

엣지 연합학습을 위한 성능-공정성 균형 기반 동적 클라이언트 선택 기법

한정은¹, 김소연², 이일구³

¹성신여자대학교 융합보안공학과 학부생

²성신여자대학교 미래융합기술공학과 박사과정

³성신여자대학교 융합보안공학과, 미래융합기술공학과 교수
{20240992, 220237014, iglee}@sungshin.ac.kr

Performance-Fairness Balanced Dynamic Client Selection Technique for Edge Federated Learning

Jeong-Eun Han¹, So-Yeon Kim², Il-Gu Lee^{1,2}

¹Dept. of Convergence Security Engineering, Sungshin Women's University

²Dept. of Future Convergence Technology Engineering, Sungshin Women's University

요약

IoT 기기의 확산으로 생성되는 데이터가 급증하면서, 빠른 처리와 개인정보 보호를 위한 엣지 컴퓨팅 기반 연합학습 방식이 효율적인 대안으로 주목받고 있다. 엣지 컴퓨팅 환경에서 연합학습을 수행하는 종래 연구에서는 모든 노드를 학습에 참여시키거나 기여도 기반으로 일부 노드를 선택하는 방식을 제안하였으나, 비독립적 데이터로 인한 성능 저하와 학습 참여 기회의 불균형으로 인한 공정성 저하 문제가 발생한다. 엣지 연합학습 환경에서 성능과 공정성의 트레이드 오프 문제를 해결하기 위해서 본 논문은 성능과 공정성의 중요도에 따라 학습에 참여하는 클라이언트를 동적으로 선택하는 방식을 제안한다. 실험 결과에 따르면, 한 요소가 중요한 환경에서도 성능-공정성 균형을 맞추지 않을 시 균형 점수가 감소하였으며 두 요소의 균형 조정이 필요함을 증명하였다.

1. 서론

최근 클라우드 기반의 IoT(Internet of Things) 서비스와 엣지 컴퓨팅(edge computing) 장치가 확산되면서 수집되는 데이터가 급증하고 있다. 이로 인해 데이터를 빠르게 처리하고 개인 정보 유출을 방지할 수 있는 엣지 컴퓨팅 기술의 중요성이 커지고 있다[1]. 이에 따라 엣지 컴퓨팅 환경의 AI 서비스 수요가 증가하며, 데이터를 중앙 서버로 전송하지 않고 학습 모델의 가중치만 공유하는 연합학습(federated learning) 방식이 효율적인 대안으로 주목받았다. 엣지 컴퓨팅 환경에서 연합학습을 수행하는 종래 연구[2,3]에서는 모든 엣지 컴퓨팅 장치를 학습에 참여시키거나, 각 노드의 기여도 점수를 기반으로 일부 노드를 선택하는 방식을 제안했다. 그러나 모든 노드 참여로 공정성을 확보한 방식은 데이터 분포의 비독립성으로 인해서 저품질 데이터나 이상치가 학습에 포함되어 성능이 저하될 수 있다. 반면, 기여도 점수에 따라 일부 노드를 선택하여 성능을 높인 방식은 특정 노드에 학습이 편중되어 노드 간 참여 기회의 공정성이 낮아지는 문제가 있다. 따라서 본 논문에서는 엣지 컴퓨팅 장치를 활용한 연합학습 환경에서 성능과 공정성의 트레이드 오프 문제를 해결하기 위해서 성능과 공정성의 중요도에 따라 노드를 동적으로 선택하는 기법을 제안한다.

본 논문의 주요 기여점은 다음과 같다.

- 기기의 환경 특성과 사용자의 요구를 반영하여, 성능과 공정성의 중요도를 기반으로 클라이언트를 동적으로 선택하는 방식을 제안하였다.
- 성능-공정성 간의 균형을 정량적으로 측정할 수 있는 평가 프레임워크를 제안하였다.
- 실험 결과, 성능 중심 환경($\beta=2$)에서는 성능 중요도(α)가 40%일 때 최고 통합 점수를 얻고 감소, 공정성 중심 환경($\beta=0.5$)은 α 가 커질수록 높은 통합 점수를 얻다가 70% 이상일 때 감소하였다.

2. 제안 방식

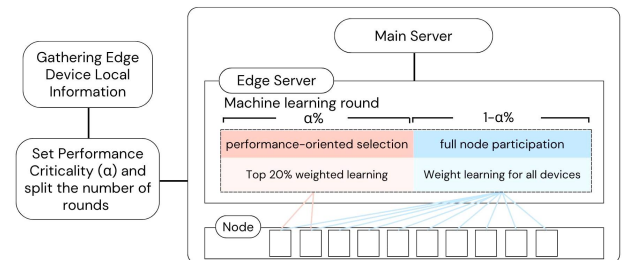


그림 1. 제안 방식의 동작 과정

그림 1은 제안 방식의 전체 동작 과정을 나타낸다. 각 엣지 컴퓨팅 장치는 로컬 데이터를 수집하고 이를 기반으로 중간 모델 가중치를 생성한다. 이후 모델 업데이트가

필요한 장치는 현재의 환경 조건 또는 사용자의 요구를 반영하여 성능 중요도 α ($0 \leq \alpha \leq 1$)를 설정하고, 이에 따라 전체 학습 라운드를 성능 중심의 학습과 공정성 중심의 학습으로 분할한다. 성능 중심 학습 단계에서는 전체 엣지 컴퓨팅 장치 중 상위 20%의 장치를 선별하여 모델을 학습하고, 공정성 중심 학습 단계에서는 모든 장치가 균등한 비율로 참여하여 모델을 업데이트한다.

