

Rozkład według wartości osobliwych
Singular Value Decomposition (SVD)
&
Rachunek różniczkowy macierzowy

Maciej Paszyński

Katedra Informatyki
Akademia Górniczo-Hutnicza w Krakowie
home.agh.edu.pl/paszynsk

Jeśli używasz fragmentów tego wykładu, zacytuj źródło

Zadanie na dzisiaj

1) Proszę dokonać rozkładu według wartości osobliwych (singular value decomposition) (slajd 8)

$$A = \begin{bmatrix} 3 & 1 \\ 6 & 2 \end{bmatrix} = U\Sigma V^T$$

2) Dla $y = \begin{bmatrix} y_1 \\ y_2 \\ y_3 \end{bmatrix} = \begin{bmatrix} x_1 \sin x_2 \cos x_3 \\ x_1 \sin x_2 \sin x_3 \\ x_1 \cos x_3 \end{bmatrix}$, $x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$, proszę policzyć

(slajd 25)

$$\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_2}{\partial x_1} & \frac{\partial y_3}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} & \frac{\partial y_3}{\partial x_2} \\ \frac{\partial y_1}{\partial x_3} & \frac{\partial y_2}{\partial x_3} & \frac{\partial y_3}{\partial x_3} \end{bmatrix}$$

oraz Jakobian $\det\left(\frac{\partial y}{\partial x}\right)$ (slajd 26)

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

Tym razem mamy macierz która może nie być kwadratowa (macierz ma n wierszy i m kolumn, reprezentuje więc odwzorowane liniowe z $\mathcal{R}^n \rightarrow \mathcal{R}^m$)

$$A \in \mathcal{R}^{n \times m}$$

Rozkład SVD to coś podobnego do LU lub QR faktoryzacji, można wykonać go również dla macierzy nie będącej macierzą kwadratową.

Def. **range** (obraz operatora reprezentowanego przez macierz A)

$$\mathcal{R}(A) = \{y \in \mathcal{R}^m : x \in \mathcal{R}^n\}$$

Def. **rank** (rzęd macierzy A)

$$\text{rank} A = \dim \mathcal{R}(A)$$

Def. **null space** (jądro operatora reprezentowanego przez macierz A)

$$\mathcal{N}(A) = \{x \in \mathcal{R}^n : Ax = 0\}$$

Mamy $\text{dim} \mathcal{R}(A) + \text{dim} \mathcal{N}(A) = m$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

Każdą macierz $A \in \mathcal{R}^{n \times m}$ da się zdekomponować

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

$U \in \mathcal{R}^{n \times n}$, $U^T = U^{-1}$, $V \in \mathcal{R}^{m \times m}$, $V^T = V^{-1}$ (macierze ortogonalne), gdzie $\Sigma \in \mathcal{R}^{n \times m}$ to macierz wartości osobliwych σ_i

$$\Sigma = \begin{bmatrix} \sigma_1 & & & & & & \\ & \sigma_2 & & & & & \\ & & \ddots & & & & \\ & & & \sigma_r & & & \\ & & & & 0 & & \\ & & & & & \ddots & \\ & & & & & & 0 \end{bmatrix}$$

$r = \text{rank}(A)$ = liczba liniowo niezależnych kolumn

Każda macierz $A \in \mathcal{R}^{n \times m}$ jest ortogonalnie równoważna do macierzy diagonalnej

Rozkład według wartości osobliwych $A = U\Sigma V^T$

Interpretacja geometryczna

$A = U\Sigma V^T / V$, V jest ortogonalne czyli $V^T V = V^{-1} V = I$
czyli $AV = U\Sigma$. Na przykład

$$A = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} = \frac{1}{\sqrt{5}} \left[\begin{bmatrix} 1 \\ 2 \end{bmatrix} \begin{bmatrix} 2 \\ -1 \end{bmatrix} \right] \begin{bmatrix} 3 & 0 & 0 \\ 0 & 2 & 0 \end{bmatrix} \frac{1}{3\sqrt{5}} \begin{bmatrix} 5 & 2 & 4 \\ 0 & 2 & -1 \\ -2 & 1 & 2 \end{bmatrix}$$

