

LEO 위성 기반 IoT 시스템의 정확도 향상을 위한 새로운 연합학습 알고리즘

이상철, 채승호*

한국공학대학교

shng9522@tukorea.ac.kr, *shchae@tukorea.ac.kr

A Novel Federated Learning Algorithm for Enhancing Accuracy in LEO Satellite IoT Systems

Sangcheol Lee, Seong Ho Chae*

Tech University of Korea

요약

본 논문은 저궤도(LEO: Low Earth Orbit) 위성 환경에서 발생하는 간헐적 통신과 사물인터넷(IoT: Internet of Things)의 클라이언트 간 자원 이질성을 고려하여, 로컬 데이터양, 모델 변화량, 로컬 업데이트 수를 통합적으로 반영한 새로운 연합학습(FL: Federated Learning) 알고리즘을 제안한다. 실험을 통해 전통적인 FL 알고리즘 대비 높은 글로벌 모델 정확도를 달성을 확인하였고, 이를 통해 제안하는 알고리즘에 대한 LEO 위성 IoT 환경에 서의 적용 가능성을 확인하였다.

I. 서론

사물인터넷(IoT: Internet of Things)은 다양한 장치들이 인터넷을 통해 연결되어 데이터를 주고받고, 자동화 및 원격 제어를 가능하게 하는 기술로, 최근에는 빅데이터 및 인공지능 기술과 융합되어 산업 전반에 걸쳐 활용되고 있다[1][2]. 농경지, 해양, 사막, 극지방 등과 같은 도심 외곽지역에서의 IoT의 활용이 확대되고 있다[3]. 그러나, 이러한 지역에서는 통신 인프라의 부재로 안정적 연결을 제공할 수 없다는 한계가 있으며, 이에 대한 대안으로 최근 저궤도(LEO: Low Earth Orbit) 위성의 활용이 주목받고 있다. LEO 위성은 상대적으로 낮은 고도에서 고속으로 지구를 공전하며, 작은 지연 시간과 넓은 통신 범위를 제공할 수 있다는 특성을 가진다[4]. 그러나, 고속 이동으로 인해 위성과 단말 간 연결 시간이 매우 짧고 간헐적이기 때문에, 기존의 중앙집중형(Centralize) 학습 방식은 적용하기 어렵다는 한계를 갖는다.

따라서, 통신 효율성을 높이고 데이터 전송 지연 시간을 최소화할 수 있는 분산(Distributed) 구조가 요구되며, 각 단말이 로컬에서 학습을 수행한 후 로컬 모델만을 서버로 공유하고, 서버에서는 글로벌 모델을 업데이트하여 배포하는 연합학습(FL: Federated Learning)이 많은 관심을 받고 있다. 또한, LEO의 간헐적 연결 특성은 기존의 동기식(Synchronized) FL에 제약을 발생시킨다. 동기식 FL은 모든 클라이언트가 로컬 모델을 전송해야만 글로벌 모델이 생성되는 방식으로, 일부 클라이언트의 로컬 학습이 지연되거나, 클라이언트가 연결되지 않는 경우 전체 학습이 지연되거나 중단되는 문제가 발생한다. 따라서, LEO 위성 기반 IoT 환경에서는 위성과 연결 가능한 클라이언트만 글로벌 모델 업데이트에 참여할 수 있도록 하는 비동기식(Asynchronized) FL 구조가 적합하다. 그러나, 전통적인 FL 알고리즘인 FedAvg[5], FedProx[6], FedNova[7] 등은 동기식 구조로 설계되었는데 이는 클라이언트와 LEO 위성 간의 연결 특성을 반영하지 못해 학습 안정성과 학습 지연을 발생시킨다.

본 논문에서는 로컬 데이터양, 클라이언트별 연산량, 모델 변화량을 모두 고려한 새로운 FL 알고리즘을 제안한다. 제안된 알고리즘은 글로벌 업데이트 이후 로컬 모델의 변화량을 고려함으로써 비동기 환경에서도 적용할 수 있으며, LEO 위성 기반 IoT 환경에서 안정적이고 효율적인 글로벌 모델 수렴을 달성을 할 수 있다.

