

Сергей Николенко

СПбГУ — Санкт-Петербург

24 октября 2024 г.

Random facts:




- 24 октября в ООН — День ООН; именно 24 октября 1945 г. официально вступил в силу устав организации
- 24 октября 1745 г. Елизавета Петровна повелела завезти в царские дворцы котов для ловли мышей
- 24 октября 1857 г. выпускники Кембриджа основали в Шеффилде первую в мире футбольную команду, Sheffield F.C., а 24 октября 1897 г. в Санкт-Петербурге был проведён первый в истории России официально зафиксированный футбольный матч
- 24 октября 1911 г. с мыса Эванс к Южному полюсу отправился Роберт Скотт и ещё 11 человек; обратно не вернулся никто
- 24 октября 1929 г. индекс Доу-Джонса за один день снизился на 11%, а в целом за неделю — более чем на 40%; «чёрный четверг» стал началом Великой депрессии
- 24 октября 1975 г. произошла «Длинная пятница» — всеобщая забастовка женщин Исландии, в которой приняло участие 90% женщин страны; в 1976 году в Исландии приняли Закон о равноправии, а в 1980 году Вигдис Финнбогадоттир стала первой женщиной в мире, избранной на пост конституционного главы государства

ЧТО ТАКОЕ ВНИМАНИЕ?




- Вы же сейчас *внимательно* меня слушаете, правильно?
- А что это значит?..
- Изображение с сетчатки тоже проходит через CNN, но потом мы часть его замечаем, а часть не особенно. Что это значит?
- Оказывается, что это довольно сложный вопрос.
- А.Р. Лурия: внимание, память и активация коры.

- Дело во взаимодействии с рабочей памятью (Knudsen, 2007):






ВНИМАНИЕ

- Как это реализовать в нейронной сети? Особенно «сознательное» внимание.
- Но и «бессознательное» тоже; например, с картинками: мы же на самом деле мало чего видим в каждый момент времени.
- Центральная ямка сетчатки (fovea):



- Simons, Chabris, 1999: <https://www.youtube.com/watch?v=vJG698U2Mvo>

- Мы делаем саккады, причём это тоже не всегда помогает:




- Или вот не совсем зрительный пример:

§ 445. Задача XIV. Лисица, преследуемая зайцем, находится от него на расстоянии 60 ея скачков; она прыгает 9 скачков в то время, в которое заяц прыгает 6; величина же 3 скачков зайца равна величине 7 скачков лисицы. Сколько скачков прыгает заяц, чтобы догнать лисицу?

FOVEAL GLIMPSES

- В нейросети мы тоже хотим осознанно понимать, «на что» смотреть.
- Одна из первых работ (Larochelle, Hinton, 2010):




- Пытаются моделировать положения фиксации и строить последовательность при помощи RBM.
- Последовательность – значит...

РЕКУРРЕНТНЫЕ МОДЕЛИ ЗРИТЕЛЬНОГО ВНИМАНИЯ

RECURRENT VISUAL ATTENTION

- По-настоящему всё появилось в (Mnih et al., 2014), «Recurrent Models of Visual Attention»:
 - из предыдущего $\mathbf{h}_{t-1}$ и положения t для нового «взгляда» f_g делает $\mathbf{g}_t$, вход для шага t ;
 - из $\mathbf{h}_{t-1}$ и $\mathbf{g}_t$ функцией f_h получается $\mathbf{h}_t$;
 - из него – «действие» $a_t = f_a(\mathbf{h}_t)$ и положение следующего «взгляда» $l_{t+1} = f_l(\mathbf{h}_t)$.



- Давайте разберёмся в модели формально:

$$\mathbf{g}_t = f_g(\mathbf{x}_t, \mathbf{l}_{t-1}; \theta_g),$$

$$\mathbf{h}_t = f_h(\mathbf{h}_{t-1}, \mathbf{g}_t; \theta_h),$$

$$\mathbf{l}_t \sim p(\cdot \mid f_l(\mathbf{h}_t; \theta_l)),$$

$$a_t \sim p(\cdot \mid f_a(\mathbf{h}_t; \theta_a)).$$

- После очередного действия получается новое наблюдение $\mathbf{x}_{t+1}$ и награда r_t , которая будет скорее всего в конце, после всех шагов, за правильную классификацию.
- Что это напоминает?..

