

## Energy-Adaptive Approximate Computing Scheme for Efficient Federated Learning in Energy-Harvesting AIoT Systems

Ikjune Yoon\*, Dong Kun Noh\*\*

\*Assistant Professor, Division of AI Computer Science and Engineering, Kyonggi University, Suwon-si, Korea  
\*\*Professor, School of AI Convergence, Soongsil University, Seoul, Korea

### [Abstract]

With recent advancements in energy harvesting technologies and the proliferation of AIoT devices capable of on-device learning, energy-harvesting AIoT systems have attracted significant attention. This study proposes an energy-adaptive approximate computing method designed to efficiently enhance federated learning performance while ensuring the stable operation of energy-constrained edge AIoT devices. Typically, there is a proportional relationship between learning performance and energy consumption; thus, performance trade-offs are inevitable under stringent energy conditions. Based on a solar energy harvesting model, the proposed scheme optimizes local training data sizes and parameter exchange volumes for each training round within limited energy budgets, performing approximate computing. This approach effectively minimizes device blackout durations, thereby improving the overall accuracy of federated learning.

▶ **Key words:** AIoT, energy-harvesting, approximate computing, federated learning, energy-adaptive, availability

### [요 약]

최근 에너지 수집 기술의 발전과 온디바이스 학습이 가능한 AIoT 장치의 확산으로 에너지 수집형 AIoT 시스템이 주목받고 있다. 본 연구는 에너지 제약이 있는 엣지 AIoT 환경에서 안정성을 유지하면서도 연합학습 성능을 효율적으로 향상시키기 위한 에너지 적응형 근사컴퓨팅 기법을 제안한다. 일반적으로 에너지 소모량과 학습 성능 간에는 비례 관계가 있어, 제한된 에너지 환경에서는 일부 성능 저하를 허용할 필요가 있다. 제안하는 방법은 태양 에너지 수집 모델을 바탕으로, 각 라운드의 제한된 에너지 예산 내에서 로컬 학습 데이터양과 파라미터 교환량을 최적화하는 근사컴퓨팅을 수행한다. 이를 통해 노드의 정전시간을 최소화하고, 결과적으로 전체 연합학습의 정확도를 개선할 수 있음을 확인하였다.

▶ **주제어:** 지능형 IoT, 에너지 수집, 근사 컴퓨팅, 연합학습, 에너지 적응, 노드 안정성, 학습 정확도

- 
- First Author: Ikjune Yoon, Corresponding Author: Dong Kun Noh  
\*Ikjune Yoon (ijyoon@kyonggi.ac.kr), Division of AI Computer Science and Engineering, Kyonggi University  
\*\*Dong Kun Noh (dnoh@ssu.ac.kr), School of AI Convergence, Soongsil University
  - Received: 2025. 05. 12, Revised: 2025. 07. 03, Accepted: 2025. 07. 04.

### I. Introduction

지금까지 IoT 환경에서 동작하는 기기들은 주로 배터리 기반으로 운영되어 에너지 공급량의 근본적인 한계를 가지고 있었다. 더욱이, 최근 AIoT 응용이 급증함에 따라[1], 고성능 추론 및 학습 기능을 갖춘 AIoT 장치들이 개발되고 있지만, 이들 기기는 기존의 IoT 장치보다 훨씬 높은 수준의 에너지를 요구한다.

또한, AIoT 기술은 스마트홈, 스마트 헬스케어 등 접근성이 높은 환경에서도 활용되고 있지만, 전원 인프라가 제한되거나 유지보수가 어려운 물리적 환경에서도 활용되고 있다. 예를 들어, 산림 지역의 산불 감지 센서, 고립된 농업지의 생육 모니터링 카메라, 원격 해안 지역의 수질 및 조류 감시 장치와 같은 응용 환경에서는 지속적인 전원 공급이 어렵고, 장치 유지관리에 소요되는 비용과 시간이 매우 크다. 이에 따라 최근 주변 환경에서 에너지를 수집하는 에너지 수집(energy harvesting, EH) 기술에 대한 연구가 활발히 진행되고 있다. 특히 태양광과 같은 고밀도 에너지원에서의 EH 기술 발전은 AIoT 장치의 안정적 구동을 가능하게 할 만큼 높은 수준에 도달하였다[2].

한편 기존의 클라우드 기반 AI 환경에서는 IoT 장치가 수집한 모든 데이터를 중앙 서버로 전송하여 학습을 수행하므로, 네트워크 비용, 데이터 전송 지연, 그리고 데이터 프라이버시 문제와 같은 단점이 존재한다. 이를 극복하기 위해 최근 엣지 AI 기술이 등장하였으며, 엣지 AIoT는 데이터 소스와 학습 장치 간의 물리적 거리를 최소화하여 위의 문제들을 해결할 수 있다[3].

다양한 엣지 환경 중에서 AIoT와 같이 다수의 저성능 노드로 구성된 환경에서는 분산형 머신러닝(distributed ML, DML)이 적용된다. 기존 엣지 AIoT의 DML 모델은 대개 그림 1(a)와 같은 엣지서버가 중심이 되는 중앙집중




Fig. 2. Overview of the Federated Learning

형 DML(centralized DML, C-DML)의 형태를 가지고 있다. 엣지서버는 각 기기에서 얻은 데이터를 수집하여 전체 혹은 일부의 학습을 수행하지만, 확장성(scalability)과 내결함성(fault-tolerance)이 낮고 데이터 프라이버시 문제도 해결하기 어렵다는 단점이 있다. 최근 이러한 문제를 극복하기 위해 그림 1(b)와 같이 엣지 서버를 없앤 탈중앙화 분산형 DML(decentralized DML, D-DML)에 대한 관심이 높아지고 있다[4].

