*\* 한양대학교 융합전자공학과 연구교수

- ORCID: <https://orcid.org/0000-0001-5369-2424>

\*\*\*\* 한양대학교 융합전자공학과 교수(교신저자)

- ORCID: <https://orcid.org/0000-0001-9631-3500>

· Corresponding Author: Dongweon Yoon

Dept. of Electronic Engineering, Hanyang University,  
222 Wangsimni-ro, Seongdong-gu, Seoul 04763, Korea  
Tel.: +82-2-2220-0362, Email: [dwyoon@hanyang.ac.kr](mailto:dwyoon@hanyang.ac.kr)

## 1. 서 론

자동 변조 분류(AMC, Automatic Modulation Classification)는 수신 신호로부터 사전 정보 없이 변조 방식을 식별하는 기술로서 현대 무선 통신에서 전송 효율과 신뢰도를 극대화하는 데 핵심적인 역할을 한다. 이러한 AMC는 인지 무선(Cognitive radio)이나 스펙트럼 감시(Spectrum surveillance) 등 다양한 협력 및 비협력 상황에서 중요하게 활용된다. AMC 기법은 접근 방식에 따라 크게 우도(Likelihood) 기반 [1]-[5], 특징값(Feature) 기반 [6]-[11], 그리고 딥러닝(Deep learning) 기반 기법 [12]-[18]으로 구분된다. 우도 기반 AMC는 수신 신호의 각 변조 방식에 대한 우도를 계산·비교하여 변조 방식을 예측하는 기법으로, 이론적으로 최적의 분류 성능을 달성할 수 있으나 정확한 우도 계산을 위해 신호의 모든 매개변수를 알고 있어야 하고 계산 복잡도가 높아 실제 적용에는 한계가 있다. 특징값 기반 AMC는 수신 신호로부터 통계적 특징값을 추출하여 변조 방식을 예측하는 기법으로, 우도 기반 방식보다 계산 복잡도가 낮다는 장점이 있다. 그러나 고려 대상 변조 방식 조합에 따라 최적의 특징값들이 달라지기 때문에, 조합에 따라 새롭게 특징값들을 선별해야 하는 번거로움이 있으며, 이러한 선별 작업은 조합에 따라 매우 어려운 문제가 될 수 있다. 딥러닝 기반 AMC는 수신 신호로부터 적절한 형태의 데이터를 구성하여 딥러닝 모델에 입력해 변조 방식을 예측하는 기법으로, 딥러닝 모델 학습을 위해 대량의 데이터가 필요하나 모델이 신호의 특징을 자동으로 추출 및 학습할 수 있고 모델 설계에 따라 높은 분류 성능을 달성할 수 있다는 장점이 있다.

이러한 장점들 덕분에 딥러닝은 AMC 분야의 주요 흐름으로 자리 잡았으며, 이와 관련된 다양한 연구 결과가 보고되고 있다. 예를 들어, 참고문헌 [12]에서는 수신 신호로부터 성상도(Constellation) 이미지를 생성한 뒤 여러 이미지 분류 모델에 입력하여 8가지 변조 방식을 분류하였다. 성상도 이미지뿐 아니라, 수신 신호의 동위상 및 직교 위상(In-phase and quadrature) 성분으로 구성된 배열 또는 시퀀스(Sequence)를 딥러닝 모델에 입력하여 변조 분류를

수행하는 연구도 활발히 이루어지고 있다. 참고문헌 [13]-[15]에서는 합성곱 신경망(CNN, Convolutional Neural Network) 모델을 이용하여 변조 방식들을 분류하였다. 또한, 참고문헌 [16]과 [17]에서는 시계열 데이터 처리에 강점을 보이는 장단기 기억(LSTM, Long Short-Term Memory) 기반 모델을 이용해 각각 4가지와 11가지 변조 방식을 분류하였다. 최근에는, 참고문헌 [18]에서 트랜스포머(Transformer) 기반 모델을 이용해 11가지 변조 방식을 분류하였다.

