

UAV 기반 무선 네트워크 환경에서 효율적인 자원 관리를 위한 연합학습 기법 연구

강석원[○], 홍충선*
경희대학교 컴퓨터공학과
{dudntdud, cshong}@khu.ac.kr

A Federated Learning for Efficient Resource Management over UAVs-Enabled Wireless Networks

SeokWon Kang[○], Choong Seon Hong*
Department of Computer Science and Engineering, Kyung Hee University

요 약

경기장, 놀이공원과 같은 통신 수요가 급증하는 곳에서 UAV는 통신 서비스를 제공하는 기지국뿐만 아니라 머신러닝을 통하여 사용자에게 저지연, 고신뢰의 서비스를 제공할 수 있다. 그러나 기존의 머신러닝 기술은 연결된 사용자의 데이터를 중앙서버로 전송해야하며 이러한 방식은 비효율적인 대역폭 사용을 야기할 뿐만 아니라 UAV의 에너지 사용 또한 비효율적이다. 본 논문에서는 UAV-BS 기반의 네트워크 환경에서 효율적인 연합학습을 위해 연결된 사용자에게 따른 UAV-BS의 배치와 네트워크 모델을 제시하고, 연합학습을 위한 시뮬레이션 환경을 설정한다. 또한 본 논문의 시스템 성능을 평가하기 위하여 이미지 분류 학습을 통해 기존의 중앙학습 방식과 비교한다.

1. 서 론

시스템의 전망에 따르면, 웨어러블, 스마트폰, 센서와 같은 네트워크에 연결된 스마트 기기가 2025년까지 750억대로 증가할 것으로 예상되고 있으며[1], 기기의 수가 증가함에 따라 생산되는 트래픽 또한 급증하고 있다. 이에 따라 네트워크 환경을 제공할 기지국의 수요가 증가하고 있으나, 경기장, 공연장, 놀이공원과 같이 통신 수요가 급증하는 지역에 고정된 소형 기지국을 배치하는 것은 경제적인 해결책이 될 수 없다. 이러한 상황에서 UAV(Unmanned Aerial Vehicle)는 쉽고 빠르게 배치될 수 있기 때문에, 임시 소형셀 기지국으로 활용될 수 있다. 현재 UAV는 무선네트워크 환경에서 통신을 위한 핵심 기술로 연구되고 있으며[2], UAV에 저장공간과 컴퓨팅 능력을 탑재하여 머신러닝을 수행하고, 사용자에게 저지연, 고신뢰의 서비스를 제공하는 기술이 적용되고 있다[3].

그러나 기존의 머신러닝 기술은 연결된 사용자의 데이터를 중앙서버로 전송해야하며 이러한 방식은 높은 대역폭을 필요로 하고, UAV의 에너지 효율을 고려해봤을 때 좋은 방법이 아니다. 따라서, UAV 기반의 네트워크 환경에서는 효율적인 머신러닝을 위해 분산 학습 솔루션이 필요한 상황이다. 최근, 구글은 분산 학습을 위한 연합학습 개념을 도입했다[4]. 연합학습에서 스마트 기기는 로컬 데이터를 사용하여 서버에 필요한 머신러닝 모델을 훈련하고, 생성된 로컬모델을 서버에 전송한다. 이러한 방식은 데이터를 서버로 전송해야하는 기존의 머신러닝에 비해 파라미터만 전송하면 되기 때문에 네트워크 효율을 개선할 수 있고, 학습에 필요한 컴퓨팅 자원을 줄일 수 있기 때문에 UAV의 에너지 효율을 개선할 수 있다.

본 논문에서는 UAV 기반의 네트워크 환경에서 연합 학습을 위한 프레임워크를 제안하고, MNIST 데이터셋을 사용하여 연결된 사용자와 UAV간 이미지 분류 연합학습을 진행한다. 또한 제안한

시스템의 성능평가를 위해 기존의 머신러닝 방식과 비교한다.

2. 시스템 모델

시스템 모델은 그림 1과 같으며, 지상 기지국, UAV 기반 기지국 그리고 User Equipment(UE)로 이루어져 있다. UE는 $U = \{1, 2, 3 \dots u\}$ 로 나타내며, UAV-BS는 $B = \{1, 2, 3, \dots b\}$ 로 나타낸다. 각 UE u 는 UAV-BS b 에 연결되어 있으며 동시에 여러 대의 UAV-BS에 연결되지 않는다. 각 UE u 는 학습된 로컬 데이터를 UAV-BS b 에 전송하며, UAV-BS b 는 로컬 모델을 통해 글로벌 모델을 만든 후에 각 UE u 에게 전송한다.

