




Отражения Хаусхолдера. Вращения
Гивенса. Ранг матрицы. Скелетон. SVD

Даня Меркулов

МФТИ. AI360

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 $n \times n$.

$$U^* U = I$$

$$U U^T = U^* U = I$$

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 $m > n$

$U^T U = I$

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

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

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

UV — ортогональна

- 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 $v^T v = 1$. $\Rightarrow \|v\|^2 = 1$

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

$$\begin{aligned} &= X - 2vv^T X = \\ &= X - 2v \cdot v^T X \cdot v \end{aligned}$$

$v \in \mathbb{R}^{n \times 1}$
 $v \cdot v^T$
 $n \times 1 \cdot 1 \times n$
 $n \times n$

$H(v) \cdot X =$
 $= (I - 2vv^T)X =$

$x - 2(v^T x)v$
 $-\langle v^T x \rangle v$
 $\pi_v(x) = \frac{v}{\|v\|} \cdot \|x\| \cdot \cos \alpha = \frac{\langle x, v \rangle}{\|x\| \cdot \|v\|}$
 $= \frac{v}{\|v\|} \cdot \cancel{\|x\|} \cdot \frac{\langle x, v \rangle}{\cancel{\|x\|} \cdot \|v\|} = v \cdot \frac{\langle x, v \rangle}{\|v\|^2}$

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:

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

$$\begin{aligned} H &= H^T \\ (I - 2vv^T)^T &= I^T - (2vv^T)^T = \\ &= I - 2v^T{}^T v^T = \\ &= I - 2vv^T = H \end{aligned}$$



Важное свойство матрицы отражения Хаусхолдера

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

Есть $\forall x \in \mathbb{R}^n$

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

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

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

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

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

где α - неизвестная константа.

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

$$\boxed{\|x\|_2 = \|Hx\|_2} = \|\alpha e_1\|_2 = |\alpha|$$

и $\alpha = \pm \|x\|_2$

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

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

$$|\alpha| = \|x\|_2$$

$$\alpha = \pm \|x\|_2$$

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

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

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

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

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

или

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

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

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
- 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

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

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

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

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

или

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

- Следовательно,

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

- 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:

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

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

$$= \begin{bmatrix} \bullet & \bullet & \bullet \\ 0 & \bullet & \bullet \\ 0 & \bullet & \bullet \end{bmatrix}$$

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

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

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

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

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

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 $n < m$.

QR-разложение матрицы


$$Q, R = \text{np.linalg.qr}(A)$$

Для произвольной матрицы $A \in \mathbb{R}^{m \times n}$ существует разложение вида:



$$A = QR,$$

где $Q \in \mathbb{R}^{m \times m}$ - ортогональная матрица ($Q^T Q = Q Q^T = I$), а $R \in \mathbb{R}^{m \times n}$ -

верхнетреугольная матрица. В случае, когда $m > n$, матрица Q может быть усечена до размера $m \times n$ с сохранением ортогональности столбцов. Если зафиксировать все диагональные элементы матрицы R , то разложение становится единственным.



reduced=True



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:

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

матрица поворота

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:

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

$\swarrow$
 2×2

$i=2, j=4$

$\begin{pmatrix} x_1 \\ x_2 \\ x_3 \\ x_4 \end{pmatrix}$

(Handwritten diagram showing a vector x with components x_1, x_2, x_3, x_4 . The components x_2 and x_4 are circled in red, indicating the plane of rotation. The text $i=2, j=4$ is written in red next to it.)

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: $2 \times 1 \quad 2 \times 2 \quad 2 \times 1$

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

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:

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

после поворота

j -ая

координата

становится

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.

x_1
 x_2
 x_3
 $\vdots$
 x_n

QR через вращения Гивенса

Также мы можем сделать матрицу верхнетреугольной с помощью вращений Гивенса:

$$\begin{bmatrix} \times & \times & \times \\ * & \times & \times \\ * & \times & \times \end{bmatrix} \xrightarrow{G_1} \begin{bmatrix} * & \times & \times \\ * & \times & \times \\ 0 & \times & \times \end{bmatrix} \xrightarrow{G_2} \begin{bmatrix} \times & \times & \times \\ 0 & * & \times \\ 0 & * & \times \end{bmatrix} \xrightarrow{G_3} \begin{bmatrix} \times & \times & \times \\ 0 & \times & \times \\ 0 & 0 & \times \end{bmatrix}$$

$$G_5 G_4 G_3 G_2 G_1 A = R$$

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.

