

УДК 519.244.4, 519.245

# АДАПТИВНЫЕ АЛГОРИТМЫ ИНЕРЦИОННОГО ЗЕРКАЛЬНОГО СПУСКА В ВЫПУКЛЫХ ЗАДАЧАХ СТОХАСТИЧЕСКОЙ ОПТИМИЗАЦИИ

**А.В. Назин**

*Институт проблем управления им. В.А. Трапезникова РАН*

Россия, 117997, Москва, Профсоюзная ул., 65

E-mail: [nazine@ipu.ru](mailto:nazine@ipu.ru)

**Ключевые слова:** задачи стохастической оптимизации, выпуклая оптимизация, метод зеркального спуска, инерционный зеркальный спуск, адаптивные алгоритмы.

**Аннотация:** Рассматривается задача минимизации математического ожидания неизвестной выпуклой функции потерь  $f(x)$  на заданном выпуклом компакте  $X \in \mathbb{R}^N$ , причем оракул последовательно выдает стохастические субградиенты  $\partial_x f(x_k)$  в указываемых пользователем точках  $x_k \in X$ . Цель состоит в адаптивной модификации метода инерционного зеркального спуска (ИЗС), предложенного в [1], близкого к детерминированным субградиентным методам с двойным усреднением [2]. Описывается адаптивный алгоритм ИЗС, доказывается теорема о верхней границе на ошибку по целевой функции, то есть на разницу текущего значения средних потерь и минимума. Проводится сравнение с неадаптивным алгоритмом ИЗС.

## 1. Введение

Метод зеркального спуска (МЗС) [3] относится к прямо-двойственным методам выпуклой оптимизации градиентного типа, в которых используется как прямое, так и двойственное пространство: текущие наблюдения субградиента целевой функции формируют траекторию в двойственном пространстве, и эта траектория отображается в заданное множество исходного пространства, на котором и проводится оптимизация. Указанное отображение является функциональным параметром и наряду с другими параметрами позволяет не только контролировать, но и в какой-то степени минимизировать верхнюю границу ошибки относительно целевой функции. При этом обычно предполагается известным ограничение на норму вектора наблюдений субградиента функции. В частном случае, когда оба пространства евклидовы, а отображение двойственного пространства на заданный выпуклый компакт соответствует метрической проекции, МЗС совпадает со стандартным методом проекции градиента. В общем же случае МЗС обладает дополнительными степенями свободы, и их правильное использование может иногда существенно расширить возможности метода даже в условиях большой размерности [3,4]. Отметим, что подавляющее большинство работ по МЗС относится к получению гарантированной верхней границы ошибки на

всем классе рассматриваемой задачи оптимизации, когда последовательности параметров метода определены априори и не меняются в процессе наблюдений градиента и итеративного оценивания оптимальной точки. Известны и адаптивные алгоритмы зеркального спуска (АЗС); см., например, [5], [6] и указанные там ссылки. В настоящем докладе этот подход развивается для достаточно общей постановки, причем представлены адаптивные АЗС с инерцией [1]. В целом АЗС с инерцией интересны тем, в частности, что потенциально позволяют использовать их структуру для построения алгоритмов управления как статических, так и динамических объектов [2]. Кроме того, отметим, что условие на ограничение нормы вектора наблюдения субградиента здесь несколько более жесткое, чем это делается в неадаптивных работах по МЗС, но позволяет уточнить верхнюю границу по целевой функции за счет учета точных значений норм текущих субградиентов, а не их верхней оценки.