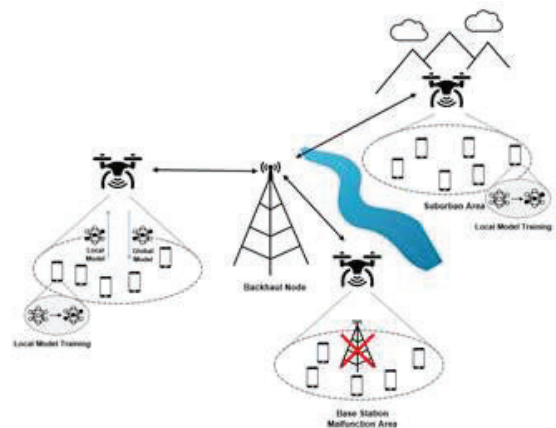


그림 1. 시스템 모델

본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 Grand ICT 연구센터지원사업 (IITP-2020-2015-0-00742) 및 한국연구재단의 지원 (No. 2020R1A4A1018607)을 받아 수행된 연구임.

*Dr. CS Hong is the corresponding author.

2.1. UAV-BS Network Model

로컬모델을 UAV-BS로 전송하기 위한 네트워크 모델은 다음과 같다. 본 논문에서 UE u 의 랜덤한 배치를 위하여 Poisson point process가 사용되었으며, 또한 UAV-BS b 에 각각 같은 수의 UE를 연결하기 위하여 K-means 클러스터링이 활용되었다. UAV-BS b 는 클러스터링된 지역의 중심인 c_b 에 위치하며, UE u 와 관련된 변수는 그림 2와 같이 나타낼 수 있다. d 의 경우 해당 UE u 와 UAV-BS 사이의 거리를 나타내며, R 은 UAV-BS b 의 커버리지를 나타낸다. UE u 와 클러스터링의 중심인 U 사이 거리인 r 은 다음과 같이 나타낼 수 있다.

$$r_{ij} = \| U - u_{ij} \| = \sqrt{(x - x_{ij})^2 + (y - y_{ij})^2}$$

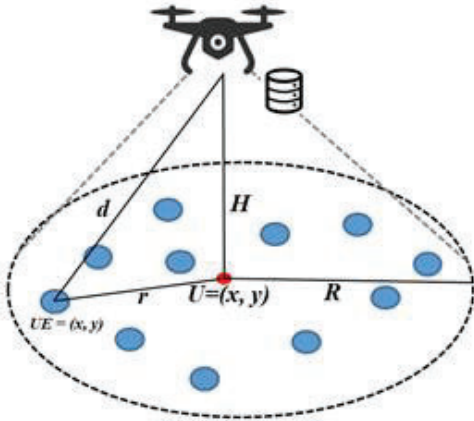


그림 2. UAV-BS와 UE간의 변수

Parameter	Description
f	Transmitter Frequency
P_t	Base Station Transmitting Power
G_t	Antenna Gains for the Base Station
G_r	Antenna Gains for the User
L	Total System Losses
B	Bandwidth
N	Noise Power

표 1. 네트워크모델 변수 설명표

또한 [5]에 따라, UE의 Line of sight (LoS) 및 Non-Line of Sight (NLoS)의 확률을 구하기 위해 본 논문은 Air-To-Ground (ATG) 채널 모델을 따르며 다음과 같이 나타낸다.

$$P_{LoS}(H, r_i) = \frac{1}{1 + a \exp(-b(\frac{180}{\pi} \tan^{-1}(\frac{H}{r_{ij}}) - a))}$$

$$P_{NLoS}(H, r_i) = 1 - P_{LoS}(H, r_i)$$

$$PL(dB) = 20 \log_{10}(\frac{4\pi df}{c}) + P_{LoS}(H, r_i) + P_{NLoS}(H, r_i),$$

위의 식에서 c 는 빛의 속도를 의미하며, 신호 대비 잡음비 (SNR)와 신호세기를 다음과 같이 나타 낼 수 있다.

$$P_r(d) = P_t + G_t - PL - G_r - L$$

$$SNR = \frac{\text{signal power}}{\text{noise power}} = \frac{P_r(d)}{N}$$

Shannon-Hartley 공식에 따라, UAV-BS b 와 UE u 사이의 데이터 전송속도는 다음과 같이 나타낼 수 있다.