- ...о да, это reinforcement learning!
- Выучить надо стохастическую стратегию $\pi(\mathbf{l}_t, a_t \mid \mathbf{s}_{1:t}; \theta)$, которая по истории будет выдавать следующее действие.
- У нас π задаётся через RNN, а оптимизировать надо

$$J(\theta) = \mathbb{E}_{p(\mathbf{s}_{1:T}; \theta)} [R] = \mathbb{E}_{p(\mathbf{s}_{1:T}; \theta)} \left[\sum_{t=1}^T r_t \right].$$

- Выглядит очень сложно – ожидание по последовательностям действий, т.е. по пространству большой размерности.
- Но есть методы – давайте сделаем preview тому, что потом будет в reinforcement learning.

- (Williams, 1992): алгоритм REINFORCE, в котором доказывается и используется выборочная оценка этого ожидания. Давайте выведем, а потом применим к нашему случаю...
- Нам надо оптимизировать

$$J(\theta) = \mathbb{E}_{\tau \sim \pi_{\theta}} \left[\sum_{t=1}^T r_t(s_t, a_t) \right] \approx \frac{1}{M} \sum_{i=1}^M \sum_{t=1}^T r(s_t^{(i)}, a_t^{(i)}),$$

где мы взяли M примеров траекторий τ .

- Определим $r(\tau) = \sum_t r(s_t, a_t)$. Тогда

$$J(\theta) = \mathbb{E}_{\tau \sim \pi_{\theta}} [r(\tau)] = \int \pi_{\theta}(\tau) r(\tau) d\tau,$$

т.е. тот самый страшный интеграл по траекториям.

- Но оказывается, что можно продифференцировать по θ ...

- Продифференцируем по θ :

$$\begin{aligned}\nabla_{\theta} J(\theta) &= \int \nabla_{\theta} \pi_{\theta}(\tau) r(\tau) d\tau \\ &= \int \pi_{\theta}(\tau) \frac{\nabla_{\theta} \pi_{\theta}(\tau)}{\pi_{\theta}(\tau)} r(\tau) d\tau \\ &= \int \pi_{\theta}(\tau) \nabla_{\theta} \log \pi_{\theta}(\tau) r(\tau) d\tau \\ &= \mathbb{E}_{\tau \sim \pi_{\theta}(\tau)} [\nabla_{\theta} \log \pi_{\theta}(\tau) r(\tau)] \\ &\approx \frac{1}{M} \sum_{i=1}^M \nabla_{\theta} \log \pi_{\theta}(\tau^{(i)}) r^{(i)}(\tau),\end{aligned}$$

если приблизить выборкой; но сначала давайте ещё посмотрим на $\pi_{\theta}(\tau)$...

- Вероятность определяется как

$$\pi_{\theta}(\tau) = p(s_1) \prod_{t=1}^T \pi_{\theta}(a_t \mid s_t) p(s_{t+1} \mid s_t, a_t).$$

- Берём логарифм, а потом заметим, что от θ зависят только действия:

$$\begin{aligned} \nabla_{\theta} \log \pi_{\theta}(\tau) &= \\ &= \nabla_{\theta} \left(\log p(s_1) + \sum_{t=1}^T \log \pi_{\theta}(a_t \mid s_t) + \sum_{t=1}^T \log p(s_{t+1} \mid s_t, a_t) \right) = \\ &= \sum_{t=1}^T \nabla_{\theta} \log \pi_{\theta}(a_t \mid s_t). \end{aligned}$$

- Итого получается вполне tractable градиент:


$$\begin{aligned}\nabla_{\theta} J(\theta) &= \mathbb{E}_{\tau \sim \pi_{\theta}(\tau)} \left[r(\tau) \sum_{t=1}^T \nabla_{\theta} \log \pi_{\theta}(a_t \mid s_t) \right] \\ &\approx \frac{1}{M} \sum_{i=1}^M r(\tau^{(i)}) \sum_{t=1}^T \nabla_{\theta} \log \pi_{\theta}(a_t^{(i)} \mid s_t^{(i)}).\end{aligned}$$

- У нас тоже можно считать, что награда R даётся целиком:

$$\nabla_{\theta} J(\theta) \approx \frac{1}{M} \sum_{i=1}^M \sum_{t=1}^T \nabla_{\theta} \log \pi \left(\mathbf{l}_t^{(i)}, a_t^{(i)} \mid \mathbf{s}_{1:t}^{(i)}; \theta \right) R^{(i)}.$$

- Т.е. надо уметь считать $\log \pi \left(\mathbf{l}_t^{(i)}, a_t^{(i)} \mid \mathbf{s}_{1:t}^{(i)}; \theta \right)$, но в случае RNN это просто градиент сети, который можно посчитать через backpropagation.
- Ещё можно сделать частично supervised loss на последнем шаге, где мы знаем классификацию.

