

**Stochastic gradient-free  
online convex optimization.  
One point and many points inexact oracles.  
Convex and strictly convex cases**

*Gasnikov Alexander (PreMoLab MIPT, IITP RAS)*

*Dvurechenski Pavel (IITP RAS, PreMoLab MIPT)*

*Krymova Ekaterina (IITP RAS, PreMoLab MIPT)*

*Usmanova Ilnura (MIPT), Fedorenko Fedor (MIPT),*

*Kamzolov Dmitry (MIPT), Merkulov Daniil (MIPT)*

*February 27, 2015*

# Стохастическая безградиентная оптимизация

Рассматривается задача стохастической выпуклой оптимизации в пространстве  $\mathbb{R}^n$

$$f(x) := E_{\xi} [f(x, \xi)] \rightarrow \min_{x \in Q}. \quad (1)$$

Считаем также, что в  $\mathbb{R}^n$  ( $n \gg 1$ ) задана норма  $\|\cdot\|$  и прокс-структура относительно этой нормы. Прокс-диаметр множества  $Q$  считаем равным  $R$ . Мы будем добавлять нижний индекс 2, если  $\|\cdot\| = \|\cdot\|_2$  и прокс-структура предполагается евклидовой. Функция  $f(x)$  предполагается  $\mu_2$ -сильно выпуклой в 2-норме ( $\mu_2 \geq 0$ , сюда включается случай просто выпуклости  $\mu_2 = 0$ ).

**Пример.** Пусть  $Q$  – единичный шар в  $p$ -норме. Относительно оптимального выбора нормы и прокс-структуры можно заметить следующее: если  $p \geq 2$ , то в качестве нормы оптимально выбирать  $\|\cdot\|_2$  и евклидову прокс-структуру. Определим  $q$  из  $1/p + 1/q = 1$ . Пусть  $1 \leq p \leq 2$ , тогда  $q \geq 2$ . Если при этом  $q = o(\log n)$ , то оптимально выбирать  $\|\cdot\| = \|\cdot\|_p$ , а прокс-структуру задавать прокс-функцией  $d(x) = \frac{1}{p-1} \|x\|_p^2$ . Во всех этих случаях прокс-диаметр множества  $Q$  есть  $R = \sqrt{\max_{x \in Q} d(x)} = O(1)$ . Для  $q \geq \Omega(\log n)$ , выберем  $a = 2 \log n / (2 \log n - 1)$ ,  $\|\cdot\| = \|\cdot\|_a$ , а прокс-структуру будем задавать прокс-функцией  $d(x) = \frac{1}{a-1} \|x\|_a^2$ . В этом случае прокс-диаметр множества  $Q$  есть  $R = O(\sqrt{\log n})$ . Детали см., например, в работе *Agarwal A., Bartlett P.L., Ravikumar P., Wainwright M.J. Information-theoretic lower bounds on the oracle complexity of stochastic convex optimization // e-print, 2011. [arXiv:1009.0571](https://arxiv.org/abs/1009.0571)*

Считаем, что имеют место неравенства

$$\|\nabla f(x) - \nabla f(y)\|_* \leq L \|x - y\|, \quad E_{\xi} \left[ \left\| \nabla f(x, \xi) - E_{\xi} [\nabla f(x, \xi)] \right\|_*^2 \right] \leq D,$$

которые предполагаются выполненными в некоторой окрестности множества  $Q$  (здесь важно, что функция  $f(x)$  задана не только на множестве  $Q$ , но и в некоторой его  $\tau_0$ -окрестности, см. ниже).

Предположим теперь, что у нас оракул может выдавать только реализацию значения функции при этом с шумом не только случайной природы.

