

Лекции по Методам оптимизации 4 семестр

Луа Yaroshevskiy

21 ноября 2024 г.

Оглавление

Лекции 1 и 2	4
1.1 Теория погрешности	4
1.1.1 Значащие цифры	4
1.1.2 Верные цифры	5
1.1.3 Распространение погрешности	5
1.2 Одномерная минимизация функций	6
1.2.1 Унимодальные функции	6
1.2.2 Прямые методы	7
Лекция 3	9
3.1 Одномерный поиск	9
3.1.1 Метод золотого сечения	9
3.1.2 Метод Фибоначчи	10
3.1.3 Метод парабол	11
Лекция 4	12
4.1 Одномерная оптимизация	12
4.1.1 Определение интервала неопределенности	12
4.2 Методы с использованием производной	13
4.2.1 Метод средней точки	13
4.2.2 Метод хорд(метод секущей)	13
4.2.3 Метод Ньютона(метод касательной)	14
Лекция 5	16
5.1 Метод Ньютона(продолжение). Вывод через ряд Тейлора	16
5.1.1 Аппроксимация производных	17
5.1.2 Метод Ньютона(продолжение)	17
5.1.3 Модификации метода Ньютона	18
5.1.4 Метод минимизации многомодальных функций	18
Лекция 6	20
6.1 Постановка задачи	20
6.1.1 Свойства квадратичных форм	21
6.1.2 Свойства выпуклых множеств и выпуклых функций	21
6.1.3 Необходимое и достаточное условие безусловного экстремума	22

Лекция 7	23
7.1 Критерии Сильвестра	23
7.1.1 Достаточный условия	23
7.1.2 Необходимые условия	23
7.2 Собственные значения	23
7.3 Общие принципы многомерной оптимизации	23
7.3.1 Выпуклые квадратичные функции	23
7.3.2 Принципы многомерной оптимизации	24
Лекция 8	27
8.1 Метод градиентного спуска	27
8.2 Метод наискорейшего спуска	30
Лекция 9	32
9.1 Метод сопряженных градиентов	32
9.2 Метод стохастического градиентного спуска	33
9.2.1 Adagrad (модификация)	33
9.3 Метод покоординатного спуска	34
Лекция 10	35
10.1 Формы хранения матриц	35
10.1.1 Диагональный	35
10.1.2 Ленточный формат	36
10.1.3 Профильный формат	36
Лекция 11	38
11.1 Разреженный формат	38
11.1.1 Строчно столбцовый формат	38
11.1.2 Решение СЛАУ. Метод Гаусса	39
11.1.3 Обратный ход Гаусса	40
Лекция 12	41
12.1 Прямые методы решения СЛАУ	41
12.1.1 Близкие к нулю главные элементы	42
12.1.2 Вектор ошибки и невязка	42
12.1.3 Векторные нормы	43
Лекция 13	45
13.1 Число обусловленности	45
13.1.1 Нормы и анализ ошибок	45
13.1.2 Оценивание числа обусловленности	46
13.2 Дополнительно о градиентных методах	47
13.2.1 Градиентный спуск	47
13.2.2 Модификация	48
Лекция 14	49
14.1 Минимизация квадратичной функции	49
14.1.1 Минимизация с использованием исчерпывающего спуска	51
14.1.2 Метод сопряженных направлений	52
14.1.3 Модификации	56

14.1.4 Выводы	57
Лекция 15	59
15.1 Метод Ньютона	59
15.1.1 Сходимость метода Ньютона	60
15.1.2 Метод Ньютона с одномерным поиском	60
15.1.3 Метод Ньютона с направлением спуска	61
15.1.4 Метод Ньютона с дроблением шага	61
15.1.5 О сходимости	62
15.2 Метод Марквардта	62
15.2.1 Идея метода	63
15.2.2 Реализация	63
15.2.3 Другая вариация метода	64
Лекция 16	65
16.1 Квазиньютоновские методы	65
16.1.1 Общий вид релаксационной последовательности	65
16.1.2 Свойства метода ДФП	67
16.1.3 Метод Бroyдена-Флетчера-Шенно (БФШ-метод)	68
16.1.4 Метод Пауэлла	68
16.1.5 Способы построения G_k	68
16.2 Сравнение методов	68
16.2.1 Сравнение по скорости	68
16.2.2 Оценка эффективности	69

Лекции 1 и 2

1.1 Теория погрешности

Отклонение от теоретического решения Виды погрешности:

1. Неустраняемая погрешность

Пример. Физические величины, другие константы

2. Устраняемая погрешность Связана с методом решения

(а) Погрешность модели

Связана с математической формулировкой задачи. Она плохо отображает реальную модель

(б) Остаточная погрешность (Погрешность аппроксимации)

(с) Погрешность округления

(д) Накапливаемая погрешность

Нецелые числа

-
- X^* — точное решение
 - X — Приближенное решение
 - $X^* - X$ — погрешность
 - $\Delta X = |X^* - X|$ — абсолютная погрешность
 $\Delta_X \geq |X^* - X|$ — предельная абсолютная погрешность, т.е.

$$X - \Delta_X \leq X^* \leq X + \Delta_X$$

- $\delta X = \left| \frac{X^* - X}{|X|} \right|$ — относительная погрешность
 $\delta_X \geq \left| \frac{X^* - X}{|X|} \right|$ — предельная относительная погрешность

1.1.1 Значащие цифры

Определение. Все цифры в изображении отличные от нуля, и нули если они содержатся между значащими цифрами, или расположены в конце числа и указывают на сохранение разряды точности. Нули стоящие левее, отличной от нуля цифры, не являются значащими-цифрами Между ненулевыми, или указывающие на точность

Пример. $\underbrace{0.00}_{\text{незнач.}} 2080$

Пример. $689000 = 0.689 \cdot 10^6$ — 3 значащие цифры $689000 = 0.689000 \cdot 10^6$ — 6 значащих цифр

1.1.2 Верные цифры

Если, значащая цифра приближенного значения, находящаяся в разряде, в котором выполняется условие — абсолютное значение погрешности не превосходит половину единицы этого разряда $\Delta \leq 0.5 \cdot 10^k$, где k — номер разряда, то она называется верной

Пример. $a = 3.635$

$\Delta a = 0.003$

$$(3) \quad k = 0 \quad \frac{1}{2} \cdot 10^0 = \frac{1}{2} \geq \Delta a$$

$$(6) \quad k = -1 \quad \frac{1}{2} \cdot 10^{-1} = 0.05 \geq \Delta a$$

$$(3) \quad k = -2 \quad \frac{1}{2} \cdot 10^{-2} = 0.005 \geq \Delta a$$

$$(5) \quad k = -3 \quad \frac{1}{2} \cdot 10^{-3} = 0.0005 < \Delta a \Rightarrow 5 \text{ — сомнительная цифра}$$

1.1.3 Распространение погрешности

Пример. $\left(\frac{\sqrt{2}-1}{\sqrt{2}+1}\right)^3 = (\sqrt{2}-1)^6 = (3-2\sqrt{2})^3 = 99 - 70\sqrt{2}$

$\sqrt{2}$

$$\frac{7}{5} = 1.4$$

$$\frac{17}{12} = 1.41666$$

$$\frac{707}{500} = 1.414$$

$$\sqrt{2} = 1.4142145624$$

$$\Delta_{x \pm y} = \Delta_x \pm \Delta_y$$

$$\Delta_{(x \cdot y)} \approx |Y| \Delta_X + |X| \Delta_Y$$

$$\Delta_{\left(\frac{x}{y}\right)} \approx \left|\frac{1}{Y}\right| \Delta_X + \left|\frac{X}{Y^2}\right| \Delta_Y$$

$$|\Delta u| = |f(x_1 + \Delta x_1, \dots, x_n + \Delta x_n) - f(x_1, \dots, x_n)|$$

$$|\Delta u| \approx |df(x_1, \dots, x_n)| = \left| \sum_{i=1}^n \frac{\partial u}{\partial x_i} \Delta x_i \right| \leq \sum_{i=1}^n \left| \frac{\partial u}{\partial x_i} \right| \cdot |\Delta x_i| \quad (1.1)$$

$$|\delta u| = \frac{1.1}{|u|} = \sum_{i=1}^n \left| \frac{\partial u}{\partial x_i} \cdot \frac{1}{u} \right| \cdot |\Delta x_i| = \sum_{i=1}^n \left| \frac{\partial \ln u}{\partial x_i} \right| \cdot |\Delta x_i|$$

$$\delta_u = \sum_{i=1}^n \left| \frac{\partial \ln u}{\partial x_i} \right| \cdot |\Delta x_i|$$

$$\delta_{(X \pm Y)} = \left| \frac{X}{X \pm Y} \right| \delta_X + \left| \frac{Y}{X \pm Y} \right| \delta_Y$$

$$\delta_{(X \cdot Y)} = \delta_X + \delta_Y$$

$$\delta_{\left(\frac{X}{Y}\right)} = \delta_X + \delta_Y$$

Пример. $x = \frac{7}{5}$

- $f_1 = \left(\frac{\sqrt{2}-1}{\sqrt{2}+1}\right)$

$$\delta_{f_1} = 3 \left| \frac{1}{x-1} - \frac{1}{x+1} \right| \cdot |\Delta X| = 6.25|\Delta X|$$

- $f_2 = (\sqrt{2} - 1)^6$

$$\delta_{f_2} = 6 \left| \frac{1}{x-1} \right| \cdot |\Delta X| = 15|\Delta X|$$

- $f_3 = (3 - 2\sqrt{2})^3$

$$\delta_{f_3} = 6 \left| \frac{1}{3-2x} \right| \cdot |\Delta X| = 30|\Delta X|$$

- $f_4 = 99 - 70\sqrt{2}$

$$\delta_{f_4} = \left| \frac{90}{99-70x} \right| \cdot |\Delta X| = 70|\Delta X|$$

Пример.

$$y^2 - 140y + 1 = 0$$

Вычислить корни.

- $y = 70 - \sqrt{4899}$
 $\sqrt{4899} = 69.992\dots$
 $\sqrt{4899} \approx 69.99$
 $y \approx 70 - 69.99 = 0.01$

$$y = \frac{1}{70 + \sqrt{4899}}$$

$$\sqrt{4899} = 69.99; 70 + 69.99 = 139.99$$

$$y = \frac{1}{140} = 0.00714285 \approx 0.007143$$

1.2 Одномерная минимизация функций

1.2.1 Унимодальные функции

$$f(x) \rightarrow \min, x \in U$$

$$f(x) \rightarrow \max \Rightarrow -f(x) \rightarrow \min$$

$$x^* \in U - \text{точка минимума: } f(x^*) \leq f(x) \forall x \in U$$

U^* — множество точек минимума

$\tilde{x} \in U : \exists V(\tilde{x}) \forall x \in V f(\tilde{x}) \leq f(x)$ — локальный минимум

Определение. $f(x)$ — унимодальная функция на $[a, b]$, если:

1. $f(x)$ — непрерывна на $[a, b]$
2. $\exists \alpha, \beta : a \leq \alpha \leq \beta \leq b$
 - (а) Если $a < \alpha$, то $[a, \alpha]$ $f(x)$ — монотонно убывает
 - (б) Если $\beta < b$, то на $[\beta, b]$ $f(x)$ — монотонно возрастает
 - (с) $\forall x \in [\alpha, \beta] f(x) = f^* = \min_{[a, b]} f(x)$

Замечание. Свойства:

1. Любая из точек локального минимума является глобальным минимумом на этом же отрезке
2. Функция унимодальная на $[a, b]$ унимодальна на $[c, d] \subset [a, b]$
3. $f(x)$ унимодальна на $[a, b]$ $a \leq x_1 < x_2 \leq b$
 - (а) если $f(x_1) \leq f(x_2)$, то $x^* \in [a, x_2]$
 - (б) если $f(x_1) > f(x_2)$, то $x^* \in [x_1, b]$

Определение. $f(x)$ выпукла на $[a, b]$, если:

- $\forall x', x'' \in [a, b]$ и $\alpha \in [0, 1]$:

$$f(\alpha x' + (1 - \alpha)x'') \leq \alpha f(x') + (1 - \alpha)f(x'')$$

Замечание. Свойства:

1. Если $f(x)$ на $[a, b]$ $[x', x''] \subset [a, b]$
2. Всякая выпуклая и непрерывная функция на $[a, b]$ является унимодальной на этом отрезке. Обратное не верно

Определение. $x : f'(x) = 0$ — стационарная точка

1.2.2 Прямые методы

Не требуют вычисления производной. Могут использовать только известные значения.

1. Метод дихотомии

$$x_1 = \frac{b + a - \delta}{2} \quad x_2 = \frac{b + a + \delta}{2} \tag{1.2}$$

$$\tau = \frac{b - x_1}{b - a} = \frac{x_2 - a}{b - a} \rightarrow \frac{1}{2}$$

$$X^*[a_i, b_i] \quad \frac{b_i - a_i}{2} \leq \varepsilon$$

- (а) x_1 и x_2 ; вычислить $f(x_1)$ и $f(x_2)$
- (б) $f(x_1)$ и $f(x_2)$
 - Если $f(x_1) \leq f(x_2) \rightarrow [a, x_2]$, т.е. $b = x_2$
 - Иначе $[x_1, b] \rightarrow [x_1, b]$, т.е. $a = x_1$

(c) $\varepsilon_n = \frac{b-a}{2^n}$ (n — номер итерации)

- Если $\varepsilon_n > \varepsilon$ — переход к следующей итерации (шаг 1)
- Если $\varepsilon_n \leq \varepsilon$, завершить поиск (шаг 4)

(d) $x^* \approx \bar{x} = \frac{a+b}{2}$ $f^* \approx f(\bar{x})$

1.2 $\delta \in (0, 2\varepsilon)$

Число итераций $n \geq \log_2 \frac{b-a-\delta}{2\varepsilon-\delta}$

Лекция 3

3.1 Одномерный поиск

3.1.1 Метод золотого сечения

Замечание. Возьмем отрезок $[0, 1]$

- $x_2 = \tau \Rightarrow x_1 = 1 - \tau$
- $x_1 \Rightarrow x'_2 = 1 - \tau \in [0, \tau]$

$$\frac{1}{\tau} = \frac{\tau}{1 - \tau} \Rightarrow \tau^2 = 1 - \tau$$

$$\tau = \frac{\sqrt{5} - 1}{2} \approx 0.61803$$

- $x_1 = 1 - \tau = \frac{3 - \sqrt{5}}{2}$
 - $x_2 = \tau = \frac{\sqrt{5} - 1}{2}$
1. $x_1 = a + \frac{3 - \sqrt{5}}{2}(b - a)$
 2. $x_2 = a + \frac{\sqrt{5} - 1}{2}(b - a)$

$$\Delta_n = \tau^n(b - a)$$

$$\varepsilon_n = \frac{\Delta_n}{2} = \frac{1}{2} \left(\frac{\sqrt{5} - 1}{2} \right)^n (b - a)$$

ε — задано. Окончание: $\varepsilon_n \leq \varepsilon$

На n -ой итерации: $x^* = \frac{a_{(n)} + b_{(n)}}{2}$

$$n \geq \frac{\ln \left(\frac{2\varepsilon}{b-a} \right)}{\ln \tau} \approx 2.1 \ln \left(\frac{b-a}{2\varepsilon} \right)$$

Алгоритм.

