

# Лекция 14. Итерационные методы для решения систем линейных уравнений

Максим Рахуба

ФКН ВШЭ  
Основы матричных вычислений 20/21

Май 11, 2021

# Введение: Прямые vs. итерационные методы

**Дано:** невырожденная  $\mathbf{A} \in \mathbb{R}^{n \times n}$ , вектор  $\mathbf{b} \in \mathbb{R}^n$ .

**Цель:** найти  $\mathbf{x} \in \mathbb{R}^n$ :  $\mathbf{Ax} = \mathbf{b}$ .

# Введение: Прямые vs. итерационные методы

**Дано:** невырожденная  $\mathbf{A} \in \mathbb{R}^{n \times n}$ , вектор  $\mathbf{b} \in \mathbb{R}^n$ .

**Цель:** найти  $\mathbf{x} \in \mathbb{R}^n$ :  $\mathbf{Ax} = \mathbf{b}$ .

## Прямые методы (LU разложение)

- ▶ Подходят и для плотных, и для разреженных  $\mathbf{A}$ .
- ▶ Для плотных:  $\mathcal{O}(n^3)$  FLOPs и  $\mathcal{O}(n^2)$  память

$n$	$10^3$	$10^4$	$10^5$
Time	0.4 s	6 s	1.7 h
Mem(A)	8 Mb	0.8 Gb	80 Gb

- ▶ Для разреженных матриц обычно невозможно добиться оптимальной сложности  $\mathcal{O}(n)$ .

# Введение: Прямые vs. итерационные методы

**Дано:** невырожденная  $\mathbf{A} \in \mathbb{R}^{n \times n}$ , вектор  $\mathbf{b} \in \mathbb{R}^n$ .

**Цель:** найти  $\mathbf{x} \in \mathbb{R}^n$ :  $\mathbf{Ax} = \mathbf{b}$ .

## Прямые методы (LU разложение)

- ▶ Подходят и для плотных, и для разреженных  $\mathbf{A}$ .
- ▶ Для плотных:  $\mathcal{O}(n^3)$  FLOPs и  $\mathcal{O}(n^2)$  память

$n$	$10^3$	$10^4$	$10^5$
Time	0.4 s	6 s	1.7 h
Mem(A)	8 Mb	0.8 Gb	80 Gb

- ▶ Для разреженных матриц обычно невозможно добиться оптимальной сложности  $\mathcal{O}(n)$ .

Сначала закончится память

## Итерационные методы

Пример: метод простой итерации (Richardson iteration):

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau(\mathbf{b} - \mathbf{Ax}_k), \quad \tau \in \mathbb{R}.$$

- ▶ Сложность определяется вычислением  $\mathbf{Ax}_k$ .
- ▶ Количество итераций  $K = K(n, \varepsilon)$

# Введение: Прямые vs. итерационные методы

**Дано:** невырожденная  $\mathbf{A} \in \mathbb{R}^{n \times n}$ , вектор  $\mathbf{b} \in \mathbb{R}^n$ .

**Цель:** найти  $\mathbf{x} \in \mathbb{R}^n$ :  $\mathbf{Ax} = \mathbf{b}$ .

## Прямые методы (LU разложение)

- ▶ Подходят и для плотных, и для разреженных  $\mathbf{A}$ .
- ▶ Для плотных:  $\mathcal{O}(n^3)$  FLOPs и  $\mathcal{O}(n^2)$  память

$n$	$10^3$	$10^4$	$10^5$
Time	0.4 s	6 s	1.7 h
Mem(A)	8 Mb	0.8 Gb	80 Gb

- ▶ Для разреженных матриц обычно невозможно добиться оптимальной сложности  $\mathcal{O}(n)$ .

Сначала закончится память

## Итерационные методы

Пример: метод простой итерации (Richardson iteration):

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau(\mathbf{b} - \mathbf{Ax}_k), \quad \tau \in \mathbb{R}.$$

- ▶ Сложность определяется вычислением  $\mathbf{Ax}_k$ .
- ▶ Количество итераций  $K = K(n, \varepsilon)$

# Введение: матвеки

Матрично-векторное произведение (матвек):

$$\mathbf{y} = \mathbf{Ax}$$


- ▶ Произвольная плотная  $\mathbf{A}$ :  $\mathcal{O}(n^2)$  операций и памяти.

# Введение: матвеки

Матрично-векторное произведение (матвек):

$$y = Ax$$

- ▶ Произвольная плотная  $A$ :  $\mathcal{O}(n^2)$  операций и памяти.
- ▶ Разреженная  $A$ :  $\mathcal{O}(\text{nnz}(A))$  операций и памяти, где  $\text{nnz}(A)$  — число ненулевых элементов (#nonzeros).




# Введение: матвеки

Матрично-векторное произведение (матвек):

$$y = Ax$$

- ▶ Произвольная плотная  $A$ :  $\mathcal{O}(n^2)$  операций и памяти.
- ▶ Разреженная  $A$ :  $\mathcal{O}(\text{nnz}(A))$  операций и памяти, где  $\text{nnz}(A)$  — число ненулевых элементов (#nonzeros).



- ▶ Сложность меньше  $\mathcal{O}(n^2)$  для некоторых структурированных матриц (Фурье, теплицевы, циркулянты, ганкелевы, ...), а также для матриц с блоками малого ранга ( $\mathcal{H}$ ,  $\mathcal{H}^2$  матрицы).



# Одношаговые итерационные методы

Сегодня будем рассматривать одношаговые методы:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

где  $\tau_k \in \mathbb{R}$  и  $\mathbf{P} \in \mathbb{R}^{n \times n}$  подбираются для ускорения сходимости.

# Одношаговые итерационные методы

Сегодня будем рассматривать одношаговые методы:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

где  $\tau_k \in \mathbb{R}$  и  $\mathbf{P} \in \mathbb{R}^{n \times n}$  подбираются для ускорения сходимости.

- ▶ Если  $\tau_k \equiv 1$ ,  $\mathbf{P} = \mathbf{A}$ , то сойдется за **1 итерацию**, но умножить на  $\mathbf{A}^{-1}$  так же сложно, как и решить  $\mathbf{A}\mathbf{x} = \mathbf{b}$ .

