

Матрицы. Матричные нормы. ~~Матричное~~
~~умножение~~. Унитарные матрицы

Даня Меркулов

МФТИ. AI360

Базовые понятия линейной алгебры

Векторы и матрицы

Мы будем считать, что все векторы являются столбцами по умолчанию. Пространство векторов длины n обозначается $\mathbb{R}^n$, а пространство вещественных $m \times n$ матриц обозначается $\mathbb{R}^{m \times n}$.¹

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad x^T = [x_1 \quad x_2 \quad \dots \quad x_n] \quad x \in \mathbb{R}^n, x_i \in \mathbb{R} \quad (1)$$

¹Подробный вводный курс по прикладной линейной алгебре можно найти в книге Introduction to Applied Linear Algebra -- Vectors, Matrices, and Least Squares - книга Стивена Бойда и Ливена Ванденбергена, которая указана в источнике. Также полезной книгой по линейной алгебре является приложение А в книге Numerical Optimization Джорджа Носедаля и Стивена Райта.

Векторы и матрицы

Мы будем считать, что все векторы являются столбцами по умолчанию. Пространство векторов длины n обозначается $\mathbb{R}^n$, а пространство вещественных $m \times n$ матриц обозначается $\mathbb{R}^{m \times n}$.¹

$$x = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \quad x^T = [x_1 \quad x_2 \quad \dots \quad x_n] \quad x \in \mathbb{R}^n, x_i \in \mathbb{R} \quad (1)$$

Аналогично, если $A \in \mathbb{R}^{m \times n}$ мы обозначаем транспонирование как $A^T \in \mathbb{R}^{n \times m}$:

$$A = \begin{bmatrix} a_{11} & a_{12} & \dots & a_{1n} \\ a_{21} & a_{22} & \dots & a_{2n} \\ \vdots & \vdots & \ddots & \vdots \\ a_{m1} & a_{m2} & \dots & a_{mn} \end{bmatrix} \quad A^T = \begin{bmatrix} a_{11} & a_{21} & \dots & a_{m1} \\ a_{12} & a_{22} & \dots & a_{m2} \\ \vdots & \vdots & \ddots & \vdots \\ a_{1n} & a_{2n} & \dots & a_{mn} \end{bmatrix} \quad A \in \mathbb{R}^{m \times n}, a_{ij} \in \mathbb{R}$$

Мы будем писать $x \geq 0$ и $x \neq 0$ для обозначения покомпонентного неравенства.

¹Подробный вводный курс по прикладной линейной алгебре можно найти в книге Introduction to Applied Linear Algebra -- Vectors, Matrices, and Least Squares - книга Стивена Бойда и Ливена Ванденбергена, которая указана в источнике. Также полезной книгой по линейной алгебре является приложение А в книге Numerical Optimization Джорджа Носедаля и Стивена Райта.




Рис. 1: Эквивалентные представления вектора

Матрица A называется симметричной, если $A = A^T$. Обозначается как $A \in \mathbb{S}^n$ (множество квадратных симметричных матриц размерности n). Заметим, что только квадратная матрица может быть симметричной по определению.

Матрица A называется симметричной, если $A = A^T$. Обозначается как $A \in \mathbb{S}^n$ (множество квадратных симметричных матриц размерности n). Заметим, что только квадратная матрица может быть симметричной по определению.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) определенной**, если для всех $x \neq 0 : x^T A x > (<) 0$. Обозначается как $A \succ (<) 0$. Множество таких матриц обозначается как $\mathbb{S}_{++}^n (\mathbb{S}_{--}^n)$.

Матрица A называется симметричной, если $A = A^T$. Обозначается как $A \in \mathbb{S}^n$ (множество квадратных симметричных матриц размерности n). Заметим, что только квадратная матрица может быть симметричной по определению.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) определенной**, если для всех $x \neq 0 : x^T A x > (<) 0$. Обозначается как $A \succ (<) 0$. Множество таких матриц обозначается как $\mathbb{S}_{++}^n (\mathbb{S}_{--}^n)$.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) полуопределенной**, если для всех $x : x^T A x \geq (\leq) 0$. Обозначается как $A \succeq (\preceq) 0$. Множество таких матриц обозначается как $\mathbb{S}_+^n (\mathbb{S}_-^n)$.

i Question

Верно ли, что положительно ^{полож}определенная матрица имеет все положительные элементы?

контрпример

$$x_1^2 - 2x_1x_2 + x_2^2 = (x_1 - x_2)^2 \geq 0$$
$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}^T \begin{pmatrix} 1 & -1 \\ -1 & 1 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} \geq 0$$

Матрица A называется симметричной, если $A = A^T$. Обозначается как $A \in \mathbb{S}^n$ (множество квадратных симметричных матриц размерности n). Заметим, что только квадратная матрица может быть симметричной по определению.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) определенной**, если для всех $x \neq 0 : x^T A x > (<) 0$. Обозначается как $A \succ (<) 0$. Множество таких матриц обозначается как $\mathbb{S}_{++}^n (\mathbb{S}_{--}^n)$.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) полуопределенной**, если для всех $x : x^T A x \geq (\leq) 0$. Обозначается как $A \succeq (\preceq) 0$. Множество таких матриц обозначается как $\mathbb{S}_{+}^n (\mathbb{S}_{-}^n)$.

Question

Верно ли, что положительно определенная матрица имеет все положительные элементы?

Question

Верно ли, что если матрица симметрична, то она положительно определена?

контрпример

$$\begin{pmatrix} -1 & 0 \\ 0 & -1 \end{pmatrix} \Rightarrow -x_1^2 - x_2^2 < 0$$

Матрица A называется симметричной, если $A = A^T$. Обозначается как $A \in \mathbb{S}^n$ (множество квадратных симметричных матриц размерности n). Заметим, что только квадратная матрица может быть симметричной по определению.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) определенной**, если для всех $x \neq 0 : x^T A x > (<) 0$. Обозначается как $A \succ (<) 0$. Множество таких матриц обозначается как $\mathbb{S}_{++}^n (\mathbb{S}_{--}^n)$.

Матрица $A \in \mathbb{S}^n$ называется **положительно (отрицательно) полуопределенной**, если для всех $x : x^T A x \geq (\leq) 0$. Обозначается как $A \succeq (\preceq) 0$. Множество таких матриц обозначается как $\mathbb{S}_+^n (\mathbb{S}_-^n)$.

i Question

Верно ли, что положительно определенная матрица имеет все положительные элементы?

i Question

Верно ли, что если матрица симметрична, то она положительно определена?

i Question

Верно ли, что если матрица положительно определена, то она симметрична?