1. x_1, x_2 по формулам 1 и 2

$$\tau = \frac{\sqrt{5} - 1}{2} \quad \varepsilon_n = \frac{b - a}{2}$$

2. $\varepsilon_n > \varepsilon$ — шаг 3, иначе 4

3. Если $f(x_1) \leq f(x_2)$, то:

- запоминаем $f(x_1)$
- $b = x_1$
- $x_2 = x_1$
- $x_1 = a + \tau(b - a)$

Иначе:

- запоминаем $f(x_2)$
- $a = x_1$
- $x_1 = x_2$
- $x_2 = b - \tau(b - a)$

$\varepsilon_n = \tau\varepsilon_n$, переход к шагу 2

4. $x^* = \bar{x} = \frac{a^{(n)} + b^{(n)}}{2}$
 $f^* \approx f(\bar{x})$

3.1.2 Метод Фибоначчи

$$F_{n+2} = F_{n+1} + F_n, \quad n = 1, \quad F_1 = F_2 = 1$$

$$F_n = \left(\left(\frac{1 + \sqrt{5}}{2} \right)^n - \left(\frac{1 - \sqrt{5}}{2} \right)^n \right) \cdot \frac{1}{\sqrt{5}}$$

$$F_n \approx \left(\frac{1 + \sqrt{5}}{2} \right)^n \cdot \frac{1}{\sqrt{5}} \quad n \rightarrow \infty$$

Итерация 0:

- $x_1 = a + \frac{F_n}{F_{n+2}}(b - a)$
- $x_2 = a + \frac{F_{n+1}}{F_{n+2}}(b - a) = a + b - x_1$

Итерация k :

•

$$x_1 = a_{(k)} + \frac{F_{n-k+1}}{F_{n-k+3}}(b_k - a_k) = a_k + \frac{F_{n-k+1}}{F_{n+2}}(b_0 - a_0)$$

•

$$x_2 = a_{(k)} + \frac{F_{n-k+2}}{F_{n-k+3}}(b_k - a_k) = a_k + \frac{F_{n-k+2}}{F_{n+2}}(b_0 - a_0)$$

Итерация n :

- $x_1 = a_n + \frac{F_1}{F_{n+1}}(b_0 - a_0)$
- $x_2 = a_n + \frac{F_2}{F_{n+2}}(b_0 - a_0)$

$$\frac{b_0 - a_0}{2} = \frac{b_0 - a_0}{F_{n+2}} < \varepsilon$$

Как выбирать n :

$$\frac{b_0 - a_0}{\varepsilon} < F_{n+2}$$

Когда n большое $\Rightarrow \frac{F_n}{F_{n+2}}$ — бесконечная десятичная дробь

3.1.3 Метод парабол

- $x_1, x_2, x_3 \in [a, b]$
- $x_1 < x_2 < x_3$
- $f(x_1) \geq f(x_2) \leq f(x_3)$

$$q(x) = a_0 + a_1(x - x_1) + a_2(x - x_1)(x - x_2)$$

- $q(x_1) = f(x_1) = f_1$
- $q(x_2) = f(x_2) = f_2$
- $q(x_3) = f(x_3) = f_3$
- $a_0 = f_1$
- $a_1 = \frac{f_2 - f_1}{x_2 - x_1}$
- $a_2 = \frac{1}{x_3 - x_2} \left(\frac{f_3 - f_1}{x_3 - x_1} - \frac{f_2 - f_1}{x_2 - x_1} \right)$

$$\bar{x} = \frac{1}{2} \left(x_1 + x_2 - \frac{a_1}{a_2} \right) \text{ — минимум параболы } q(x)$$

Лекция 4

$$\frac{l_{\text{з.с.}}^i}{l_{\text{дик.}}^i} \approx (0.87\dots)^n$$
$$\frac{l_{\text{з.с.}}^i}{l_{\text{Фиб.}}^i} \approx 1.17$$

4.1 Одномерная оптимизация

4.1.1 Определение интервала неопределенности

x_0

1. Если $f(x_0) > f(x_0 + \delta)$, то:

- $k = 1$
- $x_1 = x_0 + \delta$
- $h = \delta$

иначе если $f(x_0) > f(x_0) - \delta$, то:

- $x_1 = x_0 - \delta$
- $h = -\delta$

2. Удваиваем h :

- $h = 2h$
- $x_{k+1} = x_k + h$

3. Если $f(x_k) > f(x_{k+1})$, то:

- $k = k + 1$
- переходим к шагу 2

Иначе:

- прекращаем поиск $[x_{k-1}, x_{k+1}]$

4.2 Методы с использованием производной

- $f(x)$ — дифференцируемая или дважды дифференцируемая выпуклая функция
- вычисление производных в заданных точках

$f'(x) = 0$ — необходимое и достаточное условие глобального минимума. Если $x^* \in [a, b]$ $f'(x) \approx 0$ или $f'(x) \leq \varepsilon$ — условие остановки вычислений

4.2.1 Метод средней точки

$$f'(x) \quad \bar{x} = \frac{a+b}{2}$$

- Если $f'(\bar{x}) > 0$, то $\bar{x} \in$ монотонно возрастающая $f(x)$, минимум на $[a, \bar{x}]$
- Если $f'(\bar{x}) < 0$ минимум на $[\bar{x}, b]$
- Если $f'(\bar{x}) = 0$ то $x^* = \bar{x}$

Алгоритм

1. $\bar{x} = \frac{a+b}{2}$, вычислим $f'(\bar{x}) \rightarrow$ шаг 2
2. Если $|f'(\bar{x})| \leq \varepsilon$, то $x^* = \bar{x}$ и $f(x^*) = f(\bar{x}) \rightarrow$ завершить
3. Сравнить $f'(\bar{x})$ с нулем:
 - Если $f'(\bar{x}) > 0$, то $[a, \bar{x}]$, $b = \bar{x}$
 - Иначе $[\bar{x}, b]$, $a = \bar{x}$

\rightarrow шаг 1

$$\Delta_n = \frac{b-a}{2^n}$$

4.2.2 Метод хорд(метод секущей)

Если на концах $[a, b]$ $f'(x)$: $f'(a) \cdot f'(b) < 0$ и непрерывна, то на (a, b) $\exists x$ $f'(x) = 0$

$f(x)$ — минимум на $[a, b]$, если $f'(x) = 0$, $x \in (a, b)$

$F(x) = f'(x) = 0$ на $[a, b]$

$F(a) \cdot F(b) < 0$, \bar{x} — точка пересечения $F(x)$ с осью Ox на $[a, b]$

$$\bar{x} = a - \frac{f'(a)}{f'(a) - f'(b)}(a - b) \quad (4.1)$$

$x^* \in [a, \tilde{x}]$ либо $[\tilde{x}, b]$

Алгоритм

1. \tilde{x} — вычислим по 4.1
вычислим $f'(\tilde{x}) \rightarrow$ шаг 2
2. Если $|f'(\tilde{x})| \leq \varepsilon$, то:
 - $x^* = \tilde{x}$

- $f^* = f(\tilde{x})$
- завершить

Иначе:

- \rightarrow шаг 3

3. Переход к новому отрезку. Если $f'(\tilde{x}) > 0$, то:

- $[a, \tilde{x}]$
- $b = \tilde{x}$
- $f'(b) = f'(\tilde{x})$

Иначе:

- $[\tilde{x}, b]$
- $a = \tilde{x}$
- $f'(a) = f'(\tilde{x})$

\rightarrow шаг 1

Исключение.

1. $f'(a) \cdot f'(b) > 0$, $f(x)$ — возрастает

- $x^* = a$
- $x^* = b$

2. $f'(a) \cdot f'(b)$, **одно из:**

- $x^* = a$
- $x^* = b$

4.2.3 Метод Ньютона(метод касательной)

Если выпуклая на $[a, b]$ функция $f(x)$ — дважды непрерывно дифференцируема, то $x^* \in [a, b] : f'(x) = 0$

Пусть $x_0 \in [a, b]$ — начальное приближение к x^*

$F(x) = f'(x)$ — линеаризуем в окрестности x_0

$(x_0, f'(x_0))$, то есть:

$$F(x) \approx F(x_0) + F'(x_0)(x - x_0)$$

x_1 —

- следующее приближение к x^*
- пересечение касательной с Ox

При $x = x_1$:

$$F(x_0) + F'(x_0)(x_1 - x_0) = 0$$

$$x_1 = x_0 - \frac{F(x_0)}{F'(x_0)}$$

$\{x_k\}$, $k = 1, 2, \dots$ — итерационная последовательность
 $F(x)$ в точке $x = x_k$ имеет вид:

$$y = F(x_k) + F'(x_k)(x - x_k)$$

$x = x_{k+1}$ $y = 0$:

$$x_{k+1} = x_k - \frac{F(x_k)}{F'(x_k)}$$

$$f'(x) = 0 \quad x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}, \quad k = 1, 2, \dots$$

Итерационный процесс: $|f'(x_k)| \leq \varepsilon$:

- $x^* \approx x$
- $x^* \approx f(x_k)$

Лекция 5

5.1 Метод Ньютона(продолжение). Вывод через ряд Тейлора

- x_k — текущая оценка решения x^*

$$f(x_k + p) = f(x_k) + pf'(x_k) + \frac{1}{2!}p^2 f''(x_k) + \dots$$

$$f(x^*) = \min_x f(x) = \min_p f(x_k + p) = \min_p [f(x_k) + pf'(x_k) + \frac{1}{2}p^2 f''(x_k) + \dots] \approx$$

$$\approx \min_p [f(x_k) + pf'(x_k) + \frac{1}{2}p^2 f''(x_k)]$$

$$f'(x_k) + pf''(x_k) = 0$$

$$p = -\frac{f'(x_k)}{f''(x_k)}$$

p — аппроксимация шага: от $x_k \rightarrow x^*$. $x^* \approx x_k + p$

$$x_{k+1} = x_k + p = x_k - \frac{f'(x_k)}{f''(x_k)} \quad (5.1)$$

Главное преимущество метода Ньютона:

- высокая(квадратичная) скорость сходимости
– если x_k достаточно близка x^* и если $f''(x^*) > 0$, то:

$$|x_{k+1} - x^*| \leq \beta |x_k - x^*|^2, \quad \beta = const > 0$$

Неудачи в методе Ньютона:

1. $f(x)$ плохо аппроксимируется первыми тремя членами в ряде Тейлора. x_{k+1} может быть хуже x_k
2. $p = -\frac{f'(x_k)}{f''(x_k)}$ определено только тогда, когда $f''(x_k) \neq 0$
 $f''(x_k) > 0$ — условие минимума квадратичной аппроксимации
Если $f''(x_k) < 0$ — алгоритм сходится к максимуму
3. Кроме $f(x)$ нужно вычислять $f'(x)$ и $f''(x)$, что в реальных задачах затруднительно

5.1.1 Аппроксимация производных

Правая разностная схема:

$$f'(x_k) \approx \frac{f(x_k + h) - f(x_k)}{h}, \quad h \sim \varepsilon$$

Центральная разностная схема:

$$f'(x_k) \approx \frac{f(x_k + h) - f(x_k - h)}{2h}$$

порядок точности — $O(h^2)$

5.1.2 Метод Ньютона(продолжение)

Если $f(x)$ — квадратичная функция, то $f'(x)$ — линейная

В 5.1 точное равенство, и следовательно метод Ньютона сходится за один шаг, при любом выборе x

Пусть $x^* \in [a, b]$ и $f(x)$ — трижды непрерывно дифференцируемая и выпуклая на $[a, b]$ функция.

$\{x_k\}$ будет сходиться к пределу x^* монотонно, если:

$$0 < \frac{x^* - x_{k+1}}{x^* - x_k} < 1$$

$$f'(x^*) = 0 = f'(x_k) + f''(x_k)(x^* - x_k) + \frac{f'''(x_k)}{2}(x^* - x_k)^2$$

$$\frac{x^* - x_{k+1}}{x^* - x_k} = \frac{x^* - x_k + \frac{f'(x_k)}{f''(x_k)}}{x^* - x_k} = 1 - \frac{2}{2 + \frac{f'''(x)(x^* - x_k)^2}{f'(x_k)}}$$

Итерационная последовательность $\{x_k\}$ монотонна, если $\frac{f'''(x)}{f'(x_k)} > 0$, то есть достаточное условие монотонной сходимости метода Ньютона: постоянство x in $[x^*, x_0]$ знака $f'''(x)$ и совпадение его со знаком $f'(x^0)$

Пример.

$$f(x) = x \cdot \operatorname{arctg}(x) - \frac{1}{2} \ln(1 + x^2)$$

, пусть $|f'(x)| \leq 10^{-7}$

$$f'''(x) = -\frac{2x}{(1 + x^2)^2}$$

$$f'(x)''(x) < 0$$

Выбор начального приближение $x_0 = 1$

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k)}$$

k	x_k	$f'(x_k)$	$f''(x_k)$
0	1	0.785	$\frac{1}{2}$
1	-0.57	-0.518	0.754
2	0.117	0.116	...
3
4	$9 \cdot 10^{-8}$	$9 \cdot 10^{-8}$...

Выполнилось условие $|f'(x_k)| \leq 10^{-7}$ — окончание итерационного процесса. $x \approx 9 \cdot 10^{-8} \approx 0$

5.1.3 Модификации метода Ньютона

1. Метод Ньютона-Рафсона

$$x_{k+1} = x_k - \tau_k \frac{f'(x_k)}{f''(x_k)}, \quad 0 < \tau_k \leq 1$$

$\tau_k = \tau = const$ ($\tau = 1$ — метод Ньютона)

$$\varphi(\tau) = f\left(x_k - \tau \frac{f'(x_k)}{f''(x_k)}\right) \rightarrow \min$$

$$\tau_k = \frac{(f'(x_k))^2}{(f'(x_k))^2 + (f'(\tilde{x}_k))^2}$$

, где $\tilde{x} = x_k - \frac{f'(x_k)}{f''(x_k)}$

2. Метод Маркрафта

$$x_{k+1} = x_k - \frac{f'(x_k)}{f''(x_k) + \mu_k}, \quad \mu_k > 0$$

μ_0 рекомендуется выбирать на порядок больше значения второй производной в x_0

μ_{k+1} : $\mu_{k+1} = \frac{\mu_k}{2}$, если $f(x_{k+1}) < f(x_k)$, иначе $\mu_{k+1} = 2 \cdot \mu_k$

5.1.4 Метод минимизации многомодальных функций

1. Метод ломанных Условие Липшица: $f(x)$, $x \in [a, b]$ будет удовлетворять условию, если:

$$|f(x_1) - f(x_2)| \leq L|x_1 - x_2|, \quad \forall x_1, x_2 \in [a, b]$$

$\forall x_1, x_2 \in [a, b]$

$$\left. \begin{aligned} x_1^* &= \frac{1}{2L}[f(a) - f(b) + L(a+b)] \\ p_1^* &= \frac{1}{2}[f(a) + f(b) + L(a-b)] \end{aligned} \right\} \text{— схема}$$

(а) вместо (x_1^*, p_1^*)

• (x'_1, p_1)

$$x'_1 = x_1^* - \Delta_1$$

• (x''_1, p_1)

$$x''_1 = x_1^* + \Delta_1$$

$$p_1 = \frac{1}{2}[f(x'_1) + p_1^*]$$

$$\Delta_1 = \frac{1}{2L}[f(x'_1) - p_1^*]$$

(b) Из пар (x'_1, p_1) , (x''_1, p_1) , выбрать ту, у которой вторая компонента p минимальна и обозначить ее (x_2^*, p_2^*) и исключить из рассматриваемого множества. Переход к шагу 1

В результате множество пар (x, p) . $x^* \approx x_n^*$, $f^* \approx f(x_n^*)$

Пример.

$$f(x) = \frac{\sin(x)}{x} \quad [10, 15] \quad \varepsilon = 0.01$$

$$|f'(x)| = \left| \frac{x \cos x - \sin x}{x^2} \right| < \frac{x |\cos x| + \sin |x|}{x^2} < \frac{x+1}{x^2} \leq 0.11 \quad x \in [10, 15]$$

$$L = 0.11$$

$$x_1^* = 12.056 \quad p_1^* = -0.281$$

Лекция 6

6.1 Постановка задачи

1. $x^* = (x_1, x_2, \dots, x_n)^T$, $x_i \in U \subset E_n$, где U — множество допустимых значений, E_n — евклидово пространство размера n . $f(x^*) = \min_{x \in U} f(x)$. Если ставится задача найти максимум, то можно перейти к поиску минимума: $f(x^*) = \max_{x \in U} f(x) = -\min_{x \in U}(-f(x))$
2. $f(x^*) = \text{extr}_{x \in U} f(x)$
3. Если U задается ограничением на вектор x , то задача поиска условного экстремума. Если $U = E_n$ — не имеет ограничений, то задача поиска безусловного экстремума
4. Решение задачи поиска экстремума — пара $(x^*, f(x^*))$

Если $\forall x \in U f(x^*) \leq f(x)$ — то x^* — глобальный минимум. Локальный минимум $x^* \in U$: если $\exists \varepsilon > 0$, что $\forall x \in U$ и $\|x - x^*\| < \varepsilon$, то $f(x^*) \leq f(x)$

Определение. Поверхностью уровня функции $f(x)$ называется множество точек, в которых функция принимает постоянные значения, т.е. $f(x) = \text{const}$

Определение. Градиентом $\nabla f(x)$ непрерывно дифференцируемой функции $f(x)$ в x :

$$\nabla f(x) = \begin{pmatrix} \frac{\partial f(x)}{\partial x_1} \\ \frac{\partial f(x)}{\partial x_2} \\ \vdots \\ \frac{\partial f(x)}{\partial x_n} \end{pmatrix}$$

Градиент направлен по нормали к поверхности уровня, т.е. перпендикулярно к касательной плоскости в точке x , проведенной в сторону наибольшего возрастания функции

Определение. Матрицей Гессе $H(x)$ дважды непрерывно дифференцируемой в точке x функции $f(x)$ называется матрица частных производных второго порядка, вычисленных в данной точке.

$$H(x) = \begin{pmatrix} \frac{\partial^2 f(x)}{\partial x_1^2} & \frac{\partial^2 f(x)}{\partial x_1 x_2} & \cdots & \frac{\partial^2 f(x)}{\partial x_1 x_n} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial^2 f(x)}{\partial x_n x_1} & \frac{\partial^2 f(x)}{\partial x_n x_2} & \cdots & \frac{\partial^2 f(x)}{\partial x_n^2} \end{pmatrix}$$

1. $H(x)$ — симметричная, размер nn

2. Антиградиент: вектор, равный по модулю вектору градиента, но противоположный по направлению. Указывает в сторону наибольшего убывания функции $f(x)$

3.

$$\nabla f(x) = f(x + \Delta x) - f(x) = \nabla f(x)^T \Delta x + \frac{1}{2} \Delta x^T H(x) \Delta x + o(\|\Delta x\|^2)$$

$o(\|\Delta x\|^2)$ — сумма всех членов разложения, имеющих порядок выше второго, $\Delta x^T H(x) \Delta x$ — квадратичная форма

6.1.1 Свойства квадратичных форм

Квадратичная форма $\Delta x^T H(x) \Delta x$ (и соответствующая матрица $H(x)$) называется:

- положительно определенной $H(x) > 0$, если $\forall \Delta x \neq 0 \Delta x^T H(x) \Delta x > 0$
- отрицательно определенной $H(x) < 0$, если $\forall \Delta x \neq 0 \Delta x^T H(x) \Delta x < 0$
- положительно полуопределенной $H(x) \geq 0$, если $\forall \Delta x \neq 0 \Delta x^T H(x) \Delta x \geq 0$ и имеется $\Delta x \neq 0 : \Delta x^T H(x) \Delta x = 0$
- отрицательно полуопределенной $H(x) \leq 0$, если $\forall \Delta x \neq 0 \Delta x^T H(x) \Delta x \leq 0$ и имеется $\Delta x \neq 0 : \Delta x^T H(x) \Delta x = 0$
- неопределенной, если $\exists \Delta x, \Delta \tilde{x} : \Delta x^T H(x) \Delta x > 0, \Delta \tilde{x}^T H(x) \Delta \tilde{x} < 0$
- тождественно равной нулю $H(x) \equiv 0$, если $\forall \Delta x \Delta x^T H(x) \Delta x = 0$

6.1.2 Свойства выпуклых множеств и выпуклых функций

Определение. Пусть $x, y \in E_n$. Множество точек вида $\{z\} \subset E_n : z = \alpha x + (1 - \alpha)y, \alpha \in [0, 1], z$ — отрезок, соединяющий x и y .

