

무선연산 연합학습을 위한 디바이스 선택 및 IRS 반사 계수 설계

김민식, 장갑석, 고영조, 박대영*
한국전자통신연구원, *인하대학교

msk@etri.re.kr, kschang@etri.re.kr, koyj@etri.re.kr, *dpark@inha.ac.kr

Device Selection and IRS Reflection Coefficient Design for Over-the-Air Federated Learning

Minsik Kim, Kapseok Chang, Young-Jo Ko, Daeyoung Park*
Electronics and Telecommunications Research Institute, *Inha University

요약

무선연산 연합학습(AirComp FL)에서 많은 로컬 디바이스가 학습에 참여할수록 학습 성능이 향상된다는 것은 잘 알려져 있지만 채널 상태가 좋지 않은 디바이스가 연합학습에 참여할 경우 학습 성능이 저하될 수 있다. 본 논문에서는 제한된 에러 내에서 최대한 많은 디바이스를 선택할 수 있도록 빔포밍 벡터와 IRS 반사 계수를 최적화하는 알고리즘을 제안한다.

I. 서론

연합학습(federated learning, FL)[1]은 여러 로컬 디바이스에 대한 협력 모델 훈련을 가능하게 하는 새로운 분산 학습 방법으로 부상하고 있다. 연합학습의 성능을 높이기 위해서는 많은 디바이스가 학습에 참여해야 하지만 기존의 통신 시스템에서는 학습에 참여하는 디바이스의 수에 비례하여 필요한 무선 자원의 양이 늘어나는 문제가 있다. 이를 해결하기 위해 다중 접속 채널에서 중첩의 원리를 활용한 무선연산(over-the-air computation, Aircomp)이 연합학습에 많이 응용되고 있다[2]. 또한 지능형 반사 표면(intelligent reflecting surface, IRS)은 페이딩 채널의 해로운 영향을 해결할 수 있으며 반사 계수를 최적화하여 정보 전달율을 높이고 송신기의 전력을 최소화하는 등 무선 통신의 효율을 증가시킬 수 있다.

무선연산 연합학습에서 많은 디바이스가 참여할수록 인공지능 모델의 성능이 좋아진다고 알려져 있다. 하지만 많은 수의 디바이스가 학습에 참여하기 위해서는 무선연산에서 발생하는 에러를 더 많이 허용해야 되며 이로 인해 인공지능 모델의 성능이 약화될 수 있다[3]. 따라서 제한된 에러 내에서 더 많은 디바이스를 선택하도록 빔포밍 벡터와 반사 계수를 동시에 최적화함으로써 인공지능 모델의 성능을 향상시킬 수 있다[4].

II. 본론

연합 학습에서 federated averaging(FedAvg)[1]은 기지국이 학습에 참여할 디바이스를 선택한 후에 각 디바이스로부터 업데이트된 로컬 모델을 수집한다. 그리고 수집된 로컬 모델 \mathbf{v}_k 의 가중 평균으로 기지국의 글로벌 모델 \mathbf{w} 를 업데이트한다. 각각의 로컬 디바이스에서 업데이트된 로컬 모델은

$$\mathbf{v}_k = \mathbf{w} - \mu \nabla F_k(\mathbf{w}, \mathcal{B}_k) \quad (1)$$

이다. 여기에서 μ 는 로컬 디바이스에서의 학습률, $F_k(\mathbf{w}, \mathcal{B}_k)$ 는 모델 파라미터 \mathbf{w} 와 미니 배치 \mathcal{B}_k 가 주어졌을 때의 손실 함수이다. 기지국에서는 선택된 디바이스들

의 로컬 모델의 평균으로 다음과 같은 글로벌 모델을 얻을 수 있다.

$$\mathbf{w} = \frac{1}{|\mathcal{S}|} \sum_{k \in \mathcal{S}} \mathbf{v}_k \quad (2)$$

여기에서 $|\mathcal{S}|$ 는 집합 \mathcal{S} 의 원소의 개수(cardinality)로 학습에 참여하기로 선택된 디바이스의 수이다.

무선연산에서 각각의 디바이스들은 간섭 제거를 위한 추가 전력 b_k 을 가지고 신호를 송신하며, 기지국에서는 빔포밍 벡터를 설계하여 수신 신호들이 집계된 정보를 얻는다. 학습에 참여하는 k 번째 디바이스가 로컬 모델 $\mathbf{v}_k \in \mathbb{R}^d$ 를 위한 s_k 를 송신할 때, 수신된 신호는

$$\mathbf{r} = \sum_{k \in \mathcal{S}} \tilde{\mathbf{h}}_k b_k s_k + \mathbf{n} \quad (3)$$

이다. 여기에서 $\tilde{\mathbf{h}}_k = \mathbf{h}_k + \mathbf{R}\Phi\mathbf{t}_k$ 는 IRS가 포함된 유효 채널, $\mathbf{h}_k \in \mathbb{C}^M$ 는 기지국과 k 번째 디바이스 사이의 채널, $\mathbf{R} \in \mathbb{C}^{N \times M}$ 은 기지국과 IRS 사이의 채널, $\mathbf{t}_k \in \mathbb{C}^M$ 는 k 번째 디바이스와 IRS 사이의 채널, $\Phi = \text{diag}\{\alpha_1, \alpha_2, \dots, \alpha_M\}$ 는 IRS를 구성하는 각각의 반사 계수 $|\alpha_m| = 1$ 로 구성된 대각 행렬이다.

