

태양에너지 수집형 엣지 AIoT의 효율적인 연합학습을 위한 시스템수준 에너지 적응적 동작 기법

이창한¹, 양재훈², 이민욱², 허석문², 박준수², 노동건³

¹숭실대학교 지능시스템학과 석사과정

²숭실대학교 AI융합학부 학부생, ³숭실대학교 AI융합학부 교수

dlckdgks99@naver.com, lljhms@naver.com, lmw3164@naver.com,

tjrans303@soongsil.ac.kr, freefree9758@naver.com, dnoh@ssu.ac.kr

System-level Energy-aware Operations for the Efficient FL of the Solar-powered Edge AIoT

Changhan Lee¹, Jaehoon Yang², Minwook Lee², Seokmun Heo²,

Junsoo Park², Dong Kun Noh³

¹Dept. of Intelligent System, Soongsil University

^{2,3} School of AI Convergence, Soongsil University

요 약

지속가능한 AIoT의 필요성과 에너지 수집 기술의 발달, 그리고 온디바이스 학습이 가능한 IoT 기기들의 등장으로 인해, 최근 에너지 수집형 AIoT(AI-enabled IoT) 기술이 주목받고 있다.[1] 본 연구에서는 에너지 수집형 엣지 AIoT를 대상으로 기기의 안정적인 동작을 보장하며 동시에 연합학습 성능 수준을 높일 수 있는 시스템 수준의 에너지 적응형 동작을 제안한다. 기본적으로 각 기기에서는 학습성능과 에너지 소비량이 비례관계에 있으므로, 기기의 안정적 동작 확보를 위해 학습 성능의 감소가 필요할 때도 있다. 제안 기법에서는 에너지와 학습 성능 사이의 이러한 상충관계를 최소화하기 위해, 태양에너지 수집 모델을 기반으로 주어진 에너지 예산 내에서 각 기기의 학습 데이터양과 연합학습을 위한 파라미터 교환량을 최적화한다. 이러한 각 기기들의 정전시간 최소화(안정성 증가)는 결과적으로 전체 AIoT의 연합학습 정확도 향상으로 이어질 수 있는데, 실험 결과 기존 기법에 비해 정전시간의 감소와 연합학습의 정확도가 각각 최대 53%, 35% 향상됨을 확인할 수 있었다.

1. 서론

최근에는 주변 에너지를 이용한 에너지 수집형 (energy harvesting, EH) 기기에 관한 연구가 활발히 수행되고 있다. EH 기술은 AIoT 장치에 친환경적인 에너지를 공급할 수 있을뿐더러, 근래에는 EH 기술의 비약적 발전으로, 태양광과 같은 밀도가 높은 에너지원의 경우 AIoT 장치들을 구동시킬 수 있을 만한 높은 에너지 공급이 일정 수준 가능하게 되었다.[2]

한편, 엣지 AIoT는 사용자 IoT 네트워크 내에서 학습(ML, machine learning)이 이루어지는 환경을 일컫는다. 엣지 AIoT는 정보 생성 소스와 학습 수행 장치의 물리적 근접성이 보장되므로, 기존 클라우드 AI가 가진 프라이버시 침해 등의 문제점들을 해결할 수 있다는 장점이 있다.[3] 현재까지 엣지 AIoT와 관련하여 가장 활발히 연구되고 있는 ML 모델은 엣지서버(엣지노드라고도 불림)가 존재하는 형태이다. 이 환경에서 엣지서버는 AIoT 장치들에