Пример. $E_n : n \leq 3: z$ — отрезок(обычный)

Определение. $U \subset E_n$ выпуклое, если вместе с точками x и $(y \in U)$ оно содержит и весь отрезок $z = \alpha x + (1 - \alpha)y, \alpha \in [0, 1]$

Определение. Функция $f(x)$, заданная на выпуклом $U \subset E_n$ называется:

- выпуклой, если $\forall x, y \in U$ и $\forall \alpha \in [0, 1]$ выполняется $f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y)$
- строго выпуклой, если $\forall \alpha \in (0, 1)$ выполняется $f(\alpha x + (1 - \alpha)y) < \alpha f(x) + (1 - \alpha)f(y)$
- сильно выпуклой с константой $l > 0$, если $\forall x, y \in U$ и $\forall \alpha \in [0, 1]$ выполняется $f(\alpha x + (1 - \alpha)y) \leq \alpha f(x) + (1 - \alpha)f(y) - \frac{l}{2} \alpha(1 - \alpha) \|x - y\|^2$

Свойства:

1. Функция $f(x)$ выпуклая, если ее график целиком лежит не выше отрезка, соединяющего две ее произвольные точки
Функция $f(x)$ строго выпуклая, если ее график лежит целиком ниже отрезка, соединяющего две ее произвольные, но не совпадающие точки
2. Если функция $f(x)$ сильно выпуклая, то она одновременно строго выпуклая и выпуклая
Если функция $f(x)$ строго выпуклая, то она одновременно выпуклая

3. Выпуклость функции можно определить по матрице Гессе $H(x)$

- Если $H(x) \geq 0 \forall x \in E_n$, то $f(x)$ выпуклая
- Если $H(x) > 0 \forall x \in E_n$, то $f(x)$ строго выпуклая
- Если $H(x) \geq lE \forall x \in E_n$, где E — единичная матрица, то $f(x)$ сильно выпуклая

Свойства выпуклых функций:

1. Если $f(x)$ выпуклая функция на выпуклом множестве U , то всякая точка локального минимума есть точка глобального минимума на U
2. Если выпуклая функция достигает своего минимума в двух различных точках, то она достигает минимума во всех точках отрезка, соединяющих эти точки.
3. Если $f(x)$ строго выпуклая функция множества U , то она может достигать своего глобального минимума на U не более чем в одной точке

6.1.3 Необходимое и достаточное условие безусловного экстремума

Теорема 6.1.1 (Необходимое условие экстремума первого порядка). Пусть $x^* \in E_n$ — локальный минимум или максимум $f(x)$ на E_n и $f(x)$ — дифференцируема в точке x^* . Тогда $\nabla f(x)$ в точке x^* равен нулю $\nabla f(x^*) = 0$, т.е.

$$\frac{\partial f(x^*)}{\partial x_i} = 0, \quad i = \overline{1, n}$$

Определение. Точки $x^* : \nabla f(x^*) = 0$ — **стационарные**

Теорема 6.1.2 (Необходимое условие экстремума второго порядка). Пусть $x^* \in E_n$ — точка локального минимума или максимума $f(x)$ на E_n и $f(x)$ — дважды дифференцируемая в точке.

Тогда $H(x^*)$ — является положительно или отрицательно(если максимум) полуопределенной, т.е. $H(x^*) \geq 0$ или $H(x^*) \leq 0$ (если максимум)

Теорема 6.1.3 (Достаточное условие экстремума). Пусть $f(x)$ в $x^* \in E_n$ дважды дифференцируема, ее $\nabla f(x) = 0$, а $H(x^*) > 0$ или $H(x^*) < 0$ (для максимума).

Тогда x^* — точка локального минимума(максимума) $f(x)$ на E_n

1. Проверка выполнения условий

- вычисление угловых миноров $H(x)$
 - вычисление главных миноров $H(x)$
- (а) Исследование положительной или отрицательной определенности угловых и главных миноров
 - (б) Анализ собственных значений матрицы $H(x)$

Лекция 7

7.1 Критерии Сильвестра

7.1.1 Достаточный условия

1. $H(x^*) > 0$ и x^* — локальный минимум $\Leftrightarrow \Delta_1 > 0, \Delta_2 > 0, \dots, \Delta_n > 0$
2. $H(x^*) < 0$ и x^* — локальный максимум $\Leftrightarrow \Delta_1 < 0, \Delta_2 > 0, \dots, (-1)^n \Delta_n > 0$

, где Δ_i — угловой минор

7.1.2 Необходимые условия

1. $H(x^*) \geq 0$ и x^* — может быть локальный минимум $\Leftrightarrow \Delta_1 \geq 0, \Delta_2 \geq 0, \dots, \Delta_n \geq 0$
2. $H(x^*) \leq 0$ и x^* — может быть локальный максимум $\Leftrightarrow \Delta_1 \leq 0, \Delta_2 \geq 0, \dots, (-1)^n \Delta_n \geq 0$

, где Δ_i — главный минор

7.2 Собственные значения

Определение. Собственные значения λ_i ($i = 1..n$) $H(x^*)_{n \times n}$ находятся как корни характеристического уравнения $|H(x^*) - \lambda E| = 0$. Если $H(x)$ — вещественная, симметричная матрица, то λ_i — вещественные

7.3 Общие принципы многомерной оптимизации

7.3.1 Выпуклые квадратичные функции

$$f(x) = \frac{1}{2}ax^2 + bx + c$$

Определение. Функция вида

$$f(x) = \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{j=1}^n b_j x_j + c \quad (7.1)$$

Называется **квадратичной функцией n переменных**

Положим $a_{ij} = a_{ij} + a_{ji} \Rightarrow$ симметрия. матрица A

$$f(x) = \frac{1}{2}(Ax, x) + (b, x) + c$$

, где $b = (b_1, \dots, b_n)^T \in E_n$ — вектор коэффициентов, $x = (x_1, \dots, x_n)^T$. x, y — скалярное произведение Свойства квадратичных функций:

1. $\nabla f(x) = Ax + b$

$$\begin{aligned} \frac{\partial f}{\partial x_k} &= \frac{\partial}{\partial x_k} \left(\frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_{ij} x_i x_j + \sum_{j=1}^n b_j x_j + c \right) = \\ &= \frac{1}{2} \sum_{i=1}^n (a_{ik} + a_{ki}) x_i + b_k = \sum_{i=1}^n a_{ki} x_i + b_k \end{aligned}$$

2. $H(x) = A$, где $H(x)$ — Гессиан

$$\frac{\partial^2 f}{\partial x_i \partial x_k} = \frac{\partial}{\partial x_k} \left(\frac{\partial f}{\partial x_i} \right) = \frac{\partial}{\partial x_k} \left(\sum_{i=1}^n a_{ki} x_i + b_k \right)$$

3. Квадратичная функция $f(x)$ с положительно определенной матрицей A сильно выпукла

$$A = \begin{vmatrix} \lambda_1 & 0 & \dots & 0 \\ 0 & \lambda_2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n \end{vmatrix}$$

$$A - lE = \begin{vmatrix} \lambda_1 - l & 0 & \dots & 0 \\ 0 & \lambda_2 - l & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \lambda_n - l \end{vmatrix}$$

В этом базисе все угловые миноры матрицы A и матрицы $A - lE$ — положительны при достаточно малом $l : 0 < l < \lambda_{\min \Rightarrow f(x)}$ — сильно выпукла

7.3.2 Принципы многомерной оптимизации

$$\begin{aligned} f(x) &\rightarrow \min, x \in E_n \\ x^{k+1} &= \Phi(x^k, x^{k+1}, \dots, x^0), x^0 \in E_n \end{aligned} \quad (7.2)$$

— итерационная процедура(общего вида)

$\{x^k\}$:

$$\begin{aligned} \lim_{k \rightarrow \infty} f(x^k) &= f^* = \min_{E_n} f(x), \text{ если } U^* \neq \emptyset \\ \lim_{k \rightarrow \infty} f(x^k) &= f^* = \inf_{E_n} f(x), \text{ если } U^* = \emptyset \end{aligned}$$

, где U^* – множество точек глобального минимума функции $f(x)$
 $\{x^k\}$ + условие 7.2 = минимизирующая последовательность для $f(x)$
 Если для $U^* \neq \emptyset$ выполняется условие

$$\lim_{k \rightarrow \infty} \rho(x^k, U^*) = 0$$

, то x^k сходится к множеству U^* . Если U^* содержит единственную точку x^* , то для $\{x^k\}$ сходящейся к U^* будет справедливо $\lim_{k \rightarrow \infty} x^k = x^*$

Определение. $\rho(x, U) = \inf_{y \in U} \rho(x, y)$ — расстояние от точки x до множества U

Замечание. Минимизирующая последовательность $\{x^k\}$ может и не сходится к точке минимума

Теорема 7.3.1 (Вейерштрасса). Если $f(x)$ непрерывна в E_n и множество $U^\alpha = \{x : f(x) \leq \alpha\}$ для некоторого α непусто и ограничено, то $f(x)$ достигает глобального минимума в E_n

1. Скорость сходимости (минимизирующих последовательностей)

Определение. $\{x^k\}$ сходится к точке x^* **линейно** (со скоростью геометрической последовательности), если $\exists q \in (0, 1)$:

$$\rho(x^k, x^*) \leq q \rho(x^{k-1}, x^*) \quad (7.3)$$

$$\rho(x^k, x^*) \leq q^k \rho(x^0, x^*)$$

Определение. Сходимость называется **сверхлинейной** если

$$\rho(x^k, x^*) \leq q_k \rho(x^{k-1}, x^*)$$

, и $q_k \xrightarrow{k \rightarrow \infty} +0$

Определение. **Квадратичная сходимость:**

$$\rho(x^k, x^*) \leq [c \rho(x^{k-1}, x^*)]^2, \quad c > 0$$

2. Критерии окончания итерационного процесса

$$\rho(x^{k+1}, x^*) < \varepsilon_1$$

$$|f(x^{k+1}) - f(x^k)| < \varepsilon_2 \quad (7.4)$$

$$\|\nabla f(x^k)\| < \varepsilon_3$$

, где ε_i — заранее заданные точности

$$x^{k+1} = x^k + \alpha_k p^k, \quad k = 0, 1, \dots \quad (7.5)$$

, где p^k — направление поиска из x^k в x^{k+1} , α_k — величина шага

$$f(x^{k+1}) < f(x^k)$$

— условие выбора α_k

Определение. В итерационном процессе 7.5 производится **исчерпывающий спуск**, если величина шага α_k находится из решения одномерной задачи минимизации:

$$\Phi_k(\alpha) \rightarrow \min_{\alpha}, \quad \Phi_k(\alpha) = f(x^k + \alpha p^k) \quad (7.6)$$

Теорема 7.3.2. Если функция $f(x)$ дифференцируема в пространстве E_n , то в итерационном процессе 7.5 с выбором шага с ичерпывающим спуском для любого $k \geq 1$:

$$(\nabla f(x^{k+1}), p^k) = 0 \quad (7.7)$$

— это значит что эти два вектора ортогональны

для $\Phi_k(\alpha)$ необходимое условие минимума функции:

$$\frac{d\Phi_k(\alpha)}{d\alpha} = \sum_{j=1}^n \frac{\partial f(x^{k+1})}{\partial x_j} \cdot \frac{dx_j^{k+1}}{d\alpha} = 0$$

учитывая $x_j^{k+1} = x_j^k + \alpha p_j^k \Rightarrow \frac{dx_j^k}{d\alpha} = p_j^k$

Теорема 7.3.3. Для квадратичной функции $f(x) = \frac{1}{2}(Ax, x) + (b, x) + c$ величина α_k исчерпывающего спуска в итерационном процессе

$$x^{k+1} = x^k + \alpha_k p^k, \quad \alpha_k = 0, 1, \dots$$

равна

$$\alpha_k = -\frac{(\nabla f(x^k), p^k)}{(Ap^k, p^k)} = -\frac{(Ax^k + b, p^k)}{(Ap^k, p^k)} \quad (7.8)$$

Лекция 8

Определение. Направление вектора p^k называется **направлением убывания** функции $f(x)$ в точке x^* , если при всех достаточно малых положительных α выполняется неравенство:

$$f(x^k + \alpha p^k) < f(x^k)$$

Теорема 8.0.1 (достаточное условие направления убывания). Пусть функция $f(x)$ дифференцируема в точке x^k . Если вектор p^k удовлетворяет условию:

$$(\nabla f(x^k), p^k) < 0$$

, то направление вектора p^k является направлением убывания

Доказательство. Из свойства дифференцируемости функции и условия данной теоремы следует, что

$$\begin{aligned} f(x^{k+1}) - f(x^k) &= f(x^k + \alpha p^k) - f(x^k) = (\nabla f(x^k), \alpha p^k) + o(\alpha) = \\ &= \alpha \left((\nabla f(x^k), p^k) + \frac{o(\alpha)}{\alpha} \right) < 0 \end{aligned}$$

, при всех достаточно малых $\alpha > 0$, т.е. p^k задает направление убывания функции $f(x)$ в точке x^k \square

Замечание. Геометрическая интерпретация $(\nabla f(x^k), p^k) < 0 \implies p^k$ составляет тупой угол с $\nabla f(x^k)$

$f(x)$ дифференцируема в E_n :

$$x^{k+1} = x^k + \alpha_k p^k \quad k = 0, 1, \dots \quad (8.1)$$

где p^k определяется с учетом информации о частных производных, а величина шага $\alpha_k > 0$, такова, что:

$$f(x^{k+1}) < f(x^k) \quad k = 0, 1, \dots \quad (8.2)$$

Останов итерационного процесса: $\|\nabla f(x^k)\| < \varepsilon$

8.1 Метод градиентного спуска

В 8.1: $p^k = -\nabla f(x^k)$ — предположение. Если $\nabla f(x^k) \neq 0$, то $(\nabla f(x^k), p^k) < 0$, следовательно p^k — направление убывания функции $f(x)$, в малой окрестности точки x^k направление p^k

обеспечивает наискорейшее убывание этой функции. Таким образом можно найти такое $\alpha_k > 0$, что выполнится 8.2

Алгоритм 1 метод Градиентного спуска

Ввод $\varepsilon > 0, \alpha > 0, x \in E_k, f(x)$

- 1: **повторять**
 - 2: Вычисляем $\nabla f(x)$
 - 3: **если** Выполнено условие достижения точности $\|\nabla f(x)\| < \varepsilon$ **тогда**
 - 4: **Вернуть** $x^* := x, f^* := f(x^*)$
 - 5: **конец если**
 - 6: **повторять**
 - 7: Найти $y := x - \alpha \nabla f(x)$
 - 8: Вычислить $f(y)$
 - 9: **если** $f(y) < f(x)$ **тогда**
 - 10: $x := y$
 - 11: $f(x) := f(y)$
 - 12: Выйти из цикла
 - 13: **иначе**
 - 14: $\alpha := \frac{\alpha}{2}$
 - 15: **конец если**
 - 16: **конец повторять**
 - 17: **конец повторять**
-

Замечание. В окрестности стационарной точки функции $f(x)$ величина $\|\nabla f(x)\|$ становится малой, это приводит к замедлению сходимости последовательности $\{x^k\}$. Поэтому в 8.1 иногда полагают

$$p^k = \frac{-\nabla f(x^k)}{\|\nabla f(x^k)\|}$$

Теорема 8.1.1. Пусть симметричная матрица A квадратичной функции $f(x)$ положительно определена, а l и L — наименьшее и наибольшее собственное значение A . Тогда при любых $\alpha \in (0, \frac{2}{L})$ и $x^0 \in E_n$

$$x^{k+1} = x^k - \alpha \nabla f(x^k)$$

сходится к единственной точке глобального минимума x^* функции $f(x)$ линейно (со скоростью геометрической прогрессии)

$$\rho(x^k, x^*) \leq q^k \rho(x^0, x^*)$$

, где $q = \max\{|1 - \alpha l|, |1 - \alpha L|\}$

Доказательство. Т.к. A положительно определена, то $f(x)$ — сильно выпукла. Следовательно точка x^* — существует и единственна. $\nabla f(x^*) = 0$ в точке x^* , тогда

$$\nabla f(x^k) = Ax^k + b = Ax^k + b - \underbrace{Ax^* + b}_{\nabla f(x^*)} = A(x^k - x^*)$$

Оценим норму разности

$$\|x^k - x^*\| = \|x^{k-1} - \alpha \nabla f(x^{k-1}) - x^*\| = \|x^{k-1} - x^* - \alpha A(x^{k-1} - x^*)\| =$$

$$= \|(E - \alpha A)(x^{k-1} - x^*)\|$$

$$\|x^k - x^*\| \leq \|E - \alpha A\| \cdot \|x^{k-1} - x^*\| \leq q \|x^{k-1} - x^*\| \leq q^k \|x^0 - x^*\|$$

