

Исследования вариаций субградиентного метода на классе слабо выпуклых задач

Есения Андреевна Лушко

Физтех-школа прикладной математики и информатики, МФТИ
научный руководитель: Федор Сергеевич Стонякин

23 мая, 2023

Актуальность и смежные задачи

- ① Хорошо изучено, что субградиентные методы в сравнении с ускоренными субградиентными методами на классе выпуклых гладких функций являются более устойчивыми к погрешностям.¹
- ② Современные исследования показывают, что для невыпуклых задач, есть нижняя оценка на область сходимости.²

Цель исследования – сделать подобные результаты на классе слабо выпуклых задач с острым минимумом, т.к. они возникают в различных приложениях.³

¹ Devolder, O., Glineur, F. Nesterov, Y.: First-order methods of smooth convex optimization with inexact oracle. // Math. Program. 146, 37–75 (2014).

² Fedor Stonyakin, Ilya Kuruzov, Boris Polyak: Stopping rules for gradient methods for non-convex problems with additive noise in gradient

³ Damek Davis and Dmitriy Drusvyatskiy and Courtney Paquette: The nonsmooth landscape of phase retrieval // IMA Journal of Numerical Analysis – 2020, Vol. 40, P. 2652–2695

Теорема 1. Оценка сходимости субградиентного метода для слабо выпуклых функций с острым минимумом ⁴

Пусть f μ -слабо выпукла и имеет α -острый минимум ($\alpha, \mu > 0$), а точка $x_0 : \min_{x_* \in X_*} \|x_0 - x_*\|_2 \leq \frac{\alpha\gamma}{\mu}$ для некоторого фиксированного $\gamma \in (0; 1)$. Тогда для метода

$$x_{k+1} := \text{Proj}_Q(x_k - h_k \nabla f(x_k)), \quad k = 0, 1, 2, \dots,$$

$$\text{где } h_k := \frac{f(x_k) - f_*}{\|\nabla f(x_k)\|_2^2} \text{ (при } \nabla f(x_k) \neq 0),$$

верно неравенство

$$\min_{x_* \in X_*} \|x_{k+1} - x_*\|_2^2 \leq \prod_{i=0}^k \left(1 - \frac{\alpha^2(1-\gamma)}{\|\nabla f(x_i)\|_2^2}\right) \min_{x_* \in X_*} \|x_0 - x_*\|_2^2,$$

⁴Davis, D., Drusvyatskiy, D., MacPhee, K.J. et al. Subgradient Methods for Sharp Weakly Convex Functions. J Optim Theory Appl 179, 962–982 (2018).

Постановка задачи

Выделяются две вариации метода:

- ① На каждом шаге метода доступен субградиент целевой функции с аддитивной неточностью:

$$\left\| \tilde{\nabla} f(x_k) - \nabla f(x_k) \right\|_2 \leq \Delta,$$

где Δ положительно, но достаточно мало.

- ② На каждом шаге погрешность присутствует как для значения целевой функции, так и для значения субградиента:

$$\left\| \tilde{\nabla} f(x_k) - \nabla f(x_k) \right\|_2 \leq \Delta, \quad \left| \widetilde{f(x_k)} - f(x_k) \right| \leq \delta,$$

где $\delta, \Delta > 0$, но достаточно малые.

Анализ метода с неточной информацией о субградиенте

Пусть функция f μ -слабо выпукла, M -липшицева и имеет α -острый минимум ($\alpha, \mu > 0$). Пусть начальная точка удовлетворяет условию:

$$\|x_0 - x_*\|_2 \leq \frac{\alpha}{2\mu\sqrt{2}},$$

Тогда субградиентный метод с шагом Б.Т.Поляка:

$$x_{k+1} := \text{Proj}_Q \left(x_k - h_k \tilde{\nabla} f(x_k) \right), \quad k = 0, 1, 2, \dots,$$

при наличии неточной информации значения субградента на каждом шаге $\left(\left\| \tilde{\nabla} f(x_k) - \nabla f(x_k) \right\|_2 \leq \Delta \right)$ сходится и в худшем случае можно гарантировать

$$\|x_k - x_*\|_2^2 = O(\Delta^{2-\frac{2}{\lambda}})$$

для достаточно большого k .

Клиппинг для случая с неточным оракулом в субградиенте⁵

(a) Если $\|\tilde{\nabla}f(x_k)\|_2 \leq M\sqrt{\Delta}$, то $h_k = \frac{f(x_k) - f_*}{M^2}$ и:

$$x_{k+1} := \text{Proj}_Q \left(x_k - \frac{f(x_k) - f_*}{M^2} \cdot \tilde{\nabla}f(x_k) \right)$$

(b) Если $\|\tilde{\nabla}f(x_k)\|_2 > M\sqrt{\Delta}$, то $h_k = \frac{f(x_k) - f_*}{\|\tilde{\nabla}f(x_k)\|_2^2}$ и:

$$x_{k+1} := \text{Proj}_Q \left(x_k - \frac{f(x_k) - f_*}{\|\tilde{\nabla}f(x_k)\|_2^2} \tilde{\nabla}f(x_k) \right)$$

⁵Why gradient clipping accelerates training: a theoretical justification for adaptivity

