

태양 에너지 수집형 IoT 엣지 컴퓨팅 환경에서 효율적인 오디오 딥러닝을 위한 데이터 전처리 기법

유연태¹, 이창한², 허석문², 유나경², 김기훈², 이찬서², 노동건²

¹승실대학교 지능시스템학과

²승실대학교 AI융합학부

dbdusxo1203@soongsil.ac.kr, dlckdgs99@naver.com, tjrans303@soongsil.ac.kr,
y7858@naver.com, rlarlgnszx@naver.com, lcs0713v@gmail.com, dnoh@ssu.ac.kr

Efficient Data Preprocessing Scheme for Audio Deep Learning in Solar-Powered IoT Edge Computing Environment

Yeon-Tae Yoo¹, Chang-Han Lee², Seok-Mun Heo², Na-Kyung You²,

Ki-Hoon Kim², Chan-Seo Lee², Dong-Kun Noh²

¹Dept. of Intelligent Systems, Soongsil University

²School of AI Convergence, Soongsil University

요 약

태양 에너지 수집형 IoT 기기는 주기적으로 재충전되는 태양 에너지의 특성상, 에너지 소모를 최소화하기보다는 수집된 에너지를 최대한 유용하게 사용하는 것이 중요하다. 한편, 데이터 기밀성과 프라이버시, 응답속도, 비용 등의 이유로 클라우드가 아닌 데이터 소스 근처에서 머신러닝을 수행하는 엣지 AI에 대한 연구도 활발한데, 그 중 하나는 여러 IoT 장치들이 수집한 오디오 데이터를 활용하여, 다양한 AI 응용들을 IoT 엣지 컴퓨팅 환경에서 제공하는 것이다. 그러나, 이와 관련된 많은 연구에서, IoT 기기들은 에너지의 제약으로 인하여, 엣지 서버(IoT 서버)로의 센싱 데이터 전송만을 수행하고, 데이터 전처리를 포함한 모든 AI 과정은 엣지 서버에서 수행한다. 이 경우, 엣지 서버의 과부하 문제 뿐 아니라, 학습 및 추론에 불필요한 데이터까지도 서버에 그대로 전송되므로 네트워크 과부하 문제도 야기한다. 또한, 이를 해결하고자, 데이터 전처리 과정을 각 IoT 기기에 모두 맡긴다면, 기기의 에너지 부족으로 정전시간이 증가하는 또 다른 문제가 발생한다. 본 논문에서는 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 완화시키고자 한다. 제안 기법에서 IoT 장치는 기기가 기본적으로 동작하는 데 필요한 에너지 외의 여분의 에너지 양을 예측하고, 이 여분의 에너지가 있는 경우에만 이를 사용하여 기기에서 전처리 과정, 즉 수집 대상 소리 판별과 잡음 제거 과정을 거친 후 서버에 전송함으로써, IoT기기의 정전시간에 영향을 주지 않으면서, 에너지 적응적으로 데이터 전처리 위치(IoT기기 또는 엣지 서버)를 결정하여 수행한다.

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 예측가능성과 고밀도(15mW/cm²) 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 최소한, 기기가 소모하는 평균 에너지 양을 제공할 수

있는 에너지 수집 서브시스템(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 또 다시 충전될 것이고, 에너지를 저장할 축전기의 용량은 제한되어 있으므로, 배터리 기반 IoT 기기처럼 에너지를 최대한 아껴서 사용하기 보다는 에너지 사용률을 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]. Fig. 1과 같이, 엣지 컴퓨팅 환경은 일반적으로 IoT 기기들을

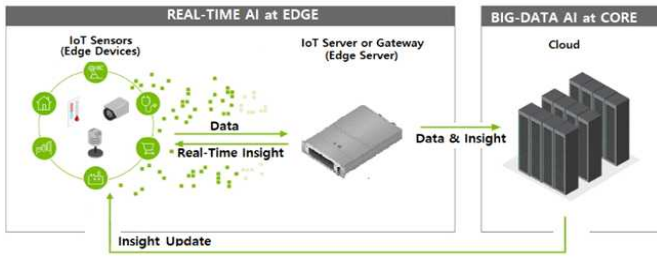


Fig 1. 엣지 컴퓨팅 환경의 구조

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 머신러닝을 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.