— из определения линейной сходимости, где q — оценка нормы матрицы через величину ее собственных значений

$$\|E - \alpha A\| \leq q = \max\{|1 - \alpha l|, |1 - \alpha L|\}$$

Если $\alpha \in (0; \frac{2}{L})$, то $q < 1$

г: $q^* = \frac{L-l}{L+l}$, при $\alpha = \alpha^* = \frac{2}{L+l}$. Т.к. $l < L$, то $1 - \alpha l = -(1 - \alpha L)$. От соотношения L и l существенно зависит число итераций градиентного метода при минимизации выпуклой квадратичной функции \square

Пример. $L = l > 0$, тогда точка минимума находится за один шаг

$$f(x) = x_1^2 + x_2^2 \rightarrow \min$$

$$x^0 = (1, 1)^T \quad \alpha = \alpha^* = \frac{2}{l + L}$$

Решение.

$$A = \begin{pmatrix} 2 & 0 \\ 0 & 2 \end{pmatrix} \implies l = L = 2$$

$$\alpha^* = \frac{2}{2+2} = \frac{1}{2}$$

$$x^1 = x^0 - \frac{1}{2} \text{grad} f(x^0) = (0, 0)^T$$

$$x^1 = x^*$$

Замечание. При $l = L$ — линии уровня $f(x)$ — концентрические окружности

Замечание. $L \gg l > 0$ — линии уровня $f(x)$ — эллипсы

Пример.

$$f(x) = x_1^2 + 100x_2^2 \rightarrow \min$$

$$x^0 = (1, 1)^T$$

$$\alpha = \alpha^*$$

Решение.

$$A = \begin{pmatrix} 2 & 0 \\ 0 & 200 \end{pmatrix} \implies l = 2, L = 200$$

Линии уровня — эллипсы сильно вытянутые вдоль оси Ox_1

$$\alpha = \alpha^* = \frac{2}{202} = \frac{1}{101}$$

$$-\nabla f(x^0) = (-2, -200)^T$$

— сильно отличается от $x^* - x^0$

$$x^* - x^0 = (-1, -1)^T$$

— направление точки глобального минимума

$$x^{k+1} = x^k - \alpha \nabla f(x^k)$$

$$\nabla f(x^k) = (2x_1, 200x_2)^T$$

$$\begin{cases} x_1^{k+1} = \frac{99}{101} x_1^k \\ x_2^{k+1} = -\frac{99}{101} x_2^k \end{cases}$$

— закон изменения координат точек, минимизирующей последовательности. $\{x^k\}$ — сходится медленно

Определение. Число обусловленности для симметричной положительно определенной матрицы $\mu = \frac{L}{l}$. Оно характеризует вытянутость линий уровня $f(x) = C$

- Если μ велико, то линии уровня сильно вытянуты и говорят что функция имеет **овражный** характер (резко меняется по одним направлением и слабо по другим) \implies Полохо обусловленная задача
- Если $\mu \sim 1$, то линии уровня близки к окружностям и задача является хорошо обусловленной

8.2 Метод наискорейшего спуска

После вычисления в начальной точке градиента функции делают в направлении антиградиента не маленький шаг, а передвигаются до тех пор, пока функция убывает. Достигнув точки минимума на выбранном направлении снова вычисляют градиент функции и повторяют описанную процедуру

$$p^k = -\nabla f(x^k)$$

α_k — находится из решения задачи одномерной оптимизации

$$\Phi_k(\alpha) \rightarrow \min$$

$$\Phi_k(\alpha) = f(x^k - \alpha \nabla f(x^k)) \quad \alpha > 0 \quad (8.3)$$

Алгоритм 2 метод наискорейшего спуска

Ввод $\varepsilon > 0, x \in E_k, f(x)$

- 1: **повторять**
 - 2: Вычислить $\nabla f(x)$
 - 3: **если** $\|\nabla f(x)\| < \varepsilon$ **тогда**
 - 4: **Вернуть** $x^* := x, f^* := f(x)$
 - 5: **конец если**
 - 6: Решить задачу одномерной оптимизации 8.3 для $x^k := x$, т.е. найти α^*
 - 7: $x := x - \alpha^* \nabla f(x)$
 - 8: **конец повторять**
-

Определение. Ненулевые векторы p^1, \dots, p^k называются сопряженными относительно матрицы A размера $n \times n$ или A -ортогональными, если

$$(Ap^i, p^j) = 0 \quad i \neq j \quad i, j = 1, \dots, k$$

Замечание. Система из n векторов p^1, \dots, p^n сопряженных относительно положительно определенной матрицы A линейно независима

Замечание. n ненулевых A -ортгоналных векторов образуют базис в E_n . Рассмотрим минимизацию квадратичной функции в E_n

$$f(x) = \frac{1}{2}(Ax, x) + (b, x) + c$$

A — положительно определенная. Итерационный процесс

$$x^k = x^{k-1} + \alpha_k p^k \quad k = 1, 2, \dots \quad (8.4)$$

, где p^k — A -ортгоналные

Замечание. Если в итерационном процессе 14.8 на каждом шаге используется исчерпывающий спуск, то

$$\alpha_k = -\frac{(\nabla f(x^0), p^k)}{(Ap^k, p^k)} \quad k = 1, 2, \dots \quad (8.5)$$

Доказательство.

$$x^k = x^{k-1} + \alpha_k p^k = x^0 + \sum_{i=1}^k \alpha_i p^i \quad (8.6)$$

$$\nabla f(x) = Ax + b$$

$$\nabla f(x^k) = \nabla f(x^0) + \sum_{i=0}^k \alpha_i Ap^i$$

умножим на p^k и учитываем $(\nabla f(x^k), p^k) = 0$, A -ортгоналность p^k

$$(\nabla f(x^0), p^k) + \alpha_k (Ap^k, p^k) = 0$$

, т.к. A — положительно определена, то $(Ap^k, p^k) > 0$, и для α_k :

$$\alpha_k = -\frac{(\nabla f(x^0), p^k)}{(Ap^k, p^k)}$$

□

Лекция 9

9.1 Метод сопряженных градиентов

$$\begin{aligned}x^{k+1} &= x^k + \alpha_k p^k \quad k = 0, 1, \dots \\p^k &= -\nabla f(x^*)\end{aligned}\tag{9.1}$$

Направление убывания может носить зигзагообразный характер. Будем находить вектор p^k не только через антиградиент, но и через p^{k-1} .

$$p^{k+1} = -\nabla f(x^{k+1}) + \beta_k p^k\tag{9.2}$$

β_k выбираются так, чтобы получалась последовательность A -ортогональных векторов p^0, p^1, \dots . Из условия:

$$\begin{aligned}(Ap^{k+1}, p^k) &= 0 \\ \beta_k &= \frac{(A\nabla f(x^{k+1}), p^k)}{(Ap^k, p^k)}\end{aligned}\tag{9.3}$$

Для квадратичных функция:

$$\alpha_k = -\frac{(\nabla f(x^k), p^k)}{(Ap^k, p^k)}\tag{9.4}$$

Утверждение: итерационный процесс, который описывается формулами 9.1, 9.2, 9.3, 9.4, с положительно определенной симметричной матрицей A дает точки x^0, \dots, x^k и векторы, такие что если $\nabla f(x^i) \neq 0$, $0 \leq i < k \leq n - 1$, то векторы p^0, \dots, p^k — A -ортогональны, а градиенты $\nabla f(x^0), \dots, \nabla f(x^i)$ — взаимно ортогональны.

Т.к. p^k в 9.2 A -ортогональны, то метод гарантирует нахождение точки минимума сильно выпуклой квадратичной функции не более чем за n шагов

$$x^{k+1} = x^k + \alpha_k p^k \quad k = 0, 1, \dots \quad x^0 \in E_k \quad p^0 = -\nabla f(x^0)\tag{9.5}$$

$$f(x^k + \alpha_k p^k) = \min_{\alpha > 0} f(x^k + \alpha p^k) \quad k = 0, 1, \dots\tag{9.6}$$

$$p^{k+1} = -\nabla f(x^{k+1}) + \beta_k p^k \quad k = 0, 1, \dots\tag{9.7}$$

$$\beta_k = \frac{\|\nabla f(x^{k+1})\|^2}{\|\nabla f(x^k)\|^2}\tag{9.8}$$

Точное определение α_k возможно только в редких случаях, т.к. p^k могут быть не A -ортогональными. В этом методе используется следующий практический прием: через N шагов производится обновление метода, т.е. $\beta_{m \cdot N} = 0 \quad m = 1, 2, \dots$, где $m \cdot N$ — момент

обновления метода (рестарта), часто полагают $N = n$ — размерность пространства E_n . Рестарт необходим для устранения накопленной погрешности метода, из-за которой вектора p^k перестанут указывать на направление убывания функции $f(x)$

Если функция хорошо аппроксимируется квадратичной функцией, то метод сопряженных градиентов даст маленькое количество шагов

9.2 Метод стохастического градиентного спуска

Этот метод по большей части связан с большими выборками. Обычные методы пострадают, из-за дорогого вычисления функции на большом наборе данных.

Наборы разбивают на K тренировочных наборов, части тренировочных наборов размера M называют minibatch. Тогда набор можно представить как:

$$X^{(k)} = \{x_i | i = M_k, \dots, (M_k + M - 1)\}$$

$$Y^{(k)} = \{y_i | i = M_k, \dots, (M_k + M - 1)\}$$

Определяют некоторую функцию, которую будем оптимизировать. Для каждого набора она будет выглядеть так:

$$L^{(k)}(\omega) = \sum_{i=0}^M L(\omega, x_{M_k+i}, y_{M_k+i}) \quad k = 0, \dots, (K - 1)$$

, где ω — точка минимума

Когда определяем функцию для каждого набора, каждая составляющая ω будет находиться на мини итерации:

$$\omega_p^{(k+1)} = \omega_p^{(k)} - \eta \cdot \nabla L^{(k)}(\omega_p^{(k)}) \quad k = 0, \dots, (K - 1)$$

$$\omega_{p+1}^{(0)} = \omega_p^{(k)}$$

Большая итерация: $p = 0, 1, \dots$ завершается когда проходим весь набор миниитераций. Такая большая итерация называется эпохой. Когда переходим к следующей эпохе, перемешивает тренировочный набор. В результате перемешивания, элементы будут попадать в разные minibatch'и на каждой эпохе.

9.2.1 Adagrad (модификация)

Предлагается использовать разные η , для каждого minibatch'а.

$$\eta_p = (\eta_p^{(1)}, \dots, \eta_p^{(d)})$$

$$\eta_0 = \text{const} \quad \eta_0^{(i)} = \eta \quad i = 1, \dots, d$$

$$\omega_p = (\omega_p^{(1)}, \dots, \omega_p^{(d)})$$

$$\nabla L(\omega_p) = (g_p^{(1)}, \dots, g_p^{(d)})$$

Определим вспомогательный вектор:

$$G_p^{(i)} = (G_p^{(1)}, \dots, G_p^{(d)})$$

$$G_p^{(i)} = \sum_{j=1}^p (g_j^{(i)})^2 \quad i = 1, \dots, d$$
$$\eta_p^{(i)} = \frac{\eta}{\sqrt{G_p^{(i)} + e}}$$

, где e — коэффициент $\sim 1e-8$

$$\omega_{p+1} = \omega_p - \eta_p \odot L(\omega_p)$$

, где \odot — поэлементное умножение двух векторов

9.3 Метод покоординатного спуска

$$f(x) \rightarrow \min_{x \in E_n}$$

Алгоритм:

- Выбираем вектор $x_0 \in E_n$

$\forall i$:

1. фиксируем значение всех переменных, кроме x_i
2. $f(x_i) \rightarrow \min$ любым методом одномерной оптимизации (золотое сечение наиболее популярный)
3. Проверка выполнения критерия останова:
 - $\|x^{k+1} - x^k\| \leq \varepsilon_1$
 - $\|f(x^{k+1}) - f(x^k)\| \leq \varepsilon_2$

Лекция 10

10.1 Формы хранения матриц

Определение. Матрица имеющая достаточное и большое число ненулевых элементов называется **разреженной**

Определение. В ином случае, называется **плотной**

Форматы хранения квадратных матриц:


1. Диагональный
2. Ленточный
3. Профильный
4. Разреженный

Характеристики:

1. Симметрия матрицы
2. Верхний и нижний треугольники матрицы
3. Ускоренный доступ к строкам матрицы


Будем называть ненулевыми элементами, те которые предполагается хранить в памяти.

10.1.1 Диагональный



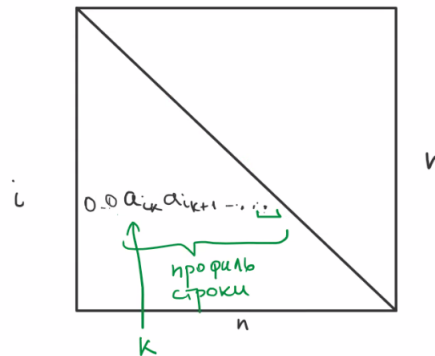
- $n \times n$, где n — размерность исходной матрицы, m — количество ненулевых диагоналей

10.1.2 Ленточный формат



$a_{ij} = 0$, если $|i - j| > k$, k — полуширина, $m = 2k + 1$ — ширина ленты

10.1.3 Профильный формат



Обычно хранят несимметричные матрицы. Структуры хранения:

- Вещественный массив $di[n]$ — массив диагональных элементов
- Вещественные массивы al — элементы нижнего треугольника по строкам, au — элементы верхнего треугольника по столбцам
- Целочисленный массив $ia(k)$ = индекс (в нумерации с 1), с которого начинаются элементы k -ой строки (столбца) в массивах al , au . Размерность равна $n+1$, при чем $ia[n+1]$ равен индексу первого незанятого элемента в al , au , $a[n+1] - 1$ — размерность al и au .

1. $ja[ia[6]] = ja[5] = 3$
2. $ja[ia[6] + 1] = ja[6] = 5$

11.1.2 Решение СЛАУ. Метод Гаусса

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \\ a_{21}x_1 + a_{22}x_2 + \dots + a_{2n}x_n = b_2 \\ \vdots \\ a_{n1}x_1 + a_{n2}x_2 + \dots + a_{nn}x_n = b_n \end{cases}$$

$$Ax = b$$

- $A = (a_{ij})_{i,j=1}^n$ — вещественные числа
 - $b = (b_1, b_2, \dots, b_n)^T$
 - $x = (x_1, x_2, \dots, x_n)^T$
- $-\frac{a_{21}}{a_{11}}, -\frac{a_{31}}{a_{11}}, \dots, -\frac{a_{n1}}{a_{11}}$ Верхний индекс обозначает этап.

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \\ a_{22}^{(1)}x_2 + a_{23}^{(1)}x_3 + \dots + a_{2n}^{(1)}x_n = b_2^{(1)} \\ a_{32}^{(1)}x_2 + a_{33}^{(1)}x_3 + \dots + a_{3n}^{(1)}x_n = b_3^{(1)} \\ \vdots \\ a_{n2}^{(1)}x_2 + a_{n3}^{(1)}x_3 + \dots + a_{nn}^{(1)}x_n = b_n^{(1)} \end{cases}$$

$$a_{ij}^{(1)} = a_{ij} - \frac{a_{i1}}{a_{11}}a_{1j} \quad b_i^{(1)} = b_i - \frac{a_{i1}}{a_{11}}b_1 \quad i, j = \overline{2, n}$$

Замечание. $a_{11} \neq 0$

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \\ a_{22}^{(1)}x_2 + a_{23}^{(1)}x_3 + \dots + a_{2n}^{(1)}x_n = b_2^{(1)} \\ a_{33}^{(2)}x_3 + a_{34}^{(2)}x_4 + \dots + a_{3n}^{(2)}x_n = b_3^{(2)} \\ \vdots \\ a_{n3}^{(2)}x_3 + a_{n4}^{(2)}x_4 + \dots + a_{nn}^{(2)}x_n = b_n^{(2)} \end{cases}$$

$$a_{ij}^{(2)} = a_{ij}^{(1)} - \frac{a_{i2}^{(1)}}{a_{22}^{(1)}}a_{2j}^{(1)} \quad b_i^{(2)} = b_i^{(1)} - \frac{a_{i2}^{(1)}}{a_{22}^{(1)}}b_2^{(1)}$$

$n - 1$ этап:

$$\begin{cases} a_{11}x_1 + a_{12}x_2 + \dots + a_{1n}x_n = b_1 \\ a_{22}^{(1)}x_2 + a_{23}^{(1)}x_3 + \dots + a_{2n}^{(1)}x_n = b_2^{(1)} \\ a_{33}^{(2)}x_3 + a_{34}^{(2)}x_4 + \dots + a_{3n}^{(2)}x_n = b_3^{(2)} \\ \vdots \\ a_{nn}^{(n-1)}x_n = b_n^{(n-1)} \end{cases}$$

$$a_{ij}^{(k)} = a_{ij}^{(k-1)} - \frac{a_{ik}^{(k-1)}}{a_{kk}^{(k-1)}} a_{kj}^{(k-1)} \quad b_i^{(k)} = b_i^{(k-1)} - \frac{a_{ik}^{(k-1)}}{a_{kk}^{(k-1)}} b_k^{(k-1)} \quad k \in \overline{1, n}; \quad i, j \in \overline{k+1, n}$$

