

Современные Безградиентные Рандомизированные Алгоритмы Выпуклой Оптимизации

Лобанов Александр Владимирович

Московский физико-технический институт
Сколковский институт науки и технологий
Институт системного программирования им. В. П. Иванникова РАН

lobbsasha@mail.ru

27 июня 2024

Рассматривается задача выпуклой оптимизации

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$

Вопрос

Когда следует использовать безградиентные алгоритмы?

Рассматривается задача выпуклой оптимизации

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$

Вопрос

Когда следует использовать безградиентные алгоритмы?

Подходы для создания рандомизированных безградиентных методов

- **Негладкий случай**
 - Схема сглаживания с l_1 рандомизацией
 - Схема сглаживания с l_2 рандомизацией
- **Гладкий случай**
 - l_1 рандомизация
 - l_2 рандомизация
- **Случай с повышенной гладкостью**
 - Рандомизация с помощью ядра

Рассматривается задача выпуклой оптимизации

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$

Вопрос

Когда следует использовать безградиентные алгоритмы?

Критерии оптимальности

- 1 Число оракульных вызовов: T
- 2 Число последовательных итераций метода: N
- 3 Максимально допустимый уровень шума Δ

Мотивация для поиска максимального уровня шума



Рис.: Экономия ресурсов



Рис.: Устойчивость к атакам



Рис.: Конфиденциальность

- 1 **Экономия ресурсов.** Чем точнее вычисляется значение объективной функции, тем дороже этот процесс.
- 2 **Устойчивость к атакам.** Повышение максимального уровня шума делает алгоритм более устойчивым к враждебным атакам.
- 3 **Конфиденциальность.** Некоторые компании из-за секретности не могут передать всю информацию.

1 Негладкая задача оптимизации

- Постановка задачи
- Основная идея
- Схемы сглаживания
- Безградиентные методы в архитектуре федеративного обучения

2 Гладкая задача оптимизации

- Постановка задачи
- Ускоренный стохастический градиентный спуск с неточным оракулом
- Ускоренный стохастический градиентный спуск нулевого порядка

3 Задача оптимизации с повышенной гладкостью

- Постановка задачи
- Выбор алгоритма первого порядка
- Главный результат
- Эксперименты

4 Задача оптимизации с Order Oracle

1 Негладкая задача оптимизации

- Постановка задачи
- Основная идея
- Схемы сглаживания
- Безградиентные методы в архитектуре федеративного обучения

2 Гладкая задача оптимизации

- Постановка задачи
- Ускоренный стохастический градиентный спуск с неточным оракулом
- Ускоренный стохастический градиентный спуск нулевого порядка

3 Задача оптимизации с повышенной гладкостью

- Постановка задачи
- Выбор алгоритма первого порядка
- Главный результат
- Эксперименты

4 Задача оптимизации с Order Oracle

Постановка задачи

Рассматривается стохастическая негладкая выпуклая задача оптимизации

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x) := \mathbb{E}_\xi [f(x, \xi)]$$

Безградиентный оракул

Предполагается, что безградиентный оракул возвращает значение функции $f(x)$, возможно, с некоторым враждебным шумом $\delta(x)$:

$$f_\delta(x) := f(x) + \delta(x)$$

Предположения

Предположение 1. (Липшицева непрерывная функция).

Функция $f(x, \xi)$ является M -Липшицевой непрерывной функцией в l_p -норме, то есть для всех $x, y \in Q$ имеем

$$|f(y, \xi) - f(x, \xi)| \leq M(\xi) \|y - x\|_p.$$

Более того, существует положительная константа M , которая определяется следующим образом: $\mathbb{E} [M^2(\xi)] \leq M^2$. В частности, для $p = 2$ используем обозначение M_2 для константы Липшица.

Предположение 2. (Ограничность шума).

Для всех $x \in Q$ выполняется $|\delta(x)| \leq \Delta$, где Δ – уровень неточности (шума).

Негладкая задача

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$



Гладкая задача

$$\min_{x \in Q \subseteq \mathbb{R}^d} f_\gamma(x)$$

Definition

Пусть l_p -шар определяется, как $B_p^d(r) := \{x \in \mathbb{R}^d : \|x\|_p \leq r\}$. Тогда гладкая аппроксимация негладкой функции $f(x)$ выглядит следующим образом

$$f_\gamma(x) := \mathbb{E}_{\tilde{e}} [f(x + \gamma \tilde{e})],$$

где $\gamma > 0$, \tilde{e} — случайный вектор, равномерно распределенный на $B_p^d(1)$ (далее ограничимся рассмотрением случаев $p = 1$ и $p = 2$).

Свойства функции $f_\gamma(x)$

Случай, когда $\tilde{e} \in RB_2^d(1)$

① $f(x) \leq f_\gamma(x) \leq f(x) + \gamma M_2;$

② f_γ — M -Липшицева:

$$|f_\gamma(y) - f_\gamma(x)| \leq M\|y - x\|_p,$$

③ f_γ имеет $L_{f_\gamma} = \frac{\sqrt{d}M}{\gamma}$ -Липшицевый градиент:

$$\|\nabla f_\gamma(y) - \nabla f_\gamma(x)\|_q \leq L_{f_\gamma}\|y - x\|_p.$$

где q такой, что $1/p + 1/q = 1$.

Первое свойство

$$f_\gamma(x) = \mathbb{E}_{\tilde{e}} [f(x + \gamma \tilde{e})] \geq \mathbb{E}_{\tilde{e}} [f(x) + \langle \nabla f(x), \gamma \tilde{e} \rangle] = \mathbb{E}_{\tilde{e}} [f(x)] = f(x).$$

$$|f_\gamma(x) - f(x)| = |\mathbb{E}_{\tilde{e}} [f(x + \gamma \tilde{e})] - f(x)| \leq \mathbb{E}_{\tilde{e}} [|f(x + \gamma \tilde{e}) - f(x)|] \leq \gamma M_2 \mathbb{E}_{\tilde{e}} [\|\tilde{e}\|_2] \leq \gamma M_2.$$

Свойства функции $f_\gamma(x)$

Случай, когда $\tilde{e} \in RB_2^d(1)$

- ① $f(x) \leq f_\gamma(x) \leq f(x) + \gamma M_2$;
- ② f_γ — M -Липшицева:

$$|f_\gamma(y) - f_\gamma(x)| \leq M \|y - x\|_p,$$

- ③ f_γ имеет $L_{f_\gamma} = \frac{\sqrt{d}M}{\gamma}$ -Липшицевый градиент:

$$\|\nabla f_\gamma(y) - \nabla f_\gamma(x)\|_q \leq L_{f_\gamma} \|y - x\|_p.$$

где q такой, что $1/p + 1/q = 1$.

Второе свойство

$$|f_\gamma(y) - f_\gamma(x)| = |\mathbb{E}_{\tilde{e}} [f(y + \gamma \tilde{e}) - f(x + \gamma \tilde{e})]| \leq \mathbb{E}_{\tilde{e}} [|f(y + \gamma \tilde{e}) - f(x + \gamma \tilde{e})|] \leq M \|y - x\|_p$$

Свойства функции $f_\gamma(x)$

Случай, когда $\tilde{e} \in RB_1^d(1)$

① $f(x) \leq f_\gamma(x) \leq f(x) + \frac{2}{\sqrt{d}}\gamma M_2;$

② f_γ — M -Липшицева:

$$|f_\gamma(y) - f_\gamma(x)| \leq M\|y - x\|_p,$$

③ f_γ имеет $L_{f_\gamma} = \frac{dM}{2\gamma}$ -Липшицевый градиент:

$$\|\nabla f_\gamma(y) - \nabla f_\gamma(x)\|_q \leq L_{f_\gamma}\|y - x\|_p.$$

где q такой, что $1/p + 1/q = 1$.

