

УДК 519.853.62

УСКОРЕННЫЙ ГРАДИЕНТНЫЙ СЛАЙДИНГ-МЕТОД В ЗАДАЧАХ МИНИМИЗАЦИИ СУММЫ ФУНКЦИЙ

© 2020 г. Д. М. Двинских¹, С. С. Омельченко^{2,*}, А. В. Гасников^{1,**}, А. И. Тюрин³

Представлено академиком РАН Ю.Г. Евтушенко 10.03.2020 г.

Поступило 20.03.2020 г.

После доработки 26.03.2020 г.

Принято к публикации 03.04.2020 г.

Предложен новый способ обоснования ускоренного градиентного слайдинга Дж. Лана, позволяющий распространить технику слайдинга на сочетание ускоренных градиентных методов с ускоренными методами редукции дисперсии. Получены новые оптимальные оценки для решения задач минимизации суммы гладких сильно выпуклых функций с гладким регуляризатором.

Ключевые слова: ускоренный градиентный слайдинг Дж. Лана, ускоренные методы редукции дисперсии, гладкие сильно выпуклые функции

DOI: 10.31857/S268695432003008X

Многие задачи анализа данных (машинного обучения) приводят к необходимости решения задач минимизации функции вида суммы (эмпирический риск) с большим числом слагаемых, отвечающих объему выборки [1, 4, 14, 15]. В последнее десятилетие активно развиваются численные методы оптимизации функции вида суммы [1, 4, 6, 9]. В частности, были получены оптимальные методы (ускоренные методы редукции дисперсии) для такого класса задач, когда слагаемые в сумме – гладкие (сильно) выпуклые функции, см., например, [9]. Были исследованы задачи, в которых дополнительно в минимизируемую функцию вносится аддитивно, возможно, негладкий, но выпуклый/сильно выпуклый композитный член (по терминологии анализа данных вносится слагаемое, отвечающее “регуляризации”), являющийся проксимально дружественным [1, 10], т.е. задача минимизации такого члена с квадратичной добавкой – простая задача. В настоящей работе предлагается способ получения оптимальных оценок для случая, когда композит-

ный член будет выпуклым (сильно выпуклым) гладким, но уже не будет проксимально дружественным. Не предполагается проксимальная ответственность и у слагаемых в сумме.

В разделе 1 техника ускоренного градиентного слайдинга Дж. Лана [9, section 8.2] будет объяснена с помощью популярной в последнее время конструкции катализ [1, 11]. Обнаруженный способ позволил распространить область приложений техники слайдинга на интересующий нас класс задач. В разделе 2 результаты обобщаются на различные негладкие постановки задач, в частности на обобщенные линейные модели [15] и другие модели, допускающие эффективное сглаживание [2, 13].

1. ОСНОВНЫЕ РЕЗУЛЬТАТЫ

Рассмотрим следующую задачу:

$$F(x) = f(x) + g(x) = f(x) + \frac{1}{m} \sum_{k=1}^m g_k(x) \rightarrow \min_x, \quad (1)$$

где f и g_k имеют L_f и L_g – липшицевы градиенты в 2-норме, а функция F – μ -сильно выпуклая в 2-норме, причем $\mu \ll L_f$. В задаче (1) введем дополнительное условие $m \leq L_g/\mu$. Результат Дж. Лана [9, section 8.2] заключается в том, что для решения рассмотренной задачи с заданной точностью достаточно $\tilde{O}(\sqrt{L_f/\mu})$ вычислений ∇f и $\tilde{O}(\sqrt{L_g/\mu})$ вычислений ∇g , т.е. $\tilde{O}(m\sqrt{L_g/\mu})$ вычислений ∇g_k . При этом не важно с какой именно точностью ε . Эта точность будет входить под логарифмами в

¹ Институт проблем передачи информации им. А.А. Харкевича Российской академии наук, Москва, Россия

² Московский физико-технический институт (национальный исследовательский университет), Долгопрудный, Московская обл., Россия

³ Национальный исследовательский университет “Высшая школа экономики”, Москва, Россия

*E-mail: sergery.omelchenko@phystech.edu

**E-mail: gasnikov@yandex.ru

приведенные далее оценки, а для наглядности логарифмические сомножители было решено опустить. Далее оговорки о точности решения возникающих подзадач также опускаются, поскольку все это влияет только на логарифмические сомножители в итоговых оценках, которые опущены. Здесь и далее $\tilde{O}(\cdot) = O(\cdot)$ с точностью до логарифмического множителя.