$$\begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} \left[\begin{bmatrix} 5 \\ 2 \\ 4 \end{bmatrix} \begin{bmatrix} 0 \\ 2 \\ -1 \end{bmatrix} \begin{bmatrix} -2 \\ 1 \\ 2 \end{bmatrix} \right] = \left[\begin{bmatrix} \frac{1}{15} \\ \frac{2}{15} \end{bmatrix} \begin{bmatrix} \frac{2}{15} \\ -\frac{1}{15} \end{bmatrix} \right] \begin{bmatrix} 3 & 0 & 0 \\ 0 & 2 & 0 \end{bmatrix}$$

Mamy zbiór wektorów bazy u_1, \dots, u_r w przestrzeni \mathcal{R}^n

Mamy zbiór wektorów bazy v_1, \dots, v_r w przestrzeni \mathcal{R}^m

Mamy odwzorowanie $A \in \mathcal{R}^{n \times m}$ które przerzuca jedną bazę w drugą

$$Av_j = \sigma_j u_j \text{ dla } j = 1, \dots, r$$

$$A^T u_j = \sigma_j v_j \text{ dla } j = 1, \dots, r$$

$$v_1 \rightarrow \sigma_1 \rightarrow u_1$$

$$\vdots \rightarrow A \rightarrow \vdots$$

$$v_r \rightarrow \sigma_r \rightarrow u_r$$

$$v_{r+1} \rightarrow 0$$

$$\vdots$$

$$v_m \rightarrow 0$$

$$\mathcal{R}(A) = \{y \in \mathcal{R}^m : x \in \mathcal{R}^n\}; \quad \mathcal{R}(A) = \text{span}\{u_1, \dots, u_r\}$$

$$\text{rank}A = \dim\mathcal{R}(A) = r$$

$$\mathcal{N}(A) = \{x \in \mathcal{R}^m : Ax = 0\}; \quad \mathcal{N}(A) = \text{span}\{v_{r+1}, \dots, v_n\}$$

Rozkład według wartości osobliwych

$$A^{-1} = A^T = V\Sigma^{-1}U^T$$

$$u_1 \rightarrow \frac{1}{\sigma_1} \rightarrow v_1$$

$$\vdots \rightarrow A^T \rightarrow \vdots$$

$$u_r \rightarrow \frac{1}{\sigma_r} \rightarrow v_r$$

$$u_{r+1} \rightarrow 0$$

$$\vdots$$

$$u_n \rightarrow 0$$

$$\mathcal{R}(A^T) = \{y \in \mathcal{R}^m : x \in \mathcal{R}^m\}$$

$$\mathcal{R}(A^T) = \text{span}\{v_1, \dots, v_r\}$$

$$\text{rank}A^T = \dim\mathcal{R}(A^T) = r$$

$$\mathcal{N}(A^T) = \{x \in \mathcal{R}^n : A^T x = 0\}$$

$$\mathcal{N}(A^T) = \text{span}\{u_{r+1}, \dots, u_n\}$$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

Każdą macierz $A \in \mathcal{R}^{n \times m}$ da się zdekomponować

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

Na przykład

$$A = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} = \left[\begin{bmatrix} u_1 \\ u_2 \end{bmatrix} \right] \begin{bmatrix} \sigma_1 & 0 & 0 \\ 0 & \sigma_2 & 0 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix}$$

gdzie $A \in \mathcal{R}^{2 \times 3}$, $U \in \mathcal{R}^{2 \times 2}$, $V \in \mathcal{R}^{3 \times 3}$,

σ_1, σ_2 to pierwiastki wartości własnych λ_1, λ_2 macierzy kwadratowej AA^T , czyli

$$\sigma_1 = \sqrt{\lambda_1}, \quad \sigma_2 = \sqrt{\lambda_2}$$

$u_1, u_2 \in \mathcal{R}^{2 \times 1}$ wektory własne AA^T (left singular values of A)