## 2. Обозначения и определения [4]

Пусть  $E$  — пространство  $\mathbb{R}^n$ , оснащенное нормой  $\|\zeta\|$  (не обязательно евклидовой), где вектор  $\zeta = (\zeta^{(1)}, \dots, \zeta^{(n)})^T \in E$ ; тогда двойственное пространство  $E^*$  представляет собой  $\mathbb{R}^n$ , оснащенное нормой

$$\|\zeta\|_* = \max_{x \in E: \|x\| \leq 1} \zeta^T x, \quad \forall \zeta \in E^*.$$

Пусть  $X$  — выпуклое замкнутое подмножество в  $E$ , параметр (обобщенная температура)  $\beta > 0$ , а функция  $V : X \rightarrow \mathbb{R}_+$  выпуклая. Назовем  $\beta$ -сопряженной функцией к  $V$  преобразование типа Лежандра–Фенхеля  $W_\beta$  от произведения  $\beta V$ , а именно:

$$W_\beta(\zeta) = \sup_{x \in X} \{-\zeta^T x - \beta V(x)\}, \quad \forall \zeta \in E^*.$$

Введем важное предположение, представляющее собой следующее условие Липшица в сопряженных нормах  $\|\cdot\|$  и  $\|\cdot\|_*$ .

**Предположение (L).** *Выпуклая функция  $V : X \rightarrow \mathbb{R}_+$  такова, что ее  $\beta$ -сопряженная  $W_\beta$  непрерывно дифференцируема на  $E^*$  с градиентом  $\nabla W_\beta$ , удовлетворяющим неравенству*

$$\|\nabla W_\beta(\zeta) - \nabla W_\beta(\zeta')\| \leq \frac{1}{\alpha\beta} \|\zeta - \zeta'\|_*, \quad \forall \zeta, \zeta' \in E^*, \beta > 0,$$

где постоянная  $\alpha > 0$  не зависит от  $\beta$ .

Известно [4], что предположение (L) связано с условием  $\alpha$ -сильной выпуклости функции  $V$  относительно исходной нормы  $\|\cdot\|$ , причем

$$(1) \quad \operatorname{argmax}_{x \in X} \{-\zeta^T x - \beta V(x)\} = -\nabla W_\beta(\zeta) \in X, \quad \forall \zeta \in E^*.$$

Такую функцию  $V$  с  $\min_{x \in X} V(x) = 0$  называем прокси-функцией.

## 3. Постановка задачи

Рассмотрим задачу стохастической минимизации неизвестной функции

$$(2) \quad f(x) = \mathbb{E}Q(x, Z), \quad x \in X,$$

где  $X$  — известное выпуклое замкнутое множество в  $\mathbb{R}^n$ ,  $n$  — натуральное число,  $Z$  — случайная величина, принимающая значения в некотором множестве  $\mathcal{Z}$ , функция потерь  $Q : X \times \mathcal{Z} \rightarrow \mathbb{R}_+$  такова, что случайная функция  $Q(\cdot, Z)$  выпукла для почти всех  $Z$ ,  $\mathbb{E}$  — полное математическое ожидание. Пусть обучающая выборка  $Z_1, \dots, Z_t$  представляет собой последовательность независимых случайных величин  $Z_k$  с одним и тем же неизвестным распределением, что и  $Z$ . Цель состоит в критериальной минимизации функции  $f(x)$  на  $X$  [7]. Это означает, что качество любой допустимой оценки  $x_t = x_t(Z_1, \dots, Z_t) \in X$ ,  $t \geq 1$ , к которой обращается оракул на шаге  $t$ , характеризуется разностью

$$(3) \quad \mathbb{E}f(x_t) - \min_{x \in X} f(x),$$

причем минимум в (3) достижим. Формирование конкретной оценки должно гарантировать по возможности «малую» величину разности (3) на заданном классе функций  $f$ . По сути, речь идет о гарантируемой критериальной скорости сходимости на классе рассматриваемых задач оптимизации. Отметим, что предложенный в [1] неадаптивный алгоритм ИЗС обеспечивает такую верхнюю оценку (см. ниже).