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}^T \begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}^T \begin{pmatrix} x_2 \\ -x_1 \end{pmatrix} = x_1^T x_2 - x_2^T x_1$$



$$\forall x \in \mathbb{R}^n : x^T A x \geq 0$$

$$\begin{pmatrix} x_1 \\ x_2 \end{pmatrix}^T \begin{pmatrix} 0 & 1 \\ -1 & 0 \end{pmatrix} \begin{pmatrix} x_1 \\ x_2 \end{pmatrix} = 0$$

Умножение матриц

Пусть A - матрица размера $m \times n$, и B - матрица размера $n \times p$, и пусть произведение AB задается как:

$$C = AB$$

тогда C - матрица размера $m \times p$, с элементом (i, j) задаваемым как:

$$c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}.$$

Эта операция в наивной реализации требует $\mathcal{O}(n^3)$ арифметических операций, где n - наибольший размер матриц.

$$A = A^T - \text{симметричная}$$

$$A = A^* - \text{эрмитова}$$

Умножение матриц

Пусть A - матрица размера $m \times n$, и B - матрица размера $n \times p$, и пусть произведение AB задается как:

$$C = AB$$

тогда C - матрица размера $m \times p$, с элементом (i, j) задаваемым как:

$$c_{ij} = \sum_{k=1}^n a_{ik} b_{kj}.$$

Эта операция в наивной реализации требует $\mathcal{O}(n^3)$ арифметических операций, где n - наибольший размер матриц.

Question

Можно ли умножить две матрицы быстрее, чем за $\mathcal{O}(n^3)$? Как насчет $\mathcal{O}(n^2)$, $\mathcal{O}(n)$?

Умножение матрицы на вектор

Пусть A - матрица размера $m \times n$, и x - вектор длины n , тогда i -й компонент произведения:

$$z = Ax$$

определяется как:

$$z_i = \sum_{k=1}^n a_{ik} x_k$$

Эта операция в наивной реализации требует $\mathcal{O}(n^2)$ арифметических операций, где n - наибольший размер матриц.

Заметим, что:

- $C = AB \quad C^T = B^T A^T$

Умножение матрицы на вектор

Пусть A - матрица размера $m \times n$, и x - вектор длины n , тогда i -й компонент произведения:

$$z = Ax$$

определяется как:

$$z_i = \sum_{k=1}^n a_{ik} x_k$$

Эта операция в наивной реализации требует $\mathcal{O}(n^2)$ арифметических операций, где n - наибольший размер матриц.

Заметим, что:

- $C = AB \quad C^T = B^T A^T$
- $AB \neq BA$

Умножение матрицы на вектор

Пусть A - матрица размера $m \times n$, и x - вектор длины n , тогда i -й компонент произведения:

$$z = Ax$$

определяется как:

$$z_i = \sum_{k=1}^n a_{ik} x_k$$

Эта операция в наивной реализации требует $\mathcal{O}(n^2)$ арифметических операций, где n - наибольший размер матриц.

Заметим, что:

- $C = AB \quad C^T = B^T A^T$
- $AB \neq BA$
- $e^A = \sum_{k=0}^{\infty} \frac{1}{k!} A^k$

Умножение матрицы на вектор

Пусть A - матрица размера $m \times n$, и x - вектор длины n , тогда i -й компонент произведения:

$$z = Ax$$

определяется как:

$$z_i = \sum_{k=1}^n a_{ik} x_k$$

Эта операция в наивной реализации требует $\mathcal{O}(n^2)$ арифметических операций, где n - наибольший размер матриц.

Заметим, что:

- $C = AB \quad C^T = B^T A^T$
- $AB \neq BA$
- $e^A = \sum_{k=0}^{\infty} \frac{1}{k!} A^k$
- $e^{A+B} \neq e^A e^B$ (но если A и B - коммутирующие матрицы, то есть $AB = BA$, то $e^{A+B} = e^A e^B$)

Умножение матрицы на вектор

Пусть A - матрица размера $m \times n$, и x - вектор длины n , тогда i -й компонент произведения:

$$z = Ax$$

определяется как:

$$z_i = \sum_{k=1}^n a_{ik} x_k$$

Эта операция в наивной реализации требует $\mathcal{O}(n^2)$ арифметических операций, где n - наибольший размер матриц.

Заметим, что:

- $C = AB \quad C^T = B^T A^T$
- $AB \neq BA$
- $e^A = \sum_{k=0}^{\infty} \frac{1}{k!} A^k$
- $e^{A+B} \neq e^A e^B$ (но если A и B - коммутирующие матрицы, то есть $AB = BA$, то $e^{A+B} = e^A e^B$)
- $\langle x, Ay \rangle = \langle A^T x, y \rangle$

Нормы

Норма - это **количественная мера малenessи вектора** и обычно обозначается как $\|x\|$.

Норма должна удовлетворять определенным свойствам:

1. $\|\alpha x\| = |\alpha| \|x\|, \alpha \in \mathbb{R}$

Нормы

Норма - это **количественная мера малenessи вектора** и обычно обозначается как $\|x\|$.

Норма должна удовлетворять определенным свойствам:

1. $\|\alpha x\| = |\alpha| \|x\|, \alpha \in \mathbb{R}$
2. $\|x + y\| \leq \|x\| + \|y\|$ (неравенство треугольника)

Нормы

Норма - это **количественная мера малenessи вектора** и обычно обозначается как $\|x\|$.

Норма должна удовлетворять определенным свойствам:

1. $\|\alpha x\| = |\alpha| \|x\|, \alpha \in \mathbb{R}$
2. $\|x + y\| \leq \|x\| + \|y\|$ (неравенство треугольника)
3. Если $\|x\| = 0$ то $x = 0$

Нормы

Норма - это **количественная мера малenessи вектора** и обычно обозначается как $\|x\|$.

Норма должна удовлетворять определенным свойствам:

1. $\|\alpha x\| = |\alpha| \|x\|, \alpha \in \mathbb{R}$
2. $\|x + y\| \leq \|x\| + \|y\|$ (неравенство треугольника)
3. Если $\|x\| = 0$ то $x = 0$

Нормы

Норма - это **количественная мера малenessи вектора** и обычно обозначается как $\|x\|$.

