

УДК 519.853.62

**Ускоренный метаалгоритм для задач выпуклой оптимизации**

**А. В. Гасников<sup>1,2</sup>, Д. М. Двинских<sup>2,1,3</sup>, П. Е. Двуреченский<sup>3,2</sup>,**  
**Д. И. Камзолов<sup>1</sup>, В. В. Матюхин<sup>1</sup>, Д. А. Пасечнюк<sup>1</sup>,**  
**Н. К. Тупица<sup>1</sup>, А. В. Чернов<sup>1</sup>**

<sup>1</sup>*Московский физико-технический институт (национальный  
исследовательский университет), Долгопрудный, Московская обл.,  
Россия*

<sup>2</sup>*Институт проблем передачи информации им. А.А. Харкевича  
Российской академии наук, Москва, Россия*

<sup>3</sup>*Институт прикладного анализа и стохастики им. К. Вейерштрасса,  
Берлин, Германия*

\* e-mail: kamzolov.dmitry@phystech.edu

Поступила в редакцию: 18 апреля 2020.

Переработанный вариант .....

Принята к публикации 24 августа 2020.

В работе предлагается оболочка, названная «ускоренный метаалгоритм», которая позволяет единообразно получать ускоренные методы решения задач выпуклой безусловной минимизации в различных постановках на базе неускоренных вариантов. В качестве приложений приводятся квазиоптимальные алгоритмы для минимизации гладких функций с Липшицевыми производными произвольного порядка, а также для решения гладких минимаксных задач. Предложенная оболочка является более общей, чем существующие, а также позволяет получать лучшие оценки скорости сходимости и практическую эффективность для ряда постановок задач.

**Ключевые слова:** выпуклая оптимизация, проксимальный ускоренный метод, тензорные методы, неточный оракул, слайдинг, каталист

# 1 Введение

В последние 15 лет в численных методах гладкой выпуклой оптимизации преобладают, так называемые, ускоренные методы. Прообразом таких методов является метод тяжелого шарика Б.Т. Поляка и моментный метод Ю.Е. Нестерова [1, 2]. Оказалось, что для многих задач гладкой выпуклой оптимизации оптимальные методы (с точки зрения числа вычислений градиента функции; в общем случае, старших производных) могут быть найдены среди ускоренных методов [1, 2, 3]. Появилось огромное число работ, в которых предлагаются различные варианты ускоренных методов для разных классов задач, см., например, обзор литературы в [1, 3]. Каждый раз процедура ускорения принимала свою причудливую форму. Естественно, возникло желание как-то унифицировать все это. В 2015 году это было сделано для широкого класса (рандомизированных) градиентных методов с помощью проксимальной ускоренной оболочки, названной Каталист<sup>1</sup> [4]. С 2013 года данные результаты стали активно переноситься на тензорные методы (использующие старшие производные) [5, 6, 7, 8]. В самое последнее время предпринимаются попытки унификации проце-

---

<sup>1</sup>Здесь и далее в качестве названий подходов / алгоритмов иногда будут использоваться англизмы. Дело в том, что дословный перевод исходно английских выражений на русский язык может только запутывать дело.

Отметим также, что под «проксимальной оболочкой» здесь и далее имеется в виду просто проксимальный алгоритм. Слово «оболочка» подразумевает, что в проксимальном алгоритме на каждой итерации имеется своя внутренняя (вспомогательная) задача оптимизации, которую, как правило, нельзя решить аналитически. Ее нужно решать численно. Поэтому внешний проксимальный метод можно понимать как «оболочку» для метода, использующегося для решения внутренней задачи.

дур ускорения для седловых задач и задач со структурой (композитных задач) [9, 10, 11, 12]. Во всех этих направлениях, по-прежнему, использовалось значительное разнообразие ускоренных проксимальных оболочек [1, 4, 5, 6, 7, 8, 10, 11, 13, 14, 15, 16]. Метод из данной работы<sup>2</sup> будет во многом базироваться на схеме из [14].

В данной работе показывается, что достаточно изучить всего одну ускоренную проксимальную оболочку, которая позволяет получать все известные нам ускоренные методы для задач гладкой выпуклой безусловной оптимизации. Причем в ряде случаев предложенный ускоренный матаалгоритм позволяет убирать логарифмические зазоры в оценках сложности (по сравнению с нижними оценками), имевшие место в предыдущих подходах.

## 2 Основные результаты

Рассмотрим следующую задачу ( $x_*$  – решение задачи)

$$\min_{x \in \mathbb{R}^d} \{F(x) := f(x) + g(x)\}, \quad (1)$$

где  $f$  и  $g$  выпуклые функции.

Везде в дальнейшем под  $\|\cdot\|$  будем понимать обычную евклидову норму в пространстве  $\mathbb{R}^d$ ,

$$D^k f(x)[h]^k = \sum_{i_1, \dots, i_d \geq 0: \sum_{j=1}^d i_j = k} \frac{\partial^k f(x)}{\partial x_1^{i_1} \dots \partial x_d^{i_d}} h_1^{i_1} \cdot \dots \cdot h_d^{i_d},$$

---

<sup>2</sup>Строго говоря, это даже не метод (алгоритм), а скорее оболочка (в смысле определенном выше). В данной статье было выбрано название «ускоренный матаалгоритм». Первое слово поясняет цель разрабатываемой оболочки – ускорение метода, использующегося в качестве базового (решающего внутреннюю задачу). Однако, в отличие от стандартной (ускоренной) оболочки, в предложенной в данной статье оболочке все же в ряде важных случаев вспомогательная задача решается аналитически, и, стало быть, говорить об этой оболочке, как «оболочке», а не как об обычном алгоритме, не совсем корректно. Поэтому было решено использовать более нейтральное в этом смысле слово – «метаалгоритм».

$$\|D^k f(x)\| = \max_{\|h\| \leq 1} \|D^k f(x)[h]^k\|.$$

Будем считать, что  $f$  имеет Липшицевы производные порядка  $p$  ( $p \in \mathbb{N}$ ):

$$\|D^p f(x) - D^p f(y)\| \leq L_{p,f} \|x - y\|. \quad (2)$$

Здесь и далее (см., например, (7)) можно считать, что  $x, y \in \mathbb{R}^d$  принадлежат евклидову шару с центром в точке  $x_*$  и радиусом  $O(\|x_0 - x_*\|)$ , где  $x_0$  – точка старта [6].

Введем аппроксимацию рядом Тейлора функции  $f$ :

$$\Omega_p(f, x; y) = f(x) + \sum_{k=1}^p \frac{1}{k!} D^k f(x) [y - x]^k, \quad y \in \mathbb{R}^d.$$

Заметим, что из (2) следует [17]

$$|f(y) - \Omega_p(f, x; y)| \leq \frac{L_{p,f}}{(p+1)!} \|y - x\|^{p+1}. \quad (3)$$

Доказательство следующей теоремы см. в Приложении 1. Литературный обзор см. в препринте [11].

