

# Градиентные методы минимизации <sup>1</sup>

М. В. Балашов (ИПУ РАН, Москва, Россия)

balashov73@mail.ru

В работе обсуждается современное состояние дел в градиентных методах решения задач поиска минимума функции на множестве: методе проекции градиента и методе условного градиента. Будут сформулированы результаты о линейной сходимости для выпуклых задач, а также рассмотрены возможные обобщения этих результатов на невыпуклый случай.

*Ключевые слова:* Метод проекции градиента, метод условного градиента, сильная выпуклость, липшицев градиент, метрическая регулярность, негладкий анализ.

# Gradient minimization methods <sup>1</sup>

M. V. Balashov (ICS RAS, Moscow, Russia)

balashov73@mail.ru

In the paper, we discuss the current state of arts in gradient methods for solving problems of finding the minimum of a function on a set: about the gradient projection method and about the conditional gradient method. Results on linear convergence for convex problems will be formulated, and possible generalizations of these results to the non-convex case will be considered.

*Keywords:* gradient projection method, conditional gradient method, strong convexity, Lipschitz continuous gradient, metric regularity, nonsmooth analysis.

## Введение

В  $\mathbb{R}^n$  через  $(x, y)$  обозначим скалярное произведение векторов  $x, y \in \mathbb{R}^n$  и соответствующую евклидову норму  $\|x\| = \sqrt{(x, x)}$ . Для функции  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  через  $f'(x)$  будем обозначать градиент Фреше  $f$  в точке  $x$ .

Рассмотрим задачу

$$f_0 = \min_{x \in \mathcal{Q}} f(x), \quad (1)$$

где  $\mathcal{Q} \subset \mathbb{R}^n$  замкнутое подмножество и  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  — функция с непрерывным по Липшицу градиентом. Через  $\Omega_0 \subset \mathcal{Q}$  будем обозначать непустое множество решений (1). Условие Липшица для градиента  $f'(x)$  достаточно требовать в некоторой равномерной окрестности множества  $\mathcal{Q}$ . Везде ниже мы будем предполагать, что решение по  $x$  задачи (1) существует, т.е.  $\Omega_0 \neq \emptyset$  и  $f_0 \in \mathbb{R}$ . Пусть  $P_{\mathcal{Q}}x$  — метрическая проекция точки  $x$  на множество  $\mathcal{Q}$  и  $\rho(x, \mathcal{Q})$  — расстояние от точки  $x$  до множества  $\mathcal{Q}$ .

---

<sup>1</sup>Статья опубликована на условиях лицензии Creative Commons Attribution 4.0 International (CC-BY 4.0)

<sup>1</sup>This is an open access article distributed under the terms of Creative Commons Attribution 4.0 International License (CC-BY 4.0)

В докладе будут обсуждаться условия линейной сходимости, т.е. сходимости со скоростью геометрической прогрессии со знаменателем  $< 1$ , метода проекции градиента

$$x_1 \in \mathcal{Q}, \quad x_{k+1} \in P_{\mathcal{Q}}(x_k - tf'(x_k)), \quad t > 0, \quad (2)$$

и метода условного градиента  $x_1 \in \mathcal{Q}$

$$z_k \in \operatorname{Arg} \max_{x \in \mathcal{Q}}(-f'(x_k), x), \quad x_{k+1} = (1 - t_k)x_k + t_k z_k, \quad t_k \in [0, 1]. \quad (3)$$

В частности, точку  $x_{k+1}$  по точкам  $x_k, z_k$  можно выбирать в алгоритме (3) по правилу

$$x_{k+1} \in \operatorname{Arg} \min_{x \in [x_k, z_k]} f(x). \quad (4)$$

Для простоты мы будем рассматривать ситуацию в  $\mathbb{R}^n$ , хотя большинство фактов легко переносится на случай вещественного гильбертова пространства.

## Общая ситуация. Монотонность алгоритмов. Выпуклый случай

Начнём с рассмотрения алгоритмов (2) и (3) для произвольного замкнутого множества  $\mathcal{Q}$  и достаточно произвольного вида функции  $f$ .

