

Natural Language Processing: Project 3

Seung-Hoon Na

Jun 10, 2024


1 Transformer

본 주제에서는 Transformer에 대한 이론적인 내용을 정리하고 numpy로 구현해보는 것을 목표로 한다.

특히, 다음 OpenAI 논문의 GPT 계열의 Decoder only model의 **Multi-layer Transformer decoder**를 구현하고, 이를 pretraining 및 finetuning까지 수행 해 보는 것을 목표로 한다.


https://s3-us-west-2.amazonaws.com/openai-assets/research-covers/language-unsupervised/language_understanding_paper.pdf.

Multi-layer Transformer decoder는 아래 그림에서 보여지다시피, self-attention 이 unidirectional하게 수행되는 것이 특징이며, 즉, 현재 토큰에 대한 contextual representation을 얻을 때, 문장내 이전의 토큰들에 대해서 attention을 수행하게 된다. 디코딩과정을 전제로 하므로, 미래에 앞으로 생성할 토큰에 대해서는 attention을 하지 못하게 된다. 단, training하는 과정에서는 미래의 토큰도 주어지는 상태로 입력을 받아 처리하는게 효과적이므로, 문장의 모든 입력을 취하되 **attention mask matrix**를 이용하여 unidirectional attention을 구현하는 것이 일반적이다.



원래 GPT 논문의 용어를 따라, GPT를 Pretraining하는 단계에서, 대규모 학습 데이터가 $\mathcal{U} = \{u_0, u_1, \dots, u_n\}$ 로 주어졌다고 하면, autoregressive 목적함수 L_1 은 다음과 같다. 이때, 편의상 n 개 단어로 구성된 하나의 문장이라고 하고, 실제 학습 데이터는 N 개의 문장이라고 하자. 여기서는 한 개 문장으로부터 Loss function과 학습에 논의를 집중한다. 편의상, u_0 를 시작토큰이라고 하자. u_n 을 End토큰이라고 할수도 있다.

$$L_1(\mathcal{U}) = \sum_i \log P(u_i | u_1, \dots, u_{i-1}; \Theta) \quad (1)$$



위의 그림에서 보이듯, Transformer decoder는 multi-layer block을 거친 후에, 학습하기 위해 마지막 단어까지의 $i \in [1, n]$ 번째 각 위치의 모든 단어 w 에 대한 $P(w \mid u_1, \dots, u_{i-1}; \Theta)$ 생성 확률들은 다음과 같이 계산한다.

$$\begin{aligned} \mathbf{H}_0 &= \mathbf{W}_e^T \mathbf{U} + \mathbf{W}_p \\ \mathbf{H}_l &= \text{transformer_block}(\mathbf{H}_{l-1}) \quad \forall l \in [1, L] \\ \mathbf{O} &= \text{softmax}(\mathbf{W}_e \mathbf{H}_L) \end{aligned} \quad (2)$$

여기서, $\mathcal{V}$ 를 단어의 집합이라 할때, $\mathbf{U} = [u_0, u_1, \dots, u_{n-1}] \in \{0, 1\}^{|\mathcal{V}| \times n}$ 은 문장 내 n 개 단어에 대한 one-hot vector들로 구성된 matrix이고, $\mathbf{W}_e \in \mathbb{R}^{|\mathcal{V}| \times d}$ 은 word embedding matrices이고 (파라미터), $\mathbf{W}_p \in \mathbb{R}^{d \times (i-1)}$ 은 position embedding이다. $\mathbf{O} \in \mathbb{R}^{|\mathcal{V}| \times n}$ 은 각 column이 단어에 대한 확률 벡터 ($|\mathcal{V}|-1$ -dimensional probability simplex)이다.

Autoregressive 생성 목적함수에서는 $i-1$ 번째에 대한 정답 출력 레이블은 i 번째 단어인 u_i 가 되어야 한다. 따라서, 정답 시퀀스 벡터는 $\mathbf{Y} = [u_1, \dots, u_n] \in \{0, 1\}^{|\mathcal{V}| \times n}$ 가 된다.