**Теорема 1.** Пусть  $y_k$  – выход Алгоритма 1  $YM(x_0, f, g, p, H, k)$  после  $k$  итераций при  $p \geq 1$  и  $H \geq (p+1)L_{p,f}$ . Тогда

$$F(y_k) - F(x_*) \leq \frac{c_p H R^{p+1}}{k^{\frac{3p+1}{2}}}, \quad (5)$$

$$\text{где } c_p = 2^{p-1}(p+1)^{\frac{3p+1}{2}}/p!, \quad R = \|x_0 - x^*\|.$$

Более того, при  $p \geq 2$  для достижения точности  $\varepsilon$ :  $F(y_k) - F(x_*) \leq \varepsilon$  на каждой итерации  $YM$  вспомогательную задачу (4) придется переписывать для подбора пары  $(\lambda_{k+1}, y_{k+1})$  не более чем  $O(\ln(\varepsilon^{-1}))$  раз.

Заметим, что приведенная выше теорема будет справедлива и при условии  $H \geq 2L_{p,f}$  (независимо от  $p \in \mathbb{N}$ ). Это выводится из (3). Условие  $H \geq (p+1)L_{p,f}$  было использовано, поскольку оно гарантирует выпуклость вспомогательной подзадачи (4) [17]. При этом условии и  $g \equiv 0$  для

---

**Algorithm 1** Ускоренный Метаалгоритм (УМ) ( $\text{УМ}(x_0, f, g, p, H, K)$ )

---

- 1: **Input:**  $p \in \mathbb{N}$ ,  $f : \mathbb{R}^d \rightarrow \mathbb{R}$ ,  $g : \mathbb{R}^d \rightarrow \mathbb{R}$ ,  $H > 0$ .
- 2:  $A_0 = 0$ ,  $y_0 = x_0$ .
- 3: **for**  $k = 0$  **to**  $k = K - 1$
- 4:     Определить пару  $\lambda_{k+1} > 0$  и  $y_{k+1} \in \mathbb{R}^d$  из условий

$$\frac{1}{2} \leq \lambda_{k+1} \frac{H \|y_{k+1} - \tilde{x}_k\|^{p-1}}{p!} \leq \frac{p}{p+1},$$

где

$$y_{k+1} = \underset{y \in \mathbb{R}^d}{\operatorname{argmin}} \left\{ \tilde{\Omega}^k(y) := \Omega_p(f, \tilde{x}_k; y) + g(y) + \frac{H}{(p+1)!} \|y - \tilde{x}_k\|^{p+1} \right\}, \quad (4)$$

$$a_{k+1} = \frac{\lambda_{k+1} + \sqrt{\lambda_{k+1}^2 + 4\lambda_{k+1}A_k}}{2}, \quad A_{k+1} = A_k + a_{k+1},$$

$$\tilde{x}_k = \frac{A_k}{A_{k+1}} y_k + \frac{a_{k+1}}{A_{k+1}} x_k.$$

- 5:      $x_{k+1} := x_k - a_{k+1} \nabla f(y_{k+1}) - a_{k+1} \nabla g(y_{k+1})$ .

6: **end for**

- 7: **return**  $y_K$
- 

$p = 1, 2, 3$  существуют эффективные способы решения вспомогательной задачи (4) [17]. Для  $p = 1$  существует явная формула для решения (4), для  $p = 2, 3$  сложность (4) такая же (с точностью до логарифмического по  $\varepsilon$  множителя), как у итерации метода Ньютона [17].

Важно отметить, что вспомогательную задачу (4) не обязательно решать точно: достаточно [11, 18] найти точку  $\tilde{y}_{k+1}$ , удовлетворяющую

$$\|\nabla \tilde{\Omega}^k(\tilde{y}_{k+1})\| \leq \frac{1}{4p(p+1)} \|\nabla F(\tilde{y}_{k+1})\|. \quad (6)$$

Такая модификация приведет лишь к появлению множителя  $12/5$  в правой

части (5).

Будем говорить, что функция  $F$  является  $r$ -равномерно выпуклой ( $p+1 \geq r \geq 2$ ) с константой  $\sigma_r > 0$ , если

$$F(y) \geq F(x) + \langle \nabla F(x), y - x \rangle + \frac{\sigma_r}{r} \|y - x\|^r, \quad x, y \in \mathbb{R}^d. \quad (7)$$

В этом случае, используя [19]

$$F(\tilde{y}_{k+1}) - F(x_*) \leq \frac{r-1}{r} \left( \frac{1}{\sigma_r} \right)^{\frac{1}{r-1}} \|\nabla F(\tilde{y}_{k+1})\|^{\frac{r}{r-1}},$$

можно завязать критерий (6) на желаемую точностью (по функции) решения исходной задачи  $\varepsilon$  [11]:  $\|\nabla \tilde{\Omega}^k(\tilde{y}_{k+1})\| = O\left((\epsilon^{r-1} \sigma_r)^{\frac{1}{r}}\right)$ .

Более того, для  $p = 1$  приведенные здесь выкладки можно уточнить, подчеркнув, тем самым, что сложность решения вспомогательной задачи может даже не зависеть от  $\varepsilon$ . Оказывается (см. [16]), что условие

$$\|\tilde{y}_{k+1} - y_{k+1}^*\| \leq \frac{H}{3H + 2L_1^g} \|\tilde{x}_k - y_{k+1}^*\|, \quad (8)$$

где  $y_{k+1}^*$  – точное решение задачи (4), а  $L_1^g$  – константа Липшица градиента  $\nabla g$ , в теоретическом плане гарантирует то же, что и условие (6) при  $p = 1$ . А именно, Теорема 1 останется верной с добавлением в правую часть (5) множителя  $12/5$ .

Отметим, что оценка скорости сходимости (5) с точностью до числового множителя  $c_p$  не может быть улучшена для класса выпуклых задач (1) с Липшицевой  $p$ -й производной и для широкого класса тензорных методов порядка  $p$ , описанном в [17]. При дополнительном предположении равномерной выпуклости  $F$  оптимальный метод можно построить на базе УМ с помощью процедуры рестартов [11] – см. Алгоритм 2.

**Теорема 2.** Пусть  $y_k$  – выход Алгоритма 2 после  $k$  итераций. Тогда если  $H \geq (p+1)L_{p,f}$ ,  $\sigma_r > 0$ , то общее число вычислений (4) для достижения

---

**Algorithm 2** Рестартованный УМ( $x_0, f, g, p, r, \sigma_r, H, K$ )

---

1: **Input:**  $r$ -равномерно выпуклая функция  $F = f + g : \mathbb{R}^d \rightarrow \mathbb{R}$  с константой  $\sigma_r$  и УМ( $x_0, f, g, p, H, K$ ).