# Одношаговые итерационные методы

Сегодня будем рассматривать одношаговые методы:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

где  $\tau_k \in \mathbb{R}$  и  $\mathbf{P} \in \mathbb{R}^{n \times n}$  подбираются для ускорения сходимости.

- ▶ Если  $\tau_k \equiv 1$ ,  $\mathbf{P} = \mathbf{A}$ , то сойдется за **1 итерацию**, но умножить на  $\mathbf{A}^{-1}$  так же сложно, как и решить  $\mathbf{A}\mathbf{x} = \mathbf{b}$ .
- ▶  $\mathbf{P}$  надо выбирать “близким” к  $\mathbf{A}$ , но, при этом, чтобы на  $\mathbf{P}^{-1}$  было быстро умножать. Например,

# Одношаговые итерационные методы

Сегодня будем рассматривать одношаговые методы:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

где  $\tau_k \in \mathbb{R}$  и  $\mathbf{P} \in \mathbb{R}^{n \times n}$  подбираются для ускорения сходимости.

- ▶ Если  $\tau_k \equiv 1$ ,  $\mathbf{P} = \mathbf{A}$ , то сойдется за **1 итерацию**, но умножить на  $\mathbf{A}^{-1}$  так же сложно, как и решить  $\mathbf{A}\mathbf{x} = \mathbf{b}$ .
- ▶  $\mathbf{P}$  надо выбирать “близким” к  $\mathbf{A}$ , но, при этом, чтобы на  $\mathbf{P}^{-1}$  было быстро умножать. Например,
  - ▶  $\mathbf{P}$  – диагональная часть  $\mathbf{A}$  (метод Якоби при  $\tau_k = 1$ )

# Одношаговые итерационные методы

Сегодня будем рассматривать одношаговые методы:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

где  $\tau_k \in \mathbb{R}$  и  $\mathbf{P} \in \mathbb{R}^{n \times n}$  подбираются для ускорения сходимости.

- ▶ Если  $\tau_k \equiv 1$ ,  $\mathbf{P} = \mathbf{A}$ , то сойдется за **1 итерацию**, но умножить на  $\mathbf{A}^{-1}$  так же сложно, как и решить  $\mathbf{A}\mathbf{x} = \mathbf{b}$ .
- ▶  $\mathbf{P}$  надо выбирать “близким” к  $\mathbf{A}$ , но, при этом, чтобы на  $\mathbf{P}^{-1}$  было быстро умножать. Например,
  - ▶  $\mathbf{P}$  – диагональная часть  $\mathbf{A}$  (метод Якоби при  $\tau_k = 1$ )
  - ▶  $\mathbf{P}$  – нижнетреугольная часть  $\mathbf{A}$  (Гаусс-Зейдель при  $\tau_k = 1$ )

# Одношаговые итерационные методы

Сегодня будем рассматривать одношаговые методы:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

где  $\tau_k \in \mathbb{R}$  и  $\mathbf{P} \in \mathbb{R}^{n \times n}$  подбираются для ускорения сходимости.

- ▶ Если  $\tau_k \equiv 1$ ,  $\mathbf{P} = \mathbf{A}$ , то сойдется за **1 итерацию**, но умножить на  $\mathbf{A}^{-1}$  так же сложно, как и решить  $\mathbf{A}\mathbf{x} = \mathbf{b}$ .
- ▶  $\mathbf{P}$  надо выбирать “близким” к  $\mathbf{A}$ , но, при этом, чтобы на  $\mathbf{P}^{-1}$  было быстро умножать. Например,
  - ▶  $\mathbf{P}$  – диагональная часть  $\mathbf{A}$  (**метод Якоби** при  $\tau_k = 1$ )
  - ▶  $\mathbf{P}$  – нижнетреугольная часть  $\mathbf{A}$  (**Гаусс-Зейдель** при  $\tau_k = 1$ )
- ▶ Будем рассматривать  $\tau_k = \tau$  (**метод простой итерации**) и переменное  $\tau_k$  (**градиентный спуск, метод Чебышёва**).

# План

**Метод простой итерации**

Градиентный спуск

Чебышёвский итерационный метод

# Метод простой итерации

Положим  $\tau_k \equiv \tau$  и перепишем в следующем виде:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau \mathbf{P}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k) \equiv \mathbf{G}\mathbf{x}_k + \mathbf{g},$$

где  $\mathbf{G} = (\mathbf{I} - \tau \mathbf{P}^{-1}\mathbf{A})$  и  $\mathbf{g} = \tau \mathbf{P}^{-1}\mathbf{b}$ .

## Теорема

Итерационный процесс  $\mathbf{x}_{k+1} = \mathbf{G}\mathbf{x}_k + \mathbf{g}$ , сходится к единственному решению для любого начального приближения  $\mathbf{x}_0$  и любого  $\mathbf{g}$  тогда и только тогда, когда  $\rho(\mathbf{G}) < 1$ .

$$\begin{aligned} \square x_1 &= G x_0 + g \\ x_2 &= G x_1 + g = G(G x_0 + g) + g = G^2 x_0 + Gg + g \\ &\vdots \\ x_k &= G^k x_0 + \underbrace{G^{k-1}g + \dots + Gg + g}_{\sum_{i=0}^{k-1} G^i g} \end{aligned}$$

## Следствие

Если  $\|G\| < 1$  для некоторой матричной  $\|\cdot\|$ , то  $\mathbf{x}_{k+1} = \mathbf{G}\mathbf{x}_k + \mathbf{g}$  сходится к единственному решению для любого  $\mathbf{x}_0$ .



# Метод простой итерации

Пусть  $\mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U}$ , где  $\mathbf{D} = \text{diag}(\mathbf{A})$ , а  $\mathbf{L}$ ,  $\mathbf{U}$  – нижне- и верхнетреугольная части  $\mathbf{A}$  без диагонали.

# Метод простой итерации

Пусть  $\mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U}$ , где  $\mathbf{D} = \text{diag}(\mathbf{A})$ , а  $\mathbf{L}, \mathbf{U}$  – ниже- и верхнетреугольная части  $\mathbf{A}$  без диагонали.

## Утверждение (сходимость метода Якоби)

Пусть матрица  $\mathbf{A}$  обладает свойством строгого строчного диагонального преобладания:  $|a_{ii}| > \sum_{j \neq i} |a_{ij}|$ , тогда процесс:

$$\mathbf{x}_{k+1} = \cancel{\mathbf{x}_k} + \mathbf{D}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k), \quad (\text{метод Якоби})$$

"L+D+U"

сходится для любого  $\mathbf{x}_0$ .