기존의 딥러닝 기반 AMC 기법들은 주로 동일한 환경에서 생성된 훈련 및 테스트 신호 데이터를 이용하여 동일한 조건에서 분류 성능을 비교 및 개선하는 데 초점을 두고 있다. 그러나 실제 환경에서 수신 신호는 여러 요인에 의해 왜곡되어 다양한 속성이 이상적인 조건과 달라질 수 있다. 그리고 특정 환경에서만 학습된 모델은 이러한 변화에 안정적으로 대응하지 못해 분류 성능이 급격히 저하될 수 있다. 따라서 다양한 환경에서 딥러닝 기반 AMC의 실제 적용 가능성을 평가하는 것은 성능 개선과 더불어 매우 중요한 연구 주제이다. 이에 따라, 본 논문에서는 다양한 환경 변화의 주요 고려 요소인 위상 오프셋(Phase offset)이 존재하는 환경에서 딥러닝 기반 AMC의 분류 성능과 실제 적용 가능성을 분석한다. 이를 위해, 다양한 위상 오프셋 조건과 변조 방식별 신호 패턴의 구조적 특성을 고려한 광범위한 컴퓨터 모의실험을 수행한다. 본 논문에서는 이 체계적인 성능 평가 결과를 바탕으로 딥러닝 기반 AMC의 실제 적용 가능성을 제시한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 논문에서 가정하는 시스템 모델에 대해 설명한다. 3장에서는 변조 분류를 위한 딥러닝 모델, 데이터셋(Dataset) 및 모의실험 결과를 상세히 설명한다. 마지막으로, 4장에서 결론을 제시한다.

## II. 시스템 모델

그림 1은 본 논문에서 가정하는 딥러닝 기반 AMC의 시스템 모델을 나타낸다. 본 논문에서는 송신 신호가 가산 백색 가우스 잡음(AWGN, Additive White Gaussian Noise) 채널을 거쳐 수신된 후, 위상

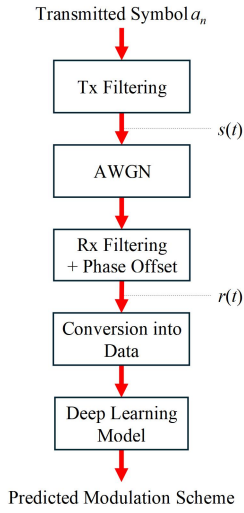


그림 1. 딥러닝 기반 AMC의 시스템 모델

Fig. 1. System model for deep learning-based AMC

오프셋에 의해 왜곡되는 상황을 가정한다. 송신 심볼을  $a_n$ , 각 심볼의 주기를  $T$ 라 할 때, 송신 신호  $s(t)$ 는 복소 기저대역 표현으로 식 (1)과 같다.

$$s(t) = \sum_n a_n g(t - nT) \quad (1)$$

여기서  $g(t)$ 는 송신기 필터가 적용된 펄스를 나타낸다. 송신 신호  $s(t)$ 는 AWGN 채널을 거쳐 수신기에 도달한 후 수신기 필터링을 거치고, 위상 오프셋에 의해 신호가 왜곡되며, 최종적으로 식 (2)와 같은 수신 신호  $r(t)$ 가 얻어진다.

$$r(t) = \sum_n a_n x(t - nT) \exp(j\phi_o) + \nu(t) \quad (2)$$

여기서  $x(t)$ 는 송신기와 수신기 필터가 모두 적용된 펄스,  $\phi_o$ 는 위상 오프셋,  $\nu(t)$ 는 수신기 필터 및 오프셋이 적용된 AWGN 성분을 나타낸다. 이후 수신기에서는 수신 신호  $r(t)$ 를 일정한 주기  $T_s$ 마다 표본화(Sampling)하여 이산시간 신호  $r[k] = r(kT_s)$ 를 얻고,  $r[k]$ 를 딥러닝 모델 입력에 적합한 형태의 데이터로 변환한 뒤, 이를 딥러닝 모델에 입력하여 신호의 변조 방식을 예측한다.

실제 환경에서는 수신 신호의 위상 오프셋  $\phi_o$ 가 시간에 따라 변화할 수 있으며, 이러한 변화는 변조

분류 성능에 직접적인 영향을 미쳐 딥러닝 기반 AMC의 실제 적용 가능성에 매우 중요한 요인으로 작용한다. 이에 본 논문에서는 다양한 위상 오프셋 조건과 변조 방식별 신호 패턴의 구조적 특성을 고려한 광범위한 컴퓨터 모의실험을 통해 변조 분류 성능을 체계적으로 평가하고, 이를 기반으로 위상 오프셋이 존재하는 환경에서 딥러닝 기반 AMC의 실제 적용 가능성을 제시한다. 이어지는 장에서는 변조 분류를 위한 딥러닝 모델, 데이터셋 및 모의실험 결과를 상세히 설명한다.

