

논문 2023-18-20

태양 에너지 수집형 IoT 엣지 컴퓨팅 환경에서 효율적인 오디오 딥러닝을 위한 에너지 적응형 데이터 전처리 기법 (Energy-Aware Data-Preprocessing Scheme for Efficient Audio Deep Learning in Solar-Powered IoT Edge Computing Environments)

유연태, 노동건*

(Yeontae Yoo, Dong Kun Noh)

Abstract : Solar energy harvesting IoT devices prioritize maximizing the utilization of collected energy due to the periodic recharging nature of solar energy, rather than minimizing energy consumption. Meanwhile, research on edge AI, which performs machine learning near the data source instead of the cloud, is actively conducted for reasons such as data confidentiality and privacy, response time, and cost. One such research area involves performing various audio AI applications using audio data collected from multiple IoT devices in an IoT edge computing environment. However, in most studies, IoT devices only perform sensing data transmission to the edge server, and all processes, including data preprocessing, are performed on the edge server. In this case, it not only leads to overload issues on the edge server but also causes network congestion by transmitting unnecessary data for learning. On the other way, if data preprocessing is delegated to each IoT device to address this issue, it leads to another problem of increased blackout time due to energy shortages in the devices. In this paper, we aim to alleviate the problem of increased blackout time in devices while mitigating issues in server-centric edge AI environments by determining where the data preprocessed based on the energy state of each IoT device. In the proposed method, IoT devices only perform the preprocessing process, which includes sound discrimination and noise removal, and transmit to the server if there is more energy available than the energy threshold required for the basic operation of the device.

Keywords : Solar-powered, IoT, Edge-computing, Data pre-processing, Audio deep-learning

1. 서론

IoT 장치는 일반적으로 배터리를 사용하기 때문에 배터리 교체 등의 유지관리가 어려운 환경이나 장시간 동작해야 할 경우, 활용에 제약이 있을 수밖에 없다. 이런 문제를 해결하기 위해 최근 에너지 수집형 IoT에 대한 연구가 진행되고 있다. 그 중, 태양 에너지는 예측 가능성과 고밀도 ($15\text{mW}/\text{cm}^2$) 등의 장점으로 인하여 가장 활발히 연구되고 있다. 태양 에너지 수집형 IoT 장치는 에너지를 주기적으로 수집하여 시스템에 공급할 수 있으므로 배터리의 제한적 에너지 문제를 근본적으로 해결할 수 있으나, 계절, 시간, 날씨 등에 따른 에너지 수집량의 변화로 인하여 매우 신중한 에너지 스케줄링이 필요하다 [1]. 일반적으로 태양 에너지 수집형 IoT 기기들은 최소한의 기기가 소모하는 평균 에너지양을 제공할 수 있는 에너지 수집 서버 시스템 (태양광 패널, 재충전 배터리, AC-DC 컨버터 등)을 장착하고 있다. 따라서, 만약 맑은 날이 지속되거나 수집할 데이터가 많이 발생하지 않는 경우에는, 노드의

기본동작에 필요한 에너지를 초과하는 여분의 에너지가 존재할 수 있다. 이 경우, 태양 에너지는 다음 날 또다시 충전될 것이고, 에너지를 저장할 축전기의 용량은 제한되어 있으므로, 배터리 기반 IoT 기기처럼 에너지를 최대한 아껴서 사용하기보다는 에너지 사용률 (utilization)을 최대화하도록 시스템을 운영하는 것이 유리하다.

