

Метод сопряженных градиентов

Даня Меркулов

ФКН ВШЭ

## Квадратичная задача оптимизации

# Сильно выпуклая квадратичная функция

Рассмотрим следующую квадратичную задачу оптимизации:


$$\min_{x \in \mathbb{R}^n} f(x) = \min_{x \in \mathbb{R}^n} \frac{1}{2} x^\top A x - b^\top x + c, \text{ где } A \in \mathbb{S}_{++}^n.$$

Не жонглируй, если ты шагов


Условия оптимальности

$$(1) \quad Ax^* = b$$

### Steepest Descent



### Conjugate Gradient



## Наискорейший спуск aka точный линейный поиск

$$\alpha_k = \arg \min_{\alpha \in \mathbb{R}^+} f(x_{k+1}) = \arg \min_{\alpha \in \mathbb{R}^+} f(x_k - \alpha \nabla f(x_k))$$

$$f(x) = \frac{1}{2} x^T A x - b^T x$$

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

Более теоретический, чем практический подход к выбору шага. Он также позволяет анализировать сходимость, но точный линейный поиск может быть численно сложным, если вычисление функции занимает слишком много времени или требует слишком много ресурсов.

Интересное теоретическое свойство этого метода заключается в том, что каждая следующая итерация метода ортогональна предыдущей:

$$\alpha_k = \arg \min_{\alpha \in \mathbb{R}^+} f(x_k - \alpha \nabla f(x_k))$$

$$\underbrace{\nabla f(x_k)^T}_{g_k^T} \underbrace{\nabla f(x_{k+1})}_{A(x_k - \alpha_k g_k) - b} = 0$$

$$g_k^T ( \underbrace{Ax_k - b}_{g_k} - \alpha_k A g_k ) = 0$$

$$g_k^T g_k - \alpha_k g_k^T A g_k = 0$$

## Наискорейший спуск aka точный линейный поиск

$$\alpha_k = \arg \min_{\alpha \in \mathbb{R}^+} f(x_{k+1}) = \arg \min_{\alpha \in \mathbb{R}^+} f(x_k - \alpha \nabla f(x_k))$$

Более теоретический, чем практический подход к выбору шага. Он также позволяет анализировать сходимость, но точный линейный поиск может быть численно сложным, если вычисление функции занимает слишком много времени или требует слишком много ресурсов.

Интересное теоретическое свойство этого метода заключается в том, что каждая следующая итерация метода ортогональна предыдущей:

$$\alpha_k = \arg \min_{\alpha \in \mathbb{R}^+} f(x_k - \alpha \nabla f(x_k))$$

Условия оптимальности:

# Наискорейший спуск aka точный линейный поиск

$$\alpha_k = \arg \min_{\alpha \in \mathbb{R}^+} f(x_{k+1}) = \arg \min_{\alpha \in \mathbb{R}^+} f(x_k - \alpha \nabla f(x_k))$$

Более теоретический, чем практический подход к выбору шага. Он также позволяет анализировать сходимость, но точный линейный поиск может быть численно сложным, если вычисление функции занимает слишком много времени или требует слишком много ресурсов.

Интересное теоретическое свойство этого метода заключается в том, что каждая следующая итерация метода ортогональна предыдущей:

$$\alpha_k = \arg \min_{\alpha \in \mathbb{R}^+} f(x_k - \alpha \nabla f(x_k))$$

Условия оптимальности:

$$\nabla f(x_k)^T \nabla f(x_{k+1}) = 0$$

🔥 Оптимальное значение для квадратичных функций

$$\nabla f(x_k)^T A(x_k - \alpha \nabla f(x_k)) - \nabla f(x_k)^T b = 0$$

$$\alpha_k = \frac{\nabla f(x_k)^T \nabla f(x_k)}{\nabla f(x_k)^T A \nabla f(x_k)}$$





Figure 1: Наискорейший спуск

Открыть в Colab

# Ортогональность

# Сопряженные направления. A-ортогональность.

$\lambda = 1$

$\frac{1}{2} x^T \cdot I x$

$v_1$  and  $v_2$  are orthogonal

$v_1^T v_2 = 0.00$

$v_1^T A v_2 = 1.19$

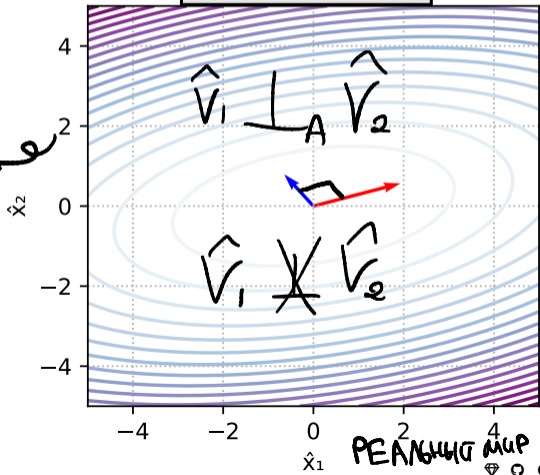

$\lambda > 1$

$\frac{1}{2} x^T A x$

$\hat{v}_1$  and  $\hat{v}_2$  are A-orthogonal

$\hat{v}_1^T \hat{v}_2 = -0.80$

$\hat{v}_1^T A \hat{v}_2 = -0.00$



## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

Поскольку  $A = Q \Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

Поскольку  $A = Q\Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x} = \frac{1}{2}\hat{x}^T Q\Lambda Q^T \hat{x}$$

## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

Поскольку  $A = Q\Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x} = \frac{1}{2}\hat{x}^T Q\Lambda Q^T \hat{x} = \frac{1}{2}\hat{x}^T Q\Lambda^{\frac{1}{2}}\Lambda^{\frac{1}{2}}Q^T \hat{x}$$

## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

Поскольку  $A = Q \Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x} = \frac{1}{2}\hat{x}^T Q \Lambda Q^T \hat{x} = \frac{1}{2}\hat{x}^T Q \Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} Q^T \hat{x} = \frac{1}{2}x^T I x$$

## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

Поскольку  $A = Q\Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x} = \frac{1}{2}\hat{x}^T Q\Lambda Q^T \hat{x} = \frac{1}{2}\hat{x}^T Q\Lambda^{\frac{1}{2}}\Lambda^{\frac{1}{2}}Q^T \hat{x} = \frac{1}{2}x^T I x \text{ и } \hat{x} = Q\Lambda^{-\frac{1}{2}}x$$

## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

Поскольку  $A = Q \Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x} = \frac{1}{2}\hat{x}^T \underline{Q \Lambda Q^T} \hat{x} = \frac{1}{2}\hat{x}^T Q \Lambda^{\frac{1}{2}} \underline{\Lambda^{\frac{1}{2}} Q^T} \hat{x} = \frac{1}{2}x^T I x \quad \hat{x} = Q \Lambda^{-\frac{1}{2}} x$$

## Сопряженные направления. $A$ -ортогональность.

Предположим, у нас есть две системы координат и квадратичная функция  $f(x) = \frac{1}{2}x^T I x$  выглядит так, как на левой части изображения 2, в то время как в других координатах она выглядит как  $f(\hat{x}) = \frac{1}{2}\hat{x}^T A \hat{x}$ , где  $A \in \mathbb{S}_{++}^n$ .

$$\frac{1}{2}x^T I x$$

$$\frac{1}{2}\hat{x}^T A \hat{x}$$

$$X = \hat{x}$$

Поскольку  $A = Q \Lambda Q^T$ :

$$\frac{1}{2}\hat{x}^T A \hat{x} = \frac{1}{2}\hat{x}^T Q \Lambda Q^T \hat{x} = \frac{1}{2}\hat{x}^T Q \Lambda^{\frac{1}{2}} \Lambda^{\frac{1}{2}} Q^T \hat{x} = \frac{1}{2}x^T I x \text{ и } \hat{x} = Q \Lambda^{-\frac{1}{2}} x$$

### $A$ -ортогональные векторы

Векторы  $x \in \mathbb{R}^n$  и  $y \in \mathbb{R}^n$  называются  $A$ -ортогональными (или  $A$ -сопряженными), если

$$x^T A y = 0 \quad \Leftrightarrow \quad x \perp_A y$$

Когда  $A = I$ ,  $A$ -ортогональность превращается в ортогональность.

## Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




Figure 3: Иллюстрация процесса Грама-Шмидта

## Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




Figure 4: Иллюстрация процесса Грама-Шмидта

## Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




Figure 5: Иллюстрация процесса Грама-Шмидта

## Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




Figure 6: Иллюстрация процесса Грама-Шмидта

## Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .






Figure 7: Иллюстрация процесса Грама-Шмидта

# Процесс Грама-Шмидта


Вход:  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .




# Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




$$d_0 = u_0$$



# Процесс Грама-Шмидта


**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .



$$d_0 = u_0$$

$$d_1 = u_1 - \pi_{d_0}(u_1)$$




$$\pi_d(u) = \frac{\langle d, u \rangle}{\|d\|_2^2} d$$

# Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .


**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .



$$d_0 = u_0$$

$$d_1 = u_1 - \pi_{d_0}(u_1)$$

$$d_2 = u_2 - \pi_{d_0}(u_2) - \pi_{d_1}(u_2)$$




$$\pi_d(u) = \frac{\langle d, u \rangle}{\|d\|_2^2} d$$

# Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




$$d_0 = u_0$$

$$d_1 = u_1 - \pi_{d_0}(u_1)$$

$$d_2 = u_2 - \pi_{d_0}(u_2) - \pi_{d_1}(u_2)$$

$\vdots$




$$\pi_d(u) = \frac{\langle d, u \rangle}{\|d\|_2^2} d$$

# Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




$$d_0 = u_0$$

$$d_1 = u_1 - \pi_{d_0}(u_1)$$

$$d_2 = u_2 - \pi_{d_0}(u_2) - \pi_{d_1}(u_2)$$

$\vdots$


$$d_k = u_k - \sum_{i=0}^{k-1} \pi_{d_i}(u_k)$$



# Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .




$$d_0 = u_0$$

$$d_1 = u_1 - \pi_{d_0}(u_1)$$

$$d_2 = u_2 - \pi_{d_0}(u_2) - \pi_{d_1}(u_2)$$

$\vdots$



$$d_k = u_k - \sum_{i=0}^{k-1} \pi_{d_i}(u_k)$$



# Процесс Грама-Шмидта

**Вход:**  $n$  линейно независимых векторов  $u_0, \dots, u_{n-1}$ .

**Выход:**  $n$  линейно независимых попарно ортогональных векторов  $d_0, \dots, d_{n-1}$ .



$$\pi_d(u) = \frac{\langle d, u \rangle}{\|d\|_2^2} d$$

$$d_0 = u_0$$

$$d_1 = u_1 - \pi_{d_0}(u_1)$$

$$d_2 = u_2 - \pi_{d_0}(u_2) - \pi_{d_1}(u_2)$$

$\vdots$

$$d_k = u_k - \sum_{i=0}^{k-1} \pi_{d_i}(u_k)$$

$$d_k = u_k + \sum_{i=0}^{k-1} \beta_{ik} d_i \quad \beta_{ik} = -\frac{\langle d_i, u_k \rangle_A}{\langle d_i, d_i \rangle_A}$$

могут быть  
GS

$$\langle x, y \rangle_A = x^T A y$$

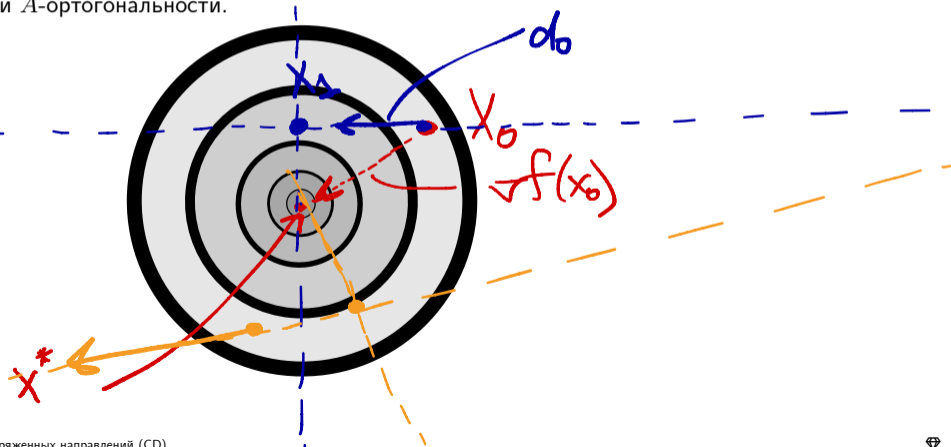
## Метод сопряженных направлений (CD)

---

CGECCD


## Общая идея

- В изотропном случае  $A = I$  метод наискорейшего спуска, запущенный из произвольной точки в  $n$  ортогональных линейно независимых направлениях, сойдется за  $n$  шагов в точных арифметических вычислениях. Мы пытаемся построить аналогичную процедуру в случае  $A \neq I$  с использованием концепции  $A$ -ортогональности.



## Общая идея

- В изотропном случае  $A = I$  метод наискорейшего спуска, запущенный из произвольной точки в  $n$  ортогональных линейно независимых направлениях, сойдется за  $n$  шагов в точных арифметических вычислениях. Мы пытаемся построить аналогичную процедуру в случае  $A \neq I$  с использованием концепции  $A$ -ортогональности.
- Предположим, у нас есть набор из  $n$  линейно независимых  $A$ -ортогональных направлений  $d_0, \dots, d_{n-1}$  (которые будут вычислены с помощью процесса Грама-Шмидта).



## Общая идея

- В изотропном случае  $A = I$  метод наискорейшего спуска, запущенный из произвольной точки в  $n$  ортогональных линейно независимых направлениях, сойдется за  $n$  шагов в точных арифметических вычислениях. Мы пытаемся построить аналогичную процедуру в случае  $A \neq I$  с использованием концепции  $A$ -ортогональности.
- Предположим, у нас есть набор из  $n$  линейно независимых  $A$ -ортогональных направлений  $d_0, \dots, d_{n-1}$  (которые будут вычислены с помощью процесса Грама-Шмидта).
- Мы хотим построить метод, который идет из  $x_0$  в  $x^*$  для квадратичной задачи с шагами  $\alpha_i$ , который, фактически, является разложением  $x^* - x_0$  в некотором базисе:

$$x^* = x_0 + \sum_{i=0}^{n-1} \alpha_i d_i$$
$$x^* - x_0 = \sum_{i=0}^{n-1} \alpha_i d_i$$

## Общая идея

- В изотропном случае  $A = I$  метод наискорейшего спуска, запущенный из произвольной точки в  $n$  ортогональных линейно независимых направлениях, сойдется за  $n$  шагов в точных арифметических вычислениях. Мы пытаемся построить аналогичную процедуру в случае  $A \neq I$  с использованием концепции  $A$ -ортогональности.
- Предположим, у нас есть набор из  $n$  линейно независимых  $A$ -ортогональных направлений  $d_0, \dots, d_{n-1}$  (которые будут вычислены с помощью процесса Грама-Шмидта).
- Мы хотим построить метод, который идет из  $x_0$  в  $x^*$  для квадратичной задачи с шагами  $\alpha_i$ , который, фактически, является разложением  $x^* - x_0$  в некотором базисе:

$$x^* = x_0 + \sum_{i=0}^{n-1} \alpha_i d_i \quad x^* - x_0 = \sum_{i=0}^{n-1} \alpha_i d_i$$

- Мы докажем, что  $\alpha_i$  и  $d_i$  могут быть построены очень эффективно с вычислительной точки зрения (метод сопряженных градиентов).

## Идея метода сопряженных направлений (CD)

Таким образом, мы формулируем алгоритм:

1. Пусть  $k = 0$  и  $x_k = x_0$ , посчитаем  $d_k = d_0 = -\nabla f(x_0)$ .