Случай малой нормы субградиента:

$$\|x_{k+1} - x_*\|_2^2 \leq \|x_0 - x_*\|_2^2 \left(1 - \frac{\alpha^2}{M^2} \cdot \frac{\sqrt{2}-1}{\sqrt{2}}\right)^{k+1} + \frac{\Delta^2}{2\mu\alpha(1-\sqrt{2})} \times \\ \times \left(\left(1 - \frac{\alpha^2}{M^2} \cdot \frac{\sqrt{2}-1}{\sqrt{2}}\right)^{k+1} - 1\right)$$

Итого, после k итераций в данном сценарии гарантируется, что

$$\|x_{k+1} - x_*\|_2^2 = O(\Delta^2)$$

Случай большой нормы субградиента:

$$\|x_{k+1} - x_*\|_2^2 \leq \|x_0 - x_*\|_2^2 \prod_{i=0}^{k+1} \left(1 - \frac{\alpha^2}{\|\tilde{\nabla}f(x_k)\|_2^2} \cdot \frac{\sqrt{2}-1}{\sqrt{2}}\right) + \frac{\Delta^{2-\frac{2}{\lambda}} M}{2\mu\alpha(1-\sqrt{2})} \times \\ \times \left(\left(1 - \frac{\alpha^2}{M^2} \cdot \frac{\sqrt{2}-1}{\sqrt{2}}\right)^{k+1} - 1\right)$$

Итого, после k итераций в данном сценарии гарантируется, что

$$\|x_{k+1} - x_*\|_2^2 = O(\Delta^{2-\frac{2}{\lambda}})$$

Постановка задачи для второго сценария

Пусть теперь у нас тот же класс функций, тот же субградиентный метод с шагом Б.Т. Поляка. При наличии в такой постановке погрешности в целевой функции и субградиенте

$\|\widetilde{\nabla}f(x_k) - \nabla f(x_k)\|_2 \leq \Delta$, $|\widetilde{f(x_k)} - f(x_k)| \leq \delta$, где $\delta, \Delta > 0$, но достаточно малые, что выполнено $\alpha^2 - 2\Delta\alpha \geq \frac{\alpha^2}{\sqrt{2}}$, то верно, что в худшем случае можно гарантировать

$$\|x_k - x_*\|_2^2 = O\left(\delta^{1-\frac{1}{\lambda}}\right)$$

для достаточно большого k , если на начальную точку наложить условие $\|x_0 - x_*\|_2 \leq \frac{\alpha}{2\mu\sqrt{2}}$.

Анализ значения погрешности целевой функции

Выделяются две вариации значения погрешности:

- 1 Значение целевой функции меньше реального:

$$f(x_k) - f_* \geq \widetilde{f}(x_k) - f_*$$

-
- 2 Значение целевой функции больше реального:

$$f(x_k) - f_* < \widetilde{f}(x_k) - f_*$$

Формально, это просто значит, что

$$\left| \widetilde{f}(x_k) - f(x_k) \right| \leq \delta,$$

раскрывается с разными знаками. Здесь $\delta > 0$, но достаточно мало.

Следствие при $\delta = 0$.

$$\min_{x_* \in X_*} \|x_{k+1} - x_*\|_2^2 \leq \prod_{i=0}^k \left(1 - \frac{\frac{\alpha^2}{2} - 2\Delta\alpha}{\|\tilde{\nabla}f(x_k)\|_2^2} \right) \|x_0 - x_*\|_2^2$$

Теперь гарантируется сходимость к точному минимуму со скоростью геометрической прогрессии. Этот результат улучшает уже имеющийся результат для данного сценария, хоть и делает дополнительные предположения.

Клиппинг для сценария с погрешностью в субградиенте и целевой функции

Пусть $\|\tilde{\nabla}f(x_k)\|_2 \leq M\sqrt[\lambda]{\delta}$. Тогда $h_k = \frac{f(x_k) - f_*}{M^2}$ и невязку можно переписать как:

$$\|x_{k+1} - x_*\|_2^2 \leq \|x_k - x_*\|_2^2 \left(1 - \frac{\alpha^2 - 2\Delta\alpha - \frac{\alpha^2}{\sqrt{2}}}{M^2}\right) + \frac{\delta\alpha^2}{M^2\mu\sqrt{2}}$$

Пусть $\|\tilde{\nabla}f(x_k)\|_2 > M\sqrt[\lambda]{\delta}$. Тогда $h_k = \frac{f(x_k) - f_*}{\|\tilde{\nabla}f(x_k)\|_2^2}$ и невязку можно переписать как:

$$\|x_{k+1} - x_*\|_2^2 \leq \|x_k - x_*\|_2^2 \left(1 - \frac{\alpha^2 - 2\Delta\alpha - \frac{\alpha^2}{\sqrt{2}}}{\|\tilde{\nabla}f(x_k)\|_2^2}\right) + \frac{\delta^{1-\frac{1}{\lambda}}\alpha^2}{M^2\mu\sqrt{2}}$$

Итоги для сценария с погрешностью в субградиенте и целевой функции

Итого, можно гарантировать окрестность сходимости:

$$\|x_k - x_*\|_2^2 = O(\delta^{1-\frac{1}{\lambda}})$$

Спасибо за внимание!