

# LoRA 기반 Fine-Tuning 을 통한 Fading 채널에서의 신속한 Semantics Alignment 알고리즘 연구

구준회, 김상혁, 고승우  
인하대학교

jeremy0915@inha.edu, inhaase20@inha.edu, swko@inha.ac.kr

## Agile Semantics Alignment over Fading Channel via LoRA based Fine-Tuning

Joon-Hoe Koo, Sang-Hyeok Kim, Seung-Woo Ko  
Inha University

### 요약

본 논문에서는 무선 채널 품질 악화에 따른 송수신기 간의 입력 Feature 벡터 차원 불일치로 인한 Semantics Misalignment 를 빠르게 해결하기 위한 통신 및 학습 기법을 제안한다. 채널 변화에 따른 입력 데이터의 Feature 차원 및 학습 데이터 숫자를 제어하고, Low-Rank Adaptation (LoRA)를 사용한 Fine-Tuning 기법을 통해 Task 를 신속히 해결한다. V2X 송수신기를 통한 실제 실험 결과, 제안 기법은 End-to-End Training 모델에 비해 비약적인 통신 및 시간 절감을 가능하게 하면서도 97.6%의 높은 분류 정확도를 보인다.

### I. 서론

지능형 단말과 고밀도 사물이 연결되는 6G 시대에는 비트 단위의 전송보다는 의미 (Semantics) 기반 정보 전달의 효율이 통신의 품질을 결정한다 [1]. 그러나 무선 채널 품질은 수시로 변화하여 전송 가능한 Feature 벡터의 차원 수가 달라지고, 이로 인해 송신기 (TX)에서 보내는 차원과 수신기 (RX)의 Pre-Trained 모델 간의 Semantics Misalignment 가 발생하며 Task 성공률을 급격히 저하시킨다 [2]. 이러한 문제를 저지연으로 해결하기 위해, 본 논문에서는 기존 Pre-Trained 모델을 유지하면서도, 송신기에서의 Feature 벡터의 차원 제어 및 Fine-Tuning 을 통해 Semantics Misalignment 를 빠르게 해결한다.

### II. 시스템 모델

본 논문에서는 Split 구조의 Semantic Communication 을 고려한다. 이 때, TX 와 RX 하나의 쌍을 고려하는데, TX 측 인코더는 입력 이미지를 Principle Component Analysis (PCA)를 통해 N 차원 Feature 벡터로 압축하며, 채널 상태에 따라 보낼 수 있는 차원의 수를 제어할 수 있다. RX 측 디코더는 End-to-End Training 된 MLP 기반 모델을 보유하고, 수신한 PCA 벡터를 복원하여 분류하는데 사용한다. 채널 환경의 변화로 전송 차원이 달라지면 원본 데이터가 그림 1 과 같이 바뀌게 된다. 바뀐 이미지를 분류하기 위해선 새로운 모델의 재학습이 필요한데, 이 때 End-to-End Training 은 많은 데이터와 시간을 필요로 하고 무선 채널 환경의 Variation 에 효율적으로 대응이 불가능하다.




그림 1. MNIST 데이터의 차원 별 PCA 결과

### III. Low-Rank Adaptation (LoRA) 기반 Fine-Tuning

III. A 를 통해 Dimension 변화에 따른 통신 Payload 구

성을 설명하고, III. B 를 통해 LoRA 알고리즘에 대해 구체적으로 설명한다. III. C 에서 TX, RX 송수신의 프레임워크에 대해 논의한다.

#### A. Dimension 변화에 따른 통신 Payload 구성

채널 상태 변화로 인해 TX 에서 전송할 테스트 데이터셋의 차원이 감소하고, 차원이 감소함에 따라 통신 Payload 에 여분의 용량이 생긴다. 여분의 용량에 Fine-Tuning 용 학습 데이터셋을 함께 전송하는데, 이 때 최대 전송용량을  $B_{max}$  로 정의할 때, 전송 가능한 학습 데이터셋의 최대 개수는 다음과 같다:

$$N_{max} = \left\lfloor \frac{B_{max} - H - t(h + \sigma\alpha)}{h + \sigma\alpha} \right\rfloor.$$

위 식에서  $H$  는 테스트 및 학습 데이터셋의 파일 전체의 헤더(8byte)이고,  $h$  는 벡터 한개의 헤더(4byte)이다.  $t$  는 테스트 데이터의 수,  $\alpha$  는 PCA 를 진행할 차원의 수이며,  $\sigma$  는  $\alpha$  당 바이트 수(float 한개당 4byte)를 뜻한다. 이 식을 통해 TX 는 PCA 차원마다 보낼 수 있는 학습 데이터셋의 수를 계산하여 테스트 데이터셋과 함께 RX 로 송신한다.




그림 2. 시스템 프레임워크 (RX 에서 1 번 진행 후 2 번을 진행한다.)

#### B. Low-Rank Adaptation

LoRA[3]는 Pretrained Model 의 원본 가중치 행렬  $W$  에 직접 손대지 않고, Low Rank 행렬  $A, B$  를 추가로 학습하는 Fine-Tuning 기법이다.  $W$  대신  $\Delta W = AB$  를 학습함으로써 학습 데이터셋과 Epoch 를 줄이면서도 모델의 성능을 유지한다. 랭크  $r$  을 조절하여  $\Delta W$  의 용량과 학습 복잡도를 제어하고, Pre-Trained 모델의 지식은 고정된 채로 새로운 차원의 특징에 빠르게 적응한다.

