

# 연합학습(Federated Learning) 네트워크에서의 형평성 보장 기법에 관한 연구

김 영 찬\*, 김 훈<sup>o</sup>

## A Survey on Fairness Provision Schemes for Federated Learning Networks

Yeong-chan Kim\*, Hoon Kim<sup>o</sup>

### 요 약

연합학습(Federated Learning, FL) 네트워크는 데이터 등 인공지능 학습 자원이 부족한 단말들이 연합 학습을 지원하는 서버와 연결되어 협력적으로 학습 모델 파라미터를 완성해 가는 것으로, 데이터를 직접 보내지 않고 학습 성능이 개선될 수 있는 효과적인 방법이다. 연합 학습이 여러 단말의 참여를 바탕으로 하여 참여자 선택, 참여자간 비중 반영 등에서의 형평성 문제가 제기된다. 본 연구에서는 이와 같은 연합 학습에서의 형평성 문제에 대한 연구 동향과 주요 기법을 소개한다. 또한 비례 균등 형평성 알고리즘을 적용하는 방안을 제시한다.

**Key Words** : Proportional fairness, Network, Scheme, Deep learning, Federated learning

### ABSTRACT

Federated Learning(FL) Network is a method in which terminals lacking artificial intelligence learning resources such as data are connected to a server that supports federated learning to cooperatively complete learning model parameters, and learning performance is

improved without directly sending data. an effective way to do it. As federated learning is based on the participation of multiple terminals, issues of fairness are raised in the selection of participants and reflection of weight among participants. In this study, research trends and major algorithms for equity issues in federated learning are introduced. In addition, a scheme to apply the proportional equality equity algorithm is presented.

### I. 서 론

데이터, 컴퓨팅 자원 등을 기반으로 하는 인공지능의 활용이 차세대 네트워크 환경에서 더욱 요구될 전망으로 자원이 제한된 단말에서의 인공지능 학습을 효과적으로 지원하는 이슈가 제기된다. 그 해결책으로 연합학습이 있으며, 서버에서 공통의 학습 모델을 단말에 보내고 단말이 보유한 데이터를 가지고 학습한 파라미터를 서버에 전송하는 것을 기초로 한다. 서버는 파라미터를 수신, 취합하여 공통의 학습 파라미터를 도출하고 이를 다시 단말에 제공한다. 학습 결과로부터 공통의 학습 파라미터를 생성하는 기준과 방식에 대한 연구가 진행된 바 있다<sup>1)</sup>. 연합학습에 참여하는 단말들로부터 얻은 결과를 데이터 양 등이 감안된 가중치를 적용하여 공통 파라미터를 계산하는 방법들이 제안되었다<sup>2-4)</sup>. 서버에서의 파라미터 취합 과정에서 개별 단말간의 성능 편차에 관한 이슈가 고려된 바 있으며, 연합학습에 참여하는 단말 선정 과정에 관한 연구들이 진행되었다<sup>5-7)</sup>.

본 연구는 연합학습에서의 참여 단말 선정 문제에서의 형평성을 보장하는 기법에 관한 것이다. 연합 학습 과정에서 형평성에 관한 연구 동향을 조사하고, 단말 선정을 위한 수식을 제시한다.

### II. 연합학습에서의 형평성 연구

연합학습 네트워크에서 단말간의 형평성 문제는 크게 단말에서 학습 결과로 얻은 파라미터의 취합 과정과 연합학습의 참여자 선정 과정에서 대두된다. 표 1

\* 이 논문은 인천대학교 2021년도 자체연구비 지원에 의하여 연구되었음.

