

저계수행렬 근사 및 CP 분해 기법을 이용한 CNN 압축

문현철, 문기화, 김재곤

한국항공대학교

{hcmoon, rlghk1461}@kau.kr, jgkim@kau.ac.kr

Compression of CNN Using Low-Rank Approximation and CP
Decomposition Methods

Hyeon-Cheol Moon, Gi-Hwa Moon, and Jae-Gon Kim

Korea Aerospace University

요 약

최근 CNN(Convolutional Neural Network)은 영상 분류, 객체 인식 등 다양한 비전 분야에서 우수한 성능을 보여주고 있으나, CNN 모델의 계산량 및 메모리가 매우 커짐에 따라 모바일 또는 IoT(Internet of Things) 장치와 같은 저전력 환경에 적용되기에는 제한이 따른다. 따라서, CNN 모델의 임무 성능을 유지하면서 네트워크 모델을 압축하는 기법들이 연구되고 있다. 본 논문에서는 행렬 분해 기술인 저계수행렬 근사(Low-rank approximation)와 CP(Canonical Polyadic) 분해 기법을 결합하여 CNN 모델을 압축하는 기법을 제안한다. 제안하는 기법은 계층의 유형에 상관없이 하나의 행렬분해 기법만을 적용하는 기존의 기법과 달리 압축 성능을 높이기 위하여 CNN의 계층 타입에 따라 두 가지 분해 기법을 선택적으로 적용한다. 제안기법의 성능검증을 위하여 영상 분류 CNN 모델인 VGG-16, ResNet50, 그리고 MobileNetV2 모델 압축에 적용하였고, 모델의 계층 유형에 따라 두 가지의 분해 기법을 선택적으로 적용함으로써 저계수행렬 근사 기법만 적용한 경우 보다 1.5 ~ 12.1 배의 동일한 압축율에서 분류 성능이 향상됨을 확인하였다.

1. 서론

CNN(Convolutional Neural Network)을 기반으로 하는 인공지능망은 최근 컴퓨터 비전, 영상 인식 및 화질 개선 등 다양한 응용에서 뛰어난 성능을 보이고 있다. 그러나, 성능의 향상을 위한 계층의 깊이 및 학습할 가중치(weight) 수의 증가로 모델의 크기 및 추론 과정에서 접근해야 할 특징 맵(feature map)을 저장하기 위한 메모리가 크게 증가하게 되었다. 이에 따라 연산 속도나 메모리가 제한된 모바일 및 IoT 기기에 인공지능망을 추론하기에는 제한이 따른다. 따라서, 기존의 학습된 네트워크 모델의 성능을 최대한 유지하면서 모델의

크기를 줄이는 인공지능망 압축 기법들이 연구되고 있다[1].

CNN 모델을 압축하는 기법은 각 모델에 포함된 가중치의 수를 줄이는 데에 중점을 두고 있다. 대표적인 기법으로는 모델의 성능에 큰 영향을 주지 않은 가중치와 노드의 연결을 끊는 가지치기(pruning) 기법 [2]과 가중치 행렬을 2 개 이상의 행렬로 분해하여 가중치의 수를 줄이는 행렬 분해 기법 등이 있다[3].

본 논문에서는 행렬 분해 기술인 저계수행렬 근사(LR: Low-Rank approximation)와 CP(Canonical Polyadic) 분해 기법을 결합하여 CNN 모델을 압축하는 기법을 제안한다.

2. 행렬 분해 기법

행렬 분해 기법은 2 차원 이상의 CNN 각 계층의 가중치 행렬을 2 개 이상의 행렬로 분해함으로써 가중치의 수 및 연산량을 줄이는 방법이다. 대표적인 행렬 분해 기법은 2 차원 행렬을 SVD(Singular Value Decomposition) 기법을 이용하여 2 개의 행렬로 분해하는 저계수행렬 근사 기법과 3 차원 이상의 행렬을 다수의 계수(rank)-1 텐서(tensor)의 선형결합 형태로 분해하는 CP 분해 기법 등이 있다.

