

Адаптивный быстрый градиентный метод в задачах стохастической оптимизации

Adaptive fast gradient method in stochastic optimization tasks

Александр Игоревич Тюрин¹

Аннотация

В данной работе приводится стохастический адаптивный ускоренный градиентный метод на основе зеркального варианта метода подобных треугольников. На сколько мы знаем, это первая попытка добавления адаптивности в стохастический метод. Ко всему прочему, главный результат приводится в виде оценки вероятностей больших отклонений.

In this paper, we describe a stochastic adaptive fast gradient descent method based on the mirror variant of similar triangles method. To our knowledge, this is the first attempt to use adaptivity in stochastic method. Additionally, a main result was proved in terms of probabilities of large deviations.

Keywords Fast Gradient Descent, Composite Optimization, Stochastic Optimization, Adaptive Optimization

Ключевые слова Быстрый Градиентный Метод, Композитная оптимизация, Стохастическая Оптимизация, Адаптивная Оптимизация

Mathematics Subject Classification 90C25, 90C60, 90C15

УДК 519.85

1 Введение

В данной работе представлен алгоритм стохастической оптимизации, который является обобщением быстрого градиентного метода [12]. Методы стохастической оптимизации в последнее время являются популярными по той причине, что они позволяют уменьшать сложность подсчета градиента, что является очень важным, так как существуют примеры функций, в которых невозможно за разумное время подсчитать градиент оптимизируемой функции хотя бы в одной точке. Помимо этого, в задачах стохастической оптимизации [1] в силу формулировки самой задачи единственный разумный способ получить направление спуска – это сэмлирование векторов, которые имеют несмещенные по отношению к истинному градиенту направления. Данный подход также популярен в глубинном обучении [9], в задачах, которые имеют вид суммы функций [1]. Стоит отметить, что сложность подсчета стохастического градиента, как правило, можно регулировать. Начиная с того, что можно считать честно полностью градиент, и заканчивая тем, что можно брать случайную грубую оценку настоящего градиента, но при этом стоит понимать, что дисперсия данной оценки может довольно сильно влиять на скорость сходимости [10, 6]. В данной работе предлагается использовать технику mini-batch, которая позволяет агрегировать случайные несмещенные оценки в достаточном количестве, при этом данная техника приводит к оптимальным оценкам. Ко всему прочему, данный метод является адаптивным [2] и поддерживает наличие композита [10].

¹atyurin@hse.ru, Национальный исследовательский университет «Высшая школа экономики», 101000, Россия, г. Москва, ул. Мясницкая, д. 20
Alexander Tyurin, National Research University Higher School of Economics, Myasnitskaya str. 20, Moscow, Russia 101000

2 Адаптивный зеркальный вариант метода подобных треугольников с неточным выборочным стохастическим (δ, L) -оракулом

Опишем сначала общую постановку задачи выпуклой оптимизации [3]. Пусть определены функции $f(x) : Q \rightarrow \mathbb{R}$ и $h(x) : Q \rightarrow \mathbb{R}$ и дана произвольная норма $\|\cdot\|$ в $\mathbb{R}^n$. Обозначим $F(x)$, как $F(x) \stackrel{\text{def}}{=} f(x) + h(x)$. Сопряженная норма определяется следующим образом:

$$\|\lambda\|_* \stackrel{\text{def}}{=} \max_{\|\nu\| \leq 1; \nu \in \mathbb{R}^n} \langle \lambda, \nu \rangle, \quad \forall \lambda \in \mathbb{R}^n. \quad (1)$$

Будем полагать, что

1. $Q \subseteq \mathbb{R}^n$, выпуклое, замкнутое.
2. $f(x)$ и $h(x)$ – непрерывные и выпуклые функции на Q .
3. $f(x)$ – гладкая функция.
4. $F(x)$ ограничена снизу на Q и достигает своего минимума в некоторой точке (необязательно единственной) $x_* \in Q$.

Рассмотрим следующую задачу оптимизации:

$$F(x) \rightarrow \min_{x \in Q}. \quad (2)$$

Введем два понятия: прокс-функция и дивергенция Брэгмана [7].

Определение 1. $d(x) : Q \rightarrow \mathbb{R}$ называется прокс-функцией, если $d(x)$ непрерывно дифференцируемая на $\text{int } Q$ и $d(x)$ является 1-сильно выпуклой относительно нормы $\|\cdot\|$ на $\text{int } Q$.

Определение 2. Дивергенцией Брэгмана называется

$$V(x, y) \stackrel{\text{def}}{=} d(x) - d(y) - \langle \nabla d(y), x - y \rangle, \quad (3)$$

где $d(x)$ – произвольная прокс-функция.

Легко показать [5], что

$$V(x, y) \geq \frac{1}{2} \|x - y\|^2. \quad (4)$$

Определение 3. Стохастическим (δ, L) -оракулом будем называть оракул, который на запрашиваемую точку $y \in Q$ дает пару $(f_\delta(y), \nabla f_\delta(y; \xi))$ такую, что

$$0 \leq f(x) - f_\delta(y) - \langle \nabla f_\delta(y), x - y \rangle \leq \frac{L}{2} \|x - y\|^2 + \delta, \quad \forall x \in Q, \quad (5)$$

$$\mathbb{E} [\nabla f_\delta(y; \xi)] = \nabla f_\delta(y), \quad \forall y \in Q, \quad (6)$$

$$\mathbb{E} \left[\exp \left(\frac{\|\nabla f_\delta(y; \xi) - \nabla f_\delta(y)\|_*^2}{\sigma^2} \right) \right] \leq \exp(1), \quad \forall y \in Q, \quad (7)$$

где $\sigma^2 > 0$.

Будем предполагать, что для $f(x)$ существует стохастический (δ, L) -оракул.

Утверждение 1. Возьмем $x = y$ в (5), тогда

$$f_\delta(y) \leq f(y) \leq f_\delta(y) + \delta, \quad \forall y \in Q. \quad (8)$$

Определим константу R_Q такую, что

$$R_Q \geq \max_{x, y \in Q} \|x - y\|. \quad (9)$$

Будем считать, что $R_Q < \infty$.