Первое свойство

$$f_\gamma(x) = \mathbb{E}_{\tilde{e}} [f(x + \gamma\tilde{e})] \geq \mathbb{E}_{\tilde{e}} [f(x) + \langle \nabla f(x), \gamma\tilde{e} \rangle] = \mathbb{E}_{\tilde{e}} [f(x)] = f(x).$$

$$|f_\gamma(x) - f(x)| = |\mathbb{E}_{\tilde{e}} [f(x + \gamma\tilde{e})] - f(x)| \leq \mathbb{E}_{\tilde{e}} [|f(x + \gamma\tilde{e}) - f(x)|]$$

$$\leq \gamma M_2 \mathbb{E}_{\tilde{e}} [\|\tilde{e}\|_2] \leq \frac{2}{\sqrt{d}}\gamma M_2.$$

Свойства функции $f_\gamma(x)$

Случай, когда $\tilde{e} \in RB_1^d(1)$

① $f(x) \leq f_\gamma(x) \leq f(x) + \frac{2}{\sqrt{d}}\gamma M_2;$

② f_γ — M -Липшицева:

$$|f_\gamma(y) - f_\gamma(x)| \leq M\|y - x\|_p,$$

③ f_γ имеет $L_{f_\gamma} = \frac{dM}{2\gamma}$ -Липшицевый градиент:

$$\|\nabla f_\gamma(y) - \nabla f_\gamma(x)\|_q \leq L_{f_\gamma}\|y - x\|_p.$$

где q такой, что $1/p + 1/q = 1$.

Лемма 1 из [2] для первого свойства

Пусть $q \in [1, \infty)$ и пусть $v \in RB_1^d(1)$. Тогда

$$\mathbb{E}[\|v\|_q] \leq \frac{qd^{\frac{1}{q}}}{d+1}$$

Свойства функции $f_\gamma(x)$

Случай, когда $\tilde{e} \in RB_1^d(1)$

① $f(x) \leq f_\gamma(x) \leq f(x) + \frac{2}{\sqrt{d}}\gamma M_2;$

② f_γ — M -Липшицева:

$$|f_\gamma(y) - f_\gamma(x)| \leq M\|y - x\|_p,$$

③ f_γ имеет $L_{f_\gamma} = \frac{dM}{2\gamma}$ -Липшицевый градиент:

$$\|\nabla f_\gamma(y) - \nabla f_\gamma(x)\|_q \leq L_{f_\gamma}\|y - x\|_p.$$

где q такой, что $1/p + 1/q = 1$.

Второе свойство

$$|f_\gamma(y) - f_\gamma(x)| = |\mathbb{E}_{\tilde{e}} [f(y + \gamma\tilde{e}) - f(x + \gamma\tilde{e})]| \leq \mathbb{E}_{\tilde{e}} [|f(y + \gamma\tilde{e}) - f(x + \gamma\tilde{e})|] \leq M\|y - x\|_p$$

Основная идея

Негладкая задача

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$



Гладкая задача

$$\min_{x \in Q \subseteq \mathbb{R}^d} f_\gamma(x)$$

Связь между задачами

Если имеем $\frac{\varepsilon}{2}$ -точность для функции $f_\gamma(x)$, то имеем ε -точность для функции $f(x)$:

$$\begin{aligned} f(x^{N+1}) - f(x_*) &\stackrel{\textcircled{1}}{\leq} f_\gamma(x^{N+1}) - f(x_*) \stackrel{\textcircled{2}}{\leq} f_\gamma(x^{N+1}) - f_\gamma(x_*) + \gamma M_2 \\ &\leq f_\gamma(x^{N+1}) - f_\gamma(x_*(\gamma)) + \gamma M_2 \leq \frac{\varepsilon}{2} + \frac{\varepsilon}{2} = \varepsilon, \end{aligned}$$

Рандомизация с двухточечной обратной связью

Обобщение формулы Стокса [2]

$$\nabla f_\gamma(x) = \mathbb{E}_{\tilde{e}}[\nabla f(x + \gamma \tilde{e})] = \frac{\text{Vol}_{d-1}(\partial D)}{\text{Vol}_d(D)} \cdot \mathbb{E}_e[f(x + \gamma e)n(e)]$$

Рандомизация с двухточечной обратной связью

l_1 -рандомизация

$$\nabla f_\gamma(x, \xi, e) = \frac{d}{2\gamma}(f_\delta(x + \gamma e, \xi) - f_\delta(x - \gamma e, \xi))\text{sign}(e), \quad (e \in RS_1^d(1))$$

l_2 -рандомизация

$$\nabla f_\gamma(x, \xi, e) = \frac{d}{2\gamma}(f_\delta(x + \gamma e, \xi) - f_\delta(x - \gamma e, \xi))e, \quad (e \in RS_2^d(1))$$

Свойства ∇f_γ для l_1 -рандомизации

- 1 Если $\Delta = 0$, то оценки будут несмещеными

$$\mathbb{E}_{e,\xi} [\nabla f_\gamma(x, \xi, e)] = \nabla f_\gamma(x)$$

- 2 ("смещение") при $\Delta > 0$

$$\mathbb{E}_{e,\xi} \langle [\nabla f_\gamma(x, \xi, e)] - \nabla f_\gamma(x), r \rangle \lesssim \frac{d\Delta R}{\gamma}, \quad \forall r : \|r\|_2 \leq R.$$

- 3 (оценка второго момента)

$$\mathbb{E}_{e,\xi} [\|\nabla f_\gamma(x, \xi, e)\|_q^2] \leq \kappa(p, d) \left(M_2^2 + \frac{d^2 \Delta^2}{12(1 + \sqrt{2})^2 \gamma^2} \right),$$

где $1/p + 1/q = 1$ и $\kappa(p, d) = 48(1 + \sqrt{2})^2 d^{2 - \frac{2}{p}}$.

Свойства ∇f_γ для l_2 -рандомизации

- ① Если $\Delta = 0$, то оценки будут несмешенными

$$\mathbb{E}_{e,\xi} [\nabla f_\gamma(x, \xi, e)] = \nabla f_\gamma(x)$$

- ② ("смещение") при $\Delta > 0$

$$\mathbb{E}_{e,\xi} \langle [\nabla f_\gamma(x, \xi, e)] - \nabla f_\gamma(x), r \rangle \lesssim \frac{\sqrt{d}\Delta R}{\gamma}, \quad \forall r : \|r\|_2 \leq R.$$

- ③ (оценка второго момента)

$$\mathbb{E}_{e,\xi} [\|\nabla f_\gamma(x, \xi, e)\|_q^2] \leq \kappa(p, d) \left(M_2^2 + \frac{d^2 \Delta^2}{\sqrt{2}\gamma^2} \right),$$

где $1/p + 1/q = 1$ и $\kappa(p, d) = \sqrt{2} \min \{q, \ln d\} d^{2-\frac{2}{p}}$.

Основная идея

Негладкая задача

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$



Гладкая задача

$$\min_{x \in Q \subseteq \mathbb{R}^d} f_\gamma(x)$$

Связь между задачами

Если имеем $\frac{\varepsilon}{2}$ -точность для функции $f_\gamma(x)$, то имеем ε -точность для функции $f(x)$:

$$\begin{aligned} f(x^{N+1}) - f(x_*) &\stackrel{(1)}{\leq} f_\gamma(x^{N+1}) - f(x_*) \stackrel{(2)}{\leq} f_\gamma(x^{N+1}) - f_\gamma(x_*) + \gamma M_2 \\ &\leq f_\gamma(x^{N+1}) - f_\gamma(x_*(\gamma)) + \gamma M_2 \leq \frac{\varepsilon}{2} + \frac{\varepsilon}{2} = \varepsilon, \end{aligned}$$

Параметры

$$\gamma = \frac{\varepsilon}{2M_2}$$

$$L_{f_\gamma} = \frac{\sqrt{d}M}{\gamma} = \frac{2\sqrt{d}MM_2}{\varepsilon}$$

$$\sigma^2 \leq 2\sqrt{2} \min \{q, \ln d\} d^{2-\frac{2}{p}} M_2^2$$




Рис.: Архитектура федеративного обучения

Algorithm	$\mathbb{E}[f(\cdot)] - f^* \lesssim \dots$	Reference
Mb-Ac-SGD	$\frac{LR^2}{N^2} + \frac{\sigma R}{\sqrt{BNK}}$	(Woodworth et al., 2021) [3]
SM-Ac-SGD	$\frac{LR^2}{N^2 K^2} + \frac{\sigma R}{\sqrt{NK}}$	(Woodworth et al., 2021) [3]
Local-AC-CA	$\frac{LR^2}{N^2 K^2} + \frac{\sigma R}{\sqrt{BNK}}$	(Woodworth et al., 2020) [4]
FedAc	$\frac{LR^2}{N^2 K} + \frac{\sigma R}{\sqrt{BNK}} + \min \left\{ \frac{L^{\frac{1}{3}} \sigma^{\frac{2}{3}} R^{\frac{4}{3}}}{NK^{\frac{1}{3}}}, \frac{L^{\frac{1}{2}} \sigma^{\frac{1}{2}} R^{\frac{3}{2}}}{NK^{\frac{1}{4}}} \right\}$	(Yuan, Ma, 2020) [5]
Mb-SMP	$\max \left\{ \frac{LR^2}{N}, \frac{\sigma R}{\sqrt{BNK}} \right\}$	
SM-SMP	$\max \left\{ \frac{LR^2}{NK}, \frac{\sigma R}{\sqrt{NK}} \right\}$	

Таблица: Результаты скорости сходимости.

