

차량 네트워크 환경에서 지연 및 프라이버시 보호를 위한 연합학습 기반 엣지 컴퓨팅 오프로딩 기법

양영준, 박세리, 김성현, 무함마드아샤르타리크, 김진홍*, 임길택*, 김동균
경북대학교, *한국전자통신연구원

youngj719@knu.ac.kr, psr0527@knu.ac.kr, sunghyunkim@knu.ac.kr, tariqashar@knu.ac.kr,
*jinhong@etri.re.kr, *ktl@etri.re.kr, dongkyun@knu.ac.kr

A Federated Learning-based Edge Computing Offloading for Latency and Privacy in Vehicular Network

Youngjoon Yang, Seri Park, Sunghyun Kim, Muhammad Ashar Tariq,
Jinhong Kim*, Kiltaek Lim*, Dongkyun Kim
Kyungpook National University, *Electronics and Telecommunication Reserach Institute

요 약

자율주행 차량의 발전과 함께 차량 네트워크 환경에서는 실시간 데이터 처리와 통신 효율성, 개인정보 보호의 중요성이 커지고 있다. 기존 오프로딩 기법은 대용량 센서 데이터를 그대로 전송함에 따라 통신 지연 및 프라이버시 침해와 같은 문제가 발생한다. 본 논문에서는 이러한 문제를 해결하기 위해 연합학습(Federated Learning, FL) 기반의 엣지 컴퓨팅 오프로딩 기법을 제안한다. 제안 기법은 차량 내 On Board Unit(OBU)가 탑재된 센서로부터 수집한 데이터를 활용하여 로컬 모델을 학습한 뒤, 학습된 모델 파라미터만 오프로딩함으로써 전체 통신 부하를 줄이고 지연 및 데이터 전송 부담을 최소화할 수 있다. 실험을 통해 기존 기법과 FL 기반 기법의 비교 분석을 진행하였으며, 본 기법의 확장 가능성과 실환경 적용 가능성을 확인하였다.

I. 서 론

차량 네트워크 기술은 Internet of Vehicles(IoV)의 발전과 함께 차량 대 차량(V2V), 인프라(V2I), 네트워크(V2N)의 통신을 기반으로 자율주행 및 지능형 교통 시스템을 지원한다. 차량에는 고해상도 카메라, 레이더, LiDAR 등 다양한 센서가 탑재되어 있으며, 이를 통해 생성되는 데이터의 양과 복잡도가 급격히 증가하고 있다 [1]. 이러한 센서 데이터는 실시간으로 처리되어야 하는데, 차량 내 OBU의 컴퓨팅 자원은 처리 성능 및 메모리 용량 측면에서 한계가 있다. 특히 객체 인식, 주행 판단 등 고부하 AI 연산을 수행하기에는 현저히 부족하다. 이를 해결하기 위해 Road Side Unit(RSU)에 내장된 엣지 서버로 센서 데이터를 오프로딩하여 처리한다.

하지만 차량에서 생성되는 센서 데이터는 대부분 대용량이며, 이를 오프로딩하는 과정에서 전송 지연이 발생한다 [2]. 기존 오프로딩 기법은 센서 데이터를 그대로 전송하기 때문에 대역폭 부담이 크고, 통신 환경에 따른 전송 실패 및 재전송으로 인한 추가 지연이 발생한다. 또한 센서 데이터에는 차량 위치, 주행 경로, 운전 패턴 등 민감한 정보가 포함되어 있어 외부로 전송되는 과정에서 개인정보 유출 위험도 존재한다 [3].

이러한 문제를 해결하기 위해, 최근 차량 네트워크 분야에서 FL이 주목받고 있다. FL은 수집된 데이터를 로컬에서 처리하여 AI 모델을 학습한 후, 전체 센서 데이터가 아닌 모델 파라미터만 서버로 전송하여 데이터 전송량을 줄일 수 있다 [4]. 이로 인해 통신 과정에서의 데이터 전송 지연이 감소하며, 패킷 손실을 또한 감소한다. 이러한 구조는 통신 효율성과 프라이버시 보호 측면에서 차량 네트워크 환경에 적합한 특성을 가진다.

본 논문에서는 차량 네트워크 환경에서 발생하는 데이터 전송 지연과 프라이버시 문제를 해결하기 위해 FL 기반 엣지 컴퓨팅 오프로딩 기법을 제안한다. FL을 활용하여 로컬 연산 기반 오프로딩 구조를 통해 전송 지연을 줄이고, 데이터 전송 부담을 최소화하는 것을 목표로 한다.

