

태양에너지 수집형 AIoT의 효율적인 연합학습을 위한 에너지 적응적 프루닝 모델 선택 기법

이창한¹, 양재훈², 이민욱², 오재빈², 노동건³

¹숭실대학교 AI융합학과 석사과정

²숭실대학교 AI융합학부 학부생, ³숭실대학교 AI융합학부 교수

dlckdgks99@naver.com, lljhms@naver.com, lmw3164@naver.com,
bynn1202@naver.com, dnoh@ssu.ac.kr

Energy-aware Pruning-Level Selection for the Efficient FL of the Solar-powered AIoT

Changhan Lee¹, Jaehoon Yang², Minwook Lee², Jaebin Oh², Dong Kun Noh³

¹Dept. of Intelligent System, Soongsil University

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

요약

에너지 수집형 AIoT 디바이스에서 연합학습을 수행할 때 에너지 수급의 불균형은 학습 성능과 서비스 가용성에 치명적인 영향을 미친다. 본 연구에서는 이러한 문제를 해결하기 위해 각 디바이스의 현재 에너지 상태에 따라 학습 모델의 경량화 수준을 달리 적용하는 에너지 적응적 프루닝 모델 선택 기법을 제안한다. 제안 기법은 딥러닝 모델의 불필요한 채널을 제거하는 네트워크 슬리밍 기반 프루닝을 활용하여, 에너지가 부족할 때는 경량 모델로 에너지 소비를 줄이고 에너지가 충분할 때는 원래 모델로 높은 정확도를 확보하도록 설계되었다. 이를 통해 노드의 정전 발생 시간을 최소화하면 서도 높은 모델 정확도를 유지할 수 있어, 연합학습의 추론 품질을 높이는 동시에 사용자에게 안정적인 추론 서비스를 제공할 수 있다.

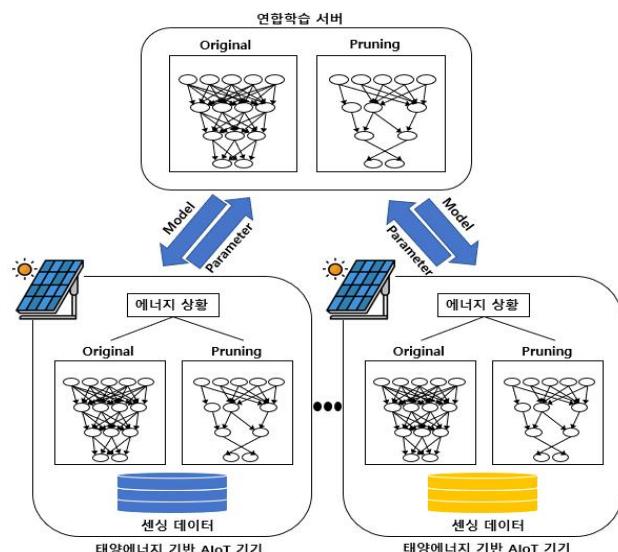
1. 서론

데이터 중심 분산학습 기술인 연합학습[1]은 로컬 디바이스에서 데이터를 보관한 채 독립적 학습 후 모델 업데이트만 중앙에 전달해 글로벌 모델을 구성 한다. 이는 데이터 프라이버시 보장, 통신 비용 절감, 에너지 효율성 향상 및 저지연 처리 등 AIoT의 요구사항을 효과적으로 만족시킨다.

한편, AIoT 시스템의 지속 가능한 운영 요구가 커지면서, 주변 환경에서 에너지를 수집해 스스로 동작하는 에너지 수집형(Energy Harvesting, EH) AIoT 기술[2]이 관심을 받고 있다. 이는 배터리 교체나 충전이 어려운 상황에서도 친환경적이고 지속 가능한 서비스를 제공할 수 있다. 특히 태양광과 같은 고밀도 에너지원 기반 EH 기술 발전으로 AIoT 장치의 안정적인 에너지 확보가 가능해졌다[3].

배터리 기반 AIoT기기는 제한된 에너지를 절약해야 하는 반면, 태양 에너지 기반 AIoT기기는 에너지 수집량에 따라 동작을 유연하게 조정할 필요가 있다. 충분한 에너지가 수집되지 않으면 노드가 정

전되며, 과잉 수집 시 에너지 낭비 문제가 발생한다. 따라서 본 연구는 태양에너지 기반 AIoT 디바이스에서 연합학습 시 각 기기의 에너지 상태에 따라 모델 경량화를 동적으로 조정하는 에너지 적응적 프루닝 모델 선택 기법을 제안한다.



