KOREA UNIVERSITY

2024 Summer Seminar

LoftQ | Divergent Token Metrics

김민혁

Preview

- LlAMA 3 - 8B, 70B
  - 8B 모델 실행에만 최소 16GB RAM
  - Fine-tuning을 위해선 고성능의 GPU 필요

Preview

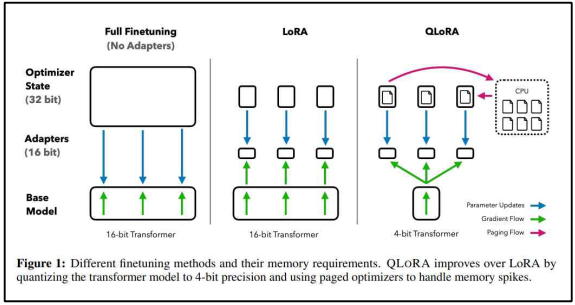

Figure 1: Different finetuning methods and their memory requirements. QLoRA improves over LoRA by quantizing the transformer model to 4-bit precision and using paged optimizers to handle memory spikes.

- QLoRA
  - Fine-tuning에 드는 컴퓨팅 자원을 최소화할 수 있는 기법

Preview

- On-Device AI
  - 모델의 구동 환경을 개인의 디바이스에 이르게끔 최적화
  - 삼성, 애플 등이 자사 제품에 On-Device AI를 적용하기 시작

Preview

원래 모델과 경량화된 모델 간의 격차를 어떻게 좁힐 것인가?

- LoftQ: LoRA-Fine-Tuning-Aware Quantization for Large Language Models
- Divergent Token Metrics: Measuring degradation to prune away LLM components – and optimize quantization

KOREA UNIVERSITY

LoftQ: LoRA-Fine-Tuning-Aware Quantization for Large Language Models

ICLR 2024

김민혁

Goal

- Full fine-tuning과 QLoRA fine-tuning 사이의 성능 차이가 발생함
  - LoFTQ(논문에서 제안하는 새로운 Quantization framework)로 이러한 차이를 최소화

Abstract

- Downstream task에서 Full fine-tuning과 QLoRA fine-tuning의 성능 차이가 나타남
- 논문에서 제안하는 LoftQ는 LLM을 양자화함과 동시에 적절한 Low-rank 초기화 값을 찾음
  - 이러한 초기화는 Quantized 모델과 Full-precision model 간의 차이를 완화함
  - Quantized 모델의 Downstream tasks 성능을 향상시킴
- 실험 결과 기존의 Quantization 기법의 성능을 능가함
  - 특히 2-bit, 2/4-bit mixed precision에서 성능 향상 폭이 컸음

Background - Quantization

$$X^{\text{INT}} = \text{round}\left((2^N - 1)F\left(X^{\text{HP}}\right)\right)$$

- Quantization
  - F는 정규화 함수 (F에 따라 Uniform / Normal Float Quantization으로 구분됨)
  - Normal Float Quantization은 X(가중치)가 중심극한정리에 따라 표준 정규 분포를 따른다고 가정함
- Dequantization은 해당 과정을 역으로 적용

Background - LoRA

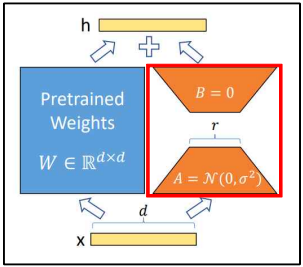

- Fine-tuning 비용을 줄이기 위해서 기존 가중치 값은 변경하지 않고, Low-rank Adaptor을 붙이고 해당 부분만 학습하는 방식

Background - LoRA

$$Y = XW + XAB^{\top}$$

- 선형 변환 **Y = XW** 의 Pre-trained 가중치 행렬 W에 두 개의 작은 가중치 행렬 A, B이 붙음
- A ~ N(0,σ ^2), B = 0 로 초기화 되며, Fine-tuning 동안 해당 값을 업데이트