### III. 모의실험 및 성능 분석

이 장에서는 딥러닝 기반 AMC의 분류 성능과 적용 가능성을 분석하기 위해 본 논문에서 고려하는 딥러닝 모델과 신호 데이터셋을 설명하고, 다양한 위상 오프셋 조건에서 분류 성능을 분석한다.

본 논문에서는 AMC에 적용 가능한 신뢰성 있는 딥러닝 모델 중 하나를 적용하여 변조 분류 실험 및 성능 분석을 수행한다. 이를 위해 잘 알려진 공학 소프트웨어인 MATLAB에 구현된 CNN을 사용한다. 모델은 6개의 합성곱층과 2개의 완전연결층으로 구성되며, 표 1에 그 구조를 나타내었다. 표 1에서  $\text{conv}(C, (H, W))$ 는 출력 채널 수가  $C$ 이고 커널(Kernel) 크기가  $(H, W)$ 인 합성곱층을,  $\text{Linear}(U)$ 는 출력 유닛(Unit) 수가  $U$ 인 완전연결층을 의미한다. 또한  $\text{bn}$ 은 배치 정규화(Batch normalization),  $\text{relu}$ 는 Rectified Linear Unit 활성화 함수,  $\text{maxpool}$ 과  $\text{avgpool}$ 은 각각 최댓값 풀링(Max pooling)과 평균값 풀링(Average pooling)을 나타낸다. 또,  $K$ 는 분류 대상 변조 방식의 수를 나타낸다.

표 1. AMC를 위한 딥러닝 모델

Table 1. Deep learning model for AMC

Layer name	Architecture
conv1	conv(16, (1, 8)) + bn + relu + maxpool
conv2	conv(24, (1, 8)) + bn + relu + maxpool
conv3	conv(32, (1, 8)) + bn + relu + maxpool
conv4	conv(48, (1, 8)) + bn + relu + maxpool
conv5	conv(64, (1, 8)) + bn + relu + maxpool
conv6	conv(96, (1, 8)) + bn + relu + avgpool
fc	linear(K)

본 논문에서는 BPSK, QPSK, 8PSK, 16QAM의 4가지 변조 방식을 고려하여 데이터셋을 구성하였다. 이를 위해, 먼저 제공된 올림 코사인(Root raised cosine) 송·수신 필터와 구간  $[-180^\circ, 180^\circ]$  내의 다양한 위상 오프셋  $\phi_o$ 를 가정한 수신 신호를  $T_s = T/4$ 마다 표본화한, 4배 과표본화된 이산시간 신호  $r[k]$ 를 생성한다. 이후  $r[k]$ 의 연속된  $L_0$ 개의 표본으로  $L_0$ 차원 복소 벡터를 구성하고, 그 성분을 반복 및 연결하여  $L$ 차원 복소 벡터를 얻는다. 이 복소 벡터를 실수부와 허수부로 분리하여 2개의  $L$ 차원 실수 벡터를 구성한 뒤, 이를 2채널 형태로 결합하여 데이터셋의 각 Example로 사용하였다. 본 논문에서 송·수신 필터의 롤 오프율(Roll-off rate)은 0.22,  $L_0=800$ ,  $L=1,600$ 으로 설정하였으며, 변조 방식당 14,000개, 3,000개, 10,000개의 Example를 생성하여 각각 모델을 위한 훈련, 검증, 테스트 셋(Set)으로 사용하였다.