이어서 II장에서는 제안하는 FL 기반 엣지 컴퓨팅 오프로딩 기법의 구조와 주요 구성 요소를 설명한다. III장에서는 기존 오프로딩 기법과 제안 기법 간의 성능을 비교 분석하여 latency와 throughput 측면에서 효과를

검증한다. 마지막으로 IV장에서는 연구 결과를 요약하고 향후 연구 방향을 제시한다.

II. 본론

차량은 객체 인식이나 이상 주행 감지와 같은 자율주행 기반 애플리케이션을 대상으로 로컬 학습을 수행한다. 예를 들어, 차량은 카메라, LiDAR, 주행 센서 등을 통해 획득한 로그 데이터를 기반으로 급정거, 급차선 변경, 이상 조향 패턴 등의 이벤트 탐지 모델을 학습시킨다. 해당 로그 데이터는 비식별 처리되어 외부 전송 없이 로컬에서 처리되며, 학습된 모델 파라미터는 RSU의 엣지 서버를 통해 간접적으로 통합 및 배포된다.




그림 1 연합학습 기반 오프로딩 구조도

[그림 1]은 FL 기반의 차량-엣지-클라우드 오프로딩 구조를 단계별로 나타낸다. 가장 하위의 Device Level에서는 OBU가 로컬 데이터를 학습하고, 해당 파라미터를 엣지로 오프로딩한다.

중간의 Edge Computing Level에서는 두 가지 방식의 기능이 수행된다. RSU는 관할 바운더리 내 차량들로부터 학습 파라미터를 수집하여 엣지 서버의 FL 모델을 학습하고, 이를 다시 하위 차량에게 배포한다. 또한, 동일하게 수집된 파라미터를 Cloud Level로 오프로딩하여 클라우드 모델의 글로벌 학습을 수행하고, 학습된 모델을 엣지 서버 및 하위 차량으로 오프로딩한다.

Edge Computing Level에서의 학습 모델은 낮은 지연과 빠른 응답성을

제공할 수 있으나, 해당 RSU의 바운더리 내 차량 수나 분포가 비대칭적일 경우, 학습 결과의 일반화 수준이 떨어진다. 따라서 안정적인 성능 확보를 위해 Cloud Level를 활용하며, 전체 네트워크의 전역적 특성을 반영한 글로벌 파라미터를 배포한다. 이를 통해 반응성과 학습 품질 간의 균형을 유지하는 것이 가능하다.

III. 실험 환경 및 성능 분석

본 연구에서는 FL 기반 오프로딩 기법과 기존 오프로딩 기법 간의 성능을 비교하기 위해 차량-RSU 기반 시뮬레이션을 설계하여 수행하였다. 시뮬레이션은 차량 네트워크 환경을 모델링하여, 각 차량의 로컬 학습과 RSU(Edge) 단의 데이터와 파라미터 집계 및 재배포 과정을 구현하였다.

항목	설정 값
CPU / RAM	AMD Ryzen Threadripper PRO 7965WX 24-Cores / 32GB
Framework	Pytorch 2.0.1, Flower(FLWR) 1.18.0
AI Model	FedAvg
Vehicle Count	10~100 (10대씩 증가)
Data Size	1MB~100MB (10MB씩 증가)
Training Epochs	1 (per client per round)
Bandwidth	20MB/s

실험 환경은 위의 표와 같이 구성되었으며, Latency와 Throughput을 주 성능 지표로 선정하였다. 차량 수와 데이터 크기를 실험 변수로 설정하여 각 조건 별 5회 반복 측정한 뒤 평균 및 표준편차 기반으로 비교 분석하였다. 모델은 PyTorch 2.0.1 기반 MLP(Multi-Layer Perceptron)를 OBU에서 1 epoch 학습한 뒤 데이터 및 파라미터를 전송하였고, FL 처리는 Flower 1.18.0 프레임워크의 FedAvg 알고리즘을 적용하였다. 네트워크 대역폭은 실험 전 구간에서 20 MB/s로 고정하여 두 오프로딩 기법의 성능을 동일한 통신 조건에서 비교할 수 있도록 설계하였다.

Latency 실험은 통신, RSU 집계, 데이터 및 파라미터 업로드 구간을 측정하였다. 기존 기법은 차량당 5 MB 원본 센서 데이터를, FL 기반 기법은 약 1.4 KB의 모델 파라미터를 전송해 지연을 비교하였다. Throughput 실험은 동일 실험 조건에서 1 epoch 후 업로드 구간의 처리량을 평가하였다.




