

채널 적응형 시맨틱 통신을 위한 벡터 양자화 기반 공동 소스-채널 부호화

신준용, 전요셉
포항공과대학교

{sjyong, yoseb.jeon}@postech.ac.kr

Vector-Quantization-based Joint Source-Channel Coding for Channel Adaptive Semantic Communications

Junyong Shin, Yo-Seb Jeon
Pohang Univ. of Science and Technology (POSTECH)

요약

본 논문은 다양한 채널 환경에 강인한 채널 적응형 시맨틱 통신을 위해 벡터 양자화 지원 공동 소스-채널 부호화(JSCC)를 제안한다. 제안된 기법은 벡터 양자화 모듈이 포함된 Autoencoder 모델을 이용해 정보를 효율적으로 압축 및 복원한다. 벡터 양자화 모듈은 단일 벡터 코드북에 포함된 여러 크기의 하위 벡터 코드북을 통해 양자화하여 채널 환경에 맞는 다중 전송률을 지원한다. 모의 실험을 통해 제안된 기법이 다중 전송률이 지원되는 단일 모델을 제공하여 채널 적응력을 높일 뿐만 아니라, 각각 따로 학습된 단일 전송률 모델보다 각 채널 환경에서 더 나은 성능을 보인다는 것을 보인다.

I. 서론

시맨틱 통신(Semantic Communications)은 송수신기 간의 지식 기반을 정렬함으로써, 적은 양의 비트를 송수신하는 것만으로도 대용량 데이터 처리 및 빠른 과제 수행을 가능케 하는 것을 목표로 한다. 이는 딥러닝(Deep learning) 기반의 공동 소스-채널 부호화(JSCC)를 통해 정보의 압축 및 오류정정능력 부여를 통해 의미론적 정보(Semantic Information)를 교환하는 것으로 많은 기존 연구들에서 행해진 바가 있다. 본 기법을 활용하여 Semantic information 을 전송하는 경우, 해당 information 을 유한 비트로 변환시키기 위해 이를 위한 딥러닝 기반 양자화 기법이 복합적으로 고려되어야 한다. 또한, 수신기의 다양한 채널 환경에 맞는 강인한 통신을 위해 다중 전송률을 지원하는 단일 모델이 필요할 것이다.

본 논문에서는 이와 같은 문제들을 해결하기 위해, 다중 전송률 시맨틱 통신을 위한 JSCC 기법을 제안한다. 제안된 기법은 벡터 양자화 모듈을 딥러닝 기반의 Autoencoder 모델과 공동학습 시킴으로써, 유한 비트 상에서의 Semantic Information 교환을 가능케 한다. 또한, 벡터 코드북 내에 여러 크기의 하위 벡터 코드북을 구성함으로써, 단일 모델 상에서 여러 전송률을 지원하는 모델을 제안하고자 한다. 해당 기법은 다양한 전송률을 유한 비트 상에서 지원할 뿐만 아니라, 단일 전송률 모델보다 더 나은 성능을 보인다는 것이 모의실험 결과에서 입증될 것이다.

II. 본론

본 논문에서는 이미지 데이터 \mathbf{x} 를 압축 및 복원하는 과제를 수행하는 통신 시스템을 고려한다. 송신기는 먼저 특정 이미지를 JSCC encoder 신경망 f_{enc} 를 거쳐 M 차원의 잠재벡터 \mathbf{z} 로 압축되고, \mathbf{z} 는 L 가지 양자화률을 지원하는 양자화 모듈 $Q^{(l)}$ ($l \in \{1, \dots, L\}$)를 통해 양자화된다. 결국 $\mathbf{z}_q^{(l)}$ 가 바로 semantic information에 해당하게 되고, 이 $\mathbf{z}_q^{(l)}$ 는 송신되는 과정에서 특정 channel impairment \mathcal{H} 를 겪어 $\tilde{\mathbf{z}}_q^{(l)} = \mathcal{H}(\mathbf{z}_q^{(l)})$ 로 변환된 상태로

수신기로 수신된다. 수신기는 decoder 신경망 f_{dec} 를 통해 이미지 데이터를 $\hat{\mathbf{x}}^{(l)} = f_{dec}(\tilde{\mathbf{z}}_q^{(l)})$ 로써 복원한다.