Напомним, что функция  $f : U \rightarrow \mathbb{R}$  слабо вогнута на выпуклом подмножестве  $U \subset \mathbb{R}^n$  с константой  $L_1 > 0$ , если функция  $h(x) = f(x) - \frac{L_1}{2} \|x\|^2$  вогнута (выпукла вверх) на  $U$ . Дифференцируемость функции  $f$  не предполагается. Супердифференциал Фреше функции  $f$  в точке  $x_0 \in U$  есть

$$\partial_F^+ f(x_0) = \left\{ p \in \mathbb{R}^n : \limsup_{x \rightarrow x_0} \frac{f(x) - f(x_0) - (p, x - x_0)}{\|x - x_0\|} \leq 0 \right\}.$$

Для слабо вогнутой с константой  $L_1$  функции  $f$  имеет место равенство [1, Proposition 1.107(i)]

$$\partial_F^+ f(x_0) = \partial^+ h(x_0) + L_1 x,$$

где  $\partial^+ h(x_0)$  супердифференциал вогнутой функции  $h$ . Будем говорить, что функция удовлетворяет условию верхней квадратичной аппроксимации с константой  $L_1$ , если

$$f(x) \leq f(x_0) + (f'(x_0), x - x_0) + \frac{L_1}{2} \|x - x_0\|^2, \quad \forall x_0, x, \quad \forall f'(x_0) \in \partial_F^+ f(x_0).$$

Из определения слабой вогнутости легко вытекает, что слабо вогнутая функция (и только слабо вогнутая функция) удовлетворяет условию верхней квадратичной аппроксимации с одной константой  $L_1$ .

**Лемма 1.** Пусть функция  $f : \mathbb{R}^n \rightarrow \mathbb{R}$  слабо вогнутая с константой  $L_1 > 0$ , множество  $\mathcal{Q}$  замкнуто,  $x_1 \in \mathcal{Q}$ ,  $t \in (0, \frac{1}{L_1})$ , суперградиент Фреше  $f'(x_1) \in \partial_F^+ f(x_1)$  и  $x_2 \in P_{\mathcal{Q}}(x_1 - tf'(x_1))$  произвольны. Тогда

$$f(x_1) - f(x_2) \geq \frac{1}{2} \left( \frac{1}{t} - L_1 \right) \|x_2 - x_1\|^2. \quad (5)$$

Заметим, что в лемме 1 множество  $\mathcal{Q}$ , как и функция  $f$ , не выпукло, поэтому проекция  $P_{\mathcal{Q}}(x_1 - tf'(x_1))$  вообще говоря не одноточечна.

*Доказательство.* Зафиксируем произвольным образом суперградиент Фреше  $f'(x_1) \in \partial_F^+ f(x_1)$ . Рассмотрим квадратичную функцию

$$\psi(x) = f(x_1) + (f'(x_1), x - x_1) + \frac{1}{2t} \|x - x_1\|^2.$$

В силу условия слабой вогнутости  $f$  с константой  $L_1$  выполнена квадратичная аппроксимация  $f$ , откуда для всякого  $x \in \mathbb{R}^n$  выполнена оценка

$$\psi(x) \geq f(x) + \frac{1}{2} \left( \frac{1}{t} - L_1 \right) \|x - x_1\|^2.$$

Для функции  $\psi(x)$  точка  $x_1 - tf'(x_1)$  является глобальным минимумом. Из того, что линии уровня  $\psi(x) = C$  — сферы с центром  $x_1 - tf'(x_1)$ , получаем  $\psi(x_2) \leq \psi(x_1)$ . Отсюда

$$f(x_1) = \psi(x_1) \geq \psi(x_2) \geq f(x_2) + \frac{1}{2} \left( \frac{1}{t} - L_1 \right) \|x_2 - x_1\|^2.$$

□

Аналогично, из условия верхней квадратичной аппроксимации в методе (3), для всякого для  $\varepsilon \in (0, 1)$  и  $t \in (\varepsilon, (2-\varepsilon)/L_1)$  найдётся константа  $C(\varepsilon) > 0$  такая, что [2, §6]

$$f(x_{k+1}) - f(x_k) \leq -C(\varepsilon) \min \left\{ (f'(x_k), x_k - z_k), \frac{(f'(x_k), x_k - z_k)^2}{\|x_k - z_k\|^2} \right\} \leq 0.$$

Таким образом, для слабо вогнутой функции алгоритм (3) также является строго монотонным.

В дальнейшем мы будем считать, что функция  $f$  имеет липшицев градиент с константой  $L_1$ . Известно, что такие функции слабо вогнутые с той же константой  $L_1$  [3, теорема 2.1.2]. Приведённые результаты гарантирует монотонность алгоритма для такой функции.

