

Week4 - Transformer

1 Sequence-to-sequence (seq2seq)

作用

输入一个序列, 输出一个序列. 输出的长度由模型决定.

使用方向

- 语音辨识
- 机器翻译
- 语音翻译
- Text-to-speech(TTS)
- Multi-label classification
- Object detection


2 Encoder

输入一组向量, 输出一组同样长度的向量 (除了 Self-attention, 还可以使用 RNN 或 CNN).

如输入 $X(x^1, x^2, x^3, x^4)$, 输出 $H(h^1, h^2, h^3, h^4)$

Encoder 中, 输入需要经过多个 Block 的处理得到输出

原理




18

如 Pic 4-1 :

1. 对输入 $X(x^1, x^2, x^3, x^4)$ 进行一次 Self-attention ;
2. 将 Self-attention 的输出丢入 Fully connect 的 Feed Forward Network 中, 输出结果.

1个 Block 做的事, 是好几个Layer在做的事情, 因此 Block 并不是 Neural Network 中的一层.

Block 具体过程



- Residual Connection: 将输出的向量加上之前输入的向量作为新的输出
- Layer Normalization:
 1. 输入一个向量, 计算其平均值 m , 标准差 σ
 2. 不同于 Batch Normalization
 - Batch Normalization: 对不同的样例, 不同特征的同一维度去计算 m 和 σ
 - Layer Normalization: 对同一样例, 同一特征的不同维度去计算 m 和 σ
 3. 根据公式 $x'_i = \frac{x_i - m}{\sigma}$ 得到新的向量

如 Pic 4-2:

1. 对向量位置有要求, 需要先对输入进行 Position Embedding
2. 对输入向量做 Self-attention, 得到 a
3. 做 Residual Connection, 得到 $(a + b)$
4. 对向量 $(a + b)$, 做 Layer Norm
5. 再对上一步得到的结果, 在做 Fully connect
6. 再对上一步的结果做 Residual 和 Layer Norm, 得到该 Block 的输出


重复多次 Block 过程。

3 Decoder

Autoregression (自回归, AT)

过程

Autoregressive



30

1. 开始给定一个Begin标记(BOS)
2. 输入向量经过 Decoder 得到输出的向量
3. 将输出的向量, 经过 Soft-max 得到每个字的分数, 将最高分数的字符作为结果
4. 将该次生成的结果作为下一次的输入, 重复第2步, 直到遇到End标记(EOS)

Pic 4-3 的 Decoder Output 可能产生 Error Propagation, 即一步错步步错.

Autoregression 的 Decoder 结构

在 Decoder 中, 通常使用 Masked Multi-head Self-attention. 原本的 Self-attention 需要考虑所有输入向量才能计算出 (q, k, v) , 之后才能得到输出向量.

而 Masked Multi-head Self-attention 只考虑自己与自己之前的向量即可, 例如需要输出向量 b^3 时, 只需要考虑 a^1, a^2, a^3 所产生的 (q, k, v) , 而无需考虑 a^4

Q1: 为什么使用 Masked Multi-head Self-attention ?

在 AutoRegression 中, 输出时一个个根据前一次的输出所产生的, 并不会考虑之后的事情.

Q2: 什么时候Encoder停下来?

准备一个特殊符号 `EOS`, 当结束时, 让End标记的几率最大时, 结束Encoder. 即让机器自己训练决定何时该结束.

Non-autoregression (NAT)

`NAT` 与 `AT` 的差别, 在于AT需要上一步的输出作为下一步的输入, 并一步步这样循环. 而 `AT` 则直接一次性输入, 直接得到输出.

如何决定 NAT 输出的长度


有两种思路:

- 另外学习一个Classifier, 输入 Encoder 的输入, 输出一个值表示该Decoder输出的长度;
- 设定一个较大上限值, 观察何处出现End标记, 丢弃End标记之后的所有输出.

NAT 优缺点

- 优点: 平行处理, 可以控制输出的长度
- 缺点: 效率与性能不如 `AT`

4 Encoder 与 Decoder 之间的通信



1. 在 Encoder 部分, 输入一组向量后输出了 (a^1, a^2, a^3)
2. 在 Decoder 部分, 得到一个输入(如 BOS), 经过 Masked Multi-head Self-attention 得到向量, 乘上矩阵做 Transformer, 得到 query - q
3. 在 Encoder 部分, 各个向量一次产生 key - $(k^1, k^2, k^3, \dots)$, 将 k 与 $(k^1, k^2, k^3, \dots)$ 进行计算得到分数 - $(\alpha^1, \alpha^2, \alpha^3, \dots)$, 进行 Soft-max, Norm 等操作, 得到 $(\alpha'_1, \alpha'_2, \alpha'_3, \dots)$
4. 在 Encoder 部分, 产生向量 $(a^1, a^2, a^3, \dots)$ 的 value - $(v^1, v^2, v^3, \dots)$, 与 $(\alpha'_1, \alpha'_2, \alpha'_3, \dots)$ 相乘. $v = \sum_h (v^i \alpha'_i)$
5. 将 v 做 Fully-connection, 丢入 Network 进行接下来的处理

5 Training

训练方式

当将 BOS 丢入 Encoder 时, 希望将输出与字符 x 越接近越好. x 会被表示成一个 one-hot vector, 只有 x 对应的那个维度是 1, 其余皆为 0.

此时 Decoder 输出一个 Distribution (几率的分布), 此时希望纪律分布与该 one-hot vector 越接近越好.

即计算输出的 `Ground Truth` 与 `Distribution` 之间的 `Cross-entropy` , 越小越好. 近似于分类问题.

在 Decoder 训练过程中, 在输入的时候基于其正确答案, 这个过程称为 `Teacher Forcing` .

在实际使用模型时, Decoder 因为仅仅时看见自己的输入, 中间存在 Mismatch.

解决Mismatch的一些方法

- Copy Mechanism
- Summarization
- Guide-attention
- Scheduled Sampling