결국, L_1 은 다음과 같이 정리될 수 수 있다.

$$L_1 = - \sum_{i=1}^n \mathbf{Y}_{(i)} \cdot \log(\mathbf{O}_{(i)}) \quad (3)$$

이때, $\mathbf{Y}_{(i)}$, $\mathbf{O}_{(i)}$ 는 각각 해당 행렬의 i 번째 column 벡터를 의미한다.

1.1 Pretraining (200 points)

1. Masked Attention이 다음과 같다고 하자.

$$\text{Attention}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{softmax} \left(\frac{\mathbf{Q}\mathbf{K}^T}{\sqrt{d_k}} + \mathbf{M} \right) \mathbf{V}$$

여기서 d_k 는 key vector의 차원이고, $\mathbf{M}$ 은 attention의 masked되는 위치에 $-\inf$ (또는 very large negative values)값을 갖고 나머지는 0인 attention mask matrix이다.

l 번째 layer의 `transformer_block`의 $\mathbf{H}_l = \text{transformer_block}(\mathbf{H}_{l-1})$ 에 대한 상세 flow는 다음과 같다.

For a given layer l :

1. Compute the linear projections for multi-head self-attention:

$$\mathbf{Q} = \mathbf{H}_{l-1} \mathbf{W}_Q^l, \quad \mathbf{K} = \mathbf{H}_{l-1} \mathbf{W}_K^l, \quad \mathbf{V} = \mathbf{H}_{l-1} \mathbf{W}_V^l$$

2. Compute the multi-head self-attention:

$$\text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) \mathbf{W}_O$$

where each $\text{head}_i = \text{Attention}(\mathbf{Q}_i, \mathbf{K}_i, \mathbf{V}_i)$.

3. Add residual connection and apply layer normalization:

$$\tilde{\mathbf{H}}_l = \text{LayerNorm}(\mathbf{H}_{l-1} + \text{MultiHead}(\mathbf{Q}, \mathbf{K}, \mathbf{V}))$$

4. Apply position-wise feed-forward network:

$$\text{FFN}_l(x) = \text{ReLU}(x \mathbf{W}_1^{(l)} + \mathbf{b}_1^{(l)}) \mathbf{W}_2^{(l)} + \mathbf{b}_2^{(l)}$$

5. Add residual connection and apply layer normalization:

$$\mathbf{H}_l = \text{LayerNorm}(\tilde{\mathbf{H}}_l + \text{FFN}(\tilde{\mathbf{H}}_l))$$

Backpropagation을 위해 L_1 에 대한 Transformer parameters의 gradients인 다음을 유도하시오 (유도과정을 보이시오).

$$\begin{aligned} \frac{\partial L_1}{\partial \mathbf{W}_e} &= \\ \frac{\partial L_1}{\partial \mathbf{W}_Q^l} &= \\ \frac{\partial L_1}{\partial \mathbf{W}_K^l} &= \\ \frac{\partial L_1}{\partial \mathbf{W}_V^l} &= \\ \frac{\partial L_1}{\partial \mathbf{W}_1^l} &= \\ \frac{\partial L_1}{\partial \mathbf{W}_2^l} &= \\ \frac{\partial L_1}{\partial \mathbf{b}_1^l} &= \\ \frac{\partial L_1}{\partial \mathbf{b}_2^l} &= \end{aligned} \tag{4}$$

2. Eq. 2에서 sinusoidal positional representation에 기반한 $\mathbf{W}_p$ 에 대한 수식을 구체적으로 기술하시오.

3. 위에서 attention mask matrix $\mathbf{M}$ 은 어떻게 설정이 되어야 한지 수식으로 명확히 기술하시오.
4. Eq. 4 및 유도과정, $\mathbf{W}_p$ 과 attention mask matrix 설정을 바탕으로, 학습데이터셋 $\mathcal{D} = (\text{sent}_i)_{i=1}^N$ 으로 총 N 개의 문장이 구성되었다고 할때, stochastic gradient descent방법을 이용한 Transformer 파라미터 pretraining을 위한 pseudo code를 기술하시오.