Background - LoRA

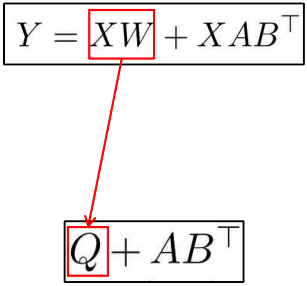

- Quantization + LoRA를 하게 되면, 기존 가중치 행렬 W와의 차이가 발생함
  - Quantization이 된 Q(W)에 이미 W와의 약간의 차이가 생겼고, 이후 A,B를 더하며 성능 저하를 초래함

Introduction

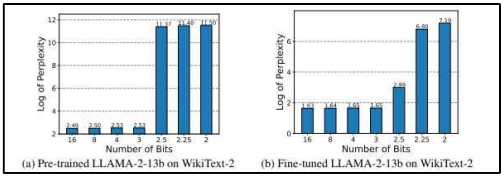

(a) Pre-trained LLAMA-2-13b on WikiText-2 (b) Fine-tuned LLAMA-2-13b on WikiText-2

- Pre-trained 모델을 Quantizing할 때 Quantization 기법 자체에 초점을 두는 경우가 많음
  - 따라서 LoRA fine-tuning시 0으로 초기화된 Low rank adapter을 붙이는 경우가 많음
  - 그러나 이러한 방식의 QLoRA는 3-bit 이하로 Quantization을 진행할 때 심각한 성능 저하를 보임

Introduction

- 본 논문에서는 LoftQ(**Lo**RA-**F**ine-**T**uning-aware Quantization)을 제안함
  - Quantization과 Low-rank approximation을 공동으로 진행

Method

$$\min_{Q,A,B} \left\| W - Q - AB^{\top} \right\|_F$$

- LoRA Aware Quantization
  - 양자화된 Q와 어댑터 A, B의 초기 값을 공동으로 최적화
- 프로베니우스 Norm 사용
- W = Q + AB 가 되도록 최적화

Method

$$Q_t = q_N(W - A_{t-1}B_{t-1}^\top)$$

- Alternating Optimization - Quantization

T만큼 반복

$$R_t = \sum_{i=1}^{d} \sigma_{t,i} u_{t,i} v_{t,i}^\top$$

- Alternating Optimization - SVD
  - W - Q 에 대한 잔차 R 에 특이값 분해를 적용

Method

$$A_t = [\sqrt{\sigma_{t,1}}u_{t,1}, ..., \sqrt{\sigma_{t,r}}u_{t,r}]$$
$$B_t = [\sqrt{\sigma_{t,1}}v_{t,1}, ..., \sqrt{\sigma_{t,r}}v_{t,r}].$$

- A,B를 통해 잔차 R을 비교적 정확히 계산할 수 있음
  - 이를 통해 원래의 가중치 행렬 W를 비교적 정확히 계산할 수 있음

Method

Algorithm 1 LoftQ

input Pre-trained weight W, target rank r, N-bit quantization function $q_N(\cdot)$, alternating step T

Initialize $A_0 \leftarrow 0, B_0 \leftarrow 0$

for t = 1 to T **do**

  Obtain quantized weight $Q_t \leftarrow q_N(W - A_{t-1}B_{t-1}^\top)$

  Obtain low-rank approximation $A_t, B_t \leftarrow \text{SVD}(W - Q_t)$ by (9)

end for

output Q_T, A_T, B_T

Experiments - Settings

- Models
  - DeBERTaV3-base (Encoder ONLY), BART-large (Encoder-Decoder), LLAMA-2 series (Decoder ONLY)
- Quantization Methods
  - Uniform Quantization
  - NF4, 2-bit variant NF2

Experiments - Results

Rank	Method	MNLI m / mm	QNLI Acc	RTE Acc	SST Acc	MRPC Acc	CoLA Matt	QQP Acc	STSB P/S Corr	SQuAD EM/F1	ANLI Acc
-	Full FT	90.5/90.6	94.0	82.0	95.3	89.5/93.3	69.2	92.4/89.8	91.6/91.1	88.5/92.8	59.8
16	LoRA	90.4/90.5	94.6	85.1	95.1	89.9/93.6	69.9	92.0/89.4	91.7/91.1	87.3/93.1	60.2
16	QLoRA	75.4/75.6	82.4	55.9	86.5	73.8/82.8	N.A.	86.8/82.3	83.0/82.8	61.5 / 71.2	N.A.
	LoftQ	**84.7/85.1**	**86.6**	**61.4**	**90.2**	**83.8/88.6**	**37.4**	**90.3/86.9**	**87.1/86.9**	**81.5/88.6**	**47.1**
32	QLoRA	78.5/78.7	80.4	56.7	86.9	73.8/82.7	N.A.	87.1/82.7	83.6/83.3	64.6/73.8	N.A.
	LoftQ	**86.0/86.1**	**89.9**	**61.7**	**92.0**	**83.6/87.2**	**47.5**	**91.0/87.9**	**87.5/87.0**	**82.9/89.8**	**49.0**

