

AWGN channel에서의 pre-training을 활용한 BSC 및 Rayleigh 채널에 서 Error Correction Code Transformer의 성능 개선

권형욱, 이주형, 윤대영, 곽희열

울산대학교

ghk9927@mail.ulsan.ac.kr, wngud387@mail.ulsan.ac.kr,

yundy@ulsan.ac.kr, hykwak@ulsan.ac.kr

Performance Enhancement of Error Correction Code Transformer for the BSC and Rayleigh channels by pre-training in the AWGN channel

Hyeonguk Kwon, Juhyeong Lee, Daeyoung Yun, Heeyoul Kwak

University of Ulsan

요약

본 논문은 error correction code transformer (ECCT)의 binary symmetric channel (BSC) 및 Rayleigh와 같은 다양한 무선 통신 채널에서의 성능 향상 기법을 제시한다. 기존 ECCT의 학습 방법은 additive white Gaussian noise (AWGN) 채널 환경에서 효과적으로 적용될 수 있지만, BSC 채널이나 Rayleigh 채널에서는 적용에 한계를 보인다. 이를 해결하기 위해 AWGN 채널에 사전 학습 (pre-training)된 모델을 BSC와 Rayleigh 채널에서 미세 조정 (fine-tuning) 하는 방식을 제안한다. 사전 학습된 모델은 다른 채널에서도 준수한 복호 성능을 보이며 미세 조정으로 추가적인 성능 개선을 이루어 낼 수 있다. 또한 미세 조정된 모델은 처음부터 각 채널에서 개별적으로 학습된 모델보다 복호 성능이 우수하다.

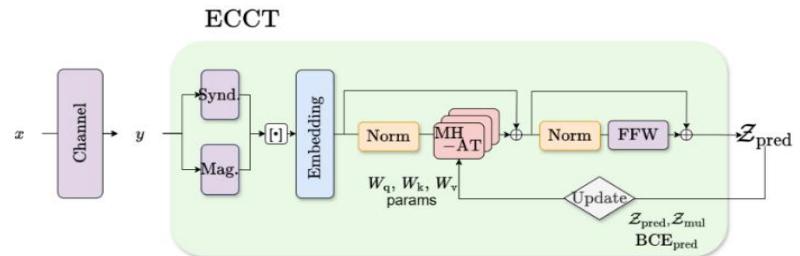
I. 서론

통신 시스템에서 신뢰성의 핵심인 오류 정정 부호 (ECC) 분야에서 최근 딥러닝의 활용이 중요해지고 있다. 이러한 흐름 속에서, 자연어 처리 등 다양한 분야에서 성공적으로 적용된 Transformer[1] 모델을 기반으로 한 error correction cod transformer (ECCT) 가 제안되었다. ECCT는 딥러닝의 표현 학습 능력을 활용하여 고성능 복호 성능 달성을 잠재력을 보인다. 그러나, 기존 연구에서는 주로 AWGN 채널만을 학습 및 평가하였고 binary symmetric channel (BSC) 및 Rayleigh 채널에서는 학습이 원활히 이루어지지 않는다. 따라서 이 한계를 해결하고자, ECCT가 기본적인 복호 능력을 갖추기에 적합한 학습 채널인 AWGN 채널에서 사전 학습 (pre-training) 을 먼저 수행하고, BSC 및 Rayleigh 채널에서 미세 조정 (fine-tuning) [3] 하는 전이 학습 방법을 제안한다. 실험 결과, 제안 방법이 각 채널별 독립 학습 모델 대비 향상된 복호 성능을 달성을 확인하였다.

II. ECCT의 학습 방법

ECCT의 학습 방법은 <그림 1>과 같다. 송신된 이진 코드 워드(x)는 통신 채널을 거치며 잡음 및 간섭 등의 왜곡에 의해 수신 신호(y)로 표현된다. 디코더는 수신 신

호로부터 각 비트의 신뢰도를 나타내는 Magnitude와 패리티 검사식의 위반 여부를 나타내는 Syndrome을 산출한다. 이 두 정보를 ECCT에 입력하여, 각 비트별 오류 발생 확률(Z_{pred})을 출력한다. 그리고, 실제 비트의 오류 발생 여부를 나타내는 Z_{mul} 와 비교를 통해 둘 사이의 차이에 대한 손실값을 계산한다. 계산된 손실은 모델의 예측에 대한 오차의 정도를 나타내며, 이 손실을 줄이는 방향으로 모델의 파라미터들이 역전파와 옵티마이저를 통해 갱신된다. 이 과정을 반복하며 모델은 채널 왜곡과 코드 구조 간 상호작용을 학습하여 효과적인 오류 복호 능력을 갖추게 된다.

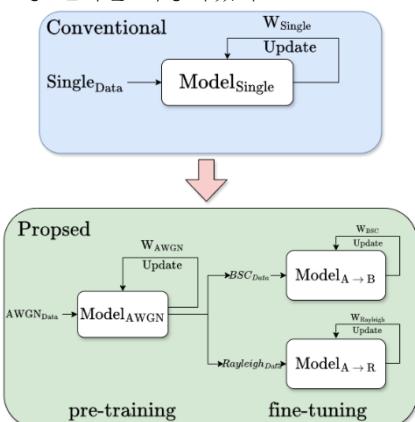


<그림 1> ECCT 동작 및 학습 방법

III. 제안하는 학습 방법

논문 [2]에서 사용된 학습 방법은 채널의 종류에 무관하게 사용 가능하다. 이 학습 방법이 적용될 수 있도록 BSC채널과 Rayleigh채널을 아래와 같이 표현하였다. BSC 채널은 각 비트가 오류 확률 (p)에 따라 독립적으로 반전되도록 모델링 된다. 수신 신호의 수식은 $y_i = sign_{flips} \cdot x_i$ 로 표현된다. 여기서 $sign_{flips} = -1$ 일 때 오류(비트 반전), +1일 때 정상 수신을 의미한다. Rayleigh 채널은 각 비트에 Rayleigh 분포를 따르는 페이딩 계수 h_i 를 곱하였고, AWGN 잡음 z_i 를 더하여, $y_i = h_i \cdot x_i + z_i$ 로 표현된다.

