

Быстрый градиентный метод

Родоманов А. О. Кротов Д. А.

Факультет ВМК
МГУ им. М. В. Ломоносова

15 апреля 2014 г.

Спецсеминар «Байесовские методы машинного обучения»

1 Введение

- Задачи и методы оптимизации
- Основные теоретические сведения

2 Метод градиентного спуска

- Стандартный метод для гладких функций
- Метод для составных функций и автоматический подбор L

3 Быстрый градиентный метод

- Метод для составных функций
- Рестарт
- Модификация подбора L и выбор L_0

4 Эксперименты и выводы

- Эксперименты
- Выводы

1 Введение

- Задачи и методы оптимизации
- Основные теоретические сведения

2 Метод градиентного спуска

- Стандартный метод для гладких функций
- Метод для составных функций и автоматический подбор L

3 Быстрый градиентный метод

- Метод для составных функций
- Рестарт
- Модификация подбора L и выбор L_0

4 Эксперименты и выводы

- Эксперименты
- Выводы

Непрерывная задача оптимизации

$$\begin{aligned} \min_{\mathbf{x}} \quad & f_0(\mathbf{x}) \\ \text{s.t.} \quad & g_i(\mathbf{x}) \leq 0, \quad i = 1, \dots, m, \\ & h_j(\mathbf{x}) = 0, \quad j = 1, \dots, k, \\ & \mathbf{x} \in S, \end{aligned}$$

где

- $\mathbf{x} = (x_1, \dots, x_n) \in \mathbb{R}^n$;
- $S \subseteq \mathbb{R}^n$;
- $f_0(\mathbf{x}), g_1(\mathbf{x}), \dots, g_m(\mathbf{x}), h_1(\mathbf{x}), \dots, h_k(\mathbf{x})$ — непрерывные вещественные функции.

- 1 Обычно метод не способен найти точное решение за конечное число шагов.
- 2 Метод генерирует бесконечную последовательность «приблизительных» решений $\{\mathbf{x}_k\}_{k=0}^{\infty}$.
- 3 Каждая следующая точка \mathbf{x}_{k+1} формируется по некоторым правилам на основе *локальной* информации, собранной на предыдущих итерациях.

Общая итеративная схема метода оптимизации

Вход: начальное приближение $\mathbf{x}_0 \in \mathbb{R}^n$ и параметр точности $\varepsilon > 0$;

Выход: решение $\bar{\mathbf{x}} \in \mathbb{R}^n$ в пределах заданной точности;

1 $\mathcal{I}_{-1} := \emptyset$;

2 для $k = 0, 1, 2, \dots$

3 {вычислить локальную информацию $\mathcal{O}(\mathbf{x}_k)$ в точке \mathbf{x}_k };

4 $\mathcal{I}_k := \mathcal{I}_{k-1} \cup (\mathbf{x}_k, \mathcal{O}(\mathbf{x}_k))$; // обновить собранную информацию

5 {применить правила метода к \mathcal{I}_k для формирования \mathbf{x}_{k+1} };

6 {проверить критерий остановки для заданной точности ε };

7 если {критерий остановки выполняется} то

8 {сформировать итоговый ответ $\bar{\mathbf{x}}$ };

9 **выход**;

- 1 Метод оптимизации должен *сходиться*.
- 2 *Скорость сходимости* метода определяет количество итераций, необходимых и достаточных для решения оптимизационной задачи.
- 3 Арифмитическая сложность метода складывается из его скорости сходимости и *арифмитической сложности одной итерации*.

- Методы *0-го порядка*
Требуют: только значения функций
- Методы *1-го порядка*
Требуют: значения функций и первые производные
- Методы *2-го порядка*
Требуют: значения функций, первые и вторые производные

Метод какого порядка использовать?

С ростом порядка метода

- 1 скорость сходимости возрастает;
- 2 арифметическая сложность одной итерации тоже возрастает.

Пример (логистическая регрессия)

$$Q(\mathbf{w}) = \frac{1}{m} \sum_{i=1}^m \ln(1 + \exp(-y_i \mathbf{w}^T \mathbf{x}_i)) \rightarrow \min_{\mathbf{w} \in \mathbb{R}^n}$$

Объект вычисления	Арифметическая сложность
Значение функции	$O(mn)$
Первые производные	$O(mn + n^2)$
Вторые производные	$O(mn + n^3)$

Вывод: при значениях $n \geq 500$ слишком дорого считать вторые производные на каждой итерации.

1 Введение

- Задачи и методы оптимизации
- Основные теоретические сведения

2 Метод градиентного спуска

- Стандартный метод для гладких функций
- Метод для составных функций и автоматический подбор L

3 Быстрый градиентный метод

- Метод для составных функций
- Рестарт
- Модификация подбора L и выбор L_0

4 Эксперименты и выводы

- Эксперименты
- Выводы

В дальнейшем мы будем рассматривать:

- методы оптимизации 1-го порядка;
- оптимизационные задачи без ограничений, т. е. задачи вида

$$f(\mathbf{x}) \rightarrow \min_{\mathbf{x} \in \mathbb{R}^n},$$

где $f(\mathbf{x})$ — некоторая непрерывная функция.

Определение

Функция $f(\mathbf{x})$ называется *гладкой*, если все ее частные производные существуют и являются непрерывными функциями.


Пример (гладкая функция: логистическая регрессия)

$$f(\mathbf{w}) = \frac{1}{m} \sum_{i=1}^m \ln(1 + \exp(-y_i \mathbf{w}^T \mathbf{x}_i))$$


Пример (негладкая функция: L_1 -регуляризатор)

$$g(\mathbf{w}) = \tau \|\mathbf{w}\|_1 = \tau \sum_{j=1}^n |w^{(j)}|, \quad \tau \geq 0$$

Гладкие и негладкие функции: иллюстрация



Негладкая функция



Гладкая функция

Определение

Градиентом гладкой функции $f(\mathbf{x})$ в точке \mathbf{x} называется вектор $\nabla f(\mathbf{x})$, составленный из частных производных функции в этой точке:

$$\nabla f(\mathbf{x}) = \left(\frac{\partial f(\mathbf{x})}{\partial x^{(j)}} \right)_{j=1}^n$$

Определение

Гессианом дважды дифференцируемой функции $f(\mathbf{x})$ в точке \mathbf{x} называется матрица $\nabla^2 f(\mathbf{x})$, составленная из вторых частных производных функции в этой точке:

$$\nabla^2 f(\mathbf{x}) = \left(\frac{\partial^2 f(\mathbf{x})}{\partial x^{(j)} \partial x^{(k)}} \right)_{j, k=1}^n$$

Формула Тейлора

Градиент и гессиан позволяют локально аппроксимировать гладкую функцию.

