

UAV 기반 비지상 네트워크에서의 개인화 연합학습 연구 동향

방정환, 박재성, 조신영, 이수경

연세대학교

{bangjh0730, parksry98, sycho3015, sklee}@yonsei.ac.kr

A Survey on Personalized Federated Learning for UAV-Based Non-Terrestrial Networks

Jeonghwan Bang, Jaeseong Park, Shinyoung Cho, Sukyoung Lee

Yonsei Univ.

요약

무인항공기(Unmanned Aerial Vehicle, UAV)를 활용한 비지상 네트워크는 지상 인프라의 커버리지 및 서비스의 연속성 문제를 개선했지만, 여전히 UAV들의 이동성과 자원 제약으로 발생하는 데이터 및 환경 이질성 문제가 남아있다. 이러한 문제점들을 완화하는 방법으로 전역 협업을 유지하면서 UAV별 특성을 반영하는 개인화 연합학습(Personalized Federated Learning, PFL)이 주목받고 있다. 본 논문은 UAV 기반 비지상 네트워크에서의 PFL 연구 동향에 대해 살펴본다.

I. 서 론

비지상 네트워크는 위성, UAV, 고고도 플랫폼 등을 활용하여 지상 네트워크의 범위를 넓히고, 재난 상황이나 인프라가 구축되지 않은 지역에서도 통신 및 컴퓨팅 서비스를 제공한다. 특히 UAV는 높은 이동성과 유연한 배치가 가능해 센싱, 엣지 컴퓨팅, 이동형 기지국 등의 역할을 수행할 수 있어 비지상 네트워크의 핵심 구성 요소로 활용된다. 그러나 UAV들이 수집하는 데이터 분포가 지리적 분산, 임무 다양성, 이동성 등으로 인해 균질하지 않고, UAV들의 통신 및 연산 자원 또한 제한되기 때문에 연합학습(Federated Learning, FL)에서 성능 저하와 수렴 불안정성 문제 가 나타난다. 특히 모든 UAV들에게 같은 전역 모델을 적용하는 방식은 지역적 특성과 임무 요구사항을 반영하지 못해 이러한 문제점들이 더욱 두드러진다 [1].

연합학습의 이점을 유지하면서도 클라이언트별 혹은 군집별 특성을 반영하여 모델을 학습시키는 방법으로 개인화 연합학습(Personalized Federated Learning, PFL)이 있다. UAV를 활용한 비지상 네트워크에서의 PFL은 참여자들의 모델을 개인화할 뿐만 아니라, 경로 계획 및 자원 관리와 같은 정책을 개인화하기도 한다. 본 논문에서는 UAV 기반 비지상 네트워크에서의 PFL 연구 동향을 모델의 개인화와 정책의 개인화 두 관점에서 정리하고, 각 접근 방식이 통계적 이질성과 시스템 제약을 어떻게 완화하는지를 논의한다.

II. 본론

2.1 모델의 개인화

UAV를 활용한 비지상 네트워크에서의 PFL은 공간적, 통계적 이질성을 고려하기 위해 모델의 개인화를 한다. 모델 개인화 연구에서 참가자들은 연합학습에 참여하면서 자신의 임무 혹은 환경에 맞는 모델을 유지하고 한다 [2-4].

[2]는 공간적으로 분산된 UAV 센싱 및 엣지 컴퓨팅 작업에서 발생하는 non-IID 데이터 문제를 해결하기 위해 DCPFL을 제안했다. 이 연구는

DBSCAN으로 클라이언트들의 모델들을 클러스터링하고, 클러스터 내부에서 모델을 교환한다. 클라이언트 개인의 모델과 교환된 모델 사이에서 deep mutual learning으로 개인화를 이루며, 안정적인 학습을 위해 손실 함수의 weighted moving average를 기반으로 교환 시점을 결정한다. 이 연구는 개인화를 통해 모델의 성능을 향상시켰으나, UAV들의 배치에 따라 성능이 감소할 수 있다는 문제가 남아있다.

[3]은 지리적으로 분산된 장치 클러스터 환경에서 계층화된 UAV 군집과 worker-leader-core 구조의 HN-PFL 프레임워크를 제안한다. 여기서 worker UAV는 meta-gradient update를 수행하고, leader는 군집 내에서 집계를 수행하며 주기적인 동기화를 통해 클러스터 간 전이 가능한 전역 모델을 생성하면서 클러스터별 개인화를 이룬다. 이를 통해 데이터 오퍼레이팅과 처리를 최적화하며, model drift 및 배터리 제약 속에서 군집 경로와 학습 시간을 계획한다. 하지만 군집별 UAV 수와 종류를 고려하지 않아, 학습 도중 UAV를 다른 군집으로 이동하는 등 swarm dimensioning으로 모델의 성능과 자원 제약 문제를 개선할 수 있을 것으로 보인다.

