

# 통신 효율적인 연합 학습을 위한 공중 아날로그 집계 연구 동향에 대한 조사

오준석, 이동현, 송치현, 허동현, 김재민, 백정엽, 신용구\*, 조성래

중앙대학교, \*고려대학교

{jsoh, dhlee, chsong, dhur, jmkim}@uclab.re.kr,  
jpaek@cau.ac.kr, \*ygshin92@korea.ac.kr, srcho@cau.ac.kr

## A Survey on Research Trends of Over-the-Air Analog Aggregation for Communication-Efficient Federated Learning

Junsuk Oh, Donghyun Lee, Chihyun Song, Donghyeon Hur, Jaemin Kim,

Jeongyeup Paek, Yonggoo Shin\*, and Sungrae Cho

Chung-Ang University, \*Korea University

### 요약

대규모 데이터 집합에 대해 점점 더 복잡한 신경망(DNN, Deep Neural Networks)의 훈련을 요구함에 따라 연합 학습(FL, Federated Learning)도 점점 더 높은 통신 비용을 요구한다. 이를 위해 FL은 다중 액세스 채널의 파형 중첩 특성을 활용하는 공중 계산(OAC, Over-the-Air Computation)을 통합하여 공중 연합 학습(FLOA, Federated Learning Over-the-Air)으로 발전한다. 이에 따라, 본 논문은 FLOA의 최근 연구 동향을 조사한다.

### I. 서론

기계 학습(ML, Machine Learning)은 빅 데이터를 통해 다양한 응용 서비스를 제공한다. 그러나 중앙 집중식 학습 패러다임은 각 장치에서 생성된 데이터를 파라미터 서버(PS, Parameter Server)가 수집하기 때문에 개인 정보 보호 문제가 발생한다. FL은 이러한 문제를 해결하기 위해 등장한 ML 패러다임으로 PS의 조정을 기반으로 수많은 장치에 저장된 로컬 데이터를 통해 하나의 글로벌 모델을 학습하는 것을 목표로 한다 [1]. FL에서는 글로벌 모델이 수렴될 때까지 PS가 각 장치에서 학습된 모델의 로컬 기울기(Gradient)를 집계하는 통신 라운드를 반복한다. 원시 데이터를 수집하지 않기 때문에 FL은 중앙 집중식 학습과 달리 개인 정보를 보호하면서 각 장치의 계산 자원을 활용할 수 있는 기회를 제공한다.

FL은 제공하는 서비스에 따라 모든 유형의 모델을 선택할 수 있다. 그러나, 모델을 구성하는 수많은 매개변수로 인해 병목 현상이 발생할 수 있다. 이러한 통신 비용을 줄이기 위해 FL은 기울기 압축 방식을 고려한다. 먼저, 양자화는 로컬 기울기에서 각 요소가 몇 개의 유한 비트로 표시되도록 제한하는 방식이다. 다음으로, 희소화는 로컬 기울기에서 일부 요소를 제거하고 중요한 요소만 남기는 방식이다. 마지막으로, 양자화와 희소화를 결합한 혼합 방식이 있다. 이외에도, 통신 검열, 압축 센싱 등 다양한 기울기 압축 방식이 있다. 그러나, 로컬 기울기 압축으로 인한 정보 손실은 글로벌 기울기 추정 오류로 인해 수렴률과 모델 성능 저하로 이어질 수 있다. 따라서, 최근 기울기 압축 방식은 다음 통신 라운드에서 정보 손실을 보상하는 오류 피드백 메커니즘을 통합한다.

로컬 기울기 압축 방식에도 불구하고 FL은 각 통신 라운드에 참여하는 장치의 수에 따라 통신 비용이 영향을 받기 때문에 여전히 병목 현상이 발생할 수 있다. 이를 위해 FL은 최근 다중 액세스 채널의 파형 중첩 특성을 활용하여 공중을 컴퓨터 및 통신 기능을 수행하는 컴퓨터로 변환하는 OAC를 통합한다. [2]. 이에 따라 FL과 OAC가 통합된 FLOA는 동일한 시간-주파수 자원에 걸쳐 모든 장치가 동시에 로컬 기울기를 전송하고