Пусть $f(\mathbf{x})$ является гладкой функцией. Тогда $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ справедливы следующие формулы:

Линейная аппроксимация

$$f(\mathbf{x}) = f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + o(\|\mathbf{x} - \mathbf{y}\|)$$

Квадратичная аппроксимация

$$f(\mathbf{x}) = f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \langle \nabla^2 f(\mathbf{y})(\mathbf{x} - \mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + o(\|\mathbf{x} - \mathbf{y}\|^2)$$

Определение

Говорят, что гладкая функция $f(\mathbf{x})$ обладает *липшицевым градиентом с константой* $L > 0$, если $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ справедливо

$$\|\nabla f(\mathbf{x}) - \nabla f(\mathbf{y})\| \leq L\|\mathbf{x} - \mathbf{y}\|.$$

Определение

Функция $f(\mathbf{x})$ называется *выпуклой*, если $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n, \forall \alpha \in [0, 1]$ справедливо

$$f(\alpha\mathbf{x} + (1 - \alpha)\mathbf{y}) \leq \alpha f(\mathbf{x}) + (1 - \alpha)f(\mathbf{y}).$$

Определение

Говорят, что $f(\mathbf{x}) \in \mathcal{F}_L^1$, если $f(\mathbf{x})$ является выпуклой функцией и обладает липшицевым градиентом с константой L .

Определение

Функция $f(\mathbf{x})$ называется *строго выпуклой*, если $\exists \mu > 0 : \forall \mathbf{y} \in \mathbb{R}^n$ функция $F(\mathbf{x}) = f(\mathbf{x}) - \frac{\mu}{2} \|\mathbf{x} - \mathbf{y}\|^2$ является выпуклой.

Число μ называется *параметром выпуклости* функции $f(\mathbf{x})$.

Замечание

При $\mu = 0$ получаем обычное определение выпуклости.

Определение

Говорят, что $f(\mathbf{x}) \in \mathcal{S}_{\mu, L}^1$, если $f(\mathbf{x})$ является строго выпуклой функцией с параметром выпуклости μ и обладает липшицевым градиентом с константой L .

Утверждение

$f(\mathbf{x}) \in \mathcal{F}_L^1$ тогда и только тогда, когда $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ справедливы оценки

$$f(\mathbf{x}) \leq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2$$

$$f(\mathbf{x}) \geq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle$$



Утверждение

$f(\mathbf{x}) \in \mathcal{S}_{\mu, L}^1$ тогда и только тогда, когда $\forall \mathbf{x}, \mathbf{y} \in \mathbb{R}^n$ справедливы оценки

$$f(\mathbf{x}) \leq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2$$

$$f(\mathbf{x}) \geq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{\mu}{2} \|\mathbf{x} - \mathbf{y}\|^2$$

Классы функций \mathcal{F}_L^1 и $\mathcal{S}_{\mu, L}^1$: иллюстрация



Утверждение

Пусть $f(\mathbf{x})$ дважды непрерывно дифференцируемая функция. Тогда $f(\mathbf{x}) \in \mathcal{F}_L^1$ тогда и только тогда, когда $\forall \mathbf{x} \in \mathbb{R}^n$ выполнено

$$\lambda_{\min}(\nabla^2 f(\mathbf{x})) \geq 0,$$

$$\lambda_{\max}(\nabla^2 f(\mathbf{x})) \leq L.$$

Утверждение

Пусть $f(\mathbf{x})$ дважды непрерывно дифференцируемая функция. Тогда $f(\mathbf{x}) \in \mathcal{S}_{\mu, L}^1$ тогда и только тогда, когда $\forall \mathbf{x} \in \mathbb{R}^n$ выполнено

$$\lambda_{\min}(\nabla^2 f(\mathbf{x})) \geq \mu,$$

$$\lambda_{\max}(\nabla^2 f(\mathbf{x})) \leq L.$$

(Здесь $\lambda_{\min}(A)$ и $\lambda_{\max}(A)$ — наименьшее и наибольшее собственные значения матрицы $A \succeq 0$.)

Пример (квадратичная функция)

Рассмотрим квадратичную функцию

$$f(\mathbf{x}) = \frac{1}{2} \langle A\mathbf{x}, \mathbf{x} \rangle + \langle \mathbf{b}, \mathbf{x} \rangle + c, \quad A = A^T \succeq 0.$$

Гессиан этой функции в каждой точке $\mathbf{x} \in \mathbb{R}^n$ одинаков и равен

$$\nabla^2 f(\mathbf{x}) = A \succeq 0.$$

Таким образом, $f(\mathbf{x}) \in \mathcal{F}_L^1$, где $L = \lambda_{\max}(A)$.

Более того, если $\lambda_{\min}(A) > 0$, то $f(\mathbf{x}) \in \mathcal{S}_{\mu, L}^1$, где $\mu = \lambda_{\min}(A)$, $L = \lambda_{\max}(A)$.

1 Введение

- Задачи и методы оптимизации
- Основные теоретические сведения

2 Метод градиентного спуска

- **Стандартный метод для гладких функций**
- Метод для составных функций и автоматический подбор L

3 Быстрый градиентный метод

- Метод для составных функций
- Рестарт
- Модификация подбора L и выбор L_0

4 Эксперименты и выводы

- Эксперименты
- Выводы

Градиентный спуск

$$\mathbf{x}_{k+1} = \mathbf{x}_k - \alpha_k \nabla f(\mathbf{x}_k), \quad k \geq 0$$

Стратегии выбора длины шага:

1 **Наискорейший спуск:**

$$\alpha_k = \min_{\alpha_k \in \mathbb{R}} f(\mathbf{x}_k - \alpha_k \nabla f(\mathbf{x}_k))$$

2 **Правило Гольдштейна:** найти α_k , такое что

$$f(\mathbf{x}_{k+1}) \leq f(\mathbf{x}_k) - \gamma \alpha_k \|\nabla f(\mathbf{x}_k)\|^2,$$

$$f(\mathbf{x}_{k+1}) \geq f(\mathbf{x}_k) - (1 - \gamma) \alpha_k \|\nabla f(\mathbf{x}_k)\|^2,$$

где $0 < \gamma < 0.5$ — некоторая константа.


3 **Константный шаг:**

- $\alpha_k = \frac{1}{L}$ для $f(\mathbf{x}) \in \mathcal{F}_L^1$;
- $\alpha_k = \frac{2}{\mu+L}$ или $\alpha_k = \frac{1}{L}$ для $f(\mathbf{x}) \in \mathcal{S}_{\mu, L}^1$.

