

Vertical federative learning for distributed networks

Pyotr Lisov
Ivan Toropin

Table of contents

- Intro
 - Motivation
 - Problem Statement
- Related works
- New results
- Plans
- Bibliography

Problem statement

Задача распределенной оптимизации в общем виде:

$$\min_{\Theta} \ell(\Theta; \mathcal{D}) \triangleq \frac{1}{N} \sum_{i=1}^N f(\Theta; \mathbf{x}_i, y_i)$$

\mathbf{x}_i, y_i - датасет. Θ - некая обобщенная модель

Problem statement

Что такое Gossip fast mix?

Основная идея - имея n штук

“псевдоградиентов” в идеале сойтись к

единому “усредненному” значению градиента

Algorithm 4 FastMix

Parameters: Vectors z_1, \dots, z_M , communic. rounds P .

Initialization: Construct matrix \mathbf{z} with rows z_1^T, \dots, z_M^T ,

choose $\mathbf{z}^{-1} = \mathbf{z}$, $\mathbf{z}^0 = \mathbf{z}$, $\eta = \frac{1 - \sqrt{1 - \lambda_2^2(\tilde{W})}}{1 + \sqrt{1 - \lambda_2^2(\tilde{W})}}$.

for $h = 0, 1, 2, \dots, P - 1$ **do**

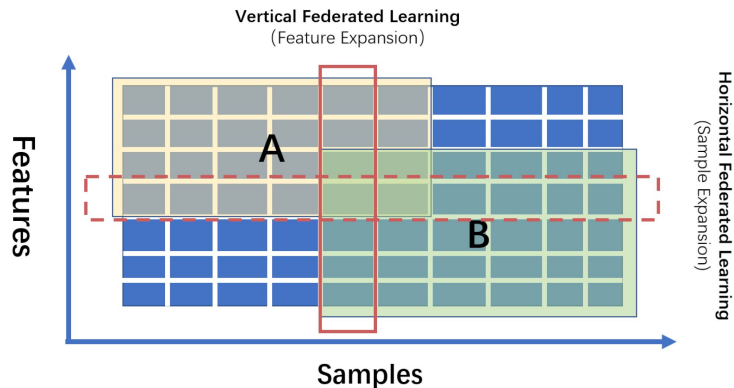
$\mathbf{z}^{h+1} = (1 + \eta)\tilde{W}\mathbf{z}^h - \eta\mathbf{z}^{h-1}$,

end for

Output: rows z_1, \dots, z_M of \mathbf{z}^P .

Motivation

Вертикальное обучение - подход к обучению моделей, при котором мы делим исходные данные на признаки. Это позволяет эффективно использовать данные, находящиеся в различных узлах сети, к тому же, такой подход является более безопасным.



Related works

В [2] задача ставится так:

$$\min_{x \in \mathbb{R}^d} \left[f(x) := \frac{1}{s} \left\| \sum_{i=1}^n A_i x_i - b \right\|^2 \right]$$

Каждая нода имеет свой собственный набор фич A_i , x_i и вычисляет градиент независимо с помощью L-Katyusha, а затем передает его с помощью функции AllReduce[3].

Related works

Работаем в 3 предположениях

- 1) μ сильная выпуклость
- 2) L гладкость
- 3) Собственные значения $AA^T \in [\mu, L]$

Related works

В данных предположениях достигается такая оценка на число итераций.

$$\mathcal{O} \left(\frac{s}{b_s} \left(\sqrt{\frac{L}{\mu}} \sqrt{\frac{1}{\beta} \left(\frac{1}{s} + (w-1) \frac{sL^2}{\mu^2} \right)} + 1 \right) \log \frac{1}{\varepsilon} \right)$$


Эта статья примечательна прежде всего тем, что она является одной из первых, которая дала гарантии теоретической сходимости в VFL, а не только в численных тестах