**Предположение 1.**  $\delta$ -оракул выдает (на запрос, в котором указывается только одна точка  $x$ )  $f(x, \xi) + \delta(x, \xi)$ , где с.в.  $\xi$  независимо разыгрывается из одного и того же распределения, фигурирующего в постановке (1), случайная величина  $\delta(x, \xi) = \tilde{\delta}(x) + \bar{\delta}(\xi)$ , где  $\bar{\delta}(\xi)$  – независимая от  $x$  случайная величина с неизвестным распределением (случайность которой может быть обусловлена не только зависимостью от  $\xi$ ), ограниченная по модулю  $\delta$ ,  $\tilde{\delta}(x)/(R\delta)$  – неизвестная 1-липшицева функция в норме  $\|\cdot\|$ .

Имея в распоряжении такого  $\delta$ -оракула, требуется предложить оптимальный метод. По определению это метод, для которого для данного класса задач в соотношении

$$E \left[ f \left( x_{N(\varepsilon)} \right) \right] - \min_{x \in Q} f(x) \leq \varepsilon,$$

$N(\varepsilon)$  – минимально. Если случайная величина  $\|\nabla f(x, \xi)\|_*^2$  – равномерно ограниченная (это условие можно обобщать), то используемые методы дают практически такие же оценки на скорость сходимости и в вероятностных категориях: с вероятностью  $\geq 1 - \sigma$  имеет место

$$f \left( x_{N(\varepsilon, \sigma)} \right) - \min_{x \in Q} f(x) \leq \varepsilon, \text{ где } N(\varepsilon, \sigma) = O \left( N(\varepsilon) \ln \left( (\sigma\varepsilon)^{-1} \right) \right).$$

**Основная идея (восходит к работам В. Polyak, J. Matyas, A. Nemirovski)!** Использовать в оптимальных методах вместо стохастического градиента

$$g_{\tau, \delta}(x, e, \xi) = \frac{n}{\tau} \left( f(x + \tau e, \xi) + \delta(x + \tau e, \xi) - (f(x, \xi) + \delta(x, \xi)) \right) e,$$

где  $e$  – случайный вектор (независимый от  $\xi$ ), равномерно распределенный на единичной сфере в 2-норме в пространстве  $\mathbb{R}^n$ ,  $\tau \sim \sqrt{\delta/L}$ .

*Spall J.C.* Introduction to stochastic search and optimization: estimation, simulation and control. Wiley, 2003.

В теореме 1 и следствии 1 предполагается, что на каждом шаге можно обращаться только к  $\delta$ -оракулу, причем не более  $2 \leq m \leq 2n$  раз с одной реализацией  $\xi$ . Отметим, что на данный момент, имеющийся у нас способ доказательства дополнительно предполагает, что в точке минимума  $x_*$  имеет место равенство (принцип Ферма)  $\nabla f(x_*) = 0$ .

**Теорема 1.** *Существуют два однопараметрических семейства методов (параметр  $p \in [0, 1]$ ), которые дают оценки на требуемое число обращений к веденному ранее (в предположении 1)  $\delta$ -оракулу*

$$N_1(\varepsilon) = n \max \left\{ O \left( \frac{LR^2}{\varepsilon} \right)^{\frac{1}{p+1}}, O \left( \frac{DR^2}{\varepsilon^2} \right) \right\}, \delta \leq \frac{1}{n} O \left( \varepsilon \cdot \left( \frac{\varepsilon}{LR^2} \right)^{\frac{p}{p+1}} \right);$$

$$N_2(\varepsilon) = n \max \left\{ O \left( \left( \frac{L_2}{\mu_2} \right)^{\frac{1}{p+1}} \ln \left( \frac{\mu_2 R_2^2}{\varepsilon} \right) \right), O \left( \frac{D_2}{\mu_2 \varepsilon} \right) \right\}, \delta \leq \frac{1}{n} O \left( \varepsilon \cdot \left( \frac{\mu_2}{L_2} \right)^{\frac{p}{p+1}} \right).$$

При этом число итераций будет, соответственно

$$\frac{n}{m} O \left( \frac{LR^2}{\varepsilon} \right)^{\frac{1}{p+1}}, \frac{n}{m} O \left( \left( \frac{L_2}{\mu_2} \right)^{\frac{1}{p+1}} \ln \left( \frac{\mu_2 R_2^2}{\varepsilon} \right) \right).$$