В методе, который мы предложим далее, будем оценивать истинный градиент на каждом шаге с помощью некоторого количества $\nabla f_\delta(y; \xi_j)$, $j \in [1 \dots m_{k+1}]$, используя технику mini-batch.

Обозначим

$$\tilde{\nabla}^{m_{k+1}} f_\delta(y) \stackrel{\text{def}}{=} \frac{1}{m_{k+1}} \sum_{j=1}^{m_{k+1}} \nabla f_\delta(y; \xi_j). \quad (10)$$

Приведем важную лемму:

Лемма 1. Пусть $(f_\delta(y), \nabla f_\delta(y; \xi_i))$, $i = 1, \dots, m_{k+1}$ — m_{k+1} независимых выходов стохастического (δ, L) -оракула, $x, y \in Q$ — случайные векторы, y и ξ_i $i = 1, \dots, m_{k+1}$ — независимы, $\tilde{L}$ случайная константа, такая, что $\tilde{L} \geq 3L/2$ почти наверное, κ — константа регулярности² из [8] для $(\mathbb{R}^n, \|\cdot\|_*)$ и выбрано произвольное $\Omega \geq 0$, тогда

$$\begin{aligned} & \mathbb{P} \left(f_\delta(x) - f_\delta(y) - \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle > (2\kappa + 4\Omega\sqrt{\kappa} + 2\Omega^2) \frac{3\sigma^2}{\tilde{L}m_{k+1}} + \frac{\tilde{L}}{2} \|x - y\|^2 + \delta \right) \\ & \leq \exp(-\Omega^2/3). \end{aligned}$$

Доказательство. Рассмотрим правую часть условия (5):

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

Учтем (8), тогда

$$f_\delta(x) - f_\delta(y) - \langle \nabla f_\delta(y), x - y \rangle \leq \frac{L}{2} \|x - y\|^2 + \delta.$$

В обе части неравенства добавим слагаемое $\langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle$:

$$\begin{aligned} f_\delta(x) - f_\delta(y) - \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle & \leq \langle \nabla f_\delta(y) - \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle + \frac{L}{2} \|x - y\|^2 + \delta \\ & \leq \langle \nabla f_\delta(y) - \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle + \frac{\tilde{L}}{3} \|x - y\|^2 + \delta. \end{aligned}$$

²Можно показать: если $\|\cdot\|_* = \|\cdot\|_2$, то $\kappa = 1$. Более того, если $\|\cdot\|_* = \|\cdot\|_q$, $q \in [2, \infty]$, то $\kappa = \min[q - 1, 2 \ln(n)]$.

Воспользуемся неравенством Фенхеля [6] (формула (7.6))

$$\begin{aligned} f_\delta(x) - f_\delta(y) - \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle &\leq \frac{\tilde{L}}{6} \|x - y\|^2 + \frac{3}{\tilde{L}} \left\| \tilde{\nabla}^{m_{k+1}} f_\delta(y) - \nabla f_\delta(y) \right\|_*^2 \\ &\quad + \frac{\tilde{L}}{3} \|x - y\|^2 + \delta. \end{aligned}$$

То есть

$$f_\delta(x) - f_\delta(y) - \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle \leq \frac{\tilde{L}}{2} \|x - y\|^2 + \frac{3}{\tilde{L}} \left\| \tilde{\nabla}^{m_{k+1}} f_\delta(y) - \nabla f_\delta(y) \right\|_*^2 + \delta. \quad (11)$$

Оценим вероятность того, что

$$f_\delta(x) - f_\delta(y) - \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle > (2\kappa + 4\Omega\sqrt{\kappa} + 2\Omega^2) \frac{3\sigma^2}{\tilde{L}m_{k+1}} + \frac{\tilde{L}}{2} \|x - y\|^2 + \delta. \quad (12)$$

Учитывая (11), из (12) будет следовать

$$\frac{3}{\tilde{L}} \left\| \tilde{\nabla}^{m_{k+1}} f_\delta(y) - \nabla f_\delta(y) \right\|_*^2 > (2\kappa + 4\Omega\sqrt{\kappa} + 2\Omega^2) \frac{3\sigma^2}{\tilde{L}m_{k+1}}, \quad (13)$$

что эквивалентно

$$\left\| \tilde{\nabla}^{m_{k+1}} f_\delta(y) - \nabla f_\delta(y) \right\|_*^2 > (2\kappa + 4\Omega\sqrt{\kappa} + 2\Omega^2) \frac{\sigma^2}{m_{k+1}}. \quad (14)$$

Воспользуемся следующим фактом из [8], пусть $\gamma_1, \dots, \gamma_N$ – случайные независимые вектора такие, что

$$\mathbb{E} \left[\exp \left(\frac{\|\gamma_i\|_*^2}{\sigma^2} \right) \right] \leq \exp(1), \quad \mathbb{E} \gamma_i = 0,$$

тогда верно, $\forall \Omega \geq 0$:

$$\mathbb{P} \left(\left\| \sum_{i=1}^N \gamma_i \right\|_* \geq (\sqrt{2\kappa} + \sqrt{2\Omega}) \sqrt{N} \sigma \right) \leq \exp(-\Omega^2/3),$$

где κ – константа регулярности из [8]. Возьмем $\gamma_i = \nabla f_\delta(\tilde{y}; \xi_i) - \nabla f_\delta(\tilde{y})$, где $\tilde{y}$ – неслучайный вектор, учтем (6) и (7), тогда

$$\begin{aligned} \mathbb{P} \left(\left\| \sum_{j=1}^{m_{k+1}} \left(\nabla f_\delta(\tilde{y}; \xi_j) - \nabla f_\delta(\tilde{y}) \right) \right\|_* > (\sqrt{2\kappa} + \sqrt{2\Omega}) \sqrt{m_{k+1}} \sigma \right) &\leq \exp(-\Omega^2/3) \Leftrightarrow \\ \mathbb{P} \left(\left\| \tilde{\nabla}^{m_{k+1}} f_\delta(\tilde{y}) - \nabla f_\delta(\tilde{y}) \right\|_* > (\sqrt{2\kappa} + \sqrt{2\Omega}) \frac{\sigma}{\sqrt{m_{k+1}}} \right) &\leq \exp(-\Omega^2/3). \end{aligned}$$

