

# Использование гладкости высших порядков в безградиентных методах с неточным оракулом для задач выпуклой стохастической оптимизации

Новицкий Василий Геннадьевич  
студент 2 курса магистратуры ФПМИ

Московский физико-технический институт  
Кафедра «Интеллектуальные системы» ВЦ РАН  
Научный руководитель д.ф.-м. н. А.В. Гасников

16 июня 2021

# Проблема

- изучается проблема выпуклой стохастической минимизации функции безградиентными методами

$$f(x) \rightarrow \min_{x \in Q}$$

# Особенности

$$f(x) \rightarrow \min_{x \in Q}$$

1. тип минимизации — стохастический градиентный
2. вместо градиента на каждой итерации известны значения функции с аддитивным шумом (с конечной дисперсией)

$$\tilde{f}(x_k, \xi_k) = f(x_k) + \xi_k, \quad \mathbb{E}[\xi_k^2] \leq \sigma^2$$

3. высокий порядок гладкости функции  $f$  по  $x$  (липшицевость гессиана или производных большего порядка)

# Актуальность проблемы

- Akhavan A., Pontil M., Tsybakov A.B. Exploiting higher-order smoothness in derivative-free optimization and continuous bandits (NeurIPS, 2020)
- Yan Zhang, Yi Zhou, Kaiyi Ji, Michael M. Zavlanos. Boosting One-point Derivative-free Online Optimization Via Residual Feedback (arXiv: 2020)
- F. Bach and V. Perchet. Highly-smooth zero-th order online optimization (PMLR, 2016)
- Shamir O. An optimal algorithm for bandit and zero-order convex optimization with two-point feedback (Journal of Machine Learning Research, 2017)