- Результаты:



(a) Translated MNIST inputs.



(b) Cluttered Translated MNIST inputs.

(a) 28x28 MNIST

Model	Error
FC, 2 layers (256 hidden each)	1.69%
Convolutional, 2 layers	1.21%
RAM, 2 glimpses, 8×8 , 1 scale	3.79%
RAM, 3 glimpses, 8×8 , 1 scale	1.51%
RAM, 4 glimpses, 8×8 , 1 scale	1.54%
RAM, 5 glimpses, 8×8 , 1 scale	1.34%
RAM, 6 glimpses, 8×8 , 1 scale	1.12%
RAM, 7 glimpses, 8×8 , 1 scale	1.07%

(b) 60x60 Translated MNIST

Model	Error
FC, 2 layers (64 hidden each)	6.42%
FC, 2 layers (256 hidden each)	2.63%
Convolutional, 2 layers	1.62%
RAM, 4 glimpses, 12×12 , 3 scales	1.54%
RAM, 6 glimpses, 12×12 , 3 scales	1.22%
RAM, 8 glimpses, 12×12 , 3 scales	1.2%

RECURRENT VISUAL ATTENTION

- Результаты:


(a) 60x60 Cluttered Translated MNIST

Model	Error
FC, 2 layers (64 hiddens each)	28.58%
FC, 2 layers (256 hiddens each)	11.96%
Convolutional, 2 layers	8.09%
RAM, 4 glimpses, 12×12 , 3 scales	4.96%
RAM, 6 glimpses, 12×12 , 3 scales	4.08%
RAM, 8 glimpses, 12×12 , 3 scales	4.04%
RAM, 8 random glimpses	14.4%


(b) 100x100 Cluttered Translated MNIST

Model	Error
Convolutional, 2 layers	14.35%
RAM, 4 glimpses, 12×12 , 4 scales	9.41%
RAM, 6 glimpses, 12×12 , 4 scales	8.31%
RAM, 8 glimpses, 12×12 , 4 scales	8.11%
RAM, 8 random glimpses	28.4%

- А вот как внимание гуляет по картинке:



- В следующей работе (Ba et al., 2015) сделали глубокую модель:



- Кстати, обучали по-другому, вариационными методами. Как это?..

- Нам нужно классифицировать, т.е. $p(y \mid \mathbf{x}, \theta)$ максимизировать.
- Маргинализуем по положениям glimpses:

$$\log p(y \mid \mathbf{x}, \theta) = \log \sum_l p(l \mid \mathbf{x}, \theta) p(y \mid l, \mathbf{x}, \theta).$$

- Запишем вариационную нижнюю оценку свободной энергии (как её получить?):

$$\begin{aligned} \log \sum_l p(l \mid \mathbf{x}, \theta) p(y \mid l, \mathbf{x}, \theta) &\geq \sum_l p(l \mid \mathbf{x}, \theta) \log p(y, l \mid \mathbf{x}, \theta) + H[l] \\ &= \sum_l p(l \mid \mathbf{x}, \theta) \log p(y \mid l, \mathbf{x}, \theta). \end{aligned}$$

- И теперь можно брать производные:

$$\begin{aligned}\frac{\partial J}{\partial \theta} &= \sum_l p(l \mid \mathbf{x}, \theta) \frac{\partial \log p(y \mid l, \mathbf{x}, \theta)}{\partial \theta} + \sum_l \log p(y \mid l, \mathbf{x}, \theta) \frac{\partial p(l \mid \mathbf{x}, \theta)}{\partial \theta} \\ &= \sum_l p(l \mid \mathbf{x}, \theta) \left[\frac{\partial \log p(y \mid l, \mathbf{x}, \theta)}{\partial \theta} + \log p(y \mid l, \mathbf{x}, \theta) \frac{\partial \log p(l \mid \mathbf{x}, \theta)}{\partial \theta} \right].\end{aligned}$$

- А эту сумму уже будем приближать выборкой:

$$\frac{\partial J}{\partial \theta} \approx \frac{1}{M} \sum_{i=1}^M \left[\frac{\partial \log p(y \mid l^{(i)}, \mathbf{x}, \theta)}{\partial \theta} + \log p(y \mid l^{(i)}, \mathbf{x}, \theta) \frac{\partial \log p(l^{(i)} \mid \mathbf{x}, \theta)}{\partial \theta} \right],$$


$$\text{где } l^{(i)} \sim p(l_n \mid \mathbf{x}, \theta) = N(l_n \mid \hat{l}_n, \Sigma).$$

- И это уже алгоритм: сэмплируем glimpses, потом используем их в backpropagation.
- Как и в (Mnih et al., 2014), надо бы уменьшить дисперсию; для этого вычитают baseline, пока не будем углубляться.