한편, 엣지 컴퓨팅은 클라우드 컴퓨팅과 대비되는 개념으로, 데이터 소스의 근거리, 즉 네트워크 구조 관점에서는 네트워크의 가장자리 (엣지)에서 데이터를 실시간으로 처리하는 기술이다 [2]. 그림 1과 같이, 엣지 컴퓨팅 환경은 일반적으로 IoT 기기들을 일컫는 엣지 디바이스들과 엣지 서버라 불리는 IoT 서버 (또는 게이트웨이)로 구성된다. 클라우드 환경에서 컴퓨팅을 수행할 때의 데이터 기밀성, 프라이버시, 응답속도, 비용 등의 문제를 해결하고자 엣지 컴퓨팅 기술이 등장하였는데, 특별히 머신러닝을 클라우드 컴퓨팅 환경이 아닌 엣지 컴퓨팅 환경에서 실시간으로 수행하고, 추후 클라우드의 도움으로 러닝 결과를 강화하는 기술을 엣지 AI라 부른다. 일반적으로 엣지 AI에서 엣지 디바이스들은 데이터를 수집하고 이를 엣지 서버로 전송하는 역할을 수행하는데, 보통 무선 IoT 센서들이 이에 해당한다 [1]. 그리고 엣지 서버에서는 전송받은 데이터의 전처리 과정과 머신러

*Corresponding Author (dnoh@ssu.ac.kr)

Received: Jun. 16, 2023, Revised: Jul. 21, 2023, Accepted: Aug. 2, 2023.
Y. Yoo: Soongsil University (M.S.)

D. K. Noh: Soongsil University (Prof.)

* 이 논문은 2023년도 정부 (교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (2021R1A2C1005919).




그림 1. 엣지 컴퓨팅 환경의 구조

Fig. 1. Overview of the Edge Computing Environment

닝을 차례로 수행한다.

그런데, 이렇게 모든 과정들을 엣지 서버에서 수행할 경우 엣지 서버의 네트워크 트래픽 부하 및 컴퓨팅 부하가 발생하여, 실시간으로 머신러닝을 수행하는데 어려움이 발생한다. 이러한 문제점들을 해결하기 위해 데이터 전처리 과정을 엣지 디바이스에 맡기는 연구들도 있는데, 이 경우 엣지 디바이스의 에너지가 고갈되어 정전시간이 증가하는 또 다른 문제가 발생할 수 있다. 따라서, 본 논문에서는 태양 에너지 수집형 IoT 기기의 에너지 특성을 이용하여 엣지 디바이스들의 에너지 부족 문제를 최소화하면서 서버 집중형 엣지 컴퓨팅 환경의 문제들을 완화시키고자 한다.

II. 관련 연구

IoT 기기들은 응용에 따라 사람이 직접 접근하기 힘든 험한 자연환경에 배치되어 군사, 생태 감시, 재난 감시 등의 목적으로 사용되기도 한다. 이러한 응용의 경우 배터리 기반의 IoT 기기들은 에너지의 제약으로 인해 짧은 시간 사용하고 버려지거나, 높은 비용을 들여 배터리 교체 등의 유지 보수 작업을 필요로 한다. 배터리 기반 IoT 기기들의 짧은 생명주기를 보완하기 위해, 기기가 사용하는 에너지를 줄이기 위한 많은 기법들이 제안되었으나, 이는 생명주기를 늘리기 위한 근본적인 해결책이 될 수는 없다. 이를 해결하기 위해, 최근 주변 환경에서 에너지를 수집하여, 노드를 영구적으로 사용할 수 있게 하는 에너지 수집에 관한 연구가 진행되고 있다. 에너지 수집은 주변 환경의 에너지, 즉 태양, 바람, 진동 등의 에너지를 전기 에너지로 변환하여 사용하는 것을 의미한다. 다양한 에너지원 중 태양 에너지는 에너지 수집률이 가장 높으며, 주기적으로 에너지가 충전된다는 장점이 있어 가장 많이 연구되고 있는데, 표 1을 통해, 태양 에너지가 다른 에너지원에 비해 높은 에너지 수집률을 보여 주고 있음을 알 수 있다 (15 mW/cm^2) [1].