Эти оценки в детерминированном случае ( $D=0$ ) при  $p=1$  и с  $\delta \equiv 0$  были получены в работе *Nesterov Yu. Random gradient-free minimization of convex functions // CORE Discussion Paper 2011/1. 2011.*

Выписанные оценки, по-видимому, не улучшаемые. Однако здесь имеются лишь частичные результаты, см. цикл недавних работ Devolder–Glineur–Nesterov, а также *Duchi J.C., Jordan M.I., Wainwright M.J., Wibisono A. Optimal rates for zero-order convex optimization: the power of two function evaluations // e-print, 2014. [arXiv:1312.2139](https://arxiv.org/abs/1312.2139)*

В точности такие же оценки получаются и для методов, когда оракул выдает зашумленное значение реализации производной по предписанному нами направлению вместо зашумленной реализации функции в двух точках, только требования к точности оракула можно ослабить  $\delta := \sqrt{L\delta}$  (А. Gasnikov et al. [arXiv:1502.06259](https://arxiv.org/abs/1502.06259)).

Следуя работе *Nesterov Yu. Universal gradient methods for convex optimization problems // CORE Discussion Paper 2013/63. 2013*, заметим, что за счет допускаемой неточности оракула, можно погрузить задачу с гельдеровым градиентом ( $\nu \in [0,1]$ )

$$\|\nabla f(x) - \nabla f(y)\|_* \leq L_\nu \|x - y\|^\nu$$

(в том числе и негладкую задачу с ограниченной нормой разности субградиентов при  $\nu = 0$ ) в класс гладких задач со специальным оракулом (Devolder–Glineur–Nesterov), выдающим стохастический градиент, и характеризующимся точностью  $\delta$ .

**Следствие 1.** *Существуют два однопараметрических семейства методов (параметр  $p \in [0,1]$ ), которые дают оценки на требуемое число обращений к введённому ранее (в предположении 1)  $\delta$ -оракулу*

$$N_1(\varepsilon) = n \max \left\{ \underbrace{\mathcal{O} \left( \left( \frac{L_\nu R^{1+\nu}}{\varepsilon} \right)^{\frac{2}{1+2p\nu+\nu}} \right)}_{\bar{N}_1(\varepsilon)}, \mathcal{O} \left( \frac{DR^2}{\varepsilon^2} \right) \right\}, \quad \delta \leq \frac{1}{n} \mathcal{O} \left( \frac{\varepsilon}{\bar{N}_1(\varepsilon)^p} \right);$$

$$N_2(\varepsilon) = n \max \left\{ \underbrace{\mathcal{O} \left( \frac{1}{\varepsilon^{1-\nu}} \ln \left( \frac{\mu_2^\nu R_2^{1+\nu}}{\varepsilon} \right) \left( \frac{L_{\nu,2}^{1+\nu}}{\mu_2} \right)^{\frac{1+\nu}{1+2p\nu+\nu}} \right)}_{\bar{N}_2(\varepsilon)}, \mathcal{O} \left( \frac{D_2}{\mu_2 \varepsilon} \right) \right\}, \quad \delta \leq \frac{1}{n} \mathcal{O} \left( \frac{\varepsilon}{\bar{N}_2(\varepsilon)^p} \right).$$

При этом число итераций будет, соответственно

$$\frac{n}{m} \mathcal{O} \left( \left( \frac{L_\nu R^{1+\nu}}{\varepsilon} \right)^{\frac{2}{1+2p\nu+\nu}} \right), \quad \frac{n}{m} \mathcal{O} \left( \frac{1}{\varepsilon^{1-\nu}} \ln \left( \frac{\mu_2^\nu R_2^{1+\nu}}{\varepsilon} \right) \left( \frac{L_{\nu,2}^{1+\nu}}{\mu_2} \right)^{\frac{1+\nu}{1+2p\nu+\nu}} \right).$$