Норма должна удовлетворять определенным свойствам:

1. $\|\alpha x\| = |\alpha| \|x\|$, $\alpha \in \mathbb{R}$
2. $\|x + y\| \leq \|x\| + \|y\|$ (неравенство треугольника)
3. Если $\|x\| = 0$ то $x = 0$

Расстояние между двумя векторами определяется как:

$$d(x, y) = \|x - y\|.$$

Наиболее широко используемой нормой является **евклидова норма**:

$$\|x\|_2 = \sqrt{\sum_{i=1}^n |x_i|^2},$$

которая соответствует расстоянию в нашей повседневной жизни. Если векторы имеют комплексные элементы, мы используем их модуль. Евклидова норма, или 2-норма, является подклассом важного класса p -норм:

$$\|x\|_p = \left(\sum_{i=1}^n |x_i|^p \right)^{1/p}.$$

p -норма вектора

Существуют два очень важных частных случая. Бесконечность норма, или норма Чебышёва, определяется как максимальный абсолютный элемент:

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

p -норма вектора

Существуют два очень важных частных случая. Бесконечность норма, или норма Чебышёва, определяется как максимальный абсолютный элемент:

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

L_1 норма (или **манхэттенское расстояние**) определяется как сумма модулей элементов вектора:

$$\|x\|_1 = \sum_i |x_i|$$

p -норма вектора

Существуют два очень важных частных случая. Бесконечность норма, или норма Чебышёва, определяется как максимальный абсолютный элемент:

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

L_1 норма (или **манхэттенское расстояние**) определяется как сумма модулей элементов вектора:

$$\|x\|_1 = \sum_i |x_i|$$

L_1 норма играет очень важную роль: она связана с методами **compressed sensing**, которые стали одной из популярных тем исследований в середине 00-х. Код для изображения ниже доступен *здесь*. Также можно посмотреть *этот* видео.




Рис. 2: Шары в разных нормах на плоскости

Матричные нормы

Матричные нормы

$\|\cdot\|$ называется **матричной нормой**, если она является векторной нормой на векторном пространстве $n \times m$ матриц:

1. $\|A\| \geq 0$ и если $\|A\| = 0$, то $A = O$

Матричные нормы

$\|\cdot\|$ называется **матричной нормой**, если она является векторной нормой на векторном пространстве $n \times m$ матриц:

1. $\|A\| \geq 0$ и если $\|A\| = 0$, то $A = O$
2. $\|\alpha A\| = |\alpha| \|A\|$

Матричные нормы

$\|\cdot\|$ называется **матричной нормой**, если она является векторной нормой на векторном пространстве $n \times m$ матриц:

1. $\|A\| \geq 0$ и если $\|A\| = 0$, то $A = O$
2. $\|\alpha A\| = |\alpha| \|A\|$
3. $\|A + B\| \leq \|A\| + \|B\|$ (неравенство треугольника)

Матричные нормы

$\|\cdot\|$ называется **матричной нормой**, если она является векторной нормой на векторном пространстве $n \times m$ матриц:

1. $\|A\| \geq 0$ и если $\|A\| = 0$, то $A = O$
 2. $\|\alpha A\| = |\alpha| \|A\|$
 3. $\|A + B\| \leq \|A\| + \|B\|$ (неравенство треугольника)
- Дополнительно, **некоторые нормы** могут удовлетворять **свойству субмультипликативности**:

$$\|AB\| \leq \|A\| \|B\|$$

Эти нормы называются **субмультипликативными нормами**.

Матричные нормы

$$\|A\|_c = 1$$

$$\|B\|_c = 1$$

$\|\cdot\|$ называется **матричной нормой**, если она является векторной нормой на векторном пространстве $n \times m$ матриц:

1. $\|A\| \geq 0$ и если $\|A\| = 0$, то $A = O$
2. $\|\alpha A\| = |\alpha| \|A\|$
3. $\|A + B\| \leq \|A\| + \|B\|$ (неравенство треугольника)

- Дополнительно, некоторые нормы могут удовлетворять **свойству субмультипликативности**:

$$\|AB\| \leq \|A\| \|B\|$$

Эти нормы называются **субмультипликативными нормами**.

- Пример несубмультипликативной нормы - норма Чебышёва:

$$\|A\|_C = \max_{i,j} |a_{ij}|$$

$$\begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix} = \begin{pmatrix} 1 & 1 \\ 1 & 1 \end{pmatrix}$$

$$= \begin{pmatrix} 2 & 2 \\ 2 & 2 \end{pmatrix}$$

$$\|AB\|_c = 2$$

Пример

i Придумайте контрпример

Покажите, что норма Чебышёва не является субмультипликативной.

Пример

i Придумайте контрпример

Покажите, что норма Чебышёва не является субмультипликативной.

Рассмотрим матрицы

$$A = B = \begin{bmatrix} 1 & 1 \\ 1 & 1 \end{bmatrix}.$$

Для каждой из них

$$\|A\|_C = \|B\|_C = 1.$$

Вычислим произведение:

$$AB = \begin{bmatrix} 1 \cdot 1 + 1 \cdot 1 & 1 \cdot 1 + 1 \cdot 1 \\ 1 \cdot 1 + 1 \cdot 1 & 1 \cdot 1 + 1 \cdot 1 \end{bmatrix} = \begin{bmatrix} 2 & 2 \\ 2 & 2 \end{bmatrix}.$$

Если норма была бы субмультипликативной, то должно выполняться

$$2 = \|AB\|_C \leq \|A\|_C \cdot \|B\|_C = 1 \cdot 1 = 1,$$

но $2 > 1$.

Нормы матриц

В некотором смысле нет большой разницы между матрицами и векторами (можно векторизовать матрицу), таким образом вводится простейшая норма матрицы **Фробениуса**:

$$\|A\|_F = \left(\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2 \right)^{1/2}$$

Нормы матриц

В некотором смысле нет большой разницы между матрицами и векторами (можно векторизовать матрицу), таким образом вводится простейшая норма матрицы **Фробениуса**:

$$\|A\|_F = \left(\sum_{i=1}^m \sum_{j=1}^n |a_{ij}|^2 \right)^{1/2}$$

Спектральная норма, $\|A\|_2$ является одной из наиболее широко используемых норм матриц (вместе с нормой Фробениуса).


$$\|A\|_2 = \sup_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2},$$

Её нельзя вычислить непосредственно из элементов, используя простую формулу, как норму Фробениуса, однако существуют эффективные алгоритмы для ее вычисления. Она непосредственно связана с **сингулярным разложением** (SVD) матрицы. Она удовлетворяет следующему свойству:

$$\|A\|_2 = \sigma_1(A) = \sqrt{\lambda_{\max}(A^T A)}$$

где $\sigma_1(A)$ является наибольшим сингулярным значением матрицы A .

