

# 트랜스포머를 이용한 채널 코딩 기술 연구

김수환, 이정우  
서울대학교 전기정보공학부

curtis05@cml.snu.ac.kr, junglee@snu.ac.kr

## Transformer-based Channel Codes for Communication Channels

Suhwan Kim, Jungwoo Lee

Department of Electrical and Computer Engineering, Seoul National University

### 요약

통신 채널에서의 노이즈를 해결하기 위해서 여러 가지 코드 설계 방식이 등장하였으며 샤논 한계에 근접하는 성능을 달성하기 위해 여러 연구가 수행되었다. 최근 여러 노이즈 환경에서의 최적의 채널 코드를 찾기 위해 딥 러닝 기반 방법들이 등장하였으나, CNN 및 RNN 을 사용하고 있어 채널 코딩 및 디코딩에 단기 메모리만 활용하게 되므로 낮은 성능을 보였다. 본 논문에서는 장기 메모리를 활용할 수 있는 트랜스포머 구조를 통해 CNN 및 RNN 을 사용한 채널 코드보다 좋은 성능을 보이는 채널 코드를 만드는 방법을 연구하였다.

### I. 서론

통신 시스템에서, 송신기와 수신기 사이의 채널은 랜덤 노이즈를 포함하고 있기 때문에 정확한 정보의 전달을 위해서는 효율적인 정보 코딩 방법과 이를 복원하는 방법이 필수적이다. 노이즈에 강건한 코드를 생성하기 위해서 송신기는 메시지를 중복적으로 사용해서 코드로 변환하고, 이는 채널을 통과하며 노이즈가 더해진 상태로 수신기에 전달된다. 수신기는 노이즈가 더해진 코드를 통해 원래의 메시지를 추정하게 된다.

효율적이고 고성능의 채널 코드 설계와 BER(Bit Error Rate)를 최소화하기 위한 디코드 기법을 위해 많은 전통적인 연구들이 있어 왔고, 수십 년의 연구 끝에 최근 샤논 한계에 근접하는 채널 코딩 기법들이 등장하기 시작했다. 그러나 이러한 방법들은 주로 정규 가산 백색 가우시안 노이즈(AWGN) 채널을 가정하고 설계되었으며, 실제 채널에서는 채널이 이러한 노이즈 가정을 벗어나는 일이 종종 발생하기 때문에 샤논 한계[1]에 못 미치는 성능을 보여주게 된다.

최근 사람이 직접 채널 코드를 설계하는 방법 대신 딥 러닝을 이용하여 정보를 인코딩 한 후 디코더에서 이를 복원하는 방법들이 제시되었다. 대표적으로 CNN 을 이용하여 인코더 및 디코더를 설계하는 방법[2] 이 등장하였고, CNN 대신 RNN 을 이용한 방법[3] 역시 등장하였다. 위 방법들의 공통적인 특징은 인코더와 디코더를 종단간 학습(End-to-End training)으로 훈련한다는 것이다. 이러한 방법을 통해 채널 상황에 따른 최적의 코드를 데이터 기반으로 찾아내어 사람이 직접 채널 상황에 맞는 복잡한 코드를 설계하는 노고를 줄이고 채널 노이즈에 대한 단순한 가정 없이 복잡한 채널에 대해서도 최적에 가까운 코드를 생성해 낼 수 있다.

그러나 위 방법들은 실제로는 모든 상황에 대해 최적의 성능을 내지 못한다. 이러한 이유는 CNN 및 RNN 이 지역적인 정보만을 이용할 수 있기 때문인데, 인코딩 시의 랜덤성이 긴 코드 블록 길이에서 코딩 이득(Coding gain)을 얻는 데 필수적임에도 불구하고[1], CNN 및 RNN 기법들은 중간 길이의 코드 블록에서도 충분한 효율을 내지 못하는 성능을 보여주었다.

이에 본 논문에서는 지역 정보만을 활용하는 것이 아닌 전체 시퀀스에 대해서 정보를 처리하는 트랜스포머(Transformer)를 이용하여 종단 간 학습으로 채널 코드 및 디코딩을 수행하는 방법에 대해 연구하였다. CNN 및 RNN 을 사용하는 기법과 트랜스포머를 사용하는 기법에 대해서 긴 코드 블록에서의 성능을 비교 검증하고, 정규 가산 백색 가우시안 노이즈 채널 외의 비정규 채널에서도 성능 이득을 얻을 수 있음을 확인하는 것을 목표로 한다.

### II. 본론

**채널 코딩 문제** 채널 코딩 문제는 인코더, 채널, 디코더 세 가지 부분으로 구분할 수 있다. 인코더는 길이  $K$  의 메시지 시퀀스를 길이  $N$  의 코드로 인코딩하게 된다 ( $K < N$ ). 채널은 인코더가 생성한 코드에 랜덤한 노이즈를 더하게 되고, 디코더는 노이즈가 더해진 코드를 원래의 메시지로 복원한다.

채널 코딩은 복원된 메시지와 원래의 메시지 간의 에러를 최소화하는 것을 목표로 한다. 가장 표준적인 척도는 BER(Bit Error Rate)이며 메시지를 비트 단위에서 비교하여 정답 비트의 비율을 측정한다.