Наложим еще одно дополнительное условие $mL_f \leq L_g$. Применим к рассмотренной задаче технику каталист [1, 11]. Отметим также, что если использовать технику каталист в варианте [1, 8], то применение данной техники не привносит дополнительного логарифмического множителя. Тогда вместо исходной задачи (1) потребуется $\tilde{O}(\sqrt{L/\mu})$ раз решать задачу вида

$$f(x) + g(x) + \frac{L}{2} \|x - x^k\|_2^2 \rightarrow \min_x, \quad (2)$$

где L по построению должно удовлетворять неравенству $\mu \leq L \leq L_f$. Задачу (2) можно решать неускоренным композитным градиентным методом [1, 12], считая $g(x) + \frac{L}{2} \|x - x^k\|_2^2$ композитом. Число итераций такого метода будет совпадать с числом вычислений ∇f и равно $\tilde{O}(L_f/(L + \mu))$. Но в условиях задачи не предполагалась проксимальная дружелюбность функции g , поэтому возникающую на каждой итерации неускоренного композитного градиентного метода задачу вида (детали см. в препринте [7])

$$\langle \nabla f(\tilde{x}^l), x - \tilde{x}^l \rangle + \frac{L_f}{2} \|x - \tilde{x}^l\|_2^2 + g(x) + \frac{L}{2} \|x - x^k\|_2^2 \rightarrow \min_x, \quad (3)$$

в свою очередь, необходимо будет решать. Для решения задачи (3) можно использовать ускоренный композитный метод редукции дисперсии [1, 9, 10], считая $\frac{L_f}{2} \|x - \tilde{x}^l\|_2^2 + \frac{L}{2} \|x - x^k\|_2^2$ композитом. Число вычислений ∇g_k для такого метода будет $\tilde{O}(\sqrt{mL_g(L_f + L)})$. Точнее говоря, оценка имеет вид: $\tilde{O}(m + \sqrt{mL_g/(L_f + L)})$. Однако в виду предположений $mL_f \leq L_g$, $L \leq L_f$:

$$\tilde{O}(m + \sqrt{mL_g/(L_f + L)}) = \tilde{O}(\sqrt{mL_g/(L_f + L)}).$$

Таким образом, общее число вычислений ∇g_k будет

$$\tilde{O}(m\sqrt{L/\mu}) + \tilde{O}(\sqrt{L/\mu}) \cdot \tilde{O}(L_f/(L + \mu)) \times \tilde{O}(\sqrt{mL_g/(L_f + L)}). \quad (4)$$

Первое слагаемое появилось из-за того, что в каталисте требуется считать ∇F на каждой итерации.

Выбирая параметр L ($\mu \leq L \leq L_f$) так, чтобы выражение (4) было минимальным, получим (с учетом сделанных предположений $mL_f \leq L_g$ и $\mu \ll L_f$), что $L \approx L_f$. Следовательно, имеет место

Теорема 1. При $mL_f \leq L_g$ задачу (1) можно решить с помощью описанной выше техники за $\tilde{O}(\sqrt{L_f/\mu})$ вычислений ∇f и $\tilde{O}(\sqrt{mL_g/\mu})$ вычислений ∇g_k .

Последняя оценка в $\tilde{O}(\sqrt{m})$ раз лучше оценки, которую можно получить, используя исходный ускоренный градиентный слайдинг Дж. Лана [9]. Несложно заметить [9], что приведенные в теореме 1 оценки оптимальны с точностью до логарифмических множителей.

Заметим, что в описанном выше подходе с $g(x)$ общего вида ускоренный метод редукции дисперсии можно заменить на покоординатный спуск или безградиентный метод [5]. Таким образом, можно получить расщепление задачи не только по гладкости или структуре слагаемых, но и по структуре оракула, доступного для каждого из слагаемых. Другой пример такого расщепления см. в [3].