2:  $z_0 = x_0$ .

3: **for**  $k = 0$  **to**  $K$

4:      $R_k = R_0 \cdot 2^{-k}$ ,

$$N_k = \max \left\{ \left\lceil \left( \frac{rc_p H 2^r}{\sigma_r} R_k^{p+1-r} \right)^{\frac{2}{3p+1}} \right\rceil, 1 \right\}. \quad (9)$$

5:      $z_{k+1} := y_{N_k}$ , где  $y_{N_k}$  – выход УМ( $z_k, f, g, p, H, N_k$ ).

6: **end for**

7: **return**  $z_K$

---

$F(y_k) - F(x_*) \leq \varepsilon$  будем:

$$N = \tilde{O} \left( \left( \frac{H R^{p+1-r}}{\sigma_r} \right)^{\frac{2}{3p+1}} \right),$$

где  $\tilde{O}()$  – означает то же самое, что  $O()$  с точностью до множителя  $\ln(\varepsilon^{-1})$ .

Все что было сказано после Теоремы 1 можно отметить и в данном случае.

### 3 Приложения

#### 3.1 Ускоренные методы композитной оптимизации

Если не думать о сложности решения подзадачи (4), например, считать, что  $g$  какая-то простая функция и (4) решается по явным формулам (как, например, для задачи LASSO), то УМ описывает класс ускоренных методов

(1, 2, 3, ... порядка) композитной оптимизации [1, 2, 6]. При этом функция  $g$  не обязана быть гладкой. В общем случае в строчке 5 Алгоритма 1 под  $\nabla g(y_{k+1})$  следует понимать такой субградиент функции  $g$  в точке  $y_{k+1}$ , с которым субградиент правой части (4) равен (близок) к нулю (немного переписав метод, от последнего ограничения можно отказаться). Отметим, что при  $p = 1$  необходимость в поиске параметра  $\lambda_{k+1}$  исчезает, что делает метод заметно проще.

### 3.2 Ускоренные проксимальные методы. Каталист

Если, считать  $p = 1$ , а  $f \equiv 0$ ,  $H > 0$  то получится ускоренный проксимальный метод. Отличительная особенность такого метода (см. также [16]) от других известных ускоренных проксимальных методов заключается в том, что не требуется очень точно решать вспомогательную задачу. Критерий (8) и сильная (2-равномерная) выпуклость вспомогательной подзадачи (4) указывают на то, что сложность решения (8) может не зависеть от желаемой точности решения исходной задачи  $\varepsilon$ . Таким образом, не теряется логарифмический множитель при использовании такой проксимальной оболочки для ускорения различных неускоренных процедур. Собственно, последнее направление получило название Каталист [4]. До настоящего момента идея (Каталист) использования ускоренной проксимальной оболочки для ‘обертывания’ неускоренных методов, решающих вспомогательную задачу (4) на каждой итерации (при должном выборе параметра  $H$ ), являлась наиболее общей идеей разработки ускоренных методов для разных задач. Мы получаем Каталист просто как частный случай УМ. Примеры использования Каталист будут приведены в п. 3.4.

### 3.3 Разделение оракульных сложностей

Если считать, что для  $g$  имеем  $L_{p,g} < \infty$  (см. (2)) и на вспомогательную задачу (4) смотреть как на равномерно выпуклую достаточно гладкую задачу (с  $f := g$ ,  $g(x) := \Omega_p(f, \tilde{x}_k; x) + \frac{(p+1)L_{p,f}}{(p+1)!} \|x - \tilde{x}_k\|^{p+1}$ ), то для решения (4), в свою очередь, можно использовать Рестартованный УМ с  $H \simeq (p+1)L_{p,g}$ . В случае, когда  $L_{p,f} \leq L_{p,g}$  удается получить такие оценки сложности [11, 3] (см. Теорему 1):

$$N_f = \tilde{O} \left( \left( \frac{L_{p,f} R^{p+1}}{\varepsilon} \right)^{\frac{2}{3p+1}} \right) \text{ — число вызовов оракула для функции } f,$$

$$N_g = \tilde{O} \left( \left( \frac{L_{p,g} R^{p+1}}{\varepsilon} \right)^{\frac{2}{3p+1}} \right) \text{ — число вызовов оракула для функции } g.$$

Вызов оракула подразумевает вычисление (старших) производных до порядка  $p$  включительно. Таким образом, число вызовов оракула для каждой из функции  $f, g$  является квазиоптимальным, т.е. оптимальным с точностью до логарифмического (от желаемой точности по функции) множителя. Аналогичные оценки можно получить и в  $r$ -равномерно ( $r \geq 2$ ) выпуклом случае, см. п. 3.4.

Заметим, что при  $p = 1$  внутреннюю задачу (4) не обязательно решать Рестартованным УМ. Можно использовать (ускоренные) покомпонентные и безградиентные методы, методы редукции дисперсии [1, 3, 20]. Причем ускорение можно получить из базовых неускоренных вариантов этих методов с помощью УМ (см. п. 3.2). По сравнению с оболочкой, использованной в [10], УМ дает оценку сложности на логарифмический множитель лучше. Это следует из теоретического анализа и было подтверждено в экспериментах [21].

### 3.4 Ускоренные методы для седловых задач

Следуя, например [9, 12], рассмотрим выпукло-вогнутую седловую задачу

$$\min_{x \in \mathbb{R}^{d_x}} \{F(x) := f(x) + \underbrace{\max_{y \in \mathbb{R}^{d_y}} \{G(x, y) - h(y)\}}_{g(x)=G(x,y^*(x))-h(y^*(x))}\}, \quad (10)$$

где  $y^*(x) = \arg \max_{y \in \mathbb{R}^{d_y}} \{G(x, y) - h(y)\}$ . Будем считать, что  $\nabla f, \nabla G, \nabla h$  являются, соответственно,  $L_f, L_G, L_h$ -Липшицевыми. Также будем считать, что  $f(x) + G(x, y) - h(y)$  – является  $\mu_x$ -сильно (2-равномерно) выпуклой по  $x$ , а  $G(x, y) - h(y)$  –  $\mu_y$ -сильно (2-равномерно) вогнутой по  $y$ . Тогда  $F(x)$  будет  $\mu_x$ -сильно выпуклой, а  $\nabla g$  будет  $L_g = (L_G + 2L_G^2/\mu_y)$ -Липшицевым [9, 12].

Если считать, что доступен  $\nabla g$ , то внешнюю задачу (10) можно решать ускоренным слайдингом (например, в варианте УМ с  $p = 1$ , см. п. 3.3) за  $\tilde{O}(\sqrt{L_f/\mu_x})$  вычислений  $\nabla f$  и  $\tilde{O}(\sqrt{L_g/\mu_x})$  вычислений  $\nabla g$ .

