

Latent 분해 및 SNR 입력 게이팅을 활용한 시맨틱 통신 기법

최은

성균관대학교

eunc812@g.skku.edu

Semantic Communication Using Partitioned Latent and SNR-Conditioned Gating

Choi Eun

Sungkyunkwan Univ.

요약

기존 JSCC 모델들은 인코더 출력을 단일 표현으로 사용하고 SNR 정보를 반영하는 방법이 제한적이다. 이는 저 SNR에서의 성능 감소로 이어질 수 있다. 이에 본 연구에선 DeepJSCC 계열인 DeepSC의 인코더 출력을 분해하여 구성 요소별 다른 표현 특성을 갖도록 유도하고 SNR을 조건 입력으로 사용하여 분리된 의미 요소들을 가중 조합하는 구조를 제안한다. 시뮬레이션 결과, 제안한 방법은 SNR 0-20dB 구간에서 DeepSC 모델보다 더 높은 BLEU와 sentence similarity를 기록했으며 실험 조건에 따라 각각 최대 0.6, 0.4 증가했다.

I. 서론

6G 통신에선 초저지연, 초고속 전송을 위해 전통적인 비트 기반 전송을 넘어 의미 단위의 정보를 전달하는 시맨틱 통신[1]이 떠오르고 있다. 인코더와 디코더를 함께 최적화하는 JSCC[2]에 딥러닝을 결합한 DeepJSCC 모델 중 DeepSC 모델은 트랜스포머를 통해 텍스트 전송을 End to End로 최적화하며 기존 JSCC보다 더 우수한 성능을 확보했다.[3] 그럼에도 불구하고 이 방법은 인코더 출력을 하나의 역할로만 사용하며 저 SNR에서 성능 열화가 두드러지는 경향이 관찰된다.

이에 본 연구에선 표현 학습 관점에서 인코더가 생성하는 latent 표현이 의미 정보를 얼마나 효과적으로 담도록 disentangle 하는지가 최종 성능에 중요한 영향을 미친다는 점에서 착안하여 인코더 출력을 구성 요소들로 분리하여 서로 다른 표현 특성을 갖도록 유도한다.[4] 또 highway network에서 사용된 gating을 참고하여, SNR을 조건으로 반영하여 분리된 의미 요소의 조합을 달리한다.[5]

II. 본론

1) 제안 기법

제안하는 기법은 인코더 출력 M 을 z_{sem} , z_{rob} , z_{snr} 으로 분리한다:

$$z_{sem} = W_{sem} \cdot M \quad (1)$$

$$z_{rob} = W_{rob} \cdot M \quad (2)$$

$$z_{snr} = W_{snr} \cdot M + f(SNR) \quad (3)$$

여기서 f 는 SNR 스칼라 값을 z_{snr} 과 동일한 차원으로 매핑하는 MLP다.

z_{snr} 을 입력으로 게이팅 네트워크는 w_{sem} , w_{rob} 를 산출한다:

$$g(z_{snr}) = W_g z_{snr} + b \quad (4)$$

$$[w_{sem}, w_{rob}] = \text{softmax}(g(z_{snr})) \quad (5)$$

각 의미 요소는 z_{total} 에 포함돼 채널을 통해 전송된다:

$$z_{total} = w_{sem} \cdot z_{sem} + w_{rob} \cdot z_{rob} \quad (6)$$

z_{sem} 은 채널 디코더 복원 신호 \hat{M} 에 더해져 의미 복원에 필요한 정보 위주로 학습되도록 유도된다:

$$C = \hat{M} + \alpha \cdot z_{sem} \quad (7)$$

여기서 α 는 학습 가능한 스칼라이다.

2) 시스템 모델

제안한 방법의 구조는 그림 1과 같다. 인코더 출력 M 은 z_{sem} , z_{rob} , z_{snr} 의 세 요소로 분리된다. z_{snr} 은 게이팅 및 softmax 함수를 거쳐 z_{sem} , z_{rob} 의 가중치를 결정한다. z_{sem} 은 채널을 거친 후 디코더 출력과 더해져 의미 복원에 필요한 정보를 학습하도록 유도된다. z_{rob} 은 채널경로를 통과해 전달되며 z_{sem} 과 구분되는 보조 표현으로 활용된다. z_{snr} 은 SNR 조건을 입력으로 하여 z_{sem} , z_{rob} 사이의 채널 조건을 반영한 가중치를 학습한다.

