

변조 분류를 위한 인공지능 기반 자동 변조 인식 모델 연구

김민식, 명정호, 신우람, 조원철, 고영조

한국전자통신연구원

{msk, jhmyung, w.shin, woncheol, koyj}@etri.re.kr

A Study on AI-based Automatic Modulation Recognition for Modulation Classification

Minsik Kim, Jungho Myung, Wooram Shin, Woncheol Cho, Young-Jo Ko
Electronics and Telecommunications Research Institute

요 약

본 논문에서는 사전 정보가 없이 무선 채널을 통과한 신호의 변조 방식을 식별하기 위한 딥러닝 기반의 자동 변조 인식 모델을 연구한다. 제안하는 모델은 합성곱 레이어와 잔차 신경망으로 신호의 지역적 특성을 추출하고 멀티 헤드 메커니즘을 통해 신호의 전역적 특성을 추출한다. 모의 실험을 통해 제안하는 모델은 적은 파라미터의 수로 학습 초기에 낮은 신호 대 잡음비에서 높은 성능을 달성하는 것을 확인하였다.

I. 서 론

자동 변조 인식(automatic modulation recognition; AMR)은 무선 통신 시스템에서 수신 신호의 변조 방식을 자동으로 식별하고 분류하는 기술이다. 이는 통신 효율성을 높이고 신호 간 간섭 관리에 중요한 영향을 미친다 [1]. AMR은 알려지지 않은 시스템 매개변수가 없는 환경에서 신호의 변조 유형을 파악하여 정보를 효율적으로 추출할 수 있다. 이를 통해 신호의 안정성, 오류 감지 및 수정 능력을 강화하며, 특정 환경에서 최적의 성능을 제공하도록 도우므로 한정된 대역폭에서 더 많은 정보를 전송할 수 있게 된다. SISO (single input single output) 시스템에서 변조 인식 문제는 우도(likelihood) 기반 또는 특징 기반의 전통적인 방법들로 연구가 진행되었다 [2]. 그러나 통신 시스템의 지속적인 발전과 함께 MIMO (multiple input multiple output) 시스템이 도입되면서 변조 인식 기술은 새로운 도전에 직면하고 있다.

MIMO 시스템에서 AMR의 정확도를 향상시키는 것은 현재 무선 통신 시스템에서 도전 과제로 남아 있다 [3]. 전통적인 AMR은 likelihood 기반 방법과 특징 기반 방법으로 나뉜다. Likelihood 기반 방법은 이론적으로 최적의 성능을 제공하지만 MIMO 시스템은 수백 개의 송수신 안테나를 사용하므로 신호 공간 차원이 현저하게 증가하고 방대한 계산량을 필요로 하는 문제가 있다. 특징 기반 방법은 수동적인 특징 추출에 의존하므로 인식 결과가 추출자의 전문성에 크게 좌우되는 문제가 발생한다. 따라서 이 방식들은 갈수록 복잡해지는 MIMO 시스템 환경에는 적합하지 않다. 또한 MIMO 시스템에서는 수신 안테나에서 다양한 신호가 생성되므로 AMR이 더욱 어려워지는 문제가 있다.

최근 인공지능, 특히 딥러닝은 통신 분야에서 혁신적인 진전을 가져왔다. 이미지 처리 및 음성 인식 분야에서의

성공을 바탕으로, 딥러닝은 신호 검출, 채널 추정, 그리고 자동 변조 분류기에 성공적으로 적용되고 있다 [4]. 따라서 본 논문에서는 MIMO 환경에서의 AMR 문제점을 해결하기 위해 딥러닝 기반의 자동 변조 인식 기법에 대해 논의한다.

II. 시스템 모델

무선 통신 시스템에서 소스(source)에 의해 생성된 심볼 스트림 $s(t)$ 는 디지털 변조 신호 $x(t)$ 로 변환되어 송신된다. 무선 채널을 통과한 수신 신호는

$$y(t) = x(t) * h(t, \tau) + n(t), \quad (1)$$

여기에서 $h(t, \tau)$ 는 무선 채널의 시간 변화 임펄스 응답이며, $n(t)$ 는 평균이 0인 AWGN이다.

일반적으로 수신된 연속 신호 $y(t)$ 는 고정된 샘플링 주파수 f_s 로 샘플링된 후 힐베르트 변환을 거친다. $y(t)$ 를 복소 이산 신호로 다시 작성하면 다음과 같다.

$$y[n] = y_A[n]e^{j\pi y_P[n]}, \quad (2)$$

여기에서 $y_A[n]$ 과 $y_P[n]$ 는 수신 신호의 진폭과 위상 성분을 나타낸다. 수신기에서는 $y[n]$ 의 변조 방식을 결정할 후 복조를 진행한다.

