

4.6 Singularni razcep

Za $A \in \mathbb{R}^{m \times n}$, $m \geq n$, obstaja *singularni razcep*

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

kjer sta $U \in \mathbb{R}^{m \times m}$ in $V \in \mathbb{R}^{n \times n}$ ortogonalni matriki in $\Sigma \in \mathbb{R}^{m \times n}$ oblike

$$\Sigma = \begin{bmatrix} \sigma_1 & & & \\ & \ddots & & \\ & & \sigma_n & \\ & & & \end{bmatrix},$$

kjer so $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_n \geq 0$ singularne vrednosti A .

A predstavlja preslikavo iz \mathbb{R}^n v \mathbb{R}^m . Geometrijski pomen SV razcepa je, da se z ortogonalnima transformacijama baz U v \mathbb{R}^m in V v \mathbb{R}^n A spremeni v diagonalno matriko:

$$Av_i = \sigma u_i, \quad i = 1, \dots, n.$$

V primeru $n < m$ dobimo SV razcep tako, da transponiramo SV razcep za A^T .

Lastnosti singularnega razcepa

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

Lastne vrednosti $A^T A$ so $\sigma_1^2, \dots, \sigma_n^2$. Ortonormirani lastni vektorji $A^T A$ so desni singularni vektorji v_1, \dots, v_n .

Lastne vrednosti AA^T so $\sigma_1^2, \dots, \sigma_n^2, \underbrace{0, \dots, 0}_{m-n}$. Ortonormirani lastni vektorji AA^T so levi singularni vektorji u_1, \dots, u_m .

Naj bo $\sigma_r > 0$ in $\sigma_{r+1} = \dots = \sigma_n = 0$. Če razdelimo

- $V = [V_1 \ V_2]$, kjer je $V_1 := [v_1 \ \dots \ v_r]$ in $V_2 := [v_{r+1} \ \dots \ v_n]$,
- $U = [U_1 \ U_2]$, kjer je $U_1 := [u_1 \ \dots \ u_r]$ in $U_2 := [u_{r+1} \ \dots \ u_m]$,

potem velja:

- r se ujema z $\text{rang}(A)$,
- stolpci U_1 tvorijo bazo za $\text{im}A$,
- stolpci V_2 tvorijo bazo za $\text{ker} A$,
- stolpci U_2 tvorijo bazo za $\text{ker} A^T$,
- stolpci V_1 tvorijo bazo za $\text{im}A^T$.

Singularni razcep in predoločeni sistem

Lema 1. Če je $A \in \mathbb{R}^{m \times n}$, $m \geq n$, $\text{rang}(A) = n$, potem je minimum $\|Ax - b\|_2$ dosežen pri

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

Dokaz. Naj bo $A = U\Sigma V^T$ in

$$U = \begin{pmatrix} n & m-n \\ U_1 & U_2 \end{pmatrix}, \quad \Sigma = \begin{matrix} n & \\ m-n & \begin{pmatrix} S \\ 0 \end{pmatrix} \end{matrix}.$$

$$\|Ax - b\|_2 = \|U\Sigma V^T x - b\|_2 = \|\Sigma V^T x - U^T b\|_2 = \left\| \begin{bmatrix} SV^T x - U_1^T b \\ U_2^T b \end{bmatrix} \right\|_2.$$

Minimum je dosežen pri $SV^T x = U_1^T b$ oziroma

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

Najboljša aproksimacija z matriko nižjega ranga

Če je $A = U\Sigma V^T$ SV razcep A in je $\text{rang}(A) = r$, potem direktno iz razcepa sledi

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

Izrek 1. Naj bo $A = U\Sigma V^T$ SV razcep A in $\text{rang}(A) > k$. Naj bo $A_k = \sum_{i=1}^k \sigma_i u_i v_i^T$ oziroma $A_k = U\Sigma_k V^T$, kjer je

$$\Sigma_k = \begin{bmatrix} \sigma_1 & & & & & & & \\ & \ddots & & & & & & \\ & & \sigma_k & & & & & \\ & & & 0 & & & & \\ & & & & \ddots & & & \\ & & & & & & 0 & \end{bmatrix}.$$

Potem velja

$$\min_{\text{rang}(B)=k} \|B - A\|_2 = \|A_k - A\|_2 = \sigma_{k+1}.$$

To pomeni, da je A_k najboljša aproksimacija matrike A z matriko ranga k , σ_{k+1} pa nam pove, kako daleč je A od prostora matrik ranga k .