При условии липшицевой дифференцируемости и выпуклости (выпуклости вниз)  $f$ , а также выпуклости и компактности множества  $\mathcal{Q}$ , оценка в алгоритмах (2) и (3) по функции имеет вид

$$f(x_k) - f_0 \leq \frac{C}{k}$$

для некоторой константы  $C > 0$ , зависящей от  $f$  и  $\mathcal{Q}$  [2]. Пример функций  $f_m(x) = x^{2m}$ ,  $m \in \mathbb{N}$ , в задаче  $\min_{x \in \mathbb{R}^n} f_m(x)$  (с очевидным решением  $x_0 = 0$ ) показывает, что скорость сходимости  $\|x_k - x_0\|$  в методе градиентного спуска может быть сколь угодно медленной. Аналогичный пример можно привести для алгоритма (3).

## Градиентный спуск в случае $\mathcal{Q} = \mathbb{R}^n$

Будем говорить, что функция  $f: \mathbb{R}^n \rightarrow \mathbb{R}$  удовлетворяет *условию Лежанского-Поляка-Лоясевича (условию LPL)* [4], если  $f$  дифференцируема по Фреше, множество  $\Omega_0 = \text{Arg min}_{x \in \mathbb{R}^n} f(x)$  ее глобальных минимумов непусто и существует такая константа  $\mu > 0$ , что для всех  $x \in \mathbb{R}^n$

$$\|f'(x)\|^2 \geq \mu(f(x) - f(x_0)) \quad \forall x_0 \in \Omega_0. \quad (6)$$

Совместно с формулой (5) леммы 1 для липшицево дифференцируемой функции  $f$ , удовлетворяющей условию (6), получаем для шага  $0 < t < 1/L_2$

$$f(x_k) - f(x_{k+1}) \geq \frac{1}{2} \left( \frac{1}{t} - L_1 \right) \|tf'(x_k)\|^2 \geq \frac{\mu}{2} (t - t^2 L_1) (f(x_k) - f_0),$$

и для  $q = q(\mu, t) = \frac{\mu}{2} (t - t^2 L_1)$  и  $\varphi_k = f(x_k) - f_0$  имеем

$$\varphi_k - \varphi_{k+1} \geq q\varphi_k, \quad \varphi_{k+1} \leq (1 - q)\varphi_k,$$

т.е. получаем линейную сходимость  $\{\varphi_k\}$  к нулю. По точке

$$\|x_{k+1} - x_k\|^2 = t^2 \|f'(x_k)\|^2 \leq \frac{\varphi_k}{\frac{1}{2}(\frac{1}{t} - L_1)}$$

также получаем линейную сходимость.

Отметим, что сильно выпуклая с константой  $\varkappa > 0$  функция (т.е. такая функция  $f$ , что функция  $f(x) - \frac{\varkappa}{2}\|x\|^2$  выпуклая вниз) удовлетворяет условию в духе (LPL) вида

$$\|p\|^2 \geq \varkappa(f(x) - f_0) \quad \forall p \in \partial f(x),$$

где  $\partial f(x) = \{p \in \mathbb{R}^n : f(z) \geq f(x) + (p, z - x), \quad \forall z \in \mathbb{R}^n\}$  есть субдифференциал функции  $f$  в точке  $x$  (дифференцируемость  $f$  не предполагается). Существуют также невыпуклые функции, удовлетворяющие условию (LPL). В градиентном спуске можно эффективно применять шаг Армихо, для вычисления которого не нужно знание констант.

## Минимизация на многообразиях

Рассмотрим частный случай задачи (1), когда множество  $\mathcal{Q}$  является гладким компактным многообразием без края, а функция  $f$  является вещественно-аналитической, т.е. для каждой точки найдётся окрестность, где функция представима некоторым сходящимся степенным рядом. Тогда для всякой точки  $x \in \mathcal{Q}$  найдётся  $\delta > 0$ ,  $\alpha \in (1, 2]$  и  $\mu > 0$  такие, что для всякого  $y \in \mathcal{Q}$ ,  $\|y - x\| \leq \delta$ , выполнено неравенство в духе неравенства Лоясевича [5, Proposition 2.2]

$$\mu|f(y) - f(x)| \leq \|P_{T_y} f'(y)\|^\alpha, \quad (7)$$

где  $T_y$  — касательное подпространство в точке  $y \in \mathcal{Q}$  к многообразию  $\mathcal{Q}$ .