본 논문에서는 인공지능 모델의 입력 데이터를 표준화하기 위해 수신 신호를 정규화된 진폭과 위상 성분으로 변환하여 사용한다. $y_P[n]$ 는 라디안(radians) 단위로 크기가 1이므로 그대로 사용하며, $y_A[n]$ 는 min-max 정규화를 사용하였다. 최종적으로 인공지능 모델의 입력 데이터는 다음과 같다.

$$\mathbf{x} = \begin{bmatrix} y_A[0], y_A[1], \dots, y_A[N-1], y_A[N] \\ y_P[0], y_P[1], \dots, y_P[N-1], y_P[N] \end{bmatrix}^T, \quad (3)$$

III. 딥러닝 기반 자동 변조 인식

사전 정보가 없는 수신 신호의 변조방식을 예측하기 위하여 인공지능을 이용한 다양한 기법들이 연구되고 있다. 전통적으로 AMR은 주로 합성곱 신경망 (CNN)을 기반으로 설계되어 왔다. 그러나 CNN은 전역적인 구조적 특징보다는 지역적 특징 추출에 더 적합하다는 한계를 지닌다. 변조된 신호는 시간적 종속성을 가지므로, 전역적인 관점에서 구조적 특징을 추출하는 것이 중요하다. 신호의 전역적인 특성을 잘 포착하기 위해 최근 멀티 헤드 어텐션 메커니즘을 사용하는 트랜스포머(transformer) 기반의 AMR 기법이 등장하였다. 또한 어텐션 메커니즘이 토큰 간의 순차적 위치 관계를 추출하지 못하는 한계를 극복하기 위해 LSTM (long short-term memory)과 트랜스포머가 결합된 인공지능 모델이 제안되었다[4].

본 논문에서 제안하는 자동 변조 인식 (AMR) 모델은 무선 신호의 특징을 효과적으로 추출하기 위해서 다음과 같이 구성된다. 먼저 수신 신호의 진폭과 위상으로부터 지역적 특징을 추출하기 위해 depthwise separable convolution 레이어와 ResNet으로 구성된다. 다음으로 합성곱 모델을 통해 임베딩된 시퀀스는 전역적인 특성을 반영하기 위해 트랜스포머와 GRU (gated recurrent unit)를 순차적으로 통과한다. 일반적으로 트랜스포머의 멀티 헤드 어텐션 메커니즘은 시퀀스 내의 종속성과 상호 관계를 포착하며, GRU는 시퀀스 데이터의 시간적 흐름을 효과적으로 임베딩하기 위해 사용된다. 마지막으로 트랜스포머와 GRU를 거쳐 추출된 고차원 특징은 FC (fully-connected) 레이어로 구성된 분류기로 전달된다. 분류기는 학습된 특징을 기반으로 사전 정보가 없는 수신 신호의 변조 방식을 최종적으로 분류한다. 모델의 학습을 위해 cross-entropy 손실 함수를 사용하였다.

III. 모의 실험

본 장에서는 RadioML[5]에서 제공하는 표준 변조 데이터 셋 RML2016.10a를 사용하였다. RML2016.10a는 아날로그와 디지털 변조 방식으로 변조된 11종류의 신호 (8PSK, BPSK, CPFSK, GFSK, PAM4, 16QAM, AM-DSB, AM-SSB, 64QAM, QPSK, WBFM)를 -20 dB부터 18 dB까지의 신호 대 잡음비 (SNR)에 따라 구성되어 있다. 각각의 데이터는 128개의 샘플을 포함하며 이는 128 μ s 동안의 신호를 의미하며, 신호의 진폭과 위상 성분을 모델의 입력 데이터로 사용하였다.

그림 1은 신호 대 잡음비에 따른 분류 정확도를 보여준다. TLDNN[4]과 제안하는 모델에 대하여 성능을 비교하였으며 모든 인공지능 모델은 전체 데이터 셋의 70%를 훈련데이터로 사용하였으며, 실험 결과는 10 epoch에서의 결과이다. 제안하는 모델은 TLDNN보다 10% 적은 학습 파라미터 수로 학습 초기에 유사한 성능을 달성하였으며 SNR이 낮은 경우 더 높은 정확도를 달성하는 것을 보였다.




그림 1. SNR (dB)에 따른 분류 정확도(%)

IV. 결론

본 논문에서는 사전 정보가 없는 수신 신호의 변조 방식을 식별하기 위한 자동 변조 인식 모델을 제안한다. 제안하는 모델은 수신 신호의 지역적 특성을 추출하는 합성곱 레이어와 잔차 신경망을 포함하고, 멀티 헤드 어텐션 메커니즘과 GRU를 통해 신호의 전역적 특성 및 시간적 종속성을 효과적으로 학습한다.

ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (NO.RS-2024-00397216, Upper-mid Band Extreme massive MIMO(E-MIMO) 시스템 기술 개발).

참 고 문 헌

- [1] B. Jdid, K. Hassan, I. Dayoub, W. H. Lim, and M. Mokayef, "Machine learning based automatic modulation recognition for wireless communications: A comprehensive survey," IEEE Access, vol. 9, pp. 57851–57873, Apr. 2021.
- [2] 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.
- [3] F. Zhang, C. Luo, J. Xu, Y. Luo, and F. Zheng, "Deep learning based automatic modulation recognition: Models, datasets, and challenges," Digit. Signal Process., vol. 129, Sep. 2022, Art. no. 103650, Sep. 2022.
- [4] Y. Qu, Z. Lu, R. Zeng, J. Wang, and J. Wang, "Enhancing Automatic Modulation Recognition Through Robust Global Feature Extraction," IEEE Trans. Veh. Technol., vol. 74, no. 3, pp. 4192–4207, Mar. 2025.
- [5] T. J. O'shea and N. West, "Radio machine learning dataset generation with GNU radio," in Proc. GNU Radio Conf., 2016, vol. 1, no. 1, pp. 1–6.