- Получился интересный результат – мы увидели, что примерно один и тот же алгоритм может получиться с двух разных сторон:
 - из обучения с подкреплением через REINFORCE;
 - из вариационной оценки собственно целевой функции.
- Важный гиперпараметр – размер *glimpse*, т.е. как переводить единицы измерений в системе координат *glimpses* в пиксели.
- То же самое легко расширить на последовательную классификацию нескольких объектов – просто фиксированное число *glimpses* на объект, потом классифицируем, плюс терминальное действие в конце всего.

RECURRENT VISUAL ATTENTION

- Вот как это работает на распознавании двух цифр:




- Любопытно, что на сложении по-другому:



МАШИННЫЙ ПЕРЕВОД:
ENCODER-DECODER
И ВНИМАНИЕ

- Перевод – очень хорошая задача:
 - очевидно очень практическая;
 - очевидно очень высокоуровневая, требует понимания;
 - считается довольно неплохо квантифицируемой (BLEU, TER – хотя см. выше);
 - имеет большие доступные датасеты параллельных переводов.

- Статистический машинный перевод (statistical machine translation, SMT): моделируем условную вероятность $p(y | x)$ перевода y при условии исходного текста x .
- Классический SMT: моделируем $\log p(y | x)$ линейной комбинацией признаков, строим признаки.



- Нам больше интересно моделирование sequence-to-sequence:
 - RNN естественным образом моделирует последовательность $X = (x_1, x_2, \dots, x_T)$ как $p(x_1), p(x_2 | x_1), \dots, p(x_T | x_{<T}) = p(x_T | x_{T-1}, \dots, x_1)$, и теперь $p(X)$ – это просто

$$p(X) = p(x_1)p(x_2 | x_1) \dots p(x_k | x_{<k}) \dots p(x_T | x_{<T});$$

- так RNN и в языковых моделях используются;
 - предсказываем следующее слово на основе скрытого состояния и предыдущего слова;
- Как применить эту идею к переводу?

МЕТРИКИ КАЧЕСТВА ДЛЯ SEQUENCE-TO-SEQUENCE МОДЕЛЕЙ

- Дальше будет самое интересное: машинный перевод, диалоговые модели, ответ на вопросы.
- Но как мы будем оценивать NLP-модели, которые генерируют текст?
- Есть метрики качества, которые сравнивают результат с правильными ответами:
 - BLEU (Bilingual Evaluation Understudy): перевзвешенная precision (в т.ч. для нескольких правильных ответов);
 - METEOR: гармоническое среднее precision и recall по униграммам;
 - TER (Translation Edit Rate): число исправлений между выходом и правильным ответом, делённое на среднее число слов;
 - LEPOR: комбинируем базовые факторы и метрики с настраиваемыми параметрами.
- Есть ещё куча метрик, связанных с представлениями слов и предложений (хотим поближе к правильному ответу).
- Одна только проблема...

- ...всё это вообще не работает.


Metric	Twitter				Ubuntu			
	Spearman	p-value	Pearson	p-value	Spearman	p-value	Pearson	p-value
Greedy	0.2119	0.034	0.1994	0.047	0.05276	0.6	0.02049	0.84
Average	0.2259	0.024	0.1971	0.049	-0.1387	0.17	-0.1631	0.10
Extrema	0.2103	0.036	0.1842	0.067	0.09243	0.36	-0.002903	0.98
METEOR	0.1887	0.06	0.1927	0.055	0.06314	0.53	0.1419	0.16
BLEU-1	0.1665	0.098	0.1288	0.2	-0.02552	0.8	0.01929	0.85
BLEU-2	0.3576	< 0.01	0.3874	< 0.01	0.03819	0.71	0.0586	0.56
BLEU-3	0.3423	< 0.01	0.1443	0.15	0.0878	0.38	0.1116	0.27
BLEU-4	0.3417	< 0.01	0.1392	0.17	0.1218	0.23	0.1132	0.26
ROUGE	0.1235	0.22	0.09714	0.34	0.05405	0.5933	0.06401	0.53
Human	0.9476	< 0.01	1.0	0.0	0.9550	< 0.01	1.0	0.0

Table 3: Correlation between each metric and human judgements for each response. Correlations shown in the human row result from randomly dividing human judges into two groups.