저계수행렬 근사 기법은 2 차원 행렬을 SVD 분해 기반으로 2 개의 2 차원 행렬로 분해하는 것으로 식 (1)과 같이 표현된다.

$$W_i = U_i V_i^T \quad (1)$$

여기서 W_i, U_i, V_i^T 는 각각 $M \times N, M \times R, R \times N$ 크기를 가지며, W_i 는 각 CNN 모델의 i 번째 층의 가중치 행렬을 의미하며, U_i, V_i^T 는 i 번째 층의 가중치 행렬로부터 분해되는 행렬을 의미한다.


CP 는 3 차원 이상의 고차원 텐서들을 rank-1 텐서들의 선형결합으로 분해한다. 예를 들어, 식 (2)와 같이 3차원 텐서 X 를 R 개로 이루어진 3개의 rank-1의 텐서로 분해할 수 있다. 여기서 R 은 계수 값이고, 해당 기법을 적용하기 위해 입력되는 하이퍼 파라미터(hyper parameter)이다. 따라서, R 값에 따라 압축율이 상대적으로 결정된다.

$$X \equiv \sum_{r=1}^R a_r \otimes b_r \otimes c_r \quad (2)$$

본 논문에서는 4 차원 기반의 컨볼루션(convolution) 가중치 텐서들을 CP 분해 기법을 적용하여 압축한다[4]. 2D 기반의 컨볼루션 층의 가중치 값들은 4D 형태(2D 필터 크기, 입력채널 수, 출력채널 수)로 구성되어 있다. 따라서, 컨볼루션 가중치 텐서 K 에 대한 CP 분해는 다음 식 (3)과 같으며, 본 논문에서는 3 개의 계층으로 분해하는 기법을 제시한다.

$$K_{t,s,j,i} \equiv \sum_{r=1}^R U_{r,s}^{(1)} U_{r,j,i}^{(2)} U_{t,r}^{(3)} \quad (3)$$

여기서 $U_{r,s}^{(1)}, U_{r,j,i}^{(2)}, U_{t,r}^{(3)}$ 는 각각 $R \times S, R \times D \times D, R \times T$ 크기를 가진다. 이 때, S 와 T 는 각각 입력과 출력의 채널 수, $D \times D$ 는 컨볼루션 필터 크기를 의미한다. 따라서, $U_{r,s}^{(1)}, U_{t,r}^{(3)}$ 은 필터 크기가 1 인 Pointwise(PW) 컨볼루션 층의 형태로 구성되며, $U_{r,j,i}^{(2)}$ 는 필터 크기가 $D \times D$ 인 Depthwise(DW) 컨볼루션 층으로 구성된다. 그림 1 은 식 (3)을 그림으로 나타낸 것이다. 따라서, 결국 하나의 컨볼루션 층을 2 개의 Pointwise, 1 개의 Depthwise 컨볼루션 층으로 분해하게 된다.



(a) 컨볼루션 층 (b) CP 분해된 컨볼루션 층
그림 1. CP 분해 기법[4]

3. 실험결과

표 1 은 압축을 하지 않은 원본 모델의 성능으로 Top-5 Accuracy 는 모델로부터 예측된 클래스 중 상위 5 개에 정답이 있을 경우의 정확도를 의미한다. 성능을 측정하기 위해 사용된 데이터셋은 ILSVRC(ImageNet Large Scale Visual Recognition Competition) 2012 의 검증(validation) 데이터셋 50,000 개에 영상에 대한 분류 성능이다[5]. 표 2는 본 논문에서의 각 실험 별 조건을 나타낸 것이다. 기존의 기법들은 계층의 유형에 상관없이 단일 분해 기법들을 적용하였다. 따라서, 기존의 기법 대비 성능 향상을 위해 각 실험에서는 계층의 유형에 따라 적용하는 행렬 분해 기법들을 다르게 적용하였다. 완전 연결(FC: Fully-Connected) 층의 경우 모든 실험조건에서 저계수행렬 근사(LR) 기법을 적용하였고, 컨볼루션 층에는 2 개의 기법을 모두 선택적으로 적용하였다. 또한, 해당 실험에서 단순히 행렬 분해 기법만을 적용하면 성능의 손실이 발생하는 관계로 별도의 재학습(Re-training)을 적용하였으며, 재학습을 위해 ILSVRC 2012의 학습 데이터 셋을 사용하였다.

