

Optimalizace

Singulární rozklad (SVD)

Tomáš Kroupa Tomáš Werner

2024


Fakulta elektrotechnická
ČVUT v Praze

K čemu slouží SVD





- Řešení PCA
- Matice nižší hodnosti (low rank approximation)
- Rozpoznávání obličejů (eigenfaces)
- Ortogonální Prokrustův problém
- Latentní sémantická analýza
- Nástroj pro numerické výpočty

PCA

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



Point Cloud Alignment



SVD teoreticky

Singulární rozklad matice

Věta (Existence SVD)

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

$$\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T = s_1\mathbf{u}_1\mathbf{v}_1^T + \cdots + s_p\mathbf{u}_p\mathbf{v}_p^T,$$

kde $p = \min\{m, n\}$, diagonální matice $\mathbf{S} \in \mathbb{R}^{p \times p}$ má na diagonále singulární čísla $s_1 \geq \cdots \geq s_p \geq 0$ a matice

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

mají ortonormální sloupce zvané levé/pravé singulární vektory.

Různé verze SVD

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

Redukované SVD

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

Plné SVD

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

Rank-minimální SVD

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

Protože $r = \text{rank } \mathbf{S}$, číslo r je počet nenulových singulárních čísel.

Příklad: SVD úzké matice

$m = 3, n = 2$

Redukované i rank-minimální SVD

$p = r = 2$


$$\begin{bmatrix} 1 & 1 \\ 2 & 0 \\ 0 & -2 \end{bmatrix} = \begin{bmatrix} \frac{\sqrt{3}}{3} & 0 \\ \frac{\sqrt{3}}{3} & \frac{\sqrt{2}}{2} \\ -\frac{\sqrt{3}}{3} & \frac{\sqrt{2}}{2} \end{bmatrix} \begin{bmatrix} \sqrt{6} & 0 \\ 0 & 2 \end{bmatrix} \begin{bmatrix} \frac{\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \end{bmatrix}$$

Plné SVD

$$\begin{bmatrix} 1 & 1 \\ 2 & 0 \\ 0 & -2 \end{bmatrix} = \begin{bmatrix} \frac{\sqrt{3}}{3} & 0 & -\frac{\sqrt{6}}{3} \\ \frac{\sqrt{3}}{3} & \frac{\sqrt{2}}{2} & \frac{\sqrt{6}}{6} \\ -\frac{\sqrt{3}}{3} & \frac{\sqrt{2}}{2} & -\frac{\sqrt{6}}{6} \end{bmatrix} \begin{bmatrix} \sqrt{6} & 0 \\ 0 & 2 \\ 0 & 0 \end{bmatrix} \begin{bmatrix} \frac{\sqrt{2}}{2} & \frac{\sqrt{2}}{2} \\ \frac{\sqrt{2}}{2} & -\frac{\sqrt{2}}{2} \end{bmatrix}$$

SVD geometricky

Efekt SVD matice $\mathbf{A} \in \mathbb{R}^{2 \times 2}$ na vektor \mathbf{x} si lze představit takto:



Obrázek: *Solomon - Numerical Algorithms*

Speciálně: $\mathbf{A}\mathbf{v}_i = s_i \mathbf{u}_i$

Jak souvisí singulární čísla s vlastními čísly?

Vlastní čísla matic $\mathbf{A}\mathbf{A}^T$ a $\mathbf{A}^T\mathbf{A}$

Z rank-minimálního SVD matice $\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T$ dostaneme

$$\mathbf{A}\mathbf{A}^T = \mathbf{U}\mathbf{S}^2\mathbf{U}^T \quad \text{a} \quad \mathbf{A}^T\mathbf{A} = \mathbf{V}\mathbf{S}^2\mathbf{V}^T.$$

To jsou spektrální rozklady se stejnou diagonální maticí \mathbf{S}^2 .

- Matice $\mathbf{A}\mathbf{A}^T$ a $\mathbf{A}^T\mathbf{A}$ mají stejná kladná vlastní čísla

$$\lambda_1 = s_1^2, \dots, \lambda_r = s_r^2$$


- Levé singulární vektory \mathbf{u}_i jsou vlastní vektory matice $\mathbf{A}\mathbf{A}^T$
- Pravé singulární vektory \mathbf{v}_i jsou vlastní vektory matice $\mathbf{A}^T\mathbf{A}$

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 bíglu je matice 3456×4608 s plnou řádkovou hodností, singulární čísla jsou v grafu s \log_{10} stupnicí