Обозначение: $R : \|x^0 - x_*\|$; B : число рабочих (компьютеров); K : число локальных обновлений; N : число коммуникационных раундов; L : гладкость.

Главный результат

Theorem

Схема сглаживания, применяемая к негладкой задаче, обеспечивает сходимость *Minibatch Accelerated SGD* [3]. Другими словами, для достижения ε точности решения негладкой задачи необходимо проделать NK итераций с максимально допустимым уровнем шума Δ и общим числом вызова безградиентного оракула T в соответствии с выбранным методом и схемой сглаживания:

- l_1 -рандомизация

$$N = O\left(\frac{d^{1/4}\sqrt{MM_2}R}{\varepsilon}\right); \quad K = 1; \quad B = O\left(\frac{\kappa(p, d)dM_2^2R^2}{KN\varepsilon^2}\right);$$
$$T = \tilde{O}\left(\frac{\kappa(p, d)dM_2^2R^2}{\varepsilon^2}\right) = \begin{cases} O\left(\frac{dM_2^2R^2}{\varepsilon^2}\right), & p = 2 \ (q = 2) \\ O\left(\frac{M_2^2R^2}{\varepsilon^2}\right), & p = 1 \ (q = \infty). \end{cases}$$

Главный результат

Theorem





Схема сглаживания, применяемая к негладкой задаче, обеспечивает сходимость *Minibatch Accelerated SGD* [3]. Другими словами, для достижения ε точности решения негладкой задачи необходимо проделать NK итераций с максимально допустимым уровнем шума Δ и общим числом вызова безградиентного оракула T в соответствии с выбранным методом и схемой сглаживания:

- l_2 -рандомизация

$$N = O\left(\frac{d^{1/4}\sqrt{MM_2}R}{\varepsilon}\right); \quad K = 1; \quad B = O\left(\frac{\kappa(p, d)dM_2^2R^2}{KN\varepsilon^2}\right);$$

$$T = \tilde{O}\left(\frac{\kappa(p, d)dM_2^2R^2}{\varepsilon^2}\right) = \begin{cases} \tilde{O}\left(\frac{dM_2^2R^2}{\varepsilon^2}\right), & p = 2 (q = 2) \\ \tilde{O}\left(\frac{(\ln d)M_2^2R^2}{\varepsilon^2}\right), & p = 1 (q = \infty). \end{cases}$$

Эксперименты



Содержание

1 Негладкая задача оптимизации

- Постановка задачи
- Основная идея
- Схемы сглаживания
- Безградиентные методы в архитектуре федеративного обучения

2 Гладкая задача оптимизации

- Постановка задачи
- Ускоренный стохастический градиентный спуск с неточным оракулом
- Ускоренный стохастический градиентный спуск нулевого порядка

3 Задача оптимизации с повышенной гладкостью

- Постановка задачи
- Выбор алгоритма первого порядка
- Главный результат
- Эксперименты

4 Задача оптимизации с Order Oracle

Постановка задачи

Рассматривается стандартная стохастическая выпуклая задача оптимизации

$$f^* = \min_{x \in \mathbb{R}^d} \{f(x) := \mathbb{E}[f(x, \xi)]\},$$

где $f : \mathbb{R}^d \rightarrow \mathbb{R}$ – гладкая выпуклая функция, которую мы хотим минимизировать на \mathbb{R}^d . Данная постановка задачи является общей, поэтому, чтобы определить конкретный класс задач (который будем рассматривать), вводится некоторые предположения о целевой функции и градиентном оракуле.

Предположения о целевой функции

Предположение 1. (Выпуклость)

Почти для каждого ξ , $f(x, \xi)$ – неотрицательная и выпуклая функция относительно x , т.е.

$$\forall x, y, \xi \quad f(y, \xi) \geq f(x, \xi) + \langle \nabla f(x, \xi), y - x \rangle.$$

Предположение 2. (Гладкость)

Почти для каждого ξ , $f(x, \xi)$ – неотрицательная, L -гладкая функция относительно x , т.е.

$$\forall x, y, \xi \quad f(y, \xi) \leq f(x, \xi) + \langle \nabla f(x, \xi), y - x \rangle + \frac{L}{2} \|y - x\|^2.$$

Предположение 3.

Функция $f(x)$ – выпуклая и имеет минимальное значение $f^* = \min_x f(x)$, которое достигается в точке x^* с $\|x^*\| \leq R$.

Определение 1. (Градиентный оракул)

Отображение $\mathbf{g} : \mathbb{R}^d \times \mathcal{D} \rightarrow \mathbb{R}^d$ такое что

$$\mathbf{g}(x, \xi) = \nabla f(x, \xi) + \mathbf{b}(x),$$

где $\mathbf{b} : \mathbb{R}^d \rightarrow \mathbb{R}^d$ такой что $\forall x \in \mathbb{R}^d : \|\mathbf{b}(x)\|^2 \leq \zeta^2$.

Предположения о градиентном оракуле

Определение 1. (Градиентный оракул)

Отображение $\mathbf{g} : \mathbb{R}^d \times \mathcal{D} \rightarrow \mathbb{R}^d$ такое что

$$\mathbf{g}(x, \xi) = \nabla f(x, \xi) + \mathbf{b}(x),$$

где $\mathbf{b} : \mathbb{R}^d \rightarrow \mathbb{R}^d$ такой что $\forall x \in \mathbb{R}^d : \|\mathbf{b}(x)\|^2 \leq \zeta^2$.

Предположение 4. (Ограниченност градиентного шума)

Существует параметр $\sigma_*^2 \geq 0$ такой что $\forall x \in \mathbb{R}^d$

$$\mathbb{E} \left[\|\nabla f(x^*, \xi) - \nabla f(x^*)\|^2 \right] \leq \sigma_*^2.$$

Предположения о градиентном оракуле

Определение 1. (Градиентный оракул)

Отображение $\mathbf{g} : \mathbb{R}^d \times \mathcal{D} \rightarrow \mathbb{R}^d$ такое что

$$\mathbf{g}(x, \xi) = \nabla f(x, \xi) + \mathbf{b}(x),$$

где $\mathbf{b} : \mathbb{R}^d \rightarrow \mathbb{R}^d$ такой что $\forall x \in \mathbb{R}^d : \|\mathbf{b}(x)\|^2 \leq \zeta^2$.

Предположение 4. (Ограниченност градиентного шума)

Существует параметр $\sigma_*^2 \geq 0$ такой что $\forall x \in \mathbb{R}^d$

$$\mathbb{E} \left[\|\nabla f(x^*, \xi) - \nabla f(x^*)\|^2 \right] \leq \sigma_*^2.$$

Сходимость алгоритма AC-SA из [6] для перепараметризованной задачи

$$\mathbb{E} \left[f(x_N^{ag}) - f^* \right] \leq c \cdot \left(\frac{LR^2}{N^2} + \frac{LR^2}{BN} + \sqrt{\frac{LR^2 f^*}{BN}} \right).$$

Theorem (Сходимость Смешенного AC-SA метода)

Пусть f удовлетворяет Предположениям 1–3 и градиентный оракул из Определения 1 удовлетворяет Предположению 4, тогда смешенный AC-SA алгоритм гарантирует сходимость с универсальной константой c

$$\mathbb{E} [f(x_N^{ag}) - f^*] \leq c \cdot \left(\frac{LR^2}{N^2} + \frac{LR^2}{BN} + \frac{\sigma_* R}{\sqrt{BN}} + \zeta R + \frac{\zeta^2}{2L} N \right).$$

Algorithm 1 Accelerated Zero-Order Stochastic Gradient Descent (AZO-SGD)

Input: Start point $x_0^{ag} = x_0 \in \mathbb{R}^d$, maximum number of iterations $N \in \mathbb{Z}_+$.