Операторные нормы



- Наиболее важный класс матричных норм - это класс **операторных норм**. Они определяются как

$$\|A\|_{\alpha \rightarrow \beta} = \sup_{x \neq 0} \frac{\|Ax\|_{\alpha}}{\|x\|_{\beta}},$$

где $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ являются **векторными нормами**.

СПЕКТРАЛЬНАЯ
НОРМА

$$\|A\|_2 = \sup_{x \neq 0} \frac{\|Ax\|_2}{\|x\|_2}$$

$$\|A\|_1 \rightarrow 2$$

$$\|A\|_1 \rightarrow \infty$$

Операторные нормы

- Наиболее важный класс матричных норм - это класс **операторных норм**. Они определяются как

$$\|A\|_{\alpha \rightarrow \beta} = \sup_{x \neq 0} \frac{\|Ax\|_{\alpha}}{\|x\|_{\beta}},$$

где $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ являются **векторными нормами**.

- Легко проверить, что они субмультипликативны, если $\|\cdot\|_{\alpha} = \|\cdot\|_{\beta}$. Иначе они не субмультипликативны, придумайте пример.

Докажем, что $\|Ax\|_p$ — субмультипликативна
 $\|A\|_p = \sup_{x \neq 0} \frac{\|Ax\|_p}{\|x\|_p}$

$$\forall A, B \in \mathbb{R}^{n \times n} : \|AB\|_p \leq \|A\|_p \cdot \|B\|_p$$

Операторные нормы

Докажем, что $\|Ax\|_p$
 $\|A\|_p = \sup_{x \neq 0} \frac{\|Ax\|_p}{\|x\|_p}$

$$\forall A, B \in \mathbb{R}^{m \times n}: \|AB\|_p \leq \|A\|_p \cdot \|B\|_p$$

- Наиболее важный класс матричных норм - это класс **операторных норм**. Они определяются как

$$\|A\|_{\alpha \rightarrow \beta} = \sup_{x \neq 0} \frac{\|Ax\|_{\alpha}}{\|x\|_{\beta}}$$

где $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ являются **векторными нормами**.

- Легко проверить, что они субмультипликативны, если $\|\cdot\|_{\alpha} = \|\cdot\|_{\beta}$. Иначе они не субмультипликативны, придумайте пример.

$$\|AB\|_p = \sup_{x \neq 0} \frac{\|ABx\|_p}{\|x\|_p} \leq \sup_{x \neq 0} \frac{\|Ax\|_p}{\|x\|_p} \cdot \sup_{x \neq 0} \frac{\|Bx\|_p}{\|x\|_p}$$

$$\|ABx\|_p \leq \|A\|_p \cdot \|Bx\|_p$$

$$\|Bx\|_p \leq \|B\|_p \cdot \|x\|_p$$

$$\| \underbrace{ABx}_t \|_p$$

$$\|A\|_p = \sup_{t \neq 0} \frac{\|At\|_p}{\|t\|_p}$$

$$\forall t \neq 0: \frac{\|At\|_p}{\|t\|_p} \leq \|A\|_p$$

$$\|At\|_p \leq \|A\|_p \|t\|_p$$

Операторные нормы

- Наиболее важный класс матричных норм - это класс **операторных норм**. Они определяются как

$$\|A\|_{\alpha \rightarrow \beta} = \sup_{x \neq 0} \frac{\|Ax\|_{\alpha}}{\|x\|_{\beta}},$$

где $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ являются **векторными нормами**.

- Легко проверить, что они субмультипликативны, если $\|\cdot\|_{\alpha} = \|\cdot\|_{\beta}$. Иначе они не субмультипликативны, придумайте пример.
- Норма Фробениуса является матричной нормой, но не является операторной нормой, т.е. нельзя найти $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ такие, чтобы они её порождали.

Операторные нормы

- Наиболее важный класс матричных норм - это класс **операторных норм**. Они определяются как

$$\|A\|_{\alpha \rightarrow \beta} = \sup_{x \neq 0} \frac{\|Ax\|_{\alpha}}{\|x\|_{\beta}},$$

где $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ являются **векторными нормами**.

- Легко проверить, что они субмультипликативны, если $\|\cdot\|_{\alpha} = \|\cdot\|_{\beta}$. Иначе они не субмультипликативны, придумайте пример.
- **Норма Фробениуса** является матричной нормой, но не является операторной нормой, т.е. нельзя найти $\|\cdot\|_{\alpha}$ и $\|\cdot\|_{\beta}$ такие, чтобы они её порождали.
- Это нетривиальный факт и общий критерий матричной нормы для того, чтобы быть операторной нормой можно найти в Теореме 6 и следствии 4.

Пример

Question

Покажите, что операторная норма $\| \cdot \|_{\alpha \rightarrow \alpha}$ является субмультипликативной.

Пример

i Question

Покажите, что операторная норма $\|\cdot\|_{\alpha \rightarrow \alpha}$ является субмультипликативной.

Определим операторную норму для матрицы A как

$$\|A\|_{\alpha \rightarrow \alpha} = \sup_{x \neq 0} \frac{\|Ax\|_{\alpha}}{\|x\|_{\alpha}}.$$

Для двух матриц A и B рассмотрим для любого $x \neq 0$:

$$\|ABx\|_{\alpha} \leq \|A\|_{\alpha \rightarrow \alpha} \|Bx\|_{\alpha} \leq \|A\|_{\alpha \rightarrow \alpha} \|B\|_{\alpha \rightarrow \alpha} \|x\|_{\alpha}.$$

Делим на $\|x\|_{\alpha}$ и берем супремум по $x \neq 0$:

$$\|AB\|_{\alpha \rightarrow \alpha} \leq \|A\|_{\alpha \rightarrow \alpha} \|B\|_{\alpha \rightarrow \alpha}.$$

Таким образом, операторная норма с одинаковыми векторными нормами является субмультипликативной.

Матричные p -нормы

Важный частный случай операторных норм - это матричные p -нормы, которые определяются для $\|\cdot\|_\alpha = \|\cdot\|_\beta = \|\cdot\|_p$.

Среди всех p -норм три наиболее часто используемые нормы:

- $p = 1, \quad \|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|.$

Матричные p -нормы

Важный частный случай операторных норм - это матричные p -нормы, которые определяются для $\|\cdot\|_\alpha = \|\cdot\|_\beta = \|\cdot\|_p$.

Среди всех p -норм три наиболее часто используемые нормы:

- $p = 1$, $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$.
- $p = 2$, спектральная норма, обозначаемая как $\|A\|_2$.

Матричные p -нормы

Важный частный случай операторных норм - это матричные p -нормы, которые определяются для $\|\cdot\|_\alpha = \|\cdot\|_\beta = \|\cdot\|_p$.


