

# Optimalizace

## 9. Singulární rozklad (SVD)

---

Tomáš Kroupa   Tomáš Werner

2022 LS

Fakulta elektrotechnická  
ČVUT v Praze

# K čemu slouží SVD

Singulární rozklad libovolné reálné matice  $\mathbf{A}$  je tvaru

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T,$$

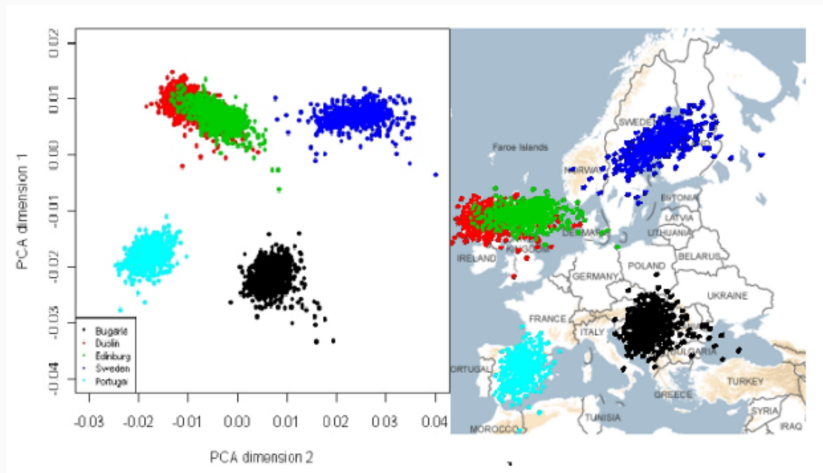
kde  $\mathbf{S}$  je diagonální a  $\mathbf{U}, \mathbf{V}$  jsou ortogonální matice.

## Aplikace

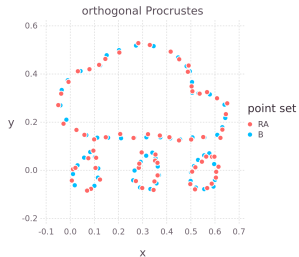



- PCA, nejbližší matice nižší hodnosti
- Rozpoznávání obličejů (eigenfaces)
- Latentní sémantická analýza
- Collaborative filtering
- Ortogonální Prokrustův problém

# PCA

Databáze genomu ( $m \approx 200\,000$  proměnných) pro  $n = 1\,400$  Evropanů byla promítnuta na  $k = 2$  hlavní komponenty:



# Hledáme optimální rotaci/zrcadlení



# SVD teoreticky

---

# Singulární rozklad matice

## Věta (Existence SVD)

Nechť  $\mathbf{A} \in \mathbb{R}^{m \times n}$  a  $p := \min\{m, n\}$ . Platí

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T,$$

kde diagonální matice  $\mathbf{S} \in \mathbb{R}^{m \times n}$  má na diagonále **singulární čísla**  $s_1, \dots, s_p \geq 0$  a ortogonální matice

$$\mathbf{U} = [\mathbf{u}_1 \cdots \mathbf{u}_m] \in \mathbb{R}^{m \times m}, \quad \mathbf{V} = [\mathbf{v}_1 \cdots \mathbf{v}_n] \in \mathbb{R}^{n \times n}$$

mají ve sloupcích **levé/pravé singulární vektory**.

Singulární čísla řadíme *sestupně*:  $s_1 \geq \dots \geq s_p$

## Spektrální rozklad

$$\mathbf{A} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T,$$

kde  $\mathbf{\Lambda}$  má na diagonále vlastní čísla seřazena sestupně v absolutní hodnotě,  $|\lambda_1| \geq \dots \geq |\lambda_n|$ .

