

# 다중입출력 다중 접속 채널 기반 연합 학습을 위한 압축 센싱 기술

박지훈, 이상욱, 윤재원, 전요셉  
포항공과대학교

{jihun4048, yisangkor, messi10, yoseb.jeon}@postech.ac.kr

## Compressed Sensing Techniques for Federated Learning over MIMO Multiple Access Channels

Jihoon Park, Sangwook Lee, Jaewon Yun, Yo-Seb Jeon  
Pohang Univ. of Science and Technology (POSTECH)

### 요 약

본 논문은 다중입출력 다중 접속 채널에서 통신 효율적인 연합 학습을 위한 압축 센싱 기반 송/수신 기법을 제안한다. 제안된 송신 기법에서 각 무선 기기는 모델 학습 결과로 얻어진 기울기 벡터를 압축하여 서버에 전달한다. 제안된 수신 기법에서 서버는 무선 기기들로부터 전달받은 압축된 기울기 벡터들에 대해 다중입출력 데이터 검출 및 압축 센싱 알고리즘을 적용하여 원래의 기울기 벡터들을 정확하게 복원한다. 모의실험을 통해, 제안된 송/수신 기법을 이용한 연합 학습이 중앙 학습에 근접한 성능을 달성하는 것을 확인할 수 있다.

### I. 서 론

연합 학습(federated learning)은 서버의 모델 학습을 위해 다수의 무선 기기들의 연합을 활용하는 분산형 기계 학습 기술이다 [1]. 연합 학습에서는 무선 기기들만 학습 데이터를 가지고 있으며, 각 기기는 학습 데이터를 서버에 직접 전송하는 대신 자신의 데이터를 이용해 모델을 학습한 결과만을 전송한다. 이 경우, 서버는 학습 데이터에 대한 직접적인 접속 없이도 무선 기기들로부터 전송받은 학습 결과만을 종합하여 전체 모델을 학습할 수 있으며, 이에 따라 학습에 참여하는 기기들의 프라이버시를 보호할 수 있게 된다. 그러나 서버의 모델 크기가 매우 큰 경우, 무선 기기가 학습 결과를 전송하는 과정에서 많은 통신 부하가 발생하게 되며, 이 문제를 해결하는 것은 연합 학습을 실현하는 데 있어 매우 시급한 과제라고 할 수 있다 [2].

본 논문은 다중입출력(multiple-input multiple-output, MIMO) 다중 접속 기반 연합 학습에서 압축 센싱을 활용하여 통신 부하를 획기적으로 줄일 수 있는 송/수신 기법을 제안한다. 먼저, 제안된 송신 기술에서 각 무선 기기는 학습 결과로 얻어진 기울기 벡터를 압축 센싱(compressed sensing)을 통해 압축된 형태로 전송하여 통신 부하를 크게 감소시킬 수 있다. 또한, 다중 접속 채널을 활용하여 모든 기기들이 압축된 기울기 벡터들을 동시에 전송하게 되며, 이를 통해 각 무선 기기의 개별 전송 대비 통신 부하를 획기적으로 감소시킬 수 있다. 제안된 수신 기술에서 서버는 압축 센싱과 다중입출력 데이터 검출을 결합한 수신 알고리즘을 활용하여 압축된 기울기 벡터들로부터 원래의 기울기 벡터들을 정확하게 복구할 수 있다. 모의 실험을 통해, 제안된 송/수신 기법을 활용한 연합 학습은 통신 부하를 획기적으로 줄일 수 있을 뿐만 아니라 중앙

학습에 매우 근접한 정확도를 달성할 수 있음을 확인할 수 있다.

### II. 본론

본 논문에서는  $U$ 개의 안테나를 가진 서버와  $K$ 개의 무선 기기가 존재하는 다중입출력 다중 접속 채널 기반 연합 학습을 고려한다. 이때 하향 링크와 상향 링크가 순차적으로 반복되는 시분할 이중통신을 가정한다. 하향 링크에서 서버는 모든 무선 기기에게 현재 학습 모델을 전송한다. 상향 링크에서 각 무선 기기는 자신의 학습 데이터를 바탕으로 현재 모델의 기울기 벡터를 계산하여 서버에 전송하며, 서버는 전송받은 기울기 벡터들을 종합하여 현재 학습 모델을 새롭게 갱신한다. 연합 학습에서 서버의 모델 크기가 매우 큰 경우, 상향 링크에서 기울기 벡터를 송신하는 과정에서 과도한 통신 부하가 발생하게 된다. 이 문제를 해결하기 위해, 본 논문은 압축 센싱을 활용하여 기울기 벡터 전송의 통신 부하를 줄일 수 있는 상향 링크 송/수신 기법을 제안한다.