Let stepsize $\eta_k > 0$, parameters $\beta_k, \tau > 0$, batch size $B \in \mathbb{Z}_+$.

1: **for** $k = 0, \dots, N - 1$ **do**

2: $\beta_k = 1 + \frac{k}{6}$ and $\eta_k = \eta(k + 1)$ for $\gamma = \min \left\{ \frac{1}{12L}, \frac{B}{24L(N+1)}, \sqrt{\frac{BR^2}{L f^* N^3}} \right\}$

3: $x_k^{md} = \beta_k^{-1} x_k + (1 - \beta_k^{-1}) x_k^{ag}$

4: Sample $\{e_1, \dots, e_B\}$ and $\{\xi_1, \dots, \xi_B\}$ independently

5: Define $\mathbf{g}_k = \frac{1}{B} \sum_{i=1}^B \mathbf{g}(x_k^{md}, \xi_i, e_i)$ using (3)

6: $\tilde{x}_{k+1} = x_k - \eta_k \mathbf{g}_k$

7: $x_{k+1} = \min \left\{ 1, \frac{R}{\|\tilde{x}_{k+1}\|} \right\} \tilde{x}_{k+1}$

8: $x_{k+1}^{ag} = \beta_k^{-1} x_{k+1} + (1 - \beta_k^{-1}) x_{k+1}^{ag}$

9: **end for**

Output: x_N^{ag} .

Смещение аппроксимации градиента

$$\begin{aligned}\|\mathbb{E}[\mathbf{g}(x_k, \xi, e)] - \nabla f(x_k)\| &= \left\| \mathbb{E} \left[\frac{d}{2\tau} (f_\delta(x_k + \tau e, \xi) - f_\delta(x_k - \tau e)) e \right] - \nabla f(x_k) \right\| \\ &\stackrel{\textcircled{1}}{=} \left\| \mathbb{E} \left[\frac{d}{\tau} (f(x_k + \tau e, \xi) + \delta(x_k + \tau e)) e \right] - \nabla f(x_k) \right\| \\ &\stackrel{\textcircled{2}}{\leq} \left\| \mathbb{E} \left[\frac{d}{\tau} f(x_k + \tau e, \xi) e \right] - \nabla f(x_k) \right\| + \frac{d\Delta}{\tau} \\ &\stackrel{\textcircled{3}}{=} \left\| \mathbb{E} [\nabla f(x_k + \tau u, \xi)] - \nabla f(x_k) \right\| + \frac{d\Delta}{\tau} \\ &= \sup_{z \in S_2^d(1)} \mathbb{E} [|\nabla_z f(x_k + \tau u) - \nabla_z f(x_k)|] + \frac{d\Delta}{\tau} \\ &\leq L\tau \mathbb{E} [\|u\|] + \frac{d\Delta}{\tau} \leq L\tau + \frac{d\Delta}{\tau}.\end{aligned}$$

Второй момент аппроксимации градиента

$$\begin{aligned}\mathbb{E} \left[\|\mathbf{g}(x^*, \xi, e)\|^2 \right] &= \frac{d^2}{4\tau^2} \mathbb{E} \left[\|(f_\delta(x^* + \tau e, \xi) - f_\delta(x^* - \tau e, \xi)) e\|^2 \right] \\ &= \frac{d^2}{4\tau^2} \mathbb{E} \left[(f(x^* + \tau e, \xi) - f(x^* - \tau e, \xi) + \delta(x^* + \tau e) - \delta(x^* - \tau e))^2 \right] \\ &\leq \frac{d^2}{2\tau^2} \left(\mathbb{E} \left[(f(x^* + \tau e, \xi) - f(x^* - \tau e, \xi))^2 \right] + 2\Delta^2 \right) \\ &\leq \frac{d^2}{2\tau^2} \left(\frac{\tau^2}{d} \mathbb{E} \left[\|\nabla f(x^* + \tau e, \xi) + \nabla f(x^* - \tau e, \xi)\|^2 \right] + 2\Delta^2 \right) \\ &= \frac{d^2}{2\tau^2} \left(\frac{\tau^2}{d} \mathbb{E} \left[\|\nabla f(x^* + \tau e, \xi) + \nabla f(x^* - \tau e, \xi) \pm 2\nabla f(x^*, \xi)\|^2 \right] + 2\Delta^2 \right) \\ &\leq 4d \|\nabla f(x^*, \xi)\|^2 + 4dL^2\tau^2 \mathbb{E} \left[\|e\|^2 \right] + \frac{d^2\Delta^2}{\tau^2} \\ &\leq 4d\sigma_*^2 + 4dL^2\tau^2 \mathbb{E} \left[\|e\|^2 \right] + \frac{d^2\Delta^2}{\tau^2}.\end{aligned}$$

Главный результат

Сходимость безградиентного алгоритма

$$\begin{aligned}\mathbb{E} [f(x_N^{ag}) - f^*] &\lesssim \underbrace{\frac{LR^2}{N^2}}_{\textcircled{1}} + \underbrace{\frac{LR^2}{BN}}_{\textcircled{2}} + \underbrace{\frac{\sqrt{d}\sigma_* R}{\sqrt{BN}}}_{\textcircled{3}} + \underbrace{\frac{\sqrt{d}L\tau R}{\sqrt{BN}}}_{\textcircled{4}} + \underbrace{\frac{d\Delta R}{\tau\sqrt{BN}}}_{\textcircled{5}} \\ &\quad + \underbrace{L\tau R}_{\textcircled{6}} + \underbrace{\frac{d\Delta R}{\tau}}_{\textcircled{7}} + \underbrace{L\tau^2 N}_{\textcircled{8}} + \underbrace{\frac{d^2\Delta^2 N}{\tau^2 L}}_{\textcircled{9}}.\end{aligned}$$

Главный результат

Theorem

Пусть f удовлетворяет Предположениям 1–3 и аппроксимация градиента с параметром $\tau \leq \frac{\varepsilon}{LR}$ удовлетворяет Предположению 4, тогда Accelerated Zero-Order Stochastic Gradient Descent (AZO-SGD) Method (см. Алгоритм 1) достигает ε -точности: $\mathbb{E} [f(x_N^{ag}) - f^*] \leq \varepsilon$ после

$$N = \mathcal{O} \left(\sqrt{\frac{LR^2}{\varepsilon}} \right), \quad T = \max \left\{ \mathcal{O} \left(\frac{LR^2}{\varepsilon} \right), \mathcal{O} \left(\frac{d\sigma_*^2 R^2}{\varepsilon^2} \right) \right\}$$

числа итераций, общего числа обращений к безградиентному оракулу и при

$$\Delta \leq \frac{\varepsilon^2}{dLR^2}$$

максимально допустимом уровне враждебного шума.

Обобщение на задачу с ограничением и расширение класса функций (L_p норма)

Замечание 1.

Используя работу [7] (а именно, Алгоритм 2) в качестве основы, и аналогичным образом обобщая результаты сходимости (Следствие 1, [7]) на случай с градиентным оракулом, можно получить безградиентный алгоритм для более общего класса задач (L_p -норма и наличие ограничений). В этом случае, параметры (число последовательных итераций N , максимально допустимый уровень враждебного шума Δ , параметр сглаживания τ) останутся такими же, за исключением общего числа обращений к безградиентному оракулу: пусть дано $1/p + 1/q = 1$, тогда


$$T = N \cdot B = \max \left\{ \mathcal{O} \left(\frac{LR^2}{\varepsilon} \right), \mathcal{O} \left(\frac{\min\{q, \ln d\} d^{2-\frac{2}{p}} \sigma_*^2 R^2}{\varepsilon^2} \right) \right\}.$$

Эксперименты

Мы рассматриваем следующую задачу оптимизации:

$$\min_{x \in \mathbb{R}^d} f(x) := \frac{1}{m} \sum_{i=1}^m (l_i(x))^2,$$

где $l(x) = Ax - b$ – система m линейных уравнений в условии перепараметризации ($d > m$), $A \in \mathbb{R}^{m \times d}$, $x, b \in \mathbb{R}^d$. Данная задача является выпуклой стохастической задачей оптимизации, также известной как the Empirical Risk Minimization problem, где $\xi = i$ – одна из m линейных уравнений.