$$c_{ij}^{UAV} = B_{UAV} \log_2(1 + SNR_{ij}^{UAV})$$

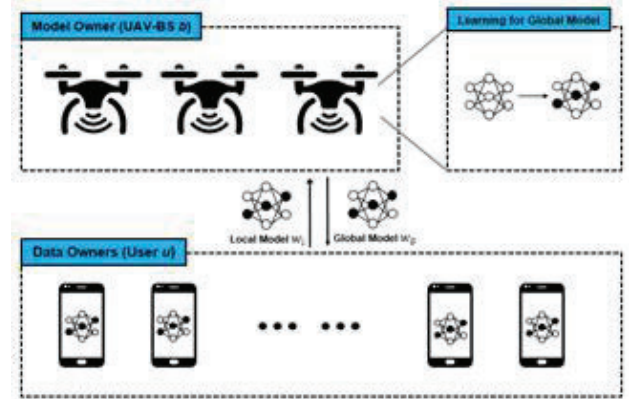


그림 3. UAV-BS 기반의 Federated Learning 과정

2.2. Federated Learning for UAV-BS Network

연합학습 시스템에서는 데이터 소유자 UE u 와 모델 소유자의 UAV-BS b 가 존재한다. 각 데이터 소유자 i 는 데이터셋 D_i 를 사용하여 로컬 모델 w_i 를 교육하고, 로컬 모델 파라미터를 UAV-BS로 전송한다. 그 후에, UAV-BS는 연결되어 있는 UE u 의 로컬 모델인 w 을 수집한 후에 글로벌 모델 w_G 를 생성한다. 본 논문에서의 연합학습 구조는 그림 3과 같다.

일반적으로 연합학습 과정은 3단계로 나타낼 수 있다 [6]. 첫 번째는 작업 초기화 과정으로, UAV-BS b 는 글로벌 모델의 하이퍼 파라미터와 학습과정을 마친 후에 글로벌 모델 W_G^0 을 각 연결된 UE u 에게 전송한다. 두 번째 단계는 로컬모델 학습과 업데이트이며, 글로벌 모델 W_G^t 에 따라 각 UE u 는 로컬모델과 로컬 디바이스를 사용하여 로컬 모델 파라미터 W_i^t 를 업데이트한다. 여기서 t 는 반복 횟수를 뜻한다. t 에 따라서 사용자 i 의 목표는 손실함수 $L(W_G^t)$ 을 최소화하는 파라미터 W_i^t 를 찾는 것이며, 다음과 같이 공식화 할 수 있다.

$$w_i^t = \arg \min L(w_i^t)$$

마지막 단계는 글로벌 모델 통합 및 업데이트 과정이다. UAV-BS는 생성한 글로벌 모델 파라미터 W_G^{t+1} 을 연결된 UE u 에게 다시 전송한다. UAV-BS의 손실함수는 다음과 같으며, 최소화하는 것이 목표이다.

$$L(w_i^t) = \frac{1}{N} \sum_{i=1}^N L(w_i^t)$$

목표한 정확도에 도달하거나 손실함수의 값이 수렴할 때 까지 연합학습이 반복된다.

3. 성능평가

본 논문에서 시뮬레이션을 수행하기 위한 환경 변수는

아래의 표2와 같다. 또한 학습결과의 비교를 위하여 UAV-BS에서 학습되는 상황, 연결된 기지국에서만 학습되는 상황과 비교하였다. 시뮬레이션은 그림 4와 같이 100대의 UE u를 Poison point process를 통해 배치시키고, K-means 클러스터링을 통하여 배치하였다. 또한 UAV-BS의 컴퓨팅 성능을 2.0Ghz로, 각 UE u의 컴퓨팅 성능을 1.5Ghz로 설정하였다. 학습을 위하여 *non-iid federated version of MNIST*의 데이터셋을 활용하였으며, 학습의 결과는 그림 5, 6과 같다.

Parameter	Value
f	1.5GHz
P_t	10dBW
G_t	8dB
G_r	0dB
L	8dB
B	10MHz
N	100dBW
Dataset	Federated version on MNIST
Server Learning rate	1.0
Client Learning rate	0.02
Batch size	20
Epochs	5

