



**МГТУ имени Н.Э. Баумана**

Кафедра ИУ-1 «Системы автоматического управления»

# Методы вычислений

Численные методы матричных операций



*Андрей Леонидович Масленников*  
[amas@bmstu.ru](mailto:amas@bmstu.ru)

2023 г.

Вектор:  $\mathbf{v} = [v_1, v_2, \dots, v_n]^T$

Матрица:  $\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1m} \\ a_{21} & a_{22} & \cdots & a_{2m} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nm} \end{bmatrix}$

Квадратная матрица:

$\mathbf{A} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ a_{21} & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}$

Верхняя и нижняя треугольная матрицы:

$\mathbf{L} = \begin{bmatrix} a_{11} & 0 & \cdots & 0 \\ a_{21} & a_{21} & \cdots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ a_{n1} & a_{n2} & \cdots & a_{nn} \end{bmatrix}, \mathbf{U} = \begin{bmatrix} a_{11} & a_{12} & \cdots & a_{1n} \\ 0 & a_{22} & \cdots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \cdots & a_{nn} \end{bmatrix}$

Обратная матрица:  $\mathbf{A}\mathbf{A}^{-1} = \mathbf{A}^{-1}\mathbf{A} = \mathbf{I}$

**Невырожденная (неособенная, обратимая) матрица** — это матрица, для которой существует обратная матрица.

**Критерии невырожденности:**

1. строки и столбцы — линейно независимы;
2. ранг матрицы равен ее размерности;
3. определитель матрицы не равен нулю.

Транспонированная матрица:  $\mathbf{A}^T = \mathbf{A}_{ji}$

Симметричная матрица:  $\mathbf{A}^T = \mathbf{A}$

Кососимметричная матрица:  $\mathbf{A}^T = -\mathbf{A}$

Сопряженно-транспонированная матрица:

$$\mathbf{U}^* = \overline{\mathbf{U}}^T$$

Эрмитова матрица:  $\mathbf{A}^* = \overline{\mathbf{A}}^T = \mathbf{A}$

Пример:

$$\mathbf{A} = \begin{bmatrix} 5 & 2+j \\ 2-j & 7 \end{bmatrix}$$

$$\overline{\mathbf{A}} = \begin{bmatrix} 5 & 2-j \\ 2+j & 7 \end{bmatrix}$$

$$\overline{\mathbf{A}}^T = \begin{bmatrix} 5 & 2+j \\ 2-j & 7 \end{bmatrix}$$

Унитарная матрица:  $\mathbf{U}\mathbf{U}^* = \mathbf{U}^*\mathbf{U} = \mathbf{I}$

Ортогональная матрица:  $\mathbf{A}\mathbf{A}^T = \mathbf{A}^T\mathbf{A} = \mathbf{I}$

$$\mathbf{A}^T = \mathbf{A}^{-1}$$

*Унитарная матрица содержит комплексные числа, а ортогональная — нет*

Нормальная матрица:  $\mathbf{U}\mathbf{U}^* = \mathbf{U}^*\mathbf{U}$

$$\mathbf{A}\mathbf{A}^T = \mathbf{A}^T\mathbf{A}$$

**Свойства нормальной матрицы:**

1. диагонализуема через унитарные матрицы, т.е. представима в виде:

$$\mathbf{A} = \mathbf{U}\mathbf{D}\mathbf{V}$$

2. нормальная матрица с действительными собственными значениями — эрмитова матрица.