배터리 기반의 IoT 기기에서는 정해진 에너지 자원을 최대한 절약하여 사용하는 것을 목표로 해야하는 반면에, 태양 에너지 기반 IoT 기기는 주기적으로 수집된 에너지의 효율적 사용에 초점을 맞추어야 한다. 즉, 수집되는 태양에너지가 많을 때도 있고, 적을 때도 있기 때문에, 노드가 동작함에 있어서 기본적으로 요구되는 에너지를 항상 확보할 수

표 1. 주변 수집 가능 에너지 종류별 특징
Table 1. Ambient Collectable Energy Types

Energy Source	Power Density
Solar cells (outdoors at noon)	15mW/cm^2
Piezoelectric (shoe inserts)	$330\mu\text{W/cm}^3$
Vibration (microwave oven)	$116\mu\text{W/cm}^3$
Thermoelectric (10 °C gradient)	$40\mu\text{W/cm}^2$
Acoustic noise (100 dB)	960nW/cm^3

있는 기법이 필요하고, 아울러 기본적으로 요구되는 에너지를 제외한 여분의 에너지를 효율적으로 소비하기 위한 기법도 필요하다. 태양 에너지는 주기적으로 충전이 되므로 이 여분의 에너지를 계속 저장해 둔다면, 저장 가능 배터리 용량을 초과하게 되어, 에너지가 저장되지 못하고 버려지는 경우도 생기기 때문이다. Yang [3]의 연구에서는 이러한 여분의 에너지량을 수학적으로 계산할 수 있는 에너지 모델을 제안하였다. 또한, Yoon [4]은 이렇게 계산된 사용 가능한 여분의 에너지를 데이터 압축에 사용하여, 송신 노드와 목적지 노드 사이의 중계 노드들이 데이터를 전달하는 데 쓰이는 에너지를 절약할 수 있게 하였다. 또한, Kang [5]은 기존의 Ring-routing 기법의 앵커 노드 근처의 에너지 불균형 문제를 해결하기 위해 에너지 수집을 통하여 획득한 여분의 에너지로 다수의 링 구조를 유지하는 Multi-ring-routing 기법을 제안하였다.

본 논문에서는 위의 연구들과 응용 대상을 달리하여, IoT 기기가 정전되지 않는 범위 내에서 태양 에너지 수집을 통하여 얻은 여분의 에너지를 오디오 딥러닝을 위한 데이터 전처리에 사용함으로써, 엣지 서버에 전달하는 데이터의 질을 향상시키고, 아울러 엣지 서버의 부하를 줄일 수 있는 기법을 제안하고자 한다.

III. 제안 기법

본 연구에서는 많은 AI 응용 중에서 오디오 데이터를 활용한 딥러닝 응용을 타겟으로 하여 제안 기법을 구현하였다. 오디오 데이터는 상황 인식, 음성 인식 등 다양한 AI 응용을 위한 데이터셋으로 유용하게 사용되고 있다 [6, 7]. 다양한 종류의 오디오 데이터를 기계 학습에 사용하기 위해서는 양질의 소리 데이터를 분리하여 확보하는 데이터 기술 [8, 9]이 필요한데, 이는 수집 대상 소리 이외의 데이터나 잡음이 포함될 경우, 학습의 정확도가 떨어질 수 있기 때문이다. 이러한 작업을 일반적으로 데이터 전처리라고 부른다.

그림 2와 같이, 대부분의 엣지 컴퓨팅 연구에서 IoT 기기들은 엣지 서버로의 센싱 데이터 전송만을 수행하고, 데이터 전처리를 포함한 모든 과정은 엣지 서버에서 수행되고 있다. 이 경우, 엣지 서버의 과부하 문제뿐 아니라, 학습에 불필요한 데이터까지도 서버에 그대로 전송되므로 네트워크 과부하 문제도 야기한다. 반대로, 이를 해결하고자 데이터




그림 2. 기존 엣지 컴퓨팅 환경에서의 데이터 전처리 위치
Fig. 2. Position of Data Preprocessing in the Typical Edge Computing Environment

