

SGD - stochastic gradient descent

$$f(x) = \frac{1}{N} \sum_{i=1}^N f_i(x) \rightarrow \min_{x \in \mathbb{R}^p}$$

$$\nabla f(x) = \frac{1}{N} \sum_{i=1}^N \nabla f_i(x) \quad - \text{gradient}$$

вместо $\nabla f(x)$ использовать g_k

$$\mathbb{E} g_k = \nabla f(x_k) \quad \text{хотелось бы!}$$


$$g_k = \nabla f_j(x_k) \quad \leftarrow j \in [1, \dots, N] \text{ выбирается слуг. образом}$$

$$\mathbb{E} g_k = \sum_{i=1}^N \frac{1}{N} \cdot \nabla f_i(x_k) = \nabla f(x_k)$$

стох.
градиент.

сэмплирование в N раз


$$x_{k+1} = x_k - \alpha_k \cdot g_k \quad \text{SGD}$$



mini
batch
SGD

$$g_k = \frac{1}{b} \sum_{j=1}^b \nabla f_{i_j}(x_k)$$

выборка b из N



Вычисление g_k можно параллелить

$b \ll N$

$$g_k = \frac{1}{3} \begin{pmatrix} \nabla f_2(x_k) \\ \nabla f_5(x_k) \\ \nabla f_{228}(x_k) \end{pmatrix}$$

GPU

~~$b=30$~~


$b=100$ 3p

float

$$p \cdot 10^9 \cdot 32 \text{ bit} \approx 16 \cdot 10^9 \cdot 32 \text{ bit} = 16 \cdot 10^9 \cdot 8$$

$$p \approx 10^9$$

$$p = 10^7 - 10^8$$



Как изменится время, затраченное на 1 эпоху ?
при $b \uparrow$?

MSE:

$$L = \frac{1}{n} \sum_{i=1}^N \left(y_{\text{pred}}(w, D^i) - y_{\text{true}}^i \right)^2$$

$$f_i = \left(y_{\text{pred}}(w, D^i) - y_{\text{true}}^i \right)^2$$

$$\nabla_w f_i = 2 \left(y_{\text{pred}}(w, D^i) - y_{\text{true}}^i \right) \cdot \frac{\partial y_{\text{pred}}(w, D^i)}{\partial w}$$

$$W_5 \cdot W_4 \cdot W_3 \cdot W_2 \cdot W_1 \cdot d_{\text{input}}$$