2. 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[3][4]. 다양한 종류의 오디오 데이터를 기계 학습에 사용하기 위해서는 양질의 소리 데이터를 분리하여 확보하는 데이터 기술[5][6]이 필요한데, 이는 수집 대상 소리 이외의 데이터나 잡음이 포함될 경우, 학습의 정확도가 떨어질 수 있기 때문이다. 이러한 작업을 일반적으로 데이터 전처리라고 부른다. 제안 기법에서는 엣지 서버에서의 효율적인 오디오 딥러닝 수행을 위하여, 각 태양 에너

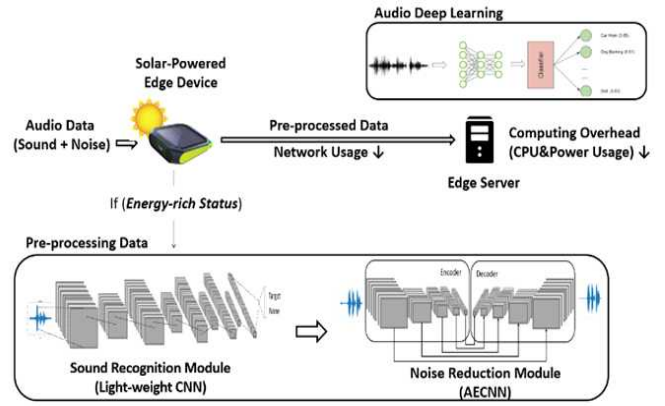


Fig 2. 제안 기법의 개요

지 수집형 IoT 기기의 잔여 에너지가 충분할 경우, 엣지 서버가 아닌 그 기기에서 데이터 전처리를 수행하는 기법을 제안한다.

2.1 전처리에 사용 가능한 에너지 양 계산

Fig. 2는 제안 기법의 전체적인 개요를 보여준다. 각 IoT 기기는 자신의 평균 에너지 수집량 및 소모량 정보를 통해 자신의 에너지 문턱값을 계산한다. 에너지 문턱값은, 그 기기의 평균적인 에너지 수집 속도와 소비 속도를 감안할 때, 기기가 정전시간 없이 동작하기 위하여 필요한 에너지 양이다. [7]의 연구에서는 이러한 에너지 문턱 값을 수학적으로 제시하고 있는데, 문턱 값은 아래 수식 (1)과 같다.

$$E_{\text{threshold}}(i) = \frac{P_{\text{sys}}(i)}{P_{\text{charge}}(i)} \cdot C(i) \quad (1)$$

여기서, $P_{\text{sys}}(i)$ 은 시스템 에너지 소모율, $P_{\text{charge}}(i)$ 은 에너지 수집률, $C(i)$ 은 재충전가능 배터리의 용량을 나타낸다. 따라서, 이 에너지 문턱값과 잔여 에너지 양을 비교하여 여분의 에너지 존재 여부를 판별하고, 현재 에너지 양이 더 많을 경우, 즉 문턱값 이상의 에너지가 존재할 경우, 이 에너지만을 이용하여 데이터 전처리를 자체적으로 수행한다.

2.2 전처리 과정 (소리 인식 모듈 및 잡음 감소 모듈)

엣지 디바이스의 전처리 과정은 경량 CNN 기반 소리 인식 모델을 통한 소리 판별과, AECNN 기반 잡음 감소 모델을 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. 결과적으로, 추후 불필요한 프로세싱과 데이터의 전송이 줄어들게 된다.

이후, 잡음 감소 모듈이 소리 데이터의 잡음을 감소시켜 명료한 소리 데이터를 만드는 역할을 한다. 잡음 감소를 위한 모델은 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 입출력 데이터 크기와 15x15 필터를 갖는 5개의 인코더 층과 5개의 디코더 층을 사용하고, 활성화 함수로 PReLU를 사용한 구조에서 총 257,928개의 파라미터를 사용한다.