## Идея метода сопряженных направлений (CD)

Таким образом, мы формулируем алгоритм:

1. Пусть  $k = 0$  и  $x_k = x_0$ , посчитаем  $d_k = d_0 = -\nabla f(x_0)$ .
2. С помощью процедуры точного линейного поиска находим оптимальную длину шага. Вычисляем  $\alpha$  минимизируя  $f(x_k + \alpha_k d_k)$  по формуле

$$\alpha_k = -\frac{d_k^\top (Ax_k - b)}{d_k^\top Ad_k}$$

(3)

## Идея метода сопряженных направлений (CD)

Таким образом, мы формулируем алгоритм:

1. Пусть  $k = 0$  и  $x_k = x_0$ , посчитаем  $d_k = d_0 = -\nabla f(x_0)$ .
2. С помощью процедуры точного линейного поиска находим оптимальную длину шага. Вычисляем  $\alpha$  минимизируя  $f(x_k + \alpha_k d_k)$  по формуле

$$\alpha_k = -\frac{d_k^\top (Ax_k - b)}{d_k^\top A d_k} \quad (3)$$

3. Выполняем шаг алгоритма:

$$x_{k+1} = x_k + \alpha_k d_k$$

## Идея метода сопряженных направлений (CD)

Таким образом, мы формулируем алгоритм:

1. Пусть  $k = 0$  и  $x_k = x_0$ , посчитаем  $d_k = d_0 = -\nabla f(x_0)$ .
2. С помощью процедуры точного линейного поиска находим оптимальную длину шага. Вычисляем  $\alpha$  минимизируя  $f(x_k + \alpha_k d_k)$  по формуле

$$\alpha_k = -\frac{d_k^\top (Ax_k - b)}{d_k^\top Ad_k} \quad (3)$$

3. Выполняем шаг алгоритма:

$$x_{k+1} = x_k + \alpha_k d_k$$

4. Вычисляем новое направление метода так, чтобы  $d_{k+1}$  было  $A$ -ортогонально всем предыдущим направлениям метода. Позднее, мы покажем, что в случае метода сопряженных градиентов (CG), для этого достаточно хранить в памяти только последнее направление. В общем случае (CD) это не так.

Выбор  $d_{k+1}$

## Идея метода сопряженных направлений (CD)

Таким образом, мы формулируем алгоритм:

1. Пусть  $k = 0$  и  $x_k = x_0$ , посчитаем  $d_k = d_0 = -\nabla f(x_0)$ .
2. С помощью процедуры точного линейного поиска находим оптимальную длину шага. Вычисляем  $\alpha$  минимизируя  $f(x_k + \alpha_k d_k)$  по формуле

$$\alpha_k = -\frac{d_k^\top (Ax_k - b)}{d_k^\top Ad_k} \quad (3)$$

3. Выполняем шаг алгоритма:

$$x_{k+1} = x_k + \alpha_k d_k$$

4. Вычисляем новое направление метода так, чтобы  $d_{k+1}$  было  $A$ -ортогонально всем предыдущим направлениям метода. Позднее, мы покажем, что в случае метода сопряженных градиентов (CG), для этого достаточно хранить в памяти только последнее направление. В общем случае (CD) это не так.
5. Повторяем шаги 2-4, пока не построим  $n$  направлений, где  $n$  - размерность пространства ( $x$ ).

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

Доказательство

Пусть  $d_1, \dots, d_n$  - ЛНЗ

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:

$$\sum_{i=1}^n \alpha_i d_i = 0$$

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

### Доказательство

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:

$$0 = \sum_{i=1}^n \alpha_i d_i$$

$$\left( d_k^T A \right) \cdot$$

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

### Доказательство

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:

$$0 = \sum_{i=1}^n \alpha_i d_i$$

Умножаем на  $d_j^T A$ .

$$= d_j^T A \left( \sum_{i=1}^n \alpha_i d_i \right)$$

$$d_i^T A d_i = 0 \\ i \neq j$$

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

### Доказательство

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:

$$0 = \sum_{i=1}^n \alpha_i d_i$$

Умножаем на  $d_j^T A$ .

$$= d_j^T A \left( \sum_{i=1}^n \alpha_i d_i \right) = \sum_{i=1}^n \alpha_i d_j^T A d_i$$

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

### Доказательство

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:

$$\begin{aligned} 0 &= \sum_{i=1}^n \alpha_i d_i \\ \text{Умножаем на } d_j^T A \cdot &= d_j^T A \left( \sum_{i=1}^n \alpha_i d_i \right) = \sum_{i=1}^n \alpha_i d_j^T A d_i \\ &= \alpha_j d_j^T A d_j + 0 + \dots + 0 \end{aligned}$$

## Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .

### Доказательство

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:

$$\begin{aligned} 0 &= \sum_{i=1}^n \alpha_i d_i \\ \text{Умножаем на } d_j^T A \cdot &= d_j^T A \left( \sum_{i=1}^n \alpha_i d_i \right) = \sum_{i=1}^n \alpha_i d_j^T A d_i \\ &= \alpha_j d_j^T A d_j + 0 + \dots + 0 \end{aligned}$$

# Метод сопряженных направлений (CD)

**i** Лемма 1. Линейная независимость  $A$ -ортогональных векторов.

Если множество векторов  $d_1, \dots, d_n$  - попарно  $A$ -ортогональны (каждая пара векторов  $A$ -ортогональна), то эти векторы линейно независимы.  $A \in \mathbb{S}_{++}^n$ .



## Доказательство

Покажем, что если  $\sum_{i=1}^n \alpha_i d_i = 0$ , то все коэффициенты должны быть равны нулю:



$$0 = \sum_{i=1}^n \alpha_i d_i$$

Умножаем на  $d_j^T A$ .

↑  
проблема

$$\begin{aligned} &= d_j^T A \left( \sum_{i=1}^n \alpha_i d_i \right) = \sum_{i=1}^n \alpha_i d_j^T A d_i \\ &= \alpha_j d_j^T A d_j + 0 + \dots + 0 \end{aligned}$$

Таким образом,  $\alpha_j = 0$ , для всех остальных индексов нужно проделать тот же процесс

## Доказательство сходимости

Введем следующие обозначения:

•  $r_k = b - Ax_k$  - невязка

$$= -\nabla f(x_k)$$

$$e_k = x_k - x^*$$

# Доказательство сходимости

Введем следующие обозначения:

- $r_k = b - Ax_k$  - невязка
- $e_k = x_k - x^*$  - ошибка

## Доказательство сходимости

Введем следующие обозначения:

- $r_k = b - Ax_k$  - невязка
- $e_k = x_k - x^*$  - ошибка
- Поскольку  $Ax^* = b$ , имеем  $r_k = b - Ax_k = Ax^* - Ax_k = -A(x_k - x^*)$

$$r_k = -Ae_k.$$

(4)

## Доказательство сходимости

Введем следующие обозначения:

- $r_k = b - Ax_k$  - невязка
- $e_k = x_k - x^*$  - ошибка
- Поскольку  $Ax^* = b$ , имеем  $r_k = b - Ax_k = Ax^* - Ax_k = -A(x_k - x^*)$

$$r_k = -Ae_k. \quad (4)$$

- Также заметим, что поскольку  $x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$ , имеем

$$e_{k+1} = e_0 + \sum_{i=0}^k \alpha_i d_i. \quad (5)$$

## Доказательство сходимости

$$f(x) = \frac{1}{2}x^T Ax - b^T x + c \rightarrow \min_{x \in \mathbb{R}^n}$$

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

**c**  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

$$x_0 + d_0 d_0^T \dots d_{n-1} d_{n-1}^T = x^*$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

$\delta_i$  - коэф. разл  $e_0$  в базисе  $d_0 \dots d_{n-1}$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

---

2. Умножаем обе части слева на  $d_k^T A$ :