Чтобы приближенно посчитать  $\nabla g(x) = \nabla_x G(x, y^*(x))$  надо решить (с достаточной точностью) вспомогательную задачу в (10), т.е. найти с нужной точностью  $y^*(x)$ . Это, в свою очередь, также можно сделать с помощью слайдинга (УМ с  $p = 1$ ) за  $\tilde{O}(\sqrt{L_h/\mu_y})$  вычислений  $\nabla h$  и  $\tilde{O}(\sqrt{L_G/\mu_y})$  вычислений  $\nabla_y G$ .

Резюмируя написанное, получаем, что исходную задачу (10) можно решить за  $\tilde{O}(\sqrt{L_f/\mu_x})$  вычислений  $\nabla f$ ,  $\tilde{O}(\sqrt{L_g/\mu_x}) \simeq \tilde{O}(\sqrt{L_G^2/(\mu_x\mu_y)})$  вычислений  $\nabla_x G$ ,  $\tilde{O}(\sqrt{L_G^3/(\mu_x\mu_y^2)})$  вычислений  $\nabla_y G$ ,  $\tilde{O}(\sqrt{L_h L_G^2/(\mu_x\mu_y^2)})$  вычислений  $\nabla h$ . Поменяв порядок взятия  $\min$  и  $\max$  аналогичным образом можно прийти к оценкам  $\tilde{O}(\sqrt{L_h/\mu_y})$  вычислений  $\nabla h$ ,  $\tilde{O}(\sqrt{L_G^2/(\mu_x\mu_y)})$  вычислений  $\nabla_y G$ ,  $\tilde{O}(\sqrt{L_G^3/(\mu_x^2\mu_y)})$  вычислений  $\nabla_x G$ ,  $\tilde{O}(\sqrt{L_f L_G^2/(\mu_x^2\mu_y)})$  вычислений  $\nabla f$ .

Оценки полученные на число вычислений  $\nabla_x G$  и  $\nabla f$  в последнем случае не являются оптимальными [12]. Чтобы улучшить данные оценки (сделать

их оптимальными с точностью до логарифмических множителей [12]) воспользуемся Каталистом, см. п. 3.2 (УМ, с  $p = 1$ ,  $H \gg \mu_x$ ,  $f \equiv 0$ ,  $g = F$ , где  $F$  определяется (10)). Если параметр метода  $H$ , то число итераций метода будет  $\tilde{O}\left(\sqrt{H/\mu_x}\right)$ , см. теорему 2. На каждой итерации необходимо будет решать с нужной точностью задачу вида (10), в которой  $L_f := L_f + H$ ,  $\mu_x := \mu_x + H \simeq H$ . Таким образом, для решения внутренней седловой задачи потребуется  $\tilde{O}\left(\sqrt{L_h/\mu_y}\right)$  вычислений  $\nabla h$ ,  $\tilde{O}\left(\sqrt{L_G^2/(H\mu_y)}\right)$  вычислений  $\nabla_y G$ ,  $\tilde{O}\left(\sqrt{L_G^3/(H^2\mu_y)}\right)$  вычислений  $\nabla_x G$ ,  $\tilde{O}\left(\sqrt{(L_f + H)L_G^2/(H^2\mu_y)}\right)$  вычислений  $\nabla f$ . Считая для наглядности  $L_f \geq L_G$  выберем  $H = L_G$ . Тогда итоговые оценки на число вычислений соответствующих градиентов будут такие:  $\tilde{O}\left(\sqrt{L_h L_G/(\mu_x \mu_y)}\right)$  вычислений  $\nabla h$ ,  $\tilde{O}\left(\sqrt{L_G^2/(\mu_x \mu_y)}\right)$  вычислений  $\nabla_y G$ ,  $\tilde{O}\left(\sqrt{L_G^2/(\mu_x \mu_y)}\right)$  вычислений  $\nabla_x G$ ,  $\tilde{O}\left(\sqrt{L_f L_G/(\mu_x \mu_y)}\right)$  вычислений  $\nabla f$ .

За счет использования УМ приведенная выше схема улучшает похожую схему рассуждений из [12] на логарифмический (по желаемой точности решения задачи) множитель, и обобщает ее на случай отличных от тождественного нуля функций  $f$  и  $h$ .

Приведенная здесь схема рассуждений наглядно демонстрирует, как из одной универсальной схемы ускорения удается получить ('собрать как в конструкторе') оптимальный метод с точностью до логарифмического (по желаемой точности множителя) (при  $f \equiv 0$  и  $h \equiv 0$  – только при этих условиях известны нижние оценки [12]).

### 3.5 Сравнение с алгоритмом Монте́йро–Свайтера

Следуя [22], рассмотрим следующую задачу оптимизации:

$$\min_{x \in \mathbb{R}^n} \{ F(x) := \underbrace{\log \left( \sum_{k=1}^p \exp (\langle A_k, x \rangle) \right)}_{=f(x)} + \underbrace{\frac{1}{2} \|Gx\|_2^2}_{=g(x)} \},$$

где  $n = 500$ ,  $p = 20000$ ,  $A$  – разреженная  $p \times n$  матрица с коэффициентом разреженности 0.001 (под коэффициентом разреженности в данном случае понимается отношение числа ненулевых элементов матрицы к общему числу ее элементов), чьи ненулевые элементы есть независимые одинаково распределенные случайные величины из равномерного распределения  $\mathcal{U}(-1, 1)$ , а матрица  $G^2$  получается из следующего выражения:

$$G^2 = \sum_{i=1}^n \lambda_i \tilde{e}_i^\top \tilde{e}_i,$$

где  $\sum_{i=1}^n \lambda_i = 1$  и  $[\tilde{e}_i]_j \sim \mathcal{U}(1, 2)$  для каждой пары  $i, j$ .

Здесь  $f$  имеет липшицев градиент с константой Липшица

$$L_f = \max_{i=1,\dots,n} \|A^{(k)}\|_2^2,$$

где за  $A^{(k)}$  обозначен  $k$ -й столбец матрицы  $A$ .

На примере данной задачи сравним работу ускоренных методов, полученных с помощью алгоритма Монте́йро–Свайтера [7] ( $L = 20L_f$ ) и с помощью УМ ( $H = L_f$ ) при использовании для решения вспомогательной задачи покомпонентного градиентного метода Нестерова (ПГМ) [23] ( $\beta = 1/2$ ).

