

전술 환경의 이질성을 고려한 DDS 기반 실시간 다중 글로벌 모델 연합학습 설계

정승민¹, 이재민², 김동성*

국립금오공과대학교, 전자공학부^{1,2,*}

{20211048¹, ljmpaul², dskim^{*}}@kumoh.ac.kr

Design of a DDS-Based Real-Time Federated Learning with Multiple Global Models Considering Heterogeneity in Tactical Environments

Seung-Min Jung¹, Jae-Min Lee², and Dong-Seong Kim*

Kumoh National Institute of Technology School of Electronic Eng.^{1,2,*}

요약

본 논문은 전술 환경에서 분산 운용되는 자율 무인체계의 실시간 협력 학습을 위해 DDS(Data Distribution Service) 기반 실시간 FL(Federated Learning) 프레임워크를 제안한다. 제안하는 프레임워크는 기존 FL이 라운드 기반 교환과 단일 글로벌 모델 운용으로 전술 환경에서의 임무 변화와 이질성을 반영한 학습 흐름을 유연하게 분리·조정이 어려운 한계를 개선하고자 한다. 이를 위해 DDS의 Topic 기반 publish/subscribe(Pub/Sub) 구조와 QoS 정책을 학습 절차에 결합하여 임무·센서 단위의 다중 글로벌 모델을 운영하고, 노드가 상태 변화에 따라 필요한 Topic을 선택적으로 구독하도록 한다. 또한 메시지 목적에 따라 QoS 정책을 차등 적용함으로써, 통신 품질 변동 상황에서도 정보 교환의 실시간성과 학습 절차의 안정성을 확보한다.

I. 서론

최근 국방 분야에서 드론(UAV, Unmanned Aerial Vehicle), 무인 지상 차량(UGV, Unmanned Ground Vehicle) 등 자율 무인체계가 함께 운용되는 복합 작전 환경이 확대되고 있다. 분산형 전술 플랫폼은 다양한 센서와 임무를 바탕으로 실시간으로 변하는 전장 상황을 분석하기 위해 데이터를 지속적으로 공유해야 한다. 그러나 전술 환경에서는 임무·센서·통신 조건의 이질성으로 인해 운용 조건이 균일하지 않으며, 네트워크 상태도 변동이 크다[1]. 따라서 임무별 정보 흐름을 구분하고, 요구 수준에 따라 전송 정책을 달리하며, 통신 품질 변동에도 견딜 수 있는 분산 학습·통신 구조가 요구된다. 전술 환경에서는 보안·통신 제약으로 데이터를 중앙에 전송하기 어려워, 로컬 데이터는 그대로 유지한 채 학습 결과만 공유하는 FL(Federated Learning)이 대안으로 고려된다. 기존 FL은 라운드 기반 업데이트로 실시간성이 부족해 전술 환경에서는 부적합하다. 또한 모든 클라이언트의 업데이트를 단일 글로벌 모델로 통합하는 구조는 임무·센서별 데이터 특성 차이를 반영하기 어려워 성능이 저하될 수 있다. 결국 전술 환경에서의 FL은 임무·센서 단위로 데이터와 학습을 분리하고, 필요시 즉시 교환이 가능한 제어 메커니즘이 필요하다. 본 연구는 DDS(Data Distribution Service)의 Topic 기반 publish/subscribe(Pub/Sub) 구조와 QoS 정책을 FL에 통합한 실시간 학습 프레임워크를 제안한다. 제안하는 프레임워크는 임무·센서 단위로 분리된 다중 글로벌 모델을 운용해 이질성을 완화하고, 메시지 목적에 따라 QoS 정책을 차등 적용해 통신 변동 환경에서도 실시간성을 지원한다.