Vlastnosti SVD

- SVD existuje pro *libovolnou* matici $\mathbf{A} \in \mathbb{R}^{m \times n}$
- Pro jeho výpočet se používají specializované metody, převod na spektrální rozklad není výpočetní vhodný
- Počet nenulových singulárních čísel matice $\mathbf{A} = \text{rank } \mathbf{A}$, ale spíše se pro malé $\varepsilon > 0$ uvažuje **numerický rank**

$$\max \{i \mid s_i > \varepsilon\}$$

- V numerických výpočtech je důležitou charakteristikou stability **číslo podmíněnosti** matice \mathbf{A} , což je poměr


$$\frac{s_1}{s_r}$$

Aplikace SVD

Nejbližší matice nižší hodnosti pomocí řešení PCA

Low rank approximation pro matici $\mathbf{A} \in \mathbb{R}^{m \times n}$

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



Minimum je $\mathbf{B}^* = \mathbf{XX}^T \mathbf{A}$, kde $\mathbf{X} = [\mathbf{v}_1 \cdots \mathbf{v}_k]$ je matice vlastních vektorů odpovídajících k největším vlastním číslům matice \mathbf{AA}^T .

Nejbližší matice nižší hodnosti pomocí SVD

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

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

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

kde $\mathbf{S}_k = \text{diag}(s_1, \dots, s_k, \mathbf{0}) \in \mathbb{R}^{p \times p}$.

Měříme kvalitu approximace

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 approximace matice \mathbf{A} maticí \mathbf{B}^* hodnosti nejvýše k určíme 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 bíglu 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 3456×4608

PCA pomocí SVD

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

Řešení

1. Spočti redukované SVD $\mathbf{A} = \mathbf{U}\mathbf{S}\mathbf{V}^T$, kde $s_1 \geq \dots \geq s_p$
2. Označ $\mathbf{X} = [\mathbf{u}_1 \dots \mathbf{u}_k] \in \mathbb{R}^{m \times k}$
3. Levé singulární vektory \mathbf{u}_i (vlastní vektory matice $\mathbf{A}\mathbf{A}^T$) tvoří ortonormální bázi hledaného podprostoru dimenze k
4. Souřadnice promítnutých bodů jsou sloupce matice $\mathbf{X}^T\mathbf{A}$
5. Optimální hodnota úlohy (absolutní chyba) je $s_{k+1}^2 + \dots + s_p^2$

Příklad (1)

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

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

$$\begin{bmatrix} 5 & 4 & 1 \\ 5 & 5 & 0 \\ 0 & 0 & 5 \\ 1 & 0 & 4 \end{bmatrix}, \quad \mathbf{A} = \begin{bmatrix} 1.67 & 0.67 & -2.33 \\ 1.67 & 1.67 & -3.33 \\ -1.67 & -1.67 & 3.33 \\ -0.67 & -1.67 & 2.33 \end{bmatrix}$$

$$\frac{1}{3} \mathbf{A} \mathbf{A}^T = \begin{bmatrix} 2.89 & 3.89 & -3.89 & -2.56 \\ 3.89 & 5.56 & -5.56 & -3.89 \\ -3.89 & -5.56 & 5.56 & 3.89 \\ -2.56 & -3.89 & 3.89 & 2.89 \end{bmatrix}$$

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

Příklad (2)

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

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

- Chyba aproximace je $s_3 = 0$


Eigenfaces (1)

- Datové vektory $\mathbf{a}_1, \dots, \mathbf{a}_n$ jsou fotky obličejů (m pixelů)
- Předpoklad: Matice $\mathbf{A} = [\mathbf{a}_1 \dots \mathbf{a}_n] \in \mathbb{R}^{m \times n}$ splňuje $\mathbf{A}\mathbf{1} = \mathbf{0}$
- Matice levých singulárních vektorů $\mathbf{X} = [\mathbf{u}_1 \cdots \mathbf{u}_k] \in \mathbb{R}^{m \times k}$ obsahuje k charakteristických obličejů
- Novou fotku $\mathbf{c} \in \mathbb{R}^m$ reprezentujeme v nových souřadnicích $\mathbf{X}^T \mathbf{c} \in \mathbb{R}^k$ a nalezneme nejbližší sloupec v $\mathbf{X}^T \mathbf{A} \in \mathbb{R}^{k \times n}$


Eigenfaces (2)



(a) Input faces




(b) Eigenfaces



(c) Projection

Ortogonalní Prokrustův problém (Point Cloud Alignment)



<https://simonensemble.github.io/posts/2018-10-27-orthogonal-procrustes/>

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

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

Optimální řešení

$\mathbf{X}^* = \mathbf{U}\mathbf{V}^T$, kde $\mathbf{BA}^T = \mathbf{USV}^T$ je redukované SVD