$v_1, v_2, v_3 \in \mathcal{R}^{3 \times 1}$ wektory własne $A^T A$ (right singular values of A)

Rozkład według wartości osobliwych Singular Value Decomposition (SVD)

$$A = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} \quad AA^T = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} \begin{bmatrix} 1 & 2 \\ 2 & 0 \\ 0 & 2 \end{bmatrix} = \begin{bmatrix} 5 & 2 \\ 2 & 8 \end{bmatrix}$$

Wielomian charakterystyczny $\det(AA^T - \lambda I) = 0$

$$\det(AA^T - \lambda I) = \begin{vmatrix} (5 - \lambda) & 2 \\ 2 & (8 - \lambda) \end{vmatrix} =$$

$$(5 - \lambda)(8 - \lambda) - 4 = 40 - 5\lambda - 8\lambda + \lambda^2 - 4 = \lambda^2 - 13\lambda + 36 = 0$$

równanie kwadratowe $\Delta = b^2 - 4ac = 13^2 - 4 * 1 * 36 = 25$,

$$\sqrt{\Delta} = \sqrt{25} = 5$$

$$\lambda = \frac{-b - \sqrt{\Delta}}{2a} = \frac{13 - 5}{2} = \frac{8}{2} = 4, \text{ oraz } \lambda = \frac{-b + \sqrt{\Delta}}{2a} = \frac{13 + 5}{2} = \frac{18}{2} = 9,$$

Sortujemy od największej do najmniejszej $\lambda_1 = 9$, $\lambda_2 = 4$.

Wartości osobliwe $\sigma_1 = \sqrt{9} = 3$, $\sigma_2 = \sqrt{4} = 2$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

Teraz obliczamy wektory własne

$$AA^T = \begin{bmatrix} 5 & 2 \\ 2 & 8 \end{bmatrix} \quad \lambda_1 = 9, \lambda_2 = 4$$

$$AA^T u_1 = \lambda_1 u_1, \quad AA^T v_2 = \lambda_2 v_2$$

$$(AA^T - \lambda_1 I) u_1 = 0, \quad (A^T A - \lambda_1 I) v_1 = 0$$

$$(AA^T - 9 * I) u_1 = 0, \quad (A^T A - 4 * I) v_2 = 0$$

$$\begin{bmatrix} (5 - 9) & 2 \\ 2 & (8 - 9) \end{bmatrix} \begin{bmatrix} u_1^1 \\ u_1^2 \end{bmatrix} = 0$$

$$\begin{bmatrix} (5 - 4) & 2 \\ 2 & (8 - 4) \end{bmatrix} \begin{bmatrix} u_2^1 \\ u_2^2 \end{bmatrix} = 0$$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

$$\begin{bmatrix} (5-9) & 2 \\ 2 & (8-9) \end{bmatrix} \begin{bmatrix} u_1^1 \\ u_1^2 \end{bmatrix} = 0$$

$$\begin{bmatrix} -4 & 2 \\ 2 & -1 \end{bmatrix} \begin{bmatrix} u_1^1 \\ u_1^2 \end{bmatrix} = 0$$

$$-4u_1^1 + 2u_1^2 = 0; \quad 2u_1^1 - 1u_1^2 = 0;$$

$$4u_1^1 = 2u_1^2; \quad 2u_1^1 = u_1^2;$$

czyli

$$u_1 = \alpha \begin{bmatrix} 1 & 2 \end{bmatrix}^T$$

wersor $\|u_1\|_2 = 1$ daje $\alpha = \frac{1}{\|u_1\|_2}$ gdzie $\|u_1\|_2 = \sqrt{1+2^2} = \sqrt{5}$ czyli

$$u_1 = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \end{bmatrix}^T$$

Rozkład według wartości osobliwych Singular Value Decomposition (SVD)

$$\begin{bmatrix} (5-4) & 2 \\ 2 & (8-4) \end{bmatrix} \begin{bmatrix} u_2^1 \\ u_2^2 \end{bmatrix} = 0$$

$$\begin{bmatrix} 1 & 2 \\ 2 & 4 \end{bmatrix} \begin{bmatrix} u_2^1 \\ u_2^2 \end{bmatrix} = 0$$