- Když je  $\mathbf{A}$  pozitivně semidefinitní, pak  $\mathbf{A} = \mathbf{V}\mathbf{\Lambda}\mathbf{V}^T$  je SVD a singulární čísla jsou vlastní čísla
- Pokud není, pak dostaneme SVD  $\mathbf{A} = \mathbf{V}'\mathbf{S}\mathbf{V}^T$  tak, že položíme  $\mathbf{S} = |\mathbf{\Lambda}|$  a  $\mathbf{V}'$  vznikne z  $\mathbf{V}$  násobením  $-1$  sloupců odpovídajících záporným vlastním číslům

## Jak souvisí singulární čísla s vlastními čísly?

### Spektrální rozklad matic $\mathbf{AA}^T$ a $\mathbf{A}^T\mathbf{A}$ pomocí SVD

$$\mathbf{AA}^T = \mathbf{USV}^T\mathbf{VS}^T\mathbf{U}^T = \mathbf{USS}^T\mathbf{U}^T$$

$$\mathbf{A}^T\mathbf{A} = \mathbf{VS}^T\mathbf{U}^T\mathbf{USV}^T = \mathbf{VS}^T\mathbf{SV}^T$$

- Matice  $\mathbf{AA}^T$  a  $\mathbf{A}^T\mathbf{A}$  mají stejná nenulová vlastní čísla
- Nenulová singulární čísla  $s_i$  matice  $\mathbf{A}$  jsou odmocniny nenulových vlastních čísel  $\lambda_i$  matice  $\mathbf{AA}^T$ , neboť  $\lambda_i = s_i^2$
- Levé singulární vektory  $\mathbf{u}_i$  jsou vlastní vektory matice  $\mathbf{AA}^T$
- Právě singulární vektory  $\mathbf{v}_i$  jsou vlastní vektory matice  $\mathbf{A}^T\mathbf{A}$



# Jak počítat SVD?

## Případ $m \gg n$

V této situaci je matice  $\mathbf{A}^T \mathbf{A} \in \mathbb{R}^{n \times n}$  malá a singulární vektory lze spočítat z jejího spektrálního rozkladu:

1. Platí  $s_i = \sqrt{\lambda_i}$ , kde  $\lambda_i > 0$  jsou vlastní čísla matice  $\mathbf{A}^T \mathbf{A}$
2. Pravé singulární vektory  $\mathbf{v}_i$  jsou vlastní vektory matice  $\mathbf{A}^T \mathbf{A}$
3. Levé singulární vektory dopočteme jako  $\mathbf{u}_i = \frac{\mathbf{A} \mathbf{v}_i}{s_i}$

Existují speciální *SVD algoritmy*, které se vyhýbají explicitnímu výpočtu matic  $\mathbf{A} \mathbf{A}^T$  a  $\mathbf{A}^T \mathbf{A}$ .

# Různé verze SVD

$$\mathbf{A} = \mathbf{USV}^T = s_1 \mathbf{u}_1 \mathbf{v}_1^T + \cdots + s_p \mathbf{u}_p \mathbf{v}_p^T$$

## Plné SVD

$$\mathbf{U} \in \mathbb{R}^{m \times m}, \mathbf{S} \in \mathbb{R}^{m \times n}, \mathbf{V} \in \mathbb{R}^{n \times n}$$

## Redukované SVD

$$\mathbf{U} \in \mathbb{R}^{m \times p}, \mathbf{S} \in \mathbb{R}^{p \times p}, \mathbf{V} \in \mathbb{R}^{n \times p}$$


## Rank-minimální SVD

$$\mathbf{U} \in \mathbb{R}^{m \times r}, \mathbf{S} \in \mathbb{R}^{r \times r}, \mathbf{V} \in \mathbb{R}^{n \times r}, \text{ kde } r := \text{rank } \mathbf{S} \leq p$$

Tedy  $r$  je počet nenulových singulárních čísel a  $r = \text{rank } \mathbf{A}$ .

# Lineární transformace s regulární maticí A jednotkové kružnice

$$\mathbf{A} = \mathbf{USV}^T = \begin{bmatrix} \mathbf{u}_1 & \mathbf{u}_2 \end{bmatrix} \begin{bmatrix} s_1 & 0 \\ 0 & s_2 \end{bmatrix} \begin{bmatrix} \mathbf{v}_1^T \\ \mathbf{v}_2^T \end{bmatrix} = s_1 \mathbf{u}_1 \mathbf{v}_1^T + s_2 \mathbf{u}_2 \mathbf{v}_2^T$$




Obrazem jednotkové kružnice je natočená elipsa s délkami os  $s_1, s_2$ .