표 2. 시뮬레이션을 위한 환경변수

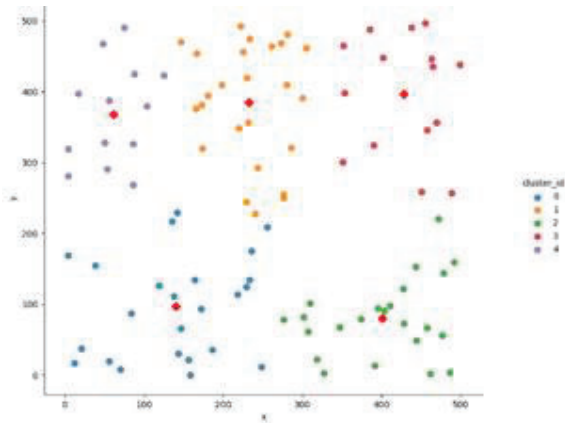


그림 4. UAV-BS와 UE의 위치

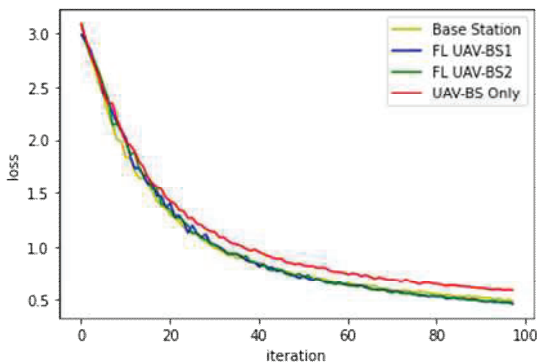


그림 5. Federated learning Loss 결과 값

그림 5와 6은 기존의 중앙집중식 학습 결과와 연합학습간의 결과를 비교하고 있으며, 기존의 방법보다 좋은 결과를 보인다.

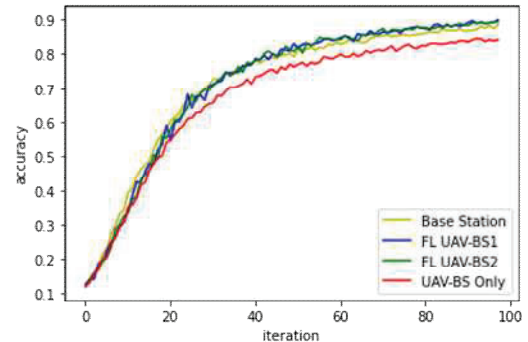


그림 6. Federated learning Accuracy 결과 값

4. 결론

본 논문에서는 UAV 기반의 네트워크 환경에서 연합학습을 위한 프레임워크를 제안했다. UAV-BS 및 연결된 UE와 함께 연합학습을 실시하여 기존의 중앙집중식 학습보다 우수한 성능을 보였다. UAV-BS의 경우 네트워크의 자원과 UAV-BS의 에너지 효율을 고려해야한다. 본 논문의 내용을 바탕으로 자원 할당 및 에너지 효율을 고려하여 연구를 진행 할 예정이다.

5. 참고문헌

- [1] *The Future of IoT Miniguide: The Burgeoning IoT Market Contin-ues* Accessed: Nov. 25, 2019 [Online]. Available: <https://www.cisco.com/c/en/us/solutions/internet-of-things/future-of-iot.html>
- [2] X. Wang, Y. Han, C. Wang, Q. Zhao, X. Chen and M. Chen, "In-Edge AI: Intelligentizing Mobile Edge Computing, Caching and Communication by Federated Learning," in *IEEE Network*, vol. 33, no. 5, pp. 156-165, Sept.-Oct. 2019
- for Ultra-reliable and Enhanced Mobile Broadband IoT Applications in Fog Network," *IEEE Transactions on Communications*, Vol.67, Issue 1, pp.489-502, January 2019
- [3] Ki Tae Kim, Yu Min Park, Choong Seon Hong, "Machine Learning Based Edge-Assisted UAV Computation Offloading for Data Analyzing," *The International Conference on Information Networking (ICOIN 2020)*, January 7-10, 2020, Barcelona, Spain
- [4] K. Bonawitz, H. Eichner, W. Grieskamp, D. Huba, A. Ingerman, V. Ivanov, C. Kiddon, J. Konečný, S. Măzocchi, H. B. McMahan, T. V. Overveldt, D. Petrou, D. Ramage, and J. Roselander, "Towards federated learning at scale: System design," 2019, *arXiv:1902.01046*
- [5] Chuan-Chi Lai, Chun-Ting Chen and Li-Chun Wang, "On-Demand Density-Aware UAV Base Station 3D Placement for Arbitrarily Distributed Users With Guaranteed Data Rates," *IEEE Wireless Communications Letter*, Vol.8, Issue.3, pp. 913-916, Feb 2019
- [6] Wu, Qiong & He, Kaiwen & Chen, Xu. (2020). "Personalized Federated Learning for Intelligent IoT Applications: A Cloud-Edge based Framework"