위상 오프셋이 존재하는 환경에서 딥러닝 기반 AMC의 분류 성능과 적용 가능성을 분석하기 위해, 먼저 단일 위상 오프셋 조건에서 분류 성능을 분석하였다. 이를 위해 심볼당 에너지 대 잡음 전력 스펙트럼 밀도 비(Energy per symbol to noise power spectral density)  $E_s/N_0$  별로 데이터셋을 생성하고 독립적으로 모델을 훈련시켰다. 편의를 위해, 훈련/검증 셋의 위상 오프셋과 테스트 셋의 위상 오프셋을 각각 훈련 위상 오프셋, 테스트 위상 오프셋이라 명명하고  $\phi_o^{(train)}$ 과  $\phi_o^{(test)}$ 로 표기하였다. 그림 2에  $\phi_o^{(train)}=0^\circ, 10^\circ, 20^\circ, 30^\circ$ ,  $\phi_o^{(test)}=\phi_o^{(train)}, \phi_o^{(train)}+20^\circ, \phi_o^{(train)}+40^\circ, \phi_o^{(train)}+60^\circ, \phi_o^{(train)}+80^\circ$ 인 위상 오프셋에서 훈련 및 테스트 위상 오프셋의 차  $\Delta\phi_o := \phi_o^{(test)} - \phi_o^{(train)}$ 에 따른 분류 정확도를 나타내었다. 그림 2에서 분류 정확도는  $E_s/N_0$ 의 증가에 따라 전반적으로 향상되지만,  $\Delta\phi_o$ 에 따라 뚜렷하게 다섯 개의 성능 그룹으로 구분되며,  $\phi_o^{(train)}$ 이 분류 성능에 유의미한 영향을 주지 않는 것을 확인할 수 있다. 이를 통해 분류 성능은 훈련 및 테스트 위상 오프셋의 절대적인 값이 아닌, 두 값의 차이에 의존한다고 추측할 수 있다. 또, 그림 2에서  $\Delta\phi_o \neq 0$ 인 경우에는  $\Delta\phi_o = 0$ 인 경우에 비해, 분류 정확도가 전




그림 2. 단일 위상 오프셋과 단일  $E_s/N_0$ 에 대해 훈련된 모델의 분류 성능

Fig. 2. Classification performance of a model trained on a single phase offset and a single  $E_s/N_0$

반적으로 크게 저하되거나 요동치는 것을 확인할 수 있다. 이로부터 단일 위상 오프셋에 대해 훈련된 딥러닝 기반 AMC 모델은 실제 환경에서 수신 신호의 위상 오프셋의 변화에 매우 민감하여 적용이 제한적일 것으로 분석된다.

그림 2에서 분류 정확도와  $\Delta\phi_o$  사이에 일관성이 없는 것을 확인할 수 있다. 예를 들어,  $E_s/N_0$ 가 2dB인 경우,  $\Delta\phi_o$ 가  $0^\circ$ 에서  $40^\circ$ 까지는 분류 정확도가 감소하며, 이어서  $40^\circ$ 에서  $80^\circ$ 까지는 증가한다. 이러한 경향을 설명하기 위하여 변조 방식별 신호 패턴의 구조적 특성을 고려하여 실험 결과를 분석하였다. 데이터셋을 생성할 때, 수신 신호  $r[k]$ 는 각 변조 방식의 정상도 점들로 구성된 심볼들의 시퀀스(Sequence)를 송·수신 필터로 보간하여 생성된다. 위상 오프셋이 존재하면 복소평면 상에서 신호 값이 해당 각도만큼 회전하며, 그로 인해 특정 변조 방식의 신호 패턴(Pattern)이 다른 변조 방식의 신호 패턴과 부분적으로 유사해질 수 있다. 이러한 현상을 시각적으로 살펴보기 위해 위상 오프셋이 없는 8PSK 신호와 QPSK 신호, 위상 오프셋이  $-22.5^\circ$ 인 QPSK 신호의 실수부와 허수부의 패턴을 복소평면 상에 그림 3에 도시하였다. 그림 3에서 QPSK 신호의 패턴이 위상 오프셋이 존재하지 않을 때는 8PSK 신호의 패턴과 명확히 구분되지만,  $-22.5^\circ$ 의 위상 오프셋이 존재할 때는 8PSK 신호의 패턴과 겹치는 것을 확인할 수 있다. 따라서 그림 2에서 확인된 바와 같이, 분류 정확도와  $\Delta\phi_o$  사이에 일관성이 없는 이유는