• First Author : Incheon National University Department of Electronics Engineering, 사물인터넷빅데이터연구센터, kyc0288@inu.ac.kr, 학생(석사과정), 학생회원

o Corresponding Author : Incheon National University Department of Electronics Engineering, 사물인터넷빅데이터연구센터, hoon@inu.ac.kr, 정교수, 종신회원

논문번호 : 202303-064-B-LU, Received March 30, 2023; Revised April 13, 2023; Accepted April 13, 2023

표 1. 연합학습 형평성 관련 연구 사례  
Table 1. case study related to fairness in federated learning

Procedure	Name	Main Content
Calculation of common parameters	FedAvg[8]	Weighted by amount of data
	q-FFL[9]	Include parameters to correct for fairness
	FairFed[10]	Weighting for common and individual indicators of equity approximation
	Ditto[11]	Definition of multi-variable objective function considering the characteristics of each terminal
Selection of participating devices	RP[12]	Reputation considerations of radio channel conditions and the impact of malicious attack capabilities
	Communication-Efficient Scheduling[13]	Statistical channel characteristics related to transmission deadline observance reliability are reflected
	CS-UCB-Q[14]	Reliability-based selection and queuing to expand opportunities guaranteed
	RBCS-F[15]	Confidence-based Include Minimum Engagement Rate Constraint

에서 두 과정에서의 형평성에 관한 연구를 요약한다.

### III. 비례 균등 참여자 선정 문제

참여 단말 선정 과정에서의 형평성을 보장하는 방안으로 비례 균등 형평성 조건을 적용하는 방법을 소개한다.

#### 3.1 시스템 모델

본 연구에서의 연합학습 네트워크는 연합학습에 참여하려는 다수의 단말과 통신하며 연합학습을 총괄하는 1개의 서버로 구성된다. 단말의 총 수는  $M$ 개이며, 연합학습의 각 라운드에서  $N(\leq M)$ 개의 단말이 참여한다. 참여 단말  $N$ 개를 선택하는 과정은 순시적으로 이루어지며, 서버로부터 공통 학습 모델과 초기 파라미터가 참여하는 단말에 제공된다. 또한 참여 단말은 자신의 데이터를 대상으로 학습을 수행하여 얻은 파라미터를 서버에 전송한다. 서버는 이를 취합하고 공

통의 학습 파라미터를 산출하고 이를 다시 단말에 회신한다. 이 과정은 매 라운드에서 학습이 완료될 때까지 반복되며, 다음 라운드에서 참여 단말이 새롭게 선정된다.

#### 3.2 비례 균등 참여자 선정 문제

연합학습에 참여하는 단말 선정시 참여자간 형평성을 고려해야 한다. 이는  $M$ 개의 단말 중  $N$ 개를 선정하는 문제에서, 형평성에 관한 기준을 설정하고 이를 보장하는 방법에 관한 것으로 형평성에 관한 목적함수를 설정하고 참여단말 집합 후보  $S$  중 이를 최대로 하는  $S^*$ 를 찾는 참여자 선정 문제로 전개될 수 있으며 식 (1)과 같이 나타낸다.

$$S^* = \arg \max_{S(i \in S)} f(S) \quad (1)$$

$$(|S| = N)$$

$f(S)$ 는 목적함수로 참여 단말 집합이  $S$ 일 때 획득되는 시스템 유틸리티 함수이다.  $f(S)$ 는 개별 단말의 동작이나 성능과 관련된 파라미터를 포함할 수 있으며 시스템 전체 학습 성능을 대표한다. 즉,  $f(S)$ 는 연합학습 네트워크에서 참여 단말 선정을 위한 중요한 기준이 되며 후보  $S$  중 최대  $f(S)$ 값을 갖도록 하는  $S^*$ 가 비례 균등 참여자 선정 문제의 해가 된다. 비례 균등 형평성을 위한  $f(S)$ 는 식 (2)와 같이 정리된다.

$$f(S) = \sum_i \log R_i^{(S)} \quad (2)$$

$R_i^{(S)}$ 는 참여단말 선정의 매 라운드에서 참여 단말을 집합  $S$ 로 했을 때 단말  $i$ 에 관한 개별 유틸리티 수치이다. 무선네트워크 패킷 스케줄링에서 개별 단말의 유틸리티가 평균전송률로 정의되어 이용되었다. 이에 로그를 취하고 모든 단말의 값들을 합하면 비례 균등 형평성을 가지는  $f(S)$ 는 식 (3)와 같다.