서 수집한 데이터를 전송받아 전체 또는 일부의 ML을 수행하거나, 또는 각 장치들에서 학습된 모델을 수합하여 보다 정교한 모델을 만드는 파라미터 서버의 역할을 한다. 각 IoT 기기에서도 일부 학습을 수행하기 때문에 분산형 ML(distributed ML, DML)에 해당하지만, 엣지서버가 학습을 주도적으로 이끌기 때문에 이를 중앙집중형 DML(centralized DML, C-DML)이라 부른다. 엣지서버의 존재는 DML의 구현을 용이하게 하지만, AIoT의 확장성(scalability)이나 내결함성(fault-tolerance)에 대한 약점을 보인다. 따라서 이를 보완할 수 있는 환경, 즉 엣지서버가 없는 완전 분산형 AIoT 환경의 필요성이 높아지고 있는데, 이러한 환경을 비중앙집중형 DML (decentralized DML, D-DML)이라 정의한다.[4]


본 연구에서는 이러한 D-DML 기반 연합학습을 에너지 수집형 엣지 AIoT에서 효율적으로 동작시키기 위한 기기 내 시스템 수준의 에너지 적응적 동작을 제안한다.

2. 제안기법

2.1 태양에너지 수집 예측 및 할당 모델

본 연구에서는 에너지가 수집되는 주기를 작은 시간슬롯들로 나누고, 슬롯 별로 수집되는 에너지양을 강화학습을 통해 예측하였다. 또한, 이전 슬롯의 실제 수집량과 예측 수집량이 많이 달랐을 경우 이번 슬롯의 시작 시에 예측값을 보정할 수 있는 ①동적 에너지 수집량 예측 기법을 제안한다. 아울러, 이렇게 예측된 에너지 충전량과 재충전가능 배터리의 용량 등을 고려하여, 버려지는 수집 에너지의 양 최소화과 할당되는 에너지 값 분산 최소화를 동시에 만족하는 ②슬롯 별 에너지 할당 기법도 설계하였다.

2.2 할당 에너지 적응적 연합학습 동작 조정 기법



(그림 1) 제안하는 시스템수준 에너지 적응형 동작

연합학습에서는 모델 전체와 데이터가 기기에 있으므로, EH-AIoT 기기들은, 안정적 동작을 위해, 스스로 각자의 에너지에 맞게 학습 방법과 수준을 조절할 수 있다. 앞 절에서, 이번 시간슬롯에 사용가능한 에너지양을 결정해주었다면, 본 장에서는 이렇게 주어진 에너지양 이내에서 최대한 에너지를 활용하여 학습을 수행함으로써, 안정성과 정확도를 확보하도록 한다. 이를 위해 우선 에너지 소비 모델을 만들어야 하는데, 연합학습을 수행하는 각 노드에서 에너지 사용은 크게 두 가지로 구분할 수 있다. 그 기기에서 학습을 수행하는 데 필요한 계산 에너지와 다른 노드의 학습결과를 받고 나의 학습결과를 전송해주는 통신 에너지가 그것이다. 본 연구에서는 이 두 가지 에너지 사용량을 제어하기 위해, ①계산 에너지는 그 기기에서 학습하는데 사용되는 데이터양으로 조절하고, ②통신 에너지는 다른 노드들과 교환할 파라미터 크기로 조절할 것이다. 이때, 에너지

사용량과 학습의 정확도는 기본적으로 상충관계에 있기 때문에, 에너지 적응적 동작으로 인해 학습의 정확도가 얼마간 감소할 수도 있다. 하지만, 이러한 에너지 적응적 동작은 노드가 정전 없이 안정적으로 동작할 수 있게 한다는 면에서 중요한 것이며, 이러한 안정성이 전체 연합학습의 효과를 높일 수 있다.