Table 1. 원본 모델 성능 (ILSVRC 2012)

Model	Model Size (MB)	Top-5 Accuracy (%)
VGG-16	527.0	90.05
ResNet50	98.2	91.93
MobileNetV2	13.8	90.06

Table 2. 실험 조건

	Layer Type		
	2D Conv.	PW & DW Conv.	FC
Baseline (LR)	LR	LR	LR
Test 1	CP	CP	
Test 2	CP	LR	

표 3 은 행렬 분해 기법을 적용한 경우의 압축 성능 실험결과이다. 각 실험별 압축율은 Baseline 으로 가정한 LR 기법을 적용한 압축된 모델의 Top-5 분류 성능이 원본 모델 대비 3% 미만의 손실일 때를 기준으로 하였다. 행렬 분해 기법이 임무 성능 손실 없이 주어진 모델을 1.5~12.1 배 압축함을 확인하였으며, 특히 VGG-16 에서는 기존의 가지치기 기법 [1] 대비 약 1.3 배 더 압축이 됨을 보여준다. 또한, 저계수행렬 근사 기법만을 적용한 Baseline 기법보다 계층의 유형에 따라 LR 과 CP 기법을 선택적으로 적용한 제안 기법이 VGG-16, ResNet50 에서 영상 분류 성능 향상이 있음을 확인하였다.

그림 2 는 ResNet50 에서의 각 실험 별 성능 압축율에 따른 성능을 나타낸 것이다. 컨볼루션 층에서 오직 CP 를 적용한 Test 1 이 Baseline 기법보다 전체 압축율 구간에서 분류 성능이 감소되었지만, 컨볼루션 층의 유형에 따라 선택적으로 분해 기법을 적용한 Test 2 에서는 낮은 압축율 범위(0.35 ~ 0.45) 에서는 기존 Baseline 기법보다 분류 성능의 향상이 있음을 확인하였다.

Table 3. 실험결과

Model	Test	Top-5 Accuracy (%)	Compression ratio (x)
VGG-16	Baseline	87.92	12.1
	Test 1	88.11	
	Hans [1]	88.05	9.0
ResNet50	Baseline	89.44	2.86
	Test 1	88.79	
	Test 2	89.87	
MobileNetV2	Baseline	88.20	1.54
	Test 1	88.07	




그림 2. ResNet50 에서의 압축률에 따른 분류 성능

4. 결론

본 논문에서는 행렬 분해 기술인 저계수행렬 근사(Low-rank approximation)와 CP(Canonical Polyadic) 분해 기법을 이용하여 학습된 CNN 모델을 압축하는 기법을 제안하였다. 영상 분류의 대표적 CNN 모델인 VGG-16, ResNet50, 그리고 MobileNetV2 에 대하여 2 가지의 행렬 분해 기술을 선택적으로 적용한 제안 기법의 압축 성능을 검증하였고, 실험결과 LR 와 CP 분해 기법을 컨볼루션 계층의 유형에 따라 선택적으로 적용하는 제안 기법이 단일 행렬 분해 기법을 적용한 경우보다 압축 성능 향상이 있음을 확인하였다.

Acknowledgement

이 논문은 2020 년도 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(No. 2020R1F1A1068106).

참 고 문 헌

- [1] S., Han, et al, "Deep Compression: Compressing Deep Neural Networks with pruning, trained quantization and Huffman coding," Computer Vision and Patter Recognition, In Proc. ICLR 2016, May 2016.
- [2] C. Aytekin, F. Cricri, T. Wang, E. Aksu, "Response to the Call for Proposals on Neural Network Compression: Training Highly Compressible Neural Networks," ISO/IEC JTC1/SC29/WG11, m47379, Mar. 2019.
- [3] M. Jaderberg, A. Vedaldi, and A. Zisserman, "Speeding up Convolutional Neural Networks with Low Rank Expansions," In Proc. CVPR, Jun. 2014.
- [4] V. Lebedev, Y. Ganin, M. Rakhuba, I. Oseledets, and V. Lempitsky, "Speding-up Convolutional Neural Networks Using Fine-tuned CP-Decomposition," In Proc. CVPR, Jun. 2015.
- [5] [Available at Online] <http://www.image-net.org/challenges/LSVRC/2012/>