그림 1. 시스템 모델  
Fig. 1. System Model

$$S^* = \arg \max_{S(i \in S)} \Pi \left( 1 + \frac{r_i}{(T-1)\overline{R}_i} \right) \quad (3)$$

(| S | = N)

#### IV. 비례 균등 참여자 선정 기법

연합학습 네트워크에서 참여 단말을 선정하는 매 라운드에서 비례 균등 형평성 조건을 만족하는 기법을 소개한다. 비례 균등 형평성은 무선네트워크 패킷 스케줄링에서 전체 시스템 성능과 단말 개별의 성능에 대한 균형을 효과적으로 달성하며, 단일 전송 채널 및 다중 전송 채널에서의 이를 달성하는 최적해가 제시된 바 있다.

연합학습 네트워크에서 비례 균등 형평성을 보장하기 위해 식 (2)에서  $R_i^{(S)}$ 를 연합학습 네트워크 상황에 맞도록 정의하는 것이 필요하다. 참여 단말 선정에 위한 매 라운드에서  $R_i^{(S)}$ 는 다음과 같이 산출될 수 있다.

$$R_i^{(S)} = \begin{cases} \frac{(T-1)\overline{R}_i + r_i}{T}, & \text{if } i \in S \\ \frac{(T-1)\overline{R}_i}{T}, & \text{elsewhere} \end{cases} \quad (4)$$

식 (4)에서 T는  $R_i^{(S)}$ 을 계산하는 평균값의 구간이며,  $\overline{R}_i$ 는 이전 라운드에서의  $R_i^{(S)}$  값이다.  $r_i$ 는 단말  $i$ 가 S에 속해있을 경우, 즉 연합학습에 참여할 경우 해당 라운드에서 순시적으로 획득되는 단말  $i$ 의 유틸리티이다. 식 (4)으로 표현되는  $R_i^{(S)}$ 를 식 (1)의 최적해를 구하는 문제에 적용하면 식 (1)은 결국 우측항이 가장 큰 N개의 단말을 찾는 문제가 되고, 이는 즉,  $r_i / \overline{R}_i$  값이 가장 큰 단말 N개를 구하는 문제로 귀결된다.

$$S^* = \arg \max_{S(i \in S)} \frac{r_i}{\overline{R}_i} \quad (5)$$

(| S | = N)

#### V. 결론

딥러닝 등 인공지능 기술의 적용이 네트워크 분야에도 고려되고 있다. 본 연구를 통해 연합학습 네트워크 환경에서 단말의 학습 성능을 지원하는 문제를 살펴본다. 특히 형평성에 기반한 참여자 선택에 관한 기존 연구를 조사하고 이를 효과적으로 반영할 수 있는 방향에 대해 소개하였다. 이를 통해 연합학습 네트워크에서 참여자간 형평성을 보장하면서 전체적인 학

습 성능 유지에도 도움이 되는 기법이 가능하다. 향후 연구에서 이에 대한 다양한 요소들을 고려하고 연합학습에서의 전체 시스템 및 단말에서의 성능 분석 등을 진행할 필요가 있다.