На рис. 1 покомпонентный метод, ускоренный с помощью алгоритма Монте́йро–Свайтера, сравнивается с методом, ускоренным оболочкой УМ с различным числом итераций метода для решения вспомогательной задачи ( $K_{\text{внутр}} = k$  соответствует  $kn$  итерациям покомпонентного метода), и

быстрым градиентным методом (БГМ). Представлен трехмерный график зависимости величины  $(F(x_k) - F(x^*))/(F(x_0) - F(x^*))$  (в лог масштабе,  $F(x^*)$  выбирается равным значению  $F$  в точке, полученной после 2500 итераций БГМ) от числа вычислений компонент градиентов  $\nabla f_i$  и  $\nabla g_i$ , а также его двухмерные проекции. Так как некоторые методы требуют вычисления полного значения градиента ( $\nabla f$  или  $\nabla g$ ), обращения к оракулам, в таком случае, учитываются с весом  $t_1/t_2 \approx 2.5$ , где  $t_1$  — среднее время вычисления полного градиента,  $t_2$  — среднее время вычисления одной компоненты. Как можно видеть из графиков, число обращений к оракулу  $\nabla f_i$  ускоренного с помощью оболочки УМ метода меньше, чем у быстрого градиентного метода. Кроме того, оболочка УМ позволяет значительно сократить число обращений к оракулу  $\nabla g_i$  по сравнению с алгоритмом Монтейро–Свайтера.

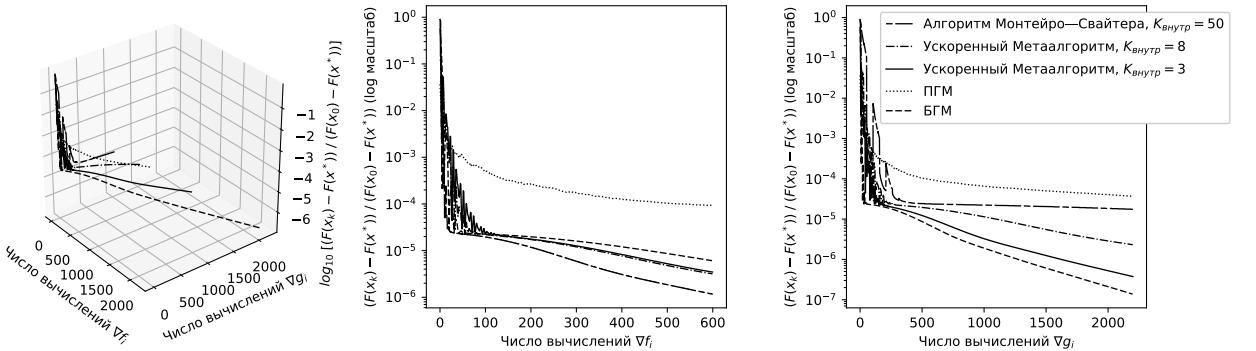


Рис. 1: График зависимости величины  $(F(x_k) - F(x^*))/(F(x_0) - F(x^*))$  (в лог масштабе) от числа вычислений компонент градиентов  $\nabla f_i$  и  $\nabla g_i$ . Двухмерные проекции

На рис. 2 сравнивается работа методов в зависимости от времени работы и числа итераций внутреннего метода. Как можно видеть из графика 2а, ускоренный с помощью оболочки УМ метод сходится по времени работы с большей скоростью, чем метод, ускоренный с помощью алгоритма Монтейро–Свайтера, а также с большей скоростью, чем быстрый гради-

ентный метод.

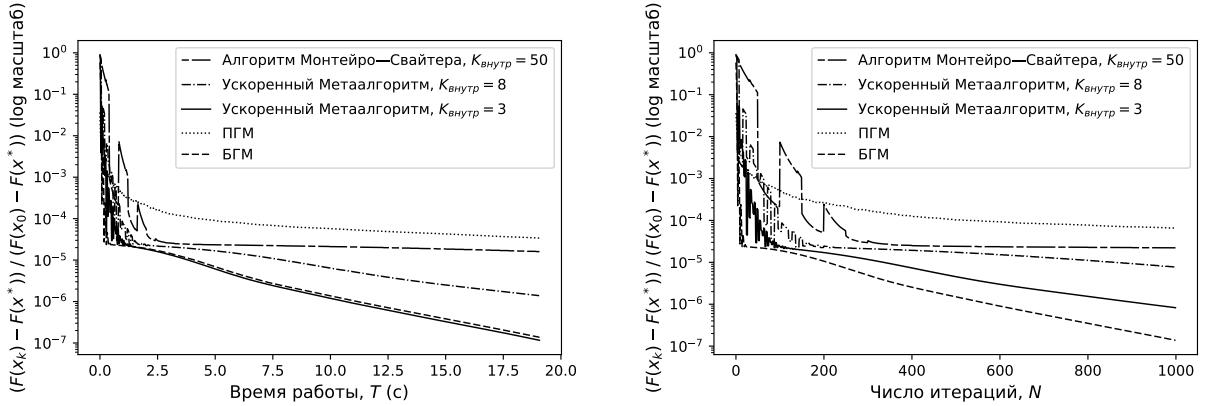


Рис. 2: Графики зависимости величины  $(F(x_k) - F(x^*))/((F(x_0) - F(x^*))$  (в log масштабе) от времени работы и числа итераций внутреннего метода

## 4 Возможные обобщения

Приводимые выше конструкции существенным образом базируются на том, что рассматриваются задачи безусловной оптимизации и используется евклидова норма. На данный момент открытым остается вопрос о перенесении приведенных в статье результатов на задачи безусловной оптимизации с заменой евклидовой нормы на дивергенцию Брэгмана [1, 5]. Тем более открытым остается вопрос об использовании других (более общих) моделей в построении мажорант целевой функции (3) [1].

В работе [24] было подмечено (в том числе и в модельной общности), что для получения оптимальных версий ускоренных алгоритмов для задач стохастической оптимизации нужно уметь оценивать как накапливается малый шум в градиенте в таких методах. Таким образом строятся ускоренные стохастические градиентные методы на базе ускоренных не стохастических (детерминированных) и конструкций, названной минибатчингом (замена градиента в детерминированном методе его оценкой, построенной на

базе стохастических градиентов). Насколько нам известно, для тензорных методов вопрос построения ускоренных методов для задач стохастической оптимизации остается открытым. В частности, не известен ответ на такой вопрос: верно ли, что для задач сильно выпуклой стохастической оптимизации требования к точности аппроксимации старших производных с помощью минибатчинга снижаются по мере роста порядка производных, как это имеет место в невыпуклом случае [25]? Для ответа на этот вопрос для тензорных методов также как и для градиентных  $p = 1$  может пригодиться анализ чувствительности исследуемых методов к неточности в вычислении производных. Некоторый задел в этом направлении уже имеется [26]. В частности, при  $p = 1$  УМ демонстрирует стандартное для ускоренных методов накопление неточностей в градиенте [24].