Среди всех p -норм три наиболее часто используемые нормы:

- $p = 1$, $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$.
- $p = 2$, спектральная норма, обозначаемая как $\|A\|_2$.
- $p = \infty$, $\|A\|_\infty = \max_i \sum_{j=1}^m |a_{ij}|$.

Пример

Покажите, что $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$.

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



$$\text{оп } \|A\|_1 = \sup_{X \neq 0} \frac{\|AX\|_1}{\|X\|_1} = \sup_{X \neq 0} \frac{\sum_{i=1}^n |a_i^T X|}{\|X\|_1}$$

a_i^T - строка A

Пример

Покажите, что $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$.

Пример

Покажите, что $\|A\|_1 = \max_j \sum_{i=1}^n |a_{ij}|$.

Решением можно разбить на две части: показать, что норма не превосходит максимальной суммы модулей столбца, и построить вектор, для которого достигается это значение. Норма $\|A\|_1$ определяется как операторная норма, индуцированная векторной 1-нормой:

$$\|A\|_1 = \sup_{x \neq 0} \frac{\|Ax\|_1}{\|x\|_1} = \sup_{\|x\|_1=1} \|Ax\|_1$$

При этом можно показать, что

$$\|Ax\|_1 = \sum_i \left| \sum_j a_{ij} x_j \right| \leq \sum_{i=1}^n \sum_{j=1}^n |a_{ij}| |x_j| = \sum_{j=1}^n |x_j| \left(\sum_{i=1}^n |a_{ij}| \right) =$$

Если выбрать x так, чтобы вся масса $\|x\|_1 = 1$ приходилась на столбец с максимальной суммой модулей, получим, что супремум равен

$$\max_j \sum_{i=1}^n |a_{ij}|.$$

$$= \sum_{j=1}^n |x_j| \cdot K_j = x_1 \cdot 1 + x_2 \cdot 2 + x_3 \cdot 3$$
$$K_j = \sum_{i=1}^n |a_{ij}| = 1 \quad x_j = \max$$

$$\left\| \begin{pmatrix} 1 & 2 \\ 3 & 4 \end{pmatrix} \right\|_1 = 6$$

Пример

Покажите, что $\|A\|_\infty = \max_i \sum_{j=1}^n |a_{ij}|$.

$$\begin{aligned}\|A\|_\infty &= \sup_{\|x\|_\infty = 1} \|Ax\|_\infty = \sup_i \max |a_i^T x| = \\ &= \sup_i \max \left| \sum_{j=1}^n a_{ij} x_j \right|\end{aligned}$$

Пример

Покажите, что $\|A\|_\infty = \max_i \sum_{j=1}^m |a_{ij}|$.

Аналогично, операторная норма, индуцированная ∞ -нормой, определяется как

$$\|A\|_\infty = \sup_{x \neq 0} \frac{\|Ax\|_\infty}{\|x\|_\infty}.$$

При этом легко доказать, что

$$\|Ax\|_\infty = \max_i \left| \sum_j a_{ij} x_j \right| \leq \max_i \sum_j |a_{ij}| \|x\|_\infty.$$

Отсюда следует, что

$$\|A\|_\infty = \max_i \sum_{j=1}^m |a_{ij}|.$$

Скалярное произведение

Стандартное скалярное (внутреннее) произведение между векторами x и y из $\mathbb{R}^n$ определяется как:

$$\langle x, y \rangle = x^T y = \sum_{i=1}^n x_i y_i = y^T x = \langle y, x \rangle$$

Здесь x_i и y_i являются i -ми компонентами соответствующих векторов.

Example

Докажите, что можно перемещать матрицу внутри скалярного произведения с транспонированием:
 $\langle x, Ay \rangle = \langle A^T x, y \rangle$ и $\langle x, yB \rangle = \langle xB^T, y \rangle$

Скалярное произведение матриц

Стандартное **скалярное (внутреннее) произведение** между матрицами X и Y из $\mathbb{R}^{m \times n}$ определяется как:

$$\langle X, Y \rangle = \text{tr}(X^T Y) = \sum_{i=1}^m \sum_{j=1}^n X_{ij} Y_{ij} = \text{tr}(Y^T X) = \langle Y, X \rangle$$

Question

Существует ли связь между нормой Фробениуса $\|\cdot\|_F$ и скалярным произведением между матрицами $\langle \cdot, \cdot \rangle$?

$$\langle X, X \rangle = \|X\|_F^2$$

Пример

i Question

Посчитайте скалярное произведение матриц

$$\left\langle \begin{bmatrix} 1 & 2 & 3 \\ 4 & 5 & 6 \end{bmatrix}, \begin{bmatrix} 1 & 0 & 0 \\ 0 & 1 & 0 \end{bmatrix} \right\rangle =$$

$$\text{tr}(A^T B)$$

$$= \sum_{i,j} a_{ij} \cdot b_{ij} = 1 + 5 = 6$$

Пример

i Question

Упростите следующее выражение:

$$\sum_{i=1}^n \langle S^{-1} a_i, a_i \rangle,$$

где $S = \sum_{i=1}^n a_i a_i^T$, $a_i \in \mathbb{R}^n$, $\det(S) \neq 0$

Ортогональные матрицы

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .
- Это может произойти **тогда и только тогда**, когда

$$U^T U = I_n,$$

где I_n - единичная матрица $n \times n$.

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .
- Это может произойти **тогда и только тогда**, когда

$$U^T U = I_n,$$

где I_n - единичная матрица $n \times n$.

- Квадратная матрица размера $n \times n$ называется **ортогональной**, если

$$U^T U = U U^T = I_n,$$

что означает, что столбцы и строки ортогональной матрицы образуют ортонормированный базис в $\mathbb{R}^n$.

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .
- Это может произойти **тогда и только тогда**, когда

$$U^T U = I_n,$$

где I_n - единичная матрица $n \times n$.

- Квадратная матрица размера $n \times n$ называется **ортогональной**, если

$$U^T U = U U^T = I_n,$$

что означает, что столбцы и строки ортогональной матрицы образуют ортонормированный базис в $\mathbb{R}^n$.

- Для матрицы из комплексных чисел вводится аналогичное определение **унитарной матрицы**:

$$U^* U = U U^* = I_n,$$

где U^* - эрмитово сопряжение матрицы U .

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .
- Это может произойти **тогда и только тогда**, когда

$$U^T U = I_n,$$

где I_n - единичная матрица $n \times n$.

