

OFDM 환경에서 저복잡도 CNN-GRU 기반 자동 변조 분류

위다영, 김유민, 박민규, 김태형

국민대학교

windy9161@kookmin.ac.kr, kym0739@kookmin.ac.kr, alsrb20511@kookmin.ac.kr, th.kim@kookmin.ac.kr

Low Complexity CNN-GRU Based Automatic Modulation Classification in OFDM Environments

Dayoung Wi, Yumin Kim, Mingyu Park, Taehyoung Kim

Kookmin University

요약

본 논문은 Orthogonal Frequency Division Multiplexing(OFDM) 기반 무선 통신 환경에서 자동 변조 분류 성능을 분석한다. 고속 이동과 큰 지연 확산을 갖는 복잡한 채널 조건을 대상으로 다양한 딥러닝 기반 Automatic Modulation Classification(AMC) 모델들의 분류 성능을 비교하였다. 실험 결과, 1D Convolutional Neural Network-Gated Recurrent Unit(CNN-GRU) 모델은 상대적으로 매우 낮은 모델 복잡도를 가지면서도, 높은 지연 확산과 이동 속도를 갖는 열악한 채널 환경에서 가장 우수한 분류 성능을 보였다. 또한 지연 확산이 증가함에 따라 모든 모델에서 분류 성능 저하가 관찰되었으나, CNN-GRU는 성능 감소 폭이 가장 작아 채널 열화에 대해 높은 강건성을 보였다. 이러한 결과는 CNN-GRU 기반 AMC가 복잡하고 열악한 무선 채널 환경에서도 효율적이고 안정적으로 적용될 수 있음을 시사한다.

I. 서론

자동 변조 분류(Automatic Modulation Classification, AMC)는 수신 신호로부터 변조 방식을 식별하는 기술로, 인지 무선 통신 및 지능형 통신 시스템에서 중요한 역할을 한다. 그러나 OFDM(Orthogonal Frequency Division Multiplexing) 기반 무선 통신 환경에서는 고속 이동으로 인한 도플러 확산과 다중 경로 전파에 따른 큰 지연 확산으로 인해 신호의 시간 및 주파수 선택성이 증가하며, 이로 인해 안정적인 변조 분류 성능 확보가 어려워진다.

최근 CNN(Convolutional Neural Network), RNN(Recurrent Neural Network), Transformer 계열의 딥러닝 기반 AMC 기법들이 이러한 문제를 해결하기 위해 제안되었다. CNN 기반 모델은 국소적인 신호 특징 추출에 효과적이며, RNN 계열 모델은 시간적 상관성을 고려할 수 있다. 또한 Transformer 기반 모델은 self-attention 메커니즘을 통해 시퀀스 데이터의 장기 의존성을 효과적으로 학습할 수 있어 복잡한 채널 환경에서의 AMC 문제에 대한 적용 가능성이 제시되고 있다.

이에 본 논문에서는 OFDM 기반 무선 통신 환경에서 CNN-GRU(1D Convolutional Neural Network-Gated Recurrent Unit) 기반 자동 변조 분류 모델을 중심으로 기존 딥러닝 기반 AMC 모델들과의 분류 성능을 비교 및 분석한다. 또한 고속 이동 환경과 큰 지연 확산을 고려하여, SNR(Signal-to-Noise Ratio) 변화 및 지연 확산 증가에 따른 CNN-GRU 구조의 성능 특성을 실험적으로 분석한다.

II. 시스템 모델

본 논문에서는 AMC를 위한 OFDM 기반 통신 시스템을 고려한다. 주파수 선택적 페이딩 채널과 AWGN(Additive White Gaussian Noise) 환경에서 1 번째 OFDM 심볼의 k 번째 서브캐리어에서 수신된 신호는 다음과 같이 표현된다.

$$Y_{k,l} = H_{k,l} \times X_{k,l} + N_{k,l} \quad (1)$$

$X_{k,l}$ 는 송신된 변조 심볼을 의미하고 $H_{k,l}$ 는 채널 주파수 응답, $N_{k,l}$ 는 AWGN을 나타낸다. 채널 주파수 응답은 파일럿 심볼을 이용하여 추정되며 추정된 채널은 $\hat{H}_{k,l}$ 로 표기한다. 채널 왜곡의 영향을 보상하기 위해 Zero-Forcing (ZF) 등화기를 적용한 심볼은 다음과 같이 계산된다.