- Тут нужно что-то новое. И пока не совсем ясно, что именно.


ENCODER-DECODER АРХИТЕКТУРЫ

- Encoder-decoder архитектуры (Sutskever et al., 2014; Cho et al., 2014):




- Сначала кодируем, потом декодируем обратно.

- Так же может работать и с переводом.




- Проблема: надо сжимать всё предложение в один вектор.
- С длинными участками текста это вообще перестаёт работать.

- Решение: давайте обучим специальные веса, показывающие, насколько та или иная часть входа важна для текущего выхода.
- Прямое применение – двунаправленный LSTM плюс внимание (Bahdanau et al. 2014):




- *Мягкое внимание* (soft attention) (Luong et al. 2015a; 2015b; Jean et al. 2015):
 - encoder – двунаправленная RNN, есть оба контекста;
 - сеть внимания выдаёт оценку релевантности – надо ли переводить это слово прямо сейчас?




- Формально очень просто: считаем веса внимания α_{tj} и перевзвешиваем векторы контекстов:


$$e_{tj} = a(z_{t-1}, j), \quad \alpha_{tj} = \text{softmax}(e_{tj}; e_{t*}),$$
$$c_t = \sum_j \alpha_{tj} h_j, \text{ и теперь } z_t = f(s_{t-1}, y_{t-1}, c_t).$$



- В результате можно визуализировать, на что смотрит сеть:




- Получается гораздо лучше порядок слов:




ВНИМАНИЕ В НЕЙРОННЫХ СЕТЯХ


- Другая необычная работа – «Grammar as a Foreign Language» (Vinyals et al., 2015)




- Сентябрь 2016: Wu et al., *Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation*:
 - как на самом деле работает Google Translate;
 - базовая архитектура та же самая: encoder, decoder, attention;
 - RNN глубокие, по 8 уровней в encoder и decoder:



- Сентябрь 2016: Wu et al., *Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation*:
 - просто stacked LSTM перестают работать далее 4-5 уровней;
 - поэтому добавляют остаточные связи, как в ResNet:



- Сентябрь 2016: Wu et al., *Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation*:
 - нижний уровень, естественно, двунаправленный:



- Сентябрь 2016: Wu et al., *Google's Neural Machine Translation System: Bridging the Gap between Human and Machine Translation*:
- в GNMT ещё две идеи о сегментации слов:
 - *wordpiece model*: разбить слова на кусочки (отдельной моделью); пример из статьи:

Jet makers feud over seat width with big orders at stake

превращается в

`_J et _makers _fe ud _over _seat _width _with _big _orders _at _stake`


- *mixed word/character model*: конвертировать слова, не попадающие в словарь, в последовательность букв-токенов; пример из статьи:

Miki превращается в `<B>M <M>i <M>k <E>i`

- (Hermann et al., 2015): «Teaching machines to read and comprehend» (Google DeepMind)
- Предлагают новый способ построить датасет для понимания, автоматически создавая тройки (context, query, answer) из текстов новостей и т.п.

Original Version	Anonymised Version
Context The BBC producer allegedly struck by Jeremy Clarkson will not press charges against the “Top Gear” host, his lawyer said Friday. Clarkson, who hosted one of the most-watched television shows in the world, was dropped by the BBC Wednesday after an internal investigation by the British broadcaster found he had subjected producer Oisin Tymon “to an unprovoked physical and verbal attack.” ...	the <i>ent381</i> producer allegedly struck by <i>ent212</i> will not press charges against the “ <i>ent153</i> ” host , his lawyer said friday . <i>ent212</i> , who hosted one of the most - watched television shows in the world , was dropped by the <i>ent381</i> wednesday after an internal investigation by the <i>ent180</i> broadcaster found he had subjected producer <i>ent193</i> “ to an unprovoked physical and verbal attack . ” ...
Query Producer X will not press charges against Jeremy Clarkson, his lawyer says.	producer X will not press charges against <i>ent212</i> , his lawyer says .
Answer Oisin Tymon	<i>ent193</i>


- Базовая модель – глубокий LSTM:



- Но так, конечно, совсем плохо работает.