$\mathbf{D}^{-1}(\mathbf{b} - (\mathbf{L} + \mathbf{U})\mathbf{x}_k)$  – альтернативная запись

$$\square \quad \|\mathbf{I} - \mathbf{D}^{-1}\mathbf{A}\|_{\infty} = \|\mathbf{D}^{-1}(\mathbf{L} + \mathbf{U})\|_{\infty} = \frac{\sum_{j \neq i} |a_{ij}|}{|a_{ii}|} < 1$$

# Метод простой итерации

Пусть  $\mathbf{A} = \mathbf{L} + \mathbf{D} + \mathbf{U}$ , где  $\mathbf{D} = \text{diag}(\mathbf{A})$ , а  $\mathbf{L}, \mathbf{U}$  – ниже- и верхнетреугольная части  $\mathbf{A}$  без диагонали.

## Утверждение (сходимость метода Якоби)

Пусть матрица  $\mathbf{A}$  обладает свойством строгого строчного диагонального преобладания:  $|a_{ii}| > \sum_{j \neq i} |a_{ij}|$ , тогда процесс:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \mathbf{D}^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k), \quad (\text{метод Якоби})$$

сходится для любого  $\mathbf{x}_0$ .

## Утверждение (сходимость метода Гаусса-Зейделя)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$ . Тогда процесс:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + (\mathbf{L} + \mathbf{D})^{-1}(\mathbf{b} - \mathbf{A}\mathbf{x}_k), \quad (\text{метод Гаусса-Зейделя})$$

сходится для любого  $\mathbf{x}_0$ .

□ Идея  $\| \mathbf{I} - (\mathbf{L} + \mathbf{D})^{-1} \mathbf{A} \|_A$ ,  $\| \mathbf{x} \|_A = \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$   
(см. семинар)

# Метод простой итерации

Рассмотрим итерационный процесс

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k).$$

## Утверждение (сходимость метода простой итерации)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  с собственными значениями  $\lambda_1 \geq \dots \geq \lambda_n > 0$ .

1. Если  $0 < \tau < 2/\lambda_1$ , то  $\{\mathbf{x}_k\}$  сходится для любого  $\mathbf{x}_0$ .
2.  $\tau = \tau_{\text{opt}} \equiv \frac{2}{\lambda_1 + \lambda_n}$  минимизирует  $\|\mathbf{I} - \tau\mathbf{A}\|_2$ , и для ошибки  $\mathbf{e}_k \equiv \mathbf{x} - \mathbf{x}_k$  справедливо

$$\|\mathbf{e}_{k+1}\|_2 \leq \frac{\overset{\text{// } 100}{\text{cond}_2(\mathbf{A}) - 1}}{\underbrace{\text{cond}_2(\mathbf{A}) + 1}} \|\mathbf{e}_k\|_2$$

$$\frac{99}{100} = 0.99$$

# Метод простой итерации

Рассмотрим итерационный процесс

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k).$$

## Утверждение (сходимость метода простой итерации)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  с собственными значениями  $\lambda_1 \geq \dots \geq \lambda_n > 0$ .

1. Если  $0 < \tau < 2/\lambda_1$ , то  $\{\mathbf{x}_k\}$  сходится для любого  $\mathbf{x}_0$ .
2.  $\tau = \tau_{\text{opt}} \equiv \frac{2}{\lambda_1 + \lambda_n}$  минимизирует  $\|\mathbf{I} - \tau\mathbf{A}\|_2$ , и для ошибки  $\mathbf{e}_k \equiv \mathbf{x} - \mathbf{x}_k$  справедливо

$$\|\mathbf{e}_{k+1}\|_2 \leq \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1} \|\mathbf{e}_k\|_2$$

## Доказательство.

$$\begin{aligned} \triangleright \|\mathbf{x} - \mathbf{x}_{k+1}\|_2 &= \|\mathbf{x} - \mathbf{x}_k - \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k)\|_2 = \|\mathbf{x} - \mathbf{x}_k - \tau(\mathbf{A}\mathbf{x} - \mathbf{A}\mathbf{x}_k)\|_2 = \\ &= \|(\mathbf{I} - \tau\mathbf{A})(\mathbf{x} - \mathbf{x}_k)\|_2 \leq \|\mathbf{I} - \tau\mathbf{A}\|_2 \|\mathbf{x} - \mathbf{x}_k\|_2. \end{aligned}$$



# Метод простой итерации

Рассмотрим итерационный процесс

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k).$$

## Утверждение (сходимость метода простой итерации)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  с собственными значениями  $\lambda_1 \geq \dots \geq \lambda_n > 0$ .

1. Если  $0 < \tau < 2/\lambda_1$ , то  $\{\mathbf{x}_k\}$  сходится для любого  $\mathbf{x}_0$ .
2.  $\tau = \tau_{\text{opt}} \equiv \frac{2}{\lambda_1 + \lambda_n}$  минимизирует  $\|\mathbf{I} - \tau\mathbf{A}\|_2$ , и для ошибки  $\mathbf{e}_k \equiv \mathbf{x} - \mathbf{x}_k$  справедливо

$$\|\mathbf{e}_{k+1}\|_2 \leq \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1} \|\mathbf{e}_k\|_2$$

## Доказательство.

- ▶  $\|\mathbf{x} - \mathbf{x}_{k+1}\|_2 = \|\mathbf{x} - \mathbf{x}_k - \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k)\|_2 = \|\mathbf{x} - \mathbf{x}_k - \tau(\mathbf{A}\mathbf{x} - \mathbf{A}\mathbf{x}_k)\|_2 = \|(\mathbf{I} - \tau\mathbf{A})(\mathbf{x} - \mathbf{x}_k)\|_2 \leq \|\mathbf{I} - \tau\mathbf{A}\|_2 \|\mathbf{x} - \mathbf{x}_k\|_2.$
- ▶  $\|\mathbf{I} - \tau\mathbf{A}\|_2 = \max_j |1 - \tau\lambda_j| < 1 \Rightarrow -1 < 1 - \tau\lambda_j < 1 \Rightarrow 0 < \tau < 2/\lambda_j \forall j.$



# Метод простой итерации

Рассмотрим итерационный процесс

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k).$$

## Утверждение (сходимость метода простой итерации)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  с собственными значениями  $\lambda_1 \geq \dots \geq \lambda_n > 0$ .