트랜스포머를 이용한 인코더 및 디코더 모듈 기준

에 연구되었던 딥 러닝 기반의 인코더 및 디코더는 주로 CNN 과 RNN 을 이용하였으며, FCN(Fully Connected Network)의 경우 단순한 반복 코딩보다도 낮은 성능을 보여주었다[2]. CNN 과 RNN 을 활용한 경우 성능이 나아지지만, 여전히 지역 정보만을 활용하기 때문에 성능이 충분하지 못하다. 본 연구에서는 지역 정보만을 활용할 수 있는 CNN, RNN 과는 달리 전체 시퀀스에 산재된 정보를 이용할 수 있는 Transformer 구조를 활용한 딥 러닝 기반 인코더 및 디코더를 설계하고 실제로 블록 길이에 대해서 성능 이득을 볼 수 있는지 확인하였다. 또한 AWGN 채널 및 ATN(Additive T-distribution Noise) 채널에서 기존 딥 러닝 기반 방법과의 성능을 비교하여 보았다.

**실험 및 결과** 본 논문에서는 원본 메시지에 비해 3 배 긴 코드를 사용하였고, 동일한 전력을 사용하기 위해 채널로 전송되는 코드에 power constraint 를 적용하였다. 메시지는 이진수로 나타내어지며 코드는 연속적인 수로 나타내어진다. 본 실험에서는 인코더를 통해 이진 메시지를 코드로 변환한 이후 노이즈를 더해주는 방식을 통해 채널 전송 상황을 시뮬레이션 하였다. 이렇게 노이즈가 더해진 신호를 디코더를 이용하여 원본 메시지로 복원하도록 딥 러닝 모델들을 학습시켰다. 그 후 학습된 모델을 통해 여러가지 noise level 에 따라서 BER 을 측정해 보았다. 트랜스포머의 경우 Transformer Encoder 모듈만을 사용해서 구현하였다. 실험 결과는 다음과 같다.

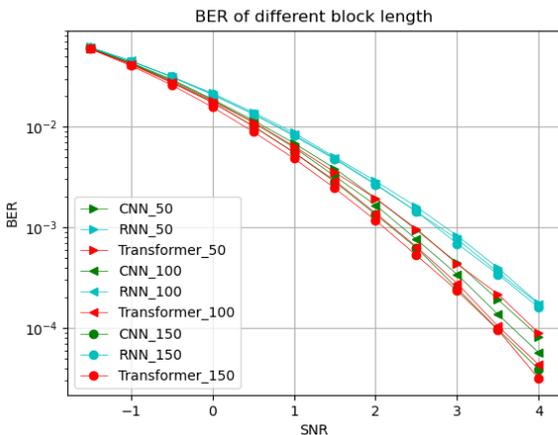


그림 1: 코드 블록 길이에 따른 성능 비교

그림 1 은 코드 블록 길이를 변화시킴에 따라 딥 러닝 모델 별 성능 변화를 보여준다. 세 모델 모두 블록 길이가 증가함에 따라 성능이 조금씩 좋아지는 모습을 보인다. RNN 은 블록 길이가 증가함에 따라 미미한 성능 이득을 보였고, 셋 중 가장 낮은 성능을 보인 반면 CNN, 트랜스포머의 경우 코드 길이가 증가함에 따라 성능 이득을 보이는 모습을 확인할 수 있었다. 또한 트랜스포머는 세 종류의 방법들 중 가장 낮은 BER 을 계속 달성하는 것을 확인할 수 있었다.

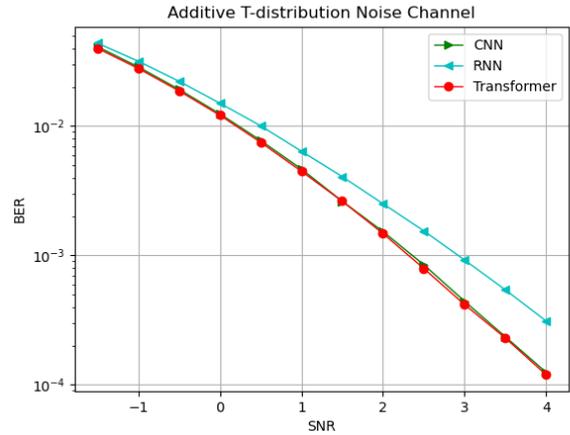


그림 2: 비정규 채널에서의 성능 비교

그림 2 는 Gaussian 노이즈가 아닌 T-distribution 노이즈에 대한 성능을 모델별로 비교한 결과이다. RNN 이 가장 낮은 성능을 보였고, 트랜스포머가 CNN 보다 약간 우세한 성능을 달성함을 확인하였다.

### III. 결론

본 논문에서는 딥 러닝 기반 채널 코딩 기술에 대해 탐구하고, 트랜스포머를 사용한 채널 코딩 방법의 성능을 다른 딥 러닝 기반 모델들과 비교하여 보았다. 트랜스포머를 사용할 경우 블록 길이가 증가하더라도 다른 모델들에 비해 더 좋은 성능을 보이며 비정규 채널에서도 다른 모델보다 우세한 성능을 보임을 확인하였다.

### ACKNOWLEDGMENT

This work was supported by Samsung Electronics Co., Ltd (Contract ID: MEM210728\_0001), National R&D Program through the National Research Foundation of Korea(NRF) funded by Ministry of Science and ICT(2021M3F3A2A02 037893), INMAC, and BK21 FOUR program.

### 참고 문헌

- [1] C. E. Shannon, "A mathematical theory of communication, part i, part ii," Bell Syst. Tech. J., vol. 27, pp. 623- 656, 1948.
- [2] B. Zhu, J. Wang, L. He and J. Song, "Joint Transceiver Optimization for Wireless Communication PHY Using Neural Network," in IEEE Journal on Selected Areas in Communications, vol. 37, no. 6, pp. 1364-1373, June 2019.
- [3] Y. Jiang, H. Kim, H. Asnani, S. Kannan, S. Oh and P. Viswanath, "LEARN Codes: Inventing Low-Latency Codes via Recurrent Neural Networks," in IEEE Journal on Selected Areas in Information Theory, vol. 1, no. 1, pp. 207-216, May 2020.