Далее, пусть определены стохастические субградиенты

$$(4) \quad u_k(x) = \partial_x Q(x, Z_k), \quad k = 1, 2, \dots,$$

то есть измеримые на  $X$  функции, что при каждом  $x \in X$  математическое ожидание  $\mathbb{E}u_k(x)$  принадлежит субдифференциалу  $\mathcal{D}f(x)$ . Наконец, будем предполагать наличие оракула первого порядка, то есть на каждом шаге  $k = 1, 2, \dots$  при любом значении  $x_{k-1} \in X$  наблюдается субградиент  $u_k(x_{k-1})$  в силу (4).

## 4. Неадаптивный алгоритм ИЗС и верхняя граница

Для начала рассмотрим алгоритм ИЗС [1], представляющий собой рекуррентную процедуру оптимизации, которая осуществляет градиентный спуск в двойственном пространстве  $E^*$  с отображением траектории в исходное пространство  $E$  и дополнительным инерциальным членом. На каждом шаге  $k$  рассматривается двойственная переменная  $\zeta_k$ , определяемая стохастическими субградиентами  $u_i(x_{i-1})$ ,  $i = 1, \dots, k$ , а исходная переменная представляет собой «зеркальное отображение»  $\zeta_k$  в  $E$  с текущим усреднением. Для настройки алгоритма используется две положительные последовательности:  $\gamma_k$  — «размер шага», и  $\beta_k$  — «обобщенная температура», причем  $\beta_k \geq \beta_{k-1}$ ,  $\forall k \geq 1$ . Алгоритм определяется следующим образом:

1) при  $k = 0$  задаются начальные значения  $\zeta_0 = 0$  и  $x_0 = -\nabla W_{\beta_0}(\zeta_0)$ ;

2) для  $k = 1, \dots, t$  выполняется рекуррентный пересчет

$$(5) \quad \zeta_k = \zeta_{k-1} + \gamma_k u_k(x_{k-1}),$$

$$(6) \quad x_k = x_{k-1} - \frac{1}{k+1} (x_{k-1} + \nabla W_{\beta_k}(\zeta_k)).$$

Выбираем параметры  $\gamma_k$  и  $\beta_k$  независимые от наблюдений субградиентов:

$$(7) \quad \gamma_k \equiv 1, \quad \beta_k = \beta_0 \sqrt{1+k}, \quad k \geq 1;$$

**Теорема 1.** Пусть  $X$  — выпуклое замкнутое подмножество в  $\mathbb{R}^n$ , а функция потерь  $Q(\cdot, \cdot)$  удовлетворяет условиям, приведенным в разделе 3, и, кроме того,

$$(8) \quad \sup_{x \in X} \mathbb{E} \|\partial_x Q(x, Z)\|_*^2 \leq L_{X,Q}^2,$$

где постоянная  $L_{X,Q} \in (0, \infty)$ . Пусть  $V$  — прокси-функция на  $X$  с параметром  $\alpha > 0$  из предположения 1, и пусть существует  $x^* \in \operatorname{Argmin}_{x \in X} f(x)$ . Тогда для любого целого  $t \geq 1$  оценка  $x_t$ , определенная алгоритмом (5), (6) со стохастическими субградиентами (4) и параметрами  $\gamma_k$  и  $\beta_k$  из (7) с произвольным  $\beta_0 > 0$ , удовлетворяет неравенству

$$\mathbb{E} f(x_t) - \min_{x \in X} f(x) \leq \left( \beta_0 V(x^*) + \frac{L_{X,Q}^2}{\alpha \beta_0} \right) \frac{\sqrt{t+2}}{t+1}.$$

Если, кроме того,  $\bar{V}$  — постоянная, такая что  $V(x^*) \leq \bar{V}$ , и при известном  $L_{X,Q}$  выбираем  $\beta_0 = L_{X,Q} (\alpha \bar{V})^{-1/2}$ , то

$$(9) \quad \mathbb{E} f(x_t) - \min_{x \in X} f(x) \leq 2 L_{X,Q} (\alpha^{-1} \bar{V})^{1/2} \frac{\sqrt{t+2}}{t+1}.$$

В частности, можно взять  $\bar{V} = \max_{x \in X} V(x)$ .