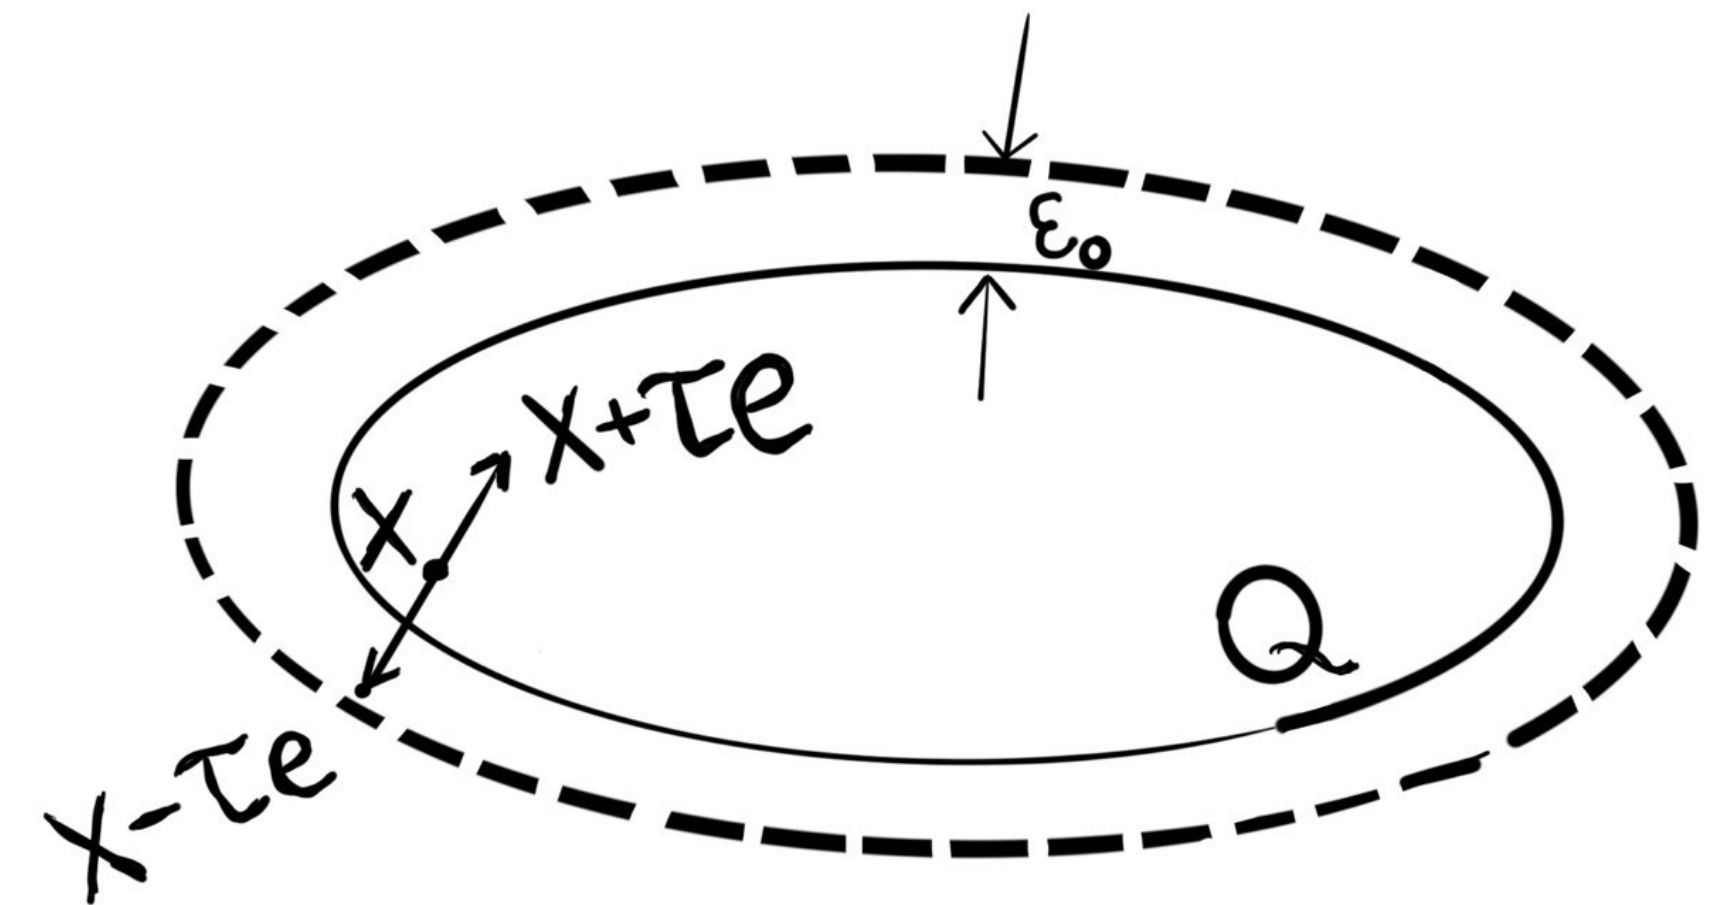
# Результаты

- получены новые верхние оценки скорости сходимости для задачи стохастической минимизации при условии повышенной гладкости целевой функции (одноточечный оракул)
- получены новые верхние оценки для седловой задачи при условии повышенной гладкости целевой функции (одноточечный оракул)
- диплом победителя конференции МФТИ
- Improved Exploiting Higher Order Smoothness in Derivative-free Optimization and Continuous Bandit (V.Novitskii, A.Gasnikov), Optimization Letters [Under Review], <https://arxiv.org/abs/2101.03821>
- One-Point Gradient-Free Methods for Smooth and Non-Smooth Saddle-Point Problems (A.Beznosikov, V.Novitskii, A.Gasnikov), MOTOR 2021 [accepted], <https://arxiv.org/pdf/2103.00321.pdf>

# Свойства функции

$$f(x) \rightarrow \min_{x \in Q},$$

- где  $f : U_{\varepsilon_0}(Q) \rightarrow \mathbb{R}$  — выпуклая функция,
- $Q \subset \mathbb{R}^n$  — выпуклое замкнутое множество
- метрика евклидова
- $\|\nabla f(x) - \nabla f(y)\| \leq G\|x - y\|$   
для всех  $x, y \in U_{\varepsilon_0}(Q)$



$$\tilde{g}_k = \frac{f(x_k + \tau_k e_k) + \xi_k^+ - f(x_k - \tau_k e_k) - \xi_k^-}{2\tau_k} n e_k$$

# Гладкость высоких порядков

Определение: функция  $f(x)$  удовлетворяет условию Гельдера с параметром  $\beta$  [ $f \in \mathcal{F}_\beta(L)$ ], если

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

- здесь  $l$  – максимальное целое число, строго меньшее, чем  $\beta$ ,  
сумма ведется по мультииндексу  $m = (m_1, \dots, m_n) \in \mathbb{N}^n$ ,  
 $m! = m_1! \cdot \dots \cdot m_n!$ ,  $L > 0$ .