Компактное гладкое многообразие без края является проксимально гладким с некоторой константой  $R > 0$  [3, теорема 1.19.1]. Последнее эквивалентно тому, что для всякого  $r \in (0, R)$  и точек  $x_0, x_1 \in \mathbb{R}^n$ ,  $0 < \varrho(x_i, \mathcal{Q}) < r$ ,  $i = 0, 1$ , выполнено условие Липшица  $\|P_{\mathcal{Q}}x_0 - P_{\mathcal{Q}}x_1\| \leq \frac{R}{R-r}\|x_0 - x_1\|$  [6]. Напомним, что основные матричные многообразия: Штифеля (матрицы  $X \in \mathbb{R}^{n \times k}$ :  $X^T X = I_{k \times k}$ ), Грассмана (может быть реализовано как множество проекторов  $XX^T$ , где  $X \in \mathbb{R}^{n \times k}$  — матрица многообразия Штифеля) и т.д. проксимально гладкие; многообразие Штифеля с константой  $R = 1$ , а многообразие Грассмана с  $R = 1/\sqrt{2}$  для всех  $n, k$ ,  $k \leq n$ . Существуют эффективные формулы для проектирования точки (матрицы) на матричные многообразия через сингулярное разложение матриц [7, 8]. Можно также доказать, что аналогом формулы (5) для двух последовательных шагов метода проекции градиента (2), который принимает вид  $x_{k+1} = P_S(x_k - tP_{T_{x_k}} f'(x_k))$ , на гладком и проксимально гладком многообразии является неравенство [9, Theorem 2]

$$f(x_{k+1}) - f(x_k) \leq -\|P_{T_{x_k}} f'(x_k)\|^2 \left( t - t^2 \left( \frac{L}{R} + \frac{L_1}{2} \right) \right), \quad (8)$$

где  $L$  и  $L_1$  — константы Липшица  $f$  и  $f'$  соответственно, а  $R$  — константа проксимальной гладкости  $S$ . Формулы (7) и (8) аналогично случаю безусловной минимизации дают линейную сходимость указанного алгоритма к локальному минимуму с сублинейной скоростью при  $\alpha < 2$  и с линейной скоростью при  $\alpha = 2$  [10]. Возможно эффективно применять шаг Армихо [8].

## Общая ситуация

Нестеров и др. доказали [11], что если в задаче (1) с выпуклой и липшицево дифференцируемой функцией  $f$  и выпуклым компактным множеством  $\mathcal{Q}$  выполнено условие квадратичного роста

$$\exists \nu > 0 \quad f(x) - f_0 \geq \nu \varrho^2(x, \Omega_0) \quad \forall x \in \mathcal{Q}, \quad (9)$$

то алгоритм (2) с достаточно малым фиксированным шагом  $t > 0$  сходится к решению (1) с линейной скоростью. Про алгоритм (3) давно известно [2], что для его линейной сходимости достаточно неравенство  $\inf_{x \in \mathcal{Q}} \|f'(x)\| > 0$  и условие сильной выпуклости множества  $\mathcal{Q}$  с радиусом  $R > 0$ , т.е.  $\mathcal{Q} = \bigcap_{x \in X} B_R(x)$  есть пересечение замкнутых евклидовых шаров  $B_R(x)$  для некоторого  $R > 0$  и произвольного множества центров шаров  $X \subset \mathbb{R}^n$ . В работе [12] было отмечено, что для линейной сходимости достаточно, чтобы условие сильной выпуклости выполнялось локально, в точке-решении  $x_0 \in \mathcal{Q}$  множество  $\mathcal{Q}$  должно иметь локальный модуль выпуклости второго порядка.

Кроме того, известно, что если в задаче (1) функция (м.б. невыпуклая) имеет липшицев градиент с константой  $L_1 > 0$ , множество  $\mathcal{Q}$  сильно выпукло с радиусом  $R > 0$  и  $\|f'(x)\| \geq m > 0$  при всех  $x \in \mathcal{Q}$ , то при условии  $\frac{RL_1}{m} < 1$  алгоритм (3) сходится при выборе  $x_{k+1} = z_k$ . Этот результат и некоторые его уточнения могут быть найдены в [4]. Мы также рекомендуем недавний обзор [13], посвященный методу условного градиента.

При попытке отказа от выпуклости мы встречаемся с определенными трудностями. Так, условие (9) не является в общем случае достаточным для сходимости алгоритма (2) в невыпуклом случае, т.к. могут существовать локальные экстремумы. Про алгоритм (3) автору не известны какие-либо условия его сходимости с невыпуклым множеством  $\mathcal{Q}$ .

Для решения ряда задач вида (1) в выпуклом и невыпуклом случае мы планируем обсудить опорное условие сильной выпуклости для компактного и в общем случае невыпуклого множества  $\mathcal{Q}$  [14]. Опорное условие для компактного множества  $\mathcal{Q}$  определяется направлением




Рис. 1: Ближайшие точки множеств  $\mathcal{R}(3)$  (множество справа) и  $\mathcal{M}$  (множество слева), разный ракурс. Решается задача  $\min_{\|p\|=1} s(p, \mathcal{R}(3) + (-\mathcal{M}))$ .