3) 시뮬레이션 결과

본 연구에선 DeepSC 모델에 제안 구조를 반영하고 시뮬레이션하여 문장 단위 의미 전달 성능을 평가했다. Europarl Corpus 데이터 셋을 사용하여 AWGN, rayleigh, rician 3가지 채널 환경에서 학습했다. 학습 후 BLEU 점수와 sentence similarity를 통해 의미 전달 성능을 그림 2-4와 같이 평가했다. BLEU는 1-gram부터 4-gram까지의 n-gram 정밀도를 동일 가중치로 반영한 sentence-level BLEU-4 점수를 사용했으며 sentence similarity는 SBERT 임베딩 간 cosine similarity로 계산했다.

시뮬레이션 결과 SNR 전구간에서 DeepSC 모델 대비 성능 향상이 나타나며 저 SNR 구간으로 갈수록 이 성능 향상이 두드러졌다. 기존 방법보다 최대 0.6 BLEU, 0.4 sentence similarity 증가를 보였다.

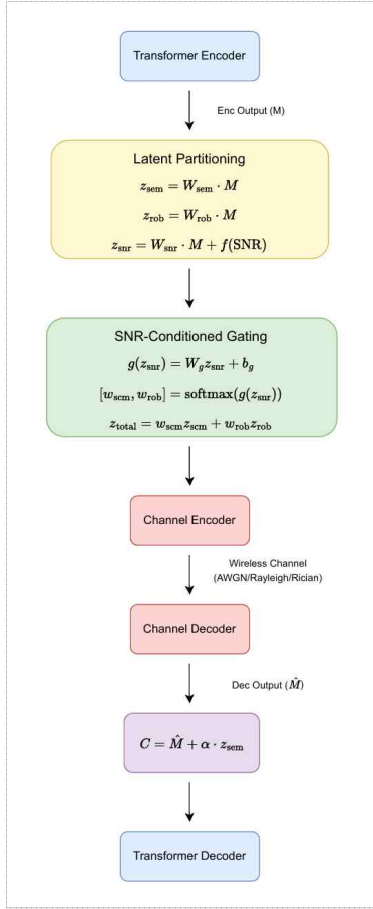


그림 1. 시스템 모델 개략도




그림 2. AWGN 채널에서의 BLEU 및 sentence similarity




그림 3. rayleigh 채널에서의 BLEU 및 sentence similarity




그림 4. rician 채널에서의 BLEU 및 sentence similarity

III. 결론

본 연구는 semantic DeepJSCC(DeepSC) 기반 텍스트 전송에서 인코더 출력을 여러 구성 요소로 분할하고 채널 조건(SNR)을 입력으로 사용하여 구성 요소들의 가중 결합을 수행하는 구조를 제안했다. 실험 결과 AWGN/rayleigh/rician 채널에서 제안 구조는 SNR 0 - 20dB 전 구간에 대해 DeepSC 대비 BLEU 및 sentence similarity가 향상됨을 확인했다. 특히 그림 2-4에서 확인되듯, 저 SNR 구간에서 개선이 상대적으로 두드러지며 이는 저 SNR 환경에서 제안 구조가 텍스트 의미 복원 성능을 개선할 수 있음을 나타낸다. BLEU와 sentence similarity는 각각 최대 0.6, 0.4 증가했다. 다만 각 구성 요소의 역할 분리가 엄밀히 보장되지 않으며 구성 요소 간의 상호성 및 게이팅 동작의 구체적 분석은 향후 연구로 남긴다.

참고 문헌

- [1] Z. Qin, X. Tao, J. Lu, W. Tong, and G. Y. Li, "Semantic communications: Principles and challenges," arXiv preprint arXiv:2201.01389, 2022.
- [2] E. Boursoulatz, D. B. Kurka, and D. Gündüz, "Deep joint source-channel coding for wireless image transmission," in *Proc. IEEE Int. Conf. Acoustics, Speech and Signal Processing (ICASSP)*, Brighton, UK, 2019, pp. 4774 - 4778.
- [3] H. Xie, Z. Qin, G. Y. Li and B. -H. Juang, "Deep learning enabled semantic communication systems," in *IEEE Transactions on Signal Processing*, vol. 69, pp. 2663-2675, 2021.
- [4] Y. Bengio, A. Courville and P. Vincent, "Representation Learning: A Review and New Perspectives," in *IEEE Transactions on Pattern Analysis and Machine Intelligence*, vol. 35, no. 8, pp. 1798-1828, Aug. 2013.
- [5] R. K. Srivastava, K. Greff, and J. Schmidhuber, "Highway networks," in *Proc. Int. Conf. Machine Learning (ICML) Workshop on Deep Learning*, 2015, arXiv:1505.00387.