## Singulární čísla některých matic

- Ortogonální matice má všechna singulární čísla rovna 1
- **Hilbertova matice**  $\mathbf{A} = \left[ \frac{1}{i+j-1} \right]_{ij}$  řádu  $n$  je regulární a např. pro  $n = 100$  platí

$$s_1 = 2.1827, \dots, s_{100} \approx 10^{-17}$$

- Černobílý obrázek psa je matice  $3456 \times 4608$  s plnou řádkovou hodnotí, její singulární čísla jsou v grafu s  $\log_{10}$  stupnicí



# SVD v optimalizaci

---

## Nejbližší matice nižší hodnosti z redukovaného SVD

$$\mathbf{A} \in \mathbb{R}^{m \times n}, \quad \mathbf{A} = \mathbf{USV}^T, \quad s_1 \geq \dots \geq s_p, \quad p = \min\{m, n\}$$

### Věta (Eckart-Young)

Nechť  $k \leq p$ . Řešením úlohy

$$\min \{ \|\mathbf{A} - \mathbf{B}\|^2 \mid \mathbf{B} \in \mathbb{R}^{m \times n}, \text{rank } \mathbf{B} \leq k \}$$

je matice

$$\mathbf{B}^* = \mathbf{US}_k \mathbf{V}^T = s_1 \mathbf{u}_1 \mathbf{v}_1^T + \dots + s_k \mathbf{u}_k \mathbf{v}_k^T,$$

kde  $\mathbf{S}_k$  vznikne z  $\mathbf{S}$  vynulováním singulárních čísel  $s_{k+1}, \dots, s_p$ .

## Tvrzení

Pro každou matici  $\mathbf{A} \in \mathbb{R}^{m \times n}$  hodnosti  $r$  platí

$$\|\mathbf{A}\| = \sqrt{s_1^2 + \cdots + s_r^2}.$$

*Relativní chybu* aproximace maticí  $\mathbf{B}^*$  hodnosti nejvýše  $k$  lze zjistit ze singulárních čísel matice  $\mathbf{A}$ :

- Pro  $k = 1, \dots, r - 1$  dostaneme

$$\frac{\|\mathbf{A} - \mathbf{B}^*\|}{\|\mathbf{A}\|} = \sqrt{\frac{s_{k+1}^2 + \cdots + s_r^2}{s_1^2 + \cdots + s_r^2}}$$

- Pro  $r \leq k \leq p$  triviálně platí  $\mathbf{B}^* = \mathbf{A}$  a chyba je 0

# Komprese obrázku psa pomocí SVD



$k = 5$ , chyba 17%,  $5 \times (3456 + 4608)$



$k = 20$ , chyba 9%,  $20 \times (3456 + 4608)$



$k = 200$ , chyba 4%,  $200 \times (3456 + 4608)$



Originál  $3456 \times 4608$



## PCA pomocí Eckart-Youngovy věty

Matice  $\mathbf{A} = [\mathbf{a}_1 \cdots \mathbf{a}_n] \in \mathbb{R}^{m \times n}$  má ve sloupcích datové vektory  $\mathbf{a}_i$  a jejich těžiště je  $\bar{\mathbf{a}} = \mathbf{0}$ . Promítáme je na podprostor dimenze  $k$ .

### Řešení

1. Spočítáme redukované SVD  $\mathbf{A} = \mathbf{USV}^T$  a seřadíme sestupně singulární čísla,  $s_1 \geq \cdots \geq s_p$
2. Označíme  $\mathbf{U} = \underbrace{[\mathbf{u}_1 \cdots \mathbf{u}_k]}_{\mathbf{U}_k} \mathbf{u}_{k+1} \cdots \mathbf{u}_m$
3. Sloupce matice  $\mathbf{U}_k$  jsou ortonormální bází hledaného podprostoru dimenze  $k$ , neboť jsou to vl. vektory matice  $\mathbf{AA}^T$
4. Souřadnice promítnutých bodů jsou  $\mathbf{U}_k \mathbf{A}$
5. Optimální hodnota úlohy (absolutní chyba) je  $s_{k+1}^2 + \cdots + s_p^2$

## Výběrová kovarianční matice

Matice  $\mathbf{A} = [\mathbf{a}_1 \cdots \mathbf{a}_n] \in \mathbb{R}^{m \times n}$  má datové vektory  $\mathbf{a}_i$  ve sloupcích a předpokládáme, že výběrové průměry veličin jsou nulové,  $\bar{\mathbf{a}} = \mathbf{0}$ .