(그림 1) EH-AIoT의 연합학습을 위한
에너지 적응형 모델 경량화 수준 선택 기법

2. 제안기법

그림 1과 같이, 본 연구에서는 태양에너지를 기반으로 동작하는 AIoT 기기의 연합학습 시 기기의 에너지 상태에 따라 모델 경량화 수준을 다르게 적용하는 방법을 제안한다. 모델 경량화는 네트워크 슬리밍 기반 프루닝 기법[4]을 사용하여 수행하였으며, 이를 통해 모델 복잡도를 줄여 AIoT 디바이스의 연산량과 에너지 소비를 감소시킬 수 있다. 모델 경량화로 일부 정확도 손실이 발생할 수 있으나, 에너지 소모와 정전 가능성을 줄이고 연합학습의 안정성과 품질을 향상시킨다.

기준연구[5]에 의하면 에너지 임계값 $E_{\text{threshold}}$ 는 아래와 같다.

$$E_{\text{threshold}} = \frac{P_{\text{sys}}}{P_{\text{solar}}} \cdot C \quad (3)$$

여기서, P_{solar} 는 시스템의 태양 에너지 수집속도 평균, P_{sys} 는 시스템의 에너지 소비속도 평균, C 는 배터리의 총 에너지 저장 용량을 나타낸다.

E_{residual} 을 현재 배터리에 저장된 에너지량이라 하면, 제안 기법은 아래와 같이 동작한다.

- $E_{\text{residual}} < E_{\text{threshold}}$: 에너지가 부족한 것으로 판단하고, 경량화된(프루닝된) 모델을 사용하여 학습 및 추론을 수행한다. 이를 통해 시스템은 에너지 소비를 절감하고, 정전 발생을 방지할 수 있다.
- $E_{\text{residual}} > E_{\text{threshold}}$: 에너지가 충분하다고 판단하여, 프루닝이 적용되지 않은 원래 모델을 사용하여 학습 및 추론을 수행한다. 이를 통해 모델 정확도를 최대한 확보할 수 있다.

이러한 방식으로 각 노드는 자신의 에너지 상태에 따라 최적화된 방식으로 연합학습에 참여할 수 있으며, 전체 시스템의 안정성과 학습 품질을 동시에 향상시킬 수 있다.

3. 성능 검증

실험 환경은 태양광 패널과 에너지 서브시스템을 포함한 Nvidia Jetson Orin Nano 5대로 구성하였다. Jetson Orin Nano는 일반 모드(약 15W)와 저전력 모드(약 7W)를 지원하며, 각 기기의 에너지 상태에 따라 매 주기 시작 시 자동 전환되도록 설정하였다. 성능 검증을 위해 원본 모델을 사용하는 Non-Slimming 기법, 경량 모델을 사용하는 Slimming 기법과 비교하였다. 성능 평가는 연합학습 서버에서 최종 모델의 정확도와 각 AIoT 기기의 평균 정전시간 비율을 기준으로 하였다.

Non-Slimming 기법은 정확도(88.4%)가 높았으나, 평균 정전시간 비율이 45.2%로 실제 서비스 가용성에 문제가 있었다. Slimming 기법은 평균 정전시간 비율이 1.5%로 낮았으나, 정확도가 77.5%로 감소했다. 반면, 제안 기법은 정전시간 비율이 2.7%로 Slimming 기법과 비슷한 수준의 안정성을 보이면서도 정확도는 87.7%로 Non-Slimming 기법에 근접한 수준을 유지하였다. 이는 제안 기법이 기기의 에너지 상태에 따라 프루닝된 경량 모델과 원본 모델을 동적으로 선택하여 높은 정확도와 서비스 안정성을 동시에 달성했음을 의미한다.

4. 결론

본 논문에서는 태양에너지로 구동되는 에너지 수집형 AIoT 디바이스에서 효율적인 연합학습을 구현하기 위해, 디바이스의 에너지 상태에 따라 딥러닝 모델의 복잡도를 조절하는 에너지 적응적 프루닝 모델 선택 기법을 제안하였다. 실제 태양광 패널과 배터리를 갖춘 Nvidia Jetson Orin Nano 5대 환경에서 VGG-19 모델을 활용한 실험을 통해 제안 기법의 효과를 검증하였다. 이를 통해, 제안기법이 에너지 수집형 AIoT 환경에서 연합학습의 서비스 가용성과 성능을 크게 향상시켜 지속 가능한 AIoT 운영에 기여할 수 있음을 확인하였다.

사사 (Acknowledgement)

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

참고문헌

- [1] Y. Li et al., "Energy-Aware, Device-to-Device Assisted Federated Learning in Edge Computing," in IEEE TPDS, 2023.
- [2] A. Matin et al., "AIoT for sustainable manufacturing: Overview, challenges, and opportunities," in Elsevier IoT, 2023.
- [3] 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.
- [4] Z. Fang, B. Yin, "A low functional redundancy-based network slimming method for accelerating deep neural networks," in Elsevier Alexandria Engineering Journal, 2025.
- [5] Yang, Y. et al. SolarStore: Enhancing Data Reliability in Solar-Powered Storage-centric Sensor Networks. in ACM MOBISYS, 2009