

Multi-GPU 환경에서의 Convolution Layer 최적화 실험

하지원¹, 테오도라 아두푸², 김윤희²

¹고려대학교 컴퓨터학과

²숙명여자대학교 컴퓨터과학과

jwh0245@naver.com, theoadufu@sookmyung.ac.kr, yulan@sookmyung.ac.kr

Empirical Experiments for Convolution Layer Optimization on Multi-GPUs

Jiwon Ha¹, Theodora Adufu², Yoonhee Kim²

¹Dept. of Computer Science and Engineering, Korea University

²Dept. of Computer Science, Sookmyung Women's University

요약

GPGPU 환경에서의 ML 모델이 다양한 분야에 지속적으로 활용되면서, 이미지 분할(image segmentation) 연구가 활발하다. multi-GPU 환경에서 성능 최적화를 위하여 병렬화 기법들이 활용되고 있다. 본 연구에서는 multi-GPU 환경에서 U-Net 모델의 전체 수행 시간을 단축하기 위해 convolution 연산을 최적화하는 기법을 적용하는 실험을 진행하였고 shared memory, data parallelism 를 적용하여 82% 성능 향상을 보여주었다.

1. 서론

CPU 를 사용한 모델 학습은 학습 데이터의 크기가 클 경우 지나치게 많은 시간이 소모되어 실험을 진행하는 데에 현실적인 어려움이 있다. 특히 이미지 데이터의 경우, 데이터의 크기와 개수가 늘어날수록 학습에 필요한 연산이 크게 증가한다. Yadan et al. [1]의 “Multi-GPU Training of ConvNets”에 따르면, CPU 환경과 비교하여 multi-GPU 환경에서 CNN (Convolutional Neural Network) 모델에 data parallelism 와 model parallelism 를 적용하였을 때, 2 GPUs model parallelism 의 경우 약 37%, 2 GPUs data parallelism 의 경우 약 33%, 4 GPUs model parallelism, data parallelism 를 병행하는 경우 약 54%의 speedup 이 가능하다.

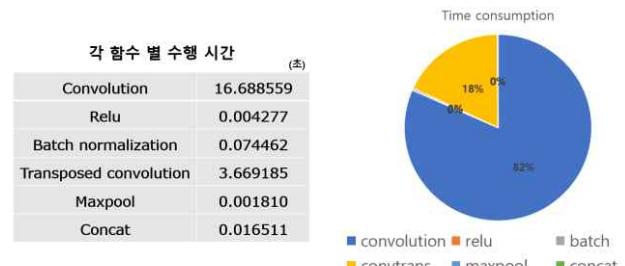
GPGPU(General-Purpose computing on Graphics Processing Units) 환경에서의 ML(Machine Learning) 모델이 다양한 분야에 지속적으로 활용되면서[2], 이미지로부터 객체를 추출하여 특정 클래스로 분류하는 이미지 분할(image segmentation) 연구가 활발하다. 의료 영상 분석, 자동차 자율주행 등 ML 모델이 사용되는 여러 task 들에서 물체를 구분하는 기능이 우선 수행되어야 하기 때문이다. 이미지 분할 모델 중에서도 2015년 발표된 U-Net 모델은[3] 현재까지도 많은 모델의 base line 이 될 정도로 이미지 분할에서 우수한 성능을 보여준다.

본 연구에서는 multi-GPU 환경에서 U-Net 모델 전

체의 수행 시간을 단축하기 위해 convolution 연산을 최적화하는 기법을 설명한다. 2 장에서는 실험의 구조, 3 장에서는 실험 결과를 설명하고 4 장에서 결론을 맺는다.

2. 실험 내용

U-Net 은[4] 크게 Encoder, Decoder 2 가지 요소로 구성된다. 두 단계 모두 convolution 연산이 반복적으로 수행된다. convolution 연산은 Relu, batch normalization 등 다른 연산에 비해 계산 과정이 복잡하다.



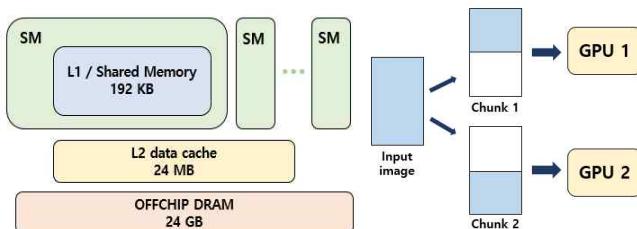
(표 1) 함수 수행 시간 (그림 1) 함수 수행 시간 비율

표 1, 그림 1 은 NVIDIA A30 머신 CPU(Intel® Xeon® Silver 4310 CPU @ 2.10GHz, 2699.998MHz, 12 CPU cores)에서 U-Net 으로 128*191 해상도의 3 channels 이미지 1 개를 처리하는 데에 함수 별 수행 시간을 정리한 것이다. U-Net 의 수행 시간의 82%가

convolution 수행에 소요되는 것을 확인할 수 있다. 실제로 convolution 연산은 VGG, ResNet과 같은 CNN 모델 수행 시간의 70% 이상을 차지한다[5], [6]. 따라서 모델 전체의 성능 향상을 위해 convolution 연산의 최적화가 중요하다.