Получаем в конечном счете, что

$$\mathbb{P} \left(\left\| \tilde{\nabla}^{m_{k+1}} f_\delta(y) - \nabla f_\delta(y) \right\|_* > (\sqrt{2\kappa} + \sqrt{2\Omega}) \frac{\sigma}{\sqrt{m_{k+1}}} \right)$$

$$\begin{aligned}
&= \mathbb{E} \left[\mathbb{P} \left(\left\| \tilde{\nabla}^{m_{k+1}} f_{\delta}(\tilde{y}) - \nabla f_{\delta}(\tilde{y}) \right\|_* > (\sqrt{2\kappa} + \sqrt{2\Omega}) \frac{\sigma}{\sqrt{m_{k+1}}} \middle| y = \tilde{y} \right) \right] \\
&\leq \mathbb{E} [\exp(-\Omega^2/3)] \\
&= \exp(-\Omega^2/3)
\end{aligned}$$

и

$$\mathbb{P} \left(\frac{3}{\tilde{L}} \left\| \tilde{\nabla}^{m_{k+1}} f_{\delta}(y) - \nabla f_{\delta}(y) \right\|_*^2 > (2\kappa + 4\Omega\sqrt{\kappa} + 2\Omega^2) \frac{3\sigma^2}{\tilde{L}m_{k+1}} \right) \leq \exp(-\Omega^2/3).$$

Из этого неравенства и из того, что из (12) следует (13), получаем утверждение леммы. $\square$

Сделаем следующее обозначение: $\tilde{\Omega} \stackrel{\text{def}}{=} 2\kappa + 4\Omega\sqrt{\kappa} + 2\Omega^2$.

Далее будет использоваться в алгоритме константу L_0 , которая имеет смысл предположительной "локальной" константы Липшица градиента в точке x_0 . Рассмотрим алгоритм оптимизации.

Адаптивный зеркальный вариант метода подобных треугольников со стохастическим (δ, L) -оракулом

Дано: x_0 – начальная точка, ϵ – желаемая точность решения, δ, L – константы из (δ, L) -оракула, β – доверительный уровень, L_0 ($L_0 \leq L$).

Возьмем

$$N := \left\lceil \frac{2\sqrt{3}\sqrt{L}R_Q}{\sqrt{\epsilon}} \right\rceil, \quad \Omega := \sqrt{6 \ln \frac{N}{\beta}}.$$

0 - шаг:

$$y_0 := x_0, \quad u_0 := x_0, \quad L_1^0 := \frac{L_0}{2}, \quad \alpha_0 := 0, \quad A_0 := \alpha_0, \quad j_1 := 0$$

$k + 1$ - шаг:

$$\alpha_{k+1} := \frac{1 + \sqrt{1 + 4A_k L_{k+1}^{j_{k+1}}}}{2L_{k+1}^{j_{k+1}}} \tag{15}$$

$$A_{k+1} := A_k + \alpha_{k+1} \tag{16}$$

$$y_{k+1} := \frac{\alpha_{k+1}u_k + A_k x_k}{A_{k+1}} \tag{17}$$

$$m_{k+1} := \left\lceil \frac{3\sigma^2 \tilde{\Omega} \alpha_{k+1}}{\epsilon} \right\rceil \tag{18}$$

Сгенерировать: $\tilde{\nabla}^{m_{k+1}} f_{\delta}(y_{k+1})$

$$\phi_{k+1}(x) \stackrel{\text{def}}{=} V(x, u_k) + \alpha_{k+1} \left(f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x - y_{k+1} \rangle + h(x) \right) \quad (19)$$

$$u_{k+1} := \arg \min_{x \in Q} \phi_{k+1}(x)$$

$$x_{k+1} := \frac{\alpha_{k+1} u_{k+1} + A_k x_k}{A_{k+1}} \quad (20)$$

Если выполнено условие

$$\begin{aligned} f_\delta(x_{k+1}) &\leq f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x_{k+1} - y_{k+1} \rangle + \\ &+ \frac{L_{k+1}^{j_{k+1}}}{2} \|x_{k+1} - y_{k+1}\|^2 + \frac{3\sigma^2 \tilde{\Omega}}{L_{k+1}^{j_{k+1}} m_{k+1}} + \delta, \end{aligned} \quad (21)$$

то

$$L_{k+2}^0 := \frac{L_{k+1}^{j_{k+1}}}{2}, \quad L_{k+1} := L_{k+1}^{j_{k+1}}, \quad j_{k+2} := 0 \quad (22)$$

и перейти к следующему шагу, иначе

$$L_{k+1}^{j_{k+1}+1} := 2L_{k+1}^{j_{k+1}}, \quad j_{k+1} := j_{k+1} + 1 \quad (23)$$

и повторить текущий шаг.

Лемма 2. Пусть

$$\Omega = \sqrt{6 \ln \frac{N}{\beta}},$$

тогда

$$\mathbb{P} \left(\bigcap_{k=0}^{N-1} \{L_{k+1} < 3L\} \right) \geq 1 - \beta.$$

Доказательство.

$$\mathbb{P} \left(\bigcup_{k=0}^{N-1} \{L_{k+1} \geq 3L\} \right) \leq_{\textcircled{1}} \sum_{k=0}^{N-1} \mathbb{P}(L_{k+1} \geq 3L).$$

① – из неравенства Бонферрони.

Обозначим за $A(k+1, j)$ – событие, заключающиеся в выполнении условия (21) на $k+1$ шаге на j -ом внутреннем цикле. Рассмотрим для случая, когда $k=0$. Из события

$$\{L_1 \geq 3L\}$$

следует событие

$$\left\{ L_1^{j_1-1} \geq \frac{3L}{2} \cap \neg A(1, j_1 - 1) \right\}.$$

Поэтому

$$\begin{aligned}\mathbb{P}(L_1 \geq 3L) &\leq \mathbb{P}\left(L_1^{j_1-1} \geq \frac{3L}{2} \cap \neg A(1, j_1 - 1)\right) \\ &\leq \mathbb{P}\left(\neg A(1, j_1 - 1) | L_1^{j_1-1} \geq \frac{3L}{2}\right) \\ &\leq_{\textcircled{1}} \exp(-\Omega^2/3).\end{aligned}$$

① – Лемма 1.