- DeBERTa V3-base (Encoder ONLY) / NF2 Quantization / GLUE, SQuADv1.1
- N.A.는 모델이 converge할 수 없었던 경우

Experiments - Results

Rank	Method	MNLI m / mm	QNLI Acc	RTE Acc	SST Acc	MRPC Acc	CoLA Matt	QQP Acc	STSB P/S Corr	SQuAD Em/F1
-	Full FT	90.5/90.6	94.0	82.0	95.3	89.5/93.3	69.2	92.4/89.8	91.6/91.1	88.5/92.8
16	LoRA	90.4/90.5	94.6	85.1	95.1	89.9/93.6	69.9	92.0/89.4	91.7/91.1	87.3/93.1
16	QLoRA	76.5/76.3	83.8	56.7	86.6	75.7/84.7	N.A	87.1/82.6	83.5/83.4	69.5/77.6
	LoftQ	**87.3/87.1**	**90.6**	**61.1**	**94.0**	**87.0/90.6**	**59.1**	**90.9/88.0**	**87.9/87.6**	**84.4/91.2**
32	QLoRA	79.9/79.5	83.7	57.8	86.9	76.5/84.5	N.A	88.6/84.7	84.1/84.0	71.6/80.2
	LoftQ	**88.0/88.1**	**92.2**	**63.2**	**94.7**	**87.5/91.2**	**60.5**	**91.3/88.3**	**89.5/89.2**	**85.2/91.6**

- DeBERTa V3-base (Encoder ONLY) / Uniform Quantization / GLUE, SQuADv1.1

Experiments - Results

Quantization	Rank	Method	XSum	CNN/DailyMail
Full Precision	-	Lead-3	16.30/1.60/11.95	40.42/17.62/36.67
		Full FT	45.14/22.27/37.25	44.16/21.28/40.90
	8	LoRA	43.40/20.20/35.20	44.72/21.58/41.84
	16	LoRA	43.95/20.72/35.68	45.03/21.84/42.15
NF4	8	QLoRA	42.91/19.72/34.82	43.10/20.22/40.06
		LoftQ	**44.08/20.72/35.89**	**43.81/20.95/40.84**
	16	QLoRA	43.29/20.05/35.15	43.42/20.62/40.44
		LoftQ	**44.51/21.14/36.18**	**43.96/21.06/40.96**
Uniform	8	QLoRA	41.84/18.71/33.74	N.A.
		LoftQ	**43.86/20.51/35.69**	**43.73/20.91/40.77**
	16	QLoRA	42.45/19.36/34.38	43.00/20.19/40.02
		LoftQ	**44.29/20.90/36.00**	**43.87/20.99/40.92**

- BART-large (Encoder-Decoder) / XSum, CNN/DailyMail

Experiments - Results

Rank	Method	XSum	CNN/DailyMail
8	QLoRA	N.A.	N.A.
	LoftQ	39.63/16.65/31.62	42.24/19.44/29.04
16	QLoRA	N.A.	N.A.
	LoftQ	40.81/17.85/32.80	42.52/19.81/39.51

- BART-large (Encoder-Decoder) / NF2 Quantization / XSum, CNN/DailyMail
- LoftQ의 N-bit 양자화에 대한 Robustness