#### References

- [1] W. Lee, "Analysis of federated learning considering model transmission delay depending on communication situation," *J. Next-generation Convergence Technol. Assoc.*, vol. 6, no. 3, pp. 379-388, 2022. (<https://doi.org/10.33097/JNCTA.2022.06.03.379>)
- [2] B. McMahan, et al., "Communication-efficient learning of deep networks from decentralized data," *Artificial Intell. and Statistics*, pp. 1273-1282, Apr. 2017. (<https://doi:10.48550/arXiv.1602.05629>)
- [3] T. Li, et al., "Federated Learning : Challenges, methods, and future directions," *IEEE Signal Process. Mag.*, vol. 37, no. 3, pp. 50-60, May 2020. (<https://doi.org/10.48550/arXiv.1908.07873>)
- [4] J. Kang, et al., "Incentive design for efficient federated learning in mobile networks: A contract theory approach," *APWCS*, pp. 1-5, Aug. 2019. (<https://doi.org/10.1109/VTAS-APWCS.2019.8851649>)
- [5] T. Nishio and R. Yonetani, "Client selection for federated learning with heterogeneous resources in mobile edge," *ICC*, pp. 1-7, Shanghai, china, 2019. (<https://doi.org/10.1109/ICC.2019.8761315>)
- [6] J. Ma, et al., "Client selection based on label quantity information for federated learning," *2021 IEEE 32nd Annu. Int. Symp. Pers., Indoor and Mobile Radio Commun.*, Helsinki, Finland, pp. 1-6, 2021. (<https://doi.org/10.1109/PIMRC50174.2021.9569487>)
- [7] C. Sun, et al., "User selection for federated learning in a wireless environment: A process to minimize the negative effect of training data correlation and improve performance," in

- IEEE Veh. Technol. Mag.*, vol. 17, no. 3, pp. 26-33, Sep. 2022.  
(<https://doi.org/10.1109/MVT.2022.3153274>)
- [8] Y. H. Ezzeldin, et al., "FairFed: Enabling group fairness in federated learning," *Accepted to appear at AAAI*, 2023.  
(<https://doi.org/10.48550/arXiv.2110.00857>)
- [9] M. Mohri, et al., "Agnostic federated learning," *Int. Conf. Mach. Learn.*, PMLR, pp. 4615-4625, 2019.  
(<https://doi.org/10.48550/arXiv.1902.00146>)
- [10] L. Lyu, et al., "Collaborative fairness in federated learning," *FL-IJCAI'20*, pp. 189-204, 2020.  
([https://doi.org/10.1007/978-3-030-63076-8\\_14](https://doi.org/10.1007/978-3-030-63076-8_14))
- [11] H. Cho, et al., "FLAME: Federated learning across multi-device environments," in *Proc. ACM Interactive, Mobile, Wearable and Ubiquitous Technologies*, vol. 6, no. 3, pp. 1-29, 2022.  
(<https://doi.org/10.1145/3550289>)
- [12] Z. Song, et al., "Reputation-based federated learning for secure wireless networks," *IEEE Internet of Things J.*, vol. 9, no. 2, pp. 1212-1226, 2021.  
(<https://doi.org/10.1109/JIOT.2021.3079104>)
- [13] J. Perazzone, et al., "Communication-efficient device scheduling for federated learning using stochastic optimization," *IEEE INFOCOM 2022-IEEE Conf. Comput. Commun.*, pp. 1449-1458, 2022.  
(<https://doi.org/10.1109/INFOCOM48880.2022.9796818>)
- [14] W. Xia, et al., "Multi-armed bandit-based client scheduling for federated learning," *IEEE Trans. Wireless Commun.*, vol. 19, no. 11, pp. 7108-7123, 2020.  
(<https://doi.org/10.1109/TWC.2020.3008091>)
- [15] T. Huang, et al., "An efficiency-boosting client selection scheme for federated learning with fairness guarantee," *IEEE Trans. Parallel and Distrib. Syst.*, vol. 32, no. 7, pp. 1552-1564, 2020.  
(<https://doi.org/10.1109/TPDS.2020.3040887>)
- [16] H. Kim and Y. Han, "A proportional fair scheduling for multicarrier transmission systems," in *IEEE Commun. Lett.*, vol. 9, no. 3, pp. 210-212, Mar. 2005.  
(<https://doi.org/10.1109/LCOMM.2005.03014>)