Zgled: uporaba SV razcepa za kompresijo podatkov

Zgled 1. *SV razcep lahko uporabimo za kompresijo slik. Sliko lahko predstavimo z matriko A , katere elementi predstavljajo nivo sivine. Namesto A vzamemo najboljšo aproksimacijo z matriko ranga k . Pri tem namesto mn podatkov potrebujemo le $(m + n)k$ podatkov za $[u_1 \cdots u_k]$ in $[\sigma_1 v_1 \cdots \sigma_k v_k]$.*

Moore-Penroseov psevdoinverz

Psevdoinverz je posplošitev inverza za matrice, ki bodisi niso kvadratne ali niso obrnljive.

Definicija 1. Psevdoinverz matrice $A \in \mathbb{R}^{m \times n}$ je matrika $X \in \mathbb{R}^{n \times m}$, ki izpolnjuje Moore-Penroseove pogoje:

- 1) $AXA = A$,
- 2) $XAX = X$,
- 3) $(AX)^T = AX$,
- 4) $(XA)^T = XA$.

(Moore-Penroseov) psevdoinverz matrice označimo z A^+ .

Če je matrika kvadratna in obrnljiva, je

$$A^+ = A^{-1}.$$

Za matriko $A \in \mathbb{R}^{m \times n}$, $m \geq n$, $\text{rang}(A) = n$, dobimo

$$A^+ = (A^T A)^{-1} A^T.$$

Povezava singularnega razcepa in psevdoinverza

Izrek 2. Naj bo $A \in \mathbb{R}^{m \times n}$, $m \geq n$, $\text{rang}(A) = r$ in $A = U\Sigma V^T$, kjer je

$$U = \begin{pmatrix} r & m-r \\ U_1 & U_2 \end{pmatrix}, \quad V = \begin{pmatrix} r & n-r \\ V_1 & V_2 \end{pmatrix}, \quad \Sigma = \begin{matrix} r & n-r \\ m-r \end{matrix} \begin{pmatrix} S & 0 \\ 0 & 0 \end{pmatrix}$$

in $S = \text{diag}(\sigma_1, \dots, \sigma_r)$. Potem je $A^+ = V\Sigma^+U^T$, kjer je

$$\Sigma^+ = \begin{matrix} r & m-r \\ n-r \end{matrix} \begin{pmatrix} S^{-1} & 0 \\ 0 & 0 \end{pmatrix}.$$

Dokaz. Matriko A^+ lahko zapišemo kot $A = VBU^T$, kjer je

$$B = \begin{matrix} r & m-r \\ n-r \end{matrix} \begin{pmatrix} B_{11} & B_{12} \\ B_{21} & B_{22} \end{pmatrix}.$$

Iz Moore-Penroseovih pogojev sledi $B_{12} = 0$, $B_{21} = 0$, $B_{22} = 0$ in $B_{11} = S^{-1}$. ■

4.7 Problemi defektnega ranga in nedoločeni problemi

Rešitev predoločenega sistema polnega ranga $Ax = b$ lahko zapišemo kot $x = A^+b$.

Če A ni polnega ranga, pravimo, da ima *defekten rang*. V primeru defektnega ranga rešitev, ki minimizira $\|Ax - b\|_2$ ni enolična, saj lahko x prištejemo poljuben $z \in \ker A$. V takšnem primeru pravimo, da je izmed vseh x , ki minimizirajo $\|Ax - b\|_2$, rešitev tisti, ki ima minimalno normo.

