

Оптимизация в нейронных сетях.


База

Обучение NN и параллельные вычисления

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Обучение NN и параллельные вычисления

Функция потерь
(меньше - лучше)


$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Обучение NN и параллельные вычисления

Функция потерь
(меньше - лучше)

Потери на одном объекте
из обучающей выборки

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Обучение NN и параллельные вычисления

Функция потерь
(меньше - лучше)

Потери на одном объекте
из обучающей выборки

Его метка

Объект из
обучающей выборки

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Обучение NN и параллельные вычисления

Размер обучающей выборки

ImageNet $\approx 1.4 \cdot 10^7$

WikiText $\approx 10^8$

Потери на одном объекте
из обучающей выборки

Функция потерь
(меньше - лучше)

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Его метка

Объект из
обучающей выборки

Обучение NN и параллельные вычисления

Размер обучающей выборки

ImageNet $\approx 1.4 \cdot 10^7$

WikiText $\approx 10^8$

Потери на одном объекте
из обучающей выборки

Функция потерь
(меньше - лучше)

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Веса модели, которые
нужно подобрать
НО КАК?

Его метка


Объект из
обучающей выборки

Обучение NN и параллельные вычисления


Метод градиентного спуска (GD)

$$W_{k+1} = W_k - \alpha \nabla_w L(W_k)$$

Loss value 0.87



w_1 0.50, w_2 3.00



Обучение NN и параллельные вычисления

Метод градиентного
спуска (GD)

$$W_{k+1} = W_k - \alpha \nabla_W L(W_k)$$

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

Обучение NN и параллельные вычисления

Метод градиентного
спуска (GD)

$$W_{k+1} = W_k - \alpha \nabla_W L(W_k)$$

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

$$\nabla_W L(W_k) = \frac{1}{N} \sum_{i=1}^N \nabla_W l(W_k, x_i, y_i)$$

Обучение NN и параллельные вычисления

Метод градиентного
спуска (GD)

$$W_{k+1} = W_k - \alpha \nabla_W L(W_k)$$

$$L(W, X, y) = \frac{1}{N} \sum_{i=1}^N l(W, x_i, y_i) \rightarrow \min_{W \in \mathbb{R}^p}$$

$$\nabla_W L(W_k) = \frac{1}{N} \sum_{i=1}^N \nabla_W l(W_k, x_i, y_i)$$

Тяжело считать при большом N 🤔

Обучение NN и параллельные вычисления

Метод стохастического
градиентного спуска (SGD)

$$W_{k+1} = W_k - \alpha g_k$$

$$\nabla_W L(W_k) = \frac{1}{N} \sum_{i=1}^N \nabla_W l(W_k, x_i, y_i)$$

Обучение NN и параллельные вычисления

Метод стохастического
градиентного спуска (SGD)

$$W_{k+1} = W_k - \alpha g_k$$

$$\nabla_W L(W_k) = \frac{1}{N} \sum_{i=1}^N \nabla_W l(W_k, x_i, y_i)$$

$$g_k = \frac{1}{b} \sum_{i=1}^b \nabla_W l(W_k, x_{j_i}, y_{j_i})$$


$$b \ll N$$

Обучение NN и параллельные вычисления


Данные X

1						
N						


Обучение NN и параллельные вычисления



Обучение NN и параллельные вычисления



Обучение NN и параллельные вычисления



Свое железо для обучения - дорого

	ARCH	VRAM	FP32 TFLOPS	ENERGY	ENPRICE	PPRICE
RTX 2080 Ti	Turing	11	13.5	250	500 €	450 €
RTX 2080 Super	Turing	8	11.2	215	430 €	350 €
RTX 2070 Super	Turing	8	9.1	175	350 €	300 €
RTX 4090	Ada Lovelace	24	82.6	450	900 €	1,900 €
RTX 4070 Ti	Ada Lovelace	12	40.1	285	570 €	1,000 €
RTX 3070 Ti	Ampere	8	21.75	290	580 €	600 €
RTX 4080	Ada Lovelace	16	48.7	320	640 €	1,300 €
RTX 3080 Ti	Ampere	12	34.1	350	700 €	1,100 €
RTX 3090 Ti	Ampere	24	40	450	900 €	1,500 €
RTX A4000	Ampere	16	19.1	140	280 €	1,000 €
RTX 4000 Ada	Ada Lovelace	20	19.2	70	140 €	1,250 €
RTX A5000	Ampere	24	27.8	230	460 €	2,500 €
RTX 6000 Ada	Ada Lovelace	48	91.1	300	600 €	7,000 €
L40	Ada Lovelace	48	90.5	300	600 €	9,000 €
RTX A6000	Ampere	48	38.7	300	600 €	6,000 €
A100	Ampere	40	19.5	250	500 €	11,000 €
H100	Hopper	80	24.1	350	700 €	35,000 €

