

## 과업지향형 통신 시스템을 위한 적응적 압축 기법

선준호, 이승우, 김수현, 선영규, 서효운\*, 김동인\*, 김진영

광운대학교, \*성균관대학교

dimlight13@kw.ac.kr, swool1467@kw.ac.kr, kimsoogus@kw.ac.kr, yakrkr@kw.ac.kr,

\*hywoonseo@skku.edu, \*dikim@skku.edu, jinyoung@kw.ac.kr

## Adaptive Compression Technique for Task-Oriented Communication Systems

Joonho Seon, Seongwoo Lee, Soo Hyun Kim, Young Ghyu Sun,

Hywoon Seo\*, Dong In Kim\*, Jin Young Kim

Kwangwoon Univ., \*Sungkyunkwan Univ.

## 요약

기존 과업지향형 통신 시스템은 동적 압축을 고려하지 못하는 한계가 있다. 본 연구에서는 심층 강화학습 기반 동적 특징 압축 방식을 제안하여, 상황에 따라 벡터 길이를 조정하거나 영상 세그먼트를 선택적으로 전송하는 전략을 적용함으로써 성능 정확도를 최적화한다. 시뮬레이션 결과, 제안한 시스템은 기존 최신 기술 대비 계산 복잡도를 최대 40% 줄이면서도 성능을 유지시키는 효과를 보였다.

## I. 서론

6G에서는 초고속, 초저지연, 초연결을 달성하기 위해 전통적인 비트 단위 전송 방식의 한계를 극복할 필요가 있다. 이를 해결하기 위해, 전송 효율을 비약적으로 향상시킬 수 있는 시맨틱 통신<sup>[1]</sup>이 제안되었다. 시맨틱 통신은 원시 데이터 대신 추출된 의미적 특징만을 전송하여 자원이 제한된 환경에서 전송 효율성을 향상시킬 수 있었다. 그러나 기존 적응형 특징 압축 방식<sup>[2]</sup>은 정적 압축에 의존하여 전문가 개입을 요구되기에, 전송 효율을 높이기 위해 적응적으로 자율적으로 압축하는 특징 압축 기술이 요구된다.

본 논문에서는 송신단에서 강화학습 기반으로 특징 선택을 최적화하는 적응형 압축 방법을 제안한다. 기존 시맨틱 통신 방식과 달리, 제안된 방법은 환경과의 상호작용을 통해 최적 전략을 학습하고, 통신 환경의 불확실성에 대응하여 작업 지향적 성능과 복원력을 동시에 확보한다. 성능 평가는 데이터 재구성 작업을 기반으로 수행되었으며, 심층 강화학습(Deep Reinforcement Learning, DRL) 에이전트가 특성 공간에서 압축을 수행하면서 작업 속도를 최적화하는 접근을 적용하였다.

## II. DRL 기반 적응형 특징 압축 기법

제안하는 심층 강화학습 시맨틱 통신(Deep Reinforcement Learning Semantic Communications, DRL-SC) 시스템에서 A2C(Advantage Actor-Critic) 알고리즘<sup>[3]</sup>을 사용하며, 해당 알고리즘의 목적 함수는 다음과 같이 표현된다:

$$\nabla_{\theta} J(\theta) = \mathbb{E}[\nabla_{\theta} \log \pi_{\theta}(a|s) \text{Adv}(s,a)], \quad (1)$$

여기서  $\text{Adv}(s,a) = R_t - V(s_t)$ 이다.  $\pi_{\theta}$ 는 파라미터  $\theta$ 를 가진 정책이며,  $s_t$ 는 시간  $t$ 에서의 상태,  $V(s_t)$ 는 시간  $t$ 에서 상태의 가치 함수,  $\text{Adv}(s,a)$ 는 실제 리턴과 크리티크에 예측한 가치 함수  $V$ 의 차이로 계산되는 advantage 함수이다.  $\theta$ 는 정책 네트워크의 파라미터이고,  $R_t$ 는 시간  $t$ 에서의 리턴이다.

송신단은 압축률(Compression Ratio, CR)을 사용하여 적응적으로 압축률을 조절할 수 있도록 설계되었다. 제안된 송신단의 프레임워크는 SNR과 CR 정보를 활용하여 압축된 특징으로부터 복원할 수 있도록 훈련된다.

압축된 벡터는 다음과 같이 표현된다:

$$f'_m = \bigcup_{k=1}^n M_{m,k} \cdot x_{m,k}, \quad (2)$$

여기서  $M_{m,k}$ 는 마스크 벡터로, 선택된 압축률에 따라 특징을 포함하거나 제외한다.