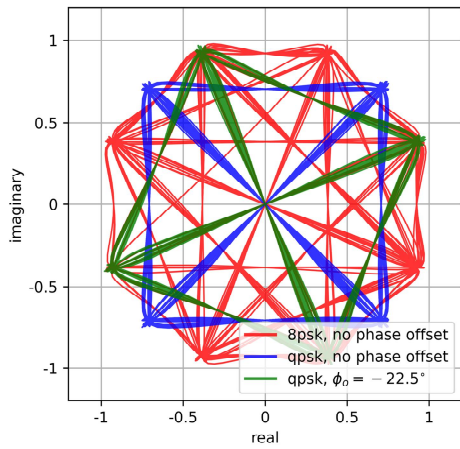



그림 3. 위상 오프셋에 따른 신호 패턴  
Fig. 3. Signal pattern with respect to phase offset


$\phi_o^{(train)}$  과  $\phi_o^{(test)}$  에 따라 특정 변조 방식의 신호 패턴들이 부분적으로 유사성을 띄게 됨으로써 발생하는 상호 혼동에 기인한 것으로 분석된다. 이를 검증하기 위해,  $\phi_o^{(train)}=0^\circ$  이고 잡음이 없는 조건에서 BPSK, QPSK, 8PSK, 16QAM의 4가지 변조 방식 중에 가능한 모든 두 가지 조합에 대하여 표 1의 딥러닝 모델( $K=2$ )을 각각 훈련하여, 위상 오프셋에 따른 분류 정확도를 확인하였다. 만약, 위의 분석이 맞다면, 잡음이 없을 때, 신호 패턴이 유사하게 겹치는 특정 변조 방식 조합에서만 분류 정확도 감소가 발생해야 하며, 그 감소는 신호 패턴이 가장 겹치는  $\phi_o^{(test)}$  에서 발생해야 한다.

그림 4에 각 조합과  $\phi_o^{(test)}$  에 따른 분류 정확도를 도시하였다. 그림 4에서 8PSK와 16QAM의 조합(그림 4(f))를 제외하면, 모든 변조 방식 조합에서 특정  $\phi_o^{(test)}$  를 기점으로 분류 정확도가 급격히 변하며 이러한 분류 정확도의 급변이 변조 방식에 따라 다르게 나타나는 것을 확인할 수 있다. 예를 들어, 그림 4(a), 4(b), 4(c)의 BPSK의 분류 정확도 변화와 그림 4(d), 4(e)의 QPSK의 분류 정확도 변화의 양상이 상이하다. 이는 복소평면 상에서 신호 패턴이 회전함에 따라 반복적으로 나타나는 위상 오프셋 값이 BPSK는  $180^\circ$ , QPSK는  $90^\circ$ 로 서로 다르기 때문으로 해석할 수 있다.


또한 앞서 설명한 것과 같이 그림 4(f)에서 8PSK와 16QAM 사이에는 위상 오프셋에 따른 혼동이




(a) BPSK, QPSK




(b) BPSK, 8PSK




(c) BPSK, 16QAM



(d) QPSK, 8PSK



(e) QPSK, 16QAM



(f) 8PSK, 16QAM

그림 4. 잡음이 없는 조건에서 이진 분류 성능  
Fig. 4. Binary classification performance under noiseless condition

발생하지 않는 것을 확인할 수 있다. 이는 앞선 해석에 따르면 8PSK의 신호 패턴을 어느 각도로 회전시켜도 16QAM의 패턴과 겹치지 않는다는 것을 의미한다. 이를 확인하기 위해 8PSK와 16QAM의 성상도 점들을 모두 연결한 신호 패턴을 그림 5에




그림 5. 8PSK와 16QAM의 성상도 패턴  
Fig. 5. Constellation patterns of 8PSK and 16QAM

도시하였다. 그림 5에서 8PSK의 패턴을 어느 각도로 회전시켜도 16QAM의 패턴 일부와 겹쳐지지 않는 것을 확인할 수 있으며, 이를 통해 두 변조 방식의 패턴 사이에 명확한 구조적 차이가 존재함을 알 수 있다. 따라서 두 변조 방식의 신호 패턴은 위상 오프셋이 바뀌어도 서로 유사성을 보이지 않으며, 이로 인한 변조 분류 성능 감소가 발생하지 않는다.

다음으로, 특정 범위 내의 다양한 위상 오프셋을 고려하여 모델을 학습한 경우의 분류 성능을 분석하였다. 이를 위해, 각 Example이 특정 구간  $[a, b]$ 에서 랜덤하게 선택한 위상 오프셋을 갖도록 훈련 및 검증 셋을 생성하였다. 편의를 위해, 임의의 매개변수  $\theta$ 가 구간  $[a, b]$  사이의 균일 분포를 따르도록 훈련 및 검증 셋을 구성하였을 때, 이를  $\theta^{(train)} \sim U(a, b)$ 라 표기하였다.