единичного вектора  $p \in \mathbb{R}^n$  и радиусом  $R$  и означает, что

$$\mathcal{Q} \subset B_R(\mathcal{Q}(p) - Rp), \quad \mathcal{Q}(p) = \arg \max_{x \in \mathcal{Q}} \langle p, x \rangle. \quad (10)$$

Оказывается, что это условие и некоторое соотношение констант достаточно для сходимости ряда алгоритмов вида (2) и (3) с  $x_{k+1} = z_k$ .

Приведём пример, см. рис. 1. Рассмотрим в  $\mathbb{R}^3$  множество достижимости  $\mathcal{R}(t) = \int_0^t e^{As} U ds$  для  $t = 3$ ,  $U = [-e_3, e_3]$ . Матрица  $A$  имеет вид жордановой клетки  $3 \times 3$  с собственным значением  $\lambda = -1.3$ , а  $\mathcal{M}$  есть сумма Минковского некоторых двух эллипсоидов. Ниже в таблице 1 приведена скорость сходимости опорной функции  $f(p) = s(p, \mathcal{R}(3) + (-\mathcal{M}))$  к минимуму (т.е.  $f(p_k) - f_0 \leq Cq^k$ ) в алгоритме (2) при  $\mathcal{Q} = \{p \in \mathbb{R}^n : \|p\| = 1\}$  для разных шагов  $t$ . При  $t > 0.4$  алгоритм может разойтись.

Таблица 1: Скорость линейной сходимости

Шаг $t$	0.05	0.1	0.15	0.2	0.25	0.3	0.35
Показатель $q$	0.914	0.829	0.744	0.660	0.574	0.633	0.862

## СПИСОК ЛИТЕРАТУРЫ

- [1] *Mordukhovich B.S.* Variational Analysis and Generalized Differentiation I: Basic Theory. Berlin: Springer, 2005.
- [2] *Левитин Е.С., Поляк В.Т.* Методы минимизации при наличии ограничений // Ж. выч. матем. и матем. ф. 1966. Т. 6. № 5. С. 787–823.
- [3] *Иванов Г.Е.* Слабо выпуклые функции и множества. М.: Физматлит, 2006.
- [4] *Balashov M. V., Polyak B. T., Tremba A. A.* Gradient Projection and Conditional Gradient Methods for Constrained Nonconvex Minimization // Numerical Functional Analysis and Optimization. 2020 V. 41. №7. P. 822–849.
- [5] *Schneider R., Uschmaev A.* Convergence results for projected line-search methods on varieties of low-rank matrices via Lojasiewicz inequality // SIAM J. Opt. 2015. V. 25. № 1. P. 622–646.
- [6] *Vial J.-P.* Strong and weak convexity of sets and functions // Mathematics of Operations Research. 1983. Vol. 8. No. 2. P. 231–259.
- [7] *Балашов М.В.* Метод проекции градиента на матричных многообразиях // Ж. выч. матем. и матем. ф. 2020. Т. 60. № 9. С. 1453–1461.
- [8] *Балашов М.В., Камалов Р. А.* Метод проекции градиента с шагом Армихо на многообразиях // Ж. выч. матем. и матем. ф. 2021. Т. 61. № 11. С. 1814–1824.
- [9] *Balashov M. V.* The gradient projection algorithm for smooth sets and functions in nonconvex case // Set-Valued Var. Anal. 2021. V. 29. P. 341–360.
- [10] *Balashov M. V.* The Lezanski – Polyak – Lojasiewicz inequality and the convergence of the gradient projection algorithm // Известия Саратовского университета. Новая серия. Серия: Математика. Механика. Информатика. 2023. Т. 23. Вып. 1. С. 4–10.
- [11] *Necoara I., Nesterov Yu., Glineur F.* Linear convergence of first order methods for non-strongly convex optimization // Math. Prog. Series A. 2019. Vol. 175. No. 1–2. P. 69–107.
- [12] *Veliov V.M.* On the convexity of integrals of multivalued mappings: application in control theory // J. of Opt. Theory and Appl. 1987. Vol. 54. No. 3. P. 541–563.
- [13] *Braun G., Carderera A., Combettes C.W., Hassani H., Karbasi A., Mokhtari A., Pokutta S.* Conditional gradient methods // arXiv:2211.14103v1. 2022.
- [14] *Балашов М.В.* Достаточные условия линейной сходимости одного алгоритма для нахождения метрической проекции точки на выпуклый компакт // Матем. зам. 2023. Т. 113. № 5. С. 655–666.