Мы исследуем функции, удовлетворяющие условию Гельдера с параметром  $\beta > 2$ .

# Как мы используем гладкость высоких порядков

Сглаживающее ядро:  $K : [-1, 1] \rightarrow \mathbb{R}$ ,

$$\mathbb{E}[K(r)] = 0, \mathbb{E}[rK(r)] = 1, \mathbb{E}[r^j K(r)] = 0, j = 2, \dots, l, \mathbb{E}[|r|^\beta |K(r)|] \leq \infty$$
$$r \sim U[-1, 1]$$

Стохастическая аппроксимация градиента:

$$g_k = \frac{f(x_k + r_k \delta_k) - f(x_k - r_k \delta_k)}{2\|\delta_k\|} n K(r_k) e_k$$

$e_k$  — распределен равномерно на Евклидовой сфере

$r_k$  — распределен равномерно на  $[-1; 1]$




# Как мы используем гладкость высоких порядков

$$K_{\beta}(r) = 3r, \quad \beta \in [2, 3],$$

$$K_{\beta}(r) = \frac{15r}{4}(5 - 7r^2), \quad \beta \in (3, 5],$$

$$K_{\beta}(r) = \frac{105r}{64}(99r^4 - 126r^2 + 35), \quad \beta \in (5, 7].$$

# Как мы используем гладкость высоких порядков



# Шум

$$f(x) \rightarrow \min_{x \in Q}$$

- значения функции на каждой итерации известны с аддитивным шумом (с, вообще говоря, ненулевым мат. ожиданием и конечной дисперсией)

$$\tilde{f}(x_k, \xi_k) = f(x_k) + \xi_k, \quad \mathbb{E}[\xi_k^2] \leq \sigma^2$$

$$\tilde{g}_k = \frac{f(x_k + \tau_k r_k e_k) + \xi_k^+ - f(x_k - \tau_k r_k e_k) - \xi_k^-}{2\tau_k} nK(r_k) e_k$$

$e_k$  — распределен равномерно на Евклидовой сфере

$r_k$  — распределен равномерно на  $[-1; 1]$

# Предположения на шум

$$\tilde{g}_k = \frac{f(x_k + \tau_k r_k e_k) + \xi_k^+ - f(x_k - \tau_k r_k e_k) - \xi_k^-}{2\tau_k} nK(r_k) e_k$$

$e_k$  — распределен равномерно на Евклидовой сфере

$r_k$  — распределен равномерно на  $[-1; 1]$

1.  $\mathbb{E}[\xi_k^+] \leq \sigma^2, \mathbb{E}[\xi_k^-] \leq \sigma^2$
2. случайные величины  $\xi_k^+$  and  $\xi_k^-$  независимы с  $e_k$  и  $r_k$
3. случайные величины  $e_k$  и  $r_k$  независимы

так как  $\xi_k^+ \neq \xi_k^-$ , то оракул одноточечный

# Алгоритм (метод проекции градиента)


**for**  $k = 1, \dots, N$  **do**

$$1. \tilde{g}_k = \frac{f(x_k + \tau_k r_k e_k) + \xi_k^+ - f(x_k - \tau_k r_k e_k) - \xi_k^-}{2\tau_k} nK(r_k) e_k$$

$$2. x_{k+1} := \text{Proj}_Q(x_k - \alpha_k \tilde{g}_k)$$

**end**

**Return:**  $\bar{x}_N = \frac{1}{N} \sum_{k=1}^N x_k$



# Задача

$$f(x) \rightarrow \min_{x \in Q}$$

- $\|\nabla f(x) - \nabla f(y)\| \leq G\|x - y\|$  для всех  $x, y \in U_{\varepsilon_0}(Q)$
- функция удовлетворяет условию Гельдера с параметром  $\beta > 2$  в  $Q$
- значения функции доступны с шумом, удовлетворяющим условиям:
  1.  $\mathbb{E}[\xi_k^+] \leq \sigma^2, \mathbb{E}[\xi_k^-] \leq \sigma^2$
  2. случайные величины  $\xi_k^+$  and  $\xi_k^-$  независимы с  $e_k$  и  $r_k$
  3. случайные величины  $e_k$  и  $r_k$  независимы

# Основной вопрос

$$\mathbb{E} [f(\bar{x}_N) - f(x^*)] \leq \varepsilon$$

Как  $\varepsilon$  зависит от параметров:

- размерность пространства  $n$
- число итераций  $N$
- параметр гладкости  $\beta$
- константа сильной выпуклости  $\gamma$  (для случая сильно выпуклой функции)

# Теорема 1. (Новицкий, 2020)

Для  $\gamma$ -сильно выпуклой функции  $f$  алгоритм с параметрами

$$\tau_k = \left( \frac{3\kappa\sigma^2 n}{2(\beta - 1)(\kappa_\beta L)^2} \right)^{\frac{1}{2\beta}} k^{-\frac{1}{2\beta}}, \quad \alpha_k = \frac{2}{\gamma k}, \quad k = 1, \dots, N$$

дает оценку ошибки оптимизации:

$$\mathbb{E} [f(\bar{x}_N) - f(x^*)] \leq \mathcal{O} \left( \frac{n^{2-\frac{1}{\beta}}}{\gamma N^{\frac{\beta-1}{\beta}}} \right).$$



# Теорема 1. (Новицкий, 2020)

Для  $\gamma$ -сильно выпуклой функции ошибка оптимизации  $\mathbb{E} [f(\bar{x}_N) - f(x^*)] \leq \varepsilon$  достигается после  $N(\varepsilon)$  итераций, где

$$N(\varepsilon) = \mathcal{O} \left( \frac{n^{2 + \frac{1}{\beta - 1}}}{(\gamma\varepsilon)^{\frac{\beta}{\beta - 1}}} \right).$$

# Теорема 2. (Новицкий, 2020)

Для выпуклой функции  $f$  ошибка оптимизации  $\mathbb{E} [f(\bar{x}_N) - f(x^*)] \leq \varepsilon$  достигается после

$$N(\varepsilon) = \mathcal{O} \left( \frac{n^{2+\frac{1}{\beta-1}}}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$$

итераций алгоритма для  $\gamma$ -сильно выпуклой регуляризованной функции  $f_\gamma(x) := f(x) + \frac{\gamma}{2} \|x - x_0\|_2^2$ , где  $\gamma \leq \frac{\varepsilon}{2\|x_0 - x^*\|^2}$ .

# Основные результаты

Зависимость количества итераций  $N(\varepsilon)$  от  $n$  (размерность пространства),  $\gamma$  (сильная выпуклость),  $\beta$  (параметр гладкости)

	сильно выпуклая	выпуклая
нижняя оценка, Akhavan, Pontil, Tsybakov (2020)	$\mathcal{O} \left( \min \left( \frac{n^{1+\frac{1}{\beta-1}}}{(\gamma\varepsilon)^{\frac{\beta}{\beta-1}}}, \frac{n^2}{\varepsilon^2} \right) \right)$	$\mathcal{O} \left( \min \left( \frac{n^{1+\frac{1}{\beta-1}}}{\varepsilon^{2+\frac{2}{\beta-1}}}, \frac{n^2}{\varepsilon^2} \right) \right)$
Новицкий (2020)	$\tilde{\mathcal{O}} \left( \frac{n^{2+\frac{1}{\beta-1}}}{(\gamma\varepsilon)^{\frac{\beta}{\beta-1}}} \right)$	$\tilde{\mathcal{O}} \left( \frac{n^{2+\frac{1}{\beta-1}}}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$
Akhavan, Pontil, Tsybakov (2020)	$\tilde{\mathcal{O}} \left( \frac{n^{2+\frac{2}{\beta-1}}}{(\gamma\varepsilon)^{\frac{\beta}{\beta-1}}} \right)$	$\tilde{\mathcal{O}} \left( \frac{n^{2+\frac{2}{\beta-1}}}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$
Bach, Perchet (2016)	$\mathcal{O} \left( \frac{n^{2+\frac{2}{\beta-1}}}{\gamma\varepsilon^{\frac{\beta+1}{\beta-1}}} \right)$	$\mathcal{O} \left( \frac{n^{2+\frac{2}{\beta-1}}}{\varepsilon^{2+\frac{2}{\beta-1}}} \right)$
Gasnikov and al. (2015), $\beta = 2$	$\tilde{\mathcal{O}} \left( \frac{n^2}{\gamma\varepsilon^2} \right)$	$\tilde{\mathcal{O}} \left( \frac{n^2}{\varepsilon^3} \right)$