Содержание

1 Негладкая задача оптимизации

- Постановка задачи
- Основная идея
- Схемы сглаживания
- Безградиентные методы в архитектуре федеративного обучения

2 Гладкая задача оптимизации

- Постановка задачи
- Ускоренный стохастический градиентный спуск с неточным оракулом
- Ускоренный стохастический градиентный спуск нулевого порядка

3 Задача оптимизации с повышенной гладкостью

- Постановка задачи
- Выбор алгоритма первого порядка
- Главный результат
- Эксперименты

4 Задача оптимизации с Order Oracle

Предположения на целевую функцию

Постановка задачи

Мы рассматриваем стандартную выпуклую задачу оптимизации:

$$\min_{x \in Q \subseteq \mathbb{R}^d} f(x)$$

где $f : \mathbb{R}^d \rightarrow \mathbb{R}$ выпуклая функция, которую хотим минимизировать на выпуклом мн-ве Q .

Предположение. (Повышенная гладкость функции)

Пусть l обозначает максимальное целое число строго меньше, чем β . Пусть $\mathcal{F}_\beta(L)$ обозначает множество всех функций $f : \mathbb{R}^d \rightarrow \mathbb{R}$, которые дифференцируемы l раз и для всех $x, z \in Q$ удовлетворяет условию Гельдера:

$$\left| f(z) - \sum_{0 \leq |n| \leq l} \frac{1}{n!} D^n f(x) (z - x)^n \right| \leq L_\beta \|z - x\|_2^\beta,$$

где $L_\beta > 0$, $n = (n_1, \dots, n_d)$ – мультииндекс, $n_i \geq 0$ – целые, $n! = n_1! \cdots n_d!$, $|n| = n_1 + \cdots + n_d$, и $\forall v = (v_1, \dots, v_d) \in \mathbb{R}^d$, а также $D^n f(x) v^n = \frac{\partial^{|n|} f(x)}{\partial^{n_1} x_1 \cdots \partial^{n_d} x_d} v_1^{n_1} \cdots v_d^{n_d}$.

Оракул нулевого порядка

Мы предполагаем, что оракул \tilde{f} может возвращать только значение целевой функции $f(x)$ в запрашиваемой точке x с некоторым стохастическим шумом ξ :

$$\tilde{f} = f(x) + \xi.$$

Предположение. (Стохастический шум)

Мы предполагаем, что выполняется следующее

- $\xi_1 \neq \xi_2$ такой что $\mathbb{E}[\xi_1^2] \leq \Delta^2$ и $\mathbb{E}[\xi_2^2] \leq \Delta^2$, $\Delta \geq 0$ – это уровень шума;
- случайные величины ξ_1 и ξ_2 являются независимыми от \mathbf{e} и r .

Градиентная аппроксимация с одноточечной обратной связью

$$\mathbf{g}(x, \mathbf{e}) = d \frac{f(x + h \mathbf{r} \mathbf{e}) + \xi_1 - f(x - h \mathbf{r} \mathbf{e}) - \xi_2}{2h} K(r) \mathbf{e}.$$

Определение. (Ядерная аппроксимация)

$$\mathbf{g}(x, \mathbf{e}) = d \frac{f(x + h r \mathbf{e}) + \xi_1 - f(x - h r \mathbf{e}) - \xi_2}{2h} K(r) \mathbf{e}.$$

где $h > 0$ – параметр сглаживания, $\mathbf{e} \in S_2^d(1)$ – равномерно распределенный вектор на единичной евклидовой сфере, r – случайный вектор равномерно распределенный на отрезке $r \in [0, 1]$.

Предположения на градиентную аппроксимацию

Определение. (Ядерная аппроксимация)

$$\mathbf{g}(x, \mathbf{e}) = d \frac{f(x + h r \mathbf{e}) + \xi_1 - f(x - h r \mathbf{e}) - \xi_2}{2h} K(r) \mathbf{e}.$$

где $h > 0$ – параметр сглаживания, $\mathbf{e} \in S_2^d(1)$ – равномерно распределенный вектор на единичной евклидовой сфере, r – случайный вектор равномерно распределенный на отрезке $r \in [0, 1]$.

Предположение. (Ядерная функция)

Пусть $K : [-1, 1] \rightarrow \mathbb{R}$ – Ядерная функция, которая удовлетворяет

$$\begin{aligned}\mathbb{E}[K(u)] &= 0, \quad \mathbb{E}[uK(u)] = 1, \\ \mathbb{E}[u^j K(u)] &= 0, \quad j = 2, \dots, l, \quad \mathbb{E}[|u|^\beta |K(u)|] < \infty.\end{aligned}$$

Предположения на градиентную аппроксимацию

Определение. (Ядерная аппроксимация)

$$\mathbf{g}(x, \mathbf{e}) = d \frac{f(x + h \mathbf{r} \mathbf{e}) + \xi_1 - f(x - h \mathbf{r} \mathbf{e}) - \xi_2}{2h} K(r) \mathbf{e}.$$

где $h > 0$ – параметр сглаживания, $\mathbf{e} \in S_2^d(1)$ – равномерно распределенный вектор на единичной евклидовой сфере, r – случайный вектор равномерно распределенный на отрезке $r \in [0, 1]$.

Предположение. (Ядерная функция)

Пусть $K : [-1, 1] \rightarrow \mathbb{R}$ – Ядерная функция, которая удовлетворяет

$$\begin{aligned}\mathbb{E}[K(u)] &= 0, \quad \mathbb{E}[uK(u)] = 1, \\ \mathbb{E}[u^j K(u)] &= 0, \quad j = 2, \dots, l, \quad \mathbb{E}[|u|^\beta |K(u)|] < \infty.\end{aligned}$$

Примеры Ядерной функции

Примером таких ядер является взвешенная сумма полиномов Лежандра.

Что было сделано ранее?

References	Iteration Complexity	Maximum Noise Level
Bach, Perchet (2016) [1]	$\mathcal{O} \left(\frac{d^{2+\frac{2}{\beta-1}} \Delta^2}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$	X
Novitskii, Gasnikov (2020) [2]	$\tilde{\mathcal{O}} \left(\frac{d^{1+\frac{1}{\beta-1}} \Delta^2}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$	X
Akhavan, Chzhen, Pontil, Tsybakov (2023) [3]	$\tilde{\mathcal{O}} \left(\frac{d^2 \Delta^2}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$	X

Is estimation on iteration complexity unimprovable?

What is the maximum noise level that can be taken?

Постановка задачи

Мы переформулируем исходную задачу оптимизации следующим образом:

$$f^* = \min_{x \in Q \subseteq \mathbb{R}^d} \{f(x) := \mathbb{E}[f(x, \xi)]\}.$$

Предположение (Выпуклость)

Функция f – выпукла, если

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle, \quad \forall x, y \in Q.$$

Предположение (L -гладкость)

Функция f – L -гладкая, если

$$f(y) \leq f(x) + \langle \nabla f(x), y - x \rangle + \frac{L}{2} \|y - x\|^2, \quad \forall x, y \in Q.$$

Градиентный оракули и предположения

Определение (Смещенный градиентный оракул)

Отображение $\mathbf{g} : \mathbb{R}^d \times \mathcal{D} \rightarrow \mathbb{R}^d$ такое что

$$\mathbf{g}(x, \xi) = \nabla f(x, \xi) + \mathbf{b}(x)$$

для смещения $\mathbf{b} : \mathbb{R}^d \rightarrow \mathbb{R}^d$ и несмещенного стох. градиента $\mathbb{E}[\nabla f(x, \xi)] = \nabla f(x)$.