Experiments - Results

Method	Bit	LLAMA-2-7b		LLAMA-2-13b	
		WikiText-2↓	GSM8K↑	WikiText-2↓	GSM8K↑
LoRA	16	5.08	38.5	5.12	48.8
QLoRA	4	5.70	**38.2**	5.22	48.8
LoftQ	4	**5.24**	38.0	**5.16**	**49.1**
QLoRA	3	5.73	32.1	5.22	40.7
LoftQ	3	**5.63**	**36.2**	**5.13**	**45.4**
QLoRA	2.5	N.A.	N.A.	19.39	N.A.
LoftQ	2.5	5.78	**31.1**	5.22	**41.1**
QLoRA	2.25	N.A.	N.A.	N.A.	N.A.
LoftQ	2.25	**6.13**	**27.5**	**5.45**	**38.1**
QLoRA	2	N.A	N.A.	N.A.	N.A.
LoftQ	2	**7.85**	**26.5**	**7.69**	**33.4**

- LLAMA-2 series (Decoder ONLY) / WikiText-2 and GSM8K

Experiments - Results

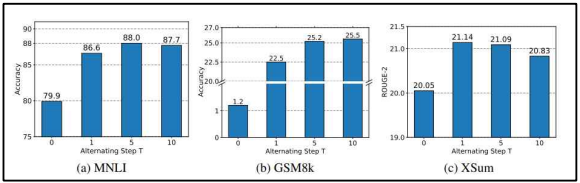

- Alternating Optimization의 반복 횟수 T 값에 따른 성능 비교
- Uniform 2-bit DeBERTaV3-base (왼쪽), NF2 2-bit LLAMA-2-13b (중간), NF4 BART-large (오른쪽)
- 일정 반복 횟수가 지나면 성능 저하가 발생함
  - 갭이 작아질수록 Alternating Optimization이 각 단계에서 일관되게 갭을 최소화하는 것이 어려워짐
  - 양자화 과정으로 인한 고유한 오류로 인해 발생

Conclusion

- Pros
  - QLoRA의 성능을 압도하는 Quantization 프레임워크 제안
  - 2bit와 같은 낮은 비트로 구성된 Quantization 환경에서도 Robustness를 보여줌
- Cons
  - Decoder ONLY 모델을 다양화해서 실험해보지 않았음

Appendix A

Method	Rank	MNLI m / mm	QNLI Acc	SST2 Acc
Full FT	-	90.5/90.6	94.0	95.3
QLoRA	32	79.9/79.5	83.8	86.6
LoftQ(SVD First)	32	87.8/87.7	84.9	89.7
LoftQ(Quantiztion First)	32	**88.0/88.1**	**92.2**	**94.7**

KOREA UNIVERSITY

Divergent Token Metrics: Measuring degradation to prune away LLM components – and optimize quantization

NAACL 2024

김민혁

Goal

- Compression(압축)에 적합한 개별 component를 찾기 위해 어떤 Metric을 사용해야 하는가?
  - PPL (Perplexity)
  - DPPL (Divergent Perplexity)
  - SDT (Share of divergent tokens)
  - FDT (First divergent token)

Abstract

- 모델 경량화를 위한 Metrics(Perplexity, Accuracy)는 한계 존재
  - Text Generation Quality를 반영하지 못함
- 논문에서 제안하는 Divergent Token Metrics(DTMs)를 통해 한계를 극복 가능
- SOTA Performance를 유지하며 25%의 Attention Components의 90%를 넘게 Pruning 가능
- 80%가 넘는 파라미터에 대해서 별도의 이상치 처리를 하지 않아도 Naive하게 int8 형태로 변환할 수 있음
  - Compression이 가능한 적절한 파라미터를 찾는게 중요함

Introduction

- Perplexity와 기존 NLP Benchmark는 Diverging performance nuance를 캡처하는데 실패함
  - 불연속적인 텍스트 생성 과정을 무시했기 때문
  - 문법이나 수치 등에서 상당한 차이가 발생할 수 있음

Introduction

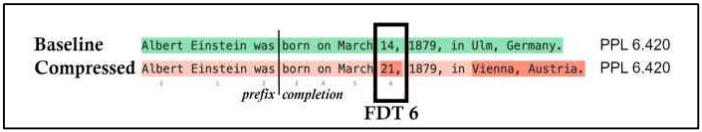

- 중요한 정보를 틀리게 생성했지만 Perplexity로는 이를 반영하지 못함
- 논문에서 제안한 Metrics 중에 하나인 FDT는 이러한 차이점을 식별할 수 있음