여기서 양자화 모듈 $Q^{(l)}$ 은 학습이 가능한 파라미터로 구성되어 있으며, $B^{(1)} \sim B^{(L)}$ 비트를 사용하여, 총 L 가지 양자화율을 가지는 벡터 양자화 함수이다. M 차원을 가지는 잠재벡터 \mathbf{z} 는 D 차원을 가지는 N 개의 하위 벡터들 \mathbf{z}_i ($i = 1, \dots, N$)로 나누어지고, 이 \mathbf{z}_i 들이 독립적으로 $Q^{(l)}$ 의 입력 값이 된다. 또한, 해당 모듈은 $\mathcal{B}^{(1)} \supset \mathcal{B}^{(2)} \supset \dots \supset \mathcal{B}^{(L)}$, 및 $|\mathcal{B}^{(l)}| = 2^{B^{(l)}}$ 를 만족시키는 총 L 개의 벡터 코드북 $\mathcal{B}^{(l)}$ 를 사용하는데, 이를 통해 하위 벡터 \mathbf{z}_i 를 코드북 내에 가장 가까운 코드 벡터로 양자화한다. 따라서 l 번째 벡터 코드북으로 양자화 할 경우, 식 $\mathbf{z}_{q,i}^{(l)} = Q^{(l)}(\mathbf{z}_i) = \arg\min_{\mathbf{b}_k \in \mathcal{B}^{(l)}} \|\mathbf{z}_i - \mathbf{b}_k\|^2$ 가 성립한다. 결국 $\mathbf{z}_{q,i}^{(l)}$ 를 연결시킨 것이 $\mathbf{z}_q^{(l)}$ 로써, 양자화 모듈의 출력 값이 된다.

Channel impairment로 인한 오류를 모델이 정정할 수 있도록 하고, 위와 같이 포함관계에 있는 다중 벡터 코드북을 효율적으로 학습시키기 위해, 본 논문은 모델의 학습 단계에서 channel impairment \mathcal{H} 를 대체하는 alignment module \mathcal{A} 를 상정하고, $\tilde{\mathbf{z}}_q^{(l)} = \mathcal{A}(\mathbf{z}_q^{(l)})$ 와 같은 관계를 모델 학습 단계에서 이용한다. 첫 번째로, \mathcal{A} 는 양자화된 모든 비트 별로 교차 확률 ϵ 을 가지는 이진 대칭 채널(Binary Symmetric Channel; BSC)을 적용시킨다. 이를 통해 비트 별 오류에 강인하도록 모델을 학습시킬 수 있다. 이 이후에 두 번째로, \mathcal{A} 는 각 양자화된 하위 벡터 $\mathbf{z}_{q,i}^{(l)}$ 의 index 중 $B^{(1)} + 1 \sim B^{(L)}$ 번째에 해당하는 비트를 각각 δ 의 확률로 0에 대응시킨다. 이를 통해 양자화 출력 값에 대응되는 코드 벡터는 대부분 낮은 index 값에 몰리는 현상을 자아낼 수 있다. 이는 곧 코드 벡터들의 출력 빈도수를 보았을 때, 낮은 index를 가지는 코드 벡터일수록 더 중요한 양자화 파라미터가 되도록 강제할 수 있다는 것이다. 따라서 코드북 $\mathcal{B}^{(l)}$ 는, 전체 코드북 $\mathcal{B}^{(1)}$ 중, 첫 $2^{B^{(l)}}$ 개의 코드 벡터만으로 구성한다.

제안된 모델은 총 L 번째 단계를 거쳐 학습이 진행된다. 그 중 l 번째 단계에서, 전체 모델을 학습시키기 위한 손실함수는 다음과 같다.

$$\mathcal{L}^{(l)} = \frac{1}{\sum_{k=1}^l \gamma^k} \sum_{i=1}^l \gamma^i (\|\hat{\mathbf{x}}^{(i)} - \mathbf{x}\|^2 + \|sg(\mathbf{z}) - \tilde{\mathbf{z}}_q^{(i)}\|^2 + \beta \|\mathbf{z} - sg(\tilde{\mathbf{z}}_q^{(i)})\|^2). \quad (1)$$

(1)에서 $sg(\cdot)$ 는 ‘stop-gradient’ 연산을 의미하며, 역전과 과정에서 계산되는 gradient 를 무시하고 해당 입력 값을 변수가 아닌 상수 취급을 하도록 한다. 또한 γ 는 hyperparameter 로서, 각 하위 벡터 코드북에 의한 손실의 비율을 조절하는 역할을 한다. L 가지 전송률을 지원하기 위해 모델은 손실함수 $\mathcal{L}^{(1)}$ 부터 $\mathcal{L}^{(L)}$ 을 통해 순차적으로 학습된다. 손실함수 $\mathcal{L}^{(l)}$ 를 통해 모델과 벡터 코드북 $\mathcal{B}^{(1)} \sim \mathcal{B}^{(l)}$ 에 대해 학습이 완료되면, $\mathcal{B}^{(1)}$ 에서 첫 $2^{\mathcal{B}^{(l+1)}}$ 개의 코드 벡터를 선정하여 $\mathcal{B}^{(l+1)}$ 을 구성한다.