Воспользуемся методом математической индукции. Пусть для k верно

$$\mathbb{P}(L_k \geq 3L) \leq k \exp(-\Omega^2/3),$$

тогда

$$\begin{aligned}\mathbb{P}(L_{k+1} \geq 3L) &= \mathbb{P}(L_{k+1} \geq 3L \cap L_k \geq 3L) + \mathbb{P}(L_{k+1} \geq 3L \cap L_k < 3L) \\ &= \mathbb{P}(L_{k+1} \geq 3L | L_k \geq 3L) \mathbb{P}(L_k \geq 3L) + \mathbb{P}(L_{k+1} \geq 3L \cap L_k < 3L) \\ &\leq k \exp(-\Omega^2/3) + \mathbb{P}(L_{k+1} \geq 3L \cap L_k < 3L) \\ &\leq k \exp(-\Omega^2/3) + \mathbb{P}\left(L_{k+1} \geq 3L \cap L_{k+1}^0 < \frac{3L}{2}\right).\end{aligned}$$

Из события

$$\left\{L_{k+1} \geq 3L \cap L_{k+1}^0 < \frac{3L}{2}\right\}$$

следует событие

$$\left\{L_{k+1}^{j_{k+1}-1} \geq \frac{3L}{2} \cap \neg A(k+1, j_{k+1} - 1)\right\}.$$

То есть

$$\begin{aligned}\mathbb{P}(L_{k+1} \geq 3L) &\leq k \exp(-\Omega^2/3) + \mathbb{P}\left(L_{k+1}^{j_{k+1}-1} \geq \frac{3L}{2} \cap \neg A(k+1, j_{k+1} - 1)\right) \\ &\leq k \exp(-\Omega^2/3) + \mathbb{P}\left(\neg A(k+1, j_{k+1} - 1) | L_{k+1}^{j_{k+1}-1} \geq \frac{3L}{2}\right) \\ &\leq_{\textcircled{1}} (k+1) \exp(-\Omega^2/3).\end{aligned}$$

① – Лемма 1.

В конечном счете получаем, что

$$\begin{aligned}\mathbb{P}\left(\bigcup_{k=0}^{N-1} \{L_{k+1} \geq 3L\}\right) &\leq \sum_{k=0}^{N-1} \mathbb{P}(L_{k+1} \geq 3L) \\ &\leq \sum_{k=0}^{N-1} (k+1) \exp(-\Omega^2/3) \\ &\leq N^2 \exp(-\Omega^2/3).\end{aligned}$$

Так как по условию леммы $\Omega = \sqrt{6 \ln \frac{N}{\beta}}$, то

$$\mathbb{P} \left(\bigcup_{k=0}^{N-1} \{L_{k+1} \geq 3L\} \right) \leq N^2 \exp(-\Omega^2/3) \leq \beta.$$

Последнее неравенство завершает доказательство леммы. $\square$

Лемма 3. Пусть для последовательности α_k выполнено

$$\alpha_0 = 0, A_k = \sum_{i=0}^k \alpha_i, \alpha_{k+1} = \frac{1 + \sqrt{1 + 4A_k L_{k+1}}}{2L_{k+1}},$$

где $\{L_k\}$ – последовательность, генерируемая алгоритмом.

Тогда с вероятностью $1 - \beta$

$$A_k \geq \frac{(k+1)^2}{12L}, \quad \forall k = 1, \dots, N. \quad (24)$$

Доказательство. Воспользуемся Леммой 2, которая говорит следующее: с вероятностью больше или равной $1 - \beta$, $\forall k \leq N$, $L_k < 3L$.

Пусть $k = 1$, тогда

$$A_1 = \alpha_1 = \frac{1}{L_1} \geq \frac{1}{3L}.$$

По индукции, пусть неравенство (24) верно для k , тогда:

$$\begin{aligned} \alpha_{k+1} &= \frac{1}{2L_{k+1}} + \sqrt{\frac{1}{4L_{k+1}^2} + \frac{A_k}{L_{k+1}}} \\ &\geq \frac{1}{2L_{k+1}} + \sqrt{\frac{A_k}{L_{k+1}}} \\ &\geq \frac{1}{6L} + \frac{1}{\sqrt{3L}} \frac{k+1}{2\sqrt{3L}} \\ &= \frac{k+2}{6L} \end{aligned}$$

Последнее неравенство следует из индукционного предположения. В конечном счете получаем, что

$$\alpha_{k+1} \geq \frac{k+2}{6L}$$

и

$$\begin{aligned} A_{k+1} &= A_k + \alpha_{k+1} \\ &= \frac{(k+1)^2}{12L} + \frac{k+2}{6L} \\ &\geq \frac{(k+2)^2}{12L}. \end{aligned}$$

$\square$

Замечание 1. Как и в [2, 13], можно получить, что с вероятностью $1 - \beta$ в среднем на каждой внешней итерации мы будем считать значение всех функций 4 раза, а стохастического градиента $\tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1})$ – 2 раза.

Докажем важную лемму.

Лемма 4. Пусть $\psi(x)$ выпуклая функция и

$$y = \arg \min_{x \in Q} \{\psi(x) + V(x, z)\}.$$

Тогда

$$\psi(x) + V(x, z) \geq \psi(y) + V(y, z) + V(x, y), \quad \forall x \in Q.$$

Доказательство. По критерию оптимальности:

$$\exists g \in \partial\psi(y), \quad \langle g + \nabla_y V(y, z), x - y \rangle \geq 0, \quad \forall x \in Q.$$

Тогда неравенство

$$\psi(x) - \psi(y) \geq \langle g, x - y \rangle \geq \langle \nabla_y V(y, z), y - x \rangle$$

и равенство

$$\begin{aligned} \langle \nabla_y V(y, z), y - x \rangle &= \langle \nabla d(y) - \nabla d(z), y - x \rangle = d(y) - d(z) - \langle \nabla d(z), y - z \rangle + \\ &+ d(x) - d(y) - \langle \nabla d(y), x - y \rangle - d(x) + d(z) + \langle \nabla d(z), x - z \rangle = \\ &= V(y, z) + V(x, y) - V(x, z) \end{aligned}$$

завершают доказательство. □

Введем обозначение: $l_f^\delta(x; y) = f_\delta(y) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y), x - y \rangle$.