TEACHING MACHINES TO READ

- Attentive Reader: обучаемся, на какую часть документа смотреть



TEACHING MACHINES TO READ

- Impatient Reader: можем перечитывать нужные части документа по мере прочтения запроса



- Получаются разумные карты внимания:

by *ent423* ,*ent261* correspondent updated 9:49 pm et ,thu
march 19,2015 (*ent261*) a *ent114* was killed in a parachute
accident in *ent45* ,*ent85* ,near *ent312* ,a *ent119* official told
ent261 on wednesday .he was identified thursday as
special warfare operator 3rd class *ent23* ,29 ,of *ent187* ,
ent265 .`` *ent23* distinguished himself consistently
throughout his career .he was the epitome of the quiet
professional in all facets of his life ,and he leaves an
inspiring legacy of natural tenacity and focused

...

ent119 identifies deceased sailor as **X** ,who leaves behind
a wife


by *ent270* ,*ent223* updated 9:35 am et ,mon march 2 ,2015
(*ent223*) *ent63* went familial for fall at its fashion show in
ent231 on sunday ,dedicating its collection to ``mamma "
with nary a pair of ``mom jeans "in sight .*ent164* and *ent21* ,
who are behind the *ent196* brand ,sent models down the
runway in decidedly feminine dresses and skirts adorned
with roses ,lace and even embroidered doodles by the
designers ' own nieces and nephews .many of the looks
featured saccharine needlework phrases like ``i love you ,

...

X dedicated their fall fashion show to moms

SHOW, ATTEND, AND TELL

- Теперь давайте про подписи к картинкам.
- Сначала было «Show and Tell» (Vinyals et al., 2015):




A group of people shopping at an outdoor market.

There are many vegetables at the fruit stand.

SHOW, ATTEND, AND TELL

- Довольно прямолинейная архитектура:
 - целевая функция – это просто $\sum_{(I,S)} \log p(S | I; \theta)$, где I – картинка, S – описание;
 - раскладываем и моделируем $p(S_t | I, S_0, \dots, S_{t-1})$ рекуррентной сетью с LSTM;
 - а CNN используем, чтобы извлечь признаки.



SHOW, ATTEND, AND TELL

- Получалось хорошо, но можно лучше:

A person riding a motorcycle on a dirt road.



Two dogs play in the grass.



A skateboarder does a trick on a ramp.



A dog is jumping to catch a frisbee.



A group of young people playing a game of frisbee.



Two hockey players are fighting over the puck.



A little girl in a pink hat is blowing bubbles.



A refrigerator filled with lots of food and drinks.



A herd of elephants walking across a dry grass field.



A close up of a cat laying on a couch.



A red motorcycle parked on the side of the road.



A yellow school bus parked in a parking lot.



Describes without errors


Describes with minor errors

Somewhat related to the image

Unrelated to the image


SHOW, ATTEND, AND TELL

- Из этого появилось «Show, Attend, and Tell» (Xu et al., 2015)



SHOW, ATTEND, AND TELL

- Soft attention vs. hard attention (стохастически выбираем однозначный кусок картинки).



- Soft attention – строим аннотацию с весами

$$\phi(\{\mathbf{a}\}_i, \{\alpha_i\}) = \sum_{i=1}^L \alpha_{t,i} \mathbf{a}_i.$$

- Hard attention обучается максимизацией вариационной нижней оценки

$$L_s = \sum_s p(s | \mathbf{a}) \log p(\mathbf{y} | s, \mathbf{a}) \leq \log \sum_s p(s | \mathbf{a}) p(\mathbf{y} | s, \mathbf{a}) = \log p(\mathbf{y} | \mathbf{a}).$$

- От L_s можно брать производные:

$$\frac{\partial L_s}{\partial W} = \sum_s p(s | \mathbf{a}) \left[\frac{\partial \log p(\mathbf{y} | s, \mathbf{a})}{\partial W} + \log p(\mathbf{y} | s, \mathbf{a}) \frac{\partial \log p(s | \mathbf{a})}{\partial W} \right].$$



- И дальше сэмплируем s_t с вероятностями α_i и приближаем ожидание выборкой.
- Опять те же трюки, вычитаем baseline, всё такое.

SHOW, ATTEND, AND TELL

- Часто получаются очень хорошие результаты:



A woman is throwing a frisbee in a park.




A dog is standing on a hardwood floor.




A stop sign is on a road with a mountain in the background.




A little girl sitting on a bed with a teddy bear.



A group of people sitting on a boat in the water.



A giraffe standing in a forest with trees in the background.



- А когда плохие, можно посмотреть почему.

SHOW, ATTEND, AND TELL

- Примеры – hard attention:



(a) A man and a woman playing frisbee in a field.