Заметим также, что если в описанном выше подходе ограничиться вариантом каталиста из [1, 11], то все рассуждения можно провести в модельной (для f) общности [1].

2. ПРИЛОЖЕНИЕ

Заметим, что аналогично случаям задач из [1, 14, 15] описанная выше техника может использоваться и тогда, когда g_k — не гладкие функции, но допускающие сглаживание [2, 13]. Скажем, двойственное сглаживание по Ю.Е. Нестерову [1, 2, 13]. А именно, предположим, что функции g_k имеют проксимально-дружелюбные сопряженные функции g_k^* . В частности, это имеет место для обобщенной линейной модели [15], в которой $g_k(x) := g_k(\langle a_k, x \rangle)$. Тогда, регуляризируя сопряженные функции g_k^* с коэффициентом регуляризации $\sim \varepsilon$, где ε — желаемая точность (по функции) решения исходной задачи, получим, что $\varepsilon/2$ -решение сглаженной задачи будет ε -решением исходной. При том, что для сглаженной задачи $L_g \sim \varepsilon^{-1}$.

Заметим, что с помощью регуляризации исходной задачи [1] описанные выше результаты распространяются с сильно выпуклого случая на просто выпуклый случай. Для этого в постановку выпуклой задачи (1) вносится регуляризация $+\mu/2 \|x\|_2^2$, где $\mu = \varepsilon/R^2$. Здесь ε — желаемая точность реше-

Таблица 1. Сравнение алгоритмов

Алгоритм	Сложность	Ссылка
FGM	$O\left(\frac{R}{\varepsilon} \sqrt{s(ms + n^2)}\right)$	[1]
Слайдинг	$\tilde{O}\left(\frac{R}{\varepsilon} \sqrt{ms} \cdot s\right) + \tilde{O}\left(\sqrt{\frac{\lambda_{\max}(C)R^2}{\varepsilon}} \cdot n^2\right)$	данная статья

ния задачи по функции, а $R = \|x_*\|_2$ – 2-норма решения (на практике можно брать оценку сверху [1]). Из [1] следует, что $\varepsilon/2$ -решение так регуляризованной задачи будет ε -решением исходной задачи (1). Продемонстрируем возможные преимущества предложенного подхода в выпуклом (но не сильно выпуклом случае).

Рассматривается постановка задачи

$$F(x) = \frac{1}{2} \langle x, Cx \rangle + \frac{1}{m} \sum_{k=1}^m g_k(\langle a_k, x \rangle) \rightarrow \min_{x \in \mathbb{R}^n}$$

Предполагаем, что $|g_k''(y)| = O(1/\varepsilon)$, матрица $A = [a_1, \dots, a_m]^T$ имеет ms ненулевых элементов, $\max_{k=1, \dots, m} \|a_k\|_2^2 = O(s)$, где $1 \ll s \leq n$ и C – неотрицательно определенная матрица с $\lambda_{\max}(C) \leq 1/(\varepsilon m)$. Ускоренный градиентный метод (FGM) [1] будет требовать

$$O\left(\sqrt{\frac{(s/\varepsilon + \lambda_{\max}(C))R^2}{\varepsilon}}\right)$$

итераций для достижения точности ε по функции со сложностью одной итерации

$$O(ms + n^2)$$

арифметических операций (а.о.). В настоящей работе предложен подход, который требует

$$\tilde{O}\left(\sqrt{\frac{\lambda_{\max}(C)R^2}{\varepsilon}}\right)$$

итераций ускоренного градиентного метода для квадратичной формы (первого слагаемого). При этом сложность одной такой итерации

$$O(n^2) \text{ а.о.}$$

Также предложенный подход требует

$$\tilde{O}\left(\sqrt{\frac{(ms/\varepsilon)R^2}{\varepsilon}}\right)$$

итераций ускоренного метода редукции дисперсии [1, 9, 10]. При этом сложность одной такой итерации

$$O(s) \text{ а.о.}$$

Для наглядности эти результаты собраны в табл. 1. Из табл. 1 можно сделать вывод, что при $s \gg 1$, $\lambda_{\max}(C) \leq 1/(\varepsilon m) \ll s/\varepsilon$, предложенный в данной работе подход имеет лучшую теоретическую сложность, чем ускоренный градиентный метод, который принято было считать наилучшим для данного класса задач.