ENPRICE - оценка стоимости работы GPU на 100% в течение года

 Сайт

Таблица ценами на GPU и сравнением

Теория



Стох. градиент - несмещенная оценка настоящего градиента

$$\mathbb{E} g_k = \nabla_W L(W_k)$$

SGD с постоянным шагом не сходится для выпуклой задачи

“Сходимость” для сильно выпуклой задачи:

$$\mathbb{E}[\|x_k - x^*\|^2] \leq (1 - 2\alpha_k\mu)^k R^2 + \frac{\alpha B^2}{2\mu},$$

SGD в отличие от GD может “выпрыгивать” из локальных минимумов

Как работает 🧠 ?




8.6×10^{10} нейронов в мозге человека


$\sim 1.5 \times 10^{14}$ связей между ними

Как работает 🧠 ?

Другие
нейроны




Реакция
нейрона



Сумма входных сигналов
от других нейронов

Как работает 🤖🧠 ?

Другие
нейроны



x_1



x_2




x_3



x_4


Как работает 🤖🧠 ?

Другие
нейроны




Как работает 🤖🧠 ?

Другие
нейроны



Как работает 🤖🧠 ?


Другие
нейроны



$$S = w_1x_1 + \dots + w_nx_n$$


Как работает 🤖🧠 ?

Другие
нейроны



Как работает 🤖🧠 ?

Другие
нейроны



Вход: x_1 x_2 x_3 x_4


Выход: $\sigma(w_1x_1 + \dots + w_nx_n)$

Параметры: w_1 w_2 w_3 w_4

$$s = w_1x_1 + \dots + w_nx_n$$

Как работает 🤖🧠 ?


Возьмем несколько нейронов и получим полносвязный слой



$$y = \sigma(Wx)$$

$3 \times 1 \qquad \qquad 3 \times 4 \quad 4 \times 1$

Как использовать 🤖🧠 ?



Обучение нейросети

Объект
 $x \in \mathbb{R}^d; y \in \mathbb{R}^c$




КОТИК





собачка

Обучающая
выборка



Обучение нейросети







Обучение нейросети



Обучение нейросети




Обучение нейросети



$$W_{k+1} = W_k - \alpha \nabla_W L(W_k)$$

Изменение параметров таким образом, чтобы уменьшать значение функции потерь на обучающей выборке



ПРАКТИКА

Нехватка памяти для обучения больших моделей

```
RuntimeError: cuda runtime error (2) : out of memory at /data/users/soumith/miniconda2/cond
```

how can i solve this error?



apaszke commented on Mar 8, 2017

Member



You're running out of memory on the GPU. It's not a bug.




16



3

Размер батча и время, затрачиваемое на одну эпоху



При наличии достаточной памяти GPU, увеличение размера батча позволяет утилизировать ресурсы параллельных вычислений.

 Paper

Accurate, Large Minibatch SGD: Training ImageNet in 1 Hour.

Просто так увеличить размер батча не получится

kn	η	top-1 error (%)
256	0.05	23.92 ± 0.10
256	0.10	23.60 ± 0.12
256	0.20	23.68 ± 0.09
8k	$0.05 \cdot 32$	24.27 ± 0.08
8k	$0.10 \cdot 32$	23.74 ± 0.09
8k	$0.20 \cdot 32$	24.05 ± 0.18
8k	0.10	41.67 ± 0.10
8k	$0.10 \cdot \sqrt{32}$	26.22 ± 0.03

Обучение ResNet-50 на датасете ImageNet с разными вариантами увеличения размера батча.

(a) **Comparison of learning rate scaling rules.** A reference learning rate of $\eta = 0.1$ works best for $kn = 256$ (23.68% error). The linear scaling rule suggests $\eta = 0.1 \cdot 32$ when $kn = 8k$, which again gives best performance (23.74% error). Other ways of scaling η give worse results.

 **Paper**

Accurate, Large Minibatch SGD: Training ImageNet in 1 Hour.