본 논문에서 제안된 기법의 우수성을 보이기 위해 모의 실험을 진행하였다. 실험에서는 CIFAR10 이미지 데이터 셋을 사용하였다. 또한, 앞에서 언급한 변수들은 $D = 16$, $L = 5$, $(\mathcal{B}^{(1)}, \dots, \mathcal{B}^{(5)}) = (6, \dots, 2)$, $\gamma = 0.8$, $\epsilon = 0.05$, $M = 2048$ 와 같이 설정되었다. Encoder, decoder 모델은 [1]의 모델을 차용하였다. 모델의 시험 단계에서, channel impairment \mathcal{H} 는 0.05 의 교차확률을 가지는 BSC 모델을 사용하였다.

그림 1 은 변수 δ 를 조절하면서 제안된 다중 전송률 모델과 단일 전송률 모델 ($L = 1$) 의 $PSNR = 10 \log(\frac{255^2}{\mathbb{E}[\|\hat{\mathbf{x}}^{(l)} - \mathbf{x}\|^2]})$ 성능을 비교한 것이다. 결과에서 확인할 수 있듯이, 제안된 기법 ($\delta = 0.05$) 은 단일 전송률을 지원하는 개별 모델들의 성능보다 더 나은 성능을 보인다. 이는 다양한 크기의 벡터 코드북이 내재적인 포함관계에 있고, 제안된 기법이 해당 관계를 활용하여 모델의 학습에 순영향을 끼친 것으로 해석된다. 따라서 제안된 기법은 여러가지 채널 환경에 대해 채널 적응력을 높일 뿐만 아니라, 고정된 채널 환경에 대해 성능 개선을 위한 좋은 솔루션이 된다는 것을 확인할 수 있다.

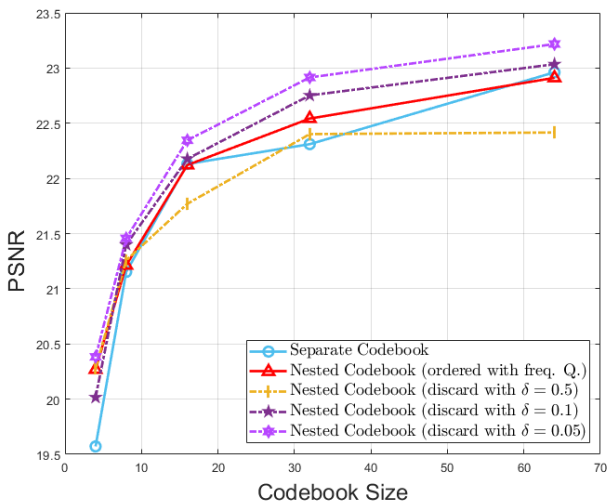


그림 1. 제안된 다중 전송률 모델과 단일 전송률 모델의 성능 비교

III. 결론

본 논문에서는 채널 적응형 디지털 시맨틱 통신을 위한 다중 전송률 JSCC 기법을 제안했다. 해당 기법은 벡터 양자화 코드북에 다양한 크기의 하위 코드북을 포함시킴으로써, 채널 적응력을 위한 다중 전송률 모델을

구성하였다. 또한, 별도의 alignment 모듈을 제안함으로써, 모델에 오류 정정능력을 부여하고, 포함관계에 있는 여러 벡터 코드북을 전체 모델과 더불어 효율적으로 학습시켰다. 결국 제시된 기법이 단일 전송률을 지원하는 각각의 모델보다도 더 나은 성능을 보임을 모의 실험에서 확인하였다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2022R1C1C1010074).

참고 문헌

- [1] A. van den Oord, O. Vinyals, and K. Kayukcuoglu, “Neural discrete representation learning,” Adv. Neural Inf. Process. Syst., pp. 6306–6315, 2017.