Предположение (Ограниченнное смещение)

Существует константы $\delta \geq 0$ такие что $\forall x \in \mathbb{R}^d$

$$\|\mathbf{b}(x)\| = \|\mathbb{E}[\mathbf{g}(x, \xi)] - \nabla f(x)\| \leq \delta.$$

Предположение (Ограниченный шум)

Существует константы $\rho, \sigma^2 \geq 0$ такие что обобщенное условие сильного роста выполняется $\forall x \in \mathbb{R}^d$

$$\mathbb{E}[\|\mathbf{g}(x, \xi)\|^2] \leq \rho \|\nabla f(x)\|^2 + \sigma^2.$$

Сходимость ускоренного алгоритма [8]

$$\mathbb{E} [f(x_N)] - f^* \lesssim \frac{\rho^2 L R^2}{N^2} + \frac{N \sigma^2}{\rho^2 L}$$




Рис.: Случай без смещения

Сходимость ускоренного алгоритма (со смещенным градиентным оракулом)

$$\mathbb{E}[f(x_N)] - f^* \lesssim \frac{\rho_B^2 LR^2}{N^2} + \frac{N\sigma^2}{\rho_B^2 LB} + \underbrace{\delta \tilde{R}}_{③} + \underbrace{\frac{N}{L} \delta^2}_{④}.$$




Рис.: Случай без смещения




Рис.: Случай со смещением

Algorithm 1 Zero-Order Accelerated Stochastic Gradient Descent

Input: iteration number N , batch size B , Kernel $K : [-1, 1] \rightarrow \mathbb{R}$, step size η , smoothing parameter h , $x_0 = y_0 = z_0 \in \mathbb{R}^d$, $\alpha_0 = \gamma_0 = 0$.

for $k = 0$ **to** $N - 1$ **do**

1. Sample vectors $\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_B$ uniformly distributed on the unit sphere $S_2^d(1)$ and scalars r_1, r_2, \dots, r_B uniformly distributed on the interval $[-1, 1]$ independently
2. Define $\mathbf{g}(x_k, \mathbf{e}_i) = d \frac{\tilde{f}(x_k + hr_i \mathbf{e}_i) - \tilde{f}(x_k - hr_i \mathbf{e}_i)}{2h} K(r_i) \mathbf{e}_i$ via (6)
3. Calculate $\mathbf{g}_k = \frac{1}{B} \sum_{i=1}^B \mathbf{g}(x_k, \mathbf{e}_i)$
4. $x_{k+1} \leftarrow y_k - \eta \mathbf{g}_k$
5. $z_{k+1} \leftarrow z_k - \gamma_k \eta \mathbf{g}_k$
6. $y_{k+1} \leftarrow \alpha_{k+1} z_{k+1} + (1 - \alpha_{k+1}) x_{k+1}$

end for

Return: x_N

Смещение градиентной аппроксимации [9]

$$\|\mathbf{b}(x)\| = \|\mathbb{E}[\mathbf{g}(x_k, \mathbf{e})] - \nabla f(x_k)\| \lesssim \kappa_\beta L h^{\beta-1}.$$

Второй момент градиентной аппроксимации [9]

$$\mathbb{E} [\|\mathbf{g}(x_k, \mathbf{e})\|^2] \leq \underbrace{4d\kappa}_{\rho} \|\nabla f(x_k)\|^2 + \underbrace{4d\kappa L^2 h^2 + \frac{\kappa d^2 \Delta^2}{h^2}}_{\sigma^2}$$

Сходимость безградиентного алгоритма

$$\mathbb{E} [f(x_N)] - f^* \lesssim \underbrace{\frac{\rho_B^2 L R^2}{N^2}}_{\textcircled{1}} + \underbrace{\frac{Nd\kappa L^2 h^2}{\rho_B^2 LB}}_{\textcircled{2}} + \underbrace{\frac{N\kappa d^2 \Delta^2}{h^2 \rho_B^2 LB}}_{\textcircled{3}} + \underbrace{\tilde{R} \kappa_\beta L_\beta h^{\beta-1}}_{\textcircled{4}} + \underbrace{\frac{N\kappa_\beta^2 L_\beta^2 h^{2(\beta-1)}}{L}}_{\textcircled{5}}.$$

Основная теорема

Theorem 4.1 (Convergence results) Let the function f satisfy Assumption 2.2 and the gradient approximation $g(x, e)$ of (7) satisfies Assumptions 2.3 and 2.4, then Zero-Order Accelerated Stochastic Gradient Descent (see Algorithm 1) with $\rho_B = \max\{1, \frac{4d\kappa}{B}\}$, and with the chosen algorithm parameters:

$$\gamma_k = \frac{\rho_B^{-1} + \sqrt{\rho_B^{-2} + 4\gamma_{k-1}^2}}{2}; \quad a_{k+1} = \gamma_k \sqrt{\eta \rho_B}; \quad \alpha_k = \frac{\gamma_k \eta}{\gamma_k \eta + a_k^2}; \quad \eta = \frac{1}{\rho_B L}$$

converges to the desired ε accuracy, $\mathbb{E}[f(x_N)] - f^* \leq \varepsilon$

- in the case $B \in [1, 4d\kappa]$, $h \lesssim \varepsilon^{3/4}$ and $\beta \geq \frac{7}{3}$ after

$$N = \mathcal{O}\left(\sqrt{\frac{d^2 LR^2}{B^2 \varepsilon}}\right); \quad T = N \cdot B = \mathcal{O}\left(\sqrt{\frac{d^2 LR^2}{\varepsilon}}\right)$$

number of iterations and gradient-free oracle calls, respectively, at

$$\Delta \lesssim \frac{\varepsilon^{3/2}}{\sqrt{d}} \quad \text{maximum noise level;}$$

- in the case $B > 4d\kappa$ and $h \lesssim \varepsilon^{1/(\beta-1)}$ after


$$N = \mathcal{O}\left(\sqrt{\frac{LR^2}{\varepsilon}}\right); \quad T = N \cdot B = \max \left\{ \mathcal{O}\left(\sqrt{\frac{d^2 LR^2}{\varepsilon}}\right), \mathcal{O}\left(\frac{d^2 \Delta^2}{\varepsilon^{2+\frac{2}{\beta-1}}}\right) \right\}$$

number of iterations and gradient-free oracle calls, respectively, at

$$\Delta \lesssim \frac{\varepsilon^{\frac{3\beta+1}{4(\beta-1)}}}{d} B^{1/2} \quad \text{maximum noise level;}$$

Функция для задачи минимизации

$$f(w) := -y \log \left[\frac{1}{1 + \exp(-w^\top X)} \right] + (1 - y) \log \left[1 - \frac{1}{1 + \exp(-w^\top X)} \right].$$



Содержание

1 Негладкая задача оптимизации

- Постановка задачи
- Основная идея
- Схемы сглаживания
- Безградиентные методы в архитектуре федеративного обучения

2 Гладкая задача оптимизации

- Постановка задачи
- Ускоренный стохастический градиентный спуск с неточным оракулом
- Ускоренный стохастический градиентный спуск нулевого порядка

3 Задача оптимизации с повышенной гладкостью

- Постановка задачи
- Выбор алгоритма первого порядка
- Главный результат
- Эксперименты

4 Задача оптимизации с Order Oracle

Постановка задачи

В данной работе рассматривается решение стандартной общей оптимизационной задачи в следующем виде:

$$\min_{x \in \mathbb{R}^d} \{f(x) := \mathbb{E}_{\xi \sim \mathcal{D}} f_\xi(x)\}, \quad (1)$$

где $f : \mathbb{R}^d \rightarrow \mathbb{R}$ - возможно невыпуклая, возможно стохастическая функция.

Такая конфигурация задачи охватывает широкий спектр приложений в сценариях машинного обучения, таких как минимизация эмпирического риска (ERM), где \mathcal{D} обозначает распределение по обучающим точкам данных, а $f_\xi(x)$ представляет собой потери модели x по точке данных ξ .