Из статьи может показаться, что для безусловных достаточно гладких задач выпуклой оптимизации предлагаемый в статье подход дает возможность всегда строить «оптимальные» методы. На самом деле это не совсем так. Во-первых, построение оптимальных методов даже на базе одного только УМ может быть совсем не простой задачей, как показывает пример из п. 3.4. Во-вторых, оговорка «с точностью до логарифмических множителей» весьма существенна. В частности, до сих пор остается открытым вопрос о том, устраним ли логарифмический мультипликативный зазор (по желаемой точности решения задачи по функции) между нижними оценками и тем, что дает УМ и другие ускоренные тензорные методы ( $p \geq 2$ ), см. Теорему 1. В-третьих, упомянутые нижние оценки были получены для класса Крыловских методов (для тензорных методов чуть хитрее [17]), однако предлагаемая оболочка УМ в некоторых вариантах ее использования, в том числе в проксимальном варианте (Каталист), см. п. 3.2, выводит из класса допустимых методов, для которого были получены нижние оценки.

Работа А.В. Гасникова поддержана грантом РФФИ 18-31-20005 мол\_а\_вед в п. 2, работа Д.И. Камзолова поддержана грантом РФФИ 19-31-90170 Аспиранты в п. 3, работа П.Е. Двуреченского поддержана грантом РФФИ 18-29-03071 мк в п. 3. Работа Д.М. Двинских и В.В. Матюхина была выполнена при поддержке Министерства науки и высшего образования Российской Федерации (госзадание) №075-00337-20-03, номер проекта 0714-2020-0005.

# Список литературы

- [1] Гасников А.В. Современные численные методы оптимизации. Метод универсального градиентного спуска. М.: МФТИ, 2018.
- [2] Nesterov Yu. Lectures on convex optimization. Vol. 137. Berlin, Germany: Springer, 2018.
- [3] Lan G. Lectures on optimization. Methods for Machine Learning // <https://pwp.gatech.edu/guanghui-lan/publications/>
- [4] Lin H., Mairal J., Harchaoui Z. Catalyst acceleration for first-order convex optimization: from theory to practice // The Journal of Machine Learning Research. – 2017. – V. 18. – No. 1. – P. 7854-7907.
- [5] Doikov N., Nesterov Yu. Contracting proximal methods for smooth convex optimization // arXiv:1912.07972.
- [6] Gasnikov A., Dvurechensky P., Gorbunov E., Vorontsova E., Selikhanovich D., Uribe C.A., Jiang B., Wang H., Zhang S., Bubeck S. and Jiang Q. Near Optimal Methods for Minimizing Convex Functions with Lipschitz  $p$ -th Derivatives // Proceedings of the Thirty-Second Conference on Learning Theory. – 2019. – P. 1392–1393.
- [7] Monteiro R.D.C., Svaiter B.F. An accelerated hybrid proximal extragradient method for convex optimization and its implications to second-order methods // SIAM Journal on Optimization. – 2013. – V. 23. – №. 2. – P. 1092-1125.
- [8] Nesterov Yu. Inexact Accelerated High-Order Proximal-Point Methods // CORE Discussion paper 2020/8.

- [9] *Alkousa, M., Dvinskikh, D., Stonyakin, F. and Gasnikov, A.*  
 Accelerated methods for composite non-bilinear saddle point problem //  
 arXiv:1906.03620.
- [10] *Ianova A., Gasnikov A., Dvurechensky P., Dvinskikh D., Tyurin A., Vorontsova E., Pasechnyuk D.* Oracle Complexity Separation in Convex Optimization // arXiv:2002.02706
- [11] *Kamzolov D., Gasnikov A., Dvurechensky P.* On the optimal combination of tensor optimization methods // arXiv:2002.01004
- [12] *Lin T., Jin C., Jordan M.* Near-optimal algorithms for minimax optimization // arXiv:2002.02417.
- [13] *Gasnikov, A., Dvurechensky, P., Gorbunov, E., Vorontsova, E., Selikhanovych, D. and Uribe, C.A.* Optimal Tensor Methods in Smooth Convex and Uniformly ConvexOptimization // Proceedings of the Thirty-Second Conference on Learning Theory. – 2019. – P. 1374–1391.
- [14] *Bubeck, S., Jiang, Q., Lee, Y.T., Li, Y. and Sidford, A.* Near-optimal method for highly smooth convex optimization // Proceedings of the Thirty-Second Conference on Learning Theory. – 2019. – P. 492–507.
- [15] *Jiang, B., Wang, H. and Zhang, S.* An optimal high-order tensor method for convex optimization // Proceedings of the Thirty-Second Conference on Learning Theory. – 2019. – P. 1799–1801.
- [16] *Ianova A., Grishchenko D., Gasnikov A., Shulgin E.* Adaptive Catalyst for smooth convex optimization // arXiv:1911.11271
- [17] *Nesterov Yu.* Implementable tensor methods in unconstrained convex optimization // Mathematical Programming. – 2019. – P. 1-27.

- [18] Kamzolov D. and Gasnikov A. Near-Optimal Hyperfast Second-Order Method for convex optimization and its Sliding// arXiv:2002.09050
- [19] Grapiglia G.N., Nesterov Yu. On inexact solution of auxiliary problems in tensor methods for convex optimization // arXiv:1907.13023
- [20] Dvurechensky P., Gasnikov A., Tiurin A. Randomized Similar Triangles Method: A unifying framework for accelerated randomized optimization methods (Coordinate Descent, Directional Search, Derivative-Free Method) // arXiv:1707.08486
- [21] Ссылка: исходный код экспериментов на GitHub <https://github.com/dmivilensky/composite-accelerated-method>
- [22] Spokoiny V., Panov M. Accuracy of Gaussian approximation in nonparametric Bernstein–von Mises Theorem //arXiv preprint arXiv:1910.06028. – 2019.
- [23] Nesterov Yu., Stich S. U. Efficiency of the accelerated coordinate descent method on structured optimization problems //SIAM Journal on Optimization. – 2017. – T. 27. – №. 1. – C. 110-123.
- [24] Dvinskikh, D., Tyurin, A., Gasnikov, A., and Omelchenko S. Accelerated and nonaccelerated stochastic gradient descent with model conception // arXiv:2001.03443
- [25] Lucchi A., Kohler J. A Stochastic Tensor Method for Non-convex Optimization // arXiv:1911.10367
- [26] Baes M. Estimate sequence methods: extensions and approximations // Institute for Operations Research, ETH, Zürich, Switzerland. – 2009.