Метод градиентного спуска: иллюстрация

На самом деле, шаг градиентного метода есть минимизация простой квадратичной функции:

$$\mathbf{x}_{k+1} = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \left[f(\mathbf{x}_k) + \langle \nabla f(\mathbf{x}_k), \mathbf{x} - \mathbf{x}_k \rangle + \frac{1}{2\alpha_k} \|\mathbf{x} - \mathbf{x}_k\|^2 \right]$$



Теорема

Пусть $f(\mathbf{x}) \in \mathcal{F}_L^1$. Тогда метод градиентного спуска с константным шагом $\alpha_k \equiv \frac{1}{L}$ имеет следующую скорость сходимости ($k \geq 1$):

$$f(\mathbf{x}_k) - f^* \leq \frac{2L}{k+4} \|\mathbf{x}_0 - \mathbf{x}^*\|^2.$$


Теорема

Пусть $f(\mathbf{x}) \in \mathcal{S}_{\mu,L}^1$. Тогда метод градиентного спуска с константным шагом $\alpha_k \equiv \frac{2}{\mu+L}$ имеет следующую скорость сходимости ($k \geq 1$):

$$f(\mathbf{x}_k) - f^* \leq \frac{L}{2} \left(1 - \frac{2}{Q+1}\right)^{2k} \|\mathbf{x}_0 - \mathbf{x}^*\|^2,$$

где $Q = \frac{L}{\mu} \geq 1$ — число обусловленности функции $f(\mathbf{x})$.

Скорость сходимости для класса $\mathcal{S}_{\mu, L}$: иллюстрация



Скорость сходимости: другие стратегии выбора шага

Для других стратегий выбора шага ситуация сильно не меняется.

Пример (наискорейший спуск для квадратичной задачи)

$$f(\mathbf{x}) = \frac{1}{2} \langle A\mathbf{x}, \mathbf{x} \rangle, \quad A = A^T \succeq 0.$$

Стратегия наискорейшего спуска:

$$\alpha_k = \min_{\alpha \in \mathbb{R}^n} f(\mathbf{x}_k - \alpha \nabla f(\mathbf{x}_k)).$$

Указанный минимум можно найти аналитически:

$$\alpha_k = \frac{\langle A^2 \mathbf{x}_k, \mathbf{x}_k \rangle}{\langle A^3 \mathbf{x}_k, \mathbf{x}_k \rangle}.$$

Можно показать, что

$$f(\mathbf{x}_k) - f^* \leq \left(1 - \frac{2}{Q+1}\right)^{2k} [f(\mathbf{x}_0) - f^*].$$

Скорость сходимости принципиально не изменилась!

- 1 Введение
 - Задачи и методы оптимизации
 - Основные теоретические сведения
- 2 Метод градиентного спуска
 - Стандартный метод для гладких функций
 - Метод для составных функций и автоматический подбор L
- 3 Быстрый градиентный метод
 - Метод для составных функций
 - Рестарт
 - Модификация подбора L и выбор L_0
- 4 Эксперименты и выводы
 - Эксперименты
 - Выводы

Определение

Составными функциями будем называть функции вида

$$F(\mathbf{x}) = f(\mathbf{x}) + h(\mathbf{x}),$$

где $f(\mathbf{x}) \in \mathcal{F}_L^1$, а $h(\mathbf{x})$ — некоторая простая (негладкая) выпуклая функция.

(Что значит «простая» станет понятно позже.)

Пример (логистическая регрессия с L_1 -регуляризатором)

$$F(\mathbf{w}) = \underbrace{\frac{1}{m} \sum_{i=1}^m \ln(1 + \exp(-y_i \mathbf{w}^T \mathbf{x}_i))}_{f(\mathbf{w})} + \underbrace{\tau \|\mathbf{w}\|_1}_{h(\mathbf{w})}, \quad \tau > 0$$

Как минимизировать составные функции?

- 1 Составные функции уже *не* являются гладкими.
- 2 Стандартный метод градиентного спуска уже *не* применим.
- 3 Можно использовать субградиентный спуск, однако в этом случае получаем скорость сходимости $O\left(\frac{1}{\sqrt{k}}\right)$, что существенно хуже, чем в гладком случае.
- 4 Мы увидим, что если правильно учесть структуру задачи и слегка модифицировать метод градиентного спуска, то получится метод со скоростью сходимости $O\left(\frac{1}{k}\right)$.

Градиентное отображение

Напомним, что в случае гладкой функции $f(\mathbf{x})$ метод градиентного спуска (с $\alpha_k \equiv 1/L$) делал итерации вида

$$\mathbf{x}_{k+1} = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \left[f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2 \right],$$

т. е. на каждой итерации минимизировал верхнюю квадратичную оценку на $f(\mathbf{x})$.

Построим аналог такой итерации для составных функций.

Определение

Градиентным отображением $T_L(\mathbf{y})$ точки $\mathbf{y} \in \mathbb{R}^n$ называется точка

$$T_L(\mathbf{y}) = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \left[f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2 + h(\mathbf{x}) \right].$$

Пример (L_1 -регуляризатор)

Пусть $g(\mathbf{x}) = \tau \|\mathbf{x}\|_1$, $\tau > 0$.

Тогда

$$T_L(\mathbf{y}) = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \left[f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2 + \tau \|\mathbf{x}\|_1 \right].$$

Данный минимум можно найти аналитически:

$$T_L(\mathbf{y}) = \mathcal{V}_{\tau/L} \left(\mathbf{y} - \frac{1}{L} \nabla f(\mathbf{y}) \right),$$

где $\mathcal{V}_\alpha^{(j)} = \max(|x^{(j)}| - \alpha, 0) \operatorname{sgn}(x^{(j)})$, $j = 1, \dots, n$ — сжимающий оператор.

Схема метода

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, $L_f > 0$;

1 для $k = 0, 1, 2, \dots$

2 | {вычислить $f(\mathbf{x}_k)$, $\nabla f(\mathbf{x}_k)$ };

3 | $\mathbf{x}_{k+1} := T_{L_f}(\mathbf{x}_k)$; // вместо $\mathbf{x}_{k+1} := \mathbf{x}_k - \frac{1}{L} \nabla f(\mathbf{x}_k)$

- 1 Что если константа Липшица L_f для функции $f(\mathbf{x})$ нам неизвестна?
- 2 Более того, что если функция в разных областях имеет сильно разные константы Липшица? В этом случае глобальная константа L_f локально будет плохо аппроксимировать изгиб функции. В результате шаги будут существенно меньше, чем они могли бы быть.
- 3 Какому основному условию должна удовлетворять локальная константа Липшица L_k , чтобы метод по-прежнему хорошо работал? Оказывается, достаточно потребовать всего лишь знакомой верхней оценки:

$$f(\mathbf{x}_{k+1}) \leq f(\mathbf{x}_k) + \langle \nabla f(\mathbf{x}_k), \mathbf{x}_{k+1} - \mathbf{x}_k \rangle + \frac{L_k}{2} \|\mathbf{x}_{k+1} - \mathbf{x}_k\|^2$$

Градиентный спуск с автоматическим подбором L_k

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, $L_0 > 0$, $\gamma_u > 1$, $\gamma_d \geq 1$;