송신기의 보상 함수는 압축률과 작업 성능의 균형을 맞추도록 설계되었다. 복원 작업에서는 의미적 유사성을 기반으로 한 메트릭(Structural Similarity Index Measure, SSIM)을 도입하여 압축률을 설정한다. 효율성 보상 함수는 채널 조건에 대한 에이전트의 적응력을 높이도록 통합되며, 최종 보상  $R_{tx,rec}$ 은 의미적 유사도와 효율성의 균형을 맞춘다.

$$R_{tx,rec} = \frac{1}{2} \left( \frac{1}{m} \sum_{i=1}^m SSIM(p_{ori}, p_{rec}) + f_{eff}(\bar{\pi}, \sigma_{\pi}^2) \right), \quad (4)$$

$$f_{eff}(\bar{\pi}, \sigma_{\pi}^2) = \zeta(\beta(\delta - |\bar{\pi} - \pi_0|)) \cdot \zeta(\beta(\delta - \sqrt{\sigma_{\pi}^2})), \quad (5)$$

여기서  $\bar{\pi}$ 는 정책의 평균,  $\pi_0$ 은 목표 정책의 평균,  $\beta$ 와  $\delta$ 는 제어 파라미터,  $\zeta$ 는 시그모이드 함수이다.  $R_{tx,rec}$ 의 범위는 0에서 1까지이다.

## III. 시뮬레이션 결과

기존의 시맨틱 통신 및 세그먼트 선택 알고리즘<sup>[2]</sup> 평가에 널리 사용되어 왔으므로 제안된 모델의 성능을 평가하기 위해 CIFAR10 데이터셋을 선택했다. DRL-SC는 재구성 작업을 목표로 설계되어, PSNR을 통한 재구성 품질과 통신 비용, 초당 부동소수점 연산(Floating Point Operations Per second, FLOPs), 추론 시간 기반의 계산 복잡성 측면에서 성능을 평가했다. 시뮬레이션은 AWGN, Rayleigh, Rician 채널 환경




그림 1. 다양한 채널 조건(AWGN, Rayleigh, Rician)에 대한 PSNR 성능 비교.

에서 수행되었으며, ‘error free’는 채널 영향이 없는 경우를 의미한다. 그림 1은 다양한 SNR 환경에서 DRL-SC와 기존 방법<sup>[1], [4]</sup>을 비교한 결과를 보여주며, 표 1은 전송 벡터 수를 기준으로 통신 비용을 비교한다.

AWGN 채널 환경에서 S1 모델은 SNR 증가에 따라 정확도가 점진적으로 상승해 약 -6dB에서 오류 없는 성능을 기록했다. PSNR 기준으로는, 최적의 CR를 계산하는 Oracle 네트워크 기반 non-DRL 방법과 비교했을 때 S1이 더욱 안정적으로 작동하는 것으로 나타났다. 이는 재구성 문제에서 세그멘테이션 접근이 단순 압축 대비 효과적일 수 있음을 시사한다. 통신 비용은 DeepJSCC 대비 약간 증가했지만, 제안된 DRL-SC는 ADeepJSCC보다 높은 노이즈 견고성과 통신 효율성을 달성해 실질적인 이점을 제공했다.

#### IV. 결론

본 논문에서는 이전 연구에서 적응형 특징 압축 문제를 해결하기 위해 새로운 DRL-SC 프레임워크가 제안되었다. 제안된 전략은 계산 복잡도를 동적으로 조절하는 강화학습 에이전트를 송신기에 구현하여 작업 관련 특징의 압축 수준을 결정함으로써 기존 방법 대비 복잡도를 증가시키지 않고도 성능을 개선할 수 있었다. 시뮬레이션 결과에 따르면 제안된 전략은 분류 및 재구성 작업에 적합한 접근 방식이 될 수 있다.

#### ACKNOWLEDGMENT

This work was supported by the MSIT, Korea, under the ITRC(Information Technology Research Center) support program(IITP-2025-RS-2023-00258639) supervised by the IITP.

#### 참 고 문 헌

- [1] E. Boursoulatz, D. B. Kurka, and D. Gundüz, “Deep joint source-channel coding for wireless image transmission,” IEEE Trans. Cogn. Commun. Netw., vol. 5, no. 3, pp. 567–579, Sept. 2019.
- [2] W. Zhang, H. Zhang, H. Ma, H. Shao, N. Wang, and V. C. M. Leung, “Predictive and adaptive deep coding for wireless image transmission in semantic communication,” IEEE Trans. Wirel. Commun., vol. 22, no. 8, pp. 5486–5501, Aug. 2023.
- [3] V. Mnih, A. P. Badia, M. Mirza, A. Graves, T. Lillicrap, T. Harley, D. Silver, and K. Kavukcuoglu, “Asynchronous methods for deep reinforcement learning,” in Proc. of the 33rd Int. Conf. on

표 1. FLOPs, 통신 비용, 지연 시간 측면에서 계산 복잡성 비교.

방법론	FLOPs	통신 비용	추론 시간
S1 (rec)	$8.889 \times 10^9$	704-832	176ms
S2 (rec)	$8.234 \times 10^9$	768	163ms
DeepJSCC (rec)	$2.183 \times 10^7$	512	54ms
ADeepJSCC (rec)	$9.864 \times 10^9$	1536	153ms
non-DRL (rec)	$8.847 \times 10^9$	1536	131ms

Machine Learning (ICML), New York, USA, 2016, pp. 1928–1937.

- [4] J. Xu, B. Ai, W. Chen, A. Yang, P. Sun, and M. Rodrigues, “Wireless image transmission using deep source channel coding with attention modules,” IEEE Trans. Circuits Syst. Video Technol., vol. 32, no. 4, pp. 2315–2328, Apr. 2022.