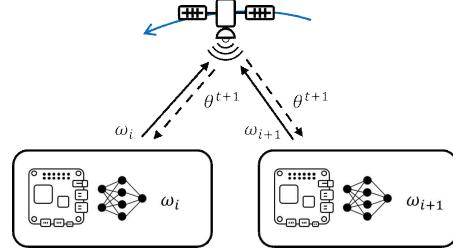


그림 1. LEO 위성 기반 IoT 시스템

II. 시스템 구성

그림 1은 본 논문에서 고려하는 LEO 위성 기반 IoT 시스템을 보여주며, LEO 위성과 IoT 클라이언트들로 구성된다. 각 클라이언트는 센서나 저전력 연산 장치 등으로 구성되어 있다. 클라이언트는 개별 로컬 데이터를 보유하고 있으며, 해당 데이터를 기반으로 독립적으로 작업을 수행한다. LEO 위성은 사전 정의된 궤도를 따라 지구를 빠른 속도로 공전하며, 일정 시간 동안 각 클라이언트와 간헐적으로 연결된다. 이때, 클라이언트는 위성과 연결되어야만 학습 결과를 전송할 수 있으며, 위성은 수신된 로컬 모델을 집계하여 글로벌 모델을 생성한다. 이후 업데이트된 모델은 다시 클라이언트에게 전송된다. 이러한 구조를 통해 LEO 위성이 갖는 통신 연결 시간의 불균형, 그리고 클라이언트 간 학습의 이질성을 반영한다.

III. 기존 알고리즘의 한계 및 제안 알고리즘

A. 기존 연합학습 알고리즘의 한계

LEO 위성 기반 IoT 환경에 기존의 FL 알고리즘을 그대로 적용하기에는 한계가 있다. 대표적인 FL 알고리즘인 FedAvg는 클라이언트별로 로컬 모델을 단순 평균하여 집계하는 방식으로, 클라이언트 간 데이터양의 편차가 커짐에 따라 성능 저하가 발생할 수 있다는 한계가 있다. FedProx는 이를 완화하기 위해 모델 간 데이터양의 이질성을 고려하였지만, 클라이언트의 실제 학습 참여 정도, 즉 로컬 업데이트 수(Epoch)를 고려하지 않는다. FedNova는 로컬 업데이트 수에 대한 고려를 통해 학습량의 차이를 정규화하지만, 모델 변화량과 같은 해당 클라이언트가 글로벌 모델의 성능에 미치는 영향에 대한 고려는 이루어지지 않았다. 또한, 위의 알고리즘 모

두 동기식 구조를 기반으로 설계되었기 때문에, 통신이 간헐적으로 연결되는 LEO 위성 환경과는 맞지 않아 학습 지연 및 병목 현상을 야기할 수 있다.

B. 제안 알고리즘

본 논문에서는 LEO 위성 기반 IoT FL 환경의 통신 불균형과 학습 정도의 이질성 등의 문제를 해결하기 위한 영향력 기반 집계 알고리즘을 제안한다. 제안하는 알고리즘은 로컬 학습에 사용된 데이터양(D_i), 글로벌 모델 업데이트 이후의 파라미터 변화량($\|\delta_i\|$), 로컬 업데이트 수(E_i)를 통합적으로 고려하여 클라이언트별 영향력을 계산한다. 영향력 수식은 다음과 같다.

$$\omega_i = \lambda_1 \cdot D_i + \lambda_2 \cdot \|\delta_i\| + \lambda_3 \cdot E_i, \quad (1)$$

이때, $\lambda_1, \lambda_2, \lambda_3$ 은 각각의 항목이 미치는 영향에 대한 비율을 나타내며, $\lambda_1 + \lambda_2 + \lambda_3 = 1$, $\lambda_i \in [0, 1]$. 이다. 이후 글로벌 모델은 가중 평균 방식으로 업데이트하며, 수식은 다음과 같다.

$$\theta^{t+1} = \theta^t + \sum_i \left(\frac{\omega_i}{\sum_j \omega_j} \cdot \Delta \omega_i \right). \quad (2)$$

V. 성능 검증 시스템 구현 및 성능 평가

본 절에서는 앞서 IV절에서 제안한 알고리즘을 검증하기 위해 FL 시스템을 하드웨어로 구현하고, 알고리즘의 학습 정확도를 비교한다. 실험에는 총 3개의 클라이언트가 참여하며, CIFAR-10 데이터를 기반으로 객체 분류(Classification) 작업을 수행한다. 이때, 클라이언트별 데이터 이질성을 위해 각 클라이언트에 학습 데이터를 불균등하게 할당하였다. 로컬 학습에 사용된 주요 파라미터는 표 1에 요약되어 있다. 알고리즘별 성능 비교를 위해, FedAvg, FedProx, FedNova 알고리즘을 비동기 방식으로 구현하고, 학습 정확도를 비교하였다. 각 클라이언트는 서버와 연결이 가능해질 때까지 개별적으로 로컬 학습을 진행하며, 연결이 가능해지면 해당 시점까지 학습된 로컬 모델 파라미터를 서버로 전송한다. 서버는 수신된 모델 파라미터를 집계하고, 알고리즘에 따라 가중 처리한 후 글로벌 모델을 생성하여 클라이언트에 전달한다. 하드웨어 구축에 사용된 서버와 클라이언트에 대한 상세 사양은 표 2에 요약되어 있다.