II. 관련 연구 및 문제점 분석

계층형 FL은 클라이언트 업데이트를 클라우드로 직접 전송하지 않고 중간 계층에서 부분 집계를 수행해 대역폭 부담과 집계 지연을 줄인다[2]. 그러나 전술 환경처럼 네트워크 상태 변동이 잦은 환경에서는 계층 구조를 안정적으로 유지하기 힘들다. 또한 계층형 FL은 통신 부담을 분산하는 데 초

점을 두어 지역 민감 정보와 신뢰성 요구 업데이트를 차등 처리하기 어렵다. 따라서 메시지 목적별 요구를 통신 계층에서 반영할 수 있는 미들웨어 기반 접근이 요구된다. DDS는 Topic 기반 Pub/Sub과 QoS 정책으로, 통신 품질 변동이 큰 환경에서도 메시지 타입별 요구를 반영할 수 있다[3]. 이를 통해 DDS를 FL의 학습 통신 미들웨어로 적용하여 분산 환경에서의 운용 가능성을 검증하는 DDS 기반 FL 연구가 제안되었다. [4]는 통신 병목과 지연을 완화하기 위해, DDS를 학습 통신 계층에 적용한 분산형 FL 구조를 제안한다. 특히 DDS의 Pub/Sub 메커니즘을 활용해 모델 파라미터를 Topic 단위로 교환하여 클라이언트와 서버 간 병목을 완화했다. 그러나 전술 환경과 같은 이질성이 강한 환경에서는 단일 글로벌 모델이 임무별 성능 저하를 초래할 수 있다. 전술 환경에서는 각 임무나 센서에 맞춘 다중 글로벌 모델을 활용하는 것이 더 효과적이며, 이를 통해 임무별 성능 최적화가 가능하다[5]. DDS는 미들웨어로서 임무·센서 이질성이 존재하는 환경에서 유연한 통신 구성을 지원하지만, 기존 DDS 기반 FL 연구는 주로 파라미터 교환 효율화에 초점을 두어 임무·센서 단위의 모델 분리와 메시지 목적별 QoS 제어는 충분히 반영하지 못한다. 또한 임무·센서 차이로 동일 학습 목표로 통합할 경우 특정 임무의 성능 저하가 발생하며, 학습 과정에서는 요구사항이 상이한 메시지가 전달된다. 이때 통신 구조를 파라미터 교환 중심으로만 설계하면, 정보나 탐지 결과처럼 지연에 민감한 정보와 모델 업데이트처럼 신뢰성이 중요한 정보를 동일 규칙으로 처리해, 통신 품질 변동 상황에서 임무 대응성과 학습 안정성을 만족시키기 어렵다.

III. 제안하는 DDS 기반 실시간 FL 시스템

본 연구는 전술 환경의 이질성 문제를 해결하고, 실시간 협력을 지원하는 DDS 기반 FL 프레임워크를 제안한다. 제안하는 프레임워크는 DDS의 Topic 기반 Pub/Sub 구조와 QoS 정책을 FL에 결합하여, 학습 정보 교환의 실시간성을 지원하고 통신을 제어한다. 구체적으로 각 글로벌 모델을 임무·센서별 Topic으로 분리하고, 클라이언트는 필요한 Topic만 구독한다. 이 구