# Стохастическая онлайн оптимизация

Требуется подобрать последовательность  $\{x^k\} \in Q$  так, чтобы минимизировать псевдо регрет:

$$\frac{1}{N} \sum_{k=1}^N E_{\xi^k} [f_k(x^k, \xi^k)] - \min_{x \in Q} \frac{1}{N} \sum_{k=1}^N E_{\xi^k} [f_k(x, \xi^k)]$$

на основе доступной информации  $\{\nabla \tilde{f}_1(x^1, \xi^1); \dots; \nabla \tilde{f}_{k-1}(x^{k-1}, \xi^{k-1})\}$  при расчете  $x^k$ , где  $\|\nabla \tilde{f}_i(x^i, \xi^i) - \nabla f_i(x^i, \xi^i)\|_* \leq \delta$ . Здесь с.в.  $\{\xi^k\}$  могут считаться независимыми одинаково распределенными. Онлайнность постановки задачи допускает, что на каждом шаге  $k$  функция  $f_k$  может подбираться из рассматриваемого класса функций враждебно по отношению к используемому нами методу генерации последовательности  $\{x^k\}$ . В частности,  $E_{\xi^k} [f_k(x^k, \xi^k)]$  может зависеть от  $\{x^1, \xi^1, f_1(\cdot); \dots; x^{k-1}, \xi^{k-1}, f_{k-1}(\cdot); x^k\}$ .

В стохастической онлайн оптимизации можно получить следующую оценку псевдо регрета (второе выражение в минимуме получается в предположении, что все функции  $E_{\xi^k} [f_k(x, \xi^k)] - \mu_2$ -сильно выпуклые по  $x$  равномерно по  $k$ )

$$\varepsilon = \min \left\{ O \left( \sqrt{\frac{M^2 R^2}{N}} + \delta \right), O \left( \frac{M^2 \ln N}{\mu_2 N} + \delta \right) \right\}, \quad (2)$$

где  $E_{\xi} [\|\nabla f_k(x, \xi)\|_*^2] \leq M^2$  – равномерно по  $k, x$ . Эти оценки достигаются (на соответствующих зеркальных спусках) и неулучшаемы (в том числе для детерминированных постановок с  $\delta = 0$ ). Как видно из этих оценок, наличие гладкости (липшицевости градиента) ничего не дает в общем случае в онлайн контексте. Все что ранее говорилось про прокс-структуру и большие отклонения, насколько нам известно, полностью и практически без изменений переносится и на онлайн случай.

*Hazan E.* Introduction to Online Convex Optimization. Graduate text in machine learning and optimization // [e-print](#), 2015

*Juditsky A., Nemirovski A.* First order methods for nonsmooth convex large-scale optimization, [I](#), [II](#). In: Optimization for Machine Learning. Eds. S. Sra, S. Nowozin, S. Wright. MIT Press, 2012.

# Стохастическая безградиентная онлайн оптимизация

Требуется подобрать последовательность  $\{x^k\} \in Q$  так, чтобы минимизировать псевдо регрет:

$$\frac{1}{N} \sum_{k=1}^N E_{\xi^k} [f_k(x^k, \xi^k)] - \min_{x \in Q} \frac{1}{N} \sum_{k=1}^N E_{\xi^k} [f_k(x, \xi^k)]$$

на основе доступной информации  $\left\{ \left\{ \tilde{f}_1(x_i^1, \xi^1) \right\}_{i=1}^m; \dots; \left\{ \tilde{f}_{k-1}(x_i^{k-1}, \xi^{k-1}) \right\}_{i=1}^m \right\}$  при расчете  $x^k$ , где  $\tilde{f}_k(x_i^k, \xi^k)$  – то, что выдает  $\delta$ -оракул. Здесь с.в.  $\{\xi^k\}$  могут считаться независимыми одинаково распределенными. Онлайнность постановки задачи допускает, что на каждом шаге  $k$  функция  $f_k$  может подбираться из рассматриваемого класса функций враждебно по отношению к используемому нами методу генерации последовательности  $\{x^k\}$ . В частности,  $f_k$  может зависеть от всей предыстории до шага  $k-1$  включительно, но в случае  $m=1$  не может зависеть от  $x^k$ , А. Flaxman et al. (если  $m \geq 2$ , то может)!