전처리 과정을 각 IoT 기기에 모두 맡긴다면, 기기의 에너지 부족으로 정전시간이 증가하는 또 다른 문제가 발생한다. 제안 기법에서는 그림 3과 같이 각 IoT 기기의 에너지 상태에 따라 데이터 전처리 여부를 결정함으로써, 기기들의 정전시간 증가 문제를 완화시키면서 서버 집중형 엣지 AI 환경의 문제들 (엣지 서버 및 네트워크 과부하)을 완화하고자 한다. 즉, 엣지 서버에서의 효율적인 오디오 디핑닝 수행을 위하여, 각 태양 에너지 수집형 IoT 기기의 잔여 에너지가 충분할 경우, 엣지 서버가 아닌 그 기기에서 데이터 전처리를 수행하는 에너지 적응형 기법을 제안한다.

1. 전처리에 사용 가능한 에너지양 계산

Yang의 연구 [3]에서는, 태양 에너지 기반 IoT 노드가 정전을 회피하는 범위 내에서 사용 가능한 에너지의 양을 제안한다. 이를 계산하기 위해, 우선 배터리가 가득 찰 때까지 걸리는 시간 T_{full} 은 다음과 같이 정의한다.

$$T_{full}(E_{residual}) = \frac{C - E_{residual}}{P_{solar} - P_{sys}} \quad (1)$$

P_{solar} 는 단위 시간당 태양 에너지 수집량, P_{sys} 는 단위 시간당 노드의 에너지 소비량, $E_{residual}$ 은 현재 배터리에 남아있는 에너지양, C 는 배터리 총량을 나타낸다. 분자의 $C - E_{residual}$ 은 앞으로 채워져야 할 에너지양을 의미하며, 분모의 $P_{solar} - P_{sys}$ 는 수집되는 에너지양에서 소비되는 에너지양을 뺀 값으로, 순수하게 충전되는 에너지양을 의미한다. 채워져야 할 에너지양을 단위 시간당 순수 충전량으로 나누어주어, 배터리가 가득 찰 때까지 걸리는 시간 T_{full} 을 도출해 낸다.

T_{full} 을 단위 시간당 노드가 소비하는 에너지와 곱해주면, 배터리가 가득 찰 때까지 노드가 소비하는 에너지양을 도출할 수 있으며, 이는 아래와 같다.

$$E_{residual} = T_{full}(E_{residual}) \cdot P_{sys} \quad (2)$$

즉, 노드의 잔여 에너지가 Equation (2)를 만족한다면, 항상 배터리가 완충되는 것을 보장한다.

Equation (3)은 Equation (2)의 T_{full} 을 Equation (1)으로 치환하여 간편화한 식이다.

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

다시 말해, 배터리에 $E_{residual}$ 만큼의 에너지가 남아있다면, 노드는 정전이 발생 되지 않으며, 이는 노드가 최소한으로 가지고 있어야 할 에너지 문턱값 $E_{threshold}$ 로 나타낼 수 있다. 노드의 현재 잔여 에너지를 $E_{residual}$ 로 표현하고, 정전 없이 추가로 사용될 수 있는 에너지 ΔE 는 다음으로 표현할 수 있고, 우리는 이 에너지를 사용하여 IoT 기기가 직접 수집 데이터 전처리를 수행할 것이다.

$$\Delta E = E_{residual} - E_{threshold} \quad (4)$$

2. 전처리 위치 선택

기존의 엣지 컴퓨팅 환경에서는, IoT 기기에서 데이터의 수집과 전송만을 담당하고, 엣지 서버에서 데이터 전처리 및 머신러닝을 모두 수행하였다. 그러나 이 경우 엣지 서버에 부하가 집중되는 문제가 있었는데, 최근 IoT 기기들의 수행 능력이 향상되고, 또한 에너지 수집 기술을 사용하게 됨으로써, IoT 기기들에서도 데이터 전처리의 일부 수행이 가능하게 되었다.

