

Координатные методы распределенной оптимизации в условиях гомогенности данных. Обзор литературы

Подготовила: Алимаскина Екатерина

Участники проекта: Максимов Роман, Алимаскина Екатерина

Руководитель: Былинкин Дмитрий, МФТИ

11.02.2025

«Распределенной оптимизации»

Algorithm Централизованный GD

Вход: Размер шага $\gamma > 0$, стартовая точка $w_0 \in \mathbb{R}^d$

```
1: for  $k = 0, 1, \dots, K - 1$  do  
2:   Отправить  $w_k$  всем рабочим  
3:   for  $i = 1, \dots, n$  параллельно do  
4:     Принять  $w_k$  от мастера  
5:     Вычислить градиент  $\nabla f_m(w_k)$  в точке  $w_k$   
6:     Отправить  $\nabla f_m(w_k)$  мастеру  
7:   end for  
8:   Принять  $\nabla f_m(w_k)$  от всех рабочих  
9:   Вычислить  $\nabla f(w_k) = \frac{1}{M} \sum_{m=1}^M \nabla f_m(w_k)$   
10:   $w_{k+1} = w_k - \gamma \nabla f(w_k)$   
11: end for  
Выход:  $w^K$ 
```

- Один мастер, много рабочих
- Узкое место – коммуникация. Хочется делать ее дешевле и реже.

«Распределенной оптимизации»

Оптимальный алгоритм одновременно и по числу коммуникаций и по кол-ву вызовов локальных градиентов

Optimal Gradient Sliding and its Application to Distributed Optimization Under Similarity

Dmitry Kovalev
KAUST
dakovalev1@gmail.com

Aleksandr Beznosikov
MIPT
anbeznosikov@gmail.com

Ekaterina Borodich
MIPT
borodich.ed@phystech.edu

Alexander Gasnikov
MIPT
gasnikov@yandex.ru

Gesualdo Scutari
Purdue University
gscutari@purdue.edu

Reference	Communication complexity	Local gradient complexity
This paper	$\mathcal{O}\left(\sqrt{\frac{\delta}{\mu}} \log \frac{1}{\varepsilon}\right)$	$\mathcal{O}\left(\sqrt{\frac{L}{\mu}} \log \frac{1}{\varepsilon}\right)$

<https://arxiv.org/pdf/2205.15136>

$$\min_{x \in \mathbb{R}^d} r(x) = \underbrace{f_1(x)}_{:=q(x)} + \underbrace{\frac{1}{n} \sum_{i=1}^n [f_i(x) - f_1(x)]}_{:=p(x)}$$

Algorithm 1 Accelerated Extragradient

- 1: **Input:** $x^0 = x_f^0 \in \mathbb{R}^d$
- 2: **Parameters:** $\tau \in (0, 1), \eta, \theta, \alpha > 0, K \in \{1, 2, \dots\}$
- 3: **for** $k = 0, 1, 2, \dots, K - 1$ **do**
- 4: $x_g^k = \tau x^k + (1 - \tau) x_f^k$
- 5: $x_f^{k+1} \approx \arg \min_{x \in \mathbb{R}^d} [A_\theta^k(x) := p(x_g^k) + \langle \nabla p(x_g^k), x - x_g^k \rangle + \frac{1}{2\theta} \|x - x_g^k\|^2 + q(x)]$
- 6: $x^{k+1} = x^k + \eta \alpha (x_f^{k+1} - x^k) - \eta \nabla r(x_f^{k+1})$
- 7: **end for**
- 8: **Output:** x^K

$r(x)$ – выпуклая

$q(x)$ – гладкая, выпуклая

$p(x)$ – гладкая, возможно невыпуклая

«Гомогенности данных»

Function similarity («похожесть»)

Assumption 6. $f_1(x) \dots, f_n(x)$ are δ -related: $\|\nabla^2 f_i(x) - \nabla^2 f(x)\| \leq \delta$, for all i and $x \in \mathbb{R}^d$, and some $\delta > 0$.

Откуда мы берем такое предположение?

Если мы случайно и одинаково распределяем данные по устройствам, то это вполне естественно.

Как это использовать?

Из Assumption 6 следует, что $\|\nabla^2 p\| \leq \delta$, то есть p имеет L_p -липшицев градиент, где $L_p = \delta$.

Но может так случиться, что разные куски данных похожи неодинаково!

«Координатные»

$$\min_{x,y} f(x,y) \quad \begin{cases} \mathcal{O}\left(\sqrt{L/\mu_x} \log \frac{1}{\epsilon}\right) \text{ calculations of } \nabla_x f \\ \mathcal{O}\left(\sqrt{L/\mu_y} \log \frac{1}{\epsilon}\right) \text{ calculations of } \nabla_y f \end{cases}$$

Литература:

<https://arxiv.org/pdf/1212.0873>

<https://arxiv.org/pdf/2212.14439>