Будем предполагать, что функции  $E_{\xi^k} [f_k(x, \xi^k)]$  заданы не только на множестве  $Q$ , но и в некоторой его  $\tau_0$ -окрестности.

$$m = 1$$

Одноточечные нелинейные многорукие бандиты соответствуют  $m=1$ . Здесь неточность оракула мало на что влияет (в отличие от случая  $m \geq 2$ ). Для простоты формулировок положим  $\delta = 0$ .

**Основная идея** (А. Flaxman et al.)! Использовать в оптимальных онлайн методах вместо стохастического градиента

$$g_\tau(x, e, \xi) = \frac{n}{\tau} f(x + \tau e, \xi) e,$$

где  $e$  – случайный вектор (независимый от  $\xi$ ), равномерно распределенный на единичной сфере в 2-норме в пространстве  $\mathbb{R}^n$ .

**Лемма 1.** Пусть  $e$  – случайный вектор, равномерно распределенный на единичной сфере в 2-норме в пространстве  $\mathbb{R}^n$ . Тогда  $E_e \left[ \|e\|_q^2 \right] = \tilde{O}(n^{2/q-1})$ ,  $2 \leq q \leq O(\log n)$ . Согласно примеру 1, другие значения  $q$  – не интересны. В частности,  $E_e \left[ \|e\|_{O(\log n)}^2 \right] = \tilde{O}(n^{-1})$ . Здесь  $\tilde{O}(\cdot) = O(\cdot)$  с точностью до  $\log n$ .

$R$ – прокс-диаметр множества $Q$ относительно нормы $\ \cdot\ _p$ , $1/p + 1/q = 1$	$E_\xi [f_k(x, \xi)]$ – выпуклые	$E_\xi [f_k(x, \xi)]$ – $\mu_2$ -сильно выпуклые
$E_\xi [  f_k(x, \xi)  ] \leq C$	$N = O\left( \frac{n^2 C^6 R^2}{\varepsilon^6 \tau_0^2} \right) \tilde{O}(n^{2/q-1})$	$N = O\left( \frac{n^2 C^6 \ln N}{\mu_2 \varepsilon^5 \tau_0^2} \right)$
$E_\xi [  f_k(x, \xi)  ] \leq C$ , $E_\xi [ \ \nabla f_k(x, \xi)\ _2^2 ] \leq M_2^2$	$N = O\left( \frac{n^2 C^2 M_2^2 R^2}{\varepsilon^4} \right) \tilde{O}(n^{2/q-1})$	$N = O\left( \frac{n^2 C^2 M_2^2 \ln N}{\mu_2 \varepsilon^3} \right)$
$E_\xi [  f_k(x, \xi)  ] \leq C$ , $\ \nabla E_\xi [f_k(x, \xi)] - \nabla E_\xi [f_k(y, \xi)]\ _2 \leq L_2 \ x - y\ _2$	$N = O\left( \frac{n^2 C^2 L_2 R^2}{\varepsilon^3} \right) \tilde{O}(n^{2/q-1})$	$N = O\left( \frac{n^2 C^2 L_2 \ln N}{\mu_2 \varepsilon^2} \right)$

Таблица 1

Приведенные результаты обобщают соответствующие результаты работ

*Flaxman A.D., Kalai A.T., McMahan H.B.* Online convex optimization in the bandit setting: gradient descent without a gradient // [e-print](#), 2004.

*Agarwal A., Dekel O., Xiao L.* Optimal algorithms for online convex optimization with multi-point bandit feedback // In Proceedings of the Twenty-Third Annual Conference on Learning Theory. [2010](#). P.28–40.

на случай прокс-структур отличных от евклидовых. Речь идет о втором столбце таблицы 1, в третьем столбце прокс-структура евклидова. Выделенная желтым цветом оценка ранее нам не встречалась в литературе.