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$\begin{aligned} d_k^T A e_0 &= \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \\ &= \delta_k d_k^T A d_k \end{aligned}$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A e_0 = \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \delta_k d_k^T A d_k$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A e_0 = \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \delta_k d_k^T A d_k$$

$$d_k^T A \left( e_0 + \sum_{i=0}^{k-1} \alpha_i d_i \right)$$

$$d_k^T A e_0 \quad \equiv \quad \underline{\hspace{10em}}$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

$$x_k = x_0 + \sum_{i=0}^{k-1} \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A e_0 = \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \delta_k d_k^T A d_k$$

$$d_k^T A \left( e_0 + \sum_{i=0}^{k-1} \alpha_i d_i \right) = d_k^T A e_k$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

$\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, A d_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A \left( e_0 + \sum_{i=0}^{k-1} \alpha_i d_i \right) = d_k^T A e_k = \delta_k d_k^T A d_k \quad (A - \text{ортогональность})$$

$\delta_k = \frac{d_k^T A e_k}{d_k^T A d_k} = -r_k$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, Ad_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A e_0 = \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \delta_k d_k^T A d_k$$

$$d_k^T A \left( e_0 + \sum_{i=0}^{k-1} \alpha_i d_i \right) = d_k^T A e_k = \delta_k d_k^T A d_k \quad (A - \text{ ортогональность})$$

$$\delta_k = \frac{d_k^T A e_k}{d_k^T A d_k}$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, Ad_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A e_0 = \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \delta_k d_k^T A d_k$$
$$d_k^T A \left( e_0 + \sum_{i=0}^{k-1} \alpha_i d_i \right) = d_k^T A e_k = \delta_k d_k^T A d_k \quad (A - \text{ ортогональность})$$
$$\delta_k = \frac{d_k^T A e_k}{d_k^T A d_k} = -\frac{d_k^T r_k}{d_k^T A d_k}$$

## Доказательство сходимости

**i** Лемма 2. Сходимость метода сопряженных направлений.

Предположим, мы решаем  $n$ -мерную квадратичную сильно выпуклую задачу оптимизации (1). Метод сопряженных направлений

$$x_{k+1} = x_0 + \sum_{i=0}^k \alpha_i d_i$$

с  $\alpha_i = \frac{\langle d_i, r_i \rangle}{\langle d_i, Ad_i \rangle}$  взятым из точного линейного поиска, сходится за не более  $n$  шагов алгоритма.

### Доказательство

1. Нужно доказать, что  $\delta_i = -\alpha_i$ :

$$e_0 = x_0 - x^* = \sum_{i=0}^{n-1} \delta_i d_i$$

2. Умножаем обе части слева на  $d_k^T A$ :

$$d_k^T A e_0 = \sum_{i=0}^{n-1} \delta_i d_k^T A d_i = \delta_k d_k^T A d_k$$

$$d_k^T A \left( e_0 + \sum_{i=0}^{k-1} \alpha_i d_i \right) = d_k^T A e_k = \delta_k d_k^T A d_k \quad (A - \text{ ортогональность})$$

$$\delta_k = \frac{d_k^T A e_k}{d_k^T A d_k} = -\frac{d_k^T r_k}{d_k^T A d_k} \Leftrightarrow \delta_k = -\alpha_k$$

## Леммы для сходимости

$$\underline{x_0 + \alpha_0 d_0 + \alpha_1 d_1 + \alpha_2 d_2 + \alpha_3 d_3 + \alpha_4 d_4 = x^*}$$

**i** Лемма 3. Разложение ошибки.

$$n = 5$$

$$e_i = \sum_{j=i}^{n-1} -\alpha_j d_j$$

(6)

$$e_3 = -\alpha_3 d_3 - \alpha_4 d_4$$


## Леммы для сходимости

**i** Лемма 3. Разложение ошибки.

$$e_i = \sum_{j=i}^{n-1} -\alpha_j d_j \quad (6)$$

**Доказательство**

По определению

$$e_i = e_0 + \sum_{j=0}^{i-1} \alpha_j d_j$$


## Леммы для сходимости

**i** Лемма 3. Разложение ошибки.

$$e_i = \sum_{j=i}^{n-1} -\alpha_j d_j \quad (6)$$

**Доказательство**

По определению

$$e_i = e_0 + \sum_{j=0}^{i-1} \alpha_j d_j = \underbrace{x_0 - x^*}_{\text{ошибка}} + \sum_{j=0}^{i-1} \alpha_j d_j$$

метод

## Леммы для сходимости

**i** Лемма 3. Разложение ошибки.

$$e_i = \sum_{j=i}^{n-1} -\alpha_j d_j \quad (6)$$

**Доказательство**

По определению

$$e_i = e_0 + \sum_{j=0}^{i-1} \alpha_j d_j = \underbrace{x_0 - x^*}_{\text{red underline}} + \sum_{j=0}^{i-1} \alpha_j d_j = - \sum_{j=0}^{n-1} \alpha_j d_j + \sum_{j=0}^{i-1} \alpha_j d_j$$

## Леммы для сходимости

**i** Лемма 3. Разложение ошибки.

$$e_i = \sum_{j=i}^{n-1} -\alpha_j d_j \quad (6)$$

### Доказательство

По определению

$$e_i = e_0 + \sum_{j=0}^{i-1} \alpha_j d_j = x_0 - x^* + \sum_{j=0}^{i-1} \alpha_j d_j = -\sum_{j=0}^{n-1} \alpha_j d_j + \sum_{j=0}^{i-1} \alpha_j d_j = \sum_{j=i}^{n-1} -\alpha_j d_j$$

## Леммы для сходимости

**i** Лемма 4. Невязка ортогональна всем предыдущим направлениям для CD.

Рассмотрим невязку метода сопряженных направлений на  $k$  итерации  $r_k$ , тогда для любого  $i < k$ :

$$d_i^T r_k = 0$$

(7)

## Леммы для сходимости

**i** Лемма 4. Невязка ортогональна всем предыдущим направлениям для CD.

Рассмотрим невязку метода сопряженных направлений на  $k$  итерации  $r_k$ , тогда для любого  $i < k$ :

$$d_i^T r_k = 0 \quad (7)$$

### Доказательство

Запишем (6) для некоторого фиксированного индекса  $k$ :

## Леммы для сходимости

**i** Лемма 4. Невязка ортогональна всем предыдущим направлениям для CD.

Рассмотрим невязку метода сопряженных направлений на  $k$  итерации  $r_k$ , тогда для любого  $i < k$ :

$$d_i^T r_k = 0 \quad (7)$$

### Доказательство

Запишем (6) для некоторого фиксированного индекса  $k$ :

$$e_k = \sum_{j=k}^{n-1} -\alpha_j d_j$$

## Леммы для сходимости

и Лемма 4. Невязка ортогональна всем предыдущим направлениям для CD.

Рассмотрим невязку метода сопряженных направлений на  $k$  итерации  $r_k$ , тогда для любого  $i < k$ :


$$d_i^T r_k = 0 \quad (7)$$

### Доказательство

Запишем (6) для некоторого фиксированного индекса  $k$ :

$$e_k = \sum_{j=k}^{n-1} -\alpha_j d_j$$

$$(d_i^T A)$$



Умножаем обе части на  $-d_i^T A$ .

$$\underline{-d_i^T A e_k} = \underline{\sum_{j=k}^{n-1} \alpha_j d_i^T A d_j} = 0$$

Таким образом,  $d_i^T r_k = 0$  и невязка  $r_k$  ортогональна всем предыдущим направлениям  $d_i$  для метода CD.