본 논문에서 제안하는 상향 링크 송신 기법은 다음과 같다. 먼저, 각 기기에서 계산된 기울기 벡터는 희소성을 보장하기 위해  $S$ 개의 큰 요소 값 외에 값을 0으로 만드는 희소화 작업을 거친다. 희소화 작업을 통해 얻어진 기울기 벡터는 0이 아닌 값을  $S$ 개만 가지고 있는  $S$ -희소 벡터가 된다. 이때, 기울기 벡터 데이터의 손실을 방지하기 위해 각 기기에서는 송신하지 않는 나머지 값들을 벡터의 형태로 저장한다.  $k$ 번째 기기에서 희소화 작업을 거친 벡터는 다음과 같이 얻어진다.

$$\tilde{\mathbf{g}}_k = \text{Sparse}(\Delta_k + \mathbf{g}_k) \in \mathbb{R}^N$$

위 식에서  $N$ 은 신경망의 모델 파라미터 개수를,  $\mathbf{g}_k \in \mathbb{R}^N$ 는  $k$ 번째 기기에서 계산한 기울기 벡터를,  $\Delta_k \in \mathbb{R}^N$ 는  $k$ 번째 기기에서의 기울기 데이터 저장 벡터를, 그리고

$\text{Sparse}(\cdot)$ 는 위에서 설명한 희소화 함수를 나타낸다. 각 무선 기기에서 희소화 작업을 거친 기울기 벡터는 압축 센싱에서 활용되는 측정 행렬을 통해 압축된다. 이때  $k$ 번째 기기의 압축된 기울기 벡터는 다음과 같이 얻어진다.

$$\mathbf{x}_k = \mathbf{A}\tilde{\mathbf{g}}_k \in \mathbb{R}^M$$

위 식에서  $M$ 은  $M < N$ 인 값으로 압축된 벡터의 차원을,  $\mathbf{A} \in \mathbb{R}^{M \times N}$ 는 각 원소가  $N(0, 1/M)$ 를 따르는 측정 행렬을 나타내고, 기울기 벡터의 압축률은  $R = N/M$ 로 얻어진다. 이때 각 기기의 상향 링크 파워  $P_k = \frac{N}{\|\mathbf{A}\tilde{\mathbf{g}}_k\|^2}$ 에 대하여 송신 신호 행렬은 다음과 같이 표현된다.

$$\bar{\mathbf{X}} = [\sqrt{P_1}\mathbf{x}_1, \dots, \sqrt{P_K}\mathbf{x}_K] = \mathbf{X}(\mathbf{P})^{\frac{1}{2}} \in \mathbb{R}^{M \times K}$$

위 식에서  $\mathbf{P} = \text{diag}(P_1, \dots, P_K)$ 인 파워 할당 행렬을,  $\mathbf{X} \in \mathbb{R}^{M \times K}$ 는  $\mathbf{x}_k$ 를  $k$ 번째 열 벡터로 가지는 압축된 기울기 행렬을 나타낸다. 각 통신 라운드에서 고정된 채널을 가진다고 가정했을 때, 상향 링크에서 서버가 수신하는 신호는 다음과 같이 표현된다.

$$\mathbf{Y} = \mathbf{H}(\bar{\mathbf{X}})^T + \mathbf{Z} = \tilde{\mathbf{H}}(\mathbf{A}\mathbf{G})^T + \mathbf{Z} \in \mathbb{R}^{U \times M}$$

위 식에서  $\mathbf{H} \in \mathbb{R}^{U \times K}$ 는 각 원소가 각 원소가  $N(0, 1)$ 를 따르는 MIMO 채널 행렬을,  $\tilde{\mathbf{H}} = \mathbf{H}(\mathbf{P})^{\frac{1}{2}}$ 인 행렬을,  $\mathbf{G} \in \mathbb{R}^{N \times K}$ 는  $\tilde{\mathbf{g}}_k$ 를  $k$ 번째 열 벡터로 가지는 기울기 행렬을, 그리고  $\mathbf{Z} \in \mathbb{R}^{U \times M}$ 는 각 원소가  $N(0, \sigma^2)$ 을 따르는 잡음 행렬을 나타낸다. 위 식을 통해, 서버에서 무선 기기들이 전송한 기울기 벡터들을 복구하기 위한 문제는  $\mathbf{Y}$ 의 수신 신호 행렬로부터  $S$ -희소 기울기 벡터들로 구성된 희소 행렬  $\mathbf{G}$ 를 찾는 압축 센싱 문제임을 확인할 수 있다. 그러나, 이때 형성된 압축 센싱 문제는 두 행렬  $\mathbf{A}$ 와  $\tilde{\mathbf{H}}$ 가 희소 행렬의 양방향에 각각 곱해진 특수한 형태를 가지므로, 기존의 압축 센싱 알고리즘을 적용하여 풀기 어려운 특이 형태를 가지고 있다.