Все что ранее говорилось про большие отклонения, насколько нам известно, полностью и практически без изменений переносится на выписанные в таблице 1 оценки. Стоит также заметить, что на данный момент нам не известно, являются ли выписанные оценки оптимальными. Тем не менее, некоторые результаты здесь есть, см., например,

*Bubeck S., Dekel O., Koren T., Peres Y.* Bandit Convex Optimization:  $\sqrt{T}$  Regret in One Dimension. Preprint, [2015](#).

Не для онлайн постановок нижние оценки известны (см., например, J. Duchi et al. для липшицевой выпуклой целевой функции)  $N = \Omega(n^2/\varepsilon^2)$ . Имеющиеся на данный момент наилучшая оценка сверху  $N = O(n^{7.5}/\varepsilon^2)$

*Belloni A., Liang T., Narayanan H., Rakhlin A.* Escaping the Local Minima via Simulated Annealing: Optimization of Approximately Convex Functions // e-print, 2015. [arXiv:1501.07242](#)

Для детерминированных не онлайн постановок (при небольших  $n$ ) имеются другого типа нижние оценки для липшицевой выпуклой целевой функции (Немировский–Юдин)  $N = \Omega(\text{Poly}(n)\log(1/\varepsilon))$ . Имеющиеся на данный момент наилучшие оценки сверху (“Русский метод” В.Ю. Протасов и др.) также отличаются от нижних оценок.

$$m \geq 2$$

Рассмотрим теперь случай многоточечных многоруких бандитов  $m \geq 2$ . Есть принципиальная разница при переходе от  $m=1$  к  $m \geq 2$ . При последующем увеличении  $m$  оценки будут меняться крайне слабо (см. оценки на число итераций в теореме 1 и следствии 1, а также J. Duchi et al.). Далее мы ограничимся рассмотрением случая  $m=2$ .

**Основная идея (новизна в слове “всегда”)! Всегда** использовать в оптимальных онлайн методах вместо стохастического градиента

$$g_{\tau,\delta}(x, e, \xi) = \frac{n}{\tau} (f(x + \tau e, \xi) + \delta(x + \tau e, \xi) - (f(x, \xi) + \delta(x, \xi))) e,$$

где  $e$  – случайный вектор (независимый от  $\xi$ ), равномерно распределенный на единичной сфере в 2-норме в пространстве  $\mathbb{R}^n$ .

$R$ – прокс-диаметр множества $\mathcal{Q}$ относительно нормы $\ \cdot\ _p$ , $1/p + 1/q = 1$	$E_\xi[f_k(x, \xi)]$ – выпуклые	$E_\xi[f_k(x, \xi)]$ – $\mu_2$ -сильно выпуклые
$E_\xi[\ f_k(x, \xi)\ ] \leq C$	$N = O\left(\frac{nC^4 R^2}{\varepsilon^4 \tau_0^2}\right) \tilde{O}(n^{2/q-1})$	$N = O\left(\frac{nC^4 \ln N}{\mu_2 \varepsilon^3 \tau_0^2}\right)$
$E_\xi[\ \nabla f_k(x, \xi)\ _2^2] \leq M_2^2$	$N = O\left(\frac{nM_2^2 R^2}{\varepsilon^2}\right) \tilde{O}(n^{2/q-1})$	$N = O\left(\frac{nM_2^2 \ln N}{\mu_2 \varepsilon}\right)$
$E_\xi[\ \nabla f_k(x, \xi)\ _2^2] \leq M_2^2$ , $\ \nabla E_\xi[f_k(x, \xi)] - \nabla E_\xi[f_k(y, \xi)]\ _2 \leq L_2 \ x - y\ _2$	$N = O\left(\frac{nM_2^2 R^2}{\varepsilon^2}\right) \tilde{O}(n^{2/q-1})$	$N = O\left(\frac{nM_2^2 \ln N}{\mu_2 \varepsilon}\right)$

Таблица 2

Приведенные результаты обобщают соответствующие результаты работ

Agarwal A., Dekel O., Xiao L. Optimal algorithms for online convex optimization with multi-point bandit feedback // In Proceedings of the Twenty-Third Annual Conference on Learning Theory. 2010. P.28–40.