$$\hat{X}_{k,l} = \frac{Y_{k,l}}{\hat{H}_{k,l}} \quad (2)$$

모든 자원 요소에 대한 등화 심볼 $\hat{X}_{k,l}$ 은 1차원 복소수 시퀀스 $x[t]$ 로 벡터화되고 각 원소는 다음과 같은 IQ(In-phase and Quadrature) 형태로 표현된다.

$$x[k,l] = i[k,l] + jq[k,l] \quad (3)$$

이후 복소수 신호의 실수부와 허수부를 분리하여 2채널 실수값 입력으로 구성한다.

$$\mathbf{x} = \begin{bmatrix} \mathbf{i} \\ \mathbf{q} \end{bmatrix} \in \mathbb{R}^{2 \times T} \quad (4)$$

T 는 서브캐리어 수와 OFDM 심볼 수에 의해 결정되는 전체 등화 심볼의 개수를 의미한다. 구성된 입력 벡터 \mathbf{x} 는 딥러닝 모델의 입력으로 사용된다.

III. 딥러닝 기반 자동 변조 분류 모델 구성

본 논문에서는 OFDM 기반 무선 통신 환경에서 자동 변조 분류 성능을 분석하기 위해 다양한 딥러닝 기반 AMC 모델들을 적용한다. 학습 데이터는 수신된 기저대역 OFDM 신호의 IQ 성분을 실수부와 허수부로 분리하여 구성하며, 다양한 무선 채널 환경을 반영하기 위해 SNR, delay spread, 이동 속도를 사전에 정의한 범위 내에서 설정하여 생성한다.

비교 대상으로는 자동 변조 분류 문제에서 기존에 널리 사용되어 온 LSTM(Long Short-Term Memory), ResNet(Residual Networks),

표 1. 시뮬레이션 파라미터

parameter	Value
Modulation schemes	BPSK, QPSK, 8PSK, 16QAM, 32QAM, 64QAM
Channel model	TDL-D
Carrier frequency	6 GHz
Subcarrier spacing	15 kHz
SNR range	0~15 dB
Delay spread	30~300 ns
Velocity	30~150 km/h
FFT size	64
Batch size	64
Maximum epochs	100

표 2. 파라미터 수

Model	Total parameters
CNN-GRU	36,198
GRUformer	1,294,406
Transformer	1,159,974
ResNet1D	3,847,430
LSTM	676,678

Transformer, GRUformer 기반 모델들을 고려한다. LSTM은 시퀀스 데이터의 시간적 특성을 학습하는 구조이며, ResNet은 합성곱 연산을 통해 입력 신호로부터 국소적인 패턴을 추출하는 데 강점을 가진다. Transformer와 GRUformer 모델은 self-attention 메커니즘을 활용하여 시퀀스 전반에 걸친 장기 의존 관계를 효과적으로 학습할 수 있다.

CNN-GRU 구조는 CNN 계층을 통해 입력 신호로부터 국소적인 변조 특징을 우선적으로 추출한 뒤, GRU(Gated Recurrent Unit) 계층을 적용하여 시간에 따른 신호 특성을 반영한다. CNN 계층에서 추출된 특징은 시퀀스 형태로 GRU 계층에 입력되며, GRU 계층의 출력은 분류 계층을 거쳐 최종 변조 방식으로 결정된다. 이후 실험 결과를 통해 CNN-GRU 모델과 기존 딥러닝 기반 AMC 모델들의 성능을 비교 및 분석한다.

IV. 실험 결과

본 실험에서는 64개의 서브캐리어와 9개의 OFDM 심볼로 구성된 하나의 OFDM 자원 그리드를 사용하였다. 이 중 1개의 OFDM 심볼을 파일럿으로 할당하여 채널 추정 및 등화를 수행하였다. 64×9 OFDM 자원 그리드를 하나의 프레임으로 정의하였으며, 각 변조 방식별로 100,000개의 프레임을 생성하였다. 데이터 구성에 대한 세부 사항은 표 1에 제시한다.