D-DML 기반 연합학습에서는 엣지 서버의 역할을 노드 간 상호 통신을 통해 대체한다. 즉, 그림 2와 같이, 각 AIoT 노드는 동일한 모델을 복제한 후, 자신이 수집한 데이터를 기반으로 로컬 학습을 수행하고, 인접한 이웃 노드들과 파라미터를 교환한다. 이러한 파라미터 교환 과정을 반복하면서 각 노드는 자신의 모델을 지속적으로 업데이트하며, 시스템 전체는 점진적으로 전역 모델(global model)에 수렴하게 된다. D-DML에서 파라미터 교환은 일반적으로 Gossip-based averaging, Ring topology, Grid topology, Fully connected 등 다양한 네트워크 토폴로지 구조를 기반으로 수행된다. 각 노드는 자신과 통신 가능한 이웃 노드로부터 전달받은 파라미터를 받아들이고, 이를 자신의 로컬 모델과 평균 또는 선형 결합하여 업데이트한다. 이와 같은 방식은 파라미터 집계 과정을 탈중앙화하고 동시에 병렬화할 수 있어, 앞서 설명한 중앙집중형 DML(C-DML)의 확장성 부족, 병목현상, 내결함성 한계 등의 문제를 효과적으로 극복할 수 있다.

본 연구는 D-DML 모델 기반의 연합학습(federated learning) 환경을 대상으로 하는데, 이와 관련한 기존 연구들은 주로 데이터 병렬성을 최대화하여 연합학습 성능을 높이는 데 초점을 맞추었으며[5], 에너지의 제약 및 가변적인 에너지 공급 환경을 고려하여 성능을 개선한 연구는 초기 단계이다[6]. 이에 본 논문은 EH-AIoT 장치의 안정성을 유지하면서 D-DML 기반 연합학습 성능을 향상시키기 위한 에너지 적응적 근사컴퓨팅 기법을 제안한다. 본 논문에서 제안하는 에너지 적응형 연합학습 기법은 다음

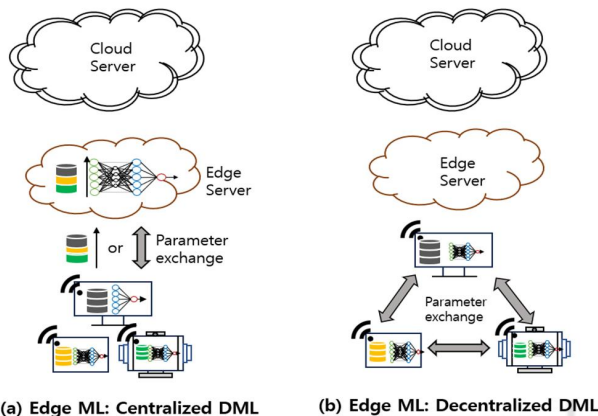


Fig. 1. Two Representative Models of Edge ML

과 같은 절차로 구성된다. 먼저, 각 AIoT 노드는 센서를 통해 이미지 데이터를 수집한 후, 에너지 상황에 따라 대표성을 갖는 일부 데이터를 샘플링한다. 이후 샘플링된 데이터는 정밀도를 조절하는 양자화 과정을 거쳐 로컬 학습에 사용되며, 생성된 모델 파라미터 또한 양자화되어 인접 노드와 교환된다. 이때 사용 가능한 에너지 예산은 사전에 강화학습 기반 예측 모델을 통해 슬롯 단위로 계산되며, 각 노드는 해당 예산 내에서 연산 성능과 에너지 소비의 균형을 고려하여 최적의 학습 조합(샘플링, 양자화)을 선택한다. 이러한 과정을 반복함으로써, 중앙 서버 없이도 전체 시스템이 점진적으로 전역 모델에 수렴할 수 있도록 구성되어 있다. 본 연구의 주요 목표는 다음과 같이 정리할 수 있다.

- EH-AIoT의 운용 안정성 확보: D-DML 기반 연합학습에서 각 노드의 지속적 참여는 필수적이며, 노드 정전 발생 시 전체 성능에 심각한 영향을 미칠 수 있음. 따라서 본 연구는 노드 정전시간 최소화를 위해 라운드별 에너지 할당 기법을 제안
- 에너지 예산 내 학습 성능 최적화: 각 라운드에 사용 가능한 제한된 에너지 예산 내에서 최대의 학습 성능을 달성하기 위해 근사컴퓨팅 기반의 에너지 적응적 최적화 방식을 적용

본 논문의 구성은 다음과 같다. II장에서는 관련 연구를 분석하고, III장에서는 제안하는 기법을 설명한다. IV장에서는 제안 기법의 성능을 평가한 실험 결과를 제시하며, V장에서 결론을 맺는다.

## II. Related Works

### 1. EH-AIoT

에너지 수집형 AIoT(energy-harvesting AIoT, EH-AIoT)는 IoT 장치의 에너지 공급 문제를 해결하기 위해 주변 환경에서 에너지를 수집하여 사용하는 기술을 AIoT 시스템에 적용한 개념이다[7]. 기존의 AIoT 시스템은 대부분 배터리나 상시 전원에 의존하였으나, 이는 장치 유지 관리의 어려움과 배터리 교체 비용, 환경적 지속 가능성 문제를 발생시킨다[8]. 이에 EH-AIoT는 태양광, 진동, 열, 무선 주파수(RF) 등과 같은 다양한 환경 에너지를 수확하여 자율적인 에너지 공급을 실현함으로써 이 문제를 근본적으로 해결하고자 한다[9][10].

