

IoT 네트워크를 위한 연합학습: 응용 분야 및 한계

송승엽, 박희재, 박래혁

서울과학기술대학교 컴퓨터공학과

{thdtmdduqdhk, prkhj98, lhpark}@seoultech.ac.kr

Federated Learning for IoT Networks: Applications and Challenges

Seungyeop Song, Heejae Park, Laihyuk Park

Department of Computer Science and Engineering
Seoul National University of Science and Technology

요약

연합학습은 사용자 데이터를 중앙 서버에서 직접 학습시키지 않고, 각 사용자가 자체적으로 학습한 후에 모델을 중앙 서버로 전송하여 처리하는 기술이다. 이를 통해 개인정보 보호 및 데이터 관리와 관련된 문제를 효과적으로 해결할 수 있어 중요한 기술로 인식되고 있다. 본 논문은 연합학습의 응용분야를 조사하고 연합학습의 장점과 한계를 알아보았으며 향후 연구방향에 대해 논하였다.

I. 서 론

최근 스마트 기기와 사물인터넷 등 디지털 기술이 발전함에 따라 데이터의 수집, 저장 및 관리가 중요해지고 있다. 전통적인 머신러닝 기법은 사용자의 데이터를 중앙 서버에 수집하여 학습한 후 사용자에게 전달하는 방식이지만, 이는 개인정보, 보안, 실시간 처리 등에서 문제가 발생할 수 있는 방식이며, 이를 해결할 수 있는 대안으로 연합학습이 연구되고 있다. 연합학습은 사용자 데이터를 중앙 서버에서 직접 학습시키지 않고, 각 사용자가 자체적으로 학습한 후에 모델을 중앙 서버로 전송하여 처리하는 기술이다 [1]. 이를 통해 머신러닝 기법들보다 향상된 성능을 달성할 수 있으며, 개인정보 보호 및 데이터 관리와 관련된 문제를 효과적으로 해결할 수 있어 중요한 기술로 인식되고 있다 [2]. 본 논문에서는 연합학습의 응용분야인 에너지관리, 헬스케어, 스마트 교통에 대해 살펴보고, 연합학습의 장점과 한계를 알아보았다.

II. 본 론

A. 에너지 관리

최근 이상기온 발생과 에너지 고갈에 따라서 에너지를 효율적으로 사용하는 것이 중요한 과제로 떠올랐다. 기존의 머신러닝 기법이 사용자의 데이터를 중앙 서버에 수집하여 학습하는 것과 같이 기존의 전력망은 중앙 집중형, 단방향 정보 흐름 구조를 가지고 있다는 단점이 존재한다. 이에 따라 연합학습을 적용한 분산형, 양방향 정보흐름 구조를 가지는 스마트 그리드 연구가 진행되고 있다. 이는 Electricity Consumer Identification, Electricity Demand Prediction과 같은 분야에서 활용될 수 있다 [3].

B. 헬스 케어

연합학습은 환자의 민감한 건강 데이터를 중앙 서버로 수집하여 관리하지 않고, 분산된 지역에서 모델을 학습시키기 위해 사용된다. 연구 [4]에서

는 EEG (Electroencephalographic) 데이터를 분류하기 위해 연합 전이 학습 (FTL, Federated Transfer Learning) 기반 모델을 제안하였다. FTL를 적용함으로써 데이터 프라이버시를 유지할 수 있을 뿐만 아니라, 기존의 딥러닝 알고리즘보다 우수한 성능을 보여주었다.

연구 [5]에서는 연합학습을 활용하여 입원 환자의 병력을 기반으로 입원 연도를 예측하는 연구를 진행했다. 저자들은 환자들의 병력 데이터를 중앙 서버로 수집하지 않고 연합학습 기반 분산 알고리즘인 cPDS (cluster Primal Dual Splitting)를 이용하여 문제를 해결했다.

C. 스마트교통

지능형교통체계를 지원하기 위해 많은 연합학습 기반 아키텍처가 제안되었다. 연구 [6]에서는 각 사용자의 통신 모드 선택과 전력 제어를 통해 차량 네트워크의 합산 정보 전달율을 최대화하는 문제를 정의하였다. 저자들은 해당 문제를 해결하기 위해 연합학습과 강화학습을 활용했다.