$$u_2^1 + 2u_2^2 = 0; \quad 2u_2^1 + 4u_2^2 = 0;$$

$$u_2^1 = -2u_2^2; \quad 2u_2^1 = -4u_2^2;$$

czyli

$$u_2 = \alpha \begin{bmatrix} 2 & -1 \end{bmatrix}^T$$

wersor $\|u_1\|_2 = 1$ daje $\alpha = \frac{1}{\|u_2\|_2}$ gdzie $\|u_2\|_2 = \sqrt{2^2 + (-1)^2} = \sqrt{5}$

czyli $u_2 = \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & -1 \end{bmatrix}^T$

Rozkład według wartości osobliwych Singular Value Decomposition (SVD)

$$u_1 = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \end{bmatrix}^T$$

$$u_2 = \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & -1 \end{bmatrix}^T$$

$$U = \begin{bmatrix} [u_1] & [u_2] \end{bmatrix} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix}$$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

$$A = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix}$$

$$A^T A = \begin{bmatrix} 1 & 2 \\ 2 & 0 \\ 0 & 2 \end{bmatrix} \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} = \begin{bmatrix} 5 & 2 & 4 \\ 2 & 4 & 0 \\ 4 & 0 & 4 \end{bmatrix}$$

Wielomian charakterystyczny $\det(A^T A - \lambda I) = 0$

$$\det(A^T A - \lambda I) = \begin{vmatrix} (5 - \lambda) & 2 & 4 \\ 2 & (4 - \lambda) & 0 \\ 4 & 0 & (4 - \lambda) \end{vmatrix} =$$

$$(5 - \lambda)(4 - \lambda)^2 + 2 * 0 * 4 + 4 * 2 * 0 - (5 - \lambda) * 0 * 0 - 2 * 2 * (4 - \lambda) - 4 * (4 - \lambda) * 4 =$$

$$(5 - \lambda)(4 - \lambda)(4 - \lambda) - 2 * 2 * (4 - \lambda) - 4 * (4 - \lambda) * 4 =$$

$$(4 - \lambda)((5 - \lambda)(4 - \lambda) - 2 * 2 - 4 * 4) =$$

$$(4 - \lambda)((5 - \lambda)(4 - \lambda) - 20) = 0$$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

$$(4 - \lambda)((5 - \lambda)(4 - \lambda) - 20) = 0$$

$$(4 - \lambda) = 0 \implies \lambda = 4$$

$$((5 - \lambda)(4 - \lambda) - 20) = 0; \quad 20 - 4\lambda - 5\lambda + \lambda^2 - 20 = 0; \quad \lambda^2 - 9\lambda = 0$$

równanie kwadratowe $\lambda(\lambda - 9) = 0$ czyli $\lambda = 0$ lub $\lambda = 9$

Sortujemy od największej do najmniejszej $\lambda_1 = 9, \lambda_2 = 4, \lambda_3 = 0$.

Wartości osobliwe $\sigma_1 = \sqrt{9} = 3, \sigma_2 = \sqrt{4} = 2$

Rozkład według wartości osobliwych (SVD)

Teraz obliczamy wektory własne

$$A^T A v_1 = \lambda_1 v_1, \quad A^T A v_2 = \lambda_2 v_2, \quad A^T A v_3 = \lambda_3 v_3$$

$$(A^T A - \lambda_1 I) v_1 = 0, \quad (A^T A - \lambda_2 I) v_2 = 0, \quad (A^T A - \lambda_3 I) v_3 = 0$$

$$(A^T A - 9 * I) v_1 = 0, \quad (A^T A - 4 * I) v_2 = 0, \quad (A^T A - 0 * I) v_3 = 0$$

$$\begin{bmatrix} (5-9) & 2 & 4 \\ 2 & (4-9) & 0 \\ 4 & 0 & (4-9) \end{bmatrix} \begin{bmatrix} v_1^1 \\ v_1^2 \\ v_1^3 \end{bmatrix} = 0$$

$$\begin{bmatrix} (5-4) & 2 & 4 \\ 2 & (4-4) & 0 \\ 4 & 0 & (4-4) \end{bmatrix} \begin{bmatrix} v_2^1 \\ v_2^2 \\ v_2^3 \end{bmatrix} = 0$$

$$\begin{bmatrix} 5 & 2 & 4 \\ 2 & 4 & 0 \\ 4 & 0 & 4 \end{bmatrix} \begin{bmatrix} v_3^1 \\ v_3^2 \\ v_3^3 \end{bmatrix} = 0$$