기지국에서는 빔포밍 벡터 $\mathbf{m} \in \mathbb{C}^N$ 와 수신신호 $\mathbf{r} \in \mathbb{C}^N$ 를 이용해서 집계된 정보를 얻을 수 있다. 무선연산에서 집계된 정보는 연합학습에서 로컬 모델들의 평균과 같아야 하므로 평균 제곱 오차(mean squared error, MSE)를 최소화해야 한다. MSE를 최소화하기 위해 영 강압으로 구한 b_k 와 송신 전력의 제한 조건 $\mathbb{E}(|b_k s_k|^2) = |b_k|^2 \leq P$ 으로 구한 $\eta = \min_{k \in \mathcal{S}} P|\mathcal{S}| \|\mathbf{m}^H \tilde{\mathbf{h}}_k\|^2$ 를 적용해서 얻은 집계 오류는 다음과 같다.

$$\text{MSE} = \frac{\sigma^2}{P|\mathcal{S}|} \max_{k \in \mathcal{S}} \frac{\|\mathbf{m}\|^2}{|\mathbf{m}^H \tilde{\mathbf{h}}_k|^2} \leq \max_{k \in \mathcal{S}} \frac{1}{|\mathbf{m}^H \tilde{\mathbf{h}}_k|^2} \leq \delta \quad (4)$$

MSE에서 \mathbf{m} 에 0이 아닌 상수 배를 해도 무관하다는 점을 사용하면 조건 $\|\mathbf{m}\|^2 \leq 1$ 을 얻을 수 있다. 또한 높은 MSE는 모델 성능을 저하시키므로 목표로 하는 MSE 값인 δ 보다 작아야 한다. 제한 조건내에서 학습에 참여하는 디바이스를 최대화하는 문제는 보조 변수 \mathbf{x} 를 도입해서 다음과 같이 희소 최적화 문제로 작성할 수 있다.

$$\begin{aligned}
(P1) \quad & \min_{\mathbf{m}, \alpha, \mathbf{x}} \|\mathbf{x}\|_0 \\
& \text{s.t. } \tau - |(\mathbf{h}_k + \mathbf{R}\Phi\mathbf{t}_k)^H \mathbf{m}|^2 \leq x_k \\
& \|\mathbf{m}\|^2 \leq 1 \\
& \Phi = \text{diag}\{\alpha_1, \alpha_2, \dots, \alpha_M\}, |\alpha_m| = 1, \forall m \quad (5)
\end{aligned}$$

여기에서 $\|\mathbf{x}\|_0$ 는 \mathbf{x} 의 l_0 -norm 으로 벡터 \mathbf{x} 에서 영이 아닌 원소의 개수를 의미한다.

(P1)은 비볼록 최적화 문제로 풀기 어려운 문제가 있다. 본 논문에서는 l_0 -norm을 볼록 함수인 l_1 -norm으로 안정화하고 교대 최적화 방법으로 문제를 해결하였다. 제안하는 교대 최적화 알고리즘에서는 먼저 Φ 를 고정하고 \mathbf{m} 을 최적화한 뒤 \mathbf{m} 을 고정하고 Φ 를 최적화하며 이 과정을 수렴할 때까지 반복한다.

먼저 Φ 가 고정되었다면 이 문제는 IRS가 없는 무선연산 연합학습에서 학습에 참여하는 디바이스의 수를 최대화하는 기존의 문제와 같다. 따라서 DC와 같은 기존 알고리즘으로 빔포밍 벡터 \mathbf{m} 을 구할 수 있다[3].

다음으로 앞서 구한 \mathbf{m} 를 사용하여 Φ 를 최적화하는 문제는 다음과 같이 간략화해서 작성할 수 있다.

$$\begin{aligned}
(P2) \quad & \min_{\alpha, \mathbf{x}} \|\mathbf{x}\|_1 \\
& \text{s.t. } \tau - |c_k + \mathbf{d}_k^H \alpha|^2 \leq x_k \\
& |\alpha_m| = 1, \forall m \quad (6)
\end{aligned}$$

여기에서 $c_k = \mathbf{m}^H \mathbf{h}_k$ 와 $\mathbf{d}_k = \text{diag}\{\mathbf{t}_k\}^H \mathbf{R}^H \mathbf{m}$ 이다. (P2)에서 첫 번째 조건은 비 볼록으로 해결하기 어려운 문제가 있다. $|c_k + \mathbf{d}_k^H \alpha|^2$ 은 α 에 대해서 볼록 함수이므로 하한인 테일러 급수를 1 차항까지 전개한 값 $\tilde{\varphi}(\alpha; \alpha^{(l)})$ 으로 대체할 수 있다. 본 논문에서는 majorization minimization (MM) 기법을 적용하여 다음과 같은 볼록 문제를 반복적으로 푸는 것으로 해를 구한다.