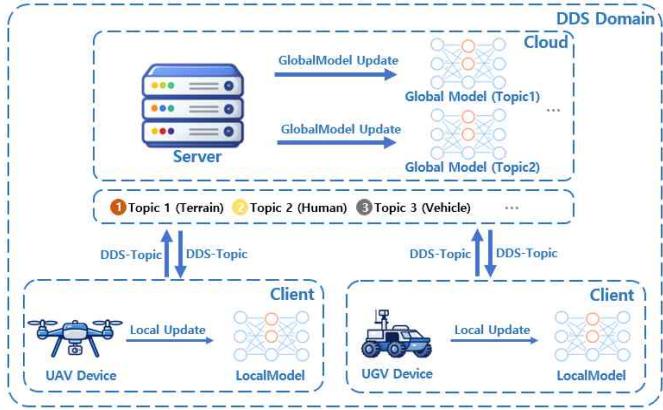


그림 1 제안하는 DDS 기반 실시간 FL 아키텍처

조는 관련성이 낮은 업데이트 교환을 최소화하고, 단일 글로벌 모델로의 평균 수렴에 따른 임무별 성능 저하를 완화하여 임무·센서 단위의 성능 최적화를 가능하게 한다. 또한 메시지 목적에 따라 QoS 정책을 차등 적용함으로써, 통신 품질 변동이 큰 상황에서도 업데이트 전달과 학습 절차 제어가 요구 수준을 만족하도록 설계하여, 실시간 정보 교환을 지원한다. 그림 1과 같이 각 클라이언트는 임무 수행 중 수집한 데이터로 로컬 모델을 학습하고 그 결과를 해당 임무·센서 Topic에 발행한다. 이때 로컬 업데이트는 참여 Topic에 의해 결정되며, 한 시점에 하나의 Topic을 선택하여 참여하는 경우 로컬 업데이트 역시 1개가 생성되어 해당 Topic으로만 발행된다. 서버는 DDS Domain에서 각 Topic의 로컬 업데이트를 구독하여 수신하고, Topic 별로 업데이트를 분리 집계함으로써 글로벌 모델을 갱신한다. Topic별 집계는 임무·센서 조건의 업데이트만 통합하므로, 서로 다른 분포의 업데이트가 단일 모델에 혼합되는 평균 수렴 문제를 완화한다. 갱신된 글로벌 모델은 다시 DDS를 통해 해당 Topic 구독자에게 전달되어, 클라이언트가 임무·센서에 적합한 모델을 지속적으로 반영할 수 있다.

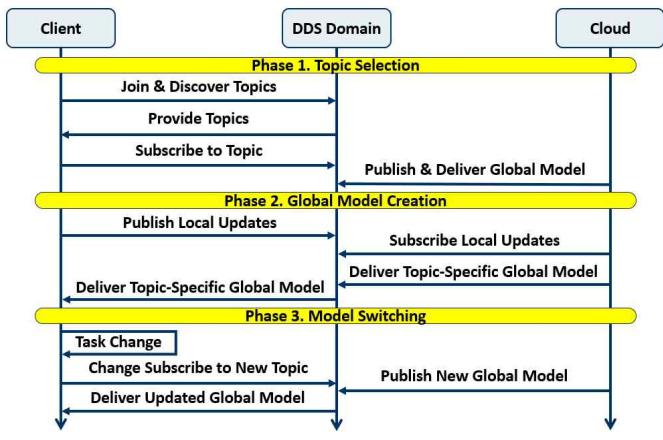


그림 2 DDS 기반 실시간 FL의 통신 흐름

그림 2는 임무·센서 Topic 기반 실시간 FL 통신 절차를 나타낸다. 각 클라이언트는 DDS에 참여한 뒤 임무·센서 Topic을 선택하여 글로벌 모델을 구독하고, 로컬 학습 결과를 로컬 업데이트 메시지로 발행한다. 이후 클라우드는 Topic별로 로컬 업데이트를 집계한 뒤, 갱신된 Topic별 글로벌 모델을 발행하고 DDS를 통해 전달한다. Model Switching에서는 임무 변경 발생 시 클라이언트가 새로운 임무·센서에 해당하는 Topic으로 구독을 전환하고, 전환된 Topic의 최신 글로벌 모델을 수신한 뒤 이를 기준으로 로컬 학습과 로컬 업데이트 발행을 지속한다. 또한 다중 임무 수행 시에는 다수의 Topic에 대해 로컬 업데이트를 병렬적으로 생성할 수 있다. 이 경우에도 서버는 수신된 업데이트를 집계해 글로벌 모델을 갱신하는 과정을 반복한다. 또한 메시지 목적에 따라 유형을 구분하고, 자연·신뢰성 등 요구에 맞춰다. 또한 메시지 목적에 따라 유형을 구분하고, 자연·신뢰성 등 요구에 맞춰