먼저  $E_s/N_0$ 마다 모델을 훈련한 경우의 분류 성능을 확인하였다. 그림 6에  $\phi_o^{(train)} \sim U(-90^\circ, 90^\circ)$ 일 때, 다양한 위상 오프셋에 대한 모델의  $E_s/N_0$ 별 분류 정확도를 도시하였다. 그림 6에서, 각  $E_s/N_0$ 별 모델이 그림 2에서와 달리 고려하는  $\phi_o^{(test)}$  전부에 대해 변조 분류가 가능하고, 전반적인 분류 정확도가  $\phi_o^{(test)}$ 에 관계없이 일정한 것을 확인할 수 있다.

다음으로 다양한  $E_s/N_0$ 를 복합적으로 고려하여 하나의 모델을 학습한 경우의 분류 성능을 분석하였다. 이를 위해  $\phi_o^{(train)} \sim U(-90^\circ, 90^\circ)$ 이고  $E_s/N_0^{(train)} \sim U(1\text{dB}, 11\text{dB})$ 일 때, 변조 분류를 수




그림 6. 다양한 위상 오프셋과 단일  $E_s/N_0$ 에 대해 훈련된 모델의 분류 성능  
Fig. 6. Classification performance of a model trained on various phase offsets and a single  $E_s/N_0$




그림 7. 다양한 위상 오프셋과  $E_s/N_0$ 에 대해 훈련된 모델의 분류 성능  
Fig. 7. Classification performance of a model trained on various phase offsets and  $E_s/N_0$

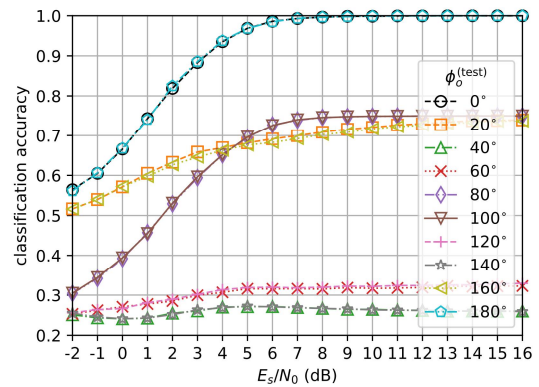
행하고 모델의 분류 성능을 그림 7에 도시하였다. 그림 7에서, 모델이 그림 6과 마찬가지로 다양한  $\phi_o^{(test)}$ 에 대해 변조 분류를 수행할 수 있음을 확인할 수 있다. 그리고 그림 6과 비교했을 때, 그림 7에서 전반적으로 더 높은 분류 정확도가 관찰된다. 이는 그림 7에 사용된 모델이 그림 6의 각  $E_s/N_0$ 별 모델보다 더 다양한  $E_s/N_0$  조건에서 훈련되어, 폭넓은 잡음 수준의 일반화된 신호 패턴을 학습할 수 있기 때문으로 분석된다. 또한 그림 6의 학습 방식은  $E_s/N_0$ 마다 별도의 모델이 필요하지만, 그림 7은 하나의 모델로 여러  $E_s/N_0$  조건에 범용적으로 대응할 수 있다. 따라서 수신 신호의  $E_s/N_0$ 를 알기

어렵거나 시간에 따라 변할 수 있는 실제 환경에서는 그림 7의 학습 방식이 더 효율적이다.


마지막으로, 모델 학습에서 다양한 위상 오프셋을 고려한 경우와 그렇지 않은 경우의 분류 성능을 비교하여 그림 8에 도시하였다. 그림 8에  $E_s/N_0^{(train)} \sim U(1\text{dB}, 11\text{dB})$  일 때,  $\phi_o^{(train)}=0^\circ$ 와  $\phi_o^{(train)} \sim U(-90^\circ, 90^\circ)$ 의 두 학습 조건에 대한 모델의  $E_s/N_0$  별 분류 정확도를 나타내었다. 두 모델의 분류 성능에 대하여 시각적 비교를 용이하게 하기 위해, 그림 8(b)에 그림 8(a)에서  $\phi_o^{(test)}=0^\circ$ 일 때의 성능 그래프를 함께 도시하였다. 그림 8에서 단일 위상 오프셋만을 고려하여 학습된 모델(그림 8(a))과 다양한 위상 오프셋을 고려하여 학습된 모델(그림 8(b))의 성능 차이를 명확히 확인할 수 있다. 단일 위상 오프셋만 학습 모델은  $\phi_o^{(train)}$ 과  $\phi_o^{(test)}$ 의 위상 변화에 매우 민감하게 반응하여 성능이 크게 저하된다. 반면, 다양한 위상 오프셋을 고려하여 학습한 모델은  $\phi_o^{(test)}=0^\circ$ 에서 약간의 성능 하락이 발생하지만, 폭넓은 위상 오프셋 조건에서 범용적이고 안정적인 분류 성능을 확보하는 것이 확인된다.