Parameters	Values
Training Episode	4,000
Learning Rate	0.01
Data Size	5,000, 10,000, 20,000
Batch Size	64

표 1. 학습 파라미터

명칭	CPU	RAM	Storage
Server	6 Core 4.40 GHz	32GB	512GB
Client 1	4 Core 2.40 GHz	8GB	32GB
Client 2	4 Core 1.80 GHz	8GB	32GB
Client 3	4 Core 1.80 GHz	4GB	32GB

표 2. 하드웨어 상세 사양

그림 2는 제안한 알고리즘과 대표적인 FL 알고리즘(FedAvg, FedProx, FedNova)의 라운드별 글로벌 모델 정확도 변화를 비교한 결과를 보여준다. 실험 결과, FedAvg는 62.1%, FedProx는 63.4%, FedNova는 63.6%의 정확도를 달성하였지만, 제안한 알고리즘은 65.7%의 정확도로, 기존 알고리즘 대비 높은 정확도를 보였다.

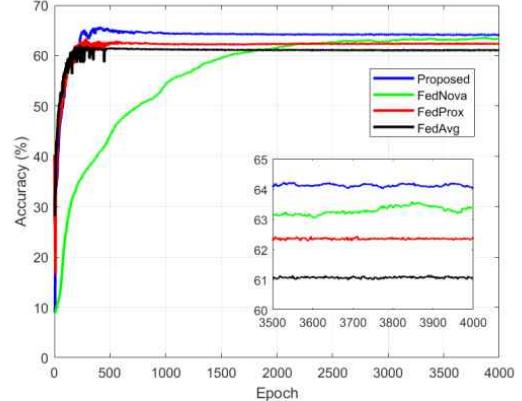


그림 2. FL 알고리즘별 글로벌 모델 정확도

IV. 결론

본 논문에서는 LEO 위성 기반 IoT 환경에서, FL의 글로벌 모델 정확도 향상을 위해 클라이언트의 로컬 데이터양, 모델 변화량, 로컬 업데이트 수를 모두 고려한 새로운 연합학습 알고리즘을 제안하였다. 실험을 통해 기존 알고리즘 대비 높은 학습 정확도를 달성할 수 있음을 확인하였다. 이를 통해 제안하는 알고리즘이 LEO 위성 기반 IoT 환경에서 적용될 수 있음을 확인하였다.

ACKNOWLEDGMENT

이 논문은 2022년도 정부(방위사업청)의 재원으로 국방기술진흥 연구소의 지원을 받아 수행된 연구임 (KRIT-CT-22-047, 우주계 층 지능통신망 특화연구실)

참 고 문 헌

- [1] A. Al-Fuqaha, M. Guizani, M. Mohammadi, M. Aledhari and M. Ayyash, "Internet of things: A survey on enabling technologies, protocols, and applications," *IEEE Communications Surveys & Tutorials*, vol. 17, pp. 2347–2376, 2015.
- [2] T. Kim and S. H. Chae, "A novel random access framework for uplink cellular IoT: Non-orthogonal preambles and multi-antennas," *IEEE Commun. Letters*, vol. 24, no. 4, pp. 748–752, Apr. 2020.
- [3] C. Lee, S. Lee, T. Kim, I. Bang, J. H. Lee, and S. H. Chae, "Multi-agent deep reinforcement learning-based multi-UAV path planning for wireless data collection and energy transfer," in Proc. of the 15th Int. Conf. on Ubiquitous and Future Networks (ICUFN), PP. 500–504, Jul. 2024.
- [4] C. Lee, I. Bang, T. Kim, H. Lee, B. C. Jung and S. H. Chae, "Multi-agent deep reinforcement learning based handover strategy for LEO satellite networks," *IEEE Commun. Lett.*, vol. 29, no. 5, pp. 1117–1121, May 2025.
- [5] B. McMahan, E. Moore, D. Ramage, S. Hampson and B. Arcas, "Communication-efficient learning of deep networks from decentralized data," in Proc. Int. Conf. on Artificial Intelligence and Statistics, pp. 1273–1282, 2017.
- [6] T. Li, A. Sahu, M. Zaheer, M. Sanjabi, A. Talwalkar and V. Smith, "Federated optimization in heterogeneous networks," *arXiv:1812.06127*. [Online]. Available: <https://arxiv.org/abs/1812.06127>
- [7] J. Wang, Q. Liu, H. Liang, G. Joshi and H. V. Poor, "A novel framework for the analysis and design of heterogeneous federated learning," *IEEE Trans. Signal Processing*, vol. 69, pp. 5234–5249, 2021.