3. 성능 평가 및 분석

본 논문에서는 우수 노드 선택 방식, 전 노드 참여 방식 그리고 제안 방식 간의 정확도와 공정성을 비교하고, 이를 기반으로 성능-공정성 균형 점수를 평가하였다. CNN 모델을 기반으로 연합학습 환경을 시뮬레이션하였으며, MNIST 데이터셋을 활용하여 50개의 클라이언트가 100라운드 동안 학습에 참여한다. 클라이언트 간 데이터 분포는 독립 동일 분포(IID)와 비독립 분포(non-IID)를 각각 50% 비율로 구성된다. 공정성을 평가하기 위해서 수식 (1)을 활용하였다. 여기서 x_i 는 클라이언트 참여 횟수이고, n 은 클라이언트 수를 의미한다.

$$Fairness = (\sum_{i=1}^n x_i)^2 / (n \cdot \sum_{i=1}^n x_i^2) \quad (1)$$




그림2. 정확도와 공정성 비교 그래프

그림 2는 성능 중요도(α)에 따른 각 방식의 정확도와 공정성 결과를 나타낸 그래프이다. 성능 중심 노드 선택 방식은 α 와 관계없이 90~95%의 높은 정확도와 20% 수준의 낮은 공정성을 유지했으며, 전 노드 참여 방식의 정확도는 23~28%로 낮지만, 공정성은 항상 100%로 유지되는 결과를 보였다. 반면, 제안 방식은 α 가 증가할수록 정확도는 향상되고, 공정성은 감소하는 결과를 보였다.

수식 (2)는 성능과 공정성 간의 균형을 반영한 균형 점수(Performance-Fairness Balance Score, PFBS)로, 두 요소를 가중 조화 평균 방식으로 계산한다. β 는 성능과 공정성 간의 중요도 비율을 조절하는 가중치 값으로, β 가 클수록 성능이 더 크게 반영되고, 작을수록 공정성이 더 크게 반영된다. 본 실험에서는 β 를 0.5, 1, 2로 설정하여 각각 공정성, 성능-공정성 균형, 성능 중심의 세 가지 평가 기준을 고려하였다.

$$PFBS_{\beta} = (1 + \beta^2) \cdot \frac{Fairness \cdot Accuracy}{\beta^2 \cdot Fairness + Accuracy} \quad (2)$$

그림 3은 β 값에 따른 제안 모델의 성능-공정성 균형 점수를 나타낸다. 실험 결과, 공정성 중심 환경($\beta=0.5$)에서는 성능 중요도(α)가 0%일 때보다 10~80%에 더 높은

점수를 얻었다. 균형 환경($\beta=1$)에선 α 가 40%, 60%일 때 최고점이었고 이후 점차 감소하는 경향을 보였다. 성능 중심 환경($\beta=2$)에서는 α 가 70%까지 점진적으로 증가하다가 이후 감소하였다. 이러한 결과는 모델 성능 중심 환경과 공정한 노드 선택 중심 환경 모두 두 요소의 균형이 유지되어야 높은 점수를 얻을 수 있으며, 제안 방식은 이러한 균형을 효과적으로 달성할 수 있음을 보여준다.

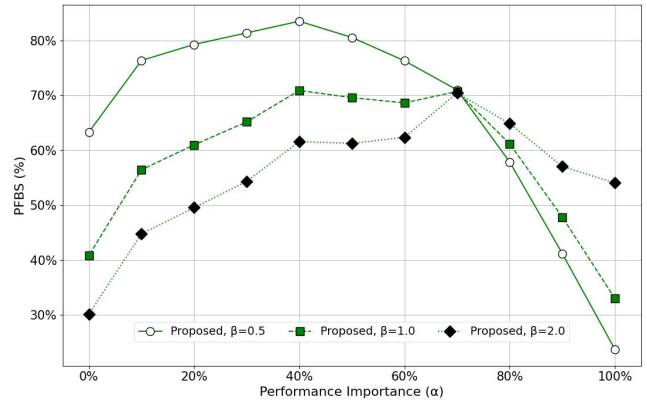


그림3. 공정성-성능 균형 점수 그래프

4. 결론

본 논문은 엣지 컴퓨팅 연합학습에서 공정성과 성능의 균형 학습을 위해 동적 클라이언트 선택 기법을 제안하였다. 실험 결과, 성능과 공정성 중심 환경에서 α 가 각각 0%, 100%일 때보다 10~80%, 40~90%일 때 더 우수함을 보여 다양한 환경에서도 균형이 필요함을 증명하였다. 향후 연구에서는 다양한 데이터셋과 실제 엣지 컴퓨팅 환경에서 제안 기법의 성능을 입증할 계획이다.

ACKNOWLEDGMENT

본 논문은 2024년도 산업통상자원부 및 한국산업기술진흥원의 산업혁신인재성장지원사업(RS-2024-00415520)과 과학기술정보통신부 및 정보통신기획평가원의 ICT혁신인재 4.0 사업의 연구결과로 수행되었음 (No. IITP-2022-RS-2022-00156310)

참고문헌

- [1] So-Eun Jeon, Sun-Jin Lee, Il-Gu Lee, "Hybrid in-network computing and distributed learning for large-scale data processing," Elsevier Computer Networks, Vol. 226, pp.1-2, 2023
- [2] Rei Ito, Mineto Tsuksda, Hiroki Matrutani "An On-Device Federated Learning Approach for Cooperative Model Update Between Edge Devices", IEEE Access, Vol. 9, pp.92986-92990, 2021
- [3] Shuai Yan, Peiying Zhang, Siyu Huang, Jian Wang, Hao Sun, Yi Zhang, Amr Tolba, "Node Selection Algorithm for Federated Learning Based on Deep Reinforcement Learning for Edge Computing in IoT", MDPI Electronics 2023, 12(11), 2478, pp.4-9, 2023