Trditev 1. Če je $A \in \mathbb{R}^{m \times n}$, $m \geq n$, $\text{rang}(A) = r < n$ in $A = U\Sigma V^T$ singularni razcep, potem ima izmed vseh vektorjev x , ki minimizirajo normo $\|Ax - b\|_2$, najmanjšo normo $x = A^+b$ oziroma

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

in

$$\|Ax - b\|_2^2 = \sum_{i=r+1}^m (u_i^T b)^2.$$

Težave z majhnimi singularnimi vrednostmi

Naj bo $A \in \mathbb{R}^{m \times n}$, $A = U\Sigma V^T$ singularni razcep in $\sigma_n > 0$.

1. Če je x rešitev predoločenega sistema $Ax = b$ po m.n.k., potem je

$$\|x\|_2 \geq \frac{|u_n^T b|}{\sigma_n}.$$

2. Če b zmotimo v $b + \delta b$, se x spremeni v $x + \delta x$, kjer je $\|\delta x\|_2 \leq \frac{\|\delta b\|_2}{\sigma_n}$.

V primeru, ko je $\text{rang}(A) = r < n$ za rešitev $Ax = b$ po m.n.k. velja

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

torej je $\|x\|_2 \leq \frac{\|b\|_2}{\sigma_r}$ in sprememba b v $b + \delta b$ spremeni rešitev največ za $\frac{\|\delta b\|_2}{\sigma_r}$.

Regularizacija

Rešujemo linearni sistem $Ax = b$, kjer je A nesingularna, a zelo občutljiva matrika velikosti $n \times n$. Predpostavimo še, da v resnici rešujemo sistem z zmoteno desno stranjo \tilde{b} , kjer so poleg b prisotne še majhne motnje, npr. zaradi meritev ali zaokrožitvenih napak. Rešitev zmotenega sistema \tilde{x} lahko s pomočjo singularnega razcepa $A = U\Sigma V^T$ izrazimo kot

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

kjer \tilde{x} razvijemo po singularnih vektorjih v_1, \dots, v_n .

Če ima matrika A najmanjše singularne vrednosti zelo blizu 0, potem vemo, da lahko zelo majhna motnja desne strani povsem pokvari rezultat, kar pomeni, da se lahko \tilde{x} močno razlikuje od x . Tovrstne težave rešujemo z *regularizacijo*. Splošni nastavek je, da za regularizirano rešitev x_{reg} vzamemo

$$x_{\text{reg}} = \sum_{i=1}^n \phi_i \frac{u_i^T \tilde{b}}{\sigma_i} v_i,$$

kjer so ϕ_i , $i = 1, \dots, n$, tako imenovani *faktorji filtra*.

Odrezani singularni razcep

Pri *TSVD* (truncated SVD) izberemo k in vzamemo

$$\phi_i = \begin{cases} 1 & : & 1 \leq k \leq i \\ 0 & : & k + 1 \leq i \leq n \end{cases}$$

To pomeni, da matriko A nadomestimo z matriko A_k , ki je najboljša aproksimacija matrike A z matriko ranga k , potem pa vzamemo

$$x_{\text{reg}} = A_k^+ b.$$

Ker smo zanemarili majhne singularne vrednosti, je to obratno stabilno in dobljena rešitev je točna rešitev bližnjega problema.

Primer v Matlabu

Regularizacija Tihonova

Izberemo regularizacijski parameter $\alpha > 0$ in za $i = 1, \dots, n$ definiramo faktorje

$$\phi_i = \frac{\sigma_i^2}{\sigma_i^2 + \alpha^2}.$$

Lema 2. Regularizacija Tihonova¹ s parametrom α vrne vektor x , ki reši naslednji problem:

$$\min_x \left\{ \|b - Ax\|_2^2 + \alpha^2 \|x\|^2 \right\}.$$

Vrednost parametra α moramo primerno izbrati:

- Če pošljemo α proti 0, potem bo x kar rešitev sistema $Ax = b$, a ker je v b tudi šum, lahko pričakujemo, da bo norma dobljenega vektorja zelo velika.
- Če vzamemo velik α , potem je bolj bistveno to, da ima x majhno normo, kot to, da reši sistem $Ax = b$.
- Pri primerni izbiri α norma izračunanega vektorja x ne bo prevelika in hkrati tudi velikost ostanka $b - Ax$ ne bo prevelika.

¹Ruski matematik Andrej Nikolajevič Tihonov (1906–1993) je postopek opisal leta 1943.