## Метод сопряженных градиентов (CG)

$$CG = CD + \text{выбор} \quad \text{конкретный} \quad d_0, \dots, d_{n-1}$$

## Идея метода сопряженных градиентов (CG)

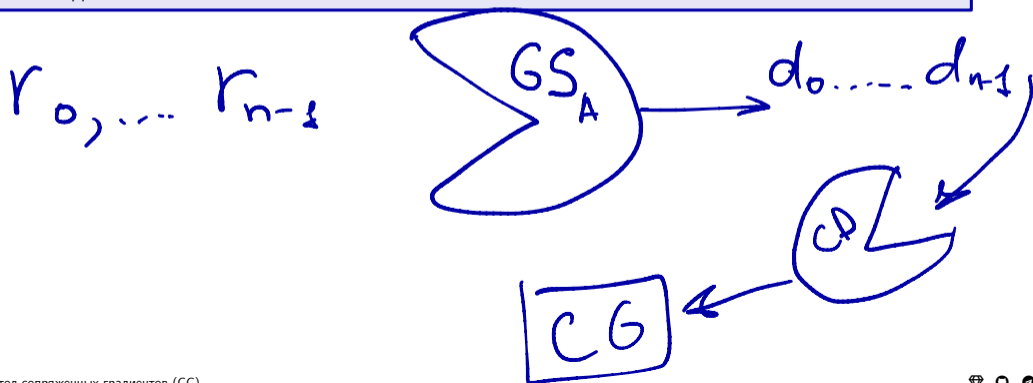
- Это буквально метод сопряженных направлений, в котором мы выбираем специальный набор  $d_0, \dots, d_{n-1}$ , позволяющий значительно ускорить процесс Грама-Шмидта.

## Идея метода сопряженных градиентов (CG)

- Это буквально метод сопряженных направлений, в котором мы выбираем специальный набор  $d_0, \dots, d_{n-1}$ , позволяющий значительно ускорить процесс Грама-Шмидта.
- Используется процесс Грама-Шмидта с  $A$ -ортогональностью вместо Евклидовой ортогональности, чтобы получить их из набора начальных векторов.

## Идея метода сопряженных градиентов (CG)

- Это буквально метод сопряженных направлений, в котором мы выбираем специальный набор  $d_0, \dots, d_{n-1}$ , позволяющий значительно ускорить процесс Грама-Шмидта.
- Используется процесс Грама-Шмидта с  $A$ -ортогональностью вместо Евклидовой ортогональности, чтобы получить их из набора начальных векторов.
- На каждой итерации  $r_0, \dots, r_{n-1}$  используются в качестве начальных векторов для процесса Грама-Шмидта.



## Идея метода сопряженных градиентов (CG)

- Это буквально метод сопряженных направлений, в котором мы выбираем специальный набор  $d_0, \dots, d_{n-1}$ , позволяющий значительно ускорить процесс Грама-Шмидта.
- Используется процесс Грама-Шмидта с  $A$ -ортогональностью вместо Евклидовой ортогональности, чтобы получить их из набора начальных векторов.
- На каждой итерации  $r_0, \dots, r_{n-1}$  используются в качестве начальных векторов для процесса Грама-Шмидта.
- Основная идея заключается в том, что для произвольного метода CD процесс Грама-Шмидта вычислительно дорогой и требует квадратичного числа операций сложения векторов и скалярных произведений  $\mathcal{O}(n^2)$ , в то время как в случае CG мы покажем, что сложность этой процедуры может быть уменьшена до линейной  $\mathcal{O}(n)$ .

## Идея метода сопряженных градиентов (CG)

- Это буквально метод сопряженных направлений, в котором мы выбираем специальный набор  $d_0, \dots, d_{n-1}$ , позволяющий значительно ускорить процесс Грама-Шмидта.
- Используется процесс Грама-Шмидта с  $A$ -ортогональностью вместо Евклидовой ортогональности, чтобы получить их из набора начальных векторов.
- На каждой итерации  $r_0, \dots, r_{n-1}$  используются в качестве начальных векторов для процесса Грама-Шмидта.
- Основная идея заключается в том, что для произвольного метода CD процесс Грама-Шмидта вычислительно дорогой и требует квадратичного числа операций сложения векторов и скалярных произведений  $\mathcal{O}(n^2)$ , в то время как в случае CG мы покажем, что сложность этой процедуры может быть уменьшена до линейной  $\mathcal{O}(n)$ .

## Идея метода сопряженных градиентов (CG)

- Это буквально метод сопряженных направлений, в котором мы выбираем специальный набор  $d_0, \dots, d_{n-1}$ , позволяющий значительно ускорить процесс Грама-Шмидта.
- Используется процесс Грама-Шмидта с  $A$ -ортогональностью вместо Евклидовой ортогональности, чтобы получить их из набора начальных векторов.
- На каждой итерации  $r_0, \dots, r_{n-1}$  используются в качестве начальных векторов для процесса Грама-Шмидта.
- Основная идея заключается в том, что для произвольного метода CD процесс Грама-Шмидта вычислительно дорогой и требует квадратичного числа операций сложения векторов и скалярных произведений  $\mathcal{O}(n^2)$ , в то время как в случае CG мы покажем, что сложность этой процедуры может быть уменьшена до линейной  $\mathcal{O}(n)$ .



CG = CD +  $r_0, \dots, r_{n-1}$  как начальные векторы для процесса Грама-Шмидта +  $A$ -ортогональность.

## Метод сопряженных градиентов (CG)

## Леммы для сходимости

**i** Лемма 5. Невязки ортогональны друг другу в методе CG

Все невязки в методе CG ортогональны друг другу:

$$r_i^T r_k = 0 \quad \forall i \neq k \quad (8)$$

## Леммы для сходимости

**i** Лемма 5. Невязки ортогональны друг другу в методе CG

Все невязки в методе CG ортогональны друг другу:

$$r_i^T r_k = 0 \quad \forall i \neq k \quad (8)$$

### Доказательство

Запишем процесс Грама-Шмидта (2) с  $\langle \cdot, \cdot \rangle$   
замененным на  $\langle \cdot, \cdot \rangle_A = x^T A y$

## Леммы для сходимости

**i** Лемма 5. Невязки ортогональны друг другу в методе CG

Все невязки в методе CG ортогональны друг другу:

$$r_i^T r_k = 0 \quad \forall i \neq k \quad (8)$$

### Доказательство

Запишем процесс Грама-Шмидта (2) с  $\langle \cdot, \cdot \rangle$  замененным на  $\langle \cdot, \cdot \rangle_A = x^T A y$

$$d_i = u_i + \sum_{j=0}^{i-1} \beta_{ji} d_j \quad \beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} \quad (9)$$

## Леммы для сходимости

**i** Лемма 5. Невязки ортогональны друг другу в методе CG

Все невязки в методе CG ортогональны друг другу:

$$r_i^T r_k = 0 \quad \forall i \neq k \quad (8)$$

### Доказательство

Запишем процесс Грама-Шмидта (2) с  $\langle \cdot, \cdot \rangle$  замененным на  $\langle \cdot, \cdot \rangle_A = x^T A y$

$$d_i = u_i + \sum_{j=0}^{i-1} \beta_{ji} d_j \quad \beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} \quad (9)$$

Тогда, мы используем невязки в качестве начальных векторов для процесса и  $u_i = r_i$ .