- Квадратная матрица размера $n \times n$ называется **ортогональной**, если

$$U^T U = U U^T = I_n,$$

что означает, что столбцы и строки ортогональной матрицы образуют ортонормированный базис в $\mathbb{R}^n$.

- Для матрицы из комплексных чисел вводится аналогичное определение **унитарной матрицы**:

$$U^* U = U U^* = I_n,$$

где U^* - эрмитово сопряжение матрицы U .

- Для прямоугольных матриц размера $m \times n$ ($n \neq m$) только одно из равенств может выполняться

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .
- Это может произойти **тогда и только тогда**, когда

$$U^T U = I_n,$$

где I_n - единичная матрица $n \times n$.

- Квадратная матрица размера $n \times n$ называется **ортогональной**, если

$$U^T U = U U^T = I_n,$$

что означает, что столбцы и строки ортогональной матрицы образуют ортонормированный базис в $\mathbb{R}^n$.

- Для матрицы из комплексных чисел вводится аналогичное определение **унитарной матрицы**:

$$U^* U = U U^* = I_n,$$

где U^* - эрмитово сопряжение матрицы U .

- Для прямоугольных матриц размера $m \times n$ ($n \neq m$) только одно из равенств может выполняться
 - $U^T U = I_n$ - матрица U называется **матрицей с ортогональными столбцами** для $m > n$

Ортогональные (унитарные) матрицы

- Пусть U - матрица размера $n \times n$, и $\|Uz\|_2 = \|z\|_2$ для всех z .
- Это может произойти **тогда и только тогда**, когда

$$U^T U = I_n,$$

где I_n - единичная матрица $n \times n$.

- Квадратная матрица размера $n \times n$ называется **ортогональной**, если

$$U^T U = U U^T = I_n,$$

что означает, что столбцы и строки ортогональной матрицы образуют ортонормированный базис в $\mathbb{R}^n$.

- Для матрицы из комплексных чисел вводится аналогичное определение **унитарной матрицы**:

$$U^* U = U U^* = I_n,$$

где U^* - эрмитово сопряжение матрицы U .

- Для прямоугольных матриц размера $m \times n$ ($n \neq m$) только одно из равенств может выполняться
 - $U^T U = I_n$ - матрица U называется **матрицей с ортогональными столбцами** для $m > n$
 - $U U^T = I_m$ - матрица U называется **матрицей с ортогональными строками** для $m < n$

Ортогональные матрицы

$$U \cdot V$$

$$U : U^T U = U U^T = I$$

$$V : V^T V = V V^T = I$$

Важное свойство: **произведение двух ортогональных матриц является ортогональной матрицей:**

$$(UV)^T UV = V^T \overset{I}{U^T U} V = \underbrace{V^T V}_I = I,$$

- Позже мы покажем, что существуют типы матриц (**отражения Хаусхолдера и вращения Гивенса**) композиция которых способна произвести любую унитарную матрицу

Ортогональные матрицы

Важное свойство: **произведение двух ортогональных матриц является ортогональной матрицей:**

$$(UV)^T UV = V^T U^T UV = V^T V = I,$$

- Позже мы покажем, что существуют типы матриц (**отражения Хаусхолдера и вращения Гивенса**) композиция которых способна произвести любую унитарную матрицу
- Эта идея является основой некоторых алгоритмов, например, QR-разложения

Ортогональная инвариантность $\|\cdot\|_2$ и $\|\cdot\|_F$ норм

- Для векторной 2-нормы мы уже видели, что $\|Uz\|_2 = \|z\|_2$ для любой ортогональной U .

Ортогональная инвариантность $\|\cdot\|_2$ и $\|\cdot\|_F$ норм

- Для векторной 2-нормы мы уже видели, что $\|Uz\|_2 = \|z\|_2$ для любой ортогональной U .
- Можно показать, что ортогональные матрицы не изменяют матричные нормы $\|\cdot\|_2$ и $\|\cdot\|_F$, т.е. для любой квадратной A и ортогональной U, V :

$$\|UAV\|_2 = \|A\|_2 \quad \|UAV\|_F = \|A\|_F.$$

Ортогональная инвариантность $\|\cdot\|_2$ и $\|\cdot\|_F$ норм

- Для векторной 2-нормы мы уже видели, что $\|Uz\|_2 = \|z\|_2$ для любой ортогональной U .
- Можно показать, что ортогональные матрицы не изменяют матричные нормы $\|\cdot\|_2$ и $\|\cdot\|_F$, т.е. для любой квадратной A и ортогональной U, V :

$$\|UAV\|_2 = \|A\|_2 \quad \|UAV\|_F = \|A\|_F.$$

- Для $\|\cdot\|_2$ это следует из определения операторной нормы и того факта, что векторная 2-норма является ортогонально инвариантной.

Ортогональная инвариантность $\|\cdot\|_2$ и $\|\cdot\|_F$ норм

- Для векторной 2-нормы мы уже видели, что $\|Uz\|_2 = \|z\|_2$ для любой ортогональной U .
- Можно показать, что ортогональные матрицы не изменяют матричные нормы $\|\cdot\|_2$ и $\|\cdot\|_F$, т.е. для любой квадратной A и ортогональной U, V :

$$\|UAV\|_2 = \|A\|_2 \quad \|UAV\|_F = \|A\|_F.$$

- Для $\|\cdot\|_2$ это следует из определения операторной нормы и того факта, что векторная 2-норма является ортогонально инвариантной.
- Для $\|\cdot\|_F$ это следует из $\|A\|_F^2 = \text{trace}(A^T A)$ и того факта, что $\text{trace}(BC) = \text{trace}(CB)$.

Примеры ортогональных матриц

- Матрица вращения

Примеры ортогональных матриц

- Матрица вращения
- Матрица перестановки

Примеры ортогональных матриц

- Матрица вращения
- Матрица перестановки
- Матрица отражения Хаусхолдера

Примеры ортогональных матриц

- Матрица вращения
- Матрица перестановки
- Матрица отражения Хаусхолдера
- Матрица вращения Гивенса


Матрица отражения Хаусхолдера

Матрица отражения Хаусхолдера - это ортогональная матрица, которая используется для отражения вектора относительно гиперплоскости. Она имеет следующий вид:

$$H \equiv H(v) = I - 2vv^T,$$

где v - вектор длины n и $v^T v = 1$.

- Покажите, что H - ортогональная матрица и $H^T = H$.



Матрица отражения Хаусхолдера


Матрица отражения Хаусхолдера - это ортогональная матрица, которая используется для отражения вектора относительно гиперплоскости. Она имеет следующий вид:

$$H \equiv H(v) = I - 2vv^T,$$

где v - вектор длины n и $v^T v = 1$.