Лемма 5. С вероятностью больше или равной $1 - \beta$, $\forall x \in Q, \forall k \in [0, N]$,

$$\begin{aligned} &l_f^\delta(x_{k+1}; y_{k+1}) + \frac{L_{k+1}}{2} \|x_{k+1} - y_{k+1}\|^2 + h(x_{k+1}) \\ &\leq \frac{A_k}{A_{k+1}} \left(l_f^\delta(x_k; y_{k+1}) + h(x_k) \right) + \frac{\alpha_{k+1}}{A_{k+1}} \left(l_f^\delta(x; y_{k+1}) \right. \\ &\quad \left. + h(x) + \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \right) \end{aligned}$$

Доказательство.

$$\begin{aligned} &l_f^\delta(x_{k+1}; y_{k+1}) + \frac{L_{k+1}}{2} \|x_{k+1} - y_{k+1}\|^2 + h(x_{k+1}) \\ &\stackrel{(20)}{=} l_f^\delta \left(\frac{\alpha_{k+1} u_{k+1} + A_k x_k}{A_{k+1}}; y_{k+1} \right) + \frac{L_{k+1}}{2} \left\| \frac{\alpha_{k+1} u_{k+1} + A_k x_k}{A_{k+1}} - y_{k+1} \right\|^2 \end{aligned}$$

$$\begin{aligned}
& + h \left(\frac{\alpha_{k+1}u_{k+1} + A_k x_k}{A_{k+1}} \right) \\
& \stackrel{(17)}{\leq} f_\delta(y_{k+1}) + \frac{\alpha_{k+1}}{A_{k+1}} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), u_{k+1} - y_{k+1} \rangle \\
& + \frac{A_k}{A_{k+1}} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x_k - y_{k+1} \rangle + \frac{L_{k+1}\alpha_{k+1}^2}{2A_{k+1}^2} \|u_{k+1} - u_k\|^2 \\
& + \frac{\alpha_{k+1}}{A_{k+1}} h(u_{k+1}) + \frac{A_k}{A_{k+1}} h(x_k) \\
& = \frac{A_k}{A_{k+1}} \left(f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x_k - y_{k+1} \rangle + h(x_k) \right) \\
& + \frac{\alpha_{k+1}}{A_{k+1}} \left(f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), u_{k+1} - y_{k+1} \rangle + h(u_{k+1}) \right) \\
& + \frac{L_{k+1}\alpha_{k+1}^2}{2A_{k+1}^2} \|u_{k+1} - u_k\|^2 \\
& = \stackrel{\textcircled{1}}{=} \frac{A_k}{A_{k+1}} \left(l_f^\delta(x_k; y_{k+1}) + h(x_k) \right) \\
& + \frac{\alpha_{k+1}}{A_{k+1}} \left(l_f^\delta(u_{k+1}; y_{k+1}) + \frac{1}{2\alpha_{k+1}} \|u_{k+1} - u_k\|^2 + h(u_{k+1}) \right) \\
& \stackrel{(4)}{\leq} \frac{A_k}{A_{k+1}} \left(l_f^\delta(x_k; y_{k+1}) + h(x_k) \right) \\
& + \frac{\alpha_{k+1}}{A_{k+1}} \left(l_f^\delta(u_{k+1}; y_{k+1}) + \frac{1}{\alpha_{k+1}} V(u_{k+1}, u_k) + h(u_{k+1}) \right) \\
& \leq \stackrel{\textcircled{2}}{=} \frac{A_k}{A_{k+1}} \left(l_f^\delta(x_k; y_{k+1}) + h(x_k) \right) \\
& + \frac{\alpha_{k+1}}{A_{k+1}} \left(l_f^\delta(x; y_{k+1}) + h(x) + \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \right).
\end{aligned}$$

□

① – из $A_{k+1} = L_{k+1}\alpha_{k+1}^2$, это следует из (15).

② – из Леммы 4 с $\psi(x) = \alpha_{k+1} \left(f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x - y_{k+1} \rangle + h(x) \right)$.

Лемма 6. С вероятностью больше или равной $1 - \beta$, $\forall x \in Q$, $\forall k \in [0, N]$,

$$\begin{aligned}
& A_{k+1}F(x_{k+1}) - A_kF(x_k) + V(x, u_{k+1}) - V(x, u_k) \\
& \leq \alpha_{k+1}F(x) + 2\delta A_{k+1} + \frac{3\sigma^2\tilde{\Omega}}{L_{k+1}m_{k+1}}A_{k+1} + \alpha_{k+1} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle.
\end{aligned}$$

Доказательство.

$$\begin{aligned}
F(x_{k+1}) & \stackrel{(21), (8)}{\leq} l_{f_\delta}(x_{k+1}; y_{k+1}) + \frac{L_{k+1}}{2} \|x_{k+1} - y_{k+1}\|^2 + h(x_{k+1}) + \frac{3\sigma^2\tilde{\Omega}}{L_{k+1}m_{k+1}} + 2\delta \\
& \stackrel{\text{Лемма 5}}{\leq} \frac{A_k}{A_{k+1}} (l_{f_\delta}(x_k; y_{k+1}) + h(x_k)) + \frac{\alpha_{k+1}}{A_{k+1}} (l_{f_\delta}(x; y_{k+1}) + h(x))
\end{aligned}$$

$$+ \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \Big) + \frac{3\sigma^2 \tilde{\Omega}}{L_{k+1} m_{k+1}} + 2\delta.$$

