

# ALS1 – Přednáška 6

## Rozklad na singulární hodnoty (SVD; Singular values decomposition)

### 1 Rozklad

Tato část rozebírá vlastnosti SVD; především to, že SVD rozklad existuje pro každou matici (věta 1). Budeme potřebovat následující tvrzení:

**Proposition 1.** Pro matici  $Q_1 \in \mathbb{R}^{m \times k}$  s ortonormálními sloupci existuje matice  $Q_2 \in \mathbb{R}^{m \times (m-k)}$  tak že  $Q = (Q_1 \ Q_2)$  je ortogonální matice.

Tvrzení 1 říká, že ortonormální báze podprostoru prostoru  $\mathbb{R}^m$  může být rozšířena na ortonormální bázi celého prostoru. Toto tvrzení je známý výsledek z lineární algebry.

**Doplnění 1** 2-norma matice:

$$\|A\|_2 = \max_x \frac{\|Ax\|_2}{\|x\|_2}$$
$$\|A\|_2 = \sqrt{\max_{1 \leq i \leq n} \lambda_i(A^T A)} =: \sigma_{\max}(A)$$

**Theorem 1.** Jakákoli  $m \times n$  matice  $A$  s  $m \geq n$  může být rozložena na

$$A = U \begin{pmatrix} \Sigma \\ 0 \end{pmatrix} V^T, \quad (1)$$

kde  $U \in \mathbb{R}^{m \times m}$  a  $V \in \mathbb{R}^{n \times n}$  jsou ortogonální a  $\Sigma \in \mathbb{R}^{n \times n}$  je diagonální

$$\Sigma = \text{diag}(\sigma_1, \sigma_2, \dots, \sigma_n),$$

$$\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0.$$

*Důkaz.* Předpoklad  $m \geq n$  není nijak omezující: v opačném případě lze větu aplikovat na  $A^T$ .

Uvažujme maximalizační problém

$$\sup_{\|x\|_2=1} \|Ax\|_2$$

Protože hledáme supremum spojitě funkce nad uzavřenou množinou, je tohoto suprema dosaženo pro nějaký vektor  $x$ . Položme  $Ax = \sigma_1 y$ , kde  $\|y\|_2 = 1$  a  $\sigma_1 = \|A\|_2$  (podle definice).

Podle Tvrzení 1 můžeme zkonstruovat ortogonální matice

$$Z_1 = (y \bar{Z}_2) \in \mathbb{R}^{m \times m}, \quad W_1 = (x \bar{W}_2) \in \mathbb{R}^{m \times m}.$$

Pak

$$Z_1^T A W_1 = \begin{pmatrix} \sigma_1 & y^T A \bar{W}_2 \\ 0 & \bar{Z}_2^T A \bar{W}_2 \end{pmatrix},$$

protože  $y^T Ax = \sigma_1$  a  $Z_2^T Ax = \sigma_1 \bar{Z}_2^T y = 0$ .

Položme

$$A_1 = Z_1^T A W_1 = \begin{pmatrix} \sigma_1 & w^T \\ 0 & B \end{pmatrix}.$$

Pak

$$\frac{1}{\sigma_1^2 + w^T w} \|A_1(\sigma_1 w)\|_2^2 = \frac{1}{\sigma_1^2 + w^T w} \left\| \begin{pmatrix} \sigma_1^2 + w^T w \\ Bw \end{pmatrix} \right\|_2^2 \geq \sigma_1^2 + w^T w.$$

Ale  $\|A_1\|_2^2 = \|Z_1^T A W_1\|_2^2 = \sigma_1^2$ . Takže musí platit  $w = 0$ . A tedy jsme provedli jeden krok v diagonalizaci  $A$ . Důkaz je pak dokončen indukcí:

Předpokládejme, že

$$B = Z_2 \begin{pmatrix} \Sigma_2 & \\ & 0 \end{pmatrix} W_2 \quad \Sigma_2 = \text{diag}(\sigma_2, \dots, \sigma_n).$$

Pak máme

$$A = Z_1 \begin{pmatrix} \sigma_1 & 0 \\ 0 & B \end{pmatrix} W_1^T = Z_1 \begin{pmatrix} 1 & 0 \\ 0 & Z_2 \end{pmatrix} \begin{pmatrix} \sigma_1 & 0 \\ 0 & \Sigma_2 \end{pmatrix} \begin{pmatrix} 1 & 0 \\ 0 & W_2^T \end{pmatrix} W_1^T.$$

Definujeme  $U, \Sigma, V$  jako

$$U = Z_1 \begin{pmatrix} 1 & 0 \\ 0 & Z_2 \end{pmatrix}, \quad \Sigma = \begin{pmatrix} \sigma_1 & 0 \\ 0 & \Sigma_2 \end{pmatrix}, \quad V = W_1 \begin{pmatrix} 1 & 0 \\ 0 & W_2^T \end{pmatrix}$$

Věta je tímto dokázána.

Sloupce  $U$  a  $V$  se nazývají **singulární vektory**, diagonální prvky  $\sigma_i$  matice  $\Sigma$  se nazývají **singulární hodnoty**.