1.2 Supervised Finetuning (100 points)

1. Sequence labelling을 위한 Supervised finetuning 순차태깅을 위해 입력문장에 추가로 정답(ground-truth) 시퀀스가 $\text{label} = l_1, \dots, l_n$ 로 주어진다고 가정하자. 각 출력 레이블 l_i 에 대한 one-hot 벡터를 $\mathbf{t}^{(i)} = \text{onehot}(l_i) \in \{0, 1\}^{|T|}$ 라고 하면, 결국 출력 시퀀스 벡터가 $\mathbf{T} = [\mathbf{t}^{(1)}, \dots, \mathbf{t}^{(n)}]$ 로 표현될 수 있다.

Supervised finetuning 위한 L_2 은 다음과 같이 정리될 수 있다.

$$\begin{aligned}
 \mathbf{H}_0 &= \mathbf{W}_e^T \mathbf{U} + \mathbf{W}_p \\
 \mathbf{H}_l &= \text{transformer_block}(\mathbf{H}_{l-1}) \quad \forall l \in [1, L] \\
 \mathbf{O} &= \text{softmax}(\mathbf{W}_y \mathbf{H}_L) \\
 L_2 &= - \sum_{i=1}^n \mathbf{T}_{(i)} \cdot \log(\mathbf{O}_{(i)})
 \end{aligned} \tag{5}$$

이때, Eq. 3와는 조금의 차이를 보이는데, 입력은 $\mathbf{U} = [u_0, u_1, \dots, u_n] \in \{0, 1\}^{|V| \times (n+1)}$ 로 전체 단어 입력을 받게 된다 (물론 pretraining과정에서도 전체 입력을 받게 하고 마지막 토큰의 결과를 loss에서 제외하는 식으로 통일하면 된다). 또한, Eq. 2와는 달리, transformer_block까지는 pretraining 과정과 동일하지만, softmax를 적용시 word embedding을 통해 vocabulary space로 projection이 되는 것이 아니라, $\mathbf{W}_y \in \mathbf{R}^{|\mathcal{K}| \times d}$ 의 **new additional parameters**를 사용하여 output tag space로 projection되는 것을 주목해야 한다. 여기서, $\mathcal{K}$ 는 가능한 정답 태그의 전체 집합을 의미한다.

위의 L_2 를 위해 L_1 과 차이를 보이는 부분을 주목하고, Transformer parameters의 gradients인 다음을 유도하시오 (유도과정을 보일 것). 다른부분에서는 특별히 차이가 없는지 확인하시오.

$$\begin{aligned}
 \frac{\partial L_2}{\partial \mathbf{W}_e} &= \\
 \frac{\partial L_2}{\partial \mathbf{W}_y} &=
 \end{aligned}$$

2. supervised 학습데이터셋 $\mathcal{C} = (\text{sent}_i, \text{label}_i)_{i=1}^N$ 으로 총 M 개의 문장과 정답 레이블열로 구성되었다고 할때, stochastic gradient descent방법을 이용한 supervised finetuning을 위해서 $\mathbf{W}_y$ 까지 포함하여 학습하는 pseudo code를 기술하시오.

1.3 Transformer의 구현 (600 points)

본 절에서는 앞에서 정리한 Transformer을 numpy코드 (gpu확장을 위해 cupy버전도 추가 포함)로 구현해보고 영문 품사 태깅 (POS tagging)에 적용해보는 것을 목표로 한다. 데이터는 이전과 동일하다.

앞서 RNN 과제와 마찬가지로, Transformer학습을 위해 영문 POS Tagging 데이터셋을 사용하고, 데이터셋은 다음과 같이 Training/dev/test셋을 위한 세개의 파일과 Training의 raw corpus, 또한 추가로 Transformer를 사전학습하기 위한 보다 규모가 큰 raw corpus 로 구성되어 있다.