Ранг матрицы

Скелетное разложение матрицы

Простое, но очень интересное разложение - скелетное, которое может быть записано в двух формах:

$$A = UV^T \quad A = \hat{C}\hat{A}^{-1}\hat{R}$$

Скелетное разложение матрицы

Простое, но очень интересное разложение - скелетное, которое может быть записано в двух формах:

$$A = UV^T \quad A = \hat{C}\hat{A}^{-1}\hat{R}$$

Последнее выражение отсылает к любопытному факту: вы можете случайным образом выбрать r линейно независимых столбцов матрицы и любых r линейно независимых строк матрицы и хранить только их, при этом имея возможность точно восстановить всю матрицу.

Скелетное разложение матрицы

Простое, но очень интересное разложение - скелетное, которое может быть записано в двух формах:

$$A = UV^T \quad A = \hat{C}\hat{A}^{-1}\hat{R}$$

Последнее выражение отсылает к любопытному факту: вы можете случайным образом выбрать r линейно независимых столбцов матрицы и любых r линейно независимых строк матрицы и хранить только их, при этом имея возможность точно восстановить всю матрицу.

Применения скелетного разложения:

- Упрощение модели, сжатие данных и ускорение вычислений в численных методах: для матрицы ранга r с $r \ll n, m$ достаточно хранить $\mathcal{O}((n+m)r) \ll nm$ элементов.




Рис. 1: Иллюстрация скелетного разложения

Скелетное разложение матрицы

Простое, но очень интересное разложение - скелетное, которое может быть записано в двух формах:

$$A = UV^T \quad A = \hat{C}\hat{A}^{-1}\hat{R}$$

Последнее выражение отсылает к любопытному факту: вы можете случайным образом выбрать r линейно независимых столбцов матрицы и любых r линейно независимых строк матрицы и хранить только их, при этом имея возможность точно восстановить всю матрицу.

Применения скелетного разложения:

- Упрощение модели, сжатие данных и ускорение вычислений в численных методах: для матрицы ранга r с $r \ll n, m$ достаточно хранить $\mathcal{O}((n+m)r) \ll nm$ элементов.
- Извлечение признаков в машинном обучении, где также известно как матричное разложение.




Рис. 1: Иллюстрация скелетного разложения

LoRA: Low-Rank Adaptation of Large Language Models (arXiv:2106.09685)

Так как современные LLM слишком большие, чтобы поместиться в память обычной GPU, мы используем некоторые трюки, чтобы сделать потребление памяти меньше. Один из самых популярных трюков - LoRA (Low-Rank Adaptation of Large Language Models).

Предположим, что у нас есть матрица $W \in \mathbb{R}^{d \times k}$ и мы хотим выполнить следующее обновление:

ищем $W = ?$

$$W = W_0 + \Delta W.$$

Основная идея LoRA - разложить обновление ΔW на две низкоранговые матрицы:

$$W = W_0 + \Delta W = W_0 + \underline{BA}, \quad B \in \mathbb{R}^{d \times r}, A \in \mathbb{R}^{r \times k}, \\ \text{rank}(A) = \text{rank}(B) = r \ll \min\{d, k\}.$$

Проверьте 🖱️ ноутбук для примера реализации LoRA.

*1 слово = 32 бита
16 бит*

*$3 \cdot 10^9 \cdot 2 \text{ байта}$
6 ГБ*






Рис. 2: Иллюстрация LoRA



$$y = f_w(x)$$

$$f_w(x) = W \cdot x$$
$$= \text{ReLU}(\underline{W \cdot x})$$

$$W = ?$$



ЯзыкоBAЯ модель

без труда получать рыбку из



Сингулярное разложение матрицы

The diagram illustrates the Singular Value Decomposition (SVD) of a matrix $A_{m \times n}$. It is shown as an equation: $A_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}^*$. The matrix $A_{m \times n}$ is represented by a light gray rounded rectangle. The matrix $U_{m \times m}$ is represented by an orange rounded rectangle. The matrix $\Sigma_{m \times n}$ is represented by a light gray rounded rectangle containing the singular values $\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_r$ along its main diagonal, with a red curved line underneath. The matrix $V_{n \times n}^*$ is represented by a purple rounded rectangle.