## Приложение 1

В этом приложении представлено доказательство Теоремы 1, основанное на доказательстве из статьи [14], с учетом добавления композитной функции. Следующая теорема базируется на Теореме 2.1 из [14]

**Теорема 3.** Пусть  $(y_k)_{k \geq 1}$  — это последовательность точек в  $\mathbb{R}^d$ , и  $(\lambda_k)_{k \geq 1}$  — это последовательность в  $\mathbb{R}_+$ . Определим  $(a_k)_{k \geq 1}$  такой, что  $\lambda_k A_k = a_k^2$  и  $A_k = \sum_{i=1}^k a_i$ . Для любого  $k \geq 0$  определим  $x_k = x_0 - \sum_{i=1}^k a_i(\nabla f(y_i) + g'(y_i))$  и  $\tilde{x}_k := \frac{a_{k+1}}{A_{k+1}}x_k + \frac{A_k}{A_{k+1}}y_k$ . Также предположим, что если для некоторого  $\sigma \in [0, 1]$

$$\|y_{k+1} - (\tilde{x}_k - \lambda_{k+1}\nabla f(y_{k+1}))\| \leq \sigma \cdot \|y_{k+1} - \tilde{x}_k\|, \quad (11)$$

тогда для любого  $x \in \mathbb{R}^d$  верны неравенства:

$$F(y_k) - F(x) \leq \frac{2\|x\|^2}{\left(\sum_{i=1}^k \sqrt{\lambda_i}\right)^2},$$

и

$$\sum_{i=1}^k \frac{A_i}{\lambda_i} \|y_i - \tilde{x}_{i-1}\|^2 \leq \frac{\|x^*\|^2}{1 - \sigma^2}.$$

Для доказательства этой теоремы мы введем дополнительные леммы, основанные на леммах 2.2-2.5 и 3.1 из [14], леммы 2.6 и 3.3 могут использоваться без изменений.

**Лемма 1.** Пусть  $\psi_0(x) = \frac{1}{2}\|x - x_0\|^2$ , и по индукции определим  $\psi_k(x) = \psi_{k-1}(x) + a_k \Omega_1(F, y_k, x)$ , тогда  $x_k = x_0 - \sum_{i=1}^k a_i(\nabla f(y_i) + g'(y_i))$  — это минимизатор функции  $\psi_k$ , и верно  $\psi_k(x) \leq A_k F(x) + \frac{1}{2}\|x - x_0\|^2$ , где  $A_k = \sum_{i=1}^k a_i$ .

**Лемма 2.** Пусть  $z_k$  такая, что

$$\psi_k(x_k) - A_k F(z_k) \geq 0.$$

Тогда для любого  $x$ ,

$$F(z_k) \leq F(x) + \frac{\|x - x_0\|^2}{2A_k}.$$

*Доказательство.* Из Леммы 1) можно получить, что

$$A_k F(z_k) \leq \psi_k(x_k) \leq \psi_k(x) \leq A_k F(x) + \frac{1}{2} \|x - x_0\|^2.$$

□

**Лемма 3.** Для любого  $x$  верно следующее неравенство

$$\begin{aligned} & \psi_{k+1}(x) - A_{k+1} F(y_{k+1}) - (\psi_k(x_k) - A_k F(z_k)) \\ & \geq A_{k+1}(\nabla f(y_{k+1}) + g'(y_{k+1})) \cdot \left( \frac{a_{k+1}}{A_{k+1}} x + \frac{A_k}{A_{k+1}} z_k - y_{k+1} \right) + \frac{1}{2} \|x - x_k\|^2. \end{aligned}$$

*Доказательство.* Во-первых, простыми вычислениями получим

$$\psi_k(x) = \psi_k(x_k) + \frac{1}{2} \|x - x_k\|^2,$$

и

$$\psi_{k+1}(x) = \psi_k(x_k) + \frac{1}{2} \|x - x_k\|^2 + a_{k+1} \Omega_1(f, y_{k+1}, x),$$

таким образом

$$\psi_{k+1}(x) - \psi_k(x_k) = a_{k+1} \Omega_1(F, y_{k+1}, x) + \frac{1}{2} \|x - x_k\|^2. \quad (12)$$

Теперь мы хотим, чтобы  $A_{k+1} F(z_{k+1}) - A_k F(z_k)$  было нижней оценкой неравенства (12), когда вычисляем  $x = x_{k+1}$ . Используя  $\Omega_1(F, y_{k+1}, z_k) \leq f(z_k)$ , мы получаем:

$$\begin{aligned} & a_{k+1} \Omega_1(F, y_{k+1}, x) = A_{k+1} \Omega_1(F, y_{k+1}, x) - A_k \Omega_1(F, y_{k+1}, x) \\ & = A_{k+1} \Omega_1(F, y_{k+1}, x) - A_k \nabla F(y_{k+1}) \cdot (x - z_k) - A_k \Omega_1(F, y_{k+1}, z_k) \\ & = A_{k+1} \Omega_1\left(F, y_{k+1}, x - \frac{A_k}{A_{k+1}}(x - z_k)\right) - A_k \Omega_1(F, y_{k+1}, z_k) \\ & \geq A_{k+1} F(y_{k+1}) - A_k F(z_k) \\ & \quad + A_{k+1}(\nabla f(y_{k+1}) + g'(y_{k+1})) \cdot \left( \frac{a_{k+1}}{A_{k+1}} x + \frac{A_k}{A_{k+1}} z_k - y_{k+1} \right), \end{aligned}$$

что завершает доказательство.  $\square$

**Лемма 4.** Обозначим  $\lambda_{k+1} := \frac{a_{k+1}^2}{A_{k+1}}$  и  $\tilde{x}_k := \frac{a_{k+1}}{A_{k+1}}x_k + \frac{A_k}{A_{k+1}}y_k$ , и получим:

$$\begin{aligned} & \psi_{k+1}(x_{k+1}) - A_{k+1}F(y_{k+1}) - (\psi_k(x_k) - A_kF(y_k)) \\ & \geq \frac{A_{k+1}}{2\lambda_{k+1}} \left( \|y_{k+1} - \tilde{x}_k\|^2 - \|y_{k+1} - (\tilde{x}_k - \lambda_{k+1}(\nabla f(y_{k+1})) + g'(y_{k+1}))\|^2 \right). \end{aligned}$$

А применив дополнительно неравенство (11), получаем

$$\psi_k(x_k) - A_kF(y_k) \geq \frac{1 - \sigma^2}{2} \sum_{i=1}^k \frac{A_i}{\lambda_i} \|y_i - \tilde{x}_{i-1}\|^2.$$