- Training dataset (tagged_train.txt): 단어별 품사태그가 부착된 POS Tagging 태스크를 위한 학습데이터셋
- Development dataset (tagged_dev.txt): 단어별 품사태그가 부착된 POS Tagging 태스크를 위한 개발용 데이터셋
- Test dataset (tagged_test.txt): 단어별 품사태그가 부착된 POS Tagging 태스크를 위한 평가용 데이터셋
- Raw Training dataset (raw_train.txt): 코퍼스상 tokenizer가 적용된 학습 데이터셋상에서 원문 문장셋
- Extra Raw dataset (raw_extra.txt): 코퍼스상 tokenizer가 적용된 보다 규모가 큰 Raw corpus (Transformer를 사전학습하는데 활용)

다음은 raw_train.txt 파일의 일부를 보여준다.

```
1130b36a9ba93d8fcbf07a2ac0048d4c281cd57c::29 Geordie Nicholson .
1130b36a9ba93d8fcbf07a2ac0048d4c281cd57c::30 Web site: burgessyachts.com .
1130b36a9ba93d8fcbf07a2ac0048d4c281cd57c::31 'Big Aron' Why we like it This
capacious 2004 yacht was refitted in 2006.
```

다음은 tagged_train.txt 파일의 일부를 보여준다.

```
42c027e4ff9730fbb3de84c1af0d2c506e41c3e4::0 LONDON/NNP ,/, England/NNP (/
Reuters/NNP )) --/: Harry/NNP Potter/NNP star/NN Daniel/NNP
Radcliffe/NNP gains/NNS access/NN to/TO a/DT reported/VBN
- 128) °20/CD million/CD (/ ( $/$ 41.1/CD million/CD ))/ fortune/NN
as/IN he/PRP turns/VBZ 18/CD on/IN Monday/NNP ,/, but/CC he/PRP
insists/VBZ the/DT money/NN wo/MD n't/RB cast/VB a/DT spell/NN on/IN
him/PRP ./.
```

```
42c027e4ff9730fbb3de84c1af0d2c506e41c3e4::1 Daniel/NNP Radcliffe/NNP as/IN
Harry/NNP Potter/NNP in/IN ``/`` Harry/NNP Potter/NNP and/CC the/DT
Order/NN of/IN the/DT Phoenix/NNP ''/'' To/TO the/DT disappointment/NN
of/IN gossip/NN columnists/NNS around/IN the/DT world/NN ,/, the/DT
young/JJ actor/NN says/VBZ he/PRP has/VBZ no/DT plans/NNS to/TO
fritter/VB his/PRP$ cash/NN away/RB on/IN fast/JJ cars/NNS ,/, drink/NN
and/CC celebrity/NN parties/NNS ./.
```

```
42c027e4ff9730fbb3de84c1af0d2c506e41c3e4::2 ``/`` I/PRP do/VBP n't/RB
plan/VB to/TO be/VB one/CD of/IN those/DT people/NNS who/WP ,/, as/RB
soon/RB as/IN they/PRP turn/VBP 18/CD ,/, suddenly/RB buy/VBP
themselves/PRP a/DT massive/JJ sports/NNS car/NN collection/NN or/CC
something/NN similar/JJ ,/, ''/'' he/PRP told/VBD an/DT Australian/JJ
interviewer/NN earlier/RBR this/DT month/NN ./.
```

위의 파일에서 각 라인의 첫번째 token은 문장 고유 id를 의미한다.

참고로, 본 데이터셋은 공개 영문 Raw corpus상에서 Stanford의 POS tagger를 적용하여, 자동으로 얻은 데이터셋이다. 따라서, Tagging된 데이터셋상에서 오류가 있을 수 있다.

다음 상세 요구사항을 참조하여 numpy코드를 작성하시오.

1.3.1 Transformer 의 Pretraining구현 및 적용

1. **Pretraining 구현:** 앞문항에서 정리된 pseudo code를 바탕으로 대규모 코퍼스상 L_1 을 최소화하면서 Transformer를 사전학습하는 numpy코드를 작성하시오.

사전학습된 모델 파라미터는 별도의 파일로 저장이 되어, 추론 단계에서 저장된 모델파일을 읽어들이어 사용할 수 있도록 한다.