Related works - Pseudocode

```
for  $k = 0, 1, 2, \dots K$  do  
  for  $i = 1 \dots n$  in parallel do  
    Select uniformly batch  $J^k$ ,  $|J^k| = b_s$   
     $x_i^k \leftarrow \theta_1 z_i^k + \theta_2 \omega_i^k + (1 - \theta_1 - \theta_2) y_i^k$   
    for  $j \in J^k$  do  
      Compute  $\langle A_{ji}^T, x_i^k - w_i^k \rangle$   
      Using communications  
      broadcast  $Q_i(\langle A_{ji}^T, x_i^k - w_i^k \rangle)$   
    end for  
     $g_i^k \leftarrow \frac{2}{b_s} \sum_{j \in J^k} A_{ji}^T \sum_{i=1}^n Q_i(\langle A_{ji}^T, x_i^k - w_i^k \rangle)$   
     $\quad \quad \quad + \frac{2}{s} (A^T A w^k - A^T b)_i$   
     $z_i^{k+1} \leftarrow \frac{1}{1+\eta\sigma} (\eta\sigma x_i^k + z_i^k - \frac{\eta}{L} g_i^k)$   
     $y_i^{k+1} \leftarrow x_i^k + \theta_1 (z_i^{k+1} - z_i^k)$   
     $\omega_i^{k+1} \leftarrow \begin{cases} y_i^k, & \text{with probability } p \\ \omega_i^k, & \text{with probability } 1 - p \end{cases}$   
    if  $w_i^{k+1} = y_i^k$  then  
      for  $j = 1 \dots s$  do  
        Compute  $\langle A_{ji}^T, x_i^k - w_i^k \rangle$   
        Using communications  
        broadcast  $\langle A_{ji}^T, x_i^k - w_i^k \rangle$   
      end for  
      Compute  $\frac{2}{s} (A^T A w^k - A^T b)_i$   
    end if  
  end for  
end for
```

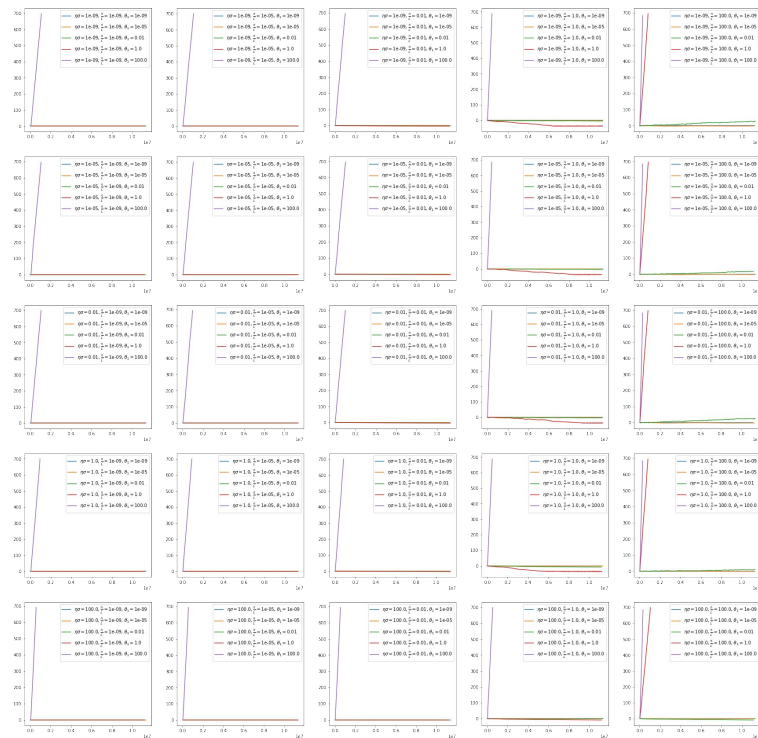
New results

Написан код для процедуры Gossip fast mix с более конкретной децентрализацией, показана сходимость.



New results

В предыдущей статье[2], эксперимент показал, что параметры сходимости отличаются порядком в 10^{-8} раз. Сейчас получено обратное. Сходимость с параметрами $\text{par} = \max(\text{par}_i)$



Github link

github.com/Lhesnor/DVPL



Plans and Expectations

Что делать дальше?

- Оценить время работы fast-mix (Просто)
- Доказать сходимость для процедуры Gossip уже аналитически.
- Доказать сходимость для нелинейной функции.

В условиях общей задачи распределенной оптимизации авторами [2], в предположении несмещенности градиента не была доказана сходимость для нелинейного случая

Подробнее можно посмотреть в доказательстве леммы C.1 в [2]

Bibliography

- [1] Allen-Zhu, Z. (2016). Katyusha: The first direct acceleration of stochastic gradient methods
- [2] Anonymous Authors (2024). Accelerated Methods with Compression for Horizontal and Vertical Federated Learning
- [3] Kovalev, D., Horvath, S., and Richtarik, P. (2019). Don't Jump Through Hoops and Remove Those Loops: SVRG and Katyusha are Better Without the Outer Loop
- [4] Ernie Chan, Marcel Heimlich, Avi Purkayastha and Robert van de Geijn (2006). Collective communication: theory, practice, and experience. Wiley InterScience.
- [5] Anastasia Koloskova, Nicolas Loizou, Sadra Boreiri, Martin Jaggi, Sebastian U. Stich (2020). A Unified Theory of Decentralized SGD with Changing Topology and Local Updates