Rozkład według wartości osobliwych Singular Value Decomposition (SVD)

$$\begin{bmatrix} -4 & 2 & 4 \\ 2 & -5 & 0 \\ 4 & 0 & -5 \end{bmatrix} \begin{bmatrix} v_1^1 \\ v_1^2 \\ v_1^3 \end{bmatrix} = 0$$

$$-4v_1^1 + 2v_1^2 + 4v_1^3 = 0; \quad 2v_1^1 - 5v_1^2 = 0; \quad 4v_1^1 - 5v_1^3 = 0;$$

$$-4v_1^1 + 2v_1^2 + 4v_1^3 = 0; \quad 2v_1^1 = 5v_1^2; \quad 4v_1^1 = 5v_1^3;$$

na przykład $v_1^1 = 5$, $v_1^2 = 2$, $v_1^3 = 4$

wówczas $-4 * 5 + 2 * 2 + 4 * 4 = -20 + 4 + 16 = 0$;

$$v_1 = \alpha \begin{bmatrix} 5 & 2 & 4 \end{bmatrix}^T$$

wektor $\|v_1\|_2 = 1$ daje $\alpha = \frac{1}{\|v_1\|_2}$ gdzie

$$\|v_1\|_2 = \sqrt{5^2 + 2^2 + 4^2} = \sqrt{25 + 4 + 16} = \sqrt{45} = 3\sqrt{5} \text{ czyli}$$

$$v_1 = \frac{1}{3\sqrt{5}} \begin{bmatrix} 5 & 2 & 4 \end{bmatrix}^T$$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

$$\begin{bmatrix} 1 & 2 & 4 \\ 2 & 0 & 0 \\ 4 & 0 & 0 \end{bmatrix} \begin{bmatrix} v_2^1 \\ v_2^2 \\ v_2^3 \end{bmatrix} = 0$$

$$v_2^1 + 2v_2^2 + 4v_2^3 = 0; \quad 2v_2^1 = 0; \quad 4v_2^1 = 0$$

$$v_2^1 = 0; \quad 2v_2^2 = -4v_2^3;$$

czyli

$$v_2 = \alpha \begin{bmatrix} 0 & 2 & -1 \end{bmatrix}^T$$

wersor $\|v_2\|_2 = 1$ daje $\alpha = \frac{1}{\|v_2\|_2}$ gdzie $\|v_2\|_2 = \sqrt{2^2 + (-1)^2} = \sqrt{5}$
czyli

$$v_2 = \frac{1}{\sqrt{5}} \begin{bmatrix} 0 & 2 & -1 \end{bmatrix}^T$$

Rozkład według wartości osobliwych

Singular Value Decomposition (SVD)

$$\begin{bmatrix} 5 & 2 & 4 \\ 2 & 4 & 0 \\ 4 & 0 & 4 \end{bmatrix} \begin{bmatrix} v_3^1 \\ v_3^2 \\ v_3^3 \end{bmatrix} = 0$$

$$5v_3^1 + 2v_3^2 + 4v_3^3 = 0; \quad 2v_3^1 + 4v_3^2 = 0; \quad 4v_3^1 + 4v_3^3 = 0$$

$$5v_3^1 + 2v_3^2 + 4v_3^3 = 0; \quad v_3^2 = -\frac{1}{2}v_3^1; \quad v_3^3 = -v_3^1$$