그림 2 차량 수에 따른 평균 Latency

[그림 2]는 차량 수에 따른 평균 Latency의 변화를 비교한 결과이다. 기존 기법에서는 차량 수 증가에 따라 전송 지연이 증가하여 네트워크 혼잡에 취약한 모습을 보인다. 반면, 제안 기법은 차량 수가 많아져도 안정적인 저지연을 유지하였다. 따라서 동일 조건에서 FL기반 기법은 대규모 차량군에서도 일관된 저지연 성능을 유지할 수 있음을 확인하였다.




그림 3 데이터 크기에 따른 throughput

[그림 3]은 데이터 크기에 따른 throughput을 비교한 결과이다. 기존 기법은 1 MB 구간에서 Handshake 지연으로 약 8 MB/s로 시작하지만, 10 MB 이상부터는 17 - 20 MB/s로 급상승하여 대역폭 한계에 근접하게 도달한다. 이는 대용량 원본 데이터를 전송하여 가용 대역폭을 거의 전량 소모하므로, 네트워크 혼잡이 발생할 가능성이 높다. 반면 FL 기반 기법은 전송 대상이 일정한 크기의 경량 파라미터이므로, 데이터 크기와 상관없이 일정한 값을 유지한다. FL 기반 기법은 처리량 자체는 낮으나, 네트워크 사용률을 0.2 % 수준으로 억제한다. 대용량 데이터 및 다중 차량 환경에서도 안정적이고 예측 가능한 통신 품질을 제공할 수 있다.

IV. 결론

본 논문에서는 차량에 탑재된 고해상도 센서 데이터의 대용량 전송으로 인한 통신 지연과 개인정보 유출 문제를 해결하고자 FL 기반 엣지 컴퓨팅 오프로딩 기법을 제안하였다. 차량 내 OBU에서 로컬 학습을 수행한 후 모델 파라미터만을 RSU로 전송함으로써, 데이터 전송량을 크게 줄이고 프라이버시를 보호하는 구조를 갖는다. 이를 검증하기 위해 기존 원본 데이터 오프로딩 기법과 FL 기반 오프로딩 기법의 비교 분석을 진행하였다. 실험 결과, 기존 방식은 차량 수·데이터 크기 증가 시 지연이 급증하고 대역폭을 최대한 점유하여 네트워크 혼잡이 심화되는 반면, 제안 기법은 저지연과 낮은 네트워크 사용률을 유지하여 우수한 확장성과 통신 효율성을 동시에 확보하였다. 이러한 결과는 FL 구조가 데이터량 축소와 프라이버시 보호를 효과적으로 달성할 수 있음을 보여준다. 향후 연구에서는 차량 이동성 예측, RSU 자원 스케줄링, 계층적 FL 프레임워크를 통합하여 실시간성과 학습 품질을 함께 최적화하는 방안을 모색할 예정이다.

ACKNOWLEDGMENT

이 논문은 정부(과학기술정보통신부)의 재원으로 과학기술사업화진흥원의 지원을 받아 수행된 연구임('학연협력플랫폼구축 시범사업' RS-2023-00304695, RS-2023-00304776).

참 고 문 헌

- [1] D. Paluszczyszyn, V. R. Stamenkovic and B. Lane, "Toward Development of Ecosystem for Connected Autonomous Vehicles: Challenges of Modeling and Testing Sensors," in IEEE Sensors Letters, vol. 8, no. 3, pp. 1-2, March 2024, Art no. 5500802
- [2] L. Wang, X. Zhu, N. Lit, Y. Liv, S. Ma and L. Zhai, "Dynamic Vehicle Aware Task Offloading Based on Reinforcement Learning in a Vehicular Edge Computing Network," 2022 18th International Conference on Mobility, Sensing and Networking (MSN), Guangzhou, China, 2022, pp. 263-270
- [3] S. Wang, J. Li, G. Wu, H. Chen and S. Sun, "Joint Optimization of Task Offloading and Resource Allocation Based on Differential Privacy in Vehicular Edge Computing," in IEEE Transactions on Computational Social Systems, vol. 9, no. 1, pp. 109-119, Feb. 2022, doi: 10.1109/TCSS.2021.3074949
- [4] V. M. R. Tummala, A. Hazra, A. Kalita and M. Gurusamy, "Efficient Task Offloading Through Federated Learning in UAV-Assisted Edge Networks," 2024 IEEE 99th Vehicular Technology Conference (VTC2024-Spring), Singapore, Singapore, 2024, pp. 1-5