$$\begin{aligned}
(P3) \quad & (\alpha^{(l+1)}, \mathbf{x}^{(l+1)}) = \max_{\alpha, \mathbf{x}} \|\mathbf{x}\|_1 \\
& \text{s.t. } \tau - \tilde{\varphi}(\alpha; \alpha^{(l)}) \leq x_k \\
& |\alpha_m| = 1, \forall m \quad (7)
\end{aligned}$$

(P3)에서 $|\alpha_m| = 1$ 대신 $|\alpha_m| \leq 1$ 을 사용하고 정규화하는 방식을 사용하면 이 문제는 볼록 최적화 문제이므로 CVX toolbox 를 사용해서 해결할 수 있다. 또한 본 논문에서는 projected subgradient method 을 적용하여 저 복잡도 알고리즘을 제안한다.

III. 모의 실험 결과

본 장에서는 IRS 반사 계수를 설계하지 않는 Random phase, 기존 알고리즘 DC[4], 이상적인 알고리즘인 Oracle-AirComp, 그리고 본 논문에서 제안하는 CVX와 Subgradient를 서로 비교한다.

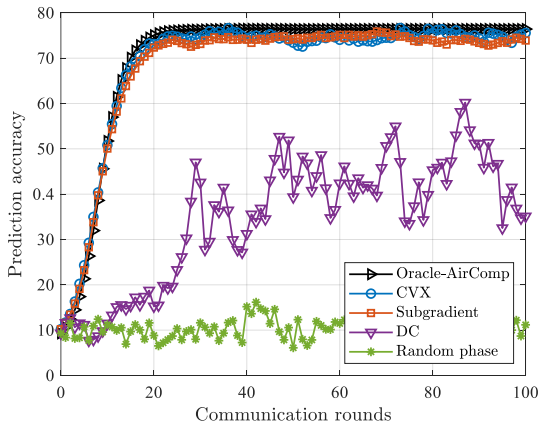


그림 1. 통신라운드에서 따른 예측 정확도

그림 1 은 기지국 안테나의 개수가 20 개, 전체 장치의 개수가 100 개, MSE threshold $\gamma = \frac{P_{ISI}}{\sigma^2} \delta$ 가 20dB일 때 통신라운드에 따른 인공지능 모델의 학습 성능을 보여준다. 모의 실험에서 1 번의 통신라운드는 연합학습이 1 번 진행되는 모든 과정을 포함하며 MNIST 데이터 셋에 대한 서포트 벡터 머신의 분류 성능을 평가하였다. DC는 통신라운드에 따라 선택되는 장치의 수가 일정하지 않기 때문에 학습에서도 불안정한 성능을 가진다. 제안하는 알고리즘인 CVX와 Subgradient는 통신 잡음이 없는 이상적인 상황을 가정한 Oracle-AirComp의 성능을 달성한다.

IV. 결론

본 논문에서는 IRS를 포함하는 무선연산 연합학습 시스템을 위한 장치 선택 및 IRS 반사 계수 설계 알고리즘을 제안하였다. 먼저 기존의 장치 선택 문제를 최소 최적화 문제로 변환하고 교대 최적화 기법을 적용하였다. 다음으로 IRS 반사 계수를 설계하기 위해 MM 기법을 적용하여 문제를 해결하였으며 projected subgradient 기법에 기반한 저 복잡도 알고리즘을 제안하였다. 모의 실험에서 제안하는 알고리즘은 기존의 SDR기반 알고리즘보다 더 많은 디바이스를 선택하며 이상적인 알고리즘인 Oracle-AirComp의 성능에 근접하는 것을 확인하였다.

ACKNOWLEDGMENT

이 논문은 2024 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.2018-0-00218, 초고주파 이동통신 무선백홀 전문연구실). 이 논문은 2024 년도 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 연구임 (No.RS-2022-00155915, 인공지능융합혁신인재양성(인하대학교)).

참고 문헌

- [1] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. Arcas, "Communication-efficient learning of deep networks from decentralized data," in Proc. Int Conf. Artif. Intell. Stat. (AISTATS), vol. 54, 2017, pp. 1273-1282.
- [2] B. Nazer and M. Gastpar, "Computation over multiple-access channels," IEEE Trans. Inf. Theory, vol. 53, no. 10, pp. 3498-3516, Oct. 2007.
- [3] K. Yang, T. Jiang, Y. Shi, and Z. Ding, "Federated learning via over-the-air computation," IEEE Trans. Wireless Commun., vol. 19, no. 3, pp. 2022-2035, Mar. 2020.
- [4] Z. Wang, J. Qiu, Y. Zhou, Y. Shi, L. Fu, W. Chen, and K. B. Letaief, "Federated learning via intelligent reflecting surface," IEEE Trans. Wireless Commun., vol. 21, no. 2, pp. 808-822, Feb. 2022.