### Definice

**Výběrová kovarianční matice** je matice  $\frac{1}{n}\mathbf{A}\mathbf{A}^T$ . Na diagonále má *výběrové rozptyly* a jinde *výběrové kovariance*.

Stejnou interpretaci má matice  $\frac{1}{n}\mathbf{A}^T\mathbf{A}$ , pokud jsou normalizované datové vektory uspořádány do řádků matice  $\mathbf{A} \in \mathbb{R}^{n \times m}$ .

## Příklad (1)

$n = 3$  recenzenti hodnotí  $m = 4$  filmy body  $0, \dots, 5$ .

Po normalizaci průměry dostaneme  $\mathbf{A}$  a kovarianční matici:

$$\mathbf{A} = \begin{bmatrix} 5 & 4 & 1 \\ 5 & 5 & 0 \\ 0 & 0 & 5 \\ 1 & 0 & 4 \end{bmatrix} = \begin{bmatrix} 1.67 & 0.67 & -2.33 \\ 1.67 & 1.67 & -3.33 \\ -1.67 & -1.67 & 3.33 \\ -0.67 & -1.67 & 2.33 \end{bmatrix}$$
$$\frac{1}{3}\mathbf{A}\mathbf{A}^T = \begin{bmatrix} 2.89 & 3.89 & -3.89 & -2.56 \\ 3.89 & 5.56 & -5.56 & -3.89 \\ -3.89 & -5.56 & 5.56 & 3.89 \\ -2.56 & -3.89 & 3.89 & 2.89 \end{bmatrix}$$

Hodnoty kovariancí naznačují, že existují  $k = 2$  typy filmů.


## Příklad (2)

- Pomocí SVD matice  $\mathbf{A} = \mathbf{USV}^T$  dostaneme levé singulární vektory  $\mathbf{U} = [\mathbf{u}_1 \ \mathbf{u}_2 \ \mathbf{u}_3 \ \mathbf{u}_4]$ , jsou seřazeny podle singulárních čísel  $s_1 = 7.05$ ,  $s_2 = 1$ ,  $s_3 = s_4 = 0$
- PCA pro  $k = 2$ : klademe  $\mathbf{U}_2 := [\mathbf{u}_1 \ \mathbf{u}_2]$  a matice souřadnic datových vektorů promítnutých do  $\mathbb{R}^2$  je

$$\mathbf{U}_2^T \mathbf{A} = \begin{bmatrix} -2.88 & -2.88 & 5.74 \\ -0.71 & 0.71 & 0 \end{bmatrix}$$

- Chyba aproximace je  $s_3 + s_4 = 0$  a proto jsou data pouze *dvourozměrná*

# Ortogonalní Prokrustův problém



- Matice  $\mathbf{A} = [\mathbf{a}_1 \cdots \mathbf{a}_n] \in \mathbb{R}^{m \times n}$  a  $\mathbf{B} = [\mathbf{b}_1 \cdots \mathbf{b}_n] \in \mathbb{R}^{m \times n}$
- Hledáme ortogonální matici  $\mathbf{X} \in \mathbb{R}^{m \times m}$  minimalizující

$$\sum_{i=1}^k \|\mathbf{X}\mathbf{a}_i - \mathbf{b}_i\|^2 = \|\mathbf{X}\mathbf{A} - \mathbf{B}\|^2$$

## Optimální řešení

$\mathbf{X}^* = \mathbf{U}\mathbf{V}^T$ , kde  $\mathbf{B}\mathbf{A}^T = \mathbf{U}\mathbf{S}\mathbf{V}^T$  je redukované SVD