1 для $k = 0, 1, 2, \dots$

2 {вычислить $f(\mathbf{x}_k)$, $\nabla f(\mathbf{x}_k)$ };

3 $L := L_k$;

4 **повторять**

5 $\mathbf{T} := T_L(\mathbf{x}_k)$;

6 {вычислить $f(\mathbf{T})$ };

7 если $f(\mathbf{T}) > f(\mathbf{x}_k) + \langle \nabla f(\mathbf{x}_k), \mathbf{T} - \mathbf{x}_k \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{x}_k\|^2$ то

8 | $L := \gamma_u L$;

9 **пока неверно, что**

$f(\mathbf{T}) \leq f(\mathbf{x}_k) + \langle \nabla f(\mathbf{x}_k), \mathbf{T} - \mathbf{x}_k \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{x}_k\|^2$;

10 $\mathbf{x}_{k+1} := \mathbf{T}$;

11 $L_{k+1} := \max\left(L_0, \frac{L}{\gamma_d}\right)$;

Теорема

Пусть N_k — количество вычислений функции $f(\mathbf{x})$ за первые k итераций градиентного спуска. Тогда

$$N_k \leq \left(1 + \frac{\ln \gamma_d}{\ln \gamma_u}\right) (k + 1) + \frac{1}{\ln \gamma_u} \max \left(\ln \frac{\gamma_u L_f}{\gamma_d L_0}, 0 \right)$$

Например, если $\gamma_d = 1, \gamma_u = 2$, то

$$N_k \leq (k + 1) + \log_2 \frac{2L_f}{L_0},$$

т. е. среднее число вычислений функции за одну итерацию равно 1.

На практике хорошие значения $\gamma_u = 2, \gamma_d = 1.1$.

Теорема

Градиентный спуск для составных функций имеет следующую скорость сходимости:

$$F(\mathbf{x}_k) - F^* \leq \frac{2\gamma_u L_f}{k+2} \|\mathbf{x}_0 - \mathbf{x}^*\|^2$$

Более того, если $F(\mathbf{x})$ является строго выпуклой с параметром выпуклости μ_F , то гарантируется следующая скорость:

$$F(\mathbf{x}_k) - F^* \leq \left(1 - \frac{\mu_F}{4\gamma_u L_f}\right)^k [F(\mathbf{x}_0) - F^*].$$

Замечание: Интересной особенностью является то, что методу не нужно заранее знать константу μ_F , чтобы гарантировать последнее неравенство.

- 1 Введение
 - Задачи и методы оптимизации
 - Основные теоретические сведения
- 2 Метод градиентного спуска
 - Стандартный метод для гладких функций
 - Метод для составных функций и автоматический подбор L
- 3 Быстрый градиентный метод
 - Метод для составных функций
 - Рестарт
 - Модификация подбора L и выбор L_0
- 4 Эксперименты и выводы
 - Эксперименты
 - Выводы

Постановка задачи

В дальнейшем мы будем рассматривать задачи вида

$$\min_{\mathbf{x} \in \mathbb{R}^n} F(\mathbf{x}),$$

где $F(\mathbf{x})$ — составная функция, т. е.

$$F(\mathbf{x}) = f(\mathbf{x}) + h(\mathbf{x}),$$

где $f(\mathbf{x}) \in \mathcal{F}_{L_f}^1$ и $h(\mathbf{x})$ — некоторая простая (негладкая) выпуклая функция.

Под «простотой» функции $h(\mathbf{x})$ подразумевается, что мы легко можем вычислить градиентное отображение

$$T_L(\mathbf{y}) = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \left[f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2 + h(\mathbf{x}) \right].$$

Определение

Оценочной последовательностью для функции $F(\mathbf{x})$ называется тройка, состоящая из

- минимизирующей последовательности $\{\mathbf{x}_k\}_{k=0}^{\infty}$,
- последовательности масштабирующих коэффициентов $\{A_k\}_{k=0}^{\infty}$,
- последовательности оценочных функций $\{\psi_k(\mathbf{x})\}_{k=0}^{\infty}$,

обеспечивающих выполнение следующих двух отношений $\forall k \geq 0$:

$$\mathcal{R}_k^1: A_k F(\mathbf{x}_k) \leq \psi_k^* \equiv \min_{\mathbf{x} \in \mathbb{R}^n} \psi_k(\mathbf{x}),$$

$$\mathcal{R}_k^2: \psi_k(\mathbf{x}) \leq A_k F(\mathbf{x}) + \psi_0(\mathbf{x}), \quad \forall \mathbf{x} \in \mathbb{R}^n.$$

(Подразумевается, что $A_k > 0$ для $k \geq 1$.)

Функция $\psi_0(\mathbf{x})$ называется проксимальной функцией.

Если отношения \mathcal{R}_k^1 и \mathcal{R}_k^2 выполняются $\forall k \geq 0$, то получаем оценку скорости сходимости:

$$F(\mathbf{x}_k) - F^* \leq \frac{1}{A_k} \psi_0(\mathbf{x}^*), \quad k \geq 1.$$

Например, если выбрать $\psi_0(\mathbf{x}) = \frac{1}{2} \|\mathbf{x} - \mathbf{x}_0\|^2$, то

$$F(\mathbf{x}_k) - F^* \leq \frac{1}{2A_k} \|\mathbf{x}^* - \mathbf{x}_0\|^2, \quad k \geq 1.$$

Таким образом, скорость сходимости определяется тем, насколько быстро растут масштабирующие коэффициенты A_k .

Далее мы построим такую оценочную последовательность, что масштабирующие коэффициенты A_k будут расти как $O(k^2)$.

Будем искать оценочные функции $\psi_k(\mathbf{x})$ и масштабирующие коэффициенты A_k в виде ($k \geq 1$)

$$\psi_k(\mathbf{x}) = \psi_{k-1}(\mathbf{x}) + a_k \underbrace{[f(\mathbf{x}_k) + \langle \nabla f(\mathbf{x}_k), \mathbf{x} - \mathbf{x}_k \rangle + h(\mathbf{x})]}_{\text{нижняя оценка на функцию } F(\mathbf{x})},$$

$$A_k = A_{k-1} + a_k,$$

где $A_0 = 0$; коэффициенты $a_k > 0$, $\forall k \geq 1$ контролируют скорость роста масштабирующих коэффициентов.

Такой выбор сразу же обеспечивает выполнение отношения \mathcal{R}_k^2 (доказывается по индукции).

- 1 Зафиксировав конкретный вид оценочных функций $\psi_k(\mathbf{x})$, мы обеспечили выполнение отношения $\mathcal{R}_k^2, \forall k \geq 0$.
- 2 Свободные параметры оценочной последовательности:
 - минимизирующая последовательность $\{\mathbf{x}_k\}_{k=0}^{\infty}$;
 - коэффициенты роста масштабирующих коэффициентов $\{a_k\}_{k=1}^{\infty}$;
 - проксимальная функция $\psi_0(\mathbf{x})$.
- 3 Далее мы обеспечим выполнение оставшегося отношения \mathcal{R}_k^1 , задействовав все свободные на текущий момент параметры, и получим конкретную схему быстрого градиентного метода.