Przyjmuję $v_3^1 = 1$ wówczas $v_3^2 = -\frac{1}{2}$, oraz $v_3^3 = -1$ czyli

$$v_3 = \alpha \begin{bmatrix} 1 & -\frac{1}{2} & -1 \end{bmatrix}^T = (\text{inna})\alpha \begin{bmatrix} -2 & 1 & 2 \end{bmatrix}^T$$

wersor $\|v_3\|_2 = 1$ daje $\alpha = \frac{1}{\|v_3\|_2}$ gdzie

$$\|v_3\|_2 = \sqrt{(-2)^2 + 1^2 + 2^2} = \sqrt{9} = 3 \text{ czyli}$$

$$v_3 = \frac{1}{3} \begin{bmatrix} -2 & 1 & 2 \end{bmatrix}^T$$

Rozkład według wartości osobliwych Singular Value Decomposition (SVD)

$$v_1 = \frac{1}{3\sqrt{5}} \begin{bmatrix} 5 & 2 & 4 \end{bmatrix}^T$$

$$v_2 = \frac{1}{\sqrt{5}} \begin{bmatrix} 0 & 2 & -1 \end{bmatrix}^T$$

$$v_3 = \frac{1}{3} \begin{bmatrix} -2 & 1 & 2 \end{bmatrix}^T$$

$$V = \left[\begin{array}{c|c|c} [v_1] & [v_2] & [v_3] \end{array} \right] = \frac{1}{3\sqrt{5}} \begin{bmatrix} 5 & 0 & -2\sqrt{5} \\ 2 & 6 & 1\sqrt{5} \\ 4 & -3 & 2\sqrt{5} \end{bmatrix}$$

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

$$A^T = (U\Sigma V^T)^T = V\Sigma^T U^T = V\Sigma U^T$$

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

$$V = A^T U \Sigma^{-1}$$

$$\begin{bmatrix} [v_1] & [v_2] & [v_3] \end{bmatrix} = A^T \begin{bmatrix} [u_1] & [u_2] \end{bmatrix} \begin{bmatrix} \frac{1}{\sigma_1} & 0 & 0 \\ 0 & \frac{1}{\sigma_2} & 0 \\ 0 & 0 & \frac{1}{\sigma_3} \end{bmatrix}$$

$$\begin{bmatrix} [v_1] \end{bmatrix} = A^T \begin{bmatrix} [u_1] \end{bmatrix} \frac{1}{\sigma_1} \quad \begin{bmatrix} [v_2] \end{bmatrix} = A^T \begin{bmatrix} [u_2] \end{bmatrix} \frac{1}{\sigma_2}$$

$$\begin{bmatrix} [v_1] \end{bmatrix} = \sigma_1^{-1} A^T \begin{bmatrix} [u_1] \end{bmatrix} \quad \begin{bmatrix} [v_2] \end{bmatrix} = \sigma_2^{-1} A^T \begin{bmatrix} [u_2] \end{bmatrix}$$

Szybszy sposób na policzenie v_1, v_2, v_3

$$v_1 = \sigma_1^{-1} A^T u_1; \quad v_2 = \sigma_2^{-1} A^T u_2$$

Mamy $\sigma_1 = 3$, $\sigma_2 = 2$, czyli $\sigma_1^{-1} = \frac{1}{3}$, $\sigma_2^{-1} = \frac{1}{2}$

$$A^T = \begin{bmatrix} 1 & 2 \\ 2 & 0 \\ 0 & 2 \end{bmatrix}$$

$$u_1 = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \end{bmatrix}^T; \quad u_2 = \frac{1}{\sqrt{5}} \begin{bmatrix} 2 & -1 \end{bmatrix}^T$$

$$v_1 = \sigma_1^{-1} A^T u_1 = \frac{1}{3} \begin{bmatrix} 1 & 2 \\ 2 & 0 \\ 0 & 2 \end{bmatrix} \frac{1}{\sqrt{5}} \begin{bmatrix} 1 \\ 2 \end{bmatrix} = \frac{1}{3\sqrt{5}} \begin{bmatrix} 1 * 1 + 2 * 2 \\ 2 * 1 + 0 * 2 \\ 0 * 1 + 2 * 2 \end{bmatrix} = \frac{1}{3\sqrt{5}} \begin{bmatrix} 5 \\ 2 \\ 4 \end{bmatrix}$$