최근 EH-AIoT 연구의 주요 관심사는 제한된 에너지 자원을 효과적으로 관리하여 시스템의 안정성을 유지하고, AI 및 기계학습(machine learning, ML)과 같은 고성능 연산 작업을 가능하게 하는 것이다[4]

### 2. Approximate Computing

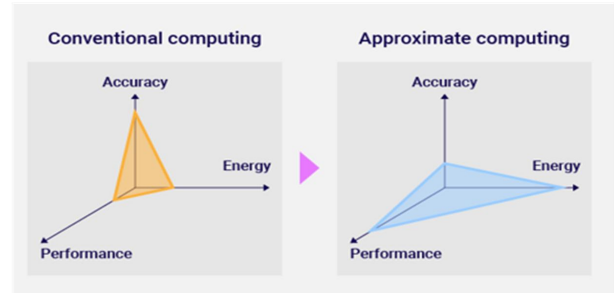


Fig. 3. Approximate Computing vs. Conventional Computing

근사 컴퓨팅(approximate Computing)은 그림 3과 같이 계산의 정확도를 일부 희생하면서 에너지 소비, 연산 속도, 회로 면적 등 자원의 효율성을 크게 높이는 기술이다[11]. 이는 많은 응용 분야가 부분적인 오류를 허용할 수 있는(error-resilient) 특성을 가지기 때문에 가능하다. 예를 들어, 멀티미디어 처리, 센서 데이터 분석, 기계학습과 같은 응용 분야에서는 정밀도가 다소 낮아져도 결과 품질에 큰 영향을 미치지 않는다[12].

특히, 엣지 컴퓨팅(edge computing) 환경에서 근사 컴퓨팅이 더욱 중요한 이유는 IoT 센서나 웨어러블 장치 등 에너지 제약이 강한 환경에서 고정밀 연산으로 인한 높은 에너지 소모가 치명적인 한계가 되기 때문이다[13]. 이러한 장치에서는 정밀 연산을 완화하는 대신 "충분히 좋은(good enough)" 결과를 얻는 방식이 현실적인 솔루션이 될 수 있다. 최근 연구에서는 알고리즘 수준부터 하드웨어 회로 수준까지 시스템 전반에 걸쳐 근사 컴퓨팅 기법을 적용하여 성능과 에너지 효율을 최적화하는 시도가 활발히 이루어지고 있다[14].

### 3. The Novelty of This Study

본 연구에서 적용한 강화학습 기반의 에너지 수집량 예측 기법과 저편향 샘플링 방식은 기존 연구에서 제안된 알고리즘을 참고하여 구현되었으며, 제안 기법의 에너지 예측 정확도와 데이터 대표성 확보를 위한 기반 요소로 활용되었다. 다만 본 연구의 핵심은 이러한 기존 기법의 단순한 사용에 있지 않고, 이를 바탕으로 슬롯별 에너지 제약 조건 하에서 가장 효율적인 학습 조합을 동적으로 선택하

는 에너지 적응형 근사컴퓨팅 기반 연합학습 전략을 새롭게 제안한 데 있다.

또한, 기존 연구들에서 연합학습 또는 근사 컴퓨팅 각각에 대한 접근은 활발히 이루어졌지만, 에너지 수집형 AIoT 환경이라는 제약 조건을 고려하여 이 두 요소를 통합적으로 최적화한 연구는 상대적으로 드물다. 나아가, 노드의 에너지 상태 변화에 따라 실시간으로 학습 전략을 조정함으로써 시스템의 운용 안정성과 학습 정확도를 동시에 향상시키는 방법에 대해서는 아직 초기 단계에 머물러 있다. 이에 본 연구는 기존 연구의 이러한 한계를 극복하고, 에너지 수집 예측과 연합학습, 근사 컴퓨팅을 통합한 에너지 적응형 연합학습 프레임워크를 제안함으로써 기존 접근 방식들과의 명확한 차별성을 갖는다.

이에 따른 본 연구의 기여점은 아래와 같이 요약된다.

- 에너지 수집형 AIoT 환경을 고려하여, 시간 슬롯 단위로 예측된 에너지 수집량 내에서 최적의 학습 조합(샘플링, 양자화)을 선택하는 에너지 적응형 연합학습 프레임워크를 제안
- 기존의 정적 연산 전략과 달리, 에너지 수집량에 따라 연산 전략을 유연하게 조정함으로써, 노드 정전율을 최소화하고 시스템 운용 안정성과 학습 성능을 동시에 향상시킬 수 있음을 입증
- 강화학습 기반의 에너지 수집 예측 기법과 효율적 샘플링을 통합하여, 현실적인 AIoT 스트리밍 환경에서도 효율적이고 편향 없는 학습 데이터 구성을 가능케 함
- ResNet 기반의 실제 엣지 디바이스(NVIDIA Jetson Orin Nano)에서 제안 기법을 구현·실험함으로써 실용성을 검증

### III. The Proposed Scheme

본 기법의 설계 원리는 다음과 같다. 시간 슬롯별로 수집 가능한 에너지가 예측되면, 이를 제약 조건으로 하여 해당 슬롯 내에서 수행 가능한 연산 조합 중 정확도가 가장 높은 조합을 선택하는 방식이다. 이는 곧, 연합학습의 안정성과 성능을 동시에 달성하기 위한 제약 최적화 기반의 근사컴퓨팅 전략이며, 정적인 설정이 아닌 에너지 상황에 반응하는 동적 경량화가 본 기법의 핵심이다.