Выберем проксимальную функцию $\psi_0(\mathbf{x}) = \frac{1}{2}\|\mathbf{x} - \mathbf{x}_0\|^2$.

Тогда

$$\psi_k(\mathbf{x}) = \underbrace{\frac{1}{2}\|\mathbf{x} - \mathbf{x}_0\|^2}_{\text{строго выпуклая}} + \sum_{i=1}^k a_i \underbrace{[f(\mathbf{x}_i) + \langle \nabla f(\mathbf{x}_i), \mathbf{x} - \mathbf{x}_i \rangle + h(\mathbf{x})]}_{\text{выпуклая}},$$

т. е. $\psi_k(\mathbf{x})$ является строго выпуклой функцией с параметром выпуклости 1.

Тогда

$$\psi_k(\mathbf{x}) \geq \psi_k^* + \frac{1}{2}\|\mathbf{x} - \mathbf{v}_k\|^2,$$

где $\mathbf{v}_k = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \psi_k(\mathbf{x})$.

Оценочная функция:

$$\psi_{k+1}(\mathbf{x}) = \psi_k(\mathbf{x}) + a_{k+1} [f(\mathbf{x}_{k+1}) + \langle \nabla f(\mathbf{x}_{k+1}), \mathbf{x} - \mathbf{x}_{k+1} \rangle + h(\mathbf{x})].$$

Пусть выполняется отношение \mathcal{R}_k^1 . Можно показать, что в этом случае

$$\underbrace{\psi_{k+1}^* \geq A_{k+1} F(\mathbf{x}_{k+1})}_{\text{отношение } \mathcal{R}_{k+1}^1} + A_{k+1} \left[\langle F'(\mathbf{x}_{k+1}), \mathbf{y}_k - \mathbf{x}_{k+1} \rangle - \frac{a_{k+1}^2}{2A_{k+1}} \|F'(\mathbf{x}_{k+1})\|^2 \right],$$

где

$$\mathbf{y}_k = \frac{A_k \mathbf{x}_k + a_{k+1} \mathbf{v}_k}{A_k + a_{k+1}},$$

а $F'(\mathbf{x}_{k+1})$ — любой субградиент функции $F(\mathbf{x})$ в точке \mathbf{x}_{k+1} .

Осталось выбором a_{k+1} и \mathbf{x}_{k+1} добиться выполнения неравенства

$$\langle F'(\mathbf{x}_{k+1}), \mathbf{y}_k - \mathbf{x}_{k+1} \rangle \geq \frac{a_{k+1}^2}{2A_{k+1}} \|F'(\mathbf{x}_{k+1})\|^2.$$

Это можно сделать с помощью градиентного шага.

Лемма

$\forall L \geq L_f$ и $\mathbf{T} = T_L(\mathbf{y})$ верно следующее неравенство:

$$\langle F'(\mathbf{T}), \mathbf{y} - \mathbf{T} \rangle \geq \frac{1}{L} \|F'(\mathbf{T})\|^2,$$

где $F'(\mathbf{T}) = L(\mathbf{y} - \mathbf{T}) - [\nabla f(\mathbf{y}) - \nabla f(\mathbf{T})]$ – конкретный субградиент в точке $\mathbf{T} = T_L(\mathbf{y})$.

Напомним, что

$$T_L(\mathbf{y}) = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \left[f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{x} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{x} - \mathbf{y}\|^2 + h(\mathbf{x}) \right].$$

Быстрый градиентный метод для составных функций

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, $0 < L_0 \leq L_f$, $\gamma_u > 1$, $\gamma_d \geq 1$;

1 $A_0 := 0$;

2 для $k = 0, 1, 2, \dots$

3 $L := L_k$;

4 **повторять**

5 {найти a из уравнения $\frac{a^2}{2(A_k+a)} = \frac{1}{L}$ };

6 {вычислить $\mathbf{v}_k = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \psi_k(\mathbf{x})$ };

7 $\mathbf{y} := \frac{A_k \mathbf{x}_k + a \mathbf{v}_k}{A_k + a}$; {вычислить $\nabla f(\mathbf{y})$ };

8 $\mathbf{T} := T_L(\mathbf{y})$; {вычислить $\nabla f(\mathbf{T})$ };

9 $s := L(\mathbf{y} - \mathbf{T}) - [\nabla f(\mathbf{y}) - \nabla f(\mathbf{T})]$;

10 если $\langle s, \mathbf{y} - \mathbf{T} \rangle < \frac{1}{L} \|s\|^2$ то $L := \gamma_u L$;

11 **пока неверно, что** $\langle s, \mathbf{y} - \mathbf{T} \rangle \geq \frac{1}{L} \|s\|^2$;

12 $\mathbf{x}_{k+1} := \mathbf{T}$; $A_{k+1} := A_k + a$; $L_{k+1} := \max\left(L_0, \frac{L}{\gamma_d}\right)$;

Быстрый градиентный метод: простая схема

Если оптимизируемая функция $F(\mathbf{x})$ гладкая (т. е. $F(\mathbf{x}) \equiv f(\mathbf{x})$) с известной константой Липшица для градиента L_f , то схема упрощается.

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$;

1 $\mathbf{v}_0 := \mathbf{x}_0$; $A_0 := 0$;

2 для $k = 0, 1, 2, \dots$

3 {найти a из уравнения $\frac{a^2}{2(A_k+a)} = \frac{1}{L_f}$ };


4 $\mathbf{y} := \frac{A_k \mathbf{x}_k + a \mathbf{v}_k}{A_k + a}$; {вычислить $\nabla f(\mathbf{y})$ };

5 $\mathbf{x}_{k+1} := \mathbf{y}_k - \frac{1}{L_f} \nabla f(\mathbf{y}_k)$; {вычислить $\nabla f(\mathbf{x}_{k+1})$ };


6 $\mathbf{v}_{k+1} := \mathbf{v}_k - a \nabla f(\mathbf{x}_{k+1})$;

7 $A_{k+1} := A_k + a$;

Одна итерация метода: иллюстрация



Траектория метода



Напомним, что параметры роста a_k масштабирующих коэффициентов A_k находятся из уравнения

$$\frac{a_k^2}{2(A_k + a_k)} = \frac{1}{L}.$$

Из этого уравнения и того, что $L \leq \gamma_u L_f$ получаем следующую оценку на скорость роста масштабирующих коэффициентов.