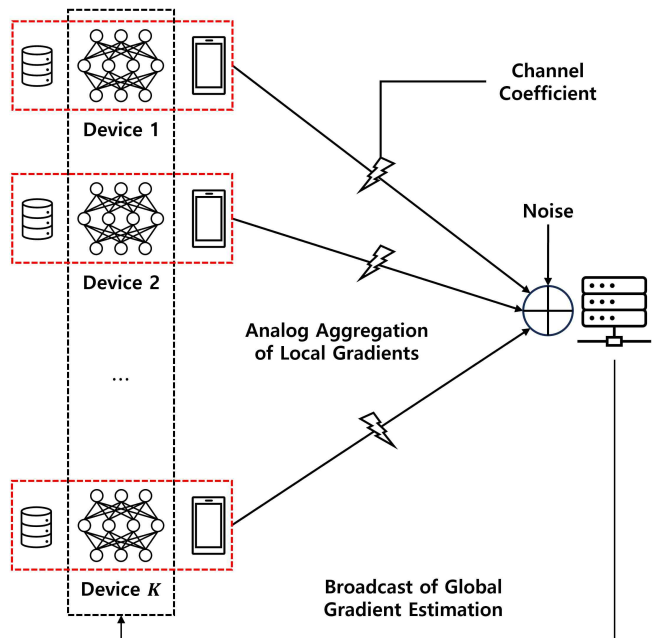


그림 1. FLOA 시스템의 프레임워크 아키텍처  
Fig. 1. The framework architecture of FLOA system

PS는 수집된 로컬 기울기를 수신한다 [3], [4]. 따라서, FLOA는 통신과 계산을 통합하여 기존 FL보다 높은 대역폭 효율을 달성할 수 있는 기회를 제공한다. 본 논문은 본문에서 이러한 FLOA의 최신 연구 동향을 조사하고, 결론에서 미래의 방향을 제시하여 마무리한다.

### II. 본론

FLOA의 그림 1과 같은 아날로그 집계 모델에서 전력 제어 설계는 잡음 및 페이딩으로 인한 신호 오류를 완화하기 위해 중요하다 [5]. 이를 위

해, [3]의 저자들은 전력 제어 및 장치 스케줄링을 위한 통신 대 학습 간 절충점을 도출하여 광대역 아날로그 집계 모델을 설계했다. 또한, 그들은 채널 상태에 따라 장치와 일부 로컬 기울기를 배제하기 위해 절단된 채널 반전 접근 방식을 도입했다. [4]은 다중 안테나 시나리오에서 주어진 평균 제공 오차 요구 사항을 최소화하여 참여 장치 수를 최대화하기 위한 수신 빔포밍 및 장치 스케줄링의 공동 설계를 제안했다. [3]과 [4]는 전력 제어의 용이성을 위해 로컬 기울기가 0의 평균 및 단위 분산으로 정규화된다고 가정한다. 그러나 FL에서 로컬 기울기 통계는 반복 및 특징에 따라 다르고 사전 지식이 없다. 따라서, PS는 로컬 기울기에 대한 사전 지식 없이 최적의 전력 제어를 설계할 수 없다. 이에 따라, [6]은 무선 전송에서 개별 집계 왜곡을 최소화하기 위한 기울기 인식 전력 제어 체계를 제안했다. 또한 FL과 아날로그 집계 사이의 관계가 명확하지 않음에 주목하여 [7]은 FL에 대한 AirComp의 효과를 정량화하고 전력 제어 및 장치 스케줄링의 공동 최적화를 제안했다. [8]의 저자들은 집계 오류와 관련하여 최적성 격차에 대한 이론적 상한을 도출하고 개별 전력 제약 아래에서 최적성 격차를 최소화하기 위한 최적의 전송 전력 제어를 제안했다. 이와 유사하게, [9]는 집계 오류가 편향 및 평균 제공 오차에 미치는 영향을 특성화하고 최적의 전력 제어 설계를 제안했다. 또한 [10]은 학습 성능에 대한 채널 잡음의 영향을 완화하기 위해 전력 제어 및 계산 자원의 공동 최적화를 제안했다. 이외에도, [11] 및 [12]의 저자들은 비잔틴 공격에 대한 강력한 전력 제어 방식을 제안했다. [13]의 저자들은 에너지 제약 장치를 고려하여 참여 장치의 평균 수를 최대화하기 위한 에너지 인식 장치 스케줄링 전략을 제안했다. [14]의 저자들은 아날로그 하향 및 상향링크 통신을 모두 고려하여, 적응적 재가중치 방식과 함께 전력 제어 및 장치 스케줄링을 위한 반정의 프로그래밍 기반 공동 최적화 방식을 제안했다.