이를 통해 에너지 예산 내에서 노드 정전율을 낮추면서도 학습 정확도를 최대화할 수 있으며, 이는 기존의 정적 근사 전략이나 중앙 집중형 통제 방식과는 차별화되는 설계라고 볼 수 있다.

### 1. Energy Allocation Model

기본적으로 에너지 수집형 장치들은 안정적 운용을 위해, 한 주기 동안 소모하는 총 에너지가 해당 주기에 수집되는 총 에너지보다 크지 않아야 한다는 에너지 중립적 동작(energy-neutral operation, ENO) 조건을 만족해야 한다[15]. 따라서 ENO 조건을 준수하기 위해 각 주기의 에너지 수집량을 정확히 예측할 필요가 있으며, 이 예측량 이하로 에너지 소비가 제한되어야 한다. 그러나 실제 환경에서는 다양한 장·단기적 변수로 인해 에너지 수집량 예측에 어려움이 따른다. 본 연구에서는 수집 주기를 작은 시간 슬롯으로 나누고, 각 슬롯별 에너지 수집량을 강화학습 기반으로 예측하였다[16].

또한, EH 장치의 운용 안정성을 보장하면서 동시에 활용 가능한 에너지를 최대화하기 위해, 예측된 에너지 수집량을 기반으로 다음과 같은 요구사항을 고려한 동적 에너지 할당 기법을 적용하였다[17].

- 버려지는 수집 에너지 최소화: 일반적으로 재충전 가능한 배터리가 완전 충전되면 이후 추가 수집되는 에너지는 사용되지 못하고 버려진다. 따라서 슬롯 단위로 최적화된 에너지 할당을 통해 버려지는 에너지를 최소화하였다.
- 할당된 에너지 분산 최소화: 특정 시간대에 집중적으로 수집된 에너지를 하나의 주기 내에서 균등하게 분산 할당함으로써, 장치가 지속적이고 안정적으로 동작할 수 있도록 하였다.

그림 4는 태양광 에너지 환경에서 본 연구의 동적 에너지 할당 기법을 적용한 예시로서, 각 시간 슬롯에 균형적으로 에너지를 배분하고 배터리 용량 초과로 인한 에너지 손실을 최소화한 결과를 나타낸다. 본 논문에서 제안하는 EH-AIoT 시스템의 에너지 적응형 근사컴퓨팅 기법은 이러한 동적 에너지 할당을 바탕으로 하며, 각 슬롯에 할당된 에너지 한도 내에서 학습 관련 연산의 근사 정도를 동적으로 조정하여 에너지 효율성을 극대화한다.




Fig. 4. Harvested Solar Energy Forecasting and Allocation

## 2. Energy-Adaptive Approximate Computing

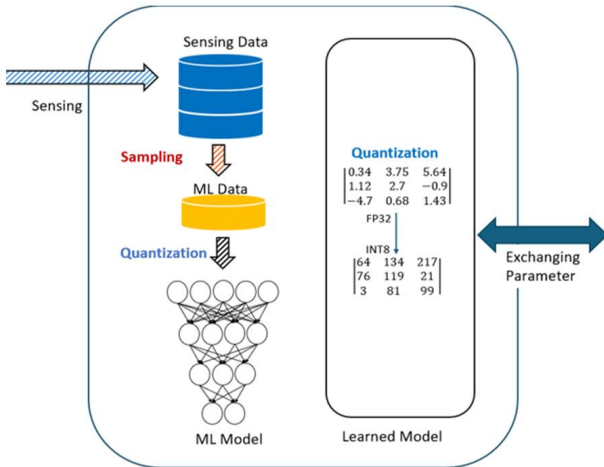


Fig. 5. Approximate Computing of the Proposed Scheme

연합학습은 모든 노드가 동일한 모델을 복제하여 공유한 뒤, 각 노드가 개별적으로 수집한 데이터만을 사용하여 로컬 학습을 수행하는 방식이다. 모델과 데이터가 각 기기에 개별적으로 저장되므로, EH-AIoT 장치들은 스스로의 에너지 상황에 따라 최적의 학습 방식을 결정할 수 있다. 앞서 제안한 에너지 할당 기법을 통해 각 시간 슬롯별로 사용 가능한 에너지가 정해지면, 이제는 주어진 에너지 한도 내에서 최대의 학습 성능을 얻을 수 있는 추가적인 기법이 필요해진다. 이는 개별 노드의 안정적 동작뿐 아니라 전체 연합학습의 성능 향상을 위해 필수적이다. 본 연구는 이러한 요구를 충족시키기 위해 에너지 적응형 근사컴퓨팅 기법을 제안한다.

제안 기법은 각 슬롯에 할당된 에너지 제한 내에서 학습 효율을 극대화하기 위해 두 가지 주요 근사컴퓨팅 기법을 사용한다.

- 데이터 샘플링 비율 조절: 전체 수집 데이터 중 일부 대표 데이터만 선별적으로 활용함으로써 연산량 및 에너지 소비를 감소시킨다.
- 양자화(quantization): 데이터와 모델 파라미터의 표현 정밀도를 낮추어 저장 및 연산 시 소모되는 에너지를 줄인다.