Далее получаем, что

$$\begin{aligned} F(x_{k+1}) &\leq \frac{A_k}{A_{k+1}} \left(f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x_k - y_{k+1} \rangle + h(x_k) \right) \\ &\quad + \frac{\alpha_{k+1}}{A_{k+1}} \left(f_\delta(y_{k+1}) + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}), x - y_{k+1} \rangle + h(x) \right) \\ &\quad + \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \Big) + \frac{3\sigma^2 \tilde{\Omega}}{L_{k+1} m_{k+1}} + 2\delta \\ &= \frac{A_k}{A_{k+1}} \left(f_\delta(y_{k+1}) + \langle \nabla f_\delta(y_{k+1}), x_k - y_{k+1} \rangle + h(x_k) \right) \\ &\quad + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x_k - y_{k+1} \rangle \\ &\quad + \frac{\alpha_{k+1}}{A_{k+1}} \left(f_\delta(y_{k+1}) + \langle \nabla f_\delta(y_{k+1}), x - y_{k+1} \rangle + h(x) \right) \\ &\quad + \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - y_{k+1} \rangle \\ &\quad + \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \Big) + \frac{3\sigma^2 \tilde{\Omega}}{L_{k+1} m_{k+1}} + 2\delta \\ &\leq \textcircled{1} \frac{A_k}{A_{k+1}} F(x_k) + \frac{\alpha_{k+1}}{A_{k+1}} \left(F(x) + \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \right) \\ &\quad + \frac{3\sigma^2 \tilde{\Omega}}{L_{k+1} m_{k+1}} + 2\delta + \frac{\alpha_{k+1}}{A_{k+1}} \left(\langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - y_{k+1} \rangle \right) \\ &\quad + \frac{\alpha_{k+1}}{A_{k+1}} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), y_{k+1} - u_k \rangle \\ &= \frac{A_k}{A_{k+1}} F(x_k) + \frac{\alpha_{k+1}}{A_{k+1}} \left(F(x) + \frac{1}{\alpha_{k+1}} V(x, u_k) - \frac{1}{\alpha_{k+1}} V(x, u_{k+1}) \right) \\ &\quad + \frac{3\sigma^2 \tilde{\Omega}}{L_{k+1} m_{k+1}} + 2\delta + \frac{\alpha_{k+1}}{A_{k+1}} \left(\langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle \right) \end{aligned}$$

\textcircled{1} – из правой части (8), Следствия 8 и $A_k(y_{k+1} - x_k) = \alpha_{k+1}(u_k - y_{k+1})$ из (17). $\square$

Нам будет полезен факт из [11, 6].

Лемма 7. Пусть $\gamma_1, \dots, \gamma_k$ – i.i.d случайные величины, Γ_k и ν_k – неслучайные функции от γ_i , и c_i – неслучайные константы, для которых верно следующее

$$\begin{aligned} \mathbb{E}[\Gamma_i | \gamma_1, \dots, \gamma_{i-1}] &= 0, \\ |\Gamma_i| &\leq c_i \nu_i, \\ \mathbb{E} \left[\exp \left(\frac{\nu_i^2}{\sigma^2} \right) \middle| \gamma_1, \dots, \gamma_{i-1} \right] &\leq \exp(1). \end{aligned}$$

Тогда

$$\mathbb{P} \left(\sum_{i=1}^k \Gamma_i \geq \sqrt{3} \sqrt{\hat{\Omega}} \sigma \sqrt{\sum_{i=1}^k c_i^2} \right) \leq \exp(-\hat{\Omega}), \quad \forall k, \quad \forall \hat{\Omega} \geq 0.$$

Лемма 8. Пусть $V(x_*, x_0) \leq R^2$, где x_0 – начальная точка, а x_* – ближайшая точка минимума к точке x_0 в смысле дивергенции Брэгмана, тогда с вероятностью $1 - 2\beta$

$$F(x_N) - F(x_*) \leq \frac{R^2}{A_N} + 2\delta N + \epsilon + R_Q \sqrt{\frac{\epsilon}{A_N}}.$$

Доказательство. Учтем (18) и (15) в Лемме 6, тогда с вероятностью большей или равной $1 - \beta$, $\forall k \geq 0$,

$$\begin{aligned} & A_{k+1}F(x_{k+1}) - A_kF(x_k) + V(x, u_{k+1}) - V(x, u_k) \\ & \leq \alpha_{k+1}F(x) + 2\delta A_{k+1} + \alpha_{k+1}\epsilon + \alpha_{k+1}\langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle \end{aligned}$$

Просуммируем неравенства по $k = 0, \dots, N - 1$,

$$\begin{aligned} & A_N F(x_N) - A_0 F(x_0) + V(x, u_N) - V(x, u_0) \\ & \leq (A_N - A_0)F(x) + 2\delta \sum_{k=0}^{N-1} A_{k+1} + \sum_{k=0}^{N-1} \alpha_{k+1}\epsilon \\ & \quad + \sum_{k=0}^{N-1} \alpha_{k+1} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle \end{aligned}$$

Откуда, с учетом неравенства $V(x, u_N) \geq 0$, $\forall x \in Q$,

$$\begin{aligned} A_N F(x_N) - A_N F(x) & \leq V(x, u_0) + 2\delta \sum_{k=0}^{N-1} A_{k+1} + A_N \epsilon \\ & \quad + \sum_{k=0}^{N-1} \alpha_{k+1} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle. \end{aligned}$$

Возьмем $x = x_*$, оценим A_{k+1} через A_N , тогда

$$\begin{aligned} A_N F(x_N) - A_N F(x_*) & \leq V(x_*, u_0) + 2\delta N A_N + A_N \epsilon \\ & \quad + \sum_{k=0}^{N-1} \alpha_{k+1} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle. \end{aligned}$$

Поделим обе части на A_N :

$$F(x_N) - F(x_*) \leq \frac{R^2}{A_N} + 2\delta N + \epsilon + \sum_{k=0}^{N-1} \frac{\alpha_{k+1}}{A_N} \langle \tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle. \quad (25)$$

Воспользуемся Леммой 7 для последнего слагаемого в неравенстве с

$$\begin{aligned} \gamma_i &= \xi_i, \\ \Gamma_i &= \frac{\alpha_{k_i+1}}{A_N m_{k_i+1}} \langle \nabla f_\delta(y_{k_i}; \xi_i) - \nabla f_\delta(y_{k_i}), x - u_{(k_i-1)} \rangle, \\ c_i &= \frac{R_Q \alpha_{k_i+1}}{A_N m_{k_i+1}}, \end{aligned}$$

$$\nu_i = \|\nabla f_\delta(y_{k_i}; \xi_i) - \nabla f_\delta(y_{k_i})\|_*,$$

$i \in [1, \dots, \sum_{k=0}^{N-1} m_{k+1}]$, где k_i равно $k+1$ для всех $i \in [m_k + 1, \dots, m_{k+1}]$. Выберем $\widehat{\Omega} = \ln(1/\beta) \leq \widetilde{\Omega}$, тогда с вероятностью не меньше $1 - \beta$

$$\sum_{k=0}^{N-1} \frac{\alpha_{k+1}}{A_N} \langle \widetilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1}) - \nabla f_\delta(y_{k+1}), x - u_k \rangle \leq \sqrt{3}\sigma\sqrt{\widehat{\Omega}} \sqrt{\sum_{i=0}^{N-1} \frac{R_Q^2 \alpha_{k+1}^2}{A_N^2 m_{k+1}}}. \quad (26)$$