이러한 특이 형태의 압축 센싱 문제를 해결하기 위해 본 논문에서 제안하는 수신 기법은 MIMO 데이터 검출과 압축 센싱을 순차적으로 수행하는 두-단계 과정으로 이루어진다. 먼저, MIMO 검출 과정에서는 수신 신호 행렬에 선형최소평균제곱오차(linear minimum mean square error, LMMSE) 검출 기법을 적용해  $\bar{\mathbf{X}}$ 를 추정한다.  $m$ 번째 수신 신호 벡터인  $\mathbf{y}_m$ 에 대해 LMMSE 기법을 적용하여 추정된 송신 신호 벡터는 다음과 같다.

$$\hat{\mathbf{x}}_m = \tilde{\mathbf{H}}^T(\tilde{\mathbf{H}}\tilde{\mathbf{H}}^T + \sigma^2\mathbf{I}_U)^{-1}\mathbf{y}_m \in \mathbb{R}^K$$

위 추정 벡터를  $m$ 번째 행 벡터로 가지는 송신 신호 행렬을  $\hat{\mathbf{X}}$ 라고 정의하면, 이 행렬의  $k$ 번째 열 벡터는 아래와 같이 표현할 수 있다.

$$\hat{\mathbf{x}}_k = \mathbf{A}\tilde{\mathbf{g}}_k + \mathbf{n}_k \in \mathbb{R}^M$$

위 식에서  $\mathbf{n}_k \in \mathbb{R}^M$ 는 해당하는 MIMO 추정 오류를 나타낸다. MIMO 검출 과정을 통해 앞서 정의되었던 특이 형태의 압축 센싱 문제를 기존 압축 센싱과 동일한 형태로 나타낼 수 있으며, 희소 행렬  $\mathbf{G}$ 를 찾는 문제에서  $S$ -희소 기울기 벡터  $\mathbf{g}_k$ 를 개별적으로 찾는 문제로 변환할 수 있다. 기울기 벡터를 개별적으로 찾는 과정은 기존 압축 센싱 알고리즘을 활용하여 쉽게 풀 수 있다.

본 논문에서 제안된 송/수신 기법의 성능 평가를 위해 모의실험을 진행하였다. 실험을 위해 MNIST 데이터셋을 이용해 0부터 9까지의 손 글씨를 분류하는 심층 학습 환경을 가정하였다. 심층 신경망은 20개의 은닉층 노드 개

수를 가진 단일 은닉층 신경망으로 구성하였고, 은닉층과 출력층에 각각 ReLU, Softmax 활성화 함수를 적용했다. 신경망 훈련을 위한 손실 함수로는 교차 엔트로피 함수를, 신경망 훈련 알고리즘으로  $\alpha = 0.01$ 로 설정한 ADAM optimizer를 사용하였다. 또한, 계산 복잡도를 줄이기 위해 기울기 벡터를  $B$ 개의 블록으로 나누어 희소화 작업 및 벡터의 압축, 압축해제를 처리하는 블록 연산을 도입하여 모의실험을 진행하였다. 그 외 실험 파라미터로  $U = 64, K = 32, N = 15910, M = 3700, B = 37$ 을 설정하였으며, 희소화 비율은 3%, 신호대잡음비 0 dB, 미니 배치 크기는 1로 설정하였다.




그림 1. 연합 학습 분류 정확도 비교 결과

그림 1은 다양한 압축 센싱 알고리즘을 적용했을 때 얻어진 모의 실험 결과이다. 위 결과는 제안된 송/수신 기법을 사용했을 때 완벽한 통신 환경을 가정한 중앙 학습과 거의 동일한 분류 정확도를 달성할 수 있음을 보여준다. 위 결과는 기울기 벡터의 희소화를 통한 압축 센싱을 활용하면 성능 손실 없이도 연합 학습의 통신 부하를 효과적으로 줄일 수 있음을 입증한다.

### III. 결론

본 논문에서는 다중입출력 다중 접속 채널에서 통신 효율적인 연합 학습을 위한 압축 센싱 기반 송/수신 기법이 제안되었다. 본 연구를 통해, 압축 센싱을 기반으로 기울기 벡터를 압축하여 송신하고 이를 MIMO 데이터 검출과 압축 센싱 알고리즘을 통해 복구하면 연합학습의 통신 부하를 효과적으로 줄일 수 있음을 입증하였다.

### ACKNOWLEDGMENT

이 성과는 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2020R1G1A1099962).

### 참고 문헌

- [1] J. Konecny, H. B. McMahan, F. X. Yu, P. Richtarik, A. T. Suresh, and D. Bacon, "Federated learning: Strategies for improving communication efficiency," arXiv:1610.05492v2 [cs.LG], Oct. 2017.
- [2] M. M. Amiri and D. Gunduz, "Machine learning at the wireless edge: Distributed stochastic gradient descent over-the-air," IEEE Trans. Signal Process., vol. 68, pp. 2155–2169, Mar. 2020.