그림 5는 본 연구에서 제안하는 에너지 적응형 연합학습 기법의 연산 최적화 흐름을 시각적으로 표현한 구조도이다. 해당 도식은 센서로부터 수집된 원시 데이터가 샘플링 비율에 따라 대표성을 가지는 일부 데이터로 축소된 후, 양자화를 통해 정밀도가 조정되어 학습에 활용되는 일

련의 과정을 나타낸다. 양자화는 입력 데이터뿐만 아니라, 로컬 학습 과정에서 생성되는 모델 파라미터에도 적용되어 연산 경량화를 유도한다. 더불어, 양자화된 파라미터는 인접 노드와의 파라미터 교환 과정에서도 통신 부하를 줄이는 효과를 가지며, 이는 D-DML 기반 연합학습 환경에서 에너지 효율성과 시스템 전체의 안정성 향상에 기여하는 핵심 요소로 작용한다.

이러한 에너지 적응형 근사컴퓨팅 기법은 일부 정확도를 희생하더라도 노드의 전력 소비량을 효율적으로 줄일 수 있다. 결과적으로 노드의 운용 안정성을 확보하여 학습 참여율을 높임으로써, 연합학습의 성능과 효율을 함께 향상시키는 효과적인 접근 방식이라고 할 수 있다.

### 2.1 Sampling Rate Control

학습 데이터량을 줄이기 위해 센싱 빈도 자체를 낮추는 접근법도 고려할 수 있다. 하지만 이 방식은 데이터의 중요도를 고려하지 않고 센싱 간격만을 늘리는 것이기에 의미 있고 중요한 데이터를 놓칠 가능성이 크다. 본 연구에서는 센싱 빈도는 그대로 유지하되 효율적인 데이터 샘플링을 통해 대표 데이터를 선별하여, 데이터량은 최소화하면서 학습 성능은 유지하는 전략을 택하였다.

본 연구에서 사용하는 카메라 기반 이미지 데이터는 고정된 위치에서 실시간으로 수집되며, 시간대 및 환경 조건의 반복으로 인해 유사한 이미지가 다수 발생하는 특성이 있다. 이러한 상황에서 단순 순차 샘플링이나 일반 무작위 샘플링을 적용할 경우 특정 조건에 편중된 데이터가 과도하게 포함되어 학습 성능을 저하시킬 수 있다.

이러한 문제를 완화하기 위해, 본 연구는 수집 이미지 스트림 전체에서 시간 순서에 영향을 받지 않도록 Reservoir 샘플링 기법[18]을 우선 적용하였다. 해당 기법은 각 이미지가 동일한 확률로 선택될 수 있도록 하여, 시간적 편향 없이 대표 샘플을 구성할 수 있다.

추가적으로, Reservoir 샘플링으로 선택된 이미지들을 대상으로 사전 학습된 CNN(MobileNet)의 중간 feature map을 활용하여 임베딩 벡터를 생성하고, 이들 간의 코사인 거리 기반 유사도 분석을 수행하였다. 이를 통해 유사 이미지들을 필터링하거나 다양한 시각적 특징을 가진 샘플을 우선 선택함으로써, 학습 데이터의 시각적 다양성과 대표성을 확보할 수 있도록 하였다.

### 2.2 Quantization

양자화는 데이터와 파라미터의 표현 정밀도를 조정하여, 로컬 학습 연산과 노드 간 파라미터 교환에 소모되는

에너지를 효과적으로 줄이는 기법이다. 양자화를 적용하면 사용되는 메모리의 양 또한 감소하여, 전체 시스템 자원 관리 측면에서 추가적인 이점을 얻을 수 있다. 특히, 정밀도를 조정하는 정도에 따라 에너지 소비량을 세부적으로 제어할 수 있다는 장점이 있다. 표 1은 NVIDIA Orin Nano 장치에서 TensorFlow Lite 라이브러리를 이용하여 8bit 양자화를 수행했을 때, 에너지 및 메모리 소비가 감소한 정도를 보여준다.

Table 1. Effect of Quantization from FP32 to INT8 [19]

	Energy Saving	Area Saving
ADD	30x	116x
Multiply	18.5x	27x

### 2.3 Heuristic Optimization Scheme

본 연구에서는 앞서 제안한 세 가지 기법(에너지 할당, 데이터 샘플링, 양자화)을 결합하여, 각 시간 슬롯에 할당된 에너지 한도 내에서 학습 정확도를 최대화하는 근사컴퓨팅 정도를 결정한다. 제안한 기법의 구체적인 동작 과정은 다음과 같다.

- ① 특정 AIoT 응용을 선정하고, 이에 적합한 연합 학습 모델을 설계한 후 각 기기에게 전달한다.
- ② 설계된 모델을 기반으로 샘플링 비율, 희소화, 양자화 등 각 근사컴퓨팅 기법이 학습 정확도와 에너지 소모에 미치는 영향을 분석한다.
- ③ 각 기기는 주어진 라운드에서 사용 가능한 에너지 양과 ②의 분석 결과를 바탕으로 실행 가능한 [샘플링 비율, 양자화 정도]의 조합을 구성하며, 가능한 조합 중 학습 정확도가 가장 높을 것으로 예측되는 조합을 휴리스틱(heuristic) 방법을 통해 선택한다.