ИСТОЧНИКИ ФИНАНСИРОВАНИЯ

Работа поддержана грантами РФФИ 18–31–20005 мол_а_вед (раздел 1) и РФФИ 19–31–90062 Аспиранты (раздел 2).

Работа первого автора (Д.М. Двинских) была выполнена при поддержке Министерства науки и высшего образования Российской Федерации (госзадание № 075-00337-20-03).

СПИСОК ЛИТЕРАТУРЫ

1. *Гасников А.В.* Современные численные методы оптимизации. Метод универсального градиентного спуска. М.: МФТИ, 2018.
2. *Allen-Zhu Z., Hazan E.* Optimal Black-Box Reductions between Optimization Objectives // *Advances in Neural Information Processing Systems*. 2016. P. 1614–1622.
3. *Beznosikov A., Gorbunov E., Gasnikov A.* Derivative-Free Method for Decentralized Distributed Non-Smooth Optimization // *IFAC 2020. The 21st World Congress of the International Federation of Automatic Control*.
4. *Bottou L., Curtis F.E., Nocedal J.* Optimization Methods for Large-Scale Machine Learning // *Siam Review*. 2018. V. 60. № 2. P. 223–311.
5. *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*
6. *Hazan E.* Lecture Notes: Optimization for Machine Learning // *arXiv:1909.03550*
7. *Ivanova A., Gasnikov A., Dvurechensky P., Dvinskikh D., Tyurin A., Vorontsova E., Pasechnyuk D.* Oracle Complexity Separation in Convex Optimization // *arXiv:2002.02706*
8. *Ivanova A., Grishchenko D., Gasnikov A., Shulgin E.* Adaptive Catalyst for Smooth Convex Optimization // *arXiv:1911.11271*

9. *Lan G.* Lectures on Optimization. Methods for Machine Learning // <https://wpw.gatech.edu/guanghui-lan/publications/>
10. *Lan G., Li Z., Zhou Y.* A Unified Variance-Reduced Accelerated Gradient Method for Convex Optimization // *Advances in Neural Information Processing Systems*. 2019. P. 10462–10472.
11. *Lin H., Mairal J., Harchaoui Z.* Catalyst Acceleration for First-Order Convex Optimization: from Theory to Practice // *J. Machine Learning Research*. 2017. V. 18. № 1. P. 7854–7907.
12. *Nesterov Yu.* Gradient Methods for Minimizing Composite Functions // *Math. Prog.* 2013. V. 140. № 1. P. 125–161.
13. *Nesterov Yu.* Smooth Minimization of Non-Smooth Function // *Math. Program.* 2005. V. 103. № 1. P. 127–152.
14. *Shalev-Shwartz S., Ben-David S.* Understanding Machine Learning: From Theory to Algorithms. Cambridge: Cambridge University Press, 2014.
15. *Shalev-Shwartz S., Shamir O., Srebro N., Sridharan K.* Stochastic Convex Optimization // *COLT*. 2009.

ACCELERATED GRADIENT SLIDING FOR MINIMIZING THE SUM OF FUNCTIONS

D. M. Dvinskikh^a, S. S. Omelchenko^b, A. V. Gasnikov^b, and A. I. Tyurin^c

^a *Institute for Information Transmission Problems of the Russian Academy of Sciences, Moscow, Russian Federation*

^b *Moscow Institute of Physics and Technology, Dolgoprudny, Moscow Region, Russian Federation*

^c *Higher School of Economics, Moscow, Russian Federation*

Presented by Academician of the RAS Yu.G. Evtushenko

In this article, we propose a new way to justify the accelerated gradient sliding of G. Lan, which allows one to extend the sliding technique to a combination of an accelerated gradient method with an accelerated variance reduced method. We obtain new optimal estimates for solving the problem of minimizing a sum of smooth strongly convex functions with a smooth regularizer.

Keywords: convex optimization, fast gradient method, dispersion reduction method, composite optimization, sliding