Оракул высокого порядка

- $G_{x_k, i} = \nabla^i f(x_k)$ например, в Тензорных методах [10–12]

Оракул высокого порядка

- $G_{x_k, i} = \nabla^i f(x_k)$ например, в Тензорных методах [10–12]

Оракул первого порядка

- $g = \nabla f(x_k)$ например, в методах типа GD/SGD [13–15]
- $g = \nabla f(x_k) + b(x_k)$ например, в смещенных методах типа GD/SGD [16–18]
- $g = \nabla_{i_k} f(x_k)$ например, в методах типа CD [19–21]

Оракул высокого порядка

- $G_{x_k, i} = \nabla^i f(x_k)$ например, в Тензорных методах [10–12]

Оракул первого порядка

- $g = \nabla f(x_k)$ например, в методах типа GD/SGD [13–15]
- $g = \nabla f(x_k) + b(x_k)$ например, в смещенных методах типа GD/SGD [16–18]
- $g = \nabla_{i_k} f(x_k)$ например, в методах типа CD [19–21]

Оракул нулевого порядка

- $\tilde{f} = f(x_k)$ например, в безградиентных алгоритмах [22, 23]
- $\tilde{f} = f(x_k) + \delta(x_k)$ например, в безградиентных алгоритмах [24, 25]
- $\tilde{f} = f(x_k) + \xi$ например, в безградиентных алгоритмах [26, 27]

A.1 Perfect coffee for everyone

As already demonstrated in Section 1 (Introduction) with the example of chocolate, the deterministic concept of the Order Oracle has many potential applications. However, this research was initiated due to a challenge one of the co-authors faced during the realization of *a startup: the creation of an ideal coffee machine that can make the perfect drink for each customer*. This startup has just started its life cycle. At the moment we have designed a coffee machine that is functioning at the testing stage (see the photo of the machine in Figure 3 and the 3D model in Figure 4).



Figure 3: Smart coffee machine.




Figure 4: 3D model of a smart coffee machine.



Рис.: Шоколад Valio

Такие компании, как Valio (см. рисунок) и SberAI, уже активно привлекают ИИ к созданию десертов. Фотография взята с сайта компании Официальный сайт.

The Order Oracle

Мы рассматриваем концепцию оракула нулевого порядка (*Order Oracle*) для решения задачи (1):

$$\phi(x, y) = \text{sign} [f(x) - f(y) + \delta(x, y)], \quad (2)$$

где $|\delta(x, y)| \leq \Delta$ – некоторый ограниченный шум.

The Order Oracle

Мы рассматриваем концепцию оракула нулевого порядка (*Order Oracle*) для решения задачи (1):

$$\phi(x, y) = \text{sign} [f(x) - f(y) + \delta(x, y)], \quad (2)$$

где $|\delta(x, y)| \leq \Delta$ – некоторый ограниченный шум.

Q: Какие методы дружат с этим оракулом?

A: Методы решения задачи линейного поиска (метод золотого сечения (GRM) и др.)

The Order Oracle

Мы рассматриваем концепцию оракула нулевого порядка (*Order Oracle*) для решения задачи (1):

$$\phi(x, y) = \text{sign} [f(x) - f(y) + \delta(x, y)], \quad (2)$$

где $|\delta(x, y)| \leq \Delta$ – некоторый ограниченный шум.

Q: Какие методы дружат с этим оракулом?

A: Методы решения задачи линейного поиска (метод золотого сечения (GRM) и др.)

Проблема: эти методы решают одномерную задачу оптимизации

Метод координатного спуска (CDM)

На каждой итерации CDM, заданный размером шага $\zeta_k > 0$ и начальной точкой $x_0 \in \mathbb{R}^d$, работает следующим образом:

$$x_{k+1} = x_k - \underbrace{\zeta_k \nabla_{i_k} f(x_k)}_{\eta_k} \mathbf{e}_{i_k},$$

где i_k - индекс координат, взятый из $[d]$.

Как интегрировать этот оракул в многомерную оптимизацию?

Метод координатного спуска (CDM)

На каждой итерации CDM, заданный размером шага $\zeta_k > 0$ и начальной точкой $x_0 \in \mathbb{R}^d$, работает следующим образом:

$$x_{k+1} = x_k - \underbrace{\zeta_k \nabla_{i_k} f(x_k)}_{\eta_k} \mathbf{e}_{i_k},$$

где i_k - индекс координат, взятый из $[d]$.

Предположения (Гладкость)

Функция $f : \mathbb{R}^d \rightarrow \mathbb{R}$ является L -координатно-липшицевой для $L_1, L_2, \dots, L_d > 0$, если для любых $i \in [d]$, $x \in \mathbb{R}^d$ и $h \in \mathbb{R}$ выполняется следующее неравенство:

$$|\nabla_i f(x + h\mathbf{e}_i) - \nabla_i f(x)| \leq L_i |h|.$$

Как интегрировать этот оракул в многомерную оптимизацию?

Метод координатного спуска (CDM)

На каждой итерации CDM, заданный размером шага $\zeta_k > 0$ и начальной точкой $x_0 \in \mathbb{R}^d$, работает следующим образом:

$$x_{k+1} = x_k - \underbrace{\zeta_k \nabla_{i_k} f(x_k)}_{\eta_k} \mathbf{e}_{i_k},$$

где i_k - индекс координат, взятый из $[d]$.

Предположение ($\mu_{1-\alpha}$ (сильной) выпуклости)

Функция $f : \mathbb{R}^d \rightarrow \mathbb{R}$ является $\mu_{1-\alpha} \geq 0$ сильно выпуклой относительно нормы $\|\cdot\|_{[1-\alpha]}$, если для любых $x, y \in \mathbb{R}^d$ выполняется следующее неравенство:

$$f(y) \geq f(x) + \langle \nabla f(x), y - x \rangle + \frac{\mu_{1-\alpha}}{2} \|y - x\|_{[1-\alpha]}^2,$$

где $\|\cdot\|_{[\alpha]} := \sqrt{\sum_{i=1}^d L_i^\alpha x_i^2}$.

Algorithm 1 Random Coordinate Descent with Order Oracle (OrderRCD)

Input: $x_0 \in \mathbb{R}^d$, random generator $\mathcal{R}_\alpha(L)$

for $k = 0$ **to** $N - 1$ **do**

1. choose active coordinate $i_k = \mathcal{R}_\alpha(L)$

2. compute $\eta_k = \operatorname{argmin}_\eta \{f(x_k + \eta \mathbf{e}_{i_k})\}$ via (GRM)

3. $x_{k+1} \leftarrow x_k + \eta_k \mathbf{e}_{i_k}$

end for

Return: x_N

$$p_\alpha(i) = L_i^\alpha / S_\alpha, \quad i \in [d];$$

$$\mathbb{E}[f(x_N)] - f(x^*) \leq \left(1 - \frac{\mu_{1-\alpha}}{S_\alpha}\right)^N F_0.$$

Результаты сходимости

Table 1: Comparison of oracle complexity for the methods proposed in this work with SOTA methods both in the coordinate descent class and in the Order Oracle concept (2). Notation: $F_0 = f(x_0) - f(x^*)$; $R = \|x_0 - x^*\|$; $R_{[1-\alpha]} = R_{1-\alpha}(x_0) = \sup_{x \in \mathbb{R}^d: f(x) \leq f(x_0)} \|x - x^*\|_{[1-\alpha]}$; ε = desired accuracy of problem solving.

Reference	Nesterov (2012)	Gorbunov et al. (2019)	Saha et al. (2021)	Tang et al. (2023)	This paper
Non-convex	\times	$\mathcal{O}\left(\frac{dS_\alpha F_0}{\varepsilon^2}\right)$	\times	$\mathcal{O}\left(\frac{dLF_0}{\varepsilon^2}\right)$	$\tilde{\mathcal{O}}\left(\frac{S_\alpha F_0}{\varepsilon^2}\right)$
Convex	$\mathcal{O}\left(\frac{S_\alpha R_{[1-\alpha]}^2}{\varepsilon}\right)$	$\mathcal{O}\left(\frac{dS_\alpha R_{[1-\alpha]}^2}{\varepsilon} \log \frac{1}{\varepsilon}\right)$	$\mathcal{O}\left(\frac{dLR^2}{\varepsilon}\right)$	\times	$\tilde{\mathcal{O}}\left(\frac{S_\alpha R_{[1-\alpha]}^2}{\varepsilon}\right)$
Strongly convex	$\mathcal{O}\left(\frac{S_\alpha}{\mu_{1-\alpha}} \log \frac{1}{\varepsilon}\right)$	$\mathcal{O}\left(\frac{S_\alpha}{\mu_{1-\alpha}} \log \frac{1}{\varepsilon}\right)$	$\mathcal{O}\left(d\frac{L}{\mu} \log \frac{1}{\varepsilon}\right)$	\times	$\tilde{\mathcal{O}}\left(\frac{S_\alpha}{\mu_{1-\alpha}} \log \frac{1}{\varepsilon}\right)$
Order Oracle?	\times	✓	✓	✓	✓
Acceleration?	\times	\times	\times	\times	✓