1. Если  $0 < \tau < 2/\lambda_1$ , то  $\{\mathbf{x}_k\}$  сходится для любого  $\mathbf{x}_0$ .
2.  $\tau = \tau_{\text{opt}} \equiv \frac{2}{\lambda_1 + \lambda_n}$  минимизирует  $\|\mathbf{I} - \tau\mathbf{A}\|_2$ , и для ошибки  $\mathbf{e}_k \equiv \mathbf{x} - \mathbf{x}_k$  справедливо

$$\|\mathbf{e}_{k+1}\|_2 \leq \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1} \|\mathbf{e}_k\|_2$$

## Доказательство.

- ▶  $\|\mathbf{x} - \mathbf{x}_{k+1}\|_2 = \|\mathbf{x} - \mathbf{x}_k - \tau(\mathbf{b} - \mathbf{A}\mathbf{x}_k)\|_2 = \|\mathbf{x} - \mathbf{x}_k - \tau(\mathbf{A}\mathbf{x} - \mathbf{A}\mathbf{x}_k)\|_2 = \|(\mathbf{I} - \tau\mathbf{A})(\mathbf{x} - \mathbf{x}_k)\|_2 \leq \|\mathbf{I} - \tau\mathbf{A}\|_2 \|\mathbf{x} - \mathbf{x}_k\|_2.$
- ▶  $\|\mathbf{I} - \tau\mathbf{A}\|_2 = \max_j |1 - \tau\lambda_j| < 1 \Rightarrow -1 < 1 - \tau\lambda_j < 1 \Rightarrow 0 < \tau < 2/\lambda_j \forall j.$
- ▶  $\|\mathbf{I} - \tau_{\text{opt}}\mathbf{A}\|_2 = \max_j \frac{|\lambda_1 + \lambda_n - 2\lambda_j|}{\lambda_1 + \lambda_n} = \frac{\lambda_1 - \lambda_n}{\lambda_1 + \lambda_n} = \frac{\lambda_1/\lambda_n - 1}{\lambda_1/\lambda_n + 1} = \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1}.$

□

# План

Метод простой итерации

Градиентный спуск

$\tau_k$

Чебышёвский итерационный метод



# $A\mathbf{x} = \mathbf{b}$ как задача минимизации

**Предположение:**  $\mathbf{A} = \mathbf{A}^T > 0$

Хотим, чтобы  $\mathbf{x}_* = \mathbf{A}^{-1}\mathbf{b}$  было также решением некоторой задачи оптимизации:

$$\mathbf{x}_* = \arg \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}).$$

# $A\mathbf{x} = \mathbf{b}$ как задача минимизации

**Предположение:**  $\mathbf{A} = \mathbf{A}^T > 0$

Хотим, чтобы  $\mathbf{x}_* = \mathbf{A}^{-1}\mathbf{b}$  было также решением некоторой задачи оптимизации:

$$\mathbf{x}_* = \arg \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}).$$

**Выбор  $f(\mathbf{x})$ :**

- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_2^2$  — необходимо знать  $\mathbf{x}_*$ .

# $Ax = b$ как задача минимизации

**Предположение:**  $A = A^T > 0$

Хотим, чтобы  $x_* = A^{-1}b$  было также решением некоторой задачи оптимизации:

$$x_* = \arg \min_{x \in \mathbb{R}^n} f(x).$$

**Выбор  $f(x)$ :**

- ▶  $\|x - x_*\|_2^2$  — необходимо знать  $x_*$ .
- ▶  $\|x - x_*\|_A^2$ , где  $\|x\|_A \stackrel{\text{def}}{=} \sqrt{x^T A x}$ :  $(x, y)_A = x^T A y$

# $A\mathbf{x} = \mathbf{b}$ как задача минимизации

**Предположение:**  $\mathbf{A} = \mathbf{A}^\top > 0$

Хотим, чтобы  $\mathbf{x}_* = \mathbf{A}^{-1}\mathbf{b}$  было также решением некоторой задачи оптимизации:

$$\mathbf{x}_* = \arg \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}).$$

**Выбор  $f(\mathbf{x})$ :**

- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_2^2$  — необходимо знать  $\mathbf{x}_*$ .
- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_A^2$ , где  $\|\mathbf{x}\|_A \stackrel{\text{def}}{=} \sqrt{\mathbf{x}^\top \mathbf{A} \mathbf{x}}$ :

$$\begin{aligned} \|\mathbf{x} - \mathbf{x}_*\|_A^2 &= (\mathbf{x} - \mathbf{x}_*)^\top \mathbf{A} (\mathbf{x} - \mathbf{x}_*) = \\ &= \mathbf{x}^\top \mathbf{A} \mathbf{x} - 2\mathbf{x}^\top \mathbf{A} \mathbf{x}_* + \mathbf{x}_*^\top \mathbf{A} \mathbf{x}_* = \\ &= \mathbf{x}^\top \mathbf{A} \mathbf{x} - 2\mathbf{x}^\top \mathbf{b} + \text{const.} \end{aligned}$$

# $A\mathbf{x} = \mathbf{b}$ как задача минимизации

**Предположение:**  $\mathbf{A} = \mathbf{A}^\top > 0$

Хотим, чтобы  $\mathbf{x}_* = \mathbf{A}^{-1}\mathbf{b}$  было также решением некоторой задачи оптимизации:

$$\mathbf{x}_* = \arg \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}).$$

**Выбор  $f(\mathbf{x})$ :**

- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_2^2$  — необходимо знать  $\mathbf{x}_*$ .
- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_A^2$ , где  $\|\mathbf{x}\|_A \stackrel{\text{def}}{=} \sqrt{\mathbf{x}^\top \mathbf{A} \mathbf{x}}$ :

$$\begin{aligned} \|\mathbf{x} - \mathbf{x}_*\|_A^2 &= (\mathbf{x} - \mathbf{x}_*)^\top \mathbf{A} (\mathbf{x} - \mathbf{x}_*) = \\ &= \mathbf{x}^\top \mathbf{A} \mathbf{x} - 2\mathbf{x}^\top \mathbf{A} \mathbf{x}_* + \mathbf{x}_*^\top \mathbf{A} \mathbf{x}_* = \\ &= \mathbf{x}^\top \mathbf{A} \mathbf{x} - 2\mathbf{x}^\top \mathbf{b} + \text{const}. \end{aligned}$$

Таким образом, будем использовать  $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^\top \mathbf{A} \mathbf{x} - \mathbf{x}^\top \mathbf{b}$ .