## Леммы для сходимости

**i** Лемма 5. Невязки ортогональны друг другу в методе CG

Все невязки в методе CG ортогональны друг другу:


$$r_i^T r_k = 0 \quad \forall i \neq k \quad (8)$$

### Доказательство

Запишем процесс Грама-Шмидта (2) с  $\langle \cdot, \cdot \rangle$  замененным на  $\langle \cdot, \cdot \rangle_A = x^T A y$

$$d_i = u_i + \sum_{j=0}^{k-1} \beta_{ji} d_j \quad \beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} \quad (9)$$

Умножаем обе части (9) на  $r_k^T$  для некоторого индекса  $k$ :



Тогда, мы используем невязки в качестве начальных векторов для процесса и  $u_i = r_i$ .

$$r_k^T d_i = r_k^T u_i + \sum_{j=0}^{k-1} \beta_{ji} r_k^T d_j$$

$$d_i = r_i + \sum_{j=0}^{k-1} \beta_{ji} d_j \quad \beta_{ji} = -\frac{\langle d_j, r_i \rangle_A}{\langle d_j, d_j \rangle_A} \quad (10)$$

## Леммы для сходимости

**i** Лемма 5. Невязки ортогональны друг другу в методе CG

Все невязки в методе CG ортогональны друг другу:


$$r_i^T r_k = 0 \quad \forall i \neq k \quad (8)$$

### Доказательство

Запишем процесс Грама-Шмидта (2) с  $\langle \cdot, \cdot \rangle$  замененным на  $\langle \cdot, \cdot \rangle_A = x^T A y$

$$d_i = u_i + \sum_{j=0}^{k-1} \beta_{ji} d_j \quad \beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} \quad (9)$$

Умножаем обе части (9) на  $r_k^T$  для некоторого индекса  $k$ :



Тогда, мы используем невязки в качестве начальных векторов для процесса и  $u_i = r_i$ .

$$r_k^T d_i = r_k^T u_i + \sum_{j=0}^{k-1} \beta_{ji} r_k^T d_j$$

$$d_i = r_i + \sum_{j=0}^{k-1} \beta_{ji} d_j \quad \beta_{ji} = -\frac{\langle d_j, r_i \rangle_A}{\langle d_j, d_j \rangle_A} \quad (10)$$

Если  $j < i < k$ , то имеем лемму 4 с  $d_i^T r_k = 0$  и  $d_j^T r_k = 0$ . Имеем:

$$r_k^T u_i = 0 \quad \text{для CD} \quad r_k^T r_i = 0 \quad \text{для CG}$$

## Леммы для сходимости

Более того, если  $k = i$ :

$$r_k^T d_k = r_k^T u_k + \sum_{j=0}^{k-1} \beta_{jk} r_k^T d_j$$

## Леммы для сходимости

Более того, если  $k = i$ :

$$r_k^T d_k = r_k^T u_k + \sum_{j=0}^{k-1} \beta_{jk} r_k^T d_j = r_k^T u_k + 0,$$

## Леммы для сходимости

Более того, если  $k = i$ :

$$r_k^T d_k = r_k^T u_k + \sum_{j=0}^{k-1} \beta_{jk} r_k^T d_j = r_k^T u_k + 0,$$

## Леммы для сходимости

Более того, если  $k = i$ :

$$r_k^T d_k = r_k^T u_k + \sum_{j=0}^{k-1} \beta_{jk} r_k^T d_j = r_k^T u_k + 0,$$

и мы имеем для любого  $k$  (из-за произвольного выбора  $i$ ):

$$r_k^T d_k = r_k^T u_k. \tag{11}$$

## Леммы для сходимости

Более того, если  $k = i$ :

$$r_k^T d_k = r_k^T u_k + \sum_{j=0}^{k-1} \beta_{jk} r_k^T d_j = r_k^T u_k + 0,$$

и мы имеем для любого  $k$  (из-за произвольного выбора  $i$ ):

$$r_k^T d_k = r_k^T u_k. \quad (11)$$

**i** Лемма 6. Пересчет невязки

$$r_{k+1} = r_k - \alpha_k A d_k \quad (12)$$

## Леммы для сходимости

Более того, если  $k = i$ :

$$r_k^T d_k = r_k^T u_k + \sum_{j=0}^{k-1} \beta_{jk} r_k^T d_j = r_k^T u_k + 0,$$

и мы имеем для любого  $k$  (из-за произвольного выбора  $i$ ):

$$r_k^T d_k = r_k^T u_k. \quad (11)$$

**i** Лемма 6. Пересчет невязки

$$r_{k+1} = r_k - \alpha_k A d_k \quad (12)$$

$$\underline{r_{k+1}} = -A e_{k+1} = -A (e_k + \alpha_k d_k) = -A e_k - \alpha_k A d_k = r_k - \alpha_k A d_k$$

Наконец, все эти вышеуказанные леммы достаточны для доказательства, что  $\beta_{ji} = 0$  для всех  $i, j$ , кроме соседних.

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\langle r_i, r_{j+1} \rangle$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\langle r_i, r_{j+1} \rangle = \langle r_i, r_j - \alpha_j A d_j \rangle$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\langle r_i, r_{j+1} \rangle = \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned} \langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ &\quad - \alpha_j \langle r_i, A d_j \rangle \end{aligned}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j} = \frac{1}{\alpha_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j} = \frac{1}{\alpha_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{d_j^T A d_j}{d_j^T r_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j} = \frac{1}{\alpha_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{d_j^T A d_j}{d_j^T r_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{\langle r_i, r_i \rangle}{\langle r_j, r_j \rangle}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j} = \frac{1}{\alpha_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{d_j^T A d_j}{d_j^T r_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{\langle r_i, r_i \rangle}{\langle r_j, r_j \rangle} = \frac{\langle r_i, r_i \rangle}{\langle r_{i-1}, r_{i-1} \rangle}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j} = \frac{1}{\alpha_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{d_j^T A d_j}{d_j^T r_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{\langle r_i, r_i \rangle}{\langle r_j, r_j \rangle} = \frac{\langle r_i, r_i \rangle}{\langle r_{i-1}, r_{i-1} \rangle}$$

## Грам-Шмидт в методе CG

Рассмотрим процесс Грам-Шмидта в методе CG

$$\beta_{ji} = -\frac{\langle d_j, u_i \rangle_A}{\langle d_j, d_j \rangle_A} = -\frac{d_j^T A u_i}{d_j^T A d_j} = -\frac{d_j^T A r_i}{d_j^T A d_j} = -\frac{r_i^T A d_j}{d_j^T A d_j}.$$

Рассмотрим скалярное произведение  $\langle r_i, r_{j+1} \rangle$  используя (12):

$$\begin{aligned}\langle r_i, r_{j+1} \rangle &= \langle r_i, r_j - \alpha_j A d_j \rangle = \langle r_i, r_j \rangle - \alpha_j \langle r_i, A d_j \rangle \\ \alpha_j \langle r_i, A d_j \rangle &= \langle r_i, r_j \rangle - \langle r_i, r_{j+1} \rangle\end{aligned}$$

1. Если  $i = j$ :  $\alpha_i \langle r_i, A d_i \rangle = \langle r_i, r_i \rangle - \langle r_i, r_{i+1} \rangle = \langle r_i, r_i \rangle$ . Этот случай не интересен по построению процесса Грам-Шмидта.
2. Соседний случай  $i = j + 1$ :  $\alpha_j \langle r_i, A d_j \rangle = \langle r_i, r_{i-1} \rangle - \langle r_i, r_i \rangle = -\langle r_i, r_i \rangle$
3. Для любого другого случая:  $\alpha_j \langle r_i, A d_j \rangle = 0$ , потому что все невязки ортогональны друг другу.

Наконец, мы имеем формулу для  $i = j + 1$ :

$$\beta_{ji} = -\frac{r_i^T A d_j}{d_j^T A d_j} = \frac{1}{\alpha_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{d_j^T A d_j}{d_j^T r_j} \frac{\langle r_i, r_i \rangle}{d_j^T A d_j} = \frac{\langle r_i, r_i \rangle}{\langle r_j, r_j \rangle} = \frac{\langle r_i, r_i \rangle}{\langle r_{i-1}, r_{i-1} \rangle}$$

И для направления  $d_{k+1} = r_{k+1} + \beta_{k,k+1} d_k$ ,  $\beta_{k,k+1} = \beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$ .