그림 1은 제안하는 에너지 적응형 연합학습 수준 조정 기법을 보여준다. 우선, ①학습할 데이터양 조절로 계산 에너지를 제어하기 위하여 데이터 샘플링 비율 조절 기법을 제안한다. 본 기법에서는 적응형 Reservoir 샘플링 기법[5]을 기반으로 동작하는데, 이 기법은 수집한 데이터로부터 편향 없이 대표 샘플링 데이터를 선택할 수 있으면서도 복잡하지 않아 자원 소비를 최소화할 수 있다는 장점이 있다. 아울러, ②모델을 훈련하는 동안 다른 노드들과 데이터를 주고받는데 필요한 통신 에너지를 제어하기 위해 파라미터 희소화(sparsification) 기법을 사용한다. 이 기법은 노드 간 주기적으로 서로 주고받는 모델 파라미터(기울기, 가중치, 액티베이션 등)의 크기를 줄이기 위해, 중복된 정보는 제거하고 이번 학습에서 업데이트된 중요하다고 판단되는 값만을 전송하게 한다. 마지막으로 ③계산 에너지와 통신 에너지를 함께 제어하기 위해 양자화(quantization) 기법을 사용한다. 이 기법은 데이터와 파라미터 표현의 정밀도를 조절함으로써 학습 자체에 소모되는 에너지와 파라미터 교환에 필요한 에너지를 제어할 수 있다.

3. 실험 결과

성능 평가는 라즈베리파이에서 오디오 데이터 기반 장면 분류(scene classification) 학습을 수행할 때의 사용 에너지양 및 학습의 정확도를 기반으로 하였다. 수집 태양 에너지 양은 기존 실험 데이터 [6]를 사용하였고, 실험 기간은 30일, 노드의 개수는 30개로 하였다. 이때 발생하는 노드의 총 정전 시간(분)과 완전 분산형 연합학습의 정확도를 측정하여, 높은 정확도를 위해 항상 최대의 학습 동작을 수행한 기법(기법1)과 높은 안정성을 위해 항상 고정된 낮은 크기의 에너지만을 학습에 사용한 기법(기법2)과 비교하였다.

그 결과 제안 기법은 기법1 대비 13%의 정확도 증가를 보였는데, 이는 약 54%의 확인한 정전시간 감소에서 기인한 것임을 확인할 수 있었다. 반면, 기법 2와 비교하여서는, 정전시간은 약 11%의 증가하였으나, 학습에 보다 많은 에너지를 소모하였으므로 정확도에서는 35%의 향상을 확인할 수 있었다.

4. 결론

Edge AIoT 환경의 각 기기에서 에너지와 학습의 성능(정확도)은 상충관계에 있다. 즉, 안정성(정전시간 최소화)을 위하여 어느 정도 학습의 성능을 희생해야 하므로, 학습 성능의 감소를 최소화하면서 안정성을 확보할 수 있는 에너지 적응적 학습이 필요하다. 본 연구에서 제안하는 이러한 에너지 적응적 동작은 각 기기의 안정성을 높이면서 최종적으로 연합학습의 전체 정확도를 높이는 결과로 이어질 수 있었다.

사사 (Acknowledgement)

"본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업의 지원을 받아 수행되었음 (2024-0-00071)"

참고문헌

- [1] A. Matin et al., "AIoT for sustainable manufacturing: Overview, challenges, and opportunities," in Elsevier IoT, p. 100901, 2023.
- [2] Y. C. Lee et al., "High-Performance Multiband Ambient RF Energy Harvesting Front-End System for Sustainable IoT Applications-A Review," in IEEE Access, 2023.
- [3] A. Bourechak et al., "At the Confluence of Artificial Intelligence and Edge Computing in IoT-Based Applications: A Review and New Perspectives," in MDPI Sensors, vol. 23, no 3, p. 1639, 2023.
- [4] E. T. M. Beltrán et al., "Decentralized federated learning: Fundamentals, state of the art, frameworks, trends, and challenges," in IEEE Communications Surveys & Tutorials, 2023.
- [5] Z. Wen et al., "Approxiot: Approximate analytics for edge computing," in IEEE ICDCS, pp. 411-421, Jul. 2018.
- [6] M. Kang et al., "Energy-aware Transmission Power Control for Solar Energy Harvesting Wireless sensor system and Its Effects on Network-wide Performance", KIICE, vol. 17, no. 2, pp.750-753, Oct. 2013.