# $A\mathbf{x} = \mathbf{b}$ как задача минимизации

**Предположение:**  $\mathbf{A} = \mathbf{A}^T > 0$

Хотим, чтобы  $\mathbf{x}_* = \mathbf{A}^{-1}\mathbf{b}$  было также решением некоторой задачи оптимизации:

$$\mathbf{x}_* = \arg \min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x}).$$

**Выбор  $f(\mathbf{x})$ :**

- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_2^2$  — необходимо знать  $\mathbf{x}_*$ .
- ▶  $\|\mathbf{x} - \mathbf{x}_*\|_A^2$ , где  $\|\mathbf{x}\|_A \stackrel{\text{def}}{=} \sqrt{\mathbf{x}^T \mathbf{A} \mathbf{x}}$ :

$$\begin{aligned} \|\mathbf{x} - \mathbf{x}_*\|_A^2 &= (\mathbf{x} - \mathbf{x}_*)^T \mathbf{A} (\mathbf{x} - \mathbf{x}_*) = \\ &= \mathbf{x}^T \mathbf{A} \mathbf{x} - 2\mathbf{x}^T \mathbf{A} \mathbf{x}_* + \mathbf{x}_*^T \mathbf{A} \mathbf{x}_* = \\ &= \mathbf{x}^T \mathbf{A} \mathbf{x} - 2\mathbf{x}^T \mathbf{b} + \text{const}. \end{aligned}$$

Таким образом, будем использовать  $f(\mathbf{x}) = \frac{1}{2}\mathbf{x}^T \mathbf{A} \mathbf{x} - \mathbf{x}^T \mathbf{b}$ .


$\mathbf{x}_*$  — точка глобального мин.  $\|\mathbf{x} - \mathbf{x}_*\|_A^2$  и  $f(\mathbf{x})$  по построению.

# $A\mathbf{x} = \mathbf{b}$ как задача минимизации


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

## Пример

$$A = \begin{bmatrix} 4 & 0 \\ 0 & 1 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \Rightarrow f(\mathbf{x}) = \frac{1}{2}(4x_1^2 + x_2^2) - 0.$$



Функция  $f(\mathbf{x})$




Изолинии  
 $f(\mathbf{x}) = \text{const}$

# $A\mathbf{x} = \mathbf{b}$ как задача минимизации


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

## Пример

$$A = U \begin{bmatrix} 4 & 0 \\ 0 & 1 \end{bmatrix} U^T, \quad U = \begin{bmatrix} \cos \frac{\pi}{4} & -\sin \frac{\pi}{4} \\ \sin \frac{\pi}{4} & \cos \frac{\pi}{4} \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 1 \\ 1 \end{bmatrix}$$



Функция  $f(\mathbf{x})$



Изолинии  
 $f(\mathbf{x}) = \text{const}$




# $A\mathbf{x} = \mathbf{b}$ как задача минимизации


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

## Пример

$$\mathbf{A} = \begin{bmatrix} 2 & 0 \\ 0 & -2 \end{bmatrix}, \quad \mathbf{b} = \begin{bmatrix} 0 \\ 0 \end{bmatrix} \Rightarrow f(\mathbf{x}) = \frac{1}{2}(2x_1^2 - 2x_2^2) - 0$$



Функция  $f(\mathbf{x})$



Изолинии  
 $f(\mathbf{x}) = \text{const}$

## $\mathbf{Ax} = \mathbf{b}$ как задача минимизации

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


непрерывно дифференцируема и  $\nabla f = \mathbf{Ax} - \mathbf{b}$ . Действительно,

$$\begin{aligned} f(\mathbf{x} + \mathbf{h}) &= \frac{1}{2}(\mathbf{x} + \mathbf{h})^T\mathbf{A}(\mathbf{x} + \mathbf{h}) - (\mathbf{x} + \mathbf{h})^T\mathbf{b} = \\ &= \frac{1}{2}\mathbf{x}^T\mathbf{Ax} + \mathbf{x}^T\mathbf{Ah} + \frac{1}{2}\mathbf{h}^T\mathbf{Ah} - \mathbf{x}^T\mathbf{b} - \mathbf{h}^T\mathbf{b} = \quad (\clubsuit) \\ &= f(\mathbf{x}) + (\mathbf{Ax} - \mathbf{b})^T\mathbf{h} + \frac{1}{2}\mathbf{h}^T\mathbf{Ah}. \end{aligned}$$

# Градиентный спуск

Хотим улучшить  $\mathbf{x}_k$ , используя направление  $\mathbf{d}_k$  и длину шага  $\tau_k$ :

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \mathbf{d}_k.$$



Вспомним формулу (♣):

$$f(\mathbf{x} + \mathbf{h}) = f(\mathbf{x}) + \nabla f(\mathbf{x})^\top \mathbf{h} + \frac{1}{2} \mathbf{h}^\top \mathbf{A} \mathbf{h}, \quad \nabla f(\mathbf{x}) = \mathbf{A} \mathbf{x} - \mathbf{b}.$$

**Выбор направления  $\mathbf{d}_k$**

Хотим найти  $\mathbf{d}$ :  $\|\mathbf{d}\|_2 = 1$ , который минимизирует производную по направлению:

$$\nabla_{\mathbf{d}} f(\mathbf{x}) = \lim_{\tau \rightarrow 0} \frac{f(\mathbf{x} + \tau \mathbf{d}) - f(\mathbf{x})}{\tau} \stackrel{(\clubsuit)}{=} \nabla f(\mathbf{x})^\top \mathbf{d} = \|\nabla f(\mathbf{x})\|_2 \cos \theta \rightarrow \min_{\theta}$$

Значит,  $\mathbf{d}_k = -\nabla f(\mathbf{x}_k) = \mathbf{b} - \mathbf{A} \mathbf{x}_k = \mathbf{r}_k$  — вектор невязки.