*Доказательство.* Используем Лемму 3 при  $z_k = y_k$  и  $x = x_{k+1}$  и получим, что (при  $\tilde{x} := \frac{a_{k+1}}{A_{k+1}}x + \frac{A_k}{A_{k+1}}y_k$ ):

$$\begin{aligned} & (\nabla f(y_{k+1}) + g'(y_{k+1})) \cdot \left( \frac{a_{k+1}}{A_{k+1}}x + \frac{A_k}{A_{k+1}}y_k - y_{k+1} \right) + \frac{1}{2A_{k+1}} \|x - x_k\|^2 \\ & = (\nabla f(y_{k+1}) + g'(y_{k+1})) \cdot (\tilde{x} - y_{k+1}) + \frac{1}{2A_{k+1}} \left\| \frac{A_{k+1}}{a_{k+1}} \left( \tilde{x} - \frac{A_k}{A_{k+1}}y_k \right) - x_k \right\|^2 \\ & = (\nabla f(y_{k+1}) + g'(y_{k+1})) \cdot (\tilde{x} - y_{k+1}) + \frac{A_{k+1}}{2a_{k+1}^2} \left\| \tilde{x} - \left( \frac{a_{k+1}}{A_k}x_k + \frac{A_k}{A_{k+1}}y_k \right) \right\|^2. \end{aligned}$$

Откуда следует следующее неравенство:

$$\begin{aligned} & \psi_{k+1}(x_{k+1}) - A_{k+1}F(y_{k+1}) - (\psi_k(x_k) - A_kF(y_k)) \\ & \geq A_{k+1} \cdot \min_{x \in \mathbb{R}^d} \left\{ (\nabla f(y_{k+1}) + g'(y_{k+1})) \cdot (x - y_{k+1}) + \frac{1}{2\lambda_{k+1}} \|x - \tilde{x}_k\|^2 \right\}. \end{aligned}$$

Значение минимума можно легко посчитать.  $\square$

Для первого выражения Теоремы 3 достаточно объединить Лемму 4 с Леммой 2 и Леммой 2.5 из [14]. Второе выражение в Теореме 3 следует из Леммы 4 и Леммы 1.

Следующая лемма доказывает, что минимизация ряда Тэйлора порядка  $p$  для (4) может быть представлено, как неявный градиентный шаг для некоторого большого размера шага.

**Лемма 5.** Неравенство (11) верно при  $\sigma = 1/2$  для (4), из этого следует, что:

$$\frac{1}{2} \leq \lambda_{k+1} \frac{L_p \cdot \|y_{k+1} - \tilde{x}_k\|^{p-1}}{(p-1)!} \leq \frac{p}{p+1}. \quad (13)$$

*Доказательство.* Из условия оптимальности следует, что

$$\nabla_y f_p(y_{k+1}, \tilde{x}_k) + \frac{L_p \cdot (p+1)}{p!} (y_{k+1} - \tilde{x}_k) \|y_{k+1} - \tilde{x}_k\|^{p-1} + g'(y_{k+1}) = 0. \quad (14)$$

Откуда следует

$$\begin{aligned} y_{k+1} - (\tilde{x}_k - \lambda_{k+1}(\nabla f(y_{k+1}) + g'(y_{k+1}))) &= \lambda_{k+1}(\nabla f(y_{k+1}) + g'(y_{k+1})) \\ &- \frac{p!}{L_p \cdot (p+1) \cdot \|y_{k+1} - \tilde{x}_k\|^{p-1}} (\nabla_y f_p(y_{k+1}, \tilde{x}_k) + g'(y_{k+1})). \end{aligned}$$

Используя ряд Тэйлора для градиента функции получаем:

$$\|\nabla f(y) - \nabla_y f_p(y, x)\| \leq \frac{L_p}{p!} \|y - x\|^p,$$

таким образом

$$\begin{aligned} &\|y_{k+1} - (\tilde{x}_k - \lambda_{k+1}(\nabla f(y_{k+1}) + g'(y_{k+1})))\| \\ &\leq \lambda_{k+1} \frac{L_p}{p!} \|y_{k+1} - \tilde{x}_k\|^p \\ &+ \left| \lambda_{k+1} - \frac{p!}{L_p \cdot (p+1) \cdot \|y_{k+1} - \tilde{x}_k\|^{p-1}} \right| \cdot \|\nabla_y f_p(y_{k+1}, \tilde{x}_k) + g'(y_{k+1})\| \\ &\leq \|y_{k+1} - \tilde{x}_k\| \\ &\cdot \left( \lambda_{k+1} \frac{L_p}{p!} \|y_{k+1} - \tilde{x}_k\|^{p-1} + \left| \lambda_{k+1} \frac{L_p \cdot (p+1) \cdot \|y_{k+1} - \tilde{x}_k\|^{p-1}}{p!} - 1 \right| \right) \\ &= \|y_{k+1} - \tilde{x}_k\| \left( \frac{\eta}{p} + \left| \eta \cdot \frac{p+1}{p} - 1 \right| \right), \end{aligned}$$

где мы используем (14) во втором неравенстве, и предполагаем

$\eta := \lambda_{k+1} \frac{L_p \cdot \|y_{k+1} - \tilde{x}_k\|^{p-1}}{(p-1)!}$  в последнем равенстве. Итоговый результат получаем из предположения, что  $1/2 \leq \eta \leq p/(p+1)$  в (13).  $\square$

В заключении, если мы заменим  $\|x^*\|$  на  $\|x_0 - x^*\|$  в Лемме 3.3 и используем Лемму 3.4 из [14], то мы получаем доказательство Теоремы 1.

## Приложение 2

В данной секции мы докажем Теорему 2.

*Доказательство.* Так как функция  $F$  является  $r$ -равномерно выпуклой, то мы получаем

$$\begin{aligned} R_{k+1} = \|z_{k+1} - x_*\| &\leq \left( \frac{r(F(z_{k+1}) - F(x_*))}{\sigma_r} \right)^{\frac{1}{r}} \stackrel{(5)}{\leq} \left( \frac{r \left( \frac{c_p L_p R_k^{p+1}}{N_k^{\frac{3p+1}{2}}} \right)}{\sigma_r} \right)^{\frac{1}{r}} \\ &= \left( \frac{rc_p L_p R_k^{p+1}}{\sigma_r N_k^{\frac{3p+1}{2}}} \right)^{\frac{1}{r}} \stackrel{(9)}{\leq} \left( \frac{R_k^{p+1}}{2^r R_k^{p+1-r}} \right)^{\frac{1}{r}} = \frac{R_k}{2}. \end{aligned}$$

Теперь вычислим общее число шагов метода 1.

$$\begin{aligned} \sum_{k=0}^K N_k &\leq \sum_{k=0}^K \left( \frac{rc_p L_p 2^r}{\sigma_r} R_k^{p+1-r} \right)^{\frac{2}{3p+1}} + K \\ &= \sum_{k=0}^K \left( \frac{rc_p L_p 2^r}{\sigma_r} (R_0 2^{-k})^{p+1-r} \right)^{\frac{2}{3p+1}} + K \\ &= \left( \frac{rc_p L_p 2^r R_0^{p+1-r}}{\sigma_r} \right)^{\frac{2}{3p+1}} \sum_{k=0}^K 2^{\frac{-2(p+1-r)k}{3p+1}} + K. \end{aligned}$$

□