Table 2. Measurement Results of Accuracy and Energy for Varying Sampling-Quantization Pairs

Sampling Rate(%)	Quantization	Energy (J)	Accuracy (%)
20	FP32	165	48
	INT8	124	42
40	FP32	192	52
	INT8	163	45
60	FP32	220	55
	INT8	182	48
80	FP32	290	59
	INT8	225	51
100	FP32	370	76
	INT8	285	69

표 2는 NVIDIA Jetson Orin Nano 장치에서 ResNet-18 CNN 모델로 학습을 수행했을 때, 에너지 소비량과 정확도를 측정하여, 본 연구를 위해 구축한 참조 결과이다. 본 연구의 성능 최적화 전략은 Sampling 비율과 Quantization 수준의 모든 조합을 동등하게 비교하는 것이 아니라, 각 시간 슬롯에서 사용 가능한 에너지 제약 하에서 정확도가 최대가 되는 조합을 휴리스틱하게 선택하는 방식이다. 이를 위해 사전 실험을 통해 Table 2와 같이 각 [Sampling, Quantization] 조합의 에너지 소비량과 정확도를 측정하였고, 이후 본 실험에서는 에너지 한도 내에서 가장 높은 정확도를 보장하는 조합을 선택하였다. 예를 들어, 주어진 슬롯의 에너지 한도가 230J일 경우, Table 2를 참고하여 해당 범위 내에서 가장 높은 정확도를 가지는 조합([60%, FP32], 정확도 55%)이 적용된다. 이와 같이 제안 기법은 정해진 에너지 예산 내에서 동적으로 최적화된 연산 조합을 선택함으로써 전체 시스템의 효율성과 안정성을 동시에 달성한다.

## IV. Performance Validation

### 1. Experimental Environments

Table 3. Experimental Parameters

Parameter	Value
Global Model	ResNet-18
AIoT Edge Device	5 of Jetson Orin Nano
Amount of Harvested Energy	150Wh ~ 400Wh depending on environments
Rechargeable Battery Capacity	240Wh (12V, 20Ah)
Time Slot Period	1 hour
Experiment Duration	10 days

제안 기법의 성능 검증을 위해 NVIDIA Jetson Orin Nano 장치 5대를 이용하여 표 3과 같이 실험 환경을 구성하였다. 각 장치는 20W급 소형 태양광 패널과 240Wh 용량의 배터리로 전력을 공급받으며, Wi-Fi를 통해 상호 연결된 상태에서 각 장치의 전력 상태는 jetson\_stats를 이용하여 실시간 모니터링하였다.

본 실험은 고정형 카메라 센서를 통해 실시간으로 수집한 이미지 데이터를 사용하여 ResNet-18 모델을 기반으로 객체 식별을 수행하였다. 실험에 사용된 데이터는 다양한 시간대 및 조도 조건에서 촬영된 컬러 이미지로 구성되

어 있으며, 사전에 정의된 10개의 객체 클래스(예: 사람, 차량, 자전거, 가로등, 나무 등)를 분류 대상으로 설정하였다. 각 이미지는 128×128 해상도로 전처리한 후 ResNet-18 모델의 입력으로 사용하였으며, 이를 통해 에너지 제약 환경에서도 효율적인 분류 성능을 평가하였다. 각 노드는 전체 10개의 클래스 중 2개씩 고유한 데이터만 보유하는 non-IID 환경으로 설정하였다. 총 실험 기간은 10일, 시간 슬롯의 단위는 1시간으로 설정하였다.

성능 평가는 다음의 세 가지 지표를 기준으로 수행하였다. 첫째, 연합학습의 최종 정확도, 둘째, 각 슬롯별 학습 참여 노드의 비율(participation rate), 셋째, 전체 운용 시간 중 노드가 정전(blackout) 상태였던 시간의 비율이다. 제안 기법의 성능 검증을 위해 다음 세 가지 방법을 비교하였다.

- ① Min Approx.: 최대 정확도를 위해 항상 최고 수준의 학습(100% 샘플링 비율, FP32)을 수행하는 방법
- ② Max Approx.: 최대 안정성을 위해 항상 최소 수준의 학습(30% 샘플링 비율, INT8)을 수행하는 방법
- ③ Ours: 본 연구의 제안 기법으로 슬롯 단위 에너지 할당 기법과 에너지 적응적 근사컴퓨팅 수행

## 2. Experimental Results

Table 4. Experimental Results

	Min Approx.	Max Approx.	Ours
Global Accuracy	72.5%	81.2%	88.2%
Participation Rate	52.3%	79.2%	98.5%
Blackout Time Ratio	44.9%	12.6%	13.4%

표 4에서 정리된 것처럼, 정확도 측면에서 제안 기법은 최종 글로벌 모델 기준 약 88.2%의 정확도를 달성하였다. 이는 이상적인 경우(모든 노드의 에너지가 무제한)에 비해 약 3.7%p 낮은 수치이다. 또한, 노드의 평균 학습 참여율은 약 98.5%로 매우 높게 나타나, 대부분의 노드가 주기적으로 연합학습에 안정적으로 참여했음을 알 수 있다. 다만 일부 주기에서 참여하지 못한 노드들이 있었는데, 이는 에너지 수집 및 소비 예측 모델의 오차로 인해 실제 사용 가능한 에너지보다 더 많은 양의 에너지가 할당되었기 때문이다. 전체 운용 시간 대비 노드의 정전 시간 비율은 약 13.4%로, 최대 안정성을 목표로 한 Max Approx. 기법과

유사한 수준을 보였다. 이는 제안된 기법이 에너지 상황에 따라 근사 컴퓨팅의 정도를 효과적으로 조절했음을 시사한다.