11.1.3 Обратный ход Гаусса

$$x_n = \frac{b_n^{(n-1)}}{a_{nn}^{(n-1)}}$$

$$\vdots$$

$$x_2 = \frac{b_2^{(1)} - a_{23}^{(1)} x_3 - \dots - a_{2n}^{(1)} x_n}{a_{22}^{(1)}}$$

$$x_1 = \frac{b_1 - a_{12} x_2 - \dots - a_{1n} x_n}{a_{11}}$$

$$x_k = \frac{b_k^{(k-1)} - \sum_{i=k+1}^n a_{ki}^{(k-1)} x_i}{a_{kk}^{(k-1)}} \quad k \in \overline{n, 1}$$

$$\sum_j^n = 0, \text{ если } j > n$$

Алгоритм 3 метод Гаусса

- 1: **для** $k = 1, \dots, n-1$ **делать**
 - 2: **для** $i = k+1, \dots, n$ **делать**
 - 3: $t_{ik} = \frac{a_{ik}}{a_{kk}}$
 - 4: $b_i = b_i - t_{ik} b_k$
 - 5: **для** $j = k+1, \dots, n$ **делать**
 - 6: $a_{ij} = a_{ij} - t_{ik} a_{kj}$
 - 7: **конец для**
 - 8: **конец для**
 - 9: **конец для**
 - 10: $x_n = \frac{b_n}{a_{nn}}$
 - 11: **для** $k = n-1, \dots, 1$ **делать**
 - 12: $x_k = \frac{(b_k - \sum_{j=k+1}^n a_{kj} x_j)}{a_{kk}}$
 - 13: **конец для**
-

Модификация с постолбцовым выбором главного элемента

Алгоритм 4 модификация алгоритма гаусса

$m : m \geq k, |a_{mk}| = \max_{i \geq k} \{|a_{ik}|\}$ $j = k, \dots, n$ поменять местами b_x и b_m поменять местами a_{kj} и a_{mj}

Лекция 12

12.1 Прямые методы решения СЛАУ

Виды разложения матрицы A :

- LU — L — нижнетреугольная матрица, U — верхнетреугольная матрица
- LL^T — метод квадратного корня
- LDL^T , $L_{ii} = 1$
- D — диагональная матрица

$$A = LU \tag{12.1}$$

$$LUx = b \quad y = Ux$$

$$Ly = b \tag{12.2}$$

1. $A \implies L$ и U
2. решить 12.2 — прямой ход: y
3. $Ux = y$ — обратный ход

$$L = \begin{bmatrix} L_{11} & 0 & 0 & \dots \\ L_{21} & L_{22} & 0 & \dots \\ L_{31} & L_{32} & L_{33} & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} U = \begin{bmatrix} 1 & U_{12} & U_{13} & \dots \\ 0 & 1 & U_{23} & \dots \\ 0 & 0 & 1 & \dots \\ \vdots & \vdots & \vdots & \ddots \end{bmatrix} \tag{12.3}$$

Красным помечено то, что мы находим на текущем шаге

- $A_{11} = L_{11}$
- $A_{21} = L_{21}$
- $A_{12} = L_{11} \cdot U_{12}$
- $A_{22} = L_{21} \cdot U_{12} + L_{22}$
- $A_{31} = L_{31}$
- $A_{32} = L_{31} \cdot U_{12} + L_{32}$

- $A_{13} = L_{11} \cdot U_{13}$
- $A_{23} = L_{21} \cdot U_{13} + L_{22} \cdot U_{23}$
- $A_{33} = L_{31} \cdot U_{13} + L_{32} \cdot U_{23} + L_{33}$

Алгоритм 5 Алгоритм разложения

$$A_{11} = L_{11}$$

для $i \leftarrow 2$ до n делать

 для $j \leftarrow 1$ до $i - 1$ делать

$$L_{ij} = A_{ij} - \sum_{k=1}^{j-1} L_{ik} \cdot U_{kj}$$

$$U_{ji} = \frac{1}{L_{jj}} \left[A_{ji} - \sum_{k=1}^{j-1} L_{jk} \cdot U_{ki} \right]$$

 конец для

$$L_{ii} = A_{ii} - \sum_{k=1}^{i-1} L_{ik} \cdot U_{ki}$$

конец для

12.1.1 Близкие к нулю главные элементы

ЭВМ: 5-разрядная арифметик с плавающей точкой

$$\begin{pmatrix} 10 & -7 & 0 \\ 0 & -1.0 \cdot 10^{-3} & 6 \\ 0 & 2.5 & 5 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \\ x_3 \end{pmatrix} = \begin{pmatrix} 7 \\ 6.001 \\ 2.5 \end{pmatrix}$$

$$6.001 \cdot 2.5 \cdot 10^{-3} = 1.50025 \cdot 10^4 \approx 1.5003 \cdot 10^4$$

$$1.5005 \cdot 10^4 \cdot x_3 = 1.5004 \cdot 10^4 \implies x_3 = \frac{1.5004 \cdot 10^4}{1.5005 \cdot 10^4} = 0.99993$$

$$-1.0 \cdot 10^{-3} \cdot x_2 + 6 \cdot 0.99993 = 6.0001 \implies x_2 = \frac{1.5 \cdot 10^{-3}}{-1.0 \cdot 10^{-3}} = -1.5$$

$$10 \cdot x_1 + (-7) \cdot (-1.5) = 7 \implies x_1 = -0.35$$

$$x = (-0.35, -1.50, 0.99993)$$

Хотя правильный ответ: $x^* = (0, -1, 1)$

12.1.2 Вектор ошибки и невязка

$$\begin{pmatrix} 0.780 & 0.563 \\ 0.457 & 0.330 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0.217 \\ 0.127 \end{pmatrix}$$

ЭВМ: трехразрядная десятичная арифметика

$$\frac{0.457}{0.780} = 0.586$$

$$\begin{pmatrix} 0.780 & 0.563 \\ 0 & 0.0000820 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} 0.217 \\ -0.000162 \end{pmatrix}$$

$$x_2 = \frac{-0.00162}{0.0000820} = -1.98$$

$$x_1 = \frac{0.217 - 0.563 \cdot x_2}{0.780} = 1.71$$

$$x = (1.71, -1.98)^T$$

Определение. Невязка $\Gamma = b - Ax$. Если решение точное, то вектор невязки близок к 0

$$\Gamma = (-0.00206, -0.00107)^T$$

Точным решением является вектор $x^* = (1, -1)^T$

Величина ошибки решения: $\frac{\|x^* - x\|}{\|x^*\|}$

Определение. $\text{cond}(A)$ — число обусловленности A . Отношение максимального и минимального собственного значения матрицы

Величина ошибки в решении приближенно равна величине решения $\times \text{cond}(A) \times \varepsilon_{\text{маш}}$.

Пример. $\text{cond}(A) = 10^6$, $\varepsilon = 10^{-8}$. В решении — 3 верных разряда

12.1.3 Векторные нормы

1. 2-норма (евклидова)

$$\|x\|_2 = \left(\sum_{i=1}^n |x_i|^2 \right)^{\frac{1}{2}}$$

2. 1-норма (манхэттенское расстояние)

$$\|x\|_1 = \sum_{i=1}^n |x_i|$$

3. max-норма (∞ -норма)

$$\|x\|_\infty = \max_i |x_i|$$

$$\|x\| > 0, \text{ если } x \neq 0 \quad \|0\| = 0$$

$$\|cx\| = |c| \cdot \|x\| \quad \forall c$$

$$\|x + y\| \leq \|x\| + \|y\|$$

$$Ax = b$$

$$M = \max_x \frac{\|Ax\|}{\|x\|} \implies \|Ax\| \leq M \cdot \|x\|$$

$$m = \min_x \frac{\|Ax\|}{\|x\|} \implies \|Ax\| \geq m \cdot \|x\|$$

$\frac{M}{m}$ — число обусловленности матрицы A

$$A(x + \Delta x) = b + \Delta b$$

Будем считать, что Δb — ошибка в b , Δx — ошибка в x . Поскольку $A(\Delta x) = \Delta b$, то можно сказать, что:

$$\|Ax\| = \|b\| \leq M \cdot \|x\|$$

$$\|A\Delta x\| = \|\Delta b\| \geq m \cdot \|\Delta x\|$$

При $M \neq 0$

$$\frac{\|\Delta x\|}{\|x\|} \leq \text{cond}(A) \cdot \frac{\|\Delta b\|}{\|b\|}$$

1. Свойства числа обусловленности

$$M \geq m$$

Свойство 1. $\text{cond}(A) \geq 1$

P — матрица перестановок, $\text{cond}(P) = 1$

$\text{cond}(I) = 1$

Свойство 2. $\text{cond}(c \cdot A) = \text{cond}(A)$

Свойство 3. D — диагональная

$$\text{cond}(D) = \frac{\max |d_{ii}|}{\min |d_{ii}|}$$

Пример. $D = \text{diag}(0.1)$, $n = 100$. $\det D = 10^{-100}$ — малое число

$$\text{cond}(A) = \frac{0.1}{0.1} = 1$$

Лекция 13

13.1 Число обусловленности

Пример.

$$\begin{aligned} Ax &= b \\ A &= \begin{pmatrix} 9.7 & 6.6 \\ 4.1 & 2.8 \end{pmatrix} \quad b = \begin{pmatrix} 9.7 \\ 4.1 \end{pmatrix} \quad x = \begin{pmatrix} 1 \\ 0 \end{pmatrix} \\ \|b\| &= 13.8 \quad \|x\| = 1 \\ \text{cond}(A) &= 2249.4 \\ b' &= \begin{pmatrix} 9.70 \\ 4.11 \end{pmatrix} \quad x' = \begin{pmatrix} 0.34 \\ 0.97 \end{pmatrix} \\ \Delta b &= b - b' \quad \|\Delta b\| = 0.01 \\ \Delta x &= x - x' \quad \|\Delta x\| = 1.63 \\ \frac{\|\Delta b\|}{\|b\|} &= 0.00072464 \\ \frac{\|\Delta x\|}{\|x\|} &= 1.63 \end{aligned}$$

13.1.1 Нормы и анализ ошибок

$$\begin{aligned} \|A\| &= \sum_{i=1}^n \sum_{j=1}^n |a_{ij}| \\ \|Ax\| &\leq \|A\| \cdot \|x\| \\ \tilde{x} : \|Ax\| &= \|A\| \cdot \|\tilde{x}\| \\ \|A\| = M &= \max_{x \neq 0} \frac{\|Ax\|}{\|x\|} \\ \|a\| &= \|a_j\| \end{aligned}$$

Результат Уилкинсона

$$x^* : (A + E)x^* = b$$

, где элементы E имеют уровень ошибок округления

$$b - Ax^* = Ex^*$$

$$\|b - Ax^*\| = \|Ex^*\| \leq \|E\| \cdot \|x^*\|$$

$$\frac{\|b - Ax^*\|}{\|A\| \cdot \|x^*\|} \leq C \cdot \varepsilon_{\text{маш.}}$$

Если A не вырождена то: $x - x^* = A^{-1} \cdot (b - Ax^*)$

$$\|x - x^*\| \leq \|A^{-1}\| \cdot \|E\| \cdot \|x^*\|$$

$$\frac{\|x - x^*\|}{\|x^*\|} \leq C \cdot \|A\| \cdot \|A^{-1}\| \cdot \varepsilon_{\text{маш.}}$$

$$\text{cond}(A) = \|A\| \cdot \|A^{-1}\|$$

$$\|A^{-1}\| = \frac{1}{m} \frac{\|x - x^*\|}{\|x^*\|} \leq C \cdot \text{cond}(A) \cdot \varepsilon_{\text{маш.}}$$

- a_j — столбцы A
- \tilde{a}_j — столбцы A^{-1}

$$\text{cond}(A) = \max_j \|a_j\| \cdot \max_j \|\tilde{a}_j\|$$

13.1.2 Оценивание числа обусловленности

$$\text{cond}(A) = \frac{\max_x \frac{\|Ax\|}{\|x\|}}{\min_x \frac{\|Ax\|}{\|x\|}}$$

$$\text{cond}(A) = \|A\| \cdot \|A^{-1}\|$$

1-норма:

- a_j — столбец

$$\|A\| = \max_j \|a_j\|$$

$$\|A^{-1}\| = \frac{1}{\min_x \frac{\|Ax\|}{\|x\|}} = \max_x \frac{\|x\|}{\|Ax\|} = \max_y \frac{\|A^{-1}y\|}{\|y\|}$$

$$y := Ax \quad Az = y$$

$$\frac{\|z\|}{\|y\|} = \underbrace{\frac{\|A^{-1}y\|}{\|y\|}}_{\text{оценка } \|A^{-1}\|}$$

Цель — подобрать y . $A^T y = c$, где c — вектор с компонентами ± 1

Пример.

$$A = \begin{pmatrix} 9.7 & 6.6 \\ 4.1 & 2.8 \end{pmatrix} = \underbrace{\begin{pmatrix} 1 & 0 \\ 0.4227 & 1 \end{pmatrix}}_L \cdot \underbrace{\begin{pmatrix} 9.7000 & 6.6000 \\ 0 & 0.0103 \end{pmatrix}}_U$$

$$y : A^T y = c \implies U^T (L^T y) = c$$

$$c_1 = 1; c_2 = ?$$

$$(L^T y)_1 = \frac{c_1}{U_{11}} = \frac{1}{9.7} = 0.1031$$

$$(L^T y)_2 = \frac{c_2 - U_{21}(L^T y)_1}{U_{22}} = \frac{\pm 1 - 6.6 \cdot 0.10031}{0.0103}$$

$(L^T y)_2$ большее, если $c_2 = -1$, значит

$$(L^T y) = (0.1031, -163)^T \quad y = (-163, 69)^T$$

$$Az = y \implies z = (12690, -18640)^T$$

$$\|A^{-1}\| \approx \frac{\|z\|}{\|y\|} = \frac{|12690| + |-18640|}{|-163| + |69|} = \frac{31330}{232} = 135.04$$

$$\|A\| = 13.8 \quad \text{cond}(A) \approx 13.8 \cdot 135.04 = 1863.6$$

13.2 Дополнительно о градиентных методах

$\{x_k\}$: $x^k = x^{k-1} + \alpha_k u^k \quad k \in \mathbb{N}$

$u^k \in E_n$. $(\nabla f(x), u) < 0$ — условие спуска

Как находить α_k

$$f(x^{k-1} + \alpha_k u^k) \leq (1 - \lambda_k) f(x^{k-1}) + \lambda_k \min_{\alpha \in E} f(x^{k-1} + \alpha u^k) \quad \lambda_k \in [0, 1]$$

$$f(x^{k-1} + \alpha_k u^k) \leq f(x^{k-1}) \quad (13.1)$$

— если это выполнено, то $\{x^k\}$ — релаксационная $\lambda_k = 0$, тогда 13.1, если же $\lambda_k = 1$, то для нахождения α_k^* решаем задачу одномерной оптимизации. Для случая $\lambda_k \in (0, 1)$:

$$f(x^{k-1}) - f(x^k) \geq \lambda_k (f(x^{k-1}) - f(x^{k-1} + \alpha_k^* u^k))$$

$$\omega(x) = -\nabla f(x)$$

13.2.1 Градиентный спуск

$$x^k = x^{k-1} + \beta_k \underbrace{\frac{\omega^k}{|\omega^k|}}_{u^k}$$

$$\beta_k = \underbrace{\alpha}_{const} |\omega^k|$$

$$x^k = x^{k-1} + \alpha \omega^k$$

В окрестности точки \tilde{x} , может быть $f(x^k) > f(x^{k-1})$

Теорема 13.2.1. Пусть $f(x)$ ограничена снизу и дифференцируема в E_n , а ее градиент удовлетворяет условию Липшица, т.е. $\forall x, y \in E_n$

$$|\nabla f(x) - \nabla f(y)| \leq L|x - y|$$

$L > 0$ — константа. Тогда $\{x^k\}$, определяемое рекуррентным соотношением

$$x^k = x^{k-1} + \alpha \omega^k$$

с $\alpha \in (0, \frac{2}{L})$ является релаксационной. При этом справедлива оценка

$$f(x^k) \leq f(x^{k-1}) - \alpha \left(1 - \frac{\alpha L}{2}\right) \cdot |\nabla f(x^{k-1})|^2$$

и $|\nabla f(x^k)| \rightarrow 0$, при $k \rightarrow +\infty$

Если $f(x)$ удовлетворяет [теореме](#), то при $\alpha = \frac{1}{L}$, $\{x^k\}$ — релаксационная последовательность и не происходит “проскакивания” стационарной точки

$$\|\omega^k\| = \|\nabla f(x^{k-1})\| \leq L|x^{k-1} - \tilde{x}|$$

\tilde{x} — стационарная точка $\implies \nabla f(\tilde{x}) = 0$

При $\alpha \leq \frac{1}{L}$

$$|x^k - x^{k-1}| = \alpha|\omega^k| \leq |x^{k-1} - \tilde{x}|$$

Пусть $f(x)$ ограничена снизу, а $\{x^k\}$, при $\gamma_0 > 0$:

$$f(x^{k-1}) - f(x^k) \geq \gamma_0|\omega^k|^2 \quad k = \overline{1, m} \quad (13.2)$$

$$f(x^0) - f(x^m) \geq \gamma_0 \sum_{k=1}^m |\nabla f(x^{k-1})|^2$$

$$\sum_{k=1}^{\infty} |\nabla f(x^{k-1})|^2$$

— знакоположительный ряд, т.е. $\nabla f(x^k) \xrightarrow[k \rightarrow \infty]{} 0$