Объединяя (25) и (26) получаем, что с вероятностью не меньше $1 - 2\beta$

$$F(x_N) - F(x_*) \leq \frac{R^2}{A_N} + 2\delta N + \epsilon + \sqrt{3}\sigma\sqrt{\widehat{\Omega}} \sqrt{\sum_{i=0}^{N-1} \frac{R_Q^2 \alpha_{k+1}^2}{A_N^2 m_{k+1}}}.$$

Учтем (18)

$$\begin{aligned} F(x_N) - F(x_*) &\leq \frac{R^2}{A_N} + 2\delta N + \epsilon + R_Q \frac{\sqrt{\widehat{\Omega}}}{\sqrt{\widetilde{\Omega}}} \sqrt{\sum_{i=0}^{N-1} \frac{\alpha_{k+1}\epsilon}{A_N^2}} \\ &\leq \frac{R^2}{A_N} + 2\delta N + \epsilon + R_Q \sqrt{\frac{\epsilon}{A_N}}. \end{aligned}$$

□

Теорема 1. Пусть

$$\delta \leq \frac{\epsilon^{\frac{3}{2}}}{6\sqrt{3}\sqrt{L}R_Q}.$$

Тогда с вероятностью $1 - 3\beta$

$$F(x_N) - F(x_*) \leq 4\epsilon.$$

Доказательство. Мы знаем из Леммы 3, что с вероятностью $1 - \beta$ верно неравенство

$$A_N \geq \frac{(N+1)^2}{12L}.$$

Из последнего неравенства и условия на N получаем, что

$$\frac{R^2}{A_N} \leq \frac{R_Q^2}{A_N} \leq \frac{12LR_Q^2}{\left(\frac{2\sqrt{3}\sqrt{L}R_Q}{\sqrt{\epsilon}} + 1\right)^2} \leq \frac{R_Q^2\epsilon}{R_Q^2} = \epsilon$$

и

$$R_Q \sqrt{\frac{\epsilon}{A_N}} \leq R_Q \sqrt{\frac{\epsilon^2}{R_Q^2}} = \epsilon.$$

Помимо этого с вероятностью $1 - 2\beta$ из Леммы 8

$$F(x_N) - F(x_*) \leq \frac{R^2}{A_N} + 2\delta N + \epsilon + R_Q \sqrt{\frac{\epsilon}{A_N}}.$$

Объединяя все вместе, включая условие на δ , получаем, что с вероятностью $1 - 3\beta$

$$F(x_N) - F(x_*) \leq 4\epsilon.$$

□

Следствие 1. *Далее все утверждения будут выполняться с вероятностью не меньше $1 - 3\beta$. Оценим количество обращений M к оракулу за стохастическими градиентами. По ходу алгоритма мы можем контролировать R_Q^2/A_N , тогда пусть $\tilde{N} + 1$ – минимальное число шагов, для которого выполнено $R_Q^2/A_{\tilde{N}+1} \leq \epsilon$. Ясно, что $\tilde{N} + 1 \leq N$, причем условие $R_Q^2/A_{\tilde{N}+1} \leq \epsilon$ является достаточным условием для достижения ϵ -решения по функции. Как и в [13, 2] количество обращений за $\tilde{\nabla}^{m_{k+1}} f_\delta(y_{k+1})$ на k -ом шаге будет равно $2 + \log(L_k/L_{k-1})$. Также отметим, что $L_{\tilde{N}+1} \leq 3L$. Поэтому общее количество обращений к оракулу за $\nabla f_\delta(y; \xi)$ будет равно*

$$\begin{aligned} M &= 2 \sum_{k=1}^{\tilde{N}+1} m_k \left(2 + \log \left(\frac{L_k}{L_{k-1}} \right) \right) \\ &= 4 \sum_{k=1}^{\tilde{N}+1} m_k + 2 \sum_{k=1}^{\tilde{N}+1} m_k \log \left(\frac{L_k}{L_{k-1}} \right) \\ &\leq 4 \sum_{k=1}^{\tilde{N}+1} m_k + 2 \sum_{j=1}^{\tilde{N}+1} m_j \sum_{k=1}^{\tilde{N}+1} \log \left(\frac{L_k}{L_{k-1}} \right) \\ &\leq \left(4 + \log \left(\frac{L_{\tilde{N}+1}}{L_0} \right) \right) \sum_{k=1}^{\tilde{N}+1} m_k \\ &\leq \left(4 + \log \left(\frac{3L}{L_0} \right) \right) \sum_{k=1}^{\tilde{N}+1} m_k \end{aligned}$$

Рассмотрим $\sum_{k=1}^{\tilde{N}+1} m_k$:

$$\sum_{k=0}^{\tilde{N}} m_{k+1} \leq \tilde{N} + 1 + \frac{3\sigma^2\tilde{\Omega}}{\epsilon} A_{\tilde{N}+1}.$$

Так как

$$\begin{aligned} \alpha_{\tilde{N}+1} &= \frac{1}{2L_{\tilde{N}+1}} + \sqrt{\frac{1}{4L_{\tilde{N}+1}^2} + \frac{A_{\tilde{N}}}{L_{\tilde{N}+1}}} \\ &\leq \textcircled{1} \frac{1}{L_{\tilde{N}+1}} + \sqrt{\frac{A_{\tilde{N}}}{L_{\tilde{N}+1}}} \\ &\leq \frac{2}{L_{\tilde{N}}} + \sqrt{\frac{2A_{\tilde{N}}}{L_{\tilde{N}}}} \end{aligned}$$

$$= \frac{2}{L_{\tilde{N}}} + \sqrt{2}\alpha_{\tilde{N}}.$$

① – из $\sqrt{x+y} \leq \sqrt{x} + \sqrt{y}$.
Ко всему прочему

$$\begin{aligned}\alpha_{\tilde{N}} &= \frac{1}{2L_{\tilde{N}}} + \sqrt{\frac{1}{4L_{\tilde{N}}^2} + \frac{A_{\tilde{N}-1}}{L_{\tilde{N}}}} \\ &\geq \frac{1}{2L_{\tilde{N}}}.\end{aligned}$$