반면 최대 정확도를 목표로 한 Min Approx. 기법은 초기에는 높은 학습 참여도를 보였으나, 높은 에너지 소모로 인해 시간이 지남에 따라 정전 노드가 빈번히 발생하여 참여도가 급격히 감소하였다. 특히 이러한 현상은 24시간의 태양에너지 수집 주기마다 반복되었으며, 결과적으로 최종 정확도의 큰 저하로 이어졌다. 한편 Max Approx. 기법 역시 초기에는 높은 참여도를 보였으나 시간이 흐를수록 점진적으로 감소하는 유사한 패턴을 보였다. 다만 Min Approx. 기법보다는 전반적으로 우수한 참여율과 낮은 정전시간을 기록하였는데, 이는 근사컴퓨팅을 최대 수준으로 유지하여 소모되는 에너지를 최소화했기 때문이다. 그러나 Max Approx. 기법의 경우에도 지나친 근사화로 인해 참여도와 정전 시간의 개선 대비 최종 정확도의 향상은 크지 않았다.

종합적으로 볼 때, 제안한 에너지 적응형 근사컴퓨팅 기반 연합학습 기법은 효율적인 시간 슬롯별 에너지 할당과 적절한 근사컴퓨팅 수준의 조절을 통해 시스템 안정성과 학습 정확도를 동시에 효과적으로 향상시킬 수 있음을 입증하였다.

## V. Conclusions

본 논문에서는 에너지 수집형 엣지 AIoT 환경에서 효율적인 연합학습을 지원하기 위한 에너지 적응형 근사 컴퓨팅 기법을 제안하였다. 특히 에너지 제약이 심한 엣지 장치들이 지속 가능한 연합학습을 수행할 수 있도록, 태양 에너지 수집량을 예측하고 이를 바탕으로 각 기기의 학습 데이터 양과 연합학습 시의 파라미터 교환량을 최적화하는 근사컴퓨팅을 사용하여 에너지 효율성을 극대화하였다. 실험 결과, 본 기법은 기기의 정전시간을 현저히 감소시켜 시스템의 운용 안정성을 확보할 수 있었으며, 동시에 전체 연합학습 정확도 향상에도 기여함을 확인하였다.

제안 기법은 기존의 분산형 연합학습 및 근사컴퓨팅 연구들과 달리, 에너지 수집 예측을 바탕으로 시간 슬롯별로 사용 가능한 에너지 제약을 고려하여 학습 전략을 유연하게 최적화하는 통합 프레임워크를 제시하였다. 이러한 접근은 기존의 정적 학습 방식보다 현실적인 IoT 환경에서 더 높은 정확도와 안정성을 동시에 확보할 수 있다는 점에서, 실용성과 당위성 측면에서 의미 있는 기여를 가진다.

본 연구에서 제안 기법이 에너지 제약 환경에서 높은 학습 성능과 운용 안정성을 달성할 수 있음을 보여주었지만, 동시에 향후 보완이 필요한 한계점도 일부 확인되었다. 예를 들어, 제안 기법에서도 일부 시간 슬롯에서 에너지 수집량 및 사용량에 대한 예측 오차로 인해, 실제 사용 가능한 에너지를 초과한 연산 설정이 적용되어 노드가 정전 상태에 빠지는 사례가 발생하였으며, 전체 운용 시간 대비 약 13.4%의 정전 비율이 관찰되었다. 이에 따라, 향후에는 에너지 예측의 정확도를 향상시키고, 에너지 예산 초과 상황에 대응할 수 있는 동적 재조정 기법(dynamic reallocation strategy) 개발이 필요하다. 이러한 후속 연구는 EH-AIoT 시스템의 실용성을 더욱 향상시키고, 다양한 실제 응용 분야에 대한 확장 가능성을 높이는 데 기여할 것으로 기대된다.

## ACKNOWLEDGEMENT

This work was partly supported by the Institute of Information & Communications Technology Planning & Evaluation(IITP)-Innovative Human Resource Development for Local Intellectualization program grant funded by the Korea government (MSIT) (IITP-2025-RS-2022-00156360, contribution rate: 50%) and the MSIT(Ministry of Science and ICT), Korea, under the Graduate School of Metaverse Convergence support program (IITP-2025-RS-2024-00430997, contribution rate: 50%) supervised by the IITP (Institute for Information & Communications Technology Planning & Evaluation).