$$v_2 = \sigma_2^{-1} A^T u_2 = \frac{1}{2} \begin{bmatrix} 1 & 2 \\ 2 & 0 \\ 0 & 2 \end{bmatrix} \frac{1}{\sqrt{5}} \begin{bmatrix} 2 \\ -1 \end{bmatrix} = \frac{1}{2\sqrt{5}} \begin{bmatrix} 1 * 2 - 2 * 1 \\ 2 * 2 + 0 \\ 0 * 2 - 1 * 2 \end{bmatrix} = \frac{1}{\sqrt{5}} \begin{bmatrix} 0 \\ 2 \\ -1 \end{bmatrix}$$

Natomiast v_3 liczymy jak poprzednio

Rozkład według wartości osobliwych Singular Value Decomposition (SVD)

Każdą macierz $A \in \mathcal{R}^{n \times m}$ da się zdekomponować

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

Na przykład

$$A = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} = \left[\begin{bmatrix} u_1 \\ u_2 \end{bmatrix} \right] \begin{bmatrix} \sigma_1 & 0 & 0 \\ 0 & \sigma_2 & 0 \end{bmatrix} \begin{bmatrix} v_1 \\ v_2 \\ v_3 \end{bmatrix}$$

$$A = \begin{bmatrix} 1 & 2 & 0 \\ 2 & 0 & 2 \end{bmatrix} = \frac{1}{\sqrt{5}} \begin{bmatrix} 1 & 2 \\ 2 & -1 \end{bmatrix} \begin{bmatrix} 3 & 0 & 0 \\ 0 & 2 & 0 \end{bmatrix} \frac{1}{3\sqrt{5}} \begin{bmatrix} 5 & 2 & 4 \\ 0 & 2 & -1 \\ -2 & 1 & 2 \end{bmatrix}$$

Pochodne skalarów względem wektorów i wektorów względem skalarów

$x \in \mathcal{R}^n$ wektor, y skalar, wówczas $\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y}{\partial x_1} \\ \vdots \\ \frac{\partial y}{\partial x_n} \end{bmatrix}$

Przykład $x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$, $y = x_1 x_2 x_3$, policzyć

$$\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y}{\partial x_1} \\ \frac{\partial y}{\partial x_2} \\ \frac{\partial y}{\partial x_3} \end{bmatrix} = \begin{bmatrix} \frac{\partial(x_1 x_2 x_3)}{\partial x_1} \\ \frac{\partial(x_1 x_2 x_3)}{\partial x_2} \\ \frac{\partial(x_1 x_2 x_3)}{\partial x_3} \end{bmatrix} = \begin{bmatrix} x_2 x_3 \\ x_1 x_3 \\ x_1 x_2 \end{bmatrix}$$

$y \in \mathcal{R}^n$ wektor, x skalar, wówczas $\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x} & \frac{\partial y_2}{\partial x} & \dots & \frac{\partial y_n}{\partial x} \end{bmatrix}$

Przykład $y = \begin{bmatrix} x & x^2 & x^3 \end{bmatrix}$, policzyć

$$\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x} & \frac{\partial y_2}{\partial x} & \frac{\partial y_3}{\partial x} \end{bmatrix} = \begin{bmatrix} \frac{\partial(x)}{\partial x} & \frac{\partial(x^2)}{\partial x} & \frac{\partial(x^3)}{\partial x} \end{bmatrix} = \begin{bmatrix} 1 & 2x & 3x^2 \end{bmatrix}$$

Pochodne wektorów względem wektorów

$x \in \mathcal{R}^n, y \in \mathcal{R}^m$ to wektory

$$\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_2}{\partial x_1} & \dots & \frac{\partial y_n}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} & \dots & \frac{\partial y_n}{\partial x_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial y_1}{\partial x_n} & \frac{\partial y_2}{\partial x_n} & \dots & \frac{\partial y_n}{\partial x_n} \end{bmatrix}$$