Duchi J.C., Jordan M.I., Wainwright M.J., Wibisono A. Optimal rates for zero-order convex optimization: the power of two function evaluations // e-print, 2014. [arXiv:1312.2139](https://arxiv.org/abs/1312.2139)

на случай прокс-структур отличных от евклидовых. Речь идет о втором столбце таблицы 2, в третьем столбце прокс-структура евклидова. Точнее говоря, в работе J. Duchi et al. как раз рассматривались различные прокс-структуры, однако исходя из прокс-структуры выбиралась рандомизация, но выбиралась лишь субоптимально. В данной работе было обнаружено, что оптимальной для безградиентных методов все же является рандомизация на евклидовой сфере вне зависимости от того, какая выбрана прокс-структура. Это позволило улучшить оценки J.

Duchi et al., например, в следующем ключе: вместо  $nM_\infty^2$  (где  $E_\xi[\|\nabla f_k(x, \xi)\|_\infty^2] \leq M_\infty^2$ ) стало возможным писать просто  $M_2^2$ , вместо  $nM_\infty^2$  стало возможным писать  $nM_2^2$ . Отметим также, что выделенные желтым цветом оценки ранее нам не встречались в литературе.

Все что ранее говорилось про большие отклонения, насколько нам известно, полностью и практически без изменений переносится на выписанные в таблице 2 оценки. Стоит также заметить, что выписанные оценки являются оптимальными, в том числе и для детерминированных постановок, и для стохастических не онлайн постановок (см. Немировский–Юдин и J. Duchi et al.). Относительно оптимальности оценок, выделенных желтым цветом, нам ничего не известно, но есть гипотеза, что они также оптимальны в онлайн контексте.

Осталось описать условие на уровень шума, при котором оценки в таблице 2 сохраняются. Мы ограничимся здесь только условиями на шум для  $\delta$ -оракула выдающим зашумленную реализацию функции в двух точках. Случай, когда оракул выдает зашумленное значение реализации производной по предписанному нами направлению также приводит к таблице 2, только требования к точности оракула можно будет ослабить.

Поскольку формулы получаются достаточно громоздкими, мы ограничимся здесь изложением механизма их получения.

$$\min\{M_2\tau, L_2\tau^2/2\} = O(\varepsilon) \text{ – условие аппроксимации}$$

$$L_2^2\tau^2n^2 + \frac{8\delta^2n^2}{\tau^2} = O(M_2^2n) \text{ – условие правильной ограниченности квадрата нормы аппроксимации стох. градиента}$$

$$M_2 = O\left(\frac{C^2}{\varepsilon\tau_0}\right) \text{ – условие на эффективную константу } M_2 \text{ для первых строк таблиц 1, 2 (A. Flaxman et al.)}$$

$$L_2 = O\left(\frac{nM_2^2}{\varepsilon}\right) \text{ – условие на эффективную константу } L_2 \text{ для второй строки таблицы 2 (Yu. Nesterov, 2011; J. Duchi et al.)}$$

Выписанные условия позволяют для всех шести полей таблицы написать соответствующие условия на допустимый уровень шума, и параллельно подобрать оптимальный размер шага  $\tau$ .

В заключение, заметим, что если не использовать концепцию  $\delta$ -оракула, а использовать общую концепцию зашумления выдачи, возможно, враждебным шумом масштаба  $\delta$ , то все приведенные в работе оценки сохранятся, только изменятся (увеличатся) требования к уровню этого шума. Поясним, каким образом, можно получить необходимые обобщения. Для этого, дополнительно потребуется рассматривать поведение такого типа сумм, отвечающих за смещенность аппроксимации стох. градиента,

$$\frac{1}{N} \sum_{k=1}^N \frac{\delta n}{\tau} \left| \langle e^k, x^k - x_* \rangle \right| = O\left( \frac{\delta \sqrt{n} R}{\tau} \right) \text{ — с большой вероятностью,}$$

где  $e^k$  — i.i.d. (ни от чего независимые) из равномерно распределенный на единичной сфере в 2-норме в пространстве  $\mathbb{R}^n$ .