OFDM 환경에서 delay spread와 이동 속도를 고려한 채널 조건하에서 CNN-GRU 기반 자동 변조 분류 모델과 기존 딥러닝 기반 모델들의 분류 성능을 비교하였다. 그림 1은 delay spread를 300 ns, 이동 속도를 150 km/h로 설정한 열악한 채널 환경에서 SNR 변화에 따른 자동 변조 분류 성능을 나타낸다. 해당 결과로부터 CNN-GRU 기반 모델이 전 SNR 구간에서 상대적으로 높은 분류 정확도를 안정적으로 유지함을 확인할 수 있다. 그림 2는 이동 속도를 150 km/h, SNR을 10 dB로 고정한 상태에서 delay spread 증가에 따른 분류 성능 변화를 나타낸다. 실험 결과, CNN-GRU 모델은 정확도 감소 폭이 가장 작게 나타나 delay spread 증가에 대해 높은 강건성을 보였다. 또한 표 2에 제시된 바와 같이 CNN-GRU 모델은 비교 모델 대비 가장 적은 파라미터 수를 가지면서도 열악한 채널 환경에서 우수한 분류 성능을 달성하여, 낮은 모델 복잡도 대비 높은 성능 효율을 보이는 것으로 확인된다.

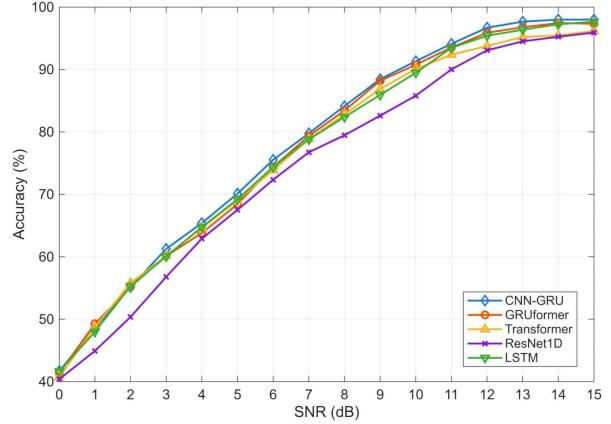


그림 1. SNR에 따른 분류 정확도

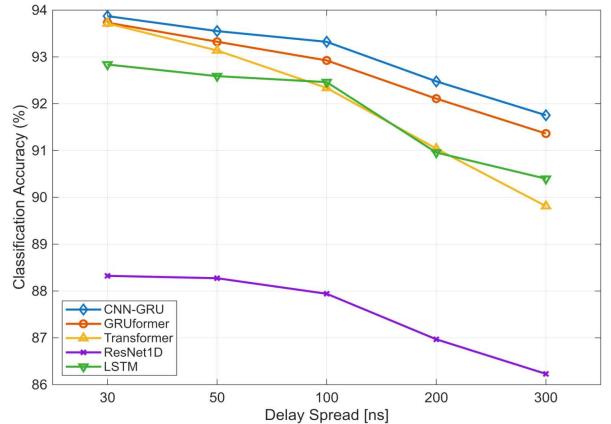


그림 2. Delay spread에 따른 분류 정확도

V. 결론

본 논문에서는 실험 결과를 통해 CNN-GRU 기반 자동 변조 분류 모델이 OFDM 기반 무선 통신 환경에서 효과적으로 적용될 수 있음을 확인하였다. 특히 고속 이동과 큰 지연 확산이 있는 복잡한 채널 환경에서도 CNN-GRU 기반 모델은 기존 딥러닝 기반 모델들과 비교하여 상대적으로 안정적인 분류 성능과 작은 성능 저하를 보였다. 또한 CNN-GRU 모델은 적은 파라미터 수를 가지는 저복잡도 구조임에도 불구하고 경쟁력 있는 분류 성능을 유지함으로써, 성능과 모델 복잡도 측면에서 모두 효율적인 특성을 나타냈다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.RS-2024-00397789).

참고 문헌

- [1] S. Huang et al., "Generalized Automatic Modulation Classification for OFDM Systems Under Unseen Synthetic Channels," in IEEE Transactions on Wireless Communications, vol. 23, no. 9, pp. 11931–11941, Sept. 2024.
- [2] Y. Zhou, T. Lin, and Y. Zhu, "Automatic modulation classification in time-varying channels based on deep learning," IEEE Access, vol. 8, pp. 197508–197522, 2020.
- [3] 3GPP, "Study on channel model for frequencies from 0.5 to 100 GHz," 3GPP TR 38.901, ver. 18.0.0 (Release 18), Apr. 2024, Retrieved Dec, 2025