[4]는 모든 학습 단계를 동일하게 처리할 때 발생하는 자원 비효율 문제를 해결하기 위해 critical learning period (CLP)을 활용한 PFL을 제안한다. 지상 장치들이 로컬 모델을 학습하면 UAV가 집계자 역할을 수행한다. 이때 각 장치별로 로컬 모델과 전역 모델의 발산 정도 등으로 CLP를 측정해 장치 참여도, UAV 방문 빈도, 집계 주기 등을 UAV 측에서 조정한다. 특히 variational Bayesian inference로 전역 모델을 각 장치의 개인화 모델을 위한 사전 분포로 활용해 개별 장치의 데이터 특성을 반영하면서도 데이터 부족으로 인해 발생하는 과적합 문제를 해결한다. 이 연구는 학습의 참여자마다 주요 학습 시점이 다르다는 점에 주목해 모델의 성능을 유지하면서도 연산 및 통신 자원 소모를 크게 감소시켰다.

모델의 개인화 연구들은 UAV 기반 비지상 네트워크의 공간적 지역성과 계층적 연결 구조를 활용하여 통계적 이질성 문제를 해결한다. 개인화를 통해 유사한 환경에서 작업하는 참여자들의 성능을 향상하며, 제한된 연산·통신 자원을 최적화할 수 있다.

표 1. 비지상 네트워크에서의 UAV 기반 개인화 연합학습 연구

구분	제안 기법	개인화 방법
모델 개인화	DCPFL [2]	공간·계층으로 묶어 모델 부분 공유
	HN-PFL [3]	계층·군집별 집계 (worker-leader-core)
	CLP-aware FL [4]	Variational Bayesian 기법, CLP 기반 참여·집계
정책 개인화	PF-DRL [5]	글로벌 정책과 로컬 정책 결합
	PFRL [6]	글로벌 모델을 개인화 정책 가이드로 사용
	FKD-PDQN [7]	Attention 기반 선택적 지식 종류

2.2 정책의 개인화

단순히 모델의 개인화 차원이 아닌 UAV 네트워크의 의사결정 및 제어에 PFL을 적용하는 연구들도 있다. 이러한 연구들은 각 UAV가 자신의 환경과 임무 목표에 맞게 궤적이나 자원 할당과 같은 정책을 개인화한다 [5-7].

[5]는 데이터 부족 문제 혹은 느리고 불안정한 학습 문제를 해결하기 위해 PF-DRL을 제안했다. 이 연구는 동적인 MEC 환경에서의 다중 UAV 경로 최적화를 위해 UAV마다 개인화된 행동 정책을 학습한다. UAV들은 학습 후 서버에 actor와 critic evaluation network를 업로드하여 연합학습을 수행한다. 이때 로컬 정책을 하나의 글로벌 모델로 대체하는 대신, 각 UAV는 로컬 모델과 글로벌 모델의 convex combination을 통해 개인화된 모델을 얻어 행동 결정을 내릴 수 있도록 지원한다. 이 연구는 개인화를 통해 성능 향상 외에도 모델의 수렴을 가속해 학습 효율을 향상할 수 있음을 보여준다.

[6]은 동적인 다중 UAV 네트워크 환경에서 장기적인 네트워크 처리량을 최대화하기 위한 PFRL 프레임워크를 제안한다. PFRL에서 각 UAV는 두 가지 DDQN 모델을 학습한다. 하나는 모델을 leading UAV로 업로드하여 전역 집계를 수행하는 로컬 모델이며, 다른 하나는 업로드 없이 로컬에서만 학습되는 개인화된 모델이다. 이때 leading UAV는 모델 집계에 이어 ensemble distillation을 수행하여 글로벌 모델을 구축해 이질적인 UAV 환경 아래 일반화 성능을 높이고 수렴을 가속한다. 이 연구는 개인화를 통해 UAV의 이동성으로 인해 변화하는 환경에 맞춰 모델을 학습할 수 있도록 하고 모델의 성능 외에도 네트워크 처리량을 향상시켰다.