## REFERENCES

- [1] Abdul Matin, Md Rafiqul Islam, Xianzhi Wang, Huan Huo, and Guandong Xu, "AIoT for sustainable manufacturing: Overview, challenges, and opportunities," *Internet of Things*, vol. 24, p. 100901, Dec. 2023. DOI: 10.1016/j.iot.2023.100901
- [2] Yi Chen Lee, Harikrishnan Ramiah, Alexander Chia Chun Choo, Kishore Kumar Pakkirisami Churchill, Nai Shyan Lai, Chee Cheow Lim, Yong Chen, Pui-In Mak, and Rui P. Martins, "High-Performance Multiband Ambient RF Energy Harvesting Front-End System for Sustainable IoT Applications - A Review," *IEEE Access*, vol. 11, pp. 123456-123467, Jan. 2023. DOI: 10.1109/ACCESS.2023.3241458
- [3] Amira Bourechak, Ouarda Zedadra, Mohamed Nadjib Kouahla, Antonio Guerrieri, Hamid Seridi, and Giancarlo Fortino, "At the Confluence of Artificial Intelligence and Edge Computing in IoT-Based Applications: A Review and New Perspectives," *Sensors*, vol. 23, no. 3, p. 1639, Feb. 2023. DOI: 10.3390/s23031639
- [4] E. T. M. Beltrán, M. Q. Pérez, P. M. Sánchez, S. L. Bernal, G. Bovet, M. G. Pérez, G. M. Pérez, and A. H. Celdrán, "Decentralized federated learning: Fundamentals, state of the art, frameworks, trends, and challenges," *IEEE Communications Surveys & Tutorials*, vol. 25, no. 4, pp. 2983-3013, Sep. 2023. DOI: 10.1109/COMST.2023.3315746
- [5] Y. Li, J. Wang, K. Zhang, and Y. Liu, "Energy-Aware, Device-to-Device Assisted Federated Learning in Edge Computing," *IEEE Transactions on Parallel and Distributed Systems*, vol. 34, no. 7, pp. 2138-2154, Jul. 2023. DOI: 10.1109/TPDS.2023.3277423
- [6] Y. Liao, H. Xu, Z. Yao, L. Wang, and C. Qiao, "Accelerating federated learning with data and model parallelism in edge computing," *IEEE/ACM Transactions on Networking*, vol. 31, no. 4, pp. 1593-1606, Aug. 2023. DOI: 10.1109/TNET.2023.3299851
- [7] A. S. Khan, M. U. Farooq, and A. A. Khan, "Advancements in Energy Harvesting Techniques for Sustainable IoT Applications: A Review," *Sustainable Computing: Informatics and Systems*, vol. 38, p. 100897, Apr. 2025. doi: 10.1016/j.suscom.2025.100897.
- [8] Z. Zhang et al., "Mechanical Intelligent Energy Harvesting: From Methodology to Applications," *Advanced Energy Materials*, vol. 13, no. 5, p. 2300557, Jan. 2023. doi: 10.1002/aenm.202300557.
- [9] W. Qi, Y. Zhang, and H. Li, "Survey on Energy Harvesting IoT Communication in the Future Network," in *Proceedings of the 2022 International Conference on Intelligent Computing and Networking Performance (ICICNP)*, Fuzhou, China, Sep. 2022, pp. 63-68. doi: 10.1109/ICICNP56456.2022.00020.
- [10] A. A. Khan et al., "Energy Harvesting Technologies and Applications for the Internet of Things: A Comprehensive Review," *Sensors*, vol. 23, no. 9, p. 11280727, Sep. 2024. doi: 10.3390/s230911280.
- [11] J. Han and M. Orshansky, "Approximate computing: An emerging paradigm for energy-efficient design," in *Proceedings of the 18th IEEE European Test Symposium (ETS)*, Avignon, France, May 2013, pp. 1-6. doi: 10.1109/ETS.2013.6569370.
- [12] Q. Xu, T. Mytkowicz, and N. S. Kim, "Approximate computing: A survey," *IEEE Design & Test*, vol. 33, no. 1, pp. 8-22, Feb. 2016. doi: 10.1109/MDAT.2015.2505723.
- [13] J. Ometov et al., "Adaptive approximate computing for ultra-low-power edge AI," *IEEE Internet of Things Journal*, vol. 9, no. 4, pp. 2950-2963, Feb. 2022. doi: 10.1109/JIOT.2021.3101839.

- [14] K. Katare et al., "Approximate computing techniques for edge AI: A review," *IEEE Access*, vol. 11, pp. 2503–2519, Jan. 2023. doi: 10.1109/ACCESS.2023.3242291.
- [15] H. S. Dhillon, P. Chawla, and A. Gupta, "Study and performance analysis of harvested energy in different scenarios and its suitability in different applications," *AIP Conference Proceedings*, vol. 2495, no. 1, p. 030002, Oct. 2023. DOI: 10.1063/5.0167090
- [16] S. Kosunalp, "A New Energy Prediction Algorithm for Energy-Harvesting Wireless Sensor Networks With Q-Learning," *IEEE Access*, vol. 4, pp. 5755–5763, Sep. 2016. DOI: 10.1109/ACCESS.2016.2606541
- [17] D. Noh, Y. Yong, L. Wang, H. K. Le, and T. Abdelzaher, "Minimum Variance Energy Allocation for a Solar-Powered Sensor System," *IEEE/ACM DCOS'09 (LNCS vol. 5516)*, pp. 44–57, Marina del Rey, CA, USA, Jun. 2009. DOI: 10.1007/978-3-642-02085-8\_4
- [18] Z. Wen, R. Shi, B. Wang, and H. Yu, "Approxiot: Approximate analytics for edge computing," *IEEE ICDCS*, pp. 411–421, Vienna, Austria, Jul. 2018. DOI: 10.1109/ICDCS.2018.00049

## Authors



Ikjune Yoon received the B.S. degree in Computer engineering from Jeonbuk National University, Korea, in 2005, and Ph.D. degree in Computer Science and Engineering from Seoul National University, Korea, in 2015.

He is currently an assistant professor in Division of AI Computer Science and Engineering at Kyonggi University. His research interests include cyber-physical systems and internet of things.



Dong Kun Noh received the B.S., M.S. and Ph.D. degrees in Computer Science and Engineering from Seoul National University, Korea, in 2000, 2002, and 2007, respectively. He is currently a professor in School of AI

Convergence, Soongsil University. His primary research interests include cyber-physical system, mobile computing, and internet of things.