### III. 결론

본 논문은 통신 효율적인 FL을 위한 공중 아날로그 집계의 연구 동향에 대한 조사를 제시한다. 경로 손실을 줄이기 위해 이전 연구에서는 주로 전력 제어와 장치 스케줄링의 공동 설계를 고려했다. FLOA의 전체 통신 비용을 더 줄이기 위해 이러한 연구들은 기울기 압축 방식을 추가로 고려할 수 있다. 따라서, 향후 새로운 연구들은 수렴률과 통신 비용 간 절충점을 체계적으로 분석하고, 앞으로 다른 어떤 공중 아날로그 집계 기술보다도 더 통신 효율적임을 증명해야 한다.

### ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원사업(IITP-2024-RS-2022-00156353)과 2022년도 및 2023년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (No. 2022R1A4A5034130 및 RS-2023-00209125).

### 참고 문헌

[1] B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y. Arcas, "Communication-Efficient Learning of Deep Networks from Decentralized Data," *Proceedings of the 20th AISTATS*, vol. 54, PMLR, 2017, pp. 1273 - 1282.

[2] B. Nazer and M. Gastpar, "Computation over Multiple-Access Channels," *IEEE Transactions on Information Theory*, vol. 53, no.

10, pp. 3498 - 3516, 2007.

[3] G. Zhu, Y. Wang, and K. Huang, "Broadband Analog Aggregation for Low-Latency Federated Edge Learning," *IEEE Transactions on Wireless Communications*, vol. 19, no. 1, pp. 491 - 506, 2020.

[4] K. Yang, T. Jiang, Y. Shi, and Z. Ding, "Federated Learning via Over-the-Air Computation," *IEEE Transactions on Wireless Communications*, vol. 19, no. 3, pp. 2022 - 2035, 2020.

[5] G. Zhu, J. Xu, K. Huang and S. Cui, "Over-the-Air Computing for Wireless Data Aggregation in Massive IoT," *IEEE Wireless Communications*, vol. 28, no. 4, pp. 57-65, 2021.

[6] N. Zhang and M. Tao, "Gradient Statistics Aware Power Control for Over-the-Air Federated Learning," *IEEE Transactions on Wireless Communications*, vol. 20, no. 8, pp. 5115-5128, 2021.

[7] X. Fan, Y. Wang, Y. Huo and Z. Tian, "Joint Optimization of Communications and Federated Learning Over the Air," *IEEE Transactions on Wireless Communications*, vol. 21, no. 6, pp. 4434-4449, 2022.

[8] X. Cao, G. Zhu, J. Xu and S. Cui, "Transmission Power Control for Over-the-Air Federated Averaging at Network Edge," *IEEE Journal on Selected Areas in Communications*, vol. 40, no. 5, pp. 1571-1586, 2022.

[9] X. Cao, G. Zhu, J. Xu, Z. Wang and S. Cui, "Optimized Power Control Design for Over-the-Air Federated Edge Learning," *IEEE Journal on Selected Areas in Communications*, vol. 40, no. 1, pp. 342-358, 2022.

[10] H. Yang, P. Qiu, J. Liu and A. Yener, "Over-the-Air Federated Learning with Joint Adaptive Computation and Power Control," *2022 IEEE International Symposium on Information Theory (ISIT)*, Espoo, Finland, 2022, pp. 1259-1264.

[11] X. Fan, Y. Wang, Y. Huo and Z. Tian, "Best Effort Voting Power Control for Byzantine-resilient Federated Learning Over the Air," *2022 IEEE International Conference on Communications Workshops (ICC Workshops)*, Seoul, Republic of Korea, 2022, pp. 806-811.

[12] X. Fan, Y. Wang, Y. Huo and Z. Tian, "BEV-SGD: Best Effort Voting SGD Against Byzantine Attacks for Analog-Aggregation-Based Federated Learning Over the Air," *IEEE Internet of Things Journal*, vol. 9, no. 19, pp. 18946-18959, 2022.

[13] Y. Sun, S. Zhou and D. Gündüz, "Energy-Aware Analog Aggregation for Federated Learning with Redundant Data," *2020 IEEE International Conference on Communications (ICC)*, Dublin, Ireland, 2020, pp. 1-7.

[14] W. Guo, R. Li, C. Huang, X. Qin, K. Shen and W. Zhang, "Joint Device Selection and Power Control for Wireless Federated Learning," *IEEE Journal on Selected Areas in Communications*, vol. 40, no. 8, pp. 2395-2410, 2022.