Model Divergence Metrics - Basic

$$\mathcal{G}(F, y_{:n}, N)_{i+1} = \arg\max_j F(\mathcal{G}(F, y_{:n}, N)_{:i})_{ij}.$$

- Model F가 있을 때, n 길이의 Prefix가 주어지고 이를 N 길이까지 생성하는 Greedy한 과정
- i+1 에 들어갈 가장 높은 Logit을 가진 j를 구함

Model Divergence Metrics - Perplexity

$$\mathrm{NLL}(y, F, n) = -\frac{1}{N-n} \sum_{i=n}^{N-1} \log \mathbb{P}(y_{i+1} | y_i, .., y_1),$$

- Model F가 n+1부터 N까지 생성할 Negative Log-likelihood
- i까지가 주어졌을 때, i+1이 발생할 조건부 확률의 로그 합의 평균을 음수화
  - 해당 값이 적을수록 모델이 안정적으로 결과값을 생성

Model Divergence Metrics - Perplexity

$$\mathrm{PPL}(y, F, n) = \exp(\mathrm{NLL}(y, F, n)).$$

- Negative Log Likelihood 값에 지수함수를 취함
- 논문이 제안한 Metrics와의 비교 지표

Model Divergence Metrics - DPPL

$$M_{\mathrm{DPPL}}(F,F',y_{:n},N) = \mathrm{PPL}(\mathcal{G}(F,y_{:n},N),F',n)\ .$$

- Divergent Perplexity (DPPL)
- Model F의 결과 값을 Ground-Truth 값으로 가정했을 때, 압축된 F'의 PPL

Model Divergence Metrics - SDT

$$\mathrm{SDT}(y, F, n) = |\{i \geq n : \ \arg\max_j \ F(y)_{ij} \neq y_{i+1}\}|,$$

- Share of divergent tokens (SDT)
- Model F의 결과 값을 Ground-Truth 값으로 가정했을 때, 압축된 F'의 수정이 필요한 정도

Model Divergence Metrics - FDT

$$\begin{aligned}&\mathrm{FDT}(y, F, n)\\&= \min\{i \geq n : \arg\max_j F(y)_{i,j} \neq y_{i+1}\} - n,\end{aligned}$$

- First divergent tokens (FDT)
- Model F의 결과 값이 Ground Truth와 달라지는 최초의 위치

Model Divergence Metrics

$$|\mathrm{PPL}(y, l, 1) - \mathrm{PPL}(y, l', 1)| < \varepsilon,$$
$$M_{\mathrm{SDT}}(l, l', y_{:1}, N) = N.$$

- 모델 l과 압축된 l'의 PPL 값의 차이가 ε 미만으로 작아도 SDT 값이 N만큼 커질 수 있음
  - (Albert Einstein was born on) March14
  - (Albert Einstein was born on) April 21

Experiments

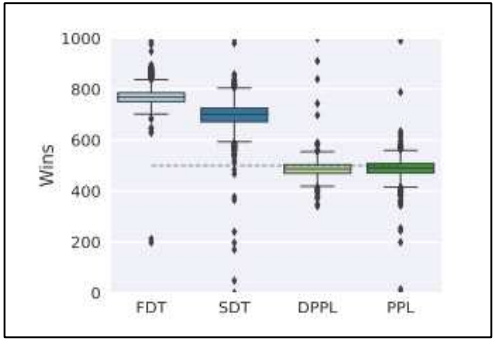

- FDT, SDT를 사용하여 Pruning한 결과 > 기존 평가지표(PPL)를 사용하여 Pruning한 결과

Experiments - Settings

- Models
  - Llama2-7B, 13B
- Evaluation
  - Wikitext2 dataset
  - NLP Benchmarks
- Sparsity
  - 20, 15, 10, 10, 5, 5, 5(%)로 점진적으로 증가시키며 실험

Experiments - Settings

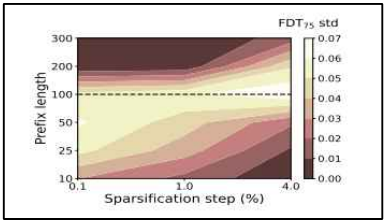

- FDT 값의 분산이 75% 이상의 구간에서 높게 나타남 (성능 비교가 용이함)
- Prefix를 100으로 주었을 때 마찬가지로 분산이 높게 나타남
- 따라서 실험은 해당 값을 고정하고 진행