- Покажите, что H - ортогональная матрица и $H^T = H$.
- Покажите, что H - отражение:

$$Hx = x - 2(v^T x)v$$



Важное свойство матрицы отражения Хаусхолдера

Хорошее свойство матрицы отражения Хаусхолдера состоит в том, что она может обнулить все элементы вектора, кроме первого:

$$H \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

- Доказательство. Пусть $e_1 = (1, 0, \dots, 0)^T$, тогда мы хотим найти v такой, что

$$Hx = x - 2(v^T x)v = \alpha e_1,$$

где α - неизвестная константа.

Важное свойство матрицы отражения Хаусхолдера

Хорошее свойство матрицы отражения Хаусхолдера состоит в том, что она может обнулить все элементы вектора, кроме первого:

$$H \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

- Доказательство. Пусть $e_1 = (1, 0, \dots, 0)^T$, тогда мы хотим найти v такой, что

$$Hx = x - 2(v^T x)v = \alpha e_1,$$

где α - неизвестная константа.

- Так как $\|\cdot\|_2$ является унитарно инвариантной, мы получаем

$$\|x\|_2 = \|Hx\|_2 = \|\alpha e_1\|_2 = |\alpha|.$$

и $\alpha = \pm \|x\|_2$

Важное свойство матрицы отражения Хаусхолдера

Хорошее свойство матрицы отражения Хаусхолдера состоит в том, что она может обнулить все элементы вектора, кроме первого:

$$H \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

- Доказательство. Пусть $e_1 = (1, 0, \dots, 0)^T$, тогда мы хотим найти v такой, что

$$Hx = x - 2(v^T x)v = \alpha e_1,$$

где α - неизвестная константа.

- Так как $\|\cdot\|_2$ является унитарно инвариантной, мы получаем

$$\|x\|_2 = \|Hx\|_2 = \|\alpha e_1\|_2 = |\alpha|.$$

и $\alpha = \pm\|x\|_2$

- Также мы можем выразить v из $x - 2(v^T x)v = \alpha e_1$:

$$v = \frac{x - \alpha e_1}{2v^T x}$$

Важное свойство матрицы отражения Хаусхолдера

Хорошее свойство матрицы отражения Хаусхолдера состоит в том, что она может обнулить все элементы вектора, кроме первого:

$$H \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

- Доказательство. Пусть $e_1 = (1, 0, \dots, 0)^T$, тогда мы хотим найти v такой, что
- Умножая последнее выражение на x^T мы получаем

$$Hx = x - 2(v^T x)v = \alpha e_1,$$

$$x^T x - 2(v^T x)x^T v = \alpha x_1;$$

где α - неизвестная константа.

или

- Так как $\|\cdot\|_2$ является унитарно инвариантной, мы получаем

$$\|x\|_2^2 - 2(v^T x)^2 = \alpha x_1.$$

$$\|x\|_2 = \|Hx\|_2 = \|\alpha e_1\|_2 = |\alpha|.$$

и $\alpha = \pm \|x\|_2$

- Также мы можем выразить v из $x - 2(v^T x)v = \alpha e_1$:

$$v = \frac{x - \alpha e_1}{2v^T x}$$

Важное свойство матрицы отражения Хаусхолдера

Хорошее свойство матрицы отражения Хаусхолдера состоит в том, что она может обнулить все элементы вектора, кроме первого:

$$H \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

- Доказательство. Пусть $e_1 = (1, 0, \dots, 0)^T$, тогда мы хотим найти v такой, что
- Умножая последнее выражение на x^T мы получаем

$$Hx = x - 2(v^T x)v = \alpha e_1,$$

$$x^T x - 2(v^T x)x^T v = \alpha x_1;$$

где α - неизвестная константа.

или

- Так как $\|\cdot\|_2$ является унитарно инвариантной, мы получаем

$$\|x\|_2^2 - 2(v^T x)^2 = \alpha x_1.$$

$$\|x\|_2 = \|Hx\|_2 = \|\alpha e_1\|_2 = |\alpha|.$$

- Следовательно,

$$(v^T x)^2 = \frac{\|x\|_2^2 - \alpha x_1}{2}.$$

и $\alpha = \pm \|x\|_2$

- Также мы можем выразить v из $x - 2(v^T x)v = \alpha e_1$:

$$v = \frac{x - \alpha e_1}{2v^T x}$$

Важное свойство матрицы отражения Хаусхолдера

Хорошее свойство матрицы отражения Хаусхолдера состоит в том, что она может обнулить все элементы вектора, кроме первого:

$$H \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

- Доказательство. Пусть $e_1 = (1, 0, \dots, 0)^T$, тогда мы хотим найти v такой, что
- Умножая последнее выражение на x^T мы получаем

$$Hx = x - 2(v^T x)v = \alpha e_1,$$

$$x^T x - 2(v^T x)x^T v = \alpha x_1;$$

где α - неизвестная константа.

или

- Так как $\|\cdot\|_2$ является унитарно инвариантной, мы получаем

$$\|x\|_2^2 - 2(v^T x)^2 = \alpha x_1.$$

$$\|x\|_2 = \|Hx\|_2 = \|\alpha e_1\|_2 = |\alpha|.$$

- Следовательно,

$$(v^T x)^2 = \frac{\|x\|_2^2 - \alpha x_1}{2}.$$

и $\alpha = \pm \|x\|_2$

- Также мы можем выразить v из $x - 2(v^T x)v = \alpha e_1$:

$$v = \frac{x - \alpha e_1}{2v^T x}$$

- Таким образом, v существует и равно

$$v = \frac{x \mp \|x\|_2 e_1}{2v^T x} = \frac{x \mp \|x\|_2 e_1}{\pm \sqrt{2}(\|x\|_2^2 \mp \|x\|_2 x_1)}.$$

Алгоритм Хаусхолдера для построения QR-разложения

- Используя полученное свойство мы можем сделать произвольную матрицу A нижней треугольной:

$$H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

Алгоритм Хаусхолдера для построения QR-разложения

- Используя полученное свойство мы можем сделать произвольную матрицу A нижней треугольной:

$$H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

- Затем находим $H_3 = \begin{bmatrix} I_2 & \\ & \tilde{H}_3 \end{bmatrix}$ такую, что

$$\tilde{H}_3 \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

Алгоритм Хаусхолдера для построения QR-разложения

- Используя полученное свойство мы можем сделать произвольную матрицу A нижней треугольной:
- Получаем

$$H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

$$H_3 H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & \times \end{bmatrix}$$

- Затем находим $H_3 = \begin{bmatrix} I_2 & \\ & \tilde{H}_3 \end{bmatrix}$ такую, что

$$\tilde{H}_3 \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

Алгоритм Хаусхолдера для построения QR-разложения

- Используя полученное свойство мы можем сделать произвольную матрицу A нижней треугольной:
- Получаем

$$H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

- Затем находим $H_3 = \begin{bmatrix} I_2 & \\ & \tilde{H}_3 \end{bmatrix}$ такую, что

$$\tilde{H}_3 \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

$$H_3 H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & \times \end{bmatrix}$$

- Аналогично находим H_4 и получаем верхнюю треугольную матрицу.