### C. 데이터 송수신 프레임워크

그림 2는 본 시스템의 프레임워크를 나타낸다. 먼저 TX에서 분류할 테스트 데이터셋을 차원  $\alpha$ 로 PCA하여 Feature 벡터를 추출한 후에, Payload 구성에 따라 학습 데이터셋의 최대 개수  $N_{max}$ 를 계산하여 그 수 만큼 동일 차원으로 PCA를 진행한다. 그 후 각 데이터셋의 Feature 벡터들을 RX로 전송을 하면, RX에선 테스트와 학습 데이터셋의 Feature 벡터들을 Inverse PCA하여 이미지를 복원한다. 복원한 학습 데이터셋을 이용하여 Pre-Trained 모델을 LoRA Fine-Tuning으로 학습하고, 복원한 테스트 데이터셋을 학습시킨 모델에 입력하여 Classification을 진행한다.

### IV. Experiments

TX, RX 역할을 하는 두 대의 SIRIUS [4] 기기와 각각 연결된 두대의 노트북을 약 2m 간격으로 배치한다. 기존 256QAM에서 64QAM의 변조방식으로 설정하여 채널 상태가 악화된 상황을 가정하였다. RX가 보유한 Pre-Trained 모델의 차원인 200 차원의 3/4인 150 차원을 시작으로 10 차원 단위로 실험을 진행하였다. RX는 수신한 학습 데이터셋을 이용하여 Pre-Trained 모델을 내장 CPU를 통해 Fine-Tuning하여 학습시킨 후, 수신된 테스트 데이터셋을 Fine-Tuned 모델에 입력하여 실험의 Task인 MNIST 데이터셋의 분류 성능을 검증한다.

Latency 측정의 경우, TX, RX 역할을 하는 각 SIRIUS 기기가 GPS 수신기로부터 Pulse Per Second (PPS) 신호로 동기화된 시간을 출력한다. TX에서 PCA를 시작하는 순간의 시각을  $A$ , RX에서 데이터를 수신한 뒤에 Image Reconstruction이 완료된 순간의 시각을  $B$ , Fine-Tuning으로 Pre-Trained 모델을 학습하는데 걸리는 시간을  $C$ , 분류에 걸리는 시간을  $D$ 라고 한다면, 전체 Latency를 나타내는 식은 다음과 같이 정의할 수 있다.

$$\text{End-to-End Latency} = (B - A) + C + D.$$

위 식에서 Computing Latency에 해당하는  $C$ 와  $D$ 를 제외한  $(B - A)$ 를 PCA에 걸리는 시간이 짧다는 점을 고려하여 Communication Latency로 간주할 수 있다.

그림 3은 각 차원에서의 세가지 Latency들을 출력한 결과이다. 낮은 차원으로 PCA를 진행할수록 테스트 데이터셋의 용량이 적어져 더 많은 학습 데이터셋을 RX로 전송할 수 있는데, 그만큼 Fine-Tuning을 진행할 때의 데이터 양이 많아져 더 오랜 시간이 걸리기 때문에  $\alpha$ 가 높아질수록 Fine-Tuning에 걸리는 시간이 줄어드는 경향성을 보인다. 그림 4는 각 차원을 사용했을 때 End-to-End Training 모델과 LoRA Fine-Tuning된 Pre-Trained 모델의 분류 정확도를 비교한다.  $\alpha = 40$ 일 때를 제외한 모든 차원에서 LoRA Fine-Tuning을 한 모델이 더 우수한 성능을 보이는 것을 확인하였다.

### V. 결론

본 논문에서 무선 채널의 품질이 악화되어 전송 가능한 Feature 벡터의 수가 줄었을 때 TX와 RX 간에 발생한 Semantics Misalignment를 신속히 해결할 수 있는 통신 및 학습 기법을 제안한다. 기존의 Backbone Model을 LoRA Fine-Tuning을 통해 기존 End-to-End Training 모델의 성능을 유지하였다. 추후에는 제안하는 알고리즘을 다양한 데이터셋과 채널 환경에서 검증하고 최적의 차원 제어 기법에 대해 연구할 예정이다.




그림 3. Latency-Dimension 그래프




그림 4. Accuracy-Dimension 그래프

### ACKNOWLEDGMENT

이 논문은 2025년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. RS-2024-00453301).

### 참고 문헌

- [1] Qin, Z., Tao, X., Lu, J., Tong, W., & Li, G. Y. (2021). Semantic communications: Principles and challenges. arXiv preprint arXiv:2201.01389.
- [2] J. Choi, J. Park, S. -W. Ko, J. Choi, M. Bennis and S. -L. Kim, "Semantics Alignment via Split Learning for Resilient Multi-User Semantic Communication," in IEEE Transactions on Vehicular Technology, vol. 73, no. 10, pp. 15815-15819, Oct. 2024, doi: 10.1109/TVT.2024.3410380.
- [3] A. Tiwary et al., "Fine-Tuning Vision Transformer Using LoRA for Image Classification," in Proc. 8th Int. Conf. Electron. Mater. Eng. Nano-Tech (IEMENTech), 2025, pp. 1-4, doi:10.1109/IEMENTech65115.2025.10959407.
- [4] Ettifos, "SIRIUS SDR Platform," Ettifos, 2025. [Online]. Available: <https://www.ettifos.com/product-sirius>. [Accessed: May 16, 2025].