$\gamma \sim \varepsilon$

# Седловая задача

$$\min_{x \in \mathcal{X}} \max_{y \in \mathcal{Y}} \varphi(x, y)$$

Изменения:

1.  $\tilde{g}_k := \frac{n}{2\tau_k} (\tilde{\varphi}_k^+ - \tilde{\varphi}_k^-) \begin{pmatrix} (\mathbf{e}_k)_x \\ -(\mathbf{e}_k)_y \end{pmatrix} K(r_k)$

2. Функция ошибки:

$$\mathbb{E} [\varphi(\bar{x}_N, y^*) - \varphi(x^*, \bar{y}_N)] \leq \max_{y \in \mathcal{Y}} \mathbb{E} [\varphi(\bar{x}_N, y)] - \min_{x \in \mathcal{X}} \mathbb{E} [\varphi(x, \bar{y}_N)] \leq \varepsilon$$

# Теорема 3 (Новицкий, 2021)

Для  $\gamma$ -сильно-выпуклой-сильно-вогнутой  $\varphi$  алгоритм с параметрами

$$\tau_k = \left( \frac{3\kappa\sigma^2 n}{2(\beta - 1)(\kappa_\beta L)^2} \right)^{\frac{1}{2\beta}} k^{-\frac{1}{2\beta}}, \quad \alpha_k = \frac{2}{\gamma k}, \quad k = 1, \dots, N$$

дает оценку ошибки оптимизации:

$$\mathbb{E} [\varphi(\bar{x}_N, y^*) - \varphi(x^*, \bar{y}_N)] \leq \max_{y \in \mathcal{Y}} \mathbb{E} [\varphi(\bar{x}_N, y)] - \min_{x \in \mathcal{X}} \mathbb{E} [\varphi(x, \bar{y}_N)] \leq \mathcal{O} \left( \frac{n^{2 - \frac{1}{\beta}}}{\gamma N^{\frac{\beta - 1}{\beta}}} \right).$$

# Теорема 3 (Новицкий, 2021)

Для  $\gamma$ -сильно-выпуклой-сильно-вогнутой функции  $\varphi$  ошибка оптимизации

$$\mathbb{E} [\varphi(\bar{x}_N, y^*) - \varphi(x^*, \bar{y}_N)] \leq \max_{y \in \mathcal{Y}} \mathbb{E} [\varphi(\bar{x}_N, y)] - \min_{x \in \mathcal{X}} \mathbb{E} [\varphi(x, \bar{y}_N)] \leq \varepsilon$$

достигается после  $N(\varepsilon)$  итераций, где

$$N(\varepsilon) = \mathcal{O} \left( \frac{n^{2 + \frac{1}{\beta - 1}}}{(\gamma \varepsilon)^{\frac{\beta}{\beta - 1}}} \right).$$

# Теорема 4 (Новицкий, 2021)

Для выпукло-вогнутой функции  $\varphi$  ошибка оптимизации

$$\mathbb{E} [\varphi(\bar{x}_N, y^*) - \varphi(x^*, \bar{y}_N)] \leq \max_{y \in \mathcal{Y}} \mathbb{E} [\varphi(\bar{x}_N, y)] - \min_{x \in \mathcal{X}} \mathbb{E} [\varphi(x, \bar{y}_N)] \leq \varepsilon$$

достигается после

$$N(\varepsilon) = \mathcal{O} \left( \frac{n^{2 + \frac{1}{\beta-1}}}{\varepsilon^{2 + \frac{2}{\beta-1}}} \right)$$

итераций алгоритма для  $\gamma$ -сильно-выпуклой-сильно-вогнутой регуляризованной функции  $\varphi_\gamma(x, y) := \varphi(x, y) + \frac{\gamma}{2} \|x - x_0\|^2 - \frac{\gamma}{2} \|y - y_0\|^2$ , где  $\gamma \leq \frac{\varepsilon}{\|x_0 - x^*\|^2 + \|y_0 - y^*\|^2}$ .