Отсюда

$$\begin{aligned}\alpha_{\tilde{N}+1} &\leq (4 + \sqrt{2})\alpha_{\tilde{N}} \\ &\leq (4 + \sqrt{2})A_{\tilde{N}} \\ &\leq 6A_{\tilde{N}}.\end{aligned}$$

Так как

$$\frac{R_Q^2}{A_{\tilde{N}}} > \epsilon,$$

это следует из минимальности $\tilde{N} + 1$, то

$$\begin{aligned}\frac{R_Q^2}{A_{\tilde{N}+1}} &= \frac{R_Q^2}{A_{\tilde{N}} + \alpha_{\tilde{N}+1}} \\ &\geq \frac{R_Q^2}{A_{\tilde{N}} + 6A_{\tilde{N}}} \\ &> \frac{\epsilon}{7}\end{aligned}$$

и

$$\begin{aligned}\sum_{k=0}^{\tilde{N}} m_{k+1} &\leq \tilde{N} + 1 + \frac{3\sigma^2\tilde{\Omega}}{\epsilon}A_{\tilde{N}+1} \\ &\leq \tilde{N} + 1 + \frac{21\sigma^2\tilde{\Omega}R_Q^2}{\epsilon^2}.\end{aligned}$$

В конечном счете

$$\begin{aligned}M &\leq \left(4 + \log\left(\frac{3L}{L_0}\right)\right) \left(\tilde{N} + 1 + \frac{21\sigma^2\tilde{\Omega}R_Q^2}{\epsilon^2}\right) \\ &\leq \left(4 + \log\left(\frac{3L}{L_0}\right)\right) \left(\frac{2\sqrt{3}\sqrt{L}R_Q}{\sqrt{\epsilon}} + \frac{21\sigma^2\tilde{\Omega}R_Q^2}{\epsilon^2} + 1\right).\end{aligned}$$

Данный результат является оптимальным [10], то есть в общем случае с точностью до константы нельзя сделать количество обращений за стохастическим градиентом меньше.

Замечание 2. Стоит отметить, что ситуация, когда мы можем точно посчитать значение функции (не делая сэмплирование) и неточно градиент, как это делается в Определении 3, вообще говоря нетипична [4, 9]. Как правило, сложность подсчета функции с точностью до мультипликативной константы равна сложности подсчета градиента, поэтому полностью подсчитать значение функции за разумное время нельзя во многих ситуациях. В таком случае нужно оценивать значение функции, используя технику *mini-batch*. В данной работе это не представлено, но по аналогии можно показать, что все оценки несильно изменятся. Более подробный анализ планируется сделать в будущих работах.

3 Заключение

В данной работе нам удалось предоставить адаптивный быстрый стохастический метод и привести полные доказательства для оценок в смысле больших уклонений. Стоит отметить, что данный подход может иметь дальнейшее развитие, в частности, в будущем планируется сделать из данного метода универсальный метод [13] и перенести его на более общие постановки с моделью [14]. Ко всему этому, мы верим, что данный подход может быть обобщен на произвольное множество.

Работа была поддержана грантом РНФ 17-11-01027.

Список литературы

- [1] Александр Гасников, Павел Двуреченский, and Ильнура Усманова. О нетривиальности быстрых (ускоренных) рандомизированных методов. *Труды МФТИ*, 8(2):67–100, 2016.
- [2] Александр Гасников and Юрий Нестеров. Универсальный метод для задач стохастической композитной оптимизации. *Журнал вычислительной математики и математической физики*, 58(1):51–68, 2018.
- [3] Юрий Нестеров. Введение в выпуклую оптимизацию. 2010.
- [4] Atilim Gunes Baydin, Barak A Pearlmutter, Alexey Andreyevich Radul, and Jeffrey Mark Siskind. Automatic differentiation in machine learning: a survey. *arXiv preprint arXiv:1502.05767*, 2015.
- [5] Aharon Ben-Tal and Arkadi Nemirovski. Lectures on modern convex optimization: analysis, algorithms, and engineering applications. http://www2.isye.gatech.edu/~nemirovs/Lect_ModConvOpt.pdf, 2013.
- [6] Olivier Devolder. *Exactness, inexactness and stochasticity in first-order methods for large-scale convex optimization*. PhD thesis, PhD Thesis, ICTEAM and CORE, Université Catholique de Louvain, 2013.
- [7] Mithun Das Gupta and Thomas Huang. Bregman distance to l1 regularized logistic regression. In *Pattern Recognition, 2008. ICPR 2008. 19th International Conference on*, pages 1–4. IEEE, 2008.

- [8] Anatoli Juditsky and Arkadii S Nemirovski. Large deviations of vector-valued martingales in 2-smooth normed spaces. *arXiv preprint arXiv:0809.0813*, 2008.
- [9] Alex Krizhevsky, Ilya Sutskever, and Geoffrey E Hinton. Imagenet classification with deep convolutional neural networks. In *Advances in neural information processing systems*, pages 1097–1105, 2012.
- [10] Guanghui Lan. An optimal method for stochastic composite optimization. *Mathematical Programming*, 133(1):365–397, 2012.
- [11] Guanghui Lan, Arkadi Nemirovski, and Alexander Shapiro. Validation analysis of mirror descent stochastic approximation method. *Mathematical programming*, 134(2):425–458, 2012.
- [12] Yurii Nesterov. *Introductory lectures on convex optimization: A basic course*, volume 87. Springer Science & Business Media, 2013.
- [13] Yurii Nesterov. Universal gradient methods for convex optimization problems. *Mathematical Programming*, 152(1-2):381–404, 2015.
- [14] Alexander Tyurin and Alexander Gasnikov. Fast gradient descent method for convex optimization problems with an oracle that generates a (δ, l) -model of a function in a requested point. *arXiv preprint arXiv:1711.02747*, 2017.