# Метод наискорейшего спуска

(градиентный спуск с оптимальным выбором  $\tau_k$ )

Мы выбрали  $\mathbf{d}_k = -\nabla f(\mathbf{x}_k) = \mathbf{r}_k$ .

Найдем  $\tau_k$  (line search):

$$\tau_k = \arg \min_{\tau \in \mathbb{R}} f(\mathbf{x}_k + \tau \mathbf{r}_k).$$



Вспомним формулу (♣):

$$f(\mathbf{x} + \mathbf{h}) = f(\mathbf{x}) + \nabla f(\mathbf{x})^T \mathbf{h} + \frac{1}{2} \mathbf{h}^T \mathbf{A} \mathbf{h}, \quad \nabla f(\mathbf{x}) = \mathbf{A} \mathbf{x} - \mathbf{b}.$$

Поиск  $\tau_k$

$$f(\mathbf{x}_k + \tau \mathbf{r}_k) \stackrel{(\clubsuit)}{=} f(\mathbf{x}_k) - \tau \mathbf{r}_k^T \mathbf{r}_k + \frac{\tau^2}{2} \mathbf{r}_k^T \mathbf{A} \mathbf{r}_k.$$

$$\frac{\partial f(\mathbf{x}_k + \tau \mathbf{r}_k)}{\partial \tau} = -\mathbf{r}_k^T \mathbf{r}_k + \tau \mathbf{r}_k^T \mathbf{A} \mathbf{r}_k \stackrel{!}{=} 0 \quad \Rightarrow \quad \tau_k = \frac{\mathbf{r}_k^T \mathbf{r}_k}{\mathbf{r}_k^T \mathbf{A} \mathbf{r}_k}.$$

$$\frac{\partial^2 f(\mathbf{x}_k + \tau \mathbf{r}_k)}{\partial \tau^2} = \mathbf{r}_k^T \mathbf{A} \mathbf{r}_k > 0.$$

# Метод наискорейшего спуска

Метод можно записать как:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \underbrace{(\mathbf{b} - \mathbf{A}\mathbf{x}_k)}_{\mathbf{r}_k}, \quad \tau_k = \frac{\mathbf{r}_k^\top \mathbf{r}_k}{\mathbf{r}_k^\top \mathbf{A} \mathbf{r}_k}.$$

# Метод наискорейшего спуска

Метод можно записать как:

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k \underbrace{(\mathbf{b} - \mathbf{A}\mathbf{x}_k)}_{\mathbf{r}_k}, \quad \tau_k = \frac{\mathbf{r}_k^\top \mathbf{r}_k}{\mathbf{r}_k^\top \mathbf{A} \mathbf{r}_k}.$$

## Эффективный алгоритм

- ▶ Проблема: **2 матрица** ( $\mathbf{A}\mathbf{x}_k$  и  $\mathbf{A}\mathbf{r}_k$ ) на каждой итерации.
- ▶ Наблюдение:  $\mathbf{r}_{k+1} = \mathbf{r}_k - \tau_k \mathbf{A}\mathbf{r}_k$ .

```
r0 = b - Ax0  
for  $k = 0, 1, \dots$  until convergence do  
     $\tau_k = \frac{\mathbf{r}_k^\top \mathbf{r}_k}{\mathbf{r}_k^\top \mathbf{A} \mathbf{r}_k}$   
    xk+1 = xk +  $\tau_k \mathbf{r}_k$   
    rk+1 = rk -  $\tau_k \mathbf{A} \mathbf{r}_k$ 
```

Критерий остановки:  $k > k_{\max}$  или  $\|\mathbf{A}\mathbf{x}_k - \mathbf{b}\|_2 \leq \text{tol}$

$\|\mathbf{x}_{k+1} - \mathbf{x}_k\|$

# Сходимость метода

## Теорема (Сходимость наискорейшего спуска)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  и  $\mathbf{x}_k$  сгенерировано с помощью метода наискорейшего спуска, тогда для ошибки  $\mathbf{e}_k := \mathbf{x}_* - \mathbf{x}_k$  справедливо:

$$\|\mathbf{e}_{k+1}\|_{\mathbf{A}} \leq \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1} \|\mathbf{e}_k\|_{\mathbf{A}},$$

## Доказательство.

1.  $2f(\mathbf{x}) + \text{const} = \|\mathbf{x} - \mathbf{x}_*\|_{\mathbf{A}}^2$ , так что

$$\tau_k = \arg \min_{\tau} f(\mathbf{x}_k + \tau \mathbf{r}_k) = \arg \min_{\tau} \|\mathbf{x}_k + \tau \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2.$$



# Сходимость метода

## Теорема (Сходимость наискорейшего спуска)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  и  $\mathbf{x}_k$  сгенерировано с помощью метода наискорейшего спуска, тогда для ошибки  $\mathbf{e}_k := \mathbf{x}_* - \mathbf{x}_k$  справедливо:

$$\|\mathbf{e}_{k+1}\|_{\mathbf{A}} \leq \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1} \|\mathbf{e}_k\|_{\mathbf{A}},$$

## Доказательство.

1.  $2f(\mathbf{x}) + \text{const} = \|\mathbf{x} - \mathbf{x}_*\|_{\mathbf{A}}^2$ , так что

$$\tau_k = \arg \min_{\tau} f(\mathbf{x}_k + \tau \mathbf{r}_k) = \arg \min_{\tau} \|\mathbf{x}_k + \tau \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2.$$

$\chi_k - \mathbf{x}_* = \mathbf{e}_k, \quad \mathbf{r}_k = -\mathbf{A}\mathbf{e}_k$

$$2. \|\mathbf{e}_{k+1}\|_{\mathbf{A}}^2 \stackrel{1.}{=} \min_{\tau} \|\mathbf{x}_k + \tau \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2 \stackrel{\forall t}{\leq} \|\mathbf{x}_k + t \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2 = \|\mathbf{A}^{-1/2}(\mathbf{I} - t\mathbf{A})\mathbf{e}_k\|_2^2$$
$$= \|\mathbf{A}^{1/2}(\mathbf{I} - t\mathbf{A})\mathbf{e}_k\|_2^2 = \|(\mathbf{I} - t\mathbf{A})\mathbf{A}^{1/2}\mathbf{e}_k\|_2^2 \leq \|\mathbf{I} - t\mathbf{A}\|_2^2 \|\mathbf{e}_k\|_{\mathbf{A}}^2.$$

$$\|\mathbf{y}\|_{\mathbf{A}}^2 = \mathbf{y}^T \mathbf{A} \mathbf{y} = \mathbf{y}^T \mathbf{A}^{1/2} \mathbf{A}^{1/2} \mathbf{y} = (\mathbf{A}^{1/2} \mathbf{y})^T \mathbf{A}^{1/2} \mathbf{y} = \|\mathbf{A}^{1/2} \mathbf{y}\|_2^2 \quad \square$$