Experiments

- 모델의 Component에 대해 다음과 같은 Metrics를 수행하여 Sparsification과 Quantization의 대상이 되는 Component와 그 비율을 선택
  - FDT
  - DPPL
  - PPL
  - Uniform

Experiments - Results

- A. FDT 기반 모델 경량화 기법의 성능이 PPL 기반 기법보다 뛰어남
- B. FDT기반 Pruning하는 과정에서 각 Layer의 Component별 중요도를 식별하는 것이 수월함

Experiments - Result A

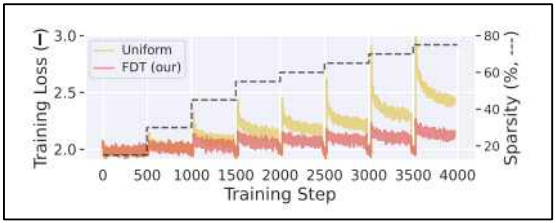

- FDT vs Uniform (Sparsification)
- Uniform 하게 Pruning하는 것보다 FDT를 사용하여 선택된 Component에 개별적으로 Pruning을 적용했을 때 Convergence가 훨씬 빠름

Experiments - Result A

Sparsification			
Model	FDT ↑	PPL ↓	NLP ↑
Llama2-13B	-	4.884	53.59
~ 60% sparse (unif.)	4.7	9.244	46.32
~ 60% sparse (our)	**7.9**	**6.242**	**48.89**
~ 75% sparse (unif.)	3.5	13.512	41.67
~ 75% sparse (our)	**5.5**	**8.101**	**46.32**
~ 80% sparse (our)	5.2	9.531	45.66

- 사용 Metric 별 성능 비교 (Uniform vs. FDT - Sparsification)
  - 모든 부문에서 FDT가 Uniform을 능가함을 확인할 수 있음
  - 70% 이상의 Sparsification이 진행됐을 때 PPL 점수가 한 자릿수를 달성한 것은 최초임

Experiments - Result A

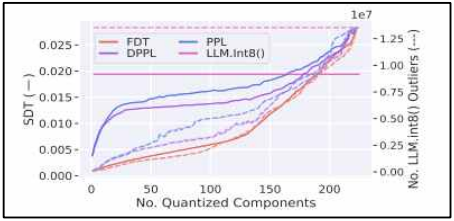

- Metrics 별 성능 비교 (Quantization)
  - Quantized Components가 많을수록 이상치와 SDT값이 증가
  - 이때, FDT가 PPL, DPPL보다 해당 값이 낮음을 보임

Experiments - Result A

Quantization	Model	FDT ↑	PPL ↓	NLP ↑
	Llama2-7B	-	5.472	50.79
int8	LLM.int8()$_{all}$	36.1	5.505	**50.81**
int8	AbsMax PPL$_{150}$	46.3	5.500	50.72
int8	AbsMax DPPL$_{150}$	54.1	5.490	50.75
int8	AbsMax FDT$_{150}$ (our)	**71.7**	**5.489**	50.75
int4	GPTQ$_{all}$	11.1	5.665	48.34
int4	GPTQ PPL$_{16}$	45.0	5.511	49.91
int4	GPTQ DPPL$_{16}$	137.0	5.476	50.02
int4	GPTQ FDT$_{16}$ (our)	**205.0**	**5.475**	**50.13**

- 사용 Metric 별 성능 비교 (Quantization)
  - int 8에서 NLP Benchmark로 평가한 지표를 제외한 나머지 부문에서 FDT가 타 Metrics를 능가함

Experiments - Result B

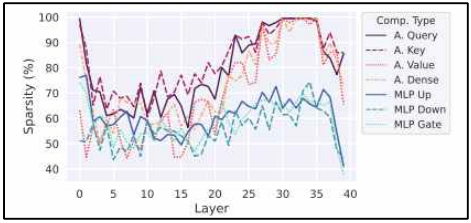

- FDT를 기반으로 하여 평균 75%의 Sparsification을 진행했을 때 각 Component별 Sparsity 정도
- 일부 Layer의 Attention Component가 90% 이상이 Pruning된 것을 확인할 수 있음