제안 기법에서는 문턱값 이상의 에너지를 가진 노드들은, 이와 같은 전처리 과정을 수행하여, 저용량의 명료한 오디오 데이터를 얻을 수 있고, 이를 엣지 서버로 전송하여, 서버에서 전처리 과정을 생략하게 되고, 결과적으로 서버의 컴퓨팅 부하가 감소되고, 네트워크의 트래픽도 줄어들 수 있다. 그러나, 잔여 에너지가 문턱값보다 작은 기기들은 데이터 전처리를 수행하지 않고, 그대로 엣지 서버에 전송한다. 전처리를 수행하면 에너지가 고갈되어, 다음 주기에 에너지가 다시 수집될 때까지 정전상태가 될 수 있기 때문이다.

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 딥러닝 수행이 가능하게 되고, IoT 기기들의 정전시간에도 영향을 주지 않는다.

2.3 성능검증

제안 기법의 성능 검증을 위해, 데이터 전처리를 엣지 서버에서 모두 수행했을 경우와 엣지 기기에서 모두 수행했을 경우의 엣지 서버의 평균 CPU 점유율과 엣지 서버가 수신하는 데이터 크기, 그리고 IoT 기기들의 수행시간 대비 정전시간 비율을 제안 기법과 비교하였다. 자세한 실험환경은 지면관계상 생략한다. 결과를 요약하면 표 1과 같이 제안 기법 에너지 적응적으로 동작하여 이 다른 두 기법의 장점을 모두 흡수하고 있음을 알 수 있다.

3. 결론

태양 에너지 수집형 IoT에서는 발생 가능한 여분

표 1. 전처리 위치에 따른 성능 지표

| 전처리 위치 | 엣지 서버 | IoT 기기 | 제안기법 (에너지 적응적 전처리 위치 선택) |
|---------------------|-------|--------|-----------------------------|
| 엣지 서버 평균 CPU 점유율(%) | 57.5 | 7.3 | 32.2 |
| 엣지 서버 수신 데이터 크기(MB) | 110.6 | 31.1 | 72.6 |
| IoT기기 정전시간 비율(%) | 2.1 | 64.8 | 2.7 |

의 에너지를 효율적으로 사용하는 것이 중요하다. 제안 기법에서는 태양 에너지 수집형 IoT 엣지 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 엣지 서버에 전송한다. 이러한 에너지 적응형 데이터 전처리를 통해 각 장치들의 에너지 부족 문제를 최소화하면서, 엣지 서버와 네트워크 트래픽의 과부하 문제를 해결할 수 있었고, 결과적으로 더욱 효율적인 실시간 딥러닝이 가능해질 수 있었다.

ACKNOWLEDGMENT

본 연구는 과학기술정보통신부 및 정보통신기획평가원의 SW중심대학사업의 연구결과로 수행되었음 (2018-0-00209)

참고문헌

[1] Sudevalayam, S. & Kulkarni, P. Energy Harvesting Sensor Nodes: Survey and Implications. IEEE Communications Surveys and Tutorials. 13, 3, 445-461(2011)

[2] Yu, W. et al. A Survey on the Edge Computing for the Internet of Things. IEEE Access. 6, 6900-6919(2018)

[3] Sonmez, Y. Ü. & Varol, A. New trends in speech emotion recognition. International Symposium on Digital Forensics and Security (ISDFS). 1-7(2019)

[4] Juan, B. P. et al. Sonyc: A system for monitoring, analyzing, and mitigating urban noise pollution. Communications of the ACM. 62, 2, 68-77(2019)

[5] Kang, S. J. & Yuh, A. H. Real-Time Sound Event Classification for Human Activity of Daily Living using Deep Neural Network. IEEE International Conferences on Internet of Things (iThings), 83-88, (2021)

[6] Turpault, N. et al. Improving sound event detection in domestic environments using sound separation. arXiv preprint arXiv:2007. 03932, (2020)

[7] Yang, Y. et al. SolarStore: Enhancing Data Reliability in Solar-Powered Storage-centric Sensor Networks. ACM International Conference on Mobile System, Application and Services (MOBISYS), 336-346, (2009)