제안 기법에서는, 문턱값 ($E_{threshold}$) 이상의 에너지를 가진 노드들은, 여분의 에너지 ΔE 를 사용하여 앞 절에서 기술한 데이터 전처리 과정을 수행한다. 이를 통해 저용량의 명료한 오디오 데이터를 얻을 수 있고, 이를 엣지 서버로 전송하여, 서버에서 전처리 과정을 생략하게 된다. 결과적으로 서버의 컴퓨팅 부하가 감소되고, 네트워크의 트래픽도 줄어들 수 있다.

그러나, 잔여 에너지가 문턱값보다 작은 기기, 즉 여분의 에너지 ΔE 가 없는 노드들은 에너지를 최소로 사용하기 위해, 기기에서 데이터 전처리를 수행하지 않고, 그대로 엣지 서버에 전송한다. 전처리를 수행하면 에너지가 고갈되어, 다음 주기에 에너지가 다시 수집될 때까지 정전상태가 될 수 있기 때문에, IoT 기기는 정전시간 동안 데이터의 수집을 할 수 없기 때문에 안정적인 동작이 이루어지려면 정전시간을 최소화해야 한다.

이렇게 태양 에너지 수집형 IoT 기기의 잔여 에너지 상태에 따라 적응적으로 데이터 전처리를 수행하여 엣지 서버에 전송하면, 엣지 서버에서는 전처리에 수행할 자원을 다른 작업에 할당할 수 있어 보다 효율적인 실시간 디핑닝 수행이 가능하게 된다. 중요한 것은 이러한 기기에서의 데이터 전처리 작업이 기기들의 정전시간에도 영향을 주지 않는다는 점이다.

3. 전처리 내용 (소리 인식 모듈 및 잡음 감소 모듈)

엣지 기기의 데이터 전처리 과정은 경량 CNN 기반 소리 인식 모델을 통한 소리 판별과, AECNN 기반 잡음 감소 모듈을 이용한 잡음제거를 포함한다.

우선, 소리 인식 모듈은 수집된 데이터가 수집 대상 소리인지 판단하는 역할을 한다. 엣지 디바이스에서 구동될 수 있게 CNN 구조를 경량화하여 설계하였다. 구체적인 CNN의 구조는 3x3의 필터를 갖는 5개의 합성곱 층과 2x2의 필터를 갖는 4개의 최대 풀링 층으로 구성된다. 또한, 활성화 함수는 ReLU를 사용하였으며 입력의 크기는 깊이가 1인 98x128 멜-스펙트로그램이다. 이후 FC (Fully Connected) 층을 softmax 함수와 함께 이용하여 예측값을 출력한다. 이와 같이, 사전 학습된 CNN 기반 모델을 사용하여 수집된 데이터가 수집 대상 소리인지 판단하며, 수집 대상 소리라고 판단된 데이터는 다음 단계인 잡음 제거 모듈로 전달하고, 그렇지 않은 데이터는 제거한다. 이렇게 정제된 데이터를 사용함으로써 불필요한 프로세싱과 데이터의 전송이 제거될 수 있다.

이후, 잡음 감소 모듈이 소리 데이터의 잡음을 감소시켜 명료한 소리 데이터를 만드는 역할을 한다. 잡음 감소를 위한 모듈은 AECNN 기반 딥러닝 모델을 사용하며, 엣지 디바이스에서 구동될 수 있게 AECNN 구조를 경량화하여 설계하였다. 구체적인 AECNN의 구조는 실시간 잡음 감소를 위해 지연 시간은 8ms로 설정하였으며, 256프레임의 입력력 데이터 크기와 15x15 필터를 갖는 5개의 인코더 층과 5개의 디코더 층을 사용하고, 활성화 함수로 PReLU를 사용한 구조에서 총 257,928개의 파라미터를 사용한다 [9]. 이처럼, 사전 학습된 AECNN 기반 잡음 감소 모듈을 사용하여 소리 인식 모듈에서 전달받은 데이터를 전처리한다.