Алгоритм Хаусхолдера для построения QR-разложения

- Используя полученное свойство мы можем сделать произвольную матрицу A нижней треугольной:
- Получаем

$$H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & \times & \times \end{bmatrix}$$

- Затем находим $H_3 = \begin{bmatrix} I_2 & \\ & \tilde{H}_3 \end{bmatrix}$ такую, что

$$\tilde{H}_3 \begin{bmatrix} \times \\ \times \\ \times \end{bmatrix} = \begin{bmatrix} \times \\ 0 \\ 0 \end{bmatrix}.$$

$$H_3 H_2 H_1 A = \begin{bmatrix} \times & \times & \times & \times \\ 0 & \times & \times & \times \\ 0 & 0 & \times & \times \\ 0 & 0 & 0 & \times \\ 0 & 0 & 0 & \times \end{bmatrix}$$

- Аналогично находим H_4 и получаем верхнюю треугольную матрицу.
- Так как произведение ортогональных и обратная к ортогональной матрицы являются ортогональными матрицами, мы получаем **следствие:** (QR-разложение) Любая $A \in \mathbb{R}^{n \times m}$ может быть представлена как

$$A = QR,$$

где Q - ортогональная и R - верхняя треугольная. См. постер, каковы размеры Q и R для $n > m$ и $n < m$.

Матрица вращения Гивенса (Якоби)

- Матрица вращения Гивенса (Якоби) - это ортогональная матрица, которая используется для вращения вектора в плоскости на угол α . Она имеет следующий вид:

$$G = \begin{bmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{bmatrix}$$

Легко проверить, что $G^T G = G G^T = I$, то есть матрица является ортогональной.

Матрица вращения Гивенса (Якоби)

- Матрица вращения Гивенса (Якоби) - это ортогональная матрица, которая используется для вращения вектора в плоскости на угол α . Она имеет следующий вид:

$$G = \begin{bmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{bmatrix}$$

Легко проверить, что $G^T G = G G^T = I$, то есть матрица является ортогональной.

- Для общего случая размерности n мы выбираем две координаты (i, j) и выполняем вращение вектора x только в этой плоскости:

$$x' = Gx,$$

где изменяются только i -я и j -я координаты:

$$x'_i = x_i \cos \alpha - x_j \sin \alpha, \quad x'_j = x_i \sin \alpha + x_j \cos \alpha,$$

при этом остальные x_k остаются неизменными.

Матрица вращения Гивенса (Якоби)

- Матрица вращения Гивенса (Якоби) - это ортогональная матрица, которая используется для вращения вектора в плоскости на угол α . Она имеет следующий вид:

$$G = \begin{bmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{bmatrix}$$

Легко проверить, что $G^T G = G G^T = I$, то есть матрица является ортогональной.

- Для общего случая размерности n мы выбираем две координаты (i, j) и выполняем вращение вектора x только в этой плоскости:

$$x' = Gx,$$

где изменяются только i -я и j -я координаты:

$$x'_i = x_i \cos \alpha - x_j \sin \alpha, \quad x'_j = x_i \sin \alpha + x_j \cos \alpha,$$

при этом остальные x_k остаются неизменными.

- Чтобы обнулить j -ю координату вектора, выбираем угол α так, что:

$$\cos \alpha = \frac{x_i}{\sqrt{x_i^2 + x_j^2}}, \quad \sin \alpha = -\frac{x_j}{\sqrt{x_i^2 + x_j^2}}$$

Матрица вращения Гивенса (Якоби)

- Матрица вращения Гивенса (Якоби) - это ортогональная матрица, которая используется для вращения вектора в плоскости на угол α . Она имеет следующий вид:

$$G = \begin{bmatrix} \cos \alpha & -\sin \alpha \\ \sin \alpha & \cos \alpha \end{bmatrix}$$

Легко проверить, что $G^T G = G G^T = I$, то есть матрица является ортогональной.

- Для общего случая размерности n мы выбираем две координаты (i, j) и выполняем вращение вектора x только в этой плоскости:

$$x' = Gx,$$

где изменяются только i -я и j -я координаты:

$$x'_i = x_i \cos \alpha - x_j \sin \alpha, \quad x'_j = x_i \sin \alpha + x_j \cos \alpha,$$

при этом остальные x_k остаются неизменными.

- Чтобы обнулить j -ю координату вектора, выбираем угол α так, что:

$$\cos \alpha = \frac{x_i}{\sqrt{x_i^2 + x_j^2}}, \quad \sin \alpha = -\frac{x_j}{\sqrt{x_i^2 + x_j^2}}$$

- Применяя последовательно матрицы Гивенса, можно привести матрицу к верхнетреугольному виду: для этого нужно $n - 1$ вращений, чтобы обнулить элементы под главной диагональю в каждом столбце.

QR через вращения Гивенса

Также мы можем сделать матрицу верхнетреугольной с помощью вращений Гивенса:

$$\begin{bmatrix} \times & \times & \times \\ * & \times & \times \\ * & \times & \times \end{bmatrix} \rightarrow \begin{bmatrix} * & \times & \times \\ * & \times & \times \\ 0 & \times & \times \end{bmatrix} \rightarrow \begin{bmatrix} \times & \times & \times \\ 0 & * & \times \\ 0 & * & \times \end{bmatrix} \rightarrow \begin{bmatrix} \times & \times & \times \\ 0 & \times & \times \\ 0 & 0 & \times \end{bmatrix}$$

Вращения Гивенса vs. отражения Хаусхолдера

- Отражения Хаусхолдера полезны для плотных матриц (сложность приблизительно в два раза меньше, чем для Якоби) и мы должны обнулить большое количество элементов.

Вращения Гивенса vs. отражения Хаусхолдера

- Отражения Хаусхолдера полезны для плотных матриц (сложность приблизительно в два раза меньше, чем для Якоби) и мы должны обнулить большое количество элементов.
- Вращения Гивенса более подходят для разреженных матриц или параллельных вычислений, так как они действуют локально на элементах.