Algorithm 2 Accelerated Coordinate Descent Method with Order Oracle (OrderACDM)

Input: $x_0 = z_0 \in \mathbb{R}^d$, $\mathcal{R}_\alpha(L)$, $A_0 = 0$, $B_0 = 1$, $\beta = \frac{\alpha}{2}$

for $k = 0$ **to** $N - 1$ **do**

1. choose active coordinate $i_k = \mathcal{R}_\beta(L)$
2. find parameter a_{k+1} from $a_{k+1}^2 S_\beta^2 = A_{k+1} B_{k+1}$,
where $A_{k+1} = A_k + a_{k+1}$ and
 $B_{k+1} = B_k + \mu_{1-\alpha} a_{k+1}$
3. $\alpha_k \leftarrow \frac{a_{k+1}}{A_{k+1}}$
4. $\beta_k \leftarrow \frac{\mu_{1-\alpha} a_{k+1}}{B_{k+1}}$
5. $y_k \leftarrow \frac{(1-\alpha_k)x_k + \alpha_k(1-\beta_k)z_k}{1-\alpha_k\beta_k}$
6. compute $\eta_k = \operatorname{argmin}_\eta \{f(y_k + \eta \mathbf{e}_{i_k})\}$ via (GRM)
7. $x_{k+1} \leftarrow y_k + \eta_k \mathbf{e}_{i_k}$
8. $w_k \leftarrow (1 - \beta_k)z_k + \beta_k y_k + \frac{a_{k+1} L_{i_k}^\alpha}{B_{k+1} p_\beta(i)} \eta_k \mathbf{e}_{i_k}$
9. compute $\zeta_k = \operatorname{argmin}_\zeta \{f(w_k + \zeta \mathbf{e}_{i_k})\}$ via (GRM)
10. $z_{k+1} \leftarrow w_k + \zeta_k \mathbf{e}_{i_k}$



end for

Return: x_N

$$p_\beta(i) = L_i^\beta / S_\beta, \quad i \in [d];$$

$$\mathbb{E} [f(x_N)] - f(x^*) \leq \left(1 - \frac{\sqrt{\mu_{1-\alpha}}}{S_{\alpha/2}}\right)^N F_0.$$

Эксперименты



Спасибо за внимание!



Рис.: Связаться со мной

- [1] *Gasnikov A., Novitskii A., Novitskii V., Abdukhakimov F., Kamzolov D., Beznosikov A., Takáč M., Dvurechensky P., Gu B.* The Power of First-Order Smooth Optimization for Black-Box Non-Smooth Problems // 2022. URL: <https://arxiv.org/pdf/2201.12289.pdf>.
- [2] *Arya Akhavan и др.* “A gradient estimator via L1-randomization for online zero-order optimization with two point feedback”. B: *arXiv preprint arXiv:2205.13910* (2022).
- [3] *Woodworth B., Bullins B., Shamir O., Srebro N.* The Min-Max Complexity of Distributed Stochastic Convex Optimization with Intermittent Communication. // Proceedings of Machine Learning Research. 2021. V. 134. P. 1–52.
- [4] *Woodworth B., Patel K. K., Stich S. U., Dai Z., Bullins B., McMahan H. B., Shamir O., Srebro N.* Is Local SGD Better than Minibatch SGD? // Proceedings of the 37th International Conference on Machine Learning, PMLR. 2020. V. 119. P. 10334–10343.
- [5] *Yuan H., Ma T.* Federated Accelerated Stochastic Gradient Descent. // Advances in Neural Information Processing Systems. 2020. V. 33. P. 5332–5344.

- [6] Blake E Woodworth и Nathan Srebro. "An even more optimal stochastic optimization algorithm: minibatching and interpolation learning". B: *Advances in Neural Information Processing Systems* 34 (2021), c. 7333—7345.
- [7] Sasila Ilandarideva и др. "Accelerated stochastic approximation with state-dependent noise". B: *arXiv preprint arXiv:2307.01497* (2023).
- [8] Sharan Vaswani, Francis Bach и Mark Schmidt. "Fast and faster convergence of sgd for over-parameterized models and an accelerated perceptron". B: *The 22nd international conference on artificial intelligence and statistics*. PMLR. 2019, c. 1195—1204.
- [9] Arya Akhavan и др. "Gradient-free optimization of highly smooth functions: improved analysis and a new algorithm". B: *arXiv preprint arXiv:2306.02159* (2023).
- [10] Bo Jiang, Haoyue Wang и Shuzhong Zhang. "An optimal high-order tensor method for convex optimization". B: *Conference on Learning Theory*. PMLR. 2019, c. 1799—1801.
- [11] Yurii Nesterov. "Implementable tensor methods in unconstrained convex optimization". B: *Mathematical Programming* 186 (2021), c. 157—183.

Reference III

- [12] Artem Agafonov и др. “Inexact tensor methods and their application to stochastic convex optimization”. B: *Optimization Methods and Software* (2023), c. 1—42.
- [13] Eduard Gorbunov, Marina Danilova и Alexander Gasnikov. “Stochastic optimization with heavy-tailed noise via accelerated gradient clipping”. B: *Advances in Neural Information Processing Systems* 33 (2020), c. 15042—15053.
- [14] Mert Gurbuzbalaban, Umut Simsekli и Lingjiong Zhu. “The heavy-tail phenomenon in SGD”. B: *International Conference on Machine Learning*. PMLR. 2021, c. 3964—3975.
- [15] Feihu Huang и др. “Accelerated zeroth-order and first-order momentum methods from mini to minimax optimization”. B: *The Journal of Machine Learning Research* 23.1 (2022), c. 1616—1685.
- [16] Ahmad Ajalloeian и Sebastian U Stich. “On the convergence of SGD with biased gradients”. B: *arXiv preprint arXiv:2008.00051* (2020).
- [17] Ahmad Ajalloeian и Sebastian U Stich. “On the convergence of SGD with biased gradients”. B: *arXiv preprint arXiv:2008.00051* (2020).

- [18] Margalit R Glasgow, Honglin Yuan и Tengyu Ma. "Sharp bounds for federated averaging (local SGD) and continuous perspective". B: *International Conference on Artificial Intelligence and Statistics*. PMLR. 2022, c. 9050—9090.
- [19] Yu Nesterov. "Efficiency of coordinate descent methods on huge-scale optimization problems". B: *SIAM Journal on Optimization* 22.2 (2012), c. 341—362.
- [20] Yin Tat Lee и Aaron Sidford. "Efficient accelerated coordinate descent methods and faster algorithms for solving linear systems". B: *2013 ieee 54th annual symposium on foundations of computer science*. IEEE. 2013, c. 147—156.
- [21] Paul Mangold и др. "High-Dimensional Private Empirical Risk Minimization by Greedy Coordinate Descent". B: *International Conference on Artificial Intelligence and Statistics*. PMLR. 2023, c. 4894—4916.
- [22] Ohad Shamir. "An optimal algorithm for bandit and zero-order convex optimization with two-point feedback". B: *The Journal of Machine Learning Research* 18.1 (2017), c. 1703—1713.

- [23] Alexander Gasnikov и др. “The power of first-order smooth optimization for black-box non-smooth problems”. B: *International Conference on Machine Learning*. PMLR. 2022, c. 7241—7265.
- [24] Aleksandr Lobanov и др. “Gradient-Free Federated Learning Methods with l_1 and l_2 -Randomization for Non-Smooth Convex Stochastic Optimization Problems”. B: *arXiv preprint arXiv:2211.10783* (2022).
- [25] Nikita Kornilov и др. “Accelerated Zeroth-order Method for Non-Smooth Stochastic Convex Optimization Problem with Infinite Variance”. B: *Thirty-seventh Conference on Neural Information Processing Systems*. 2023.
- [26] Francis Bach и Vianney Perchet. “Highly-smooth zero-th order online optimization”. B: *Conference on Learning Theory*. PMLR. 2016, c. 257—283.
- [27] Arya Akhavan, Massimiliano Pontil и Alexandre Tsybakov. “Distributed zero-order optimization under adversarial noise”. B: *Advances in Neural Information Processing Systems 34* (2021), c. 10209—10220.