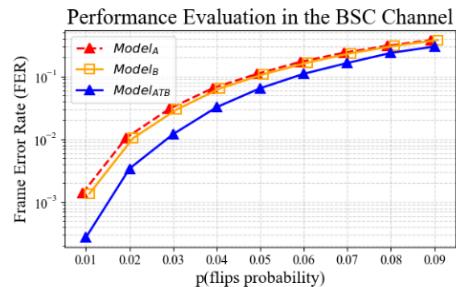
본 연구에서는 <그림 1>의 학습 방법을 AWGN, BSC, Rayleigh 채널에서 각각 적용해 보았다. 적용 방법을 간단하게 표현해보면 <그림 2>의 Conventional 방법과 같이 표현할 수 있다. 그 결과, AWGN 채널과 달리 BSC, Rayleigh 채널에서는 최대화된 복호 성능을 얻을 수 없었다. 이는 BSC 및 Rayleigh 채널이 ECCT가 기본적인 복호 기능을 학습 하기에 적합하지 않은 채널이기 때문이라고 보인다. 특히, BSC채널은 ECCT의 입력 정보 중 magnitude가 동일하기 때문에 학습 정보가 부족하다고 볼 수 있다. 따라서 <그림 2>와 같은 새로운 학습 방법을 제안한다. 각 채널에 학습하기 이전 AWGN채널을 사전학습 시킨다. 이때, AWGN채널을 사전 학습 모델로 선정한 이유는 잡음 왜곡 특성을 대표하는 기초 환경으로서 ECCT가 안정적으로 일반화 특성을 학습하기에 가장 적합하기 때문이다. 사전 학습 시 학습량은 AWGN채널에 과적합되지 않도록 설정한다. 다음, BSC 및 Rayleigh 채널의 학습 데이터를 사전 학습된 모델에 입력시켜 각 채널에 조정되는 미세 조정 전략을 사용하였다.



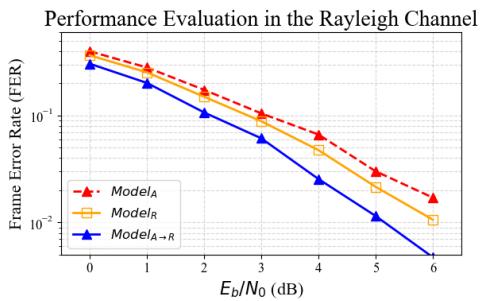
<그림2> 기존 방법과 제안하는 방법의 학습 방법 비교

IV. 모의 실험 결과

본 논문에서 제안하는 학습 방법의 성능을 검증하기 위해 BCH(31, 16)부호를 적용한 모의 실험을 수행하였다. <그림 3>과 <그림 4>에 각각 BSC채널과 Rayleigh 채널에서의 복호 성능 결과를 제시한다. 성능 비교를 위해 세 가지 모델을 고려하였다: 논문 [2]에서 제안된 AWGN, BSC, Rayleigh 채널에서 학습된 모델들을 각각 $Model_A$, $Model_B$, $Model_R$ 이라고 하자. 그리고 본 논문에서 제안하는 AWGN에서 사전학습한 뒤 BSC 및 Rayleigh에서 미세조정 한 모델 각각 $Model_{A \rightarrow B}$, $Model_{A \rightarrow R}$ 이라 하자.



<그림3> BSC Channel 실험 결과



<그림4> Rayleigh Channel 실험 결과

<그림 3>은 BSC채널 환경에서의 복호 성능을 보여준다. BSC채널은 비트 반전 오류 발생 여부를 판단하기 때문에 Magnitude의 정보에 대한 학습이 적어 단일 채널과 논문 [2]의 모델이 거의 비슷한 성능을 보임을 확인할 수 있다. 하지만, fine tuning을 통해 BSC채널에 더 잘 적응하여 복호 성능이 크게 향상됨을 확인하였다.

<그림 4>는 Rayleigh 채널 환경에서의 복호 성능을 보여준다. BSC와는 달리 Magnitude와 Syndrome의 정보를 모두 학습하기 때문에 단일 채널 학습 모델이 논문[2]의 모델보다 좋은 성능을 보였다. 여기서, Fine tuning을 적용함으로 가장 우수한 복호 성능을 달성함을 확인하였다.

V. 결론

본 논문에서는 ECCT 모델의 성능 개선을 위해 BSC 및 Rayleigh 채널에서의 미세조정 학습 전략을 제안 및 검증하였다. 제안한 방법은 복호 기능을 학습 하기 어려운 채널에서 AWGN 채널의 사전 학습을 통해 효과적으로 BSC 및 Rayleigh 채널에서 학습을 할 수 있었던 것으로 보인다. 특히, BSC 채널에서 본 논문에서 제안하는 학습 방법이 효과적인 것을 볼 수 있다.

참고 문헌

- [1] Vaswani, Ashish, et al. "Attention is all you need." Advances in neural information processing systems 30 (2017).
- [2] Choukroun, Yoni, and Lior Wolf. "Error correction code transformer." Advances in Neural Information Processing Systems 35 (2022): 38695–38705.
- [3] Howard, J., & Ruder, S. "Universal language model fine-tuning for text classification." In Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics, 2 Volume 1 (2018):pp. 328–339