IV. 성능검증

제안 기법의 성능 검증을 위해, 데이터 전처리를 ① 엣지 서버에서 모두 수행했을 경우 (서버사이드 기법)와 ② 엣지 IoT 기기에서 모두 수행했을 경우 (IoT기기사이드 기법), 그리고 ③ 제안 기법 (하이브리드 기법)에서 ①엣지 서버의 평균 CPU 점유율과 ②엣지 서버가 수신하는 데이터의 양 (네트워크 트래픽), 그리고 ③ IoT 기기들의 수행시간 대비 정전시간 비율을 측정하여 비교하였다.

1. 실험 환경

실험을 위한 엣지 IoT 기기로 RaspberryPI4 5대를 사용하였고, 엣지 서버로 HP-Z2를 사용하였다. 자세한 실험 파라미터는 표2와 같다. 에너지 모듈은 따로 소프트웨어적으로 구현하여 실험하였는데, 여기에서 사용된 에너지 관련 값들은 에너지 소비 및 수집 모듈을 만들기 위하여, 실험값을 토대로 설정한 값이다. 엣지 IoT 기기, 즉 RaspberryPI의 에너지 소비율은 Inspector 2 장비로 측정된 값이며, 태양

표 2. 실험 파라미터

Table 2. Experiment parameter

Parameters	Value
Data Set	Noisy speech database for training speech enhancement algorithms and TTS models
Test Data	1,152 seconds noise + voice data, 2,448 seconds only noise data
Edge Server CPU	Intel(R) Core(TM) i9-10900K CPU @ 3.70GHz
Edge Server GPU	NVIDIA GeForce RTX 3080
IoT Device CPU	Quad Core ARM Cortex-A72 1.5GHz
IoT Device GPU	500MHz VideoCore VI
IoT Device Energy Consumption Rate	- Pre-processing: 5.53W - Sensing: 3.9W - Idle: 2.3W
IoT Device Energy Harvesting Rate	Random value of 60Wh/day ~ 100Wh/day
IoT Device Rechargeable Battery Capacity	400Wh

에너지 수집률은 50cm×30cm 결정형 솔라패널과 SolLight CMF40L 배터리로 에너지 수집 시스템을 만들어 측정할 값을 기준으로 하였다. 측정할 에너지 수집률에 따르면, 비가 오는 날에는 최소 약 60Wh/day의 수집률을 보였고, 맑은 날에는 최대 약 100Wh/day의 수집률을 보였다. 실험에서는 날씨를 랜덤하게 선택하였고, 또 날씨가 중간에 바뀌기도 하기 때문에 에너지 수집률의 경우 60Wh/day와 100Wh/day 사이의 임의값을 선택하도록 하였다. 또한, 테스트 데이터는 1152초의 노이즈 포함 음성 데이터를 이용하여 라즈베리파이 5대에서 직접 센싱한 데이터양을 기초로 시뮬레이션하였다.

2. 모델 학습

모델 학습은 별도의 서버에서 진행한다. 데이터셋을 16kHz로 샘플링하여 음성 데이터를 1초 단위로 분할한 후 학습을 진행하였다. 소리 인식 CNN 모델은 2.1의 구조에 따른 잡음이 포함된 음성을 사용하고, 배치 사이즈 16, 에폭 40으로 설정하여 학습을 진행하였다. 잡음 감소 AECNN 모델은 잡음이 포함된 음성과 잡음이 포함되지 않은 음성을 학습에 사용하고 2.2의 구조에 배치 사이즈 100, 에폭 40으로 설정하여 학습을 수행하였다.

3. 실험 과정

데이터 세트에서 392개의 총 1,152초 길이의 음성 데이터와 잡음만 있는 2,448초의 데이터를 결합하여 1시간 길이의 테스트 데이터를 생성하였다. 테스트 데이터를 1초 단위로 분할하고 CNN 모델을 사용하여 샘플링된 데이터가 수집

표 3. 전처리 위치에 따른 성능 지표

Table 3. Performance according to preprocessing location

	Edge Server Side	IoT Device Side	Proposed Scheme
Edge Server Average CPU Usage (%)	67.5	11.3	40.2
Edge Server Average Amount of Received Data (MB)	550.6	152.1	340.6
IoT Device Black-out rate (%)	2.1	64.8	2.7

대상 음성인지 판단하고 수집 대상 음성이 아닌 경우 삭제하였다. 이어 연속된 오디오 파일을 결합한 후 AECNN 모델을 사용하여 잡음 감소를 수행한다.