SHOW, ATTEND, AND TELL


- Примеры – soft attention:



(b) A woman is throwing a frisbee in a park.

SHOW, ATTEND, AND TELL


- Примеры – hard attention:



(a) A giraffe standing in the field with trees.

SHOW, ATTEND, AND TELL


- Примеры – soft attention:



(b) A large white bird standing in a forest.

SHOW, ATTEND, AND TELL

- Примеры – hard attention:



(a) A woman is holding a donut in his hand.

SHOW, ATTEND, AND TELL

- Примеры – soft attention:




(b) A woman holding a clock in her hand.

TRANSFORMER И ЧТО ИЗ НЕГО
ПОЛУЧИЛОСЬ

- Мы изучали перевод на рекуррентных сетях и дошли до архитектуры Google NMT
- Но в 2017 году оказалось, что всё может быть ещё проще и интереснее
- Google: «Attention is all you need» (Vaswani et al., 2017)
- Основная идея – self-attention; оказывается очень плодотворной для всевозможных seq2seq задач
- Главная мотивация – попробовать всё-таки уйти от кодирования вектором постоянной длины

TRANSFORMER


- Общая схема:




- Теперь подробнее...

TRANSFORMER


- Суть, как и раньше, – encoder-decoder:



- 6 слоёв encoder'а, результат потом дают 6 слоям декодера:




- В каждом слое – слой self-attention, а потом feedforward layer, который независимо применяется к каждой позиции входа. У декодера ещё есть attention между ними:



TRANSFORMER

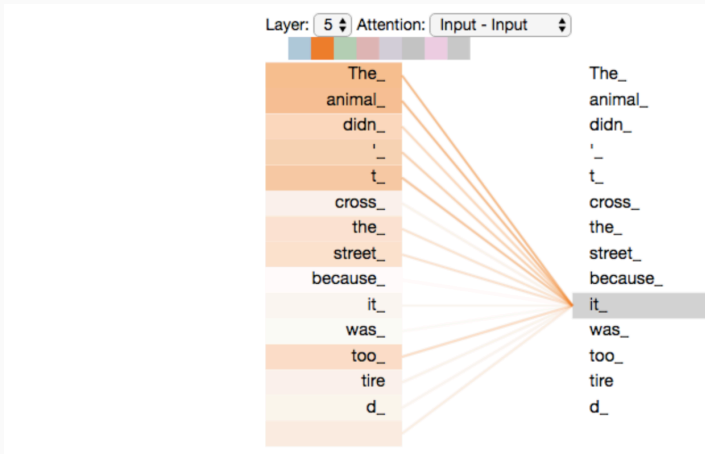
- Слова, естественно, представляются векторами, в feedforward слое всё параллельно:



- Но что же это такое – self-attention?

TRANSFORMER

- Идея в том, чтобы обучить веса, с которыми обработка текущего слова будет учитывать другие слова:




- Теперь детально...

TRANSFORMER


- Scaled Dot-Product Attention состоит из queries, keys и values:

$$\text{Attention}(Q, K, V) = \text{softmax} \left(\frac{1}{\sqrt{d_k}} Q K^\top \right) V$$

Scaled Dot-Product Attention




Multi-Head Attention




TRANSFORMER

- Векторы query и key считаются обычным умножением на матрицы весов:





TRANSFORMER

- Они нужны, чтобы вычислить веса внимания скалярным произведением, совсем как в поиске:




TRANSFORMER

- Они нужны, чтобы вычислить веса внимания скалярным произведением, совсем как в поиске:

Input	Thinking	Machines
Embedding	x_1 	x_2 
Queries	q_1 	q_2 
Keys	k_1 	k_2 
Values	v_1 	v_2 
Score	$q_1 \cdot k_1 = 112$	$q_1 \cdot k_2 = 96$
Divide by 8 ($\sqrt{d_k}$)	14	12
Softmax	0.88	0.12


TRANSFORMER

- Итого:

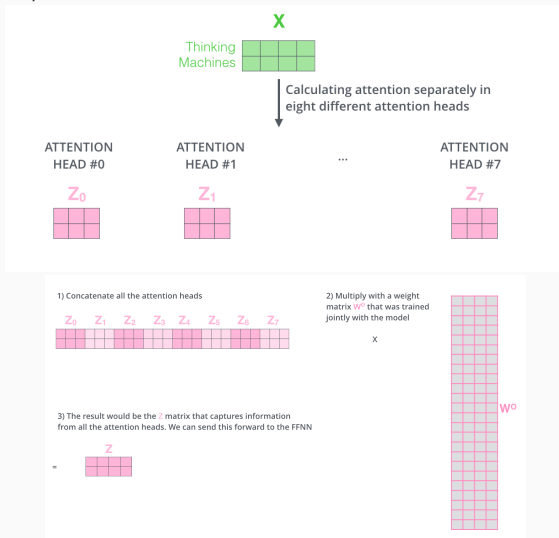


TRANSFORMER

- Multi-head attention объединяет несколько self-attention карт:




- А потом мы просто всё конкатенируем и объединим ещё одной матрицей весов:



TRANSFORMER

- Putting it all together:




TRANSFORMER

- И всё это можно представить как одно большое матричное вычисление:


$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \dots, \text{head}_h) W^O,$$
$$\text{head}_i = \text{Attention}(QW_i^Q, KW_i^K, VW_i^V),$$

где проекции W_i^* – это обучаемые матрицы весов.

Scaled Dot-Product Attention




Multi-Head Attention




TRANSFORMER

- Последний вопрос – сейчас модель совсем не учитывает порядок слов!
- Для этого добавляем к представлениям слов ещё positional embeddings:



- По каждой размерности i идёт своя синусоида; идея $\sin/\cos$ в том, чтобы для каждого фиксированного k PE_{pos+k} было бы линейной функцией от PE_{pos} , и это облегчило бы обучение того, как смотреть на относительные смещения:

$$PE_{(pos,2i)} = \sin(pos/10000^{2i/d_{model}}),$$
$$PE_{(pos,2i+1)} = \cos(pos/10000^{2i/d_{model}}),$$



TRANSFORMER

- Putting it all together:


1) This is our input sentence*

Thinking
Machines


2) We embed each word*



3) Split into 8 heads.
We multiply X or R with weight matrices



...



4) Calculate attention using the resulting $Q/K/V$ matrices



...



5) Concatenate the resulting Z matrices, then multiply with weight matrix W^O to produce the output of the layer




...



* In all encoders other than #0, we don't need embedding. We start directly with the output of the encoder right below this one




- Декодер устроен почти точно так же, но с ещё одним блоком:




TRANSFORMER

- Это такой же блок self-attention, но Q и K берутся от encoder'a (а V — от decoder'a):



TRANSFORMER

- И всё, дальше декодер работает авторегрессивно:



- Бонус от self-attention – во-первых, вычислительный, во-вторых, сокращает пути между словами, в-третьих, потенциальная интерпретируемость.

Table 1: Maximum path lengths, per-layer complexity and minimum number of sequential operations for different layer types. n is the sequence length, d is the representation dimension, k is the kernel size of convolutions and r the size of the neighborhood in restricted self-attention.

Layer Type	Complexity per Layer	Sequential Operations	Maximum Path Length
Self-Attention	$O(n^2 \cdot d)$	$O(1)$	$O(1)$
Recurrent	$O(n \cdot d^2)$	$O(n)$	$O(n)$
Convolutional	$O(k \cdot n \cdot d^2)$	$O(1)$	$O(\log_k(n))$
Self-Attention (restricted)	$O(r \cdot n \cdot d)$	$O(1)$	$O(n/r)$

- Работает лучше, обучается в сто раз быстрее:

Model	BLEU		Training Cost (FLOPs)	
	EN-DE	EN-FR	EN-DE	EN-FR
ByteNet [15]	23.75			
Deep-Att + PosUnk [32]		39.2		$1.0 \cdot 10^{20}$
GNMT + RL [31]	24.6	39.92	$2.3 \cdot 10^{19}$	$1.4 \cdot 10^{20}$
ConvS2S [8]	25.16	40.46	$9.6 \cdot 10^{18}$	$1.5 \cdot 10^{20}$
MoE [26]	26.03	40.56	$2.0 \cdot 10^{19}$	$1.2 \cdot 10^{20}$
Deep-Att + PosUnk Ensemble [32]		40.4		$8.0 \cdot 10^{20}$
GNMT + RL Ensemble [31]	26.30	41.16	$1.8 \cdot 10^{20}$	$1.1 \cdot 10^{21}$
ConvS2S Ensemble [8]	26.36	41.29	$7.7 \cdot 10^{19}$	$1.2 \cdot 10^{21}$
Transformer (base model)	27.3	38.1	$3.3 \cdot 10^{18}$	
Transformer (big)	28.4	41.0	$2.3 \cdot 10^{19}$	

СПАСИБО!

Спасибо за внимание!