Лемма

Для масштабирующих коэффициентов A_k справедлива оценка

$$A_k \geq \frac{k^2}{2\gamma_u L_f}, \quad k \geq 0.$$

Теорема

Быстрый градиентный метод для составных функций имеет следующую скорость сходимости:

$$F(\mathbf{x}_k) - F^* \leq \frac{\gamma_u L_f}{k^2} \|\mathbf{x}_0 - \mathbf{x}^*\|^2$$

Напомним, что скорость сходимости обычного градиентного спуска на порядок хуже:

$$F(\mathbf{x}_k) - F^* \leq \frac{2\gamma_u L_f}{k+2} \|\mathbf{x}_0 - \mathbf{x}^*\|^2.$$

- 1 Введение
 - Задачи и методы оптимизации
 - Основные теоретические сведения
- 2 Метод градиентного спуска
 - Стандартный метод для гладких функций
 - Метод для составных функций и автоматический подбор L
- 3 Быстрый градиентный метод
 - Метод для составных функций
 - Рестарт
 - Модификация подбора L и выбор L_0
- 4 Эксперименты и выводы
 - Эксперименты
 - Выводы

Что насчет строго выпуклых функций?

- 1 Для строго выпуклой функции $F(\mathbf{x})$ с параметром выпуклости μ_F обычный градиентный спуск имеет следующую скорость сходимости:

$$F(\mathbf{x}_k) - F^* \leq \left(1 - \frac{\mu_F}{4\gamma_u L_f}\right)^k [F(\mathbf{x}_0) - F^*].$$

При этом методу совсем не требуется знание константы μ_F .

- 2 Можно ли гарантировать подобный результат для быстрого градиентного метода? Оказывается, что можно. Но для этого необходима модификация метода.
- 3 Далее мы рассмотрим технику т. н. *рестарта*, которая потребует знания константы μ_F . Затем мы откажемся от этого требования благодаря стратегии *адаптивного рестарта*.

Пусть функция $F(\mathbf{x})$ является строго выпуклой с параметром выпуклости μ_F .

Вспомним, что для быстрого градиентного метода справедлива следующая оценка скорости сходимости ($k \geq 0$):

$$F(\mathbf{x}_k) - F^* \leq \frac{\gamma_u L_f}{k^2} \|\mathbf{x}_0 - \mathbf{x}^*\|^2.$$

Из данной оценки и строгой выпуклости $F(\mathbf{x})$ вытекает, что $\forall k \geq 0$

$$F(\mathbf{x}_k) - F^* \leq \frac{2\gamma_u L_f}{\mu_F k^2} [F(\mathbf{x}_0) - F^*].$$

Если положить $k = \left\lceil 2\sqrt{\frac{\gamma_u L_f}{\mu_F}} \right\rceil \equiv N$, то получим

$$F(\mathbf{x}_N) - F^* \leq \frac{1}{2} [F(\mathbf{x}_0) - F^*].$$

Мы получили, что для $N = \left\lceil 2\sqrt{\frac{\gamma_u L_f}{\mu_F}} \right\rceil$ справедлива оценка

$$F(\mathbf{x}_N) - F^* \leq \frac{1}{2} [F(\mathbf{x}_0) - F^*],$$

т. е. за N итераций быстрый градиентный метод уменьшает невязку по значению функции как минимум вдвое.

Если после N итераций метода положить $\mathbf{x}_0 = \mathbf{x}_N$, т. е. *перезапустить* метод из новой начальной точки \mathbf{x}_N , то получим что

$$F(\mathbf{x}_{2N}) - F^* \leq \frac{1}{2} [F(\mathbf{x}_N) - F^*] \leq \frac{1}{4} [F(\bar{\mathbf{x}}_0) - F^*],$$

где $\bar{\mathbf{x}}_0$ — исходная начальная точка.

Невязка уменьшилась уже в четыре раза!

Получаем геометрическую прогрессию:

$$F(\mathbf{x}_{KN}) - F^* \leq \frac{1}{2^K} [F(\bar{\mathbf{x}}_0) - F^*].$$

Будем обозначать $\mathcal{A}_N(\mathbf{u})$ точку, полученную быстрым градиентным методом за N итераций из начального приближения \mathbf{u} .

Для реализации рестарта можно использовать следующую двухуровневую схему.

Процедура рестарта

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, N — частота рестартов;

- 1 $\mathbf{u}_0 = \mathbf{x}_0$;
- 2 для $k = 0, 1, 2, \dots$
- 3 | $\mathbf{u}_{k+1} := \mathcal{A}_N(\mathbf{u}_k)$;

Вместо двухуровневой схемы можно интегрировать рестарт внутрь метода (следующий слайд).

Быстрый градиентный метод с рестартом

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, $0 < L_0 \leq L_f$, $\gamma_u > 1$, $\gamma_d \geq 1$, N — частота рестартов;

1 $A_0 := 0$;

2 для $k = 0, 1, 2, \dots$

3 $L := L_k$;

4 **повторять**

5 $\{ \text{найти } a \text{ из уравнения } \frac{a^2}{2(A_k+a)} = \frac{1}{L} \}$;

6 $\{ \text{вычислить } \mathbf{v}_k = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \psi_k(\mathbf{x}) \}$;

7 $\mathbf{y} := \frac{A_k \mathbf{x}_k + a \mathbf{v}_k}{A_k + a}$; $\{ \text{вычислить } \nabla f(\mathbf{y}) \}$;

8 $\mathbf{T} := T_L(\mathbf{y})$; $\{ \text{вычислить } \nabla f(\mathbf{T}) \}$;

9 $s := L(\mathbf{y} - \mathbf{T}) - [\nabla f(\mathbf{y}) - \nabla f(\mathbf{T})]$;

10 если $\langle s, \mathbf{y} - \mathbf{T} \rangle < \frac{1}{L} \|s\|^2$ то $L := \gamma_u L$;

11 пока неверно, что $\langle s, \mathbf{y} - \mathbf{T} \rangle \geq \frac{1}{L} \|s\|^2$;

12 $\mathbf{x}_{k+1} := \mathbf{T}$; $A_{k+1} := A_k + a$; $L_{k+1} := \max\left(L_0, \frac{L}{\gamma_d}\right)$;

13 если $N \mid k$ то $\mathbf{x}_{k+1} := \mathbf{x}_k$; $A_{k+1} := 0$;

Утверждение

Для генерации ε -решения по значению функции быстрому градиентному методу с рестартом достаточно $O\left(\sqrt{\frac{L_f}{\mu_F}} \ln \frac{1}{\varepsilon}\right)$ итераций.

Заметим, что гарантия обычного градиентного спуска составляет $O\left(\frac{L_f}{\mu_F} \ln \frac{1}{\varepsilon}\right)$ итераций, что значительно хуже.