**Доказательство теоремы 1.** Приводится в [1].

## 5. Адаптивный алгоритм ИЗС и основной результат

В отличие от предыдущего алгоритма (5), (6) (при  $\gamma_k \equiv 1$ ) добавляется рекуррентный пересчет последовательности  $\beta_k$ , использующий на каждом шаге  $\|\cdot\|_*$ -норму наблюдаемого субградиента:

$$(10) \quad \beta_k = \sqrt{\beta_{k-1}^2 + (\alpha \bar{V})^{-1} \|u_k(x_{k-1})\|_*^2}, \quad k \geq 1.$$

Начальные значения  $\zeta_0 = 0$  и  $x_0 = -\nabla W_{\beta_0}(\zeta_0)$  выбираются теми же, что и в неадаптивном алгоритме ИЗС, а  $\beta_0$  указывается ниже, в условиях теоремы 2.

**Теорема 2.** Пусть в условиях теоремы 1 выполняется предположение

$$(11) \quad \sup_{x \in X} \|\partial_x Q(x, Z)\|_* \leq L_{X,Q} \quad \text{н.н.}$$

и используется оценка  $x_t$  из алгоритма (5), (6) и (10) со стохастическими субградиентами из (4) и  $\beta_0 = L_{X,Q} (2\alpha \bar{V})^{-1/2}$ . Тогда для любого целого  $t \geq 1$

$$(12) \quad \mathbb{E} f(x_t) - \min_{x \in X} f(x) \leq \frac{2}{t} (\alpha^{-1} \bar{V})^{1/2} \mathbb{E} \sqrt{0.5 L_{X,Q}^2 + \sum_{k=1}^t \|u_k(x_{k-1})\|_*^2} \leq$$

$$(13) \quad \leq 2 (\alpha^{-1} \bar{V})^{1/2} \frac{\sqrt{t+0.5}}{t},$$

где  $\bar{V} \geq V(x^*)$ ; если  $X$  — выпуклый компакт, то можно положить  $\bar{V} = \max_{x \in X} V(x)$ .

**Доказательство теоремы 2.** Запишем (П.1) в [1] следующим образом:

$$(14) \quad \begin{aligned} \mathbb{E} \left[ \sum_{i=1}^t (f(x_{i-1}) - f(x)) + \sum_{i=1}^t \tau_{i-1} (f(x_{i-1}) - f(x_{i-2})) \right] &\leq \\ &\leq \mathbb{E} \left[ \beta_t V(x) + \sum_{i=1}^t \frac{\|u_i(x_{i-1})\|_*^2}{2\alpha \beta_{i-1}} \right]. \end{aligned}$$

Аналогично [1] повторяем преобразование левой части (14). Теперь делим обе части на  $\tau_t = t$ , и при  $x = x^*$  получаем

$$(15) \quad \mathbb{E}[f(x_{t-1}) - f(x^*)] \leq \frac{\bar{V}}{t} \mathbb{E} \left[ \beta_t + \frac{1}{2} \sum_{i=1}^t \frac{\|u_i(x_{i-1})\|_*^2}{\alpha \bar{V} \beta_{i-1}} \right].$$