4. 실험 결과

표 3은 세 가지 기법들의 주요 성능 비교를 나타낸다. 엷지 서버 평균 CPU 점유율은 엷지 서버에서 전처리할 경우 67.5%, IoT 기기에서 전처리할 경우 11.3%로 후자의 경우 엷지 서버의 평균 CPU 점유율이 크게 감소를 확인할 수 있다. 엷지 서버가 수신하는 데이터양도 엷지 서버에서 전처리할 경우 550.6MB, IoT 기기에서 전처리할 경우 152.1MB로 후자의 경우 데이터 크기가 많이 감소함을 확인할 수 있다. 이것은 예상했던 결과인데, IoT 기기를 통해 전처리 과정을 거치는 것이 엷지 서버의 사용량 및 네트워크 사용량을 감소시켜 엷지 서버의 부하를 감소시키기 때문이다. 그러나 이렇게 IoT 기기 쪽에서 데이터 전처리를 모두 담당하게 되면, IoT 기기의 에너지가 급격하게 소진되어 IoT 기기의 정전시간 비율이 64% 이상으로 올라간다. 정전시간 후에 다시 에너지가 수집되면 다시 깨어나긴 하지만, 정전시간이 이렇게 길다면 IoT 응용의 안정적인 동작을 보장하지 못하게 된다. 반대로, 안정적인 동작을 위해 IoT 기기가 아닌 서버 쪽에서만 데이터 전처리를 수행한다면, 결과표에서 보듯이 IoT 기기 정전시간은 많이 줄지만, 서버의 CPU 부하, 트래픽 점유율이 매우 높아지는 것을 확인할 수 있다. 이 경우, 만약 엷지 서버에서 담당하고 있는 IoT 기기가 많아지게 되면, 네트워크 및 계산 지연시간이 기하급수적으로 증가할 수 있다.

제안기법의 경우에는 엷지 서버의 CPU와 트래픽의 양이 다른 두 기법의 중간 정도 값을 보이지만, 우리가 주의 깊게 볼 것은 IoT 기기의 정전시간이 엷지 서버에서만 전처리를 수행할 때와 비교해서, 거의 높아지지 않았다는 점이다. 이는 제안 기법이 에너지 수집량에 따라서 적응적으로 데이터 전처리를 수행했기 때문이며, 여분의 에너지만 사용한 결과 정전시간은 최소화 유지하면서 다른 성능 지표의 값을 향상시킬 수 있었다.

V. 결론

태양 에너지 수집형 IoT에서는 발생 가능한 여분의 에너지를 효율적으로 사용하는 것이 중요하다. 제안 기법에서는 태양 에너지 수집형 IoT 엷지 컴퓨팅 환경에서 오디오 딥러닝을 효율적으로 수행하기 위해, 노드의 동작에 필요한 에너지의 문턱값을 계산하고, 에너지 문턱값과 잔여 에너지를 비교하여, 여분의 에너지가 존재할 경우에만 기기에서 (소리 인식 및 잡음 제거 등의) 데이터 전처리를 수행한 후 엷지 서버에 전송한다. 이러한 에너지 적응형 데이터 전처리를 통해 각 장치들의 에너지 부족 문제를 최소화하면서, 엷지 서버와 네트워크 트래픽의 과부하 문제를 해결할 수 있었고, 결과적으로 더욱 효율적인 실시간 딥러닝이 가능해질 수 있었다.