# Сходимость метода

## Теорема (Сходимость наискорейшего спуска)

Пусть  $\mathbf{A} = \mathbf{A}^T > 0$  и  $\mathbf{x}_k$  сгенерировано с помощью метода наискорейшего спуска, тогда для ошибки  $\mathbf{e}_k := \mathbf{x}_* - \mathbf{x}_k$  справедливо:

$$\|\mathbf{e}_{k+1}\|_{\mathbf{A}} \leq \frac{\text{cond}_2(\mathbf{A}) - 1}{\text{cond}_2(\mathbf{A}) + 1} \|\mathbf{e}_k\|_{\mathbf{A}},$$

## Доказательство.

1.  $2f(\mathbf{x}) + \text{const} = \|\mathbf{x} - \mathbf{x}_*\|_{\mathbf{A}}^2$ , так что

$$\tau_k = \arg \min_{\tau} f(\mathbf{x}_k + \tau \mathbf{r}_k) = \arg \min_{\tau} \|\mathbf{x}_k + \tau \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2.$$

2.  $\|\mathbf{e}_{k+1}\|_{\mathbf{A}}^2 \stackrel{1.}{=} \min_{\tau} \|\mathbf{x}_k + \tau \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2 \stackrel{\forall t}{\leq} \|\mathbf{x}_k + t \mathbf{r}_k - \mathbf{x}_*\|_{\mathbf{A}}^2 = \|(\mathbf{I} - t\mathbf{A})\mathbf{e}_k\|_{\mathbf{A}}^2$   
 $= \|\mathbf{A}^{1/2}(\mathbf{I} - t\mathbf{A})\mathbf{e}_k\|_2^2 = \|(\mathbf{I} - t\mathbf{A})\mathbf{A}^{1/2}\mathbf{e}_k\|_2^2 \leq \|\mathbf{I} - t\mathbf{A}\|_2^2 \|\mathbf{e}_k\|_{\mathbf{A}}^2.$

3. Выберем  $t = \frac{2}{\lambda_1 + \lambda_n}$ .



# План

Метод простой итерации

Градиентный спуск

**Чебышёвский итерационный метод**

# Чебышёвский итерационный метод

Хотим ускорить сходимость

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

$$A = A^T > 0$$

по сравнению с простой итерацией и наискорейшим спуском.

## Идея

Будем оптимизировать по всем итерациям:

$$\begin{aligned} \|\mathbf{e}_k\|_2 &= \|\mathbf{I} - \tau_{k-1}\mathbf{A}\|_2 \|\mathbf{e}_{k-1}\|_2 = \|\mathbf{I} - \tau_{k-1}\mathbf{A}\|_2 \dots \|\mathbf{I} - \tau_0\mathbf{A}\|_2 \|\mathbf{e}_0\|_2 = \\ &= \|\rho_k(\mathbf{A})\mathbf{e}_0\|_2 \leq \|\rho_k(\mathbf{A})\|_2 \|\mathbf{e}_0\|_2, \quad \rho_k \in \mathbb{P}_k, \quad \rho_k(0) = 1. \end{aligned}$$

# Чебышёвский итерационный метод

Хотим ускорить сходимость

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

по сравнению с простой итерацией и наискорейшим спуском.

## Идея

Будем оптимизировать по всем итерациям:

$$\begin{aligned}\|\mathbf{e}_k\|_2 &= \|(\mathbf{I} - \tau_{k-1}\mathbf{A})\mathbf{e}_{k-1}\|_2 = \|(\mathbf{I} - \tau_{k-1}\mathbf{A}) \dots (\mathbf{I} - \tau_0\mathbf{A})\mathbf{e}_0\|_2 = \\ &= \|\rho_k(\mathbf{A})\mathbf{e}_0\|_2 \leq \|\rho_k(\mathbf{A})\|_2 \|\mathbf{e}_0\|_2, \quad \rho_k \in \mathbb{P}_k, \quad \rho_k(0) = 1.\end{aligned}$$

Из собственного разложения  $\mathbf{A} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^*$  получим

$$\|\rho_k(\mathbf{A})\|_2 = \|\mathbf{U}\rho_k(\mathbf{\Lambda})\mathbf{U}^*\|_2 = \|\rho_k(\mathbf{\Lambda})\|_2 = \max_i |\rho_k(\lambda_i)| \leq \max_{\lambda \in [\lambda_n, \lambda_1]} |\rho_k(\lambda)|.$$

# Чебышёвский итерационный метод

Хотим ускорить сходимость

$$\mathbf{x}_{k+1} = \mathbf{x}_k + \tau_k(\mathbf{b} - \mathbf{A}\mathbf{x}_k),$$

по сравнению с простой итерацией и наискорейшим спуском.

## Идея

Будем оптимизировать по всем итерациям:

$$\begin{aligned}\|\mathbf{e}_k\|_2 &= \|(\mathbf{I} - \tau_{k-1}\mathbf{A})\mathbf{e}_{k-1}\|_2 = \|(\mathbf{I} - \tau_{k-1}\mathbf{A}) \dots (\mathbf{I} - \tau_0\mathbf{A})\mathbf{e}_0\|_2 = \\ &= \|\rho_k(\mathbf{A})\mathbf{e}_0\|_2 \leq \|\rho_k(\mathbf{A})\|_2 \|\mathbf{e}_0\|_2, \quad \rho_k \in \mathbb{P}_k, \quad \rho_k(0) = 1.\end{aligned}$$

Из собственного разложения  $\mathbf{A} = \mathbf{U}\mathbf{\Lambda}\mathbf{U}^*$  получим

$$\|\rho_k(\mathbf{A})\|_2 = \|\mathbf{U}\rho_k(\mathbf{\Lambda})\mathbf{U}^*\|_2 = \|\rho_k(\mathbf{\Lambda})\|_2 = \max_i |\rho_k(\lambda_i)| \leq \max_{\lambda \in [\lambda_n, \lambda_1]} |\rho_k(\lambda)|.$$

Итог – хотим решить минимакс задачу:

$$\min_{\substack{\rho_k \in \mathbb{P}_k \\ \rho_k(0)=1}} \max_{\lambda \in [\lambda_n, \lambda_1]} |\rho_k(\lambda)|,$$

то есть найти полином, наименее отклоняющийся от 0 на  $[\lambda_n, \lambda_1]$ .