13.2.2 Модификация

$$x^k = x^{k-1} + \alpha_k \omega^k \quad k \in \mathbb{N}$$

$\alpha_k > 0$

$$\varphi_k(\alpha) = f(x^{k-1} + \alpha \omega^k)$$

$$\varphi'_k(0) = (\nabla f(x), \omega^k) = -|\omega^k|^2 < 0$$

φ_k — убывает в окрестности $\alpha = 0$ до $\tilde{\alpha}_k$. $\alpha_k = \alpha_k^*$ — исчерпывающий спуск. Если $f(x)$ удовлетворяет [теореме](#), то $\{x^k\}$ по исчерпывающему спуску удовлетворяет условиям [13.2](#):

$$\varphi'_k(\alpha) = (\nabla f(x^{k-1} + \alpha \omega^k), \omega^k)$$

$$x^k = x^{k-1} + \alpha_k^* \omega^k$$

$$(\omega^{k+1}, \omega^k) = (-\nabla f(x^k), \omega^k) = -\varphi'_k(\alpha_k^*) = 0$$

$$\begin{aligned} \|\omega^k\|^2 &= (\omega^k, \omega^k - \omega^{k+1}) \leq |\omega^k| \cdot |\omega^k - \omega^{k+1}| = \\ &= |\omega^k| \cdot |\nabla f(x^{k-1}) - \nabla f(x^k)| \leq L|\omega^k| \cdot |x^{k-1} - x^k| = L \cdot \alpha_k^* |\omega^k|^2 \end{aligned}$$

$\alpha_k^* \geq \frac{1}{L}$:

$$f(x^{k-1}) - f(x^k) \geq f(x^{k-1}) - f(\tilde{x}^k) \geq \frac{1}{2L} |\omega^k|^2$$

$$\tilde{x}^k = x^{k-1} + \underbrace{\frac{1}{L}}_{\alpha} \omega^k$$

Лекция 14

14.1 Минимизация квадратичной функции

$$f(x) = \frac{1}{2} \langle Ax, x \rangle + \langle b, x \rangle + c$$

- A — симметричная матрица
- $A = H$ — матрица Гессе $f(x)$

$$\nabla f(x) = Ax + b$$

Если A невырождена, то $f(x)$ в силу необходимого условия экстремума имеет единственную стационарную точку $x^* = -A^{-1}b$. x^* будет точкой наименьшего значения $f(x)$ тогда и только тогда, когда квадратичная форма $\langle Ax, x \rangle$ положительно определена

Пусть $x^* = 0$, то есть минимум квадратичной функции в начале координат (вектор $b = 0$), тогда будем рассматривать

$$f(x) = \frac{1}{2} \langle Ax, x \rangle \quad x \in E_n \quad (14.1)$$

A — положительно определена. Тогда квадратичная функция $\frac{1}{2} \langle Ax, x \rangle$ неотрицательная в E_n и достигает наименьшего значения 0 в единственной точке $x^* = 0$

Рассмотрим метод градиентного спуска. Для $f(x)$ из 14.1 $\nabla f(x) = Ax$ в точке x . Пусть $x^0 \neq 0$, тогда $w^1 = -\nabla f(x^0) = -Ax^0$

$$x^k = x^{k-1} + \alpha_k w^k \quad k \in \mathbb{N}$$

$$x^1 = x^0 + \alpha_1 w^1 - x^0 - \alpha_1 Ax^0 = (I - \alpha_1 A)x^0 \quad (14.2)$$

Из 14.2 следует:

- точку минимума квадратичной функции можно достичь за одну итерацию, если x^0 — собственный вектор матрицы $A \implies$ если x^0 — собственный вектор матрицы A , а λ_j — его собственное значение, то

$$Ax^0 = \lambda_j x^0 \text{ и } (A - \lambda_j I)x^0 = 0$$

Если $\alpha_1 = \frac{1}{\lambda_j}$

$$x^1 = (I - \frac{1}{\lambda_j} A)x^0 = -\frac{1}{\lambda_j} (A - \lambda_j I)x^0 = 0$$

тогда x^1 совпадает с точкой минимума $x^* = 0$

В 2-мерном случае $f(x) = \frac{1}{2} \langle Ax, x \rangle$ — эллиптический параболоид с центром в начале координат.

Метод градиентного спуска приведет в точку $(0, 0)$ за одну итерацию, если начальная точка выбрана на одной из осей эллипсов: радиус-вектор точки является собственным вектором матрицы A .

- **Частный случай** $A = \lambda I$ — все собственные значения A совпадают, а каждый ненулевой вектор $x \in E_n$ является собственным. Тогда минимум функции $f(x)$ 14.1 достигается за одну итерацию при любом выборе x^0

Квадратичную форму 14.1 невырожденной заменой переменных можно привести к каноническому виду с единичной матрицей. Применим ортогональное преобразование к квадратичной форме, тогда

$$f_1(\xi) = \sum_{j=1}^n \lambda_j \xi_j^2$$

, $\xi = (\xi_1, \dots, \xi_n)$, λ_j — положительные собственные значения A ($j = \overline{1, n}$)

Изменим масштабы переменных, введем замену

$$\eta_j = \sqrt{\lambda_j} \xi_j \quad j = \overline{1, n}$$

тогда

$$f_2(\eta) = \sum_{j=1}^n \eta_j^2 \quad \eta = (\eta_1, \dots, \eta_n)$$

В новых переменных η_1, \dots, η_n минимум квадратичной функции методом градиентного спуска достигается за одну итерацию при любом выборе начальной точки x^0

- Недостаток — трудоемкие вычисления, сложности решения задачи на собственные значения A
- Преимущества — полезен метод, когда функция имеет овражный характер

Рассмотрим метод градиентного спуска с $\alpha_k = \alpha = const$ на всех итерациях

На k -й итерации

$$x^k = x^{k-1} - \alpha \nabla f(x^{k-1}) = (I - \alpha A)x^{k-1} \quad (14.3)$$

Заключение о сходимости $\{x^k\}$ можно сделать на основе теоремы о неподвижной точке. Согласно теореме $\{x^k\}$ сходится к неподвижной точке x^* отображения $f(x)$, если это отображение является **сжимающим**, то есть подчиняется условию Липшица

$$|f(x) - f(y)| \leq g|x - y| \quad g = const < 1 \quad (14.4)$$

В 14.3 отображение — линейный оператор, который является сжимающим отображением, если имеет норму, меньше единицы. Норма = спектральная норма (для симметричной матрицы) = $|\lambda_{\max}|$

В итоге для сходимости $\{x^k\}$:

$$x^k = x^{k-1} - \alpha \nabla f(x^{k-1}) \quad \alpha > 0$$

согласно 14.3 и теореме о неподвижной точке достаточно выполнения

$$g(\alpha) = \|I - \alpha A\| < 1$$

Для квадратичной функции с положительно определенной матрицей A с собственными значениями $0 < \lambda_1 < \dots < \lambda_n$ матрицы $I - \alpha A$ имеет собственные значения $1 - \alpha \lambda_j$, $j = \overline{1, n}$:

$$1 - \alpha \lambda_n < 1 - \alpha \lambda_{n-1} < \dots < 1 - \alpha \lambda_1 < 1$$

Тогда условие

$$g(\alpha) = \|I - \alpha A\| < 1$$

равносильно

$$\begin{cases} 1 - \alpha \lambda_n > -1 \\ 1 - \alpha \lambda_n < 1 \end{cases} \implies \alpha \in \left(0, \frac{2}{\lambda_n}\right)$$

из теоремы о неподвижной точке следует, что для $\{x^k\}$ верна оценка $|x^k - x^*| \leq g^k |x^0 - x^*|$, g — постоянная Липшица (из 14.4)

Для ускорения сходимости $\{x^k\}$ g должно быть как можно меньше. В рассматриваемом случае $g(\alpha) = \min$, когда собственные значения $1 - \alpha \lambda_n$ и $1 - \alpha \lambda_1$ матрицы $I - \alpha A$ совпадают по абсолютной величине и противоположны по знаку

$$-(1 - \alpha \lambda_1) = 1 - \alpha \lambda_n$$

, откуда оптимальное α :

$$\alpha^* = \frac{2}{\lambda_1 + \lambda_n} \leq \frac{2}{\lambda_n}$$

Выбирая $\alpha = \alpha^*$

$$g^* = g(\alpha^*) = \frac{\lambda_n - \lambda_1}{\lambda_n + \lambda_1} = \frac{\text{cond}(A) - 1}{\text{cond}(A) + 1} \quad (14.5)$$

$$\text{cond}(A) = \frac{\lambda_n}{\lambda_1}$$

$\text{cond}(A) \gg 1$ — овражная структура, $\{x^k\}$ сходится медленно

- Если $A = I$, то все собственные значения = 1, поэтому $\text{cond}(A) = 1$ и $g^* = 0$, тогда минимум достигается за одну итерацию при любом выборе x^0
- Если $\alpha \notin \left(0, \frac{2}{\lambda_n}\right)$, $\{x^k\}$ не релаксационная, а метод расходится или заикликивается

14.1.1 Минимизация с использованием исчерпывающего спуска

$$f(x) = \frac{1}{2} \langle Ax, x \rangle$$

происходит с нарушением условия $\alpha_k \in \left(0, \frac{2}{\lambda_n}\right)$ Исчерпывающий спуск на k -й итерации: поиск стационарной точки $\varphi_k(\alpha) = f(x^{k-1} + \alpha w^k)$

$$\varphi_k(\alpha) = \frac{1}{2} \langle A(x^{k-1} + \alpha w^k), x^{k-1} + \alpha w^k \rangle = f(x^{k-1}) + \alpha \langle Ax^{k-1}, w^k \rangle + \frac{\alpha^2}{2} \langle Aw^k, w^k \rangle$$

— функция с положительным коэффициентом при старшей степени, поэтому они имеют единственную стационарную точку

$$\alpha_k = -\frac{\langle Ax^{k-1}, w^k \rangle}{\langle Aw^k, w^k \rangle} = \frac{|w^k|^2}{\langle Aw^k, w^k \rangle} \quad (14.6)$$

Из 14.6:

- $\alpha_k = \frac{1}{\lambda_n}$, если x^{k-1} собственный вектор A с собственным значением λ_n
- $\alpha_k = \frac{1}{\lambda_1}$, если x^{k-1} собственный вектор A с собственным значением λ_1

$$\lambda_1 < \lambda_2 < \dots < \lambda_n \quad \frac{1}{\lambda_1} > \frac{1}{\lambda_2} > \dots > \frac{1}{\lambda_n}$$

Если $\text{cond}(A) = \frac{\lambda_n}{\lambda_1} > 2$, то $\alpha_k \in \left(0, \frac{2}{\lambda_n}\right)$ нарушается при $\alpha_k = \frac{1}{\lambda_1}$

При $\alpha = \text{const}$ шаг определяется без учета скорости убывания функции. В случае наискорейшего спуска шаг спуска тем больше, чем медленнее функция убывает

Замечание. Для квадратичной функции метод наискорейшего спуска эквивалентен градиентному методу с исчерпывающим спуском (т.к. квадратичная функция является строго выпуклой)

14.1.2 Метод сопряженных направлений

$$x^k = x^{k-1} + \alpha_k p^k \quad k \in \mathbb{N} \quad (14.7)$$

α_k — шаг, p^k — вектор спуска $\in E_n$ (может быть не единичным)

Рассмотрим квадратичную функцию (частный случай) $f(x) = \frac{1}{2} \langle Ax, x \rangle$, A — положительно определенная матрица. $f(x)$ можно привести к каноническому виду

$$f_2(\eta) = \sum_{j=1}^n (\eta_j)^2 \quad \eta = (\eta_1, \dots, \eta_n) \quad (14.8)$$

в переменных η метод градиентного спуска сходится за одну итерацию. Минус такого подхода — вычисление градиента к координатам η , приведение к каноническому виду затратная операция

Необходим другой подход: Линейная невырожденная замена переменных в квадратичной формуле \sim переход в E_n от одного базиса к другому. Тогда приведение к каноническому виду = выбор базиса в E_n . Если A симметричная, положительно определенная матрица, то $\langle x, y \rangle_A = \langle Ax, y \rangle$ — скалярное произведение в E_n , $\langle Ax, x \rangle$ — квадрат евклидовой нормы вектора x в евклидовом пространстве с указанным скалярным произведением. Приведение квадратичной формы к каноническому виду = выбор ортонормированного базиса в евклидовом пространстве со скалярным произведением $\langle x, y \rangle_A$

Плюсы подхода

- позволяет упростить вид квадратичной формы
- вместо решения задачи на собственные значения можно использовать процедуру построение ортогонального базиса (процесс ортогонализации)

1. Условие ортогональности

$$p^1 \neq 0 \quad p^2 \neq 0$$

относительно скалярного произведения $\langle x, y \rangle_A$ имеет вид

$$\langle Ap^1, p^2 \rangle = 0$$

Такие вектора называются сопряженными относительно положительно определенной матрицы A , или A -ортогональными. Направления, определяемые p^1 и p^2 , сопряженные направления.

Рассмотрим A -ортогональный базис p^j , $j = \overline{1, n}$. В этом базисе $f(x) = \frac{1}{2} \langle Ax, x \rangle$ имеет канонический вид

$$f_1(\xi) = \lambda_1 \xi_1^2 + \dots + \lambda_n \xi_n^2 \quad \xi = (\xi_1, \dots, \xi_n)$$

, $\lambda_j > 0$, $j = \overline{1, n}$ — определяются нормами $\|p^j\|_A$ с введенным скалярным произведением

$$\lambda_j = \frac{1}{2} \|p^j\|_A^2$$

Замечание. $f_1(\xi)$ — половина квадрата нормы вектора (ξ_1, \dots, ξ_n) . Если $p^j = 0, 0, \dots, \frac{1}{2}, \dots, 0$

\implies

$$\lambda_j = \frac{1}{2} \|p^j\|_A^2$$

Функция $f_1(\xi)$ — сепарабельна:

- исчерпывающий спуск в направлении p^j — минимизация одного из слагаемых такой функции
- последовательность из n исчерпывающих спусков в направлении p^1, \dots, p^n все слагаемые \implies в точку минимума

Выберем x^0 , исчерпывающий спуск для квадратичной функции $f(x)$ в направлении p^1 — исчерпывающий спуск для $f_1(\xi)$ в направлении первого базисного вектора и приведет к обнулению первой координаты точки x^0 в базисе p^1, \dots, p^n . Следовательно $x^1 = x^0 - \xi_1^0 p^1$, где ξ_1^0 — первая координата x^0 в ортогональном базисе p^j :

$$\xi_1^0 = \frac{\langle Ax^0, p^1 \rangle}{\langle Ap^1, p^1 \rangle}$$

Сравним $x^1 = x^0 - \xi_1^0 p^1$ и $x^k = x^{k-1} + \alpha_k p^k$. Повторим схему для всех p^j

Теорема 14.1.1. Точка минимума квадратичной функции $f(x) = \frac{1}{2} \langle Ax, x \rangle$ с положительно определенной матрицей A достигается не более чем за n итераций спуска, если направления спуска задаются векторами $p^k \in E_n$, сопряженными относительно матрицы A , а параметры α_k , определяющие шаг спуска в 14.7, вычисляются по формуле исчерпывающего спуска

$$\alpha_k = -\frac{\langle Ax^{k-1}, p^k \rangle}{\langle Ap^k, p^k \rangle} \quad k = \overline{1, n} \quad (14.9)$$

Замечание. Если p^j и $-p^j$ в точке x^{k-1} не определяют направление спуска, то $\langle Ax^{j-1}, p_j \rangle = 0$, значит $\alpha_j = 0 \implies$ спуск в направлении p^j не производится, количество итераций $< n$

Координаты произвольного x^0 в A -ортогональном базисе можно выразить через скалярное произведение:

$$x^0 = \sum_{i=1}^n \frac{\langle Ax^0, p^i \rangle}{\langle Ap^i, p^i \rangle} p^i \quad (14.10)$$

Если x^* — точка минимума квадратичной формы с положительно определенной матрицей A , то

$$x^0 - x^* = \sum_{i=1}^n \frac{\langle A(x^0 - x^*), p^i \rangle}{\langle Ap^i, p^i \rangle} p^i = \sum_{i=1}^n \frac{\langle \nabla f(x^0), p^i \rangle}{\langle Ap^i, p^i \rangle} p^i$$

$$x^* = x^0 - \sum_{i=1}^n \frac{\langle \nabla f(x^0), p^i \rangle}{\langle Ap^i, p^i \rangle} p^i \quad (14.11)$$

Замечание.

$$\langle Ax^0, p^i \rangle = p^i \langle p^i, Ax^0 \rangle = p^i (p^i)^T Ax^0$$

Тогда 14.10 примет вид:

$$x^0 = \sum_{i=1}^n \frac{p^i (p^i)^T}{\langle Ap^i, p^i \rangle} Ax^0$$

— верно для любого x^0 , значит линейный оператор в E_n с матрицей

$$\sum_{i=1}^n \frac{p^i (p^i)^T}{\langle Ap^i, p^i \rangle} A$$

является тождественным и

$$A^{-1} = \sum_{i=1}^n \frac{p^i (p^i)^T}{\langle Ap^i, p^i \rangle} \quad (14.12)$$

таким образом система векторов p^1, \dots, p^n сопряженных относительно положительно определенной матрицы A , позволяет построить A^{-1} . Тогда 14.11 перепишем в виде

$$\begin{aligned} x^* &= x^0 - \sum_{i=1}^n \frac{\langle \nabla f(x^0), p^i \rangle}{\langle Ap^i, p^i \rangle} p^i = \\ &= x^0 - \sum_{i=1}^n \frac{p^i (p^i)^T}{\langle Ap^i, p^i \rangle} \nabla f(x^0) = x^0 - A^{-1} \nabla f(x^0) \end{aligned}$$

Для квадратичной функции $f(x)$ выполнение n итераций исчерпывающего спуска \sim одному спуску вида

$$x^* = x^0 - A^{-1} \nabla f(x^0)$$

Замечание. Использование векторов p^j — основа метода сопряженных направлений

Различие в способах построения сопряженных векторов — порождает несколько вариантов метода сопряженных направлений