그런데, IoT 기기에서 여분의 에너지가 존재하지 않더라도, 데이터 전처리를 수행하여 엷지 서버로 보내는 것이, IoT 기기의 에너지 측면에서 유리할 경우도 존재한다. IoT 기기에서 전처리를 생략하고 보낸다면, 보내야 하는 데이터의 양이 커져서 오히려 전처리하는데 사용되는 에너지의 양보다 데이터를 보내는데 사용되는 에너지의 양이 더 커질 수 있기 때문이다. 따라서 향후 연구에서는, 여분의 에너지 뿐만 아니라, 데이터 전처리에 사용되는 에너지의 양과 데이터 전처리를 통해서 감소되는 데이터 전송 에너지를 함께 고려하여, 데이터 전처리 여부를 결정하는 기법에 대해 연구할 계획이다.

References

- [1] S. Sudevalayam, P. Kulkarni, "Energy Harvesting Sensor Nodes: Survey and Implications," *Journal of IEEE Communications Surveys and Tutorials*, Vol. 13, No. 3, pp. 443-461, 2011.
- [2] W. Yu, F. Liang, X. He, W. G. Hatcher, C. Lu, J. Lin, X. Yang, "A Survey on the Edge Computing for the Internet of Things," *Journal of IEEE Access*, Vol. 6, pp. 6900-6919, 2018.
- [3] Y. Yang, L. Wang, D. K. Noh, H. K. Le, T. F. Abdelzaher, "SolarStore: Enhancing Data Reliability in Solar-Powered Storage-centric Sensor Networks," *Proceedings of the 7th International Conference on Mobile Systems, Applications, and Services(MOBISYS)*, pp. 336-346, 2009.
- [4] I. J. Yoon, H. Kim, D. K. Noh, "Adaptive Data Aggregation and Compression to Improve Energy Utilization in Solar-powered Wireless Sensor Networks," *Journal of MDPI Sensors*, Vol. 17, No. 6, pp. 1226-1235, 2017.
- [5] M. J. Kang, I. Yoon, D. K. Noh, "Efficient Location Service for a Mobile Sink in Solar-Powered Wireless Sensor Networks," *Journal of MDPI Sensors*, Vol. 19, No. 6, pp. 272-282, 2019.

- [6] S. Ü. Sonmez, A. Varol, "New Trends in Speech Emotion Recognition, " Proceedings of 2019 7th International Symposium on Digital Forensics and Security (ISDFS), pp. 1-7, 2019.
- [7] J. P. Bello, C. Silva, O. Nov, R. L. Dubois, A. Arora, J. Salamon, C. Mydlarz, H. Doraiswamy, "Sonyc: A System for Monitoring, Analyzing, and Mitigating Urban Noise Pollution, " Journal of Communications of the ACM, Vol. 62, No. 2, pp. 68-77, 2019.
- [8] S. J. Kang, A. H. Yuh, "Real-Time Sound Event Classification for Human Activity of Daily Living using Deep Neural Network, " Proceedings of IEEE International Conferences on Internet of Things (iThings), pp. 83-88, 2021.
- [9] N. Turpault, S. Wisdom, H. Erdogan, J. Hershey, R. Serizel, E. Fonseca, P. Seetharaman, J. Salamon, "Improving Sound Event Detection in Domestic Environments Using Sound Separation, " Proceedings of Detection and Classification of Acoustic Scenes and Events, 2020.

Yeontae Yoo (유연태)



2021 Electronic Engineering (IT convergence) from Soongsil University (B.S.)
2022~Intelligent Systems from Soongsil University (M.S.)

Field of Interests: Internet of Things, Embedded System, Artificial Intelligence
Email: dbdusxo1203@soongsil.ac.kr

Dong Kun Noh (노동건)



2000 Computer Engineering from Seoul National University (B.S.)
2002 Electronic and Computer Engineering from Seoul National University (M.S.)
2007 Electronic and Computer Engineering from Seoul National University (Ph.D)

Career:

2007~2010 Post-doctoral Research Staff in UIUC
2018~2019, 2022 Visiting Scholar in UW-Madison
2012~Dept. of AI Convergence in Soongsil University (Prof.)
Field of Interests: Cyber-Physical System, Mobile Computing, Internet of Things
Email: dnoh@ssu.ac.kr