Experiments - Result B

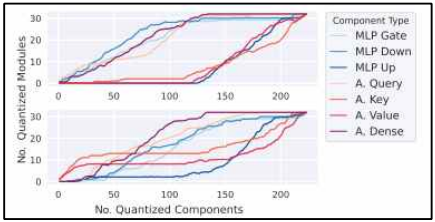

- FDT (위) vs PPL (아래) Component Type에 따른 Quantized Module의 갯수
  - FDT를 기반으로 했을 때 Attention의 Key와 Value에 해당하는 Component가 비교적 나중에 Quantization이 이루어진 것을 확인할 수 있음

Experiments - Result B

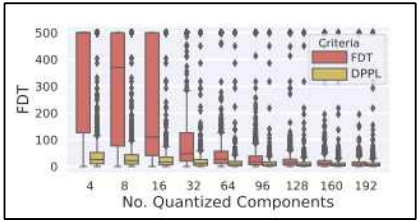

- GPTQ에서 FDT와 DPPL의 FDT값 비교
  - FDT기반 Quantization의 FDT값 분산이 커서 Component별 중요도에 따른 top-k Component를 파악하기 용이함

Conclusion

- Pros
  - 경량화 모델의 성능을 향상시킴
  - 경량화의 정도를 증가
    - 개별 Component의 중요도를 파악했기 때문
- Cons
  - 다양한 Sparsification 기법을 실험해보지 않았음
  - 영어로 훈련된 모델로만 실험
    - 한국어는 비교적 단어의 배치가 자유로운데, FDT값을 임의로 조정한다면 어떤 결과가 발생할지?

감사합니다.

Q&A

Appendix A

Algorithm 1 Iteration of pruning algorithm

input: $F, step$ ▷ current model, target sparsity

fdt_sparse_map $\leftarrow \{\}$
for $c_i \in$ Components **do**
  fdt_sparse_map[c_i] $\leftarrow$ [100,
    $\mathcal{M}_{\text{FDT}_{75}}(F, F^{c_i+step/2})$,
    $\mathcal{M}_{\text{FDT}_{75}}(F, F^{c_i+step+step/2}), 0$]
  ▷ FDT values measured for added sparsities of $0, step/2, step + step/2, 100\%$ to component c_i on model F. The maximal FDT value measured is 100.
end for

$f \leftarrow 100$ ▷ iteratively decrease from maximum
$s \leftarrow 0$ ▷ track current added sparsity
comp_sparse_map $\leftarrow \{\}$
while $s \leq step$ and $f \geq 0$ **do**
  for $c_i \in$ Components **do**
    comp_sparse_map[c_i] $\leftarrow$
      $lin\_interpol$(fdt_sparse_map[c_i], f)
  end for
  $s \leftarrow weighted\_mean$(comp_sparse_map)
  $f \leftarrow f - 1$
end while
$F' \leftarrow F$ pruned by comp_sparse_map
output: F'

Appendix B

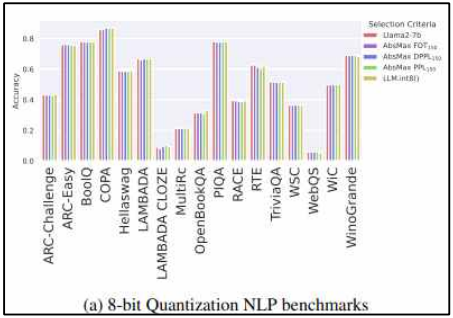

(a) 8-bit Quantization NLP benchmarks

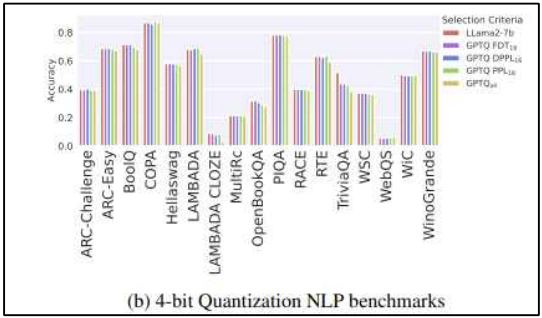

(b) 4-bit Quantization NLP benchmarks