2. Рассмотрим минимизацию

$$f(x) = \frac{1}{2} \langle Ax, x \rangle + \langle b, x \rangle$$

- можно использовать любой базис, проводя процесс ортогонализации относительно скалярного произведения $\langle x, y \rangle_A$
- более эффективно исходить их системы антиградиентов, тем самым объединяя в процессе спуска процесс ортогонализации

Выберем $x^0 \in E_n$:

$$w^1 = -\nabla f(x^0) = -Ax^0 - b$$

$p^1 = w^1$, если $|p^1| \neq 0$, то p^1 — направление спуска, иначе $x^0 = x^*$

Проводим исчерпывающий спуск в направлении $p^1 = w^1$ (по формуле 14.6)

$$\alpha_1 = \frac{|w^1|^2}{\langle Aw^1, w^1 \rangle} = \frac{|p^1|^2}{\langle Ap^1, p^1 \rangle}$$

$$x^1 = x^0 + \alpha_1 p^1$$

Вторая итерация:

$$w^2 = -Ax^1 - b$$

если $|w^2| = 0$, $x^1 = x^*$, иначе проводим ортогонализацию p^1 и w^2 относительно скалярного произведения $\langle x, y \rangle_A$:

$$p^2 = w^2 - \frac{\langle Ap^1, w^2 \rangle}{\langle Ap^1, p^1 \rangle} p^1 \quad (14.13)$$

$\langle w^2, p^1 \rangle = 0$ поскольку w^2 и p^1 — антиградиенты на двух последовательных итерациях исчерпывающего спуска, а значит w^2 и p^1 — линейно независимы, а $|p^2| \neq 0$. Вектор p^2 — направление спуска из x^1 , учитывая ортогональность w^2 и p^1 :

$$\langle \nabla f(x^1), p^2 \rangle = -\langle w^2, \beta_1 p^1 + w^2 \rangle = -\langle w^2 w^2 \rangle = -|w^2|^2 < 0$$

$$\beta_1 = -\frac{\langle Ap^1, w^2 \rangle}{\langle Ap^1, p^1 \rangle}$$

Продолжим процесс исчерпывающего спуска вдоль очередного направления, полученного корректировкой антиградиента в текущей точке, получим n сопряженных направлений спусков и достигнем точки минимума через n итераций (или раньше)

3. Уточнения

- (а) каждый w^k ортогонален не только предпоследнему направлению спуска p^{k-1} , но и всем $p^i, i = \overline{1, k-2}$

$$w^j = -Ax^{j-1} - b \implies w^k - x^{k-1} = -A(x^{k-1} - x^{k-2}) = -\alpha_{k-1} Ap^{k-1}$$

при $k-1 > j$:

$$\langle w^k, p^i \rangle = \langle w^{k-1}, p^i \rangle - \alpha_{k-1} \langle Ap^{k-1}, p^i \rangle = \langle w^{k-1}, p^i \rangle$$

следовательно

$$\langle w^k, p^i \rangle = \langle w^{k-1}, p^i \rangle = \dots = \langle w^{i+1}, p^i \rangle = 0$$

Вывод: w^k и $w^i, k > i$ — ортогональны, т.к. w^i — линейная комбинация p^1, \dots, p^n , ортогональных w^k

- (б) антиградиент w^k сопряжен со всеми $p^i, i < k-1$:

$$\alpha_i \langle Ap^i, w^k \rangle = \langle w^i - w^{i+1}, w^k \rangle = \langle w^i, w^k \rangle - \langle w^{i+1}, w^k \rangle = 0$$

Из 1, 2 следует, что процесс ортогонализации

$$\begin{aligned} p^k &= w^k - \sum_{i=1}^{k-1} \frac{\langle Ap^i, w^k \rangle}{\langle Ap^i, p^i \rangle} p^i \implies \\ \implies p^k &= w^k - \frac{\langle Ap^{k-1}, w^k \rangle}{\langle Ap^{k-1}, p^{k-1} \rangle} p^{k-1} \end{aligned}$$

Замечание. главный плюс при использовании в процессе ортогонализации последовательности антиградиентов

4. Общая схема для $k = 1$: x^0

$$\begin{aligned} w^1 &= -Ax^0 - b \\ p^1 &= w^1 \\ \alpha_1 &= \frac{|p^1|^2}{\langle Ap^1, p^1 \rangle} \end{aligned}$$

для $k > 1$:

$$\begin{cases} w^k = -Ax^{k-1} - b \\ p^k = w^k - \frac{\langle Ap^{k-1}, w^k \rangle}{\langle Ap^{k-1}, p^{k-1} \rangle} p^{k-1} \\ x^k = x^{k-1} + \alpha_k p^k \end{cases} \quad (14.14)$$

α_k — определять из условия исчерпывающего спуска, например

$$\alpha_k = \frac{\langle w^k, p^k \rangle}{\langle Ap^k, p^k \rangle} \quad (14.15)$$

На каждой итерации выполняются

$$\begin{aligned} \langle w^k, w^i \rangle &= 0 \quad k \neq i \\ \langle w^k, p^i \rangle &= 0 \quad k > i \\ \langle Ap^k, p^i \rangle &= 0 \quad k \neq i \end{aligned}$$

Метод сопряженных направлений можно использовать для неквадратичной функции: в 14.14 A заменить матрицей Гессе $f(x)$, тогда получим: При $k = 1$: x_0

$$\begin{aligned} w^1 &= -\nabla f(x^0) \\ p^1 &= w^1 \end{aligned}$$

При $k > 1$:

$$\begin{cases} w^k = -\nabla f(x^{k-1}) \\ p^k = w^k + \beta_k p^{k-1} \\ x^k = x^{k-1} + \alpha_k p^k \end{cases} \quad (14.16)$$

$$\beta_k = -\frac{\langle H_k p^{k-1}, w^k \rangle}{\langle H_k p^{k-1}, p^{k-1} \rangle} \quad (14.17)$$

, H — матрица Гессе, α_k — из условия исчерпывающего спуска (например из 14.15)

14.1.3 Модификации

Для квадратичной функции — без использования A

1. Метод сопряженных градиентов $w^{k-1} - w^k = \alpha_{k-1} Ap^k \quad k > 1$

$$\langle Ap^{k-1}, w^k \rangle = \frac{\langle w^{k-1} - w^k, w^k \rangle}{\alpha_{k-1}} = -\frac{|w^k|^2}{\alpha_{k-1}} \quad (14.18)$$

$$\langle Ap^{k-1}, p^{k-1} \rangle = \frac{\langle w^{k-1} - w^k, p^{k-1} \rangle}{\alpha_{k-1}} = \frac{\langle w^{k-1}, p^{k-1} \rangle}{\alpha_{k-1}} \quad (14.19)$$

Выполнив замену в 14.14, получим 14.16, где

$$\beta_k = \frac{|w^k|^2}{\langle w^{k-1}, p^{k-1} \rangle} \quad k = 2, \dots \quad (14.20)$$

2. Метод Флетчера-Ривса

$$p^{k-1} = w^{k-1} + \beta_k p^{k-1}$$

p^{k-1} и p^{k-2} ортогональны \implies

$$\begin{aligned} \langle p^{k-1}, w^{k-1} \rangle &= |w^{k-1}|^2 + \beta_k \langle p^{k-2}, w^{k-1} \rangle = |w^{k-1}|^2 \implies \\ \implies \beta_k &= \frac{|w^k|^2}{|w^{k-1}|^2} \quad k = 2, \dots \end{aligned} \quad (14.21)$$

3. Метод Полака-Рибьера w^k и w^{k-1} — ортогональны

$$\begin{aligned} |w^k|^2 &= \langle w^k - w^{k-1}, w^k \rangle \implies \\ \implies \beta_k &= \frac{\langle w^k - w^{k-1}, w^k \rangle}{|w^{k-1}|^2} \quad k = 2, \dots \end{aligned} \quad (14.22)$$

14.1.4 Выводы

14.20-14.22 эквивалентны для квадратичных функций, для неквадратичных приводят к разным итерационным процессам. Для неквадратичных функций точку минимума не удастся найти за конечное число шагов, а процесс может оказаться расходящимся или зацикливающимся.

α_k в общем случае находится численно, решая задачу одномерной минимизации \implies погрешность на каждой итерации, что снижает скорость сходимости или приводит к расходимости

Чтобы снизить влияние погрешности используют ‘обновление’ алгоритма:

1. $\beta_k = 0$ через заданное число итераций (моменты рестарта кратные n). Это позволяет избежать накопления вычислительных погрешностей и уменьшить вероятность построения после каждых n итераций линейно зависимых направлений спуска, но приводит к росту общего числа итераций
2. На практике метод работает $\leq n$ итераций, рестарт может не вызваться ни разу. Альтернативный вариант рестарта — условие Пауэлла:

$$|\langle \nabla f(x^k), \nabla f(x^{k+1}) \rangle| \geq v \|\nabla f(x^{k+1})\|^2$$

— оптимально выбрать $v = 0.1$

Метод Флетчера-Ривса без рестартов является менее эффективным. Наиболее популярным является метод Полака-Рибьера

Замечание. Линейный метод Флетчера-Ривса

- в начальной точке x^0 :

$$w^1 = -\nabla f(x^0) \quad p^1 = w^1$$

- $k > 1$, α_k — линейный поиск

$$x^k = x^{k-1} + \alpha_k p^k$$

$$\beta_k = \frac{|w^k|^2}{|w^{k-1}|^2}$$

$$p^k = w^k + \beta_k p^{k-1}$$

В общем случае метод Флетчера-Ривса не гарантирует того, что p^k — направление спуска

- существует доказательство того, что если в линейном поиске (одномерная минимизация) используются сильные условия Вульфа с $c_2 < \frac{1}{2}$, то p^k будет направлением спуска (то есть поиск должен быть точнее)
- Сильное условие Вульфа:

$$\Phi_k(\alpha) \leq \Phi_k(0) + c_1 \alpha \Phi'_k(0)$$

$$|\Phi'_k(\alpha)| \leq c_2 |\Phi'_k(0)|$$

используются квадратичные/кубические аппроксимации

Лекция 15

15.1 Метод Ньютона

Если целевая функция дважды дифференцируема в пространстве E_n в процессе поиска можно использовать не только информации о градиенте, но и матрице Гесса. Для оптимизируемой функции $f(x) \in E_n$ разложение по формуле Тейлора:

$$\begin{aligned} f(x) &= f(x^{k-1}) + (\nabla f(x^{k-1}), x - x^{k-1}) + \frac{1}{2}(H(x^{k-1})(x - x^{k-1}), x - x^{k-1}) + o(|x - x^{k-1}|) \\ \varphi_k(x) &= f(x^{k-1}) + (\nabla f(x^{k-1}), x - x^{k-1}) + \frac{1}{2}(H(x^{k-1})(x - x^{k-1}), x - x^{k-1}) \\ \nabla \varphi_k(x) &= \nabla f(x^{k-1}) + H(x^{k-1})(x - x^{k-1}) \\ & \quad [\nabla(a^T x) = a; \quad \nabla(x^T A x) = 2Ax] \\ x^k &= x^{k-1} - H^{-1}(x^{k-1})\nabla f(x^{k-1}) \quad k \in \mathbb{N} \end{aligned} \tag{15.1}$$

\tilde{x}^k — вспомогательная точка для построения релаксационной последовательности $\{x^k\}$

$$x^k = x^{k-1} + \alpha_k(\tilde{x}^k - x^{k-1}) = x^{k-1} + \alpha_k p^k \quad \alpha_k > 0 \tag{15.2}$$

$p^k = \tilde{x}^k - x^{k-1}$ — направление спуска

$$p^k = -H^{-1}(x^{k-1})\nabla f(x^{k-1}) \tag{15.3}$$

$$(\nabla f(x^{k-1}), p^k) = -(\nabla f(x^{k-1}), H^{-1}(x^{k-1})\nabla f(x^{k-1})) < 0$$

H — положительно определена $\implies H^{-1}$ — положительно определена Выбор $\alpha_k \rightarrow$

1. $\varphi_k(\alpha) = f(x^{k-1} + \alpha p^k) \rightarrow \min$
2. исчерпывающий спуск по p^k
3. дробление α_k

$f(x)$ — квадратичная функция с положительно определенной матрицей A . $x^0 - p^k$ — ньютоновское направление \implies точка минимума за одну итерацию

$$f(x) = \frac{1}{2}(Ax, x) + (b, x); \quad A = H$$

$$p^1 = -A^{-1}\nabla f(x^0) = -A^{-1}(Ax^0 + b) = -x^0 - A^{-1}b$$

$$x^1 = x^0 + p^1 = -A^{-1}b$$

15.1.1 Сходимость метода Ньютона

- Зависит от x^0 . Если $f(x)$ сильно выпуклая и $\forall x, y \in E_n$

$$H(x) : \|H(x) - H(y)\| \leq L|x - y| \quad L > 0$$

и удачный выбор x^0 (x^0 близок к x^*), то метод Ньютона при $\alpha_k = 1$ в 15.2 обладает квадратичной сходимости

$$|x^k - x^*| \leq C|x^{k-1} - x^*|^2 \quad C = const$$

Если $f(x)$ не является сильно выпуклой или начальное приближение x^0 далеко от x^*
 \implies метод Ньютона может расходиться

Алгоритм 6 Метод Ньютона

повторять

Вычислить $\nabla f(x)$

$$H = \nabla^2 f(x)$$

Решить СЛАУ: $Hp^k = -\nabla f(x)$

$$x^k = x^{k-1} + p^k$$

до тех пор пока $\|x^k - x^{k-1}\| < \varepsilon$ ($\|p^k\| < \varepsilon$)

$$x^* = x^k$$

15.1.2 Метод Ньютона с одномерным поиском

$x^k \rightarrow$ одномерный поиск в направлении p^k

$$\alpha_k = \min_{\alpha} f(x^k + \alpha p^k) \tag{15.4}$$

$$H(x^{k-1})p^k = -\nabla f(x^{k-1})$$

Пока $\|x^k - x^{k-1}\| \geq \varepsilon$ — итерации продолжать

Алгоритм 7 Метод Ньютона с одномерным поиском

повторять

Вычислить $\nabla f(x)$

$$H = \nabla^2 f(x)$$

Решить СЛАУ: $Hp^k = -\nabla f(x)$

$$\alpha_k = \min_{\alpha} f(x^{k-1} + \alpha p^k)$$

$$x^k = x^{k-1} + \alpha_k p^k$$

до тех пор пока $\|x^k - x^{k-1}\| < \varepsilon$ ($\|p^k\| < \varepsilon$)

$$x^* = x^k$$

Метод надежнее обычного метода Ньютона, но его эффективность существенно зависит от того, является ли p^k направлением спуска

15.1.3 Метод Ньютона с направлением спуска

Если p^k — направление спуска: $(p^k)^T \nabla f(x^k) < 0$. Если $(p^k)^T \nabla f(x^k) > 0$, то p^k — не является направлением спуска, в этом случае использовать антиградиент $-\nabla f(x^k)$.

$$H(x^k)p^k = -\nabla f(x^k) \implies p^k = \begin{cases} p^k & (p^k)^T \nabla f(x^k) < 0 \\ -\nabla f(x^k) & (p^k)^T \nabla f(x^k) > 0 \end{cases} \quad (15.5)$$

$$x^1 = x^0 + \alpha_0 p^0 \quad p^0 = -\nabla f(x^0) \quad \alpha_0 = \min_{\alpha} f(x^0 + \alpha p^0) \quad (15.6)$$

($k > 1$)

$$x^k = x^{k-1} + \alpha_k p^k \quad \alpha_k = \min_{\alpha} f(x^{k-1} + \alpha p^{k-1}) \quad (15.7)$$

$$\|x^k - x^{k-1}\| > \varepsilon$$

Алгоритм 8 Метод Ньютона с направлением спуска

повторять

Вычислить $\nabla f(x)$

$H = \nabla^2 f(x)$

Решить СЛАУ: $H p^k = -\nabla f(x)$

если $(p^k)^T \nabla f(x^k) > 0$ **тогда**

$p^k = -\nabla f(x^k)$

конец если

$\alpha_k = \min_{\alpha} f(x^{k-1} + \alpha p^k)$

$x^k = x^{k-1} + \alpha_k p^k$

до тех пор пока $\|x^k - x^{k-1}\| < \varepsilon$ ($\|p^k\| < \varepsilon$)

$x^* = x^k$

15.1.4 Метод Ньютона с дроблением шага

$$f(x^{k-1}) - f(x^k) \geq -\omega \alpha_k (\nabla f(x^{k-1}), p^k) \quad \omega \in \left(0, \frac{1}{2}\right) \quad (15.8)$$

Начальное $\alpha_k = 1 \implies$ проверим условие 15.8, если нарушено, то α_k — корректировка, $\alpha_k^* \nu$, ν — коэффициент, снова проверка \dots , $\nu \in (0, 1)$