연구 [7]에서는 데이터를 중앙 서버와 공유하지 않는 연합학습 및 강화학습 기반 교통 시뮬레이터를 제안했다. 해당 시뮬레이터는 지연 시간과 프라이버시가 중요한 관심사 중 하나인 고속 자율 주행에서 차량 충돌 회피 작업을 효율적으로 지원할 수 있을 것으로 기대된다.

D. 한계

앞서 말했듯이 연합학습은 많은 분야에 활용될 수 있지만 한계도 존재한다. 각 사용자의 혼란 데이터가 다른 크기와 분포를 가질 때, 데이터 처리 비용이 증가할 수 있고 사용자 수가 기하급수적으로 늘어날 경우에는 네트워크 채널 부하로 인해 서버 간 통신이 어려워질 수 있다 [8]. 뿐만 아니라 연합학습을 진행할 때 모든 개별 장치가 학습을 위한 저장 장치와 컴퓨팅 리소스를 사용해야 하는데, 이로 인해 특정 장치의 리소스 제약이 발생하면 지연이 발생할 수 있고, 배터리 부족과 같은 현실적인 문제도 발

생할 수 있다.

III. 결 론

연합학습은 사용자 데이터를 중앙 서버에서 직접 학습시키지 않고, 각 사용자가 자체적으로 학습한 후에 모델을 중앙 서버로 전송하여 처리하는 기술이다. 이를 통해 실시간으로 향상된 성능을 달성할 수 있으며, 개인정보 보호 및 데이터 관리와 관련된 문제를 효과적으로 해결할 수 있어 중요한 기술로 인식되고 있다. 본 논문에서는 연합학습의 응용분야인 에너지 관리, 헬스케어, 스마트 교통과 연합학습의 한계에 대해 살펴보았다. 향후 연구에서는 각각의 응용분야에 대해 추가적인 연합학습의 적용사례를 조사하여 장점과 한계를 알아볼 것이다.

ACKNOWLEDGMENT

본 연구는 정부 (과학기술정보통신부)의 재원으로 한국연구재단의 지원과 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터육성지원 사업의 연구결과로 수행되었음 (No. 2021R1F1A1062881, IIITP-2024-RS-2022-00156353)

참 고 문 헌

- [1] L. U. Khan, W. Saad, Z. Han, E. Hossain and C. S. Hong, "Federated Learning for Internet of Things: Recent Advances, Taxonomy, and Open Challenges," in IEEE Communications Surveys & Tutorials, vol. 23, no. 3, pp. 1759–1799, June 2021.
- [2] D. C. Nguyen, M. Ding, P. N. Pathirana, A. Seneviratne, J. Li and H. Vincent Poor, "Federated Learning for Internet of Things: A Comprehensive Survey," in IEEE Communications Surveys & Tutorials, vol. 23, no. 3, pp. 1622–1658, Apr. 2021.
- [3] Y. Wang, M. Jia, N. Gao, L. Von Krannichfeldt, M. Sun and G. Hu, "Federated Clustering for Electricity Consumption Pattern Extraction," in IEEE Transactions on Smart Grid, vol. 13, no. 3, pp. 2425–2439, May. 2022.
- [4] C. Ju, D. Gao, R. Mane, B. Tan, Y. Liu and C. Guan, "Federated Transfer Learning for EEG Signal Classification," 2020 42nd Annual International Conference of the IEEE Engineering in Medicine & Biology Society (EMBC), Montreal, QC, Canada, pp. 3040–3045, Aug. 2020.
- [5] Brismi, T. S., Chen, R., Mela, T., Olshevsky, A., Paschalidis, I. C., and Shi, W., "Federated learning of predictive models from federated electronic health records," International journal of medical informatics, vol. 112, pp. 59–67, Apr. 2018.
- [6] X. Zhang, M. Peng, S. Yan and Y. Sun, "Deep-Reinforcement-Learning-Based Mode Selection and Resource Allocation for Cellular V2X Communications," in IEEE Internet of Things Journal, vol. 7, no. 7, pp. 6380–6391, Jul. 2020.
- [7] Liang, Xinle, et al. "Federated transfer reinforcement learning for autonomous driving." *Federated and Transfer Learning*. Cham: Springer International Publishing, pp. 357–371, Oct. 2022.
- [8] Bonawitz, Keith, et al. "Towards federated learning at scale: System design." *Proceedings of machine learning and systems* 1, pp. 374–388, 2019.