2. **Pretraining 학습 수행 및 평가:** 작성된 numpy코드를 바탕으로 Extra Raw dataset상 (raw_extra.txt 사전학습을 수행하고, Train/Dev/test셋상에서 사전학습되는 과정에서 perplexity가 어떻게 감소되는지 추이를 그래프로 보이시오.

3. **Greedy Decoding 구현 및 테스트:** Greedy decoding 내용을 조사하고, 사전학습된 model을 읽어들이어 주어진 입력을 일부 받아들이어 나머지 문장을 생성하는 Greedy decoding을 수행하는 알고리즘을 구현하시오.

샘플 디코딩 결과에 대해서 보고서에 포함시키시오.

1.3.2 Transformer 의 supervised finetuning구현 및 적용

1. **Supervised finetuning 구현:** 위의 Training셋에 있는 모든 문장을 읽어 들여, $\mathcal{D} = (sent_i, label_i)_{i=1}^N$ 를 구성하여, Stochastic gradient descent에 기반하여 L_2 를 최적화하는 finetuning 코드를 작성하시오. 학습된 모델 파라미터는 별도의 파일로 저장이 되어, 추론 단계에서 저장된 모델파일을 읽어 들여 테스트 및 평가할 수 있도록 한다.

2. **Transformer기반 inference 구현:** 앞서 얻은 finetuning된 모델 파일을 읽어 들여, 주어진 입력 문장에 대해서 forward를 수행하여 가장 높은 태그열을 생성하는 numpy코드를 작성하시오.

테스트를 위해서, 인자로 model파일을 입력으로 받도록 하고, 콘솔환경에서 문장은 공백라인으로 끝나도록 하고, 엔터로 입력이 끝나면 태그열을 생성하도록 하라. 배치 처리를 위해 python argparse등에 기반하여 모델파일외에 입력파일과 출력파일을 추가 인자로 제시하도록 하여, 입력파일내에 있는 모든 문장에 대한 tagging결과를 출력파일에 각각 출력하도록 하라.

3. **학습된 Transformer기반 평가:** 위의 학습된 Transformer 모델을 바탕으로 제공된 Test셋상에서 적용하여, POS tagging 평가를 수행하시오. 평가 결과로 1) 총 단어수, 2) Transformer에 기반한 POS Tag를 정확히 맞춘 총 단어수, 3) Accuracy 의 수치가 포함되도록 출력하시오. 이때, Accuracy는 다음과 같이 정의된다.

$$Accuracy = \frac{\text{예측된 POS Tag가 정답과 일치하는 총 단어수}}{\text{테스트셋상 총 단어수}} \quad (6)$$

4. **이전 HMM과 LSTM과 비교 및 추가 실험:** 이전 과제의 LSTM과 성능을 비교하고, Transformer의 레이어 갯수 L 의 변화 등에 따른 성능 변화등을 비교해보시오.
5. **GPU를 이용하기 위해 Cupy버전 추가:** 사전학습까지 수행하기 위해서는, GPU를 이용하여 학습속도를 개선시켜야 한다. LSTM과 마찬가지로 적어도 Transformer 사전학습하는 코드는 cupy버전으로 확장하여, GPU적용까지 수행하도록 하시오. 실제 수행후에 CPU기반 버전과 GPU기반 버전의 학습 속도 차이를 보고서에 정리하시오.

2 제출 내용 및 평가 방식

Section 1.1과 Section 1.2에 대해서는 **문제 답안 상세 결과물**을 제출해야 한다.

Section 1.3의 구현 문제의 경우 **python**코드외에 결과보고서도 함께 제출해야 하며, 정리하면 다음과 같다.

- **코드 전체**
- **테스트 결과:** 각 내용별 테스트 코드 및 해당 로그 또는 출력 결과.
- **결과보고서:** 구현 방법을 요약한 보고서.

Section 1.3 구현 문항의 평가항목 및 배점은 다음과 같다.

- **각 세부내용의 구현 정확성 및 완결성 (80%)**
- **코드의 Readability 및 체계성 (10%)**
- **결과 보고서의 구체성 및 완결성 (10%)**