Константы L_f и μ_F неизвестны

- 1 Рестарт гарантирует хорошую скорость сходимости для строго выпуклых функций, однако он требует знания констант L_f и μ_F , которые на практике редко известны.
- 2 Как отказаться от требования знания констант L_f и μ_F ?
- 3 Можно перезапускать метод, например, каждые $N = 100$, $N = 200$ или $N = 500$ итераций. Главный недостаток такой стратегии состоит в том, что нет никаких правил для выбора N .
- 4 Обязательно ли делать рестарт с одинаковым периодом N ? Почему бы не заменить условие рестарта « $N \mid k$ » на какое-нибудь другое?
- 5 Далее мы увидим, что можно делать т. н. *адаптивный рестарт*, который не требует знания констант L_f и μ_F .

Предлагается в качестве условия рестарта использовать следующее.

Градиентное условие рестарта


$$\langle g_L(\mathbf{y}_k), \mathbf{x}_{k+1} - \mathbf{x}_k \rangle > 0,$$

где $g_L(\mathbf{y}) = L(\mathbf{y} - T_L(\mathbf{y}))$ — аналог градиента для составных функций.

Таким образом, если переход от точки \mathbf{x}_k к точке \mathbf{x}_{k+1} произошел по направлению убывания в точке \mathbf{y}_k , то все хорошо. Иначе рестарт.

Замечание: Данное условие является скорее эвристикой, чем фундаментальной научной идеей. Возможны и другие (похожие) условия рестарта.

Адаптивный рестарт: иллюстрация



Алгоритм

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, $0 < L_0 \leq L_f$, $\gamma_u > 1$, $\gamma_d \geq 1$;

1 $A_0 := 0$;

2 для $k = 0, 1, 2, \dots$

3 $L := L_k$;

4 **повторять**

5 $\{\text{найти } a \text{ из уравнения } \frac{a^2}{2(A_k+a)} = \frac{1}{L}\}$;

6 $\{\text{вычислить } \mathbf{v}_k = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \psi_k(\mathbf{x})\}$;

7 $\mathbf{y} := \frac{A_k \mathbf{x}_k + a \mathbf{v}_k}{A_k + a}$; $\{\text{вычислить } \nabla f(\mathbf{y})\}$;

8 $\mathbf{T} := T_L(\mathbf{y})$; $\{\text{вычислить } \nabla f(\mathbf{T})\}$;

9 $s := L(\mathbf{y} - \mathbf{T}) - [\nabla f(\mathbf{y}) - \nabla f(\mathbf{T})]$;


10 если $\langle s, \mathbf{y} - \mathbf{T} \rangle < \frac{1}{L} \|s\|^2$ то $L := \gamma_u L$;

11 пока неверно, что $\langle s, \mathbf{y} - \mathbf{T} \rangle \geq \frac{1}{L} \|s\|^2$;


12 $\mathbf{x}_{k+1} := \mathbf{T}$; $A_{k+1} := A_k + a$; $L_{k+1} := \max\left(L_0, \frac{L}{\gamma_d}\right)$;

13 если $\langle \mathbf{y} - \mathbf{x}_{k+1}, \mathbf{x}_{k+1} - \mathbf{x}_k \rangle > 0$ то $\mathbf{x}_{k+1} := \mathbf{x}_k$; $A_{k+1} := 0$;


Траектория метода без рестарта




Траектория метода с рестартом




Траектория метода с рестартом ($k = 20$)




Траектория метода с рестартом ($k = 21$)




Траектория метода с рестартом ($k = 22$): рестарт




Траектория метода без рестарта ($k = 22$)




Траектория метода без рестарта ($k = 23$): мимо




Траектория метода без рестарта ($k = 24$)




Траектория метода без рестарта ($k = 25$)




Траектория метода без рестарта ($k = 30$): разворот




Траектория метода без рестарта ($k = 31$): обратно




Траектория метода без рестарта ($k = 32$): обратно




Траектория метода без рестарта ($k = 33$): обратно



Траектория метода без рестарта ($k = 34$): обратно



Траектория метода без рестарта ($k = 35$): обратно



- 1 Корректность данной схемы доказана лишь в случае квадратичной функции. Корректность для неквадратичных функций является открытым вопросом.
- 2 На практике схема адаптивного рестарта почти всегда дает ускорение в сходимости и работает гораздо лучше схемы рестарта с фиксированным периодом.

- 1 Введение
 - Задачи и методы оптимизации
 - Основные теоретические сведения
- 2 Метод градиентного спуска
 - Стандартный метод для гладких функций
 - Метод для составных функций и автоматический подбор L
- 3 Быстрый градиентный метод
 - Метод для составных функций
 - Рестарт
 - Модификация подбора L и выбор L_0
- 4 Эксперименты и выводы
 - Эксперименты
 - Выводы

Схема автоматического подбора L : модификация

Текущая схема подбора L :

- 1 $L := L_k$;
- 2 **повторять**
- 3 {вычислить точки \mathbf{y} и $\mathbf{T} = T_L(\mathbf{y})$ };
- 4 $\mathbf{s} := L(\mathbf{y} - \mathbf{T}) - [\nabla f(\mathbf{y}) - \nabla f(\mathbf{T})]$;
- 5 если $\langle \mathbf{s}, \mathbf{y} - \mathbf{T} \rangle < \frac{1}{L} \|\mathbf{s}\|^2$ то $L := \gamma_u L$;
- 6 **пока неверно**, что $\langle \mathbf{s}, \mathbf{y} - \mathbf{T} \rangle \geq \frac{1}{L} \|\mathbf{s}\|^2$;
- 7 $L_{k+1} := \max\left(L_0, \frac{L}{\gamma_d}\right)$;

Предлагается вместо условия выхода из цикла $\langle \mathbf{s}, \mathbf{y} - \mathbf{T} \rangle \geq \frac{1}{L} \|\mathbf{s}\|^2$ использовать следующее стандартное условие для L :

$$f(\mathbf{T}) \leq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2.$$

(Как в обычном градиентном спуске.)

Модифицированная схема автоматического подбора L

- 1 $L := L_k$;
- 2 повторять
- 3 {вычислить точки \mathbf{y} и $\mathbf{T} = T_L(\mathbf{y})$ };
- 4 если $f(\mathbf{T}) > f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2$ то
- 5 | $L := \gamma_u L$;
- 6 пока неверно, что $f(\mathbf{T}) \leq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2$;
- 7 $L_{k+1} := \max\left(L_0, \frac{L}{\gamma_d}\right)$;

На практике эта схема работает лучше, чем предыдущая.

Начальное приближение L_0

- 1 Как выбирать начальное приближение L_0 ?
- 2 Текущая схема требует только одно условие: $L_0 < L_f$.
- 3 Чем сильнее L_0 недооценивает L в области, в которой находится x_0 , тем больше схема «разогревается» и «простраивает» вначале.