# Эксперимент

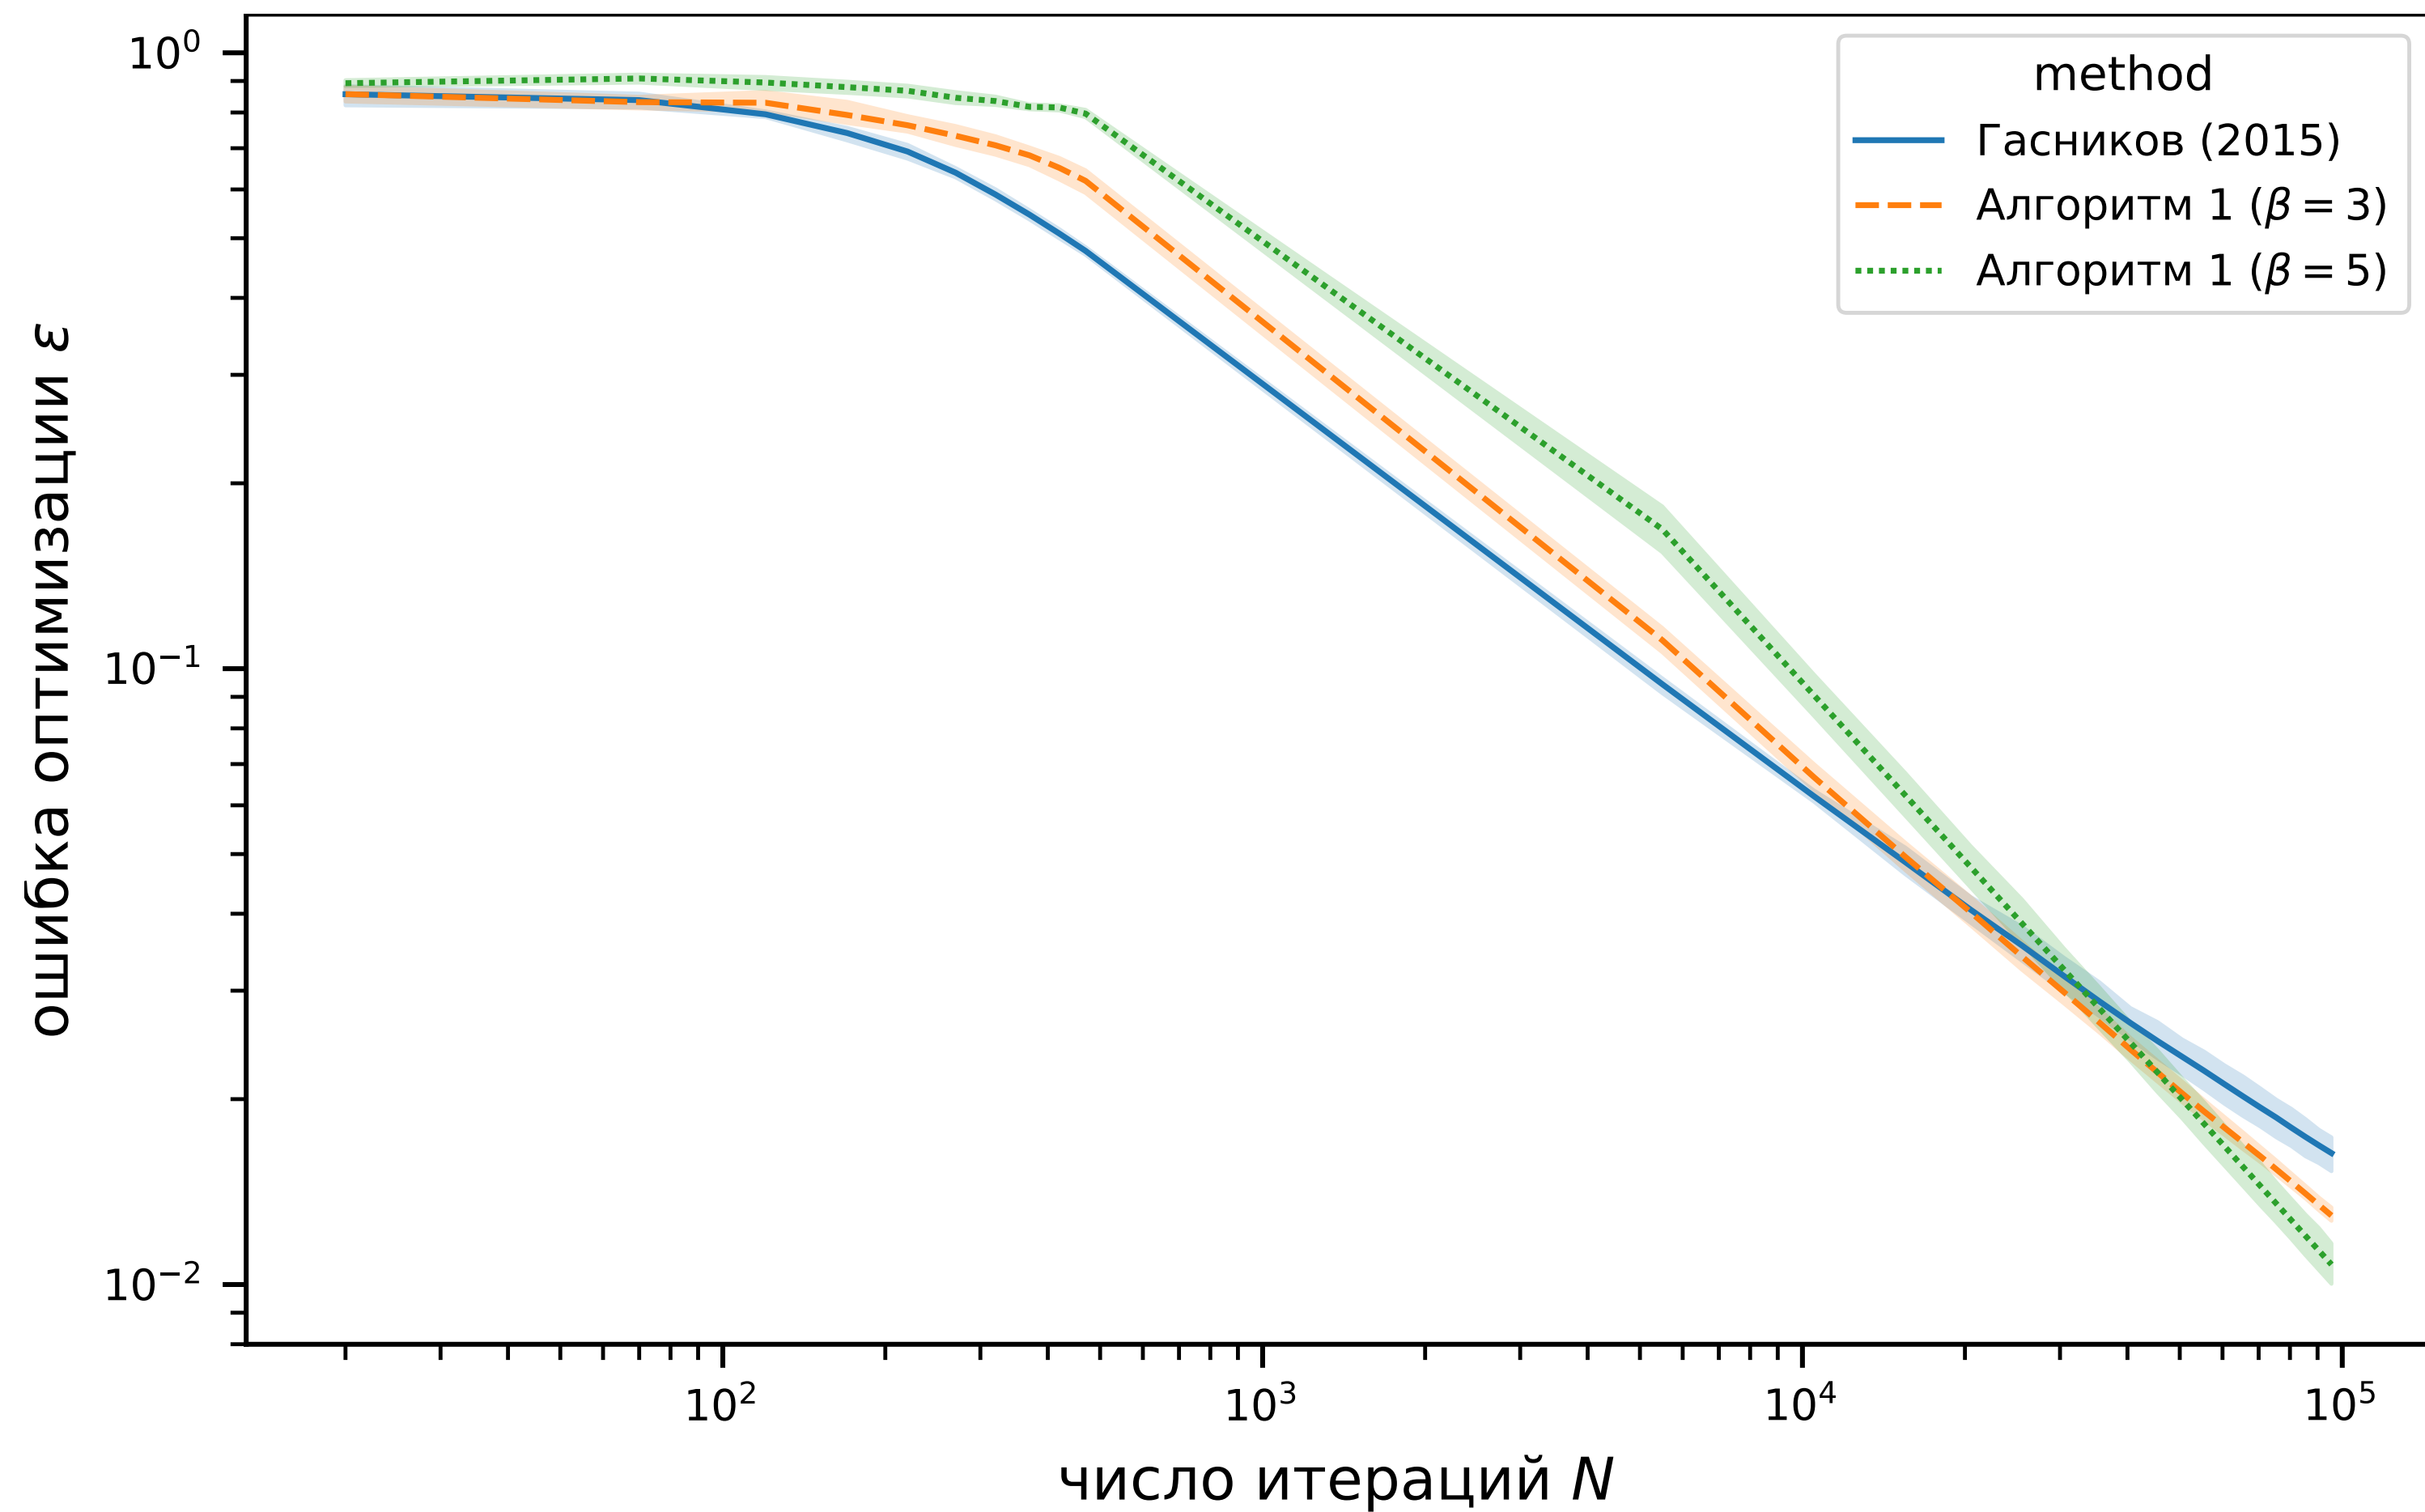
$$f(x) = \frac{1}{2}x^T Ax + \frac{1}{10} \sum_{k=1}^{50} |x_k|^4 \rightarrow \min_{x \in B_1(0)}$$