Обозначим  $c_k = (\alpha \bar{V})^{-1} \|u_i(x_{i-1})\|_*^2$ , и в силу (10) имеем  $\beta_t = \sqrt{\beta_0^2 + \sum_{k=1}^t c_k}$ . Суммируя по частям, получаем, с учетом монотонности  $\beta_k$ :

$$(16) \quad \begin{aligned} \sum_{i=1}^t \frac{\|u_i(x_{i-1})\|_*^2}{\alpha \bar{V} \beta_{i-1}} &= \sum_{i=1}^t \frac{c_i}{\beta_{i-1}} = \sum_{i=1}^t \frac{c_i}{\beta_i} + \sum_{i=1}^t c_i \left( \frac{1}{\beta_{i-1}} - \frac{1}{\beta_i} \right) \leq \\ &\leq \sum_{k=1}^t \frac{c_k}{\sqrt{\beta_0^2 + \sum_{i=1}^k c_i}} + \frac{\sup c_k}{\beta_0} \leq \int_0^{\sum_{i=1}^t c_i} \frac{dv}{\sqrt{\beta_0^2 + v}} + \frac{L_{X,Q}^2}{\alpha \bar{V} \beta_0}. \end{aligned}$$

Подставляя эту оценку сверху, приходим к

$$(17) \quad \begin{aligned} \mathbb{E}f(x_t) - \min_{x \in X} f(x) &\leq \frac{\bar{V}}{t} \mathbb{E} \left( 2\beta_t - \beta_0 + \frac{L_{X,Q}^2}{2\alpha \bar{V} \beta_0} \right) = \\ &= \frac{2}{t} (\alpha^{-1} \bar{V})^{1/2} \mathbb{E} \sqrt{0.5 L_{X,Q}^2 + \sum_{k=1}^t \|u_k(x_{k-1})\|_*^2} \leq 2L_{X,Q} (\alpha^{-1} \bar{V})^{1/2} \frac{\sqrt{t+0.5}}{t}. \end{aligned}$$

В последних соотношениях использованы выражение доказываемой теоремы для  $\beta_0$  и известная лемма Иенсена. Теорема доказана.

## 6. Заключение

Алгоритм ИЗС (5), (6) и (10) отличается от неадаптивной версии алгоритма (5)–(7) тем, что последовательность  $\beta_k$  в нем не определена априори, а формируется в соответствии с рекуррентной формулой (10). Сравнивая результаты, сформулированные в теоремах 1 и 2, можно видеть, что адаптивный ИЗС (5), (6) и (10), гарантируя ту же верхнюю границу ошибки (3) на всем классе рассматриваемых задач оптимизации, обеспечивает улучшенную верхнюю границу еще и за счет адаптивности. Некоторой платой за эту адаптивность является более жесткое условие (11) по сравнению с (8).

Работа поддержана грантом Российского научного фонда № 16–11–10015.

## Список литературы

1. Назин А.В. Алгоритмы инерционного зеркального спуска в выпуклых задачах стохастической оптимизации // Автоматика и телемеханика. 2018. № 1. С. 100–112.
2. Nesterov Yu., Shikhman V. Quasi-monotone Subgradient Methods for Nonsmooth Convex Minimization // Journal of Optimization Theory and Applications. 2015. Vol. 165, No. 3. P. 917–940.
3. Немировский А.С., Юдин Д.Б. Сложность задач и эффективность методов оптимизации. М.: Наука, 1979.
4. Юдицкий А.Б., Назин А.В., Цыбаков А.Б., Ваятис Н. Рекуррентное агрегирование оценок методом зеркального спуска с усреднением // Проблемы передачи информации. 2005. Т. 41, Вып. 4. С. 78–96.
5. Nazin A., Polyak B. Adaptive Randomized Algorithm for Finding Eigenvector of Stochastic Matrix with Application to PageRank // Proceedings of the Joint 48th IEEE Conference on Decision and Control and 28th Chinese Control Conference. Shanghai, P.R. China, December 16–18, 2009. P. 127–132. DOI: 10.1109/CDC.2009.5400036
6. Назин А.В. Адаптивные алгоритмы зеркального спуска в задачах выпуклой стохастической оптимизации // Труды ИСА РАН. 2014. Т. 64, № 3. С. 7–12.
7. Поляк Б.Т., Цыпкин Я.З. Критериальные алгоритмы стохастической оптимизации // Автоматика и телемеханика. 1984. № 6. С. 95–104.