Convolution 최적화를 위해 실험에 사용할 최적화 기법은 크게 2 가지다. 첫 번째는 GPU의 메모리 구조 중 shared memory를 이용한 tiling 기법이다. GPU의 SM(Streaming Multiprocessor)은 SM 내부에 고유한 shared memory를 가진다(그림 2의 shared memory block 참조). shared memory로의 접근은 off-chip 메모리인 글로벌 메모리에 접근하는 것보다 약 100배 빠르므로 최적화에 사용할 수 있다. 실험에서는 convolution 연산에 사용되는 input과 filter weight를 shared memory에 올린다.

두 번째 최적화 기법은 multi-GPUs, multi-streams을 이용한 data parallelism이다. 그림 3은 전체 데이터를 2개의 chunk로 분할한 data parallelism 예시이다. convolution 연산의 경우 각 데이터 간의 의존성(dependency)이 존재하지 않으므로 데이터 분할이 자유롭다.



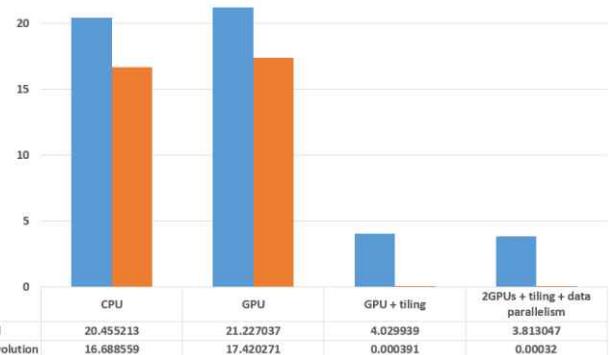
(그림 2) GPU 메모리 구조[2] (그림 3) data parallelism

3. 실험 결과

학습 데이터는 128*191 해상도의 3 channels 이미지 데이터를 사용한다. 우선 최적화하지 않은 기본 모델을 각각 CPU, NVIDIA A30 머신(Compute capability 8.0, Device memory 24GB) GPU에서 학습시킨다. 이어서 tiling 기법을 적용한 모델을 1 GPU에서 학습시키고 tiling과 data parallelism 기법을 적용한 모델을 2 GPUs 환경에서 학습시킨다.

실험 결과, 수행 시간은 그림 4와 같다. 최적화하지 않은 모델을 GPU에서 훈련시켰을 때 convolution 연산에 소요되는 시간은 CPU에 비해 약 0.74초 증가하였다. CPU에서 GPU로 데이터를 transfer하는 데에 소요되는 시간이 영향을 미치기 때문에 추정된다. 최적화한 모델에서 convolution 연산에 소요되는 시간은 CPU 16.6초에서 1 GPU 0.00039초, 2 GPUs 0.00032초로 크게 감소하였다. U-Net의 전체 학습 시간 또한 20.4초에서 1 GPU 4.0초로 약 80%, 2 GPUs 3.8초로

약 81% 속도가 향상되었다. 최적화한 모델이 1 GPU와 2 GPUs에서 큰 성능 차이가 나지 않는 이유는 데 이터셋의 크기가 충분히 크지 않기 때문으로 추정된다.



(그림 4) 실행 환경에 따른 실행 시간 비교

4. 결론

Multi GPUs 환경에서 convolution 연산을 최적화하는 기법(shared memory, data parallelism)을 통하여 U-Net의 성능을 향상하였다. 다른 최적화 기법들을 추가로 적용하여 convolution layer를 포함하는 VGG, ResNet 등 여러 CNN 모델의 수행 시간 성능 향상을 실험할 예정이다.

이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원(No. 2021R1A2C1003379)과 2023년도 정부재원(과학기술정보통신부 여대학원생 공학연구팀제 지원사업)으로 과학기술정보통신부와 한국여성과학기술인육성재단의 지원을 받아 연구되었습니다.

참고문헌

- [1] Omry Yadan et al., "Multi-GPU Training of ConvNets", arXiv:1312.5853, pp 1, 2014
- [2] Jieun Kim et al., "Empirical experiments of profiled data locality for memory-divergent workloads on GPU", KNOM Review Vol.25, No.01, Jan 2022
- [3] Olaf Ronneberger et al., "U-Net: Convolutional Networks for Biomedical Image Segmentation", MICCAI 2015, pp 234-241, May 2015
- [4] Kyung-Min Gwak et al., "Tracking Method of Dynamic Smoke based on U-net", IIBC Vol. 21, No.4, pp 81-87, Aug 31, 2021
- [5] X. Li, et al. "Performance Analysis of GPU-Based Convolutional Neural Networks," 2016 45th International Conference on Parallel Processing (ICPP), Philadelphia, PA, pp. 67-76, 2016
- [6] Xu QQ, An H, Wu Z, Jin X. "Hardware Design and Performance Analysis of Mainstream Convolutional Neural Networks". Computer Systems and Applications, 29(2): 49-57(in Chinese), 2020