**Разреженная матрица** — это матрица, которая преимущественно состоит из нулевых значений (сколько точно — зависит от задачи)

**Минор** — это определитель квадратной матрицы, составленной из элементов этой матрицы с номерами строк и столбцов от 1 до  $k$  включительно

Пример:

$$M = \det \begin{bmatrix} 1 & 2 & 3 \\ 4 & 1 & 6 \\ 7 & 8 & 1 \end{bmatrix} = 104$$

**Главный минор** — это минор матрицы  $A$  для которого совпадают выбранные номера строк и столбцов

**Угловой минор** — это минор матрицы  $A$  состоящий из первых  $k$  столбцов матрицы  $A$ .

**Базисный минор** — это ненулевой минор матрицы  $A$  максимального порядка

**Ранг матрица** — скалярное значение соответствующее порядку базисного минора

**Линейная независимость** — свойство системы векторов при котором уравнение

$$\alpha_1 \mathbf{v}_1 + \alpha_2 \mathbf{v}_2 + \dots + \alpha_n \mathbf{v}_n = \mathbf{0}$$

имеет тривиальное решение только при

$$\alpha_1 = \alpha_2 = \dots = \alpha_n = 0$$

**Дополнительный минор** — это определитель матрицы  $\mathbf{A}$ , составленный из элементов матрицы  $\mathbf{A}$  путем удаления  $i$  и  $j$  строк

Пример:

$$M_{23} = \det \begin{bmatrix} 1 & 2 & \times \\ \times & \times & \times \\ 7 & 8 & \times \end{bmatrix} = \det \begin{bmatrix} 1 & 2 \\ 7 & 8 \end{bmatrix} = 8 - 14 = -6$$

**Алгебраическое дополнение** — это скалярное значение определяемое следующим образом:

$$A_{ij} = (-1)^{i+j} M_{ij}$$

Присоединенная матрица:

$$\text{adj}\mathbf{C} = \begin{bmatrix} A_{11} & A_{21} & \cdots & A_{n1} \\ A_{12} & A_{22} & \cdots & A_{n2} \\ \vdots & \vdots & \ddots & \vdots \\ A_{1n} & A_{2n} & \cdots & A_{nn} \end{bmatrix}$$

Используется при вычислении обратной матрица:

$$\mathbf{A}^{-1} = \frac{1}{\det \mathbf{A}} \text{adj}\mathbf{C}$$

**Матричная экспонента:**

$$e^{\mathbf{A}} = \sum_{k=0}^{\infty} \frac{1}{k!} \mathbf{A}^k$$

**Свойства матричной экспоненты:**

1.  $e^{\mathbf{0}} = \mathbf{I}$

2.  $e^{\mathbf{A}^T} = (e^{\mathbf{A}})^T$

3.  $e^{\mathbf{YXY}^{-1}} = \mathbf{Y}e^{\mathbf{X}}\mathbf{Y}^{-1}$

**Квадратный корень из матрицы** — это матрица, произведение которой на саму себя дает исходную, т.е.:  $\mathbf{B}\mathbf{B} = \mathbf{A}$

**Методы получения:**

1. через матричное разложение:

$$\sqrt{\mathbf{A}} = \mathbf{V}\sqrt{\mathbf{D}}\mathbf{V}^{-1}$$

2. метод Денмана—Биверса;

3. Вавилонский метод.

**Метод Денмана—Биверса:**

$$\mathbf{Y}_0 = \mathbf{A}$$

$$\mathbf{Z}_0 = \mathbf{I}$$

$$\mathbf{B}_0 = \mathbf{Z}_{k-1}^{-1}$$

$$\mathbf{Y}_{k+1} = 0.5(\mathbf{Y}_k + \mathbf{Z}_k^{-1})$$

$$\mathbf{Z}_{k+1} = 0.5(\mathbf{Z}_k + \mathbf{Y}_k^{-1})$$

$$\mathbf{B}_{k+1} = 2\mathbf{B}_{k-1} - \mathbf{B}_k \mathbf{Z}_k \mathbf{B}_k$$

**Вавилонский метод:**

$$\mathbf{B}_0 = \mathbf{I}$$

$$\mathbf{B}_{k+1} = 0.5(\mathbf{B}_k + \mathbf{A}\mathbf{B}_{k-1}^{-1})$$

**В Вавилонском методе обратная матрица вычисляется только один раз на каждом шаге, но устойчивость и сходимость хуже, чем у метода Денмана—Биверса**