### 1.1 SVD symbolicky

$$\begin{array}{c} \boxed{\begin{array}{c} n \\ m \end{array} A} = \boxed{\begin{array}{c} m \\ m \end{array} U} \circ \boxed{\begin{array}{c} n \\ m \end{array} \begin{array}{c} \Sigma \\ 0 \end{array}} \circ \boxed{\begin{array}{c} n \\ n \end{array} V^T}$$

Matici  $U$  můžeme vertikálně rozseknout na  $m \times n$  matici  $U_1$  a  $m \times (m - n)$  matici  $U_2$ .

$$U = \begin{array}{c} \boxed{\begin{array}{c} n \\ m \end{array} U_1} \quad \boxed{\begin{array}{c} m - n \\ m \end{array} U_2} \end{array}$$

Při násobení  $U\Sigma$  se hodnoty z  $U_2$  násobí pouze nulami. Můžeme tedy psát:

$$\boxed{\begin{array}{c} n \\ m \end{array} A} = \boxed{\begin{array}{c} n \\ m \end{array} U_1} \circ \boxed{\begin{array}{c} n \\ n \end{array} \begin{array}{c} \Sigma \\ 0 \end{array}} \circ \boxed{\begin{array}{c} n \\ n \end{array} V^T}$$

## 2 Fundamentální podprostory dané SVD rozkladem

SVD dává ortogonální báze pro čtyři fundamentáln podprostory matice.

*Obor hodnot* matice  $A$  je lineární podprostor

$$\mathcal{R}(A) = \{y \mid y = Ax \text{ pro lib. } x\}$$

Uvažujme, že  $A$  má hodnost  $r$ :

$$\sigma_1 \geq \dots \geq \sigma_r > \sigma_{r+1} = \dots = \sigma_n = 0.$$

Pak máme

$$y = Ax = \sum_{i=1}^r \sigma_i u_i v_i^T x = \sum_{i=1}^r (\sigma_i v_i^T x) u_i = \sum_{i=1}^r \alpha_i u_i.$$

Nulový prostor matice  $A$  je lineární podprostor

$$\mathcal{N}(A) = \{x \mid Ax = 0\}.$$

Protože  $Ax = \sum_{i=1}^r \sigma_i u_i v_i^T x$ , dostáváme, že pro libovolný vektor  $z = \sum_{i=r+1}^n \beta_i v_i$  je v tom nulovém prostoru

$$Az = \left( \sum_{i=1}^r \sigma_i u_i v_i^T \right) \left( \sum_{i=r+1}^n \beta_i v_i \right) = 0.$$

Totéž můžeme ukázat pro  $A^T$ .


### Theorem 2.

1. Singulární vektory  $u_1, u_2, \dots, u_r$  jsou ortogonální báze v  $\mathcal{R}(A)$  a  $h(A) = \dim(\mathcal{R}(A)) = r$ .
2. Singulární vektory  $v_{r+1}, v_{r+2}, \dots, v_n$  jsou ortogonální báze v  $\mathcal{N}(A)$  a  $\dim(\mathcal{N}(A)) = n - r$ .
3. Singulární vektory  $v_1, v_2, \dots, v_r$  jsou ortogonální báze v  $\mathcal{R}(A^T)$ .
4. Singulární vektory  $u_{r+1}, u_{r+2}, \dots, u_m$  jsou ortogonální báze v  $\mathcal{N}(A^T)$ .

## 3 Aplikace SVD

### 3.1 Aproximace matic

Uvažujme, že matice  $A$  matice s nízkou hodnotí a přidaným šumem:  $A = A_0 + N$ , kde šum je malý v porovnání s  $A_0$ . Singulární hodnoty matice  $A$  se pak typicky chovají jako ty na obrázku 1.



**Obrázek 1.** Singulární hodnoty matice hodnosti 10 s přidaným šumem.

Pokud je šum dostatečně malý, můžeme uvažovat pouze velké vlastní hodnoty, rekonstruovat matici  $A$  pouze pomocí nich (a odpovídajících singulárních vektorů) a aproximovat tak matici  $A$  maticí s nižší hodnotí. Předpokládejme, že počet velkých vlastních hodnot je  $k$ . Pak aproximujeme

$$A = \sum_{i=1}^n \sigma_i u_i v_i^T = A_k.$$

Tomuto se říká ořezaná SVD (*truncated SVD*). Ořezaná SVD je řešením aproximačního problému, kde se chce aproximovat danou matici maticí nižší hodnotí.