[7]은 각 자율항공기 (autonomous aerial vehicles, AAV)가 사용자 요구와 AAV별 성능에 따라 각자에게 최적화된 연산 오프로딩 및 제어 정책을 학습한다. 각 AAV는 행동 정책을 parameterized deep Q-network (PDQN)을 이용해 학습한 다음 어텐션 메커니즘을 이용해 이웃한 AAV들로부터 지식을 선택적으로 종류·집계하여 개인화를 이룬다. 이는 모델의 전체 파라미터를 교환하지 않아 통신 오버헤드 부담을 줄여준다. 이 연구는 성능 향상과 더불어 사용자의 작업 지연 시간과 AAV의 에너지 소비를 기준 연구 대비 크게 줄였다.

정책의 개인화 연구들은 강화학습을 사용해 UAV(AAV) 별 환경 변화와 임무 차이에 적응적인 의사결정을 가능하게 한다. 전역 모델은 로컬 정책을 직접 대체하기보다 개인화된 정책 학습을 유도하는 기준으로 주로 활용된다. 이를 통해 이질적인 네트워크 환경과 자원 제약 하에서도 학습 안정성과 성능을 유지한다.

III. 결론

본 논문에서는 UAV 기반 비지상 네트워크 환경에서의 개인화 연합학습 연구를 모델의 개인화와 정책의 개인화로 구분하여 살펴보았다. 모델의 개인화는 UAV 간 공간적·계층적 특성을 활용해 모델의 성능을 향상시킨다. 반면, 정책의 개인화는 강화학습 기법을 통해 UAV 별 환경과 임무에 적응적인 의사결정을 가능하게 한다. 기존 연구들은 PFL이 전역 모델의 일반화 한계를 보완할 수 있음을 보여주었으나, 고 이동성 환경에서의 개인화 범위 설정과 통신 비용과 성능 사이 균형 문제는 여전히 해결해야 한다. 향후 연구에서는 네트워크 계층 간 역할 분화와 구조적 연계를 고려한 다계층 개인화 연합학습 설계가 중요한 방향이 될 것으로 보인다.

ACKNOWLEDGMENT

본 논문은 2026년도 정부(과학기술정보통신부)의 재원으로 한국연구재단 중견연구(No. RS-2025-00573388)의 지원을 받아 수행된 연구임

참 고 문 헌

- [1] Y. Cheriguene, W. Jaafar, and H. Yanikomeroglu, “Federated learning in UAV-assisted MEC systems: A comprehensive survey,” IEEE Open J. Commun. Soc., vol. 6, pp. 7645 - 7676, Sep. 2025.
- [2] W.-C. Chien, C.-H. Lin, T. Zhu, C. Dai, S. Garg, and A. Mukherjee, “Density-clustering aggregation for personalized federated learning with AI-enabled aerial and edge computing in UAVs,” IEEE Internet Things J., vol. 12, no. 9, pp. 11220 - 11232, May 2025.
- [3] S. Wang, S. Hosseinalipour, M. Gorlatova, C. G. Brinton, and M. Chiang, “UAV-assisted online machine learning over multi-tiered networks: A hierarchical nested personalized federated learning approach,” IEEE Trans. Netw. Serv. Manage., vol. 20, no. 2, pp. 1847 - 1865, Jun. 2023.
- [4] Y. Li, Y. Liu, Y. Huang, and Z. Zhang, “Seizing critical learning period in UAV-assisted hierarchical personalized federated learning,” IEEE Trans. Mobile Comput., early access, 2025.
- [5] Z. Song, C. Ma, M. Ding, H. H. Yang, Y. Qian, and X. Zhou, “Personalized federated deep reinforcement learning-based trajectory optimization for multi-UAV assisted edge computing,” in Proc. 2023 IEEE/CIC Int. Conf. Commun. China (ICCC), Dalian, China, pp. 1 - 6, Aug. 2023.
- [6] X. Xu, G. Feng, S. Qin, Y. Liu, and Y. Sun, “Joint UAV deployment and resource allocation: A personalized federated deep reinforcement learning approach,” IEEE Trans. Veh. Technol., vol. 73, no. 3, pp. 4005 - 4018, Mar. 2024.
- [7] J. Chai, Z. Wang, C. Ma, G. Gao, and L. Shi, “Personalized federated reinforcement learning for multi-UAV assisted edge computing,” IEEE Wireless Commun. Lett., vol. 14, no. 7, pp. 2074 - 2078, Jul. 2025.