Собственный вектор  $\mathbf{v}$  и соответствующее ему значение  $\lambda$  удовлетворяют следующему матричному уравнению

$$\mathbf{A}\mathbf{v} = \lambda\mathbf{v}$$

Сингулярные значения  $\sigma$  удовлетворяет следующему матричному уравнению, где вектора  $\mathbf{u}$  и  $\mathbf{v}$  единичной длины

$$\mathbf{A}\mathbf{v} = \sigma\mathbf{u}$$

**Вычисление собственных значений:**

Через решение матричного уравнения:

$$(\mathbf{A} - \lambda\mathbf{I})\mathbf{v} = \mathbf{0}$$

*Аналитические решения есть только для небольших матриц, а численные подходы не универсальны*

Через спектральное разложение:

$$\mathbf{A} = \mathbf{V}\mathbf{\Lambda}\mathbf{U}^*$$

*Нет универсального численного метода. Можно использовать другие виды разложений*

**Положительно определенная матрица** — это эрмитова матрица, которая удовлетворяет любому из следующих условий

**Условия положительной определенности:**

1.  $\mathbf{z}^* \mathbf{A} \mathbf{z} > 0$
2.  $\lambda_i(\mathbf{A}) > 0$
3. Определители всех угловых миноров положительны — Критерий Сильвестра

*Существуют и другие критерии*

**Положительно полуопределенная** — это эрмитова матрица, которая удовлетворяет тем же условиям, но со знаком « $\geq$ »

**Отрицательно определенная** — это эрмитова матрица, которая удовлетворяет тем же условиям, но со знаком « $<$ »

**Отрицательно полуопределенная** — это эрмитова матрица, которая удовлетворяет тем же условиям, но со знаком « $\leq$ »

**Обозначения:**

1. Положительно определенная:  $\mathbf{A} > 0$
2. Положительно полуопределенная:  $\mathbf{A} \geq 0$
3. Отрицательно определенная:  $\mathbf{A} < 0$
4. Отрицательно полуопределенная:  $\mathbf{A} \leq 0$



**Норма матрица** — это скалярное значение, характеризующее меру объема матрицы (насколько большое в ней значения)

### Операторная норма:

1. Максимальная сумма значений в столбцах:

$$\|\mathbf{A}\|_1 = \max_{1 \leq j \leq m} \sum_{i=1}^n |a_{ij}|$$

2. Максимальная сумма значений в строках:

$$\|\mathbf{A}\|_\infty = \max_{1 \leq i \leq n} \sum_{j=1}^m |a_{ij}|$$

3. Спектральная норма:

$$\|\mathbf{A}\|_2 = \sqrt{\lambda_{\max}(\mathbf{A}^* \mathbf{A})}$$

### Свойства норм:

1.  $\|\mathbf{A}\| > 0$ , для  $\mathbf{A} \neq \mathbf{0}$
2.  $\|\mathbf{A} + \mathbf{B}\| < \|\mathbf{A}\| + \|\mathbf{B}\|$
4.  $\|\alpha \mathbf{A}\| = |\alpha| \|\mathbf{A}\|$

### Векторная $p$ -норма:

$$\|\mathbf{A}\|_p = \|\text{vec}(\mathbf{A})\|_p = \left( \sum_{i=1}^n \sum_{j=1}^m |a_{ij}|^p \right)^{1/p}$$

### Норма Шаттена:

$$\|\mathbf{A}\|_p = \left( \sum_{i=1}^{\min(n,m)} \sigma_i^p(\mathbf{A}) \right)^{1/p}$$

### Индукцированная норма:

$$\|\mathbf{A}\|_p = \sup_{\mathbf{x} \neq \mathbf{0}} \frac{\|\mathbf{A}\mathbf{x}\|_p}{\|\mathbf{x}\|_p}$$

### Норма $L_{p,q}$ :

$$\|\mathbf{A}\|_{p,q} = \left( \sum_{i=1}^n \left( \sum_{j=1}^m |a_{ij}|^p \right)^{q/p} \right)^{1/p}$$

### Норма Фробениуса:

$$\|\mathbf{A}\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^m |a_{ij}|^2}$$