собственные значения матрицы: 0.25, 1, 4.

	теория
Гасников, $\beta = 2$ , 2015	$\varepsilon \sim N^{-0.5}$
Алгоритм, $\beta = 3$ , 2020	$\varepsilon \sim N^{-2/3}$
Алгоритм, $\beta = 5$ , 2020	$\varepsilon \sim N^{-4/5}$



# Эксперимент



	теория	эксперимент
Гасников, $\beta = 2$ , 2015	$\varepsilon \sim N^{-0.5}$	$\varepsilon \sim N^{-0.61}$
Алгоритм, $\beta = 3$ , 2020	$\varepsilon \sim N^{-2/3}$	$\varepsilon \sim N^{-0.73}$
Алгоритм, $\beta = 5$ , 2020	$\varepsilon \sim N^{-4/5}$	$\varepsilon \sim N^{-0.91}$

# Результаты

- получены новые верхние оценки для задачи стохастической минимизации при условии повышенной гладкости целевой функции (одноточечный оракул)
- получены новые верхние оценки для седловой задачи при условии повышенной гладкости целевой функции (одноточечный оракул)
- диплом победителя конференции МФТИ
- Improved Exploiting Higher Order Smoothness in Derivative-free Optimization and Continuous Bandit (V. Novitskii, A. Gasnikov), Optimization Letters [Under Review], <https://arxiv.org/abs/2101.03821>
- One-Point Gradient-Free Methods for Smooth and Non-Smooth Saddle-Point Problems (A. Beznosikov, V. Novitskii, A. Gasnikov), MOTOR 2021 [accepted], <https://arxiv.org/pdf/2103.00321.pdf>