**Theorem 3.** Předpokládejme, že matice  $A \in \mathbb{R}^{m \times n}$  má hodnot  $r > k$ . Problém aproximace matice

$$\min_{h(Z)=k} \|A - Z\|_2$$

má řešení

$$Z = A_k = U_k \Sigma_k V_k^T,$$

kde  $U_k = (u_1, \dots, u_k)$ ,  $V_k = (v_1, \dots, v_k)$ , and  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k)$ . To minimum je

$$\|A - A_k\|_2 = \sigma_{k+1}.$$

Dá se ukázat, že totéž platí i pro Frobeniovu normu

$$\|A\|_F = \sqrt{\sum_{i,j} a_{ij}^2}.$$

**Theorem 4.** Předpokládejme, že matice  $A \in \mathbb{R}^{m \times n}$  má hodnotu  $r > k$ . Problém aproximace matice

$$\min_{h(Z)=k} \|A - Z\|_F$$

má řešení

$$Z = A_k = U_k \Sigma_k V_k^T,$$

kde  $U_k = (u_1, \dots, u_k)$ ,  $V_k = (v_1, \dots, v_k)$ , and  $\Sigma_k = \text{diag}(\sigma_1, \dots, \sigma_k)$ . To minimum je

$$\|A - A_k\|_F = \left( \sum_{i=k+1}^p \sigma_i^2 \right)^{\frac{1}{2}},$$

kde  $p = \min(m, n)$ .

### 3.2 Analýza hlavních komponent (principal component analysis (PCA))

Aproximační vlastnosti SVD mohou být použity k vysvětlení ekvivalence SVD a PCA. Uvažujme že  $X \in \mathbb{R}^{m \times n}$  je datová matice, kde každý sloupec je pozorování reálně-hodnotového náhodného vektoru s nulovým průměrem. Nechť SVD matice  $X$  je  $X = U \Sigma V^T$ . Právě singulární vektory  $v_i$  se nazývají směry hlavních komponent v  $X$ . Vektor

$$z_1 = X v_1 = \sigma_1 u_1$$

má největší varianci ve vzorku mezi všemi normalizovanými lineárními kombinacemi sloupců z  $X$ :

$$\text{Var}(z_1) = \text{Var}(X v_1) = \frac{\sigma_1^2}{m}.$$

Nalezení vektoru s maximální variancí je ekvivalentní maximalizaci tzv. Rayleighova kvocientu:

$$\sigma_1^2 = \max_{v \neq 0} \frac{v^T X^T X v}{v^T v}, \quad \text{argmax}_{v \neq 0} \frac{v^T X^T X v}{v^T v}.$$

Normalizovaná proměnná  $u_1 = (1/\sigma_1) X v_1$  se nazývá normalizovaná hlavní komponenta v  $X$ .

Pokud máme nalezený vektor největší variance ve vzorku, obvykle chceme pokračovat a najít vektor druhé největší variance ve vzorku, který je kolmý k tomu prvnímu. Toto je provedeno výpočtem vektoru redukované matice  $X - \sigma_1 u_1 v_1^T$ . Pokračováním tohoto procesu můžeme najít všechny hlavní komponenty, tedy vypočítáme singulární vektory.

### 3.3 Řešení problému nejmenších čtverců

Problém nejmenších čtverců může být vyřešen použitím SVD. Uvažujme, že máme systém  $Ax \approx b$ , kde matice  $A \in \mathbb{R}^{m \times n}$  má hodnotu  $h(A) = n$  a SVD je

$$A = (U_1 U_2) \begin{pmatrix} \Sigma \\ 0 \end{pmatrix} V^T,$$

kde  $U_1 \in \mathbb{R}^{m \times n}$ . Použitím SVD a faktu, že norma je invariantní k ortogonálním transformacím, dostáváme

$$\|r\|^2 = \|b - Ax\|^2 = \|b - U \begin{pmatrix} \Sigma \\ 0 \end{pmatrix} V^T x\|^2 = \left\| \begin{pmatrix} b_1 \\ b_2 \end{pmatrix} - \begin{pmatrix} \Sigma \\ 0 \end{pmatrix} y \right\|^2,$$

kde  $b_i = U_i^T b$  a  $y = V^T x$ . Tedy

$$\|r\|^2 = \|b_1 - \Sigma y\|^2 + \|b_2\|^2.$$

Nyní můžeme snadno minimalizovat  $\|r\|^2$  položením  $y = \Sigma^{-1}b_1$ . Řešení nejmenších čtverců je dánp

$$x = Vy = V\Sigma^{-1}b_1 = V\Sigma^{-1}U_1^T b.$$

Protože  $\Sigma$  je diagonální a diagonální hodnoty jsou nenulové (jelikož  $A$  má hodnost  $n$ ), můžeme jednoduše najít  $\Sigma^{-1}$ :

$$\Sigma^{-1} = \text{diag} \left( \frac{1}{\sigma_1}, \frac{1}{\sigma_2}, \dots, \frac{1}{\sigma_n} \right).$$

Takže minimální řešení může být zapsáno jako

$$x = \sum_{i=1}^n \frac{u_i^T b}{\sigma_i} v_i.$$

**Theorem 5.** *Mějme matici  $A \in \mathbb{R}^{m \times n}$  s hodností  $n$ , a úzkou SVD  $A = U_1 \Sigma V^T$ . Pak problém nejmenších čtverců  $\min_x \|Ax - b\|_2$  má řešení*

$$x = V\Sigma^{-1}U_1^T b = \sum_{i=1}^n \frac{u_i^T b}{\sigma_i} v_i.$$