Пример

Пусть $L_0 = 1$, а L в области, в которой находится x_0 , равно 100; $\gamma_u = 2$. Тогда процедура подбора L на первом шаге метода совершит 7 итераций внутреннего цикла (14 вызовов функции) прежде, чем будет получена точка x_1 .

- 4 На практике имеет смысл выбрать L_0 , которое будет переоценивать локальное L , чтобы метод сразу же начал «шагать». Чтобы это было возможно, потребуется небольшая модификация схемы.

Модификация, позволяющая выбрать большое L_0

- 1 $L := L_k$;
- 2 повторять
- 3 {вычислить точки \mathbf{y} и $\mathbf{T} = T_L(\mathbf{y})$ };
- 4 если $f(\mathbf{T}) > f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2$ то
- 5 | $L := \gamma_u L$;
- 6 пока неверно, что $f(\mathbf{T}) \leq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2$;
- 7 $L_{k+1} := \frac{L}{\gamma_d}$;

На практике

- ① $L_0 = L_f$, если глобальная константа Липшица L_f известна;
- ② $L_0 = 500$, если L_f неизвестно.

Итоговый алгоритм быстрого градиентного метода

Вход: $\mathbf{x}_0 \in \mathbb{R}^n$, $L_0 > 0$, $\gamma_u > 1$, $\gamma_d \geq 1$;

1 $A_0 := 0$;

2 для $k = 0, 1, 2, \dots$

3 $L := L_k$;

4 повторять

5 {найти a из уравнения $\frac{a^2}{2(A_k+a)} = \frac{1}{L}$ };

6 {вычислить $\mathbf{v}_k = \arg \min_{\mathbf{x} \in \mathbb{R}^n} \psi_k(\mathbf{x})$ };

7 $\mathbf{y} := \frac{A_k \mathbf{x}_k + a \mathbf{v}_k}{A_k + a}$; {вычислить $\nabla f(\mathbf{y})$ };

8 $\mathbf{T} := T_L(\mathbf{y})$; {вычислить $\nabla f(\mathbf{T})$ };

9 если $f(\mathbf{T}) > f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2$ то

10 | $L := \gamma_u L$;

11 пока неверно, что $f(\mathbf{T}) \leq f(\mathbf{y}) + \langle \nabla f(\mathbf{y}), \mathbf{T} - \mathbf{y} \rangle + \frac{L}{2} \|\mathbf{T} - \mathbf{y}\|^2$;


12 $\mathbf{x}_{k+1} := \mathbf{T}$; $A_{k+1} := A_k + a$; $L_{k+1} := \frac{L}{\gamma_d}$;

13 если $\langle \mathbf{y} - \mathbf{x}_{k+1}, \mathbf{x}_{k+1} - \mathbf{x}_k \rangle > 0$ то $\mathbf{x}_{k+1} := \mathbf{x}_k$; $A_{k+1} := 0$;

Рекомендуемые параметры: $L_0 = 500$ (или L_f), $\gamma_u = 2$, $\gamma_d = 1.1$.


- 1 Введение
 - Задачи и методы оптимизации
 - Основные теоретические сведения
- 2 Метод градиентного спуска
 - Стандартный метод для гладких функций
 - Метод для составных функций и автоматический подбор L
- 3 Быстрый градиентный метод
 - Метод для составных функций
 - Рестарт
 - Модификация подбора L и выбор L_0
- 4 Эксперименты и выводы
 - Эксперименты
 - Выводы

Схемы автоматического подбора L




Логистическая регрессия с L_1 -регуляризатором,
 $\tau = 0.0001$, 500 объектов, 4 933 признаков.

Градиентный спуск и быстрый градиентный метод




Логистическая регрессия с L_2 -регуляризатором,
 $\tau = 0.001$, 100 объектов, 4 933 признаков.

Градиентный спуск и быстрый градиентный метод – 2




Квадратичная функция,
 $n = 200, \mu = 0.01, L = 10$.



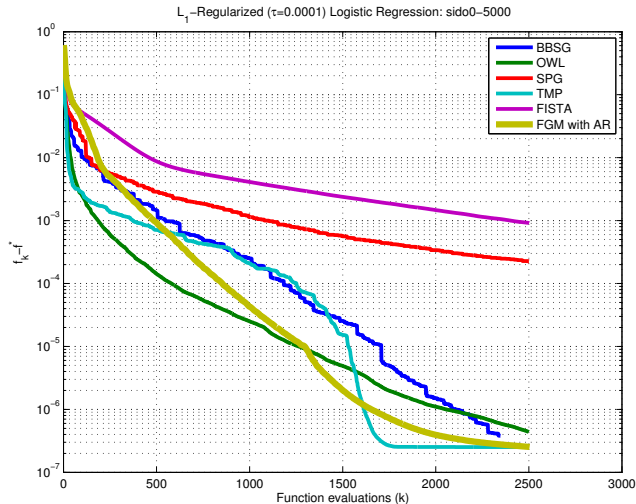
Квадратичная функция,
 $n = 200, \mu = 0.01, L = 10.$

Быстрый градиентный метод и L-BFGS




Логистическая регрессия с L_2 -регуляризатором,
 $\tau = 0.001$, 1 000 объектов, 4 933 признаков.

Быстрый градиентный метод и другие методы



Логистическая регрессия с L_1 -регуляризатором,
 $\tau = 0.0001$, 5 000 объектов, 4 933 признаков.

Быстрый градиентный метод и PSSas



Логистическая регрессия с L_1 -регуляризатором,
 $\tau = 0.0001$, 5 000 объектов, 4 933 признаков.

- 1 Введение
 - Задачи и методы оптимизации
 - Основные теоретические сведения
- 2 Метод градиентного спуска
 - Стандартный метод для гладких функций
 - Метод для составных функций и автоматический подбор L
- 3 Быстрый градиентный метод
 - Метод для составных функций
 - Рестарт
 - Модификация подбора L и выбор L_0
- 4 Эксперименты и выводы
 - Эксперименты
 - Выводы

- 1 Быстрый градиентный метод работает на порядок быстрее обычного градиентного метода.
- 2 Как и обычный градиентный спуск, быстрый градиентный метод легко обобщается на случай составных функций, что позволяет решать гладкие задачи с простой негладкой добавкой.
- 3 Метод можно обобщить на случай выпуклых задач с гладкими ограничениями. Однако итоговая схема получится существенно сложнее и уже будет иметь некоторую другую скорость сходимости.
- 4 Несмотря на то, что методы типа L-BFGS не имеют хороших гарантий сходимости, в отличие от быстрого градиентного метода, на практике они работают существенно быстрее последнего.

- 1 Ускорение текущей версии метода за счет
 - модификации градиентного шага: более хорошая схема подбора L , шаг типа L-BFGS и т. п.;
 - модификации оценочных функций: например, оценка с помощью пучка (англ. bundle).
- 2 Обобщение метода для невыпуклых функций.
- 3 Обобщение метода на стохастический случай.