# Метод сопряженных градиентов (CG)

$$p_k = Ad_k$$

$$\mathbf{r}_0 := \mathbf{b} - \mathbf{A}\mathbf{x}_0$$

if  $\mathbf{r}_0$  is sufficiently small, then return  $\mathbf{x}_0$  as the result

$$\mathbf{d}_0 := \mathbf{r}_0$$

$$k := 0$$

repeat

$$\alpha_k := \frac{\mathbf{r}_k^\top \mathbf{r}_k}{\mathbf{d}_k^\top \mathbf{A} \mathbf{d}_k}$$

← линия шага Line Search

$$\mathbf{x}_{k+1} := \mathbf{x}_k + \alpha_k \mathbf{d}_k$$

← шаг

$$\mathbf{r}_{k+1} := \mathbf{r}_k - \alpha_k \mathbf{A} \mathbf{d}_k$$

← обновл. невязки

if  $\mathbf{r}_{k+1}$  is sufficiently small, then exit loop

$$\beta_k := \frac{\mathbf{r}_{k+1}^\top \mathbf{r}_{k+1}}{\mathbf{r}_k^\top \mathbf{r}_k}$$

← для CG

$$\mathbf{d}_{k+1} := \mathbf{r}_{k+1} + \beta_k \mathbf{d}_k$$

GS<sub>A</sub>  
очень эффективна


$$k := k + 1$$

end repeat


return  $\mathbf{x}_{k+1}$  as the result

# Закрываем квадратичный вопрос

$\kappa = 1.0$



$\kappa = 100.0$



## Сходимость

**Теорема 1.** Если матрица  $A$  имеет только  $r$  различных собственных значений, то метод сопряженных градиентов сходится за  $r$  итераций.

**Теорема 2.** Следующая оценка сходимости выполняется для метода сопряженных градиентов, как для итерационного метода в сильно выпуклой задаче:

$$\|x_k - x^*\|_A \leq 2 \left( \frac{\sqrt{\kappa(A)} - 1}{\sqrt{\kappa(A)} + 1} \right)^k \|x_0 - x^*\|_A,$$


где  $\|x\|_A^2 = x^\top Ax$  и  $\kappa(A) = \frac{\lambda_1(A)}{\lambda_n(A)}$  - это число обусловленности матрицы  $A$ ,  $\lambda_1(A) \geq \dots \geq \lambda_n(A)$  - собственные значения матрицы  $A$

**Примечание:** Сравните коэффициент геометрической прогрессии с его аналогом в методе градиентного спуска.

# Численные эксперименты

$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$


Convex quadratics.  $n=60$ , random matrix.



# Численные эксперименты

$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$

Strongly convex quadratics, n=60, random matrix.




# Численные эксперименты


$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$

Strongly convex quadratics.  $n=60$ , random matrix.


Eigenvalues



Function gap



Norm of Gradient




— Gradient Descent    - - - Steepest Descent    - - - Conjugate Gradients

# Численные эксперименты

$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$


Strongly convex quadratics.  $n=60$ , clustered matrix.



# Численные эксперименты

$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$


Strongly convex quadratics.  $n=600$ , clustered matrix.



# Численные эксперименты

$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$


Strongly convex quadratics.  $n=60$ , uniform spectrum matrix.



# Численные эксперименты

$$f(x) = \frac{1}{2}x^T Ax - b^T x \rightarrow \min_{x \in \mathbb{R}^n}$$

Strongly convex quadratics.  $n=60$ , Hilbert matrix.



## Патологический пример

Пусть  $t \in (0, 1)$  и

$$W = \begin{bmatrix} t & \sqrt{t} & & & \\ \sqrt{t} & 1+t & \sqrt{t} & & \\ & \sqrt{t} & 1+t & \sqrt{t} & \\ & & \ddots & \ddots & \ddots \\ & & & \sqrt{t} & 1+t \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- Так как  $W$  невырождена, существует единственное решение  $Wx = b$ . Решение методом сопряженных градиентов даёт довольно плохую сходимость.

## Патологический пример

Пусть  $t \in (0, 1)$  и

$$W = \begin{bmatrix} t & \sqrt{t} & & & \\ \sqrt{t} & 1+t & \sqrt{t} & & \\ & \sqrt{t} & 1+t & \sqrt{t} & \\ & & \ddots & \ddots & \ddots \\ & & & \sqrt{t} & 1+t \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- Так как  $W$  невырождена, существует единственное решение  $Wx = b$ . Решение методом сопряженных градиентов даёт довольно плохую сходимость.
- Во время работы CG ошибка растёт экспоненциально (!), пока внезапно не становится нулевой, когда находится единственное решение.

## Патологический пример

Пусть  $t \in (0, 1)$  и

$$W = \begin{bmatrix} t & \sqrt{t} & & & & \\ \sqrt{t} & 1+t & \sqrt{t} & & & \\ & \sqrt{t} & 1+t & \sqrt{t} & & \\ & & \ddots & \ddots & \ddots & \\ & & & \sqrt{t} & 1+t & \\ & & & & & \ddots & \ddots \end{bmatrix}, \quad b = \begin{bmatrix} 1 \\ 0 \\ \vdots \\ 0 \end{bmatrix}$$

- Так как  $W$  невырождена, существует единственное решение  $Wx = b$ . Решение методом сопряженных градиентов даёт довольно плохую сходимость.
- Во время работы CG ошибка растёт экспоненциально (!), пока внезапно не становится нулевой, когда находится единственное решение.
- Невязка  $\|Wx_k - b\|^2$  растёт экспоненциально как  $(1/t)^k$  до  $n$ -й итерации, после чего резко падает к нулю.

## Метод сопряженных градиентов для неквадратичных задач (Non-linear CG)

## Метод сопряженных градиентов для неквадратичных задач (Non-linear CG)

В случае, когда нет аналитического выражения для функции или ее градиента, мы, скорее всего, не сможем решить одномерную задачу минимизации аналитически. Поэтому шаг 2 алгоритма заменяется обычной процедурой линейного поиска. Но есть следующий математический трюк для четвертого шага:

Для двух итераций справедливо:

$$x_{k+1} - x_k = cd_k,$$

## Метод сопряженных градиентов для неквадратичных задач (Non-linear CG)

В случае, когда нет аналитического выражения для функции или ее градиента, мы, скорее всего, не сможем решить одномерную задачу минимизации аналитически. Поэтому шаг 2 алгоритма заменяется обычной процедурой линейного поиска. Но есть следующий математический трюк для четвертого шага:

Для двух итераций справедливо:

$$x_{k+1} - x_k = cd_k,$$

где  $c$  - некоторая константа. Тогда для квадратичного случая мы имеем:

$$\nabla f(x_{k+1}) - \nabla f(x_k) = (Ax_{k+1} - b) - (Ax_k - b) = A(x_{k+1} - x_k) = cAd_k$$

## Метод сопряженных градиентов для неквадратичных задач (Non-linear CG)

В случае, когда нет аналитического выражения для функции или ее градиента, мы, скорее всего, не сможем решить одномерную задачу минимизации аналитически. Поэтому шаг 2 алгоритма заменяется обычной процедурой линейного поиска. Но есть следующий математический трюк для четвертого шага:

Для двух итераций справедливо:

$$x_{k+1} - x_k = cd_k,$$

где  $c$  - некоторая константа. Тогда для квадратичного случая мы имеем:

$$\nabla f(x_{k+1}) - \nabla f(x_k) = (Ax_{k+1} - b) - (Ax_k - b) = A(x_{k+1} - x_k) = cAd_k$$

Выражая из этого уравнения величину  $Ad_k = \frac{1}{c} (\nabla f(x_{k+1}) - \nabla f(x_k))$ , мы избавляемся от знания функции в определении  $\beta_k$ , тогда пункт 4 будет переписан как:

$$\beta_k = \frac{\nabla f(x_{k+1})^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}{d_k^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}.$$

Однако данная формула — это формула Хестенса-Штифеля (Hestenes-Stiefel, HS). Для неквадратичного случая существует несколько различных вариантов выбора  $\beta_k$ , которые совпадают в квадратичном случае, но отличаются на общих функциях.