#### IV. 결 론

본 논문에서는 위상 오프셋이 존재할 때 딥러닝 기반 AMC의 분류 성능과 실제 적용 가능성을 분석하였다. 이를 위해 다양한 위상 오프셋 조건을 포함한 훈련 및 테스트 조건을 고려하여 광범위한 컴퓨터 모의실험을 수행하고 분류 성능을 체계적으로 평가하였다. 그 결과, 위상 오프셋을 고려하지 않는 기존 딥러닝 기반 AMC 기법과 단일 위상 오프셋을 고려한 딥러닝 기반 AMC 기법은 수신 신호의 위상 오프셋 변화에 매우 민감하여 다양한 위상 오프셋이 존재하는 실제 환경에서 적용이 제한적이지만, 본 논문에서와 같이 다양한 위상 오프셋을 고려하여 학습한 딥러닝 모델은 폭넓은 위상 오프셋의 신호에 대해 범용적이고 안정적인 분류 성능을 확보하여, 실제 환경에서의 실질적인 효용성을 입증하였다. 향후에는 주파수 오프셋 등 추가적인 오프셋과 페이딩(Fading)과 같은 보다 복잡한 채널 환경을 고려한 연구가 필요할 것으로 사료된다.



(a)  $\phi_o^{(train)}=0^\circ$



(b)  $\phi_o^{(train)} \sim U(-90^\circ, 90^\circ)$

그림 8. 훈련 위상 오프셋 조건에 따른 분류 성능  
Fig. 8. Classification performance under different training phase offset conditions


#### References

- [1] C.-Y. Huang and A. Polydoros, "Likelihood methods for MPSK modulation classification", IEEE Trans. Commun., Vol. 43, pp. 1493-1504, Feb.-Apr. 1995. <https://doi.org/10.1109/26.380199>.
- [2] W. Wei and J. M. Mendel, "Maximum likelihood classification for digital amplitude-phase modulations", IEEE Trans. Commun., Vol. 48, No. 2, pp. 189-193, Feb. 2000. <https://doi.org/10.1109/26.823550>.
- [3] O. A. Dobre, A. Abdi, Y. Bar-Ness, and W. Su, "Survey of automatic modulation classification techniques: Classical approaches and new trends",