Алгоритм 9 Метод Ньютона с дроблением шага**Ввод** $\nu \in (0, 1)$ **повторять**Вычислить $\nabla f(x)$ $H = \nabla^2 f(x)$ Решить СЛАУ: $H p^k = -\nabla f(x)$ **если** $(p^k)^T \nabla f(x^k) > 0$ **тогда** $p^k = -\nabla f(x^k)$ **конец если** $\alpha_k = \min_{\alpha} f(x^{k-1} + \alpha p^k)$ **пока** $f(x^{k-1}) - f(x^k) < -\omega \alpha_k (\nabla f(x^{k-1}), p^k)$ **делать** $\alpha_k = \alpha_k \cdot \nu$ **конец пока** $x^k = x^{k-1} + \alpha_k p^k$ **до тех пор пока** $\|x^k - x^{k-1}\| < \varepsilon$ ($\|p^k\| < \varepsilon$) $x^* = x^k$ **15.1.5 О сходимости**Квадратичная сходимость: $|x^k - x^*| \leq L|x^{k-1} - x^*|^2$ 1. x^0 $H(x^0), H^{-1}$

$$p^k = -H^{-1}(x_0) \nabla f(x^{k-1}) \quad (15.9)$$

Если $H(x^0)$ не является положительно определенной, то в 15.9

$$\tilde{H}^1 = \tau_1 I + H(x^0)$$

, $\tau_1 \implies \tilde{H}^1$ — положительно определенная. Этот подход дает линейную скорость сходимости $|x_k - x^*| \leq q|x^{k-1} - x^*|$, $q > 0$ 2. H — обновляется через фиксированное количество итераций m $H^{-1}(x^0)$ $2m$ $H^{-1}(x^m)$ Этот подход имеет сверхлинейную скорость сходимости: $|x^{km} - x^*| \leq C|x^{(k-1)m} - x^*|^{m+1}$, $C > 0$ **15.2 Метод Марквардта**

Комбинация методов наискорейшего спуска и метода Ньютона

1. движение из x^0 в направлении $\nabla f(x)$ приводит к существенному уменьшению $f(x)$
2. направление эффективного поиска в окрестности точки x^* определяется по методу Ньютона

15.2.1 Идея метода

$$(H(x) + \tau I) p^k = -\nabla f(x) \quad (15.10)$$

, где τ — скалярный параметр, I — единичная матрица

При большом τ в 15.10 матрицей $H(x)$ можно пренебречь, тогда получим $\tau I p^k = -\nabla f(x)$, то есть $p^k = \frac{-\nabla f(x)}{\tau}$ — совпадает с направлением антиградиента — направлением наискорейшего спуска

При $\tau \rightarrow 0$ в 15.10 можно пренебречь τI , тогда $H(x) p^k = -\nabla f(x)$ — метод Ньютона

При промежуточном τ направление p^k лежит между направлением антиградиента и направлением метода Ньютона

15.2.2 Реализация

Выбираем $\tau \gg 1$. В процессе поиска $\tau_k = \tau_{k-1} \cdot \beta$, $\beta \in (0, 1)$. В этом случае на начальных шагах выполняются итерации по методу наискорейшего спуска, а на конечных — по методу Ньютона

$$\begin{aligned} x^k &= x^{k-1} + p^k \\ (H(x^{k-1}) + \tau_{k-1} I) p^k &= -\nabla f(x^{k-1}) \\ \tau_k &= \tau_{k-1} \cdot \beta \end{aligned} \quad (15.11)$$

$\|x^k - x^{k-1}\| < \varepsilon$ — условие останова

τ_k — позволяет изменять направление поиска и регулировать длину шага. Если шаг слишком большой и $f(x^{k+1}) > f(x^k)$, то $\tau_k = \frac{\tau_k}{\beta}$ и вновь применяют 15.11, но уже с меньшим p^k . Метод Марквардта позволяет устранить недостаток метода Ньютона, связанный с возможной плохой обусловленностью СЛАУ:

- для $I \implies \text{cond}(I) = 1$
- для $H \implies \text{cond}(H) \geq 1$

В общем случае H может быть вырожденной \implies СЛАУ 15.3 не имеет решения, однако СЛАУ 15.11 лишена этого недостатка

В точках, далеких от минимума, H является, как правило, плохо обусловленной, но в этих точках $\tau \gg 1$, поэтому

$$H + \tau U \approx \tau I$$

$$\text{cond}(H + \tau I) \approx \text{cond}(\tau I) = \|\tau U\| \cdot \|(\tau I)^{-1}\| = \tau \cdot 1 \cdot \frac{1}{\tau} = 1$$

поэтому в 15.11 СЛАУ хорошо обусловлена

Алгоритм 10 Метод Марквардта**Ввод** $x^0, \tau_0, \beta, \varepsilon$ $x = x_0$, вычислить $f(x)$ **повторять**вычислить $\nabla f(x)$, $H(x)$, $\tau = \tau_0 \cdot \beta$ **повторять**

$$\tau = \frac{\tau}{\beta}$$

СЛАУ: $(H(x) + \tau I)p = -\nabla f(x)$

$$y = x + p, f(y)$$

до тех пор пока $f(y) > f(x)$

$$x = y, f(x) = f(y), \tau_0 = \tau_0 \cdot \beta$$

до тех пор пока $\|p\| > \varepsilon$

Метод характеризуется:

- относительной простотой
- свойством убывания $f(x)$ при переходе от итерации к итерации
- высокой скоростью сходимости в окрестности x^*
- отсутствием процедуры одномерного поиска

В некоторых случаях метод Марквардта дополняют одномерным поиском, тогда

$$x^k = x^{k-1} + \alpha_k p^k$$

$$\alpha_k = \min_{\alpha} f(x^{k-1} + \alpha p^k)$$

$$(H(x^{k-1}) + \tau_k I) p^k = -\nabla f(x^{k-1})$$

$$\tau_k = \tau_{k-1} \cdot \beta$$

 $\|x^k - x^{k-1}\| < \varepsilon$ — условие останова**15.2.3 Другая вариация метода**

$$(H(x) + \tau I) p^k = -\nabla f(x)$$

Начать с $\tau = 0$

На каждой итерации проверять условие:

- $H(x) + \tau I > 0$ — положительно определена?
- если отрицательно определена, то $\tau = \max(1, 2\tau)$ и снова проверка

Замечание. Условие положительно определенной матрицы $H(x) + \tau I$ проверяется с помощью алгоритма Холецкого:

$$H(x) + \tau I = LL^T$$

, где L — нижнетреугольная матрица. Если разложение $H(x) + \tau I$ на LL^T возможно, то матрица > 0 Сложность этого алгоритма — $\frac{n^3}{3}$, сложность метода — число запусков алгоритма Холецкого. Метод Марквардта широко используется при решении задач, в которых целевая функция записывается в виде суммы квадратов

Лекция 16

16.1 Квазиньютоновские методы

- объединение достоинств
 1. наискорейшего спуска
 2. метода Ньютона
- не требует обращения матрицы H
- сохраняют высокую сходимость итерационной последовательности

16.1.1 Общий вид релаксационной последовательности

$$\begin{aligned}x^k &= x^{k-1} + \alpha_k p^k \\ p^k &= G_k w^k \quad k \in N \\ w^k &= -\nabla f(x^{k-1})\end{aligned}\tag{16.1}$$

G_k — положительно определенная матрица ($n \times n$) специального вида. Поскольку $G_k > 0$, то p^k задает направление спуска:

$$\langle \nabla f(x^{k-1}), p^k \rangle = -\langle w^k, G_k w^k \rangle = -\langle G_k w^k, w^k \rangle < 0$$

1. Вычисление матриц G_k

$$\{G_k\} \xrightarrow[k \rightarrow \infty]{} H^{-1}(x^*)$$

, где x^* — точка минимума

На первой итерации полагают $G_1 = I$ — выполняется градиентный спуск

2. Параметр α_k в 16.1

- задать $\alpha_k = 1$
- применить дробление шага
- использовать исчерпывающий спуск в направлении p^k (чаще всего используется на практике)

Поскольку $\{G_k\} \rightarrow \{H^{-1}(x^*)\}$, то G_k на завершающей стадии поиска близка к $H^{-1}(x^{k-1})$, используемой в методе Ньютона \implies квазиньютоновские методы сохраняют высокую скорость сходимости, присущую методу Ньютона. Таким образом G_k должна быть близка к $H^{-1}(x^*)$ и G_k получают путем аппроксимации $H^{-1}(x^{k-1})$

Выбор удачной аппроксимации может существенно сократить объем вычислений по сравнению с обращением матрицы H , тем самым упростить процедуру построения направления спуска p^k — **идея квазиньютоновских методов**
Каждую G_{k+1} строят, корректируя ранее вычисленную матрицу G_k

$$G_{k+1} = G_k + \Delta G_k \quad k \in \mathbb{N} \quad (16.2)$$

ΔG_k — положительно определенная матрица ($n \times n$) — **поправочная матрица**
Способ выбора ΔG_k определяет конкретный квазиньютоновский метод. На первой итерации $G_1 = I$

Пример. Пусть

$$f(x) = \frac{1}{2} \langle Ax, x \rangle + \langle b, x \rangle$$

, где A — положительно определенная

Тогда $\forall x : A = H, \nabla f(x) = Ax + b$

Введем: $\Delta w^k = w^k - w^{k-1}, \Delta x^k = x^k - x^{k-1}$, следовательно

$$\Delta w^k = \nabla f(x^{k-1}) - \nabla f(x^k) = A(x^{k-1} - x^k) = -A\Delta x^k$$

Таким образом, для квадратичной функции

$$A^{-1}\Delta w^k = -x^k, k \in \mathbb{N} \quad (16.3)$$

Иначе в виду 16.3 для общего случая потребуется, чтобы матрица G_{k+1} удовлетворяли условию

$$G_{k+1}\Delta w^k = -\Delta x^k \quad k \in \mathbb{N} \quad (16.4)$$

— **квазиньютоновское условие**

Для поправочных матриц условие 16.4 примет вид

$$\Delta G_k \Delta w^k = -\Delta x^k - G_k \Delta w^k$$

Этому условию удовлетворяют матрицы

$$\Delta G_k = -\frac{\Delta x^k y^T}{\langle \Delta w^k, y \rangle} - \frac{G_k \Delta w^k z^T}{\langle \Delta w^k, z \rangle} \quad (16.5)$$

$y, z \in E_n$ — выбираются произвольно, ΔG_k — симметричные матрицы (необходимое условие, чтобы аппроксимация H^{-1} давала симметричную матрицу)

Пусть в 16.5 $y = \Delta x^k, z = G_k w^k$ и учитывая 16.2, получим

$$G_{k+1} = G_k - \frac{\Delta x^k (\Delta x^k)^T}{\langle \Delta w^k, \Delta x^k \rangle} - \frac{G_k \Delta w^k (\Delta w^k)^T G_k^T}{\langle G_k \Delta w^k, \Delta w^k \rangle} \quad (16.6)$$

Формула 16.6 в сочетании с исчерпывающим спуском по направлениям векторов p^k — **метод Давидона-Флетчера-Пауэлла** (ДФП-метод)

- на первой итерации: $G_1 = I$, задается x^0

$$w^1 = -\nabla f(x^0) \quad p^1 = w^1$$

$$\alpha_1 = \min_{\alpha} f(x^0 + \alpha p^1)$$

$$x_1 = x^0 + \alpha p^1 \quad \Delta x^1 = x^1 - x^0$$

- $\forall k > 1$

$$\begin{aligned}
 w^k &= -\nabla f(x^{k-1}) \\
 \Delta w^k &= w^k - w^{k-1} \\
 v^k &= G_{k-1} \Delta w^k \\
 G_k &= G_{k-1} - \frac{\Delta x^{k-1} (\Delta x^{k-1})^T}{\langle \Delta w^k, \Delta x^{k-1} \rangle} - \frac{v^k (v^k)^T}{\langle v^k, \Delta w^k \rangle} \\
 p^k &= G_k w^k \\
 \alpha_k &= \min_{\alpha} f(x^{k-1} + \alpha p^k) \\
 x^k &= x^{k-1} + \alpha_k p^k \quad \Delta x^k = x^k - x^{k-1}
 \end{aligned}$$

условие останова $\|\Delta x^k\| < \varepsilon$

16.1.2 Свойства метода ДФП

Свойство 1. G_k по условию 16.6 сохраняет положительную определенность: если $G_k > 0$, то $G_{k+1} > 0$ (при условии $(\Delta x^k)^T \Delta w^k > 0$)

Свойство 2. Если в 16.6 G_k — симметричная, то G_{k+1} — симметричная

Свойство 3. При минимизации квадратичная функция с положительно определенной матрицей A метод ДФП сводится к методу сопряженных градиентов, т.к. первые n векторов p^k (задающих направление спуска) являются сопряженными относительно матрицы A . Следовательно ДФП-метод не более чем за n итераций дает точное решение квадратичной функции

Свойство 4. Матрицы G_k , вычисленные по ДФП-методу, связаны равенством

$$G_k A p^i = p^i \quad i = \overline{1, k} \quad k = \overline{1, n}$$

При $k = n$ следует, что n векторов p^i являются собственными для симметричной матрицы $G_n A$, а соответствующие собственные значения равны 1. Следовательно $G_n A = I$ и $G_n = A^{-1}$, т.е. G_n оказывается обратной к матрице Гессе $H(x^*) = A$ квадратичной функции в точке x^*

Свойство 5. Если $f(x)$ не является квадратичной, то ДФП-метод не позволяет найти минимум за конечное число итераций.

Чтобы ослабить влияние накапливаемых погрешностей на сходимость итерационной последовательности и уменьшить вероятность появления после очередных n итераций линейно зависимых направлений спуска, в ДФП-методе применяют процедуру ‘обновления’ алгоритма: через каждые n итераций в качестве G_n используют $G_n = I$

Свойство 6. Если $f(x)$ — квадратичная функция с $H > 0$, то ДФП-метод (с точным одномерным поиском) после n итераций дает

$$H^{-1} = \sum_{i=1}^n \frac{\Delta x^i (\Delta x^i)^T}{(\Delta x^i)^T \cdot \Delta w^i}$$

ДФП-метод очень чувствителен к точности одномерного поиска

16.1.3 Метод Бroyдена-Флетчера-Шенно (БФШ-метод)

На первой итерации $G_1 = I$, затем

$$G_{k+1} = G_k - \frac{\Delta x^k (\Delta x^k)^T}{\langle \Delta w^k, \Delta x^k \rangle} - \frac{G_k \Delta w^k (\Delta w^k)^T G_k^t}{\rho_k} + \rho_k r^k (r^k)^T \quad (16.7)$$

$$r^k = \frac{G_k \Delta w^k}{\rho_k} - \frac{\Delta x^k}{\langle \Delta x^k, \delta w^k \rangle}$$

$$\rho_k = \langle G_k \Delta w^k, \Delta w^k \rangle$$

16.1.4 Метод Пауэлла

На первой итерации $G_1 = I$, затем

$$G_{k+1} = G_k - \frac{\Delta \tilde{x}^k (\Delta \tilde{x}^k)^T}{\langle \Delta w^k, \Delta \tilde{x}^k \rangle} \quad k \in \mathbb{N} \quad (16.8)$$

$$\Delta \tilde{x}^k = \Delta x^k + G_k \Delta w^k$$

16.1.5 Способы построения G_k

- сохраняет свойство положительно определенности матрицы
- последовательность $\{G_k\} \xrightarrow[k \rightarrow \infty]{} H^{-1}(x^*)$

16.2 Сравнение методов

Методы:

- нулевого порядка (не используют значения производных)
- первого порядка (наискорейший спуск, сопряженные градиенты, квазиньютоновские методы)
- второго порядка (метод Ньютона и его модификации, метод Марквардта)

16.2.1 Сравнение по скорости

Методы порождают последовательность $\{x^k\}$:

$$\lim_{k \rightarrow \infty} x^k = x^*$$

тогда по свойству предела

$$\|x^{k+1} - x^*\| < \|x^k - x^*\|$$

поэтому

$$\frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} < 1$$

В этом случае говорят о сходимости метода

Пример. Если $f(x)$ — непрерывно дифференцируемая функция и $f(x) \rightarrow +\infty$ при $\|x\| \rightarrow +\infty$, то для любого x^0 метод наискорейшего спуска сходится к стационарной точке $f(x)$

- Глобальная сходимость методов сопряженных градиентов обеспечена с использованием рестартов. Тогда их глобальная сходимость следует из глобальной сходимости метода наискорейшего спуска
- Метод Ньютона не обладает свойством глобальной сходимости. Если x^0 далека от x^* , то метод не сходится
Но метод Ньютона с одномерным поиском и направлением спуска и метод Марквардта обладают глобальнойходимостью
- Квазиньютоновские методы ДФП и БФШ обладают глобальнойходимостью в случае применения рестартов

16.2.2 Оценка эффективности

Эффективность зависит от числа итераций

Если

$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = \alpha < 1 \quad \alpha \neq 0$$

,то сходимость линейная. Если

$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|} = 0$$

, то сходимость сверхлинейная. Если $\exists \gamma > 1$:

$$\lim_{k \rightarrow \infty} \frac{\|x^{k+1} - x^*\|}{\|x^k - x^*\|^\gamma} < +\infty$$

то сходимость порядка γ . В частности при $\gamma = 2$ — квадратичная сходимость

- Методы сопряженных градиентов имеют сверхлинейную скорость сходимости по n шагам.
Если $H(x)$ удовлетворяет условию Липшица, то эти методы имеют квадратичную сходимость по n шагам
- Квазиньютоновские методы ДФП и БФШ имеют сверхлинейную скорость сходимости
Если $H(x)$ удовлетворяет условию Липшица, то эти методы имеют квадратичную скорость сходимости
Это показывает преимущество квазиньютоновских методов перед методами сопряженных градиентов, которые требуют \approx в n раз больше итераций для одного и того же асимптотического поведения. Однако это преимущество сильно снижается загрузкой памяти $\sim n^2$ и объемом промежуточных матричных вычислений $\sim n^2$
- Метод Ньютона имеет квадратичную локальную сходимость, если $H(x)$ удовлетворяет условию Липшица
Следовательно в малой окрестности x^* метод Ньютона при указанных предположениях целевой функции $f(x)$ сходится быстрее остальных методов.