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$
2.  $\alpha_k$  — из линейного поиска (например, условия Вульфа)

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$
2.  $\alpha_k$  — из линейного поиска (например, условия Вульфа)
3.  $x_{k+1} = x_k + \alpha_k d_k$

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$
2.  $\alpha_k$  — из линейного поиска (например, условия Вульфа)
3.  $x_{k+1} = x_k + \alpha_k d_k$
4.  $\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$
2.  $\alpha_k$  — из линейного поиска (например, условия Вульфа)
3.  $x_{k+1} = x_k + \alpha_k d_k$
4.  $\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$
5.  $d_{k+1} = -\nabla f(x_{k+1}) + \beta_k^{FR} d_k$

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$
2.  $\alpha_k$  — из линейного поиска (например, условия Вульфа)
3.  $x_{k+1} = x_k + \alpha_k d_k$
4.  $\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$
5.  $d_{k+1} = -\nabla f(x_{k+1}) + \beta_k^{FR} d_k$

## Метод Флетчера-Ривза (Fletcher-Reeves, FR)

Метод Флетчера-Ривза (1964) — исторически первый нелинейный метод сопряженных градиентов.

**Идея:** Непосредственно перенести формулу  $\beta_k$  из линейного (квадратичного) CG на общий случай. В

квадратичном случае  $r_k = -\nabla f(x_k)$ , и формула  $\beta_k = \frac{\langle r_{k+1}, r_{k+1} \rangle}{\langle r_k, r_k \rangle}$  принимает вид:

$$\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$$

Алгоритм FR:

1.  $d_0 = -\nabla f(x_0)$
2.  $\alpha_k$  — из линейного поиска (например, условия Вульфа)
3.  $x_{k+1} = x_k + \alpha_k d_k$
4.  $\beta_k^{FR} = \frac{\|\nabla f(x_{k+1})\|^2}{\|\nabla f(x_k)\|^2}$
5.  $d_{k+1} = -\nabla f(x_{k+1}) + \beta_k^{FR} d_k$

### Caution

Метод Флетчера-Ривза гарантированно сходится при использовании сильных условий Вульфа для линейного поиска. Однако на практике метод может «застрывать» — генерировать малые шаги без

## Метод Полака-Рибьера (Polak-Ribière, PR)

Метод Полака-Рибьера (1969) модифицирует формулу для  $\beta_k$ , используя разность градиентов:

$$\beta_k^{PR} = \frac{\nabla f(x_{k+1})^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}{\|\nabla f(x_k)\|^2}$$

## Метод Полака-Рибьера (Polak-Ribière, PR)

Метод Полака-Рибьера (1969) модифицирует формулу для  $\beta_k$ , используя разность градиентов:

$$\beta_k^{PR} = \frac{\nabla f(x_{k+1})^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}{\|\nabla f(x_k)\|^2}$$

**Идея и преимущество:** В квадратичном случае  $\beta_k^{PR} = \beta_k^{FR}$ , так как невязки ортогональны:  $\nabla f(x_{k+1})^\top \nabla f(x_k) = 0$ . Однако для общих (неквадратичных) функций  $\beta_k^{PR}$  может принимать отрицательные значения, что эквивалентно автоматическому перезапуску метода — направление спуска сбрасывается ближе к антиградиенту, когда последовательные градиенты становятся почти параллельны. Это делает метод PR значительно более устойчивым на практике по сравнению с FR.

## Метод Полака-Рибьера (Polak-Ribière, PR)

Метод Полака-Рибьера (1969) модифицирует формулу для  $\beta_k$ , используя разность градиентов:

$$\beta_k^{PR} = \frac{\nabla f(x_{k+1})^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}{\|\nabla f(x_k)\|^2}$$

**Идея и преимущество:** В квадратичном случае  $\beta_k^{PR} = \beta_k^{FR}$ , так как невязки ортогональны:  $\nabla f(x_{k+1})^\top \nabla f(x_k) = 0$ . Однако для общих (неквадратичных) функций  $\beta_k^{PR}$  может принимать отрицательные значения, что эквивалентно автоматическому перезапуску метода — направление спуска сбрасывается ближе к антиградиенту, когда последовательные градиенты становятся почти параллельны. Это делает метод PR значительно более устойчивым на практике по сравнению с FR.

### Caution

На практике часто используют модификацию  $\beta_k^{PR+} = \max(\beta_k^{PR}, 0)$ , которая гарантирует, что направление спуска всегда является направлением убывания, и обеспечивает глобальную сходимость при сильных условиях Вульфа.

## Сравнение вариантов нелинейного CG



Метод	$\beta_k$	Особенности
Флетчер-Ривз (FR)	$\frac{\ \nabla f(x_{k+1})\ ^2}{\ \nabla f(x_k)\ ^2}$	Гарантия сходимости, может застревать
Полак-Рибьер (PR)	$\frac{\nabla f(x_{k+1})^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}{\ \nabla f(x_k)\ ^2}$	Встроенный рестарт, лучше на практике
Хестенс-Штифель (HS)	$\frac{\nabla f(x_{k+1})^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}{d_k^\top (\nabla f(x_{k+1}) - \nabla f(x_k))}$	Эквивалентен PR в квадратичном случае

Все три формулы совпадают для квадратичных функций с точным линейным поиском. Для неквадратичных задач на практике рекомендуется использовать метод Полака-Рибьера с периодическим рестартом (обнуление  $\beta_k$  каждые  $n$  шагов или при  $\beta_k < 0$ ).

# Численные эксперименты

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=0$





— Gradient Descent    -.- Steepest Descent    - - - Conjugate Gradients PR    - - - Conjugate Gradients FR

# Численные эксперименты

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$





— Gradient Descent    -.- Steepest Descent    - - - Conjugate Gradients PR    - - - Conjugate Gradients FR

# Численные эксперименты

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$





- Gradient Descent
- - - Conjugate Gradients PR
- . - Steepest Descent
- Conjugate Gradients PR, restart 20
- - - Conjugate Gradients FR
- Conjugate Gradients FR, restart 20

# Численные эксперименты

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$





- Gradient Descent
- - - Conjugate Gradients PR
- - - Conjugate Gradients FR
- . - Steepest Descent
- Conjugate Gradients PR, restart 50
- Conjugate Gradients FR, restart 50

# Численные эксперименты

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=10$





— Gradient Descent    -.- Steepest Descent    - - - Conjugate Gradients PR    - - - Conjugate Gradients FR

# Численные эксперименты

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=10$





- Gradient Descent
- - - Conjugate Gradients PR
- - - Conjugate Gradients FR
- · - Steepest Descent
- Conjugate Gradients PR, restart 20
- Conjugate Gradients FR, restart 20

## Сравнение FR, PR, HS. $\mu = 1$ , без рестарта

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$





— Gradient Descent    - - - Steepest Descent    - - - Conjugate Gradients PR    - - - Conjugate Gradients FR    ···· Conjugate Gradients HS

## Сравнение FR, PR, HS. $\mu = 10$ , без рестарта

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=10$





— Gradient Descent    — Steepest Descent    - - Conjugate Gradients PR    - - Conjugate Gradients FR    ··· Conjugate Gradients HS

# Сравнение FR, PR, HS. $\mu = 0.1$ , без рестарта

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=0.1$





— Gradient Descent    -·- Steepest Descent    - - - Conjugate Gradients PR    - - - Conjugate Gradients FR    ··· Conjugate Gradients HS

## Сравнение FR, PR, HS. $\mu = 1$ , рестарт каждые 20 итераций

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$ . Restart=20





— Gradient Descent    - - Steepest Descent    - - Conjugate Gradients PR    - - Conjugate Gradients FR    . . . Conjugate Gradients HS

## Сравнение FR, PR, HS. $\mu = 1$ , рестарт каждые 50 итераций

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$ . Restart=50





— Gradient Descent    - - Steepest Descent    - - Conjugate Gradients PR    - - Conjugate Gradients FR    ··· Conjugate Gradients HS

# PR vs PR+. $\mu = 1$

$$f(x) = \frac{\mu}{2} \|x\|_2^2 + \frac{1}{m} \sum_{i=1}^m \log(1 + \exp(-y_i \langle a_i, x \rangle)) \rightarrow \min_{x \in \mathbb{R}^n}$$

PR vs PR+. Regularized binary logistic regression.  $n=300$ .  $m=1000$ .  $\mu=1$



— Gradient Descent    - - - Conjugate Gradients PR    - - - Conjugate Gradients PR+    - - - Conjugate Gradients FR    ···· Conjugate Gradients HS