- IET Commun., Vol. 1, No. 2, pp. 137-156, Apr. 2007. <https://doi.org/10.1049/iet-com:20050176>.
- [4] F. Hameed, O. A. Dobre, and D. C. Popescu, "On the likelihood-based approach to modulation classification", *IEEE Trans. Wireless Commun.*, Vol. 8, No. 12, pp. 5884-5892, Dec. 2009. <https://doi.org/10.1109/TWC.2009.12.080883>.
- [5] V. G. Chavali and C. R. C. M. da Silva, "Maximum-likelihood classification of digital amplitude-phase modulated signals in flat fading non-Gaussian channels", *IEEE Trans. Commun.*, Vol. 59, No. 8, pp. 2051-2056, Aug. 2011. <https://doi.org/10.1109/TCOMM.2011.051711.100184>.
- [6] S. S. Soliman and S.-Z. Hsue, "Signal classification using statistical moments", *IEEE Trans. Commun.*, Vol. 40, No. 5, pp. 908-916, May 1992. <https://doi.org/10.1109/26.141456>.
- [7] E. E. Azzouz and A. K. Nandi, "Automatic identification of digital modulation types", *Signal Process.*, Vol. 47, No. 1, pp. 55-59, Nov. 1995. [https://doi.org/10.1016/0165-1684\(95\)00099-2](https://doi.org/10.1016/0165-1684(95)00099-2).
- [8] Y. Yang and S. S. Soliman, "A suboptimal algorithm for modulation classification", *IEEE Trans. Aerosp. Electron. Syst.*, Vol. 33, No. 1, pp. 38-45, Jan. 1997. <https://doi.org/10.1109/7.570706>.
- [9] A. Swami and B. M. Sadler, "Hierarchical digital modulation classification using cumulants", *IEEE Trans. Commun.*, Vol. 48, No. 3, pp. 416-429, Mar. 2000. <https://doi.org/10.1109/26.837045>.
- [10] H. 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. <https://doi.org/10.1109/TWC.2008.070015>.
- [11] J. Lee, S. Ahn, J. Choi, and D. Yoon, "Phase mapping recognition and modulation classification algorithm using new higher-order cumulants", *J. Korean Inst. Inf. Technol.*, Vol. 15, No. 2, pp. 153-160, Feb. 2017. <https://doi.org/10.14801/jkiit.2017.15.2.153>.
- [12] 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. <https://doi.org/10.1109/TNNLS.2018.2850703>.
- [13] T. O'Shea and N. West, "Radio machine learning dataset generation with GNU radio", in *Proc. GNU Radio Conf.*, Boulder, CO, USA, pp. 1-6, Sep. 2016.
- [14] G. Song, D. Kim, J. Ro, and D. Yoon, "Deep learning-based automatic modulation classification using improved loss function", *J. Korean Inst. Inf. Technol.*, Vol. 22, No. 8, pp. 65-73, Aug. 2024. <https://doi.org/10.14801/jkiit.2024.22.8.65>.
- [15] G. Song, M. Jang, and D. Yoon, "Automatic modulation classification for OFDM signals based on CNN with  $\alpha$ -softmax loss function", *IEEE Trans. Aerosp. Electron. Syst.*, Vol. 60, No. 5, pp. 7491-7497, Oct. 2024. <https://doi.org/10.1109/TAES.2024.3397787>.
- [16] S. Hu, Y. Pei, and Y.-C. Liang, "Deep neural network for robust modulation classification under uncertain noise conditions", *IEEE Trans. Veh. Technol.*, Vol. 69, No. 1, pp. 564-577, Jan. 2020. <https://doi.org/10.1109/TVT.2019.2951594>.
- [17] Z. Ke and H. Vikalo, "Real-time radio technology and modulation classification via an LSTM auto-encoder", *IEEE Trans. Wireless Commun.*, Vol. 21, No. 1, pp. 370-382, Jan. 2022. <https://doi.org/10.1109/TWC.2021.3095855>.
- [18] J. Cai, F. Gan, X. Cao, and W. Liu, "Signal modulation classification based on the transformer network", *IEEE Trans. Cogn. Commun. Netw.*, Vol. 8, No. 3, pp. 1348-1357, Sep. 2022. <https://doi.org/10.1109/TCCN.2022.3176640>.

## 저자소개

### 송 건 호 (Geonho Song)



2021년 2월 : 한양대학교  
융합전자공학부(공학사)  
2021년 3월 ~ 현재 : 한양대학교  
융합전자공학과 석박사통합과정  
관심분야 : 무선 및 이동 통신  
시스템, 머신러닝, 신호정보

### 김 재 윤 (Jaeyun Kim)



2002년 2월 : 한양대학교  
전자공학과(공학사)  
2004년 2월 : 한양대학교  
전자공학과(공학석사)  
2004년 1월 ~ 현재 : LIG넥스원  
전자기전연구소 연구위원  
관심분야 : 디지털신호처리,

신호분석 알고리즘

### 김 동 영 (Dongyeong Kim)



2013년 2월 : 한양대학교  
수학과(이학사)  
2020년 2월 : 한양대학교  
수학과(이학박사)  
2020년 3월 ~ 현재 : 한양대학교  
융합전자공학부 BK연구조교수  
관심분야 : 블록암호, 통신 제원

추정

### 윤 동 원 (Dongweon Yoon)



1989년 2월 : 한양대학교  
전자통신공학과(공학사)  
1992년 2월 : 한양대학교  
전자통신공학과(공학석사)  
1995년 8월 : 한양대학교  
전자통신전파공학과(공학박사)  
2004년 3월 ~ 현재 : 한양대학교

융합전자공학부 석학교수

관심분야 : 통신이론, 위성 및 우주통신, 추정 및 검출