Для любой матрицы $A \in \mathbb{R}^{m \times n}$ существует разложение:

$$A = U \Sigma V^*,$$

где

- $U \in \mathbb{R}^{m \times m}$ - унитарная матрица левых сингулярных векторов

Сингулярное разложение матрицы

The diagram illustrates the Singular Value Decomposition (SVD) of a matrix $A_{m \times n}$. It is represented as the product of three matrices: $U_{m \times m}$ (orange box), $\Sigma_{m \times n}$ (light gray box with diagonal elements $\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_r$), and $V_{n \times n}^*$ (purple box). The equation is shown as $A_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}^*$.

Для любой матрицы $A \in \mathbb{R}^{m \times n}$ существует разложение:

$$A = U \Sigma V^*,$$

где

- $U \in \mathbb{R}^{m \times m}$ - унитарная матрица левых сингулярных векторов
 - $\Sigma \in \mathbb{R}^{m \times n}$ - диагональная матрица сингулярных чисел
- $$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$$

Сингулярное разложение матрицы

The diagram illustrates the Singular Value Decomposition (SVD) of a matrix $A_{m \times n}$. It is shown as the product of three matrices: $U_{m \times m}$ (orange box), $\Sigma_{m \times n}$ (grey box with diagonal elements $\sigma_1, \sigma_2, \sigma_3, \dots, \sigma_r$), and $V_{n \times n}^*$ (purple box). The equation is represented as $A_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}^*$.

Для любой матрицы $A \in \mathbb{R}^{m \times n}$ существует разложение:

$$A = U \Sigma V^*,$$

где

- $U \in \mathbb{R}^{m \times m}$ - унитарная матрица левых сингулярных векторов
- $\Sigma \in \mathbb{R}^{m \times n}$ - диагональная матрица сингулярных чисел
 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$
- $V \in \mathbb{R}^{n \times n}$ - унитарная матрица правых сингулярных векторов

Сингулярное разложение матрицы

$$A_{m \times n} = U_{m \times m} \Sigma_{m \times n} V_{n \times n}^*$$

единицы

σ_1
 σ_2
 σ_3
 $\dots$
 σ_r

Для любой матрицы $A \in \mathbb{R}^{m \times n}$ существует разложение:


$$A = U \Sigma V^*,$$

где

- $U \in \mathbb{R}^{m \times m}$ - унитарная матрица левых сингулярных векторов
- $\Sigma \in \mathbb{R}^{m \times n}$ - диагональная матрица сингулярных чисел
 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$
- $V \in \mathbb{R}^{n \times n}$ - унитарная матрица правых сингулярных векторов
- Сингулярные числа единственны. Если все сингулярные числа различны, то разложение единственно с точностью до унитарной диагональной матрицы D :
 $U \Sigma V^* = U D \Sigma (V D)^* = U \Sigma V^*.$

$$\begin{aligned} A &= U \Sigma V^T \\ A^T &= (U \Sigma V^T)^T = \\ &= (\Sigma V^T)^T \cdot U^T = \\ &= V \Sigma^T \cdot U^T = V \Sigma U^T \end{aligned}$$

Сингулярное разложение матрицы



Для любой матрицы $A \in \mathbb{R}^{m \times n}$ существует разложение:

$$A = U \Sigma V^*,$$

где

- $U \in \mathbb{R}^{m \times m}$ - унитарная матрица левых сингулярных векторов
- $\Sigma \in \mathbb{R}^{m \times n}$ - диагональная матрица сингулярных чисел
 $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_{\min(m,n)} \geq 0$
- $V \in \mathbb{R}^{n \times n}$ - унитарная матрица правых сингулярных векторов
- Сингулярные числа единственны. Если все сингулярные числа различны, то разложение единственно с точностью до унитарной диагональной матрицы D :
 $U \Sigma V^* = U D \Sigma (V D)^* = U \Sigma V^*.$




$$A = U \Sigma V^T \quad A^T = V \Sigma^T U^T$$

$$\underline{A A^T} = U \Sigma V^T V \Sigma^T U^T = \underline{U \Sigma^2 U^T}$$

$$\underline{A^T A} = V \Sigma^T U^T U \Sigma V^T = \underline{V \Sigma^2 V^T}$$

$$A = Q \Lambda Q^T$$

↑
спектральное
разлож.



$E(\text{Россия})$