Przykład $y = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} x_1^2 - x_2 \\ x_3^2 + 3x_2 \end{bmatrix}$, $x = \begin{bmatrix} x_1 \\ x_2 \\ x_3 \end{bmatrix}$, policzyć

$$\frac{\partial y}{\partial x} = \begin{bmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_2}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} \\ \frac{\partial y_1}{\partial x_3} & \frac{\partial y_2}{\partial x_3} \end{bmatrix} = \begin{bmatrix} \frac{\partial(x_1^2 - x_2)}{\partial x_1} & \frac{\partial(x_3^2 + 3x_2)}{\partial x_1} \\ \frac{\partial(x_1^2 - x_2)}{\partial x_2} & \frac{\partial(x_3^2 + 3x_2)}{\partial x_2} \\ \frac{\partial(x_1^2 - x_2)}{\partial x_3} & \frac{\partial(x_3^2 + 3x_2)}{\partial x_3} \end{bmatrix} = \begin{bmatrix} 2x_1 & 0 \\ -1 & 3 \\ 0 & 2x_3 \end{bmatrix}$$

$x, y \in \mathcal{R}^n$ to wektory tego samego rozmiaru, wówczas możemy policzyć Jakobian odwzorowania y

$$Jac(y) = \det\left(\frac{\partial y}{\partial x}\right) = \begin{vmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_2}{\partial x_1} & \dots & \frac{\partial y_n}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} & \dots & \frac{\partial y_n}{\partial x_2} \\ \vdots & \vdots & \ddots & \vdots \\ \frac{\partial y_1}{\partial x_n} & \frac{\partial y_2}{\partial x_n} & \dots & \frac{\partial y_n}{\partial x_n} \end{vmatrix}$$

Przykład $y = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} x_1^2 - x_2 \\ x_1^2 + 3x_2 \end{bmatrix}$, $x = \begin{bmatrix} x_1 \\ x_2 \end{bmatrix}$, policzyć

$$Jac(y) = \det\left(\frac{\partial y}{\partial x}\right) =$$

$$\begin{vmatrix} \frac{\partial y_1}{\partial x_1} & \frac{\partial y_2}{\partial x_1} \\ \frac{\partial y_1}{\partial x_2} & \frac{\partial y_2}{\partial x_2} \end{vmatrix} = \begin{vmatrix} \frac{\partial(x_1^2 - x_2)}{\partial x_1} & \frac{\partial(x_1^2 + 3x_2)}{\partial x_1} \\ \frac{\partial(x_1^2 - x_2)}{\partial x_2} & \frac{\partial(x_1^2 + 3x_2)}{\partial x_2} \end{vmatrix} = \begin{vmatrix} 2x_1 & 1 \\ -1 & 3 \end{vmatrix} = 6x_1 + 1$$

$$1) y = x^T A x$$

wówczas

$$\frac{\partial y}{\partial x} = A x + A^T x$$

Jeśli A jest symetryczna, czyli $A = A^T$, wówczas

$$\frac{\partial y}{\partial x} = A x + A^T x = 2A x$$

Ponadto

$$\frac{\partial}{\partial x} \frac{\partial y}{\partial x} = 2A^T$$

Jeśli A jest symetryczna, czyli $A = A^T$, wówczas

$$\frac{\partial}{\partial x} \frac{\partial y}{\partial x} = 2A$$

2) $y = Ax$ wówczas $\frac{\partial y}{\partial x} = A^T$

Jeśli A jest symetryczna, czyli $A = A^T$, wówczas $\frac{\partial y}{\partial x} = A$

3) $y = x^T A$ wówczas $\frac{\partial y}{\partial x} = A$

4) $y = x^T x$ wówczas $\frac{\partial y}{\partial x} = 2x$

5) $x \in \mathcal{R}^n$ wektor, $y \in \mathcal{R}^r$ wektor, $z \in \mathcal{R}^m$ wektor, oraz $z = y(x)$
wówczas $\frac{\partial z}{\partial x} = \frac{\partial y}{\partial x} \frac{\partial x}{\partial y}$