표 1 메시지 목적별 DDS QoS 정책 매핑

Message Type	Purpose	QoS 설정
Alert/ Detection Result	이상 탐지 결과 공유 및 긴급 경보	Reliable, Low Latency, High Priority
Model Update	모델 파라미터 교환 및 배포	Reliable, History(Keep last N), Durability(Transient Local)
Node Status/ Telemetry	노드·링크·센서 상태 공유	Best Effort, Volatile, Lifespan(Short)
Coordination/ Control	Topic 선택 및 학습 절차 제어	Reliable, History(Keep last 1), Liveliness

QoS를 차등 적용한다. 이상 탐지 결과 및 긴급 경보는 Low Latency와 High Priority를 적용하여 전송 지연을 줄이도록 설계한다. 모델 업데이트는 성능과 수렴 안정성에 영향을 미쳐 Reliable, History, Durability를 적용해 최근 N개의 업데이트를 보존하고, 일시적인 지연이 발생하더라도 업데이트 누락을 완화한다. 노드·링크·센서 상태 정보는 플랫폼의 가용성과 통신 환경을 빠르게 파악하기 위한 정보이므로 Best Effort, Volatile, Lifespan을 적용하여 핵심 상태만 주기적으로 요약해 공유하고, 오래된 정보가 자동 만료도록 구성하여 불필요한 트래픽을 억제한다. 또한 학습 절차 제어 신호에는 Reliable, History, Liveliness를 적용하여 참여 Topic 결정과 단계 전환 동기화를 지원한다. 다음 표 1은 제안 시스템에서 사용되는 QoS 설정을 나타낸다.

IV. 결론

본 논문은 전술 환경에서 자율 무인체계의 실시간 협력 학습을 위한 DDS 기반 FL 프레임워크를 제안하였다. Topic 기반 Pub/Sub으로 임무·센서 단위 다중 글로벌 모델을 운용해 데이터 분포 불일치(Non-IID) 문제를 완화하고, QoS 차등 적용으로 라운드 교환 지연을 줄여 실시간성을 지원한다. 향후 연구로는 시뮬레이션을 통해 적용 가능성을 검증할 예정이다.

ACKNOWLEDGMENT

본 논문은 정부(과학기술정보통신부)의 재원으로 정보통신기획평가원의 지원을 받아 수행된 지역지능화혁신인지강성사업(IITP-2025-RS-2020-II201612, 33%)과 2025년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업(2018R1A6A1A03024003, 33%)과 과학기술정보통신부 및 정보통신기획평가원의 대학ICT연구센터사업의 연구결과로 수행되었음(IITP-2025-RS-2024-00438430, 34%)

참 고 문 헌

- [1] D. H. Stolfi, M. R. Brust, G. Danoy, and P. Bouvry, “UAV–UGV–UMV Multi–Swarms for Cooperative Surveillance,” *Frontiers in Robotics and AI*, vol. 8, pp. 1–11, Feb. 2021.
- [2] S. S. Shahid, T. Salman, M. Baza, and M. A. Teixeira, “Hierarchical Federated Learning: Approaches, Applications, and Open Challenge,” *IEEE Access*, vol. 13, pp. 190333–190353, Nov. 2025.
- [3] M.-H. Jang, H.-J. Kim, Y.-K. Go, N.-J. Choi, J.-H. Lee, J.-H. Yu, J.-M. Lee, T.-S. Jun, and D.-S. Kim, “Design and Implementation of Network Simulator for High-Level Naval Ship System,” *IEEE Access*, vol. 13, pp. 90612 – 90625, Mar. 2025.
- [4] H. Liu, “Federated learning implementation based on DDS data distribution service,” *Proceedings of the 6th International Conference on Computing and Data Science*, pp. 83 - 90, Jul. 2024.
- [5] G. Long, M. Xie, T. Shen, T. Zhou, X. Wang, amd J. Jiang, “Multi-center federated learning: clients clustering for better personalization,” *World Wide Web*, vol. 26, pp. 481–500, Jun. 2022.