# Чебышёвский итерационный метод

Решение задачи

$$\min_{\substack{p_k \in \mathbb{P}_k \\ p_k(0)=1}} \max_{\lambda \in [\lambda_n, \lambda_1]} |p_k(\lambda)|,$$

можно выразить с помощью полиномов Чебышёва.

## Полиномы Чебышёва


$$T_0(x) = 1, \quad T_1(x) = x,$$

$$T_{n+1}(x) = 2xT_n(x) - T_{n-1}(x), \quad n = 1, 2, \dots$$

Альтернативные формулы:

$$1. \quad T_n(x) = \begin{cases} \cos(n \arccos x), & |x| \leq 1 \\ \text{ch}(n \text{arcch} x), & |x| > 1 \end{cases}$$

$$2. \quad T_n(x) = \frac{1}{2} \left( (x + \sqrt{x^2 - 1})^n + (x - \sqrt{x^2 - 1})^{-n} \right) \quad \forall x \in \mathbb{C}$$



# Чебышёвский итерационный метод

## Теорема

Пусть  $\xi \notin [a, b]$ . Решение задачи

$$\min_{\substack{p_k \in \mathbb{P}_k \\ p_k(\xi) = M}} \max_{\lambda \in [a, b]} |p_k(\lambda)|,$$


имеет вид

$$p_k(\lambda) = \frac{M}{T_k\left(\frac{2\xi - a - b}{b - a}\right)} T_k\left(\frac{2\lambda - a - b}{b - a}\right)$$

□  $[-1, 1] = [a, b]$ ,  $\xi \notin [-1, 1]$ ,  $t = \frac{2\xi - a - b}{b - a}$

]]  $\tilde{p}_k(x)$ :  $\tilde{E} = \max_{x \in [-1, 1]} |\tilde{p}_k(x)| < E = \max_{x \in [-1, 1]} |p_k(x)|$

$$\varphi_k(x) = p_k(x) - \tilde{p}_k(x)$$



$n+1$  корней у  $\varphi_k(x)$

$$\Downarrow \\ \varphi_k(x) \equiv 0$$

# Чебышёвский итерационный метод



## Чебышёвский итерационный метод

- ▶ Обозначим  $\sigma(x) = x + \sqrt{x^2 - 1}$ , тогда  $T_k(x) = \frac{1}{2}(\sigma(x)^k + \sigma(x)^{-k})$

# Чебышёвский итерационный метод

- ▶ Обозначим  $\sigma(x) = x + \sqrt{x^2 - 1}$ , тогда  $T_k(x) = \frac{1}{2}(\sigma(x)^k + \sigma(x)^{-k})$
- ▶ Применяя теорему при  $M = 1$ ,  $[a, b] = [\lambda_n, \lambda_1]$  и учитывая, что  $|T_k(x)| \leq 1$  при  $x \in [-1, 1]$ , получим:

$$\rho_k(\lambda) \leq \frac{1}{\left| T_k \left( \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} \right) \right|} = \frac{2\sigma \left( \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} \right)^k}{1 + \sigma \left( \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} \right)^{2k}} \leq 2\sigma \left( \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} \right)^k,$$

где

$$\frac{1}{2}(\sigma^k + \sigma^{-k})$$

$$\sigma \equiv \sigma \left( \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} \right) = \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} + \sqrt{\left( \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} \right)^2 - 1} = \frac{\sqrt{\frac{\lambda_1}{\lambda_n}} - 1}{\sqrt{\frac{\lambda_1}{\lambda_n}} + 1}$$

# Чебышёвский итерационный метод

- ▶ Обозначим  $\sigma(x) = x + \sqrt{x^2 - 1}$ , тогда  $T_k(x) = \frac{1}{2}(\sigma(x)^k + \sigma(x)^{-k})$
- ▶ Применяя теорему при  $M = 1$ ,  $[a, b] = [\lambda_n, \lambda_1]$  и учитывая, что  $|T_k(x)| \leq 1$  при  $x \in [-1, 1]$ , получим:

$$\rho_k(\lambda) \leq \frac{1}{T_k\left(\frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n}\right)} = \frac{2\sigma\left(\frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n}\right)^k}{1 + \sigma\left(\frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n}\right)^{2k}} \leq 2\sigma\left(\frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n}\right)^k,$$

где

$$\sigma \equiv \sigma\left(\frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n}\right) = \frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n} + \sqrt{\left(\frac{\lambda_1 + \lambda_n}{\lambda_1 - \lambda_n}\right)^2 - 1} = \frac{\sqrt{\frac{\lambda_1}{\lambda_n} - 1}}{\sqrt{\frac{\lambda_1}{\lambda_n} + 1}}$$

- ▶ Итог:  $\|e_k\| \leq \frac{\text{cond} - 1}{\text{cond} + 1} \|e_{k-1}\| \leq \left(\frac{\text{cond} - 1}{\text{cond} + 1}\right)^k \|e_0\|$
- $$\|e_k\|_2 \leq 2 \left( \frac{\sqrt{\text{cond}_2(\mathbf{A})} - 1}{\sqrt{\text{cond}_2(\mathbf{A})} + 1} \right)^k \|e_0\|_2, \quad \uparrow \text{было}$$

где  $1/\tau_k$  – корни  $\rho_k(\lambda)$ .

# Литература

- ▶ Saad Y., Iterative methods for sparse linear systems. SIAM, 2003.
- ▶ Лебедев В.И. Функциональный анализ и вычислительная математика, Физматлит, 2005.
- ▶ Тыртышников Е. Е. Методы численного анализа. – Академия, 2007. – 320 с.